翼 MapReduce 服务（MRS）

组件操作指南

天翼云科技有限公司

目 录

1 使用 CarbonData

1.1 概述

1.1.1 CarbonData 简介

CarbonData 是一种新型的 Apache Hadoop 本地文件格式，使用先进的列式存储、索引、压缩和编码技术，以提高计算效率，有助于加速超过 PB 数量级的数据查询，可用于更快的交互查询。同时，CarbonData 也是一种将数据源与 Spark 集成的高性能分析引擎。

图1-1 CarbonData 基本架构

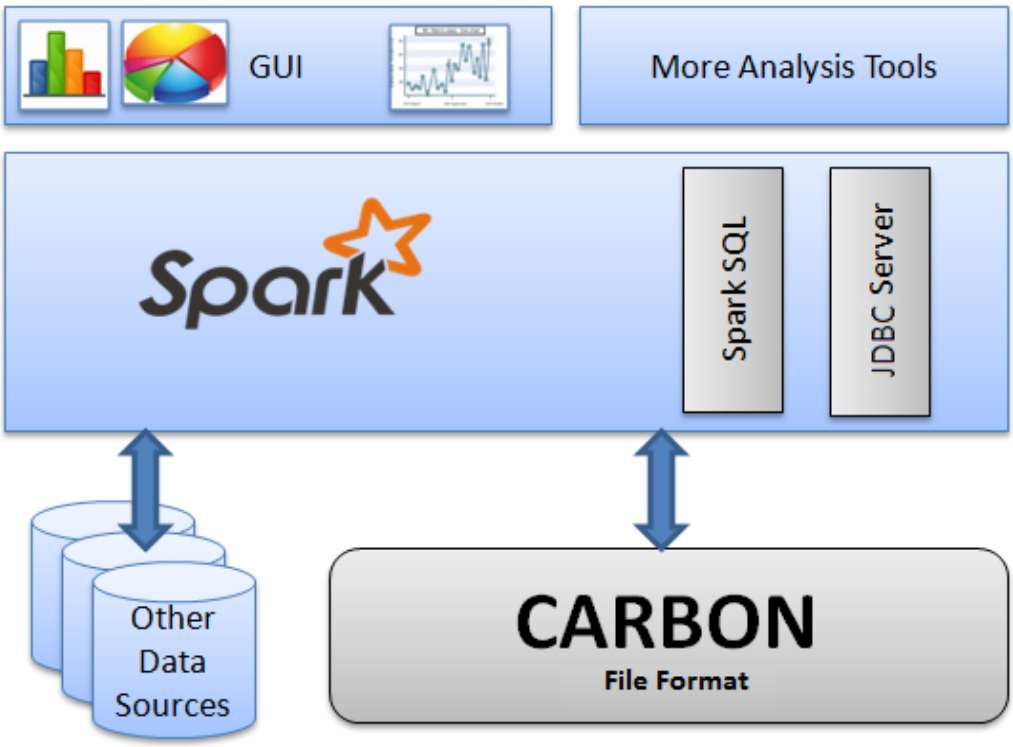

使用 CarbonData 的目的是对大数据即席查询提供超快速响应。从根本上说，CarbonData 是一个 OLAP 引擎，采用类似于 RDBMS 中的表来存储数据。用户可将大量（10TB 以上）的数据导入以 CarbonData 格式创建的表中，CarbonData 将以压缩的多维索引列格式自动组织和存储数据。数据被加载到 CarbonData 后，就可以执行即席查询，CarbonData 将对数据查询提供秒级响应。

CarbonData 将数据源集成到 Spark 生态系统，用户可使用 Spark SQL 执行数据查询和分析。也可以使用 Spark 提供的第三方工具 JDBCServer 连接到 Spark SQL。

CarbonData 结构

CarbonData 作为 Spark 内部数据源运行，不需要额外启动集群节点中的其他进程，CarbonData Engine 在 Spark Executor 进程之中运行。

图1-2 CarbonData 结构

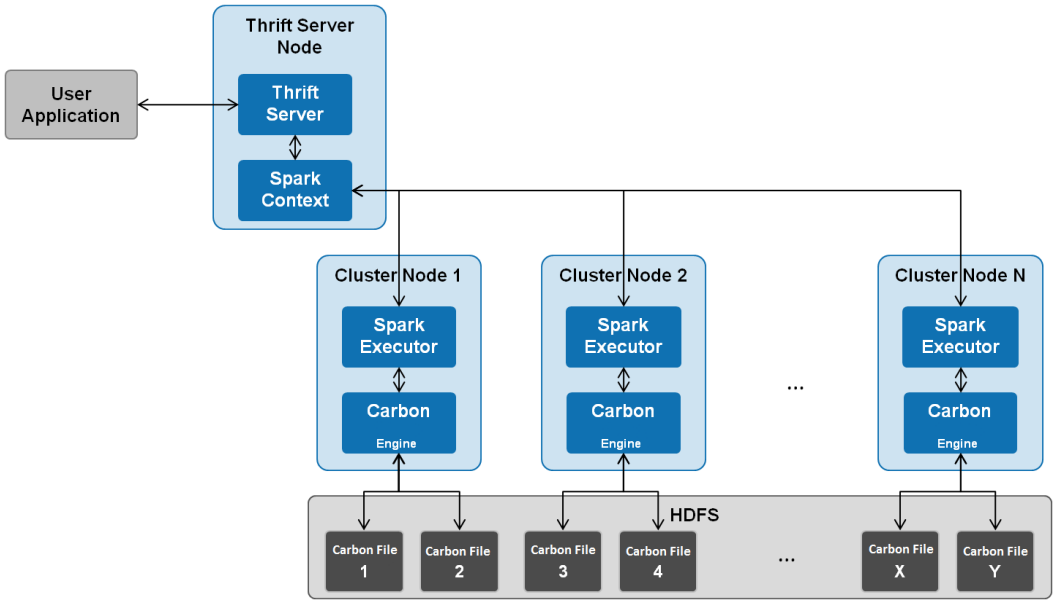

存储在 CarbonData Table 中的数据被分成若干个 CarbonData 数据文件，每一次数据查询时，CarbonData Engine 模块负责执行数据集的读取、过滤等实际任务。CarbonData Engine 作为 Spark Executor 进程的一部分运行，负责处理数据文件块的一个子集。

Table 数据集数据存储在 HDFS 中。同一 Spark 集群内的节点可以作为 HDFS 的数据节点。

CarbonData 特性

- SQL 功能：CarbonData 与 Spark SQL 完全兼容，支持所有可以直接在 Spark SQL 上运行的 SQL 查询操作。
- 简单的 Table 数据集定义：CarbonData 支持易于使用的 DDL(数据定义语言)语句来定义和创建数据集。CarbonData DDL 十分灵活、易于使用，并且足够强大，可以定义复杂类型的 Table。

- 便捷的数据管理：CarbonData 为数据加载和维护提供多种数据管理功能。CarbonData 支持加载历史数据以及增量加载新数据。加载的数据可以基于加载时间进行删除，也可以撤销特定的数据加载操作。
- CarbonData 文件格式是 HDFS 中的列式存储格式。该格式具有许多新型列存储文件的特性，例如，分割表和数据压缩。CarbonData 具有以下独有的特点：
  - 伴随索引的数据存储：由于在查询中设置了过滤器，可以显著加快查询性能，减少 I/O 扫描次数和 CPU 资源占用。CarbonData 索引由多个级别的索引组成，处理框架可以利用这个索引来减少需要安排和处理的任务，也可以通过在任务扫描中以更精细的单元（称为 blocklet）进行 skip 扫描来代替对整个文件的扫描。
  - 可选择的数据编码：通过支持高效的数据压缩，可基于压缩/编码数据进行查询，在将结果返回给用户之前，才将编码转化为实际数据，这被称为“延迟物化”。
  - 支持一种数据格式应用于多种用例场景：例如，交互式 OLAP-style 查询，顺序访问（big scan），随机访问（narrow scan）。

CarbonData 关键技术和优势

- 快速查询响应：高性能查询是 CarbonData 关键技术的优势之一。CarbonData 查询速度大约是 Spark SQL 查询的 10 倍。CarbonData 使用的专用数据格式围绕高性能查询进行设计，其中包括多种索引技术和多次的 Push down 优化，从而对 TB 级数据查询进行最快响应。
- 高效率数据压缩：CarbonData 使用轻量级压缩和重量级压缩的组合压缩算法压缩数据，可以减少 60%~80%数据存储空间，很大程度上节省硬件存储成本。

1.1.2 CarbonData 主要规格

CarbonData 主要规格

表1-1 CarbonData 主要规格

实体	测试值	测试环境
表数	10000	3 个节点，每个 executor 4 个 CPU 核，20GB。Driver 内存 5GB，3 个 Executor。 总列数：107 String：75 Int：13 BigInt：7 Timestamp：6 Double：6
表的列数	2000	3 个节点，每个 executor4 个 CPU 核，20GB。Driver 内存 5GB，3 个 Executor。
原始 CSV 文件大小的最大	200GB	17 个 cluster 节点，每个 executor 150GB，25 个 CPU 核。Driver 内存 10 GB，17 个

实体	测试值	测试环境
值		Executor。
每个文件夹的 CSV 文件数	100 个文件夹，每个文件夹 10 个文件，每个文件大小 50MB。	3 个节点，每个 executor4 个 CPU 核，20GB。Driver 内存 5GB，3 个 Executor。
加载文件夹数	10000	3 个节点，每个 executor4 个 CPU 核，20GB。Driver 内存 5GB，3 个 Executor。

数据加载所需的内存取决于以下因素：

- 列数
- 列值大小
- 并发（使用“carbon.number.of.cores.while.loading”进行配置）
- 在内存中排序的大小（使用“carbon.sort.size”进行配置）
- 中间缓存（使用“carbon.graph.rowset.size”进行配置）

加载包含 1000 万条记录和 300 列的 8 GB CSV 文件的数据，每行大小约为 0.8KB 的 8GB CSV 文件的数据，需要约为 10GB 的 executor 执行内存，也就是说，“carbon.sort.size” 配置为“100000”，所有其他前面的配置保留默认值。

二级索引表规格

表1-2 二级索引表规格

实体	测试值
二级索引表数量	10
二级索引表中的组合列的列数	5
二级索引表中的列名长度（单位：字符）	120
二级索引表名长度（单位：字符）	120
表中所有二级索引表的表名+列名的累积长度*（单位：字符）	3800**

说明

- * Hive 允许的上限值或可用资源的上限值。

- ** 二级索引表使用 hive 注册，并以 json 格式的值存储在 HiveSERDEPROPERTIES 中。由 hive 支持的 SERDEPROPERTIES 的最大字符数为 4000 个字符，无法更改。

1.2 CarbonData 常用参数

本章节介绍 CarbonData 所有常用参数配置的详细信息。

carbon.properties 相关参数

根据用户实际使用场景在服务端或者客户端配置 CarbonData 相关参数。

- 服务端：登录 FusionInsight Manager 页面，选择“集群 > 服务 > Spark > 配置 > 全部配置 > JDBCServer（角色） > 自定义”，在参数“spark.carbon.customized.configs”中添加 CarbonData 相关参数配置。
- 客户端：登录客户端节点，在“*{客户端安装目录}*/Spark/spark/conf/carbon.properties”文件中配置相关参数。

表1-3 carbon.properties 中的系统配置

参数	默认值	描述
carbon.ddl.base.hdfs.url	hdfs://hacluster/opt/data	此属性用于从 HDFS 基本路径配置 HDFS 相对路径，在“fs.defaultFS”中进行配置。在“carbon.ddl.base.hdfs.url”中配置的路径将被追加到在“fs.defaultFS”中配置的 HDFS 路径中。如果配置了这个路径，则用户不需要通过完整路径加载数据。 例如：如果 CSV 文件的绝对路径是“hdfs://10.18.101.155:54310/data/cnbc/2016/xyz.csv”，其中，路径“hdfs://10.18.101.155:54310”来源于属性“fs.defaultFS”并且用户可以把“/data/cnbc/”作为“carbon.ddl.base.hdfs.url”配置。 当前，在数据加载时，用户可以指定 CSV 文件为“/2016/xyz.csv”。
carbon.badRecords.location	-	指定 Bad records 的存储路径。此路径为 HDFS 路径。默认值为 Null。如果启用了 bad records 日志记录或者 bad records 操作重定向，则该路径必须由用户进行配置。
carbon.bad.records.action	fail	以下是 bad records 的四种行为类型： FORCE：通过将 bad records 存储为 NULL 来自动更正数据。 REDIRECT：Bad records 被写入

参数	默认值	描述
		carbon.badRecords.location 配置路径下的 CSV 文件而不是被加载。 IGNORE：Bad records 既不被加载也不被写入 CSV 文件。 FAIL：如果找到任何 bad records，则数据加载失败。
carbon.update.sync.folder	/tmp/carbondata	modifiedTime.mdt 文件路径，可以设置为已有路径或新路径。 **说明** 如果设置为已有路径，需确保所有用户都可以访问该路径，且该路径具有 777 权限。
carbon.enable.badrecord.action.redirect	false	是否在数据加载中开启 redirect 方式来处理 bad records。启用该配置后，源文件中的 bad records 会被记录在指定存储位置生成的 CSV 文件中。在 Windows 操作系统中打开此类 CSV 文件时，可能会发生 CSV 注入。
carbon.enable.partitiondata.trash	false	启动该配置后，ALTER DROP PARTITION 操作时会将删除的分区数据移动到 Carbon 回收站中。 **说明** MRS 3.2.0 及之后版本支持才支持该功能。
carbon.enable.show.mv.for.showtables	false	在设置为 true 时，会在执行 **show tables** 命令时过滤 materialized views。在表多的情况下，开启该参数会导致 **show tables** 命令执行时间很长，请谨慎开启。 **说明** MRS 3.2.0 及之后版本支持才支持该功能。
carbon.enable.droptable.remove.staleentry	true	在设置为 true 时，会在执行 **drop table** 命令时去 cache 中删除该表的废弃记录。在 database 数量较多时，开启该参数会导致 **drop table** 命令执行时间很长。 **说明** MRS 3.2.0 及之后版本支持才支持该功能。
carbon.enable.multi.version.table.status	false	是否开启 tablestatus 文件多版本管理，开启该参数后，每次 load/insert/IUD 都会产生一个 tablestatus 文件。 **说明** 如果同时使用 JDBCServer 和客户端对表进行数据加载，那在使用该特性时，需要保证同时开启或同时关闭。

参数	默认值	描述
carbon.tablestatus.multi.version.file.coun	3	仅在开启 tablestatus 文件多版本管理后生效，默认保留最近的 tablestatus 文件数，超出该参数限制的老的 tablestatus 文件会被删除。

表1-4 carbon.properties 中的性能配置

参数	默认值	描述
数据加载配置		
carbon.sort.file.write.buffer.size	16384	为了限制内存的使用，CarbonData 会将数据排序并写入临时文件中。该参数控制读取和写入临时文件过程使用的缓存大小。单位：字节。 取值范围为：10240~10485760。
carbon.graph.rowset.size	100000	数据加载图步骤之间交换的行集大小。 最小值=500，最大值=1000000
carbon.number.of.cores.while.loading	6	数据加载时所使用的核数。配置的核数越大压缩性能越好。如果 CPU 资源充足可以增加此值。
carbon.sort.size	500000	内存排序的数据大小。
carbon.enableXXHash	true	用于 hashkey 计算的 hashmap 算法。
carbon.number.of.cores.block.sort	7	数据加载时块排序所使用的核数。
carbon.max.driver.lru.cache.size	-1	在 driver 端加载数据所达到的最大 LRU 缓存大小。以 MB 为单位，默认值为-1，表示缓存没有内存限制。只允许使用大于 0 的整数值。
carbon.max.executor.lru.cache.size	-1	在 executor 端加载数据所达到的最大 LRU 缓存大小。以 MB 为单位，默认值为-1，表示缓存没有内存限制。只允许使用大于 0 的整数值。如果未配置该参数，则将考虑参数“carbon.max.driver.lru.cache.size”的值。
carbon.merge.sort.prefetch	true	在数据加载过程中，从排序的临时文件中读取数据进行合并排序时，启用数据预取。
carbon.update.persis	true	启用此参数将考虑持久化数据，减少

参数	默认值	描述
t.enable		UPDATE 操作的执行时间。
enable.unsafe.sort	true	指定在数据加载期间是否使用非安全排序。非安全的排序减少了数据加载操作期间的垃圾回收（GC），从而提高了性能。默认值为“true”，表示启用非安全排序功能。
enable.offheap.sort	true	在数据加载期间启用堆排序。
offheap.sort.chunk.size.inmb	64	指定需要用于排序的数据块的大小。最小值为 1MB，最大值为 1024MB。
carbon.unsafe.working.memory.in.mb	512	指定非安全工作内存的大小。这将用于排序数据，存储列页面等。单位是 MB。 数据加载所需内存： (“carbon.number.of.cores.while.loading”的值[默认值 = 6]) x 并行加载数据的表格 x (“offheap.sort.chunk.size.inmb”的值[默认值 = 64 MB] + “carbon.blockletgroup.size.in.mb”的值[默认值 = 64 MB] + 当前的压缩率[64 MB/3.5]) = ~900 MB 每表格 数据查询所需内存： (SPARK_EXECUTOR_INSTANCES. [默认值 = 2]) x (carbon.blockletgroup.size.in.mb [默认值 = 64 MB] + “carbon.blockletgroup.size.in.mb”解压内容[默认值 = 64 MB * 3.5]) x (每个执行器核数[默认值 = 1]) = ~ 600 MB
carbon.sort.inmemory.storage.size.in.mb	512	指定要存储在内存中的中间排序数据的大小。达到该指定的值，系统会将数据写入磁盘。单位是 MB。
sort.inmemory.size.inmb	1024	指定要保存在内存中的中间排序数据的大小。达到该指定值后，系统会将数据写入磁盘。单位：MB。 如果配置了“carbon.unsafe.working.memory.in.mb”和“carbon.sort.inmemory.storage.size.in.mb”，则不需要配置该参数。如果此时也配置了该参数，那么这个内存的 20%将用于工作内存“carbon.unsafe.working.memory.in.mb”，

参数	默认值	描述
		80%将用于排序存储内存“carbon.sort.inmemory.storage.size.in.mb”。 **说明** Spark 配置参数“spark.yarn.executor.memoryOverhead”的值应该大于 CarbonData 配置参数“sort.inmemory.size.inmb”的值，否则如果堆外（off heap）访问超出配置的 executor 内存，则 YARN 可能会停止 executor。
carbon.blockletgroup.size.in.mb	64	数据作为 blocklet group 被系统读入。该参数指定 blocklet group 的大小。较高的值会有更好的顺序 IO 访问性能。 最小值为 16MB，任何小于 16MB 的值都将重置为默认值（64MB）。 单位：MB。
enable.inmemory.merge.sort	false	指定是否启用内存合并排序（inmemorymerge sort）。
use.offheap.in.query.processing	true	指定是否在查询处理中启用 offheap。
carbon.load.sort.scope	local_sort	指定加载操作的排序范围。支持两种类型的排序，batch_sort 和 local_sort。选择 batch_sort 将提升加载性能，但会降低查询性能。 **说明** local_sort 与分区表的 DDL 操作存在冲突，不能同时使用，且对分区表性能提升不明显，不建议在分区表上启用该特性。
carbon.batch.sort.size.inmb	-	指定在数据加载期间为批处理排序而考虑的数据大小。推荐值为小于总排序数据的 45%。该值以 MB 为单位。 **说明** 如果没有设置参数值，那么默认情况下其大约等于“sort.inmemory.size.inmb”参数值的 45%。
enable.unsafe.columnpage	true	指定在数据加载或查询期间，是否将页面数据保留在堆内存中，以避免垃圾回收受阻。
carbon.use.local.dir	false	是否使用 YARN 本地目录加载多个磁盘的数据。设置为 true，则使用 YARN 本地目录加载多个磁盘的数据，以提高数据加载性能。

参数	默认值	描述
carbon.use.multiple.temp.dir	false	是否使用多个临时目录存储临时文件以提高数据加载性能。
carbon.load.datamaps.parallel.db_name.table_name	NA	值为 true 或者 false。可以设置数据库名和表名，使得该表的首次查询性能得到提升。
压缩配置		
carbon.number.of.cores.while.compacting	2	在压缩过程中用于写入数据所使用的核数。配置的核数越大压缩性能越好。如果 CPU 资源充足可以增加此值。
carbon.compaction.level.threshold	4,3	该属性用于 Minor 压缩，决定合并 segment 的数量。 例如：如果被设置为“2,3”，则将每 2 个 segment 触发一次 Minor 压缩。“3”是 Level 1 压缩的 segment 个数，这些 segment 将进一步被压缩为新的 segment。 有效值为 0-100。
carbon.major.compaction.size	1024	使用该参数配置 Major 压缩的大小。总数低于该阈值的 segment 将被合并。 单位为 MB。
carbon.horizontal.compaction.enable	true	该参数用于配置打开/关闭水平压缩。在每个 DELETE 和 UPDATE 语句之后，如果增量（DELETE / UPDATE）文件超过指定的阈值，则可能发生水平压缩。默认情况下，该参数值设置为“true”，打开水平压缩功能，可将参数值设置为“false”来关闭水平压缩功能。
carbon.horizontal.update.compaction.threshold	1	该参数指定 segment 内的 UPDATE 增量文件数的阈值限制。在增量文件数量超过阈值的情况下，segment 内的 UPDATE 增量文件变得适合水平压缩，并压缩为单个 UPDATE 增量文件。默认情况下，该参数值设置为 1。可以设置为 1 到 10000 之间的值。
carbon.horizontal.delete.compaction.threshold	1	该参数指定 segment 的 block 中的 DELETE 增量文件数量的阈值限制。在增量文件数量超过阈值的情况下，segment 特定 block 的 DELETE 增量文件变得适合水平压缩，并压缩为单个 DELETE 增量文件。 默认情况下，该参数值设置为 1。可以设置为 1 到 10000 之

参数	默认值	描述
		间的值。
查询配置		
carbon.number.of.cores	4	查询时所使用的核数。
carbon.limit.block.distribution.enable	false	当查询语句中包含关键字 limit 时，启用或禁用 CarbonData 块分布。默认值为“false”，将对包含关键字 limit 的查询语句禁用块分布。此参数调优请参考 1.4.3 性能调优的相关配置。
carbon.custom.block.distribution	false	指定是使用 Spark 还是 CarbonData 的块分配功能。默认情况下，其配置值为“false”，表明启用 Spark 块分配。若要使用 CarbonData 块分配，请将配置值更改为“true”。
carbon.infilter.subquery.pushdown.enable	false	如果启用此参数，并且用户在具有 subquery 的过滤器中触发 Select 查询，则执行子查询，并将输出作为 IN 过滤器广播到左表，否则将执行 SortMergeSemiJoin。建议在 IN 过滤器子查询未返回太多记录时启用此参数。例如，IN 子句子查询返回 10k 或更少的记录时，启用此参数将更快地给出查询结果。 示例：***select * from flow_carbon_256b where cus_no in (select cus_no from flow_carbon_256b where dt>='20260101' and dt<='20260701' and txn_bk='tk_1' and txn_br='tr_1') limit 1000;***
carbon.scheduler.minRegisteredResourcesRatio	0.8	启动块分布所需的最小资源（executor）比率。默认值为“0.8”，表示所请求资源的 80%被分配用于启动块分布。
carbon.dynamicAllocation.schedulerTimeout	5	此参数值指示调度器等待 executors 处于活动状态的最长时间。默认值为“5”秒，允许的最大值为“15”秒。
enable.unsafe.in.query.processing	true	指定在查询操作期间是否使用非安全排序。非安全排序减少查询操作期间的垃圾回收（GC），从而提高性能。默认值为“true”，表示启用非安全排序功能。
carbon.enable.vector.reader	true	为结果收集（result collection）启用向量处理，以增强查询性能。
carbon.query.show.d	true	**SHOW TABLES** 会展示所有的表包含主

参数	默认值	描述
atamaps		表和 datamap。如果需要过滤掉 datamap，将该配置设置为 false。
二级索引配置		
carbon.secondary.index.creation.threads	1	该参数用于配置启动二级索引创建期间并行处理 segments 的线程数。当表的 segments 数较多时，该参数有助于微调系统生成二级索引的速度。该参数值范围为 1 到 50。
carbon.si.lookup.partialstring	true	• 当配置为 true 时，它包括开始，结尾和包含。 • 当配置为 false 时，它只包括从二级索引开始。
carbon.si.segment.merge	true	开启这个配置后会合并二级索引表 segment 内的**.carbondata** 文件。合并发生在导入操作后，在二级索引表导入操作的最后，会检查小文件并合。 **说明** Table Block Size 会用作合并小文件的大小阈值。

表1-5 carbon.properties 中的其它配置

参数	默认值	描述
数据加载配置		
carbon.lock.type	HDFSLOCK	该配置指定了表上并发操作过程中所要求的锁的类型。 有以下几种类型锁实现方式： • LOCALLOCK：基于本地文件系统的文件来创建的锁。该锁只适用于一台机器上只运行一个 Spark Driver（或者 JDBCServer）的情况。 • HDFSLOCK：基于 HDFS 文件系统上的文件来创建的锁。该锁适用于集群上有多个运行的 Spark 应用而且没有可用的 ZooKeeper 的情况。
carbon.sort.intermediate.files.limit	20	中间文件的最小数量。生成中间文件后开始排序合并。此参数调优请参考 1.4.3 性能调优的相关配置。
carbon.csv.read.buff	1048576	CSV 读缓冲区大小。

参数	默认值	描述
ersize.byte		
carbon.merge.sort.reader.thread	3	用于读取中间文件进行最终合并的最大线程数。
carbon.concurrent.lock.retries	100	指定获取并发操作锁的最大重试次数。该参数用于并发加载。
carbon.concurrent.lock.retry.timeout.sec	1	指定获取并发操作的锁重试之间的间隔。
carbon.lock.retries	3	指定除导入操作外其他所有操作尝试获取锁的次数。
carbon.lock.retry.timeout.sec	5	指定除导入操作外其他所有操作尝试获取锁的时间间隔。
carbon.tempstore.location	/opt/Carbon/TempStoreLoc	临时存储位置。默认情况下，采用“System.getProperty("java.io.tmpdir")”方法获取。此参数调优请参考 1.4.3 性能调优的相关配置中关于“carbon.use.local.dir”的描述。
carbon.load.log.counter	500000	数据加载记录计数日志。
SERIALIZATION_NULL_FORMAT	\N	指定需要替换为 NULL 的值。
carbon.skip.empty.line	false	设置此属性将在数据加载期间忽略 CSV 文件中的空行。
carbon.load.datamaps.parallel	false	该配置项将会开启对所有会话所有表的 datamap 并行加载。该配置项通过将导入 datamap 到内存的工作分发给所有的 executor 来缩短时间，进而提升查询性能。
合并配置		
carbon.numberof.preserve.segments	0	若用户希望从被合并的 segment 中保留一定数量的 segment，可设置该属性参数。 例如：“carbon.numberof.preserve.segments”=“2”，那么合并的 segement 中将不包含最新的 2 个 segment。 默认保留 No segment 的状态。
carbon.allowed.compaction.days	0	合并将合并在配置的指定天数中加载的 segment。 例如：如果配置值为“2”，那么只有在

参数	默认值	描述
		2 天时间框架中加载的 segment 被合并。2 天以外被加载的 segment 不会被合并。 该参数默认为禁用。
carbon.enable.auto.load.merge	false	在数据加载时启用压缩。
carbon.merge.index.in.segment	true	如果设置，则 Segment 内的所有 Carbon 索引文件（.carbonindex）将合并为单个 Carbon 索引合并文件（.carbonindexmerge）。 这增强了首次查询性能
carbon.enable.compact.autoclean	false	在设置为 true 时，会在执行 compact 成功后调用 **clean files** 命令来清理废弃文件。 **说明** MRS 3.2.0 及之后版本支持才支持该功能。
查询配置		
max.query.execution.time	60	单次查询允许的最大时间。 单位为分钟。
carbon.enableMinMax	true	MinMax 用于提高查询性能。设置为 false 可禁用该功能。
carbon.lease.recovery.retry.count	5	需要为恢复文件租约所需的最大尝试次数。 最小值：1 最大值：50
carbon.lease.recovery.retry.interval	1000 (ms)	尝试在文件上进行租约恢复之后的间隔（Interval）或暂停（Pause）时间。 最小值：1000（ms） 最大值：10000（ms）

spark-defaults.conf 相关参数

- 登录客户端节点，在“*{客户端安装目录}*/Spark/spark/conf/spark-defaults.conf”文件中配置表 1-6 相关参数。

表1-6 spark-defaults.conf 中的 Spark 配置参考

参数	默认值	描述
spark.driver.memory	4G	指定用于 driver 端进程的内存，其中

参数	默认值	描述
		SparkContext 已初始化。 说明 在客户端模式下，不要使用 SparkConf 在应用程序中设置该参数，因为驱动程序 JVM 已经启动。要配置该参数，请在--driver-memory 命令行选项或默认属性文件中进行配置。
spark.executor.memory	4GB	指定每个执行程序进程使用的内存。
spark.sql.crossJoin.enabled	true	如果查询包含交叉连接，请启用此属性，以便不会抛出错误，此时使用交叉连接而不是连接，可实现更好的性能。

- 在 Spark Driver 端的“spark-defaults.conf”文件中配置以下参数。
  - 在 spark-sql 模式下配置：登录 Spark 客户端节点，在“*{客户端安装目录}*/Spark/spark/conf/spark-defaults.conf”文件中配置表 1-7 相关参数。

表1-7 spark-sql 模式下的配置参数

参数	配置值	描述
spark.driver.extraJavaOptions	-Dlog4j.configuration=file:/opt/client/Spark/spark/conf/log4j.properties -Djetty.version=x.y.z -Dzookeeper.server.principal=zookeeper/hadoop.<*系统域名*> -Djava.security.krb5.conf=/opt/client/KrbClient/kerberos/var/krb5kdc/krb5.conf -Djava.security.auth.login.config=/opt/client/Spark/spark/conf/jaas.conf -Dorg.xerial.snappy.tempdir=/opt/client/Spark/tmp -Dcarbon.properties.filepath=/opt/client/Spark/spark/conf/carbon.properties -Djava.io.tmpdir=/opt/client/Spark/tmp	默认值中“/opt/client/Spark/spark”为客户端的 CLIENT_HOME，且该默认值是追加到参数“spark.driver.extraJavaOptions”其他值之后的，此参数用于指定 Driver 端的“carbon.properties”文件路径。 说明 请注意“=”两边不要有空格。

参数	配置值	描述
spark.sql.session.state.builder	org.apache.spark.sql.hive.FIHiveACLSessionStateBuilder	指定会话状态构造器。
spark.carbon.sqlastbuilder.classname	org.apache.spark.sql.hive.CarbonInternalSqlAstBuilder	指定 AST 构造器。
spark.sql.catalog.class	org.apache.spark.sql.hive.HiveACLExternalCatalog	指定 Hive 的外部目录实现。启用 Spark ACL 时必须提供。
spark.sql.hive.implementation	org.apache.spark.sql.hive.HiveACLClientImpl	指定 Hive 客户端调用的实现。启用 Spark ACL 时必须提供。
spark.sql.hiveClient.isolation.enabled	false	启用 Spark ACL 时必须提供。

- 在 JDBCServer 服务中配置：登录 JDBCServer 安装节点，在“{BIGDATA_HOME}/FusionInsight_Spark_*/*_JDBCServer/etc/spark-defaults.conf”文件中配置表 1-8 相关参数。

表1-8 JDBCServer 服务中的配置参数

参数	配置值	描述
spark.driver.extraJavaOptions	-Xloggc:${SPARK_LOG_DIR}/indexserver-omm-%p-gc.log -XX:+PrintGCDetails -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:MaxDirectMemorySize=512M -XX:MaxMetaspaceSize=512M -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=20 -XX:GCLogFileSize=10M -XX:OnOutOfMemoryError='kill -9 %p'	默认值中${SPARK_CONF_DIR}需视具体的集群而定，且该默认值是追加到参数“spark.driver.extraJavaOptions”其他值之后的，此参数用于指定 Driver 端的“carbon.properties”文件路径。 **说明** 请注意“=”两边不要有空格。

参数	配置值	描述
	-Djetty.version=x.y.z -Dorg.xerial.snappy.tempdir=${BIGDATA_HOME}/tmp/spark/JDBCServer/snappy_tmp -Djava.io.tmpdir=${BIGDATA_HOME}/tmp/spark/JDBCServer/io_tmp -Dcarbon.properties.filepath=${SPARK_CONF_DIR}/carbon.properties -Djdk.tls.ephemeralDHKeySize=2048 -Dspark.ssl.keyStore=${SPARK_CONF_DIR}/child.keystore #{java_stack_prefer}	
spark.sql.session.state.builder	org.apache.spark.sql.hive.FIHiveACLSessionStateBuilder	指定会话状态构造器。
spark.carbon.sqlastbuilder.classname	org.apache.spark.sql.hive.CarbonInternalSqlAstBuilder	指定 AST 构造器。
spark.sql.catalog.class	org.apache.spark.sql.hive.HiveACLExternalCatalog	指定 Hive 的外部目录实现。启用 Spark ACL 时必须提供。
spark.sql.hive.implementation	org.apache.spark.sql.hive.HiveACLClientImpl	指定 Hive 客户端调用的实现。启用 Spark ACL 时必须提供。
spark.sql.hiveClient.isolation.enabled	false	启用 Spark ACL 时必须提供。

1.3 CarbonData 操作指导

1.3.1 CarbonData 快速入门

本章节介绍创建 CarbonData table、加载数据，以及查询数据的快速入门流程。该快速入门提供基于 Spark Beeline 客户端的操作。如果使用 Spark shell，需将查询命令写在 spark.sql()的括号中。

本操作以从 CSV 文件加载数据到 CarbonData Table 为例

表1-9 CarbonData 快速入门

操作	说明
准备 CSV 文件	准备加载到 CarbonData Table 的 CSV 文件。
连接到 CarbonData	在对 CarbonData 进行任何一种操作之前，首先需要连接到 CarbonData。
创建 CarbonData Table	连接到 CarbonData 之后，需要创建 CarbonData table 用于加载数据和执行查询操作。
加载数据到 CarbonData Table	创建 CarbonData table 之后，可以从 CSV 文件加载数据到所创建的 table 中。
在 CarbonData 中查询数据	创建 CarbonData table 并加载数据之后，可以执行所需的查询操作，例如 filters，groupby 等。

准备 CSV 文件

1. 在本地准备 CSV 文件，文件名为：test.csv，样例如下：

```
13418592122,1001,MAC 地址,2017-10-23 15:32:30,2017-10-24 15:32:30,62.50,74.56
13418592123,1002,MAC 地址,2017-10-23 16:32:30,2017-10-24 16:32:30,17.80,76.28
13418592124,1003,MAC 地址,2017-10-23 17:32:30,2017-10-24 17:32:30,20.40,92.94
13418592125,1004,MAC 地址,2017-10-23 18:32:30,2017-10-24 18:32:30,73.84,8.58
13418592126,1005,MAC 地址,2017-10-23 19:32:30,2017-10-24 19:32:30,80.50,88.02
13418592127,1006,MAC 地址,2017-10-23 20:32:30,2017-10-24 20:32:30,65.77,71.24
13418592128,1007,MAC 地址,2017-10-23 21:32:30,2017-10-24 21:32:30,75.21,76.04
13418592129,1008,MAC 地址,2017-10-23 22:32:30,2017-10-24 22:32:30,63.30,94.40
13418592130,1009,MAC 地址,2017-10-23 23:32:30,2017-10-24 23:32:30,95.51,50.17
13418592131,1010,MAC 地址,2017-10-24 00:32:30,2017-10-25 00:32:30,39.62,99.13
```

2. 使用 WinSCP 工具将 CSV 文件导入客户端节点，例如“/opt”目录下。
3. 登录 FusionInsight Manager 页面，选择“系统 > 权限 > 用户”，添加人机用户 sparkuser，用户组（hadoop、hive），主组（hadoop）。
4. 进入客户端目录，加载环境变量并认证用户：

   cd */客户端安装目录*

   source ./bigdata_env

   source ./Spark2x/component_env

说明

MRS 3.3.0-LTS 及之后的版本中，Spark2x 服务改名为 Spark，服务包含的角色名也有差异，例如 JobHistory2x 变更为 JobHistory。相关涉及服务名称、角色名称的描述和操作请以实际版本为准。

kinit sparkuser

5. 上传 CSV 中的文件到 HDFS 的“/data”目录：

   hdfs dfs -put /opt/test.csv /data/

连接到 CarbonData

- 使用 Spark SQL 或 Spark shell 连接到 Spark 并执行 Spark SQL 命令。
- 开启 JDBCServer 并使用 JDBC 客户端（例如，Spark Beeline）连接。

  执行如下命令：

  cd ./Spark2x/spark/bin

  ./spark-beeline

创建 CarbonData Table

在 Spark Beeline 被连接到 JDBCServer 之后，需要创建一个 CarbonData table 用于加载数据和执行查询操作。下面是创建一个简单的表的命令。

create table x1 (imei string, deviceInformationId int, mac string, productdate timestamp, updatetime timestamp, gamePointId double, contractNumber double) STORED AS carbondata TBLPROPERTIES ('SORT_COLUMNS'='imei,mac');

命令执行结果如下：

```
+----------+
| Result  |
+----------+
+----------+
No rows selected (1.093 seconds)
```

加载数据到 CarbonData Table

创建 CarbonData table 之后，可以从 CSV 文件加载数据到所创建的表中。

用所要求的参数运行以下命令从 CSV 文件加载数据。该表的列名需要与 CSV 文件的列名匹配。

LOAD DATA inpath 'hdfs://hacluster/data/*test.csv*' into table *x1* options('DELIMITER'=',', 'QUOTECHAR'='"','FILEHEADER'='imei, deviceinformationid,mac, productdate,updatetime, gamepointid,contractnumber');

其中，“test.csv”为准备 CSV 文件的 CSV 文件，“x1”为示例的表名。

CSV 样例内容如下：

```
13418592122,1001,MAC 地址,2017-10-23 15:32:30,2017-10-24 15:32:30,62.50,74.56
13418592123,1002,MAC 地址,2017-10-23 16:32:30,2017-10-24 16:32:30,17.80,76.28
13418592124,1003,MAC 地址,2017-10-23 17:32:30,2017-10-24 17:32:30,20.40,92.94
13418592125,1004,MAC 地址,2017-10-23 18:32:30,2017-10-24 18:32:30,73.84,8.58
13418592126,1005,MAC 地址,2017-10-23 19:32:30,2017-10-24 19:32:30,80.50,88.02
```

```
13418592127,1006,MAC 地址,2017-10-23 20:32:30,2017-10-24 20:32:30,65.77,71.24
13418592128,1007,MAC 地址,2017-10-23 21:32:30,2017-10-24 21:32:30,75.21,76.04
13418592129,1008,MAC 地址,2017-10-23 22:32:30,2017-10-24 22:32:30,63.30,94.40
13418592130,1009,MAC 地址,2017-10-23 23:32:30,2017-10-24 23:32:30,95.51,50.17
13418592131,1010,MAC 地址,2017-10-24 00:32:30,2017-10-25 00:32:30,39.62,99.13
```

命令执行结果如下：

```
+-------------+
|Segment ID  |
+-------------+
|0          |
+-------------+
No rows selected (3.039 seconds)
```

在 CarbonData 中查询数据

创建 CarbonData table 并加载数据之后，可以执行所需的数据查询操作。以下为一些查询操作举例。

- **获取记录数**

  为了获取在 CarbonData table 中的记录数，可以运行以下命令。

  select count(*) from x1;

- **使用 Groupby 查询**

  为了获取不重复的 deviceinformationid 记录数，可以运行以下命令。

  select deviceinformationid,count (distinct deviceinformationid) from x1 group by deviceinformationid;

- **用 Filter 查询**

  为了获取特定 deviceinformationid 的记录，可以运行以下命令。

  select * from x1 where deviceinformationid='1010';

在 Spark-shell 上使用 CarbonData

用户若需要在 Spark-shell 上使用 CarbonData，需通过如下方式创建 CarbonData Table，加载数据到 CarbonData Table 和在 CarbonData 中查询数据的操作。

```
spark.sql("CREATE TABLE x2(imei string, deviceInformationId int, mac string,
productdate timestamp, updatetime timestamp, gamePointId double, contractNumber
double) STORED AS carbondata")
spark.sql("LOAD DATA inpath 'hdfs://hacluster/data/x1_without_header.csv' into
table x2 options('DELIMITER'=',', 'QUOTECHAR'='\"','FILEHEADER'='imei,
deviceinformationid,mac, productdate,updatetime, gamepointid,contractnumber')")
spark.sql("SELECT * FROM x2").show()
```

1.3.2 管理 CarbonData Table

1.3.2.1 CarbonData Table 简介

简介

CarbonData 中的数据存储在 table 实体中。CarbonData table 与 RDBMS 中的表类似。RDBMS 数据存储在由行和列构成的表中。CarbonData table 存储的也是结构化的数据，拥有固定列和数据类型。

支持数据类型

CarbonData 支持以下数据类型：

- Int
- String
- BigInt
- Smallint
- Char
- Varchar
- Boolean
- Decimal
- Double
- TimeStamp
- Date
- Array
- Struct
- Map

下表对所支持的数据类型及其各自的范围进行了详细说明。

表1-10 CarbonData 数据类型

数据类型	范围
Int	4 字节有符号整数，从-2,147,483,648 到 2,147,483,647 说明 非字典列如果是 Int 类型，会在内部存储为 BigInt 类型。
String	100000 字符 说明 如果在 **CREATE TABLE** 中使用 Char 或 Varchar 数据类型，则这两种数据类型将自动转换为 String 数据类型。 如果存在字符长度超过 32000 的列，需要在建表时，将该列加入到 tblproperties 的 LONG_STRING_COLUMNS 属性里。
BigInt	64-bit，从-9,223,372,036,854,775,808 到 9,223,372,036,854,775,807

数据类型	范围
SmallInt	范围-32,768 到 32,767
Char	范围 A 到 Z&a 到 z
Varchar	范围 A 到 Z&a 到 z&0 到 9
Boolean	范围 true 或者 false
Decimal	默认值是(10,0) ，最大值是(38,38) **说明** 当进行带过滤条件的查询时，为了得到准确的结果，需要在数字后面加上 BD。例如，*select * from carbon_table where num = 1234567890123456.22BD.*
Double	64-bit，从 4.9E-324 到 1.7976931348623157E308
TimeStamp	NA，默认格式为“yyyy-MM-dd HH:mm:ss”。
Date	DATE 数据类型用于存储日历日期。 默认格式为“yyyy-MM-dd”。
Array<data_type>	NA **说明** 现仅支持 2 层复杂类型的嵌套。
Struct<col_name: data_type COMMENT col_comment, ...>	
Map<primitive_type, data_type>	

1.3.2.2 新建 CarbonData Table

操作场景

使用 CarbonData 前需先创建表，才可在其中加载数据和查询数据。可通过 **Create Table** 命令来创建表。该命令支持使用自定义列创建表。

使用自定义列创建表

可通过指定各列及其数据类型来创建表。

命令示例：

CREATE TABLE *IF NOT EXISTS productdb.productSalesTable (*

productNumber Int,

productName String,

storeCity String,

storeProvince String,

productCategory String,

productBatch String,

saleQuantity Int,

revenue Int)

STORED AS *carbondata*

TBLPROPERTIES (

'table_blocksize'='128');

上述命令所创建的表的详细信息如下：

表1-11 表信息定义

参数	描述
productSalesTable	待创建的表的名称。该表用于加载数据进行分析。 表名由字母、数字、下划线组成。
productdb	数据库名称。该数据库将与其中的表保持逻辑连接以便于识别和管理。 数据库名称由字母、数字、下划线组成。
productName storeCity storeProvince procuctCategory productBatch saleQuantity revenue	表中的列，代表执行分析所需的业务实体。 列名（字段名）由字母、数字、下划线组成。
table_blocksize	CarbonData 表使用的数据文件的 block 大小，默认值为 1024，最小值为 1，最大值为 2048，单位为 MB。 如果“table_blocksize”值太小，数据加载时，生成过多的小数据文件，可能会影响 HDFS 的使用性能。 如果“table_blocksize”值太大，数据查询时，索引匹配的 block 数据量较大，某些 block 会包含较多的 blocklet，导致读取并发度不高，从而降低查询性能。 一般情况下，建议根据数据量级别来选择大小。例如：GB 级别用 256，TB 级别用 512，PB 级别用 1024。

说明

- 所有 Integer 类型度量均以 BigInt 类型进行处理与显示。
- CarbonData 遵循严格解析，因此任何不可解析的数据都会被保存为 null。例如，在 BigInt 列中加载 double 值（3.14），将会保存为 null。

- 在 Create Table 中使用的 Short 和 Long 数据类型在 DESCRIBE 命令中分别显示为 Smallint 和 Bigint。
- 可以使用 DESCRIBE 格式化命令查看表数据大小和表索引大小。

操作结果

根据命令创建表。

1.3.2.3 删除 CarbonData Table

操作场景

可使用 **DROP TABLE** 命令删除表。删除表后，所有 metadata 以及表中已加载的数据都会被删除。

操作步骤

运行如下命令删除表。

命令：

DROP TABLE *[IF EXISTS] [db_name.]table_name;*

一旦执行该命令，将会从系统中删除表。命令中的“db_name”为可选参数。如果没有指定“db_name”，那么将会删除当前数据库下名为“table_name”的表。

示例：

DROP TABLE *productdb.productSalesTable;*

通过上述命令，删除数据库“productdb”下的表“productSalesTable”。

操作结果

从系统中删除命令中指定的表。删除完成后，可通过 **SHOW TABLES** 命令进行查询，确认所需删除的表是否成功被删除，详见 1.6.1.4 SHOW TABLES。

1.3.2.4 修改 CarbonData Table

SET 和 UNSET

当使用 set 命令时，所有新 set 的属性将会覆盖已存在的旧的属性。

- SORT SCOPE
  SET SORT SCOPE 命令示例：
  ALTER TABLE *tablename* **SET TBLPROPERTIES('SORT_SCOPE'**=*'no_sort'*)
  当 UNSET SORT SCOPE 后，会使用默认值 NO_SORT。
  UNSET SORT SCOPE 命令示例：
  ALTER TABLE *tablename* **UNSET TBLPROPERTIES('SORT_SCOPE')**
- SORT COLUMNS
  SET SORT COLUMNS 命令示例：

ALTER TABLE *tablename* **SET TBLPROPERTIES('SORT_COLUMNS'**=*'column1'*)

在执行该命令后，新的导入会使用新的 SORT_COLUMNS 配置值。 用户可以根据查询的情况来调整 SORT_COLUMNS，但是不会直接影响旧的数据。所以对历史的 segments 的查询性能不会受到影响，因为历史的 segments 不是按照新的 SORT_COLUMNS。

不支持 UNSET 命令，但是可以使用 set SORT_COLUMNS 等于空字符串来代替 UNSET 命令。

ALTER TABLE *tablename* **SET TBLPROPERTIES('SORT_COLUMNS'**=*''*)

说明

- 后续版本会加强自定义合并来对旧的 segment 重新排序。
- 流式表不支持修改 SORT_COLUMNS。
- 如果 inverted index 的列从 SORT_COLUMNS 里面移除了，该列不会再创建 inverted index。但是旧的 INVERTED_INDEX 配置值不会变化。

1.3.3 管理 CarbonData Table 数据

1.3.3.1 加载数据

操作场景

CarbonData table 创建成功后，可使用 **LOAD DATA** 命令在表中加载数据，并可供查询。触发数据加载后，数据以 CarbonData 格式进行编码，并将多维列式存储格式文件压缩后复制到存储 CarbonData 文件的 HDFS 路径下供快速分析查询使用。HDFS 路径可以配置在 carbon.properties 文件中。具体请参考 1.2 CarbonData 常用参数。

1.3.3.2 删除 Segments

操作场景

如果用户将错误数据加载到表中，或者数据加载后出现许多错误记录，用户希望修改并重新加载数据时，可删除对应的 segment。可使用 segment ID 来删除 segment，也可以使用加载数据的时间来删除 segment。

说明

删除 segment 操作只能删除未合并的 segment，已合并的 segment 可以通过 **CLEAN FILES** 命令清除 segment。

通过 Segment ID 删除

每个 Segment 都有与其关联的唯一 Segment ID。使用这个 Segment ID 可以删除该 Segment。

步骤 1 运行如下命令获取 Segment ID。

命令：

SHOW SEGMENTS FOR Table *dbname.tablename LIMIT number_of_loads;*

示例：

SHOW SEGMENTS FOR TABLE *carbonTable;*

上述命令可显示 tablename 为 carbonTable 的表的所有 Segment 信息。

SHOW SEGMENTS FOR TABLE *carbonTable LIMIT 2;*

上述命令可显示 *number_of_loads* 规定条数的 Segment 信息。

输出结果如下：

```
+-----+----------+--------------------------+-----------------+------------+------
------+-------------+--------------+--+
| ID  |  Status  |    Load Start Time       | Load Time Taken  | Partition  | Data Size
| Index Size  | File Format  |
+-----+----------+--------------------------+-----------------+------------+------
------+-------------+--------------+--+
| 3   | Success  | 2020-09-28 22:53:26.336  | 3.726S          | {}         | 6.47KB
| 3.30KB      | columnar_v3  |
| 2   | Success  | 2020-09-28 22:53:01.702  | 6.688S          | {}         | 6.47KB
| 3.30KB      | columnar_v3  |
+-----+----------+--------------------------+-----------------+------------+------
------+-------------+--------------+--+
```

说明

SHOW SEGMENTS 命令输出包括 ID、Status、Load Start Time、Load Time Taken、Partition、Data Size、Index Size、File Format。最新的加载信息在输出中第一行显示。

步骤 2 获取到需要删除的 Segment 的 Segment ID 后，执行如下命令删除对应 Segment：

命令：

DELETE FROM TABLE tableName WHERE SEGMENT.ID IN (load_sequence_id1, load_sequence_id2, ...);

示例：

DELETE FROM TABLE carbonTable WHERE SEGMENT.ID IN (1,2,3);

详细信息，请参阅 1.6.2.5 DELETE SEGMENT by ID。

----结束

通过加载数据的时间删除

用户可基于特定的加载时间删除数据。

命令：

DELETE FROM TABLE db_name.table_name WHERE SEGMENT.STARTTIME BEFORE date_value;

示例：

DELETE FROM TABLE carbonTable WHERE SEGMENT.STARTTIME BEFORE '2017-07-01 12:07:20';

上述命令可删除'2017-07-01 12:07:20'之前的所有 segment。

有关详细信息，请参阅 1.6.2.6 DELETE SEGMENT by DATE。

删除结果

数据对应的 segment 被删除，数据将不能再被访问。可通过 **SHOW SEGMENTS** 命令显示 segment 状态，查看是否成功删除。

说明

- 调用 **DELETE SEGMENT** 命令时，物理上而言，Segment 并没有从文件系统中被删除。使用命令 **SHOW SEGMENTS** 查看 Segment 信息，可看见被删除的 Segment 的状态被标识为 "Marked for Delete"。但使用 **SELECT * FROM tablename** 命令查询时，不会显示被删除的 Segment 的内容。
- 下一次加载数据且达到最大查询执行时间（由“max.query.execution.time”配置，默认为“60分钟”）后，Segment 才会从文件系统中真正删除。
- 如果用户想要强制删除物理 Segment 文件，那么可以使用 **CLEAN FILES** 命令。

  示例：

  CLEAN FILES FOR TABLE table1;

  该命令将从物理上删除状态为“Marked for delete”的 Segment 文件。

  如果在“max.query.execution.time”规定的时间到达之前使用该命令，可能会导致查询失败。“max.query.execution.time”可在“carbon.properties”文件中设置，表示一次查询允许花费的最长时间。

1.3.3.3 合并 Segments

操作场景

频繁的数据获取导致在存储目录中产生许多零碎的 CarbonData 文件。由于数据排序只在每次加载时进行，所以，索引也只在每次加载时执行。这意味着，对于每次加载都会产生一个索引，随着数据加载数量的增加，索引的数量也随之增加。由于每个索引只在一次加载时工作，索引的性能被降低。CarbonData 提供加载压缩。压缩过程通过合并排序各 segment 中的数据，将多个 segment 合并为一个大的 segment。

前提条件

已经加载了多次数据。

操作描述

有 Minor 合并、Major 合并和 Custom 合并三种类型。

- Minor 合并：

  在 Minor 合并中，用户可指定合并数据加载的数量。如果设置了参数“carbon.enable.auto.load.merge”，每次数据加载都可触发 Minor 合并。如果任意 segment 均可合并，那么合并将于数据加载时并行进行。

  Minor 合并有两个级别。

  - Level 1：合并未合并的 segment。
  - Level 2：合并已合并的 segment，以形成更大的 segment。
- Major 合并：

  在 Major 合并中，许多 segment 可以合并为一个大的 segment。用户将指定合并尺寸，将对未达到该尺寸的 segment 进行合并。Major 合并通常在非高峰时段进行。

- Custom 合并：

  在 Custom 合并中，用户可以指定几个 segment 的 id 合并为一个大的 segment。所有指定的 segment 的 id 必须存在并且有效，否则合并将会失败。Custom 合并通常在非高峰时段进行。

具体的命令操作，请参考 1.6.1.5 ALTER TABLE COMPACTION。

表1-12 合并参数

参数	默认值	应用类型	描述
carbon.enable.auto.load.merge	false	Minor	数据加载时启用合并。 “true”：数据加载时自动触发 segment 合并。 “false”：数据加载时不触发 segment 合并。
carbon.compaction.level.threshold	4,3	Minor	对于 Minor 合并，该属性参数决定合并 segment 的数量。 例如，如果该参数设置为“2,3”，在 Level 1，每 2 个 segment 触发一次 Minor 合并。在 Level2，每 3 个 Level 1 合并的 segment 将被再次合并为新的 segment。 合并策略根据实际的数据大小和可用资源决定。 有效值为 0-100。
carbon.major.compaction.size	1024mb	Major	通过配置该参数可配置 Major 合并。低于该阈值的 segment 之和将被合并。 例如，如果该阈值是 1024MB，且有 5 个大小依次为 300MB，400MB，500MB，200MB，100MB 的 segment 用于 Major 合并，那么只有相加的总数小于阈值的 segment 会被合并，也就是 300+400+200+100 = 1000MB 的 segment 会被合并，而 500MB 的 segment 将会被跳过。
carbon.numberof.preserve.segments	0	Minor/Major	如果用户希望从被合并的 segment 中保留一定数量的 segment，可通过该属性参数进行设置。 例如，“carbon.numberof.preserve.segments”=“2”，那么最新的 2 个 segment 将不会包含在合并中。 默认不保留任何 segment。

参数	默认值	应用类型	描述
carbon.allowed.compaction.days	0	Minor/Major	合并将合并在指定的配置天数中加载的 segment。 例如，如果配置为“2”，那么只有在 2 天的时间框架中被加载的 segment 可以被合并。在 2 天以外被加载的 segment 将不被合并。 默认为禁用。
carbon.number.of.cores.while.compacting	2	Minor/Major	在合并过程中写入数据时所用的核数。配置的核数越大合并性能越好。如果 CPU 资源充足可以增加此值。
carbon.merge.index.in.segment	true	SEGMENT_INDEX	如果设置为 true，则一个 segment 中所有 Carbon 索引文件（.carbonindex）将合并为单个 Carbon 索引合并文件（.carbonindexmerge）。 这增强了首次查询性能。

参考信息

建议避免对历史数据进行 minor compaction，请参考 1.8.2 如何避免对历史数据进行 minor compaction？

1.3.4 迁移 CarbonData 数据

操作场景

如果用户需要快速从一个集群中将 CarbonData 的数据迁移到另外一个集群的 CarbonData 中，可以使用 CarbonData 的数据备份与恢复命令来完成该任务。使用此方法迁移数据，无需在新集群执行数据导入的过程，可以减少迁移的时间。

前提条件

两个集群已安装 Spark2x 客户端，例如安装目录为“/opt/client”。假设原始数据所在集群为 A，需要迁移到集群 B。

操作步骤

步骤 1 使用客户端安装用户登录 A 集群客户端所在节点。

步骤 2 使用客户端用户执行以下命令，配置环境变量。

source /opt/client/bigdata_env

source /opt/client/Spark2x/component_env

步骤 3 如果集群为安全模式，执行以下命令进行用户认证。普通模式集群无需执行用户认证。

kinit *carbondatauser*

carbondatauser 需要为原始数据的使用者，即拥有表的读写权限。

说明

该用户需要加入 hadoop，hive 组，主组选择 hadoop 组，并关联角色 System_administrator。

步骤 4 执行以下命令连接数据库，并查看表的数据在 HDFS 保存的位置：

spark-beeline

desc formatted ***原始数据的表名称*****;**

查看系统显示的信息中“Location”表示数据文件所在目录。

步骤 5 使用客户端安装用户登录 B 集群客户端所在节点，并执行以下命令，配置环境变量。

source /opt/client/bigdata_env

source /opt/client/Spark2x/component_env

步骤 6 如果集群为安全模式，执行以下命令进行用户认证。普通模式集群无需执行用户认证。

kinit *carbondatauser2*

carbondatauser2 需要为上传数据的用户。

说明

该用户需要加入 hadoop，hive 组，主组选择 hadoop 组，并关联角色 System_administrator。

步骤 7 执行 **spark-beeline** 命令连接数据库。

步骤 8 原始数据对应的数据库是否存在？

- 是，执行步骤 9。
- 否，执行命令 **create database** *数据库名称*，创建一个同名的数据库，然后执行步骤 9。

步骤 9 将原始数据从集群 A 的 HDFS 目录中，拷贝数据到集群 B 的 HDFS 中。

在集群 B 上传数据时，上传目录中需要存在与原始目录有相同的数据库以及表名目录，且上传用户需要有在此目录写入数据的权限。上传后该用户将拥有数据的读写权限。

例如，原始数据保存在“/user/carboncadauser/warehouse/db1/tb1”，则在新集群中数据可以保存在“/user/carbondatauser2/warehouse/db1/tb1”中：

1. 下载原始数据到集群 A 的“/opt/backup”目录下：

   hdfs dfs -get /user/carboncadauser/warehouse/db1/tb1 /opt/backup

2. 拷贝集群 A 的原始数据到集群 B 客户端节点的“/opt/backup”目录下：

   scp /opt/backup root@*集群 B 客户端节点 IP***:/opt/backup**

3. 上传拷贝到集群 B 的数据到 HDFS 中：

hdfs dfs -put /opt/backup /user/carbondatauser2/warehouse/db1/tb1

步骤 10 在集群 B 的客户端环境执行以下命令，在 Hive 中生成原始数据对应的表所关联的元数据：

REFRESH TABLE *$dbName.$tbName;*

$dbName 和$tbName 分别表示数据对应的数据库名称以及表名称。

步骤 11 如果原表存在索引表，执行步骤 9 和步骤 10，将集群 A 的索引表目录迁移到集群 B。

步骤 12 执行以下命令，为 CarbonData 表注册索引表（注意，如果原表没有创建索引表，则不需要执行此步骤）：

REGISTER INDEX TABLE *$tableName* ON *$maintable*;

$tableName 和$maintable 分别表示索引表名称和主表名称。

----结束

1.3.5 迁移 Spark1.5 的 Carbondata 数据到 Spark2x 的 Carbondata 中

迁移方案概览

本次迁移目标是将 Spark1.5 的 CarbonData 表数据迁移到 Spark2x 的 CarbonData 表中。

说明

执行本操作前需要将 spark1.5 的 carbondata 表入库业务中断，将数据一次性迁移至 spark2x 的 carbondata 表，完成迁移后使用 spark2x 进行业务操作。

迁移思路：

1. 先通过 Spark1.5 将历史数据迁移至中间表。
2. 再通过 Spark2x 将中间表的数据迁移至目标表，然后将目标表名修改为原表名。
3. 迁移完成后使用 Spark2x 操作 CarbonData 表中的数据。

具体迁移方案和命令

历史数据迁移

步骤 1 中断 CarbonData 的数据入库业务，用 Spark1.5 的 spark-beeline，查看 CarbonData 表当前最新的 Segment 的 ID 和时间，并记录此 Segment 的 ID。

show segments for table dbname.tablename;

步骤 2 用创建原 CarbonData 表的用户，执行 Spark1.5 的 spark-beeline，创建 ORC（或 PARQUET）格式的中间表，然后将原 CarbonData 表中的数据导入该中间表，导入完成后即可恢复 CarbonData 表的业务。

创建 ORC 表：

CREATE TABLE dbname.mid_tablename_orc STORED AS ORC as select * from dbname.tablename;

创建 PARQUET 表：

CREATE TABLE dbname.mid_tablename_parq STORED AS PARQUET as select * from dbname.tablename;

其中 dbname 指数据库名，tablename 指原 CarbonData 表名。

步骤 3 用创建原 CarbonData 表的用户，执行 Spark2x 的 spark-beeline；然后通过旧表的建表语句，创建新的 CarbonData 表。

说明

创建新表的语句中，字段顺序和类型必须和旧表的完全一致，如此才能保留原表的索引列等结构，且可以避免后续插入数据时因用到了 select * 而出错。

通过 Spark1.5 的 spark-beeline 命令查看旧表的建表语句：**SHOW CREATE TABLE dbname.tablename**;

创建新 CarbonData 表，名称为：**dbname.new_tablename**

步骤 4 用创建原 CarbonData 表的用户，执行 Spark2x 的 spark-beeline，将步骤 2 中创建的 ORC（或 PARQUET）格式的中间表的数据，加载到步骤 3 创建的新表中。此步骤可能耗时较长（200G 数据耗时约 2 小时）。加载数据的命令以 ORC 格式的中间表举例：

insert into dbname.new_tablename select *

from dbname. mid_tablename_orc;

步骤 5 用创建原 CarbonData 表的用户，执行 Spark2x 的 spark-beeline，对新表的数据进行查询检验，确认数据无误后，将原 CarbonData 表修改为其他名称，再将新 CarbonData 表修改为原 CarbonData 表的名称。

ALTER TABLE dbname.tablename RENAME TO dbname.old_tablename;

ALTER TABLE dbname.new_tablename RENAME TO dbname.tablename;

步骤 6 迁移完成。此时即可通过 Spark2x 对新表进行查询、重建二级索引等操作。

----结束

1.4 CarbonData 性能调优

1.4.1 调优指导

查询性能调优

CarbonData 可以通过调整各种参数来提高查询性能。大部分参数聚焦于增加并行性处理和更好地使用系统资源。

- Spark Executor 数量：Executor 是 Spark 并行性的基础实体。通过增加 Executor 数量，集群中的并行数量也会增加。关于如何配置 Executor 数量，请参考 Spark 资料。
- Executor 核：每个 Executor 内，并行任务数受 Executor 核的配置控制。通过增加 Executor 核数，可增加并行任务数，从而提高性能。

- HDFS block 容量：CarbonData 通过给不同的处理器分配不同的 block 来分配查询任务。所以一个 HDFS block 是一个分区单元。另外，CarbonData 在 Spark 驱动器中，支持全局 block 级索引，这有助于减少需要被扫描的查询 block 的数量。设置较大的 block 容量，可提高 I/O 效率，但是会降低全局索引效率；设置较小的 block 容量，意味着更多的 block 数量，会降低 I/O 效率，但是会提高全局索引效率，同时，对于索引查询会要求更多的内存。
- 扫描线程数量：扫描仪（Scanner）线程控制每个任务中并行处理的数据块的数量。通过增加扫描仪线程数，可增加并行处理的数据块的数量，从而提高性能。可使用“carbon.properties”文件中的“carbon.number.of.cores”属性来配置扫描仪线程数。例如，“carbon.number.of.cores = 4”。
- B-Tree 缓存：为了获得更好的查询特性，可以通过 B-tree LRU（least recently used，最近最少使用）缓存来优化缓存内存。在 driver 中，B-Tree LRU 缓存配置将有助于通过释放未被访问或未使用的表 segments 来释放缓存。类似地，在 executor 中，B-Tree LRU 缓存配置将有助于释放未被访问或未使用的表 blocks。具体可参考表 1-4 中的参数“carbon.max.driver.lru.cache.size”和“carbon.max.executor.lru.cache.size”的详细描述。

CarbonData 查询流程

当 CarbonData 首次收到对某个表（例如表 A）的查询任务时，系统会加载表 A 的索引数据到内存中，执行查询流程。当 CarbonData 再次收到对表 A 的查询任务时，系统则不需要再加载其索引数据。

在 CarbonData 中执行查询时，查询任务会被分成几个扫描任务。即，基于 CarbonData 数据存储的 HDFS block 对扫描任务进行分割。扫描任务由集群中的执行器执行。扫描任务可以并行、部分并行，或顺序处理，具体采用的方式取决于执行器的数量以及配置的执行器核数。

查询任务的某些部分可在独立的任务级上处理，例如 select 和 filter。查询任务的某些部分可在独立的任务级上进行部分处理，例如 group-by、count、distinct count 等。

某些操作无法在任务级上处理，例如 Having Clause（分组后的过滤），sort 等。这些无法在任务级上处理，或只能在任务级上部分处理的操作需要在集群内跨执行器来传输数据（部分结果）。这个传送操作被称为 shuffle。

任务数量越多，需要 shuffle 的数据就越多，会对查询性能产生不利影响。

由于任务数量取决于 HDFS block 的数量，而 HDFS block 的数量取决于每个 block 的大小，因此合理选择 HDFS block 的大小很重要，需要在提高并行性，进行 shuffle 操作的数据量和聚合表的大小之间达到平衡。

分割和 Executors 的关系

如果分割数小于等于 Executor 数乘以 Executor 核数，那么任务将以并行方式运行。否则，某些任务只有在其他任务完成之后才能开始。因此，要确保 Executor 数乘以 Executor 核数大于等于分割数。同时，还要确保有足够的分割数，这样一个查询任务可被分为足够多的子任务，从而确保并行性。

配置扫描仪线程

扫描仪线程属性决定了每个分割的数据被划分的可并行处理的数据块的数量。如果数量过多，会产生很多小数据块，性能会受到影响。如果数量过少，并行性不佳，性能也会受到影响。因此，决定扫描仪线程数时，需要考虑一个分割内的平均数据大小，选择一个使数据块不会很小的值。经验法则是将单个块大小（MB）除以 250 得到的值作为扫描仪线程数。

增加并行性还需考虑的重要一点是集群中实际可用的 CPU 核数，确保并行计算数不超过实际 CPU 核数的 75%至 80%。

CPU 核数约等于：

并行任务数 x 扫描仪线程数。其中并行任务数为分割数和执行器数 x 执行器核数两者之间的较小值。

数据加载性能调优

数据加载性能调优与查询性能调优差异很大。跟查询性能一样，数据加载性能也取决于可达到的并行性。在数据加载情况下，工作线程的数量决定并行的单元。因此，更多的执行器就意味着更多的执行器核数，每个执行器都可以提高数据加载性能。

同时，为了得到更好的性能，可在 HDFS 中配置如下参数。

表1-13 HDFS 配置

参数	建议值
dfs.datanode.drop.cache.behind.reads	false
dfs.datanode.drop.cache.behind.writes	false
dfs.datanode.sync.behind.writes	true

压缩调优

CarbonData 结合少数轻量级压缩算法和重量级压缩算法来压缩数据。虽然这些算法可处理任何类型的数据，但如果数据经过排序，相似值在一起出现时，就会获得更好的压缩率。

CarbonData 数据加载过程中，数据基于 Table 中的列顺序进行排序，从而确保相似值在一起出现，以获得更好的压缩率。

由于 CarbonData 按照 Table 中定义的列顺序将数据进行排序，因此列顺序对于压缩效率起重要作用。如果低 cardinality 维度位于左边，那么排序后的数据分区范围较小，压缩效率较高。如果高 cardinality 维度位于左边，那么排序后的数据分区范围较大，压缩效率较低。

内存调优

CarbonData 为内存调优提供了一个机制，其中数据加载会依赖于查询中需要的列。不论何时，接收到一个查询命令，将会获取到该查询中的列，并确保内存中这些列有数据加载。在该操作期间，如果达到内存的阈值，为了给查询需要的列提供内存空间，最少使用加载级别的文件将会被删除。

1.4.2 创建 CarbonData Table 的建议

操作场景

本章节根据超过 50 个测试用例总结得出建议，帮助用户创建拥有更高查询性能的 CarbonData 表。

表1-14 CarbonData 表中的列

Column name	Data type	Cardinality	Attribution
msname	String	3 千万	dimension
BEGIN_TIME	bigint	1 万	dimension
host	String	1 百万	dimension
dime_1	String	1 千	dimension
dime_2	String	500	dimension
dime_3	String	800	dimension
counter_1	numeric(20,0)	NA	measure
...	...	NA	measure
counter_100	numeric(20,0)	NA	measure

操作步骤

- 如果待创建的表有一个常用于过滤的列 ，例如 80%以上的场景使用此列过滤。

  针对此类场景，调优方法如下：

  将常用于过滤的列放在 sort_columns 第一列。

  例如，msname 作为过滤条件在查询中使用的最多，则将其放在第一列。创建表的命令如下，其中采用 msname 作为过滤条件的查询性能将会很好。

  ```
  create table carbondata_table(
     msname String,
     ...
     )STORED AS carbondata TBLPROPERTIES ('SORT_COLUMS'='msname');
  ```

- 如果待创建的表有多个常用于过滤的列。

  针对此类场景，调优方法如下：

  为常用的过滤列创建索引。

例如，如果 msname，host 和 dime_1 是过滤经常使用的列，根据 cardinality，sort_columns 列的顺序是 dime_1-> host-> msname…。创建表命令如下，以下命令可提高 dime_1，host 和 msname 上的过滤性能。

```
create table carbondata_table(
   dime_1 String,
   host String,
   msname String,
   dime_2 String,
   dime_3 String,
   ...
   )STORED AS carbondata
TBLPROPERTIES ('SORT_COLUMS'='dime_1,host,msname');
```

- 如果每个用于过滤的列的频率相当。

  针对此类场景，调优方法如下：

  sort_columns 按照 cardinality 从低到高的顺序排列。

  创建表的命令如下：

```
create table carbondata_table(
   Dime_1 String,
   BEGIN_TIME bigint,
   HOST String,
   msname String,
   ...
   )STORED AS carbondata
TBLPROPERTIES ('SORT_COLUMS'='dime_2,dime_3,dime_1, BEGIN_TIME,host,msname');
```

- 按照维度的 cardinality 从低到高创建表后，再为高 Cardinality 列创建 SECONDARY INDEX。创建索引的语句如下：

```
create index carbondata_table_index_msidn on tablecarbondata_table (
msname String) as 'carbondata' PROPERTIES ('table_blocksize'='128');
create index carbondata_table_index_host on tablecarbondata_table (
host String) as 'carbondata' PROPERTIES ('table_blocksize'='128');
```

- 对于不需要高精度的度量，无需使用 numeric (20,0)数据类型，建议使用 double 数据类型来替换 numeric (20,0)数据类型，以提高查询性能。

  在一个测试用例中，使用 double 来替换 numeric (20, 0)，查询时间从 15 秒降低到 3 秒，查询速度提高了 5 倍。创建表命令如下：

```
create table carbondata_table(
   Dime_1 String,
   BEGIN_TIME bigint,
   HOST String,
   msname String,
   counter_1 double,
   counter_2 double,
   ...
   counter_100 double,
   )STORED AS carbondata
;
```

- 如果列值总是递增的，如 start_time。

  例如，每天将数据加载到 CarbonData，start_time 是每次加载的增量。对于这种情况，建议将 start_time 列放在 sort_columns 的最后，因为总是递增的值可以始终使用最小/最大索引。创建表命令如下：

```
create table carbondata_table(
    Dime_1 String,
    HOST String,
    msname String,
    counter_1 double,
    counter_2 double,
    BEGIN_TIME bigint,
    ...
    counter_100 double,
    )STORED AS carbondata
    TBLPROPERTIES ( 'SORT_COLUMS'='dime_2,dime_3,dime_1..BEGIN_TIME');
```

1.4.3 性能调优的相关配置

操作场景

CarbonData 的性能与配置参数相关，本章节提供了能够提升性能的相关配置介绍。

操作步骤

用于 CarbonData 查询的配置介绍，详情请参见表 1-15 和表 1-16。

表1-15 Shuffle 过程中，启动 Task 的个数

参数	spark.sql.shuffle.partitions
所属配置文件	spark-defaults.conf
适用于	数据查询
场景描述	Spark shuffle 时启动的 Task 个数。
如何调优	一般建议将该参数值设置为执行器核数的 1 到 2 倍。例如，在聚合场景中，将 task 个数从 200 减少到 32，有些查询的性能可提升 2 倍。

表1-16 设置用于 CarbonData 查询的 Executor 个数、CPU 核数以及内存大小

参数	spark.executor.cores spark.executor.instances spark.executor.memory
所属配置文件	spark-defaults.conf
适用于	数据查询
场景描述	设置用于 CarbonData 查询的 Executor 个数、CPU 核数以及内存大小。
如何调优	在银行方案中，为每个执行器提供 4 个 CPU 内核和 15GB 内存，可以获得良好的性能。这 2 个值并不意味着越多越好，在资源有

	限的情况下，需要正确配置。例如，在银行方案中，每个节点有足够的 32 个 CPU 核，而只有 64GB 的内存，这个内存是不够的。例如，当每个执行器有 4 个内核和 12GB 内存，有时在查询期间发生垃圾收集（GC），会导致查询时间从 3 秒增加到超过 15 秒。在这种情况下需要增加内存或减少 CPU 内核。

用于 CarbonData 数据加载的配置参数，详情请参见表 1-17、表 1-18 和表 1-19。

表1-17 设置数据加载使用的 CPU core 数量

参数	carbon.number.of.cores.while.loading
所属配置文件	carbon.properties
适用于	数据加载
场景描述	数据加载过程中，设置处理数据使用的 CPU core 数量。
如何调优	如果有更多的 CPU 个数，那么可以增加 CPU 值来提高性能。例如，将该参数值从 2 增加到 4，那么 CSV 文件读取性能可以增加大约 1 倍。

表1-18 是否使用 YARN 本地目录进行多磁盘数据加载

参数	carbon.use.local.dir
所属配置文件	carbon.properties
适用于	数据加载
场景描述	是否使用 YARN 本地目录进行多磁盘数据加载。
如何调优	如果将该参数值设置为“true”，CarbonData 将使用 YARN 本地目录进行多表加载磁盘负载平衡，以提高数据加载性能。

表1-19 加载时是否使用多路径

参数	carbon.use.multiple.temp.dir
所属配置文件	carbon.properties
适用于	数据加载
场景描述	是否使用多个临时目录存储 sort 临时文件。
如何调优	设置为 true，则数据加载时使用多个临时目录存储 sort 临时文件。此配置能提高数据加载性能并避免磁盘单点故障。

用于 CarbonData 数据加载和数据查询的配置参数，详情请参见表 1-20。

表1-20 设置数据加载和查询使用的 CPU core 数量

参数	carbon.compaction.level.threshold
所属配置文件	carbon.properties
适用于	数据加载和查询
场景描述	对于 minor 压缩，在阶段 1 中要合并的 segment 数量和在阶段 2 中要合并的已压缩的 segment 数量。
如何调优	每次 CarbonData 加载创建一个 segment，如果每次加载的数据量较小，将在一段时间内生成许多小文件，影响查询性能。配置该参数将小的 segment 合并为一个大的 segment，然后对数据进行排序，可提高查询性能。 压缩的策略根据实际的数据大小和可用资源决定。如某银行 1 天加载一次数据，且加载数据选择在晚上无查询时进行，有足够的资源，压缩策略可选择为 6、5。

表1-21 使用索引缓存服务器时是否开启数据预加载

参数	carbon.indexserver.enable.prepriming
所属配置文件	carbon.properties
适用于	数据加载
场景描述	使用索引缓存服务器过程中开启数据预加载可以提升首次查询的性能。
如何调优	用户可以将该参数设置为 true 来开启预加载。默认情况，该参数为 false。

1.5 CarbonData 访问控制

下表提供了对 CarbonData Table 执行相应操作所需的 Hive ACL 特权的详细信息。

前提条件

已经设置了表 1-7 或表 1-8 中 Carbon 相关参数。

Hive ACL 权限

表1-22 CarbonData 表级操作所需的 Hive ACL 权限

场景	所需权限
DESCRIBE TABLE	SELECT (of table)
SELECT	SELECT (of table)
EXPLAIN	SELECT (of table)
CREATE TABLE	CREATE (of database)
CREATE TABLE As SELECT	CREATE (on database), INSERT (on table), RW on data file, and SELECT (on table)
LOAD	INSERT (of table) RW on data file
DROP TABLE	OWNER (of table)
DELETE SEGMENTS	DELETE (of table)
SHOW SEGMENTS	SELECT (of table)
CLEAN FILES	DELETE (of table)
INSERT OVERWRITE / INSERT INTO	INSERT (of table) RW on data file and SELECT (of table)
CREATE INDEX	OWNER (of table)
DROP INDEX	OWNER (of table)
SHOW INDEXES	SELECT (of table)
ALTER TABLE ADD COLUMN	OWNER (of table)
ALTER TABLE DROP COLUMN	OWNER (of table)
ALTER TABLE CHANGE DATATYPE	OWNER (of table)
ALTER TABLE RENAME	OWNER (of table)
ALTER TABLE COMPACTION	INSERT (on table)
FINISH STREAMING	OWNER (of table)
ALTER TABLE SET STREAMING PROPERTIES	OWNER (of table)
ALTER TABLE SET TABLE PROPERTIES	OWNER (of table)
UPDATE CARBON TABLE	UPDATE (of table)
DELETE RECORDS	DELETE (of table)
REFRESH TABLE	OWNER (of main table)

场景	所需权限
REGISTER INDEX TABLE	OWNER (of table)
SHOW PARTITIONS	SELECT (on table)
ALTER TABLE ADD PARTITION	OWNER (of table)
ALTER TABLE DROP PARTITION	OWNER (of table)

说明

- 如果数据库下的表由多个用户创建，那么执行 Drop database 命令会失败，即使执行的用户是数据库的拥有者。
- 在二级索引中，当父表（parent table）触发时，insert 和 compaction 将在索引表上触发。 如果选择具有过滤条件匹配索引表列的查询，用户应该为父表和索引表提供选择权限。
- LockFiles 文件夹和 LockFiles 文件夹中创建的锁定文件将具有完全权限，因为 LockFiles 文件夹不包含任何敏感数据。
- 如果使用 ACL，确保不要为 DDL 或 DML 配置任何被其他进程使用中的路径，建议创建新路径。

  以下配置项需要配置路径：

  1) carbon.badRecords.location

  2) 创建数据库时 Db_Path 及其他。
- 对于非安全集群中的 Carbon ACL 权限，hive-site.xml 中的参数 hive.server2.enable.doAs 必须设置为 false。 将此属性设置为 false，查询将以 hiveserver2 进程运行的用户身份运行。

1.6 CarbonData 语法参考

1.6.1 DDL

1.6.1.1 CREATE TABLE

命令功能

CREATE TABLE 命令通过指定带有表属性的字段列表来创建 CarbonData Table。

命令格式

CREATE TABLE *[IF NOT EXISTS] [db_name.]table_name*

[(col_name data_type, ...)]

STORED AS *carbondata*

[TBLPROPERTIES (property_name=property_value, ...)];

所有表的附加属性都会放到 TBLPROPERTIES 中来定义。

参数描述

表1-23 CREATE TABLE 参数描述

参数	描述
db_name	Database 名称，由字母、数字和下划线（_）组成。
col_name data_type	以逗号分隔的带数据类型的列表。列名由字母、数字和下划线（_）组成。 说明 在 CarbonData 表创建过程中，不允许使用 tupleId，PositionId 和 PositionReference 为列命名，因为具有这些名称的列由二级索引命令在内部使用。
table_name	Database 中的表名，由字母、数字和下划线（_）组成。
STORED AS	参数 carbondata，定义和创建 CarbonData table。
TBLPROPERTIES	CarbonData table 属性列表。

注意事项

以下是表格属性的使用。

- Block 大小

  单个表的数据文件 block 大小可以通过 TBLPROPERTIES 进行定义，系统会选择数据文件实际大小和设置的 blocksize 大小中的较大值，作为该数据文件在 HDFS 上存储的实际 blocksize 大小。单位为 MB，默认值为 1024MB，范围为 1MB~2048MB。若设置值不在[1, 2048]之间，系统将会报错。

  一旦 block 大小达到配置值，写入程序将启动新的 CarbonData 数据的 block。数据以页面大小（32000 个记录）的倍数写入，因此边界在字节级别上不严格。 如果新页面跨越配置 block 的边界，则不会将其写入当前 block，而是写入新的 block。

  TBLPROPERTIES('table_blocksize'='128')

  说明

  - 当在 CarbonData 表中配置了较小的 blocksize，而加载的数据生成的数据文件比较大时，在 HDFS 上显示的 blocksize 会与设置值不同。这是因为，对于每一个本地 block 文件的首次写入，即使待写入数据的大小大于 blocksize 的配置值，也直接将待写入数据写入此 block。所以，HDFS 上 blocksize 的实际值为待写入数据大小与 blocksize 配置值中的较大值。
  - 当 CarbonData 表中的数据文件 block.num 小于任务并行度（parellelism）时，CarbonData 数据文件的 block 会被切为新的 block，使得 blocks.num 大于 parellelism，这样所有 core 均可被使用。这种优化称为 block distribution。

- SORT_SCOPE：指定表创建时的排序范围。如下为四种排序范围。
  - GLOBAL_SORT：它提高了查询性能，特别是点查询。
    TBLPROPERTIES('SORT_SCOPE'='GLOBAL_SORT')
  - LOCAL_SORT：数据会本地排序（任务级别排序）。

  - NO_SORT：默认排序。它将以不排序的方式加载数据，这将显着提升加载性能。

- SORT_COLUMNS

  此表属性指定排序列的顺序。

  TBLPROPERTIES('SORT_COLUMNS'='column1, column3')

  说明

  - 如果未指定此属性，则默认情况下，没有列会被排序。
  - 如果指定了此属性，但具有空参数，则表将被加载而不进行排序。例如，*('SORT_COLUMNS'='')*。
  - SORT_COLUMNS 将接受 string，date，timestamp，short，int，long, byte 和 boolean 数据类型。

- RANGE_COLUMN

  此表属性指定一列，该列将会按照一个范围值来对输入的数据进行分区。仅可配置一列。在数据导入过程中，可以使用“global_sort_partitions”或者“scale_factor”来避免生成小文件。

  TBLPROPERTIES('RANGE_COLUMN'='column1')

- LONG_STRING_COLUMNS

  普通 String 类型的长度不能超过 32000 字符，如果需要存储超过 32000 字符的字符串，指定 LONG_STRING_COLUMNS 配置为该列。

  TBLPROPERTIES('LONG_STRING_COLUMNS'='column1, column3')

  说明

  LONG_STRING_COLUMNS 仅可以设置 string/char/varchar 类型的列，并且不能为 SORT_COLUMNS 和复杂列。

使用场景

通过指定列创建表

CREATE TABLE 命令与 Hive DDL 相同。CarbonData 的额外配置将作为表格属性给出。

CREATE TABLE *[IF NOT EXISTS] [db_name.]table_name*

[(col_name data_type , ...)]

STORED AS *carbondata*

[TBLPROPERTIES (property_name=property_value, ...)];

示例

CREATE TABLE *IF NOT EXISTS productdb.productSalesTable (*

productNumber Int,

productName String,

storeCity String,

storeProvince String,

productCategory String,

productBatch String,

saleQuantity Int,

revenue Int)

STORED AS carbondata

TBLPROPERTIES (

'table_blocksize'='128',

'SORT_COLUMNS'='productBatch, productName')

系统响应

Table 创建成功，创建成功的消息将被记录在系统日志中。

1.6.1.2 CREATE TABLE As SELECT

命令功能

CREATE TABLE As SELECT 命令通过指定带有表属性的字段列表来创建 CarbonData Table。

命令格式

CREATE TABLE *[IF NOT EXISTS] [db_name.]table_name* ***STORED AS carbondata*** *[TBLPROPERTIES (key1=val1, key2=val2, ...)] AS select_statement;*

参数描述

表1-24 CREATE TABLE 参数描述

参数	描述
db_name	Database 名称，由字母、数字和下划线（_）组成。
table_name	Database 中的表名，由字母、数字和下划线（_）组成。
STORED AS	使用 CarbonData 数据格式存储数据。
TBLPROPERTIES	CarbonData table 属性列表。详细信息，见注意事项。

注意事项

NA

示例

CREATE TABLE ctas_select_parquet ***STORED AS*** carbondata as select * from parquet_ctas_test;

系统响应

该命令会从 Parquet 表上创建一个 Carbon 表，同时导入所有 Parquet 表的数据。

1.6.1.3 DROP TABLE

命令功能

DROP TABLE 的功能是用来删除已存在的 Table。

命令格式

DROP TABLE *[IF EXISTS] [db_name.]table_name;*

参数描述

表1-25 DROP TABLE 参数描述

参数	描述
db_name	Database 名称。如果未指定，将选择当前 database。
table_name	需要删除的 Table 名称。

注意事项

在该命令中，IF EXISTS 和 db_name 是可选配置。

示例

DROP TABLE IF EXISTS productDatabase.productSalesTable;

系统响应

Table 将被删除。

1.6.1.4 SHOW TABLES

命令功能

SHOW TABLES 命令用于显示所有在当前 database 中的 table，或所有指定 database 的 table。

命令格式

SHOW TABLES *[IN db_name];*

参数描述

表1-26 SHOW TABLES 参数描述

参数	描述
IN db_name	Database 名称，仅当需要显示指定 Database 的所有 Table 时配置。

注意事项

IN db_Name 为可选配置。

示例

SHOW TABLES IN ProductDatabase;

系统响应

显示所有 Table。

1.6.1.5 ALTER TABLE COMPACTION

命令功能

ALTER TABLE COMPACTION 命令将合并指定数量的 segment 为一个 segment。这将提高该表的查询性能。

命令格式

ALTER TABLE*[db_name.]table_name COMPACT 'MINOR/MAJOR/SEGMENT_INDEX';*

ALTER TABLE*[db_name.]table_name COMPACT 'CUSTOM' WHERE SEGMENT.ID IN (id1, id2, ...);*

参数描述

表1-27 ALTER TABLE COMPACTION 参数描述

Parameter	Description
db_name	数据库名。若未指定，则选择当前数据库。
table_name	表名。
MINOR	Minor 合并，详见 1.3.3.3 合并 Segments。

Parameter	Description
MAJOR	Major 合并，详见 1.3.3.3 合并 Segments。
SEGMENT_INDEX	这会将一个 segment 内的所有 Carbon 索引文件（.carbonindex）合并为一个 Carbon 索引合并文件（.carbonindexmerge）。 这增强了首次查询性能。详见表 1-12。
CUSTOM	Custom 合并，详见合并 Segments。

注意事项

NA

示例

ALTER TABLE ProductDatabase COMPACT 'MINOR';

ALTER TABLE ProductDatabase COMPACT 'MAJOR';

ALTER TABLE ProductDatabase COMPACT 'SEGMENT_INDEX';

ALTER TABLE ProductDatabase COMPACT 'CUSTOM' WHERE SEGMENT.ID IN (0, 1);

系统响应

由于为后台运行，**ALTER TABLE COMPACTION** 命令不会显示压缩响应。

如果想要查看 MINOR 合并和 MAJOR 合并的响应结果，用户可以检查日志或运行 ***SHOW SEGMENTS*** 命令查看。

示例：

```
+------+------------+--------------------------+------------------+------------+---
---------+-------------+--------------+--+
|  ID  |   Status   |    Load Start Time     | Load Time Taken  | Partition  | Data
Size  | Index Size  | File Format  |
+------+------------+--------------------------+------------------+------------+---
---------+-------------+--------------+--+
| 3    | Success    | 2020-09-28 22:53:26.336  | 3.726S           | {}         | 6.47KB
| 3.30KB      | columnar_v3  |
| 2    | Success    | 2020-09-28 22:53:01.702  | 6.688S           | {}         | 6.47KB
| 3.30KB      | columnar_v3  |
| 1    | Compacted  | 2020-09-28 22:51:15.242  | 5.82S            | {}         | 6.50KB
| 3.43KB      | columnar_v3  |
| 0.1  | Success    | 2020-10-30 20:49:24.561  | 16.66S           | {}         | 12.87KB
| 6.91KB      | columnar_v3  |
| 0    | Compacted  | 2020-09-28 22:51:02.6    | 6.819S           | {}         | 6.50KB
| 3.43KB      | columnar_v3  |
+------+------------+--------------------------+------------------+------------+---
---------+-------------+--------------+--+
```

其中，

- Compacted 表示该数据已被合并。
- 0.1 表示 segment0 与 segment1 合并之后的结果。

数据合并前后的其他操作没有差别。

被合并的 segments（例如 segment0 和 segment1）即成为无用的 segments，会占用空间，因此建议合并之后使用 ***CLEAN FILES*** 命令进行彻底删除，再进行其他操作。**CLEAN FILES** 命令的使用方法可参考 1.6.2.11 CLEAN FILES。

1.6.1.6 TABLE RENAME

命令功能

RENAME 命令用于重命名现有表。

命令语法

ALTER TABLE *[db_name.]table_name* **RENAME TO** *new_table_name*;

参数描述

表1-28 RENAME 参数描述

参数	描述
db_name	数据库名。若未指定，则选择当前数据库。
table_name	现有表名。
new_table_name	现有表名的新表名。

注意事项

- 并行运行的查询（需要使用表名获取路径，以读取 CarbonData 存储文件）可能会在此操作期间失败。
- 不允许二级索引表重命名。

示例

ALTER TABLE *carbon* **RENAME TO** *carbondata*;

ALTER TABLE *test_db.carbon* **RENAME TO** *test_db.carbondata*;

系统响应

CarbonData 库中的文件夹将显示新表名称，可以通过运行 SHOW TABLES 显示新表名称。

1.6.1.7 ADD COLUMNS

命令功能

ADD COLUMNS 命令用于为现有表添加新列。

命令语法

ALTER TABLE *[db_name.]table_name* **ADD COLUMNS** *(col_name data_type,...)* **TBLPROPERTIES***("COLUMNPROPERTIES.columnName.shared_column'='sharedFolder.sharedColumnName,...', 'DEFAULT.VALUE.COLUMN_NAME'='default_value')*;

参数描述

表1-29 ADD COLUMNS 参数描述

参数	描述
db_name	数据库名。若未指定，则选择当前数据库。
table_name	表名。
col_name data_type	带数据类型且用逗号分隔的列的名称。列名称包含字母，数字和下划线（_）。 **说明** 创建 CarbonData 表时，不要将列名命名为 tupleId，PositionId 和 PositionReference，因为将在 UPDATE，DELETE 和二级索引命令内部使用这些名称。

注意事项

- 除了 shared_column 和 default_value 之外，将不会读取其他属性。如果指定了任何其他属性名称，则不会抛出错误，其他属性将被忽略。
- 如果未指定默认值，则新列的默认值将被视为 null。
- 如果在该列上应用 filter，则在排序期间不会考虑新增列，新增列可能会影响查询性能。

示例

- **ALTER TABLE** *carbon* **ADD COLUMNS** *(a1 INT, b1 STRING)*;
- **ALTER TABLE** *carbon* **ADD COLUMNS** *(a1 INT, b1 STRING)* **TBLPROPERTIES***('COLUMNPROPERTIES.b1.shared_column'='sharedFolder.b1')*;
- ALTER TABLE *carbon* **ADD COLUMNS** *(a1 INT, b1 STRING)* **TBLPROPERTIES***('DEFAULT.VALUE.a1'='10')*;

系统响应

通过运行 DESCRIBE 命令，可显示新添加的列。

1.6.1.8 DROP COLUMNS

命令功能

DROP COLUMNS 命令用于删除表中现有的列或多个列。

命令语法

ALTER TABLE *[db_name.]table_name* **DROP COLUMNS** *(col_name, ...)*;

参数描述

表1-30 DROP COLUMNS 参数描述

参数	描述
db_name	数据库名。若未指定，则选择当前数据库。
table_name	表名。
col_name	表中的列名称。支持多列。列名称包含字母，数字和下划线（_）。

注意事项

对于删除列操作，至少要有一个 key 列在删除操作后存在于 schema 中，否则将显示出错信息，删除列操作将失败。

示例

假设表包含 4 个列，分别命名为 a1，b1，c1 和 d1。

- 删除单个列：
  ALTER TABLE *carbon* **DROP COLUMNS** *(b1)*;
  ALTER TABLE *test_db.carbon* **DROP COLUMNS** *(b1)*;
- 删除多个列：
  ALTER TABLE *carbon* **DROP COLUMNS** *(b1,c1)*;
  ALTER TABLE *test_db.carbon* **DROP COLUMNS** *(b1,c1)*;

系统响应

运行 DESCRIBE 命令，将不会显示已删除的列。

1.6.1.9 CHANGE DATA TYPE

命令功能

CHANGE 命令用于将数据类型从 INT 更改为 BIGINT 或将 Decimal 精度从低精度改为高精度。

命令语法

ALTER TABLE *[db_name.]table_name* **CHANGE** *col_name col_name changed_column_type*;

参数描述

表1-31 CHANGE DATA TYPE 参数描述

参数	描述
db_name	数据库名。若未指定，则选择当前数据库。
table_name	表名。
col_name	表中的列名称。列名称包含字母，数字和下划线（_）。
changed_column_type	所要更改为的新数据类型。

注意事项

- 仅在没有数据丢失的情况下支持将 Decimal 数据类型从较低精度更改为较高精度例如：
  - 无效场景：将 Decimal 数据精度从（10,2）更改为（10,5）无效，因为在这种情况下，只有 scale 增加，但总位数保持不变。
  - 有效场景：将 Decimal 数据精度从（10,2）更改为（12,3）有效，因为总位数增加 2，但是 scale 仅增加 1，这不会导致任何数据丢失。
- 将 Decimal 数据类型从较低精度更改为较高精度，其允许的最大精度(precision, scale)范围为(38,38)，并且只适用于不会导致数据丢失的有效提升精度的场景。

示例

- 将列 a1 的数据类型从 INT 更改为 BIGINT。

  ALTER TABLE *test_db.carbon* **CHANGE** *a1 a1 BIGINT*;
- 将列 a1 的精度从 10 更改为 18。

  ALTER TABLE *test_db.carbon* **CHANGE** *a1 a1 DECIMAL(18,2)*;

系统响应

通过运行 DESCRIBE 命令，将显示被修改列变更后的数据类型。

1.6.1.10 REFRESH TABLE

命令功能

REFRESH TABLE 命令用于将已有的 Carbon 表数据注册到 Hive 元数据库中。

命令语法

REFRESH TABLE *db_name.table_name*;

参数描述

表1-32 REFRESH TABLE 参数描述

参数	描述
db_name	数据库名。若未指定，则选择当前数据库。
table_name	表名。

注意事项

- 在执行此命令之前，应将旧表的表结构定义 schema 和数据复制到新数据库位置。
- 对于旧版本仓库，源集群和目的集群的时区应该相同。
- 新的数据库和旧数据库的名字应该相同。
- 执行命令前，旧表的表结构定义 schema 和数据应该复制到新的数据库位置。
- 如果表是聚合表，则应将所有聚合表复制到新的数据库位置。
- 如果旧集群使用 HIVE 元数据库来存储表结构，则刷新将不起作用，因为文件系统中不存在表结构定义 schema 文件。

示例

REFRESH TABLE *dbcarbon.productSalesTable*;

系统响应

通过运行该命令，已有的 Carbon 表数据会被注册到 Hive 元数据库中。

1.6.1.11 REGISTER INDEX TABLE

命令功能

REGISTER INDEX TABLE 命令用于将索引表注册到主表。

命令语法

REGISTER INDEX TABLE *indextable_name* ON *db_name.maintable_name*;

参数描述

表1-33 REFRESH INDEX TABLE 参数描述

参数	描述
db_name	数据库名。若未指定，则选择当前数据库。
indextable_name	索引表名。
maintable_name	主表名。

注意事项

在执行此命令之前，使用 REFRESH TABLE 将主表和二级所索引表都注册到 Hive 元数据中。

示例

create database productdb;

use productdb;

CREATE TABLE productSalesTable(a int,b string,c string) stored as carbondata;

create index productNameIndexTable on table productSalesTable(c) as 'carbondata';

insert into table productSalesTable select 1,'a','aaa';

create database productdb2;

使用 hdfs 命令将 productdb 数据库下的 productSalesTable 和 productNameIndexTable 拷贝到 productdb2。

refresh table productdb2.productSalesTable ;

refresh table productdb2.productNameIndexTable ;

explain select * from productdb2.productSalesTable where c = 'aaa'; //可以发现该查询命令没有使用索引表

REGISTER INDEX TABLE productNameIndexTable ON productdb2.productSalesTable;

explain select * from productdb2.productSalesTable where c = 'aaa'; //可以发现该查询命令使用了索引表

系统响应

通过运行该命令，索引表会被注册到主表。

1.6.2 DML

1.6.2.1 LOAD DATA

命令功能

LOAD DATA 命令以 CarbonData 特定的数据存储类型加载原始的用户数据，这样，CarbonData 可以在查询数据时提供良好的性能。

说明

仅支持加载位于 HDFS 上的原始数据。

命令格式

LOAD DATA *INPATH 'folder_path' INTO TABLE [db_name.]table_name OPTIONS(property_name=property_value, ...);*

参数描述

表1-34 LOAD DATA 参数描述

参数	描述
folder_path	原始 CSV 数据文件夹或者文件的路径。
db_name	Database 名称。若未指定，则使用当前 database。
table_name	所提供的 database 中的表的名称。

注意事项

以下是可以在加载数据时使用的配置选项：

- DELIMITER：可以在加载命令中提供分隔符和引号字符。默认值为,。
  OPTIONS('DELIMITER'=',', 'QUOTECHAR'='"')
  可使用'DELIMITER'='\t'来表示用制表符 tab 对 CSV 数据进行分隔。
  OPTIONS('DELIMITER'='\t')
  CarbonData 也支持\001 和\017 作为分隔符。

  说明

  对于 CSV 数据，分隔符为单引号（'）时，单引号必须在双引号（" "）内。例如：'DELIMITER='"'"。
- QUOTECHAR：可以在加载命令中提供分隔符和引号字符。默认值为"。
  OPTIONS('DELIMITER'=',', 'QUOTECHAR'='"')
- COMMENTCHAR：可以在加载命令中提供注释字符。在加载操作期间，如果在行的开头遇到注释字符，那么该行将被视为注释，并且不会被加载。默认值为＃。

OPTIONS('COMMENTCHAR'='#')

- FILEHEADER：如果源文件中没有表头，可在 LOAD DATA 命令中提供表头。

  OPTIONS('FILEHEADER'='column1,column2')

- ESCAPECHAR：如果用户想在 CSV 上对 Escape 字符进行严格验证，可以提供 Escape 字符。默认值为\。

  OPTIONS('ESCAPECHAR'='\')

说明

如果在 CSV 数据中输入 ESCAPECHAR，该 ESCAPECHAR 必须在双引号（" "）内。例如："a\b"。

- Bad Records 处理：

  为了使数据处理应用程序为用户增值，不可避免地需要对数据进行某种程度的集成。在大多数情况下，数据质量问题源于生成源数据的上游（主要）系统。

  有两种完全不同的方式处理 Bad Data：

  - 按照原始数据加载所有数据，之后进行除错处理。
  - 在进入数据源的过程中，可以清理或擦除 Bad Data，或者在发现 Bad Data 时让数据加载失败。

  有多个选项可用于在 CarbonData 数据加载过程中清除源数据。对于 CarbonData 数据中的 Bad Records 管理，请参见表 1-35。

表1-35 Bad Records Logger

配置项	默认值	描述
BAD_RECORDS_LOGGER_ENABLE	false	若设置为 true，则将创建 Bad Records 日志文件，其中包含 Bad Records 的详细信息。
BAD_RECORDS_ACTION	FAIL	以下为 Bad Records 的四种操作类型： • FORCE：通过将 Bad Records 存储为 NULL 来自动校正数据。 • REDIRECT：无法加载 Bad Records，并将其写入 BAD_RECORD_PATH 下的 CSV 文件中，默认不开启该类型，如需使用该类型，需要设置参数 carbon.enable.badrecord.action.redirect 为 true。 • IGNORE：既不加载 Bad Records 也不将其写入 CSV 文件。 • FAIL：如果发现存在 Bad Records，数据加载将会失败。 说明 在加载数据时，如果所有记录都是 Bad Records，则参数 BAD_RECORDS_ACTION 将不起作用，加

配置项	默认值	描述
		载数据操作将会失败。
IS_EMPTY_DATA_BAD_RECORD	false	如果设置为“false”，则空（""或"或,,）数据将不被视为 Bad Records，如果设置为“true”，则空数据将被视为 Bad Records。
BAD_RECORD_PATH	-	指定存储 Bad Records 的 HDFS 路径。默认值为 Null。 如果启用了 Bad Records 日志记录或者 Bad Records 操作重定向，则该路径必须由用户进行配置。

示例：

LOAD DATA INPATH *'filepath.csv'* **INTO TABLE** *tablename OPTIONS('BAD_RECORDS_LOGGER_ENABLE'='true', 'BAD_RECORD_PATH'='hdfs://hacluster/tmp/carbon', 'BAD_RECORDS_ACTION'='REDIRECT', 'IS_EMPTY_DATA_BAD_RECORD'='false');*

说明

使用“REDIRECT”选项，CarbonData 会将所有的 Bad Records 添加到单独的 CSV 文件中，但是该文件内容不能用于后续的数据加载，因为其内容可能无法与源记录完全匹配。用户必须清理原始源记录以便于进一步的数据提取。该选项的目的只是让用户知道哪些记录被视为 Bad Records。

- MAXCOLUMNS：该可选参数指定了在一行中，由 CSV 解析器解析的最大列数。

  OPTIONS('MAXCOLUMNS'='400')

表1-36 MAXCOLUMNS

可选参数名称	默认值	最大值
MAXCOLUMNS	2000	20000

表1-37 MAXCOLUMNS 可选参数的行为图

MAXCOLUMNS 值	在文件 Header 选项中的列数	考虑的最终值
在加载项中未指定	5	2000
在加载项中未指定	6000	6000
40	7	文件 header 列数与 MAXCOLUMNS 值，两者中的最大值
22000	40	20000

MAXCOLUMNS 值	在文件 Header 选项中的列数	考虑的最终值
60	在加载项中未指定	CSV 文件第一行的列数与 MAXCOLUMNS 值，两者中的最大值

说明

对于设置 MAXCOLUMNS Option 的最大值，要求 executor 具有足够的内存，否则，数据加载会由于内存不足的错误而失败。

- 如果在创建表期间将 SORT_SCOPE 定义为 GLOBAL_SORT，则可以指定在对数据进行排序时要使用的分区数。如果未配置或配置小于 1，则将使用 map 任务的数量作为 reduce 任务的数量。 建议每个 reduce 任务处理 512MB - 1GB 数据。

  OPTIONS('GLOBAL_SORT_PARTITIONS'='2')

说明

增加分区数可能需要增加“spark.driver.maxResultSize”，因为在 driver 中收集的采样数据随着分区的增加而增加。

- DATEFORMAT：此选项用于指定表的日期格式。

  OPTIONS('DATEFORMAT'='dateFormat')

说明

日期格式由日期模式字符串指定。 Carbon 中的日期模式字母与 JAVA 中的日期模式字母相同。

- TIMESTAMPFORMAT：此选项用于指定表的时间戳格式。
- *OPTIONS('TIMESTAMPFORMAT'='timestampFormat')*
- SKIP_EMPTY_LINE：数据加载期间，此选项将忽略 CSV 文件中的空行。

  OPTIONS('SKIP_EMPTY_LINE'='TRUE/FALSE')
- **可选:** SCALE_FACTOR：针对 RANGE_COLUMN，SCALE_FACTOR 用来控制分区的数量，根据如下公式：

```
splitSize = max(blocklet_size, (block_size - blocklet_size)) *
scale_factor
numPartitions = total size of input data / splitSize
```

  默认值为 3，range 的范围为[1, 300]。

  OPTIONS('SCALE_FACTOR'='10')

说明

- 如果 GLOBAL_SORT_PARTITIONS 和 SCALE_FACTOR 同时使用，只有 GLOBAL_SORT_PARTITIONS 生效。
- RANGE_COLUMN 合并默认使用 LOCAL_SORT。

使用场景

可使用下列语句从 CSV 文件加载 CarbonData table。

LOAD DATA *INPATH 'folder path' INTO TABLE tablename OPTIONS(property_name=property_value, ...);*

示例

data.csv 源文件数据如下所示：

```
ID,date,country,name,phonetype,serialname,salary
4,2014-01-21 00:00:00,xxx,aaa4,phone2435,ASD66902,15003
5,2014-01-22 00:00:00,xxx,aaa5,phone2441,ASD90633,15004
6,2014-03-07 00:00:00,xxx,aaa6,phone294,ASD59961,15005
```

CREATE TABLE carbontable(ID int, date Timestamp, country String, name String, phonetype String, serialname String,salary int) STORED AS carbondata;

LOAD DATA *inpath 'hdfs://hacluster/tmp/data.csv' INTO table carbontable*

options('DELIMITER'=',');

系统响应

可在 driver 日志中查看命令运行成功或失败。

1.6.2.2 UPDATE CARBON TABLE

命令功能

UPDATE 命令根据列表达式和可选的过滤条件更新 CarbonData 表。

命令格式

- 格式 1：

  UPDATE <CARBON TABLE> SET (column_name1, column_name2, ... column_name n) = (column1_expression , column2_expression , column3_expression ... column n_expression) [WHERE { <filter_condition> }];

- 格式 2：

  UPDATE <CARBON TABLE> SET (column_name1, column_name2,) = (select sourceColumn1, sourceColumn2 from sourceTable [WHERE { <filter_condition> }]) [WHERE { <filter_condition> }];

参数描述

表1-38 UPDATE 参数

参数	描述
CARBON TABLE	在其中执行更新操作的 CarbonData 表的名称。
column_name	待更新的目标列。
sourceColumn	需在目标表中更新的源表的列值。
sourceTable	将其记录更新到目标 CarbonData 表中的表。

注意事项

以下是使用 UPDATE 命令的条件：

- 如果源表中的多个输入行与目标表中的单行匹配，则 UPDATE 命令失败。
- 如果源表生成空记录，则 UPDATE 操作将在不更新表的情况下完成。
- 如果源表的行与目标表中任何已有的行不对应，则 UPDATE 操作将完成，不更新表。
- 具有二级索引的表不支持 UPDATE 命令。
- 在子查询中，如果源表和目标表相同，则 UPDATE 操作失败。
- 如果在 UPDATE 命令中使用的子查询包含聚合函数或 group by 子句，则 UPDATE 操作失败。

  例如，**update t_carbn01 a set (a.item_type_code, a.profit) = (select b.item_type_cd, sum(b.profit) from t_carbn01b b where item_type_cd =2 group by item_type_code);**

  其中，在子查询中使用聚合函数 sum(b.profit)和 group by 子句，因此 UPDATE 操作失败。
- 如果查询的表设置了 carbon.input.segments 属性，则 UPDATE 操作失败。要解决该问题，在查询前执行以下语句。

  语法：

  SET carbon.input.segments. <database_name>. <table_name>=*;

示例

- 示例 1：

  update carbonTable1 d set (d.column3,d.column5) = (select s.c33 ,s.c55 from sourceTable1 s where d.column1 = s.c11) where d.column1 = 'country' exists(select * from table3 o where o.c2 > 1);
- 示例 2：

  update carbonTable1 d set (c3) = (select s.c33 from sourceTable1 s where d.column1 = s.c11) where exists(select * from iud.other o where o.c2 > 1);
- 示例 3：

  update carbonTable1 set (c2, c5) = (c2 + 1, concat(c5 , "y"));
- 示例 4：

  update carbonTable1 d set (c2, c5) = (c2 + 1, "xyx") where d.column1 = 'india';
- 示例 5：

  update carbonTable1 d set (c2, c5) = (c2 + 1, "xyx") where d.column1 = 'india' and exists(select * from table3 o where o.column2 > 1);

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

1.6.2.3 DELETE RECORDS from CARBON TABLE

命令功能

DELETE RECORDS 命令从 CarbonData 表中删除记录。

命令格式

DELETE FROM CARBON_TABLE [WHERE expression];

参数描述

表1-39 DELETE RECORDS 参数

参数	描述
CARBON TABLE	在其中执行删除操作的 CarbonData 表的名称。

注意事项

- 删除 segment 将删除相应 segment 的所有二级索引。
- 如果查询的表设置了 carbon.input.segments 属性，则 DELETE 操作失败。要解决该问题，在查询前执行以下语句。

  语法：

  SET carbon.input.segments. <database_name>.<table_name>=*;

示例

- 示例 1：

  delete from columncarbonTable1 d where d.column1 = 'country';
- 示例 2：

  delete from dest where column1 IN ('country1', 'country2');
- 示例 3：

  delete from columncarbonTable1 where column1 IN (select column11 from sourceTable2);
- 示例 4：

  delete from columncarbonTable1 where column1 IN (select column11 from sourceTable2 where column1 = 'xxx');
- 示例 5：

  delete from columncarbonTable1 where column2 >= 4;

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

1.6.2.4 INSERT INTO CARBON TABLE

命令功能

INSERT 命令用于将 SELECT 查询结果加载到 CarbonData 表中。

命令格式

INSERT INTO [CARBON TABLE] [select query];

参数描述

表1-40 INSERT INTO 参数

参数	描述
CARBON TABLE	需要执行 INSERT 命令的 CarbonData 表的名称。
select query	Source 表上的 SELECT 查询（支持 CarbonData、Hive 和 Parquet 表）。

注意事项

- 表必须已经存在。
- 用户应属于数据加载组以执行数据加载操作。默认情况下，数据加载组被命名为“ficommon”。
- CarbonData 表不支持 Overwrite。
- 源表和目标表的数据类型应该相同，否则原表中的数据将被视为 Bad Records。
- **INSERT INTO** 命令不支持部分成功（partial success），如果存在 Bad Records，该命令会失败。
- 在从源表插入数据到目标表的过程中，无法在源表中加载或更新数据。

  若要在 INSERT 操作期间启用数据加载或更新，请将以下参数配置为“true”。

  “carbon.insert.persist.enable”=“true”

  默认上述参数配置为“false”。

说明

启用该参数将降低 INSERT 操作的性能。

示例

create table carbon01(a int,b string,c string) stored as carbondata;

insert into table carbon01 values(1,'a','aa'),(2,'b','bb'),(3,'c','cc');

create table carbon02(a int,b string,c string) stored as carbondata;

INSERT INTO carbon02 select * from carbon01 where a > 1;

系统响应

可在 driver 日志中查看命令运行成功或失败。

1.6.2.5 DELETE SEGMENT by ID

命令功能

DELETE SEGMENT by ID 命令是使用 Segment ID 来删除 segment。

命令格式

DELETE FROM TABLE db_name.table_name WHERE SEGMENT.ID IN (segment_id1,segment_id2);

参数描述

表1-41 DELETE LOAD 参数描述

参数	描述
segment_id	将要删除的 Segment 的 ID。
db_name	Database 名称，若未指定，则使用当前 database。
table_name	在给定的 database 中的表名。

注意事项

流式表不支持删除 segment。

示例

DELETE FROM TABLE CarbonDatabase.CarbonTable WHERE SEGMENT.ID IN (0);

DELETE FROM TABLE CarbonDatabase.CarbonTable WHERE SEGMENT.ID IN (0,5,8);

系统响应

操作成功或失败会在 CarbonData 日志中被记录。

1.6.2.6 DELETE SEGMENT by DATE

命令功能

DELETE SEGMENT by DATE 命令用于通过加载日期删除 CarbonData segment，在特定日期之前创建的 segment 将被删除。

命令格式

DELETE FROM TABLE db_name.table_name WHERE SEGMENT.STARTTIME BEFORE date_value;

参数描述

表1-42 DELETE SEGMENT by DATE 参数描述

参数	描述
db_name	Database 名称，若未指定，则使用当前 database。
table_name	给定 database 中的表名。
date_value	有效 Segment 加载启动时间。在这个指定日期前的 Segment 将被删除。

注意事项

流式表不支持删除 segment。

示例

DELETE FROM TABLE db_name.table_name WHERE SEGMENT.STARTTIME BEFORE '2017-07-01 12:07:20';

其中，STARTTIME 是不同负载的加载启动时间。

系统响应

操作成功或失败会在 CarbonData 日志中被记录。

1.6.2.7 SHOW SEGMENTS

命令功能

SHOW SEGMENTS 命令是用来向用户展示 CarbonData table 的 Segment。

命令格式

SHOW SEGMENTS FOR TABLE *[db_name.]table_name* **LIMIT** *number_of_loads;*

参数描述

表1-43 SHOW SEGMENTS FOR TABLE 参数描述

参数	描述

参数	描述
db_name	Database 名，若未指定，则使用当前 database。
table_name	在给定 database 中的表名。
number_of_loads	加载数的限制。

注意事项

无。

示例

create table carbon01(a int,b string,c string) stored as carbondata;

insert into table carbon01 select 1,'a','aa';

insert into table carbon01 select 2,'b','bb';

insert into table carbon01 select 3,'c','cc';

SHOW SEGMENTS FOR TABLE carbon01 LIMIT 2;

系统响应

```
+-----+----------+--------------------------+------------------+------------+------
------+-------------+--------------+--+
| ID  |  Status  |    Load Start Time       | Load Time Taken  | Partition  | Data Size
| Index Size  | File Format  |
+-----+----------+--------------------------+------------------+------------+------
------+-------------+--------------+--+
| 3   | Success  | 2020-09-28 22:53:26.336  | 3.726S           | {}         | 6.47KB
| 3.30KB      | columnar_v3  |
| 2   | Success  | 2020-09-28 22:53:01.702  | 6.688S           | {}         | 6.47KB
| 3.30KB      | columnar_v3  |
+-----+----------+--------------------------+------------------+------------+------
------+-------------+--------------+--+
```

1.6.2.8 CREATE SECONDARY INDEX

命令功能

该命令用于在 CarbonData 表中创建二级索引表。

命令格式

CREATE INDEX *index_name*

ON TABLE *[db_name.]table_name (col_name1, col_name2)*

AS *'carbondata'*

PROPERTIES *('table_blocksize'='256')*;

参数描述

表1-44 CREATE SECONDARY INDEX 参数

参数	描述
index_name	索引表的名称。表名称应由字母数字字符和下划线（_）特殊字符组成。
db_name	数据库的名称。数据库名称应由字母数字字符和下划线（_）特殊字符组成。
table_name	数据库中的表名称。表名称应由字母数字字符和下划线（_）特殊字符组成。
col_name	表中的列名称。支持多列。列名称应由字母数字字符和下划线（_）特殊字符组成。
table_blocksize	数据文件的 block 大小。更多详细信息，请参考•Block 大小。

注意事项

db_name 为可选项。

示例

create table productdb.productSalesTable(id int,price int,productName string,city string) stored as carbondata;

CREATE INDEX productNameIndexTable on table productdb.productSalesTable (productName,city) as 'carbondata' ;

上述示例将创建名为“productdb.productNameIndexTable”的二级表并加载所提供列的索引信息。

系统响应

将创建二级索引表，加载与所提供的列相关的索引信息到二级索引表中，并将成功消息记录在系统日志中。

1.6.2.9 SHOW SECONDARY INDEXES

命令功能

该命令用于在所提供的 CarbonData 表中显示所有的二级索引表。

命令格式

SHOW INDEXES ON db_name.table_name;

参数描述

表1-45 SHOW SECONDARY INDEXES 参数

参数	描述
db_name	数据库的名称。数据库名称应由字母数字字符和下划线（_）特殊字符组成
table_name	数据库中的表名称。表名称应由字母数字字符和下划线（_）特殊字符组成。

注意事项

db_name 为可选项。

示例

create table productdb.productSalesTable(id int,price int,productName string,city string) stored as carbondata;

CREATE INDEX productNameIndexTable on table productdb.productSalesTable (productName,city) as 'carbondata' ;

SHOW INDEXES ON productdb.productSalesTable;

系统响应

显示列出给定 CarbonData 表中的所有索引表和相应的索引列。

1.6.2.10 DROP SECONDARY INDEX

命令功能

该命令用于删除给定表中存在的二级索引表。

命令格式

DROP INDEX [IF EXISTS] index_name ON [db_name.]table_name;

参数描述

表1-46 DROP SECONDARY INDEX 参数

参数	描述
index_name	索引表的名称。表名称应由字母数字字符和下划线（_）特殊字符组成。
db_name	数据库的名称。若未指定，选择当前默认数据库。

参数	描述
table_name	需要删除的表的名称。

注意事项

该命令中 IF EXISTS 和 db_name 为可选项。

示例

DROP INDEX if exists productNameIndexTable ON productdb.productSalesTable;

系统响应

二级索引表将被删除，索引信息将在 CarbonData 表中被清除，删除成功的消息将记录在系统日志中。

1.6.2.11 CLEAN FILES

命令功能

DELETE SEGMENT 命令会将被删除的 segments 标识为 delete 状态；segment 合并后，旧的 segments 状态会变为 compacted。这些 segments 的数据文件不会从物理上删除。如果用户希望强制删除这些文件，可以使用 **CLEAN FILES** 命令。

但是，使用该命令可能会导致查询命令执行失败。

命令格式

CLEAN FILES FOR TABLE *[db_name.]table_name* ;

参数描述

表1-47 CLEAN FILES FOR TABLE 参数描述

参数	描述
db_name	数据库名称。数据库名称由字母，数字和下划线组成。
table_name	数据库中的表的名称。表名由字母，数字和下划线组成。

注意事项

无。

示例

添加 carbon 配置参数

```
carbon.clean.file.force.allowed = true
```

create table carbon01(a int,b string,c string) stored as carbondata;

insert into table carbon01 select 1,'a','aa';

insert into table carbon01 select 2,'b','bb';

delete from table carbon01 where segment.id in (0);

show segments for table carbon01;

CLEAN FILES FOR TABLE carbon01 options('force'='true');

show segments for table carbon01;

上述命令将从物理上删除所有 DELETE SEGMENT 命令删除的 segment 和合并后的旧的 segment。

系统响应

可在 driver 日志中查看命令运行成功或失败。

1.6.2.12 SET/RESET

命令功能

此命令用于动态 Add，Update，Display 或 Reset CarbonData 参数，而无需重新启动 driver。

命令格式

- Add 或 Update 参数值：
  SET *parameter_name=parameter_value*
  此命令用于添加或更新“parameter_name”的值。
- Display 参数值：
  SET *parameter_name*
  此命令用于显示指定的“parameter_name”的值。
- Display 会话参数：
  SET
  此命令显示所有支持的会话参数。
- Display 会话参数以及使用细节：
  SET -v
  此命令显示所有支持的会话参数及其使用细节。
- Reset 参数值：
  RESET
  此命令清除所有会话参数。

参数描述

表1-48 SET 参数描述

参数	描述
parameter_name	其值需要被动态添加（add），更新（update）或显示（display）的参数名称。
parameter_value	将要设置的“parameter_name”的新值。

注意事项

以下为分别使用 SET 和 RESET 命令进行动态设置或清除操作的属性：

表1-49 属性描述

属性	描述
carbon.options.bad.records.logger.enable	启用或禁用 bad record 日志记录。
carbon.options.bad.records.action	指定 bad record 操作，例如，强制（force），重定向（redirect），失败（fail）或忽略（ignore）。有关详细信息，请参阅•Bad Records 处理：
carbon.options.is.empty.data.bad.record	指定空数据是否被视为 bad record。有关详细信息，请参阅 Bad Records 处理：
carbon.options.sort.scope	指定数据加载期间排序的范围。
carbon.options.bad.record.path	指定需要存储 bad record 的 HDFS 路径。
carbon.custom.block.distribution	指定是否使用 Spark 或 CarbonData 的块分布功能。
enable.unsafe.sort	指定在数据加载期间是否使用不安全的排序。不安全的排序可减少数据加载操作期间的垃圾回收，从而实现更好的性能。
carbon.si.lookup.partialstring	当参数设置为 TRUE 时，二级索引采用 starts-with、ends-with、contains 和 LIKE 分区条件字符串。 当参数设置为 FALSE 时，二级索引只采用 starts-with 分区条件字符串。
carbon.input.segments	指定要查询的段 ID。 此属性允许您查询指定表的指定段。CarbonScan 将仅从指定的段 ID 读取数据。

属性	描述
	语法： “carbon.input.segments. <database_name>. <table_name> = < list of segment ids >” 如果用户想在多线程模式下查询指定段，可使用 **CarbonSession.threadSet** 代替 **SET** 语句。 语法： “CarbonSession.threadSet ("carbon.input.segments. <database_name>. <table_name>","< list of segment ids >");” **说明** 不建议在 **carbon.properties** 文件中设置该属性，因为所有会话都包含段列表，除非发生会话级或线程级覆盖。

示例

- 添加（Add）或更新（Update）：

  SET *enable.unsafe.sort=true*
- 显示（Display）属性值：

  SET *enable.unsafe.sort*
- 显示段 ID 列表，段状态和其他所需详细信息的示例，然后指定要读取的段列表：

  SHOW SEGMENTS FOR *TABLE carbontable1;*

  SET *carbon.input.segments.db.carbontable1 = 1, 3, 9;*
- 多线程模式查询指定段示例如下：

  CarbonSession.threadSet (*"carbon.input.segments.default.carbon_table_MulTI_THread", "1,3"*);
- 在多线程环境中使用 **CarbonSession.threadSet** 查询段示例如下（以 Scala 代码为例）：

```
def main(args: Array[String]) {
 Future
{            CarbonSession.threadSet("carbon.input.segments.default.carbon_tabl
e_MulTI_THread", "1")
     spark.sql("select count(empno) from carbon_table_MulTI_THread").show()
   }
}
```

- 重置（Reset）：

  RESET

系统响应

- 若运行成功，将记录在 driver 日志中。
- 若出现故障，将显示在用户界面（UI）中。

1.6.3 操作并发

1.6.1 DDL 和 1.6.2 DML 中的操作，执行前，需要获取对应的锁，各操作需要获取锁的情况见表 1-50，√表示需要获取该锁，一个操作仅在获取到所有需要获取的锁后，才能继续执行。

任意两个操作是否可以并发执行，可以通过如下方法确定：表 1-50 两行代表两个操作，这两行没有任意一列都标记√，即不存在某一列两行全为√。

表1-50 操作获取锁一览表

操作	METADATA_LOCK	COMPACTION_LOCK	DROP_TABLE_LOCK	DELETE_SEGMENT_LOCK	CLEAN_FILES_LOCK	ALTER_PARTITION_LOCK	UPDATE_LOCK	STREAMING_LOCK	CONCURRENT_LOAD_LOCK	SEGMENT_LOCK
CREATE TABLE	-	-	-	-	-	-	-	-	-	-
CREATE TABLE As SELECT	-	-	-	-	-	-	-	-	-	-
DROP TABLE	√	-	√	-	-	-	-	√	-	-
ALTER TABLE COMPACTION	-	√	-	-	-	-	√	-	-	-
TABLE RENAME	-	-	-	-	-	-	-	-	-	-
ADD COLUMNS	√	√	-	-	-	-	-	-	-	-

操作	METADATA_LOCK	COMPACTION_LOCK	DROP_TABLE_LOCK	DELETE_SEGMENT_LOCK	CLEAN_FILES_LOCK	ALTER_PARTITION_LOCK	UPDATE_LOCK	STREAMING_LOCK	CONCURRENT_LOAD_LOCK	SEGMENT_LOCK
DROP COLUMNS	√	√	-	-	-	-	-	-	-	-
CHANGE DATA TYPE	√	√	-	-	-	-	-	-	-	-
REFRESH TABLE	-	-	-	-	-	-	-	-	-	-
REGISTER INDEX TABLE	√	-	-	-	-	-	-	-	-	-
REFRESH INDEX	-	√	-	-	-	-	-	-	-	-
LOAD DATA/INSERT INTO	-	-	-	-	-	-	-	-	√	√
UPDATE CARBON TABLE	√	√	-	-	-	-	√	-	-	-
DELETE REC	√	√	-	-	-	-	√	-	-	-

操作	METADATA_LOCK	COMPACTION_LOCK	DROP_TABLE_LOCK	DELETE_SEGMENT_LOCK	CLEAN_FILES_LOCK	ALTER_PARTITION_LOCK	UPDATE_LOCK	STREAMING_LOCK	CONCURRENT_LOAD_LOCK	SEGMENT_LOCK
ORDS from CARBON TABLE										
DELETE SEGMENT by ID	-	-	-	√	√	-	-	-	-	-
DELETE SEGMENT by DATE	-	-	-	√	√	-	-	-	-	-
SHOW SEGMENTS	-	-	-	-	-	-	-	-	-	-
CREATE SECONDARY INDEX	√	√	-	√	-	-	-	-	-	-
SHOW SECONDARY INDEXES	-	-	-	-	-	-	-	-	-	-
DROP SECOND	√	-	√	-	-	-	-	-	-	-

操作	METADATA_LOCK	COMPACTION_LOCK	DROP_TABLE_LOCK	DELETE_SEGMENT_LOCK	CLEAN_FILES_LOCK	ALTER_PARTITION_LOCK	UPDATE_LOCK	STREAMING_LOCK	CONCURRENT_LOAD_LOCK	SEGMENT_LOCK
ARY INDEX										
CLEAN FILES	-	-	-	-	-	-	-	-	-	-
SET/ RESET	-	-	-	-	-	-	-	-	-	-
Add Hive Partition	-	-	-	-	-	-	-	-	-	-
Drop Hive Partition	√	√	√	√	√	√	-	-	-	-
Drop Partition	√	√	√	√	√	√	-	-	-	-
Alter table set	√	√	-	-	-	-	-	-	-	-

1.6.4 API

本章节描述 Segment 的 API 以及使用方法，所有方法在 org.apache.spark.util.CarbonSegmentUtil 类中。

如下方法已废弃：

```
/**
* Returns the valid segments for the query based on the filter condition
* present in carbonScanRdd.
*
* @param carbonScanRdd
* @return Array of valid segments
*/
@deprecated def getFilteredSegments(carbonScanRdd: CarbonScanRDD[InternalRow]):
Array[String];
```

使用方法

使用如下方法从查询语句中获得 CarbonScanRDD：

```
val df=carbon.sql("select * from table where age='12'")
val myscan=df.queryExecution.sparkPlan.collect {
case scan: CarbonDataSourceScan if scan.rdd.isInstanceOf[CarbonScanRDD[InternalRow]]
=> scan.rdd
case scan: RowDataSourceScanExec if
scan.rdd.isInstanceOf[CarbonScanRDD[InternalRow]] => scan.rdd
}.head
val carbonrdd=myscan.asInstanceOf[CarbonScanRDD[InternalRow]]
```

例子：

```
CarbonSegmentUtil.getFilteredSegments(carbonrdd)
```

可以通过传入 sql 语句来获取过滤后的 segment：

```
/**
* Returns an array of valid segment numbers based on the filter condition provided
in the sql
* NOTE: This API is supported only for SELECT Sql (insert into,ctas,.., is not
supported)
*
* @param sql
* @param sparkSession
* @return Array of valid segments
* @throws UnsupportedOperationException because Get Filter Segments API supports if
and only
* if only one carbon main table is present in query.
*/
def getFilteredSegments(sql: String, sparkSession: SparkSession): Array[String];
```

例子：

```
CarbonSegmentUtil.getFilteredSegments("select * from table where age='12'",
sparkSession)
```

传入数据库名和表名，获取会被合并的 segment 列表，得到的 segment 列表可以当做 getMergedLoadName 函数的参数传入：

```
/**
* Identifies all segments which can be merged with MAJOR compaction type.
* NOTE: This result can be passed to getMergedLoadName API to get the merged load
name.
*
* @param sparkSession
* @param tableName
* @param dbName
* @return list of LoadMetadataDetails
*/
def identifySegmentsToBeMerged(sparkSession: SparkSession,
tableName: String,
dbName: String) : util.List[LoadMetadataDetails];
```

例子：

```
CarbonSegmentUtil.identifySegmentsToBeMerged(sparkSession, "table_test","default")
```

传入数据库名、表名和自定义的 segment 列表，获取自定义合并操作会被合并的 segment 列表，得到的 segment 列表可以当做 getMergedLoadName 函数的参数传入：

```
/**
* Identifies all segments which can be merged with CUSTOM compaction type.
*  NOTE: This result can be passed to getMergedLoadName API to get the merged load
name.
*
* @param sparkSession
* @param tableName
* @param dbName
* @param customSegments
* @return list of LoadMetadataDetails
* @throws UnsupportedOperationException if customSegments is null or empty.
* @throws MalformedCarbonCommandException if segment does not exist or is not valid
*/
def identifySegmentsToBeMergedCustom(sparkSession: SparkSession,
tableName: String,
dbName: String,
customSegments: util.List[String]): util.List[LoadMetadataDetails];
```

例子：

```
val customSegments = new util.ArrayList[String]()
customSegments.add("1")
customSegments.add("2")
CarbonSegmentUtil.identifySegmentsToBeMergedCustom(sparkSession,
"table_test","default", customSegments)
```

给定 segment 列表，返回合并后新的导入名称：

```
/**
* Returns the Merged Load Name for given list of segments
*
* @param list of segments
* @return Merged Load Name
* @throws UnsupportedOperationException if list of segments is less than 1
*/
def getMergedLoadName(list: util.List[LoadMetadataDetails]): String;
```

例子：

```
val carbonTable = CarbonEnv.getCarbonTable(Option(databaseName),
tableName)(sparkSession)
val loadMetadataDetails =
SegmentStatusManager.readLoadMetadata(carbonTable.getMetadataPath)
CarbonSegmentUtil.getMergedLoadName(loadMetadataDetails.toList.asJava)
```

1.6.5 空间索引

快速示例

```
create table IF NOT EXISTS carbonTable
(
COLUMN1    BIGINT,
```

```
LONGITUDE    BIGINT,
LATITUDE    BIGINT,
COLUMN2    BIGINT,
COLUMN3    BIGINT
)
STORED AS carbondata
TBLPROPERTIES
('SPATIAL_INDEX.mygeohash.type'='geohash','SPATIAL_INDEX.mygeohash.sourcecolumns'='
longitude,
latitude','SPATIAL_INDEX.mygeohash.originLatitude'='39.850713','SPATIAL_INDEX.mygeo
hash.gridSize'='50','SPATIAL_INDEX.mygeohash.minLongitude'='115.828503','SPATIAL_IN
DEX.mygeohash.maxLongitude'='720.000000','SPATIAL_INDEX.mygeohash.minLatitude'='39.
850713','SPATIAL_INDEX.mygeohash.maxLatitude'='720.000000','SPATIAL_INDEX'='mygeoha
sh','SPATIAL_INDEX.mygeohash.conversionRatio'='1000000','SORT_COLUMNS'='column1,col
umn2,column3,latitude,longitude');
```

空间索引介绍

空间数据包括多维点、线、矩形、立方体、多边形和其他几何对象。空间数据对象占据空间的某一区域，称为空间范围，通过其位置和边界描述。空间数据可以是点数据，也可以是区域数据。

- 点数据：一个点具有一个空间范围，仅通过其位置描述。它不占用空间，没有相关的边界。点数据由二维空间中的点的集合组成。点可以存储为一对经纬度。
- 区域数据：一个区域有空间范围，有位置和边界。位置可以看作是一个定点在区域内的位置，例如它的质心。在二维中，边界可以可视化为一条线（有限区域，闭环）。区域数据包含一系列区域。

目前仅限于支持点数据，存储点数据。

经纬度可以编码为唯一的 GeoID。Geohash 是 Gustavo Niemeyer 发明的公共域地理编码系统，它将地理位置编码为一串由字母和数字组成的短字符串。它是一种分层的空间数据结构，把空间细分为网格形状的桶，是被称为 Z 阶曲线和通常称为空间填充曲线的许多应用之一。

点在多维中的 Z 值是简单地通过交织其坐标值的二进制表示来计算的，如下图所示。使用 Geohash 创建 GeoID 时，数据按照 GeoID 排序，而不是按照经纬度排序，数据按照空间就近性排序存储。

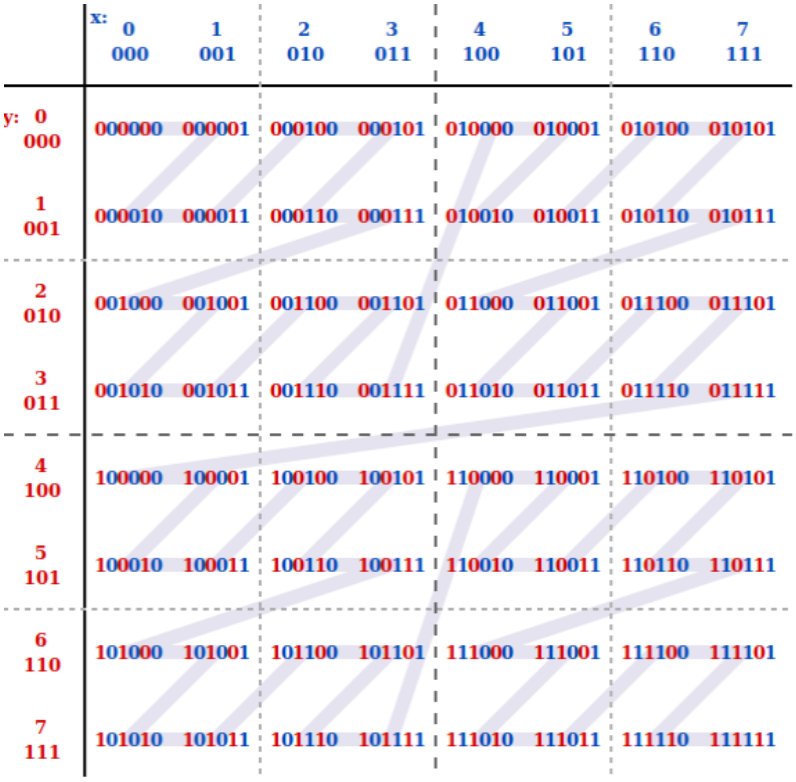

建表

GeoHash 编码：

```
create table IF NOT EXISTS carbonTable
(
...
`LONGITUDE`     BIGINT,
`LATITUDE`      BIGINT,
...
)
STORED AS carbondata
TBLPROPERTIES
('SPATIAL_INDEX.mygeohash.type'='geohash','SPATIAL_INDEX.mygeohash.sourcecolumns'='
longitude,
latitude','SPATIAL_INDEX.mygeohash.originLatitude'='xx.xxxxxx','SPATIAL_INDEX.mygeo
hash.gridSize'='xx','SPATIAL_INDEX.mygeohash.minLongitude'='xxx.xxxxxx','SPATIAL_IN
DEX.mygeohash.maxLongitude'='xxx.xxxxxx','SPATIAL_INDEX.mygeohash.minLatitude'='xx.
xxxxxx','SPATIAL_INDEX.mygeohash.maxLatitude'='xxx.xxxxxx','SPATIAL_INDEX'='mygeoha
sh','SPATIAL_INDEX.mygeohash.conversionRatio'='1000000','SORT_COLUMNS'='column1,col
umn2,column3,latitude,longitude');
```

SPATIAL_INDEX：自定义索引处理器。此处理程序允许用户从表结构列集合中创建新的列。新创建的列名与处理程序名相同。处理程序的 type 和 sourcecolumns 属性是必需的属性。目前，type 属性只支持“geohash”。Carbon 提供一个简单的默认实现类。用户可以通过扩展默认实现类来挂载 geohash 的自定义实现类。该默认处理程序还需提供以下的表属性：

- SPATIAL_INDEX.xxx.originLatitude：Double 类型，坐标原点纬度

- SPATIAL_INDEX.xxx.gridSize：Int 类型，栅格长度（米）
- SPATIAL_INDEX.xxx.minLongitude：Double 类型，最小经度
- SPATIAL_INDEX.xxx.maxLongitude：Double 类型，最大经度
- SPATIAL_INDEX.xxx.minLatitude：Double 类型，最小纬度
- SPATIAL_INDEX.xxx.maxLatitude：Double 类型，最大纬度
- SPATIAL_INDEX.xxx.conversionRatio：Int 类型，将经纬度小数值转换为整型值

用户可以按照上述格式为处理程序添加自己的表属性，并在自定义实现类中访问它们。originLatitude，gridSize 及 conversionRatio 是必选参数，其余属性在 Carbon 中都是可选的。可以使用“SPATIAL_INDEX.xxx.class”属性指定它们的实现类。

默认实现类可以为每一行的 sourcecolumns 生成 handler 列值，并且支持基于 sourcecolumns 的过滤条件查询。生成的 handler 列对用户不可见。除 SORT_COLUMNS 表属性外，任何 DDL 命令和属性都不允许包含 handler 列。

说明

- 生成的 handler 列默认被视为排序列。如果 SORT_COLUMNS 不包含任何 sourcecolumns，则将 handler 列追加到现有的 SORT_COLUMNS 最后。如果在 SORT_COLUMNS 中已经指定了该 handler 列，则它在 SORT_COLUMNS 的顺序将保持不变。
- 如果 SORT_COLUMNS 包含任意的 sourcecolumns，但是没有包含 handler 列，则 handler 列将自动插入到 SORT_COLUMNS 中的 sourcecolumns 之前。
- 如果 SORT_COLUMNS 需要包含任意的 sourcecolumns，那么需要保证 handler 列出现在 sourcecolumns 之前，这样 handler 列才能在排序中生效。

GeoSOT 编码：

```
CREATE TABLE carbontable(
…
longitude DOUBLE,
latitude DOUBLE,
…)
STORED AS carbondata
TBLPROPERTIES ('SPATIAL_INDEX'='xxx',
'SPATIAL_INDEX.xxx.type'='geosot',
'SPATIAL_INDEX.xxx.sourcecolumns'='longitude, latitude',
'SPATIAL_INDEX.xxx.level'='21',
'SPATIAL_INDEX.xxx.class'='org.apache.carbondata.geo.GeoSOTIndex')
```

表1-51 参数说明

参数	说明
SPATIAL_INDEX	指定表属性“SPATIAL_INDEX”，空间索引列，列名与该属性的值相同。
SPATIAL_INDEX.xxx.type	必填参数，值为 geosot。
SPATIAL_INDEX.xxx.sourcecolumns	必填参数，空间索引列属性，指定计算空间索引的源数据列，需为 2 个存在的列，且类型为 double。
SPATIAL_INDEX.xxx.level	可选参数，用于计算空间索引列。默认值为 17，因为该值可以计算出足够精确的结果，同时拥有良好的性

参数	说明
	能。
SPATIAL_INDEX.xxx.class	可选参数，用于指定 geo 的实现类，默认为“org.apache.carbondata.geo.GeoSOTIndex”。

使用示例：

```
create table geosot(
timevalue bigint,
longitude double,
latitude double)
stored as carbondata
TBLPROPERTIES ('SPATIAL_INDEX'='mygeosot',
'SPATIAL_INDEX.mygeosot.type'='geosot',
'SPATIAL_INDEX.mygeosot.level'='21',
'SPATIAL_INDEX.mygeosot.sourcecolumns'='longitude, latitude');
```

准备数据

- 准备数据文件 1：geosotdata.csv

```
timevalue,longitude,latitude
1575428400000,116.285807,40.084087
1575428400000,116.372142,40.129503
1575428400000,116.187332,39.979316
1575428400000,116.337069,39.951887
1575428400000,116.359102,40.154684
1575428400000,116.736367,39.970323
1575428400000,116.720179,40.009893
1575428400000,116.346961,40.13355
1575428400000,116.302895,39.930753
1575428400000,116.288955,39.999101
1575428400000,116.17609,40.129953
1575428400000,116.725575,39.981115
1575428400000,116.266922,40.179415
1575428400000,116.353706,40.156483
1575428400000,116.362699,39.942444
1575428400000,116.325378,39.963129
```

- 准备数据文件 2：geosotdata2.csv

```
timevalue,longitude,latitude
1575428400000,120.17708,30.326882
1575428400000,120.180685,30.326327
1575428400000,120.184976,30.327105
1575428400000,120.189311,30.327549
1575428400000,120.19446,30.329698
1575428400000,120.186965,30.329133
1575428400000,120.177481,30.328911
1575428400000,120.169713,30.325614
1575428400000,120.164563,30.322243
1575428400000,120.171558,30.319613
1575428400000,120.176365,30.320687
1575428400000,120.179669,30.323688
```

```
1575428400000,120.181001,30.320761
1575428400000,120.187094,30.32354
1575428400000,120.193574,30.323651
1575428400000,120.186192,30.320132
1575428400000,120.190055,30.317464
1575428400000,120.195376,30.318094
1575428400000,120.160786,30.317094
1575428400000,120.168211,30.318057
1575428400000,120.173618,30.316612
1575428400000,120.181001,30.317316
1575428400000,120.185162,30.315908
1575428400000,120.192415,30.315871
1575428400000,120.161902,30.325614
1575428400000,120.164306,30.328096
1575428400000,120.197093,30.325985
1575428400000,120.19602,30.321651
1575428400000,120.198638,30.32354
1575428400000,120.165421,30.314834
```

导入数据

GeoHash 默认实现类扩展自定义索引抽象类。如果没有配置 handler 属性为自定义的实现类，则使用默认的实现类。用户可以通过扩展默认实现类来挂载 geohash 的自定义实现类。自定义索引抽象类方法包括：

- Init 方法，用来提取、验证和存储 handler 属性。在失败时抛出异常，并显示错误信息。
- Generate 方法，用来生成索引。它为每行数据生成一个索引数据。
- Query 方法，用来对给定输入生成索引值范围列表。

导入命令同普通 Carbon 表：

LOAD DATA inpath '/tmp/*geosotdata.csv*' INTO TABLE geosot OPTIONS ('DELIMITER'= ',');

LOAD DATA inpath '/tmp/*geosotdata2.csv*' INTO TABLE geosot OPTIONS ('DELIMITER'= ',');

说明

geosotdata.csv 和 geosotdata2.csv 表请参考准备数据。

不规则空间集合的聚合查询

查询语句及 Filter UDF

- 根据 polygon 过滤数据

  IN_POLYGON(pointList)

  UDF 输入参数：

参数	类型	说明
pointList	String	将多个点输入为一个字符串，每个点以 **longitude latitude** 表示。经纬度间用空格

参数	类型	说明
		分隔，每对经纬度用逗号分隔，字符串首尾经纬度一致。

UDF 输出参数：

参数	类型	说明
inOrNot	Boolean	判断数据是否在指定的 polygon_list 之内。

使用示例：

```
select longitude, latitude from geosot where IN_POLYGON('116.321011 40.123503, 116.137676 39.947911, 116.560993 39.935276, 116.321011 40.123503');
```

- 根据 polygon 列表过滤数据。

  IN_POLYGON_LIST(polygonList, opType)

  UDF 输入参数：

参数	类型	说明
polygonList	String	将多个 polygon 输入为一个字符串，每个 polygon 以 **POLYGON ((longitude1 latitude1, longitude2 latitude2, …))**表示。注意“POLYGON”后有空格，经纬度间用空格分隔，每对经纬度用逗号分隔，一个 polygon 的首尾经纬度一致。IN_POLYGON_LIST 必须输入 2 个以上 polygon。 一个 polygon 示例： `POLYGON ((116.137676 40.163503, 116.137676 39.935276, 116.560993 39.935276, 116.137676 40.163503))`
opType	String	对多个 polygon 进行并交差操作。 目前支持的操作类型： • OR：A ∪ B ∪ C (假设输入了三个 POLYGON，A、B、C) • AND：A ∩ B ∩ C

UDF 输出参数：

参数	类型	说明
inOrNot	Boolean	判断数据是否在指定的 polygon_list 之

参数	类型	说明
		内。

使用示例：

```
select longitude, latitude from geosot where IN_POLYGON_LIST('POLYGON
((120.176433 30.327431,120.171283 30.322245,120.181411 30.314540, 120.190509
30.321653,120.185188 30.329358,120.176433 30.327431)), POLYGON ((120.191603
30.328946,120.184179 30.327465,120.181819 30.321464, 120.190359
30.315388,120.199242 30.324464,120.191603 30.328946))', 'OR');
```

- 根据 polyline 列表过滤数据。

  IN_POLYLINE_LIST(polylineList, bufferInMeter)

  UDF 输入参数：

参数	类型	说明
polylineList	String	将多个 polyline 输入为一个字符串，每个 polyline 以 **LINESTRING (longitude1 latitude1, longitude2 latitude2, …)**表示。注意“LINESTRING”后有空格，经纬度间用空格分隔，每组经纬度用逗号分隔。 对多个 polyline 区域内的数据会输出并集结果。 一个 polyline 示例： `LINESTRING (116.137676 40.163503, 116.137676 39.935276, 116.260993 39.935276)`
bufferInMeter	Float	polyline 的 buffer 距离，单位为米。末端使用直角创建缓冲区。

UDF 输出参数：

参数	类型	说明
inOrNot	Boolean	判断数据是否在指定的 polyline_list 之内。

使用示例：

```
select longitude, latitude from geosot where IN_POLYLINE_LIST('LINESTRING
(120.184179 30.327465, 120.191603 30.328946, 120.199242 30.324464, 120.190359
30.315388)', 65);
```

- 根据 GeoId 区间列表过滤数据。

  IN_POLYGON_RANGE_LIST(polygonRangeList, opType)

UDF 输入参数：

参数	类型	说明
polygonRangeList	String	将多个 rangeList 输入为一个字符串，每个 rangeList 以 **RANGELIST (startGeoId1 endGeoId1, startGeoId2 endGeoId2, ···)**表示。注意“RANGELIST”后有空格，首尾 GeoId 间用空格分隔，每组 GeoId range 用逗号分隔。 一个 rangeList 示例： `RANGELIST (855279368848 855279368850, 855280799610 855280799612, 855282156300 855282157400)`
opType	String	对多个 rangeList 进行并交差操作。 目前支持的操作类型： • OR：A U B U C (假设输入了三个 RANGELIST，A、B、C) • AND：A ∩ B ∩ C

UDF 输出参数：

参数	类型	说明
inOrNot	Boolean	判断数据是否在指定的 polyRange_list 之内。

使用示例：

```
select mygeosot, longitude, latitude from geosot where
IN_POLYGON_RANGE_LIST('RANGELIST (526549722865860608 526549722865860618,
532555655580483584 532555655580483594)', 'OR');
```

- polygon 连接查询

  IN_POLYGON_JOIN(GEO_HASH_INDEX_COLUMN, POLYGON_COLUMN)

  两张表做 join 查询，一张表为空间数据表（有经纬度列和 GeoHashIndex 列），另一张表为维度表，保存 polygon 数据。

  查询使用 IN_POLYGON_JOIN UDF，参数 GEO_HASH_INDEX_COLUMN 和 polygon 表的 POLYGON_COLUMN。Polygon_column 列是一系列的点（经纬度列）。Polygon 表的每一行的第一个点和最后一个点必须是相同的。Polygon 表的每一行的所有点连接起来形成一个封闭的几何对象。

  UDF 输入参数：

参数	类型	说明
GEO_HASH_INDE	Long	空间数据表的 GeoHashIndex 列。

参数	类型	说明
X_COLUMN		
POLYGON_COLUMN	String	Polygon 表的 polygon 列，数据为 polygon 的字符串表示。例如，一个 polygon 是 POLYGON ((longitude1 latitude1, longitude2 latitude2, …))

使用示例：

```
CREATE TABLE polygonTable(
polygon string,
poiType string,
poiId String)
STORED AS carbondata;

insert into polygonTable select 'POLYGON ((120.176433 30.327431,120.171283
30.322245, 120.181411 30.314540,120.190509 30.321653,120.185188
30.329358,120.176433 30.327431))','abc','1';

insert into polygonTable select 'POLYGON ((120.191603 30.328946,120.184179
30.327465, 120.181819 30.321464,120.190359 30.315388,120.199242
30.324464,120.191603 30.328946))','abc','2';

select t1.longitude,t1.latitude from geosot t1
inner join
(select polygon,poiId from polygonTable where poitype='abc') t2
on in_polygon_join(t1.mygeosot,t2.polygon) group by t1.longitude,t1.latitude;
```

- range_list 连接查询

  IN_POLYGON_JOIN_RANGE_LIST(GEO_HASH_INDEX_COLUMN, POLYGON_COLUMN)

  同 IN_POLYGON_JOIN，使用 IN_POLYGON_JOIN_RANGE_LIST UDF 关联空间数据表和 polygon 维度表，关联基于 Polygon_RangeList。直接使用 range list 可以避免 polygon 到 range list 的转换。

  UDF 输入参数：

参数	类型	说明
GEO_HASH_INDEX_COLUMN	Long	空间数据表的 GeoHashIndex 列。
POLYGON_COLUMN	String	Polygon 表的 rangelist 列，数据为 rangeList 的字符串。例如，一个 rangelist 是 RANGELIST (startGeoId1 endGeoId1, startGeoId2 endGeoId2, …)

使用示例：

```
CREATE TABLE polygonTable(
polygon string,
```

```
poiType string,
poiId String)
STORED AS carbondata;

insert into polygonTable select 'RANGELIST (526546455897309184
526546455897309284, 526549831217315840 526549831217315850, 532555655580483534
532555655580483584)','xyz','2';

select t1.*
from geosot t1
inner join
(select polygon,poiId from polygonTable where poitype='xyz') t2
on in_polygon_join_range_list(t1.mygeosot,t2.polygon);
```

空间索引工具类 UDF

- GeoID 转栅格行列号。

  GeoIdToGridXy(geoId)

  UDF 输入参数：

参数	类型	说明
geoId	Long	根据 GeoId 计算栅格行列号。

  UDF 输出参数：

参数	类型	说明
gridArray	Array[Int]	返回该 geoid 所包含的栅格行列号，以数组的方式返回，第一位为行，第二位为列。

  使用示例：

```
select longitude, latitude, mygeohash, GeoIdToGridXy(mygeohash) as GridXY from
geoTable;
```

- 经纬度转 GeoID。

  LatLngToGeoId(latitude, longitude oriLatitude, gridSize)

  UDF 输入参数：

参数	类型	说明
longitude	Long	经度，注：转换后的整数类型。
latitude	Long	纬度，注：转换后的整数类型。
oriLatitude	Double	原点纬度，计算 GeoId 需要参数。
gridSize	Int	栅格大小，计算 GeoId 需要参数。

UDF 输出参数：

参数	类型	说明
geoId	Long	通过编码获得一个表示经纬度的数。

使用示例：

```
select longitude, latitude, mygeohash, LatLngToGeoId(latitude, longitude,
39.832277, 50) as geoId from geoTable;
```

- GeoID 转经纬度。

  GeoIdToLatLng(geoId, oriLatitude, gridSize)

  UDF 输入参数：

参数	类型	说明
geoId	Long	根据 GeoId 计算经纬度。
oriLatitude	Double	原点纬度，计算经纬度需要参数。
gridSize	Int	栅格大小，计算经纬度需要参数。

说明

由于 GeoId 由栅格坐标生成，坐标为栅格中心点，则计算出的经纬度是栅格中心点经纬度，与生成该 GeoId 的经纬度可能有[0 度~半个栅格度数]的误差。

UDF 输出参数：

参数	类型	说明
latitudeAndLongitude	Array[Double]	返回该 geoid 所表示的栅格的中心点的经纬度坐标，以数组的方式返回，第一位为 latitude，第二位为 longitude。

使用示例：

```
select longitude, latitude, mygeohash, GeoIdToLatLng(mygeohash, 39.832277, 50)
as LatitudeAndLongitude from geoTable;
```

- 计算金字塔模型向上汇聚一层的 GeoID。

  ToUpperLayerGeoId(geoId)

  UDF 输入参数：

参数	类型	说明
geoId	Long	根据输入 GeoId 计算金字塔模型上一层 GeoId。

UDF 输出参数：

参数	类型	说明
geoId	Long	金字塔模型上一层 GeoId。

使用示例：

```
select longitude, latitude, mygeohash, ToUpperLayerGeoId(mygeohash) as
upperLayerGeoId from geoTable;
```

- 输入 polygon 获得 GeoID 范围列表。

  ToRangeList(polygon, oriLatitude, gridSize)

  UDF 输入参数：

参数	类型	说明
polygon	String	输入 polygon 字符串，用一组经纬度表示。 经纬度间用空格分隔，每对经纬度间用逗号分隔，首尾经纬度一致。
oriLatitude	Double	原点纬度，计算 GeoId 需要参数。
gridSize	Int	栅格大小，计算 GeoId 需要参数。

UDF 输出参数：

参数	类型	说明
geoIdList	Buffer[Array[Long]]	将 polygon 转换为一串 geoid 的范围列表。

使用示例：

```
select ToRangeList('116.321011 40.123503, 116.137676 39.947911, 116.560993
39.935276, 116.321011 40.123503', 39.832277, 50) as rangeList from geoTable;
```

- 计算金字塔模型向上汇聚一层的 longitude。

  ToUpperLongitude (longitude, gridSize, oriLat)

  UDF 输入参数：

参数	类型	说明
longitude	Long	输入 longitude，用一个长整型表示。
gridSize	Int	栅格大小，计算 longitude 需要参数。
oriLatitude	Double	原点纬度，计算 longitude 需要参数。

UDF 输出参数：

参数	类型	说明
longitude	Long	返回上一层的 longitude。

使用示例：

```
select ToUpperLongitude (-23575161504L, 50, 39.832277) as upperLongitude from geoTable;
```

- 计算金字塔模型向上汇聚一层的 Latitude。

  ToUpperLatitude(Latitude, gridSize, oriLat)

  UDF 输入参数：

参数	类型	说明
latitude	Long	输入 latitude，用一个长整型表示。
gridSize	Int	栅格大小，计算 latitude 需要参数。
oriLatitude	Double	原点纬度，计算 latitude 需要参数。

UDF 输出参数：

参数	类型	说明
Latitude	Long	返回上一层的 latitude。

使用示例：

```
select ToUpperLatitude (-23575161504L, 50, 39.832277) as upperLatitude from geoTable;
```

- 经纬度转 GeoSOT

  LatLngToGridCode(latitude, longitude, level)

  UDF 输入参数：

参数	类型	说明
latitude	Double	输入 latitude。
longitude	Double	输入 longitude。
level	Int	输入 level，值区间[0-32]。

UDF 输出参数：

参数	类型	说明
geoId	Long	通过 GeoSOT 编码获得一个表示经纬度的数。

使用示例：

```
select LatLngToGridCode(39.930753, 116.302895, 21) as geoId;
```

1.7 CarbonData 故障处理

1.7.1 当在 Filter 中使用 Big Double 类型数值时，过滤结果与 Hive 不一致

现象描述

当在 filter 中使用更高精度的 double 数据类型的数值时，过滤结果没有按照所使用的 filter 的要求返回正确的值。

可能原因

如果 filter 使用更高精度的 double 数据类型的数值，系统将会对该值四舍五入进行比较，因此在这种情况下，即使小数部分不同，系统仍然会认为 double 数据类型的值是相同的。

定位思路

无。

处理步骤

当需要高精度的数据比较时，可以使用 Decimal 数据类型的数值，例如，在财务应用程序中，equality 和 inequality 检查，以及取整运算，均可使用 Decimal 数据类型的数值。

参考信息

无。

1.7.2 查询性能下降

现象描述

在不同的查询周期内运行查询功能，查询性能会有起伏。

可能原因

在处理数据加载时，为每个 executor 程序实例配置的内存不足，可能会产生更多的 Java GC（垃圾收集）。当 GC 发生时，会发现查询性能下降。

定位思路

在 Spark UI 上，会发现某些 executors 的 GC 时间明显比其他 executors 高，或者所有的 executors 都表现出高 GC 时间。

处理步骤

登录 Manager 页面，选择“集群 > 服务 > Spark2x > 配置 > 全部配置”，在搜索框搜索“spark.executor.memory”，通过参数“spark.executor.memory”配置更高的内存值。

参考信息

无。

1.8 CarbonData FAQ

1.8.1 为什么对 decimal 数据类型进行带过滤条件的查询时会出现异常输出？

问题

当对 decimal 数据类型进行带过滤条件的查询时，输出结果不正确。

例如，

select * from carbon_table where num = 1234567890123456.22;

输出结果：

```
+------+----------------------+--+
| name |       num            |
+------+----------------------+--+
| IAA  | 1234567890123456.22 |
| IAA  | 1234567890123456.21 |
+------+----------------------+--+
```

回答

为了得到准确的输出结果，需在数字后面加上“BD”。

例如，

select * from carbon_table where num = 1234567890123456.22BD;

输出结果：

```
+------+----------------------+--+
| name |       num            |
```

```
+------+----------------------+--+
| IAA  | 1234567890123456.22 |
+------+----------------------+--+
```

1.8.2 如何避免对历史数据进行 minor compaction？

问题

如何避免对历史数据进行 minor compaction？

回答

如果要先加载历史数据，后加载增量数据，则以下步骤可避免对历史数据进行 minor compaction：

1. 加载所有历史数据。
2. 将 major compaction 大小配置为小于历史数据 segment 大小的值。
3. 对历史数据进行一次 major compaction，之后将不会考虑这些 segments 进行 minor compaction。
4. 加载增量数据。
5. 用户可以根据自己的需要配置 minor compaction 阈值。

配置示例和预期输出：

1. 用户将所有历史数据加载到 CarbonData，此数据的一个 segment 的大小假定为 500GB。
2. 用户设置 major compaction 参数的阈值：“carbon.major.compaction.size” = “491520（480gb * 1024）”。其中，*491520* 可配置。
3. 运行 major compaction。由于每个 segment 的大小超过配置值的大小，因此这些 segments 将会被压缩。
4. 加载增量负载。
5. 配置 minor compaction 参数的阈值：“compaction.level.threshold” = “6,6”。
6. 运行 minor compaction。此时只考虑增量负载。

1.8.3 如何在 CarbonData 数据加载时修改默认的组名？

问题

如何在 CarbonData 数据加载时修改默认的组名？

回答

CarbonData 数据加载时，默认的组名为“ficommon”。可以根据需要修改默认的组名。

1. 编辑“carbon.properties”文件。
2. 根据需要修改关键字“carbon.dataload.group.name”的值。其默认值为“ficommon”。

1.8.4 为什么 INSERT INTO CARBON TABLE 失败？

问题

为什么 ***INSERT INTO CARBON TABLE*** 命令无法在日志文件中记录以下信息？

```
Data load failed due to bad record
```

回答

在以下场景中，**INSERT INTO CARBON TABLE** 命令会失败：

- 当源表和目标表的列数据类型不同时，源表中的数据将被视为 Bad Records，则 INSERT INTO 命令会失败。
- 源列上的 aggregartion 函数的结果超过目标列的最大范围，则 INSERT INTO 命令会失败。

  解决方法：

  在进行插入操作时，可在对应的列上使用 cast 函数。

  示例：

  a. 使用 DESCRIBE 命令查询目标表和源表。

  DESCRIBE *newcarbontable*;

  结果：

  ```
  col1 int
  col2 bigint
  ```

  DESCRIBE *sourcetable*;

  结果：

  ```
  col1 int
  col2 int
  ```

  b. 添加 cast 函数以将 BigInt 类型数据转换为 Integer 类型数据。

  INSERT INTO *newcarbontable select col1, cast(col2 as integer) from sourcetable*;

1.8.5 为什么含转义字符的输入数据记录到 Bad Records 中的值与原始数据不同？

问题

为什么含转义字符的输入数据记录到 Bad Records 中的值与原始数据不同？

回答

转义字符以反斜线"\"开头，后跟一个或几个字符。如果输入记录包含类似\t，\b，\n，\r，\f，\'，\"，\\的转义字符，Java 将把转义符'\'和它后面的字符一起处理得到转义后的值。

例如：如果 CSV 数据类似“2010\\10,test”，将这两列插入“String,int”类型时，因为“test”无法转换为 int 类型，表会将这条记录重定向到 Bad Records 中。但记录到 Bad Records 中的值为“2010\10”，Java 会将原始数据中的“\\”转义为“\”。

1.8.6 为什么 Bad Records 导致数据加载性能降低？

问题

为什么 Bad Records 导致数据加载性能降低？

回答

如果数据中存在 Bad Records，并且“BAD_RECORDS_LOGGER_ENABLE”参数值为“true”或“BAD_RECORDS_ACTION”参数值为“redirect”，则由于将失败原因写入日志文件中或将 Bad Records 重定向到原始 CSV 文件中导致的额外的 I/O 开销，数据加载性能就会降低 。

1.8.7 当初始 Executor 为 0 时，为什么 INSERT INTO/LOAD DATA 任务分配不正确，打开的 task 少于可用的 Executor？

问题

当初始 Executor 为 0 时，为什么 INSERT INTO/LOAD DATA 任务分配不正确，打开的 task 少于可用的 Executor？

回答

在这种场景下，CarbonData 会给每个节点分配一个 INSERT INTO 或 LOAD DATA 任务。如果 Executor 不是不同的节点分配的，CarbonData 将会启动较少的 task。

解决措施：

您可以适当增大 Executor 内存和 Executor 核数，以便 YARN 可以在每个节点上启动一个 Executor。具体的配置方法如下：

1. 配置 Executor 核数。
   - 将“spark-defaults.conf”中的“spark.executor.cores”配置项或者“spark-env.sh”中的“SPARK_EXECUTOR_CORES”配置项设置为合适大小。
   - 在使用 spark-submit 命令时，添加“--executor-cores NUM”参数设置核数。
2. 配置 Executor 内存。
   - 将“spark-defaults.conf”中的“spark.executor.memory”配置项或者“spark-env.sh”中的“SPARK_EXECUTOR_MEMORY”配置项设置为合适大小。
   - 在使用 spark-submit 命令时，添加“--executor-memory MEM”参数设置内存。

1.8.8 为什么并行度大于待处理的 block 数目时，CarbonData 仍需要额外的 executor？

问题

为什么并行度大于待处理的 block 数目时，CarbonData 仍需要额外的 executor？

回答

CarbonData 块分布对于数据处理进行了如下优化：

1. 优化数据处理并行度。
2. 优化了读取块数据的并行性。

为了优化并行数据处理及并行读取块数据，CarbonData 根据块的局域性申请 executor，因此 CarbonData 可获得所有节点上的 executor。

为了优化并行数据处理及并行读取块数据，运用动态分配的用户需配置以下特性。

1. 使用参数“spark.dynamicAllocation.executorIdleTimeout”并将此参数值设置为 15min（或平均查询时间）。
2. 正确配置参数“spark.dynamicAllocation.maxExecutors”，不推荐使用默认值（2048），否则 CarbonData 将申请最大数量的 executor。
3. 对于更大的集群，配置参数“carbon.dynamicAllocation.schedulerTimeout”为 10～15sec，默认值为 5sec。
4. 配置参数“carbon.scheduler.minRegisteredResourcesRatio”为 0.1～1.0，默认值为 0.8。只要达到此参数值，块分布可启动。

1.8.9 为什么在 off heap 时数据加载失败？

问题

为什么在 off heap 时数据加载失败？

回答

YARN Resource Manager 将（Java 堆内存 + “spark.yarn.am.memoryOverhead”）作为内存限制，因此在 off heap 时，内存可能会超出此限制。您需配置参数“spark.yarn.am.memoryOverhead”以增加 memory。

1.8.10 为什么创建 Hive 表失败？

问题

为什么创建 Hive 表失败？

回答

当源表或子查询具有大数据量的 Partition 时，创建 Hive 表失败。执行查询需要很多的 task，此时输出的文件数就会很多，从而导致 driver OOM。

可以在创建 Hive 表的语句中增加 ***distribute by*** 子句来解决这个问题，其中 ***distribute by*** 的字段要选取合适的 cardinality（即 distinct 值的个数）。

distribute by 子句限制了 Hive 表的 Partition 数量。增加 ***distribute by*** 子句后，最终的输出文件数取决于指定列的 cardinality 和“spark.sql.shuffle.partitions”参数值。但如果 distribute by 的字段的 cardinality 值很小，例如，“spark.sql.shuffle.partitions”参数值为 200，但 ***distribute by*** 字段的 cardinality 只有 100，则输出的 200 个文件中，只有其中 100 个文件有数据，剩下的 100 个文件为空文件。也就是说，如果选取的字段的 cardinality 过低，如 1，则会造成严重的数据倾斜，从而严重影响查询性能。

因此，建议选取的 distribute by 字段的 cardinality 个数要大于“spark.sql.shuffle.partitions”参数，可大于 2~3 倍。

示例：

create table hivetable1 as select * from sourcetable1 distribute by col_age;

1.8.11 如何在不同的 namespaces 上逻辑地分割数据

问题

如何在不同的 namespaces 上逻辑地分割数据？

回答

- 配置：

  要在不同 namespaces 之间逻辑地分割数据，必须更新 HDFS，Hive 和 Spark 的“core-site.xml”文件中的以下配置。

  说明

  改变 Hive 组件将改变 carbonstore 的位置和 warehouse 的位置。

  - HDFS 中的配置
    - fs.defaultFS - 默认文件系统的名称。URI 模式必须设置为“viewfs”。当使用“viewfs”模式时，权限部分必须是“ClusterX”。
    - fs.viewfs.mountable.ClusterX.homedir - 主目录基本路径。每个用户都可以使用在“FileSystem/FileContext”中定义的 getHomeDirectory()方法访问其主目录。
    - fs.viewfs.mountable.default.link.<dir_name> - ViewFS 安装表。

    示例：

    ```
    <property>
    <name>fs.defaultFS</name>
    <value>viewfs://ClusterX/</value>
    </property>
    <property>
    <name>fs.viewfs.mounttable.ClusterX.link./folder1</name>
    ```

```
<value>hdfs://NS1/folder1</value>
</property>
<property>
<name>fs.viewfs.mounttable.ClusterX.link./folder2</name>
<value>hdfs://NS2/folder2</value>
</property>
```

- Hive 和 Spark 中的配置

  fs.defaultFS - 默认文件系统的名称。URI 模式必须设置为“viewfs”。 当使用“viewfs”模式时，权限部分必须是“ClusterX”。

- 命令格式：

  LOAD DATA INPATH *'path to data' INTO TABLE table_name OPTIONS ('...');*

  说明

  每当 Spark 配置有 viewFS 文件系统时，当尝试从 HDFS 加载数据时，用户必须在 ***LOAD*** 语句中指定如“viewfs://”这样的路径或相对路径作为文件路径。

- 示例：
  - viewFS 路径举例：

    LOAD DATA INPATH *'viewfs://ClusterX/dir/data.csv' INTO TABLE table_name OPTIONS ('...');*
  - 相对路径举例：

    LOAD DATA INPATH *'/apps/input_data1.txt'* ***INTO TABLE*** *table_name*;

1.8.12 为什么 drop 数据库抛出 Missing Privileges 异常？

问题

为什么 drop 数据库抛出以下异常？

```
Error: org.apache.spark.sql.AnalysisException: Missing Privileges;(State=,code=0)
```

回答

当数据库的所有者执行 ***drop database <database_name> cascade*** 命令（包含其他用户创建的表）时，会抛出此错误。

1.8.13 为什么在 Spark Shell 中不能执行更新命令？

问题

为什么在 Spark Shell 中不能执行更新命令？

回答

本文档中给出的语法和示例是关于 Beeline 的命令，而不是 Spark Shell 中的命令。

若要在 Spark Shell 中使用更新命令，可以使用以下语法。

- 语法 1

<carbon_context>.sql("UPDATE <CARBON TABLE> SET (column_name1, column_name2, ... column_name n) = (column1_expression , column2_expression , column3_expression ... column n_expression) [WHERE { <filter_condition> }];").show

- 语法 2

  <carbon_context>.sql("UPDATE <CARBON TABLE> SET (column_name1, column_name2,) = (select sourceColumn1, sourceColumn2 from sourceTable [WHERE { <filter_condition> }]) [WHERE { <filter_condition> }];").show

示例：

如果 CarbonData 的 context 是“carbon”，那么更新命令如下：

carbon.sql("update carbonTable1 d set (d.column3,d.column5) = (select s.c33 ,s.c55 from sourceTable1 s where d.column1 = s.c11) where d.column1 = 'country' exists(select * from table3 o where o.c2 > 1);").show

1.8.14 如何在 CarbonData 中配置非安全内存？

问题

如何在 CarbonData 中配置非安全内存？

回答

在 Spark 配置中，“spark.yarn.executor.memoryOverhead”参数的值应大于 CarbonData 配置参数“sort.inmemory.size.inmb” 与“Netty offheapmemory required”参数值的总和，或者“carbon.unsafe.working.memory.in.mb” 、“carbon.sort.inememory.storage.size.in.mb” 与 “Netty offheapmemory required”参数值的总和。否则，如果堆外（off heap）访问超出配置的 executor 内存，则 YARN 可能会停止 executor。

“Netty offheapmemory required”说明：当“spark.shuffle.io.preferDirectBufs”设为 true 时，Spark 中 netty 传输服务从"spark.yarn.executor.memoryOverhead"中拿掉部分堆内存[~ 384 MB or 0.1 x 执行器内存]。

详细信息请参考常见 21.2.7.5 配置 executor 堆外内存大小。

1.8.15 设置了 HDFS 存储目录的磁盘空间配额，CarbonData 为什么会发生异常？

问题

设置了 HDFS 存储目录的磁盘空间配额，CarbonData 为什么会发生异常。

回答

创建、加载、更新表或进行其他操作时，数据会被写入 HDFS。若 HDFS 目录的磁盘空间配额不足，则操作失败并抛出以下异常。

```
org.apache.hadoop.hdfs.protocol.DSQuotaExceededException: The DiskSpace quota of
/user/tenant is exceeded: quota = 314572800 B = 300 MB but diskspace consumed =
402653184 B = 384 MB at
org.apache.hadoop.hdfs.server.namenode.DirectoryWithQuotaFeature.verifyStoragespace
Quota(DirectoryWithQuotaFeature.java:211) at
org.apache.hadoop.hdfs.server.namenode.DirectoryWithQuotaFeature.verifyQuota(Direct
oryWithQuotaFeature.java:239) at
org.apache.hadoop.hdfs.server.namenode.FSDirectory.verifyQuota(FSDirectory.java:941)
at
org.apache.hadoop.hdfs.server.namenode.FSDirectory.updateCount(FSDirectory.java:745)
```

若发生此异常，请为租户配置足够的磁盘空间配额。

例如：

需要的磁盘空间配置可以按照如下方法计算：

如果 HDFS 的副本数为 3， HDFS 默认的块大小为 128MB，则最小需要 384MB 的磁盘空间用于写表的 schema 文件到 HDFS 上。计算公式：no. of block x block_size x replication_factor of the schema file = 1 x 128 x 3 = 384 MB

说明

数据加载时，由于默认块大小为 1024MB，每个 fact 文件需要的最小空间为 3072MB。

1.8.16 为什么数据查询/加载失败，且抛出“org.apache.carbondata.core.memory.MemoryException: Not enough memory”异常？

问题

为什么数据查询/加载失败，且抛出“org.apache.carbondata.core.memory.MemoryException: Not enough memory”异常？

回答

当执行器中此次数据查询和加载所需要的堆外内存不足时，便会抛出此异常。

在这种情况下，请增大“carbon.unsafe.working.memory.in.mb”和“spark.yarn.executor.memoryOverhead”的值。

详细信息请参考 1.8.14 如何在 CarbonData 中配置非安全内存？

该内存被数据查询和加载共享。所以如果加载和查询需要同时进行，建议将“carbon.unsafe.working.memory.in.mb”和“spark.yarn.executor.memoryOverhead”的值配置为 2048 MB 以上。

可以使用以下公式进行估算：

数据加载所需内存：

(“carbon.number.of.cores.while.loading”的值[默认值 = 6]) x 并行加载数据的表格 x (“offheap.sort.chunk.size.inmb”的值[默认值 = 64 MB] + “carbon.blockletgroup.size.in.mb”的值[默认值 = 64 MB] + 当前的压缩率[64 MB/3.5])

= ~900 MB 每表格

数据查询所需内存：

(SPARK_EXECUTOR_INSTANCES. [默认值 = 2]) x (carbon.blockletgroup.size.in.mb [默认值 = 64 MB] + “carbon.blockletgroup.size.in.mb”解压内容[默认值 = 64 MB * 3.5]) x (每个执行器核数[默认值 = 1])

= ~ 600 MB

1.8.17 开启防误删下，为什么 Carbon 表没有执行 drop table 命令，回收站中也会存在该表的文件？

问题

开启防误删下，为什么 Carbon 表没有执行 drop table 命令，回收站中也会存在该表的文件？

回答

在 Carbon 适配防误删后，调用文件删除命令，会将删除的文件放入回收站中。在 insert、load 等命令中会有中间文件.carbonindex 文件的删除，所以在未执行 drop table 命令的时候，回收站中也可能会存在该表的文件。如果这个时候再执行 drop table 命令，那么按照回收站机制，会生成一个带时间戳的该表目录，该目录中的文件是完整的。

1.8.18 开启 TableStatus 多版本特性下，最新 tablestatus 文件丢失或损坏，如何恢复

问题

开启 TableStatus 多版本特性下，最新的 tablestatus 文件丢失或其他异常原因损坏的情况下，如何恢复？

回答

使用当前可得的最近的 tablestatus 文件进行恢复，分为如下两个场景来进行恢复：

场景一：当前批次的 CarbonData 数据文件和.segment 文件损坏无法恢复。

1. 进入客户端节点，执行如下命令，查看 HDFS 对应表的 tablestatus 文件，找到最近的 tablestatus 版本号。

   cd *客户端安装路径*

   source bigdata_env

   source Spark/component_env

   kinit *组件业务用户* （普通集群无需执行 kinit 命令）

   hdfs dfs -ls /user/hive/warehouse/hrdb.db/car01/Metadata

```
[root@192-168-64-146 Spark2x]# hdfs dfs -ls /user/hive/warehouse/hrdb.db/car01/Metadata
Found 6 items
-rw-r--r--   3 admintest hive        470 2022-11-21 15:41 /user/hive/warehouse/hrdb.db/car01/Metadata/schema
drwxrwxr-x+  - admintest hive          0 2022-11-21 19:08 /user/hive/warehouse/hrdb.db/car01/Metadata/segments
-rw-rw-r--+  3 admintest hive       1051 2022-11-21 15:52 /user/hive/warehouse/hrdb.db/car01/Metadata/tablestatus_1669017138012
-rw-rw-r--+  3 admintest hive       1226 2022-11-21 19:07 /user/hive/warehouse/hrdb.db/car01/Metadata/tablestatus_1669028830530
-rw-rw-r--+  3 admintest hive       1401 2022-11-21 19:07 /user/hive/warehouse/hrdb.db/car01/Metadata/tablestatus_1669028852132
-rw-rw-r--+  3 admintest hive       1576 2022-11-21 19:08 /user/hive/warehouse/hrdb.db/car01/Metadata/tablestatus_1669028899548
```

说明

上图中，当前批次文件 tablestatus_1669028899548 损坏，需要使用 tablestatus_1669028852132 文件。

2. 进入 spark sql，执行如下命令来修改表属性 latestversion 为当前最近的版本号。

   alter table car01 set SERDEPROPERTIES ('latestversion'='1669082252132');

```
spark-sql> alter table car01 set SERDEPROPERTIES ('latestversion'='1669028852132');
Time taken: 0.513 seconds
spark-sql> show create table car01;
2022-11-21 19:15:14,825 | AUDIT | main | {"time":"November 21, 2022 7:15:14 PM CST","username":"admintest","opName":"S
n.audit.logOperationStart(Auditor.java:74)
2022-11-21 19:15:15,034 | AUDIT | main | {"time":"November 21, 2022 7:15:15 PM CST","username":"admintest","opName":"S
e":"209 ms","table":"hrdb.car01","extraInfo":{}} | carbon.audit.logOperationEnd(Auditor.java:97)
CREATE TABLE `hrdb`.`car01` (
  `a` INT,
  `b` STRING,
  `c` STRING)
USING carbondata
OPTIONS (
  `bad_record_path` '',
  `dbName` 'hrdb',
  `latestversion` '1669028852132',
  `indextableexists` 'true',
  `local_dictionary_enable` 'true',
```

   需要退出当前 session，重新连接后执行查询。该方式已尽可能恢复客户数据，一般现网情况下，如断电场景 segment 数据文件也会存在不可恢复情况。

场景二：当前批次的 Carbondata 数据文件和.segment 文件完整，可恢复。

使用 TableStatusRecovery 恢复工具，当前工具仅针对非分区表进行恢复。进入 Spark 客户端节点，执行如下命令：

cd *客户端安装路径*

source bigdata_env

source Spark/component_env

kinit *组件业务用户*（普通集群无需执行 kinit 命令）

spark-submit --master yarn --class org.apache.carbondata.recovery.tablestatus.TableStatusRecovery Spark/spark/carbonlib/carbondata-spark_*.jar *hrdb car01*

参数说明：hrdb car01 表名称。

```
[root@192-168-43-241 client]#spark-submit --master yarn --class org.apache.carbondata.recovery.tablestatus.TableStatusRecovery Spark2x/spark/carbonlib/carbondata-spark_*.jar hrdb car01
2022-11-22 14:25:59,990 | WARN  | main | The configuration key 'spark.yarn.access.hadoopFileSystems' has been deprecated as of Spark 3.0 and may be removed in the future. Please use the new
 key 'spark.kerberos.access.hadoopFileSystems' instead. | org.apache.spark.SparkConf.logWarning(Logging.scala:69)
2022-11-22 14:25:59,993 | WARN  | main | The configuration key 'spark.yarn.kerberos.relogin.period' has been deprecated as of Spark 3.0 and may be removed in the future. Please use the new
key 'spark.kerberos.relogin.period' instead. | org.apache.spark.SparkConf.logWarning(Logging.scala:69)
2022-11-22 14:25:59,995 | WARN  | main | The configuration key 'spark.executor.plugins' has been deprecated as of Spark 3.0.0 and may be removed in the future. Feature replaced with new plu
gin API. See Monitoring documentation. | org.apache.spark.SparkConf.logWarning(Logging.scala:69)
2022-11-22 14:25:59,996 | WARN  | main | The configuration key 'spark.reducer.maxReqSizeShuffleToMem' has been deprecated as of Spark 2.3 and may be removed in the future. Please use the ne
w key 'spark.network.maxRemoteBlockSizeFetchToMem' instead. | org.apache.spark.SparkConf.logWarning(Logging.scala:69)
2022-11-22 14:26:00,189 | WARN  | main | The configuration key 'spark.yarn.access.hadoopFileSystems' has been deprecated as of Spark 3.0 and may be removed in the future. Please use the new
 key 'spark.kerberos.access.hadoopFileSystems' instead. | org.apache.spark.SparkConf.logWarning(Logging.scala:69)
```

TableStatusRecovery 恢复工具限制：

- 合并后，如果 tablestatus 文件丢失或损坏，使用该工具无法恢复合并状态的 segment，因为丢失或损坏的 tablestatus 文件才存在该 segment 合并信息。
- Delete segment by Id/Date 后，如果 tablestatus 文件丢失或损坏，则无法恢复已删除的 segment 信息，因为只有丢失或损坏的 tablestatus 文件才存在该 segment 的删除信息。
- 不支持在 mv 表上使用该工具。

- 由于最新的 tablestatus 文件存在问题，使用该工具恢复后无法正常查询时，可以移除最新的 tablestatus 文件，使用上一个 tablestatus 文件进行恢复。

2 使用 CDL

2.1 CDL 使用说明

CDL 是一种简单、高效的数据实时集成服务，能够从各种 OLTP 数据库中抓取 Data Change 事件，然后推送至 Kafka 中，最后由 Sink Connector 消费 Topic 中的数据并导入到大数据生态软件应用中，从而实现数据的实时入湖。

CDL 服务包含了两个重要的角色：CDLConnector 和 CDLService。CDLConnector 是具体执行数据抓取任务的实例，CDLService 是负责管理和创建任务的实例。

CDL 支持在 CDLService WebUI 界面创建数据同步任务和数据比较任务，使用流程如图 2-1 所示。

图2-1 CDL 使用流程

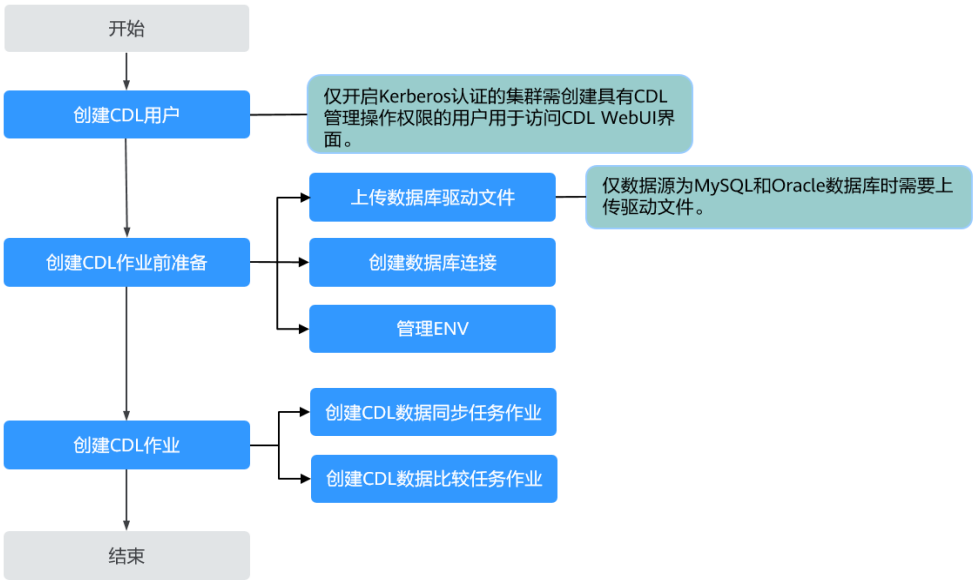

数据同步任务

- CDL 支持的数据同步任务类型：

表2-1 CDL 支持的数据同步任务类型

数据源	目的端	描述
MySQL	Hudi	该任务支持从 MySQL 同步数据到 Hudi。
	Kafka	该任务支持从 MySQL 同步数据到 Kafka。
PgSQL	Hudi	该任务支持从 PgSQL 同步数据到 Hudi。
	Kafka	该任务支持从 PgSQL 同步数据到 Kafka。
Hudi	DWS	该任务支持从 Hudi 同步数据到 DWS。
	ClickHouse	该任务支持从 Hudi 同步数据到 ClickHouse。
ThirdKafka	Hudi	该任务支持从 ThirdKafka 同步数据到 Hudi。
	Kafka	该任务支持从 ThirdKafka 同步数据到 Kafka。
openGuass（MRS 3.3.0 及之后版本支持）	ThirdKafka（DMS/DRS）->Hudi	该任务支持 openGuass 通过 ThirdKafka（DMS/DRS）同步数据到 Hudi。
	Hudi	该任务支持从 openGuass 同步数据到 Hudi。
	Kafka	该任务支持从 openGuass 同步数据到 Kafka。
ogg-oracle-avro（MRS 3.3.0 及之后版本支持）	ThirdKafka（DMS/DRS）->Hudi	该任务支持 avro-oracle 通过 ThirdKafka（DMS/DRS）同步数据到 Hudi。

- CDL 支持的数据同步任务中数据库版本范围：

  Kafka（包括 ThirdKafka 使用 MRS Kafka 作为源端）、Hudi 和 ClickHouse 数据源是直接使用 MRS 集群内的相关组件作为数据源，版本号介绍请参见，其他数据库版本号如表 2-2 所示。

表2-2 CDL 支持的数据库类型及版本范围

数据库名称	数据源	目的端	版本号
MySQL	支持	不支持	5.7.x、8.0.x
PgSQL	支持	不支持	9.6、10、11、12、13
Opengauss(开源版本)	支持	不支持	2.1.0 及之后版本
DWS	不支持	支持	8.1.1 及之后版本

- 使用约束：
  - 如果需要使用 CDL， Kafka 服务的配置参数“log.cleanup.policy”参数值必须为“delete”。
  - MRS 集群中已安装 CDL 服务。
  - CDL 仅支持抓取非系统表下的增量数据，MySQL、PostgreSQL 等数据库的内置数据库不支持抓取增量数据。
  - 从 Hudi 同步数据到 DWS 或 ClickHouse 任务中，在 Hudi 中物理删除的数据目的端不会同步删除。例如，在 Hudi 中执行 **delete from** *tableName* 命令硬删除表数据，目的端 DWS 或 ClickHouse 仍存在该表数据。
  - MySQL 数据库需要开启 MySQL 的 bin log 功能（默认情况下是开启的）和 GTID 功能，CDL 不支持抓取表名包含“$”特殊字符的表。
    - **查看 MySQL 是否开启 bin log：**

      使用工具或者命令行连接 MySQL 数据库（本示例使用 Navicat 工具连接），执行 **show variables like 'log_%'**命令查看。

      例如在 navicat 工具选择“File > New Query”新建查询，输入如下 SQL 命令，单击“Run”在结果中“log_bin”显示为“ON”则表示开启成功。

      show variables like 'log_%'

      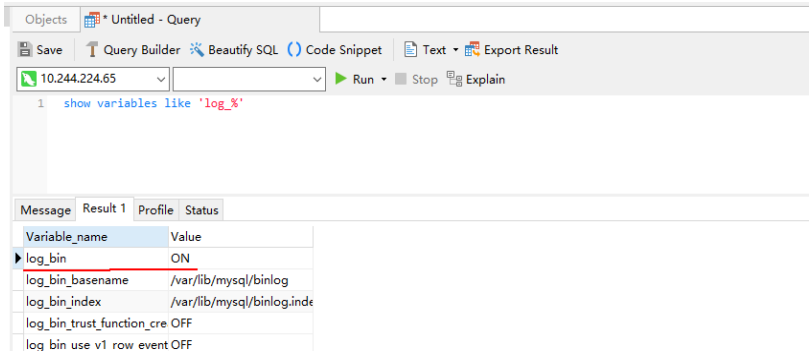

    - **若当前 MySQL 未开启 bin log 功能，需执行以下操作：**

      可以通过修改 MySQL 的配置文件“my.cnf” （Windows 系统是“my.ini”）开启，操作如下：

      ```
      server-id        = 223344
      log_bin          = mysql-bin
      binlog_format    = ROW
      binlog_row_image  = FULL
      expire_logs_days  = 10
      ```

      修改完成之需要重启 MySQL 服务使配置生效。

    - **查看 MySQL 是否开启 GTID 功能：**

      使用 **show global variables like '%gtid%'**命令查看是否开启， 具体开启方法参考 MySQL 对应版本的官方文档。

      （MySQL 8.x 版本开启指导请参见 https://dev.mysql.com/doc/refman/8.0/en/replication-mode-change-online-enable-gtids.html）

```
mysql> show global variables like '%gtid%';
+--------------------------------+-------------------------------------------+
| Variable_name                  | Value                                     |
+--------------------------------+-------------------------------------------+
| binlog_gtid_simple_recovery    | ON                                        |
| enforce_gtid_consistency       | ON                                        |
| gtid_executed                  | da708678-09f9-11eb-8d03-fa163e62b70b:1-41 |
| gtid_executed_compression_period | 1000                                    |
| gtid_mode                      | ON                                        |
| gtid_owned                     |                                           |
| gtid_purged                    |                                           |
| session_track_gtids            | OFF                                       |
+--------------------------------+-------------------------------------------+
8 rows in set (0.07 sec)
```

- **用户权限设置：**

  用户执行 MySQL 任务需要的权限需要包括 **SELECT、RELOAD、SHOW DATABASES、REPLICATION SLAVE、REPLICATION CLIENT**。

  可执行以下命令进行赋权，命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

  GRANT SELECT, RELOAD, SHOW DATABASES, REPLICATION SLAVE, REPLICATION CLIENT ON *.* TO '*数据库用户名*' **IDENTIFIED BY** '*数据库用户密码*';

  执行以下命令刷新权限：

  FLUSH PRIVILEGES;

- PostgreSQL 数据库需要修改预写日志的策略。

说明

- 连接 PostgreSQL 数据库的用户需要具有 replication 权限和对数据库的 create 权限，对表要有 owner 权限。
- CDL 不支持抓取表名包含“$”特殊字符的表。
- PostgreSQL 数据库需要有修改“statement_timeout”和“lock_timeout”两个超时参数的设置权限以及查询删除 Slot 和 publication 权限。
- “max_wal_senders”建议设置为 Slot 的 1.5 倍或 2 倍。
- 在 PostgreSQL 表的复制标识是 **default** 的情况下，若存在以下场景，需要开启全字段补全功能：
- 场景一：

  在源端数据库存在 **delete** 操作场景下，**delete** 事件只包含主键信息， 在这时写入到 Hudi 的 **delete** 数据会出现只有主键字段有值， 其他业务字段都是 null 的情况。
- 场景二：

  在数据库单条数据大小超过 8k（包括 8k）场景下，**update** 事件只包含变更字段，此时 Hudi 数据中会出现部分字段的值为 **__debezium_unavailable_value** 的情况。

  相关命令如下，其中：
- 查询 PostgreSQL 表复制标识的命令为：

  SELECT CASE relreplident WHEN 'd' THEN 'default' WHEN 'n' THEN 'nothing' WHEN 'f' THEN 'full' WHEN 'i' THEN 'index' END AS replica_identity FROM pg_class WHERE oid = '*tablename***'::regclass;**
- 为表开启全字段补齐功能的命令为：

  ALTER TABLE *tablename* **REPLICA IDENTITY FULL;**

  i. 修改数据库配置文件“postgresql.conf”（默认在 PostgreSQL 安装目录的 data 文件夹下）中的参数项“wal_level = logical”。

```
#------------------------------------------------
#WRITE-AHEAD LOG
#------------------------------------------------

# - Settings -
wal_level = logical        # minimal, replica, or logical
                    # (change requires restart)
#fsync = on           #flush data to disk for crash safety
...
```

ii. 重启数据库服务：

```
#停止
pg_ctl stop
#启动
pg_ctl start
```

- DWS 数据库前置准备。

  同步任务启动前，源表和目标表必须存在，且表结构保持一致。DWS 表中“ads_last_update_date”取值为系统当前时间。

- ThirdPartyKafka 前置准备。

  上层源支持 opengauss 和 ogg，源端 Kafka Topic 可被 MRS 集群 Kafka 消费。

说明

ThirdKafka 不支持同步分布式 Openguass 数据库数据到 CDL。

- ClickHouse 前置准备。

  用户需要有操作 ClickHouse 的权限，相关操作请参见 3.2.1 ClickHouse 用户及权限管理。

- openGauss 数据库需要开启预写日志功能（MRS 3.3.0 及之后版本支持）。

说明

- 连接 openGauss 数据库的用户需要具有逻辑复制权限。
- 不支持同步 openGauss 间隔分区表、中文名称表。
- 源端 openGauss 数据库中的表若不存在主键，则不支持 **delete** 该表的数据。
- 若源端 openGauss 数据库存在 **delete** 数据操作，则需要开启全字段补全功能，命令如下：
- 查询 openGauss 表复制标识的命令为：

  SELECT CASE relreplident WHEN 'd' THEN 'default' WHEN 'n' THEN 'nothing' WHEN 'f' THEN 'full' WHEN 'i' THEN 'index' END AS replica_identity FROM pg_class WHERE oid = '*tablename*'::regclass;
- 为表开启全字段补齐功能的命令为：

  ALTER TABLE *tablename* REPLICA IDENTITY FULL;

  i. 修改数据库配置文件“postgresql.conf”（默认在 Openguass 安装目录的 data 文件夹下）中的参数项“wal_level = logical”。

```
#------------------------------------------------
#WRITE-AHEAD LOG
#------------------------------------------------

# - Settings -
wal_level = logical        # minimal, replica, or logical
                    # (change requires restart)
```

```
#fsync = on             #flush data to disk for crash safety
...
```

ii. 重启数据库服务：

```
#停止
pg_ctl stop
#启动
pg_ctl start
```

CDL 同步任务支持的数据类型及映射关系

主要介绍 CDL 同步任务支持的数据类型，以及源端数据库数据类型跟 Spark 数据类型的映射关系。

表2-3 PgSQL 和 Spark 数据类型映射关系

PostgreSQL 数据类型	Spark（Hudi）数据类型
int2	int
int4	int
int8	bigint
numeric(p, s)	decimal[p,s]
bool	boolean
char	string
varchar	string
text	string
timestamptz	timestamp
timestamp	timestamp
date	date
json, jsonb	string
float4	float
float8	double

表2-4 MySQL 和 Spark 数据类型映射关系

MySQL 数据类型	Spark（Hudi）数据类型
int	int
integer	int
bigint	bigint
double	double

MySQL 数据类型	Spark（Hudi）数据类型
decimal[p,s]	decimal[p,s]
varchar	string
char	string
text	string
timestamp	timestamp
datetime	timestamp
date	date
json	string
float	double

表2-5 Ogg/Ogg Oracle Avro（MRS 3.3.0 及之后版本）和 Spark 数据类型映射关系

Oracle 数据类型	Spark（Hudi）数据类型
NUMBER(3)，NUMBER(5)	bigint
INTEGER	decimal
NUMBER(20)	decimal
NUMBER	decimal
BINARY_DOUBLE	double
CHAR	string
VARCHAR	string
TIMESTAMP, DATETIME	timestamp
timestamp with time zone	timestamp
DATE	timestamp

表2-6 DRS Opengauss Json 和 Spark 数据类型映射关系（MRS 3.3.0 及之后版本支持）

Opengauss Json 数据类型	Spark（Hudi）数据类型
int2	int
int4	int
int8	bigint
numeric(p,s)	decimal[p,s]

Opengauss Json 数据类型	Spark（Hudi）数据类型
bool	boolean
varchar	string
timestamp	timestamp
timestampz	timestamp
date	date
jsonb	string
json	string
float4	float
float8	duble
text	string

表2-7 DRS Oracle Json 和 Spark 数据类型映射关系（MRS 3.3.0 及之后版本支持）

Oracle Json 数据类型	Spark（Hudi）数据类型
number(p,s)	decimal[p,s]
binary double	double
char	string
varchar2	string
nvarchar2	string
timestamp	timestamp
timestamp with time zone	timestamp
date	timestamp

表2-8 DRS Oracle Avro 和 Spark 数据类型映射关系（MRS 3.3.0 及之后版本支持）

Oracle Avro 数据类型	Spark（Hudi）数据类型
nuber[p,s]	decimal[p,s]
flaot(p)	float
binary_double	double
char(p)	string
varchar2(p)	string

Oracle Avro 数据类型	Spark（Hudi）数据类型
timestamp(p)	timestamp
date	timestamp

表2-9 openGauss 和 Spark 数据类型映射关系（MRS 3.3.0 及之后版本支持）

Opengauss 数据类型	Spark（Hudi）数据类型
int1	int
int2	int
int4	int
int8	bigint
numeric(p,s)	decimal[p,s]
bool	boolean
char	string
bpchar	string
nvarchar2	string
text	string
date	date
timestamp	timestamp
timestampz	timestamp
json	string
jsonb	string
float4	float
float8	double
real	float

表2-10 Spark（Hudi）和 DWS 数据类型映射关系

Spark（Hudi）数据类型	DWS 数据类型
int	int
long	bigint
float	float

Spark（Hudi）数据类型	DWS 数据类型
double	double
decimal[p,s]	decimal[p,s]
boolean	boolean
string	varchar
date	date
timestamp	timestamp

表2-11 Spark（Hudi）和 ClickHouse 数据类型映射关系

Spark（Hudi）数据类型	ClickHouse 数据类型
int	Int32
long	Int64 (bigint)
float	Float32 (float)
double	Float64 (double)
decimal[p,s]	Decimal(P,S)
boolean	bool
string	String (LONGTEXT, MEDIUMTEXT, TINYTEXT, TEXT, LONGBLOB, MEDIUMBLOB, TINYBLOB, BLOB, VARCHAR, CHAR)
date	Date
timestamp	DateTime

数据比较任务

数据比对即是对源端数据库中的数据和目标端 Hive 中的数据作数据一致性校验，如果数据不一致，CDL 可以尝试修复不一致的数据。相关操作请参见 2.5.2 创建 CDL 数据比较任务作业。

2.2 从零开始使用 CDL

操作场景

CDL 支持多种场景的数据同步或比较任务，本章节指导用户通过开启 Kerberos 认证的集群的 CDLService WebUI 界面从 PgSQL 导入数据到 Kafka，更多 CDL 作业示例请参见 2.5.3 常见 CDL 作业示例。

前提条件

- 集群已安装 CDL、Kafka 服务且运行正常。
- PostgreSQL 数据库需要修改预写日志的策略，操作步骤请参考 PostgreSQL 数据库修改预写日志的策略。
- 在 FusionInsight Manager 中创建一个人机用户，例如“cdluser”，加入用户组 **cdladmin**、**hadoop**、**kafka**，主组选择“cdladmin”组，关联角色“System_administrator”。

操作步骤

步骤 1 使用 **cdluser** 用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > CDL”，在 CDL“概览”界面单击“CDLService UI”右侧的超链接，进入 CDL 原生界面。

步骤 2 选择“连接管理 > 新增连接”，进入“新增连接”参数配置窗口，参考下表，分别新增“pgsql”和“kafka”连接，相关数据连接参数介绍请参见 2.4.4 创建数据库连接。

表2-12 PgSQL 数据连接配置参数

参数名称	示例
Link Type	pgsql
Name	pgsqllink
Host	10.10.10.10
Port	5432
DB Name	testDB
User	user
Password	*user 用户密码*
Description	-

表2-13 Kafka 数据连接配置参数

参数名称	示例
Link Type	kafka

参数名称	示例
Name	kafkalink
Description	-

步骤 3 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

步骤 4 在“作业管理”页面单击“新建作业”。在“新建作业”窗口中填写配置。单击“下一步”，进入作业参数配置页面。

其中：

参数名称	示例
Name	job_pgsqltokafka
Desc	xxx

步骤 5 配置 PgSQL 作业参数。

1. 在作业参数配置页面，选取左侧“pgsql”图标拖入右侧编辑区域，然后双击此图标进入 PgSQL 作业参数配置窗口，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-14 PgSQL 作业参数

参数名称	示例
Link	pgsqllink
Tasks Max	1
Mode	insert、update、delete
Schema	public
dbName Alias	cdc
Slot Name	test_solt
Slot Drop	否
Connect With Hudi	否
Use Exist Publication	是
Publication Name	test

2. 单击“+”按钮展开更多选项。

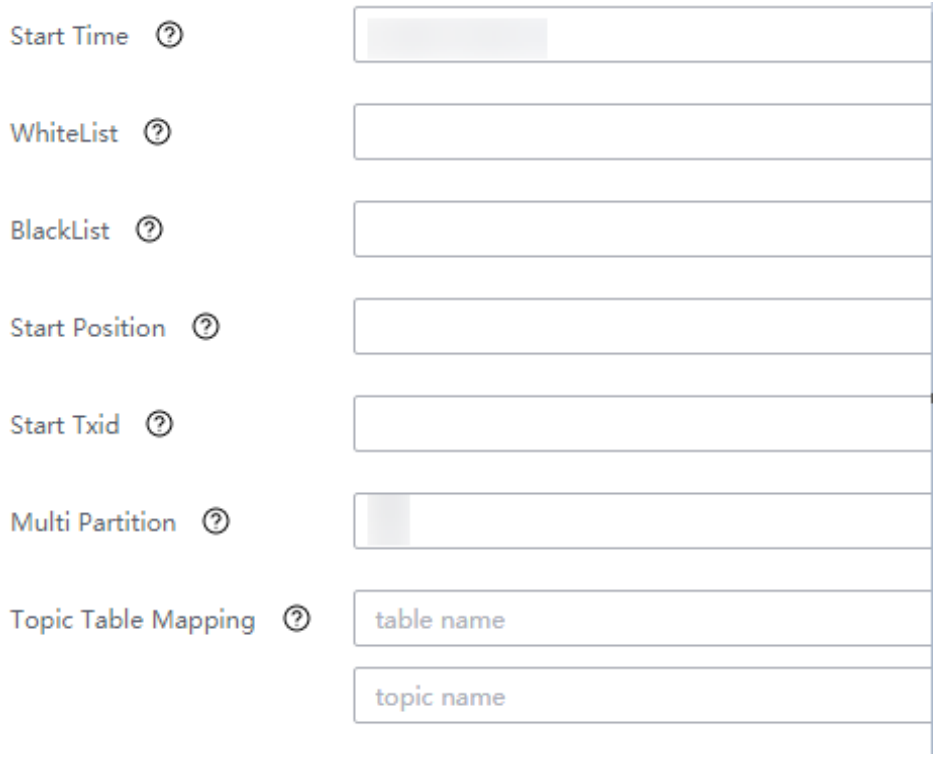

说明

- “WhiteList”：输入数据库中的表（如 myclass）
- “Topic Table Mapping”：第一个框输入 topic 名（与步骤 4 中作业名称“Name”的值不能一样，例如 myclass_topic）。 第二个框输入表名（例如 myclass。该值与第一个框的 topic 只能是一对一的关系）。

3. 单击“确定”，PgSQL 作业参数配置完成。

步骤 6 配置 Kafka 作业参数。

1. 在作业参数配置页面，选取左侧“kafka”图标拖入右侧编辑区域，然后双击此图标进入 Kafka 作业参数配置窗口。参考表 2-15 进行参数配置。

表2-15 Kafka 作业参数

参数名称	示例
Link	kafkalink

2. 单击“确定”，完成 Kafka 作业参数配置。

步骤 7 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

步骤 8 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 PgSQL 数据库中对表进行插入数据操作，然后参考 16.17.5 使用 KafkaUI 管理 Topic 进入 KafkaUI 界面查看 Kafka 的 Topic 中是否有数据生成。

----结束

2.3 创建 CDL 用户

操作场景

在使用 CDL 服务前，需集群管理员创建用户并指定其操作权限以满足业务使用需求。

CDL 用户分为管理员用户和普通用户，系统默认的 CDL 管理员用户组为“cdladmin”，CDL 普通用户对应用户组为“cdl”。

- 关联了“cdladmin”用户组的用户可以执行 CDL 的任何操作。
- 关联了“cdl”用户组的用户可以执行 CDL 的创建和查询操作。

启用了 Ranger 鉴权时，如果用户创建后需要继续为用户配置创建、执行、查询、删除权限，请参考 20.7 添加 CDL 的 Ranger 访问权限策略。

对于手动停用了 Ranger 鉴权的集群，可参考 20.2 启用 Ranger 鉴权章节重新启用 Ranger 鉴权。

说明

该章节内容仅适用于开启了 Kerberos 认证的集群。

操作步骤

步骤 1 登录 FusionInsight Manager。

步骤 2 选择“系统 > 权限 > 用户 > 添加用户”。

步骤 3 填写“用户名”，例如“cdl_admin”。

步骤 4 设置“用户类型”，选择“人机”。

步骤 5 填写“密码”和“确认密码”。

步骤 6 设置“用户组”和“主组”。

- CDL 管理员用户权限：添加“cdladmin”用户组，选择“cdladmin”作为主组。
- CDL 普通用户权限：为该用户添加“cdl”用户组，选择“cdl”作为主组。

步骤 7 单击“确定”，完成 CDL 用户创建。

----结束

2.4 创建 CDL 作业前准备

2.4.1 开启 Kafka 高可靠功能

操作场景

若需执行表 2-16 中的 CDL 数据同步任务时，需开启 Kafka 高可靠性功能，防止当 Kafka 发生故障或者 Kafka 重启时传输的数据丢失。

表2-16 使用 MRS Kafka 同步数据的 CDL 任务

数据源	目的端	描述
MySQL	Hudi	该任务支持从 MySQL 同步数据到 Hudi。
	Kafka	该任务支持从 MySQL 同步数据到 Kafka。
PgSQL	Hudi	该任务支持从 PgSQL 同步数据到 Hudi。
	Kafka	该任务支持从 PgSQL 同步数据到 Kafka。
Hudi	DWS	该任务支持从 Hudi 同步数据到 DWS。
	ClickHouse	该任务支持从 Hudi 同步数据到 ClickHouse。
ThirdKafka	Hudi	该任务支持从 ThirdKafka 同步数据到 Hudi。
	Kafka	该任务支持从 ThirdKafka 同步数据到 Kafka。
openGuass（MRS 3.3.0 及之后版本支持）	ThirdKafka（DMS/DRS）->Hudi	该任务支持 openGuass 通过 ThirdKafka（DMS/DRS）同步数据到 Hudi。
	Hudi	该任务支持从 openGuass 同步数据到 Hudi。
	Kafka	该任务支持从 openGuass 同步数据到 Kafka。
ogg-oracle-avro（MRS 3.3.0 及之后版本支持）	ThirdKafka（DMS/DRS）->Hudi	该任务支持 avro-oracle 通过 ThirdKafka（DMS/DRS）同步数据到 Hudi。

前提条件

- MRS 集群已安装 CDL 组件，并且正常运行。
- CDL 数据同步任务使用到 Kafka 组件。

操作步骤

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > Kafka > 配置 > 全部配置”。

步骤 2 在右上角搜索框中搜索如下表 2-17 参数，并修改对应的参数值。

表2-17 修改 Kafka 参数

参数	推荐值	说明
unclean.leader.election.enable	false	是否允许不在 ISR 中的副本被选举为 Leader，若设置为“true”，可能会造成数据丢失。
min.insync.replicas	2	当“offsets.commit.required.acks”参数值为“-1”时，指定需要写入成功的副本的最小数目。

步骤 3 单击“保存”，保存配置。

步骤 4 单击“概览”，选择“更多 > 滚动重启服务”，滚动重启 Kafka。

----结束

2.4.2 登录 CDLService WebUI

操作场景

MRS 集群安装 CDL 组件后，用户可以通过 CDL 的图形化界面进行数据连接管理和可视化作业编排等。

本任务指导用户在 MRS 集群中访问 CDL WebUI。

说明

Internet Explorer 浏览器可能存在兼容性问题，建议使用 Google Chrome 浏览器访问 CDLService UI。

CDL 不支持抓取表名包含$特殊字符的表。

前提条件

- MRS 集群已安装 CDL 组件，并且正常运行。
- 开启 Kerberos 认证的集群已参考 2.3 创建 CDL 用户创建具有 CDL 管理操作权限的用户。

操作步骤

步骤 1 使用具有 CDL 管理操作权限的用户或 **admin** 用户（未开启 Kerberos 认证的集群）登录 FusionInsight Manager，选择“集群 > 服务 > CDL”。

步骤 2 在“CDLService UI”右侧，单击链接，访问 CDLService WebUI。

CDL WebUI 界面支持以下功能：

- 驱动管理：可以上传、查看和删除连接数据库对应的驱动文件。
- 连接管理：可以新建、查看、编辑和删除数据连接。
- 作业管理：使用作业管理可以新建、查看、启动、暂停、恢复、停止、重启、删除和编辑作业等。
- ENV 管理：可以创建、查看、编辑、删除 Hudi 环境变量。

----结束

2.4.3 上传驱动文件

操作场景

CDL 是一种简单、高效的数据实时集成服务，能够从各种 OLTP 数据库中抓取事件推送至 Kafka。通过 CDLService WebUI 创建数据库连接时，可将数据库对应的驱动文件通过界面上传，方便统一管理。

前提条件

- 已获取待连接数据库对应的驱动 Jar 包。
- 仅数据源 MySQL、Oracle（MRS 3.3.0 及之后版本支持）需要上传相应的驱动，驱动对应的版本号如表 2-18 所示，且驱动需要在 MySQL 或 Oracle 官网下载。

表2-18 MySQL、Oracle 数据源支持的驱动

数据源	支持的驱动包
MySQL	mysql-connector-java-8.0.24.jar
Oracle（MRS 3.3.0 及之后版本支持）	ojdbc8-12.2.0.1.jar

说明

此处 Oracle 仅作为 ThirdKafka 数据源使用。

- 开启 Kerberos 认证的集群需已参考 2.3 创建 CDL 用户创建具有 CDL 管理操作权限的用户。

操作步骤

步骤 1 使用具有 CDL 管理操作权限的用户或 **admin** 用户（未开启 Kerberos 认证的集群）登录 CDLService WebUI 界面，请参考 2.4.2 登录 CDLService WebUI。

步骤 2 选择“驱动管理 > 上传驱动”，在弹出的窗口选择本地已准备的数据库驱动文件，单击“打开”，等待驱动上传完成。

步骤 3 在“驱动管理”界面，查看驱动文件名列表是否显示正常。

说明

- 如果驱动不再使用，或者上传错误，可单击“删除”，删除对应驱动文件。
- 驱动文件列表较多时，可通过搜索框快速检索。

----结束

2.4.4 创建数据库连接

操作场景

通过 CDLService WebUI 创建数据库连接时，可参考该章节进行 CDL 作业编排。

前提条件

- 已获取待连接数据对应的驱动 Jar 包并上传。
- 开启 Kerberos 认证的集群需已参考 2.3 创建 CDL 用户创建具有 CDL 管理操作权限的用户。

操作步骤

步骤 1 使用具有 CDL 管理操作权限的用户或 **admin** 用户（未开启 Kerberos 认证的集群）登录 CDLService WebUI 界面，请参考 2.4.2 登录 CDLService WebUI。

步骤 2 选择“连接管理 > 新增连接”，在弹出窗口中输入数据连接的名称（Name，不能与已存在的名称相同）并选择连接类型（Link Type）。

步骤 3 根据不同的连接类型，界面信息输入数据相关链接参数。

表2-19 MySQL 数据连接配置参数

参数名称	描述	示例
Link Type	连接类型。	mysql
Name	连接配置名称。	mysqllink
DB driver	选择已上传的 MySQL 驱动文件“mysql-connector-java-8.0.24.jar”。	mysql-connector-java-8.0.24.jar
Host	MySQL 数据库 IP 地址。	10.10.10.10
Port	MySQL 数据库端口。	3306
User	MySQL 数据库访问用户。	user
Password	MySQL 数据库访问密码。	*user 用户密码*

参数名称	描述	示例
Description	描述信息。	xxx

表2-20 PgSQL 数据连接配置参数

参数名称	描述	示例
Link Type	连接类型。	pgsql
Name	连接配置名称。	pgsqllink
Host	PgSQL 数据库 IP 地址。	10.10.10.10
Port	PgSQL 数据库端口。	5432
DB Name	PgSQL 数据库名称。	testDB
User	PgSQL 数据库访问用户。	user
Password	PgSQL 数据库访问密码。	*user 用户密码*
Description	描述信息。	xxx

表2-21 Kafka 数据连接配置参数

参数名称	描述	示例
Link Type	连接类型。	kafka
Name	连接配置名称。	kafkalink
Description	描述信息。	-

表2-22 Hudi 数据连接配置参数

参数名称	描述	示例
Link Type	连接类型。	hudi
Name	连接配置名称。	hudilink
Storage Type	存储类型。 hdfs：数据存储到 HDFS 中。	hdfs
Auth KeytabFile	访问用户的 keytab 文件。可单击“上传文件”进行上传。	${BIGDATA_HOME}/FusionInsight_CDL_*X.X.X*/install/FusionInsight-CDL-

参数名称	描述	示例
	安全模式集群填写该参数，普通模式集群不显示该参数。 说明 该文件可在 Manager 界面选择“系统 > 权限 > 用户”，在待操作用户后选择“更多 > 下载用户凭证”获取。	*X.X.X*/cdl/keytabs/cdl.keytab
Principal	访问用户的域名用户。 安全模式集群填写该参数，普通模式集群不显示该参数。	cdl/test.com@HADOOP.COM
Description	描述信息。	xxx

表2-23 thirdparty-kafka 数据连接配置参数

参数名称	描述	示例
Link Type	连接类型。	thirdparty-kafka
Name	连接配置名称。	thirdparty-kafkalink
Bootstrap Servers	Kafka 代理实例，即是 *Kafka 的 Broker 实例业务 IP*:*Kafka 端口号*。 说明 若以 MRS Kafka 作为 thirdparty-kafka 源端，端口号可登录 Manager 界面，选择“集群 > 服务 > Kafka > 配置”，在搜索框中搜索端口，根据相应的加密协议获取对应的端口号。	10.10.10.10:21005
Security Protocol	加密协议，包括： • SASL_PLAINTEXT • PLAINTEXT • SASL_SSL • SSL	SASL_SSL
Username	在实例创建期间启用“SASL_SSL”时指定的用户名。 说明 仅加密协议为“SASL_PLAINTEXT”和	test

参数名称	描述	示例
	“SASL_SSL”支持该参数。	
Password	在实例创建期间启用“SASL_SSL”时指定的密码。 说明 仅加密协议为“SASL_PLAINTEXT”和“SASL_SSL”支持该参数。	xxx
SSL Truststore Location	上传“client.truststore.jks”认证文件。 说明 仅加密协议为“SASL_SSL”和“SSL”支持该参数。	-
SSL Truststore Password	“client.truststore.jks”证书文件对应的密码。 说明 仅加密协议为“SASL_SSL”和“SSL”支持该参数。	xxx
Datastore Type	上层源的类型，包括： • MRS 3.2.0 版本： – opengauss – ogg – oracle – drs-avro-oracle • MRS 3.3.0 及之后版本： – drs-opengauss-json – ogg-oracle-avro – drs-oracle-json – drs-oracle-avro	• opengauss • drs-opengauss-json
DB driver	选择已上传的 thirdparty-kafka 驱动文件。 说明 “Datastore Type”为“ogg”（MRS 3.3.0 及之后版本为“ogg-oracle-avro”）显示该参数。	-
Host	thirdparty-kafka 数据库的 IP 地址。 说明	11.11.xxx.xxx,12.12.xxx.xxx

参数名称	描述	示例
	“Datastore Type”为“oracle”（MRS 3.3.0 及之后版本为“drs-oracle-json”）时不支持该参数。	
Port	thirdparty-kafka 数据库的端口。 说明 “Datastore Type”为“oracle”（MRS 3.3.0 及之后版本为“drs-oracle-json”）时不支持该参数。	8000
DB Name	thirdparty-kafka 数据库名称。 说明 “Datastore Type”为“opengauss”（MRS 3.3.0 及之后版本为“drs-opengauss-json”）显示该参数。	opengaussdb
User	thirdparty-kafka 数据库访问用户。 说明 “Datastore Type”为“oracle”（MRS 3.3.0 及之后版本为“drs-oracle-json”）时不支持该参数。	opengaussuser
DB Password	thirdparty-kafka 数据库访问密码。 说明 “Datastore Type”为“oracle”（MRS 3.3.0 及之后版本为“drs-oracle-json”）时不支持该参数。	*opengaussuser 用户密码*
Sid	Oracle 的服务 ID。 说明 “Datastore Type”为“ogg”MRS 3.3.0 及之后版本为“ogg-oracle-avro”）显示该参数。	-
Description	描述信息。	-

表2-24 DWS 数据连接配置参数

参数名称	描述	示例

参数名称	描述	示例
Link Type	连接类型。	dws
Name	连接配置名称。	dwslink
Host	待连接的 DWS 数据库 IP 地址。	10.10.10.10
Port	数据库端口。	8000
DB Name	待连接的数据库名称。	default
User	数据库访问用户。	test
Password	数据库访问密码。	xxx
Description	描述信息。	-

表2-25 opengauss 数据连接配置参数

参数名称	描述	示例
Link Type	连接类型。	opengauss
Name	连接配置名称。	opengaussslink
Host	待连接的 opengauss 数据库 IP 地址。	10.10.10.10
Port	数据库端口。	8000
DB Name	待连接的数据库名称。	default
User	数据库访问用户。	test
Password	数据库访问密码。	xxx
Description	描述信息。	-

表2-26 ClickHouse 数据连接配置参数

参数名称	描述	示例
Link Type	连接类型。	dws
Name	连接配置名称。	clickhouselink
Host	*ClickHouse 的 ClickHouseBalancer 实例业务 IP 地址:HTTP Balancer 端口号*。支持连	10.10.10.10:21428

参数名称	描述	示例
	接多个 ClickHouse 实例，使用,分隔。 说明 *HTTP Balancer 端口号*可登录 Manager 界面，选择“集群 > 服务 > ClickHouse > 逻辑集群”，在集群列表的“HTTP Balancer 端口号”列获取。	
User	数据库访问用户。	test
Password	数据库访问密码。	xxx
Description	描述信息。	-

步骤 4 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

----结束

2.4.5 管理 ENV

操作场景

如果需要将数据抓取至 Hudi 或者从 Hudi 抓取数据时，请执行该章节操作创建 Hudi 环境变量并进行管理。

前提条件

开启 Kerberos 认证的集群需已参考 2.3 创建 CDL 用户创建具有 CDL 管理操作权限的用户。

操作步骤

步骤 1 使用具有 CDL 管理操作权限的用户或 **admin** 用户（未开启 Kerberos 认证的集群）登录 CDLService WebUI 界面，请参考 2.4.2 登录 CDLService WebUI。

步骤 2 选择“ENV 管理 > 新建 ENV”，在弹出的窗口中输入相关信息。

表2-27 新建 ENV 配置参数

参数名称	描述	示例
Name	ENV 名称。	spark-env
Type	ENV 类型。	spark

参数名称	描述	示例
Driver Memory	Driver 内存大小，单位默认为 GB。	1GB
Executor Memory	每个 Executor 进程的内存 ，和 JVM 内存串拥有相同的格式，单位默认为 GB。	1GB
Executor Cores	每个 Executor 所占用的 CPU 核的数目。	1
Number Executors	Executor 的个数。	1
Queue	Yarn 的租户队列名。不指定将默认提交到 default 队列上。	-
Description	描述信息。	-

步骤 3 单击“确定”完成 ENV 创建。

创建完成后可以在“操作”列单击“编辑”进行修改，或者单击“删除”删除该 ENV。

----结束

2.4.6 配置同步任务的心跳和数据判齐

操作场景

心跳和数据判齐功能用于统计 CDL 同步任务的全链路信息， 包括从数据库管理系统 RDBMS 到 Kafka 的数据耗时、从 Kafka 消费数据写入到 Hudi 的数据耗时和数据条数等一系列信息，并将其写入到特定的 Topic（cdl_snapshot_topic）中，用户可自行消费 Topic 中的数据并写入到某个特定 Hudi 表作数据判齐使用。心跳判齐数据不仅可以用来判断心跳时间之前的数据已经同步到数据湖，还可以根据事物时间，写 Kafka 的时间，数据开始入湖时间和数据入湖结束时间来判断数据时延问题。

同时对于 PgSQL 任务，配置心跳表可以定期向前推进 PgSQL 中 Slot 记录的 LSN 的信息，避免由于某个任务配置了某部分变化很小的表导致数据库日志积压。

配置从 Oracle（ogg）抓取数据到 Hudi 任务的心跳表

步骤 1 在需要同步数据的 Oracle 数据库中执行以下命令创建一张心跳表，心跳表归属于 **CDC_CDL** Schema，表名为 **CDC_HEARTBEAT**，主键为 **CDL_JOB_ID**：

```
CREATE TABLE "CDC_CDL"."CDC_HEARTBEAT" (
"CDL_JOB_ID" VARCHAR(22)  PRIMARY KEY,
```

"CDL_LAST_HEARTBEAT" TIMESTAMP,

SUPPLEMENTAL LOG DATA (ALL) COLUMNS

);

步骤 2 将 **CDC_HEARTBEAT** 表加入到 Oracle 或者 ogg 的任务中，确保心跳数据可以正常发送到 Kafka。

说明

如果是 Oracle 任务，直接执行步骤 4。

步骤 3 在 CDL WebUI 配置 thirdparty-kafka（ogg）连接增加 Oracle 的连接信息。

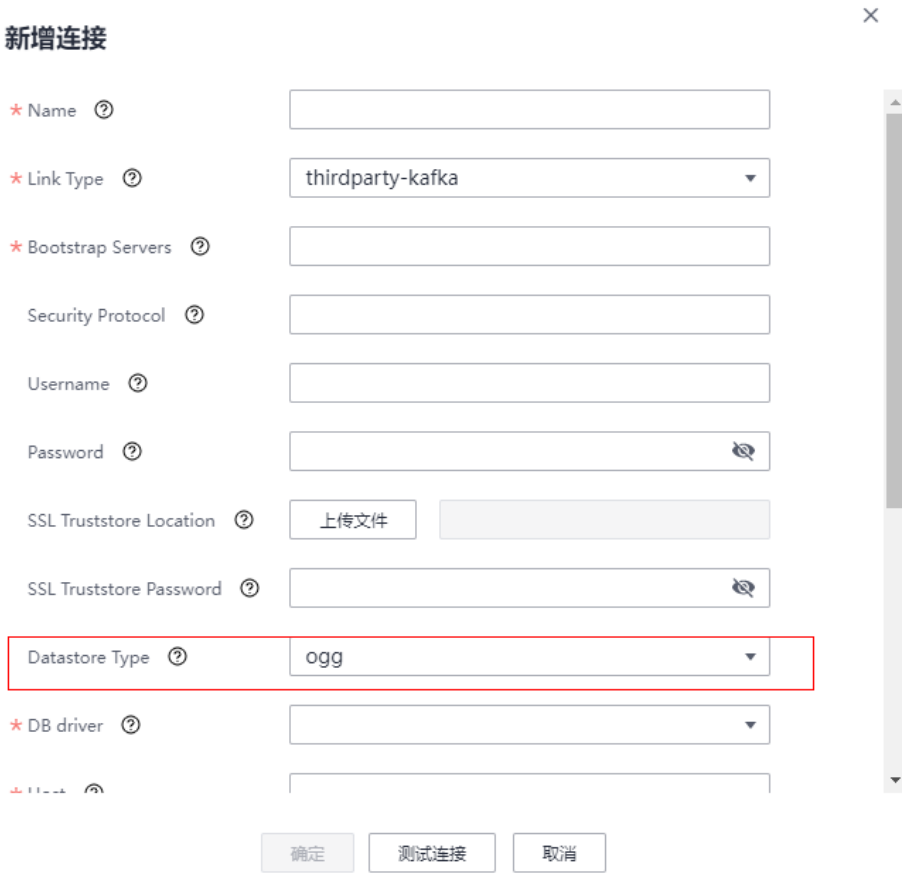

步骤 4 配置完成后，在 CDL WebUI 界面创建从 Oracle（ogg）抓取数据到 Hudi 任务并启动即可收到心跳数据。

----结束

配置从 Postgresql 抓取数据到 Hudi 任务的心跳表

步骤 1 在需要同步的 Postgresql 数据库下执行以下命令创建一张心跳表，心跳表归属 **cdc_cdl** Schema，表名为 **cdc_heartbeat**，主键为 **cdl_job_id**：

DROP TABLE IF EXISTS cdc_cdl.cdc_heartbeat;

```
CREATE TABLE cdc_cdl.cdc_heartbeat (
cdl_job_id int8 NOT NULL,
cdl_last_heartbeat timestamp(6)
);
ALTER TABLE cdc_cdl.cdc_heartbeat ADD CONSTRAINT cdc_heartbeat_pkey
PRIMARY KEY (cdl_job_id);
```

步骤 2 心跳表创建完成后，在 CDL WebUI 界面创建从 Postgresql 抓取数据到 Hudi 的同步任务并启动即可收到心跳数据。

----结束

配置 opengauss 到 Hudi 任务的心跳表

步骤 1 在需要同步的 opengauss 数据库下执行以下命令创建一张心跳表，心跳表归属 **cdc_cdl** Schema，表名为 **cdc_heartbeat**，主键为 **cdl_job_id**：

```
DROP TABLE IF EXISTS cdc_cdl.cdc_heartbeat;
CREATE TABLE cdc_cdl.cdc_heartbeat (
cdl_job_id int8 NOT NULL,
cdl_last_heartbeat timestamp(6)
);
ALTER TABLE cdc_cdl.cdc_heartbeat ADD CONSTRAINT cdc_heartbeat_pkey
PRIMARY KEY (cdl_job_id);
```

步骤 2 将该心跳表加入到 DRS 任务，以确保心跳表数据正常发送到 DRS Kafka。

步骤 3 在 CDL WebUI 界面配置 openguass 的 thirdparty-kafka 连接时增加 opengauss 的连接信息，如果 opengauss 部署为一主多备模式，需在“host”填写所有的 IP。

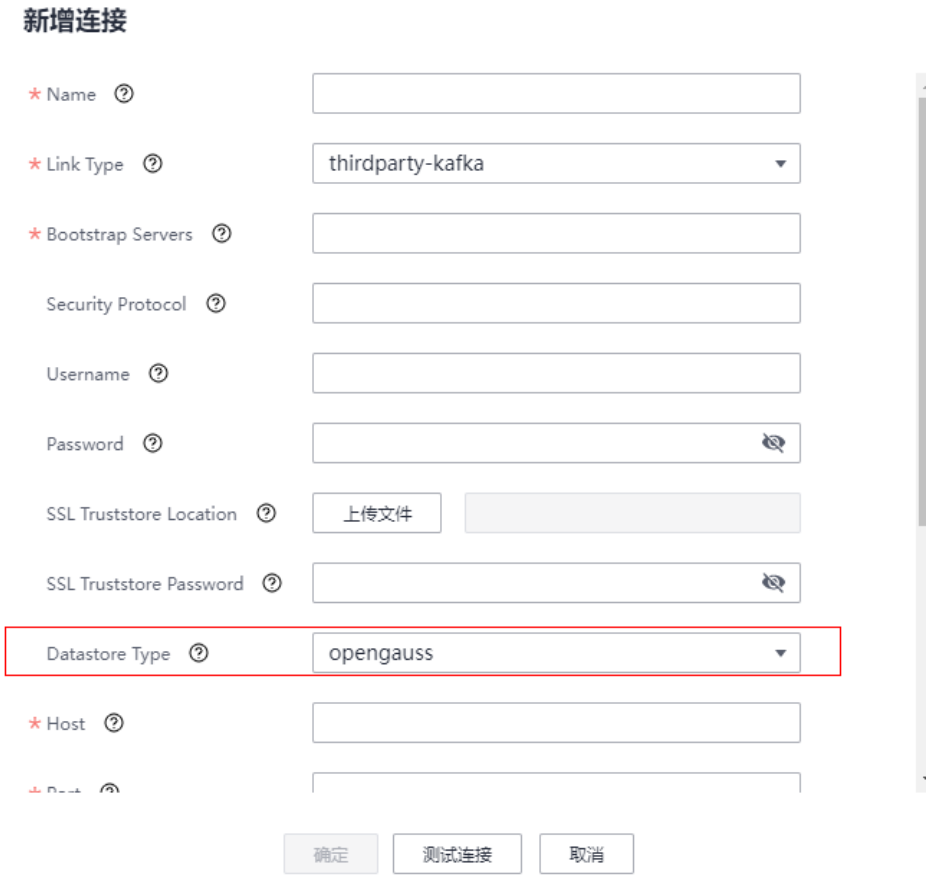

步骤 4 配置完成之后，在 CDL WebUI 界面创建从 thirdparty-kafka 抓取数据到 Hudi 的任务并启动即可收到心跳数据。

----结束

数据判齐消息字段含义

表2-28 数据判齐消息字段

字段名	描述
cdl_job_name	本批次数据所属同步任务名称
target_table_schema	本批次数据写入 Schema 名称
target_table_name	本批次数据写入 Hudi 表名称
target_table_path	本批次数据保存的 Hudi 表路径
total_num	本批次数据总数
cdl_original_heartbeat	本批次数据中包含的心跳数据的最大时间， 如果本批次不包含心跳数据则值为空
cdl_last_heartbeat	本批次数据中包含的心跳数据的最小时间，如果本批次不包含心跳数据则取

字段名	描述
	“event_time_min”的值
insert_num	本批次数据 **insert** 事件总数
update_num	本批次数据 **update** 事件总数
delete_num	本批次数据 **delete** 事件总数
event_time_min	本批次数据源端最小事物提交时间
event_time_max	本批次数据源端最大事物提交时间
event_time_avg	本批次数据源端平均事物提交时间
kafka_timestamp_min	本批次数据发送到 Kafka 的最小时间
kafka_timestamp_max	本批次数据发送到 Kafka 的最大时间
begin_time	本批次数据开始写入 Hudi 的时间
end_time	本批次数据写入 Hudi 的结束时间
cdc_partitioned_time	心跳表的时间分区字段
cdc_last_update_date	该条判齐记录写入时间

2.5 创建 CDL 作业

2.5.1 创建 CDL 数据同步任务作业

操作场景

CDLService WebUI 提供可视化的作业编排页面，用户可快速创建 CDL 作业，实现实时数据入湖。

前提条件

开启 Kerberos 认证的集群需已创建具有 CDL 管理操作权限的用户。

操作步骤

步骤 1 使用具有 CDL 管理操作权限的用户或 **admin** 用户（未开启 Kerberos 认证的集群）登录 CDLService WebUI 界面，请参考 2.4.2 登录 CDLService WebUI。

步骤 2 选择“作业管理 > 数据同步任务 > 新建作业”，在弹出的窗口中输入作业相关信息，然后单击“下一步”。

参数名称	描述	示例

参数名称	描述	示例
Name	作业名称。	job_pgsqltokafka
Desc	描述信息。	xxx

步骤 3 在“作业管理”界面，根据业务数据流向，从界面左侧列表中分别选择“Source”和“Sink”中数据连接元素并将其拖到右侧的操作界面中。

MRS 3.2.0 版本：

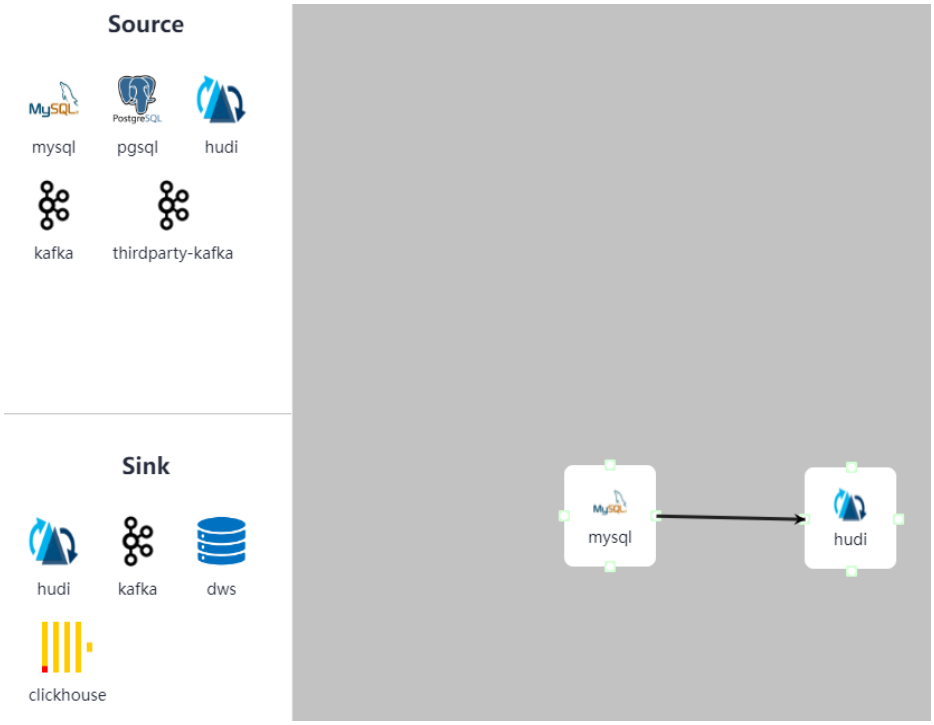

MRS 3.3.0 及之后版本：

双击数据连接元素，并配置对应参数。

如需删除数据连接元素，选择该目标并单击界面右下角的“删除”。

表2-29 MySQL 作业参数

参数名称	描述	示例
Link	已创建的 MySQL 连接。	mysqllink
Tasks Max	允许 Connector 创建的最大 Task 的数量，数据库类型的 Connector 只允许配置为 1。	1
Mode	任务需要抓取的 CDC 事件类型。 • insert：插入操作 • update：更新操作 • delete：删除操作	insert、update、delete
DB Name	MySQL 数据库名称。	cdl-test

参数名称	描述	示例
Schema Auto Create	是否在启动任务时抓取表的 Schema 信息。	否
Connect With Hudi	是否对接 Hudi。	是
DBZ Snapshot Locking Mode	任务启动执行快照时的锁模式。 • minimal：仅在获取数据库 schema 和其他元数据时，持有全局读锁。 • extend：在整个执行快照期间都持有全局读锁，阻塞全部写入操作。 • none: 无锁模式，要求启动 CDL 任务期间不能有 schema 的变更。 可选参数，单击显示该参数。	none
WhiteList	待抓取表的白名单。 配置需要抓取的表的名单列表，多个表可以用英文逗号分隔，支持通配符。 可选参数，单击显示该参数。	testtable
BlackList	表的黑名单。 配置不需要抓取的表的名单列表，多个表可以用英文逗号分隔，支持通配符。 可选参数，单击显示该参数。	-
Multi Partition	是否开启 Topic 的多分区。 开启之后需要配置“Topic TableMapping”并指定 Topic 的分区数量， 单表数据将分散在多个分区中。 可选参数，单击显示该参数。	否

参数名称	描述	示例
	说明 ● 此配置项为高危配置，开启后无法保证数据的时间顺序。 ● 默认分区数为“5”，若需修改则需登录FusionInsight Manager，选择“集群 > 服务 > CDL > 配置”，在搜索框中搜索“topics.max.partitions”并修改该值为需要修改的分区数，例如，修改值为“10”，保存配置并重启CDL服务。 ● MRS 3.3.0及之后版本，当源端表为分区表且该参数为否时，CDL创建的Topic分区表数量为源端表分区数量+1。	
Topic Table Mapping	Topic与表的映射关系。 用于指定某个表的数据发送到指定的Topic中，开启多分区功能后需要配置Topic的分区数，分区数必须大于1。MRS 3.3.0及之后版本，数据过滤时间用于过滤数据，当源端数据的时间小于设定时间时，该数据将会被丢弃，当源端数据的时间大于设定时间时，该数据发送到下游。 单击显示该参数。若“Connect With Hudi”选择“是”，则该参数为必填项。	testtable testtable_topic 2023/03/10 11:33:37（MRS 3.3.0及之后版本支持）

表2-30 PgSQL 作业参数

参数名称	描述	示例
Link	已创建的PgSQL连接。	pgsqllink
Tasks Max	允许Connector创建的最大Task的数量，数据库类型的Connector只允许配	1

参数名称	描述	示例
	置为 1。	
Mode	任务需要抓取的 CDC 事件类型。 • insert：插入操作 • update：更新操作 • delete：删除操作	insert、update、delete
dbName Alias	数据库名称。	test
Schema	待连接的数据库的 Schema 名称。	public
Slot Name	PgSQL 逻辑复制槽的名称。 不同任务之间槽名不能重名，支持小写字母和下划线。	test_solt
Enable FailOver Slot	开启 Failover Slot 功能，将指定为 Failover Slot 的逻辑复制槽信息从主实例同步到备实例，当主备切换之后逻辑订阅能够继续进行，实现逻辑复制槽的故障转移。	否
Slot Drop	任务停止时是否删除 Slot。	否
Connect With Hudi	是否对接 Hudi。	是
Use Exist Publication	使用已创建的 publication。	是
Publication Name	已创建的 publication 名称。 “Use Exist Publication”选择“是”时显示该参数。	test
Start Time（MRS 3.2.0 版本）	同步表的起始时间。	2022/03/16 11:33:37
Data Filter Time（MRS 3.3.0 及之后版本）	数据过滤的起始时间。	2022/03/16 11:33:37
WhiteList	待抓取表的白名单。 配置需要抓取的表的名单列表，多个表可以用英文	testtable

参数名称	描述	示例
	逗号分隔，支持通配符。 可选参数，单击显示该参数。	
BlackList	表的黑名单。 配置不需要抓取的表的名单列表，多个表可以用英文逗号分隔，支持通配符。 可选参数，单击显示该参数。	-
Start Position	任务抓取数据的起始 LSN 位置。 仅 MRS 3.2.0 版本支持。	-
Start Txid	任务抓取数据的起始 TXID 位置。 仅 MRS 3.2.0 版本支持。	-
Multi Partition	是否开启 Topic 的多分区。 开启之后需要配置“Topic TableMapping”并指定 Topic 的分区数量， 单表数据将分散在多个分区中。 可选参数，单击显示该参数。 **说明** ● 此配置项为高危配置，开启后无法保证数据的时间顺序。 ● 默认分区数为“5”，若需修改则需登录 FusionInsight Manager，选择“集群 > 服务 > CDL > 配置”，在搜索框中搜索“topics.max.partitions”并修改该值为需要修改的分区数，例如，修改值为“10”，保存配置并重启 CDL 服务。 ● MRS 3.3.0 及之后版本，当源端表为分区表且该参数为否时，CDL 创建的 Topic 分区表数量为源	否

参数名称	描述	示例
	端表分区数量+1。	
Topic Table Mapping	Topic 与表的映射关系。 用于指定某个表的数据发送到指定的 Topic 中，开启多分区功能后需要配置 Topic 的分区数，分区数必须大于 1。MRS 3.3.0 及之后版本，数据过滤时间用于过滤数据，当源端数据的时间小于设定时间时，该数据将会被丢弃，当源端数据的时间大于设定时间时，该数据发送到下游。 单击显示该参数。若“Connect With Hudi”选择“是”，则该参数为必填项。	testtable testtable_topic 2023/03/10 11:33:37（MRS 3.3.0 及之后版本）

表2-31 Source Hudi 作业参数（MRS 3.2.0 版本）

参数名称	描述	示例
Link	Hudi App 使用的 Link。	hudilink
Interval	同步 Hudi 表的时间间隔，单位：秒。	10
Start Time	同步表的起始时间。	2022/03/16 11:40:52
Max Commit Number	单次增量视图拉取 Commit 的最大数量。	10
Hudi Custom Config	Hudi 相关的自定义配置。	-
Table Info	同步表的详细配置信息。要求 Hudi 与 DWS 的表名一致，且字段类型相同。	{"table1":[{"source.database":"base1","source.tablename":"table1"}],"table2":[{"source.database":"base2","source.tablename":"table2"}],"table3":[{"source.database":"base3","source.tablename":"table3"}]}
Execution Env	Hudi App 运行时需要的环境变量，当前若无可用的 ENV，则需先手动创建	defaultEnv

参数名称	描述	示例
	ENV。	

表2-32 Source Hudi 作业参数（MRS 3.3.0 及之后版本）

参数名称	描述	示例
Link	Hudi App 使用的 Link。	hudilink
Interval	同步 Hudi 表的时间间隔，单位：秒。	10
Data Filter Time	数据过滤时间。	2023/08/16 11:40:52
Max Commit Number	单次增量视图拉取 Commit 的最大数量。	10
Hudi 表属性配置方式	Hudi 表属性配置方式，包括： • 可视化视图。 • JSON 视图。	可视化视图
Hudi Custom Config	Hudi 相关的自定义配置。	-
Table Info	同步表的详细配置信息。要求 Hudi 与 DWS 的表名一致，且字段类型相同。	{"table1":[{"source.database":"base1","source.tablename":"table1"}],"table2":[{"source.database":"base2","source.tablename":"table2"}],"table3":[{"source.database":"base3","source.tablename":"table3"}]}
Table Info-Section Name	单表标签名称，仅支持数字、字母、下划线。	-
Table Info-Source DataBase	需要同步的 Hudi 数据库名称。	base1
Table Info-Source TableName	需要同步的 Hudi 表名。	table1
Table Info-Target SchemaName	数据写入目标数据库的 Schema 名称。	-
Table Info-Target TableName	数据写入目标数据库的表名称。	-
Table Info-Enable Sink Precombine	目标数据库是否启用预合并，当前仅支持目标库为 DWS 时启用预合并功能。	是

参数名称	描述	示例
	该功能用于当新值预合并字段比目标端预合并字段大时，则覆盖目标端已有数据；当新值预合并字段比目标端预合并字段小时，则丢弃新数据。	
Table Info-Custom Config	Hudi 自定义配置。	-
Execution Env	Hudi App 运行时需要的环境变量，当前若无可用的 ENV，则需先手动创建 ENV。	defaultEnv

表2-33 Source Kafka 作业参数（仅适用于 MRS 3.2.0 版本）

参数名称	描述	示例
Link	已创建的 kafka 连接。	kafkalink

表2-34 thirdparty-kafka 作业参数

参数名称	描述	示例
Link	已创建的 thirdparty-kafka 连接。	thirdparty-kafkalink
DB Name	待连接的数据库名称，名称只能由英文字母、数字、下划线和中划线组成，且必须以英文字母开头。	opengaussdb
Schema	待检测数据库的 Schema 名称。	oprngaussschema
Datastore Type	上层源的类型。 • MRS 3.2.0 版本： – opengauss – ogg – oracle – drs-avro-oracle • MRS 3.3.0 及之后版本： – drs-opengauss-json	• opengauss • drs-opengauss-json

参数名称	描述	示例
	– ogg-oracle-avro – drs-oracle-json – drs-oracle-avro	
Avro Schema Topic	Ogg Kafka 使用的 Schema Topic 以 JSON 格式存储表的 Schema。 说明 “Datastore Type”为“ogg”（MRS 3.3.0 及之后版本为“ogg-oracle-avro”）显示该参数。	ogg_topic
Source Topics	源端 Topic 可以包含英文字母、数字、特殊字符(-,_)，各 Topic 应该以英文逗号分隔。	topic1
Tasks Max	允许 Connector 创建的最大 Task 的数量，数据库类型的 Connector 只允许配置为 1。	10
Tolerance	容灾策略。 • none 表示低容错，即出错后导致 Connector 任务失败。 • all 表示高容错，出错后忽略失败的记录并继续运行。	all
Start Time（MRS 3.2.0 版本）	同步表的起始时间。	2022/03/16 14:14:50
Data Filter Time（MRS 3.3.0 及之后版本）	数据过滤的起始时间。	2022/03/16 14:14:50
Kaka Message Format	Kafka 中的消息格式，包括： • Debezium Json • CDL Json 说明 • 仅 MRS 3.3.0 及之后版本支持该参数。 • 仅“Datastore Type”为“drs-opengauss-json”时支持该参数。	CDL Json
Multi Partition	是否开启 Topic 多分区功	否

参数名称	描述	示例
	能，开启之后需要配置 Topic TableMapping 并指定 Topic 的分区数量， 单表数据将分散在多个分区中。其中： • MRS 3.2.0 版本，“Datastore Type”参数值为“ogg”或“drs-avro-oracle”或“oracle”时不支持开启 Topic 多分区功能。 • MRS 3.3.0 及之后版本，当“Datastore Type”参数值为“ogg-oracle-avro”或“drs-oracle-avro”或“drs-oracle-json”时不支持开启 Topic 多分区功能。 说明 默认分区数为“5”，若需修改则需登录 FusionInsight Manager，选择“集群 > 服务 > CDL > 配置”，在搜索框中搜索“topics.max.partitions”并修改该值为需要修改的分区数，例如，修改值为“10”，保存配置并重启 CDL 服务。	
Topic Table Mapping	Topic 与表的映射关系。 用于指定某个表的数据发送到指定的 Topic 中，开启多分区功能后需要配置 Topic 的分区数，分区数必须大于 1。MRS 3.3.0 及之后版本，数据过滤时间用于过滤数据，当源端数据的时间小于设定时间时，该数据将会被丢弃，当源端数据的时间大于设定时间时，该数据发送到下游。	testtable testtable_topic 2023/03/10 11:33:37（MRS 3.3.0 及之后版本）

表2-35 openguass 作业参数（仅适用于 MRS 3.3.0 及之后版本）

参数名称	描述	示例
Link	已创建的 openguass 连接。	openguasslink
Tasks Max	允许 Connector 创建的最大 Task 的数量，值为“1”。	1
Mode	任务需要抓取的 CDC 事件类型。 • insert：插入操作 • update：更新操作 • delete：删除操作	insert、update、delete
dbName Alias	数据库名称。	test
Slot Name	openguass 逻辑复制槽的名称。 不同任务之间槽名不能重名，支持小写字母和下划线。	test_solt
Slot Drop	任务停止时是否删除 Slot。	否
Connect With Hudi	是否对接 Hudi。	是
WhiteList	待抓取表的白名单。 配置需要抓取的表的名单列表，多个表可以用英文逗号分隔，支持通配符。	testtable
Data Filter Time	数据过滤时间。	-
Multi Partition	是否开启 Topic 的多分区。 开启之后需要配置“Topic TableMapping”并指定 Topic 的分区数量， 单表数据将分散在多个分区中。 说明 • 此配置项为高危配置，开启后无法保证数据的时间顺序。 • 默认分区数为“5”，若需修改则需登录 FusionInsight Manager，	否

参数名称	描述	示例
	选择“集群 > 服务 > CDL > 配置”，在搜索框中搜索“topics.max.partitions”并修改该值为需要修改的分区数，例如，修改值为“10”，保存配置并重启 CDL 服务。	
Key Management Tool	秘钥管理工具。当前仅支持“his_kms”秘钥管理工具。	his_kms
Key Environment Information	密钥信息。仅配置了“Key Management Tool”密钥管理工具才支持该参数。	-
Custom Config	自定义解码配置。	-
Topic Table Mapping	Topic 与表的映射关系，表名格式为：*Schema 名.表名*。 用于指定某个表的数据发送到指定的 Topic 中，开启多分区功能后需要配置 Topic 的分区数，分区数必须大于 1。数据过滤时间用于过滤数据，当源端数据的时间小于设定时间时，该数据将会被丢弃，当源端数据的时间大于设定时间时，该数据发送到下游。 若“Connect With Hudi”选择“是”，则该参数为必填项。	cdlschema.testtable testtable_topic 2023/03/10 11:33:37

表2-36 Sink Hudi 作业参数

参数名称	描述	示例
Link	已创建的 Hudi 连接。	hudilink
Path	数据存储路径。	/cdldata
Interval	Spark RDD 的执行周期，单位：秒。	1

参数名称	描述	示例
Max Rate Per Partition	使用 Kafka direct stram API 时，从每个 Kafka 分区读取数据的最大速率限制，单位：个/秒， 0 表示无限制。	0
Parallelism	写 Hudi 时的并发数。	100
Target Hive Database	目标 Hive 的数据库名称。	default
Hudi 表属性配置方式	Hudi 表属性配置方式，包括： • 可视化视图 • JSON 视图	可视化视图
Hudi 表属性全局配置	Hudi 侧的全局参数。	-
Hudi 表属性配置	Hudi 表属性配置。	-
Hudi 表属性配置-Table Name/Source Table Name（MRS 3.3.0 及之后版本）	源端表名。	-
Hudi 表属性配置-Table Type Opt Key	Hudi 表类型，包括： • COPY_ON_WRITE • MERGE_ON_READ	MERGE_ON_READ
Hudi 表属性配置-Hudi TableName Mapping	Hudi 表名称，若不设置，则默认与源表名相同。	-
Hudi 表属性配置-Hive TableName Mapping	Hudi 表同步到 Hive 的表名映射关系，自定义表名。	-
Hudi 表属性配置-Table Primarykey Mapping	Hudi 表的主键对应关系。	id
Hudi 表属性配置-Table Hudi Partition Type	Hudi 表和分区字段映射关系，如果 Hudi 表采用分区表，则需要配置表名和分区字段的对应关系，包括“time”和“customized”。	time
Hudi 表属性配置-Custom Config	自定义配置。 **说明** MRS 3.3.0 及之后版本，从 MySQL 同步数据到 Hudi 时，需要指定“hoodie.datasource.write.precombine.field”参数，若 MySQL	-

参数名称	描述	示例
	的 timestamp、datetime 类型精度只支持秒级，则不建议指定 timestamp、datetime 类型及_hoodie_event_time 字段作为 precombine 字段。该功能用于当新值预合并字段比 Hudi 端预合并字段大时，则覆盖 Hudi 端已有数据；当新值预合并字段比 Hudi 端预合并字段小时，则丢弃新数据。	
Execution Env	Hudi App 运行时需要的环境变量，当前若无可用的 ENV，则需先参考 2.4.5 管理 ENV 进行创建。	defaultEnv

表2-37 Sink Kafka 作业参数

参数名称	描述	示例
Link	已创建的 kafka 连接。	kafkalink

表2-38 DWS 作业参数

参数名称	描述	示例
Link	Connector 使用的连接。	dwslink
Query Timeout	连接 DWS 的超时时间，单位：毫秒。	180000
Batch Size	批次写入 DWS 的数据量。	50
Sink Task Number	单个表写入 DWS 时的最大并行作业数。	-
DWS Custom Config	自定义配置。	-

表2-39 ClickHouse 作业参数

参数名称	描述	示例
Link	Connector 使用的连接。	dwslink
Query Timeout	连接 ClickHouse 的超时时	60000

参数名称	描述	示例
	间，单位：毫秒。	
Batch Size	批次写入 ClickHouse 的数据量。 **说明** 设置单批次写入 ClickHouse 的数据量时数值尽量大，建议取值范围为：10000~100000。	100000

步骤 4 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

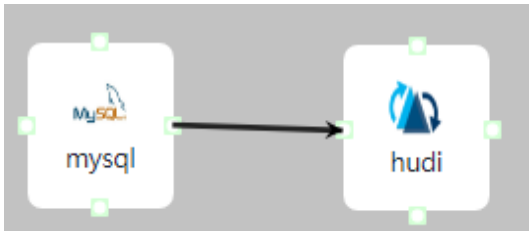

步骤 5 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 MySQL 数据库中对作业中指定的表进行插入数据操作，查看 Hudi 导入的文件内容是否正常。

----结束

2.5.2 创建 CDL 数据比较任务作业

操作场景

数据比对即是对源端数据库中的数据和目标端 Hive 中的数据作数据一致性校验，如果数据不一致，CDL 可以尝试修复不一致的数据。

当前数据对比任务支持手动全量任务比对。数据比对任务采用 On Yarn 的运行形态，比对结果会上传到 HDFS 目录。

说明

- 数据比对目前仅支持基本数据类型比对， 不支持日期、时间戳、decimal、numeric、json 等特殊数据类型的比对。
- 数据比对任务不支持数据表字段名包含数据库关键字的表进行数据比对。
- 数据比对任务单表比较仅支持 100 个以内的字段进行比较， 如果单表的字段超过一百， 可以分两次指定不同的比较字段的白名单进行数据比对。
- 当前只支持对从 PgSQL 抓取到 Hudi 的数据进行比对，若“比较结果”为“不一致”，不一致的数据需小于或等于 2000 行才会生成报告地址；若不一致的数据大于 2000 行，则不会生成报告地址，并且不支持修复数据。

- 参与比对的 CDL 任务 kafka lag 不为 0 时会导致比对结果不一致。

前提条件

1. 准备 Hive UDF Jar 包， 从 CDL 的安装目录拷贝“${BIGDATA_HOME}/FusionInsight_CDL_*/install/FusionInsight-CDL-*/cdl/hive-checksum/cdl-dc-hive-checksum-*.jar”UDF Jar 到 Hive 的“${BIGDATA_HOME}/third_lib/Hive”目录下，并设置该 Jar 包的权限为大于或等于 750。
2. 开启 Kerberos 认证的集群需已创建具有 CDL 管理操作权限的用户。若当前集群开启了 Ranger 鉴权，还需参考 20.10 添加 Hive 的 Ranger 访问权限策略章节授予用户 Hive 管理员权限和 UDF 操作权限。
3. 使用具有 Hive 管理员权限的用户在 Hive 客户端创建全局的 UDF 算法：

   创建 CheckSum 函数（在 default 数据库下执行）：

   create function checksum_aggregate as 'com.xxx.hive.checksum.ChecksumUdaf'
4. 创建比较任务之前一定要存在 CDL 同步任务，比较任务会在启动前感知同步任务的状态和数据同步情况来决定对哪些数据做比较。
5. 数据比对关联的数据同步任务中的数据库用户需要对当前 Schema 具有 **create function** 权限。

操作步骤

步骤 1 使用已创建的用户或 **admin** 用户（未开启 Kerberos 认证的集群）登录 CDLService WebUI 界面，请参考 2.4.2 登录 CDLService WebUI。

步骤 2 选择“作业管理 > 数据比较任务 > 新建作业”，在弹出的窗口中输入作业相关信息，然后单击“下一步”。其中：

参数名称	说明	示例
Name	数据比较任务名	job_dc_test
CDL Job Name	关联的同步任务名（注意：此处运行比较任务的用户就是关联的同步任务中 Hudi Link 对应的用户）	pg2hudi_test
Execution Env	运行 Spark 任务时需要的环境变量，若当前若无可用的 ENV，则需先参考 2.4.5 管理 ENV 进行创建。	dc_env
Desc	描述信息	-

步骤 3 在“创建 Compare-Pair”界面参照下表进行参数设置，并单击“创建”。

参数名称	说明	示例
Name	当前比对任务名。	test
Source Table	源端表名。	tabletest
Target Table	目标端表名。	tabletest
WhiteList Columns	参与数据比较的列族。	-
BlackList Columns	不参与数据比较的列族。	-
Where Condition	自定义比较条件	-

若需比较多张表，可单击“添加”新增。

步骤 4 在数据比较任务列表中单击新建作业所在行的“启动”，启动数据比对任务。

步骤 5 运行结束后，可在数据比较任务列表的“比较结果”列查看运行结果。

步骤 6 若“比较结果”为“不一致”，可选择“更多 > 查看记录”。

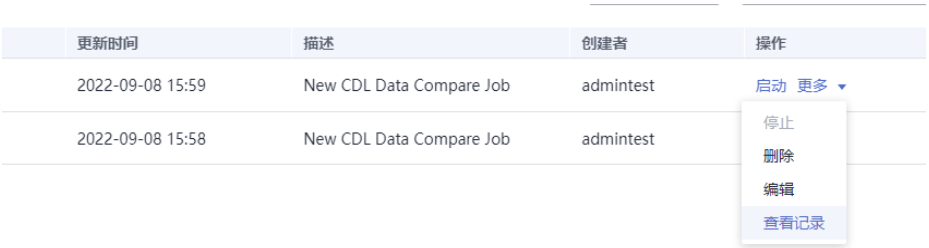

步骤 7 进入任务运行记录窗口，单击对应任务的“操作”列的“查看结果”。

步骤 8 单击“修复”，尝试修复内容。

步骤 9 修复完成后，查看“比较结果”是否为“一致”，“一致”则表示数据修复成功；若比较结果为“不一致”，则表示修复失败，可以根据“报告地址”在 HDFS 对应目录中获取报告，进行手动修复。

----结束

2.5.3 常见 CDL 作业示例

2.5.3.1 从 PgSQL 同步数据到 Kafka

操作场景

本章节指导用户通过 MRS 3.2.0 版本开启 Kerberos 认证的集群的 CDLService WebUI 界面，从 PgSQL 导入数据到 Kafka。

前提条件

- 集群已安装 CDL、Kafka 服务且运行正常。
- PostgreSQL 数据库需要修改预写日志的策略，操作步骤请参考 PostgreSQL 数据库修改预写日志的策略。
- 在 FusionInsight Manager 中创建一个人机用户，例如“cdluser”，加入用户组 **cdladmin**、**hadoop**、**kafka**，主组选择“cdladmin”组，关联角色“System_administrator”。

操作步骤

步骤 1 使用 **cdluser** 用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > CDL”，在 CDL“概览”界面单击“CDLService UI”右侧的超链接，进入 CDL 原生界面。

步骤 2 选择“连接管理 > 新增连接”，进入“新增连接”参数配置窗口，参考下表，分别新增“pgsql”和“kafka”连接，相关数据连接参数介绍请参见 2.4.4 创建数据库连接。

表2-40 PgSQL 数据连接配置参数

参数名称	示例
Link Type	pgsql
Name	pgsqllink
Host	10.10.10.10
Port	5432
DB Name	testDB
User	user
Password	*user 用户密码*
Description	-

表2-41 Kafka 数据连接配置参数

参数名称	示例
Link Type	kafka
Name	kafkalink
Description	-

步骤 3 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

步骤 4 在“作业管理”页面单击“新建作业”。在“新建作业”窗口中填写配置。单击“下一步”，进入作业参数配置页面。

其中：

参数名称	示例
Name	job_pgsqltokafka
Desc	xxx

步骤 5 配置 PgSQL 作业参数。

1. 在作业参数配置页面，选取左侧“pgsql”图标拖入右侧编辑区域，然后双击此图标进入 PgSQL 作业参数配置窗口，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-42 PgSQL 作业参数

参数名称	示例
Link	pgsqllink
Tasks Max	1
Mode	insert、update、delete
Schema	public
dbName Alias	cdc
Slot Name	test_solt
Slot Drop	否
Connect With Hudi	否
Use Exist Publication	是
Publication Name	test

2. 单击“+”按钮展开更多选项。

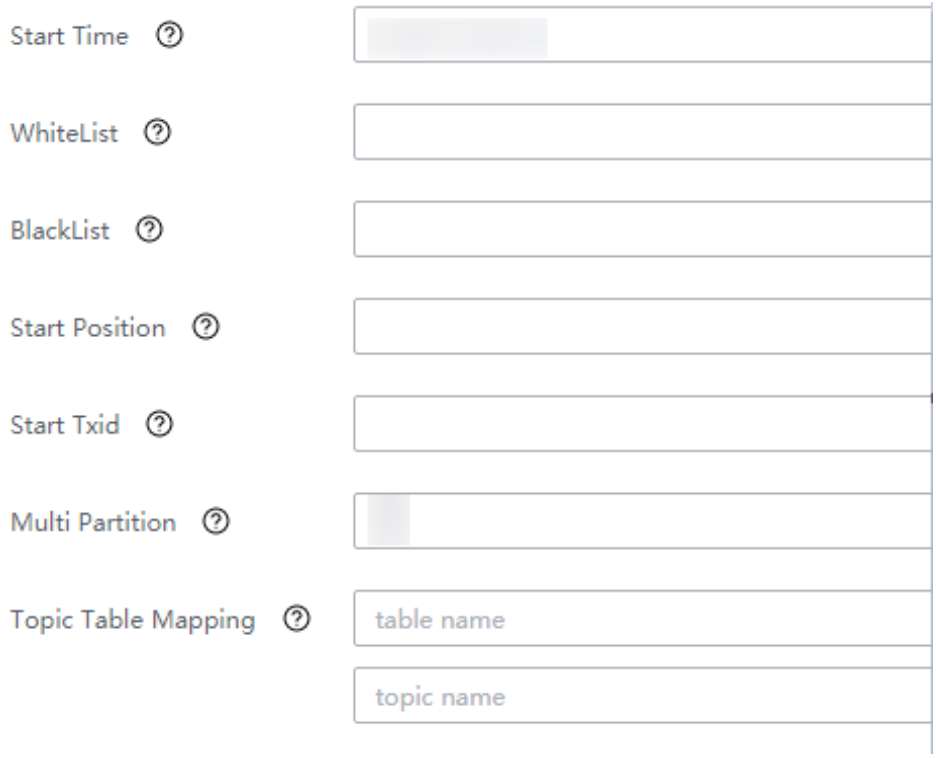

说明

- “WhiteList”：输入数据库中的表（如 myclass）
- “Topic Table Mapping”：第一个框输入 topic 名（与步骤 4 中作业名称“Name”的值不能一样，例如 myclass_topic）。 第二个框输入表名（例如 myclass。该值与第一个框的 topic 只能是一对一的关系）。

3. 单击“确定”，PgSQL 作业参数配置完成。

步骤 6 配置 Kafka 作业参数。

1. 在作业参数配置页面，选取左侧“kafka”图标拖入右侧编辑区域，然后双击此图标进入 Kafka 作业参数配置窗口。参考表 2-43 进行参数配置。

表2-43 Kafka 作业参数

参数名称	示例
Link	kafkalink

2. 单击“确定”，完成 Kafka 作业参数配置。

步骤 7 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

步骤 8 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 PgSQL 数据库中对表进行插入数据操作，然后参考 16.17.5 使用 KafkaUI 管理 Topic 进入 KafkaUI 界面查看 Kafka 的 Topic 中是否有数据生成。

----结束

2.5.3.2 从 PgSQL 同步数据到 Hudi

操作场景

本章节指导用户通过 MRS 3.2.0 版本开启 Kerberos 认证的集群的 CDLService WebUI 界面，从 PgSQL 导入数据到 Hudi。

前提条件

- 集群已安装 CDL、Hudi 服务且运行正常。
- PgSQL 数据库需要开启前置要求，操作步骤请参考 PostgreSQL 数据库修改预写日志的策略。
- 在 FusionInsight Manager 中创建一个人机用户，例如“cdluser”，加入用户组 **cdladmin**、**hadoop**、**kafka**、**supergroup**，主组选择“cdladmin”组，关联角色“System_administrator”。

操作步骤

步骤 1 使用 **cdluser** 用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接，进入 CDLService WebUI 界面。

步骤 2 选择“连接管理 > 新增连接”，进入“新增连接”参数配置窗口，参考下表，分别新增“pgsql”、“hudi”连接，相关数据连接参数介绍请参见 2.4.4 创建数据库连接。

表2-44 PgSQL 数据连接配置参数

参数名称	示例
Link Type	pgsql
Name	pgsqllink
Host	10.10.10.10

参数名称	示例
Port	5432
DB Name	testDB
User	user
Password	*user 用户密码*
Description	-

表2-45 Hudi 数据连接配置参数

参数名称	示例
Link Type	hudi
Name	hudilink
Storage Type	hdfs
Auth KeytabFile	/opt/Bigdata/third_lib/CDL/user_libs/cdluser.keytab
Principal	cdluser
Description	xxx

步骤 3 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

步骤 4 （可选）选择“ENV 管理 > 新建 ENV”，进入“新建 ENV”参数配置窗口，参考下表进行参数配置。

表2-46 新建 ENV 配置参数

参数名称	示例
Name	test-env
Driver Memory	1GB
Type	spark
Executor Memory	1GB
Executor Cores	1
Number Executors	1
Queue	-
Description	-

参数配置完成后，单击“确定”创建 ENV。

步骤 5 选择“作业管理 > 数据同步任务 > 新建作业”，在“新建作业”窗口中填写配置。单击“下一步”，进入作业参数配置页面。

其中：

参数名称	示例
Name	job_pgtohudi
Desc	-

步骤 6 配置 PgSQL 作业参数。

1. 在作业参数配置页面，选取左侧“pgsql”图标拖入右侧编辑区域，然后双击此图标进入 PgSQL 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-47 PgSQL 作业参数

参数名称	示例
Link	pgsqllink
Tasks Max	1
Mode	insert、update、delete
dbName Alias	pgsqldb
Schema	pgschema
Slot Name	pg_slot
Enable FailOver Slot	否
Slot Drop	否
Connect With Hudi	是
Use Exist Publication	否
Publication Name	publicationtest

2. 单击“+”按钮展开更多选项。

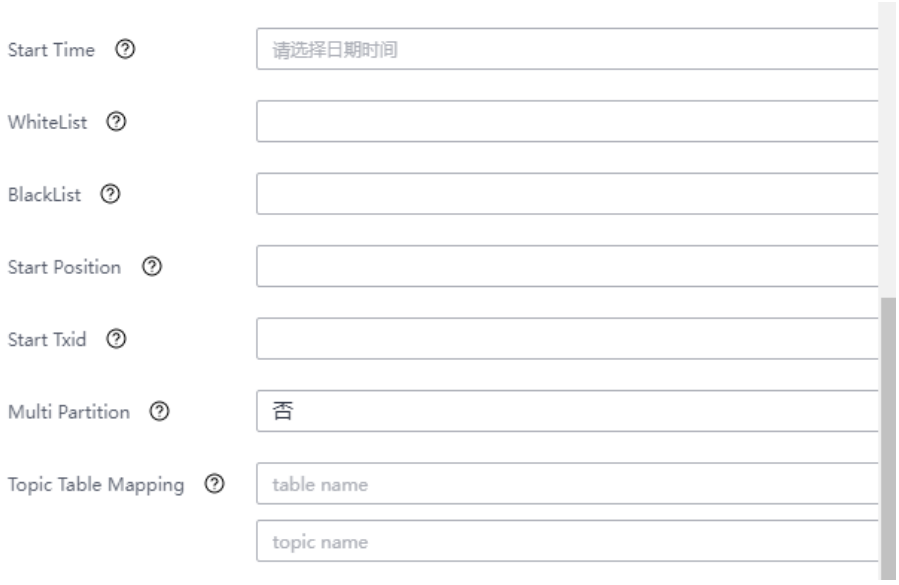

说明

- "Start Time" ：同步表起始时间。
- “WhiteList”：输入数据库中的表。
- “BlackList”： 输入不抓取数据的数据库中的表。
- “Topic Table Mapping”：
- 若“Connect With Hudi”选择“是”，则该参数为必填项。
- 第一个框输入表名（例如“test”）。 第二个框输入 Topic 名（例如“test_topic”，该值与第一个框的表名只能是一对一的关系）。

3. 单击“确定”，Pgsql 作业参数配置完成。

步骤 7 配置 Hudi 作业参数。

1. 在作业参数配置页面，选取左侧 Sink 区域的“hudi”图标拖入右侧编辑区域，然后双击此图标进入 Hudi 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-48 Sink Hudi 作业参数

参数名称	示例
Link	hudilink
Path	/cdl/test
Interval	10
Max Rate Per Partition	0
Parallelism	10
Target Hive Database	default
Hudi 表属性配置方式	可视化视图
Hudi 表属性全局配置	-

参数名称	示例
Hudi 表属性配置-Table Name	test
Hudi 表属性配置-Table Type Opt Key	COPY_ON_WRITE
Hudi 表属性配置-Hudi TableName Mapping	-
Hudi 表属性配置-Hive TableName Mapping	-
Hudi 表属性配置-Table Primarykey Mapping	id
Hudi 表属性配置-Table Hudi Partition Type	-
Hudi 表属性配置-Custom Config	-

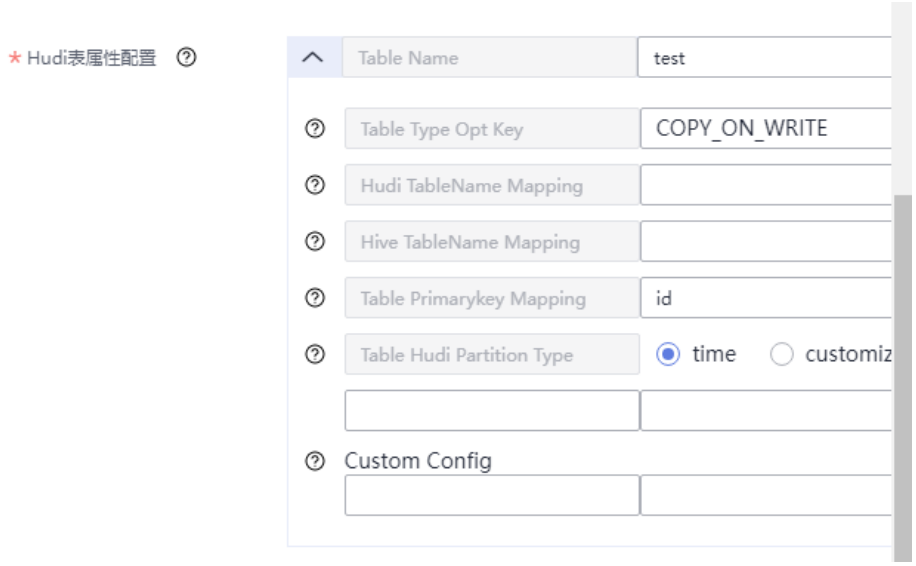

2. （可选）单击“+”按钮展开更多选项，选择已创建的 ENV，默认为“defaultEnv”。

3. 单击“确定”，完成 Hudi 作业参数配置。

步骤 8 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

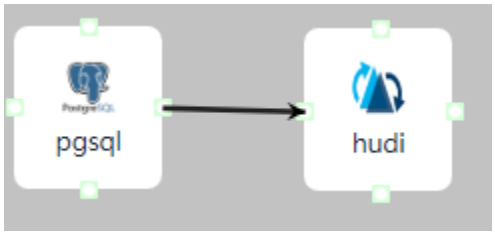

步骤 9 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 PgSQL 数据库中对表进行插入数据操作，查看 Hudi 导入的文件内容。

----结束

2.5.3.3 从 Openguass 同步数据到 Hudi

操作场景

本章节指导用户通过开启 Kerberos 认证的集群的 CDLService WebUI 界面从 Openguass 导入数据到 Hudi。

该章节内容适用于 MRS 3.3.0 及之后版本支持。

前提条件

- 集群已安装 CDL、Hudi 服务且运行正常。
- Openguass 数据库需要开启预写日志功能，操作步骤请参考 Openguass 数据库开启预写日志功能。
- 在 FusionInsight Manager 中创建一个人机用户，例如“cdluser”，加入用户组 **cdladmin**、**hadoop**、**kafka**、**supergroup**，主组选择“cdladmin”组，关联角色“System_administrator”。

操作步骤

步骤 1 使用 **cdluser** 用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接，进入 CDLService WebUI 界面。

步骤 2 选择“连接管理 > 新增连接”，进入“新增连接”参数配置窗口，参考下表，分别新增“openguass”、“hudi”连接，相关数据连接参数介绍请参见 2.4.4 创建数据库连接。

表2-49 openguass 数据连接配置参数

参数名称	示例
Link Type	openguass
Name	openguasslink

参数名称	示例
Host	100.85.xxx.xxx
Port	8000
DB Name	opengaussdb
User	opengaussuser
Password	*opengaussuser 用户密码*
Description	-

表2-50 Hudi 数据连接配置参数

参数名称	示例
Link Type	hudi
Name	hudilink
Storage Type	hdfs
Auth KeytabFile	/opt/Bigdata/third_lib/CDL/user_libs/cdluser.keytab
Principal	cdluser
Description	xxx

步骤 3 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

步骤 4 （可选）选择“ENV 管理 > 新建 ENV”，进入“新建 ENV”参数配置窗口，参考下表进行参数配置。

表2-51 新建 ENV 配置参数

参数名称	示例
Name	test-env
Driver Memory	1GB
Type	spark
Executor Memory	1GB
Executor Cores	1
Number Executors	1
Queue	-

参数名称	示例
Description	-

参数配置完成后，单击“确定”创建 ENV。

步骤 5 选择“作业管理 > 数据同步任务 > 新建作业”，在“新建作业”窗口中填写配置。单击“下一步”，进入作业参数配置页面。

其中：

参数名称	示例
Name	job_opengaustohudi
Desc	-

步骤 6 配置 Openguass 作业参数。

1. 在作业参数配置页面，选取左侧“openguass”图标拖入右侧编辑区域，然后双击此图标进入 openguass 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-52 Openguass 作业参数

参数名称	示例
Link	openguasslink
Tasks Max	1
Mode	insert、update、delete
dbName Alias	opengaussdb
Slot Name	oct_twenty_two
Slot Drop	否
Connect With Hudi	是
Topic Table Mapping	cdlschema.testtable/testtable_topic

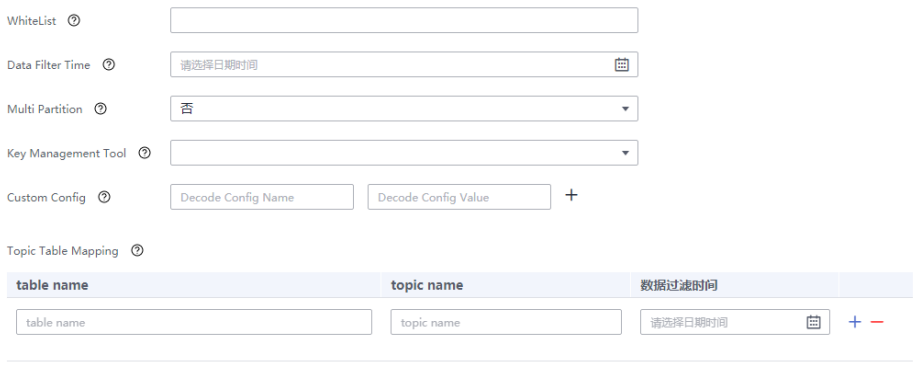

2. 单击“确定”，Openguass 作业参数配置完成。

步骤 7 配置 Hudi 作业参数。

1. 在作业参数配置页面，选取左侧 Sink 区域的“hudi”图标拖入右侧编辑区域，然后双击此图标进入 Hudi 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-53 Sink Hudi 作业参数

参数名称	示例
Link	hudilink
Path	/cdl/test
Interval	5
Max Rate Per Partition	0
Parallelism	10
Hudi 表属性配置方式	可视化视图
Hudi 表属性全局配置	-
Hudi 表属性配置-Source Table Name	cdlschema.testtable
Hudi 表属性配置-Table Type Opt Key	MERGE_ON_READ
Hudi 表属性配置-Hudi TableName Mapping	“testtable”或“/cdlschema/testtable”
Hudi 表属性配置-Hive TableName Mapping	cdlschema.testtable
Hudi 表属性配置-Table Primarykey Mapping	so_line_id,order_number
Hudi 表属性配置-Table Hudi Partition Type	time
Hudi 表属性配置-Custom Config	-

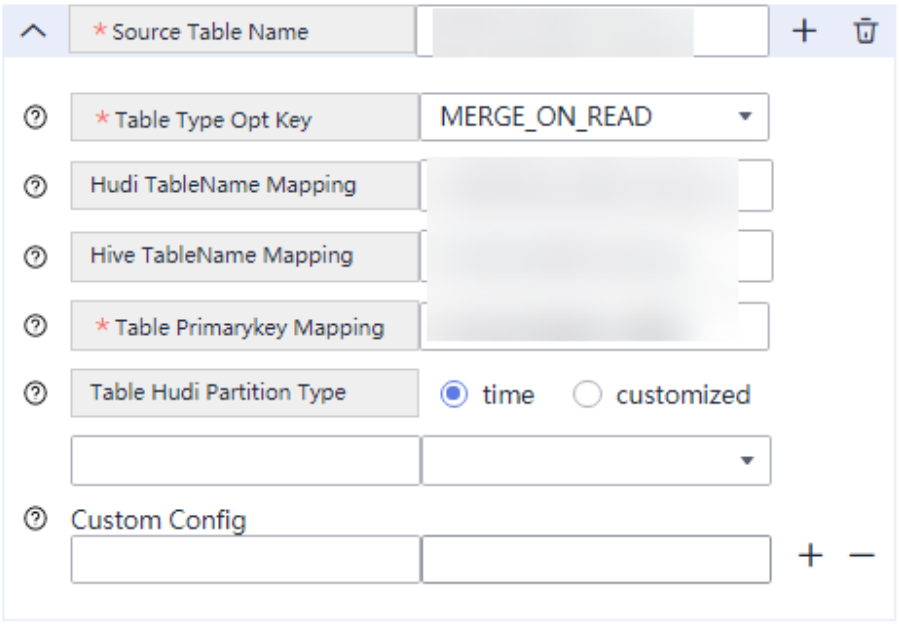

2. （可选）选择已创建的 ENV，默认为“defaultEnv”。

3. 单击“确定”，完成 Hudi 作业参数配置。

步骤 8 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

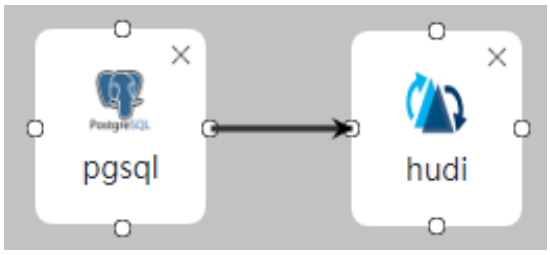

步骤 9 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 openguass 数据库中对表进行插入数据操作，查看 Hudi 导入的文件内容。

----结束

2.5.3.4 从 ThirdKafka 同步 openGauss 数据到 Hudi

操作场景

本章节指导用户通过 MRS 3.2.0 版本开启 Kerberos 认证的集群的 CDLService WebUI 界面，从 ThirdKafka 导入 openGauss 数据到 Hudi。

前提条件

- 集群已安装 CDL、Hudi 服务且运行正常。
- ThirdKafka 数据库的 Topic 需要能被 MRS 集群消费，操作步骤请参考 ThirdPartyKafka 前置准备。
- 在 FusionInsight Manager 中创建一个人机用户，例如“cdluser”，加入用户组 **cdladmin**、**hadoop**、**kafka**、**supergroup**，主组选择“cdladmin”组，关联角色“System_administrator”。

操作步骤

步骤 1 使用 **cdluser** 用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接，进入 CDLService WebUI 界面。

步骤 2 选择“连接管理 > 新增连接”，进入“新增连接”参数配置窗口，参考下表，分别新增“thirdparty-kafka”、“hudi”连接，相关数据连接参数介绍请参见 2.4.4 创建数据库连接。

表2-54 thirdparty-kafka 数据连接配置参数

参数名称	示例
Name	opengausslink
Link Type	thirdparty-kafka
Bootstrap Servers	10.10.10.10:9093
Security Protocol	SASL_SSL
Username	testuser
Password	*testuser 用户密码*
SSL Truststore Location	单击“上传文件”，上传认证文件
SSL Truststore Password	-
Datastore Type	opengauss
Host	11.11.xxx.xxx,12.12.xxx.xxx
Port	8000
DB Name	opengaussdb
User	opengaussuser
DB Password	*opengaussuser 用户密码*
Description	-

说明

thirdparty-kafka 也可以使用 MRS Kafka 作为源端，若使用用户名（Username）密码（Password）进行登录认证，则需先登录 Manager 界面，选择“集群 > 服务 > Kafka > 配置”，在搜索框中搜索“sasl.enabled.mechanisms”，为该参数值增加“PLAIN”，单击“保存”保存配置，并重启 Kafka 服务使配置生效：

再在 CDL WebUI 界面配置使用 MRS Kafka 作为源端的 thirdparty-kafka 连接，例如相关数据连接配置如下：

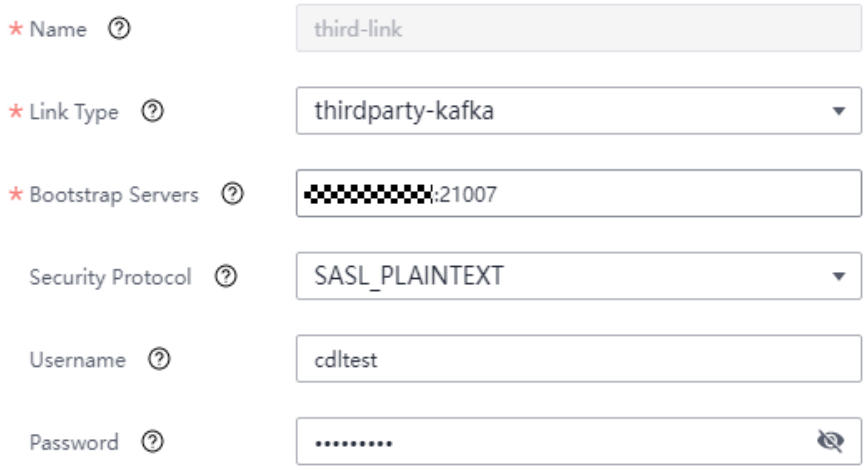

表2-55 Hudi 数据连接配置参数

参数名称	示例
Link Type	hudi
Name	hudilink
Storage Type	hdfs
Auth KeytabFile	/opt/Bigdata/third_lib/CDL/user_libs/cdluser.keytab
Principal	cdluser
Description	-

步骤 3 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

步骤 4 （可选）选择“ENV 管理 > 新建 ENV”，进入“新建 ENV”参数配置窗口，参考下表进行参数配置。

表2-56 新建 ENV 配置参数

参数名称	示例
Name	test-env
Driver Memory	1GB
Type	spark
Executor Memory	1GB
Executor Cores	1
Number Executors	1
Queue	-
Description	-

参数配置完成后，单击“确定”创建 ENV。

步骤 5 选择“作业管理 > 数据同步任务 > 新建作业”，在“新建作业”窗口中填写配置。单击“下一步”，进入作业参数配置页面。

其中：

参数名称	示例
Name	job_opengausstohudi
Desc	New CDL Job

步骤 6 配置 ThirdKafka 作业参数。

1. 在作业参数配置页面，选取左侧“thirdparty-kafka”图标拖入右侧编辑区域，然后双击此图标进入 ThirdpartyKafka 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-57 thirdparty-kafka 作业参数

参数名称	示例
Link	opengausslink
DB Name	opengaussdb
Schema	opengaussschema
Datastore Type	opengauss
Source Topics	source_topic
Tasks Max	1
Tolerance	none

参数名称	示例
Start Time	-
Multi Partition	否
Topic Table Mapping	test/hudi_topic

2. 单击“确定”，ThirdpartyKafka 作业参数配置完成。

步骤 7 配置 Hudi 作业参数。

1. 在作业参数配置页面，选取左侧 Sink 区域的“hudi”图标拖入右侧编辑区域，然后双击此图标进入 Hudi 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-58 Sink Hudi 作业参数

参数名称	示例
Link	hudilink
Path	/cdl/test
Interval	10
Max Rate Per Partition	0
Parallelism	10
Target Hive Database	default
Hudi 表属性配置方式	可视化视图
Hudi 表属性全局配置	-
Hudi 表属性配置-Table Name	test
Hudi 表属性配置-Table Type Opt Key	COPY_ON_WRITE
Hudi 表属性配置-Hudi TableName	-

参数名称	示例
Mapping	
Hudi 表属性配置-Hive TableName Mapping	-
Hudi 表属性配置-Table Primarykey Mapping	id
Hudi 表属性配置-Table Hudi Partition Type	-
Hudi 表属性配置-Custom Config	-

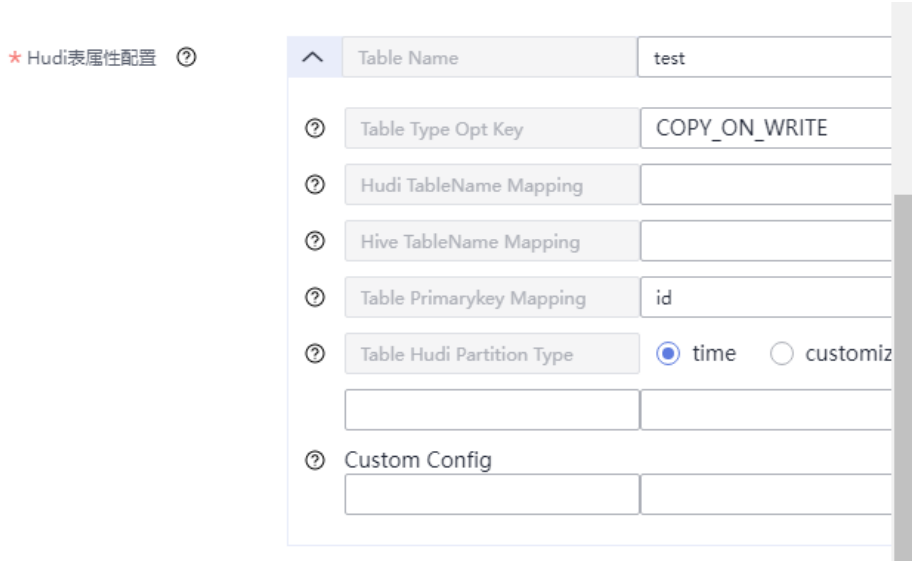

2. （可选）单击“+”按钮展开更多选项，选择已创建的 ENV，默认为“defaultEnv”。

3. 单击“确定”，完成 Hudi 作业参数配置。

步骤 8 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

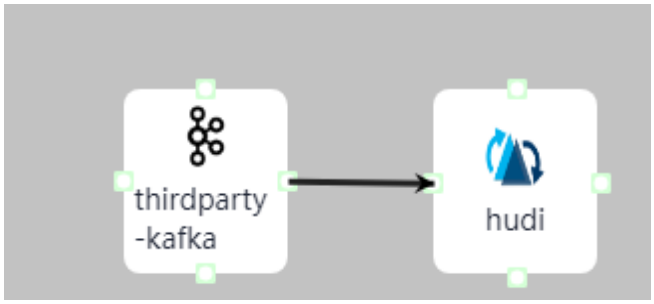

步骤 9 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 opengauss 数据库中对表进行插入数据操作，查看 Hudi 导入的文件内容。

----结束

2.5.3.5 从 ThirdKafka 同步 drs-oracle-json 数据库数据到 Hudi

操作场景

本章节指导用户通过开启 Kerberos 认证的集群的 CDLService WebUI 界面从 ThirdKafka 导入 Oracle 数据库数据到 Hudi。

该章节内容适用于 MRS 3.3.0 及之后版本。

前提条件

- 集群已安装 CDL、Hudi 服务且运行正常。
- ThirdKafka 数据库的 Topic 需要能被 MRS 集群消费，操作步骤请参考 ThirdPartyKafka 前置准备。
- 在 FusionInsight Manager 中创建一个人机用户，例如“cdluser”，加入用户组 **cdladmin**、**hadoop**、**kafka**、**supergroup**，主组选择“cdladmin”组，关联角色“System_administrator”。

操作步骤

步骤 1 使用 **cdluser** 用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接，进入 CDLService WebUI 界面。

步骤 2 选择“连接管理 > 新增连接”，进入“新增连接”参数配置窗口，参考下表，分别新增“thirdparty-kafka”、“hudi”连接，相关数据连接参数介绍请参见 2.4.4 创建数据库连接。

表2-59 thirdparty-kafka 数据连接配置参数

参数名称	示例
Name	oraclelink
Link Type	thirdparty-kafka
Bootstrap Servers	10.10.10.10:9093
Security Protocol	SASL_SSL
Username	testuser
Password	*testuser 用户密码*
SSL Truststore Location	单击“上传文件”，上传认证文件

参数名称	示例
SSL Truststore Password	-
Datastore Type	drs-oracle-json
Description	thirdparty-kafka Link

说明

thirdparty-kafka 也可以使用 MRS Kafka 作为源端，若使用用户名（Username）密码（Password）进行登录认证，则需先登录 Manager 界面，选择“集群 > 服务 > Kafka > 配置”，在搜索框中搜索“sasl.enabled.mechanisms”，为该参数值增加“PLAIN”，单击“保存”保存配置，并重启 Kafka 服务使配置生效：

再在 CDL WebUI 界面配置使用 MRS Kafka 作为源端的 thirdparty-kafka 连接，例如相关数据连接配置如下：

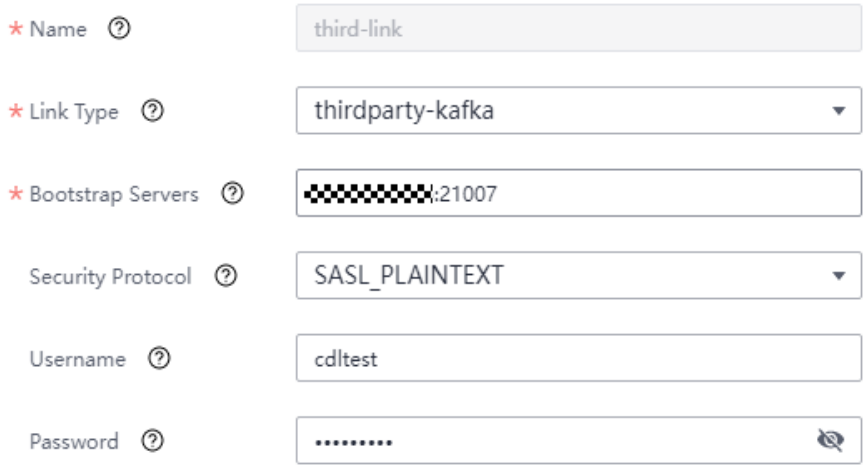

表2-60 Hudi 数据连接配置参数

参数名称	示例
Link Type	hudi
Name	hudilink
Storage Type	hdfs
Auth KeytabFile	/opt/Bigdata/third_lib/CDL/user_libs/cdluser.keytab
Principal	cdluser
Description	-

步骤 3 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

步骤 4 （可选）选择“ENV 管理 > 新建 ENV”，进入“新建 ENV”参数配置窗口，参考下表进行参数配置。

表2-61 新建 ENV 配置参数

参数名称	示例
Name	test-env
Driver Memory	1GB
Type	spark
Executor Memory	1GB
Executor Cores	1
Number Executors	1
Queue	-
Description	-

参数配置完成后，单击“确定”创建 ENV。

步骤 5 选择“作业管理 > 数据同步任务 > 新建作业”，在“新建作业”窗口中填写配置。单击“下一步”，进入作业参数配置页面。

其中：

参数名称	示例
Name	job_oracletohudi
Desc	New CDL Job

步骤 6 配置 ThirdKafka 作业参数。

1. 在作业参数配置页面，选取左侧“thirdparty-kafka”图标拖入右侧编辑区域，然后双击此图标进入 ThirdpartyKafka 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-62 thirdparty-kafka 作业参数

参数名称	示例
Link	oraclelink
DB Name	oracledb

参数名称	示例
Schema	oracleschema
Datastore Type	drs-oracle-json
Source Topics	source_topic
Tasks Max	1
Tolerance	none
Data Filter Time	-
Topic Table Mapping	test/hudi_topic

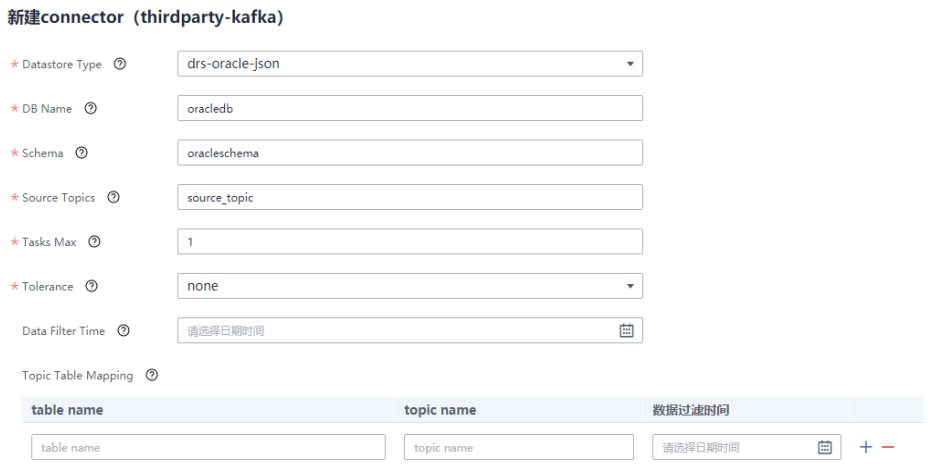

2. 单击“确定”，ThirdpartyKafka 作业参数配置完成。

步骤 7 配置 Hudi 作业参数。

1. 在作业参数配置页面，选取左侧 Sink 区域的“hudi”图标拖入右侧编辑区域，然后双击此图标进入 Hudi 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-63 Sink Hudi 作业参数

参数名称	示例
Link	hudilink
Path	/cdl/test
Interval	10
Max Rate Per Partition	0
Parallelism	10
Target Hive Database	default

参数名称	示例
Hudi 表属性配置方式	可视化视图
Hudi 表属性全局配置	-
Hudi 表属性配置-Table Name	test
Hudi 表属性配置-Table Type Opt Key	COPY_ON_WRITE
Hudi 表属性配置-Hudi TableName Mapping	-
Hudi 表属性配置-Hive TableName Mapping	-
Hudi 表属性配置-Table Primarykey Mapping	id
Hudi 表属性配置-Table Hudi Partition Type	-
Hudi 表属性配置-Custom Config	-

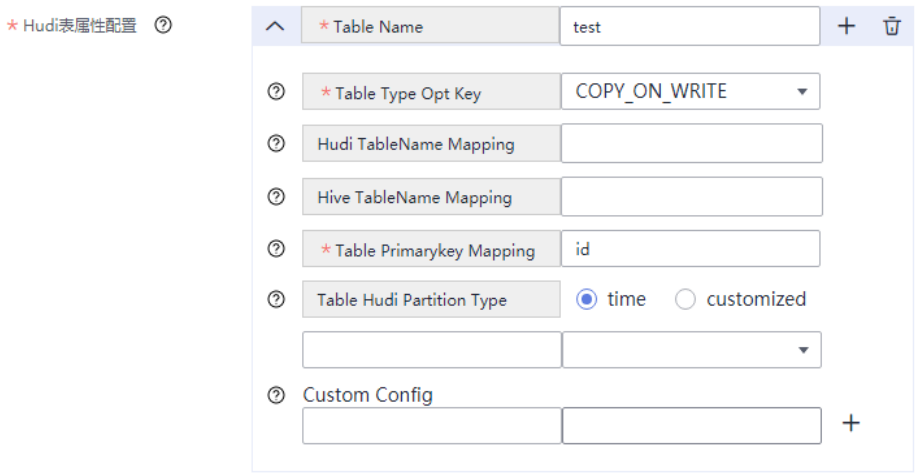

2. （可选）单击“+”按钮展开更多选项，选择已创建的 ENV，默认为“defaultEnv”。

3. 单击“确定”，完成 Hudi 作业参数配置。

步骤 8 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

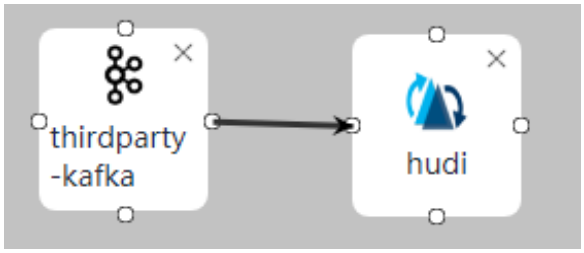

步骤 9 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 Oracle 数据库中对表进行插入数据操作，查看 Hudi 导入的文件内容。

----结束

2.5.3.6 从 ThirdKafka 同步 drs-oracle-avro 数据库数据到 Hudi

操作场景

本章节指导用户通过开启 Kerberos 认证的集群的 CDLService WebUI 界面从 ThirdKafka 导入 drs-avro-oracle 数据库数据到 Hudi。

该章节内容适用于 MRS 3.3.0 及之后版本。

前提条件

- 集群已安装 CDL、Hudi 服务且运行正常。
- ThirdKafka 数据库的 Topic 需要能被 MRS 集群消费，操作步骤请参考 ThirdPartyKafka 前置准备。
- 在 FusionInsight Manager 中创建一个人机用户，例如“cdluser”，加入用户组 **cdladmin**、**hadoop**、**kafka**、**supergroup**，主组选择“cdladmin”组，关联角色“System_administrator”。

操作步骤

步骤 1 使用 **cdluser** 用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接，进入 CDLService WebUI 界面。

步骤 2 选择“连接管理 > 新增连接”，进入“新增连接”参数配置窗口，参考下表，分别新增“thirdparty-kafka”、“hudi”连接，相关数据连接参数介绍请参见 2.4.4 创建数据库连接。

表2-64 thirdparty-kafka 数据连接配置参数

参数名称	示例
Name	drs_avro_oracle_link
Link Type	thirdparty-kafka

参数名称	示例
Bootstrap Servers	10.10.10.10:9093
Security Protocol	SASL_SSL
Username	testuser
Password	*testuser 用户密码*
SSL Truststore Location	单击“上传文件”，上传认证文件
SSL Truststore Password	-
Datastore Type	drs-oracle-avro
Description	thirdparty-kafka Link

说明

thirdparty-kafka 也可以使用 MRS Kafka 作为源端，若使用用户名（Username）密码（Password）进行登录认证，则需先登录 Manager 界面，选择“集群 > 服务 > Kafka > 配置”，在搜索框中搜索“sasl.enabled.mechanisms”，为该参数值增加“PLAIN”，单击“保存”保存配置，并重启 Kafka 服务使配置生效：

再在 CDL WebUI 界面配置使用 MRS Kafka 作为源端的 thirdparty-kafka 连接，例如相关数据连接配置如下：

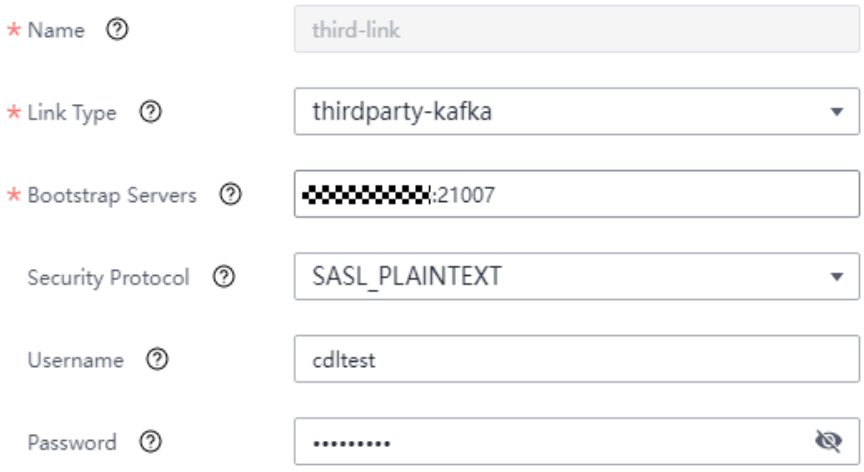

表2-65 Hudi 数据连接配置参数

参数名称	示例
Link Type	hudi
Name	hudilink

参数名称	示例
Storage Type	hdfs
Auth KeytabFile	/opt/Bigdata/third_lib/CDL/user_libs/cdluser.keytab
Principal	cdluser
Description	-

步骤 3 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

步骤 4 （可选）选择“ENV 管理 > 新建 ENV”，进入“新建 ENV”参数配置窗口，参考下表进行参数配置。

表2-66 新建 ENV 配置参数

参数名称	示例
Name	test-env
Driver Memory	1GB
Type	spark
Executor Memory	1GB
Executor Cores	1
Number Executors	1
Queue	-
Description	-

参数配置完成后，单击“确定”创建 ENV。

步骤 5 选择“作业管理 > 数据同步任务 > 新建作业”，在“新建作业”窗口中填写配置。单击“下一步”，进入作业参数配置页面。

其中：

参数名称	示例
Name	job_avro_oracletohudi
Desc	New CDL Job

步骤 6 配置 ThirdKafka 作业参数。

1. 在作业参数配置页面，选取左侧“thirdparty-kafka”图标拖入右侧编辑区域，然后双击此图标进入 ThirdpartyKafka 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-67 thirdparty-kafka 作业参数

参数名称	示例
Link	job_avro_oracletohudi
DB Name	avrooracledb
Schema	avrooracleschema
Datastore Type	drs-oracle-avro
Source Topics	source_topic
Tasks Max	1
Tolerance	none
Data Filter Time	-
Topic Table Mapping	test/hudi_topic

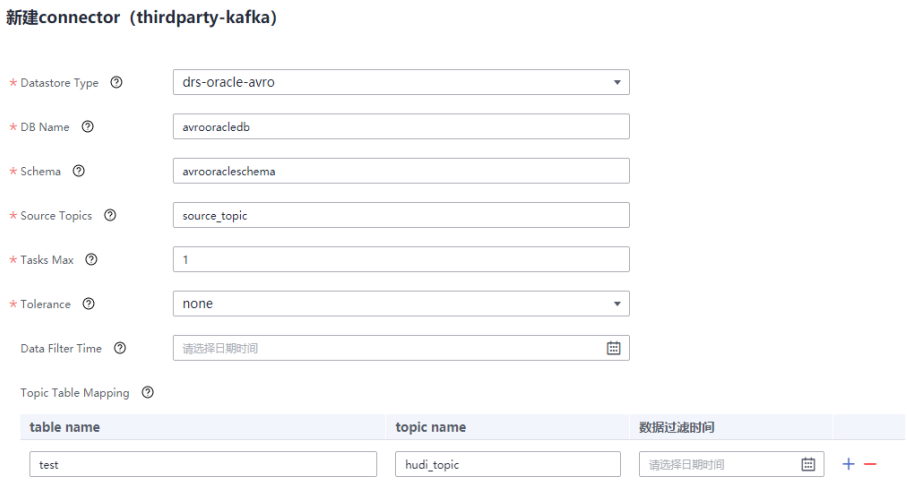

2. 单击“确定”，ThirdpartyKafka 作业参数配置完成。

步骤 7 配置 Hudi 作业参数。

1. 在作业参数配置页面，选取左侧 Sink 区域的“hudi”图标拖入右侧编辑区域，然后双击此图标进入 Hudi 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-68 Sink Hudi 作业参数

参数名称	示例
Link	hudilink

参数名称	示例
Path	/cdl/test
Interval	10
Max Rate Per Partition	0
Parallelism	10
Target Hive Database	default
Hudi 表属性配置方式	可视化视图
Hudi 表属性全局配置	-
Hudi 表属性配置-Table Name	test
Hudi 表属性配置-Table Type Opt Key	COPY_ON_WRITE
Hudi 表属性配置-Hudi TableName Mapping	-
Hudi 表属性配置-Hive TableName Mapping	-
Hudi 表属性配置-Table Primarykey Mapping	id
Hudi 表属性配置-Table Hudi Partition Type	-
Hudi 表属性配置-Custom Config	-

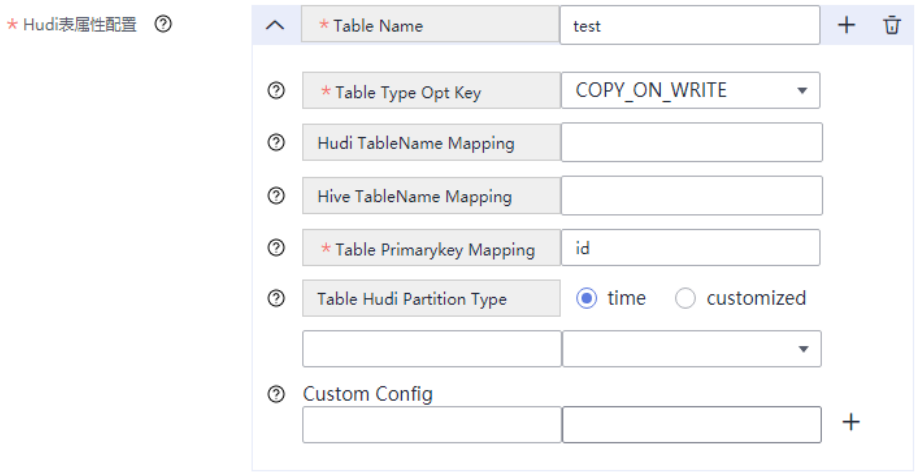

2. （可选）单击“+”按钮展开更多选项，选择已创建的 ENV，默认为“defaultEnv”。

3. 单击“确定”，完成 Hudi 作业参数配置。

步骤 8 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

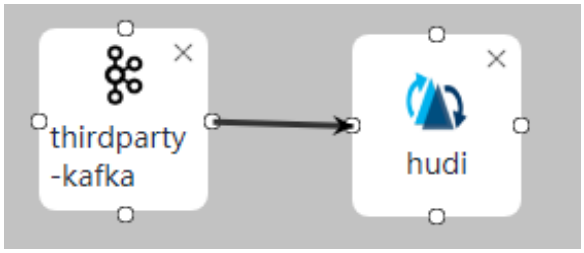

步骤 9 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 drs-avro-oracle 数据库中对表进行插入数据操作，查看 Hudi 导入的文件内容。

----结束

2.5.3.7 从 Hudi 同步数据到 DWS

操作场景

本章节指导用户通过 MRS 3.2.0 版本开启 Kerberos 认证的集群的 CDLService WebUI 界面，从 Hudi 导入数据到 DWS。

前提条件

- 集群已安装 CDL、Hudi 服务且运行正常。
- DWS 数据库需要开启前置要求，操作步骤请参考 DWS 数据库前置准备。
- 在 FusionInsight Manager 中创建一个人机用户，例如“cdluser”，加入用户组 **cdladmin**、**hadoop**、**kafka**、**supergroup**，主组选择“cdladmin”组，关联角色“System_administrator”。

操作步骤

步骤 1 使用 **cdluser** 用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接，进入 CDLService WebUI 界面。

步骤 2 选择“连接管理 > 新增连接”，进入“新增连接”参数配置窗口，参考下表，分别新增“dws”和“hudi”连接，相关数据连接参数介绍请参见 2.4.4 创建数据库连接。

表2-69 DWS 数据连接配置参数

参数名称	示例
Link Type	dws
Name	dwstest
Host	10.10.10.10

参数名称	示例
Port	8000
DB Name	dwsdb
User	dbuser
Password	*dbuser 用户密码*
Description	-

表2-70 Hudi 数据连接配置参数

参数名称	示例
Link Type	hudi
Name	hudilink
Storage Type	hdfs
Auth KeytabFile	/opt/Bigdata/third_lib/CDL/user_libs/cdluser.keytab
Principal	cdluser
Description	xxx

步骤 3 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

步骤 4 （可选）选择“ENV 管理 > 新建 ENV”，进入“新建 ENV”参数配置窗口，参考下表进行参数配置。

表2-71 新建 ENV 配置参数

参数名称	示例
Name	test-env
Driver Memory	1GB
Type	spark
Executor Memory	1GB
Executor Cores	1
Number Executors	1
Queue	-
Description	-

参数配置完成后，单击“确定”创建 ENV。

步骤 5 选择“作业管理 > 数据同步任务 > 新建作业，在“新建作业”窗口中填写配置。单击“下一步”，进入作业参数配置页面。

其中：

参数名称	示例
Name	job_huditodws
Desc	-

步骤 6 配置 Hudi 作业参数。

1. 在作业参数配置页面，选取左侧 Source 区域的“hudi”图标拖入右侧编辑区域，然后双击此图标进入 Hudi 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-72 Source Hudi 作业参数

参数名称	示例
Link	hudilink
Interval	10
Table Info	{"table1":[{"source.database":"dwsdb","source.tablename":"tabletest","target.tablename":"tabletest"}]}

说明

- 从 Hudi 同步数据到 DWS 任务支持 precombine 字段与 Hudi precombine 字段一致的场景。
- DWS 表中必须包含 precombine 字段与主键。
- 默认为 Hudi 内置字段**_hoodie_event_time**，若不使用，需要设置“enable.sink.precombine”参数，例如：

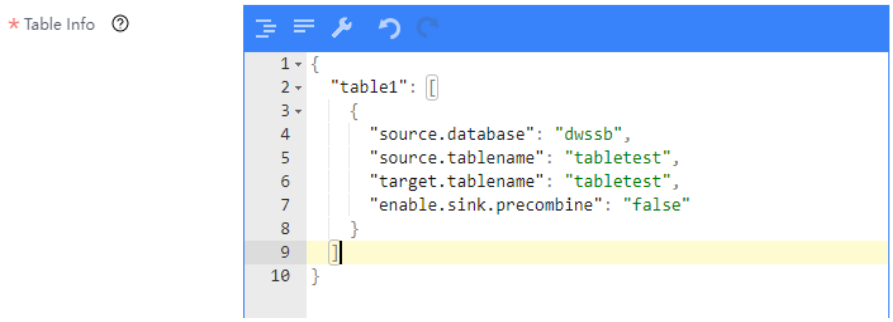

2. 单击“确定”，Hudi 作业参数配置完成。

步骤 7 配置 DWS 作业参数。

1. 在作业参数配置页面，选取左侧“dws”图标拖入右侧编辑区域，然后双击此图标进入 dws 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-73 DWS 作业参数

参数名称	示例
Link	dwstest
Query Timeout	180000
Batch Size	10

2. 单击“确定”，完成 Hudi 作业参数配置。

步骤 8 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

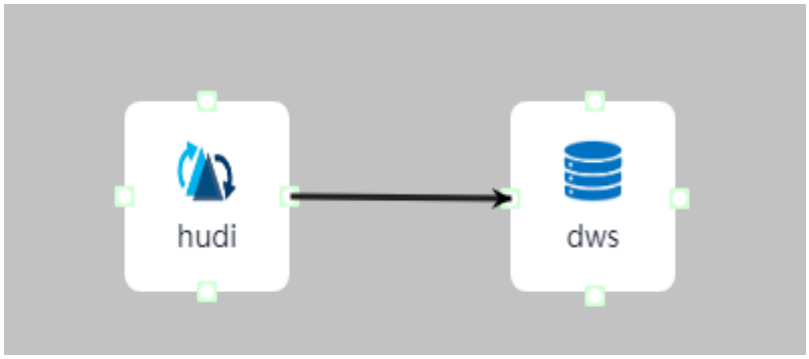

步骤 9 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 Hudi 中对表进行插入数据操作，查看 DWS 导入的文件内容。

----结束

2.5.3.8 从 Hudi 同步数据到 ClickHouse

操作场景

本章节指导用户通过 MRS 3.2.0 版本开启 Kerberos 认证的集群的 CDLService WebUI 界面，从 Hudi 导入数据到 ClickHouse。

前提条件

- 集群已安装 CDL、Hudi 和 ClickHouse 服务且运行正常。
- 用户需要有操作 ClickHouse 的权限，相关操作请参见 3.2.1 ClickHouse 用户及权限管理。
- 在 FusionInsight Manager 中创建一个人机用户，例如“cdluser”，该用户需具有 ClickHouse 管理员权限（相关操作请参见 3.2.1 ClickHouse 用户及权限管理），并加入用户组 **cdladmin**、**hadoop**、**kafka**、**supergroup**，主组选择“cdladmin”组，关联角色“System_administrator”。
- 手动创建 ClickHouse 侧的本地表和分布式表， 本地表使用 ReplicatedReplacingMergeTree 引擎，详细操作请参见 3.6 ClickHouse 表创建章节。

操作步骤

步骤 1 使用 **cdluser** 用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接，进入 CDLService WebUI 界面。

步骤 2 选择“连接管理 > 新增连接”，进入“新增连接”参数配置窗口，参考下表，分别新增“clickhouse”和“hudi”连接，相关数据连接参数介绍请参见 2.4.4 创建数据库连接。

表2-74 ClickHouse 数据连接配置参数

参数名称	示例
Link Type	clickhouse
Name	cklink
Host	10.10.10.10:21428
User	*cdluser*
Password	*cdluser 用户密码*
Description	-

表2-75 Hudi 数据连接配置参数

参数名称	示例
Link Type	hudi

参数名称	示例
Name	hudilink
Storage Type	hdfs
Auth KeytabFile	/opt/Bigdata/third_lib/CDL/user_libs/cdluser.keytab
Principal	cdluser
Description	-

步骤 3 参数配置完成后，单击“测试连接”，检查数据连通是否正常。

连接校验通过后，单击“确定”完成数据连接创建。

步骤 4 （可选）选择“ENV 管理 > 新建 ENV”，进入“新建 ENV”参数配置窗口，参考下表进行参数配置。

表2-76 新建 ENV 配置参数

参数名称	示例
Name	test-env
Driver Memory	1GB
Type	spark
Executor Memory	1GB
Executor Cores	1
Number Executors	1
Queue	-
Description	-

参数配置完成后，单击“确定”创建 ENV。

步骤 5 选择“作业管理 > 数据同步任务 > 新建作业”，在“新建作业”窗口中填写配置。单击“下一步”，进入作业参数配置页面。

其中：

参数名称	示例
Name	job_huditock
Desc	-

步骤 6 配置 Hudi 作业参数。

1. 在作业参数配置页面，选取左侧 Source 区域的“hudi”图标拖入右侧编辑区域，然后双击此图标进入 Hudi 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业。

表2-77 Source Hudi 作业参数

参数名称	示例
Link	hudilink
Interval	10
Table Info	{"table1":[{"source.database":"db","source.tablename":"tabletest","target.tablename":"default.tabletest"}]} 说明 无需配置 Hudi 自带的字段，只配置需同步至 ClickHouse 的业务字段即可。

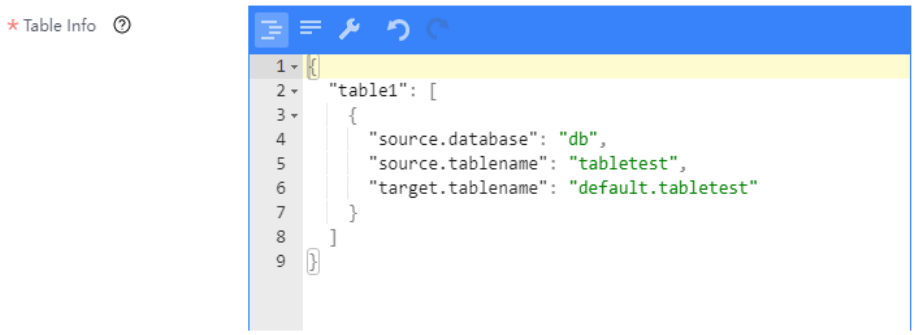

2. 单击“确定”，Hudi 作业参数配置完成。

步骤 7 配置 ClickHouse 作业参数。

1. 在作业参数配置页面，选取左侧“clickhouse”图标拖入右侧编辑区域，然后双击此图标进入 ClickHouse 作业参数配置窗口。参考下表进行参数配置，相关作业参数介绍请参见 2.5.1 创建 CDL 数据同步任务作业：

表2-78 ClickHouse 作业参数

参数名称	示例
Link	cklink
Query Timeout	60000
Batch Size	100

2. 单击“确定”，完成 ClickHouse 作业参数配置。

步骤 8 作业参数配置完成后，拖拽图标将作业进行关联，然后单击“保存”，作业配置完成。

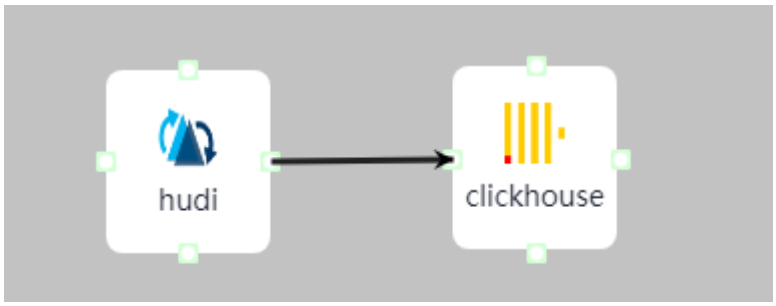

步骤 9 在“作业管理”的作业列表中，找到创建的作业名称，单击操作列的“启动”，等待作业启动。

观察数据传输是否生效，例如在 Hudi 中对表进行插入数据操作，查看 ClickHouse 导入的文件内容。

----结束

2.6 DDL 变更

DDL 变更操作包括创建数据库/表、变更表字段类型、变更表字段名称、表列增/删等数据表结构变化操作。当前 CDL 仅支持从 PgSQL 同步数据到 Hudi 的 DDL 变更，所有 DDL 变更操作顺序为：

1. 停止 CDL 任务。
2. Hudi 侧执行 DDL 变更。
3. 源端库进行 DDL 变更。

本章节适用于 MRS 3.3.0 及之后版本，提供了新增字段、修改字段类型、修改字段名称、删除字段等 DDL 变更操作指导。

新增字段

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择需进行 DDL 变更作业所在行的“更多 > 停止”，停止 CDL 作业。

步骤 2 使用客户端安装用户登录安装了客户端的节点，并执行以下命令：

cd *客户端安装目录*

source bigdata_env

source Hudi/component_env

kinit *组件业务用户*（若集群未开启 Kerberos 认证，请跳过该操作）

步骤 3 执行以下命令登录 spark-sql 命令行：

cd Spark/spark/bin

./spark-sql

步骤 4 执行以下命令：

set hoodie.schema.evolution.enable=true;

步骤 5 执行以下命令在表中新增字段：

alter table *tableName* **add columns(***columnName columnType***);**

步骤 6 在源端数据库中新增与 Hudi 新增的同样列名与数据类型。

步骤 7 在 CDL WebUI 界面启动步骤 1 停止的任务。

----结束

修改字段类型

说明

字段类型转换时，需要确保源值的数据类型能够正确转换为目标类型。如果数据类型不兼容，转换可能会失败，进而导致任务失败。

- 将数据类型 VARCHAR 修改为 NUMBER
  a. 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择需进行 DDL 变更作业所在行的“更多 > 停止”，停止 CDL 作业。
  b. 使用客户端安装用户登录安装了客户端的节点，并执行以下命令：
     cd *客户端安装目录*
     source bigdata_env
     source Hudi/component_env
     kinit *组件业务用户*（若集群未开启 Kerberos 认证，请跳过该操作）
  c. 执行以下命令登录 spark-sql 命令行：
     cd Spark/spark/bin
     ./spark-sql
  d. 在 Hudi 侧执行 DDL 变更，修改数据类型 **string** 为 **decimal**：
     ALTER TABLE *ddltest* **ALTER COLUMN string TYPE decimal(20,10);**
  e. 在源数据库中插入数据，数据可以正常写入 Hudi。
  f. 在源数据库侧，将数据类型 VARCHAR 修改为 NUMBER。
  g. 在 CDL WebUI 界面启动任务，源数据库更新数据。

- 将数据类型 NUMBER 修改为 VARCHAR
  a. 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择需进行 DDL 变更作业所在行的“更多 > 停止”，停止 CDL 作业。
  b. 使用客户端安装用户登录安装了客户端的节点，并执行以下命令：

     cd *客户端安装目录*

     source bigdata_env

     source Hudi/component_env

     kinit *组件业务用户*（若集群未开启 Kerberos 认证，请跳过该操作）
  c. 执行以下命令登录 spark-sql 命令行：

     cd Spark/spark/bin

     ./spark-sql
  d. 在 Hudi 侧执行 DDL 变更，修改数据类型 decimal 为 string：

     ALTER TABLE *ddltest* **ALTER COLUMN decimal TYPE string;**
  e. 在源数据库中插入数据，数据可以正常写入 Hudi。
  f. 在源数据库侧，将数据类型 NUMBER 修改为 VARCHAR。
  g. 在 CDL WebUI 界面启动任务，源数据库更新数据。
- 将数据类型 DATE 修改为 VARCHAR
  a. 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择需进行 DDL 变更作业所在行的“更多 > 停止”，停止 CDL 作业。
  b. 使用客户端安装用户登录安装了客户端的节点，并执行以下命令：

     cd *客户端安装目录*

     source bigdata_env

     source Hudi/component_env

     kinit *组件业务用户*（若集群未开启 Kerberos 认证，请跳过该操作）
  c. 执行以下命令登录 spark-sql 命令行：

     cd Spark/spark/bin

     ./spark-sql
  d. 在 Hudi 侧执行 DDL 变更，修改数据类型 date 为 string：

     ALTER TABLE *ddltest2* **ALTER COLUMN date TYPE string;**
  e. 在源数据库插入数据，数据可以正常写入 Hudi。
  f. 在源数据库侧，将数据类型 DATE 修改为 VARCHAR。
  g. 在 CDL WebUI 界面启动任务，源数据库更新数据。
- 不带时区 DATA 类型修改为带时区的 DATA 类型
  a. 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择需进行 DDL 变更作业所在行的“更多 > 停止”，停止 CDL 作业。

b. 在源数据库侧，将数据类型 timestamp 修改为 timestamptz。

c. 在源数据库插入数据，数据可以正常写入 Hudi。

d. 在 CDL WebUI 界面启动任务，源数据库更新数据。

- 字符扩长

a. 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择需进行 DDL 变更作业所在行的“更多 > 停止”，停止 CDL 作业。

b. 在源数据库将字符长度增大。

c. 在源数据库插入数据，数据成功写入 Hudi。

d. 在 CDL WebUI 界面启动任务，源数据库更新数据。

- decimal 精度变大

a. 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择需进行 DDL 变更作业所在行的“更多 > 停止”，停止 CDL 作业。

b. 使用客户端安装用户登录安装了客户端的节点，并执行以下命令：

cd *客户端安装目录*

source bigdata_env

source Hudi/component_env

kinit *组件业务用户*（若集群未开启 Kerberos 认证，请跳过该操作）

c. 执行以下命令登录 spark-sql 命令行：

cd Spark/spark/bin

./spark-sql

d. 在 Hudi 侧执行 DDL 变更，将 decimal 类型精度变大：

ALTER TABLE *ddltest2* **ALTER COLUMN decimal TYPE decimal(***30***,***15***);**

e. 在源数据库侧，将 decimal 类型精度变大。

f. 在源数据库插入数据，数据可以正常写入 Hudi。

g. 在 CDL WebUI 界面启动任务，源数据库更新数据。

修改字段名称

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择需进行 DDL 变更作业所在行的“更多 > 停止”，停止 CDL 作业。

步骤 2 使用客户端安装用户登录安装了客户端的节点，并执行以下命令：

cd *客户端安装目录*

source bigdata_env

source Hudi/component_env

kinit *组件业务用户*（若集群未开启 Kerberos 认证，请跳过该操作）

步骤 3 执行以下命令登录 spark-sql 命令行：

cd Spark/spark/bin

./spark-sql

步骤 4 在 Hudi 侧执行 DDL 变更，修改字段名称：

ALTER TABLE *ddltest* **RENAME COLUMN** *columnName* **TO** *newColumnName;*

步骤 5 在源数据库修改字段名称。

步骤 6 在 CDL WebUI 界面启动任务，源数据库更新数据。

----结束

删除字段

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择需进行 DDL 变更作业所在行的“更多 > 停止”，停止 CDL 作业。

步骤 2 使用客户端安装用户登录安装了客户端的节点，并执行以下命令：

cd *客户端安装目录*

source bigdata_env

source Hudi/component_env

kinit *组件业务用户*（若集群未开启 Kerberos 认证，请跳过该操作）

步骤 3 执行以下命令登录 spark-sql 命令行：

cd Spark/spark/bin

./spark-sql

步骤 4 在 Hudi 侧执行 DDL 变更，删除字段：

ALTER TABLE ddltest **DROP COLUMN** *columnName*;

步骤 5 在 CDL WebUI 界面启动任务，源数据库更新数据。

----结束

2.7 CDL 日志介绍

日志描述

日志路径：CDL 默认的日志存储路径为“/var/log/Bigdata/cdl/*角色名简写*”。

- CDLService：“/var/log/Bigdata/cdl/service”（运行日志），“/var/log/Bigdata/audit/cdl/service”（审计日志）。
- CDLConnector：“/var/log/Bigdata/cdl/connector”（运行日志）。

表2-79 日志介绍

日志类型	日志文件	日志描述
运行日志	connect.log	CDLConnector 的运行日志。
	prestartDetail.log	服务启动前初始化集群的日志。
	startDetail.log	启动服务的日志。
	stopDetail.log	停止服务的日志。
	cleanupDetail.log	服务执行 cleanup 的日志。
	check-serviceDetail.log	服务安装完成之后验证服务状态的。
	cdl-db-operation.log	服务启动时初始化数据库的日志。
	cdl-app-launcher.log	CDL 数据同步任务的 Spark App 启动日志。
	cdl-dc-app-launcher.log	CDL 数据比对任务的 Spark App 启动日志。
	serviceInstanceCheck.log	CDLService 的实例检查日志。
	connectorInstanceCheck.log	CDLConnector 的实例检查日志。
	ModifyDBPasswd.log	重置服务数据库密码的日志。
	ranger-cdl-plugin-enable.log	服务启用或停用 Ranger 鉴权的日志。
	postinstallDetail.log	服务安装日志。
	cdl_connector_pidxxx_gc.log.x	CDLConnector 的 GC 日志。
	cdl_service_pidxxx_gc.log.x	CDLService 的 GC 日志。
	threadDump-CDLConnector-xxx.log	CDLConnector 的堆栈日志。
	threadDump-CDLService-xxx.log	CDLService 的堆栈日志。
审计日志	cdl-audit.log	服务的审计日志。

日志级别

CDL 提供了如表 2-80 所示的日志级别。

运行日志的级别优先级从高到低分别是 FATAL、ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表2-80 日志级别

日志类型	级别	描述
运行日志&审计日志	FATAL	fatal 表示系统的致命错误
	ERROR	error 表示系统运行的错误信息。
	WARN	warning 表示当前事件处理存在异常信息。
	INFO	information 表示记录系统及各事件正常运行状态信息。
	DEBUG	debug 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

步骤 1 请参考 25.1 修改集群服务配置参数，进入 CDL 的“全部配置”页面。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别。

步骤 4 保存配置，在弹出窗口中单击“确定”使配置生效。

说明

配置完成后立即生效，不需要重启服务。

----结束

日志格式

CDL 的日志格式如下所示：

表2-81 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2021-06-15 17:25:19,658	DEBUG	qtp2009591182-1754	>fill SslConnection@5d04c5a0SocketChannelEndPoint@7c011c24{l=/10.244.224.65:21

日志类型	格式	示例
		495,r=/10.244.224.83:53724,OPEN,fill=-,flush=-,to=1/30000}{io=0/0,kio=0,kro=1}->SslConnection@5d04c5a0{NOT_HANDSHAKING,eio=-1/-1,di=-1,fill=IDLE,flush=IDLE}~>DecryptedEndPoint@771f2f77{l=/10.244.224.65:21495,r=/10.244.224.83:53724,OPEN,fill=-,flush=-,to=19398/30000}=>HttpConnection@68c5859b[p=HttpParser{s=CONTENT,0 of -1},g=HttpGenerator@536e2de0{s=END}]=>HttpChannelOverHttp@7bf252bd{s=HttpChannelState@38be31e{s=IDLE rs=COMPLETED os=COMPLETED is=IDLE awp=false se=false i=false al=0},r=1,c=true/true,a=IDLE,uri=https://10.244.224.65:21495/api/v1/cdl/monitor/jobs/metrics,age=19382} | SslConnection.java:614
审计日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2021-06-15 11:07:00,262 | INFO | qtp1846345504-30 | STARTTIME=2021-06-15 11:06:47.912 ENDTIME=2021-06-15 11:07:00.261 USERIP=10.144.116.198 USER=CDL User INSTANCE=10-244-224-65 OPERATION=Start CDL Job TARGET=CDCJobExecutionResource RESULT=SUCCESS | CDCAuditLogger.java:93

2.8 CDL 常见问题

2.8.1 CDL 任务执行后 Hudi 中没有接收到数据

现象描述

抓取数据到 Hudi 中的 CDL 任务运行后，Kafka 中有相关数据，Spark 的 RDD 处理中无记录，Hudi 中没有相关数据，并且 Yarn 日志报错：TopicAuthorizationException: No authorized to access topics

可能原因

当前用户没有消费 Kafka 数据的权限。

处理步骤

步骤 1 登录 FusionInsight Manager，选择“系统 > 权限 > 用户”，单击提交 CDL 任务用户所在行的“修改”，添加“kafkaadmin”用户组，单击“确定”。

步骤 2 使用该用户登录 FusionInsight Manager 界面，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，重新启动该任务。

----结束

2.8.2 CDL 任务运行一段时间后发生“104”或“143”报错

现象描述

CDL 任务运行一段时间后，Yarn 任务失败，并返回状态码“104”或“143”。

可能原因

抓取到 Hudi 中的一批数据量过大，导致任务内存不足。

处理步骤

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择该作业所在行的“更多 > 停止”，等待任务停止完成后选择“更多 > 编辑”。

步骤 2 修改 Hudi 的“max.rate.per.partition”参数值为“6000”，并单击“保存”。

步骤 3 在数据同步任务作业列表界面选择该任务所在行的“更多 > 重启”，重新启动该任务。

----结束

2.8.3 启动从 PgSQL 中抓取数据到 Hudi 任务报错

现象描述

启动从 PgSQL 中抓取数据到 Hudi 任务报错：Record key is empty

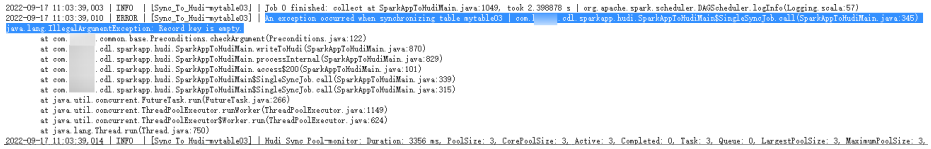

可能原因

Hudi 表主键参数“table.primarykey.mapping”未配置。

处理步骤

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择该作业所在行的“更多 > 停止”，等待任务停止完成后选择“更多 > 编辑”。

步骤 2 配置“Hudi 表属性配置”的“Table Primarykey Mapping”参数，并单击“保存”，该参数介绍请参见表 2-36。

步骤 3 在数据同步任务作业列表界面选择该任务所在行的“启动”，重新启动该任务。

----结束

2.8.4 停止 CDL 任务时报“403”错误

现象描述

在 CDLService WebUI 界面停止 CDL 任务时报错：parameter exception with code: 403

可能原因

当前用户没有停止该任务的权限。

处理步骤

使用创建该任务的用户停止该任务，创建该任务的用户可登录 CDLService WebUI 界面，在作业管理列表的“创建者”列查看。

2.8.5 启用 Ranger 鉴权场景下，删除用户所有权限后，该用户仍能够操作自己创建的任务

现象描述

在启用 Ranger 鉴权场景下，取消用户所有权限后，该用户仍能够操作自己创建的任务。例如：

1. 在 Ranger WebUI 界面取消用户 **admintest** 的所有权限：

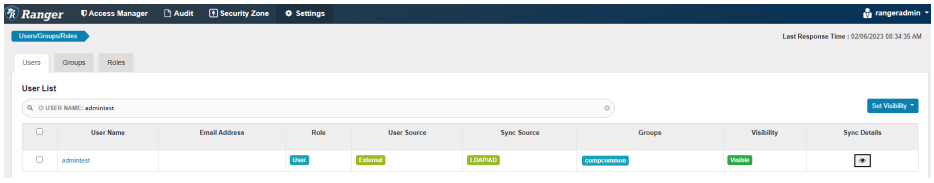

2. 使用 **admintest** 用户登录 CDL WebUI 界面后，该用户可以在“作业管理界面”操作自己创建的任务：

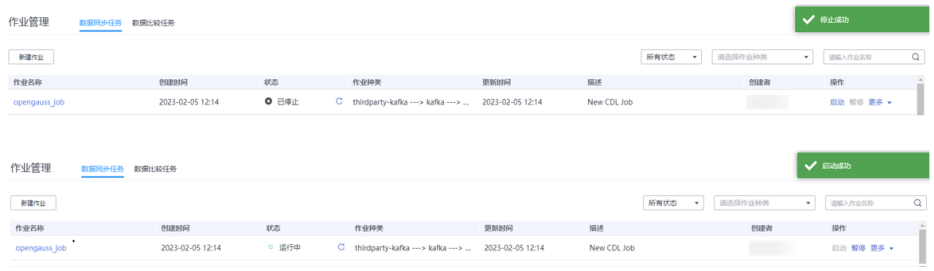

可能原因

用户未删除 Ranger 策略上的“{OWNER}”权限。

处理步骤

步骤 1 使用 **admin** 用户登录 FusionInsight Manager，选择“集群 > 服务 > Ranger”，单击“RangerAdmin UI”右侧的超链接进入 Ranger WebUI 界面。

步骤 2 在 Ranger WebUI 界面，单击右上角用户名，选择“Log Out”，退出当前用户。并使用 **rangeradmin** 用户重新登录。

步骤 3 在首页中单击“CDL”区域的组件插件名称，例如“CDL”，进入如下页面：

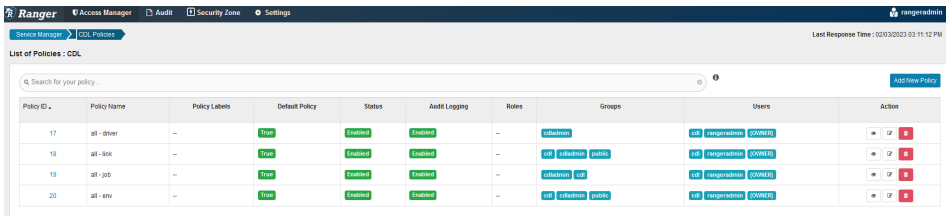

步骤 4 依次单击每条策略“Action”列的  ，删除“Allow Conditions”区域“Select User”列中的“{OWNER}”用户，单击“Save”。

步骤 5 等待 10 分钟后，使用删除“{OWNER}”权限的用户再次登录 CDL WebUI 界面操作自己创建的作业，发现没有权限进行相关操作。

----结束

2.8.6 MySQL 链路任务启动时如何从指定位置抓取数据

现象描述

MySQL 链路任务启动时，可以从指定位置抓取数据，本章节主要介绍如何获取指定位置参数。

图2-2 启动任务

处理步骤

步骤 1 使用工具或者命令行连接 MySQL 数据库（本示例使用 Navicat 工具连接）。

步骤 2 执行以下命令。

SHOW MASTER STATUS

例如在 Navicat 工具选择“File > New Query”新建查询，输入 **SHOW MASTER STATUS**，执行结果如下：

图2-3 SQL 执行结果

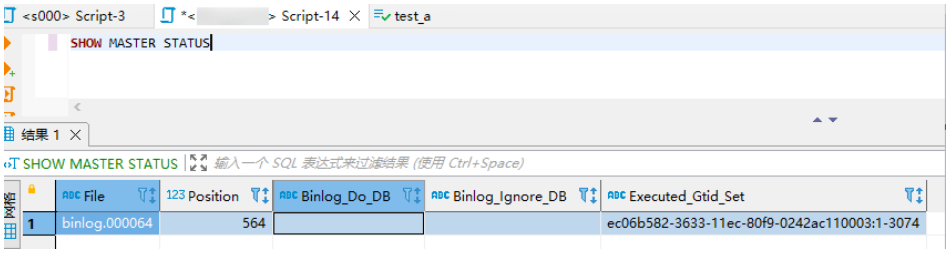

步骤 3　将图 2-3 中的“File”列的值填入“Start Binlog”，“Position”列的值填入“Start Position”，“Executed_Gtid_Set”列的值填入“Start Gtidset”，单击“确定”，任务启动。

说明

若步骤 2 查询到的“Executed_Gtid_Set”存在两个值且以逗号分隔，则记录第一个值，并将该值填入“Start Gtidset”，如下图所示，“Start Gtidset”值为“13a90ad1-1f02-11ee-9ba9-fa163e6190d3:1-2794”：

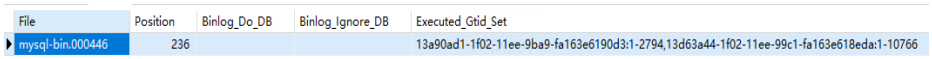

----结束

2.8.7 从 ogg 同步数据到 Hudi 时，ogg Source 配置的 Task 值与任务实际运行的 Task 数量不一致

现象描述

执行从 ogg 同步数据到 Hudi 的 CDL 任务时，源端（ThirdKafka）中指定的“tasks.max”值与任务实际运行的 Task 数量不一致。

例如，在 CDL WebUI 界面查看源端作业 ThirdKafka 配置的“tasks.max”值为“3”：

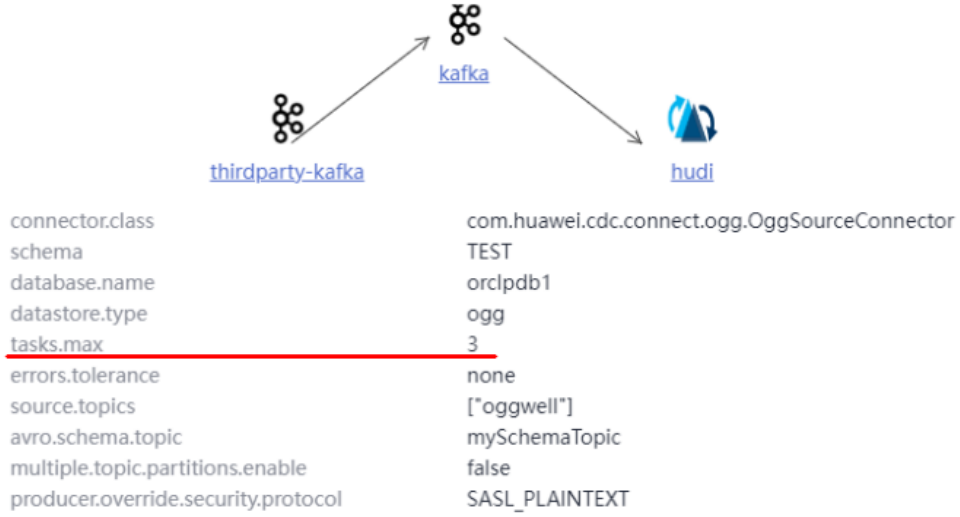

但查看任务实际运行的 Task 只有“id: 0, state: xxx”，即 Task 数量为 1：

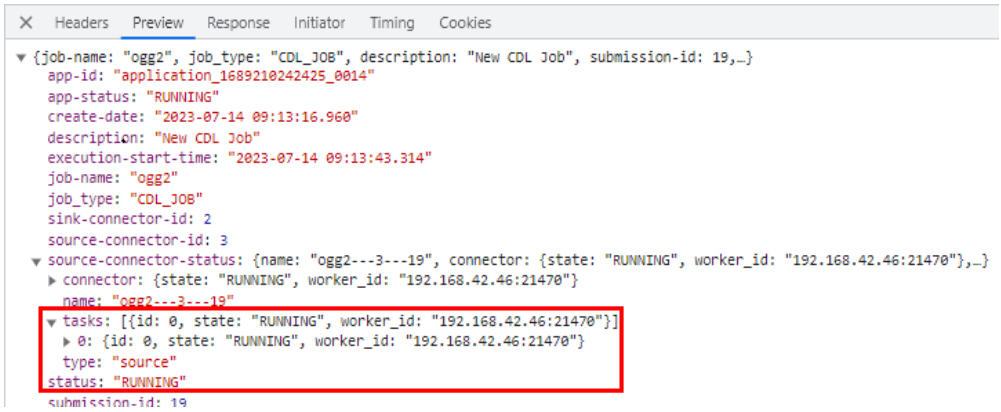

可能原因

当 ogg 为 CDL 同步任务的数据源时，ogg Source 实际运行 task 数量取“source.topics”与“tasks.max”配置的参数值的最小值。

处理步骤

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择该作业所在行的“更多 > 停止”，等待任务停止完成后选择“更多 > 编辑”。

步骤 2 修改 Thirdk Kafka 的“tasks.max”参数值与“source.topics”配置的 Topic 数一致，并单击“保存”。

步骤 3 在数据同步任务作业列表界面选择该任务所在行的“启动”，重新启动该任务。

----结束

2.8.8 CDL 同步任务名对应的 Topic 分区过多

现象描述

CDL 任务启动后，在 Kaka WebUI 的“Topic List”列表中查看到该 CDL 任务的名称的“Partitions Num”值过大。

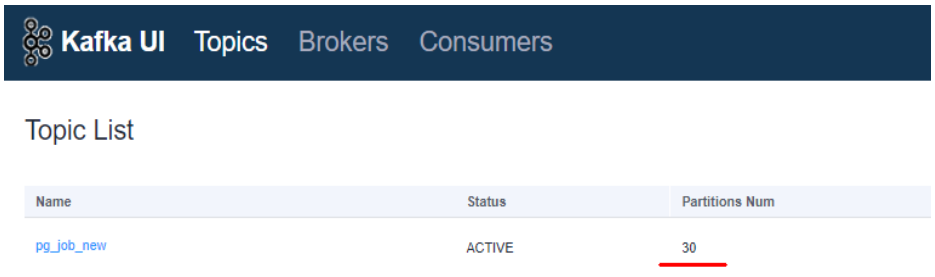

可能原因

CDL 任务配置了 Topic Table Mapping，未配置 WhiteList 参数，该任务所配置的 Schema 的 CDL 任务未同步的表过多，导致 CDL 任务名称创建时分区过多。

处理步骤

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDLService WebUI 界面，在数据同步任务作业列表界面选择该作业所在行的“更多 > 停止”，等待任务停止完成后选择“更多 > 编辑”。

步骤 2 修改 Source 侧的“WhiteList”参数值与配置的 Topic Table Mapping 表数一致，并单击“保存”。

步骤 3 登录 FusionInsight Manager，选择“集群 > 服务 > Kafka”，单击“Kafka UI”右侧的超链接进入 Kafka WebUI 界面，在 Topics 页签搜索 CDL 任务名称，选择“Operation ”列的“Action > Delete”。

步骤 4 在 CDL WebUI 界面的数据同步任务作业列表中，选择该任务所在行的“启动”，重新启动该任务。

----结束

2.8.9 执行 CDL 同步数据到 Hudi 任务，报错当前用户无权限在其他用户创建的数据库中创建表

现象描述

执行 CDL 同步数据到 Hudi 任务后，在 Manager 界面，选择“集群 > 服务 > Yarn”，单击“ResourceManager Web UI”后的超链接进入 Yarn WebUI 界面，在任务列表中单击该任务 ID，单击“Logs”，报错当前用户无权限创建表，具体报错如下：

```
org.apache.hadoop.hive.ql.security.authorization.plugin.HiveAccessControlException:
Permission denied: Principal [name=xxx, type=USER] does not have following
privileges for operation CREATETABLE [[CREATE] on Object [type=DATABASE, name=xxx]]
```

可能原因

CDL 业务运行用户无权限在其他用户创建的数据库中创建表。

处理步骤

步骤 1 登录 FusionInsight Manager，选择“系统 > 角色 > 添加角色”，填写角色名称，在“配置资源权限”表格中选择“*待操作的集群名称* > Hive > Hive 读写权限”，在待操作数据库所在行勾选“查询”、“删除”、“插入”、“建表”、“Select 授权”、“Delete 授权”、“Insert 授权”和“递归”权限，单击“确定”。

步骤 2 单击“用户”，单击提交该任务的用户所在行的“修改”，在角色中新增步骤 1 新建的角色，单击“确定”。

步骤 3 选择“集群 > 服务 > CDL”，单击“CDLService UI”右侧的超链接进入 CDL WebUI 界面，选择该作业所在行的“更多 > 停止”，停止 CDL 任务。任务停止成功后，再单击“启动”，重新启动该任务。

----结束

3 使用 ClickHouse

3.1 从零开始使用 ClickHouse

ClickHouse 是面向联机分析处理的列式数据库，支持 SQL 查询，且查询性能好，特别是基于大宽表的聚合分析查询性能非常优异，比其他分析型数据库速度快一个数量级。

前提条件

已安装客户端，例如安装目录为“/opt/client”。以下操作的客户端目录只是举例，请根据实际安装目录修改。在使用客户端前，需要先下载并更新客户端配置文件，确认 Manager 的主管理节点后才能使用客户端。

操作步骤

步骤 1 以客户端安装用户，登录安装客户端的节点。

步骤 2 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 3 执行以下命令配置环境变量。

source bigdata_env

步骤 4 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 ClickHouse 表的权限，具体请参见 3.2.1 ClickHouse 用户及权限管理章节，为用户绑定对应角色。如果当前集群未启用 Kerberos 认证，则无需执行本步骤。

kinit *组件业务用户*

例如，**kinit** clickhouseuser。

步骤 5 执行 ClickHouse 组件的客户端命令。

执行 **clickhouse -h**，查看 ClickHouse 组件命令帮助。

回显信息如下：

```
Use one of the following commands:
clickhouse local [args]
```

```
clickhouse client [args]
clickhouse benchmark [args]
clickhouse server [args]
clickhouse performance-test [args]
clickhouse extract-from-config [args]
clickhouse compressor [args]
clickhouse format [args]
clickhouse copier [args]
clickhouse obfuscator [args]
...
```

使用 **clickhouse client** 命令连接 ClickHouse 服务端：

说明

以下连接 ClickHouse 服务端命令中所使用的端口为开源端口，如果在创建集群时使用了定制端口，则请参考常见问题进行替换。

- 例如，当前集群未启用 Kerberos 认证，使用非 ssl 方式登录：

  clickhouse client --host *ClickHouse 的实例 IP* **--port** 9000 **--user** *用户名* **--password**

  输入用户密码

- 例如，当前集群已启用 Kerberos 认证，使用 ssl 安全方式登录。

  Kerberos 集群场景下没有默认用户，必须在 Manager 上创建用户。

  clickhouse client --host *ClickHouse 的实例 IP* **--port** 9440 **--user** *用户名* **--password --secure**

  输入用户密码

执行 **quit;**命令，退出 ClickHouse 服务端连接。

相关参数使用说明如表 3-1：

表3-1 clickhouse client 命令行参数说明

参数名	参数说明
--host	服务端的 host 名称，默认是 localhost。您可以选择使用 ClickHouse 实例所在节点主机名或者 IP 地址。 **说明** ClickHouse 的实例 IP 地址可登录集群 FusionInsight Manager，然后选择“集群 > 服务 > ClickHouse > 实例”，获取 ClickHouseServer 实例对应的业务 IP 地址。
--port	连接的端口。 • 如果使用 ssl 安全连接则默认端口为 9440，并且需要携带参数--secure。具体的端口值可通过 ClickHouseServer 实例配置搜索“tcp_port_secure”参数获取。 • 如果使用非 ssl 安全连接则默认端口为 9000，不需要携带参数--secure。具体的端口值可通过 ClickHouseServer 实例配置搜索“tcp_port”参数获取。
--user	用户名。 可以在 Manager 上创建该用户名并绑定对应的角色权限。

参数名	参数说明
	• 如果当前集群已启用 Kerberos 认证（集群为安全模式），使用 kinit 认证成功后，客户端登录时可以不携带--user 和--password 参数，即使用 kinit 认证的用户登录。Kerberos 集群场景下没有默认用户，必须在 Manager 上创建该用户名。 • 如果当前集群未启用 Kerberos 认证（集群为普通模式），客户端登录时如果需要指定用户名和密码，不能使用 FusionInsight Manager 页面创建的 ClickHouse 用户，需要使用客户端命令行执行 **create user SQL** 语句创建 ClickHouse 用户。客户端登录时如果不需要指定用户名和密码参数时，默认使用 default 用户登录。
--password	密码。 默认值：空字符串。该参数和--user 参数配套使用，可以在 Manager 上创建用户名时设置该密码。
--query	使用非交互模式查询。
--database	默认当前操作的数据库。默认值：服务端默认的配置（默认是 default）。
--multiline	如果指定，允许多行语句查询（Enter 仅代表换行，不代表查询语句完结）。
--multiquery	如果指定，允许处理用;号分隔的多个查询，只在非交互模式下生效。
--format	使用指定的默认格式输出结果。
--vertical	如果指定，默认情况下使用垂直格式输出结果。在这种格式中，每个值都在单独的行上打印，适用显示宽表的场景。
--time	如果指定，非交互模式下会打印查询执行的时间到 stderr 中。
--stacktrace	如果指定，如果出现异常，会打印堆栈跟踪信息。
--config-file	配置文件的名称。
--secure	如果指定，将通过 ssl 安全模式连接到服务器。
--history_file	存放命令历史的文件的路径。
--param_<name>	带有参数的查询，并将值从客户端传递给服务器。

----结束

常见问题

执行连接 ClickHouse 组件客户端命令后，登录报错“Connection refused”。

请检查当前集群是否为定制端口（在创建集群时将“组件端口”参数选择为“定制”），如果为定制端口，则需要将连接 ClickHouse 组件客户端命令中所使用的端口替换为下表中的“定制默认端口”。

配置参数	开源默认端口	定制默认端口	端口说明
tcp_port	9000	21423	业务客户端 TCP 接入端口。
http_port	8123	21421	业务客户端 HTTP 接入端口。
https_port	8443	21422	业务客户端 HTTPS 接入端口。
tcp_port_secure	9440	21427	业务客户端 TCP With SSL 接入端口。默认仅在安全模式下开放。

3.2 ClickHouse 权限管理

3.2.1 ClickHouse 用户及权限管理

用户权限模型

ClickHouse 用户权限管理实现了对集群中各个 ClickHouse 实例上用户、角色、权限的统一管理。通过 Manager UI 的权限管理模块进行创建用户、创建角色、绑定 ClickHouse 访问权限配置等操作，通过用户绑定角色的方式，实现用户权限控制。

管理资源：Clickhouse 权限管理支持的资源如表 3-2 所示。

资源权限：ClickHouse 支持的资源权限如表 3-3 所示。

表3-2 ClickHouse 支持的权限管理对象

资源列表	是否集成	备注
数据库	是（一级）	-
表	是（二级）	-
视图	是（二级）	与表一致

表3-3 资源权限列表

资源对象	可选权限	备注
数据库（DATABASE）	CREATE	CREATE DATABASE/TABLE/VIEW/DICTIONARY 权限

资源对象	可选权限	备注
表/视图（TABLE/VIEW）	SELECT/INSERT	-

前提条件

- ClickHouse 服务运行正常，Zookeeper 服务运行正常。
- 用户在集群中创建数据库或者表时需使用 ON CLUSTER 语句，保证各个 ClickHouse 节点上数据库、表的元信息相同。

说明

ClickHouse 赋权成功后，权限生效时间大约为 1 分钟。

添加 ClickHouse 角色

步骤 1 登录 Manager，选择“系统 > 权限 > 角色”，在“角色”界面单击“添加角色”按钮，进入添加角色页面。

步骤 2 在添加角色界面输入“角色名称”，在配置资源权限处单击集群名称，进入服务列表页面，单击 ClickHouse 服务，进入 ClickHouse 权限资源页面。

根据业务需求确定是否要创建具有 ClickHouse 管理员权限的角色。

说明

- ClickHouse 管理员权限为：除去对 user/role 的创建、删除和修改之外的所有数据库操作权限。
- 对于用户和角色的管理，仅有 ClickHouse 的内置用户 **clickhouse** 具有权限。

- 是，执行步骤 3。
- 否，执行步骤 4。

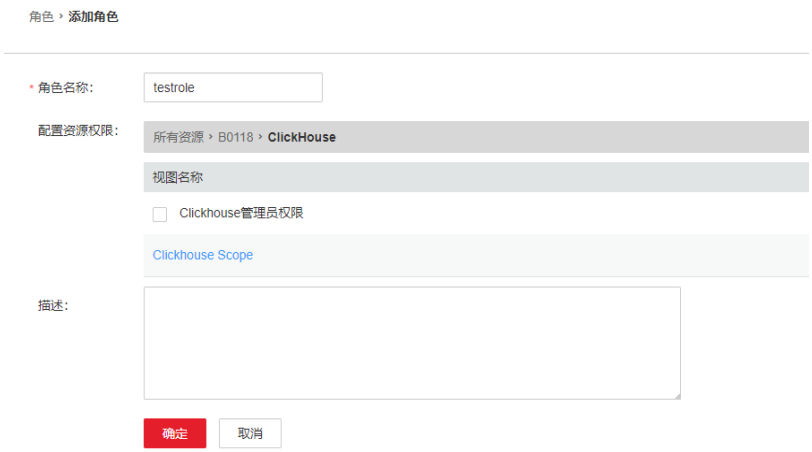

步骤 3 勾选“ClickHouse 管理员权限”，单击“确定”操作结束。

步骤 4 单击“ClickHouse Scope”，进入 ClickHouse 数据库资源列表。勾选“创建”权限，则该角色将拥有该数据库下的创建（CREATE）权限。

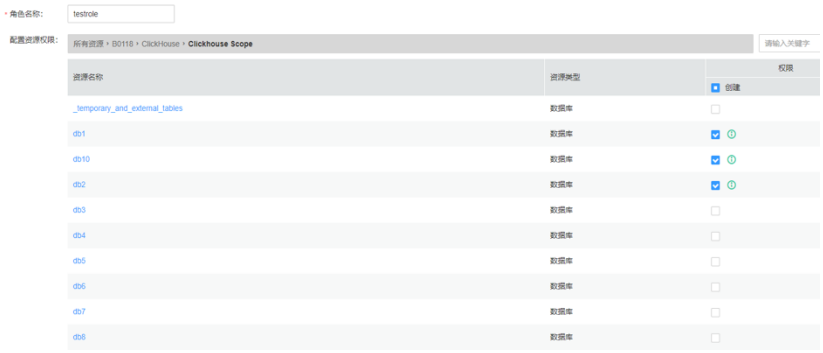

根据业务需求确定是否赋权。

- 是，单击“确定”操作结束。
- 否，执行步骤 5。

步骤 5 单击“资源名称 > *待操作的数据库资源名称*”，进入表、视图页面，根据业务需要，勾选“读”（SELECT 权限）或者“写”（INSERT 权限）权限，单击“确定”。

----结束

添加用户并将 ClickHouse 对应角色绑定到该用户

步骤 1 登录 Manager，选择“系统 > 权限 > 用户”，单击“添加用户”，进入添加用户页面。

步骤 2 “用户类型”选择“人机”，在“密码”和“确认密码”参数设置该用户对应的密码。

说明

- 用户名：添加的用户名不能包含字符“-”，否则会导致认证失败。
- 密码：设置的密码不能携带“$”、“.”、“#”特殊字符，否则会导致认证失败。

步骤 3 在“角色”处单击“添加”，在弹框中选择具有 ClickHouse 权限的角色，单击“确定”添加到角色，单击“确定”完成操作。

步骤 4 登录 ClickHouse 客户端安装节点，使用新添加的用户及设置的密码连接 ClickHouse 服务。

- 执行以下命令，切换到客户端安装目录。

  cd /opt/*客户端安装目录*

- 执行以下命令配置环境变量。

  source bigdata_env

- 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 ClickHouse 表的权限，具体请参见添加 ClickHouse 角色，为用户绑定对应角色。如果当前集群未启用 Kerberos 认证，则无需执行本步骤。

  kinit ***步骤 1*** *中添加的用户*

- 使用新添加的用户登录验证。

  当前集群未启用 Kerberos 认证：

  clickhouse client --host *ClickHouse 的实例 IP* **--multiline --port** *ClickHouse 的端口号* **--secure**

当前集群已启用 Kerberos 认证：

clickhouse client --host *ClickHouse 的实例 IP* **--user** *用户名* **--password --port** 9440 **--secure**

输入用户密码

说明

普通模式的用户为默认的 default 用户，或者使用 ClickHouse 社区开源能力添加管理用户。不能使用在 FusionInsight Manager 页面创建的用户。

----结束

异常场景下登录客户端操作赋权

ClickHouse 集群默认每个节点上的表元信息是相同的，因此在 Manager 的权限管理页面上默认采集的是任意 ClickHouse 节点的表信息，如果有个别节点上创建 DATABASE/TABLE 时未使用 ON CLUSTER 语句，则权限操作可能无法展示该资源，不保证可以对其赋权。对于这样单个 ClickHouse 节点中的本地表，如果需要赋权，则可以通过后台客户端进行操作。

说明

以下操作，需要提前获取到需要赋权的角色、数据库或表名称、对应的 ClickHouseServer 实例所在的节点 IP。

- ClickHouseServer 的实例 IP 地址可登录集群 FusionInsight Manager，然后选择“集群 > 服务 > ClickHouse > 实例”，获取 ClickHouseServer 实例对应的业务 IP 地址。
- 系统域名：默认为 hadoop.com。可登录集群 FusionInsight Manager，单击“系统 > 权限 > 域和互信”，“本端域”参数值即为系统域名。在执行命令时改为小写。

步骤 1 以 root 用户登录 ClickHouseServer 实例所在的节点。

步骤 2 执行以下命令获取“clickhouse.keytab”文件路径。

ls ${BIGDATA_HOME}/FusionInsight_ClickHouse_*/install/FusionInsight-ClickHouse-*/clickhouse/keytab/clickhouse.keytab

步骤 3 以客户端安装用户，登录安装客户端的节点。

步骤 4 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 5 执行以下命令配置环境变量。

source bigdata_env

步骤 6 执行如下命令使用客户端命令连接 ClickHouseServer 实例。

如果当前集群已启用 Kerberos 认证，执行以下命令：

clickhouse client --host *ClickHouseServer 实例所在节点 IP* **--user clickhouse/hadoop.**<*系统域名*> **--password** *步骤 2 中获取的 clickhouse.keytab 路径* **--port** *ClickHouse 的端口号* **--secure**

如果当前集群未启用 Kerberos 认证，执行以下命令：

clickhouse client --host *ClickHouseServer 实例所在节点 IP* **--user clickhouse --port** *ClickHouse 的端口号*

步骤 7 对某 DATABASE 进行赋权操作，执行如下命令。

授权操作语法，其中 *DATABASE* 为要操作的数据库名称，*role* 为需要操作的角色。

GRANT [ON CLUSTER *cluster_name***]** *privilege* **ON** *{DATABASE|TABLE}* **TO** *{user | role}*

例如，给用户 testuser 授予数据库 t2 的 CREATE 权限：

GRANT CREATE ON *m2* **to** *testuser***;**

步骤 8 对 TABLE/VIEW 进行赋权操作，执行如下命令，其中 *TABLE* 为要操作的表或视图名称，*user* 为需要操作的角色。

对某数据库下的表赋予查询权限：

GRANT SELECT ON *TABLE* **TO** *user;*

对某数据库下的表赋予写入权限：

GRANT INSERT ON *TABLE* **TO** *user;*

步骤 9 执行如下命令，退出客户端。

quit;

----结束

3.2.2 配置 ClickHouse 默认用户密码（MRS 3.1.2-LTS 版本）

ClickHouse 集群创建成功后，可以通过 ClickHouse 客户端访问连接 ClickHouse 服务端，默认的用户名为“default”。

该操作指导 ClickHouse 集群创建成功后，设置 ClickHouse 的用户名密码。

说明

- 本章节适用于 MRS 3.1.2 版本。
- “default”为 ClickHouse 默认系统用户，仅普通模式（未开启 kerberos 认证）下可使用的 ClickHouse 管理员用户。

配置 ClickHouse 默认用户密码

步骤 1 登录集群 Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”。

步骤 2 在搜索栏中搜索参数“users.default.password”，并修改参数密码，如图 3-1 所示：

图3-1 修改默认用户密码

步骤 3 登录安装客户端的节点，执行以下命令，切换到客户端安装目录。

cd *集群客户端安装目录*

步骤 4 执行以下命令配置环境变量。

source bigdata_env

步骤 5 使用新修改的密码登录 ClickHouse。

clickhouse client --host *ClickHouse 实例 IP* **--user** *default* **--password**

输入用户密码

说明

ClickHouse 实例 IP 获取方式：在集群详情页面，选择“组件管理 > ClickHouse > 实例”，获取 ClickHouse 的 IP 地址。

----结束

3.2.3 配置 ClickHouse 默认用户密码（MRS 3.3.0-LTS 版本）

ClickHouse 集群创建成功后，可以通过 ClickHouse 客户端访问连接 ClickHouse 服务端。

本章节指导用户创建 ClickHouse 集群（普通模式）后，设置 ClickHouse 的默认用户“default”和“clickhouse”的密码。

说明

- 本章节适用于 MRS 3.3.0-LTS 及后续版本。
- “default”和“clickhouse”用户为普通模式（未开启 kerberos 认证）集群下 ClickHouse 默认内部管理员用户。
- 如果普通模式 ClickHouse 的默认用户“default”和“clickhouse”修改了默认密码，ClickHouseServer 节点重装主机后，重装主机节点的“default”和“clickhouse”用户密码也会重置，需要重新修改密码。

配置 ClickHouse 默认用户密码

步骤 1 使用 **root** 用户登录 ClickHouse 安装节点，切换到 **omm** 用户，进入“$BIGDATA_HOME/FusionInsight_ClickHouse_*/install/FusionInsight-ClickHouse-*/clickhouse/clickhouse_change_password”目录。

su - omm

cd $BIGDATA_HOME/FusionInsight_ClickHouse_*/install/FusionInsight-ClickHouse-*/clickhouse/clickhouse_change_password

步骤 2 执行如下命令修改 **default** 或 **clickhouse** 用户密码：

./change_password.sh

如下所示：以 clickhouse 用户为例，按照提示输入 clickhouse 和密码，等待密码修改完成。

```
[omm@192-168-43-165 clickhouse_change_password]\>./change_password.sh
/opt/clickhouseclient/ClickHouse/clickhouse_change_password/clickhouse-common.sh: line 16: /ENV_VARS: No such file or directory
/opt/clickhouseclient/ClickHouse/clickhouse_change_password/clickhouse-common.sh: line 17: /clickhouse-env.sh: No such file or directory
mkdir: cannot create directory ‘’: No such file or directory
mkdir: cannot create directory ‘’: No such file or directory

Please enter the username that you would like to change password, the user should be default or clickhouse
clickhouse

Please enter a password contains at least a small letter, a capital letter, a number and a special character from -%;[]{}@_
Retype a password:
```

说明

密码复杂度要求：

- 密码长度限制是 8~64 位。
- 至少包含一个小写字母、一个大写字母、一个数字和一个特殊字符，支持的特殊字符包含-%;[]{}@_。

步骤 3 查看密码修改结果：

1. 执行如下命令，查看“客户端安装目录/ClickHouse/clickhouse/config/clickhouse-env.sh”文件中参数“CLICKHOUSE_CONF_DIR”的值

   cd *客户端安装目录*/**ClickHouse/clickhouse/config/**

   vi clickhouse-env.sh

   如下所示：

   ```
   LICKHOUSE_CONF_DIR="${BIGDATA_HOME}/FusionInsight_ClickHouse_*/*_ClickHouseServer/etc"
   CLICKHOUSE_SECURITY_ENABLED="true"
   CLICKHOUSE_BALANCER_LIST="192.168.42.14,192.168.67.89"
   CLICKHOUSE_STARTUP_PRINCIPAL="clickhouse/hadoop.hadoop.com@HADOOP.COM"
   USER_REALM="HADOOP.COM"
   OM_DECOMMISSION_HOSTNAME_LIST=""
   CLICKHOUSE_INSTALL_HOME="/opt/xxx/Bigdata/FusionInsight_ClickHouse_8.3.0/install/FusionInsight-ClickHouse-v22.3.2.2-lts"
   CK_BALANCER_LIST="server-2110081635-0003,server-2110082001-0019"
   ```

2. 登录到 ClickHouse Server 节点的，查看“${BIGDATA_HOME}/FusionInsight_ClickHouse_*/*_ClickHouseServer/etc/users.xml”文件中参数“password_sha256_hex”的值，即为存储修改后的密码。

   cd ${BIGDATA_HOME}/*FusionInsight_ClickHouse_*/*_ClickHouseServer*/**etc/**

   vi users.xml

   如下所示：用 password_sha256_hex 来存储修改后的密码。配置文件中包含认证密码信息可能存在安全风险，建议当前场景执行完毕后删除相关配置文件或加强安全管理。

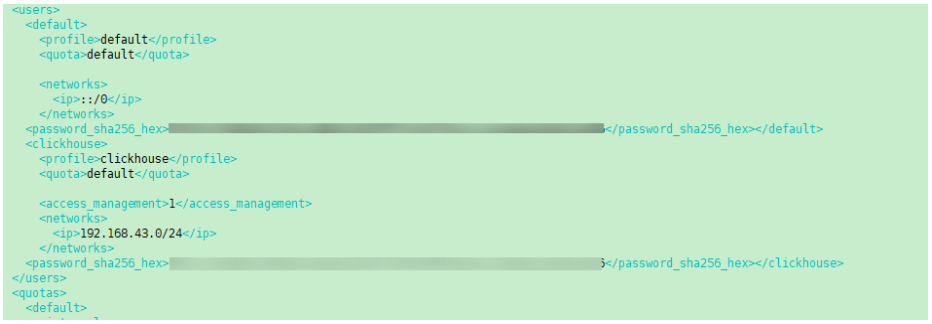

----结束

3.2.4 ClickHouse 使用 OpenLDAP 认证

ClickHouse 支持和 OpenLDAP 进行对接，通过在 ClickHouse 上添加 OpenLDAP 服务器配置和创建用户，实现账号和权限的统一集中管理和权限控制等操作。此方案适合从 OpenLDAP 服务器中批量向 ClickHouse 中导入用户。

本章节操作仅支持 MRS 3.1.0 及以上集群版本。

前提条件

- MRS 集群及 ClickHouse 实例运行正常，已安装 ClickHouse 客户端。
- OpenLDAP 已安装且状态正常。

对接 OpenLDAP 服务器创建 ClickHouse 用户

步骤 1 登录集群 Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”。

步骤 2 选择“ClickHouseServer（角色）> 自定义”，在“clickhouse-config-customize”配置项中添加如下 OpenLDAP 配置参数。

表3-4 OpenLDAP 参数说明

参数名	参数值说明	参数取值参考
ldap_servers.ldap_server_name.host	OpenLDAP 服务器主机名或 IP，不能为空。	localhost
ldap_servers.ldap_server_name.port	OpenLDAP 服务器端口。 如果 enable_tls 参数设置为 true，则默认端口号为 636，否则为 389。	636
ldap_servers.ldap_server_name.auth_dn_prefix	用于构造要绑定到的 DN 的前缀和后缀。 生成的 DN 将被构造为 auth_dn_prefix + escape(user_name) + auth_dn_suffix 字符串。 auth_dn_suffix 通常应将逗号	uid=
ldap_servers.ldap_server_name.auth_dn_suffix		,ou=Group,dc=node1,dc=com

参数名	参数值说明	参数取值参考
	“,”作为其第一个非空格字符。	
ldap_servers.ldap_server_name.enable_tls	触发使用 OpenLDAP 服务器安全连接的标志。 • 纯文本（ldap://）协议指定“no”（不推荐）。 • LDAP over SSL/TLS (ldaps://)协议指定“yes”。	yes
ldap_servers.ldap_server_name.tls_require_cert	SSL/TLS 对端证书校验行为。 取值范围为： 'never'、'allow'、'try'、'require'。	allow

说明

其他参数说明详细可以参考<ldap_servers>配置参数详解。

步骤 3 添加完配置后，单击“保存”，在弹出对话框中单击“确定”，配置保存成功后，单击“完成”。

步骤 4 Manager 页面，单击“实例”，选择 ClickHouseServer 实例，单击“更多 > 重启实例 ”，弹出对话框输入密码，单击“确定”。重启实例对话框，单击“确定”，根据界面提示信息确认实例重启成功，单击“完成”重启操作完成。

步骤 5 登录 ClickHouseServer 实例所在主机节点，进入“${BIGDATA_HOME}/FusionInsight_ClickHouse_*版本号*/*x_x*_ClickHouseServer/etc”目录。

cd ${BIGDATA_HOME}/FusionInsight_ClickHouse_*/*x_x*_ClickHouseServer/etc

步骤 6 执行以下命令，查看配置文件 config.xml，确认 OpenLDAP 参数是否配置成功。

cat config.xml

```
[root@k                3 etc]# cat config.xml
<yandex>
  <ldap_servers>
    <ldap_server_name>
      <auth_dn_prefix>uid=</auth_dn_prefix>
      <port>636</port>
      <host>localhost</host>
      <enable_tls>yes</enable_tls>
      <tls_require_cert>allow</tls_require_cert>
      <auth_dn_suffix>,ou=Group,dc=node1,dc=com</auth_dn_suffix>
    </ldap_server_name>
  </ldap_servers>
  <zookeeper>
```

步骤 7 以 root 用户登录 ClickHouseServer 实例所在的节点。

步骤 8 执行以下命令获取“clickhouse.keytab”文件路径。

ls ${BIGDATA_HOME}/FusionInsight_ClickHouse_*/install/FusionInsight-ClickHouse-*/clickhouse/keytab/clickhouse.keytab

步骤 9 以客户端安装用户，登录安装客户端的节点。

步骤 10 执行以下命令，切换到 ClickHouse 客户端安装目录。

cd /opt/client

步骤 11 执行以下命令配置环境变量。

source bigdata_env

步骤 12 执行如下命令使用客户端命令连接 ClickHouseServer 实例。

- 如果当前集群已启用 Kerberos 认证，使用 clickhouse.keytab 连接 ClickHouseServer 实例：

  clickhouse client --host *ClickHouseServer 实例所在节点 IP* **--user clickhouse/hadoop.**<*系统域名*> **--password** *步骤 8 中获取的 clickhouse.keytab 路径* **--port** *ClickHouse 的端口号*

  说明

  系统域名：默认为 hadoop.com。具体可登录集群 FusionInsight Manager，单击“系统 > 权限 > 域和互信”，“本端域”参数值即为系统域名。在执行命令时改为小写。

- 如果当前集群未启用 Kerberos 认证，使用 ClickHouse 管理员用户连接 ClickHouseServer 实例：

  clickhouse client --host *ClickHouseServer 实例所在节点 IP* **--user clickhouse --port** *ClickHouse 的端口号*

步骤 13 创建 OpenLDAP 中的普通用户。

如以下语句，在集群 default_cluster 上创建 testUser 用户，设置 ldap_server 为步骤 6 中<ldap_servers>标签下的 OpenLDAP 服务名，本示例为 ldap_server_name。

CREATE USER *testUser* **ON CLUSTER** *default_cluster* **IDENTIFIED WITH ldap_server BY** 'ldap_server_name'**;**

testUser 用户为 OpenLDAP 中已有的用户名，请根据实际情况修改。

步骤 14 退出客户端，使用新建的用户登录验证配置是否成功。

exit;

clickhouse client --host *ClickHouseServer 实例 IP* **--user** *testUser* **--password --port** *ClickHouse 的端口号*

输入 testUser 对应的密码

----结束

<ldap_servers>配置参数详解

- host

  OpenLDAP 服务器主机名或 IP，必选参数，不能为空。

- port

  OpenLDAP 服务器端口，如果 enable_tls 参数设置为 true，则默认为 636，否则为 389。

- auth_dn_prefix，auth_dn_suffix

用于构造要绑定到的 DN 的前缀和后缀。

实际上，生成的 DN 将被构造为 auth_dn_prefix + escape(user_name) + auth_dn_suffix 字符串。

注意，这意味着 auth_dn_suffix 通常应将逗号“,”作为其第一个非空格字符。

- enable_tls
  触发使用 OpenLDAP 服务器安全连接的标志。
  为纯文本（ldap://）协议指定“no”（不推荐）。
  为 LDAP over SSL/TLS (ldaps://)协议指定“yes”（建议为默认值）。
- tls_minimum_protocol_version
  SSL/TLS 的最小协议版本。
  接受的值是： 'ssl2'、'ssl3'、'tls1.0'、'tls1.1'、'tls1.2'（默认值）。
- tls_require_cert
  SSL/TLS 对端证书校验行为。
  接受的值是： 'never'、'allow'、'try'、'require'（默认值）。
- tls_cert_file
  证书文件。
- tls_key_file
  证书密钥文件。
- tls_ca_cert_file
  CA 证书文件。
- tls_ca_cert_dir
  CA 证书所在的目录。
- tls_cipher_suite
  允许加密套件。

3.3 使用 ClickHouse 多租户

3.3.1 ClickHouse 多租户介绍

说明

本章节内容仅适用于 MRS 3.2.0 及之后版本。

ClickHouse 多租户介绍

ClickHouse 多租户特性通过“用户 > 租户角色 > 资源 profiles 管理”的模型，使用户拥有对集群资源的管理能力，目前支持内存和 CPU 优先级管理。多租户设计模型如下图所示：

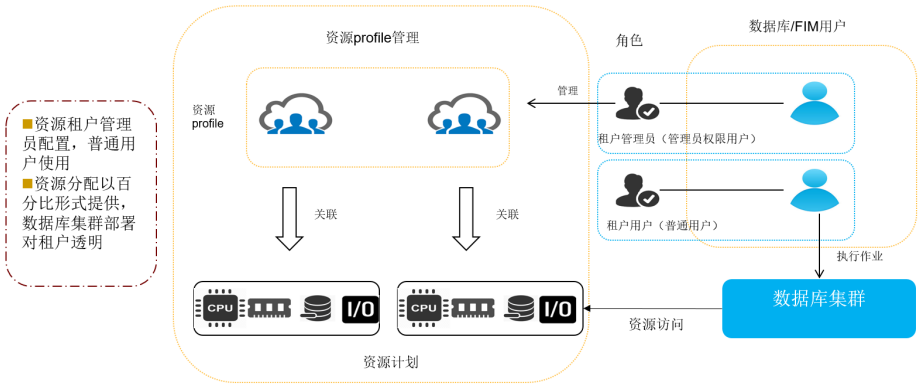

通过 FusionInsight Manager 服务配置和租户管理页面的操作，用户可以实现设置服务内存限额、创建租户、关联 ClickHouse 服务、绑定逻辑集群、设置租户可用内存和 CPU 优先级、租户关联用户等操作。Manager 侧和 ClickHouse 侧的角色关联关系如下图所示：

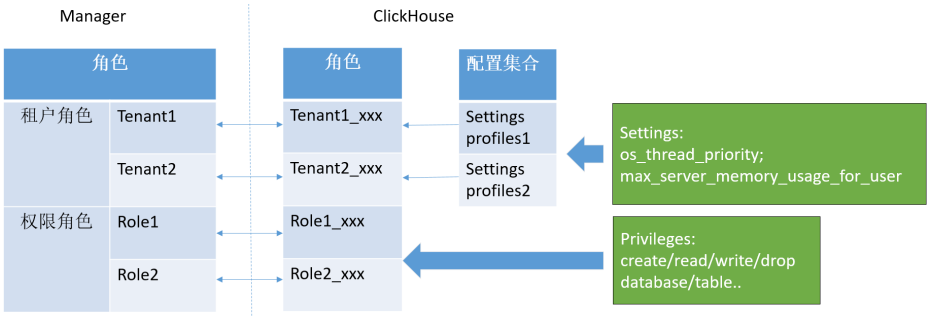

当前版本支持的资源配置列表如下表所示：

资源	取值范围	描述	备注
服务级别内存资源限额	0~1	表示当前 ClickHouseServer 在服务器上可用内存的比例。	如服务器物理内存为 10G，该值设置为 0.9，则 ClickHouse 服务在当前服务器上可用内存为 10G* 0.9 = 9G
租户级别内存资源限制	0%~100%	表示当前租户在 ClickHouseServer 中可用内存的百分比。	如该值设置为 80，则当前租户可使用的内存总额为：服务可使用内存 * 80%
租户级别 CPU 优先级	-20~19	该值关联 OS 的 NICE 值，值越小，则进程的 CPU 优先级越高。	该特性依赖 OS 的 CAP_SYS_NICE 能力，集群安装后默认不开启，如需使用，请参考 3.3.2 开启 CPU 优先级特性。

3.3.2 开启 CPU 优先级特性

说明

本章节内容仅适用于 MRS 3.2.0 及之后版本。

操作场景

ClickHouse 租户支持 CPU 优先级，该特性依赖 OS 的 CAP_SYS_NICE 能力，需要开启该能力才可以生效。

操作步骤

步骤 1 使用 **root** 用户登录 ClickHouseServer 实例节点，执行如下命令：

setcap cap_sys_nice=+ep /opt/Bigdata/FusionInsight_ClickHouse_*/install/FusionInsight-ClickHouse-*/clickhouse/bin/clickhouse

说明

所有的 ClickHouseServer 节点都需要执行该命令。

步骤 2 登录 FusionInsight Manager 页面，选择“集群 > 服务 > ClickHouse > 实例”，勾选所有的 ClickHouseServer 实例，选择“更多 > 重启实例”，重启所有 ClickHouseServer 实例。

步骤 3 执行如下命令，查看 CPU 优先级特性能力是否开启：

getcap /opt/Bigdata/FusionInsight_ClickHouse_*/install/FusionInsight-ClickHouse-*/clickhouse/bin/clickhouse

如下返回值表示 CPU 优先级特性已开启：

```
/opt/Bigdata/FusionInsight_ClickHouse_*/install/FusionInsight-
ClickHouse*/clickhouse/bin/clickhouse = cap_sys_nice+ep
```

----结束

3.3.3 管理 ClickHouse 租户

说明

本章节内容仅适用于 MRS 3.2.0 及之后版本。

操作场景

集群管理员通过 FusionInsight Manager 页面可以创建 ClickHouse 租户，并关联逻辑集群。系统用户绑定该租户后，则拥有该租户的逻辑集群相关权限。

创建 ClickHouse 租户

步骤 1 登录 FusionInsight Manager，单击“租户资源”。

步骤 2 单击，打开添加租户的配置页面，参见表 3-5 为租户配置属性。

表3-5 租户参数一览

参数名	描述
集群	选择要创建租户的集群。
名称	• 指定当前租户的名称，长度为 3~50 个字符，可包含数字、字母或下划线（_）。 • 根据业务需求规划租户的名称，不得与当前集群中已有的角色、HDFS 目录或者 Yarn 队列重名。
租户资源类型	选择“叶子租户资源” **说明** 创建 ClickHouse 租户，租户资源类型只能选择“叶子租户”。
计算资源	为当前租户选择动态计算资源。 • 选择“Yarn”时，系统自动在 Yarn 中以租户名称创建任务队列。 • 不选择“Yarn”时，系统不会自动创建任务队列。
配置模式	计算资源参数配置模式。 • 选择“基础”时，只需配置“默认资源池容量（%）”参数即可。 • 选择“高级”时，可手动配置资源分配权重，租户的最小/最大/预留资源。
默认资源池容量 （%）	配置当前租户在默认资源池中使用的计算资源百分比，取值范围 0~100%。
权重	资源分配权重，取值范围从 0 到 100。
最小资源	保证租户资源能获得的资源（有抢占支持）。取值可以是父租户资源的百分比或绝对值。当租户资源作业量比较少时，资源会自动借给其他租户资源，当租户资源能使用的资源不满足最小资源时，可以通过抢占来要回之前借出的资源。
最大资源	租户资源最多能使用的资源，租户资源不能得到比最大资源设定更多的资源。取值可以是父租户资源的百分比或绝对值。
预留资源	租户资源预留资源。即使租户资源内没有作业，预留的资源也不能给别的租户资源使用。取值可以是父租户资源的百分比或绝对值。
存储资源	为当前租户选择存储资源。 • 选择“HDFS”时，系统将分配存储资源。 • 不选择“HDFS”时，系统不会分配存储资源。

参数名	描述
文件\目录数上限	配置文件和目录数量配额。
存储空间配额	配置当前租户使用的 HDFS 存储空间配额。 • 取值范围：当存储空间配额单位设置为 MB 时，范围为 1～8796093022208。当存储空间配额单位设置为 GB 时，范围为 1～8589934592。 • 此参数值表示租户可使用的 HDFS 存储空间上限，不代表一定使用了这么多空间。 • 如果参数值大于 HDFS 物理磁盘大小，实际最多使用全部的 HDFS 物理磁盘空间。
存储路径	配置租户在 HDFS 中的存储目录。 • 系统默认将自动在“/tenant”目录中以租户名称创建文件夹。例如租户“ta1”，默认 HDFS 存储目录为“/tenant/ta1”。 • 第一次创建租户时，系统自动在 HDFS 根目录创建“/tenant”目录。支持自定义存储路径。
服务	• “服务”选择“ClickHouse”。 – 关联类型”：当“服务”选择“ClickHouse”时，关联类型”只支持“共享”。 – “关联逻辑集群”：若 ClickHouse 没有开启逻辑集群，则默认关联 default_cluster，若已经开启逻辑集群，则按需选择需要关联的逻辑集群。 – “CPU 优先级”：CPU 优先级取值范围为-20~19，该值关联 OS 的 NICE 值，取值越小，CPU 优先级越高。如需开启 CPU 优先级请参考 3.3.2 开启 CPU 优先级特性。 – “内存”：内存限制为百分比，如该值设置为 80，则当前租户可使用的内存总额为：服务可使用内存 * 80%。
描述	配置当前租户的描述信息。

步骤 3 单击“确定”，等待界面提示租户创建成功。

步骤 4 ClickHouse 租户创建完成后，可以在“租户资源”中查看并修改租户资源。

1. 在 FusionInsight Manager 页面，选择“租户资源”，在租户列表中选中需要查看的 ClickHouse 租户，查看租户概述和资源配额。
2. 选择“资源”，单击“资源详情”后的  ，对租户资源进行修改。
3. 修改完成后，单击“确定”，返回“资源”页面，展示修改后的资源详情。

说明

修改 ClickHouse 租户资源配额后，需要重新登录 ClickHouse 客户端才能生效。

----结束

添加用户并绑定租户

- 新添加用户绑定租户：登录 FusionInsight Manager，选择“系统 > 权限 > 用户”，单击“添加用户”，添加一个人机用户，在角色中添加创建 ClickHouse 租户的租户。此时该用户具有 ClickHouse 逻辑集群权限。
- 为已有的用户绑定租户：登录 FusionInsight Manager，选择“系统 > 权限 > 用户”，在该用户的“操作”列单击“修改”，在角色中添加创建 ClickHouse 租户的租户。如果用户需要删除 ClickHouse 租户，只需在角色中删除 ClickHouse 租户即可。

说明

- 用户绑定 ClickHouse 租户后，即用户改租户的逻辑集群权限。
- 当有多个用户绑定同一个租户时，当前版本租户级别内存限制不支持实时的总量限制。例如 user1 和 user2 同时绑定 tenant1 租户，租户内存限制为 10 GB，user1 执行的查询共使用内存 5 GB，则此时 user2 发起查询时，会限制 user2 可使用的内存为 5 GB，且在本次查询过程中，服务不会动态的更新这个限制。
- 当前版本不支持一个用户绑定多个 ClickHouse 租户，若 user1 已经关联 tenant1，那么再关联 tenant2 时，界面不会报错，后台日志中会打印相关说明，该用户已经关联租户，此次关联操作无效。

为已有的租户关联 ClickHouse 服务

1. 在 FusionInsight Manager 页面，选择“租户资源”，选中需要操作的租户，选择“服务关联”页签，单击“关联服务”，具体参数如下表所示：

参数	描述
服务	选择“ClickHouse”
关联类型	选择“共享”
关联逻辑集群	若 ClickHouse 没有开启逻辑集群，则默认关联 default_cluster，若已经开启逻辑集群，则按需选择需要关联的逻辑集群
CPU 优先级	CPU 优先级取值范围为-20~19，该值关联 OS 的 NICE 值，取值越小，CPU 优先级越高。如需开启 CPU 优先级请参考 3.3.2 开启 CPU 优先级特性
内存	内存限制为百分比，如该值设置为 80，则当前租户可使用的内存总额为：服务可使用内存 * 80%

2. 在弹出的页签中按照业务需求进行租户配置，单击“确定”，租户关联服务。
3. 如果需要解除关联 ClickHouse 服务：

在 FusionInsight Manager 页面，选择“租户资源”，选中需要操作的租户，在“操作”列单击“删除”，在弹窗中单击“确定”，解除关联 ClickHouse 服务。

说明

当租户解除关联 ClickHouse 服务后，该租户将不再拥有 ClickHouse 逻辑集群的权限。同时绑定该租户的用户也不再拥有 ClickHouse 逻辑集群的权限。

3.3.4 修改 ClickHouse 服务级别内存限制

说明

本章节内容仅适用于 MRS 3.2.0 及之后版本。

操作场景

为保证 ClickHouseServer 实例所在节点其他服务实例的正常使用，ClickHouseServer 支持修改在当前节点占用的最大内存。

操作步骤

步骤 1 登录 FusuinInsight Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置 > ClickHouseServer（角色） > 性能”。

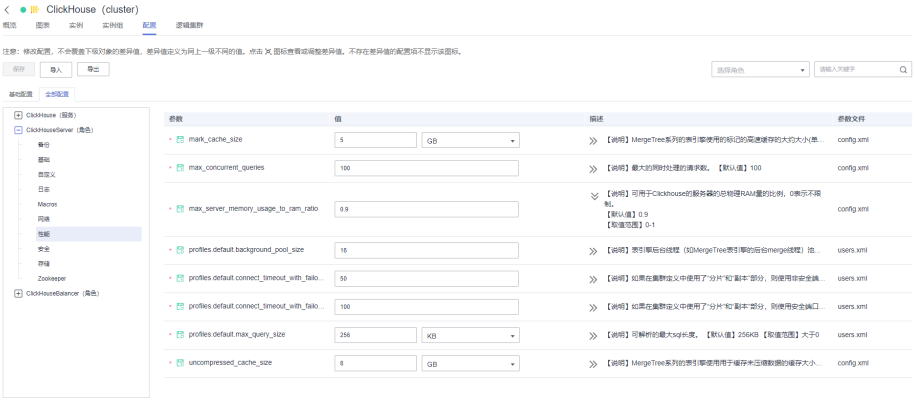

步骤 2 按需修改“max_server_memory_usage_to_ram_ratio”参数值，并保存配置。

说明

- 修改该参数不需要重启即可生效。
- 参数取值范围为 0~1，表示可用于 ClickHouse 的服务器的总物理 RAM 量的比例。如服务器物理内存为 10G，该值设置为 0.9，则 ClickHouse 服务在当前服务器上可用内存为 10G* 0.9 = 9G，若参数设置为 0，则表示不限制，那么 ClickHouse 服务可以使用服务器的所有物理内存。该参数最多有效位为小数点后两位。

----结束

3.4 ClickHouse 数据类型

本章节介绍 MRS 的 ClickHouse 服务数据类型。

表3-6 ClickHouse 数据类型

分类	关键字	数据类型	描述
数据类型	Int8	Int8	取值范围：【-128，127】
	Int16	Int16	取值范围：【-32768，32767】
	Int32	Int32	取值范围：【-2147483648，2147483647】
	Int64	Int64	取值范围：【-9223372036854775808，9223372036854775807】
浮点类型	Float32	单精度浮点数	同 C 语言 Float 类型，单精度浮点数在机内占 4 个字节，用 32 位二进制描述。
	Float64	双精度浮点数	同 C 语言 Double 类型，双精度浮点数在机内占 8 个字节，用 64 位二进制描述。
Decimal 类型	Decimal	Decimal	有符号的定点数，可在加、减和乘法运算过程中保持精度。支持几种写法： • Decimal(P, S) • Decimal32(S) • Decimal64(S) • Decimal128(S) 说明 • P：精度，有效范围：[1:38]，决定可以有多少个十进制数字（包括分数）。 • S：规模，有效范围：[0：P]，决定数字的小数部分中包含的小数位数。
字符串类型	String	字符串	字符串可以是任意长度的。它可以包含任意的字节集，包含空字节。因此，字符串类型可以代替其他 DBMSs 中的 VARCHAR、BLOB、CLOB 等类型。
	FixedString	固定字符串	当数据的长度恰好为 N 个字节时，FixedString 类型是高效的。在其他情况下，这可能会降低效率。可以有效存储在 FixedString 类型的列中的值的示例： • 二进制表示的 IP 地址（IPv6

分类	关键字	数据类型	描述
			使用 FixedString（16）） • 语言代码（ru_RU, en_US … ） • 货币代码（USD, RUB … ） • 二进制表示的哈希值（MD5 使用 FixedString（16），SHA256 使用 FixedString（32））
时间日期类型	Date	日期	用两个字节存储，表示从 1970-01-01（无符号）到当前的日期值。日期中没有存储时区信息。
	DateTime	时间戳	用四个字节（无符号的）存储 Unix 时间戳。允许存储与日期类型相同的范围内的值。最小值为 1970-01-01 00:00:00。时间戳类型值精确到秒（没有闰秒）。时区使用启动客户端或服务器时的系统时区。
	DateTime64	DateTime64	此类型允许以日期（date）加时间（time）的形式来存储一个时刻的时间值。
布尔型	Boolean	Boolean	ClickHouse 没有单独的类型来存储布尔值。可以使用 UInt8 类型，取值限制为 0 或 1。
数组类型	Array	Array	Array(T)，由 T 类型元素组成的数组。T 可以是任意类型，包含数组类型。但不推荐使用多维数组，ClickHouse 对多维数组的支持有限。例如，不能在 MergeTree 表中存储多维数组。
元组类型	Tuple	Tuple	Tuple(T1, T2, ...)，元组，其中每个元素都有单独的类型，不能在表中存储元组（除了内存表）。它们可以用于临时列分组。在查询中，IN 表达式和带特定参数的 lambda 函数可以来对临时列进行分组。
Domains 数据类型	Domains	Domains	Domains 类型是特定实现的类型： IPv4 是与 UInt32 类型保持二进制兼容的 Domains 类型，用于

分类	关键字	数据类型	描述
			存储 IPv4 地址的值。它提供了更为紧凑的二进制存储的同时支持识别可读性更加友好的输入输出格式。 IPv6 是与 FixedString（16）类型保持二进制兼容的 Domain 类型，用于存储 IPv6 地址的值。它提供了更为紧凑的二进制存储的同时支持识别可读性更加友好的输入输出格式。
枚举类型	Enum8	Enum8	取值范围：【-128，127】 Enum 保存 'string'= integer 的对应关系，例如：Enum8('hello' = 1, 'world' = 2)
	Enum16	Enum16	取值范围：【-32768，32767】
可为空	Nullable	Nullable	除非在 ClickHouse 服务器配置中另有说明，否则 NULL 是任何 Nullable 类型的默认值。Nullable 类型字段不能包含在表索引中。 可以与 TypeName 的正常值存放一起。例如，Nullable(Int8) 类型的列可以存储 Int8 类型值，而没有值的行将存储 NULL。
嵌套类型	nested	nested	嵌套的数据结构就像单元格内的表格。嵌套数据结构的参数（列名和类型）的指定方式与 CREATE TABLE 查询中的指定方式相同。每个表行都可以对应于嵌套数据结构中的任意数量的行。 示例：Nested(Name1 Type1, Name2 Type2, …)

3.5 ClickHouse 表引擎介绍

背景介绍

表引擎在 ClickHouse 中的作用十分关键，不同的表引擎决定了：

- 数据存储和读取的位置
- 支持哪些查询方式
- 能否并发式访问数据
- 能不能使用索引
- 是否可以执行多线程请求
- 数据复制使用的参数

其中 MergeTree 和 Distributed 是 ClickHouse 表引擎中最重要，也是最常使用的两个引擎，本文将重点进行介绍。

MergeTree 系列引擎

MergeTree 用于高负载任务的最通用和功能最强大的表引擎，其主要有以下关键特征：

- 基于分区键（partitioning key）的数据分区分块存储
- 数据索引排序（基于 primary key 和 order by）
- 支持数据复制（带 Replicated 前缀的表引擎）
- 支持数据抽样

在写入数据时，该系列引擎表会按照分区键将数据分成不同的文件夹，文件夹内每列数据为不同的独立文件，以及创建数据的序列化索引排序记录文件。该结构使得数据读取时能够减少数据检索时的数据量，极大的提高查询效率。

- MergeTree

  建表语法：

```
CREATE TABLE [IF NOT EXISTS] [db.]table_name [ON CLUSTER cluster]
(
   name1 [type1] [DEFAULT|MATERIALIZED|ALIAS expr1] [TTL expr1],
   name2 [type2] [DEFAULT|MATERIALIZED|ALIAS expr2] [TTL expr2],
   ...
   INDEX index name1 expr1 TYPE type1(...) GRANULARITY value1,
   INDEX index name2 expr2 TYPE type2(...) GRANULARITY value2
) ENGINE = MergeTree()
ORDER BY expr
[PARTITION BY expr]
[PRIMARY KEY expr]
[SAMPLE BY expr]
[TTL expr [DELETE|TO DISK 'xxx'|TO VOLUME 'xxx'], ...]
[SETTINGS name=value, ...]
```

  使用示例：

```
CREATE TABLE default.test (
  name1 DateTime,
  name2 String,
  name3 String,
  name4 String,
  name5 Date,
  ...
) ENGINE = MergeTree()
PARTITION BY toYYYYMM(name5)
```

```
ORDER BY (name1, name2)
SETTINGS index_granularity = 8192
```

示例参数说明如下：

- **ENGINE = MergeTree()**：MergeTree 表引擎。
- **PARTITION BY** toYYYYMM(name4)：分区，示例数据将以月份为分区，每个月份一个文件夹。
- **ORDER BY**：排序字段，支持多字段的索引排序，第一个相同的时候按照第二个排序依次类推。
- **index_granularity = 8192**：排序索引的颗粒度，每 8192 条数据记录一个排序索引值。

如果被查询的数据存在于分区或排序字段中，能极大降低数据查找时间。

- ReplacingMergeTree

  该引擎和 MergeTree 的不同之处在于它会删除排序键值相同的重复项。ReplacingMergeTree 适合于清除重复数据节省存储空间，但是它不保证重复数据不出现，一般不建议使用。

  建表语法：

```
CREATE TABLE [IF NOT EXISTS] [db.]table_name [ON CLUSTER cluster]
(
   name1 [type1] [DEFAULT|MATERIALIZED|ALIAS expr1],
   name2 [type2] [DEFAULT|MATERIALIZED|ALIAS expr2],
   ...
) ENGINE = ReplacingMergeTree([ver])
[PARTITION BY expr]
[ORDER BY expr]
[SAMPLE BY expr]
[SETTINGS name=value, ...]
```

- SummingMergeTree

  当合并 SummingMergeTree 表的数据片段时，ClickHouse 会把所有具有相同主键的行合并为一行，该行包含了被合并的行中具有数值数据类型的列的汇总值。如果主键的组合方式使得单个键值对应于大量的行，则可以显著的减少存储空间并加快数据查询的速度。

  建表语法：

```
CREATE TABLE [IF NOT EXISTS] [db.]table name [ON CLUSTER cluster]
(
   name1 [type1] [DEFAULT|MATERIALIZED|ALIAS expr1],
   name2 [type2] [DEFAULT|MATERIALIZED|ALIAS expr2],
   ...
) ENGINE = SummingMergeTree([columns])
[PARTITION BY expr]
[ORDER BY expr]
[SAMPLE BY expr]
[SETTINGS name=value, ...]
```

  使用示例：

  创建一个 SummingMergeTree 表 testTable：

```
CREATE TABLE testTable
(
   id UInt32,
```

```
    value UInt32
)
ENGINE = SummingMergeTree()
ORDER BY id
```

插入表数据：

```
INSERT INTO testTable Values(5,9),(5,3),(4,6),(1,2),(2,5),(1,4),(3,8);
INSERT INTO testTable
Values(88,5),(5,5),(3,7),(3,5),(1,6),(2,6),(4,7),(4,6),(43,5),(5,9),(3,6);
```

在未合并 parts 查询所有数据：

```
SELECT * FROM testTable
┌─id─┬─value─┐
│  1 │     6 │
│  2 │     5 │
│  3 │     8 │
│  4 │     6 │
│  5 │    12 │
└────┴───────┘
┌─id─┬─value─┐
│  1 │     6 │
│  2 │     6 │
│  3 │    18 │
│  4 │    13 │
│  5 │    14 │
│ 43 │     5 │
│ 88 │     5 │
└────┴───────┘
```

ClickHouse 还没有汇总所有行，如果需要通过 ID 进行汇总聚合，需要用到 sum 和 GROUP BY 子句：

```
SELECT id, sum(value) FROM testTable GROUP BY id
┌─id─┬─sum(value)─┐
│  4 │         19 │
│  3 │         26 │
│ 88 │          5 │
│  2 │         11 │
│  5 │         26 │
│  1 │         12 │
│ 43 │          5 │
└────┴────────────┘
```

手工执行合并操作：

```
OPTIMIZE TABLE testTable
```

此时再查询 testTable 表数据：

```
SELECT * FROM testTable
┌─id─┬─value─┐
│  1 │    12 │
│  2 │    11 │
│  3 │    26 │
│  4 │    19 │
│  5 │    26 │
│ 43 │     5 │
│ 88 │     5 │
└────┴───────┘
```

SummingMergeTree 根据 ORDER BY 排序键作为聚合数据的条件 Key。即如果排序 key 是相同的，则会合并成一条数据，并对指定的合并字段进行聚合。

后台执行合并操作时才会进行数据的预先聚合，而合并操作的执行时机无法预测，所以可能存在部分数据已经被预先聚合、部分数据尚未被聚合的情况。因此，在执行聚合计算时，SQL 中仍需要使用 GROUP BY 子句。

- AggregatingMergeTree

  AggregatingMergeTree 是预先聚合引擎的一种，用于提升聚合计算的性能。AggregatingMergeTree 引擎能够在合并分区时，按照预先定义的条件聚合数据，同时根据预先定义的聚合函数计算数据并通过二进制的格式存入表内。

  建表语法：

```
CREATE TABLE [IF NOT EXISTS] [db.]table_name [ON CLUSTER cluster]
(
   name1 [type1] [DEFAULT|MATERIALIZED|ALIAS expr1],
   name2 [type2] [DEFAULT|MATERIALIZED|ALIAS expr2],
   ...
) ENGINE = AggregatingMergeTree()
[PARTITION BY expr]
[ORDER BY expr]
[SAMPLE BY expr]
[TTL expr]
[SETTINGS name=value, ...]
```

  使用示例：

  AggregatingMergeTree 无单独参数设置，在分区合并时，在每个数据分区内，会按照 ORDER BY 聚合，使用何种聚合函数，对哪些列字段计算，则是通过定义 AggregateFunction 函数类型实现，例如：

```
create table test_table (
name1 String,
name2 String,
name3 AggregateFunction(uniq,String),
name4 AggregateFunction(sum,Int),
name5 DateTime
) ENGINE = AggregatingMergeTree()
PARTITION BY toYYYYMM(name5)
ORDER BY (name1,name2)
PRIMARY KEY name1;
```

  AggregateFunction 类型的数据在写入和查询时需要分别调用*state、*merge 函数，*表示定义字段类型时使用的聚合函数。如上示例表 test_table 定义的 name3、name4 字段分别使用了 uniq、sum 函数，那么在写入数据时需要调用 uniqState、sumState 函数，并使用 INSERT SELECT 语法。

```
insert into test_table select
'8','test1',uniqState('name1'),sumState(toInt32(100)),'2021-04-30 17:18:00';
insert into test_table select
'8','test1',uniqState('name1'),sumState(toInt32(200)),'2021-04-30 17:18:00';
```

  在查询数据时也需要调用对应的函数 uniqMerge、sumMerge：

```
select name1,name2,uniqMerge(name3),sumMerge(name4) from test_table group by
name1,name2;
┌name1─┬─name2─┬─uniqMerge(name3)─┬─sumMerge(name4)─┐
│ 8    │ test1 │                1 │             300 │
└──────┴───────┴──────────────────┴─────────────────┘
```

AggregatingMergeTree 更常用的方式是结合物化视图使用，物化视图即其它数据表上层的一种查询视图。

- CollapsingMergeTree

  CollapsingMergeTree 它通过定义一个 sign 标记位字段记录数据行的状态。如果 sign 标记为 1，则表示这是一行有效的数据；如果 sign 标记为-1，则表示这行数据需要被删除。

  建表语法：

```
CREATE TABLE [IF NOT EXISTS] [db.]table_name [ON CLUSTER cluster]
(
    name1 [type1] [DEFAULT|MATERIALIZED|ALIAS expr1],
    name2 [type2] [DEFAULT|MATERIALIZED|ALIAS expr2],
    ...
) ENGINE = CollapsingMergeTree(sign)
[PARTITION BY expr]
[ORDER BY expr]
[SAMPLE BY expr]
[SETTINGS name=value, ...]
```

- VersionedCollapsingMergeTree

  VersionedCollapsingMergeTree 表引擎在建表语句中新增了一列 version，用于在乱序情况下记录状态行与取消行的对应关系。主键相同，且 Version 相同、Sign 相反的行，在 Compaction 时会被删除。

  建表语法：

```
CREATE TABLE [IF NOT EXISTS] [db.]table_name [ON CLUSTER cluster]
(
    name1 [type1] [DEFAULT|MATERIALIZED|ALIAS expr1],
    name2 [type2] [DEFAULT|MATERIALIZED|ALIAS expr2],
    ...
) ENGINE = VersionedCollapsingMergeTree(sign, version)
[PARTITION BY expr]
[ORDER BY expr]
[SAMPLE BY expr]
[SETTINGS name=value, ...]
```

- GraphiteMergeTree

  GraphiteMergeTree 引擎用来存储时序数据库 Graphite 的数据。

  建表语法：

```
CREATE TABLE [IF NOT EXISTS] [db.]table_name [ON CLUSTER cluster]
(
    Path String,
    Time DateTime,
    Value <Numeric_type>,
    Version <Numeric_type>
    ...
) ENGINE = GraphiteMergeTree(config_section)
[PARTITION BY expr]
[ORDER BY expr]
[SAMPLE BY expr]
[SETTINGS name=value, ...]
```

Replicated*MergeTree 引擎

ClickHouse 中的所有 MergeTree 家族引擎前面加上 Replicated 就成了支持副本的合并树引擎。

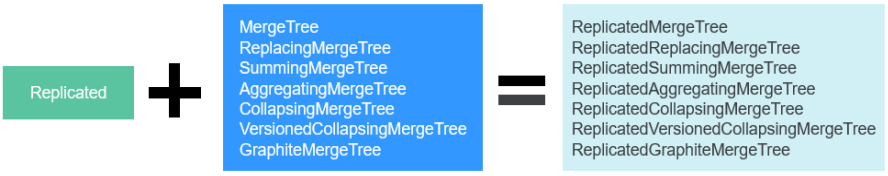

Replicated 系列引擎借助 ZooKeeper 实现数据的同步，创建 Replicated 复制表时通过注册到 ZooKeeper 上的信息实现同一个分片的所有副本数据进行同步。

Replicated 表引擎的创建模板：

```
ENGINE = Replicated*MergeTree('ZooKeeper 存储路径','副本名称', ...)
```

Replicated 表引擎需指定两个参数：

- ZooKeeper 存储路径：ZooKeeper 中该表相关数据的存储路径，建议规范化，如：*/clickhouse/tables/{shard}/数据库名/表名。*
- 副本名称，一般用**{replica}**即可。

Replicated 表引擎使用示例可以参考：3.6 ClickHouse 表创建。

Distributed 表引擎

Distributed 表引擎本身不存储任何数据，而是作为数据分片的透明代理，能够自动路由数据到集群中的各个节点，分布式表需要和其他本地数据表一起协同工作。分布式表会将接收到的读写任务分发到各个本地表，而实际上数据的存储在各个节点的本地表中。

图3-2 Distributed

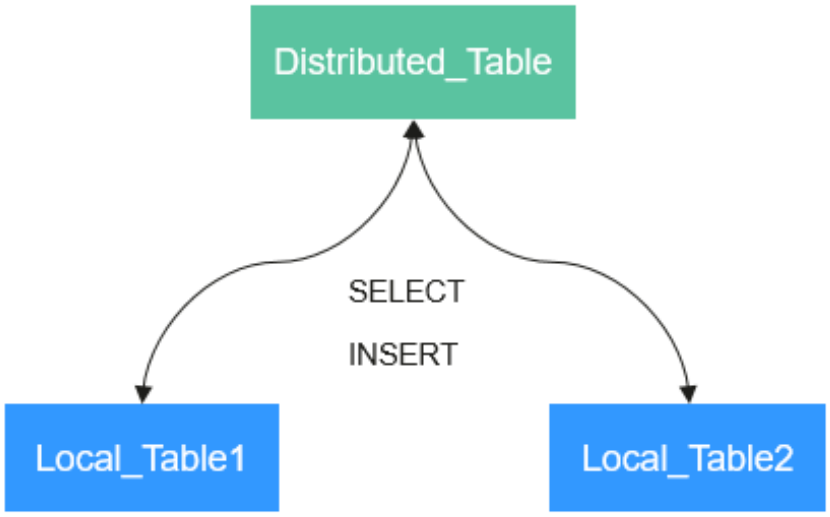

Distributed 表引擎的创建模板：

```
ENGINE = Distributed(cluster_name, database_name, table_name, [sharding_key])
```

Distributed 表参数解析如下：

- cluster_name：集群名称，在对分布式表执行读写的过程中，使用集群的配置信息查找对应的 ClickHouse 实例节点。
- database_name：数据库名称。
- table_name：数据库下对应的本地表名称，用于将分布式表映射到本地表上。
- sharding_key：分片键（可选参数），分布式表会按照这个规则，将数据分发到各个本地表中。

Distributed 表引擎使用示例：

```
--先创建一个表名为 test 的 ReplicatedMergeTree 本地表
CREATE TABLE default.test ON CLUSTER default_cluster_1
(
    `EventDate` DateTime,
    `id` UInt64
)
ENGINE = ReplicatedMergeTree('/clickhouse/tables/{shard}/default/test', '{replica}')
PARTITION BY toYYYYMM(EventDate)
ORDER BY id

--基于本地表 test 创建表名为 test_all 的 Distributed 表
CREATE TABLE default.test_all ON CLUSTER default_cluster_1
(
    `EventDate` DateTime,
    `id` UInt64
```

```
)
ENGINE = Distributed(default_cluster_1, default, test, rand())
```

分布式表创建规则：

- 创建 Distributed 表时需加上 **on cluster** *cluster_name*，这样建表语句在某一个 ClickHouse 实例上执行一次即可分发到集群中所有实例上执行。
- 分布式表通常以本地表加“_all”命名。它与本地表形成一对多的映射关系，之后可以通过分布式表代理操作多张本地表。
- 分布式表的表结构尽量和本地表的结构一致。如果不一致，在建表时不会报错，但在查询或者插入时可能会抛出异常。

3.6 ClickHouse 表创建

ClickHouse 依靠 ReplicatedMergeTree 引擎与 ZooKeeper 实现了复制表机制，用户在创建表时可以通过指定引擎选择该表是否高可用，每张表的分片与副本都是互相独立的。

同时 ClickHouse 依靠 Distributed 引擎实现了分布式表机制，在所有分片（本地表）上建立视图进行分布式查询，使用很方便。ClickHouse 有数据分片（shard）的概念，这也是分布式存储的特点之一，即通过并行读写提高效率。

CPU 架构为鲲鹏计算的 ClickHouse 集群表引擎不支持使用 HDFS 和 Kafka。

查看 ClickHouse 服务 cluster 等环境参数信息

步骤 1 使用 ClickHouse 客户端连接到 ClickHouse 服务端，具体请参考 3.1 从零开始使用 ClickHouse。

步骤 2 查询集群标识符 cluster 等其他环境参数信息。

select cluster,shard_num,replica_num,host_name from system.clusters;

```
SELECT
   cluster,
   shard_num,
   replica_num,
   host_name
FROM system.clusters

┌─cluster─────────────┬─shard_num─┬─replica_num─┬─host_name────────┐
│ default_cluster_1   │         1 │           1 │ node-master1dOnG │
│ default_cluster_1   │         1 │           2 │ node-group-1tXED0001
│
│ default_cluster_1   │         2 │           1 │ node-master2OXQS │
│ default_cluster_1   │         2 │           2 │ node-group-1tXED0002
│
│ default_cluster_1   │         3 │           1 │ node-master3QsRI │
│ default_cluster_1   │         3 │           2 │ node-group-1tXED0003
│
└─────────────────── ┴──────── ┴──────── ┴──────────────┘
```

```
6 rows in set. Elapsed: 0.001 sec.
```

步骤 3 查询分片标识符 shard 和副本标识符 replica。

select * from system.macros;

```
SELECT *
FROM system.macros

┌─macro───┬─substitution─┐
│ id      │ 76           │
│ replica │ 2            │
│ shard   │ 3            │
└─────────┴──────────────┘

3 rows in set. Elapsed: 0.001 sec.
```

----结束

创建本地复制表和分布式表

步骤 1 客户端登录 ClickHouse 节点，例如：**clickhouse client --host** *node-master3QsRI* **--multiline --port 9440 --secure;**

说明

node-master3QsRI 参数为查看 ClickHouse 服务 cluster 等环境参数信息中步骤 2 对应的 host_name 参数的值。

步骤 2 使用 ReplicatedMergeTree 引擎创建复制表。

例如，如下在 default_cluster_1 集群节点上和 default 数据库下创建表名为 test 的 ReplicatedMergeTree 表：

CREATE TABLE *default.test* **ON CLUSTER** *default_cluster_1*

(

`EventDate` DateTime,

`id` UInt64

)

ENGINE = ReplicatedMergeTree('*/clickhouse/tables/{shard}/default/test***', '***{replica}***')**

PARTITION BY toYYYYMM(EventDate)

ORDER BY id;

参数说明如下：

- ON CLUSTER 语法表示分布式 DDL，即执行一次就可在集群所有实例上创建同样的本地表。
- default_cluster_1 为查看 ClickHouse 服务 cluster 等环境参数信息中步骤 2 查询到的 cluster 集群标识符。

⚠ 注意

ReplicatedMergeTree 引擎族接收两个参数：

- ZooKeeper 中该表相关数据的存储路径。

  该路径必须在/clickhouse 目录下，否则后续可能因为 ZooKeeper 配额不够导致数据插入失败。

  为了避免不同表在 ZooKeeper 上数据冲突，目录格式必须按照如下规范填写：

  /clickhouse/tables/{shard}/default/test，其中/clickhouse/tables/{shard}为固定值，default 为数据库名，test 为创建的表名。

- 副本名称，一般用**{replica}**即可。

```
CREATE TABLE default.test ON CLUSTER default_cluster_1
(
    `EventDate` DateTime,
    `id` UInt64
)
ENGINE = ReplicatedMergeTree('/clickhouse/tables/{shard}/default/test', '{replica}')
PARTITION BY toYYYYMM(EventDate)
ORDER BY id

┌─host──────────────────┬─port─┬─status─┬─error─┬─num_hosts_remaining─┬─num_hosts_ac
tive─┐
│ node-group-1tXED0002  │ 9000 │      0 │       │                   5 │
│              3 │
│ node-group-1tXED0003  │ 9000 │      0 │       │                   4 │
│              3 │
│ node-master1dOnG      │ 9000 │      0 │       │                   3 │
│              3 │
└───────────────────────┴──────┴────────┴───────┴─────────────────────┴──────────┘
┌─host──────────────────┬─port─┬─status─┬─error─┬─num_hosts_remaining─┬─num_hosts_ac
tive─┐
│ node-master3QsRI      │ 9000 │      0 │       │                   2 │
│              0 │
│ node-group-1tXED0001  │ 9000 │      0 │       │                   1 │
│              0 │
│ node-master2OXQS      │ 9000 │      0 │       │                   0 │
│              0 │
└───────────────────────┴──────┴────────┴───────┴─────────────────────┴──────────┘

6 rows in set. Elapsed: 0.189 sec.
```

步骤 3 使用 Distributed 引擎创建分布式表。

例如，以下将在 default_cluster_1 集群节点上和 default 数据库下创建名为 test_all 的 Distributed 表：

CREATE TABLE *default.test_all* **ON CLUSTER** *default_cluster_1*

(

`EventDate` DateTime,

`id` UInt64

)

ENGINE = Distributed(*default_cluster_1, default, test, rand()***);**

```
CREATE TABLE default.test_all ON CLUSTER default_cluster_1
(
    `EventDate` DateTime,
    `id` UInt64
)
ENGINE = Distributed(default_cluster_1, default, test, rand())

┌─host──────────────────┬─port─┬─status─┬─error─┬─num_hosts_remaining─┬─num_hosts_ac
tive─┐
│ node-group-1tXED0002  │ 9000 │      0 │       │                   5
│                    0 │
│ node-master3QsRI      │ 9000 │      0 │       │                   4
│                    0 │
│ node-group-1tXED0003  │ 9000 │      0 │       │                   3
│                    0 │
│ node-group-1tXED0001  │ 9000 │      0 │       │                   2
│                    0 │
│ node-master1dOnG      │ 9000 │      0 │       │                   1
│                    0 │
│ node-master2OXQS      │ 9000 │      0 │       │                   0
│                    0 │
└───────────────────────┴──────┴────────┴───────┴─────────────────────┴──────────┘

6 rows in set. Elapsed: 0.115 sec.
```

说明

Distributed 引擎需要以下几个参数：

- default_cluster_1 为查看 ClickHouse 服务 cluster 等环境参数信息中步骤 2 查询到的 cluster 集群标识符。
- default 本地表所在的数据库名称。
- test 为本地表名称，该例中为步骤 2 中创建的表名。
- （可选的）分片键（sharding key）

  该键与 config.xml 中配置的分片权重（weight）一同决定写入分布式表时的路由，即数据最终落到哪个物理表上。它可以是表中一列的原始数据（如 site_id），也可以是函数调用的结果，如上面的 SQL 语句采用了随机值 rand()。注意该键要尽量保证数据均匀分布，另外一个常用的操作是采用区分度较高的列的哈希值，如 intHash64(user_id)。

----结束

ClickHouse 表数据操作

步骤 1 客户端登录 ClickHouse 节点。例如：

clickhouse client --host *node-master3QsRI* **--multiline --port 9440 --secure;**

说明

node-master3QsRI 参数为查看 ClickHouse 服务 cluster 等环境参数信息中步骤 2 对应的 host_name 参数的值。

步骤 2 参考创建本地复制表和分布式表创建表后，可以插入数据到本地表。

例如插入数据到本地表：test

insert into test values(toDateTime(now()), rand());

步骤 3 查询本地表信息。

例如查询步骤 2 中的表 test 数据信息：

select * from test;

```
SELECT *
FROM test

┌─────────EventDate─┬──────────id─┐
│ 2020-11-05 21:10:42           │ 1596238076          │
└──────────────────── ┴─────────────┘

1 rows in set. Elapsed: 0.002 sec.
```

步骤 4 查询 Distributed 分布式表。

例如步骤 3 中因为分布式表 test_all 基于 test 创建，所以 test_all 表也能查询到和 test 相同的数据。

select * from test_all;

```
SELECT *
FROM test_all

┌─────────EventDate─┬──────────id─┐
│ 2020-11-05 21:10:42           │ 1596238076          │
└──────────────────── ┴─────────────┘

1 rows in set. Elapsed: 0.004 sec.
```

步骤 5 切换登录节点为相同 shard_num 的 shard 节点，并且查询当前表信息，能查询到相同的表数据。

例如，退出原有登录节点：**exit;**

切换到节点 node-group-1tXED0003：

clickhouse client --host *node-group-1tXED0003* **--multiline --port 9440 --secure;**

说明

通过步骤 2 可以看到 node-group-1tXED0003 和 node-master3QsRI 的 shard_num 值相同。

show tables;

```
SHOW TABLES

┌─name─────┐
│ test          │
│ test_all      │
└──────────┘
```

步骤 6 查询本地表数据。例如在节点 node-group-1tXED0003 查询 test 表数据。

select * from test;

```
SELECT *
FROM test

┌─────────EventDate─┬──────id─┐
│ 2020-11-05 21:10:42 │ 1596238076 │
└─────────────────── ┴─────────┘

1 rows in set. Elapsed: 0.005 sec.
```

步骤 7 切换到不同 shard_num 的 shard 节点，并且查询之前创建的表数据信息。

例如退出之前的登录节点 node-group-1tXED0003：

exit;

切换到 node-group-1tXED0001 节点。通过步骤 2 可以看到 node-group-1tXED0001 和 node-master3QsRI 的 shard_num 值不相同。

clickhouse client --host *node-group-1tXED0001* **--multiline --port 9440 --secure;**

查询 test 本地表数据，因为 test 是本地表所以在不同分片节点上查询不到数据。

select * from test;

```
SELECT *
FROM test

Ok.
```

查询 test_all 分布式表数据，能正常查询到数据信息。

select * from test_all;

```
SELECT *
FROM test

┌─────────EventDate─┬──────id─┐
│ 2020-11-05 21:12:19 │ 3686805070 │
└─────────────────── ┴─────────┘

1 rows in set. Elapsed: 0.002 sec.
```

----结束

3.7 修改 ClickHouse 表为只读表模式

说明

本章节仅适用于 MRS 3.2.0 及之后版本。

操作场景

在数据迁移、一键均衡和退服缩容时，ClickHouse 支持 only_allow_select_statement 表级参数，可以对 mergetree 系列表引擎配置 only_allow_select_statement 参数来限制 alter、rename、drop、insert 操作，只允许 select 操作。

设置表只读模式

步骤 1 安装客户端，具体请参考 25.3.1 安装客户端章节。

步骤 2 使用 **root** 用户登录安装客户端的节点，执行以下命令：

cd *客户端安装目录*

source bigdata_env

步骤 3 如果当前集群为安全模式（开启 Kerberos 认证），执行以下命令认证当前用户，如果当前集群为普通模式（关闭 Kerberos 认证），则无需执行本步骤。

kinit *组件业务用户*

说明

该用户需要具有 ClickHouse 管理员权限。

步骤 4 执行 ClickHouse 组件的客户端命令连接服务端。

- 普通模式：

  clickhouse client --host *ClickHouse 的实例 IP* **--user** *用户名* **--password --port** 9440 **--secure**

  输入用户密码

- 安全模式：

  clickhouse client --host *ClickHouse 的实例 IP* **--port** 9440 **--secure**

说明

- 普通模式的用户为默认的 default 用户，或者使用 ClickHouse 社区开源能力添加管理用户。不能使用在 FusionInsight Manager 页面创建的用户。
- ClickHouse 的实例 IP 地址可登录集群 FusionInsight Manager，然后选择“集群 > 服务 > ClickHouse > 实例”，获取 ClickHouseServer 实例对应的业务 IP 地址。

步骤 5 执行如下语句，设置表为只读模式：

ALTER TABLE *{table_name}* **MODIFY SETTING only_allow_select_statement = true;**

----结束

3.8 收集 ClickHouse 系统表转储日志

说明

本章节适用于 MRS 3.3.0-LTS 及之后版本。

操作场景

在日常使用 ClickHouse 时，如果出现一些异常故障，需要紧急重启恢复业务，在紧急重启之前，需要及时转储 ClickHouse 各系统表状态信息，用于问题定位，提升 ClickHouse 问题定位的效率。

针对不同的系统表日志可以分为实时转储和一键转储，如下表所示：

系统表转储日志	系统表
实时转储系统表日志	• system.asynchronous_metrics • system.clusters • system.distribution_queue • system.events • system.grants • system.mutations • system.processes • system.metrics • system.part_moves_between_shards • system.replicas • system.replicated_fetches • system.replication_queue
一键转储系统表日志	• system.distributed_ddl_queue • system.errors • system.parts • system.parts_columns • system.query_log • system.query_thread_log • system.trace_log

收集实时转储系统表日志

步骤 1 登录 FusionInsight Manager 页面，选择“运维 > 日志 > 下载”，在“服务”勾选“ClickHouseSystemTableDump”。

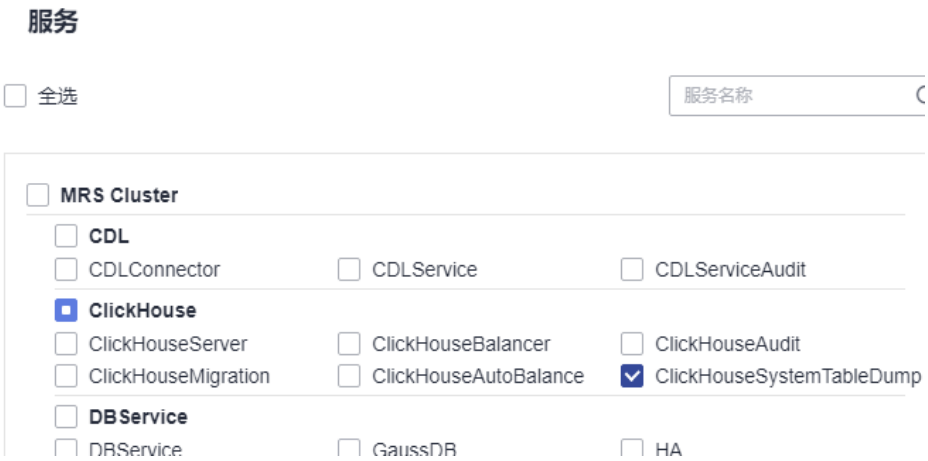

步骤 2 在“主机”中勾选需要获取的主机信息，单击“确定”。

步骤 3 单击右上角的时间编辑按钮，设置日志收集的“开始时间”和“结束时间”。

说明

收集异常故障日志时间长短可以咨询技术支持人员。

步骤 4 单击“下载”，实时转储的系统表会被保存在本地。

----结束

收集一键转储系统表日志

步骤 1 使用 **root** 用户后台登录任一 ClickHouseServer 节点，进入到 sbin 目录下。

cd ${BIGDATA_HOME}/FusionInsight_ClickHouse_*/*_*_ClickHouseServer/install/clickhouse/sbin

步骤 2 执行如下命令获取转储日志：

./clickhouse_systemtable_dump.sh 1 "*收集开始时间***" "***收集结束时间***"**

例如：**./clickhouse_systemtable_dump.sh 1 "2023-08-04 12:00:00" "2023-08-04 16:37:20"**

步骤 3 进入“/var/log/Bigdata/clickhouse/systemTableDump/oneclickTable”目录，查看一键转储压缩日志。

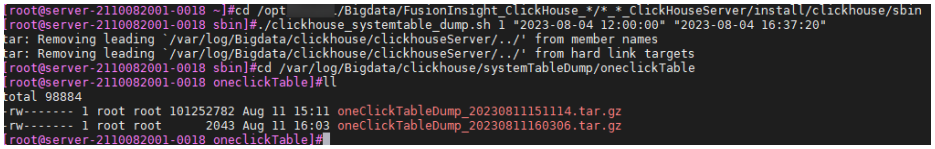

----结束

3.9 ClickHouse 数据迁移

3.9.1 ClickHouse 数据导入导出

使用 ClickHouse 客户端导入导出数据

本章节主要介绍使用 ClickHouse 客户端导入导出文件数据的基本语法和使用说明。

- CSV 格式数据导入

  clickhouse client --host *主机名/ClickHouse 实例 IP 地址* **--database** *数据库名* **--port** *端口号* **--secure --format_csv_delimiter="***csv 文件数据分隔符***" --query="INSERT INTO** *数据表名* **FORMAT CSV" <** *csv 文件所在主机路径*

  使用示例：

  ```
  clickhouse client --host 10.5.208.5 --database testdb --port 9440 --secure --format_csv_delimiter="," --query="INSERT INTO testdb.csv_table FORMAT CSV" < /opt/data
  ```

  数据表需提前创建好。

- CSV 格式数据导出

注意

导出数据为 CSV 格式的文件，可能存在 CSV 注入的安全风险，请谨慎使用。

  clickhouse client --host *主机名/ClickHouse 实例 IP 地址* **--database** *数据库名* **--port** *端口号* **-m --secure --query="SELECT * FROM** *表名***" >** *csv 文件导出路径*

  使用示例：

  ```
  clickhouse client --host 10.5.208.5 --database testdb --port 9440 -m --secure --query="SELECT * FROM test_table" > /opt/test
  ```

- parquet 格式数据导入

  cat *parquet 格式文件* **| clickhouse client --host** *主机名/ClickHouse 实例 IP* **--database** *数据库名* **--port** *端口号* **-m --secure --query="INSERT INTO** *表名* **FORMAT Parquet"**

  使用示例：

```
cat /opt/student.parquet | clickhouse client --host 10.5.208.5 --database
testdb --port 9440 -m --secure --query="INSERT INTO parquet_tab001 FORMAT
Parquet"
```

- parquet 格式数据导出

  clickhouse client --host *主机名/ClickHouse 实例 IP* **--database** *数据库名* **--port** *端口号* **-m --secure --query="select * from** *表名* **FORMAT Parquet"** > *parquet 格式文件输出路径*

  使用示例：

```
clickhouse client --host 10.5.208.5 --database testdb --port 9440 -m --secure -
-query="select * from test_table FORMAT Parquet" > /opt/student.parquet
```

- ORC 格式数据导入

  cat *orc 格式文件路径* **| clickhouse client --host** *主机名/ClickHouse 实例 IP* **--database** *数据库名* **--port** *端口号* **-m --secure --query="INSERT INTO** *表名* **FORMAT ORC"**

  使用示例：

```
cat /opt/student.orc | clickhouse client --host 10.5.208.5 --database testdb --
port 9440 -m --secure --query="INSERT INTO orc_tab001 FORMAT ORC"
#orc 格式文件格式文件数据可以从 HDFS 中导出，例如：
hdfs dfs -cat /user/hive/warehouse/hivedb.db/emp_orc/000000_0_copy_1 |
clickhouse client --host 10.5.208.5 --database testdb --port 9440 -m --secure -
-query="INSERT INTO orc_tab001 FORMAT ORC"
```

- ORC 格式数据导出

  clickhouse client --host *主机名/ClickHouse 实例 IP* **--database** *数据库名* **--port** *端口* -m **--secure --query="select * from** *表名* **FORMAT ORC"** > *输出的 ORC 格式文件路径*

  使用示例：

```
clickhouse client --host 10.5.208.5 --database testdb --port 9440 -m --secure -
-query="select * from csv_tab001 FORMAT ORC" > /opt/student.orc
```

- JSON 格式数据导入

  INSERT INTO *表名* **FORMAT JSONEachRow** *JSON 格式字符串 1 JSON 格式字符串 2*

  使用示例：

```
INSERT INTO test_table001 FORMAT JSONEachRow {"PageViews":5,
"UserID":"4324182021466249494", "Duration":146,"Sign":-1}
{"UserID":"4324182021466249494","PageViews":6,"Duration":185,"Sign":1}
```

- JSON 格式数据导出

  clickhouse client --host *主机名/ClickHouse 实例 IP* **--database** *数据库名* **--port** *端口号* **-m --secure --query="SELECT * FROM** *表名* **FORMAT JSON|JSONEachRow|JSONCompact|..."** > *json 文件输出路径*

  使用示例

```
#导出 json
clickhouse client --host 10.5.208.5 --database testdb --port 9440 -m --secure -
-query="SELECT * FROM test_table FORMAT JSON" > /opt/test.json

#导出 json(JSONEachRow)
clickhouse client --host 10.5.208.5 --database testdb --port 9440 -m --secure -
```

```
-query="SELECT * FROM test_table FORMAT JSONEachRow" >
/opt/test_jsoneachrow.json

#导出 json(JSONCompact)
clickhouse client --host 10.5.208.5 --database testdb --port 9440 -m --secure -
-query="SELECT * FROM test_table FORMAT JSONCompact" >
/opt/test_jsoncompact.json
```

3.9.2 将 Kafka 数据同步至 ClickHouse

您可以通过创建 Kafka 引擎表将 Kafka 数据自动同步至 ClickHouse 集群，具体操作详见本章节描述。

前提条件

- 已创建 Kafka 集群。已安装 Kafka 客户端。
- 已创建 ClickHouse 集群，并且 ClickHouse 集群和 Kafka 集群在同一 VPC 下，网络可以互通，并安装 ClickHouse 客户端。

约束限制

当前 ClickHouse 不支持和开启安全模式的 Kafka 集群进行对接。

Kafka 引擎表使用语法说明

- **语法**

```
CREATE TABLE [IF NOT EXISTS] [db.]table_name [ON CLUSTER cluster]
(
    name1 [type1] [DEFAULT|MATERIALIZED|ALIAS expr1],
    name2 [type2] [DEFAULT|MATERIALIZED|ALIAS expr2],
    ...
) ENGINE = Kafka()
SETTINGS
    kafka_broker_list = 'host1:port1,host2:port2',
    kafka_topic_list = 'topic1,topic2,...',
    kafka_group_name = 'group_name',
    kafka_format = 'data_format';
    [kafka_row_delimiter = 'delimiter_symbol',]
    [kafka_schema = '',]
    [kafka_num_consumers = N]
```

- **参数说明**

表3-7 Kafka 引擎表参数说明

参数名	是否必选	参数说明
kafka_broker_list	是	Kafka 集群 broker 实例的 IP 和端口列表。例如：*kafka 集群 broker 实例 IP1*:**9092**,*kafka 集群 broker 实例 IP2*:**9092**,*kafka 集群 broker 实例 IP3*:**9092**。 **说明** 启用 Kerberos 认证下，使用 21005 端口需要

参数名	是否必选	参数说明
		“allow.everyone.if.no.acl.found”参数值设置为 **true**； 若不设置此参数，操作会报错。 Kafka 集群 broker 实例 IP 获取方法如下： 登录 FusionInsight Manager，然后选择“集群 > 服务 > Kafka”。单击“实例”，查看 Kafka 角色实例的 IP 地址。
kafka_topic_list	是	Kafka 的 topic 列表。
kafka_group_name	是	Kafka 的 Consumer Group 名称，可以自己指定。
kafka_format	是	Kafka 消息体格式。例如 JSONEachRow、CSV、XML 等。
kafka_row_delimiter	否	每个消息体（记录）之间的分隔符。
kafka_schema	否	如果解析格式需要一个 schema 时，此参数必填。
kafka_num_consumers	否	单个表的消费者数量。默认值是：1，如果一个消费者的吞吐量不足，则指定更多的消费者。消费者的总数不应该超过 topic 中分区的数量，因为每个分区只能分配一个消费者。

Kafka 数据同步至 ClickHouse 操作示例

步骤 1 参考 16.11 使用 Kafka 客户端，切换到 Kafka 客户端安装目录。

1. 以 Kafka 客户端安装用户，登录 Kafka 安装客户端的节点。
2. 执行以下命令，切换到客户端安装目录。

   cd /opt/client
3. 执行以下命令配置环境变量。

   source bigdata_env
4. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

   kinit *组件业务用户*

步骤 2 执行以下命令，创建 Kafka 的 Topic。详细的命令使用可以参考 16.2 管理 Kafka 主题。

kafka-topics.sh --topic *kafkacktest2* **--create --zookeeper** *ZooKeeper 角色实例 IP:ZooKeeper 侦听客户端连接的端口*/**kafka --partitions** *2* **--replication-factor** *1*

说明

- **--topic** 参数值为要创建的 Topic 名称，本示例创建的名称为 kafkacktest2 。

- **--zookeeper：**ZooKeeper 角色实例所在节点 IP 地址，填写三个角色实例其中任意一个的 IP 地址即可。ZooKeeper 角色实例所在节点 IP 获取参考如下：

  登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。然后选择“集群 > 服务 > ZooKeeper > 实例”。查看 ZooKeeper 角色实例的 IP 地址。

- **--partitions** 主题分区数和**--replication-factor** 主题备份个数不能大于 Kafka 角色实例数量。
- *ZooKeeper 侦听客户端连接的端口*获取方式：登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。默认为 24002。

步骤 3 参考 3.1 从零开始使用 ClickHouse 登录 ClickHouse 客户端。

1. 执行以下命令，切换到客户端安装目录。

   cd /opt/client

2. 执行以下命令配置环境变量。

   source bigdata_env

3. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 ClickHouse 表的权限，具体请参见 3.2.1 ClickHouse 用户及权限管理章节，为用户绑定对应角色。如果当前集群未启用 Kerberos 认证，则无需执行本步骤。

   kinit *组件业务用户*

   例如，**kinit** clickhouseuser。

4. 执行以下命令连接到要导入数据的 ClickHouse 实例节点。

   clickhouse client --host *ClickHouse 的实例 IP* **--user** *登录名* **--password --port** *ClickHouse 的端口号* **--database** *数据库名* **--multiline**

   输入用户密码

步骤 4 参考 Kafka 引擎表使用语法说明，在 ClickHouse 中创建 Kafka 引擎表。例如，如下建表语句在 default 数据库下，创建表名为 kafka_src_tbl3，Topic 名为 kafkacktest2、消息格式为 JSONEachRow 的 Kafka 引擎表。

```
create table kafka_src_tbl3 on cluster default_cluster
(id UInt32, age UInt32, msg String)
ENGINE=Kafka()
SETTINGS
 kafka_broker_list='kafka集群broker实例IP1:9092,kafka集群broker实例IP2:9092,kafka集群broker实例IP3:9092',
 kafka_topic_list='kafkacktest2',
 kafka_group_name='cg12',
 kafka_format='JSONEachRow';
```

步骤 5 创建 ClickHouse 本地复制表。例如，如下创建表名为 kafka_dest_tbl3 的 ReplicatedMergeTree 表。

```
create table kafka_dest_tbl3 on cluster default_cluster
( id UInt32, age UInt32, msg String )
engine = ReplicatedMergeTree('/clickhouse/tables/{shard}/default/kafka_dest_tbl3',
'{replica}')
partition by age
order by id;
```

步骤 6 创建 MATERIALIZED VIEW，该视图会在后台转换 Kafka 引擎中的数据并将其放入创建的 ClickHouse 表中。

```
create materialized view consumer3 on cluster default_cluster to kafka_dest_tbl3 as
select * from kafka_src_tbl3;
```

步骤 7 再次执行步骤 1，进入 Kafka 客户端安装目录。

步骤 8 执行以下命令，在 Kafka 的 Topic 中产生消息。例如，如下命令向步骤 2 中创建的 Topic 发送消息。

kafka-console-producer.sh --broker-list *kafka 集群 broker 实例 IP1*:9092,*kafka 集群 broker 实例 IP2*:9092,*kafka 集群 broker 实例 IP3*:9092 **--topic** *kafkacktest2*

```
>{"id":31, "age":30, "msg":"31 years old"}
>{"id":32, "age":30, "msg":"31 years old"}
>{"id":33, "age":30, "msg":"31 years old"}
>{"id":35, "age":30, "msg":"31 years old"}
```

步骤 9 使用 ClickHouse 客户端登录步骤 3 中 ClickHouse 实例节点，查询 ClickHouse 表数据。例如，查询 kafka_dest_tbl3 本地复制表，Kafka 消息中的数据已经同步到该表。

```
select * from kafka_dest_tbl3;
```

```
ClickHouseKXya.mrs-2xxk.com :) select * from kafka_dest_tbl3;

SELECT *
FROM kafka_dest_tbl3

Query id: 386ed9db-26b6-4823-8ce5-5b2de14384bb

┌─id─┬─age─┬─msg──────────┐
│ 31 │  30 │ 31 years old │
└────┴─────┴──────────────┘

┌─id─┬─age─┬─msg──────────┐
│ 32 │  30 │ 31 years old │
└────┴─────┴──────────────┘

┌─id─┬─age─┬─msg──────────┐
│ 33 │  30 │ 31 years old │
└────┴─────┴──────────────┘

┌─id─┬─age─┬─msg──────────┐
│ 35 │  30 │ 31 years old │
└────┴─────┴──────────────┘

4 rows in set. Elapsed: 0.003 sec.
```

----结束

3.9.3 使用 ClickHouse 数据迁移工具

ClickHouse 数据迁移工具可以将某几个 ClickHouseServer 实例节点上的一个或多个 MergeTree 引擎分区表的部分分区迁移至其他 ClickHouseServer 节点上相同的表中。在扩容场景中，可以使用该工具将原节点上的部分数据迁移至新增节点上，从而达到扩容后的数据均衡。

前提条件

- ClickHouse 服务运行正常，Zookeeper 服务运行正常，迁入、迁出节点的 ClickHouseServer 实例状态正常。
- 请确保迁入节点已有待迁移数据表，且确保该表是 MergeTree 系列引擎的分区表。

- 创建迁移任务前请确保所有对待迁移数据表的写入任务已停止，且任务启动后，只允许对待迁移数据表进行查询操作，禁止对该表进行写入、删除等操作，否则可能会造成迁移前后数据不一致。
- 迁入节点的 ClickHouse 数据目录有足够的空间。

操作步骤

步骤 1 登录 Manager，选择“集群 > 服务 > ClickHouse”， 在 ClickHouse 服务界面单击“数据迁移”页签，进入数据迁移界面。

步骤 2 单击“创建迁移任务”。

步骤 3 在创建迁移任务界面，填写迁移任务的相关参数，具体参考如下表 3-8。

表3-8 迁移任务参数说明

参数名	参数取值说明
任务名称	填写具体的任务名称。可由字母、数组及下划线组成，长度为 1~50 位，且不能与已有的迁移任务相同。
任务类型	• 定时任务：选择定时任务时，可以设置“开始时间”参数，设定任务在当前时间以后的某个时间点执行。 • 即时任务：任务启动后立即开始执行。
开始时间	在“任务类型”参数选择“定时任务”时填写，有效值为当前时间以后的某个时间（最长为 90 天以后）。

步骤 4 在选择迁移节点界面，填写“迁入节点主机名”、“迁出节点主机名”，单击“下一步”。

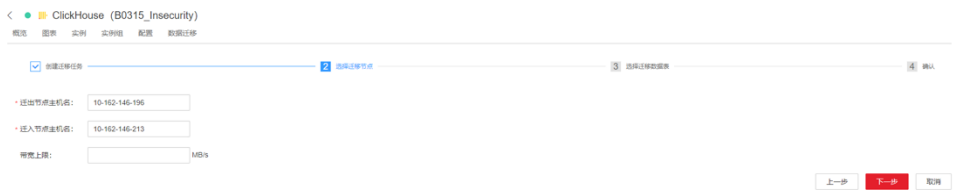

说明

- “迁入节点主机名”与“迁出节点主机名”只能各填写一个主机名，不支持多节点迁移。

  具体的参数值可以在 ClickHouse 服务界面单击“实例”页签，查看当前 ClickHouseServer 实例所在“主机名称”列获取。
- “带宽上限”为可选参数，若不填写则为无上限，最大可设置为 10000MB/s。

步骤 5 在选择迁移数据表界面，单击“数据库”后的 ，选择待迁出节点上存在的数据库，在“数据表”处选择待迁移的数据表，数据表下拉列表中展示的是所选数据库中的 MergeTree 系列引擎的分区表。“节点信息”中展示的为当前迁入节点、迁出节点上 ClickHouse 服务数据目录的空间使用情况，单击“下一步”。

步骤 6 确认任务信息，确认无误后可以单击“提交”提交任务。

数据迁移工具将根据待迁移数据表的大小自动计算需要迁移的分区，数据迁移量则是计算出的需要迁移的分区总大小。

步骤 7 提交迁移任务成功后，单击操作列的“启动”。如果任务类型是即时任务则开始执行任务，如果是定时任务则开始倒计时。

步骤 8 迁移任务执行过程中，可单击“取消”取消正在执行的迁移任务，若取消任务，则会回退掉迁入节点上已迁移的数据。

可以单击“更多 > 详情”查看迁移过程中的日志信息。

步骤 9 迁移完成后，选择“更多 > 结果”查看迁移结果；选择“更多 > 删除”清理 ZooKeeper 以及迁出节点上该迁移任务相关的目录。

----结束

3.9.4 使用迁移工具快速迁移 ClickHouse 集群数据

说明

本章节仅适用于 MRS 3.2.0 及之后版本。

操作场景

场景一：随着 MRS ClickHouse 业务数量的增长，原有集群的存储和计算资源已不满足业务需求，需要对集群进行拆分，将部分用户业务及数据库数据迁移到新建集群中。

场景二：MRS ClickHouse 集群后端主机所在机房需要搬迁，需要将 ClickHouse 集群整体迁移到另外一个机房的新集群当中。

为了解决上述场景下对搬迁能力的要求，MRS 提供了 ClickHouse 集群数据一键式工具搬迁能力，将源集群中的 ClickHouse 数据库、表对象 DDL、业务数据迁移到新建集群中。

迁移方案原理介绍

- Replicated*MergeTree 引擎的复制表迁移：

  ClickHouse 利用 ZooKeeper 将同一分片下不同副本的 Replicated*MergeTree 引擎表数据自动进行同步，本迁移方案利用该特性进行数据迁移。大致逻辑步骤如下：

  首先，在目标集群的配置文件中添加源集群的 ZooKeeper 信息作为辅助 ZooKeeper。其次，再在目标集群中创建和源集群相同 ZooKeeper 路径不同副本并且表结构和源集群一致的临时表。临时表创建完成源集群中的数据将会自动同步到临时表。最后，等待源集群数据同步到目标集群的临时表完成后，将目标集群中的临时表数据拷贝到正式表即可。

  图3-3 Replicated*MergeTree 引擎表迁移架构图

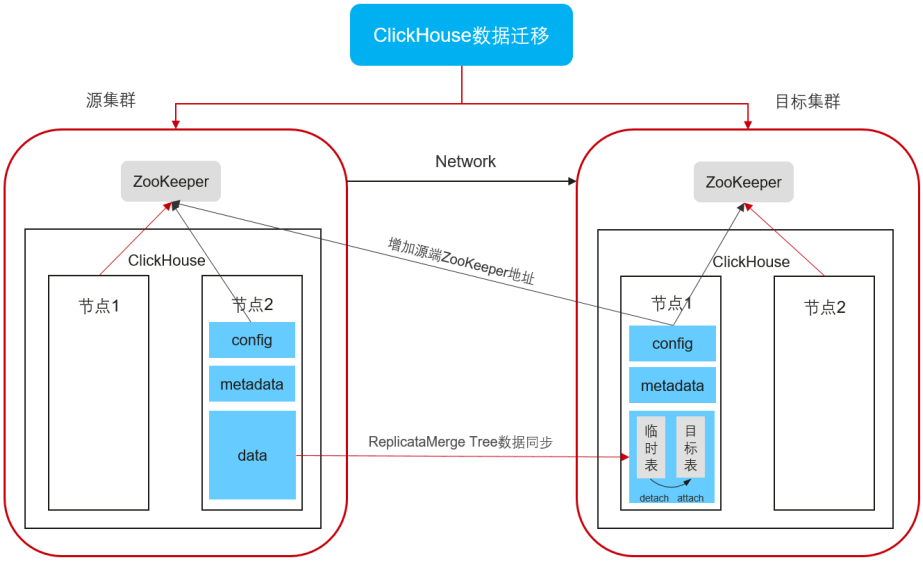

- 分布式表迁移：

分布式表不涉及表数据，只涉及表的元数据信息，迁移过程中会将源集群 ClickHouse 分布式表的元数据信息导出，然后将元数据信息修改为目标集群的 ZooKeeper 路径和副本，根据修改后的元数据信息在目标集群新建表即可。

- 非复制表和物化视图迁移：

  针对非复制表和物化视图采用调用 remote 函数方式进行数据迁移。

上述迁移的操作步骤通过迁移工具脚本做了封装处理，只需修改相关配置文件执行迁移脚本即可完成一键式迁移操作，具体可以参考操作步骤说明。

前提条件

- 待迁移的源 ClickHouse 集群状态正常，并且集群模式为安全集群。
- 已创建待迁移数据的 ClickHouse 目标集群，该集群版本为 MRS 3.1.3 及以上版本且必须为安全集群。该 ClickHouse 集群的 ClickHouserver 实例数量需要大于等于源集群。
- 逻辑集群当前只支持副本数相同的集群间的数据搬迁。

迁移约束

- 该搬迁指导仅支持迁移表数据及表对象 DDL 元数据，用户业务 ETL 等 SQL 语句需要自行迁移。
- 为了保证迁移后源目标集群数据的一致性，迁移开始前需要短暂停止源集群的 ClickHouse 业务，具体停止时机请参考操作步骤说明。
- 搬迁过程中如果源集群表被删除，迁移程序无法自动处理该场景，需要手动进行处理。

迁移整体流程

迁移整体流程和步骤参考如下：

图3-4 迁移流程图

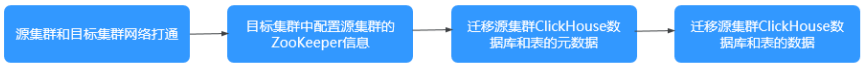

表3-9 迁移流程说明

阶段	流程说明
步骤 1：源集群和目标集群网络打通	将源 ClickHouse 集群和目标 ClickHouse 集群的网络需要打通，保证两个集群 ClickHouse 实例节点网络可以互通。
步骤 2：在目标集群配置文件中增加源集群的 ZooKeeper 信息	通过在目标集群的 ClickHouse 配置文件中添加源集群的 ZooKeeper 信息，将源集群中的 ZooKeeper 做为迁移过程中的辅助 ZooKeeper。

阶段	流程说明
步骤 3：迁移源 ClickHouse 集群下数据库和表的元数据信息到目标集群	执行元数据迁移脚本，将源集群中的 ClickHouse 数据库和表的数据库名、表名、表结构等元数据信息迁移到目标集群。
步骤 4：迁移源 ClickHouse 集群下数据库和表数据到目标集群	执行数据迁移脚本，将源集群中的 ClickHouse 数据库和表的数据迁移至目标集群。

步骤 1：源集群和目标集群网络打通

1. 打通源集群和目标集群的网络。保证两个集群 ClickHouse 实例节点网络可以互通。
2. 在目标集群的所有节点配置中添加源集群的 hosts 信息，同时在源集群的所有节点配置中添加目标集群的 hosts 信息。
   a. 登录源 ClickHouse 集群的 FusionInsight Manager，选择“集群 > ClickHouse > 实例”，查看 ClickHouseServer 实例节点的业务 IP 地址。
   b. 使用 ssh 登录任意一个 ClickHouseServer 节点，执行以下命令查看源集群 ClickHouse 实例的 hosts 配置。

      cat /etc/hosts

      例如，如下示例显示命令查询示例集群查询结果，获取 ClickHouse 实例的主机配置信息。

      ```
      [root@19          ~]# cat /etc/hosts
      127.0.0.1   localhost localhost.localdomain localhost4 localhost4.localdomain4
      ::1         localhost localhost.localdomain localhost6 localhost6.localdomain6

      192.168.64.59 100-93-30-239 100-93-30-239.
      192.168.64.157 100-95-140-144 100-95-140-144.
      192.168.64.139 100-94-12-218 100-94-12-218.
      192.168.64.81 100-94-163-99 100-94-163-99.
      192.168.64.66 192-168-64-66 192-168-64-66.
      192.168.64.24 192-168-64-24 192-168-64-24.
      192.168.64.91 192-168-64-91 192-168-64-91.
      192.168.64.162 192-168-64-162 192-168-64-162.
      10.10.10.10 hadoop.hadoop.com
      ```

   c. 登录目标 ClickHouse 集群的 FusionInsight Manager，选择“集群 > ClickHouse > 实例”，查看目标集群 ClickHouseServer 实例节点的业务 IP 地址。
   d. 以 **root** 用户登录所有目标集群的 ClickHouse 实例节点，执行编辑命令修改节点的“**/etc/hosts**”配置。

      vi /etc/hosts

      将步骤 2.b 中获取的源集群 ClickHouse 实例的 hosts 信息，拷贝到该 hosts 文件中。
   e. 参考 2.a 到 2.d 将目标集群的节点 IP 信息添加到源集群节点 hosts 中。
3. 源集群和目标集群之间配置系统互信。

步骤 2：在目标集群配置文件中增加源集群的 ZooKeeper 信息

1. 登录源集群的 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，查看源集群 ZooKeeper 实例 quorumpeer 的业务 IP 地址。

例如图 3-5 显示示例集群获取的 ZooKeeper 实例 IP 地址。

图3-5 源集群 ZooKeeper 实例地址

2. 登录目标端 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，搜索“clickhouse-config-customize”配置项。
3. 在“clickhouse-config-customize”配置项中，参考表 3-10 分别添加源集群的 ZooKeeper 实例信息。

表3-10 “clickhouse-config-customize”配置名称和值参考

名称	值
auxiliary_zookeepers.zookeeper2.node[1].host	1 中获取的源集群第一个 ZooKeeper 实例 quorumpeer 的业务 IP 地址。注意：该参数当前仅支持配置 ZooKeeper 实例的 IP 地址，不支持配置主机名。
auxiliary_zookeepers.zookeeper2.node[1].port	2181
auxiliary_zookeepers.zookeeper2.node[2].host	1 中获取的源集群第二个 ZooKeeper 实例 quorumpeer 的业务 IP 地址。注意：该参数当前仅支持配置 ZooKeeper 实例的 IP 地址，不支持配置主机名。
auxiliary_zookeepers.zookeeper2.node[2].port	2181
auxiliary_zookeepers.zookeeper2.node[3].host	1 中获取的源集群第三个 ZooKeeper 实例 quorumpeer 的业务 IP 地址。注意：该参数当前仅支持配置 ZooKeeper 实例的 IP 地址，不支持配置主机名。
auxiliary_zookeepers.zookeeper2.node[3].port	2181

4. 添加完配置后，单击“保存”，在弹出的对话框中单击“确定”完成配置保存。
5. 保存成功后，以 **root** 用户登录任意一个目的集群的 ClickHouseServer 实例节点。执行以下命令查看 ClickHouseServer 实例信息。

   ps -ef |grep clickhouse

   根据查询的结果，获取“--config-file”参数值，即 ClickHouseServer 的配置文件 config.xml 目录。

图3-6 获取 ClickHouseServer 配置文件目录

6. 执行以下命令查看 ClickHouse 配置文件 config.xml，可以看到<auxiliary_zookeepers>相关信息已添加成功。

   cat *5 中获取的 config.xml 文件路径*

图3-7 查看已添加的源集群的 ZooKeeper 信息

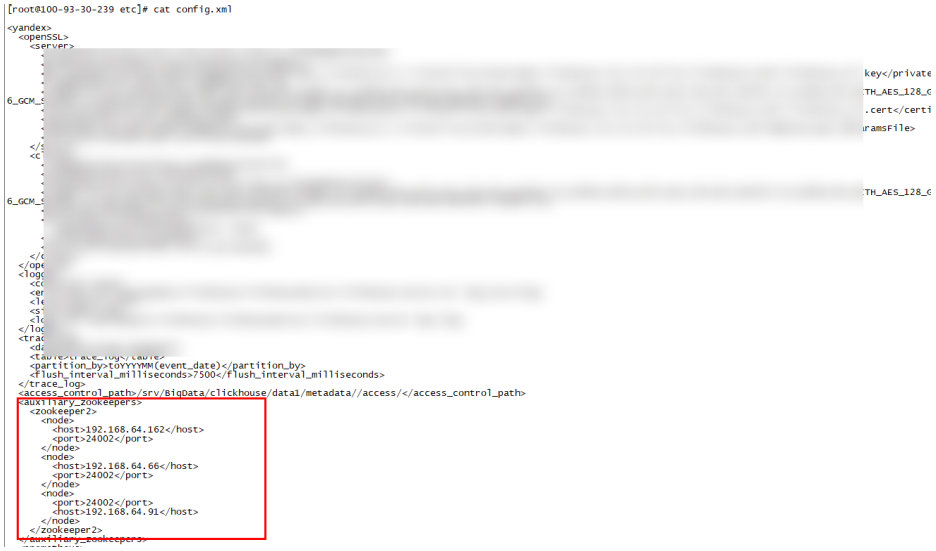

7. 在 5 中获取的配置文件目录下，执行以下命令获取源集群 ZooKeeper 的认证信息。

   cat ENV_VARS | grep ZK

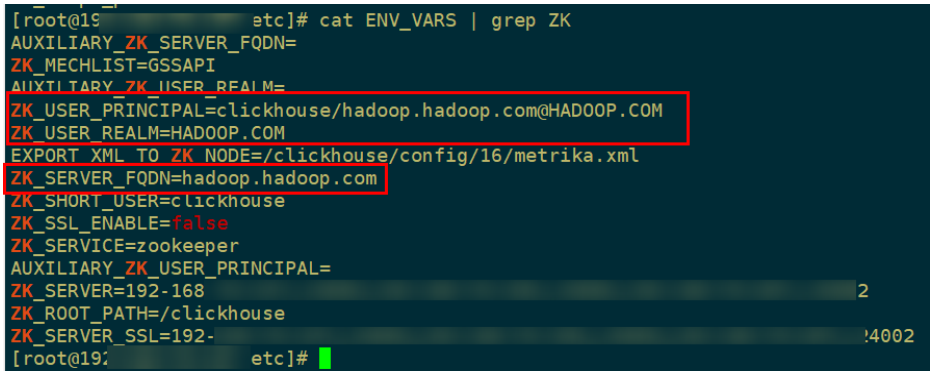

   分别获取：ZK_SERVER_FQDN、ZK_USER_PRINCIPAL、ZK_USER_REALM 三个参数的值。

8. 登录目标端 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，在“ClickHouseServer（角色）”下选择“备份”，参考下表配置具体参数。

表3-11 配置源集群 ZooKeeper 认证信息

参数	值
AUXILIARY_ZK_SERVER_FQDN	在 7 中获取的 ZK_SERVER_FQDN 参数值。
AUXILIARY_ZK_SERVER_PRINCIPAL	在 7 中获取的 ZK_USER_PRINCIPAL 参数值。
AUXILIARY_ZK_SERVER_REALM	在 7 中获取的 ZK_USER_REALM 参数值。
METADATA_COLLECTION_TIMEOUT	配置为 180。 含义为：元数据备份时等待其他节点完成的超时时间，单位为秒。

图3-8 配置源集群 ZooKeeper 认证信息

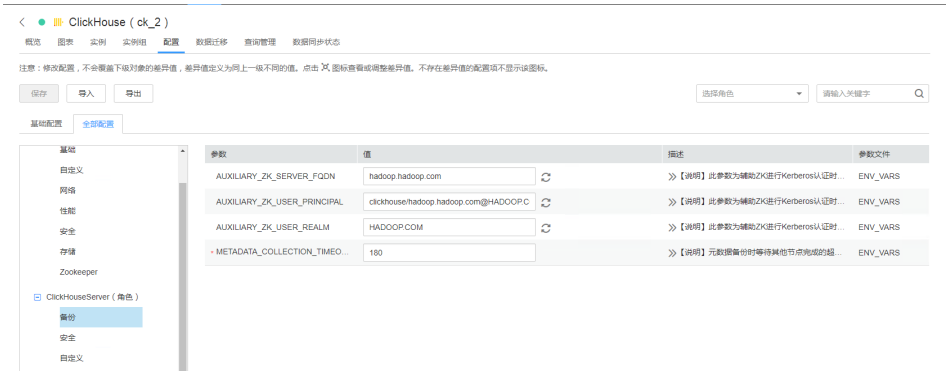

9. 在“ClickHouseServer（角色）”下选择“存储”，修改参数 max_partition_size_to_drop，max_table_size_to_drop 值为 0。

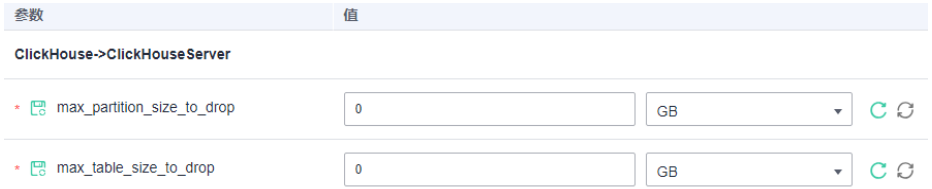

10. 配置修改完成后，单击“保存”，在弹出的对话框中单击“确定”完成配置保存。
11. 在 ClickHouse 服务页面，选择“实例”，勾选 ClickHouseServer 实例，选择“更多 > 重启实例”，重启 ClickHouseServer 实例。

步骤 3：迁移源 ClickHouse 集群下数据库和表的元数据信息到目标集群

1. 分别登录源和目标集群的 FusionInsight Manager，创建迁移需要的用户名和密码，具体步骤如下。

a. 登录 Manager，选择“系统 > 权限 > 角色”，在“角色”界面单击“添加角色”按钮，进入添加角色页面。

b. 在添加角色界面输入“角色名称”，例如 ckrole，在配置资源权限处单击集群名称，进入服务列表页面，单击 ClickHouse 服务，进入 ClickHouse 权限资源页面。

c. 勾选“ClickHouse 管理员权限”，单击“确定”操作结束。

d. 选择“系统 > 权限 > 用户”，单击“添加用户”，进入添加用户页面。

e. “用户类型”选择“人机”，在“密码”和“确认密码”参数设置该用户对应的密码。

说明

- 用户名：添加的用户名不能包含字符“-”，否则会导致认证失败。
- 密码：设置的密码不能携带“$”、“.”、“#”特殊字符，否则会导致认证失败。

f. 在“角色”处单击“添加”，在弹框中选择 1.b 的角色名，单击“确定”添加到角色，单击“确定”完成操作。

g. 创建完用户后，单击右上角的用户名，注销当前用户登录。使用新创建的用户名登录，根据提示修改当前用户密码。

2. 下载和并使用 **omm** 安装 ClickHouse 客户端到目标集群。

3. 使用 **omm** 用户登录到客户端节点，进入到“*客户端安装目录*/ClickHouse/clickhouse_migration_tool/clickhouse-metadata-migration”目录下配置迁移信息，执行以下命令，参考表 3-12 修改“example_config.yaml”配置文件。

cd *客户端安装目录*/**ClickHouse/clickhouse_migration_tool/clickhouse-metadata-migration**

vi example_config.yaml

修改完配置后，请务必将所有#号的注释信息删除，只保留有效的配置信息，否则后续迁移脚本执行可能会报错。

表3-12 **元数据 example_config.yaml 参数说明**

配置项	配置子项	配置说明
source_cluster	host	源集群的任意一个 ClickHouseServer 节点的 IP 地址即可。
	cluster_name	源集群 ClickHouse 的 cluster 名，可以参考 3.1 从零开始使用 ClickHouse 使用客户端登录，执行以下命令获取，如果没有修改过，默认为：default_cluster。 **select cluster,shard_num,replica_num,host_name from system.clusters;**
	https_port	可以登录源集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，搜索“https_port”参数获取。
	zookeeper_root_path	可以登录源集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，搜索“clickhouse.zookeeper.root.path”参数获取。

配置项	配置子项	配置说明
	system	系统参数。当前可不用配置，保持示例配置即可。

	databases	可选配置。
		• 如果指定该参数，则表示迁移源 ClickHouse 集群指定数据库的数据，可指定多个。配置参考如下：
		`databases:`
		`- "database"`
		`- "database_1"`
		表示迁移源集群的 database 和 database_1 数据库。
		• 如果不指定该参数，则表示迁移源 ClickHouse 集群所有数据库的表数据。databases 参数配置保留为空即可，参考如下：
		`databases:`
		表示迁移源 ClickHouse 集群的所有数据库的表信息。

	tables	可选配置。参数格式为：数据库名.表名。表名前的数据库名必须在 databases 参数列表中。
		• 如果指定该参数，则表示迁移源 ClickHouse 集群数据库下的指定表数据，可指定多个。配置参考如下：
		`tables:`
		`- "database.table_1"`
		`- "database_1.table_2"`
		表示迁移源集群的 database 数据库下的 table_1 数据和 database_1 数据库下的 table_2 数据。
		• 如果不指定该参数，如果指定了 databases 参数则表示迁移 databases 数据库下的所有表数据，没有指定 databases 参数则表示迁移源 ClickHouse 集群所有数据库下的所有表数据。参考如下：
		`tables:`

destination_cluster	host	目标集群的任意一个 ClickHouseServer 节点的 IP 地址即可。
	cluster_name	目标集群 ClickHouse 的 cluster 名，可以参考 3.1 从零开始使用 ClickHouse 使用客户端登录，执行以下命令获取，如果没有修改过，默认为：default_cluster。 **select cluster,shard_num,replica_num,host_name from system.clusters;**
	user	1 中创建的目标集群 ClickHouse 登录的用户名。
	https_port	可以登录目标集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，搜索“https_port”参数获取。

配置项	配置子项	配置说明
	zookeeper_root_path	可以登录目标集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，搜索“clickhouse.zookeeper.root.path”参数获取。
	system	系统参数。当前可不用配置，保持示例配置即可。

4. 执行以下命令，开始进行数据迁移，等待脚本执行完成。

   ./clickhouse_migrate_metadata.sh -f yaml_file

   输入源集群、目的集群的用户名和密码

```
please input source cluster user name:
please input source cluster user password:
please input destination cluster user name:
please input destination cluster user password:
```

说明

元数据搬迁失败处理方法：

1. 排查元数据搬迁失败原因，仔细排查配置文件内容，检视是否有参数配置错误。
   - 是，如果有参数配置错误，请重新配置并执行元数据搬迁。
   - 否，如果没有参数配置错误，请执行 2。
2. 参考表 3-12 中的“databases”和“tables”参数，在元数据搬迁配置文件中设置搬迁失败的表名，重新执行元数据搬迁命令。如果迁移失败，请联系运维人员。

步骤 4：迁移源 ClickHouse 集群下数据库和表数据到目标集群

1. 使用 **omm** 用户登录到目标集群 ClickHouse 客户端节点的“*客户端安装目录*/ClickHouse/clickhouse_migration_tool/clickhouse-data-migration”目录下。

   cd *客户端安装目录*/**ClickHouse/clickhouse_migration_tool/clickhouse-data-migration**

2. 执行以下命令，参考表 3-13 修改“example_config.yaml”配置文件。

   vi example_config.yaml

   修改完配置后，请务必将所有#号的注释信息删除，只保留有效的配置信息，否则后续迁移脚本执行可能会报错。

表3-13 example_config.yaml 参数说明

配置项	配置子项	配置说明
source_cluster	host	源集群的任意一个 ClickHouseServer 节点的 IP 地址即可。
	cluster_name	源集群 ClickHouse 的 cluster 名，可以参考 3.1 从零开始使用 ClickHouse 使用客户端登录，执行以下命令获取，如果没有修改过，默认为：default_cluster。 **select cluster,shard_num,replica_num,host_name from**

配置项	配置子项	配置说明
		system.clusters;
	user	1 中创建的源集群 ClickHouse 登录的用户名。
	https_port	可以登录源集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，搜索“https_port”参数获取。
	tcp_port	可以登录源集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，安全集群搜索“tcp_port_secure”参数获取，普通集群搜索“tcp_port”参数获取。
	zookeeper_root_path	可以登录源集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，搜索“clickhouse.zookeeper.root.path”参数获取。
	system	系统参数。当前可不用配置，保持示例配置即可。

	databases	可选配置。
		• 如果指定该参数，则表示迁移源 ClickHouse 集群指定数据库的数据，可指定多个。配置参考如下：
		`databases:`
		`  - "database"`
		`  - "database_1"`
		表示迁移源集群的 database 和 database_1 数据库。
		• 如果不指定该参数，则表示迁移源 ClickHouse 集群所有数据库的表数据。databases 参数配置保留为空即可，参考如下：
		`databases:`
		表示迁移源 ClickHouse 集群的所有数据库的表信息。

	tables	可选配置。参数格式为：数据库名.表名。表名前的数据库名必须在 databases 参数列表中。
		• 如果指定该参数，则表示迁移源 ClickHouse 集群数据库下的指定表数据，可指定多个。配置参考如下：
		`tables:`
		`  - "database.table_1"`
		`  - "database_1.table_2"`
		表示迁移源集群的 database 数据库下的 table_1 数据和 database_1 数据库下的 table_2 数据。
		• 如果不指定该参数，如果指定了 databases 参数则表示迁移 databases 数据库下的所有表数据，没有指定 databases 参数则表示迁移源 ClickHouse 集群所有数据库下的所有表数据。参考如下：

配置项	配置子项	配置说明
		`tables:`
destination_cluster	host	目标集群的任意一个 ClickHouseServer 节点的 IP 地址即可。
	cluster_name	目标集群 ClickHouse 的 cluster 名，可以参考 3.1 从零开始使用 ClickHouse 使用客户端登录，执行以下命令获取，如果没有修改过，默认为：default_cluster。 **select cluster,shard_num,replica_num,host_name from system.clusters;**
	user	1 中创建的目标集群 ClickHouse 登录的用户名。
	https_port	可以登录目标集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，搜索“https_port”参数获取。
	tcp_port	。可以登录目标集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，安全集群搜索“tcp_port_secure”参数获取，普通集群搜索“tcp_port”参数获取。
	zookeeper_root_path	可以登录目标集群的 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，搜索“clickhouse.zookeeper.root.path”参数获取。
	system	系统参数。当前可不用配置，保持示例配置即可。
auxiliary_zookeepers	name	在 3 中配置的源 ClickHouse 的 ZooKeeper 名。例如当前为 zookeeper2。

	hosts	源 ClickHouse 集群的 ZooKeeper 的实例 IP 地址。可以登录源集群的 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，查看源集群 ZooKeeper 实例 quorumpeer 的业务 IP 地址。
		格式参考为：
		`hosts:`
		`  - "192.168.1.2"`
		`  - "192.168.1.3"`
		`  - "192.168.1.4"`

	port	2181
execution_procedure	-	默认为空，表示执行一次脚本，将业务数据同步。参数还支持 firststep 和 secondstep。 • firststep：表示只执行完成临时复制表的创建，通过辅助 Zookeeper 能够将原集群的数据实时同步到临时表。 • secondstep：表示将临时复制表里面的数据 attach 到目的集群的本地表中。

配置项	配置子项	配置说明
		注意 参数值为 secondstep 时，脚本执行前，需要运维人员和用户确认 ClickHouse 相关业务必须已经停止。
onereplica_use_auxiliaryzookeeper	-	• 参数值为 1，表示只为 shard 里面的一个副本创建临时表。 • 参数值为 0，表示为 shard 里面的两个副本创建临时表。

3. 停止当前源集群的 ClickHouse 业务。
4. 执行以下命令，开始进行数据迁移，等待脚本执行完成。

   ./clickhouse_migrate_data.sh -f yaml_file

   输入源集群、目的集群的用户名和密码
5. 脚本执行完成后，根据迁移结果日志确认源集群和目标集群迁移的数据是否一致，具体操作如下：

   登录到目标集群 ClickHouse 客户端节点的“*客户端安装目录*/ClickHouse/clickhouse_migration_tool/clickhouse-data-migration/comparison_result”目录下。

   对比如下迁移后的结果文件信息，确认迁移后源集群和目标集群数据的一致性：

   - source_cluster_table_info：源集群迁出数据的统计
   - destination_cluster_table_info：目标集群迁入的数据统计
   - compare_result_file.txt：迁移前后数据一致性对比结果

   对于迁移前后数据不一致的表，需要清空目的集群中该表的数据，并针对该表重新单独进行数据迁移或人工完成数据迁移。

   另外，也可以分别登录到源和目标集群的 ClickHouse 数据库，手工查询表数据数量，分区个数等是否一致。
6. 登录目标集群的 FusionInsight Manager，将 2 在“clickhouse-config-customize”添加的 ZooKeeper 信息删除。

   完成后单击“保存”，在弹出的对话框中单击“确定”完成配置保存。
7. 数据迁移完成后，将业务指向迁移后的目标 ClickHouse 集群，完成业务切流。
8. 分别进入到目标集群 ClickHouse 节点的“*客户端安装目录*/ClickHouse/clickhouse_migration_tool/clickhouse-data-migration”和“*客户端安装目录*/ClickHouse/clickhouse_migration_tool/clickhouse-metadata-migration”目录下。

   vi example_config.yaml

   将配置文件中 password 参数密码信息清除，防止密码泄露。

说明

业务数据搬迁失败：

1. 排查元数据搬迁失败原因，仔细排查配置文件内容，检视是否有参数配置错误。

- 是，如果有参数配置错误，请重新配置并执行业务数据搬迁。
- 否，如果没有参数配置错误，请执行 2。

2. 执行 **drop table** *table_name* 命令，删除目的集群搬迁失败节点上该表的相关数据表。
3. 执行 **show create table** *table_name* 命令，查询源集群该表相关的创表语句，在目的集群重新创建该表。
4. 参考表 3-13 中的“databases”和“tables”参数，在业务数据搬迁配置文件中设置搬迁失败的表名，重新执行业务数据搬迁命令。如果执行失败请联系运维人员。

3.9.5 ClickHouse 数据批量导入

说明

本章节适用于 MRS 3.3.0 及之后版本。

操作场景

当同时存在较多待导入的数据文件，用户可以使用多线程导入工具批量导入 ClickHouse。

前提条件

- 已安装 ClickHouse 客户端，例如客户端安装目录为“/opt/client”。
- 若集群为安全模式需要创建一个具有 ClickHouse 相关权限的用户，例如创建用户“clickhouseuser”，具体请参考 3.2.1 ClickHouse 用户及权限管理。
- 准备待导入的数据文件，并将数据文件上传到客户端节点目录，例如上传到目录“/opt/data”。ClickHouse 支持的所有数据类型请参考：https://clickhouse.com/docs/en/interfaces/formats

操作步骤

步骤 1 以客户端安装用户，登录客户端所在节点。

步骤 2 进入多线程写入工具“clickhouse_insert_tool”所在目录：

cd /opt/client/ClickHouse/clickhouse_insert_tool

步骤 3 使用文本编辑器打开 clickhouse_insert_tool.sh，按照注释填写所需信息：

参数	参数描述	示例
datapath	待导入数据所在目录。	/opt/data
balancer_ip_list	ClickHouse 服务 Balancer 实例 IP 地址列表,整体使用括号括起，单个 IP 使用双引号引起，IP 之间使用空格分隔。	("192.168.1.1" "192.168.1.2")
balancer_tcp_port	ClickHouse 服务 Balancer 实例 TCP 端口。	21428
local_table_name	待导入的本地库名.本地表名。	testdb1.testtb1
thread_num	并发导入线程数。	10
data_format	待导入数据的格式。	CSV

参数	参数描述	示例
is_security_cluster	是否为安全模式集群。 • true：表示安全模式 • false：表示普通模式	true

步骤 4 保存修改后的 “clickhouse_insert_tool.sh”，并执行如下命：

cd /opt/client

source bigdata_env

安全模式（开启 Kerberos 认证）执行 kinit 命令，普通模式（关闭 Kerberos 认证）无需执行：

kinit *clickhouseuser*

步骤 5 运行脚本，导入数据。

./ClickHouse/clickhouse_insert_tool/clickhouse_insert_tool.sh

步骤 6 登录 ClickHouse 客户端节点，链接服务端，具体请参考 3.1 从零开始使用 ClickHouse。

步骤 7 执行如下命令，查询插入数据的本地表对应的分布式表，查看结果是否符合预期：

select count(1) from testdb1.testtb1_all;

----结束

3.10 通过数据文件备份恢复 ClickHouse 数据

操作场景

本章节主要介绍通过把 ClickHouse 中的表数据导出到 CSV 文件进行备份，后续可以通过备份的 CSV 文件数据再进行恢复操作。

前提条件

- 已安装 ClickHouse 客户端。
- 在 Manager 已创建具有 ClickHouse 相关表权限的用户。
- 已准备好备份服务器。

备份数据

步骤 1 以客户端安装用户，登录安装客户端的节点。

步骤 2 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 3 执行以下命令配置环境变量。

source bigdata_env

步骤 4 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 ClickHouse 表的权限。如果当前集群未启用 Kerberos 认证，则无需执行本步骤。

1. 如果是 MRS 3.1.0 版本集群，则需要先执行：

   export CLICKHOUSE_SECURITY_ENABLED=true

2. **kinit** *组件业务用户*

   例如，**kinit** clickhouseuser。

步骤 5 执行 ClickHouse 组件的客户端命令，将要备份 ClickHouse 表数据导出到指定目录下。

clickhouse client --host *主机名/实例 IP* **--secure --port 9440 --query="***表查询语句***" >** *输出的 csv 格式文件路径*

例如，如下是在 ClickHouse 实例 10.244.225.167 下备份 test 表数据到 default_test.csv 文件中。

clickhouse client --host 10.244.225.167 --secure --port 9440 --query="select * from default.test FORMAT CSV" > /opt/clickhouse/default_test.csv

步骤 6 将导出的 csv 数据文件上传至备份服务器。

----结束

恢复数据

步骤 1 将备份服务器上的备份数据文件上传到 ClickHouse 客户端所在目录。

例如，上传 default_test.csv 备份文件到：/opt/clickhouse 目录下。

步骤 2 以客户端安装用户，登录安装客户端的节点。

步骤 3 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 4 执行以下命令配置环境变量。

source bigdata_env

步骤 5 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 ClickHouse 表的权限。如果当前集群未启用 Kerberos 认证，则无需执行本步骤。

1. 如果是 MRS 3.1.0 版本集群，则需要先执行：

   export CLICKHOUSE_SECURITY_ENABLED=true

2. **kinit** *组件业务用户*

   例如，**kinit** clickhouseuser。

步骤 6 执行 ClickHouse 组件的客户端命令，登录 ClickHouse 集群。

clickhouse client --host *主机名/实例 IP* **--secure --port 9440**

步骤 7 创建与 CSV 备份数据文件格式对应的表。

CREATE TABLE [IF NOT EXISTS] *[database_name.]table_name* **[ON CLUSTER** *Cluster 名***]**

(

name1 **[***type1***] [DEFAULT**|*materialized*|**ALIAS** *expr1***],**

name2 **[***type2***] [DEFAULT**|*materialized*|**ALIAS** *expr2***],**

...

) *ENGINE = engine*

步骤 8 将备份数据文件中的内容导入到步骤 7 创建的表中进行数据恢复。

clickhouse client --host *主机名/实例 IP* **--secure --port 9440 --query="insert into** *表信息* **FORMAT CSV" <** *csv 文件路径*

例如，如下在 ClickHouse 实例 10.244.225.167 中，恢复 default_test.csv 备份文件数据到 test_cpy 表中。

clickhouse client --host 10.244.225.167 --secure --port 9440 --query="insert into default.test_cpy FORMAT CSV" < /opt/clickhouse/default_test.csv

----结束

3.11 配置 ClickHouse 对接 HDFS

本章节适用于 MRS 3.2.0 及之后版本。

操作场景

本章节主要介绍使用 ClickHouse 对接 HDFS 组件进行文件读写。

前提条件

- 已安装 ClickHouse 客户端，例如客户端安装目录为“/opt/client”。
- 在 FusionInsight Manager 已创建具有 ClickHouse 相关表权限和访问 HDFS 的权限的用户，例如：clickhouseuser。
- 在对接 HDFS 组件之前，需要注意首先确保 HDFS 中有对应的目录，ClickHouse 的 HDFS 引擎只会操作文件不会创建或删除目录。
- 当前系统只支持部署在 x86 节点的 ClickHouse 集群对接 HDFS，部署在 ARM 节点的 ClickHouse 集群不支持对接 HDFS。

操作步骤

步骤 1 以客户端安装用户，登录客户端所在节点。

步骤 2 执行以下命令切换到客户端安装目录。

cd /opt/client

步骤 3 执行以下命令配置环境变量。

source bigdata_env

步骤 4 执行以下命令认证当前用户（首次认证需要修改密码，未启用 Kerberos 认证集群跳过此步骤）。

kinit clickhouseuser

步骤 5 执行 ClickHouse 组件的客户端命令登录客户端。

clickhouse client --host *ClickHouseServer 的实例业务 IP* **--secure --port 9440**

步骤 6 执行以下命令对接 HDFS 组件。

CREATE TABLE default.hdfs_engine_table (`name` String, `value` UInt32) ENGINE = HDFS('hdfs://*{namenode_ip}***:***{dfs.namenode.rpc.port}***/tmp/secure_ck.txt', 'TSV')**

说明

- ClickHouseServer 的实例业务 IP 地址获取方式：

  在 FusionInsight Manager 首页，选择“集群 > 服务 > ClickHouse > 实例”，获取 ClickHouseServer 实例对应的业务 IP 地址。

- namenode_ip 的获取方式：

  在 FusionInsight Manager 首页，选择“集群 > 服务 > HDFS > 实例”，获取主 NameNode 业务 IP。

- dfs.namenode.rpc.port 的获取方式：

  在 FusionInsight Manager 首页，选择“集群 > 服务 > HDFS > 配置 > 全部配置”，搜索并获取参数“dfs.namenode.rpc.port”的值。

- 访问的 HDFS 文件路径：

  如果是访问的多个文件，需要指定到文件夹后边加上*号，如：**hdfs://***{namenode_ip}***:***{dfs.namenode.rpc.port}***/tmp/***

----结束

3.12 配置 ClickHouse 对接 Kafka

3.12.1 通过用户密码对接 Kafka

说明

本章节适用于 MRS 3.3.0-LTS 及之后版本。

操作场景

本章节主要介绍 ClickHouse 通过用户名和密码的方式连接 Kafka，消费 Kafka 的数据。

前提条件

- 已创建 Kafka 集群，且为安全模式。
- 已安装集群客户端。
- 如果 ClickHouse 与 Kafka 不在同一个集群需要建立跨集群互信。

操作步骤

步骤 1 登录 Kafka 服务所在 Manager 页面，选择“系统 > 权限 > 用户 > 添加用户”，创建一个具有 Kafka 权限的人机用户，例如创建人机用户 ck_user1，首次使用需要修改初始密码。Kafka 用户权限介绍请参考 16.4 管理 Kafka 用户权限。

步骤 2 选择“集群 > 服务 > Kafka > 配置 > 全部配置”，搜索参数“sasl.enabled.mechanisms”，修改参数值为“GSSAPI,PLAIN”，单击“保存”。

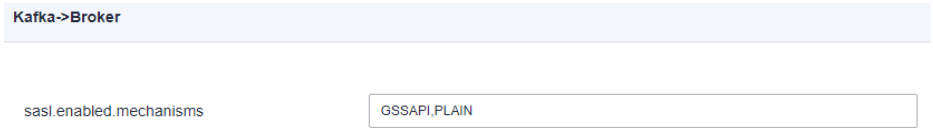

步骤 3 登录 ClickHouse 服务所在 Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置 > ClickHouseServer（角色） > 引擎”，修改如下参数，配置连接 Kafka 的用户名和密码。

参数	参数说明
kafka.sasl_mechanisms	指定连接 Kafka 使用的 SASL 认证机制，参数值为 PLAIN。
kafka.sasl_password	连接 Kafka 用户的密码，新建的用户 ck_user1 需要先修改初始密码，否则会导致认证失败。
kafka.sasl_username	连接 Kafka 的用户名，输入步骤 1 创建的用户名。
kafka_auth_mode	ClickHouse 连接 Kafka 的认证方式，参数值选择 UserPassword。

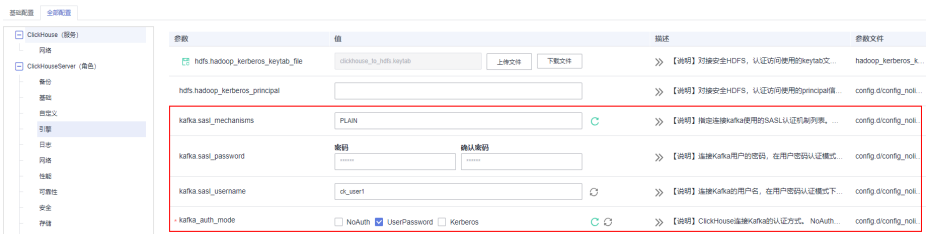

步骤 4 单击“保存”，在弹窗页面中单击“确定”，保存配置。单击“实例”，勾选 ClickHouseServer 实例，选择“更多 > 滚动重启实例”，重启 ClickHouseServer 实例。

步骤 5 参考 16.11 使用 Kafka 客户端，登录到 Kafka 客户端安装目录。

1. 以 Kafka 客户端安装用户，登录 Kafka 安装客户端的节点。
2. 执行以下命令，切换到客户端安装目录。

   cd /opt/client
3. 执行以下命令配置环境变量。

   source bigdata_env

4. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

   kinit *组件业务用户*

步骤 6 执行以下命令，创建 Kafka 的 Topic。详细的命令使用可以参考 16.2 管理 Kafka 主题。

kafka-topics.sh --topic *topic1* **--create --zookeeper** *ZooKeeper 角色实例 IP:ZooKeeper 侦听客户端连接的端口*/**kafka --partitions** *2* **--replication-factor** *1*

说明

- **--topic** 参数值为要创建的 Topic 名称，本示例创建的名称为 topic1 。
- **--zookeeper：**ZooKeeper 角色实例所在节点 IP 地址，填写三个角色实例其中任意一个的 IP 地址即可。ZooKeeper 角色实例所在节点 IP 获取参考如下：

  登录 FusionInsight Manager 页面，选择“集群 > 服务 >ZooKeeper> 实例”，查看 ZooKeeper 角色实例的 IP 地址。
- **--partitions** 主题分区数和**--replication-factor** 主题备份个数不能大于 Kafka 角色实例数量。
- *ZooKeeper 侦听客户端连接的端口*获取方式：登录 FusionInsight Manager，选择“集群 > 服务 >ZooKeeper”，在“配置”页签查看“clientPort”的值，默认为 24002。

步骤 7 登录 ClickHouse 客户端节点，连接 ClickHouse 服务端，具体请参考 3.1 从零开始使用 ClickHouse 章节。

步骤 8 创建 Kafka 的表引擎，示例如下：

```
CREATE TABLE queue1 (
key String,
value String,
event_date DateTime
) ENGINE = Kafka()
SETTINGS kafka_broker_list = 'kafka_ip1:21007,kafka_ip2:21007,kafka_ip3:21007',
kafka_topic_list = 'topic1',
kafka_group_name = 'group1',
kafka_format = 'CSV',
kafka_row_delimiter = '\n',
kafka_handle_error_mode='stream';
```

相关参数说明如下表：

参数	参数说明
kafka_broker_list	Kafka 集群 Broker 实例的 IP 和端口列表。例如：*kafka 集群 broker 实例 IP1*:9092,*kafka 集群 broker 实例 IP2*:9092,*kafka 集群 broker 实例 IP3*:9092。 Kafka 集群 Broker 实例 IP 获取方法如下： 登录 FusionInsight Manager 页面，选择“集群 > 服务 > Kafka”。单击“实例”，查看 Kafka 角色实例的 IP 地址。
kafka_topic_list	消费 Kafka 的 Topic。
kafka_group_name	Kafka 消费组。

<table>
<tr><th>参数</th><th>参数说明</th></tr>
<tr><td>kafka_format</td><td>消费数据的格式化类型，JSONEachRow 表示每行一条数据的 json 格式，CSV 格式表示逗号分隔的一行数据。</td></tr>
<tr><td>kafka_row_delimiter</td><td>每个消息体（记录）之间的分隔符。</td></tr>
<tr><td>kafka_handle_error_mode</td><td>设置为 stream，会把每条消息处理的异常打印出来。需要创建视图，通过视图查询异常数据的具体处理异常。
创建视图语句，示例如下：
<pre><code>CREATE MATERIALIZED VIEW default.kafka_errors2
(
`topic` String,
`key` String,
`partition` Int64,
`offset` Int64,
`timestamp` Date,
`timestamp_ms` Int64,
`raw` String,
`error` String
)
ENGINE = MergeTree
ORDER BY (topic, partition, offset)
SETTINGS index_granularity = 8192 AS
SELECT
_topic AS topic,
_key AS key,
_partition AS partition,
_offset AS offset,
_timestamp AS timestamp,
_timestamp_ms AS timestamp_ms,
_raw_message AS raw,
_error AS error
FROM default.queue1;</code></pre>
查询视图，示例如下：
<pre><code>host1 :) select * from kafka_errors2; SELECT * FROM
kafka_errors2 Query id: bf4d788f-bcb9-44f5-95d0-
a6c83c591ddb
┌─topic──┬─key─┬─partition─┬─offset─┬──timestamp─┬─times
tamp_ms─┬─raw─┬─error──────────────────────────────────
──
─────────────────────────┐ │ topic1 │   │   1 │
8 │ 2023-06-20 │ 1687252213 │ 456 │ Cannot parse date:
value is too short: (at row 1) Buffer has gone, cannot
extract information about what has been parsed. │
└────────┴─────┴───────────┴────────┴────────────┴───────
────────┴─────┴──
──
─────────────────────────┘ 1 rows in set. Elapsed:
0.003 sec. host1 :)</code></pre></td></tr>
<tr><td>kafka_skip_broken_messages</td><td>（可选）表示忽略解析异常的 Kafka 数据的条数。如果出现了 N 条异常后，后台线程结束，Materialized View 会被</td></tr>
</table>

参数	参数说明
	重新安排后台线程去监测数据。
kafka_num_consumers	（可选）单个 Kafka Engine 的消费者数量，通过增加该参数，可以提高消费数据吞吐，但总数不应超过对应 topic 的 partitions 总数。

步骤 9 通过客户端连接 ClickHouse 创建本地表，示例如下：

```
CREATE TABLE daily1(
key String,
value String,
event_date DateTime
)ENGINE = MergeTree()
ORDER BY key;
```

步骤 10 通过客户端连接 ClickHouse 创建物化视图，示例如下：

```
CREATE MATERIALIZED VIEW default.consumer TO default.daily1 (
`event_date` DateTime,
`key` String,
`value` String
) AS
SELECT
event_date,
key,
value
FROM default.queue1;
```

步骤 11 再次执行步骤 5，进入 Kafka 客户端安装目录。

步骤 12 执行以下命令，在 Kafka 的 Topic 中产生消息。例如，如下命令向步骤 6 中创建的 Topic 发送消息。

kafka-console-producer.sh --broker-list *kafka 集群 broker 实例 IP1*:9092,*kafka 集群 broker 实例 IP2*:9092,*kafka 集群 broker 实例 IP3*:9092 **--topic** *topic1*

```
>a1,b1,'2020-08-01 10:00:00'
>a2,b2,'2020-08-02 10:00:00'
>a3,b3,'2020-08-02 10:00:00'
>a4,b4,'2023-09-02 10:00:00'
```

步骤 13 查询消费到的 Kafka 数据，查询上述的物化视图，示例如下：

```
select * from daily1;
```

```
┌key─┬value─┬─────────event_date─┐
│ >a1 │ b1    │ 2020-08-01 10:00:00 │
│ >a2 │ b2    │ 2020-08-02 10:00:00 │
│ >a3 │ b3    │ 2020-08-02 10:00:00 │
│ >a4 │ b4    │ 2023-09-02 10:00:00 │
└─────┴───────┴─────────────────────┘
```

----结束

3.12.2 通过 Kerberos 认证对接 Kafka

说明

本章节适用于 MRS 3.3.0-LTS 及之后版本。

操作场景

本章节介绍 ClickHouse 通过 Kerberos 认证的方式连接 Kafka，消费 Kafka 的数据。

前提条件

- 已创建 Kafka 集群，且为安全模式。
- 已安装集群客户端。
- 如果 ClickHouse 与 Kafka 不在同一个集群需要建立跨集群互信。

操作步骤

步骤 1 登录 Kafka 服务所在集群的 Manager 页面，选择“系统 > 权限 > 用户 > 添加用户”，创建一个具有 Kafka 权限的用户，例如创建机机用户 ck_user1。Kafka 用户权限介绍请参考 16.4 管理 Kafka 用户权限。

步骤 2 选择“系统 > 权限 > 用户”，在用户名中选择 ck_user1，单击操作列的“更多 > 下载认证凭据”下载认证凭据文件，保存后解压得到用户的“user.keytab”文件与“krb5.conf”文件。将“user.keytab”文件重命名为“clickhouse_to_kafka.keytab”。

步骤 3 登录 ClickHouse 服务所在集群的 Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置 > ClickHouseServer（角色） > 引擎”，修改如下参数：

参数	参数说明
kafka.sasl_kerberos_principal	连接 Kafka 的 principal，输入步骤 1 创建的用户名。
kafka.sasl_kerberos_realm	配置为 Kafka 集群的域名。
kafka.sasl_mechanisms	指定连接 Kafka 使用的 SASL 认证机制，参数值为 GSSAPI。
kafka_auth_mode	ClickHouse 连接 Kafka 的认证方式，参数值选择 Kerberos。
sasl_kerberos_keytab	连接 Kafka 的认证文件，上传步骤 2 的“clickhouse_to_kafka.keytab”文件。

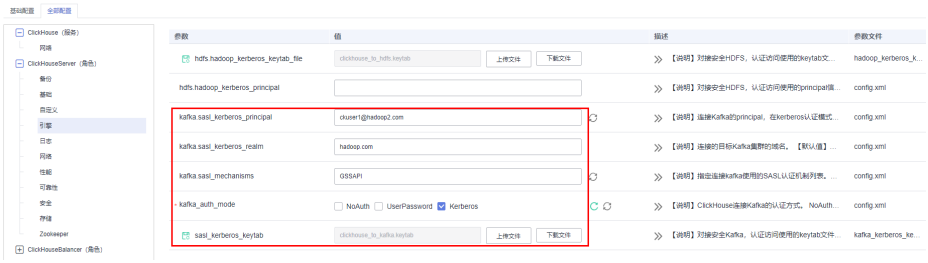

步骤 4 单击“保存”，在弹窗页面中单击“确定”，保存配置。单击“实例”，勾选 ClickHouseServer 实例，选择“更多 > 滚动重启实例”，重启 ClickHouseServer 实例。

步骤 5 参考 16.11 使用 Kafka 客户端，登录到 Kafka 客户端安装目录。

1. 以 Kafka 客户端安装用户，登录 Kafka 安装客户端的节点。
2. 执行以下命令，切换到客户端安装目录。

   cd /opt/client
3. 执行以下命令配置环境变量。

   source bigdata_env
4. 执行以下命令认证当前用户。

   kinit *组件业务用户*

步骤 6 执行以下命令，创建 Kafka 的 Topic。详细的命令使用可以参考 16.2 管理 Kafka 主题。

kafka-topics.sh --topic *topic1* **--create --zookeeper** *ZooKeeper 角色实例 IP:ZooKeeper 侦听客户端连接的端口*/**kafka --partitions** *2* **--replication-factor** *1*

说明

- **--topic** 参数值为要创建的 Topic 名称，本示例创建的名称为 topic1 。
- **--zookeeper：** ZooKeeper 角色实例所在节点 IP 地址，填写三个角色实例其中任意一个的 IP 地址即可。ZooKeeper 角色实例所在节点 IP 获取参考如下：

  登录 FusionInsight Manager 页面，选择“集群 > 服务 >ZooKeeper> 实例”，查看 ZooKeeper 角色实例的 IP 地址。
- **--partitions** 主题分区数和**--replication-factor** 主题备份个数不能大于 Kafka 角色实例数量。
- *ZooKeeper 侦听客户端连接的端口*获取方式：登录 FusionInsight Manager，选择“集群 > 服务 >ZooKeeper”，在“配置”页签查看“clientPort”的值，默认为 24002。

步骤 7 登录 ClickHouse 客户端节点，连接 ClickHouse 服务端，具体请参考 3.1 从零开始使用 ClickHouse 章节。

步骤 8 创建 Kafka 的表引擎，示例如下：

```
CREATE TABLE queue1 (
key String,
value String,
event_date DateTime
) ENGINE = Kafka()
SETTINGS kafka_broker_list = 'kafka_ip1:21007,kafka_ip2:21007,kafka_ip3:21007',
kafka_topic_list = 'topic1',
kafka_group_name = 'group2',
```

```
kafka_format = 'CSV',
kafka_row_delimiter = '\n',
kafka_handle_error_mode='stream';
```

相关参数说明如下表：

参数	参数说明
kafka_broker_list	Kafka 集群 Broker 实例的 IP 和端口列表。例如：*kafka 集群 broker 实例 IP1*:9092,*kafka 集群 broker 实例 IP2*:9092,*kafka 集群 broker 实例 IP3*:9092。 Kafka 集群 Broker 实例 IP 获取方法如下： 登录 FusionInsight Manager 页面，选择“集群 > 服务 > Kafka”。单击“实例”，查看 Kafka 角色实例的 IP 地址。
kafka_topic_list	消费 Kafka 的 Topic。
kafka_group_name	Kafka 消费组。
kafka_format	消费数据的格式化类型，JSONEachRow 表示每行一条数据的 json 格式，CSV 格式表示逗号分隔的一行数据。
kafka_row_delimiter	每个消息体（记录）之间的分隔符。
kafka_handle_error_mode	设置为 stream，会把每条消息处理的异常打印出来。需要创建视图，通过视图查询异常数据的具体处理异常。 创建视图语句，示例如下： `CREATE MATERIALIZED VIEW default.kafka_errors2 ( `topic` String, `key` String, `partition` Int64, `offset` Int64, `timestamp` Date, `timestamp_ms` Int64, `raw` String, `error` String ) ENGINE = MergeTree ORDER BY (topic, partition, offset) SETTINGS index_granularity = 8192 AS SELECT _topic AS topic, key AS key, partition AS partition, offset AS offset, timestamp AS timestamp, timestamp_ms AS timestamp_ms, raw_message AS raw, _error AS error FROM default.queue1;` 查询视图，示例如下：

参数	参数说明
	host1 :) select * from kafka_errors2; SELECT * FROM kafka_errors2 Query id: bf4d788f-bcb9-44f5-95d0-a6c83c591ddb ┌─topic──┬─key─┬─partition─┬─offset─┬──timestamp─┬─timestamp_ms─┬─raw─┬─error──┐ │ topic1 │ │ 1 │ 8 │ 2023-06-20 │ 1687252213 │ 456 │ Cannot parse date: value is too short: (at row 1) Buffer has gone, cannot extract information about what has been parsed. │ └────────┴─────┴───────────┴────────┴────────────┴──────────────┴─────┴──┘ 1 rows in set. Elapsed: 0.003 sec. host1 :)
kafka_skip_broken_messages	（可选）表示忽略解析异常的 Kafka 数据的条数。如果出现了 N 条异常后，后台线程结束，Materialized View 会被重新安排后台线程去监测数据。
kafka_num_consumers	（可选）单个 Kafka Engine 的消费者数量，通过增加该参数，可以提高消费数据吞吐，但总数不应超过对应 topic 的 partitions 总数。

步骤 9 通过客户端连接 ClickHouse 创建本地表，示例如下：

```
CREATE TABLE daily1(
key String,
value String,
event_date DateTime
)ENGINE = MergeTree()
ORDER BY key;
```

步骤 10 通过客户端连接 ClickHouse 创建物化视图，示例如下：

```
CREATE MATERIALIZED VIEW default.consumer1 TO default.daily1 (
`event_date` DateTime,
`key` String,
`value` String
) AS
SELECT
event_date,
key,
value
FROM default.queue1;
```

步骤 11 再次执行步骤 5，进入 Kafka 客户端安装目录。

步骤 12 执行以下命令，在 Kafka 的 Topic 中产生消息。例如，如下命令向步骤 6 中创建的 Topic 发送消息。

kafka-console-producer.sh --broker-list *kafka 集群 broker 实例 IP1*:9092,*kafka 集群 broker 实例 IP2*:9092,*kafka 集群 broker 实例 IP3*:9092 **--topic** *topic1*

```
>a1,b1,'2020-08-01 10:00:00'
>a2,b2,'2020-08-02 10:00:00'
>a3,b3,'2020-08-02 10:00:00'
>a4,b4,'2023-09-02 10:00:00'
```

步骤 13 查询消费到的 Kafka 数据，查询上述的物化视图，示例如下：

```
select * from daily1;
```

----结束

3.12.3 对接普通模式 Kafka

说明

本章节适用于 MRS 3.3.0-LTS 及之后版本。

操作场景

本章节主要介绍 ClickHouse 连接普通模式的 Kafka，消费 Kafka 的数据。

前提条件

- 已创建 Kafka 集群，且为普通模式。
- 已创建 ClickHouse 集群，并且 ClickHouse 集群和 Kafka 集群网络可以互通，并安装 ClickHouse 客户端。

操作步骤

步骤 1 登录 ClickHouse 服务所在集群的 Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置 > ClickHouseServer（角色） > 引擎”，修改如下参数：

参数	参数说明
kafka_auth_mode	ClickHouse 连接 Kafka 的认证方式，参数值选择 NoAuth。

步骤 2 选择“集群 > 服务 > ClickHouse > 配置 > 全部配置 > ClickHouseServer（角色） > 自定义”，在“clickhouse-config-customize”中添加如下参数：

名称	值
kafka.security_protocol	plaintext

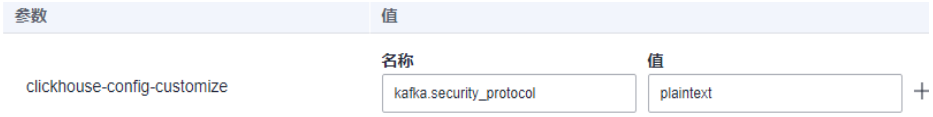

步骤 3 单击“保存”，在弹窗页面中单击“确定”，保存配置。单击“实例”，勾选 ClickHouseServer 实例，选择“更多 > 滚动重启实例”，重启 ClickHouseServer 实例。

步骤 4 参考 16.11 使用 Kafka 客户端，登录到 Kafka 客户端安装目录。

1. 以 Kafka 客户端安装用户，登录 Kafka 安装客户端的节点。
2. 执行以下命令，切换到客户端安装目录。

   cd /opt/client
3. 执行以下命令配置环境变量。

   source bigdata_env
4. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

   kinit *组件业务用户*

步骤 5 执行以下命令，创建 Kafka 的 Topic。详细的命令使用可以参考 16.2 管理 Kafka 主题。

kafka-topics.sh --topic *topic1* **--create --zookeeper** *ZooKeeper 角色实例 IP:ZooKeeper 侦听客户端连接的端口*/**kafka --partitions** *2* **--replication-factor** *1*

说明

- **--topic** 参数值为要创建的 Topic 名称，本示例创建的名称为 topic1 。
- **--zookeeper：** ZooKeeper 角色实例所在节点 IP 地址，填写三个角色实例其中任意一个的 IP 地址即可。ZooKeeper 角色实例所在节点 IP 获取参考如下：

  登录 FusionInsight Manager 页面，选择“集群 > 服务 >ZooKeeper> 实例”，查看 ZooKeeper 角色实例的 IP 地址。
- **--partitions** 主题分区数和**--replication-factor** 主题备份个数不能大于 Kafka 角色实例数量。
- *ZooKeeper 侦听客户端连接的端口*获取方式：登录 FusionInsight Manager，选择“集群 > 服务 >ZooKeeper”，在“配置”页签查看“clientPort”的值，默认为 24002。

步骤 6 登录 ClickHouse 客户端节点，连接 ClickHouse 服务端，具体请参考 3.1 从零开始使用 ClickHouse 章节。

步骤 7 创建 Kafka 的表引擎，示例如下：

```
CREATE TABLE queue1 (
key String,
value String,
event_date DateTime
) ENGINE = Kafka()
SETTINGS kafka_broker_list = 'kafka ip1:21005,kafka ip2:21005,kafka ip3:21005',
kafka_topic_list = 'topic1',
kafka_group_name = 'group2',
kafka_format = 'CSV',
kafka_row_delimiter = '\n',
kafka_handle_error_mode='stream';
```

相关参数说明如下表：

参数	参数说明
kafka_broker_list	Kafka 集群 Broker 实例的 IP 和端口列表。例如：*kafka 集群 broker 实例 IP1*:9092,*kafka 集群 broker 实例 IP2*:9092,*kafka 集群 broker 实例 IP3*:9092。 Kafka 集群 broker 实例 IP 获取方法如下： 登录 FusionInsight Manager 页面，选择“集群 > 服务 > Kafka”。单击“实例”，查看 Kafka 角色实例的 IP 地址。
kafka_topic_list	消费 Kafka 的 Topic。
kafka_group_name	Kafka 消费组。
kafka_format	消费数据的格式化类型，JSONEachRow 表示每行一条数据的 json 格式，CSV 格式表示逗号分隔的一行数据。
kafka_row_delimiter	每个消息体（记录）之间的分隔符。

kafka_handle_error_mode	设置为 stream，会把每条消息处理的异常打印出来。需要创建视图，通过视图查询异常数据的具体处理异常。
	创建视图语句，示例如下：
	`CREATE MATERIALIZED VIEW default.kafka errors2 ( `topic` String, `key` String, `partition` Int64, `offset` Int64, `timestamp` Date, `timestamp_ms` Int64, `raw` String, `error` String ) ENGINE = MergeTree ORDER BY (topic, partition, offset) SETTINGS index_granularity = 8192 AS SELECT _topic AS topic, _key AS key, _partition AS partition, _offset AS offset, _timestamp AS timestamp, _timestamp_ms AS timestamp_ms, _raw_message AS raw, _error AS error FROM default.queue1;`
	查询视图，示例如下：
	`host1 :) select * from kafka_errors2; SELECT * FROM kafka_errors2 Query id: bf4d788f-bcb9-44f5-95d0-a6c83c591ddb ┌─topic──┬─key─┬─partition─┬─offset─┬──timestamp─┬─times`

参数	参数说明
	tamp_ms─┬─raw─┬─error────────────────────────────── ── ─────────────────────────┐ │ topic1 │ │ 1 │ 8 │ 2023-06-20 │ 1687252213 │ 456 │ Cannot parse date: value is too short: (at row 1) Buffer has gone, cannot extract information about what has been parsed. │ └────────┴─────┴───────────┴────────┴────────────┴────── ────────┴─────┴───────────────────────────────── ── ─────────────────────────┘ 1 rows in set. Elapsed: 0.003 sec. host1 :)
kafka_skip_broken_messages	（可选）表示忽略解析异常的 Kafka 数据的条数。如果出现了 N 条异常后，后台线程结束，Materialized View 会被重新安排后台线程去监听数据。
kafka_num_consumers	（可选）单个 Kafka Engine 的消费者数量，通过增加该参数，可以提高消费数据吞吐，但总数不应超过对应 topic 的 partitions 总数。

步骤 8 通过客户端连接 ClickHouse 创建本地表，示例如下：

```
CREATE TABLE daily1(
key String,
value String,
event_date DateTime
)ENGINE = MergeTree()
ORDER BY key;
```

步骤 9 通过客户端连接 ClickHouse 创建物化视图，示例如下：

```
CREATE MATERIALIZED VIEW default.consumer1 TO default.daily1 (
`event_date` DateTime,
`key` String,
`value` String
) AS
SELECT
event_date,
key,
value
FROM default.queue1;
```

步骤 10 再次执行步骤 4，进入 Kafka 客户端安装目录。

步骤 11 执行以下命令，在 Kafka 的 Topic 中产生消息。例如，如下命令向步骤 5 中创建的 Topic 发送消息。

kafka-console-producer.sh --broker-list *kafka 集群 broker 实例 IP1*:**9092**,*kafka 集群 broker 实例 IP2*:**9092**,*kafka 集群 broker 实例 IP3*:**9092** **--topic** *topic1*

```
>a1,b1,'2020-08-01 10:00:00'
>a2,b2,'2020-08-02 10:00:00'
```

```
>a3,b3,'2020-08-02 10:00:00'
>a4,b4,'2023-09-02 10:00:00'
```

步骤 12 查询消费到的 Kafka 数据，查询上述的物化视图，示例如下：

```
select * from daily;
```

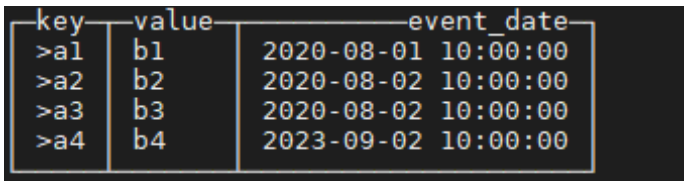

key	value	event_date
>a1	b1	2020-08-01 10:00:00
>a2	b2	2020-08-02 10:00:00
>a3	b3	2020-08-02 10:00:00
>a4	b4	2023-09-02 10:00:00

----结束

3.13 配置 ClickHouse 副本间数据强一致

说明

本章节适用于 MRS 3.3.0-LTS 及之后版本。

操作场景

ClickHouse 支持多副本能力，但进行本地表写入的时候，当前节点的数据会立即更新成功，但其他副本之间的数据同步是异步的。

本章节主要介绍如何配置 ClickHouse 保证副本间数据强一致。

参数配置

说明

配置 ClickHouse 副本间数据强一致优先级别：单条语句设置 > 会话级别设置 > 全局默认设置。

副本间强一致必须要结合原子性一起使用，否则在插入过程中出现异常，无法回退成功。

登录 FusionInsight Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置 > 可靠性”，修改以下参数：

参数	参数说明
profiles.default.insert_quorum	默认值为 0，指的不开启副本间强一致， 取值范围：0-9 或者 auto 或者 all。 • 当设置为数字时候指的是 ClickHouse 在 insert_quorum_timeout 期间将数据正确写入副本的 insert_quorum 时，INSERT 才能成功。 • auto 指的是正确写入副本超过副本数的一半，INSERT 才成功。 • all 指的是正确写入副本等于副本数，INSERT 才成功。
profiles.default.insert_quorum	副本间强一致写入超时时间，默认值为 600000ms，取

参数	参数说明
_timeout	值范围：大于 0。

3.14 配置 ClickHouse 支持事务能力

说明

本章节适用于 MRS 3.3.0-LTS 及之后版本。

操作场景

原子性是指事务是一个不可分割的工作单元，一个事务可以包含多个操作，这些操作要么全部执行，要么全都不执行。但是由于事务在执行过程中，可能出现一些意外，例如用户回滚了事务、连接断开、断电等等，导致事务被中断执行。

ClickHouse 支持原子性写入能力，支持事务能力。实现事务的原子性，在事务的某个操作失败后，支持回滚到事务执行之前的状态。

本章节主要介绍如何开启 ClickHouse 事务。

说明

- 使用本地表场景进行数据写入性能更优，故推荐本地表的数据增、删、改、查场景的多副本分布式事务支持。
- 对于使用分布式表进行数据写入场景的分布式事务，需要结合分布式表事务 insert_distributed_sync+本地表事务（Mergetree/ReplicateMergeTree）完整的事务支持数据写入。

参数配置

登录 FusionInsight Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置 > 可靠性”，修改以下参数：

参数	参数说明
allow_transactions	此参数应用于是否支持事务， 取值范围：0，1。 • 默认值为 0，不支持事务。 • 设置参数值为 1，保存配置，重启服务生效支持事务。
_clickhouse.metrika.cluster.internal_replication	表示是否只将数据写入其中一个副本， 取值范围：true，false。 • 默认值为 true，只插入一个副本就返回。 • 设置值为 false，表示要两个副本都插入。

说明

- 通过执行语句 **set implicit_transaction='true';**，可以使用会话级别的隐式事务。ClickHouse 目前没有 alter queries 中断机制，所以 alter queries（如：lightweight delete）执行过程中被中断之后，即便开启隐式事务能力，也无法回滚，与开源保持一致。
- 分布式表事务性插入使用方法：

  登录 FusionInsight Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，修改参数_clickhouse.metrika.cluster.internal_replication 值为 false，表示 insert 分布式表时，会在分片的所有副本都写入一份。

  会话级别通过 **set insert_distributed_sync='true';**，表示 insert 分布式表时，以同步方式插入数据到各个实际表中。

3.15 ClickHouse 开启 mysql_port 配置

本章节指导用户使用 MySQL 客户端连接 ClickHouse。

说明

本章节仅适用于 MRS 3.1.2 版本。

操作步骤

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > ClickHouse >配置 > 全部配置”。搜索参数项“clickhouse-config-customize”添加名称为“mysql_port”，值为“9004”的参数值。

说明

参数值可以自行设置。

修改完成后，单击“保存”。

步骤 2 单击“概览”页签，选择“ 更多 > 重启实例”或者“ 更多 > 滚动重启实例”。

----结束

3.16 ClickHouse 慢查询语句和复制表数据同步指标监控

3.16.1 慢查询语句监控

操作场景

在 ClickHouse 上执行 SQL 语句查询时，常因为 SQL 语句的分区、where 条件以及索引等设置不合理问题，导致 SQL 查询很慢，影响数据库的整体性能。针对该场景，MRS 提供了 ClickHouse 慢查询语句的监控功能。

正在进行的慢查询

当前还在执行没有返回结果的慢 SQL 语句信息可以通过该界面查询。

- **慢查询菜单路径**

  登录 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 查询管理”，单击“正在进行的慢查询”页签。

- **慢查询参数说明**

表3-14 慢查询参数说明

参数	参数说明
Server 节点 IP	ClickHouseServer 实例的 IP。具体可以到 Manager，选择“集群 > 服务 > ClickHouse > 实例”，ClickHouseServer 角色的 IP。
查询 id	内部生成的唯一 ID。
查询语句	具体慢查询的 SQL 语句。
开始时间	慢查询的 SQL 语句的执行开始时间。
结束时间	慢查询的 SQL 语句的执行结束时间。
查询时长（s）	慢查询的 SQL 语句当前累计执行的时间，单位是秒。
用户	执行慢查询的 SQL 语句的 ClickHouse 用户。
客户端 IP	提交该慢查询 SQL 语句的客户端 IP。
占用的内存空间（MB）	慢查询 SQL 语句占用的内存大小统计，单位是 MB。
操作	当前查询出来的慢 SQL 语句，可以单击“终止”结束该慢 SQL 语句查询。

- **慢查询过滤条件**

  选择对应的过滤条件，输入查询条件值进行过滤查询。

表3-15 慢查询界面过滤条件

条件	参数说明
慢查询运行时长大于	按照慢 SQL 查询语句查询累计时长过滤查询。 支持时长大于：3(s)、9(s)、15(s)、25(s)
按查询 id	根据查询界面对应慢查询语句的“查询 id”字段过滤查询。 支持按照“查询 id”的部分值进行模糊查询，例如，查询 ID 为“111-222-333-444-555”，则输入“111-222”或“-222-333”也能查询到。
按用户查询	对应执行慢 SQL 的 ClickHouse 用户。

条件	参数说明
	支持按照用户名的部分值进行模糊查询。
按客户端 IP 查询	对应慢查询 SQL 语句的客户端 IP。 支持按照客户端 IP 的部分值进行模糊查询，例如，客户端 IP 为“192.168.0.1”，则输入“192.168”或“192.168.0”也能查询到。

已经结束的查询

已经执行完成并且已返回结果的慢 SQL 语句信息可以通过该界面查询。

界面访问路径：登录 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 查询管理”，单击“已经结束的查询”页签。

界面的参数说明参考表 3-14，过滤条件说明参考表 3-15 说明。

3.16.2 复制表数据同步监控

操作场景

Replicated*MergeTree 系列引擎表同分片下的多个副本数据相互进行同步，MRS 针对该场景下的表数据同步进行了状态监控。

约束限制

当前只支持 Replicated*MergeTree 系列引擎表并且建表语句携带 **ON CLUSTER** 关键字的表监控查询。

复制表数据同步

- **数据同步菜单路径**

  登录 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 数据同步状态”。

- **数据同步参数说明**

表3-16 数据状态同步参数说明

参数	参数说明
数据表	Replicated*MergeTree 系列引擎表表名。
所属数据库	数据表所在的数据库。
分片信息	数据表所在的 ClickHouse 分片。
同步状态	分为以下几种状态。 • 无数据：当前分片节点上该表没有数据。

参数	参数说明
	• 已同步：当前分片节点上该表有数据，并且分片下多个副本实例间的数据一致。 • 未同步：当前分片节点上该表有数据，当分片下多个副本实例间的表数据不一致。
详情	数据表在对应 ClickHouseServer 实例上的表数据同步详情。

- **过滤条件**

  选择“按数据表查询”，搜索框输入对应的数据表表名进行过滤查询。

3.17 ClickHouse 常用 SQL 语法

3.17.1 CREATE DATABASE 创建数据库

本章节主要介绍 ClickHouse 创建数据库的 SQL 基本语法和使用说明。

基本语法

CREATE DATABASE [IF NOT EXISTS] *database_name* **[ON CLUSTER** *ClickHouse 集群名***]**

说明

ON CLUSTER *ClickHouse 集群名*的语法，使得该 DDL 语句执行一次即可在集群中所有实例上都执行。集群名信息可以使用以下语句的 **cluster** 字段获取：

select cluster,shard_num,replica_num,host_name from system.clusters;

使用示例

```
--创建数据库名为 test 的数据库
CREATE DATABASE test ON CLUSTER default_cluster;
--创建成功后，通过查询命令验证
show databases;
┌─name───┐
│ default    │
│ system     │
│ test       │
└────────┘
```

3.17.2 CREATE TABLE 创建表

本章节主要介绍 ClickHouse 创建表的 SQL 基本语法和使用说明。

基本语法

- 方法一：在指定的“database_name”数据库中创建一个名为“table_name ”的表。

  如果建表语句中没有包含“database_name”，则默认使用客户端登录时选择的数据库作为数据库名称。

  CREATE TABLE [IF NOT EXISTS] *[database_name.]table_name* **[ON CLUSTER** *ClickHouse 集群名***]**

  (

  name1 **[***type1***] [DEFAULT|MATERIALIZED|ALIAS** *expr1***],**

  name2 **[***type2***] [DEFAULT|MATERIALIZED|ALIAS** *expr2***],**

  ...

) *ENGINE = engine_name()*

  [**PARTITION BY** *expr_list*]

  [**ORDER BY** *expr_list*]

> **⚠ 注意**
>
> ClickHouse 在创建表时建议携带 **PARTITION BY** 创建表分区。因为 ClickHouse 数据迁移工具是基于表的分区作数据迁移，在创建表时如果不携带 **PARTITION BY** 创建表分区，则在 3.9.3 使用 ClickHouse 数据迁移工具界面无法对该表进行数据迁移。

- 方法二：创建一个与 database_name2.table_name2 具有相同结构的表，同时可以对其指定不同的表引擎声明。

  如果没有表引擎声明，则创建的表将与 database_name2.table_name2 使用相同的表引擎。

  CREATE TABLE [IF NOT EXISTS] *[database_name.]table_name* **AS** [*database_name2.*]*table_name2* [ENGINE = *engine_name*]
- 方法三：使用指定的引擎创建一个与 SELECT 子句的结果具有相同结构的表，并使用 SELECT 子句的结果填充它。

  CREATE TABLE [IF NOT EXISTS] *[database_name.]table_name ENGINE = engine_name* **AS SELECT** ...

使用示例

```
--在 default 数据库和 default_cluster 集群下创建名为 test 表
CREATE TABLE default.test ON CLUSTER default_cluster
(
    `EventDate` DateTime,
    `id` UInt64
)
ENGINE = ReplicatedMergeTree('/clickhouse/tables/{shard}/default/test', '{replica}')
PARTITION BY toYYYYMM(EventDate)
ORDER BY id
```

3.17.3 INSERT INTO 插入表数据

本章节主要介绍 ClickHouse 插入表数据的 SQL 基本语法和使用说明。

基本语法

- 方法一：标准格式插入数据。

  INSERT INTO *[database_name.]table* [(*c1, c2, c3*)] **VALUES** (*v11, v12, v13*), (*v21, v22, v23*), ...

- 方法二：使用 SELECT 的结果写入。

  INSERT INTO *[database_name.]table* [(c1, c2, c3)] **SELECT** ...

使用示例

```
--给 test2 表插入数据
insert into test2 (id, name) values (1, 'abc'), (2, 'bbbb');
--查询 test2 表数据
select * from test2;
┌─id─┬─name─┐
│  1 │ abc  │
│  2 │ bbbb │
└────┴──────┘
```

3.17.4 Delete 轻量化删除表数据

本章节主要介绍轻量化 delete 删除表数据的 SQL 基本语法和使用说明。

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

基本语法

DELETE FROM *[db.]table [ON CLUSTER cluster]* **WHERE** *expr*

使用示例

- 建表：

```
CREATE TABLE default.test_ligtwight_delete
(
`id`    Int32,
`pdate` Date,
`name`  String,
`class` Int32
)
ENGINE =
ReplicatedMergeTree('/clickhouse/tables/distributed_tests/{shard}/test_ligtwigh
t_delete', '{replica}')
PARTITION BY toYYYYMM(pdate)
PRIMARY KEY id
ORDER BY id
SETTINGS index_granularity = 8192,
vertical_merge_algorithm_min_rows_to_activate = 1,
vertical_merge_algorithm_min_columns_to_activate = 1, min_rows_for_wide_part =
1, min_bytes_for_wide_part = 1;
```

- 插入数据：

```
insert into default.test_ligtwight_delete select rand(), rand() % 365, rand(),
rand() from numbers(10);
```

- 删除数据：

```
delete from default.test_ligtwight_delete where id > 0;
```

注意事项

- 已删除的行会立即标记为已删除，并将自动从所有后续查询中过滤掉。数据清理在后台异步发生。此功能仅适用于 MergeTree 表引擎系列；
- 当前能力只支持本地表和复制表的轻量化删除功能，分布式表暂不支持。
- 数据删除功能的执行性能还依赖 merge 和 mutation（alter table update/delete）任务的多少。queue 队列中的 mutation 任务优先级最低（同一个表上的 mutation 任务是串行执行的），能并行执行多少个 delete 任务直接受 merge 任务执行情况的影响。
- 表中 part 个数也决定了轻量化删除的性能，part 越多，删除越慢。
- Wide part 格式文件删除会更快，Compact 格式文件删除性能会更慢一些，因为所有列数据都存储在一个文件中。

3.17.5 SELECT 查询表数据

本章节主要介绍 ClickHouse 查询表数据的 SQL 基本语法和使用说明。

基本语法

SELECT [**DISTINCT**] expr_list

[**FROM** [*database_name*.]*table* | (subquery) | table_function] [**FINAL**]

[SAMPLE sample_coeff]

[ARRAY **JOIN** ...]

[**GLOBAL**] [**ANY**|**ALL**|**ASOF**] [**INNER**|**LEFT**|**RIGHT**|**FULL**|**CROSS**]
[**OUTER**|SEMI|ANTI] **JOIN** (subquery)|**table** (**ON** <expr_list>)|(**USING** <column_list>)

[PREWHERE expr]

[**WHERE** expr]

[**GROUP BY** expr_list] [**WITH** TOTALS]

[**HAVING** expr]

[**ORDER BY** expr_list] [**WITH** FILL] [**FROM** expr] [**TO** expr] [STEP expr]

[**LIMIT** [offset_value,]n **BY** columns]

[**LIMIT** [n,]m] [**WITH** TIES]

[**UNION ALL** ...]

[**INTO** OUTFILE filename]

[FORMAT format]

使用示例

```
--查看 ClickHouse 集群信息
select * from system.clusters;
--显示当前节点设置的宏
select * from system.macros;
--查看数据库容量
select
sum(rows) as "总行数",
formatReadableSize(sum(data_uncompressed_bytes)) as "原始大小",
formatReadableSize(sum(data_compressed_bytes)) as "压缩大小",
round(sum(data_compressed_bytes) / sum(data_uncompressed_bytes) * 100,
0) "压缩率"
from system.parts;
--查询 test 表容量。where 条件根据实际情况添加修改
select
sum(rows) as "总行数",
formatReadableSize(sum(data_uncompressed_bytes)) as "原始大小",
formatReadableSize(sum(data_compressed_bytes)) as "压缩大小",
round(sum(data_compressed_bytes) / sum(data_uncompressed_bytes) * 100,
0) "压缩率"
from system.parts
where table in ('test')
and partition like '2020-11-%'
group by table;
```

3.17.6 ALTER TABLE 修改表结构

本章节主要介绍 ClickHouse 修改表结构的 SQL 基本语法和使用说明。

基本语法

ALTER TABLE [*database_name*].*name* [**ON CLUSTER** *cluster*]
ADD|**DROP**|**CLEAR**|**COMMENT**|**MODIFY COLUMN** ...

说明

ALTER 仅支持 *MergeTree ， Merge 以及 Distributed 等引擎表。

使用示例

```
--给表 t1 增加列 test01
ALTER TABLE t1 ADD COLUMN test01 String DEFAULT 'defaultvalue';
--查询修改后的表 t1
desc t1
┌─name────┬─type─┬─default_type─┬─default_expression
┬─comment─┬─codec_expression─┬─ttl_expression─┐
│ id      │ UInt8  │              │                  │         │                │
│
│ name    │ String │              │                  │         │                │
│
│ address    │ String │              │                  │         │
│              │
│ test01     │ String │ DEFAULT      │ 'defaultvalue'    │         │
│              │
└─────────┴──────┴──────────┴──────────── ┴──── ┴──────────┴──────────┘
```

```
--修改表 t1 列 name 类型为 UInt8
ALTER TABLE t1 MODIFY COLUMN name UInt8;
--查询修改后的表 t1
desc t1
┌─name────┬─type─┬─default_type─┬─default_expression
┬─comment─┬─codec_expression─┬─ttl_expression─┐
│ id      │ UInt8 │              │                  │         │                  │
│ name    │ UInt8 │              │                  │         │                  │
│ address │ String │              │                  │         │
│ test01  │ String │ DEFAULT      │ 'defaultvalue'   │         │
└─────────┴──────┴──────────┴──────────── ┴─────  ┴──────────┴──────────┘
--删除表 t1 的列 test01
ALTER TABLE t1 DROP COLUMN test01;
--查询修改后的表 t1
desc t1
┌─name────┬─type─┬─default_type─┬─default_expression
┬─comment─┬─codec_expression─┬─ttl_expression─┐
│ id      │ UInt8 │              │                  │         │                  │
│ name    │ UInt8 │              │                  │         │                  │
│ address │ String │              │                  │         │
└─────────┴──────┴──────────┴──────────── ┴─────  ┴──────────┴──────────┘
```

3.17.7 ALTER TABLE 修改表数据

- 建议慎用 delete、update 的 mutation 操作

  标准 SQL 的更新、删除操作是同步的，即客户端要等服务端反回执行结果（通常是 int 值）；而 ClickHouse 的 update、delete 是通过异步方式实现的，当执行 update 语句时，服务端立即返回执行成功还是失败结果，但是实际上此时数据还没有修改完成，而是在后台排队等着进行真正的修改，可能会出现操作覆盖的情况，也无法保证操作的原子性。

  业务场景要求有 update、delete 等操作，建议使用 ReplacingMergeTree、CollapsingMergeTree、VersionedCollapsingMergeTree 引擎，使用方式参见：https://clickhouse.tech/docs/zh/engines/table-engines/mergetree-family/collapsingmergetree/。

- 建议少或不增删数据列

  业务提前规划列个数，如果将来有更多列要使用，可以规划预留多列，避免在生产系统跑业务过程中进行大量的 alter table modify 列操作，导致不可以预知的性能、数据一致性问题。

3.17.8 DESC 查询表结构

本章节主要介绍 ClickHouse 查询表结构的 SQL 基本语法和使用说明。

基本语法

DESC|DESCRIBE TABLE [*database_name*.]*table* [**INTO** OUTFILE filename] [FORMAT format]

使用示例

```
--查询表 t1 的表结构
desc t1;
┌─name────┬─type──┬─default_type─┬─default_expression
┬─comment─┬─codec_expression─┬─ttl_expression─┐
│ id        │ UInt8  │             │                │         │                │
│
│ name      │ UInt8  │             │                │         │                │
│
│ address   │ String │             │                │         │
│           │
└─────────┴───────┴──────────  ┴─────  ┴──────────┴──────────┘
```

3.17.9 DROP 删除表

本章节主要介绍 ClickHouse 删除表的 SQL 基本语法和使用说明。

基本语法

DROP [**TEMPORARY**] **TABLE** [**IF EXISTS**] [*database_name*.]*name* [**ON CLUSTER** *cluster*] [SYNC]

使用示例

```
--删除表 t1
drop table t1 SYNC;
```

说明

在删除复制表时，因为复制表需要在 Zookeeper 上建立一个路径，存放相关数据。ClickHouse 默认的库引擎是原子数据库引擎，删除 Atomic 数据库中的表后，它不会立即删除，而是会在 480 秒后删除。在删除表时，加上 SYNC 字段，即可解决该问题，例如：**drop table** *t1* **SYNC;**

删除本地表和分布式表，则不会出现该问题，可不带 SYNC 字段，例如：**drop table** *t1***;**

3.17.10 SHOW 显示数据库和表信息

本章节主要介绍 ClickHouse 显示数据库和表信息的 SQL 基本语法和使用说明。

基本语法

show databases

show tables

使用示例

```
--查询数据库
show databases;
┌─name───┐
```

```
| default     |
| system      |
| test        |
└─────────┘
--查询表信息
show tables;
┌─name─┐
| t1      |
| test    |
| test2   |
| test5   |
└──────┘
```

3.17.11 Upsert 数据写入

本章节主要介绍 ClickHouse 数据写入时数据去重写入功能的 SQL 基本语法和使用说明。

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

基本语法

- 方法一：使用 INSERT VALUES 方式进行数据写入。

  UPSERT INTO *[database_name.]table* [(*c1, c2, c3*)] **VALUES** (*v11, v12, v13*), (*v21, v22, v23*), ...

- 方法二：使用 INSERT SELECT 方式进行数据写入。

  UPSERT INTO *[database_name.]table* [(c1, c2, c3)] **SELECT** ...

使用示例

- 建表样例：

```
CREATE TABLE default.upsert_tab ON CLUSTER default_cluster
(
`id`    Int32,
`pdate`  Date,
`name`   String
)ENGINE = ReplicatedMergeTree('/clickhouse/tables/default/{shard}/upsert_tab',
'{replica}')
PARTITION BY toYYYYMM(pdate)
PRIMARY KEY id
ORDER BY id
SETTINGS index_granularity = 8192;
```

- Upsert 数据去重写入：

```
Upsert into upsert_tab(id, pdate, name) values (1, rand() % 365, 'abc'), (2,
rand() % 365, 'bcd'), (1, rand() % 365, 'def');
```

- 查询 test_upsert 表数据

```
select * from upsert_tab;
┌─id─┬──pdate─┬─name─┐
| 2   |   1970-06-09| bcd   |
```

```
| 1    |    1970-11-30|  def    |
└────┴────  ────┴────┘
```

- Upsert 支持事务

  与其他 SQL 语法类型一样，upsert 语法也支持显式和隐式事务，使用事务前需要进行相应的事务功能开启配置。

注意事项

- MergeTree 和 ReplicatedMergeTree 建表要指定 primary key 或 order by 字段作为去重唯一键。如果未指定主键，只指定了 order by 建表属性，去重键以 order by 字段为准。
- 数据去重的 key 需要提前在应用中进行 sharding 计算，保证相同的 key 会 sharding 到同一个 shard，才能保证后续相同的 key 字段数据 sharding 到同一个 shard 进行数据的精确去重。

3.18 ClickHouse 日志介绍

日志描述（MRS 3.2.0 及之后版本）

日志路径：ClickHouse 相关日志的默认存储路径为“${BIGDATA_LOG_HOME}/clickhouse”。

- ClickHouse 运行相关日志：“/var/log/Bigdata/clickhouse/clickhouseServer/ *.log”
- Balancer 运行日志：“/var/log/Bigdata/clickhouse/balance/*.log”
- 数据迁移日志：“/var/log/Bigdata/clickhouse/migration/${task_name}/clickhouse-copier_{timestamp}_{processId}/copier.log”
- ClickHouse 审计日志：“/var/log/Bigdata/audit/clickhouse/clickhouse-server-audit.log”

日志归档规则：

- ClickHouse 日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 100MB 的时，会自动压缩。
- 压缩后的日志文件名规则为：“<原有日志名>.[编号].gz”。
- 默认最多保留最近的 10 个压缩文件，压缩文件保留个数可以在 Manager 界面中配置。

表3-17 ClickHouse 日志列表

日志类型	日志文件名	描述
ClickHouse 相关日志	/var/log/Bigdata/clickhouse/clickhouseServer/clickhouse-server.err.log	ClickHouseServer 服务运行错误日志文件路径。
	/var/log/Bigdata/clickhouse/clickhouseServer/checkService.log	ClickHouseServer 服务运行关键日志文件路径。
	/var/log/Bigdata/clickhouse/clickhouseServer/clickhouse-	

日志类型	日志文件名	描述
	server.log	
	/var/log/Bigdata/clickhouse/clickhouseServer/ugsync.log	用户角色同步工具打印日志。
	/var/log/Bigdata/clickhouse/clickhouseServer/prestart.log	ClickHouse 预启动日志。
	/var/log/Bigdata/clickhouse/clickhouseServer/start.log	ClickHouse 启动日志。
	/var/log/Bigdata/clickhouse/clickhouseServer/checkServiceHealthCheck.log	ClickHouse 健康检查日志。
	/var/log/Bigdata/clickhouse/clickhouseServer/checkugsync.log	用户角色同步检查日志。
	/var/log/Bigdata/clickhouse/clickhouseServer/checkDisk.log	ClickHouse 磁盘检测日志文件路径
	/var/log/Bigdata/clickhouse/clickhouseServer/backup.log	ClickHouse 在 Manager 上执行备份恢复操作的日志文件路径。
	/var/log/Bigdata/clickhouse/clickhouseServer/stop.log	ClickHouse 停止日志
	/var/log/Bigdata/clickhouse/clickhouseServer/postinstall.log	ClickHouse 的 postinstall.sh 脚本调用日志
	/var/log/Bigdata/clickhouse/balance/start.log	ClickHouseBalancer 服务启动日志文件路径。
	/var/log/Bigdata/clickhouse/balance/error.log	ClickHouseBalancer 服务运行错误日志文件路径。
	/var/log/Bigdata/clickhouse/balance/access_http.log	ClickHouseBalancer 服务运行 http 日志文件路径。
	/var/log/Bigdata/clickhouse/balance/access_tcp.log	ClickHouseBalancer 服务运行 tcp 日志文件路径。
	/var/log/Bigdata/clickhouse/balance/checkService.log	ClickHouseBalancer 服务检查日志
	/var/log/Bigdata/clickhouse/balance/postinstall.log	ClickHouseBalacer 的 postinstall.sh 脚本调用日志
	/var/log/Bigdata/clickhouse/balance/prestart.log	ClickHouseBalancer 服务预启动日志文件路径
	/var/log/Bigdata/clickhouse/balance/stop.log	ClickHouseBalancer 服务关闭日志文件路径
	/var/log/coredump/clickhouse-*.core.gz	ClickHouse 进程异常崩溃后生成的内存转储文件压缩包。 该日志仅适用于 MRS 3.3.0 及之后版本

日志类型	日志文件名	描述
数据迁移日志	/var/log/Bigdata/clickhouse/migration/*数据迁移任务名*/clickhouse-copier_*{timestamp}*_*{processId}*/copier.log	参考 3.9.3 使用 ClickHouse 数据迁移工具使用迁移工具时产生的运行日志。
	/var/log/Bigdata/clickhouse/migration/*数据迁移任务名*/clickhouse-copier_*{timestamp}*_*{processId}*/copier.err.log	参考 3.9.3 使用 ClickHouse 数据迁移工具使用迁移工具时产生的错误日志。
clickhouse-tomcat 日志	/var/log/Bigdata/tomcat/clickhouse/web_clickhouse.log	ClickHouse 自定义 UI 运行日志。
	/var/log/Bigdata/tomcat/audit/clickhouse/clickhouse_web_audit.log	clickhouse 的数据迁移审计日志。
clickhouse 审计日志	/var/log/Bigdata/audit/clickhouse/clickhouse-server-audit.log	ClickHouse 的审计日志文件路径。

日志描述（MRS 3.2.0 之前版本）

日志路径：ClickHouse 相关日志的默认存储路径为“${BIGDATA_LOG_HOME}/clickhouse”。

日志归档规则：ClickHouse 日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 100MB 的时候，会自动压缩，压缩后的日志文件名规则为：“<原有日志名>.[编号].gz”。默认最多保留最近的 10 个压缩文件，压缩文件保留个数可以在 Manager 界面中配置。

表3-18 ClickHouse 日志列表

日志类型	日志文件名	描述
运行日志	/var/log/Bigdata/clickhouse/clickhouseServer/clickhouse-server.err.log	ClickHouseServer 服务运行错误日志文件路径。
	/var/log/Bigdata/clickhouse/clickhouseServer/checkService.log	ClickHouseServer 服务运行关键日志文件路径。
	/var/log/Bigdata/clickhouse/clickhouseServer/clickhouse-server.log	
	/var/log/Bigdata/clickhouse/balance/start.log	ClickHouseBalancer 服务启动日志文件路径。
	/var/log/Bigdata/clickhouse/balance/error.log	ClickHouseBalancer 服务运行错误日志文件路径。
	/var/log/Bigdata/clickhouse/balance/access_http.log	ClickHouseBalancer 服务运行日志文件路径。
数据迁移日	/var/log/Bigdata/clickhouse/migration/数据迁移任务名	参考 3.9.3 使用 ClickHouse 数

日志类型	日志文件名	描述
志	/clickhouse-copier_{timestamp}_{processId}/copier.log	据迁移工具使用迁移工具时产生的运行日志。
	/var/log/Bigdata/clickhouse/migration/数据迁移任务名/clickhouse-copier_{timestamp}_{processId}/copier.err.log	参考 3.9.3 使用 ClickHouse 数据迁移工具使用迁移工具时产生的错误日志。

日志级别

ClickHouse 提供了如表 3-19 所示的日志级别。

运行日志的级别优先级从高到低分别是 error、warning、trace、information、debug，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表3-19 日志级别

级别	描述
error	error 表示系统运行的错误信息。
warning	warning 表示当前事件处理存在异常信息。
trace	trace 表示当前事件处理跟踪信息。
information	information 表示记录系统及各事件正常运行状态信息。
debug	debug 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

步骤 1 登录 FusionInsight Manager 系统。

步骤 2 选择“集群 > 服务 > ClickHouse > 配置”。

步骤 3 单击“全部配置”。

步骤 4 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 5 选择所需修改的日志级别。

步骤 6 单击“保存”，然后单击“确定”，成功后配置生效。

----结束

说明

配置完成后即生效，不需要重启服务。

日志格式

ClickHouse 的日志格式如下所示：

表3-20 日志格式

日志类型	格式	示例
ClickHouse 运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2021.02.23 15:26:30.691301 [6085] {} <Error> DynamicQueryHandler: Code: 516, e.displayText() = DB::Exception: default: Authentication failed: password is incorrect or there is no user with such name, Stack trace (when copying this message, always include the lines below): 0. Poco::Exception::Exception(std::__1::basic_string<char, std::__1::char_traits<char>, std::__1::allocator<char> > const&, int) @ 0x1250e59c
clickhouse-tomcat 运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2022-08-16 12:55:12,109 | INFO | pool-7-thread-1 | zookeeper is secure. | com.xxx.bigdata.om.extui.clickhouse.service.impl.QueryServiceImpl.initAuthContext(QueryServiceImpl.java:136)
数据迁移日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2022.08.07 14:41:01.814235 [28651] {} <Debug> ClusterCopier: Task /clickhouse/copier_tasks/TEST0807_02/tables/dblv85.startsea_zh_imoriginck_new/20201031/piece_4/shards/1 has been successfully executed by 8%2D5%2D226%2D156#20220807124849_28651
审计日志	<yyyy-MM-dd HH:mm:ss,SSS>|query id|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2022.08.16 20:58:16.723643 [11382] {cc9554b6-8a26-42e9-8ab8-d848500544e6} <Information> executeQuery_audit [executeQuery.cpp:202] : (0 from 192.168.64.81:45204, user: clickhouse, using experimental parser) select shard_num, host_name, host_address from system.clusters format JSON

3.19 ClickHouse 性能调优

3.19.1 数据表报错 Too many parts 解决方法

问题排查步骤

1. 登录 ClickHouse 客户端，需要排查是否存在异常的 Merge。

   select database, table, elapsed, progress, merge_type from system.merges;
2. 业务上建议 insert 频率不要太快，不要小批量数据的插入，适当增大每次插入的时间间隔。
3. 数据表分区分配不合理，导致产生太多的区分，需要重新划分分区。
4. 如果没有触发 Merge，或者 Merge 较慢，需要调整参数加快 Merge。

   加速 Merge，需要调整如下参数，请参考 3.19.2 加速 Merge 操作：

配置项	参考值
max_threads	CPU 核数*2
background_pool_size	CPU 核数
merge_max_block_size	8192 的整数倍，根据 CPU 内存资源大小调整
cleanup_delay_period	适当小于默认值 30

修改 parts_to_throw_insert 值

⚠ 注意

增大 Too many parts 的触发阈值，除非特殊场景，不建议修改此配置。此配置在一定程度起到潜在问题预警的作用，如果集群硬件资源不足，此配置调整不合理，会导致服务潜在问题不能及时被发现，可能进一步引起其他故障，恢复难度增加。

登录 FusionInsight Manager 界面，选择“集群 > ClickHouse > 配置 > 全部配置 > ClickHouseServer > 自定义 > clickhouse-config-customize”，添加如下参数，保存配置，重启服务。

名称	值
merge_tree.parts_to_throw_insert	clickhouse 实例内存 / 32GB * 300 （保守估计值）

验证修改结果：

登录 ClickHouse 客户端，执行命令 **select * from system.merge_tree_settings where name = 'parts_to_throw_insert';**

3.19.2 加速 Merge 操作

加速后台任务，需要优先调整 Zookeeper 服务配置，否则 Zookeeper 会因为 znode 等资源不足，导致 ClickHouse 服务异常，后台任务异常。

1. 调整 Zookeeper 配置：登录 FusionInsight Manager 界面，选择“集群 > Zookeeper > 配置 > 全部配置 > quorumpeer > 系统”，修改参数“GC_OPTS”的值，保存配置，滚动重启 Zookeeper 服务，如下表所示

配置项	参考值	描述
GC_OPTS	Xmx 最大内存数参考值：(Master 节点内存 - 16GB) * 0.65 （保守估计值）	JVM 用于 gc 的参数。仅当 GC_PROFILE 设置为 custom 时该配置才会生效。需确保 GC_OPT 参数设置正确，否则进程启动会失败。 **注意** 请谨慎修改该项。如果配置不当，将造成服务不可用。

2. 调整 ClickHouse 配置：在 FusionInsight Manager 界面，选择“集群 > ClickHouse > 配置 > 全部配置 > ClickHouse > Zookeeper ”，修改如下参数，保存配置，无需重启服务。

配置项	参考值	描述
clickhouse.zookeeper.quota.node.conut	Xmx 最大内存数 /4GB * 1500000	ClickHouse 在 ZooKeeper 上的顶层目录的节点数量配额。 数量配额的单位是个，最小值是-1（无限制），不能等于 0。 **注意** 设置的数量配额值，如果小于当前 ZooKeeper 目录的实际值，保存配置可成功，但是配置值不会生效，并且界面会上报告警。
clickhouse.zookeeper.quota.size	Xmx 最大内存数 /4GB * 1G	ClickHouse 在 ZooKeeper 上的顶层目录的容量配额。 **注意** 设置的数量配额值，如果小于当前 ZooKeeper 目录的实际值，保存配置可成功，但是配置值不会生效，并且界面会上报告警。

3.19.3 加速 TTL 操作

ClickHouse 触发 TTL 的时候，对 CPU 和内存会存在较大消耗和占用。

登录 FusionInsight Manager 界面，选择“集群 > ClickHouse > 配置 > 全部配置 > ClickHouseServer > 自定义 > clickhouse-config-customize”，添加如下配置，保存配置，重启服务。

配置项	参考值	作用
merge_tree.max_replicated_merges_with_ttl_in_queue	CPU 核数一半	在 ReplicatedMergeTree 队列中允许同时使用 TTL 合并部件的任务数。
merge_tree.max_number_of_merges_with_ttl_in_pool	CPU 核数	在 ReplicatedMergeTree 队列中允许 TTL 合并部件的线程池。

说明

当集群写入压力较大，不建议修改此配置。需要给常规 Merge 留出空闲线程，避免“Too manyparts parts”。

3.20 ClickHouse 常见问题

3.20.1 在 System.disks 表中查询到磁盘 status 是 fault 或者 abnormal

问题

在 System.disks 表中查询到磁盘 status 是 fault 或者 abnormal。

回答

这种情况是由于磁盘存在 IO 错误，处理方法如下：

- 方法一：登录 FusionInsight Manager 页面，检查 Manager 界面上是否磁盘 IO 异常的告警，如果有，可参考对应的告警帮助文档，通过更换硬盘恢复。
- 方法二：登录 FusionInsight Manager 页面，重启 ClickHouse 实例，恢复磁盘状态。

说明

此时磁盘未更换，有 IO 错误发生时，磁盘状态还会被置为 fault 或者 abnormal。

3.20.2 如何迁移 Hive/HDFS 的数据到 ClickHouse

问题

如何迁移 Hive/HDFS 的数据到 ClickHouse。

回答

可以将 Hive 中的数据导出为 CSV 文件，再将 CSV 文件导入到 ClickHouse。

1. 从 Hive 中导出数据为 CSV：

   hive -e "select * from db_hive.student limit 1000"| tr "\t" "," > /data/bigdata/hive/student.csv;

2. 导入到 ClickHouse 的 default 数据库中的 student_hive 表中：

   clickhouse --client --port 9002 --password *xxx* **-m --query='INSERT INTO default.student_hive FORMAT CSV' < /data/bigdata/hive/student.csv**

   命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

3.20.3 使用辅助 Zookeeper 或者副本数据同步表数据时，日志报错

问题

使用辅助 Zookeeper 或者副本数据同步表数据时，日志报错:

```
DB::Exception: Cannot parse input: expected 'quorum:' before: 'merge_type: 2'…
Too many parts (315). Merges are processing significantly slower than inserts…
```

回答

复制表副本版本不一致存在兼容性问题，表结构中有 TTL 语句，ClickHouse 20.9 之后版本新加了 TTL_DELETE，之前的版本不识别，高版本复制表副本被选作 leader 时会出现该问题。

可修改高版本 ClickHouse 配置文件 config.xml 文件做规避，需尽可能保证复制表副本见 ClickHouse 版本一致。

3.20.4 如何为 ClickHouse 用户赋予数据库级别的 Select 权限

操作步骤

步骤 1 登录到 MRS 集群装有 ClickHouse 客户端的节点，执行如下命令：

su - omm

source *{客户端安装目录}*/**bigdata_env**

kinit *组件用户*（普通集群无需执行 kinit 命令）

clickhouse client --host *clickhouse 实例节点 IP* **--port 9000 -m --user clickhouse --password** *'clickhouse 用户密码'*

说明

- 查看 ClickHouse 用户密码：

  登录 FusionInsight Manager 界面，选择“集群 > 服务 > ClickHouse > 实例”，单击任意 ClickHouseServer 角色名称。进入 ClickHouseServer“概览”页面，单击“配置文件”中的 users.xml 文件，查看 ClickHouse 用户密码。

- 命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

步骤 2 创建指定数据库只读权限角色，有如下两种方案：

方案一：

1. 创建指定数据库只读权限角色（以 default 数据库为例，下同）：

   create role ck_role on cluster default_cluster;

   GRANT SELECT ON default.* TO ck_role on cluster default_cluster;

2. 创建普通用户

   CREATE USER user_01 on cluster default_cluster IDENTIFIED WITH PLAINTEXT_PASSWORD BY '*password*';

3. 将只读权限角色赋予普通用户

   GRANT ck_role to user_01 on cluster default_cluster;

4. 查看用户权限

   show grants for user_01;

   select * from system.grants where role_name = 'ck_role';

方案二：

创建指定数据库只读权限用户：

1. 创建用户：

   CREATE USER user_01 on cluster default_cluster IDENTIFIED WITH PLAINTEXT_PASSWORD BY '*password*';

2. 给用户赋予指定数据库的查询权限：

   grant select on default.* to user_01 on cluster default_cluster;

3. 查询用户权限：

   select * from system.grants where user_name = 'user_01';

----结束

4 使用 DBService

4.1 配置 HA 模块的 SSL

操作场景

本任务将对安装 DBService 的集群进行手动配置 DBService 服务 HA 模块 SSL 的操作。

说明

执行该操作后，如需还原，请执行 4.2 还原 HA 模块的 SSL。

前提条件

- 已经成功完成集群安装操作。
- 主备 DBService 节点的“$BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0/security”目录下的“root-ca.crt”和“root-ca.pem”相同。

操作步骤

步骤 1 以 **omm** 用户登录到需要配置 SSL 的 DBService 节点上。

步骤 2 进入“$BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0/sbin/”目录，执行以下命令：

./proceed_ha_ssl_cert.sh *DBService 安装目录 节点业务 IP 地址。*

例如：

cd $BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0/sbin/

./proceed_ha_ssl_cert.sh $BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0 10.10.10.10

说明

“$BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0”为 DBService 工作区安装目录，请按照实际环境进行修改。

步骤 3 进入“$BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0/ha/module/hacom/script/”目录，执行以下命令重启 HA：

./stop_ha.sh

./start_ha.sh

步骤 4 在以上节点执行以下命令获取 HA 进程的“pid”：

ps -ef |grep "ha.bin" |grep DBSERVICE

步骤 5 执行以下命令，查看协议是否全部变更为 TCP：

netstat -nap | grep *pid* **| grep -v unix**

- 是，结束操作。
- 否，执行步骤 2。

```
(Not all processes could be identified, non-owned process info
 will not be shown, you would have to be root to see it all.)
tcp       0      0 127.0.0.1:20054         0.0.0.0:*             LISTEN
11896/ha.bin
tcp       0      0 10.10.10.10:20052   10.10.10.14:20052       ESTABLISHED
11896/ha.bin
tcp       0      0 10.10.10.10:20053   10.10.10.14:20053       ESTABLISHED
11896/ha.bin
```

----结束

4.2 还原 HA 模块的 SSL

操作场景

本任务将对安装 DBService 的集群进行还原 DBService 服务 HA 模块 SSL 的操作。

前提条件

DBService 服务 HA 模块已开启 SSL 配置。

说明

检查 DBService 服务 HA 模块是否开启 SSL 配置：

查看“$BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0/ha/module/hacom/conf/hacom.xml”，如果包含“<hadataprotocol value="ssl"></hadataprotocol>”，则已开启 SSL。

操作步骤

步骤 1 以 **omm** 用户登录到需要还原的 DBService 节点。

步骤 2 执行以下命令恢复 DBService 的“hacom_local.xml”配置文件：

cd $BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0/ha/local/hacom/conf/

cp hacom_local.xml $BIGDATA_HOME/tmp/

cat hacom_local.xml | grep "ssl>" -n | cut -d':' -f1 | xargs | sed 's/ /,/g' |xargs -n 1 -i sed -i '{}d' hacom_local.xml

步骤 3 依次执行如下命令恢复 DBService 的“hacom.xml”配置文件：

cd $BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0/ha/module/hacom/conf/

cp hacom.xml $BIGDATA_HOME/tmp/

sed -i 's#<hadataprotocol.*#<hadataprotocol value="tcp"/>#g' hacom.xml

sed -i 's#<rpcsupportssl.*#<rpcsupportssl value="true"/>#g' hacom.xml

说明

“$BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0/”为 DBService 工作区的安装目录，请按照实际升级环境进行修改。

步骤 4 进入“$BIGDATA_HOME/FusionInsight_BASE_*x.x.x*/install/FusionInsight-dbservice-2.7.0/ha/module/hacom/script/”目录，执行以下命令重启 HA：

./stop_ha.sh

./start_ha.sh

步骤 5 执行以下命令获取 HA 进程的“pid”：

ps -ef |grep "ha.bin" |grep DBSERVICE

步骤 6 执行以下命令，查看协议是否全部变更为 TCP：

netstat -nap | grep *pid* | grep -v unix

- 是，结束操作。
- 否，请联系运维人员。

```
[omm@host03]\>netstat -nap | grep 49989
(Not all processes could be identified, non-owned process info
 will not be shown, you would have to be root to see it all.)
tcp        0      0 127.0.0.1:20054         0.0.0.0:*               LISTEN
49989/ha.bin
tcp        0      0 10.10.10.10:20052       0.0.0.0:*                       49989/ha.bin
tcp        0      0 10.10.10.10:20053       0.0.0.0:*                       49989/ha.bin
```

----结束

4.3 配置 DBService 备份任务超时时间

操作场景

针对 DBService 备份任务执行的默认超时时间为 2 小时，在 DBService 中数据量过大时，任务执行时间会超过 2 小时导致备份任务执行失败。

该操作指导工程师调整 DBService 备份任务的超时时间。

前提条件

- 集群正常安装。
- DBService 服务运行正常。

操作步骤

步骤 1 使用 PuTTY，以 **omm** 用户登录主 OMS 节点，修改配置文件“${CONTROLLER_HOME}/etc/om/controller.properties”中参数“controller.backup.conf.script.execute.timeout”值为“10000000”（根据当前集群中的 DBService 数据量调大超时时间）。

步骤 2 使用 PuTTY，以 **omm** 用户登录备 OMS 节点，重复步骤 1。

步骤 3 使用 PuTTY，以 **omm** 用户登录主 OMS 节点，执行以下命令查询 **BackupRecoveryPluginProcess** 进程 id，并结束此进程：

jps|grep -i BackupRecoveryPluginProcess

kill -9 *查询到的 pid*

步骤 4 登录到 Manager 页面重新执行 DBService 备份任务。

步骤 5 执行以下命令查看 **BackupRecoveryPluginProcess** 进程是否已开启：

jps|grep -i BackupRecoveryPluginProcess

----结束

4.4 DBService 日志介绍

日志描述

日志存储路径：DBService 相关日志的默认存储路径为“/var/log/Bigdata/dbservice”。

- gaussDB：“/var/log/Bigdata/dbservice/DB”（gaussDB 运行日志目录），“/var/log/Bigdata/dbservice/scriptlog/gaussdbinstall.log”（gaussDB 安装日志），“/var/log/gaussdbuninstall.log”（gaussDB 卸载日志）。
- HA：“/var/log/Bigdata/dbservice/ha/runlog”（HA 运行日志目录），“/var/log/Bigdata/dbservice/ha/scriptlog”（HA 脚本日志目录）。

- DBServer：“/var/log/Bigdata/dbservice/healthCheck”（服务进程健康状态检查日志目录）。

  “/var/log/Bigdata/dbservice/scriptlog”（运行日志目录），
  “/var/log/Bigdata/audit/dbservice/”（审计日志目录）。

日志归档规则：DBService 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 1MB 的时候，会自动压缩，压缩后的日志文件名规则为：“*<原有日志名>*_*<编号>*.gz”。最多保留最近的 20 个压缩文件。

说明

日志归档规则用户不能修改。

表4-1 DBService 日志列表

日志类型	日志文件名	描述
DBServer 运行相关日志	dbservice_serviceCheck.log	服务检查脚本运行日志
	dbservice_processCheck.log	进程检查脚本运行日志
	backup.log	备份恢复操作运行日志（需执行 DBService 备份恢复操作）
	checkHaStatus.log	HA 检查日志
	cleanupDBService.log	卸载日志（需执行 DBService 卸载日志操作）
	componentUserManager.log	数据库用户添加删除操作日志 （需添加依赖 DBService 的服务）
	install.log	安装日志
	preStartDBService.log	预启动日志
	start_dbserver.log	DBServer 启动操作日志（需执行启动 DBService 服务的操作）
	stop_dbserver.log	DBServer 停止操作日志（需执行停止 DBService 服务的操作）
	status_dbserver.log	DBServer 状态检查日志（需执行 **$DBSERVICE_HOME/sbin/status-dbserver.sh**）
	modifyPassword.log	DBService 修改密码脚本

日志类型	日志文件名	描述
		运行日志（需执行 **$DBSERVICE_HOME/sbin/modifyDBPwd.sh**）
	modifyDBPwd_yyyy-mm-dd.log	修改密码工具运行日志（需执行 **$DBSERVICE_HOME/sbin/modifyDBPwd.sh**）
	dbserver_switchover.log	DBServer 执行主备倒换脚本的日志（需执行主备倒换操作）
GAUSSDB 运行日志	gaussdb.log	记录数据库运行信息
	gs_ctl-current.log	记录 gs_ctl 工具的操作
	gs_guc-current.log	记录 gs_guc 工具的操作，主要是参数修改
	gaussdbinstall.log	gaussDB 安装日志
	gaussdbuninstall.log	gaussDB 卸载日志
HA 脚本相关运行日志	floatip_ha.log	Floatip 资源脚本日志
	gaussDB_ha.log	gaussDB 资源脚本日志
	ha_monitor.log	HA 进程监控日志
	send_alarm.log	告警发送日志
	ha.log	HA 运行日志
DBService 审计日志	dbservice_audit.log	dbservice 操作审计日志（例如：备份恢复操作）

日志格式

DBService 的日志格式如下所示：

表4-2 日志格式

日志类型	格式	示例
运行日志	[<yyyy-MM-dd HH:mm:ss>] <Log Level>： [<*产生该日志的脚本名称*：*行号*>]： <*log 中的 message*>	[2020-12-19 15:56:42] INFO [postinstall.sh:653] Is cloud flag is false. (main)

日志类型	格式	示例
审计日志	[<yyyy-MM-dd HH:mm:ss,SSS>] UserName:<*用户名称*> UserIP:<*用户 IP*> Operation:<*操作内容*> Result:<*操作结果*> Detail:<*具体信息*>	[2020-05-26 22:00:23] UserName:omm UserIP:192.168.10.21 Operation:DBService data backup Result: SUCCESS Detail: DBService data backup is successful.

5 使用 Doris

5.1 安装 MySQL 客户端

Doris 支持 MySQL 协议，所以大部分支持 MySQL 协议的客户端都可以访问 Doris，包括命令行或者 IDE，例如 MariaDB、DBeaver、Navicat for MySQL 等。

本操作以安装 RedHat 的 MySQL 8.0.22 客户端为例进行演示。

前提条件

待安装 MySQL 客户端的节点与 MRS 集群网络互通。

操作步骤

步骤 1 以 **root** 用户登录待安装 MySQL 客户端的节点。

步骤 2 执行以下命令查看 MySQL 客户端依赖库 **ncurses-libs** 的版本：

rpm -qa | grep ncurses

```
[root@node-master1hlrt ~]# rpm -qa | grep ncurses
ncurses-base-6.3-2.r2.hce2.noarch
ncurses-libs-6.3-2.r2.hce2.x86_64
ncurses-6.3-2.r2.hce2.x86_64
```

步骤 3 从 https://downloads.mysql.com/archives/community/下载 MySQL 客户端对应的软件包，建议安装 8.x 版本，以 RedHat 发行版本为例：

- 如果步骤 2 的依赖库是 6.x 建议下载对应 OS Version 为 RedHat8 的 MySQL 软件包。
- 如果步骤 2 的依赖库是 5.x 建议下载对应 OS Version 为 RedHat7 的 MySQL 软件包。

例如，若需安装 RedHat 的 MySQL 8.0.22 客户端需下载如下四个软件包：

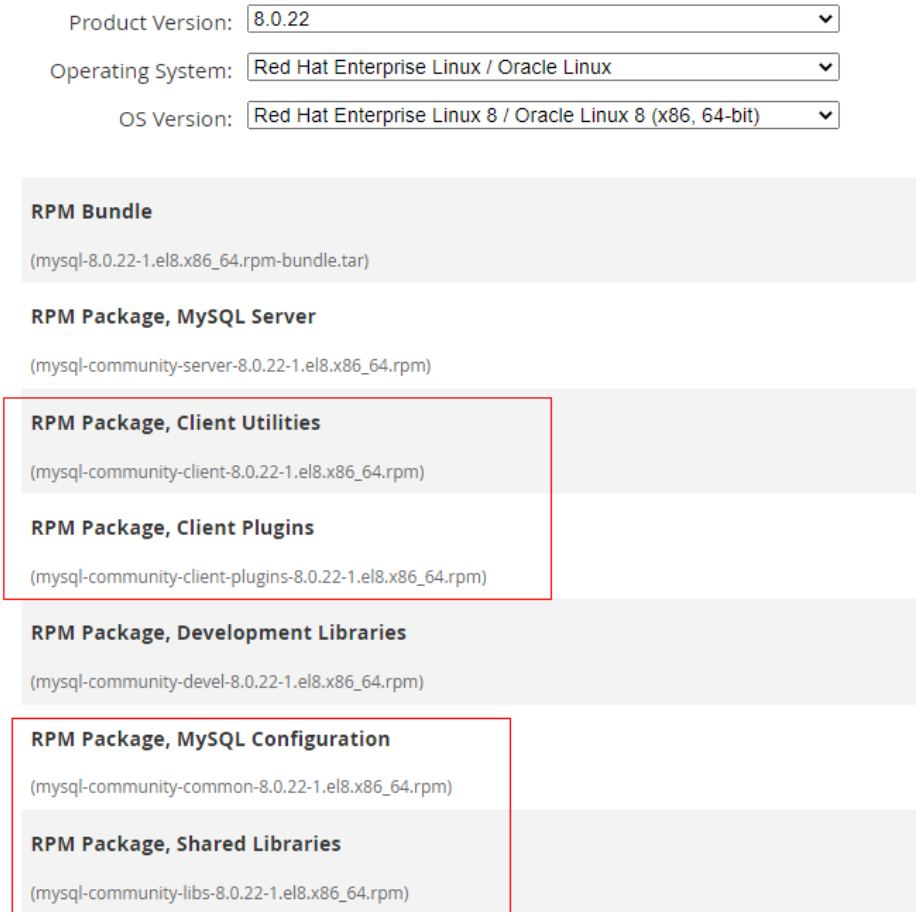

步骤 4 将下载的软件包上传到待安装 MySQL 客户端的节点上。

步骤 5 在上传的文件所在目录执行以下命令，安装 MySQL 客户端及对应的依赖包。

rpm -ivh mysql-community-client-8.0.22-1.el8.x86_64.rpm --nodeps --force

rpm -ivh mysql-community-client-plugins-8.0.22-1.el8.x86_64.rpm --nodeps --force

rpm -ivh mysql-community-common-8.0.22-1.el8.x86_64.rpm --nodeps --force

rpm -ivh mysql-community-libs-8.0.22-1.el8.x86_64.rpm --nodeps --force

步骤 6 执行以下命令查看 MySQL 客户端的版本：

mysql --version

```
[root@node-master1hlrt ~]# mysql --version
mysql  Ver 8.0.22 for Linux on x86_64 (MySQL Community Server - GPL)
```

步骤 7 MySQL 客户端安装成功后，即可访问 Doris，详细操作请参见 5.2 从零开始使用 Doris。

----结束

5.2 从零开始使用 Doris

Doris 是一个基于 MPP 架构的高性能、实时的分析型数据库，不仅可以支持高并发的点查询场景，也能支持高吞吐的复杂分析场景。

本文主要通过示例介绍如何快速使用 MRS Doris 集群进行基本的建表和查询操作。

说明

Doris 数据库名和表名区分大小写。

前提条件

- 已创建包含 Doris 服务的集群，集群内各服务运行正常。
- 待连接 Doris 数据库的节点与 MRS 集群网络互通。
- 已安装 MySQL 客户端，相关操作可参考 5.1 安装 MySQL 客户端。

操作步骤

步骤 1 创建具有 Doris 管理权限的用户。

- 集群已启用 Kerberos 认证（安全模式）
  a. 登录 FusionInsight Manager，选择“系统 > 权限 > 角色 > 添加角色”，填写角色名称，如“dorisrole”，在“配置资源权限”选择“*待操作的集群* > Doris”，勾选“Doris 管理员权限”，单击“确定”。
  b. 选择“用户 > 添加用户”，填写用户名称，如“dorisuser”，“用户类型”选择“人机”，“密码策略”默认，输入用户密码并确认密码，关联“dorisrole”角色，单击“确定”。
  c. 使用新建的 **dorisuser** 用户重新登录 FusionInsight Manager，修改该用户初始密码。
- 集群未启用 Kerberos 认证（普通模式）
  a. 登录安装了 MySQL 客户端的节点，使用 **admin** 用户连接 Doris 服务。

     mysql -uadmin -P *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- **admin** 用户默认密码为空。
- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。
- 仅 MRS 3.3.0 及之后版本的集群支持通过 FusionInsight Manager 创建角色进行赋权，若集群为 MRS 3.3.0 之前的版本，无论是否开启 Kerberos 认证，都需要通过 **root** 用户（默认密码为空）来连接数据库。

  b. 执行以下命令创建角色：

     CREATE ROLE *dorisrole*;

  c. 执行以下命令给角色授权，具体权限介绍请参见用户权限介绍。例如，授予角色 ADMIN_PRIV 权限：

GRANT *ADMIN_PRIV* **ON *.*.* TO ROLE '***dorisrole***';**

d. 执行以下命令创建用户并绑定角色：

CREATE USER '*dorisuser***'@'%' IDENTIFIED BY '***password***' DEFAULT ROLE '***dorisrole***';**

命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

步骤 2 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

步骤 3 执行以下命令可查看 FE 运行状态。

SHOW FRONTENDS\G;

SHOW BACKENDS\G;

步骤 4 创建一个数据库。

create database if not exists *mrs_demo*;

use *mrs_demo*;

说明

更多 Doris SQL 命令及语法说明请参考 Doris SQL 手册。

步骤 5 数据库创建成功后，继续创建数据表。

```
CREATE TABLE IF NOT EXISTS mrs_table
(
`user_id` LARGEINT NOT NULL COMMENT "用户 id",
`date` DATE NOT NULL COMMENT "数据灌入日期",
`city` VARCHAR(20) COMMENT "城市",
`age` SMALLINT COMMENT "年龄",
`sex` TINYINT COMMENT "性别",
`last_visit_date` DATETIME REPLACE DEFAULT "1970-01-01 00:00:00" COMMENT "用户最后一次访问时间",
```

`cost` BIGINT SUM DEFAULT "0" COMMENT "用户总消费",

`max_dwell_time` INT MAX DEFAULT "0" COMMENT "用户最大停留时间",

`min_dwell_time` INT MIN DEFAULT "99999" COMMENT "用户最小停留时间"

)

AGGREGATE KEY(`user_id`, `date`, `city`, `age`, `sex`)

DISTRIBUTED BY HASH(`user_id`) BUCKETS 1

PROPERTIES (

"replication_allocation" = "tag.location.default: 1"

);

步骤 6 在当前节点的任意目录下创建“test.csv”文件，内容如下：

```
10000,2017-10-01,city1,20,0,2017-10-01 06:00:00,20,10,10
10000,2017-10-01,city2,20,0,2017-10-01 07:00:00,15,2,2
10001,2017-10-01,city3,30,1,2017-10-01 17:05:45,2,22,22
10002,2017-10-02,city4,20,1,2017-10-02 12:59:12,200,5,5
10003,2017-10-02,city5,32,0,2017-10-02 11:20:00,30,11,11
10004,2017-10-01,city6,35,0,2017-10-01 10:00:15,100,3,3
10004,2017-10-03,city7,35,0,2017-10-03 10:20:22,11,6,6
```

步骤 7 通过 Stream load 方式将“test.csv”中的数据导入到步骤 5 创建的表中。

cd *test.csv 所在目录*

curl -k --location-trusted -u *doris 用户名*:*用户密码* **-H "***label*:*table1_20230217*" **-H "***column_separator*:,**" -T test.csv http://***Doris FE 实例 IP 地址*:*HTTP 端口* **/api/mrs_demo/***mrs_table***/_stream_load**

说明

- Doris FE 实例 IP 地址可在 Manager 界面，选择“集群 > 服务 > Doris > 实例”查看。
- HTTP 端口号可在 Manager 界面，选择“集群 > 服务 > Doris > 配置”，搜索“http_port”查看。

步骤 8 查询数据。

select * from *mrs_table* **where city='city1';**

----结束

5.3 Doris 权限管理

Doris 权限管理系统实现了行级别细粒度的权限控制，和基于角色的权限访问控制。

用户权限介绍

Doris 目前支持的权限如表 5-1 所示。

表5-1 Doris 权限列表

权限名称	权限介绍
Node_priv	节点变更权限。包括 FE、BE、DBroker 节点的添加、删除、下线等操作。 该权限只能赋予 Global 级别。
Admin_priv	除 NODE_PRIV 以外的所有权限。
Grant_priv	权限变更权限，允许执行授权、撤权、添加/删除/变更用户/角色等操作。 拥有该权限的用户不能赋予其他用户“node_priv”权限，除非用户本身拥有“node_priv”权限。
Select_priv	对数据库、表的只读权限。
Load_priv	对数据库、表的写权限，包括 Load、Insert、Delete 等。
Alter_priv	对数据库、表的更改权限。包括重命名库/表、添加/删除/变更列、添加/删除分区等操作。
Create_priv	创建数据库、表、视图的权限。
Drop_priv	删除数据库、表、视图的权限。
Usage_priv	资源的使用权限和 workload group 权限。

根据权限适用范围的不同，将库表的权限分为以下四个层级：

- **CATALOG LEVEL**：数据目录（Catalog）级权限。被授予的权限适用于指定 Catalog 中的任意库表。
- **DATABASE LEVEL**：数据库级权限。被授予的权限适用于指定数据库中的任意表。
- **TABLE LEVEL**：表级权限。被授予的权限适用于指定数据库中的指定表。
- **RESOURCE LEVEL**： 资源级权限。被授予的权限适用于指定资源。

前提条件

- Doris 服务运行正常。
- 角色名称不能为 **operator** 和 **admin**。
- 集群已启用 Kerberos 认证（安全模式）时，Doris 赋权成功后，权限生效时间大约为 2 分钟。
- 仅 MRS 3.3.0 及之后版本的集群支持通过 FusionInsight Manager 创建角色进行赋权，若集群为 MRS 3.3.0 之前的版本，无论是否开启 Kerberos 认证，都需要通过 **root** 用户（默认密码为空）来连接数据库。

添加 Doris 角色（集群已启用 Kerberos 认证（安全模式））

步骤 1 登录 Manager，选择“系统 > 权限 > 角色”，在“角色”界面单击“添加角色”按钮，进入添加角色页面。

步骤 2 在添加角色界面输入“角色名称”，在配置资源权限处单击集群名称，进入服务列表页面，单击 Doris 服务，进入 Doris 权限资源页面。

根据业务需求确定是否要创建具有 Doris 管理员权限的角色。

说明

- Doris 管理员权限为：除去节点操作权限外的所有权限。
- 角色名：添加的角色名不能包含中划线字符“-”，否则会导致认证失败。

- 是，执行步骤 3。
- 否，执行步骤 4。

步骤 3 勾选“Doris 管理员权限”，单击“确定”，操作结束。

步骤 4 单击“Doris 读写权限”，勾选对应资源的查询、删除、插入、修改、创建或授权权限。

根据业务需求确定是否赋权。

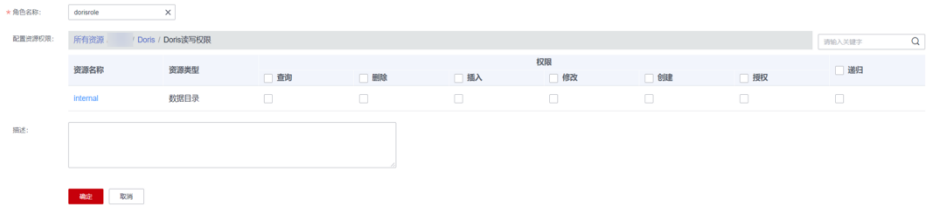

步骤 5 授权完成后，单击“确定”操作结束。

----结束

添加用户并绑定 Doris 对应角色（集群已启用 Kerberos 认证（安全模式））

步骤 1 登录 Manager，选择“系统 > 权限 > 用户”，单击“添加用户”，进入添加用户页面。

步骤 2 “用户类型”选择“人机”，在“密码”和“确认密码”参数设置该用户对应的密码。

说明

- 用户名：添加的用户名不能包含中划线字符“-”，否则会导致认证失败。
- 密码：设置的密码不能携带“$”、“.”、“#”特殊字符，否则会导致认证失败。

步骤 3 在“角色”处单击“添加”，在弹框中选择具有 Doris 权限的角色，单击“确定”添加到角色，单击“确定”完成操作。

步骤 4 使用新建的用户重新登录 FusionInsight Manager，修改该用户初始密码。

步骤 5 登录安装了 MySQL 客户端的节点，使用新添加的用户及修改后的密码连接 Doris 服务。

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u*dorisuser* **-p** *用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

----结束

添加角色并绑定给用户（集群未启用 Kerberos 认证（普通模式））

步骤 1 登录安装了 MySQL 客户端的节点，使用 **admin** 用户连接 Doris 服务。

mysql -uadmin -P *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- **admin** 用户默认密码为空。
- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

步骤 2 执行以下命令创建角色：

CREATE ROLE *dorisrole*;

步骤 3 执行以下命令给角色授权，具体权限介绍请参见用户权限介绍。例如，授予角色 ADMIN_PRIV 权限：

GRANT *ADMIN_PRIV* **ON *.*.* TO ROLE '***dorisrole***';**

步骤 4 执行以下命令创建用户并绑定角色：

CREATE USER '*dorisuser*'@'%' IDENTIFIED BY '*password*' DEFAULT ROLE '*dorisrole*';

----结束

5.4 访问 Doris 原生 Web 页面

步骤 1 使用具有 Manager 管理员权限的用户登录 FusionInsight Manager 页面，选择“集群 > 服务 > Doris”。

步骤 2 在概览页面，单击“FE WebUI”右侧的超链接进入 Doris WebUI 登录页面，输入具有 Doris 管理权限的用户名和密码（集群已启用 Kerberos 认证（安全模式）需已修改初始密码），创建用户相关操作请参见 5.3 Doris 权限管理，单击“Login”：

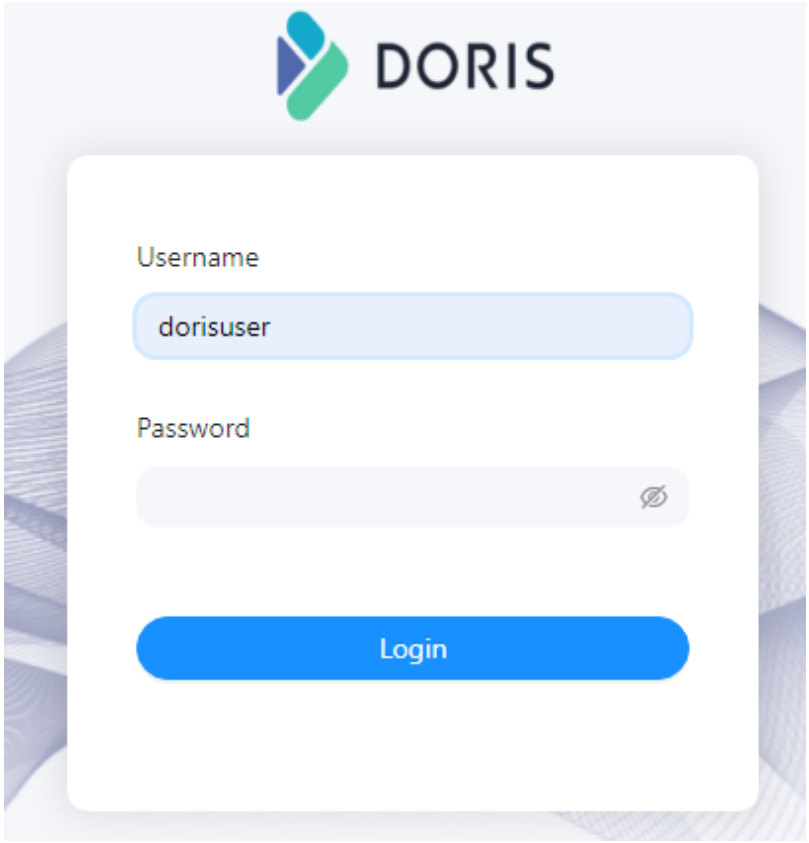

步骤 3 在 Doris WebUI 首页中查看 Doris 集群相关信息，也可以在“Playground”中查看 Doris 表信息并执行查询 SQL 语句。

----结束

5.5 Doris 数据模型介绍

基本概念

在 Doris 中，数据以表（Table）的形式进行逻辑上的描述。 一张表包括行（Row）和列（Column）。Row 即用户的一行数据，Column 用于描述一行数据中不同的字段。Column 可以分为 Key 和 Value 两大类。从业务角度看，Key 和 Value 可以分别对应维度列和指标列。

Doris 的数据模型主要分为以下三类：

- Aggregate
- Unique
- Duplicate

Aggregate 模型

建 Aggregate 模型表语句如下：

CREATE TABLE IF NOT EXISTS *example_db.example_tbl*

(

`user_id` LARGEINT NOT NULL COMMENT "用户 id",

`date` DATE NOT NULL COMMENT "数据灌入日期时间",

`city` VARCHAR(20) COMMENT "用户所在城市",

`age` SMALLINT COMMENT "用户年龄",

`sex` TINYINT COMMENT "用户性别",

`last_visit_date` DATETIME REPLACE DEFAULT "1970-01-01 00:00:00" COMMENT "用户最后一次访问时间",

`cost` BIGINT SUM DEFAULT "0" COMMENT "用户总消费",

`max_dwell_time` INT MAX DEFAULT "0" COMMENT "用户最大停留时间",

`min_dwell_time` INT MIN DEFAULT "99999" COMMENT "用户最小停留时间"

)

AGGREGATE KEY(`user_id`, `date`, `city`, `age`, `sex`)

DISTRIBUTED BY HASH(`user_id`) BUCKETS 1

PROPERTIES (

"replication_allocation" = "tag.location.default: 1"

);

说明

当导入数据时，对于 Key 列相同的行会聚合成一行，而 Value 列会按照设置的 AggregationType 进行聚合。 AggregationType 目前有以下四种聚合方式：

- SUM：求和，多行的 Value 进行累加。
- REPLACE：替代，下一批数据中的 Value 会替换之前导入过的行中的 Value。
- MAX：保留最大值。
- MIN：保留最小值。

表中的列按照是否设置了 AggregationType，分为 Key (维度列) 和 Value（指标列）。例如，没有设置 AggregationType 的，如 user_id、date、age 等称为 Key，而设置了 AggregationType 的称为 Value。

Unique 模型

- 读时合并

  这类表没有聚合需求，只需保证主键（user_id 和 username）的唯一性。且 Unique 模型的读时合并实现完全可以用 Aggregate 模型中的 REPLACE 方式替代。建表示例如下：

  CREATE TABLE IF NOT EXISTS *example_db.example_tbl*
  (
  `user_id` LARGEINT NOT NULL COMMENT "用户 id",
  `username` VARCHAR(50) NOT NULL COMMENT "用户昵称",
  `city` VARCHAR(20) COMMENT "用户所在城市",
  `age` SMALLINT COMMENT "用户年龄",
  `sex` TINYINT COMMENT "用户性别",
  `phone` LARGEINT COMMENT "用户电话",
  `address` VARCHAR(500) COMMENT "用户地址",
  `register_time` DATETIME COMMENT "用户注册时间"
)
  UNIQUE KEY(`user_id`, `username`)
  DISTRIBUTED BY HASH(`user_id`) BUCKETS 1
  PROPERTIES (
  "replication_allocation" = "tag.location.default: 1"
  );

- 写时合并

  Unique 模型的写时合并实现，与 Aggregate 模型是完全不同的两种模型，查询性能更接近于 Duplicate 模型，在有主键约束需求的场景上相比 Aggregate 模型有较大的查询性能优势，适用于在聚合查询以及需要用索引过滤大量数据的查询场景。

  可以在建表时指定如下 property 的方式开启 Unique 模型：

  "enable_unique_key_merge_on_write" = "true"

  例如：

  CREATE TABLE IF NOT EXISTS *example_db.example_tbl*
  (
  `user_id` LARGEINT,
  `username` VARCHAR(50) NOT NULL,
  `city` VARCHAR(20),

```
`age` SMALLINT,
`sex` TINYINT,
`phone` LARGEINT,
`address` VARCHAR(500),
`register_time` DATETIME
)
UNIQUE KEY(`user_id`, `username`)
DISTRIBUTED BY HASH(`user_id`) BUCKETS 1
PROPERTIES (
"replication_allocation" = "tag.location.default: 1",
"enable_unique_key_merge_on_write" = "true"
);
```

说明

在开启了写时合并选项的 Unique 表，数据在导入阶段就会去将被覆盖和被更新的数据进行标记删除，同时将新的数据写入新的文件。在查询时，所有被标记删除的数据都会在文件级别被过滤，读取出来的数据是最新的数据，消除了读时合并中的数据聚合过程，并且支持多种谓词的下推，因此在聚合查询场景下能带来较大的性能提升。

Duplicate 模型

数据既没有主键，也没有聚合需求时，可以使用 Duplicate 数据模型建表。Duplicate 模型数据完全按照导入文件中的数据进行存储，不会有任何聚合。即使两行数据完全相同，也都会保留。 而在建表语句中指定的 **DUPLICATE KEY**，只是用来指明底层数据按照指定的列进行排序。

建 Duplicate 模型表语句如下：

```
CREATE TABLE IF NOT EXISTS example_db.example_tbl
(
`timestamp` DATETIME NOT NULL COMMENT "日志时间",
`type` INT NOT NULL COMMENT "日志类型",
`error_code` INT COMMENT "错误码",
`error_msg` VARCHAR(1024) COMMENT "错误详细信息",
`op_id` BIGINT COMMENT "负责人 id",
`op_time` DATETIME COMMENT "处理时间"
)
DUPLICATE KEY(`timestamp`, `type`, `error_code`)
DISTRIBUTED BY HASH(`type`) BUCKETS 1
PROPERTIES (
"replication_allocation" = "tag.location.default: 1"
);
```

Key 列

Duplicate、Aggregate、Unique 模型，都会在建表时指定 Key 列，区别为：

- Duplicate 模型，：表的 Key 列只是**排序列**，并非起到唯一标识的作用。
- Aggregate、Unique 模型：这两种聚合类型的表，Key 列是兼顾**排序列**和**唯一标识列**，是真正意义上的 **Key 列**。

数据模型的选择建议

因为数据模型在建表时就已经确定，且无法修改。所以，选择一个合适的数据模型非常重要。

- Aggregate 模型可以通过预聚合，极大地降低聚合查询时所需扫描的数据量和查询的计算量，适合有固定模式的报表类查询场景，但是该模型不适用于 **count(*)**查询。同时因为固定了 Value 列上的聚合方式，在进行其他类型的聚合查询时，需要考虑语意正确性。
- Unique 模型针对需要唯一主键约束的场景，可以保证主键唯一性约束。但是无法利用 ROLLUP 等预聚合带来的查询优势。
  - 对于聚合查询有较高性能需求的用户，推荐使用写时合并实现。
  - Unique 模型仅支持整行更新，如果用户既需要唯一主键约束，又需要更新部分列（例如将多张源表导入到一张 Doris 表的场景），则可以考虑使用 Aggregate 模型，同时将非主键列的聚合类型设置为 **REPLACE_IF_NOT_NULL**。
- Duplicate 适合任意维度的 Ad-hoc 查询。虽然无法利用预聚合的特性，但是不受聚合模型的约束，可以发挥列存模型的优势（只读取相关列，而不需要读取所有 Key 列）。

5.6 数据操作

5.6.1 数据导入

5.6.1.1 Broker Load

Broker Load 是一个异步的导入方式，支持的数据源取决于 Broker 进程支持的数据源。

Doris 表中的数据是有序的，Broker Load 在导入数据时要利用 Doris 集群资源对数据进行排序，相对于 Spark Load 来完成海量历史数据迁移，对 Doris 的集群资源占用比较大。Broker Load 方式是在用户没有 Spark 计算资源的情况下使用，如果有 Spark 计算资源建议使用 Spark Load。

用户需要通过 MySQL 协议创建 Broker Load 导入，并通过查看导入命令检查导入结果。适用以下场景：

- 源数据在 Broker 可以访问的存储系统中，如 HDFS。
- 数据量在几十到百 GB 级别。
- 支持导入 CSV、Parquet、ORC 格式的数据，默认支持导入 CSV 格式数据。

前提条件

- 已创建包含 Doris 服务的集群，集群内各服务运行正常。
- 待连接 Doris 数据库的节点与 MRS 集群网络互通。
- 创建具有 Doris 管理权限的用户。
  - 集群已启用 Kerberos 认证（安全模式）

    在 FusionInsight Manager 中创建一个人机用户，例如“dorisuser”，创建一个拥有“Doris 管理员权限”的角色绑定给该用户。

    使用新建的用户 **dorisuser** 重新登录 FusionInsight Manager，修改该用户初始密码。
  - 集群未启用 Kerberos 认证（普通模式）

    使用 **admin** 用户连接 Doris 后，创建具有管理员权限的角色并绑定给用户。
- 已安装 MySQL 客户端，相关操作可参考 5.1 安装 MySQL 客户端。
- Doris 中已安装并启动 DBroker 实例。
- 已安装 Hive 客户端。

导入 Hive 表数据到 Doris 中

- 导入 Text 格式的 Hive 表数据到 Doris 中

  a. 执行以下命令登录 Hive beeline 命令行：

  cd /opt/hadoopclient

  source bigdata_env

  kinit *组件业务用户*（若集群未启用 Kerberos 认证（普通模式）请跳过该操作）

  b. 执行以下命令在 **default** 库创建 Hive 表，分区字段为“c4”：

  CREATE TABLE *test_table***(**

  `c1` int,

  `c2` int,

  `c3` string)

  PARTITIONED BY (c4 string)

  row format delimited fields terminated by ','lines terminated by '\n' stored as textfile ;

  c. 执行以下命令插入数据到 Hive 表中：

  insert into table *test_table* **values(1,1,'1','2022-04-10'),(2,2,'2','2022-04-22');**

  d. 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

  若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

  export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

  mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

e. 执行以下命令创建 Doris 表：

CREATE TABLE *example_db.test_t1* **(**
`c1` int NOT NULL,
`c4` date NULL,
`c2` int NOT NULL,
`c3` String NOT NULL
) ENGINE=OLAP
UNIQUE KEY(`c1`, `c4`)
PARTITION BY RANGE(`c4`)
(
PARTITION P_202204 VALUES [('2022-04-01'), ('2022-05-01')))
DISTRIBUTED BY HASH(`c1`) BUCKETS 1
PROPERTIES (
"replication_allocation" = "tag.location.default: 3",
"dynamic_partition.enable" = "true",
"dynamic_partition.time_unit" = "MONTH",
"dynamic_partition.start" = "-2147483648",
"dynamic_partition.end" = "2",
"dynamic_partition.prefix" = "P_",
"dynamic_partition.buckets" = "1",
"in_memory" = "false",
"storage_format" = "V2"
);

f. 执行以下命令导入数据：

- 集群已启用 Kerberos 认证（安全模式）

LOAD LABEL *broker_load_2022_03_23*
(
DATA INFILE("hdfs://主 *NameNode 实例 IP 地址*:*RPC 端口号*
/user/hive/warehouse/*test_table***/*/*")**
INTO TABLE *test_t1*
COLUMNS TERMINATED BY ","
(c1,c2,c3)
COLUMNS FROM PATH AS (`c4`)
SET
(
c4 = str_to_date(`c4`,'%Y-%m-%d'),c1=c1,c2=c2,c3=c3

)

)

WITH BROKER "*broker_192_168_67_78***"**

(

"hadoop.security.authentication"="kerberos",

"kerberos_principal"="doris/hadoop.hadoop.com@HADOOP.COM",

"kerberos_keytab"="${BIGDATA_HOME}/FusionInsight_Doris_8.3.0/install/FusionInsight-Doris-1.2.3/doris-fe/bin/doris.keytab"

)

PROPERTIES

(

"timeout"="1200",

"max_filter_ratio"="0.1"

);

- 集群未启用 Kerberos 认证（普通模式）

LOAD LABEL *broker_load_2022_03_23*

(

DATA INFILE("hdfs://*主 NameNode 实例 IP 地址***:***RPC 端口号***/user/hive/warehouse/***test_table***/*/*")**

INTO TABLE *test_t1*

COLUMNS TERMINATED BY ","

(c1,c2,c3)

COLUMNS FROM PATH AS (`c4`)

SET

(

c4 = str_to_date(`c4`,'%Y-%m-%d'),c1=c1,c2=c2,c3=c3

)

)

WITH BROKER "*broker_192_168_67_78***"**

(

"username"="hdfs",

"password"=""

)

PROPERTIES

(

"timeout"="1200",

"max_filter_ratio"="0.1"

);

说明

- 主 NameNode 实例 IP 地址可在 Manager 界面，选择“集群 > 服务 > HDFS > 实例”查看。
- RPC 端口号可在 Manager 界面，选择“集群 > 服务 > HDFS > 配置”，搜索“dfs.namenode.rpc.port”查看。

- *broker_192_168_67_78* 表示 Broker 名称，可在 MySQL 客户端执行 **show broker;**命令查看。

g. 执行以下命令查看导入任务的状态信息：

show load order by createtime desc limit 1\G;

```
JobId: 41326624
Label: broker_load_2022_03_23
State: FINISHED
Progress: ETL:100%; LOAD:100%
Type: BROKER
EtlInfo: unselected.rows=0; dpp.abnorm.ALL=0; dpp.norm.ALL=27
TaskInfo: cluster:N/A; timeout(s):1200; max_filter_ratio:0.1
ErrorMsg: NULL
CreateTime: 2022-04-01 18:59:06
EtlStartTime: 2022-04-01 18:59:11
EtlFinishTime: 2022-04-01 18:59:11
LoadStartTime: 2022-04-01 18:59:11
LoadFinishTime: 2022-04-01 18:59:11
URL: NULL
JobDetails: {"Unfinished backends":{"5072bde59b74b65-
8d2c0ee5b029adc0":[]},"ScannedRows":27,"TaskNumber":1,"All
backends":{"5072bde59b74b65-
8d2c0ee5b029adc0":[36728051]},"FileNumber":1,"FileSize":5540}
1 row in set (0.01 sec)
```

h. 可手动取消 Broker Load 作业状态不为“CANCELLED”或“FINISHED”的导入任务，取消时需要指定待取消导入任务的 Label ，命令为：

CANCEL LOAD FROM *数据库名称* WHERE LABEL = "*Label 名称*";

例如：撤销数据库 **demo** 上， label 为 **broker_load_2022_03_23** 的导入作业：

CANCEL LOAD FROM demo WHERE LABEL = "broker_load_2022_03_23";

- 导入 ORC 格式的 Hive 表数据到 Doris 中

a. 执行以下命令登录 Hive beeline 命令行：

cd /opt/hadoopclient

source bigdata_env

kinit *组件业务用户*（若集群未启用 Kerberos 认证（普通模式）请跳过该操作）

b. 执行以下命令在 **default** 库创建 ORC 格式的 Hive 表：

CREATE TABLE *test_orc_tbl*(

`c1` int,

`c2` int,

`c3` string)

PARTITIONED BY (c4 string)

row format delimited fields terminated by ','lines terminated by '\n' stored as orc;

c. 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

d. 执行以下命令创建 Doris 表：

CREATE TABLE *example_db.test_orc_t1* **(**
`c1` int NOT NULL,
`c4` date NULL,
`c2` int NOT NULL,
`c3` String NOT NULL
) ENGINE=OLAP
UNIQUE KEY(`c1`, `c4`)
PARTITION BY RANGE(`c4`)
(
PARTITION P_202204 VALUES [('2022-04-01'), ('2022-05-01'))
DISTRIBUTED BY HASH(`c1`) BUCKETS 1
PROPERTIES (
"replication_allocation" = "tag.location.default: 3",
"dynamic_partition.enable" = "true",
"dynamic_partition.time_unit" = "MONTH",
"dynamic_partition.start" = "-2147483648",
"dynamic_partition.end" = "2",
"dynamic_partition.prefix" = "P_",
"dynamic_partition.buckets" = "1",
"in_memory" = "false",
"storage_format" = "V2"
);

e. 执行以下命令使用 Broker Load 导入数据：

- 集群已启用 Kerberos 认证（安全模式）：

  LOAD LABEL *broker_load_2022_03_24*
  (
  DATA INFILE("hdfs://*主 NameNode 实例 IP 地址:RPC 端口号***/user/hive/warehouse/***test_orc_tbl***/*/*")**
  INTO TABLE *test_orc_t1*
  COLUMNS TERMINATED BY ","
  FORMAT AS "orc"
  (c1,c2,c3)

COLUMNS FROM PATH AS (`c4`)
SET
(
c4 = str_to_date(`c4`,'%Y-%m-%d'),c1=c1,c2=c2,c3=c3
)
)
WITH BROKER "broker_192_168_67_78"
(
"hadoop.security.authentication"="kerberos",
"kerberos_principal"="doris/hadoop.hadoop.com@HADOOP.COM",
"kerberos_keytab"="${BIGDATA_HOME}/FusionInsight_Doris_8.3.0/install/FusionInsight-Doris-1.2.3/doris-fe/bin/doris.keytab"
)
PROPERTIES
(
"timeout"="1200",
"max_filter_ratio"="0.1"
);

- 集群未启用 Kerberos 认证（普通模式）

LOAD LABEL *broker_load_2022_03_24*
(
DATA INFILE("hdfs://*主 NameNode 实例 IP 地址:RPC 端口号***/user/hive/warehouse/***test_orc_tbl**/*/*")**
INTO TABLE *test_orc_t1*
COLUMNS TERMINATED BY ","
FORMAT AS "orc"
(c1,c2,c3)
COLUMNS FROM PATH AS (`c4`)
SET
(
c4 = str_to_date(`c4`,'%Y-%m-%d'),c1=c1,c2=c2,c3=c3
)
)
WITH BROKER "broker_192_168_67_78"
(
'username"="hdfs",
'password"=""
)
PROPERTIES
(
"timeout"="1200",
"max_filter_ratio"="0.1"

);

说明

- **FORMAT AS "orc"** ：已指定待导入的数据格式为 ORC。
- **SET**：定义 Hive 表和 Doris 表之间的字段映射关系及字段转换的规则。
- 主 NameNode 实例 IP 地址可在 Manager 界面，选择“集群 > 服务 > HDFS > 实例”查看。
- RPC 端口号可在 Manager 界面，选择“集群 > 服务 > HDFS > 配置”，搜索“dfs.namenode.rpc.port”查看。
- *broker_192_168_67_78* 表示 Broker 名称，可在 MySQL 客户端执行 **show broker;**命令查看。

f. 执行以下命令查看导入任务的状态信息：

show load order by createtime desc limit 1\G;

g. 可手动取消 Broker Load 作业状态不为“CANCELLED”或“FINISHED”的导入任务，取消时需要指定待取消导入任务的 Label ，命令为：

CANCEL LOAD FROM *数据库名称* WHERE LABEL = "*Label 名称*";

例如：撤销数据库 **demo** 上， label 为 **broker_load_2022_03_23** 的导入作业：

CANCEL LOAD FROM demo WHERE LABEL = "broker_load_2022_03_23";

相关参数配置

以下配置属于 Broker Load 的系统级别配置，作用于所有 Broker Load 导入任务。

登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置 > FE（角色） > 自定义”，在自定义参数“fe.conf.customized.configs”中新增以下参数：

- min_bytes_per_broker_scanner：用于限制了单个 BE 处理的数据量的最小值，默认值为：64MB，单位为：bytes。
- max_bytes_per_broker_scanner：用于限制了单个 BE 处理的数据量的最大值，默认值为：3G，单位为：bytes。
- max_broker_concurrency：用于限制一个作业的最大的导入并发数，默认值为：10。

最小处理的数据量，最大并发数，源文件的大小和当前集群 BE 节点的个数共同决定了本次任务导入的并发数：

- 本次导入并发数 = Math.min（源文件大小/最小处理量，最大并发数，当前 BE 节点个数）
- 本次导入单个 BE 的处理量 = 源文件大小/本次导入的并发数

通常一个导入作业支持的最大数据量为 **max_bytes_per_broker_scanner** * BE 节点数。如果需要导入更大数据量，则需要适当调整“max_bytes_per_broker_scanner”参数的大小。

5.6.1.2 Stream Load

Stream Load 是一个同步的导入方式，用户通过 HTTP 协议发送请求将本地文件或数据流导入到 Doris 中。Stream Load 同步执行导入并返回导入结果，用户可直接通过请求的返回体判断本次导入是否成功。

Stream Load 主要适用于导入本地文件，或通过程序导入数据流中的数据。支持导入 CSV、Parquet、ORC 格式的数据，默认支持导入 CSV 格式数据。

语法介绍

- 创建 Stream Load 导入任务

  Stream Load 通过 HTTP 协议提交和传输数据。该操作通过 curl 命令演示如何提交导入，也可以使用其他 HTTP Client 进行操作。

  - 集群已启用 Kerberos 认证（安全模式）：

    curl -k --location-trusted -u *user:passwd* **[-H ""...] -T data.file -XPUT https://***Doris FE 实例 IP 地址*:*HTTPS 端口号*/api/{数据库名称}/{表名}/_stream_load

  - 集群未启用 Kerberos 认证（普通模式）

    curl --location-trusted -u *user:passwd* **[-H ""...] -T data.file -XPUT http://***Doris FE 实例 IP 地址*:*HTTP 端口号*/api/{数据库名称}/{表名}/_stream_load

  Doris FE 实例 IP 地址可在 Manager 界面，选择“集群 > 服务 > Doris > 实例”查看。

  HTTPS 端口号可在 Manager 界面，选择“集群 > 服务 > Doris > 配置”，搜索“https_port”查看。

  HTTP 端口号可在 Manager 界面，选择“集群 > 服务 > Doris > 配置”，搜索“http_port”查看。

  表 5-2 介绍了创建 Stream Load 任务的其他部分参数。

表5-2 Stream Load 任务参数介绍

参数		描述
签名参数	user:passwd	Stream Load 创建导入的协议使用的是 HTTP 协议，通过 Basic access authentication 进行签名。Doris 系统会根据签名验证用户身份和导入权限。
导入任务参数（格式为：**-H "key1:value1"**）	label	导入任务的标识。每个导入任务，都有一个在单 database 内部唯一的 label。label 是用户在导入命令中自定义的名称。通过这个 label，用户可以查看对应导入任务的执行情况。
	column_separator	用于指定导入文件中的列分隔符，默认为**\t**，可以使用多个字符的组合作为列分隔符。如果是不可见字符，则需要加**\x** 作为前缀，使用十六进制来表示分隔符。如 Hive 文件的分隔符**\x01**，需要指定为**-H "column_separator:\x01"**。
	line_delimiter	用于指定导入文件中的换行符，默认为**\n**，可以使用做多个字符的组合作为换行符。
	max_filter_ratio	导入任务的最大容忍率，默认为 0 容忍，取值范围是 0~1。当导入的错误率超过该值，则导入失败。
	where	导入任务指定的过滤条件。Stream Load 支持对原始数据指定 **where** 语句进行过滤，被过滤的数据将不会被导入，也不会参与 **filter ratio** 的计算，但会被计入 **num_rows_unselected**。

参数		描述
	Partitions	待导入表的 Partition 信息，如果待导入数据不属于指定的 Partition，则不会被导入，这些数据将计入 dpp.abnorm.ALL。
	columns	待导入数据的函数变换配置，目前 Stream Load 支持的函数变换方法包含列的顺序变化以及表达式变换，其中表达式变换的方法与查询语句一致。
	format	指定导入数据格式，支持 CSV、JSON、Parquet、ORC 等，默认是 CSV。
	exec_mem_limit	导入内存限制，默认为：2GB，单位为：字节。
	strict_mode	Stream Load 导入可以开启 strict mode 模式，在 HEADER 中声明 **strict_mode=true** 即可开启，默认关闭 strict mode。 strict mode 用于对导入过程中的列类型转换进行严格过滤，策略如下： • 对于列类型转换来说，如果 **strict mode** 为“true”，则错误的数据将被 filter。错误数据是指原始数据并不为空值，在参与列类型转换后结果为空值的数据。 • 对于导入的某列由函数变换生成时，strict mode 对其不产生影响。 • 对于导入的某列类型包含范围限制的，如果原始数据能正常通过类型转换，但无法通过范围限制，strict mode 对其也不产生影响。例如：如果类型是 decimal(1,0)，原始数据为 10，则属于可以通过类型转换但不在列声明的范围内，这种数据 strict 对其不产生影响。
	merge_type	数据的合并类型，支持 APPEND、DELETE 和 MERGE 三种类型，默认为 APPEND。APPEND 表示这批数据需要全部追加到现有数据中；DELETE 表示删除与这批数据 Key 相同的所有行；MERGE 语义需要与 **delete** 条件联合使用，满足 delete 条件的数据按照 DELETE 语义处理，其余的按照 APPEND 语义处理。
	two_phase_commit	Stream Load 导入可以开启两阶段事务提交模式。在 Stream Load 过程中，数据写入完成即会返回信息给用户，此时数据不可见，事务状态为“PRECOMMITTED”，用户手动触发 **commit** 操作之后，数据才可见。
	enable_profile	当“enable_profile”为“true”时，Stream Load profile 将会打印到日志中，否则不会打印。

- 返回结果

  由于 Stream Load 是一种同步的导入方式，所以导入的结果会通过创建导入的返回值直接返回，例如：

```
{
"TxnId": 1003,
"Label": "b6f3bc78-0d2c-45d9-9e4c-faa0a0149bee",
"Status": "Success",
"ExistingJobStatus": "FINISHED", // optional
"Message": "OK",
"NumberTotalRows": 1000000,
"NumberLoadedRows": 1000000,
"NumberFilteredRows": 1,
"NumberUnselectedRows": 0,
"LoadBytes": 40888898,
"LoadTimeMs": 2144,
"BeginTxnTimeMs": 1,
"StreamLoadPutTimeMs": 2,
"ReadDataTimeMs": 325,
"WriteDataTimeMs": 1933,
"CommitAndPublishTimeMs": 106,
"ErrorURL":
"http://192.168.1.1:8042/api/_load_error_log?file=__shard_0/error_log_insert_st
mt_db18266d4d9b4ee5-abb00ddd64bdf005_db18266d4d9b4ee5_abb00ddd64bdf005"
}
```

导入结果参数介绍如表 5-3 所示。

表5-3 Stream Load 导入任务结果参数介绍

参数	描述
TxnId	导入的事务 ID。用
Label	导入 Label，由用户指定或系统自动生成。
Status	导入完成状态，包括： • Success：表示导入成功。 • Publish Timeout：该状态也表示导入已完成，只是数据可能会延迟可见，无需重试。 • Label Already Exists：Label 重复，需更换 Label。 • Fail：导入失败。
ExistingJobStatus	已存在的 Label 对应的导入作业的状态。 该字段只有当 Status 为**"Label Already Exists"**时才显示。可以通过这个状态，查看已存在 Label 对应的导入作业的状态。**"RUNNING"** 表示作业还在执行，**"FINISHED"**表示作业执行成功。
Message	导入错误信息。
NumberTotalRows	导入总处理的行数。
NumberLoadedRows	成功导入的行数。
NumberFiltered	数据不合格的行数。

参数	描述
Rows	
NumberUnselectedRows	被 where 条件过滤的行数。
LoadBytes	导入的字节数
LoadTimeMs	导入完成时间，单位为：毫秒。
BeginTxnTimeMs	向 FE 请求开始一个事务所花费的时间，单位为：毫秒。
StreamLoadPutTimeMs	向 FE 请求获取导入数据执行计划所花费的时间，单位为：毫秒。
ReadDataTimeMs	读取数据所花费的时间，单位为：毫秒。
WriteDataTimeMs	执行写入数据操作所花费的时间，单位为：毫秒。
CommitAndPublishTimeMs	向 FE 请求提交并且发布事务所花费的时间，单位为：毫秒。
ErrorURL	如果有数据问题，通过访问该 URL 查看具体错误行。

说明

由于 Stream Load 是同步的导入方式，所以不会在 Doris 系统中记录导入信息，用户无法异步通过查看导入命令看到 Stream Load。使用时需查看创建导入请求的返回值获取导入结果。

- 取消导入

  用户无法手动取消 Stream Load，Stream Load 在超时或者导入错误后会被系统自动取消。

- 查看 Stream Load

  用户可以通过 **show stream load** 查看已经完成的 Stream Load 任务。

  默认 BE 不记录 Stream Load 的导入信息，如果需要查看需在配置 **enable_stream_load_record=true** 参数启用记录。

前提条件

- 已创建包含 Doris 服务的集群，集群内各服务运行正常。
- 待连接 Doris 数据库的节点与 MRS 集群网络互通。
- 创建具有 Doris 管理权限的用户。
  - 集群已启用 Kerberos 认证（安全模式）

    在 FusionInsight Manager 中创建一个人机用户，例如“dorisuser”，创建一个拥有“Doris 管理员权限”的角色绑定给该用户。

    使用新建的用户 **dorisuser** 重新登录 FusionInsight Manager，修改该用户初始密码。

- 集群未启用 Kerberos 认证（普通模式）

  使用 **admin** 用户连接 Doris 后，创建具有管理员权限的角色并绑定给用户。

- 已安装 MySQL 客户端，相关操作可参考 5.1 安装 MySQL 客户端。

Stream Load 任务示例

步骤 1 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

步骤 2 执行以下命令创建数据库：

create database if not exists *example_db*;

步骤 3 执行以下命令创建表：

CREATE TABLE *example_db.test_stream_tbl* **(**

`c1` int NOT NULL,

`c2` int NOT NULL,

`c3` string NOT NULL,

`c4` date NOT NULL

) ENGINE=OLAP

UNIQUE KEY(`c1`, `c2`)

DISTRIBUTED BY HASH(`c1`) BUCKETS 1;

步骤 4 创建数据文件“data.csv”，内容为：

```
1,1,1,2020-02-21
2,2,2,2020-03-21
3,3,3,2020-04-21
```

步骤 5 使用 Stream Load 导入“data.csv”中的数据到步骤 3 创建的表中：

- 集群已启用 Kerberos 认证（安全模式）

  curl -k --location-trusted -u ***user:passwd*** **-H "***label:table1_20230217***" -H "***column_separator:,***" -T data.csv https://***Doris FE 实例 IP 地址*:*HTTPS 端口*/**api**/*example_db*/*test_stream_tbl*/**_stream_load**

- 集群未启用 Kerberos 认证（普通模式）

curl --location-trusted -u *user:passwd* -H "*label:table1_20230217***" -H "c*olumn_separator:,*" -T data.csv http://*Doris FE 实例 IP 地址:HTTP 端口*/api/*example_db*/*test_stream_tbl*/_stream_load**

步骤 6 执行以下命令查看表数据：

select * from *example_db.test_stream_tbl*;

----结束

相关参数配置

登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置 > 全部配置”，新增如下参数：

- 选择“FE（角色） > 自定义”，在自定义参数“fe.conf.customized.configs”中新增参数：

  stream_load_default_timeout_second：表示导入任务的超时时间（单位为秒），若导入任务在设定的时间内未完成则会被系统取消，状态变为“CANCELLED”。默认超时时间为 600 秒，如果导入的源文件无法在规定时间内完成导入，可以在 Stream Load 请求中设置单独的超时时间，或调整“stream_load_default_timeout_second”参数值设置全局的默认超时时间。

- 选择“BE（角色） > 自定义”，在自定义参数“be.conf.customized.configs”中新增参数：

  streaming_load_max_mb：表示 Stream Load 的最大导入文件大小，默认值为 10G，单位为 MB。如果原始文件超过该值，则需要适当调整该参数值。

5.6.2 数据导出

5.6.2.1 导出数据

数据导出（Export）功能可以将用户指定的表或分区的数据，以文本的格式，通过 Broker 进程导出到远端存储上，如 HDFS/对象存储（支持 S3 协议） 等。

说明

- 不建议一次性导出大量数据。一个 Export 作业建议的导出数据量最大在几十 GB。过大的导出会导致更多的垃圾文件和更高的重试成本。
- 如果表数据量过大，建议按照分区导出。
- 在 Export 作业运行过程中，如果 FE 发生重启或主备倒换，则 Export 作业会失败，需要用户重新提交。
- 如果 Export 作业运行失败，在远端存储中产生的“__doris_export_tmp_*xxx*”临时目录，及已经生成的文件不会被删除，需手动删除。
- 如果 Export 作业运行成功，在远端存储中产生的“__doris_export_tmp_*xxx*”目录，根据远端存储的文件系统语义，可能会保留，也可能会被清除。

  例如，对象存储（支持 S3 协议）中，通过 **rename** 操作将一个目录中的最后一个文件移走后，该目录也会被删除。如果该目录没有被清除，可以手动清除。
- 当 Export 运行完成后（成功或失败），FE 发生重启或主备倒换，则 **SHOW EXPORT** 展示的作业的部分信息会丢失，无法查看。
- Export 作业只会导出 Base 表的数据，不会导出 Rollup Index 的数据。
- Export 作业会扫描数据，占用 I/O 资源，可能会影响系统的查询延迟。

语法介绍

- 导出 Doris 数据到 HDFS
  - 集群已启用 Kerberos 认证（安全模式）

    EXPORT TABLE *db1.tbl1*
    PARTITION (p1,p2)
    [WHERE [expr]]
    TO "hdfs://*主 NameNode 实例 IP 地址:RPC 端口号/tmp/export/***"**
    PROPERTIES
    (
    "label" = "*mylabel***",**
    "column_separator"=",",
    "columns" = "col1,col2",
    "exec_mem_limit"="2147483648",
    "timeout" = "3600"
)
    WITH BROKER "broker_name"
    (
    "hadoop.security.authentication"="kerberos",
    "kerberos_principal"="doris/hadoop.hadoop.com@HADOOP.COM",
    "kerberos_keytab"="${BIGDATA_HOME}/FusionInsight_Doris_*/install/FusionInsight-Doris-*/doris-fe/bin/doris.keytab"
    );
  - 集群未启用 Kerberos 认证（普通模式）

    EXPORT TABLE *db1.tbl1*
    PARTITION (p1,p2)
    [WHERE [expr]]
    TO "hdfs://*主 NameNode 实例 IP 地址:RPC 端口号/tmp/export/***"**
    PROPERTIES
    (
    "label" = "*mylabel***",**
    "column_separator"=",",
    "columns" = "col1,col2",
    "exec_mem_limit"="2147483648",
    "timeout" = "3600"
)
    WITH BROKER "broker_name"
    (
    "username" = "*user***",**
    "password" = "*passwd***"**
    );

主 NameNode 实例 IP 地址可在 Manager 界面，选择“集群 > 服务 > HDFS > 实例”查看。

RPC 端口号可在 Manager 界面，选择“集群 > 服务 > HDFS > 配置”，搜索“dfs.namenode.rpc.port”查看。

其他参数解释表 5-4 所示。

表5-4 导出 Doris 数据到 HDFS 命令相关参数介绍

参数	描述
label	本次导出作业的标识。可以使用这个标识查看作业状态。
column_separator	列分隔符，默认为**\t**。支持不可见字符，例如：'\x07'。
columns	要导出的列，使用英文逗号分隔，如果不设置该参数默认导出表的所有列。
line_delimiter	行分隔符，默认为**\n**。支持不可见字符，例如：'\x07'。
exec_mem_limit	表示导出作业中，一个查询计划在单个 BE 上的内存使用限制。默认为 2GB，单位为字节。
timeout	作业超时时间，默认值为 2 小时，单位为秒。
tablet_num_per_task	每个查询计划分配的最大分片数，默认值为 5。

- 查看导出作业状态

  提交作业后，可以通过 **SHOW EXPORT;**命令查询导出作业状态。例如：

```
JobId: 14008
State: FINISHED
Progress: 100%
TaskInfo: {"partitions":["*"],"exec mem limit":2147483648,"column
separator":",","line delimiter":"\n","tablet num":1,"broker":"hdfs","coord
num":1,"db":"default_cluster:db1","tbl":"tbl3"}
Path: hdfs://host/path/to/export/
CreateTime: 2019-06-25 17:08:24
StartTime: 2019-06-25 17:08:28
FinishTime: 2019-06-25 17:08:34
Timeout: 3600
ErrorMsg: NULL
1 row in set (0.01 sec)
```

  参数解释如表所示：

表5-5 导出作业状态参数介绍

参数	描述
JobId	作业的 ID，值唯一。
State	作业状态，包括：

参数	描述
	• PENDING：作业待调度。 • EXPORTING：数据导出中。 • FINISHED：作业导出成功。 • ANCELLED：导出作业运行失败。
Progress	作业进度，以查询计划为单位。假设一共 10 个查询计划，当前已完成 3 个，则进度为 30%。
TaskInfo	以 JSON 格式展示的作业信息，其中： • db：数据库名。 • tbl：表名 • partitions：指定导出的分区。*表示所有分区。 • exec mem limit：查询计划内存使用限制。单位为字节。 • column separator：导出文件的列分隔符。 • line delimiter：导出文件的行分隔符。 • tablet num：总 Tablet 数量。 • broker：使用的 Broker 的名称。 • coord num：查询计划的个数。
Path	远端存储上的导出路径。
CreateTime/StartTime/FinishTime：	作业的创建时间、开始调度时间和结束时间。
Timeout	作业超时时间，单位是秒。该时间从 CreateTime 开始计算。
ErrorMsg	如果作业出现错误，ErrorMsg 会显示错误原因。

- 取消导出任务

  提交作业后，可以通过 **CANCEL_EXPORT** 命令取消导出作业。取消命令如下：

  CANCEL EXPORT
  FROM *example_db*
  WHERE LABEL like "*%example%***";**

前提条件

- 已创建包含 Doris 服务的集群，集群内各服务运行正常。
- 待连接 Doris 数据库的节点与 MRS 集群网络互通。
- 创建具有 Doris 管理权限的用户。
  - 集群已启用 Kerberos 认证（安全模式）

    在 FusionInsight Manager 中创建一个人机用户，例如“dorisuser”，创建一个拥有“Doris 管理员权限”的角色绑定给该用户。

使用新建的用户 **dorisuser** 重新登录 FusionInsight Manager，修改该用户初始密码。

- 集群未启用 Kerberos 认证（普通模式）

  使用 **admin** 用户连接 Doris 后，创建具有管理员权限的角色并绑定给用户。

- 已安装 MySQL 客户端，相关操作可参考 5.1 安装 MySQL 客户端。

导出作业示例

步骤 1 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

步骤 2 执行以下命令创建数据库。

create database if not exists *example_db*;

步骤 3 执行以下命令创建表。

CREATE TABLE *example_db.test_export_tbl* **(**

`c1` int NOT NULL,

`c2` int NOT NULL,

`c3` string NOT NULL,

`c4` date NOT NULL

) ENGINE=OLAP

DUPLICATE KEY(`c1`, `c2`)

DISTRIBUTED BY HASH(`c1`) BUCKETS 1;

步骤 4 执行以下命令插入数据。

insert into example_db.test_export_tbl values(1,1,1,"2020-02-21"),(2,2,2,"2020-03-21"),(3,3,3,"2020-04-21");

步骤 5 执行以下命令导出“test_export_tbl”表数据到 HDFS 中。

EXPORT TABLE *example_db.test_export_tbl*

TO "hdfs://*主 NameNode 实例 IP 地址***:***RPC 端口号***/tmp/export/"**

PROPERTIES

```
(
"label" = "label_exporthdfs_20230218031",
"column_separator"=",",
"columns" = "c1,c2,c3,c4",
"exec_mem_limit"="2147483648",
"timeout" = "3600"
)
with broker "broker_192_168_67_78"
(
"hadoop.security.authentication"="kerberos",
"kerberos_principal"="doris/hadoop.hadoop.com@HADOOP.COM",
"kerberos_keytab"="${BIGDATA_HOME}/FusionInsight_Doris_8.3.0/install/FusionInsight-Doris-1.2.3/doris-fe/bin/doris.keytab"
);
```

步骤 6 执行以下命令查询导出作业状态。

```
SHOW EXPORT;
```

----结束

相关配置参数

登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置 > FE（角色） > 自定义”，在自定义参数“fe.conf.customized.configs”中新增以下参数：

- export_checker_interval_second：Export 作业调度器的调度间隔，默认为 5 秒。设置该参数后需重启 FE。
- export_running_job_num_limit：正在运行的 Export 作业数量限制。如果超过该值，则作业将等待并处于 **PENDING** 状态。默认值为 5，可以在运行时调整。
- export_task_default_timeout_second：Export 作业默认超时时间。默认为 2 小时，可以在运行时调整。
- export_tablet_num_per_task：一个查询计划负责的最大分片数，默认为 5。
- label：用户手动指定的 EXPORT 任务 label，如果不指定会自动生成一个 label。

5.6.2.2 导出查询结果集

介绍如何使用 **SELECT INTO OUTFILE** 命令进行查询结果的导出操作。、

说明

- 导出命令不会检查文件及文件路径是否存在。是否会自动创建路径、或是否会覆盖已存在文件，由远端存储系统的语义决定。
- 如果在导出过程中出现错误，可能会有导出文件残留在远端存储系统上，Doris 不会清理这些文件，需要手动清理。

- 导出命令的超时时间同查询的超时时间，可以通过 **SET query_timeout=***xxx* 进行设置。
- 对于结果集为空的查询，依然会产生一个大小为 0 的文件。
- 文件切分会保证一行数据完整的存储在单一文件中。因此文件的大小并不严格等 max_file_size。
- 对于部分输出为非可见字符的函数，如 BITMAP、HLL 类型，输出为\N，即 NULL。
- 目前部分地理信息函数，如 ST_Point 的输出类型为 VARCHAR，但实际输出值为经过编码的二进制字符，当前这些函数会输出乱码。对于地理函数，请使用 ST_AsText 进行输出。

语法介绍

query_stmt

INTO OUTFILE "file_path"

[format_as]

[properties]

file_path

format_as

properties

说明

format_as 表示指定导出格式，支持 CSV、PARQUET、CSV_WITH_NAMES、CSV_WITH_NAMES_AND_TYPES、ORC，默认为 CSV。

示例

- 导出到 HDFS

  将简单查询结果导出到文件“hdfs://path/to/result.txt”中，并指定导出格式为 CSV。

  - 集群已启用 Kerberos 认证（安全模式）

    SELECT * FROM example_db.test_export_tbl
    INTO OUTFILE "hdfs://*192.168.67.78:25000***/tmp/result_"**
    FORMAT AS CSV
    PROPERTIES
    (
    "broker.name" = "broker_192_168_67_78",
    "column_separator" = ",",
    "line_delimiter" = "\n",
    "max_file_size" = "100MB",
    "broker.hadoop.security.authentication" = "kerberos",
    "broker.kerberos_principal" = "doris/hadoop.hadoop.com@HADOOP.COM",
    "broker.kerberos_keytab" = "${BIGDATA_HOME}/FusionInsight_Doris_8.3.0/install/FusionInsight-Doris-1.2.3/doris-fe/bin/doris.keytab"
    );

- 集群未启用 Kerberos 认证（普通模式）

  SELECT * FROM example_db.test_export_tbl
  INTO OUTFILE "hdfs://*192.168.67.78:25000***/tmp/result_"**
  FORMAT AS CSV
  PROPERTIES
  (
  "broker.name" = "broker_192_168_67_78",
  "column_separator" = ",",
  "line_delimiter" = "\n",
  "max_file_size" = "100MB",
  "broker.username"="hdfs",
  "broker.password"=""
  );

- 导出到本地文件

  导出到本地文件时需要先在“fe.conf”中配置 **enable_outfile_to_local=true**。

  select * from *tbl1* **limit 10**
  INTO OUTFILE "file:///*home/work/path/result_***";**

5.7 Doris 常用 SQL 语法

5.7.1 创建数据库

本章节主要介绍 Doris 创建数据库的 SQL 基本语法和使用说明。

基本语法

CREATE DATABASE [IF NOT EXISTS] *db_name*

[PROPERTIES ("key"="value", ...)];

使用示例

步骤 1 使用具有 Doris 管理权限的用户通过 MySQL 客户端连接到 Doris。

步骤 2 执行以下命令创建数据库 **example_db**：

create database if not exists example_db;

步骤 3 执行以下命令查看数据库信息：

SHOW DATABASES;

```
mysql> SHOW DATABASES;
+--------------------+
| Database           |
+--------------------+
| example_db         |
| information_schema |
```

```
+--------------------+
2 rows in set (0.00 sec)
```

步骤 4 执行以下命令切换到 **example_db**：

use example_db;

----结束

5.7.2 创建表

本章节主要介绍 Doris 创建表的 SQL 基本语法和使用说明。

基本语法

CREATE TABLE [IF NOT EXISTS] [database.]*table*

(

column_definition_list,

[index_definition_list]

)

[engine_type]

[keys_type]

[table_comment]

[partition_info]

distribution_desc

[rollup_list]

[properties]

[extra_properties]

使用示例

- 创建一个名为 **table1** 的普通表：

  CREATE TABLE example_db.table1
  (
  k1 TINYINT,
  k2 DECIMAL(10, 2) DEFAULT "10.5",
  k3 CHAR(10) COMMENT "string column",
  k4 INT NOT NULL DEFAULT "1" COMMENT "int column"
)
  COMMENT "table comment"
  DISTRIBUTED BY HASH(k1) BUCKETS 32;

- 创建一个名为 **table2** 的分区表。

使用 **event_day** 列做为分区列，建立 3 个分区：p201706、p201707、p201708，取值为：

- p201706：范围为 [最小值, 2017-07-01)
- p201707：范围为 [2017-07-01, 2017-08-01)
- p201708：范围为 [2017-08-01, 2017-09-01)

每个分区使用 **siteid** 进行哈希分桶，桶数为 10。

创建表命令如下：

```
CREATE TABLE table2
(
event_day DATE,
siteid INT DEFAULT '10',
citycode SMALLINT,
username VARCHAR(32) DEFAULT '',
pv BIGINT SUM DEFAULT '0'
)
AGGREGATE KEY(event_day, siteid, citycode, username)
PARTITION BY RANGE(event_day)
(
PARTITION p201706 VALUES LESS THAN ('2017-07-01'),
PARTITION p201707 VALUES LESS THAN ('2017-08-01'),
PARTITION p201708 VALUES LESS THAN ('2017-09-01')
)
DISTRIBUTED BY HASH(siteid) BUCKETS 10
PROPERTIES("replication_num" = "1");
```

说明

- 以上创建表设置 **replication_num** 建的都是单副本表，Doris 建议采用默认的 3 副本设置，以保证高可用。
- 可以对 Table 增加上卷表（Rollup）以提高查询性能。
- 表的列的 Null 属性默认为 **true**，会对查询性能有一定的影响。
- Doris 表必须指定分桶列。

- 查看表内容：
  - **SHOW TABLES;**

```
+----------------------+
| Tables_in_example_db |
+----------------------+
| table1               |
| table2               |
+----------------------+
2 rows in set (0.01 sec)
```

  - **DESC table1;**

```
+----------+-------------+------+-------+---------+-------+
| Field    | Type        | Null | Key   | Default | Extra |
+----------+-------------+------+-------+---------+-------+
```

```
| siteid   | int(11)     | Yes  | true  | 10      |       |
| citycode | smallint(6) | Yes  | true  | N/A     |       |
| username | varchar(32) | Yes  | true  |         |       |
| pv       | bigint(20)  | Yes  | false | 0       | SUM   |
+----------+-------------+------+-------+---------+-------+
4 rows in set (0.00 sec)
```

- **DESC table2;**

```
+-----------+-------------+------+-------+---------+-------+
| Field     | Type        | Null | Key   | Default | Extra |
+-----------+-------------+------+-------+---------+-------+
| event_day | date        | Yes  | true  | N/A     |       |
| siteid    | int(11)     | Yes  | true  | 10      |       |
| citycode  | smallint(6) | Yes  | true  | N/A     |       |
| username  | varchar(32) | Yes  | true  |         |       |
| pv        | bigint(20)  | Yes  | false | 0       | SUM   |
+-----------+-------------+------+-------+---------+-------+
5 rows in set (0.00 sec)
```

5.7.3 插入数据

本章节主要介绍 Doris 插入表数据的 SQL 基本语法和使用说明。

基本语法

INSERT INTO *table_name*

[PARTITION (p1, ...)]

[WITH LABEL label]

[(column [, ...])]

[[hint [, ...]]]

{ VALUES ({ expression | DEFAULT } [, ...]) [, ...] | query }

使用示例

- 给 **test** 表中一次性插入多行数据：
  INSERT INTO test VALUES (1, 2), (3, 4);
- 向 **test** 表中导入一个查询语句结果：
  INSERT INTO test (c1, c2) SELECT * from test2;

5.7.4 修改表结构

修改表结构时，针对聚合模型和非聚合模型的修改方式不同；针对 Key 列和 Value 列的修改方式也不同。其中：

- 建表时指定 **AGGREGATE KEY** 时，为聚合模型；其它场景为非聚合模型。
- 建表语句中的关键字**'unique key'**或**'aggregate key'**或**'duplicate key'**后面的列就是 Key 列，剩下的就是 Value 列。

聚合模型示例

聚合列不支持修改聚合类型。

- 在 **col1** 列后添加 **new_col** 列（key 列）：

  ALTER TABLE example_db.my_table　ADD COLUMN new_col INT DEFAULT "0" AFTER col1;
- 在 **col1** 后添加 **new_col** 列（Value 列 SUM 聚合类型）：

  ALTER TABLE example_db.my_table ADD COLUMN new_col INT SUM DEFAULT "0" AFTER col1;
- 修改 **col1** 列的类型为 BIGINT（Key 列）：

  ALTER TABLE example_db.my_table MODIFY COLUMN col1 BIGINT DEFAULT "1";
- 修改 **col1** 列的类型为 BIGINT（Value 列）：

  ALTER TABLE example_db.my_table MODIFY COLUMN col1 BIGINT MAX DEFAULT "1";
- 删除 **col1** 列：

  ALTER TABLE example_db.my_table DROP COLUMN col1;

非聚合模型示例

- 在 **col1** 列后添加 **new_col** 列（添加 Key 列）：

  ALTER TABLE example_db.my_table ADD COLUMN new_col INT KEY DEFAULT "0" AFTER col1;
- 在 **col1** 列后添加 **new_col** 列（添加 Value 列）：

  ALTER TABLE example_db.my_table ADD COLUMN new_col INT DEFAULT "0" AFTER col1;
- 修改 **col1** 列的类型为 BIGINT（Key 列）：

  ALTER TABLE example_db.my_table MODIFY COLUMN col1 BIGINT KEY DEFAULT "1";
- 修改 **col1** 列的类型为 BIGINT（Value 列）：

  ALTER TABLE example_db.my_table MODIFY COLUMN col1 BIGINT DEFAULT "1";
- 删除 **col1** 列：

  ALTER TABLE example_db.my_table DROP COLUMN col1;

5.7.5 删除表

本章节主要介绍 Doris 删除表的 SQL 基本语法和使用说明。

基本语法

DROP TABLE [IF EXISTS] [db_name.]*table_name* [FORCE]**;**

使用示例

- 删除表 **my_table**：

DROP TABLE IF EXISTS example_db.my_table;

5.8 备份恢复 Doris 数据

5.8.1 备份 Doris 数据

Doris 支持将当前数据以文件的形式，通过 Broker 备份到远端存储系统中。可实现将 Doris 数据定期进行快照备份及数据迁移操作。

说明

- 备份恢复相关的操作目前只允许拥有 **ADMIN** 权限的用户执行。
- 一个 DataBase 内，只允许有一个正在执行的备份作业。
- Doris 数据备份支持最小分区（Partition）级别的操作，当表的数据量很大时，建议按分区分别执行，以降低失败重试的代价。
- 因为备份恢复操作，操作的都是实际的数据文件。所以当一个表的分片过多，或者一个分片有过多的小版本时，可能即使总数据量很小，依然需要备份很长时间。
- 当通过 **SHOW BACKUP** 或者 **SHOW RESTORE** 命令查看作业状态时，有可能会在 TaskErrMsg 列中看到错误信息，只要 **State** 列不为 **CANCELLED**，则说明作业依然在继续。这些 Task 有可能会重试成功，但有些 Task 错误，会导致作业失败。

数据备份原理介绍

备份操作是将指定表或分区的数据，直接以 Doris 存储的文件的形式，上传到远端仓库中进行存储。当用户提交 Backup 请求后，系统内部会做如下操作：

1. 快照及快照上传

   备份都是对快照进行操作，快照阶段会对指定的表或分区数据文件进行快照。快照只是对当前数据文件产生一个硬链，耗时较少。快照后，对表进行的更改、导入等操作都不再影响备份的结果。快照完成后，系统会开始对这些快照文件进行逐一上传，由各个 Backend 并发完成。

2. 元数据准备及上传

   数据文件快照上传完成后，Frontend 会首先将对应元数据写成本地文件，然后通过 Broker 将本地元数据文件上传到远端仓库，完成备份作业操作。

说明

- 如果备份的表是动态分区表，备份之后会自动禁用动态分区属性，在执行数据恢复操作前需手动将该表的动态分区属性启用，命令为：

  ALTER TABLE *tbl1* **SET ("dynamic_partition.enable"="true")**

- 数据备份操作不会保留表的 **colocate_with** 属性。

前提条件

- 已创建包含 Doris 服务的集群，集群内各服务运行正常。
- 待连接 Doris 数据库的节点与 MRS 集群网络互通。
- 已安装 MySQL 客户端，相关操作可参考 5.1 安装 MySQL 客户端章节。
- 创建具有 Doris 管理权限的用户。

- 集群已启用 Kerberos 认证（安全模式）

  在 FusionInsight Manager 中创建一个人机用户，例如“dorisuser”，创建一个拥有“Doris 管理员权限”的角色绑定给该用户。

  使用新建的用户 **dorisuser** 重新登录 FusionInsight Manager，修改该用户初始密码。
- 集群未启用 Kerberos 认证（普通模式）

  使用 **admin** 用户连接 Doris 后，创建具有管理员权限的角色并绑定给用户。

备份 Doris 数据

步骤 1 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

步骤 2 执行以下命令在 HDFS 中创建一个远程仓库 **example_repo**：

集群已启用 Kerberos 认证（安全模式）

```
CREATE REPOSITORY `example_repo`
WITH BROKER `hdfs_broker`
ON LOCATION "hdfs://hadoop-name-node:25000/path/to/repo/"
PROPERTIES
(
"hadoop.security.authentication"="kerberos",
"kerberos_principal"="doris/hadoop.hadoop.com@HADOOP.COM",
"kerberos_keytab"="/opt/xxx/Bigdata/FusionInsight_Doris_8.3.0/install/FusionInsight-Doris-1.2.3/doris-fe/bin/doris.keytab"
);
```

集群未启用 Kerberos 认证（普通模式）

```
CREATE REPOSITORY `example_repo`
WITH BROKER `hdfs_broker`
ON LOCATION "hdfs://hadoop-name-node:25000/path/to/repo/"
```

PROPERTIES

(

"username" = "hdfs",

"password" = ""

);

步骤 3 查看已经创建的仓库：

SHOW REPOSITORIES;

步骤 4 备份数据到 **example_repo** 中，可备份表数据也可以备份分区数据，例如：

- 全量备份 **example_db** 中的表 **example_tbl** 数据到 **example_repo** 中：

  BACKUP SNAPSHOT example_db.snapshot_label1

  TO example_repo

  ON (example_tbl)

  PROPERTIES ("type" = "full");

- 全量备份 **example_db** 中的表 **example_tbl** 的 **p1**、**p2** 分区，以及表 **example_tbl2** 到 **example_repo** 中：

  BACKUP SNAPSHOT example_db.snapshot_label2

  TO example_repo

  ON

  (

  example_tbl PARTITION (p1,p2),

  example_tbl2

  );

步骤 5 执行以下命令查看 backup 作业的执行情况：

show BACKUP;

步骤 6 在远端仓库中查看备份是否成功。

SHOW SNAPSHOT ON example_repo WHERE SNAPSHOT = "snapshot_label1";

```
+-----------------+---------------------+--------+
| Snapshot        | Timestamp           | Status |
+-----------------+---------------------+--------+
| snapshot_label1 | 2022-04-08-15-52-29 | OK     |
+-----------------+---------------------+--------+
1 row in set (0.15 sec)
```

----结束

5.8.2 恢复 Doris 数据

Doris 支持将当前数据以文件的形式，通过 Broker 备份到远端存储系统中。再通过恢复命令，从远端存储系统中将数据恢复到任意 Doris 集群中。可实现将 Doris 数据定期进行快照备份及数据迁移操作。

说明

- 备份恢复相关的操作目前只允许拥有 **ADMIN** 权限的用户执行。
- 一个 DataBase 内，只允许有一个正在执行的恢复作业。
- Doris 数据恢复支持最小分区（Partition）级别的操作，当表的数据量很大时，建议按分区分别执行，以降低失败重试的代价。
- 因为备份恢复操作，操作的都是实际的数据文件。所以当一个表的分片过多，或者一个分片有过多的小版本时，可能即使总数据量很小，依然需要恢复很长时间。
- 当通过 **SHOW BACKUP** 或者 **SHOW RESTORE** 命令查看作业状态时，有可能会在 TaskErrMsg 列中看到错误信息，只要 **State** 列不为 **CANCELLED**，则说明作业依然在继续。这些 Task 有可能会重试成功，但有些 Task 错误，会导致作业失败。
- 如果恢复作业是一次覆盖操作（指定恢复数据到已经存在的表或分区中），那么从恢复作业的 COMMIT 阶段开始，当前集群上被覆盖的数据有可能不再被还原。如果恢复作业失败或被取消，有可能造成之前的数据损坏且无法访问。这种情况下，只能通过再次执行恢复操作，并等待作业完成。因此，不推荐使用覆盖的方式恢复数据，除非确认当前数据已不再使用。

数据恢复原理介绍

Doris 数据恢复操作需指定一个远端仓库中已存在的备份数据，再将备份数据恢复到本地集群中。当提交 Restore 请求后，系统内部会做如下操作：

1. 在本地创建对应的元数据

   会在本地集群中创建恢复对应的表分区等结构。创建完成后，该表可见，但是不可访问。

2. 本地 snapshot

   将在本地集群中创建的表做一个快照，是一个空快照（刚创建的表没有数据），用于在 Backend 上产生对应的快照目录，接收从远端仓库下载的快照文件。

3. 下载快照

   远端仓库中的快照文件，会被下载到对应的生成的快照目录中，由各个 Backend 并发完成。

4. 生效快照

   快照下载完成后，要将各个快照映射为当前本地表的元数据。然后重新加载这些快照，使之生效，完成最终的恢复作业。

前提条件

- 已创建包含 Doris 服务的集群，集群内各服务运行正常。
- 待连接 Doris 数据库的节点与 MRS 集群网络互通。
- 已安装 MySQL 客户端，相关操作可参考 5.1 安装 MySQL 客户端章节。
- 创建具有 Doris 管理权限的用户。
  - 集群已启用 Kerberos 认证（安全模式）

    在 FusionInsight Manager 中创建一个人机用户，例如“dorisuser”，创建一个拥有“Doris 管理员权限”的角色绑定给该用户。

    使用新建的用户 **dorisuser** 重新登录 FusionInsight Manager，修改该用户初始密码。
  - 集群未启用 Kerberos 认证（普通模式）

使用 **admin** 用户连接 Doris 后，创建具有管理员权限的角色并绑定给用户。

- 已参考 5.8.1 备份 Doris 数据完成备份需要恢复的 Doris 表或分区数据。

恢复 Doris 数据

步骤 1 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

步骤 2 从远端已备份数据的仓库中恢复表或分区数据。例如：

- 从 **example_repo** 中恢复备份 snapshot_label1 中的表 **example_tbl** 到数据库 **example_db2**，时间版本为“2018-05-04-16-45-08”，恢复为 1 个副本：

  RESTORE SNAPSHOT *example_db2*.**`snapshot_label1`**
  FROM `*example_repo*`
  ON (`*example_tbl*` **)**
  PROPERTIES
  (
  "backup_timestamp"="2023-08-16-20-13-55",
  "replication_num" = "1"
  );
  “backup_timestamp”可通过 **SHOW SNAPSHOT ON example_repo WHERE SNAPSHOT = "snapshot_label1";**命令获取。

- 从 **example_repo** 中恢复备份 **snapshot_label2** 中的表 **example_tbl** 的分区 **p1** 和 **p2**，以及恢复表 **example_tbl2** 到数据库 **example_db1**，并重命名为 **new_tbl**，时间版本为“2018-05-04-17-11-01”，默认恢复为 3 个副本：

  RESTORE SNAPSHOT *example_db1*.`*snapshot_2*`
  FROM `*example_repo*`
  ON
  (
  `*backup_tbl*` **PARTITION (**`*p1*`, `*p2*`**),**
  `*backup_tbl2*` **AS** `*new_tbl*`
)
  PROPERTIES
  (

"backup_timestamp"="2023-08-16-20-13-55**"**

);

注意：backup_timestamp 可通过 **SHOW SNAPSHOT ON example_repo WHERE SNAPSHOT = "snapshot_label1";**命令获取

步骤 3 执行以下命令查看恢复作业的执行情况：

SHOW RESTORE\G;

----结束

5.9 Hive 数据源分析

5.9.1 多源数据目录

多源数据目录旨在能够更方便对接外部数据目录，以增强 Doris 的数据湖分析和联邦数据查询能力。

多源数据目录功能在原有的元数据层级上，新增一层 Catalog，构成 Catalog -> Database -> Table 的三层元数据层级。其中，Catalog 可以直接对应到外部数据目录。

基础概念

- Internal Catalog

  Doris 原有的 Database 和 Table 都将归属于 Internal Catalog。Internal Catalog 是内置的默认 Catalog，用户不可修改或删除。

- External Catalog

  可以通过 **CREATE CATALOG** 命令创建一个 External Catalog，创建后，可以通过 **SHOW CATALOGS** 命令查看已创建的 Catalog。

- 切换 Catalog

  用户登录 Doris 后，默认进入 Internal Catalog，因此默认的使用和之前版本并无差别，可以直接使用 **SHOW DATABASES**，**USE DB** 等命令查看和切换数据库。

  用户可以通过 SWITCH 命令切换 Catalog，例如：

  ```
  SWITCH internal;
  SWITCH hive_catalog;
  ```

  切换后，可以直接通过 **SHOW DATABASES**，**USE DB** 等命令查看和切换对应 Catalog 中的 Database。Doris 会自动同步 Catalog 中的 Database 和 Table。用户可以像使用 Internal Catalog 一样，对 External Catalog 中的数据进行查看和访问。

  当前，Doris 只支持对 External Catalog 中的数据进行只读访问。

- 删除 Catalog

  External Catalog 中的 Database 和 Table 都是只读的。但是可以删除 Catalog（Internal Catalog 无法删除）。可以通过 **DROP CATALOG** 命令删除一个 External Catalog。

  该操作仅会删除 Doris 中该 Catalog 的映射信息，并不会修改或变更任何外部数据目录的内容。

- Resource

Resource 是一组配置的集合。用户可以通过 CREATE RESOURCE 命令创建一个 Resource，之后可以在创建 Catalog 时使用这个 Resource。

一个 Resource 可以被多个 Catalog 使用，以复用其中的配置。

5.9.2 Hive 数据源

通过连接 Hive Metastore，或者兼容 Hive Metatore 的元数据服务，Doris 可以自动获取 Hive 的库表信息，并进行数据查询。

除 Hive 外，很多其他系统也会使用 Hive Metastore 存储元数据。通过 Hive Catalog，不仅能访问 Hive，也能访问使用 Hive Metastore 作为元数据存储的系统，例如 Iceberg、Hudi 等。

说明

- 支持 Managed Table。
- 可以识别 Hive Metastore 中存储的 Hive 和 Hudi 元数据。
- 若想访问非当前用户创建的 Catalog，需授予用户 Catalog 所在的 OBS 路径的操作权限。
- Hive 表格式仅支持 Parquet、ORC、TextFile。

前提条件

- 已创建包含 Doris 服务的集群，集群内各服务运行正常。
- 待连接 Doris 数据库的节点与 MRS 集群网络互通。
- 创建具有 Doris 管理权限的用户。
  - 集群已启用 Kerberos 认证（安全模式）

    在 FusionInsight Manager 中创建一个人机用户，例如“dorisuser”，创建一个拥有“Doris 管理员权限”的角色绑定给该用户。

    使用新建的用户 **dorisuser** 重新登录 FusionInsight Manager，修改该用户初始密码。
  - 集群未启用 Kerberos 认证（普通模式）

    使用 **admin** 用户连接 Doris 后，创建具有管理员权限的角色并绑定给用户。
- 已安装 MySQL 客户端，相关操作可参考 5.1 安装 MySQL 客户端。

Hive 表操作

步骤 1 若需使用 Doris 读取 Hive 存储在 OBS 中的数据时，需执行以下操作。

1. 登录天翼云管理控制台，在“控制台”页面，鼠标移动至右上方的用户名，在下拉列表中选择“我的凭证”。
2. 单击“访问密钥”页签，单击“新增访问密钥”，输入验证码或密码。单击“确定”，生成并下载访问密钥。

   在.csv 文件中获取创建 Catalog 所需的 AWS_ACCESS_KEY、AWS_SECRET_KEY 参数值，对应关系为：
   - AWS_ACCESS_KEY 参数值为.csv 文件中“Access Key Id”列的值。
   - AWS_SECRET_KEY 参数值为.csv 文件中“Secret Access Key”列的值。

说明

- 请及时下载保存，弹窗关闭后将无法再次获取该密钥信息，但您可重新创建新的密钥。
- 为了账号安全性，建议您妥善保管并定期修改访问密钥，修改访问密钥的方法为删除旧访问密钥，然后重新生成。

3. 创建 Catalog 所需的 AWS_REGION 可在获取。
4. 登录“对象存储服务 OBS”管理控制台，单击“并行文件系统”，单击 Hive 表所在的 OBS 并行文件系统名称，在概览界面查看“Endpoint”参数值，该值为创建 Catalog 时设置 AWS_ENDPOINT 参数的值。

步骤 2 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

步骤 3 创建 Catalog。

- Hive 表数据存储在 HDFS 中，执行以下命令创建 Catalog：
  - 集群已启用 Kerberos 认证（安全模式）：

    CREATE CATALOG hive_catalog PROPERTIES (

    'type'='hms',

    'hive.metastore.uris' = 'thrift://*192.168.67.161:21088***',**

    'hive.metastore.sasl.enabled' = 'true',

    'hive.server2.thrift.sasl.qop' = 'auth-conf',

    'hive.server2.authentication' = 'KERBEROS',

    'dfs.nameservices'='hacluster',

    'dfs.ha.namenodes.hacluster'='*24,25***',**

    'dfs.namenode.rpc-address.hacluster.*24***'='***主 NameNodeIP 地址:RPC 通信端口***',**

    'dfs.namenode.rpc-address.hacluster.*25***'='***主 NameNodeIP 地址:RPC 通信端口***',**

    'dfs.client.failover.proxy.provider.hacluster'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider',

    'hive.version' = '3.1.0',

    'yarn.resourcemanager.address' = '*192.168.67.78:26004***',**

    'yarn.resourcemanager.principal' = 'mapred/hadoop.hadoop.com@HADOOP.COM',

    'hive.metastore.kerberos.principal' = 'hive/hadoop.hadoop.com@HADOOP.COM',

'hadoop.security.authentication' = 'kerberos',

'hadoop.kerberos.keytab' = '${BIGDATA_HOME}/FusionInsight_Doris_8.3.0/install/FusionInsight-Doris-1.2.3/doris-be/bin/doris.keytab',

'hadoop.kerberos.principal' = 'doris/hadoop.hadoop.com@HADOOP.COM',

'java.security.krb5.conf' = '${BIGDATA_HOME}/FusionInsight_BASE_*/1_16_KerberosClient/etc/krb5.conf',

'hadoop.rpc.protection' = 'privacy'

);

- 集群未启用 Kerberos 认证（普通模式）：

CREATE CATALOG hive_catalog PROPERTIES (

'type'='hms',

'hive.metastore.uris' = 'thrift://*192.168.67.161:21088***',**

'hive.version' = '3.1.0',

'hadoop.username' = 'hive',

'yarn.resourcemanager.address' = '*192.168.67.78:26004***',**

'dfs.nameservices'='hacluster',

'dfs.ha.namenodes.hacluster'='24,25',

'dfs.namenode.rpc-address.hacluster.24'='192-168-67-172:25000',

'dfs.namenode.rpc-address.hacluster.25'='192-168-67-78:25000',

'dfs.client.failover.proxy.provider.hacluster'='org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider'

);

说明

- hive.metastore.uris：Hive MetaStore 的 URL，格式为“**thrift://**<Hive MetaStore 的 IP 地址>**:**<端口号>”，支持多个值，以逗号分隔。
- dfs.nameservices：集群 NameService 名称。可在 NameNode 所在节点的“${BIGDATA_HOME}/FusionInsight_HD_*/1_*_NameNode/etc”目录下的“hdfs-site.xml”中查找该配置项的值。
- dfs.ha.namenodes.hacluster：集群 NameService 前缀，包含两个值。可在 NameNode 所在节点的“${BIGDATA_HOME}/FusionInsight_HD_*/1_*_NameNode/etc”目录下的“hdfs-site.xml”中查找该配置项的值。
- dfs.namenode.rpc-address.hacluster.*xx1*：主 NameNode 的 RPC 通信地址。可在 NameNode 所在节点的“${BIGDATA_HOME}/FusionInsight_HD_*/1_*_NameNode/etc”目录下的“hdfs-site.xml”中查找该配置项的值，*xx* 为“dfs.ha.namenodes.hacluster”参数的值。
- dfs.namenode.rpc-address.hacluster.*xx2*：备 NameNode 的 RPC 通信地址。可在 NameNode 所在节点的“${BIGDATA_HOME}/FusionInsight_HD_*/1_*_NameNode/etc”目录下的“hdfs-site.xml”中查找该配置项的值，*xx* 为“dfs.ha.namenodes.hacluster”参数的值。
- dfs.client.failover.proxy.provider.hacluster：指定 HDFS 客户端连接集群中 Active 状态节点的 Java 类。值为“org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider”。
- hive.version：Hive 版本。可在 Manager 界面，选择“集群 > 服务 > Hive”，在概览页面查看“版本”获取。
- yarn.resourcemanager.address：主 ResourceManager 实例的 IP 地址。可在 Manager 界面，选择“集群 > 服务 > Yarn > 实例”，查看主 ResourceManager 实例的业务 IP 地址。

- hadoop.rpc.protection：设置 Hadoop 中各模块的 RPC 通道是否加密，默认为“privacy”。可在 Manager 界面，选择“集群 > 服务 > HDFS > 配置”，搜索“hadoop.rpc.protection”获取。
- 集群已启用 Kerberos 认证（安全模式）：
- hive.metastore.sasl.enabled：MetaStore 的管理权限开关。值为“true”。
- hive.server2.thrift.sasl.qop：HiveServer2 和客户端交互是否加密传输，值为“auth-conf”。
- hive.server2.authentication：访问 HiveServer 的安全认证方式，值为“KERBEROS”。
- yarn.resourcemanager.principal：访问 Yarn 集群的 Principal，值为“mapred/hadoop.hadoop.com@HADOOP.COM”。
- hive.metastore.kerberos.principal：访问 Hive 集群的 Principal，值为“hive/hadoop.hadoop.com@HADOOP.COM”。
- hadoop.security.authentication：访问 Hadoop 的安全认证方式，值为“KERBEROS”。
- hadoop.kerberos.keytab：访问 Hadoop 集群的 keytab，值为“${BIGDATA_HOME}/FusionInsight_Doris_*/install/FusionInsight-Doris-*/doris-be/bin/doris.keytab”文件所在的具体路径。
- hadoop.kerberos.principal：访问 Hadoop 集群的 Principal，值为“doris/hadoop.hadoop.com@HADOOP.COM”。
- java.security.krb5.conf：krb5 文件，值为“${BIGDATA_HOME}/FusionInsight_BASE_*/1_*_KerberosClient/etc/krb5.conf”文件所在的具体路径。
- 集群未启用 Kerberos 认证（普通模式）：

  hadoop.username：访问 Hadoop 集群的用户名，值为“hdfs”。

- Hive 表数据存储在 OBS 中，执行以下命令创建 Catalog，相关参数值请参见步骤 1 获取：

  CREATE CATALOG *hive_obs_catalog* **PROPERTIES (**
  'type'='hms',
  'hive.version' = '3.1.0',
  'hive.metastore.uris' = 'thrift://*192.168.67.161:21088***',**
  'AWS_ACCESS_KEY' = '*AK***',**
  'AWS_SECRET_KEY' = '*SK***',**
  'AWS_ENDPOINT' = '*OBS 并行文件系统的 Endpoint 地址***',**
  'AWS_REGION' = '*sa-fb-1***'**
  );

步骤 4 查询 Hive 表：

- 执行以下命令查询 catalogs：

  show catalogs;

- 执行以下命令查询 catalog 下面的库：

  show databases from *hive_catalog***;**

- 执行以下命令切换 Catalog 下，在进入到数据库中：

  switch *hive_catalog***;**
  use *default***;**

- 查询 Catalog 中某个库的所有表：

  show tables from \`*hive_catalog*\`.\`*default*\`**;**
  查询指定表：

select * from `*hive_catalog*`.`*default*`.`*test_table*`;

执行以下命令查看表的 Schema：

DESC *test_table*;

步骤 5 新建或操作 Hive 表后，需要在 Doris 中执行刷新：

refresh catalog *hive_catalog*;

步骤 6 执行以下命令与其他数据目录中的表进行关联查询：

SELECT h.h_shipdate FROM *hive_catalog.default.htable* **h WHERE h.h_partkey IN (SELECT p_partkey FROM internal.db1.part) LIMIT 10;**

说明

- 通过 **catalog.database.table** 全限定的方式标识一张表，如：internal.db1.part。
- 其中 **catalog** 和 **database** 可以省略，缺省使用当前 **SWITCH** 和 **USE** 切换后的 catalog 和 database。
- 可以使用 **INSERT INTO** 命令，将 Hive Catalog 中的表数据，插入到 interal catalog 中的内部表，从实现导入外部数据目录数据。

----结束

5.10 生态扩展

5.10.1 Spark Doris Connector

Spark Doris Connector 可以支持通过 Spark 读取 Doris 中存储的数据，也支持通过 Spark 写入数据到 Doris 中。

- 支持从 Doris 中读取数据
- 支持 Spark DataFrame 批量/流式写入 Doris。
- 可以将 Doris 表映射为 DataFrame 或者 RDD，推荐使用 DataFrame。
- 支持在 Doris 端完成数据过滤，减少数据传输量。

前提条件

- 已创建包含 Doris 服务的集群，集群内各服务运行正常。
- 待连接 Doris 数据库的节点与 MRS 集群网络互通。
- 创建具有 Doris 管理权限的用户。
  - 集群已启用 Kerberos 认证（安全模式）

    在 FusionInsight Manager 中创建一个人机用户，例如“dorisuser”，创建一个拥有“Doris 管理员权限”的角色绑定给该用户。

    使用新建的用户 **dorisuser** 重新登录 FusionInsight Manager，修改该用户初始密码。
  - 集群未启用 Kerberos 认证（普通模式）

    使用 **admin** 用户连接 Doris 后，创建具有管理员权限的角色并绑定给用户。
- 已安装 MySQL 客户端，相关操作可参考 5.1 安装 MySQL 客户端。

- 已安装 Spark 客户端。

操作步骤

在 Doris 中创建表并插入数据。

步骤 1 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

步骤 2 执行以下命令创建数据库并切换：

create database if not exists *sparkconnector*;

use *sparkconnector*;

步骤 3 执行以下命令创建表：

CREATE TABLE *spark_connector_test_decimal* **(**

c1 int NOT NULL,

c2 VARCHAR(25) NOT NULL,

c3 VARCHAR(152),

c4 boolean,

c5 tinyint,

c6 smallint,

c7 bigint,

c8 float,

c9 double,

c10 date,

c11 datetime,

c12 char,

c13 largeint,

c14 varchar,

c15 decimal(15, 5)

)

DUPLICATE KEY(`c1`)

COMMENT "OLAP"

DISTRIBUTED BY HASH(`c1`) BUCKETS 1;

步骤 4 分别执行执行以下命令向表中插入数据：

insert into *spark_connector_test_decimal* **values(10000,'aaa','abc',true, 100, 3000, 100000, 1234.567, 12345.678, '2022-12-01','2022-12-01 12:00:00', 'a', 200000, 'g', 1000.12345);**

insert into *spark_connector_test_decimal* **values(10001,'aaa','abc',false, 100, 3000, 100000, 1234.567, 12345.678, '2022-12-01','2022-12-01 12:00:00', 'a', 200000, 'g', 1000.12345);**

insert into *spark_connector_test_decimal* **values(10002,'aaa','abc',True, 100, 3000, 100000, 1234.567, 12345.678, '2022-12-01','2022-12-01 12:00:00', 'a', 200000, 'g', 1000.12345);**

insert into *spark_connector_test_decimal* **values(10003,'aaa','abc',False, 100, 3000, 100000, 1234.567, 12345.678, '2022-12-01','2022-12-01 12:00:00', 'a', 200000, 'g', 1000.12345);**

spark 侧操作。

步骤 5 执行以下命令登录 spark-sql 客户端：

cd *Spark 客户端安装目录*

source bigdata_env

kinit *组件业务用户*（若集群未启用 Kerberos 认证（普通模式）请跳过该操作）

spark-sql --master yarn

步骤 6 执行以下命令创建临时视图：

CREATE TEMPORARY VIEW *spark_doris_decimal*

USING doris

OPTIONS(

"table.identifier"="sparkconnector.spark_connector_test_decimal",

"fenodes"="*FE 实例 IP 地址***:***29991***",**

"user"="*dorisuser***",**

"password"="*用户密码***",**

'doris.enable.https' = 'true',

'doris.ignore.https.ca' = 'true'

);

执行以下命令查询 Doris 表中的数据：

select * from *spark_doris_decimal***;**

执行以下命令向 Doris 表中插入数据：

insert into *spark_doris_decimal* **values(10005,'aaa','abc',False, 100, 3000, 100000, 1234.567, 12345.678, '2022-12-01','2022-12-01 12:00:00', 'a', 200000, 'g', 1000.12345);**

说明

- 切换为 HTTP 后，需要在创建表的 **with** 子句中删除如下配置参数：
- **'doris.enable.https' = 'true'**
- **'doris.ignore.https.ca' = 'true'**
- *29991* 为 FE 服务的 HTTPS 端口，切换为 HTTP 后，需要修改端口号为 29980。可登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置”，在搜索框中搜索“http”查看。

----结束

5.10.2 Flink Doris Connector

Flink Doris Connector 支持通过 Flink 操作（读取、插入、修改、删除）Doris 中存储的数据。

说明

只能对 Unique Key 模型的表进行修改和删除操作。

前提条件

- 已创建包含 Doris 服务的集群，集群内各服务运行正常。
- 待连接 Doris 数据库的节点与 MRS 集群网络互通。
- 创建具有 Doris 管理权限的用户。
  - 集群已启用 Kerberos 认证（安全模式）

    在 FusionInsight Manager 中创建一个人机用户，例如“dorisuser”，创建一个拥有“Doris 管理员权限”的角色绑定给该用户。

    使用新建的用户 **dorisuser** 重新登录 FusionInsight Manager，修改该用户初始密码。
  - 集群未启用 Kerberos 认证（普通模式）

    使用 **admin** 用户连接 Doris 后，创建具有管理员权限的角色并绑定给用户。
- 已安装 MySQL 客户端，相关操作可参考 5.1 安装 MySQL 客户端。
- 已安装 Flink 客户端。

操作步骤

Doris 侧操作。

步骤 1 登录安装了 MySQL 的节点，执行以下命令，连接 Doris 数据库。

若集群已启用 Kerberos 认证（安全模式），需先执行以下命令再连接 Doris 数据库：

export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

说明

- 数据库连接端口为 Doris FE 的查询连接端口，可以通过登录 Manager，单击“集群 > 服务 > Doris > 配置”，查询 Doris 服务的“query_port”参数获取。
- Doris FE 实例 IP 地址可通过登录 MRS 集群的 Manager 界面，单击“集群 > 服务 > Doris > 实例”，查看任一 FE 实例的 IP 地址。
- 用户也可以使用 MySQL 连接软件或者 Doris WebUI 界面连接数据库。

步骤 2 执行以下命令创建数据库并切换：

create database if not exists *testdb*;

use *testdb*;

步骤 3 执行以下命令创建表 **z_test** 并插入数据：

create table *z_test*(**id int, name string) distributed by hash(id) buckets 10;**

insert into *z_test* **values(123, 'aaa'), (234, 'bbb'), (345, 'ccc');**

步骤 4 执行以下命令创建 **z_test_sink_3** 表：

create *table z_test_sink_3*(**id int, name string) distributed by hash(id) buckets 10;**

Flink 侧操作。

步骤 5 以客户端安装用户登录安装了 Flink 客户端的节点，执行以下命令：

cd *客户端安装目录*

source bigdata_env

kinit *组件业务用户*（若集群未启用 Kerberos 认证（普通模式），请跳过该操作）

步骤 6 执行以下命令登录 Flink SQL 客户端：

cd Flink/flink/bin/

sql-client.sh

步骤 7 在 Flink 客户端创建流或批 Flink SQL 作业。例如：

CREATE TABLE *flink_doris_source* **(id INT, name STRING) WITH (**

'connector' = 'doris',

'fenodes' = '*FE 实例 IP 地址***:29991',**

'table.identifier' = 'testdb.z_test',

'username' = '*user***',**

'password' = '*password***',**

'doris.enable.https' = 'true',

'doris.ignore.https.ca' = 'true'

);

CREATE TABLE *flink_doris_sink* **(id INT, name STRING) WITH (**

'connector' = 'doris',

'fenodes' = '*FE 实例 IP 地址***:***29991***',**

'table.identifier' = 'testdb.z_test_sink_3',

'username' = '*user***',**

'password' = '*password***',**

'sink.label-prefix' = 'doris_label_6',

'doris.enable.https' = 'true',

'doris.ignore.https.ca' = 'true'

);

执行以下命令插入数据：

INSERT INTO

flink_doris_sink

select

id,

name

from

flink_doris_source;

说明

- 开启 HTTPS 后，需要在创建表的 **with** 子句中添加如下配置参数：
- **'doris.enable.https' = 'true'**
- **'doris.ignore.https.ca' = 'true'**
- Source 和 Sink 表对应的字段需和 Doris 中表的字段名保持一致。
- *29991* 为 FE 服务的 HTTPS 端口，切换为 HTTP 后，需要修改端口号为 29980。可登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置”，在搜索框中搜索“http”查看。
- 创建 Flink 作业时，username 配置项为 Doris 用户，password 配置项为 Doris 用户密码。

----结束

5.11 Doris 常见问题

5.11.1 数据目录 SSD 和 HDD 的配置导致建表时偶现报错 Failed to find enough host with storage medium and tag

现象描述

建表时偶现报错“Failed to find enough host with storage medium and tag”。

原因分析

Doris 支持一个 BE 节点配置多个存储路径，并支持指定路径的存储介质属性，如 SSD 或 HDD。通常情况下，每块盘配置一个存储路径即可。

若“be.conf”中只配置了 SSD 的介质，而 FE 中参数“default_storage_medium”默认为 HDD，因此建表时会发现没有 HDD 介质的存储而报错。Doris 并不会自动感知存储路径所在磁盘的实际存储介质类型，需要用户在路径配置中显式的表示。“.HDD”和“.SSD”只是用于标识存储目录“相对”的“低速”和“高速”之分，而并不是标识实际的存储介质类型，所以如果 BE 节点上的存储路径没有介质区别，则无需填写后缀。

处理步骤

- 修改 FE 的“default_storage_medium”配置为正确的存储介质，并重启 FE 生效。
- 将“be.conf”中 SSD 的显式配置删除。
- 创建表时增加 properties 参数“properties {"storage_medium" = "ssd"}”。

5.11.2 多副本场景下，如果有部分副本丢失损坏，查询时如果运行在副本丢失的 Be 节点，查询报错

现象描述

若多个副本直接从磁盘上丢失了副本，比如 **mv** 改名，内核不会感知到该副本丢失，执行查询时如果请求运行在副本丢失的 BE 节点，报错：

```
mysql>
mysql> select * from liudan_test.expamle_tbl;
ERROR 1105 (HY000): errCode = 2, detailMessage = (192.168.67.78)[INTERNAL_ERROR]failed to initialize storage reader. tablet=11016.910825491.a24ccddc5bc24f38-8b80a5af4a99a6a7, res=[E-3109], backend
=192.168.67.78
mysql>
```

处理步骤

步骤 1 登录安装了 MySQL 的节点，连接 Doris 数据库。

步骤 2 调用 BE 的 **check_tablet_segment_lost** 请求自动修复丢失的副本。

curl -X POST http://*192.168.67.78:29986***/api/check_tablet_segment_lost?repair=true**
（

192.168.67.78 为异常的 BE 节点 IP 地址，*29986* 为 BE 的 HTTP Server 的服务端口，可在 Manger 的 Doris 配置界面搜索“webserver_port”查看。

```
[root@192-168-64-78 opt]# curl -X POST http://192.168.67.78:29986/api/check_tablet_segment_lost?repair=true
{"status":"Success","msg":"Succeed to check all tablet segment","num":1,"bad_tablets":[11016],"set_bad":"true","host":"192.168.67.78"}[root@192-168-64-78 opt]#
```

步骤 3 执行以下命令，获取 DetailCmd。

show tablet *tabletId*

```
mysql>
mysql> show tablet 11016;
+-----------------------+-----------+---------------+-----------+-------+---------+-------------+---------+--------+-------+-----------------------------------------------------------------------------+
| DbName                | TableName | PartitionName | IndexName | DbId  | TableId | PartitionId | IndexId | IsSync | Order | DetailCmd                                                                   |
+-----------------------+-----------+---------------+-----------+-------+---------+-------------+---------+--------+-------+-----------------------------------------------------------------------------+
| default_cluster:liudan_test | expamle_tbl | expamle_tbl | expamle_tbl | 11001 | 11014 | 11013 | 11015 | true | 0 | SHOW PROC '/dbs/11001/11014/partitions/11013/11015/11016'; |
+-----------------------+-----------+---------------+-----------+-------+---------+-------------+---------+--------+-------+-----------------------------------------------------------------------------+
```

步骤 4 执行 DetailCmd，当异常节点的副本已经被移除时，再次进行业务查询正常即可。

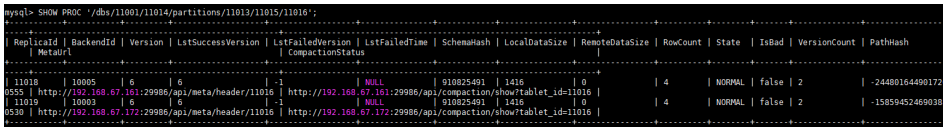

----结束

5.11.3 使用 Stream Load 时报 RPC 超时错误

问题现象

导入数据时 BE 打开 tablet writer 的 RPC 超时，报错：

```
failed to open tablet writer, error=RPC call is timeout, error_text=[E1008] Reached timeout=xxx ms
```

原因分析

由于导入数据时 BE 打开 tablet writer 操作可能涉及多个分片内存块的写盘操作，导致 RPC 超时，可以适当调整该 RPC 超时时间减少超时错误。

操作步骤

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置 > 全部配置”

步骤 2 在左侧导航栏选择“BE（角色） > 自定义”，在自定义参数“be.conf.customized.configs”中新增自定义参数项“tablet_writer_open_rpc_timeout_sec”，参数值为 RPC 超时时间，默认值为“60”，可适当调大该参数值，例如，可将该参数值设置为“300”。

步骤 3 单击“实例”，勾选所有的 BE 实例，选择“更多 > 重启实例”，重启 BE 实例。

----结束

5.11.4 FE 服务故障恢复

问题现象

FE 可能因为某些原因出现无法启动 bdbje、FE 之间无法同步等问题，无法进行元数据写操作、没有 MASTER 等。需要手动操作来恢复 FE，手动恢复 FE 先通过当前“meta_dir”中的元数据，启动一个新的 MASTER，然后再逐台添加其他 FE。

操作步骤

步骤 1 结束所有 FE 进程，同时结束所有业务访问，保证在元数据恢复期间不受外部访问出现不可预期的问题。

步骤 2 查找 FE 所有实例节点上元数据，找到最新的一个节点 FE，作为恢复的 Master。

1. 进入 FE 后台节点，查看配置文件“${BIGDATA_HOME}/FusionInsight_Doris_x.x.x/x_x_FE/etc/fe.conf”中参数“meta_dir”的值，该值即为元数据存储目录
2. 寻找所有 FE 的元数据存储目录，查看此存储目录下子文件“image/image.*xxxx*”，其中“image.*xxxx*”后面的数字越大表示元数据越新，找到最新的一个 FE，作为即将首个恢复的 FE，即 Master。
3. 备份所有 FE 的元数据存储目录。

   例如，元数据存储目录为“/srv/BigData/doris_fe/doris-meta”，执行以下命令进行备份：

   cp -r /srv/BigData/doris_fe/doris-meta /srv/BigData/doris_fe/doris-meta.bak

步骤 3 进入步骤 2 找到的元数据最新的 FE 所在节点（即 Master），添加配置“metadata_failure_recovery=true”到“${BIGDATA_HOME}/FusionInsight_Doris_x.x.x/x_x_FE/etc/fe.conf”中，如果存在“${BIGDATA_HOME}/FusionInsight_Doris_x.x.x/x_x_FE_UPDATE”目录，则需要在“x_x_FE_UPDATE 下 fe.conf”中也添加该配置。

步骤 4 登录 FusionInsight Manager 页面，选择“集群 > 服务 > 实例”，勾选步骤 3 修改配置的 FE 节点，选择“更多 > 重启实例”重启 FE 实例，其他实例依旧停止状态不做操作。

步骤 5 观察 FE 启动后状态，启动成功后，在浏览器中连接此 FE，例如，访问地址为“http://*192.168.67.27*:*29980*”。

登录 FE WebUI 界面后，单击“Playground”，选择“default_cluster:information_schema”，在右侧命令框中输入 **show frontends** 命令，单击“Excute”，若“Results”列表中当前 FE 的“Alive”列的值为“true”，表示此 FE 已经恢复正常：

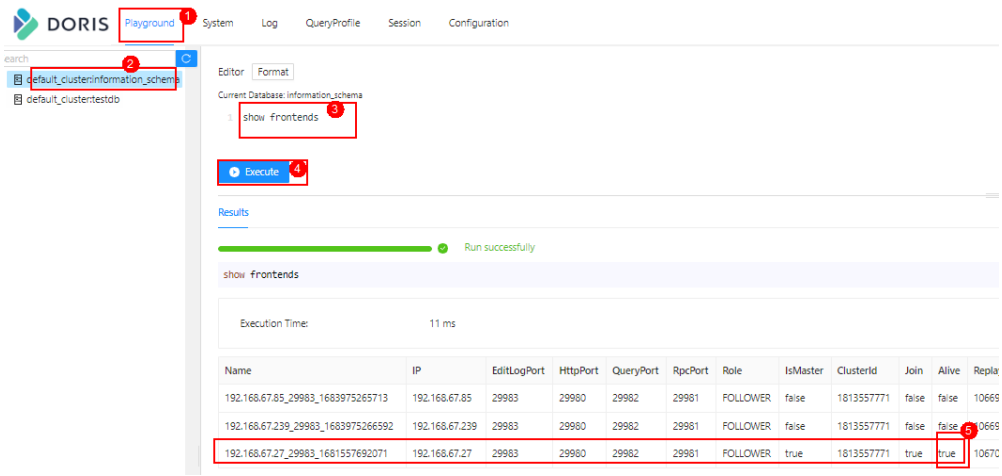

步骤 6 在 FusionInsight Manager 页面，选择“集群 > 服务 > 实例”，勾选非 Master 且运行状态为未启动的 FE 实例，选择“更多 > 删除实例”：

步骤 7 删除成功后，单击“添加实例”，重新添加步骤 6 删除了的 FE 实例。

步骤 8 勾选配置过期的实例，选择“更多 > 重启实例”重启配置过期的 FE 实例，删除手动在 FE 所在节点上的“fe.conf”中添加的参数“metadata_failure_recovery”。

步骤 9 检查集群是否已经正常运行，并在 FE WebUI 中执行命令检查 FE、BE、DBroker 进程是否健康且都在一个集群中，查询结果中“Results”列表中所有实例的“Alive”列的值为“true”则表示进程健康：

例如，以下命令都在 Doris WebUI 界面的“Playground”的“default_cluster:information_schema”中执行：

- 执行以下命令检查 FE 进程是否都健康：

  show frontends;

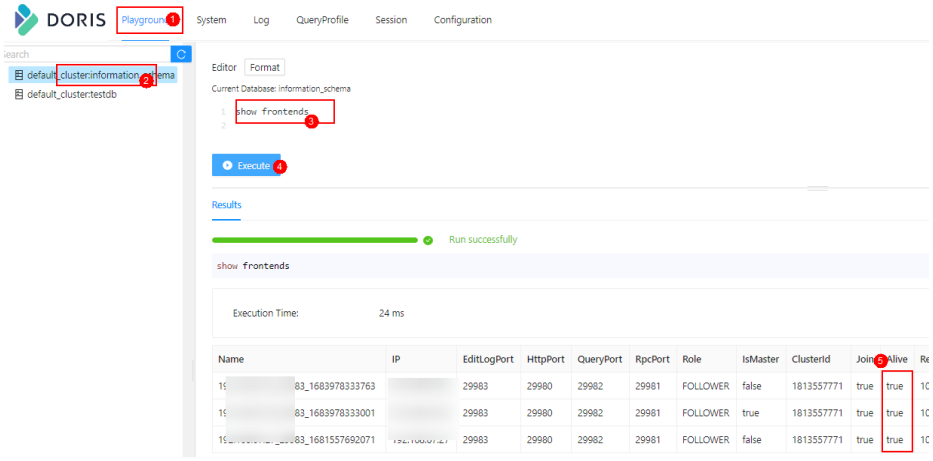

- 执行以下命令检查 BE 进程是否都健康：

  show backends;

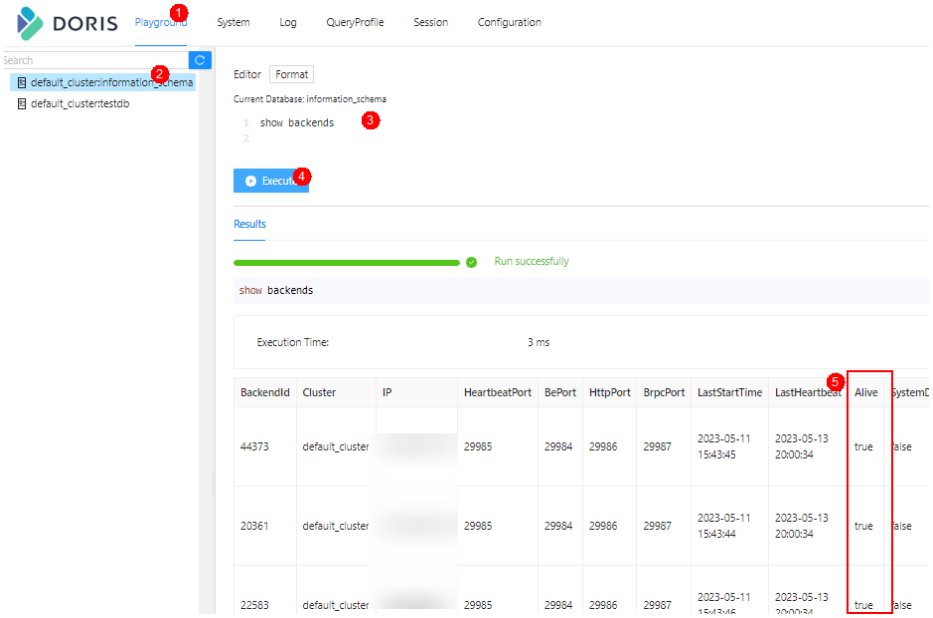

- 执行以下命令检查 DBroker 进程是否都健康：

  show broker;

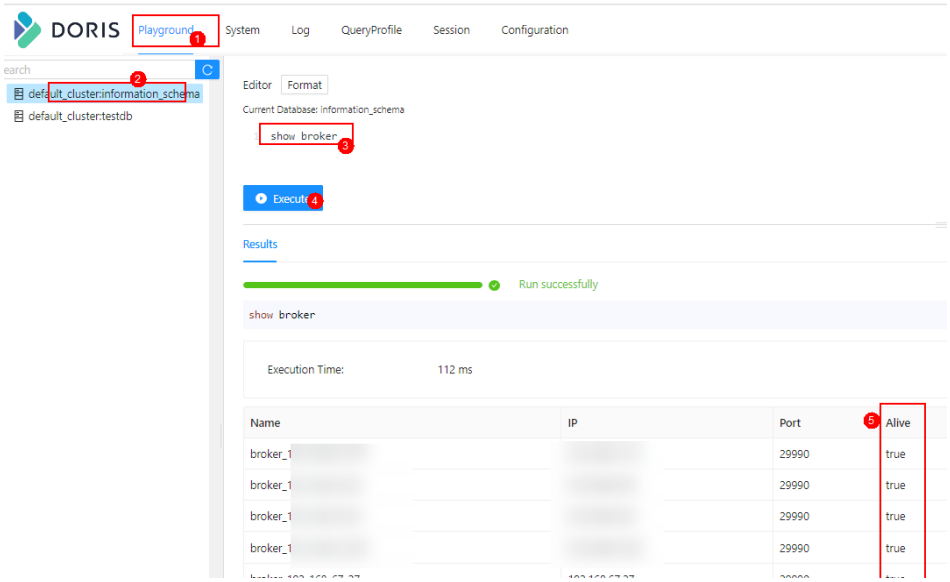

----结束

5.11.5 使用 MySQL 客户端连接 Doris 数据库时报错“plugin not enabled”如何处理

问题现象

使用 MySQL 客户端连接 Doris 数据库时报错：

```
ERROR 2059 (HY000): Authentication plugin 'mysql_clear_password' cannot be loaded:
plugin not enabled
```

原因分析

未启用 mysql_clear_password 插件。

操作步骤

- 使用 MySQL 客户端连接 Doris 数据库时，在命令中新增“--enable-cleartext-plugin”，命令如下：

  mysql --enable-cleartext-plugin -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址*

- 在安装了 MySQL 客户端的节点执行以下命令启用 mysql_clear_password 插件，再重新连接 Doris 即可。

  export LIBMYSQL_ENABLE_CLEARTEXT_PLUGIN=1

5.11.6 FE 启动失败

现象描述

FE 实例启动失败，“/var/log/Bigdata/doris/fe/fe.log”日志中一直滚动报错：

```
wait catalog to be ready. FE type UNKNOWN
```

原因分析

- FE 安装节点有多个网卡 IP，没有正确设置“priority_network”参数导致 FE 启动时匹配了错误的 IP 地址。
- 集群内多数 Follower FE 节点未启动，例如有 3 个 Follower FE，只启动了一个。

处理步骤

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置”。

步骤 2 搜索“priority_network”参数，并正确设置 FE 的该参数值，FE 节点已绑定的网卡 IP 可通过“*FE 安装目录*/FusionInsight_Doris_*/1_*_FE/etc/ENV_VARS”中的“CURRENT_INSTANCE_IP”变量查看。

“priority_network”主要用于帮助系统选择正确的网卡 IP 作为 FE 或 BE 的 IP，建议任何情况下，都显式的设置该参数，避免后续机器增加新网卡导致 IP 选择不正确问题。“priority_network”的值是 CIDR 格式表示的，用于保证所有节点都可以使用统一的配置值。参数值分为两部分，第一部分是点分十进制的 IP 地址，第二部分是一个前缀长度。

例如，10.168.1.0/8 会匹配所有 10.xx.xx.xx 的 IP 地址；10.168.1.0/16 会匹配所有 10.168.xx.xx 的 IP 地址；若有两个节点：10.168.10.1 和 10.168.10.2，则可以使用 10.168.10.0/24 来作为 “priority_network”的值。

步骤 3 单击“实例”，勾选需启动的 Follower FE，单击“启动实例”。例如有 3 个 Follower，只启动了一个，此时需要将另外至少一个 FE 也启动，FE 可选举组才能选举出 Master 提供服务。

步骤 4 若 FE 依然启动失败，请运维进行恢复。

----结束

5.11.7 BE 匹配错误 IP 导致启动失败

现象描述

BE 实例启动失败，报错：

```
backend ip saved in master does not equal to backend local ipx.x.x.x vs. x.x.x.x
```

原因分析

BE 安装节点有多个网卡 IP，没有正确设置“priority_network”参数值导致 BE 启动时匹配了错误的 IP 地址。

处理步骤

步骤 1 登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置”。

步骤 2 搜索“priority_network”参数，并正确设置 BE 的该参数值，BE 节点已绑定的网卡 IP 可通过“*BE 安装目录*/FusionInsight_Doris_*/1_*_BE/etc/ENV_VARS”中的“CURRENT_INSTANCE_IP”变量查看。

“priority_network”主要用于帮助系统选择正确的网卡 IP 作为 FE 或 BE 的 IP，建议任何情况下，都显式的设置该参数，避免后续机器增加新网卡导致 IP 选择不正确问题。“priority_network”的值是 CIDR 格式表示的，用于保证所有节点都可以使用统一的配置值。参数值分为两部分，第一部分是点分十进制的 IP 地址，第二部分是一个前缀长度。

例如，10.168.1.0/8 会匹配所有 10.xx.xx.xx 的 IP 地址；10.168.1.0/16 会匹配所有 10.168.xx.xx 的 IP 地址；若有两个节点：10.168.10.1 和 10.168.10.2，则可以使用 10.168.10.0/24 来作为 “priority_network”的值。

----结束

5.11.8 MySQL 客户端连接 Doris 报错“Read timed out”

现象描述

在 MySQL 客户端连接 Doris 报错：

```
java.net.SocketTimeoutException: Read timed out
```

原因分析

Doris 服务端响应较慢。

处理步骤

使用 MySQL 客户端连接 Doris 数据库时，在命令中新增“connect_timeout”参数，默认值为 10 秒，命令如下：

mysql -u *数据库登录用户* **-p** *数据库登录用户密码* **-P** *数据库连接端口* **-h***Doris FE 实例 IP 地址* **--connect_timeout=***120*

5.11.9 BE 运行数据导入或查询任务报错

现象描述

导入或查询数据时，报错：

```
Not connected to 192.168.100.1:8060 yet, server_id=384
```

原因分析

- 运行任务的 BE 节点宕机。
- RPC 拥塞或其他错误。

处理步骤

- 若运行任务的 BE 节点宕机，需查看具体的宕机原因再进行解决。
- 若 RPC 源端有大量未发送的数据超过了阈值，可设置如下参数：
  - **brpc_socket_max_unwritten_bytes**：用于设置未发送的数据量的阈值，默认为 1GB。若未发送数据量超过该值，则会报 OVERCROWDED 错，可适当调大该值。
  - **tablet_writer_ignore_eovercrowded**：是否忽略数据导入过程中出现的 OVERCROWDED 错误，默认值为“false”。该参数主要用于避免导入失败，以提高导入的稳定性。
  - **max_body_size**：用于设置 RPC 的包大小阈值 ，默认为 3GB。如果查询中带有超大 String 类型，或者 bitmap 类型数据时，可以通过修改该参数规避。

5.11.10 Broker Load 导入数据时报超时错误

现象描述

使用 Broker Load 导入数据时报错：

```
org.apache.thrift.transport.TTransportException: java.net.SocketException: Broken
pipe
```

原因分析

从外部存储（例如 HDFS）导入数据时，由于目录下文件过多，导致列出文件目录超时。

处理步骤

登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置 > 全部配置 > FE（角色） > 自定义”，新增自定义参数“broker_timeout_ms”，默认值为 10 秒，需适当调大该参数值，如 1000，并重启配置过期的 FE 实例。

5.11.11 Broker Load 导入任务的数据量超过阈值

现象描述

使用 Broker Load 导入数据时报错：

```
Scan bytes per broker scanner exceed limit:xxx
```

原因分析

BE 处理的单个导入任务的最大数据量为 3GB，超过该值的待导入文件需要通过调整 Broker Load 的导入参数来实现大文件的导入。

处理步骤

根据当前 BE 实例的个数和待导入文件的大小修改单个 BE 的任务的最大扫描量和最大并发数。操作如下：

1. 登录 FusionInsight Manager，选择“集群 > 服务 > Doris”，在概览界面查看“Leader 所在的主机”的 IP 地址，确认主 FE 所在节点。
2. 单击“实例”，单击 IP 地址为 1 查看到的 BE 实例，选择“实例配置 > 全部配置 BE（角色） > 自定义”，新增如下参数：
   - max_broker_concurrency：值为 BE 节点个数。
   - max_bytes_per_broker_scanner：值为待导入文件大小/BE 节点个数。

   说明

   配置项仅在 Leader FE 的“fe.conf”中修改才会生效。
3. 单击“保存”保存配置，并重启配置过期的实例。

5.11.12 使用 Broker Load 导入数据报错

现象描述

使用 Broker Load 导入数据时报错“failed to send batch”或“TabletWriter add batch with unknown id”。

原因分析

系统并发量较大或数据量大导致任务执行超时。

处理步骤

步骤 1 登录 MySQL 客户端，执行以下命令适当调大“query_timeout”参数值，默认为 300 秒。

SET GLOBAL query_timeout = *xxx*;

步骤 2 登录 FusionInsight Manager，选择“集群 > 服务 > Doris > 配置 > 全部配置 > BE（角色） > 自定义”，新增自定义参数“streaming_load_rpc_max_alive_time_sec”，默认值为 1200 秒，需适当调大该参数值，并重启配置过期的 BE 实例。

----结束

5.12 Doris 日志介绍

日志描述

日志路径：Doris 相关日志的默认存储路径为“/var/log/Bigdata/doris/*角色名*”。

- FE：“/var/log/Bigdata/doris/fe”（运行日志），“/var/log/Bigdata/audit/doris/fe”（审计日志）。
- BE：“/var/log/Bigdata/doris/be”（运行日志）。
- DBroker：“/var/log/Bigdata/doris/dbroker”（运行日志）。

日志归档规则：Doris 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过指定大小的时候（此日志文件大小可进行配置），会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”。最多保留最近的 20 个压缩文件，压缩文件保留个数和压缩文件阈值可以配置。

表5-6 Hive 日志列表

日志类型	日志文件名	描述
运行日志	/fe/fe.out	标准/错误输出的日志（stdout 和 stderr）
	/fe/fe.log	主日志，包括除 fe.out 外的所有内容
	/fe/fe.warn.log	“fe.log”的子集，仅记录级别为 WARN 和 ERROR 的日志
	/fe/fe-omm-<日期>-<PID>-gc.log.<编号>	FE 进程的 GC 日志
	/fe/preStart.log	FE 启动前的工作日志

日志类型	日志文件名	描述
	/fe/check_fe_status.log.log	FE 服务启动是否成功的检查日志
	/fe/cleanup.log	FE 卸载的清理日志
	/fe/start_fe.log	FE 进程启动日志
	/fe/stop_fe.log	FE 进程停止日志
	/fe/postinstallDetail.log	FE 安装后启动前的工作日志
	/be/be.INFO	BE 进程的运行日志
	be.WARNING	“be.log”的子集，仅记录级别为 WARN 和 FATAL 的日志
	/be/be-omm-<日期>-<PID>-gc.log.<编号>	BE 进程的 GC 日志
	/be/postinstallDetail.log	BE 安装后启动前的工作日志
	/be/preStart.log	BE 启动前的工作日志
	/be/cleanup.log	BE 卸载的清理日志
	/be/start_be.log	BE 进程启动日志
	/be/stop_be.log	BE 进程停止日志
	/be/check_be_status.log	BE 服务启动是否成功的检查日志
	/be/be.out	BE 进程标准/错误输出的日志（stdout 和 stderr）
	/dbroker/start_broker.log	DBroker 进程启停正常日志
	/dbroker/stop_broker.log	DBroker 进程启停异常日志
	/dbroker/preStart.log	DBroker 启动前的工作日志
	/dbroker/cleanup.log	DBroker 卸载时或安装前的清理日志
	/dbroker/check_db_status.log	DBroker 服务启动是否成功的检查日志
	/dbroker/dbroker-omm-<日期>-<PID>-gc.log.<编号>	DBroker 进程的 GC 日志
	/dbroker/apache_hdfs_broker.log	DBroker 进程的运行日志
审计日志	fe.audit.log	审计日志，记录 FE 接收的所有 SQL 请求

日志级别

Doris 提供了如表 5-7 所示的日志级别。

运行日志的级别优先级从高到低分别是 FATAL、ERROR、WARN、INFO，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表5-7 日志级别

级别	描述
FATAL	FATAL 通常表示程序断言错误。
ERROR	ERROR 表示系统运行的错误信息。
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息。

如果您需要修改日志级别，请执行如下操作：

步骤 1 登录 FusionInsight Manager 界面，选择“集群 > 服务 > Doris > 配置 > 全部配置”，进入 Doris 服务的全部配置页面。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别并保存。

说明

配置 Doris 日志级别后可立即生效，无需重启服务。

----结束

日志格式

Doris 的日志格式如下所示：

表5-8 日志格式

日志类型	格式	示例
FE 运行日志	<yyyy-MM-dd HH:mm:ss,SSS><LogLevel> (线程名称|线程 ID) <日志事件的发生位置>|<log 中的 message>	2023-04-13 11:17:14,371 INFO (tablet stat mgr|34) [TabletStatMgr.runAfterCatalogReady():125] finished to update index row num of all databases. cost: 0 ms
BE 运行日志	<日志等级，I 表示 INFO，W 表示 WARN，F 表示 FATAL|MMdd HH:mm:ss.SSS> <线程 ID> <日志事件的发生位置> <log 中的 message>	I0413 11:26:03.439189 25248 tablet_manager.cpp:895] begin to build all report tablets info

日志类型	格式	示例
DBroker 运行日志	<MMdd HH:mm:ss.SSS> <线程 ID> <LogLevel><log 中的 message>	2023-04-11 11:43:13 [main:0] - [INFO] starting apache hdfs broker....
审计日志	<yyyy-MM-dd HH:mm:ss,SSS [操作类型]>|<Client>|<User Name>|<Db Name>|<State>|<ErrorCode>|<ErrorMessage>|<Time>|<ScanBytes>|<ScanRows>|<ReturnRows>|<StmtId>|<QueryId>|<IsQuery>|<feIp>| <Stmt>|<CpuTimeMS>|<SqlHash>|<peakMemoryBytes>|<SqlDigest>|<TraceId>|<FuzzyVariables>	2023-04-13 10:49:26,410 [query] |Client=192.168.64.223:44382|User=root|Db=hivedoris|State=ERR|ErrorCode=1105|ErrorMessage=errCode = 2, detailMessage = (192.168.64.78)[INTERNAL_ERROR]failed to init reader for file /user/hive/warehouse/hivedoris.db/test/000000_0, err: [INTERNAL_ERROR]connect to hdfs failed. error: (255), Unknown error 255), reason: NullPointerException: |Time=67|ScanBytes=0|ScanRows=0|ReturnRows=0|StmtId=91|QueryId=e1125283f12c4994-a69e3a323044d681|IsQuery=true|feIp=192.168.64.78|Stmt=select * from test|CpuTimeMS=0|SqlHash=3bbc220823c3e757002fb9490196cf84|peakMemoryBytes=0|SqlDigest=|TraceId=|FuzzyVariables=

6 使用 Flink

6.1 从零开始使用 Flink

本节提供使用 Flink 运行 wordcount 作业的操作指导。

前提条件

- MRS 集群中已安装 Flink 组件。
- 集群正常运行，已安装集群客户端，例如安装目录为“/opt/hadoopclient”。以下操作的客户端目录只是举例，请根据实际安装目录修改。

使用 Flink 客户端

步骤 1 以客户端安装用户，登录安装客户端的节点。

步骤 2 执行以下命令，切换到客户端安装目录。

cd /opt/hadoopclient

步骤 3 执行如下命令初始化环境变量。

source /opt/hadoopclient/bigdata_env

步骤 4 若集群开启 Kerberos 认证，需要执行以下步骤，若集群未开启 Kerberos 认证请跳过该步骤。

1. 准备一个提交 Flink 作业的用户。

   登录 Manager，选择“系统 > 权限 > 角色”，单击“添加角色”，输入角色名称与描述。在“配置资源权限”的表格中选择“*待操作集群的名称* > Flink”，勾选“FlinkServer 管理操作权限”，单击“确定”，返回角色管理。

   选择“系统 > 权限 > 用户”，单击“添加用户”，输入用户名、密码等，用户类型选择“人机”，用户组根据需求添加“hadoop”、“yarnviewgroup”和“hadooppmanager”，并添加“System_administrator”、“default”和创建的角色，单击“确定”完成 Flink 作业用户创建（首次创建的用户需使用该用户登录 Manager 修改密码）。

2. 登录 Manager，下载认证凭据。

登录集群的 Manager 界面，选择“系统 > 权限 > 用户”，在已增加用户所在行的“操作”列，选择“更多 > 下载认证凭据”。

3. 将下载的认证凭据压缩包解压缩，并将得到的文件拷贝到客户端节点中，例如客户端节点的“/opt/hadoopclient/Flink/flink/conf”目录下。如果是在集群外节点安装的客户端，需要将得到的文件拷贝到该节点的“/etc/”目录下。
4. 将客户端安装节点的业务 IP 和 Master 节点 IP 添加到配置文件“/opt/hadoopclient/Flink/flink/conf/flink-conf.yaml”中的“jobmanager.web.access-control-allow-origin”和“jobmanager.web.allow-access-address”配置项中，IP 地址之间使用英文逗号分隔。

```
jobmanager.web.access-control-allow-origin:
xx.xx.xxx.xxx,xx.xx.xxx.xxx,xx.xx.xxx.xxx
jobmanager.web.allow-access-address: xx.xx.xxx.xxx,xx.xx.xxx.xxx,xx.xx.xxx.xxx
```

说明

客户端安装节点的业务 IP 获取方法：

- 集群内节点：

  登录 MapReduce 服务管理控制台，选择“集群列表 > 现有集群”，选中当前的集群并单击集群名，进入集群信息页面。

  在“节点管理”中查看安装客户端所在的节点 IP。

- 集群外节点：安装客户端所在的弹性云服务器的 IP。

5. 配置安全认证，在“/opt/hadoopclient/Flink/flink/conf/flink-conf.yaml”配置文件中的对应配置添加 keytab 路径以及用户名。

```
security.kerberos.login.keytab: <user.keytab 文件路径>
security.kerberos.login.principal: <用户名>
```

例如：

```
security.kerberos.login.keytab: /opt/hadoopclient/Flink/flink/conf/user.keytab
security.kerberos.login.principal: test
```

6. 在 Flink 的客户端 bin 目录下，执行如下命令进行安全加固，并设置一个用于提交作业的密码。

cd /opt/hadoopclient/Flink/flink/bin

sh generate_keystore.sh

该脚本会自动替换“/opt/hadoopclient/Flink/flink/conf/flink-conf.yaml”中关于 SSL 的值。

说明

执行认证和加密后会在 Flink 客户端的“conf”目录下生成“flink.keystore”和“flink.truststore”文件，并且在客户端配置文件“flink-conf.yaml”中将以下配置项进行了默认赋值：

- 将配置项“security.ssl.keystore”设置为“flink.keystore”文件所在绝对路径。
- 将配置项“security.ssl.truststore”设置为“flink.truststore”文件所在的绝对路径。
- 将配置项“security.cookie”设置为“generate_keystore.sh”脚本自动生成的一串随机规则密码。
- 默认“flink-conf.yaml”中“security.ssl.encrypt.enabled: false”，“generate_keystore.sh”脚本将配置项“security.ssl.key-password”、“security.ssl.keystore-password”和“security.ssl.truststore-password”的值设置为调用“generate_keystore.sh”脚本时输入的密码。

- 如果需要使用密文时，设置“flink-conf.yaml”中“security.ssl.encrypt.enabled: true”，“generate_keystore.sh”脚本不会配置“security.ssl.key-password”、“security.ssl.keystore-password”和“security.ssl.truststore-password”的值，需要使用 Manager 明文加密 API 进行获取，执行 **curl -k -i -u** *user name*:*password* **-X POST -HContent-type:application/json -d '{"plainText":"***password***"}' 'https://***x.x.x.x***:28443/web/api/v2/tools/encrypt'**

  其中 *user name*:password 分别为当前系统登录用户名和密码；**"plainText"**的 password 为调用“generate_keystore.sh”脚本时的密码；x.x.x.x 为集群 Manager 的浮动 IP。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

7. 配置客户端访问 flink.keystore 和 flink.truststore 文件的路径。
   - 相对路径（推荐）：

     执行如下步骤配置 flink.keystore 和 flink.truststore 文件路径为相对路径，并确保 Flink Client 执行命令的目录可以直接访问该相对路径。

     i. 在“/opt/hadoopclient/Flink/flink/conf/”目录下新建目录，例如 ssl。

     cd /opt/hadoopclient/Flink/flink/conf/

     mkdir ssl

     ii. 移动 flink.keystore 和 flink.truststore 文件到“/opt/hadoopclient/Flink/flink/conf/ssl/”中。

     mv flink.keystore ssl/

     mv flink.truststore ssl/

     iii. 修改 flink-conf.yaml 文件中如下两个参数为相对路径。

     ```
     security.ssl.keystore: ssl/flink.keystore
     security.ssl.truststore: ssl/flink.truststore
     ```

   - 绝对路径：

     执行“generate_keystore.sh”脚本后，在 flink-conf.yaml 文件中将 flink.keystore 和 flink.truststore 文件路径自动配置为绝对路径“/opt/hadoopclient/Flink/flink/conf/”，此时需要将 conf 目录中的 flink.keystore 和 flink.truststore 文件分别放置在 Flink Client 以及 Yarn 各个节点的该绝对路径上。

步骤 5 运行 wordcount 作业。

须知

用户在 Flink 提交作业或者运行作业时，应具有如下权限：

- 如果启用 Ranger 鉴权，当前用户必须属于 hadoop 组或者已在 Ranger 中为该用户添加“/flink”的读写权限。
- 如果停用 Ranger 鉴权，当前用户必须属于 hadoop 组。

- 普通集群（未开启 Kerberos 认证）可通过如下两种方式提交作业：
  - 执行如下命令启动 session，并在 session 中提交作业。

    yarn-session.sh -nm "*session-name***" -d**

    flink run /opt/hadoopclient/Flink/flink/examples/streaming/WordCount.jar

  - 执行如下命令在 Yarn 上提交单个作业。

flink run -m yarn-cluster
/opt/hadoopclient/Flink/flink/examples/streaming/WordCount.jar

- 安全集群（开启 Kerberos 认证）根据 flink.keystore 和 flink.truststore 文件的路径有如下两种方式提交作业：
  - flink.keystore 和 flink.truststore 文件路径为相对路径时：
    - 在“ssl”的同级目录下执行如下命令启动 session，并在 session 中提交作业。

      其中“ssl”是相对路径，如“ssl”所在目录是“opt/hadoopclient/Flink/flink/conf/”，则在“opt/hadoopclient/Flink/flink/conf/”目录下执行命令。

      cd /opt/hadoopclient/Flink/flink/conf

      yarn-session.sh -t ssl/ -nm "*session-name***" -d**

      flink run
      /opt/hadoopclient/Flink/flink/examples/streaming/WordCount.jar
    - 执行如下命令在 Yarn 上提交单个作业。

      cd /opt/hadoopclient/Flink/flink/conf

      flink run -m yarn-cluster -yt ssl/
      /opt/hadoopclient/Flink/flink/examples/streaming/WordCount.jar
  - flink.keystore 和 flink.truststore 文件路径为绝对路径时：
    - 执行如下命令启动 session，并在 session 中提交作业。

      cd /opt/hadoopclient/Flink/flink/conf

      yarn-session.sh -nm "*session-name***" -d**

      flink run
      /opt/hadoopclient/Flink/flink/examples/streaming/WordCount.jar
    - 执行如下命令在 Yarn 上提交单个作业。

      flink run -m yarn-cluster
      /opt/hadoopclient/Flink/flink/examples/streaming/WordCount.jar

步骤 6 作业提交成功后，客户端界面显示如下。

图6-1 在 Yarn 上提交作业成功

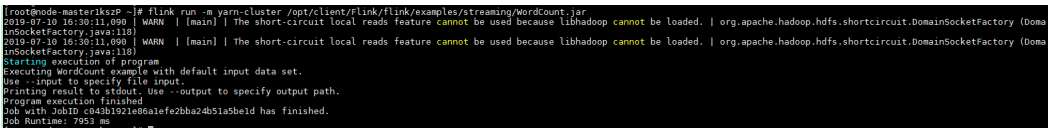

图6-2 启动 session 成功

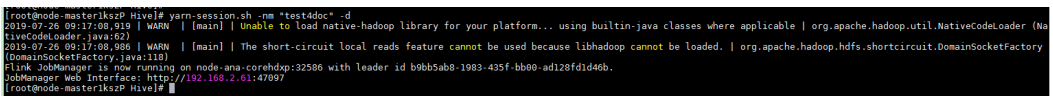

图6-3 在 session 中提交作业成功

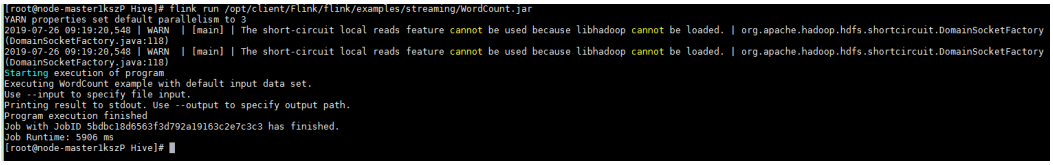

步骤 7 使用运行用户进入 Yarn 服务的原生页面，找到对应作业的 application，单击 application 名称，进入到作业详情页面

- 若作业尚未结束，可单击“Tracking URL”链接进入到 Flink 的原生页面，查看作业的运行信息。
- 若作业已运行结束，对于在 session 中提交的作业，可以单击“Tracking URL”链接登录 Flink 原生页面查看作业信息。

图6-4 application

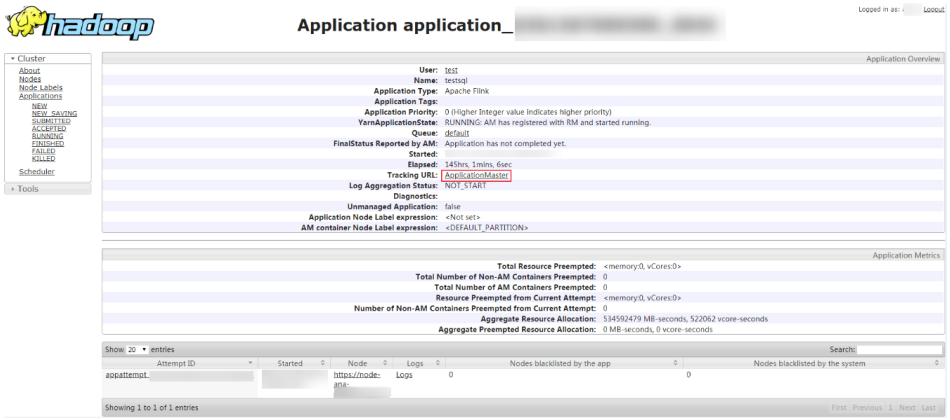

----结束

6.2 查看 Flink 作业信息

用户可以通过 Yarn 的 WebUI，在图形化界面查看 Flink 作业的相关信息。

前提条件

集群已安装 Flink 服务。

访问 Yarn 的 WebUI

步骤 1 进入 Yarn 服务页面：

登录 FusionInsight Manager，然后选择“集群 > 服务 > Yarn > 概览”。

步骤 2 单击“ResourceManager WebUI”后面对应的链接，进入 Yarn 的 WebUI 页面。

----结束

6.3 配置 Flink 服务参数

配置说明

Flink 所有的配置参数都可以在客户端侧进行配置，建议用户直接修改客户端的“flink-conf.yaml”配置文件进行配置，如果通过 Manager 界面修改 Flink 服务参数，配置完成之后需要重新下载安装客户端：

- 配置文件路径：*客户端安装路径*/Flink/flink/conf/flink-conf.yaml。
- 文件的配置格式为 *key: value*。

  例：**taskmanager.heap.size: 1024mb**

  注意配置项 key:与 value 之间需有空格分隔。

配置详情

本章节为你介绍如下参数配置：

- JobManager & TaskManager：

  JobManager 和 TaskManager 是 Flink 的主要组件，针对各种安全场景和性能场景，配置项包括通信端口，内存管理，连接重试等。

- Blob 服务端：

  JobManager 节点上的 Blob 服务端是用于接收用户在客户端上传的 Jar 包，或将 Jar 包发送给 TaskManager，传输 log 文件等，配置项包括端口，SSL，重试次数，并发等。

- Distributed Coordination (via Akka)：

  Flink 客户端与 JobManager 的通信，JobManager 与 TaskManager 的通信和 TaskManager 与 TaskManager 的通信都基于 Akka actor 模型。相关参数可以根据网络环境或调优策略进行配置，配置项包括消息发送和等待的超时设置，akka 监测机制 Deathwatch 等。

- SSL：

  当需要配置安全 Flink 集群时，需要配置 SSL 相关配置项，配置项包括 SSL 开关，证书，密码，加密算法等。

- Network communication (via Netty)：

  Flink 运行 Job 时，Task 之间的数据传输和反压检测都依赖 Netty，某些环境下可能需要对 Netty 参数进行配置。对于高级调优，可调整部分 Netty 配置项，默认配置已可满足大规模集群并发高吞吐量的任务。

- JobManager Web Frontend：

  JobManager 启动时，会在同一进程内启动 Web 服务器，访问 Web 服务器可以获取当前 Flink 集群的信息，包括 JobManager，TaskManager 及集群内运行的 Job。Web 服务器参数的配置项包括端口，临时目录，显示项目，错误重定向，安全相关等。

- File Systems：

  Task 运行中会创建结果文件，支持对文件创建行为进行配置，配置项包括文件覆盖策略，目录创建等。

- State Backend：

  Flink 提供了 HA 和作业的异常恢复，并且提供版本升级时作业的暂停恢复。对于作业状态的存储，Flink 依赖于 state backend，作业的重启依赖于重启策略，用户可以对这两部分进行配置。配置项包括 state backend 类型，存储路径，重启策略等。

- Kerberos-based Security：

  Flink 安全模式下必须配置 Kerberos 相关配置项，配置项包括 kerberos 的 keytab、principal 等。

- HA：

  Flink 的 HA 模式依赖于 ZooKeeper，所以必须配置 ZooKeeper 相关配置，配置项包括 ZooKeeper 地址，路径，安全认证等。

- Environment：

  对于 JVM 配置有特定要求的场景，可以通过配置项传递 JVM 参数到客户端，JobMananger，TaskManager 等。

- Yarn：

  Flink 运行在 Yarn 集群上时，JobManager 运行在 Application Master 上。JobManager 的一些配置参数依赖于 Yarn，通过配置 YARN 相关的配置，使 Flink 更好的运行在 Yarn 上，配置项包括 yarn container 的内存，虚拟内核，端口等。

- Pipeline：

  为适应某些场景对降低时延的需求，设计多个 Job 间采用 Netty 直接相连的方式传递数据，即分别使用 NettySink 用于 Server 端、NettySource 用于 Client 端进行数据传输。配置项包括 NettySink 的信息存放路径、NettySink 的端口监测范围、连接是否通过 SSL 加密以及 NettySink 监测所使用的网络所在域等。

- 配置客户端提交作业开启告警功能：

  通过 Flink 客户端提交的作业默认未开启告警功能，若要开启告警功能，需要在提交作业的节点安装两个 FlinkServer 实例，并在客户端的“flink-conf.yaml”文件中配置相关参数。

JobManager & TaskManager

表6-1 JobManager & TaskManager 参数说明

参数	描述	默认值	是否必选
taskmanager.rpc.port	TaskManager 的 IPC 端口范围。	32326-32390	否
taskmanager.memory.segment-size	内存管理器和网络堆栈使用的内存缓冲区大小。单位：bytes。	32768	否
taskmanager.data.port	TaskManager 数据交换端口范围。	32391-32455	否

参数	描述	默认值	是否必选
taskmanager.data.ssl.enabled	TaskManager 之间数据传输是否使用 SSL 加密，仅在全局开关 security.ssl 开启时有效。	false	否
taskmanager.numberOfTaskSlots	TaskManager 占用的 slot 数，一般配置成物理机的核数，yarn-session 模式下只能使用-s 参数传递，yarn-cluster 模式下只能使用-ys 参数传递。	1	否
parallelism.default	默认并行度，用于未指定并行度的作业。	1	否
task.cancellation.interval	两次连续任务取消操作的间隔时间。单位：ms。	30000	否
client.rpc.port	Flink client 端 Akka system 监测端口。	32651-32720	否
jobmanager.heap.size	JobManager 堆内存大小，yarn-session 模式下只能使用-jm 参数传递，yarn-cluster 模式下只能使用-yjm 参数传递，如果小于 YARN 配置文件中 yarn.scheduler.minimum-allocation-mb 大小，则使用 YARN 配置中的值。单位：B/KB/MB/GB/TB。	1024mb	否
taskmanager.heap.size	TaskManager 堆内存大小，yarn-session 模式下只能使用-tm 参数传递，yarn-cluster 模式下只能使用-ytm 参数传递，如果小于 YARN 配置文件中 yarn.scheduler.minimum-allocation-mb 大小，则使用 YARN 配置中的值。单位：B/KB/MB/GB/TB。	1024mb	否
taskmanager.network.numberOfBuffers	TaskManager 网络传输缓冲栈数量，如果作业运行中出错提示系统中可用缓冲不足，可以增加这个配置项的值。	2048	否
taskmanager.debug.memory.startLogThread	调试 Flink 内存和 GC 相关问题时可开启，TaskManager 会定时采集内存和 GC 的统计信息，包括当前堆内，堆外，内存池的使用率和 GC 时间。	false	否
taskmanager.debug.memory.logIntervalMs	TaskManager 定时采集内存和 GC 的统计信息的采集间隔。	0	否
taskmanager.maxRegistrationDuration	TaskManager 向 JobManager 注册自己的最长时间，如果超过时间，TaskManager 会关闭。	5 min	否

参数	描述	默认值	是否必选
taskmanager.initial-registration-pause	两次连续注册的初始间隔时间。该值需带一个时间单位（ms/s/min/h/d）（比如 5 秒）。 时间数值和单位之间有半角字符空格。ms/s/m/h/d 表示毫秒、秒、分钟、小时、天。	500 ms	否
taskmanager.max-registration-pause	TaskManager 注册失败最大重试间隔。单位：ms/s/m/h/d。	30 s	否
taskmanager.refused-registration-pause	TaskManager 注册连接被 JobManager 拒绝后的重试间隔。单位：ms/s/m/h/d。	10 s	否
classloader.resolve-order	从用户代码加载类时定义类解析策略，这意味着是首先检查用户代码 jar（“child-first”）还是应用程序类路径（“parent-first”）。默认设置指示首先从用户代码 jar 加载类，这意味着用户代码 jar 可以包含和加载不同于 Flink 使用的（依赖）依赖项。	child-first	否
slot.idle.timeout	Slot Pool 中空闲 Slot 的超时时间（以 ms 为单位）。	50000	否
slot.request.timeout	从 Slot Pool 请求 Slot 的超时（以 ms 为单位）。	300000	否
task.cancellation.timeout	取消任务超时时间（以 ms 为单位），超时后会触发 TaskManager 致命错误。设置为 0，取消任务卡住则不会报错。	180000	否
taskmanager.network.detailed-metrics	启用网络队列长度的详细指标监控。	false	否
taskmanager.network.memory.buffers-per-channel	每个传出/传入通道（子分区/输入通道）使用的最大网络缓冲区数。在基于信用的流量控制模式下，这表示每个输入通道中有多少信用。它应配置至少 2 以获得良好的性能。1 个缓冲区用于接收子分区中的飞行中数据，1 个缓冲区用于并行序列化。	2	否
taskmanager.network.memory.floating-buffers-per-gate	每个输出/输入门（结果分区/输入门）使用的额外网络缓冲区数。在基于信用的流量控制模式中，这表示在所有输入通道之间共享多少浮动信用。浮动缓冲区基于积压（子分区中的实时输出缓冲	8	否

参数	描述	默认值	是否必选
	区）反馈来分布，并且可以帮助减轻由子分区之间的不平衡数据分布引起的背压。如果节点之间的往返时间较长和/或群集中的机器数量较多，则应增加此值。		
taskmanager.network.memory.fraction	用于网络缓冲区的 JVM 内存的占比。这决定了 TaskManager 可以同时拥有多少流数据交换通道以及通道缓冲的程度。如果作业被拒绝或者收到系统没有足够缓冲区的警告，请增加此值或“taskmanager.network.memory.min”和“taskmanager.network.memory.max”。另请注意，“taskmanager.network.memory.min”和“taskmanager.network.memory.max”可能会覆盖此占比。	0.1	否
taskmanager.network.memory.max	网络缓冲区的最大内存大小。该值需带一个大小单位（B/KB/MB/GB/TB）。	1 GB	否
taskmanager.network.memory.min	网络缓冲区的最小内存大小。该值需带一个大小单位（B/KB/MB/GB/TB）。	64 MB	否
taskmanager.network.request-backoff.initial	输入通道的分区请求的最小退避。	100	否
taskmanager.network.request-backoff.max	输入通道的分区请求的最大退避。	10000	否
taskmanager.registration.timeout	TaskManager 注册的超时时间，在该时间内未成功注册，TaskManager 将终止。该值需带一个时间单位（ms/s/min/h/d）。	5 min	否
resourcemanager.taskmanager-timeout	释放空闲 TaskManager 的超时（以 ms 为单位）。	30000	否

Blob 服务端

表6-2 Blob 服务端参数说明

参数	描述	默认值	是否必选

参数	描述	默认值	是否必选
blob.server.port	blob 服务器端口。	32456-32520	否
blob.service.ssl.enabled	blob 传输通道是否加密传输，仅在全局开关 security.ssl 开启时有。	true	是
blob.fetch.retries	TaskManager 从 JobManager 下载 blob 文件的重试次数。	50	否
blob.fetch.num-concurrent	JobManager 支持的下载 blob 的并发数。	50	否
blob.fetch.backlog	JobManager 支持的 blob 下载队列大小，比如下载 Jar 包等。单位：个。	1000	否
library-cache-manager.cleanup.interval	当用户取消 flink job 后，jobmanager 删除 HDFS 上存放用户 jar 包的时间，单位为 s。	3600	否

Distributed Coordination (via Akka)

表6-3 Distributed Coordination 参数说明

参数	描述	默认值	是否必选
akka.ask.timeout	akka 所有异步请求和阻塞请求的超时时间。如果 Flink 发生超时失败，可以增大这个值。当机器处理速度慢或者网络阻塞时会发生超时。单位：ms/s/m/h/d。	10s	否
akka.lookup.timeout	查找 JobManager actor 对象的超时时间。单位：ms/s/m/h/d。	10s	否
akka.framesize	JobManager 和 TaskManager 间最大消息传输大小。当 Flink 出现消息大小超过限制的错误时，可以增大这个值。单位：b/B/KB/MB。	10485760b	否
akka.watch.heartbeat.interval	Akka DeathWatch 机制检测失联 TaskManager 的心跳间隔。如果 TaskManager 经常发生由于心跳消息丢失或延误而被错误标记为失联的情况，可以增大这个值。单位：ms/s/m/h/d。	10s	否
akka.watch.heartbeat.pause	Akka DeathWatch 可接受的心跳暂停时间，较小的数值表示不允许不规律的心跳。单位：ms/s/m/h/d。	60s	否
akka.watch.thr	DeathWath 失败检测阈值，较小的数值	12	否

参数	描述	默认值	是否必选
eshold	容易把正常 TaskManager 标记为失败，较大的值增加了失败检测的时间。		
akka.tcp.timeout	发送连接 TCP 超时时间，如果经常发生满网络环境下连接 TaskManager 超时，可以增大这个值。单位：ms/s/m/h/d。	20s	否
akka.throughput	Akka 批量处理消息的数量，一次操作完后把处理线程归还线程池。较小的数值代表 actor 消息处理的公平调度，较大的值以牺牲调度公平的代价提高整体性能。	15	否
akka.log.lifecycle.events	Akka 远程时间日志开关，当需要调试时可打开此开关。	false	否
akka.startup-timeout	远程组件启动失败前的超时时间。该值需带一个时间单位（ms/s/min/h/d）	与 akka.ask.timeout 的值一致	否
akka.ssl.enabled	Akka 通信 SSL 开关，仅在全局开关 security.ssl 开启时有。	true	是
akka.client-socket-worker-pool.pool-size-factor	计算线程池大小的因子，计算公式：ceil（可用处理器*因子），计算结果限制在 pool-size-min 和 pool-size-max 之间。	1.0	否
akka.client-socket-worker-pool.pool-size-max	基于因子计算的线程数上限。	2	否
akka.client-socket-worker-pool.pool-size-min	基于因子计算的线程数下限。	1	否
akka.client.timeout	【说明】客户端超时时间。该值需带一个时间单位（ms/s/min/h/d）。	60s	否
akka.server-socket-worker-pool.pool-size-factor	【说明】计算线程池大小的因子，计算公式：ceil（可用处理器*因子），计算结果限制在 pool-size-min 和 pool-size-max 之间。	1.0	否
akka.server-socket-worker-pool.pool-size-max	基于因子计算的线程数上限。	2	否
akka.server-socket-worker-	基于因子计算的线程数下限。	1	否

参数	描述	默认值	是否必选
pool.pool-size-min			

SSL

表6-4 SSL 参数说明

参数	描述	默认值	是否必选
security.ssl.protocol	SSL 传输的协议版本。	TLSv1.2	是
security.ssl.algorithms	支持的 SSL 标准算法。	TLS_DHE_RSA_WITH_AES_128_GCM_SHA256,TLS_ECDHE_RSA_WITH_AES_128_GCM_SHA256,TLS_DHE_RSA_WITH_AES_256_GCM_SHA384,TLS_ECDHE_RSA_WITH_AES_256_GCM_SHA384	是
security.ssl.enabled	内部通信 SSL 总开关，按照集群的安装模式自动配置。	• 安全模式：true • 普通模式：false	是
security.ssl.keystore	Java keystore 文件。	-	是
security.ssl.keystore-password	keystore 文件解密密码。	-	是
security.ssl.key-password	keystore 文件中服务端 key 的解密密码。	-	是
security.ssl.truststore	truststore 文件包含公共 CA 证书。	-	是
security.ssl.truststore-password	truststore 文件解密密码。	-	是

Network communication (via Netty)

表6-5 Network communication 参数说明

参数	描述	默认值	是否必选
taskmanager.network.netty.num-arenas	Netty 内存块数。	1	否
taskmanager.network.netty.server.numThreads	Netty 服务器线程的数量。	1	否
taskmanager.network.netty.client.numThreads	Netty 客户端线程数。	1	否
taskmanager.network.netty.client.connectTimeoutSec	Netty 客户端连接超时。单位：s。	120	否
taskmanager.network.netty.sendReceiveBufferSize	Netty 发送和接收缓冲区大小。 默认为系统缓冲区大小（cat / proc / sys / net / ipv4 / tcp_ [rw] mem），在现代 Linux 中为 4MB。单位：bytes。	4096	否
taskmanager.network.netty.transport	Netty 传输类型，“nio”或“epoll”。	nio	否

JobManager Web Frontend

表6-6 JobManager Web Frontend 参数说明

参数	描述	默认值	是否必选
jobmanager.web.allow-access-address	web 访问白名单，ip 以逗号隔开。只有在白名单中的 ip 才能访问 web。	*	是
flink.security.enable	用户安装 Flink 集群时，需要选择“安全模式”或“普通模式”。 • 当选择“安全模式”，自动配置为“true”。 • 当选择“普通模式”，自动配置为“false”。 对于已经安装好的 Flink 集群，用户可以通过查看配置的值来区分当前安装的是安全模式还是普通模式。	自动配置	否
rest.bind-port	web 端口，支持范围：32261-32325。	32261-32325	否

参数	描述	默认值	是否必选
jobmanager.web.history	显示“flink.security.enable”最近的 job 数目。	5	否
jobmanager.web.checkpoints.disable	禁用 checkpoint 统计。	false	否
jobmanager.web.checkpoints.history	Checkpoint 统计记录数。	10	否
jobmanager.web.backpressure.cleanup-interval	未访问反压记录清理周期。单位：ms。	600000	否
jobmanager.web.backpressure.refresh-interval	反压记录刷新周期。单位：ms。	60000	否
jobmanager.web.backpressure.num-samples	计算反压使用的堆栈跟踪记录数。	100	否
jobmanager.web.backpressure.delay-between-samples	计算反压的采样间隔。单位：ms	50	否
jobmanager.web.ssl.enabled	web 是否使用 SSL 加密传输，仅在全局开关 security.ssl 开启时有。	false	是
jobmanager.web.accesslog.enable	web 操作日志使能开关，日志会存放在 webaccess.log 中。	true	是
jobmanager.web.x-frame-options	http 安全头 X-Frame-Options 的值，可选范围为：SAMEORIGIN、DENY、ALLOW-FROM uri。	DENY	是
jobmanager.web.cache-directive	web 页面是否支持缓存。	no-store	是
jobmanager.web.expires-time	web 页面缓存过期时长。单位：ms。	0	是
jobmanager.web.access-control-allow-origin	网页同源策略，防止跨域攻击。	*	是
jobmanager.web.refresh-interval	web 网页刷新时间。单位：ms。	3000	是

参数	描述	默认值	是否必选
jobmanager.web.logout-timer	配置无操作情况下自动登出时间间隔。单位：ms。	600000	是
jobmanager.web.403-redirect-url	web403 页面，访问若遇到 403 错误，则会重定向到配置的页面。	自动配置	是
jobmanager.web.404-redirect-url	web404 页面，访问若遇到 404 错误，则会重定向到配置的页面。	自动配置	是
jobmanager.web.415-redirect-url	web415 页面，访问若遇到 415 错误，则会重定向到配置的页面。	自动配置	是
jobmanager.web.500-redirect-url	web500 页面，访问若遇到 500 错误，则会重定向到配置的页面。	自动配置	是
rest.await-leader-timeout	客户端等待 Leader 地址的时间（以 ms 为单位）。	30000	否
rest.client.max-content-length	客户端处理的最大内容长度（以字节为单位）。	104857600	否
rest.connection-timeout	客户端建立 TCP 连接的最长时间（以 ms 为单位）。	15000	否
rest.idleness-timeout	连接保持空闲状态的最长时间（以 ms 为单位）。	300000	否
rest.retry.delay	客户端在连续重试之间等待的时间（以 ms 为单位）。	3000	否
rest.retry.max-attempts	如果可重试算子操作失败，客户端将尝试重试的次数。	20	否
rest.server.max-content-length	服务端处理的最大内容长度（以字节为单位）。	104857600	否
rest.server.numThreads	异步处理请求的最大线程数。	4	否
web.timeout	web 监控超时时间（以 ms 为单位）。	10000	否

File Systems

表6-7 File Systems 参数说明

参数	描述	默认值	是否必选

参数	描述	默认值	是否必选
fs.overwrite-files	文件输出写操作是否默认覆盖已有文件。	false	否
fs.output.always-create-directory	当文件写入程序的并行度大于 1 时，输出文件的路径下会创建一个目录，并将不同的结果文件（每个并行写程序任务）放入该目录。 • 设置为 true，那么并行度为 1 的写入程序也将创建一个目录并将一个结果文件放入其中。 • 设置为 false，则并行度为 1 的写入程序将直接在输出路径中创建文件，而不再创建目录。	false	否

State Backend

表6-8 State Backend 参数说明

参数	描述	默认值	是否必选
state.backend.fs.checkpointdir	当 backend 为 filesystem 时的路径，路径必须能够被 JobManager 访问到，本地路径只支持 local 模式，集群模式下请使用 HDFS 路径。	hdfs:///flink/checkpoints	否
state.savepoints.dir	Flink 用于恢复和更新作业的保存点存储目录。当触发保存点的时候，保存点元数据信息将会保存到该目录中。	hdfs:///flink/savepoint	安全模式下必配
restart-strategy	默认重启策略，用于未指定重启策略的作业： • fixed-delay • failure-rate • none	none	否
restart-strategy.fixed-delay.attempts	fixed-delay 策略重试次数。	• 作业中开启了checkpoint，默认值为Integer.MAX_VALUE。 • 作业中未开启	否

参数	描述	默认值	是否必选
		checkpoint，默认值为3。	
restart-strategy.fixed-delay.delay	fixed-delay 策略重试间隔时间。单位：ms/s/m/h/d。	• 作业中开启了checkpoint，默认值是10 s。 • 作业中未开启checkpoint，默认值和配置项akka.ask.timeout的值一致。	否
restart-strategy.failure-rate.max-failures-per-interval	故障率策略下作业失败前给定时间段内的最大重启次数。	1	否
restart-strategy.failure-rate.failure-rate-interval	failure-rate 策略重试时间。单位：ms/s/m/h/d。	60 s	否
restart-strategy.failure-rate.delay	failure-rate 策略重试间隔时间。单位：ms/s/m/h/d。	默认值和akka.ask.timeout 配置值一样。可参考Distributed Coordination (via Akka)。	否

Kerberos-based Security

表6-9 Kerberos-based Security 参数说明

参数	描述	默认值	是否必选

参数	描述	默认值	是否必选
security.kerberos.login.keytab	该参数为客户端参数，keytab 路径。	根据实际业务配置	是
security.kerberos.login.principal	该参数为客户端参数，如果 keytab 和 principal 都设置，默认会使用 keytab 认证。	根据实际业务配置	否
security.kerberos.login.contexts	该参数为服务器端参数，flink 生成 jass 文件的 contexts。	Client、KafkaClient	是

HA

表6-10 HA 参数说明

参数	描述	默认值	是否必选
high-availability	HA 模式，是启用 HA 还是非 HA 模式。当前支持两种模式： • none，只运行单个 jobManager，jobManager 的状态不进行 Checkpoint。 • ZooKeeper。 – 非 YARN 模式下，支持多个 jobManager，通过选举产生 leader。 – YARN 模式下只存在一个 jobManager。	zookeeper	否
high-availability.zookeeper.quorum	ZooKeeper quorum 地址。	自动配置	否
high-availability.zookeeper.path.root	Flink 在 ZooKeeper 上创建的根目录，存放 HA 模式必须的元数据。	/flink	否
high-availability.storageDir	存放 state backend 中 JobManager 元数据，ZooKeeper 只保存实际数据的指针。	hdfs:///flink/recovery	否
high-availability.zookeeper.client.session-timeout	ZooKeeper 客户端会话超时时间。单位：ms。	60000	否
high-availability.zookeeper.client.connection	ZooKeeper 客户端连接超时时间。单位：ms。	15000	否

参数	描述	默认值	是否必选
-timeout			
high-availability.zookeeper.client.retry-wait	ZooKeeper 客户端重试等待时间。单位：ms。	5000	否
high-availability.zookeeper.client.max-retry-attempts	ZooKeeper 客户端最大重试次数。	3	否
high-availability.job.delay	当 jobManager 恢复后重启 job 的延迟时间。	默认值和 akka.ask.timeout 配置值保持一致	否
high-availability.zookeeper.client.acl	设置 ZooKeeper 节点的 ACL (open creator)，按照集群的安全模式自动配置。	• 安全模式：creator • 非安全模式：open	是
zookeeper.sasl.disable	基于 SASL 认证的使能开关，按照集群的安全模式自动配置：。	• 安全模式：false • 非安全模式：true	是
zookeeper.sasl.service-name	• 如果 ZooKeeper 服务端配置了不同于“ZooKeeper”的服务名，可以设置此配置项。 • 如果客户端和服务端的服务名不一致，认证会失败。	zookeeper	是

Environment

表6-11 Environment 参数说明

参数	描述	默认值	是否必选
env.java.opts	JVM 参数，会传递到启动脚本，JobManager，TaskManag	-Xloggc:<LOG_DIR>/gc.log -XX:+PrintGCDetails -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=20 -XX:GCLogFileSize=20M -Djdk.tls.ephemeralDHKeySize=2048 -	否

参数	描述	默认值	是否必选
	er，Yarn客户端。比如传递远程调试的参数等。	Djava.library.path=${HADOOP_COMMON_HOME}/lib/native -Djava.net.preferIPv4Stack=true -Djava.net.preferIPv6Addresses=false -Dbeetle.application.home.path=/opt/*xxx*/Bigdata/common/runtime/security/config	

Yarn

表6-12 Yarn 参数说明

参数	描述	默认值	是否必选
yarn.maximum-failed-containers	当 TaskManager 所属容器出错后，重新申请 container 次数。默认值为 Flink 集群启动时 TaskManager 的数量。	5	否
yarn.application-attempts	Application master 重启次数，次数是算在一个 validity interval 的最大次数，validity interval 在 flink 中设置为 akka 的 timeout。重启后 AM 的地址和端口会变化，client 需要手动连接。	2	否
yarn.heartbeat-delay	Application Master 和 YARN Resource Manager 心跳的时间间隔。单位：seconds	5	否
yarn.containers.vcores	每个 Yarn 容器的虚拟核数。	TaskManager 的 slot 数	否
yarn.application-master.port	Application Master 端口号设置，支持端口范围。	32586-32650	否

Pipeline

表6-13 Pipeline 参数说明

参数	描述	默认值	是否必选
nettyconnector.registerserver.topic.storage	设置 NettySink 的 IP、端口及并发度信息在第三方注册服务器上的路径。建议用户使用 ZooKeeper 进行存储。	/flink/nettyconnector	否，当使用 pipeline 特性为必选

参数	描述	默认值	是否必选
nettyconnector.sink server.port.range	设置 NettySink 的端口范围。	28444-28843	否，当使用 pipeline 特性为必选
nettyconnector.ssl.enabled	设置 NettySink 与 NettySource 之间通信是否配置 SSL 加密。其中加密密钥以及加密协议等请参见 SSL。	false	否，当使用 pipeline 特性为必选
nettyconnector.message.delimiter	用来配置 nettysink 发送给 nettysource 消息的分隔符，长度为 2-4 个字节，不可包含“\n”，“ ”， “#” 。	默认使用“$_”	否，当使用 pipeline 特性为必选

配置客户端提交作业开启告警功能

适用于 MRS 3.2.0 及之后的版本。

表6-14 客户端提交作业开启告警功能参数说明

参数	描述	配置值	是否必选
job.alarm.enable	是否开启作业告警功能	true	是
flinkserver.host.ip	FlinkServer 两个实例的业务 IP	*x.x.x.x,x.x.x.x*	是

6.4 配置 Flink 安全特性

6.4.1 安全特性描述

Flink 认证和加密

- Flink 集群中，各部件支持认证。
  - Flink 集群内部各部件和外部部件之间，支持和外部部件如 YARN、HDFS、ZooKeeprer 进行 kerberors 认证。
  - Flink 集群内部各部件之间，如 Flink client 和 JobManager、JobManager 和 TaskManager、TaskManager 和 TaskManager 之间支持 security cookie 认证。
- Flink 集群中，各部件支持 SSL 加密传输；集群内部各部件之间，如 Flink client 和 JobManager、JobManager 和 TaskManager、TaskManager 和 TaskManager 之间支持 SSL 加密传输。

详情可参考 6.4.2 认证和加密。

ACL 控制

在 HA 模式下，支持 ACL 控制。

Flink 在 HA 模式下，支持用 ZooKeeper 来管理集群和发现服务。ZooKeeper 支持 SASL ACL 控制，即只有通过 SASL（kerberos）认证的用户，才有往 ZK 上操作文件的权限。如果要在 Flink 上使用 SASL ACL 控制，需要在 Flink 配置文件中设置如下配置：

```
high-availability.zookeeper.client.acl: creator
zookeeper.sasl.disable: false
```

具体配置项介绍请参考 HA。

Web 安全

Flink Web 安全加固，支持白名单过滤，Flink Web 只能通过 YARN 代理访问，支持安全头域增强。在 Flink 集群中，各部件的监测端口支持范围可配置。

- 编码规范：
  - 说明：Web Service 客户端和服务器间使用相同的编码方式，是为了防止出现乱码现象，也是实施输入校验的基础。
  - 安全加固：web server 响应消息统一采用 UTF-8 字符编码。
- 支持 IP 白名单过滤：
  - 说明：防止非法用户登录，需在 web server 侧添加 IP Filter 过滤源 IP 非法的请求。
  - 安全加固：支持 IP Filter 实现 Web 白名单配置，配置项是“jobmanager.web.allow-access-address”，默认情况下只支持 YARN 用户接入。

说明

安装客户端之后需要将客户端节点 IP 追加到 jobmanager.web.allow-access-address 配置项中。

- 禁止将文件绝对路径发送到客户端：
  - 说明：文件绝对路径发送到客户端会暴露服务端的目录结构信息，有助于攻击者遍历了解系统，为攻击者攻击提供帮助。
  - 安全加固：Flink 配置文件中所有配置项中如果包含以/开头的，则删掉第一级目录。
- 同源策略：
  - 说明：如果两个 URL 的协议，主机和端口均相同，则它们同源；如果不同源，默认不能相互访问；除非被访问者在其服务端显示指定访问者的来源。
  - 安全加固：响应头“Access-Control-Allow-Origin”头域默认配置为 YARN 集群 ResourceManager 的 IP 地址，如果源不是来自 YARN 的，则不能互相访问。
- 防范敏感信息泄露：
  - 说明：带有敏感数据的 Web 页面都应该禁止缓存，以防止敏感信息泄漏或通过代理服务器上网的用户数据互窜现象。

  - 安全加固：添加“Cache-control”、“Pragma”、“Expires”安全头域，默认值为：“Cache-Control：no-store”，“Pragma ：no-cache”，“Expires ： 0”。实现了安全加固，Flink 和 web server 交互的内容将不会被缓存。

- 防止劫持：
  - 说明：由于点击劫持（ClickJacking）和框架盗链都利用到框架技术，所以需要采用安全措施。
  - 安全加固：添加“X-Frame-Options”安全头域，给浏览器提供允许一个页面可否在“iframe”、“frame”或“object”网站中的展现页面的指示，如果默认配置为“X-Frame-Options: DENY”，则确保任何页面都不能被嵌入到别的“iframe”、“frame”或“object”网站中，从而避免了点击劫持 (clickjacking) 的攻击。
- 对 Web Service 接口调用记录日志：
  - 说明：对“Flink webmonitor restful”接口调用进行日志记录。
  - 安全加固：“access log”支持配置：“jobmanager.web.accesslog.enable”，默认为“true”。且日志保存在单独的“webaccess.log”文件中。
- 跨站请求（CSRF）伪造防范：
  - 说明：在 B/S 应用中，对于涉及服务器端数据改动（如增加、修改、删除）的操作必须进行跨站请求伪造的防范。跨站请求伪造是一种挟制终端用户在当前已登录的 Web 应用程序上执行非本意的操作的攻击方法。
  - 安全加固：现有请求修改的接口有 2 个 post，1 个 delete，其余均是 get 请求，非 get 请求的接口均已删除。
- 异常处理：
  - 说明：应用程序出现异常时，捕获异常，过滤返回给客户端的信息，并在日志中记录详细的错误信息。
  - 安全加固：默认的错误提示页面，进行信息过滤，并在日志中记录详细的错误信息。新加四个配置项，默认配置为 FusionInsight 提供的跳转 URL，错误提示页面跳转到固定配置的 URL 中，防止暴露不必要的信息。

表6-15 四个配置项参数介绍

参数	描述	默认值	是否必选配置
jobmanager.web.403-redirect-url	web403 页面，访问若遇到 403 错误，则会重定向到配置的页面。	-	是
jobmanager.web.404-redirect-url	web404 页面，访问若遇到 404 错误，则会重定向到配置的页面。	-	是
jobmanager.web.415-redirect-url	web415 页面，访问若遇到 415 错误，则会重定向到配置的页面。	-	是
jobmanager.web.500-redirect-url	web500 页面，访问若遇到 500 错误，则会重定向到配置的页面。	-	是

- HTML5 安全：

- 说明：HTML5 是下一代的 Web 开发规范，为开发者提供了许多新的功能并扩展了标签。这些新的标签及功能增加了攻击面，存在被攻击的风险（例如跨域资源共享、客户端存储、WebWorker、WebRTC、WebSocket 等）。
- 安全加固：添加“Access-Control-Allow-Origin”配置，如运用到跨域资源共享功能，可对 HTTP 响应头的“Access-Control-Allow-Origin”属性进行控制。

说明

Flink 不涉及如客户端存储、WebWorker、WebRTC、WebSocket 等安全风险。

安全声明

- Flink 的安全都为开源社区提供和自身研发。有些是需要用户自行配置的安全特性，如认证、SSL 传输加密等，这些特性可能对性能和使用方便性造成一定影响。
- Flink 作为大数据计算和分析平台，对客户输入的数据是否包含敏感信息无法感知，因此需要客户保证输入数据是脱敏的。
- 客户可以根据应用环境，权衡配置安全与否。
- 任何与安全有关的问题，请联系运维人员。

6.4.2 认证和加密

安全认证

Flink 整个系统存在三种认证方式：

- 使用 kerberos 认证：Flink yarn client 与 Yarn Resource Manager、JobManager 与 Zookeeper、JobManager 与 HDFS、TaskManager 与 HDFS、Kafka 与 TaskManager、TaskManager 和 Zookeeper。
- 使用 security cookie 进行认证：Flink yarn client 与 Job Manager、JobManager 与 TaskManager、TaskManager 与 TaskManager。
- 使用 YARN 内部的认证机制：Yarn Resource Manager 与 Application Master（简称 AM）。

说明

- Flink 的 JobManager 与 YARN 的 AM 是在同一个进程下。
- 如果用户集群开启 Kerberos 认证需要使用 kerberos 认证。

表6-16 安全认证方式

安全认证方式	说明	配置方法
Kerberos 认证	当前只支持 keytab 认证方式。	1. 从 FusionInsight Manager 下载用户 keytab，并将 keytab 放到 Flink 客户端所在主机的某个文件夹下。 2. 在“flink-conf.yaml”上配置： a. keytab 路径。 `security.kerberos.login.keytab:`

安全认证方式	说明	配置方法
		/home/flinkuser/keytab/abc222.keytab 说明： “/home/flinkuser/keytab/abc222.keytab”表示的是用户目录。 b. principal 名。 security.kerberos.login.principal: abc222 c. 对于 HA 模式，如果配置了 ZooKeeper，还需要设置 ZK kerberos 认证相关的配置。配置如下： zookeeper.sasl.disable: false security.kerberos.login.contexts: Client d. 如果用户对于 Kafka client 和 Kafka broker 之间也需要做 kerberos 认证，配置如下： security.kerberos.login.contexts: Client,KafkaClient
Security Cookie 认证	-	1. 在 Flink 客户端的“bin”目录下，调用“generate_keystore.sh”脚本，生成“Security Cookie”、“flink.keystore”文件和“flink.truststore”文件。 执行 **sh generate_keystore.sh**，输入用户自定义密码。密码不允许包含#。 **说明** 执行脚本后，在 Flink 客户端的“conf”目录下生成“flink.keystore”和“flink.truststore”文件，并且在客户端配置文件“flink-conf.yaml”中将以下配置项进行了默认赋值。 • 将配置项“security.ssl.keystore”设置为“flink.keystore”文件所在绝对路径。 • 将配置项“security.ssl.truststore”设置为“flink.truststore”文件所在的绝对路径。 • 将配置项“security.cookie”设置为“generate_keystore.sh”脚本自动生成的一串随机规则密码。 • 默认“flink-conf.yaml”中“security.ssl.encrypt.enabled: false”，“generate_keystore.sh”脚本将配置项“security.ssl.key-password”、“security.ssl.keystore-password”和“security.ssl.truststore-password”的值设置为调用“generate_keystore.sh”脚本时输入的密码。 • 如果需要使用密文时，设置“flink-conf.yaml”中“security.ssl.encrypt.enabled: true”，“generate_keystore.sh”脚本不会配置“security.ssl.key-password”、“security.ssl.keystore-password”和“security.ssl.truststore-password”的值，需要使用 Manager 明文加密 API 进行获取，执行 **curl -k -i -u** *user name*:*password* **-X POST -HContent-type:application/json -d '{"plainText":"***password***"}' 'https://***x.x.x.x***:28443/web/api/v2/tools/encrypt'** 其中 *user name*:password 分别为当前系统登录用户名和密码；**"plainText"**的 password 为调用“generate_keystore.sh”脚本时的密码；x.x.x.x 为集群 Manager 的浮动 IP。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。 2. 查看是否打开“Security Cookie”开关，即查看配置

安全认证方式	说明	配置方法
		“flink-conf.yaml”文件中的“security.enable: true”，查看“security cookie”是否已配置成功，例如： `security.cookie: ae70acc9-9795-4c48-ad35-8b5adc8071744f605d1d-2726-432e-88ae-dd39bfec40a9` **说明** 使用 MRS 客户端预制“generate_keystore.sh”脚本获取 SSL 证书有效期为 5 年。 若要关闭默认的 SSL 认证方式，需在“flink-conf.yaml”文件中配置“security.ssl.enabled”的值为“false”，并且注释如下参数：security.ssl.key-password、security.ssl.keystore-password、security.ssl.keystore、security.ssl.truststore-password、security.ssl.trustore。
YARN 内部认证方式	该方式是 YARN 内部的认证方式，不需要用户配置。	-

说明

当前一个 Flink 集群只支持一个用户，一个用户可以创建多个 Flink 集群。

加密传输

Flink 整个系统存在三种加密传输方式：

- 使用 Yarn 内部的加密传输方式：Flink yarn client 与 Yarn Resource Manager、Yarn Resource Manager 与 Job Manager。
- SSL：Flink yarn client 与 JobManager、JobManager 与 TaskManager、TaskManager 与 TaskManager。
- 使用 Hadoop 内部的加密传输方式：JobManager 和 HDFS、TaskManager 和 HDFS、JobManager 与 ZooKeeper、TaskManager 与 ZooKeeper。

说明

Yarn 内部和 Hadoop 内部都不需要用户配置加密，用户只需要配置 SSL 加密传输方式。

配置 SSL 传输，用户主要在客户端的“flink-conf.yaml”文件中做如下配置：

1. 打开 SSL 开关和设置 SSL 加密算法，配置参数如表 6-17 所示，请根据实际情况修改对应参数值。

表6-17 参数描述

参数	参数值示例	描述
security.ssl.enabled	true	打开 SSL 总开关。
akka.ssl.enabled	true	打开 akka SSL 开关。
blob.service.ssl.enabled	true	打开 blob 通道 SSL 开关。
taskmanager.data.ssl.enabled	true	打开 taskmanager 之间通信的 SSL 开关。
security.ssl.algorithms	TLS_DHE_RSA_WITH_AES_128_GCM_SHA256,TLS_ECDHE_RSA_WITH_AES_128_GCM_SHA256,TLS_DHE_RSA_WITH_AES_256_GCM_SHA384,TLS_ECDHE_RSA_WITH_AES_256_GCM_SHA384	设置 SSL 加密的算法。

说明

如果打开 Task Manager 之间 data 传输通道的 SSL，对性能会有较大影响，需要用户从安全和性能综合考虑。

2. 在 Flink 客户端的 bin 目录下，执行命令 **sh generate_keystore.sh** <*password*>，请参考 6.4.2 认证和加密，表 6-18 中的配置项会被默认赋值，用户也可以手动配置。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

表6-18 参数描述

参数	参数值示例	描述
security.ssl.keystore	${path}/flink.keystore	keystore 的存放路径，“flink.keystore”表示用户通过 generate_keystore.sh*工具生成的 keystore 文件名称。
security.ssl.keystore-password	-	keystore 的 password，-表示需要用户输入自定义设置的密码值。
security.ssl.key-password	-	ssl key 的 password，-表示需要用户输入自定义设置的密码值。
security.ssl.truststore	${path}/flink.truststore	truststore 存放路径，“flink.truststore”表示用户通过 generate_keystore.sh*工具生成的 truststore 文件名称。
security.ssl.truststore-password	-	truststore 的 password，-表示需要用户输入自定义设置的密码值。

说明

“path”目录是用来存放 SSL keystore、truststore 相关配置文件，该目录是由用户自定义创建。

3. 配置客户端访问 keystore 或 truststore 文件路径。
   - 相对路径（推荐）

     请执行如下步骤配置“flink.keystore”和“flink.truststore”文件路径为相对路径，并确保 Flink 客户端执行命令的目录可以直接访问该相对路径。

     i. 在 Flink 客户端“conf”目录下新建目录，例如 ssl。

     cd */Flink 客户端目录*/**Flink/flink/conf/**

     mkdir ssl

     ii. 移动“flink.keystore”和“flink.truststore”文件到新建目录中。

     mv flink.keystore ssl/

     mv flink.truststore ssl/

     iii. 修改“flink-conf.yaml”文件中如下两个参数为相对路径。

     vi */Flink 客户端目录*/**Flink/flink/conf/flink-conf.yaml**

     ```
     security.ssl.keystore: ssl/flink.keystore
     security.ssl.truststore: ssl/flink.truststore
     ```

   - 绝对路径

     执行“generate_keystore.sh”脚本后，默认在“flink-conf.yaml”文件中将“flink.keystore”和“flink.truststore”文件路径自动配置为绝对路径，此时需要将“conf”目录中的“flink.keystore”和“flink.truststore”文件分别放置在 Flink 客户端以及 Yarn 各个节点的该绝对路径上。

6.4.3 配置对接 Kafka

Flink 样例工程的数据存储在 Kafka 组件中。向 Kafka 组件发送数据（需要有 Kafka 权限用户），并从 Kafka 组件接收数据。

步骤 1 确保集群安装完成，包括 HDFS、Yarn、Flink 和 Kafka。

步骤 2 创建 Topic。

- 用户使用 Linux 命令行创建 topic，执行命令前需要使用 kinit 命令进行人机认证，如 **kinit flinkuser**。

说明

flinkuser 需要用户自己创建，并拥有创建 Kafka 的 topic 权限。

创建 topic 的命令格式：{zkQuorum}表示 ZooKeeper 集群信息，格式为 IP:port。{Topic}表示 Topic 名称。

bin/kafka-topics.sh --create --zookeeper {zkQuorum}/kafka --replication-factor 1 --partitions 5 --topic {Topic}

例如此处以 topic1 的数据为例：

```
/opt/client/Kafka/kafka/bin/kafka-topics.sh --create --zookeeper
10.96.101.32:2181,10.96.101.251:2181,10.96.101.177:2181,10.91.8.160:2181/kafka
--replication-factor 1 --partitions 5 --topic topic1
```

说明

ZooKeeper 集群信息如下：

- ZooKeeper 的 quorumpeer 实例业务 IP

  ZooKeeper 服务所有 quorumpeer 实例业务 IP。登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。

- ZooKeeper 客户端端口号

  登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。

- 服务端 topic 权限配置。

  将 Kafka 的 Broker 配置参数“allow.everyone.if.no.acl.found”的值修改为“true”。

步骤 3 安全认证。

安全认证的方式有三种：Kerberos 认证、SSL 加密认证和 Kerberos+SSL 模式认证，用户在使用的时候可任选其中一种方式进行认证。

- **Kerberos 认证配置**
  - 客户端配置。

    在 Flink 配置文件“flink-conf.yaml”中，增加 kerberos 认证相关配置（主要在“contexts”项中增加“KafkaClient”），示例如下：

    ```
    security.kerberos.login.keytab: /home/demo/keytab/flinkuser.keytab
    security.kerberos.login.principal: flinkuser
    security.kerberos.login.contexts: Client,KafkaClient
    security.kerberos.login.use-ticket-cache: false
    ```

  - 运行参数。

    关于“SASL_PLAINTEXT”协议的运行参数示例如下：

    ```
    --topic topic1 --bootstrap.servers 10.96.101.32:21007 --security.protocol SASL_PLAINTEXT  --sasl.kerberos.service.name kafka --kerberos.domain.name hadoop.系统域名.com //10.96.101.32:21007 表示 kafka 服务器的 IP:port
    ```

- **SSL 加密配置**
  - 服务端配置。

    登录 FusionInsight Manager 页面，选择“集群 > 服务 > Kafka > 配置”，参数类别设置为“全部配置”，搜索“ssl.mode.enable”并配置为“true”。

  - 客户端配置。

    i. 登录集群的 FusionInsight Manager，选择“集群 > 服务 > Kafka > 更多 > 下载客户端”，下载客户端压缩文件到本地机器。

    ii. 使用客户端根目录中的“ca.crt”证书文件生成客户端的“truststore”。

    执行命令如下：

    ```
    keytool -noprompt -import -alias myservercert -file ca.crt -keystore truststore.jks
    ```

    命令执行结果查看：

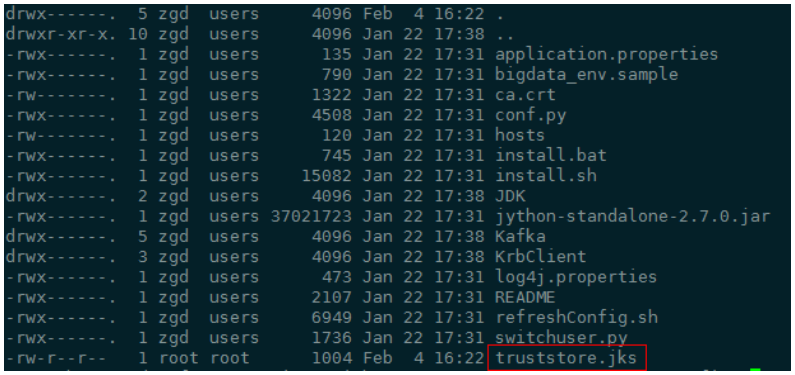

iii. 运行参数。

“ssl.truststore.password”参数内容需要跟创建“truststore”时输入的密码保持一致，执行以下命令运行参数。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

```
--topic topic1 --bootstrap.servers 10.96.101.32:9093 --
security.protocol SSL --ssl.truststore.location
/home/zgd/software/FusionInsight_Kafka_ClientConfig/truststore.jks --
ssl.truststore.password XXX
```

- **Kerberos+SSL 模式配置**

  完成上文中 Kerberos 和 SSL 各自的服务端和客户端配置后，只需要修改运行参数中的端口号和协议类型即可启动 Kerberos+SSL 模式。

```
--topic topic1 --bootstrap.servers 10.96.101.32:21009 --security.protocol
SASL_SSL --sasl.kerberos.service.name kafka --ssl.truststore.location --
kerberos.domain.name hadoop.系统域名.com
/home/zgd/software/FusionInsight_Kafka_ClientConfig/truststore.jks --
ssl.truststore.password XXX
```

----结束

6.4.4 配置 Pipeline

1. 配置文件。
   - nettyconnector.registerserver.topic.storage：设置 NettySink 的 IP、端口及并发度信息在第三方注册服务器上的路径（必填），例如：

     ```
     nettyconnector.registerserver.topic.storage: /flink/nettyconnector
     ```

   - nettyconnector.sinkserver.port.range：设置 NettySink 的端口范围（必填），例如：

     ```
     nettyconnector.sinkserver.port.range: 28444-28843
     ```

   - nettyconnector.ssl.enabled：设置 NettySink 与 NettySource 之间通信是否 SSL 加密（默认为 false），例如：

     ```
     nettyconnector.ssl.enabled: true
     ```

2. 安全认证配置。
   - Zookeeper 的 SASL 认证，依赖“flink-conf.yaml”中有关 HA 的相关配置。

- SSL 的 keystore、truststore、keystore password、truststore password 以及 password 等也使用“flink-conf.yaml”的相关配置，具体配置请参见加密传输。

6.5 配置开发 Flink 可视化作业

6.5.1 Flink WebUI 应用简介

Flink WebUI 提供基于 Web 的可视化开发平台，用户只需要编写 SQL 即可开发作业，极大降低作业开发门槛。同时通过作业平台能力开放，支持业务人员自行编写 SQL 开发作业来快速应对需求，大大减少 Flink 作业开发工作量。

Flink WebUI 特点

Flink WebUI 主要有以下特点：

- 企业级可视化运维：运维管理界面化、作业监控、作业开发 Flink SQL 标准化等。

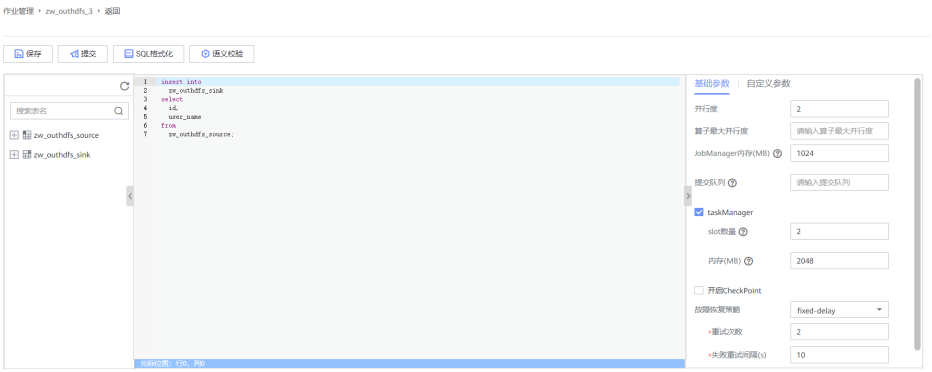

- 快速建立集群连接：通过集群连接功能配置访问一个集群，需要客户端配置、用户认证密钥文件。
- 快速建立数据连接：通过数据连接功能配置访问一个组件。创建“数据连接类型”为“HDFS”类型时需创建集群连接，其他数据连接类型的“认证类型”为“KERBEROS”需创建集群连接，“认证类型”为“SIMPLE”不需创建集群连接。

说明

“数据连接类型”为“Kafka”时，认证类型不支持“KERBEROS”。

- 可视化开发平台：支持自定义输入/输出映射表，满足不同输入来源、不同输出目标端的需求。
- 图形化作业管理：简单易用。

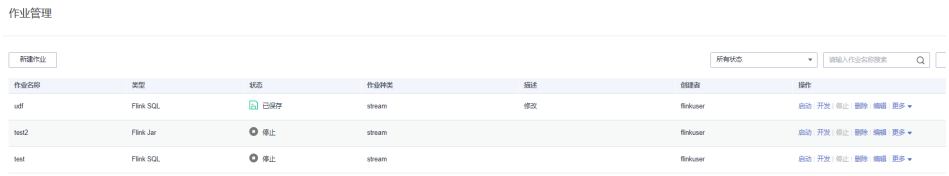

Flink WebUI 关键能力

FlinkWebUI 关键能力如表 6-19：

表6-19 Flink WebUI 关键能力

关键能力分类	描述
批流一体	• 支持一套 Flink SQL 定义批作业和流作业。
Flink SQL 内核能力	• Flink SQL 支持自定义大小窗、24 小时以内流计算、超出 24 小时批处理。 • Flink SQL 支持 Kafka、HDFS 读取；支持写入 Kafka 和 HDFS。 • 支持同一个作业定义多个 Flink SQL，多个指标合并在一个作业计算。当一个作业是相同主键、相同的输入和输出时，该作业支持多个窗口的计算。 • 支持 AVG、SUM、COUNT、MAX 和 MIN 统计方法。
Flink SQL 可视化定义	• 集群连接管理，配置 Kafka、HDFS 等服务所属的集群信息。 • 数据连接管理，配置 Kafka、HDFS 等服务信息。 • 数据表管理，定义 Sql 访问的数据表信息，用于生成 DDL 语句。 • Flink SQL 作业定义，根据用户输入的 Sql，校验、解析、优化、转换成 Flink 作业并提交运行。
Flink 作业可视化管理	• 支持可视化定义流作业和批作业。 • 支持作业资源、故障恢复策略、Checkpoint 策略可视化配置。 • 流作业和批作业的状态监控。 • Flink 作业运维能力增强，包括原生监控页面跳转。
性能&可靠性	• 流处理支持 24 小时窗口聚合计算，毫秒级性能。 • 批处理支持 90 天窗口聚合计算，分钟级计算完成。 • 支持对流处理和批处理的数据进行过滤配置，过滤无效数据。 • 读取 HDFS 数据时，提前根据计算周期过滤。 • 作业定义平台故障、服务降级，不支持再定义作业，但是不影响已有作业计算。 • 作业故障有自动重启机制，重启策略可配置。

Flink WebUI 应用流程

Flink WebUI 应用流程参考如下步骤：

图6-5 Flink WebUI 应用流程

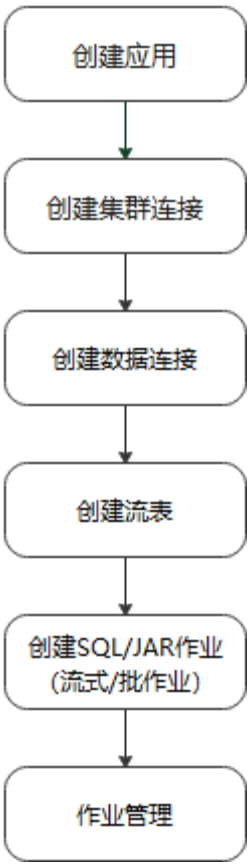

表6-20 Flink WebUI 应用流程说明

阶段	说明	参考章节
创建应用	通过应用来隔离不同的上层业务。	6.5.5 创建应用
创建集群连接	通过集群连接配置访问不同的集群。	6.5.6 创建集群连接
创建数据连接	通过数据连接，访问不同的数据服务，包括 HDFS、Kafka 等。	6.5.7 创建数据连接
创建流表	通过数据表，定义源表、维表、输出表的基本属性和字段信息。	6.5.8 创建流表
创建 SQL/JAR 作业（流式/批作业）	定义 Flink 作业的 API，包括 Flink SQL 和 Flink Jar 作业。	6.5.9 创建作业
作业管理	管理创建的作业，包括作业启动、开发、停止、删除和编辑等。	6.5.9 创建作业

6.5.2 Flink WebUI 权限管理

访问并使用 Flink WebUI 进行业务操作需为用户赋予 FlinkServer 相关权限，Manager 的 **admin** 用户没有 FlinkServer 的业务操作权限。

FlinkServer 中应用（租户）是最大管理范围，包含集群连接管理、数据连接管理、应用管理、流表和作业管理等。

FlinkServer 中有如表 6-21 所示三种资源权限：

表6-21 FlinkServer 资源权限

权限名称	权限描述	备注
FlinkServer 管理员权限	具有所有应用的编辑、查看权限。	是 FlinkServer 的最高权限。如果已经具有 FlinkServer 管理员权限，则会自动具备所有应用的权限。
应用编辑权限	具有当前应用编辑权限的用户，可以执行创建、编辑和删除集群连接、数据连接，创建流表、创建作业及运行作业等操作。	同时具有当前应用查看权限。
应用查看权限	具有当前应用查看权限的用户，可以查看应用。	-

6.5.3 创建 FlinkServer 角色

该任务指导 MRS 集群管理员在 Manager 创建并设置 FlinkServer 的角色。FlinkServer 角色可设置 FlinkServer 管理员权限以及应用的编辑和查看权限。

用户需要在 FlinkServer 中对指定的用户设置权限，才能够更新数据、查询数据和删除数据等。

前提条件

集群管理员已根据业务需要规划权限。

操作步骤

步骤 1 登录 Manager。

步骤 2 选择“系统 > 权限 > 角色”。

步骤 3 单击“添加角色”，然后在“角色名称”和“描述”输入角色名字与描述。

步骤 4 设置角色“配置资源权限”。

FlinkServer 权限类型：

- FlinkServer 管理员权限：是最高权限，具有 FlinkServer 所有应用的业务操作权限。
- FlinkServer 应用权限：可设置对应用的“应用查看”、“应用编辑”权限。

表6-22 设置角色

任务场景	角色授权操作
设置 FlinkServer 管理员权限	在“配置资源权限”的表格中选择“*待操作集群的名称* > Flink”，勾选“FlinkServer 管理操作权限”。
设置 FlinkServer 应用权限	在“配置资源权限”的表格中选择“*待操作集群的名称* > Flink > FlinkServer 应用”，在“权限”列，根据需要勾选“应用查看”或“应用编辑”。

步骤 5 单击“确定”完成，返回角色管理。

步骤 6 （可选）创建具有 FlinkServer 相关权限的用户。

FlinkServer 角色创建成功后，可创建一个 FlinkServer 用户，并绑定设置的 FlinkServer 角色和用户组。

----结束

6.5.4 访问 Flink WebUI

操作场景

MRS 集群安装 Flink 组件后，用户可以通过 Flink 的 WebUI，在图形化界面进行集群连接、数据连接、流表管理和作业管理等。

该任务指导用户在 MRS 集群中访问 Flink WebUI。

对系统的影响

第一次访问 Manager 和 Flink WebUI，需要在浏览器中添加站点信任以继续访问 Flink WebUI。

操作步骤

步骤 1 使用具有 FlinkServer 管理员权限的用户登录 FusionInsight Manager，选择“集群 > 服务 > Flink”。

说明

对于开启了 Kerberos 认证的 MRS 集群，访问 Flink WebUI，需提前创建具有 FlinkServer 管理员权限或应用查看、应用编辑权限的角色，并为用户绑定该角色，角色创建可参考 6.5.3 创建 FlinkServer 角色。

步骤 2 在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

Flink WebUI 支持以下功能：

- 使用系统管理可以支持以下功能：
  - 使用集群连接管理可以创建、查看、编辑、测试和删除集群连接。
  - 使用数据连接管理可以创建、查看、编辑、测试和删除数据连接。数据连接类型包含 HDFS、Kafka 等。
  - 使用应用管理可以创建、查看、删除应用。
- 使用流表管理可以新建、查看、编辑和删除流表。
- 使用作业管理可以新建、查看、启动、开发、编辑、停止和删除作业等。

----结束

6.5.5 创建应用

操作场景

通过应用来隔离不同的上层业务。

创建应用

步骤 1 使用具有 FlinkServer 管理员权限的用户访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 选择“系统管理 > 应用管理”，进入应用管理页面。

步骤 3 单击“创建应用”，在弹出的页面中填写应用信息，单击“确定”，完成应用创建。

应用创建成功后，在 Flink WebUI 左上角即可切换待操作的应用，然后进行相关的作业开发。

----结束

6.5.6 创建集群连接

操作场景

通过集群连接配置访问不同的集群。

创建集群连接

步骤 1 访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 选择“系统管理 > 集群连接管理”，进入集群连接管理页面。

步骤 3 单击“创建集群连接”，在弹出的页面中参考表 6-23 填写信息，单击“确定”，完成集群连接创建。创建完成后，可在对应集群连接的“操作”列对集群连接进行编辑、测试、删除等操作。

表6-23 创建集群连接信息

参数名称	参数描述
集群连接名称	集群连接的名称。
描述	集群连接名称描述信息。
版本	选择集群版本。
是否安全版本	• 是，安全集群选择是。需要输入访问用户名和上传用户凭证； • 否，非安全集群选择否。
访问用户名	访问用户需要包含访问集群中服务所需要的最小权限。 “是否安全版本”选择“是”时存在此参数。
客户端配置文件	集群客户端配置文件，格式为 tar。
用户凭据	FusionInsight Manager 中用户的认证凭据，格式为 tar。 “是否安全版本”选择“是”时存在此参数。 输入访问用户名后才可上传文件。

说明

集群客户端配置文件获取方法：

1. 登录 FusionInsight Manager，选择“集群 > 概览”。
2. 选择“更多 > 下载客户端 > 仅配置文件”，选择平台类型后单击“确定”。

用户凭据获取方法：

1. 登录 FusionInsight Manager，单击“系统”。
2. 在对应用户的“操作”列，选择“更多 > 下载认证凭据”，选择集群后单击“确定”。

----结束

6.5.7 创建数据连接

操作场景

通过数据连接，访问不同的数据服务，当前 FlinkServer 支持 HDFS、Kafka 类型的数据连接。

创建数据连接

步骤 1 访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 选择“系统管理 > 数据连接管理”，进入数据连接管理页面。

步骤 3 单击“创建数据连接”，在弹出的页面中选择数据连接类型，参考表 6-24 填写信息，单击“确定”，完成数据连接创建。创建完成后，可在对应数据连接的“操作”列对数据连接进行编辑、测试、删除等操作。

表6-24 创建数据连接信息

参数名称	参数描述	示例
数据连接类型	选择数据连接的类型，包含 HDFS、Kafka。	-
数据连接名称	数据连接的名称。	-
集群连接	配置管理里的集群连接名称。 HDFS 类型数据连接需配置该参数。	-
Kafka broker	Kafka Broker 实例的连接信息，格式为“IP 地址:端口”，多个实例之间通过逗号分割。 Kafka 类型数据连接需配置该参数。	192.168.0.1:21005,192.168.0.2:21005
认证类型	• SIMPLE：表示对接的服务是非安全模式，无需认证。 • KERBEROS：表示对接的服务是安全模式，安全模式的服务统一使用 Kerberos 认证协议进行安全认证。	-

----结束

6.5.8 创建流表

操作场景

通过数据表，定义源表、维表、输出表的基本属性和字段信息。

新建流表

步骤 1 访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 单击“流表管理”进入流表管理页面。

步骤 3 单击“新建流表”，在新建流表页面参考表 6-25 填写信息，单击“确定”，完成流表创建。创建完成后，可在对应流表的“操作”列对流表进行编辑、删除等操作。

表6-25 新建流表信息

参数名称	参数描述	备注
流/表名称	流/表的名称。	例如：flink_sink

参数名称	参数描述	备注
描述	流/表的描述信息。	-
映射表类型	Flink SQL 本身不带有数据存储功能，所有涉及表创建的操作，实际上均是对于外部数据表、存储的引用映射。 类型包含 Kafka、HDFS。	-
类型	包含数据源表 Source，数据结果表 Sink。不同映射表类型包含的表如下所示。 • Kafka：Source、Sink • HDFS：Source、Sink	-
数据连接	选择数据连接。	-
Topic	读取的 Kafka 的 topic，支持从多个 Kakfa topic 中读取，topic 之间使用英文分隔符进行分隔。 “映射表类型”选择“Kafka”时存在此参数。	-
文件路径	要传输的 HDFS 目录或单个文件路径。 “映射表类型”选择“HDFS”时存在此参数。	例如： “/user/sqoop/ ”或“/user/sqoop/example.csv”
编码	选择不同“映射表类型”对应的编码如下： • Kafka：CSV、JSON • HDFS：CSV	-
前缀	“映射表类型”选择“Kafka”，且“类型”选择“Source”，“编码”选择“JSON”时含义为：多层嵌套 json 的层级前缀，使用英文逗号(,)进行分隔。	例如：data,info 表示取嵌套 json 中 data，info 下的内容，作为 json 格式数据输入
分隔符	选择不同“映射表类型”对应的含义为：用于指定 CSV 字段分隔符。当数据“编码”为“CSV”时存在此参数。	例如：“,”
行分隔符	文件中的换行符，包含“\r”、“\n”、“\r\n”。 “映射表类型”选择“HDFS”时存在此参数。	-
列分隔符	文件中的字段分隔符。 “映射表类型”选择“HDFS”时存在此参数。	例如：“,”
流/表结构	填写流/表结构，包含名称，类型。	-
Proctime	指系统时间，与数据本身的时间戳无关，即在 Flink 算子内计算完成的时间。	-

参数名称	参数描述	备注
	“类型”选择“Source”时存在此参数。	
Event Time	指事件产生的时间，即数据产生时自带时间戳。 “类型”选择“Source”时存在此参数。	-

----结束

6.5.9 创建作业

操作场景

定义 Flink 的作业，包括 Flink SQL 和 Flink Jar 作业。

新建作业

步骤 1 访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 单击“作业管理”进入作业管理页面。

步骤 3 单击“新建作业”，在新建作业页面可选择新建 Flink SQL 作业或 Flink Jar 作业，然后填写作业信息，单击“确定”，创建作业成功并进入作业开发界面。

步骤 4 （可选）如果需要立即进行作业开发，可以在作业开发界面进行作业配置。

进行作业开发时，系统支持对作业添加锁的功能，锁定作业的用户具备该作业的所有权限，其他用户不具备被锁定的作业的开发、启动和删除等权限，但可通过强制获取锁来具备作业的所有权限。开启该功能后，可直接通过单击“锁定作业”、“解锁作业”、“强制获取锁”来获取相应的权限。

说明

系统默认开启作业锁功能，可在 Manager 查看该功能启用状态。适用于 MRS 3.3.0 及以后版本。

登录 Manager，选择“集群 > 服务 > Flink > 配置 > 全部配置”，搜索参数“job.edit.lock.enable”，参数值为“true”表示开启，值为“false”表示关闭。

- 新建 Flink SQL 作业
  a. 在作业开发界面进行作业开发。

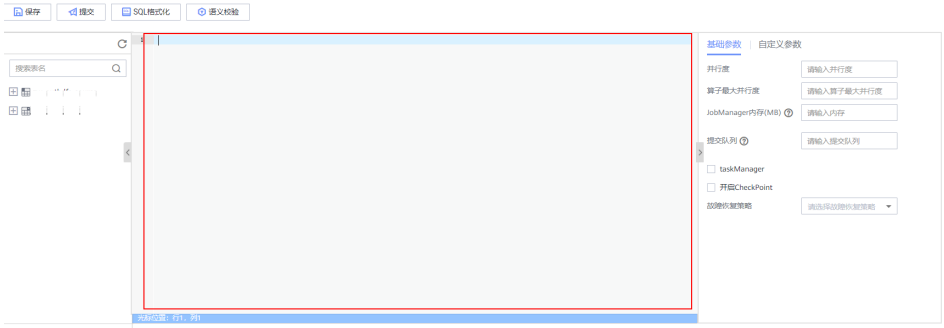

b. 可以单击上方“语义校验”对输入内容校验，单击“SQL 格式化”对 SQL 语句进行格式化。

c. 作业 SQL 开发完成后，请参考表 6-26 设置基础参数，还可根据需要设置自定义参数，然后单击“保存”。

表6-26 基础参数

参数名称	参数描述
并行度	并行数量。
算子最大并行度	算子最大的并行度。
JobManager 内存（MB）	JobManager 的内存。输入值最小为 4096。
提交队列	作业提交队列。不填默认提交到 default。
taskManager	taskManager 运行参数。该参数需配置以下内容： • slot 数量：不填默认是 1，建议填 CPU 核数； • 内存（MB）：输入值最小为 4096。
开启 CheckPoint	是否开启 CheckPoint。开启后，需配置以下内容： • 时间间隔（ms）：必填； • 模式：必填； 可选项为：EXACTLY_ONCE、AT_LEAST_ONCE； • 最小间隔（ms）：输入值最小为 10； • 超时时间：输入值最小为 10； • 最大并发量：正整数，且不能超过 64 个字符； • 是否清理：是/否； • 是否开启增量 Checkpoint：是/否。
故障恢复策略	作业的故障恢复策略，包含以下三种，详情请参考 6.11 Flink 重启策略。 • fixed-delay：需配置“重试次数”和“失败重试间隔（s）”； • failure-rate：需配置“最大重试次数”、“时间间隔（min）”和“失败重试间隔（s）”； • none：无。

d. 单击左上角“提交”提交作业。

- 新建 Flink Jar 作业

a. 单击“选择”，上传本地 Jar 文件，并参考表 6-27 配置参数或添加自定义参数。

表6-27 参数配置

参数名称	参数描述
本地 jar 文件	上传 jar 文件。直接上传本地文件，大小不能超过“flinkserver.upload.jar.max.size”设置的阈值，默认 500MB。 登录 Manager，选择“集群 > 服务 > Flink > 配置 > 全部配置”，搜索参数“flinkserver.upload.jar.max.size”即可设置 jar 文件阈值，取值范围为 100-5120，单位 MB。
Main Class	Main-Class 类型。 • 默认：默认根据 Jar 包文件的 Mainfest 文件指定类名。 • 指定：手动指定类名。
类名	类名。 “Main Class”选择“指定”时存在该参数。
类参数	类参数，为 Main-Class 的参数（参数间用空格分隔）。
并行度	并行数量。 并行数为作业每个算子的并行数，适度增加并行数会提高作业整体算力，但也须考虑线程增多带来的切换开销，其上限是计算单元 SPU 数的四倍，最佳实践为计算单元 SPU 数的 1-2 倍。
JobManager 内存（MB）	JobManager 的内存。输入值最小为 4096。
提交队列	作业提交队列。不填默认提交到 default。
taskManager	taskManager 运行参数。该参数需配置以下内容： • slot 数量：不填默认是 1，建议填 CPU 核数； • 内存（MB）：输入值最小为 4096。

b. 单击“保存”保存配置，单击“提交”提交作业。

步骤 5 返回作业管理页面，可以查看到已创建的作业名称、类型、状态、作业种类和描述等信息。

作业创建完成后，可在对应作业的“操作”列对作业进行启动、开发、停止、编辑、删除、查看作业详情和 Checkpoint 故障恢复等操作。

说明

- 若要使用其他用户在节点上读取已提交的作业相关文件，需确保该用户与提交作业的用户具有相同的用户组和具有对应的 FlinkServer 应用管理权限角色，如参考 6.5.3 创建 FlinkServer 角色勾选“应用查看”。
- 作业状态为“运行中”的作业可以查看作业详情。
- 作业状态为“运行失败”、“运行成功”和“停止”的作业可以进行 Checkpoint 故障恢复。

----结束

6.5.10 配置依赖管理

本章节适用于 MRS 3.3.0 及之后的版本。

Flink 支持通过第三方依赖包来运行自定义 Flink 作业。可以在 Flink WebUI 界面中上传并管理依赖 jar 包，然后在运行作业时调用对应依赖。依赖管理暂不支持“语义”校验功能，依赖 jar 包名称需以字母、数字或下划线开头，且不超过 32 个字符。支持如下两种第三方依赖：

- 自定义 connector 依赖：用户自定义 connector jar 包，上传后在 Flink WebUI 界面中“依赖类型”显示为“connector”。
- 非自定义 connector 依赖：非用户自定义 connector jar 包，如作业依赖包，上传后在 Flink WebUI 界面中“依赖类型”显示为“normal”。

前提条件

准备依赖文件。若通过“指定路径”方式将依赖上传到集群，需提前创建 HDFS 路径，并将 jar 包上传至 HDFS 中。

上传依赖包

步骤 1 登录 FusionInsight Manager，访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 单击“依赖管理”进入依赖管理页面。

步骤 3 单击“添加依赖”，可参考如下添加依赖。

表6-28 添加依赖

参数	描述	示例
是否自定义 connector	是否自定义 connector，根据实际需求选择： • 是：文件为自定义 connector 依赖包。 • 否：文件为非自定义 connector 依赖包。	是
名称	添加的依赖名称，需与上传的依赖包中 connector 的连接名一致。不支持上传同名依赖包。	kafka
注册 jar	jar 包的上传方式： • 上传文件：添加本地的 jar 包 • 指定路径：已准备好的依赖文件的 HDFS 路径	上传文件
上传文件	注册 jar 选择为“上传文件”时，需通过该项上传本地 jar 文件。	-
指定路径	注册 jar 选择为“指定路径”时，需通过该项输入依赖文件的 HDFS 路径（需提前准备好 jar 包上传至 HDFS）。	/flink_upload_test/flink-connector-kafka-

参数	描述	示例
		customization.jar
描述信息	添加的依赖的描述信息。	-

步骤 4 单击“确定”。

----结束

使用示例

- 自定义 connector 依赖
  a. 参考上传依赖包上传自定义 connector 依赖。
     如上传依赖名称为“**kafka**”，自定义 connector jar 包名称为“flink-connector-kafka-customization.jar”。
  b. 参考 6.5.9 创建作业新建 SQL 作业，该 SQL 中的“connector”需填写为对应的依赖名称，如**'connector' = 'kafka'**。

```
CREATE TABLE KafkaSinkTable (`user_id` INT, `name` VARCHAR) WITH (
  'connector' = 'kafka',
  'topic' = 'test_sink6',
  'properties.bootstrap.servers' = '192.168.20.134:21005',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'earliest-offset',
  'format' = 'csv'
);
CREATE TABLE datagen (`user_id` INT, `name` VARCHAR) WITH (
  'connector' = 'datagen',
  'rows-per-second' = '5',
  'fields.user_id.kind' = 'sequence',
  'fields.user_id.start' = '1',
  'fields.user_id.end' = '1000'
);
insert INTO
  KafkaSinkTable
select
  *
from
  datagen;
```

- 非自定义 connector 依赖使用样例
  参考上传依赖包上传作业依赖的非自定义 connector 依赖即可。

6.5.11 配置管理 UDF

本章节适用于 MRS 3.1.2 及之后的版本。

用户可以自定义一些函数，用于扩展 SQL 以满足个性化的需求，这类函数称为 UDF。用户可以在 Flink WebUI 界面中上传并管理 UDF jar 包，然后在运行作业时调用相关 UDF 函数。

Flink 支持以下 3 类自定义函数，如表 6-29。

表6-29 函数分类

分类	描述
UDF（User Defined Scalar Function）	自定义函数，支持一个或多个输入参数，返回一个结果值。详情请参考 UDF java 代码及 SQL 样例。
UDAF（User Defined Aggregation Function）	自定义聚合函数，将多条记录聚合成一个值。详情请参考 UDAF java 代码及 SQL 样例。
UDTF（User Defined Table-valued Function）	自定义表值函数，支持一个或多个输入参数，可返回多行多列。详情请参考 UDTF java 代码及 SQL 样例。

前提条件

准备 UDF jar 文件，大小不能超过 200MB。

上传 UDF

步骤 1 访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 单击“UDF 管理”进入 UDF 管理页面。

步骤 3 单击“添加 UDF”，在“本地 Jar 文件”参数后选择并上传本地已准备好的 UDF jar 文件。

步骤 4 填写 UDF 名称以及描述信息后，单击“确定”。

说明

- “UDF 名称”最多可添加 10 项，“名称”可自定义，“类名”需与上传的 UDF jar 文件中 UDF 函数全限定类名一一对应。
- 上传 UDF jar 文件后，服务器默认保留 5 分钟，5 分钟内单击确定则完成 UDF 创建，超时后单击确定则创建 UDF 失败并弹出错误提示：本地 UDF 文件路径有误。

步骤 5 在 UDF 列表中，可查看当前应用内所有的 UDF 信息。可在对应 UDF 信息的“操作”列编辑或删除 UDF 信息（只能删除未被使用的 UDF 项）。

步骤 6 （可选）如果需要立即运行或开发作业，可在“作业管理”进行相关作业配置，可参考 6.5.9 创建作业。

----结束

UDF java 代码及 SQL 样例

- UDF java 使用样例

```
package com.xxx.udf;
import org.apache.flink.table.functions.ScalarFunction;
public class UdfClass_UDF extends ScalarFunction {
    public int eval(String s) {
```

```
        return s.length();
    }
}
```

- UDF SQL 使用样例

```
CREATE TEMPORARY FUNCTION udf as 'com.xxx.udf.UdfClass_UDF';
CREATE TABLE udfSource (a VARCHAR) WITH ('connector' = 'datagen','rows-per-
second'='1');
CREATE TABLE udfSink (a VARCHAR,b int) WITH ('connector' = 'print');
INSERT INTO
  udfSink
SELECT
  a,
  udf(a)
FROM
  udfSource;
```

UDAF java 代码及 SQL 样例

- UDAF java 使用样例

```
package com.xxx.udf;
import org.apache.flink.table.functions.AggregateFunction;
public class UdfClass_UDAF {
    public static class AverageAccumulator  {
        public int sum;
    }
    public static class Average extends AggregateFunction<Integer,
AverageAccumulator> {
        public void accumulate(AverageAccumulator acc, Integer value) {
            acc.sum += value;
        }
        @Override
        public Integer getValue(AverageAccumulator acc) {
            return acc.sum;
        }
        @Override
        public AverageAccumulator createAccumulator() {
            return new AverageAccumulator();
        }
    }
}
```

- UDAF SQL 使用样例

```
CREATE TEMPORARY FUNCTION udaf as 'com.xxx.udf.UdfClass_UDAF$Average';
CREATE TABLE udfSource (a int) WITH ('connector' = 'datagen','rows-per-
second'='1','fields.a.min'='1','fields.a.max'='3');
CREATE TABLE udfSink (b int,c int) WITH ('connector' = 'print');
INSERT INTO
  udfSink
SELECT
  a,
  udaf(a)
FROM
  udfSource group by a;
```

UDTF java 代码及 SQL 样例

- UDTF java 使用样例

```
package com.xxx.udf;
import org.apache.flink.api.java.tuple.Tuple2;
import org.apache.flink.table.functions.TableFunction;
public class UdfClass_UDTF extends TableFunction<Tuple2<String, Integer>> {
    public void eval(String str) {
        Tuple2<String, Integer> tuple2 = Tuple2.of(str, str.length());
        collect(tuple2);
    }
}
```

- UDTF SQL 使用样例

```
CREATE TEMPORARY FUNCTION udtf as 'com.xxx.udf.UdfClass_UDTF';
CREATE TABLE udfSource (a VARCHAR) WITH ('connector' = 'datagen','rows-per-
second'='1');
CREATE TABLE udfSink (b VARCHAR,c int) WITH ('connector' = 'print');
INSERT INTO
  udfSink
SELECT
  str,
  strLength
FROM
  udfSource,lateral table(udtf(udfSource.a)) as T(str,strLength);
```

6.5.12 Flink UDF 重用

本章节适用于 MRS 3.3.0 及以后版本。

操作场景

FlinkSQL 的 UDF 新增重用功能，当 UDF 被多次执行时，第 N（N>1）次执行只复制第 1 次结果，可以确保 UDF 多次执行的数据一致性，同时确保 UDF 只被执行一次，提高算子性能。

使用方法

配置 Flink 作业时，可通过在 FlinkServer WebUI 的 Flink 作业开发界面添加自定义参数“table.optimizer.function-reuse-enabled”为“true”开启 UDF 重用功能，可参考 6.5.9 创建作业。

示例

- UDF：

```
class ItemExist extends ScalarFunction {
  val items: mutable.Set[String] = mutable.Set[String]()

  def eval(item: String): Boolean = {
    val exist = items.contains(item);
    if (!exist) {
      items.add(item)
    }
```

```
    exist
  }
}
```

- SQL 语句：

  SELECT * FROM (SELECT `a`, IfExist(b) as `exist`, `c` FROM Table1) WHERE exist IS FALSE;

- 执行结果：
  - 未开启 UDF 重用时的返回值：

    ```
    a,true,c
    ```

    因为在 WHERE 条件中 IfExist 被执行一次，并且结果为 false，所以在其缓存中已存储该数据，在 SELECT 中再次执行时即返回 true。
  - 开启 UDF 重用时的返回值：

    ```
    a,false,c
    ```

6.5.13 导入导出作业

操作场景

FlinkServer WebUI 页面支持作业、UDF、流表的导入导出，不支持集群管理、数据连接、应用管理、CheckPoint 的导入导出。

- 当导入时，同一集群内不支持导入同名的作业、同名的流表、同名的 UDF。
- 作业导出时，需手动勾选作业依赖的流表、UDF 等信息，若未勾选，校验时会弹出提示框提示需要勾选的依赖数据。作业的应用信息不会导出。
- 流表导出时，不解析处理流表的依赖，即流表依赖的应用信息不会导出。
- UDF 导出时，不解析处理 UDF 的依赖和被动依赖，即 UDF 依赖的应用信息和在哪些作业被使用的信息不会导出。
- 支持不同应用之间的导入导出。

须知

根据安全需求，导入或导出 FlinkSQL 作业时，作业中的“password”字段会被置为空。提交作业前，需手动补齐密码信息。

导入作业

步骤 1 使用具有 FlinkServer 管理员权限的用户访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 选择“系统管理 > 导入作业”，进入导入作业页面。

步骤 3 单击“选择”，选择本地 Tar 文件，单击“确定”，等待导入完成。

说明

上传的本地 Tar 文件最大支持 200M。

----结束

导出作业

步骤 1 使用具有 FlinkServer 管理员权限的用户访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 选择“系统管理 > 导出作业”，进入导出作业页面。

步骤 3 可通过如下两种方式选择待导出的内容，单击“清除选中节点”可取消勾选。

- 根据需求直接勾选待导出的内容。
- 单击“正则表达式输入”，选择待导出的类型（流表管理、作业管理、UDF 管理），输入关键字，单击“查询”，待数据匹配成功后，单击“同步”即完成勾选。

说明

数据匹配成功后，单击“同步”会勾选所有匹配的数据，暂不支持挑选部分数据同步。

步骤 4 单击“校验”，校验通过后单击“确定”，等待导出完成。

----结束

6.5.14 Flink 作业级巡检能力

本章节适用于 MRS 3.3.0 及之后的版本。

操作场景

当集群运行大量 Flink 作业时，为方便用户对每个作业进行健康状态评估，FlinkServer WebUI 提供 Flink 作业健康度管理功能，用户可直接在页面查看当前作业的健康情况，并可一键导出所有作业的健康度信息。作业状态分如下情况：

- 健康：作业运行正常，作业状态健康。
- 亚健康：
  - 出现“ALM-45637 Flink 作业 task 持续背压”告警，根据告警信息修复告警后，健康状态自动恢复至健康。
  - 出现“ALM-45639 Flink 作业 checkpoint 完成时间超过阈值”告警，根据告警信息修复告警后，健康状态自动恢复至健康。
- 不健康：
  - 出现“ALM-45636 Flink 作业连续 checkpoint 失败”告警，根据告警信息修复告警后，健康状态自动恢复至健康。
  - 出现“ALM-45638 Flink 作业失败重启次数超阈值”告警，根据告警信息修复告警后，需重启该作业，作业自动恢复至健康。

前提条件

- 集群运行正常，并已安装集群客户端。

- 提交作业前，需配置“*客户端安装路径*/Flink/flink/conf/flink-conf.yaml”文件，开启作业注册到 FlinkServer 功能和作业告警功能，参数设置如下：

表6-30 开启作业注册和作业告警功能

参数	值	描述
job.register.enable	true	是否开启作业注册到 FlinkServer： • true：开启 • false：不开启
job.alarm.enable	true	是否开启作业告警： • true：开启 • false：不开启

说明

通过客户端注册到 FlinkServer 的作业，若未开启作业注册到 FlinkServer 功能，暂不支持在 FlinkServer WebUI 执行启动、开发、停止等操作。

- 需确保未使用“Session 模式”提交作业并且需要指定作业名。

操作步骤

步骤 1 访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 单击“作业管理”进入作业管理页面。

- 查看作业健康度

  在作业管理页面查看当前作业的健康状态：

  - 空：作业未运行，无健康状态
  - 绿色图标：健康
  - 黄色图标：亚健康
  - 红色图标：不健康

- 导出所有作业健康报告

  单击“作业健康报告”，系统会自动将所有作业的健康状态信息导出至本地，包括作业名称，健康度，提交用户，告警信息，配置信息和启动时间等。

  - 健康度为“0”：健康
  - 健康度为“1”：亚健康
  - 健康度为“2”：不健康

----结束

6.6 配置 FlinkServer 对接其他组件

6.6.1 FlinkServer 对接 ClickHouse

本章节适用于 MRS 3.1.2 及之后的版本。

操作场景

Flink 通过对接 ClickHouse 的 ClickHouseBalancer 实例进行读写，有效避免 ClickHouse 流量分发问题。

须知

MRS 3.2.0 及以后版本，根据安全需求，FlinkServer 界面回显 FlinkSQL 时，SQL 中的“password”字段将显示为空，在回显状态下需要将密码信息补齐后再提交作业。

前提条件

- 集群中已安装 ClickHouse、HDFS、Yarn、Flink 和 Kafka 等服务。
- 客户端已安装，例如安装路径为：/opt/client。

FlinkSQL 与 ClickHouse 数据类型对应关系

FlinkSQL 数据类型	ClickHouse 数据类型
BOOLEAN	UInt8
TINYINT	Int8
SMALLINT	Int16
INTEGER	Int32
BIGINT	Int64
FLOAT	Float32
DOUBLE	Float64
CHAR	String
VARCHAR	String
VARBINARY	FixedString
DATE	Date
TIMESTAMP	DateTime
DECIMAL	Decimal

操作步骤

步骤 1 使用 **root** 用户登录安装客户端的节点。

步骤 2 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 3 执行以下命令配置环境变量。

source bigdata_env

步骤 4 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 ClickHouse 表的权限。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

kinit *组件业务用户*

例如，**kinit clickhouseuser**。

步骤 5 连接 ClickHouse 客户端，可参考 3.1 从零开始使用 ClickHouse。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

- 普通模式：

  clickhouse client --host *ClickHouse 的实例 IP* **--user** *登录名* **--password '***密码***' --port** *ClickHouse 的端口号* **--multiline**

- 安全模式：

  clickhouse client --host *ClickHouse 的实例 IP* **--user** *登录名* **--password '***密码***'--port** *ClickHouse 的端口号* **--secure --multiline**

步骤 6 执行以下命令创建复制表和分布式表。

1. 创建复制表“default.test1”。

```
CREATE TABLE default.test1 on cluster default_cluster
(
`pid` Int8,
`uid` UInt8,
`Int_16` Int16,
`Int_32` Int32,
`Int_64` Int64,
`String_x` String,
`String_y` String,
`float_32` Float32,
`float_64` Float64,
`Decimal_x` Decimal32(2),
`Date_x` Date,
`DateTime_x` DateTime
)
ENGINE =
ReplicatedReplacingMergeTree('/clickhouse/tables/{shard}/test1','{replica}')
PARTITION BY pid
ORDER BY (pid, DateTime_x);
```

2. 创建分布式表“test1_all”。

```
CREATE TABLE test1_all ON CLUSTER default_cluster
(
```

```
`pid` Int8,
`uid` UInt8,
`Int_16` Int16,
`Int_32` Int32,
`Int_64` Int64,
`String_x` String,
`String_y` String,
`float_32` Float32,
`float_64` Float64,
`Decimal_x` Decimal32(2),
`Date_x` Date,
`DateTime_x` DateTime
)
ENGINE = Distributed(default_cluster, default, test1, rand());
```

步骤 7 登录 Manager，选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 8 参考新建作业，新建 Flink SQL 作业，作业类型选择“流作业”。在作业开发界面进行如下作业配置，并启动作业。需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“60000”，“模式”可使用默认值。

- 如果当前 MRS 集群为安全模式，执行以下操作：

```
create table kafkasource(
`pid` TINYINT,
`uid` BOOLEAN,
`Int_16` SMALLINT,
`Int_32` INTEGER,
`Int_64` BIGINT,
`String_x` CHAR,
`String_y` VARCHAR(10),
`float_32` FLOAT,
`float_64` DOUBLE,
`Decimal_x` DECIMAL(9,2),
`Date_x` DATE,
`DateTime_x` TIMESTAMP
) with(
  'connector' = 'kafka',
  'topic' = 'input',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'properties.group.id' = 'group1',
  'scan.startup.mode' = 'earliest-offset',
  'format' = 'json',
  'properties.sasl.kerberos.service.name' = 'kafka',
  'properties.security.protocol' = 'SASL_PLAINTEXT',
  'properties.kerberos.domain.name' = 'hadoop.系统域名'
);
CREATE TABLE cksink (
`pid` TINYINT,
`uid` BOOLEAN,
`Int_16` SMALLINT,
`Int_32` INTEGER,
`Int_64` BIGINT,
`String_x` CHAR,
`String_y` VARCHAR(10),
```

```
`float_32` FLOAT,
`float_64` DOUBLE,
`Decimal_x` DECIMAL(9,2),
`Date_x` DATE,
`DateTime_x` TIMESTAMP
) WITH (
'connector' = 'jdbc',
'url' = 'jdbc:clickhouse://ClickHouseBalancer实例IP1:ClickHouseBalancer端口,ClickHouseBalancer实例IP2:ClickHouseBalancer端口
/default?ssl=true&sslmode=none',
'username' = 'ClickHouse用户，详见说明',
'password' = 'ClickHouse用户密码，详见说明',
'table-name' = 'test1_all',
'driver' = 'ru.yandex.clickhouse.ClickHouseDriver',
'sink.buffer-flush.max-rows' = '0',
'sink.buffer-flush.interval' = '60s'
);
Insert into cksink
select
*
from
kafkasource;
```

- 如果当前 MRS 集群为普通模式，执行以下操作：

```
create table kafkasource(
`pid` TINYINT,
`uid` BOOLEAN,
`Int_16` SMALLINT,
`Int_32` INTEGER,
`Int_64` BIGINT,
`String_x` CHAR,
`String_y` VARCHAR(10),
`float_32` FLOAT,
`float_64` DOUBLE,
`Decimal_x` DECIMAL(9,2),
`Date_x` DATE,
`DateTime_x` TIMESTAMP
) with(
  'connector' = 'kafka',
  'topic' = 'kinput',
  'properties.bootstrap.servers' = 'Kafka的Broker实例业务IP:Kafka端口号',
  'properties.group.id' = 'kafka_test',
  'scan.startup.mode' = 'earliest-offset',
  'format' = 'json'
);
CREATE TABLE cksink (
`pid` TINYINT,
`uid` BOOLEAN,
`Int_16` SMALLINT,
`Int_32` INTEGER,
`Int_64` BIGINT,
`String_x` CHAR,
`String y` VARCHAR(10),
`float 32` FLOAT,
`float 64` DOUBLE,
`Decimal_x` DECIMAL(9,2),
```

```
`Date_x` DATE,
`DateTime_x` TIMESTAMP
) WITH (
'connector' = 'jdbc',
'url' = 'jdbc:clickhouse://ClickHouseBalancer实例IP1:ClickHouseBalancer端口,ClickHouseBalancer实例IP2:ClickHouseBalancer端口/default',
'table-name' = 'test1_all',
'driver' = 'ru.yandex.clickhouse.ClickHouseDriver',
'sink.buffer-flush.max-rows' = '0',
'sink.buffer-flush.interval' = '60s'
);
Insert into cksink
select
*
from
kafkasource;
```

说明

- MRS 集群安全模式下，创建的 cksink 表中 username、password 参数填写的用户为具有 ClickHouse 相应表权限的用户及密码，详见 3.2.1 ClickHouse 用户及权限管理。
- Kafka 端口号：
- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为 9092，则需要配置“allow.everyone.if.no.acl.found”参数为 true，具体操作如下：

  登录 FusionInsight Manager 系统，选择“集群 > 服务 > Kafka > 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为 true，保存配置即可。
- 系统域名：可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。
- ClickHouseBalancer 端口号要根据对接的 ClickHouse 集群选择：
- 当 ClickHouse 所在集群为安全模式集群时，ClickHouseBalancer 端口号默认为“21428”。
- 当 ClickHouse 所在集群为普通模式集群时，ClickHouseBalancer 端口号默认为“21426”。
- url：可配置多个 ClickHouseBalancer 实例 IP 以避免 ClickHouseBalancer 实例单点故障。
- 写入 ClickHouse 时会过滤 Flink 计算过程中产生的 DELETE 消息。
- 攒批写参数：Flink 会将数据先放入内存，到达触发条件时再 flush 到数据库表中。相关配置如下。

  sink.buffer-flush.max-rows：攒批写 ClickHouse 的行数，默认 100。

  sink.buffer-flush.interval：攒批写入的间隔时间，默认 1s。

  这两个条件只要有一个满足，就会触发一次 sink，即到达触发条件时再 flush 到数据库表中。
- 情况一：60s sink 一次

  'sink.buffer-flush.max-rows' = '0',

  'sink.buffer-flush.interval' = '60s'
- 情况二：100 条 sink 一次

  'sink.buffer-flush.max-rows' = '100',

  'sink.buffer-flush.interval' = '0s'
- 情况三：数据不 sink

  'sink.buffer-flush.max-rows' = '0',

  'sink.buffer-flush.interval' = '0s'

步骤 9 查看作业管理界面，作业状态为“运行中”。

步骤 10 参考 16.5 管理 Kafka 主题中的消息，向 kafka 中写入数据。

sh kafka-console-producer.sh --broker-list *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic** *主题名称* **--producer.config** *客户端目录* **/Kafka/kafka/config/producer.properties**

例如本示例使用主题名称为 kinput：**sh kafka-console-producer.sh --broker-list** *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic kinput --producer.config /opt/client/Kafka/kafka/config/producer.properties**

输入消息内容：

```
{"pid": "3","uid":false,"Int_16": "6533","Int_32": "429496294","Int_64":
"1844674407370955614","String_x": "abc1","String_y": "abc1defghi","float_32":
"0.1234","float_64": "95.1","Decimal_x": "0.451236414","Date_x": "2021-05-
29","DateTime_x": "2021-05-21 10:05:10"}
{"pid": "4","uid":false,"Int_16": "6533","Int_32": "429496294","Int_64":
"1844674407370955614","String_x": "abc1","String_y": "abc1defghi","float_32":
"0.1234","float_64": "95.1","Decimal_x": "0.4512314","Date_x": "2021-05-
29","DateTime_x": "2021-05-21 10:05:10"}
```

输入完成后按回车发送消息。

步骤 11 连接 ClickHouse 查询表数据。

clickhouse client --host *ClickHouse 的实例 IP* **--user** *登录名* **--password '***密码***'--port** *ClickHouse 的端口号* **--secure --multiline**

执行查询命令查询 ClickHouse 表是否已写入数据。例如，当前 ClickHouse 表为 test1_all。

select * from test1_all;

----结束

6.6.2 FlinkServer 对接 GaussDB(DWS)

本章节适用于 MRS 3.2.0 及之后的版本。

操作场景

FlinkServer 支持对接 GaussDB（DWS）8.1.x 及之后版本，本章节介绍 GaussDB（DWS）作为 Source 表、Sink 表以及维表的 DDL 定义，以及创建表时使用的 WITH 参数和代码示例，并指导如何在 FlinkServer 作业管理页面操作。

本示例以安全模式 FlinkServer、Kafka 为例，对接安全模式 GaussDB（DWS）。

须知

根据安全需求，FlinkServer 界面回显 FlinkSQL 时，SQL 中的“password”字段将显示为空，在回显状态下需要将密码信息补齐后再提交作业。

FlinkSQL 与 GaussDB（DWS）数据类型对应关系

FlinkSQL 数据类型	GaussDB（DWS）数据类型
BOOLEAN	BOOLEAN
TINYINT	-
SMALLINT	SMALLINT(INT2)
	SMALLSERIAL(SERIAL2)
INTEGER	INTEGER
	SERIAL
BIGINT	BIGINT
	BIGSERIAL
FLOAT	REAL
	FLOAT4
DOUBLE	DOUBLE
	FLOAT8
CHAR	CHAR(n)
VARCHAR	VARCHAR(n)
DATE	DATE
TIMESTAMP	TIMESTAMP[(p)] [WITHOUT TIME ZONE]
DECIMAL	NUMERIC[(p[,s])]
	DECIMAL[(p[,s])]

前提条件

- 需确保 FlinkServer 所在集群和 GaussDB（DWS）所在集群网络互通，确保“可用区”、“虚拟私有云”、“安全组”配置相同。
- FlinkServer 所在集群（安全模式）：
  - 集群中已安装 HDFS、Yarn、Kafka、ZooKeeper 和 Flink 服务。
  - 包含 Kafka 服务的客户端已安装，安装路径如：/opt/client。
  - 参考 6.5.3 创建 FlinkServer 角色创建一个具有 FlinkServer 管理员权限的用户用于访问 Flink WebUI，如：**flinkuser**。
- 待对接的 GaussDB（DWS）所在集群（安全模式）：

  可参考如下命令连接数据库并创建接受数据的表：

  gsql -d *postgres* **-h** *IP* **-U** *username* **-p** *port* **-W** *password* **-r**

说明

- postgres：需要连接的数据库名称。
- IP：GaussDB(DWS) 集群地址。如果通过公网地址连接，请指定为集群“公网访问域名”，如果通过内网地址连接，请指定为集群“内网访问域名”。如果通过弹性负载均衡连接，请指定为“弹性负载均衡地址”。
- username 和 password：连接数据库的用户名及密码。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。
- port ：Coordinator 的端口号，请根据实际情况替换，可使用 **gs_om -t status --detail** 查询 Coordinator 数据路径，在该路径下的“postgresql.conf”文件中查看端口号信息。

创建用于接受数据的空表，如表“customer_t1”：

```
CREATE TABLE customer_t1
(
    c_customer_sk           INTEGER,
    c_customer_name         VARCHAR(32)
)
with (orientation = column,compression=middle)
distribute by hash (c_customer_name);
```

GaussDB 作为 Sink 表

步骤 1 使用 **flinkuser** 登录 Manager，选择“集群 > 服务 >Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 2 参考新建作业，新建 Flink SQL 流作业，参考如下内容在作业开发界面进行作业开发，配置完成后启动作业。

需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“60000”，“模式”可使用默认值。

```
CREATE TABLE MyUserTable(
  c_customer_sk INTEGER,
  c_customer_name VARCHAR(32)
) WITH(
  'connector' = 'jdbc',
  'url' = 'jdbc:gaussdb://GaussDB 的服务器 IP:数据库端口/postgres',
  'table-name' = 'customer_t1',--若在 schema（名为“base”）下创建表“customer_t1”时，配置规则为'table-name' = 'base"."customer_t1'
  'username' = 'username',--连接 GaussDB（DWS）数据库的用户名
  'password' = 'password',--连接 GaussDB（DWS）数据库的密码，注意提交作业需补齐密码
  'write.mode' = 'upsert',--数据写入模式为 upsert 时可设置是否忽略空值（适用于 MRS 3.3.0 及以后版本）
  'ignoreNullWhenUpsert' = 'false'--true 表示忽略 null 值，false 表示不忽略空值，将空值写到数据库中
);
CREATE TABLE KafkaSource (
  c_customer_sk INTEGER,
  c_customer_name VARCHAR(32)
) WITH (
  'connector' = 'kafka',
  'topic' = 'customer_source',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
```

```
  'value.format' = 'csv',
  'properties.sasl.kerberos.service.name' = 'kafka',  --FlinkServer所在集群为非安全模式去掉此参数
  'properties.security.protocol' = 'SASL_PLAINTEXT',  --FlinkServer所在集群为非安全模式去掉此参数
  'properties.kerberos.domain.name' = 'hadoop.系统域名'  --FlinkServer所在集群为非安全模式去掉此参数
);
Insert into
  MyUserTable
select
  *
from
  KafkaSource;
```

说明

- Kafka端口号：
- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为9092，则需要配置“allow.everyone.if.no.acl.found”参数为true，具体操作如下：

  登录FusionInsight Manager系统，选择“集群 > 服务 > Kafka > 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为true，保存配置即可。
- properties.group.id：Kafka的使用者组ID，Kafka作为source时必选。
- 系统域名：可登录FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。

步骤3 查看作业管理界面，作业状态为“运行中”。

步骤4 参考16.5 管理Kafka主题中的消息，查看Topic并向Kafka中写入数据。

./kafka-topics.sh --list --zookeeper *ZooKeeper的quorumpeer实例业务IP:ZooKeeper客户端端口号***/kafka**

sh kafka-console-producer.sh --broker-list *Kafka角色实例所在节点的IP地址:Kafka端口号* **--topic** *主题名称* **--producer.config** *客户端目录***/Kafka/kafka/config/producer.properties**

例如本示例使用主题名称为customer_source：

sh kafka-console-producer.sh --broker-list *Kafka角色实例所在节点的IP地址:Kafka端口号* **--topic customer_source --producer.config /opt/client/Kafka/kafka/config/producer.properties**

输入消息内容：

```
3,zhangsan
4,wangwu
8,zhaosi
```

输入完成后按回车发送消息。

说明

- ZooKeeper的quorumpeer实例业务IP：

  ZooKeeper服务所有quorumpeer实例业务IP。登录FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有quorumpeer实例所在主机业务IP地址。

- ZooKeeper 客户端端口号：

  登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。

步骤 5 登录 GaussDB 客户端执行以下命令查看 Sink 表中是否接收到数据，如下图所示。

Select * from customer_t1;

```
postgres=> select * from customer_t1;
 c_customer_sk | c_customer_name
---------------+-----------------
             1 | new Data
             8 | zhaosi
             0 | data 0
             3 | zhangsan
             4 | wangwu
             2 | data 2
(6 rows)
```

----结束

GaussDB 作为 Source 表

步骤 1 使用 **flinkuser** 登录 Manager，选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 2 参考新建作业，新建 Flink SQL 流作业，参考如下内容在作业开发界面进行作业开发，配置完成后启动作业。

需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“5000”，“模式”可使用默认值。

```
CREATE TABLE MyUserTable(
  --GuassDB 作为 source 表
  c_customer_sk INTEGER,
  c_customer_name VARCHAR(32)
) WITH(
  'connector' = 'jdbc',
  'url' = 'jdbc:gaussdb://GaussDB 的服务器 IP:数据库端口/postgres',
  'table-name' = 'customer_t1',
  'username' = 'username ',
  'password' = 'password '
);
CREATE TABLE KafkaSink (
  -- Kafka 作为 sink 表
  c_customer_sk INTEGER,
  c_customer_name VARCHAR(32)
) WITH (
  'connector' = 'kafka',
  'topic' = 'customer_sink',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
```

```
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'value.format' = 'csv',
  'properties.sasl.kerberos.service.name' = 'kafka',  --FlinkServer 所在集群为非安全模式去掉此参数
  'properties.security.protocol' = 'SASL_PLAINTEXT',  --FlinkServer 所在集群为非安全模式去掉此参数
  'properties.kerberos.domain.name' = 'hadoop.系统域名'  --FlinkServer 所在集群为非安全模式去掉此参数
);
Insert into
  KafkaSink
select
  *
from
  MyUserTable;
```

说明

- Kafka 端口号：
- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为9092，则需要配置“allow.everyone.if.no.acl.found”参数为 true，具体操作如下：

  登录 FusionInsight Manager 系统，选择“集群 > 服务 > Kafka > 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为 true，保存配置即可。
- properties.group.id：Kafka 的使用者组 ID，Kafka 作为 source 时必选。
- 系统域名：可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。

步骤 3 查看作业管理界面，作业状态为“运行中”。

步骤 4 参考 16.5 管理 Kafka 主题中的消息，执行以下命令查看 Sink 表中是否接收到数据，即查看 Kafka topic 是否正常写入数据，如下图所示。

sh kafka-console-consumer.sh --topic customer_sink --bootstrap-server *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--consumer.config /opt/client/Kafka/kafka/config/consumer.properties**

----结束

GaussDB 作为维表

kafkaSource 作为事实表，“customer_t2”作为维度表，结果写入 kafkaSink。

步骤 1 在 GaussDB 客户端创建维度表“customer_t2”，建表语句示例如下：

```
CREATE TABLE customer_t2(
c_customer_sk INTEGER PRIMARY KEY,
c_customer_age INTEGER,
c_customer_address VARCHAR(32)
)DISTRIBUTE BY HASH(c_customer_sk);
```

```
INSERT INTO customer_t2 VALUES(1,18,'city a');
INSERT INTO customer_t2 VALUES(2,14,'city b');
INSERT INTO customer_t2 VALUES(3,16,'city c');
INSERT INTO customer_t2 VALUES(4,24,'city d');
INSERT INTO customer_t2 VALUES(5,32,'city e');
INSERT INTO customer_t2 VALUES(6,27,'city f');
INSERT INTO customer_t2 VALUES(7,41,'city a');
INSERT INTO customer_t2 VALUES(8,35,'city h');
INSERT INTO customer_t2 VALUES(9,16,'city j');
```

步骤 2 使用 **flinkuser** 登录 Manager，选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 3 参考新建作业，新建 Flink SQL 流作业，参考如下内容在作业开发界面进行作业开发，配置完成后启动作业。

需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“5000”，“模式”可使用默认值。

```
CREATE TABLE KafkaSource (
  -- Kafka 作为 source 表
  c_customer_sk INTEGER,
  c_customer_name VARCHAR(32),
  proctime as proctime()
) WITH (
  'connector' = 'kafka',
  'topic' = 'customer_source',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'value.format' = 'csv',
  'properties.sasl.kerberos.service.name' = 'kafka',  --FlinkServer 所在集群为非安全模式去掉此参数
  'properties.security.protocol' = 'SASL_PLAINTEXT',  --FlinkServer 所在集群为非安全模式去掉此参数
  'properties.kerberos.domain.name' = 'hadoop.系统域名'  --FlinkServer 所在集群为非安全模式去掉此参数
);
CREATE TABLE KafkaSink (
  -- Kafka 作为 sink 表
  c_customer_sk INTEGER,
  c_customer_name VARCHAR(32),
  c_customer_age INTEGER,
  c_customer_address VARCHAR(32)
) WITH (
  'connector' = 'kafka',
  'topic' = 'customer_sink',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'value.format' = 'csv',
  'properties.sasl.kerberos.service.name' = 'kafka',  --FlinkServer 所在集群为非安全模式去掉此参数
  'properties.security.protocol' = 'SASL_PLAINTEXT',  --FlinkServer 所在集群为非安全模式去掉此参数
  'properties.kerberos.domain.name' = 'hadoop.系统域名'  --FlinkServer 所在集群为非安全模
```

```
式去掉此参数
);
CREATE TABLE MyUserTable (
  -- GaussDB 作为维表
  c_customer_sk INTEGER PRIMARY KEY,
  c_customer_age INTEGER,
  c_customer_address VARCHAR(32)
) WITH (
  'connector' = 'jdbc',
  'url' = 'jdbc:gaussdb://GaussDB 的服务器 IP:数据库端口/postgres',
  'table-name' = 'customer_t2',
  'username' = 'username ',
  'password' = 'password '
);
INSERT INTO
  KafkaSink
SELECT
  t.c_customer_sk,
  t.c_customer_name,
  d.c_customer_age,
  d.c_customer_address
FROM
  KafkaSource as t
  JOIN MyUserTable FOR SYSTEM_TIME AS OF t.proctime as d ON t.c_customer_sk =
d.c_customer_sk;
```

说明

- Kafka 端口号：
- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为9092，则需要配置“allow.everyone.if.no.acl.found”参数为 true，具体操作如下：

  登录 FusionInsight Manager 系统，选择“集群 > 服务 >Kafka> 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为 true，保存配置即可。
- properties.group.id：Kafka 的使用者组 ID，Kafka 作为 source 时必选。
- 系统域名：可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。

步骤 4 参考 16.5 管理 Kafka 主题中的消息，执行以下命令查看 Sink 表中是否接收到数据，即步骤 5 执行完成后查看 Kafka topic 是否正常写入数据。

sh kafka-console-consumer.sh --topic customer_sink --bootstrap-server *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--consumer.config /opt/client/Kafka/kafka/config/consumer.properties**

步骤 5 参考 16.5 管理 Kafka 主题中的消息，查看 Topic 并向 Kafka 中写入数据，输入完成后可在步骤 4 中的窗口查看执行结果。

./kafka-topics.sh --list --zookeeper *ZooKeeper 的 quorumpeer 实例业务 IP:ZooKeeper 客户端端口号***/kafka**

sh kafka-console-producer.sh --broker-list *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic** *主题名称* **--producer.config** *客户端目录* **/Kafka/kafka/config/producer.properties**

说明

- ZooKeeper 的 quorumpeer 实例业务 IP：

  ZooKeeper 服务所有 quorumpeer 实例业务 IP。登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。

- ZooKeeper 客户端端口号：

  登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。

例如本示例使用主题名称为 customer_source：

sh kafka-console-producer.sh --broker-list *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic customer_source --producer.config /opt/client/Kafka/kafka/config/producer.properties**

输入消息内容：

```
3,zhangsan
5,zhaosi
1,xiaoming
2,liuyang
7,liubei
10,guanyu
20,zhaoyun
```

输入完成后按回车发送消息，步骤 4 中的 kafka-console-consumer 窗口打印结果如下：

```
3,zhangsan,16,city c
5,zhaosi,32,city e
1,xiaoming,18,city a
2,liuyang,14,city b
7,liubei,41,city a
```

----结束

6.6.3 FlinkServer 对接 HBase

本章节适用于 MRS 3.1.2 及之后的版本。

操作场景

FlinkServer 支持对接 HBase，详情如下：

- 支持对接维表、Sink 表。
- 当 HBase 与 Flink 为同一集群或互信的集群，支持 FlinkServer 对接 HBase。
- 当 HBase 与 Flink 不在同一集群或不互信的集群，则只支持 Flink 和 HBase 均为普通模式集群的对接。

前提条件

- 集群已安装，包括 HDFS、Yarn、Flink 和 HBase。
- 包含 HBase 服务的客户端已安装，安装路径如：/opt/client。

- 参考 8.2 使用 HBase 客户端，登录 HBase 客户端，使用 **create 'dim_province', "f1"**创建 dim_province 表。

操作步骤

步骤 1 以客户端安装用户登录安装客户端的节点，拷贝 HBase 的“/opt/client/HBase/hbase/conf/”目录下的所有配置文件至部署 FlinkServer 的所有节点的一个空目录，如“/tmp/client/HBase/hbase/conf/”。

修改 FlinkServer 节点上面配置文件目录及其上层目录属主为 omm。

chown omm: /tmp/client/HBase/ -R

说明

- FlinkServer 节点：

  登录 Manager，选择“集群 > 服务 > Flink > 实例”，查看 FlinkServer 所在的“业务 IP”。
- 若 FlinkServer 实例所在节点与包含 HBase 服务客户端的安装节点相同，则该节点不执行此步骤。

步骤 2 登录 Manager，选择“集群 > 服务 > Flink > 配置 > 全部配置”，搜索“HBASE_CONF_DIR”参数，在该参数的“值”中填写步骤 1 中拷贝了 HBase 配置文件的 FlinkServer 的目录，如“/tmp/client/HBase/hbase/conf/”。

说明

若 FlinkServer 实例所在节点与包含 HBase 服务客户端的安装节点相同，则在 HBASE_CONF_DIR”参数的“值”填写 HBase 的“/opt/client/HBase/hbase/conf/”目录。

步骤 3 填写完成后单击“保存”，确认修改配置后单击“确定”。

步骤 4 单击“实例”，勾选所有 FlinkServer 实例，选择“更多 > 重启实例”，输入密码，单击“确定”重启实例。

步骤 5 登录 Manager，选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 6 参考新建作业，新建 Flink SQL 作业，作业类型选择“流作业”。在作业开发界面进行如下作业配置并启动作业。

需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“60000”，“模式”可使用默认值。

安全集群且 HBase 的认证模式为 hbase.rpc.protection=authentication 时参考如下样例，建立 Flink SQL 作业。

```
CREATE TABLE ksource1 (
user_id STRING,
item_id STRING,
proctime as PROCTIME()
) WITH (
'connector' = 'kafka',
'topic' = 'ksource1',
'properties.group.id' = 'group1',
'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP1:Kafka 端口号,Kafka 的 Broker 实例业务 IP2:Kafka 端口号',
```

```
'format' = 'json',
'properties.sasl.kerberos.service.name' = 'kafka',--普通模式集群不需要该参数
'properties.security.protocol' = 'SASL_PLAINTEXT',--普通模式集群不需要该参数
'properties.kerberos.domain.name' = 'hadoop.系统域名'--普通模式集群不需要该参数
);

CREATE TABLE hsink1 (
rowkey STRING,
f1 ROW < item_id STRING >,
PRIMARY KEY (rowkey) NOT ENFORCED
) WITH (
'connector' = 'hbase-2.2',
'table-name' = 'dim_province',
'zookeeper.quorum' = 'ZooKeeper 的 quorumpeer 实例业务 IP1:ZooKeeper 客户端端口
号,ZooKeeper 的 quorumpeer 实例业务 IP2:ZooKeeper 客户端端口号'
);

INSERT INTO
hsink1
SELECT
user id as rowkey,
ROW(item id) as f1
FROM
ksource1;
```

说明

- Kafka 端口号：
- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为9092，则需要配置“allow.everyone.if.no.acl.found”参数为 true，具体操作如下：

  登录 FusionInsight Manager 系统，选择“集群 > 服务 >Kafka> 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为 true，保存配置即可。
- ZooKeeper 的 quorumpeer 实例业务 IP：

  ZooKeeper 服务所有 quorumpeer 实例业务 IP。登录 FusionInsight Manager，选择“集群 > 服务 >ZooKeeper> 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。
- ZooKeeper 客户端端口号：

  登录 FusionInsight Manager，选择“集群 > 服务 >ZooKeeper”，在“配置”页签查看“clientPort”的值。
- 系统域名：可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。
- HBase 认证模式：

  登录 FusionInsight Manager，选择“集群 > 服务 >HBase> 配置 > 全部配置”，搜索“hbase.rpc.protection”，查看 HBase 认证模式，当认证模式为“integrity”和“privacy”时添加如下参数：

  'properties.hbase.rpc.protection' = '*HBase 认证模式*'

  'properties.zookeeper.znode.parent' = '/hbase'

  'properties.hbase.security.authorization' = 'true'

  'properties.hbase.security.authentication' = 'kerberos'

步骤 7 查看作业管理界面，作业状态为“运行中”。

步骤 8 参考 16.5 管理 Kafka 主题中的消息，向 kafka 中写入数据。

sh kafka-console-producer.sh --broker-list *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic** ***主题名称*** **--producer.config** *客户端目录* **/Kafka/kafka/config/producer.properties**

例如本示例使用主题名称为 ksource1：**sh kafka-console-producer.sh --broker-list** *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic ksource1 --producer.config /opt/client/Kafka/kafka/config/producer.properties**

输入消息内容：

```
{"user_id": "3","item_id":"333333"}
{"user_id": "4","item_id":"44444444"}
```

输入完成后按回车发送消息。

步骤 9 参考 8.2 使用 HBase 客户端，登录 HBase 客户端，查看表数据信息。

hbase shell

scan 'dim_province'

----结束

应用端提交作业

- 若使用 Flink run 模式，推荐使用 export HBASE_CONF_DIR=hbase 的配置目录，例如：export HBASE_CONF_DIR=/opt/hbaseconf。
- 若使用 Flink run-application 模式，则有如下两种方式。
  - 在建表语句中添加如下配置（推荐）

配置	说明
'properties.hbase.rpc.protection' = 'authentication'	需和 HBase 服务端的配置一致
'properties.zookeeper.znode.parent' = '/hbase'	多服务场景中，会存在 hbase1，hbase2，需明确要访问的集群
'properties.hbase.security.authorization' = 'true'	开启鉴权
'properties.hbase.security.authentication' = 'kerberos'	开启 kerberos 认证

示例：

```
CREATE TABLE hsink1 (
    rowkey STRING,
    f1 ROW < q1 STRING >,
    PRIMARY KEY (rowkey) NOT ENFORCED
   ) WITH (
    'connector' = 'hbase-2.2',
    'table-name' = 'cc',
    'zookeeper.quorum' = 'x.x.x.x:clientPort',
    'properties.hbase.rpc.protection' = 'authentication',
```

```
    'properties.zookeeper.znode.parent' = '/hbase',
    'properties.hbase.security.authorization' = 'true',
    'properties.hbase.security.authentication' = 'kerberos'
  );
```

- 提交作业时将 HBase 的配置添加到 yarnShip 中。

  例如：Dyarn.ship-files=/opt/hbaseconf。

6.6.4 FlinkServer 对接 HDFS

本章节适用于 MRS 3.1.2 及之后的版本。

操作场景

本章节介绍 HDFS 作为 sink 表的 DDL 定义，以及创建 sink 表时使用的 WITH 参数和代码示例，并指导如何在 FlinkServer 作业管理页面操作。

本示例以安全模式 Kafka 为例。

前提条件

- 集群中已安装 HDFS、Yarn、Flink 服务。
- 包含 HDFS 服务的客户端已安装，安装路径如：/opt/client。
- 参考 6.5.3 创建 FlinkServer 角色创建一个具有 FlinkServer 管理员权限的用户用于访问 Flink WebUI，如：flink_admin。

操作步骤

步骤 1 使用 **flink_admin** 登录 Manager，选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 2 参考新建作业，新建 Flink SQL 流作业，参考如下内容在作业开发界面进行作业开发，配置完成后启动作业。

需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“60000”，“模式”可使用默认值。

```
CREATE TABLE kafka_table (
  user_id STRING,
  order_amount DOUBLE,
  log_ts TIMESTAMP(3),
  WATERMARK FOR log_ts AS log_ts - INTERVAL '5' SECOND
) WITH (
  'connector' = 'kafka',
  'topic' = 'user_source',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'format' = 'csv',
   --跳过解析失败的 csv 数据
  'csv.ignore-parse-errors' = 'true',--如果是 json 数据格式，设置'json.ignore-parse-
errors' = 'true'
  'properties.sasl.kerberos.service.name' = 'kafka',
```

```
  'properties.security.protocol' = 'SASL_PLAINTEXT',
  'properties.kerberos.domain.name' = 'hadoop.系统域名'

);

CREATE TABLE fs_table (
  user_id STRING,
  order_amount DOUBLE,
  dt STRING,
  `hour` STRING
) PARTITIONED BY (dt, `hour`) WITH ( --根据日期进行文件分区
  'connector'='filesystem',
  'path'='hdfs:///sql/parquet',
  'format'='parquet',
  'sink.partition-commit.delay'='0 s',--该延迟时间之前分区不会被提交。如果是按天分区，可以设置为'1 d'，如果是按小时分区，应设置为'1 h'
  'sink.partition-commit.policy.kind'='success-file'
);
-- streaming sql, insert into file system table
INSERT INTO fs_table SELECT user_id, order_amount, DATE_FORMAT(log_ts, 'yyyy-MM-dd'), DATE_FORMAT(log_ts, 'HH') FROM kafka_table;
```

说明

- Kafka 端口号：
- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为9092，则需要配置“allow.everyone.if.no.acl.found”参数为 true，具体操作如下：

  登录 FusionInsight Manager 系统，选择“集群 > 服务 > Kafka > 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为 true，保存配置即可。
- 系统域名：可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。

步骤 3 查看作业管理界面，作业状态为“运行中”。

步骤 4 参考 16.5 管理 Kafka 主题中的消息，查看 Topic 并向 Kafka 中写入数据。

./kafka-topics.sh --list --zookeeper *ZooKeeper 的 quorumpeer 实例业务 IP:ZooKeeper 客户端端口号***/kafka**

sh kafka-console-producer.sh --broker-list *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic** *主题名称* **--producer.config** *客户端目录***/Kafka/kafka/config/producer.properties**

例如本示例使用主题名称为 user_source：**sh kafka-console-producer.sh --broker-list** *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic user_source --producer.config /opt/client/Kafka/kafka/config/producer.properties**

输入消息内容：

```
3,3333,"2021-09-10 14:00"
4,4444,"2021-09-10 14:01"
```

输入完成后按回车发送消息。

说明

- ZooKeeper 的 quorumpeer 实例业务 IP：

  ZooKeeper 服务所有 quorumpeer 实例业务 IP。登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。

- ZooKeeper 客户端端口号：

  登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。

步骤 5 执行以下命令查看 Sink 表中是否接收到数据，即 HDFS 目录是否正常写入文件。

hdfs dfs -ls -R /sql/parquet

----结束

Flink 对接 HDFS 分区

- Flink 对接 HDFS 支持自定义分区。

  Flink 文件系统分区支持使用标准的 Hive 格式。不需要将分区预先注册到表目录中，分区是根据目录结构推断。

  例如，根据下面的目录分区的表将被推断为包含日期时间和小时分区。

```
path
└── datetime=2021-09-03
    └── hour=11
        ├── part-0.parquet
        ├── part-1.parquet
    └── hour=12
        ├── part-0.parquet
└── datetime=2021-09-24
    └── hour=6
        ├── part-0.parquet
```

- 分区文件的滚动策略。

  分区目录中的数据被拆分为 part 文件，每个分区将至少包含一个 part 文件，用于接收 sink 的子任务的数据写入。

  如下参数介绍分区文件如何进行滚动。

配置项	默认值	类型	描述
sink.rolling-policy.file-size	128MB	MemorySize	分区文件达到该阈值后，进行滚动。
sink.rolling-policy.rollover-interval	30min	Duration	分区文件在滚动前可以保持打开的最长持续时间。
sink.rolling-policy.check-interval	1min	Duration	检查基于时间的滚动策略的时间间隔。

- 分区目录的文件合并。

  支持文件压缩，允许应用程序具有更小的检查点间隔，而无需生成大量文件。

说明

仅压缩单个检查点中的文件，即生成的文件数量至少与检查点数量相同。合并前的文件是不可见的，因此文件的可见性是：检查点间隔+压缩时间之后。如果压缩时间太长，将延长检查点的时间段。

配置项	默认值	类型	描述
auto-compaction	false	Boolean	是否启用自动压缩。数据将写入临时文件。检查点完成后，检查点生成的临时文件将被压缩。压缩前临时文件不可见。
compaction.file-size	none	MemorySize	压缩目标文件大小，默认值为滚动文件大小。

- 分区文件的提交。

  文件写入分区后，通常需要通知下游应用程序。如将分区添加到 Hive 元存储中，或在目录中写入_SUCCESS 文件。分区文件的提交操作基于触发器和策略的组合方式。

  - 分区文件提交触发器相关配置

配置项	默认值	类型	描述
sink.partition-commit.trigger	process-time	String	• process-time：基于计算节点的系统时间，它既不需要分区时间提取，也不需要生成 watermark。即“当前系统时间”超过“分区创建时的系统时间”加上“延迟”时间，就提交分区。 • partition-time：基于从分区提取的时间，它需要生成 watermark。即“watermark 时间”超过“从分区提取的时间”加上“延迟”时间，就提交分区。
sink.partition-commit.delay	0 s	Duration	分区在延迟时间之前不会提交。如果是每日分区，则应为“1 d”，如果是每小时分区，则应为“1 h”。

  - 分区问文件提交策略相关配置

配置项	默认值	类型	描述
sink.partition-commit.policy.kind	-	String	提交分区的策略。 • metastore：将分区添加到元存储。只有 hive 表支持元存储策略，文件系统通过目录结构管理分区。 • success-file：将 success-file 文件添加到

配置项	默认值	类型	描述
			目录中。 • 两者可以同时配置，即：'sink.partition-commit.policy.kind'='metastore,success-file'。
sink.partition-commit.policy.class	-	String	用于实现分区提交策略接口的分区提交策略类。 仅在自定义提交策略中生效。
sink.partition-commit.success-file.name	_SUCCESS	String	success-file 分区提交策略的文件名，默认值为_SUCCESS。

6.6.5 FlinkServer 对接 Hive

本章节适用于 MRS 3.1.2 及之后的版本。

操作场景

目前 FlinkServer 对接 Hive 使用对接 metaStore 的方式，所以需要 Hive 开启 MetaStore 功能。Hive 可以作为 source，sink 和维表。

本示例以安全模式 Kafka 为例。

前提条件

- 集群已安装 HDFS、Yarn、Kafka、Flink 和 Hive 等服务。
- 包含 Hive 服务的客户端已安装，安装路径如：/opt/client。
- Flink 支持 1.12.2 及以后版本，Hive 支持 3.1.0 及以后版本。
- 参考 6.5.3 创建 FlinkServer 角色创建一个具有 FlinkServer 管理员权限的用户用于访问 Flink WebUI，如：flink_admin。
- 参考创建集群连接中的“说明”获取访问 Flink WebUI 用户的客户端配置文件及用户凭据。

操作步骤

以映射表类型为 Kafka 对接 Hive 流程为例。

步骤 1 使用 **flink_admin** 访问 Flink WebUI，请参考 6.5.4 访问 Flink WebUI。

步骤 2 新建集群连接，如：flink_hive。

1. 选择“系统管理 > 集群连接管理”，进入集群连接管理页面。
2. 单击“创建集群连接”，在弹出的页面中参考表 6-31 填写信息，单击“测试”，测试连接成功后单击“确定”，完成集群连接创建。

表6-31 创建集群连接信息

参数名称	参数描述	取值样例
集群连接名称	集群连接的名称，只能包含英文字母、数字和下划线，且不能多于 100 个字符。	flink_hive
描述	集群连接名称描述信息。	-
版本	选择集群版本。	MRS 3
是否安全版本	• 是，安全集群选择是。需要输入访问用户名和上传用户凭证； • 否，非安全集群选择否。	是
访问用户名	访问用户需要包含访问集群中服务所需要的最小权限。只能包含英文字母、数字和下划线，且不能多于 100 个字符。 “是否安全版本”选择“是”时存在此参数。	flink_admin
客户端配置文件	集群客户端配置文件，格式为 tar。	-
用户凭据	FusionInsight Manager 中用户的认证凭据，格式为 tar。 “是否安全版本”选择“是”时存在此参数。 输入访问用户名后才可上传文件。	flink_admin 的用户凭据

步骤 3 新建 Flink SQL 流作业，如：flinktest1。

1. 单击“作业管理”进入作业管理页面。
2. 单击“新建作业”，在新建作业页面参考表 6-32 填写信息，单击“确定”，创建作业成功并进入作业开发界面。

表6-32 新建作业信息

参数名称	参数描述	取值样例
类型	作业类型，包括 Flink SQL 和 Flink Jar。	Flink SQL
名称	作业名称，只能包含英文字母、数字和下划线，且不能多于 64 个字符。	flinktest1
作业类型	作业数据来源类型，包括流作业和批作业。	流作业
描述	作业描述，不能超过 100 个字符。	-

步骤 4 在作业开发界面进行作业开发，输入如下语句，可以单击上方“语义校验”对输入内容校验。

```
CREATE TABLE test_kafka (
  user_id varchar,
  item_id varchar,
  cat_id varchar,
  zw_test timestamp
) WITH (
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'format' = 'json',
  'topic' = 'zw_tset_kafka',
  'connector' = 'kafka',
  'scan.startup.mode' = 'latest-offset',
  'properties.sasl.kerberos.service.name' = 'kafka',
  'properties.security.protocol' = 'SASL_PLAINTEXT',
  'properties.kerberos.domain.name' = 'hadoop.系统域名'

);
CREATE CATALOG myhive WITH (
  'type' = 'hive',
  'hive-version' = '3.1.0',
  'default-database' = 'default',
  'cluster.name' = 'flink hive'
);
use catalog myhive;
set table.sql-dialect = hive;create table user behavior hive tbl no partition (
   user id STRING,
   item id STRING,
   cat id STRING,
   ts timestamp
  ) PARTITIONED BY (dy STRING, ho STRING, mi STRING) stored as textfile
TBLPROPERTIES (
   'partition.time-extractor.timestamp-pattern' = '$dy $ho:$mi:00',
   'sink.partition-commit.trigger' = 'process-time',
   'sink.partition-commit.delay' = '0S',
   'sink.partition-commit.policy.kind' = 'metastore,success-file'
  );
INSERT into
  user_behavior_hive_tbl_no_partition
SELECT
  user_id,
  item_id,
  cat_id,
  zw_test,
  DATE_FORMAT(zw_test, 'yyyy-MM-dd'),
  DATE_FORMAT(zw_test, 'HH'),
  DATE_FORMAT(zw_test, 'mm')
FROM
  default_catalog.default_database.test_kafka;
```

说明

- Kafka 端口号：
- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为9092，则需要配置“allow.everyone.if.no.acl.found”参数为 true，具体操作如下：

  登录 FusionInsight Manager 系统，选择“集群 > 服务 > Kafka > 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为 true，保存配置即可。

- 'cluster.name' = 'flink_hive'的值为步骤 2 新建的集群连接名称。
- 系统域名：可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。

步骤 5 作业 SQL 开发完成后，请勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“60000”，“模式”可使用默认值。

步骤 6 单击左上角“提交”提交作业。

步骤 7 作业运行成功后，选择“更多 > 作业详情”可查看作业运行详情。

步骤 8 参考 16.5 管理 Kafka 主题中的消息，查看 Topic 并向 Kafka 中写入数据。

./kafka-topics.sh --list --zookeeper *ZooKeeper 的 quorumpeer 实例业务 IP:ZooKeeper 客户端端口号***/kafka**

sh kafka-console-producer.sh --broker-list *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic** *主题名称* **--producer.config** *客户端目录* **/Kafka/kafka/config/producer.properties**

例如本示例使用主题名称为 zw_tset_kafka：**sh kafka-console-producer.sh --broker-list** *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic zw_tset_kafka --producer.config /opt/client/Kafka/kafka/config/producer.properties**

输入消息内容：

```
{"user_id": "3","item_id":"333333","cat_id":"cat333","zw_test":"2021-09-08 09:08:01"}
{"user_id": "4","item_id":"444444","cat_id":"cat444","zw_test":"2021-09-08 09:08:01"}
```

输入完成后按回车发送消息。

说明

- ZooKeeper 的 quorumpeer 实例业务 IP：

  ZooKeeper 服务所有 quorumpeer 实例业务 IP。登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。

- ZooKeeper 客户端端口号：

  登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。

步骤 9 执行以下命令查看 Sink 表中是否接收到数据，即 Hive 表是否正常写入数据。

beeline

select * from user_behavior_hive_tbl_no_partition;

----结束

6.6.6 FlinkServer 对接 Hudi

本章节适用于 MRS 3.1.2 及之后的版本。

操作场景

本指南通过使用 FlinkServer 写 FlinkSQL 对接 Hudi。

前提条件

- 集群已安装 HDFS、Yarn、Flink 和 Hudi 等服务。
- 包含 Hudi 服务的客户端已安装，例如安装路径为：/opt/client。
- Flink 要求 1.12.2 及以后版本，Hudi 要求 0.9.0 及以后版本。
- 参考 6.5.3 创建 FlinkServer 角色创建一个具有 FlinkServer 管理员权限的用户用于访问 Flink WebUI，如：flink_admin。

Flink 对 Hudi 表的读写支持

Flink 对 Hudi 表的 COW 表、MOR 表类型读写支持详情见表 6-33。

表6-33 Flink 对 Hudi 表的读写支持

Flink SQL	COW 表	MOR 表
批量写	支持	支持
批量读	支持	支持
流式写	支持	支持
流式读	支持	支持

操作步骤

步骤 1 使用 **flink_admin** 登录 Manager，选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 2 参考新建作业，新建 Flink SQL 流作业，在作业开发界面进行如下作业配置。并启动作业。

需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“60000”，“模式”可使用默认值。

说明

- 由于 FlinkSQL 作业在触发 CheckPoint 时才会往 Hudi 表中写数据，所以需要在 Flink WebUI 界面中开启 CheckPoint。CheckPoint 间隔根据业务需要调整，建议间隔调大。
- 如果 CheckPoint 间隔太短，数据来不及刷新会导致作业异常；建议 CheckPoint 间隔为分钟级。
- FlinkSQL 作业写 MOR 表时需要做异步 compaction，控制 compaction 间隔的参数，见 Hudi 官网：https://hudi.apache.org/docs/configurations.html

- FlinkSQL 流式写入 MOR 表。

```
CREATE TABLE stream_mor(
uuid VARCHAR(20),
```

```
name VARCHAR(10),
age INT,
ts INT,
`p` VARCHAR(20)
) PARTITIONED BY (`p`) WITH (
'connector' = 'hudi',
'path' = 'hdfs://hacluster/tmp/hudi/stream_mor',
'table.type' = 'MERGE_ON_READ'
);

CREATE TABLE kafka(
uuid VARCHAR(20),
name VARCHAR(10),
age INT,
ts INT,
`p` VARCHAR(20)
) WITH (
'connector' = 'kafka',
'topic' = 'writehudi',
'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
'properties.group.id' = 'testGroup1',
'scan.startup.mode' = 'latest-offset',
'format' = 'json'
);

insert into
stream mor
select
*
from
kafka;
```

- FlinkSQL 流式写入 COW 表

```
CREATE TABLE stream_write_cow(
uuid VARCHAR(20),
name VARCHAR(10),
age INT,
ts INT,
`p` VARCHAR(20)
) PARTITIONED BY (`p`) WITH (
'connector' = 'hudi',
'path' = 'hdfs://hacluster/tmp/hudi/stream_cow'
);

CREATE TABLE kafka(
uuid VARCHAR(20),
name VARCHAR(10),
age INT,
ts INT,
`p` VARCHAR(20)
) WITH (
'connector' = 'kafka',
'topic' = 'writehudi',
'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
'properties.group.id' = 'testGroup1',
'scan.startup.mode' = 'latest-offset',
```

```
'format' = 'json'
);

insert into
stream_write_cow
select
*
from
kafka;
```

- FlinkSQL 读取 MOR 表

```
CREATE TABLE hudi_read_spark_mor(
uuid VARCHAR(20),
name VARCHAR(10),
age INT,
ts INT,
`p` VARCHAR(20)
) PARTITIONED BY (`p`) WITH (
'connector' = 'hudi',
'path' = 'hdfs://hacluster/tmp/default/tb_hudimor',
'table.type' = 'MERGE_ON_READ'
);

CREATE TABLE kafka(
uuid VARCHAR(20),
name VARCHAR(10),
age INT,
ts timestamp(6)INT,
`p` VARCHAR(20)
) WITH (
'connector' = 'kafka',
'topic' = 'writehudi',
'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
'properties.group.id' = 'testGroup1',
'scan.startup.mode' = 'latest-offset',
'format' = 'json'
);

insert into
kafka
select
*
from
hudi_read_spark_mor;
```

说明

Kafka 端口号：

- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为9092，则需要配置“allow.everyone.if.no.acl.found”参数为 true，具体操作如下：

  登录 FusionInsight Manager 系统，选择“集群 > 服务 > Kafka > 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为 true，保存配置即可。

步骤 3 FlinkSQL 写入 Hudi 表数据后，通过 Spark、Hive 读该数据时，需要使用 run_hive_sync_tool.sh 将 Hudi 表数据同步到 Hive 中。同步方法请参考 12.3.2.3 将 Hudi 表数据同步到 Hive。

须知

同步前需要保证不再新增分区，同步后新增的分区将不能被读取。

----结束

Flink On Hudi 同步元数据到 Hive

适用于 MRS 3.2.0 及之后版本。

- 使用 JDBC 方式同步元数据到 Hive

```
CREATE TABLE stream_mor(
uuid VARCHAR(20),
name VARCHAR(10),
age INT,
ts INT,
`p` VARCHAR(20)
) PARTITIONED BY (`p`) WITH (
'connector' = 'hudi',
'path' = 'hdfs://hacluster/tmp/hudi/stream_mor',
'table.type' = 'MERGE_ON_READ',
'hive_sync.enable' = 'true',
'hive_sync.table' = '要同步到Hive的表名',
'hive_sync.db' = '要同步到Hive的数据库名',
'hive_sync.metastore.uris' = 'Hive客户端hive-site.xml文件中hive.metastore.uris的值',
'hive_sync.jdbc_url' = 'Hive客户端component_env文件中CLIENT_HIVE_URI的值'
);
```

- 使用 HMS 方式同步元数据到 Hive

```
CREATE TABLE stream_mor(
uuid VARCHAR(20),
name VARCHAR(10),
age INT,
ts INT,
`p` VARCHAR(20)
) PARTITIONED BY (`p`) WITH (
'connector' = 'hudi',
'path' = 'hdfs://hacluster/tmp/hudi/stream_mor',
'table.type' = 'MERGE_ON_READ',
'hive_sync.enable' = 'true',
'hive_sync.table' = '要同步到Hive的表名',
'hive_sync.db' = '要同步到Hive的数据库名',
'hive_sync.mode' = 'hms',
'hive_sync.metastore.uris' = 'Hive客户端hive-site.xml文件中hive.metastore.uris的值',
'properties.hive.metastore.kerberos.principal' = 'Hive客户端hive-site.xml文件中
```

```
hive.metastore.kerberos.principal 的值'
);
```

6.6.7 FlinkServer 对接 Kafka

本章节适用于 MRS 3.1.2 及之后的版本。

操作场景

本章节介绍 Kafka 作为 source 表或者 sink 表的 DDL 定义，以及创建表时使用的 WITH 参数和代码示例，并指导如何在 FlinkServer 作业管理页面操作。

本示例以安全模式 Kafka 为例。

前提条件

- 集群中已安装 HDFS、Yarn、Kafka 和 Flink 服务。
- 包含 Kafka 服务的客户端已安装，例如安装路径为：/opt/client
- 参考 6.5.3 创建 FlinkServer 角色创建一个具有 FlinkServer 管理员权限的用户用于访问 Flink WebUI，如：flink_admin。

操作步骤

步骤 1 使用 **flink_admin** 登录 Manager，选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 2 参考新建作业，新建 Flink SQL 流作业，在作业开发界面进行作业开发，配置完成后启动作业。

需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“60000”，“模式”可使用默认值。

```
CREATE TABLE KafkaSource (
  `user_id` VARCHAR,
  `user_name` VARCHAR,
  `age` INT
) WITH (
  'connector' = 'kafka',
  'topic' = 'test_source',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'format' = 'csv',
  'properties.sasl.kerberos.service.name' = 'kafka',
  'properties.security.protocol' = 'SASL_PLAINTEXT',
  'properties.kerberos.domain.name' = 'hadoop.系统域名'
);
CREATE TABLE KafkaSink(
  `user_id` VARCHAR,
  `user_name` VARCHAR,
  `age` INT
) WITH (
  'connector' = 'kafka',
```

```
  'topic' = 'test_sink',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'scan.startup.mode' = 'latest-offset',
  'value.format' = 'csv',
  'properties.sasl.kerberos.service.name' = 'kafka',
  'properties.security.protocol' = 'SASL_PLAINTEXT',
  'properties.kerberos.domain.name' = 'hadoop.系统域名'
);
Insert into
  KafkaSink
select
  *
from
  KafkaSource;
```

说明

- Kafka 端口号：
- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为9092，则需要配置“allow.everyone.if.no.acl.found”参数为 true，具体操作如下：

  登录 FusionInsight Manager 系统，选择“集群 > 服务 > Kafka > 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为 true，保存配置即可。
- 系统域名：可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。

步骤 3 查看作业管理界面，作业状态为“运行中”。

步骤 4 参考 16.5 管理 Kafka 主题中的消息，执行以下命令查看 Sink 表中是否接收到数据，即步骤 5 执行完成后查看 Kafka topic 是否正常写入数据。

sh kafka-console-consumer.sh --topic test_sink --bootstrap-server *Kafka 的 Broker 实例业务 IP:Kafka 端口号* **--consumer.config /opt/client/Kafka/kafka/config/consumer.properties**

步骤 5 参考 16.5 管理 Kafka 主题中的消息，查看 Topic 并向 Kafka 中写入数据，输入完成后可在步骤 4 中的窗口查看执行结果。

./kafka-topics.sh --list --zookeeper *ZooKeeper 的 quorumpeer 实例业务 IP:ZooKeeper 客户端端口号***/kafka**

sh kafka-console-producer.sh --broker-list *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic** *主题名称* **--producer.config** *客户端目录***/Kafka/kafka/config/producer.properties**

例如本示例使用主题名称为 test_source：**sh kafka-console-producer.sh --broker-list** *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic test_source --producer.config /opt/client/Kafka/kafka/config/producer.properties**

输入消息内容：

```
1,clw,33
```

输入完成后按回车发送消息。

说明

- ZooKeeper 的 quorumpeer 实例业务 IP：

  ZooKeeper 服务所有 quorumpeer 实例业务 IP。登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。

- ZooKeeper 客户端端口号：

  登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。

----结束

WITH 主要参数说明

配置项	是否必选	类型	描述
connector	必选	String	指定要使用的连接器，Kafka 使用“kafka”
topic	• kafka 作为 sink，必选 • kafka 作为 source，可选	String	主题名称 • 当表用作 source 时，要从中读取数据的主题名称。支持主题列表，通过按分号分隔主题，如“主题-1；主题-2” • 当表用作 sink 时，主题名称为写入数据的主题。sink 不支持主题列表
topic-pattern	kafka 作为 source 时可选	String	主题模式 当表用作 source 时可设置该参数，主题名称需使用正则表达式 **说明** 不能同时设置“topic-pattern”和“topic”。
properties.bootstrap.servers	必选	String	Kafka broker 列表，以逗号分隔
properties.group.id	kafka 作为 source 时必选	String	Kafka 的使用者组 ID
format	必选	String	用于反序列化和序列化 Kafka 消息的值部分的格式
properties.*	可选	String	安全模式下需增加认证相关的参数

6.6.8 FlinkServer 对接 Redis

本章节适用于 MRS 3.1.2 及之后的版本。

操作场景

本章节介绍 Redis 作为 sink 表或者维表的 DDL 定义，以及创建表时使用的 WITH 参数和代码示例，并指导如何在 FlinkServer 作业管理页面操作。

本示例以安全模式 Kafka 为例。

前提条件

- 集群中已安装 HDFS、Yarn、Redis 和 Flink 服务。
- 包含 Redis 服务的客户端已安装，例如安装路径为：/opt/client
- 参考 6.5.3 创建 FlinkServer 角色创建一个具有 FlinkServer 管理员权限的用户用于访问 Flink WebUI，如：flink_admin。

操作步骤

场景一：Redis 作为 sink 表。

步骤 1 使用 **flink_admin** 登录 Manager，选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 2 参考新建作业，新建 Flink SQL 流作业，在作业开发界面进行作业开发，配置完成后启动作业。

需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“60000”，“模式”可使用默认值。

```
CREATE TABLE kafka source (
  account varchar(10),
  costs int,
  ts AS PROCTIME()
) WITH (
  'connector' = 'kafka',
  'topic' = 'user_source',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'format' = 'json',
  'properties.sasl.kerberos.service.name' = 'kafka',
  'properties.security.protocol' = 'SASL_PLAINTEXT',
  'properties.kerberos.domain.name' = 'hadoop.系统域名'
);
CREATE table redis_sink(
  account varchar,
  costs int,
  PRIMARY KEY(account) NOT ENFORCED
) WITH (
  'connector' = 'redis',
  'deploy-mode'='cluster',
  'need-kerberos-auth' = 'true',
  'service-kerberos-name' = 'redis/hadoop.系统域名',
  'login-context-name' = 'Client',
  'host' = '10.10.10.169',
  'port' = '22400',
```

```
  'data-type' = 'string',
  'namespace' = 'redis_table_2'

);
INSERT INTO
  redis_sink
SELECT
  account,
  SUM(costs)
FROM
  kafka_source
GROUP BY
  TUMBLE(ts, INTERVAL '90' SECOND),
  --为了快速看到计算结果
  account;
```

说明

- Kafka 端口号：
- 集群的“认证模式”为“安全模式”时为“sasl.port”的值，默认为“21007”。
- 集群的“认证模式”为“普通模式”时为“port”的值，默认为“9092”。如果配置端口号为9092，则需要配置“allow.everyone.if.no.acl.found”参数为 true，具体操作如下：

  登录 FusionInsight Manager 系统，选择“集群 > 服务 > Kafka > 配置 > 全部配置”，搜索“allow.everyone.if.no.acl.found”配置，修改参数值为 true，保存配置即可。
- host、port：分别为 Redis 集群的其中一个实例 IP（业务平面）和端口号。

  Redis 实例的端口计算方式为：22400+该实例的 ID-1。

  实例 ID 可以通过在 FusionInsight Manager 中选择“集群 > *待操作集群的名称* > 服务 > Redis > Redis 管理”，单击 Redis 集群名称查看。

  例如 Redis 集群内角色 R1 对应的 Redis 实例的端口为 22400+1-1=22400。
- namespace：用于拼接 Redis 数据库的键，格式为“namespace 的值:account 的值”。如发送数据的 account 的值为“A1”，namespace 的值为“redis_table_2”，那么此数据在 Redis 数据库中的键为 redis_table_2:A1。
- 系统域名：可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。

步骤 3 查看作业管理界面，作业状态为“运行中”。

步骤 4 参考 16.5 管理 Kafka 主题中的消息，执行以下命令查看 Sink 表中是否接收到数据，即步骤 5 执行完成后查看 Kafka topic 是否正常写入数据。

sh kafka-console-consumer.sh --topic *主题名称* **--bootstrap-server** *Kafka 的 Broker 实例业务 IP:Kafka 端口号* **--consumer.config /opt/client/Kafka/kafka/config/consumer.properties**

步骤 5 参考 16.5 管理 Kafka 主题中的消息，查看 Topic 并向 Kafka 中写入数据，输入完成后可在步骤 4 中的窗口查看执行结果。

./kafka-topics.sh --list --zookeeper *ZooKeeper 的 quorumpeer 实例业务 IP:ZooKeeper 客户端端口号***/kafka**

sh kafka-console-producer.sh --broker-list *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic** *主题名称* **--producer.config** *客户端目录* **/Kafka/kafka/config/producer.properties**

例如本示例使用主题名称为 user_source：**sh kafka-console-producer.sh --broker-list** *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic user_source --producer.config /opt/client/Kafka/kafka/config/producer.properties**

输入消息内容：

```
{"account": "A1","costs":"11"}
{"account": "A1","costs":"22"}
{"account": "A2","costs":"33"}
{"account": "A3","costs":"44"}
```

输入完成后按回车发送消息。

说明

- ZooKeeper 的 quorumpeer 实例业务 IP：

  ZooKeeper 服务所有 quorumpeer 实例业务 IP。登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。

- ZooKeeper 客户端端口号：

  登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。

步骤 6 执行以下命令登录 Redis 客户端查询结果，以查询“redis_table_2:A1”为例。

redis-cli -c -h *Redis 集群中其中一个实例业务 IP* **-p** *Redis 端口号*

get *redis_table_2:A1*

----结束

场景二：Redis 作为维表。

步骤 1 使用 **flink_admin** 登录 Manager，选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 2 参考新建作业，新建 Flink SQL 流作业，在作业开发界面进行作业开发，配置完成后启动作业。

需勾选“基础参数”中的“开启 CheckPoint”，“时间间隔（ms）”可设置为“60000”，“模式”可使用默认值。

```
CREATE TABLE KafkaSource ( -- Kafka 作为 source 表
  `user_id` VARCHAR,
  `user_name` VARCHAR,
  `age` INT,
   proctime as proctime()
) WITH (
  'connector' = 'kafka',
  'topic' = 'user_source',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'value.format' = 'csv',
  'properties.sasl.kerberos.service.name' = 'kafka',
  'properties.security.protocol' = 'SASL_PLAINTEXT',
  'properties.kerberos.domain.name' = 'hadoop.系统域名'
```

```
);
CREATE TABLE KafkaSink (  -- Kafka 作为 sink 表
  `user_id` VARCHAR,
  `user_name` VARCHAR,
  `age` INT,
  `phone_number` VARCHAR,
  `address` VARCHAR
) WITH (
  'connector' = 'kafka',
  'topic' = 'user_sink',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'value.format' = 'csv',
  'properties.sasl.kerberos.service.name' = 'kafka',
  'properties.security.protocol' = 'SASL_PLAINTEXT',
  'properties.kerberos.domain.name' = 'hadoop.系统域名'
);
CREATE TABLE RedisTable ( -- Redis 作为维表
  user_name VARCHAR,
  score INT,
  phone_number VARCHAR,
  address VARCHAR
) WITH (

  'connector' = 'redis',
  'deploy-mode'='cluster',
  'need-kerberos-auth' = 'true',
  'service-kerberos-name' = 'redis/hadoop.系统域名',
  'login-context-name' = 'Client',
  'zset-score-column' = 'score',
  'host' = '10.10.10.169',
  'port' = '22400',
  'key-ttl-mode' = 'no-ttl',
  'data-type' = 'sorted-set',
  'namespace' = 'dkdz_redis_table_1',
  'zset-delimiter' = ',',
  'key-column' = 'user_name'
);

INSERT INTO
  KafkaSink
SELECT
  t.user_id,
  t.user_name,
  t.age,
  d.phone_number,
  d.address
FROM
  KafkaSource as t
  JOIN RedisTable FOR SYSTEM_TIME AS OF t.proctime as d ON t.user_name =
d.user_name;
  -- 必须加上 FOR SYSTEM_TIME AS OF t.proctime，表示 JOIN 维表当前时刻所看到的每条数据
```

步骤 3 执行以下命令向 Redis 维表中写入测试数据。

cd /opt/client/Redis/bin

./redis-cli -h *10.10.10.11* **-p** *22400* **-c**

输入消息内容：

```
ZADD redis_zset:zhangsan 80 153xxxx1111,city1
ZADD redis_zset:lisi 70 153xxxx2222,city2
ZADD redis_zset:wangwu 90 153xxxx3333,city3
```

说明

若 Redis 启用通道加密，使用命令：**./redis-cli -h** *10.10.10.11* **-p** *22400* **--tls -c**

登录 Manager，选择“集群 > 服务 > Redis > 配置 > 全部配置”，搜索“REDIS_SSL_ON”，将参数“值”设置为“true”，Redis 启用 SSL 通道加密。通道加密在数据传输中对数据进行加密保护，会损耗性能，Redis 中无重要或敏感信息不建议开启。

步骤 4 生产数据，写入 Kafka Source 表中。

sh kafka-console-producer.sh --broker-list *Kafka 角色实例所在节点的 IP 地址:Kafka 端口号* **--topic** *主题名称* **--producer.config** *客户端目录* **/Kafka/kafka/config/producer.properties**

输入消息内容：

```
1,zhangsan,20
2,lisi,25
3,wangwu,28
```

步骤 5 执行以下命令查看 Sink 表中是否接收到数据，即查看 Kafka topic 是否正常写入数据。

sh kafka-console-consumer.sh --topic *主题名称* **--bootstrap-server** *Kafka 的 Broker 实例业务 IP:Kafka 端口号* **--consumer.config** ***客户端目录*** **/Kafka/kafka/config/consumer.properties**

结果如下：

```
1,zhangsan,20,153xxxx1111,city1
2,lisi,25,153xxxx2222,city2
3,wangwu,28,153xxxx3333,city3
```

----结束

WITH 主要参数说明

配置项	是否必选	类型	描述
zSetScoreColumn	可选	String	Redis 作为维表时，ZSet 格式 score 字段对应的列名
hashKeyColumn	可选	String	Hash 格式，Hash 字段对应的列名
host	必选	String	Redis 集群连接 IP，为 Redis 集群的实例 IP（业务平面）
port	必选	Stri	端口为对应的 Redis 实例的端口

配置项	是否必选	类型	描述
		ng	Redis 实例的端口计算方式为：22400+该实例的 ID-1 实例 ID 可以通过在 FusionInsight Manager 中选择“集群 > *待操作集群的名称* > 服务 > Redis > Redis 管理”，单击 Redis 集群名称查看 例如 Redis 集群内角色 R1 对应的 Redis 实例的端口为 22400+1-1=22400
separator	可选	String	Redis 作为维表时，value 中的字段分割符，示例：“(,)”、“(\u200b)”
ttlDeadlineSecond	可选	String	TTL 截止时间，Sink 专用，例如：1615305600，表示写入的 key 将在 2021-03-10 00:00:00 数据过期
ttlDurationSecond	可选	String	TTL 时间，Sink 专用，例如：1000，表示写入的 key 将在写入 1000 秒后过期
keyPrefix	可选	String	Redis key 的前缀

6.7 配置任务运行残留信息清理

操作场景

Flink 任务异常停止时会在 ZooKeeper、HDFS 中残留目录，开启 FlinkServer 目录残留清理功能可以清理残留目录。

前提条件

集群已安装 FlinkServer 实例并运行正常。

配置步骤

步骤 1 登录 Manager 页面。

步骤 2 选择“集群 > 服务 > Flink > 配置 > 全部配置”，搜索参数“ClearUpEnabled”并将值设置为“true”开启目录残留清理功能，相关参数详情请见表 6-34。

表6-34 FlinkServer 目录残留清理参数

参数	描述	默认值	取值范围
ClearUpEnabled	FlinkServer 是否开启目录残留清理功能。	true	true、false
ClearUpPeriod	FlinkServer 残留目录清理周期。单	1440	1440~214748364

参数	描述	默认值	取值范围
	位：分钟		7
TrashDirectoryRetentionPeriod	FlinkServer 保留残留目录的周期。单位：分钟	10080	10080~2147483647

步骤 3 配置完成后，单击左上角“保存”并确定保存。

须知

- 该特性只会清理 ZooKeeper 的“/flink_base”目录和 HDFS 的“/flink/recovery”目录下的残留目录，用户自定义修改的目录不会清理。
- HDFS 中的“checkpoints”目录需用户手动删除，该特性不会删除。

----结束

6.8 Flink 日志介绍

日志描述

日志存储路径：

- Flink 作业运行日志：“${BIGDATA_DATA_HOME}/hadoop/data${i}/nm/containerlogs/application_${appid}/container_{$contid}”。

说明

运行中的任务日志存储在以上路径中，运行结束后会基于 Yarn 的配置确定是否汇聚到 HDFS 目录中。

- FlinkResource 运行日志：“/var/log/Bigdata/flink/flinkResource”。
- FlinkServer HA 脚本相关运行日志（MRS 3.2.0 及以后版本）：“/var/log/Bigdata/audit/flink/flinkserver/ha”

日志归档规则：

1. FlinkResource 运行日志：
   - 服务日志默认 20MB 滚动存储一次，最多保留 20 个文件，不压缩。
   - 日志大小和压缩文件保留个数可以在 Manager 界面中配置或者修改客户端“*客户端安装目录*/Flink/flink/conf/”中的 log4j-cli.properties、log4j.properties、log4j-session.properties 中对应的配置项。

表6-35 FlinkResource 日志列表

日志类型	日志文件名	描述

日志类型	日志文件名	描述
FlinkResource 运行日志	checkService.log	健康检查日志。
	kinit.log	初始化日志。
	postinstall.log	服务安装日志。
	prestart.log	prestart 脚本日志。
	start.log	启动日志。

2. FlinkServer 服务日志、审计日志和 HA 相关日志。
   - FlinkServer 服务日志、审计日志和 HA 相关日志默认 100MB 滚动存储一次，服务日志最多保留 30 天，审计日志最多保留 90 天。
   - 日志大小和压缩文件保留个数可以在 Manager 界面中配置或者修改客户端“*客户端安装目录*/Flink/flink/conf/”中的 log4j-cli.properties、log4j.properties、log4j-session.properties 中对应的配置项。

表6-36 FlinkServer 日志列表

日志类型	日志文件名	描述
FlinkServer 运行日志	checkService.log	健康检查日志。
	checkFlinkServer.log	FlinkServer 健康检查日志。
	localhost_access_log.*yyyy-mm-dd*.txt	FlinkServer 访问 URL 日志。
	start_thrift_server.out	thrift server 启动日志。
	thrift_server_thriftServer_*xxx*.log.last	
	cleanup.log	安装卸载实例时的清理日志。
	flink-omm-client-*IP*.log	作业启动日志。
	flinkserver_*yyyymmdd-x*.log.gz	业务归档日志。
	flinkserver.log	业务日志。
	flinkserver---*pidxxxx*-gc.log.*x*.current	GC 日志。
	kinit.log	初始化日志。
	postinstall.log	服务安装日志。
	prestart.log	prestart 脚本日志。

日志类型	日志文件名	描述
	start.log	启动日志。
	stop.log	停止日志。
	catalina.*yyyy-mm-dd*.log	tomcat 运行日志.。
	catalina.out	
	host-manager.*yyyy-mm-dd*.log	
	localhost.*yyyy-mm-dd*.log	
	manager.*yyyy-mm-dd*.log	
FlinkServer HA 脚本相关运行日志（MRS 3.2.0 及以后版本）	ha.log	HA 运行日志。
	ha_monitor.log	HA 进程监控日志。
	floatip_ha.log	FloatIP 资源脚本日志。
	rcommflinkserver.log	FlinkServer 资源脚本日志。
	checkHaStatus.log	HA 进程日志。
	checknode.log	HA 健康状态日志。
	rs-sendAlarm.log	HA 告警发送日志。
	flink_roll.log	FlinkServer 主备倒换日志（需执行主备倒换操作）。
FlinkServer 审计日志	flinkserver_audit_*yyyymmdd-x*.log.gz	审计归档日志。
	flinkserver_audit.log	审计日志。
堆栈信息日志（MRS 3.2.0 及以后版本）	threadDump-<*DATE*>.log	实例重启或实例停止时会打印。

日志级别

Flink 中提供了如表 6-37 所示的日志级别。日志级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG。程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表6-37 日志级别

级别	描述
ERROR	ERROR 表示当前时间处理存在错误信息。

级别	描述
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

步骤 1 请参考 25.1 修改集群服务配置参数，进入 Flink 的“全部配置”页面。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别。

步骤 4 保存配置，在弹出窗口中单击“确定”使配置生效。

----结束

说明

- 配置完成后不需要重启服务，重新下载客户端使配置生效。
- 也可以直接修改客户端“*客户端安装目录*/Flink/flink/conf/”中 log4j-cli.properties、log4j.properties、log4j-session.properties 文件中对应的日志级别配置项。
- 通过客户端提交作业时会在客户端 log 文件夹中生成相应日志文件，由于系统默认 umask 值是 0022，所以日志默认权限为 644；如果需要修改文件权限，需要修改 umask 值；例如修改 omm 用户 umask 值：
- 在“/home/omm/.baskrc”文件末尾添加“umask 0026”；
- 执行命令 **source /home/omm/.baskrc** 使文件权限生效。

日志格式

表6-38 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2019-06-27 21:30:31,778	INFO	[flink-akka.actor.default-dispatcher-3]	TaskManager container_e10_1498290698388_0004_02_000007 has started.	org.apache.flink.yarn.YarnFlinkResourceManager (FlinkResourceManager.java:368)

6.9 Flink 性能调优

6.9.1 配置内存

操作场景

Flink 是依赖内存计算，计算过程中内存不够对 Flink 的执行效率影响很大。可以通过监控 GC（Garbage Collection），评估内存使用及剩余情况来判断内存是否变成性能瓶颈，并根据情况优化。

监控节点进程的 YARN 的 Container GC 日志，如果频繁出现 Full GC，需要优化 GC。

说明

GC 的配置：在客户端的“conf/flink-conf.yaml”配置文件中，在“env.java.opts”配置项中添加参数：“-Xloggc:<LOG_DIR>/gc.log -XX:+PrintGCDetails -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=20 -XX:GCLogFileSize=20M”。 此处默认已经添加 GC 日志。

操作步骤

- 优化 GC。

  调整老年代和新生代的比值。在客户端的“conf/flink-conf.yaml”配置文件中，在“env.java.opts”配置项中添加参数：“-XX:NewRatio”。如“ -XX:NewRatio=2”，则表示老年代与新生代的比值为 2:1，新生代占整个堆空间的 1/3，老年代占 2/3。
- 开发 Flink 应用程序时，优化 DataStream 的数据分区或分组操作。
  - 当分区导致数据倾斜时，需要考虑优化分区。
  - 避免非并行度操作，有些对 DataStream 的操作会导致无法并行，例如 WindowAll。
  - keyBy 尽量不要使用 String。

6.9.2 设置并行度

操作场景

并行度控制任务的数量，影响操作后数据被切分成的块数。调整并行度让任务的数量和每个任务处理的数据与机器的处理能力达到更优。

查看 CPU 使用情况和内存占用情况，当任务和数据不是平均分布在各节点，而是集中在个别节点时，可以增大并行度使任务和数据更均匀的分布在各个节点。增加任务的并行度，充分利用集群机器的计算能力。

操作步骤

任务的并行度可以通过以下四种层次（按优先级从高到低排列）指定，用户可以根据实际的内存、CPU、数据以及应用程序逻辑的情况调整并行度参数。

- 算子层次

  一个算子、数据源和 sink 的并行度可以通过调用 setParallelism()方法来指定，例如

```
final StreamExecutionEnvironment env =
StreamExecutionEnvironment.getExecutionEnvironment();

DataStream<String> text = [...]
DataStream<Tuple2<String, Integer>> wordCounts = text
    .flatMap(new LineSplitter())
    .keyBy(0)
    .timeWindow(Time.seconds(5))
    .sum(1).setParallelism(5);

wordCounts.print();

env.execute("Word Count Example");
```

- 执行环境层次

  Flink 程序运行在执行环境中。执行环境为所有执行的算子、数据源、data sink 定义了一个默认的并行度。

  执行环境的默认并行度可以通过调用 setParallelism()方法指定。例如：

  ```
  final StreamExecutionEnvironment env =
  StreamExecutionEnvironment.getExecutionEnvironment();
  env.setParallelism(3);
  DataStream<String> text = [...]
  DataStream<Tuple2<String, Integer>> wordCounts = [...]
  wordCounts.print();
  env.execute("Word Count Example");
  ```

- 客户端层次

  并行度可以在客户端将 job 提交到 Flink 时设定。对于 CLI 客户端，可以通过“-p”参数指定并行度。例如：

  ```
  ./bin/flink run -p 10 ../examples/*WordCount-java*.jar
  ```

- 系统层次

  在系统级可以通过修改 Flink 客户端 conf 目录下的“flink-conf.yaml”文件中的“parallelism.default”配置选项来指定所有执行环境的默认并行度。

6.9.3 配置进程参数

操作场景

Flink on YARN 模式下，有 JobManager 和 TaskManager 两种进程。在任务调度和运行的过程中，JobManager 和 TaskManager 承担了很大的责任。

因而 JobManager 和 TaskManager 的参数配置对 Flink 应用的执行有着很大的影响意义。用户可通过如下操作对 Flink 集群性能做优化。

操作步骤

步骤 1 配置 JobManager 内存。

JobManager 负责任务的调度，以及 TaskManager、RM 之间的消息通信。当任务数变多，任务平行度增大时，JobManager 内存都需要相应增大。

您可以根据实际任务数量的多少，为 JobManager 设置一个合适的内存。

- 在使用 yarn-session 命令时，添加“-jm MEM”参数设置内存。
- 在使用 yarn-cluster 命令时，添加“-yjm MEM”参数设置内存。

步骤 2 配置 TaskManager 个数。

每个 TaskManager 每个核同时能跑一个 task，所以增加了 TaskManager 的个数相当于增大了任务的并发度。在资源充足的情况下，可以相应增加 TaskManager 的个数，以提高运行效率。

步骤 3 配置 TaskManager Slot 数。

每个 TaskManager 多个核同时能跑多个 task，相当于增大了任务的并发度。但是由于所有核共用 TaskManager 的内存，所以要在内存和核数之间做好平衡。

- 在使用 yarn-session 命令时，添加“-s NUM”参数设置 SLOT 数。
- 在使用 yarn-cluster 命令时，添加“-ys NUM”参数设置 SLOT 数。

步骤 4 配置 TaskManager 内存。

TaskManager 的内存主要用于任务执行、通信等。当一个任务很大的时候，可能需要较多资源，因而内存也可以做相应的增加。

- 将在使用 yarn-session 命令时，添加“-tm MEM”参数设置内存。
- 将在使用 yarn-cluster 命令时，添加“-ytm MEM”参数设置内存。

----结束

6.9.4 设计分区方法

操作场景

合理的设计分区依据，可以优化 task 的切分。在程序编写过程中要尽量分区均匀，这样可以实现每个 task 数据不倾斜，防止由于某个 task 的执行时间过长导致整个任务执行缓慢。

操作步骤

以下是几种分区方法。

- **随机分区**：将元素随机地进行分区。

```
dataStream.shuffle();
```

- **Rebalancing (Round-robin partitioning)**：基于 round-robin 对元素进行分区，使得每个分区负责均衡。对于存在数据倾斜的性能优化是很有用的。

```
dataStream.rebalance();
```

- **Rescaling**：以 round-robin 的形式将元素分区到下游操作的子集中。如果你想要将数据从一个源的每个并行实例中散发到一些 mappers 的子集中，用来分散负载，但是又不想要完全的 rebalance 介入（引入`rebalance()`），这会非常有用。

```
dataStream.rescale();
```

- **广播**：广播每个元素到所有分区。

```
dataStream.broadcast();
```

- **自定义分区**：使用一个用户自定义的 Partitioner 对每一个元素选择目标 task，由于用户对自己的数据更加熟悉，可以按照某个特征进行分区，从而优化任务执行。

  简单示例如下所示：

```
// fromElements 构造简单的 Tuple2 流
DataStream<Tuple2<String, Integer>> dataStream =
env.fromElements(Tuple2.of("hello",1), Tuple2.of("test",2),
Tuple2.of("world",100));

// 定义用于分区的 key 值，返回即属于哪个 partition 的，该值加 1 就是对应的子任务的 id 号
Partitioner<Tuple2<String, Integer>> strPartitioner = new
Partitioner<Tuple2<String, Integer>>() {
   @Override
   public int partition(Tuple2<String, Integer> key, int numPartitions) {
      return (key.f0.length() + key.f1) % numPartitions;
   }
};

// 使用 Tuple2 进行分区的 key 值
dataStream.partitionCustom(strPartitioner, new KeySelector<Tuple2<String,
Integer>, Tuple2<String, Integer>>() {
   @Override
   public Tuple2<String, Integer> getKey(Tuple2<String, Integer> value) throws
Exception {
      return value;
   }
}).print();
```

6.9.5 配置 netty 网络通信

操作场景

Flink 通信主要依赖 netty 网络，所以在 Flink 应用执行过程中，netty 的设置尤为重要，网络通信的好坏直接决定着数据交换的速度以及任务执行的效率。

操作步骤

以下配置均可在客户端的“conf/flink-conf.yaml”配置文件中进行修改适配，默认已经是相对较优解，请谨慎修改，防止性能下降。

- “taskmanager.network.netty.num-arenas”： 默认是“taskmanager.numberOfTaskSlots”，表示 netty 的域的数量。
- “taskmanager.network.netty.server.numThreads”和“taskmanager.network.netty.client.numThreads”：默认是“taskmanager.numberOfTaskSlots”，表示 netty 的客户端和服务端的线程数目设置。
- “taskmanager.network.netty.client.connectTimeoutSec”：默认是 120s，表示 taskmanager 的客户端连接超时的时间。
- “taskmanager.network.netty.sendReceiveBufferSize”：默认是系统缓冲区大小(cat /proc/sys/net/ipv4/tcp_[rw]mem) ，一般为 4MB，表示 netty 的发送和接收的缓冲区大小。

- “taskmanager.network.netty.transport”：默认为“nio”方式，表示 netty 的传输方式，有“nio”和“epoll”两种方式。

6.9.6 状态后端优化

6.9.6.1 RocksDB 状态后端调优

本章节适用于 MRS 3.3.0 及以后版本。

操作场景

当启用 RocksDB 作为作业的状态后端时，大量的状态数据会导致 RocksDB 的读写性能差。可通过如下方法排查算子性能是否受 RocksDB 影响：

- 在 TaskManager 页面的 ThreadDump 查看算子是否长时间执行在 RocksDB 的操作接口上，多次刷新后出现如下所示即长时间执行在 RocksDB 的操作接口上。

```
Join[5] -> Calc[6] -> Sink: print[7] (1/1)#0" Id=113 RUNNABLE (in native)
    at org.rocksdb.RocksDB.put(Native Method)
    at org.rocksdb.RocksDB.put(RocksDB.java:955)
    at
org.apache.flink.contrib.streaming.state.RocksDBValueState.update(RocksDBValueS
tate.java:103)
```

- 通过开启火焰图（自定义配置 rest.flamegraph.enabled=true 打开火焰图）重新提交作业查看算子热点，如下图所示算子热点达到 100%。

图6-6 通过火焰图查看算子热点

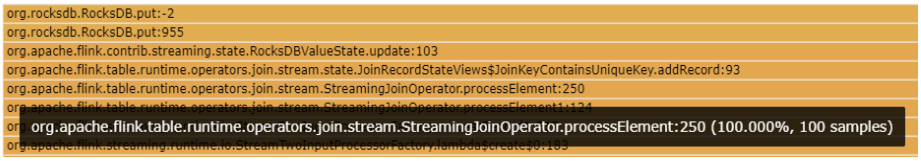

当发生 RocksDB 读写延迟大时，可开启 RocksDB 监测和告警，通过监测和相关告警项对作业的 RocksDB 参数进行调优。当作业调优后，建议关闭 RocksDB 的监测和告警，因为 RocksDB 的监测和告警会损失 RocksDB 的 5%~10%性能。

为了避免对其他作业的影响，RocksDB 监测的相关配置通过自定义参数生效，本章节为你介绍开启 RocksDB 监测和告警和相关调优参数。

操作步骤

步骤 1 使用具有 FlinkServer 管理员权限的用户登录 FusionInsight Manager。

步骤 2 选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 3 单击“作业管理”进入作业管理页面。

步骤 4 找到待调优的并处于非运行中的作业，在“操作”列单击“开发”进入作业开发界面。

步骤 5 在作业开发界面的“自定义参数”项中，添加如下参数并保存。

- 开启 RocksDB 监测

表6-39 RocksDB 监测配置

参数名称	值	说明
state.backend.rocksdb.metrics.hot.enabled	true	Rocksdb 非统计的监测，非统计的监测包含 Rocksdb Property 包含的监测项
state.backend.rocksdb.metrics.statistics.enabled	true	Rocksdb Statistics 统计监测
state.backend.rocksdb.metrics.num-immutable-mem-table	true	监测 RocksDB 中不可变 Memtable 的数量，该值若一直增加，或大于设置的阈值，会影响写性能
state.backend.rocksdb.metrics.mem-table-flush-pending	true	监测 RocksDB 中 Pending 的 Memtable flush 数
state.backend.rocksdb.metrics.compaction-pending	true	监测 RocksDB 中 Pending 的 Compaction 数。如果 Pending Compaction 存在，则返回“1”，否则返回“0”
state.backend.rocksdb.metrics.background-errors	true	监测 RocksDB 中 metrics.background-errors 的数量
state.backend.rocksdb.metrics.cur-size-active-mem-table	true	监测 Active Memtable 的大致大小，单位：字节
state.backend.rocksdb.metrics.cur-size-all-mem-tables	true	监测 Active 和未 Flush 的不可变 Memtable 的大致大小，单位：字节
state.backend.rocksdb.metrics.size-all-mem-tables	true	监测 Active memtable、未 Flush 的和 Pinned 的 Memtable 的大致大小，单位：字节
state.backend.rocksdb.metrics.num-entries-active-mem-table	true	监测 Active memtable 中的条目总数
state.backend.rocksdb.metrics.num-entries-imm-mem-tables	true	监测 imm-mem-tables 中的条目总数
state.backend.rocksdb.metrics.num-deletes-active-mem-table	true	监测 Active memtable 中删除条目的总数
state.backend.rocksdb.metrics.num-deletes-imm-mem-tables	true	监测未刷新的不可变 Memtable 中删除条目的总数
state.backend.rocksdb.metrics.estimate-num-keys	true	监测 RocksDB 中的 Key 数量

参数名称	值	说明
state.backend.rocksdb.metrics.estimate-table-readers-mem	true	监测用于读取 SST 表的内存，不包括块缓存（如过滤器和索引块）中使用的内存，单位：字节
state.backend.rocksdb.metrics.num-snapshots	true	监测数据库未发布快照的数量
state.backend.rocksdb.metrics.num-live-versions	true	监测实时版本的数量。版本是内部数据结构，版本太多说明 RocksDB 可能会因为查询或者 Compaction 而不能删除旧版本
state.backend.rocksdb.metrics.estimate-live-data-size	true	监测实时数据量，单位：字节（由于空间放大，通常小于 SST 文件大小）
state.backend.rocksdb.metrics.total-sst-files-size	true	监测所有版本的 SST 文件的总大小，单位：字节。文件太多，可能会降低查询的速度
state.backend.rocksdb.metrics.live-sst-files-size	true	监测属于最新版本的所有 SST 文件的总大小，单位：字节。文件太多，可能会降低查询的速度
state.backend.rocksdb.metrics.estimate-pending-compaction-bytes	true	监测 Compaction 的数据总大小，单位：字节。以使所有级别降至目标大小以下，基于级别以外的其他压缩无效
state.backend.rocksdb.metrics.num-running-compactions	true	监测当前运行的 Compaction 数量，如果线程数都是 Running，可能会影响写性能
state.backend.rocksdb.metrics.num-running-flushes	true	监测当前运行的 Flush 任务数，如果线程数都是 Running，可能会影响写性能
state.backend.rocksdb.metrics.actual-delayed-write-rate	true	监测当前实际延迟写入速率。返回 0 表示无延迟
state.backend.rocksdb.metrics.is-write-stopped	true	监测 RocksDB 中的写入是否已停止。如果写入已停止，则返回 1，否则返回 0
state.backend.rocksdb.metrics.block-cache-capacity	true	监测 Block cache 容量
state.backend.rocksdb.metrics.block-cache-usage	true	监测 Block cache 中数据占用内存大小
state.backend.rocksdb.metrics.block-cache-pinned-usage	true	监测 Block cache 中 pinned 数据占用内存大小
state.backend.rocksdb.metrics.compression-ratio	true	监测每层的压缩率
state.backend.rocksdb.metrics.compression-ratio-levelN	7	监测压缩率的层数，取值范围：0-配置的层数

参数名称	值	说明
state.backend.rocksdb.metrics.num-files	true	监测每层的文件数
state.backend.rocksdb.metrics.num-files-levelN	7	监测文件数的层数，取值范围：0-配置的层数
state.backend.rocksdb.metrics.statistics.ticker	block.cache.miss,block.cache.hit,block.cache.index.miss,block.cache.index.hit,block.cache.filter.miss,block.cache.filter.hit,block.cache.data.miss,block.cache.data.hit,bloom.filter.useful,memtable.hit,memtable.miss,l0.hit,l1.hit,l2andup.hit,stall.micros	statistics ticker 监测项 如需添加新的监测项，在其末尾追加并以逗号分隔
state.backend.rocksdb.metrics.statistics.histogram	db.get.micros,db.write.micros,db.flush.micros,compaction.times.micros	statistics 直方监测项 如需添加新的监测项，在其末尾追加并以逗号分隔

- 开启 RocksDB 告警

表6-40 RocksDB 告警配置

配置项	默认值	说明
metrics.reporter.alarm.job.alarm.rocksdb.metrics.enable	true	是否开启 RocksDB 监测，默认不开启。只有状态后端为 RocksDB 时该配置才有效
metrics.reporter.alarm.job.alarm.rocksdb.metrics.duration	180s	RocksDB 监测转告警的周期
metrics.reporter.alarm.job.alarm.rocksdb.metrics.print.enabled	true	是否将 RocksDB 监测打印到 TaskManager 当 metrics.reporter.alarm.job.alarm.rocksdb.metrics.enable=true 时，该配置项默认为 true
metrics.reporter.alarm.job.alarm.rocksdb.metrics.print.interval	5min	RocksDB 监测打印到 TaskManager 的间隔时间
metrics.reporter.alarm.job.alarm.rocksdb.get.micros.threshold	1000	Get 耗时阈值，周期（metrics.reporter.alarm.job.alarm.rocksdb.metrics.duration）内连续出现超过该阈值，作业将上报告警，单位：微秒
metrics.reporter.alarm.job.alarm.rocksdb.write.micros.threshold	3000	Write 耗时阈值，周期（metrics.reporter.alarm.job.alarm.rocksdb.metrics.duration）内连续出现超过该阈值，作业将上报告警，单位：微秒
metrics.reporter.alarm.job.alarm.actual-delayed-write-rate.threshold	0	周期（metrics.reporter.alarm.job.alarm.rocksdb.metrics.duration）内连续出现写限速，作业将上报告警，“0”表示不限速
metrics.reporter.alarm.job.alarm.rocksdb.background.jobs.multiplier	2	flush/compaction 的请求量超过了 state.backend.rocksdb.thread.num 的 multiplier 倍数，作业将上报告警

步骤 6 在“作业管理”页面单击“启动”运行作业。然后根据 RocksDB 监测和告警情况，在作业开发界面的“自定义参数”项中添加如下参数调优作业。作业调优完成后建议关闭 RocksDB 的监测和告警。

表6-41 RocksDB 调优参数配置

参数名称	值	说明
state.backend.rocksdb.writebuffer.count	2	设置 Active memtable 和 Immutable memtable 数，当写入过快或者 Flink 线程太少，会导致写入阻塞。启用 SPINNING_DISK_OPTIMIZED_HIGH_MEM

参数名称	值	说明
		时，默认值为“4” 建议该值大于等于“state.backend.rocksdb.writebuffer.number-to-merge”的值加“2”
state.backend.rocksdb.writebuffer.size	64MB	Memtable 大小
state.backend.rocksdb.thread.num	2	RocksDB Flush 和 Compaction 的线程数，启用 SPINNING_DISK_OPTIMIZED_HIGH_MEM 时，默认值为“4”
state.backend.rocksdb.writebuffer.number-to-merge	1	Immutable flush 前的个数，n 个 Immutable flush 时会去重，启用 SPINNING_DISK_OPTIMIZED_HIGH_MEM 时，默认值是“3”
state.backend.rocksdb.compaction.level.max-size-level-base	256MB	Level1 的 SSL 文件总大小，启用 SPINNING_DISK_OPTIMIZED_HIGH_MEM 时，默认值是“1GB”
state.backend.rocksdb.compaction.level.target-file-size-base	64MB	Level1+的 SSL 文件大小，启用 SPINNING_DISK_OPTIMIZED_HIGH_MEM 时，默认值是“128MB”
state.backend.rocksdb.num_levels	7	RocksDB 的 Level 数
state.backend.rocksdb.level0_slowdown_writes_trigger	20	Level0 触发 Slowdown 的文件数，小于“0”表示永远不会触发
state.backend.rocksdb.level0_stop_writes_trigger	36	Level0 触发 Stop 的最大文件数
state.backend.rocksdb.max_compaction_bytes	-	一次 Compaction 最大的 Bytes，默认值：（state.backend.rocksdb.compaction.level.target-file-size-base） * 25
state.backend.rocksdb.level0_file_num_compaction_trigger	4	Level0 的 SST 数量达到阈值，触发 Level0 到 Level1 的 Compaction
state.backend.rocksdb.compression	snappy	SST 文件压缩算法 取值范围：null、snapp、zlib、bzip2、lz4、lz4hc、xpress、zstd
state.backend.rocksdb.bottommost_compression	snappy	底层使用重量级的压缩类型，减少空间。因为底层的数据可能是冷数据，如果要启用，推荐使用 zstd 或者 zlib 取值范围：null、snapp、zlib、bzip2、lz4、lz4hc、xpress、zstd

参数名称	值	说明
state.backend.rocksdb.max_bytes_for_level_multiplier	10	Level1 加相邻 2 层的数据量倍数因子
state.backend.rocksdb.hard-pending-compaction-bytes-limit	256GB	当 Pending 的 Compaction 超过该阈值，写停止
state.backend.rocksdb.soft-pending-compaction-bytes-limit	64GB	当 Pending 的 Compaction 超过该阈值，写限流
state.backend.rocksdb.use-bloom-filter	true	Bloom 过滤器，开启后每个新创建的 SST 文件都将包含一个 Bloom 过滤器
state.backend.rocksdb.block.cache-size	8MB	Cache 缓存大小，启用 SPINNING_DISK_OPTIMIZED_HIGH_MEM 时，默认值是“256MB”
state.backend.rocksdb.block.blocksize	4KB	Block 大小，启用 SPINNING_DISK_OPTIMIZED_HIGH_MEM 时，默认值是“128KB”
state.backend.rocksdb.files.open	-1	最大打开句柄数，主要被用在 SST 文件句柄上，“-1”表示不限制

----结束

6.9.6.2 开启状态后端冷热分级存储

本章节适用于 MRS 3.3.0 及以后版本。

在宽表关联计算场景中，每张表字段较多，导致状态后端数据量较大，严重影响状态后端性能时，可开启状态后端冷热分级存储功能。

前提条件

- 集群已安装，包括 HDFS、Yarn、Flink 和 HBase。
- 包含 Flink、HBase 等服务的客户端已安装，安装路径如：/opt/hadoopclient。

开启状态后端冷热分级存储功能步骤

步骤 1 以客户端安装用户登录安装客户端的节点，拷贝 HBase 的“/opt/client/HBase/hbase/conf/”目录下的所有配置文件至部署 FlinkServer 的所有节点的一个空目录，如“/tmp/client/HBase/hbase/conf/”。

修改 FlinkServer 节点上面配置文件目录及其上层目录属主为 omm。

chown omm: /tmp/client/HBase/ -R

说明

- FlinkServer 节点：

  登录 Manager，选择“集群 > 服务 > Flink > 实例”，查看 FlinkServer 所在的“业务 IP”。
- 若 FlinkServer 实例所在节点与包含 HBase 服务客户端的安装节点相同，则该节点不执行此步骤。

步骤 2 登录 Manager，选择“集群 > 服务 > Flink > 配置 > 全部配置”，搜索“HBASE_CONF_DIR”参数，在该参数的“值”中填写步骤 1 中拷贝了 HBase 配置文件的 FlinkServer 的目录，如“/tmp/client/HBase/hbase/conf/”。

步骤 3 填写完成后单击“保存”，确认修改配置后单击“确定”。

步骤 4 单击“实例”，勾选所有 FlinkServer 实例，选择“更多 > 重启实例”，输入密码，单击“确定”重启实例。

步骤 5 使用具有 FlinkServer 管理员权限的用户登录 FusionInsight Manager。

步骤 6 选择“集群 > 服务 > Flink”，在“Flink WebUI”右侧，单击链接，访问 Flink 的 WebUI。

步骤 7 单击“作业管理”进入作业管理页面。

步骤 8 找到待调优的并处于非运行中的作业，在“操作”列单击“开发”进入作业开发界面。

步骤 9 在作业开发界面的“自定义参数”项中，根据实际需求添加如下参数并保存，热数据（常用及使用中数据）可参考表 6-42，冷数据（不常用、较长时间未使用的数据）可参考表 6-43。

表6-42 RocksDB 状态后端存储

参数名称	参数说明	取值示例
table.exec.state.cold.enabled	是否开启冷热分离的 RocksDB。 • false（默认值）：关闭。 • true：开启。	false
state.backend.rocksdb.cold.localdir	冷数据的存储目录。	-
state.backend.rocksdb.cold.predefined-options	冷数据 RocksDB 的预定义配置： • DEFAULT（默认值）：不强制 RocksDB 写磁盘，建议配置为当前值。 • SPINNING_DISK_OPTIMIZED_HIGH_MEM：预置优化 RocksDB 写磁盘参数，由于 Flink 不依赖 RocksDB 数据恢复作业，所以不建议使用当前配置。	DEFAULT
state.backend	状态后端存储介质，建议“rocksdb”。	rocksdb

表6-43 HBase 作为冷数据二级状态后端存储

参数名称	参数说明	取值示例
table.exec.state.cold.enabled	是否开启冷热分级存储。 • false（默认值）：关闭。 • true：开启。	false
state.backend.cold	指定冷数据状态后端存储，当前仅支持“hbase”。	hbase
table.exec.state.ttl	数据状态变化的超时时间。 • table.exec.state.cold.enabled 为 true 时：表示热数据的超期时间，超过该值热数据将成为冷数据。 • table.exec.state.cold.enabled 为 false 时：表示所有数据的超期时间，超过该值数据将被清理。 • 默认值：0，表示数据永不过期。	0
state.backend.hbase.zookeeper.quorum	访问 HBase 使用的 ZooKeeper 的连接地址，格式：*ZooKeeper 的 quorumpeer 实例业务 IP:ZooKeeper 客户端端口号,ZooKeeper 的 quorumpeer 实例业务 IP:ZooKeeper 客户端端口号,ZooKeeper 的 quorumpeer 实例业务 IP:ZooKeeper 客户端端口号*	192.168.10.10:24002,192.168.10.11:24002,192.168.10.12:24002
state.backend	状态后端存储介质，建议“rocksdb”。	rocksdb

说明

- ZooKeeper 的 quorumpeer 实例业务 IP：

  ZooKeeper 服务所有 quorumpeer 实例业务 IP。登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。

- ZooKeeper 客户端端口号：

  登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。

----结束

6.9.7 经验总结

数据倾斜

当数据发生倾斜（某一部分数据量特别大），虽然没有 GC（Gabage Collection，垃圾回收），但是 task 执行时间严重不一致。

- 需要重新设计 key，以更小粒度的 key 使得 task 大小合理化。
- 修改并行度。
- 调用 rebalance 操作，使数据分区均匀。

缓冲区超时设置

- 由于 task 在执行过程中存在数据通过网络进行交换，数据在不同服务器之间传递的缓冲区超时时间可以通过 setBufferTimeout 进行设置。
- 当设置“setBufferTimeout(-1)”，会等待缓冲区满之后才会刷新，使其达到最大吞吐量；当设置“setBufferTimeout(0)”时，可以最小化延迟，数据一旦接收到就会刷新；当设置“setBufferTimeout”大于 0 时，缓冲区会在该时间之后超时，然后进行缓冲区的刷新。

  示例可以参考如下：

```
env.setBufferTimeout(timeoutMillis);

env.generateSequence(1,10).map(new MyMapper()).setBufferTimeout(timeoutMillis);
```

资源冗余量

Flink 任务运行时，建议整个集群的 Yarn 资源留有一定的余量。比如当前 Yarn 总体的资源有 100Vcore，200GB，则建议 Yarn 的任务使用 90vcore，180GB，保留 10%的资源用于当部分节点故障时，任务可以自动重试恢复。

6.10 Flink 常见 Shell 命令

在使用 Flink 的 Shell 脚本前，首先需要执行以下操作，详细使用场景可参考 6.1 从零开始使用 Flink 运行 wordcount 作业：

步骤 1 安装 Flink 客户端，例如安装目录为“/opt/client”。

步骤 2 初始化环境变量。

source /opt/client/bigdata_env

步骤 3 如果当前集群已启用 Kerberos 认证，需先配置客户端认证，可参考步骤 4。如果当前集群未启用 Kerberos 认证，则无需执行该步骤。

步骤 4 参考表 6-44 运行相关命令。

表6-44 Flink Shell 命令参考

命令	参数说明	描述

命令	参数说明	描述
yarn-session.sh	-at,--applicationType <arg>：为 Yarn application 自定义类型。 -D <property=value>：动态参数配置。 -d,--detached：关闭交互模式，启动一个分离的 Flink YARN session。 -h,--help: 显示 Yarn session CLI 的帮助。 -id,--applicationId <arg>：绑定到一个已经运行的 Yarn session。 -j,--jar <arg>：设置用户 jar 包路径。 -jm,--jobManagerMemory <arg>：为 JobManager 设置内存。 -m,--jobmanager <arg>：要连接的 JobManager 的地址，使用该参数可以连接特定的 JobManager。 -nl,--nodeLabel <arg>: 指定 YARN application 的 nodeLabel 。 -nm,--name <arg>：为 Yarn application 自定义名称。 -q,--query：查询可用的 Yarn 资源。 -qu,--queue <arg>：指定 YARN 队列。 -s,--slots <arg>：设置每个 Taskmanager 的 SLOT 个数。 -t,--ship <arg>：指定待发送文件的目录。 -tm,--taskManagerMemory <arg>：为 TaskManager 设置内存。 -yd,--yarndetached：以分离模式启动。 -z,--zookeeperNamespace <args>：指定 zookeeper 的 namespace。 -h：获取帮助。	启动一个常驻的 Flink 集群，接受来自 Flink 客户端的任务。
flink run	-c,--class <classname>：指定一个类作为程序运行的入口点。 -C,--classpath <url>：指定 classpath。 -d,--detached：以分离方式运行 job。 -files,--dependencyFiles <arg>：Flink 程序依赖的文件。该参数适用于 MRS 3.2.0 及以后版本。 -n,--allowNonRestoredState： 从快照点恢复时允许跳过不能恢复的状态。比如删除了程序中某个操作符，那么在恢复快照点时需要增加该参数。	Flink 提交作业。 1."-y*"参数是指 yarn-cluster 模式下使用。 2.非"-y*"参数用户在用该命令提交任务前需要先用 yarn-session 启动 Flink 集群。

命令	参数说明	描述
	-m,--jobmanager <host:port>：指定 JobManager。 -p,--parallelism <parallelism>：指定 job 并行度，会覆盖配置文件中配置的并行度参数。 -q,--sysoutLogging：禁止 flink 日志输出至控制台。 -s,--fromSavepoint <savepointPath>：指定用于恢复 job 的 savepoint 路径。 -z,--zookeeperNamespace <zookeeperNamespace>：指定 zookeeper 的 namespace。 -yat,--yarnapplicationType <arg>：为 Yarn application 自定义类型。 -yD <arg>：动态参数配置。 -yd,--yarndetached：以分离模式启动。 -yh,--yarnhelp：获取 yarn 帮助。 -yid,--yarnapplicationId <arg>：绑定到 yarn session 运行 job。 -yj,--yarnjar <arg>：设置 Flink jar 文件路径。 -yjm,--yarnjobManagerMemory <arg>：为 JobManager 设置内存（MB）。 -ynm,--yarnname <arg>：为 Yarn application 自定义名称。 -yq,--yarnquery：查询可用的 YARN 资源（内存、CPU）。 -yqu,--yarnqueue <arg>：指定 YARN 队列。 -ys,--yarnslots：设置每个 TaskManager 的 SLOT 个数。 -yt,--yarnship <arg>：指定待发送文件的路径。 -ytm,--yarntaskManagerMemory <arg>：为 TaskManager 设置内存（MB）。 -yz,--yarnzookeeperNamespace <arg>：指定 zookeeper 的 namespace，需与 yarn-session.sh -z 保持一致。 -h：获取帮助。	
flink info	-c,--class <classname>：指定一个类作为程序运行的入口点。 -p,--parallelism <parallelism>：指定程序运行的并行度。	显示所运行程序的执行计划（JSON）

命令	参数说明	描述
	-h：获取帮助。	
flink list	-a,--all：显示所有的 Job。 -m,--jobmanager <host:port>：指定 JobManager。 -r,--running：仅显示 running 状态的 Job。 -s,--scheduled：仅显示 scheduled 状态的 Job。 -z,--zookeeperNamespace <zookeeperNamespace>：指定 zookeeper 的 namespace。 -yid,--yarnapplicationId <arg>：绑定 YARN session。 -h：获取帮助。	查询集群中运行的程序。
flink stop	-d,--drain：在触发 savepoint 和停止作业之前，发送 MAX_WATERMARK。 -p,--savepointPath <savepointPath>：savepoint 的储存路径，默认目录 state.savepoints.dir。 -m,--jobmanager <host:port>：指定 JobManager。 -z,--zookeeperNamespace <zookeeperNamespace>：指定 zookeeper 的 namespace。 -yid,--yarnapplicationId <arg>：绑定 YARN session。 -h：获取帮助。	强制停止一个运行中的 Job（仅支持 streaming jobs、业务代码 source 端需要 implements StoppableFunction）
flink cancel	-m,--jobmanager <host:port>：指定 JobManager。 -s,--withSavepoint <targetDirectory>：取消 Job 时触发 savepoint，默认目录 state.savepoints.dir -z,--zookeeperNamespace <zookeeperNamespace>：指定 zookeeper 的 namespace。 -yid,--yarnapplicationId <arg>：绑定 YARN session。 -h：获取帮助。	取消一个运行中 Job
flink savepoint	-d,--dispose <arg>：指定 savepoint 的保存目录。 -m,--jobmanager <host:port>：指定 JobManager。 -z,--zookeeperNamespace <zookeeperNamespace>：指定 zookeeper 的	触发一个 savepoint

命令	参数说明	描述
	namespace。 -yid,--yarnapplicationId <arg>：绑定 YARN session。 -h：获取帮助。	
source *客户端安装目录* **/bigdata_env**	无	导入客户端环境变量。 使用限制：如果用户使用自定义脚本（例如 A.sh）并在脚本中调用该命令，则脚本 A.sh 不能传入参数。如果确实需要给 A.sh 传入参数，则需采用二次调用方式。 例如 A.sh 中调用 B.sh，在 B.sh 中调用该命令。A.sh 可以传入参数，B.sh 不能传入参数。
start-scala-shell.sh	local | remote <host> <port> | yarn：运行模式	scala shell 启动脚本
sh generate_keystore.sh	-	用户调用“generate_keystore.sh”脚本工具生成“Security Cookie”、“flink.keystore”和“flink.truststore”。需要输入自定义密码（不能包含#）。

----结束

6.11 Flink 重启策略

概述

Flink 支持不同的重启策略，以在发生故障时控制作业是否重启以及如何重启。若不指定重启策略，集群会使用默认的重启策略。用户也可以在提交作业时指定一个重启策略，可参考 6.5.9 创建作业在作业开发界面配置（MRS 3.1.0 及以后版本）。

重启策略也可以通过 Flink 的配置文件“*客户端安装目录*/Flink/flink/conf/flink-conf.yaml”中的参数“restart-strategy”指定，为全局配置，还可以在应用代码中动态指定，会覆盖全局配置，重启策略包括失败率（failure-rate）和两种默认策略，默认策略为如下：

- 无重启（No restart）：若没有启用 CheckPoint，默认使用该策略。
- 固定间隔（fixed-delay）：若启用了 CheckPoint，但没有配置重启策略，默认使用该策略。

No restart 策略

发生故障时作业会直接失败，不会尝试重启。

参数配置为：

```
restart-strategy: none
```

fixed-delay 策略

发生故障时会尝试重启作业固定次数，如果超过了最大的尝试次数，作业最终会失败。并且在两次连续重启尝试之间，重启策略会等待固定的时间。

以配置若重启失败了 3 次则认为该 Job 失败，重试时间间隔为 10s 为例，参数配置为：

```
restart-strategy: fixed-delay
restart-strategy.fixed-delay.attempts: 3
restart-strategy.fixed-delay.delay: 10 s
```

failure-rate 策略

在作业失败后会直接重启，但超过设置的失败率后，作业会被认定为失败。在两个连续的重启尝试之间，重启策略会等待一个固定的时间。

以配置 10 分钟内若重启失败了 3 次则认为该作业失败，重试时间间隔为 10s 为例，参数配置为：

```
restart-strategy: failure-rate
restart-strategy.failure-rate.max-failures-per-interval: 3
restart-strategy.failure-rate.failure-rate-interval: 10 min
restart-strategy.failure-rate.delay: 10 s
```

重启策略选择

- 如果用户在作业失败后，不希望重试，则推荐使用 No restart 策略。
- 如果用户在作业失败后，希望对作业进行重试，推荐使用 failure-rate 策略。因为 fixed-delay 策略可能会因为网络、内存等硬件故障导致用户作业失败次数达到最大重试次数，从而导致作业失败。

  为了防止在 failure-rate 策略下的无限重启，推荐如下参数配置：

  ```
  restart-strategy: failure-rate
  restart-strategy.failure-rate.max-failures-per-interval: 3
  restart-strategy.failure-rate.failure-rate-interval: 10 min
  restart-strategy.failure-rate.delay: 10 s
  ```

6.12 FlinkSQL 特性增强

6.12.1 FlinkSQL DISTRIBUTEBY

本章节适用于 MRS 3.3.0 及以后版本。

FlinkSQL 新增 DISTRIBUTEBY 特性，根据指定的字段进行分区，支持单字段及多字段，解决数据仅需要分区的场景。示例如下：

```
SELECT /*+ DISTRIBUTEBY('id') */ id, name FROM t1;
SELECT /*+ DISTRIBUTEBY('id', 'name') */ id, name FROM t1;
SELECT /*+ DISTRIBUTEBY('id1') */ id as id1, name FROM t1;
```

6.12.2 FlinkSQL 窗口函数支持迟到数据

本章节适用于 MRS 3.3.0 及以后版本。

FlinkSQL 新增窗口函数支持迟到数据特性，解决迟到数据需要处理的场景。目前支持 TUMBLE、HOP、OVER、CUMULATE 窗口函数的迟到数据，示例如下：

```
CREATE TABLE T1 (
 `int` INT,
 `double` DOUBLE,
 `float` FLOAT,
 `bigdec` DECIMAL(10, 2),
 `string` STRING,
 `name` STRING,
 `rowtime` TIMESTAMP(3),
 WATERMARK for `rowtime` AS `rowtime` - INTERVAL '1' SECOND
) WITH (
 'connector' = 'values',
);

-- 该 Sink 的字段必须和窗口的输入数据保持一致，但顺序不要求一致
CREATE TABLE LD_SINK(
 `float` FLOAT, `string` STRING, `name` STRING,  `rowtime` TIMESTAMP(3)
) WITH (
 'connector' = 'print',
);

SELECT  /*+ LATE_DATA_SINK('sink.name'='LD_SINK') */
  `name`,
  MIN(`float`),
  COUNT(DISTINCT `string`)
FROM TABLE(
  TUMBLE(TABLE T1, DESCRIPTOR(rowtime), INTERVAL '5' SECOND))
GROUP BY `name`, window_start, window_end
```

该特性还支持窗口接收到迟到数据时输出当前窗口的开始时间和结束时间，可通过添加在 Hint 中'window.start.field'和'window.end.field'使用，字段类型必须是 timestamp，示例如下：

```
CREATE TABLE LD_SINK(
 `float` FLOAT, `string` STRING, `name` STRING,  `rowtime` TIMESTAMP(3),
`windowStart` TIMESTAMP(3), `windowEnd` TIMESTAMP(3)
```

```
) WITH (
 'connector' = 'print',
);

SELECT  /*+ LATE_DATA_SINK('sink.name'='LD_SINK',
'window.start.field'='windowStart', 'window.end.field'='windowEnd') */
  `name`,
  MIN(`float`),
  COUNT(DISTINCT `string`)
FROM TABLE(
  TUMBLE(TABLE T1, DESCRIPTOR(rowtime), INTERVAL '5' SECOND))
GROUP BY `name`, window_start, window_end
```

6.12.3 Flink 多流 Join 配置表级别 TTL

本章节适用于 MRS 3.3.0 及以后版本。

在 Flink 双流 Join 场景下，若 Join 的左表和右表其中一个表数据变化快，需要较短时间的过期时间，而另一个表数据变化较慢，需要较长时间的过期时间。目前 Flink 只有表级别的 TTL（Time To Live：生存时间），为了保证 Join 的准确性，需要将表级别的 TTL 设置为较长时间的过期时间，此时状态后端中保存了大量的已经过期的数据，给状态后端造成了较大的压力。为了减少状态后端的压力，可以单独为左表和右表设置不同的过期时间。不支持 where 子句。

可通过使用 Hint 方式单独为左表和右表设置不同的过期时间，如左表（state.ttl.left）设置 TTL 为 60 秒，右表（state.ttl.right）设置 TTL 为 120 秒：

- Hint 方式格式：

  ```
  /*+ OPTIONS('state.ttl.left'='60S', 'state.ttl.right'='120S') */
  ```

- 在 SQL 语句中配置示例：
  - 示例 1：

    ```
    CREATE TABLE user_info (`user_id` VARCHAR, `user_name` VARCHAR) WITH (
      'connector' = 'kafka',
      'topic' = 'user_info_001',
      'properties.bootstrap.servers' = '192.168.64.138:21005',
      'properties.group.id' = 'testGroup',
      'scan.startup.mode' = 'latest-offset',
      'value.format' = 'csv'
    );
    CREATE table print(
      `user_id` VARCHAR,
      `user_name` VARCHAR,
      `score` INT
    ) WITH ('connector' = 'print');
    CREATE TABLE user_score (user_id VARCHAR, score INT) WITH (
      'connector' = 'kafka',
      'topic' = 'user_score_001',
      'properties.bootstrap.servers' = '192.168.64.138:21005',
      'properties.group.id' = 'testGroup',
      'scan.startup.mode' = 'latest-offset',
      'value.format' = 'csv'
    );
    INSERT INTO
    ```

```
  print
SELECT
  t.user_id,
  t.user_name,
  d.score
FROM
  user_info as t
  JOIN
  -- 为左表和右表设置不同的 TTL 时间
  /*+ OPTIONS('state.ttl.left'='60S', 'state.ttl.right'='120S') */
  user_score as d ON t.user_id = d.user_id;
```

- 示例 2

```
INSERT INTO
  print
SELECT
  t1.user_id,
  t1.user_name,
  t3.score
FROM
  t1
  JOIN
  -- 为左表和右表设置不同的 TTL 时间
  /*+ OPTIONS('state.ttl.left' = '60S', 'state.ttl.right' = '120S') */
  (
    select
      UPPER(t2.user_id) as user_id,
      t2.score
    from
      t2
  ) as t3 ON t1.user_id = t3.user_id;
```

6.12.4 FlinkSQL Client SQL 校验

本章节适用于 MRS 3.3.0 及以后版本。

使用场景

通过 SQL Client 进行 SQL 作业开发时，支持进入校验模式校验 SQL 语法正确性。校验模式下执行 SQL 命令不会启动 Flink job。

使用方法

- 校验 SQL 语句
  - 执行 SQL shell 命令时添加“-v”参数（或“--validate”参数）直接进入校验模式。

    sql-client.sh -v
  - 执行 SQL shell 命令时通过 SET 命令进入或退出校验模式。
    - 进入校验模式：**SET table.validate = true;**
    - 退出校验模式：**SET table.validate = false;**
- 校验 SQL 脚本

当使用“-f”参数指定 SQL 脚本时，可添加“-v”参数进入校验模式。

sql-client.sh -f *test.sql* **-v**

6.12.5 FlinkSQL Client 提交作业

本章节适用于 MRS 3.3.0 及以后版本。

操作场景

本章节提供一个使用 FlinkSQL Client 提交作业的操作入门指导。

前提条件

- MRS 集群中已安装 Flink 组件且集群内各组件正常运行。
- 已安装集群客户端，例如安装目录为“/opt/hadoopclient”。

操作步骤

步骤 1 以客户端安装用户，登录安装客户端的节点。

步骤 2 执行以下命令，切换到客户端安装目录。

cd /opt/hadoopclient

步骤 3 执行如下命令初始化环境变量。

source /opt/hadoopclient/bigdata_env

步骤 4 进入 FlinkSQL Client 并提交作业。

1. 参考 6.1 从零开始使用 Flink 启动 yarn-session，并记录 yarn-session ID（yid）。
   yarn-session.sh -nm "*session-name***"**
2. 执行以下命令进入 FlinkSQL Client。
   cd /opt/hadoopclient/Flink/flink/bin
   ./sql-client.sh

图6-7 进入 FlinkSQL Client

3. 设置“high-availability.cluster-id”为 yarn-session ID。

   SET high-availability.cluster-id=*yarn-session ID***;**

4. 执行以下 SQL 语句，执行成功后控制台显示如下：

   SELECT name, COUNT(*) AS cnt FROM (VALUES ('Bob'), ('Alice'), ('Greg'), ('Bob')) AS NameTable(name) GROUP BY name;

图6-8 执行结果

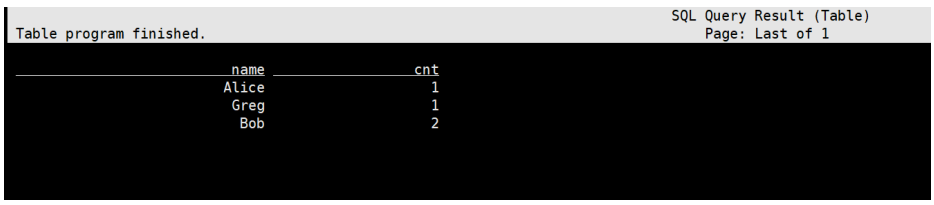

5. 可在 Yarn 上查看执行的任务。

登录 FusionInsight Manager 页面，选择“集群 > 服务 > Yarn > 概览”，单击“ResourceManager WebUI”后面对应的链接，进入 Yarn 的 WebUI 页面，查看对应任务。

图6-9 作业任务

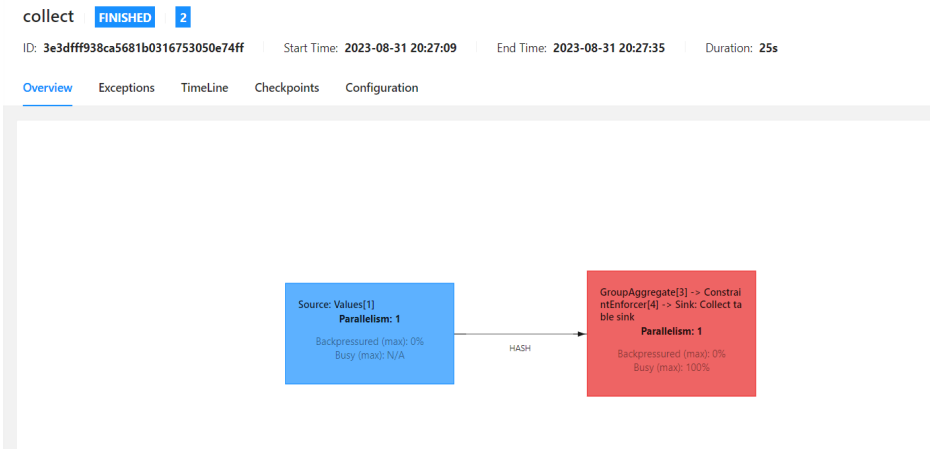

----结束

6.12.6 Flink 作业大小表 Join

本章节适用于 MRS 3.3.0 及以后版本。

使用场景

Flink 作业双流 Join 时存在大小表数据，通过内核 broadcast 策略确保小表数据发送到 Join 的 task 中，通过 rebalance 策略将大表数据打散到 Join 中，提高 Flink SQL 易用性，增强作业稳定性。

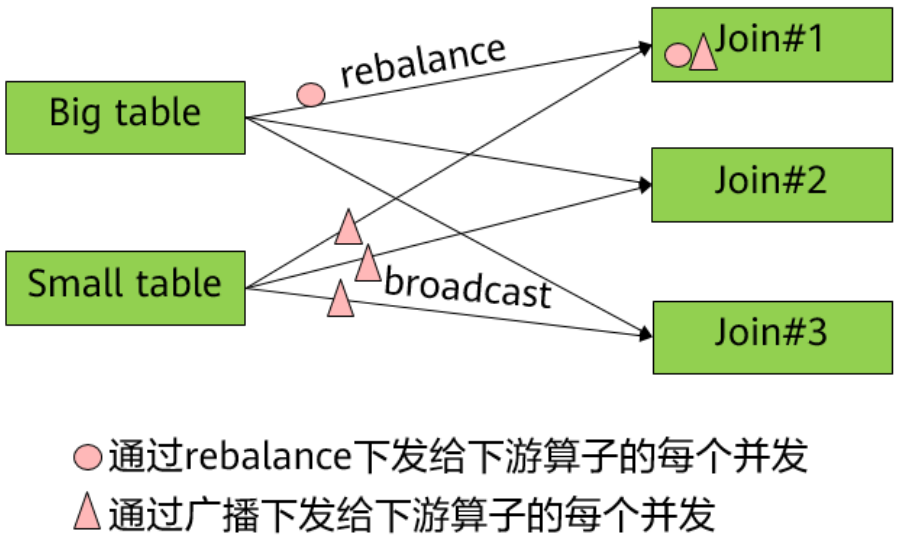

使用方法

在使用 Flink SQL 时，该特性通过 hints 方法指定 Join 的左表或右表为广播表，另一张表为 rebalance 表，SQL 语句实例如下，分别以 A\C 作为小表实例：

- 以 A 表作为广播表
  - 使用 Join 方式

    ```
    SELECT /*+ BROADCAST(A) */ a2, b2 FROM A JOIN B ON a1 = b1
    ```

  - 使用 Where 方式

    ```
    SELECT /*+ BROADCAST(A) */ a2, b2 FROM A, B WHERE a1 = b1
    ```

- 以 A 和 C 表作为广播表

  ```
  SELECT /*+ BROADCAST(A, C) */ a2, b2, c2 FROM A JOIN B ON a1 = b1 JOIN C ON a1 = c1
  ```

说明

- 支持通过“/*+ BROADCAST(smallTable1, smallTable2) */”方式使用该特性，兼容开源双流 Join 逻辑。
- 不支持开源双流 Join 和该特性的切换，因为该特性会将数据广播到每个 Join 算子。
- 不支持 LEFT JOIN 时小表为左表，RIGHT JOIN 时小表为右表。

6.12.7 Flink 作业大小表 Join 去重

本章节适用于 MRS 3.3.0 及以后版本。

在双流关联的业务模型中，关联算子接收到其中一个流发送的大量重复数据，则会导致下游算子需要处理大量重复数据，影响作业性能。

如 A 表字段（P1，A1，A2）使用如下方式关联 B 表字段（P1，B1，B2，B3）生成 C 的场景中，B 表信息发生大量更新，但是 B 中的所需字段没有更新，在该关联中仅用到了 B 表的 B1 和 B2 字段，对于 B 表，每个记录更新只更新 B3 字段，B1 和 B2 不更新，因此当 B 表更新，可以忽略更新后的数据。

```
select  A.A1,B.B1,B.B2 from A join B on A.P1=B.P1
```

为解决如上问题可通过使用 hint 单独为左表（duplicate.left）或右表（duplicate.right）设置去重：

- 格式
  - 为左表设置去重

    ```
    /*+ OPTIONS('duplicate.left'='true')*/
    ```

  - 为右表设置去重

    ```
    /*+ OPTIONS('duplicate.right'='true')*/
    ```

  - 同时为左表和右表设置去重

    ```
    /*+ OPTIONS('duplicate.left'='true','duplicate.right'='true')*/
    ```

- 在 SQL 语句中配置

  如同时为左表“user_info”和右表“user_score”设置去重。

  ```
  CREATE TABLE user_info (`user_id` VARCHAR, `user_name` VARCHAR) WITH (
    'connector' = 'kafka',
    'topic' = 'user_info_001',
  ```

```
  'properties.bootstrap.servers' = '192.168.64.138:21005',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'value.format' = 'csv'
);
CREATE table print(
  `user_id` VARCHAR,
  `user_name` VARCHAR,
  `score` INT
) WITH ('connector' = 'print');
CREATE TABLE user_score (user_id VARCHAR, score INT) WITH (
  'connector' = 'kafka',
  'topic' = 'user_score_001',
  'properties.bootstrap.servers' = '192.168.64.138:21005',
  'properties.group.id' = 'testGroup',
  'scan.startup.mode' = 'latest-offset',
  'value.format' = 'csv'
);
INSERT INTO
  print
SELECT
  t.user_id,
  t.user_name,
  d.score
FROM
  user_info as t
  JOIN
  -- 为左表和右表设置去重
  user_score /*+ OPTIONS('duplicate.left'='true','duplicate.right'='true')*/ as
d ON t.user_id = d.user_id;
```

6.12.8 FlinkSQL 支持设置 Source 的并发

本章节适用于 MRS 3.3.0 及以后版本。

FlinkSQL 支持通过使用参数“source.parallelism”设置 Source 算子的并发数，解决下游算子的并发数引起的一些问题，例如下游算子发送数据倾斜、背压、作业性能慢等问题。

该特性会将 Source 和下游算子的 Forward 分区改为 Rebalance 分区，所以当 Source 算子的并发数和下游算子的并发数（parallelism 数）不一致时，且作业不允许数据乱序，需要在启用该特性的同时开启 DISTRIBUTEBY 特性，可参考 6.12.1 FlinkSQL DISTRIBUTEBY。

如设置 Source 并发数为“2”并开启 DISTRIBUTEBY 特性：

```
CREATE TABLE KafkaSource (
`user_id` VARCHAR,
`user_name` VARCHAR,
 `age` INT
 ) WITH (
 'connector' = 'kafka',
 'topic' = 'test_source',
 'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
 'properties.group.id' = 'testGroup',
```

```
 'scan.startup.mode' = 'latest-offset',
 'format' = 'csv',
 'properties.sasl.kerberos.service.name' = 'kafka',
 'properties.security.protocol' = 'SASL_PLAINTEXT',
 'properties.kerberos.domain.name' = 'hadoop.系统域名',
 -- 设置 Source 并发数
 'source.parallelism' = '2'
 );
CREATE TABLE KafkaSink(
  `user_id` VARCHAR,
  `user_name` VARCHAR,
 `age` INT
 ) WITH (
  'connector' = 'kafka',
  'topic' = 'test_sink',
  'properties.bootstrap.servers' = 'Kafka 的 Broker 实例业务 IP:Kafka 端口号',
  'value.format' = 'csv',
  'properties.sasl.kerberos.service.name' = 'kafka',
   'properties.security.protocol' = 'SASL_PLAINTEXT',
   'properties.kerberos.domain.name' = 'hadoop.系统域名'
 );
-- Insert into KafkaSink select user id, user name, age from KafkaSource;（未开启 DISTRIBUTEBY 特性）
-- 开启 DISTRIBUTEBY 特性
Insert into KafkaSink select/*+ DISTRIBUTEBY('user_id') */ user_id, user_name, age from KafkaSource;
```

7 使用 Flume

7.1 从零开始使用 Flume

操作场景

Flume 支持将采集的日志信息导入到 Kafka。

前提条件

- 已创建开启 Kerberos 认证的包含 Flume、Kafka 等组件的流式集群。
- 已配置网络，使日志生成节点与流集群互通。

使用 Flume 客户端

说明

普通集群不需要执行步骤 2-步骤 6。

步骤 1 安装 Flume 客户端。

可参考 7.3.1 安装 Flume 客户端在日志生成节点安装 Flume 客户端，例如安装目录为“/opt/Flumeclient”。以下操作的客户端目录只是举例，请根据实际安装目录修改。

步骤 2 将 Master1 节点上的认证服务器配置文件，复制到安装 Flume 客户端的节点，保存到 Flume 客户端中 *Flume 客户端安装目录*/fusioninsight-flume-*Flume 组件版本号*/conf 目录下。

文件完整路径为“${BIGDATA_HOME}/FusionInsight_BASE_*XXX*/1_*X*_KerberosClient/etc/kdc.conf”。其中“XXX”为产品版本号，“X”为随机生成的数字，请根据实际情况修改。同时文件需要以 Flume 客户端安装用户身份保存，例如 **root** 用户。

步骤 3 查看任一部署 Flume 角色节点的“业务 IP”。

登录 FusionInsight Manager 页面，选择“集群 > 服务 > Flume > 实例”。查看任一部署 Flume 角色节点的“业务 IP”。

说明

若集群详情页面没有“组件管理”页签，请先完成 IAM 用户同步（在集群详情页的“概览”页签，单击“IAM 用户同步”右侧的“同步”进行 IAM 用户同步）。

步骤 4 将此节点上的用户认证文件，复制到安装 Flume 客户端的节点，保存到 Flume 客户端中“Flume 客户端安装目录/fusioninsight-flume-*Flume 组件版本号*/conf”目录下。

文件完整路径为${BIGDATA_HOME}/FusionInsight_Porter_*XXX*/install/FusionInsight-Flume-*Flume 组件版本号*/flume/conf/flume.keytab。

其中“XXX”为产品版本号，请根据实际情况修改。同时文件需要以 Flume 客户端安装用户身份保存，例如 **root** 用户。

步骤 5 将此节点上的配置文件“jaas.conf”，复制到安装 Flume 客户端的节点，保存到 Flume 客户端中“conf”目录。

文件完整路径为${BIGDATA_HOME}/FusionInsight_Current/1_*X*_Flume/etc/jaas.conf。

其中“X”为随机生成的数字，请根据实际情况修改。同时文件需要以 Flume 客户端安装用户身份保存，例如 **root** 用户。

步骤 6 登录安装 Flume 客户端节点，切换到客户端安装目录，执行以下命令修改文件：

vi conf/jaas.conf

修改参数“keyTab”定义的用户认证文件完整路径即步骤 4 中保存用户认证文件的目录：“Flume 客户端安装目录/fusioninsight-flume-*Flume 组件版本号*/conf”，然后保存并退出。

步骤 7 执行以下命令，修改 Flume 客户端配置文件“flume-env.sh”：

vi *Flume 客户端安装目录*/**fusioninsight-flume-***Flume 组件版本号*/**conf/flume-env.sh**

在“-XX:+UseCMSCompactAtFullCollection”后面，增加以下内容：

```
-Djava.security.krb5.conf=Flume 客户端安装目录/fusioninsight-flume-1.9.0/conf/kdc.conf
-Djava.security.auth.login.config=Flume 客户端安装目录/fusioninsight-flume-
1.9.0/conf/jaas.conf -Dzookeeper.request.timeout=120000
```

例如：**"-XX:+UseCMSCompactAtFullCollection -Djava.security.krb5.conf=/opt/FlumeClient/fusioninsight-flume-***Flume 组件版本号***/conf/kdc.conf -Djava.security.auth.login.config=*/opt/FlumeClient*/fusioninsight-flume-***Flume 组件版本号***/conf/jaas.conf -Dzookeeper.request.timeout=120000"**

请根据实际情况，修改“Flume 客户端安装目录”，然后保存并退出。

步骤 8 执行以下命令，重启 Flume 客户端：

cd *Flume 客户端安装目录*/**fusioninsight-flume-***Flume 组件版本号*/**bin**

./flume-manage.sh restart

例如：

cd /opt/FlumeClient/fusioninsight-flume-*Flume 组件版本号*/**bin**

./flume-manage.sh restart

说明

Flume 客户端停止后会自动重启，如果不需自动重启，请执行以下命令：

./flume-manage.sh stop force

需要启动时，可执行以下命令：

./flume-manage.sh start force

步骤 9 根据实际业务场景配置作业。

- 部分参数可直接在 Manager 界面配置。
- 在“properties.properties”文件中配置，以配置 SpoolDir Source+File Channel+Kafka Sink 为例。

  在安装 Flume 客户端的节点执行以下命令，根据实际业务需求，在 Flume 客户端配置文件“properties.properties”中配置并保存作业。

  vi *Flume 客户端安装目录*/**fusioninsight-flume-***Flume 组件版本号*/**conf/properties.properties**

```
################################################################################
##########
client.sources = static_log_source
client.channels = static_log_channel
client.sinks = kafka_sink
################################################################################
##########
#LOG_TO_HDFS_ONLINE_1

client.sources.static_log_source.type = spooldir
client.sources.static_log_source.spoolDir = 监控目录
client.sources.static_log_source.fileSuffix = .COMPLETED
client.sources.static_log_source.ignorePattern = ^$
client.sources.static_log_source.trackerDir = 传输过程中元数据存储路径
client.sources.static_log_source.maxBlobLength = 16384
client.sources.static_log_source.batchSize = 51200
client.sources.static_log_source.inputCharset = UTF-8
client.sources.static_log_source.deserializer = LINE
client.sources.static_log_source.selector.type = replicating
client.sources.static_log_source.fileHeaderKey = file
client.sources.static_log_source.fileHeader = false
client.sources.static_log_source.basenameHeader = true
client.sources.static_log_source.basenameHeaderKey = basename
client.sources.static_log_source.deletePolicy = never

client.channels.static_log_channel.type = file
client.channels.static_log_channel.dataDirs = 数据缓存路径，设置多个路径可提升性能，
中间用逗号分开
client.channels.static_log_channel.checkpointDir = 检查点存放路径
client.channels.static_log_channel.maxFileSize = 2146435071
client.channels.static_log_channel.capacity = 1000000
client.channels.static_log_channel.transactionCapacity = 612000
client.channels.static_log_channel.minimumRequiredSpace = 524288000

client.sinks.kafka_sink.type = org.apache.flume.sink.kafka.KafkaSink
client.sinks.kafka_sink.kafka.topic = 数据写入的topic，如flume_test
client.sinks.kafka_sink.kafka.bootstrap.servers = XXX.XXX.XXX.XXX:kafka端口
```

```
号,XXX.XXX.XXX.XXX:kafka端口号,XXX.XXX.XXX.XXX:kafka端口号
client.sinks.kafka_sink.flumeBatchSize = 1000
client.sinks.kafka_sink.kafka.producer.type = sync
client.sinks.kafka_sink.kafka.security.protocol = SASL_PLAINTEXT
client.sinks.kafka_sink.kafka.kerberos.domain.name = Kafka Domain名称，安全集群必填，如hadoop.xxx.com
client.sinks.kafka_sink.requiredAcks = 0

client.sources.static_log_source.channels = static_log_channel
client.sinks.kafka_sink.channel = static_log_channel
```

说明

- client.sinks.kafka_sink.kafka.topic：数据写入的 topic。若 kafka 中该 topic 不存在，默认情况下会自动创建该 topic。
- client.sinks.kafka_sink.kafka.bootstrap.servers：Kafkabrokers 列表，多个用英文逗号分隔。默认情况下，安全集群端口 21007，普通集群对应端口 9092。
- client.sinks.kafka_sink.kafka.security.protocol：安全集群为 SASL_PLAINTEXT，普通集群为 PLAINTEXT。
- client.sinks.kafka_sink.kafka.kerberos.domain.name：

  普通集群无需配置此参数。安全集群对应此参数的值为 Kafka 集群中“kerberos.domain.name”对应的值。

  其中 X 为随机生成的数字，请根据实际情况修改。同时文件需要以 Flume 客户端安装用户身份保存，例如 **root** 用户。

  具体可到 Broker 实例所在节点上查看“${BIGDATA_HOME}/FusionInsight_Current/1_X_Broker/etc/server.properties”。

步骤 10 参数配置并保存后，Flume 客户端将自动加载“properties.properties”中配置的内容。当 spoolDir 生成新的日志文件，文件内容将发送到 Kafka 生产者，并支持 Kafka 消费者消费。

----结束

7.2 使用简介

Flume 是一个分布式、可靠和高可用的海量日志聚合的系统。它能够将不同数据源的海量日志数据进行高效收集、聚合、移动，最后存储到一个中心化数据存储系统中。支持在系统中定制各类数据发送方，用于收集数据。同时，提供对数据进行简单处理，并写到各种数据接受方（可定制）的能力。

Flume 分为客户端和服务端，两者都是 FlumeAgent。服务端对应着 FlumeServer 实例，直接部署在集群内部。而客户端部署更灵活，可以部署在集群内部，也可以部署在集群外。它们之间没有必然联系，都可以独立工作，并且提供的功能是一样的。

Flume 客户端需要单独安装，支持将数据直接导到集群中的 HDFS 和 Kafka 等组件上，也可以结合 Flume 服务端一起使用。

使用流程

通过同时利用 Flume 服务端和客户端，构成 Flume 的级联任务，采集日志的流程如下所示。

1. 安装 Flume 客户端。

2. 配置 Flume 服务端和客户端参数。
3. 查看 Flume 客户端收集日志。
4. 停止及卸载 Flume 客户端。

图7-1 Flume 使用流程

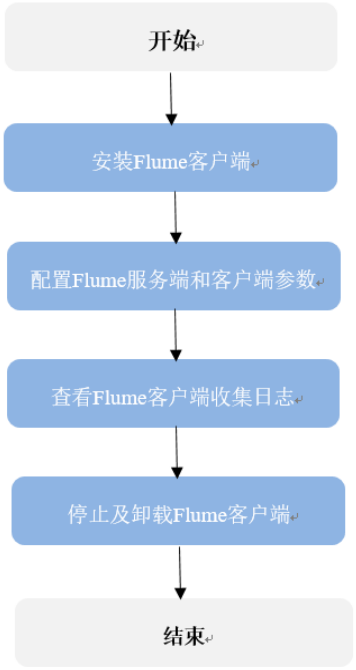

Flume 模块介绍

Flume 客户端/服务端由一个或多个 Agent 组成，而每个 Agent 是由 Source、Channel、Sink 三个模块组成，数据先进入 Source 然后传递到 Channel，最后由 Sink 发送到下一个 Agent 或目的地（客户端外部）。各模块说明见表 7-1。

表7-1 模块说明

名称	说明
Source	Source 负责接收数据或产生数据，并将数据批量放到一个或多个 Channel。Source 有两种类型：数据驱动和轮询。 典型的 Source 样例如下： • 和系统集成并接收数据的 Sources：Syslog、Netcat。 • 自动生成事件数据的 Sources：Exec、SEQ。 • 用于 Agent 和 Agent 之间通信的 IPC Sources：Avro。 Source 必须至少和一个 Channel 关联。
Channel	Channel 位于 Source 和 Sink 之间，用于缓存 Source 传递的数据，当 Sink 成功将数据发送到下一跳的 Channel 或最终数据处理端，缓存数据将自动从 Channel 移除。

名称	说明
	不同类型的 Channel 提供的持久化水平也是不一样的： • Memory Channel：非持久化 • File Channel：基于预写式日志（Write-Ahead Logging，简称 WAL）的持久化实现 • JDBC Channel：基于嵌入 Database 的持久化实现 Channel 支持事务特性，可保证简易的顺序操作，同时可以配合任意数量的 Source 和 Sink 共同工作。
Sink	Sink 负责将数据传输到下一跳或最终目的，成功完成后将数据从 Channel 移除。 典型的 Sink 样例如下： • 存储数据到最终目的终端 Sink，比如：HDFS、Kafka • 自动消耗的 Sinks，比如：Null Sink • 用于 Agent 和 Agent 之间通信的 IPC sink：Avro Sink 必须关联到一个 Channel。

每个 Flume 的 Agent 可以配置多个 Source、Channel、Sink 模块，即一个 Source 将数据发送给多个 Channel，再由多个 Sink 发送到下一个 Agent 或目的地。

Flume 支持多个 Flume 配置级联，即上一个 Agent 的 Sink 将数据再发送给另一个 Agent 的 Source。

Flume 支持多个 Flume 配置级联，即上一个 Agent 的 Sink 将数据再发送给另一个 Agent 的 Source。

补充说明

1. Flume 可靠性保障措施。
   - Source 与 Channel、Channel 与 Sink 之间支持事务机制。
   - Sink Processor 支持配置 failover、load_balance 机制。

     例如 load_balance 示例如下：

     ```
     server.sinkgroups=g1
     server.sinkgroups.g1.sinks=k1 k2
     server.sinkgroups.g1.processor.type=load_balance
     server.sinkgroups.g1.processor.backoff=true
     server.sinkgroups.g1.processor.selector=random
     ```
2. Flume 多客户端聚合级联时的注意事项。
   - 级联时需要走 Avro 或者 Thrift 协议进行级联。
   - 聚合端存在多个节点时，连接配置尽量配置均衡，不要聚合到单节点上。
3. Flume 客户端可以包含多个独立的数据流，即在一个配置文件 properties.properties 中配置多个 Source、Channel、Sink。这些组件可以链接以形成多个流。

   例如在一个配置中配置两个数据流，示例如下：

```
server.sources = source1 source2
server.sinks = sink1 sink2
server.channels = channel1 channel2

#dataflow1
server.sources.source1.channels = channel1
server.sinks.sink1.channel = channel1

#dataflow2
server.sources.source2.channels = channel2
server.sinks.sink2.channel = channel2
```

7.3 安装 Flume 客户端

7.3.1 安装 Flume 客户端

操作场景

使用 Flume 搜集日志时，需要在日志主机上安装 Flume 客户端。用户可以创建一个新的 ECS 并安装 Flume 客户端。

前提条件

- 已创建包含 Flume 组件的集群。
- 日志主机需要与 MRS 集群在相同的 VPC 和子网。
- 已获取日志主机的登录方式。
- 安装目录可以不存在，会自动创建。但如果存在，则必须为空。目录路径不能包含空格。

操作步骤

步骤 1 获取软件包。

登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume”进入 Flume 服务界面，在右上角选择“更多 > 下载客户端”，选择“选择客户端类型”为“完整客户端”，下载 Flume 服务客户端文件。

客户端文件名称为“FusionInsight_Cluster_<*集群 ID*>_Flume_Client.tar”，本章节以“FusionInsight_Cluster_1_Flume_Client.tar”为例进行描述。

步骤 2 上传软件包。

以 **user** 用户将软件包上传到将要安装 Flume 服务客户端的节点目录上，例如“/opt/client”。

说明

user 用户为安装和运行 Flume 客户端的用户。

步骤 3 解压软件包。

以 **user** 用户登录将要安装 Flume 服务客户端的节点。进入安装包所在目录，例如“/opt/client”，执行如下命令解压安装包到当前目录。

cd /opt/client

tar -xvf FusionInsight_Cluster_1_Flume_Client.tar

步骤 4 校验软件包。

执行 **sha256sum -c** 命令校验解压得到的文件，返回“OK”表示校验通过。例如：

sha256sum -c FusionInsight_Cluster_1_Flume_ClientConfig.tar.sha256

```
FusionInsight_Cluster_1_Flume_ClientConfig.tar: OK
```

步骤 5 解压文件。

tar -xvf FusionInsight_Cluster_1_Flume_ClientConfig.tar

步骤 6 若在集群外节点安装 Flume 客户端，需执行如下步骤配置安装环境。在集群内节点安装可不执行该步骤。

1. 执行以下命令，安装客户端运行环境到新的目录，例如“/opt/Flumeenv”。安装时自动生成目录。

   sh /opt/client/FusionInsight_Cluster_1_Flume_ClientConfig/install.sh /opt/Flumeenv

   查看安装输出信息，如有以下结果表示客户端运行环境安装成功：

   ```
   Components client installation is complete.
   ```

2. 执行以下命令，配置环境变量。

   source /opt/Flumeenv/bigdata_env

步骤 7 客户端数量是否为 1。

- 是，采用单独安装模式，执行步骤 8，安装结束。
- 否，采用批量安装模式，执行步骤 9。

步骤 8 在 Flume 客户端安装目录下执行以下命令，安装客户端到指定目录（绝对路径），例如安装到“/opt/FlumeClient”目录。客户端安装成功后单独安装结束。

cd /opt/client/FusionInsight_Cluster_1_Flume_ClientConfig/Flume/FlumeClient

./install.sh -d */opt/FlumeClient* **-f** *MonitorServer 角色的业务 IP 或主机名* **-c** *用户业务配置文件 properties.properties 放置路径* **-s** *cpu 阈值* **-l /var/log/Bigdata -e** *FlumeServer 的业务 IP 或主机名* **-n** *Flume*

说明

- “-d”：Flume 客户端安装路径。
- “-f”（可选）：两个 MonitorServer 角色的业务 IP 或主机名，中间用逗号分隔，若不设置则 Flume 客户端将不向 MonitorServer 发送告警信息，同时在 FusionInsight Manager 界面上看不到该客户端的相关信息。
- “-c”（可选）：指定业务配置文件，该文件需要用户根据自己业务生成，具体操作可在 Flume 服务端中“配置工具”页面生成，并上传到待安装客户端节点上的任一目录下。若安装时未指定（即不配置该参数），可在安装后上传已经生成的业务配置文件 properties.properties 到“/opt/FlumeClient/fusioninsight-flume-1.9.0/conf”目录下。

- “-s”（可选）：Cgroup 阈值，阈值取值范围为 1~100*N 之间的整数，N 表示机器 cpu 核数。默认阈值为“-1”，表示加入到 Cgroup 的进程不受 cpu 使用率限制。
- “-l”（可选）：日志路径，默认值为“/var/log/Bigdata”（“user”用户需要对此目录有写权限）。首次安装客户端会生成名为 flume-client 的子目录，之后安装会依次生成名为“flume-client-*n*”的子目录，n 代表一个序号，从 1 依次递增。在 Flume 客户端安装目录下的 conf 目录中，编辑 ENV_VARS 文件，搜索 FLUME_LOG_DIR 属性，可查看客户端日志路径。
- “-e”（可选）：FlumeServer 的业务 IP 地址或主机名，主要用于接收客户端上报的监控指标信息。
- “-n”（可选）：Flume 客户端的名称，可以通过在 FusionInsight Manager 上选择“集群 > *待操作集群名称* > 服务 > Flume > Flume 管理”查看对应节点上客户端的名称。
- 若产生以下错误提示，可执行命令 **export JAVA_HOME=***JDK 路径*进行处理。可使用 **echo $JAVA_HOME** 查找 JDK 路径。

  ```
  JAVA_HOME is null in current user,please install the JDK and set the JAVA_HOME
  ```

- IBM 的 JDK 不支持“-Xloggc”，需要修改“flume/conf/flume-env.sh”，将“-Xloggc”修改为“-Xverbosegclog”，若 JDK 为 32 位，“-Xmx”不能大于 3.25GB。
- 集群混搭时，安装跨平台客户端时，请进入 /opt/client/FusionInsight_Cluster_1_Flume_ClientConfig/Flume/FusionInsight-Flume-1.9.0.tar.gz 路径下进行 Flume 客户端安装。

步骤 9 进入批量安装客户端目录。

cd /opt/client/FusionInsight_Cluster_1_Flume_ClientConfig/Flume/FlumeClient/batch_install

说明

集群混搭时，安装跨平台客户端时，请进入 /opt/client/FusionInsight_Cluster_1_Flume_ClientConfig/Flume/FusionInsight-Flume-1.9.0.tar.gz 路径下进行 Flume 客户端安装。

步骤 10 配置 host_info.cfg 文件，配置文件格式如下：

host_ip="",user="",password="",install_path="",flume_config_file="",monitor_server_ip="",log_path="",flume_server_ip="",cgroup_threshold="",client_name=""

说明

- host_ip（必填项）：待安装 Flume 客户端的节点 IP。
- user（必填项）：远程登录到待安装 Flume 客户端节点的用户名。
- password（必填项）：远程登录到待安装 Flume 客户端节点密码。配置文件中包含认证密码信息可能存在安全风险，建议当前场景执行完毕后删除相关配置文件或加强安全管理。
- install_path（必填项）：Flume 客户端安装路径。
- flume_config_file（可选）：flume 运行时的配置文件，建议用户在安装时指定该配置文件，如果用户不填写该项，保持该配置项值为""即可，不能删除该配置参数。
- monitor_server_ip（可选）：集群内 Flume 的 MonitorServer 的业务 ip，可在 FusionInsight Manager 上查看，该 ip 有两个，选择其中一个即可，如果不配置，客户端如果进程故障不会发送告警信息到集群内。
- log_path（可选）：Flume 运行时日志保存路径，如果不配置，默认日志打印在“/var/log/Bigdata/flume-client-*索引*/”。索引取值：如果只有一个客户端在此路径下，那么该值为 1，如果有多个，那么索引值在前加 1。
- flume_server_ip（可选）：Flume server 的业务 IP，客户端的指标信息通过该节点上报到集群内，可以在 web 界面上显示该客户端指标信息，如果不配置，客户端指标信息不会显示。

- cgroup_threshold（可选）：Cgroup 阈值，阈值取值范围为 1~100*N 之间的整数，N 表示机器 cpu 核数。默认阈值为“-1”，表示加入到 Cgroup 的进程不受 cpu 使用率限制。
- client_name（可选）：客户端名称，在客户端监控界面上可以显示该客户端名称，如果不配置，该客户端名字显示为空。
- 若需要添加多个节点，格式如下：

  host_ip="ip1",user="user1",password="******",install_path="/tmp/flumeclient",flume_config_file="",monitor_server_ip="xxx.xxx.xxx.xxx",log_path="",flume_server_ip="xxx.xxx.xxx.xxx",cgroup_threshold="",client_name="ip1-client-1"

  host_ip="ip2",user="user1",password="******",install_path="/tmp/flumeclient",flume_config_file="",monitor_server_ip="xxx.xxx.xxx.xxx",log_path="",flume_server_ip="xxx.xxx.xxx.xxx",cgroup_threshold="",client_name="ip2-client-1"

  host_ip="ip3",user="user1",password="******",install_path="/tmp/flumeclient",flume_config_file="",monitor_server_ip="xxx.xxx.xxx.xxx",log_path="",flume_server_ip="xxx.xxx.xxx.xxx",cgroup_threshold="",client_name="ip3-client-1"

步骤 11 执行如下命令批量安装 Flume 客户端。

./batch_install.sh -p /opt/client/FusionInsight_Cluster_1_Flume_Client.tar

步骤 12 删除 host_info.cfg 文件中的密码信息。

批量安装完成后，请立即删除 host_info.cfg 文件中的密码信息，否则会存在密码泄露的风险。

----结束

7.4 查看 Flume 客户端日志

操作场景

查看日志以便定位问题。

前提条件

Flume 客户端已经正确安装。

操作步骤

步骤 1 进入 Flume 客户端日志目录，默认为“/var/log/Bigdata”。

步骤 2 执行如下命令查看日志文件列表。

ls -lR flume-client-*

日志文件示例如下：

```
flume-client-1/flume:
total 7672
-rw-------. 1 root root      0 Sep  8 19:43 Flume-audit.log
-rw-------. 1 root root 1562037 Sep 11 06:05 FlumeClient.2017-09-11_04-05-
09.[1].log.zip
-rw-------. 1 root root 6127274 Sep 11 14:47 FlumeClient.log
-rw-------. 1 root root   2935 Sep  8 22:20 flume-root-20170908202009-pid72456-
```

```
gc.log.0.current
-rw-------. 1 root root   2935 Sep  8 22:27 flume-root-20170908202634-pid78789-
gc.log.0.current
-rw-------. 1 root root   4382 Sep  8 22:47 flume-root-20170908203137-pid84925-
gc.log.0.current
-rw-------. 1 root root   4390 Sep  8 23:46 flume-root-20170908204918-pid103920-
gc.log.0.current
-rw-------. 1 root root   3196 Sep  9 10:12 flume-root-20170908215351-pid44372-
gc.log.0.current
-rw-------. 1 root root   2935 Sep  9 10:13 flume-root-20170909101233-pid55119-
gc.log.0.current
-rw-------. 1 root root   6441 Sep  9 11:10 flume-root-20170909101631-pid59301-
gc.log.0.current
-rw-------. 1 root root      0 Sep  9 11:10 flume-root-20170909111009-pid119477-
gc.log.0.current
-rw-------. 1 root root  92896 Sep 11 13:24 flume-root-20170909111126-pid120689-
gc.log.0.current
-rw-------. 1 root root   5588 Sep 11 14:46 flume-root-20170911132445-pid42259-
gc.log.0.current
-rw-------. 1 root root   2576 Sep 11 13:24 prestartDetail.log
-rw-------. 1 root root   3303 Sep 11 13:24 startDetail.log
-rw-------. 1 root root   1253 Sep 11 13:24 stopDetail.log

flume-client-1/monitor:
total 8
-rw-------. 1 root root  141 Sep  8 19:43 flumeMonitorChecker.log
-rw-------. 1 root root 2946 Sep 11 13:24 flumeMonitor.log
```

其中 **FlumeClient.log** 即为 Flume 客户端的运行日志。

----结束

7.5 停止或卸载 Flume 客户端

操作场景

指导运维工程师停止、启动 Flume 客户端，以及在不需要 Flume 数据采集通道时，卸载 Flume 客户端。

操作步骤

- 停止 Flume 角色的客户端。

  假设 Flume 客户端安装路径为“/opt/FlumeClient”，执行以下命令，停止 Flume 客户端：

  cd /opt/FlumeClient/fusioninsight-flume-*Flume 组件版本号*/bin

  ./flume-manage.sh stop

  执行脚本后，显示如下信息，说明成功的停止了 Flume 客户端：

  ```
  Stop Flume PID=120689 successful..
  ```

说明

Flume 客户端停止后会自动重启，如果不需自动重启，请执行以下命令：

./flume-manage.sh stop force

需要启动时，可执行以下命令：

./flume-manage.sh start force

- 卸载 Flume 角色的客户端。

  假设 Flume 客户端安装路径为“/opt/FlumeClient”，执行以下命令，卸载 Flume 客户端：

  cd /opt/FlumeClient/fusioninsight-flume-*Flume 组件版本号*/inst

  ./uninstall.sh

7.6 使用 Flume 客户端加密工具

操作场景

安装 Flume 客户端后，配置文件的部分参数可能需要填写加密的字符，Flume 客户端中提供了加密工具。

前提条件

已完成客户端安装。

操作步骤

步骤 1 登录安装 Flume 客户端的节点，并切换到客户端安装目录。例如“/opt/FlumeClient”。

步骤 2 切换到以下目录

cd fusioninsight-flume-*Flume 组件版本号*/bin

步骤 3 执行以下命令，加密原始信息：

./genPwFile.sh

输入两次待加密信息。

步骤 4 执行以下命令，查看加密后的信息：

cat password.property

说明

如果加密参数是用于 Flume Server，那么需要到相应的 Flume Server 所在节点执行加密。需要使用 omm 用户执行加密脚本进行加密。

加密路径为“/opt/Bigdata/FusionInsight_Porter_XXX/install/FusionInsight-Flume-*Flume 组件版本号*/flume/bin/genPwFile.sh”。其中 XXX 为产品的版本号。

----结束

7.7 Flume 业务配置指南

该操作指导用户完成 Flume 常用业务的配置。

说明

- 各个表格中所示参数，黑体加粗的参数为必选参数。
- Sink 的 BatchSize 参数必须小于 Channel 的 transactionCapacity。
- 集群 Flume 配置工具界面篇幅有限，Source、Channel、Sink 只展示部分参数，详细请参考如下常用配置。
- 集群 Flume 配置工具界面上所展示 Customer Source、Customer Channel 及 Customer Sink 需要用户根据自己开发的代码来进行配置，下述常用配置不再展示。

常用 Source 配置

- **Avro Source**

  Avro Source 监测 Avro 端口，接收外部 Avro 客户端数据并放入配置的 Channel 中。常用配置如下表所示：

表7-2 Avro Source 常用配置

参数	默认值	描述
channels	-	与之相连的 channel，可以配置多个。
type	avro	avro source 的类型，必须为 avro。
bind	-	监测主机名/IP。
port	-	绑定监测端口，该端口需未被占用。
threads	-	source 工作的最大线程数。
compression-type	none	消息压缩格式：“none”或“deflate”。“none”表示不压缩，“deflate”表示压缩。
compression-level	6	数据压缩级别（1-9），数值越高，压缩率越高。
ssl	false	是否使用 SSL 加密。设置为 true 时还必须指定“密钥(keystore)”和“密钥存储密码(keystore-password)”。
truststore-type	JKS	Java 信任库类型，“JKS”或“PKCS12”。

参数	默认值	描述
		说明 JKS 的密钥库和私钥采用不同的密码进行保护，而 PKCS12 的密钥库和私钥采用相同密码进行保护。
truststore	-	Java 信任库文件。
truststore-password	-	Java 信任库密码。
keystore-type	JKS	ssl 启用后密钥存储类型，“JKS”或“PKCS12”。 说明 JKS 的密钥库和私钥用不同的密码进行保护，而 PKCS12 的密钥库和私钥用相同密码进行保护。
keystore	-	ssl 启用后密钥存储文件路径，开启 ssl 后，该参数必填。
keystore-password	-	ssl 启用后密钥存储密码，开启 ssl 后，该参数必填。
trust-all-certs	false	是否关闭 SSL server 证书检查。设置为“true”时将不会检查远端 source 的 SSL server 证书，不建议在生产中使用。
exclude-protocols	SSLv3	排除的协议列表，用空格分开。默认排除 SSLv3 协议。
ipFilter	false	是否开启 ip 过滤。
ipFilter.rules	-	定义 N 网络的 ipFilters，多个主机或 IP 地址用逗号分割。ipFilter 设置为“true”时，配置规则有允许和禁止两种，配置格式如下： ipFilterRules=allow:ip:127.*, allow:name:localhost, deny:ip:*

- **SpoolDir Source**

Spool Dir Source 监控并传输目录下新增的文件，可实现实时数据传输。常用配置如下表所示：

表7-3 Spooling Directory Source 常用配置

参数	默认值	描述
channels	-	与之相连的 channel，可以配置多个。
type	spooldir	spooling source 的类型，必须设置为 spooldir。
spoolDir	-	Spooldir source 的监控目录，flume 运行用户需要对该目录具有可读可写可执行权限。
monTime	0（不开启）	线程监控阈值，更新时间超过阈值后，重新启动该 Source，单位：秒。
fileSuffix	.COMPLETED	文件传输完成后添加的后缀。
deletePolicy	never	文件传输完成后源文件删除策略，never 或 immediate。“never”表示不删除已完成传输的源文件，“immediate”表示传输完成后立刻删除源文件。
ignorePattern	^$	忽略文件的正则表达式表示。默认为“^$”，表示忽略空格。
includePattern	^.*$	包含文件的正则表达式表示。可以与 ignorePattern 同时使用，如果一个文件既满足 ignorePattern 也满足 includePattern，则该文件会被忽略。另外，以“.”开头的文件不会被过滤。
trackerDir	.flumespool	传输过程中元数据存储路径。
batchSize	1000	批次写入 Channel 的 Event 数量。
decodeErrorPolicy	FAIL	编码错误策略。 **说明** 如果文件中有编码错误，请配置“decodeErrorPolicy”为“REPLACE”或“IGNORE”，Flume 遇到编码错误将跳过编码错误，继续采集后续日志。
deserializer	LINE	文件解析器，值为“LINE”或“BufferedLine”。 • 配置为“LINE”时，对从文件读取的字符逐个转码。 • 配置为“BufferedLine”时，对文件读取的一行或多行的字符进行批量转码，性能更优。
deserializer.maxLineLength	2048	按行解析最大长度。
deserializer.maxBa	1	按行解析最多行数，如果行数设置为多行，

参数	默认值	描述
tchLine		maxLineLength 也应该设置为相应的倍数。 说明 用户设置 Interceptor 时，需要考虑多行合并后的场景，否则会造成数据丢失。如果 Interceptor 无法处理多行合并场景，请将该配置设置为 1。
selector.type	replicating	选择器类型，“replicating”或“multiplexing”。“replicating”表示将数据复制多份，分别传递给每一个 channel，每个 channel 接收到的数据都是相同的，而“multiplexing”表示根据 event 中 header 的 value 来选择特定的 channel，每个 channel 中的数据是不同的。
interceptors	-	拦截器。多个拦截器用空格分开。
inputCharset	UTF-8	读取文件的编码格式。须与读取数据源文件编码格式相同，否则字符解析可能会出错。
fileHeader	false	是否把文件名（包含路径）添加到 event 的 header 中。
fileHeaderKey	-	设置 header 中数据存储结构为<key,value>模式，需要 fileHeaderKey 与 fileHeader 配合使用。若 fileHeader 设置为 true，可参考如下示例。 示例：将 fileHeaderKey 定义为 file，当读取到文件名为/root/a.txt 的内容时，header 中以 file=/root/a.txt 的形式存在。
basenameHeader	false	是否把文件名（不包含路径）添加到 event 的 header 中。
basenameHeaderKey	-	设置 header 中数据存储结构为<key,value>模式，需要 basenameHeaderKey 与 basenameHeader 配合使用。若 basenameHeader 设置为 true，可参考如下示例。 示例：将 basenameHeaderKey 定义为 file，当读取到文件名为 a.txt 的内容时，header 中以 file=a.txt 的形式存在。
pollDelay	500	轮询监控目录下新文件时的时延。单位：毫秒。
recursiveDirectorySearch	false	是否监控配置的目录下子目录中的新文件。
consumeOrder	oldest	监控目录下文件的消耗次序。如果配置为 oldest 或者 youngest，会根据监控目录下文件的最后修改时间来决定，当目录下有大量文件时，会消耗较长时间去寻找 oldest 或者 youngest 的文件。需要注意的是，如果配置为 random，创建比较早的文件有可能长时间未被读取。如果配置为 oldest

参数	默认值	描述
		或者 youngest，那么进程会需要较多时间来查找最新的或最旧的文件。可选值：random，youngest，oldest。
maxBackoff	4000	当 Channel 满了以后，尝试再次去写 Channel 所等待的最大时间。超过这个时间，则会抛出异常。对应的 Source 会以一个较小的时间开始，然后每尝试一次，该时间数字指数增长直到达到当前指定的值，如果还不能成功写入，则认为失败。时间单位：秒。
emptyFileEvent	true	是否采集空文件信息发送到 Sink 端，默认值为 true，表示将空文件信息发送到 Sink 端。该参数只对 HDFS Sink 有效，其他 Sink 该参数无效。以 HDFS Sink 为例，当参数为 true 时，如果 spoolDir 路径下存在空文件，那么 HDFS 的 hdfs.path 路径下就会创建一个同名的空文件。

说明

SpoolDir Source 在按行读取过程中会忽略掉每一个 event 的最后一个换行符，该换行符所占用的数据量指标不会被 Flume 统计。

- **Kafka Source**

  Kafka Source 从 Kafka 的 topic 中消费数据，可以设置多个 Source 消费同一个 topic 的数据，每个 Source 会消费 topic 的不同 partitions。常用配置如下表所示：

表7-4 Kafka Source 常用配置

参数	默认值	描述
channels	-	与之相连的 channel，可以配置多个。
type	org.apache.flume.source.kafka.KafkaSource	kafka source 的类型，必须设置为 org.apache.flume.source.kafka.KafkaSource。
kafka.bootstrap.servers	-	Kafka 的 bootstrap 地址端口列表。如果集群已安装 Kafka 并且配置已经同步，服务端可以不配置此项，默认值为 Kafka 集群中所有的 broker 列表。客户端必须配置该项，多个值用逗号分隔。端口和安全协议的匹配规则必须为：21007 匹配安全模式（SASL_PLAINTEXT），9092 匹配普通模式（PLAINTEXT）。
kafka.topics	-	订阅的 Kafka topic 列表，用逗号分隔。

参数	默认值	描述
kafka.topics.regex	-	符合正则表达式的 topic 会被订阅，优先级高于“kafka.topics”，如果存在将覆盖“kafka.topics”。
monTime	0（不开启）	线程监控阈值，更新时间超过阈值后，重新启动该 Source，单位：秒。
nodatatime	0（不开启）	告警阈值，从 Kafka 中订阅不到数据的时长超过阈值时发送告警，单位：秒。该参数可在配置文件 properties.properties 进行设置。
batchSize	1000	批次写入 Channel 的 Event 数量。
batchDurationMillis	1000	批次消费 topic 数据的最大时长，单位：ms。
keepTopicInHeader	false	是否在 Event Header 中保存 topic。设置为 true，则 Kafka Sink 配置的 topic 将无效。
setTopicHeader	true	当设置为 true 时，会将“topicHeader”中定义的 topic 名称存储到 Header 中。
topicHeader	topic	当 setTopicHeader 属性设置为 true，此参数用于定义存储接收的 topic 名称。如果与 Kafka Sink 的 topicHeader 属性结合使用，应该注意，避免将消息循环发送到同一主题。
useFlumeEventFormat	false	默认情况下，event 会以字节的形式从 kafka topic 传递到 event 的 body 体中。设置为 true，则会以 Flume 的 Avro 二进制格式来读取 Event。与 KafkaSink 或 KakfaChannel 中同名的 parseAsFlumeEvent 参数一起使用时，会保留从数据源产生的任何设定的 Header。
keepPartitionInHeader	false	是否在 Event Header 中保存 partitionID。设置为 true，则 Kafka Sink 将写入对应的 Partition。
kafka.consumer.group.id	flume	Kafka 消费组 ID。多个源或代理中设置相同的 ID 表示它们是同一个 consumer group。
kafka.security.protocol	SASL_PLAINTEXT	Kafka 安全协议，普通模式集群下须配置为“PLAINTEXT”。端口和安全协议的匹配规则必须为：21007 匹配安全模式（SASL_PLAINTEXT），9092 匹

参数	默认值	描述
		配普通模式（PLAINTEXT）。
Other Kafka Consumer Properties	-	其他 Kafka 配置，可以接受任意 Kafka 支持的消费配置，配置需要加前缀“kafka.”。

- **Taildir Source**

  Taildir Source 监控目录下文件的变化并自动读取文件内容，可实现实时数据传输，常用配置如下表所示：

表7-5 Taildir Source 常用配置

参数	默认值	描述
channels	-	与之相连的 channel，可以配置多个。
type	TAILDIR	taildir source 的类型，必须为 TAILDIR。
filegroups	-	设置采集文件目录分组名字，分组名字中间使用空格间隔。
filegroups.<filegroupName>	-	文件路径，需要配置为绝对路径。
filegroups.<filegroupName>.parentDir	-	父目录，需要配置为绝对路径。
filegroups.<filegroupName>.filePattern	-	相对父目录的文件路径，可以包含目录，支持正则表达式，须与父目录联合使用。
positionFile	-	传输过程中元数据存储路径。
headers.<filegroupName>.<headerKey>	-	设置某一个分组采集数据时 event 中的 key-value 值。
byteOffsetHeader	false	是否在每一个 event 头中携带该 event 在源文件中的位置信息。设置为 true，则该信息保存在 byteoffset 变量中。
maxBatchCount	Long.MAX_VALUE	控制从一个文件中连续读取的最大批次。如果监控目录会一直读取多个文件，且其中一个文件以非常快的速率在写入，那么其他文件可能会无法处理。因为高速写入的这个文件会陷入无限读取的循环中。这种情况下，应该降低此值。
skipToEnd	false	Flume 在重启后是否直接定位到文件最新的位置处读取最新的数据。设置为 true，则重启后直接定位到文件最新位置读取最新数据。

参数	默认值	描述
idleTimeout	120000	设置读取文件的空闲时间，单位：毫秒，如果在该时间内文件内容没有变更，关闭掉该文件，关闭后如果该文件有数据写入，重新打开并读取数据。
writePosInterval	3000	设置将元数据写入到文件的周期，单位：毫秒。
batchSize	1000	批次写入 Channel 的 Event 数量。
monTime	0（不开启）	线程监控阈值，更新时间超过阈值后，重新启动该 Source，单位：秒。
fileHeader	false	是否把文件名（包含路径）添加到 event 的 header 中。
fileHeaderKey	file	设置 header 中数据存储结构为<key,value>模式，需要 fileHeaderKey 与 fileHeader 配合使用。若 fileHeader 设置为 true，可参考如下示例。 示例：将 fileHeaderKey 定义为 file，当读取到文件名为/root/a.txt 的内容时，header 中以 file=/root/a.txt 的形式存在。

- **Http Source**

  Http Source 接收外部 HTTP 客户端发送过来的数据，并放入配置的 Channel 中，常用配置如下表所示：

表7-6 Http Source 常用配置

参数	默认值	描述
channels	-	与之相连的 channel，可以配置多个。
type	http	http source 的类型，必须为 http。
bind	-	监测主机名/IP。
port	-	绑定监测端口，该端口需未被占用。
handler	org.apache.flume.source.http.JSONHandler	http 请求的消息解析方式，支持 Json 格式解析（org.apache.flume.source.http.JSONHandler）和二进制 Blob 块解析（org.apache.flume.sink.solr.morphline.BlobHandler）。
handler.*	-	设置 handler 的参数。

参数	默认值	描述
exclude-protocols	SSLv3	排除的协议列表，用空格分开。默认排除 SSLv3 协议。
include-cipher-suites	-	包含的协议列表，用空格分开。如果设置为空，则默认支持所有协议。
enableSSL	false	http 协议是否启用 SSL。设置为 true 时还必须指定“密钥(keystore)”和“密钥存储密码(keystore-password)”。
keystore-type	JKS	Keystore 类型，可以为 JKS 或者 PKCS12。
keystore	-	http 启用 SSL 后设置 keystore 的路径。
keystorePassword	-	http 启用 SSL 后设置 keystore 的密码。

- **Thrift Source**

  Thrift Source 监测 thrift 端口，接收外部 Thrift 客户端数据并放入配置的 Channel 中。常用配置如下表所示：

参数	默认值	描述
channels	-	与之相连的 channel，可以配置多个。
type	thrift	thrift source 的类型，必须设置为 thrift。
bind	-	监测主机名/IP。
port	-	绑定监测端口，该端口需未被占用。
threads	-	允许运行的最大的 worker 线程数目。
kerberos	false	是否启用 Kerberos 认证。
agent-keytab	-	服务端使用的 keytab 文件地址，必须使用机机账号。建议使用 Flume 服务安装目录下 flume/conf/flume_server.keytab。
agent-principal	-	服务端使用的安全用户的 Principal，必须使用机机账户。建议使用 Flume 服务默认用户 flume_server/hadoop.*<系统域名>@<系统域名>* **说明** “flume_server/hadoop.*<系统域名>*”为用户名，用户的用户名所包含的系统域名所有字母为小写。例如“本端域”参数为“9427068F-6EFA-4833-B43E-60CB641E5B6C.COM”，用户名为“flume_server/hadoop.9427068f-6efa-4833-b43e-60cb641e5b6c.com”。

参数	默认值	描述
compression-type	none	消息压缩格式：“none”或“deflate”。“none”表示不压缩，“deflate”表示压缩。
ssl	false	是否使用 SSL 加密。设置为 true 时还必须指定“密钥(keystore)”和“密钥存储密码(keystore-password)”。
keystore-type	JKS	SSL 启用后密钥存储类型。
keystore	-	SSL 启用后密钥存储文件路径，开启 SSL 后，该参数必填。
keystore-password	-	SSL 启用后密钥存储密码，开启 ssl 后，该参数必填。
truststore-type	JKS	Java 信任库类型，“JKS”或“PKCS12”。 说明 JKS 的密钥库和私钥采用不同的密码进行保护，而 PKCS12 的密钥库和私钥采用相同密码进行保护。
truststore	-	Java 信任库文件。
truststore-password	-	Java 信任库密码。

常用 Channel 配置

- **Memory Channel**

  Memory Channel 使用内存作为缓存区，Events 存放在内存队列中。常用配置如下表所示：

表7-7 Memory Channel 常用配置

参数	默认值	描述
type	-	memory channel 的类型，必须设置为 memory。
capacity	10000	缓存在 channel 中的最大 Event 数。
transactionCapacity	1000	每次存取的最大 Event 数。 说明 • 此参数值需要大于 source 和 sink 的 batchSize。 • 事务缓存容量必须小于或等于 Channel 缓存容量。
channelfullcount	10	channel full 次数，达到该

参数	默认值	描述
		次数后发送告警。
keep-alive	3	当事务缓存或 Channel 缓存满时，Put、Take 线程等待时间。单位：秒。
byteCapacity	JVM 最大内存的 80%	channel 中最多能容纳所有 event body 的总字节数，默认是 JVM 最大可用内存（-Xmx ）的 80%，单位：bytes。
byteCapacityBufferPercentage	20	channel 中字节容量百分比（%）。

- **File Channel**

  File Channel 使用本地磁盘作为缓存区，Events 存放在设置的 dataDirs 配置项文件夹中。常用配置如下表所示：

表7-8 File Channel 常用配置

参数	默认值	描述
type	-	file channel 的类型，必须设置为 file。
checkpointDir	${BIGDATA_DATA_HOME}/hadoop/data1~N/flume/checkpoint 说明 此路径随自定义数据路径变更。	检查点存放路径。
dataDirs	${BIGDATA_DATA_HOME}/hadoop/data1~N/flume/data 说明 此路径随自定义数据路径变更。	数据缓存路径，设置多个路径可提升性能，中间用逗号分开。
maxFileSize	2146435071	单个缓存文件的最大值，单位：bytes。
minimumRequiredSpace	524288000	缓冲区空闲空间最小值，单位：bytes。
capacity	1000000	缓存在 channel 中的最大 Event 数。
transactionCapacity	10000	每次存取的最大 Event 数。 说明 • 此参数值需要大于

参数	默认值	描述
		source 和 sink 的 batchSize。 • 事务缓存容量必须小于或等于 Channel 缓存容量。
channelfullcount	10	channel full 次数，达到该次数后发送告警。
useDualCheckpoints	false	是否备份检查点。设置为“true”时，必须设置 backupCheckpointDir 的参数值。
backupCheckpointDir	-	备份检查点路径。
checkpointInterval	30000	检查点间隔时间，单位：秒。
keep-alive	3	当事务缓存或 Channel 缓存满时，Put、Take 线程等待时间。单位：秒。
use-log-replay-v1	false	是否启用旧的回复逻辑。
use-fast-replay	false	是否使用队列回复。
checkpointOnClose	true	channel 关闭时是否创建检查点。

- **Memory File Channel**

  Memory File Channel 同时使用内存和本地磁盘作为缓存区，消息可持久化，性能优于 File Channel，接近 Memory Channel 的性能。此 Channel 目前处于试验阶段，可靠性不够高，不建议在生产环境使用。常用配置如下表所示：

表7-9 Memory File Channel 常用配置

参数	默认值	描述
type	org.apache.flume.channel.MemoryFileChannel	memory file channel 的类型，必须设置为“org.apache.flume.channel.MemoryFileChannel”。
capacity	50000	Channel 缓存容量：缓存在 Channel 中的最大 Event 数。
transactionCapacity	5000	事务缓存容量：一次事务能处理的最大 Event 数。 说明

参数	默认值	描述
		• 此参数值需要大于 source 和 sink 的 batchSize。 • 事务缓存容量必须小于或等于 Channel 缓存容量。
subqueueByteCapacity	20971520	每个 subqueue 最多保存多少 byte 的 Event，单位：byte。 Memory File Channel 采用 queue 和 subqueue 两级缓存，event 保存在 subqueue，subqueue 保存在 queue。 subqueue 能保存多少 event，由“subqueueCapacity”和“subqueueInterval”两个参数决定，“subqueueCapacity”限制 subqueue 内的 Event 总容量，“subqueueInterval”限制 subqueue 保存 Event 的时长，只有 subqueue 达到“subqueueCapacity”或“subqueueInterval”上限时，subqueue 内的 Event 才会发往目的地。 **说明** “subqueueByteCapacity”必须大于一个 batchsize 内的 Event 总容量。
subqueueInterval	2000	每个 subqueue 最多保存一段多长时间的 Event，单位：毫秒。
keep-alive	3	当事务缓存或 Channel 缓存满时，Put、Take 线程等待时间。 单位：秒。
dataDir	-	缓存本地文件存储目录。
byteCapacity	JVM 最大内存的 80%	Channel 缓存容量。 单位：bytes。
compression-type	None	消息压缩格式：“none”或“deflate”。“none”表示不压缩，“deflate”表示压缩。
channelfullcount	10	channel full 次数，达到该次数后发送告警。

Memory File Channel 配置样例：

```
server.channels.c1.type = org.apache.flume.channel.MemoryFileChannel
server.channels.c1.dataDir = /opt/flume/mfdata
server.channels.c1.subqueueByteCapacity = 20971520
server.channels.c1.subqueueInterval=2000
server.channels.c1.capacity = 500000
server.channels.c1.transactionCapacity = 40000
```

- **Kafka Channel**

  Kafka Channel 使用 Kafka 集群缓存数据，Kafka 提供高可用、多副本，以防 Flume 或 Kafka Broker 崩溃，Channel 中的数据会立即被 Sink 消费。

表7-10 Kafka channel 常用配置

Parameter	Default Value	Description
type	-	kafka channel 的类型，必须设置为“org.apache.flume.channel.kafka.KafkaChannel”。
kafka.bootstrap.servers	-	Kafka 的 bootstrap 地址端口列表。 如果集群已安装 Kafka 并且配置已经同步，则服务端可以不配置此项，默认值为 Kafka 集群中所有的 broker 列表。客户端必须配置该项，多个值用逗号分隔。端口和安全协议的匹配规则必须为：21007 匹配安全模式（SASL_PLAINTEXT），9092 匹配普通模式（PLAINTEXT）。
kafka.topic	flume-channel	channel 用来缓存数据的 topic。
kafka.consumer.group.id	flume	从 kafka 中获取数据的组标识，此参数不能为空。
parseAsFlumeEvent	true	是否解析为 Flume event。
migrateZookeeperOffsets	true	当 Kafka 没有存储 offset 时，是否从 ZooKeeper 中查找，并提交到 Kafka。
kafka.consumer.auto.offset.reset	latest	当没有 offset 记录时从什么位置消费，可选为“earliest”、“latest”或“none”。“earliest”表示将 offset 重置为初始点，“latest”表示将 offset 置为最新位置点，“none”表示若没有 offset 则抛出异常。
kafka.producer.security.prot	SASL_PLAINTEXT	Kafka 生产安全协议。端

Parameter	Default Value	Description
ocol		口和安全协议的匹配规则必须为：21007 匹配安全模式（SASL_PLAINTEXT），9092 匹配普通模式（PLAINTEXT）。 说明 若该参数没有显示，请单击弹窗左下角的"+"显示全部参数。
kafka.consumer.security.protocol	SASL_PLAINTEXT	同上，但用于消费。端口和安全协议的匹配规则必须为：21007 匹配安全模式（SASL_PLAINTEXT），9092 匹配普通模式（PLAINTEXT）。
pollTimeout	500	consumer 调用 poll()函数能接受的最大超时时间，单位：毫秒。
ignoreLongMessage	false	是否丢弃超大消息。
messageMaxLength	1000012	Flume 写入 Kafka 的消息的最大长度。

常用 Sink 配置

- **HDFS Sink**

  HDFS Sink 将数据写入 Hadoop 分布式文件系统（HDFS）。常用配置如下表所示：

表7-11 HDFS Sink 常用配置

参数	默认值	描述
channel	-	与之相连的 channel。
type	hdfs	hdfs sink 的类型，必须设置为 hdfs。
hdfs.path	-	HDFS 上数据存储路径，必须以“hdfs://hacluster/”开头。
monTime	0（不开启）	线程监控阈值，更新时间超过阈值后，重新启动该 Sink，单位：秒。
hdfs.inUseSuffix	.tmp	正在写入的 hdfs 文件后缀。

参数	默认值	描述
hdfs.rollInterval	30	按时间滚动文件，单位：秒，同时需将“hdfs.fileCloseByEndEvent”设置为“false”。
hdfs.rollSize	1024	按大小滚动文件，单位：bytes，同时需将“hdfs.fileCloseByEndEvent”设置为“false”。
hdfs.rollCount	10	按 Event 个数滚动文件，同时需将“hdfs.fileCloseByEndEvent”设置为“false”。 **说明** 参数“rollInterval”、“rollSize”和“rollCount”可同时配置，三个参数采取优先原则，哪个参数值先满足，优先按照哪个参数进行压缩。
hdfs.idleTimeout	0	自动关闭空闲文件超时时间，单位：秒。
hdfs.batchSize	1000	批次写入 HDFS 的 Event 个数。
hdfs.kerberosPrincipal	-	认证 HDFS 的 Kerberos principal，普通模式集群不配置，安全模式集群必须配置。
hdfs.kerberosKeytab	-	认证 HDFS 的 Kerberos keytab，普通模式集群不配置，安全模式集群中，用户必须对 jaas.cof 文件中的 keyTab 路径有访问权限。
hdfs.fileCloseByEndEvent	true	收到源文件的最后一个 Event 时是否关闭 hdfs 文件。
hdfs.batchCallTimeout	-	批次写入 HDFS 超时控制时间，单位：毫秒。 当不配置此参数时，对每个 Event 写入 HDFS 进行超时控制。当“hdfs.batchSize”大于 0 时，配置此参数可以提升写入 HDFS 性能。 **说明** “hdfs.batchCallTimeout”设置多长时间需要考虑“hdfs.batchSize”的大小，“hdfs.batchSize”越大，“hdfs.batchCallTimeout”也要调整更长时间，设置过短时间容易导致写 HDFS 失败。
serializer.appendNewline	true	将一个 Event 写入 HDFS 后是否追加换行符（'\n'），如果追加该换行符，该换行符所占用的数据量指标不会被 HDFS Sink 统计。
hdfs.filePrefix	over_%{basename}	数据写入 hdfs 后文件名的前缀。
hdfs.fileSuffix	-	数据写入 hdfs 后文件名的后缀。

参数	默认值	描述
hdfs.inUsePrefix	-	正在写入的 hdfs 文件前缀。
hdfs.fileType	DataStream	hdfs 文件格式，包括“SequenceFile”、“DataStream”以及“CompressedStream”。 **说明** “SequenceFile”和“DataStream”不压缩输出文件，不能设置参数“codeC”，“CompressedStream”压缩输出文件，必须设置“codeC”参数值配合使用。
hdfs.codeC	-	文件压缩格式，包括 gzip、bzip2、lzo、lzop、snappy。
hdfs.maxOpenFiles	5000	最大允许打开的 hdfs 文件数，当打开的文件数达到该值时，最早打开的文件将会被关闭。
hdfs.writeFormat	Writable	文件写入格式，“Writable”或者“Text”。
hdfs.callTimeout	10000	写入 HDFS 超时控制时间，单位：毫秒。
hdfs.threadsPoolSize	-	每个 HDFS sink 用于 HDFS io 操作的线程数。
hdfs.rollTimerPoolSize	-	每个 HDFS sink 用于调度定时文件滚动的线程数。
hdfs.round	false	时间戳是否四舍五入。若设置为 true，则会影响所有基于时间的转义序列（%t 除外）。
hdfs.roundUnit	second	时间戳四舍五入单位，可选为“second”、“minute”或“hour”，分别对应为秒、分钟和小时。
hdfs.useLocalTimeStamp	true	是否启用本地时间戳，建议设置为“true”。
hdfs.closeTries	0	hdfs sink 尝试关闭重命名文件的最大次数。默认为 0 表示 sink 会一直尝试重命名，直至重命名成功。
hdfs.retryInterval	180	尝试关闭 hdfs 文件的时间间隔，单位：秒。 **说明** 每个关闭请求都会有多个 RPC 往返 Namenode，因此设置的太低可能导致 Namenode 超负荷。如果设置 0，如果第一次尝试失败的话，该 Sink 将不会尝试关闭文件，并且把文件打开，或者用“.tmp”作为扩展名。
hdfs.failcount	10	数据写入 hdfs 失败的次数。该参数作为 sink 写入 hdfs 失败次数的阈值，当超过该阈值后上报数据传输异常告警。

- **Avro Sink**

  Avro Sink 把 events 转化为 Avro events 并发送到配置的主机的监测端口。常用配置如下表所示：

表7-12 Avro Sink 常用配置

参数	默认值	描述
channel	-	与之相连的 channel。
type	-	avro sink 的类型，必须设置为 avro。
hostname	-	绑定的主机名/IP。
port	-	监测端口，该端口需未被占用。
batch-size	1000	批次发送的 Event 个数。
client.type	DEFAULT	客户端实例类型，根据所配置的模型实际使用到的通信协议设置。该值可选值包括： • DEFAULT，返回 AvroRPC 类型的客户端实例。 • OTHER，返回 NULL。 • THRIFT，返回 Thrift RPC 类型的客户端实例。 • DEFAULT_LOADBALANCING， 返回 LoadBalancing RPC 客户端实例。 • DEFAULT_FAILOVER， 返回 Failover RPC 客户端实例。
ssl	false	是否使用 SSL 加密。设置为 true 时还必须指定“密钥(keystore)”和“密钥存储密码(keystore-password)”。
truststore-type	JKS	Java 信任库类型，“JKS”或“PKCS12”。 **说明**

参数	默认值	描述
		JKS 的密钥库和私钥采用不同的密码进行保护，而 PKCS12 的密钥库和私钥采用相同密码进行保护。
truststore	-	Java 信任库文件。
truststore-password	-	Java 信任库密码。
keystore-type	JKS	ssl 启用后密钥存储类型。
keystore	-	ssl 启用后密钥存储文件路径，开启 ssl 后，该参数必填。
keystore-password	-	ssl 启用后密钥存储密码，开启 ssl 后，该参数必填。
connect-timeout	20000	第一次连接的超时时间，单位：毫秒。
request-timeout	20000	第一次请求后一次请求的最大超时时间，单位：毫秒。
reset-connection-interval	0	一次断开连接后，等待多少时间后进行重新连接，单位：秒。默认为 0 表示不断尝试。
compression-type	none	批数据压缩类型，“none”或“deflate”，“none”表示不压缩，“deflate”表示压缩。该值必须与 AvroSource 的 compression-type 匹配。
compression-level	6	批数据压缩级别（1-9），数值越高，压缩率越高。
exclude-protocols	SSLv3	排除的协议列表，用空格分开。默认排除 SSLv3 协议。

- **HBase Sink**

  HBase Sink 将数据写入到 HBase 中。常用配置如下表所示：

表7-13 HBase Sink 常用配置

参数	默认值	描述
channel	-	与之相连的 channel。
type	-	hbase sink 的类型，必须设置为 hbase。
table	-	HBase 表名称。
columnFamily	-	HBase 列族。
monTime	0（不开启）	线程监控阈值，更新时间超过阈值后，重新启动该 Sink，单位：秒。
batchSize	1000	批次写入 HBase 的 Event 个数。
kerberosPrincipal	-	认证 HBase 的 Kerberos principal，普通模式集群不配置，安全模式集群必须配置。
kerberosKeytab	-	认证 HBase 的 Kerberos keytab，普通模式集群不配置，安全模式集群中，flume 运行用户必须对 jaas.cof 文件中的 keyTab 路径有访问权限。
coalesceIncrements	true	是否在同一个处理批次中，合并对同一个 hbase cell 多个操作。设置为 true 有利于提高性能。

- **Kafka Sink**

  Kafka Sink 将数据写入到 Kafka 中。常用配置如下表所示：

表7-14 Kafka Sink 常用配置

参数	默认值	描述
channel	-	与之相连的 channel。
type	-	kafka sink 的类型，必须设置为 org.apache.flume.sink.kafka.KafkaSink。
kafka.bootstrap.servers	-	Kafka 的 bootstrap 地址端口列表。如果集群安装有 kafka 并且配置已经同步，服务端可以不配置此项，默认值为 Kafka 集群中所有的 broker 列表，客户端必须配置该项，多个用逗号分隔。端口和安全协议的匹配规则必须为：21007 匹配安全模式（SASL_PLAINTEXT），9092 匹配普通模式（PLAINTEXT）。
monTime	0（不开启）	线程监控阈值，更新时间超过阈值后，重新启动该 Sink，单位：秒。
kafka.producer.acks	1	必须收到多少个 replicas 的确认信息才认为写入成功。0 表示不需要接收确认信息，1 表示

参数	默认值	描述
		只等待 leader 的确认信息。-1 表示等待所有的 relicas 的确认信息。设置为-1，在某些 leader 失败的场景中可以避免数据丢失。
kafka.topic	-	数据写入的 topic，必须填写。
allowTopicOverride	false	是否将 Event Header 中保存的 topic 替换 kafka.topic 中配置的 topic。
flumeBatchSize	1000	批次写入 Kafka 的 Event 个数。
kafka.security.protocol	SASL_PLAINTEXT	Kafka 安全协议，普通模式集群下须配置为“PLAINTEXT”。端口和安全协议的匹配规则必须为：21007 匹配安全模式（SASL_PLAINTEXT），9092 匹配普通模式（PLAINTEXT）。
ignoreLongMessage	false	是否丢弃超大消息的开关。
messageMaxLength	1000012	Flume 写入 Kafka 的消息的最大长度。
defaultPartitionId	-	用于指定 channel 中的 events 被传输到哪一个 Kafka partition ID ，此值会被 partitionIdHeader 覆盖。默认情况下，如果此参数不设置，会由 Kafka Producer's partitioner 进行 events 分发(可以通过指定 key 或者 kafka.partitioner.class 自定义的 partitioner)。
partitionIdHeader	-	设置时，对应的 Sink 将从 Event 的 Header 中获取使用此属性的值命名的字段的值，并将消息发送到主题的指定分区。 如果该值无对应的有效分区，则会抛出 EventDeliveryException。 如果 Header 值已经存在，则此设置将覆盖参数 defaultPartitionId。
Other Kafka Producer Properties	-	其他 Kafka 配置，可以接受任意 Kafka 支持的生产配置，配置需要加前缀 .kafka。

- **Thrift Sink**

  Thrift Sink 把 events 转化为 Thrift events 并发送到配置的主机的监测端口。常用配置如下表所示：

表7-15 Thrift Sink 常用配置

参数	默认值	描述
channel	-	与之相连的 channel。

参数	默认值	描述
type	thrift	thrift sink 的类型，必须设置为 thrift。
hostname	-	绑定的主机名/IP。
port	-	监测端口，该端口需未被占用。
batch-size	1000	批次发送的 Event 个数。
connect-timeout	20000	第一次连接的超时时间，单位：毫秒。
request-timeout	20000	第一次请求后一次请求的最大超时时间，单位：毫秒。
kerberos	false	是否启用 Kerberos 认证。
client-keytab	-	客户端使用的 keytab 文件地址，flume 运行用户必须对认证文件具有访问权限。
client-principal	-	客户端使用的安全用户的 Principal。
server-principal	-	服务端使用的安全用户的 Principal。
compression-type	none	Flume 发送数据的压缩类型，“none”或“deflate”，“none”表示不压缩，“deflate”表示压缩。
maxConnections	5	Flume 发送数据时的最大连接池大小。
ssl	false	是否使用 SSL 加密。
truststore-type	JKS	Java 信任库类型。
truststore	-	Java 信任库文件。
truststore-password	-	Java 信任库密码。
reset-connection-interval	0	一次断开连接后，等待多少时间后进行重新连接，单位：秒。默认为 0 表示不断尝试。

注意事项

- Flume 可靠性保障措施有哪些？
  - Source&Channel、Channel&Sink 之间的事务机制。
  - Sink Processor 支持配置 failover、load_blance 机制，例如负载均衡示例如下。

```
server.sinkgroups=g1
server.sinkgroups.g1.sinks=k1 k2
server.sinkgroups.g1.processor.type=load_balance
server.sinkgroups.g1.processor.backoff=true
server.sinkgroups.g1.processor.selector=random
```

- Flume 多 agent 聚合级联时的注意事项？
  - 级联时需要使用 Avro 或者 Thrift 协议进行级联。
  - 聚合端存在多个节点时，连接配置尽量配置均衡，不要聚合到单节点上。

7.8 Flume 配置参数说明

部分参数可在 Manager 界面配置。

基本介绍

使用 Flume 需要配置 Source、Channel 和 Sink，各模块配置参数说明可通过本节内容了解。

MRS 3.x 及之后版本部分参数可通过 Manager 界面配置，选择“集群 > 服务 > Flume > 配置工具”，选择要使用的 Source、Channel 以及 Sink，将其拖到右侧的操作界面中，双击对应的 Source、Channel 以及 Sink，根据实际环境可配置 Source、Channel 和 Sink 参数。“channels”、“type”等参数仅在客户端配置文件“properties.properties”中进行配置，配置文件路径为“*Flume 客户端安装目录*/**fusioninsight-flume-***Flume 组件版本号*/**conf/properties.properties**”。

说明

部分配置可能需要填写加密后的信息，请参见 7.6 使用 Flume 客户端加密工具。

常用 Source 配置

- **Avro Source**

  Avro Source 监测 Avro 端口，接收外部 Avro 客户端数据并放入配置的 Channel 中。常用配置如表 7-16 所示：

表7-16 Avro Source 常用配置

参数	默认值	描述
channels	-	与之相连的 Channel，可以配置多个。用空格隔开。 在单个代理流程中，是通过 channel 连接 sources 和 sinks。一个 source 实例对应多

参数	默认值	描述
		个 channels，但一个 sink 实例只能对应一个 channel。 格式如下： **<Agent >.sources.<Source>.channels = <channel1> <channel2> <channel3>...** **<Agent >.sinks.<Sink>.channels = <channel1>** 仅可在“properties.properties”文件中配置。
type	avro	类型，需设置为“avro”。每一种 source 的类型都为相应的固定值。 仅可在“properties.properties”文件中配置。
bind	-	绑定和 source 关联的主机名或 IP 地址。
port	-	绑定端口号。
ssl	false	是否使用 SSL 加密。 • true • false
truststore-type	JKS	Java 信任库类型。填写 JKS 或其他 java 支持的 truststore 类型。
truststore	-	Java 信任库文件。
truststore-password	-	Java 信任库密码。
keystore-type	JKS	密钥存储类型。填写 JKS 或其他 java 支持的 truststore 类型。
keystore	-	密钥存储文件。
keystore-password	-	密钥存储密码。

- **SpoolDir Source**

  SpoolDir Source 监控并传输目录下新增的文件，可实现准实时数据传输。常用配置如表 7-17 所示：

表7-17 SpoolDir Source 常用配置

参数	默认值	描述
channels	-	与之相连的 Channel，可以配置多个。 仅可在“properties.properties”文件中配置。

参数	默认值	描述
type	spooldir	类型，需设置为“spooldir”。 仅可在“properties.properties”文件中配置。
monTime	0（不开启）	线程监控阈值，更新时间大于阈值时会重新启动该 Source，单位：秒。
spoolDir	-	监控目录。
fileSuffix	.COMPLETED	文件传输完成后添加的后缀。
deletePolicy	never	文件传输完成后源文件删除策略，支持“never”或“immediate”。分别是从不删除和立即删除。
ignorePattern	^$	忽略文件的正则表达式表示。
trackerDir	.flumespool	传输过程中元数据存储路径。
batchSize	1000	Source 传输粒度。
decodeErrorPolicy	FAIL	编码错误策略。仅可在“properties.properties”文件中配置。 可选 FAIL、REPLACE、IGNORE。 FAIL：抛出异常并让解析失败。 REPLACE：将不能识别的字符用其它字符代替，通常是字符 U+FFFD。 IGNORE：直接丢弃不能解析的字符串。 **说明** 如果文件中有编码错误，请配置“decodeErrorPolicy”为“REPLACE”或“IGNORE”，Flume 遇到编码错误将跳过编码错误，继续采集后续日志。
deserializer	LINE	文件解析器，值为“LINE”或“BufferedLine”。 • 配置为“LINE”时，对从文件读取的字符逐个转码。 • 配置为“BufferedLine”时，对文件读取的一行或多行的字符进行批量转码，性能更优。
deserializer.maxLineLength	2048	按行解析最大长度。0 到 2,147,483,647。
deserializer.maxBatchLine	1	按行解析最多行数，如果行数设置为多行，“maxLineLength”也应该设置为相应的倍数。例如 maxBatchLine 设置为 2，“maxLineLength”相应的设置为

参数	默认值	描述
		2048*2 为 4096。
selector.type	replicating	选择器类型，支持“replicating”或“multiplexing”。 • “replicating”表示同样的内容会发给每一个 channel。 • “multiplexing”表示根据分发规则，有选择地发给某些 channel。
interceptors	-	拦截器配置。 仅可在“properties.properties”文件中配置。

说明

Spooling Source 在按行读取过程中，会忽略掉每一个 Event 的最后一个换行符，该换行符所占用的数据量指标不会被 Flume 统计。

- **Kafka Source**

  Kafka Source 从 Kafka 的 topic 中消费数据，可以设置多个 Source 消费同一个 topic 的数据，每个 Source 会消费 topic 的不同 partitions。常用配置如表 7-18 所示：

表7-18 Kafka Source 常用配置

参数	默认值	描述
channels	-	与之相连的 Channel，可以配置多个。 仅可在“properties.properties”文件中配置。
type	org.apache.flume.source.kafka.KafkaSource	类型，需设置为“org.apache.flume.source.kafka.KafkaSource”。 仅可在“properties.properties”文件中配置。
monTime	0（不开启）	线程监控阈值，更新时间大于阈值时重新启动该 Source，单位：秒。
nodatatime	0（不开启）	告警阈值，从 Kafka 中订阅不到数据的时长大于阈值时发送告警，单位：秒。
batchSize	1000	每次写入 Channel 的 Event 数量。
batchDurationMillis	1000	每次消费 topic 数据的最大时长，单位：毫秒。
keepTopicInHeader	false	是否在 Event Header 中保存 topic，如果保存，Kafka Sink 配置的 topic 将无效。

参数	默认值	描述
		• true • false 仅可在“properties.properties”文件中配置。
keepPartitionInHeader	false	是否在 Event Header 中保存 partitionID，如果保存，Kafka Sink 将写入对应的 Partition。 • true • false 仅可在“properties.properties”文件中配置。
kafka.bootstrap.servers	-	brokers 地址列表，多个地址用英文逗号分隔。
kafka.consumer.group.id	-	Kafka 消费者组 ID。
kafka.topics	-	订阅的 kafka topic 列表，用英文逗号分隔。
kafka.topics.regex	-	符合正则表达式的 topic 会被订阅，优先级高于“kafka.topics”，如果配置将覆盖“kafka.topics”。
kafka.security.protocol	SASL_PLAINTEXT	Kafka 安全协议，未启用 Kerberos 集群中须配置为“PLAINTEXT”。
kafka.kerberos.domain.name	-	此参数的值为 Kafka 集群中 kerberos 的“default_realm”，仅安全集群需要配置。 仅可在“properties.properties”文件中配置。
Other Kafka Consumer Properties	-	其他 Kafka 配置，可以接受任意 Kafka 支持的消费参数配置，配置需要加前缀“.kafka”。 仅可在“properties.properties”文件中配置。

- **Taildir Source**

  Taildir Source 监控目录下文件的变化并自动读取文件内容，可实现实时数据传输，常用配置如表 7-19 所示：

表7-19 Taildir Source 常用配置

参数	默认值	描述

参数	默认值	描述
channels	-	与之相连的 Channel，可以配置多个。 仅可在“properties.properties”文件中配置。
type	taildir	类型，需配置为“taildir”。 仅可在“properties.properties”文件中配置。
filegroups	-	设置采集文件目录分组名字，分组名字中间使用空格间隔。
filegroups.<filegroupName>.parentDir	-	父目录，需要配置为绝对路径。 仅可在“properties.properties”文件中配置。
filegroups.<filegroupName>.filePattern	-	相对父目录的文件路径，可以包含目录，支持正则表达式，须与父目录联合使用。 仅可在“properties.properties”文件中配置。
positionFile	-	传输过程中元数据存储路径。
headers.<filegroupName>.<headerKey>	-	设置某一个分组采集数据时 Event 中的 key-value 值。 仅可在“properties.properties”文件中配置。
byteOffsetHeader	false	是否在每一个 Event 头中携带该 Event 在源文件中的位置信息，该信息保存在“byteoffset”变量中。
skipToEnd	false	Flume 在重启后是否直接定位到文件最新的位置处，以读取最新的数据。
idleTimeout	120000	设置读取文件的空闲时间，单位：毫秒。如果在该时间内文件内容没有变更，关闭掉该文件，关闭后如果该文件有数据写入，重新打开并读取数据。
writePosInterval	3000	设置将元数据写入到文件的周期，单位：毫秒。
batchSize	1000	批次写入 Channel 的 Event 数量。
monTime	0（不开启）	线程监控阈值，更新时间大于阈值时重新启动该 Source，单位：秒。

- **Http Source**

  Http Source 接收外部 HTTP 客户端发送过来的数据，并放入配置的 Channel 中，常用配置如表 7-20 所示：

表7-20 Http Source 常用配置

参数	默认值	描述
channels	-	与之相连的 Channel，可以配置多个。仅可在“properties.properties”文件中配置。
type	http	类型，需配置为“http”。仅可在“properties.properties”文件中配置。
bind	-	绑定关联的主机名或 IP 地址。
port	-	绑定端口。
handler	org.apache.flume.source.http.JSONHandler	http 请求的消息解析方式，支持以下两种： • “org.apache.flume.source.http.JSONHandler”：表示 Json 格式解析。 • “org.apache.flume.sink.solr.morphline.BlobHandler”：表示二进制 Blob 块解析。
handler.*	-	设置 handler 的参数。
enableSSL	false	http 协议是否启用 SSL。
keystore	-	http 启用 SSL 后设置 keystore 的路径。
keystorePassword	-	http 启用 SSL 后设置 keystore 的密码。

常用 Channel 配置

- **Memory Channel**

  Memory Channel 使用内存作为缓存区，Events 存放在内存队列中。常用配置如表 7-21 所示：

表7-21 Memory Channel 常用配置

参数	默认值	描述
type	-	类型，需配置为“memory”。仅可在“properties.properties”文件中配置。
capacity	10000	缓存在 Channel 中的最大 Event 数。
transactionCapacity	1000	每次存取的最大 Event 数。

参数	默认值	描述
channelfullcount	10	Channel full 次数，达到该次数后发送告警。

- **File Channel**

  File Channel 使用本地磁盘作为缓存区，Events 存放在设置的“dataDirs”配置项文件夹中。常用配置如表 7-22 所示：

表7-22 File Channel 常用配置

参数	默认值	描述
type	-	类型，需配置为“file”。仅可在“properties.properties”文件中配置。
checkpointDir	${BIGDATA_DATA_HOME}/flume/checkpoint	检查点存放路径。
dataDirs	${BIGDATA_DATA_HOME}/flume/data	数据缓存路径，设置多个路径可提升性能，中间用逗号分开。
maxFileSize	2146435071	单个缓存文件的最大值，单位：字节。
minimumRequiredSpace	524288000	缓冲区空闲空间最小值，单位：字节。
capacity	1000000	缓存在 Channel 中的最大 Event 数。
transactionCapacity	10000	每次存取的最大 Event 数。
channelfullcount	10	Channel full 次数，达到该次数后发送告警。

- **Kafka Channel**

  Kafka Channel 使用 kafka 集群缓存数据，Kafka 提供高可用、多副本，以防 Flume 或 Kafka Broker 崩溃，Channel 中的数据会立即被 Sink 消费。常用配置如表 7-23 所示：

表7-23 Kafka Channel 常用配置

参数	默认值	描述
type	-	类型，需配置为“org.apache.flume.channel.kafka.KafkaChannel”.。 仅可在“properties.properties”文件中配

参数	默认值	描述
		置。
kafka.bootstrap.servers	-	kafka broker 列表。
kafka.topic	flume-channel	Channel 用来缓存数据的 topic。
kafka.consumer.group.id	flume	Kafka 消费者组 ID。
parseAsFlumeEvent	true	是否解析为 Flume event。
migrateZookeeperOffsets	true	当 Kafka 没有存储 offset 时，是否从 ZooKeeper 中查找，并提交到 Kafka。
kafka.consumer.auto.offset.reset	latest	当没有 offset 记录时，从指定的位置消费数据。
kafka.producer.security.protocol	SASL_PLAINTEXT	Kafka 生产者安全协议。
kafka.consumer.security.protocol	SASL_PLAINTEXT	Kafka 消费者安全协议。

常用 Sink 配置

- **HDFS Sink**

  HDFS Sink 将数据写入 HDFS。常用配置如表 7-24 所示：

表7-24 HDFS Sink 常用配置

参数	默认值	描述
channel	-	与之相连的 Channel。仅可在“properties.properties”文件中配置。
type	hdfs	类型，需配置为“hdfs”。仅可在“properties.properties”文件中配置。
monTime	0（不开启）	线程监控阈值，更新时间大于阈值时重新启动该 Sink，单位：秒。
hdfs.path	-	HDFS 路径。
hdfs.inUseSuffix	.tmp	正在写入的 HDFS 文件后缀。
hdfs.rollInterval	30	按时间滚动文件，单位：秒，同时需将“hdfs.fileCloseByEndEvent”设置为“false”。
hdfs.rollSize	1024	按大小滚动文件，单位：字节，同时需将“hdfs.fileCloseByEndEvent”设置为“false”。

参数	默认值	描述
hdfs.rollCount	10	按 Event 个数滚动文件，同时需将“hdfs.fileCloseByEndEvent”设置为“false”。
hdfs.idleTimeout	0	自动关闭空闲文件超时时间，单位：秒。
hdfs.batchSize	1000	每次写入 HDFS 的 Event 个数。
hdfs.kerberosPrincipal	-	认证 HDFS 的 Kerberos 用户名，未启用 Kerberos 认证集群不配置。
hdfs.kerberosKeytab	-	认证 HDFS 的 Kerberos keytab 路径，未启用 Kerberos 认证集群不配置
hdfs.fileCloseByEndEvent	true	收到最后一个 Event 时是否关闭文件。
hdfs.batchCallTimeout	-	每次写入 HDFS 超时控制时间，单位：毫秒。 当不配置此参数时，对每个 Event 写入 HDFS 进行超时控制。当“hdfs.batchSize”大于 0 时，配置此参数可以提升写入 HDFS 性能。 **说明** “hdfs.batchCallTimeout”设置多长时间需要考虑“hdfs.batchSize”的大小，“hdfs.batchSize”越大，“hdfs.batchCallTimeout”也要调整更长时间，设置过短时间容易导致数据写入 HDFS 失败。
serializer.appendNewline	true	将一个 Event 写入 HDFS 后是否追加换行符（'\n'），如果追加该换行符，该换行符所占用的数据量指标不会被 HDFS Sink 统计。

- **Avro Sink**

  Avro Sink 把 events 转化为 Avro events 并发送到配置的主机的监测端口。常用配置如表 7-25 所示：

表7-25 Avro Sink 常用配置

参数	默认值	描述
channel	-	与之相连的 Channel。仅可在“properties.properties”文件中配置。
type	-	类型，需配置为“avro”。仅可在

参数	默认值	描述
		“properties.properties”文件中配置。
hostname	-	绑定关联的主机名或 IP 地址。
port	-	监测端口。
batch-size	1000	批次发送的 Event 个数。
ssl	false	是否使用 SSL 加密。
truststore-type	JKS	Java 信任库类型。
truststore	-	Java 信任库文件。
truststore-password	-	Java 信任库密码。
keystore-type	JKS	密钥存储类型。
keystore	-	密钥存储文件。
keystore-password	-	密钥存储密码

- **HBase Sink**

  HBase Sink 将数据写入到 HBase 中。常用配置如表 7-26 所示：

表7-26 HBase Sink 常用配置

参数	默认值	描述
channel	-	与之相连的 Channel。仅可在“properties.properties”文件中配置。
type	-	类型，需配置为“hbase”。仅可在“properties.properties”文件中配置。
table	-	HBase 表名称。
monTime	0（不开启）	线程监控阈值，更新时间大于阈值时重新启动该 Sink，单位：秒。
columnFamily	-	HBase 列族名称。
batchSize	1000	每次写入 HBase 的 Event 个数。
kerberosPrincipal	-	认证 HBase 的 Kerberos 用户名，未启用 Kerberos 认证集群不配置。
kerberosKeytab	-	认证 HBase 的 Kerberos keytab 路径，未启用 Kerberos 认证集群不配置。

- **Kafka Sink**

Kafka Sink 将数据写入到 Kafka 中。常用配置如表 7-27 所示：

表7-27 Kafka Sink 常用配置

参数	默认值	描述
channel	-	与之相连的 Channel。仅可在“properties.properties”文件中配置。
type	-	类型，需配置为“org.apache.flume.sink.kafka.KafkaSink”。 仅可在“properties.properties”文件中配置。
kafka.bootstrap.servers	-	Kafkabrokers 列表，多个用英文逗号分隔。
monTime	0（不开启）	线程监控阈值，更新时间大于阈值时重新启动该 Sink，单位：秒。
kafka.topic	default-flume-topic	数据写入的 topic。
flumeBatchSize	1000	每次写入 Kafka 的 Event 个数。
kafka.security.protocol	SASL_PLAINTEXT	Kafka 安全协议，未启用 Kerberos 认证集群下须配置为“PLAINTEXT”。
kafka.kerberos.domain.name	-	Kafka Domain 名称。安全集群必填。仅可在“properties.properties”文件中配置。
Other Kafka Producer Properties	-	其他 Kafka 配置，可以接受任意 Kafka 支持的生产参数配置，配置需要加前缀“.kafka”。 仅可在“properties.properties”文件中配置。

7.9 在配置文件 properties.properties 中使用环境变量

操作场景

本章节描述如何在配置文件“properties.properties”中使用环境变量。

前提条件

Flume 服务运行正常并已成功安装 Flume 客户端。

操作步骤

步骤 1 以 **root** 用户登录安装 Flume 客户端所在节点。

步骤 2 切换到以下目录。

cd *Flume 客户端安装目录*/**fusioninsight-flume-***Flume 组件版本号*/**conf**

步骤 3 在该目录下的“flume-env.sh”文件中添加环境变量。

- 格式：

```
export 变量名=变量值
```

- 示例：

```
JAVA_OPTS="-Xms2G -Xmx4G -XX:CMSFullGCsBeforeCompaction=1 -
XX:+UseConcMarkSweepGC -XX:+CMSParallelRemarkEnabled -
XX:+UseCMSCompactAtFullCollection -
DpropertiesImplementation=org.apache.flume.node.EnvVarResolverProperties"
export TAILDIR_PATH=/tmp/flumetest/201907/20190703/1/.*log.*
```

步骤 4 重启 Flume 实例进程。

1. 登录 FusionInsight Manager。
2. 选择“集群 > 服务 > Flume > 实例”，勾选 Flume 实例，选择“更多 > 重启实例”输入密码，单击“确定”等待实例重启成功。

须知

服务端 flume-env.sh 生效后不能通过 Manager 界面重启整个 Flume 服务，否则用户自定义环境变量丢失，仅需在 Manager 界面重启对应实例即可。

步骤 5 在“*Flume 客户端安装目录*/**fusioninsight-flume-***Flume 组件版本号*/**conf/properties.properties**”配置文件中使用“${变量名}”格式引用变量，示例如下：

```
client.sources.s1.type = TAILDIR
client.sources.s1.filegroups = f1
client.sources.s1.filegroups.f1 = ${TAILDIR_PATH}
client.sources.s1.positionFile =
/tmp/flumetest/201907/20190703/1/taildir_position.json
client.sources.s1.channels = c1
```

须知

- 必须保证“flume-env.sh”生效之后，再执行步骤 5 配置“properties.properties”文件。
- 若在本地配置该文件，配置完成后可参考如下步骤在 Manager 界面上传配置文件。若操作顺序不规范，可能造成用户自定义环境变量丢失。

- 登录 FusionInsight Manager。

1. 选择“集群 > 服务 > Flume > 配置”，勾选 Flume 实例，在“flume.config.file”后单击“上传文件”，上传“properties.properties”文件。

----结束

7.10 非加密传输

7.10.1 配置非加密传输

操作场景

该操作指导安装工程师在集群及 Flume 服务安装完成后，分别配置 Flume 服务的服务端和客户端参数，使其可以正常工作。

说明

本配置默认集群网络环境是安全的，数据传输过程不需要启用 SSL 认证。如需使用加密方式，请参考 7.11.1 配置加密传输。

前提条件

- 已安装 Flume 客户端。
- 已成功安装集群及 Flume 服务。
- 确保集群网络环境安全。

操作步骤

步骤 1 配置 Flume 角色客户端参数。

1. 使用 FusionInsight Manager 界面中的 Flume 配置工具来配置 Flume 角色客户端参数并生成配置文件。
   a. 登录 FusionInsight Manager，选择“集群 > 服务 > Flume > 配置工具”。
   b. “Agent 名”选择“client”，然后选择要使用的 Source、Channel 以及 Sink，将其拖到右侧的操作界面中并将其连接。

      例如采用 SpoolDir Source、File Channel 和 Avro Sink，如图 7-2 所示。

      图7-2 Flume 配置工具示例

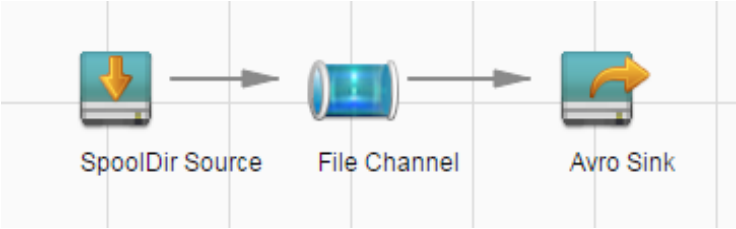

c. 双击对应的 Source、Channel 以及 Sink，根据实际环境并参考表 7-28 设置对应的配置参数。

说明

- 如果对应的 Flume 角色之前已经配置过客户端参数，为保证与之前的配置保持一致，可以到“*客户端安装目录*/fusioninsight-flume-1.9.0/conf/properties.properties”获取已有的客户端参数配置文件。然后登录 FusionInsight Manager，选择“集群 > 服务 > Flume > 配置 > 导入”，将该文件导入后再修改非加密传输的相关配置项即可。
- 导入配置文件时，建议配置 Source/Channel/Sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。

表7-28 Flume 角色客户端所需修改的参数列表

参数名称	参数值填写规则	参数样例
ssl	是否启用 SSL 认证（基于安全要求，建议启用此功能） 只有“Avro”类型的 Source 才有此配置项 • true 表示启用 • false 表示不启用	false

d. 单击“导出”，将配置文件“properties.properties”保存到本地。

2. 将“properties.properties”文件上传到 Flume 客户端安装目录下的“flume/conf/”下。

步骤 2 配置 Flume 角色的服务端参数，并将配置文件上传到集群。

1. 使用 FusionInsight Manager 界面中的 Flume 配置工具来配置服务端参数并生成配置文件。
   a. 登录 FusionInsight Manager，选择“集群 > 服务 > Flume > 配置工具”。
   b. “Agent 名”选择“server”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。
      例如采用 Avro Source、File Channel 和 HDFS Sink，如图 7-3 所示。

图7-3 Flume 配置工具示例

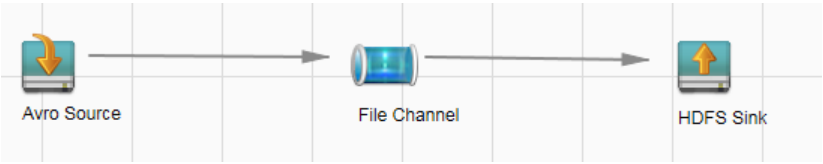

   c. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-29 设置对应的配置参数。

说明

- 如果对应的 Flume 角色之前已经配置过服务端参数，为保证与之前的配置保持一致，在 FusionInsight Manager 界面选择“集群 > 服务 > Flume > 实例”，选择相应的 Flume 角色实例，单击“实例配置 ”页面“flume.config.file”参数后的“下载文件”，可获取已有的服务端参数配置文件。然后选择“集群 > 服务 > Flume > 配置 > 导入”，将该文件导入后再修改非加密传输的相关配置项即可。
- 导入配置文件时，建议配置 source/channel/sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。
- 不同的 File Channel 均需要配置一个不同的 checkpoint 目录。

表7-29 Flume 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
ssl	是否启用 SSL 认证（基于安全要求，建议启用此功能） 只有“Avro”类型的 Source 才有此配置项 • true 表示启用 • false 表示不启用	false

d. 单击“导出”，将配置文件“properties.properties”保存到本地。

2. 登录 FusionInsight Manager，选择“集群 > 服务 > Flume”，在“实例”下单击“Flume”角色。
3. 选择准备上传配置文件的节点行的“Flume”角色，单击“实例配置 ”页面“flume.config.file”参数后的“上传文件”，选择“properties.properties”文件完成操作。

说明

- 每个 Flume 实例均可以上传单独的服务端配置文件。
- 更新配置文件需要按照此步骤操作，后台修改配置文件是不规范操作，同步配置时后台做的修改将会被覆盖。

4. 单击“保存”，单击“确定”。
5. 单击“完成”完成操作。

----结束

7.10.2 典型场景：从本地采集静态日志保存到 Kafka

操作场景

该任务指导用户使用 Flume 服务端从本地采集静态日志保存到 Kafka 的 Topic 列表（test1）。

说明

本配置默认集群网络环境是安全的，数据传输过程不需要启用 SSL 认证。如需使用加密方式，请参考 7.11.1 配置加密传输。该配置为只用一个 Flume 场景，例如：Spooldir Source+Memory Channel+Kafka Sink.

前提条件

- 已成功安装集群，包含 Kafka 及 Flume 服务。
- 确保集群网络环境安全。
- MRS 集群管理员已明确业务需求，并准备一个 Kafka 管理员用户 **flume_kafka**。

操作步骤

步骤 1 配置 Flume 的参数。

使用 Manager 界面中的 Flume 配置工具来配置 Flume 角色服务端参数并生成配置文件。

1. 登录 FusionInsight Manager，选择“集群 > 服务 > Flume > 配置工具”。
2. “Agent 名”选择“client”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

   采用 SpoolDir Source、Memory Channel 和 Kafka Sink，如图 7-4 所示。

   图7-4 Flume 配置工具示例

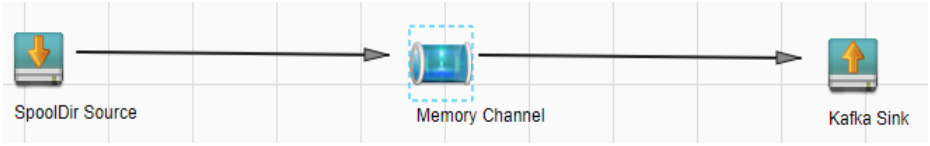

3. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-30 设置对应的配置参数。

说明

- 如果想在之前的“properties.propretites”文件上进行修改后继续使用，则登录 Manager，选择“集群 > 服务 > Flume > 配置工具 > 导入”，将该文件导入后再修改非加密传输的相关配置项即可。
- 导入配置文件时，建议配置 Source/Channel/Sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。

表7-30 Flume 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
名称	不能为空，必须唯一	test
spoolDir	待采集的文件所在的目录路径，此参数不能为空。该路径需存在，且对 flume 运行用户有读写	/srv/BigData/hadoop/data1/zb

参数名称	参数值填写规则	参数样例
	执行权限。	
trackerDir	flume 采集文件信息元数据保存路径。	/srv/BigData/hadoop/data1/tracker
batchSize	Flume 一次发送的事件个数（数据条数）。增大会提升性能，降低实时性；反之降低性能，提升实时性。	61200
kafka.topics	订阅的 Kafka topic 列表，多个 topic 用逗号分隔，此参数不能为空。	test1
kafka.bootstrap.servers	Kafka 的 bootstrap 地址端口列表，默认值为 Kafka 集群中所有的 Kafkabrokers。	192.168.101.10:21007

4. 单击“导出”，将配置文件“properties.properties”保存到本地。

步骤 2 上传配置文件。

将步骤 1.4 导出的文件上传至集群的“flume/conf”目录下，可参考步骤 2.2。

步骤 3 验证日志是否传输成功。

1. 登录 Kafka 客户端：

   cd *Kafka 客户端安装目录*/**Kafka/kafka**

   kinit flume_kafka（输入密码）

2. 读取 KafkaTopic 中的数据。

   bin/kafka-console-consumer.sh --topic *主题名称* **--bootstrap-server** *Kafka 角色实例所在节点的业务 IP 地址*:**21007 --consumer.config config/consumer.properties --from-beginning**

   系统显示待采集文件目录下的内容：

```
[root@host1 kafka]# bin/kafka-console-consumer.sh --topic test1 --bootstrap-server 192.168.101.10:21007 --consumer.config config/consumer.properties --from-beginning
Welcome to flume
```

----结束

7.10.3 典型场景：从本地采集静态日志保存到 HDFS

操作场景

该任务指导用户使用 Flume 服务端从本地采集静态日志保存到 HDFS 上“/flume/test”目录下。

说明

本配置默认集群网络环境是安全的，数据传输过程不需要启用 SSL 认证。如需使用加密方式，请参考 7.11.1 配置加密传输。该配置为只用一个 Flume 场景，例如：Spooldir Source+Memory Channel+HDFS Sink。

前提条件

- 已成功安装集群，包含 HDFS 及 Flume 服务。
- 确保集群网络环境安全。
- 已创建用户 **flume_hdfs** 并授权验证日志时操作的 HDFS 目录和数据。

操作步骤

步骤 1 在 FusionInsight Manager 管理界面，选择“系统 > 权限 > 用户”，选择用户 **flume_hdfs**，选择“更多 > 下载认证凭据”下载 Kerberos 证书文件并保存在本地。

步骤 2 配置 Flume 参数。

使用 FusionInsight Manager 界面中的 Flume 来配置 Flume 角色服务端参数并生成配置文件。

1. 登录 FusionInsight Manager，选择“集群 > 服务 >Flume> 配置工具”。
2. “Agent 名”选择“client”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

   采用 SpoolDir Source、Memory Channel 和 HDFS Sink，如图 7-5 所示。

图7-5 Flume 配置工具示例

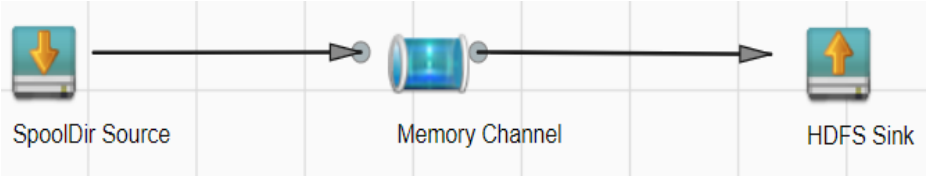

3. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-31 设置对应的配置参数。

说明

- 如果想在之前的“properties.propretites”文件上进行修改后继续使用，则登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 >Flume> 配置工具 > 导入”，将该文件导入后再修改非加密传输的相关配置项即可。
- 导入配置文件时，建议配置 source/channel/sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。

表7-31 Flume 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
名称	不能为空，必须唯一。	test

参数名称	参数值填写规则	参数样例
spoolDir	待采集的文件所在的目录路径，此参数不能为空。该路径需存在，且对 flume 运行用户有读写执行权限。	/srv/BigData/hadoop/data1/zb
trackerDir	flume 采集文件信息元数据保存路径。	/srv/BigData/hadoop/data1/tracker
batchSize	Flume 一次发送数据的最大事件数。	61200
hdfs.path	写入 HDFS 的目录，此参数不能为空。	hdfs://hacluster/flume/test
hdfs.filePrefix	数据写入 HDFS 后文件名的前缀。	TMP_
hdfs.batchSize	一次写入 HDFS 的最大事件数目。	61200
hdfs.kerberosPrincipal	kerberos 认证时用户，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	flume_hdfs
hdfs.kerberosKeytab	kerberos 认证时 keytab 文件路径，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	/opt/test/conf/user.keytab **说明** user.keytab 文件从下载用户 **flume_hdfs** 的 kerberos 证书文件中获取，另外，确保用于安装和运行 Flume 客户端的用户对 user.keytab 文件有读写权限。
hdfs.useLocalTimeStamp	是否使用本地时间，取值为"true"或者"false"。	true

4. 单击“导出”，将配置文件“properties.properties”保存到本地。

步骤 3 上传配置文件。

将步骤 2.4 导出的文件上传至集群的“flume/conf”目录下，可参考步骤 2.2。

步骤 4 验证日志是否传输成功。

1. 以具有 HDFS 组件管理权限的用户登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。在 FusionInsight Manager 界面选择“集群 > 服务 > HDFS”，单击“NameNode(主)”对应的链接，打开 HDFS WebUI，然后选择“Utilities > Browse the file system”。
2. 观察 HDFS 上“/flume/test”目录下是否有产生数据。

图7-6 查看 HDFS 目录和文件

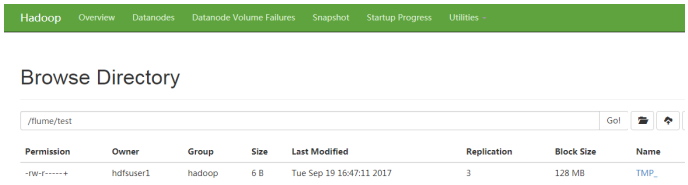

----结束

7.10.4 典型场景：从本地采集动态日志保存到 HDFS

操作场景

该任务指导用户使用 Flume 服务端从本地采集动态日志保存到 HDFS 上“/flume/test”目录下。

说明

本配置默认集群网络环境是安全的，数据传输过程不需要启用 SSL 认证。如需使用加密方式，请参考 7.11.1 配置加密传输。该配置为只用一个 Flume 场景，例如：Taildir Source+Memory Channel+HDFS Sink。

前提条件

- 已成功安装集群，包含 HDFS 及 Flume 服务。
- 确保集群网络环境安全。
- 已创建用户 **flume_hdfs** 并授权验证日志时操作的 HDFS 目录和数据。

操作步骤

步骤 1 在 FusionInsight Manager 管理界面，选择“系统 > 权限 > 用户”，选择“更多 > 下载认证凭据”下载用户 **flume_hdfs** 的 kerberos 证书文件并保存在本地。

步骤 2 配置 Flume 参数。

使用 FusionInsight Manager 界面中的 Flume 配置工具来配置 Flume 角色服务端参数并生成配置文件。

1. 登录 FusionInsight Manager，选择“集群 > 服务 > Flume > 配置工具”。
2. “Agent 名”选择“client”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

   采用 Taildir Source、Memory Channel 和 HDFS Sink，如图 7-7 所示。

图7-7 Flume 配置工具示例

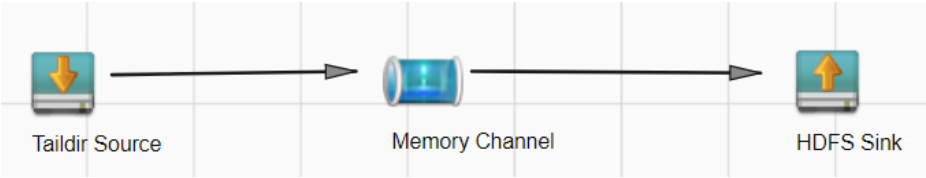

3. 双击对应的 Source、Channel 以及 Sink，根据实际环境并参考表 7-32 设置对应的配置参数。

说明

- 如果想在之前的“properties.propretites”文件上进行修改后继续使用，则登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具 > 导入”，将该文件导入后再修改非加密传输的相关配置项即可。
- 导入配置文件时，建议配置 Source/Channel/Sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。

表7-32 Flume 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
名称	不能为空，必须唯一。	test
filegroups	文件分组列表名，此参数不能为空。该值包含如下两项参数： • 名称：文件分组列表名。 • filegroups：动态日志文件绝对路径。	-
positionFile	保存当前采集文件信息（文件名和已经采集的位置），此参数不能为空。该文件不需要手工创建，但其上层目录需对 flume 运行用户可写。	/home/omm/flume/positionfile
batchSize	Flume 一次发送数据的最大事件数。	61200
hdfs.path	写入 HDFS 的目录，此参数不能为空。	hdfs://hacluster/flume/test
hdfs.filePrefix	数据写入 HDFS 后文件名的前缀。	TMP_
hdfs.batchSize	一次写入 HDFS 的最大事件数目。	61200
hdfs.kerberosPrincipal	kerberos 认证时用户，在安全版本下必须填写。安全集群需	flume_hdfs

参数名称	参数值填写规则	参数样例
	要配置此项，普通模式集群无需配置。	
hdfs.kerberosKeytab	kerberos 认证时 keytab 文件路径，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	/opt/test/conf/user.keytab 说明 user.keytab 文件从下载用户 **flume_hdfs** 的 kerberos 证书文件中获取，另外，确保用于安装和运行 Flume 客户端的用户对 user.keytab 文件有读写权限。
hdfs.useLocalTimeStamp	是否使用本地时间，取值为"true"或者"false"。	true

4. 单击“导出”，将配置文件“properties.properties”保存到本地。

步骤 3 上传配置文件。

将步骤 2.4 导出的文件上传至集群的“flume/conf”目录下，可参考步骤 2.2。

步骤 4 验证日志是否传输成功。

1. 以具有 HDFS 组件管理权限的用户登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。在 FusionInsight Manager 界面选择“集群 > 服务 > HDFS”，单击“NameNode(*节点名称*，主)”对应的链接，打开 HDFS WebUI，然后选择“Utilities > Browse the file system”。
2. 观察 HDFS 上“/flume/test”目录下是否有产生数据。

图7-8 查看 HDFS 目录和文件

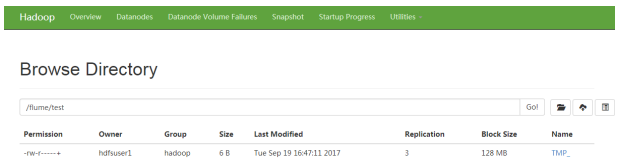

----结束

7.10.5 典型场景：从 Kafka 采集日志保存到 HDFS

操作场景

该任务指导用户使用 Flume 服务端从 Kafka 的 Topic 列表(test1)采集日志保存到 HDFS 上“/flume/test”目录下。

说明

本配置默认集群网络环境是安全的，数据传输过程不需要启用 SSL 认证。如需使用加密方式，请参考 7.11.1 配置加密传输。该配置为只用一个 Flume 场景，例如：Kafka Source+Memory Channel+HDFS Sink.

前提条件

- 已成功安装集群，包含 HDFS、Kafka 及 Flume 服务。
- 确保集群网络环境安全。
- 已创建用户 **flume_hdfs** 并授权验证日志时操作的 HDFS 目录和数据。

操作步骤

步骤 1 在 FusionInsight Manager 管理界面，选择“系统 > 权限 > 用户”，选择“更多 > 下载认证凭据”下载用户 **flume_hdfs** 的 kerberos 证书文件并保存在本地。

步骤 2 配置 Flume 角色服务端参数。

使用 FusionInsight Manager 界面中的 Flume 配置工具来配置 Flume 角色服务端参数并生成配置文件。

1. 登录 FusionInsight Manager，选择“集群 > 服务 >Flume> 配置工具”。
2. “Agent 名”选择“client”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

   例如采用 Kafka Source、Memory Channel 和 HDFS Sink，如图 7-9 所示。

图7-9 Flume 配置工具示例

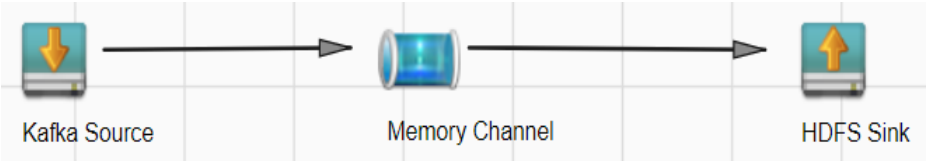

3. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-33 设置对应的配置参数。

说明

- 如果想在之前的“properties.propretites”文件上进行修改后继续使用，则登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 >Flume> 配置工具 > 导入”，将该文件导入后再修改非加密传输的相关配置项即可。
- 导入配置文件时，建议配置 source/channel/sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。

表7-33 Flume 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
名称	不能为空，必须唯一。	test

参数名称	参数值填写规则	参数样例
kafka.topics	订阅的 Kafka topic 列表，用逗号分隔，此参数不能为空。	test1
kafka.consumer.group.id	从 Kafka 中获取数据的组标识，此参数不能为空。	flume
kafka.bootstrap.servers	Kafka 的 bootstrap 地址端口列表，默认值为 Kafka 集群中所有的 Kafka 列表。如果集群安装有 Kafka 并且配置已经同步，可以不配置此项。	192.168.101.10:9092
batchSize	Flume 一次发送的事件个数（数据条数）。	61200
hdfs.path	写入 HDFS 的目录，此参数不能为空。	hdfs://hacluster/flume/test
hdfs.filePrefix	数据写入 HDFS 后文件名的前缀。	TMP_
hdfs.batchSize	一次写入 HDFS 的最大事件数目。	61200
hdfs.kerberosPrincipal	kerberos 认证时用户，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	flume_hdfs
hdfs.kerberosKeytab	kerberos 认证时 keytab 文件路径，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	/opt/test/conf/user.keytab 说明 user.keytab 文件从下载用户 **flume_hdfs** 的 kerberos 证书文件中获取，另外，确保用于安装和运行 Flume 客户端的用户对 user.keytab 文件有读写权限。
hdfs.useLocalTimeStamp	是否使用本地时间，取值为"true"或者"false"。	true

4. 单击“导出”，将配置文件“properties.properties”保存到本地。

步骤 3 上传配置文件。

将步骤 2.4 导出的文件上传至集群的“flume/conf”目录下，可参考步骤 2.2。

步骤 4 验证日志是否传输成功。

1. 以具有 HDFS 组件管理权限的用户登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。在 FusionInsight Manager 界

面选择“集群 > 服务 > HDFS”，单击“NameNode(*节点名称*，主)”对应的链接，打开 HDFS WebUI，然后选择“Utilities > Browse the file system”。

2. 观察 HDFS 上“/flume/test”目录下是否有产生数据。

图7-10 查看 HDFS 目录和文件

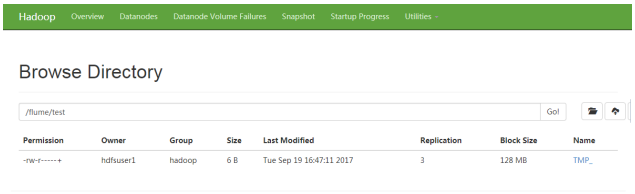

----结束

7.10.6 典型场景：从 Kafka 客户端采集日志经 Flume 客户端保存到 HDFS

操作场景

该任务指导用户使用 Flume 客户端从 Kafka 客户端的 Topic 列表(test1)采集日志保存到 HDFS 上“/flume/test”目录下。

说明

本配置默认集群网络环境是安全的，数据传输过程不需要启用 SSL 认证。如需使用加密方式，请参考 7.11.1 配置加密传输。

前提条件

- 已安装 Flume 客户端。
- 已成功安装集群，包含 HDFS、Kafka 及 Flume 服务。
- 已创建用户 **flume_hdfs** 并授权验证日志时操作的 HDFS 目录和数据。
- 确保集群网络环境安全。

操作步骤

步骤 1 在 FusionInsight Manager 管理界面，选择“系统 > 权限 > 用户”，选择“更多 > 下载认证凭据”下载用户 **flume_hdfs** 的 kerberos 证书文件并保存在本地。

步骤 2 配置 Flume 角色客户端参数。

1. 使用 FusionInsight Manager 界面中的 Flume 配置工具来配置 Flume 角色服务端参数并生成配置文件。
   a. 登录 FusionInsight Manager，选择“集群 > 服务 > Flume > 配置工具”。
   b. “Agent 名”选择“client”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

      例如采用 Kafka Source、File Channel 和 HDFS Sink，如图 7-11 所示。

图7-11 Flume 配置工具示例

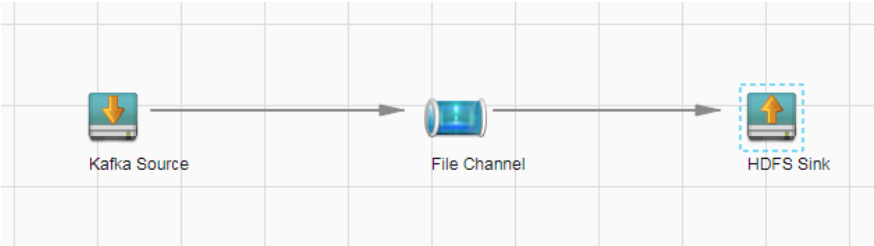

c. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-34 设置对应的配置参数。

说明

- 如果想在之前的“properties.propretites”文件上进行修改后继续使用，则登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具 > 导入”，将该文件导入后再修改非加密传输的相关配置项即可。
- 导入配置文件时，建议配置 source/channel/sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。

表7-34 Flume 角色客户端所需修改的参数列表

参数名称	参数值填写规则	参数样例
名称	不能为空，必须唯一。	test
kafka.topics	订阅的 Kafka topic 列表，用逗号分隔，此参数不能为空。	test1
kafka.consumer.group.id	从 Kafka 中获取数据的组标识，此参数不能为空。	flume
kafka.bootstrap.servers	Kafka 的 bootstrap 地址端口列表，默认值为 Kafka 集群中所有的 Kafka 列表。如果集群安装有 Kafka 并且配置已经同步，可以不配置此项。	192.168.101.10:21007
batchSize	Flume 一次发送的事件个数（数据条数）。	61200
dataDirs	缓冲区数据保存目录，默认为运行目录。配置多个盘上的目录可以提升传输效率，多个目录使用逗号分隔。如果为集群内，则可以指定在如下目录 /srv/BigData/hadoop/dataX/flume/data，dataX 为	/srv/BigData/hadoop/data1/flume/data

参数名称	参数值填写规则	参数样例
	data1~dataN。如果为集群外，则需要单独规划。	
checkpointDir	checkpoint 信息保存目录，默认在运行目录下。如果为集群内，则可以指定在如下目录 /srv/BigData/hadoop/dataX/flume/checkpoint，dataX 为 data1~dataN。如果为集群外，则需要单独规划。	/srv/BigData/hadoop/data1/flume/checkpoint
transactionCapacity	事务大小：即当前 channel 支持事务处理的事件个数，建议和 Source 的 batchSize 设置为同样大小，不能小于 batchSize。	61200
hdfs.path	写入 HDFS 的目录，此参数不能为空。	hdfs://hacluster/flume/test
hdfs.filePrefix	数据写入 HDFS 后文件名的前缀。	TMP_
hdfs.batchSize	一次写入 HDFS 的最大事件数目。	61200
hdfs.kerberosPrincipal	kerberos 认证时用户，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	flume_hdfs
hdfs.kerberosKeytab	kerberos 认证时 keytab 文件路径，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	/opt/test/conf/user.keytab **说明** user.keytab 文件从下载用户 **flume_hdfs** 的 kerberos 证书文件中获取，另外，确保用于安装和运行 Flume 客户端的用户对 user.keytab 文件有读写权限。
hdfs.useLocalTimeStamp	是否使用本地时间，取值为"true"或者"false"	true

d. 单击“导出”，将配置文件“properties.properties”保存到本地。

2. 将“properties.properties”文件上传到 Flume 客户端安装目录下的“flume/conf/”下。
3. Flume 客户端连接到 HDFS，还需要补充如下配置：

a. 通过“用户”下载用户 **flume_hdfs** 的 kerberos 证书文件获取 krb5.conf 配置文件，并上传至客户端所在节点安装目录的“fusioninsight-flume-1.9.0/conf/”下。

b. 新建 jaas.conf 配置文件到客户端所在节点安装目录的“fusioninsight-flume-1.9.0/conf/”下。

vi jaas.conf

```
KafkaClient {
com.sun.security.auth.module.Krb5LoginModule required
useKeyTab=true
keyTab="/opt/test/conf/user.keytab"
principal="flume_hdfs@<系统域名>"
useTicketCache=false
storeKey=true
debug=true;
};
```

参数 keyTab 和 principal 根据实际情况修改。

c. 从/opt/FusionInsight_Cluster_<*集群 ID*>_Flume_ClientConfig/Flume/config 目录下获取 core-site.xml 和 hdfs-site.xml 配置文件，并上传至客户端所在节点安装目录的“fusioninsight-flume-1.9.0/conf/”下。

4. 进入客户端所在节点安装目录的“fusioninsight-flume-1.9.0/bin”下，执行以下命令重启 Flume 进程。

./flume-manage.sh restart

步骤 3 验证日志是否传输成功。

1. 以具有 HDFS 组件管理权限的用户登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。在 FusionInsight Manager 界面选择“集群 > 服务 > HDFS”，单击“NameNode(*节点名称*，主)”对应的链接，打开 HDFS WebUI，然后选择“Utilities > Browse the file system”。

2. 观察 HDFS 上“/flume/test”目录下是否有产生数据。

图7-12 查看 HDFS 目录和文件

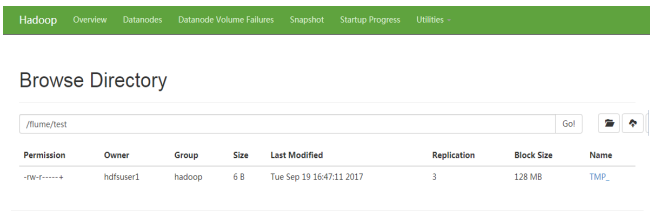

----结束

7.10.7 典型场景：从本地采集静态日志保存到 HBase

操作场景

该任务指导用户使用 Flume 客户端从本地采集静态日志保存到 HBase 表：flume_test。该场景介绍的是多级 agent 串联操作。

说明

本配置默认集群网络环境是安全的，数据传输过程不需要启用 SSL 认证。如需使用加密方式，请参考 7.11.1 配置加密传输。该配置可以只用一个 Flume 场景，例如 Server：Spooldir Source+File Channel+HBase Sink。

前提条件

- 已成功安装集群，包含 HBase 及 Flume 服务。
- 已安装 Flume 客户端。
- 确保集群网络环境安全。
- 已创建 HBase 表：**create 'flume_test', 'cf'**。
- MRS 集群管理员已明确业务需求，并准备一个 HBase 管理员用户 **flume_hbase**。

操作步骤

步骤 1 在 FusionInsight Manager 管理界面，选择“系统 > 权限 > 用户”，选择“更多 > 下载认证凭据”下载用户 **flume_hbase** 的 kerberos 证书文件并保存在本地。

步骤 2 配置 Flume 角色客户端参数。

1. 使用 FusionInsight Manager 界面中的 Flume 配置工具来配置 Flume 角色客户端参数并生成配置文件。
   a. 登录 FusionInsight Manager，选择“集群 > 服务 > Flume > 配置工具”。
   b. “Agent 名”选择“client”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

      采用 SpoolDir Source、File Channel 和 Avro Sink，如图 7-13 所示。

      图7-13 Flume 配置工具示例

      

   c. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-35 设置对应的配置参数。

说明

- 如果想在之前的“properties.propretites”文件上进行修改后继续使用，则登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具 > 导入”，将该文件导入后再修改非加密传输的相关配置项即可。
- 导入配置文件时，建议配置 source/channel/sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。

表7-35 Flume 角色客户端所需修改的参数列表

参数名称	参数值填写规则	参数样例
名称	不能为空，必须唯一。	test
spoolDir	待采集的文件所在的目录路径，此参数不能为空。该路径需存在，且对 flume 运行用户有读写执行权限。	/srv/BigData/hadoop/data1/zb
trackerDir	flume 采集文件信息元数据保存路径。	/srv/BigData/hadoop/data1/tracker
batchSize	Flume 一次发送的事件个数（数据条数）。增大会提升性能，降低实时性；反之降低性能，提升实时性。	61200
dataDirs	缓冲区数据保存目录，默认为运行目录。配置多个盘上的目录可以提升传输效率，多个目录使用逗号分隔。如果为集群内，则可以指定在如下目录 /srv/BigData/hadoop/dataX/flume/data，dataX 为 data1~dataN。如果为集群外，则需要单独规划。	/srv/BigData/hadoop/data1/flume/data
checkpointDir	checkpoint 信息保存目录，默认在运行目录下。如果为集群内，则可以指定在如下目录 /srv/BigData/hadoop/dataX/flume/checkpoint，dataX 为 data1~dataN。如果为集群外，则需要单独规划。	/srv/BigData/hadoop/data1/flume/checkpoint
transactionCapacity	事务大小：即当前 channel 支持事务处理的事件个数，建议和 Source 的 batchSize 设置为同样大	61200

参数名称	参数值填写规则	参数样例
	小，不能小于 batchSize。	
hostname	要发送数据的主机名或者IP，此参数不能为空。须配置为与之相连的 avro source 所在的主机名或IP。	192.168.108.11
port	要发送数据的端口，此参数不能为空。须配置为与之相连的 avro source 监测的端口。	21154
ssl	是否启用 SSL 认证（基于安全要求，建议启用此功能）。 只有“Avro”类型的 Source 才有此配置项。 • true 表示启用 • false 表示不启用	false

d. 单击“导出”，将配置文件“properties.properties”保存到本地。

2. 将“properties.properties”文件上传到 Flume 客户端安装目录下的“flume/conf/”下。

步骤 3 配置 Flume 角色的服务端参数，并将配置文件上传到集群。

1. 使用 FusionInsight Manager 界面中的 Flume 配置工具来配置服务端参数并生成配置文件。

a. 登录 FusionInsight Manager，选择“集群 > 服务 > Flume > 配置工具”。

b. “Agent 名”选择“server”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

采用 Avro Source、File Channel 和 HBase Sink，如图 7-14 所示。

图7-14 Flume 配置工具示例

c. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-36 设置对应的配置参数。

说明

- 如果对应的 Flume 角色之前已经配置过服务端参数，为保证与之前的配置保持一致，在 FusionInsight Manager 界面选择“集群 > *待操作集群的名称* > 服务 > Flume > 实例”，选择相应的 Flume 角色实例，单击“实例配置”页面“flume.config.file”参数后的“下载文件”，可获取已有的服务端参数配置文件。然后选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具 > 导入”，将该文件导入后再修改非加密传输的相关配置项即可。
- 导入配置文件时，建议配置 source/channel/sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。
- 不同的 File Channel 均需要配置一个不同的 checkpoint 目录。

表7-36 Flume 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
名称	不能为空，必须唯一。	test
bind	avro source 绑定的 ip 地址，此参数不能为空。须配置为服务端配置文件即将要上传的主机 IP。	192.168.108.11
port	avro source 监测的端口，此参数不能为空。须配置为未被使用的端口。	21154
ssl	是否启用 SSL 认证（基于安全要求，建议启用此功能）。 只有“Avro”类型的 Source 才有此配置项。 • true 表示启用 • false 表示不启用	false
dataDirs	缓冲区数据保存目录，默认为运行目录。配置多个盘上的目录可以提升传输效率，多个目录使用逗号分隔。如果为集群内，则可以指定在如下目录 /srv/BigData/hadoop/dataX/flume/data，dataX 为 data1~dataN。如果为集群外，则需要单独规划。	/srv/BigData/hadoop/data1/flumeserver/data
checkpointDir	checkpoint 信息保存目录，默认在运行目录下。如果为集群内，则可以指定在如下目录 /srv/BigData/hadoop/dataX/flume/checkpoint，dataX 为 data1~dataN。如果为集群外，则需要单独规划。	/srv/BigData/hadoop/data1/flumeserver/checkpoint
transactionCapacity	事务大小：即当前 channel 支持事务处理的事件个数。建议和 Source 的 batchSize 设置为同样大小，不能小于 batchSize。	61200
table	HBase 表名，此参数不能为空。	flume_test

参数名称	参数值填写规则	参数样例
columnFamily	HBase 列族名，此参数不能为空。	cf
batchSize	Flume 一次写入 HBase 中的最大事件数。	61200
kerberosPrincipal	kerberos 认证时用户，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	flume_hbase
kerberosKeytab	kerberos 认证时文件路径，,在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	/opt/test/conf/user.keytab **说明** user.keytab 文件从下载用户 **flume_hbase** 的 kerberos 证书文件中获取，另外，确保用于安装和运行 Flume 客户端的用户对 user.keytab 文件有读写权限。

d. 单击“导出”，将配置文件“properties.properties”保存到本地。

2. 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume”，在“实例”下单击“Flume”角色。
3. 选择准备上传配置文件的节点行的“Flume”角色，单击“实例配置”页面“flume.config.file”参数后的“上传文件”，选择“properties.properties”文件完成操作。

说明

- 每个 Flume 实例均可以上传单独的服务端配置文件。
- 更新配置文件需要按照此步骤操作，后台修改配置文件是不规范操作，同步配置时后台做的修改将会被覆盖。

4. 单击“保存”，单击“确定”。
5. 单击“完成”完成操作。

步骤 4 验证日志是否传输成功。

1. 进入 HBase 客户端目录：

   cd */客户端安装目录*/**HBase/hbase**

   kinit flume_hbase（输入密码）
2. 执行 **hbase shell** 进入 HBase 客户端。
3. 执行语句：**scan 'flume_test'** ，可以看到日志按行写入 HBase 列族里。

```
hbase(main):001:0> scan 'flume_test'
ROW                                                   COLUMN+CELL
2017-09-18 16:05:36,394 INFO  [hconnection-0x415a3f6a-shared--pool2-t1]
ipc.AbstractRpcClient: RPC Server Kerberos principal name for
service=ClientService is hbase/hadoop.<系统域名>@<系统域名>
 default4021ff4a-9339-4151-a4d0-00f20807e76d                column=cf:pCol,
```

```
timestamp=1505721909388, value=Welcome to flume
 incRow                                          column=cf:iCol,
timestamp=1505721909461, value=\x00\x00\x00\x00\x00\x00\x00\x01
2 row(s) in 0.3660 seconds
```

----结束

7.11 加密传输

7.11.1 配置加密传输

操作场景

该操作指导安装工程师在集群安装完成后，分别设置 Flume 服务（包括 Flume 角色和 MonitorServer 角色）的服务端和客户端参数，使其可以正常工作。

前提条件

已成功安装集群及 Flume 服务。

操作步骤

步骤 1 分别生成 Flume 角色服务端和客户端的证书和信任列表。

1. 使用 ECM 远程以 **omm** 用户登录将要安装 Flume 服务端的节点。进入“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin”目录。

   cd ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin

   说明

   此处版本号 xxx 为示例，具体以实际环境的版本号为准。

2. 执行以下命令，生成并导出 Flume 角色服务端、客户端证书。

   sh geneJKS.sh -f *xxx* **-g** *xxx*

   生成的证书在“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf”路径下。其中：

   - “flume_sChat.jks”是 Flume 角色服务端的证书库，“flume_sChat.crt”是“flume_sChat.jks”证书的导出文件，“-f”配置项是证书和证书库的密码；
   - “flume_cChat.jks”是 Flume 角色客户端的证书库，“flume_cChat.crt”是“flume_cChat.jks”证书的导出文件，“-g”配置项是证书和证书库的密码；
   - “flume_sChatt.jks”和“flume_cChatt.jks”分别为 Flume 服务端、客户端 SSL 证书信任列表。

   说明

   本章节涉及到所有的用户自定义密码，需满足以下复杂度要求：

   - 至少包含大写字母、小写字母、数字、特殊符号 4 种类型字符。
   - 至少 8 位，最多 64 位。

- 出于安全考虑，建议用户定期更换自定义密码（例如三个月更换一次），并重新生成各项证书和信任列表。

步骤 2 配置 Flume 角色的服务端参数，并将配置文件上传到集群。

1. 使用 ECM 远程，以 **omm** 用户登录任意一个 Flume 角色所在的节点。执行以下命令进入“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin”。

   cd ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin

2. 执行以下命令，生成并得到 Flume 服务端密钥库密码、信任列表密码和 keystore-password 加密的私钥信息。连续输入两次密码并确认，该密码是 *flume_sChat.jks* 证书库的密码。

   ./genPwFile.sh

   cat password.property

3. 使用 FusionInsight Manager 界面中的 Flume 配置工具来配置服务端参数并生成配置文件。

   a. 登录 FusionInsight Manager，选择“ 服务 > Flume > 配置工具”。

   b. “Agent 名”选择“server”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

   例如采用 Avro Source、File Channel 和 HDFS Sink，如图 7-15 所示。

   图7-15 Flume 配置工具示例

   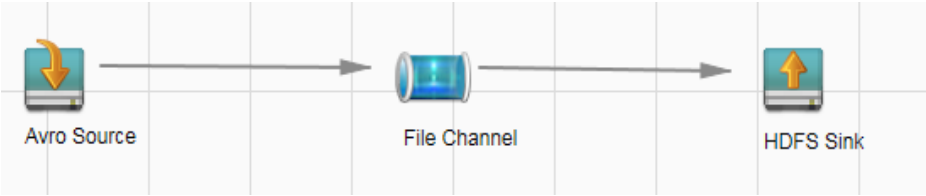

   c. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-37 设置对应的配置参数。

   说明

   - 如果对应的 Flume 角色之前已经配置过服务端参数，为保证与之前的配置保持一致，在 FusionInsight Manager 界面选择“ 服务 > Flume > 实例”，选择相应的 Flume 角色实例，单击“实例配置”页面“flume.config.file”参数后的“下载文件”，可获取已有的服务端参数配置文件。然后选择“ 服务 > Flume > 导入”，将该文件导入后再修改加密传输的相关配置项即可。
   - 导入配置文件时，建议配置 Source/Channel/Sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。

   d. 单击“导出”，将配置文件“properties.properties”保存到本地。

表7-37 Flume 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
ssl	是否启用 SSL 认证（基于安全要	true

参数名称	参数值填写规则	参数样例
	求，建议启用此功能）。 • true 表示启用。 • false 表示不启用。	
keystore	服务端证书。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/flume_sChat.jks
keystore-password	密钥库密码，获取 keystore 信息所需密码。 输入步骤 2.2 中获取的“password”值。	-
truststore	服务端的 SSL 证书信任列表。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/flume_sChatt.jks
truststore-password	信任列表密码，获取 truststore 信息所需密码。 输入步骤 2.2 中获取的“password”值。	-

4. 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume”服务，在“角色”下单击“Flume”角色。
5. 选择准备上传配置文件的节点行的“Flume”角色，单击“实例配置”页面“flume.config.file”参数后的“上传文件”，选择“properties.properties”文件完成操作。

   说明

   - 每个 Flume 实例均可以上传单独的服务端配置文件。
   - 更新配置文件需要按照此步骤操作，后台修改配置文件是不规范操作，同步配置时后台做的修改将会被覆盖。
6. 单击“保存”，单击“确定”。单击“完成”完成操作。

步骤 3 设置 Flume 角色客户端参数。

1. 执行以下命令将生成的客户端证书（flume_cChat.jks）和客户端信任列表（flume_cChatt.jks）复制到客户端目录下，如“/opt/flume-client/fusionInsight-flume-1.9.0/conf/”（要求已安装 Flume 客户端），其中 **10.196.26.1** 为客户端所在节点业务平面的 IP 地址。

   scp ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/flume_cChat.jks user@10.196.26.1:/opt/flume-client/fusionInsight-flume-1.9.0/conf/

scp ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/flume_cChatt.jks user@10.196.26.1:/opt/flume-client/fusionInsight-flume-1.9.0/conf/

说明

复制过程中需要输入客户端所在主机（如 **10.196.26.1**）**user** 用户的密码。

2. 以 **user** 用户登录解压 Flume 客户端的节点。执行以下命令进入客户端目录“opt/flume-client/fusionInsight-flume-1.9.0/bin”。

   cd opt/flume-client/fusionInsight-flume-1.9.0/bin

3. 执行以下命令，生成并得到 Flume 客户端密钥库密码、信任列表密码和 keystore-password 加密的私钥信息。连续输入两次密码并确认，该密码是别名为 *flumechatclient* 的证书和 *flume_cChat.jks* 证书库的密码。

   ./genPwFile.sh

   cat password.property

说明

若产生以下错误提示，可执行命令 **export JAVA_HOME=***JDK 路径*进行处理。

```
JAVA_HOME is null in current user,please install the JDK and set the JAVA_HOME
```

4. 执行 **echo $SCC_PROFILE_DIR** 检查 SCC_PROFILE_DIR 环境变量是否为空。
   - 是，执行 **source .sccfile**。
   - 否，执行步骤 3.5。
5. 使用 FusionInsight Manager 界面中的 Flume 配置工具来配置 Flume 角色客户端参数并生成配置文件。
   a. 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具”。
   b. “Agent 名”选择“client”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

      例如采用 SpoolDir Source、File Channel 和 Avro Sink，如图 7-16 所示。

      图7-16 Flume 配置工具示例

      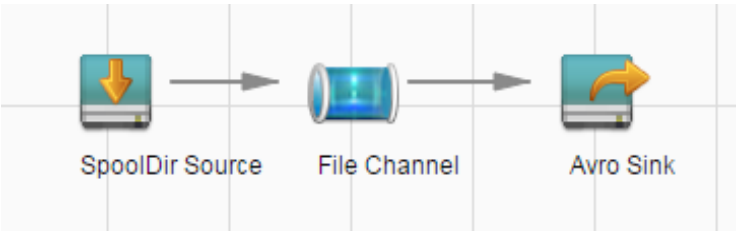

   c. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-38 设置对应的配置参数。

说明

- 如果对应的 Flume 角色之前已经配置过客户端参数，为保证与之前的配置保持一致，可以到“客户端安装目录/fusioninsight-flume-1.9.0/conf/properties.properties”获取已有的客户端参数配置文件。然后登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具 > 导入”，将该文件导入后再修改加密传输的相关配置项即可。

- 导入配置文件时，建议配置 source/channel/sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。
- 不同的 File Channel 均需要配置一个不同的 checkpoint 目录。

d. 单击“导出”，将配置文件“properties.properties”保存到本地。

表7-38 Flume 角色客户端所需修改的参数列表

参数名称	参数值填写规则	参数样例
ssl	是否启用 SSL 认证（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true
keystore	客户端证书。	/opt/flume-client/fusionInsight-flume-1.9.0/conf/flume_cChat.jks
keystore-password	密钥库密码，获取 keysore 信息所需密码。 输入步骤 3.3 中获取的“password”值。	-
truststore	客户端的 SSL 证书信任列表。	/opt/flume-client/fusionInsight-flume-1.9.0/conf/flume_cChatt.jks
truststore-password	信任列表密码，获取 truststore 信息所需密码。 输入步骤 3.3 中获取的“password”值。	-

6. 将“properties.properties”文件上传到 Flume 客户端安装目录下的“flume/conf/”下。

步骤 4 分别生成 MonitorServer 角色服务端和客户端的证书和信任列表。

1. 使用 ECM 以 **omm** 用户登录 MonitorServer 角色所在主机。

   进入“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin”目录。

   cd ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin

2. 执行以下命令，生成并导出 MonitorServer 角色服务端、客户端证书。

   sh geneJKS.sh -m *xxx* **-n** ***xxx***

   生成的证书在“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf”路径下，其中：

- “ms_sChat.jks”是 MonitorServer 角色服务端的证书库，“ms_sChat.crt”是“ms_sChat.jks”证书的导出文件，“-m”配置项是证书和证书库的密码；
- “ms_cChat.jks”是 MonitorServer 角色客户端的证书库，“ms_cChat.crt”是“ms_cChat.jks”证书的导出文件，“-n”配置项是证书和证书库的密码；
- “ms_sChatt.jks”、“ms_cChatt.jks”分别为 MonitorServer 服务端、客户端 SSL 证书信任列表。

步骤 5 配置 MonitorServer 角色服务端参数。

1. 执行以下命令，生成并得到 MonitorServer 服务端密钥库密码、信任列表密码和 keystore-password 加密的私钥信息。连续输入两次密码并确认，该密码是别名为 *mschatserver* 的证书和 *ms_sChat.jks* 证书库的密码。

   ./genPwFile.sh

   cat password.property

2. 使用以下命令打开“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/service/application.properties”文件。根据表 7-39 中的说明，修改相关参数，并保存退出。

   vi ${BIGDATA_HOME}/FusionInsight_Porter_xxx**/install/FusionInsight-Flume-1.9.0/flume/conf/service/application.properties**

表7-39 MonitorServer 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
ssl_need_kspasswd_decrypt_key	是否开启自定义密钥加解密功能（基于安全要求，建议启用此功能）。 • true 表示启用。 • false 表示不启用。	true
ssl_server_enable	是否启用 SSL 认证（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true
ssl_server_key_store	根据具体的存放位置进行修改。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_sChat.jks
ssl_server_trust_key_store	根据具体的存放位置进行修改。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_sChatt.jks
ssl_server_key_store_password	keystore 密码，根据具体制作证书的实际情况修改（生成证书的明文密钥）	-

参数名称	参数值填写规则	参数样例
	输入步骤 5.1 中获取的“password”值。	
ssl_server_trust_key_store_password	krustkeystore 密码，根据具体制作证书的实际情况修改（生成信任列表的明文密钥）。 输入步骤 5.1 中获取的“password”值。	-
ssl_need_client_auth	是否启用客户端认证（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true

3. 重启 MonitorServer 实例。选择“ 服务 > Flume > 实例 > MonitorServer”，勾选配置的“MonitorServer”实例，选择“更多 > 重启实例”。输入集群管理员密码，单击“确定”，重启完成后单击“完成”完成操作。

步骤 6 配置 MonitorServer 角色客户端参数。

1. 执行以下命令将生成的客户端证书（ms_cChat.jks）和客户端信任列表（ms_cChatt.jks）复制到客户端的“/opt/flume-client/fusionInsight-flume-1.9.0/conf/”目录下，其中 **10.196.26.1** 为客户端所在节点业务平面的 IP 地址。

   scp ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_cChat.jks user@10.196.26.1:/opt/flume-client/fusionInsight-flume-1.9.0/conf/

   scp ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_cChatt.jks user@10.196.26.1:/opt/flume-client/fusionInsight-flume-1.9.0/conf/

2. 以 **user** 用户登录 Flume 客户端所在的节点。执行以下命令进入客户端目录“/opt/flume-client/fusionInsight-flume-1.9.0/bin”。

   cd /opt/flume-client/fusionInsight-flume-1.9.0/bin

3. 执行以下命令，生成并得到 MonitorServer 客户端密钥库密码、信任列表密码和 keystore-password 加密的私钥信息。连续输入两次密码并确认，该密码是别名为 *mschatclient* 的证书和 *ms_cChat.jks* 证书库的密码。

   ./genPwFile.sh

   cat password.property

4. 使用以下命令打开“/opt/flume-client/fusionInsight-flume-1.9.0/conf/service/application.properties”文件（“/opt/flume-client/fusionInsight-flume-1.9.0”为客户端软件安装后的目录）。根据表 7-40 中的说明，修改相关参数，并保存退出。

   vi /opt/flume-client/fusionInsight-flume-1.9.0/flume/conf/service/application.properties

表7-40 MonitorServer 角色客户端所需修改的参数列表

参数名称	参数值填写规则	参数样例
ssl_need_kspasswd_decrypt_key	是否开启自定义密钥加解密功能（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true
ssl_client_enable	是否启用 SSL 认证（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true
ssl_client_key_store	根据具体的存放位置进行修改。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_cChat.jks
ssl_client_trust_key_store	根据具体的存放位置进行修改。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_cChatt.jks
ssl_client_key_store_password	keystore 密码，根据具体制作证书的实际情况修改（生成证书的明文密钥）。 输入步骤 6.3 中获取的“password”值。	-
ssl_client_trust_key_store_password	trustkeystore 密码，根据具体制作证书的实际情况修改（生成信任列表的明文密钥）。 输入步骤 6.3 中获取的“password”值。	-
ssl_need_client_auth	是否启用客户端认证（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true

----结束

7.11.2 典型场景：从本地采集静态日志保存到 HDFS

操作场景

该任务指导用户使用 Flume 从本地采集静态日志保存到 HDFS 上如下目录“/flume/test”。

前提条件

- 已成功安装集群、HDFS 及 Flume 服务、Flume 客户端。
- 已创建用户 **flume_hdfs** 并授权验证日志时操作的 HDFS 目录和数据。

操作步骤

步骤 1 分别生成 Flume 角色服务端和客户端的证书和信任列表。

1. 以 **omm** 用户登录 Flume 服务端所在节点。进入“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin”目录。

   cd ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin

2. 执行以下命令，生成并导出 Flume 角色服务端、客户端证书。

   sh geneJKS.sh -f *密码* **-g** *密码*

   生成的证书在“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf”路径下。其中：

   - “flume_sChat.jks”是 Flume 角色服务端的证书库，“flume_sChat.crt”是“flume_sChat.jks”证书的导出文件，“-f”配置项是证书和证书库的密码；
   - “flume_cChat.jks”是 Flume 角色客户端的证书库，“flume_cChat.crt”是“flume_cChat.jks”证书的导出文件，“-g”配置项是证书和证书库的密码；
   - “flume_sChatt.jks”和“flume_cChatt.jks”分别为 Flume 服务端、客户端 SSL 证书信任列表。

   说明

   本章节涉及到所有的用户自定义密码，需满足以下复杂度要求：

   - 至少包含大写字母、小写字母、数字、特殊符号 4 种类型字符
   - 至少 8 位，最多 64 位
   - 出于安全考虑，建议用户定期更换自定义密码（例如三个月更换一次），并重新生成各项证书和信任列表。

步骤 2 在 FusionInsight Manager 管理界面，选择“系统 > 权限 > 用户”，选择“更多 > 下载认证凭据”下载用户 **flume_hdfs** 的 kerberos 证书文件并保存在本地。

步骤 3 配置 Flume 角色的服务端参数，并将配置文件上传到集群。

1. 以 **omm** 用户登录任意一个 Flume 角色所在的节点。执行以下命令进入“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin”。

cd ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin

2. 执行以下命令，生成并得到 Flume 服务端密钥库密码、信任列表密码和 keystore-password 加密的私钥信息。连续输入两次密码并确认，该密码是 *flume_sChat.jks* 证书库的密码。

   ./genPwFile.sh

   cat password.property

3. 使用 FusionInsight Manager 界面中的 Flume 配置工具来配置服务端参数并生成配置文件。

   a. 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具”。

   b. “Agent 名”选择“server”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

      采用 SpoolDir Source、File Channel 和 HDFS Sink，如图 7-17 所示。

      图7-17 Flume 配置工具示例

      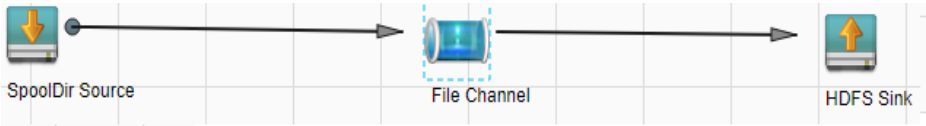

   c. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-41 设置对应的配置参数。

   说明

   - 如果对应的 Flume 角色之前已经配置过服务端参数，为保证与之前的配置保持一致，在 FusionInsight Manager 界面选择“集群 > *待操作集群的名称* > 服务 > Flume > 实例”，选择相应的 Flume 角色实例，单击“实例配置”页面“flume.config.file”参数后的“下载文件”按钮，可获取已有的服务端参数配置文件。然后选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具 > 导入”，将该文件导入后再修改加密传输的相关配置项即可。
   - 导入配置文件时，建议配置 source/channel/sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。
   - 不同的 File Channel 均需要配置一个不同的 checkpoint 目录。

   d. 单击“导出”，将配置文件“properties.properties”保存到本地。

表7-41 Flume 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
名称	不能为空，必须唯一。	test
bind	avro source 绑定的 ip 地址，此参数不能为空。须配置为服务端配置文件即将要上传的主机 IP。	192.168.108.11
port	avro source 监测的端口，此参数不能为空。须配置为未被使用的端口。	21154

参数名称	参数值填写规则	参数样例
ssl	是否启用 SSL 认证（基于安全要求，建议用户启用此功能）。 只有“Avro”类型的 Source 才有此配置项。 • true 表示启用。 • false 表示不启用。	true
keystore	服务端证书。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/flume_sChat.jks
keystore-password	密钥库密码，获取 keystore 信息所需密码。 输入步骤 3.2 中获取的“password”值。	-
truststore	服务端的 SSL 证书信任列表。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/flume_sChatt.jks
truststore-password	信任列表密码，获取 truststore 信息所需密码。 输入步骤 3.2 中获取的“password”值。	-
dataDirs	缓冲区数据保存目录，默认为运行目录。配置多个盘上的目录可以提升传输效率，多个目录使用逗号分隔。如果为集群内，则可以指定在如下目录/srv/BigData/hadoop/dataX/flume/data，dataX 为 data1~dataN。如果为集群外，则需要单独规划。	/srv/BigData/hadoop/data1/flumeserver/data
checkpointDir	checkpoint 信息保存目录，默认在运行目录下。如果为集群内，则可以指定在如下目录/srv/BigData/hadoop/dataX/flume/checkpoint，dataX 为 data1~dataN。如果为集群外，则需要单独规划。	/srv/BigData/hadoop/data1/flumeserver/checkpoint
transactionCapacity	事务大小：即当前 channel 支持事务处理的事件个数。建议和 Source 的 batchSize 设置为同样大小，不能小于 batchSize。	61200

参数名称	参数值填写规则	参数样例
hdfs.path	写入 HDFS 的目录，此参数不能为空。	hdfs://hacluster/flume/test
hdfs.inUsePrefix	正在写入 HDFS 的文件的前缀。	TMP_
hdfs.batchSize	一次写入 HDFS 的最大事件数目。	61200
hdfs.kerberosPrincipal	kerberos 认证时用户，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	flume_hdfs
hdfs.kerberosKeytab	kerberos 认证时 keytab 文件路径，在安全版本下必须填写。安全集群需要配置此项，普通模式集群无需配置。	/opt/test/conf/user.keytab 说明 user.keytab 文件从下载用户 **flume_hdfs** 的 kerberos 证书文件中获取，另外，确保用于安装和运行 Flume 客户端的用户对 user.keytab 文件有读写权限。
hdfs.useLocalTimeStamp	是否使用本地时间，取值为"true"或者"false"。	true

4. 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume”，在“角色”下单击“Flume”角色。
5. 选择准备上传配置文件的节点行的“Flume”角色，单击“实例配置”页面“flume.config.file”参数后的“上传文件”，选择“properties.properties”文件完成操作。

   说明

   - 每个 Flume 实例均可以上传单独的服务端配置文件。
   - 更新配置文件需要按照此步骤操作，后台修改配置文件是不规范操作，同步配置时后台做的修改将会被覆盖。
6. 单击“保存”，单击“确定”。
7. 单击“完成”完成操作。

步骤 4 配置 Flume 角色客户端参数。

1. 执行以下命令将生成的客户端证书（flume_cChat.jks）和客户端信任列表（flume_cChatt.jks）复制到客户端目录下，如“/opt/flume-client/fusionInsight-flume-1.9.0/conf/”（要求已安装 Flume 客户端），其中 **10.196.26.1** 为客户端所在节点业务平面的 IP 地址。

   scp ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/flume_cChat.jks user@10.196.26.1:/opt/flume-client/fusionInsight-flume-1.9.0/conf/

scp ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/flume_cChatt.jks user@10.196.26.1:/opt/flume-client/fusionInsight-flume-1.9.0/conf/

说明

复制过程中需要输入客户端所在主机（如 **10.196.26.1**）**user** 用户的密码。

2. 以 **user** 用户登录解压 Flume 客户端的节点。执行以下命令进入客户端目录“/opt/flume-client/fusionInsight-flume-1.9.0/bin”。

   cd opt/flume-client/fusionInsight-flume-1.9.0/bin

3. 执行以下命令，生成并得到 Flume 客户端密钥库密码、信任列表密码和 keystore-password 加密的私钥信息。连续输入两次密码并确认，该密码是别名为 *flumechatclient* 的证书和 *flume_cChat.jks* 证书库的密码。

   ./genPwFile.sh

   cat password.property

说明

若产生以下错误提示，可执行命令 **export JAVA_HOME=***JDK 路径*进行处理。

```
JAVA_HOME is null in current user,please install the JDK and set the JAVA_HOME
```

4. 执行 **echo $SCC_PROFILE_DIR** 检查 SCC_PROFILE_DIR 环境变量是否为空。
   - 是，执行 **source .sccfile**。
   - 否，执行步骤 4.5。
5. 使用 FusionInsight Manager 界面中的 Flume 配置工具来配置 Flume 角色客户端参数并生成配置文件。
   a. 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具”。
   b. “Agent 名”选择“client”，然后选择要使用的 source、channel 以及 sink，将其拖到右侧的操作界面中并将其连接。

      采用 SpoolDir Source、File Channel 和 HDFS Sink，如图 7-18 所示。

      图7-18 Flume 配置工具示例

      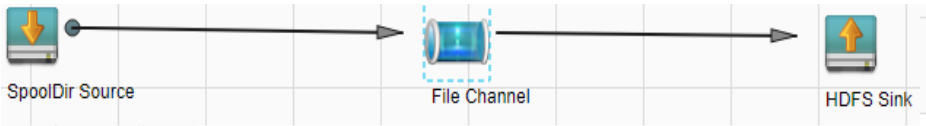

   c. 双击对应的 source、channel 以及 sink，根据实际环境并参考表 7-42 设置对应的配置参数。

说明

- 如果对应的 Flume 角色之前已经配置过客户端参数，为保证与之前的配置保持一致，可以到“*客户端安装目录*/fusioninsight-flume-1.9.0/conf/properties.properties”获取已有的客户端参数配置文件。然后登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Flume > 配置工具 > 导入”，将该文件导入后再修改加密传输的相关配置项即可。
- 导入配置文件时，建议配置中 source/channel/sink 的各自的个数都不要超过 40 个，否则可能导致界面响应时间过长。

   d. 单击“导出”，将配置文件“properties.properties”保存到本地。

表7-42 Flume 角色客户端所需修改的参数列表

参数名称	参数值填写规则	参数样例
名称	不能为空，必须唯一。	test
spoolDir	待采集的文件所在的目录路径，此参数不能为空。该路径需存在，且对flume 运行用户有读写执行权限。	/srv/BigData/hadoop/data1/zb
trackerDir	flume 采集文件信息元数据保存路径。	/srv/BigData/hadoop/data1/tracker
batch-size	Flume 一次发送数据的最大事件数。	61200
dataDirs	缓冲区数据保存目录，默认为运行目录。配置多个盘上的目录可以提升传输效率，多个目录使用逗号分隔。如果为集群内，则可以指定在如下目录/srv/BigData/hadoop/dataX/flume/data，dataX 为data1~dataN。如果为集群外，则需要单独规划。	/srv/BigData/hadoop/data1/flume/data
checkpointDir	checkpoint 信息保存目录，默认在运行目录下。如果为集群内，则可以指定在如下目录/srv/BigData/hadoop/dataX/flume/checkpoint，dataX 为 data1~dataN。如果为集群外，则需要单独规划。	/srv/BigData/hadoop/data1/flume/checkpoint
transactionCapacity	事务大小：即当前 channel 支持事务处理的事件个数，建议和 Source 的 batchSize 设置为同样大小，不能小于 batchSize。	61200
hostname	要发送数据的主机名或者IP，此参数不能为空。须配置为与之相连的 avro source 所在的主机名或IP。	192.168.108.11
port	avro sink 监测的端口，此参数不能为空。须配置为与之相连的 avro source 监	21154

参数名称	参数值填写规则	参数样例
	测的端口。	
ssl	是否启用 SSL 认证（基于安全要求，建议用户启用此功能）。 只有“Avro”类型的 Source 才有此配置项。 • true 表示启用。 • false 表示不启用。	true
keystore	服务端生成的 flume_cChat.jks 证书。	/opt/flume-client/fusionInsight-flume-1.9.0/conf/flume_cChat.jks
keystore-password	密钥库密码，获取 keystore 信息所需密码。 输入步骤 4.3 中获取的“password”值。	-
truststore	服务端的 SSL 证书信任列表。	/opt/flume-client/fusionInsight-flume-1.9.0/conf/flume_cChatt.jks
truststore-password	信任列表密码，获取 truststore 信息所需密码。 输入步骤 4.3 中获取的“password”值。	-

6. 将“properties.properties”文件上传到 Flume 客户端安装目录下的“flume/conf/”下。

步骤 5 分别生成 MonitorServer 角色服务端和客户端的证书和信任列表。

1. 以 **omm** 用户登录 MonitorServer 角色所在主机。

   进入“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin”目录。

   cd ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/bin

2. 执行以下命令，生成并导出 MonitorServer 角色服务端、客户端证书。

   sh geneJKS.sh -m *密码* **-n** *密码*

   生成的证书在“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf”路径下，其中：

   - “ms_sChat.jks”是 MonitorServer 角色服务端的证书库，“ms_sChat.crt”是“ms_sChat.jks”证书的导出文件，“-m”配置项是证书和证书库的密码；
   - “ms_cChat.jks”是 MonitorServer 角色客户端的证书库，“ms_cChat.crt”是“ms_cChat.jks”证书的导出文件，“-n”配置项是证书和证书库的密码；

- “ms_sChatt.jks”、“ms_cChatt.jks”分别为 MonitorServer 服务端、客户端 SSL 证书信任列表。

步骤 6 配置 MonitorServer 角色服务端参数。

1. 执行以下命令，生成并得到 MonitorServer 服务端密钥库密码、信任列表密码和 keystore-password 加密的私钥信息。连续输入两次密码并确认，该密码是别名为 *mschatserver* 的证书和 *ms_sChat.jks* 证书库的密码。

   ./genPwFile.sh

   cat password.property

2. 使用以下命令打开“${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/service/application.properties”文件。根据表 7-43 中的说明，修改相关参数，并保存退出。

   vi ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/service/application.properties

表7-43 MonitorServer 角色服务端所需修改的参数列表

参数名称	参数值填写规则	参数样例
ssl_need_kspasswd_decrypt_key	是否开启自定义密钥加解密功能（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true
ssl_server_enable	是否启用 SSL 认证（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true
ssl_server_key_store	根据具体的存放位置进行修改。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_sChat.jks
ssl_server_trust_key_store	根据具体的存放位置进行修改。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_sChatt.jks
ssl_server_key_store_password	keystore 密码，根据具体制作证书的实际情况修改（生成证书的明文密钥）。 输入步骤 6.1 中获取的“password”值。	-
ssl_server_trust_key_store_passwor	krustkeystore 密码，根据具体制作证书的实际情况修改（生	-

参数名称	参数值填写规则	参数样例
d	成信任列表的明文密钥）。 输入步骤 6.1 中获取的“password”值。	
ssl_need_client_auth	是否启用客户端认证（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true

3. 重启 MonitorServer 实例。选择“集群 > *待操作集群的名称* > 服务 > Flume > 实例 > MonitorServer”，勾选配置的“MonitorServer”实例，选择“更多 > 重启实例”。输入集群管理员密码，单击“确定”，重启完成后单击“完成”完成操作。

步骤 7 配置 MonitorServer 角色客户端参数。

1. 执行以下命令将生成的客户端证书（ms_cChat.jks）和客户端信任列表（ms_cChatt.jks）复制到客户端的“/opt/flume-client/fusionInsight-flume-1.9.0/conf/”目录下，其中 **10.196.26.1** 为客户端所在节点业务平面的 IP 地址。

   scp ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_cChat.jks user@10.196.26.1:/opt/flume-client/fusionInsight-flume-1.9.0/conf/

   scp ${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_cChatt.jks user@10.196.26.1:/opt/flume-client/fusionInsight-flume-1.9.0/conf/

2. 以 **user** 用户登录 Flume 客户端所在的节点。执行以下命令进入客户端目录“/opt/flume-client/fusionInsight-flume-1.9.0/bin”。

   cd /opt/flume-client/fusionInsight-flume-1.9.0/bin

3. 执行以下命令，生成并得到 MonitorServer 客户端密钥库密码、信任列表密码和 keystore-password 加密的私钥信息。连续输入两次密码并确认，该密码是别名为 *mschatclient* 的证书和 *ms_cChat.jks* 证书库的密码。

   ./genPwFile.sh

   cat password.property

4. 使用以下命令打开“/opt/flume-client/fusionInsight-flume-1.9.0/conf/service/application.properties”文件（“/opt/flume-client/fusionInsight-flume-1.9.0”为客户端安装后的目录）。根据表 7-44 中的说明，修改相关参数，并保存退出。

   vi /opt/flume-client/fusionInsight-flume-1.9.0/conf/service/application.properties

表7-44 MonitorServer 角色客户端所需修改的参数列表

参数名称	参数值填写规则	参数样例
ssl_need_kspassw	是否开启自定义密钥加解密功	true

参数名称	参数值填写规则	参数样例
d_decrypt_key	能（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	
ssl_client_enable	是否启用 SSL 认证（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true
ssl_client_key_store	根据具体的存放位置进行修改。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_cChat.jks
ssl_client_trust_key_store	根据具体的存放位置进行修改。	${BIGDATA_HOME}/FusionInsight_Porter_xxx/install/FusionInsight-Flume-1.9.0/flume/conf/ms_cChatt.jks
ssl_client_key_store_password	keystore 密码，根据具体制作证书的实际情况修改（生成证书的明文密钥）。 输入步骤 7.3 中获取的“password”值。	-
ssl_client_trust_key_store_password	trustkeystore 密码，根据具体制作证书的实际情况修改（生成信任列表的明文密钥）。 输入步骤 7.3 中获取的“password”值。	-
ssl_need_client_auth	是否启用客户端认证（基于安全要求，建议用户启用此功能）。 • true 表示启用。 • false 表示不启用。	true

步骤 8 验证日志是否传输成功。

1. 以具有 HDFS 组件管理权限的用户登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。在 FusionInsight Manager 界面选择“集群 > *待操作集群的名称* > 服务 > HDFS”，单击“NameNode(*节点名称*，主)”对应的链接，打开 HDFS WebUI，然后选择“Utilities > Browse the file system”
2. 观察 HDFS 上“/flume/test”目录下是否有产生数据。

图7-19 查看 HDFS 目录和文件

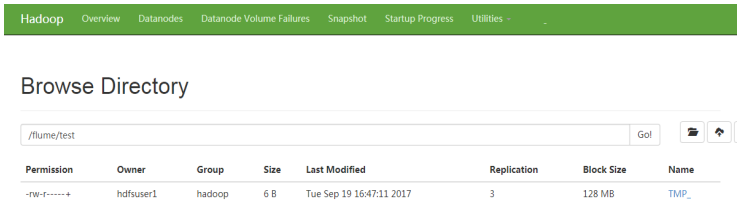

----结束

7.12 查看 Flume 客户端监控信息

操作场景

集群外的 Flume 客户端也是端到端数据采集的一环，与集群内 Flume 服务端一起都需要监控，用户通过 FusionInsight Manager 可以对 Flume 客户端进行监控，可以查看客户端的 Source、Sink、Channel 的监控指标以及客户端的进程状态。

操作步骤

步骤 1 登录 FusionInsight Manager。

步骤 2 选择“集群 > *待操作集群的名称* > 服务 > Flume > Flume 管理”，即可查看当前 Flume 客户端列表及进程状态。

步骤 3 选择“实例 ID”，进入客户端监控列表，在“实时”区域框中，可查看客户端的各监控指标。

步骤 4 选择“历史”进入历史监控数据查询界面。筛选时间段，单击“查看”可显示该时间段内的监控数据。

----结束

7.13 Flume 对接安全 Kafka 指导

操作场景

使用 Flume 客户端对接安全 kafka。

操作步骤

步骤 1 新增 jaas.conf 文件，并保存到“${Flume 客户端安装目录}/conf”下，jaas.conf 文件内容如下：

```
KafkaClient {
com.sun.security.auth.module.Krb5LoginModule required
```

```
useKeyTab=true
keyTab="/opt/test/conf/user.keytab"
principal="flume_hdfs@<系统域名>"
useTicketCache=false
storeKey=true
debug=true;
 };
```

其中 **keyTab** 和 **principal** 的值请按照实际情况配置，所配置的 **principal** 需要有相应的 kafka 的权限。

步骤 2 配置业务，其中 **kafka.bootstrap.servers** 的端口号使用 21007，**kafka.security.protocol** 使用 **SASL_PLAINTEXT**。

步骤 3 如果 Kafka 所在集群的域名发生了更改，需要对${Flume 客户端安装目录}/conf/flume-env.sh 文件中的**-Dkerberos.domain.name** 项的值做修改，具体请根据实际域名进行配置。

步骤 4 上传所配置的 **properties.properties** 文件到${Flume 客户端安装目录}/conf 目录下。

----结束

7.14 Flume 对接安全 Hive 指导

操作场景

使用 Flume 对接集群中的 Hive（3.1.0 版本）。

前置条件

集群正确安装了 Flume 服务和 Hive 服务，且服务正常无告警异常。

操作步骤

步骤 1 使用 **omm** 用户将如下 jar 包导入到需要测试的 Flume 实例的 lib 目录下（客户端/服务端），列表如下：

- antlr-*版本号*.jar
- antlr-runtime-*版本号*.jar
- calcite-core-*版本号*.jar
- hadoop-mapreduce-client-core-*版本号*.jar
- hive-beeline-*版本号*.jar
- hive-cli-*版本号*.jar
- hive-common-*版本号*.jar
- hive-exec-*版本号*.jar
- hive-hcatalog-core-*版本号*.jar
- hive-hcatalog-pig-adapter-*版本号*.jar
- hive-hcatalog-server-extensions-*版本号*.jar

- hive-hcatalog-streaming-*版本号*.jar
- hive-metastore-*版本号*.jar
- hive-service-*版本号*.jar
- libfb303-*版本号*.jar
- hadoop-plugins-*版本号*.jar

相关 jar 包可从 Hive 安装目录中获取，重启对应的 Flume 进程，保证 jar 包加载到运行环境中。

步骤 2 配置 Hive 配置项。

在 FusionInsight Manager 界面，选择“集群 > 服务 > Hive > 配置 > 全部配置 > HiveServer（角色） > 自定义 > hive.server.customized.configs”，添加如下参数：

表7-45 hive.server.customized.configs 参数值配置

名称	值
hive.support.concurrency	true
hive.exec.dynamic.partition.mode	nonstrict
hive.txn.manager	org.apache.hadoop.hive.ql.lockmgr.DbTxnManager
hive.compactor.initiator.on	true
hive.compactor.worker.threads	1

步骤 3 准备具备 supergroup 和 Hive 权限的系统用户 flume_hive，安装客户端并创建所需的 Hive 表。

示例如下：

1. 正确安装集群客户端，例如安装目录为“/opt/client”。
2. 执行以下命令完成用户认证。

   cd /opt/client

   source bigdata_env

   kinit flume_hive
3. 执行 **beeline** 命令，然后执行以下建表语句。

```
create table flume_multi_type_part(id string, msg string)
partitioned by (country string, year_month string, day string)
clustered by (id) into 5 buckets
stored as orc TBLPROPERTIES('transactional'='true');
```

4. 执行 **select * from** *表名*命令**;**，查询表中数据。

   此时表中数据量为 0 行。

步骤 4 准备相关配置文件，假设下载的客户端安装包在“/opt/FusionInsight_Cluster_1_Services_ClientConfig”。

1. 从“${*客户端解压目录*}/Hive/config”目录获取以下文件：
   - hivemetastore-site.xml
   - hive-site.xml
2. 从“${*客户端解压目录*}/HDFS/config”目录下获取以下文件：

   core-site.xml
3. 在 Flume 实例启动的机器上创建目录，将准备好的上述文件放置在创建的目录下。

   例如：“/opt/hivesink-conf/hive-site.xml”。
4. 将“hivemetastore-site.xml”文件中的所有 property 配置，拷贝至“hive-site.xml”，并保证处于原有配置之前。

   因为 hive 内部加载有顺序。

说明

保证配置文件所在的目录对于 Flume 运行用户 **omm** 有读写权限。

步骤 5 结果观察。

在 Hive 的客户端执行，**select * from** *表名*;查看对应的数据是否已经写入到 Hive 表中。

----结束

参考实例

Flume 配置参考示例（SpoolDir--Mem--Hive）：

```
server.sources = spool_source
server.channels = mem_channel
server.sinks = Hive_Sink

#config the source
server.sources.spool_source.type = spooldir
server.sources.spool_source.spoolDir = /tmp/testflume
server.sources.spool_source.montime =
server.sources.spool_source.fileSuffix =.COMPLETED
server.sources.spool_source.deletePolicy = never
server.sources.spool_source.trackerDir =.flumespool
server.sources.spool_source.ignorePattern = ^$
server.sources.spool_source.batchSize = 20
server.sources.spool_source.inputCharset =UTF-8
server.sources.spool_source.selector.type = replicating
server.sources.spool_source.fileHeader = false
server.sources.spool_source.fileHeaderKey = file
server.sources.spool_source.basenameHeaderKey= basename
server.sources.spool_source.deserializer = LINE
server.sources.spool_source.deserializer.maxBatchLine= 1
server.sources.spool_source.deserializer.maxLineLength= 2048
server.sources.spool_source.channels = mem_channel

#config the channel
server.channels.mem_channel.type = memory
server.channels.mem_channel.capacity =10000
```

```
server.channels.mem_channel.transactionCapacity= 2000
server.channels.mem_channel.channelfullcount= 10
server.channels.mem_channel.keep-alive = 3
server.channels.mem_channel.byteCapacity =
server.channels.mem_channel.byteCapacityBufferPercentage= 20

#config the sink
server.sinks.Hive_Sink.type = hive
server.sinks.Hive_Sink.channel = mem_channel
server.sinks.Hive_Sink.hive.metastore = thrift://${任意 metastore 业务 IP}:21088
server.sinks.Hive_Sink.hive.hiveSite = /opt/hivesink-conf/hive-site.xml
server.sinks.Hive_Sink.hive.coreSite = /opt/hivesink-conf/core-site.xml
server.sinks.Hive_Sink.hive.metastoreSite = /opt/hivesink-conf/hivemeatastore-
site.xml
server.sinks.Hive_Sink.hive.database = default
server.sinks.Hive_Sink.hive.table = flume_multi_type_part
server.sinks.Hive_Sink.hive.partition = Tag,%Y-%m,%d
server.sinks.Hive_Sink.hive.txnsPerBatchAsk= 100
server.sinks.Hive_Sink.hive.autoCreatePartitions= true
server.sinks.Hive_Sink.useLocalTimeStamp = true
server.sinks.Hive Sink.batchSize = 1000
server.sinks.Hive Sink.hive.kerberosPrincipal= super1
server.sinks.Hive Sink.hive.kerberosKeytab= /opt/mykeytab/user.keytab
server.sinks.Hive Sink.round = true
server.sinks.Hive Sink.roundValue = 10
server.sinks.Hive Sink.roundUnit = minute
server.sinks.Hive Sink.serializer = DELIMITED
server.sinks.Hive_Sink.serializer.delimiter= ";"
server.sinks.Hive_Sink.serializer.serdeSeparator= ';'
server.sinks.Hive_Sink.serializer.fieldnames= id,msg
```

7.15 Flume 业务模型配置指导

7.15.1 概述

本任务旨在提供 Flume 常用模块的性能差异，用于指导用户进行合理的 Flume 业务配置，避免出现前端 Source 和后端 Sink 性能不匹配进而导致整体业务性能不达标的场景。

本任务只针对于单通道的场景进行比较说明。

7.15.2 业务模型配置指导

Flume 业务配置及模块选择过程中，一般要求 Sink 的极限吞吐量需要大于 Source 的极限吞吐量，否则在极限负载的场景下，Source 往 Channel 的写入速度大于 Sink 从 Channel 取出的速度，从而导致 Channel 频繁被写满，进而影响性能表现。

Avro Source 和 Avro Sink 一般都是成对出现，用于多个 Flume Agent 间进行数据中转，因此一般场景下 Avro Source 和 Avro Sink 都不会成为性能瓶颈。

模块间性能

根据模块间极限性能对比，可以看到对于前端是 SpoolDir Source 的场景下，Kafka Sink 和 HDFS Sink 都能满足吞吐量要求，但是 HBase Sink 由于自身写入性能较低的原因，会成为性能瓶颈，会导致数据都积压在 Channel 中。但是如果有必须使用 HBase Sink 或者其他性能容易成为瓶颈的 Sink 的场景时，可以选择使用 **Channel Selector** 或者 **Sink Group** 来满足性能要求。

Channel Selector

Channel Selector 可以允许一个 Source 对接多个 Channel，通过选择不同的 Selector 类型来将 Source 的数据进行分流或者复制，目前 Flume 提供的 Channel Selector 有两种：Replicating 和 Multiplexing。

Replicating：表示 Source 的数据同步发送给所有 Channel。

Multiplexing：表示根据 Event 中的 Header 的指定字段的值来进行判断，从而选择相应的 Channel 进行发送，从而起到根据业务类型进行分流的目的。

- Replicating 配置样例：

```
client.sources = kafkasource
client.channels = channel1 channel2
client.sources.kafkasource.type = org.apache.flume.source.kafka.KafkaSource
client.sources.kafkasource.kafka.topics = topic1,topic2
client.sources.kafkasource.kafka.consumer.group.id = flume
client.sources.kafkasource.kafka.bootstrap.servers = 10.69.112.108:21007
client.sources.kafkasource.kafka.security.protocol = SASL_PLAINTEXT
client.sources.kafkasource.batchDurationMillis = 1000
client.sources.kafkasource.batchSize = 800
client.sources.kafkasource.channels = channel1 c el2

client.sources.kafkasource.selector.type = replicating
client.sources.kafkasource.selector.optional = channel2
```

表7-46 Replicating 配置样例参数说明

选项名称	默认值	描述
Selector.type	replicating	Selector 类型，应配置为 replicating
Selector.optional	-	可选 Channel，可以配置为列表

- Multiplexing 配置样例：

```
client.sources = kafkasource
client.channels = channel1 channel2
client.sources.kafkasource.type = org.apache.flume.source.kafka.KafkaSource
client.sources.kafkasource.kafka.topics = topic1,topic2
client.sources.kafkasource.kafka.consumer.group.id = flume
client.sources.kafkasource.kafka.bootstrap.servers = 10.69.112.108:21007
client.sources.kafkasource.kafka.security.protocol = SASL_PLAINTEXT
```

```
client.sources.kafkasource.batchDurationMillis = 1000
client.sources.kafkasource.batchSize = 800
client.sources.kafkasource.channels = channel1 channel2

client.sources.kafkasource.selector.type = multiplexing
client.sources.kafkasource.selector.header = myheader
client.sources.kafkasource.selector.mapping.topic1 = channel1
client.sources.kafkasource.selector.mapping.topic2 = channel2
client.sources.kafkasource.selector.default = channel1
```

表7-47 Multiplexing 配置样例参数说明

选项名称	默认值	描述
Selector.type	replicating	Selector 类型，应配置为 multiplexing
Selector.header	Flume.selector.header	-
Selector.default	-	-
Selector.mapping.*	-	-

Multiplexing 类型的 Selector 的样例中，选择 Event 中 Header 名称为 topic 的字段来进行判断，当 Header 中 topic 字段的值为 topic1 时，向 channel1 发送该 Event，当 Header 中 topic 字段的值为 topic2 时，向 channel2 发送该 Event。

这种 Selector 需要借助 Source 中 Event 的特定 Header 来进行 Channel 的选择，需要根据业务场景选择合理的 Header 来进行数据分流。

SinkGroup

当后端单 Sink 性能不足、需要高可靠性保证或者异构输出时可以使用 Sink Group 来将指定的 Channel 和多个 Sink 对接，从而满足相应的使用场景。目前 Flume 提供了两种 Sink Processor 用于对 Sink Group 中的 Sink 进行管理：Load Balancing 和 Failover。

Failover：表示在 Sink Group 中同一时间只有一个 Sink 处于活跃状态，其他 Sink 作为备份处于非活跃状态，当活跃状态的 Sink 故障时，根据优先级从非活跃状态的 Sink 中选择一个来接管业务，保证数据不会丢失，多用于高可靠性场景。

Load Balancing：表示在 Sink Group 中所有 Sink 都处于活跃状态，每个 Sink 都会从 Channel 中去获取数据并进行处理，并且保证在运行过程中该 Sink Group 的所有 Sink 的负载是均衡的，多用于性能提升场景。

- Load Balancing 配置样例：

```
client.sources = source1
client.sinks = sink1 sink2
client.channels = channel1

client.sinkgroups = g1
client.sinkgroups.g1.sinks = sink1 sink2
client.sinkgroups.g1.processor.type = load_balance
client.sinkgroups.g1.processor.backoff = true
```

```
client.sinkgroups.g1.processor.selector = random

client.sinks.sink1.type = logger
client.sinks.sink1.channel = channel1

client.sinks.sink2.type = logger
client.sinks.sink2.channel = channel1
```

表7-48 Load Balancing 配置样例参数说明

选项名称	默认值	描述
sinks	-	Sink Group 的 sink 列表，多个以空格分隔
processor.type	default	Processor 的类型，应配置为 load_balance
processor.backoff	false	是否以指数的形式退避失败的 Sinks
processor.selector	round_robin	选择机制。必须是 round_robin，random 或者自定义的类，且该类继承了 AbstractSinkSelector
processor.selector.maxTimeOut	30000	屏蔽故障 sink 的时间，默认是 30000 毫秒

- Failover 配置样例：

```
client.sources = source1
client.sinks = sink1 sink2
client.channels = channel1

client.sinkgroups = g1
client.sinkgroups.g1.sinks = sink1 sink2
client.sinkgroups.g1.processor.type = failover
client.sinkgroups.g1.processor.priority.sink1 = 10
client.sinkgroups.g1.processor.priority.sink2 = 5
client.sinkgroups.g1.processor.maxpenalty = 10000

client.sinks.sink1.type = logger
client.sinks.sink1.channel = channel1

client.sinks.sink2.type = logger
client.sinks.sink2.channel = channel1
```

表7-49 **Failover** 配置样例参数说明

选项名称	默认值	描述
sinks	-	Sink Group 的 sink 列表，多个以空格分隔

选项名称	默认值	描述
processor.type	default	Processor 的类型，应配置为 failover
processor.priority.<sinkName>	-	优先级值。<sinkName> 必须是 sinks 中有定义的。优先级值高 Sink 会更早被激活。值越大，优先级越高。**注：**多个 sinks 的话，优先级的值不要相同，如果优先级相同的话，只会有一个生效。
processor.maxpenalty	30000	失败的 Sink 最大的退避时间(单位：毫秒)

Interceptors

Flume 的拦截器（Interceptor）支持在数据传输过程中修改或丢弃传输的基本单元 Event。用户可以通过在配置中指定 Flume 内建拦截器的类名列表，也可以开发自定义的拦截器来实现 Event 的修改或丢弃。Flume 内建支持的拦截器如下表所示，本章节会选取一个较为复杂的作为示例。其余的用户可以根据需要自行配置使用。

说明

1. 拦截器用在 Flume 的 Source、Channel 之间，大部分的 Source 都带有 Interceptor 参数。用户可以依据需要配置。
2. Flume 支持一个 Source 配置多个拦截器，各拦截器名称用空格分开。
3. 指定拦截器的顺序就是它们被调用的顺序。
4. 使用拦截器在 Header 中插入的内容，都可以在 Sink 中读取并使用。

表7-50 Flume 内建支持的拦截器类型

拦截器类型	简要描述
Timestamp Interceptor	该拦截器会在 Event 的 Header 中插入一个时间戳。
Host Interceptor	该拦截器会在 Event 的 Header 中插入当前 Agent 所在节点的 IP 或主机名。
Remove Header Interceptor	该拦截器会依据 Header 中包含的符合正则匹配的字符串，丢弃掉对应的 Event。
UUID Interceptor	该拦截器会为每个 Event 的 Header 生成一个 UUID 字符串。
Search and Replace Interceptor	该拦截器基于 Java 正则表达式提供简单的基于字符串的搜索和替换功能。与 Java Matcher.replaceAll() 的规则相同。
Regex Filtering Interceptor	该拦截器通过将 Event 的 Body 体解释为文本文件，与配置的正则表达式进行匹配来选择性的过滤 Event。提供的正则表达式可用于排除或包含事件。
Regex Extractor Interceptor	该拦截器使用正则表达式抽取原始 events 中的内容，并将该内容加入 events 的 header 中。

下面以 Regex Filtering Interceptor 为例说明 Interceptor 使用（其余的可参考官网配置）：

表7-51 Regex Filtering Interceptor 配置参数说明

选项名称	默认值	描述
type	-	组件类型名称，必须写为 regex_filter。
regex	-	用于匹配事件的正则表达式。
excludeEvents	false	默认收集匹配到的 Event。设置为 true，则会删除匹配的 Event，保留不匹配的。

配置示例（为了方便观察，此模型使用了 netcat tcp 作为 Source 源，logger 作为 Sink）。配置好如下参数后，在 Linux 的配置的主机节点上执行 Linux 命令“telnet *主机名或 IP* 44444”，并任意敲入符合正则和不符合正则的字符串。会在日志中观察到，只有匹配到的字符串被传输了。

```
#define the source、channel、sink
server.sources = r1

server.channels = c1
server.sinks = k1

#config the source
server.sources.r1.type = netcat
server.sources.r1.bind = ${主机 IP}
server.sources.r1.port = 44444
server.sources.r1.interceptors= i1
server.sources.r1.interceptors.i1.type= regex_filter
server.sources.r1.interceptors.i1.regex= (flume)|(myflume)
server.sources.r1.interceptors.i1.excludeEvents= false
server.sources.r1.channels = c1

#config the channel
server.channels.c1.type = memory
server.channels.c1.capacity = 1000
server.channels.c1.transactionCapacity = 100
#config the sink
server.sinks.k1.type = logger
server.sinks.k1.channel = c1
```

7.16 Flume 日志介绍

日志描述

日志路径：Flume 相关日志的默认存储路径为“/var/log/Bigdata/角色名”。

- FlumeServer：“/var/log/Bigdata/flume/flume”
- FlumeClient：“/var/log/Bigdata/flume-client-n/flume”
- MonitorServer：“/var/log/Bigdata/flume/monitor”

日志归档规则：Flume 日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 50MB 的时候，会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”。最多保留最近的 20 个压缩文件，压缩文件保留个数可以在 Manager 界面中配置。

表7-52 Flume 日志列表

日志类型	日志文件名	描述
运行日志	/flume/flumeServer.log	FlumeServer 运行环境信息日志。
	/flume/install.log	FlumeServer 安装日志。
	/flume/flumeServer-gc.log.<编号>	FlumeServer 进程的 GC 归档日志。
	/flume/prestartDvietail.log	Flume 启动前的工作日志。
	/flume/startDetail.log	Flume 进程启动工作日志。
	/flume/stopDetail.log	Flume 进程停止日志。
	/monitor/monitorServer.log	MonitorServer 运行环境信息日志。
	/monitor/startDetail.log	MonitorServer 进程启动工作日志。
	/monitor/stopDetail.log	MonitorServer 进程停止日志。
	function.log	外部函数调用日志。
	/flume/flume-*用户名-日期-pid*-gc.log	Flume 进程的 GC 日志。
	/flume/Flume-audit.log	Flume 客户端的审计日志。
	/flume/startAgent.out	Flume 启动前的进程参数日志。
堆栈信息日志（MRS 3.2.0 及以后版本）	threadDump-<DATE>.log	NodeAgent 下发停止服务指令时打印 jstack 日志。

日志级别

Flume 提供了如表 7-53 所示的日志级别。

运行日志的级别优先级从高到低分别是 FATAL、ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表7-53 日志级别

日志类型	级别	描述
运行日志	FATAL	FATAL 表示系统运行的致命错误信息。
	ERROR	ERROR 表示系统运行的错误信息。
	WARN	WARN 表示当前事件处理存在异常信息。
	INFO	INFO 表示记录系统及各事件正常运行状态信息。
	DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

步骤 2 请参考 25.1 修改集群服务配置参数，进入 Flume 的“全部配置”页面。

步骤 3 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 4 选择所需修改的日志级别。

步骤 5 保存配置，在弹出窗口中单击“确定”使配置生效。

----结束

说明

配置完成后即生效，不需要重启服务。

日志格式

Flume 的日志格式如下所示：

表7-54 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2014-12-12 11:54:57,316 | INFO | [main] | log4j dynamic load is start. | org.apache.flume.tools.LogDynamicLoad.start(LogDynamicLoad.java:59)

日志类型	格式	示例
	<yyyy-MM-dd HH:mm:ss,SSS><User Name><User IP><Time><Operation><Resource><Result><Detail>	2014-12-12 23:04:16,572 | INFO | [SinkRunner-PollingRunner-DefaultSinkProcessor] | SRCIP=null OPERATION=close

7.17 Flume 客户端 Cgroup 使用指导

操作场景

该操作指导用户加入、退出 Cgroup，查询 Cgroup 状态以及更改 Cgroup cpu 阈值。

操作步骤

- **加入 Cgroup**

  执行以下命令，加入 Cgroup，假设 Flume 客户端安装路径为“/opt/FlumeClient”，Cgroup cpu 阈值设置为 50%：

  cd /opt/FlumeClient/fusioninsight-flume-1.9.0/bin

  ./flume-manage.sh cgroup join 50

  说明

  - 该命令不仅可以加入 Cgroup，同时也可以更改 Cgroup cpu 阈值。
  - Cgroup cpu 阈值取值范围为 1~100*N 之间的整数，N 表示机器 cpu 核数。

- **查询 Cgroup 状态**

  执行以下命令，查询 Cgroup 状态，假设 Flume 客户端安装路径为“/opt/FlumeClient”：

  cd /opt/FlumeClient/fusioninsight-flume-1.9.0/bin

  ./flume-manage.sh cgroup status

- **退出 Cgroup**

  执行以下命令，退出 Cgroup，假设 Flume 客户端安装路径为“/opt/FlumeClient”：

  cd /opt/FlumeClient/fusioninsight-flume-1.9.0/bin

  ./flume-manage.sh cgroup exit

  说明

  - 客户端安装完成后，会自动创建默认 Cgroup。若安装客户端时未配置“-s”参数，则默认值为“-1”，表示 agent 进程不受 cpu 使用率限制。
  - 加入、退出 Cgroup 时，agent 进程不受影响。若 agent 进程未启动，加入、退出 Cgroup 仍然可以成功执行，待下一次 agent 启动时生效。
  - 客户端卸载完成后，安装时期创建的 Cgroup 会自动删除。

7.18 Flume 第三方插件二次开发指导

操作场景

该操作指导用户进行第三方插件二次开发。

前提条件

- 第三方 jar 包。
- 已成功安装 Flume 服务端或者客户端，如安装目录为“/opt/flumeclient”。

操作步骤

将自主研发的代码打成 jar 包。

步骤 1 建立插件目录布局。

1. 进入“*Flume 客户端安装目录*/fusionInsight-flume-*/plugins.d”路径下，使用以下命令建立目录，可根据实际业务进行命名，无固定名称：

   cd /opt/flumeclient/fusioninsight-flume-1.9.0/plugins.d

   mkdir thirdPlugin

   cd thirdPlugin

   mkdir lib libext native

   显示结果如下：

   ```
   [root@ plugins.d]#mkdir thirdPlugin
   [root@ plugins.d]#ll
   total 8
   drwxr-x--- 3 root root 4096  native
   drwxr-xr-x 2 root root 4096  thirdPlugin
   [root@ plugins.d]#cd thirdPlugin/
   [root@ thirdPlugin]#mkdir lib libext native
   [root@ thirdPlugin]#ll
   total 12
   drwxr-xr-x 2 root root 4096  lib
   drwxr-xr-x 2 root root 4096  libext
   drwxr-xr-x 2 root root 4096  native
   [root@ thirdPlugin]#
   ```

2. 将第三方 jar 包放入“*Flume 客户端安装目录*/fusionInsight-flume-*/plugins.d/thirdPlugin/lib”路径下，若该 jar 包依赖其他 jar 包，则将所依赖的 jar 包放入“*Flume 客户端安装目录*/fusionInsight-flume-*/plugins.d/thirdPlugin/libext”文件夹中，“*Flume 客户端安装目录*/fusionInsight-flume-*/plugins.d/thirdPlugin/native”放置本地库文件。

步骤 2 配置“*Flume 客户端安装目录*/fusionInsight-flume-*/conf/properties.properties”文件。

具体 **properties.properties** 参数配置方法，参考 7.10 非加密传输和 7.11 加密传输对应典型场景中 **properties.properties** 文件参数列表的说明。

----结束

7.19 Flume 常见问题

Flume 日志保存在/var/log/Bigdata/flume/flume/flumeServer.log 里。绝大多数数据传输异常、数据传输不成功，在日志里都可以看到提示。可以直接输入以下命令查看：

tailf /var/log/Bigdata/flume/flume/flumeServer.log

- 问题：当配置文件上传后，发现异常，重新上传配置文件，发现仍然没有满足场景要求，但日志上没有任何异常。

  解决方法：重启此 flume 进程，**kill -9** *进程代码*，再看日志。

- 问题：连接 HDFS 出现 java.lang.IllegalArgumentException: Keytab is not a readable file: /opt/test/conf/user.keytab。

  解决方法：添加 Flume 运行用户读写权限。

- 问题：执行 Flume 客户端连接 Kafka 报如下错误：

  ```
  Caused by: java.io.IOException: /opt/FlumeClient/fusioninsight-flume-1.9.0/cof//jaas.conf (No such file or directory)
  ```

  解决方法：新增 jaas.conf 配置文件并保存到 flume client 的 conf 路径下。

  vi jaas.conf

  ```
  KafkaClient {
  com.sun.security.auth.module.Krb5LoginModule required
  useKeyTab=true
  keyTab="/opt/test/conf/user.keytab"
  principal="flume_hdfs@<系统域名>"
  useTicketCache=false
  storeKey=true
  debug=true;
  };
  ```

  参数 keyTab 和 principal 根据实际情况修改。

- 问题：执行 Flume 客户端连接 HBase 报如下错误：

  ```
  Caused by: java.io.IOException: /opt/FlumeClient/fusioninsight-flume-1.9.0/cof//jaas.conf (No such file or directory)
  ```

  解决方法：新增 jaas.conf 配置文件并保存到 flume client 的 conf 路径下。

  vi jaas.conf

  ```
  Client {
  com.sun.security.auth.module.Krb5LoginModule required
  useKeyTab=true
  keyTab="/opt/test/conf/user.keytab"
  principal="flume_hbase@<系统域名>"
  useTicketCache=false
  storeKey=true
  debug=true;
  };
  ```

  参数 keyTab 和 principal 根据实际情况修改。

- 问题：一旦提交配置文件后，flume agent 即在占用资源运行，如何恢复到没有上传配置文件的状态？

  解决方法：提交一个内容为空的 properties.properties 文件。

8 使用 HBase

8.1 从零开始使用 HBase

HBase 是一个高可靠性、高性能、面向列、可伸缩的分布式存储系统。本章节提供从零开始使用 HBase 的操作指导，在集群 Master 节点中更新客户端，通过客户端实现创建表，往表中插入数据，修改表，读取表数据，删除表中数据以及删除表的功能。

背景信息

假定用户开发一个应用程序，用于管理企业中的使用 A 业务的用户信息，使用 HBase 客户端实现 A 业务操作流程如下：

- 创建用户信息表 user_info。
- 在用户信息中新增用户的学历、职称信息。
- 根据用户编号查询用户姓名和地址。
- 根据用户姓名进行查询。
- 用户销户，删除用户信息表中该用户的数据。
- A 业务结束后，删除用户信息表。

表8-1 用户信息

编号	姓名	性别	年龄	地址
12005000201	A	男	19	A 城市
12005000202	B	女	23	B 城市
12005000203	C	男	26	C 城市
12005000204	D	男	18	D 城市
12005000205	E	女	21	E 城市
12005000206	F	男	32	F 城市
12005000207	G	女	29	G 城市

编号	姓名	性别	年龄	地址
12005000208	H	女	30	H 城市
12005000209	I	男	26	I 城市
12005000210	J	男	25	J 城市

前提条件

已安装客户端，例如安装目录为“/opt/client”。以下操作的客户端目录只是举例，请根据实际安装目录修改。在使用客户端前，需要先下载并更新客户端配置文件，确认 Manager 的主管理节点后才能使用客户端。

操作步骤

在主管理节点使用客户端。

1. 以客户端安装用户登录客户端安装节点，执行以下命令切换到客户端目录。

   cd /opt/client

2. 执行以下命令配置环境变量。

   source bigdata_env

3. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 HBase 表的权限。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

   kinit *MRS 集群用户*

   例如，**kinit hbaseuser**。

4. 直接执行 HBase 组件的客户端命令。

   hbase shell

步骤 1 运行 HBase 客户端命令，实现 A 业务。

1. 根据表 8-1 创建用户信息表 user_info 并添加相关数据。

   create '*user_info*',{**NAME** => 'i'}

   以增加编号 12005000201 的用户信息为例，其他用户信息参照如下命令依次添加：

   put '*user_info*','*12005000201*','***i:name***','*A*'

   put '*user_info*','*12005000201*','***i:gender***','*Male*'

   put '*user_info*','*12005000201*','***i:age***','*19*'

   put '*user_info*','*12005000201*','***i:address***','*City A*'

2. 在用户信息表 user_info 中新增用户的学历、职称信息。

   以增加编号为 12005000201 的用户的学历、职称信息为例，其他用户类似。

   put '*user_info*','*12005000201*','**i:degree**','*master*'

   put '*user_info*','*12005000201*','**i:pose**','*manager*'

3. 根据用户编号查询用户姓名和地址。

以查询编号为 12005000201 的用户姓名和地址为例，其他用户类似。

scan'*user_info*',{**STARTROW**=>'*12005000201*',**STOPROW**=>'*12005000201*',**COLUMNS**=>['**i:name**','**i:address**']}

4. 根据用户姓名进行查询。

   以查询 A 用户信息为例，其他用户类似。

   scan'*user_info*',{**FILTER**=>"SingleColumnValueFilter('i','name',=,'binary:*A*')"}

5. 删除用户信息表中该用户的数据。

   所有用户的数据都需要删除，以删除编号为 12005000201 的用户数据为例，其他用户类似。

   - 依次删除编号为 12005000201 的用户的所有数据字段，以删除“age”字段为例：

     delete '*user_info*','*12005000201*','i:age'

   - 删除编号为 12005000201 的用户的所有数据：

     deleteall '*user_info*','*12005000201*'

6. 删除用户信息表。

   disable'*user_info*'

   drop '*user_info*'

----结束

8.2 使用 HBase 客户端

操作场景

该任务指导用户在运维场景或业务场景中使用 HBase 客户端。

前提条件

- 已安装客户端。例如安装目录为“/opt/hadoopclient”，以下操作的客户端目录只是举例，请根据实际安装目录修改。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建。

  “机机”用户需要下载 keytab 文件，“人机”用户第一次登录时需修改密码。
- 非 **root** 用户使用 HBase 客户端，请确保该 HBase 客户端目录的属主为该用户，否则请参考如下命令修改属主。

  chown user:group -R *客户端安装目录*/**HBase**

使用 HBase 客户端

以客户端安装用户，登录安装客户端的节点。

步骤 1 执行以下命令切换到客户端目录。

cd /opt/hadoopclient

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 HBase 表的权限。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

kinit *组件业务用户*

例如，**kinit hbaseuser**。

步骤 4 直接执行 HBase 组件的客户端命令。

hbase shell

----结束

HBase 客户端常用命令

常用的 HBase 客户端命令如下表所示。

表8-2 HBase 客户端命令

命令	说明
create	创建一张表，例如 **create 'test', 'f1', 'f2', 'f3'**。
disable	停止指定的表，例如 **disable 'test'**。
enable	启动指定的表，例如 **enable 'test'**。
alter	更改表结构。可以通过 alter 命令增加、修改、删除列族信息以及表相关的参数值，例如 **alter 'test', {NAME => 'f3', METHOD => 'delete'}**。
describe	获取表的描述信息，例如 **describe 'test'**。
drop	删除指定表。删除前表必须已经是停止状态，例如 **drop 'test'**。
put	写入指定 cell 的 value。Cell 的定位由表、rowk、列组合起来唯一决定，例如 **put 'test','r1','f1:c1','myvalue1'**。
get	获取行的值或者行的指定 cell 的值。例如 **get 'test','r1'**。
scan	查询表数据。参数中指定表名和 scanner，例如 **scan 'test'**。

8.3 创建 HBase 角色

操作场景

该任务指导 MRS 集群管理员在 Manager 创建并设置 HBase 的角色。HBase 角色可设置 HBase 管理员权限以及 HBase 表和列族的读（R）、写（W）、创建（C）、执行（X）或管理（A）权限。

用户需要在 HBase 中对指定的数据库或表设置权限，才能够创建表、查询数据、删除数据、插入数据、更新数据以及授权他人访问 HBase 表。

说明

- 安全模式支持创建 HBase 角色，普通模式不支持创建 HBase 角色。
- 如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.9 添加 HBase 的 Ranger 访问权限策略。

前提条件

- MRS 集群管理员已明确业务需求。
- 已登录 Manager。

操作步骤

在 Manager 界面，选择“系统 > 权限 > 角色”。

步骤 1 单击“添加角色”，然后在“角色名称”和“描述”输入角色名字与描述。

步骤 2 设置角色“配置资源权限”请参见表 8-3。

HBase 权限：

- HBase Scope：对 HBase 表授权，最小支持设置列的读（R）和写（W）权限。
- HBase 管理员权限：HBase 管理员权限。

说明

用户对自己创建的表具有读（R）、写（W）、创建（C）、执行（X）或管理（A）权限。

表8-3 设置角色

任务场景	角色授权操作
设置 HBase 管理员权限	在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase”，勾选“HBase 管理员权限”。
设置用户创建表的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope”。 2. 单击“global”。 3. 在指定命名空间的“权限”列，勾选“创建”和“执行”。例如勾选默认命名空间“default”的“创建”和“执行”。
设置用户写入数据的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global”。 2. 在指定命名空间的“权限”列，勾选“写”。例如勾选默认命名空间“default”的“写”。HBase 子对象默认可从父对象继承权限，此时已授予向命名空间中的表写入数据的权限。
设置用户读取数据的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global”。

任务场景	角色授权操作
	2. 在指定命名空间的“权限”列，勾选“读”。例如勾选默认命名空间“default”的“读”。HBase 子对象默认可从父对象继承权限，此时已授予从命名空间中的表读取数据的权限。
设置用户管理命名空间或表的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global”。 2. 在指定命名空间的“权限”列，勾选“管理”。例如勾选默认命名空间“default”的“管理”。
设置列的读取或写入权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global”，单击指定命名空间显示命名空间的表。 2. 单击指定的表。 3. 单击指定的列族。 4. 确认是否是新建角色？ • 是，在“资源名称”的输入框输入列名称，多个列用英文逗号分隔，勾选“读”或“写”。如果 HBase 表中不存在同名的列，则创建同名的列后角色将拥有该列的权限。列权限设置完成。 • 否，修改已有 HBase 角色的列权限，表格将显示已单独设置权限的列，执行步骤 3.5。 5. 角色新增列权限，在“资源名称”的输入框输入列名称并设置列的权限。角色修改列权限，可以在“资源名称”的输入框输入列名称并设置列权限，也可以在表格中直接修改列的权限。若在表格中修改了列权限，又同时增加了同名的列权限，则无法保存。角色修改列权限，建议直接修改列的权限。支持搜索功能。

步骤 3 单击“确定”完成，返回“角色”。

----结束

8.4 配置 HBase 备份

操作场景

HBase 集群备份作为提高 HBase 集群系统高可用性的一个关键特性，为 HBase 提供了实时的异地数据备份功能。它对外提供了基础的运维工具，包含主备关系维护、重建，数据校验，数据同步进展查看等功能。为了实现数据的实时备份，可以把本 HBase 集群中的数据备份到另一个集群。

前提条件

- 主备集群都已经安装并启动成功（在 Console 页面“现有集群”页签，查看集群状态为“运行中”），且获取集群的管理员权限。
- 必须保证主备集群间的网络畅通和端口的使用。
- 主备集群必须已配置跨集群互信。
- 如果主集群上有历史数据，需要同步到备集群上，那么主备集群必须配置跨集群拷贝，请参见 8.5 启用集群间拷贝功能。
- 主备集群上的时间必须一致，而且主备集群上的 NTP 服务必须使用同一个时间源。
- 必须在主备集群中的“/etc/hosts”文件中，配置**主备集群所有机器**的机器名与业务 IP 地址的对应关系。配置方式为在 hosts 文件中追加"192.***.***.*** host1"。
- 主备集群间的网络带宽需要根据业务流量而定，不应少于最大的可能业务流量。

使用约束

- 尽管备份提供了实时的数据复制功能，但实际的数据同步进展，由多方面的因素决定的，例如，当前主集群业务的繁忙程度，备集群进程的健康状态等。因此，在正常情形下，备集群不应该接管业务。极端情形下是否可以接管业务，可由系统维护人员以及决策人员根据当前的数据同步指标来决定。
- 备份功能当前仅支持一主一备。
- 通常情况下，不允许对备集群的同步表进行表级别的操作，例如修改表属性、删除表等，一旦误操作备集群后会造成主集群数据同步失败、备集群对应表的数据丢失。
- 主集群的 HBase 表已启用备份功能同步数据，用户每次修改表的结构时，需要手动修改备集群的同步表结构，保持与主集群表结构一致。

操作步骤

启用主集群的备份功能来同步 put 方式写入的数据

登录 MRS 控制台，单击集群名称，选择“组件管理”。

步骤 1 进入 HBase 服务参数“全部配置”界面，具体操作请参考 25.1 修改集群服务配置参数。

说明

若集群详情页面没有“组件管理”页签，请先完成 IAM 用户同步（在集群详情页的“概览”页签，单击“IAM 用户同步”右侧的“同步”进行 IAM 用户同步）。

步骤 2 （可选）如表 8-4 所示，为 HBase 备份操作过程中的可选配置项，您可以根据描述来进行参数配置，或者使用缺省提供的值。

表8-4 可选配置项

配置入口	配置项	默认值	描述
“HMaster >	hbase.master.logcleaner.ttl	600000	HLog 文件生存时间。如果配置值为“604800000”（单位：毫

配置入口	配置项	默认值	描述
性能”			秒），表示 HLog 的保存期限为 7 天。
	hbase.master.cleaner.interval	60000	HMaster 清理过去 HLog 文件的周期，即超过设置的时间的 HLog 会被自动删除。建议尽可能配置大的值来保留更多的 HLog。
“RegionServer > Replication”	replication.source.size.capacity	16777216	edits 最大大小。单位为 byte。如果 edit 大小超过这个值 Hlog edits 将会发送到备集群。
	replication.source.nb.capacity	25000	edits 最大数目，是另一个触发 Hlog edits 到备集群的条件。当主集群同步数据到备集群中时，主集群会从 HLog 中读取数据，此时会根据本参数配置的个数读取并发送。与“replication.source.size.capacity”一起配置使用。
	replication.source.maxretriesmultiplier	10	replication 出现异常时的最大重试次数。
	replication.source.sleepforretries	1000	每次重试的 sleep 时间。（单位：毫秒）
	hbase.regionserver.replication.handler.count	6	RegionServer 上的 replication RPC 服务器实例数。

启用主集群备份功能来同步 Bulkload 方式写入的数据

是否启用 Bulkload 写数据备份功能？

说明

当使用了 HBase 的 Bulkload 导入数据的特性时且需要同步这些数据时，需要开启批量写数据备份功能。

是，执行步骤 5。

否，执行步骤 9。

步骤 3 参考 25.1 修改集群服务配置参数进入 HBase 服务参数“全部配置”界面。

步骤 4 在主、备集群的 HBase 配置界面，搜索并修改“hbase.replication.cluster.id”参数，表示主、备集群 HBase 的 id，例如主集群 HBase 的 id 配置为“replication1”，备集群 HBase 的 id 配置为“replication2”，用于主备集群的连接。为了节省数据开销建议参数值长度不超过 30。

步骤 5 在备集群的 HBase 配置界面，搜索并修改“hbase.replication.conf.dir”参数，表示备集群中所使用主集群客户端的 HBase 配置，用于启用 bulkload 数据备份功能时的数据备份。参数值为路径名，例如“/home”。

说明

- 当启用 bulkload 数据备份功能时，需在备集群的所有 RegionServer 节点上手动放置主集群中 HBase 相应客户端配置文件(core-site.xml, hdfs-site.xml, hbase-site.xml)，放置配置文件的实际路径为“${hbase.replication.conf.dir}/${hbase.replication.cluster.id}”。例如备集群的 hbase.replication.conf.dir 配置为“/home”，主集群的 hbase.replication.cluster.id 配置为“replication1”，则配置文件放置在备集群中实际的路径为“/home/replication1”。并修改对应目录及文件相应权限，可执行如下命令 **chown -R omm:wheel /home/replication1**。
- 客户端配置文件可从主集群中的客户端中获取，例如，路径为“/opt/client/HBase/hbase/conf”。

步骤 6 在主集群的 HBase 配置界面，搜索并修改“hbase.replication.bulkload.enabled”参数，将配置项的值修改为“true”，启用 Bulkload 写数据备份功能。

重启 HBase 服务并安装客户端。

保存配置，并重启 HBase 服务。

步骤 7 在主备集群，请参见 25.3.2 更新客户端，更新客户端配置文件。

同步主集群表数据。（主集群无数据可不执行）

以“hbase”用户进入集群的 HBase shell 界面。

1. 在已更新客户端的主管理节点，执行以下命令切换到客户端目录。

   cd /opt/client

2. 执行以下命令配置环境变量。

   source bigdata_env

3. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

   kinit hbase

   说明

   执行 **kinit hbase** 后系统提示输入密码，hbase 用户默认密码是 Hbase@123。

4. 直接执行 HBase 组件的客户端命令。

   hbase shell

检查备集群上是否已有历史数据。如果有历史数据且需要保持主备集群上的数据完全一致，需要先清理备集群上的数据。

1. 在备集群的 hbase shell 界面中，执行 **list** 命令查看备集群中已经存在的表。
2. 根据输出列表删除备集群上的数据表。

   disable '*tableName*'

   drop '*tableName*'

步骤 8 检查配置 HBase 备份并启用数据同步后，主集群是否已存在表及数据，且历史数据需要同步到备集群。

执行 **list** 命令查看主集群中已经存在的表，使用 **scan** '*tableName*'命令查看表中是否已经有历史数据。

- 是，存在表且需要同步数据，执行步骤 14。
- 否，不需要同步数据，任务结束。

步骤 9 配置 HBase 备份时不支持自动同步表中的历史数据，需要对主集群的历史数据进行备份，然后再手动同步历史数据到备集群中。

手动同步即单表的同步，单表手动同步通过 Export、distcp、Import 来完成。

单表手动同步操作步骤：

1. 从主集群导出表中数据。

   hbase org.apache.hadoop.hbase.mapreduce.Export -Dhbase.mapreduce.include.deleted.rows=true *表名 保存源数据的目录*

   例如，**hbase org.apache.hadoop.hbase.mapreduce.Export -Dhbase.mapreduce.include.deleted.rows=true t1 /user/hbase/t1**

2. 把导出的数据复制到备集群。

   hadoop distcp *主集群保存源数据的目录 hdfs://ActiveNameNodeIP:9820/备集群保存源数据的目录*

   其中，ActiveNameNodeIP 是备集群中主 NameNode 节点的 IP 地址。

   例如，**hadoop distcp /user/hbase/t1 hdfs://192.168.40.2:9820/user/hbase/t1**

3. 使用备集群 HBase 表用户，在备集群中导入数据。

   hbase org.apache.hadoop.hbase.mapreduce.Import *-Dimport.bulk.output=备集群保存输出的目录 表名 备集群保存源数据的目录*

   hbase org.apache.hadoop.hbase.mapreduce.LoadIncrementalHFiles *备集群保存输出的目录 表名*

   例如，**hbase org.apache.hadoop.hbase.mapreduce.Import -Dimport.bulk.output=/user/hbase/output_t1 t1 /user/hbase/t1**

   hbase org.apache.hadoop.hbase.mapreduce.LoadIncrementalHFiles /user/hbase/output_t1 t1

添加主备集群备份关系。

在 HBase shell 中执行如下命令，创建主集群 HBase 与备集群 HBase 之间的备份同步关系。

add_peer '*备集群 ID', CLUSTER_KEY => '备集群 ZooKeeper 地址信息*',**{HDFS_CONFS => true}**

- 备集群 ID 表示主集群识别备集群使用的 id，建议使用字母与数字。
- 备集群 ZooKeeper 地址信息包含 ZooKeeper 业务 IP 地址、侦听客户端连接的端口和备集群的 HBase 在 ZooKeeper 上的根目录。
- **{HDFS_CONFS => true}**表示将主集群的默认 HDFS 配置信息同步到对应集群，用于备集群的 HBase 访问主集群的 HDFS。如果不启用 Bulkload 批量写数据备份，可以不使用此参数。

  例如，添加包含 BulkLoad 数据的主备集群备份关系，若备集群 ID 为“replication2”，备集群 ZooKeeper 地址信息为“**192.168.40.2,192.168.40.3,192.168.40.4:2181:/hbase**”。

安全集群请执行：**add_peer 'replication2',CLUSTER_KEY => '192.168.40.2,192.168.40.3,192.168.40.4:2181:/hbase',CONFIG => { "hbase.regionserver.kerberos.principal" => "<val>", "hbase.master.kerberos.principal" => "<val2>" }**，普通集群请执行 **add_peer 'replication2',CLUSTER_KEY => '192.168.40.2,192.168.40.3,192.168.40.4:2181:/hbase'**

其中参数“hbase.master.kerberos.principal”和“hbase.regionserver.kerberos.principal”为安全集群中 hbase 的 kerberos 用户，可搜索客户端中 hbase-site.xml 文件得到参数值。例如，客户端安装在 master 节点的“/opt/client”下，则可使用命令 **grep "kerberos.principal" /opt/client/HBase/hbase/conf/hbase-site.xml -A1** 获取，如下图所示。

图8-1 获取 hbase 的 principal

```
[root@xxxxx-xxxxx5 opt]# grep "kerberos.principal" /opt/client/HBase/hbase/conf/hbase-site.xml -A1
<name>hbase.regionserver.kerberos.principal</name>
<value>hbase/hadoop.hadoop.com@HADOOP.COM</value>
--
<name>hbase.master.kerberos.principal</name>
<value>hbase/hadoop.hadoop.com@HADOOP.COM</value>
--
```

说明

1. 获取 ZooKeeper 业务 IP 地址。

   登录 MRS 控制台，单击集群名称，选择“组件管理 > ZooKeeper > 实例”，获取 ZooKeeper 业务 IP 地址。

2. 在 ZooKeeper 服务参数“全部配置”界面，搜索获取 clientPort，即为客户端连接服务器的端口。

3. 执行 **list_peers** 命令判断主备备份关系添加结果，当界面提示以下信息表示成功。

   ```
   hbase(main):003:0> list_peers
   PEER_ID CLUSTER_KEY ENDPOINT_CLASSNAME STATE REPLICATE_ALL NAMESPACES
   TABLE_CFS BANDWIDTH SERIAL
   replication2 192.168.0.13,192.168.0.177,192.168.0.25:2181:/hbase ENABLED
   true   0 false
   ```

指定主备集群写数据状态。

在主集群 HBase shell 界面，执行以下命令保持写数据状态。

set_clusterState_active

界面提示以下信息表示执行成功：

```
hbase(main):001:0> set_clusterState_active
=> true
```

步骤 10 在备集群 HBase shell 界面，执行以下命令保持只读数据状态。

set_clusterState_standby

界面提示以下信息表示执行成功：

```
hbase(main):001:0> set clusterState standby
=> true
```

启用 HBase 备份功能同步数据。

检查备集群的 HBase 服务实例中，是否已存在一个命名空间，与待启用备份功能的 HBase 表所属的命名空间名称相同？

在备集群的 HBase shell 中，执行 **list_namespace** 命令，查询命名空间。

- 是，存在同名的命令空间，执行步骤 19。
- 否，不存在同名的命令空间，需先在备集群的 HBase shell 中，执行 **create_namespace 'ns1'**创建同名的命名空间，然后执行步骤 19。

步骤 11 在主集群的 HBase shell 中，执行以下命令，启用主集群表的数据实时备份功能，确保后续主集群中修改的数据能够实时同步到备集群中。

一次只能针对一个 HTable 进行数据同步。

enable_table_replication '*表名***'**

说明

- 若备集群中不存与要开启实时同步的表同名的表，则该表会自动创建。
- 若备集群中存在与要开启实时同步的表同名的表，则两个表的结构必须一致。
- 若'表名'设置了加密算法 SMS4 或 AES，则不支持对此 HBase 表启用将数据从主集群实时同步到备集群的功能。
- 若备集群不在线，或备集群中已存在同名但结构不同的表，启用备份功能将失败。

  若备集群不在线，请启动备集群。

  若备集群中已存在同名但结构不同的表，请修改备集群的表结构为相同的表结构。在备集群的 HBase shell 中，执行 ***alter*** 命令，参考示例修改。

步骤 12 在主集群的 HBase shell 中，执行以下命令，启用主集群的实时备份功能，同步 HBase 的权限表。

enable_table_replication 'hbase:acl'

说明

主集群 HBase 源数据表修改权限时，如果备集群需要正常读取数据，请修改备集群角色的权限。

检验主备集群数据同步状态。

在 HBase 客户端执行以下命令，校验主备集群同步的数据。启用备份同步功能后，也可以执行该命令检验新的同步数据是否一致。

hbase org.apache.hadoop.hbase.mapreduce.replication.VerifyReplication --starttime=*开始时间* **--endtime**=*结束时间 列族名称 备集群 ID 表名*

说明

- 开始时间必须早于结束时间。
- 开始时间和结束时间需要填写时间戳的格式，例如执行 **date -d "2015-09-30 00:00:00" +%s** 将普通时间转化为时间戳格式。因此命令返回的为 10 位数字（精确到秒），而 HBase 识别的为 13 位（精确到毫秒），所以需要在 date 命令返回的结果后补上 3 个 0。

主备集群发生倒换

说明

1. 当备集群需要被倒换为主集群时，请参见步骤 2~步骤 10 和步骤 15~步骤 20 重新配置主备关系。
2. 勿需执行“同步集群表数据”操作，即步骤 11~步骤 14。

----结束

相关命令

表8-5 HBase 备份

操作	命令	描述
建立主备关系		建立主集群与备集群的关系，让其互相对应。如果启用 Bulkload 批量写数据备份，则命令为 **add_peer** *'备集群 ID'*，***CLUSTER_KEY*** **=>** *'备集群地址信息'*，并配置参数 *"hbase.replication.conf.dir"*，同时手动拷贝主集群的 hbase 相应客户端配置文件到备集群的所有 RegionServer 节点，详情请参考步骤 4~11。
移除主备关系	**remove_peer** *'备集群 ID'* 示例： **remove_peer '1'**	在主集群中移除备集群的信息。
查询主备关系	**list_peers**	在主集群中查询已经设置的备集群的信息，主要为 Zookeeper 信息。
启用用户表实时同步	**enable_table_replication** *'表名'* 示例： **enable_table_replication 't1'**	在主集群中，设置已存在的表同步到备集群。
禁用用户表实时同步	**disable_table_replication** *'表名'* 示例： **disable_table_replication 't1'**	在主集群中，设置已存在的表不同步到备集群。
主备集群数据校验	**bin/hbase org.apache.hadoop.hbase.mapreduce.replication.VerifyReplication --starttime**=*开始时间* **--endtime=** *结束时间 列族名称 备集群 ID 表名*	检查指定的表在主备集群间的数据是否一致。 命令行中参数说明如下： • 开始时间：如果未设置，则取默认的开始时间为 0。 • 结束时间：如果未设置，则取默认的结束时间为当前操作提交的时间。

操作	命令	描述
		• 表名：如果未输入表名，则默认校验所有的启用了实时同步的用户表。
切换数据写入状态	**set_clusterState_active** **set_clusterState_standby**	设置集群 HBase 表是否可写入数据。

8.5 启用集群间拷贝功能

操作场景

当用户需要将保存在 HDFS 中的数据从当前集群备份到另外一个集群时，需要使用 DistCp 工具。DistCp 工具依赖于集群间拷贝功能，该功能默认未启用。两个集群都需要配置。

该任务指导 MRS 集群管理员在 MRS 修改参数以启用集群间拷贝功能。

对系统的影响

启用集群间复制功能需要重启 Yarn，服务重启期间无法访问。

前提条件

两个集群 HDFS 的参数“hadoop.rpc.protection”需使用相同的数据传输方式。设置为“privacy”表示加密，“authentication”表示不加密。

说明

参考 25.1 修改集群服务配置参数，进入 HDFS 服务参数“全部配置”界面“，搜索 hadoop.rpc.protection 查看。

操作步骤

进入 Yarn 服务参数“全部配置”界面，具体操作请参考 25.1 修改集群服务配置参数。

说明

若集群详情页面没有“组件管理”页签，请先完成 IAM 用户同步（在集群详情页的“概览”页签，单击“IAM 用户同步”右侧的“同步”进行 IAM 用户同步）。

步骤 1 左边菜单栏中选择“Yarn > 集群间拷贝”。

步骤 2 设置“dfs.namenode.rpc-address”参数的“haclusterX.remotenn1”值为对端集群其中一个 NameNode 实例的业务 IP 和 RPC 端口，设置“haclusterX.remotenn2”值为对端集群另外一个 NameNode 实例的业务 IP 和 RPC 端口。按照“*IP:port*”格式填写。

说明

登录 FusionInsight Manager 页面，选择“集群 > *待操作集群的名称* > 服务 > HDFS > 实例”，获取 NameNode 实例的业务 IP。

“dfs.namenode.rpc-address.haclusterX.remotenn1”和“dfs.namenode.rpc-address.haclusterX.remotenn2”不区分主备 NameNode。NameNode RPC 端口可登录 Manager 界面，进入到 HDFS 服务配置页面搜索“dfs.namenode.rpc.port”参数获取，不支持通过 Manager 修改。

修改后参数值例如：“10.1.1.1:9820”和“10.1.1.2:9820”。

步骤 3 保存配置并在概览页面选择“更多 > 重启服务”，重启 Yarn 服务。

界面提示“操作成功。”，单击“完成”，Yarn 服务启动成功。

步骤 4 登录另外一个集群，重复以上操作。

----结束

8.6 使用 ReplicationSyncUp 工具

前提条件

1. 主备集群已经安装并且启动。
2. 主备集群上的时间必须一致，而且主备集群上的 NTP 服务必须使用同一个时间源。
3. 当主集群 HBase 服务关闭时，Zookeeper 和 HDFS 服务应该启动并运行。
4. 该工具应该由启动 HBase 进程的系统用户运行。
5. 如果处于安全模式，请确保备用集群的 HBase 系统用户具有主集群 HDFS 的读取权限。因为它将更新 HBase 系统 Zookeeper 节点和 HDFS 文件。
6. 主集群 HBase 故障后，主集群的 Zookeeper，文件系统和网络依然可用。

场景介绍

Replication 机制可以使用 WAL 将一个集群的状态与另一个集群的状态保持同步。启用 HBase 备份后，若主集群出现故障，ReplicationSyncUp 工具会使用来自 zookeeper 的信息将主集群中的启用 HBase 备份功能的数据增量同步到备集群中。数据同步完成后，备集群可以作为主集群使用。

参数配置

参数	描述	默认值
hbase.replication.bulkload.enabled	是否开启批量加载数据复制功能。参数值类型为 Boolean。开启批量加载数据复制功能后该参数须在主集群中设置为 true。	false
hbase.replication.cluster.id	源 HBase 集群 ID。开启批量加载数据	-

参数	描述	默认值
	复制功能是必须设置该参数，在源集群定义。参数值类型为 String。	

工具使用

在主集群 client 上输入如下命令使用：

hbase org.apache.hadoop.hbase.replication.regionserver.ReplicationSyncUp -Dreplication.sleep.before.failover=1

说明

replication.sleep.before.failover 是指在 RegionServer 启动失败时备份其剩余数据前需要的休眠时间。由于 30 秒（默认值）的睡眠时间没有任何意义，因此将其设置为 1（s），使备份过程更快触发。

注意事项

1. 当主集群关闭时，此工具将从 ZooKeeper 节点（RS znode）获得 WAL 的处理进度以及 WAL 的处理队列，并将未复制的队列复制到备集群中。
2. 每个主集群的 RegionServer 在备集群 ZooKeeper 上的 replication 节点下都有自己的 znode。它包含每个对等集群的一个 znode。
3. 当 Regionserver 故障时，主集群的每个 RegionServer 都会通过 watcher 收到通知，并尝试锁定故障 RegionServer 的 znode，包含它的队列。成功创建的 RegionServer 会将所有队列转移到自己队列的 znode 下。队列传输后，它们将从旧位置删除。
4. 在主集群关闭期间，ReplicationSyncUp 工具将使用来自 ZooKeeper 节点的信息同步主备集群的数据，并且 RegionServer znode 的 wals 将被移动到备集群下。

限制和约束

如果备集群处于关闭状态或关闭了对等关系，该工具正常运行，只有该对等关系复制不会发生。

8.7 自研增强 Phoenix

8.7.1 CsvBulkloadTool 支持解析数据文件中的自定义分隔符

操作场景

Phoenix 提供了批量数据导入工具 CsvBulkloadTool，在此特性基础上，支持导入自定义分隔符文件，即用户可以采用限定长度内的任意可见字符进行组合作为分隔符来导入数据文件。

说明

该章节内容仅适用于 MRS 3.2.0 及之后版本。

使用约束

- 自定义分隔符不能为空字符串。
- 自定义分隔符长度必须小于等于 16 个字符。

说明

自定义分隔符过长会影响解析效率，降低数据导入速度，且会导致有效数据占比率降低，使得文件占用过大，因此不建议使用过长的分隔符。

- 自定义分隔符必须为可见字符。

说明

自定义分隔符白名单，避免可能的注入问题，目前支持的分隔字符包括：字母、数字、特殊符号（`~!@#$%^&*()\\-_=+\\[\\]{}\\\\|;:'\",<>./?）。

- 自定义分隔符不能首尾相同。

新增参数说明

基于开源 CsvBulkloadTool，新增以下两个参数：

- **--multiple-delimiter(-md)**
  用于指定自定义分隔符，当此命令参数存在时，会优先生效，覆盖掉原命令中的**-d** 参数。
- **--multiple-delimiter-skip-check(-mdsc)**
  用于跳过分隔符长度及白名单校验，不建议使用。

操作步骤

将数据文件上传到客户端所在节点，例如上传名为“data.csv”的文件到客户端所在节点的“/opt/test”目录下，分隔符为“|^[”，文件内容如下所示：

```
0|^[lucy|^[81|^[city3|^[true|^[9.18914949740991|^[-22.18269890221688
1|^[zhangshan|^[46|^[city4|^[true|^[5.322036259193896|^[-38.48904063764235
2|^[james|^[11|^[city3|^[true|^[7.7681483995935885|^[-25.7800264590591
3|^[james|^[87|^[city2|^[false|^[81.60003424030911|^[-75.3247097149487
4|^[wangwu|^[35|^[city3|^[true|^[32.95621554646283|^[-53.02547887416576
5|^[james|^[71|^[city5|^[true|^[83.12680099627629|^[-10.747627215038714
6|^[wangwu|^[23|^[city1|^[false|^[91.50905273357168|^[-39.53314273786492
7|^[james|^[8|^[city2|^[false|^[12.530415667410132|^[-24.858112869804337
8|^[lucy|^[87|^[city1|^[false|^[39.39199423544571|^[-68.35869628818902
9|^[lucy|^[92|^[city3|^[true|^[33.1217894946113O6|^[-55.48365486185375
10|^[lucy|^[51|^[city5|^[true|^[32.883181700707965|^[-78.04791713353062
```

步骤 1 以客户端安装用户，登录安装客户端的节点。

步骤 2 执行以下命令切换到客户端目录。

cd *客户端安装目录*

步骤 3 执行以下命令配置环境变量。

source bigdata_env

步骤 4 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 HBase 表的权限和 HDFS 的操作权限：

kinit *组件业务用户*

如果当前集群未启用 Kerberos 认证，则执行以下命令设置 Hadoop 用户名：

export HADOOP_USER_NAME=hbase

步骤 5 执行以下命令，把步骤 1 的数据文件“data.csv”上传至 HDFS 目录，例如上传至“/tmp”目录：

hdfs dfs -put /opt/test/data.csv /tmp

步骤 6 执行 Phoenix 客户端命令。

sqlline.py

步骤 7 执行以下命令创建 **TEST** 表：

CREATE TABLE TEST (ID INTEGER NOT NULL PRIMARY KEY, NAME VARCHAR, AGE INTEGER, ADDRESS VARCHAR, GENDER BOOLEAN, A DECIMAL, B DECIMAL) split on (1, 2, 3,4,5,6,7,8,9);

表创建成功后，执行**!quit** 退出 Phoenix 命令行。

步骤 8 执行导入命令：

hbase org.apache.phoenix.mapreduce.CsvBulkLoadTool -md '*自定义分隔符***' -t** *表名* **-i** *数据路径*

例如：导入数据文件“data.csv”到 **TEST** 表：

hbase org.apache.phoenix.mapreduce.CsvBulkLoadTool -md '|^[' -t TEST -i /tmp/data.csv

步骤 9 执行以下命令，查看导入表 **TEST** 的数据：

sqlline.py

SELECT * FROM TEST LIMIT 10;

```
No rows affected (2.307 seconds)
0: jdbc:phoenix:> SELECT * FROM TEST LIMIT 10;
+----+-----------+-----+----------+--------+--------------------+---------------------+
| ID |    NAME   | AGE | ADDRESS  | GENDER |         A          |          B          |
+----+-----------+-----+----------+--------+--------------------+---------------------+
| 0  | lucy      | 81  | city3    | true   | 9.18914949740991   | -22.18269890221688  |
| 1  | zhangshan | 46  | city4    | true   | 5.322036259193896  | -38.48904063764235  |
| 2  | james     | 11  | city3    | true   | 7.7681483995935885 | -25.7800264590591   |
| 3  | james     | 87  | city2    | false  | 81.60003424030911  | -75.3247097149487   |
| 4  | wangwu    | 35  | city3    | true   | 32.95621554646283  | -53.02547887416576  |
| 5  | james     | 71  | city5    | true   | 83.12680099627629  | -10.747627215038714 |
| 6  | wangwu    | 23  | city1    | false  | 91.50905273357168  | -39.53314273786492  |
| 7  | james     | 8   | city2    | false  | 12.530415667410132 | -24.858112869804337 |
| 8  | lucy      | 87  | city1    | false  | 39.39199423544571  | -68.35869628818902  |
| 9  | lucy      | 92  | city3    | true   | 33.121789494611306 | -55.48365486185375  |
+----+-----------+-----+----------+--------+--------------------+---------------------+
```

----结束

8.8 使用 HIndex

8.8.1 HIndex 介绍

场景介绍

HBase 是基于 Key-Value 的分布式存储数据库，基于 rowkeys 对表中的数据按照字典进行排序。如果您根据指定的 rowkey 查询数据，或者扫描指定 rowkey 范围内的数据，HBase 可以快速查找到需要读取的数据，从而提高效率。在大多数实际情况下，会需要查询列值为 XXX 的数据。HBase 提供了 Filter 功能来查询具有特定列值的数据：所有数据按 RowKey 的顺序进行扫描，然后将数据与特定的列值进行匹配，直到找到所需的数据。过滤器功能会 scan 一些不必要的数据以获取所需的数据。基于前面的描述，Filter 功能不能满足高性能标准频繁查询的要求。

这就是 HBase HIndex 产生的背景。如图 8-2 所示，HBase HIndex 为 HBase 提供了能够根据特定的列值进行索引的能力，使得查询会变得更快。

图8-2 HBase HIndex

说明

- 索引数据不支持滚动升级。
- 复合索引：用户必须将所有参与复合索引的列全部放入/删除，否则会导致数据不一致。
- 用户不应将任何 split policy 显式地配置到已建立索引的数据表中。
- 不支持 mutation 操作，如 increment,append。
- 不支持列索引的版本 maxVersions> 1。
- 添加索引的列值不应超过 32KB。
- 当用户数据由于列族级 TTL 失效而被删除时，相应的索引数据不会立即删除。索引数据将在 major compaction 期间被删除。
- 创建索引后，不应更改用户列族的 TTL。
- 如果在创建索引后将列族 TTL 更改为更高值，则应删除并重新创建索引，否则某些已生成的索引数据可能比用户数据先删除。
- 如果在创建索引后将列族 TTL 更改为较低值，则索引可能会晚于用户数据被删除。

- HBase 表启动容灾之后，主集群新建二级索引，索引表变更不会自动同步到备集群。要实现该容灾场景，必须执行以下操作：
- 在主表创建二级索引之后，需要在备集群使用相同方法创建结构、名称完全相同的二级索引。

1. 在主集群手动将索引列族（默认是 d）的 REPLICATION_SCOPE 设置为 1。

参数配置

1. 登录 MRS 控制台，单击集群名称，选择“组件管理”。
2. 进入 HBase 服务参数“全部配置”界面，具体操作请参考 25.1 修改集群服务配置参数。
3. 在 HBase 全部配置界面查看参数。

配置入口	配置项	默认值	描述
“HMaster > 系统”	hbase.coprocessor.master.classes	org.apache.hadoop.hbase.hindex.server.master.HIndexMasterCoprocessor,com.xxx.hadoop.hbase.backup.services.RecoveryCoprocessor,org.apache.ranger.authorization.hbase.RangerAuthorizationCoprocessor,org.apache.hadoop.hbase.security.access.ReadOnlyClusterEnabler,org.apache.hadoop.hbase.rsgroup.RSGroupAdminEndpoint	该协处理器用于在启用 Hindex 功能后处理 Master 级的操作，比如创建索引 meta 表，添加索引，删除索引，删除表删除索引元数据。
“RegionServer > RegionServer”	hbase.coprocessor.regionserver.classes	org.apache.hadoop.hbase.hindex.server.regionserver.HIndexRegionServerCoprocessor,org.apache.hadoop.hbase.JMXListener,org.apache.ranger.authorization.hbase.RangerAuthorizationCoprocessor	该协处理器用于在启用 Hindex 功能后实际上处理 master 下发到 Regionserver 上的操作。
	hbase.coprocessor.region.cl	org.apache.hadoop.hbase.hind	该协处理器用于在启用 Hindex 功能后实际上操作 Region 上的

配置入口	配置项	默认值	描述
	asses	ex.server.regionserver.HIndexRegionCoprocessor,org.apache.hadoop.hbase.security.token.TokenProvider,com.xxx.hadoop.hbase.backup.services.RecoveryCoprocessor,org.apache.ranger.authorization.hbase.RangerAuthorizationCoprocessor,org.apache.hadoop.hbase.security.access.SecureBulkLoadEndpoint,org.apache.hadoop.hbase.security.access.ReadOnlyClusterEnabler,org.apache.hadoop.hbase.coprocessor.MetaTableMetrics	数据。

说明

1.上述默认值为启用 HBase HIndex 功能后需额外配置的值，当前支持 HBase HIndex 功能的 MRS 集群默认已配置。

2.必须确保 master 参数配置在 hmster 上，region/regionserver 参数配置在 regonserver 上。

相关接口

使用 HIndex 的 API 都在类 org.apache.hadoop.hbase.hindex.client.HIndexAdmin 中，相关接口介绍如下：

操作	接口	描述	注意事项
添加索引	addIndices()	将索引添加到没有数据的表中。调用此接口会将用户指定的索引添加到表中，但会跳过生成索引数据。因此，在此操作之后，索引不能用于 scan/filter 操作。它的使用场景为用户想要在具有大量预先存在用户数据的表上批量添加索	• 索引一旦添加则不能修改。若要修改，则需先删除旧的索引然后重新创建。 • 用户应注意不要在具有不同索引名称

操作	接口	描述	注意事项
		引，其具体操作为使用诸如 TableIndexer 工具之类的外部工具来构建索引数据。	的相同列上创建两个索引。如果这样做，将会导致存储和处理的浪费。 • 索引不能添加到系统表中。 • 向索引列 put 数据时不支持 append 和 increment 操作。 • 如果客户端出现任何故障，除非发生 DoNotRetryIOException，否则用户应该重试。 • 索引列族根据可用性按顺序从以下条件中选择： – 默认索引列族“d”或者如果设置了属性“hindex.default.family.name”的值，则以该值为准。 – 符号#，@，$或% – #0，@0，$0，%0，#1，@1 ...上至#255，@255，$255，%255 – throw Exception • 可以通过 HIndex TableIndexer 工具添加索引而无需建立索引数据。
	addIndicesWithData()	将索引添加到有数据的表中。此方法将用户指定的索引添加到表中，并会对已经存在的用户数据创建对应的索引数据，也可先调用该方法生成索引再在存入用户数据的同时生成索引数据。在此操作之后，这些索引立即可用于 scan/filter 操作。	
删除索引	dropIndices()	仅删除索引。该 API 从表中删除用户指定的索引，但跳过相应的索引数据。在此操作之后，索引不能用于 scan/filter 操作。集群在 major compaction 期间会自动删除旧的索引数据。 此 API 使用场景为表中包含大	• 在索引的状态为 ACTIVE，INACTIVE 和 DROPPING 时，允许禁用索引的操作。 • 对于使用 dropIndices()删除索

操作	接口	描述	注意事项
		量索引数据且dropIndicesWithData()不可行。另外，用户也可以通过TableIndexer 工具删除索引以及索引数据。	引的操作，用户必须确保在将索引添加到具有相同索引名的表之前，相应的索引数据已被删除（即 major compaction 已完成）。 • 用户删除相应的索引会删除： – 一个带有索引的列族。 – 组合索引所有列族中的任一个列族。 • 索引可以通过 HIndex TableIndexer 工具与索引数据一起删除。
	dropIndicesWithData()	删除索引数据。此 API 删除用户指定的索引，并删除用户表中与这些索引对应的所有索引数据。在此操作之后，删除的索引完全从表中删除，不再可用于 scan/filter 操作。	
启用/禁用索引	disableIndices()	该 API 禁用所有用户指定的索引，使其不再可用于 scan/filter 操作。	• 在索引的状态为 ACTIVE，INACTIVE 和 BUILDING 时允许启用索引的操作。 • 在索引的状态为 ACTIVE 和 INACTIVE 时允许禁用索引操作。 • 在禁用索引之前，用户必须确保索引数据与用户数据一致。如果在索引处于禁用状态期间没有在表中添加新的数据，索引数据与用户数据将保持一致。 • 启用索引时，可以通过使用 TableIndexer 工具构建索引来保证数据一致性。
	enableIndices()	该 API 启用所有用户指定的索引，使其可用于 scan/filter 操作。	
查看已创建的索引	listIndices()	该 API 可用于列出给定表中的所有索引。	无

基于索引查询数据

在具有索引的用户表中，可以使用 Filter 来查询数据。对于创建单索引和组合索引的用户表，使用过滤器查询的结果与没有使用索引的表相同，但数据查询性能高于没有使用索引的表。

索引的使用规则如下：

- 对于为一个或多个列创建单个索引的情况：
  - 当将此列用于 AND 或 OR 查询筛选时，使用索引可以提高查询性能。

    例如，Filter_Condition（IndexCol1）AND / OR Filter_Condition（IndexCol2）。
  - 当在查询中使用“索引列和非索引列”进行过滤时，此索引可以提高查询性能。

    例如，Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol2）AND Filter_Condition（NonIndexCol1）。
  - 当在查询中使用“索引列或非索引列”进行筛选时，但不使用索引，查询性能不会提高。

    例如，Filter_Condition（IndexCol1）AND / OR Filter_Condition（IndexCol2）OR Filter_Condition（NonIndexCol1）。
- 对于为多个列创建组合索引的情况：
  - 当用于查询的列是组合索引的全部或部分列并且与组合索引具有相同的顺序时，使用索引会提高查询性能。

    例如，为 C1，C2 和 C3 创建组合索引。
    - 该索引在以下情况下生效：

      Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol2）AND Filter_Condition（IndexCol3）

      Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol2）

      FILTER_CONDITION（IndexCol1）
    - 该索引在下列情况下不生效：

      Filter_Condition（IndexCol2）AND Filter_Condition（IndexCol3）

      Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol3）

      FILTER_CONDITION（IndexCol2）

      FILTER_CONDITION（IndexCol3）
  - 当在查询中使用“索引列和非索引列”进行过滤时，使用索引可提高查询性能。

    例如：

    Filter_Condition（IndexCol1）AND Filter_Condition（NonIndexCol1）

    Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol2）AND Filter_Condition（NonIndexCol1）

- 当在查询中使用“索引列或非索引列”进行筛选时，但不使用索引，查询性能不会提高。

  例如：

  Filter_Condition（IndexCol1）OR Filter_Condition（NonIndexCol1）

  （Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol2））OR（Filter_Condition（NonIndexCol1））
- 当多个列用于查询时，只能为组合索引中的最后一列指定值范围，而其他列只能设置为指定值。

  例如，为 C1，C2 和 C3 创建组合索引。在范围查询中，只能为 C3 设置数值范围，过滤条件为“C1 = XXX，C2 = XXX，C3 = 数值范围”。

查询策略选择

使用 SingleColumnValueFilter 或 SingleColumnRangeFilter，它会在一个在过滤条件中提供确定值 column_family:qualifierpair（称该列为 col1）。

若 col1 作为表上的第一个索引列，那么该表上的任何索引都可以成为查询期间使用的候选索引。例如：

如果有 col1 上的索引，可以将此索引作为候选索引，因为 col1 是此索引的第一列也是唯一的列；如果在 col1 和 col2 上有另一个索引，可以将此索引视为候选索引，因为 col1 是索引列列表中的第一列。另一方面，如果在 col2 和 col1 上有一个索引，则不能将此索引作为候选索引，因为索引列列表中的第一列不是 col1。

现在最适合使用索引的方法是，当有多个候选索引时，需要从可能的候选索引中选择最适合 scan 数据的索引。

可借助以下方案来了解如何选择索引策略：

- 可以完全匹配。

  场景：有两个索引可用，一个用于 col1＆col2，另一个单独用于 col1。

  在上面的场景中，第二个索引会比第一个索引更好，因为它会使 scan 的较少索引数据。
- 如果有多个候选多列索引，则选择具有较少索引列的索引。

  场景：有两个索引可用，一个用于 col1＆col2，另一个用于 col1＆col2＆col3。

  在这种情况下，需要使用 col1 和 col2 上的索引，因为它会使 scan 的较少索引数据。

说明

- 基于索引查询时索引的状态必须为 ACTIVE（可通过调用 listIndices() API 查看索引的状态）。
- 为了保证基于索引查询数据的正确性，用户应该确保索引数据与用户数据的一致性。
- 使用以下命令可通过 HBase shell 客户端执行复杂查询（假定此时 已为指定列建立索引）。

  scan 'tablename', {FILTER => "SingleColumnValueFilter(family, qualifier, compareOp, comparator, filterIfMissing, latestVersionOnly)"}

  例如：**scan 'test', {FILTER => "SingleColumnValueFilter('info', 'age', =, 'binary:26', true, true)"}**

（在以上场景中，用户希望在结果中保存没有查询到的列所在行时，不应该在任何这样的列上创建任何索引，因为如果查询的列不存在于其中时，使用 SCVF 扫描索引列会过滤出一行。而使用 filterIfMissingset 为 false（这是默认值）的 SCVF 扫描非索引列时，也将会在结果中返回没有查询列的行。因此，为避免查询结果不一致，建议在为索引列创建 SCVF 后将 filterIfMissing 设置为 true。）

- 在 hbase shell 中可以通过以下命令查看为用户数据建立的索引数据。

  scan 'tablename', {ATTRIBUTES => {'FETCH_INDEX_DATA' => 'true'}}

8.8.2 批量加载索引数据

场景介绍

HBase 本身提供了 ImportTsv＆LoadIncremental 工具来批量加载用户数据。当前提供了 HIndexImportTsv 来支持加载用户数据的同时可以完成对索引数据的批量加载。HIndexImportTsv 继承了 HBase 批量加载数据工具 ImportTsv 的所有功能。此外，若在执行 HIndexImportTsv 工具之前未建表，直接运行该工具，将会在创建表时创建索引，并在生成用户数据的同时生成索引数据。

操作步骤

1. 将数据导入到 HDFS 中。

   hdfs dfs -mkdir <*inputdir*>

   hdfs dfs -put <local_data_file> <*inputdir*>

   例如定义数据文件“data.txt”，内容如下：

   ```
   12005000201,Zhang San,Male,19,City a, Province a
   12005000202,Li Wanting,Female,23,City b, Province b
   12005000203,Wang Ming,Male,26,City c, Province c
   12005000204,Li Gang,Male,18,City d, Province d
   12005000205,Zhao Enru,Female,21,City e, Province e
   12005000206,Chen Long,Male,32,City f, Province f
   12005000207,Zhou Wei,Female,29,City g, Province g
   12005000208,Yang Yiwen,Female,30,City h, Province h
   12005000209,Xu Bing,Male,26,City i, Province i
   12005000210,Xiao Kai,Male,25,City j, Province j
   ```

   执行以下命令：

   hdfs dfs -mkdir /datadirImport

   hdfs dfs -put data.txt /datadirImport

2. 建表 bulkTable，进入 hbase shell，执行命令建表，例如：

   create 'bulkTable', {NAME => 'info',COMPRESSION => 'SNAPPY', DATA_BLOCK_ENCODING => 'FAST_DIFF'},{NAME=>'address'}

   执行完成后退出 hbase shell。

3. 执行如下命令，生成 HFile 文件（StoreFiles）：

   hbase org.apache.hadoop.hbase.hindex.mapreduce.HIndexImportTsv -Dimporttsv.separator=<*separator*>

   -Dimporttsv.bulk.output=<*/path/for/output*> **-Dindexspecs.to.add=**<indexspecs> **-Dimporttsv.columns=**<columns> tableName <*inputdir*>

   - -Dimport.separator：分隔符，例如，-Dimport.separator=','。

- -Dimport.bulk.output=</path/for/output>：指的是执行结果输出路径，需指定一个不存在的路径。
- <columns>：指的是导入数据在表中的对应关系，例如，-Dimporttsv.columns=HBASE_ROW_KEY,info:name,info:gender,info:age,address:city,address:province。
- <tablename>：指的是要操作的表名。
- <inputdir>：指的是要批量导入的数据目录。
- -Dindexspecs.to.add=<indexspecs>：指的是索引名与列的映射，例如-Dindexspecs.to.add='index_bulk=>info:[age->String]'。 其构成可以表示如下：

  indexNameN=>familyN :[columnQualifierN-> columnQualifierDataType], [columnQualifierM-> columnQualifierDataType];familyM: [columnQualifierO-> columnQualifierDataType]# indexNameN=> familyM: [columnQualifierO-> columnQualifierDataType]

  其中，列限定符用逗号（,）分隔

  例如：“index1 => f1：[c1-> String]，[c2-> String]”

  列族由分号（;）分隔

  例如：“index1 => f1：[c1-> String]，[c2-> String]; f2：[c3-> Long]”

  多个索引由#号键（＃）分隔

  例如：“index1 => f1：[c1-> String]，[c2-> String]; f2：[c3-> Long]＃index2 => f2：[c3-> Long]”

  列限定的数据类型：

  可用的数据类型有：STRING，INTEGER，FLOAT，LONG，DOUBLE，SHORT，BYTE，CHAR

说明

数据类型也可以用小写传递。

例如执行以下命令：

hbase org.apache.hadoop.hbase.hindex.mapreduce.HIndexImportTsv -Dimporttsv.separator=',' -Dimporttsv.bulk.output=/dataOutput -Dindexspecs.to.add='index_bulk=>info:[age->String]' -Dimporttsv.columns=HBASE_ROW_KEY,info:name,info:gender,info:age,address:city,address:province bulkTable /datadirImport/data.txt

输出：

```
[root@shap000000406 opt]# hbase
org.apache.hadoop.hbase.hindex.mapreduce.HIndexImportTsv -
Dimporttsv.separator=',' -Dimporttsv.bulk.output=/dataOutput -
Dindexspecs.to.add='index_bulk=>info:[age->String]' -
Dimporttsv.columns=HBASE_ROW_KEY,info:name,info:gender,info:age,address:city,ad
dress:province bulkTable /datadirImport/data.txt
2018-05-08 21:29:16,059 INFO  [main] mapreduce.HFileOutputFormat2: Incremental
table bulkTable output configured.
2018-05-08 21:29:16,069 INFO  [main]
client.ConnectionManager$HConnectionImplementation: Closing master protocol:
MasterService
2018-05-08 21:29:16,069 INFO  [main]
client.ConnectionManager$HConnectionImplementation: Closing zookeeper
sessionid=0x80007c2cb4fd5b4d
```

```
2018-05-08 21:29:16,072 INFO  [main] zookeeper.ZooKeeper: Session:
0x80007c2cb4fd5b4d closed
2018-05-08 21:29:16,072 INFO  [main-EventThread] zookeeper.ClientCnxn:
EventThread shut down for session: 0x80007c2cb4fd5b4d
2018-05-08 21:29:16,379 INFO  [main] client.ConfiguredRMFailoverProxyProvider:
Failing over to 147
2018-05-08 21:29:17,328 INFO  [main] input.FileInputFormat: Total input files
to process : 1
2018-05-08 21:29:17,413 INFO  [main] mapreduce.JobSubmitter: number of splits:1
2018-05-08 21:29:17,430 INFO  [main] Configuration.deprecation:
io.bytes.per.checksum is deprecated. Instead, use dfs.bytes-per-checksum
2018-05-08 21:29:17,687 INFO  [main] mapreduce.JobSubmitter: Submitting tokens
for job: job_1525338489458_0002
2018-05-08 21:29:18,100 INFO  [main] impl.YarnClientImpl: Submitted application
application_1525338489458_0002
2018-05-08 21:29:18,136 INFO  [main] mapreduce.Job: The url to track the job:
http://shap000000407:8088/proxy/application_1525338489458_0002/
2018-05-08 21:29:18,136 INFO  [main] mapreduce.Job: Running job:
job_1525338489458_0002
2018-05-08 21:29:28,248 INFO  [main] mapreduce.Job: Job job_1525338489458_0002
running in uber mode : false
2018-05-08 21:29:28,249 INFO  [main] mapreduce.Job:  map 0% reduce 0%
2018-05-08 21:29:38,344 INFO  [main] mapreduce.Job:  map 100% reduce 0%
2018-05-08 21:29:51,421 INFO  [main] mapreduce.Job:  map 100% reduce 100%
2018-05-08 21:29:51,428 INFO  [main] mapreduce.Job: Job job_1525338489458_0002
completed successfully
2018-05-08 21:29:51,523 INFO  [main] mapreduce.Job: Counters: 50
```

4. 执行如下命令将生成的 HFile 导入 HBase 中：

   hbase org.apache.hadoop.hbase.mapreduce.LoadIncrementalHFiles *</path/for/output> <tablename>*

   例如执行以下命令：

   hbase org.apache.hadoop.hbase.mapreduce.LoadIncrementalHFiles /dataOutput bulkTable

   输出：

```
[root@shap000000406 opt]# hbase
org.apache.hadoop.hbase.mapreduce.LoadIncrementalHFiles /dataOutput bulkTable
2018-05-08 21:30:01,398 WARN  [main] mapreduce.LoadIncrementalHFiles: Skipping
non-directory hdfs://hacluster/dataOutput/_SUCCESS
2018-05-08 21:30:02,006 INFO  [LoadIncrementalHFiles-0] hfile.CacheConfig:
Created cacheConfig: CacheConfig:disabled
2018-05-08 21:30:02,006 INFO  [LoadIncrementalHFiles-2] hfile.CacheConfig:
Created cacheConfig: CacheConfig:disabled
2018-05-08 21:30:02,006 INFO  [LoadIncrementalHFiles-1] hfile.CacheConfig:
Created cacheConfig: CacheConfig:disabled
2018-05-08 21:30:02,085 INFO  [LoadIncrementalHFiles-2] compress.CodecPool: Got
brand-new decompressor [.snappy]
2018-05-08 21:30:02,120 INFO  [LoadIncrementalHFiles-0]
mapreduce.LoadIncrementalHFiles: Trying to load
hfile=hdfs://hacluster/dataOutput/address/042426c252f74e859858c7877b95e510
first=12005000201 last=12005000210
2018-05-08 21:30:02,120 INFO  [LoadIncrementalHFiles-2]
mapreduce.LoadIncrementalHFiles: Trying to load
hfile=hdfs://hacluster/dataOutput/info/f3995920ae0247a88182f637aa031c49
```

```
first=12005000201 last=12005000210
2018-05-08 21:30:02,128 INFO  [LoadIncrementalHFiles-1]
mapreduce.LoadIncrementalHFiles: Trying to load
hfile=hdfs://hacluster/dataOutput/d/c53b252248af42779f29442ab84f86b8
first=\x00index_bulk\x00\x00\x00\x00\x00\x00\x00\x0018\x00\x0012005000204
last=\x00index_bulk\x00\x00\x00\x00\x00\x00\x00\x0032\x00\x0012005000206
2018-05-08 21:30:02,231 INFO  [main]
client.ConnectionManager$HConnectionImplementation: Closing master protocol:
MasterService
2018-05-08 21:30:02,231 INFO  [main]
client.ConnectionManager$HConnectionImplementation: Closing zookeeper
sessionid=0x81007c2cf0f55cc5
2018-05-08 21:30:02,235 INFO  [main] zookeeper.ZooKeeper: Session:
0x81007c2cf0f55cc5 closed
2018-05-08 21:30:02,235 INFO  [main-EventThread] zookeeper.ClientCnxn:
EventThread shut down for session: 0x81007c2cf0f55cc5
```

8.8.3 使用索引生成工具

场景介绍

为了快速对用户数据创建索引，HBase 提供了可通过 MapReduce 功能创建索引的 TableIndexer 工具，该工具可实现添加，构建和删除索引。具体使用场景如下：

- 在用户的表中预先存在大量数据的情况下，可能希望在某个列上添加索引。但是，使用 addIndicesWithData（）API 添加索引会生成与相关用户数据对应的索引数据，这将花费大量时间。另一方面，使用 addIndices（）创建的索引不会构建与用户数据对应的索引数据。因此，为了为这样的用户数据建立索引数据，用户可以使用 TableIndexer 工具来完成索引的构建。
- 如果索引数据与用户数据不一致，该工具可用于重新构建索引数据。

  如果用户暂时禁用索引并且在此期间，向禁用的索引列执行新的 put 操作，然后直接将索引从禁用状态启用可能会导致索引数据与用户数据不一致。因此，用户必须注意在再次使用之前重新构建所有索引数据。
- 对于大量现有的索引数据，用户可以使用 TableIndexer 工具将索引数据从用户表中完全删除。
- 对于未建立索引的用户表，该工具允许用户同时添加和构建索引。

使用方法

- **添加新的索引到用户表**

  命令如下所示：

  hbase org.apache.hadoop.hbase.hindex.mapreduce.TableIndexer -Dtablename.to.index=tablename -Dindexspecs.to.add='idx_0=>cf_0:[q_0->string],[q_1];cf_1:[q_2],[q_3]#*idx_1*=>cf_1:[q_4]'

  它需要以下参数:

  - **tablename.to.index**：表示创建索引的表的名称
  - **indexspecs.to.add**：表示与索引名与对应用户表的列的映射
  - **scan.caching**（可选）：包含一个整数值，表示在扫描数据表时将传递给扫描器的缓存行数

上述命令中的参数描述如下：

- **idx_1**：表示索引名称
- **cf_0**：表示列族名称
- **q_0**：表示列名称
- **string**：表示数据类型。它可以是 STRING，INTEGER，FLOAT，LONG，DOUBLE，SHORT，BYTE 或 CHAR

说明

- '#'用于分隔索引，';' 用于分隔列族，','用于分隔列限定符。
- 列名及其数据类型应包含在'[]'中。
- 列名及其数据类型通过'->'分隔。
- 如果未指定具体列的数据类型，则使用默认数据类型（string）。
- 如果未设置可选参数 scan.caching，则将采用默认值 1000。
- 用户表必须存在。
- 表中指定的索引不能存在。
- 如果用户表中已经存在名称为'd'的 ColumnFamily，则用户必须使用 TableIndexer 工具构建索引数据。

在执行以上的命令之后，指定的索引将被添加到表中并且将处于 INACTIVE 状态。该行为与 addIndices() API 类似。

- **为用户表中的现有索引构建索引数据**

  该命令如下：

  hbase org.apache.hadoop.hbase.hindex.mapreduce.TableIndexer -Dtablename.to.index=tablename -Dindexnames.to.build='idx_0＃idx_1'

  它采用以下参数：

  - **tablename.to.index**：表示创建索引的表的名称
  - **indexspecs.to.build**：表示与索引名称
  - **scan.caching**（可选）：包含一个整数值，表示在扫描数据表时将传递给扫描器的缓存行数

  上述命令中的参数描述如下：

  - **idx_1**：表示索引名称

  说明

  - '#'用于分隔索引名称。
  - 如果未设置可选参数 scan.caching，则将采用默认值 1000。
  - 用户表必须存在。

  在执行以上的命令之后，指定的索引将被设置为 ACTIVE 状态。用户扫描数据时可以使用它们。

- **从用户表中删除现有索引及其数据**

  该命令如下：

  hbase org.apache.hadoop.hbase.hindex.mapreduce.TableIndexer -Dtablename.to.index=tablename -Dindexnames.to.drop='idx_0＃idx_1'

  它需要以下参数：

  - **tablename.to.index**：表示创建索引的表的名称

- **indexnames.to.drop**：表示应该和其数据一起删除的索引的名称（必须存在于表中）
- **scan.caching**（可选）：其中包含一个整数值，指示在扫描数据表时将传递给扫描器的缓存行数

上述命令中的参数描述如下：

- **idx_1**：表示索引名称

说明

- '#'用于分隔索引名称。
- 如果未设置可选参数 scan.caching，则将采用默认值 1000。
- 用户表必须存在。

在执行前面的命令之后，指定的索引将从表中删除。

- **为用户表添加新的索引以及基于现有数据的数据构建**

  该命令如下：

  hbase org.apache.hadoop.hbase.hindex.mapreduce.TableIndexer -Dtablename.to.index=tablename -Dindexspecs.to.add='idx_0 => cf_0：[q_0-> string],[q_1];cf_1:[q_2]，[q_3]＃idx_1 => cf_1:[q_4]' -Dindexnames.to.build='idx_0'

  说明

  - 参数与之前的情况相同。
  - 用户表必须存在。
  - indexspecs.to.add 中指定的索引不得存在于表中。
  - indexnames.to.build 中指定的索引名称必须已经存在于表中，或者应该是 indexspecs.to.add 的一部分。

  在执行前面的命令之后，indexspecs.to.add 中指定的所有索引都将添加到该表中，并且将为通过 indexnames.to.build 为指定的所有索引构建索引数据。

8.9 使用全局二级索引

8.9.1 全局二级索引介绍

场景介绍

使用 HBase 二级索引可以加速带 Filter 的条件查询，支持 HIndex（本地索引，即 Local Secondary Index，简称为 LSI）和全局二级索引（Global Secondary Index，简称为 GSI）。全局二级索引相较于本地索引（HIndex），查询性能更好，适合读时延要求高的场景。

HBase 全局二级索引，使用独立的索引表存储索引数据。当给定的查询条件可以命中索引时，可以将对数据表的全表查询转换为对索引表的精确范围查询，提升查询速度。开启全局二级索引特性后，应用侧代码无需特殊修改，简单易用。

说明

MRS 3.3.0 及之后版本的集群默认启用 HBase 全局二级索引功能，如果需要修改全局二级索引相关参数，需登录 FusionInsight Manager，选择“集群 > 服务 > HBase > 配置 > 全部配置”，在“RegionServer（角色） > 二级索引”和“HMaster（角色） > 二级索引”中修改。

HBase 全局二级索引支持以下重点特性：

- **复合索引**

  支持指定多个列作为索引列（支持跨列族）。

- **覆盖索引**

  支持指定多个列/列族作为覆盖列/列族冗余存储到索引表中，用于支持索引查询中对非索引列的快速查询。

- **索引 TTL**

  支持索引表 TTL，用于支持数据表开启 TTL 的场景，为了保障与数据表的一致性，索引表 TTL 将自动继承数据表索引列和覆盖列的 TTL，不支持手动指定。

- **索引在线变更**

  支持索引在线创建、删除和修改状态，不影响数据表读写。

- **索引在线修复**

  当查询命中的索引数据无效时，可以触发索引修复，保障最终查询结果正确。

- **索引工具**

  支持索引一致性检查、索引修复、索引创建/删除/修改状态、索引数据重建等功能。

8.9.2 全局二级索引限制与约束

使用场景限制

- GSI 不支持与 HIndex 同时使用，即不支持在同一个数据表上同时创建本地索引与全局索引。
- 索引表不支持容灾。
- 索引数据不支持滚动升级。
- 不支持直接对索引表执行 DISABLE、DROP、MODIFY 和 TRUNCATE 操作。
- 索引 DDL 操作支持修改索引状态、删除索引、创建索引；不支持修改索引定义，如需修改，请先删除后重新创建。

索引创建约束

- 索引名需要符合正则要求，不支持其他字符。正则要求支持的字符为：**[a-zA-Z_0-9-.]:**
- 数据表必须存在，要创建的索引不能已存在。
- 索引表不支持多版本

  不支持在多版本（VERSION>1）的数据表上创建索引，且索引表的版本 VERSION=1。

- 单个数据表的索引个数不能超过 5 个

不建议为单个数据表创建过多索引，索引数量过多会造成存储成本较高，写入耗时大。如果需创建超过 5 个索引，请在 HMaster 的自定义配置“hbase.hmaster.config.expandor”中新增参数“hbase.gsi.max.index.count.per.table”，设置值大于 5，并重启 HMaster 使配置生效。

- 索引名长度不能超过 18 个字符

  不建议使用过长的索引名。如果需创建较长的索引名，请在 HMaster 的自定义配置“hbase.hmaster.config.expandor”中新增参数“hbase.gsi.max.index.name.length”，设置值大于 18，并重启 HMaster 使配置生效。

- 不支持为索引表创建索引

  不支持嵌套创建多个索引，索引表仅用于加速查询，不承担数据表功能。

- 不支持创建可以被已有索引覆盖的索引

  新建索引时，如果之前已存在的索引能够完全覆盖新建的索引（即创建的索引是已有索引的子集），则无法创建此索引，重复功能的索引会造成存储浪费。例如，以下操作将无法创建索引 2：

  创建数据表：**create 't1','cf1'**

  创建索引 1：**hbase org.apache.hadoop.hbase.hindex.global.mapreduce.GlobalTableIndexer -Dtablename.to.index='t1' -Dindexspecs.to.add='idx1=>cf1:[q1],[q2]'**

  创建索引 2：**hbase org.apache.hadoop.hbase.hindex.global.mapreduce.GlobalTableIndexer -Dtablename.to.index='t1' -Dindexspecs.to.add='idx2=>cf1:[q1]'**

- 不支持在同一张数据表上创建同名索引，支持在不同数据表上创建同名索引。
- 索引表列族 TTL 继承原表，索引列族 TTL 必须一致

  索引表所有列族 TTL 相同，继承自数据表，要求数据表中相关列族 TTL 必须一致，否则无法创建相关索引。

- 不支持为表创建索引时自定义索引的其他属性，例如，压缩方式、BLOCKSIZE、列编码等。

索引写入约束

- 索引数据生成仅支持 Put/Delete 接口，使用其他方式（Increment、Append、Bulkload 等）写入数据表时不会生成对应索引。
- 索引列数据定义为 String 类型时，要避免写入**\x00** 和**\x01** 两个特殊字符（特殊不可见字符）。
- 避免指定时间戳的方式写入索引列。

索引查询约束

- 索引查询时索引的状态必须为 **ACTIVE**。
- 索引查询不支持**指定时间戳范围查询**。如果需要通过索引查询时间范围内的数据，请添加时间列存储该条数据时间戳，否则会使用数据表进行查询
- 索引查询仅支持 **SingleColumnValueFilter**，使用其他 Filter 或无 Filter 条件时无法触发索引加速。

8.9.3 使用全局二级索引工具

8.9.3.1 创建索引

场景介绍

- 在用户的表中预先存在大量数据的情况下，可以在某个列上添加索引。
- 对于未建立索引的用户表，该工具允许用户同时添加和构建索引。

使用方法

在 HBase 客户端执行以下命令即可添加或创建索引，执行命令后，指定的索引将被添加到表中：

hbase org.apache.hadoop.hbase.hindex.global.mapreduce.GlobalTableIndexer -Dtablename.to.index='*table*' **-Dindexspecs.to.add=**'*idx1=>cf1:[c1->string],[c2]#idx2=>cf2:[c1->string],[c2]#idx3=>cf1:[c1];cf2:[c1]*' **-Dindexspecs.covered.family.to.add=**'*idx2=>cf1*' **-Dindexspecs.covered.to.add=**'*idx1=>cf1:[c3],[c4]*' **-Dindexspecs.coveredallcolumn.to.add=**'*idx3=>true*' **-Dindexspecs.splitkeys.to.set=**'*idx1=>[\x010,\x011,\x012]#idx2=>[\x01a,\x01b,\x01c]#idx3=>[\x01d,\x01e,\x01f]*'

相关参数介绍如下：

- **tablename.to.index**：表示创建索引的数据表的名称。

  说明

  当使用 **tablename.to.index** 创建索引时，若数据表为空表，创建的索引状态为 ACTIVE，否则索引状态为 INACTIVE。

- **indexspecs.to.addandbuild**（可选）：表示创建时同时生成索引数据，数据表数据量较大时**不建议使用**，建议使用索引数据生成工具完成索引数据生成。

  说明

  indexspecs.to.addandbuild 和 **tablename.to.index** 不能同时使用，当使用 **indexspecs.to.addandbuild** 时，索引状态为 BUILDING，当索引数据完整生成后，索引状态会修改为 ACTIVE。

- **tablename.to.index**：表示创建索引的数据表的名称。
- **indexspecs.to.add**：表示索引名与对应数据表的列的映射（索引列定义）。
- **indexspecs.covered.to.add**（可选）：表示索引中冗余存储的数据表的列（覆盖列定义）。
- **indexspecs.covered.family.to.add**（可选）：表示索引表冗余存储的数据表的列族（覆盖列族定义）。
- **indexspecs.coveredallcolumn.to.add**（可选）：表示索引表冗余存储数据表中的所有数据（覆盖所有列）。
- **indexspecs.splitkeys.to.set**（可选）：表示索引表预分区切分点，**建议指定**，避免索引表 Region 成为热点。预分区指定格式为：
  - '#'用于分隔索引。
  - splitkey 包含在'[]'中。

- ','用于分隔 splitkey。

说明

预分区每个 splitkey 必须由**\x01** 开头。

上述命令中的参数描述如下：

- **idx1、idx2、idx3**：表示索引名称。
- **cf1、cf2**：表示列族名称。
- **c1、c2、c3、c4**：表示列名称。
- **string**：表示数据类型。支持 STRING、INTEGER、FLOAT、LONG、DOUBLE、SHORT、BYTE 和 CHAR。

说明

- '#'用于分隔索引，';' 用于分隔列族，','用于分隔列限定符。
- 列名及其数据类型应包含在'[]'中。
- 列名及其数据类型通过'->'分隔。
- 如果未指定具体列的数据类型，则使用默认数据类型（string）。

8.9.3.2 索引信息查询

场景介绍

用户可以使用全局二级索引工具批量查看某个数据表相关索引的定义及状态。

使用方法

在 HBase 客户端执行以下命令可查看索引的定义及状态：

hbase org.apache.hadoop.hbase.hindex.global.mapreduce.GlobalTableIndexer -Dtablename.to.show='*数据表名称*'

查询结果如图 8-3 所示，会打印索引列定义、覆盖列定义、TTL、预分区信息、索引状态等：

图8-3 索引查询结果

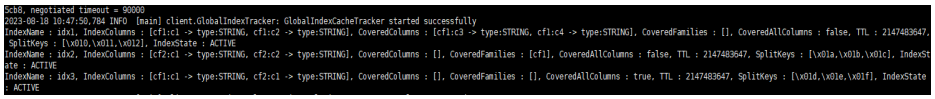

8.9.3.3 删除索引

场景介绍

用户可以使用全局二级索引工具删除某个索引。

使用方法

在 HBase 客户端执行以下命令可删除某个索引：

hbase org.apache.hadoop.hbase.hindex.global.mapreduce.GlobalTableIndexer -Dtablename.to.index='*table*' **-Dindexnames.to.drop=**'*idx1#idx2*'

相关参数介绍如下：

- **tablename.to.index**：表示需删除的索引所在的表名称
- **indexnames.to.drop**：表示需要删除的索引名称，可以同时指定多个，用#号分隔。

8.9.3.4 修改索引状态

索引状态介绍

索引状态反映了索引当前的使用情况，全局二级索引支持以下五种状态：

- ACTIVE：索引正常，可以正常读写。
- UNUSABLE：索引被禁用，索引数据会正常写入，查询时无法使用这个索引。
- INACTIVE：索引异常，索引数据与数据表不一致，跳过生成这个索引的索引数据，查询数据时无法使用这个索引。
- BUILDING：索引数据正常批量生成，索引数据生成工具执行结束会自动转换到ACTIVE 状态，此状态下可以正常读写。
- DROPPING：索引正在被删除，跳过生成这个索引的索引数据，查询数据时无法使用这个索引。

基于工具的索引状态修改，支持图 8-4 所示的状态转换。

图8-4 索引状态转换图

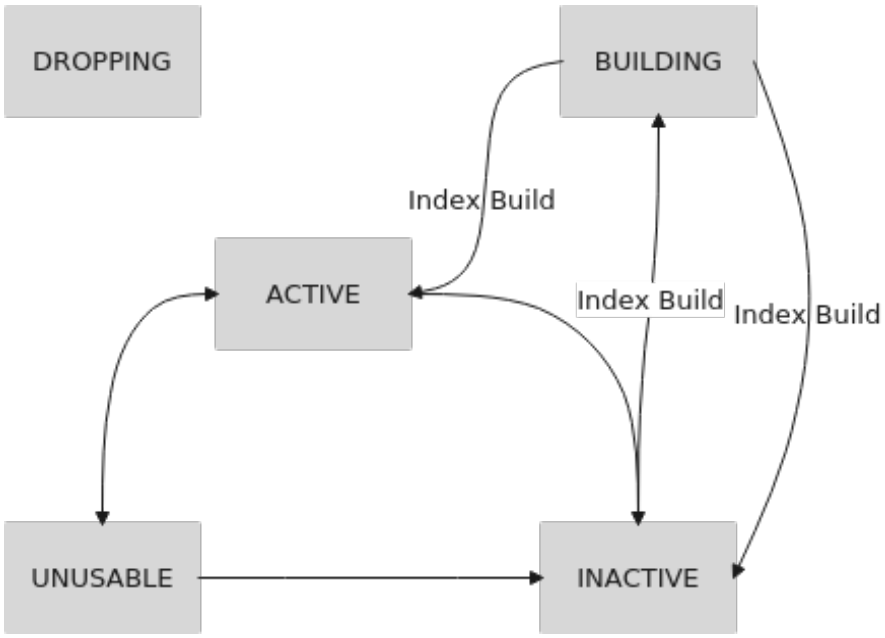

场景介绍

用户可以使用全局二级索引工具禁用/启用某个索引。

使用方法

在 HBase 客户端执行以下命令可禁用/启用某个索引：

hbase org.apache.hadoop.hbase.hindex.global.mapreduce.GlobalTableIndexer -Dtablename.to.index='*table*' **-D**[idx_state_opt]='*idx1*'

相关参数介绍如下:

- **tablename.to.index**：表示需修改索引状态的数据表的名称。
- **idx_state_opt**：表示修改索引的目标状态，可选参数如下：
  - **indexnames.to.inactive**：表示将指定的索引转换为 INACTIVE 状态。
  - **indexnames.to.active**：表示将指定的索引转换为 ACTIVE 状态。
  - **indexnames.to.unusable**：表示将指定的索引转换为 UNUSABLE 状态。

例如：修改状态为 ACTIVE 的 **table** 表的索引 **idx1** 的状态为 UNUSABLE：

hbase org.apache.hadoop.hbase.hindex.global.mapreduce.GlobalTableIndexer -Dtablename.to.index='table' -Dindexnames.to.unusable='idx1'

执行成功后，再次查看索引信息：

hbase org.apache.hadoop.hbase.hindex.global.mapreduce.GlobalTableIndexer -Dtablename.to.show='table'

如图 8-5 所示，**idx1** 的索引状态已被修改：

图8-5 idx1 索引状态

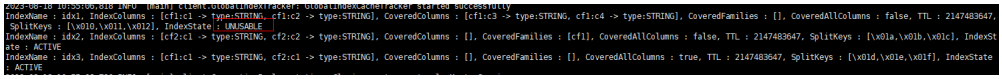

8.9.3.5 索引数据批量构建

场景介绍

在用户的表中预先存在大量数据的情况下，基于 MapReaduce 任务，批量构建已有数据的索引数据。

使用方法

须知

- 只有处于 INACTIVE 状态的索引才能进行批量构建，如需重建索引数据，请先修改索引状态。
- 数据表中存在大量数据时，构建耗时较长，建议使用 nohup 命令放在后台执行，避免操作被意外中断。

在 HBase 客户端执行以下命令可批量构建已有数据的索引数据：

hbase org.apache.hadoop.hbase.hindex.global.mapreduce.GlobalTableIndexer -Dtablename.to.index='*table*' -Dindexnames.to.build='*idx1*'

相关参数介绍如下:

- **tablename.to.index**：表示需修改索引状态的数据表的名称。
- **indexnames.to.build**：指定的需要批量生成数据的索引名，可以同时指定多个，用#号分割。
- **hbase.gsi.cleandata.enabled**（可选）：表示构建索引数据前是否需要清空索引表，默认值为“false”。
- **hbase.gsi.cleandata.timeout**（可选）：表示构建索引数据前等待清空索引表超时时间，默认值为“1800”，单位为：秒。

8.9.3.6 索引一致性检查与修复

场景介绍

可使用全局二级索引工具检查用户数据和索引数据的一致性，如果索引数据与用户数据不一致，该工具可用于重新构建索引数据。

使用方法

在 HBase 客户端执行以下命令可检查数据一致性，若不一致，将重新构建索引数据。一致性检查结果会保存到“*{数据表所在的NameSpace}*:**GSI_INCONSISTENCY_TABLE**”表中。

hbase org.apache.hadoop.hbase.hindex.global.tools.GlobalHIndexConsistencyTool -dt *table1* **-n** *idx3* **-src** *BOTH* **-r**

相关参数介绍如下：

- **-dt,--data-table**：要进行一致性检查的数据表名称。
- **-n,--index-name**：要进行一致性检查的索引名称。
- **-src,--source**：检查模式选择，默认为“**BOTH**”，支持以下模式：
  - **INDEX_TABLE_SOURCE**：索引表作为源表。
  - **DATA_TABLE_SOURCE**：数据表作为源表。
  - **BOTH**：索引表和数据表均作为源表。
- **-r,--repair**：索引数据修复选项，添加此参数，表示检查后进行修复。
- **-sc,--scan-caching**（可选） ：一致性检查/修复的 MapReduce 任务中 scan caching 大小。

8.9.4 全局二级索引 API 介绍

使用全局索引的 API 都在类“org.apache.hadoop.hbase.hindex.global.GlobalIndexAdmin”中，相关接口介绍如下：

操作	接口	描述
添加索引	addIndices()	将索引添加到没有数据的表中。调用此接口会将用户指定的索引添加到表中，但会跳过生成索引数据。该接口的使用场景为用户想要在具有大量预先存在用户数据的表上批量添加索引，然后使用 GlobalTableIndexer 工具来构建索引数据。
	addIndicesWithData()	将索引添加到有数据的表中。此方法将用户指定的索引添加到表中，并会对已经存在的用户数据创建对应的索引数据，也可先调用该方法生成索引再在存入用户数据的同时生成索引数据。当数据表中存在大量数据时，不建议使用此接口。
删除索引	dropIndices()	仅删除索引，索引元数据与索引数据均会被删除，在此操作之后，索引不能用于 **scan**/**filter** 操作。
索引状态修改	alterGlobalIndicesUnusable()	禁用用户指定的索引，使其不再可用于 **scan**/**filter** 操作。
	alterGlobalIndicesActive()	启用用户指定的索引，使其可用于 **scan**/**filter** 操作。
	alterGlobalIndicesInactive()	禁用用户指定的索引，且放弃生成索引数据，不再可用于 **scan**/**filter** 操作，通常用于索引修复流程。
查看已创建的索引	listIndices()	可用于列出给定表中的所有索引。

8.9.5 基于索引查询数据

基于索引查询

在具有索引的用户表中，可以使用 SingleColumnValueFilter 来查询数据。当查询条件可以命中索引时，查询速度远快于原表查询。

索引的命中规则如下：

- 多个 AND 条件查询
  - 当用于查询的列至少包含索引第一个列时，使用索引会提高查询性能。
    例如，为 C1、C2 和 C3 创建组合索引。

该索引在以下情况下生效：

Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol2）AND Filter_Condition（IndexCol3）

Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol2）

Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol3）

Filter_Condition（IndexCol1）

该索引在下列情况下不生效：

Filter_Condition（IndexCol2）AND Filter_Condition（IndexCol3）

Filter_Condition（IndexCol2）

Filter_Condition（IndexCol3）

- 当在查询中使用“索引列和非索引列”进行过滤时，使用索引可提高查询性能。当非索引列命中覆盖列时，查询性能最优；如果有需经常查询的非索引列，建议定义为覆盖列。例如：

  Filter_Condition（IndexCol1）AND Filter_Condition（NonIndexCol1）

  Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol2）AND Filter_Condition（NonIndexCol1）

- 当多个列用于查询时，只能为组合索引中的最后一列指定值范围，而其他列只能设置为指定值。

  例如，为 C1、C2 和 C3 创建组合索引。在范围查询中，只能为 C3 设置数值范围，过滤条件为“C1 = XXX，C2 = XXX，C3 = 数值范围”。

- 多个 OR 条件查询

  例如，为 C1、C2 和 C3 创建组合索引。

  - 仅对索引列首个字段进行过滤时（支持范围过滤），使用索引可提高查询性能。

    Filter_Condition（IndexCol1）OR Filter_Condition（IndexCol1）OR Filter_Condition（IndexCol1）

  - 对非索引和非索引列进行过滤时，无法命中索引，查询性能不会提高。

    Filter_Condition（IndexCol1）OR Filter_Condition（NonIndexCol1）

  - 组合查询时，最外层包含 OR 条件时无法命中索引，查询性能不会提高。

    Filter_Condition（IndexCol1）OR Filter_Condition（NonIndexCol1）

    （Filter_Condition（IndexCol1）AND Filter_Condition（IndexCol2））OR（Filter_Condition（NonIndexCol1））

说明

减少 **OR** 条件使用，尤其是 OR 条件+范围条件，命中索引的情况下也会造成大范围查询，速度较慢。

8.10 配置 RSGroup

操作场景

HBase 服务的数据节点较多，需要根据不同的业务规模将数据节点资源分配给特定的业务，从而达到资源独占使用的目的。当 AZ 容灾特性被开启时，为了保证 AZ 容灾生效，保障业务可靠性，在为 RSGroup 分配 RegionServer 时，需遵循分配结果能使该 RSGroup 在每个 AZ 下都存在 RegionServer 实例的规则。

前提条件

- 已登录 Manager。
- 登录角色拥有 Manager 管理员权限。
- 将 RSGroup 最小节点数设置为下述三种情况的最大值。
  - 为了保证服务的可靠性，RSGroup 内的 RegionServer 节点数量需要配置一定的冗余量，确保冗余节点数>（RSGroup 内业务表 region 总数/2000）*50%。
  - 如果系统表在单独的 RSGroup，需要确保该 RSGroup 的节点数量>2。
  - 为了不影响滚动重启功能，如果 RegionServer 节点总数在 300 以内，那么单个 RSGroup 的节点数量不应小于 3。如果 RegionServer 节点总数大于等于 300，那么单个 RSGroup 的节点数量不应小于（节点数*1%）+1。

可能的影响

- 由于 RSGroup 约束了 region 转移可用的 RegionServer 节点，如果 RSGroup 内部分节点故障或者滚动重启，可能会触发 region 超过阈值的告警，也可能会导致业务性能下降。
- 当提交修改 RSGroup 请求产生大量 region 转移任务时，如果进行相关 RSGroup 操作会面临失败。需先观察原生页面的 region 转移情况，等待转移任务结束后再进行后续操作。

操作步骤

创建 RSGroup

在 FusionInsight Manager 界面，选择“集群 > 服务 > HBase > RSGroup 管理”。

步骤 1 单击“添加 RSGroup”按钮，在弹出的添加 RSGroup 页面填写新增的 RSGroup 名称，RSGroup 名称包括数字、字母或下划线（_），长度为 1-120 个字符。然后单击“确定”。

查看 RSGroup

选择待操作的 RSGroup，在操作列单击“查看”，即可在弹出框中查看该 RSGroup 的 RegionServers 详情和 Tables 详情。

说明

default RSGroup 是 HBase 的默认 RSGroup，所有已启动并且未手动添加到其他 RSGroup 的 RegionServer 节点都会添加到 default RSGroup。

修改 RSGroup 名称

选择待操作的 RSGroup，在操作列单击“修改名称”。在修改 RSGroup 名称弹出框中填写 RSGroup 新名称，新名称不能与已存在名称相同，单击“确定”。

修改 RSGroup

单击待操作的 RSGroup 名称，跳转到修改 RSGroup 页面。

步骤 2 勾选欲分配的 RegionServer 实例，单击“下一步”。

说明

- 一次分配操作仅允许勾选来自同一 RSGroup 的一个到多个 RegionServer 实例，且 default 组中的 RegionServer 的运行状态不为良好时不允许被勾选分配。若想要分配来自不同 RSGroup 的 RegionServer 实例，请分多次修改操作进行分配。
- 开启跨 AZ 特性时，分配操作需要保证分配结果能使每个 AZ 中均存在该 RSGroup 的 RegionServer 实例，而且无法对开启前已分配的 RSGroup 进行 AZ 约束校验。

步骤 3 勾选欲分配的表，单击“下一步”。

说明

- 一次分配操作仅允许勾选来自同一 RSGroup 的一个或多个表。若想要分配来自不同 RSGroup 的 RegionServer 实例，请分多次修改来进行分配。
- 当修改 RSGroup 操作中同时勾选了分配 RegionServer 和表时，RegionServer 和表需来自同一 RSGroup。
- 当修改 RSGroup 操作中只勾选了分配表，且分配前该 RSGroup 下不存在 RegionServer，则将修改失败。

单击“提交”。修改成功后，提示修改结果，页面将跳转至 RSGroup 列表展示界面。

当提示“任务入队”相关信息时，页面将跳转至 RSGroup 列表展示界面。此次提交的修改 RSGroup 请求，已进入任务队列中，请按照界面提示，观察原生界面 region 转移完成，确认入队任务执行成功，再进行后续操作。

删除 RSGroup

在 RSGroup 管理页面，勾选需要删除的 RSGroup，然后选择“删除 RSGroup > 确定”。

说明

RSGroup 删除失败可能原因及解决方法：

1. “default”组不允许被删除。
2. 该 RSGroup 中仍包含 RegionServer 或 Table，请将该 RSGroup 中 RegionServer 或 Table 分配给别的 RSGroup 组后，再进行删除。

----结束

8.11 配置 HBase 容灾

操作场景

HBase 集群容灾作为提高 HBase 集群系统高可用性的一个关键特性，为 HBase 提供了实时的异地数据容灾功能。它对外提供了基础的运维工具，包含灾备关系维护，重建，数据校验，数据同步进展查看等功能。为了实现数据的实时容灾，可以把本 HBase 集群中的数据备份到另一个集群。支持 HBase 表普通写数据与 Bulkload 批量写数据场景下的容灾。

前提条件

- 主备集群都已经安装并启动成功，且获取集群的管理员权限。
- 必须保证主备集群间的网络畅通和端口的使用。
- 如果主集群部署为安全模式且不由一个 FusionInsight Manager 管理，主备集群必须已配置跨集群互信。如果主集群部署为普通模式，不需要配置跨集群互信。
- 主备集群必须已配置跨集群拷贝。
- 主备集群上的时间必须一致，而且主备集群上的 NTP 服务必须使用同一个时间源。
- 必须在主备集群的所有节点的 hosts 文件中，配置主备集群所有机器的机器名与业务 IP 地址的对应关系。

说明

若主集群的客户端安装在集群外的节点上，也需在该节点的 hosts 文件中配置主备集群所有机器的机器名与业务 IP 地址的对应关系。

- 主备集群间的网络带宽需要根据业务流量而定，不应少于最大的可能业务流量。
- 主备集群安装的 MRS 版本需要保持一致。
- 备集群规模不小于主集群规模。

使用约束

- 尽管容灾提供了实时的数据复制功能，但实际的数据同步进展，由多方面的因素决定的，例如，当前主集群业务的繁忙程度，备集群进程的健康状态等。因此，在正常情形下，备集群不应该接管业务。极端情形下是否可以接管业务，可由系统维护人员以及决策人员根据当前的数据同步指标来决定。
- 容灾功能当前仅支持一主一备。
- 通常情况下，不允许对备集群的灾备表进行表级别的操作，例如修改表属性、删除表等，一旦误操作备集群后会造成主集群数据同步失败、备集群对应表的数据丢失。
- 主集群的 HBase 表已启用容灾功能同步数据，用户每次修改表的结构时，需要手动修改备集群的灾备表结构，保持与主集群表结构一致。

操作步骤

配置主集群普通写数据容灾参数。

登录主集群的 Manager。

步骤 1 选择“集群 > *待操作集群的名称* > 服务 >HBase> 配置”，单击“全部配置”，进入 HBase 配置界面。

步骤 2 （可选）如表 8-6 所示，为 HBase 容灾操作过程中的可选配置项，您可以根据描述来进行参数配置，或者使用缺省提供的值。

表8-6 可选配置项

配置入口	配置项	缺省值	描述
“HMaster > 性能”	hbase.master.logcleaner.ttl	600000	指定 HLog 的保存期限。如果配置值为“604800000”（单位：毫秒），表示 HLog 的保存期限为 7 天。
	hbase.master.cleaner.interval	60000	HMaster 清理过去 HLog 文件的周期，即超过设置的时间的 HLog 会被自动删除。建议尽可能配置大的值来保留更多的 HLog。
“RegionServer > Replication”	replication.source.size.capacity	16777216	edits 最大大小。单位为 byte。如果 edit 大小超过这个值 Hlog edits 将会发送到备集群。
	replication.source.nb.capacity	25000	edits 最大数目，这是另一个触发 Hlog edits 到备集群的条件。当主集群同步数据到备集群中时，主集群会从 HLog 中读取数据，此时会根据本参数配置的个数读取并发送。与“replication.source.size.capacity”一起配置使用。
	replication.source.maxretriesmultiplier	10	replication 出现异常时的最大重试次数。
	replication.source.sleepforretries	1000	每次重试的 sleep 时间。（单位：毫秒）
	hbase.regionserver.replication.handler.count	6	RegionServer 上的 replication RPC 服务器实例数。

配置主集群 Bulkload 批量写数据容灾参数。

是否启用 Bulkload 批量写数据容灾功能？

是，执行步骤 5。

否，执行步骤 8。

步骤 3 选择“集群 > *待操作集群的名称* > 服务 >HBase> 配置”，单击“全部配置”，进入 HBase 配置界面。

步骤 4 搜索并修改“hbase.replication.bulkload.enabled”参数，将配置项的值修改为“true”，启用 Bulkload 批量写数据容灾功能。

步骤 5 搜索并修改“hbase.replication.cluster.id”参数，表示标识主集群 HBase 的 ID，用于备集群连接主集群。参数值支持大小写字母、数字和下划线（_），长度不超过 30。

重启 HBase 服务并安装客户端。

单击“保存”，保存配置。在弹出的窗口中单击“确定”。重启 HBase 服务。

步骤 6 在主备集群，选择“集群 > 服务 >HBase> 更多 > 下载客户端”，下载客户端并安装。

添加主备集群容灾关系。

以“hbase”用户进入主集群的 HBase shell 界面。

步骤 7 在 HBase shell 中执行如下命令，创建主集群 HBase 与备集群 HBase 之间的容灾同步关系。

add_peer '*备集群 ID***', CLUSTER_KEY => "***备集群 ZooKeeper 业务 ip 地址***", CONFIG => {"hbase.regionserver.kerberos.principal" => "***备集群 RegionServer principal***", "hbase.master.kerberos.principal" => "***备集群 HMaster principal***"}**

- 备集群 ID 表示主集群识别备集群使用的 id，请重新指定 id 值。可以任意指定，建议使用数字。
- 备集群 ZooKeeper 地址信息包含 ZooKeeper 业务 IP 地址、侦听客户端连接的端口和备集群的 HBase 在 ZooKeeper 上的根目录。
- hbase.master.kerberos.principal 、hbase.regionserver.kerberos.principal 在备集群 HBase hbase-site.xml 配置文件中查找。

例如，添加主备集群容灾关系，执行：**add_peer '***备集群 ID***', CLUSTER_KEY => "*192.168.40.2,192.168.40.3,192.168.40.4:24002:/hbase*", CONFIG => {"hbase.regionserver.kerberos.principal" => "*hbase/hadoop.hadoop.com@HADOOP.COM*", "hbase.master.kerberos.principal" => "*hbase/hadoop.hadoop.com@HADOOP.COM*"}**

步骤 8 （可选）如果启用 Bulkload 批量写数据容灾功能，主集群 HBase 客户端配置必须拷贝到备集群。

- 在备集群 HDFS 创建目录/hbase/replicationConf/*主集群 hbase.replication.cluster.id*
- 主机群 HBase 客户端配置文件，拷贝到备集群 HDFS 目录/hbase/replicationConf/*主集群 hbase.replication.cluster.id*

  例如：**hdfs dfs -put HBase/hbase/conf/core-site.xml HBase/hbase/conf/hdfs-site.xml HBase/hbase/conf/yarn-site.xml hdfs://***NameNode IP***:*25000*/hbase/replicationConf/*source_cluster***

启用 HBase 容灾功能同步数据。

检查备集群的 HBase 服务实例中，是否已存在一个命名空间，与待启用容灾功能的 HBase 表所属的命名空间名称相同？

- 是，存在同名的命令空间，执行步骤 14。
- 否，不存在同名的命令空间，需先在备集群的 HBase shell 中，创建同名的命名空间，然后执行步骤 14。

步骤 9 在主集群的 HBase shell 中，以“hbase”用户执行以下命令，启用将主集群表的数据实时容灾功能，确保后续主集群中修改的数据能够实时同步到备集群中。

一次只能针对一个 HTable 进行数据同步。

enable_table_replication '*表名*'

说明

- 若备集群中不存在与要开启实时同步的表同名的表，则该表会自动创建。
- 若备集群中存在与要开启实时同步的表同名的表，则两个表的结构必须一致。
- 若'表名'设置了加密算法 SMS4 或 AES，则不支持对此 HBase 表启用将数据从主集群实时同步到备集群的功能。
- 若备集群不在线，或备集群中已存在同名但结构不同的表，启用容灾功能将失败。
- 若主集群中部分 Phoenix 表启用容灾功能同步数据，则备集群中不能存在与主集群 Phoenix 表同名的普通 HBase 表，否则启用容灾功能失败或影响备集群的同名表正常使用。
- 若主集群中 Phoenix 表启用容灾功能同步数据，还需要对 Phoenix 表的元数据表启用容灾功能同步数据。需配置的元数据表包含 SYSTEM.CATALOG、SYSTEM.FUNCTION、SYSTEM.SEQUENCE 和 SYSTEM.STATS。
- 若主集群的 HBase 表启用容灾功能同步数据，用户每次为 HBase 表增加新的索引，需要手动在备集群的灾备表增加二级索引，保持与主集群二级索引结构一致。

步骤 10 （可选）如果 HBase 没有使用 Ranger，在主集群的 HBase shell 中，以“hbase”用户执行以下命令，启用主集群的 HBase 表权限控制信息数据实时容灾功能。

enable_table_replication 'hbase:acl'

创建用户

登录备集群的 FusionInsight Manager，选择“系统 > 权限 > 角色 > 添加角色”创建一个角色，并根据主集群 HBase 源数据表的权限，为角色添加备数据表的相同权限。

步骤 11 选择“系统 > 权限 > 用户 > 添加用户”创建一个用户，根据业务需要选择用户类型为“人机”或“机机”，并将用户加入创建的角色。使用新创建的用户，访问备集群的 HBase 容灾数据。

说明

- 主集群 HBase 源数据表修改权限时，如果备集群需要正常读取数据，请修改备集群角色的权限。
- 如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.9 添加 HBase 的 Ranger 访问权限策略。

同步主集群表数据。

检查配置 HBase 容灾并启用数据同步后，主集群是否已存在表及数据，且历史数据需要同步到备集群？

- 是，存在表且需要同步数据，以 HBase 表用户登录安装主集群 HBase 客户端的节点，并执行 kinit 用户名认证身份。该用户需要拥有表的读写权限，以及“hbase:meta”表的执行权限。然后执行步骤 19。
- 否，不需要同步数据，任务结束。

步骤 12 配置 HBase 容灾时不支持自动同步表中的历史数据，需要对主集群的历史数据进行备份，然后再手动恢复历史数据到备集群中。

手动恢复即单表的恢复，单表手动恢复通过 Export、distcp、Import 来完成。

单表手动恢复操作步骤：

1. 从主集群导出表中数据。

   hbase org.apache.hadoop.hbase.mapreduce.Export -Dhbase.mapreduce.include.deleted.rows=true *表名 保存源数据的目录*

   例如，**hbase org.apache.hadoop.hbase.mapreduce.Export -Dhbase.mapreduce.include.deleted.rows=true t1 /user/hbase/t1**

2. 把导出的数据复制到备集群。

   hadoop distcp *主集群保存源数据的目录 hdfs://ActiveNameNodeIP:8020/备集群保存源数据的目录*

   其中，ActiveNameNodeIP 是备集群中主 NameNode 节点的 IP 地址。

   例如，**hadoop distcp /user/hbase/t1 hdfs://192.168.40.2:8020/user/hbase/t1**

3. 使用备集群 HBase 表用户，在备集群中导入数据。

   在备集群 HBase shell 界面，使用“hbase”用户执行以下命令保持写数据状态：

   set_clusterState_active

   界面提示以下信息表示执行成功：

   ```
   hbase(main):001:0> set_clusterState_active
   => true
   ```

   hbase org.apache.hadoop.hbase.mapreduce.Import *-Dimport.bulk.output=备集群保存输出的目录 表名 备集群保存源数据的目录*

   hbase org.apache.hadoop.hbase.mapreduce.LoadIncrementalHFiles *备集群保存输出的目录 表名*

   例如：

   ```
   hbase(main):001:0> set_clusterState_active
   => true
   ```

   hbase org.apache.hadoop.hbase.mapreduce.Import -Dimport.bulk.output=/user/hbase/output_t1 t1 /user/hbase/t1

   hbase org.apache.hadoop.hbase.mapreduce.LoadIncrementalHFiles /user/hbase/output_t1 t1

在 HBase 客户端执行以下命令，校验主备集群同步的数据。启用容灾功能同步功能后，也可以执行该命令检验新的同步数据是否一致。

hbase org.apache.hadoop.hbase.mapreduce.replication.VerifyReplication --starttime=*开始时间* **--endtime**=*结束时间 列族名称 备集群 ID 表名*

说明

- 开始时间必须早于结束时间
- 开始时间和结束时间需要填写时间戳的格式，例如执行 date -d "2015-09-30 00:00:00" +%s 将普通时间转化为时间戳格式。

指定主备集群写数据状态。

在主集群 HBase shell 界面，使用“hbase”用户执行以下命令保持写数据状态。

set_clusterState_active

界面提示以下信息表示执行成功：

```
hbase(main):001:0> set_clusterState_active
=> true
```

步骤 13 在备集群 HBase shell 界面，使用“hbase”用户执行以下命令保持只读数据状态。

set_clusterState_standby

界面提示以下信息表示执行成功：

```
hbase(main):001:0> set_clusterState_standby
=> true
```

----结束

相关命令

表8-7 HBase 容灾

操作	命令	描述
建立灾备关系	add_peer '*备集群 ID*', CLUSTER_KEY => "*备集群 ZooKeeper 业务 ip 地址*", CONFIG => {"hbase.regionserver.kerberos.principal" => "*备集群 RegionServer principal*", "hbase.master.kerberos.principal" => "*备集群 HMaster principal*"} **add_peer '1','zk1,zk2,zk3:2181:/hbase1'** **2181** 表示集群中 ZooKeeper 的端口号。	建立主集群与备集群的关系，让其互相对应。 如果启用 Bulkload 批量写数据容灾： • 在备集群 HDFS 创建目录 /hbase/replicationConf/*主集群 hbase.replication.cluster.id* • 主集群 HBase 客户端配置文件，拷贝到备集群 HDFS 目录 /hbase/replicationConf/*主集群 hbase.replication.cluster.id*
移除灾备关系	**remove_peer** *'备集群 ID'* 示例： **remove_peer '1'**	在主集群中移除备集群的信息。
查询灾备关系	**list_peers**	在主集群中查询已经设置的备集群的信息，主要为 Zookeeper 信息。
启用用户表实时同步	**enable_table_replication** *'表名'* 示例： **enable_table_replication 't1'**	在主集群中，设置已存在的表同步到备集群。
禁用用户表实时同	**disable_table_replication** *'表名'* 示例：	在主集群中，设置已存在的表不同步到备集群。

操作	命令	描述
步	**disable_table_replication 't1'**	
主备集群数据校验	**bin/hbase org.apache.hadoop.hbase.mapreduce.replication.VerifyReplication --starttime**=*开始时间* **--endtime=***结束时间 列族名称 备集群 ID 表名*	检查指定的表在主备集群间的数据是否一致。 命令行中参数说明如下： • 开始时间：如果未设置，则取默认的开始时间为 0。 • 结束时间：如果未设置，则取默认的结束时间为当前操作提交的时间。 • 表名：如果未输入表名，则默认校验所有的启用了实时同步的用户表。
切换数据写入状态	**set_clusterState_active** **set_clusterState_standby**	设置集群 HBase 表是否可写入数据。
新增或更新已经在对端集群保存的主集群中 HDFS 配置	**hdfs dfs -put -f HBase/hbase/conf/core-site.xml HBase/hbase/conf/hdfs-site.xml HBase/hbase/conf/yarn-site.xml hdfs://**备集群 ***NameNode IP:PORT*/hbase/replicationConf/***主集群 hbase.replication.cluster.id*	启用包含 Bulkload 数据的容灾，在主集群修改 HDFS 参数时，新的参数值默认不会从主集群自动同步到备集群，需要手动执行命令同步。受影响的参数如下： • “fs.defaultFS” • “dfs.client.failover.proxy.provider.hacluster” • “dfs.client.failover.connection.retries.on.timeouts” • “dfs.client.failover.connection.retries” 例如，“fs.defaultFS”修改为“hdfs://hacluster_sale”， 主集群 HBase 客户端配置文件，重新拷贝到备集群 HDFS 目录 /hbase/replicationConf/*主集群 hbase.replication.cluster.id*
在开启批量加载数据复制功能（即“hbase.replication.bulkload.enabled”参数值为“true”）	**disable_bulkload_replication** *'peerId','表名'* 示例： **disable_bulkload_replication '1','t1'**	主集群配置了 Bulkload 批量写数据容灾，并启用了用户表的实时同步能力，可使用该命令中断表的 Bulkload 数据同步能力。 *peerId* 可通过 **list_peers** 命令查看备集群信息获取，进行命令拼接。 仅 MRS 3.3.0 及之后版本支持。

操作	命令	描述
的情况下，禁用单表的批量加载数据复制能力		
在开启批量加载数据复制功能（即“hbase.replication.bulkload.enabled”参数值为“true”）的情况下，启用单表的批量加载数据能力	**enable_bulkload_replication** *'peerId','表名'* 示例： **enable_bulkload_replication '1','t1'**	主集群配置了 Bulkload 批量写数据容灾，并启用了用户表的实时同步能力，使用 **disable_bulkload_replication** 中断了该表的 Bulkload 数据同步后想再次开启 Bulkload 数据同步时，可使用该命令。 通过 **get_peer_config** *'peerId'*命令查看对应备集群容灾配置。其中以 **BULREP_**前缀开头拼接表名的字段，对应值为“false”时，表明该表被禁用了 Bulkload 数据同步。 **说明** • 仅 MRS 3.3.0 及之后版本支持。 • 中断 Bulkload 数据同步期间的数据在重新开启后不会被同步。 • 由于该操作在服务端同步生效需要几分钟，为了避免同步时间差导致 Bulkload 数据丢失，可通过搜索 RegionServer 运行日志，确认执行该命令后 RegionServer 上均存在“Update peer configs succeed.”日志打印，再开启后续主集群 Bulkload 数据操作。

8.12 配置 HBase 数据压缩和编码

操作场景

HBase 可以通过对 HFile 中的 data block 编码，减少 keyvalue 中 key 的重复部分，从而减少空间的使用。目前对 data block 的编码方式有：NONE、PREFIX、DIFF、FAST_DIFF 和 ROW_INDEX_V1，其中 NONE 表示不使用编码。另外，HBase 还支持使用压缩算法对 HFile 文件进行压缩，默认支持的压缩算法有：NONE、GZ、SNAPPY 和 ZSTD，其中 NONE 表示 HFile 不压缩。

这两种方式都是作用在 HBase 的列簇上，可以同时使用，也可以单独使用。

前提条件

- 已安装 HBase 客户端。例如，客户端安装目录为“/opt/client”。
- 如果 HBase 已经开启了鉴权，操作的用户还需要具备对应的操作权限。即创建表时需要具备对应的 namespace 或更高级别的创建(C)或者管理(A)权限，修改表时需要具备已创建的表或者更高级别的创建(C)或者管理(A)权限。具体的授权操作请参考 8.3 创建 HBase 角色章节。

操作步骤

创建时设置 data block encoding 和压缩算法。

- **方法一：使用 hbase shell**。
  a. 以客户端安装用户，登录安装客户端的节点。
  b. 执行以下命令切换到客户端目录。
     cd /opt/client
  c. 执行以下命令配置环境变量。
     source bigdata_env
  d. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。
     kinit *组件业务用户*
     例如，**kinit hbaseuser**。
  e. 直接执行 HBase 组件的客户端命令。
     hbase shell
  f. 创建表。
     create '*t1***', {NAME => '***f1***', COMPRESSION => '***SNAPPY***', DATA_BLOCK_ENCODING => '***FAST_DIFF***'}**

  说明
  - t1：表名。
  - f1：列簇名。
  - SNAPPY：该列簇使用的压缩算法为 SNAPPY。
  - FAST_DIFF：使用的编码方式为 FAST_DIFF。
  - {}内的参数为指定列簇的参数，多个列簇可以用多个{}，然后用逗号隔开。关于建表语句的更多使用说明可以在 **hbase shell** 中执行 **help 'create'** 进行查看。

- **方法二：使用 Java API**。
  以下代码片段仅展示如何在建表时设置列簇的编码和压缩方式，完整的建表代码以及如何通过代码建表请参考中“HBase 开发指南 > 修改表”章节。

```
TableDescriptorBuilder htd =
TableDescriptorBuilder.newBuilder(TableName.valueOf("t1"));// 创建 t1 表的
descriptor.
ColumnFamilyDescriptorBuilder hcd =
ColumnFamilyDescriptorBuilder.newBuilder(Bytes.toBytes("f1"));//  创建列簇 f1 的
builder.
hcd.setDataBlockEncoding(DataBlockEncoding.FAST_DIFF);// 设置列簇 f1 的编码方式为
FAST_DIFF.
hcd.setCompressionType(Compression.Algorithm.SNAPPY);// 设置列簇 f1 的压缩算法为
```

```
SNAPPY
htd.setColumnFamily(hcd.build())// 将列簇 f1 添加到 t1 表的 descriptor.
```

对已存在的表设置或修改 data block encoding 和压缩算法

- **方法一：使用 hbase shell**。
  a. 以客户端安装用户，登录安装客户端的节点。
  b. 执行以下命令切换到客户端目录。
     cd /opt/client
  c. 执行以下命令配置环境变量。
     source bigdata_env
  d. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。
     kinit *组件业务用户*
     例如，**kinit hbaseuser**。
  e. 直接执行 HBase 组件的客户端命令。
     hbase shell
  f. 执行修改表的命令。
     alter '*t1***', {NAME => '***f1***', COMPRESSION => '***SNAPPY***', DATA_BLOCK_ENCODING => '***FAST_DIFF***'}**
- **方法二：使用 Java API**。
  以下代码片段仅展示如何修改指定表的已有列簇的编码和压缩方式，完整的修改表代码以及如何通过代码修改表请参考 HBase 应用开发指南：

```
TableDescriptor htd = admin.getDescriptor(TableName.valueOf("t1"));// 获取表 t1 的 descriptor
ColumnFamilyDescriptor originCF = htd.getColumnFamily(Bytes.toBytes("f1"));// 获取列簇 f1 的 descriptor
builder.ColumnFamilyDescriptorBuilder hcd = ColumnFamilyDescriptorBuilder.newBuilder(originCF);// 通过已有的列簇属性构造一个 builder
hcd.setDataBlockEncoding(DataBlockEncoding.FAST_DIFF);// 重新设置列簇的编码方式为 FAST_DIFF
hcd.setCompressionType(Compression.Algorithm.SNAPPY);// 重新设置列簇的压缩算法为 SNAPPY
admin.modifyColumnFamily(TableName.valueOf("t1"), hcd.build());// 提交到服务端修改列簇 f1 的属性
```

  修改后完成后，已有的 HFile 的编码和压缩方式需要在下次做完 compaction 后才会生效。

8.13 HBase 容灾业务切换

操作场景

MRS 集群管理员可配置 HBase 集群容灾功能，以提高系统可用性。容灾环境中的主集群完全故障影响 HBase 上层应用连接时，需要为 HBase 上层应用配置备集群信息，才可以使得该应用在备集群上运行。

对系统的影响

切换业务后，写入备集群的数据默认不会同步到主集群。主集群故障修复后，备集群新增的数据需要通过备份恢复的方式同步到主集群。如果需要自动同步数据，需要切换 HBase 容灾主备集群。

操作步骤

登录备集群 FusionInsight Manager。

步骤 1 下载并安装 HBase 客户端。

步骤 2 在备集群 HBase 客户端，以 **hbase** 用户执行以下命令指定备集群写数据状态启用。

kinit hbase

hbase shell

set_clusterState_active

界面提示以下信息表示执行成功：

```
hbase(main):001:0> set_clusterState_active
=> true
```

步骤 3 确认 HBase 上层应用中原有的配置文件“hbase-site.xml”、“core-site.xml”和“hdfs-site.xml”是否为适配应用运行修改或新增过配置内容。

- 是，将相关内容同步更新到新的配置文件中，并替换旧的配置文件。
- 否，使用新的配置文件替换 HBase 上层应用中原有的配置文件。

步骤 4 配置 HBase 上层应用所在主机与备集群的网络连接。

说明

当客户端所在主机不是集群中的节点时，配置客户端网络连接，可避免执行客户端命令时出现错误。

1. 确保客户端所在主机能与客户端安装包文件解压目录下的“hosts”文件中所列出的集群各主机在网络上互通。
2. 当客户端所在主机不是集群中的节点时，需要在客户端所在节点的“/etc/hosts”文件中设置主机名和 IP 地址（业务平面）映射。主机名和 IP 地址请保持一一对应。

步骤 5 配置 HBase 上层应用所在主机的时间与备集群的时间保持一致，时间差要小于 5 分钟。

步骤 6 检查主集群的认证模式。

- 若为安全模式，执行步骤 8。
- 若为普通模式，任务结束。

步骤 7 获取 HBase 上层应用用户的 keytab 文件和 krb5.conf 配置文件。

1. 在备集群 FusionInsight Manager 界面，选择“系统 > 权限 > 用户”。
2. 在用户所在行的“操作”列单击“更多 > 下载认证凭据”，下载 keytab 文件到本地。
3. 解压得到“user.keytab”和“krb5.conf”。

步骤 8 使用“user.keytab”和“krb5.conf”两个文件替换 HBase 上层应用中原有的文件。

步骤 9 停止上层业务。

步骤 10 是否需要切换 HBase 主备集群，即主变成备，备变成主。如果不切换，数据将不再同步。

- 是，先执行 HBase 容灾主备集群倒换，具体请参考 8.14 HBase 容灾主备集群倒换，然后再执行步骤 12。
- 否，直接执行步骤 12。

步骤 11 启动上层业务。

----结束

8.14 HBase 容灾主备集群倒换

操作场景

当前环境 HBase 已经是容灾集群，因为某些原因，需要将主备集群互换，即备集群变成主集群，主集群变成备集群。

对系统的影响

主备集群互换后，原先主集群将不能再写入数据，原先备集群将变成主集群，接管上层业务。

操作步骤

确保上层业务已经停止

确保上层业务已经停止，如果没有停止，先执行 参考 8.13 HBase 容灾业务切换。

关闭主集群写功能

下载并安装 HBase 客户端。

步骤 1 在备集群 HBase 客户端，以 **hbase** 用户执行以下命令指定备集群写数据状态关闭。

kinit hbase

hbase shell

set_clusterState_standby

界面提示以下信息表示执行成功：

```
hbase(main):001:0> set_clusterState_standby
=> true
```

检查当前主备同步是否完成

执行以下命令，确保当前数据已经同步，要求 SizeOfLogQueue=0，SizeOfLogToReplicate=0，如果不为零，等待，重复执行以下命令，直到等于 0。

status 'replication'

关闭主备集群同步

查询所有的同步集群，获取 PEER_ID。

list_peers

步骤 2 删除所有同步集群。

remove_peer '备集群 ID'

示例：

remove_peer *'1'*

步骤 3 查询所有同步的 table。

list_replicated_tables

步骤 4 分别 disable 上面查询到的所有同步的 table。

disable_table_replication *'表名'*

示例：

disable_table_replication *'t1'*

切换主备

重新配置 HBase 容灾，参考 8.11 配置 HBase 容灾。

----结束

8.15 社区 BulkLoad Tool

Apache HBase 官方网站提供了批量导入数据的功能，详细操作请参见官网对“Import”和“ImportTsv”工具的描述：http://hbase.apache.org/2.2/book.html#tools。

8.16 配置 MOB

配置场景

在实际应用中，需要存储大大小小的数据，比如图像数据、文档。小于 10MB 的数据一般都可以存储在 HBase 上，对于小于 100KB 的数据，HBase 的读写性能是更优的。如果存放在 HBase 的数据大于 100KB 甚至到 10MB 大小时，插入同样个数的数据文件，但是总的数据量会很大，会导致频繁的 compaction 和 split，占用很多 CPU，磁盘 IO 频率很高，性能严重下降。

通过将 MOB（Medium-sized Objects）数据（即 100KB 到 10MB 大小的数据）直接以 HFile 的格式存储在文件系统上（例如 HDFS 文件系统），通过 expiredMobFileCleaner 和 Sweeper 工具集中管理这些文件，然后把这些文件的地址信息及大小信息作为 value 存储在普通 HBase 的 store 上。这样就可以大大降低 HBase 的 compaction 和 split 频率，提升性能。

HBase 当前默认开启 MOB 功能，相关配置项如表 8-8 所示。如果需要使用 MOB 功能，用户需要在创建表或者修改表属性时在指定的列族上指定使用 mob 方式存储数据。

说明

MRS 3.3.0 及之后版本不推荐使用 HBase MOB 功能。

配置描述

为了开启 HBase MOB 功能，用户需要在创建表或者修改表属性时在指定的列族上指定使用 mob 方式存储数据。

使用代码声明使用 mob 存储的方式：

```
HColumnDescriptor hcd = new HColumnDescriptor("f");
hcd.setMobEnabled(true);
```

使用 shell 声明使用 mob 的方式，MOB_THRESHOLD 单位是字节：

```
hbase(main):009:0> create 't3',{NAME => 'd', MOB_THRESHOLD => '102400', IS_MOB =>
'true'}

0 row(s) in 0.3450 seconds

=> Hbase::Table - t3
hbase(main):010:0> describe 't3'
Table t3 is ENABLED


t3


COLUMN FAMILIES DESCRIPTION


{NAME => 'd', MOB_THRESHOLD => '102400', VERSIONS => '1', KEEP_DELETED_CELLS =>
'FALSE', DATA_BLOCK_ENCODING => 'NONE',
```

```
TTL => 'FOREVER', MIN_VERSIONS => '0', REPLICATION_SCOPE => '0', BLOOMFILTER =>
'ROW',
IN_MEMORY => 'false', IS_MOB => 'true', COMPRESSION => 'NONE', BLOCKCACHE => 'true',
BLOCKSIZE => '65536'}

1 row(s) in 0.0170 seconds
```

参数入口：

在 FusionInsight Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > HBase > 配置”，单击“全部配置”。在搜索框中输入参数名称。

表8-8 参数描述

参数	描述	默认值
hbase.mob.file.cache.size	已经打开的文件句柄的缓存区大小。如果该值设置的比较大，cache 可以缓存更多的文件句柄，从而降低打开关闭文件的频率。但是如果该值设置过大会导致打开的文件句柄数过多。默认值是：“1000”。此参数在服务端 ResionServer 上配置。	1000
hbase.mob.cache.evict.period	缓存 mob 文件在 mob 缓存中的超期时间，单位为秒。	3600
hbase.mob.cache.evict.remain.ratio	mob cache 回收之后保留的文件个数占 cache 容量个数的比例。hbase.mob.cache.evict.remain.ratio 是一个算法因子，当缓存 mob 文件数达到 hbase.mob.file.cache.size*hbase.mob.cache.evict.remain.ratio 的大小后触发缓存回收。	0.5
hbase.master.mob.ttl.cleaner.period	过期文件清理任务的运行周期，以秒为单位。默认值是一天(86400 秒)。 **说明** 如果生存时间值过期了，即文件从创建起已经超过了 24 小时，则 MOB 文件将会被过期 mob 文件清理工具删除。	86400

8.17 配置安全的 HBase Replication

配置场景

安全模式下，在交叉域设置 Kerberos 时，配置安全的 HBase replication 的过程。

前提条件

- 在 Kerberos 配置文件中必须定义所有 FQDN 映射到它的域。
- ONE.COM 和 TWO.COM 的密码和 keytab 必须要一样。

操作步骤

为两个域创建 krbtgt 账户名。

比如，有 ONE.COM 和 TWO.COM 两个域，需要添加如下账户名：krbtgt/ONE.COM@TWO.COM 及 krbtgt/TWO.COM@ONE.COM。

在两个域中均添加这两个账户名。

```
kadmin: addprinc -e "<enc_type_list>" krbtgt/ONE.COM@TWO.COM
kadmin: addprinc -e "<enc_type_list>" krbtgt/TWO.COM@ONE.COM
```

说明

在这两个域之间必须至少有一个共同的 keytab 模式。

步骤 1 在 Zookeeper 中，为创建短名称添加规则。

Dzookeeper.security.auth_to_local 是 Zookeeper 服务器进程的参数。以下例子说明了如何支持 ONE.COM，在账户名中有两个成员（如 service/instance@ONE.COM）。

```
Dzookeeper.security.auth_to_local=RULE:[2:\$1@\$0](.*@\\QONE.COM\\E$)s/@\\QONE.COM\
\E$//DEFAULT
```

以上代码案例为在不同的域中支持 ONE.COM。因此在 replication 中，需要为在从属集群域的主集群域添加规则。DEFAULT 是已经添加了默认规则。

步骤 2 在 Hadoop 进程中，为创建短名称添加规则。

在从属集群的 HBase 进程中的“core-site.xml”配置文件的属性 hadoop.security.auth_to_local。比如：支持 ONE.COM：

```
<property>
<name>hadoop.security.auth_to_local</name>
<value>RULE:[2:$1@$0](.*@\QONE.COM\E$)s/@\QONE.COM\E$//DEFAULT</value>
</property>
```

说明

如果启用 bulkload replication 功能，那么在主集群 HBase 进程的配置文件“core-site.xml”中需要添加支持从属域的相同属性。

例如：

```
<property>
<name>hadoop.security.auth_to_local</name>
<value>RULE:[2:$1@$0](.*@\QTWO.COM\E$)s/@\QTWO.COM\E$//DEFAULT</value>
</property>
```

----结束

8.18 配置 Region Transition 恢复线程

配置场景

在故障环境中，由于诸如 region 服务器响应慢，网络不稳定，ZooKeeper 节点版本不匹配等各种原因，有可能导致 region 长时间处于 transition 下。在 region transition 下，由于一些 region 不能对外提供服务，客户端操作可能无法正常执行。

配置描述

在 HMaster 上设置 chore 服务，用于识别和恢复长期处于 transition 的 region。

下表是用于启用此功能的配置参数。

表8-9 参数描述

参数	描述	默认值
hbase.region.assignment.auto.recovery.enabled	配置该参数以启用或禁用 region 分配恢复线程功能。	true

8.19 开启 HBase 分时 Compaction 功能

操作场景

HBase 支持设置非业务高峰期和非高峰期的 Compaction 吞吐量，通过在非高峰期设置较大的吞吐量，加快 Compaction 的执行速度，减小高峰期 Compaction 对业务的影响。

该操作仅 MRS 3.3.0 及之后版本支持。

配置 HBase 分时 Compaction 吞吐量参数

登录 FusionInsight Manager，选择“集群 > 服务 > HBase > 配置”，在搜索框中搜索表 8-10 中的参数，并根据业务实际情况修改参数值以启用 HBase 分时 Compaction 吞吐量功能，且参数支持动态生效，修改配置保存后，登录 **hbase shell** 命令行执行 **update_all_config** 即可更新配置，无需重启实例。

说明

开启 HBase 分时 Compaction 吞吐量功能需“hbase.offpeak.start.hour”和“hbase.offpeak.end.hour”参数值都不为“-1”。

表8-10 配置 HBase 分时 Compaction 吞吐量参数

参数名称	参数描述	默认值

参数名称	参数描述	默认值
hbase.offpeak.start.hour	HBase 集群运行的非高峰开始时间，取值范围为：-1~23，且值只能为整数，当参数值为“-1”则不支持 HBase 分时 Compaction 吞吐量功能。	-1
hbase.offpeak.end.hour	HBase 集群运行的非高峰结束时间，取值范围为：-1~23，且值只能为整数，当参数值为“-1”则不支持 HBase 分时 Compaction 吞吐量功能。	-1
hbase.hstore.compaction.throughput.offpeak	非高峰期 Compaction 吞吐量，单位为：bytes/秒。	104857600

HBase 分时 Compaction 配置示例

登录 FusionInsight Manager，选择“集群 > 服务 > HBase > 配置”，根据业务实际情况设置非高峰期时段。例如：

- 设置“hbase.offpeak.start.hour”参数值为“18”，设置“hbase.offpeak.end.hour”参数值为“23”时，表示每天 18:00 到 23:00 之间为非高峰期。
- 设置“hbase.offpeak.start.hour”参数值为“23”，设置“hbase.offpeak.end.hour”参数值为“8”时，表示每天 23:00 到第二天 8:00 之间为非高峰期。

步骤 1 非高峰期时，在 Manger 界面选择“集群 > 服务 > HBase > 图表”，观察图表“Compaction 操作队列大小-所有实例”的值是否一直在增大，且图表“RegionServer Compaction 流量-所有实例”有部分 RegionServer 的值已达到或超过“hbase.hstore.compaction.throughput.offpeak”配置项的值。

- 是，根据集群磁盘使用情况调大“hbase.hstore.compaction.throughput.offpeak”配置项的值，执行步骤 3。
- 否，结束。

步骤 2 观察 HBase 图表“P99 RegionServer 的 RPC 请求响应时间-所有实例”的值是否持续上升：

- 是，执行步骤 4。
- 否，结束。

步骤 3 观察 RegionServer 所在主机的图表“磁盘 IO 利用率”的值是否超过 90%：

- 是，磁盘 IO 已达到瓶颈，考虑减小写入速度或者扩容磁盘。
- 否，结束。

----结束

8.20 使用二级索引

操作场景

HIndex 为 HBase 提供了按照某些列的值进行索引的能力，缩小搜索范围并缩短时延。

使用约束

- 列族应以“;”分隔。
- 列和数据类型应包含在“[]”中。
- 列数据类型在列名称后使用“->”指定。
- 如果未指定列数据类型，则使用默认数据类型（字符串）。
- “＃”用于在两个索引详细信息之间进行分隔。
- 以下是一个可选参数：
  -Dscan.caching：在扫描数据表时的缓存行数。
  如果不设置该参数，则默认值为 1000。
- 为单个 Region 构建索引是为了修复损坏的索引。
  此功能不应用于生成新索引。

操作步骤

安装 HBase 客户端，详情参见 8.2 使用 HBase 客户端。

步骤 1 进入客户端安装路径，例如“/opt/client”

cd /opt/client

步骤 2 配置环境变量。

source bigdata_env

步骤 3 如果集群为安全模式，执行以下命令进行用户认证。普通模式集群无需执行用户认证。

kinit *组件业务用户*

步骤 4 执行以下命令访问 Hindex。

hbase org.apache.hadoop.hbase.hindex.mapreduce.TableIndexer

表8-11 HIndex 常用命令

说明	命令
增加索引	TableIndexer-Dtablename.to.index=table1-Dindexspecs.to.add='IDX1=>cf1:[q1->datatype],[q2],[q3];cf2:[q1->datatype],[q2->datatype]#IDX2=>cf1:[q5]'
构建索引	TableIndexer -Dtablename.to.index=table1 -Dindexnames.to.build='IDX1#IDX2'

说明	命令
删除索引	TableIndexer -Dtablename.to.index=table1 -Dindexnames.to.drop='IDX1#IDX2'
禁用索引	TableIndexer -Dtablename.to.index=table1 -Dindexnames.to.disable='IDX1#IDX2'
同时添加和构建索引	TableIndexer -Dtablename.to.index=table1 -Dindexspecs.to.add='IDX1=>cf1:[q1->datatype],[q2],[q3];cf2:[q1->datatype],[q2->datatype]#IDX2=>cf1:[q5]' -Dindexnames.to.build='IDX1'
为单个 Region 构建索引	TableIndexer -Dtablename.to.index=table1 -Dregion.to.index=regionEncodedName -Dindexnames.to.build='IDX1#IDX2'

说明

- **IDX1**：索引名称。
- **cf1**：列族名称。
- **q1**：列名称。
- **datatype**：数据类型，包括 String，Integer，Double，Float，Long，Short，Byte，Char。

----结束

8.21 查看 HBase 慢请求和超大请求

操作场景

该章节主要介绍如何在 HBase Shell 命令行查询慢请求或超大请求信息。慢请求是指通过 **hbase shell** 命令查询服务端时，RPC 请求响应时长超过阈值（即 HBase 服务端配置参数“hbase.ipc.warn.response.time”，默认值为“3000”ms）的请求；超大请求是指通过 **hbase shell** 命令查询服务端时，RPC 请求一次返回数据量大小超过阈值（即 HBase 服务端配置参数“hbase.ipc.warn.response.size”，默认值为“5MB”）的请求。

每个 RegionServer 节点默认会缓存最近的 256 条慢请求和超大请求，可以通过 FusionInsight Manager 中 HBase 服务端配置参数“hbase.regionserver.slowlog.ringbuffer.size”调整缓存的大小。

说明

该章节内容适用于 MRS 3.3.0 及之后版本。

命令说明

该操作主要涉及新增的 **hbase shell** 命令如下：

- **get_slowlog_responses**：查询慢请求信息。
- **get_largelog_responses**：查询超大请求信息。

- **clear_slowlog_responses**：清理 RegionServer 缓存中的数据。

可以在 **hbase shell** 中执行如下命令查看相关命令如何使用：

help '*cmdName*'

例如，执行 **help 'clear_slowlog_responses'**查看 **clear_slowlog_responses** 命令的使用方法：

```
hbase:010:0> help 'clear_slowlog_responses'
Clears SlowLog Responses maintained by each or specific RegionServers.
Specify array of server names for specific RS. A server name is
the host, port plus startcode of a RegionServer.
e.g.: host187.example.com,60020,1289493121758 (find servername in
master ui or when you do detailed status in shell)

Examples:

  hbase> clear_slowlog_responses                                  => clears slowlog responses from all RS
  hbase> clear_slowlog_responses ['SERVER_NAME1', 'SERVER_NAME2']    => clears slowlog responses from SERVER_NAME1,
                                                                     SERVER_NAME2
```

查看请求信息

由于 **get_slowlog_responses** 和 **get_largelog_responses** 使用方法和支持的参数一致，这里主要介绍 **get_slowlog_responses** 的使用方法。

已登录 HBase Shell 命令行，详细操作请参见 8.2 使用 HBase 客户端。

- 查看所有 RegionServer 的慢请求：

  get_slowlog_responses '*', {'LIMIT' => *50***}**

  “LIMIT”参数控制每个 RegionServer 返回的记录条数，如果不指定则默认返回 10 条。

- 查看指定 RegionServer 的慢请求：

  get_slowlog_responses ['*SERVER_NAME1***', '***SERVER_NAME2***']**

  参数 SERVER_NAME1、SERVER_NAME2 为要查看的 RegionServer 的 ServerName（可以登录 FusionInsight Manager，选择“集群 > 服务 > HBase”，单击“HMaster WebUI”后的超链接进入 HBase WebUI 界面，在“Region Servers”区域的“Base Stats”页签的“ServerName”获取所有的 RegionServer 的 ServerName。），支持一到多个参数。

- 查看指定表、指定 Region 的慢请求：

  get_slowlog_responses '*', {'TABLE_NAME' => '*t1*'**}**

  get_slowlog_responses '*', {'REGION_NAME' => '*hbase:meta,,1*'**}**

  get_slowlog_responses '*', {'REGION_NAME' => '*hbase:meta,,1*'**, 'TABLE_NAME' =>** '*t1*'**, 'FILTER_BY_OP' => 'AND'}**

  参数 TABLE_NAME 和 REGION_NAME 分别为指定的表名和 Region 名，如果指定参数**'FILTER_BY_OP' => 'AND'**，则返回的每条结果必须匹配所有的指定条件，否则只需匹配任一条件即可。

- 查看指定用户、指定客户端的慢请求，以下命令表示返回满足 USER 或 CLIENT_IP 的结果：

  get_slowlog_responses '*', {'USER' => '*user_name*'**, 'CLIENT_IP' =>** '*192.162.1.40:60225*'**}**

参数 USER 和 CLIENT_IP 为要匹配的用户名和客户端 IP 及端口号，如果指定参数**'FILTER_BY_OP' => 'AND'**，则返回同时匹配 USER 和 CLIENT_IP 的结果，否则只需匹配 USER 和 CLIENT_IP 任一条件即可。

清理请求信息

已登录 HBase Shell 命令行，详细操作请参见 8.2 使用 HBase 客户端。

清理所有 RegionServer 或者指定 RegionServer 的慢请求和超大请求数据的缓存，命令为：

clear_slowlog_responses

clear_slowlog_responses ['*SERVER_NAME1***', '***SERVER_NAME2***']**

8.22 HBase 日志介绍

日志描述

日志存储路径：HBase 相关日志的默认存储路径为“/var/log/Bigdata/hbase/*角色名*”。

- HMaster：“/var/log/Bigdata/hbase/hm”（运行日志），“/var/log/Bigdata/audit/hbase/hm”（审计日志）。
- RegionServer：“/var/log/Bigdata/hbase/rs”（运行日志），“/var/log/Bigdata/audit/hbase/rs”（审计日志）。
- ThriftServer：“/var/log/Bigdata/hbase/ts2”（运行日志，ts2 为具体实例名称），“/var/log/Bigdata/audit/hbase/ts2”（审计日志，ts2 为具体实例名称）。

日志归档规则：HBase 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 30MB 的时候，会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”。最多保留最近的 20 个压缩文件，压缩文件保留个数可以在 Manager 界面中配置。

表8-12 HBase **日志列表**

日志类型	日志文件名	描述
运行日志	hbase-<SSH_USER>-<process_name>-<hostname>.log	HBase 系统日志，主要包括启动时间，启动参数信息以及 HBase 系统运行时候所产生的大部分日志。
	hbase-<SSH_USER>-<process_name>-<hostname>.out	HBase 运行环境信息日志。
	<process_name>-<SSH_USER>-<DATE>-<PID>-gc.log	HBase 服务垃圾回收日志。
	checkServiceDetail.log	HBase 服务启动是否成功的检查

日志类型	日志文件名	描述
		日志。
	hbase.log	HBase 服务健康检查脚本以及部分告警检查脚本执行所产生的日志。
	sendAlarm.log	HBase 告警检查脚本上报告警信息日志。
	hbase-haCheck.log	HMaster 主备状态检测日志。
	stop.log	HBase 服务进程启停操作日志。
审计日志	hbase-audit-<process_name>.log	HBase 安全审计日志。

日志级别

HBase 中提供了如表 8-13 所示的日志级别。日志级别优先级从高到低分别是 FATAL、ERROR、WARN、INFO、DEBUG。程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表8-13 日志级别

级别	描述
FATAL	FATAL 表示当前事件处理出现严重错误信息，可能导致系统崩溃。
ERROR	ERROR 表示当前事件处理出现错误信息，系统运行出错。
WARN	WARN 表示当前事件处理存在异常信息，但认为是正常范围，不会导致系统出错。
INFO	INFO 表示记录系统及各事件正常运行状态信息
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

进入 HBase 服务参数“全部配置”界面，具体操作请参考 25.1 修改集群服务配置参数。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别。

步骤 4 保存配置，在弹出窗口中单击“确定”使配置生效。

说明

配置完成后立即生效，不需要重启服务。

----结束

日志格式

HBase 的日志格式如下所示：

表8-14 日志格式

日志类型	组件	格式	示例
运行日志	HMaster	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的message>|<日志事件的发生位置>	2020-01-19 16:04:53,558 | INFO | main | env:HBASE_THRIFT_OPTS = | org.apache.hadoop.hbase.util.ServerCommandLine.logProcessInfo(ServerCommandLine.java:113)
	RegionServer	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的message>|<日志事件的发生位置>	2020-01-19 16:05:18,589 | INFO | regionserver16020-SendThread(linux-k6da:2181) | Client will use GSSAPI as SASL mechanism. | org.apache.zookeeper.client.ZooKeeperSaslClient$1.run(ZooKeeperSaslClient.java:285)
	ThriftServer	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的message>|<日志事件的发生位置>	2020-02-16 09:42:55,371 | INFO | main | loaded properties from hadoop-metrics2.properties | org.apache.hadoop.metrics2.impl.MetricsConfig.loadFirst(MetricsConfig.java:111)
审计日志	HMaster	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的message>|<日志事件的发生位置>	2020-02-16 09:42:40,934 | INFO | master:linux-k6da:16000 | Master: [master:linux-k6da:16000] start operation called. | org.apache.hadoop.hbase.master.HMaster.run(HMaster.java:581)
	RegionServer	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的message>|<日志事件的发生位置>	2020-02-16 09:42:51,063 | INFO | main | RegionServer: [regionserver16020] start operation called. | org.apache.hadoop.hbase.regionserver.HRegionServer.startRegionServer(HRegionServer.java:2396)
	ThriftServer	<yyyy-MM-dd	2020-02-16 09:42:55,512 |

日志类型	组件	格式	示例
		HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的message>|<日志事件的发生位置>	INFO | main | thrift2 server start operation called. | org.apache.hadoop.hbase.thrift2.ThriftServer.main(ThriftServer.java:421)

8.23 HBase 性能调优

8.23.1 提升 BulkLoad 效率

操作场景

批量加载功能采用了 MapReduce jobs 直接生成符合 HBase 内部数据格式的文件，然后把生成的 StoreFiles 文件加载到正在运行的集群。使用批量加载相比直接使用 HBase 的 API 会节约更多的 CPU 和网络资源。

ImportTSV 是一个 HBase 的表数据加载工具。

前提条件

在执行批量加载时需要通过“Dimporttsv.bulk.output”参数指定文件的输出路径。

操作步骤

参数入口：执行批量加载任务时，在 BulkLoad 命令行中加入如下参数。

表8-15 增强 BulkLoad 效率的配置项

参数	描述	配置的值
-Dimporttsv.mapper.class	用户自定义 mapper 通过把键值对的构造从 mapper 移动到 reducer 以帮助提高性能。mapper 只需要把每一行的原始文本发送给 reducer，reducer 解析每一行的每一条记录并创建键值对。 说明 当该值配置为“org.apache.hadoop.hbase.mapreduce.TsvImporterByteMapper”时，只在执行没有 *HBASE_CELL_VISIBILITY OR HBASE_CELL_TTL* 选项的批量加载命令时使用。使用“org.apache.hadoop.hbase.mapreduce.TsvImporterByteMapper”时可以得到更好的性能。	org.apache.hadoop.hbase.mapreduce.TsvImporterByteMapper 和 org.apache.hadoop.hbase.mapreduce.TsvImporterTextMapper

8.23.2 提升连续 put 场景性能

操作场景

对大批量、连续 put 的场景，配置下面的两个参数为“false”时能大量提升性能。

- “hbase.regionserver.wal.durable.sync”
- “hbase.regionserver.hfile.durable.sync”

当提升性能时，缺点是对于 DataNode（默认是 3 个）同时故障时，存在小概率数据丢失的现象。对数据可靠性要求高的场景请慎重配置。

操作步骤

参数入口：

在 FusionInsight Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > HBase > 配置”，单击“全部配置”。在搜索框中输入参数名称，并进行修改。

表8-16 提升连续 put 场景性能的参数

参数	描述	配置值
hbase.wal.hsync	设置是否启用 WAL 文件耐久性以将 WAL 数据持久化到磁盘。若将该参数设置为 true，则性能将受到影响，原因是每个 WAL 的编辑都会被 hadoop fsync 同步到磁盘上。	false
hbase.hfile.hsync	设置是否启用 Hfile 耐久性以将数据持久化到磁盘。若将该参数设置为 true，则性能将受到影响，原因是每个 Hfile 写入时都会被 hadoop fsync 同步到磁盘上。	false

8.23.3 Put 和 Scan 性能综合调优

操作场景

HBase 有很多与读写性能相关的配置参数。读写请求负载不同的情况下，配置参数需要进行相应的调整，本章节旨在指导用户通过修改 RegionServer 配置参数进行读写性能调优。

操作步骤

- JVM GC 参数

RegionServer GC_OPTS 参数设置建议：

- -Xms 与-Xmx 设置相同的值，需要根据实际情况设置，增大内存可以提高读写性能，可以参考参数“hfile.block.cache.size”（见表 8-18）和参数“hbase.regionserver.global.memstore.size”（见表 8-17）的介绍进行设置。
- -XX:NewSize 与-XX:MaxNewSize 设置相同值，建议低负载场景下设置为“512M”，高负载场景下设置为“2048M”。
- -XX:CMSInitiatingOccupancyFraction 建议设置为“100 * (hfile.block.cache.size + hbase.regionserver.global.memstore.size + 0.05)”，最大值不超过 90。
- -XX:MaxDirectMemorySize 表示 JVM 使用的堆外内存，建议低负载情况下设置为“512M”，高负载情况下设置为“2048M”。

说明

GC_OPTS 参数中-XX:MaxDirectMemorySize 默认没有配置，如需配置，用户可在 GC_OPTS 参数中自定义添加。

- Put 相关参数

  RegionServer 处理 put 请求的数据，会将数据写入 memstore 和 hlog，

  - 当 memstore 大小达到设置的“hbase.hregion.memstore.flush.size”参数值大小时，memstore 就会刷新到 HDFS 生成 HFile。
  - 当当前 region 的列簇的 HFile 数量达到“hbase.hstore.compaction.min”参数值时会触发 compaction。
  - 当当前 region 的列簇 HFile 数达到“hbase.hstore.blockingStoreFiles”参数值时会阻塞 memstore 刷新生成 HFile 的操作，导致 put 请求阻塞。

表8-17 Put 相关参数

参数	描述	默认值
hbase.wal.hsync	每一条 wal 是否持久化到硬盘。 参考 8.23.2 提升连续 put 场景性能。	true
hbase.hfile.hsync	hfile 写是否立即持久化到硬盘。 参考 8.23.2 提升连续 put 场景性能。	true
hbase.hregion.memstore.flush.size	若 MemStore 的大小（单位：Byte）超过指定值，MemStore 将被冲洗至磁盘。该参数值将被运行每个 hbase.server.thread.wakefrequency 的线程所检验。建议设置为 HDFS 块大小的整数倍，在内存足够 put 负载大情况下可以调整增大。	134217728
hbase.regionserver.global.memstore.size	更新被锁定以及强制冲洗发生之前一个 RegionServer 上支持的所有 MemStore 的大小。建议设置	0.4

参数	描述	默认值
	为“hbase.hregion.memstore.flush.size * 写活跃 region 数 / RegionServer GC -Xmx”。默认值为“0.4”，表示使用 RegionServer GC -Xmx 的 40%。	
hbase.hstore.flusher.count	memstore 的 flush 线程数，在 put 高负载场景下可以适当调大。	2
hbase.regionserver.thread.compaction.small	小压缩线程数，在 put 高负载情况下可以适当调大。	10
hbase.hstore.blockingStoreFiles	若一个 Store 内的 HStoreFile 文件数量超过指定值，则针对此 HRegion 的更新将被锁定直到一个压缩完成或者 base.hstore.blockingWaitTime 被超过。每冲洗一次 MemStore 一个 StoreFile 文件被写入。在 put 高负载场景下可以适当调大。	15

- Scan 相关参数

表8-18 Scan 相关参数

参数	描述	默认值
hbase.client.scanner.timeout.period	客户端和 RegionServer 端参数，表示客户端执行 scan 的租约超时时间。建议设置为 60000ms 的整数倍，在读高负载情况下可以适当调大。单位：毫秒。	60000
hfile.block.cache.size	数据缓存所占的 RegionServer GC -Xmx 百分比，在读高负载情况下可以适当调大以增大缓存命中率以提高性能。表示分配给 HFile/StoreFile 所使用的块缓存的最大 heap（-Xmx setting）的百分比。	当 offheap 关闭时，默认值为 0.25，当 offheap 开启时，默认值是 0.1。

- Handler 相关参数

表8-19 Handler 相关参数

参数	描述	默认值
hbase.regionserver.handler.count	RegionServer 上的 RPC 侦听器实例数，建议设置为 200～400 之间。	200
hbase.regionserver.metahandler.count	RegionServer 中处理优先请求的程序实例的数量，建议设置为 200～400 之间。	200

8.23.4 提升实时写数据效率

操作场景

需要把数据实时写入到 HBase 中或者对于大批量、连续 put 的场景。

前提条件

调用 HBase 的 put 或 delete 接口，把数据保存到 HBase 中。

操作步骤

- **写数据服务端调优**

  参数入口：

  进入 HBase 服务参数“全部配置”界面，具体操作请参考 25.1 修改集群服务配置参数章节。

表8-20 影响实时写数据配置项

配置参数	描述	默认值
hbase.wal.hsync	控制 HLog 文件在写入到 HDFS 时的同步程度。如果为 true，HDFS 在把数据写入到硬盘后才返回；如果为 false，HDFS 在把数据写入 OS 的缓存后就返回。 把该值设置为 false 比 true 在写入性能上会更优。	true
hbase.hfile.hsync	控制 HFile 文件在写入到 HDFS 时的同步程度。如果为 true，HDFS 在把数据写入到硬盘后才返回；如果为 false，HDFS 在把数据写入 OS 的缓存后就返回。 把该值设置为 false 比 true 在写入性能上会更优。	true

配置参数	描述	默认值
GC_OPTS	HBase 利用内存完成读写操作。提高 HBase 内存可以有效提高 HBase 性能。GC_OPTS 主要需要调整 HeapSize 的大小和 NewSize 的大小。调整 HeapSize 大小的时候，建议将 Xms 和 Xmx 设置成相同的值，这样可以避免 JVM 动态调整 HeapSize 大小的时候影响性能。调整 NewSize 大小的时候，建议把其设置为 HeapSize 大小的 1/8。 • HMaster：当 HBase 集群规模越大、Region 数量越多时，可以适当调大 HMaster 的 GC_OPTS 参数。 • RegionServer：RegionServer 需要的内存一般比 HMaster 要大。在内存充足的情况下，HeapSize 可以相对设置大一些。 说明 主 HMaster 的 HeapSize 为 4G 的时候，HBase 集群可以支持 100000 region 数的规模。根据经验值，集群每增加 35000 个 region，HeapSize 增加 2G，主 HMaster 的 HeapSize 不建议超过 32GB。	• HMaster -server -Xms4G -Xmx4G -XX:NewSize=512M -XX:MaxNewSize=512M -XX:MetaspaceSize=128M -XX:MaxMetaspaceSize=512M -XX:+UseConcMarkSweepGC -XX:+CMSParallelRemarkEnabled -XX:CMSInitiatingOccupancyFraction=65 -XX:+PrintGCDetails -Dsun.rmi.dgc.client.gcInterval=0x7FFFFFFFFFFFFFE -Dsun.rmi.dgc.server.gcInterval=0x7FFFFFFFFFFFFFE -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=10 -XX:GCLogFileSize=1M • Region Server -server -Xms6G -Xmx6G -XX:NewSize=1024M -XX:MaxNewSize=1024M -XX:MetaspaceSize=128M -

配置参数	描述	默认值
		XX:MaxMetaspaceSize=512M -XX:+UseConcMarkSweepGC -XX:+CMSParallelRemarkEnabled -XX:CMSInitiatingOccupancyFraction=65 -XX:+PrintGCDetails -Dsun.rmi.dgc.client.gcInterval=0x7FFFFFFFFFFFFE -Dsun.rmi.dgc.server.gcInterval=0x7FFFFFFFFFFFFE -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=10 -XX:GCLogFileSize=1M
hbase.regionserver.handler.count	表示在 RegionServer 上启动的 RPC 侦听器实例数。如果设置过高会导致激烈线程竞争，如果设置过小，请求将会在 RegionServer 长时间等待，降低处理能力。根据资源情况，适当增加处理线程数。 建议根据 CPU 的使用情况，可以选择设置为 100 至 300 之间的值。	200
hbase.hregion.max.filesize	HStoreFile 的最大大小（单位：Byte）。若任何一个列族 HStoreFile 超过此参数值，则托管 Hregion 将会一分为二。	10737418240
hbase.hregion.memstore.flush.size	在 RegionServer 中，当写操作内存中存在超过 memstore.flush.size 大小的 memstore，则 MemStoreFlusher 就启动	134217728

配置参数	描述	默认值
	flush 操作将该 memstore 以 hfile 的形式写入对应的 store 中。 如果 RegionServer 的内存充足，而且活跃 Region 数量也不是很多的时候，可以适当增大该值，可以减少 compaction 的次数，有助于提升系统性能。 同时，这种 flush 产生的时候，并不是紧急的 flush，flush 操作可能会有一定延迟，在延迟期间，写操作还可以进行，Memstore 还会继续增大，最大值为“memstore.flush.size” * “hbase.hregion.memstore.block.multiplier”。当超过最大值时，将会阻塞操作。适当增大“hbase.hregion.memstore.block.multiplier”可以减少阻塞，减少性能波动。单位：字节。	
hbase.regionserver.global.memstore.size	更新被锁定以及强制冲洗发生之前一个 RegionServer 上支持的所有 MemStore 的大小。RegionServer 中，负责 flush 操作的是 MemStoreFlusher 线程。该线程定期检查写操作内存，当写操作占用内存总量达到阈值，MemStoreFlusher 将启动 flush 操作，按照从大到小的顺序，flush 若干相对较大的 memstore，直到所占用内存小于阈值。 阈值 = “hbase.regionserver.global.memstore.size” * “hbase.regionserver.global.memstore.size.lower.limit” * “HBase_HEAPSIZE” **说明** 该配置与“hfile.block.cache.size”的和不能超过 0.8，也就是写和读操作的内存不能超过 HeapSize 的 80%，这样可以保证除读和写外其它操作的正常运行。	0.4
hbase.hstore.blockingStoreFiles	在 region flush 前首先判断 file 文件个数，是否大于 hbase.hstore.blockingStoreFiles。 如果大于需要先 compaction 并且让 flush 延时 90s（这个值可以通过 hbase.hstore.blockingWaitTime 进行配置），在延时过程中，将会继续写从而使得 Memstore 还会继续增大超过最大值 “memstore.flush.size” *	15

配置参数	描述	默认值
	“hbase.hregion.memstore.block.multiplier”，导致写操作阻塞。当完成 compaction 后，可能就会产生大量写入。这样就导致性能激烈震荡。 增加 hbase.hstore.blockingStoreFiles，可以减低 BLOCK 几率。	
hbase.regionserver.thread.compaction.throttle	大于此参数值的压缩将被大线程池执行，单位：Byte。控制一次 Minor Compaction 时，进行 compaction 的文件总大小的阈值。Compaction 时的文件总大小会影响这一次 compaction 的执行时间，如果太大，可能会阻塞其它的 compaction 或 flush 操作。	1610612736
hbase.hstore.compaction.min	每次执行 minor compaction 的 HStoreFile 的最小数量。当一个 Store 文件超过该值时，会进行 compact，适当增大该值，可以减少文件被重复执行 compaction。但是如果过大，会导致 Store 文件数过多而影响读取的性能。	6
hbase.hstore.compaction.max	每次执行 minor compaction 的 HStoreFile 的最大数量。与“hbase.hstore.compaction.max.size”的作用基本相同，主要是控制一次 compaction 操作的时间不要太长。	10
hbase.hstore.compaction.max.size	如果一个 HFile 文件的大小大于该值，那么在 Minor Compaction 操作中不会选择这个文件进行 compaction 操作，除非进行 Major Compaction 操作。 这个值可以防止较大的 HFile 参与 compaction 操作。在禁止 Major Compaction 后，一个 Store 中可能存在几个 HFile，而不会合并成为一个 HFile，这样不会对数据读取造成太大的性能影响。单位：字节。	9223372036854775807
hbase.hregion.majorcompaction	单个区域内所有 HStoreFile 文件主压缩的时间间隔，单位：毫秒。由于执行 Major Compaction 会占用较多的系统资源，如果正在处于系统繁忙时期，会影响系统的性能。 如果业务没有较多的更新、删除、回收过期数据空间时，可以把该值设置为 0，以禁止 Major Compaction。 如果必须要执行 Major Compaction，以	604800000

配置参数	描述	默认值
	回收更多的空间，可以适当增加该值，同时配置参数“hbase.offpeak.end.hour”和“hbase.offpeak.start.hour”以控制 Major Compaction 发生在业务空闲的时期。单位：毫秒。	
• hbase.regionserver.maxlogs • hbase.regionserver.hlog.blocksize	• 表示一个 RegionServer 上未进行 Flush 的 Hlog 的文件数量的阈值，如果大于该值，RegionServer 会强制进行 flush 操作。 • 表示每个 HLog 文件的最大大小。如果 HLog 文件大小大于该值，就会滚动出一个新的 HLog 文件，旧的将被禁用并归档。 这两个参数共同决定了 RegionServer 中可以存在的未进行 Flush 的 hlog 数量。当这个数据量小于 MemStore 的总大小的时候，会出现由于 HLog 文件过多而触发的强制 flush 操作。这个时候可以适当调整这两个参数的大小，以避免出现这种强制 flush 的情况。单位：字节。	• 32 • 134217728

- **写数据客户端调优**

  写数据时，在场景允许的情况下，更适合使用 Put List 的方式，可以极大的提升写性能。每一次 Put 的 List 的长度，需要结合单条 Put 的大小，以及实际环境的一些参数进行设定。建议在选定之前先做一些基础的测试。

- **写数据表设计调优**

表8-21 影响实时写数据相关参数

配置参数	描述	默认值
COMPRESSION	配置数据的压缩算法，这里的压缩是 HFile 中 block 级别的压缩。对于可以压缩的数据，配置压缩算法可以有效减少磁盘的 IO，从而达到提高性能的目的。 说明 并非所有数据都可以进行有效压缩。例如一张图片的数据，因为图片一般已经是压缩后的数据，所以压缩效果有限。常用的压缩算法是 SNAPPY，因为它有较好的 Encoding/Decoding 速度和可以接受的压缩率。	NONE
BLOCKSIZE	配置 HFile 中 block 块的大小，不同的 block	65536

配置参数	描述	默认值
	块大小，可以影响 HBase 读写数据的效率。越大的 block 块，配合压缩算法，压缩的效率就越好；但是由于 HBase 的读取数据是以 block 块为单位的，所以越大的 block 块，对于随机读的情况，性能可能会比较差。 如果要提升写入的性能，一般扩大到 128KB 或者 256KB，可以提升写数据的效率，也不会影响太大的随机读性能。单位：字节	
IN_MEMORY	配置这个表的数据优先缓存在内存中，这样可以有效提升读取的性能。对于一些小表，而且需要频繁进行读取操作的，可以设置此配置项。	false

8.23.5 提升实时读数据效率

操作场景

需要读取 HBase 数据场景。

前提条件

调用 HBase 的 get 或 scan 接口，从 HBase 中实时读取数据。

操作步骤

- **读数据服务端调优**

  参数入口：

  进入 HBase 服务参数“全部配置”界面，具体操作请参考 25.1 修改集群服务配置参数章节。

表8-22 影响实时读数据配置项

配置参数	描述	默认值
GC_OPTS	HBase 利用内存完成读写操作。提高 HBase 内存可以有效提高 HBase 性能。 GC_OPTS 主要需要调整 HeapSize 的大小和 NewSize 的大小。调整 HeapSize 大小的时候，建议将 Xms 和 Xmx 设置成相同的值，这样可以避免 JVM 动态调整 HeapSize 大小的时候影响性能。调整 NewSize 大小的时候，建议把其设置为 HeapSize 大	• HMaster -server -Xms4G -Xmx4G -XX:NewSize=512M -XX:MaxNewSize=512M -XX:MetaspaceSize=128M -XX:MaxMetaspaceSize=512

配置参数	描述	默认值
	小的 1/8。 • HMaster：当 HBase 集群规模越大、Region 数量越多时，可以适当调大 HMaster 的 GC_OPTS 参数。 • RegionServer：RegionServer 需要的内存一般比 HMaster 要大。在内存充足的情况下，HeapSize 可以相对设置大一些。 说明 主 HMaster 的 HeapSize 为 4G 的时候，HBase 集群可以支持 100000 region 数的规模。根据经验值，集群每增加 35000 个 region，HeapSize 增加 2G，主 HMaster 的 HeapSize 不建议超过 32GB。	M -XX:+UseConcMarkSweepGC -XX:+CMSParallelRemarkEnabled -XX:CMSInitiatingOccupancyFraction=65 -XX:+PrintGCDetails -Dsun.rmi.dgc.client.gcInterval=0x7FFFFFFFFFFFFFE -Dsun.rmi.dgc.server.gcInterval=0x7FFFFFFFFFFFFFE -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=10 -XX:GCLogFileSize=1M • Region Server -server -Xms6G -Xmx6G -XX:NewSize=1024M -XX:MaxNewSize=1024M -XX:MetaspaceSize=128M -XX:MaxMetaspaceSize=512M -XX:+UseConcMarkSweepGC -XX:+CMSPar

配置参数	描述	默认值
		allelRemarkEnabled -XX:CMSInitiatingOccupancyFraction=65 -XX:+PrintGCDetails -Dsun.rmi.dgc.client.gcInterval=0x7FFFFFFFFFFFFFE -Dsun.rmi.dgc.server.gcInterval=0x7FFFFFFFFFFFFFE -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=10 -XX:GCLogFileSize=1M
hbase.regionserver.handler.count	表示 RegionServer 在同一时刻能够并发处理多少请求。如果设置过高会导致激烈线程竞争，如果设置过小，请求将会在 RegionServer 长时间等待，降低处理能力。根据资源情况，适当增加处理线程数。 建议根据 CPU 的使用情况，可以选择设置为 100 至 300 之间的值。	200
hfile.block.cache.size	HBase 缓存区大小，主要影响查询性能。根据查询模式以及查询记录分布情况来决定缓存区的大小。如果采用随机查询使得缓存区的命中率较低，可以适当降低缓存区大小。	当 offheap 关闭时，默认值为 0.25。当 offheap 开启时，默认值是 0.1。

说明

如果同时存在读和写的操作，这两种操作的性能会互相影响。如果写入导致的 flush 和 Compaction 操作频繁发生，会占用大量的磁盘 IO 操作，从而影响读取的性能。如果写入导致阻塞较多的 Compaction 操作，就会出现 Region 中存在多个 HFile 的情况，从而影响读取的性能。所以如果读取的性能不理想的时候，也要考虑写入的配置是否合理。

- **读数据客户端调优**

  Scan 数据时需要设置 caching（一次从服务端读取的记录条数，默认是 1），若使用默认值读性能会降到极低。

  当不需要读一条数据所有的列时，需要指定读取的列，以减少网络 IO。

  只读取 RowKey 时，可以为 Scan 添加一个只读取 RowKey 的 filter（FirstKeyOnlyFilter 或 KeyOnlyFilter）。

- **读数据表设计调优**

表8-23 影响实时读数据相关参数

配置参数	描述	默认值
COMPRESSION	配置数据的压缩算法，这里的压缩是 HFile 中 block 级别的压缩。对于可以压缩的数据，配置压缩算法可以有效减少磁盘的 IO，从而达到提高性能的目的。 说明 并非所有数据都可以进行有效压缩。例如一张图片的数据，因为图片一般已经是压缩后的数据，所以压缩效果有限。常用的压缩算法是 SNAPPY，因为它有较好的 Encoding/Decoding 速度和可以接受的压缩率。	NONE
BLOCKSIZE	配置 HFile 中 block 块的大小，不同的 block 块大小，可以影响 HBase 读写数据的效率。越大的 block 块，配合压缩算法，压缩的效率就越好；但是由于 HBase 的读取数据是以 block 块为单位的，所以越大的 block 块，对于随机读的情况，性能可能会比较差。 如果要提升写入的性能，一般扩大到 128KB 或者 256KB，可以提升写数据的效率，也不会影响太大的随机读性能。单位：字节。	65536
DATA_BLOCK_ENCODING	配置 HFile 中 block 块的编码方法。当一行数据中存在多列时，一般可以配置为“FAST_DIFF”，可以有效的节省数据存储的空间，从而提供性能。	NONE

8.23.6 JVM 参数优化

操作场景

当集群数据量达到一定规模后，JVM 的默认配置将无法满足集群的业务需求，轻则集群变慢，重则集群服务不可用。所以需要根据实际的业务情况进行合理的 JVM 参数配置，提高集群性能。

操作步骤

参数入口：

HBase 角色相关的 JVM 参数需要配置在安装有 HBase 服务的节点的“${BIGDATA_HOME}/FusionInsight_HD_*/install/FusionInsight-HBase-2.2.3/hbase/conf/”目录下的“hbase-env.sh”文件中。

每个角色都有各自的 JVM 参数配置变量，如表 8-24。

表8-24 HBase 相关 JVM 参数配置变量

变量名	变量影响的角色
HBASE_OPTS	该变量中设置的参数，将影响 HBase 的所有角色。
SERVER_GC_OPTS	该变量中设置的参数，将影响 HBase Server 端的所有角色，例如：Master、RegionServer 等。
CLIENT_GC_OPTS	该变量中设置的参数，将影响 HBase 的 Client 进程。
HBASE_MASTER_OPTS	该变量中设置的参数，将影响 HBase 的 Master。
HBASE_REGIONSERVER_OPTS	该变量中设置的参数，将影响 HBase 的 RegionServer。
HBASE_THRIFT_OPTS	该变量中设置的参数，将影响 HBase 的 Thrift。

配置方式举例：

```
export HADOOP_NAMENODE_OPTS="-Dhadoop.security.logger=${HADOOP_SECURITY_LOGGER:-INFO,RFAS} -Dhdfs.audit.logger=${HDFS_AUDIT_LOGGER:-INFO,NullAppender} $HADOOP_NAMENODE_OPTS"
```

8.24 HBase 常见问题

8.24.1 客户端连接服务端时，长时间无法连接成功

问题

在 HBase 服务端出现问题，无法提供服务，此时 HBase 客户端进行表操作，会出现该操作挂起，长时间无任何反应。

回答

问题分析

当 HBase 服务端出现问题，HBase 客户端进行表操作的时候，会进行重试，并等待超时。该超时默认值为 Integer.MAX_VALUE (2147483647 ms)，所以 HBase 客户端会在这么长的时间内一直重试，造成挂起表象。

解决方法

HBase 客户端提供两个配置项来控制客户端的重试超时方式，如表 8-25。

在“*客户端安装路径*/HBase/hbase/conf/hbase-site.xml”配置文件中配置如下参数。

表8-25 HBase 客户端操作重试超时相关配置

配置参数	描述	默认值
hbase.client.operation.timeout	客户端操作超时时间。需在配置文件中手动添加。	2147483647 ms
hbase.client.retries.number	最大重试次数。用于表示所有可重试操作所支持的最大重试次数。	35

这两个参数的重试超时的配合方式如图 8-6 所示。

图8-6 HBase 客户端操作重试超时流程

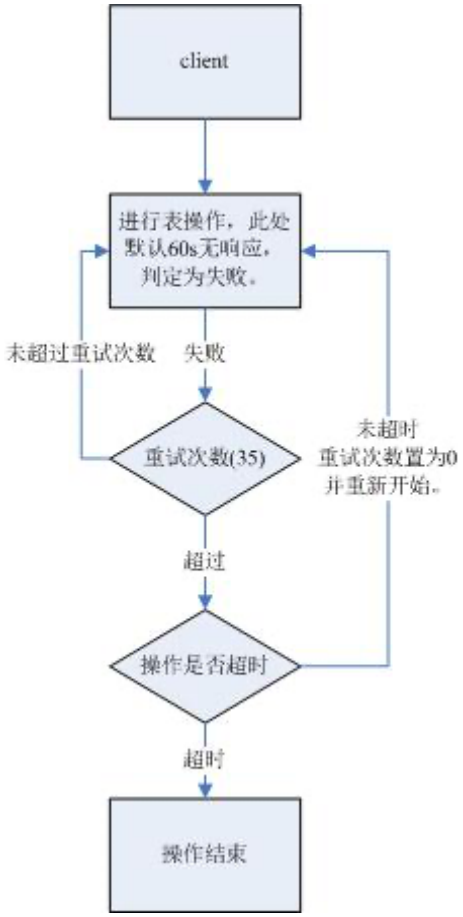

从该流程可以看出，如果未对这两个配置参数根据具体使用场景进行配置，会造成挂起迹象。建议根据使用场景，配置合适的超时时间，如果是长时间操作，则把超时时间设置长一点；如果是短时间操作，则把超时时间设置短一点。而重试次数可以设置为：“(hbase.client.retries.number)*60*1000(ms)”。刚好大于“hbase.client.operation.timeout”设置的超时时间。

8.24.2 结束 BulkLoad 客户端程序，导致作业执行失败

问题

执行 BulkLoad 程序导入数据时，如果结束客户端程序，为什么有时会导致已提交的作业执行失败？

回答

BulkLoad 程序在客户端启动时会生成一个 partitioner 文件，用于划分 Map 任务数据输入的范围。此文件在 BulkLoad 客户端退出时会被自动删除。一般来说当所有 Map 任务都启动运行以后，退出 BulkLoad 客户端也不会导致已提交的作业失败。但由于 Map 任务存在重试机制和推测执行机制；Reduce 任务下载一个已运行完成的 Map 任务的数据失败次数过多时，Map 任务也会被重新执行。如果此时 BulkLoad 客户端已经退出，

则重试的 Map 任务会因为找不到 partitioner 文件而执行失败，导致作业执行失败。因此，强烈建议 BulkLoad 程序在数据导入期间不要结束客户端程序。

8.24.3 在 HBase 连续对同一个表名做删除创建操作时，可能出现创建表异常

问题

在 HBase 连续对同一个表名做删除创建操作时，可能出现创建表异常。

回答

执行过程：Disable Table > Drop Table > Create Table > Disable Table > Drop Table >...

1. 在 Disable 表时，HMaster 会发送 RPC 请求到 RegionServer，RegionServer 会将相关 Region 下线。当 RegionServer 上的 Region 关闭所需的时间超过 HBase 的 HMaster 等待 Region 处于 RIT 状态的超时时间，HMaster 会默认该 Region 下线，实际上该 Region 可能还处在 flush memstore 阶段。
2. 发送 RPC 请求关闭 Region 之后，HMaster 会判断该表的所有 Region 是否下线，上述 1 的情况下关闭超时也会认为是下线，然后 HMaster 返回关闭成功。
3. 关闭成功之后，删除表，HBase 表对应的数据目录被删掉。
4. 在删除表之后，该数据目录会被还处于 flush memstore 阶段的 Region 重新创建。
5. 再创建该表时，将 temp 目录拷贝到 HBase 数据目录时，由于 HBase 数据目录不为空，导致调用 HDFS rename 接口时，数据目录变为 temp 目录最后一层追加到 HBase 的数据目录下，如$rootDir/data/$nameSpace/$tableName/$tableName，那样创建表就会失败。

解决办法：

出现该问题时，请检查该表对应的 HBase 数据目录是否存在，如果存在请将该目录重命名。

HBase 数据目录由$rootDir/data/$nameSpace/$tableName 组成，例如“hdfs://hacluster/hbase/data/default/TestTable”，其中$rootDir 是 HBase 的根目录，该值通过在“hbase-site.xml”中配置 hbase.rootdir.perms 得到，data 目录是 HBase 的固定目录，$nameSpace 是 nameSpace 名字，$tableName 是表名。

8.24.4 HBase 占用网络端口，连接数过大会导致其他服务不稳定

问题

HBase 占用网络端口，连接数过大会导致其他服务不稳定。

回答

使用操作系统命令 ***lsof*** 或者 ***netstat*** 发现大量 TCP 连接处于 CLOSE_WAIT 状态，且连接持有者为 HBase RegionServer，可能导致网络端口耗尽或 HDFS 连接超限，那样可能会导致其他服务不稳定。HBase CLOSE_WAIT 现象为 HBase 机制。

HBase CLOSE_WAIT 产生原因：HBase 数据以 HFile 形式存储在 HDFS 上，这里可以叫 StoreFiles，HBase 作为 HDFS 的客户端，HBase 在创建 StoreFile 或启动加载 StoreFile 时创建了 HDFS 连接，当创建 StoreFile 或加载 StoreFile 完成时，HDFS 方面认为任务已完成，将连接关闭权交给 HBase，但 HBase 为了保证实时响应，有请求时就可以连接对应数据文件，需要保持连接，选择不关闭连接，所以连接状态为 CLOSE_WAIT（需客户端关闭）。

什么时候会创建 StoreFile：当 HBase 执行 Flush 时。

什么时候执行 Flush：HBase 写入数据首先会存在内存 memstore，只有内存使用达到阈值或手动执行 ***flush*** 命令时会触发 flush 操作，将数据写入 HDFS。

解决方法：

由于 HBase 连接机制，若想减小 HBase 端口占用，则需控制 StoreFile 数量，具体可以通过触发 HBase 的 compaction 动作完成，即触发 HBase 文件合并，方法如下：

方法 1：使用 HBase shell 客户端，在客户端手动执行 ***major_compact*** 操作。

方法 2：编写 HBase 客户端代码，调用 HBaseAdmin 类中的 compact 方法触发 HBase 的 compaction 动作。

如果 compact 无法解决 HBase 端口占用现象，说明 HBase 使用情况已经达到瓶颈，需考虑如下几点：

- table 的 Region 数初始设置是否合适。
- 是否存在无用数据。

若存在无用数据，可删除对应数据以减小 HBase 存储文件数量，若以上情况都不满足，则需考虑扩容。

8.24.5 HBase bulkload 任务（单个表有 26T 数据）有 210000 个 map 和 10000 个 reduce，任务失败

问题

HBase bulkLoad 任务（单个表有 26T 数据）有 210000 个 map 和 10000 个 reduce，任务失败。

回答

ZooKeeper IO 瓶颈观测手段：

1. 通过 Manager 的监控页面查看单个节点上 ZooKeeper 请求监控，判断是否严重超出规格限制。
2. 通过观测 ZooKeeper 的日志以及 HBase 的日志，查看是否有大量的 IO Exception Timeout 或者 SocketTimeout Exception 异常。

调优建议：

1. 将 ZooKeeper 实例个数调整为 5 个及以上，可以通过设置 peerType=observer 来增加 observer 的数目。

2. 通过控制单个任务并发的 map 数或减少每个节点下运行 task 的内存，降低节点负载。
3. 升级 ZooKeeper 数据磁盘，如 SSD 等。

8.24.6 如何修复长时间处于 RIT 状态的 Region

问题

在 HBase WEBUI 界面看到有长时间处于 RIT 状态的 Region，如何修复？

回答

登录 HMaster WebUI，在导航栏选择“Procedure & Locks”，查看是否有处于 Waiting 状态的 process id。如果有，需要执行以下命令将 procedure lock 释放：

hbase hbck -j *客户端安装目录*/**HBase/hbase/tools/hbase-hbck2-*.jar bypass -o** *pid*

查看 State 是否处于 Bypass 状态，如果界面上的 procedures 一直处于 RUNNABLE(Bypass)状态，需要进行主备切换。执行 **assigns** 命令使 region 重新上线。

hbase hbck -j *客户端安装目录*/**HBase/hbase/tools/hbase-hbck2-*.jar assigns -o** *regionName*

8.24.7 HMaster 等待 namespace 表上线时超时退出

问题

为什么在等待 namespace 表上线时超时 HMaster 退出？

回答

在 HMaster 主备倒换或启动期间，HMaster 为先前失败/停用的 RegionServer 执行 WAL splitting 及 region 恢复。

在后台运行有多个监控 HMaster 启动进程的线程：

- TableNamespaceManager

  这是一个帮助类，用于在 HMaster 主备倒换或启动期间，管理 namespace 表及监控表 region 的分配。如果 namespace 表在规定时间（hbase.master.namespace.init.timeout，默认为 3600000ms）内没有上线，那么它就会异常中断 HMaster 进程。
- InitializationMonitor

  这是一个主 HMaster 初始化线程监控类，用于监控主 Master 的初始化。如果在规定时间（hbase.master.initializationmonitor.timeout，默认为 3600000ms）内初始化线程失败，该线程会异常终止 HMaster（如果该 hbase.master.initializationmonitor.haltontimeout 被启动，默认为 false）。

在 HMaster 主备倒换或启动期间，如果 WAL hlog 文件存在，它会初始化 WAL splitting 任务。如果 WAL hlog splitting 任务完成，它将初始化表 region 分配任务。

HMaster 通过 ZooKeeper 协调 log splitting 任务和有效的 RegionServer，并追踪任务的发展。如果主 HMaster 在 log splitting 任务期间退出，新的主 HMaster 会尝试重发没有完成的任务，RegionServer 从头启动 log splitting 任务。

HMaster 初始化工作完成情况会由于很多原因被延迟：

- 间歇性的网络故障。
- 磁盘瓶颈。
- log split 任务工作负荷较大，RegionServer 运行缓慢。
- RegionServer（region openning）响应缓慢。

在以上场景中，为使 HMaster 更早完成恢复任务，建议增加以下配置参数，否则 Master 将退出导致整个恢复进程被更大程度地延迟。

- 增加 namespace 表在线等待超时周期，保证 Master 有足够的时间协调 RegionServer workers split 任务，避免一次次重复相同的任务。

  “hbase.master.namespace.init.timeout”（默认为 3600000ms）
- 通过 RegionServer worker 增加并行 split 任务执行数，保证 RegionServer worker 能并行处理 split work（RegionServer 需要有更多的核心）。在“*客户端安装路径*/HBase/hbase/conf/hbase-site.xml”中添加参数：

  “hbase.regionserver.wal.max.splitters”（默认为 2）
- 如果所有的恢复过程都需要时间，增加初始化监控线程超时时间。

  “hbase.master.initializationmonitor.timeout”（默认为 3600000ms）

8.24.8 客户端查询 HBase 出现 SocketTimeoutException 异常

问题

使用 HBase 客户端操作表数据的时候客户端出现类似如下异常：

```
2015-12-15 02:41:14,054 | WARN  | [task-result-getter-2] | Lost task 2.0 in stage
58.0 (TID 3288, linux-175):
org.apache.hadoop.hbase.client.RetriesExhaustedException: Failed after attempts=36,
exceptions:
Tue Dec 15 02:41:14 CST 2015, null, java.net.SocketTimeoutException:
callTimeout=60000, callDuration=60303:
row 'xxxxxx' on table 'xxxxxx' at
region=xxxxxx,\x05\x1E\x80\x00\x00\x00\x80\x00\x00\x00\x00\x00\x00\x00\x80\x00\x00\
x00\x00\x00\x00\x00\x000\x00\x80\x00\x00\x00\x80\x00\x00\x00\x80\x00\x00,
1449912620868.6a6b7d0c272803d8186930a3bfdb10a9.,
hostname=xxxxxx,16020,1449941841479, seqNum=5
at
org.apache.hadoop.hbase.client.RpcRetryingCallerWithReadReplicas.throwEnrichedExcep
tion(RpcRetryingCallerWithReadReplicas.java:275)
at
org.apache.hadoop.hbase.client.ScannerCallableWithReplicas.call(ScannerCallableWith
Replicas.java:223)
at
org.apache.hadoop.hbase.client.ScannerCallableWithReplicas.call(ScannerCallableWith
Replicas.java:61)
at
```

```
org.apache.hadoop.hbase.client.RpcRetryingCaller.callWithoutRetries(RpcRetryingCall
er.java:200)
at org.apache.hadoop.hbase.client.ClientScanner.call(ClientScanner.java:323)
```

同时，在 RegionServer 上出现类似如下日志：

```
2015-12-15 02:45:44,551 | WARN  | PriorityRpcServer.handler=7,queue=1,port=16020 |
(responseTooSlow):
{"call":"Scan(org.apache.hadoop.hbase.protobuf.generated.ClientProtos$ScanRequest)
","starttimems":1450118730780,"responsesize":416,"method":"Scan","processingtimems"
:13770,"client":"10.91.8.175:41182","queuetimems":0,"class":"HRegionServer"} |
org.apache.hadoop.hbase.ipc.RpcServer.logResponse(RpcServer.java:2221)
2015-12-15 02:45:57,722 | WARN  | PriorityRpcServer.handler=3,queue=1,port=16020 |
(responseTooSlow):
{"call":"Scan(org.apache.hadoop.hbase.protobuf.generated.ClientProtos$ScanRequest)"
,"starttimems":1450118746297,"responsesize":416,
"method":"Scan","processingtimems":11425,"client":"10.91.8.175:41182","queuetimems"
:1746,"class":"HRegionServer"} |
org.apache.hadoop.hbase.ipc.RpcServer.logResponse(RpcServer.java:2221)
2015-12-15 02:47:21,668 | INFO  | LruBlockCacheStatsExecutor | totalSize=7.54 GB,
freeSize=369.52 MB, max=7.90 GB, blockCount=406107,
accesses=35400006, hits=16803205, hitRatio=47.47%, , cachingAccesses=31864266,
cachingHits=14806045, cachingHitsRatio=46.47%,
evictions=17654, evicted=16642283, evictedPerRun=942.69189453125 |
org.apache.hadoop.hbase.io.hfile.LruBlockCache.logStats(LruBlockCache.java:858)
2015-12-15 02:52:21,668 | INFO  | LruBlockCacheStatsExecutor | totalSize=7.51 GB,
freeSize=395.34 MB, max=7.90 GB, blockCount=403080,
accesses=35685793, hits=16933684, hitRatio=47.45%, , cachingAccesses=32150053,
cachingHits=14936524, cachingHitsRatio=46.46%,
evictions=17684, evicted=16800617, evictedPerRun=950.046142578125 |
org.apache.hadoop.hbase.io.hfile.LruBlockCache.logStats(LruBlockCache.java:858)
```

回答

出现该问题的主要原因为 RegionServer 分配的内存过小、Region 数量过大导致在运行过程中内存不足，服务端对客户端的响应过慢。在 RegionServer 的配置文件“hbase-site.xml”中需要调整如下对应的内存分配参数。

表8-26 RegionServer 内存调整参数

参数	描述	默认值
GC_OPTS	在启动参数中给 RegionServer 分配的初始内存和最大内存。	-Xms8G -Xmx8G
hfile.block.cache.size	分配给 HFile/StoreFile 所使用的块缓存的最大 heap（-Xmx setting）的百分比。	当 offheap 关闭时，默认值为 0.25。当 offheap 开启时，默认值是 0.1。

8.24.9 使用 scan 命令仍然可以查询到已修改和已删除的数据

问题

为什么使用如下 **scan** 命令仍然可以查询到已修改和已删除的数据？

```
scan
'<table_name>',{FILTER=>"SingleColumnValueFilter('<column_family>','column',=,'bina
ry:<value>')"}
```

回答

由于 HBase 的可扩展性，在查询表的时候，默认情况下会匹配被查询列的所有版本的值，即使被删除或被修改的值也可以查询出来。对于命中列失败的行（即在某一行中不存在该列），HBase 会将该行查询出来。

如果用户仅需查询该表的最新值和命中列成功的行，可使用如下查询语句：

```
scan
'<table_name>',{FILTER=>"SingleColumnValueFilter('<column_family>','column',=,'bina
ry:<value>',true,true)"}
```

使用该命令，不但可以过滤掉命中列失败的行，而且查询的是表的当前数据的最新版本的值，即不查询被修改之前的值和被删除的值。

说明

过滤器 SingleColumnValueFilter 的相关参数说明如下：

SingleColumnValueFilter(final byte[] family, final byte[] qualifier, final CompareOp compareOp, ByteArrayComparable comparator, final boolean filterIfMissing, final boolean latestVersionOnly)

参数说明：

- family：需要查询的列所在的列族；
- qualifier：需要查询的列；
- compareOp：比较符，如“=”、“>”等等；
- comparator：需要查找的目标值；
- filterIfMissing：如果某一行不存在该列，是否过滤，默认值为 false；
- latestVersionOnly：是否仅查询最新版本的值，默认值为 false。

8.24.10 在启动 HBase shell 时，为什么会抛出“java.lang.UnsatisfiedLinkError: Permission denied”异常

问题

在启动 HBase shell 时，为什么会抛出“java.lang.UnsatisfiedLinkError: Permission denied”异常？

回答

在执行 HBase shell 期间，JRuby 会在“java.io.tmpdir”路径下创建一个临时文件，该路径的默认值为“/tmp”。如果为“/tmp”目录设置 NOEXEC 权限，然后 HBase shell 会启动失败并抛出“java.lang.UnsatisfiedLinkError: Permission denied”异常。

因此，如果为“/tmp”目录设置了 NOEXEC 权限，那么“java.io.tmpdir”必须设置为 HBASE_OPTS/CLIENT_GC_OPTS 中不同的路径。

8.24.11 在 HMaster Web UI 中显示处于“Dead Region Servers”状态的 RegionServer 什么时候会被清除掉

问题

在 HMaster Web UI 中显示处于“Dead Region Servers”状态的 RegionServer 什么时候会被清除掉？

回答

当一个在线的 RegionServer 突然运行停止，会在 HMaster Web UI 中显示处于“Dead Region Servers”状态。当停止运行的 RegionServer 重启并且向 HMaster 上报成功信息，在 HMaster Web UI 中会清除掉“Dead Region Servers”信息。

当 HMaster 主备倒换操作成功执行时，在 HMaster Web UI 中也会清除掉“Dead Region Servers”信息。

以防掌控有一些 region 的主用 HMaster 突然停止响应，备用的 HMaster 将会成为新的主用 HMaster，同时显示先前主用 HMaster 变成 dead RegionServer。当 HMaster 主备倒换操作成功执行，在 HMaster Web UI 中也会清除掉“Dead Region Servers”。

8.24.12 使用 HBase bulkload 导入数据成功，执行相同的查询时却可能返回不同的结果

问题

在使用 HBase bulkload 导入数据时，如果导入的数据存在相同的 rowkey 值，数据可以导入成功，但是执行相同的查询时可能返回不同的结果。

回答

正常情况下，相同 rowkey 值的数据加载到 HBase 是有先后顺序的，HBase 以最近的时间戳的数据为最新数据，一般的默认查询中，没有指定时间戳的，就会对相同 rowkey 值的数据仅返回最新数据。

使用 bulkload 加载数据，由于数据在内存中处理生成 HFile，速度是很快的，很可能出现相同 rowkey 值的数据具有相同时间戳，从而造成查询结果混乱的情况。

建议在建表和数据加载时，设计好 rowkey 值，尽量避免在同一个数据文件中存在相同 rowkey 值的情况。

8.24.13 如何处理由于 Region 处于 FAILED_OPEN 状态而造成的建表失败异常

问题

如何处理由于 Region 处于 FAILED_OPEN 状态而造成的建表失败异常。

回答

建表过程中如果发生网络故障、HDFS 故障或者 Active HMaster 故障等情况时，可能会造成部分 Region 上线失败而处于 FAILED_OPEN 状态，导致建表失败。

由于 Region 上线失败而处于 FAILED_OPEN 状态造成的建表失败异常不能直接修复，需要删除该表后重新建表。

操作步骤如下：

1. 在集群客户端使用如下命令修复表的状态。

   hbase hbck -fixTableStates

2. 进入 HBase shell 并执行以下命令完成表的清理。

   truncate *'<table_name>'*

   disable *'<table_name>'*

   drop *'<table_name>'*

3. 使用建表命令重新创建该表。

8.24.14 如何清理由于建表失败残留在 ZooKeeper 中/hbase/table-lock 目录下的表名

问题

安全模式下，由于建表失败，在 ZooKeeper 的 table-lock 节点（默认路径/hbase/table-lock）下残留有新建的表名，请问该如何清理？

回答

操作步骤如下：

1. 在安装好客户端的环境下，使用 hbase 用户进行 kinit 认证。
2. 执行 ***hbase zkcli*** 命令进入 ZooKeeper 命令行。
3. 在 ZooKeeper 命令行中执行 ***ls /hbase/table***，查看新建的表名是否存在。
   - 是，结束。
   - 否，执行 ***ls /hbase/table-lock*** 查看新建的表名是否存在，若存在新建的表名时使用 ***delete*** 命令（***delete /hbase/table-lock/<table>***，其中<table>为残留的表名）删除该表名。

8.24.15 为什么给 HDFS 上的 HBase 使用的目录设置 quota 会造成 HBase 故障

问题

为什么给 HDFS 上的 HBase 使用的目录设置 quota 会造成 HBase 故障？

回答

表的 flush 操作是在 HDFS 中写 memstore 数据。

如果 HDFS 目录没有足够的磁盘空间 quota，flush 操作会失败，这样 region server 将会终止。

```
Caused by: org.apache.hadoop.hdfs.protocol.DSQuotaExceededException: The DiskSpace
quota of /hbase/data/<namespace>/<tableName> is exceeded: quota = 1024 B = 1 KB but
diskspace consumed = 402655638 B = 384.00 MB
?at
org.apache.hadoop.hdfs.server.namenode.DirectoryWithQuotaFeature.verifyStoragespace
Quota(DirectoryWithQuotaFeature.java:211)
?at
org.apache.hadoop.hdfs.server.namenode.DirectoryWithQuotaFeature.verifyQuota(Direct
oryWithQuotaFeature.java:239)
?at
org.apache.hadoop.hdfs.server.namenode.FSDirectory.verifyQuota(FSDirectory.java:882)
?at
org.apache.hadoop.hdfs.server.namenode.FSDirectory.updateCount(FSDirectory.java:711)
?at
org.apache.hadoop.hdfs.server.namenode.FSDirectory.updateCount(FSDirectory.java:670)
?at
org.apache.hadoop.hdfs.server.namenode.FSDirectory.addBlock(FSDirectory.java:495)
```

上述异常中，表“/hbase/data/<namespace>/<tableName>”的磁盘空间 quota 值为 1KB，但是 memstore 数据为 384.00MB，所以 flush 操作失败并且 region server 会终止。

在 region server 终止时，HMaster 对终止的 region server 的 WAL 文件进行 replay 操作以恢复数据。由于限制了磁盘空间 quota 值，导致 WAL 文件的 replay 操作失败进而导致 HMaster 进程异常退出。

```
2016-07-28 19:11:40,352 | FATAL | MASTER_SERVER_OPERATIONS-10-91-9-131:16000-0 |
Caught throwable while processing event M_SERVER_SHUTDOWN |
org.apache.hadoop.hbase.master.HMaster.abort(HMaster.java:2474)
java.io.IOException: failed log splitting for 10-91-9-131,16020,1469689987884, will
retry
?at
org.apache.hadoop.hbase.master.handler.ServerShutdownHandler.resubmit(ServerShutdow
nHandler.java:365)
?at
org.apache.hadoop.hbase.master.handler.ServerShutdownHandler.process(ServerShutdown
Handler.java:220)
?at org.apache.hadoop.hbase.executor.EventHandler.run(EventHandler.java:129)
?at java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1142)
?at java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:617)
```

```
?at java.lang.Thread.run(Thread.java:745)
Caused by: java.io.IOException: error or interrupted while splitting logs in
[hdfs://hacluster/hbase/WALs/<RS-Hostname>,<RS-Port>,<startcode>-splitting] Task =
installed = 6 done = 3 error = 3
?at
org.apache.hadoop.hbase.master.SplitLogManager.splitLogDistributed(SplitLogManager.
java:290)
?at
org.apache.hadoop.hbase.master.MasterFileSystem.splitLog(MasterFileSystem.java:402)
?at
org.apache.hadoop.hbase.master.MasterFileSystem.splitLog(MasterFileSystem.java:375)
```

因此，不支持用户对 HDFS 上的 HBase 目录进行 quota 值设置。上述问题可通过下述步骤解决：

在客户端命令提示符下运行 **kinit** *用户名*命令，使 HBase 用户获得安全认证。

步骤 1 运行 **hdfs dfs -count -q** */hbase/data/<namespace>/<tableName>*命令检查分配的磁盘空间 quota。

步骤 2 使用下列命令取消 quota 值限制，恢复 HBase。

hdfs dfsadmin -clrSpaceQuota */hbase/data/<namespace>/<tableName>*

----结束

8.24.16 为什么在使用 OfflineMetaRepair 工具重新构建元数据后，HMaster 启动的时候会等待 namespace 表分配超时，最后启动失败

问题

为什么在使用 OfflineMetaRepair 工具重新构建元数据后，HMaster 启动的时候会等待 namespace 表分配超时，最后启动失败？

且 HMaster 将输出下列 FATAL 消息表示中止：

```
2017-06-15 15:11:07,582 FATAL [Hostname:16000.activeMasterManager] master.HMaster:
Unhandled exception. Starting shutdown.
java.io.IOException: Timedout 120000ms waiting for namespace table to be assigned
      at
org.apache.hadoop.hbase.master.TableNamespaceManager.start(TableNamespaceManager.ja
va:98)
      at org.apache.hadoop.hbase.master.HMaster.initNamespace(HMaster.java:1054)
      at
org.apache.hadoop.hbase.master.HMaster.finishActiveMasterInitialization(HMaster.jav
a:848)
      at org.apache.hadoop.hbase.master.HMaster.access$600(HMaster.java:199)
      at org.apache.hadoop.hbase.master.HMaster$2.run(HMaster.java:1871)
      at java.lang.Thread.run(Thread.java:745)
```

回答

当通过 OfflineMetaRepair 工具重建元数据时，HMaster 在启动期间等待所有 region server 的 WAL 分割，以避免数据不一致问题。一旦 WAL 分割完成，HMaster 将进行用

户 region 的分配。所以当在集群异常的场景下，WAL 分割可能需要很长时间，这取决于多个因素，例如太多的 WALs，较慢的 I/O，region servers 不稳定等。

为确保 HMaster 能够成功完成所有 region server WAL 分割，请执行以下步骤：

1. 确保集群稳定，不存在其他问题。如有任何问题，请先修复。
2. 为“hbase.master.initializationmonitor.timeout”参数配置一个较大的值，默认值为“3600000”毫秒。
3. 重启 HBase 服务。

8.24.17 为什么 splitWAL 期间 HMaster 日志中频繁打印出 FileNotFoundException 及 no lease 信息

问题

当集群重启后会进行 split WAL 操作，在 splitWAL 期间，HMaster 出现不能 close log，日志中频繁打印出 FileNotFoundException 及 no lease 信息。

```
2017-06-10 09:50:27,586 | ERROR | split-log-closeStream-2 | Couldn't close log at
hdfs://hacluster/hbase/data/default/largeT1/2b48346d087275fe751fc049334fda93/recove
red.edits/000000000000000000.temp |
org.apache.hadoop.hbase.wal.WALSplitter$LogRecoveredEditsOutputSink$2.call(WALSplit
ter.java:1330)
java.io.FileNotFoundException: No lease on
/hbase/data/default/largeT1/2b48346d087275fe751fc049334fda93/recovered.edits/000000
0000000000000.temp (inode 1092653): File does not exist. [Lease.  Holder:
DFSClient_NONMAPREDUCE_1202985678_1, pendingcreates: 1936]
?at
org.apache.hadoop.hdfs.server.namenode.FSNamesystem.checkLease(FSNamesystem.java:34
32)
?at
org.apache.hadoop.hdfs.server.namenode.FSNamesystem.analyzeFileState(FSNamesystem.j
ava:3223)
?at
org.apache.hadoop.hdfs.server.namenode.FSNamesystem.getNewBlockTargets(FSNamesystem
.java:3057)
?at
org.apache.hadoop.hdfs.server.namenode.FSNamesystem.getAdditionalBlock(FSNamesystem
.java:3011)
?at
org.apache.hadoop.hdfs.server.namenode.NameNodeRpcServer.addBlock(NameNodeRpcServer
.java:842)
?at
org.apache.hadoop.hdfs.protocolPB.ClientNamenodeProtocolServerSideTranslatorPB.addB
lock(ClientNamenodeProtocolServerSideTranslatorPB.java:526)
?at
org.apache.hadoop.hdfs.protocol.proto.ClientNamenodeProtocolProtos$ClientNamenodePr
otocol$2.callBlockingMethod(ClientNamenodeProtocolProtos.java)
?at
org.apache.hadoop.ipc.ProtobufRpcEngine$Server$ProtoBufRpcInvoker.call(ProtobufRpcE
ngine.java:616)
?at org.apache.hadoop.ipc.RPC$Server.call(RPC.java:973)
?at org.apache.hadoop.ipc.Server$Handler$1.run(Server.java:2260)
```

```
?at org.apache.hadoop.ipc.Server$Handler$1.run(Server.java:2256)
?at java.security.AccessController.doPrivileged(Native Method)
?at javax.security.auth.Subject.doAs(Subject.java:422)
?at
org.apache.hadoop.security.UserGroupInformation.doAs(UserGroupInformation.java:1769)
?at org.apache.hadoop.ipc.Server$Handler.run(Server.java:2254)

?at sun.reflect.GeneratedConstructorAccessor40.newInstance(Unknown Source)
?at
sun.reflect.DelegatingConstructorAccessorImpl.newInstance(DelegatingConstructorAcce
ssorImpl.java:45)
?at java.lang.reflect.Constructor.newInstance(Constructor.java:423)
?at
org.apache.hadoop.ipc.RemoteException.instantiateException(RemoteException.java:106)
?at
org.apache.hadoop.ipc.RemoteException.unwrapRemoteException(RemoteException.java:73)
?at  org.apache.hadoop.hdfs.DataStreamer.locateFollowingBlock(DataStreamer.java:1842)
?at
org.apache.hadoop.hdfs.DataStreamer.nextBlockOutputStream(DataStreamer.java:1639)
?at org.apache.hadoop.hdfs.DataStreamer.run(DataStreamer.java:665)
```

回答

在 splitWAL 的过程中，参数“hbase.splitlog.manager.timeout”控制 splitWAL 的超时时间，若该时间内 splitWAL 无法完成，则会再次提交相同的任务，在一定时间内多次提交了相同的任务，当其中某次任务执行完毕时会删除这个 temp 文件，所以在后来的任务执行时无法找到这个文件，故出现 FileNotFoudException。需做如下调整：

当前“hbase.splitlog.manager.timeout”的默认时间为“600000ms”，集群规格为每个 regionserver 上有 2000~3000 个 region，在集群正常情况下(HBase 无异常，HDFS 无大量的读写操作等)，建议此参数依据集群的规格进行调整，若实际规格（实际平均每个 regonserver 上 region 的个数）大于默认规格（默认平均每个 regionserver 上 region 的个数，即 2000），则调整方案为（实际规格 / 默认规格）* 默认时间。

在服务端的“hbase-site.xml”文件中配置 splitlog 参数，如表 8-27 所示。

表8-27 splitlog 参数说明

参数	描述	默认值
hbase.splitlog.manager.timeout	分布式日志分裂管理程序接收 worker 回应的超时时间	600000

8.24.18 租户访问 Phoenix 提示权限不足

问题

使用租户访问 Phoenix 提示权限不足。

回答

创建租户的时候需要关联 HBase 服务和 Yarn 队列。

租户要操作 Phoenix 还需要额外操作的权限，即 Phoenix 系统表的 RWX 权限。

例如：

创建好的租户为 **hbase**，使用 **admin** 用户登录 hbase shell，执行 **scan 'hbase:acl'**命令查询租户对应的角色为 **hbase_1450761169920**（格式为：租户名_时间戳）。

执行以下命令进行授权（如果还没有生成 Phoenix 系统表，请用 **admin** 用户登录 Phoenix 客户端后再回到 hbase shell 里授权）：

grant '@hbase_1450761169920','RWX','*SYSTEM.CATALOG*'

grant '@hbase_1450761169920','RWX','*SYSTEM.FUNCTION*'

grant '@hbase_1450761169920','RWX','*SYSTEM.SEQUENCE*'

grant '@hbase_1450761169920','RWX','*SYSTEM.STATS*'

新建用户 **phoenix** 并绑定租户 **hbase**，该用户 phoenix 就可以用来访问 Phoenix 客户端。

8.24.19 如何解决 HBase 恢复数据任务失败后错误详情中提示：Rollback recovery failed 的回滚失败问题

问题

HBase 恢复任务执行失败后系统自动回滚数据，若页面详情中提示“Rollback recovery failed”信息，表示回滚失败。由于回滚失败后就不会处理数据，所以有可能产生垃圾数据，需要如何解决？

回答

在下次执行备份或恢复任务前，需要手动清除这些垃圾数据。

安装集群客户端，例如安装目录为“/opt/client”。

步骤 1 使用客户端安装用户，执行 **source /opt/client/bigdata_env** 命令配置环境变量。

步骤 2 执行 **kinit admin** 命令。

步骤 3 执行 **zkCli.sh -server *ZooKeeper 节点业务 IP 地址*:2181** 连接 ZooKeeper。

步骤 4 执行 **deleteall /recovering** 删除垃圾数据。然后执行 **quit** 退出 ZooKeeper 连接。

说明

执行该命令会导致数据丢失，请谨慎操作。

步骤 5 执行 **hdfs dfs -rm -f -r /user/hbase/backup** 删除临时数据。

步骤 6 登录 FusionInsight Manager 界面，选择“运维 > 备份恢复 > 恢复管理”，在任务列表中对应任务的“操作”列，单击“查询历史”，在弹出的窗口中，在指定一次执行记录前单击，即可查看相关的快照名称信息：

```
Snapshot [ snapshot name ] is created successfully before recovery.
```

步骤 7 切换到客户端，执行 **hbase shell**，然后运行 **delete_all_snapshot** '*snapshot name*.*'删除临时快照。

----结束

8.24.20 如何修复 Region Overlap

问题

使用 HBck 工具检查 Region 状态，若日志中存在“ERROR: (regions region1 and region2) There is an overlap in the region chain.”或者“ERROR: (region region1) Multiple regions have the same startkey: xxx”信息，表示某些 Region 存在 Overlap 的问题，需要如何解决？

回答

修复步骤如下：

执行 **hbase hbck -repair** *tableName* 命令修复存在 overlap 的表。

步骤 1 执行 **hbase hbck** *tableName* 命令检查修复的表是否还存在 overlap。

- 如果不存在 overlap，执行步骤 3。
- 如果存在 overlap，执行步骤 1。

步骤 2 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > HBase > 更多 > 执行 HMaster 倒换”，完成 HMaster 主备倒换。

步骤 3 执行 **hbase hbck** *tableName* 命令检查修复的表是否还存在 overlap。

- 如果不存在 overlap，修复完成。
- 如果存在 overlap，从步骤 1 开始重新执行修复步骤。

----结束

8.24.21 HBase RegionServer GC 参数 Xms，Xmx 配置 31G，导致 RegionServer 启动失败

问题

查看 RegionServer 启动失败节点的 hbase-omm-*.out 日志，发现日志中存在“An error report file with more information is saved as: /tmp/hs_err_pid*.log”，查看 /tmp/hs_err_pid*.log 发现日志存在“#Internal Error (vtableStubs_aarch64.cpp:213),

pid=9456, tid=0x0000ffff97fdd200”和“#guarantee(__ pc() <= s->code_end()) failed: overflowed buffer”，表示此问题是由 JDK 导致，需要如何解决？

回答

修复步骤如下：

在 RegionServer 启动失败的某个节点执行 **su - omm**，切换到 **omm** 用户。

步骤 1 在 omm 用户下执行 **java -XX:+PrintFlagsFinal -version |grep HeapBase**，出现如下类似结果。

```
uintx HeapBaseMinAddress = 2147483648 {pd product}
```

步骤 2 修改“GC_OPTS”中“-Xms”和“-Xmx”的值使其不在 32G-HeapBaseMinAddress 和 32G 的值之间，不包括 32G 和 32G-HeapBaseMinAddress 的值。

步骤 3 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > HBase > 实例”，选择失败实例，选择“更多 > 重启实例”来重启失败实例。

----结束

8.24.22 使用集群内节点执行批量导入，为什么 LoadIncrementalHFiles 工具执行失败报“Permission denied”的异常

问题

在普通集群中手动创建 Linux 用户，并使用集群内 DataNode 节点执行批量导入时，为什么 LoadIncrementalHFiles 工具执行失败报“Permission denied”的异常？

```
2020-09-20 14:53:53,808 WARN  [main] shortcircuit.DomainSocketFactory: error
creating DomainSocket
java.net.ConnectException: connect(2) error: Permission denied when trying to
connect to '/var/run/FusionInsight-HDFS/dn_socket'
    at org.apache.hadoop.net.unix.DomainSocket.connect0(Native Method)
    at org.apache.hadoop.net.unix.DomainSocket.connect(DomainSocket.java:256)
    at
org.apache.hadoop.hdfs.shortcircuit.DomainSocketFactory.createSocket(DomainSocketFa
ctory.java:168)
    at
org.apache.hadoop.hdfs.client.impl.BlockReaderFactory.nextDomainPeer(BlockReaderFac
tory.java:804)
    at
org.apache.hadoop.hdfs.client.impl.BlockReaderFactory.createShortCircuitReplicaInfo
(BlockReaderFactory.java:526)
    at
org.apache.hadoop.hdfs.shortcircuit.ShortCircuitCache.create(ShortCircuitCache.java
:785)
    at
org.apache.hadoop.hdfs.shortcircuit.ShortCircuitCache.fetchOrCreate(ShortCircuitCac
he.java:722)
    at
```

```
org.apache.hadoop.hdfs.client.impl.BlockReaderFactory.getBlockReaderLocal(BlockRead
erFactory.java:483)
    at
org.apache.hadoop.hdfs.client.impl.BlockReaderFactory.build(BlockReaderFactory.java
:360)
   at  org.apache.hadoop.hdfs.DFSInputStream.getBlockReader(DFSInputStream.java:663)
    at org.apache.hadoop.hdfs.DFSInputStream.blockSeekTo(DFSInputStream.java:594)
    at
org.apache.hadoop.hdfs.DFSInputStream.readWithStrategy(DFSInputStream.java:776)
    at org.apache.hadoop.hdfs.DFSInputStream.read(DFSInputStream.java:845)
    at java.io.DataInputStream.readFully(DataInputStream.java:195)
    at
org.apache.hadoop.hbase.io.hfile.FixedFileTrailer.readFromStream(FixedFileTrailer.j
ava:401)
    at org.apache.hadoop.hbase.io.hfile.HFile.isHFileFormat(HFile.java:651)
    at org.apache.hadoop.hbase.io.hfile.HFile.isHFileFormat(HFile.java:634)
    at
org.apache.hadoop.hbase.tool.LoadIncrementalHFiles.visitBulkHFiles(LoadIncrementalH
Files.java:1090)
    at
org.apache.hadoop.hbase.tool.LoadIncrementalHFiles.discoverLoadQueue(LoadIncrementa
lHFiles.java:1006)
    at
org.apache.hadoop.hbase.tool.LoadIncrementalHFiles.prepareHFileQueue(LoadIncrementa
lHFiles.java:257)
    at
org.apache.hadoop.hbase.tool.LoadIncrementalHFiles.doBulkLoad(LoadIncrementalHFiles
.java:364)
    at
org.apache.hadoop.hbase.tool.LoadIncrementalHFiles.run(LoadIncrementalHFiles.java:1
263)
    at
org.apache.hadoop.hbase.tool.LoadIncrementalHFiles.run(LoadIncrementalHFiles.java:1
276)
    at
org.apache.hadoop.hbase.tool.LoadIncrementalHFiles.run(LoadIncrementalHFiles.java:1
311)
    at org.apache.hadoop.util.ToolRunner.run(ToolRunner.java:76)
    at
org.apache.hadoop.hbase.tool.LoadIncrementalHFiles.main(LoadIncrementalHFiles.java:
1333)
```

回答

如果 LoadIncrementalHFiles 工具依赖的 Client 在集群内安装，且和 DataNode 在相同的节点上，在工具执行过程中 HDFS 会创建短路读提高性能。短路读依赖“/var/run/FusionInsight-HDFS”目录(“dfs.domain.socket.path”)，该目录默认权限是750。而当前 Linux 用户没有权限操作该目录。

上述问题可通过执行以下方法解决：

方法一：创建新用户(推荐使用)。

通过 Manager 页面创建新的用户，该用户属组中默认包含 ficommon 组。

```
[root@xxx-xxx-xxx-xxx ~]# id test
uid=20038(test) gid=9998(ficommon) groups=9998(ficommon)
```

步骤 1 重新执行 ImportData。

----结束

方法二：修改当前用户的属组。

将该用户添加到 ficommon 组中。

```
[root@xxx-xxx-xxx-xxx ~]# usermod -a -G ficommon test
[root@xxx-xxx-xxx-xxx ~]# id test
uid=2102(test) gid=2102(test) groups=2102(test),9998(ficommon)
```

步骤 2 重新执行 ImportData。

----结束

8.24.23 Phoenix sqlline 脚本使用，报 import argparse 错误

问题

在客户端使用 sqlline 脚本时，报 import argparse 错误。

回答

以 **root** 用户登录安装 HBase 客户端的节点，使用 **hbase** 用户进行安全认证。

步骤 1 进入 HBase 客户端 sqlline 脚本所在目录执行 **python3 sqlline.py** 命令。

----结束

8.24.24 Phoenix BulkLoad Tool 限制

问题

当更新索引字段数据时，若用户表已经存在一批数据，则 BulkLoad 工具不能更新全局和局部可变索引。

回答

问题分析

1. 创建表。

```
CREATE TABLE TEST_TABLE(
DATE varchar not null,
NUM integer not null,
SEQ_NUM integer not null,
ACCOUNT1 varchar not null,
ACCOUNTDES varchar,
FLAG varchar,
```

```
SALL double,
CONSTRAINT PK PRIMARY KEY (DATE,NUM,SEQ_NUM,ACCOUNT1)
);
```

2. 创建全局索引

   CREATE INDEX TEST_TABLE_INDEX ON TEST_TABLE(ACCOUNT1,DATE,NUM,ACCOUNTDES,SEQ_NUM);

3. 插入数据

   UPSERT INTO TEST_TABLE (DATE,NUM,SEQ_NUM,ACCOUNT1,ACCOUNTDES,FLAG,SALL) values ('20201001',30201001,13,'367392332','sffa1','','');

4. 执行 BulkLoad 任务更新数据

   hbase org.apache.phoenix.mapreduce.CsvBulkLoadTool -t TEST_TABLE -i /tmp/test.csv，test.csv 内容如下：

```
20201001    30201001    13    367392332    sffa888    1231243    23
```

5. 问题现象：无法直接更新之前存在的索引数据，导致存在两条索引数据。

```
+------------+-----------+-----------+---------------+-----------------+
| :ACCOUNT1  |   :DATE   |   :NUM    | 0:ACCOUNTDES  | :SEQ_NUM  |
+------------+-----------+-----------+---------------+-----------------+
| 367392332  | 20201001  | 30201001  | sffa1         |  13               |
| 367392332  | 20201001  | 30201001  | sffa888       | 13                |
+------------+-----------+-----------+---------------+-----------------+
```

解决方法

删除旧的索引表。

DROP INDEX TEST_TABLE_INDEX ON TEST_TABLE;

步骤 1 异步方式创建新的索引表。

CREATE INDEX TEST_TABLE_INDEX ON TEST_TABLE(ACCOUNT1,DATE,NUM,ACCOUNTDES,SEQ_NUM) ASYNC;

步骤 2 索引重建。

hbase org.apache.phoenix.mapreduce.index.IndexTool --data-table TEST_TABLE --index-table TEST_TABLE_INDEX --output-path /user/test_table

----结束

8.24.25 CTBase 对接 Ranger 权限插件，提示权限不足

问题

CTBase 访问启用 Ranger 插件的 HBase 服务时，如果创建聚簇表，提示权限不足。

```
ERROR: Create ClusterTable failed. Error:
org.apache.hadoop.hbase.security.AccessDeniedException: Insufficient permissions
for user 'ctbase2@HADOOP.COM' (action=create)
at
org.apache.ranger.authorization.hbase.AuthorizationSession.publishResults(Authoriza
tionSession.java:278)
```

```
at
org.apache.ranger.authorization.hbase.RangerAuthorizationCoprocessor.authorizeAcces
s(RangerAuthorizationCoprocessor.java:654)
at
org.apache.ranger.authorization.hbase.RangerAuthorizationCoprocessor.requirePermiss
ion(RangerAuthorizationCoprocessor.java:772)
at
org.apache.ranger.authorization.hbase.RangerAuthorizationCoprocessor.preCreateTable
(RangerAuthorizationCoprocessor.java:943)
at
org.apache.ranger.authorization.hbase.RangerAuthorizationCoprocessor.preCreateTable
(RangerAuthorizationCoprocessor.java:428)
at
org.apache.hadoop.hbase.master.MasterCoprocessorHost$12.call(MasterCoprocessorHost.
java:351)
at
org.apache.hadoop.hbase.master.MasterCoprocessorHost$12.call(MasterCoprocessorHost.
java:348)
at
org.apache.hadoop.hbase.coprocessor.CoprocessorHost$ObserverOperationWithoutResult.
callObserver(CoprocessorHost.java:581)
at
org.apache.hadoop.hbase.coprocessor.CoprocessorHost.execOperation(CoprocessorHost.j
ava:655)
at
org.apache.hadoop.hbase.master.MasterCoprocessorHost.preCreateTable(MasterCoprocess
orHost.java:348)
at org.apache.hadoop.hbase.master.HMaster$5.run(HMaster.java:2192)
at
org.apache.hadoop.hbase.master.procedure.MasterProcedureUtil.submitProcedure(Master
ProcedureUtil.java:134)
at org.apache.hadoop.hbase.master.HMaster.createTable(HMaster.java:2189)
at
org.apache.hadoop.hbase.master.MasterRpcServices.createTable(MasterRpcServices.java
:711)
at
org.apache.hadoop.hbase.shaded.protobuf.generated.MasterProtos$MasterService$2.call
BlockingMethod(MasterProtos.java)
at org.apache.hadoop.hbase.ipc.RpcServer.call(RpcServer.java:458)
at org.apache.hadoop.hbase.ipc.CallRunner.run(CallRunner.java:133)
at org.apache.hadoop.hbase.ipc.RpcExecutor$Handler.run(RpcExecutor.java:338)
at org.apache.hadoop.hbase.ipc.RpcExecutor$Handler.run(RpcExecutor.java:318)
```

回答

CTBase 用户在 Ranger 界面配置权限策略，赋予 CTBase 元数据表_ctmeta_、聚簇表和索引表 RWCAE（READ，WRITE，EXEC，CREATE，ADMIN）权限。

8.24.26 如何查看 ENABLED 表的 CLOSED 状态的 Region

问题

如何在 HBase 客户端查看 ENABLED 表的 CLOSED 状态的 Region。

该操作仅 MRS 3.3.0 及之后版本支持。

处理步骤

以客户端安装用户登录到安装了 HBase 客户端的节点。

步骤 1 切换到客户端安装目录并配置环境变量：

cd *客户端安装目录*

source bigdata_env

步骤 2 若集群已启用 Kerberos 认证（安全模式），需执行以下命令进行安全认证，若集群未启用 Kerberos 认证（普通模式）请跳过该步骤。

kinit *组件业务用户*

步骤 3 执行以下命令查看 ENABLED 表的 CLOSED 状态的 Region：

hbase hbck -j HBase/hbase/tools/hbase-hbck2-*.jar reportClosedRegions [-details] [<TABLENAME>...]

其中：

- 不输入**-details** 时只输出 CLOSED 状态的 Region 数量，输入**-details** 时输出所有 CLOSED 状态的 Region 名称。
- 不指定 *TABLENAME* 时默认查看所有表。
- 命令执行后若输出“Closed region due to split”，说明该 Region 是由于 Split 而转为 CLOSED 状态的，Split 完成后该 Region 会自动从 meta 表中移除。

```
Table meta_graph is okay.
Table hbase:namespace is okay.
Table hbase:hindex is okay.
Table hbase:rsgroup is okay.
Table ns1:test1 is okay.
Table graphbaseORM_systemNotifications is okay.
Table hbase:acl is okay.
Table testComp has 1 closed regions.
Closed region due to split testComp,,1690447776336.d5f1eb4a53bf63eb688441a1e58f9835.
```

----结束

8.24.27 集群异常掉电导致 HBase 文件损坏，如何快速自恢复？

问题

集群异常掉电导致 HBase 的 StoreFile 文件或 WAL 文件损坏，如何快速恢复？

该操作仅 MRS 3.3.0 及之后版本支持。

原因分析

当 StoreFile 文件损坏时，相关的 Region 会一直上线失败并重试，无法对外提供服务；当 WAL 文件损坏时，日志拆分会一直失败并重试，相关的 Region 无法重新上线并对外提供服务。

处理步骤

HBase 服务端提供两个配置项来控制是否跳过损坏的 StoreFile 文件或 WAL 文件。登录 FusionInsight Manager，选择“集群 > 服务 > HBase > 配置”，搜索并配置表 8-28 中的参数，参数支持动态生效，保存配置后登录 **hbase shell** 执行 **update_all_config** 即生效。

跳过损坏的文件可能会导致数据丢失，因此如下参数设置为“true”后，如果跳过了损坏的 StoreFile 文件或 WAL 文件，服务会上报“ALM-19025 HBase 存在损坏的 StoreFile 文件”或“ALM-19026 HBase 存在损坏的 WAL 文件”告警，请参考相应的告警帮助进行处理。

表8-28 HBase 服务端跳过损坏的文件相关配置

参数名称	参数描述	默认值
hregion.hfile.skip.errors	Region 上线时遇到 HFile 损坏是否跳过并移动到“/hbase/autocorrupt”或“/hbase/MasterData/autocorrupt”目录，容灾场景不建议开启此参数。	false
hbase.hlog.split.skip.errors	日志拆分时是否跳过损坏的 WAL 文件并移动到“/hbase/corrupt”目录。	false

9 使用 HDFS

9.1 从零开始使用 Hadoop

本章节提供从零开始使用 Hadoop 提交 wordcount 作业的操作指导，wordcount 是最经典的 Hadoop 作业，它用来统计海量文本的单词数量。

操作步骤

准备 wordcount 程序。

开源的 Hadoop 的样例程序包含多个例子，其中包含 wordcount。可以从 https://dist.apache.org/repos/dist/release/hadoop/common/中下载 Hadoop 的样例程序。

例如，选择 hadoop-*x.x.x* 版本，下载“hadoop-x.x.x.tar.gz”，解压后在“hadoop-x.x.x\share\hadoop\mapreduce”路径下获取“hadoop-mapreduce-examples-x.x.x.jar”，即为 Hadoop 的样例程序。“hadoop-mapreduce-examples-x.x.x.jar”样例程序包含了 wordcount 程序。

说明

hadoop-*x.x.x* 表示 Hadoop 的版本号，具体以实际为准。

步骤 1 准备数据文件。

数据文件无格式要求，准备一个或多个 txt 文件即可，如下内容为 txt 文件样例：

```
qwsdfhoedfrffrofhuncckgktpmhutopmma
jjpsffjfjorgjgtyiuyjmhombmbogohoyhm
jhheyeombdhuaqqiquyebchdhmamdhdemmj
doeyhjwedcrfvtgbmojiyhhqssddddddfkf
kjhhjkehdeiyrudjhfhfhffooqweopuyyyy
```

步骤 2 上传数据至 OBS。

1. 登录 OBS 控制台。
2. 单击“并行文件系统 > 创建并行文件系统”，创建一个名称为 wordcount01 的文件系统。

   wordcount01 仅为示例，文件系统名称必须全局唯一，否则会创建并行文件系统失败。

3. 在 OBS 文件系统列表中单击文件系统名称 wordcount01，选择“文件 > 新建文件夹”，分别创建 program、input 文件夹。
   - program：存放用户程序
   - input：存放用户数据文件
4. 进入 program 文件夹，选择“上传文件 > 添加文件”，从本地选择步骤 1 中下载的程序包，然后单击“上传”。
5. 进入 input 文件夹，将步骤 2 中准备的数据文件上传到 input 文件夹。

步骤 3 登录 MRS 控制台，在左侧导航栏选择“集群列表 > 现有集群”，单击集群名称，该集群需要包含 Hadoop 组件，且已为 MRS 集群绑定具有 OBS 文件系统操作权限的 IAM 权限委托。

查看或绑定委托的操作如下：

1. 登录 MRS 集群的“概览”页面，查看“委托”参数是否有值，且绑定的委托具有 OBS 文件系统操作权限。

   

   - 是，集群已绑定委托。
   - 否，执行步骤 4.2。
2. 单击“管理委托”，为集群绑定具有 OBS 文件系统操作权限的委托。

   您可以直接选择系统默认的“MRS_ECS_DEFAULT_AGENCY”，也可以单击“新建委托”自行创建其他具有 OBS 文件系统操作权限的委托。

步骤 4 提交 wordcount 作业。

在 MRS 控制台选择“作业管理”页签，单击“添加”，进入“添加作业”页面。

- 作业类型选择“MapReduce”。
- 作业名称为“mr_01”。
- 执行程序路径配置为 OBS 上存放程序的地址。例如：obs://wordcount01/program/hadoop-mapreduce-examples-*x.x.x*.jar。
- 执行程序参数中填写的参数为：wordcount obs://wordcount01/input/ obs://wordcount01/output/。

  说明
  - 参数“**obs://wordcount01/input/**”中的 OBS 文件系统名需要替换为实际环境创建的文件系统名。
  - 参数“**obs://wordcount01/output/**”中的 OBS 文件系统名需要替换为实际环境创建的文件系统名，目录 output 为一个不存在的目录，具体以实际为准。
- 服务配置参数无需填写。

只有集群处于“运行中”状态时才能提交作业。

作业提交成功后默认为“已接受”状态，不需要用户手动执行作业。

步骤 5 查看作业执行结果。

1. 进入“作业管理”页面，查看作业是否执行完成。

   作业运行需要时间，作业运行结束后，刷新作业列表。

   作业执行成功或失败后都不能再次执行，只能新增或者复制作业，配置作业参数后重新提交作业。

2. 登录 OBS 控制台，进入 OBS 路径，查看作业输出信息。

   进入到步骤 5 中创建的 output 路径查看相关的 output 文件，需要下载到本地以文本方式打开进行查看。

----结束

9.2 配置内存管理

配置场景

在 HDFS 中，每个文件对象都需要在 NameNode 中注册相应的信息，并占用一定的存储空间。随着文件数的增加，当原有的内存空间无法存储相应的信息时，需要修改内存大小的设置。

配置描述

参数入口：

请参考 25.1 修改集群服务配置参数，进入 HDFS“全部配置”页面。

表9-1 参数说明

配置参数	说明	默认值
GC_PROFILE	NameNode 所占内存主要由 FsImage 大小决定。FsImage Size = 文件数 * 900 Bytes，根据计算结果可估算 hdfs 的 NameNode 应设内存大小。 该参数项的内存大小取值如下： • high：4G • medium：2G • low：256M • custom：根据实际数据量大小在 GC_OPTS 中设置内存大小。	custom
GC_OPTS	JVM 用于 gc 的参数。仅当 GC_PROFILE 设置为 custom 时该配置才会生效。需确保 GC_OPT 参数设置正确，否	-Xms2G -Xmx4G -XX:NewSize=128M -XX:MaxNewSize=256M -XX:MetaspaceSize=128M -XX:MaxMetaspaceSize=128M -

配置参数	说明	默认值
	则进程启动会失败。 须知 请谨慎修改该项。如果配置不当，将造成服务不可用。	XX:+UseConcMarkSweepGC -XX:+CMSParallelRemarkEnabled -XX:CMSInitiatingOccupancyFraction=65 -XX:+PrintGCDetails -Dsun.rmi.dgc.client.gcInterval=0x7FFFFFFFFFFFFE -Dsun.rmi.dgc.server.gcInterval=0x7FFFFFFFFFFFFE -XX:-OmitStackTraceInFastThrow -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=10 -XX:GCLogFileSize=1M -Djdk.tls.ephemeralDHKeySize=2048

9.3 创建 HDFS 角色

操作场景

该任务指导 MRS 集群管理员在 FusionInsight Manager 创建并设置 HDFS 的角色。HDFS 角色可设置 HDFS 目录或文件的读、写和执行权限。

用户在 HDFS 中对自己创建的目录或文件拥有完整权限，可直接读取、写入以及授权他人访问此 HDFS 目录与文件。

说明

- 安全模式支持创建 HDFS 角色，普通模式不支持创建 HDFS 角色。
- 如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置 HDFS 相关策略进行权限管理，具体操作可参考 20.8 添加 HDFS 的 Ranger 访问权限策略。

前提条件

MRS 集群管理员已明确业务需求。

操作步骤

登录 FusionInsight Manager，选择“系统 > 权限 > 角色”。

步骤 1 单击“添加角色”，然后在“角色名称”和“描述”中输入角色名字与描述。

步骤 2 配置资源权限，请参见表 9-2。

“文件系统”：HDFS 中的目录和文件授权。

HDFS 常见目录如下：

- “flume”：Flume 数据存储目录。

- “hbase”：HBase 数据存储目录。
- “mr-history”：MapReduce 任务信息存储目录。
- “tmp”：临时数据存储目录。
- “user”：用户数据存储目录。

表9-2 设置角色

任务场景	角色授权操作
设置 HDFS 管理员权限	在“配置资源权限”的表格中选择“*待操作集群的名称* > HDFS”，勾选“集群管理操作权限 ”。 说明 设置 HDFS 管理员权限需要重启 HDFS 服务才可生效。
设置用户执行 HDFS 检查和 HDFS 修复的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HDFS > 文件系统”。 2. 定位到指定目录或文件在 HDFS 中保存的位置。 3. 在指定目录或文件的“权限”列，勾选“读”和“执行”。
设置用户读取其他用户的目录或文件的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HDFS > 文件系统”。 2. 定位到指定目录或文件在 HDFS 中保存的位置。 3. 在指定目录或文件的“权限”列，勾选“读”和“执行”。
设置用户在其他用户的文件写入数据的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HDFS > 文件系统”。 2. 定位到指定文件在 HDFS 中保存的位置。 3. 在指定文件的“权限”列，勾选“写”和“执行”。
设置用户在其他用户的目录新建或删除子文件、子目录的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HDFS > 文件系统”。 2. 定位到指定目录在 HDFS 中保存的位置。 3. 在指定目录的“权限”列，勾选“写”和“执行”。
设置用户在其他用户的目录或文件执行的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HDFS > 文件系统”。 2. 定位到指定目录或文件在 HDFS 中保存的位置。 3. 在指定目录或文件的“权限”列，勾选“执行”。
设置子目录继承上级目录权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HDFS > 文件系统”。 2. 定位到指定目录或文件在 HDFS 中保存的位置。 3. 在指定目录或文件的“权限”列，勾选“递归”。

步骤 3 单击“确定”完成，返回“角色”。

----结束

9.4 使用 HDFS 客户端

操作场景

该任务指导用户在运维场景或业务场景中使用 HDFS 客户端。

前提条件

- 已安装客户端。

  例如安装目录为“/opt/client”，以下操作的客户端目录只是举例，请根据实际安装目录修改。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建。安全模式下，“机机”用户需要下载 keytab 文件。“人机”用户第一次登录时需修改密码。（普通模式不涉及）

使用 HDFS 客户端

以客户端安装用户，登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 如果集群为安全模式，执行以下命令进行用户认证。普通模式集群无需执行用户认证。

kinit *组件业务用户*

步骤 4 直接执行 HDFS Shell 命令。例如：

hdfs dfs -ls /

----结束

HDFS 客户端常用命令

常用的 HDFS 客户端命令如下表所示。

表9-3 HDFS 客户端常用命令

命令	说明	样例
hdfs dfs -mkdir *文件夹名*	创建文件夹	**hdfs dfs -mkdir /tmp/mydir**

命令	说明	样例
称		
hdfs dfs -ls *文件夹名称*	查看文件夹	**hdfs dfs -ls /tmp**
hdfs dfs -put *客户端节点上本地文件 HDFS 指定路径*	上传本地文件到 HDFS 指定路径	**hdfs dfs -put /opt/test.txt /tmp** 上传客户端节点“/opt/test.txt”文件到 HDFS 的“/tmp”路径下
hdfs dfs -get *hdfs 指定文件 客户端节点上指定路径*	下载 HDFS 文件到本地指定路径	**hdfs dfs -get /tmp/test.txt /opt/** 下载 HDFS 的“/tmp/test.txt”文件到客户端节点的“/opt”路径下
hdfs dfs -rm -r -f *hdfs 指定文件夹*	删除文件夹	**hdfs dfs -rm -r -f /tmp/mydir**
hdfs dfs -chmod *权限参数 文件目录*	为用户设置 HDFS 目录权限	**hdfs dfs -chmod 700 /tmp/test**

客户端常见使用问题

1. 当执行 HDFS 客户端命令时，客户端程序异常退出，报“java.lang.OutOfMemoryError”的错误。

   这个问题是由于 HDFS 客户端运行时的所需的内存超过了 HDFS 客户端设置的内存上限（默认为 128MB）。可以通过修改“<*客户端安装路径*>/HDFS/component_env”中的“CLIENT_GC_OPTS”来修改 HDFS 客户端的内存上限。例如，需要设置该内存上限为 1GB，则设置：

   ```
   CLIENT_GC_OPTS="-Xmx1G"
   ```

   在修改完后，使用如下命令刷新客户端配置，使之生效：

   source <*客户端安装路径*>**/bigdata_env**

2. 如何设置 HDFS 客户端运行时的日志级别？

   HDFS 客户端运行时的日志是默认输出到 Console 控制台的，其级别默认是 INFO 级别。有的时候为了定位问题，需要开启 DEBUG 级别日志，可以通过导出一个环境变量来设置，命令如下：

   export HADOOP_ROOT_LOGGER=DEBUG,console

   在执行完上面命令后，再执行 HDFS Shell 命令时，即可打印出 DEBUG 级别日志。

   如果想恢复 INFO 级别日志，可执行如下命令：

   export HADOOP_ROOT_LOGGER=INFO,console

3. 如何彻底删除 HDFS 文件？

   由于 HDFS 的回收站机制，一般删除 HDFS 文件后，文件会移动到 HDFS 的回收站中。如果确认文件不再需要并且需要立马释放存储空间，可以继续清理对应的回收站目录（例如：hdfs://hacluster/user/*xxx*/.Trash/Current/*xxx*）。

9.5 使用 distcp 命令

操作场景

distcp 是一种在集群间或集群内部拷贝大量数据的工具。它利用 MapReduce 任务实现大量数据的分布式拷贝。

前提条件

- 已安装 Yarn 客户端或者包括 Yarn 的客户端。例如安装目录为“/opt/client”。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建。安全模式下，“机机”用户需要下载 keytab 文件。“人机”用户第一次登录时需修改密码。（普通模式不涉及）
- 如需在集群间拷贝数据，拷贝数据的集群双方都需要启用集群间拷贝数据功能。

操作步骤

登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 如果集群为安全模式，执行 distcp 命令的用户所属的用户组必须为 **supergroup** 组，且执行以下命令进行用户认证。普通模式集群无需执行用户认证。

kinit *组件业务用户*

步骤 4 直接执行 distcp 命令。例如：

hadoop distcp hdfs://hacluster/source hdfs://hacluster/target

----结束

distcp 常见用法

1. 最常见的 distcp 用法，示例如下：

```
hadoop distcp -numListstatusThreads 40 -update -delete -prbugpaxtq
hdfs:///cluster1/source hdfs:///cluster2/target
```

说明

在上述命令中：

- -numListstatusThreads 指定了 40 个构建被拷贝文件的列表的线程数；
- -update -delete 表示将源位置和目标位置的文件同步，删除掉目标位置多余的文件，注意如果需要增量拷贝文件，请将-delete 删掉；
- -prbugpaxtq 与-update 配合，表示被拷贝文件的状态信息也会被更新；
- hdfs://cluster1/source、hdfs://cluster2/target 分别表示源位置和目标位置。

2. 集群间的数据拷贝，示例如下：

```
hadoop distcp hdfs://cluster1/foo/bar hdfs://cluster2/bar/foo
```

说明

集群 cluster1 和集群 cluster2 之间的网络必须保持互通，且两个集群需要使用相同或兼容的 HDFS 版本。

3. 多个源目录的数据拷贝，示例如下：

```
hadoop distcp hdfs://cluster1/foo/a \
hdfs://cluster1/foo/b \
hdfs://cluster2/bar/foo
```

上面的命令的效果是将集群 cluster1 的文件夹 a、b 拷贝到集群 cluster2 的“/bar/foo”目录下，它的效果等效于下面的命令：

```
hadoop distcp -f hdfs://cluster1/srclist \
hdfs://cluster2/bar/foo
```

其中 srclist 里面的内容如下。注意运行 distcp 命令前，需要将 srclist 文件上传到 HDFS 上。

```
hdfs://cluster1/foo/a
hdfs://cluster1/foo/b
```

4. update 和 overwrite 选项的用法，-update 用于被拷贝的文件在目标位置中不存在，或者更新目标位置中被拷贝文件的内容；-overwrite 用于覆盖在目标位置中已经存在的文件。

不加选项和加两个选项中任一个选项的区别，示例如下：

假设，源位置的文件结构如下：

```
hdfs://cluster1/source/first/1
hdfs://cluster1/source/first/2
hdfs://cluster1/source/second/10
hdfs://cluster1/source/second/20
```

不加选项的命令：

```
hadoop distcp hdfs://cluster1/source/first  hdfs://cluster1/source/second
hdfs://cluster2/target
```

上述命令默认会在目标位置创建文件夹 first、second，所以拷贝结果如下：

```
hdfs://cluster2/target/first/1
hdfs://cluster2/target/first/2
hdfs://cluster2/target/second/10
hdfs://cluster2/target/second/20
```

加两个选项中任一个选项的命令，例如加 update 选项：

```
hadoop distcp -update hdfs://cluster1/source/first
hdfs://cluster1/source/second  hdfs://cluster2/target
```

上述命令只会将源位置的内容拷贝到目标位置，所以拷贝结果如下：

```
hdfs://cluster2/target/1
hdfs://cluster2/target/2
hdfs://cluster2/target/10
hdfs://cluster2/target/20
```

说明

- 如果多个源位置有相同名称的文件，则 distcp 命令会失败。
- 在不使用 update 和 overwrite 选项的情况下，如果被拷贝文件在目标位置中已经存在，则该文件会跳过。

- 在使用 update 选项的情况下，如果被拷贝文件在目标位置中已经存在，但文件内容不同，则目标位置的文件内容会被更新。
- 在使用 overwrite 选项的情况下，如果被拷贝文件在目标位置中已经存在，目标位置的文件依然会被覆盖。

5. 其它命令选项：

表9-4 其他命令选项

选项	描述
-p[rbugpcaxtq]	当同时使用-update 选项时，即使被拷贝文件的内容没有被更新，它的状态信息也会被更新 r：副本数，b：块大小，u：所属用户，g：所属用户组，p：许可，c：校验和类型，a：访问控制，t：时间戳，q：Quota 信息
-i	拷贝过程中忽略失败
-log <logdir>	指定日志路径
-v	指定日志中的额外信息
-m <num_maps>	最大的同时运行的执行拷贝的任务数
-numListstatusThreads	构建被拷贝文件的文件列表时所用的线程数，该选项会提高 distcp 的运行速度
-overwrite	覆盖目标位置的文件
-update	如果源位置和目标位置的文件的大小，校验和不同，则更新目标位置的文件
-append	当同时使用-update 选项时，追加源位置的文件内容到目标位置的文件
-f <urilist_uri>	将<urilist_uri>文件的内容作为需要拷贝的文件列表
-filters	指定一个本地文件，其文件内容是多条正则表达式。当被拷贝的文件与某条正则表达式匹配时，则该文件不会被拷贝
-async	异步运行 distcp 命令
-atomic {-tmp <tmp_dir>}	指定一次原子性的拷贝，可以添加一个临时目录的选项，作为拷贝过程中的暂存目录
-bandwidth	指定每个拷贝任务的传输带宽，单位 MB/s
-delete	删除掉目标位置中存在，但源位置不存在的文件。该选项通常会和-update 配合使用，表示将源位置和目标位置的文件同步，删除掉目标位置多余的文件
-diff <oldSnapshot> <newSnapshot>	将新旧版本之间的差异内容，拷贝到目标位置的旧版本文件中

选项	描述
-skipcrccheck	是否跳过源文件和目标文件之间的 CRC 校验
-strategy {dynamic|uniformsize}	指定拷贝任务的拷贝策略，默认策略是 uniformsize，即每个拷贝任务复制相同的字节数

distcp 常见使用问题

1. 当使用 distcp 命令时，如果某些被拷贝的文件内容较大时，建议修改执行拷贝任务的 mapreduce 的超时时间。可以通过在 distcp 命令中指定 **mapreduce.task.timeout** 选项实现。例如，修改超时时间为 30 分钟，则命令如下：

   ```
   hadoop distcp -Dmapreduce.task.timeout=1800000 hdfs://cluster1/source
   hdfs://cluster2/target
   ```

   您也可以使用选项 filters，不对这种大文件进行拷贝，命令示例如下：

   ```
   hadoop distcp -filters /opt/client/filterfile hdfs://cluster1/source
   hdfs://cluster2/target
   ```

   其中 filterfile 是本地文件，它的内容是多条用于匹配不拷贝文件路径的正则表达式，它的内容示例如下：

   ```
   .*excludeFile1.*
   .*excludeFile2.*
   ```

2. 当使用 distcp 命令时，命令异常退出，报“java.lang.OutOfMemoryError”的错误。

   这个问题的原因是拷贝任务运行时所需的内存超过了客户端设置的内存上限（默认为 128MB）。可以通过修改“*<客户端安装路径>*/HDFS/component_env”中的“CLIENT_GC_OPTS”来修改客户端的内存上限。例如，需要设置该内存上限为 1GB，则设置：

   ```
   CLIENT_GC_OPTS="-Xmx1G"
   ```

   在修改完后，使用如下命令刷新客户端配置，使之生效：

   source *<客户端安装路径>*/**bigdata_env**

3. 使用 dynamic 策略执行 distcp 命令时，命令异常退出，报“Too many chunks created with splitRatio”的错误。

   这个问题的原因是“distcp.dynamic.max.chunks.tolerable”的值（默认值为 20000）小于“distcp.dynamic.split.ratio”的值（默认为 2）乘以 Map 数。即一般出现在 Map 数超过 10000 的情况。可以通过-m 参数降低 Map 数小于 10000：

   ```
   hadoop distcp -strategy dynamic -m 9500 hdfs://cluster1/source
   hdfs://cluster2/target
   ```

   或通过-D 参数指定更大的“distcp.dynamic.max.chunks.tolerable”的值：

   ```
   hadoop distcp -Ddistcp.dynamic.max.chunks.tolerable=30000 -strategy dynamic
   hdfs://cluster1/source hdfs://cluster2/target
   ```

9.6 HDFS 文件系统目录简介

HDFS 文件系统中目录结构如下表所示。

表9-5 HDFS 文件系统目录结构

路径	类型	简略功能	是否可以删除	删除的后果
/tmp/spark2x/sparkhive-scratch	固定目录	存放 Spark2x JDBCServer 中 metastore session 临时文件	否	任务运行失败
/tmp/sparkhive-scratch	固定目录	存放 Spark2x cli 方式运行 metastore session 临时文件	否	任务运行失败
/tmp/logs/	固定目录	存放 container 日志文件	是	container 日志不可查看
/tmp/carbon/	固定目录	数据导入过程中，如果存在异常 CarbonData 数据，则将异常数据放在此目录下	是	错误数据丢失
/tmp/Loader-${作业名}_${MR 作业 id}	临时目录	存放 Loader Hbase bulkload 作业的 region 信息，作业完成后自动删除	否	Loader Hbase Bulkload 作业失败
/tmp/hadoop-omm/yarn/system/rmstore	固定目录	ResourceManager 运行状态信息	是	ResourceManager 重启后状态信息丢失
/tmp/archived	固定目录	MR 任务日志在 HDFS 上的归档路径	是	MR 任务日志丢失
/tmp/hadoop-yarn/staging	固定目录	保存 AM 运行作业运行日志、作业概要信息和作业配置属性	否	任务运行异常
/tmp/hadoop-yarn/staging/history/d	固定	所有任务运行完成后，临时存放/tmp/hadoop-yarn/staging 目	否	MR 任务日志丢失

路径	类型	简略功能	是否可以删除	删除的后果
one_intermediate	目录	录下文件		
/tmp/hadoop-yarn/staging/history/done	固定目录	周期性扫描线程定期将done_intermediate 的日志文件转移到 done 目录	否	MR 任务日志丢失
/tmp/mr-history	固定目录	存储预加载历史记录文件的路径	否	MR 历史任务日志数据丢失
/tmp/hive-scratch	固定目录	Hive 运行时生成的临时数据，如会话信息等	否	当前执行的任务会失败
/user/{user}/.sparkStaging	固定目录	存储 SparkJDBCServer 应用临时文件	否	executor 启动失败
/user/spark2x/jars	固定目录	存放 Spark2x executor 运行依赖包	否	executor 启动失败
/user/loader	固定目录	存放 loader 的作业脏数据以及 HBase 作业数据的临时存储目录	否	HBase 作业失败或者脏数据丢失
/user/loader/etl_dirty_data_dir				
/user/loader/etl_hbase_putlist_tmp				
/user/loader/etl_hbase_tmp				
/user/oozie	固定目录	存放 oozie 运行时需要的依赖库，需用户手动上传	否	oozie 调度失败
/user/mapred/hadoop-mapreduce-*xxx*.tar.gz	固定文件	MR 分布式缓存功能使用的各 jar 包	否	MR 分布式缓存功能无法使用
/user/hive	固	Hive 相关数据存储的默认路	否	用户数据丢失

路径	类型	简略功能	是否可以删除	删除的后果
	定目录	径，包含依赖的 spark lib 包和用户默认表数据存储位置等		
/user/omm-bulkload	临时目录	HBase 批量导入工具临时目录	否	HBase 批量导入任务失败
/user/hbase	临时目录	HBase 批量导入工具临时目录	否	HBase 批量导入任务失败
/spark2xJobHistory2x	固定目录	Spark2x eventlog 数据存储目录	否	HistoryServer 服务不可用，任务运行失败
/flume	固定目录	Flume 采集到 HDFS 文件系统中的数据存储目录	否	Flume 工作异常
/mr-history/tmp	固定目录	MapReduce 作业产生的日志存放位置	是	日志信息丢失
/mr-history/done	固定目录	MR JobHistory Server 管理的日志的存放位置	是	日志信息丢失
/tenant	添加租户时创建	配置租户在 HDFS 中的存储目录，系统默认将自动在“/tenant”目录中以租户名称创建文件夹。例如租户“ta1”，默认 HDFS 存储目录为“tenant/ta1”。第一次创建租户时，系统自动在 HDFS 根目录创建“/tenant”目录。支持自定义存储路径。	否	租户不可用
/apps{1~5}/	固定目录	WebHCat 使用到 Hive 的包的路径	否	执行 WebHCat 任务会失败

路径	类型	简略功能	是否可以删除	删除的后果
/hbase	固定目录	HBase 数据存储目录	否	HBase 用户数据丢失
/hbaseFileStream	固定目录	HFS 文件存储目录	否	HFS 文件丢失，且无法恢复

9.7 更改 DataNode 的存储目录

操作场景

HDFS DataNode 定义的存储目录不正确或 HDFS 的存储规划变化时，MRS 集群管理员需要在 FusionInsight Manager 中修改 DataNode 的存储目录，以保证 HDFS 正常工作。适用于以下场景：

- 更改 DataNode 角色的存储目录，所有 DataNode 实例的存储目录将同步修改。
- 更改 DataNode 单个实例的存储目录，只对单个实例生效，其他节点 DataNode 实例存储目录不变。

对系统的影响

- 更改 DataNode 角色的存储目录需要停止并重新启动 HDFS 服务，集群未完全启动前无法提供服务。
- 更改 DataNode 单个实例的存储目录需要停止并重新启动实例，该节点 DataNode 实例未启动前无法提供服务。
- 服务参数配置如果使用旧的存储目录，需要更新为新目录。

前提条件

- 在各个数据节点准备并安装好新磁盘，并格式化磁盘。
- 规划好新的目录路径，用于保存旧目录中的数据。
- 已安装好 HDFS 客户端。
- 准备好业务用户 **hdfs**。
- 更改 DataNode 单个实例的存储目录时，保持活动的 DataNode 实例数必须大于“dfs.replication”的值。

操作步骤

检查环境

以 **root** 用户登录安装 HDFS 客户端的服务器，执行以下命令配置环境变量。

source *HDFS 客户端安装目录*/**bigdata_env**

步骤 1 如果集群为安全模式，执行以下命令认证用户身份。

kinit hdfs

步骤 2 在 HDFS 客户端执行以下命令，检查 HDFS 根目录下全部目录和文件是否状态正常。

hdfs fsck /

检查 fsck 显示结果：

- 显示如下信息，表示无文件丢失或损坏，执行步骤 4。

  ```
  The filesystem under path '/' is HEALTHY
  ```

- 显示其他信息，表示有文件丢失或损坏，执行步骤 5。

步骤 3 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务”查看 HDFS 的状态“运行状态”是否为“良好”。

- 是，执行步骤 6。
- 否，HDFS 状态不健康，执行步骤 5。

步骤 4 修复 HDFS 异常的具体操作，任务结束。

步骤 5 确定修改 DataNode 的存储目录场景。

- 更改 DataNode 角色的存储目录，执行步骤 7。
- 更改 DataNode 单个实例的存储目录，执行步骤 12。

更改 DataNode 角色的存储目录

选择“集群 > *待操作集群的名称* > 服务 >HDFS > 停止服务”，停止 HDFS 服务。

步骤 6 以 **root** 用户登录到安装 HDFS 服务的各个数据节点中，执行如下操作：

1. 创建目标目录（data1,data2 为集群原有目录）。

   例如目标目录为“${BIGDATA_DATA_HOME}/hadoop/data3/dn”：

   执行 **mkdir -p ${BIGDATA_DATA_HOME}/hadoop/data3/dn**。

2. 挂载目标目录到新磁盘。例如挂载“${BIGDATA_DATA_HOME}/hadoop/data3”到新磁盘。

3. 修改新目录的权限。

   例如新目录路径为“${BIGDATA_DATA_HOME}/hadoop/data3/dn”：

   执行 **chmod 700 ${BIGDATA_DATA_HOME}/hadoop/data3/dn -R** 和 **chown omm:wheel ${BIGDATA_DATA_HOME}/hadoop/data3/dn -R**。

4. 将数据复制到目标目录。

   例如旧目录为“${BIGDATA_DATA_HOME}/hadoop/data1/dn”，目标目录为“${BIGDATA_DATA_HOME}/hadoop/data3/dn”：

执行 **cp -af ${BIGDATA_DATA_HOME}/hadoop/data1/dn/* ${BIGDATA_DATA_HOME}/hadoop/data3/dn**。

步骤 7 在 FusionInsight Manager 管理界面，选择“集群 > *待操作集群的名称* > 服务 > HDFS > 配置 > 全部配置”，打开 HDFS 服务配置页面。

将配置项“dfs.datanode.data.dir”从默认值“%{@auto.detect.datapart.dn}”修改为新的目标目录，例如“${BIGDATA_DATA_HOME}/hadoop/data3/dn”。

例如：原有的数据存储目录为“/srv/BigData/hadoop/data1”，“/srv/BigData/hadoop/data2”，如需将 data1 目录的数据迁移至新建的“/srv/BigData/hadoop/data3”目录，则将服务级别的此参数替换为现有的数据存储目录，如果有多个存储目录，用“,”隔开。则本示例中，为“/srv/BigData/hadoop/data2,/srv/BigData/hadoop/data3”。

步骤 8 单击“保存”。然后在“集群 > *待操作集群的名称* > 服务”界面启动集群中各个停止的服务。

步骤 9 启动 HDFS 成功以后，在 HDFS 客户端执行以下命令，检查 HDFS 根目录下全部目录和文件是否复制正确。

hdfs fsck /

检查 fsck 显示结果：

- 显示如下信息，表示无文件丢失或损坏，数据复制成功，操作结束。

```
The filesystem under path '/' is HEALTHY
```

- 显示其他信息，表示有文件丢失或损坏，则检查 8.4 是否正确，并执行 **hdfs fsck** *损坏的文件名称* **-delete**。

更改 DataNode 单个实例的存储目录

选择“集群 > *待操作集群的名称* > 服务 > HDFS > 实例”，勾选需要修改存储目录的 DataNode 单个实例，选择“更多 > 停止实例”。

步骤 10 以 **root** 用户登录到这个 DataNode 节点，执行如下操作。

1. 创建目标目录。

   例如目标目录为“${BIGDATA_DATA_HOME}/hadoop/data3/dn”：

   执行 **mkdir -p ${BIGDATA_DATA_HOME}/hadoop/data3/dn**。

2. 挂载目标目录到新磁盘。

   例如挂载“${BIGDATA_DATA_HOME}/hadoop/data3”到新磁盘。

3. 修改新目录的权限。

   例如新目录路径为“${BIGDATA_DATA_HOME}/hadoop/data3/dn”：

   执行 **chmod 700 ${BIGDATA_DATA_HOME}/hadoop/data3/dn -R 和 chown omm:wheel ${BIGDATA_DATA_HOME}/hadoop/data3/dn -R**。

4. 将数据复制到目标目录。

   例如旧目录为“${BIGDATA_DATA_HOME}/hadoop/data1/dn”，目标目录为“${BIGDATA_DATA_HOME}/hadoop/data3/dn”：

执行 **cp -af ${BIGDATA_DATA_HOME}/hadoop/data1/dn/* ${BIGDATA_DATA_HOME}/hadoop/data3/dn**。

步骤 11 在 FusionInsight Manager 管理界面，选择“集群 > *待操作集群的名称* > 服务 > HDFS > 实例”，单击指定的 DataNode 实例并切换到“实例配置”页签。

将配置项“dfs.datanode.data.dir”从默认值“%{@auto.detect.datapart.dn}”修改为新的目标目录，例如“${BIGDATA_DATA_HOME}/hadoop/data3/dn”。

示例：原有的数据存储目录为“/srv/BigData/hadoop/data1,/srv/BigData/hadoop/data2”，此处如需将 data1 目录的数据迁移至新建的/srv/BigData/hadoop/data3 目录，则将该参数修改为“/srv/BigData/hadoop/data2,/srv/BigData/hadoop/data3”。

步骤 12 单击“保存”，单击“确定”。

界面提示“操作成功。”，单击“完成”。

步骤 13 选择“更多 > 重启实例”，重启 DataNode 实例。

----结束

9.8 配置 HDFS 目录权限

操作场景

默认情况下，某些 HDFS 的文件目录权限为 777 或者 750，存在安全风险。建议您在安装完成后修改该 HDFS 目录的权限，增加用户的安全性。

操作步骤

在 HDFS 客户端中，使用具有 HDFS 管理员权限的用户，执行如下命令，将“/user”的目录权限进行修改。

此处将权限修改为“1777”，即在权限处增加“1”，表示增加目录的粘性，即只有创建的用户才可以删除此目录。

hdfs dfs -chmod 1777 */user*

为了系统文件的安全，建议用户将非临时目录进行安全加固，例如：

- /user:777
- /mr-history:777
- /mr-history/tmp:777
- /mr-history/done:777
- /user/mapred:755

9.9 配置 NFS

操作场景

用户在部署集群前，可根据需要规划 Network File System（简称 NFS）服务器，用于存储 NameNode 元数据，以提高数据可靠性。

如果您已经部署 NFS 服务器，并已配置 NFS 服务，本操作提供集群侧的配置指导，为可选任务。

操作步骤

在 NFS 服务器上检查 NFS 的共享目录权限，确认服务器可以访问 MRS 集群的 NameNode。

步骤 1 以 **root** 用户登录 NameNode 主节点。

步骤 2 执行如下命令，创建目录并赋予目录写权限。

mkdir ${BIGDATA_DATA_HOME}/namenode-nfs

chown omm:wheel ${BIGDATA_DATA_HOME}/namenode-nfs

chmod 750 ${BIGDATA_DATA_HOME}/namenode-nfs

步骤 3 执行如下命令，挂载 NFS 到 NameNode 主节点。

mount -t nfs -o rsize=8192,wsize=8192,soft,nolock,timeo=3,intr *NFS 服务器 IP 地址:共享目录* **${BIGDATA_DATA_HOME}/namenode-nfs**

例如，NFS 服务器的 IP 为“192.168.0.11”，共享目录为“/opt/Hadoop/NameNode”，则执行命令：

mount -t nfs -o rsize=8192,wsize=8192,soft,nolock,timeo=3,intr 192.168.0.11:/opt/Hadoop/NameNode ${BIGDATA_DATA_HOME}/namenode-nfs

步骤 4 在 NameNode 备节点上执行步骤 2～步骤 4。

说明

主备 NameNode 节点在 NFS 服务器上创建的共享目录名称（如“/opt/Hadoop/NameNode”）不能相同。

步骤 5 登录 FusionInsight Manager 系统，选择“集群 > *待操作集群的名称* > 服务 > HDFS > 配置 > 全部配置”。

步骤 6 在界面右侧的“搜索”框中输入“dfs.namenode.name.dir”搜索，在其值中增加“${BIGDATA_DATA_HOME}/namenode-nfs”路径，多个路径间使用“,”隔开，然后单击“保存”。

步骤 7 单击“确定”。在概览页面选择“更多 > 重启服务”，重启服务。

----结束

9.10 规划 HDFS 容量

HDFS DataNode 以 Block 的形式，保存用户的文件和目录，同时在 NameNode 中生成一个文件对象，对应 DataNode 中每个文件、目录和 Block。

NameNode 文件对象需要占用一定的内存，消耗内存大小随文件对象的生成而线性递增。DataNode 实际保存的文件和目录越多，NameNode 文件对象总量增加，需要消耗更多的内存，使集群现有硬件可能会难以满足业务需求，且导致集群难以扩展。

规划存储大量文件的 HDFS 系统容量，就是规划 NameNode 的容量规格和 DataNode 的容量规格，并根据容量设置参数。

容量规格

- NameNode 容量规格

  在 NameNode 中，每个文件对象对应 DataNode 中的一个文件、目录或 Block。

  一个文件至少占用一个 Block，默认每个 Block 大小为“134217728”即 128MB，对应参数为“dfs.blocksize”。默认情况下一个文件小于 128MB 时，只占用一个 Block；文件大于 128MB 时，占用 Block 数为：文件大小/128MB。目录不占用 Block。

  根据“dfs.blocksize”，NameNode 的文件对象数计算方法如下：

  表9-6 NameNode 文件对象数计算

单个文件大小	文件对象数
小于 128MB	1（对应文件）+1（对应 Block）=2
大于 128MB（例如 128G）	1（对应文件）+1,024（对应 128GB/128MB=1024 Block）=1,025

  主备 NameNode 支持最大文件对象的数量为 300,000,000（最多对应 150,000,000 个小文件）。“dfs.namenode.max.objects”规定当前系统可生成的文件对象数，默认值为“0”表示不限制。

- DataNode 容量规格

  在 HDFS 中，Block 以副本的形式存储在 DataNode 中，默认副本数为“3”，对应参数为“dfs.replication”。

  集群中所有 DataNode 角色实例保存的 Block 总数为：HDFS Block * 3。集群中每个 DataNode 实例平均保存的 Blocks= HDFS Block * 3/DataNode 节点数。

  表9-7 DataNode 支持规格

项目	规格
单个 DataNode 实例支持最大 Block 数	5,000,000
单个 DataNode 实例上单个磁盘支持最大 Block 数	500,000

项目	规格
单个 DataNode 实例支持最大 Block 数需要的最小磁盘数	10

表9-8 DataNode 节点数规划

HDFS Block 数	最少 DataNode 角色实例数
10,000,000	10,000,000 *3/5,000,000 = 6
50,000,000	50,000,000 *3/5,000,000 = 30
100,000,000	100,000,000 *3/5,000,000 = 60

内存参数设置

- NameNode JVM 参数配置规则

  NameNode JVM 参数“GC_OPTS”默认值为：

  -Xms2G -Xmx4G -XX:NewSize=128M -XX:MaxNewSize=256M -XX:MetaspaceSize=128M -XX:MaxMetaspaceSize=128M -XX:+UseConcMarkSweepGC -XX:+CMSParallelRemarkEnabled -XX:CMSInitiatingOccupancyFraction=65 -XX:+PrintGCDetails -Dsun.rmi.dgc.client.gcInterval=0x7FFFFFFFFFFFFE -Dsun.rmi.dgc.server.gcInterval=0x7FFFFFFFFFFFFE -XX:-OmitStackTraceInFastThrow -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=10 -XX:GCLogFileSize=1M -Djdk.tls.ephemeralDHKeySize=3072 -Djdk.tls.rejectClientInitiatedRenegotiation=true -Djava.io.tmpdir=${Bigdata_tmp_dir}

  NameNode 文件数量和 NameNode 使用的内存大小成比例关系，文件对象变化时请修改默认值中的“-Xms2G -Xmx4G -XX:NewSize=128M -XX:MaxNewSize=256M”。参考值如下表所示。

表9-9 NameNode JVM 配置

文件对象数量	参考值
10,000,000	“-Xms6G -Xmx6G -XX:NewSize=512M -XX:MaxNewSize=512M”
20,000,000	“-Xms12G -Xmx12G -XX:NewSize=1G -XX:MaxNewSize=1G”
50,000,000	“-Xms32G -Xmx32G -XX:NewSize=3G -XX:MaxNewSize=3G”
100,000,000	“-Xms64G -Xmx64G -XX:NewSize=6G -XX:MaxNewSize=6G”

文件对象数量	参考值
200,000,000	“-Xms96G -Xmx96G -XX:NewSize=9G -XX:MaxNewSize=9G”
300,000,000	“-Xms164G -Xmx164G -XX:NewSize=12G -XX:MaxNewSize=12G”

- DataNode JVM 参数配置规则

  DataNode JVM 参数“GC_OPTS”默认值为：

  -Xms2G -Xmx4G -XX:NewSize=128M -XX:MaxNewSize=256M -XX:MetaspaceSize=128M -XX:MaxMetaspaceSize=128M -XX:+UseConcMarkSweepGC -XX:+CMSParallelRemarkEnabled -XX:CMSInitiatingOccupancyFraction=65 -XX:+PrintGCDetails -Dsun.rmi.dgc.client.gcInterval=0x7FFFFFFFFFFFFE -Dsun.rmi.dgc.server.gcInterval=0x7FFFFFFFFFFFFE -XX:-OmitStackTraceInFastThrow -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=10 -XX:GCLogFileSize=1M -Djdk.tls.ephemeralDHKeySize=3072 -Djdk.tls.rejectClientInitiatedRenegotiation=true -Djava.io.tmpdir=${Bigdata_tmp_dir}

  集群中每个 DataNode 实例平均保存的 Blocks= HDFS Block * 3/DataNode 节点数，单个 DataNode 实例平均 Block 数量变化时请修改默认值中的“-Xms2G -Xmx4G -XX:NewSize=128M -XX:MaxNewSize=256M”。参考值如下表所示。

表9-10 DataNode JVM 配置

单个 DataNode 实例平均 Block 数量	参考值
2,000,000	“-Xms6G -Xmx6G -XX:NewSize=512M -XX:MaxNewSize=512M”
5,000,000	“-Xms12G -Xmx12G -XX:NewSize=1G -XX:MaxNewSize=1G”

  Xmx 内存值对应 DataNode 节点块数阈值，每 GB 对应 500000 块数，用户可根据需要调整内存值。

查看 HDFS 容量状态

- NameNode 信息

  登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > HDFS > NameNode(主)”，单击“Overview”，查看“Summary”显示的当前 HDFS 文件对象、文件数量、目录数量和 Block 数量信息。

- DataNode 信息

登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > HDFS > NameNode(主)”，单击“DataNodes”，查看所有告警 DataNode 节点的 Block 数量信息。

- 告警信息

  监控 ID 为 14007、14008、14009 的告警是否产生，根据业务需要修改告警阈值。

9.11 设置 HBase 和 HDFS 的 ulimit

现象描述

当打开一个 HDFS 文件时，句柄数限制导出，出现如下错误：

```
IOException (Too many open files)
```

处理步骤

您可以联系集群管理员增加各用户的句柄数。该配置为操作系统的配置，并非 HBase 或者 HDFS 的配置。建议集群管理员根据 HBase 和 HDFS 的业务量及各操作系统用户的权限进行句柄数设置。如果某一个用户需对业务量很大的 HDFS 进行很频繁且很多的操作，则为此用户设置较大的句柄数，避免出现以上错误。

使用 **root** 用户登录集群所有节点机器或者客户端机器的操作系统，并进入“/etc/security”目录。

步骤 1 执行如下命令编辑“limits.conf”文件。

vi limits.conf

新增如下内容：

```
hdfs  -      nofile  32768
hbase -      nofile  32768
```

其中“hdfs”和“hbase”表示业务中用到的操作系统用户名称。

说明

- 只有 **root** 用户有权限编辑“limits.conf”文件。
- 如果修改的配置不生效，请确认“/etc/security/limits.d”目录下是否有针对操作系统用户的其他 nofile 值。这样的值可能会覆盖“/etc/security/limits.conf”中配置的值。
- 如果用户需要对 HBase 进行操作，建议将该用户的句柄数设置为“10000”以上。如果用户需要对 HDFS 进行操作，建议根据业务量大小设置对应的句柄数，建议不要给太小的值。如果用户需要对 HBase 和 HDFS 操作，建议设置较大的值，例如“32768”。

步骤 2 您可以使用如下命令查看某一用户的句柄数限制。

su - *user_name*

ulimit -n

界面会返回此用户的句柄数限制值。如下所示：

```
8194
```

----结束

9.12 配置 HDFS DataNode 数据均衡

操作场景

HDFS 集群可能出现 DataNode 节点间磁盘利用率不平衡的情况，比如集群中添加新数据节点的场景。如果 HDFS 出现数据不平衡的状况，可能导致多种问题，比如 MapReduce 应用程序无法很好地利用本地计算的优势、数据节点之间无法达到更好的网络带宽使用率或节点磁盘无法利用等等。所以 MRS 集群管理员需要定期检查并保持 DataNode 数据平衡。

HDFS 提供了一个容量均衡程序 Balancer。通过运行这个程序，可以使得 HDFS 集群达到一个平衡的状态，使各 DataNode 磁盘使用率与 HDFS 集群磁盘使用率的偏差不超过阈值。图 9-1 和图 9-2 分别是 Balance 前后 DataNode 的磁盘使用率变化。

图9-1 执行均衡操作前 DataNode 的磁盘使用率

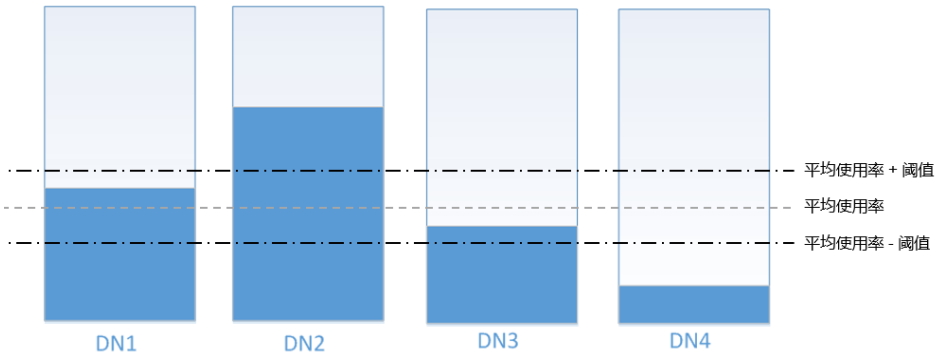

图9-2 执行均衡操作后 DataNode 的磁盘使用率

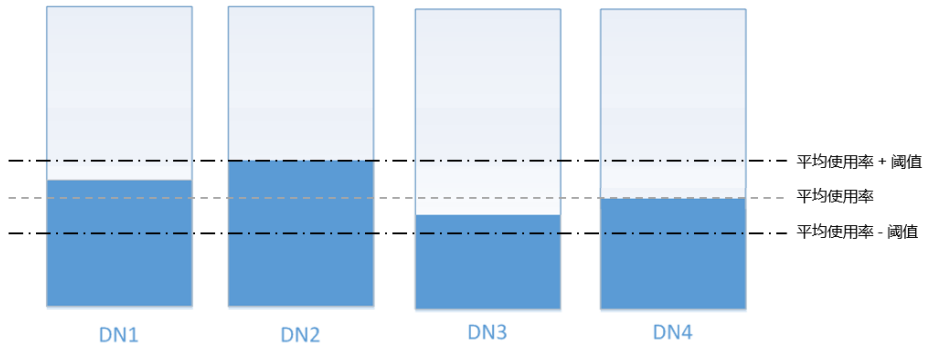

均衡操作时间估算受两个因素影响：

1. 需要迁移的总数据量：

   每个 DataNode 节点的数据量应大于（平均使用率-阈值）*平均数据量，小于（平均使用率+阈值）*平均数据量。若实际数据量小于最小值或大于最大值即存在不平衡，系统选择所有 DataNode 节点中偏差最多的数据量作为迁移的总数据量。

2. Balancer 的迁移是按迭代（iteration）方式串行顺序处理的，每个 iteration 迁移数据量不超过 10GB，每个 iteration 重新计算使用率的情况。

因此针对集群情况，可以大概估算每个 iteration 耗费的时间（可以通过执行 Balancer 的日志观察到每次 iteration 的时间），并用总数据量除以 10GB 估算任务执行时间。

由于按 iteration 处理，Balancer 可以随时启动或者停止。

对系统的影响

- 执行 Balance 操作时会占用 DataNode 的网络带宽资源，请根据业务需求在维护期间执行任务。
- 默认使用带宽控制为 20MB/s，如果重新设置带宽流量或加大数据量，Balance 操作可能会对正在运行的业务产生影响。

前提条件

已安装 HDFS 客户端。

操作步骤

使用客户端安装用户登录客户端所在节点。执行命令切换到客户端安装目录，例如“/opt/client”。

cd /opt/client

说明

如果集群为普通模式，需先执行 **su - omm** 切换为 **omm** 用户。

步骤 1 执行以下命令配置环境变量。

source bigdata_env

步骤 2 如果集群为安全模式，执行以下命令认证 **hdfs** 身份。

kinit hdfs

步骤 3 是否调整带宽控制？

- 是，执行步骤 5。
- 否，执行步骤 6。

步骤 4 执行以下命令，修改 Balance 的最大带宽，然后执行步骤 6。

hdfs dfsadmin -setBalancerBandwidth <*bandwidth in bytes per second*>

<bandwidth in bytes per second>表示带宽控制的数值，单位为字节。例如要设置带宽控制为 20MB/s，对应值为 20971520，完整命令为：

hdfs dfsadmin -setBalancerBandwidth 20971520

说明

- 默认为 20MB/s，适用于当前集群使用万兆网络，且有业务正在执行的场景。若没有足够的业务空闲时间窗用于 Balance 维护，可适当增加该值以缩短 Balance 时间，如增大到 209715200（即 200MB/s）。

- 这个参数的调整要看组网情况，如果集群负载较高，可以改为 209715200(200MB/s)；如果集群空闲，可以改为 1073741824 (1GB/s)。
- 如果 DataNode 节点的带宽无法达到指定的最大带宽，可以在 FusionInsight Manager 修改 HDFS 的参数“dfs.datanode.balance.max.concurrent.moves”，将每个 DataNode 节点执行均衡的线程数修改为“32”，并重启 HDFS 服务。

步骤 5 执行以下命令，启动 Balance 任务。

bash /opt/client/HDFS/hadoop/sbin/start-balancer.sh -threshold <*threshold of* balancer>

-threshold 表示 HDFS 数据达到平衡状态时 DataNode 磁盘使用率偏差值，各个 DataNode 节点磁盘的使用率和整体 HDFS 集群的磁盘空间平均使用率偏差小于此阈值时，系统认为 HDFS 集群已经达到了平衡的状态并结束 Balance 任务。

例如，需要设置偏差率为 5%，则执行：

bash /opt/client/HDFS/hadoop/sbin/start-balancer.sh -threshold 5

说明

- 上述命令会在后台执行该任务，相关日志可以通过客户端安装目录“/opt/client/HDFS/hadoop/logs”下的 hadoop-root-balancer-*主机名*.out 查看。
- 如果需要停止 Balance 任务，请执行以下命令：

  bash /opt/client/HDFS/hadoop/sbin/stop-balancer.sh
- 如果只需要对部分节点进行数据均衡，可以在脚本上加上-include 参数指定要移动的节点。具体参数使用方法，可通过命令行查看。

  例如执行：**bash /opt/client/HDFS/hadoop/sbin/start-balancer.sh -threshold 5 -include** *IP1,IP2,IP3*
- “/opt/client”为客户端安装目录，如果不一致，替换即可。
- 如果该命令执行失败，在日志中看到的错误信息为“Failed to APPEND_FILE /system/balancer.id”，则需要执行如下命令强行删除“/system/balancer.id”，再次执行 **start-balancer.sh** 脚本即可。

  hdfs dfs -rm -f /system/balancer.id

步骤 6 用户在执行了步骤 6 的脚本后，会在客户端安装目录“/opt/client/HDFS/hadoop/logs”目录下生成名为 hadoop-root-balancer-*主机名*.out 日志。打开该日志可以看到如下字段信息：

- Time Stamp：时间戳
- Bytes Already Moved：已经移动的字节数
- Bytes Left To Move：待移动的字节数
- Bytes Being Moved：正在移动的字节数

日志出现“Balancing took *xxx* seconds”信息表示均衡操作已完成。

----结束

相关任务

设置自动执行 Balance 任务

登录 FusionInsight Manager。

步骤 1 选择“集群 > *待操作集群的名称* > 服务 > HDFS > 配置”，选择“全部配置”，搜索以下参数名并修改参数值。

- “dfs.balancer.auto.enable”表示是否启用自动执行 Balance 任务，默认值为“false”表示不启用，修改为“true”表示启用。
- “dfs.balancer.auto.cron.expression”表示任务执行的时间，默认值“0 1 * * 6”表示在每周六的 1 点执行任务。仅在启用自动执行 Balance 功能时有效。

  修改此参数时，表达式介绍如表 9-11 所示。支持“*”表示连续的时间段。

表9-11 执行表达式参数解释

列	说明
第 1 列	分钟，参数值为 0～59。
第 2 列	小时，参数值为 0～23。
第 3 列	日期，参数值为 1～31。
第 4 列	月份，参数值为 1～12。
第 5 列	星期，参数值为 0～6，0 表示星期日。

- “dfs.balancer.auto.stop.cron.expression”表示任务自动停止的时间，默认值为空，表示不自动停止正在运行的 Balancer 任务。以“0 5 * * 6”为例，则表示在每周六的 5 点停止正在运行的 Balancer 任务。仅在启用自动执行 Balance 功能时有效。

  修改此参数时，表达式介绍如表 9-11 所示。支持“*”表示连续的时间段。

步骤 2 修改自动 Balancer 的运行参数，如表 9-12 所示：

表9-12 自动 Balancer 运行参数

参数名	参数介绍	默认值
dfs.balancer.auto.threshold	表示磁盘容量百分比的均衡阈值。仅当 dfs.balancer.auto.enable 设置为 true 时才有效。	10
dfs.balancer.auto.exclude.datanodes	不需要执行磁盘自动均衡的 DataNode 列表，用逗号分隔。仅当 dfs.balancer.auto.enable 设置为 true 时才有效。	默认为空
dfs.balancer.auto.bandwidthPerSec	每个 DataNode 可用于负载均衡的最大带宽量（单位：MB/s）。	20
dfs.balancer.auto.maxIdleIterations	Balancer 的最大连续空闲迭代次数。一次空闲迭代为没有 Block 块被移动的迭代，当连续空闲迭代次数达到最大连续空闲迭代次数时，本次	5

参数名	参数介绍	默认值
	Balancer 结束。当取值为-1 时，代表无穷大。	
dfs.balancer.auto.maxDataNodesNum	该参数用来控制进行自动 Balancer 的 DataNode 数量。假设该参数值为 N，当 N 大于 0， 则选择剩余空间比例最高的 N 个 DataNode 和最低的 N 个 DataNode 之间进行数据均衡；当 N 等于 0， 则对集群中所有 DataNode 进行数据均衡。	5

步骤 3 单击“保存”使配置生效。无需重启 HDFS 服务。

任务执行日志保存在主 NameNode 节点中，请查看“/var/log/Bigdata/hdfs/nn/hadoop-omm-balancer-*主机名*.log”。

----结束

9.13 配置 DataNode 节点间容量异构时的副本放置策略

操作场景

默认情况下，NameNode 会随机选择 DataNode 节点写文件。当集群内某些数据节点的磁盘容量不一致（某些节点的磁盘总容量大，某些总容量小），会导致磁盘总容量小的节点先写满。通过修改集群默认的 DataNode 写数据时的磁盘选择策略为“节点磁盘可用空间块放置策略”，可提高将块数据写到磁盘可用空间较大节点的概率，解决因为数据节点磁盘容量不一致导致的节点使用率不均衡的情况。

对系统的影响

修改磁盘选择策略为“节点磁盘可用空间块放置策略（org.apache.hadoop.hdfs.server.blockmanagement.AvailableSpaceBlockPlacementPolicy）”，经过测试验证，在该测试结果中，修改前后，HDFS 写文件性能影响范围在 3%以内。

说明

NameNode 默认的副本存储策略为：

1. 第一副本：存放到客户端所在节点。
2. 第二副本：远端机架的数据节点。
3. 第三副本：存放到客户端所在节点的相同机架的不同节点。

如还有更多副本，则随机选择其它 DataNode。

“节点磁盘可用空间块放置策略”的副本选择机制为：

1. 第一个副本：存放在客户端所在 DataNode（和默认的存放策略一样）。
2. 第二个副本：

- 选择存储节点的时候，先挑选 2 个满足要求的数据节点。

- 比较这 2 个节点磁盘空间使用比例，如果磁盘空间使用率的相差小于 5%，随机存放到第一个节点。
- 如果磁盘空间使用率相差超过 5%，即有 60%（由 dfs.namenode.available-space-block-placement-policy.balanced-space-preference-fraction 指定，默认值 0.6）的概率写到磁盘空间使用率低的节点。

3. 第三副本等其他后续副本的存储情况，也参考第二个副本的选择方式。

前提条件

集群里 DataNode 节点的磁盘总容量偏差不能超过 100%。

操作步骤

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面。

步骤 1 调整 HDFS 写数据时的依据的磁盘选择策略参数。搜索“dfs.block.replicator.classname”参数，并将参数的值改为“org.apache.hadoop.hdfs.server.blockmanagement.AvailableSpaceBlockPlacementPolicy”。

步骤 2 保存修改的配置。保存完成后请重新启动配置过期的服务或实例以使配置生效。

----结束

9.14 配置 HDFS 单目录文件数量

操作场景

通常一个集群上部署了多个服务，且大部分服务的存储都依赖于 HDFS 文件系统。当集群运行时，不同组件（例如 Spark、Yarn）或客户端可能会向同一个 HDFS 目录不断写入文件。但 HDFS 系统支持的单目录文件数目是有上限的，因此用户需要提前做好规划，防止单个目录下的文件数目超过阈值，导致任务出错。

HDFS 提供了“dfs.namenode.fs-limits.max-directory-items”参数设置单个目录下可以存储的文件数目。

操作步骤

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面。

步骤 1 搜索配置项“dfs.namenode.fs-limits.max-directory-items”。

表9-13 参数说明

参数名称	描述	默认值
dfs.namenode.fs-limits.max-directory-items	定义目录中包含的最大条目数。 取值范围：1～6400000	1048576

步骤 2 设置单个 HDFS 目录下最大可容纳的文件数目。保存修改的配置。保存完成后请重新启动配置过期的服务或实例以使配置生效。

说明

用户尽量将数据做好存储规划，可以按时间、业务类型等分类，不要单个目录下直属的文件过多，建议使用默认值，单个目录下约 100 万条。

----结束

9.15 配置回收站机制

配置场景

在 HDFS 中，删除的文件将被移动到回收站（trash）中，以便在误操作的情况下恢复被删除的数据。

您可以设置文件保留在回收站中的时间阈值，一旦文件保存时间超过此阈值，将从回收站中永久地删除。如果回收站被清空，回收站中的所有文件将被永久删除。

配置描述

在 HDFS 中，如果删除 HDFS 的文件，文件会被保存到 trash 空间中，不会被立即清除。被删除的文件在超过老化时间后将变为老化文件，会基于系统机制清除或用户手动清除。

参数入口：

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-14 参数说明

参数	描述	默认值
fs.trash.interval	以分钟为单位的垃圾回收时间，垃圾站中数据超过此时间，会被删除。取值范围：1440～259200。	1440
fs.trash.checkpoint.interval	垃圾检查点间的间隔。单位：分钟。应小于等于 fs.trash.interval 的值。检查点程序每次运行时都会创建一个新的检查点并会移除 fs.trash.interval 分钟前创建的检查点。例如，系统每 10 分钟检测是否存在老化文件，如果发现有老化文件，则删除。对于未老化文件，则会存储在 checkpoint 列表中，等待下一次检查。 如果此参数的值设置为 0，则表示系统不会检查老化文件，所有老化文件会被保存在系统中。	60

参数	描述	默认值
	取值范围：0～*fs.trash.interval*。 说明 不推荐将此参数值设置为 0，这样系统的老化文件会一直存储下去，导致集群的磁盘空间不足。	

9.16 配置文件和目录的权限

配置场景

HDFS 支持用户进行文件和目录默认权限的修改。HDFS 默认用户创建文件和目录的权限的掩码为“022”，如果默认权限满足不了用户的需求，可以通过配置项进行默认权限的修改。

配置描述

参数入口：

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-15 参数说明

参数	描述	默认值
fs.permissions.umask-mode	当客户端在 HDFS 上创建文件和目录时使用此 umask 值（用户掩码）。类似于 linux 上的文件权限掩码。 可以使用八进制数字也可以使用符号，例如：“022” (八进制，等同于以符号表示的 u=rwx,g=r-x,o=r-x)，或者“u=rwx,g=rwx,o=”(符号法，等同于八进制的“007”)。 说明 8 进制的掩码，和实际权限设置值正好相反，建议使用符号表示法，描述更清晰。	022

9.17 配置 token 的最大存活时间和时间间隔

配置场景

安全模式下，HDFS 中用户可以对 token 的最大存活时间和 token renew 的时间间隔进行灵活地设置，根据集群的具体需求合理地配置。

配置描述

参数入口：

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-16 参数说明

参数	描述	默认值
dfs.namenode.delegation.token.max-lifetime	该参数为服务器端参数，设置 token 的最大存活时间，单位为毫秒。取值范围：10000~10000000000000。	604800000
dfs.namenode.delegation.token.renew-interval	该参数为服务器端参数，设置 token renew 的时间间隔，单位为毫秒。取值范围：10000~10000000000000。	86400000

9.18 配置磁盘坏卷

配置场景

在开源版本中，如果为 DataNode 配置多个数据存放卷，默认情况下其中一个卷损坏，则 DataNode 将不再提供服务。用户可以通过修改配置项“dfs.datanode.failed.volumes.tolerated”的值，指定失败的个数，小于该个数，DataNode 可以继续提供服务。

配置描述

参数入口：

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-17 参数说明

参数	描述	默认值
dfs.datanode.failed.vol	DataNode 停止提供服务前允许失败的卷数。	-1

参数	描述	默认值
umes.tolerated	默认情况下，必须至少有一个有效卷。值-1 表示有效卷的最小值是 1。大于等于 0 的值表示允许失败的卷数。	

9.19 使用安全加密通道

配置场景

安全加密通道是 HDFS 中 RPC 通信的一种加密协议，当用户调用 RPC 时，用户的 login name 会通过 RPC 头部传递给 RPC，之后 RPC 使用 Simple Authentication and Security Layer（SASL）确定一个权限协议（支持 Kerberos 和 DIGEST-MD5 两种），完成 RPC 授权。用户在部署安全集群时，需要使用安全加密通道，配置如下参数。

配置描述

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-18 参数说明

参数	描述	默认值
hadoop.rpc.protection	须知 • 设置后需要重启服务生效，且不支持滚动重启。 • 设置后需要重新下载客户端配置，否则 HDFS 无法提供读写服务。 设置 Hadoop 中各模块的 RPC 通道是否加密。通道包括： • 客户端访问 HDFS 的 RPC 通道。 • HDFS 中各模块间的 RPC 通道，如 DataNode 与 NameNode 间的 RPC 通道。 • 客户端访问 Yarn 的 RPC 通道。 • NodeManager 和 ResourceManager 间的 RPC 通道。 • Spark 访问 Yarn，Spark 访问 HDFS 的 RPC 通道。 • Mapreduce 访问 Yarn，Mapreduce 访问 HDFS 的 RPC 通道。 • HBase 访问 HDFS 的 RPC 通道。 说明 用户可在 HDFS 组件的配置界面中设置该参数的值，设置后全局生效，即 Hadoop 中各模块的 RPC 通道的加密属性全部	• 安全模式：privacy • 普通模式：authentication

参数	描述	默认值
	生效。 对 RPC 的加密方式，有如下三种取值： • “authentication”：普通模式默认值，指数据在鉴权后直接传输，不加密。这种方式能保证性能但存在安全风险。 • “integrity”：指数据直接传输，即不加密也不鉴权。 为保证数据安全，请谨慎使用这种方式。 • “privacy”：安全模式默认值，指数据在鉴权及加密后再传输。这种方式会降低性能。	

9.20 在网络不稳定的情况下，降低客户端运行异常概率

配置场景

在网络不稳定的情况下，调整如下参数，降低客户端应用运行异常概率。

配置描述

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-19 参数说明

参数	描述	默认值
ha.health-monitor.rpc-timeout.ms	zkfc 对 namenode 健康状态检查的超时时间。增大该参数值，可以防止出现双 Active NameNode，降低客户端应用运行异常的概率。 单位：毫秒。取值范围：30000~3600000	180000
ipc.client.connect.max.retries.on.timeouts	客户端与服务端建立 Socket 连接超时时，客户端的重试次数。 取值范围：1~256	45
ipc.client.connect.timeout	客户端与服务端建立 socket 连接的超时时间。增大该参数值，可以增加建立连接的超时时间。 单位：毫秒。取值范围：1~3600000	20000

9.21 配置 NameNode blacklist

配置场景

在现有的缺省 DFSclient failover proxy provider 中，一旦某进程中的一个 NameNode 发生故障，在同一进程中的所有 HDFS client 实例都会尝试再次连接 NameNode，导致应用长时间等待超时。

当位于同一 JVM 进程中的客户端对无法访问的 NameNode 进行连接时，会对系统造成负担。为了避免这种负担，MRS 集群搭载了 NameNode blacklist 功能。

在新的 Blacklisting DFSClient failover provider 中，故障的 NameNode 将被记录至一个列表中。DFSClient 会利用这些信息，防止客户端再次连接这些 NameNode。该功能被称为 NameNode blacklisting。

例如，如下集群配置：

namenode：nn1、nn2

dfs.client.failover.connection.retries：20

单 JVM 中的进程：10 个客户端

在上述集群中，如果当前处于 active 状态的 nn1 无法访问，client1 将会对 nn1 进行 20 次重新连接，之后发生故障转移，client1 将会连接至 nn2。与此相同，client2 至 client10 也会在对 nn1 进行 20 次重新连接后连接至 nn2。这样会延长 NameNode 的整体故障恢复时间。

针对该情况，当 client1 试图连接当前处于 active 状态的 nn1，但其已经发生故障时，nn1 将会被添加至 blacklist。这样其余 client 就不会连接已被添加至 blacklist 的 nn1，而是会选择连接 nn2。

说明

若在任一时刻，所有 NameNode 都被添加至 blacklist，则其内容会被清空，client 会按照初始的 NameNode list 重新尝试连接。若再次出现任何故障，NameNode 仍会被添加至 blacklist。

图9-3 NameNode blacklisting 状态图

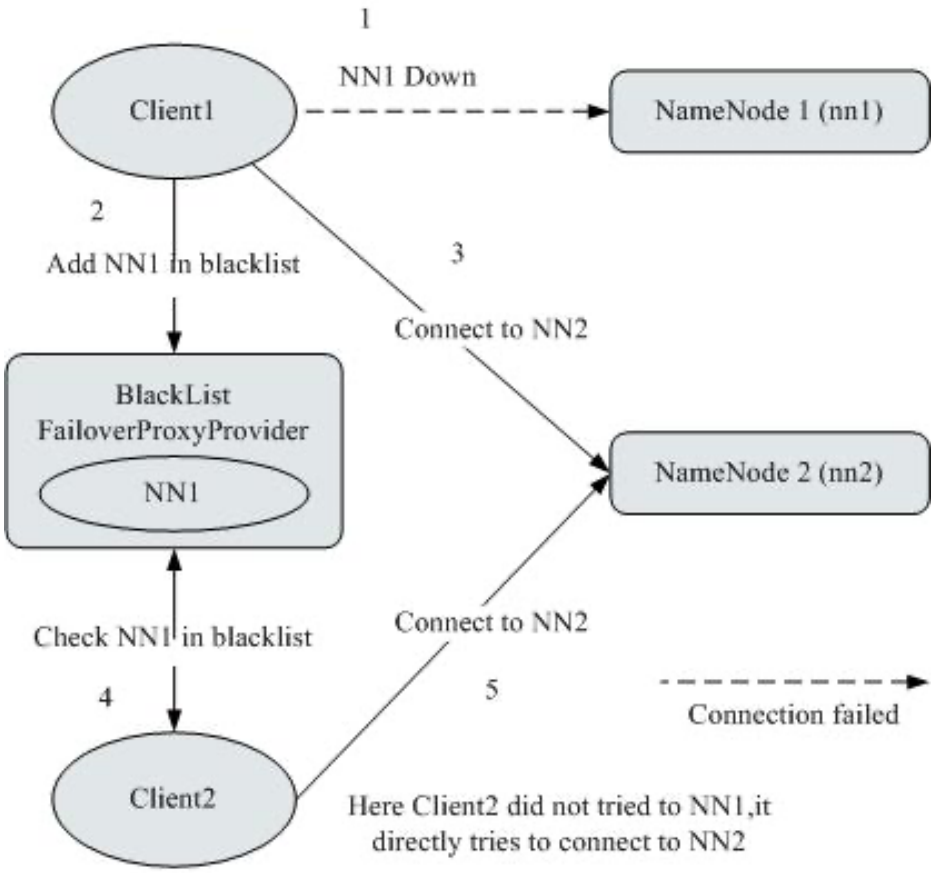

配置描述

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-20 NameNode blacklisting 的相关参数

参数	描述	默认值
dfs.client.failover.proxy.provider.*[nameservice ID]*	利用已通过的协议创建 namenode 代理的 Client Failover proxy provider 类。 将参数值设置为“org.apache.hadoop.hdfs.server.namenode.ha.BlackListingFailoverProxyProvider”， 可使用从 NameNode 支持读的特性。	org.apache.hadoop.hdfs.server.namenode.ha.AdaptiveFailoverProxyProvider

9.22 优化 HDFS NameNode RPC 的服务质量

配置场景

数个成品 Hadoop 集群由于 NameNode 超负荷运行并失去响应而发生故障。

这种阻塞现象是由于 Hadoop 的初始设计造成的。在 Hadoop 中，NameNode 作为单独的机器，在其 namespace 内协调 HDFS 的各种操作。这些操作包括获取数据块位置，列出目录及创建文件。NameNode 接受 HDFS 的操作，将其视作 RPC 调用并置入 FIFO 调用队列，供读取线程处理。虽然 FIFO 在先到先服务的情况下足够公平，但如果用户执行的 I/O 操作较多，相比 I/O 操作较少的用户，将获得更多的服务。在这种情况下，FIFO 有失公平并且会导致延迟增加。

图9-4 基于 FIFO 调用队列的 NameNode 请求处理

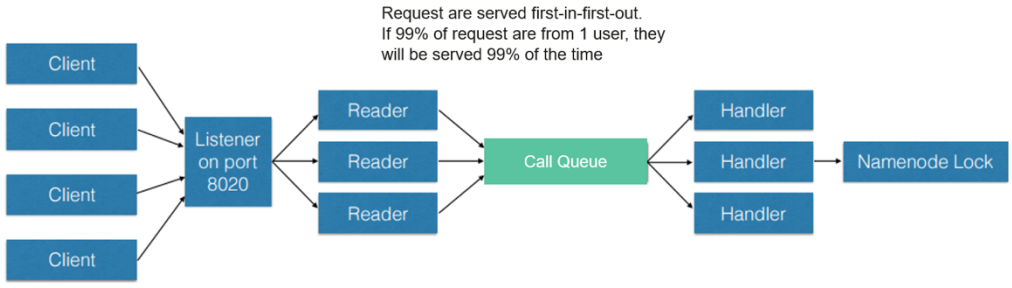

如果将 FIFO 队列替换为一种被称作 FairCallQueue 的新型队列，这种情况就能够得到改善。按照这种方法，FAIR 队列会根据调用者的调用规模将传入的 RPC 调用分配至多个队列中。调度模块会跟踪最新的调用，并为调用量较小的用户分配更高的优先级。

图9-5 基于 FAIRCallQueue 的 NameNode 请求处理

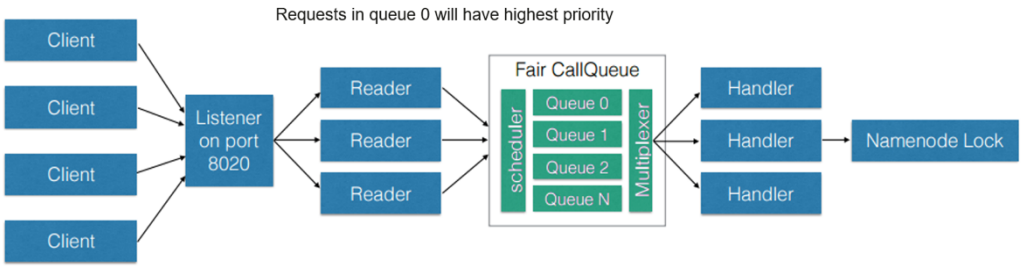

配置描述

- FairCallQueue 通过在内部调整 RPC 调用的顺序确保服务质量。

  该队列由以下三部分组成：

  a. 调度模块（DecayRpcScheduler）用于提供从 0 至 N 的优先值数字（0 的优先级最高）。

b. 多级队列（位于 FairCallQueue 内部）保持调用在内部按优先级排列。

c. 多路转换器（提供有 WeightedRoundRobinMultiplexer）为队列选择提供逻辑控制。

在对 FairCallQueue 进行配置后，由控制模块决定将收到的调用分配至哪个子队列。当前调度模块为 DecayRpcScheduler。该模块仅持续对各类调用的优先级数字进行追踪，并周期性地对这些数字进行减小处理。

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-21 Fair 调用队列参数

参数	描述	默认值
ipc.<*port*>.callqueue.impl	队列的实现类。用户需要通过“org.apache.hadoop.ipc.FairCallQueue”启用 QoS 特性。	java.util.concurrent.LinkedBlockingQueue

- RPC BackOff

  Backoff 是 FairCallQueue 的功能之一，要求客户端在一段时间后重试操作（如创建，删除，打开文件等）。当 Backoff 发生时，RCP 服务器将抛出 RetriableException 异常。FairCallQueue 在以下两种情况时进行 Backoff。

  - 当队列已满，即队列中有许多客户端调用时。
  - 当队列的响应时间大于配置的阈值（由参数“ipc.<port>.decay-scheduler.backoff.responsetime.thresholds”决定）时。

表9-22 RPC BackOff 配置

参数	描述	默认值
ipc.<*port*>.backoff.enable	启用 Backoff 配置参数。当前，如果应用程序中包含较多的用户调用，假设没有达到操作系统的连接限制，则 RPC 请求将处于阻塞状态。或者，当 RPC 或 NameNode 在重负载时，可以基于某些策略将一些明确定义的异常抛回给客户端，客户端将理解这种异常并进行指数回退，以此作为类 RetryInvocationHandler 的另一个实现。	false
ipc.<*port*>.decay-scheduler.backoff.responsetime.enable	根据队列平均响应时间启用 Backoff。	false

参数	描述	默认值
ipc.<*port*>.decay-scheduler.backoff.responsetime.thresholds	配置每个队列的响应时间阈值。ResponseTime 阈值必须与优先级数目（ipc.<port> .faircallqueue.priority-levels）相匹配。单位：毫秒。	10000,20000,30000,40000

说明

- <port>表示在 NameNode 上配置的 RPC 端口。
- 只有在“ipc.<port> .backoff.enable”为“true”时，响应时间 backoff 功能才会起作用。

9.23 优化 HDFS DataNode RPC 的服务质量

配置场景

当客户端写入 HDFS 的速度大于 DataNode 的硬盘带宽时，硬盘带宽会被占满，导致 DataNode 失去响应。客户端只能通过取消或恢复通道进行规避，这会导致写入失败及不必要的通道恢复操作。

配置步骤

引入了新的配置参数“dfs.pipeline.ecn”。当该配置启用时，DataNode 会在写入通道超出负荷时从其中发出信号。客户端可以基于该阻塞信号进行退避，从而防止系统超出负荷。引入该配置参数的目的是为了使通道更加稳定，并减少不必要的取消或恢复操作。收到信号后，客户端会退避一定的时间（5000ms），然后根据相关过滤器调整退避时间（单次退避最长时间为 50000ms）。

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-23 DN ECN 配置

参数	描述	缺省值
dfs.pipeline.ecn	进行该配置后，DataNode 能够向客户端发送阻塞通知。	false

9.24 配置 DataNode 预留磁盘百分比

配置场景

当 YARN 本地目录和 DataNode 目录配置在同一个磁盘时，具有较大容量的磁盘可以运行更多的任务，因此将有更多的中间数据存储在 YARN 本地目录。

目前 DataNode 支持通过配置“dfs.datanode.du.reserved”来配置预留磁盘空间大小。配置较小的数值不能满足更大的磁盘要求。但对于更小的磁盘配置更大的数值将浪费大量的空间。

为了避免这种情况，添加一个新的参数“dfs.datanode.du.reserved.percentage”来配置预留磁盘空间占总磁盘空间大小的百分比，那样可以基于总的磁盘空间来预留磁盘百分比。

说明

- 如果用户同时配置“dfs.datanode.du.reserved.percentage”和“dfs.datanode.du.reserved”，则采用这两个参数较大的数值作为 DataNode 的预留空间大小。
- 建议基于磁盘空间设置“dfs.datanode.du.reserved”或者“dfs.datanode.du.reserved.percentage”。

配置描述

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-24 参数描述

参数	描述	默认值
dfs.datanode.du.reserved.percentage	DataNode 预留空间占总磁盘空间大小的百分比。DataNode 会永久预留由此百分比计算得出的磁盘空间大小。 整数值，取值范围是 0～100。	10

9.25 配置 HDFS NodeLabel

配置场景

用户需要通过数据特征灵活配置 HDFS 文件数据块的存储节点。通过设置 HDFS 目录/文件对应一个标签表达式，同时设置每个 Datanode 对应一个或多个标签，从而给文件的数据块存储指定了特定范围的 Datanode。

当使用基于标签的数据块摆放策略，为指定的文件选择 DataNode 节点进行存放时，会根据文件的标签表达式选择出 Datanode 节点范围，然后在这些 Datanode 节点范围内，选择出合适的存放节点。

说明

开启单集群跨 AZ 高可用后，不支持配置 HDFS NodeLabel 功能。

- 场景 1 DataNodes 分区场景。

  场景说明：

  用户需要让不同的应用数据运行在不同的节点，分开管理，就可以通过标签表达式，来实现不同业务的分离，指定业务存放到对应的节点上。

  通过配置 NodeLabel 特性使得：

  - /HBase 下的数据存储在 DN1、DN2、DN3、DN4 节点上。
  - /Spark 下的数据存储在 DN5、DN6、DN7、DN8 节点上。

  图9-6 DataNode 分区场景

说明

- 通过 **hdfs nodelabel -setLabelExpression -expression 'LabelA[fallback=NONE]' -path /Hbase** 命令，给 Hbase 目录设置表达式。从图 9-6 中可知，“/Hbase”文件的数据块副本会被放置在有 LabelA 标签的节点上，即 DN1、DN2、DN3、DN4。同理，通过 **hdfs nodelabel -setLabelExpression -expression 'LabelB[fallback=NONE]' -path /Spark** 命令，给 Spark 目录设置表达式。在“/Spark”目录下文件对应的数据块副本只能放置到 LabelB 标签上的节点，如 DN5、DN6、DN7、DN8。
- 设置数据节点的标签参考配置描述。
- 如果同一个集群上存在多个机架，每个标签下需要有多个机架的 datanodes，以确保数据块摆放的可靠性。

- 场景 2 多机架下指定副本位置场景

  场景说明：

  在异构集群中，客户需要分配一些特定的具有高可靠性的节点用以存放重要的商业数据，可以通过标签表达式指定副本位置，指定文件数据块的其中一个副本存放到高可靠性的节点上。

  “/data”目录下的数据块，默认三副本情况下，其中至少有一个副本会被存放到 RACK1 或 RACK2 机架的节点上（RACK1 和 RACK2 机架的节点为高可靠性节点），另外两个副本会被分别存放到 RACK3 和 RACK4 机架的节点上。

图9-7 场景样例

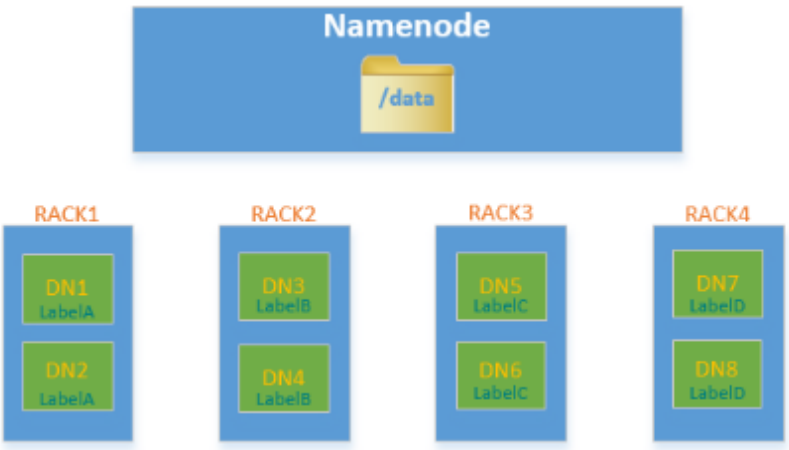

说明

通过 **hdfs nodelabel -setLabelExpression -expression 'LabelA||LabelB[fallback=NONE],LabelC,LabelD' -path /data** 命令给“/data”目录设置表达式。

当向“/data”目录下写数据时，至少有一个数据块副本存放在 LabelA 或者 LabelB 标签的节点中，剩余的两个数据块副本会被存放在有 LabelC 和 LabelD 标签的节点上。

配置描述

- Datanode 节点标签配置

  请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-25 参数说明

参数	描述	默认值
dfs.block.replicator.classname	配置 HDFS 的 DataNode 原则策略。 如果需要开启 NodeLabeNodel 功能，需要将该值设置为 org.apache.hadoop.hdfs.server.blockmanagement.BlockPlacementPolicyWithNodeLabel。	org.apache.hadoop.hdfs.server.blockmanagement.AvailableSpaceBlockPlacementPolicy
host2tags	配置 DataNode 主机与标签的对应关系。 主机名称支持配置 IP 扩展表达式（如 192.168.1.[1-128]或者 192.168.[2-3].[1-128]，且 IP 必须为业务 IP），或者为前后加上 / 的主机名的正则表达式（如 /datanode-[123]/或者/datanode-\d{2}/）。标签配置名称不允许包含 =/\ 字符。【注意】配置 IP 时必须是业务 IP。	-

说明

- host2tags 配置项内容详细说明：

  假如有一套集群，有 20 个 Datanode：dn-1 到 dn-20，对应的 IP 地址为 10.1.120.1 到 10.1.120.20，host2tags 配置文件内容可以使用如下的表示方式。

  主机名正则表达式

  “/dn-\d/ = label-1”表示 dn-1 到 dn-9 对应的标签为 label-1，即 dn-1 = label-1，dn-2 = label-1，...dn-9 = label-1。

  “/dn-((1[0-9]$)|(20$))/ = label-2”表示 dn-10 到 dn-20 对应的标签为 label-2，即 dn-10 = label-2，dn-11 = label-2，...dn-20 = label-2。

  IP 地址范围表示方式

  “10.1.120.[1-9] = label-1”表示 10.1.120.1 到 10.1.120.9 对应的标签为 label-1，即 10.1.120.1 = label-1，10.1.120.2 = label-1，...10.1.120.9 = label-1。

  “10.1.120.[10-20] = label-2”表示 10.1.120.10 到 10.1.120.20 对应的标签为 label-2，即 10.1.120.10 = label-2，10.1.120.11 = label-2，...10.1.120.20 = label-2。

- 基于标签的数据块摆放策略支持扩容减容场景：

  当集群中新增加 DataNode 节点时，如果该 DataNode 对应的 IP 匹配 **host2tags** 配置项中的 IP 地址范围，或者该 DataNode 的主机名匹配 **host2tags** 配置项中的主机名正则表达式，则该 DataNode 节点会被设置成对应的标签。

  例如“host2tags”配置值为 10.1.120.[1-9] = label-1，而当前集群只有 10.1.120.1 到 10.1.120.3 三个数据节点。进行扩容后，又添加了 10.1.120.4 这个数据节点，则该数据节点会被设置成 label-1 的标签；如果 10.1.120.3 这个数据节点被删除或者退出服务后，数据块不会再被分配到该节点上。

- 设置目录/文件的标签表达式
  - 在 HDFS 参数配置页面配置“path2expression”，配置 HDFS 目录与标签的对应关系。当配置的 HDFS 目录不存在时，也可以配置成功，新建不存在的同名目录，已设置的标签对应关系将在 30 分钟之内被继承。设置了标签的目录被删除后，新增一个同名目录，原有的对应关系也将在 30 分钟之内被继承。
  - 命令行设置方式请参考 **hdfs nodelabel -setLabelExpression** 命令。
  - Java API 设置方式通过 NodeLabelFileSystem 实例化对象调用 setLabelExpression(String src, String labelExpression)方法。*src* 为 HDFS 上的目录或文件路径，“labelExpression”为标签表达式。
- 开启 NodeLabel 特性后，可以通过命令 **hdfs nodelabel -listNodeLabels** 查看每个 Datanode 的标签信息。

块副本位置选择

Nodelabel 支持对各个副本的摆放采用不同的策略，如表达式“label-1,label-2,label-3”，表示 3 个副本分别放到含有 label-1、label-2、label-3 的 DataNode 中，不同的副本策略用逗号分隔。

如果 label-1，希望放 2 个副本，可以这样设置表达式：“label-1[replica=2],label-2,label-3”。这种情况下，如果默认副本数是 3，则会选择 2 个带有 label-1 和一个 label-2 的节点；如果默认副本数是 4，会选择 2 个带有 label-1、一个 label-2 以及一个 label-3 的节点。可以注意到，副本数是从左到右依次满足各个副本策略的，但也有副本数超过表达式表述的情况，当默认副本数为 5 时，多出来的一个副本会放到最后一个节点中，也就是 label-3 的节点里。

当启用 ACLs 功能并且用户无权访问表达式中使用的标签时，将不会为副本选择属于该标签的 DataNode。

多余块副本删除选择

如果块副本数超过参数“dfs.replication”值（即用户指定的文件副本数），hdfs 会删除多余块副本来保证集群资源利用率。

删除规则如下：

- 优先删除不满足任何表达式的副本。

  示例：文件默认副本数为 3

  /test 标签表达式为“LA[replica=1],LB[replica=1],LC[replica=1]”，

  /test 文件副本分布的四个节点（D1～D4）以及对应标签（LA～LD）：

  ```
  D1:LA
  D2:LB
  D3:LC
  D4:LD
  ```

  则选择删除 D4 节点上的副本块。
- 如果所有副本都满足表达式，删除多于表达式指定的数量的副本。

  示例：文件默认副本数为 3

  /test 标签表达式为“LA[replica=1],LB[replica=1],LC[replica=1]”，

  /test 文件副本分布的四个节点以及对应标签：

  ```
  D1:LA
  D2:LA
  D3:LB
  D4:LC
  ```

  则选择删除 D1 或者 D2 上的副本块。
- 如果文件所有者或文件所有者的组不能访问某个标签，则优先删除映射到该标签的 DataNode 中的副本。

基于标签的数据块摆放策略样例

假如有一套集群，有六个 DataNode：dn-1，dn-2，dn-3，dn-4，dn-5 以及 dn-6，对应的 IP 为 10.1.120.[1-6]。有六个目录需要配置标签表达式，Block 默认备份数为 3。

- 下面给出 3 种 DataNode 标签信息在“host2labels”文件中的表示方式，其作用是一样的。
  - 主机名正则表达式

    ```
    /dn-[1456]/ = label-1,label-2
    /dn-[26]/ = label-1,label-3
    /dn-[3456]/ = label-1,label-4
    /dn-5/ = label-5
    ```
  - IP 地址范围表示方式

    ```
    10.1.120.[1-6] = label-1
    10.1.120.1 = label-2
    10.1.120.2 = label-3
    ```

```
10.1.120.[3-6] = label-4
10.1.120.[4-6] = label-2
10.1.120.5 = label-5
10.1.120.6 = label-3
```

- 普通的主机名表达式

```
/dn-1/ = label-1, label-2
/dn-2/ = label-1, label-3
/dn-3/ = label-1, label-4
/dn-4/ = label-1, label-2, label-4
/dn-5/ = label-1, label-2, label-4, label-5
/dn-6/ = label-1, label-2, label-3, label-4
```

- 目录的标签表达式设置结果如下：

```
/dir1 = label-1
/dir2 = label-1 && label-3
/dir3 = label-2 || label-4[replica=2]
/dir4 = (label-2 || label-3) && label-4
/dir5 = !label-1
/sdir2.txt = label-1 && label-3[replica=3,fallback=NONE]
/dir6 = label-4[replica=2],label-2
```

说明

标签表达式设置方式请参考 **hdfs nodelabel -setLabelExpression** 命令。

文件的数据块存放结果如下：

- “/dir1”目录下文件的数据块可存放在 dn-1，dn-2，dn-3，dn-4，dn-5 和 dn-6 六个节点中的任意一个。
- “/dir2”目录下文件的数据块可存放在 dn-2 和 dn-6 节点上。Block 默认备份数为 3，表达式只匹配了两个 DataNode 节点，第三个副本会在集群上剩余的节点中选择一个 DataNode 节点存放。
- “/dir3”目录下文件的数据块可存放在 dn-1，dn-3，dn-4，dn-5 和 dn-6 中的任意三个节点上。
- “/dir4”目录下文件的数据块可存放在 dn-4，dn-5 和 dn-6。
- “/dir5”目录下文件的数据块没有匹配到任何一个 DataNode，会从整个集群中任意选择三个节点存放（和默认选块策略行为一致）。
- “/sdir2.txt”文件的数据块，两个副本存放在 dn-2 和 dn-6 节点上，虽然还缺失一个备份节点，但由于使用了 fallback=NONE 参数，所以只存放两个备份。
- “/dir6”目录下文件的数据块在具备 label-4 的节点中选择 2 个节点(dn-3 -- dn-6)，然后在 label-2 中选择一个节点，如果用户指定“/dir6”下文件副本数大于 3，则多出来的副本均在 label-2。

使用限制

配置文件中，“key”、“value”是以“=”、“：”及空白字符作为分隔的。因此，“key”对应的主机名中间请勿包含以上字符，否则会被误认为分隔符。

9.26 配置 HDFS Mover

配置场景

Mover 是一个新的数据迁移工具，工作方式与 HDFS 的 Balancer 接口工作方式类似。Mover 能够基于设置的数据存储策略，将集群中的数据重新分布。

通过运行 Mover，周期性地检测 HDFS 文件系统中用户指定的 HDFS 文件或目录，判断该文件或目录是否满足设置的存储策略，如果不满足，则进行数据迁移，使目标目录或文件满足设定的存储策略。

配置描述

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-26 参数说明

参数	描述	默认值
dfs.mover.auto.enable	是否开启数据副本迁移功能，该功能支持多种。默认值为“false”，表示关闭该特性。	false
dfs.mover.auto.cron.expression	HDFS 执行自动数据迁移的 CRON 表达式，用于控制数据迁移操作的开始时间。仅当 dfs.mover.auto.enable 设置为 true 时才有效。默认值“0 * * * *”表示在每个整点执行任务。表达式的具体含义可参见表 9-27。	0 * * * *
dfs.mover.auto.hdfsfiles_or_dirs	指定集群执行自动副本迁移的 HDFS 文件或目录列表，以空格分隔。仅当 dfs.mover.auto.enable 设置为 true 时才有效。	-

表9-27 Cron 表达式解释

列	说明
第 1 列	分钟，参数值为 0~59。
第 2 列	小时，参数值为 0~23。
第 3 列	日期，参数值为 1~31。
第 4 列	月份，参数值为 1~12。
第 5 列	星期，参数值为 0~6，0 表示星期日。

使用限制

若要在 HDFS 的客户端通过命令行执行 mover 功能，其命令格式如下：

hdfs mover -p <*HDFS 文件全路径或目录路径*>

说明

在客户端执行此命令时，用户需要具备 supergroup 权限。可以使用 HDFS 服务的系统用户 hdfs。或者在集群上创建一个具有 supergroup 权限的用户，再在客户端中执行此命令。

9.27 使用 HDFS AZ Mover

操作场景

AZ Mover 是一个副本迁移工具，用来移动副本以满足目录上设置的新 AZ 策略。它可以用来从一个 AZ 策略迁移到另一个 AZ 策略，AZ Mover 通过指示 NameNode 按照新的 AZ 策略来移动副本，如果 NameNode 拒绝删除旧副本就不能保证一定能满足新的策略，例如副本被标记为过时等原因。

使用限制

- 将策略更改为 LOCAL_AZ 与更改为 ONE_AZ 相同，因为上传文件写入时无法确定写入期间的客户端位置。
- Mover 无法确定 AZ 的状态，因此可能会导致将副本移动到异常的 AZ，并依赖 NameNode 来进一步处理。
- Mover 依赖于每个 AZ 的 DataNode 节点数达到最小要求，如果在一个 DataNode 节点数很少的 AZ 执行，可能会导致与预期不同的结果。
- Mover 只满足 AZ 级别的策略，并不保证满足基本 BPP。
- Mover 不支持更改复制因子，新旧 AZ 策略之间的副本计数差异会导致异常结果。

操作步骤

执行以下命令，切换到客户端安装目录。例如客户端安装目录为“/opt/client”。

cd /opt/client

步骤 1 执行以下命令配置环境变量。

source bigdata_env

步骤 2 如果集群为安全模式，执行的用户需要源目录或文件读权限，目的目录有写权限，且执行以下命令进行用户认证。普通模式集群无需执行用户认证。

kinit *组件业务用户*

步骤 3 创建目录并设置 AZ 策略。

执行以下命令创建目录：

hdfs dfs -mkdir <*path*>

执行以下命令设置 AZ 策略，azexpression 代表 AZ 策略：

hdfs dfsadmin -setAZExpression <*path*> <*azexpression*>

执行以下命令查看 AZ 策略：

hdfs dfsadmin -getAZExpression <*path*>

步骤 4 在目录中上传文件。

hdfs dfs -put <*localfile***> <***hdfs-path***>**

步骤 5 删除目录上的旧策略，再设置一个新的策略。

执行以下命令清楚旧策略：

hdfs dfsadmin -clearAZExpression <*path***>**

执行以下命令设置新策略：

hdfs dfsadmin -setAZExpression <*path***> <***azexpression***>**

步骤 6 执行 **azmover** 命令，使副本分布满足新的 AZ 策略。

hdfs azmover -p /targetDirecotry

----结束

9.28 配置 HDFS DiskBalancer

配置场景

DiskBalancer 是一个在线磁盘均衡器，旨在根据各种指标重新平衡正在运行的 DataNode 上的磁盘数据。工作方式与 HDFS 的 Balancer 工具类似。不同的是，HDFS Balancer 工具用于 DataNode 节点间的数据均衡，而 HDFS DiskBalancer 用于单个 DataNode 节点上各磁盘之间的数据均衡。

长时间运行的集群会因为曾经删除过大量的文件，或者集群中的节点做磁盘扩容等操作导致节点上出现磁盘间数据不均衡的现象。磁盘间数据不均衡会引起 HDFS 整体并发读写性能的下降或者因为不恰当的 HDFS 写策略导致业务故障。此时需要平衡节点磁盘间的数据密度，防止异构的小磁盘成为该节点的性能瓶颈。

配置描述

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面，在搜索框中输入参数名称。

表9-28 参数说明

参数	描述	默认值
dfs.disk.balancer.auto.enabled	是否开启自动执行 HDFS diskbalancer 特性。默认值为“false”，表示关闭该特性。	false

参数	描述	默认值
dfs.disk.balancer.auto.cron.expression	HDFS 磁盘均衡操作的 CRON 表达式，用于控制均衡操作的开始时间。仅当 dfs.disk.balancer.auto.enabled 设置为 true 时才有效。默认值“0 1 * * 6”表示在每周六的 1 点执行任务。表达式的具体含义可参见表 9-29。默认值表示每周六一点执行。	0 1 * * 6
dfs.disk.balancer.max.disk.throughputInMBperSec	执行磁盘数据均衡时可使用的最大磁盘带宽。单位为 MB/s，默认值为 10，可依据集群的实际磁盘条件设置。	10
dfs.disk.balancer.max.disk.errors	设置能够容忍的在指定的移动过程中出现的最大错误次数，超过此阈值则移动失败。	5
dfs.disk.balancer.block.tolerance.percent	设置磁盘之间进行数据均衡操作时，各个磁盘的数据存储量与理想状态之间的差异阈值。例如，各个磁盘的理想数据存储量为 1TB，此参数设置为 10。那么，当目标磁盘的数据存储量达到 900GB 时，就认为该磁盘的存储状态就已经足够好了。取值范围[1-100]。	10
dfs.disk.balancer.plan.threshold.percent	设置在磁盘数据均衡中可容忍的两磁盘之间的数据密度阈值差。如果任意两个磁盘数据密度差值的绝对值超过了此阈值，意味着对应的磁盘应该进行数据均衡。取值范围[1-100]。	10
dfs.disk.balancer.top.nodes.number	该参数用来指定集群中需要执行磁盘数据均衡的 Top N 节点。	5

使用此功能时，需要先将参数 dfs.disk.balancer.auto.enabled 设置为 true，并配置合理的 CRON 表达式。其它参数依据集群状况设置。

表9-29 CRON 表达式解释

列	说明
第 1 列	分钟，参数值为 0~59。
第 2 列	小时，参数值为 0~23。
第 3 列	日期，参数值为 1~31。
第 4 列	月份，参数值为 1~12。
第 5 列	星期，参数值为 0~6，0 表示星期日。

使用限制

1. 只支持同类型磁盘之间的数据移动，例如 SSD->SSD，DISK->DISK 等。
2. 执行该特性会占用涉及节点的磁盘 IO 资源、网络带宽资源，请尽量在业务不繁忙的时候使用。
3. 参数 dfs.disk.balancer.top.nodes.number 指定 Top N 节点返回的 DataNode 列表是不断重新计算的，因此不必设置的过大。
4. 如果要在 HDFS 客户端通过命令行使用 DiskBalancer 功能，其接口如下：

表9-30 DiskBalancer 功能的接口说明

命令格式	说明
hdfs diskbalancer -report -top <N>	N 可以指定为大于 0 的整数，先利用此条命令查询集群中最需要执行磁盘数据均衡的 Top N 节点。
hdfs diskbalancer -plan <Hostname| IP Address>	此条命令可以根据传入的 DN 生成一个 Json 文件，该文件包含了数据移动的源磁盘、目标磁盘、待移动的块等信息。同时，该命令还支持指定一些其他网络带宽参数等。
hdfs diskbalancer -query <Hostname:$dfs.datanode.ipc.port>	集群默认的 port 值为 9867。此条命令可以查询当前节点上运行的 DiskBalancer 任务的运行状态。
hdfs diskbalancer -execute <planfile>	此命令中的 planfile 指的是第二条命令中生成的 Json 文件，请使用绝对路径。
hdfs diskbalancer -cancel <planfile>	取消正在运行的 planfile，同样需要使用绝对路径。

说明

- 在客户端执行此命令时，用户需要具备 supergroup 权限。可以使用 HDFS 服务的系统用户 hdfs。或者在集群上创建一个具有 supergroup 权限的用户，再在客户端中执行此命令。
- 表 9-30 只说明了命令接口的含义及使用方法，实际每个接口提供了更多的配置参数。具体信息可通过"hdfs diskbalancer -help <command>"命令查看。
- 在集群运维过程中，排查性能类问题时。可查看集群的事件信息中是否有 HDFS 磁盘均衡任务事件发生，如果有的话。可以排查集群中是否开启了 DiskBalancer。
- 自动执行磁盘均衡的特性开启以后，会在此次数据均衡执行完成之后才会退出。无法在执行均衡中途取消本次执行任务。
- 如果想要灵活选择某些指定节点进行数据均衡，可以在客户端手动指定执行。

9.29 配置从 NameNode 支持读

配置场景

在配置了 HA 的 HDFS 集群中，存在一个主 NameNode 和一个备 NameNode。主 NameNode 处理所有的客户端请求，备 NameNode 保持最新的元数据信息和块位置信息。但是在这种架构存在一个缺点：主 NameNode 会成为客户端请求处理的瓶颈，在请求繁忙的集群中表现更为明显。

为了解决主 NameNode 的瓶颈问题，引入了一个新状态的 NameNode：从 NameNode。从 NameNode 类似于备 NameNode，也保持着最新的元数据信息和块位置信息。除此之外，从 NameNode 也可以像主 NameNode 一样处理客户端的读请求。由于在典型的 HDFS 集群中，读请求占大多数，因此从 NameNode 支持读可以降低主 NameNode 的负载，提高集群处理能力。

对系统的影响

- 配置从 NameNode 支持读可以降低主 NameNode 的负载，提高 HDFS 集群的处理能力，尤其是在大集群下效果明显。
- 配置从 NameNode 支持读需要更新客户端应用配置。

前提条件

- 已安装 HDFS 集群，主备 NameNode 正常，HDFS 服务正常。
- 规划安装从 NameNode 的节点已经创建“${BIGDATA_DATA_HOME}/namenode”分区。

操作步骤

以配置 hacluster 的从 NameNode 支持读为例来说明，如果集群中有多对 NameService，且都在使用，可参考如下步骤为每对 NameService 配置从 NameNode 支持读。

登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > *待操作集群的名称* > 服务 > HDFS > 管理 NameService”。

步骤 2 单击 hacluster 后的“添加”按钮。

步骤 3 在添加 NameNode 页面，“NameNode 类型”选择“从”，单击“下一步”。

步骤 4 在分配角色页面，选择已规划的主机，添加从 NameNode，单击“下一步”。

说明

每对 NameService 最多可添加 5 个从 NameNode。

步骤 5 在配置页面，按照规划配置 NameNode 的存储目录、端口等信息，单击“下一步”。

步骤 6 确认信息无误，单击“提交”，等待从 NameNode 安装完成。

重启依赖 HDFS 的上层组件，更新客户端应用配置，重启客户端应用。

----结束

9.30 使用 HDFS 文件并发操作命令

操作场景

集群内并发修改文件和目录的权限及访问控制的工具。

对系统的影响

因为集群内使用文件并发修改命令会对集群性能造成较大负担，所以在集群空闲时使用文件并发操作命令。

前提条件

- 已安装 HDFS 客户端或者包括 HDFS 的客户端。例如安装目录为“/opt/client”。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建。安全模式下，“机机”用户需要下载 keytab 文件。“人机”用户第一次登录时需修改密码（普通模式不涉及）。

操作步骤

以客户端安装用户，登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 如果集群为安全模式，执行的用户所属的用户组必须为 **supergroup** 组，且执行以下命令进行用户认证。普通模式集群无需执行用户认证。

kinit *组件业务用户*

步骤 4 增大客户端的 JVM 大小，防止 OOM，方法如下。（1 亿文件建议 **32G**）

说明

若执行 HDFS 客户端命令时，客户端程序异常退出，并且报“java.lang.OutOfMomeryError”错误。

这个问题是由于 HDFS 客户端运行时的所需的内存超过了 HDFS 客户端设置的内存上限（默认 128M）。可通过修改“*<客户端安装路径>*/HDFS/component_env”中的“CLIENT_GC_OPTS”来修改 HDFS 客户端的内存上限。例如，需要设置内存上限为 1GB，则设置：

CLIENT_GC_OPTS="-Xmx1G"

在修改完后，使用如下命令刷新客户端配置，使之生效;

source *<客户端安装路径>*/**bigdata_env**

步骤 5 直接执行并发命令，命令详情如下表。

命令	参数及说明	命令作用
hdfs quickcmds [-t	threadsNumber：并发线程数，默认	多并发设置目录

命令	参数及说明	命令作用
threadsNumber] [-p principal] [-k keytab] -setrep <rep> <path> ...	为本机 CPU 核数 principal：Kerberos 用户 keytab：Keytab 文件 rep：副本数 path：HDFS 目录	中所有文件的副本数
hdfs quickcmds [-t threadsNumber] [-p principal] [-k keytab] -chown [owner][:[group]] <path> ...	threadsNumber：并发线程数，默认为本机 CPU 核数 principal：Kerberos 用户 keytab：Keytab 文件 owner：所属用户 group：所属组 path：HDFS 目录	多并发设置目录中所有文件的属组
hdfs quickcmds [-t threadsNumber] [-p principal] [-k keytab] -chmod <mode> <path> ...	threadsNumber：并发线程数，默认为本机 CPU 核数 principal：Kerberos 用户 keytab：Keytab 文件 mode：权限（如 754） path：HDFS 目录	多并发设置目录中所有文件的权限
hdfs quickcmds [-t threadsNumber] [-p principal] [-k keytab] -setfacl [{-b|-k} {-m|-x <acl_spec>} <path> ...]|[--set <acl_spec> <path> ...]	threadsNumber：并发线程数，默认为本机 CPU 核数 principal：Kerberos 用户 keytab：Keytab 文件 acl_spec：逗号分隔的 ACL 列表 path：HDFS 目录	多并发设置目录中所有文件的 ACL 信息

----结束

9.31 配置 HDFS 快速关闭文件

操作场景

默认情况下关闭 HDFS 文件时需要等待所有的 Block 都上报成功（处于 COMPLETED 状态）。因此 HDFS 的一部分写性能消耗为等待 DataNode 块上报以及 NameNode 处理块上报。对于一个负载较大的集群，等待的消耗对集群影响较大。HDFS 可以通过配置 NameNode 参数“dfs.namenode.file.close.num-committed-allowed”来提前关闭文件，提升写数据性能。但是由于提前关闭了文件，可能在读取数据的时候由于块找不到或

者 NameNode 元数据中记录的数据块信息和 DataNode 中存储的真实副本不一致而失败。**因此该特性不适用于写完数据即读的场景，请结合业务场景谨慎使用该特性。**

说明

该功能适用于 MRS 3.2.0-LTS.1 及之后版本。

操作步骤

登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > 服务 > HDFS > 配置 > 全部配置”进入 HDFS 全部配置页面。

步骤 2 搜索并修改“dfs.namenode.file.close.num-committed-allowed”参数，配置项详细说明如下表。

参数	参数说明
dfs.namenode.file.close.num-committed-allowed	关闭文件时，允许待关闭文件中处于 COMMITTED 状态的 Block 的数量。 默认为：0，即关闭该特性。如果开启该特性，一般建议值为 1~2，不建议太大。 例如：若该参数值为 1，则表示无需等待最后一个 Block 状态变成 COMPLETED 即可关闭文件。

步骤 3 参数修改后保存配置。

步骤 4 在 HDFS“实例”界面，勾选主备 NameNode 实例，选择“更多 > 滚动重启实例”，等待滚动重启完成生效。

----结束

9.32 HDFS 日志介绍

日志描述

日志存储路径：HDFS 相关日志的默认存储路径为“/var/log/Bigdata/hdfs/角色名”

- NameNode：“/var/log/Bigdata/hdfs/nn”（运行日志），“/var/log/Bigdata/audit/hdfs/nn”（审计日志）。
- DataNode：“/var/log/Bigdata/hdfs/dn”（运行日志），“/var/log/Bigdata/audit/hdfs/dn”（审计日志）。
- ZKFC：“/var/log/Bigdata/hdfs/zkfc”（运行日志），“/var/log/Bigdata/audit/hdfs/zkfc”（审计日志）。
- JournalNode：“/var/log/Bigdata/hdfs/jn”（运行日志），“/var/log/Bigdata/audit/hdfs/jn”（审计日志）。

- Router：“/var/log/Bigdata/hdfs/router”（运行日志），“/var/log/Bigdata/audit/hdfs/router”（审计日志）。
- HttpFS：“/var/log/Bigdata/hdfs/httpfs”（运行日志），“/var/log/Bigdata/audit/hdfs/httpfs”（审计日志）。

日志归档规则：HDFS 的日志启动了自动压缩归档功能，默认情况下，当日志大小超过 100MB 的时候，会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”。最多保留最近的 100 个压缩文件，压缩文件保留个数可以在 Manager 界面中配置。

表9-31 HDFS 日志列表

日志类型	日志文件名	描述
运行日志	hadoop-<SSH_USER>-<process_name>-<hostname>.log	HDFS 系统日志，记录 HDFS 系统运行时候所产生的大部分日志。
	hadoop-<SSH_USER>-<process_name>-<hostname>.out	HDFS 运行环境信息日志。
	hadoop.log	Hadoop 客户端操作日志。
	hdfs-period-check.log	周期运行的脚本的日志记录。包括：自动均衡、数据迁移、journalnode 数据同步检测等。
	<process_name>-<SSH_USER>-<DATE>-<PID>-gc.log	垃圾回收日志。
	postinstallDetail.log	HDFS 服务安装后启动前工作日志。
	hdfs-service-check.log	HDFS 服务启动是否成功的检查日志。
	hdfs-set-storage-policy.log	HDFS 数据存储策略日志。
	cleanupDetail.log	HDFS 服务卸载时候的清理日志。
	prestartDetail.log	HDFS 服务启动前集群操作的记录日志。
	hdfs-recover-fsimage.log	NameNode 元数据恢复日志。
	datanode-disk-check.log	集群安装过程和使用过程中磁盘状态检测的记录日志。
	hdfs-availability-check.log	HDFS 服务是否可用日

日志类型	日志文件名	描述
		志。
	hdfs-backup-fsimage.log	NameNode 元数据备份日志。
	startDetail.log	hdfs 服务启动的详细日志。
	hdfs-blockplacement.log	HDFS 块放置策略记录日志。
	upgradeDetail.log	升级日志。
	hdfs-clean-acls-java.log	HDFS 清除已删除角色的 ACL 信息的日志。
	hdfs-haCheck.log	NameNode 主备状态获取脚本运行日志。
	<process_name>-jvmpause.log	进程运行中，记录 JVM 停顿的日志。
	hadoop-<SSH_USER>-balancer-<hostname>.log	HDFS 自动均衡的运行日志。
	hadoop-<SSH_USER>-balancer-<hostname>.out	HDFS 运行自动均衡的环境信息日志。
	hdfs-switch-namenode.log	HDFS 主备倒换运行日志
	hdfs-router-admin.log	管理挂载表操作的运行日志
	threadDump-<DATE>.log	实例进程堆栈日志
Tomcat 日志	hadoop-omm-host1.out，httpfs-catalina.<DATE>.log，httpfs-host-manager.<DATE>.log，httpfs-localhost.<DATE>.log，httpfs-manager.<DATE>.log，localhost_access_web_log.log	tomcat 运行日志
审计日志	hdfs-audit-<process_name>.log ranger-plugin-audit.log	HDFS 操作审计日志（例如：文件增删改查）。
	SecurityAuth.audit	HDFS 安全审计日志。

日志级别

HDFS 中提供了如表 9-32 所示的日志级别，日志级别优先级从高到低分别是 FATAL、ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表9-32 日志级别

级别	描述
FATAL	FATAL 表示系统运行的致命错误信息。
ERROR	ERROR 表示系统运行的错误信息。
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示系统及系统调试信息。

如果您需要修改日志级别，请执行如下操作：

请参考 25.1 修改集群服务配置参数，进入 HDFS 的“全部配置”页面。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别。

步骤 4 保存配置，在弹出窗口中单击“确定”使配置生效。

说明

配置完成后立即生效，不需要重启服务。

----结束

日志格式

HDFS 的日志格式如下所示：

表9-33 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2015-01-26 18:43:42,840	INFO	IPC Server handler 40 on 8020	Rolling edit logs	org.apache.hadoop.hdfs.server.namenode.FSEditLog.rollEditLog(FSEditLog.java:1096)
审计日志	<yyyy-MM-dd	2015-01-26 18:44:42,607	

日志类型	格式	示例
	HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	INFO | IPC Server handler 32 on 8020 | allowed=true ugi=hbase (auth:SIMPLE) ip=/10.177.112.145 cmd=getfileinfo src=/hbase/WALs/hghoulaslx410,16020,1421743096083/hghoulaslx410%2C16020%2C1421743096083.1422268722795 dst=null perm=null | org.apache.hadoop.hdfs.server.namenode.FSNamesystem$DefaultAuditLogger.logAuditMessage(FSNamesystem.java:7950)

9.33 HDFS 性能调优

9.33.1 提升写性能

操作场景

在 HDFS 中，通过调整属性的值，使得 HDFS 集群更适应自身的业务情况，从而提升 HDFS 的写性能。

操作步骤

参数入口：

在 FusionInsight Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > HDFS > 配置”，选择“全部配置”。在搜索框中输入参数名称。

表9-34 HDFS 写性能优化配置

参数	描述	默认值
dfs.datanode.drop.cache.behind.reads	表示是否让 DataNode 将在缓冲区中的数据传递给客户端后自动清除缓冲区中的所有数据。 • true：表示丢弃缓存的数据（需要在 DataNode 中配置）。 当同一份数据，重复读取的次数较少时，建议设置为 true，使得缓存能够被其他操作使用。 • false：重复读取的次数较多时，设置为	false

参数	描述	默认值
	false 能够提升重复读取的速度。 说明 在提升写性能操作中，该参数为可选参数，请根据实际需要进行修改。	
dfs.client-write-packet-size	客户端写包的大小。当 HDFS Client 往 DataNode 写数据时，将数据生成一个包。然后将这个包在网络上传出。此参数指定传输数据包的大小，可以通过各 Job 来指定。单位：字节。 在万兆网部署下，可适当增大该参数值，来提升传输的吞吐量。	262144

9.33.2 使用客户端元数据缓存提高读取性能

操作场景

通过使用客户端缓存元数据块的位置来提高 HDFS 读取性能。

说明

此功能仅用于读取不经常修改的文件。因为在服务器端由某些其他客户端完成的数据修改，对于高速缓存的客户端将是不可见的，这可能导致从缓存中拿到的元数据是过期的。

操作步骤

设置参数的路径：

在 FusionInsight Manager 页面中，选择“集群 > *待操作集群的名称* > 服务 > HDFS > 配置”，选择“全部配置”，并在搜索框中输入参数名称。

表9-35 参数配置

参数	描述	默认值
dfs.client.metadata.cache.enabled	启用/禁用块位置元数据的客户端缓存。将此参数设置为“true”，搭配“dfs.client.metadata.cache.pattern”参数以启用缓存。	false
dfs.client.metadata.cache.pattern	需要缓存的文件路径的正则表达式模式。只有这些文件的块位置元数据被缓存，直到这些元数据过期。此配置仅在参数“dfs.client.metadata.cache.enabled”设置为“true”时有效。 示例：“/test.*”表示读取其路径是以“/test”开头的所有文件。	-

参数	描述	默认值
	说明 ● 为确保一致性，配置特定模式以仅缓存其他客户端不经常修改的文件。 ● 正则表达式模式将仅验证 URI 的 path 部分，而不验证在 Fully Qualified 路径情况下的 schema 和 authority。	
dfs.client.metadata.cache.expiry.sec	缓存元数据的持续时间。缓存条目在该持续时间过期后失效。即使在缓存过程中经常使用的元数据也会发生失效。 配置值可采用时间后缀 s/m/h 表示，分别表示秒，分钟和小时。 说明 若将该参数配置为“0s”，将禁用缓存功能。	60s
dfs.client.metadata.cache.max.entries	缓存一次最多可保存的非过期数据条目。	65536

说明

要在过期前完全清除客户端缓存，可调用 *DFSClient#clearLocatedBlockCache()*。

用法如下所示。

```
FileSystem fs = FileSystem.get(conf);
DistributedFileSystem dfs = (DistributedFileSystem) fs;
DFSClient dfsClient = dfs.getClient();
dfsClient.clearLocatedBlockCache();
```

9.33.3 使用当前活动缓存提升客户端与 NameNode 的连接性能

操作场景

HDFS 部署在具有多个 NameNode 实例的 HA（High Availability）模式中，HDFS 客户端需要依次连接到每个 NameNode，以确定当前活动的 NameNode 是什么，并将其用于客户端操作。

一旦识别出来，当前活动的 NameNode 的详细信息就可以被缓存并共享给在客户端机器中运行的所有客户端。这样，每个新客户端可以首先尝试从缓存加载活动的 NameNode 的详细信息，并将 RPC 调用保存到备用的 NameNode。在异常情况下有很多优势，例如当备用的 NameNode 连接长时间不响应时。

当发生故障，将另一个 NameNode 切换为活动状态时，缓存的详细信息将被更新为当前活动的 NameNode 的信息。

操作步骤

设置参数的路径如下：

在 FusionInsight Manager 页面中，选择“集群 > *待操作集群的名称* > 服务 > HDFS > 配置”，选择“全部配置”，并在搜索框中输入参数名称。

表9-36 配置参数

参数	描述	默认值
dfs.client.failover.proxy.provider.[nameservice ID]	用已通过的协议创建 namenode 代理的 Client Failover proxy provider 类。配置成 org.apache.hadoop.hdfs.server.namenode.ha.BlackListingFailoverProxyProvider，可在 HDFS 客户端使用 NameNode 黑名单特性。配置成 org.apache.hadoop.hdfs.server.namenode.ha.ObserverReadProxyProvider，可使用从 NameNode 支持读的特性。	org.apache.hadoop.hdfs.server.namenode.ha.AdaptiveFailoverProxyProvider
dfs.client.failover.activeinfo.share.flag	启用缓存并将当前活动的 NameNode 的详细信息共享给其他客户端。若要启用缓存，需将其设置为“true”。	false
dfs.client.failover.activeinfo.share.path	指定将在机器中的所有客户端创建的共享文件的本地目录。如果要为不同用户共享缓存，该文件夹应具有必需的权限（如在给定目录中创建，读写缓存文件）。	/tmp
dfs.client.failover.activeinfo.share.io.timeout.sec	控制超时的可选配置。用于在读取或写入缓存文件时获取锁定。如果在该时间内无法获取缓存文件上的锁定，则放弃尝试读取或更新缓存。单位为秒。	5

说明

由 HDFS 客户端创建的缓存文件必须由其他客户端重新使用。因此，这些文件永远不会从本地系统中删除。若禁用该功能，可能需要进行手动清理。

9.34 HDFS 常见问题

9.34.1 NameNode 启动慢

问题

删除大量文件之后立刻重启 NameNode（例如删除 100 万个文件），NameNode 启动慢。

回答

由于在删除了大量文件之后，DataNode 需要时间去删除对应的 Block。当立刻重启 NameNode 时，NameNode 会去检查所有 DataNode 上报的 Block 信息，发现已删除的 Block 时，会输出对应的 INFO 日志信息，如下所示：

```
2015-06-10 19:25:50,215 | INFO  | IPC Server handler 36 on 25000 | BLOCK*
processReport:
blk_1075861877_2121067 on node 10.91.8.218:9866 size 10249 does not belong to any
file |
org.apache.hadoop.hdfs.server.blockmanagement.BlockManager.processReport(BlockManag
er.java:1854)
```

每一个被删除的 Block 会产生一条日志信息，一个文件可能会存在一个或多个 Block。当删除的文件数过多时，NameNode 会花大量的时间打印日志，然后导致 NameNode 启动慢。

当出现这种现象时，您可以通过如下方式提升 NameNode 的启动速度。

1. 删除大量文件时，不要立刻重启 NameNode，待 DataNode 删除了对应的 Block 后重启 NameNode，即不会存在这种情况。

   您可以通过 ***hdfs dfsadmin -report*** 命令来查看磁盘空间，检查文件是否删除完毕。
2. 如已大量出现以上日志，您可以将 NameNode 的日志级别修改为 ERROR，NameNode 不会再打印此日志信息。

   等待 NameNode 启动完毕后，再将此日志级别修改为 INFO。修改日志级别后无需重启服务。

9.34.2 DataNode 状态正常，但无法正常上报数据块

问题

DataNode 正常，但无法正常上报数据块，导致存在的数据块无法使用。

回答

当某个数据目录中的数据块数量超过 4 倍的数据块限定值(1M)时，可能会出现该错误。DataNode 会产生相应的错误日志记录，如下所示：

```
2015-11-05 10:26:32,936 | ERROR |
DataNode:[[[DISK]file:/srv/BigData/hadoop/data1/dn/]] heartbeating to
vm-210/10.91.8.210:8020 | Exception in BPOfferService for Block pool BP-805114975-
10.91.8.210-1446519981645
(Datanode Uuid bcada350-0231-413b-bac0-8c65e906c1bb) service to vm-
210/10.91.8.210:8020 | BPServiceActor.java:824
java.lang.IllegalStateException:com.google.protobuf.InvalidProtocolBufferException:
Protocol message was too large.May
be malicious.Use CodedInputStream.setSizeLimit() to increase the size limit. at
org.apache.hadoop.hdfs.protocol.BlockListAsLongs$BufferDecoder$1.next(BlockListAsLo
ngs.java:369)
at
org.apache.hadoop.hdfs.protocol.BlockListAsLongs$BufferDecoder$1.next(BlockListAsLo
ngs.java:347) at org.apache.hadoop.hdfs.
protocol.BlockListAsLongs$BufferDecoder.getBlockListAsLongs(BlockListAsLongs.java:3
```

```
25) at org.apache.hadoop.hdfs.protocolPB.DatanodeProtocolClientSideTranslatorPB.
blockReport(DatanodeProtocolClientSideTranslatorPB.java:190) at
org.apache.hadoop.hdfs.server.datanode.BPServiceActor.blockReport(BPServiceActor.ja
va:473)
at
org.apache.hadoop.hdfs.server.datanode.BPServiceActor.offerService(BPServiceActor.j
ava:685) at
org.apache.hadoop.hdfs.server.datanode.BPServiceActor.run(BPServiceActor.java:822)
at java.lang.Thread.run(Thread.java:745) Caused
by:com.google.protobuf.InvalidProtocolBufferException:Protocol message was too
large.May be malicious.Use CodedInputStream.setSizeLimit()
to increase the size limit. at
com.google.protobuf.InvalidProtocolBufferException.sizeLimitExceeded(InvalidProtoco
lBufferException.java:110) at
com.google.protobuf.CodedInputStream.refillBuffer(CodedInputStream.java:755)
at com.google.protobuf.CodedInputStream.readRawByte(CodedInputStream.java:769) at
com.google.protobuf.CodedInputStream.readRawVarint64(CodedInputStream.java:462) at
com.google.protobuf.
CodedInputStream.readSInt64(CodedInputStream.java:363) at
org.apache.hadoop.hdfs.protocol.BlockListAsLongs$BufferDecoder$1.next(BlockListAsLo
ngs.java:363)
```

如今，数据目录中数据块的数量会显示为 Metric。用户可以通过以下 URL 对该值进行监视 http://<datanode-ip>:<http-port>/jmx，如果该值超过 4 倍的限定值(4*1M)，建议用户配置多个驱动器并重新启动 HDFS。

恢复步骤：

1. 在 DataNode 上配置多个数据目录。

   示例：在原先只配置了/data1/datadir 的位置

   ```
   <property> <name>dfs.datanode.data.dir</name> <value>/data1/datadir</value>
   </property>
   ```

   按照如下内容进行配置。

   ```
   <property> <name>dfs.datanode.data.dir</name>
   <value>/data1/datadir/,/data2/datadir,/data3/datadir</value> </property>
   ```

   说明

   建议多个数据目录应该配置到多个磁盘中，否则所有的数据都将写入同一个磁盘，对性能有很大的影响。

2. 重新启动 HDFS。
3. 按照如下方法将数据移动至新的数据目录。

   mv */data1/datadir/current/finalized/subdir1　/data2/datadir/current/finalized/subdir1*

4. 重新启动 HDFS。

9.34.3 HDFS Web UI 无法正常刷新损坏数据的信息

问题

1. 当 DataNode 的“dfs.datanode.data.dir”所配置的目录因权限或者磁盘损坏发生错误时，HDFS Web UI 没有显示损坏数据的信息。
2. 当此错误被修复后，HDFS Web UI 没有及时移除损坏数据的相关信息。

回答

1. DataNode 只有在执行文件操作发生错误时，才会去检查磁盘是否正常，若发现数据损坏，则将此错误上报至 NameNode，此时 NameNode 才会在 HDFS Web UI 显示数据损坏信息。
2. 当错误修复后，需要重启 DataNode。当重启 DataNode 时，会检查所有数据状态并上传损坏数据信息至 NameNode。所以当此错误被修复后，只有重启 DataNode 后，才会不显示损坏数据信息。

9.34.4 distcp 命令在安全集群上失败并抛出异常

问题

为何 distcp 命令在安全集群上失败并抛出异常？

客户端出现异常：

```
Invalid arguments:Unexpected end of file from server
```

服务器端出现异常：

```
javax.net.ssl.SSLException:Unrecognized SSL message, plaintext connection?
```

回答

当用户在 distcp 命令中使用 **webhdfs://**时，会抛出上述异常，是由于集群所使用的 HTTP 政策为 HTTPS，即配置在“core-site.xml”的“dfs.http.policy”值为“HTTPS_ONLY”。所以要避免出现此异常，应使用 **swebhdfs://**替代 **webhdfs://**。

例如：

./hadoop distcp swebhdfs://IP:PORT/testfile hdfs://IP:PORT/testfile1

9.34.5 当 dfs.datanode.data.dir 中定义的磁盘数量等于 dfs.datanode.failed.volumes.tolerated 的值时，DataNode 启动失败

问题

当“dfs.datanode.data.dir”中定义的磁盘数量等于“dfs.datanode.failed.volumes.tolerated”的值时，DataNode 启动失败。

回答

默认情况下，单个磁盘的故障将会引起 HDFS DataNode 进程关闭，导致 NameNode 为每一个存在 DataNode 上的 block 调度额外的副本，在没有故障的磁盘中引起不必要的块复制。

为了防止此情况，用户可以通过配置 DataNodes 来承受 dfs.data.dir 目录的故障。登录 Manager，选择“集群 > 服务 > HDFS > 配置 > 全部配置”搜索参数“dfs.datanode.failed.volumes.tolerated”。例如：如果该参数值为 3，DataNode 只有在 4 个或者更多个目录故障之后才会出现故障。该值会影响到 DataNode 的启动。

如果想要 DataNode 不出现故障，配置的“dfs.datanode.failed.volumes.tolerated”一定要小于所配置的卷数，也可以将“dfs.datanode.failed.volumes.tolerated”设置成-1，相当于设置该值为 n-1（n 为卷数），那样 DataNode 就不会出现启动失败。

9.34.6 当多个 data.dir 被配置在一个磁盘分区内，DataNode 的容量计算将会出错

问题

当多个 data.dir 被配置在一个磁盘分区内，DataNode 的容量计算将会出错。

回答

目前容量计算是基于磁盘的，类似于 Linux 里面的 ***df*** 命令。理想状态下，用户不会在同一个磁盘内配置多个 data.dir，否则所有的数据都将写入一个磁盘，在性能上会有很大的影响。

因此配置如下：

例如，如果机器有如下磁盘：

```
host-4:~ # df -h
Filesystem     Size   Used   Avail   Use%  Mounted on
/dev/sda1      352G   11G    324G    4%    /
udev            190G   252K   190G    1%    /dev
tmpfs           190G   72K    190G    1%    /dev/shm
/dev/sdb1      2.7T   74G    2.5T     3%   /data1
/dev/sdc1      2.7T   75G    2.5T     3%   /data2
/dev/sdd1      2.7T   73G    2.5T     3%   /da
```

建议的配置方式：

```
<property>
<name>dfs.datanode.data.dir</name>
<value>/data1/datadir/,/data2/datadir,/data3/datadir</value>
</property>
```

不建议的配置方式：

```
<property>
<name>dfs.datanode.data.dir</name>
<value>/data1/datadir1/,/data2/datadir1,/data3/datadir1,/data1/datadir2,data1/datad
ir3,/data2/datadir2,/data2/datadir3,/data3/datadir2,/data3/datadir3</value>
</property>
```

9.34.7 当 Standby NameNode 存储元数据（命名空间）时，出现断电的情况，Standby NameNode 启动失败

问题

当 Standby NameNode 存储元数据（命名空间）时，出现断电的情况，Standby NameNode 启动失败并抛出如下错误信息。

```
2015-12-04 11:49:12,121 | ERROR | main | Failed to load image from FS
ImageFile(file=/srv/BigData/namenode/current/fsimage_0000000000000096
080,
cpktTxId=0000000000000096080) | FSImage.java:685
java.io.IOException: Invalid MD5 file /srv/BigData/namenode/current/f
simage_0000000000000096080.md5:
the content "锘斤拷锘斤拷锘斤拷锘斤拷锘斤拷[1m^A!锘 does not match the expecte
d pattern.
at org.apache.hadoop.hdfs.util.MD5FileUtils.readStoredMd5(MD5FileUtil
s.java:92)
at org.apache.hadoop.hdfs.util.MD5FileUtils.readStoredMd5ForFile(MD5F
ileUtils.java:109)
at org.apache.hadoop.hdfs.server.namenode.FSImage.loadFSImage(FSImage
.java:975)
at org.apache.hadoop.hdfs.server.namenode.FSImage.loadFSImageFile(FSI
mage.java:744)
at org.apache.hadoop.hdfs.server.namenode.FSImage.loadFSImage(FSImage
.java:682)
at org.apache.hadoop.hdfs.server.namenode.FSImage.recoverTransitionRe
ad(FSImage.java:300)
at org.apache.hadoop.hdfs.server.namenode.FSNamesystem.loadFSImage(FS
Namesystem.java:968)
at org.apache.hadoop.hdfs.server.namenode.FSNamesystem.loadFromDisk(F
SNamesystem.java:675)
at org.apache.hadoop.hdfs.server.namenode.NameNode.loadNamesystem(Nam
eNode.java:625)
at org.apache.hadoop.hdfs.server.namenode.NameNode.initialize(NameNod
e.java:685)
at org.apache.hadoop.hdfs.server.namenode.NameNode.<init>(NameNode.ja
va:889)
at org.apache.hadoop.hdfs.server.namenode.NameNode.<init>(NameNode.ja
va:872)
at org.apache.hadoop.hdfs.server.namenode.NameNode.createNameNode(Nam
eNode.java:1580)
at org.apache.hadoop.hdfs.server.namenode.NameNode.main(NameNode.java
:1654)
```

回答

当 Standby NameNode 存储元数据（命名空间）时，出现断电的情况，Standby NameNode 启动失败，MD5 文件会损坏。通过移除损坏的 fsimage，然后启动 Standby NameNode，可以修复此问题。Standby NameNode 会加载先前的 fsimage 并重现所有的 edits。

修复步骤：

1. 移除损坏的 fsimage。

   rm -rf ${BIGDATA_DATA_HOME}/namenode/current/fsimage_0000000000000096

2. 启动 Standby NameNode。

9.34.8 在存储小文件过程中，系统断电，缓存中的数据丢失

问题

在存储小文件过程中，系统断电，缓存中的数据丢失。

回答

由于断电，当写操作完成之后，缓存中的 block 不会立即被写入磁盘，如果要同步地将缓存的 block 写入磁盘，用户需要将“*客户端安装路径*/HDFS/hadoop/etc/hadoop/hdfs-site.xml”中的“dfs.datanode.synconclose”设置为“true”。

默认情况下，“dfs.datanode.synconclose”为“false”，虽然性能很高，但是断电之后，存储在缓存中的数据会丢失。将“dfs.datanode.synconclose”设置为“true”，可以解决此问题，但对性能有很大影响。请根据具体的应用场景决定是否开启该参数。

9.34.9 FileInputFormat split 的时候出现数组越界

问题

HDFS 调用 FileInputFormat 的 getSplit 方法的时候，出现 ArrayIndexOutOfBoundsException: 0，日志如下：

```
java.lang.ArrayIndexOutOfBoundsException: 0
at org.apache.hadoop.mapred.FileInputFormat.identifyHosts(FileInputFormat.java:708)
at
org.apache.hadoop.mapred.FileInputFormat.getSplitHostsAndCachedHosts(FileInputForma
t.java:675)
at org.apache.hadoop.mapred.FileInputFormat.getSplits(FileInputFormat.java:359)
at org.apache.spark.rdd.HadoopRDD.getPartitions(HadoopRDD.scala:210)
at org.apache.spark.rdd.RDD$$anonfun$partitions$2.apply(RDD.scala:239)
at org.apache.spark.rdd.RDD$$anonfun$partitions$2.apply(RDD.scala:237)
at scala.Option.getOrElse(Option.scala:120)
at org.apache.spark.rdd.RDD.partitions(RDD.scala:237)
at org.apache.spark.rdd.MapPartitionsRDD.getPartitions(MapPartitionsRDD.scala:35)
```

回答

每个 block 对应的机架信息组成为：/default/rack0/:,/default/rack0/datanodeip:port。

该问题是由于某个 block 块损坏或者丢失，导致该 block 对应的机器 ip 和 port 为空引起的，出现该问题的时候使用 **hdfs fsck** 检查对应文件块的健康状态，删除损坏或者恢复丢失的块，重新进行任务计算即可。

9.34.10 当分级存储策略为 LAZY_PERSIST 时，为什么文件的副本的存储类型都是 DISK

问题

当文件的存储策略为 LAZY_PERSIST 时，文件的第一副本的存储类型应为 RAM_DISK，其余副本为 DISK。

为什么文件的所有副本的存储类型都是 DISK？

回答

当用户写入存储策略为 LAZY_PERSIST 的文件时，文件的三个副本会逐一写入。第一副本会优先选择客户端所在的 DataNode 节点，在以下情况下，当文件的存储策略为 LAZY_PERSIST 时，文件的所有副本的存储类型都是 DISK：

- 当客户端所在的 DataNode 节点没有 RAM_DISK 时，则会写入客户端所在的 DataNode 节点的 DISK 磁盘，其余副本会写入其他节点的 DISK 磁盘。
- 当客户端所在的 DataNode 节点有 RAM_DISK，但"dfs.datanode.max.locked.memory"参数值未设置或设置过小（小于“dfs.blocksize”参数值）时（对应参数值可登录 Manager，选择“集群 > 服务 > HDFS > 配置 > 全部配置”搜索该参数获取），则会写入客户端所在的 DataNode 节点的 DISK 磁盘，其余副本会写入其他节点的 DISK 磁盘。

9.34.11 NameNode 节点长时间满负载，HDFS 客户端无响应

问题

当 NameNode 节点处于满负载、NameNode 所在节点的 CPU 100%耗尽时，导致 NameNode 无法响应，对于新连接到该 NameNode 的 HDFS 客户端，能够主备切换连接到另一个 NameNode，进行正常的操作，而对于已经连接到该 NameNode 节点的 HDFS 客户端可能会卡住，无法进行下一步操作。

回答

目前出现上述问题时使用的是默认配置，如表 9-37 所示，HDFS 客户端到 NameNode 的 RPC 连接存在 keep alive 机制，保持连接不会超时，尽力等待服务器的响应，因此导致已经连接的 HDFS 客户端的操作会卡住。

对于已经卡住的 HDFS 客户端，可以进行如下操作：

- 等待 NameNode 响应，一旦 NameNode 所在节点的 CPU 利用率回落，NameNode 可以重新获得 CPU 资源时，HDFS 客户端即可得到响应。
- 如果无法等待更长时间，需要重启 HDFS 客户端所在的应用程序进程，使得 HDFS 客户端重新连接空闲的 NameNode。

解决措施：

为了避免该问题出现，可以在“*客户端安装路径*/HDFS/hadoop/etc/hadoop/core-site.xml”中做如下配置。

表9-37 参数说明

参数	描述	默认值
ipc.client.ping	当配置为 true 时，客户端会尽力等待服务端响应，定期发送 ping 消息，使得连接不会因为 tcp timeout 而断开。 当配置为 false 时，客户端会使用配置项“ipc.ping.interval”对应的值，作为 timeout 时	true

参数	描述	默认值
	间，在该时间内没有得到响应，即会超时。 在上述问题场景下，建议配置为 false。	
ipc.ping.interval	当“ipc.client.ping”配置为 true 时，表示发送 ping 消息的周期。 当“ipc.client.ping”设置为 false 时，表示连接的超时时间。 在上述问题场景下，建议配置一个较大的超时时间，避免服务繁忙时的超时，建议配置为 900000，单位为 ms。	60000

9.34.12 DataNode 禁止手动删除或修改数据存储目录

问题

- 数据块在 DataNode 上的存储目录由“dfs.datanode.data.dir”配置项指定，是否可以修改该配置项来修改数据存储目录？
- 是否可以手动拷贝数据存储目录下的文件？

回答

“dfs.datanode.data.dir”配置项用于指定数据块在 DataNode 上的存储目录，在系统安装时需要指定根目录，并且可以指定多个根目录。

- 请谨慎修改该配置项，可以添加新的数据根目录。
- 禁止删除原有存储目录，否则会造成数据块丢失，导致文件无法正常读写。
- 禁止手动删除或修改存储目录下的数据块，否则可能会造成数据块丢失。

说明

NameNode 和 JournalNode 存在类似的配置项，也同样禁止删除原有存储目录，禁止手动删除或修改存储目录下的数据块。

- dfs.namenode.edits.dir
- dfs.namenode.name.dir
- dfs.journalnode.edits.dir

9.34.13 成功回滚后，为什么 NameNode UI 上显示有一些块缺失

问题

回滚成功后，为什么 NameNode UI 上显示有一些块缺失？

回答

原因：具有新 id/genstamps 的块可能存在于 DataNode 上。DataNode 中的块文件可能具有与 NameNode 的回滚 image 中不同的生成标记和长度，所以 NameNode 会拒绝 DataNode 中的这些块，并将文件标记为已损坏。

场景如下：

1. 升级前

   客户端 A - >将一些数据写入文件 X（假设已写入“A”字节）
2. 升级开始了

   客户端 A - >仍然将数据写入文件 X（现在文件中的数据是“A + B”字节）
3. 升级完成

   客户端 A - >完成写入文件。最终数据为“A + B”字节。
4. 回滚开始

   将回滚到步骤 1（升级前）的状态。因此，NameNode 中的文件 X 将具有“A”字节，但 DataNode 中的块文件将具有“A + B”字节。

恢复步骤：

1. 从 NameNode Web UI 中获取已损坏的文件列表，或者通过下面的命令获取。

   hdfs fsck <filepath> -list-corruptfileblocks
2. 对于不需要的文件，请使用以下命令删除文件。

   hdfs fsck <corrupt file path> - delete

   说明

   删除文件为高危操作，在执行操作前请务必确认对应文件是否不再需要。
3. 对于所需的文件，执行 fsck 命令来获取块列表和块的顺序。
   - 在 fsck 中给出的块序列表中，使用块 id 搜索 DataNode 中的数据目录，并从 DataNode 下载相应的块。
   - 按照序列以追加的方式写入所有这样的块文件，并构造成原始文件。

     例如：

     File 1--> blk_1, blk_2, blk_3

     通过组合来自同一序列的所有三个块文件的内容来创建文件。
   - 从 HDFS 中删除旧文件并重写新构建的文件。

9.34.14 为什么在往 HDFS 写数据时报"java.net.SocketException: No buffer space available"异常

问题

为什么在往 HDFS 写数据时报"java.net.SocketException: No buffer space available"异常？

这个问题发生在往 HDFS 写文件时。查看客户端和 DataNode 的错误日志。

客户端日志如下：

图9-8 客户端日志

DataNode 日志如下：

```
2017-07-24 20:43:39,269 | ERROR | DataXceiver for client
DFSClient_NONMAPREDUCE_996005058_86
 at /192.168.164.155:40214 [Receiving block BP-1287143557-192.168.199.6-
1500707719940:blk_1074269754_528941 with io weight 10] |
DataNode{data=FSDataset{dirpath='[/srv/BigData/hadoop/data1/dn/current,
/srv/BigData/hadoop/data2/dn/current, /srv/BigData/hadoop/data3/dn/current,
/srv/BigData/hadoop/data4/dn/current, /srv/BigData/hadoop/data5/dn/current,
/srv/BigData/hadoop/data6/dn/current, /srv/BigData/hadoop/data7/dn/current]'},
localName='192-168-164-155:9866', datanodeUuid='a013e29c-4e72-400c-bc7b-
bbbf0799604c', xmitsInProgress=0}:Exception transfering block BP-1287143557-
192.168.199.6-1500707719940:blk_1074269754_528941 to mirror 192.168.202.99:9866:
java.net.SocketException: No buffer space available | DataXceiver.java:870
2017-07-24 20:43:39,269 | INFO | DataXceiver for client
DFSClient_NONMAPREDUCE_996005058_86
 at /192.168.164.155:40214 [Receiving block BP-1287143557-192.168.199.6-
1500707719940:blk_1074269754_528941 with io weight 10] | opWriteBlock BP-
1287143557-192.168.199.6-1500707719940:blk_1074269754_528941 received exception
java.net.SocketException: No buffer space available | DataXceiver.java:933
2017-07-24 20:43:39,270 | ERROR | DataXceiver for client
DFSClient_NONMAPREDUCE_996005058_86
 at /192.168.164.155:40214 [Receiving block BP-1287143557-192.168.199.6-
1500707719940:blk_1074269754_528941 with io weight 10] | 192-168-164-
155:9866:DataXceiver error processing WRITE_BLOCK operation src:
/192.168.164.155:40214 dst: /192.168.164.155:9866 | DataXceiver.java:304
java.net.SocketException: No buffer space available
 at sun.nio.ch.Net.connect0(Native Method)
 at sun.nio.ch.Net.connect(Net.java:454)
 at sun.nio.ch.Net.connect(Net.java:446)
 at sun.nio.ch.SocketChannelImpl.connect(SocketChannelImpl.java:648)
 at org.apache.hadoop.net.SocketIOWithTimeout.connect(SocketIOWithTimeout.java:192)
 at org.apache.hadoop.net.NetUtils.connect(NetUtils.java:531)
 at org.apache.hadoop.net.NetUtils.connect(NetUtils.java:495)
 at
org.apache.hadoop.hdfs.server.datanode.DataXceiver.writeBlock(DataXceiver.java:800)
```

```
 at
org.apache.hadoop.hdfs.protocol.datatransfer.Receiver.opWriteBlock(Receiver.java:13
8)
 at
org.apache.hadoop.hdfs.protocol.datatransfer.Receiver.processOp(Receiver.java:74)
 at org.apache.hadoop.hdfs.server.datanode.DataXceiver.run(DataXceiver.java:265)
 at java.lang.Thread.run(Thread.java:748)
```

回答

上述问题可能是因为网络内存枯竭而导致的。

问题的解决方案是根据实际场景适当增大网络设备的阈值级别。

例如：

```
[root@xxxxx ~]# cat /proc/sys/net/ipv4/neigh/default/gc_thresh*
128
512
1024
[root@xxxxx ~]# echo 512 > /proc/sys/net/ipv4/neigh/default/gc_thresh1
[root@xxxxx ~]# echo 2048 > /proc/sys/net/ipv4/neigh/default/gc_thresh2
[root@xxxxx ~]# echo 4096 > /proc/sys/net/ipv4/neigh/default/gc_thresh3
[root@xxxxx ~]# cat /proc/sys/net/ipv4/neigh/default/gc_thresh*
512
2048
4096
```

还可以将以下参数添加到“/etc/sysctl.conf”中，即使主机重启，配置依然能生效。

```
net.ipv4.neigh.default.gc_thresh1 = 512
net.ipv4.neigh.default.gc_thresh2 = 2048
net.ipv4.neigh.default.gc_thresh3 = 4096
```

9.34.15 为什么主 NameNode 重启后系统出现双备现象

问题

为什么主 NameNode 重启后系统出现双备现象？

出现该问题时，查看 Zookeeper 和 ZKFC 的日志，发现 Zookeeper 服务端与客户端（ZKFC）通信时所使用的 session 不一致，Zookeeper 服务端的 sessionId 为 0x164cb2b3e4b36ae4，ZKFC 的 sessionId 为 0x144cb2b3e4b36ae4。这意味着 Zookeeper 服务端与客户端（ZKFC）之间数据交互失败。

Zookeeper 日志，如下所示：

```
2015-04-15 21:24:54,257 | INFO | CommitProcessor:22 | Established session
0x164cb2b3e4b36ae4 with negotiated timeout 45000 for client /192.168.0.117:44586 |
org.apache.zookeeper.server.ZooKeeperServer.finishSessionInit(ZooKeeperServer.java:
623)
2015-04-15 21:24:54,261 | INFO | NIOServerCxn.Factory:192-168-0-
114/192.168.0.114:2181 | Successfully authenticated client:
authenticationID=hdfs/hadoop@<系统域名>; authorizationID=hdfs/hadoop@<系统域名>. |
org.apache.zookeeper.server.auth.SaslServerCallbackHandler.handleAuthorizeCallback(
SaslServerCallbackHandler.java:118)
```

```
2015-04-15 21:24:54,261 | INFO | NIOServerCxn.Factory:192-168-0-
114/192.168.0.114:2181 | Setting authorizedID: hdfs/hadoop@<系统域名> |
org.apache.zookeeper.server.auth.SaslServerCallbackHandler.handleAuthorizeCallback(
SaslServerCallbackHandler.java:134)
2015-04-15 21:24:54,261 | INFO | NIOServerCxn.Factory:192-168-0-
114/192.168.0.114:2181 | adding SASL authorization for authorizationID:
hdfs/hadoop@<系统域名> |
org.apache.zookeeper.server.ZooKeeperServer.processSasl(ZooKeeperServer.java:1009)
2015-04-15 21:24:54,262 | INFO | ProcessThread(sid:22 cport:-1): | Got user-level
KeeperException when processing sessionid:0x164cb2b3e4b36ae4 type:create cxid:0x3
zxid:0x20009fafc txntype:-1 reqpath:n/a Error Path:/hadoop-
ha/hacluster/ActiveStandbyElectorLock Error:KeeperErrorCode = NodeExists for
/hadoop-ha/hacluster/ActiveStandbyElectorLock |
org.apache.zookeeper.server.PrepRequestProcessor.pRequest(PrepRequestProcessor.java
:648)
```

ZKFC 日志，如下所示：

```
2015-04-15 21:24:54,237 | INFO | main-SendThread(192-168-0-114:2181) | Socket
connection established to 192-168-0-114/192.168.0.114:2181, initiating session |
org.apache.zookeeper.ClientCnxn$SendThread.primeConnection(ClientCnxn.java:854)
2015-04-15 21:24:54,257 | INFO | main-SendThread(192-168-0-114:2181) | Session
establishment complete on server 192-168-0-114/192.168.0.114:2181, sessionid =
0x144cb2b3e4b36ae4 , negotiated timeout = 45000 |
org.apache.zookeeper.ClientCnxn$SendThread.onConnected(ClientCnxn.java:1259)
2015-04-15 21:24:54,260 | INFO | main-EventThread | EventThread shut down |
org.apache.zookeeper.ClientCnxn$EventThread.run(ClientCnxn.java:512)
2015-04-15 21:24:54,262 | INFO | main-EventThread | Session connected. |
org.apache.hadoop.ha.ActiveStandbyElector.processWatchEvent(ActiveStandbyElector.ja
va:547)
2015-04-15 21:24:54,264 | INFO | main-EventThread | Successfully authenticated to
ZooKeeper using SASL. |
org.apache.hadoop.ha.ActiveStandbyElector.processWatchEvent(ActiveStandbyElector.ja
va:573)
```

回答

- 原因分析

  NameNode 的主节点重启后，它原先在 Zookeeper 上建立的临时节点（/hadoop-ha/hacluster/ActiveStandbyElectorLock）就会被清理。同时，NameNode 备节点发现这个信息后进行抢占希望升主，所以它重新在 Zookeeper 上建立了 active 的节点/hadoop-ha/hacluster/ActiveStandbyElectorLock。但是 NameNode 备节点通过客户端（ZKFC）与 Zookeeper 建立连接时，由于网络问题、CPU 使用率高、集群压力大等原因，出现了客户端（ZKFC）的 session（0x144cb2b3e4b36ae4）与 Zookeeper 服务端的 session（0x164cb2b3e4b36ae4）不一致的问题，这就导致了 NameNode 备节点的 watcher 没有感知到自己已经成功建立临时节点，依然认为自己还是备。而 NameNode 主节点启动后，发现/hadoop-ha/hacluster 目录下已经有 active 的节点，所以也无法升主，导致两个节点都为备。

- 解决方法

  建议通过在 FusionInsight Manager 界面上重启 HDFS 的两个 ZKFC 加以解决。

9.34.16 HDFS 执行 Balance 时被异常停止，再次执行 Balance 会失败

问题

在 HDFS 客户端启动一个 Balance 进程，该进程被异常停止后，再次执行 Balance 操作，操作会失败。

回答

通常，HDFS 执行 Balance 操作结束后，会自动释放“/system/balancer.id”文件，可再次正常执行 Balance。

但在上述场景中，由于第一次的 Balance 操作是被异常停止的，所以第二次进行 Balance 操作时，“/system/balancer.id”文件仍然存在，则会触发 ***append /system/balancer.id*** 操作，进而导致 Balance 操作失败。

- 如果“/system/balancer.id”文件的释放时间超过了软租期 60s，则第二次执行 Balance 操作的客户端的 append 操作会抢占租约，此时最后一个 block 处于 under construction 或者 under recovery 状态，会触发 block 的恢复操作，那么“/system/balancer.id”文件必须等待 block 恢复完成才能关闭，所以此次 append 操作失败。

  append /system/balancer.id 操作失败后，会向客户端抛出 RecoveryInProgressException 异常：

  ```
  org.apache.hadoop.ipc.RemoteException(org.apache.hadoop.protocol.RecoveryInProgressException): Failed to APPEND_FILE /system/balancer.id for DFSClient because lease recovery is in progress. Try again later.
  ```

- 如果该文件的释放时间没有超过默认设置 60s，原有客户端会继续持有该租约，则会抛出 AlreadyBeingCreatedException 异常，实际上向客户端返回的是 null，导致客户端出现如下异常：

  ```
  java.io.IOException: Cannot create any NameNode Connectors.. Exiting...
  ```

可通过以下方法避免上述问题：

- 方案 1：等待硬租期超过 1 小时后，原有客户端释放租约，再执行第二次 Balance 操作。
- 方案 2：执行第二次 Balance 操作之前删除“/system/balancer.id”文件。

9.34.17 IE 浏览器访问 HDFS 原生 UI 界面失败，显示无法显示此页

问题

通过 IE 9、IE 10 和 IE 11 浏览器访问 HDFS 的原生 UI 界面，偶尔出现访问失败情况。

现象

访问页面失败，浏览器无法显示此页，如下图所示：

原因

IE 9、IE 10、IE 11 浏览器的某些版本在处理 SSL 握手有问题导致访问失败。

解决方法

重新刷新页面即可。

9.34.18 EditLog 不连续导致 NameNode 启动失败

问题

在 JournalNode 节点有断电，数据目录磁盘占满，网络异常时，会导致 JournalNode 上的 EditLog 不连续。此时如果重启 NameNode，很可能会失败。

现象

重启 NameNode 会失败。在 NameNode 运行日志中会报如下的错误：

```
2019-11-08 16:30:28,399 | ERROR | main | Failed to start namenode. | NameNode.java:1732
java.io.IOException: There appears to be a gap in the edit log.  We expected txid 13698019, but got txid 13698088.
        at org.apache.hadoop.hdfs.server.namenode.MetaRecoveryContext.editLogLoaderPrompt(MetaRecoveryContext.java:94)
        at org.apache.hadoop.hdfs.server.namenode.FSEditLogLoader.loadEditRecords(FSEditLogLoader.java:278)
        at org.apache.hadoop.hdfs.server.namenode.FSEditLogLoader.loadFSEdits(FSEditLogLoader.java:188)
        at org.apache.hadoop.hdfs.server.namenode.FSImage.loadEdits(FSImage.java:924)
        at org.apache.hadoop.hdfs.server.namenode.FSImage.loadFSImage(FSImage.java:771)
        at org.apache.hadoop.hdfs.server.namenode.FSImage.recoverTransitionRead(FSImage.java:331)
        at org.apache.hadoop.hdfs.server.namenode.FSNamesystem.loadFSImage(FSNamesystem.java:1108)
        at org.apache.hadoop.hdfs.server.namenode.FSNamesystem.loadFromDisk(FSNamesystem.java:727)
        at org.apache.hadoop.hdfs.server.namenode.NameNode.loadNamesystem(NameNode.java:638)
        at org.apache.hadoop.hdfs.server.namenode.NameNode.initialize(NameNode.java:700)
        at org.apache.hadoop.hdfs.server.namenode.NameNode.<init>(NameNode.java:943)
        at org.apache.hadoop.hdfs.server.namenode.NameNode.<init>(NameNode.java:916)
        at org.apache.hadoop.hdfs.server.namenode.NameNode.createNameNode(NameNode.java:1655)
        at org.apache.hadoop.hdfs.server.namenode.NameNode.main(NameNode.java:1725)
```

解决方法

1. 找到重启前的主 NameNode，进入其数据目录（查看配置项“dfs.namenode.name.dir”可获取，例如/srv/BigData/namenode/current），得到最新的 FSImage 文件的序号。一般如下：

```
-rw-------. 1 omm wheel     574 Oct  2 01:12 edits_0000000000013259401-0000000000013
-rw-------. 1 omm wheel     575 Oct  2 01:13 edits_0000000000013259409-0000000000013
-rw-------. 1 omm wheel      42 Oct  2 01:13 edits_0000000000013259417-0000000000013
-rw-------. 1 omm wheel 1048576 Nov  8 16:01 edits_inprogress_0000000000013698088
-rw-------. 1 omm wheel  314803 Nov  8 15:53 fsimage_0000000000013698018
-rw-------. 1 omm wheel      62 Nov  8 15:53 fsimage_0000000000013698018.md5
-rw-------. 1 omm wheel  314803 Nov  8 15:56 fsimage_0000000000013698050
-rw-------. 1 omm wheel      62 Nov  8 15:56 fsimage_0000000000013698050.md5
-rw-------. 1 omm wheel  314803 Nov  8 15:59 fsimage_0000000000013698066
-rw-------. 1 omm wheel      62 Nov  8 15:59 fsimage_0000000000013698066.md5
-rw-------. 1 omm wheel       9 Oct  2 01:13 seen_txid
-rw-------. 1 omm wheel     187 Nov  8 15:59 VERSION
```

2. 查看各 JournalNode 的数据目录（查看配置项“dfs.journalnode.edits.dir”可获取，例如/srv/BigData/journalnode/hacluster/current），查看序号从第一部获取到的序号开始的 edits 文件，看是否有不连续的情况（即前一个 edits 文件的最后一个序号和 后一个 edits 文件的第一个序号 不是连续的，如下图中的 edits_0000000000013259231-0000000000013259237 就和后一个 edits_0000000000013259239-0000000000013259246 就是不连续的）。

```
-rw-------. 1 omm wheel     576 Oct  2 00:41 edits_0000000000013259151-0000000000013259158
-rw-------. 1 omm wheel     575 Oct  2 00:43 edits_0000000000013259159-0000000000013259166
-rw-------. 1 omm wheel     576 Oct  2 00:43 edits_0000000000013259167-0000000000013259174
-rw-------. 1 omm wheel     575 Oct  2 00:45 edits_0000000000013259175-0000000000013259182
-rw-------. 1 omm wheel     575 Oct  2 00:45 edits_0000000000013259183-0000000000013259190
-rw-------. 1 omm wheel     576 Oct  2 00:47 edits_0000000000013259191-0000000000013259198
-rw-------. 1 omm wheel     575 Oct  2 00:48 edits_0000000000013259199-0000000000013259206
-rw-------. 1 omm wheel     575 Oct  2 00:49 edits_0000000000013259207-0000000000013259214
-rw-------. 1 omm wheel     575 Oct  2 00:50 edits_0000000000013259215-0000000000013259222
-rw-------. 1 omm wheel     573 Oct  2 00:51 edits_0000000000013259223-0000000000013259230
-rw-------. 1 omm wheel     571 Oct  2 00:52 edits_0000000000013259231-0000000000013259237
-rw-------. 1 omm wheel     576 Oct  2 00:53 edits_0000000000013259239-0000000000013259246
-rw-------. 1 omm wheel     575 Oct  2 00:54 edits_0000000000013259247-0000000000013259254
-rw-------. 1 omm wheel     576 Oct  2 00:55 edits_0000000000013259255-0000000000013259262
-rw-------. 1 omm wheel      42 Oct  2 00:56 edits_0000000000013259263-0000000000013259264
-rw-------. 1 omm wheel    1107 Oct  2 00:57 edits_0000000000013259265-0000000000013259278
-rw-------. 1 omm wheel      42 Oct  2 00:58 edits_0000000000013259279-0000000000013259280
-rw-------. 1 omm wheel    1109 Oct  2 00:59 edits_0000000000013259281-0000000000013259294
-rw-------. 1 omm wheel      42 Oct  2 01:00 edits_0000000000013259295-0000000000013259296
-rw-------. 1 omm wheel    1299 Oct  2 01:01 edits_0000000000013259297-0000000000013259312
-rw-------. 1 omm wheel     260 Oct  2 01:02 edits_0000000000013259313-0000000000013259316
-rw-------. 1 omm wheel     984 Oct  2 01:03 edits_0000000000013259317-0000000000013259328
-rw-------. 1 omm wheel     572 Oct  2 01:04 edits_0000000000013259329-0000000000013259336
-rw-------. 1 omm wheel     575 Oct  2 01:05 edits_0000000000013259337-0000000000013259344
-rw-------. 1 omm wheel     983 Oct  2 01:06 edits_0000000000013259345-0000000000013259356
```

3. 如果有这种不连续的 edits 文件，则需要查看其它的 JournalNode 的数据目录或 NameNode 数据目录中，有没有连续的该序号相关的连续的 edits 文件。如果可以找到，复制一个连续的片段到该 JournalNode。
4. 如此把所有的不连续的 edits 文件全部都修复。
5. 重启 NameNode，观察是否成功。如还是失败，请联系技术支持。

10 使用 HetuEngine

10.1 从零开始使用 HetuEngine

本章节指导用户从零开始使用 HetuEngine 对接 Hive 数据源，并通过 HetuEngine 查询本集群 Hive 数据源的数据库表。

前提条件

- 集群已安装 HetuEngine、Hive 服务且运行正常。
- 如集群已启用 Kerberos 认证，需提前创建 HetuEngine 的用户并授予相关权限，具体操作请参见 10.3 创建 HetuEngine 用户。且需要通过 Ranger 为该用户配置操作数据源的数据库、表、列的管理权限，具体操作请参考 20.14 添加 HetuEngine 的 Ranger 访问权限策略。
- 已安装集群客户端，例如安装目录为“/opt/client”。

操作步骤

创建并启动 HetuEngine 计算实例。

1. 使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。
2. 在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。
3. 在实例列表上方单击“创建配置”，在“配置实例”弹框内填写参数。
   a. 在“基本配置”区域中，选择“所属资源队列”为用户所关联的租户队列，配置“实例部署超时时间(秒)”。
   b. 根据实际资源规划配置“Coordinator 容器资源配置”、“Worker 容器资源配置”以及“高级配置”区域相关参数，参数详情可参考 10.4 创建 HetuEngine 计算实例章节或保持默认值即可。

须知

创建计算实例时的默认配置只申请极少量的资源，仅供基本功能测试。用户需要根据实际业务需求和可用资源进行参数配置，可参考 10.5.1 配置资源组和 10.5.2 配置 Worker 节点数量。

c. 配置完成后勾选“立即启动”，等待实例配置完成。

步骤 1 登录安装有 HetuEngine 客户端的节点，执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 2 执行以下命令，配置环境变量。

source bigdata_env

步骤 3 认证或指定用户。

- 安全模式集群：执行以下命令认证用户

  kinit *HetuEngine 组件操作用户*

  例如：

  kinit hetu_test

  根据提示输入用户密码，首次登录需重置密码。
- 普通模式集群：执行以下命令指定用户

  hetu-cli --user *HetuEngine 组件操作用户*

  例如：

  hetu-cli --user hetu_test

步骤 4 执行以下命令，登录数据源的 catalog。支持通过使用“--mode”参数来选择通过 ZooKeeper 连接或 HSFabric 连接方式登录数据源。

- 通过 ZooKeeper 连接（不指定“--mode”参数则默认为该方式）

  hetu-cli --catalog *数据源名称*

  例如执行以下命令：

  hetu-cli --catalog hive
- 通过 HSFabric 连接（需确保已安装 HSFabric 实例）

  hetu-cli --mode hsfabric --catalog *数据源名称*

  例如执行以下命令：

  hetu-cli --mode hsfabric --catalog hive

说明

本集群的 Hive 数据源名称默认为“hive”。如需对接集群外部的数据源，可参考 10.9 配置数据源进行操作，在 HSConsole 界面配置外部数据源。

```
java -
Djava.security.auth.login.config=/opt/client/HetuEngine/hetuserver/conf/jaas.conf -
Dzookeeper.sasl.clientconfig=Client -Dzookeeper.auth.type=kerberos -
Djava.security.krb5.conf=/opt/client/KrbClient/kerberos/var/krb5kdc/krb5.conf -
Djava.util.logging.config.file=/opt/client/HetuEngine/hetuserver/conf/hetuserver-
client-logging.properties -jar /opt/client/HetuEngine/hetuserver/jars/hetu-cli-*-
executable.jar --catalog hive --deployment-mode on_yarn --server
```

```
https://10.112.17.189:24002,10.112.17.228:24002,10.112.17.150:24002?serviceDiscover
yMode=zooKeeper&zooKeeperNamespace=hsbroker --krb5-remote-service-name HTTP --krb5-
config-path /opt/client/KrbClient/kerberos/var/krb5kdc/krb5.conf
hetuengine>
```

步骤 5 执行以下命令，查看数据库信息：

show schemas;

```
    Schema
--------------------
 default
 information_schema
(2 rows)
Query 20200730_080535_00002_ct2eg, FINISHED, 3 nodes
Splits: 36 total, 36 done (100.00%)
0:02 [2 rows, 35B] [0 rows/s, 15B/s]
```

----结束

10.2 HetuEngine 权限管理

10.2.1 HetuEngine 权限管理概述

MRS 3.3.0 以前版本，HetuEngine 在安全模式集群下支持权限管控，在非安全模式下不会进行权限管控。

MRS 3.3.0 及以后版本，HetuEngine 在集群已启用 Kerberos 认证（安全模式）时提供了如下两种权限管控方式，默认使用 Ranger 权限模型；在集群未启用 Kerberos 认证（普通模式）时提供了 Ranger 权限模型，默认未开启 Ranger 权限模型：

在安全模式下，HetuEngine 提供了如下两种权限管控方式，默认使用 Ranger 权限模型：

- Ranger 权限管控方式，可参考 10.2.2 HetuEngine 基于 Ranger 权限管控。
- Metastore 权限管控方式，可参考 10.2.3 HetuEngine 基于 MetaStore 权限管控。

Ranger 和 MetaStore 的差异见下表，两者都支持用户、用户组以及角色的鉴权。

表10-1 Ranger 和 MetaSore 差异

权限管控方式	权限模型	支持的数据源	描述
Ranger	PBAC	Hive、HBase、Elasticsearch、GaussDB、HetuEngine、ClickHouse	支持行过滤、列脱敏以及更细粒度的权限管控
MetaStore	RBAC	Hive	-

权限原则与约束

- HetuEngine 访问同集群数据源。

  HetuEngine 启用 Ranger 鉴权，则统一使用 Ranger 的 PBAC 权限策略做鉴权。

  HetuEngine 停用 Ranger 鉴权，则统一使用 MetaStore 的 RBAC 权限策略做鉴权。
- HetuEngine 访问跨集群数据源。

  同时受 HetuEngine 端权限和数据源端权限管控（Hive 场景下，依赖于 HDFS）。
- 查询视图时，仅需给目标视图授予 select 权限即可；使用视图联表查询时，需要同时给两者授予 select 权限。

说明

HetuEngine 服务在切换权限控制类型时，需要重启整个 HetuEngine 服务，包括 HSConsole 页面上正在运行的 HetuEngine 计算实例。

10.2.2 HetuEngine 基于 Ranger 权限管控

新安装集群默认采用 Ranger 进行鉴权，对于历史版本升级集群或者手动停用了 Ranger 鉴权的集群，可参考启用 Ranger 鉴权重新启用 Ranger 鉴权。启用 Ranger 鉴权的集群，管理员可通过 Ranger 为 HetuEngine 用户配置操作数据源的数据库、表、列的管理权限，详情请参考 20.14 添加 HetuEngine 的 Ranger 访问权限策略。

启用 Ranger 鉴权

登录 FusionInsight Manager。

步骤 1 集群未启用 Kerberos 认证（普通模式）时需添加“ranger.usersync.sync.source”参数，集群已启用 Kerberos 认证（安全模式）不执行此步骤。适用于 MRS 3.3.0 及以后版本。

1. 选择“集群 > 服务 > Ranger > 配置 > 全部配置”。
2. 搜索参数“ranger.usersync.config.expandor”，在该参数的值中填入自定义参数，名称为“ranger.usersync.sync.source”，值为“ldap”并保存。
3. 选择“概览 > 更多 > 重启服务”，输入密码，根据界面提示重启 Ranger。

步骤 2 选择“集群 > 服务 > HetuEngine > 更多 > 启用 Ranger 鉴权”。

步骤 3 选择“集群 > 服务 > HetuEngine > 更多 > 重启服务”。

步骤 4 在 HSConsole 页面重启计算实例，具体请参见 10.5 管理 HetuEngine 计算实例。

----结束

10.2.3 HetuEngine 基于 MetaStore 权限管控

约束：只适用于 Hive 类型数据源。

HetuEngine 多个集群组网进行协同计算时，元数据由管理集群集中管理，计算在所有集群进行，访问 HetuEngine 集群用户的权限需要在管理集群进行配置，并在所有计算实例添加拥有 Hive 用户组权限的同名用户。

启用 MetaStore 鉴权

登录 FusionInsight Manager。

步骤 1 选择“集群 > 服务 > HetuEngine > 更多 > 停用 Ranger 鉴权”。

步骤 2 选择“集群 > 服务 > HetuEngine > 更多 > 重启服务”。

步骤 3 在 HSConsole 页面重启计算实例，具体请参见•HetuEngine 计算实例重启。

----结束

MetaStore 权限

类似于 Hive，HetuEngine 也是建立在 Hadoop 上的数据仓库框架，提供类似 SQL 的结构化数据。

集群中的各类权限需要先授予角色，然后将用户或者用户组与角色绑定。用户只有绑定角色或者加入绑定角色的用户组，才能获得权限。

权限管理介绍

HetuEngine 的权限管理是指 HetuEngine 中管理用户操作数据库的权限系统，以保证不同用户之间操作数据库的独立性和安全性。如果一个用户想操作另一个用户的表、数据库等，需要获取相应的权限才能进行操作，否则会被拒绝。

HetuEngine 权限管理部分集成了 Hive 权限管理的功能。使用 HetuEngine 权限管理功能需要使用 Hive 的 MetaStore 服务和页面上的赋权功能。

- 页面赋权：HetuEngine 仅支持页面赋权的方式。在 Manager 的“系统 > 权限”中，可以进行用户、用户组和角色的添加/删除操作，可以对某个角色进行赋权/撤权。
- 服务获权并判断：当接收到客户端的 DDL、DML 的 SQL 命令时，HetuEngine 服务会向 MetaStore 服务获取客户端用户对数据库信息的已有权限，并检查是否包含了所需的所有权限，如果是则继续执行，否则拒绝该用户的操作。当通过了 MetaStore 的权限检查后，还需进行 HDFS 的 ACLs 权限检查。

HetuEngine 权限模型

用户使用 HetuEngine 服务进行 SQL 操作，必须对 HetuEngine 数据库和表（含外表和视图）拥有相应的权限。完整的 HetuEngine 权限模型由元数据权限与 HDFS 文件权限组成。使用数据库或表时所需要的各种权限都是 HetuEngine 权限模型中的一种。

- 元数据权限

  元数据权限即在元数据层上进行权限控制，与传统关系型数据库类似，HetuEngine 数据库包含“建表”和“查询”权限，表和列包含“查询”、“插入”、“UPDATE”和“删除”权限。HetuEngine 中还包含拥有者权限“OWNERSHIP”和集群管理员权限“ADMIN”。

- 数据文件权限，即 HDFS 文件权限

  HetuEngine 的数据库、表对应的文件保存在 HDFS 中。默认创建的数据库或表保存在 HDFS 目录“/user/hive/warehouse”。系统自动以数据库名称和数据库中表的

名称创建子目录。访问数据库或者表，需要在 HDFS 中拥有对应文件的权限，包含“读”、“写”和“执行”权限。

用户对 HetuEngine 数据库或表执行不同操作时，需要关联不同的元数据权限与 HDFS 文件权限。例如，对 HetuEngine 数据表执行查询操作，需要关联元数据权限“查询”，以及 HDFS 文件权限“读”和“执行”。

使用 FusionInsight Manager 界面图形化的角色管理功能来管理 HetuEngine 数据库和表的权限，只需要设置元数据权限，系统会自动关联 HDFS 文件权限，减少界面操作，提高效率。

HetuEngine 使用场景及对应权限

用户通过 HetuEngine 服务创建数据库需要加入 Hive 组，不需要角色授权。用户在 Hive 和 HDFS 中对自己创建的数据库或表拥有完整权限，可直接创建表、查询数据、删除数据、插入数据、更新数据以及授权他人访问表与对应 HDFS 目录与文件。

如果用户访问别人创建的表或数据库，需要授予权限。所以根据 HetuEngine 使用场景的不同，用户需要的权限可能也不相同。

表10-2 HetuEngine 使用场景

主要场景	用户需要的权限
使用 HetuEngine 表、列或数据库	使用其他用户创建的表、列或数据库，不同的场景需要不同的权限，例如： • 创建表，需要“建表”权限。 • 查询数据，需要“查询”权限。 • 插入数据，需要“插入”权限。

在一些特殊 HetuEngine 使用场景下，需要单独设置其他权限。

表10-3 HetuEngine 授权注意事项

场景	用户需要的权限
创建 HetuEngine 数据库、表、外表，或者为已经创建的表或外表添加分区，且 Hive 用户指定数据文件保存在“/user/hive/warehouse”以外的 HDFS 目录。	需要此目录已经存在，客户端用户是目录的属主，且用户对目录拥有“读”、“写”和“执行”权限。同时用户对此目录上层的每一级目录都拥有“读”和“执行”权限。
操作 Hive 中所有的数据库和表。	需加入到 supergroup 用户组，并且授予“ADMIN”权限。

配置表、列和数据库的权限

启用 MetaStore 鉴权后，使用 HetuEngine 操作表或者数据库时，如果用户访问别人创建的表或数据库，需要授予对应的权限。为了实现更严格权限控制，HetuEngine 也支持列级别的权限控制。如果要访问别人创建的表上某些列，需要授予列权限。

说明

- 在权限管理中，为了方便用户使用，授予数据库下表的任意权限将自动关联该数据库目录的 HDFS 权限。为了避免产生性能问题，取消表的任意权限，系统不会自动取消数据库目录的 HDFS 权限，但对应的用户只能登录数据库和查看表名。
- 若为角色添加或删除数据库的查询权限，数据库中的表也将自动添加或删除查询权限。此机制为 Hive 实现，HetuEngine 与 Hive 保持一致。
- HetuEngine 不支持 struct 数据类型中列名称含有特殊字符（除字母、数字、下划线外的其他字符）。如果 struct 类型中列名称含有特殊字符，在 FusionInsight Manager 的“角色”页面进行授权时，该列将无法正确显示。

操作步骤：

登录 FusionInsight Manager 页面。

步骤 1 选择“系统 > 权限 > 角色”。

步骤 2 单击“添加角色”，输入“角色名称”和“描述”。

步骤 3 在“配置资源权限”列表，选择“*待操作的集群名称* > Hive”，设置角色权限，请参见表 10-4。

- “Hive 管理员权限”：Hive 管理员权限。
- “Hive 读写权限”：Hive 数据表管理权限，可设置与管理已创建的表的数据操作权限。

说明

- Hive 角色管理支持授予管理员权限、访问表和视图的权限，不支持数据库的授权。
- Hive 管理员权限不支持管理 HDFS 的权限。
- 如果数据库中的表或者表中的文件数量比较多，在授权时可能需要等待一段时间。例如表的文件数量为 1 万时，可能需要等待 2 分钟。

表10-4 设置角色

任务场景	角色授权操作
设置在默认数据库中，查询其他用户表的权限	1. 在“视图名称”的表格中单击“Hive 读写权限”。 2. 在数据库列表中单击指定的数据库名称，显示数据库中的表。 3. 在指定表的“权限”列，勾选“查询”。
设置在默认数据库中，导入数据到其他用户表的权限	1. 在“视图名称”的表格中单击“Hive 读写权限”。 2. 在数据库列表中单击指定的数据库名称，显示数据库中的表。 3. 在指定表的“权限”列，勾选“删除”和“插入”。

单击“确定”完成，返回“角色”页面。

说明

角色创建完成后，可参考 10.3 创建 HetuEngine 用户创建 HetuEngine 用户，并为其赋予相关角色权限。

----结束

SQL 语句在 HetuEngine 中进行处理对应的权限要求如表 10-5 所示。

表10-5 使用 HetuEngine 表、列或数据

操作场景	用户需要的权限
DESCRIBE TABLE	查询（Select）
ANALYZE TABLE	查询（Select）、插入（Insert）
SHOW COLUMNS	查询（Select）
SHOW TABLE STATUS	查询（Select）
SHOW TABLE PROPERTIES	查询（Select）
SELECT	查询（Select）
EXPLAIN	查询（Select）
CREATE VIEW	查询（Select）、Select 授权（Grant Of Select）、建表（Create）
CREATE TABLE	建表（Create）
ALTER TABLE ADD PARTITION	插入（Insert）
INSERT	插入（Insert）
INSERT OVERWRITE	插入（Insert）、删除（Delete）
ALTER TABLE DROP PARTITION	需要授予 Table 级别的修改（Alter）、删除（Delete）和 Column 级别的查询（Select）权限
ALTER DATABASE	Hive 管理员权限（Hive Admin Privilege）

10.2.4 HetuEngine 使用代理用户鉴权

适用于 MRS 3.3.0 及以后版本。

HetuEngine 支持使用 FusionInsight Manager 用户认证时通过客户自有用户（代理用户）使用 Ranger 鉴权的能力。即在使用 HetuEngine 客户端时，通过**--session-user** 来指定代理用户。

创建认证用户或代理用户请参考 10.3 创建 HetuEngine 用户。

启用 Ranger 鉴权并为代理用户配置操作数据源的数据库、表、列的管理权限，具体操作请参考 20.14 添加 HetuEngine 的 Ranger 访问权限策略。

- 集群已启用 Kerberos 认证（安全模式）
  a. 使用 **kinit** 指定认证用户（需为 HetuEngine 管理员用户，并额外添加 **supergroup** 用户组才能代理其他用户鉴权），如 **hetuadmin1**。

     kinit hetuadmin1

     根据提示输入用户密码，首次登录需重置密码。
  b. 再使用**--session-user** 指定代理用户，如 **user1**。

     hetu-cli --session-user user1
- 集群未启用 Kerberos 认证（普通模式）

  使用**--user** 指定认证用户（需拥有 **hetuuser** 用户组才能代理其他用户鉴权），如 **user**；使用**--session-user** 指定代理用户，如 **user1**。

  hetu-cli --user user --session-user user1

说明

该功能不适用于 HiveMetastore 数据源鉴权与多用户映射共存的场景。

10.3 创建 HetuEngine 用户

操作场景

安全模式的集群，在使用 HetuEngine 服务前，需集群管理员创建用户并指定其操作权限以满足业务使用需求。

HetuEngine 用户分为管理员用户和普通用户，系统默认的 HetuEngine 管理员用户组为“hetuadmin”，HetuEngine 普通用户对应用户组为“hetuuser”。

- 关联了“hetuadmin”用户组的用户可获得 HetuEngine 的 HSConsole WebUI 界面和 HetuEngine 计算实例 WebUI 的运维管理员权限。
- 关联了“hetuuser”用户组的用户可获得 SQL 执行权限。

启用了 Ranger 鉴权时，如果用户创建后需要继续为用户配置操作数据源的数据库、表、列的管理权限，请参考 20.14 添加 HetuEngine 的 Ranger 访问权限策略。

前提条件

在使用 HetuEngine 服务请确保已提前规划并创建 HetuEngine 用户待关联的租户。

说明

普通用户只能操作和查看自己关联租户对应的集群信息。

操作步骤

创建 HetuEngine 管理员用户

登录 FusionInsight Manager。

步骤 1 选择“系统 > 权限 > 用户 > 添加用户”。

步骤 2 填写“用户名”，例如“hetu_admin”。

步骤 3 设置“用户类型”，选择“人机”。

步骤 4 填写“密码”和“确认密码”。

步骤 5 在“用户组”，单击“添加”，为该用户添加“hive”、“hetuadmin”、“hadoop”、“hetuuser”、“yarnviewgroup”用户组。

步骤 6 在“主组”下拉列表，选择“hive”作为主组。

步骤 7 在“角色”，单击“添加”，为该用户绑定“default”、“System_administrator”以及待关联的租户角色权限。

步骤 8 单击“确定”，完成 HetuEngine 管理员用户创建。

----结束

创建 HetuEngine 普通用户

登录 FusionInsight Manager。

步骤 9 选择“系统 > 权限 > 用户 > 添加用户”。

步骤 10 填写“用户名”，例如“hetu_test”。

步骤 11 设置“用户类型”，选择“人机”。

步骤 12 填写“密码”和“确认密码”。

步骤 13 在“用户组”，单击“添加”，为该用户添加“hetuuser”用户组。

说明

- MRS 集群中 HetuEngine 服务默认启用了 Ranger 鉴权，HetuEngine 普通用户只需关联“hetuuser”用户组即可。如果关闭了 Ranger 鉴权，必须给用户同时关联“hive”用户组并将其设置为主组，否则可能无法正常使用 HetuEngine 服务。
- 启用了 Ranger 鉴权时，如果用户创建后需要继续为用户配置操作数据源的数据库、表、列的管理权限，请参考 20.14 添加 HetuEngine 的 Ranger 访问权限策略。

步骤 14 在“角色”，单击“添加”，为该用户绑定“default”或者待关联的租户角色权限。

步骤 15 单击“确定”，完成 HetuEngine 普通用户创建。

----结束

10.4 创建 HetuEngine 计算实例

操作场景

本章节指导用户新创建 HetuEngine 计算实例。计算实例创建成功后，停止集群前需手动停止计算实例；重启集群后，要使用集群中的计算实例，需要手动启动计算实例。

单个租户可以创建多个计算实例，多个计算实例负载均衡，可以提高性能及容错能力（MRS 3.3.0 及以后版本）。

前提条件

- 已创建用于访问 HetuEngine WebUI 界面的用户，如 **hetu_user**，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。
- 已在待操作集群创建所需租户。请确保修改 HetuEngine 计算实例配置时，对应的租户有足够的内存和 CPU 资源。

  说明

  - 创建 HetuEngine 计算实例时必须使用“叶子租户”类型的租户，只有叶子租户的队列才能提交 Yarn 任务。
  - 为了避免资源竞争带来的不确定性因素，建议为 HetuEngine 使用的租户创建独立资源池。
- HetuEngine 计算实例启动依赖 Python3，需确保集群所有节点已安装 Python3，并在“/usr/bin/”目录下添加 Python 软连接，可参考 10.15.5 如何处理计算实例启动失败报错 Python 不存在。

操作步骤

使用 **hetu_user** 登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 在实例列表上方单击“创建配置”，在“配置实例”弹框内填写参数。

1. 配置“基本配置”，参数配置请参考表 10-6。

表10-6 基本配置说明

参数	描述	取值样例
所属资源队列	实例所属资源队列，一个资源队列下只能创建一个计算实例。	在“所属资源队列”下拉列表中选取。
实例部署超时时间(秒)	通过 Yarn Service 部署启动计算实例的超时时间。从启动计算实例开始计时，当超过该时间后，如果计算实例仍在“创建中”或“启动中”，则该计算实例状态会显示为“错误”，同时会停止 Yarn 上正在创建或启动中的计算实例。	300 取值范围：1~2147483647

参数	描述	取值样例
实例数量（MRS 3.3.0 及以后版本）	在当前所属租户下创建的计算实例个数。	1 取值范围：1-50

2. 配置“Coordinator 容器资源配置”，参数配置请参考表 10-7。

表10-7 Coordinator 容器资源配置参数说明

参数	描述	取值样例
容器内存(MB)	Yarn 分配给计算实例 Coordinator 的单个 Container 的内存大小，单位：MB。	默认值：5120 取值范围：1~2147483647
vcore	Yarn 分配给计算实例 Coordinator 的单个 Container 的 CPU(vcore)数量。	默认值：1 取值范围：1~2147483647
数量	Yarn 分配给计算实例 Coordinator 的 Container 的数量。	默认值：2 取值范围：1~3
JVM	登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine > 配置”，在“全部配置”页签搜索“extraJavaOptions”，属于“coordinator.jvm.config”参数文件内该参数的值即为 JVM 的参数取值。	-

3. 配置“Worker 容器资源配置”，参数配置请参考表 10-8。

表10-8 Worker 容器资源配置参数说明

参数	描述	取值样例
容器内存(MB)	Yarn 分配给计算实例 Worker 的单个 Container 的内存大小，单位：MB。	默认值：10240 取值范围：1~2147483647
vcore	Yarn 分配给计算实例 Worker 的单个 Container 的 CPU(vCore)数量。	默认值：1 取值范围：1~2147483647
数量	Yarn 分配给计算实例 Worker 的 Container 的数量。	默认值：2 取值范围：1~256
JVM	登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine > 配置”，在“全部配置”页签搜索“extraJavaOptions”，属于	-

参数	描述	取值样例
	“worker.jvm.config”参数文件内该参数的值即为 JVM 的参数取值。	

4. 配置“高级配置”参数，参数配置请参考表 10-9。

表10-9 高级配置参数说明

参数	描述	取值样例
查询内存占比	节点查询内存占 jvm 内存的比例，默认值 0.7。当参数等于 0 时计算功能关闭，且 JVM 配置中-Xmx 值需满足大于或者等于 Coordinator 或者 Worker 配置的 memory.heap-headroom-per-node 与 query.max-memory-per-node 之和。	0.7
是否开启动态伸缩	若开启动态伸缩，可以在不重启实例的情况下，增加或者减少 Worker 数量；开启后可能会影响实例性能。开启动态伸缩参数介绍见 10.5.2 配置 Worker 节点数量章节。	-
是否用作维护实例	如果要启动物化视图的自动刷新能力，必须存在一个被设置为维护实例的计算实例。	-

5. 配置“自定义配置”参数。在“高级配置 > 自定义配置”中，用户可以添加自定义参数到指定的参数文件中。单击“参数文件”下拉列表选择指定的参数文件：
   - 单击“增加”可以增加自定义配置参数。
   - 单击“删除”可以删除已增加的自定义配置参数。
   - 可通过选择“参数文件”为“resource-groups.json”来配置资源组机制，资源组配置参数请参考表 10-10，详细说明请参考 10.5.1 配置资源组。

表10-10 资源组配置参数说明

参数	描述	取值样例

resourcegroups	集群的资源管理组配置，参数文件下拉列表要选择“resource-groups.json”。	<pre>{
		"rootGroups": [{
		"name": "global",
		"softMemoryLimit": "100%",
		"hardConcurrencyLimit": 1000,
		"maxQueued": 10000,
		"killPolicy": "no_kill"
		}],
		"selectors": [{
		"group": "global"
		}]
		}</pre>

说明

- 对于“coordinator.config.properties”、“worker.config.properties”、“log.properties”和“resource-groups.json”参数文件，用户配置自定义参数后，如果该自定义参数名称在指定的参数文件中已经存在，那么会使用自定义参数值替换参数文件中原有参数的值。如果不存在，则添加自定义参数到指定的参数文件中。
- killPolicy：当查询提交给 Worker 后，如果总内存使用量超过 softMemoryLimit，可选择一种策略终止正在运行的查询，策略如下所示。
- no_kill（默认值）：不终止查询。
- recent_queries：根据执行顺序的倒序终止查询。
- oldest_queries：根据执行顺序终止查询。
- finish_percentage_queries：根据查询执行百分比终止查询。执行百分比最小的查询将首先被终止。
- high_memory_queries：根据内存使用量终止查询。具有较高内存使用量的查询将首先被终止，以便在查询终止次数最少的情况下，释放更多内存。当两个查询的内存使用量都在限制的 10%以内，则进度慢（执行的百分比）的查询被终止，同时两个查询在完成百分比方面的差异在 5%以内，则内存使用量大的查询被终止。

6. 确定配置完成后是否立即启动实例：
   - 勾选“立即启动”，配置完成后立即启动实例。
   - 不勾选“立即启动”，配置完成后需手动启动实例。

步骤 3 单击“确定”，等待实例配置完成。

须知

- HetuEngine 服务重启

  当 HetuEngine 服务处于重启或者滚动重启过程中，请勿通过 HSConsole 对 HetuEngine 计算实例进行“创建”、“启动”、“停止”和“删除”等运维操作。

- HetuEngine 计算实例批量操作

  同时处于启动中、创建中、删除中、停止中、扩容中、缩容中或滚动重启中等状态的计算实例个数默认最多为 10 个，超过 10 个的计算实例运维操作会在后台进入等待状态。若需要修改并发处理个数，可在 Manager 界面，选择“HetuEngine > 配置 > 全部配置”，搜索并调整参数“hsbroker.event.task.executor.threads”的值。

- HetuEngine 计算实例重启
- 当 HetuEngine 计算实例处于重启或者滚动重启过程中，请勿对 HetuEngine 服务和 HetuEngine WebUI 界面的数据源进行变更操作，包括修改配置，重启等操作。
- 如果计算实例只有 1 个 Coordinator 或者 Worker，请勿对计算实例进行滚动重启。
- 如果 Worker 的数量大于 10 个，实例滚动重启的时间可能会超过 200 分钟，期间请勿做其他运维操作。
- 计算实例滚动重启过程 HetuEngine 会释放 Yarn 资源并且重新申请，请保证滚动重启过程中 Yarn 资源的 CPU 和内存空闲资源足够启动 Worker 总数量 20%的 Worker，及该期间 Yarn 资源不被其他任务抢占，否则会导致实例滚动重启失败。

  Yarn 资源：登录 FusionInsight Manager，选择“租户资源 > 租户资源管理”，在“资源配额”中查看队列的空余资源信息。

单个 Worker 的 CPU 和内存资源：使用用于访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入 HSConsole 界面，单击对应实例所在行“操作”列中的“配置”，在“Worker 容器资源配置”中查看容器内存和 vcore。

- 滚动重启过程中，请保证 Yarn 队列的 Coordinator 或者 Worker 的 Application Manager（am）运行平稳。

  异常处理

- 如果滚动重启期间 Yarn 队列的 Coordinator 或者 Worker 的 Application Manager（am）发生重启，可能会导致计算实例发生异常，需要停止计算实例，然后启动计算实例进行恢复。
- 计算实例滚动重启失败后，实例处于亚健康的状态，可能会有 Coordinator 或者 Worker 配置不一样或者数量不一样的情况，计算实例的亚健康状态不会自动恢复，需要手动检查确认和恢复，或者再次执行滚动重启操作，或者执行停止计算实例再启动操作。

----结束

计算实例状态说明

MRS 3.3.0 及以后版本计算实例创建成功后，可在“计算实例”页签查看当前已创建的实例信息，包括实例所属租户名、对应实例数量、实例状态和资源总量等，实例状态信息如下：

图10-1 计算实例状态

- 绿色图标：实例处于运行中或亚健康状态。
- 红色图标：实例故障。
- 灰色图标：实例已停止、待启动。
- 蓝色图标：实例处于其他状态，包括扩容中、缩容中、滚动重启中、创建中、启动中、安全启动中、停止中、安全停机中、删除中、已删除、停止中等。

10.5 管理 HetuEngine 计算实例

10.5.1 配置资源组

资源组介绍

资源组机制从资源分配的角度控制实例的整体查询负载，并可以对查询实施排队策略。可以在一个计算实例资源下创建多个资源组，并且每个提交的查询将分配给一个特定的资源组执行。在资源组执行新查询之前，将检查当前资源组的资源负载是否超

过实例分配给它的资源量。如果超过，则将阻止新到达的查询，使其处于排队状态，甚至直接拒绝它。

资源组使用场景

通过资源组可以实现计算实例内的资源管理。对不同用户、不同查询分配不同的资源组，可以起到资源隔离的作用，避免单个用户或查询独占计算实例的资源，也能通过资源组件的权重优先级配置保障重要任务优先执行。典型资源组使用场景如表 10-11 所示。

表10-11 典型资源组使用场景

典型场景	解决方案
随着使用计算实例的业务团队的增加，当某个团队的任务更加重要并且不想执行查询时没有资源。	每个团队分配一个指定的资源组；重要任务分配到资源较多的资源组；保证子资源组的占比和小于等于 100%时，可保证某一个队列的资源不被其他资源组抢占，类似于静态化分资源。
当实例资源负载很高时，两个用户同时提交一个查询。一开始，两个查询都在排队。当有空闲资源时，可以调度特定用户的查询首先获取到资源。	两个用户分配不同的资源组，重要的任务可以分配到权重高或优先级高的资源组，调度策略由 schedulingPolicy 配置，不同的调度策略，会有不同的资源分配顺序。
对于即席查询和批量查询，可以根据不同的 SQL 类型进行更合理的资源分配。	可以对不同的查询类型，比如 EXPLAIN、INSERT、SELECT 和 DATA_DEFINITION 等类型，匹配到不同的资源组，分配不同的资源来执行查询。

启用资源组

在创建计算实例的时候，增加参数文件“resource-groups.json”的自定义配置参数，具体操作请参见 10.4 创建 HetuEngine 计算实例中的步骤 3.5。

资源组属性

资源组属性配置请参见表 10-12。

表10-12 资源组属性

配置项	必选/可选	配置说明
name	必选	资源组名称。

配置项	必选/可选	配置说明
maxQueued	必选	最大排队查询数，当达到此阈值后，新的查询将被拒绝。
hardConcurrencyLimit	必选	最大运行查询数。
softMemoryLimit	可选	资源组最大内存使用量，当达到此阈值后，新任务进入排队；可以指定为固定数值（如，10GB）或百分比（如，集群内存的 10%）。
softCpuLimit	可选	在一个周期内（参见全局属性的 cpuQuotaPeriod 参数）可以使用 CPU 的时间，必须同时指定 hardCpuLimit 参数，在达到该阈值后，该资源组内占据最大 CPU 资源的查询的 CPU 资源会被减少。
hardCpuLimit	可选	在一个周期内可以使用的最大 CPU 时间。
schedulingPolicy	可选	指定查询从排队到运行状态的调度策略。 • fair（default） 当一个资源组下，有几个子资源组都同时有排队的查询，这些子资源组间按照定义的顺序，轮流获得资源，同一个子资源组的查询按照先来先执行的规则获取资源。 • weighted_fair 采取这种策略的每一个资源组会配置一个属性schedulingWeight，每个子资源组会计算一个比值：*当前子资源组查询数量*/schedulingWeight。比值越小的子资源组越先得到资源。 • weighted 默认值为 1，子资源组的 schedulingWeight 越大，越先得到资源。 • query_priority 所有的子资源组都要配置为 query_priority ，排队的查询严格按照指定的 query_priority 大小顺序来进行获取资源。
schedulingWeight	可选	该分组的权重，见 schedulingPolicy，默认为 1。
jmxExport	可选	如果为 true，则组统计信息将被导出到 JMX 中进行监控，默认为 false。
subGroups	可选	子分组列表。
killPolicy	可选	当查询提交给 Worker 后，如果总内存使用量超过 softMemoryLimit，可选择一种策略终止正在运行的查询，策略如下所示：

配置项	必选/可选	配置说明
		• no_kill（默认值）：不终止查询。 • recent_queries：根据执行顺序的倒序终止查询。 • oldest_queries：根据执行顺序终止查询。 • finish_percentage_queries：根据查询执行百分比终止查询。执行百分比最小的查询将首先被终止。 high_memory_queries：根据内存使用量终止查询。具有较高内存使用量的查询将首先被终止，以便在查询终止次数最少的情况下，释放更多内存。当两个查询的内存使用量都在限制的 10%以内，则进度慢（执行的百分比）的查询被终止，同时两个查询在完成百分比方面的差异在 5%以内，则内存使用量大的查询被终止。

选择器规则

选择器按顺序进行匹配，将使用第一个匹配到的资源组，一般来说建议配置一个默认资源组，如果没有设置默认资源组，而又不符合其他资源组选择器条件则查询会被拒绝。选择器规则参数配置请参见表 10-13。

表10-13 选择器规则

配置项	必选/可选	配置说明
user	可选	匹配用户名的正则表达式。
source	可选	匹配请求源，参见选择器属性的配置中--source 选项的配置值。
queryType	可选	配置任务类型： • DATA_DEFINITION：更改/创建/删除模式/表/视图的元数据的查询，以及管理预准备语句、权限、会话和事务的查询。 • DELETE：DELETE 查询。 • DESCRIBE：DESCRIBE、DESCRIBE INPUT、DESCRIBE OUTPUT 和 SHOW 查询。 • EXPLAIN：EXPLAIN 查询。 • INSERT：插入和 CREATE TABLE AS 查询。 • SELECT：SELECT 查询。
clientTags	可选	匹配客户端标签，每个标签都必须在用户提交任务的标签列表里，参见选择器属性的配置中--client-tags 选项的配置值。

配置项	必选/可选	配置说明
group	必选	在其中运行查询的资源组。

全局属性

全局属性配置请参见表 10-14。

表10-14 全局属性

配置项	必选/可选	配置说明
cpuQuotaPeriod	可选	CPU 配额生效的时间段，与资源组属性的 softCpuLimit 以及 hardCpuLimit 结合使用。

选择器属性的配置

数据源名称（source）可设置如下：

- CLI：使用--source 选项。
- JDBC：在 Connection 实例上设置 ApplicationName 客户端信息属性。

客户端标签（clientTags）的设置方式如下：

- CLI：使用--client-tags 选项。
- JDBC：在 Connection 实例上设置 ClientTags client info 属性。

配置示例

图10-2 配置示例

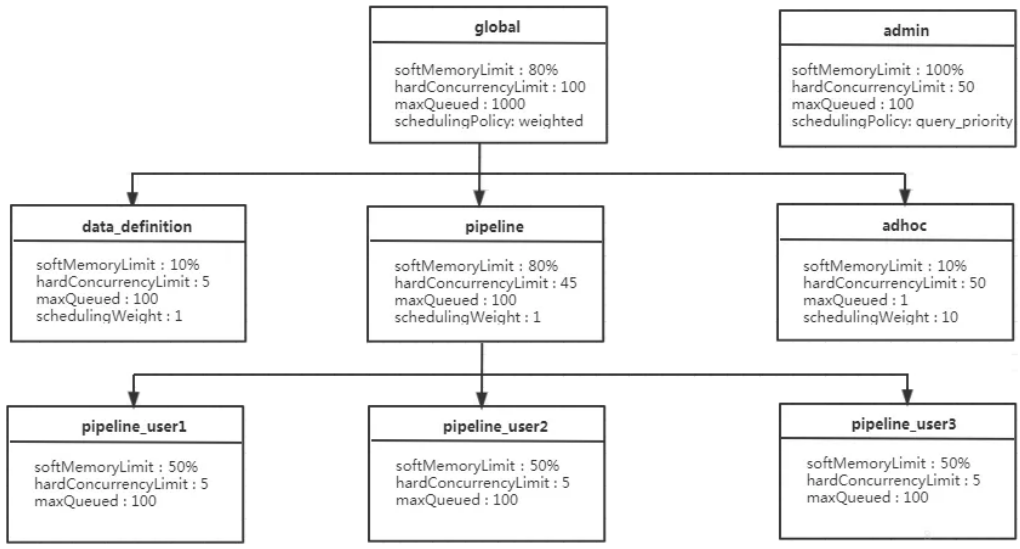

如图 10-2 所示：

- 对于 global 资源组而言，最多可同时运行 100 个查询，有 1000 查询处于排队状态，在它下面有三个子资源组：data_definition、adhoc 和 pipeline；
- pipeline 资源组下每一个用户最多可同时运行 5 个查询，占用 pipeline 资源组 50% 的内存资源，其组内默认采用 fair 的调度策略，所以是按照先来先执行的顺序执行；
- 为了充分利用实例资源，各个子资源组的内存配额的总和可大于父资源组，比如 global 资源组(80%)+admin(100%)=180%>100% 。

在下面的示例配置中，存在多个资源组，其中一些资源组是模板。模板允许 HetuEngine 管理员动态构建资源组树。例如，在 pipeline_${USER}组中，${USER}将扩展为提交查询的用户名称。${SOURCE}也支持，后续会扩展到提交查询的来源。也可以在 source 表达式和 user 正则表达式中使用自定义命名变量。

资源组选择器示例如下：

```
"selectors": [{
    "user": "bob",
    "group": "admin"
},
{
    "source": ".*pipeline.*",
    "queryType": "DATA_DEFINITION",
    "group": "global.data_definition"
},
{
    "source": ".*pipeline.*",
    "group": "global.pipeline.pipeline_${USER}"
},
```

```
{
    "source": "jdbc#(?<toolname>.*)",
    "clientTags": ["hipri"],
    "group": "global.adhoc.bi-${toolname}.${USER}"
},
{
    "group": "global.adhoc.other.${USER}"
}]
```

有四个选择器用于定义在哪个资源组中运行查询：

- 第一个选择器匹配来自 bob 的查询，并将它们放在 admin 组中。
- 第二个选择器匹配来自包括 pipeline 的源名称的所有数据定义（DDL）查询，并将它们放在 global.data_definition 组中。这有助于减少此类查询的排队时间，因为它们预计速度很快。
- 第三个选择器匹配来自包括 pipeline 的源名称的查询，并将它们放在 global.pipeline 组下动态创建的单用户管道组中。
- 第四个选择器匹配来自 BI 工具的查询，BI 工具有一个源与正则表达式 jdbc#(?.*) 匹配，并且客户端提供的标签是 hi-pri 的超集。这些查询被放置在 global.adhoc 组下动态创建的子组中。动态子组将基于命名变量 toolname 创建，该命名变量从源的正则表达式中提取。假设有一个源为 jdbc#powerfulbi，用户为 kayla，客户端标签为 hipri 和 fast 的查询。此查询将被路由到 global.adhoc.bi-powerfulbi.kayla 资源组。
- 最后一个选择器是一个默认选择器，它将所有尚未匹配的查询放入该资源组。

这些选择器一起实现以下策略：

- bob 是 HetuEngine 管理员用户，可以同时运行 50 个查询。查询将根据用户提供的优先级运行。
- 对于剩余用户：
  - 同时运行的查询总数不能超过 100 个。
  - 使用源 pipeline 最多可以运行 5 个并发的 DDL 查询。查询按 FIFO 顺序运行。
  - 非 DDL 查询将在 global.pipeline 组下运行，总并发数为 45，每用户并发数为 5。查询按 FIFO 顺序运行。
  - 对于 BI 工具，每个工具最多可以运行 10 个并发查询，每个用户最多可以运行 3 个。如果总需求超过 10 个限制，运行查询最少的用户将获得下一个并发槽。这项策略使得资源争夺时更加公平。
  - 所有剩余的查询都放在 global.adhoc.other 下的每个用户组中，该组行为类似。

查询匹配选择器的说明：

- 如上每一个大括号代表一个匹配资源组的选择器 selector，这里一共配置了 5 个选择器以匹配上面的 5 个资源组：

```
admin
global.data_definition
global.pipeline.pipeline_${USER}
global.adhoc.bi-${toolname}.${USER}
global.adhoc.other.${USER}
```

- 要全部满足当前 selector 全部条件，才可放进当前队列执行。比如 amy 用户使用 jdbc 方式提交的查询，如果没有配置 clientTags，是不能够分配到资源组 global.adhoc.bi-${toolname}.${USER}对应的资源；
- 当一个查询能同时满足两个 selector 时，会匹配第一个满足要求的 selector。比如 bob 用户提交一个 source 为 pipeline 的 DATA_DEFINITION 类型的 job，只会匹配到资源组 admin 对应的资源，而非 global.data_definition 对应的资源；
- 当前 4 个 selector 都没有匹配上，会使用最后一个 selector 指定的资源组 global.adhoc.other.${USER}的资源。该资源组相当于起到一个默认资源组的作用，如果没有设置默认资源组，而又不符合其他资源组选择器条件则会被拒绝执行。

  如下是完整样例：

```
{
    "rootGroups": [{
        "name": "global",
        "softMemoryLimit": "80%",
        "hardConcurrencyLimit": 100,
        "maxQueued": 1000,
        "schedulingPolicy": "weighted",
        "jmxExport": true,
        "subGroups": [{
            "name": "data_definition",
            "softMemoryLimit": "10%",
            "hardConcurrencyLimit": 5,
            "maxQueued": 100,
            "schedulingWeight": 1
        },
        {
            "name": "adhoc",
            "softMemoryLimit": "10%",
            "hardConcurrencyLimit": 50,
            "maxQueued": 1,
            "schedulingWeight": 10,
            "subGroups": [{
                "name": "other",
                "softMemoryLimit": "10%",
                "hardConcurrencyLimit": 2,
                "maxQueued": 1,
                "schedulingWeight": 10,
                "schedulingPolicy": "weighted_fair",
                "subGroups": [{
                    "name": "${USER}",
                    "softMemoryLimit": "10%",
                    "hardConcurrencyLimit": 1,
                    "maxQueued": 100
                }]
            },
            {
                "name": "bi-${toolname}",
                "softMemoryLimit": "10%",
                "hardConcurrencyLimit": 10,
                "maxQueued": 100,
                "schedulingWeight": 10,
                "schedulingPolicy": "weighted_fair",
                "subGroups": [{
```

```
                    "name": "${USER}",
                    "softMemoryLimit": "10%",
                    "hardConcurrencyLimit": 3,
                    "maxQueued": 10
                }]
            }]
        },
        {
            "name": "pipeline",
            "softMemoryLimit": "80%",
            "hardConcurrencyLimit": 45,
            "maxQueued": 100,
            "schedulingWeight": 1,
            "jmxExport": true,
            "subGroups": [{
                "name": "pipeline_${USER}",
                "softMemoryLimit": "50%",
                "hardConcurrencyLimit": 5,
                "maxQueued": 100
            }]
        }]
    },
    {
        "name": "admin",
        "softMemoryLimit": "100%",
        "hardConcurrencyLimit": 50,
        "maxQueued": 100,
        "schedulingPolicy": "query_priority",
        "jmxExport": true
    }],
    "selectors": [{
        "user": "bob",
        "group": "admin"
    },
    {
        "source": ".*pipeline.*",
        "queryType": "DATA_DEFINITION",
        "group": "global.data_definition"
    },
    {
        "source": ".*pipeline.*",
        "group": "global.pipeline.pipeline_${USER}"
    },
    {
        "source": "jdbc#(?<toolname>.*)",
        "clientTags": ["hipri"],
        "group": "global.adhoc.bi-${toolname}.${USER}"
    },
    {
        "group": "global.adhoc.other.${USER}"
    }],
    "cpuQuotaPeriod": "1h"
}
```

10.5.2 配置 Worker 节点数量

操作场景

在 HetuEngine 的 WebUI 界面，可以对计算实例的 Worker 节点个数进行调整，实现计算实例在资源不够时扩充资源，资源空闲时释放资源。其中包含手动扩缩容和自动扩缩容两种方式进行 Worker 个数调整。

前提条件

已创建好用于访问 HetuEngine WebUI 界面的用户，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。

说明

- 实例在扩缩容中时，原有业务不受影响，实例仍可以正常使用。
- 实例动态扩缩容存在一定滞后性，旨在实现长时间周期内资源消耗的平滑调整，不能实时响应当前正在运行 SQL 任务对可用资源的需求。
- 实例进行动态扩缩容后，HSConsole 页面上实例配置处显示的 Worker 个数会保持初始设置的值，不随动态扩缩容个数变化而改变。
- 实例开启动态扩缩容后，重启 HSBroker 和 Yarn 服务会影响扩缩容功能，如需重启，建议先关闭实例的动态扩缩容功能。
- 进行计算实例扩容时，需要当前队列有足够的资源进行扩容，否则扩容无法达到预期，并影响后续缩容操作。
- 手动扩缩容可以设置超时时间，通过在 Manager 界面，选择“HetuEngine > 配置 > 全部配置”，搜索“application.customized.properties”，增加“yarn.hetuserver.engine.flex.timeout.sec”参数，值默认值为“300”（单位秒）。

操作步骤

使用可访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在概览页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 在“计算实例”页签，在待操作的实例所在行“操作”列单击“配置”，进入“配置实例”页签。

- 如需手动扩缩容，修改配置界面中“Worker 容器资源配置”中的“数量”的值，单击“确定”，此计算实例会进入“扩容中”或者“缩容中”状态，待扩缩容完成，计算实例状态恢复至“运行中”。
- 如需自动扩缩容，将“高级配置”中的“是否开启动态伸缩”开关置于“ON”，并参考表 10-15 配置参数，开启动态伸缩：

表10-15 动态伸缩参数说明

参数	描述	取值样例
扩容阈值	当实例资源的使用率在伸缩决策周期内的平均值都超过此阈值，实例自动启动扩容操作。	0.9

参数	描述	取值样例
扩容量	当实例启动扩容时，每次扩容的 Worker 数量。	1
扩容决策周期	决策实例是否需要扩容的时间周期。单位：秒。	200
缩容阈值	当实例资源的使用率在伸缩决策周期内的平均值都超过此阈值，实例自动启动缩容操作。	0.1
缩容量	当实例启动缩容时，每次缩容的 Worker 数量。	1
缩容决策周期	决策实例是否需要缩容的时间周期。单位：秒。	300
负载采集周期	每进行一次实例负载采集间隔的时间。单位：秒	10
扩容超时时间	扩容操作的超时时间。单位:秒	400
缩容超时时间	缩容操作的超时时间。单位：秒	600

步骤 3 配置完成后单击“确定”。

----结束

10.5.3 配置 HetuEngine 维护实例

操作场景

维护实例是承担自动化任务的一种特殊的计算实例，主要负责物化视图的自动刷新、自动创建和自动删除。

只能有一个计算实例被设置为维护实例，也可以同时承担计算实例的业务。

前提条件

- 已创建好用于访问 HetuEngine WebUI 界面的用户，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。
- 待配置的计算实例状态需为“已停止”状态。

操作步骤

使用用于访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager。

步骤 1 选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 2 在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 3 在待操作的实例所在行“操作”列单击“配置”。

步骤 4 查看“高级配置”的“是否用作维护实例”是否处于“ON”，否则修改为“ON”。

步骤 5 修改完成后，勾选“立即启动”，单击“确定”。

----结束

10.5.4 导入导出计算实例配置

操作场景

在 HetuEngine 的 WebUI 界面，可以导入/导出实例配置文件、下载实例配置模板。

前提条件

已创建好用于访问 HetuEngine WebUI 界面的用户，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。

操作步骤

使用可访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在概览页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

- 导入实例配置文件：在实例列表上方单击“导入”，在本地选择 JSON 格式的实例配置文件后，单击“打开”。
- 导出实例配置文件：勾选待导出的实例，然后在实例列表上方单击“导出”，可将当前实例配置文件导出至本地。

----结束

10.5.5 查看实例监控页面

操作场景

在 HetuEngine 的 WebUI 界面，可以查看指定业务的详细信息，包括每个 SQL 的执行情况（各版本稍有差异，请以实际展示为准）。如果当前集群是双平面，需要一台和集群业务平面可以连通的 Windows 机器进行操作。

前提条件

已创建好用于访问 HetuEngine WebUI 界面的管理员用户，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。

操作步骤

使用可访问 HetuEngine WebUI 界面的管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 单击待操作“实例名”所在行的“WebUI”列的“LINK”链接，将在新页面展示计算实例任务监控页面信息。首次进入为“Query History”页面，单击“Metrics”即可查看计算实例任务监控页面信息。

表10-16 指标含义

指标	指标含义
Cluster CPU Usage	当前实例 cpu 使用率
Cluster Free Memory	当前实例空闲内存
Average Cluster CPU Usage	当前实例平均 cpu 使用率
Used Query Memory	当前实例已使用内存
Running Queries	当前实例并发执行的任务
Queued Queries	当前实例中等待队列中等待执行的任务数
Blocked Queries	当前实例中由于资源或其他原因被阻塞的任务数
Active Workers	当前实例中的有效 Worker 数量
Avg Running Tasks	当前实例平均正在运行的任务数
Avg CPU cycles per worker	当前实例每个 Worker 的平均 CPU 周期

步骤 3 通过“Query History”页面的 State 选项可以对查询任务进行筛选。

表10-17 State 含义

State	含义
Select All	查看所有状态的任务
Queued	查看等待队列中等待执行的任务
Waiting For Resources	查看正在等待资源的任务
Dispatching	查看正在被调度的任务
Planning	查看正在执行计划的任务
Starting	查看开始运行的任务
Running	查看当前正在运行中的任务
Finishing	查看正在结束中的任务
Finished	查看执行完成的任务
Failed	查看执行失败的任务，并可以按照任务失败原因进行过滤

步骤 4 单击任务编号，可以进一步查看任务的基本信息、资源占用情况、Stages 划分、 Tasks 划分等信息，对于失败的任务，也可以在查询详情页面查看相关日志。

图10-3 查看任务详情

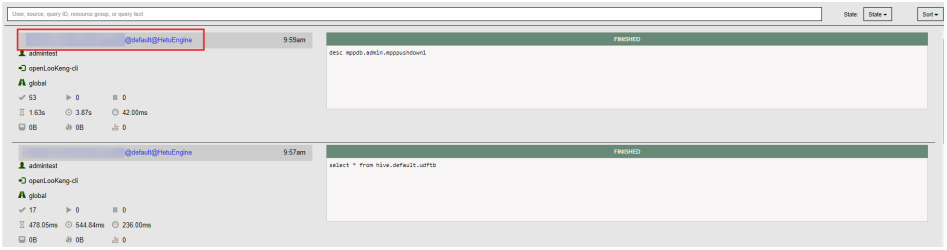

图10-4 任务资源使用情况

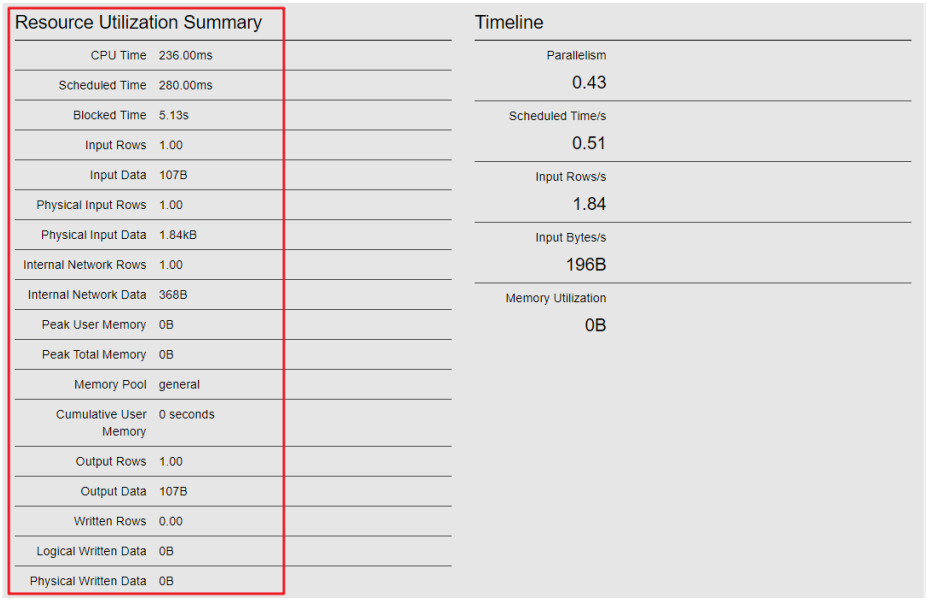

图10-5 任务 Stages 划分

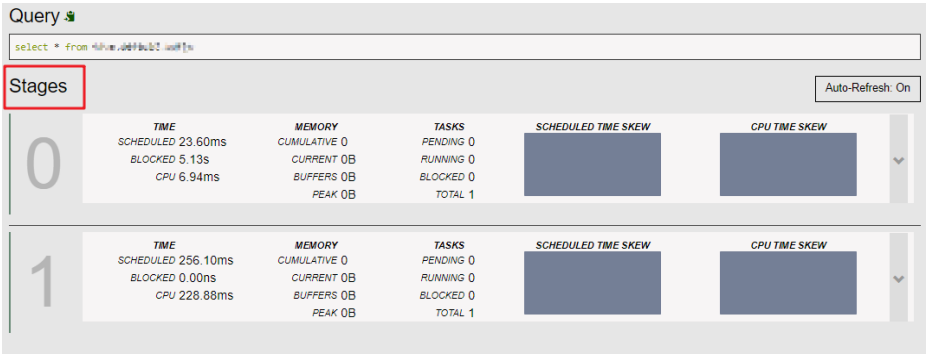

表10-18 Stages 监控信息

监控项	含义
SCHEDULED TIME SKEW	代表当前 Stage 节点并发任务被调度的时间
CPU TIME SKEW	可以判断是否存在 Stage 阶段并发任务是否存在计算倾斜

图10-6 Tasks 划分

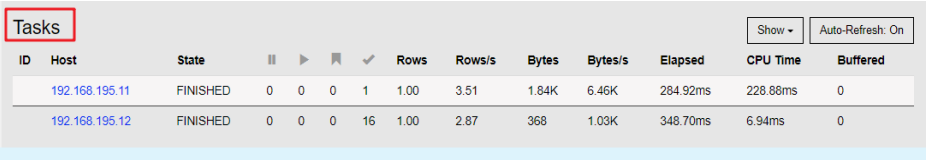

表10-19 Tasks 监控项

监控项	含义
ID	代表多阶段并发执行 Task 的 ID，格式为 StageID:TaskID
Host	代表当前任务在哪个 Worker 节点执行
State	当前任务执行的状态，主要状态 PLANNED、RUNNING、FINISHED、CANCELED、ABORTED、FAILED
Rows	Task 读取的总数据条数，单位为千（k）、百万（M），通过分析相同 Stage 阶段不同 Task 读取的条数可以快速判断当前任务是否存在数据倾斜
Rows/s	Task 每秒钟读取的数据条数，通过分析相同 Stage 阶段不同 Task 每秒中读取数据条数可以快速判断节点是否存在网络带宽差异，定位是否节点网卡存在问题
Bytes	Task 读取的数据量
Bytes/s	Task 每秒中读取的数据量
Elapsed	Task 执行时长
CPU Time	Task 使用的 CPU 时间
Buffered	Task 的缓存数据大小

步骤 5 单击“Host”的链接，可以查看每个节点 task 资源占用情况。

图10-7 Task 节点资源占用情况

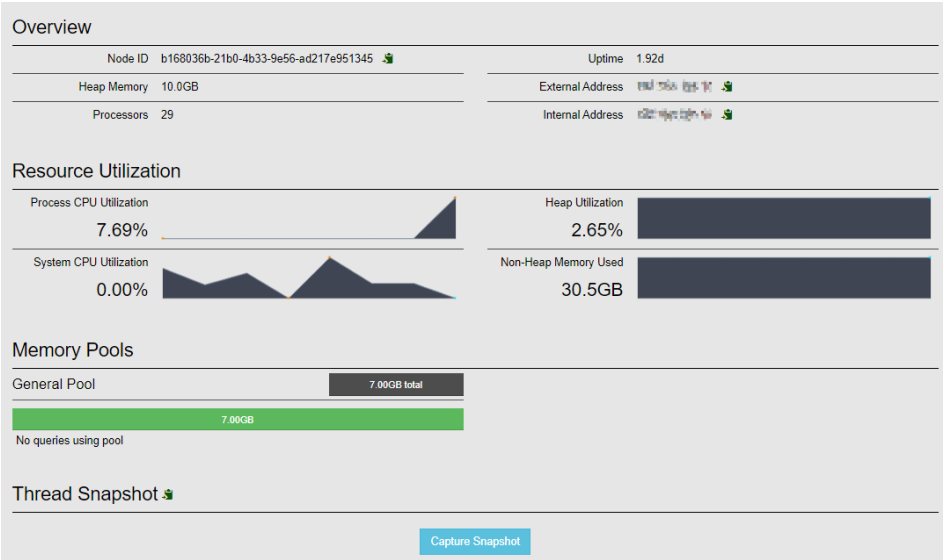

表10-20 节点资源监控指标

指标名称	含义
Node ID	节点 ID
Heap Memory	最大堆内存大小
Processors	处理器个数
Uptime	运行时长
External Address	外部地址
Internal Address	内部地址
Process CPU Utilization	物理 CPU 使用率
System CPU Utilization	系统 CPU 使用率
Heap Utilization	堆内存使用率
Non-Heap Memory Used	非堆内存使用大小
Memory Pools	当前 Worker 节点内存池大小

----结束

10.5.6 查看 Coordinator 和 Worker 日志

操作场景

在 HetuEngine 的 WebUI 界面，可以通过单击 LogUI 链接跳转至 Yarn WebUI 界面查看 Coordinator 和 Worker 日志。

前提条件

已创建好用于访问 HetuEngine WebUI 界面的用户，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。

操作步骤

使用可访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在概览页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 单击待操作实例所在行的“LogUI”列的“Coordinator”或“Worker”，将在 Yarn WebUI 展示 Coordinator 和 Worker 日志。

----结束

10.5.7 配置查询容错执行能力

本章节适用于 MRS 3.3.0 及以后版本。

操作场景

当集群中的节点因网络、硬件或软件问题发生故障时，在故障节点上运行的所有查询任务都将丢失。这可能会严重影响集群生产力并造成资源浪费，尤其对于长时间运行的查询影响较大。HetuEngine 提供一种故障恢复机制，即容错执行能力。集群可通过自动重新运行受影响的查询或其组件任务来降低查询失败概率。可降低人工干预并提高了容错性，但会延长总执行时间。

当前支持如下两种容错执行机制：

- QUERY 级重试策略：开启 QUERY 级别容错不会进行中间数据落盘，如果查询任务失败，将自动重试该查询任务的所有 task。当集群的大部分工作由小查询组成时建议使用此策略。
- TASK 级重试策略：开启 TASK 级别容错会默认配置 HDFS 作为交换区，将 exchange 中间数据落盘，如果查询任务失败，将重试失败的 task。建议在执行大批量查询时使用此策略，集群可以更高效的重试查询中的小颗粒任务，而不是整个查询。

本示例介绍设置“TASK”重试策略容错执行机制。

使用须知

- 容错不适用于已损坏的查询或其他用户错误场景。例如：不会花费资源重试由于无法解析 SQL 而失败的查询任务。
- 不同数据源对 SQL 语句的容错支持能力存在差异：
  - 所有数据源都支持**读操作**的容错执行。
  - Hive 数据源支持**写操作**的容错执行。
- 容错能力非常适合大批量查询，如果用户在容错集群上同时运行大量短时间小查询，则可能会遇到延迟。因此，建议处理批处理操作时使用专用的容错计算实例，与进行交互式查询的更高查询量的计算实例分开。

操作步骤

使用可访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在概览页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 在“计算实例”页签，在待操作的实例所属租户所在行的“操作”列单击“配置”。

步骤 3 在“自定义配置”单击“增加”添加如下参数。

表10-21 容错执行参数

参数	取值示例	参数文件	描述
retry-policy	TASK	• coordinator.config.properties • worker.config.properties	• 容错执行重试策略。 • 取值范围：QUERY、TASK
task-retry-attempts-per-task	4	• coordinator.config.properties • worker.config.properties	• 开启 TASK 容错时，在声明查询失败之前尝试重试单个任务的最大次数。 • 默认值：4
query-retry-attempts	4	• coordinator.config.properties • worker.config.properties	• 开启 QUERY 容错时，在声明查询失败之前尝试重试查询的最大次数。 • 默认值：4
fault-tolerant-execution-task-memory	5GB	• coordinator.config.properties • worker.config.properties	• “retry-policy”设置为“TASK”时可配置该参数，不配置默认为5GB。节点会根据可用内存和估计的内存使用情况分配任务。 • 用于初始任务分配节点时的内存需求估计。值越大表明每个TASK 预估使用的内存更大，但

参数	取值示例	参数文件	描述
			会导致集群并发能力变小，可根据实际业务情况动态调整。

步骤 4 添加完成后将“立即启动”置为“是”，单击“确定”。

须知

- 启用 TASK 容错模式后，会产生中间数据并缓存到文件系统中，过大的查询并发会对文件系统产生较大的磁盘压力。当前 HetuEngine 默认支持将中间数据缓冲至 HDFS 文件系统的临时目录中。存算分离场景对接 OBS 文件系统时，也能够支持 TASK 容错，但是中间数据仍然落盘至 HDFS 临时目录中。
- 集群默认会在查询结束时完成缓冲区文件清理，且每小时检测并清理存在超期 1 天的残留缓冲区文件，可通过如下操作关闭周期性清理功能：

  登录 Manager，选择“集群 > 服务 > HetuEngine > 配置 > 全部配置 > HSBroker（角色） > 容错执行”，将参数“fte.exchange.clean.task.enabled”的值置为“false”并保存配置。单击“实例”，勾选所有 HSBroker，选择“更多 > 重启实例”，根据界面提示重启实例以使配置生效。

----结束

10.6 使用 HetuEngine 客户端

操作场景

若计算实例未创建或未启动，通过登录 HetuEngine 客户端可主动创建或启动计算实例。该任务指导用户在运维场景或业务场景中使用客户端管理计算实例。

HetuEngine 提供服务级默认资源队列配置项，如果没指定租户信息，默认使用 Yarn 为用户指定的默认租户，可能出现多个用户都默认使用相同的租户队列，从而无法达到资源隔离的效果。

若用户需要进行资源隔离，将 SQL 分配给指定的资源队列来执行，来达到资源合理分配的目的时，可通过开启租户的严格校验模式来实现该需求，仅需配置“tenant.strict.mode.enabled”参数为“true”并在使用客户端时添加“--tenant”参数指定租户资源队列即可。

说明

- 开启租户的严格校验模式：适用于 MRS 3.3.0 及以后版本

  登录 Manager，选择“集群 > 服务 > HetuEngine > 配置 > 全部配置”，搜索“tenant.strict.mode.enabled”，将参数的值选为“true”并保存。单击“实例”，勾选配置过期的角色实例，选择“更多 > 重启实例”，根据界面提示重启实例以使配置生效。

- 如果开启了租户的严格校验模式，使用 HetuEngine 的跨域功能，需要配置 HetuEngine 数据源的“hsfabric.local.tenant”参数，可参考 10.9.6 配置 HetuEngine 数据源。

前提条件

- 已安装集群客户端。例如安装目录为“/opt/client”。
- 已创建具有 Hive（关闭 Ranger 场景）、hetuuser 和 default 队列权限的 HetuEngine 普通用户，例如 **hetu_test**。

  创建用户的具体操作请参考 10.3 创建 HetuEngine 用户。

操作步骤

以客户端安装用户登录 HetuEngine 服务客户端所在节点，切换到客户端安装目录。

cd /opt/client

步骤 1 执行以下命令配置环境变量。

source bigdata_env

步骤 2 根据集群认证模式，完成 HetuEngine 客户端登录。

- 安全模式：执行以下命令，完成用户认证并登录 HetuEngine 客户端。

  kinit hetu_test

  hetu-cli --catalog hive --tenant default --schema default
- 普通模式：执行以下命令，登录 HetuEngine 客户端。

  hetu-cli --catalog hive --tenant default --schema default --user hetu_test

说明

hetu_test 是一个至少具备“--tenant”指定租户角色的业务用户，且不能是操作系统用户。

参数说明：

- **--catalog**：（可选）指定的数据源名称。
- **--tenant**：（可选）指定集群启动的租户资源队列，不指定为租户的默认队列。使用此参数时，业务用户需要具有该租户对应角色的权限。MRS 3.3.0 及以后版本是否可选根据如下判断：
  - 可选：未启用租户的严格校验模式。
  - 必选：启用了租户的严格校验模式。
- **--schema**：（可选）指定要访问数据源下的 schema 名称。
- **--user**：（普通模式下必选）指定要登录客户端执行业务的用户名称，该用户至少需要具有“--tenant”指定队列的相应角色。

说明

- 首次登录客户端需要启动后台 HetuEngine 集群，大约需等待 120 秒，可以进入客户端界面。
- 支持 SQL 语法，兼容开源 openLooKeng 1.2.0 版本 SQL 语法。
- 其他参数可以执行 **hetu-cli --help** 查看。

----结束

10.7 使用 HetuEngine 跨源功能

HetuEngine 跨源功能简介

出于管理和信息收集的需要，企业内部会存储海量数据，包括数目众多的各种数据库、数据仓库等，此时会面临数据源种类繁多、数据集结构化混合、相关数据存放分散等困境，导致跨源查询开发成本高，跨源复杂查询耗时长。

HetuEngine 提供了统一标准 SQL 实现跨源协同分析，简化跨源分析操作。

图10-8 HetuEngine 跨源功能示意

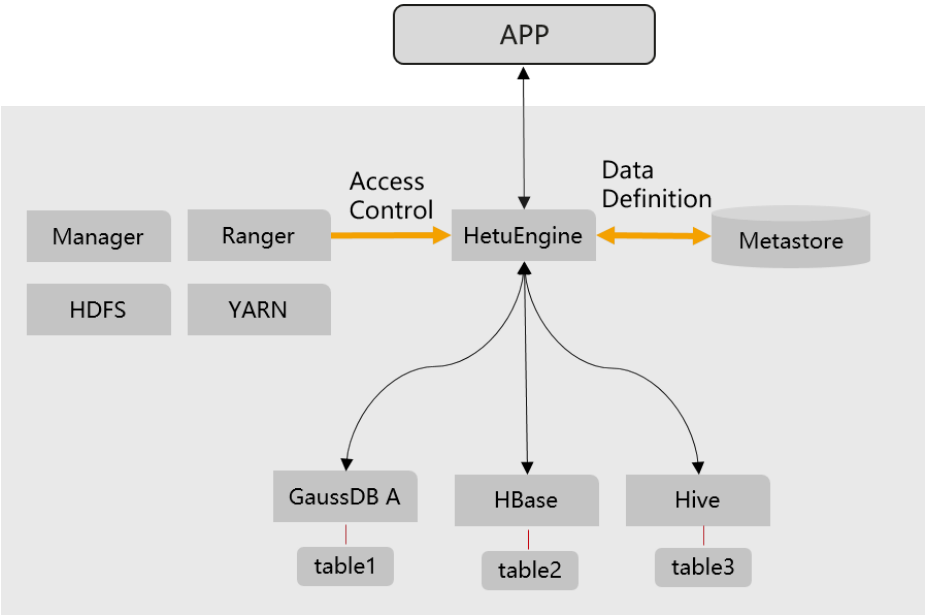

关键技术和优势

- 计算下推：在通过 HetuEngine 进行跨源协同分析时，为了提升访问效率，HetuEngine 从如下所示维度增强了计算下推的能力。
  - Basic Pushed Down 类型：Predicate、Projection、Sub-query、Limit。
  - Aggregation Pushed Down 类型：Group by、Order by、Count、Sum、Min、Max。
  - Operator Pushed Down 类型：<, >、Like、or。
- 多源异构：协同分析既支持 Hive、GaussDB、ClickHouse 等结构化数据源，也支持 HBase、Elasticsearch 等非结构化数据源。
- 全局元数据：对于非结构化数据源 HBase，提供映射表方式将非结构化 SCHEMA 映射成结构化 SCHEMA，实现 HetuEngine 对 HBase 的无差别 SQL 访问；对于数据源信息，提供全局管理。
- 全局权限控制：数据源的权限均可通过 HetuEngine 开放给 Ranger 集中管理，统一控制。

跨源功能使用指导

HetuEngine 能够支持多种数据源的快速联合查询并提供可视化的数据源配置、管理页面，可通过 HSConsole 界面快速添加如下数据源，配置数据源前请先参考 10.9.1 配置数据源前必读：

- 10.9.2 配置 Hive 数据源
- 10.9.3 配置 ClickHouse 数据源
- 10.9.4 配置 GAUSSDB 数据源
- 10.9.5 配置 HBase 数据源
- 10.9.6 配置 HetuEngine 数据源
- 10.9.7 配置 IoTDB 数据源

使用跨源协同分析流程

1. 参考 10.6 使用 HetuEngine 客户端登录 HetuEngine 客户端。
2. 注册 Hive、HBase、GaussDB A 等数据源。

```
hetuengine> show catalogs;
  Catalog
----------
dws
hive
hive_dg
hbase
system
systemremote
(6 rows)
```

3. 编写 SQL 进行跨源协同分析。

```
select * from hive_dg.schema1.table1 t1 join hbase.schema3.table3 t2 join
dws.schema02.table4 t3 on t1.name = t2.item and t2.id = t3.cardNo;
```

10.8 使用 HetuEngine 跨域功能

HetuEngine 跨域功能简介

HetuEngine 提供统一标准 SQL 对分布于多个地域（或数据中心）的多种数据源实现高效访问，屏蔽数据在结构、存储及地域上的差异，实现数据与应用的解耦。

图10-9 HetuEngine 跨域功能示意

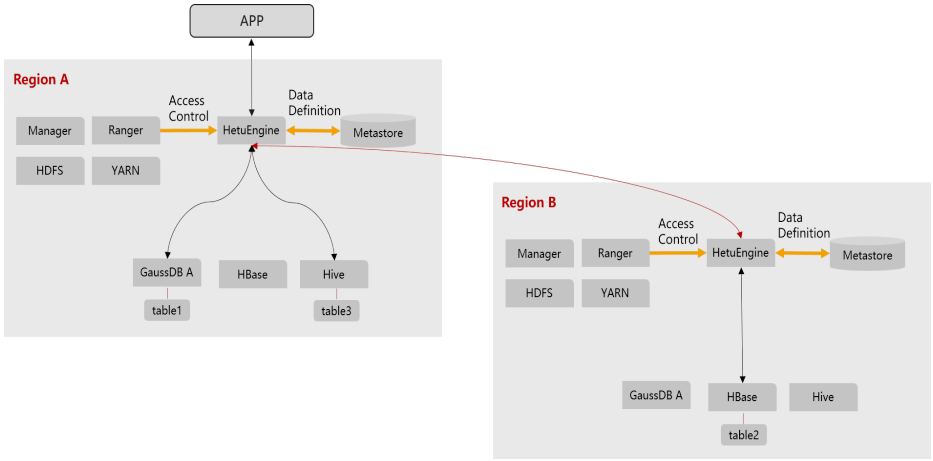

关键技术和优势

- 无单点瓶颈：HSFabric 可进行水平扩展，多通道并行传输，速率最大化，跨地域延迟不再成为瓶颈。
- 更好地计算资源利用：将数据压缩，序列化的任务下推到 Worker 并行计算。
- 高效序列化：优化数据序列化格式，同等数据量级下，更低的数据传输量。
- 流式传输：基于 HTTP 2.0 stream，保证 HTTP 协议通用性的同时，减少大量数据传输中 RPC 重复调用。
- 断点续传：防止数据传输过程中连接异常断开后重传大量数据。
- 流量管控：支持按地区限制数据传输所占用的网络带宽，避免在跨地域有限带宽场景下因流量独占而影响其他业务的正常使用。

跨域功能使用指导

前提条件：

- 确保本端和远端集群的数据节点上分别部署至少一个 HSFabric 实例。
- 确保本端和远端集群的 HSFabric 实例所在节点的网络互通。

操作步骤：

开放本域数据源。通过创建 Virtual Schema 方式来对远端访问请求屏蔽本域的物理数据源的真实 Schema 信息、实例信息，远端使用 Virtual Schema 名称即可访问本域对应的数据源。

```
CREATE VIRTUAL SCHEMA hive01.vschema01 WITH (
  catalog = 'hive01',
  schema = 'ins1'
);
```

步骤 1 参考 10.9.6 配置 HetuEngine 数据源，在远端 HetuEngine 上注册“HetuEngine”类型数据源，添加本域 HetuEngine。

步骤 2 使用跨域协同分析。

```
// 1. 在远端 HetuEngine 上开放 hive1.ins2 数据源
CREATE VIRTUAL SCHEMA hive1.vins2 WITH (
  catalog = 'hive1',
  schema = 'ins2'
);

// 2. 在本域 HetuEngine 上注册 Hive、GaussDB A、HetuEngine 等 3 种数据源
hetuengine> show catalogs;
  Catalog
----------
dws
hetuengine_dc
hive
hive_dg
system
systemremote
(6 rows)

// 3. 在本域 HetuEngine 上进行跨源协同分析
select * from hive_dg.schema1.table1 t1 join hetuengine_dc.vins2.table3 t2 join
dws.schema02.table4 t3 on t1.name = t2.item and t2.id = t3.cardNo;
```

----结束

10.9 配置数据源

10.9.1 配置数据源前必读

HetuEngine 能够支持多种数据源的快速联合查询并提供可视化的数据源配置、管理页面，用户可通过 HSConsole 界面快速添加数据源。

当前版本 HetuEngine 支持对接的数据源如表 10-22 所示。

表10-22 HetuEngine 对接数据源一览表

HetuEngine 模式	数据源	数据源模式	支持对接的数据源版本
安全模式	Hive	安全模式	MRS 3.x、FusionInsight 6.5.1
	HBase		MRS 3.x、FusionInsight 6.5.1
	HetuEngine		MRS 3.1.1 及以后
	GaussDB		GaussDB 200、GaussDB A 8.0.0 及以后
	Hudi		MRS 3.1.2 及以后
	ClickHouse		MRS 3.1.1 及以后
	IoTDB		MRS 3.2.0 及以后

HetuEngine 模式	数据源	数据源模式	支持对接的数据源版本
	MySQL		MySQL 5.7、MySQL 8.0 及以后
普通模式	Hive	普通模式	MRS 3.x、FusionInsight 6.5.1
	HBase		MRS 3.x、FusionInsight 6.5.1
	Hudi		MRS 3.1.2 及以后
	ClickHouse		MRS 3.1.1 及以后
	IoTDB		MRS 3.2.0 及以后
	GaussDB	安全模式	GaussDB 200、GaussDB A 8.0.0 及以后
	MySQL		MySQL 5.7、MySQL 8.0 及以后

HetuEngine 数据源的添加、配置、删除等操作支持动态生效，无须重启集群。

目前动态生效不支持关闭，数据源动态生效时间默认为 60 秒。如需修改动态生效时间，请参考 10.4 创建 HetuEngine 计算实例的步骤 3.5 修改“coordinator.config.properties”和“worker.config.properties”中的参数“catalog.scanner-interval”值为需要设定的动态生效时间，例如：

```
catalog.scanner-interval =120s
```

HetuEngine 支持查询下推（pushdown），它能把查询，或者部分查询，下推到连接的数据源。这意味着特殊的谓词，聚合函数或者其它一些操作，可以被传递到底层数据库或者文件系统进行处理。查询下推能带来以下好处：

1. 提升整体的查询性能。
2. 减少 HetuEngine 和数据源之间的网络流量。
3. 减少远端数据源的负载。

HetuEngine 对查询下推的具体支持情况，依赖于具体的 Connector，以及 Connector 相关的底层数据源或存储系统。

说明

- 数据源集群域名与 HetuEngine 集群域名不能相同，HetuEngine 也不支持同时对接两个相同域名的数据源（Hive，Hbase，Hudi 数据源）。
- 数据源集群与 HetuEngine 集群节点业务平面网络互通。

10.9.2 配置 Hive 数据源

10.9.2.1 配置共部署 Hive 数据源

操作场景

本章节指导用户在 HSConsole 界面配置与 HetuEngine 在一个 Hadoop 集群的 Hive 类型数据源。

HetuEngine 目前支持对接的数据格式包括：avro、text、rctext、orc、parquet、sequencefile。

HetuEngine 对接 Hive 数据源，不支持指定多分隔符建表，但对于在 Hive 数据源中指定 MultiDelimitSerDe 类作为序列化类来创建 text 数据格式的多分隔符表，可以通过 HetuEngine 查询，其他场景不支持。

HetuEngine 对接的 Hive 数据源支持 Hudi 表重定向功能。适用于 MRS 3.3.0 及以后版本。该功能支持在 Hive connector 访问 Hudi 表时重定向到 Hudi connector，从而使用 Hudi connector 高级功能。使用该功能需提前配置目标 Hudi 数据源，并确保 Hudi 数据源与当前 Hive 数据源的 Metastore URL 一致，并在 Hive 数据源中配置“开启 Hudi 重定向”参数即可。

前提条件

已创建 HetuEngine 计算实例。

说明

HetuEngine 服务在安装时已经将共部署的 Hive 数据源默认实现对接，数据源名称为“hive”，不可删除，部分默认配置不可修改，不可修改的配置发生更新时，重启 HetuEngine 服务可以自动同步。

若需要使用 Hive Metastore 隔离功能，需要在 Hive 侧配置“HIVE_METASTORE_URI_HETU”，配置完成后需在 HetuEngine 服务重启 Hsbroke 实例，刷新 Hive Metastore URI 信息。

操作步骤

使用 HetuEngine 管理员用户登录 Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在“概览”页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 单击“数据源”，在 hive 数据源所在行的“操作”列下单击“编辑”，在页面内修改配置，可修改配置如下表。

参数	描述	取值样例
开启数据源鉴权	是否同时使用 Hive 数据源的权限策略进行鉴权。 HetuEngine 服务 Ranger 不启用时必须选“是”，Ranger 启用后选“否”。	否

参数	描述	取值样例
yarn-site 文件	在数据源客户端 Yarn/config 路径下获取，只有对接 Hudi 数据源的时候才需要上传此文件。 配置 Hive 数据源请勿修改此项参数。	-
开启 Hudi 重定向 适用于 MRS 3.3.0 及以后版本	已配置与当前 Hive 数据源的 Metastore URL 一致的目标 Hudi 数据源时可配置此功能。 开启后可以在 Hive connector 访问 Hudi 表时重定向到 Hudi connector，从而使用 Hudi connector 高级功能。	否
Hudi 数据源名称 适用于 MRS 3.3.0 及以后版本	开启 Hudi 重定向时需配置目标 Hudi 数据源。 下拉框中显示所有已配置的 Hudi 数据源，只能选择满足 Metastore URL 条件的 Hudi 数据源。	-
是否开启连接池	访问 hive metastore 时是否开启连接池。默认“是”。	是
最大连接数	访问 hive metastore 时连接池的最大连接数。	50（取值范围 20~200）

步骤 3 （可选）若用户需添加“自定义配置”，可参考步骤 6.7 配置完成后单击“确定”保存配置。

----结束

数据类型映射

目前 Hive 数据源支持的数据类型为：BOOLEAN、TINYINT、SMALLINT、INT、BIGINT、REAL、DOUBLE、DECIMAL、NUMERIC、DEC、VARCHAR、VARCHAR（X）、CHAR、CHAR（X）、STRING、DATE、TIMESTAMP、TIME WITH TIMEZONE、TIMESTAMP WITH TIME ZONE、TIME、ARRAY、MAP、UNIOMTYPE、STRUCT、ROW。

性能优化

- 元数据缓存

  Hive 连接器支持元数据缓存，以便更快地提供对各种操作的元数据请求。可参考 10.14.4 调整元数据缓存。
- CBO（Cost based Optimizer）优化

  定期通过 Analyze 命令收集表统计信息有助于 Hive 连接器 CBO 优化。
- 动态过滤

开启动态过滤有助于 Hive 连接器的 Join 算子的计算优化。可参考 10.14.6 调整动态过滤。

- 带分区条件查询

  建立分区表并且查询带分区过滤条件有助于过滤部分分区数据，从而提高性能。

- Insert 优化

  通过设置“task.writer-count”的值为“1”和增大“hive.max-partitions-per-writers”的值有助于提升 Insert 性能。可参考 10.14.3 调整 INSERT 写入优化。

约束

- DELETE 语法可以删除整个表的数据，或者分区表的指定分区。
- Hive 元数据库不支持 Schema 重命名，即不支持 ALTER SCHEMA RENAME 语法。

10.9.2.2 配置独立部署 Hive 数据源

操作场景

本章节指导用户在 HSConsole 界面添加 Hive 类型数据源。

HetuEngine 目前支持对接传统数据格式数据源类型包括：avro、text、rctext、orc、parquet、sequencefile。

HetuEngine 对接 Hive 数据源，不支持指定多分隔符建表，但对于在 Hive 数据源中指定 MultiDelimitSerDe 类作为序列化类来创建 text 数据格式的多分隔符表，可以通过 HetuEngine 查询，其他场景不支持。

HetuEngine 对接的 Hive 数据源支持 Hudi 表重定向功能。适用于 MRS 3.3.0 及以后版本。该功能支持在 Hive connector 访问 Hudi 表时重定向到 Hudi connector，从而使用 Hudi connector 高级功能。使用该功能需提前配置目标 Hudi 数据源，并确保 Hudi 数据源与当前 Hive 数据源的 Metastore URL 一致，并在 Hive 数据源中配置“开启 Hudi 重定向”参数即可。

前提条件

- 数据源所在集群域名与 HetuEngine 集群域名不能相同。
- 数据源所在集群与 HetuEngine 集群节点网络互通。
- 在 HetuEngine 所在集群的所有节点的“/etc/hosts”文件中，添加待对接数据源所在集群的主机名称和对应的 IP 映射，及其“/etc/hosts”文件中的“10.10.10.10 hadoop.*系统域名*”（如“10.10.10.10 hadoop.hadoop.com”），否则 HetuEngine 无法根据主机名称连接到非本集群节点。
- 已创建 HetuEngine 计算实例。

操作步骤

获取 Hive 数据源集群的“hdfs-site.xml”和“core-site.xml”配置文件。

1. 登录 Hive 数据源所在集群的 FusionInsight Manager 页面。
2. 下载客户端。

- MRS 3.3.0 之前版本：选择“集群 > 概览 > 更多 > 下载客户端”，根据界面提示下载“完整客户端”文件到本地。
- MRS 3.3.0 及之后版本：在“主页”右上方单击“下载客户端”，根据界面提示下载“完整客户端”文件到本地。

3. 将下载的客户端文件压缩包解压，获取“FusionInsight_Cluster_1_Services_ClientConfig/HDFS/config”路径下的“core-site.xml”和“hdfs-site.xml”文件。
4. 查看“core-site.xml”文件中是否有“fs.trash.interval”配置项，若没有，则新增以下配置。该参数为以分钟为单位的垃圾回收时间，垃圾站中数据超过此时间，会被删除。取值范围：1440～259200。

```
<property>
<name>fs.trash.interval</name>
<value>2880</value>
</property>
```

5. 将“hdfs-site.xml”文件中的“dfs.client.failover.proxy.provider.*nameservice 名称*”配置值修改成“org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider”，利用已通过的协议创建 namenode 代理的 Client Failover proxy provider 类。如下所示：

```
<property>
<name>dfs.client.failover.proxy.provider.hacluster</name>
<value>org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvide
r</value>
</property>
```

- 如果 HDFS 有多个 NameService，那么“hdfs-site.xml”文件中多个 NameService 对应的“dfs.client.failover.proxy.provider.*NameService 名称*”配置值均需要改成“org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider”。
- 如果“hdfs-site.xml”文件中引用到了非 HetuEngine 集群节点的主机名称，需要在 HetuEngine 集群的每个节点的“/etc/hosts”文件中，加上引用到的主机名称和对应的 IP 的映射，及其“/etc/hosts”文件中的“10.10.10.10 hadoop.*系统域名*”（如“10.10.10.10 hadoop.hadoop.com”），否则 HetuEngine 无法根据主机名称连接到非本集群节点。

须知

若对接的 Hive 数据源集群和 HetuEngine 处于同一个 Hadoop 集群中，“hdfs-site.xml”和“core-site.xml”配置文件的获取方式为从 HDFS 中获取，参考 9.4 使用 HDFS 客户端进入集群 HDFS 客户端，执行以下命令获取：

hdfs dfs -get /user/hetuserver/fiber/restcatalog/hive/core-site.xml

hdfs dfs -get /user/hetuserver/fiber/restcatalog/hive/hdfs-site.xml

步骤 1 获取 Hive 数据源的代理用户的“user.keytab”和“krb5.conf”文件。

1. 登录 Hive 数据源所在集群的 FusionInsight Manager 页面。
2. 选择“系统 > 权限 > 用户”。

3. 选择对应的数据源用户，在“操作”列中选择“更多 > 下载认证凭据”。
4. 从下载的文件中解压后获取“user.keytab”和“krb5.conf”文件。

说明

Hive 数据源的代理用户需至少关联“hive”用户组。

步骤 2 获取 Metastore URL 和服务端 Principal。

1. 获取 Hive 数据源所在集群客户端文件压缩包解压路径下的“FusionInsight_Cluster_1_Services_ClientConfig/Hive/config”下的“hive-site.xml”文件。
2. 打开“hive-site.xml”文件，搜索“hive.metastore.uris”，其对应的值即为 Metastore URL 的值。搜索“hive.server2.authentication.kerberos.principal”，其对应的值即为服务端 Principal 的值。

步骤 3 使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 4 在概览页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 5 选择“数据源”，单击“添加数据源”。在“添加数据源”页面填写参数。

1. 配置“基本配置”，填写数据源名称，选择数据源类型“Hive”。
2. 配置“Hive 配置”，参数配置请参考下表。

表10-23 Hive 配置

参数	描述	取值样例
驱动	默认为 fi-hive-hadoop。	fi-hive-hadoop
hdfs-site 文件	在本地选择步骤 1 获取的“hdfs-site.xml”配置文件，文件名固定。	-
core-site 文件	在本地选择步骤 1 获取的“core-site.xml”配置文件，文件名固定。	-
yarn-site 文件	在数据源客户端 Yarn/config 路径下获取，只有对接 Hudi 数据源的时候才需要上传此文件。	-
krb5 文件	开启安全模式时填写此参数。 Kerberos 认证用到的配置文件，在本地选择步骤 2 获取的“krb5.conf”文件。	krb5.conf
开启数据源鉴权	是否同时使用 Hive 数据源的权限策略进行鉴权。 HetuEngine 服务 Ranger 不启用时必须选“是”，Ranger 启用后选“否”。	否

3. 配置“Metastore 配置”，参数配置请参考下表。

表10-24 Metastore 配置

参数	描述	取值样例
Metastore URL	数据源的 Metastore 的 URL。获取方法请参考步骤 3。	thrift://10.92.8.42:21088,thrift://10.92.8.43:21088,thrift://10.92.8.44:21088
开启 Hudi 重定向 适用于 MRS 3.3.0 及以后版本	已配置与当前 Hive 数据源的 Metastore URL 一致的目标 Hudi 数据源时可配置此功能。 开启后可以在 Hive connector 访问 Hudi 表时重定向到 Hudi connector，从而使用 Hudi connector 高级功能。	否
Hudi 数据源名称 适用于 MRS 3.3.0 及以后版本	开启 Hudi 重定向时需配置目标 Hudi 数据源。 下拉框中显示所有已配置的 Hudi 数据源，只能选择满足 Metastore URL 条件的 Hudi 数据源。	-
安全认证机制	打开安全模式后自动默认为 KERBEROS。	KERBEROS
服务端 Principal	开启安全模式时填写此参数。 meta 访问 metastore 带域名的用户名。获取方法请参考步骤 3。	hive/hadoop.hadoop.com@HADOOP.COM
客户端 Principal	开启安全模式时填写此参数。 格式为：*访问 metastore 的用户名*@*域名大写*.COM。 *访问 metastore 的用户名*就是步骤 2 中获取的“user.keytab”文件所属的用户。	admintest@HADOOP.COM
keytab 文件	开启安全模式时填写此参数。 连接 metastore 用户名的 keytab 凭据文件，固定名称。在本地选择步骤 2 获取的“user.keytab”文件。	user.keytab

4. 配置“连接池配置”，参数配置请参考下表。

表10-25 连接池配置

参数	描述	取值样例
是否开启连接池	访问 hive metastore 时是否开启连接池。	是
最大连接数	访问 hive metastore 时连接池的最大连接数。	50

5. 配置“Hive 用户信息配置”，参数配置请参考下表。

   “Hive 用户信息配置”与“HetuEngine-Hive 用户映射配置”要搭配使用，HetuEngine 在对接 Hive 数据源时，通过用户映射，使得 HetuEngine 的用户具备与 Hive 数据源被映射的用户访问 Hive 数据源时同样的权限。可以多个 HetuEngine 用户对应一个 Hive 用户。

表10-26 Hive 用户信息配置

参数	描述
Data Source User	数据源用户信息。 如果配置了数据源用户为 hiveuser1，那么必须有映射到 hiveuser1 的 HetuEngine 用户。例如创建 hetuuser1 映射到 hiveuser1。
keytab 文件	获取该数据源对应用户的认证凭据。

6. （可选）配置“HetuEngine-Hive 用户映射配置”，参数配置请参考下表。

表10-27 HetuEngine-Hive 用户映射配置

参数	描述
HetuEngine User	HetuEngine 用户信息。
Data Source User	数据源用户信息。如 hiveuser1（表 10-26 中配置的数据源用户）。

7. （可选）修改自定义配置。
   - 单击“增加”，参考下表增加自定义配置参数。

表10-28 自定义配置

参数	描述	取值样例
hive.metastore.connection.pool.maxTotal	连接池可创建的最大连接数。	50（取值范围 20~200）
hive.metastore.connection.pool.maxIdle	连接池最大空闲线程数，当空闲线程达到最大值时不会释放新的线程。 默认值：8	8（取值范围 0~200，不能超过最大连接数）
hive.metastore.connection.pool.minIdle	连接池最小空闲线程数，此时线程池不会创建新的线程。 默认值：0	0（取值范围 0~200，不能超过 hive.metastore.connec

参数	描述	取值样例
		tion.pool.maxIdle 的值）
hive.orc.use-column-names	是否按照列名方式访问 ORC 存储文件： • true：是 • false（默认值）：否	false
hive.parquet.use-column-names	是否按照列名方式访问 PARQUET 存储文件。： • true：是 • false（默认值）：否	false
hive.hdfs.wire-encryption.enabled	若对接数据源上 HDFS 的“hadoop.rpc.protection”参数值为“authentication”或“integrity”时，需添加此参数，并设置值为 false。	false
hive.strict-mode-restrictions	可设置如下约束条件限制用户查询： • NONE：没有约束 • DISALLOW_EXCEEDED_SCAN_ON_PARTITION（默认值）：不允许单 Hive 分区表扫描最大分区数大于 hive.max-partitions-per-scan 参数值	DISALLOW_EXCEEDED_SCAN_ON_PARTITION
hive.ignore-absent-partitions	查询是否忽略分区下是否有文件丢失。 • true：允许查询分区下存在文件丢失的情况 • false：不允许查询分区下存在文件丢失的情况，会直接报错（手动对接数据源时，不填则默认为该值）	true

- 单击“删除”，可以删除已增加的自定义配置参数。

说明

- 以上自定义配置项，均可通过增加“coordinator.”和“worker.”前缀分别对 Coordinator 和 Worker 进行差异化配置。例如自定义添加“worker.hive.metastore.connection.pool.maxTotal”为 50，表示配置 Worker 访问 hive metastore 时的最大连接数为 50。若未添加前缀，则表示该配置项对 Coordinator 和 Worker 都生效。

- 系统默认设置 Coordinator 访问 hive metastore 时的最大连接数为 50，最大空闲连接数为 8，最小空闲连接数为 0，Worker 访问 hive metastore 时的最大连接数为 20，最大空闲和最小空闲连接数为 0。
- hive.max-partitions-per-scan：为单 Hive 分区表扫描最大分区个数。系统默认 100000。
- HetuEngine 服务在安装时共部署的 Hive 数据源的“hive.ignore-absent-partitions”默认为“true”。

8. 单击“确定”。

步骤 6 登录集群客户端所在节点，执行以下命令，切换到客户端安装目录并认证用户。

cd /opt/client

source bigdata_env

kinit *HetuEngine 组件操作用户*　　（普通模式集群跳过）

步骤 7 执行以下命令，登录数据源的 catalog。

hetu-cli --catalog *数据源名称* **--schema** *数据库名*

例如执行以下命令：

hetu-cli --catalog hive_1 --schema default

步骤 8 执行以下命令，可正常查看数据库表信息或不报错即表示连接成功。

show tables;

----结束

数据类型映射

目前 Hive 数据源支持的数据类型为：BOOLEAN、TINYINT、SMALLINT、INT、BIGINT、REAL、DOUBLE、DECIMAL、NUMERIC、DEC、VARCHAR、VARCHAR（X）、CHAR、CHAR（X）、STRING、DATE、TIMESTAMP、TIME WITH TIMEZONE、TIMESTAMP WITH TIME ZONE、TIME、ARRAY、MAP、UNIOMTYPE、STRUCT、ROW。

性能优化

- 元数据缓存

  Hive 连接器支持元数据缓存，以便更快地提供对各种操作的元数据请求。可参考 10.14.4 调整元数据缓存。

- 动态过滤

  开启动态过滤有助于 Hive 连接器的 Join 算子的计算优化。可参考 10.14.6 调整动态过滤。

- 带分区条件查询

  建立分区表并且查询带分区过滤条件有助于过滤部分分区数据，从而提高性能。

- Insert 优化

  通过设置“task.writer-count”的值为“1”和增大“hive.max-partitions-per-writers”的值有助于提升 Insert 性能。可参考 10.14.3 调整 INSERT 写入优化。

约束

- DELETE 语法可以删除整个表的数据，或者分区表的指定分区。
- Hive 元数据库不支持 Schema 重命名，即不支持 ALTER SCHEMA RENAME 语法。

10.9.2.3 配置 Hudi 格式数据源

操作场景

说明

HetuEngine 不支持 Hudi 的 bootstrap 表的读取。

前提条件

- 创建 Hudi 数据源的代理用户，该代理用户为人机用户且需拥有 hive 组。
- 在 HetuEngine 所在集群的所有节点的“/etc/hosts”文件中，添加待对接数据源所在集群的主机名称和对应的 IP 映射，及其“/etc/hosts”文件中的“10.10.10.10 hadoop.*系统域名*”（如“10.10.10.10 hadoop.hadoop.com”），否则 HetuEngine 无法根据主机名称连接到非本集群节点。
- 参考 10.3 创建 HetuEngine 用户创建 HetuEngine 管理员用户。

操作步骤

获取 Hive 数据源集群的“hdfs-site.xml”，“core-site.xml”和“yarn-site.xml”配置文件。

1. 登录 Hive 数据源所在集群的 FusionInsight Manager 页面。
2. 下载客户端。
   - MRS 3.3.0 之前版本：选择“集群 > 概览 > 更多 > 下载客户端”，根据界面提示下载“完整客户端”文件到本地。
   - MRS 3.3.0 及之后版本：在“主页”右上方单击“下载客户端”，根据界面提示下载“完整客户端”文件到本地。
3. 将下载的客户端文件压缩包解压，获取“FusionInsight_Cluster_1_Services_ClientConfig/HDFS/config”路径下的“core-site.xml”和“hdfs-site.xml”，以及“FusionInsight_Cluster_1_Services_ClientConfig/Yarn/config”路径下的“yarn-site.xml”文件。
4. 查看“core-site.xml”文件中是否有“fs.trash.interval”配置项，若没有，则新增以下配置。

   ```
   <property>
   <name>fs.trash.interval</name>
   <value>2880</value>
   </property>
   ```

5. 将“hdfs-site.xml”文件中的“dfs.client.failover.proxy.provider.hacluster”配置值修改成“org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider”，如下所示：

```
<property>
<name>dfs.client.failover.proxy.provider.hacluster</name>
<value>org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvide
r</value>
</property>
```

- 如果 HDFS 有多个 NameService，那么“hdfs-site.xml”文件中多个 NameService 对应的“dfs.client.failover.proxy.provider.*NameService 名称*”配置值均需要改成“org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailoverProxyProvider”。
- 如果“hdfs-site.xml”文件中引用到了非 HetuEngine 集群节点的主机名称，需要在 HetuEngine 集群的每个节点的“/etc/hosts”文件中，加上引用到的主机名称和对应的 IP 的映射，否则 HetuEngine 无法根据主机名称连接到非本集群节点。

须知

若对接的 Hive 数据源集群和 HetuEngine 处于同一个 Hadoop 集群中，“hdfs-site.xml”和“core-site.xml”配置文件的获取方式为从 HDFS 中获取，参考 9.4 使用 HDFS 客户端进入集群 HDFS 客户端，执行以下命令获取：

hdfs dfs -get /user/hetuserver/fiber/restcatalog/hive/core-site.xml

hdfs dfs -get /user/hetuserver/fiber/restcatalog/hive/hdfs-site.xml

步骤 1 获取 Hive 数据源的代理用户的“user.keytab”和“krb5.conf”文件。

1. 登录 Hive 数据源所在集群的 FusionInsight Manager 页面。
2. 选择“系统 > 权限 > 用户”。
3. 选择对应的数据源用户，在“操作”列中选择“更多 > 下载认证凭据”。
4. 从下载的文件中解压后获取“user.keytab”和“krb5.conf”文件。

说明

Hive 数据源的代理用户需至少关联“hive”用户组。

步骤 2 获取 Metastore URL 和服务端 Principal。

1. 获取 Hive 数据源所在集群客户端文件压缩包解压路径下的“FusionInsight_Cluster_1_Services_ClientConfig/Hive/config”下的“hive-site.xml”文件。
2. 打开“hive-site.xml”文件，搜索“hive.metastore.uris”，其对应的值即为 Metastore URL 的值。搜索“hive.server2.authentication.kerberos.principal”，其对应的值即为服务端 Principal 的值。

步骤 3 使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 4 在概览页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 5 选择“数据源”，单击“添加数据源”。在“添加数据源”页面填写参数。

- MRS 3.3.0 及之后版本：
  a. 配置“基本配置”，填写数据源名称，选择数据源类型“Hudi”。
  b. 配置“Hudi 配置”，参数配置请参考下表。

表10-29 Hudi 配置

参数	描述	取值样例
驱动	默认为 hudi。	hudi
hdfs-site 文件	在本地选择步骤 1 获取的“hdfs-site.xml”配置文件，文件名固定。	-
core-site 文件	在本地选择步骤 1 获取的“core-site.xml”配置文件，文件名固定。	-
krb5 文件	开启安全模式时填写此参数。 Kerberos 认证用到的配置文件，在本地选择步骤 2 获取的“krb5.conf”文件。	krb5.conf

  c. 配置“Metastore 配置”，参数配置请参考下表。

表10-30 Metastore 配置

参数	描述	取值样例
Metastore URL	数据源的 Metastore 的 URL。获取方法请参考步骤 3。	thrift://10.92.8.42:21088,thrift://10.92.8.43:21088,thrift://10.92.8.44:21088
安全认证机制	打开安全模式后自动默认为 KERBEROS。	KERBEROS
服务端 Principal	开启安全模式时填写此参数。 meta 访问 metastore 带域名的用户名。获取方法请参考步骤 3。	hive/hadoop.hadoop.com@HADOOP.COM
客户端 Principal	开启安全模式时填写此参数。 格式为：*访问 metastore 的用户名*@*域名大写*.COM。 *访问 metastore 的用户名*就是步骤 2 中获取的“user.keytab”文件所属的用户。	admintest@HADOOP.COM
keytab 文件	开启安全模式时填写此参数。 连接 metastore 用户名的 keytab 凭据文件，固定名称。在本地选择步骤 2 获取的“user.keytab”文件。	user.keytab

d. 单击“确定”。

- MRS 3.3.0 之前版本：
  a. 配置“基本配置”，填写数据源名称，选择数据源类型“Hive”。
  b. 配置“Hive 配置”，参数配置请参考下表。

表10-31 Hive 配置

参数	描述	取值样例
驱动	默认为 fi-hive-hadoop。	fi-hive-hadoop
hdfs-site 文件	在本地选择步骤 1 获取的“hdfs-site.xml”配置文件，文件名固定。	-
core-site 文件	在本地选择步骤 1 获取的“core-site.xml”配置文件，文件名固定。	-
yarn-site 文件	在本地选择步骤 1 获取的“yarn-site.xml”配置文件，文件名固定。	-
krb5 文件	开启安全模式时填写此参数。 Kerberos 认证用到的配置文件，在本地选择步骤 2 获取的“krb5.conf”文件。	krb5.conf
开启数据源鉴权	是否同时使用 Hive 数据源的权限策略进行鉴权。 HetuEngine 服务 Ranger 不启用时必须选“是”，Ranger 启用后选“否”。	否

c. 配置“Metastore 配置”，参数配置请参考下表。

表10-32 Metastore 配置

参数	描述	取值样例
Metastore URL	数据源的 Metastore 的 URL。获取方法请参考步骤 3。	thrift://10.92.8.42:21088,thrift://10.92.8.43:21088,thrift://10.92.8.44:21088
安全认证机制	打开安全模式后自动默认为 KERBEROS。	KERBEROS
服务端 Principal	开启安全模式时填写此参数。 meta 访问 metastore 带域名的用户名。获取方法请参考步骤 3。	hive/hadoop.hadoop.com@HADOOP.COM
客户端 Principal	开启安全模式时填写此参数。 格式为：*访问 metastore 的用户名@域名大写*.COM。	admintest@HADOOP.COM

参数	描述	取值样例
	*访问 metastore 的用户名*就是步骤 2 中获取的“user.keytab”文件所属的用户。	
keytab 文件	开启安全模式时填写此参数。 连接 metastore 用户名的 keytab 凭据文件，固定名称。在本地选择步骤 2 获取的“user.keytab”文件。	user.keytab

d. 配置“连接池配置”，参数配置请参考表 10-33。

表10-33 连接池配置

参数	描述	取值样例
是否开启连接池	访问 hive metastore 时是否开启连接池。	是
最大连接数	访问 hive metastore 时连接池的最大连接数。	50

e. 配置“Hive 用户信息配置”，参数配置请参考表 10-34。

“Hive 用户信息配置”与“HetuEngine-Hive 用户映射配置”要搭配使用，HetuEngine 在对接 Hive 数据源时，通过用户映射，使得 HetuEngine 的用户具备与 Hive 数据源被映射的用户访问 Hive 数据源时同样的权限。可以多个 HetuEngine 用户对应一个 Hive 用户。

表10-34 Hive 用户信息配置

参数	描述
Data Source User	数据源用户信息。 如果配置了数据源用户为 hiveuser1，那么必须有映射到 hiveuser1 的 HetuEngine 用户。例如创建 hetuuser1 映射到 hiveuser1。
keytab 文件	获取该数据源对应用户的认证凭据。

f. 修改自定义配置，“hive.parquet.use-column-names”和“hive.partition-use-column-names”参数为必填项。

- 单击“增加”，参考下表增加自定义配置参数。

表10-35 自定义配置（必选）

参数	描述	取值样例

参数	描述	取值样例
hive.parquet.use-column-names	值为“true”时，表示根据 Parquet 文件中记录的名称而不是默认的顺序位置访问列。	true （取值范围：true、false）
hive.partition-use-column-names	值为“true”时，表示根据 partition 分区中记录名称而不是默认的顺序位置访问列。	true （取值范围：true、false）

表10-36 自定义配置（可选）

参数	描述	取值样例
hive.metastore.connection.pool.maxTotal	连接池可创建的最大连接数。	50（取值范围 20~200）
hive.metastore.connection.pool.maxIdle	连接池最大空闲线程数，当空闲线程达到最大值时不会释放新的线程。 默认值：8	8（取值范围 0~200，不能超过最大连接数）
hive.metastore.connection.pool.minIdle	连接池最小空闲线程数，此时线程池不会创建新的线程。 默认值：0	0（取值范围 0~200，不能超过 hive.metastore.connection.pool.maxIdle 的值）
hive.hdfs.wire-encryption.enabled	若对接数据源上 HDFS 的“hadoop.rpc.protection”参数值为“authentication”或“integrity”时，需添加此参数，并设置值为 false。	false

- 单击“删除”，可以删除已增加的自定义配置参数。

说明

- 以上自定义配置项，均可通过增加“coordinator.”和“worker.”前缀分别对 Coordinator 和 Worker 进行差异化配置。例如自定义添加“worker.hive.metastore.connection.pool.maxTotal”为 50，表示配置 Worker 访问 hive metastore 时的最大连接数为 50。若未添加前缀，则表示该配置项对 Coordinator 和 Worker 都生效。
- 系统默认设置 Coordinator 访问 hive metastore 时的最大连接数为 50，最大空闲连接数为 8，最小空闲连接数为 0，Worker 访问 hive metastore 时的最大连接数为 20，最大空闲和最小空闲连接数为 0。

g. 单击“确定”。

步骤 6 登录集群客户端所在节点，执行以下命令，切换到客户端安装目录并认证用户。

cd /opt/client

source bigdata_env

kinit *HetuEngine 组件操作用户*　　（普通模式集群跳过）

步骤 7　执行以下命令，登录数据源的 catalog。

hetu-cli --catalog *数据源名称* **--schema** *数据库名*

例如执行以下命令：

hetu-cli --catalog hudi_1 --schema default

步骤 8　执行以下命令，可正常查看数据库表信息或不报错即表示连接成功。

show tables;

----结束

数据类型映射

目前 Hudi 数据源支持的数据类型为：INT、BIGINT、FLOAT、DOUBLE、DECIMAL、STRING、DATE、TIMESTAMP、BOOLEAN、BINARY、MAP、STRUCT、ARRAY。

性能优化

- 元数据缓存

  Hudi 连接器支持元数据缓存，以便更快地提供对各种操作的元数据请求。可参考 10.14.4 调整元数据缓存。

- 动态过滤

  开启动态过滤有助于 Hudi 连接器的 Join 算子的计算优化。可参考 10.14.6 调整动态过滤。

- 带分区条件查询

  建立分区表并且查询带分区过滤条件有助于过滤部分分区数据，从而提高性能。

约束

Hudi 数据源只支持查询操作，更新和插入操作均不支持。

10.9.3 配置 ClickHouse 数据源

操作场景

ClickHouse 数据源中同一个 Schema（或 Database）下不能存在名字内容相同但大小写格式不同的 Table，例如：cktable（小写）、CKTABLE（大写）和 CKtable（大小写混合），该内容的 Table 只能有一个，否则 HetuEngine 无法使用该 Schema（或 Database）下的表。

前提条件

参考 10.3 创建 HetuEngine 用户创建 HetuEngine 管理员用户。

操作步骤

使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在“概览”页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 选择“数据源”，单击“添加数据源”，在“添加数据源”页面填写参数。

1. 配置“基本配置”，填写数据源名称，选择数据源类型“JDBC > ClickHouse”。
2. 配置“ClickHouse 配置”，参数配置请参考表 10-37。

表10-37 ClickHouse 配置

参数	描述	取值样例
驱动	默认为“clickhouse”。	clickhouse
JDBC URL	ClickHouse 数据源的 JDBC URL 地址。 • ClickHouse 数据源使用 IPV4，则格式为：jdbc:clickhouse://<host>:<port>； • ClickHouse 数据源使用 IPV6，则格式为：jdbc:clickhouse://[<host>]:<port> 其中： • <host>获取方法：登录 ClickHouse 数据源所在集群的 Manager 页面，选择“集群 > 服务 > ClickHouse > 实例”，查看 ClickHouseBalancer 所在的“业务 IP”。随机选取一个 IP 地址即可，目前仅支持填写一个 IP 地址。 • MRS 3.2.0 之前版本，<port>获取方法：登录 ClickHouse 数据源所在集群的 Manager 页面，选择“集群 > 服务 > ClickHouse > 配置 > 全部配置”，如果 ClickHouse 数据源是安全模式则查看 ClickHouseBalancer 实例 HTTPS 端口，即“lb_https_port”参数的“值”；如果 ClickHouse 数据源是普通模式则查看 ClickHouseBalancer 实例 HTTP 端口，即“lb_http_port”参数的“值”。 • MRS 3.2.0 及之后版本，<port>获取方法：登录 FusionInsight Manager，选择“集群 > 服务 > ClickHouse > 逻辑集群”，查看对应逻辑集群的 HTTP Balancer 端口号。	jdbc:clickhouse://10.162.156.243:21426 或者 jdbc:clickhouse://10.162.156.243:21425

参数	描述	取值样例
用户名	连接 ClickHouse 数据源的用户名。	根据连接数据源的用户名修改。
密码	连接 ClickHouse 数据源的用户密码。	根据连接数据源的用户密码修改。
Schema/Table 大小写敏感	支持数据源的 Schema/Table 名称大小写格式敏感。 HetuEngine 支持数据源的 Schema/Table 名称大小写格式敏感。 • 否：当数据源同一个 Schema 下有多个 Table 名称，如 cktable（小写）、CKTABLE（大写）和 CKtable（大小写混合），HetuEngine 只能使用 cktable（小写）。 • 是：要求数据源同一个 Schema 下只能有一个 Table 名称，如 cktable（小写）或者 CKTABLE（大写）或者 CKtable（大小写混合），否则 HetuEngine 无法使用该 Schema 下的所有表。	-

3. （可选）自定义配置。

   单击“增加”可以增加自定义配置参数。配置 ClickHouse 数据源自定义参数，参考表 10-38。

表10-38 ClickHouse 数据源自定义配置参数

参数	描述	取值样例
use-connection-pool	是否使用 JDBC 连接池	true
jdbc.connection.pool.maxTotal	JDBC 连接池中最大连接数	8
jdbc.connection.pool.maxIdle	JDBC 连接池中最大空闲连接数	8
jdbc.connection.pool.minIdle	JDBC 连接池中最小空闲连接数	0
jdbc.connection.pool.testOnBorrow	从 JDBC 连接池中获取连接使用时是否对连接的有效性做检验	false
jdbc.pushdown-enabled	下推功能是否启用 默认值：true	true
jdbc.pushdown-module	下推类型	-

参数	描述	取值样例
	• DEFAULT：不下推任何算子 • BASE_PUSHDOWN：仅下推 Filter、Aggregation、Limit、TopN、Projection 等算子 • FULL_PUSHDOWN：下推所有可支持的算子	
clickhouse.map-string-as-varchar	是否将 ClickHouse 数据源 String 和 FixedString 类型处理成 Varchar 类型 默认值：true	true
clickhouse.socket-timeout	连接 ClickHouse 数据源超时时长 单位：毫秒 默认值：120000	120000
case-insensitive-name-matching.cache-ttl	数据源的大小写敏感的 Schema/Table 名称缓存超时时长 单位：分钟 默认值：1	1

单击“删除”可以删除已增加的自定义配置参数。

4. 单击“确定”。

步骤 3 登录集群客户端所在节点，执行以下命令，切换到客户端安装目录并认证用户。

cd /opt/client

source bigdata_env

kinit *HetuEngine 组件操作用户*　　（普通模式集群跳过）

步骤 4 执行以下命令，登录数据源的 catalog。

hetu-cli --catalog *数据源名称* **--schema** *数据库名*

例如执行以下命令：

hetu-cli --catalog clickhouse_1 --schema default

步骤 5 执行以下命令，可正常查看数据库表信息或不报错即表示连接成功。

show tables;

----结束

数据类型映射

ClickHouse 数据类型到 HetuEngine 数据类型映射

ClickHouse 类型	HetuEngine 类型

ClickHouse 类型	HetuEngine 类型
BOOLEAN	BOOLEAN
UInt8	SMALLINT
UInt16	INTEGER
UInt32	BIGINT
UInt64	DECIMAL(20, 0)
Int8	TINYINT
Int16	SMALLINT
Int32	INTEGER
Int64	BIGINT
Float32	REAL
Float64	DOUBLE
Decimal(P, S)	DECIMAL(P, S)
Decimal32(S)	DECIMAL(P, S)
Decimal64(S)	DECIMAL(P, S)
Decimal128(S)	DECIMAL(P, S)
IPv4	VARCHAR
IPv6	VARCHAR
UUID	VARCHAR
Enum8	VARCHAR
Enum16	VARCHAR
String	VARCHAR / VARBINARY
Fixedstring(N)	VARCHAR / VARBINARY
Date	DATE
DateTime	TIMESTAMP

性能优化

- 查询下推

  支持使用查询下推功能，提高查询速度。

  查询下推功能默认关闭，可参考步骤 3.3 添加相关自定义参数开启查询下推功能并选择下推类型。
- Scalar UDF 下推

Scalar UDF 下推功能默认打开。使用该功能前需根据需求在 HetuEngine 中创建映射函数。

约束

- HetuEngine 支持对接 ClickHouse 操作的 SQL 语法：SHOW CATALOGS/SCHEMAS/TABLES/COLUMNS、DESCRIBE、USE、SELECT 表/视图。
- HetuEngine 支持对接 ClickHouse 操作的表和视图：

名称	支持对接 ClickHouse 操作的表、视图
HetuEngine 支持对 ClickHouse 操作的表	本地表（MergeTree）
	复制表（ReplicatedReplacingMergeTree）
	分布式表（Distributed）
HetuEngine 支持对 ClickHouse 操作的视图	普通视图（Normal）
	物化视图（Materialized）

10.9.4 配置 GAUSSDB 数据源

操作场景

本章节指导用户在 HSConsole 界面添加 GaussDB 类型的 JDBC 数据源。

前提条件

- 数据源所在集群与 HetuEngine 集群节点网络互通。
- 在 HetuEngine 所在集群的所有节点的“/etc/hosts”文件中，添加待对接数据源所在集群的主机名称和对应的 IP 映射，及其“/etc/hosts”文件中的“10.10.10.10 hadoop.*系统域名*”（如“10.10.10.10 hadoop.hadoop.com”），否则 HetuEngine 无法根据主机名称连接到非本集群节点。
- 已创建 HetuEngine 计算实例。

操作步骤

使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在“概览”页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 选择“数据源”，单击“添加数据源”。在“添加数据源”页面填写参数。

1. 配置“基本配置”，填写数据源名称，选择数据源类型“JDBC > GAUSSDB-A”。

2. 配置“GAUSSDB-A 配置”，参数配置请参考表 10-39。

表10-39 GAUSSDB-A 配置

参数	描述	取值样例
驱动	默认为“gaussdba”。	gaussdba
JDBC URL	连接 GaussDB 数据库的 JDBC URL 地址。格式为： jdbc:postgresql://*CN 业务 IP*:*端口*/*数据库名称*	jdbc:postgresql://10.0.136.1:25308/postgres
用户名	GaussDB 数据源连接用户名。	根据连接数据源的用户名修改。
密码	GaussDB 数据源连接密码。	根据连接数据源的用户名密码修改。

3. （可选）配置 Gauss 数据源用户信息，参考表 10-40。

“GaussDB 用户信息配置”与“HetuEngine-GaussDB 用户映射配置”要搭配使用，HetuEngine 在对接的 GaussDB 数据源时，通过用户映射，使得 HetuEngine 的用户具备与 GaussDB 数据源被映射的用户访问 GaussDB 数据源时同样的权限。可以多个 HetuEngine 用户对应一个 GaussDB 用户。

在 GaussDB 数据库中，创建的用户名要符合标识符的命名规范，且最大长度不超过 63 个字符。当用户名中包含大写字母时数据库将自动转换为小写字母，如果需要创建包含大写字母的用户名则需要使用双引号括起来。因此，配置“Data Source User”时，必须使用 GaussDB 数据库转换后的用户名。

例如：

- 在 GaussDB 数据库创建的用户名为 Gaussuser1，则 Data Source User 应为 gaussuser1。
- 在 GaussDB 数据库创建的用户名为“Gaussuser1”，则 Data Source User 应为 Gaussuser1。

表10-40 GaussDB 用户信息配置

名称	描述
Data Source User	数据源用户名称。 如果配置了数据源用户为 gaussuser1，那么必须有映射到 gaussuser1 的 HetuEngine 用户。例如创建 hetuuser1 映射到 gaussuser1。
Password	对应数据源的用户认证密码。

4. （可选）配置 HetuEngine-GaussDB 用户映射配置，参考表 10-41

表10-41 HetuEngine-GaussDB 用户映射配置

名称	描述
HetuEngine User	HetuEngine 用户名。
Data Source User	数据源用户，如 gaussuser1（表 10-40 中配置的数据源用户）。

5. （可选）自定义配置。
   - 单击“增加”可以增加自定义配置参数。配置 GaussDB 数据源自定义参数，参考表 10-42。

表10-42 GaussDB 数据源自定义配置参数

名称	描述	取值样例
use-connection-pool	是否使用 JDBC 连接池	true
jdbc.connection.pool.maxTotal	JDBC 连接池中最大连接数	8
jdbc.connection.pool.maxIdle	JDBC 连接池中最大空闲连接数	8
jdbc.connection.pool.minIdle	JDBC 连接池中最小空闲连接数	0
jdbc.pushdown-enabled	true：允许将 SQL 下推到数据源执行 false: SQL 不会被下推到数据源执行，因此会消耗更多的网络和计算资源	true
jdbc.pushdown-module	前提条件：下推功能已开启 • DEFAULT：不下推任何算子 • BASE_PUSHDOWN：仅下推 Filter、Aggregation、Limit、TopN、Projection 等算子 • FULL_PUSHDOWN：下推所有可支持的算子	DEFAULT
source-encoding	GaussDB 数据源编码方式	UTF-8
multiple-cnn-enabled	是否使用 GaussDB 多 CN 配置。如果使用，首先确保关闭 JDBC 连接池功能，其次 JDBC URL 格式为：jdbc:postgresql://host:port/database,jdbc:postgresql://host:port/database,jdbc:postgresql://host:port/database	false
parallel-read-enabled	是否使用并行数据读取功能 启用并行数据读取功能将基于节点分布和	false

名称	描述	取值样例
	“max-splits”参数值来确定实际的 split 数。 并行读取将与数据源创建多个连接，被依赖的数据源应当具备支持负载的能力。	
split-type	并行数据读取类型 • NODE：基于 GaussDB 数据源 DN 节点划分并行度 • PARTITION：基于表分区划分并行度 • INDEX：基于表索引划分并行度	NODE
max-splits	最大并行度	5
use-copymanager-for-insert	数据写入时是否使用 CopyManager 批量导入功能	false
unsupported-type-handling	当连接器不支持此数据类型时，可以转换为 VARCHAR，从而避免失败 • CONVERT_TO_VARCHAR：不支持的类型将转为 VARCHAR 类型，并且只支持对它们的读操作，不支持的类型包括：BIT VARYING、CIDR、MACADDR、INET、OID、REGTYPE、REGCONFIG、POINT • IGNORE（默认值）：不支持的类型将不在查询结果中显示	CONVERT_TO_VARCHAR
max-bytes-in-a-batch-for-copymanager-in-mb	CopyManager 批量导入每一批次最大数据量，单位：MB	10
decimal-mapping	默认情况下 HetuEngine 会跳过未指定精度或超过最大精度 38 位的 Decimal/Number/Numeric 数据类型，通过设置“decimal-mapping=allow_overflow”，将其映射为 Decimal(38，*x*)数据类型，x 值为 decimal-default-scale 的值	allow_overflow
decimal-default-scale	Decimal/Number/Numeric 映射数据类型 Decimal(38，*x*)小数位精度值，取值范围 0~38，默认为 0	0
case-insensitive-name-matching	HetuEngine 支持的 GAUSSDB 数据源的 Schema 和 Table 名称大小写格式敏感。 • false：仅支持查询全小写的 Schema 或 Table。默认值为 false。 • true： – 忽略大小写后无同名的 Schema 或 Table：支持查询该 Schema 或 Table。	false

名称	描述	取值样例
	– 忽略大小写后存在同名的 Schema 或 Table：不支持查询该 Schema 或 Table。	

– 单击“删除”可以删除已增加的自定义配置参数。

6. 单击“确定”。

步骤 3 登录集群客户端所在节点，执行以下命令，切换到客户端安装目录并认证用户。

cd /opt/client

source bigdata_env

kinit *HetuEngine 组件操作用户*　　（普通模式集群跳过）

步骤 4 执行以下命令，登录数据源的 catalog。

hetu-cli --catalog *数据源名称* **--schema** *数据库名*

例如执行以下命令：

hetu-cli --catalog guassdb_1 --schema admin

步骤 5 执行以下命令，可正常查看数据库表信息或不报错即表示连接成功。

show tables;

----结束

数据类型映射

GAUSSDB 数据类型（data type）	HetuEngine 数据类型（data type）
BOOLEAN	BOOLEAN
TINYINT	TINYINT
SMALLINT	SMALLINT
INTEGER	INTEGER
BINARY_INTEGER	INTEGER
BIGINT	BIGINT
SMALLSERIAL	SMALLINT
SERIAL	INTEGER
BIGSERIAL	BIGINT
FLOAT4 (REAL)	REAL
FLOAT8(DOUBLE PRECISION)	DOUBLE PRECISION

GAUSSDB 数据类型（data type）	HetuEngine 数据类型（data type）
DECIMAL[p (,s)]	DECIMAL[p (,s)]
NUMERIC[p (,s)]	DECIMAL[p (,s)]
CHAR(n)	CHAR(n)
CHARACTER(n)	CHAR(n)
NCHAR(n)	CHAR(n)
VARCHAR(n)	VARCHAR(n)
CHARACTER VARYING(55)	VARCHAR(n)
VARCHAR2(n)	VARCHAR(n)
NVARCHAR2(n)	VARCHAR
TEXT(CLOB)	VARCHAR
DATE	TIMESTAMP
TIMESTAMP	TIMESTAMP
UUID	UUID
JSON	JSON

约束

- 不支持如下语法：GRANT、REVOKE、SHOW GRANTS、SHOW ROLES、SHOW ROLE GRANTS。
- UPDATE 和 DELETE 语法不支持筛选条件子句中包含跨 catalog 的条件，例如：UPDATE mppdb.table SET column1=value WHERE column2 IN (SELECT column2 from hive.table)。
- UPDATE 语法不支持更新 DATE/TIMESTAMP/VARBINARY 字段。
- 不支持查询 WHERE 语句条件为 REAL，例如 SELECT * FROM mppdb.table WHERE column1 = REAL '1.1'。
- DELETE 语法不支持筛选条件子句中包含子查询，例如：DELETE FROM mppdb.table WHERE column IN (SELECT column FROM mppdb.table1)。
- HetuEngine 支持 GaussDB 数据源 Decimal/Number/Numeric 类型数据的最大精度不超过 38 位。
- 当谓词的前后两端任意一端包含子查询时，该谓词不会下推，如示例语句 count(*) 后面存在子查询，则不下推，但子查询中的 min 函数可以下推。

```
select count(*) from item where i_current_price = (select min(i_current_price) from item);
```

10.9.5 配置 HBase 数据源

操作场景

本章节指导用户在 HSConsole 界面添加 HBase 数据源。

前提条件

- 数据源所在集群域名与 HetuEngine 集群域名不能相同。
- 数据源所在集群与 HetuEngine 集群节点网络互通。
- 在 HetuEngine 所在集群的所有节点的“/etc/hosts”文件中，添加待对接数据源所在集群的主机名称和对应的 IP 映射，及其“/etc/hosts”文件中的“10.10.10.10 hadoop.*系统域名*”（如“10.10.10.10 hadoop.hadoop.com”），否则 HetuEngine 无法根据主机名称连接到非本集群节点。
- 已创建 HetuEngine 计算实例。
- 数据源所在集群与 HetuEngine 所在集群上 ZooKeeper 的 SSL 通信加密配置需保持一致。

说明

登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 配置 > 全部配置”，搜索“ssl.enabled”，值为“true”，表示启用 SSL 通信加密，值为“false”表示关闭 SSL 通信加密。

操作步骤

获取 HBase 数据源的“hbase-site.xml”、“hdfs-site.xml”和“core-site.xml”配置文件。

1. 登录 HBase 数据源所在集群的 FusionInsight Manager 页面。
2. 下载客户端。
   - MRS 3.3.0 之前版本：选择“集群 > 概览 > 更多 > 下载客户端”，根据界面提示下载“完整客户端”文件到本地。
   - MRS 3.3.0 及之后版本：在“主页”右上方单击“下载客户端”，根据界面提示下载“完整客户端”文件到本地。
3. 将下载的客户端文件压缩包解压，获取“FusionInsight_Cluster_1_Services_ClientConfig/HBase/config”路径下的“hbase-site.xml”、“core-site.xml”和“hdfs-site.xml”文件。
4. 如果“hbase-site.xml”文件中存在“hbase.rpc.client.impl”参数，那么“hbase.rpc.client.impl”的配置值修改成“org.apache.hadoop.hbase.ipc.RpcClientImpl”（客户端通过 RpcClientImpl 进行远程 RPC 调用），如下所示：

```
<property>
<name>hbase.rpc.client.impl</name>
<value>org.apache.hadoop.hbase.ipc.RpcClientImpl</value>
</property>
```

说明

如果“hdfs-site.xml”、“hbase-site.xml”文件中引用到了非 HetuEngine 集群节点的 host 名称，需要在 HetuEngine 集群的每个节点的“/etc/hosts”文件中，加上引用到的 host 名称和对应的 IP 的映射，否则 HetuEngine 无法根据 host 名称连接到非本集群节点。

步骤 1 获取 HBase 数据源的代理用户的“user.keytab”和“krb5.conf”文件。

1. 登录 HBase 数据源所在集群的 FusionInsight Manager 页面。
2. 选择“系统 > 权限 > 用户”。
3. 选择对应的数据源用户，在“操作”列中选择“更多 > 下载认证凭据”。
4. 从下载的文件中解压获取“user.keytab”和“krb5.conf”文件。

说明

数据源的代理用户需要具有对 HBase 的相关操作权限。

步骤 2 使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 3 在概览页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

选择“数据源”，单击“添加数据源”。在“添加数据源”页面填写参数。

1. 配置“基本配置”，填写数据源名称，选择数据源类型“HBase”。
2. 配置“HBase 配置”，参数配置请参考表 10-43。

表10-43 HBase 配置

参数	描述	取值样例
驱动	默认为“hbase-connector”。	hbase-connector
ZooKeeper Quorum 地址	该数据源 ZooKeeper 服务所有 quorumpeer 实例业务 IP。当该数据源 ZooKeeper 服务使用 IPv6 时，则需额外在 ZooKeeper Quorum 地址中指定客户端端口号。 登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。	• IPv4：10.0.136.132,10.0.136.133,10.0.136.134 • IPv6：[0.0.0.0.0.0.0.0]:24002
ZooKeeper 客户端端口号	ZooKeeper 客户端端口号。 登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。	2181
HBase RPC 通信保护	根据步骤 1 获取的“hbase-site.xml”里配置项“hbase.rpc.protection”的值进行选择： • 为“authentication”时选择“否”。 • 为“privacy”时选择“是”。	否
安全认证机制	打开安全模式后自动默认为 KERBEROS。	KERBEROS
Principal	开启安全认证机制时填写此参数。就是步骤 2 中获取的“user.keytab”文件所属的	user_hbase@HADOOP2.COM

参数	描述	取值样例
	用户。	
keytab 文件	开启安全模式时填写此参数。安全认证的密钥，在本地选择步骤 2 获取的“user.keytab”文件。	user.keytab
krb5 文件	开启安全模式时填写此参数。Kerberos 认证用到的配置文件，在本地选择步骤 2 获取的“krb5.conf”文件。	krb5.conf
hbase-site 文件	开启安全模式时填写此参数。连接 hdfs 时，需要的配置文件。在本地选择步骤 1 获取的“hbase-site.xml”文件。	hbase-site.xml
core-site 文件	开启安全模式时填写此参数。连接 hdfs 时需要用到的配置。在本地选择步骤 1 获取的“core-site.xml”文件。	core-site.xml
hdfs-site 文件	开启安全模式时填写此参数。连接 hdfs 时需要用到的配置。在本地选择步骤 1 获取的“hdfs-site.xml”文件。	hdfs-site.xml

3. （可选）自定义配置。
4. 单击“确定”。

步骤 4 登录集群客户端所在节点，执行以下命令，切换到客户端安装目录并认证用户。

cd /opt/client

source bigdata_env

kinit *HetuEngine 组件操作用户*　　（普通模式集群跳过）

步骤 5 执行以下命令，登录数据源的 catalog。

hetu-cli --catalog *数据源名称* **--schema** *数据库名*

例如执行以下命令：

hetu-cli --catalog hbase_1 --schema default

步骤 6 执行以下命令，可正常查看数据库表信息或不报错即表示连接成功。

show tables;

步骤 7 创建结构化映射表。

映射表建表语句格式：

```
CREATE TABLE schemaName.tableName (
  rowId VARCHAR,
  qualifier1 TINYINT,
  qualifier2 SMALLINT,
  qualifier3 INTEGER,
```

```
  qualifier4 BIGINT,
  qualifier5 DOUBLE,
  qualifier6 BOOLEAN,
  qualifier7 TIME,
  qualifier8 DATE,
  qualifier9 TIMESTAMP
)
WITH (
column_mapping =
'qualifier1:f1:q1,qualifier2:f1:q2,qualifier3:f2:q3,qualifier4:f2:q4,qualifier5:f2:
q5,qualifier6:f3:q1,qualifier7:f3:q2,qualifier8:f3:q3,qualifier9:f3:q4',
row_id = 'rowId',
hbase_table_name = 'hbaseNamespace:hbaseTable',
external = true
);
```

须知

“schemaName”必须与“hbase_table_name”中的“hbaseNamespace”一致，且 MRS 3.2.0 及以前版本只能是小写字母。

- 映射表建表支持：直接关联 HBase 数据源中的表、创建并关联 HBase 数据源中不存在的新表的两种形式。
- 映射表字段支持的数据类型包括：VARCHAR、TINYINT、SMALLINT、INTEGER、BIGINT、DOUBLE、BOOLEAN、TIME、DATE、TIMESTAMP。
- 映射表建表语句关键字说明见下表。

表10-44 映射表建表语句关键字说明

关键字	类型	是否必填	默认值	备注
column_mapping	String	否	所有的列在同一个 Family 列族下	指定映射表中列与 HBase 数据源表中列族的映射关系。如果需要关联一张 HBase 数据源中的表，那么 column_mapping 必须与 HBase 数据源中的一致；如果创建一张 HBase 数据源中不存在的新表，column_mapping 由用户指定。
row_id	String	否	映射表的第一列	HBase 数据源中表 rowkey 对应的列名。
hbase_table_name	String	否	空	指定需要关联的 HBase 数据源上的表空间和表名，用:连接。默认表空间为 default。如果创建一张 HBase 数据源中不存在的新表，hbase_table_name 不需要指定。
external	Boolean	否	true	如果 external=true ，表示该表为 HBase 数据源中表的一个映射表，不支持删除

关键字	类型	是否必填	默认值	备注
				HBase 数据源上的原始表；如果 external=false，则删除 Hetu-HBase 表的同时，会删除 HBase 数据源上的表。

----结束

数据类型映射

HBase 是基于字节的分布式存储系统，它将所有数据类型存储为字节数组。要在 HetuEngine 中表示 HBase 数据，需要先在 HetuEngine 中通过创建映射表的方式为 HetuEngine 列限定符选择与 HBase 列限定符的值相匹配的数据类型。

目前 HetuEngine 列限定符支持以下数据类型：VARCHAR、TINYINT、SMALLINT、INTEGER、BIGINT、DOUBLE、BOOLEAN、TIME、DATE 和 TIMESTAMP。

性能优化

- 谓词下推

  查询支持大部分算子下推，例如基于 Row Key 的点查和基于 Row Key 的范围查询。

  查询支持的谓词条件有：=、>=、>、<、<=、!=、IN、NOT IN、IS NULL、IS NOT NULL 和 BETWEEN AND。

- 批量 GET 查询

  批量 GET 即在 HBase 的 API 中将所要查询的多个 Row Key 封装成一个 List<Get>，然后请求这个列表以获取数据的查询方式。该方式能避免每个 Row Key 都发起一次请求。

- HBase 单表查询范围扫描优化

  HBase 单表查询范围扫描优化是指根据 HBase 的列的谓词条件尝试自动推断 rowkey 的起止地址，在 tableScan 的时候设置 hbase scan 起止地址从而提高访问性能。

  比如假设 HBase 数据表的 rowkey 由 building_code:house_code:floor:uuid 四列组成，对于查询过滤条件 where building_code = ‘123’ and house_code = ‘456’，HetuEngine 单表查询优化会只扫描 rowkey 范围前缀为‘123-456’的列，从而提高性能。

  开启 HBase 单表查询范围扫描优化的功能需要在 5.3 中添加自定义参数“hbase.rowkey.adaptive.optimization.enabled”，值为“true”。

  此外，在建表语句的建表属性中需指定 rowkey 的组成列和分隔字符：

表10-45 HBase 的 rowkey 组成列和分隔字符

表属性	表属性含义	样例
row_id_construct_columns	HBase 数据表的 rowkey 组	building_code:house_cod

表属性	表属性含义	样例
	成列	e:floor:uuid
row_id_construct_columns_terminal	HBase 数据表的 rowkey 组成列的分割字符	:

例如一个有 building_code:house_code:floor:uuid 四列组成的 rowkey 的建表语句如下：

```
CREATE TABLE test.table_hbase_test (
row_id string,
col1 string,
col2 string,
col3 string,
building_code string,
house_code string,
floor string,
uuid string)
WITH (column_mapping = '
col1:attr:col1,
col2:attr:col2,
col3:attr:col3,
building_code:attr:building_code,
house_code:attr:house_code,
floor:attr:floor,
uuid:attr:uuid',
row_id = 'row_id',
row_id_construct_columns = 'building_code:house_code:floor:uuid',
row_id_construct_columns_terminal = ':',
hbase_table_name='test:table_hbase_test',
external = true)
```

- Hbase 多表联合查询动态过滤优化

  HBase 支持“like、>、>=、<、<=、=”六种算子的优化。

  开启动态过滤功能，需先开启 HBase 单表查询范围扫描优化功能，然后还需要在计算实例中添加“coordinator.config.properties”参数文件的自定义参数“dynamic_filtering_pushdown_callexpression”，值为“true”，可参考步骤 3.5。

约束

不支持如下语法：ALTER，VIEW。

10.9.6 配置 HetuEngine 数据源

操作场景

本章节指导用户在安全模式集群下通过 HSConsole 界面添加另一个 HetuEngine 数据源。

操作步骤

获取他域 HetuEngine 集群的代理用户的“user.keytab”文件。

1. 登录他域 HetuEngine 集群 FusionInsight Manager 页面。
2. 选择“系统 > 权限 > 用户”。
3. 选择对应的数据源用户，在“操作”列中选择“更多 > 下载认证凭据”。
4. 从下载的文件中解压出来的“user.keytab”文件就是用户的凭据文件。

步骤 1 使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 2 在概览页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 3 选择“数据源”，单击“添加数据源”。在“添加数据源”页面填写参数。

1. 配置“基本配置”，填写数据源名称，选择数据源类型“HetuEngine”。
2. 配置“HetuEngine 配置”，参数配置请参考表 10-46。

表10-46 HetuEngine 配置

参数	描述	取值样例
驱动	默认“hsfabric-initial”。	hsfabric-initial
用户名	开启安全模式时填写此参数。 访问远端 HetuEngine 的用户。就是步骤 1 中获取“user.keytab”所属用户。	hetu_test
keytab 文件	开启安全模式时填写此参数。 访问远端 DataCenter 的用户 Keytab 文件。在本地选择步骤 1k 获取的“user.keytab”文件。	user.keytab
开启双向传输	跨域数据传输是否开启双向传输，默认为“是”。 • 是：双向传输，请求通过本端的 HSFabric 将转发至远端的 HSFabric，如果开启双向传输，需要配置本端 HSFabric 地址。 • 否，单向传输，请求直接发至远端的 HSFabric。	是
本端地址信息	本端 MRS 集群的 HetuEngine 服务负责对外通信的 HSFabric 实例的主机 IP 地址及端口号。 1. 登录本端集群 FusionInsight Manager，选择“集群 > 服务 > HetuEngine > 实例”，查看 HSFabric 的业务 IP 地址。 2. 单击“HSFabric”，选择“实例配置”，查看“server.port”的值，默认为	192.162.157.32:29900

参数	描述	取值样例
	“29900”。	
远端地址信息	远端 MRS 集群的 HetuEngine 服务负责对外通信的 HSFabric 实例的主机 IP 地址及端口号。 1. 登录远端集群 FusionInsight Manager，选择“集群 > 服务 > HetuEngine > 实例”，查看 HSFabric 的业务 IP 地址。 2. 单击“HSFabric”，选择“实例配置”，查看“server.port”的值，默认为“29900”。	192.168.1.1:29900
区域	当前请求发起方所属区域，只能包数字和下划线。	0755_01
接收超时时长(秒)	等待接收数据的超时时长(单位：秒)。	60
Task 总超时时长(秒)	每个跨域 Task 执行的总超时时长(单位：秒)。	300
Worker 节点使用 Task 数	每个 Worker 节点接收数据时使用的 Task 数量。	5
开启数据压缩	• 是：启动数据压缩。 • 否：不启动数据压缩。	是

3. （可选）自定义配置。
   - 单击“增加”可以增加自定义配置参数。配置 HetuEngine 数据源自定义参数，参考表 10-47。

表10-47 HetuEngine 数据源自定义配置参数

名称	描述	取值样例
hsfabric.health.check.time	设置检测 HSFabric 实例状态的周期间隔，单位：秒	60
hsfabric.subquery.pushdown	开启跨域查询下推参数，默认开启。 • true：开启跨域查询下推。 • false：不开启跨域查询下推。	true
hsfabric.local.tenant 适用于 MRS 3.3.0 及以后版本	指定远端 HetuEngine 计算所使用的租户队列。 • 未配置该参数，系统会根据配置的用户，随机选择该用户所属的租户。 • 配置该参数，系统则会指定租户。适用于包括开启了租户的严格校验模式等场景。	-

- 单击“删除”可以删除已增加的自定义配置参数。

4. 单击“确定”。

步骤 4 登录集群客户端所在节点，执行以下命令，切换到客户端安装目录并认证用户。

cd /opt/client

source bigdata_env

kinit *HetuEngine 组件操作用户*　　（普通模式集群跳过）

步骤 5 执行以下命令，登录数据源的 catalog。

hetu-cli --catalog *数据源名称* **--schema** *数据库名*

例如执行以下命令：

hetu-cli --catalog hetuengine_1 --schema default

步骤 6 执行以下命令，可正常查看数据库表信息或不报错即表示连接成功。

show tables;

----结束

数据类型映射

目前 HetuEngine 数据源支持的数据类型为：BOOLEAN、TINYINT、SMALLINT、INT、BIGINT、REAL、DOUBLE、DECIMAL、VARCHAR、CHAR、DATE、TIMESTAMP、ARRAY、MAP、TIME WITH TIMEZONE、TIMESTAMP WITH TIME ZONE、TIME。

性能优化

支持使用查询下推功能，提高查询速度。

查询下推功能默认打开，也可参考步骤 4.3 添加相关自定义参数开启查询下推功能。

约束

- 不支持如下语法：CREATE、ALTER、DROP VIEW、INSERT OVERWRITE、UPDATE、DELETE。
- 不支持跨域数据源的 INSERT 操作。

10.9.7 配置 IoTDB 数据源

本章节适用于 MRS 3.2.0 及之后的版本。

操作场景

本章节指导用户在安全模式集群的 HSConsole 界面添加 IoTDB 类型的 JDBC 数据源。

前提条件

- 数据源所在集群域名与 HetuEngine 集群域名不能相同。
- 数据源所在集群与 HetuEngine 集群节点网络互通。
- 已创建 HetuEngine 计算实例。
- 安全集群的 IoTDB 默认开启了 SSL，开启了 SSL 后需上传“truststore.jks”文件，可参考 14.2 使用 IoTDB 客户端获取该文件。

操作步骤

使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在“概览”页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 选择“数据源”，单击“添加数据源”。在“添加数据源”页面填写参数。

1. 配置“基本配置”，填写数据源名称，选择数据源类型“JDBC > IoTDB”。
2. 配置“IoTDB 配置”，参数配置请参考表 10-48。

表10-48 IoTDB 配置

参数	描述	取值样例
驱动	默认为“iotdb”。	iotdb
JDBC URL	连接 IoTDB 的 JDBC URL 地址。 • IoTDB 数据源使用 IPV4，则格式为：jdbc:iotdb://*IoTDBServer 业务 IP*:*端口号*; • IoTDB 数据源使用 IPV6，则格式为：jdbc:iotdb://[*IoTDBServer 业务 IP*]:*端口号*	• IPV4：jdbc:iotdb://10.10.10.11:22260 • IPV6：jdbc:iotdb://[10:10::10:11]:22260
用户名	连接 IoTDB 数据源的 IoTDB 用户名。	**说明** 当 IoTDB 所在集群为非安全模式时，需使用 IoTDB 默认用户“root”。
密码	连接 IoTDB 数据源的 IoTDB 用户密码。	**说明** 当 IoTDB 所在集群为非安全模式时，请咨询 IoTDB 所在集群的集群管理员获取用户“root”的密码。
开启 ssl	IoTDB 服务是否开启了 SSL，安全集群默认开启。	是
truststore 文件	IoTDB 开启 SSL 后需上传“truststore.jks”文件。	-

说明

- IoTDBServer 业务 IP：
  登录 Manager，选择“集群 > 服务 > IoTDB > 实例”，查看 IoTDBServer 的业务 IP。
- 端口号：
  登录 Manager，选择“集群 > 服务 > IoTDB > 配置”，搜索并查看“IOTDB_SERVER_RPC_PORT”的值，默认为“22260”。

3. （可选）根据需求可添加自定义配置。
4. 单击“确定”。

步骤 3 登录集群客户端所在节点，执行以下命令，切换到客户端安装目录并认证用户。

cd /opt/client

source bigdata_env

kinit *HetuEngine 组件操作用户*　　（普通模式集群跳过）

步骤 4 执行以下命令，登录数据源的 catalog。

hetu-cli --catalog *数据源名称* **--schema** *数据库名*

例如执行以下命令：

hetu-cli --catalog iotdb_1 --schema root.ln

步骤 5 执行以下命令，可正常查看数据库表信息或不报错即表示连接成功。

show tables;

----结束

数据类型映射

IoTDB 数据类型（data type）	HetuEngine 数据类型（data type）
BOOLEAN	BOOLEAN
INT32	BIGINT
INT64	BIGINT
FLOAT	DOUBLE
DOUBLE	DOUBLE
TEXT	VARCHAR

功能增强

- IoTDB 可为时间序列设置任意标签字段，HetuEngine 侧查询可将 IoTDB 的这些标签字段与其他数据源进行融合查询。
- IoTDB 存储组节点到时间序列中的任意节点，均可作为 HetuEngine 侧查询的表进行数据查询。

约束

- 不支持 IoTDB 数据创建，只支持 IoTDB 数据查询。
- 使用 HetuEngine 进行查询的 IoTDB 用户至少需要配置根目录 root 下的读权限。

10.9.8 配置 MySQL 数据源

本章节适用于 MRS 3.3.0 及之后的版本。

HetuEngine 支持配置 MySQL 数据源实现对 MySQL 数据源的接入与查询功能。本章节指导用户在集群的 HSConsole 界面添加 MySQL 类型的 JDBC 数据源。

前提条件

- 数据源与 HetuEngine 集群节点网络互通。
- 集群已启用 Kerberos 认证（安全模式）创建 HetuEngine 管理员用户，集群未启用 Kerberos 认证（普通模式）创建 HetuEngine 业务用户，并为其赋予 HDFS 管理员权限，即创建用户时需同时加入“hadoop”和“hadoopmanager”用户组，创建用户可参考 10.3 创建 HetuEngine 用户。
- 已创建 HetuEngine 计算实例，可参考 10.4 创建 HetuEngine 计算实例。
- 已获取 MySQL 数据库所在的 IP 地址，端口号，用户名及密码。

HetuEngine 对接 MySQL 数据源约束

- HetuEngine 支持对接 MySQL 操作的 SQL 语法：SHOW CATALOGS/SCHEMAS/TABLES/COLUMNS、DESCRIBE、USE、SELECT 表/视图。
- HetuEngine 支持的 MySQL 数据源的 Schema 和 Table 名称不区分大小写。
- 不支持在具有 CHAR 或 VARCHAR 等文本类型的列上下推任何谓词。

  例如：由于 name 是 VARCHAR 类型的列，因此如下两个查询的谓词均不会下推。

```
SELECT * FROM nation WHERE name>'abcd';
SELECT * FROM nation WHERE name='abcd';
```

配置 MySQL 数据源步骤

安装集群客户端

安装包含 HetuEngine 服务的集群客户端，例如安装目录为“/opt/hadoopclient”。

准备 MySQL 驱动

从 MySQL 官网获取 MySQL 驱动文件，格式为“*xxx*.jar”，支持版本为 MySQL 5.7，MySQL 8.0 及以后版本。

步骤 1 上传 MySQL 驱动文件至 HetuEngine 所在集群。

可通过如下两种方式：

- 通过 Manager 界面上传至 HDFS：

a. 使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HDFS”，进入 HDFS 服务页面。

b. 在“概览”页签下的“基本信息”区域，单击“NameNode Web UI”后的链接，进入 NameNode Web UI 界面。

c. 选择“Utilities > Browse the file system”，单击  ，创建“/user/hetuserver/fiber/extra_file/driver/mysql”目录。

d. 进入“/user/hetuserver/fiber/extra_file/driver/mysql”目录，单击  上传步骤 2 获取的 MySQL 驱动文件。

e. 单击驱动文件所在行的“Permission”列的值，勾选“User”列的“Read”和“Write”，“Group”列的“Read”和“Other”列的“Read”，单击“Set”。

- 通过使用 HDFS 命令直接上传：

a. 登录 HDFS 服务客户端所在节点，切换到客户端安装目录，如“/opt/hadoopclient”。

cd /opt/hadoopclient

b. 执行以下命令配置环境变量。

source bigdata_env

c. 如果集群为安全模式，执行以下命令进行用户认证。普通模式集群无需执行用户认证。

kinit *HetuEngine 管理员用户*

根据回显提示输入密码。

d. 执行如下命令创建目录“/user/hetuserver/fiber/extra_file/driver/mysql”，并上传步骤 2 获取的 MySQL 驱动，然后修改对应的权限。

hdfs dfs -mkdir -p /user/hetuserver/fiber/extra_file/driver/mysql

hdfs dfs -put ./*MySQL 驱动文件* **/user/hetuserver/fiber/extra_file/driver/mysql**

hdfs dfs -chmod -R 644 /user/hetuserver/fiber/extra_file/driver/mysql

配置 MySQL 数据源

使用 HetuEngine 管理员用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 2 在“概览”页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 3 选择“数据源”，单击“添加数据源”。在“添加数据源”页面填写参数。

1. 配置“基本配置”，填写数据源名称，选择数据源类型“JDBC > MySQL”。
2. 配置“MySQL 配置”，参数配置请参考表 10-49。

表10-49 MySQL 配置

参数	描述	取值样例

参数	描述	取值样例
驱动	默认为“mysql”。	mysql
驱动名称	选择步骤 2 中已提前上传的待使用的 MySQL 驱动，格式为 *xxx*.jar。	mysql-connector-java-8.0.11.jar
JDBC URL	连接 MySQL 的 JDBC URL 地址。 格式：jdbc:mysql://*MySQL 数据库所在的 IP 地址*:*端口号*。 端口号默认为 3306。	• IPV4：jdbc:mysql://10.10.10.11:3306 • IPV6：jdbc:mysql://[10:10::10:11]:3306
用户名	连接 MySQL 数据源的 MySQL 用户名。	-
密码	连接 MySQL 数据源的 MySQL 用户密码。	-

3. （可选）自定义配置。

   单击“增加”可以增加自定义配置参数。配置 MySQL 数据源自定义参数，参考表 10-50。

表10-50 MySQL 数据源自定义配置参数

参数	描述	取值样例
mysql.auto-reconnect	是否自动重连。 • true（默认值）：开启自动重连。 • false：关闭自动重连。	true
mysql.max-reconnects	最大重连次数，默认值：3。	3
mysql.jdbc.use-information-schema	驱动程序是否应该使用 INFORMATION_SCHEMA 来派生“DatabaseMetaData”使用的信息。	true
use-connection-pool	是否使用 JDBC 连接池，默认值：false。	false
jdbc.connection.pool.maxTotal	JDBC 连接池中最大连接数，默认值：8。	8
jdbc.connection.pool.maxIdle	JDBC 连接池中最大空闲连接数，默认值：8。	8
jdbc.connection.pool.minIdle	JDBC 连接池中最小空闲连接数，默认值：0。	0
case-insensitive-name-matching	HetuEngine 支持的 MySQL 数据源的 Schema 和 Table 名称大小写格式敏感。 • false（默认值）：仅支持查询全小写的	false

参数	描述	取值样例
	Schema 和 Table。 • true： – 忽略大小写后无同名的 Schema 和 Table：支持查询该 Schema 和 Table。 – 忽略大小写后存在同名的 Schema 和 Table：不支持查询该 Schema 和 Table。	
case-insensitive-name-matching.cache-ttl	MySQL 数据源的大小写敏感的 Schema 和 Table 名称缓存超时时长，默认值：1m（1 分钟）。	1m
dynamic-filtering.enabled	是否将动态过滤器下推到 JDBC 查询中。 • true（默认值）：开启下推。 • false：关闭下推。	true
dynamic-filtering.wait-timeout	在启动 JDBC 查询之前，HetuEngine 将等待从连接的构建端收集动态过滤器的最大持续时间。使用较大的超时可能会导致更详细的动态过滤器。但是也会增加某些查询的延迟，默认值：20s。	20s
unsupported-type-handling	当连接器不支持此数据类型时，是否将其转换为 VARCHAR，从而避免失败。 • CONVERT_TO_VARCHAR：将不支持的类型转为 VARCHAR 类型，并且只支持对它们的读操作。 • IGNORE（默认值）：不支持的类型将不在查询结果中显示。	IGNORE
join-pushdown.enabled	是否启用 Join 下推。 • true（默认值）：开启 Join 下推。 • false：关闭 Join 下推。	true
join-pushdown.strategy	用于评估 Join 操作是否被下推的策略。默认值：AUTOMATIC • AUTOMATIC（默认值）：启用基于成本的连接下推。 • EAGER：尽可能下推 Join。即使表统计信息不可用， EAGER 也可以下推 Join，这可能会导致查询性能下降，因此仅建议将 EAGER 用于测试和故障排除场景。	AUTOMATIC

单击“删除”可以删除已增加的自定义配置参数。

4. 单击“确定”。

步骤 4 登录集群客户端所在节点，执行以下命令，切换到客户端安装目录并认证用户。

cd /opt/hadoopclient

source bigdata_env

kinit *HetuEngine 组件操作用户*　　（普通模式集群跳过）

步骤 5　执行以下命令，登录数据源的 catalog。

hetu-cli --catalog *数据源名称* **--schema** *数据库名*

例如执行以下命令：

hetu-cli --catalog mysql_1 --schema mysql

步骤 6　执行以下命令，可正常查看数据库表信息或不报错即表示连接成功。

show tables;

----结束

MySQL 与 HetuEngine 数据类型映射

MySQL 数据类型到 HetuEngine 数据类型映射

MySQL 类型	HetuEngine 类型
BIT	BOOLEAN
BOOLEAN	TINYINT
TINYINT	TINYINT
SMALLINT	SMALLINT
INTEGER	INTEGER
BIGINT	BIGINT
DOUBLE PRECISION	DOUBLE
FLOAT	REAL
REAL(m, d)	REAL(m, d)
DECIMAL(p, s)	DECIMAL(p, s)
CHAR(n)	CHAR(n)
VARCHAR(n)	VARCHAR(n)
TINYTEXT	VARCHAR(255)
TEXT	VARCHAR(65535)
MEDIUMTEXT	VARCHAR(16777215)
LONGTEXT	VARCHAR
ENUM(n)	VARCHAR(n)
BINARY, VARBINARY, TINYBLOB,	VARBINARY

MySQL 类型	HetuEngine 类型
BLOB, MEDIUMBLOB, LONGBLOB	
JSON	JSON
DATE	DATE
TIME(n)	TIME(n)
DATETIME(n)	TIMESTAMP(n)
TIMESTAMP(n)	TIMESTAMP(n)

10.9.9 管理已配置的数据源

操作场景

在 HetuEngine 的 WebUI 界面，用户可以对已添加的数据源进行查看、编辑和删除等操作。

前提条件

已创建用于访问 HetuEngine WebUI 界面的 HetuEngine 管理员用户，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。

操作步骤

使用 HetuEngine 管理员用户登录 Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在“概览”页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 单击“数据源”，在数据源列表中可以查看数据源名称、数据源描述、数据源类型和创建时间等信息，在“操作”列下也可以编辑和删除数据源。

----结束

10.10 使用 HetuEngine 物化视图

10.10.1 物化视图概述

物化视图功能适用于 MRS 3.2.0 及以后版本。

背景介绍

HetuEngine 具备物化视图能力。在实际运用中，将高频访问的 SQL 查询和有高耗时的算子（连接， 聚合等算子）的 SQL 通过建立物化视图进行预计算，然后在查询的

SQL 中将能匹配到物化视图的查询或者子查询转换为物化视图，避免了数据的重复计算，这种情况下往往能较大地提高查询的响应效率。

物化视图通常基于对数据表进行聚合和连接的查询结果创建。

物化视图支持“查询重写”，这是一种优化技术，即将基于原始表编写的查询语句转换为查询一个或多个物化视图语句的等效请求。如下物化视图的 SQL 示例：

```
create materialized view mv.default.mv1 with(storage_table='hive.default.mv1') AS
select id from hive.mvschema.t1;
```

该物化视图实际数据的存储表为“hive.default.mv1”，在查询重写时，查询 SQL“select id from hive.mvschema.t1”会被重写成查询物化视图的表，即“select id from hive.default.mv1”。

使用场景

与普通的视图相比，物化视图会存储实际数据，占用存储资源，并且会有预计算带来的数据滞后性的问题，因此物化视图推荐在如下场景中使用：

- 执行频次高的查询。
- 查询包含非常耗时的操作，比如聚合、连接操作等。
- 对查询结果数据可以允许有一定的滞后性。
- 物化视图仅支持对接共部署 Hive 和外接 Hive 数据源，并且数据源表的存储格式为 ORC 或者 PARQUET，不支持跨源跨域场景。

权限介绍

物化视图权限如表 10-51。物化视图权限控制依赖 Ranger，若关闭 Ranger 鉴权会带来权限失效的风险。

表10-51 HetuEngine 物化视图权限介绍

操作	catalog mv 权限	物化视图存储表的权限	原始物理表的权限
创建物化视图	建表权限	NA	对应列的查询权限
删除物化视图	删除表权限	NA	NA
刷新物化视图	表的更新权限	NA	对应列的查询权限
使用物化视图重写查询语句	NA	NA	对应列的查询权限
使用物化视图重写查询语句的执行计划（EXPLAIN）	NA	对应列的查询权限	对应列的查询权限
查询物化视图	对应列的查询权限	NA	NA
物化视图和非物化视图	对应列的查询	NA	对应列的查询权限

操作	catalog mv 权限	物化视图存储表的权限	原始物理表的权限
的物理表联合查询	权限		
查看物化视图	NA	NA	NA
查看物化视图的创建语句	表的 Show 权限	表的 Show 权限	NA

使用介绍

表10-52 物化视图使用介绍

阶段	说明	参考章节
物化视图 SQL 示例	介绍物化视图支持的操作，包括创建物化视图、列举物化视图、查询物化视图等	10.10.2 物化视图 SQL 示例
配置物化视图改写能力	开启物化视图能力，提高查询的响应效率	10.10.3 配置物化视图改写能力
配置物化视图推荐能力	自动学习并推荐对业务最有价值的物化视图 SQL，使在线查询效率获得倍数提升，同时有效降低系统负载压力	10.10.4 配置物化视图推荐能力
配置物化视图缓存能力	可将多次执行并改写后的 SQL 保存到缓存中，再次执行这条 SQL 时会直接从缓存中获取改写后的 SQL，而不是重新对 SQL 进行改写，提高查询效率	10.10.5 配置物化视图缓存能力
配置物化视图有效期与数据刷新	• 设置物化视图的有效期，当前系统只会使用有效期内的物化视图进行自动改写 • 设置数据定期更新，可定时手动刷新或自动刷新物化视图	10.10.6 配置物化视图的有效期与数据刷新能力
配置智能物化视图	提供自动化物化视图的创建，无需手动执行 SQL 创建物化视图（推荐使用）	10.10.7 配置智能物化视图能力
查看物化视图自动化任务记录	看任务执行情况，帮助评估集群运行健康状况	10.10.8 查看物化视图自动化任务

10.10.2 物化视图 SQL 示例

物化视图 SQL 示例请参考表 10-53。

表10-53 物化视图的操作

操作	功能	物化视图 SQL 样例	备注
创建物化视图	创建永不过期的物化视图	create materialized view mv.default.mv1 with(storage_table='hive.default.mv11') AS select id from hive.mvschema.t1;	• storage_table：物化视图数据物化成物理表的位置 • 创建物化视图时的 catalog 必须指定 mv，schema 可以自行创建 • AS SELECT 子句需注意创建物化视图的“AS SELECT”的子句列出的事项
	创建有效期为 1 天不启动自动刷新的物化视图	create materialized view mv.default.mv1 with(storage_table='hive.default.mv11', mv_validity = '24h') AS select id from hive.mvschema.t1;	mv_validity：物化视图的有效期
	创建每小时自动刷新一次数据的物化视图	create materialized view mv.default.mv1 with(storage_table='hive.default.mv1', need_auto_refresh = true, mv_validity = '1h', start_refresh_ahead_of_expiry = 0.2, refresh_priority = 3, refresh_duration = '5m') AS select id from hive.mvschema.t1;	• need_auto_refresh：是否启用自动刷新 • start_refresh_ahead_of_expiry：刷新任务在“mv_validity*（1-start_refresh_ahead_of_expiry）”的时间触发一次更新状态为“可刷新” • refresh_priority：刷新任务优先级 • refresh_duration：刷新任务的最大允许时间
列举物化视图	列举 catalog 名为“mv”，schema 名为“mvschema”的所有物化视图	show materialized views from mvschema;	mvschema 是 schema 的名称，catalog 固定为“mv”
	根据子句“LIKE”筛选视图名满足规则运算	show MATERIALIZED VIEWs in mvschema tables like '*mvtb_0001';	mvschema 是 schema 的名称

操作	功能	物化视图 SQL 样例	备注
	表达式的物化视图		
查询物化视图的创建语句	查询 mv.default.mv1 的物化视图创建语句	show create materialized view mv.default.mv1;	mv1 是物化视图的名称
查询物化视图	查询 mv.default.mv1 的数据	select * from mv.default.mv1;	mv1 是物化视图的名称
刷新物化视图	刷新 mv.default.mv1 的物化视图	refresh materialized view mv.default.mv1;	-
修改物化视图属性	修改 mv.default.mv1 的物化视图的属性	Alter materialized view mv.mvtestprop.pepa_ss set PROPERTIES(refresh_priority = 2);	refresh_priority = 2 是物化视图的属性
修改物化视图状态	修改 mv.default.mv1 的物化视图的状态	alter materialized view mv.default.mv1 set status SUSPEND;	SUSPEND 是物化视图的状态，状态还包括： • SUSPEND：暂停使用状态，暂停使用的物化视图不会参与改写 • ENABLED：可使用状态 • Refreshing：正在刷新物化视图数据，不可用于改写 • DISABLED：关闭使用 • UNKNOWN：缓存与数据库不一致，建议执行 SQL: refresh catalog mv; 手动刷新仅支持 ENABLED 和 SUSPEND 相互转换
删除物化视图	删除 mv.default.mv1 的物化视图	drop materialized view mv.default.mv1;	-

操作	功能	物化视图 SQL 样例	备注
启用使用物化视图改写 SQL 进行优化	在 session 级别启用使用物化视图改写 SQL 进行优化	set session materialized_view_rewrite_enabled=true;	-
验证查询是否能通过改写成物化视图进行 SQL 优化	验证查询 SQL 语句能否被 mv.default.mv1 改写优化	verify materialized view mvname(mv.default.mv1) originalsql select id from hive.mvschema.t1;	-
SQL 级别使用指定的物化视图进行 SQL 改写优化	在查询中强制使用 mv.default.mv1 进行优化	/*+ REWRITE(mv.default.mv1) */ select id from hive.mvschema.t1;	-
SQL 级别禁用物化视图进行 SQL 改写优化	在查询中禁止物化视图进行优化	/*+ NOREWRITE */ select id from hive.mvschema.t1;	-
刷新物化视图元数据信息缓存	同步不同租户间物化视图元数据信息缓存	refresh catalog mv;	-

创建物化视图的“AS SELECT”的子句

创建物化视图的“AS SELECT”的子句不能包含 calcite SQL 解析和改写功能中的保留关键词，如“default”。如果想要在创建物化视图的“AS SELECT”子句中使用保留关键词，需要遵循以下的任一解决方案：

- 在创建 MV 和执行原始查询时，需给默认模式名称添加双引号

  以在“AS SELECT”子句中使用保留关键词“default”为例：

  创建物化视图

  ```
  CREATE MATERIALIZED VIEW mv.default.mv1 WITH(storage_table='hive.default.mv11')
  AS SELECT id FROM hive."default".t1;
  ```

  SELECT 查询

  ```
  SELECT id FROM hive."default".t1;
  ```

- 在 Session 级别设置相应的 catalog 和 schema，而不是在查询中传递完全限定的名称

以指定 catalogname 为“hive”，schemaname 为“default”为例：

```
USE hive.default;
```

创建物化视图

```
CREATE MATERIALIZED VIEW mv.default.mv1 WITH(storage_table='hive.default.mv11')
AS SELECT id FROM t1;
```

SELECT 查询

```
SELECT id FROM t1;
```

10.10.3 配置物化视图改写能力

开启物化视图改写能力

HetuEngine 支持在 System 级别或者 Session 级别开启物化视图改写能力，开启方法如下所示：

- Session 级别：

  参考 10.6 使用 HetuEngine 客户端在 HetuEngine 客户端执行 **set session materialized_view_rewrite_enabled=true**

- System 级别：

  a. 使用用于访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager。

  b. 选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

  c. 在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

  d. 查看待操作的实例的状态是否为“停止”，否则修改为“停止”。

  e. 在待操作的实例所在行“操作”列单击“配置”，添加如下自定义参数。

名称	值	参数文件
materialized.view.rewrite.enabled	true	coordinator.config.properties
materialized.view.rewrite.timeout	5	coordinator.config.properties

说明

适用于 MRS 3.2.0 及之后版本。

- materialized.view.rewrite.timeout：物化视图的重写超时控制（单位：秒），推荐 5s。物化视图重写时会消耗一定的时间，添加该参数可限制重写所带来的性能损耗，物化视图重写超时后会执行原始 SQL。
- 若使用 Session 级别开启物化视图功能，并需要开启物化视图重写超时控制，可先执行 **set session materialized_view_rewrite_timeout = 5**。

  f. 参数添加完成后，勾选“立即启动”，单击“确定”。

物化视图改写能力支持范围

- 物化视图支持的类型

BOOLEAN、DECIMAL、DOUBLE、REAL/FLOAT、INT、BIGINT、SMALLINT、TINYINT、CHAR/VARCHAR、DATE、TIME、TIMESTAMP、INTERVAL YEAR TO MONTH、INTERVAL DAY TO SECOND、BINARY/VARBINARY、UUID。

- 物化视图改写支持的函数
  - 转换函数：只支持 CAST 函数。
  - 字符串函数：支持所有字符串函数，包括 char_length、character_length、chr、codepoint、decode、encode、find_in_set、format_number、locate、hamming_distance、instr、levenshtein、levenshtein_distance、ltrim、lpad、octet_length、position、quote、repeat2。
  - 数学运算符：支持所有数学运算符。
  - 聚合函数：支持的聚合函数包括 COUNT、SUM、MIN、MAX、AVG、LEAD、LAG、FIRST_VALUE、LAST_VALUE、COVAR_POP、COVAR_SAMP、REGR_SXX、REGR_SYY、STDDEV_POP、STDDEV_SAMP、VAR_POP、VAR_SAMP、ROW_NUMBER、RANK、PERCENT_RANK、DENSE_RANK、CUME_DIST。

须知

以下场景，物化视图不支持对包含了函数的 SQL 查询进行改写：

- SQL 中包含无参函数
- SQL 中包含了 HetuEngine 支持的会根据参数的类型获得不同类型的返回值的函数
- SQL 中函数存在嵌套使用，或者是使用的函数会抛出异常导致重写失败的函数

物化视图改写场景示例

物化视图的改写的核心原理是逻辑上创建的物化视图的数据要包含未来的查询语句要查询的数据，也可以是未来查询中的子查询要包含的全部数据。建议用户打开自动创建物化视图功能针对性的创建物化视图，以下为部分场景示例：

创建物化视图 SQL 样例中省略“CREATE MATERIALIZED VIEW *xxx* WITH(*xxx*) AS”，完整语句模板可参考表 10-53。

表10-54 物化视图改写场景示例

场景	描述	创建物化视图 SQL 样例	用户查询 SQL 样例	查询 SQL 是否能被改写	备注
全表查询	最基本的全表查询场景	select * from tb_a;	select * from tb_a;	否	创建全表扫描的物化视图没有实际意义，不支

场景	描述	创建物化视图 SQL 样例	用户查询 SQL 样例	查询 SQL 是否能被改写	备注
					持
列查询	最基本的列查询场景	select col1,col2,col3 from tb_a;	select col1,col2,col3 from tb_a;	是	-
	用户查询重命名	select col1 from tb_a;	select col1 as a from tb_a;	是	-
		select col1,col2,col3 from tb_a;	select col1 as a,col2 as b,col3 as c from tb_a;	是	-
	数学表达式	select col1*col2 from tb_a;	select col2*col1 from tb_a;	是	需要两个列的类型一样
	物化视图使用源列，用户查询使用 cast	select col1,col2 from tb_a;	select cast(col1 as varchar),col2 from tb_a;	否	物化视图使用原数据列，用户查询使用函数没有过滤条件不改写 物化视图使用原数据列，用户查询也是用原数据列加过滤条件可改写
	case when 场景	select col1, (case col2 when 1 then 'b' when 2 'a' end) as col from tb_a;	select col1, (case col2 when 1 then 'b' when 2 'a' end) as col from tb_a;	否	不支持查询列中出现 case when 场景
	字符串函数	select col13 from tb_a;	select length(col13) from tb_a;	否	所有的字符串函数用原表数据建立物化视图不加过滤条件的查询

场景	描述		创建物化视图 SQL 样例	用户查询 SQL 样例	查询 SQL 是否能被改写	备注
						做物化视图不会改写
			select length(col13) from tb_a;	select length(col13) from tb_a;	是	-
聚合函数列查询	count	物化视图和用户查询一样使用 count	select count(col1) from tb_a;	select count(col1) from tb_a;	是	-
		物化视图使用源数据，用户查询使用 count	select col1 from tb_a;	select count(col1) from tb_a;	是	-
	sum	物化视图和用户查询一样使用 sum	select sum(col1) from tb_a;	select sum(col1) from tb_a;	是	-
		物化视图使用源数据，用户查询使用 sum	select col1 from tb_a;	select sum(col1) from tb_a;	是	-
过滤查询（核心在于物化视图的数据逻辑上要比查询 SQL 相	where 过滤	物化视图最大范围(<)	select col1 from tb_a;	select col1 from tb_a where col1<11;	是	-
		物化视图范围大于用户查询范围(<)	select col1 from tb_a where col1<50;	select col1 from tb_a where col1<45;	是	-
			select col1 from tb_a	select col1 from tb_a where	是	-

场景	描述		创建物化视图 SQL 样例	用户查询 SQL 样例	查询 SQL 是否能被改写	备注
同或者更多）			where col1<50;	col1<=45;		
			select col1 from tb_a where col1<50;	select col1 from tb_a where col1 between 21 and 29;	是	-
		物化视图范围等于用户查询范围(>)	select col1 from tb_a where col1<50;	select col1 from tb_a where col1<50;	是	-
		物化视图范围大于用户查询范围(and)	select col1 from tb_a where col1<60 and col1>30;	select col1 from tb_a where col1<55 and col1>30;	是	-
			select col1 from tb_a where col1<60 and col1>30;	select col1 from tb_a where col1 between 35 and 55;	是	-
			select col1 from tb_a where col1<60 and col1>30;	select col1 from tb_a where (col1<55 and col1>30) and col1 = 56;	是	-
	where 嵌套子查询	子查询源表做物化视图	select col1 from tb_a;	select count(col1) from tb_a where col1=(select min(col1) from tb_a);	是	-
		子查询做物化视图	select min(col1) from tb_a;	select count(col1) from tb_a where col1=(select min(col1) from tb_a);	是	-
		父查询源表做物化视图	select col1 from tb_a where col1=(select min(col1) from tb_a);	select count(col1) from tb_a where col1=(select min(col1) from tb_a);	是	-

场景	描述		创建物化视图 SQL 样例	用户查询 SQL 样例	查询 SQL 是否能被改写	备注
		父查询做物化视图	select count(col1) from tb_a where col1=(select min(col1) from tb_a);	select count(col1) from tb_a where col1=(select min(col1) from tb_a);	是	-
	limit	limit 在查询里	select col1 from tb_a;	select col1 from tb_a limit 5;	是	-
			select col1 from tb_a limit 5;	select col1 from tb_a limit 5;	是	-
			select col1 from tb_a limit 5;	select col1 from tb_a;	否	-
		limit 结合 order by	select col1 from tb_a;	select col1 from tb_a order by col1 limit 5;	是	创建物化视图时建议不要使用 order by，如果查询 SQL 中有 order by 和 limit，建议物化视图 SQL 去掉 limit 和 order by
			select col1 from tb_a order by col1;	select col1 from tb_a order by col1 limit 5;	是	
			select col1 from tb_a order by col1 limit 5;	select col1 from tb_a order by col1 limit 5;	否	
	having 过滤	物化视图最大范围(<)	select col1 from tb_a;	select col1 from tb_a group by col1 having col1 <11;	是	group by + having：having 的场景和 where 不一样，having 的条件无法做到补偿，要求物化视图 SQL 的没有 having 条件或者
		物化视图范围大于用户查询范围(<)	select col1 from tb_a group by col1 having col1<50;	select col1 from tb_a group by col1 having col1<45;	否	
			select col1 from tb_a group by col1 having	select col1 from tb_a group by col1 having col1<=45;	否	

场景	描述		创建物化视图 SQL 样例	用户查询 SQL 样例	查询 SQL 是否能被改写	备注
			col1<50;			与用户查询 SQL 的 having 条件一致
			select col1 from tb_a group by col1 having col1<50;	select col1 from tb_a group by col1 having col1=45;	否	
			select col1 from tb_a group by col1 having col1<50;	select col1 from tb_a group by col1 having col1 between 21 and 29;	否	
		物化视图范围等于用户查询范围(<)	select col1 from tb_a group by col1 having col1<50;	select col1 from tb_a group by col1 having col1<50;	是	
JOIN 关联查询	两个子查询做物化视图		select col1,col3 from tb_a where col1<11;	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select col1,col2 from t1 join t2 on t1.col3=t2.col3;	是	-
			select cast(col2 as varchar) col2,col3 from tb_b;	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select col1,col2 from t1 join t2 on t1.col3=t2.col3;	是	-
	父查询做物化视图		with t1 as (select col1,col3 from tb_a),t2 as (select col2,col3 from	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar)	是	-

场景	描述	创建物化视图 SQL 样例	用户查询 SQL 样例	查询 SQL 是否能被改写	备注
		tb_b) select col1,col2 from t1 join t2 on t1.col3=t2.col3 ;	col2,col3 from tb_b) select col1,col2 from t1 join t2 on t1.col3=t2.col3;		
聚合+JOIN查询	源表数据做物化视图	select col1,col3 from tb_a;	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select count(col1) from t1 join t2 on t1.col3=t2.col3;	是	-
		select col2,col3 from tb_b;	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select count(col1) from t1 join t2 on t1.col3=t2.col3;	是	-
	子查询做物化视图	select col1,col3 from tb_a where col1<11;	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select count(col1) from t1 join t2 on t1.col3=t2.col3;	是	-
		select cast(col2 as varchar) col2,col3 from tb_b;	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select	是	-

场景	描述	创建物化视图 SQL 样例	用户查询 SQL 样例	查询 SQL 是否能被改写	备注
			count(col1) from t1 join t2 on t1.col3=t2.col3;		
	子查询使用源表的父查询(非聚合查询)做物化视图	with t1 as (select col1,col3 from tb_a),t2 as (select col2,col3 from tb_b) select col1,col2 from t1 join t2 on t1.col3=t2.col3 ;	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select count(col1) from t1 join t2 on t1.col3=t2.col3;	是	-
	父查询(非聚合查询)做物化视图	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select col1,col2 from t1 join t2 on t1.col3=t2.col3 ;	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select count(col1) from t1 join t2 on t1.col3=t2.col3;	是	-
	父查询做物化视图	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select count(col1) from t1 join t2 on t1.col3=t2.col3 ;	with t1 as (select col1,col3 from tb_a where col1<11),t2 as (select cast(col2 as varchar) col2,col3 from tb_b) select count(col1) from t1 join t2 on t1.col3=t2.col3;	是	-

10.10.4 配置物化视图推荐能力

操作场景

HetuEngine QAS 实例可对用户的 SQL 执行历史记录提供自动感知、自动学习、自动诊断服务，开启物化视图推荐能力后，系统能自动学习并推荐对业务最有价值的物化视图 SQL，使 HetuEngine 具备自动预计算加速能力，在相关场景下在线查询效率获得倍数提升，同时有效降低系统负载压力。

前提条件

- 集群运行正常并至少安装一个 QAS 实例。
- 已创建用于访问 HetuEngine WebUI 界面的用户，如 **Hetu_user**，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。

开启物化视图推荐功能

以 **Hetu_user** 用户登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > 服务 > HetuEngine > 配置 > 全部配置 > QAS（角色） > 物化视图推荐“，参考表 10-55 配置物化视图推荐参数，其他参数保持默认即可。

表10-55 物化视图推荐参数

参数名称	值	描述
qas.enable.auto.recommendation	true	开启物化视图推荐，默认值为“false”
qas.sql.submitter	如：default,zuhu1	启用物化视图推荐功能的租户名称，多租户用英文逗号隔开
qas.schedule.fixed.delay	1d	推荐物化视图的周期，建议一天一次
qas.threshold.for.mv.recommend	0.05	物化视图推荐筛选阈值，取值范围为“0.001-1”，建议根据实际业务情况调整

步骤 2 单击“保存”，保存配置。

步骤 3 单击“实例”，勾选所有 QAS 实例，选择“更多 > 重启实例”，输入密码重启 QAS 所有实例使参数生效。

----结束

查看物化视图推荐结果

以 **Hetu_user** 用户登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 2 在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入HSConsole 界面。

步骤 3 选择“SQL 运维 > 物化视图推荐”，可根据“租户”、“状态”、“推荐周期”、“物化视图名称”进行搜索，支持模糊搜索，支持导出指定物化视图推荐结果信息。

物化视图任务的“状态”包括如下：

表10-56 物化视图任务的“状态”

状态名称	描述	状态名称	描述
To Be Created	待创建	Deleting	删除中
Creating	创建中	Deleted	已删除
Created	创建完成	Planning	计划中
Failed	创建失败	Aborted	已终止
Updating	更新中	Duplicated	重复推荐

----结束

10.10.5 配置物化视图缓存能力

对于一条 SQL，创建了对应的物化视图后，执行这条 SQL 时，将被改写为通过物化视图查询。如果开启了物化视图的“重写缓存”功能，那么多次执行这条 SQL 后，改写后的 SQL 将会保存到缓存中（默认最多保存 10000 条），在缓存有效时间（默认 24 小时）内，执行这条 SQL 时会直接从缓存中获取改写后的 SQL，而不是重新对 SQL 进行改写。

可在计算实例中添加自定义参数“rewrite.cache.timeout”和“rewrite.cache.limit”分别设置缓存有效时间和最多能保存的改写 SQL 的条数。

- 创建一个新的物化视图，或者删除一个已有的物化视图时，缓存将失效。
- 如果缓存中被改写的 SQL 查询所关联的物化视图失效，或者处于 REFRESHING 状态，该条被改写的 SQL 查询将不会被使用。
- 当使用缓存时，被执行的 SQL 不能有任何改变，否则它将被当做一条新的 SQL 查询。
- 创建的物化视图中最多有 500 个可以用于 SQL 查询的改写，也就是 SQL 改写时使用的物化视图如果被包含在这 500 个中，那么就会进行改写，否则就当做普通 SQL 执行。可参考•System 级别：在计算实例中添加自定义参数“hetu.select.top.materialized.view”来改变允许使用的物化视图个数。

开启物化视图“重写缓存”

- Session 级别：

  参考 10.6 使用 HetuEngine 客户端在 HetuEngine 客户端执行 **set session rewrite_cache_enabled=true**

- System 级别：
  a. 使用用于访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager。
  b. 选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。
  c. 在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。
  d. 查看待操作的实例的状态是否为“停止”，否则修改为“停止”。
  e. 在待操作的实例所在行“操作”列单击“配置”，添加如下自定义参数。

名称	值	参数文件	描述
rewrite.cache.enabled	true	coordinator.config.properties	启用物化视图“重写缓存”
rewrite.cache.timeout	86400000	coordinator.config.properties	• 修改“重写缓存”的有效期 • 不填则使用默认值：86400000，单位：ms
rewrite.cache.limit	10000	coordinator.config.properties	• 修改“重写缓存”的缓存上限 • 不填则使用默认值：10000，单位：条

  f. 参数添加完成后，勾选“立即启动”，单击“确定”。

10.10.6 配置物化视图的有效期与数据刷新能力

物化视图的有效期

创建物化视图的“mv_validity”字段为物化视图的有效期，HetuEngine 只会使用有效期内的物化视图进行自动改写。

物化视图的数据刷新

如果需要数据定期更新，需要定时刷新物化视图，可以使用如下两种方式实现：

- 手动刷新物化视图

  参考 10.6 使用 HetuEngine 客户端在 HetuEngine 客户端执行 **refresh materialized view** <*mv name*>，或者在用户的业务程序通过 JDBC 驱动执行 **refresh materialized view** <*mv name*>进行手动更新。
- 自动刷新物化视图

  使用“create materialized view”创建具备自动刷新的物化视图。

说明

- 如果要启动物化视图的自动刷新能力，必须存在一个被设置为维护实例的计算实例，设置维护实例可参考 10.5.3 配置 HetuEngine 维护实例。
- 如果物化视图过多，可能会导致物化视图在刷新的等待队列中等待时间过长而过期。
- 自动刷新功能不会自动刷新状态为 disable 的物化视图。

10.10.7 配置智能物化视图能力

概述

基于智能物化视图，HetuEngine 可以提供智能预计算与缓存加速能力。HetuEngine QAS 角色能够自动提取历史 SQL 语句进行分析学习，基于收益最大化原则自动生成高价值物化视图的候选 SQL。在实际运用中，HetuEngine 管理员可选择通过配置“维护实例”等，开启物化视图的自动创建与自动刷新功能。业务用户可以通过配置客户端 Session 来获得基于自动创建的物化视图的自动改写与提速。

该能力可以极大降低用户使用物化视图功能的使用难度，带来业务无感知的分析加速效果。HetuEngine 管理员通过付出少量的计算资源和存储空间，可实现对高频 SQL 业务的智能加速。同时，该能力可以降低数据平台的整体负载（CPU、内存、IO 等），有助于提升系统稳定性。

智能物化视图包括以下几个功能：

- 自动推荐物化视图
- 自动创建物化视图
- 自动刷新物化视图
- 自动删除物化视图

前提条件

集群运行正常并至少安装一个 QAS 实例。

应用流程

图10-10 HetuEngine 智能物化视图应用流程

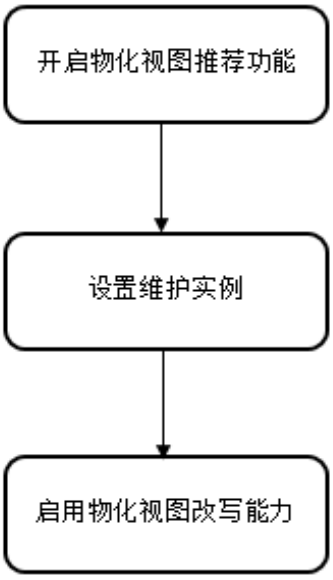

表10-57 HetuEngine 智能物化视图应用流程说明

阶段	说明	参考章节
开启物化视图推荐功能	开启物化视图推荐功能之后，QAS 实例会根据用户的 SQL 执行记录自动推荐高价值的物化视图 SQL，推荐的物化视图语句可在 HSConsole 界面的物化视图推荐页面查看，可参考查看物化视图推荐结果。	开启物化视图推荐功能
设置维护实例	设置计算实例为维护实例之后，维护实例会对物化视图推荐功能所推荐的物化视图 SQL 进行自动创建、刷新、删除等操作，所产生的自动化任务记录可在 HetuEngine 自动化任务页面查看，可参考 10.10.8 查看物化视图自动化任务。	10.5.3 配置 HetuEngine 维护实例
启用物化视图改写能力	开启物化视图改写能力之后，HetuEngine 会根据用户输入的 SQL 语句判断是否满足物化视图改写，将能匹配到物化视图的查询或者子查询转换为物化视图，避免了数据的重复计算。	10.10.3 配置物化视图改写能力

10.10.8 查看物化视图自动化任务

操作场景

本章节指导用户在 HSConsole 页面查看 HetuEngine 自动化任务的任务状态和任务执行结果等信息。用户可定期查看任务执行情况，帮助评估集群运行健康状况。

前提条件

已创建用于访问 HetuEngine WebUI 界面的用户，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。

操作步骤

使用用于访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 单击“自动化任务”进入任务查询页面，用户可根据任务的“任务类型”、“状态”、“附加信息”、“开始时间”或“结束时间”进行搜索，支持模糊搜索。

搜索条件	描述
任务类型	Refresh of materialized view：刷新物化视图

搜索条件	描述
	Recommendation of materialized view：推荐物化视图
	Auto create materialized view：自动创建物化视图
	Drop auto created and stale materialized view：自动删除物化视图
状态	success：任务运行成功
	failed：任务运行失败
	waiting：任务等待
	running：任务正常运行
	skip_execute：此任务跳过
	timeout：任务执行超时
	unknown：任务状态未知

步骤 3 单击“搜索”，页面即展示匹配的任务信息，可单击“任务详情”列的“LINK”展开指定任务信息。

----结束

10.11 使用 HetuEngine SQL 诊断功能

本章节适用于 MRS 3.2.0 及以后版本。

操作场景

HetuEngine QAS 实例可对用户的 SQL 执行历史记录提供自动感知、自动学习、自动诊断服务，提升在线 SQL 运维能力，自动加速在线 SQL 分析任务，开启 SQL 诊断能力后，系统可实现如下能力：

- 自动感知并向集群管理员展现不同时间周期范围内的租户级、用户级的 SQL 任务统计，帮助集群管理员快速预判业务运行状态和潜在风险。
- 自动诊断出大 SQL、慢 SQL 及相关提交信息，面向集群管理员多维度可视化呈现，同时提供大 SQL、慢 SQL 的诊断与优化建议。

前提条件

- 集群运行正常并至少安装一个 QAS 实例。
- 已创建用于访问 HetuEngine WebUI 界面的用户，如 **Hetu_user**，用户创建具体操作请参见 10.3 创建 HetuEngine 用户。

开启 SQL 诊断功能

HetuEngine 的 SQL 诊断功能默认开启，可参考如下步骤配置其他常见参数或保持默认：

以 **Hetu_user** 用户登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > 服务 > HetuEngine > 配置 > 全部配置 > QAS（角色） > SQL 诊断“，参数“qas.sql.auto.diagnosis.enabled”为“true”表示开启 SQL 诊断功能，可根据业务需求配置 SQL 诊断推荐参数。

步骤 2 单击“保存”，保存配置。

步骤 3 单击“实例”，勾选所有 QAS 实例，选择“更多 > 重启实例”，输入密码重启 QAS 所有实例使参数生效。

----结束

查看 SQL 诊断结果

以 **Hetu_user** 用户登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 2 在概览页签下的“基本信息”区域单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 3 单击“SQL 运维”，可查看如下 SQL 诊断结果：

- 在“概览”页面，可查看历史任务的整体运行状况，包括：查询分段耗时分布图、查询用户分布图、SQL 提交总数、SQL 执行成功率、SQL 平均响应时间、查询个数、平均执行耗时、平均等待耗时。
- 选择“SQL 诊断 > 慢查询分布”，用户可查看历史任务的慢查询分布情况，包括：
  - 慢 SQL 统计：统计各个租户的慢查询（查询时间大于慢查询阈值）提交个数。
  - 慢查询 TOP 用户请求统计列表：统计各个用户的慢查询统计明细，支持列表排序和全部导出功能。
- 选择“SQL 诊断 > 慢查询列表”，用户可查看历史任务的慢查询列表、诊断结果和优化建议，支持导出查询结果。

说明

历史统计信息的有效期取决于 HSConsole 实例的 JVM 内存大小，最多不超过 60 天。

----结束

10.12 开发和应用 Function 及 UDF 功能

10.12.1 开发和应用 HetuEngine Function Plugin

用户可以自定义一些函数，用于扩展 SQL 以满足个性化的需求，这类函数称为 UDF。

本章节主要介绍开发和应用 HetuEngine Function Plugin 的具体步骤。

说明

MRS 3.3.0 及以后版本，需要基于 JDK17.0.4 及以上版本开发。本章节以 MRS 3.3.0 版本为例。

开发 Function Plugin 项目

本样例实现两个 Function Plugin，说明见下表。

表10-58 HetuEngine Function Plugin 说明

名称	说明	类型
add_two	输入一个整数，返回其加 2 后的结果	ScalarFunction
avg_double	聚合计算指定列的平均值，且该列的字段类型为 double	AggregationFunction

创建 Maven 项目，“groupId”配置“**com.test.functions**”，“artifactId”配置“**myfunctions**”。这个两个值可根据实际情况自定义。

步骤 2 修改“pom.xml”文件如下：

```
<project xmlns="http://maven.apache.org/POM/4.0.0"
xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
xsi:schemaLocation="http://maven.apache.org/POM/4.0.0
http://maven.apache.org/xsd/maven-4.0.0.xsd">
      <modelVersion>4.0.0</modelVersion>
      <groupId>com.test.functions</groupId>
      <artifactId>myfunctions</artifactId>
      <version>0.0.1-SNAPSHOT</version>
      <packaging>trino-plugin</packaging>
     <properties>
        <project.build.targetJdk>17</project.build.targetJdk>
        <dep.guava.version>31.1-jre</dep.guava.version>
         <dep.hetu.version>399-h0.cbu.mrs.321.r13</dep.hetu.version>
     </properties>

      <dependencies>
         <dependency>
            <groupId>com.google.guava</groupId>
            <artifactId>guava</artifactId>
            <version>${dep.guava.version}</version>
         </dependency>
```

```
        <dependency>
            <groupId>io.trino</groupId>
            <artifactId>trino-spi</artifactId>
            <version>${dep.hetu.version}</version>
            <scope>provided</scope>
        </dependency>

    </dependencies>

    <build>
        <plugins>
            <plugin>
                <groupId>org.apache.maven.plugins</groupId>
                <artifactId>maven-assembly-plugin</artifactId>
                <version>3.3.0</version>
                <configuration>
                    <encoding>UTF-8</encoding>
                </configuration>
            </plugin>
            <plugin>
                <groupId>io.trino</groupId>
                <artifactId>trino-maven-plugin</artifactId>
                <version>11</version>
                <extensions>true</extensions>
            </plugin>
        </plugins>
    </build>
</project>
```

步骤 3 创建 Function Plugin 实现类。

1. 创建 Function Plugin 实现类 **com.test.functions.scalar.MyFunction**，其内容如下：

```
package com.test.functions.scalar;
import io.trino.spi.function.ScalarFunction;
import io.trino.spi.function.SqlNullable;
import io.trino.spi.function.SqlType;
import io.trino.spi.type.StandardTypes;
import jdk.jfr.Description;
public class MyFunction {
    private MyFunction() {
    }
    @Description("Add two")
    @ScalarFunction("add_two")
    @SqlType(StandardTypes.INTEGER)
    public static long add2(@SqlNullable @SqlType(StandardTypes.INTEGER) Long i)
{
        return i + 2;
    }
}
```

2. 创建 Function Plugin 实现类 **com.test.function.aggregation.MyAverageAggregationFunction**，其内容如下：

```
package com.test.functions.aggregation;

import static io.trino.spi.type.DoubleType.DOUBLE;
```

```
import io.trino.spi.block.BlockBuilder;
import io.trino.spi.function.AggregationFunction;
import io.trino.spi.function.AggregationState;
import io.trino.spi.function.CombineFunction;
import io.trino.spi.function.InputFunction;
import io.trino.spi.function.OutputFunction;
import io.trino.spi.function.SqlType;
import io.trino.spi.type.StandardTypes;

@AggregationFunction("avg_double")
public class MyAverageAggregationFunction
{
    private MyAverageAggregationFunction() {}

    @InputFunction
    public static void input(
        @AggregationState LongAndDoubleState state,
        @SqlType(StandardTypes.DOUBLE) double value)
    {
        state.setLong(state.getLong() + 1);
        state.setDouble(state.getDouble() + value);
    }

    @CombineFunction
    public static void combine(
        @AggregationState LongAndDoubleState state,
        @AggregationState LongAndDoubleState otherState)
    {
        state.setLong(state.getLong() + otherState.getLong());
        state.setDouble(state.getDouble() + otherState.getDouble());
    }

    @OutputFunction(StandardTypes.DOUBLE)
    public static void output(@AggregationState LongAndDoubleState state,
BlockBuilder out)
    {
        long count = state.getLong();
        if (count == 0) {
            out.appendNull();
        }
        else {
            double value = state.getDouble();
            DOUBLE.writeDouble(out, value / count);
        }
    }
}
```

步骤 4 创建 AverageAggregation 的依赖接口 **com.test.functions.aggregation.LongAndDoubleState**。

```
package com.test.functions.aggregation;

import io.trino.spi.function.AccumulatorState;

public interface LongAndDoubleState
    extends AccumulatorState
```

```
{
    long getLong();

    void setLong(long value);

    double getDouble();

    void setDouble(double value);
}
```

步骤 5 创建 Function Plugin 注册类 **com.test.functions.MyFunctionsPlugin**，其内容如下：

```
package com.test.functions;

import com.google.common.collect.ImmutableSet;
import com.test.functions.aggregation.MyAverageAggregationFunction;
import com.test.functions.scalar.MyFunction;

import io.trino.spi.Plugin;

import java.util.Set;

public class MyFunctionsPlugin
    implements Plugin
{
    @Override
    public Set<Class<?>> getFunctions() {
        return ImmutableSet.<Class<?>>builder()
            .add(MyFunction.class)
            .add(MyAverageAggregationFunction.class)
            .build();
    }
}
```

步骤 6 打包 Maven 项目，获取 target 目录下的 udf-test-0.0.1-SNAPSHOT 目录，最终项目整体结构如下图所示。

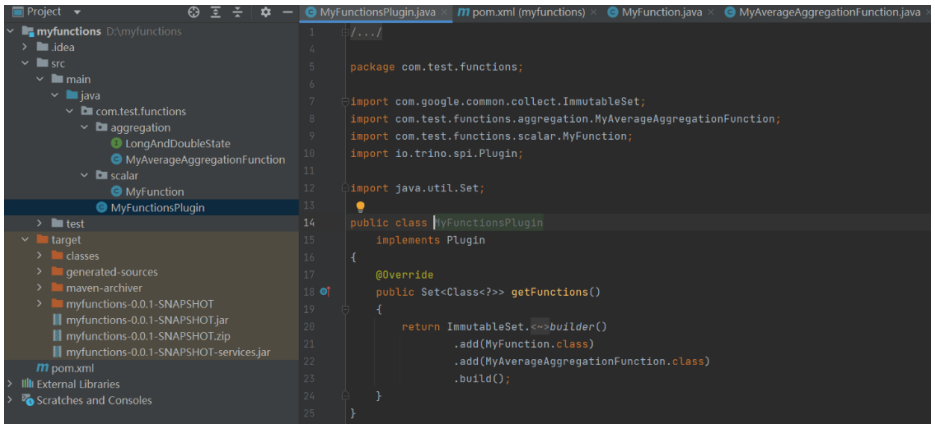

----结束

部署 Function Plugin

部署前需要确认：

- HetuEngine 服务处于正常状态。
- HDFS 和 HetuEngine 客户端已经安装到集群节点，例如“/opt/client”目录下。
- 已创建 HetuEngine 用户，用户创建请参考 10.3 创建 HetuEngine 用户。

将打包 Maven 项目得到的 **myfunctions-0.0.1-SNAPSHOT** 目录上传到安装客户端节点的任意目录。

步骤 1 将 **myfunctions-0.0.1-SNAPSHOT** 目录上传到 HDFS 中。

1. 登录客户端安装节点，执行安全认证。

   cd /opt/client

   source bigdata_env

   kinit *HetuEngine 的用户*

   根据回显提示输入密码，首次认证需要修改密码。
2. HDFS 中创建如下路径，如已存在则不需创建。

   hdfs dfs -mkdir -p /user/hetuserver/udf/data/externalFunctionsPlugin
3. 上传 **myfunctions-0.0.1-SNAPSHOT** 目录到 HDFS。

   hdfs dfs -put myfunctions-0.0.1-SNAPSHOT /user/hetuserver/udf/data/externalFunctionsPlugin
4. 修改目录属主。

   hdfs dfs -chown -R hetuserver:hadoop /user/hetuserver/udf/data

步骤 2 重启 HetuEngine 计算实例。

----结束

使用验证 Function Plugin

登录客户端安装节点，执行安全认证。

cd /opt/client

source bigdata_env

kinit *HetuEngine 用户*

hetu-cli

步骤 1 执行如下命令验证 Function Plugin。

1. 查询表。

   select * from hive.default.test1;

   ```
   select * from hive.default.test1;
   name  |  price
   --------|-------
   apple   |  17.8
   orange |  25.0
   (2 rows)
   ```
2. 返回平均值。

   select avg_double(price) from hive.default.test1;

```
select avg_double(price) from hive.default.test1;
_col0
-------
  21.4
(1 row)
```

3. 返回输入整数加 2 的值。

   select add_two(4);

```
select add_two(4);
_col0
-------
   6
(1 row)
```

----结束

10.12.2 开发和应用 Hive UDF

用户可以自定义一些函数，用于扩展 SQL 以满足个性化的需求，这类函数称为 UDF。

本章节主要介绍开发和应用 Hive UDF 的具体步骤。

说明

MRS 3.3.0 及以后版本，需要基于 JDK17.0.4 及以上版本开发。本章节以 MRS 3.3.0 版本为例。

开发 Hive UDF 项目

本样例实现一个 Hive UDF，说明见下表。

表10-59 Hive UDF 说明

名称	说明
AutoAddOne	对输入的数字加 1 后返回

说明

- 一个普通 Hive UDF 必须继承自“org.apache.hadoop.hive.ql.exec.UDF”。
- 一个普通 Hive UDF 必须至少实现一个 evaluate()方法，evaluate 方法支持重载。
- 当前只支持以下数据类型：
- boolean、byte、short、int、long、float、double
- Boolean、Byte、Short、Int、Long、Float、Double
- List、Map

  目前暂不支持除以上类型外的更复杂数据类型的 UDF、UDAF 和 UDTF。
- 当前只支持入参数量小于或等于 5 个的 Hive UDF，大于 5 个入参的 Hive UDF 将无法被注册。
- 如果 Hive UDF 入参为 null，系统调用 Hive UDF 将直接返回 null，不会解析 null 作为入参的 Hive UDF 逻辑，这可能导致处理 null 值的 Hive UDF 执行结果与 Hive 执行结果不一致。
- 需要在 maven 工程中添加 hive-exec-3.1.1 的依赖，可从 Hive 服务安装目录下获取。

- （可选）若用户存在 Hive UDF 依赖的配置文件，建议将其作为资源文件放在 resources 目录下，即可打包到 Hive UDF 函数包中。

创建 Maven 项目，“groupId”配置“com.test.udf”，“artifactId”配置“udf-test”。这个两个值可根据实际情况自定义。

步骤 2 修改“pom.xml”文件如下：

```
<project xmlns="http://maven.apache.org/POM/4.0.0"
xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
xsi:schemaLocation="http://maven.apache.org/POM/4.0.0
http://maven.apache.org/xsd/maven-4.0.0.xsd">
      <modelVersion>4.0.0</modelVersion>
      <groupId>com.test.udf</groupId>
      <artifactId>udf-test</artifactId>
      <version>0.0.1-SNAPSHOT</version>

      <dependencies>
        <dependency>
          <groupId>org.apache.hive</groupId>
          <artifactId>hive-exec</artifactId>
          <version>3.1.1</version>
        </dependency>
      </dependencies>

      <build>
        <plugins>
          <plugin>
             <artifactId>maven-shade-plugin</artifactId>
             <executions>
                <execution>
                   <phase>package</phase>
                   <goals>
                      <goal>shade</goal>
                   </goals>
                </execution>
             </executions>
          </plugin>
          <plugin>
             <artifactId>maven-resources-plugin</artifactId>
             <executions>
                <execution>
                   <id>copy-resources</id>
                   <phase>package</phase>
                   <goals>
                      <goal>copy-resources</goal>
                   </goals>
                   <configuration>

<outputDirectory>${project.build.directory}/</outputDirectory>
                      <resources>
                         <resource>
                            <directory>src/main/resources/</directory>
                            <filtering>false</filtering>
                         </resource>
                      </resources>
```

```
                    </configuration>
                </execution>
            </executions>
        </plugin>
    </plugins>
</build>
</project>
```

步骤 3 创建 Hive UDF 实现类。

```
import org.apache.hadoop.hive.ql.exec.UDF;

/**
 * AutoAddOne
 *
 * @since 2020-08-24
 */
public class AutoAddOne extends UDF {
   public int evaluate(int data) {
       return data + 1;
   }
}
```

步骤 4 打包 Maven 项目，target 目录下的 udf-test-0.0.1-SNAPSHOT.jar 文件即为 Hive UDF 函数包。

----结束

配置 Hive UDF

用户通过在配置文件“udf.properties”中添加注册信息来注册 Hive UDF，需按“函数名称 类路径”格式添加每一行内容：

以“udf.properties” 为例，已明确要注册的四个 Hive UDF：

```
booleanudf io.hetu.core.hive.dynamicfunctions.examples.udf.BooleanUDF
shortudf io.hetu.core.hive.dynamicfunctions.examples.udf.ShortUDF
byteudf io.hetu.core.hive.dynamicfunctions.examples.udf.ByteUDF
intudf io.hetu.core.hive.dynamicfunctions.examples.udf.IntUDF
```

说明

- 如果用户添加的 Hive UDF 注册信息有误，比如错误的格式或者不存在的类路径，系统将忽略这些错误的注册信息，并打印相应日志。
- 如果用户注册重复的 Hive UDF，系统将只注册一次，并忽略重复的注册。
- 如果用户注册的 Hive UDF 与系统内部注册的相同，系统将会抛出异常并无法正常启动。解决该异常需要用户删除对应的 Hive UDF 注册信息。

部署 Hive UDF

要在 HetuEngine 中使用 Hive UDF，需要用户将相应的 UDF 函数包、“udf.properties”、UDF 依赖的配置文件上传到指定 HDFS 路径，例如“/user/hetuserver/udf/”，并重启 HetuEngine 计算实例。

创建“/user/hetuserver/udf/data/externalFunctions”文件夹，将“udf.properties”放在“/user/hetuserver/udf”，将 UDF 函数包放在“/user/hetuserver/udf/data/externalFunctions”，将 UDF 依赖的配置文件放在“/user/hetuserver/udf/data”。

- 使用 HDFS 的页面上传。
  a. 使用 *HetuEngine 用户*登录 FusionInsight Manager，选择“集群 > 服务 > HDFS”，进入 HDFS 服务页面。
  b. 在概览页签下的“基本信息”区域，单击“NameNode WebUI”后的链接，进入 NameNode WebUI 界面。
  c. 选择“Utilities > Browse the file system”，单击  创建“/user/hetuserver/udf/data/externalFunctions”。
  d. 进入“/user/hetuserver/udf”，单击  上传“udf.properties”。
  e. 进入“/user/hetuserver/udf/data/”，单击  上传 UDF 依赖的配置文件。
  f. 进入“/user/hetuserver/udf/data/externalFunctions”，单击  上传 UDF 函数包。
- 使用 HDFS 命令行上传。
  a. 登录 HDFS 服务客户端所在节点，切换到客户端安装目录，例如“/opt/client”。
     cd /opt/client
  b. 执行以下命令配置环境变量。
     source bigdata_env
  c. 如果集群为安全模式，执行以下命令进行用户认证。普通模式集群无需执行用户认证。
     kinit *HetuEngine 用户*
     根据回显提示输入密码。
  d. 执行如下命令创建目录，并将已准备好相应的 UDF 函数包、“udf.properties”、UDF 依赖的配置文件上传到目录路径。
     hdfs dfs -mkdir /user/hetuserver/udf/data/externalFunctions
     hdfs dfs -put ./*UDF 依赖的配置文件* **/user/hetuserver/udf/data**
     hdfs dfs -put ./udf.properties /user/hetuserver/udf
     hdfs dfs -put ./*UDF 函数包* **/user/hetuserver/udf/data/externalFunctions**

步骤 1 重启 HetuEngine 计算实例。

----结束

使用 Hive UDF

使用客户端访问：

1. 进入 HetuEngine 客户端，请参考 10.6 使用 HetuEngine 客户端。
2. 执行如下命令应用 Hive UDF：

   select AutoAddOne(1);

```
select AutoAddOne(1);
_col0
-------
    2
(1 row)
```

10.12.3 开发和应用 HetuEngine UDF

用户可以自定义一些函数，用于扩展 SQL 以满足个性化的需求，这类函数称为 UDF。

本章节主要介绍开发和应用 HetuEngine UDF。

说明

MRS 3.3.0 及以后版本，需要基于 JDK17.0.4 及以上版本开发。本章节以 MRS 3.3.0 版本为例。

开发 HetuEngine UDF 项目

本样例实现一个 HetuEngine UDF，说明见下表。

表10-60 HetuEngine UDF 说明

名称	说明
AddTwo	对输入的数字加 2 后返回

创建 Maven 项目，“groupId”配置“com.test.udf”，“artifactId”配置“udf-test”。这个两个值可根据实际情况自定义。

步骤 2 修改“pom.xml”文件如下：

```
<project xmlns="http://maven.apache.org/POM/4.0.0"
xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
xsi:schemaLocation="http://maven.apache.org/POM/4.0.0
http://maven.apache.org/xsd/maven-4.0.0.xsd">
      <modelVersion>4.0.0</modelVersion>
      <groupId>com.test.udf</groupId>
      <artifactId>udf-test</artifactId>
      <version>0.0.1-SNAPSHOT</version>

      <build>
        <plugins>
          <plugin>
             <artifactId>maven-shade-plugin</artifactId>
             <executions>
                <execution>
                   <phase>package</phase>
                   <goals>
                      <goal>shade</goal>
```

```
                    </goals>
                </execution>
            </executions>
        </plugin>
        <plugin>
            <artifactId>maven-resources-plugin</artifactId>
            <executions>
                <execution>
                    <id>copy-resources</id>
                    <phase>package</phase>
                    <goals>
                        <goal>copy-resources</goal>
                    </goals>
                    <configuration>

<outputDirectory>${project.build.directory}/</outputDirectory>
                        <resources>
                            <resource>
                                <directory>src/main/resources/</directory>
                                <filtering>false</filtering>
                            </resource>
                        </resources>
                    </configuration>
                </execution>
            </executions>
        </plugin>
    </plugins>
</build>
</project>
```

步骤 3 创建 HetuEngine UDF 实现类。

```
package com.xxx.bigdata.hetuengine.functions;

public class AddTwo {
    public Integer evaluate(Integer num) {
        return num + 2;
    }
}
```

步骤 4 打包 Maven 项目，target 目录下的“udf-test-0.0.1-SNAPSHOT.jar”文件即为 HetuEngine UDF 函数包。

----结束

说明

- 一个普通 HetuEngine UDF 必须至少实现一个 evaluate()方法，evaluate 方法支持重载。
- 当前只支持入参数量小于或等于 5 个的 HetuEngine UDF，大于 5 个入参的 HetuEngine UDF 将无法被注册。
- 需要将所有依赖文件都打包到 jar 包里。
- （可选）若用户存在 HetuEngine UDF 依赖的配置文件，建议将其作为资源文件放在 resources 目录下，即可打包到 HetuEngine UDF 函数包中。

部署 HetuEngine UDF

要在 HetuEngine 中使用 HetuEngine UDF，需要用户将相应的 UDF 函数包上传到指定 HDFS 路径，例如“/udf/hetuserver”。这个路径可根据实际情况自定义。

创建“/udf/hetuserver”文件夹，将 UDF 函数包放在“/udf /hetuserver”。

- 使用 HDFS 的页面上传。
  a. 使用 *HetuEngine 用户*登录 FusionInsight Manager，选择“集群 > 服务 > HDFS”，进入 HDFS 服务页面。
  b. 在概览页签下的“基本信息”区域，单击“NameNode WebUI”后的链接，进入 NameNode WebUI 界面。
  c. 选择“Utilities > Browse the file system”，单击  创建“/udf/hetuserver”。
  d. 进入“/udf/hetuserver”，单击  上传 UDF 函数包。
- 使用 HDFS 命令行上传。
  a. 登录 HDFS 服务客户端所在节点，切换到客户端安装目录，例如“/opt/client”。
  cd /opt/client
  b. 执行以下命令配置环境变量。
  source bigdata_env
  c. 如果集群为安全模式，执行以下命令进行用户认证。普通模式集群无需执行用户认证。
  kinit*HetuEngine 用户*
  根据回显提示输入密码。
  d. 执行如下命令创建目录，并将已准备好相应的 UDF 函数包上传到目录路径。
  hdfs dfs -mkdir -p /udf/hetuserver
  hdfs dfs -put ./*UDF 函数包* **/udf/hetuserver**
  e. 修改 UDF 函数包权限。
  hdfs dfs -chmod 644 /udf/hetuserver/*UDF 函数包*

须知

- 将 UDF JAR 文件上传到 HDFS 上自定义的目录存放，要确保用户对 JAR 文件具有读权限，建议权限设置“chmod 644”。若希望 HetuEngine 服务在卸载时一并删除 UDF JAR 文件，那么可以将自定义的目录创建在“/user/hetuserver/”路径中。
- 当前 HetuEngine 仅支持 UDF JAR 文件存放在“hdfs://*资源 URI*”的 HDFS 中。
- 因修改函数或增加函数而导致的重新上传 JAR 文件，HetuEngine 会默认缓存 5 分钟，不会即时生效，5 分钟后才会进行 JAR 文件的更新和重新加载。

使用 HetuEngine UDF

使用客户端访问：

1. 进入 HetuEngine 客户端，请参考 10.6 使用 HetuEngine 客户端。
2. 执行如下命令创建 HetuEngine UDF：

```
CREATE FUNCTION example.namespace01.add_two (
 num integer
)
RETURNS integer
LANGUAGE JAVA
DETERMINISTIC
SYMBOL "com.xxx.bigdata.hetuengine.functions.AddTwo"
URI "hdfs://hacluster/udf/hetuserver/udf-test-0.0.1-SNAPSHOT.jar";
```

3. 执行如下命令使用 HetuEngine UDF:

```
select example.namespace01.add_two(2);
_col0
-------
    4
(1 row)
```

说明

函数实现类中通过重载方法来区分同名的不同函数，在创建 HetuEngine UDF 时要指定不同的函数名称。

10.13 HetuEngine 日志介绍

日志描述

日志存储路径：

HetuEngine 的日志保存路径为“/var/log/Bigdata/hetuengine/”和“/var/log/Bigdata/audit/hetuengine/”。

日志归档规则：

日志归档规则采用 FixedWindowRollingPolicy 策略，可配置项为单个文件最大值、日志归档的最大保留数目，具体规则如下：

- 当单个文件超过默认单个文件最大值时，就会生成一个新的归档压缩文件，归档后的日志压缩文件命名规则为*<原有日志名>.[编号]*.log.gz。
- 日志归档文件数目达到最大值时，会删除最旧的日志文件。

审计日志默认单个文件最大值为 30M，日志归档文件最大数目为 20。

运行日志默认单个文件最大值为 100M，日志归档文件最大数目为 20。

如果需要修改实例的运行日志或审计日志的单个文件最大值或者日志归档文件最大数目，请执行如下操作：

登录 Manager。

步骤 1 选择“集群 > 服务 > HetuEngine > 配置 > 全部配置 ”。

步骤 2 在参数列表中查看日志级别的参数，搜索“logback.xml”，可以看到 HSBroker、HSConsole、HSFabric、QAS 当前的运行日志和审计日志的配置。

步骤 3 选择要修改的配置项进行修改。

步骤 4 单击“保存”，然后单击“确定”，成功后等待大约 30 秒，配置自动生效。

----结束

表10-61 HetuEngine 日志列表

日志类别	日志文件名	描述
安装启停日志	prestart.log	启动前预处理脚本日志。
	start.log	启动日志。
	stop.log	停止日志。
	postinstall.log	安装日志。
运行日志	*实例名*.log	运行日志。
	*实例名*_wsf.log	接口参数校验日志。
	hdfs://hacluster/hetuserverhistory/*租户*/coordinator 或 worker/*application_ID*/*container_ID*/*yyyyMMdd*/server.log	HetuEngine 计算实例的运行日志。
状态检查日志	service_check.log	健康检查日志。
	service_getstate.log	状态检查日志。
	availability-check.log	HetuEngine 服务是否可用状态检查日志。
	haCheck.log（MRS 3.2.0 及以后版本）	QAS 检查高可用状态打印的日志。
审计日志	*实例名*-audit.log	审计日志。

日志类别	日志文件名	描述
	hdfs://hacluster/hetuserverhistory/*租户*/coordinator/*application_ID*/*container_ID*/*yyyyMMdd*/hetuserver-engine-audit.log	HetuEngine 计算实例的审计日志。
queryInfo 日志	hdfs://hacluster/hetuserverhistory/*租户*/coordinator/*application_ID*/*container_ID*/*yyyyMMdd*/queryinfo.log	HetuEngine 计算实例的 queryInfo 日志，SQL 运行的统计信息。
清理日志	cleanup.log	清理脚本日志。
初始化日志	hetupg.log	元数据初始化日志。
	ranger-presto-plugin-enable.log	Ranger 插件集成到 HetuEngine 内核的操作日志。
客户端日志（MRS 3.2.0 及以后版本）	qas_client.log	QAS 实例 ZooKeeper 客户端日志。
堆栈信息日志（MRS 3.2.0 及以后版本）	threadDump-<*DATE*>.log	实例重启或实例停止时会打印。
其它（MRS 3.2.0 及以后版本）	hetu-updateKrb5.log	部署 Hive 集群更换域后，Hive 数据源配置自动刷新时打印的日志。
	hetu_utils.log	启动时预处理脚本调用工具类上传文件到 HDFS 时打印的日志。

日志级别

HetuEngine 中提供了如表 10-62 所示的日志级别。日志级别优先级从高到低分别是 OFF、ERROR、WARN、INFO、DEBUG。程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表10-62 日志级别

级别	描述
OFF	OFF 表示不记录日志。
ERROR	ERROR 表示记录当前时间处理存在错误信息。
WARN	WARN 表示记录当前事件处理存在异常信息。

级别	描述
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改实例的运行日志或审计日志级别，请执行如下操作：

登录 FusionInsight Manager。

步骤 2 选择“集群 > 服务 > HetuEngine > 配置 > 全部配置 ”。

步骤 3 在参数列表中查看日志级别的参数，搜索“logback.xml”，可以看到 HSBroker、HSConsole、HSFabric 当前的运行日志和审计日志的级别。

步骤 4 选择所需修改的日志级别。

步骤 5 单击“保存”，然后单击“确定”，成功后等待大约 30 秒，配置自动生效。

----结束

如果要修改 HetuEngine Coordinator/Worker 日志级别，请执行如下操作：

登录 FusionInsight Manager。

步骤 6 选择“集群 > 服务 > HetuEngine > 配置 > 全部配置 ”。

步骤 7 在参数列表中查看日志级别的参数，搜索“log.properties”，可以看到当前的日志级别。

步骤 8 选择所需修改的日志级别。

步骤 9 单击“保存”，然后单击“确定”，等待操作成功。

步骤 10 选择“集群 > 服务 > HetuEngine > 实例”，单击角色列表的 HSBroker 实例，选择“更多 > 重启实例”。

步骤 11 待 HSBroker 实例重启后，选择“集群 > 服务 > HetuEngine”在 概览页面单击“HSConsole WebUI”后的链接，进入计算实例界面。

步骤 12 选择计算实例，单击“停止”，待实例停止后，再单击“启动”重新启动计算实例。

----结束

10.14 HetuEngine 性能调优

10.14.1 调整 Yarn 服务配置

操作场景

HetuEngine 依赖 Yarn 服务提供的资源分配、控制等能力，需要根据实际业务和集群的服务器配置情况调整 Yarn 服务配置，以获得最佳的性能效果。

操作步骤

登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > 服务 > Yarn > 配置 > 全部配置“，参考表 10-63 配置 Yarn 服务参数。

表10-63 Yarn 服务配置参数

参数名称	描述	默认值	建议值
yarn.nodemanager.resource.memory-mb	表示该节点上 YARN 可使用的物理内存总量，默认为 16384，单位：MB。若该节点有其他业务的常驻进程，请降低此参数值给该进程预留足够运行资源。	16384	为达到更优性能，可配置为集群中节点最小物理内存的 90%。
yarn.nodemanager.resource.cpu-vcores	可分配给 container 的 CPU 核数。	8	为达到更优性能，可配置为集群中节点最小 CPU vCores。
yarn.scheduler.maximum-allocation-mb	为 ResourceManager 中每个 container 请求分配的最大内存。单位：MB。如果请求的内存量很多，将分配该参数设置的内存量。	65536	为达到更优性能，可配置为集群中节点最小物理内存的 90%。
yarn.scheduler.maximum-allocation-vcores	ResourceManager 中每个 container 请求的最大分配值，用虚拟 CPU 核数表示。高于该值的请求将不生效，且将覆写为该值。	32	为达到更优性能，可配置为集群中节点最小 CPU vCores。

步骤 2 单击“保存”，保存配置。

步骤 3 选择“集群 > 服务 > Yarn > 更多 > 重启服务”，重启 Yarn 服务让参数生效。

----结束

10.14.2 调整集群节点资源配置

操作场景

HetuEngine 默认的内存大小参数和硬盘溢出路径参数默认并非最佳，需要根据实际业务和集群的服务器配置情况调整集群节点资源配置，以获得最佳的性能效果。

操作步骤

登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > 服务 > HetuEngine > 配置 > 全部配置”，参考表 10-64 调整集群节点资源配置参数。

表10-64 集群节点资源配置参数

参数名称	默认值	建议值	参数解释	参数文件
yarn.hetuserver.engine.coordinator.memory	5120	比“yarn.scheduler.maximum-allocation-mb”至少少2GB。	单个 Coordinator 节点使用的内存大小。	application.properties
yarn.hetuserver.engine.coordinator.number-of-containers	2	2	Coordinator 节点数量。	application.properties
yarn.hetuserver.engine.coordinator.number-of-cpus	1	比“yarn.scheduler.maximum-allocation-vcores”至少少 2 个 vCores。	单个 Coordinator 节点使用的 CPU vCores。	application.properties
yarn.hetuserver.engine.worker.memory	10240	比“yarn.scheduler.maximum-allocation-mb”至少少2GB。	单个 Worker 节点使用的内存大小。	application.properties
yarn.hetuserver.engine.worker.number-of-containers	2	根据具体业务调整。	Worker 节点数量。	application.properties
yarn.hetuserver.engine.worker.number-of-cpus	1	比“yarn.scheduler.maximum-allocation-vcores”至少少 2	单个 Worker 节点使用的 CPU vCores。	application.properties

参数名称	默认值	建议值	参数解释	参数文件
		个 vCores。		
extraJavaOptions 参数中的 Xmx 大小	8GB	*单个 Worker 节点使用的内存大小* * 0.8。	Worker JVM 进程最大可用内存。	worker.jvm.config
query.max-memory-per-node	5GB	Worker JVM * 0.7。	Query 单节点最大可用内存。	worker.config.properties
query.max-total-memory-per-node	5GB	Worker JVM * 0.7。	Query + System 单节点最大可用内存。	worker.config.properties
memory.heap-headroom-per-node	3GB	Worker JVM * 0.3。	系统堆单节点最大可用内存。	worker.config.properties
extraJavaOptions 参数中的 Xmx 大小	4GB	*单个 Coordinator 节点使用的内存大小* * 0.8。	Coordinator JVM 进程最大可用内存。	coordinator.jvm.config
query.max-memory-per-node	3GB	Coordinator JVM * 0.7。	节点查询可使用的用户内存最大值。	coordinator.config.properties
query.max-total-memory-per-node	3GB	Coordinator JVM * 0.7。	Query + System 单节点最大可用内存。	coordinator.config.properties
memory.heap-headroom-per-node	1GB	Coordinator JVM * 0.3。	系统堆单节点最大可用内存。	coordinator.config.properties
query.max-memory	7GB	Sum(query.max-memory-per-node) * 0.7。	Query 集群最大可用内存。	worker.config.properties/coordinator.config.properties
experimental.spiller-spill-path	CONTAINER_ROOT_PATH/tmp/hetuserver/hetuserver-sqlengine/	一块或多块独立的 SSD 硬盘。	磁盘吐出文件路径。	worker.config.properties/coordinator.config.properties
experimental.max-spill-per-node	10GB	Sum(每个节点可用空间) * 50%。	所有查询在单节点上磁盘吐出文件可用空间。	worker.config.properties/coordinator.config.properties

参数名称	默认值	建议值	参数解释	参数文件
experimental.query-max-spill-per-node	10GB	节点可用硬盘空间的 80%。	单个查询在单节点上磁盘吐出文件可用空间。	worker.config.properties/coordinator.config.properties

步骤 2 单击“保存”，保存配置。

步骤 3 选择“集群 > 服务 > HetuEngine > 更多 > 重启服务”，重启 HetuEngine 服务让参数生效。

----结束

10.14.3 调整 INSERT 写入优化

操作场景

HetuEngine 向 Hive 数据源分区表写入数据时，需要根据实际业务的查询结果中分区列数量添加相关自定义配置，以获得最佳的性能效果。

操作步骤

使用 HetuEngine 管理员用户登录 FusionInsight Manager 页面，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在“概览”页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 单击“数据源”，在 Hive 数据源所在行的“操作”列下单击“编辑”，在页面内新增自定义配置， 参考表 10-65 调整自定义参数。

表10-65 INSERT 语句性能调优参数

参数名称	值
hive.max-partitions-per-writers	大于或等于要写入数据的 Hive 数据源分区表所有分区列 distinct 的 count 值的乘积。
task.writer-count	1

说明

distinct 的 count 值举例：

结果表“t2”有“col1”，“col2”和“col3”三列，查询结果数据如下所示：

col1 col2 col3

A 100 5

C 103 4

B	101	3
E	110	4
D	100	5

- 若“col3”为分区列，其 distinct（去重）的 count 值为 3，“hive.max-partitions-per-writers”的值建议大于或等于 3。
- 若结果表有多个分区列，如“col2”和“col3”都是分区列，“col2”的 distinct 的 count 值为 4，“col3”的 distinct 的 count 值为 3，则“hive.max-partitions-per-writers”的值建议大于或等于 12（distinct 的 count 值乘积）。

步骤 3 单击“确定”完成配置。

----结束

10.14.4 调整元数据缓存

操作场景

当 HetuEngine 访问 Hive 数据源时，需要访问 Hive metastore 获取元数据信息。HetuEngine 提供了元数据缓存的功能，当首次访问 Hive 数据源的库或表时，会将该库或表的元数据信息（数据库名、表名、表字段、分区信息、权限信息等）缓存起来，后续访问时不需要再次访问 Hive metastore，在 Hive 数据源的表数据变化不频繁的场景下，可以一定程度上提升查询的性能。

操作步骤

登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > 服务 > HetuEngine > 配置 > 全部配置”，参考表 10-66 调整元数据缓存参数。

表10-66 元数据缓存参数

参数名称	参数解释	默认值	参数文件
hive.metastore-cache-ttl	共部署 hive 数据源的元数据信息的缓存有效时间	0s	hive.properties
hive.metastore-cache-maximum-size	共部署 hive 数据源的元数据信息的最大缓存大小	10000	hive.properties
hive.metastore-refresh-interval	共部署 hive 的元数据的刷新周期。	1s	hive.properties
hive.per-transaction-metastore-cache-maximum-size	共部署 hive 数据源的每条事务的元数据信息的最大缓存大小	1000	hive.properties

步骤 2 单击“保存”，保存配置。

步骤 3 选择“集群 > 服务 > HetuEngine > 更多 > 重启服务”，重启 HetuEngine 服务让参数生效。

----结束

10.14.5 调整 CTE（公用表表达式）配置

操作场景

如果查询中包含的表或公用表表达式（CTE）出现多次且具有相同的投影和过滤器，则可以配置打开 CTE Reuse 功能来将数据缓存在内存中，可以避免多次从磁盘读取数据，减少执行查询所需的时间。

操作步骤

登录 FusionInsight Manager 页面。

步骤 1 选择“集群 > 服务 > HetuEngine > 配置 > 全部配置”，参考表 10-67 配置相关参数。

表10-67 CTE 配置参数

参数名称	参数解释	建议值	默认值	参数文件
optimizer.reuse-table-scan	是否启用 cte 的表数据重用功能	true	false	coordinator.config.properties、worker.config.properties
experimental.spill-reuse-tablescan	是否启用重用 tablescan 时尝试将内存溢出到磁盘功能	true	false	coordinator.config.properties、worker.config.properties
optimizer.cte-reuse-enabled	是否启动 cte 重用的功能，启用此标志后，无论主查询中使用同一 CTE 多少次，都仅执行一次公用表表达式（CTE）	true	false	coordinator.config.properties、worker.config.properties
dynamic-filtering-max-per-driver-size	动态过滤开始时每个 driver 可以收集的最大数据量	100 MB	1MB	coordinator.config.properties、worker.config.properties

步骤 2 单击“保存”，保存配置。

步骤 3 选择“集群 > 服务 > HetuEngine > 更多 > 重启服务”，输入密码后重启 HetuEngine 服务让参数生效。

----结束

10.14.6 调整动态过滤

本章节适用于 MRS 3.2.0 及以后版本。

操作场景

HetuEngine 提供了动态过滤的功能，在 Join 场景中开启动态过滤往往有较大的性能提升。

本章节介绍如何开启动态过滤功能。

操作步骤

使用可访问 HetuEngine WebUI 界面的用户登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在概览页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 在“计算实例”页签，在待操作的实例所在行的“操作”列单击“配置”。

步骤 3 在“自定义配置”单击“增加”添加如下参数。

表10-68 动态过滤参数

名称	值	参数文件	参数解释
hetu.seed-store.enabled	true	coordinator.config.properties 和 worker.config.properties	开启 seed-store 功能，默认“false”。开启动态过滤功能时需设置为“true”。
hetu.embedded-state-store.enabled	true	coordinator.config.properties 和 worker.config.properties	开启 state-store 功能，默认“false”。开启动态过滤功能时需设置为“true”。
enable-dynamic-filtering	true	coordinator.config.properties 和 worker.config.properties	开启动态过滤功能，默认“false”。
dynamic-filtering-wait-time	1s	coordinator.config.properties 和 worker.config.properties	等待动态过滤条件生成的最长等待时间，默认值：1s。
dynamic-filtering-max-size	1000000	coordinator.config.properties 和 worker.config.properties	每个 dynamic filter 的大小上限，如果预估大小超过设定值，代价优化器不会生成对应的 dynamic

名称	值	参数文件	参数解释
			filter，默认值：1000000。
dynamic-filtering-max-per-driver-size	100M	coordinator.config.properties 和 worker.config.properties	动态过滤开始时每个 driver 可以收集的最大数据量，默认值：1M。
dynamic-filtering-max-per-driver-row-count	20000	coordinator.config.properties 和 worker.config.properties	动态过滤每一个 driver 存放的数据行数，默认值：20000。

步骤 4 添加完成后勾选“立即启动”，单击“确定”。

----结束

10.14.7 调整自适应查询执行

本章节适用于 MRS 3.2.0 及以后版本。

操作场景

一般来说，大任务的 SQL 语句（例如在从整个表中扫描大量数据的情况）会占用大量的资源，在资源紧张的情况下，会影响其他任务的负载。这不仅导致用户体验不佳，也会提高运维成本。为了解决上述问题，HetuEngine 提供了自适应查询执行的功能，该功能会自适应地调度执行查询。

本章节介绍如何开启自适应查询执行功能。

操作步骤

使用 HetuEngine 管理员用户登录 Manager，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在“概览”页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 单击“数据源”，在待修改的 Hive 数据源所在行的“操作”列下单击“编辑”，

步骤 3 可参考步骤 6.7，在自定义参数中添加“hive.strict-mode-restrictions”，值为“NONE”，开启自适应查询执行功能。

步骤 4 单击“确定”保存修改。

----结束

10.14.8 调整 Hive 元数据超时

本章节适用于 MRS 3.3.0 及以后版本。

操作场景

大分区表包含过多分区，导致任务超时，同时大量分区可能需要更多时间来加载与元存储缓存同步。因此，为了在更大规模存储中获得更好的性能，建议相应地调整加载元数据缓存最大超时时间和加载元数据连接池最大等待时间。

操作步骤

使用 HetuEngine 管理员用户登录 FusionInsight Manager 页面，选择“集群 > 服务 > HetuEngine”，进入 HetuEngine 服务页面。

步骤 1 在“概览”页签下的“基本信息”区域，单击“HSConsole WebUI”后的链接，进入 HSConsole 界面。

步骤 2 单击“数据源”，在 Hive 数据源所在行的“操作”列下单击“编辑”，在页面内新增如下自定义配置：

表10-69 元数据超时参数

参数名称	默认值	描述
hive.metastore-timeout	10s	• 共部署 Hive 数据源加载元数据缓存最大超时时间，单位为秒或分钟 • 对于大分区表中的操作，值可为 60s 或更大，需要根据数据量进行配置
hive.metastore.connection.pool.maxWaitMillis	1000	• 共部署 Hive 数据源加载元数据连接池最大等待时间，单位为毫秒 • 对于访问连接池频繁且连接池连接数较少情况下，值可为 100000 或更大，需要根据业务量进行配置

步骤 3 单击“确定”完成配置。

----结束

10.15 HetuEngine 常见问题

10.15.1 如何进行域名修改后的相关操作

问题

用户修改域名后，会导致已安装的客户端配置和数据源配置失效，且新创建的集群不可用。对接不同域的数据源时，HetuEngine 会自动的合并 krb5.conf 文件。域名修改后，kerberos 认证的域名会发生变化，所以此前对接的数据源信息会失效。

回答

- 需要重新安装集群客户端。
- 参考 10.9.9 管理已配置的数据源删除 HSConsole 上旧的数据源信息，然后参考 10.9 配置数据源重新在 HSConsole 配置数据源信息。

10.15.2 如何处理通过客户端启动集群超时

问题

通过客户端启动集群，集群启动时间过长会等待超时并退出等待界面。

回答

等待集群启动超时，会自动退出等待界面，用户可以等待集群启动成功后再重新登录，用户还可以在 HSConsole 页面上查看集群的运行状态当集群处于运行中状态时再重新登录。如果集群启动失败用户可以通过启动日志定位失败原因（参见 10.13 HetuEngine 日志介绍）。

10.15.3 如何处理数据源丢失问题

问题

登录客户端查看 HSConsole 界面对接的数据源，数据源丢失。

回答

数据源丢失可能原因是 DBservice 主备倒换或数据库连接数使用率超过阈值造成，用户可以登录 FusionInsight Manager 页面查看告警信息，根据告警指导清除 DBService 告警，问题即可解决。

10.15.4 如何处理 HetuEngine 告警

问题

登录 FusionInsight Manager，发现集群有 HetuEngine 相关告警信息。

回答

登录 FusionInsight Manager，进入运维页面告警项，查看详细告警信息。单击关注告警的下拉按钮可以看到告警详细信息。大部分告警通过详情中的告警原因项就可以获得定位和处理告警的方法。用户还可以通过告警信息的查看帮助操作项查看告警的联机帮助信息，如果是非自动清除类告警，在告警处理完后用户可以手动清除告警信息。

1. 登录 FusionInsight Manager。
2. 选择“运维 > 告警 > 告警 ”。
3. 在告警信息列表中查看告警信息详情。

4. 单击告警所在行“操作”列的“查看帮助”，查看告警联机帮助获取更多帮助信息。
5. 根据联机帮助中提供的 HetuEngine 告警可能原因进行定位，并根据提供的处理步骤指导清除告警。

10.15.5 如何处理计算实例启动失败报错 Python 不存在

问题

启动 HetuEngine 计算实例失败，查看 coordinator Container 下面的“stderr.txt”日志报错如下：

```
/usr/bin/env: ‘python’: No such file or directory
```

回答

HetuEngine 计算实例的启动依赖 Python 文件，需确保各节点“/usr/bin/”路径下面存在 Python 文件。

登录 FusionInsight Manager，单击“主机”，查看并记录所有主机的业务 IP。

步骤 1 以 **root** 用户登录步骤 1 记录的节点，在所有节点都执行以下命令，在“/usr/bin/”目录下添加“python3”的软连接。

cd /usr/bin

ln -s python3 python

步骤 2 重新启动 HetuEngine 计算实例。

----结束

10.15.6 如何处理计算实例启动 30 秒后直接故障

本章节适用于 MRS 3.3.0 及以后版本。

问题

启动 HetuEngine 计算实例后，大约过了 30 秒，计算实例直接进入故障状态。

回答

HetuEngine 启动计算实例时，会给 Yarn 发送命令启动对应的 application，若 30 秒内没有接收到 Yarn 的响应消息，则因超时结束此次请求。

若由于机器性能或者是网络环境问题，无法在 30 秒内接收到 Yarn 启动 application 的响应消息时，可适当延长对应的超时时间。

登录 FusionInsight Manager。

步骤 1 选择“集群 > 服务 > HetuEngine > 配置 > 全部配置”。

步骤 2 搜索参数“application.customized.properties”，添加并保存自定义参数“yarn.application.start.timeout”，根据需求填写超时时间（仅填写数字，不输入单位），单位：秒。

步骤 3 单击“实例”，勾选所有 HSBroker 实例，选择“更多 > 重启实例”根据界面提示完成重启 HSBroker 实例。

----结束

10.16 HetuEngine SQL 语法

10.16.1 数据类型

10.16.1.1 数据类型介绍

目前建表时支持的数据类型有：tinyint，smallint，bigint，int，boolean，real，decimal，double，varchar，string，binary，varbinary，timestamp，date，char，array，row，map，struct。其余的类型在数据查询和运算时支持。

通常情况下，大部分非复合数据类型都可以通过字面量加字符串的方式来输入，示例为添加了一个 json 格式的字符串：

```
select json '{"name": "aa", "sex": "man"}';
           _col0
---------------------------------
 {"name":"aa","sex":"man"}
(1 row)
```

10.16.1.2 布尔类型

“真”值的有效文本值是：TRUE、't'、'true'、'1'。

“假”值的有效文本值是：FALSE、'f'、'false'、'0'。

使用 TRUE 和 FALSE 是比较规范的用法（也是 SQL 兼容的用法）。

示例：

```
select BOOLEAN '0';
 _col0
-------
 false
(1 row)

select BOOLEAN 'TRUE';
 _col0
-------
 true
(1 row)

select BOOLEAN 't';
 _col0
-------
```

```
 true
(1 row)
```

10.16.1.3 整数类型

表10-70 整数类型

名称	描述	存储空间	取值范围	字面量
TINYINT	微整数	8 位	-128~127	TINYINT
SMALLINT	小整数	16 位	-32,768 ~ +32,767	SMALLINT
INTEGER	整数	32 位	-2,147,483,648 ~ +2,147,483,647	INT
BIGINT	大整数	64 位	-9,223,372,036,854,775,808 ~ 9,223,372,036,854,775,807	BIGINT

示例：

```
--创建具有 TINYINT 类型数据的表。
CREATE TABLE int_type_t1  (IT_COL1 TINYINT) ;
--插入 TINYINT 类型数据
insert into int_type_t1  values (TINYINT'10');
--查看数据。
SELECT * FROM int_type_t1;
 it_col1
---------
 10
(1 row)
--删除表。
DROP TABLE int_type_t1;
```

10.16.1.4 固定精度型

名称	描述	存储空间	取值范围	字面量
DECIMAL	固定精度的十进制数。精度最高支持到38 位，但精度小于 18 位能保障性能最好。 Decimal 有两个输入参数： • precision：总位数，默认 38 • scale：小数部分的位数，默认 0 说明 如果小数位为零，即十进制（38,0），则支持最	64 位	$-10^{38}+1$ ~ $10^{38}-1$	DECIMAL

名称	描述	存储空间	取值范围	字面量
	高 19 位精度。			
NUMERIC	同 DECIMAL	128 位	$-10^{38}+1 \sim 10^{38}-1$	NUMERIC

表10-71 字面量示例

字面量示例	数据类型
DECIMAL '0'	DECIMAL(1)
DECIMAL '12345'	DECIMAL(5)
DECIMAL '0000012345.1234500000'	DECIMAL(20, 10)

```
--创建具有 DECIMAL 类型数据的表
CREATE TABLE decimal_t1 (dec_col1 DECIMAL(10,3)) ;

--插入具有 DECIMAL 类型数据
insert into decimal_t1 values (DECIMAL '5.325');

--查看数据
SELECT * FROM decimal_t1;
 dec_col1
---------
 5.325
(1 row)

--反例：小数位数超出定义长度，sql 执行失败
insert into decimal_t1 values (DECIMAL '5.3253');
Query 20201126_034601_00053_tq98i@default@HetuEngine failed: Insert query has
mismatched column types: Table: [decimal(10,3)], Query: [decimal(5,4)]

--删除表
DROP TABLE decimal_t1;

--创建 NUMERIC 类型表
CREATE TABLE tb_numberic_hetu(col1 NUMERIC(9,7));
CREATE TABLE

--插入数据
INSERT INTO tb_numberic_hetu values(9.12);
INSERT: 1 row

--查看数据
SELECT * FROM tb_numberic_hetu;
col1
------------
```

```
 9.1200000
(1 row)
```

10.16.1.5 浮点型

名称	描述	存储空间	取值范围	字面量
REAL	实数	32位	1.40129846432481707e-45 ~3.40282346638528860e+38，正或负	REAL
DOUBLE	双精度浮点数，15到17个有效位，具体取决于使用场景，有效位位数并不取决于小数点位置	64位	4.94065645841246544e-324 ~1.79769313486231570e+308，正或负	DOUBLE
FLOAT	单精度浮点数，6到9个有效位，具体取决于使用场景，有效位位数并不取决于小数点位置	32位	1.40129846432481707e-45 ~3.40282346638528860e+38，正或负	FLOAT

用法说明：

- 分布式查询使用高性能硬件指令进行单精度或者双精度运算时，由于每次执行的顺序不一样，在调用聚合函数，比如SUM()，AVG()，特别是当数据规模非常大时，达到数千万甚至数十亿，其运算结果可能会略有不同。这种情况下，建议使用DECIMAL数据类型来运算。
- 可以使用别名来指定数据类型。

  示例：

  ```
  --创建具有 float 类型数据的表
  CREATE TABLE float_t1 (float_col1 FLOAT) ;
  --插入具有 float 类型数据
  insert into float_t1 values (float '3.50282346638528862e+38');
  --查看数据
  SELECT * FROM float_t1;
  float_col1
  ------------
  Infinity
  (1 row)
  --删除表
  DROP TABLE float_t1;
  ```

- 当小数部分为0时，可以通过cast()转为对应范围的整数处理，小数部分会四舍五入。

  示例：

```
select CAST(1000.0001 as INT);
_col0
-------
1000
(1 row)
select CAST(122.5001 as TINYINT);
_col0
-------
123
(1 row)
```

- 使用指数表达式时，可以将字符串转为对应类型。

  示例：

```
select CAST(152e-3 as double);
_col0
-------
0.152
(1 row)
```

10.16.1.6 字符类型

名称	描述
VARCHAR(n)	变长字符串，n 指字节长度。
CHAR(n)	定长字符串，不足补空格。n 是指字节长度，如不带精度 n，默认为 1。
VARBINARY	变长二进制数据。需要带上前缀 X，如：X'65683F'，暂不支持指定长度的二进制字符串。
JSON	取值可以是 a JSON object、a JSON array、a JSON number、a JSON string、true、false or null。
STRING	兼容 impala 的 String，底层是 varchar。
BINARY	兼容 hive 的 Binary，底层实现为 varbinary。

- SQL 表达式中，支持简单的字符表达式，也支持 Unicode 方式，一个 Unicode 字符串是以 U&为固定前缀，以 4 位数值表示的 Unicode 前需要加转义符。

```
-- 字符表达式
select 'hello,winter!';
     _col0
------------------
 hello,winter!
(1 row)
-- Unicode 表达式
select U&'Hello winter \2603 !';
     _col0
------------------
 Hello winter ☃ !
(1 row)
-- 自定义转义符
```

```
select U&'Hello winter #2603 !' UESCAPE '#';
     _col0
------------------
 Hello winter ☃ !
(1 row)
```

- VARBINARY 与 BINARY。

```
-- 创建 VARBINARY 类型或 BINARY 类型的表
 create table binary_tb(col1 BINARY);

-- 插入数据
 INSERT INTO binary_tb values (X'63683F');

--查询数据
 select * from binary_tb ;  -- 63 68 3f
```

- 在做 CHAR 数值比较的时候，在对两个仅尾部空格数不同的 CHAR 进行比较时，会认为它们是相等的。

```
SELECT CAST('FO' AS CHAR(4)) = CAST('FO    ' AS CHAR(5));
 _col0
-------
 true
(1 row)
```

10.16.1.7 时间和日期类型

限制

时间和日期类型目前精确到毫秒。

表10-72 时间和日期类型

名称	描述	存储空间
DATE	日期和时间。仅支持 ISO 8601 格式：'2020-01-01'	32 位
TIME	不带时区的时间（时、分、秒、毫秒） 例如：TIME '01:02:03.456'	64 位
TIME WITH TIMEZONE	带时区的时间（时、分、秒、毫秒），时区用 UTC 值表示 例如：TIME '01:02:03.456 -08:00'	96 位
TIMESTAMP	时间戳	64 位
TIMESTAMP WITH TIMEZONE	带时区的时间戳	64 位
INTERVAL YEAR TO MONTH	时间间隔字面量，年，月，格式： SY-M S：可选符号（+/-） Y：年数	128 位

名称	描述	存储空间
	M：月数	
INTERVAL DAY TO SECOND	时间间隔字面量，日，小时，分钟，秒，精确到毫秒，格式：SD H:M:S.nnn S：可选符号（+/-） D：天数 M：分钟数 S：秒数 nnn：毫秒数	128 位

示例：

```
-- 查询日期
SELECT DATE '2020-07-08';
    col0
------------
 2020-07-08
(1 row)

-- 查询时间
SELECT TIME '23:10:15';
 _col0
--------------
 23:10:15
(1 row)

SELECT TIME '01:02:03.456 -08:00';
 _col0
--------------
 01:02:03.456-08:00
(1 row)

-- 时间间隔用法
SELECT TIMESTAMP '2015-10-18 23:00:15' + INTERVAL '3 12:15:4.111' DAY TO SECOND;
 _col0
-------------------------
 2015-10-22 11:15:19.111
(1 row)

SELECT TIMESTAMP '2015-10-18 23:00:15' + INTERVAL '3-1' YEAR TO MONTH;
         _col0
-------------------------
 2018-11-18 23:00:15
(1 row)

select INTERVAL '3' YEAR + INTERVAL '2' MONTH ;
 _col0
-------
 3-2
(1 row)
```

```
select INTERVAL '1' DAY+INTERVAL '2' HOUR +INTERVAL '3' MINUTE +INTERVAL '4'
SECOND ;
    _col0
----------------
 1 02:03:04.000
(1 row)
```

10.16.1.8 复杂类型

ARRAY

数组。

示例：ARRAY[1, 2, 3]。

```
--创建 ARRAY 类型表
create table array_tb(col1 ARRAY<STRING>);

--插入一条 ARRAY 类型数据
insert into array_tb values(ARRAY['HetuEngine','Hive','Mppdb']);

--查询数据
select * from array_tb; --    [HetuEngine, Hive, Mppdb]
```

MAP

键值对数据类型。

示例：MAP(ARRAY['foo', 'bar']、ARRAY[1, 2])。

```
--创建 Map 类型表
create table map_tb(col1 MAP<STRING,INT>);

--插入一条 Map 类型数据
insert into map_tb values(MAP(ARRAY['foo','bar'],ARRAY[1,2]));

--查询数据
select * from map_tb; --   {bar=2, foo=1}
```

ROW

ROW 的字段可是任意所支持的数据类型，也支持各字段数据类型不同的混合方式。

```
--创建 ROW 表
create table row_tb (id int,col1 row(a int,b varchar));

--插入 ROW 类型数据
insert into row_tb values (1,ROW(1,'HetuEngine'));

--查询数据
select * from row_tb;
 id |     col1
----|--------------
  1 | {a=1, b=HetuEngine}
```

```
--字段是支持命名的，默认情况下，Row 的字段是未命名的
select  row(1,2e0),CAST(ROW(1, 2e0) AS ROW(x BIGINT, y DOUBLE));
         _col0         |    _col1
-----------------------|--------------
 {1, 2.0} | {x=1, y=2.0}
(1 row)

--命名后的字段，可以通过域操作符"."访问
select col1.b from row_tb; -- HetuEngine

--命名和未命名的字段，都可以通过位置索引来访问，位置索引从 1 开始，且必须是一个常量
select col1[1] from row_tb;   -- 1
```

IPADDRESS

IP 地址，可以表征 IPv4 或者 IPv6 地址。但在系统内，该类型是一个统一的 IPv6 地址。

对于 IPv4 的支持，是通过将 IPv4 映射到 IPv6 的取值范围（RFC 4291#section-2.5.5.2）来实现的。当创建一个 IPv4 时，会被映射到 IPv6。当格式化时，如果数据是 IPv4 又会被重新映射为 IPv4。 其他的地址则会按照 RFC 5952 所定义的规范格式来进行格式化。

示例：

```
select IPADDRESS '10.0.0.1', IPADDRESS '2001:db8::1';
  _col0   |    _col1
----------|-------------
 10.0.0.1 | 2001:db8::1
(1 row)
```

UUID

标准 UUID (Universally Unique IDentifier)，也被称为 GUID (Globally Unique IDentifier)。

遵从 RFC 4122 标准所定义的格式。

示例：

```
select UUID '12151fd2-7586-11e9-8f9e-2a86e4085a59';
              _col0
--------------------------------------
 12151fd2-7586-11e9-8f9e-2a86e4085a59
(1 row)
```

HYPERLOGLOG

基数统计。

用 HyperLogLog 来近似计算唯一数的计数值，其代价要远远小于用 count 来计算。

参见 10.16.3.20 HyperLogLog 函数函数。

- HyperLogLog

A HyperLogLog sketch 可以用来高效的计算 distinct()的近似值。

它以一个稀疏的表征开始，然后变成一个密集的表征，此时效率将变得更高。

- P4HyperLogLog

  类似于 A HyperLogLog sketch，但是它以一个密集的表征开始。

QDIGEST

分位数（Quantile），亦称分位点，是指将一个随机变量的概率分布范围分为几个等份的数值点，常用的有中位数（即二分位数）、四分位数、百分位数等。quantile digest 是一个分位数的集合，当需要查询的数据落在某个分位数附近时，就可以用这个分位数做为要查询数据的近似值。它的精度可以调节，但更高精度的结果会带来空间的昂贵开销。

STRUCT

底层用 ROW 实现，参照 ROW。

示例：

```
-- 创建 struct 表
create table struct_tab (id int,col1 struct<col2: integer, col3: string>);

--插入 struct 类型数据
 insert into struct_tab VALUES(1, struct<2, 'HetuEngine'>);

--查询数据
select * from struct_tab;
 id |       col1
----|---------------------
  1 | {col2=2, col3=HetuEngine}
```

10.16.2 SQL 语法

该章主要描述 HetuEngine 支持的 SQL 语法。本章节样例均以连接 Hive 数据源为使用场景进行构建。

10.16.2.1 DDL 语法

10.16.2.1.1 CREATE SCHEMA

CREATE (DATABASE|SCHEMA) [IF NOT EXISTS] database_name

[COMMENT database_comment]

[LOCATION hdfs_path]

[WITH DBPROPERTIES (property_name=property_value,...)];

CREATE (DATABASE|SCHEMA) [IF NOT EXISTS] database_name

[WITH (property_name=property_value,...)]

描述

创建一个空的 schema。schema 是表、视图以及其他数据库对象的容器。当指定可选参数 IF NOT EXISTS 时，如果系统已经存在同名的 schema，将不会报错。

Schema 默认路径为 hdfs://hacluster/user/hive/warehouse/。

示例

- 创建一个名为 web 的 schema：

```
CREATE SCHEMA web;
```

- 在指定路径创建 schema，兼容写法示例：

```
CREATE SCHEMA test_schema_5 LOCATION '/user/hive';
```

- 在名为 Hive 的 CATALOG 下创建一个名为 sales 的 schema：

```
CREATE SCHEMA hive.sales;
```

- 如果当前 catalogs 下名为 traffic 的 schema 不存在时，则创建一个名为 traffic 的 schema：

```
CREATE SCHEMA IF NOT EXISTS traffic;
```

- 创建一个带属性的 schema：

```
CREATE DATABASE createtestwithlocation COMMENT 'Holds all values' LOCATION
'/user/hive/warehouse/create_new' WITH dbproperties('name'='akku', 'id' ='9');

--通过 describe schema|database 语句来查看刚创建的 schema
describe schema createtestwithlocation;
```

10.16.2.1.2 CREATE VIRTUAL SCHEMA

CREATE/DROP/SHOW VIRTUAL SCHEMA(S)

- **CREATE**

  HetuEngine 中的 CREATE 语句用来创建 SCHEMA 映射，通过映射信息对外开放本域数据源。

  语法如下：

```
CREATE VIRTUAL SCHEMA [ IF NOT EXISTS ] [ ctlg dest.]schema name WITH
( [catalog = ctlg_name,] schema = schm_name, [property_name = expression, ...] )
```

  说明

  创建一个 virtual schema，需要在 WITH 中提供具体映射的 schema 信息。

  ctlg_dest 为在哪个数据源创建 virtual schema，参数可选，如果不指定则取当前 Session 中的 catalog，如果当前 Session 中也未指定 catalog 则会创建失败。

  WITH 必选，schema 参数必选，catalog 参数可选（如果不指定则取当前 Session 中的 catalog）。

  样例语句：

```
CREATE VIRTUAL SCHEMA hive_default WITH (catalog = 'hive', schema = 'default');
```

- **DROP**

  HetuEngine 中的 DROP 语句用来删除 SCHEMA 映射。

  语法如下：

```
DROP VIRTUAL SCHEMA [ IF EXISTS ] schema_name
```

说明

schema_name 也可以替换为全限定名（catalogName.virtualSchema）。

样例语句：

```
DROP VIRTUAL SCHEMA hive_default;
```

- **SHOW**

  HetuEngine 中的 SHOW 语句用来查询所有 SCHEMA 映射。

  语法如下：

  ```
  SHOW VIRTUAL SCHEMAS [ FROM catalog ] [ LIKE pattern ]
  ```

  样例语句：

  ```
  SHOW VIRTUAL SCHEMAS;
  ```

10.16.2.1.3 CREATE TABLE

语法

①

CREATE TABLE [IF NOT EXISTS]

[catalog_name.][db_name.]table_name (

{ column_name data_type [NOT NULL]

[COMMENT col_comment]

[WITH (property_name = expression [, ...])]

| LIKE existing_table_name

[{ INCLUDING | EXCLUDING } PROPERTIES]

}

[, ...]

)

[COMMENT table_comment]

[WITH (property_name = expression [, ...])]

②

CREATE [EXTERNAL] TABLE [IF NOT EXISTS]

[catalog_name.][db_name.]table_name (

{ column_name data_type [NOT NULL]

[COMMENT comment]

[WITH (property_name = expression [, ...])]

| LIKE existing_table_name

[{ INCLUDING | EXCLUDING } PROPERTIES]

}

[, ...]

)

[COMMENT 'table_comment']

[PARTITIONED BY(col_name data_type, ...)]

[CLUSTERED BY (col_name, col_name, ...) [SORTED BY (col_name, col_name, ...)] INTO num_buckets BUCKETS]]

[ROW FORMAT row_format]

[STORED AS file_format]

[LOCATION 'hdfs_path']

[TBLPROPERTIES (orc_table_property = value [, ...])]

③

CREATE [EXTERNAL] TABLE [IF NOT EXISTS]

[catalog_name.][db_name.]table_name (

{ column_name data_type [NOT NULL]

[COMMENT comment]

[WITH (property_name = expression [, ...])]

| LIKE existing_table_name

[{ INCLUDING | EXCLUDING } PROPERTIES]

}

[, ...]

)

[PARTITIONED BY(col_name data_type, ...)]

[SORT BY ([*column* [, *column* ...]])]

[COMMENT 'table_comment']

[ROW FORMAT row_format]

[STORED AS file_format]

[LOCATION 'hdfs_path']

[TBLPROPERTIES (orc_table_property = value [, ...])]

限制

- session 属性可以设置 bucket_count，默认值为-1，表示未设置。创建分区表时，如果 bucket_count 为-1 且建表语句中未设置 buckets，则使用默认值 16。
- 默认外部表存储位置/user/hive/warehouse/{*schema_name*}/{*table_name*}，其中{schema_name}为建表时使用的 schema，{table_name}为表名。

- 指定属性“transactional=true”可以让表支持“原子性、一致性、隔离性、持久性”写入的事务能力，但是将表定义为事务表后，无法通过设置“transactional=false”将其退化为非事务表。

  transactional='true'或 '0'在执行过程中不会进行类型转换，所以这种写法会抛出异常：

  Cannot convert ['true'] to boolean

  Cannot convert ['0'] to boolean
- 默认不允许向托管表（表属性 external = true）插入数据，如需使用该功能，可参考注意事项，添加 hive 自定义属性：hive.non-managed-table-writes-enabled=true。
- Mppdb 有一个限制，数据库的标识符的最大长度为 63，如果把标识符命名超过了最大长度，那么会被自动截取掉超出的部分，只留下最大长度的标识符。
- 跨域场景不支持建表。

描述

使用 CREATE TABLE 创建一个具有指定列的、新的空表。使用 CREATE TABLE AS 创建带数据的表。

- 使用可选参数 IF NOT EXISTS，如果表已经存在则不会报错。
- WITH 子句可用于在新创建的表或单列上设置属性，如表的存储位置（location）、是不是外表（external）等。
- LIKE 子句用于在新表中包含来自现有表的所有列定义。可以指定多个 LIKE 子句，从而允许从多个表中复制列。如果指定了 INCLUDING PROPERTIES，则将所有表属性复制到新表中。如果 WITH 子句指定的属性名称与复制的属性名称相同，则将使用 WITH 子句中的值。默认是 EXCLUDING PROPERTIES 属性，而且最多只能为一个表指定 INCLUDING PROPERTIES 属性。
- PARTITIONED BY 能够用于指定分区的列；CLUSTERED BY 能够被用于指定分桶的列；SORT BY 和 SORTED BY 能够用于给指定的分桶列进行排序；BUCKETS 能够被用于指定分桶数；EXTERNAL 可用于指定创建外部表；STORED AS 能被用于指定文件存储的格式；LOCATION 能被用于指定在 HDFS 上存储的路径。

想要查看支持哪些 column 属性，可以运行以下命令，会显示当前对接的 catalog 分别支持哪些列属性。

SELECT * FROM system.metadata.column_properties;

想要查看支持哪些 table 属性，可以运行以下命令：

SELECT * FROM system.metadata.table_properties;

下表为 catalog 为 hive 时的查询结果。

```
SELECT * FROM system.metadata.table_properties where catalog_name = 'hive';
```

catalog_name	property_name	default_value	type	description
hive	auto_purge	false	boolean	Skip trash when table or partition is deleted

catalog_name	property_name	default_value	type	description
hive	avro_schema_url	-	varchar	URI pointing to Avro schema for the table
hive	bucket_count	0	integer	Number of buckets
hive	bucketed_by	[]	array(varchar)	Bucketing columns
hive	bucketing_version	-	integer	Bucketing version
hive	csv_escape	-	varchar	CSV escape character
hive	csv_quote	-	varchar	CSV quote character
hive	csv_separator	-	varchar	CSV separator character
hive	external_location	-	varchar	File system location URI for external table
hive	format	ORC	varchar	Hive storage format for the table. Possible values: [ORC, PARQUET, AVRO, RCBINARY, RCTEXT, SEQUENCEFILE, JSON, TEXTFILE, TEXTFILE_MULTIDELIM, CSV]
hive	orc_compress	GZIP	varchar	Compression codec used. Possible values: [NONE, SNAPPY, LZ4, ZSTD, GZIP, ZLIB]
hive	orc_compress_size	262144	bigint	orc compression size
hive	orc_row_index_stride	10000	integer	no. of row index strides
hive	orc_stripe_size	67108864	bigint	orc stripe size
hive	orc_bloom_filter_columns	[]	array(varchar)	ORC Bloom filter index columns
hive	orc_bloom_filter_fpp	0.05	double	ORC Bloom filter false positive probability
hive	partitioned_by	[]	array(varchar)	Partition columns
hive	sorted_by	[]	array(varchar)	Bucket sorting columns
hive	textfile_skip_footer_line_count	-	integer	Number of footer lines
hive	textfile_skip_hea	-	integer	Number of header lines

catalog_name	property_name	default_value	type	description
	der_line_count			
hive	transactional	false	boolean	Is transactional property enabled

示例

- 创建一个新表 orders，使用子句 with 指定创建表的存储格式、存储位置、以及是否为外表。

  通过“auto.purge”参数可以指定涉及到数据移除操作（如 DROP、DELETE、INSERT OVERWRITE、TRUNCATE TABLE）时是否清除相关数据：

  - "auto.purge"='true'时，清除元数据和数据文件。
  - "auto.purge"='false'时，仅清除元数据，数据文件会移入 HDFS 回收站。默认值为“false”，且不建议用户修改此属性，避免数据删除后无法恢复。

```
CREATE TABLE orders (
orderkey bigint,
orderstatus varchar,
totalprice double,
orderdate date
)
WITH (format = 'ORC', location='/user',orc_compress='ZLIB',external=true,
"auto.purge"=false);

-- 通过 DESC FORMATTED 语句，可以查看建表的详细信息
desc formatted  orders ;
                      Describe Formatted Table
-------------------------------------------------------------------------------
 # col_name     data_type     comment
 orderkey     bigint
 orderstatus     varchar
 totalprice     double
 orderdate     date

 # Detailed Table Information
 Database:               default
 Owner:                  admintest
 LastAccessTime:           0
 Location:               hdfs://hacluster/user
 Table Type:             EXTERNAL_TABLE

 # Table Parameters:
       EXTERNAL             TRUE
       auto.purge           false
       orc.compress.size      262144
       orc.compression.codec   ZLIB
       orc.row.index.stride    10000
       orc.stripe.size        67108864
       presto_query_id        20220812_084110_00050_srknk@default@HetuEngine
       presto_version         1.2.0-h0.cbu.mrs.320.r1-SNAPSHOT
       transient_lastDdlTime   1660293670
```

```
 # Storage Information
 SerDe Library:           org.apache.hadoop.hive.ql.io.orc.OrcSerde
 InputFormat:             org.apache.hadoop.hive.ql.io.orc.OrcInputFormat
 OutputFormat:            org.apache.hadoop.hive.ql.io.orc.OrcOutputFormat
 Compressed:              No
 Num Buckets:             -1
 Bucket Columns:          []
 Sort Columns:            []
 Storage Desc Params:
       serialization.format    1
(1 row)
```

- 创建一个新表，指定 Row format：

```
--建表时，指定表的字段分隔符为‘,’号（如果创建外表，要求数据文件中的每条记录的字段是以逗号进行分隔）
CREATE TABLE student(
id string,birthday string,
grade int,
memo string)
ROW FORMAT DELIMITED FIELDS TERMINATED BY ',';

--建表时，指定字段分隔符为'\t'，换行符为'\n'
CREATE TABLE test(
id int,
name string ,
tel string)
ROW FORMAT DELIMITED FIELDS TERMINATED BY '\t'
LINES TERMINATED BY '\n'
STORED AS TEXTFILE;
```

- 如果表 orders 不存在，则创建表 orders，并且增加表注释和列注释：

```
CREATE TABLE IF NOT EXISTS orders (
orderkey bigint,
orderstatus varchar,
totalprice double COMMENT 'Price in cents.',
orderdate date
)
COMMENT 'A table to keep track of orders.';
insert into orders values
(202011181113,'online',9527,date '2020-11-11'),
(202011181114,'online',666,date '2020-11-11'),
(202011181115,'online',443,date '2020-11-11'),
(202011181115,'offline',2896,date '2020-11-11');
```

- 使用表 orders 的列定义创建表 bigger_orders：

```
CREATE TABLE bigger_orders (
another_orderkey bigint,
LIKE orders,
another_orderdate date
);

SHOW CREATE TABLE bigger_orders ;
                       Create Table
------------------------------------------------------------------------
 CREATE TABLE hive.default.bigger_orders (
```

```
   another_orderkey bigint,
   orderkey bigint,
   orderstatus varchar,
   totalprice double,
   ordersdate date,
   another_orderdate date
)
WITH (
   external = false,
   format = 'ORC',
   location = 'hdfs://hacluster/user/hive/warehouse/bigger_orders',
   orc_compress = 'GZIP',
   orc_compress_size = 262144,
   orc_row_index_stride = 10000,
   orc_stripe_size = 67108864
)
(1 row)
```

- 标号① 建表示例：

```
CREATE EXTERNAL TABLE hetu_test (orderkey bigint, orderstatus varchar,
totalprice double, orderdate date) PARTITIONED BY(ds int) SORT BY (orderkey,
orderstatus) COMMENT 'test' STORED AS ORC LOCATION '/user' TBLPROPERTIES
(orc_compress = 'SNAPPY', orc_compress_size = 6710422, orc_bloom_filter_columns
= 'orderstatus,totalprice');
```

- 标号② 建表示例：

```
CREATE EXTERNAL TABLE hetu_test1 (orderkey bigint, orderstatus varchar,
totalprice double, orderdate date) COMMENT 'test' PARTITIONED BY(ds int)
CLUSTERED BY (orderkey, orderstatus) SORTED BY (orderkey, orderstatus) INTO 16
BUCKETS STORED AS ORC LOCATION '/user'  TBLPROPERTIES (orc_compress = 'SNAPPY',
orc_compress_size = 6710422, orc_bloom_filter_columns =
'orderstatus,totalprice');
```

- 标号③ 建表示例：

```
CREATE TABLE hetu_test2 (orderkey bigint, orderstatus varchar, totalprice
double, orderdate date, ds int) COMMENT 'This table is in Hetu syntax' WITH
(partitioned_by = ARRAY['ds'], bucketed_by = ARRAY['orderkey', 'orderstatus'],
sorted_by = ARRAY['orderkey', 'orderstatus'], bucket_count = 16, orc_compress =
'SNAPPY', orc_compress_size = 6710422, orc_bloom_filter_columns =
ARRAY['orderstatus', 'totalprice'], external = true, format = 'orc', location =
'/user');
```

- 查看表的建表语句：

```
show create table hetu_test1;
                       Create Table
-----------------------------------------------------------------
 CREATE TABLE hive.default.hetu_test1 (
   orderkey bigint,
   orderstatus varchar,
   totalprice double,
   orderdate date,
   ds integer
)
 COMMENT 'test'
 WITH (
   bucket_count = 16,
```

```
   bucketed_by = ARRAY['orderkey','orderstatus'],
   bucketing_version = 1,
   external_location = 'hdfs://hacluster/user',
   format = 'ORC',
   orc_bloom_filter_columns = ARRAY['orderstatus','totalprice'],
   orc_bloom_filter_fpp = 5E-2,
   orc_compress = 'SNAPPY',
   orc_compress_size = 6710422,
   orc_row_index_stride = 10000,
   orc_stripe_size = 67108864,
   partitioned_by = ARRAY['ds'],
   sorted_by = ARRAY['orderkey','orderstatus']
)
(1 row)
```

创建分区表

```
--创建 schema
CREATE SCHEMA hive.web WITH (location = 'hdfs://hacluster/user');
--创建分区表
CREATE TABLE hive.web.page_views (
  view_time timestamp,
  user_id bigint,
  page_url varchar,
  ds date,
  country varchar
)
WITH (
  format = 'ORC',
  partitioned_by = ARRAY['ds', 'country'],
  bucketed_by = ARRAY['user_id'],
  bucket_count = 50
);
--插入空的分区
CALL system.create_empty_partition(
    schema_name => 'web',
    table_name => 'page_views',
    partition_columns => ARRAY['ds', 'country'],
    partition_values => ARRAY['2020-07-17', 'US']);

CALL system.create_empty_partition(
    schema_name => 'web',
    table_name => 'page_views',
    partition_columns => ARRAY['ds', 'country'],
    partition_values => ARRAY['2020-07-18', 'US']);

--查看分区
SELECT * FROM hive.web."page_views$partitions";
    ds     | country
------------|---------
 2020-07-18 | US
 2020-07-17 | US
--插入数据
insert into hive.web.page_views values(timestamp '2020-07-17 23:00:15',bigint
'15141','www.local.com',date '2020-07-17','US' );
insert into hive.web.page_views values(timestamp '2020-07-18 23:00:15',bigint
```

```
'18148','www.local.com',date '2020-07-18','US' );

--查询数据
 select * from hive.web.page_views;
      view_time       | user_id |   page_url    |     ds     | country
------------------------|---------|---------------|------------|---------
 2020-07-17 23:00:15.000 |   15141 | www.local.com | 2020-07-17 | US
2020-07-18 23:00:15.000 |   18148 | www.local.com | 2020-07-18 | US
```

10.16.2.1.4 CREATE TABLE AS

语法

CREATE [EXTERNAL]① TABLE [IF NOT EXISTS] [catalog_name.][db_name.]table_name [(column_alias, ...)]

[[PARTITIONED BY ①(col_name, ...)] [SORT BY① ([*column* [, *column* ...])]]①

[COMMENT 'table_comment']

[WITH (property_name = expression [, ...])]②

[[STORED AS file_format]①

[LOCATION 'hdfs_path']①

[TBLPROPERTIES (orc_table_property = value [, ...])]]①

AS query

[WITH [NO] DATA]②

限制

① 和 ②的语法不能组合使用。

当使用了 avro_schema_url 属性时，以下操作是不支持的：

- 不支持 CREATE TABLE AS 操作
- 使用 CREATE TABLE 时不支持 partitioned_by 和 bucketed_by
- 不支持使用 alter table 修改 column

描述

创建包含 SELECT 查询结果的新表。

使用 CREATE TABLE 创建空表。

使用 IF NOT EXISTS 子句时，如果表已经存在则不会报错。

可选 WITH 子句可用于设置新创建的表的属性，如表的存储位置（location）、是不是外表（external）等。

示例

- 用指定列的查询结果创建新表 orders_column_aliased：

```
CREATE TABLE orders_column_aliased (order_date, total_price)
AS
SELECT orderdate, totalprice FROM orders;
```

- 用表 orders 的汇总结果新建一个表 orders_by_data：

```
CREATE TABLE orders_by_date
COMMENT 'Summary of orders by date'
WITH (format = 'ORC')
AS
SELECT orderdate, sum(totalprice) AS price
FROM orders
GROUP BY orderdate;
```

- 如果表 orders_by_date 不存在，则创建表 orders_by_date：

```
CREATE TABLE IF NOT EXISTS orders_by_date AS
SELECT orderdate, sum(totalprice) AS price
FROM orders
GROUP BY orderdate;
```

- 用和表 orders 具有相同 schema 创建新表 empty_orders table，但是没数据：

```
CREATE TABLE empty_orders AS
SELECT *
FROM orders
WITH NO DATA;
```

- 使用 VALUES 创建表，参考 10.16.2.1.22 VALUES。
- 分区表示例:

```
CREATE EXTERNAL TABLE hetu_copy(corderkey, corderstatus, ctotalprice,
corderdate, cds)
 PARTITIONED BY(cds)
 SORT BY (corderkey, corderstatus)
 COMMENT 'test'
 STORED AS orc
 LOCATION '/user/hetuserver/tmp'
 TBLPROPERTIES (orc_bloom_filter_fpp = 0.3, orc_compress = 'SNAPPY',
orc_compress_size = 6710422, orc_bloom_filter_columns =
'corderstatus,ctotalprice')
 as select * from hetu_test;

 CREATE TABLE hetu copy1(corderkey, corderstatus, ctotalprice, corderdate, cds)
 WITH (partitioned by = ARRAY['cds'], bucketed by = ARRAY['corderkey',
'corderstatus'],
 sorted by = ARRAY['corderkey', 'corderstatus'],
 bucket count = 16,
 orc compress = 'SNAPPY',
 orc compress size = 6710422,
 orc_bloom_filter_columns = ARRAY['corderstatus', 'ctotalprice'],
 external = true,
 format = 'orc',
 location = '/user/hetuserver/tmp ')
  as select * from hetu_test;
```

10.16.2.1.5 CREATE TABLE LIKE

语法

```
CREATE TABLE [ IF NOT EXISTS] table_name ( { coulumn_name    data_type
[ COMMENT comment] [ WITH    (property_name = expression [,…] ) ]    | LIKE
existing_table_name [ {INCLUDING| EXCLUDING} PROPERTIES] } ) [,…] [ COMMENT
table_comment] [WITH (property_name = expression [,…  ] ) ]
```

描述

使用 LIKE 子句可以在一个新表中包含一个已存在的表所有的列定义。可以使用多个 LIKE 来复制多个表的列。

如果使用了 INCLUDING PROPERTIES，表的所有属性也会被复制到新表，该选项最多只能对一个表生效。

对于从表中复制过来的属性，可以使用 WITH 子句指定属性名进行修改。

默认使用 EXCLUDING PROPERTIES 属性。

对于带分区的表，如果用括号包裹 like 子句，复制的列定义不会包含分区键的信息。

示例

- 创建基础表 order01 和 order02

```
CREATE TABLE order01(id int,name string,tel string) ROW FORMAT DELIMITED FIELDS
TERMINATED BY '\t' LINES TERMINATED BY '\n'STORED AS TEXTFILE;
CREATE TABLE order02(sku int, sku_name string, sku_describe string);
```

- 创建表 orders_like01，它将包含表 order01 定义的列及表属性

```
CREATE TABLE orders_like01 like order01 INCLUDING PROPERTIES;
```

- 创建表 orders_like02，它将包含表 order02 定义的列，并将表的存储格式设置为‘TEXTFILE’

```
CREATE TABLE orders_like02 like order02 STORED AS TEXTFILE;
```

- 创建表 orders_like03，它将包含表 order01 定义的列及表属性，order02 定义的列，以及额外的列 c1 和 c2

```
CREATE TABLE orders_like03 (c1 int,c2 float,LIKE order01 INCLUDING
PROPERTIES,LIKE order02);
```

- 创建表 orders_like04 和 orders_like05，它们都会包含同一个表 order_partition 的定义，但 orders_like04 不会包含分区键信息，而 orders_like05 会包含分区键的信息

```
CREATE TABLE order_partition(id int,name string,tel string) PARTITIONED BY (sku
int);
CREATE TABLE orders_like04 (like order_partition);
CREATE TABLE orders_like05 like order_partition;
DESC orders_like04;
 Column |  Type   | Extra | Comment
--------|---------|-------|---------
 id     | integer |       |
 name   | varchar |       |
 tel    | varchar |       |
 sku    | integer |       |
```

```
(4 rows)

DESC orders_like05;

 Column |  Type   |    Extra     | Comment
--------|---------|--------------|---------
 id     | integer |              |
 name   | varchar |              |
 tel    | varchar |              |
 sku    | integer | partition key |
(4 rows)
```

10.16.2.1.6 CREATE VIEW

语法

CREATE [OR REPLACE] VIEW view_name [(column_name [COMMENT 'column_comment'][, ...])] [COMMENT 'view_comment'] [TBLPROPERTIES (property_name = property_value)] AS query

限制

仅 Hive 数据源的 Catalog 支持视图的列描述。

在 HetuEngine 中创建的视图，视图的定义以编码方式存储在数据源里。在数据源可以查询到该视图，但无法对该视图执行操作。

视图是只读的，不可对它执行 LOAD、INSERT 操作。

视图可以包含 ORDER BY 和 LIMIT 子句，如果关联了该视图的查询语句也包含了这些子句，那么查询语句中的 ORDER BY 和 LIMIT 子句将以视图的结果为基础进行运算。

描述

使用 SELECT 查询结果创建新视图。视图是一个逻辑表，可以被将来的查询所引用，视图中没有数据。该视图对应的查询在每次被其他查询引用该视图时都会被执行。

如果视图已经存在，则可选 ORREPLACE 子句将导致视图被替换，而不会报错。

示例

- 通过表 orders 创建一个视图 test：

```
CREATE VIEW test (oderkey comment 'orderId',orderstatus comment 'status',half comment 'half') AS
SELECT orderkey, orderstatus, totalprice / 2 AS half FROM orders;
```

- 通过表 orders 的汇总结果创建视图 orders_by_date：

```
CREATE VIEW orders_by_date AS
SELECT orderdate, sum(totalprice) AS price
FROM orders
GROUP BY orderdate;
```

- 创建一个新视图来替换已经存在的视图：

```
CREATE OR REPLACE VIEW test AS
SELECT orderkey, orderstatus, totalprice / 4 AS quarter
FROM orders
```

- 创建一个视图的同时设置表属性：

```
create or replace view  view1 comment 'the first view'
TBLPROPERTIES('format'='orc') as select * from fruit;
```

注意事项

当使用 alter 修改创建视图所依赖的表时，需要重新创建视图，否则再次查询视图会报错。

可以通过 alter table 来修改视图名：alter table orders_by_date　rename to obd;

10.16.2.1.7 CREATE FUNCTION

语法

CREATE FUNCTION qualified_function_name (

parameter_name parameter_type

[, ...]

)

RETURNS return_type

[COMMENT function_description]

[LANGUAGE [JAVA]]

[SPECIFIC specificName]

[DETERMINISTIC | NOT DETERMINISTIC]

[RETURNS NULL ON NULL INPUT | CALLED ON NULL INPUT]

[SYMBOL class_name]

[URI hdfs_path_to_jar]

描述

通过给定的定义创建一个新的函数。

- 每一个函数都由其限定函数名称和参数类型列表唯一标识。“qualified_function_name”的格式需要为“catalog.schema.function_name”，函数命名空间（格式为“catalog.schema”）可以自行规划管理，与 HetuEngine 中的 catalog、schema 概念无关联；“parameter_type”需要为 HetuEngine 支持的数据类型。
- “return_type”需要为 HetuEngine 支持的数据类型，要与函数的返回实际类型匹配，不做类型强制转换。
- 可以指定一组特征来修饰函数并指定其行为，每个特征最多只能指定一次，详情请参考表 10-73。

表10-73 特征说明

特征	默认值	描述
Language clause	-	定义函数的语言。目前支持 JAVA 语言。 • JAVA 函数：需要提供函数实现的 JAR 文件，并将 JAR 文件放入 HetuEngine 可以读取的 HDFS 中。
Deterministic characteristic	NOT DETERMINISTIC	函数是否确定性。 • DETERMINISTIC：如果函数在使用相同的输入集调用时总是返回相同的结果集，则该函数被视为确定性。 • NOT DETERMINISTIC：如果函数在使用相同的输入集调用时不返回相同的结果集，则该函数将被视为非确定性。
Null-call clause	CALLED ON NULL INPUT	函数的行为。 • RETURNS NULL ON NULL INPUT：当“NULL”作为函数参数时，返回“NULL”。 • CALLED ON NULL INPUT：当“NULL”作为函数参数时调用。
Symbol class_name	-	JAVA 函数使用，指定函数实现的限定类名。
Uri hdfs_path_to_jar	-	JAVA 函数使用，指定函数实现的 JAR 文件路径。

限制

- 权限控制仅使用基于用户组方式进行控制，详情如表 10-74。

表10-74 权限控制

操作	权限控制
CREATE	不控制权限
DROP	只有 owner 才有权限执行
SELECT	不控制权限
SHOW	不控制权限

示例

- 创建一个新的 JAVA 函数“example.default.add_two”（需要先构建和部署 UDF）

```
CREATE FUNCTION example.default.add_two (
 num integer
)
RETURNS integer
LANGUAGE JAVA
DETERMINISTIC
SYMBOL "com.example.functions.AddTwo"
URI "hdfs://hacluster/udfs/function-1.0.jar";

--执行函数
select hetu.default.add_two(2);
```

10.16.2.1.8 CREATE MATERIALIZED VIEW

语法

CREATE [OR REPLACE] MATERIALIZED VIEW [IF NOT EXISTS] view_name [COMMENT string] [WITH properties] AS query

描述

该语法是使用 SELECT 查询结果创建物化视图。物化视图是一个数据库对象，它包含了一个查询的结果，例如：它可以是远程数据的本地副本，单表查询或者多表 join 后查询的结果的行或列、行和列的子集，也可以是使用聚合函数的汇总表。

物化视图通常基于对数据表进行聚合和连接的查询结果创建。物化视图支持“查询重写”，这是一种优化技术，它将以原始表编写的用户查询转换为包括一个或多个物化视图的等效请求。

语法支持的属性包括：

- storage_table：指定存储表表名。
- need_auto_refresh： 管理计算实例时，预先创建维护实例后，可通过设置 need_auto_refresh 为 true，创建具备自动刷新能力的物化视图，它会自动创建并提交物化视图刷新任务，在此基础上，可对 refresh_duration，start_refresh_ahead_of_expiry,refresh_priority 等属性做进一步配置来调整自动刷新任务。
- mv _validity：物化视图生命周期。0 表示永久有效，最短为 1 分钟。need_auto_refresh 设置为 false 时，mv _validity 默认值为 0；设置为 true 时，默认值为 24 小时。
- refresh_duration：物化视图自动刷新任务的最长等待时间。默认为 5 分钟，取值范围为 1 分钟到 24 小时。若自动刷新任务的等待时间超过设定的最长等待时间，自动化任务界面对应的任务状态显示为"timeout"。
- start_refresh_ahead_of_expiry：基于 mv _validity 设置物化视图自动刷新任务的提交时间，表示达到物化生命周期的指定百分比时，提交自动刷新任务，默认值为 0.2，最小值为 0.05。
- refresh_priority：物化视图提交自动刷新任务的优先级。默认值为 3，最大值为 3，1 表示最高优先级。高优先级的任务会有更大机会先被执行。

示例

- 在 mv catalog 和数据存储的 catalog（示例中使用的数据存储的 catalog 为 Hive）中创建相同的 schema，并启用物化视图“查询重写”。

```
hetuengine:tpcds_2gb> set session materialized_view_rewrite_enabled=true;
hetuengine:tpcds_2gb> create schema mv.tpcds;
CREATE SCHEMA
hetuengine:tpcds_2gb> create schema hive.tpcds;
CREATE SCHEMA
```

- 创建表。

```
hetuengine:tpcds 2gb> create table t1 (id int, c1 varchar);
hetuengine:tpcds 2gb> Insert into t1 values (1,'abc'), (2,'abc2'), (3,'abc3'),
(4,'abc4'), (5,'abc5'),(6, 'abc6');
hetuengine:tpcds 2gb> create table tb a(a int ,b varchar, c varchar);
hetuengine:tpcds_2gb> create table tb_b(a int ,d varchar, e varchar);
```

- 在 mv catalog 的 tpcds schema 中创建名为“mv.tpcds.test”的视图。如果已存在具有此名称的物化视图，则将抛出错误信息。

```
hetuengine:tpcds_2gb> create materialized view mv.tpcds.test as select c1 from
t1 where id <7;
CREATE MATERIALIZED VIEW
```

- 在 mv catalog 和 tpcds schema 中创建具有指定列名的物化视图“mv.tpcds.test”。

```
hetuengine:tpcds_2gb> create materialized view mv.tpcds.test (a ,b) as select
c1, id from t1 where id<7;
CREATE MATERIALIZED VIEW
```

- 在 mv catalog 和 tpcds schema 中使用“**if not exists**”关键字创建物化视图。如果视图已存在，不会抛出错误信息。

```
hetuengine:tpcds_2gb> create materialized view if not exists mv.tpcds.test as
select c1, id from t1 where id<7;
CREATE MATERIALIZED VIEW
```

- 在 mv catalog 和 tpcds schema 中创建具有指定属性的物化视图。

```
hetuengine:tpcds 2gb> create materialized view mv.tpcds.test with
(storage table='mppdb.tpcds.test2',need auto refresh = true, mv validity =
'10m', start refresh ahead of expiry = 0.2, refresh priority = 1,
refresh duration = '5m') as select c1, id from t1 where id<7;
CREATE MATERIALIZED VIEW
```

- 创建带有注释的物化视图。

```
hetuengine:tpcds_2gb> create materialized view mv.tpcds.test comment
'test_comment' as select c1, id from t1 where id<7;
CREATE MATERIALIZED VIEW
```

注意事项

- 创建物化视图时，mv catalog 应存在。
- 创建物化视图之后，需要使用 refresh materialized view xxx 来填充物化视图的数据。
- 需要在 System 或者 Session 级别开启物化视图重写功能。
- 用于在 mv catalog 中创建视图的 schema，需要在用于数据存储的 catalog 和 mv catalog 中提前创建好。

- 不要删除用于存储的 catalog 中存在的物化视图数据表。
- 创建物化视图时，建议查询中不要包含 Order By。
- 创建物化视图时，查询语句不要包含子查询和子查询 join，若包含子查询和子查询 join 需使用 with 子查询代替。

  例如：

  ```
  hetuengine:tpcds_2gb> create materialized view mv.tpcds.test1 as select t1.a, b, d from ((select a, b, c from tb_a) as t1 join (select a, d, e from tb_b) as t2 on t1.a=t2.a);
  ```

  上述场景可用 with 语句代替：

  ```
  hetuengine:tpcds_2gb>
  create materialized view mv.tpcds.test1 as
  with t1 as (select a, b, c from tb_a),
  t2 as (select a, d, e from tb_b)select t1.a, b, d from t1 join t2 on t1.a = t2.a;
  ```

- 不支持查询部分物化视图的重写，这意味着当查询或子查询需要视图中的部分数据（物化视图的子集数据）时，查询将无法被转换为包含物化视图的等效请求。

  如使用“select id from test where id <100”创建物化视图 t1，若用户需要查询“select id from test where id <50”，则不会发生重写，因为查询试图使用物化视图的部分数据。
- 创建物化视图时表名必须是全限定名（catalogName.schemaName.tableName）或者表名。

  例如：

  ```
  hetuengine:tpcds 2gb> create materialized view mv.tpcds.test as select c1 from t1 where id <7;
  ```

  其中表名“t1”也可替换为全限定名“hive.tpcds_2gb.t1”，但不能为“tpcds_2gb.t1”。
- 物化视图的“查询重写”不支持全表扫描，SQL 查询没有使用 Where 子句，无法被查询重写。

  例如：表“hivetb1”的列定义包含了“id”、“name”、“age”三个列，如下 SQL 查询就无法被“查询重写”。

  ```
  Create MV SQL : select id,name,age from hivetb1;
  ```

10.16.2.1.9 ALTER MATERIALIZED VIEW STATUS

语法

ALTER MATERIALIZED VIEW qualifiedName SET STATUS <status>

描述

修改物化视图的状态，仅支持修改处于“ENABLED”和“SUSPEND”状态的物化视图，且只能修改为其中一种状态。物化视图所有状态包含如下：

- INIT: 物化视图第一次创建时的状态
- SUSPEND：暂停使用状态，暂停使用的物化视图不会参与改写
- ENABLED：可使用状态

- REFRESHING：正在刷新物化视图数据，不可用于改写
- DISABLED：关闭使用

示例

将“mv.default.mv1”的状态更新为“SUSPEND”。

```
alter materialized view mv.default.mv1 set status SUSPEND;
```

10.16.2.1.10 ALTER MATERIALIZED VIEW

语法

ALTER MATERIALIZED VIEW QUALIFIEDNAME SET PROPERTIES PROPERTY_NAME=PROPERTY_VALUE;

描述

修改物化视图的属性，相关属性可以参考 10.16.2.1.8 CREATE MATERIALIZED VIEW。

示例

将“mv.default.mv1mv.mvtestprop.pepa_ss”的物化视图提交自动刷新任务的优先级“PROPERTIES”属性更新为“refresh_priority = 2”。

```
Alter materialized view mv.mvtestprop.pepa_ss set PROPERTIES refresh_priority = 2;
```

10.16.2.1.11 ALTER TABLE

语法

说明

name，new_name，column_name，new_column_name，table_name_*为用户自定义参数。

1. 重命名一个表。

   ALTER TABLE name RENAME TO new_name

2. 修改表的列名，为列添加注释（可选项）和属性（可选项），可参考描述查看支持的列属性。

   ALTER TABLE name ADD COLUMN column_name data_type [COMMENT comment] [WITH (property_name = expression [, ...])]

3. 删除表中名为 column_name 的列。

   ALTER TABLE name DROP COLUMN column_name

须知

- 不支持删除分区列或者分桶列。
- DROP COLUMN 不支持 rctext、rcbinary、rcfile 格式存储的表。由于 connector 对不同文件格式的列访问模式不同，drop column 后可能会出现查询失败的情况，例如：
- 对于 orc 格式存储的非分区表 ，drop column 后如果查询失败，需要设置 Session 属性：

  set session hive.orc_use_column_names=true;
- 对于 parquet 格式存储的非分区表，drop column 后如果查询失败，需要设置 Session 属性：

  set session hive.parquet_use_column_names=true;
- 对于 orc 或 parquet 格式的分区表或事务表，drop column 后无法通过设置 Session 属性的方式来确保查询成功。

4. 将表中列名为 column_name 的列重命名为 new_column_name。

   ALTER TABLE name RENAME COLUMN column_name TO new_column_name

须知

不支持重命名分区列或者分桶列。

5. 分区表添加分区。

   ALTER TABLE name ADD [IF NOT EXISTS] PARTITION partition_spec [LOCATION 'location'][PARTITION partition_spec [LOCATION 'location'], ...];
6. 分区表删除分区。这个操作会从分区移除数据和元数据。无论表是 internal table 还是 external table，如果 ADD PARTITION 时指定了分区保存路径，那么在 DROP PARTITION 执行后，分区所在文件夹和数据不会被删除。如果 ADD PARTITION 时未指定分区保存路径，分区目录将从 HDFS 上删除，数据会移到.Trash/Current 文件夹。

   ALTER TABLE table_name DROP [IF EXISTS] PARTITION partition_spec[, PARTITION partition_spec, ...];

须知

对于外接 Hive 数据源的场景，分区键如果是定长字符串，如 char(5)，那么对应的数据如果字符串长度小于 5 位，则 drop partition 的操作就会失败。

7. 重命名分区。

   ALTER TABLE table_name PARTITION(partition_key = partition_value1) rename to partition(partition_key = partition_value2)
8. 将 table_name_1 的分区转移给 table_name_2。

   ALTER TABLE table_name_2 EXCHANGE PARTITION (partition_spec) WITH TABLE table_name_1;
9. 同时将 table_name_1 的多个分区转移给 table_name_2。

ALTER TABLE table_name_2 EXCHANGE PARTITION (partition_spec, partition_spec2, ...) WITH TABLE table_name_1;

10. 新增/修改表属性。

    ALTER TABLE table_name SET TBLPROPERTIES (property_name = property_value[, property_name = property_value, …]);

    说明

    TBLPROPERTIES 允许用户通过键值对的方式（属性名和属性都必须是单引号或双引号包裹的字符串），添加或修改连接器支持的表属性，以 Hive 连接器为例：

    - TBLPROPERTIES ("transactional"="true") ，可能的取值为[true,false]
    - TBLPROPERTIES ("auto.purge"="true") ，可能的取值为[true,false]

11. 修改表的列属性。

    ALTER TABLE table_name [PARTITION partition_spec] CHANGE [COLUMN] col_old_name col_new_name column_type [COMMENT col_comment] [FIRST|AFTER column_name] [CASCADE|RESTRICT]

须知

- 对一个已经存在的表，修改列名、数据类型、注释、位置（[FIRST|AFTER column_name] 用于指定列被修改后出现的位置）或者以上任意组合。如果语法中包含了分区子句，那么相应分区的元数据也会一起变动。CASCADE 模式会让语法对表和表分区的元数据产生作用，而默认的模式为 RESTRICT，对列的修改，仅对表的元数据产生作用。
- 列修改命令只能修改表/分区的元数据，而不会修改数据本身。用户应确保表/分区的实际数据布局符合元数据定义。
- 不支持更改表的分区列/桶列，也不支持更改 ORC 表。

12. 修改表或分区的存储位置。

    ALTER TABLE table_name [PARTITION partition_spec] SET LOCATION location;

    说明

    - 可以使用 ALTER TABLE [PARTITION] SET 位置设置表的表或分区位置。
    - 在 Set location 命令之后，表/分区数据可能不会显示。
    - Set location 在创建表/分区目录时会使用给定目录路径，而不是 hive 在创建表/分区时创建的默认路径。
    - 该语句不会对表或分区原有数据产生影响，也不会修改原有的表或分区目录，但是新增的数据，都会保存到新指定的目录下。

13. 修改表或分区的数据文件保存格式。

    ALTER TABLE table_name [PARTITION partition_spec] SET FILEFORMAT file_format;

    说明

    - 该操作仅会改变表或分区的元数据，对存量数据文件的文件类型变更，SQL 层面无法操作，只能在外部进行操作。
    - 支持的文件格式包括：AVRO、PARQUET、ORC、RCFILE、TEXTFILE 和 SEQUENCEFILE。

14. 修改表的存储属性，用于修改表的物理存储属性。

    ALTER TABLE table_name CLUSTERED BY (col_name, col_name, ...) [SORTED BY (col_name, ...)] INTO num_buckets BUCKETS;

限制

- EXCHANGE PARTITION：
  - 被迁移的单个或多个分区，迁移前必须都是已存在的分区，并归属于来源表，且在目标表中不包含这些分区；
  - 该操作涉及的表需要有相同的列定义，并且有相同的分区键；
  - 如果表中包含索引，该操作会失败；
  - 来源表和目标表中任意一个为事务表时，不允许 Exchange partition 操作；
  - 对于目标表，在一次操作中，多个分区要么同时迁移成功，要么全部失败。对于来源表，操作成功后，所有迁移的分区都会被释放；
  - Alter table change column 不支持 orc 格式的表。
- ALTER TABLE table_name ADD | DROP col_name 命令仅对于 ORC/PARQUET 存储格式的非分区表可用。

示例

- 将表名从 users 修改为 people：

  ALTER TABLE *users* **RENAME TO** *people*;
- 在表 users 中增加名为 zip 的列：

  ALTER TABLE *users* **ADD COLUMN** *zip* **varchar;**
- 从表 users 中删除名为 zip 的列：

  ALTER TABLE *users* **DROP COLUMN** *zip*;
- 将表 users 中列名 id 更改为 user_id：

  ALTER TABLE *users* **RENAME COLUMN id TO** *user_id*;
- 修改分区操作：

```
--创建两个分区表
CREATE TABLE IF NOT EXISTS hetu_int_table5 (eid int, name String, salary String,
destination String, dept String, yoj int) COMMENT 'Employee Names' partitioned
by (dt timestamp,country String, year int, bonus decimal(10,3)) STORED AS
TEXTFILE;

CREATE TABLE IF NOT EXISTS hetu_int_table6 (eid int, name String, salary String,
destination String, dept String, yoj int) COMMENT 'Employee Names' partitioned
by (dt timestamp,country String, year int, bonus decimal(10,3)) STORED AS
TEXTFILE;

--添加分区
ALTER TABLE hetu_int_table5 ADD IF NOT EXISTS PARTITION (dt='2008-08-08
10:20:30.0', country='IN', year=2001, bonus=500.23) PARTITION (dt='2008-08-09
10:20:30.0', country='IN', year=2001, bonus=100.50) ;

--查看分区
show partitions hetu_int_table5;
         dt          | country | year |  bonus
```

```
-------------------------|---------|------|---------
 2008-08-09 10:20:30.000 | IN      | 2001 | 100.500
 2008-08-08 10:20:30.000 | IN      | 2001 | 500.230
(2 rows)

--删除分区
ALTER TABLE hetu_int_table5 DROP IF EXISTS PARTITION (dt=timestamp '2008-08-08
10:20:30.0', country='IN', year=2001, bonus=500.23);

--查看分区
show partitions hetu_int_table5;
          dt           | country | year |  bonus
-------------------------|---------|------|---------
 2008-08-09 10:20:30.000 | IN      | 2001 | 100.500
(1 row)

--迁移分区示例
CREATE SCHEMA part_test;
CREATE TABLE hetu_exchange_partition1 (a string, b string) PARTITIONED BY (ds
string);
CREATE TABLE part_test.hetu_exchange_partition2 (a string, b string)
PARTITIONED BY (ds string);
ALTER TABLE hetu exchange partition1 ADD PARTITION (ds='1');

--查看分区
 show partitions hetu_exchange_partition1;
 ds
----
 1
(1 row)

show partitions part_test.hetu_exchange_partition2;
 ds
----
(0 rows)

--迁移分区，从 T1 到 T2
ALTER TABLE part_test.hetu_exchange_partition2 EXCHANGE PARTITION (ds='1') WITH
TABLE hetu_exchange_partition1;

--再次查看分区，可以看到分区迁移成功
show partitions hetu_exchange_partition1;
 ds
----
 (0 row)

show partitions part_test.hetu_exchange_partition2;
 ds
----
1
(1 rows)

--重命名分区
CREATE TABLE IF NOT EXISTS hetu_rename_table ( eid int, name String, salary
String, destination String, dept String, yoj int)
```

```
COMMENT 'Employee details'
partitioned by (year int)
STORED AS TEXTFILE;

ALTER TABLE hetu_rename_table ADD IF NOT EXISTS PARTITION (year=2001);

SHOW PARTITIONS hetu_rename_table;
year
------
 2001
(1 row)

ALTER TABLE hetu_rename_table PARTITION (year=2001) rename to partition
(year=2020);

SHOW PARTITIONS hetu_rename_table;
year
------
 2020
(1 row)

--修改分区表
create table altercolumn4(a integer, b string) partitioned by (c integer);

--修改表的文件格式
alter table altercolumn4 SET FILEFORMAT textfile;

insert into altercolumn4 values (100, 'Daya', 500);

alter table altercolumn4 partition (c=500) change column b empname string
comment 'changed column name to empname' first;

--修改分区表的存储位置（需要先在 hdfs 上创建目录，执行语句后，无法查到之前插入的那条数据）
alter table altercolumn4 partition (c=500) set Location
'/user/hive/warehouse/c500';

--修改列 b 改名为 name，同时类型从 integer 转为 string
create table altercolumn1(a integer, b integer) stored as textfile;

alter table altercolumn1 change column b name string;

--修改 altercolumn1 的存储属性
ALTER TABLE altercolumn1 CLUSTERED BY(a, name) SORTED BY(name) INTO 25 BUCKETS;

--查看 altercolumn1 的属性
describe formatted altercolumn1;
                          Describe Formatted Table
--------------------------------------------------------------------------------
---------
 # col_name     data_type     comment
 a     integer
 name     varchar

 # Detailed Table Information
 Database:               default
```

```
 Owner:                  admintest
 LastAccessTime:           0
 Location:               hdfs://hacluster/user/hive/warehouse/altercolumn1
 Table Type:             MANAGED_TABLE

 # Table Parameters:
       STATS_GENERATED_VIA_STATS_TASK  workaround for potential lack of HIVE-
12730
       numFiles             0
       numRows              0
       orc.compress.size      262144
       orc.compression.codec   GZIP
       orc.row.index.stride    10000
       orc.stripe.size        67108864
       presto_query_id        20210325_025238_00034_f63xj@default@HetuEngine
       presto_version
       rawDataSize           0
       totalSize             0
       transient_lastDdlTime   1616640758

 # Storage Information
 SerDe Library:           org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
 InputFormat:             org.apache.hadoop.mapred.TextInputFormat
 OutputFormat:
org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
 Compressed:              No
 Num Buckets:             25
 Bucket Columns:           [a, name]
 Sort Columns:            [SortingColumn{columnName=name, order=ASCENDING}]
 Storage Desc Params:
       serialization.format    1
(1 row)

Query 20210325_090522_00091_f63xj@default@HetuEngine, FINISHED, 1 node
Splits: 1 total, 1 done (100.00%)
0:00 [0 rows, 0B] [0 rows/s, 0B/s]
```

10.16.2.1.12 ALTER VIEW

语法

- ALTER VIEW view_name AS select_statement;
- ALTER VIEW view_name SET TBLPROPERTIES table_properties;

描述

“ALTER VIEW view_name AS select_statement;”用于改变已存在的视图的定义，语法效果与 CREATE OR REPLACE VIEW 类似。

“ALTER VIEW view_name SET TBLPROPERTIES table_properties;”中 table_properties 格式为 (property_name = property_value, property_name = property_value, ...)。

视图可以包含 Limit 和 ORDER BY 子句，如果关联视图的查询语句也包含了这类子句，则最后执行结果将根据视图的子句运算后得到。例如视图 V 指定了返回 5 条数据，而关联查询为 select * from V limit 10，则最终只有 5 条数据返回。

限制

以上两种语法不可混用。

当视图包含分区，那么将无法通过这个语法来改变定义。

示例

```
CREATE OR REPLACE VIEW tv_view as SELECT id,name from (values (1, 'HetuEngine')) as
x(id,name);

SELECT * FROM tv_view;
 id | name
----|------
  1 | HetuEngine
(1 row)

ALTER VIEW tv_view as SELECT id, brand FROM (VALUES (1, 'brand_1', 100), (2,
'brand_2', 300) ) AS x (id, brand, price);

SELECT * FROM tv_view;
 id |  brand
----|---------
  1 | brand 1
  2 | brand 2
(2 rows)

ALTER VIEW tv_view SET TBLPROPERTIES ('comment' = 'This is a new comment');

show tblproperties tv_view;
                      SHOW TBLPROPERTIES
-------------------------------------------------------------------------
       comment              'This is a new comment'
       presto_query_id       '20210325_034712_00040_f63xj@default@HetuEngine'
       presto_version
       presto_view           'true'
       transient_lastDdlTime   '1616644032'
(1 row)
```

10.16.2.1.13 ALTER SCHEMA

语法

ALTER (DATABASE|SCHEMA) schema_name SET LOCATION hdfs_location

ALTER (DATABASE|SCHEMA) database_name SET OWNER USER username

ALTER (DATABASE|SCHEMA) database_name SET DBPROPERTIES (property_name=property_value, ...);

描述

这条命令并不会将 SCHEMA 当前的内容移动到修改后的路径下，也不会修改与指定 schema 关联的表或分区，它只会修改新添加进数据库的表的上级目录。

示例

```
Create schema foo;
--修改 schema 存储路径
ALTER SCHEMA foo SET LOCATION 'hdfs://hacluster/newlocation';
--修改 schema 的所有者
ALTER SCHEMA foo SET OWNER user admin;
```

10.16.2.1.14 DROP SCHEMA

语法

DROP (DATABASE|SCHEMA) [IF EXISTS] databasename [RESTRICT|CASCADE]

描述

DATABASE 和 SCHEMA 在概念上是等价可互换的。

该语法用于删除数据库 databasename，如果目标数据库不存在，将抛出错误提示，但如果使用了 IF EXISTS 子句则不会抛出错误提示。

可选参数 RESTRICT|CASCADE 用于指定删除的模式，默认是 RESTRICT 模式，在这种模式下，数据库必须为空，不包含任何表才能删除，如果是 CASCADE 模式，表示级联删除，会先删除数据库下面的表 ，再删除数据库。

示例

- 删除 schema web：

  ```
  DROP SCHEMA web;
  ```

- 如果 schema sales 存在，删除该 schema：

  ```
  DROP SCHEMA IF EXISTS sales;
  ```

- 级联删除 schema test_drop，schema test_drop 中存在表 tb_web，会先删除 tb_web，再删除 test_drop：

  ```
  CREATE SCHEMA test_drop;

  USE test_drop;

  CREATE TABLE tb_web(col1 int);

  DROP DATABASE test_drop CASCADE;
  ```

10.16.2.1.15 DROP TABLE

语法

DROP TABLE [IF EXISTS] table_name

描述

删除存在的表，可选参数 IF EXISTS 指定时，如果删除的表不存在，则不会报错。被删除的数据行将被移动到 HDFS 的回收站。

示例

```
create table testfordrop(name varchar);
drop table if exists testfordrop;
```

10.16.2.1.16 DROP VIEW

语法

DROP VIEW [IF EXISTS] view_name

描述

删除存在的视图，可选参数 IF EXISTS 指定时，如果删除的视图不存在，则不会报错。

示例

- 创建视图

  ```
  create view orders_by_date as select * from orders;
  ```

- 删除视图 orders_by_date，如果视图不存在则会报错

  ```
  DROP VIEW orders_by_date;
  ```

- 删除视图 orders_by_date，使用参数 IF EXISTS，如果视图存在则删除视图，如果视图不存在，也不会报错

  ```
  DROP VIEW IF EXISTS orders_by_date;
  ```

10.16.2.1.17 DROP FUNCTION

语法

DROP FUNCTION [IF EXISTS] qualified_function_name

描述

删除与给定函数名称匹配的现有函数。如果不存在匹配的函数，可选的“IF EXISTS”子句会导致“NOT_FOUND”错误被抑制。

示例

- 删除函数“example.namespace01.date_diff”

  DROP FUNCTION example.namespace01.date_diff

- 如果函数“example.namespace01.date_diff”存在，则删除

  DROP FUNCTION IF EXISTS example.namespace01.date_diff

10.16.2.1.18 DROP MATERIALIZED VIEW

语法

DROP MATERIALIZED VIEW [IF EXISTS] view_name

描述

用于删除现有的物化视图。若删除的视图不存在，且指定了可选参数 if exists，则不会抛出错误信息。

删除物化视图将导致删除与指定视图关联的元数据和表数据。

说明

如果在删除物化视图之前部分数据被删除（元数据或表数据），则删除物化视图将失败。

示例

- 创建表。

```
hetuengine:tpcds_2gb> create table t1 (id int, c1 varchar);
hetuengine:tpcds_2gb> Insert into t1 values (1,'abc'), (2,'abc2'), (3,'abc3'), (4,'abc4'), (5,'abc5'), (6,'abc6');
```

- 创建物化视图。

```
hetuengine:tpcds_2gb> create materialized view mv.tpcds.t1 as select c1 from t1 where id <7;
```

- 删除物化视图，如果视图不存在，则报错。

```
hetuengine:tpcds_2gb> drop materialized view mv.tpcds.t1;
Query 20211206_095415_00003_k4wwu failed: line 1:1: MATERIALIZED VIEW 'mv.tpcds.t1' does not exist
```

- 删除物化视图，并使用 if exists 参数，如果视图存在，则将删除该视图；如果视图不存在，则不会报错。

```
hetuengine:tpcds_2gb> drop materialized view if exists mv.tpcds.t1;
DROP MATERIALIZED VIEW
```

10.16.2.1.19 REFRESH MATERIALIZED VIEW

语法

REFRESH MATERIALIZED VIEW materialized_view_name

描述

用于更新物化视图的数据。

示例

```
hetuengine:tpcds_orc_hive_2> refresh materialized view mv.tpcds.test;
REFRESH MATERIALIZED VIEW: 10 rows
```

10.16.2.1.20 TRUNCATE TABLE

语法

TRUNCATE [TABLE] table_name [PARTITION partition_spec];

partition_spec:

: (partition_column = partition_col_value, partition_column = partition_col_value, ...)

描述

从表或分区中移除所有行。用户可以通过 partition_spec 一次性删除分区表的多个分区，如果不指定就一次清除分区表的所有分区。当表属性“auto.purge”采用默认值“false”时，被删除的数据行将保存到文件系统的回收站，否则，当“auto.purge”设置为“true”时，数据行将被直接删除。

限制

目标表必须是管控表（表属性 external=false），否则执行语句将报错。

示例

```
-- 删除原生/管控表
Create table simple(id int, name string);

Insert into simple values(1,'abc'),(2,'def');

select * from simple;
 id | name
----|------
  1 | abc
  2 | def
(2 rows)

Truncate table simple;

select * from simple;
 id | name
----|------
(0 rows)

--删除表分区
Create table tb_truncate_part (id int, name string) partitioned by (age int, state
string);

Insert into tb_truncate_part values
(1,'abc',10,'ap'),(2,'abc',10,'up'),(3,'abc',20,'ap'),(4,'abc',20,'up');

select * from tb_truncate_part;
 id | name | age | state
----|------|-----|-------
  2 | abc  |  10 | up
  3 | abc  |  20 | ap
  1 | abc  |  10 | ap
  4 | abc  |  20 | up
(4 rows

Truncate table tb_truncate_part partition (state = 'ap', age = 10);

select * from tb_truncate_part;
id | name | age | state
----|------|-----|-------
  4 | abc  |  20 | up
```

```
 2 | abc  |  10 | up
 3 | abc  |  20 | ap
(3 rows)
```

10.16.2.1.21 COMMENT

语法

COMMENT ON TABLE name IS 'comments'

描述

设置表的注释信息，可以通过设置注释信息为 NULL 来删除注释。

示例

修改表 users 的注释为“master table”，表的注释语句可以通过 show create table tablename 语句查看：

```
COMMENT ON TABLE users IS 'master table';
```

10.16.2.1.22 VALUES

语法

VALUES row [, ...]

where row is a single expression or

(column_expression [, ...])

描述

VALUES 用于查询可以使用的任何地方（例如 SELECT、INSERT 的 FROM 子句）。VALUES 用于创建了一个没有列名的匿名表，但是表和列可以使用具有列别名的 AS 子句命名。

示例

- 返回一个 1 列 3 行的表：

  ```
  VALUES 1, 2, 3
  ```

- 返回一个 2 列 3 行的表：

  ```
  VALUES
  (1, 'a'),
  (2, 'b'),
  (3, 'c')
  ```

- 返回具有列名 id、name 的表：

  ```
  SELECT * FROM (values (1, 'a'), (2, 'b'),(3, 'c')) AS t (id, name);
  ```

- 创建一个具有列名 id、name 的新表：

  ```
  CREATE TABLE example AS
   SELECT * FROM (VALUES (1, 'a'), (2, 'b'), (3, 'c')) AS t (id, name);
  ```

10.16.2.1.23 SHOW 语法使用概要

SHOW 语法主要用来查看数据库对象的相关信息，其中 LIKE 子句用来对数据库对象过滤，匹配规则如下，具体示例可参看 SHOW TABLES：

规则 1：_可以用来匹配单个任意字符。

规则 2：%可以用来匹配 0 个或者任意个任意字符。

规则 3：* 可以用来匹配 0 个或者任意个任意字符。

规则 4：|可以用来配置多种规则，规则之间用“|”分隔。

规则 5：当想将“_”作为匹配条件时，可以使用 ESCAPE 指定一个转义字符，对“_”进行转义，以免按照规则 1 对“_”进行解析。

10.16.2.1.24 SHOW CATALOGS

语法

SHOW CATALOGS [LIKE pattern [ESCAPE escapeChar]]

描述

这个表达式用于列出可用的 catalogs。可选参数 like 被用于基于关键字来进行匹配。

示例

- 列出所有 catalogs：

```
SHOW CATALOGS;
```

- 列出所有名字前缀为 sys 的 catalogs：

```
SHOW CATALOGS LIKE 'sys%';
```

10.16.2.1.25 SHOW SCHEMAS（DATABASES）

语法

SHOW SCHEMAS|DATABASES [(FROM| IN) catalog] [LIKE pattern [ESCAPE escapeChar]]

描述

该语法中 DATABASES 和 SCHEMAS 在概念上是等价的，是可互换的，该语法用于例举所有 metastore 中定义的 schemas。可选子句 LIKE 可以使用规则运算来过滤结果，它支持的通配符为“*”（匹配任意字符）和“|”(匹配可选项)。

示例

列出当前 catalog 所有的 schemas：

```
SHOW SCHEMAS;
```

列出指定 catalog 下的 schema_name 前缀为 " t " 的所有 schemas：

```
SHOW SCHEMAS FROM hive LIKE 't%';

--等价写法:
SHOW SCHEMAS IN hive LIKE 't%';
```

如果匹配字符串中有字符与通配符冲突，可以指定转义字符来标识，示例为查询 hive 这个 catalog 下，schema_name 前缀为“pm_”的所有 schema，转义字符为“/”：

```
SHOW SCHEMAS IN hive LIKE 'pm/_%' ESCAPE '/';
```

10.16.2.1.26 SHOW TABLES

语法

SHOW TABLES [(FROM | IN) schema] [LIKE pattern [ESCAPE escapeChar]]

描述

这个表达式用于列出指定 schema 下的所有表。如果没有指定 schema，则默认使用当前所在的 schema。

可选参数 like 被用于基于关键字来进行匹配。

示例

```
--创建测试表
Create table show_table1(a int);
Create table show_table2(a int);
Create table showtable5(a int);
Create table intable(a int);
Create table fromtable(a int);

--匹配单字符'_'
show tables in  default like 'show_table_';
  Table
-------------
 show_table1
 show_table2
(2 rows)

--匹配多字符'*', '%'
show tables in default like 'show%';
Table
-------------
 show_table1
 show_table2
 showtable5
(3 rows)

show tables in default like 'show*';
Table
-------------
 show_table1
 show_table2
 showtable5
```

```
(3 rows)

--转义字符使用,第二个示例将'_'作为过滤条件，结果集不包含 showtable5
show tables in default like 'show_%';
   Table
-------------
 show_table1
 show_table2
 showtable5
(3 rows)

show tables in default like 'show$_%' ESCAPE '$';
   Table
-------------
 show_table1
 show_table2
(2 rows)

--同时满足多个条件，查询 default 中'show_'开头或者'in'开头的表
show tables in default like 'show$_%|in%' ESCAPE '$';
   Table
-------------
 intable
 show_table1
 show_table2
(3 rows)
```

10.16.2.1.27 SHOW TBLPROPERTIES TABLE | VIEW

语法

SHOW TBLPROPERTIES table_name|view_name[(property_name)]

描述

如果不指定属性的关键词，该语句将返回所有的表属性，否则返回给定关键词的属性值。

示例

```
--查看 show_table1 的所有表属性
                        SHOW TBLPROPERTIES
-------------------------------------------------------------------------------
       STATS_GENERATED_VIA_STATS_TASK  'workaround for potential lack of HIVE-12730'
       auto.purge            'false'
       numFiles              '0'
       numRows               '0'
       orc.compress.size      '262144'
       orc.compression.codec   'GZIP'
       orc.row.index.stride    '10000'
       orc.stripe.size        '67108864'
       presto_query_id        '20230909_095107_00042_2hwbg@default@HetuEngine'
       presto_version         '399'
       rawDataSize           '0'
       totalSize             '0'
```

```
      transient_lastDdlTime   '1694253067'

(1 row)

--查看 show_table1 的压缩算法
SHOW TBLPROPERTIES show_table1('orc.compression.codec');
SHOW TBLPROPERTIES
---------------------
 GZIP
(1 row)
```

10.16.2.1.28 SHOW TABLE/PARTITION EXTENDED

语法

SHOW TABLE EXTENDED [IN | FROM schema_name] LIKE 'identifier_with_wildcards' [PARTITION (partition_spec)]

描述

用于展示表或分区的详细信息。

可以使用规则运算表达式来同时匹配多个表，但不可用于匹配分区。

展示的信息将包括表的基本信息和相关的文件系统信息，其中文件系统信息包括总文件数、总文件大小、最大文件长度、最小文件长度、最后访问时间以及最后更新时间。如果指定了分区，将给出指定分区的文件系统信息，而不是分区所在表的文件系统信息。

参数说明

- IN | FROM schema_name
  指定 schema 名称，未指定时默认使用当前的 schema。
- LIKE 'identifier_with_wildcards'
  identifier_with_wildcards 只支持包含“*”和“|”的规则匹配表达式。
  其中“*”可以匹配单个或多个字符，“|”适用于匹配多种规则匹配表达式中的任意一种的情况，它用于分隔这些规则匹配表达式。
  规则匹配表达式首尾的空格，不会参与匹配计算。
- partition_spec
  一个可选参数，使用键值对来指定分区列表，键值对之间通过逗号分隔。需要注意，指定分区时，表名不支持模糊匹配。

示例

```
-- 演示数据准备
create schema show_schema;

use show_schema;

create table show_table1(a int,b string);
create table show_table2(a int,b string);
create table from_table1(a int,b string);
```

```
create table in_table1(a int,b string);

--查询表名以"show"开始的表的详细信息
show table extended  like 'show*';
                           tab_name
--------------------------------------------------------------------------------
 tableName:show_table1
 owner:admintest
 location:hdfs://hacluster/user/hive/warehouse/show_schema.db/show_table1
 InputFormat:org.apache.hadoop.hive.ql.io.orc.OrcInputFormat
 OutputFormat:org.apache.hadoop.hive.ql.io.orc.OrcOutputFormat
 columns:struct columns {int a,string b}
 partitioned:false
 partitionColumns:
 totalNumberFiles:0
 totalFileSize:0

 tableName:show_table2
 owner:admintest
 location:hdfs://hacluster/user/hive/warehouse/show_schema.db/show_table2
 InputFormat:org.apache.hadoop.hive.ql.io.orc.OrcInputFormat
 OutputFormat:org.apache.hadoop.hive.ql.io.orc.OrcOutputFormat
 columns:struct columns {int a,string b}
 partitioned:false
 partitionColumns:
 totalNumberFiles:0
 totalFileSize:0

(1 row)

-- 查询表名以"from"或者"show"开头的表的详细信息
 show table extended  like 'from*|show*';
                          tab_name
--------------------------------------------------------------------------------
 tableName          show_table1
 owner             admintest
 location           hdfs://hacluster/user/hive/warehouse/show_table1
 InputFormat        org.apache.hadoop.hive.ql.io.orc.OrcInputFormat
 OutputFormat       org.apache.hadoop.hive.ql.io.orc.OrcOutputFormat
 columns           struct columns {int a,string b}
 partitioned        false
 partitionColumns
 totalNumberFiles    0
 totalFileSize      null

 tableName          from_table1
 owner             admintest
 location           hdfs://hacluster/user/hive/warehouse/from_table1
 InputFormat        org.apache.hadoop.hive.ql.io.orc.OrcInputFormat
 OutputFormat       org.apache.hadoop.hive.ql.io.orc.OrcOutputFormat
 columns           struct columns {int a,string b}
 partitioned        false
 partitionColumns
 totalNumberFiles    0
 totalFileSize      null
```

```
tableName          show_table2
owner              admintest
location           hdfs://hacluster/user/hive/warehouse/show_table2
InputFormat        org.apache.hadoop.hive.ql.io.orc.OrcInputFormat
OutputFormat       org.apache.hadoop.hive.ql.io.orc.OrcOutputFormat
columns            struct columns {int a,string b}
partitioned        false
partitionColumns
totalNumberFiles    0
totalFileSize       null

(1 row)
-- 查询 web schema 下的 page_views 表扩展信息
 show table extended from web like 'page*';
                            tab_name
--------------------------------------------------------------------------------
 tableName:page_views
 owner:admintest
 location:hdfs://hacluster/user/web.db/page_views
 InputFormat:org.apache.hadoop.hive.ql.io.orc.OrcInputFormat
 OutputFormat:org.apache.hadoop.hive.ql.io.orc.OrcOutputFormat
 columns:struct columns {timestamp view_time,bigint user_id,string page_url}
 partitioned:true
 partitionColumns: struct partition columns {date ds,string country}
 totalNumberFiles:0
 totalFileSize:0

(1 row)
```

10.16.2.1.29 SHOW STATS

语法

SHOW STATS FOR table_name;

SHOW STATS FOR (SELECT * FROM table [WHERE condition]);

限制

SHOW STATS 首先会 ANALYZE 表，参考 10.16.2.5.14 ANALYZE。在 ANALYZE 之前对目标表进行 show stats 会显示所有的值都是空值。

描述

返回表的近似统计信息。

返回每一列的统计信息。

列	描述
column_name	列名（汇总行为 NULL）
data_size	列中所有值的总大小（以字节为单位）

列	描述
distinct_values_count	列中不同值的数量
nulls_fraction	列中值为 NULL 的部分
row_count	行数（仅针对摘要行返回）
low_value	在此列中找到的最小值（仅对于某些类型）
high_value	在此列中找到的最大值（仅适用于某些类型）

示例

```
SHOW STATS FOR orders;
SHOW STATS FOR (SELECT * FROM orders);
```

- 在 Analyze nation 表之前：

```
SHOW STATS FOR nation;
column name | data size | distinct values count | nulls fraction | row count |
low value | high value
-------------|-----------|-----------------------|----------------|-----------
|-----------|------------
 name        |     NULL |                NULL |          NULL |      NULL | NULL
| NULL
 regionkey   |     NULL |                NULL |          NULL |      NULL | NULL
| NULL
 NULL        |     NULL |                NULL |          NULL |       6.0 | NULL
| NULL
(3 rows)
```

- 在 Analyze nation 表之后：

```
Analyze nation;
ANALYZE: 6 rows

--查询分析后的结果
SHOW STATS FOR nation;
column_name | data_size | distinct_values_count | nulls_fraction | row_count |
low_value | high_value
-------------|-----------|-----------------------|----------------|-----------
|-----------|------------
 name        |     45.0 |                 5.0 |           0.0 |      NULL | NULL
| NULL
 regionkey   |     NULL |                 2.0 |           0.0 |      NULL | 0
| 2
 NULL        |     NULL |                NULL |          NULL |       6.0 | NULL
| NULL
(3 rows)
```

10.16.2.1.30 SHOW FUNCTIONS

语法

SHOW FUNCTIONS [LIKE pattern [ESCAPE escapeChar]];

SHOW EXTERNAL FUNCTIONS;

SHOW EXTERNAL FUNCTION qualified_function_name;

描述

显示所有内置函数的定义信息。

显示所有 JAVA 函数的描述信息。

显示给定函数的定义信息。

示例

```
SHOW functions;

--使用 LIKE 子句
show functions like 'boo_%';
 Function | Return Type | Argument Types | Function Type | Deterministic |
Description
----------|-------------|----------------|---------------|---------------|---------
----
 bool_and | boolean     | boolean        | aggregate     | true          |
 bool_or  | boolean     | boolean        | aggregate     | true          |
(2 rows)

--如果匹配字符串中有字符与通配符冲突，可以指定转义字符来标识，示例为查询 default 这个 schema 下，
table_name 前缀为 " t_ " 的所有 table，转义字符为 " \ " :
SHOW FUNCTIONS LIKE 'array\_%' escape '\';
  Function     | Return Type |        Argument Types         | Function Type |
Deterministic
|                                      Description
| Variable Arity | Built In
-----------------|-------------|-------------------------------|---------------|-
--------------
|-----------------------------------------------------------------------------------
----------------------|----------------|----------
 array_agg       | array(T)    | T                           | aggregate     | true
| return an array of values
| false         | true
 array_contains  | boolean     | array(T), T                   | scalar        | true
| Determines whether given value exists in the array
| false         | true
 array_distinct  | array(E)    | array(E)                      | scalar        | true
| Remove duplicate values from the given array
| false         | true
 array except    | array(E)    | array(E), array(E)            | scalar        | true
| Returns an array of elements that are in the first array but not the second,
without duplicates.      | false         | true
 array intersect | array(E)    | array(E), array(E)            | scalar        | true
| Intersects elements of the two given arrays
| false         | true
 array join      | varchar     | array(T), varchar             | scalar        | true
| Concatenates the elements of the given array using a delimiter and an optional
string to replace nulls | false         | true
 array_join      | varchar     | array(T), varchar, varchar    | scalar        | true
```

```
| Concatenates the elements of the given array using a delimiter and an optional
string to replace nulls | false        | true
 array_max      | T         | array(T)                    | scalar       | true
| Get maximum value of array
| false        | true
 array_min      | T         | array(T)                    | scalar       | true
| Get minimum value of array
| false        | true
 array_position  | bigint     | array(T), T                  | scalar       | true
| Returns the position of the first occurrence of the given value in array (or 0 if
not found)          | false        | true
 array_remove    | array(E)    | array(E), E                  | scalar       | true
| Remove specified values from the given array
| false        | true
 array_sort     | array(E)    | array(E)                    | scalar       | true
| Sorts the given array in ascending order according to the natural ordering of its
elements.           | false        | true
 array_sort     | array(T)    | array(T), function(T,T,integer) | scalar       |
true
| Sorts the given array with a lambda comparator.
| false        | true
 array_union     | array(E)    | array(E), array(E)            | scalar       | true
| Union elements of the two given arrays
| false        | true

--查看所有 JAVA 函数
SHOW external functions;
  Function               |   Owner
-----------------------------|-----------
 example.namespace02.repeat | admintest
 hetu.default.add_two      | admintest
(2 rows)

--查看给定函数的定义信息
SHOW external function example.namespace02.repeat;
        External Function
--------------------------------------
External FUNCTION example.namespace02.repeat (
   s varchar,
   n integer
 )
 RETURNS varchar

 COMMENT 'repeat'
 LANGUAGE JAVA
 DETERMINISTIC
 CALLED ON NULL INPUT
 SYMBOL com.test.udf.hetuengine.functions.repeat
 URI hdfs://hacluster/user/hetuserver/udf/data/hetu_udf/udf-test-0.0.1-SNAPSHOT.jar

 FUNCPROPERTIES (
   owner = 'admintest'
 )
```

10.16.2.1.31 SHOW SESSION

语法

SHOW SESSION;

描述

这个表达式用于列出所有 session 的配置参数。

示例

```
show session;
```

10.16.2.1.32 SHOW PARTITIONS

语法

SHOW PARTITIONS [catalog_name.][db_name.]table_name [PARTITION (partitionSpecs)];

描述

这个表达式用于列出指定的的所有分区。

示例

```
SHOW PARTITIONS test PARTITION(hr = '12', ds = 12);
SHOW PARTITIONS test PARTITION(ds > 12);
```

10.16.2.1.33 SHOW COLUMNS

语法

SHOW COLUMNS [FROM | IN] table

描述

这个表达式用于列出指定表的列信息。

示例

列出 fruit 表的列信息：

```
SHOW COLUMNS FROM fruit;
SHOW COLUMNS IN fruit;
```

10.16.2.1.34 SHOW CREATE TABLE

语法

SHOW CREATE TABLE table_name

描述

显示指定数据表的 SQL 创建语句。

示例

显示能够创建 orders 表的 SQL 语句：

```
CREATE TABLE orders (
 orderkey bigint,
 orderstatus varchar,
 totalprice double,
 orderdate date
 )
 WITH (format = 'ORC', location='/user',orc_compress='ZLIB',external=true,
"auto.purge"=false);

show create table orders;

               Create Table
-------------------------------------------------
 CREATE TABLE hive.default.orders (
   orderkey bigint,
   orderstatus varchar,
   totalprice double,
   orderdate date
 )
 WITH (
   external_location = 'hdfs://hacluster/user',
   format = 'ORC',
   orc compress = 'ZLIB',
   orc compress size = 262144,
   orc row index stride = 10000,
   orc stripe size = 67108864
 )
(1 row)
```

10.16.2.1.35 SHOW VIEWS

语法

SHOW VIEWS [IN/FROM database_name] [LIKE pattern [ESCAPE escapeChar]]

描述

列举指定 Schema 中所有满足条件的视图。

默认使用当前 Schema，也可以通过 in/from 子句来指定 Schema。

通过可选子句“LIKE”，筛选视图名满足规则运算表达式的视图，如果不使用这个子句，会列举所有视图。匹配的视图会按字母顺序排列。

目前规则运算表达式只支持“*”（匹配任意字符）。

示例

创建示例所需视图：

```
Create schema test1;
Use test1;
Create table t1(id int, name string);
Create view v1 as select * from t1;
Create view v2 as select * from t1;
Create view t1view as select * from t1;
Create view t2view as select * from t1;

Show views;
Table
--------
 t1view
 t2view
 v1
 v2
(4 rows)

Show views like 'v1';
 Table
-------
 v1
(1 row)

Show views 'v_';
Table
-------
 v1
 v2
(2 rows)
show views like 't*';
 Table
--------
 t1view
 t2view

Show views in test1;
 Table
--------
 t1view
 t2view
 v1
 v2
(4 rows)
```

10.16.2.1.36 SHOW CREATE VIEW

语法

SHOW CREATE VIEW view_name

描述

显示指定数据视图的 SQL 创建语句。

示例

显示能够创建 order_view 视图的 SQL 语句：

```
SHOW CREATE VIEW test_view;
           Create View
---------------------------------------
 CREATE VIEW hive.default.test_view AS
 SELECT
   orderkey
 , orderstatus
 , (totalprice / 4) quarter
 FROM
   orders
(1 row)
```

10.16.2.1.37 SHOW MATERIALIZED VIEWS

语法

SHOW MATERIALIZED VIEWS [IN/FROM schema_name] [WITH TABLES LIKE pattern]

描述

列出 catalogName 为 mv 中的所有物化视图以及对应的数据表。如果希望只查看某个 schema 中的物化视图，可以使用子句[IN/FROM schema_name]

通过可选子句“LIKE”，筛选视图名满足规则运算表达式的视图，如果不使用这个子句，会列举所有视图。匹配的视图会按字母顺序排列。

目前规则运算表达式支持“*”或“%”用于匹配任何字符，下划线“_”用于匹配一个字符，或“|”用于条件连接两个或多个条件。

示例

- SHOW MATERIALIZED VIEWS;

```
hetuengine:tpcds_2gb> SHOW MATERIALIZED VIEWS;
                 Materialized Views                 |     Last Refresh Time
| Status | State | SyncStatus
-----------------------------------------------------------|-------------------
-----------|--------|-------|------------
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_1   | Wed Sep 07
15:37:39 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_103 | Wed Sep 07
15:31:41 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_15  | Wed Sep 07
14:47:09 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_16  | Wed Sep 07
15:39:09 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_18  | Wed Sep 07
```

```
14:46:42 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_23  | Wed Sep 07
15:39:49 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_24  | Wed Sep 07
14:48:19 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_28  | Wed Sep 07
15:38:38 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_29  | Wed Sep 07
15:38:19 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_30  | Wed Sep 07
15:38:04 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_31  | Wed Sep 07
15:39:28 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_33  | Wed Sep 07
15:39:39 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_34  | Wed Sep 07
14:47:38 CST 2022 | ENABLE | Stale | true
```

说明

- Materialized Views：物化视图的名称
- Last Refresh Time：最近一次刷新物化视图的时间
- Status：物化视图状态
- DISABLE：物化视图连续三次自动刷新失败导致的不可用状态，不可用作被改写
- ENABLE：正常状态
- REFRESHING：刷新中
- INIT: 物化视图首次被创建，没有实体数据
- SUSPEND：挂起状态，不能改写，不能刷新
- State：物化视图有效期
- Stale：物化视图过期
- Valid：物化视图未过期，正常状态
- SyncStatus：物化视图缓存是否同步

- SHOW MATERIALIZED VIEWS FROM tpcds;

```
hetuengine:tpcds_2gb> SHOW MATERIALIZED VIEWS FROM auto_created_mv;
                 Materialized Views                 |     Last Refresh Time
| Status | State | SyncStatus
-----------------------------------------------------------|-------------------
-----------|--------|-------|------------
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_1   | Wed Sep 07
15:37:39 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_103 | Wed Sep 07
15:31:41 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_15  | Wed Sep 07
14:47:09 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_16  | Wed Sep 07
15:39:09 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_18  | Wed Sep 07
14:46:42 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_23  | Wed Sep 07
15:39:49 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_24  | Wed Sep 07
14:48:19 CST 2022 | ENABLE | Stale | true
```

```
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_28  | Wed Sep 07
15:38:38 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_29  | Wed Sep 07
15:38:19 CST 2022 | ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_30  | Wed Sep 07
15:38:04 CST 2022 | ENABLE | Stale | true
```

- SHOW MATERIALIZED VIEWS WITH TABLES LIKE 'hive.tpcds_bin_partitioned_orc_2.call_center';

```
hetuengine:tpcds_2gb> SHOW MATERIALIZED VIEWS WITH TABLES LIKE
'hive.tpcds_bin_partitioned_orc_2.call_center';
                  Materialized Views                |                Tables
|     Last Refresh Time      | Status | State | SyncStatus
-----------------------------------------------------|--------------------
-------------------------|------------------------------|--------|-------|----
--------
 mv.auto_created_mv.auto_created_mv_20220907_142132_mv_65 |
hive.tpcds_bin_partitioned_orc_2.call_center | Wed Sep 07 15:28:20 CST 2022 |
ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220907_152143_mv_19 |
hive.tpcds_bin_partitioned_orc_2.call_center | Wed Sep 07 15:37:07 CST 2022 |
ENABLE | Stale | true
```

- SHOW MATERIALIZED VIEWS WITH TABLES LIKE '_ive.tpcds_bin_partitioned_orc_2.call_center';

```
hetuengine:tpcds_2gb> SHOW MATERIALIZED VIEWS WITH TABLES LIKE
'_ive.tpcds_bin_partitioned_orc_2.call_center';
                  Materialized Views                |                Tables
|     Last Refresh Time      | Status | State | SyncStatus
-----------------------------------------------------|--------------------
-------------------------|------------------------------|--------|-------|----
--------
 mv.auto_created_mv.auto_created_mv_20220907_142132_mv_65 |
hive.tpcds_bin_partitioned_orc_2.call_center | Wed Sep 07 15:28:20 CST 2022 |
ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220907_152143_mv_19 |
hive.tpcds_bin_partitioned_orc_2.call_center | Wed Sep 07 15:37:07 CST 2022 |
ENABLE | Stale | true
```

- SHOW MATERIALIZED VIEWS TABLES LIKE '*.call_center';

```
hetuengine:tpcds_2gb> SHOW MATERIALIZED VIEWS WITH TABLES LIKE '*.call_center';
                  Materialized Views                |                Tables
|     Last Refresh Time      | Status | State | SyncStatus
-----------------------------------------------------|--------------------
-------------------------|------------------------------|--------|-------|----
--------
 mv.auto_created_mv.auto_created_mv_20220907_142132_mv_65 |
hive.tpcds_bin_partitioned_orc_2.call_center | Wed Sep 07 15:28:20 CST 2022 |
ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220907_152143_mv_19 |
hive.tpcds_bin_partitioned_orc_2.call_center | Wed Sep 07 15:37:07 CST 2022 |
ENABLE | Stale | true
```

- SHOW MATERIALIZED VIEWS WITH TABLES LIKE '*.**call_center**|*.date_dim';

```
hetuengine:tpcds_2gb> SHOW MATERIALIZED VIEWS WITH TABLES LIKE
'*.call_center|*.date_dim';
                  Materialized Views                |                Tables
```

```
|     Last Refresh Time      | Status | State | SyncStatus
-----------------------------------------------------------|--------------------
-------------------------|------------------------------|--------|-------|----
--------
 mv.auto_created_mv.auto_created_mv_20220907_142132_mv_65 |
hive.tpcds_bin_partitioned_orc_2.call_center | Wed Sep 07 15:28:20 CST 2022 |
ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220907_152143_mv_19 |
hive.tpcds_bin_partitioned_orc_2.call_center | Wed Sep 07 15:37:07 CST 2022 |
ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_1  |
hive.tpcds_bin_partitioned_orc_2.date_dim    | Wed Sep 07 15:37:39 CST 2022 |
ENABLE | Stale | true
 mv.auto_created_mv.auto_created_mv_20220906_201815_mv_103|
hive.tpcds_bin_partitioned_orc_2.date_dim    | Wed Sep 07 15:31:41 CST 2022 |
ENABLE | Stale | true
```

10.16.2.1.38 SHOW CREATE MATERIALIZED VIEW

语法

SHOW CREATE MATERIALIZED VIEW materialized_view_name

描述

显示用于创建物化视图的 SQL 语句。

示例

显示创建物化视图的 SQL 语句。

```
hetuengine:tpcds_2gb> show create materialized view mv.tpcds.test;
           Create Materialized View
-------------------------------------------------
 CREATE MATERIALIZED VIEW mv.tpcds.test ( c1, id )
 WITH (
    storage_table = 'mppdb.tpcds.test'
 ) AS
 SELECT
   c1
 , id
 FROM
   t1
WHERE (id < 7)
```

10.16.2.2 DML 语法

10.16.2.2.1 INSERT

语法

INSERT { INTO | OVERWRITE } [TABLE] table_name [(column_list)] [PARTITION (partition_clause)] {select_statement | VALUES (value [, value ...]) [, (value [, value ...]) ...] }

FROM from_statement INSERT OVERWRITE TABLE tablename1 [PARTITION (partcol1=val1, partcol2=val2 ...)] select_statement

FROM from_statement INSERT INTO TABLE tablename1 [PARTITION (partcol1=val1, partcol2=val2 ...) select_statement

限制

如果数据表中只有一个字段，且字段类型为 row、struct、uniontype，那么插入数据时需要用 row 对类型进行包裹。

```
-- 单字段表插入复杂类型需要用 row()包裹
CREATE TABLE test_row (id row(c1 int, c2 string));

INSERT INTO test_row values row(row(1, 'test'));

CREATE TABLE test_union (id uniontype<int, string>);

INSERT INTO test_union values row(uniontype<0,1,'test'>);

--多字段表复杂类型可以直接插入
CREATE TABLE test_multy_value(id int, col row(c1 int, c2 string));

INSERT INTO test_multy_value values (1,row(1,'test'));
```

描述

- 向表中插入新的数据行。
- 如果指定了列名列表，那么这些列名列表必须与 query 语句产生列列表名完全匹配。表中不在列名列表中的每一列，其值会设置为 null。
- 如果没有指定列名列表，则 query 语句产生的列必须与将要插入的列完全匹配。
- 使用 insert into 时，会往表中追加数据，而使用 insert overwrite 时，如果表属性“auto.purge”被设置为“true”，直接删除原表数据，再写入新的数据。
- 如果对象表是分区表时，insert overwrite 会删除对应分区的数据而非所有数据。
- insert into 后面的 table 关键字为可选，以兼容 hive 语法。

示例

- 创建 fruit 和 fruit_copy 表：

```
create table fruit (name varchar,price double);
create table fruit_copy (name varchar,price double);
```

- 向 fruit 表中插入一行数据：

```
insert into fruit values('LIchee',32);
-- 兼容写法示例,带上 table 关键字
insert into table fruit values('Cherry',88);
```

- 向 fruit 表中插入多行数据：

```
insert into fruit values('banana',10),('peach',6),('lemon',12),('apple',7);
```

- 将 fruit 表中的数据行加载到 fruit_copy 表中，执行后表中有 5 条记录：

```
insert into fruit_copy select * from fruit;
```

- 先清空 fruit_copy 表，再将 fruit 中的数据加载到表中，执行之后表中有 2 条记录：

```
insert overwrite fruit_copy select *  from fruit limit 2;
```

- 对于 varchar 类型，仅当目标表定义的列字段长度大于源表的实际字段长度时，才可以使用 INSERT... SELECT...的形式从源表中查数据并且插入到目标表：

```
create table varchar50(c1 varchar(50));
insert into varchar50 values('hetuEngine');
create table varchar100(c1 varchar(100));
insert into varchar100 select * from varchar50;
```

- 分区表使用 insert overwrite 语句时，只会清理插入值所在分区的数据，而不是整个表：

```
--创建表
create table test_part (id int, alias varchar) partitioned by (dept_id int,
status varchar);

insert into test_part  partition(dept_id=10, status='good') values (1, 'xyz'),
(2, 'abc');

select * from test_part order by id;
 id | alias | dept_id | status
----|-------|---------|--------
  1 | xyz   |     10 | good
  2 | abc   |     10 | good
(2 rows)

--清理分区 partition(dept_id=25, status='overwrite')，并插入一条数据
insert overwrite test_part (id, alias, dept_id, status) values (3, 'uvw', 25,
'overwrite');
 select * from test_part ;
 id | alias | dept_id |  status
----|-------|---------|-----------
  1 | xyz   |     10 | good
  2 | abc   |     10 | good
  3 | uvw   |     25 | overwrite

--清理分区 partition(dept_id=10, status='good')，并插入一条数据
insert overwrite test_part (id, alias, dept_id, status) values (4, 'new', 10,
'good');
select * from test_part ordr;
 id | alias | dept_id |  status
----|-------|---------|-----------
  3 | uvw   |     25 | overwrite
  4 | new   |     10 | good
(2 rows)

--分区表插入数据
create table test_p_1(name string, age int) partitioned by (provice string,
city string);

 create table test_p_2(name string, age int) partitioned by (provice string,
city string);

-- 填充数据到 test_p_1
```

```
 insert into test_p_1 partition (provice = 'hebei', city= 'baoding') values
('xiaobei',15),( 'xiaoming',22);
-- 根据 test_p_1 插入数据到 test_p_2

-- 方式一
from test_p_1 insert into table test_p_2 partition (provice = 'hebei', city=
'baoding') select name,age;

-- 方式二
insert into test_p_2 partition(provice = 'hebei', city= 'baoding') select
name,age from test_p_1;
```

注意事项

默认无法对外部表（external）插入数据的，如需使用该功能，可以给数据源添加配置。

- 共部署情况

  登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine > 概览”，单击“HSConsole WebUI”的 HSConsole 链接进入计算实例界面。

  然后选择“数据源 > hive > 编辑 > 自定义配置 > 增加”来新增一条用户自定义配置项，名称为“hive.non-managed-table-writes-enabled”，值为“true”。

- 独立部署 Hive 情况

  登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine > 概览”，单击“HSConsole WebUI”的 HSConsole 链接进入计算实例界面。

  然后选择“数据源 > *{hive 数据源名称}* > 编辑 > 自定义配置 > 增加”来新增一条用户自定义配置项，名称为“hive.non-managed-table-writes-enabled”，值为“true”。

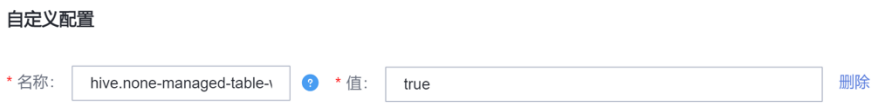

10.16.2.2.2 DELETE

语法

DELETE FROM table_name [WHERE condition]

描述

从表中删除数据行。

当前版本，使用 delete 可以删除整个表的数据，或者分区表的指定分区。

对于事务表（指定了属性 transactional = true），如果指定了 where 条件，将删除条件匹配的数据行。

示例

非事务表场景：

- 清空表数据

```
--创建表并插入数据
 create table tb_del as select * from
(values(1,'suse'),(2,'centos'),(3,'euler')) as t (id,os);
select * from tb_del;
 id |   os
----|--------
  1 | suse
  2 | centos
  3 | euler
(3 rows)

--不支持通过 where 子句删除单条数据
delete from tb_del where id =1;
Query 20201116_081955_00027_iyct5@default@HetuEngine failed: This connector
only supports delete where one or more partitions are deleted entirely for Non-
Transactional tables

--清空表数据
delete from tb_del;
select * from tb_del;
 id | os
----|----
(0 rows)
```

- 删除分区表 hive.web.page_views 中 partition(date='2020-07-17', country='US')的分区：

```
delete from hive.web.page_views where ds=date '2020-07-17' and country='US';
```

事务表场景：删除指定记录

```
--创建事务表
create table tb_trans(a int,b string) with (transactional=true);
CREATE TABLE

--插入数据
insert into tb_trans values(1,'a'),(2,'b'),(3,'c');
INSERT: 3 rows

--删除数据
delete from tb_trans where a=1;
DELETE: 1 row
```

10.16.2.2.3 UPDATE

语法

UPDATE tablename SET column = value [, column = value ...] [WHERE expression]

描述

根据条件更新表数据。

限制

- 仅支持 orc 格式的事务表，并且不能为 external Table。
- 不支持 set(column_name1,column_name2,…)=(value1,value2,…)的语法。

示例

```
-- 创建事务表
create table upd_tb(col1 int,col2 string)  with (format='orc',transactional=true);

--插入数据
insert into upd_tb values (3,'A'),(4,'B');

--修改 col1 = 4 的数据
update upd_tb set col1=5 where col1=4;

--查询表，col1=4 的记录已被修改
select * from upd_tb; --
 col1 | col2
------|------
    5 | B
    3 | A
```

10.16.2.2.4 LOAD

语法

LOAD DATA INPATH filepath [OVERWRITE] INTO TABLE tablename

[PARTITION (partcol1=value1,partcol2=values2…)]

描述

LOAD DATA 命令用于从文件或者文件夹加载数据到 table。

Filepath：需要填写文件或目录的绝对路径。

OVERWRITE：如果使用了这个关键字，目标表（或分区）的数据将被删除，并使用文件中读取的数据来替代。

限制

如果要加载数据到指定分区，用户必须在 partition 子句中列出表的所有字段。

不支持复杂类型数据，比如 Array，Map 等。

不支持外部表（external）。

数据文件的格式应当与目标表的文件格式一样。

创建目标表时，应该指定好文件的分割符，并且分割符要与数据文件中的分割符保持一致。

示例

创建文件“f1.txt”，填入 3 行数字，并通过 HDFS 上传到“/opt/load_test/”目录下。

```
--读取 f1.txt 的数据填充表 f1
CREATE TABLE tb_load_f1(id int) with (format='TEXTFILE');

LOAD DATA INPATH '/opt/load_test/f1.txt' into table tb_load_f1;

select * from tb_load_f1;
 id
----
  1
  2
  3
(3 rows)

--读取/opt/load_test/目录下的文件，填充表 f2
CREATE TABLE tb_load_f2(id int) with (format='TEXTFILE');

LOAD DATA INPATH '/opt/load_test/' into table tb_load_f2;

select * from tb_load_f2;
 id
----
  1
  2
  3
(3 rows)

--读取 f3.txt 文件内容填充表 f3（多字段，数据分割符为'-'）,并通过 HDFS 上传到/opt/load_test/ 目录下，f3.txt 文件内容如下：
 1-n1
 2-n2
-- 创建目标表 tb_load_f3
CREATE TABLE tb_load_f3(id int,name varchar)
with(format='TEXTFILE',textfile_field_separator='-');

Load data inpath '/opt/load_test/f3.txt' into table tb_load_f3;

Select * from tb_load_f3;
id | name
----|------
  1 | n1
  2 | n2
(2 rows)
```

10.16.2.3 TCL 语法

10.16.2.3.1 START TRANSACTION

语法

START TRANSACTION [mode [, ...]]

其中 mode 用于设置事务的隔离级别，可选的参数有：

ISOLATION LEVEL { READ UNCOMMITTED | READ COMMITTED | REPEATABLE READ | SERIALIZABLE }

READ { ONLY | WRITE }

描述

在当前会话下，开启一个新的事务。

示例

```
START TRANSACTION;
START TRANSACTION ISOLATION LEVEL REPEATABLE READ;
START TRANSACTION READ WRITE;
START TRANSACTION ISOLATION LEVEL READ COMMITTED, READ ONLY;
START TRANSACTION READ WRITE, ISOLATION LEVEL SERIALIZABLE;
```

说明

不支持嵌套事务，也就是开启事务后，在 commit 之前不能再开启其它事务。

10.16.2.3.2 COMMIT

语法

COMMIT [WORK]

描述

提交当前的事务。

示例

```
COMMIT;
COMMIT WORK;
```

10.16.2.3.3 ROLLBACK

语法

ROLLBACK [WORK]

描述

回滚当前的事务。

示例

```
ROLLBACK;
ROLLBACK WORK;
```

10.16.2.4 DQL 语法

10.16.2.4.1 SELECT

语法

[/*+ query_rewrite_hint*/]

[WITH [RECURSIVE] with_query [, ...]]

SELECT [ALL | DISTINCT] select_expression [, ...]

[FROM from_item [, ...]]

[WHERE condition]

[GROUP BY [ALL | DISTINCT] grouping_element [, ...]]

[HAVING condition]

[{ UNION | INTERSECT | EXCEPT } [ALL | DISTINCT] select]

[ORDER BY expression [ASC | DESC] [, ...]]

[OFFSET count [ROW | ROWS]]

[LIMIT { count | ALL }]

[FETCH { FIRST | NEXT } [count] { ROW | ROWS } { ONLY | WITH TIES }]

说明

- from_item 可以是以下形式：
- table_name [[AS] alias [(column_alias [, ...])]]
- from_item join_type from_item [ON join_condition | USING (join_column [, ...])]
- table_name [[AS] alias [(column_alias [, ...])]]
  MATCH_RECOGNIZE pattern_recognition_specification
  [[AS] alias [(column_alias [, ...])]]
- join_type 可以是以下形式：
- [INNER] JOIN
- LEFT [OUTER] JOIN
- RIGHT [OUTER] JOIN
- FULL [OUTER] JOIN
- LEFT [SEMI] JOIN
- RIGHT [SEMI] JOIN
- LEFT [ANTI] JOIN
- RIGHT [ANTI] JOIN
- CROSS JOIN
- grouping_element 可以是以下形式：
- ()
- expression

- GROUPING SETS ((column [, ...]) [, ...])
- CUBE (column [, ...])
- ROLLUP (column [, ...])

描述

从零个或多个表中检索行数据。

查询 stu 表的内容。

```
SELECT id,name FROM stu;
```

10.16.2.4.2 WITH

WITH 子句定义查询子句的命名关系，可以展平嵌套查询或简化子查询语句。例如下面的查询语句是等价的：

```
SELECT name, maxprice FROM (SELECT mame, MAX(price) AS maxprice FROM fruit GROUP BY
name) AS x;

WITH x AS (SELECT name, MAX(price) AS maxprice FROM fruit GROUP BY name) SELECT
name, price FROM x;
```

多个子查询

```
with
t1 as(select name,max(price) as maxprice from fruit group by name),
t2 as(select name,avg(price) as avgprice from fruit group by name)
select t1.*,t2.* from t1 join t2 on t1.name = t2.name;
```

WITH 的链式形式

```
WITH
x AS (SELECT a FROM t),
y AS (SELECT a AS b FROM x),
z AS (SELECT b AS c FROM y)
SELECT c FROM z;
```

10.16.2.4.3 GROUP BY

GROUP BY

GROUP BY 将 SELECT 语句的输出行划分成包含匹配值的分组。简单的 GROUP BY 可以包含由输入列组成的任何表达式，也可以是按位置选择输出列的序号。

以下查询是等效的：

```
SELECT count(*), nationkey FROM customer GROUP BY 2;
SELECT count(*), nationkey FROM customer GROUP BY nationkey;
```

GROUP BY 可以按未出现在 SELECT 语句输出中的输入列名对输出进行分组。

例如：

```
SELECT count(*) FROM customer GROUP BY mktsegment;
GROUPING SETS
```

可以指定多个列进行分组，结果列中不属于分组列的将被设置为 NUll。具有复杂分组语法（GROUPING SETS、CUBE 或 ROLLUP）的查询只从基础数据源读取一次，而使用 UNION ALL 的查询将读取基础数据三次。这就是当数据源不具有确定性时，使用 UNION ALL 的查询可能会产生不一致的结果的原因。

```
--创建一个航运表
create table shipping(origin_state varchar(25),origin_zip integer,destination_state
varchar(25) ,destination_zip integer,package_weight integer);

--插入数据
insert into shipping values ('California',94131,'New Jersey',8648,13),
('California',94131,'New Jersey',8540,42),
('California',90210,'Connecticut',6927,1337),
('California',94131,'Colorado',80302,5),
('New York',10002,'New Jersey',8540,3),
('New Jersey',7081,'Connecticut',6708,225);

--执行查询 Grouping sets
SELECT
    origin_state,
    origin_zip,
    destination_state,
    sum( package_weight )
FROM shipping
GROUP BY GROUPING SETS (
        ( origin_state ),
    ( origin_state, origin_zip ),
    ( destination_state ));
--这个的查询在逻辑上等同于多个分组查询的 union all
SELECT origin_state, NULL,NULL,sum( package_weight ) FROM shipping GROUP BY
origin_state UNION ALL  SELECT origin_state,origin_zip,NULL,sum( package_weight )
FROM shipping GROUP BY origin_state,origin_zip UNION ALL  SELECT
NULL,NULL,destination_state,sum( package_weight ) FROM  shipping GROUP BY
destination_state;
--结果
 origin_state | origin_zip | destination_state | _col3
--------------|------------|-------------------|-------
 New Jersey   |      NULL | NULL              |   225
 California   |     94131 | NULL              |    60
 California   |      NULL | NULL              |  1397
 New York     |     10002 | NULL              |     3
 NULL         |      NULL | New Jersey        |    58
 NULL         |      NULL | Connecticut       |  1562
 California   |     90210 | NULL              |  1337
 New York     |      NULL | NULL              |     3
 NULL         |      NULL | Colorado          |     5
 New Jersey   |      7081 | NULL              |   225
(10 rows)
```

CUBE

为给定的列生成所有可能的分组，比如 (origin_state, destination_state) 的可能分组为：(origin_state, destination_state)，(origin_state)，(destination_state)，()。

```
SELECT
    origin_state,
```

```
    destination_state,
    sum( package_weight )
FROM
    shipping
GROUP BY
    CUBE ( origin_state, destination_state );
--等同于
SELECT
origin_state,
destination_state,
sum( package_weight )
FROM
    shipping
GROUP BY
    GROUPING SETS (
        ( origin_state, destination_state ),
        ( origin_state ),
    ( destination_state ),
    ());
```

ROLLUP

为给定的列集生成部分可能的分类汇总：

```
SELECT
    origin_state,
    origin_zip,
    sum( package_weight )
FROM
    shipping
GROUP BY
    ROLLUP ( origin_state, origin_zip );
--等同于
SELECT
origin_state,
origin_zip,
sum( package_weight )
FROM
    shipping
GROUP BY
    GROUPING SETS ((origin_state,origin_zip ),( origin_state ),());
```

说明

Group by 子句目前不支持使用列的别名，例如：

select count(userid) as num ,dept as aaa from salary group by aaa having sum(sal)>2000;

报错如下：

Query 20210630_084610_00018_wc8n9@default@HetuEngine failed: line 1:63: Column 'aaa' cannot be resolved

10.16.2.4.4 HAVING

HAVING

HAVING 与聚合函数和 GROUP BY 一起使用，来控制选在哪些组。HAVING 能够在分组和聚合计算之后，过滤掉不满足给定条件的组。

例如：

```
SELECT count(*), mktsegment, nationkey,
CAST(sum(acctbal) AS bigint) AS totalbal
FROM customer
GROUP BY mktsegment, nationkey
HAVING sum(acctbal) > 5700000
ORDER BY totalbal DESC;
```

10.16.2.4.5 UNION | INTERSECT | EXCEPT

UNION、INTERSECT 和 EXCEPT 都是集合操作。都用来将多个 SELECT 语句的结果集合并成单个结果集。

UNION

UNION 将第一个查询的结果集中的所有行与第二个查询的结果集中的行合并。

query UNION [ALL | DISTINCT] query

ALL 和 DISTINCT 表示是否返回包含重复的行。ALL 返回所有的行；DISTINCT 返回只包含唯一的行。如果未设置，默认为 DISTINCT。

INTERSECT

query INTERSECT [DISTINCT] query

INTERSECT 仅返回第一个和第二个查询的结果相交的行。以下是最简单的 INTERSECT 子句之一的示例。它选择值 13 和 42，并将此结果集与选择值 13 的第二个查询合并。由于 42 仅在第一个查询的结果集中，因此不包含在最终结果中。

```
SELECT * FROM (VALUES 13,42) INTERSECT SELECT 13;
 col0 -------
   13
(1 row)
```

EXCEPT

query EXCEPT [DISTINCT] query

EXCEPT 返回在第一个查询结果而不在第二个查询结果中的行。

```
SELECT * FROM (VALUES 13, 42) EXCEPT SELECT 13;
 _col0
-------
   42
(1 row)
```

说明

Having 子句目前不支持使用列的别名，例如：

select count(userid) as num ,dept as aaa from salary group by dept having aaa='d1';

报错如下：

Query 20210630_085136_00024_wc8n9@default@HetuEngine failed: line 1:75: Column 'aaa' cannot be resolved

10.16.2.4.6 ORDER BY

ORDER BY

ORDER BY 子句用于按一个或多个输出表达式对结果集排序。

ORDER BY expression [ASC | DESC] [NULLS { FIRST | LAST }] [, ...]

每个 expression 可以由输出列组成，也可以是按位置选择输出列的序号。

ORDER BY 子句在 GROUP BY 或 HAVING 子句之后，在 OFFSET、LIMIT 或 FETCH FIRST 子句之前进行计算。

须知

按照 SQL 规范，ORDER BY 子句只影响包含该子句的查询结果的行顺序。HetuEngine 遵循该规范，并删除该子句的冗余用法，以避免对性能造成负面影响。

例如在执行 INSERT 语句时，ORDER BY 子句不会对插入的数据产生影响，是个冗余的操作，会对整个 INSERT 语句的整体性能产生负面影响，因此 HetuEngine 会跳过 ORDER BY 操作。

- ORDER BY 只作用于 SELECT 子句：

```
INSERT INTO some table
SELECT * FROM another table
ORDER BY field;
```

- ORDER BY 冗余的例子是嵌套查询，不影响整个语句的结果：

```
SELECT *
FROM some_table
JOIN (SELECT * FROM another_table ORDER BY field) u
ON some_table.key = u.key;
```

10.16.2.4.7 OFFSET

OFFSET

OFFSET 的作用是丢弃结果集中的前若干行数据。

OFFSET count [ROW | ROWS]

如果有 ORDER BY，则 OFFSET 将会作用于排序后的结果集，OFFSET 丢弃前若干行数据后保留的数据集，仍然是排序的：

```
SELECT name FROM fruit ORDER BY name OFFSET 3;
name
------------
peach
pear
watermelon
(3 rows)
```

否则，如果没有使用 ORDER BY，被丢弃的行可能是任意的行。如果 OFFSET 指定的行数等于或超过了结果集的大小，则最终返回的结果为空。

10.16.2.4.8 LIMIT | FETCH FIRST

LIMIT 和 FETCH FIRST 都可以限制结果集中的行数。Limit 和 offset 可以配合使用进行分页查询。

LIMIT

LIMIT { count | ALL }

下面的查询限制返回的行数为 5：

```
SELECT * FROM fruit LIMIT 5;
```

LIMIT ALL 与省略 LIMIT 的作用一样。

FETCH FIRST

FETCH { FIRST | NEXT } [count] { ROW | ROWS } { ONLY | WITH TIES

FETCH FIRST 支持 FIRST 或 NEXT 关键字以及 ROW 或 ROWS 关键字。这些关键字等效，不影响 query 执行。

- 如果 FETCH FIRST 未指定数量，默认为 1：

```
SELECT orderdate FROM orders FETCH FIRST ROW ONLY;
  orderdate
--------------
 2020-11-11

SELECT *  FROM new_orders FETCH FIRST 2 ROW ONLY;
   orderkey   | orderstatus | totalprice |  orderdate
--------------|-------------|------------|--------------
 202011181113 | online     |    9527.0 | 2020-11-11
 202011181114 | online     |     666.0 | 2020-11-11
(2 rows)
```

- 如果使用了 OFFSET，则 LIMIT 或 FETCH FIRST 会在 OFFSET 之后应用于结果集：

```
SELECT * FROM (VALUES 5, 2, 4, 1, 3) t(x) ORDER BY x OFFSET 2  FETCH FIRST ROW
ONLY;
 x
---
 3
(1 row)
```

- 对于 FETCH FIRST 子句，参数 ONLY 或 WITH TIES 控制结果集中包含哪些行。

  如果指定了 ONLY 参数，则结果集将限制为包含参数数量的前若干行。

  如果指定了 WITH TIES 参数，则要求必须带 ORDER BY 子句。其结果集中包含符合条件的前若干行基本结果集以及额外的行。这些额外的返回行与基本结果集中最后一行的 ORDER BY 的参数一样：

```
CREATE TABLE nation (name varchar,  regionkey integer);

insert into nation values
('ETHIOPIA',0),('MOROCCO',0),('ETHIOPIA',2),('KENYA',2),('ALGERIA',0),('MOZAMBI
QUE',0);
```

```
--返回 regionkey 与第一条相同的所有记录。
SELECT name, regionkey FROM nation ORDER BY regionkey FETCH FIRST ROW WITH TIES;
   name    | regionkey
-----------|-----------
 ALGERIA   |         0
 ETHIOPIA  |         0
 MOZAMBIQUE |        0
 MOROCCO   |         0
(4 rows)
```

10.16.2.4.9 TABLESAMPLE

有 BERNOULLI 和 SYSTEM 两种采样方法。

这两种采样方法都不允许限制结果集返回的行数。

BERNOULLI

每一行都将基于指定的采样率选择到采样表中。当使用 Bernoulli 方法对表进行采样时，将扫描表的所有物理块并跳过某些行（基于采样百分比和运行时计算的随机值之间的比较）。结果中包含一行的概率与任何其他行无关。这不会减少从磁盘读取采样表所需的时间。如果进一步处理采样输出，则可能会影响总查询时间。

```
SELECT * FROM users TABLESAMPLE BERNOULLI (50);
```

SYSTEM

此采样方法将表划分为数据的逻辑段，并按此粒度对表进行采样。此采样方法要么从特定数据段中选择所有行，要么跳过它（基于采样百分比与运行时计算的随机值之间的比较）。系统采样中行的选择依赖于使用的 connector。例如，如果使用 Hive 数据源，这将取决于数据在 HDFS 上的布局。这种采样方法不能保证独立的抽样概率。

```
SELECT * FROM users TABLESAMPLE SYSTEM (75);
```

10.16.2.4.10 UNNEST

UNNEST 可以将 ARRAY 或 MAP 展开成 relation。ARRAYS 展开为单独一列，MAP 展开为两列（key，value）。UNNEST 还可以与多个参数一起使用，将被展开成多列，行数与最高基数参数相同（其他列用空填充）。UNNEST 可以选择使用 WITH ORDINALITY 子句，在这种情况下，会在末尾添加一个额外的 ORDINALITY 列。UNNEST 通常与 JOIN 一起使用，可以引用 JOIN 左侧关系中的列。

使用单独一列

```
SELECT student, score FROM tests CROSS JOIN UNNEST(scores) AS t (score);
```

使用多个列

```
SELECT numbers, animals, n, a
FROM (
VALUES
(ARRAY[2, 5], ARRAY['dog', 'cat', 'bird']),
(ARRAY[7, 8, 9], ARRAY['cow', 'pig'])
```

```
) AS x (numbers, animals)
CROSS JOIN UNNEST(numbers, animals) AS t (n, a);
```

10.16.2.4.11 JOINS

允许合并多个 relation 的数据。

HetuEngine 支持 JOIN 类型为：CROSS JOIN、INNER JOIN、OUTER JOIN（LEFT JOIN、RIGHT JOIN、FULL JOIN）、SEMIN JOIN 和 ANTI JOIN。

CROSS JOIN

CROSS JOIN 返回两个关系的笛卡尔积。可以使用 CROSS JOIN 语法指定，也可以在 FROM 子句中指定多个 relation。

以下的 query 是等价的：

```
SELECT * FROM nation CROSS JOIN region;
SELECT * FROM nation, region;
```

INNER JOIN

两个表中至少存在一个相匹配的数据时才返回行，等价于 JOIN。也可以转换为等价的 WHERE 语句，转换方式如下：

```
SELECT * FROM nation (INNER) JOIN region ON nation.name=region.name;
SELECT * FROM nation ,region WHERE nation.name=region.name;
```

OUTER JOIN

OUTER JOIN 返回符合查询条件的行的同时也返回不符合的行，分为以下三类：

- 左外连接：LEFT JOIN 或 LEFT OUTER JOIN，表示以左表（nation）为基础返回左表所有的行及右表（region）中相匹配行的数据，若右表中没有匹配，则该行对应的右表的值为空。
- 右外连接：RIGHT JOIN 或 RIGHT OUTER JOIN，表示以右表（region）为基础返回右表所有的行及左表（nation）中相匹配行的数据，若左表中没有匹配，则该行对应的左表的值为空。
- 全外连接：FULL JOIN 或 FULL OUTER JOIN，表示只要其中某个表存在匹配，则返回相匹配的行，相当于 LEFT JOIN 和 RIGHT JOIN 结合。

```
SELECT * FROM nation LEFT (OUTER) JOIN region ON nation.name=region.name;
SELECT * FROM nation RIGHT (OUTER) JOIN region ON nation.name=region.name;
SELECT * FROM nation FULL (OUTER) JOIN region ON nation.name=region.name;
```

LATERAL

FROM 中的子查询可以加上 LATERAL 关键字，允许引用前面 FROM 项提供的列：

```
SELECT name, x, y FROM nation CROSS JOIN LATERAL (SELECT name || ' :-' AS x) CROSS
JOIN LATERAL (SELECT x || ')' AS y);
```

SEMI JOIN、ANTI JOIN

当一张表在另一张表找到匹配的记录之后，半连接（semi-join）返回第一张表中的记录。与条件连接相反，即使在右节点中找到几条匹配的记录，左节点的表也只会返回一条记录。另外，右节点的表一条记录也不会返回。半连接通常使用 IN 或 EXISTS 作为连接条件。

而 anti-join 则与 semi-join 相反，即当在第二张表没有发现匹配记录时，才会返回第一张表里的记录；当使用 not exists/not in 的时候会用到。

其他支持的条件包括如下内容：

- where 子句中的多个条件
- 别名关系
- 下标表达式
- 解引用表达式
- 强制转换表达式
- 特定函数调用

须知

目前，只在如下情况下支持多个 semi/anti join 表达式：第一个表中的列在其直接后续的 join 表达式中被查询，且不与其它 join 表达式有关系。

示例如下：

```
CREATE SCHEMA testing ;

USE testing;

CREATE TABLE table1(id int, name varchar,rank int);

INSERT INTO table1
VALUES(10,'sachin',1),(45,'rohit',2),(46,'rohit',3),(18,'virat',4),(25,'dhawan',5);

CREATE TABLE table2(serial int,name varchar);

INSERT INTO table2 VALUES(1,'sachin'),(2,'sachin'),(3,'rohit'),(4,'virat');

CREATE TABLE table3(serial int, name varchar,country varchar);

INSERT INTO table3
VALUES(1,'sachin','india'),(20,'bhuvi','india'),(45,'boult','newzealand'),(3,'maxwe
ll','australia'),(45,'rohit','india'),(4,'pant','india'),(10,'KL','india'),(445,'ro
hit','india');

CREATE TABLE table4(id int, name varchar,rank int);

INSERT INTO table4
VALUES(10,'sachin',1),(45,'rohit',2),(46,'rohit',3),(18,'virat',4),(25,'dhawan',5);
```

```
select * from table1 left semi join table2 on table1.name=table2.name where
table1.name='rohit' and table2.serial=3;
 id | name  | rank
----|-------|------
 45 | rohit |    2
 46 | rohit |    3
(2 rows)


select * from table1 left anti join table2 on table1.name=table2.name where
table1.name='rohit' and table2.serial=3;
 id |  name  | rank
----|--------|------
 10 | sachin |    1
 18 | virat  |    4
 25 | dhawan |    5
(3 rows)

select * from table1 right semi join table2 on table1.name=table2.name where
table1.name='rohit' and table2.serial=3;
 serial | name
--------|-------
      3 | rohit
(1 row)

select * from table1 right anti join table2 on table1.name=table2.name where
table1.name='rohit' and table2.serial=3;
 serial |  name
--------|--------
      1 | sachin
      2 | sachin
      4 | virat
(3 rows)

SELECT * FROM table1 t1 LEFT SEMI JOIN table2 t2 on t1.name=t2.name left semi join
table3 t3 on t1.name = t3.name left semi join table4 t4 on t1.name=t4.name;
id | name  | rank
----|-------|------
 10 | sachin |   1
 45 | rohit |    2
 46 | rohit |    3
(3 rows)
```

Qualifying Column Names

当 JOIN 的两个 relation 有相同的列名时，列引用必须使用 relation 别名（如果 relation 有别名）或 relation 名称进行限定：

```
SELECT nation.name, region.name FROM nation CROSS JOIN region;
SELECT n.name, r.name FROM nation AS n CROSS JOIN region AS r;
SELECT n.name, r.name FROM nation n CROSS JOIN region r;
```

10.16.2.4.12 Subqueries

EXISTS

EXISTS 谓词确定是否返回任意行：

```
SELECT name FROM nation WHERE EXISTS (SELECT * FROM region WHERE region.regionkey =
nation.regionkey)
```

IN

确定子查询生成的任意值是否等于给定的表达式。IN 的结果遵循 null 的标准规则。子查询必须只生成一列：

```
SELECT name FROM nation WHERE regionkey IN (SELECT regionkey FROM region)
```

10.16.2.4.13 SELECT VIEW CONTENT

语法

SELECT column_name FROM view_name

描述

查询视图内容

```
SELECT * FROM test_view;
```

10.16.2.4.14 REWRITE HINT

提示可以与 SELECT 语句一起提供，用于使用指定的物化视图重写查询，这将优化查询，并有助于更快地执行它们。必须在查询开始时给出提示。目前支持两种类型的提示，如下所示：

- NOREWRITE
  不会进行查询重写。格式为：/*+ NOREWRITE */
- REWRITE(materialized_view_name ..)
  查询将使用提到的物化视图名称重写。可以提供多个物化视图名称，以空格分隔。物化视图名称应为完全限定名称。
  格式为：/*+ REWRITE(mv1 mv2 ..) */

示例

- 强制按原 SQL 执行，不对 SQL 进行查询重写

  ```
  /*+ NOREWRITE */ SELECT c1,c2 FROM table;
  ```

- 使用指定物化视图进行查询重写

  ```
  SET SESSION materialized_view_rewrite_enabled=true;  --启用物化视图查询改写能力
  CREATE TABLE t1 (id int, c1 varchar);
  INSERT INTO t1 VALUES (1,'abc'), (2,'abc2'), (3,'abc3'), (4,'abc4'),
  (5,'abc5'),(6,'abc6');
  CREATE TABLE t2 (id1 int, c1 varchar);
  INSERT INTO t2 VALUES (1,'abc'), (2,'abc2'), (3,'abc3'), (4,'abc4'),
  ```

```
(5,'abc5'),(6,'abc6');
-- 创建查询 SQL 的物化视图，并对 SQL 包含的子查询也分别创建物化视图
CREATE MATERIALIZED VIEW mv.tpcds.test7 AS SELECT a.id,b.c1 FROM (SELECT id
FROM t1 WHERE id>5) as a,(SELECT id1,c1 FROM t2 WHERE id1>4) AS b WHERE a.id =
b.id1;
CREATE MATERIALIZED VIEW mv.tpcds.test6a AS SELECT id FROM t1 WHERE id>5;
CREATE MATERIALIZED VIEW mv.tpcds.test6b AS SELECT id1,c1 FROM t2 WHERE id1>4;
-- 指定使用子查询的物化视图进行查询重写
EXPLAIN /*+ REWRITE(mv.tpcds.test6a mv.tpcds.test6b) */ SELECT a.id,b.c1 FROM
(SELECT id FROM t1 WHERE id>5) AS a,(SELECT id1,c1 FROM t2 WHERE id1>4) AS b
WHERE a.id = b.id1;
                                                Query Plan
--------------------------------------------------------------------------------
--------------------------------------------
 Output[id, c1]
 │   Layout: [id:integer, c1:varchar]
 │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
 └─ RemoteExchange[GATHER]
    │   Layout: [id:integer, c1:varchar]
    │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
    └─ InnerJoin[("id" = "id1")][$hashvalue, $hashvalue_22]
       │   Layout: [id:integer, c1:varchar]
       │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
       │   Distribution: PARTITIONED
       ├─ RemoteExchange[REPARTITION][$hashvalue]
       │  │   Layout: [id:integer, $hashvalue:bigint]
       │  │   Estimates: {rows: ? (?), cpu: ?, memory: 0B, network: ?}
       │  └─ ScanProject[table = hive:tpcds:test6a]
       │        Layout: [id:integer, $hashvalue_21:bigint]
       │        Estimates: {rows: ? (?), cpu: ?, memory: 0B, network:
0B}/{rows: ? (?), cpu: ?, memory: 0B, network: 0B}
       │        $hashvalue_21 := combine_hash(BIGINT 0,
COALESCE($operator$hash_code(id), BIGINT 0))
       │        id := id:int:0:REGULAR
       └─ LocalExchange[HASH][$hashvalue_22] ("id1")
          │   Layout: [id1:integer, c1:varchar, $hashvalue_22:bigint]
          │   Estimates: {rows: ? (?), cpu: ?, memory: 0B, network: ?}
          └─ RemoteExchange[REPARTITION][$hashvalue_23]
             │   Layout: [id1:integer, c1:varchar, $hashvalue_23:bigint]
             │   Estimates: {rows: ? (?), cpu: ?, memory: 0B, network: ?}
             └─ ScanProject[table = hive:tpcds:test6b]
                   Layout: [id1:integer, c1:varchar, $hashvalue_24:bigint]
                   Estimates: {rows: ? (?), cpu: ?, memory: 0B, network:
0B}/{rows: ? (?), cpu: ?, memory: 0B, network: 0B}
                   $hashvalue_24 := combine_hash(BIGINT 0,
COALESCE($operator$hash_code(id1), BIGINT 0))
                   id1 := id1:int:0:REGULAR
                   c1 := c1:string:1:REGULAR

(1 row)

-- 指定查询 SQL 整体对应的物化视图进行查询重写
EXPLAIN SELECT a.id,b.c1 FROM (SELECT id FROM t1 WHERE id>5) AS a,(SELECT
id1,c1 FROM t2 WHERE id1>4) AS b WHERE a.id = b.id1;
                        Query Plan
```

```
-----------------------------------------------------------------------
 Output[id, c1]
 │   Layout: [id:integer, c1:varchar]
 │   Estimates: {rows: ? (?), cpu: ?, memory: 0B, network: ?}
 └─ RemoteExchange[GATHER]
    │   Layout: [id:integer, c1:varchar]
    │   Estimates: {rows: ? (?), cpu: ?, memory: 0B, network: ?}
    └─ TableScan[table = hive:tpcds:test7]
           Layout: [id:integer, c1:varchar]
           Estimates: {rows: ? (?), cpu: ?, memory: 0B, network: 0B}
           id := id:int:0:REGULAR
           c1 := c1:string:1:REGULAR

(1 row)
```

10.16.2.5 辅助命令语法

10.16.2.5.1 USE

语法

- USE catalog.schema
- USE schema

描述

指定当前会话所使用的 catalog 和 schema。如果 cataglog 未指定，则默认使用当前的 catalog。

示例

指定当前的会话到 hive catalog 下名为 test 的 schema：

```
USER hive.test
```

注意事项

无。

10.16.2.5.2 SET SESSION

语法

```
SET SESSION name = expression;
SET SESSION catalog.name = expression;
```

描述

设置当前会话的指定属性。

示例

```
SET SESSION optimize_hash_generation = true;
SET SESSION hive.optimized_reader_enabled = true;
```

10.16.2.5.3 RESET SESSION

语法

- RESET SESSION name
- RESET SESSION catalog.name

描述

重置当前会话的指定属性。

示例

```
RESET SESSION optimize_hash_generation;
RESET SESSION hive.optimized_reader_enabled;
```

10.16.2.5.4 DESCRIBE

语法

DESCRIBE [EXTENDED| FORMATTED] table_name

DESCRIBE [EXTENDED| FORMATTED] table_name PARTITION (partition_spec)

描述

查看指定表的元数据信息。该语法目前只能显示列的元数据信息，等效于语法 SHOW COLUMNS。

添加 EXTENDED 关键字会将表的所有元数据信息以“Thrift”序列化的格式显示出来。

添加 FORMATTED 关键字会将表的元数据信息以表格的形式展示。

示例

显示 fruit 数据表的列信息：

```
DESCRIBE fruit;
```

显示 fruit 元数据信息：

```
DESCRIBE FORMATTED fruit;
                      Describe Formatted Table
-------------------------------------------------------------------------------
 # col_name     data_type     comment
 name     varchar
 price     integer

 # Detailed Table Information
 Database:               default
 Owner:                  admintest
 LastAccessTime:           0
 Location:               hdfs://hacluster/user/hive/warehouse/fruit
 Table Type:              MANAGED_TABLE
```

```
# Table Parameters:
      Owner                ggg
      STATS_GENERATED_VIA_STATS_TASK  workaround for potential lack of HIVE-12730
      numFiles             0
      numRows              0
      orc.compress.size      262144
      orc.compression.codec   GZIP
      orc.row.index.stride    10000
      orc.stripe.size        67108864
      presto_query_id        20210308_072339_00075_5ck2k@default@HetuEngine
      presto_version
      rawDataSize           0
      totalSize             0
      transient_lastDdlTime   1615188219

# Storage Information
SerDe Library:            org.apache.hadoop.hive.ql.io.orc.OrcSerde
InputFormat:              org.apache.hadoop.hive.ql.io.orc.OrcInputFormat
OutputFormat:             org.apache.hadoop.hive.ql.io.orc.OrcOutputFormat
Compressed:               No
Num Buckets:              -1
Bucket Columns:           []
Sort Columns:             []
serialization.format:      1
(1 row)

Query 20210309_022835_00007_2i9yy@default@HetuEngine, FINISHED, 1 node
Splits: 1 total, 1 done (100.00%)
0:01 [0 rows, 0B] [0 rows/s, 0B/s];
```

10.16.2.5.5 DESCRIBE FORMATTED COLUMNS

语法

DESCRIBE FORMATTED [db_name.]table_name [PARTITION partition_spec] col_name

描述

描述表或分区的列信息，将包含指定表或分区的列的统计数据。

示例

```
describe formatted show_table1 a;
 Describe Formatted Column
------------------------------
col_name           a
data_type          integer
min
max
num_nulls
distinct_count      0
avg_col_len
max_col_len
num_trues
```

```
 num_falses
 comment
(1 row)
```

10.16.2.5.6 DESCRIBE DATABASE | SCHEMA

语法

DESCRIBE DATABASE|SCHEMA [EXTENDED] schema_name

描述

DATABASE 和 SCHEMA 在此处是等价的，可互换的，它们有这相同的含义。

该语法用于显示 SCHEMA 的名称、注释、还有它在文件系统上的根路径。

可选项 EXTENDED 可以用来显示 SCHEMA 的数据库属性。

示例

```
CREATE SCHEMA web;

DESCRIBE SCHEMA web;
                        Describe Schema
-----------------------------------------------------------------------------
 web     hdfs://hacluster/user/hive/warehouse/web.db   admintest   USER
(1 row)
```

10.16.2.5.7 DESCRIBE INPUT

语法

DESCRIBE INPUT statement_name

描述

列举预编译语句（**prepared statement**）的输入参数，以及参数位置，每个输入参数的类型。对于未确定的参数类型，会显示为 unknown。

示例

- 准备一个预编译的语句，且有三个输入参数，然后罗列该预编译语句的参数列表：

  ```
  PREPARE my_select1 FROM SELECT ? FROM fruit WHERE name  = ? AND price < ?;
  DESCRIBE INPUT my_select1;
  ```

- 一个没有输入参数的预编译语句：

  ```
  PREPARE my_select2 FROM SELECT * FROM fruit;
  DESCRIBE INPUT my_select2;
  ```

10.16.2.5.8 DESCRIBE OUTPUT

语法

DESCRIBE OUTPUT statement_name

描述

列举预编译语句（**prepared statement**）的输出列，包括列名（或者别名），catalog，schema，表名，类型，类型的大小（in bytes），以及一个 boolean 值标识是否为别名。

示例

```
--PREPARE my_select1 FROM SELECT * FROM fruit;
  DESCRIBE OUTPUT my_select1;
--PREPARE my_select2 FROM SELECT count(*) as my_count, 1+2 FROM fruit;
  DESCRIBE OUTPUT my_select2;
--PREPARE my_create FROM CREATE TABLE foo AS SELECT * FROM fruit;
  DESCRIBE OUTPUT my_create;
```

10.16.2.5.9 EXPLAIN

语法

EXPLAIN [(option [, ...])] statement

其中选项可以是以下选项之一：

FORMAT { TEXT | GRAPHVIZ | JSON }

TYPE { LOGICAL | DISTRIBUTED | VALIDATE | IO | COST}

描述

显示一条语句的逻辑的或者分布式的执行计划，也可以用于校验一条 SQL 语句，或者是分析 IO。

参数 TYPE DISTRIBUTED 用于显示分片后的计划（fragmented plan）。每一个 fragment 都会被一个或者多个节点执行。Fragments separation 表示数据在两个节点之间进行交换。Fragment type 表示一个 fragment 如何被执行以及数据在不同 fragment 之间怎样分布。

- SINGLE

  Fragment 会在单个节点上执行。
- HASH

  Fragment 会在固定数量的节点上执行，输入数据通过哈希函数进行分布。
- ROUND_ROBIN

  Fragment 会在固定数量的节点上执行，片段在固定数量的节点上执行，输入数据以轮循方式进行分布。
- BROADCAST

  Fragment 会在固定数量的节点上执行，输入数据被广播到所有的节点。

- SOURCE

  Fragment 在访问输入分段的节点上执行。

示例

- LOGICAL：

```
CREATE TABLE testTable (regionkey int, name varchar);
EXPLAIN SELECT regionkey, count(*) FROM testTable GROUP BY 1;
                                                 Query Plan
-------------------------------------------------------------------------------
-----------------------------------------------------
 Output[regionkey, _col1]
 │   Layout: [regionkey:integer, count:bigint]
 │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
 │   _col1 := count
 └─ RemoteExchange[GATHER]
     │   Layout: [regionkey:integer, count:bigint]
     │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
     └─ Project[]
         │   Layout: [regionkey:integer, count:bigint]
         │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
         └─ Aggregate(FINAL)[regionkey][$hashvalue]
             │   Layout: [regionkey:integer, $hashvalue:bigint, count:bigint]
             │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
             │   count := count("count_8")
             └─ LocalExchange[HASH][$hashvalue] ("regionkey")
                 │   Layout: [regionkey:integer, count_8:bigint, $hashvalue:bigint]
                 │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
                 └─ RemoteExchange[REPARTITION][$hashvalue_9]
                     │   Layout: [regionkey:integer, count_8:bigint,
$hashvalue_9:bigint]
                     │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
                     └─ Aggregate(PARTIAL)[regionkey][$hashvalue_10]
                         │   Layout: [regionkey:integer, $hashvalue_10:bigint,
count_8:bigint]
                         │   count_8 := count(*)
                         └─ ScanProject[table = hive:default:testtable]
                                 Layout: [regionkey:integer, $hashvalue_10:bigint]
                                 Estimates: {rows: 0 (0B), cpu: 0, memory: 0B, network:
0B}/{rows: 0 (0B), cpu: 0, memory: 0B, network: 0B}
                                 $hashvalue_10 := "combine_hash"(bigint '0',
COALESCE("$operator$hash_code"("regionkey"), 0))
                                 regionkey := regionkey:int:0:REGULAR
```

- DISTRIBUTED：

```
EXPLAIN (type DISTRIBUTED) SELECT regionkey, count(*) FROM testTable GROUP BY 1;
                                             Query Plan
-------------------------------------------------------------------------------
----------------------------------------
 Fragment 0 [SINGLE]
     Output layout: [regionkey, count]
     Output partitioning: SINGLE []
     Stage Execution Strategy: UNGROUPED_EXECUTION
     Output[regionkey, _col1]
     │   Layout: [regionkey:integer, count:bigint]
```

```
    │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
    │   _col1 := count
    └─ RemoteSource[1]
          Layout: [regionkey:integer, count:bigint]

 Fragment 1 [HASH]
    Output layout: [regionkey, count]
    Output partitioning: SINGLE []
    Stage Execution Strategy: UNGROUPED_EXECUTION
    Project[]
    │   Layout: [regionkey:integer, count:bigint]
    │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
    └─ Aggregate(FINAL)[regionkey][$hashvalue]
       │   Layout: [regionkey:integer, $hashvalue:bigint, count:bigint]
       │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
       │   count := count("count_8")
       └─ LocalExchange[HASH][$hashvalue] ("regionkey")
          │   Layout: [regionkey:integer, count_8:bigint, $hashvalue:bigint]
          │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
          └─ RemoteSource[2]
                Layout: [regionkey:integer, count_8:bigint, $hashvalue_9:bigint]

 Fragment 2 [SOURCE]
    Output layout: [regionkey, count_8, $hashvalue_10]
    Output partitioning: HASH [regionkey][$hashvalue_10]
    Stage Execution Strategy: UNGROUPED_EXECUTION
    Aggregate(PARTIAL)[regionkey][$hashvalue_10]
    │   Layout: [regionkey:integer, $hashvalue_10:bigint, count_8:bigint]
    │   count_8 := count(*)
    └─ ScanProject[table = hive:default:testtable, grouped = false]
          Layout: [regionkey:integer, $hashvalue_10:bigint]
          Estimates: {rows: 0 (0B), cpu: 0, memory: 0B, network: 0B}/{rows: 0
(0B), cpu: 0, memory: 0B, network: 0B}
          $hashvalue_10 := "combine_hash"(bigint '0',
COALESCE("$operator$hash_code"("regionkey"), 0))
          regionkey := regionkey:int:0:REGULAR
```

- VALIDATE：

```
EXPLAIN (TYPE VALIDATE) SELECT id, count(*) FROM testTable GROUP BY 1;
 Valid
-------
 true
```

- IO：

```
EXPLAIN (TYPE IO, FORMAT JSON) SELECT regionkey , count(*) FROM testTable GROUP
BY 1;

          Query Plan
---------------------------------
 {
   "inputTableColumnInfos" : [ {
     "table" : {
       "catalog" : "hive",
       "schemaTable" : {
         "schema" : "default",
         "table" : "testtable"
```

```
      }
    },
    "columnConstraints" : [ ]
  } ]
}
```

- COST：

```
EXPLAIN (TYPE COST, FORMAT JSON) SELECT regionkey , count(*) FROM testTable
GROUP BY 1;
       Query Plan
-----------------------------
 "Aggregated": {
   "CPU Time": 0.0
   "MaxMemory": 0.0
   "outputRows": 0.0
   "outputSize(bytes)": 0.0
 }
(1 row)
```

10.16.2.5.10 EXPLAIN ANALYZE

语法

EXPLAIN ANALYZE [VERBOSE] statement

描述

执行一条 SQL 语句，并显示分布式执行计划，以及过程中每个操作的代价。

VERBOSE 可选参数，带上这个参数意味着会显示更多详细信息和底层统计数据。这个统计信息不能保证完全正确，特别是对于一些快速执行完成的语句。

限制

Explain analyze 不支持 DDL 语句。

示例

下面这个例子，你可以看到每个阶段（Stage）的 CPU 时间消耗，每个计划节点相应的代价。

须知

这个代价是基于现实时间（wall time），而非 CPU 的相关时间。

对每一个计划节点，都可以看到额外的统计信息，例如每个节点实例的输入平均值，哈希碰撞（hash collisions）的平均次数。这些统计信息对于分析一条 SQL 语句中的数据异常情况（skewness 数据倾斜，abnormal hash collisions）非常有用。

```
EXPLAIN  ANALYZE  SELECT count(*),sum(totalprice) FROM new_orders GROUP BY
orderstatus;
```

```
                                          Query Plan
-------------------------------------------------------------------------------------
--------------------------------------------
 Fragment 1 [HASH]
    CPU: 29.19ms, Scheduled: 134.78ms, Input: 2 rows (77B); per task: avg.: 1.00
std.dev.: 1.00, Output: 2 rows (36B)
    Output layout: [count, sum]
    Output partitioning: SINGLE []
    Stage Execution Strategy: UNGROUPED_EXECUTION
    Project[]
    │   Layout: [count:bigint, sum:double]
    │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
    │   CPU: 4.00ms (2.34%), Scheduled: 10.00ms (33.33%), Output: 2 rows (36B)
    │   Input avg.: 0.06 rows, Input std.dev.: 387.30%
    └─ Aggregate(FINAL)[orderstatus][$hashvalue]
       │   Layout: [orderstatus:varchar, $hashvalue:bigint, count:bigint, sum:double]
       │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
       │   CPU: 6.00ms (3.51%), Scheduled: 17.00ms (56.67%), Output: 2 rows (77B)
       │   Input avg.: 0.06 rows, Input std.dev.: 387.30%
       │   count := count("count_9")
       │   sum := sum("sum_10")
       └─ LocalExchange[HASH][$hashvalue] ("orderstatus")
          │   Layout: [orderstatus:varchar, sum_10:double, count_9:bigint,
$hashvalue:bigint]
          │   Estimates: {rows: ? (?), cpu: ?, memory: ?, network: ?}
          │   CPU: 2.00ms (1.17%), Scheduled: 3.00ms (10.00%), Output: 2 rows (77B)
          │   Input avg.: 0.06 rows, Input std.dev.: 556.78%
          └─ RemoteSource[2]
                 Layout: [orderstatus:varchar, sum_10:double, count_9:bigint,
$hashvalue_11:bigint]
                 CPU: 1.00ms (0.58%), Scheduled: 3.00ms (10.00%), Output: 2 rows (77B)
                 Input avg.: 0.06 rows, Input std.dev.: 556.78%

 Fragment 2 [SOURCE]
    CPU: 17.35ms, Scheduled: 80.04ms, Input: 4 rows (81B); per task: avg.: 4.00
std.dev.: 0.00, Output: 2 rows (77B)
    Output layout: [orderstatus, sum_10, count_9, $hashvalue_12]
    Output partitioning: HASH [orderstatus][$hashvalue_12]
    Stage Execution Strategy: UNGROUPED_EXECUTION
    Aggregate(PARTIAL)[orderstatus][$hashvalue_12]
    │   Layout: [orderstatus:varchar, $hashvalue_12:bigint, sum_10:double,
count_9:bigint]
    │   CPU: 1.00ms (0.58%), Scheduled: 6.00ms (20.00%), Output: 2 rows (77B)
    │   Input avg.: 4.00 rows, Input std.dev.: 0.00%
    │   sum_10 := sum("totalprice")
    │   count_9 := count(*)
    └─ ScanProject[table = hive:default:new_orders, grouped = false]
           Layout: [orderstatus:varchar, totalprice:double, $hashvalue_12:bigint]
           Estimates: {rows: 4 (292B), cpu: 256, memory: 0B, network: 0B}/{rows: 4
(292B), cpu: 548, memory: 0B, network: 0B}
           CPU: 16.00ms (9.36%), Scheduled: 132.00ms (440.00%), Output: 4 rows (117B)
           Input avg.: 4.00 rows, Input std.dev.: 0.00%
           $hashvalue_12 := "combine_hash"(bigint '0',
COALESCE("$operator$hash_code"("orderstatus"), 0))
           orderstatus := orderstatus:string:1:REGULAR
```

```
          totalprice := totalprice:double:2:REGULAR
          Input: 4 rows (81B), Filtered: 0.00%
(1 row)
```

10.16.2.5.11 REFRESH CATALOG

用于手动刷新 HetuEngine Metastore 缓存，用以同步 Hive 数据源的表、分区、数据库等的 Metadata。

语法

REFRESH CATALOG catalog_name

示例

登录 FusionInsight Manager，选择“服务 > HetuEngine > 概览”，单击“HSConsole WebUI”后的 HSConsole 链接进入计算实例界面，然后选择“数据源 > *hive 数据源名称* > 编辑 > 自定义配置 > 增加”，新增如下自定义配置项。

参数名称	值	描述
hive.metastore-cache-ttl	5m	cache 的存活时间，单位：分钟
hive.metastore-refresh-interval	5m	元数据缓存刷新时间，单位：分钟

通过 hive 创建表 tb3，此时 Hetu-cli 查询结果：

```
 show tables;
 Table
-------
 tb1
 tb2
(2 rows)
```

刷新元数据缓存后再次查询：

```
 refresh catalog hive;
show tables;
 Table
-------
 tb1
 tb2
 tb3
(3 rows)
```

10.16.2.5.12 REFRESH SCHEMA

语法

REFRESH SCHEMA schema_name

描述

刷新 SCHEMA 元数据缓存。

示例

```
refresh schema default;
REFRESH
```

10.16.2.5.13 REFRESH TABLE

语法

REFRESH TABLE table_name

描述

刷新 TABLE 元数据缓存。

示例

```
refresh table fruit;
REFRESH
```

10.16.2.5.14 ANALYZE

语法

ANALYZE table_name [WITH (property_name = expression [, ...])]

描述

收集给定表的表和列统计信息。

可选 WITH 子句可用于指定 connector 的属性。使用下面命令可列出所有可用的属性：SELECT * FROM system.metadata.analyze_properties。当前只有 hive connector 支持该属性。

示例

- 收集表 fruit 的统计信息：

```
ANALYZE fruit;
```

- 统计 catalog hive、schema default 下的表存储：

```
ANALYZE hive.default.orders;
```

- 从 hive 分区表中统计分区'2020-07-17' , '2020-07-18'信息：

```
ANALYZE hive.web.page_views WITH (partitions = ARRAY[ARRAY['2020-07-17','US'],
ARRAY['2020-07-18','US']]);
```

10.16.2.5.15 CALL

语法

CALL procedure_name ([name =>] expression [, ...])

描述

调用指定的存储过程。

存储过程由各个连接（connnectors）提供，实现数据操作或者管理任务。例如，系统连接器（System Connector）就定义了存储过程可以取消一个正在运行的查询。有些数据源，例如 PostgreSQL，其系统有定义自己的存储过程，这与连接器定义的存储过程不同，是无法被 CALL 调用的。

检查并更新 metastroe 中分区数组，它支持 3 种模式：

- ADD：将文件系统中存在但 metastore 里没有的分区系统同步到 metastroe 中。
- DROP：drop 元数据表中存在但文件系统中不存在的分区。
- FULL：同时进行 ADD 和 DROP 操作。

示例

```
CALL system.create_empty_partition(
   schema_name => 'web',
   table_name => 'page_views',
   partition_columns => ARRAY['ds', 'country'],
   partition_values => ARRAY['2020-07-19', 'UK']);
```

hive connector 支持的存储过程。

```
system.sync_partition_metadata(schema_name, table_name, mode)
```

10.16.2.5.16 PREPARE

语法

PREPARE statement_name FROM statement

描述

预处理一条语句，以便以后执行。预处理语句是将查询保存在给定名称的会话中。语句可以包含参数，以代替执行时要替换的文本，参数用问号表示。

示例

- 预处理查询

  ```
  PREPARE my_select1 FROM SELECT * FROM fruit;
  ```

- 预处理一个包含参数的查询，在 10.16.2.5.18 EXECUTE 语句中，与 regionkey 和 nationkey 比较的值会被替换

  ```
  PREPARE my_select2 FROM  SELECT name FROM fruit WHERE name= ? AND  price< ?;
  ```

- 预处理插入查询

```
PREPARE my_insert FROM INSERT INTO fruit VALUES ('watermelon',18);
```

10.16.2.5.17 DEALLOCATE PREPARE

语法

DEALLOCATE PREPARE statement_name

描述

从会话中的预处理语句列表中移除语句名为 statement_name 的语句。

示例

删除预处理语句 name my_query:

```
DEALLOCATE PREPARE my_select1;
```

10.16.2.5.18 EXECUTE

语法

EXECUTE statement_name [USING parameter1 [, parameter2, ...]]

描述

执行预编译的 SQL 语句（prepared statement），并可以使用 USING 来指定输入参数。

示例

- 执行一个不带输入参数的预编译语句

```
PREPARE my_select1 FROM SELECT name FROM fruit;
EXECUTE my_select1;
```

- 执行一个带有两个输入参数的 SQL 语句

```
PREPARE my_select2 FROM SELECT name FROM  fruit WHERE name= ? and price< ?;
EXECUTE my_select2 USING  'peach',10;
This is equivalent to:
SELECT name FROM fruit WHERE name = 'peach' AND price<10;
```

10.16.2.5.19 VERIFY

语法

VERIFY MATERIALIZED VIEW MVNAME (mvname1,mvname2...) ORIGINALSQL query

描述

给定一条 SQL 查询语句，验证它是否可以被指定的物化视图重写。

示例

验证指定 SQL 是否能被物化视图 mv.tpcds.test 和 mv.tpcds.t1 重写。

```
verify materialized view mvname(mv.tpcds.test,mv.tpcds.t1) originalsql select c1
from t1 where id < 7;
MV_NAME    | VERIFY RESULT |       REMARKS
---------------|---------------|------------------------
 mv.tpcds.test | true         | MV verified
 mv.tpcds.t1   | false        | This MV is not present
(2 rows)
```

10.16.2.6 预留关键字

表 10-75 罗列了系统预留的关键字，以及它们在其他 SQL 标准中是否为预留关键字。如果需要使用这些关键字作为标识符，请加注双引号。

表10-75 关键字

Keyword	SQL：2016	SQL-92
ALTER	reserved	reserved
AND	reserved	reserved
AS	reserved	reserved
BETWEEN	reserved	reserved
BY	reserved	reserved
CASE	reserved	reserved
CAST	reserved	reserved
CONSTRAINT	reserved	reserved
CREATE	reserved	reserved
CROSS	reserved	reserved
CUBE	reserved	reserved
CURRENT_DATE	reserved	reserved
CURRENT_PATH	reserved	reserved
CURRENT_ROLE	reserved	reserved
CURRENT_TIME	reserved	reserved
CURRENT_TIMESTAMP	reserved	reserved
CURRENT_USER	reserved	reserved
DEALLOCATE	reserved	reserved
DELETE	reserved	reserved
DESCRIBE	reserved	reserved

Keyword	SQL：2016	SQL-92
DISTINCT	reserved	reserved
DROP	reserved	reserved
ELSE	reserved	reserved
END	reserved	reserved
ESCAPE	reserved	reserved
EXCEPT	reserved	reserved
EXECUTE	reserved	reserved
EXISTS	reserved	reserved
EXTRACT	reserved	reserved
FALSE	reserved	reserved
FOR	reserved	reserved
FROM	reserved	reserved
FULL	reserved	reserved
GROUP	reserved	reserved
GROUPING	reserved	reserved
HAVING	reserved	reserved
IN	reserved	reserved
INNER	reserved	reserved
INSERT	reserved	reserved
INTERSECT	reserved	reserved
INTO	reserved	reserved
IS	reserved	reserved
JOIN	reserved	reserved
LEFT	reserved	reserved
LIKE	reserved	reserved
LOCALTIME	reserved	reserved
LOCALTIMESTAMP	reserved	reserved
NATURAL	reserved	reserved
NORMALIZE	reserved	reserved
NOT	reserved	reserved
NULL	reserved	reserved

Keyword	SQL：2016	SQL-92
ON	reserved	reserved
OR	reserved	reserved
ORDER	reserved	reserved
OUTER	reserved	reserved
PREPARE	reserved	reserved
RECURSIVE	reserved	reserved
RIGHT	reserved	reserved
ROLLUP	reserved	reserved
SELECT	reserved	reserved
TABLE	reserved	reserved
THEN	reserved	reserved
TRUE	reserved	reserved
UESCAPE	reserved	reserved
UNION	reserved	reserved
UNNEST	reserved	reserved
USING	reserved	reserved
VALUES	reserved	reserved
WHEN	reserved	reserved
WHERE	reserved	reserved
WITH	reserved	reserved

10.16.3 SQL 函数和操作符

10.16.3.1 逻辑运算符

逻辑运算符

操作	描述	例子
AND	两个值都为 true，则为 true	a AND b
OR	两个值其中一个为 true，则为 true	a OR b
NOT	值为 false，结果则为 true	NOT a

以下真值表反映了 AND 和 OR 如何处理 NULL 值：

a	b	a AND b	a OR b
TRUE	TRUE	TRUE	TRUE
TRUE	FALSE	FALSE	TRUE
TRUE	NULL	NULL	TRUE
FALSE	TRUE	FALSE	TRUE
FALSE	FALSE	FALSE	FALSE
FALSE	NULL	FALSE	NULL
NULL	TRUE	NULL	TRUE
NULL	FALSE	FALSE	NULL
NULL	NULL	NULL	NULL

以下真值表反映了 NOT 如何处理 NULL 值：

value	NOT value
TRUE	FALSE
FALSE	TRUE
NULL	NULL

10.16.3.2 比较函数和运算符

比较操作

操作	描述
<	小于
>	大于
<=	小于等于
>=	大于等于
=	等于
<>	不等于
!=	不等于

- 范围比较：between

  between 适用于值在一个特定的范围内，如：value BETWEEN min AND max

  Not between 适用于值不在某个特定范围内。

  null 值不能出现在 between 操作中，如下两种执行结果都是 Null：

  ```
  SELECT NULL BETWEEN 2 AND 4; -- null
  SELECT 2 BETWEEN NULL AND 6; -- null
  ```

  HetuEngine 中，value，min 和 max 三个参数在 between 和 not between 中必须是同一数据类型。

  错误示例：'John’ between 2.3 and 35.2

  BETWEEN 等价写法示例：

  ```
  SELECT 3 BETWEEN 2 AND 6; -- true
  SELECT 3 >= 2 AND 3 <= 6; -- true
  ```

  NOT BETWEEN 等价写法示例：

  ```
  SELECT 3 NOT BETWEEN 2 AND 6; -- false
  SELECT 3 < 2 OR 3 > 6; -- false
  ```

- IS NULL 和 IS NOT NULL

  用于判断值是否为空，所有数据类型都可以用于此判断。

  ```
  SELECT 3.0 IS NULL; -- false
  ```

- IS DISTINCT FROM 和 IS NOT DISTINCT FROM

  特有用法。在 HetuEngine 的 SQL 中，NULL 代表未知值，所有与 NULL 有关的比较，产生的结果也是 NULL。IS DISTINCT FROM 和 IS NOT DISTINCT FROM 可以把 null 值当成某个已知值，从而使结果返回 true 或者 false（即使表达式中有 Null 值）。

  示例：

  ```
  --建表
  create table dis_tab(col int);
  --插入数据
  insert into dis_tab values (2),(3),(5),(null);
  --查询
  select col from dis_tab where col is distinct from null;
   col
  ----
   2
   3
   5
  (3 rows)
  ```

  如以下真值表，演示了 IS DISTINCT FROM 和 IS NOT DISTINCT FROM 对正常数据和 NULL 值的处理结果：

a	b	a = b	a <> b	a DISTINCT b	a NOT DISTINCT b
1	1	TRUE	FALSE	FALSE	TRUE
1	2	FALSE	TRUE	TRUE	FALSE

a	b	a = b	a <> b	a DISTINCT b	a NOT DISTINCT b
1	NULL	NULL	NULL	TRUE	FALSE
NULL	NULL	NULL	NULL	FALSE	TRUE

- GREATEST 和 LEAST

  这两个函数不是 SQL 标准函数，是常用的扩展。参数中不能有 Null 值。

  - greatest(value1, value2, ..., valueN)

    返回提供的最大值。

  - least(value1, value2, ..., valueN) → [same as input]

    返回提供的最小值。

- 批量比较判断：ALL，ANY 和 SOME

  量词 ALL，ANY 和 SOME 可以参考以下方式，结合比较操作符一起使用：

  ```
  expression operator quantifier ( subquery )
  ```

  以下是一些量词和比较运算符组合的含义，ANY 和 SOME 具有相同的含义，表中的 ANY 换为 SOME 也同样：

表达式	含义
A = ALL (...)	当 A 与所有值相等时返回 true
A <> ALL (...)	当 A 与任何值都不相等时返回 true。
A < ALL (...)	当 A 小于最小值时返回 true。
A = ANY (...)	当 A 与任意一个值相同时返回 true。等价于 A IN (...)。
A <> ANY (...)	当 A 与任意一个值都不相同时返回 true。
A < ANY (...)	当 A 小于最大值时返回 true。

  例如：

```
SELECT 'hello' = ANY (VALUES 'hello', 'world'); -- true
SELECT 21 < ALL (VALUES 19, 20, 21); -- false
SELECT 42 >= SOME (SELECT 41 UNION ALL SELECT 42 UNION ALL SELECT 43);-- true
```

10.16.3.3 条件表达式

CASE

标准的 SQL CASE 表达式有两种模式。

- “简单模式”从左向右查找表达式的每个 value，直到找出相等的 expression：

CASE expression

WHEN value THEN result

[WHEN ...]

[ELSE result]

END

返回匹配 value 的 result。如果没有匹配到任何值，则返回 ELSE 子句的 result；如果没有 ELSE 子句，则返回空。示例：

```
select a,
case a
 when 1 then 'one'
 when 2 then 'two'
 else 'many' end from
 (values (1),(2),(3),(4)) as t(a);
 a | _col1
---|-------
 1 | one
 2 | two
 3 | many
 4 | many
(4 rows)
```

- “查找模式”从左向右判断每个 condition 的布尔值，直到判断为真，返回匹配 result：

  CASE

  WHEN condition THEN result

  [WHEN ...]

  [ELSE result] END

  如果判断条件都不成立，则返回 ELSE 子句的 result；如果没有 ELSE 子句，则返回空。示例：

```
select a,b,
case
when a=1 then 'one'
when b=2 then 'tow'
else 'many' end from (values (1,2),(3,4),(1,3),(4,2)) as t(a,b);
 a | b | _col2
---|---|-------
 1 | 2 | one
 3 | 4 | many
 1 | 3 | one
 4 | 2 | tow
(4 rows)
```

IF

IF 函数是语言结构，它与下面的 CASE 表达式功能相同：

CASE

WHEN condition THEN true_value

[ELSE false_value] END

- if(condition, true_value)
  如果 condition 为真，返回 true_value；否则返回 NULL，true_value 不进行计算。

```
select if(a=1,8) from (values (1),(1),(2)) as t(a); -- 8 8 NULL
select if(a=1,'value') from (values (1),(1),(2)) as t(a); -- value value NULL
```

- if(condition, true_value, false_value)
  如果 condition 为真，返回 true_value；否则计算并返回 false_value 。

```
select if(a=1,'on','off') from (values (1),(1),(2)) as t(a);
_col0
-------
 on
 on
 off
(3 rows)
```

COALESCE

coalesce(value[, ...])

返回参数列表中的第一个非空 value。与 CASE 表达式相似，仅在必要时计算参数。

可类比 MySQL 的 nvl 功能，经常用于转空值为 0 或者''（空字符）。

```
select coalesce(a,0) from (values (2),(3),(null)) as t(a); -- 2 3 0
```

NULLIF

- nullif(value1, value2)
  如果 value1 与 value2 相等，返回 NULL；否则返回 value1 。

```
select nullif(a,b) from (values (1,1),(1,2)) as t(a,b); --
 _col0
-------
  NULL
     1
(2 rows)
```

- ZEROIFNULL(value)
  如果 value 为 null，返回 0，否则返回原值。目前支持数值类型还有 varchar 类型。

```
select zeroifnull(a),zeroifnull(b),zeroifnull(c) from (values
(null,13.11,bigint '157'),(88,null,bigint '188'),(55,14.11,null)) as t(a,b,c);
 _col0 | _col1 | _col2
-------|-------|-------
     0 | 13.11 |   157
    88 |  0.00 |   188
    55 | 14.11 |     0
(3 rows)
```

- NVL(value1,value2)
  如果 value1 为 NULL，返回 value2，否则，返回 value1。

```
select nvl(NULL,3);  -- 3
select nvl(2,3);    --2
```

- ISNULL(value)
  如果 value1 为 NULL，返回 true，否则返回 false。

```
Create table nulltest(col1 int,col2 int);
insert into nulltest values(null,3);
select isnull(col1),isnull(col2) from nulltest;
 _col0 | _col1
-------|-------
 true  | false
(1 row)
```

- ISNOTNULL(value)

  如果 value1 为 NULL，返回 false，否则返回 true。

```
select isnotnull(col1),isnotnull(col2) from nulltest;
 _col0 | _col1
-------|-------
 false | true
(1 row)
```

TRY

评估一个表达式，如果出错，则返回 Null。类似于编程语言中的 try catch。try 函数一般结合 COALESCE 使用，COALESCE 可以将异常的空值转为 0 或者空，以下情况会被 try 捕获：

- 分母为 0
- 错误的 cast 操作或者函数入参
- 数字超过了定义长度

不推荐使用，应该明确以上异常，做数据预处理

示例：

假设有以下表，字段 origin_zip 中包含了一些无效数据：

```
-- 创建表
create  table shipping (origin_state varchar,origin_zip varchar,packages
int ,total_cost int);

-- 插入数据
insert into shipping
values
('California','94131',25,100),
('California','P332a',5,72),
('California','94025',0,155),
('New Jersey','08544',225,490);

-- 查询数据
SELECT * FROM shipping;
 origin_state | origin_zip | packages | total_cost
 -------------+------------+----------+------------
 California   |     94131  |      25  |       100
 California   |     P332a  |       5  |        72
 California   |     94025  |       0  |       155
 New Jersey   |     08544  |     225  |       490
(4 rows)
```

不使用 Try 查询失败：

```
SELECT CAST(origin_zip AS BIGINT) FROM shipping;
Query failed: Cannot cast 'P332a' to BIGINT
```

使用 Try 返回 NULL：

```
SELECT TRY(CAST(origin_zip AS BIGINT)) FROM shipping;
 origin_zip
 ------------
    94131
    NULL
    94025
    08544
 (4 rows)
```

不使用 try 查询失败：

```
SELECT total cost/packages AS per package FROM shipping;
Query failed: Division by zero
```

使用 TRY 和 COALESCE 返回默认值：

```
SELECT COALESCE(TRY(total_cost/packages),0) AS per_package FROM shipping;
 per_package
 -------------
   4
   14
   0
   19
 (4 rows)
```

10.16.3.4 Lambda 表达式

Lambda 表达式可以用->来表示：

```
x->x+1
(x,y)->x+y
x->regexp_like(x,'a+')
x->x[1]/x[2]
x->IF(x>0,x,-x)
x->COALESCE(x,0)
x->CAST(xASJSON)
x->x+TRY(1/0)
```

大部分 SQL 表达式都可以在 Lambda 函数体内使用，除了以下场景：

- 不支持子查询

  ```
  x -> 2 + (SELECT 3)
  ```

- 不支持聚合函数

  ```
  x -> max(y)
  ```

示例

- 通过 transform()函数获取数组元素的平方：

  ```
  SELECT numbers, transform(numbers, n -> n * n) as squared_numbers FROM (VALUES
  (ARRAY[1, 2]),(ARRAY[3, 4]),(ARRAY[5, 6, 7])) AS t(numbers);
    numbers  | squared_numbers
  ```

```
-----------|-----------------
 [1, 2]    | [1, 4]
 [3, 4]    | [9, 16]
 [5, 6, 7] | [25, 36, 49]
(3 rows)
```

- 利用 transform()函数将数组元素转为字符串，无法转换则转为 NULL 输出，避免报错产生：

```
SELECT transform(prices, n -> TRY_CAST(n AS VARCHAR) || '$') as price_tags FROM
(VALUES (ARRAY[100, 200]),(ARRAY[30, 4])) AS t(prices);
 price_tags
--------------
 [100$, 200$]
 [30$, 4$]
(2 rows)
```

- 在对数组元素进行运算时，也能获取其它列来参与运算。例如使用 transform()来计算线性方程 f(x) =ax + b：

```
SELECT xvalues, a, b, transform(xvalues, x -> a * x + b) as
linear_function_values FROM (VALUES (ARRAY[1, 2], 10, 5), (ARRAY[3, 4], 4, 2))
AS t(xvalues, a, b);
 xvalues | a  | b | linear_function_values
---------|----|---|------------------------
 [1, 2]  | 10 | 5 | [15, 25]
 [3, 4]  |  4 | 2 | [14, 18]
(2 rows)
```

- 通过 any_match()过滤出至少有一个元素值大于 100 的数组：

```
SELECT numbers FROM (VALUES (ARRAY[1,NULL,3]), (ARRAY[10,200,30]),
(ARRAY[100,20,300])) AS t(numbers) WHERE any_match(numbers, n ->  COALESCE(n,
0) > 100);
   numbers
----------------
 [10, 200, 30]
 [100, 20, 300]
(2 rows)
```

- 使用 regexp_replace()将首字母大写：

```
SELECT regexp_replace('once upon a time ...', '^(\w)(\w*)(\s+.*)$',x ->
upper(x[1]) || x[2] || x[3]); -- Once upon a time ...
```

- 在聚合函数中应用 Lambda 表达式。如使用 reduce_agg()计算一个较为复杂的按列求元素和：

```
SELECT reduce_agg(value, 0, (a, b) -> a + b, (a, b) -> a + b) sum_values FROM
(VALUES (1), (2), (3), (4), (5)) AS t(value);
 sum_values
------------
         15
(1 row)
```

10.16.3.5 转换函数

cast 转换函数

HetuEngine 会将数字和字符值隐式转换成正确的类型。HetuEngine 不会把字符和数字类型相互转换。例如，一个查询期望得到一个 varchar 类型的值，HetuEngine 不会自动将 bigint 类型的值转换为 varchar 类型。

如果有必要，可以将值显式转换为指定类型。

- cast(value AS type) → type

  显式转换一个值的类型。可以将 varchar 类型的值转为数字类型，反过来转换也可以。

```
select cast('186' as int );
select cast(186 as varchar);
```

- try_cast(value AS type) → type

  与 cast()相似，区别是转换失败返回 null。

```
select try_cast(1860 as tinyint);
 _col0
-------
  NULL
(1 row)
```

说明

当出现数字溢出，null 值转换等情况，会返回 NULL，但无法转换的情况，还是会报错。

例如：select try_cast(186 as date);

Cannot cast integer to date

Format

- format(format, args...) → varchar

  描述：对一个字符串，按照格式字符串指定的方式进行格式化，并返回。

```
SELECT format('%s%%',123);-- '123%'
SELECT format('%.5f',pi());-- '3.14159'
SELECT format('%03d',8);-- '008'
SELECT format('%,.2f',1234567.89);-- '1,234,567.89'
SELECT format('%-7s,%7s','hello','world');-- 'hello  ,  world'
SELECT format('%2$s %3$s %1$s','a','b','c');-- 'b c a'
SELECT format('%1$tA, %1$tB %1$te, %1$tY',date'2006-07-04');-- 'Tuesday, July 4,
2006
```

- format_number(number) → varchar

  描述：返回按照单位符号格式化的字符串

```
SELECT format number(123456); -- '123K'
SELECT format_number(1000000); -- '1M'
```

Data Size

parse_presto_data_size 函数支持以下单位：

单位	描述	值
B	Bytes	1
kB	Kilobytes	1024
MB	Megabytes	1024^2
GB	Gigabytes	1024^3
TB	Terabytes	1024^4
PB	Petabytes	1024^5
EB	Exabytes	1024^6
ZB	Zettabytes	1024^7
YB	Yottabytes	1024^8

parse_presto_data_size(string) → decimal(38)

将带单位的格式化的值转为数字，值可以是小数，如下所示：

```
SELECT parse_presto_data_size('1B'); -- 1
SELECT parse_presto_data_size('1kB'); -- 1024
SELECT parse_presto_data_size('1MB'); -- 1048576
SELECT parse_presto_data_size('2.3MB'); -- 2411724
```

其它

typeof(expr) → varchar

返回表达式的数据类型名称。

```
SELECT typeof(123);-- integer
SELECT typeof('cat');-- varchar(3)
SELECT typeof(cos(2)+1.5);-- double
```

10.16.3.6 数学函数和运算符

数学运算符

运算符	描述
+	加
-	减
*	乘
/	除
%	取余

数学函数

- abs(x) → [same as input]
  返回 x 的绝对值

```
SELECT abs(-17.4);-- 17.4
```

- bin(bigint x) -> string
  返回 x 的二进制格式

```
select bin(5); --101
```

- bround(double x) -> double
  银行家舍入法：
  - 1~4：舍
  - 6~9：进
  - 5 的前位数是偶数：舍
  - 5 的前位数是奇数：进

```
select bround(3.5); -- 4.0
select bround(2.5); -- 2.0
select bround(3.4); -- 3.0
```

- bround(double x, int y) -> double
  保留 y 位小数的银行家舍入法

```
select bround(8.35,1); --8.4
select bround(8.355,2); --8.36
```

- ceil(x) → [same as input]
  同 ceiling()

```
SELECT ceil(-42.8); -- -42
```

  ceiling(x) → [same as input]
  返回 x 的向上取整的数值

```
SELECT ceiling(-42.8); -- -42
```

- conv(bigint num, int from_base, int to_base)
- conv(string num, int from_base, int to_base)
  对 num 做进制转换操作，示例为从 10 进制转为 2 进制

```
select conv('123',10,2); -- 1111011
```

- rand() → double
  返回 0 到 1 之间的随机小数

```
select rand();--  0.049510824616263105
```

- cbrt(x) → double
  返回 x 的立方根

```
SELECT cbrt(27.0); -- 3
```

- e() → double
  返回欧拉常数

```
select e();-- 2.718281828459045
```

- exp(x) → double

返回 e 的 x 次方

```
select exp(1);--2.718281828459045
```

- factorial(int x) -> bigint

  返回 x 的阶乘，x 的有效值范围[0,20]

```
select factorial(4); --24
```

- floor(x) → [same as input]

  返回 x 舍入最接近的整数

```
SELECT floor(-42.8);-- -43
```

- from_base(string, radix) → bigint

  将一个指定进制数转为 bigint，如将 3 进制数'200' 转为十进制数

```
select from_base('200',3);--18
```

- hex(bigint|string|binary x) -> string

  如果 x 为 int 或二进制形式，则十六进制格式数字以 string 类型返回。否则，如果 x 为 string，则会将字符串的每个字符转换为十六进制表示形式，并返回结果 string

```
select hex(68); -- 44
select hex('AE'); -- 4145
```

- to_base(*x*, *radix*) → varchar

  将一个整数转成 radix 进制数的字符表示，如将十进制的 18 转为 3 进制的表示法

```
select to_base(18,3);-- 200
```

- ln(x) → double

  返回 x 的自然对数

```
select ln(10);--2.302585092994046
select ln(e());--1.0
```

- log2(x) → double

  返回 x 的以 2 为底的对数

```
select log2(4);-- 2.0
```

- log10(x) → double

  返回 x 的以 10 为底的对数

```
select log10(1000);-- 3.0
```

- log(b, x) → double

  返回 x 的以 b 为底的对数

```
select log(3,81); -- 4.0
```

- mod(n, m) → [same as input]

  返回 n 除以 m 的模数

```
select mod(40,7) ;-- 5
select mod(-40,7);  -- -5
```

- pi() → double

  返回圆周率

```
select pi();--3.141592653589793
```

- pmod(int x,int y) -> int

- pmod(double x,double y) -> double
  返回 x 除 y 的余数的绝对值

```
select pmod(8,3); --2
Select pmod(8.35,2.0); --0.35
```

- pow(x, p) → double
  同 power()

```
select pow(3.2,3);-- 32.76800000000001
```

- power(x,p)
  返回 x 的 p 次方

```
select power(3.2,3);-- 32.76800000000001
```

- radians(x) → double
  将角度 x 转为弧度

```
 select radians(57.29577951308232);-- 1.0
```

- degrees(x) → double
  将角度 x（以弧度表示）转为角度

```
select degrees(1);-- 57.29577951308232
```

- round(*x*) → [same as input]
  返回 x 舍入到最近的整数

```
select round(8.57);-- 9
```

- round(*x*, *d*) → [same as input]
  x 四舍五入到保留 d 位小数

```
select round(8.57,1);-- 8.60
```

- shiftleft(tinyint|smallint|int x, int y) -> int
- shiftleft(bigint x, int y) -> bigint
  返回 x 左移 y 个位置的值

```
select shiftleft(8,2);--32
```

- shiftright(tinyint|smallint|int a, int b) -> int
- shiftright(bigint a, int b) -> bigint
  返回 x 右移 y 个位置的值

```
select shiftright(8,2);--2
```

- shiftrightunsigned(tinyint|smallint|int x, int y) -> int
- shiftrightunsigned(bigint x, int y) -> bigint
  按位无符号右移，返回 x 右移 y 个位置的值。当 x 为 tinyint、smallint、int 时，返回 int 类型；当 x 为 bigint 时，返回 bigint 类型

```
select shiftrightunsigned(8,3); -- 1
```

- sign(*x*) → [same as input]
  返回 x 的符号函数
  - 如果 x=0，返回 0
  - x<0，返回-1
  - x>0，返回 1

```
select sign(-32.133);-- -1
select sign(32.133); -- 1
select sign(0);--0
```

对于 double 类型的参数

- 参数是 NaN，返回 NaN
- 参数是+∞，返回 1
- 参数是-∞，返回-1

```
select sign(NaN());--NaN
select sign(Infinity());-- 1.0
select  sign(-infinity());-- -1.0
```

- sqrt(*x*) → double

  返回 x 的平方根

```
select sqrt(100); -- 10.0
```

- truncate(*number,num_digits*)
  - Number 需要截尾取整的数字，Num_digits 用于指定取整精度的数字
  - Num_digits 的默认值为 0
  - truncate ()函数截取时不进行四舍五入

```
select truncate(10.526); -- 10
select truncate(10.526,2); --  10.520
```

- trunc(*number,num_digits*)　参考 truncate(*number,num_digits*)
- unhex(string x) -> binary

  返回十六进制的倒数

```
select unhex('123'); --^A#
```

- width_bucket(*x*, *bound1*, *bound2*, *n*) → bigint

  在具有指定 bound1 和 bound2 边界以及 n 个存储桶的等宽直方图中返回 x 的容器数量

```
select value,width_bucket(value,1,5000,10) from (values
(1),(100),(500),(1000),(2000),(2500),(3000),(4000),(4500),(5000),(8000)) as
t(value);
value | _col1
-------|-------
    1 |    1
  100 |    1
  500 |    1
 1000 |    2
 2000 |    4
 2500 |    5
 3000 |    6
 4000 |    8
 4500 |    9
 5000 |   11
 8000 |   11
(11 rows)
```

- width_bucket(*x*, *bins*) → bigint

  根据数组 bin 指定的 bin 返回 x 的 bin 数量。bins 参数必须是双精度数组，并假定为升序排列

```
select width_bucket(x,array [1.00,2.89,3.33,4.56,5.87,15.44,20.78,30.77]) from
(values (3),(4)) as t(x);
 _col0
-------
     2
     3
(2 rows)
```

- quotient(BIGINT numerator, BIGINT denominator)→bigint

  描述：计算左边数字除于右边数字的值，会抛弃部分小数部分的值

```
select quotient(25,4);-- 6
```

随机数

- rand() → double

  同 random()

- random() → double

  返回范围为 0.0 <= x <1.0 的伪随机值

```
select random();-- 0.021847965885988363
select random();-- 0.5894438037549372
```

- random(*n*) → [same as input]

  返回介于 0 和 n（不包括 n）之间的伪随机数

```
select random(5);-- 2
```

须知

random(n)包含数据类型 tinyint，bigint，smallint，integer。

统计学函数

二项分布的置信区间有多种计算公式，最常见的是["正态区间"]，但是，它只适用于样本较多的情况（np > 5 且 n(1 − p) > 5），对于小样本，它的准确性很差。于是采用威尔逊区间：

$$\left(\hat{p}+\frac{z_{\alpha/2}^2}{2n}\pm z_{\alpha/2}\sqrt{[\hat{p}(1-\hat{p})+z_{\alpha/2}^2/4n]/n}\right)/(1+z_{\alpha/2}^2/n).$$

z —— 正态分布，均值 + z * 标准差　置信度。 z = 1.96，置信度为 95%

以好评率统计为例，pos 是好评数，n 是评论总数，phat 是好评率

z = 1.96

phat= 1.0* pos/n

z1=phat + z * z/(2 * n)

z2= $z*\sqrt{\text{paht}(1-\text{phat})/n+z^2/(4*n^2)}$

m= (1 + z * z / n)

下界值(z1-z2)/m，上界值 (z1+z2)/m

- wilson_interval_lower(successes, trials, z) → double

  返回伯努利试验过程的威尔逊分数区间的下界，置信值由 z 分数 z 指定。

```
select wilson_interval_lower(1, 5, 1.96);-- 0.036223160969787456
```

- wilson_interval_upper(successes, trials, z) → double

  返回伯努利试验过程的威尔逊分数区间的上界，置信值由 z 分数 z 指定。

```
 select wilson_interval_upper(1, 5, 1.96);--  0.6244717358814612
```

- cosine_similarity(*x*, *y*) → double

  返回稀疏向量 x 和 y 之间的余弦相似度。

```
SELECT cosine_similarity
(MAP(ARRAY['a'],ARRAY[1.0]),MAP(ARRAY['a'],ARRAY[2.0]));-- 1.0
```

累计分布函数

- beta_cdf(*a*, *b*, *v*) → double

用给定的 a，b 参数计算贝塔分布的累计分布函数：P（N <v; a，b）。参数 a，b 必须为正实数，而值 v 必须为实数。值 v 必须位于间隔[0，1]上。

beta 分布的累积分布函数公式也称为不完全 beta 函数比(常用 Ix 表示)，对应公式：

$$F(x) = I_x(p,q) = \frac{\int_0^x t^{p-1}(1-t)^{q-1}dt}{B(p,q)} \quad 0 \le x \le 1; p,q > 0$$

```
select beta_cdf(3,4,0.0004); --  1.278848368599041E-9
```

- inverse_beta_cdf(*a*, *b*, *p*) → double

  贝塔累计分布函数的逆运算，通过给定累计概率 p 的 a 和 b 参数：P（N <n）。参数 a，b 必须为正实数，p 在区间[0,1]上。

```
select inverse_beta_cdf(2, 5, 0.95) ;--0.5818034093775719
```

- inverse_normal_cdf(*mean*, *sd*, *p*) → double

  给定累积概率（p）：P（N <n）相关的均值和标准偏差，计算正态累计分布函数的逆。平均值必须是实数值，标准偏差必须是正实数值。概率 p 必须位于间隔（0，1）上。

```
select inverse_normal_cdf(2, 5, 0.95);-- 10.224268134757361
```

- normal_cdf(*mean*, *sd*, *v*) → double

  给定平均值和标准差，计算正态分布函数值。P(N<v;mean,sd)，平均值和 v 必须是实数值，标准差必须是正实数值。

```
 select normal_cdf(2, 5, 0.95);--  0.4168338365175577
```

三角函数

所有三角函数的参数都是以弧度表示。参考单位转换函数 degrees()和 radians()。

- acos(x) → double
  求反余弦值。
  ```
  SELECT acos(-1);-- 3.14159265358979
  ```
- asin(x) → double
  求反正弦值。
  ```
  SELECT asin(0.5);-- 0.5235987755982989
  ```
- atan(x) → double
  求 x 的反正切值。
  ```
  SELECT atan(1);-- 0.7853981633974483
  ```
- atan2(y, x) → double
  返回 y/x 的反正切值。
  ```
  SELECT atan2(2,1);-- 1.1071487177940904
  ```
- cos(x) → double
  返回 x 的余弦值。
  ```
  SELECT cos(-3.1415927);-- -0.9999999999999989
  ```
- cosh(x) → double
  返回 x 的双曲余弦值。
  ```
  SELECT cosh(3.1415967);-- 11.592000006553231
  ```
- sin(x) → double
  求 x 的正弦值。
  ```
  SELECT sin(1.57079);--  0.9999999999799858
  ```
- tan(x) → double
  求 x 的正切值。
  ```
  SELECT tan(20);-- 2.23716094422474
  ```
- tanh(x) → double
  求 x 双曲正切值。
  ```
  select tanh(3.1415927);-- 0.9962720765661324
  ```

浮点函数

- infinity() → double
  返回表示正无穷大的常数。
  ```
  select infinity();-- Infinity
  ```
- is_finite(x) → boolean
  判断 x 是否有限值。
  ```
  select is_finite(infinity());-- false
  select is_finite(50000);--true
  ```
- is_infinite(x) → boolean
  判断 x 是否无穷大。
  ```
  select is_infinite(infinity());-- true
  select is_infinite(50000);--false
  ```

- is_nan(x) → boolean
  判断 x 是否非数字。

```
--输入的值必须为 double 类型
select is_nan(null); -- NULL
select is_nan(nan()); -- true
select is_nan(45);-- false
```

- nan() → double
  返回表示非数字的常数。

```
select nan(); -- NaN
```

10.16.3.7 Bitwise 函数

- bit_count(x, bits) → bigint
  计算 2 的补码表示法中 x 中设置的位数（视为有符号位的整数）。

```
SELECT bit_count(9, 64); -- 2
SELECT bit_count(9, 8); -- 2
SELECT bit_count(-7, 64); -- 62
SELECT bit_count(-7, 8); -- 6
```

- bitwise_and(x, y) → bigint
  以二进制补码形式返回 x 和 y 按位与的结果。

```
select bitwise_and(8, 7); -- 0
```

- bitwise_not(x) → bigint
  以二进制补码形式返回 x 按位非的结果。

```
select bitwise_not(8);-- -9
```

- bitwise_or(x, y) → bigint
  以二进制补码形式返回 x 和 y 按位或的结果。

```
select bitwise_or(8,7);-- 15
```

- bitwise_xor(x, y) → bigint
  以二进制补码形式返回 x 和 y 按位异或的结果。

```
SELECT bitwise_xor(19,25); -- 10
```

- bitwise_left_shift(*value*, *shift*) → [same as value]
  描述：返回 value 左移 shift 位后的值。

```
SELECT bitwise_left_shift(1, 2); -- 4
SELECT bitwise_left_shift(5, 2); -- 20
SELECT bitwise_left_shift(0, 1); -- 0
SELECT bitwise_left_shift(20, 0); -- 20
```

- bitwise_right_shift(value, shift) → [same as value]
  描述：返回 value 右移 shift 位后的值。

```
SELECT bitwise_right_shift(8, 3); -- 1
SELECT bitwise_right_shift(9, 1); -- 4
SELECT bitwise_right_shift(20, 0); -- 20
SELECT bitwise_right_shift(0, 1); -- 0
-- 右移超过 64 位，返回 0
SELECT bitwise_right_shift( 12, 64); -- 0
```

- bitwise_right_shift_arithmetic(*value*, *shift*) → [same as value]

  描述：返回 value 的算术右移值，当 shift 小于 64 位时，返回结果与 bitwise_right_shift 一样，当移动位数达到或者超过 64 位时，value 是正数时返回 0，负数时返回-1：

```
SELECT bitwise_right_shift_arithmetic( 12, 64); --  0
SELECT bitwise_right_shift_arithmetic(-45, 64); -- -1
```

10.16.3.8 十进制函数和操作符

DECIMAL 字面量

可以使用 DECIMAL 'xxxxxxx.yyyyyyy' 语法来定义 DECIMAL 类型的字面量。

DECIMAL 类型的字面量精度将等于字面量（包括尾随零和前导零）的位数。范围将等于小数部分（包括尾随零）的位数。

示例字面量	数据类型
DECIMAL '0'	DECIMAL(1)
DECIMAL '12345'	DECIMAL(5)
DECIMAL '0000012345.1234500000'	DECIMAL(20, 10)

二进制算术 decimal 运算符

支持标准数学运算符。下表说明了结果的精度和范围计算规则。假设 x 的类型为 DECIMAL(xp, xs)，y 的类型为 DECIMAL(yp, ys)。

运算	结果类型精度	结果类型范围
x + y 和 x - y	min(38, 1 + min(xs, ys) + min(xp - xs, yp - ys))	max(xs, ys)
x * y	min(38, xp + yp)	xs + ys
x / y	min(38, xp + ys + max(0, ys-xs))	max(xs, ys)
x % y	min(xp - xs, yp - ys) + max(xs, bs)	max(xs, ys)

如果运算的数学结果无法通过结果数据类型的精度和范围精确地表示，则发生异常情况：Value is out of range。

当对具有不同范围和精度的 decimal 类型进行运算时，值首先被强制转换为公共超类型。对于接近于最大可表示精度 (38) 的类型，当一个操作数不符合公共超类型时，这可能会导致“值超出范围”错误。例如：decimal(38, 0) 和 decimal(38, 1) 的公共超类型是 decimal(38, 1)，但某些符合 decimal(38, 0) 的值无法表示为 decimal(38, 1)。

比较运算符

所有标准比较运算符和 BETWEEN 运算符都适用于 DECIMAL 类型。

一元 decimal 运算符

运算符“-”执行取负运算，结果的类型与参数的类型相同。

10.16.3.9 字符串函数和运算符

字符串运算符

||表示字符连接

```
SELECT 'he'||'llo'; -hello
```

字符串函数

这些函数假定输入字符串包含有效的 UTF-8 编码的 Unicode 代码点。不会显式检查 UTF-8 数据是否有效，对于无效的 UTF-8 数据，函数可能会返回错误的结果。可以使用 from_utf8 来更正无效的 UTF-8 数据。

此外，这些函数对 Unicode 代码点进行运算，而不是对用户可见的字符（或字形群集）进行运算。某些语言将多个代码点组合成单个用户感观字符（这是语言书写系统的基本单位），但是函数会将每个代码点视为单独的单位。

lower 和 upper 函数不执行某些语言所需的区域设置相关、上下文相关或一对多映射。

- chr(n) → varchar

  描述：返回 Unicode 编码值为 n 的字符值。

  ```
  select chr(100); --d
  ```

- char_length(string) → bigint

  参考 length(string)

- character_length(string) → bigint

  参考 length(string)

- codepoint(*string*) → integer

  描述：返回单个字符对应的 Unicode 编码。

  ```
  select codepoint('d'); --100
  ```

- concat(string1, string2) → varchar

  描述：字符串连接。

  ```
  select concat('hello','world'); -- helloworld
  ```

- concat_ws(string0, string1, ..., stringN) → varchar

  描述：将 string1、string2、...,stringN，以 string0 作为分隔符串联成一个字符串。如果 string0 为 null，则返回值为 null。分隔符后的参数如果是 NULL 值，将会被跳过。

  ```
  select concat_ws(',','hello','world'); -- hello,world
  select concat_ws(NULL,'def'); --NULL
  ```

```
select concat_ws(',','hello',NULL,'world'); -- hello,world
select concat_ws(',','hello','','world'); -- hello,,world
```

- concat_ws(string0, array(varchar)) → varchar

  描述：将数组中的元素以 string0 为分隔符进行串联。如果 string0 为 null，则返回值为 null。数组中的任何 null 值都将被跳过。

```
select concat_ws(NULL,ARRAY['abc']);--NULL
select concat_ws(',',ARRAY['abc',NULL,NULL,'xyz']); -- abc,xyz
select concat_ws(',',ARRAY['hello','world']); -- hello,world
```

- decode(binary bin, string charset) →varchar

  描述：根据给定的字符集将第一个参数编码为字符串，支持的字符集包括（'UTF-8', 'UTF-16BE', 'UTF-16LE', 'UTF-16'），当第一个参数为 null，将返回 null。

```
select decode(X'70 61 6e 64 61','UTF-8');
 _col0
-------
 panda
(1 row)

select decode(X'00 70 00 61 00 6e 00 64 00 61','UTF-16BE');
 _col0
-------
 panda
(1 row)
```

- encode(string str, string charset) →binary

  描述：字符串按照给定的字符集进行编码。

```
select encode('panda','UTF-8');
    _col0
----------------
 70 61 6e 64 61
(1 row)
```

- find_in_set (string str, string strList) →int

  描述：返回 str 在逗号分隔的 strList 中第一次出现的位置。当有参数为 null 时，返回值也为 null。

```
select find_in_set('ab', 'abc,b,ab,c,def'); -- 3
```

- format_number(number x, int d) →string

  描述：将数字 x 格式化为'#,###,###.##'，保留 d 位小数，以字符串的形式返回结果。

```
select format_number(541211.212,2); -- 541,211.21
```

- format(format,args...) → varchar

  描述：参见 Format。

- locate(string substr, string str, int pos]) →int

  描述：返回子串在字符串的第 pos 位后第一次出现的位置。没有满足条件的返回 0。

```
select locate('aaa','bbaaaaa',6);-- 0
select locate('aaa','bbaaaaa',1);-- 3
select locate('aaa','bbaaaaa',4);-- 4
```

- length(string) → bigint

描述：返回字符串的长度。

```
select length('hello');-- 5
```

- levenshtein_distance(string1, string2) → bigint

  描述：计算 string1 和 string2 的 Levenshtein 距离，即将 string 转为 string2 所需要的单字符编辑（包括插入、删除或替换）最少次数。

```
select levenshtein_distance('helo word','hello,world'); -- 3
```

- hamming_distance(*string1*, *string2*) → bigint

  描述：返回字符串 1 和字符串 2 的汉明距离，即对应位置字符不同的数量。 请注意，两个字符串的长度必须相同。

```
select hamming_distance('abcde','edcba');-- 4
```

- instr(string,substring) → bigint

  描述：查找 substring 在 string 中首次出现的位置。

```
select instr('abcde', 'cd');--3
```

- levenshtein(*string1*, *string2*) → bigint 参考 levenshtein_distance(*string1*, *string2*)
- levenshtein_distance(*string1*, *string2*) → bigint

  描述：返回字符串 1 和字符串 2 的 Levenshtein 编辑距离，即将字符串 1 更改为字符串 2 所需的最小单字符编辑（插入，删除或替换）次数。

```
select levenshtein_distance('apple','epplea');-- 2
```

- lower(string) → varchar

  描述：将字符转换为小写。

```
select lower('HELLo!');-- hello!
```

- lcase(string A) → varchar

  描述：同 lower(string)。

- ltrim(string) → varchar

  描述：去掉字符串开头的空格。

```
select ltrim('   hello');-- hello
```

- lpad(*string*, *size*, *padstring*) → varchar

  描述：右填充字符串以使用 padstring 调整字符大小。如果 size 小于字符串的长度，则结果将被截断为 size 个字符。大小不能为负，并且填充字符串必须为非空。

```
select lpad('myk',5,'dog'); -- domyk
```

- luhn_check(string) → boolean

  描述：根据 Luhn 算法测试数字字符串是否有效。

  这种校验和函数，也称为模 10，广泛应用于信用卡号码和政府身份证号码，以区分有效号码和键入错误、错误的号码。

```
select luhn_check('79927398713'); -- true
select luhn_check('79927398714'); -- false
```

- octet_length(string str) → int

  描述：返回用于保存 UTF-8 编码的字符串 str 的字节数。

```
select octet_length('query');--5
```

- parse_url(string urlString, string partToExtract [, string keyToExtract]) →string

  描述：返回 URL 的指定部分。partToExtract 参数有效值包括：HOST、PATH、QUERY、REF、PROTOCOL、AUTHORITY、FILE 和 USERINFO。keyToExtract 为可选参数，用于选取 QUERY 中的 key 对应的值。

```
select parse_url('https://www.example.com/index.html','HOST');
 _col0
----------
 www.example.com
(1 row)

-- 查询 URL 中 QUERY 部分 service 对应的值
select
parse_url('https://www.example.com/query/index.html?name=panda','QUERY','name');
 _col0
-------
 panda
(1 row)
```

- position(*substring IN string*) →bigint

  描述：返回子串在父串中第一次出现的位置

```
select position('ab' in 'sssababa');-- 4
```

- quote(String text) → string

  描述：返回单引号包裹的字符串。不支持含单引号的字符串。

```
select quote('DONT');-- 'DONT'
select quote(NULL);-- NULL
```

- repeat2(string str, int n) → string

  描述：返回 str 重复 n 次获得的字符串。

```
select repeat2('abc',4);
   _col0
--------------
 abcabcabcabc
(1 row)
```

- replace(string, ‘a’) → varchar

  描述：去掉字符串中的 a 字符。

```
select replace('hello','e');-- hllo
```

- replace(string, ‘a’, ‘b’) → varchar

  描述：把字符串中所有的 a 字符 替换为 b。

```
select replace('hello','l','m');-- hemmo
```

- reverse(string) → varchar

  描述：字符串倒序。

```
select reverse('hello');-- olleh
```

- rpad(*string*, *size*, *padstring*) → varchar

  描述：右填充字符串以使用 padstring 调整字符大小。如果 size 小于字符串的长度，则结果将被截断为 size 个字符。大小不能为负，并且填充字符串必须为非空。

```
select rpad('myk',5,'dog'); -- mykdo
```

- rtrim(string) → varchar

  描述：去掉字符串尾部的空格。

```
select rtrim('hello world!   ');-- hello world!
```

- space(int n) → varchar

  描述：返回 n 个空格。

```
select space(4);
 _col0
-------

(1 row)

select length(space(4));
 _col0
-------
     4
(1 row)
```

- split(string, delimiter) → array

  描述：将字符串按限定符（delimiter）分隔为一个 array。

```
select split('a:b:c:d',':');-- [a, b, c, d]
```

- split(string, delimiter, limit) → array

  描述：将字符串按 delimiter 分割为一个 array，元素个数为 limit。最后一个元素包含了最后一个字符串后面所有的字符。Limit 必须是个数字。

```
select split('a:b:c:d',':',2);-- [a, b:c:d]
select split('a:b:c:d',':',4);-- [a, b, c, d]
```

- split_part(string, delimiter, index) → varchar

  描述：将字符串按 delimiter 分隔为一个 array，并取出索引值为 index 的元素。index 从 1 开始，如果 index 超过了数组长度，则返回 null。

```
select split_part('a:b:c:d',':',2); -- b
select split_part('a:b:c:d',':',5); -- NULL
```

- split_to_map (string, entryDelimiter, keyValueDelimiter) → map<varchar, varchar>

  描述：将字符串按 entryDelimiter 分割为 Map 的键值对，而每个键值对又按照 keyValueDelimiter 来区分 Key 和 Value。

```
select split_to_map('li:18,wang:17',',',':');--{wang=17, li=18}
```

- split_to_multimap(string, entryDelimiter, keyValueDelimiter) -> map(varchar, array(varchar)

  描述：将字符串按照 entryDelimiter 和 keyValueDelimiter 分割，返回一个 map，每个 key 对应一个类型为 array 的 value。其中，entryDelimiter 将字符串分割为键值对，keyValueDelimiter 将键值对分割为 Key 和 Value。

```
select split_to_multimap('li:18,wang:17,li:19,wang:18',',',':');--{wang=[17,
18], li=[18, 19]}
```

- strpos(string, substring) → bigint

  描述：返回字符串中第一次出现 substring 的位置。从 1 开始，如果未找到，返回 0。举例：

```
select strpos('hello world!','l'); --3
select strpos('hello world!','da'); --0
```

- str_to_map() 参考 split_to_map()
- substr(string, start) → varchar

  描述：从 start 位置开始截取字符串。

```
select substr('hello world',3);-- llo world
```

- substr(string, start, length) → varchar

  描述：从 start 位置开始截取字符串，截取的长度为 length。

  一般用于截取时间戳格式。

```
Select substr('2019-03-10 10:00:00',1,10); --截取到日 2019-03-10
Select substr('2019-03-10 10:00:00',1,7); --截取到月 2019-03
```

- substring(string, start) → varchar

  参考 substr(string, start)

- substring_index(string A, string delim, int count) → varchar

  描述：当 count 为正数时，返回从左边开始计数的第 count 个分隔符 delim 左边的所有内容。当 count 为负数时，返回从右边开始计数的第 count 个分隔符 delim 右侧的所有内容。

```
select substring_index('one.two.three','.',2);
     _col0
-----------------
 one.two
(1 row)

select substring_index('one.two.three','.',-2);
     _col0
-----------------
 two.three
(1 row)

select substring index('one.two.three','.',0);
  _col0
-------
 NULL
(1 row)
```

- soundex(string A) →varchar

  描述：SOUNDEX 返回由四个字符组成的代码（SOUNDEX）以评估两个字符串在发音时的相似性。规则如下：

表10-76 字符对应规则

字符	对应数字
a、e、h、i、o、u、w、y	0
b、f、p、v	1
c、g、j、k、q、s、x、z	2
d、t	3
l	4

字符	对应数字
m、n	5
r	6

- 提取字符串的首字母作为 soundex 的第一个值。
- 按照上面的字母对应规则，将后面的字母逐个替换为数字。如果有连续的相等的数字，只保留一个，其余的都删除掉，并去除所有的 0。
- 如果结果超过 4 位，取前四位。如果结果不足 4 位向后补 0。

```
select soundex('Miller');
 _col0
-------
 M460
(1 row)
```

- translate(string|char|varchar input, string|char|varchar from, string|char|varchar to) → varchar

  描述：对于 input 字符串，将其中的参数 from 指代字符串替换为参数 to 指代的字符串。三个参数有一个为 NULL，则结果返回 NULL。

```
select translate('aabbcc','bb','BB');
 _col0
--------
 aaBBcc
(1 row)
```

- trim(string) → varchar

  描述：去掉字符串首尾的空格。

```
select trim('  hello world!  ');-- hello world!
```

- btrim(String str1,String str2) → varchar

  描述：从 str1 首尾去掉 str2 中包含的所有字符。

```
select btrim('hello','hlo');-- e
```

- upper(string) → varchar

  描述：将字符串转为大写。

```
select upper('heLLo');-- HELLO
```

- ucase(string A) → varchar

  描述：同 upper(string)。

- base64decode(STRING str)

  描述：对字符串进行 base64 反编码。

```
SELECT to_base64(CAST('hello world' as varbinary));-- aGVsbG8gd29ybGQ=
select base64decode('aGVsbG8gd29ybGQ=');-- hello world
```

- jaro_distance(STRING str1, STRING str2)

  描述：比较两个字符串的相似度。

```
select JARO_DISTANCE('hello', 'hell');-- 0.9333333333333332
```

- FNV_HASH(type v)

描述：计算字符串的 hash 值。

```
select FNV_HASH('hello');-- -6615550055289275125
```

- word_stem(word) → varchar

  描述：返回英语单词的词干。

```
select word_stem('greating');-- great
```

- word_stem(*word*, *lang*) → varchar

  描述：返回指定语种单词中的词干。

```
select word_stem('ultramoderne','fr');-- ultramodern
```

- translate(*source*, *from*, *to*) → varchar

  描述：通过将源字符串中找到的字符替换为目标字符串中的相应字符来返回翻译后的源字符串。如果 from 字符串包含重复项，则仅使用第一个。如果源字符在 from 字符串中不存在，则将复制源字符而不进行翻译。如果在 from 字符串中匹配字符的索引超出了 to 字符串的长度，则将从结果字符串中省略源字符。

```
SELECT translate('abcd', '', ''); -- 'abcd'
SELECT translate('abcd', 'a', 'z'); -- 'zbcd'
SELECT translate('abcda', 'a', 'z'); -- 'zbcdz'
SELECT translate('Palhoça', 'ç','c'); -- 'Palhoca'
SELECT translate('abcd', 'a', ''); -- 'bcd'
SELECT translate('abcd', 'a', 'zy'); -- 'zbcd'
SELECT translate('abcd', 'ac', 'z'); -- 'zbd'
SELECT translate('abcd', 'aac', 'zq'); -- 'zbd'
```

Unicode 函数

- normalize(string) → varchar

  描述：返回 NFC 形式的标准字符串。

```
select normalize('e');
 _col0
-------
 e
(1 row)
```

- normalize(string, form) → varchar

  描述：Unicode 允许你用不同的字节来写相同的字符，例如é和 é，第一个是由 0xC3 0xA9 这两个字节组成的，第二个是由 0x65 0xCC 0x81 这三个字节组成的。

  normalize()将根据参数 form 给定的 Unicode 规范化形式 （包括 NFC、NFD、NFKC、NFKD）返回标准字符串，如未指定参数，默认使用 NFC。

```
select to_utf8('é');
 _col0
-------
 c3 a9
(1 row)

select to_utf8('é');
  _col0
----------
 65 cc 81
(1 row)
```

```
select normalize('é',NFC)=normalize('é',NFC);
 _col0
-------
 true
(1 row)
```

- to_utf8(string) → varbinary

  将字符串编码为 utf8 格式字符串。

```
select to_utf8('panda');
    _col0
----------------
 70 61 6e 64 61
(1 row)
```

- from_utf8(binary) → varchar

  描述：将一个二进制串编码为 UTF-8 格式字符串。无效的 UTF-8 序列将被 Unicode 字符 U+FFFD 替换。

```
select from_utf8(X'70 61 6e 64 61');
 _col0
-------
 panda
(1 row)
```

- from_utf8(binary, replace) → varchar

  描述：将一个二进制串编码为 UTF-8 格式字符串。无效的 UTF-8 序列将被参数 replace 替换。参数 replace 必须为单个字符或空（以免无效字符被移除）。

```
select from_utf8(X'70 61 6e 64 61 b1','!');
 _col0
--------
 panda!
(1 row)
```

10.16.3.10 正则表达式函数

概述

所有的正则表达式函数都使用 Java 样式的语法。但以下情况除外：

- 使用多行模式（通过（？ m）标志启用）时，只有\ n 被识别为行终止符。 此外，不支持（？ d）标志，因此不能使用。
- 大小写区分模式（通过（？ i）标志启用）时，总是以 unicode 的模式去实现。同时，不支持上下文敏感匹配和局部敏感匹配。此外，不支持（？ u）标志。
- 不支持 Surrogate Pair 编码方式。例如，\ uD800 \ uDC00 不被视为 U + 10000，必须将其指定为\ x {10000}。
- 边界字符（\b）无法被正确处理，因为它一个不带基字符的非间距标记。
- \Q 和\E 在字符类（如[A-Z123]）中不受支持，而是作为文本处理。
- 支持 Unicode 字符类（\ p {prop}），但有以下差异：
  - 名称中的所有下划线都必须删除。例如，使用 OldItalic 而不是 Old_Italic
  - 必须直接指定脚本，不能带 Is，script =或 sc =前缀。示例：\ p {Hiragana}
  - 必须使用 In 前缀指定块。不支持 block =和 blk =前缀。示例：\p{Mongolian}

- 必须直接指定类别，而不能带 Is，general_category =或 gc =前缀。示例：\p{L}
- 二进制属性必须直接指定，而不是 Is。示例：\p{NoncharacterCodePoint}

函数

- regexp_count(*string*, *pattern*) → bigint

  描述：返回字符串中 pattern 匹配的次数。

```
SELECT regexp_count('1a 2b 14m', '\s*[a-z]+\s*'); -- 3
```

- regexp_extract_all(string, pattern) -> array(varchar)

  描述：以数组格式返回匹配的所有子串。

```
SELECT regexp_extract_all('1a 2b 14m','\d+');-- [1, 2, 14]
```

- regexp_extract_all(string, pattern, group) -> array(varchar)

  描述：当 pattern 包含多个分组时，用 group 指定返回满足被捕获分组的所有子串。

```
SELECT regexp_extract_all('1a 2b 14m','(\d+)([a-z]+)',2);-- [a, b, m]
```

- regexp_extract(string, pattern) → varchar

  描述：返回与字符串中的正则表达式模式匹配的第一个子字符串。

```
SELECT regexp_extract('1a 2b 14m','\d+');-- 1
```

- regexp_extract(string, pattern, group) → varchar

  描述：当 pattern 包含多个分组时，用 group 指定返回满足被捕获分组的第一个子字符串。

```
SELECT regexp_extract('1a 2b 14m','(\d+)([a-z]+)',2);-- 'a'
```

- regexp_like(string, pattern) → boolean

  描述：验证字符串是否包含满足正则表达式的子串，如果有，返回 true。

```
SELECT regexp_like('1a 2b 14m','\d+b');-- true
```

- regexp_position(string, pattern) → integer

  描述：返回字符串中 pattern 第一次匹配到的索引。没有匹配的项则返回-1。

```
SELECT regexp_position('I have 23 apples, 5 pears and 13 oranges', '\b\d+\b');
-- 8
```

- regexp_position(string, pattern, start) → integer

  描述：返回字符串从 start（含 start）开始 pattern 第一次匹配到的项的索引。没有匹配的项则返回-1。

```
SELECT regexp_position('I have 23 apples, 5 pears and 13 oranges', '\b\d+\b',
5); -- 8
SELECT regexp_position('I have 23 apples, 5 pears and 13 oranges', '\b\d+\b',
12); -- 19
```

- regexp_position(string, pattern, start, occurrence) → integer

  描述：返回字符串中从索引 start（含 start）开始，pattern 第 occurrence 次匹配到的项的索引。没有匹配的项则返回-1。

```
SELECT regexp_position('I have 23 apples, 5 pears and 13
oranges','\b\d+\b',12,1);-- 19
SELECT regexp_position('I have 23 apples, 5 pears and 13
oranges','\b\d+\b',12,2);-- 31
```

```
SELECT regexp_position('I have 23 apples, 5 pears and 13
oranges','\b\d+\b',12,3);-- -1
```

- regexp_replace(string, pattern) → varchar

  描述：从目标字符串中移除满足正则表达式的子串。

```
SELECT regexp_replace('1a 2b 14m','\d+[ab] ');-- '14m'
```

- regexp_replace(string, pattern, replacement) → varchar

  描述：使用 replacement 替换目标字符串中满足正则表达式的子串。如果 replacement 中包含'$'字符，使用'\$' 进行转义。在替换中，可以对编号组使用$g 引用捕获组，对命名组使用${name}引用捕获组。

```
SELECT regexp_replace('1a 2b 14m','(\d+)([ab]) ','3c$2 ');-- '3ca 3cb 14m'
```

- regexp_replace(string, pattern, function) → varchar

  描述：使用 function 替换与字符串中的正则表达式模式匹配的子字符串的每个实例。对于每个匹配，以数组形式传递的捕获组都会调用 lambda 表达式函数。捕获组号从 1 开始；整个匹配没有分组（如果需要，请用括号将整个表达式括起来）。

```
SELECT regexp_replace('new york','(\w)(\w*)',x->upper(x[1])||lower(x[2]));--
'New York'
```

- regexp_split(string, pattern) -> array(varchar)

  描述：使用正则表达式模式拆分字符串并返回一个数组。尾随的空字符串被保留。

```
SELECT regexp_split('1a 2b 14m','\s*[a-z]+\s*');-- [1, 2, 14, ]
```

10.16.3.11 二进制函数和运算符

二进制运算符

|| 运算符执行连接。

二进制函数

- length(binary) → bigint

  返回 binary 的字节长度。

```
select length(x'00141f');-- 3
```

- concat(binary1, ..., binaryN) → varbinary

  将 binary1，binary2，binaryN 串联起来。这个函数返回与 SQL 标准连接符||相同的功能。

```
select concat(X'32335F',x'00141f'); -- 32 33 5f 00 14 1f
```

- to_base64(binary) → varchar

  将 binary 编码为 base64 字符串表示。

```
select to_base64(CAST('hello world' as binary)); -- aGVsbG8gd29ybGQ=
```

- from_base64(string) → varbinary

  将 base64 编码的 string 解码为 varbinary。

```
select from_base64('helloworld'); --  85 e9 65 a3 0a 2b 95
```

- to_base64url(binary) → varchar

使用 URL 安全字符，将 binary 编码为 base64 字符串表示。

```
select to_base64url(x'555555');  -- VVVV
```

- from_base64url(string) → varbinary

  使用 URL 安全字符，将 base64 编码的 string 解码为二进制数据。

```
select from_base64url('helloworld'); --  85 e9 65 a3 0a 2b 95
```

- to_hex(binary) → varchar

  将 binary 编码为 16 进制字符串表示。

```
select to_hex(x'15245F');  --  15245F
```

- from_hex(string) → varbinary

  将 16 进制编码的 string 解码为二进制数据。

```
select from_hex('FFFF'); --  ff ff
```

- to_big_endian_64(*bigint*) → varbinary

  将 bigint 类型的数字编码为 64 位大端补码格式。

```
select to_big_endian_64(1234);
        _col0
-------------------------
 00 00 00 00 00 00 04 d2
(1 row)
```

- from_big_endian_64(*binary*) → bigint

  64 位大端补码格式的二进制解码为 bigint 类型的数字。

```
select from_big_endian_64(x'00 00 00 00 00 00 04 d2');
 _col0
-------
  1234
(1 row)
```

- to_big_endian_32(*integer*) → varbinary

  将 bigint 类型的数字编码为 32 位大端补码格式。

```
select to_big_endian_32(1999);
   _col0
-------------
 00 00 07 cf
(1 row)
```

- from_big_endian_32(*binary*) → integer

  32 位大端补码格式的二进制解码为 bigint 类型的数字。

```
select from_big_endian_32(x'00 00 07 cf');
 _col0
-------
  1999
(1 row)
```

- to_ieee754_32(*real*) → varbinary

  根据 IEEE 754 算法，将单精度浮点数编码为一个 32 位大端字节序的二进制块。

```
select to_ieee754_32(3.14);
   _col0
-------------
```

```
 40 48 f5 c3
(1 row)
```

- from_ieee754_32(*binary*) → real

  对采用 IEEE 754 单精度浮点格式的 32 位大端字节序 binary 进行解码。

```
select from_ieee754_32(x'40 48 f5 c3');
 _col0
-------
  3.14
(1 row)
```

- to_ieee754_64(*double*) → varbinary

  根据 IEEE 754 算法，将双精度浮点数编码为一个 64 位大端字节序的二进制块。

```
select to_ieee754_64(3.14);
 _col0
-------------------------
 40 09 1e b8 51 eb 85 1f
(1 row)
```

- from_ieee754_64(*binary*) → double

  对采用 IEEE 754 单精度浮点格式的 64 位大端字节序 binary 进行解码。

```
 select from_ieee754_64(X'40 09 1e b8 51 eb 85 1f');
 _col0
-------
  3.14
(1 row)
```

- lpad(*binary*, *size*, *padbinary*) → varbinary

  左填充二进制以使用 padbinary 调整字节大小。如果 size 小于二进制文件的长度，则结果将被截断为 size 个字符。size 不能为负，并且 padbinary 不能为空。

```
select lpad(x'15245F', 11,x'15487F') ; -- 15 48 7f 15 48 7f 15 48 15 24 5f
```

- rpad(*binary*, *size*, *padbinary*) → varbinary

  右填充二进制以使用 padbinary 调整字节大小。如果 size 小于二进制文件的长度，则结果将被截断为 size 个字符。size 不能为负，并且 padbinary 不能为空。

```
SELECT rpad(x'15245F', 11,x'15487F'); -- 15 24 5f 15 48 7f 15 48 7f 15 48
```

- crc32(*binary*) → bigint

  计算二进制块的 CRC 32 值。

- md5(*binary*) → varbinary

  计算二进制块的 MD 5 哈希值。

- sha1(*binary*) → varbinary

  计算二进制块的 SHA 1 哈希值。

- sha256(*binary*) → varbinary

  计算二进制块的 SHA 256 哈希值。

- sha512(*binary*) → varbinary

  计算二进制块的 SHA 512 哈希值。

- xxhash64(*binary*) → varbinary

  计算二进制块的 XXHASH 64 哈希值。

- spooky_hash_v2_32(*binary*) → varbinary
  计算二进制块的 32 位 SpookyHashV2 哈希值。
- spooky_hash_v2_64(*binary*) → varbinary
  计算二进制块的 64 位 SpookyHashV2 哈希值。
- hmac_md5(*binary*, *key*) → varbinary
  使用给定的 key 计算二进制块的 HMAC 值（采用 md5）。
- hmac_sha1(*binary*, *key*) → varbinary
  使用给定的 key 计算二进制块的 HMAC 值（采用 sha1）。
- hmac_sha256(*binary*, *key*) → varbinary
  使用给定的 key 计算二进制块的 HMAC 值（采用 sha256）。
- hmac_sha512(*binary*, *key*) → varbinary
  使用给定的 key 计算二进制块的 HMAC 值（采用 sha512）。

须知

CRC32、MD5、SHA1 算法在密码学场景已被攻击者破解，不建议应用于密码学安全场景。

10.16.3.12 Json 函数和运算符

- Cast to JSON

```
SELECT CAST(9223372036854775807 AS JSON); -- JSON '9223372036854775807'
```

- Cast from JSON

```
SELECT CAST(JSON '[1,23,456]' AS ARRAY(INTEGER)); -- [1, 23, 456]
```

JSON 函数

说明

NULL 到 JSON 的转换并不能简单地实现。从独立的 NULL 进行转换将产生一个 SQLNULL，而不是 JSON 'null'。不过，在从包含 NULL 的数组或 Map 进行转换时，生成的 JSON 将包含 NULL。

在从 ROW 转换为 JSON 时，结果是一个 JSON 数组，而不是一个 JSON 对象。这是因为对于 SQL 中的行，位置比名称更重要。

支持从 BOOLEAN、TINYINT、SMALLINT、INTEGER、BIGINT、REAL、DOUBLE 或 VARCHAR 进行转换。当数组的元素类型为支持的类型之一、Map 的键类型是 VARCHAR 且 Map 的值类型是支持的类型之一或行的每个字段类型是支持的类型之一时支持从 ARRAY、MAP 或 ROW 进行转换。下面通过示例展示了转换的行为：

```
SELECT CAST(NULL AS JSON);-- NULL
SELECT CAST(1 AS JSON);-- JSON '1'
SELECT CAST(9223372036854775807 AS JSON);-- JSON '9223372036854775807'
SELECT CAST('abc' AS JSON);-- JSON '"abc"'
SELECT CAST(true AS JSON);-- JSON 'true'
SELECT CAST(1.234 AS JSON);-- JSON '1.234'
SELECT CAST(ARRAY[1, 23, 456] AS JSON);-- JSON '[1,23,456]'
```

```
SELECT CAST(ARRAY[1, NULL, 456] AS JSON);-- JSON '[1,null,456]'
SELECT CAST(ARRAY[ARRAY[1, 23], ARRAY[456]] AS JSON);-- JSON '[[1,23],[456]]'
SELECT CAST(MAP(ARRAY['k1', 'k2', 'k3'], ARRAY[1, 23, 456]) AS JSON);-- JSON '{"
k1":1,"k2":23,"k3":456}'
SELECT CAST(CAST(ROW(123, 'abc', true) AS ROW(v1 BIGINT, v2 VARCHAR, v3 BOOLEAN))
AS JSON);-- JSON '[123,"abc",true]'
```

JSON 转其它类型

```
SELECT CAST(JSON 'null' AS VARCHAR);-- NULL
SELECT CAST(JSON '1' AS INTEGER);-- 1
SELECT CAST(JSON '9223372036854775807' AS BIGINT);-- 9223372036854775807
SELECT CAST(JSON '"abc"' AS VARCHAR);-- abc
SELECT CAST(JSON 'true' AS BOOLEAN);-- true
SELECT CAST(JSON '1.234' AS DOUBLE);-- 1.234
SELECT CAST(JSON '[1,23,456]' AS ARRAY(INTEGER));-- [1, 23, 456]
SELECT CAST(JSON '[1,null,456]' AS ARRAY(INTEGER));-- [1, NULL, 456]
SELECT CAST(JSON '[[1,23],[456]]' AS ARRAY(ARRAY(INTEGER)));-- [[1, 23], [456]]
SELECT CAST(JSON '{"k1":1, "k2":23, "k3":456}' AS MAP(VARCHAR, INTEGER));-- {k1=1,
k2=23, k3=456}
SELECT CAST(JSON '{"v1":123, "v2":"abc","v3":true}' AS ROW(v1 BIGINT, v2 VARCHAR,
v3 BOOLEAN));-- {v1=123, v2=abc, v3=true}
SELECT CAST(JSON '[123, "abc",true]' AS ROW(v1 BIGINT, v2 VARCHAR, v3 BOOLEAN));--
{value1=123, value2=abc, value3=true}
SELECT CAST(JSON'[[1, 23], 456]'AS ARRAY(JSON));-- [JSON '[1,23]', JSON '456']
SELECT CAST(JSON'{"k1": [1, 23], "k2": 456}'AS MAP(VARCHAR,JSON));-- {k1 = JSON
'[1,23]', k2 = JSON '456'}
SELECT CAST(JSON'[null]'AS ARRAY(JSON));-- [JSON 'null']
```

说明

在从 JSON 转换为 ROW 时，支持 JSON 数组和 JSON 对象。

JSON 数组可以具有混合元素类型，JSON Map 可以有混合值类型。这使得在某些情况下无法将其转换为 SQL 数组和 Map。为了解决该问题，HetuEngine 支持对数组和 Map 进行部分转换：

```
SELECT CAST(JSON'[[1, 23], 456]'AS ARRAY(JSON));-- [JSON '[1,23]', JSON '456']
SELECT CAST(JSON'{"k1": [1, 23], "k2": 456}'AS MAP(VARCHAR,JSON));-- {k1 = JSON
'[1,23]', k2 = JSON '456'}
SELECT CAST(JSON'[null]'AS ARRAY(JSON));-- [JSON 'null']
```

- is_json_scalar(json) → boolean

  判断 json 是否为标量（即 JSON 数字、JSON 字符串、true、false 或 null）：

  ```
  select is_json_scalar(json'[1,22]'); -- false
  ```

- json_array_contains(json, value) → boolean

  判断 json 中是否包含某 value

  ```
  select json_array_contains(json '[1,23,44]',23); -- true
  ```

- json_array_get(json_array, index) → json

须知

该函数的语义已被破坏。如果提取的元素是字符串，它将被转换为未正确使用引号括起来的无效 JSON 值（值不会被括在引号中，任何内部引号不会被转义）。建议不要使用该函数。无法在不影响现有用法的情况下修正该函数，可能会在将来的版本中删除该函数。

返回指定索引位置的 json 元素，索引从 0 开始

```
SELECT json_array_get('["a", [3, 9], "c"]', 0); -- JSON 'a' (invalid JSON)
SELECT json_array_get('["a", [3, 9], "c"]', 1); -- JSON '[3,9]'
```

索引页支持负数，表示从最后开始，-1 表示最后一个元素，索引超过实际长度会返回 null

```
SELECT json array get('["c", [3, 9], "a"]', -1); -- JSON 'a' (invalid JSON)
SELECT json_array_get('["c", [3, 9], "a"]', -2); -- JSON '[3,9]'
```

如果指定索引位置的 json 元素不存在，将返回 NULL 值

```
SELECT json_array_get('[]', 0);              -- NULL
SELECT json_array_get('["a", "b", "c"]', 10);  -- NULL
SELECT json_array_get('["c", "b", "a"]', -10); -- NULL
```

- json_array_length(json) → bigint

  返回 json 的长度

```
SELECT json_array_length(json '[1,2,3,4]'); -- 4
SELECT json_array_length('[1, 2, 3]'); -- 3
```

- get_json_object(string json,string json_path)；

  按照 json_path 格式抓取 json 中的信息

```
SELECT get_json_object('{"id": 1, "value":"xxx"}', '$.value');  -- "xxx"
```

- json_extract(json, json_path) → json

  按照 json_path 格式抓取 json 中的信息

```
SELECT json_extract(json '{"id": 1, "value":"xxx"}', '$.value');-- JSON "xxx"
```

- json_extract_scalar(json, json_path) → varchar

  和 json_extract 功能相同，返回值是 varchar

```
SELECT json_extract_scalar(json '{"id": 1, "value": "xxx"}', '$.value'); -- xxx
```

- json_format(json) → varchar

  把 json 值转为序列化的 json 文本，这是 json_parse 的反函数：

```
SELECT JSON_format(json '{"id": 1, "value":"xxx"}'); -- {"id":1, "value":"xxx"}
```

  注意：

  json_format 和 CAST(json AS VARCHAR)具有完全不同的语义。

  json_format 将输入 JSON 值序列化为遵守 7159 标准的 JSON 文本。JSON 值可以是 JSON 对象、JSON 数组、JSON 字符串、JSON 数字、true、false 或 null：

```
SELECT json_format(JSON '{"a": 1, "b": 2}'); -- '{"a":1,"b":2}'
SELECT json_format(JSON '[1, 2, 3]'); -- '[1,2,3]'
SELECT json_format(JSON '"abc"'); -- '"abc"'
SELECT json_format(JSON '42'); -- '42'
SELECT json_format(JSON 'true'); -- 'true'
SELECT json_format(JSON 'null'); -- 'null'
```

CAST(json AS VARCHAR)将 JSON 值转换为对应的 SQL VARCHAR 值。对于 JSON 字符串、JSON 数字、true、false 或 null，转换行为与对应的 SQL 类型相同。JSON 对象和 JSON 数组无法转换为 VARCHAR：

```
SELECT CAST(JSON '{"a": 1, "b": 2}' AS VARCHAR); -- NULL
SELECT CAST(JSON '[1, 2, 3]' AS VARCHAR); -- NULL
SELECT CAST(JSON '"abc"' AS VARCHAR); -- 'abc'; Note the double quote is gone
SELECT CAST(JSON '42' AS VARCHAR); -- '42'
SELECT CAST(JSON 'true' AS VARCHAR); -- 'true'
SELECT CAST(JSON 'null' AS VARCHAR); -- NULL
```

- json_parse(string) → json

  和 json_format(json)功能相反，将 json 格式的字符串转换为 json

  Json_parse 和 json_extract 通常结合使用，用于解析数据表中的 json 字符串

```
select JSON_parse('{"id": 1, "value":"xxx"}'); -- json {"id":1, "value":"xxx"}
```

- json_size(json, json_path) → bigint

  和 json_extract 类似，但是返回的是 json 里的对象个数

```
SELECT json_size('{ "x": {"a": 1, "b": 2} }', '$.x'); => 2
SELECT json_size('{ "x": [1, 2, 3] }', '$.x'); =>3
SELECT json_size('{ "x": {"a": 1, "b": 2} }', '$.x.a'); => 0
```

10.16.3.13 日期、时间函数及运算符

日期时间运算符

运算符	示例	结果
+	date '2012-08-08' + interval '2' day	2012-08-10
+	time '01:00' + interval '3' hour	04:00:00.000
+	timestamp '2012-08-08 01:00' + interval '29' hour	2012-08-09 06:00:00.000
+	timestamp '2012-10-31 01:00' + interval '1' month	2012-11-30 01:00:00.000
+	interval '2' day + interval '3' hour	2 03:00:00.000
+	interval '3' year + interval '5' month	3-5
-	date '2012-08-08' - interval '2' day	2012-08-06
-	time '01:00' - interval '3' hour	22:00:00.000
-	timestamp '2012-08-08 01:00' - interval '29' hour	2012-08-06 20:00:00.000
-	timestamp '2012-10-31 01:00' - interval '1' month	2012-09-30 01:00:00.000
-	interval '2' day - interval '3' hour	1 21:00:00.000
-	interval '3' year - interval '5' month	2-7

时区转换

运算符：AT TIME ZONE，用于设置一个时间戳的时区。

```
SELECT timestamp '2012-10-31 01:00 UTC';-- 2012-10-31 01:00:00.000 UTC
SELECT timestamp '2012-10-31 01:00 UTC' AT TIME ZONE 'Asia/Singapore'; -- 2012-10-30 09:00:00.000 Asia/Singapore
```

日期时间函数

- current_date -> date
  返回当前日期(utc 时区)

  ```
  select current_date; -- 2020-07-25
  ```

- current_time -> time with time zone
  返回当前时间(utc 时区)

  ```
  select current_time;-- 16:58:48.601+08:00
  ```

- current_timestamp -> timestamp with time zone
  返回当前时间戳(当前时区)

  ```
  select current_timestamp; -- 2020-07-25 11:50:27.350 Asia/Singapore
  ```

- current_timezone() → varchar
  返回当前时区

  ```
  select current_timezone();-- Asia/Singapore
  ```

- date(x) → date
  将日期字面量转换成日期类型的变量

  ```
  select date('2020-07-25');-- 2020-07-25
  ```

- from_iso8601_timestamp(string) → timestamp with time zone
  将 ISO 8601 格式的时戳字面量转换成带时区的时戳变量

  ```
  SELECT from_iso8601_timestamp('2020-05-11');-- 2020-05-11 00:00:00.000 Asia/Singapore
  SELECT from_iso8601_timestamp('2020-05-11T11:15:05'); -- 2020-05-11 11:15:05.000 Asia/Singapore
  SELECT from_iso8601_timestamp('2020-05-11T11:15:05.055+01:00');-- 2020-05-11 11:15:05.055 +01:00
  ```

- from_iso8601_date(string) → date
  将 ISO 8601 格式的日期字面量转换成日期类型的变量

  ```
  SELECT from_iso8601_date('2020-05-11');-- 2020-05-11
  SELECT from_iso8601_date('2020-W10');-- 2020-03-02
  SELECT from_iso8601_date('2020-123');-- 2020-05-02
  ```

- from_unixtime(unixtime) → timestamp with time zone
  将 UNIX 时戳转换为时间戳变量（当前时区）

  ```
  Select FROM_UNIXTIME(1.595658735E9); -- 2020-07-25 14:32:15.000 Asia/Singapore
  Select FROM_UNIXTIME(875996580); --1997-10-05 04:23:00.000 Asia/Singapore
  ```

- from_unixtime(unixtime, string) → timestamp with time zone
  将 UNIX 时戳转换成时戳变量，可以带时区选项

```
select from_unixtime(1.595658735E9, 'Asia/Singapore');-- 2020-07-25
14:32:15.000 Asia/Singapore
```

- from_unixtime(unixtime, hours, minutes) → timestamp with time zone

  将 UNIX 时戳转换成带时区的时戳变量，hours 和 minutes 表示时区偏移量

```
select from_unixtime(1.595658735E9, 8, 30);-- 2020-07-25 14:32:15.000 +08:30
```

- localtime -> time

  获取当前时间

```
select localtime;-- 14:16:13.096
```

- localtimestamp -> timestamp

  获取当前时间戳

```
select localtimestamp;-- 2020-07-25 14:17:00.567
```

- months_between(date1, date2) -> double

  返回 date1 和 date2 之间的月数，如果 date1 比 date2 迟，结果就是正数，那么结果就是负数；如果两个日期的日数相同，那么结果就是整数，否则按照每月 31 天以及时分秒的差异来计算小数部分。date1 和 date2 的类型可以是 date，timestamp，也可以是“yyyy-MM-dd”或“yyyy-MM-dd HH:mm:ss”格式的字符串

```
select months_between('2020-02-28 10:30:00', '2021-10-30');-- -20.05040323
select months_between('2021-01-30', '2020-10-30'); -- 3.0
```

- now() → timestamp with time zone

  获取当前时间，current_timestamp 的别名

```
select now();-- 2020-07-25 14:39:39.842 Asia/Singapore
```

- unix_timestamp()

  获取当前 unix 时间戳

```
select unix_timestamp(); -- 1600930503
```

- to_iso8601(x) → varchar

  将 x 转换成 ISO8601 格式的字符串。这里 x 可以是 DATE、TIMESTAMP [with time zone]这几个类型

```
select to_iso8601(date '2020-07-25'); -- 2020-07-25
select to_iso8601(timestamp '2020-07-25 15:22:15.214'); -- 2020-07-
25T15:22:15.214
```

- to_milliseconds(interval) → bigint

  获取当前距当天零时已经过去的毫秒数

```
select to_milliseconds(interval '8' day to second);-- 691200000
```

- to_unixtime(timestamp) → double

  将时间戳转换成 UNIX 时间

```
select to unixtime(cast('2020-07-25 14:32:15.147' as timestamp));--
1.595658735147E9
```

- trunc(string date, string format) →string

  按照 format 格式去截取日期值，支持的格式有：MONTH/MON/MM，YEAR/YYYY/YY, QUARTER/Q

```
select trunc(date '2020-07-08','yy');-- 2020-01-01
select trunc(date '2020-07-08','MM');-- 2020-07-01
```

说明

使用下列 SQL 标准函数时，兼容使用圆括号的方式：

- current_date
- current_time
- current_timestamp
- localtime
- Localtimestamp

如：select current_date();

截取函数

类似于保留几位小数的操作，函数 date_trunc 支持如下单位：

单位	截取后的值
second	2001-08-22 03:04:05.000
minute	2001-08-22 03:04:00.000
hour	2001-08-22 03:00:00.000
day	2001-08-22 00:00:00.000
week	2001-08-20 00:00:00.000
month	2001-08-01 00:00:00.000
quarter	2001-07-01 00:00:00.000
year	2001-01-01 00:00:00.000

上面的例子使用时间戳 2001-08-22 03:04:05.321 作为输入。

date_trunc(unit, x) → [same as input]

返回 x 截取到单位 unit 之后的值。

```
select date_trunc('hour', timestamp '2001-08-22 03:04:05.321'); -- 2001-08-22
03:00:00.000
```

间隔函数

本章中的函数支持如下所列的间隔单位：

单位	描述
second	Seconds
minute	Minutes
hour	Hours
day	Days

单位	描述
week	Weeks
month	Months
quarter	Quarters of a year
year	Years

- date_add(unit, value, timestamp) → [same as input]

  在 timestamp 的基础上加上 value 个 unit。如果想要执行相减的操作，可以通过将 value 赋值为负数来完成。

```
SELECT date_add('second', 86, TIMESTAMP '2020-03-01 00:00:00');-- 2020-03-01 00:01:26
SELECT date_add('hour', 9, TIMESTAMP '2020-03-01 00:00:00');-- 2020-03-01 09:00:00
SELECT date_add('day', -1, TIMESTAMP '2020-03-01 00:00:00 UTC');-- 2020-02-29 00:00:00 UTC
```

- date_diff(unit, timestamp1, timestamp2) → bigint

  返回 timestamp2 - timestamp1 之后的值，该值的表示单位是 unit。

  unit 的值是字符串。例如：‘day’、‘week’、‘year’

```
SELECT date_diff('second', TIMESTAMP '2020-03-01 00:00:00', TIMESTAMP '2020-03-02 00:00:00');-- 86400
SELECT date_diff('hour', TIMESTAMP '2020-03-01 00:00:00 UTC', TIMESTAMP '2020-03-02 00:00:00 UTC');-- 24
SELECT date_diff('day', DATE '2020-03-01', DATE '2020-03-02');-- 1
SELECT date_diff('second', TIMESTAMP '2020-06-01 12:30:45.000', TIMESTAMP '2020-06-02 12:30:45.123');-- 86400
SELECT date_diff('millisecond', TIMESTAMP '2020-06-01 12:30:45.000', TIMESTAMP '2020-06-02 12:30:45.123');-- 86400123
```

- adddate(date, bigint)→ [same as input]

  描述：日期加法。输入的类型可以是 date 或 timestamp，表示对日期做加减，当做减法时，bigint 对应值为负。

```
select ADDDATE(timestamp '2020-07-04 15:22:15.124',-5);-- 2020-06-29 15:22:15.124
select ADDDATE(date '2020-07-24',5); -- 2020-07-29
```

持续时间函数

持续时间可以使用以下单位：

单位	描述
ns	纳秒
us	微秒
ms	毫秒

单位	描述
s	秒
m	分钟
h	小时
d	天

parse_duration(string) → interval

```
SELECT parse_duration('42.8ms'); -- 0 00:00:00.043
SELECT parse_duration('3.81 d'); -- 3 19:26:24.000
SELECT parse_duration('5m'); -- 0 00:05:00.000
```

MySQL 日期函数

在这一章节使用与 MySQL date_parse 和 str_to_date 方法兼容的格式化字符串。

- date_format(timestamp, format) → varchar
  使用 format 格式化 timestamp。
  ```
  select date_format(timestamp '2020-07-22 15:00:15', '%Y/%m/%d');-- 2020/07/22
  ```
- date_parse(string, format) → timestamp
  按 format 格式解析日期字面量。
  ```
  select date_parse('2020/07/20', '%Y/%m/%d');-- 2020-07-20 00:00:00.000
  ```

下面的表格是基于 MySQL 手册列出的，描述了各种格式化描述符：

格式化描述符	描述
%a	对应的星期几（Sun .. Sat）
%b	对应的月份（Jan .. Dec）
%c	对应的月份（1 .. 12）
%D	对应该月的第几天（0th, 1st, 2nd, 3rd, ...）
%d	对应该月的第几天，数字（01 .. 31）（两位，前面会补 0）
%e	对应该月的第几天，数字（1 .. 31）
%f	小数以下的秒（6 digits for printing: 000000 .. 999000; 1 - 9 digits for parsing: 0 .. 999999999）
%H	小时（00 .. 23）
%h	小时（01 .. 12）
%I	小时（01 .. 12）
%i	分钟，数字（00 .. 59）

格式化描述符	描述
%j	一年的第几天（001 .. 366）
%k	小时（0 .. 23）
%l	小时（1 .. 12）
%M	月份名称（January .. December）
%m	月份，数字（01 .. 12）
%p	AM or PM
%r	时间，12 小时制（hh:mm:ss followed by AM or PM）
%S	秒（00 .. 59）
%s	秒（00 .. 59）
%T	时间，24 小时制（hh:mm:ss）
%U	周（00 .. 53）， 星期天是一周的第一天
%u	周（00 .. 53）， 星期一是一周的第一天
%V	周（01 .. 53），星期天是一周的第一天，与%X 配合使用
%v	星期（01 .. 53）， 第一条为星期一，与%X 配合使用
%W	周几（Sunday .. Saturday）
%w	本周的第几天（0 .. 6），星期天是一周的第一天
%X	年份，数字，4 位，第一天为星期日
%x	年份，数字，4 位，第一天为星期一
%Y	年份，数字，4 位
%y	年份，数字，2 位，表示年份范围为[1970, 2069]
%%	表示字符'%'

示例：

```
select date_format(timestamp '2020-07-25 15:04:00.124','一年的第%j 天，%m 月的第%d
天，%p %T %W');
                    _col0
-----------------------------------------------------
 一年的第 207 天，07 月的第 25 天，PM 15:04:00 Saturday
(1 row)
```

说明

这些格式化描述符现在还不支持：%D、%U、%u、%V、%w、%X。

- date_format(timestamp, format) → varchar

使用 format 格式化 timestamp

- date_parse(string, format) → timestamp
  解析时间戳字符串

```
select date_parse('2020/07/20', '%Y/%m/%d');-- 2020-07-20 00:00:00.000
```

Java 日期函数

在这一章节中使用的格式化字符串都是与 Java 的 SimpleDateFormat 样式兼容的。

- format_datetime(timestamp, format) → varchar
  使用 format 格式化 timestamp
- parse_datetime(string, format) → timestamp with time zone
  使用指定的格式，将字符串格式化为 timestamp with time zone

```
select parse_datetime('1960/01/22 03:04', 'yyyy/MM/dd HH:mm');
              _col0
---------------------------------------
 1960-01-22 03:04:00.000 Asia/Shanghai
(1 row)
```

常用提取函数

域	描述
YEAR	year()
QUARTER	quarter()
MONTH	month()
WEEK	week()
DAY	day()
DAY_OF_MONTH	day_of_month()
DAY_OF_WEEK	day_of_week()
DOW	day_of_week()
DAY_OF_YEAR	day_of_year()
DOY	day_of_year()
YEAR_OF_WEEK	year_of_week()
YOW	year_of_week()
HOUR	hour()
MINUTE	minute()
SECOND	second()
TIMEZONE_HOUR	timezone_hour()
TIMEZONE_MINUTE	timezone_minute()

例如：

```
select second(timestamp '2020-02-12 15:32:33.215');-- 33
select timezone_hour(timestamp '2020-02-12 15:32:33.215');-- 8
```

- MONTHNAME(date)

  描述：获取月份名称。

  ```
  SELECT monthname(timestamp '2019-09-09 12:12:12.000');-- SEPTEMBER
  SELECT monthname(date '2019-07-09');--JULY
  ```

- extract(field FROM x) → bigint

  描述：从 x 中返回域，对应的域字段，参照本篇的表格。

  ```
  select extract(YOW FROM timestamp '2020-02-12 15:32:33.215');-- 2020
  select extract(SECOND FROM timestamp '2020-02-12 15:32:33.215');-- 33
  select extract(DOY FROM timestamp '2020-02-12 15:32:33.215');--43
  ```

函数	示例	描述
SECONDS_ADD(TIMESTAMP date, INT seconds)	SELECT seconds_add(timestamp '2019-09-09 12:12:12.000', 10);	给时间以秒为单位进行加法
SECONDS_SUB(TIMESTAMP date, INT seconds)	SELECT seconds_sub(timestamp '2019-09-09 12:12:12.000', 10);	给时间以秒为单位进行减法
MINUTES_ADD(TIMESTAMP date, INT minutes)	SELECT MINUTES_ADD(timestamp '2019-09-09 12:12:12.000', 10);	给时间以分钟为单位进行加法
MINUTES_SUB(TIMESTAMP date, INT minutes)	SELECT MINUTES_SUB(timestamp '2019-09-09 12:12:12.000', 10);	给时间以分钟为单位进行减法
HOURS_ADD(TIMESTAMP date, INT hours)	SELECT HOURS_ADD(timestamp '2019-09-09 12:12:12.000', 1);	给时间以小时为单位进行加法
HOURS_SUB(TIMESTAMP date, INT hours)	SELECT HOURS_SUB(timestamp '2019-09-09 12:12:12.000', 1);	给时间以小时为单位进行减法

- last_day(timestamp) -> date

  描述：根据指定的时间戳返回每个月的最后一天。

  ```
  SELECT last_day(timestamp '2019-09-09 12:12:12.000');--  2019-09-30
  SELECT last_day(date '2019-07-09');--2019-07-31
  ```

- add_months(timestamp) -> [same as input]

  描述：通过将指定的月份增加指定的日期来返回正确的日期。

  ```
  SELECT add_months(timestamp'2019-09-09 00:00:00.000', 11);-- 2020-08-09
  00:00:00.000
  ```

- next_day() (timestamp, string) -> date

  描述：根据指定日期返回指定周几的下一天日期。

  ```
  SELECT next_day(timestamp'2019-09-09 00:00:00.000', 'monday');-- 2019-09-16
  00:00:00.000
  SELECT next_day(date'2019-09-09', 'monday');-- 2019-09-16
  ```

- numtoday(integer) -> BIGINT

  描述：将传递的整数值转换为 day 类型，例如 BIGINT 类型。

```
SELECT numtoday(2);-- 2
```

10.16.3.14 聚合函数

聚合函数对一组值进行运算，最终获得一个单值。

除 count()、count_if()、max_by()、min_by()和 approx_distinct()外，其它聚合函数都忽略空值，并在没有输入行或所有值都为空时返回空值。例如 sum()返回 null 而不是零，并且 avg()在统计时不会包含 null 值。coalesce 函数可用于将 null 转换为零。

聚合函数的子句

- 排序 order by

  有些聚合函数可能会因为输入值的顺序不同而导致产生不同的结果，可以通过在聚合函数中使用 order by 子句来指定此顺序。

```
array_agg(x ORDER BY y DESC);
array_agg(x ORDER BYx,y,z);
```

- 过滤 filter

  使用 filter 关键字可以在聚合的过程中，通过使用 where 的条件表达式来过滤掉不需要的行。所有的聚合函数都支持这个功能。

```
aggregate_function(...) FILTER (WHERE <condition>)
```

示例：

```
--建表
create table fruit (name varchar, price int);
--插入数据
insert into fruit values ('peach',5),('apple',2);
--排序
select array_agg (name order by price) from fruit;-- [apple, peach]
--过滤
select array_agg(name) filter (where price<10) from fruit;-- [peach, apple]
```

常用聚合函数

聚合函数通常作用于数据集（表或视图）的某个具体字段，以下的参数 x，均用于代指该字段。

- arbitrary(x)

  描述：返回类型和 X 一样，返回 X 的任意一个非 null 值。

```
select arbitrary(price) from fruit;-- 5
```

- array_agg(x)

  描述：返回由输入的 x 字段构成的数组，元素类型和输入字段一样。

```
select array_agg(price) from fruit;-- [5,2]
```

- avg(x)

  描述：以 double 类型返回所有输入值的平均值。

```
select avg(price) from fruit;-- 3.5
```

- avg(time interval type)

  描述： 返回所有输入时间间隔的平均长度，返回类型为 interval。

```
select avg(last login) from (values ('admin',interval '0 06:15:30' day to
second),('user1',interval '0 07:15:30' day to second),('user2',interval '0
08:15:30' day to second)) as login log(user,last login);
-- 0 07:15:30.000  假设有日志表记录用户距离上次登录的时间，那么这个结果表明平均登录时间间隔为 0 天 7 小时 15 分钟 30 秒
```

- bool_and(boolean value)

  描述：当每个输入值都是 true，返回 true，否则返回 false。

```
select bool_and(isfruit) from (values ('item1',true),
('item2',false),('item3',true)) as items(item,isfruit);--false
select bool_and(isfruit) from (values ('item1',true),
('item2',true),('item3',true)) as items(item,isfruit);-- true
```

- bool_or(boolean value)

  描述：只要输入值中有为 true 的，返回 true，否则返回 false。

```
select bool_or(isfruit) from (values ('item1',false),
('item2',false),('item3',false)) as items(item,isfruit);-- false
select bool_or(isfruit) from (values ('item1',true),
('item2',false),('item3',false)) as items(item,isfruit); --true
```

- checksum(x)

  描述：返回输入值的检查和，其值不受输入顺序影响，结果类型为 varbinary。

```
select checksum(price) from fruit; -- fb 28 f3 9a 9a fb bf 86
```

- count(*)

  描述：返回输入记录的条数，结果类型为 bigint。

```
select count(*) from fruit; -- 2
```

- count(x）

  描述：返回输入字段非 null 值的记录条数，结果类型为 bigint。

```
select count(name) from fruit;-- 2
```

- count_if(x)

  描述：类似于 count(CASE WHEN x THEN 1 END)，返回输入值为 true 的记录数，bigint 类型。

```
select count_if(price>7) from fruit;-- 0
```

- every(boolean)

  描述：是 bool_and()的一个别名。

- geometric_mean(x)

  描述：返回输入字段值的几何平均数，double 类型。

```
select geometric_mean(price) from fruit; -- 3.162277660168379
```

- listagg(x, separator) → varchar

  描述：返回由输入值连接的字符串，输入值之间由指定分隔符隔开

  语法：

```
LISTAGG( expression [, separator] [ON OVERFLOW overflow_behaviour])   WITHIN
GROUP (ORDER BY sort_item, [...])
```

  如果 separator 未指定， 将默认使用空字符作为分隔符。

```
SELECT listagg(value, ',') WITHIN GROUP (ORDER BY value) csv_value FROM (VALUES
'a', 'c', 'b') t(value);
csv_value
-----------
'a,b,c'
```

当该函数的输出值超过了 1048576 字节时，overflow_behaviour 可以指定这种情况下的行为，默认是抛出一个 Error：

```
SELECT listagg(value, ',' ON OVERFLOW ERROR) WITHIN GROUP (ORDER BY value)
csv_value FROM (VALUES 'a', 'b', 'c') t(value);
```

也可以是当函数输出长度超出 1048576 字节，截断超出非空字符串，并用 TRUNCATE 指定的字符串替代，WITH COUNT 和 WITHOUT COUNT,表示输出结果是否包含计数：

```
SELECT LISTAGG(value, ',' ON OVERFLOW TRUNCATE '.....' WITH COUNT) WITHIN GROUP
(ORDER BY value)FROM (VALUES 'a', 'b', 'c') t(value);
```

listagg 函数也可以用于分组相关的场景，例如：

```
SELECT id, LISTAGG(value, ',') WITHIN GROUP (ORDER BY o) csv_value FROM (VALUES
    (100, 1, 'a'),
    (200, 3, 'c'),
    (200, 2, 'b') ) t(id, o, value)
 GROUP BY id
 ORDER BY id;
 id   | csv_value
 -----+-------------
 100  | a  200 | b,c
```

- max_by(x, y)

  描述：返回与所有输入值中 y 字段的最大值相关联的 x 的值。

```
select max_by(name,price) from fruit; -- peach
```

- max_by(x, y, n)

  描述：返回按 y 降序排列的对应 n 个 x 值。

```
select max_by(name,price,2) from fruit;-- [peach, apple]
```

- min_by(x,y)

  描述：返回与所有输入值中 y 字段的最小值相关联的 x 的值。

```
select min_by(name,price) from fruit;-- apple
```

- min_by(x, y, n)

  描述：返回按 y 升序排列的对应 n 个 x 值。

```
select min_by(name,price,2) from fruit;-- [apple, peach]
```

- max(x)

  描述：返回输入字段 x 的最大值。

```
select max(price) from fruit;-- 5
```

- max(x, n)

  描述：返回输入字段 x 降序排列的前 n 个值。

```
select max(price,2) from fruit; -- [5, 2]
```

- min(x)

  描述：返回输入字段 x 的最小值。

```
select min(price) from fruit;-- 2
```

- min(x, n)

  描述：返回输入字段 x 升序排列的前 n 个值。

```
select min(price,2) from fruit;-- [2, 5]
```

- sum(T, x)

  描述：对输入字段 x 求和，T 为数值类型，如 int，double，interval day to second 等。

```
select sum(price) from fruit;-- 7
```

- regr_avgx(T independent, T dependent) → double

  描述：计算回归线的自变量（expr2）的平均值，去掉了空对（expr1, expr2）后，等于 AVG(expr2)。

```
create table sample_collection(id int,time_cost int,weight decimal(5,2));

insert into sample_collection values
(1,5,86.38),
(2,10,281.17),
(3,15,89.91),
(4,20,17.5),
(5,25,88.76),
(6,30,83.94),
(7,35,44.26),
(8,40,17.4),
(9,45,5.6),
(10,50,145.68);

select regr_avgx(time_cost,weight) from sample_collection;
      _col0
--------------------
 86.06000000000002
(1 row)
```

- regr_avgy(T independent, T dependent) → double

  描述：计算回归线的因变量（expr1）的平均值，去掉了空对（expr1, expr2）后，等于 AVG(expr1)。

```
select regr avgy(time cost,weight) from sample collection;
  col0
-------
  27.5
(1 row)
```

- regr_count(T independent, T dependent) → double

  描述：返回用于拟合线性回归线的非空对数。

```
select regr_count(time_cost,weight) from sample_collection;
 _col0
-------
    10
(1 row)
```

- regr_r2(T independent, T dependent) → double

  描述：返回回归的确定系数。

```
select regr_r2(time_cost,weight) from sample_collection;
      _col0
```

```
--------------------
 0.1446739237728169
(1 row)
```

- regr_sxx(T independent, T dependent) → double

  描述：返回值等于 REGR_COUNT(expr1, expr2) * VAR_POP(expr2)。

```
select regr_sxx(time_cost,weight) from sample_collection;
      _col0
--------------------
 59284.886600000005
(1 row)
```

- regr_sxy(T independent, T dependent) → double

  描述：返回值等于 REGR_COUNT(expr1, expr2) * COVAR_POP(expr1, expr2)。

```
select regr_sxy(time_cost,weight) from sample_collection;
  _col0
----------
 -4205.95
(1 row)
```

- regr_syy(T independent, T dependent) → double

  描述：返回值等于 REGR_COUNT(expr1, expr2) * VAR_POP(expr1)。

```
select regr_syy(time_cost,weight) from sample_collection;
 _col0
--------
 2062.5
(1 row)
```

Bitwise 聚合函数

- bitwise_and_agg(x)

  描述：用补码表示输入字段 x 的按位与，返回类型为 bigint。

```
select bitwise_and_agg(x) from (values (31),(32)) as t(x);-- 0
```

- bitwise_or_agg(x)

  描述：用补码表示输入字段 x 的按位或，返回类型为 bigint。

```
select bitwise_or_agg(x) from (values (31),(32)) as t(x);-- 63
```

Map 聚合函数

- histogram(x) -> map(K, bigint)

  描述：返回一个 map，包含了所有输入字段 x 出现的次数。

```
select histogram(x),histogram(y) from (values (15,17),(15,18),(15,19),(15,20))
as t(x,y);-- {15=4},{17=1, 18=1, 19=1, 20=1}
```

- map_agg(key, value) -> map(K, V)

  描述：返回一个由输入字段 key 和输入字段 value 为键值对的 map。

```
select map_agg(name,price) from fruit;-- {apple=2, peach=5}
```

- map_union(x(K, V)) -> map(K, V)

  描述：返回所有输入 map 的并集。如果一个 key 值在输入集中出现多次，对应的 value 取输入集中的 key 对应的任意值。

```
select map_union(x) from (values
(map(array['banana'],array[10.0])),(map(array['apple'],array[7.0]))) as t(x);--
{banana=10.0, apple=7.0}
select map_union(x) from (values
(map(array['banana'],array[10.0])),(map(array['banana'],array[7.0]))) as t(x);-
- {banana=10.0}
```

- multimap_agg(key, value) -> map(K, array(V))

  描述：返回一个由输入 key、value 键值对组成的多重映射 map。每个 key 可以对应多个 value。

```
select multimap_agg(key, value) from (values
('apple',7),('apple',8),('apple',8),('lemon',5) ) as t(key,value); - {apple=[7,
8, 8], lemon=[5]}
```

近似值聚合函数

在实际情况下，对大量数据进行统计时，有时只关心一个近似值，而非具体值，比如统计某产品的销量，这种时候，近似值聚合函数就很有用，它使用较少的内存和 CPU 资源，以便可以获取数据结果而不会出现任何问题，例如溢出到磁盘或 CPU 峰值。这对于数十亿行数据运算的需求很有用。

- approx_distinct(x) → bigint

  描述：该函数返回类型为 bigint，它提供了 count(distinct x)的近似计数。如果所有输入都是 null 值，则返回 0。

  此函数所有可能的值相对于正确的值的误差服从近似正态分布，其标准差为 2.3%。它不保证任何特定输入集误差的上限。

```
select approx_distinct(price) from fruit; -- 2
```

- approx_distinct(x, e)→ bigint

  描述：该函数返回类型为 bigint，它提供了 count(distinct x)的近似计数。如果所有输入都是 null 值，则返回 0。

  此函数所有可能的值相对于正确的值的误差服从近似正态分布，其标准差应小于 e。它不保证任何特定输入集的误差的上限。

  当前该函数的实现中，e 的取值范围为[0.0040625,0.26000]。

```
select approx_distinct(weight,0.0040625) from sample_collection; -- 10
select approx_distinct(weight,0.26) from sample_collection; -- 8
```

- approx_most_frequent(*buckets*, *value*, *capacity*) → map<[same as value], bigint>

  描述：近似统计出前 buckets 个最频繁出现的元素。函数统计高频值时，采用近似估算的方式使用的内存更少。capacity 值越大，结果越精确，但消耗的内存也更多。该函数的返回结果是一个 map，map 的键值对为高频值及对应的频次。

```
SELECT approx_most_frequent(3, x, 15) FROM (values 'A', 'B', 'A', 'C', 'A', 'B',
'C', 'D', 'E') t(x); --  {A=3, B=2, C=2}
SELECT approx_most_frequent(3, x, 100) FROM (values 1, 2, 1, 3, 1, 2, 3, 4, 5)
t(x); -- {1=3, 2=2, 3=2}
```

说明

分位数，常用的有二分位数，四分位数，十分位数，百分位数等，意味将输入集合均分为对应等份，然后找到大约位于该位置的数值。比如 approx_percentile(x, 0.5)就是找到大约位于 x 值排序后大约 50%位置的值，也就是二分位数。

- approx_percentile(x, percentage)→[same as x]

  描述：根据给定的百分比，返回对应的近似百分位数。这个百分比的值对于所有输入的行来说必须是 0 到 1 之间的一个常量。

```
select approx_percentile(x, 0.5) from ( values (2),(3),(7),(8),(9)) as t(x); --
7
```

- approx_percentile(x, percentages)→ array<[same as x]>

  描述：以给定的百分比数组中的每个百分比，返回所有输入字段 x 值的近似百分位数。这个百分比数组中的每个值对于所有输入的行来说必须是 0 到 1 之间的一个常量。

```
select approx_percentile(x, array[0.1,0.2,0.3,0.5]) from ( values
(2),(3),(7),(8),(9)) as t(x); --[2, 3, 3, 7]
```

- approx_percentile(x, w, percentage)→array<[same as x]>

  描述：按照百分比 percentage，返回所有 x 输入值的近似百分位数。每一项的权重值为 w 且必须为正数。x 设置有效的百分位。percentage 的值必须在 0 到 1 之间，并且所有输入行必须为常量。

```
select approx_percentile(x, 5,array[0.1,0.2,0.3,0.5]) from ( values
(2),(3),(7),(8),(9)) as t(x); --[2, 3, 3, 7]
```

- approx_percentile(x, w, percentage, accuracy) →[same as x]

  描述：按照百分比 percentage，返回所有 x 输入值的近似百分位数。每一项的权重值为 w 且必须为正数。x 设置有效的百分位。percentage 的值必须在 0 到 1 之间，并且所有输入行必须为常量。其中，近似值的最大进度误差由 accuracy 指定。

```
select approx_percentile(x, 5,0.5,0.97) from ( values (2),(3),(7),(8),(9)) as
t(x); --7
```

- approx_percentile(x, w, percentages)→[same as x]

  描述：按照百分比数组中的每个百分比值，返回所有 x 输入值的近似百分位数。每一项的权重值为 w 且必须为正数。x 设置有效的百分位。百分比数组中每个元素值必须在 0 到 1 之间，并且所有输入行必须为常量。

```
select approx_percentile(x,5, array[0.1,0.2,0.3,0.5]) from ( values
(2),(3),(7),(8),(9)) as t(x);  -- [2, 3, 3, 7]
```

说明

以上 approx_percentile 函数也支持同参数集的 percentile_approx 函数。

- numeric_histogram(buckets, value, weight)

  描述：按照 buckets 桶的数量，为所有的 value 计算近似直方图，每一项的宽度使用 weight。本算法大体上基于。

```
Yael Ben-Haim and Elad Tom-Tov, "A streaming parallel decision tree algorithm",
J. Machine Learning Research 11 (2010), pp. 849--872.
```

  buckets 必须是 bigint。value 和 weight 必须是数值类型。

```
select numeric_histogram(20,x,4) from ( values (2),(3),(7),(8),(9)) as t(x);
_col0
-----------------------------------------------
 {2.0=4.0, 3.0=4.0, 7.0=4.0, 8.0=4.0, 9.0=4.0}
(1 row)
```

- numeric_histogram(buckets, value)

  描述：与 numeric_histogram(buckets, value,weight)相比，相当于将 weight 设为 1。

```
select numeric_histogram(20,x) from ( values (2),(3),(7),(8),(9)) as t(x);
_col0
-----------------------------------------------
 {2.0=1.0, 3.0=1.0, 7.0=1.0, 8.0=1.0, 9.0=1.0}
(1 row)
```

统计聚合函数

- corr(y,x)

  描述：返回输入值的相关系数。

  ```
  select corr(y,x) from (values (1,5),(2,6),(3,7),(4,8)) as t(x,y);-- 1.0
  ```

- covar_pop(y, x)

  描述：返回输入值的总体协方差。

  ```
  select covar_pop(y,x) from (values (1,5),(2,6),(3,7),(4,8)) as t(x,y); --1.25
  ```

- *covar_samp(y, x)*

  描述：返回输入值的样本协方差。

  ```
  select covar_samp(y,x) from (values (1,5),(2,6),(3,7),(4,8)) as t(x,y);--
  1.6666666
  ```

- kurtosis(*x*)

  描述：峰度又称峰态系数，表征概率密度分布曲线在平均值处峰值高低的特征数，即是描述总体中所有取值分布形态陡缓程度的统计量。直观看来，峰度反映了峰部的尖度。这个统计量需要与正态分布相比较。

  定义上峰度是样本的标准四阶中心矩（standardized 4th central moment)。

  随机变量的峰度计算方法为随机变量的四阶中心矩与方差平方的比值。

  具体计算公式为：

  $$\text{Kurtosis} = \frac{1}{n-1}\sum_{i=1}^{n}(x_i - \bar{x})^4 / \text{SD}^4 - 3$$

  ```
  select kurtosis(x) from (values (1),(2),(3),(4)) as t(x); -- -
  1.1999999999999993
  ```

- regr_intercept(y, x)

  描述：返回输入值的线性回归截距。y 是从属值。x 是独立值。

  ```
  select regr_intercept(y,x) from (values (1,5),(2,6),(3,7),(4,8)) as t(x,y);--
  4.0
  ```

- regr_slope(y, x)

  描述：返回输入值的线性回归斜率。y 是从属值。x 是独立值。

  ```
  select regr_slope(y,x) from (values (1,5),(2,6),(3,7),(4,8)) as t(x,y);--  1.0
  ```

- skewness(x)

  描述：返回所有输入值的偏斜度。

  ```
  select skewness(x) from (values (1),(2),(3),(4)) as t(x); -- 0.0
  ```

- stddev(x)

  描述：stedev_samp()的别名。

- stddev_pop(x)

描述：返回所有输入值的总体标准差。

```
select stddev_pop(x) from (values (1),(2),(3),(4)) as t(x);--
1.1180339887498895
```

- stddev_samp(x)

  描述：返回所有输入值的样本标准偏差。

```
select stddev_samp(x) from (values (1),(2),(3),(4)) as t(x);--
1.2909944487358056
```

- variance(x)

  描述：var_samp()的别名。

- var_pop(x)

  描述：返回所有输入值的总体方差。

```
select var_pop(x) from (values (1),(2),(3),(4)) as t(x);-- 1.25
```

- var_samp(x)

  描述：返回所有输入值的样本方差。

```
select var_samp(x) from (values (1),(2),(3),(4)) as t(x);--  1.6666666666666667
```

Lambda 聚合函数

reduce_agg(*inputValue T*, *initialState S*, *inputFunction(S, T, S)*, *combineFunction(S, S, S)*)

每个非空输入值将调用 inputFunction。除了获取输入值之外，inputFunction 还获取当前状态，最初为 initialState，然后返回新状态。将调用 CombineFunction 将两个状态合并为一个新状态。 返回最终状态。

```
SELECT id, reduce_agg(value, 0, (a, b) -> a + b, (a, b) -> a + b)
FROM (
   VALUES
       (1, 3),
       (1, 4),
       (1, 5),
       (2, 6),
       (2, 7)
) AS t(id, value)
GROUP BY id;
-- (1, 12)
-- (2, 13)

SELECT id, reduce_agg(value, 1, (a, b) -> a * b, (a, b) -> a * b)
FROM (
   VALUES
       (1, 3),
       (1, 4),
       (1, 5),
       (2, 6),
       (2, 7)
) AS t(id, value)
GROUP BY id;
-- (1, 60)
-- (2, 42)
```

说明

状态值必须是 boolean、integer、 floating-point 或 date、time、interval。

10.16.3.15 窗口函数

窗口函数跨查询结果的行执行计算。它们在 HAVING 子句之后但在 ORDER BY 子句之前运行。调用窗口函数需要使用 OVER 子句来指定窗口的特殊语法。窗口具有三个组成部分：

- 分区规范，它将输入行分为不同的分区。这类似于 GROUP BY 子句如何将行分为聚合函数的不同组。
- 排序规范，它确定窗口函数将处理输入行的顺序。
- 窗口框架，指定给定行该功能要处理的行的滑动窗口。如果未指定帧，则默认为“RANGE UNBOUNDED PRECEDING”，与“UNBOUNDEEN PREBODING AND CURRENT ROWGE”相同。该帧包含从分区的开始到当前行的最后一个对等方的所有行。在没有 ORDER BY 的情况下，所有行都被视为对等行，因此未绑定的前导和当前行之间的范围等于未绑定的前导和未绑定的后续之间的范围。

  例如：下面的查询将 salary 表中的信息按照每个部门员工工资的大小进行排序。

```
 --创建数据表并插入数据
create table salary (dept varchar, userid varchar, sal double);
 insert into salary values
('d1','user1',1000),('d1','user2',2000),('d1','user3',3000),('d2','user4',4000)
,('d2','user5',5000);

--数据查询
select dept,userid,sal,rank() over (partition by dept order by sal desc) as rnk
from salary order by dept,rnk;
dept | userid |  sal   | rnk
------|--------|--------|-----
 d1   | user3  | 3000.0 |   1
 d1   | user2  | 2000.0 |   2
 d1   | user1  | 1000.0 |   3
 d2   | user5  | 5000.0 |   1
 d2   | user4  | 4000.0 |   2
```

Aggregate Functions

所有的聚合函数都能通过添加 over 子句来当做窗口函数使用。聚合函数将在当前窗口框架下的每行记录进行运算。

下面的查询生成每个职员按天计算的订单价格的滚动总和。

```
select dept,userid,sal,sum(sal) over (partition by dept order by sal desc) as
rolling_sum from salary order by dept,userid,sal;
dept | userid |  sal   | rolling_sum
------|--------|--------|-------------
 d1   | user1  | 1000.0 |      6000.0
 d1   | user2  | 2000.0 |      5000.0
 d1   | user3  | 3000.0 |      3000.0
 d2   | user4  | 4000.0 |      9000.0
 d2   | user5  | 5000.0 |      5000.0
(5 rows)
```

Ranking Functions

- cume_dist()→ bigint

  描述：小于等于当前值的行数/分组内总行数 - 比如，统计小于等于当前薪水的人数，所占总人数的比例。

```
 --查询示例
SELECT dept, userid, sal, CUME_DIST() OVER(ORDER BY sal) AS rn1, CUME_DIST()
OVER(PARTITION BY dept ORDER BY sal) AS rn2 FROM salary;
dept | userid |  sal   | rn1 |       rn2
------|--------|--------|-----|--------------------
 d2   | user4  | 4000.0 | 0.8 |             0.5
 d2   | user5  | 5000.0 | 1.0 |             1.0
 d1   | user1  | 1000.0 | 0.2 | 0.3333333333333333
 d1   | user2  | 2000.0 | 0.4 | 0.6666666666666666
 d1   | user3  | 3000.0 | 0.6 |             1.0
(5 rows)
```

- dense_rank()→ bigint

  描述：返回值在一组值中的排名。这与 rank（）相似，不同的是 tie 值不会在序列中产生间隙。

- ntile(*n*)→ bigint

  描述：用于将分组数据按照顺序切分成 n 片，返回当前切片值。NTILE 不支持 ROWS BETWEEN，比如 NTILE(2) OVER(PARTITION BY cookieid ORDER BY createtime ROWS BETWEEN 3 PRECEDING AND CURRENT ROW)如果切片不均匀，默认增加第一个切片的分布。

```
--创建表并插入数据
create table cookies_log (cookieid varchar,createtime  date,pv int);
insert into cookies_log values
    ('cookie1',date '2020-07-10',1),
    ('cookie1',date '2020-07-11',5),
    ('cookie1',date '2020-07-12',7),
    ('cookie1',date '2020-07-13',3),
    ('cookie1',date '2020-07-14',2),
    ('cookie1',date '2020-07-15',4),
    ('cookie1',date '2020-07-16',4),
    ('cookie2',date '2020-07-10',2),
    ('cookie2',date '2020-07-11',3),
    ('cookie2',date '2020-07-12',5),
      ('cookie2',date '2020-07-13',6),
      ('cookie2',date '2020-07-14',3),
      ('cookie2',date '2020-07-15',9),
    ('cookie2',date '2020-07-16',7);
-- 查询结果
SELECT cookieid,createtime,pv,
NTILE(2) OVER(PARTITION BY cookieid ORDER BY createtime) AS rn1,  --分组内将数据分成 2 片
NTILE(3) OVER(PARTITION BY cookieid ORDER BY createtime) AS rn2,  --分组内将数据分成 3 片
NTILE(4) OVER(ORDER BY createtime) AS rn3   --将所有数据分成 4 片
FROM cookies_log
ORDER BY cookieid,createtime;
cookieid  | createtime | pv | rn1 | rn2 | rn3
----------|------------|----|-----|-----|-----
```

```
 cookie1  | 2020-07-10 |  1 |   1 |   1 |   1
 cookie1  | 2020-07-11 |  5 |   1 |   1 |   1
 cookie1  | 2020-07-12 |  7 |   1 |   1 |   2
 cookie1  | 2020-07-13 |  3 |   1 |   2 |   2
 cookie1  | 2020-07-14 |  2 |   2 |   2 |   3
 cookie1  | 2020-07-15 |  4 |   2 |   3 |   4
 cookie1  | 2020-07-16 |  4 |   2 |   3 |   4
 cookie2  | 2020-07-10 |  2 |   1 |   1 |   1
 cookie2  | 2020-07-11 |  3 |   1 |   1 |   1
 cookie2  | 2020-07-12 |  5 |   1 |   1 |   2
 cookie2  | 2020-07-13 |  6 |   1 |   2 |   2
 cookie2  | 2020-07-14 |  3 |   2 |   2 |   3
 cookie2  | 2020-07-15 |  9 |   2 |   3 |   3
 cookie2  | 2020-07-16 |  7 |   2 |   3 |   4
(14 rows)
```

- percent_rank()→ double

  描述：返回值在一组值中的百分比排名。 结果为（r-1）/（n-1），其中 r 是该行的 rank（），n 是窗口分区中的总行数。

```
SELECT dept,userid,sal,
PERCENT_RANK() OVER(ORDER BY sal) AS rn1,   --分组内
RANK() OVER(ORDER BY sal) AS rn11,         --分组内 RANK 值
SUM(1) OVER(PARTITION BY NULL) AS rn12,     --分组内总行数
PERCENT_RANK() OVER(PARTITION BY dept ORDER BY sal) AS rn2
from salary;
 dept | userid |  sal   | rn1  | rn11 | rn12 | rn2
------|--------|--------|------|------|------|-----
 d2   | user4  | 4000.0 | 0.75 |    4 |    5 | 0.0
 d2   | user5  | 5000.0 |  1.0 |    5 |    5 | 1.0
 d1   | user1  | 1000.0 |  0.0 |    1 |    5 | 0.0
 d1   | user2  | 2000.0 | 0.25 |    2 |    5 | 0.5
 d1   | user3  | 3000.0 |  0.5 |    3 |    5 | 1.0
(5 rows)
```

- rank()→ bigint

  描述：返回值在一组值中的排名。等级为 1 加上该行之前与该行不对等的行数。因此，排序中的平局值将在序列中产生缺口。对每个窗口分区执行排名。

```
SELECT
cookieid,
createtime,
pv,
RANK() OVER(PARTITION BY cookieid ORDER BY pv desc) AS rn1,
DENSE_RANK() OVER(PARTITION BY cookieid ORDER BY pv desc) AS rn2,
ROW_NUMBER() OVER(PARTITION BY cookieid ORDER BY pv DESC) AS rn3
FROM cookies_log
WHERE cookieid = 'cookie1';
 cookieid | createtime | pv | rn1 | rn2 | rn3
----------|------------|----|-----|-----|-----
 cookie1  | 2020-07-12 |  7 |   1 |   1 |   1
 cookie1  | 2020-07-11 |  5 |   2 |   2 |   2
 cookie1  | 2020-07-15 |  4 |   3 |   3 |   3
 cookie1  | 2020-07-16 |  4 |   3 |   3 |   4
 cookie1  | 2020-07-13 |  3 |   5 |   4 |   5
 cookie1  | 2020-07-14 |  2 |   6 |   5 |   6
```

```
 cookie1  | 2020-07-10 |  1 |   7 |   6 |   7
(7 rows)
```

- row_number()→ bigint

  描述：从 1 开始，按照顺序，生成分组内记录的序列 - 比如，按照 pv 降序排列，生成分组内每天的 pv 名次 ROW_NUMBER() 的应用场景非常多，再比如，获取分组内排序第一的记录。获取一个 session 中的第一条 refer 等。

```
SELECT cookieid, createtime, pv, ROW_NUMBER() OVER(PARTITION BY cookieid ORDER
BY pv desc) AS rn from cookies_log;
  cookieid | createtime | pv | rn
 ----------|-------------- |----|----
 cookie2  | 2020-07-15 |  9 |  1
 cookie2  | 2020-07-16 |  7 |  2
 cookie2  | 2020-07-13 |  6 |  3
 cookie2  | 2020-07-12 |  5 |  4
 cookie2  | 2020-07-14 |  3 |  5
 cookie2  | 2020-07-11 |  3 |  6
 cookie2  | 2020-07-10 |  2 |  7
 cookie1  | 2020-07-12 |  7 |  1
 cookie1  | 2020-07-11 |  5 |  2
 cookie1  | 2020-07-15 |  4 |  3
 cookie1  | 2020-07-16 |  4 |  4
 cookie1  | 2020-07-13 |  3 |  5
 cookie1  | 2020-07-14 |  2 |  6
 cookie1  | 2020-07-10 |  1 |  7
(14 rows)
```

Value Functions

通常情况下，要重视 null 值。如果指定了 IGNORE NULLS，那么计算中所有包含 x 为 null 值的行都会被排除掉，如果所有行的 x 字段值都是 null 值，将会返回默认值，否则返回 null 值。

```
-- 数据准备
create table cookie_views( cookieid varchar,createtime timestamp,url varchar);
insert into cookie_views values
('cookie1',timestamp '2020-07-10 10:00:02','url20'),
('cookie1',timestamp '2020-07-10 10:00:00','url10'),
('cookie1',timestamp '2020-07-10 10:03:04','url13'),
('cookie1',timestamp '2020-07-10 10:50:05','url60'),
('cookie1',timestamp '2020-07-10 11:00:00','url70'),
('cookie1',timestamp '2020-07-10 10:10:00','url40'),
('cookie1',timestamp '2020-07-10 10:50:01','url50'),
('cookie2',timestamp '2020-07-10 10:00:02','url23'),
('cookie2',timestamp '2020-07-10 10:00:00','url11'),
('cookie2',timestamp '2020-07-10 10:03:04','url33'),
('cookie2',timestamp '2020-07-10 10:50:05','url66'),
('cookie2',timestamp '2020-07-10 11:00:00','url77'),
('cookie2',timestamp '2020-07-10 10:10:00','url47'),
('cookie2',timestamp '2020-07-10 10:50:01','url55');
```

- first_value(*x*)→ [same as input]

  描述：返回窗口的第一个值。

```
SELECT cookieid,
createtime,
url,
ROW_NUMBER() OVER(PARTITION BY cookieid ORDER BY createtime) AS rn,
FIRST_VALUE(url) OVER(PARTITION BY cookieid ORDER BY createtime) AS first1
FROM cookie_views;
cookieid |      createtime       |  url  | rn | first1
----------|-------------------------|-------|----|--------
 cookie1  | 2020-07-10 10:00:00.000 | url10 |  1 | url10
 cookie1  | 2020-07-10 10:00:02.000 | url20 |  2 | url10
 cookie1  | 2020-07-10 10:03:04.000 | url13 |  3 | url10
 cookie1  | 2020-07-10 10:10:00.000 | url40 |  4 | url10
 cookie1  | 2020-07-10 10:50:01.000 | url50 |  5 | url10
 cookie1  | 2020-07-10 10:50:05.000 | url60 |  6 | url10
 cookie1  | 2020-07-10 11:00:00.000 | url70 |  7 | url10
 cookie2  | 2020-07-10 10:00:00.000 | url11 |  1 | url11
 cookie2  | 2020-07-10 10:00:02.000 | url23 |  2 | url11
 cookie2  | 2020-07-10 10:03:04.000 | url33 |  3 | url11
 cookie2  | 2020-07-10 10:10:00.000 | url47 |  4 | url11
 cookie2  | 2020-07-10 10:50:01.000 | url55 |  5 | url11
 cookie2  | 2020-07-10 10:50:05.000 | url66 |  6 | url11
 cookie2  | 2020-07-10 11:00:00.000 | url77 |  7 | url11
(14 rows)
```

- last_value(*x*)→ [same as input]

  描述：返回窗口的最后一个值。

```
SELECT cookieid,createtime,url,
ROW NUMBER() OVER(PARTITION BY cookieid ORDER BY createtime) AS rn,
LAST_VALUE(url) OVER(PARTITION BY cookieid ORDER BY createtime) AS last1
FROM cookie_views;
 cookieid |      createtime       |  url  | rn | last1
----------|-------------------------|-------|----|-------
 cookie2  | 2020-07-10 10:00:00.000 | url11 |  1 | url11
 cookie2  | 2020-07-10 10:00:02.000 | url23 |  2 | url23
 cookie2  | 2020-07-10 10:03:04.000 | url33 |  3 | url33
 cookie2  | 2020-07-10 10:10:00.000 | url47 |  4 | url47
 cookie2  | 2020-07-10 10:50:01.000 | url55 |  5 | url55
 cookie2  | 2020-07-10 10:50:05.000 | url66 |  6 | url66
 cookie2  | 2020-07-10 11:00:00.000 | url77 |  7 | url77
 cookie1  | 2020-07-10 10:00:00.000 | url10 |  1 | url10
 cookie1  | 2020-07-10 10:00:02.000 | url20 |  2 | url20
 cookie1  | 2020-07-10 10:03:04.000 | url13 |  3 | url13
 cookie1  | 2020-07-10 10:10:00.000 | url40 |  4 | url40
 cookie1  | 2020-07-10 10:50:01.000 | url50 |  5 | url50
 cookie1  | 2020-07-10 10:50:05.000 | url60 |  6 | url60
 cookie1  | 2020-07-10 11:00:00.000 | url70 |  7 | url70
(14 rows)
```

- nth_value(*x*, *offset*)→ [same as input]

  描述：返回距窗口开头指定偏移量的值。偏移量从 1 开始。偏移量可以是任何标量表达式。如果偏移量为 null 或大于窗口中的值数，则返回 null。偏移量不允许为 0 或者负数。

```
SELECT cookieid,createtime,url,
ROW_NUMBER() OVER(PARTITION BY cookieid ORDER BY createtime) AS rn,
NTH_VALUE(url,3) OVER(PARTITION BY cookieid ORDER BY createtime) AS last1
```

```
FROM cookie_views;
cookieid |      createtime       | url  | rn | last1
----------|-----------------------|-------|----|-------
 cookie1  | 2020-07-10 10:00:00.000 | url10 |  1 | NULL
 cookie1  | 2020-07-10 10:00:02.000 | url20 |  2 | NULL
 cookie1  | 2020-07-10 10:03:04.000 | url13 |  3 | url13
 cookie1  | 2020-07-10 10:10:00.000 | url40 |  4 | url13
 cookie1  | 2020-07-10 10:50:01.000 | url50 |  5 | url13
 cookie1  | 2020-07-10 10:50:05.000 | url60 |  6 | url13
 cookie1  | 2020-07-10 11:00:00.000 | url70 |  7 | url13
 cookie2  | 2020-07-10 10:00:00.000 | url11 |  1 | NULL
 cookie2  | 2020-07-10 10:00:02.000 | url23 |  2 | NULL
 cookie2  | 2020-07-10 10:03:04.000 | url33 |  3 | url33
 cookie2  | 2020-07-10 10:10:00.000 | url47 |  4 | url33
 cookie2  | 2020-07-10 10:50:01.000 | url55 |  5 | url33
 cookie2  | 2020-07-10 10:50:05.000 | url66 |  6 | url33
 cookie2  | 2020-07-10 11:00:00.000 | url77 |  7 | url33
(14 rows)
```

- lead(*x*[, *offset*[, *default_value*]])→ [same as input]

  描述：返回窗口分区中当前行之后的偏移行处的值。偏移量从 0 开始，即当前行。偏移量可以是任何标量表达式。默认偏移量为 1。如果偏移量为 null，则返回 null。如果偏移量指向不在分区内的行，则返回 default_value，或者如果未指定，则返回 null。lead（）函数要求指定窗口顺序。不得指定窗框。

```
SELECT cookieid,createtime,url,
ROW_NUMBER() OVER(PARTITION BY cookieid ORDER BY createtime) AS rn,
LEAD(createtime,1,timestamp '2020-01-01 00:00:00') OVER(PARTITION BY cookieid
ORDER BY createtime) AS next_1_time,
LEAD(createtime,2) OVER(PARTITION BY cookieid ORDER BY createtime) AS
next_2_time
FROM cookie_views;
 cookieid |      createtime       | url  | rn |      next_1_time      |
next_2_time
----------|-----------------------|-------|----|-----------------------|---
----------------------
 cookie2  | 2020-07-10 10:00:00.000 | url11 |  1 | 2020-07-10 10:00:02.000 |
2020-07-10 10:03:04.000
 cookie2  | 2020-07-10 10:00:02.000 | url23 |  2 | 2020-07-10 10:03:04.000 |
2020-07-10 10:10:00.000
 cookie2  | 2020-07-10 10:03:04.000 | url33 |  3 | 2020-07-10 10:10:00.000 |
2020-07-10 10:50:01.000
 cookie2  | 2020-07-10 10:10:00.000 | url47 |  4 | 2020-07-10 10:50:01.000 |
2020-07-10 10:50:05.000
 cookie2  | 2020-07-10 10:50:01.000 | url55 |  5 | 2020-07-10 10:50:05.000 |
2020-07-10 11:00:00.000
 cookie2  | 2020-07-10 10:50:05.000 | url66 |  6 | 2020-07-10 11:00:00.000 |
NULL
 cookie2  | 2020-07-10 11:00:00.000 | url77 |  7 | 2020-01-01 00:00:00.000 |
NULL
 cookie1  | 2020-07-10 10:00:00.000 | url10 |  1 | 2020-07-10 10:00:02.000 |
2020-07-10 10:03:04.000
 cookie1  | 2020-07-10 10:00:02.000 | url20 |  2 | 2020-07-10 10:03:04.000 |
2020-07-10 10:10:00.000
 cookie1  | 2020-07-10 10:03:04.000 | url13 |  3 | 2020-07-10 10:10:00.000 |
2020-07-10 10:50:01.000
```

```
 cookie1  | 2020-07-10 10:10:00.000 | url40 |  4 | 2020-07-10 10:50:01.000 |
2020-07-10 10:50:05.000
 cookie1  | 2020-07-10 10:50:01.000 | url50 |  5 | 2020-07-10 10:50:05.000 |
2020-07-10 11:00:00.000
 cookie1  | 2020-07-10 10:50:05.000 | url60 |  6 | 2020-07-10 11:00:00.000 |
NULL
 cookie1  | 2020-07-10 11:00:00.000 | url70 |  7 | 2020-01-01 00:00:00.000 |
NULL
(14 rows)
```

- lag(*x*[, *offset*[, *default_value*]])→ [same as input]

  描述：返回窗口分区中当前行之前的偏移行的值，偏移量从 0 开始，即当前行，偏移量可以是任何标量表达式，默认偏移量为 1。如果偏移量为 null，则返回 null。如果偏移量指向不在分区内的行，则返回 default_value。如果未指定，则返回 null。lag（）函数要求指定窗口顺序，不得指定窗框。

```
 SELECT cookieid, createtime, url, ROW_NUMBER() OVER(PARTITION BY cookieid
ORDER BY createtime) AS rn,
   LAG(createtime,1, timestamp '2020-01-01 00:00:00') OVER(PARTITION BY
cookieid ORDER BY createtime)  AS last_1_time,
   LAG(createtime,2) OVER(PARTITION BY cookieid ORDER BY createtime)  AS
last_2_time
    FROM cookie_views;

cookieid |      createtime        | url  | rn |      last_1_time      |
last_2_time
----------|-------------------------|-------|----|-------------------------|---
--------------------
 cookie2  | 2020-07-10 10:00:00.000 | url11 |  1 | 2020-01-01 00:00:00.000 |
NULL
 cookie2  | 2020-07-10 10:00:02.000 | url23 |  2 | 2020-07-10 10:00:00.000 |
NULL
 cookie2  | 2020-07-10 10:03:04.000 | url33 |  3 | 2020-07-10 10:00:02.000 |
2020-07-10 10:00:00.000
 cookie2  | 2020-07-10 10:10:00.000 | url47 |  4 | 2020-07-10 10:03:04.000 |
2020-07-10 10:00:02.000
 cookie2  | 2020-07-10 10:50:01.000 | url55 |  5 | 2020-07-10 10:10:00.000 |
2020-07-10 10:03:04.000
 cookie2  | 2020-07-10 10:50:05.000 | url66 |  6 | 2020-07-10 10:50:01.000 |
2020-07-10 10:10:00.000
 cookie2  | 2020-07-10 11:00:00.000 | url77 |  7 | 2020-07-10 10:50:05.000 |
2020-07-10 10:50:01.000
 cookie1  | 2020-07-10 10:00:00.000 | url10 |  1 | 2020-01-01 00:00:00.000 |
NULL
 cookie1  | 2020-07-10 10:00:02.000 | url20 |  2 | 2020-07-10 10:00:00.000 |
NULL
 cookie1  | 2020-07-10 10:03:04.000 | url13 |  3 | 2020-07-10 10:00:02.000 |
2020-07-10 10:00:00.000
 cookie1  | 2020-07-10 10:10:00.000 | url40 |  4 | 2020-07-10 10:03:04.000 |
2020-07-10 10:00:02.000
 cookie1  | 2020-07-10 10:50:01.000 | url50 |  5 | 2020-07-10 10:10:00.000 |
2020-07-10 10:03:04.000
 cookie1  | 2020-07-10 10:50:05.000 | url60 |  6 | 2020-07-10 10:50:01.000 |
2020-07-10 10:10:00.000
 cookie1  | 2020-07-10 11:00:00.000 | url70 |  7 | 2020-07-10 10:50:05.000 |
```

```
2020-07-10 10:50:01.000
(14 rows)
```

10.16.3.16 数组函数和运算符

下标操作符：[]

描述：下标操作符用于访问数组中的元素，并从 1 开始建立索引。

```
select myarr[5] from (values array [1,4,6,78,8,9],array[2,4,6,8,10,12]) as t(myarr);
 _col0
-------
     8
    10
```

Concatenation Operator : ||

|| 操作符用于将相同类型的数组或数值串联起来。

```
SELECT ARRAY[1] || ARRAY[2];
 _col0
--------
 [1, 2]
(1 row)

SELECT ARRAY[1] || 2;
 _col0
--------
 [1, 2]
(1 row)

SELECT 2 || ARRAY[1];
  col0
--------
 [2, 1]
(1 row)
```

Array 函数

下标运算符: []

下标运算符 [] 用于获取数组中对应位置的值。

```
SELECT ARRAY[5,3,41,6][1] AS first_element; -- 5
```

Concatenation Operator: ||

The || operator is used to concatenate an array with an array or an element of the same type:

```
SELECT ARRAY[1]||ARRAY[2];-- [1, 2]
SELECT ARRAY[1]||2; -- [1, 2]
SELECT 2||ARRAY[1];-- [2, 1]
```

- array_contains(*x*, *element*) → boolean

  描述：如果数组 x 中包含 element，则返回 true。

  ```
  select array_contains (array[1,2,3,34,4],4); -- true
  ```

- all_match(array(T), function(T, boolean)) → boolean

  描述：返回是否数组的所有元素满足给定的断言函数。如果都满足断言函数或者数组为空时，返回 true，如果有一个或者多个元素不满足断言函数，则返回 false。当断言函数对于一个或者多个元素的结果是 NULL 时，返回结果也是 NULL：

```
select all_match(a, x-> true) from (values array[]) t(a); -- true
select all_match(a, x-> x>2) from (values array[4,5,7]) t(a); -- true
select all_match(a, x-> x>2) from (values array[1,5,7]) t(a); -- false
select all_match(a, x-> x>1) from (values array[NULL, NULL ,NULL]) t(a); --NULL
```

- any_match(array(T), function(T, boolean)) → boolean

  描述：返回数组是否存在满足断言的元素。当一个或多个元素满足断言时，返回 true。都不满足断言或者数组为空时，返回 false。当断言函数对于一个或者多个元素的结果是 NULL 时，返回结果也是 NULL：

```
select any_match(a, x-> true) from (values array[]) t(a); -- false
select any_match(a, x-> x>2) from (values array[0,1,2]) t(a); -- false
select any_match(a, x-> x>2) from (values array[1,5,7]) t(a); -- true
select any_match(a, x-> x>1) from (values array[NULL, NULL ,NULL]) t(a); --
NULL
```

- array_distinct(*x*) → array

  描述：输出去重后的数组 x。

```
select  array_distinct(array [1,1,1,1,1,1,3,3,3,33,4,5,6,6,6,6]);--  [1, 3, 33,
4, 5, 6]
```

- array_intersect(*x*, *y*) → array

  描述：返回两个数组去重后的交集。

```
select array_intersect(array [1,3,5,7,9],array [1,2,3,4,5]);
  _col0
-----------
 [1, 3, 5]
(1 row)
```

- array_union(*x*, *y*) → array

  描述：返回两个数组的并集。

```
select array_union(array [1,3,5,7,9],array [1,2,3,4,5]);
       _col0
-----------------------
 [1, 3, 5, 7, 9, 2, 4]
(1 row)
```

- array_except(*x*, *y*) → array

  描述：返回去重后的在 x 中但不在 y 中的元素数组。

```
select array_except(array [1,3,5,7,9],array [1,2,3,4,5]);
 _col0
--------
 [7, 9]
(1 row)
```

- array_join(*x*, *delimiter*, *null_replacement*) → varchar

  描述：使用分隔符来连接给定数组 x 的元素，并用可选字符替换 x 中的 null 值。

```
select array_join(array[1,2,3,null,5,6],'|','0');--  1|2|3|0|5|6
```

- array_max(*x*) → x

描述：返回数组 x 的最大值。

```
select array_max(array[2,54,67,132,45]);  -- 132
```

- array_min(*x*) → x

  描述：返回数组 x 的最小值。

```
select array_min(array[2,54,67,132,45]);  -- 2
```

- array_position(x,element) → bigint

  描述：返回数组 x 中 element 第一次出现的位置，没找到则返回 0。

```
select array_position(array[2,3,4,5,1,2,3],3); -- 2
```

- array_remove(*x*, *element*) → array

  描述：移除数组 x 中的值为 element 的元素并返回。

```
select array_remove(array[2,3,4,5,1,2,3],3); --  [2, 4, 5, 1, 2]
```

- array_sort(*x*) → array

  排序并返回数组 x。 x 的元素必须是可排序的。 空元素将放置在返回数组的末尾。

```
select array_sort(array[2,3,4,5,1,2,3]); -- [1, 2, 2, 3, 3, 4, 5]
```

- array_sort(*array(T)*, *function(T, T, int))*

  描述：根据给定的比较器函数对数组进行排序并返回。比较器将使用两个可为空的参数，表示数组的两个可为空的元素。当第一个可为空的元素小于，等于或大于第二个可为空的元素时，它将返回-1、0 或 1。如果比较器函数返回其他值（包括 NULL），则查询将失败并引发错误。

```
SELECT array_sort(ARRAY [3, 2, 5, 1, 2], (x, y) -> IF(x < y, 1, IF(x = y, 0, -
1)));
 _col0
--------
[5, 3, 2, 2, 1]
(1 row)

SELECT array_sort(ARRAY ['bc', 'ab', 'dc'], (x, y) -> IF(x < y, 1, IF(x = y, 0,
-1)));
 _col0
--------
[dc, bc, ab]
(1 row)

 -- null 值排在前，其余值按降序排列
SELECT array_sort(ARRAY [3, 2, null, 5, null, 1, 2],
               (x, y) -> CASE WHEN x IS NULL THEN -1
                           WHEN y IS NULL THEN 1
                           WHEN x < y THEN 1
                           WHEN x = y THEN 0
                           ELSE -1 END);
  col0
--------
[null, null, 5, 3, 2, 2, 1]
(1 row)

-- null 值在后的降序排列
SELECT array_sort(ARRAY [3, 2, null, 5, null, 1, 2],
```

```
              (x, y) -> CASE WHEN x IS NULL THEN 1
                            WHEN y IS NULL THEN -1
                            WHEN x < y THEN 1
                            WHEN x = y THEN 0
                            ELSE -1 END);
 _col0
--------
[5, 3, 2, 2, 1, null, null]
(1 row)

-- 按字符串长度排序
SELECT array_sort(ARRAY ['a', 'abcd', 'abc'],
               (x, y) -> IF(length(x) < length(y), -1,
                         IF(length(x) = length(y), 0, 1)));
 _col0
--------
[a, abc, abcd]
(1 row)

-- 按数组长度排序
SELECT array_sort(ARRAY [ARRAY[2, 3, 1], ARRAY[4, 2, 1, 4], ARRAY[1, 2]],
               (x, y) -> IF(cardinality(x) < cardinality(y),
                         -1,
                         IF(cardinality(x) = cardinality(y), 0, 1)));
  _col0
--------
[[1, 2], [2, 3, 1], [4, 2, 1, 4]]
(1 row)
```

- arrays_overlap(*x*, *y*)

  描述：如果两个数组有共同的非 null 元素，则返回 true。否则返回 false。

```
select arrays_overlap(array[1,2,3],array[3,4,5]);-- true
select arrays_overlap(array[1,2,3],array[4,5,6]);-- false
```

- cardinality(*x*)

  描述:返回数组 x 的容量。

```
select cardinality(array[1,2,3,4,5,6]); --6
```

- concat(*array1*, *array2*, ..., *arrayN*)

  描述：此函数提供与 sql 标准连接运算符(||)相同的功能。

- combinations(*array(T)*, *n) -> array(array(T)*)

  描述：返回输入数组的 n 个元素子组。 如果输入数组没有重复项，则组合将返回 n 个元素的子集。

```
SELECT combinations(ARRAY['foo', 'bar', 'baz'], 2); -- [[foo, bar], [foo, baz],
[bar, baz]]

SELECT combinations(ARRAY[1, 2, 3], 2); -- [[1, 2], [1, 3], [2, 3]]

SELECT combinations(ARRAY[1, 2, 2], 2); -- [[1, 2], [1, 2], [2, 2]]
```

  子组以及子组中的元素，虽未指明，都是有序的。参数 n 必须不大于 5，且产生的子组个数最大不超过 100000。

- contains(*x*, *element*)

  描述：如果数组 x 中包含 element，则返回 true。

```
select contains(array[1,2,3,34,4],4); -- true
```

- element_at(*array(E)*, *index*)

  描述：返回给定索引处数组的元素。 如果 index> 0，则此函数提供与 SQL 标准下标运算符（[]）相同的功能，但在访问大于数组长度的索引时该函数返回 NULL，且下标运算符在这种情况下将失败。 如果 index <0，则 element_at 从最后到第一个访问元素。

```
select element_at(array['a','b','c','d','e'],3); -- c
```

- filter(*array(T)*, *function(T, boolean)) -> array(T)*

  描述：删选出按函数运算结果为 true 的元素构成的数组。

```
SELECT filter(ARRAY [], x -> true); -- []

SELECT filter(ARRAY [5, -6, NULL, 7], x -> x > 0); -- [5, 7]

SELECT filter(ARRAY [5, NULL, 7, NULL], x -> x IS NOT NULL); -- [5, 7]
```

- flatten(*x*)

  描述：以串联的方式将 array(array(T)) 展开为 array(T)。

- ngrams(*array(T)*, *n) -> array(array(T)*)

  描述：返回数组的 n 元语法（相邻 n 个元素的子序列）。结果中 n 元语法的顺序未指定。

```
SELECT ngrams(ARRAY['foo', 'bar', 'baz', 'foo'], 2); -- [[foo, bar], [bar, baz],
[baz, foo]]

SELECT ngrams(ARRAY['foo', 'bar', 'baz', 'foo'], 3); -- [[foo, bar, baz], [bar,
baz, foo]]

SELECT ngrams(ARRAY['foo', 'bar', 'baz', 'foo'], 4); -- [[foo, bar, baz, foo]]

SELECT ngrams(ARRAY['foo', 'bar', 'baz', 'foo'], 5); -- [[foo, bar, baz, foo]]

SELECT ngrams(ARRAY[1, 2, 3, 4], 2); -- [[1, 2], [2, 3], [3, 4]]
```

- none_match(*array(T)*, *function(T, boolean)*)

  描述：返回数组是否没有元素与给定谓词匹配。如果没有元素与谓词匹配，则返回 true（特殊情况是当数组为空时）。如果一个或多个元素匹配，则为 false；如果谓词函数对一个或多个元素返回 NULL，而对所有其他元素返回 false，则为 NULL。

- reduce(*array(T)*, *initialState S*, *inputFunction(S, T, S)*, *outputFunction(S, R)*)

  返回从数组减少的单个值。将按顺序为数组中的每个元素调用 inputFunction。除了获取元素之外，inputFunction 还获取当前状态，最初为 initialState，然后返回新状态。将调用 outputFunction 将最终状态转换为结果值。它可能是恒等函数（i-> i）。

```
SELECT reduce(ARRAY [], 0, (s, x) -> s + x, s -> s); -- 0
SELECT reduce(ARRAY [5, 20, 50], 0, (s, x) -> s + x, s -> s); -- 75
SELECT reduce(ARRAY [5, 20, NULL, 50], 0, (s, x) -> s + x, s -> s); -- NULL
SELECT reduce(ARRAY [5, 20, NULL, 50], 0, (s, x) -> s + COALESCE(x, 0), s -> s);
-- 75
SELECT reduce(ARRAY [5, 20, NULL, 50], 0, (s, x) -> IF(x IS NULL, s, s + x), s
-> s); -- 75
SELECT reduce(ARRAY [2147483647, 1], CAST (0 AS BIGINT), (s, x) -> s + x, s ->
```

```
s); -- 2147483648
SELECT reduce(ARRAY [5, 6, 10, 20],           CAST(ROW(0.0, 0) AS ROW(sum
DOUBLE, count INTEGER)),

           (s, x) -> CAST(ROW(x + s.sum, s.count + 1) AS ROW(sum DOUBLE, count
INTEGER)),
           s -> IF(s.count = 0, NULL, s.sum / s.count)); -- 10.25
```

- repeat(*element*, *count*)

  描述：将 element 重复输出 count 次，填充到数组中。

```
select repeat(4,5);-- [4, 4, 4, 4, 4]
```

- reverse(*x*)

  描述：以相反顺序将数组元素填充到返回的新数组中。

```
select reverse(array[1,2,3,4,5]); --[5, 4, 3, 2, 1]
```

- sequence(start, *stop)*

  描述：输出一个从 start 开始，到 *stop* 结束的数组。start 不大于 *stop* 时，每次递增 1，否则，每次递减 1。

  start 和 stop 的数据类型还可以是 date 或者 timstamp 类型，按 1 天递增或递减。

```
select sequence(5,1);
     _col0
-----------------
 [5, 4, 3, 2, 1]
(1 row)

select sequence(5,10);
      _col0
---------------------
 [5, 6, 7, 8, 9, 10]
(1 row)
```

- sequence(*start*, *stop*, *step)*→ array

  描述：以步长 step 从 start 输出到 stop。

```
select sequence(1,30,5);--  [1, 6, 11, 16, 21, 26]
```

- shuffle(*x*)→ array

  描述：根据给的数组随机排列获得一个新的数组。

```
select shuffle(array[1,2,3,4,5]);-- [1, 5, 4, 2, 3]
select shuffle(array[1,2,3,4,5]);--  [2, 1, 3, 5, 4]
```

- size(*x*) → bigint

  描述：返回 arrayx 的容量。

```
select size(array[1,2,3,4,5,6]); --6
```

- slice(*x*, *start*, *length*) → array

  描述：子集数组 x 从索引开头开始（如果 start 为负，则从结尾开始），长度为 length。

```
select slice(array[1,2,3,4,5,6],2,3);-- [2, 3, 4]
```

- sort_array(x)

  参考 array_sort(x)。

- trim_array(*x*, *n*) → array

描述：返回数组末尾 n 个元素。

```
SELECT trim_array(ARRAY[1, 2, 3, 4], 1); -- [1, 2, 3]
SELECT trim_array(ARRAY[1, 2, 3, 4], 2); -- [1, 2]
```

- transform(*array(T)*, *function(T, U)) -> array(U*)

  描述：返回一个数组，该数组是将函数应用于数组的每个元素的结果。

```
SELECT transform(ARRAY [], x -> x + 1); -- []
SELECT transform(ARRAY [5, 6], x -> x + 1); -- [6, 7]
SELECT transform(ARRAY [5, NULL, 6], x -> COALESCE(x, 0) + 1); -- [6, 1, 7]
SELECT transform(ARRAY ['x', 'abc', 'z'], x -> x || '0'); -- [x0, abc0, z0]
SELECT transform(ARRAY [ARRAY [1, NULL, 2], ARRAY[3, NULL]], a -> filter(a, x -
> x IS NOT NULL)); -- [[1, 2], [3]]
```

- zip(*array1, array2[, ...]) -> array(row*)

  描述：将给定数组按元素合并到单个行数组中。第 N 个自变量的第 M 个元素将是第 M 个输出元素的第 N 个字段。如果参数长度不均匀，则缺少的值将填充为 NULL。

```
SELECT zip(ARRAY[1, 2], ARRAY['1b', null, '3b']); --  [{1, 1b}, {2, NULL},
{NULL, 3b}]
```

- zip_with(*array(T)*, *array(U)*, *function(T, U, R)) -> array(R*)

  描述：使用函数将两个给定的数组逐个元素合并到单个数组中。如果一个数组较短，则在应用函数之前，将在末尾添加空值以匹配较长数组的长度。

```
SELECT zip_with(ARRAY[1, 3, 5], ARRAY['a', 'b', 'c'], (x, y) -> (y, x)); -- [{a,
1}, {b, 3}, {c, 5}]

SELECT zip_with(ARRAY[1, 2], ARRAY[3, 4], (x, y) -> x + y); -- [4, 6]

SELECT zip_with(ARRAY['a', 'b', 'c'], ARRAY['d', 'e', 'f'], (x, y) -> concat(x,
y)); -- [ad, be, cf]

SELECT zip_with(ARRAY['a'], ARRAY['d', null, 'f'], (x, y) -> coalesce(x, y)); -
- [a, null, f]
```

10.16.3.17 Map 函数和运算符

下表操作符: []

描述：[]运算符用于从映射中检索与给定键对应的值。

```
select age_map['li'] from (values (map(array['li','wang'],array[15,27]))) as
table_age(age_map);-- 15
```

Map 函数

- cardinality(*x*)

  描述：返回 map x 的基数大小。

```
select cardinality(map(array['num1','num2'],array[11,12]));-- 2
```

- element_at(*map(K, V)*, *key*)

  描述：返回 map 中 key 对应值，如果 map 中不包含这个 key，则返回 NULL。

```
select element_at(map(array['num1','num2'],array[11,12]),'num1'); --11
select element_at(map(array['num1','num2'],array[11,12]),'num3');-- NULL
```

- map()
  描述：返回一个空的 map。

```
select map();-- {}
```

- map(*array(K)*, *array(V)) -> map(K, V)*
  描述：根据给定的键值对数组，返回 map。聚合函数中的 map_agg()和 multimap_agg()也同样能用于生成 map。

```
SELECT map(ARRAY[1,3],ARRAY[2,4]);-- {1=2, 3=4}
```

- map_from_entries(*array(row(K, V))) -> map(K, V)*
  描述：使用给定数组生成 map。

```
SELECT map_from_entries(ARRAY[(1, 'x'), (2, 'y')]); --  {1=x, 2=y}
```

- multimap_from_entries(*array(row(K, V))) -> map(K, array(V)*)
  描述：根据给定的 row 数组返回复合 map，每个键可以对应多个值。

```
SELECT multimap_from_entries(ARRAY[(1, 'x'), (2, 'y'), (1, 'z')]); -- {1=[x, z],
2=[y]}
```

- map_entries(*map(K, V)) -> array(row(K, V)*)
  描述：使用给定 map 生成一个 row 数组。

```
SELECT map_entries(MAP(ARRAY[1, 2], ARRAY['x', 'y'])); --  [{1, x}, {2, y}]
```

- map_concat(*map1(K, V)*, *map2(K, V)*, ..., *mapN(K, V))*
  描述：合并多个 map，当 key 值一样时，取最后一个 map 的 value 来构造键值对。如下示例中，a 就使用了最后一个 map 的 value 值 10。

```
select map_concat(map(ARRAY['a','b'],ARRAY[1,2]),map(ARRAY['a', 'c'], ARRAY[10,
20]));
       col0
--------------------
 {a=10, b=2, c=20}
(1 row)
```

- map_filter(*map(K, V)*, *function(K, V, boolean)) -> map(K, V)*
  描述：使用 map 中仅给定函数映射为 true 的 entry 去构造一个新的 map。

```
SELECT map_filter(MAP(ARRAY[], ARRAY[]), (k, v) -> true); -- {}
SELECT map_filter(MAP(ARRAY[10, 20, 30], ARRAY['a', NULL, 'c']), (k, v) -> v IS
NOT NULL); -- {10=a, 30=c}
SELECT map_filter(MAP(ARRAY['k1', 'k2', 'k3'], ARRAY[20, 3, 15]), (k, v) -> v >
10); -- {k3=15, k1=20}
```

- map_keys(*x(K, V)) -> array(K*)
  描述：返回 map 中所有的 key 构造的数组。

```
select map_keys(map(array['num1','num2'],array[11,12])); -- [num1, num2]
```

- map_values(*x(K, V)) -> array(V*)
  描述：返回 map 中所有的 value 构造的数组。

```
select map_values(map(array['num1','num2'],array[11,12]));-- [11, 12]
```

- map_zip_with(*map(K, V1)*, *map(K, V2)*, *function(K, V1, V2, V3))*
  描述：通过将函数应用于具有相同键的一对值，将两个给定的 map 合并为一个 map。对于仅在一个 map 中显示的键，将传递 NULL 作为缺少键的值。

```
SELECT map_zip_with(MAP(ARRAY[1, 2, 3], ARRAY['a', 'b', 'c']), -- {1 -> ad, 2 -
> be, 3 -> cf}
```

```
                MAP(ARRAY[1, 2, 3], ARRAY['d', 'e', 'f']),
                (k, v1, v2) -> concat(v1, v2));
      _col0
--------------------
 {1=ad, 2=be, 3=cf}
(1 row)

SELECT
map_zip_with(MAP(ARRAY['k1','k2'],ARRAY[1,2]),Map(ARRAY['K2','k3'],ARRAY[4,9]),
(k,v1,v2)->(v1,v2));  -- {k3={NULL, 9}, k1={1, NULL}, k2={2, NULL}, K2={NULL,
4}}

                                _col0
--------------------------------------------------------------------------------
{k3={NULL, 9}, k1={1, NULL}, k2={2, NULL}, K2={NULL, 4}}
(1 row)

 SELECT map_zip_with(MAP(ARRAY['a', 'b', 'c'], ARRAY[1, 8, 27]), -- {a -> a1, b
-> b4, c -> c9}
                MAP(ARRAY['a', 'b', 'c'], ARRAY[1, 2, 3]),
                (k, v1, v2) -> k || CAST(v1/v2 AS VARCHAR));
      _col0
--------------------
 {a=a1, b=b4, c=c9}
(1 row)
```

- transform_keys(*map(K1, V)*, *function(K1, V, K2)) -> map(K2, V)*

  描述：对 map 中的每个 entry，将 key 值 K1 映射为新的 key 值 K2，保持对应的 value 不变。

```
SELECT transform_keys(MAP(ARRAY[], ARRAY[]), (k, v) -> k + 1); -- {}

SELECT transform_keys(MAP(ARRAY [1, 2, 3], ARRAY ['a', 'b', 'c']), (k, v) -> k
+ 1); -- {2=a, 3=b, 4=c}

SELECT transform_keys(MAP(ARRAY ['a', 'b', 'c'], ARRAY [1, 2, 3]), (k, v) -> v
* v); -- {1=1, 9=3, 4=2}

SELECT transform_keys(MAP(ARRAY ['a', 'b'], ARRAY [1, 2]), (k, v) -> k ||
CAST(v as VARCHAR)); --  {a1=1, b2=2}

SELECT transform_keys(MAP(ARRAY [1, 2], ARRAY [1.0, 1.4]), (k, v) ->
MAP(ARRAY[1, 2], ARRAY['one', 'two'])[k]); -- {two=1.4, one=1.0}
```

- size(*x*) → bigint

  描述：返回 Map(x) 的容量。

```
select size(map(array['num1','num2'],array[11,12])); --2
```

- transform_values(*map(K, V1)*, *function(K, V2, V2)) -> map(K, V2)*

  描述：对 map 中的每个 entry，将 value 值 V1 映射为新的 value 值 V2，保持对应的 key 不变。

```
SELECT transform_values(MAP(ARRAY[], ARRAY[]), (k, v) -> v + 1); -- {}

SELECT transform_values(MAP(ARRAY [1, 2, 3], ARRAY [10, 20, 30]), (k, v) -> v +
k); -- {1=11, 2=22, 3=33}
```

```
SELECT transform_values(MAP(ARRAY [1, 2, 3], ARRAY ['a', 'b', 'c']), (k, v) ->
k * k); -- {1=1, 2=4, 3=9}

SELECT transform_values(MAP(ARRAY ['a', 'b'], ARRAY [1, 2]), (k, v) -> k ||
CAST(v as VARCHAR)); --  {a=a1, b=b2}

SELECT transform_values(MAP(ARRAY [1, 2], ARRAY [1.0, 1.4]),(k, v) ->
MAP(ARRAY[1, 2], ARRAY['one', 'two'])[k] || '_' || CAST(v AS VARCHAR)); --
{1=one_1.0, 2=two_1.4}
```

10.16.3.18 URL 函数

提取函数

描述：提取函数用于从 HTTP URL（或任何符合 RFC 2396 标准的 URL）中提取内容。

```
[protocol:][//host[:port]][path][?query][#fragment]
```

提取的内容不会包含 URI 的语法分割符，比如“：”或“？”。

- url_extract_fragment(*url*) → varchar
  描述：返回 url 的片段标识符，即#后面的字符串。

  ```
  select
  url_extract_fragment('http://www.example.com:80/stu/index.html?name=xxx&age=25#
  teacher');--teacher
  ```

- url_extract_host(url)→ varchar
  描述：返回 url 中的主机域名。

  ```
   select
  url_extract_host('http://www.example.com:80/stu/index.html?name=xxx&age=25#teac
  her');-- www.example.com
  ```

- url_extract_parameter(*url*, *name*)→ varchar
  描述：返回 url 中参数名为 name 的参数。

  ```
  select
  url_extract_parameter('http://www.example.com:80/stu/index.html?name=xxx&age=25
  #teacher','age');-- 25
  ```

- url_extract_path(*url*)→ varchar
  描述：提取 url 中的路径。

  ```
   select
  url_extract_path('http://www.example.com:80/stu/index.html?name=xxx&age=25#teac
  her');-- /stu/index.html
  ```

- url_extract_port(*url*)→ bigint
  描述：提取 url 中的端口。

  ```
  select
  url_extract_port('http://www.example.com:80/stu/index.html?name=xxx&age=25#teac
  her');-- 80
  ```

- url_extract_protocol(*url*)→ varchar
  描述：提取 url 中的协议。

```
select
url_extract_protocol('http://www.example.com:80/stu/index.html?name=xxx&age=25#teacher'); -- http
```

- url_extract_query(*url*)→ varchar

  描述：提取 url 中的查询字符串。

```
select
url_extract_query('http://www.example.com:80/stu/index.html?name=xxx&age=25#teacher'); -- name=xxx&age=25
```

编码函数

- url_encode(*value*) → varchar

  描述：对 value 进行转义处理，以便可以安全地将其包含在 URL 查询参数名和值中：

  - 字母字符不会被编码。
  - 字符 ., -, * 和 _不会被编码。
  - ASCII 空格字符会被编码为+ 。
  - 所有其他字符都将转换为 UTF-8，并且字节被编码为字符串%XX，其中 XX 是 UTF-8 字节的大写十六进制值。

```
select
url_encode('http://www.example.com:80/stu/index.html?name=xxx&age=25#teacher');
--
http%3A%2F%2Fwww.example.com%3A80%2Fstu%2Findex.html%3Fname%3Dxxx%26age%3D25%23teacher
```

- url_decode(*value*) → varchar

  描述：对 value 编码后的 URL 进行解码操作。

```
select
url_decode('http%3A%2F%2Fwww.example.com%3A80%2Fstu%2Findex.html%3Fname%3Dxxx%26age%3D25%23teacher');
-- http://www.example.com:80/stu/index.html?name=xxx&age=25#teacher
```

10.16.3.19 Geospatial 函数

以 ST_前缀开头的 HetuEngine Geospatial 功能支持 SQL、MM 规范，并符合 Open Geospatial Consortium（OGC）的 OpenGIS 规范。因此，许多 HetuEngine Geospatial 功能要求或更准确地说是假设要操作的几何图形既简单又有效。例如，计算在多边形外部定义了孔的多边形的面积，或者从非简单边界线构造多边形是没有意义的。

HetuEngine 地理空间功能支持空间对象的已知文本（WKT）和已知二进制（WKB）形式：

- POINT (0 0)
- LINESTRING (0 0, 1 1, 1 2)
- POLYGON ((0 0, 4 0, 4 4, 0 4, 0 0), (1 1, 2 1, 2 2, 1 2, 1 1))
- MULTIPOINT (0 0, 1 2)
- MULTILINESTRING ((0 0, 1 1, 1 2), (2 3, 3 2, 5 4))
- MULTIPOLYGON (((0 0, 4 0, 4 4, 0 4, 0 0), (1 1, 2 1, 2 2, 1 2, 1 1)), ((-1 -1, -1 -2, -2 -2, -2 -1, -1 -1)))

- GEOMETRYCOLLECTION (POINT(2 3), LINESTRING (2 3, 3 4))

WKT(Well-known text)是开放地理空间联盟 OGC（Open GIS Consortium ）制定的一种文本标记语言，用于表示矢量几何对象、空间参照系统及空间参照系统之间的转换。

WKB(well-known binary) 是 WKT 的二进制表示形式，解决了 WKT 表达方式冗余的问题，便于传输和在数据库中存储相同的信息。

GeoJSON 一种 JSON 格式的 Feature 信息输出格式，它便于被 JavaScript 等脚本语言处理，OpenLayers 等地理库便是采用 GeoJSON 格式。此外，TopoJSON 等更精简的扩展格式。

使用 ST_GeometryFromText（）和 ST_GeomFromBinary（）函数从 WKT 或 WKB 创建几何对象。

SphericalGeography 类型为地理坐标（有时称为大地坐标或 lat / lon 或 lon / lat）上表示的空间要素提供本地支持。地理坐标是以角度单位（度）表示的球坐标。几何类型的基础是平面。平面上两点之间的最短路径是一条直线。这意味着可以使用笛卡尔数学和直线矢量来计算几何形状（面积，距离，长度，交点等）。

SphericalGeography 类型的基础是一个球体。球面上两点之间的最短路径是大圆弧。这意味着必须使用更复杂的数学方法在球体上计算地形（区域，距离，长度，交点等）。不支持考虑到实际球体形状的更精确的测量。

测量函数 ST_Distance（）和 ST_Length（）返回的值以米为单位；ST_Area（）返回的值以平方米为单位。

使用 to_spherical_geography（）函数将几何对象转换为地理对象。

例如 ST_Distance（ST_Point（-71.0882，42.3607），ST_Point（-74.1197，40.6976））以欧几里得平面上传入值的单位返回 3.4577，而 ST_Distance（to_spherical_geography（ST_Point（-71.0882，42.3607）） ，to_spherical_geography（ST_Point（-74.1197，40.6976）））以米为单位返回 312822.179。

构造器

- ST_AsBinary(*Geometry*)→ varbinary

  描述：返回几何图形的二进制表示。

```
select ST_AsBinary(ST_GeometryFromText('POINT(12 13)'));
                  _col0
------------------------------------------------------------------
01 01 00 00 00 00 00 00 00 00 00 28 40 00 00 00 00 00 00 2a 40
(1 row)
```

- ST_AsText(*Geometry*) → varchar

  描述：返回几何图形的 WKT 表示。对于空的几何图形 ST_AsText(ST_LineFromText('LINESTRING EMPTY')) 将生成 'MULTI LINE STRING EMPTY' ， ST_AsText(ST_Polygon('POLYGON EMPTY')) 生成 'MULTIPOLYGON EMPTY'。

```
SELECT st_astext(ST_GeometryFromText('LINESTRING (0 0, 1 1, 1 2)'));--
LINESTRING (0 0, 1 1, 1 2)
```

- ST_GeometryFromText(*varchar*)→ Geometry

  描述：返回一个 WKT 表示的几何对象。

```
select ST_GeometryFromText('POLYGON ((0 0, 4 0, 4 4, 0 4, 0 0), (1 1, 2 1, 2 2, 1 2, 1 1))');
--POLYGON ((0 0, 4 0, 4 4, 0 4, 0 0), (1 1, 1 2, 2 2, 2 1, 1 1))
```

- ST_GeomFromBinary(*varbinary*)→ Geometry

  描述：返回一个 WKB 表示的几何类型。

```
select ST_geomFromBinary(ST_AsBinary(ST_GeometryFromText('POINT(12 13)')));--
POINT (12 13)
```

- ST_LineFromText(*varchar*)→ LineString

  描述：返回 WKT 表示的线条字符串对象。

```
select st_lineFromText('LINESTRING (0 0, 1 1, 1 2)');--  LINESTRING (0 0, 1 1, 1 2)
```

- ST_Point(*double*, *double*)

  描述：返回具有给定坐标值的几何类型点对象。

```
select st_point(12.1,34.1);
POINT (12.1 34.1)
```

- ST_Polygon(*varchar*)

  描述：返回 WKT 字符串表示的多边形。

```
select ST_Polygon('POLYGON ((0 0, 4 0, 4 4, 0 4, 0 0), (1 1, 2 1, 2 2, 1 2, 1 1))');
POLYGON ((0 0, 4 0, 4 4, 0 4, 0 0), (1 1, 1 2, 2 2, 2 1, 1 1))
```

Operations

- ST_Boundary(*Geometry*) → Geometry

  描述：返回一个封闭图形的边界。

```
select ST_boundary(ST_Polygon('POLYGON ((0 0, 4 0, 4 4, 0 4, 0 0), (1 1, 2 1, 2 2, 1 2, 1 1))'));
MULTILINESTRING ((0 0, 4 0, 4 4, 0 4, 0 0), (1 1, 1 2, 2 2, 2 1, 1 1))
```

- ST_Buffer(*Geometry*, *distance*) → Geometry

  描述：返回表示与指定几何图形之间的距离小于或等于指定距离的所有点的几何图形。

```
select ST_Buffer(ST_POINT(0,0),4);
POLYGON ((4 0, 3.9914356929544113 0.2616125169205717, 3.965779445495239
0.5221047688802056, 3.923141121612919 0.7803612880645122, 3.8637033051562706
1.035276180410082, 3.7877205179804205 1.2857578612126452, 3.695518130045145
1.5307337294603...
```

- ST_Difference(*Geometry*, *Geometry*) → Geometry

  描述：返回表示给定几何图形的点集差异的几何图形值。

```
select ST_Difference(ST_POINT(0,0),ST_POINT(2,3));-- POINT (0 0)
```

- ST_EnvelopeAsPts(*Geometry) -> array(Geometry*)

  描述：返回包含两个点的数组：几何图形的边界矩形多边形的左下角和右上角。如果输入几何为空，则返回 NULL。

```
select ST_EnvelopeAsPts(ST_LineFromText('LINESTRING (0 0, 1 1, 1 2)'));--
[POINT (0 0), POINT (1 2)]
```

- ST_Intersection(*Geometry*, *Geometry*) → Geometry

  描述：返回表示两个几何的点集交集的几何值。

```
 select ST_Intersection(ST_LineFromText('LINESTRING (0 0, 1 1, 1 2)'),
ST_LineFromText('LINESTRING (0 0, 1 1, 1 3)'));
-- LINESTRING (0 0, 1 1, 1 2)
```

- ST_SymDifference(*Geometry*, *Geometry*) → Geometry

  描述：返回表示两个几何的点集对称差异的几何值。

```
select ST_SymDifference(ST_LineFromText('LINESTRING (0 0, 1 1, 1 2)'),
ST_LineFromText('LINESTRING (0 0, 1 1, 1 3)'));--  LINESTRING (1 2, 1 3)
```

- ST_Union(*Geometry*, *Geometry*) → Geometry

  描述：返回一个表示输入几何图形的点集并集的几何图形。

```
 select ST_Union(ST_LineFromText('LINESTRING (0 0, 1 1, 1 2)'),
ST_LineFromText('LINESTRING (0 0, 1 1, 1 3)')); --  LINESTRING (0 0, 1 1, 1 2,
1 3)
```

10.16.3.20 HyperLogLog 函数

HetuEngine 使用 HyperLogLog 数据结构实现 rox_distinct（）函数。

数据结构

HyperLogLog（hll）是一种统计基数的算法。它实际上不会存储每个元素出现的次数，它使用的是概率算法，通过存储元素的 32 位 hash 值的第一个 1 的位置，来计算元素数量。通常分为稀疏存储结构和密集存储结构两种。hll 创建时是稀疏存储结构，当需要更高效处理时会转为密集型数据结构。P4HyperLogLog 则在其整改生命周期都是密集型数据结构。如有必要，可以显式地转换 cast(hll as P4HyperLogLog)。在当前数据引擎的实现中，hll 的数据草图是通过一组 32 位的桶来存储对应的最大 hash。

序列化

数据草图可以通过 varbinary 进行序列化和反序列化。这使得可以被方便地存储，以备后用。通过合并多个草图，可以在查询分区中所有元素的 approx_distinct()，即每个元素出现的近似次数，进而通过很小的开销去完成整个查询。

例如，只要计算每日每个用户浏览了多少次网页，就可以通过累加的方式，去计算每周、每年对应的数据，类似于通过汇总每日收入来计算每周收入。

可以将 approx_distinct()与 GROUPING SETS 一起使用转换为 HyperLogLog。如下所示：

```
CREATE TABLE visit_summaries(visit_date date,hll varbinary);

INSERT INTO visit_summaries
SELECT visit_date,cast(approx_set(user_id) AS varbinary)
FROM user_visits
GROUP BY visit_date;

SELECT cardinality(merge(cast(hll AS HyperLogLog)))AS weekly_unique_users
FROM visit_summaries
WHERE visit_date>=current_date-interval'7'day;
```

函数

- approx_set(*x*) → HyperLogLog

  描述：返回 HyperLogLog。这个数据草图是 approx distinct()的基础，可以通过调用 cardinality()来存储和使用。

```
select approx set(cookieid) from cookies log;--02 0c 02 00 c0 77 15 40 c1 2f 1b
c2
```

- cardinality(*hll*) → bigint

  描述：计算 hll 汇总的数据。

```
select cardinality(approx_set(cookieid)) from cookies_log; --2
```

- empty_approx_set()→ HyperLogLog

  描述：返回一个空的 hyperloglog。

```
select empty_approx_set();--02 0c 00 00
```

- merge(*HyperLogLog*) → HyperLogLog

  描述：对每个独立的 hll 数据草图进行汇总求并集的操作。

```
CREATE TABLE visit_summaries (  visit_date date,  hll varbinary);

insert into visit_summaries select createtime,cast(approx_set(cookieid) as
varbinary) from cookies_log group by createtime;

SELECT cardinality(merge(cast(hll AS HyperLogLog))) AS weekly_unique_users FROM
visit_summaries WHERE visit_date >=date '2020-07-11';
 weekly_unique_users
---------------------
                   2
(1 row)
```

10.16.3.21 UUID 函数

使用该函数产生一个伪随机的唯一通用标识符。

```
select uuid();
```

10.16.3.22 Color 函数

- bar(*x*, *width*)

  描述：使用默认的低频红色和高频绿色渲染 ANSI 条形图中的单个条形。例如，如果将 25%的 x 和 40 的宽度传递给此函数。将绘制一个 10 个字符的红色条形，后跟 30 个空格，以创建一个 40 个字符的条形。

- bar(x, width, low_color, high_color)

  描述：在 ANSI 条形图中以指定宽度绘制一条直线。参数 x 是 0 到 1 之间的一个双精度值。x 的值超出[0，1]范围将被截断为 0 或 1 值。low_color 和 high_color 捕获用于水平条形图任一端的颜色。例如，如果 x 为 0.5，宽度为 80，low_color 为 0xFF0000，high_color 为 0x00FF00，则此函数将返回一个 40 个字符的条形，该条形由红色（0xFF0000）和黄色（0xFFFF00）组成，其余 80 个字符条为用空格填充。

```
 select bar(0.75,80,rgb(255,0,0),rgb(0,255,0));
```

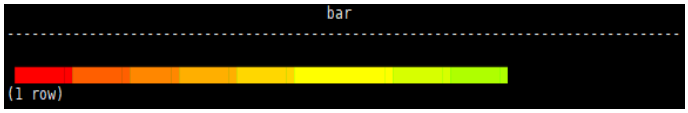

- render(b)
  描述：根据布尔值返回对错符号。

```
select render(true),render(false);
```

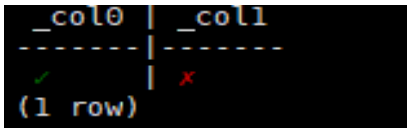

10.16.3.23 Session 信息

current_user

描述：返回当前用户。

```
select current_user;
```

current_user()

参考 current_user。

current_catalog

描述：返回当前的 catalog 名字。

```
select current_catalog;
```

current_schema

描述：返回当前的 schema 名字。

```
select current_schema;
```

10.16.3.24 Teradata 函数

以下函数提供 Teradata SQL 的能力。

字符串函数

- char2hexint(*string*)
  描述：返回字符串的 UTF-16BE 编码的十六进制表示形式。
- index(*string*, *substring*)
  描述：同 strpos() 函数。

日期函数

本节中的函数使用与 Teradata datetime 函数兼容的格式字符串。下表基于 Teradata 参考手册，描述了受支持的格式说明符。

说明符	说明
- / , . ; :	忽略标点符号

说明符	说明
dd	一个月中的第几日（1-31）
hh	一天中的第几个小时（1-12）
hh24	一天中的第几个小时（0-23）
mi	分钟（0-59）
mm	月份（01-12）
ss	秒（0-59）
yyyy	四位年份
yy	两位年份

说明

当前不支持不区分大小写。 所有说明符必须小写。

- to_char(*timestamp*, *format*)

  描述：将时间戳按指定格式输出为字符串。

```
select to_char(timestamp '2020-12-18 15:20:05','yyyy/mmdd hh24:mi:ss');--
2020/1218 15:20:05
```

- to_timestamp(*string*, *format*)

  描述：将字符串按规定格式解析为 timestamp。

```
select to_timestamp('2020-12-18 15:20:05','yyyy-mm-dd hh24:mi:ss'); -- 2020-12-
18 15:20:05.000
```

- to_date(*string*, *format*)

  描述：将字符串按格式转换为日期。

```
select to_date('2020/12/04','yyyy/mm/dd'); -- 2020-12-04
```

10.16.3.25 Data masking 函数

数据脱敏(Data masking) 指对某些敏感信息通过脱敏规则进行数据的变形，实现敏感隐私数据的可靠保护。

- mask_first_n(string str[, int n]) →varchar

  描述：返回 str 的屏蔽版本，前 n 个值被屏蔽。大写字母被转为 " X " ，小写字母被转为 " x " ，数字被转为 " n " 。

```
select mask_first_n('Aa12-5678-8765-4321', 4);
      _col0
---------------------
 Xxnn-5678-8765-4321
(1 row)
```

- mask_last_n(string str[, int n]) →varchar

  描述：返回 str 的屏蔽版本，后 n 个值被屏蔽。大写字母被转为 " X " ，小写字母被转为 " x " ，数字被转为 " n " 。

```
select mask_last_n('1234-5678-8765-Hh21', 4);
       _col0
---------------------
 1234-5678-8765-Xxnn
(1 row)
```

- mask_show_first_n(string str[, int n]) →varchar

  描述：返回 str 的屏蔽版本，只显示前 n 个字符。大写字母被转为 " X " ，小写字母被转为 " x " ，数字被转为 " n " 。

```
select mask_show_first_n('1234-5678-8765-4321',4);
       _col0
---------------------
 1234-nnnn-nnnn-nnnn
(1 row)
```

- mask_show_flairst_n(string str[, int n]) →varchar

  描述：返回 str 的屏蔽版本，只显示后 n 个值。大写字母被转为 " X " ，小写字母被转为 " x " ，数字被转为 " n " 。

```
select mask_show_last_n('1234-5678-8765-4321',4);
       _col0
---------------------
 nnnn-nnnn-nnnn-4321
(1 row))
```

- mask_hash(string|char|varchar str) →varchar

  描述：返回基于 str 的散列值。散列是一致的，可以用于跨表连接被屏蔽的值。对于非字符串类型，返回 NULL。

```
select mask_hash('panda');
                          _col0
------------------------------------------------------------------
 a7cdf5d0586b392473dd0cd08c9ba833240006a8a7310bf9bc8bf1aefdfaeadb
(1 row)
```

10.16.3.26 IP Address 函数

contains(network, address) → boolean

当 CIDR 网络中包含 address 时返回 true。

```
SELECT contains('10.0.0.0/8', IPADDRESS '10.255.255.255'); -- true
SELECT contains('10.0.0.0/8', IPADDRESS '11.255.255.255'); -- false
SELECT contains('2001:0db8:0:0:0:ff00:0042:8329/128', IPADDRESS
'2001:0db8:0:0:0:ff00:0042:8329'); -- true
SELECT contains('2001:0db8:0:0:0:ff00:0042:8329/128', IPADDRESS
'2001:0db8:0:0:0:ff00:0042:8328'); -- false
```

10.16.3.27 Quantile digest 函数

概述

Quantile digest（分位数摘要）是存储近似百分位信息的数据草图。HetuEngine 中用 qdigest 表示这种数据结构。

函数

- merge(qdigest) → qdigest

  描述：将所有输入的 qdigest 数据合并成一个 qdigest。
- value_at_quantile(qdigest(T), quantile) → T

  描述：给定 0 到 1 之间的数字分位数，返回分位数摘要中的近似百分位值。
- values_at_quantiles(qdigest(T), quantiles) -> array(T)

  描述：给定一组 0 到 1 之间的数字分位数，从分位数摘要中返回对应的近似百分位值组成的数组。
- qdigest_agg(x) -> qdigest([same as x])

  描述：返回由 x 的所有输入值组成的 qdigest。
- qdigest_agg(x, w) -> qdigest([same as x])

  描述：返回由 x 的所有输入值（使用每项权重 w）组成的 qdigest。
- qdigest_agg(x, w, accuracy) -> qdigest([same as x])

  描述：返回由 x 的所有输入值（使用每项权重 w 和最大误差 accuracy）组成的 qdigest。accuracy 必须是一个大于 0 且小于 1 的值，并且对于所有输入行是一个常量。

10.16.3.28 T-Digest 函数

概述

T-digest 是存储近似百分位信息的数据草图。HetuEngine 中用 tdigest 表示这种数据结构。T-digest 可以合并，在存储时可以强转为 VARBINARY，检索时再由 VARBINARY 转换为 T-digest

函数

- merge(tdigest)→tdigest

  描述：将所有输入的 tdigest 数据合并成一个 tdigest。
- value_at_quantile(tdigest,quantile)→double

  描述：给定 0 到 1 之间的数字分位数，返回 T-digest 中的近似百分位值。
- values_at_quantiles(tdigest,quantiles)->array(double)

  描述：给定一组 0 到 1 之间的数字分位数，从 T-digest 中返回对应的分位数组成的数组。
- tdigest_agg(x)->tdigest

  描述：返回由 x 的所有输入值组成的 tdigest。x 可以是任何数值类型。
- tdigest_agg(x,w)->tdigest

  描述：返回由 x 的所有输入值（使用每项权重 w）组成的 tdigest。w 必须大于或等于 1。x 和 w 可以是任何数值类型。

10.16.3.29 Set Digest 函数

概述

HetuEngine 提供了几个处理 MinHash 技术的函数。

MinHash 用于估计两个集合的 Jaccard 相似系数。它通常用于数据挖掘，用于大规模检测近乎相同的网页。通过使用这些信息，搜索引擎有效地避免了在搜索结果中显示两个几乎相同的网页。

以下示例展示了如何使用 Set Digest 函数来简单估计文本之间的相似性。通过使用函数 ngrams()将输入文本分割为 4-shingles（文本被分成长度为 4 的连续子序列，每个子序列称为一个 shingle 或者 gram），它们被用于创建每个初始文本的集合摘要。将集合摘要相互比较，以获得其相应初始文本相似性的近似值。

```
WITH text_input(id, text) AS (
        VALUES
            (1, 'The quick brown fox jumps over the lazy dog'),
            (2, 'The quick and the lazy'),
            (3, 'The quick brown fox jumps over the dog')
    ),
   text_ngrams(id, ngrams) AS (
       SELECT id,
              transform(
                ngrams(
                  split(text, ' '),
                  4
                ),
                token -> array_join(token, ' ')
              )
        FROM text_input
    ),
    minhash_digest(id, digest) AS (
        SELECT id,
               (SELECT make_set_digest(v) FROM unnest(ngrams) u(v))
        FROM text_ngrams
    ),
    setdigest_side_by_side(id1, digest1, id2, digest2) AS (
        SELECT m1.id as id1,
              m1.digest as digest1,
              m2.id as id2,
              m2.digest as digest2
        FROM (SELECT id, digest FROM minhash_digest) m1
        JOIN (SELECT id, digest FROM minhash_digest) m2
          ON m1.id != m2.id AND m1.id < m2.id
    )
SELECT id1,
      id2,
      intersection_cardinality(digest1, digest2) AS intersection_cardinality,
      jaccard_index(digest1, digest2)
          AS jaccard_index
FROM setdigest_side_by_side
ORDER BY id1, id2;
 id1 | id2 | intersection_cardinality | jaccard_index
-----|-----|--------------------------|---------------
```

```
  1 |   2 |                   0 |         0.0
  1 |   3 |                   4 |         0.6
  2 |   3 |                   0 |         0.0
(3 rows)
```

上述结果列表指出，正如预期的那样，id 为 1 和 3 的文本非常相似。

说明

Data sketches（数据草图）可以序列化为 varbinary，也可以从 varbinary 反序列化。因此可以用 varbinary 来存储数据草图。

函数

- make_set_digest(x) → setdigest

  描述：将所有的输入值 X，组合到 setdigest 中。

```
SELECT make_set_digest(value) FROM (VALUES 1, 2, 3) T(value);
                  _col0
-------------------------------------------------
 01 10 00 00 00 02 0b 03 00 80 03 44 00 00 58 3d
 5b 80 20 08 de 00 20 00 00 03 00 00 00 a8 c0 76
 6c a0 20 08 de 4a c4 05 fb b7 03 44 00 0c 8b 48
 b2 39 58 3d 5b 01 00 01 00 01 00
(1 row)

SELECT make_set_digest(value) FROM (VALUES 'Trino', 'SQL', 'on', 'everything')
T(value);
                  _col0
-------------------------------------------------
 01 14 00 00 00 02 0b 04 00 c0 8c 7d 1e c0 75 c9
 2d c0 1a 1a 66 03 11 c3 a5 00 20 00 00 04 00 00
 00 06 e5 2d 45 05 11 c3 a5 48 85 6b d5 e0 8c 7d
 1e b9 1a 8a 39 ff 75 c9 2d 02 ad 0c 7c ed 1a 1a
 66 01 00 01 00 01 00 01 00
(1 row)
```

- merge_set_digest(setdigest) → setdigest

  描述：返回由输入值 setdigest 聚合组成的 setdigest。

- cardinality(setdigest) → long

  描述：基于内部 HyperLogLog 组件返回 setdigest 的基数。

```
SELECT cardinality(make_set_digest(value)) FROM (VALUES 1, 2, 2, 3, 3,4, 4, 4,
5) T(value); -- 5
```

- intersection_cardinality(x, y) → long

  描述：返回两个集合摘要交集的基数估计。其中 x,y 都是 setdigest 类型。

```
SELECT intersection_cardinality(make_set_digest(v1), make_set_digest(v2)) FROM
(VALUES (1, 1), (NULL, 2), (2, 3), (3, 4)) T(v1, v2); -- 3
```

- jaccard_index(x, y) → double

  描述：返回两个集合摘要的 Jaccard 索引估计值。其中 x,y 都是 setdigest 类型。

```
SELECT jaccard_index(make_set_digest(v1), make_set_digest(v2)) FROM (VALUES (1,
1), (NULL,2), (2, 3), (NULL, 4)) T(v1, v2); -- 0.5
```

- hash_counts(x)

  描述：返回一个包含 Murmur3Hash128 哈希值及其在属于 x 的内部 MinHash 结构中出现的计数的 Map。其中 x 是 setdigest 类型。

```
SELECT hash_counts(make_set_digest(value)) FROM (VALUES 1, 1, 1, 2, 2) T(value);
-- {19144387141682250=3, -2447670524089286488=2}
```

10.17 数据类型隐式转换

10.17.1 简介

数据类型隐式转换指用户通过客户端访问 HetuEngine 资源时，当查询的数据类型和表的数据类型不匹配时，HetuEngine 能自动进行数据类型转换，避免用户在使用时因强数据类型校验带来的不便。当前在插入数据（Insert）、条件判断（Where）、运算操作（+、-、*、/）以及函数调用（连接操作 ||）时能提供数据类型隐式转换功能。

10.17.2 开启/关闭隐式转换功能

类型隐式转换功能是可以打开、关闭的，默认是关闭状态，使用前需要先打开隐式转换功能。

10.17.3 开启隐式转换

在 Session 级别开启隐式转换

登录 HetuEngine 客户端。

步骤 1 执行以下命令，开启数据类型隐式转换功能。

set session implicit_conversion=true;

----结束

在 Session 级别开启 UDF 函数运算结果的隐式转换

登录 HetuEngine 客户端。

步骤 1 执行以下命令，开启 UDF 函数运算结果的隐式转换功能。

set session udf_implicit_conversion=true;

----结束

在 System 级别开启隐式转换或 UDF 函数运算结果的隐式转换

登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine > 概览”，单击“HSConsole WebUI”的 HSConsole 链接进入计算实例界面。

步骤 1 选择并停止需要配置的计算实例，单击计算实例的“配置”，进入计算实例配置界面。

步骤 2 根据使用场景添加如下自定义配置并保存。

名称	值	参数文件	说明
implicit-conversion	true	coordinator.config.properties	隐式转换
udf-implicit-conversion	true	coordinator.config.properties	UDF 函数运算结果的隐式转换

步骤 3 勾选“立即启动”，单击“确定”启动计算实例。

----结束

10.17.4 关闭隐式转换

在 Session 级别关闭隐式转换

登录 HetuEngine 客户端。

步骤 1 执行以下命令，关闭隐式转换功能。

set session implicit_conversion=false;

----结束

在 Session 级别关闭 UDF 函数运算结果的隐式转换

登录 HetuEngine 客户端。

步骤 1 执行以下命令，关闭隐式转换功能。

set session udf_implicit_conversion=false;

----结束

在 System 级别关闭隐式转换或 UDF 函数运算结果的隐式转换

登录 FusionInsight Manager，选择“集群 > 服务 > HetuEngine > 概览”，单击“HSConsole WebUI”的 HSConsole 链接进入计算实例界面。

步骤 1 选择并停止需要配置的计算实例，单击计算实例的“配置”，进入计算实例配置界面。

步骤 2 根据使用场景删除如下自定义配置并保存。

名称	值	参数文件	说明
implicit-conversion	true	coordinator.config.properties	隐式转换
udf-implicit-conversion	true	coordinator.config.properties	UDF 函数运算结果的隐式转换

步骤 3 勾选“立即启动”，单击“确定”启动计算实例。

----结束

10.17.5 隐式转换对照表

在开启隐式转换功能后，当数据类型不匹配时会隐式转换，但并是不是所有的数据类型都支持隐式转换。以下为当前隐式转换功能支持的数据类型转换表：

表10-77 隐式转换对照表

-	BOOLEAN	TINYINT	SMALLINT	INTEGER	BIGINT	REAL	DOUBLE	DECIMAL	VARCHAR
BOOLEAN	\	Y(1)	Y	Y	Y	Y	Y	Y	Y(2)
TINYINT	Y(3)	\	Y	Y	Y	Y	Y	Y	Y
SMALLINT	Y	Y(4)	\	Y	Y	Y	Y	Y	Y
INTEGER	Y	Y	Y	\	Y	Y	Y	Y	Y
BIGINT	Y	Y	Y	Y	\	Y	Y	Y	Y
REAL	Y	Y	Y	Y	Y	\	Y	Y(5)	Y
DOUBLE	Y	Y	Y	Y	Y	Y	\	Y	Y
DECIMAL	Y	Y	Y	Y	Y	Y	Y	\(6)	Y
VARCHAR	Y(7)	Y	Y	Y	Y	Y	Y	Y(8)	\
CHAR	N	N	N	N	N	N	N	N	Y
VARBINARY	N	N	N	N	N	N	N	N	N
JSON	N	N	N	N	N	N	N	N	Y
DATE	N	N	N	N	N	N	N	N	Y
TIME	N	N	N	N	N	N	N	N	Y
TIME WITH TIME ZONE	N	N	N	N	N	N	N	N	Y

-	BOOLEAN	TINYINT	SMALLINT	INTEGER	BIGINT	REAL	DOUBLE	DECIMAL	VARCHAR
TIMESTAMP	N	N	N	N	N	N	N	N	Y
TIMESTAMP WITH TIME ZONE	N	N	N	N	N	N	N	N	Y

表10-78 隐式转换对照表（续）

-	CHAR	VARBINARY	JSON	DATE	TIME	TIME WITH TIME ZONE	TIMESTAMP	TIMESTAMP WITH TIME ZONE
BOOLEAN	N	N	Y	N	N	N	N	N
TINYINT	N	N	Y	N	N	N	N	N
SMALLINT	N	N	Y	N	N	N	N	N
INTEGER	N	N	Y	N	N	N	N	N
BIGINT	N	N	Y	N	N	N	N	N
REAL	N	N	Y	N	N	N	N	N
DOUBLE	N	N	Y	N	N	N	N	N
DECIMAL	N	N	Y	N	N	N	N	N
VARCHAR	Y(9)	Y	Y	Y(10)	Y(11)	Y(12)	Y(13)	Y
CHAR	\	N	N	N	N	N	N	N
VARBINARY	N	\	N	N	N	N	N	N
JSON	N	N	\	N	N	N	N	N
DATE	N	N	Y	\	N	N	Y(14)	Y

-	CHAR	VARBINARY	JSON	DATE	TIME	TIME WITH TIME ZONE	TIMESTAMP	TIMESTAMP WITH TIME ZONE
TIME	N	N	N	N	\	Y(15)	Y(16)	Y
TIME WITH TIME ZONE	N	N	N	N	Y	\	Y	Y
TIMESTAMP	N	N	N	Y	Y	Y	\	Y
TIMESTAMP WITH TIME ZONE	N	N	N	Y	Y	Y	Y	\

说明

- BOOLEAN->NUMBER 结果只会是 0/1。
- BOOLEAN->VARCHAR 字符结果只会是‘TRUE’/‘FALSE’。
- NUMBER -> BOOLEAN 0 就是 false，非 0 就是 true。
- BIG PRECISION -> SMALL 不能大于目标类型的取值范围，否则会报错。
- REAL/FLOAT ->DECIMAL 目标类型的整数位必须大于或等于 REAL/FLOAT 整数位，否则转换报错，小数位不足会截断。
- DECIMAL->DECIMAL 目标类型整数位的范围必须大于等于源类型，否则转换失败，小数位不足会截断。
- VARCHAR->BOOLEAN 字符只有 '0'，'1'，'TRUE'，'FALSE' 可转换。
- VARCHAR->DECIMAL 如果小数位大于目标 decimal 的小数位，则会发生截断，如果整数位超过目标 decimal 的范围则报错。
- VARCHAR->CHAR 如果 VARCHAR 长度超过目标长度，则会截断。
- VARCHAR->DATE 仅支持按照“-”分割的日期，例如 2000-01-01。
- VARCHAR->TIME 仅支持严格的日期格式：HH:MM:SS.XXX。
- VARCHAR->TIME ZONE 仅支持严格的格式：例如 01:02:03.456 America/Los_Angeles。
- VARCHAR->TIMESTAMP 仅支持严格的格式 YYYY-MM-DD HH:MM:SS.XXX。
- DATE->TIMESTAMP 自动补齐时间，补零 '2010-01-01' -> 2010-01-01 00:00:00.000。
- TIME->TIME WITH TIME ZONE 自动补齐时区。
- TIME->TIMESTAMP 自动补齐日期，取默认值 1970-01-01。

10.18 附录

10.18.1 本文样例表数据准备

```
--创建具有 TINYINT 类型数据的表。
 CREATE TABLE int_type_t1  (IT_COL1 TINYINT) ;
--插入 TINYINT 类型数据
 insert into int_type_t1  values (TINYINT'10');
--创建具有 DECIMAL 类型数据的表。
CREATE TABLE decimal_t1      (dec_col1 DECIMAL(10,3)) ;
--插入具有 DECIMAL 类型数据
insert into decimal_t1  values (DECIMAL '5.325' );
create table array_tb(col1 array<int>,col2 array<array<int>>);
create table row_tb(col1 row(a int,b varchar));

--创建 Map 类型表
create table map_tb(col1 MAP<STRING,INT>);
--插入一条 Map 类型数据
insert into map_tb values(MAP(ARRAY['foo','bar'],ARRAY[1,2]));
--查询数据
select * from map_tb; --   {bar=2, foo=1}

--创建 ROW 表
create table row_tb (id int,col1 row(a int,b varchar));
--插入 ROW 类型数据
insert into row_tb values (1,ROW(1,'SSS'));
--查询数据
select * from row_tb; --
 id |    col1
----|--------------
  1 | {a=1, b=SSS}
select col1.b from row_tb; -- SSS
select col1[1] from row_tb; -- 1

-- 创建 struct 表
create table struct_tab (id int,col1 struct<col2: integer, col3: string>);
--插入 struct 类型数据
 insert into struct_tab VALUES(1, struct<2, 'test'>);
--查询数据
select * from struct_tab; --
 id |       col1
----|---------------------
  1 | {col2=2, col3=test}


--创建一个名为 web 的 schema:
CREATE SCHEMA web;
--在 hive 数据源下创建一个名为 sales 的 schema:
CREATE SCHEMA hive.sales;
--创建一个名为 traffic，如果不存在的话:
CREATE SCHEMA IF NOT EXISTS traffic;

--创建一个新表 orders，使用子句 with 指定创建表的存储格式、存储位置、以及是否为外表:
CREATE TABLE orders (
```

```
orderkey bigint,
orderstatus varchar,
totalprice double,
orderdate date
)
WITH (format = 'ORC', location='/user',external=true);
--如果表 orders 不存在，则创建表 orders，并且增加表注释和列注释：
CREATE TABLE IF NOT EXISTS new_orders (
orderkey bigint,
orderstatus varchar,
totalprice double COMMENT 'Price in cents.',
orderdate date
)
COMMENT 'A table to keep track of orders.';
--使用表 orders 的列定义创建表 bigger_orders：
CREATE TABLE bigger_orders (
another_orderkey bigint,
LIKE orders,
another_orderdate date
);

CREATE SCHEMA hive.web WITH (location = 'hdfs://hacluster/user');
--创建分区表
CREATE TABLE hive.web.page views (
  view time timestamp,
  user id bigint,
  page url varchar,
  ds date,
  country varchar
)
WITH (
  format = 'ORC',
  partitioned_by = ARRAY['ds', 'country'],
  bucketed_by = ARRAY['user_id'],
  bucket_count = 50
);
--插入空的分区
CALL system.create_empty_partition(
    schema_name => 'web',
    table_name => 'page_views',
    partition_columns => ARRAY['ds', 'country'],
    partition_values => ARRAY['2020-07-17', 'US']);

CALL system.create_empty_partition(
    schema_name => 'web',
    table_name => 'page_views',
    partition_columns => ARRAY['ds', 'country'],
    partition_values => ARRAY['2020-07-18', 'US']);
--插入数据
insert into hive.web.page_views values(timestamp '2020-07-17 23:00:15',bigint
'15141','www.local.com',date '2020-07-17','US' );
insert into hive.web.page_views values(timestamp '2020-07-17 23:00:16',bigint
'15142','www.abc.com',date '2020-07-17','US' );
insert into hive.web.page_views values(timestamp '2020-07-18 23:00:18',bigint
'18148','www.local.com',date '2020-07-18','US' );
```

```
-- 删除分区表数据（删除 where 子句指定的分区所有数据）
delete from hive.web.page_views where ds=date '2020-07-17' and country='US';

--用指定列的查询结果创建新表 orders_column_aliased:
CREATE TABLE orders_column_aliased (order_date, total_price)
AS
SELECT orderdate, totalprice FROM orders;
--用表 orders 的汇总结果新建一个表 orders_by_data:
CREATE TABLE orders_by_date
COMMENT 'Summary of orders by date'
WITH (format = 'ORC')
AS
SELECT orderdate, sum(totalprice) AS price
FROM orders
GROUP BY orderdate;
--如果表 orders_by_date 不存在，则创建表 orders_by_date:
CREATE TABLE IF NOT EXISTS orders_by_date AS
SELECT orderdate, sum(totalprice) AS price
FROM orders
GROUP BY orderdate;
--用和表 orders 具有相同 schema 创建新表 empty orders table，但是没数据:
CREATE TABLE empty orders AS
SELECT *
FROM orders
WITH NO DATA;

--通过表 orders 创建一个视图 test_view:
CREATE VIEW test_view (oderkey comment 'orderId',orderstatus comment 'status',half
comment 'half') AS
SELECT orderkey, orderstatus, totalprice / 2 AS half FROM orders;
--通过表 orders 的汇总结果创建视图 orders_by_date_view:
CREATE VIEW orders_by_date_view AS
SELECT orderdate, sum(totalprice) AS price
FROM orders
GROUP BY orderdate;
--创建一个新视图来替换已经存在的视图:
CREATE OR REPLACE VIEW test_view AS
SELECT orderkey, orderstatus, totalprice / 4 AS quarter
FROM orders;

--更改已存在表的定义。
--数据准备
create table users (id int,name varchar);
--将表名从 users 修改为 people:
ALTER TABLE users RENAME TO people;
--在表 people 中增加名为 zip 的列:
ALTER TABLE people ADD COLUMN zip varchar;
--从表 people 中删除名为 zip 的列:
ALTER TABLE people DROP COLUMN zip;
--将表 people 中列名 id 更改为 user_id:
ALTER TABLE people RENAME COLUMN id TO user_id;

create table testfordrop(name varchar);
```

```
--创建视图
create view orders_by_date as select * from orders;
--设置表的注释信息，可以通过设置注释信息为 NULL 来删除注释
COMMENT ON TABLE people IS 'master table';

--创建一个具有列名 id、name 的新表：
CREATE TABLE example AS
SELECT * FROM (
VALUES
(1, 'a'),
(2, 'b'),
(3, 'c')
) AS t (id, name);

--创建 fruit 和 fruit_copy 表
create table fruit (name varchar,price double);
create table fruit_copy (name varchar,price double);
--向 fruit 表中插入一行数据
insert into fruit values('LIchee',32);
--向 fruit 表中插入多行数据
insert into fruit values('banana',10),('peach',6),('lemon',12),('apple',7);
--将 fruit 表中的数据行加载到 fruit_copy 表中，执行后表中有 5 条记录
insert into fruit copy select * from fruit;
--先清空 fruit copy 表，再将 fruit 中的数据加载到表中，执行之后表中有 2 条记录。
insert overwrite fruit_copy select *  from fruit limit 2;

--创建一个航运表
create table shipping(origin_state varchar(25),origin_zip integer,destination_state
varchar(25) ,destination_zip integer,package_weight integer);

--插入数据
insert into shipping values ('California',94131,'New Jersey',8648,13),
('California',94131,'New Jersey',8540,42),
('California',90210,'Connecticut',6927,1337),
('California',94131,'Colorado',80302,5),
('New York',10002,'New Jersey',8540,3),
('New Jersey',7081,'Connecticut',6708,225);

--创建表并插入数据
create table cookies_log (cookieid varchar,createtime  date,pv int);
insert into cookies_log values
    ('cookie1',date '2020-07-10',1),
    ('cookie1',date '2020-07-11',5),
    ('cookie1',date '2020-07-12',7),
    ('cookie1',date '2020-07-13',3),
    ('cookie1',date '2020-07-14',2),
    ('cookie1',date '2020-07-15',4),
    ('cookie1',date '2020-07-16',4),
    ('cookie2',date '2020-07-10',2),
    ('cookie2',date '2020-07-11',3),
    ('cookie2',date '2020-07-12',5),
     ('cookie2',date '2020-07-13',6),
      ('cookie2',date '2020-07-14',3),
      ('cookie2',date '2020-07-15',9),
    ('cookie2',date '2020-07-16',7);
```

```
-- 创建表
create  table new_shipping (origin_state varchar,origin_zip varchar,packages
int ,total_cost int);

-- 插入数据
insert into new_shipping
values
('California','94131',25,100),
('California','P332a',5,72),
('California','94025',0,155),
('New Jersey','08544',225,490);

--创建数据表并插入数据
create table salary (dept varchar, userid varchar, sal double);
 insert into salary values
('d1','user1',1000),('d1','user2',2000),('d1','user3',3000),('d2','user4',4000),('d
2','user5',5000);

-- 数据准备
create table cookie_views( cookieid varchar,createtime timestamp,url varchar);
insert into cookie_views values
('cookie1',timestamp '2020-07-10 10:00:02','url20'),
('cookie1',timestamp '2020-07-10 10:00:00','url10'),
('cookie1',timestamp '2020-07-10 10:03:04','url13'),
('cookie1',timestamp '2020-07-10 10:50:05','url60'),
('cookie1',timestamp '2020-07-10 11:00:00','url70'),
('cookie1',timestamp '2020-07-10 10:10:00','url40'),
('cookie1',timestamp '2020-07-10 10:50:01','url50'),
('cookie2',timestamp '2020-07-10 10:00:02','url23'),
('cookie2',timestamp '2020-07-10 10:00:00','url11'),
('cookie2',timestamp '2020-07-10 10:03:04','url33'),
('cookie2',timestamp '2020-07-10 10:50:05','url66'),
('cookie2',timestamp '2020-07-10 11:00:00','url77'),
('cookie2',timestamp '2020-07-10 10:10:00','url47'),
('cookie2',timestamp '2020-07-10 10:50:01','url55');

CREATE TABLE visit_summaries (  visit_date date,  hll varbinary);

insert into visit_summaries select createtime,cast(approx_set(cookieid) as
varbinary) from cookies_log group by createtime;

CREATE TABLE nation (name varchar,  regionkey integer);
insert into nation values ('ETHIOPIA',0),
('MOROCCO',0),
('ETHIOPIA',0),
('KENYA',0),
('ALGERIA',0),
('MOZAMBIQUE',0);

CREATE TABLE region (  name varchar,  regionkey integer);
insert into region values ('ETHIOPIA',0),
('MOROCCO',0),
('ETHIOPIA',0),
('KENYA',0),
```

```
('ALGERIA',0),
('MOZAMBIQUE',0);
```

10.18.2 常用数据源语法兼容性

语法	Hive	MPPDB	Elasticsearch	HBase	HetuEngine(跨域)	ClickHouse	Hudi	MySQL
数据库的 show schemas	Y	Y	Y	Y	Y	Y	Y	Y
数据库的 create schema	Y	Y	N	Y	N	N	Y	N
数据库的 use schema	Y	Y	Y	Y	Y	Y	Y	Y
数据库的 alter schema	Y	N	N	N	N	N	N	N
数据库的 drop schema	Y	Y	Y	Y	N	N	Y	N
表的 show tables/show create table/show functions/show session	Y	Y	Y	Y	Y	Y	Y	Y
表的 create	Y	Y	N	Y	N	N	N	N
表的 create table TABLENAME as	Y	Y	Y	Y	N	N	N	N
表的 insert into TABLENAME values	Y	Y	Y	Y	Y	N	N	N
表的 insert into TABLENAME select	Y	Y	Y	Y	Y	N	N	N
表的 insert overwrite TABLENAME values	Y	N	N	N	N	N	N	N
表的 insert overwrite TABLENAME select	Y	N	N	N	N	N	N	N
表的 alter	Y	Y	N	N	N	N	N	N
表的 select	Y	Y	Y	Y	Y	Y	Y	Y
表的 update	Y	Y	Y	N	N	N	N	N
表的 delete	Y	Y	Y	Y	N	N	N	N
表的 drop	Y	N	Y	Y	Y	N	N	N
表的 desc/describe TABLENAME	Y	Y	Y	Y	Y	Y	Y	Y
表的 analyze	Y	Y	Y	N	N	N	Y	N
表的 comment	Y	N	N	N	N	N	N	N

语法	Hive	MPPDB	Elasticsearch	HBase	HetuEngine(跨域)	ClickHouse	Hudi	MySQL
表的 explain	Y	Y	Y	Y	Y	N	Y	N
表的 show stats	Y	Y	Y	N	N	N	Y	N
表的 show columns	Y	Y	Y	Y	Y	Y	Y	Y
表的 select column	Y	Y	Y	Y	Y	Y	Y	Y
视图的 create view	Y	Y	N	N	N	N	N	N
视图的 create or replace view	Y	N	N	N	N	N	N	N
视图的 alter	Y	N	N	N	N	N	N	N
视图的 drop	Y	N	N	N	N	N	N	N
视图的 select	Y	Y	N	N	Y	Y	Y	Y
视图的 desc/describe VIEWNAME	Y	Y	N	N	Y	Y	Y	Y
视图的 show views/show create view	Y	Y	N	N	N	Y	Y	Y
视图的 show columns	Y	Y	Y	Y	Y	Y	Y	Y
视图的 select column	Y	Y	Y	Y	Y	Y	Y	Y

11 使用 Hive

11.1 从零开始使用 Hive

Hive 是基于 Hadoop 的一个数据仓库工具，可将结构化的数据文件映射成一张数据库表，并提供类 SQL 的功能对数据进行分析处理，通过类 SQL 语句快速实现简单的 MapReduce 统计，不必开发专门的 MapReduce 应用，十分适合数据仓库的统计分析。

背景信息

假定用户开发一个应用程序，用于管理企业中的使用 A 业务的用户信息，使用 Hive 客户端实现 A 业务操作流程如下：

普通表的操作：

- 创建用户信息表 user_info。
- 在用户信息中新增用户的学历、职称信息。
- 根据用户编号查询用户姓名和地址。
- A 业务结束后，删除用户信息表。

表11-1 用户信息

编号	姓名	性别	年龄	地址
12005000201	A	男	19	A 城市
12005000202	B	女	23	B 城市
12005000203	C	男	26	C 城市
12005000204	D	男	18	D 城市
12005000205	E	女	21	E 城市
12005000206	F	男	32	F 城市
12005000207	G	女	29	G 城市
12005000208	H	女	30	H 城市

编号	姓名	性别	年龄	地址
12005000209	I	男	26	I 城市
12005000210	J	女	25	J 城市

操作步骤

下载客户端配置文件。

1. 登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. MRS 3.3.0 之前版本，选择“集群 > 概览 > 更多 > 下载客户端”；MRS 3.3.0 及之后版本，在“主页”右上方单击“下载客户端”。
3. 下载集群客户端。

   “选择客户端类型”选择“仅配置文件”，、单击“确定”开始生成客户端配置文件，文件生成后默认保存在主管理节点“/tmp/FusionInsight-Client/”。

步骤 1 登录 Manager 的主管理节点。

1. 以 **root** 用户登录任意部署 Manager 的节点。
2. 执行以下命令确认主备管理节点。

   sh ${BIGDATA_HOME}/om-server/om/sbin/status-oms.sh

   界面打印信息中“HAActive”参数值为“active”的节点为主管理节点（如下例中“node-master1”为主管理节点），参数值为“standby”的节点为备管理节点（如下例中“node-master2”为备管理节点）。

   ```
   HAMode
   double
   NodeName            HostName        HAVersion         StartTime
   HAActive            HAAllResOK          HARunPhase
   192-168-0-30         node-master1    V100R001C01       2020-05-01 23:43:02
   active              normal              Actived
   192-168-0-24         node-master2    V100R001C01       2020-05-01 07:14:02
   standby             normal              Deactived
   ```

3. 以 **root** 用户登录主管理节点，并执行以下命令切换到 **omm** 用户。

   sudo su - omm

步骤 2 执行以下命令切换到客户端安装目录。

提前已安装集群客户端，以下客户端安装目录为举例，请根据实际情况修改。

cd /opt/client

步骤 3 执行以下命令，更新主管理节点的客户端配置。

sh refreshConfig.sh /opt/client *客户端配置文件压缩包完整路径*

例如，执行命令：

sh refreshConfig.sh /opt/client /tmp/FusionInsight-Client/FusionInsight_Cluster_1_Services_Client.tar

界面显示以下信息表示配置刷新更新成功：

```
ReFresh components client config is complete.
Succeed to refresh components client config.
```

步骤 4 在 Master 节点使用客户端。

1. 在已更新客户端的主管理节点，例如“192-168-0-30”节点，执行以下命令切换到客户端目录，客户端安装目录如：/opt/client。

   cd /opt/client

2. 执行以下命令配置环境变量。

   source bigdata_env

3. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 Hive 表的权限。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

   kinit *MRS 集群用户*

   例如，**kinit hiveuser**。

4. 直接执行 Hive 组件的客户端命令。

   beeline

步骤 5 运行 Hive 客户端命令，实现 A 业务。

内部表的操作：

1. 根据表 11-1 创建用户信息表 user_info 并添加相关数据，例如：

   create table user_info(id string,name string,gender string,age int,addr string);

   insert into table user_info(id,name,gender,age,addr) values("12005000201","A","男",19,"A 城市");

2. 在用户信息表 user_info 中新增用户的学历、职称信息。

   以增加编号为 12005000201 的用户的学历、职称信息为例，其他用户类似。

   alter table user_info add columns(education string,technical string);

3. 根据用户编号查询用户姓名和地址。

   以查询编号为 12005000201 的用户姓名和地址为例，其他用户类似。

   select name,addr from user_info where id='12005000201';

4. 删除用户信息表。

   drop table user_info;

外部分区表的操作：

创建外部分区表并导入数据：

1. 创建外部表数据存储路径：

   hdfs dfs -mkdir /hive/

   hdfs dfs -mkdir /hive/user_info

2. 建表：

create external table user_info(id string,name string,gender string,age int,addr string) partitioned by(year string) row format delimited fields terminated by ' ' lines terminated by '\n' stored as textfile location '/hive/user_info';

说明

fields terminated 指明分隔的字符，如按空格分隔，' '。

lines terminated 指明分行的字符，如按换行分隔，'\n'。

/hive/user_info 为数据文件的路径。

3. 导入数据。
   a. 使用 insert 语句插入数据。

      insert into user_info partition(year="2018") values ("12005000201","A","男",19,"A 城市");

   b. 使用 load data 命令导入文件数据。
      i. 根据表 11-1 数据创建文件。如，文件名为 txt.log，以空格拆分字段，以换行符作为行分隔符。
      ii. 上传文件至 hdfs。

      hdfs dfs -put txt.log /tmp

      iii. 加载数据到表中。

      load data inpath '/tmp/txt.log' into table user_info partition (year='2011');
4. 查询导入数据。

   select * from user_info;
5. 删除用户信息表。

   drop table user_info;
6. 执行以下命令退出客户端。

   !q

----结束

11.2 配置 Hive 常用参数

参数入口

登录 FusionInsight Manager，选择“集群 > 服务 > Hive > 配置 > 全部配置”。

参数说明

表11-2 Hive 参数说明

参数	参数说明	默认值
hive.auto.convert.join	Hive 基于输入文件大小将普通 join 转为 mapjoin 的开关。 说明 在使用 Hive 进行联表查询，且关联的表无	取值范围： • true • false

参数	参数说明	默认值
	大小表的分别（小表数据<24M）时，建议将此参数值改为 false，如果此时将此参数设置为 true，执行联表查询时无法生成新的 mapjoin。	默认值为 true
hive.default.fileformat	Hive 使用的默认文件格式。	RCFile
hive.exec.reducers.max	Hive 提交的 MR 任务中 reducer 的最大个数。	999
hive.server2.thrift.max.worker.threads	HiveServer 内部线程池，最大能启动的线程数量。	1000
hive.server2.thrift.min.worker.threads	HiveServer 内部线程池，初始化时启动的线程数量。	5
hive.hbase.delete.mode.enabled	从 Hive 删除 HBase 记录的功能开关。如果启用，用户可以使用“remove table xx where xxx”从 Hive 中删除 HBase 记录。	true
hive.metastore.server.min.threads	MetaStore 启动的用于处理连接的线程数，如果超过设置的值之后，MetaStore 就会一直维护不低于设定值的线程数，即常驻 MetaStore 线程池的线程会维护在指定值之上。	200
hive.server2.enable.doAs	HiveServer2 在与其他服务（如 YARN、HDFS 等）会话时是否模拟客户端用户。如果将此配置项从 false 改成 true，会导致只有列权限的用户访问相应表权限缺失。	true

11.3 Hive SQL

Hive SQL 支持 Hive-3.1.0 版本中的所有特性。

系统提供的扩展 Hive 语句如表 11-3 所示。

表11-3 扩展 Hive 语句

扩展语法	语法说明	语法示例	示例说明
CREATE [TEMPORARY] [EXTERNAL] TABLE [IF NOT EXISTS]	创建一个 hive 表，并指定表数据文件分布的 locator 信息。详细说明请参见 11.6 使用 HDFS	CREATE TABLE tab1 (id INT, name STRING) row format delimited fields terminated by	创建表 tab1，并指定 tab1 的表数据分布在 locator1 节点上。

扩展语法	语法说明	语法示例	示例说明
[db_name.]table_name (col_name data_type [COMMENT col_comment], ...) [ROW FORMAT row_format] [STORED AS file_format] | STORED BY 'storage.handler.class.name' [WITH SERDEPROPERTIES (...)] ..... [TBLPROPERTIES ("groupId"=" group1","locatorId"="locator1")] ...;	Colocation 存储 Hive 表。	'\t' stored as RCFILE TBLPROPERTIES("groupId"=" group1","locatorId"="locator1");	
CREATE [TEMPORARY] [EXTERNAL] TABLE [IF NOT EXISTS] [db_name.]table_name (col_name data_type [COMMENT col_comment], ...) [ROW FORMAT row_format] [STORED AS file_format] | STORED BY 'storage.handler.class.name' [WITH SERDEPROPERTIES (...)] ... [TBLPROPERTIES (**'column.encode.columns'**='col_name1, col_name2'| **'column.encode.indices'**='col_id1,col_id2', **'column.encode.classname'**='encode_classname')]...;	创建一个 hive 表，并指定表的加密列和加密算法。详细说明请参见 11.7 使用 Hive 列加密功能。	create table encode_test(id INT, name STRING, phone STRING, address STRING) ROW FORMAT SERDE 'org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe' WITH SERDEPROPERTIES ('column.encode.indices'='2,3', 'column.encode.classname'='org.apache.hadoop.hive.serde2.SMS4Rewriter') STORED AS TEXTFILE;	创建表 encode_test，并指定插入数据时对第 2、3 列加密，加密算法类为 org.apache.hadoop.hive.serde2.SMS4Rewriter。
REMOVE TABLE *hbase_tablename* [WHERE where_condition];	删除 hive on hbase 表中符合条件的数据。详细说明请参见 11.10 删除 Hive	remove table hbase_table1 where id = 1;	删除表中符合条件“id =1”的数据。

扩展语法	语法说明	语法示例	示例说明
	on HBase 表中的单行记录。		
CREATE [TEMPORARY] [EXTERNAL] TABLE [IF NOT EXISTS] [db_name.]table_name (col_name data_type [COMMENT col_comment], ...) [ROW FORMAT row_format] **STORED AS inputformat 'org.apache.hadoop.hive.contrib.fileformat.SpecifiedDelimiterInputFormat'** outputformat 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat';	创建 hive 表，并设定表可以指定自定义行分隔符。详细说明请参见 11.8 自定义行分隔符。	create table blu(time string, num string, msg string) row format delimited fields terminated by ',' **stored as inputformat 'org.apache.hadoop.hive.contrib.fileformat.SpecifiedDelimiterInputFormat'** outputformat 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat';	创建表 blu，指定 inputformat 为 SpecifiedDelimiterInputFormat，以便查询时可以指定表的查询行分隔符。

11.4 权限管理

11.4.1 Hive 权限介绍

Hive 是建立在 Hadoop 上的数据仓库框架，提供类似 SQL 的 HQL 操作结构化数据。

MRS 提供用户、用户组和角色，集群中的各类权限需要先授予角色，然后将用户或者用户组与角色绑定。用户只有绑定角色或者加入绑定角色的用户组，才能获得权限。

说明

- Hive 在安全模式下需要进行权限管理，在普通模式下无需进行权限管理。
- 如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.10 添加 Hive 的 Ranger 访问权限策略。

Hive 权限模型

使用 Hive 组件，必须对 Hive 数据库和表（含外表和视图）拥有相应的权限。在 MRS 中，完整的 Hive 权限模型由 Hive 元数据权限与 HDFS 文件权限组成。使用数据库或表时所需要的各种权限都是 Hive 权限模型中的一种。

- Hive 元数据权限。

  与传统关系型数据库类似，MRS 的 Hive 数据库包含“建表”和“查询”权限，Hive 表和列包含“查询”、“插入”和“删除”权限。Hive 中还包含拥有者权限“OWNERSHIP”和“Hive 管理员权限”。

- Hive 数据文件权限，即 HDFS 文件权限。

  Hive 的数据库、表对应的文件保存在 HDFS 中。默认创建的数据库或表保存在 HDFS 目录“/user/hive/warehouse”。系统自动以数据库名称和数据库中表的名称创建子目录。访问数据库或者表，需要在 HDFS 中拥有对应文件的权限，包含“读”、“写”和“执行”权限。

用户对 Hive 数据库或表执行不同操作时，需要关联不同的元数据权限与 HDFS 文件权限。例如，对 Hive 数据表执行查询操作，需要关联元数据权限“查询”，以及 HDFS 文件权限“读”和“写”。

使用 Manager 界面图形化的角色管理功能来管理 Hive 数据库和表的权限，只需要设置元数据权限，系统会自动关联 HDFS 文件权限，减少界面操作，提高效率。

Hive 用户对象

MRS 提供了用户和角色来使用 Hive，比如创建表、在表中插入数据或者查询表。Hive 中定义了“USER”类，对应用户实例；定义了“GROUP”类，对应角色实例。

使用 Manager 设置 Hive 用户对象的权限，只支持在角色中设置，用户或用户组需要绑定角色才能获得权限。支持授予 Hive 管理员权限、访问数据库、表和列的权限。

Hive 支持级联鉴权功能（适用于 MRS 3.3.0 及之后版本）

开启了 Ranger 鉴权的集群的 Hive 表支持开启表的级联授权功能，极大地提升了鉴权易用性，只需在 Ranger 页面上对业务表进行一次授权，后台就会自动细粒度关联数据存储源的权限，不需要感知表的存储路径，无需进行二次授权。同时也补齐了基于存算分离授权功能的缺陷。详细操作请参见 20.16 Hive 表支持级联授权功能。

Hive 使用场景及对应权限

用户使用 Hive 并创建数据库需要加入 hive 组，不需要角色授权。用户在 Hive 和 HDFS 中对自己创建的数据库或表拥有完整权限，可直接创建表、查询数据、删除数据、插入数据、更新数据以及授权他人访问表与对应 HDFS 目录与文件。

如果用户访问别人创建的表或数据库，需要授予权限。所以根据 Hive 使用场景的不同，用户需要的权限可能也不相同。

表11-4 Hive 使用场景

主要场景	用户需要的权限
使用 Hive 表、列或数据库	使用其他用户创建的 Hive 表、列或数据库，不同的场景需要不同的 Hive 权限，例如： • 创建表，需要“建表”。

主要场景	用户需要的权限
	• 查询数据，需要“查询”。 • 插入数据，需要“插入”。 • 删除数据，需要“删除”。
关联使用其他组件	部分场景除了 Hive 权限，还可能需要组件的权限，例如： • 执行部分 HQL 命令，例如 **insert**，**count**，**distinct**，**group by**，**order by**，**sort by** 或 **join** 等语句时，需要设置 YARN 权限。建议为每个 Hive 用户的角色添加此权限。 • 使用 Hive over HBase，例如在 Hive 中查询 HBase 表数据，需要设置 HBase 权限。

在一些特殊 Hive 使用场景下，需要单独设置其他权限。

表11-5 Hive 授权注意事项

可能场景	用户需要的权限
创建 Hive 数据库、表、外表，或者为已经创建的 Hive 表或外表添加分区，且 Hive 用户指定数据文件保存在“/user/hive/warehouse”以外的 HDFS 目录。	需要此目录已经存在，Hive 用户是目录的属主，且用户对目录拥有“读”、“写”和“执行”权限。同时用户对此目录上层的每一级目录都拥有“读”和“写”权限。然后管理员通过角色管理功能授予角色使用 Hive 的权限，会自动关联 HDFS 权限。
Hive 用户使用 **load** 将指定目录下所有文件或者指定文件，导入数据到 Hive 表。	• 数据源为 Linux 本地磁盘，指定目录时需要此目录已经存在，系统用户“omm”对此目录以及此目录上层的每一级目录拥有“r”和“x”的权限。指定文件时需要此文件已经存在，“omm”对此文件拥有“r”的权限，同时对此文件上层的每一级目录拥有“r”和“x”的权限。 • 数据源为 HDFS，指定目录时需要此目录已经存在，Hive 用户是目录属主，且用户对此目录及其子目录拥有“读”、“写”和“执行”权限，并且其上层的每一级目录拥有“读”和“写”权限。指定文件时需要此文件已经存在，Hive 用户是文件属主，且用户对文件拥有“读”、“写”和“执

可能场景	用户需要的权限
	行”权限，同时对此文件上层的每一级目录拥有“读”和“执行”权限。 说明 使用 **load** 从 Linux 本地磁盘导入数据时，文件需上传到执行命令的 HiveServer 并修改权限。建议使用客户端执行命令，可查看客户端连接的 HiveServer。例如，Hive 客户端显示“0: jdbc:hive2://10.172.0.43:21066/>”，表示当前连接的 HiveServer 节点 IP 地址为“10.172.0.43”。
创建函数、删除函数或者修改任意数据库。	需要授予“Hive 管理员权限”。
操作 Hive 中所有的数据库和表。	需加入到 supergroup 用户组，并且授予“Hive 管理员权限”。

11.4.2 创建 Hive 角色

操作场景

该任务指导 MRS 集群管理员在 Manager 创建并设置 Hive 的角色。Hive 角色可设置 Hive 管理员权限以及 Hive 数据表的数据操作权限。

用户使用 Hive 并创建数据库需要加入 hive 组，不需要角色授权。用户在 Hive 和 HDFS 中对自己创建的数据库或表拥有完整权限，可直接创建表、查询数据、删除数据、插入数据、更新数据以及授权他人访问表与对应 HDFS 目录与文件。默认创建的数据库或表保存在 HDFS 目录“/user/hive/warehouse”。

说明

- 安全模式支持创建 Hive 角色，普通模式不支持创建 Hive 角色。
- 如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.10 添加 Hive 的 Ranger 访问权限策略。

前提条件

- MRS 集群管理员已明确业务需求。
- 已登录 Manager。
- 已安装好 Hive 客户端。

操作步骤

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。

步骤 1 选择“系统 > 权限 > 角色”。

步骤 2 单击“添加角色”，输入“角色名称”和“描述”。

步骤 3 设置角色“配置资源权限”请参见表 11-6。

- 设置 HDFS 目录的读和执行权限。
  - 选择“*待操作集群的名称* >HDFS> 文件系统 >hdfs://hacluster/>user”，在“hive”的“权限”列，勾选“读”和“执行”。
  - 选择“*待操作集群的名称* >HDFS> 文件系统 >hdfs://hacluster/>user>hive”，在“warehouse”的“权限”列，勾选“读”和“执行”。
  - 选择“*待操作集群的名称* >HDFS> 文件系统 >hdfs://hacluster/>tmp”,在“hive-scratch”的“权限”列，勾选“读”和“执行”。
- “Hive 管理员权限”：Hive 管理员权限。
- “Hive 读写权限”：Hive 数据表管理权限，可设置与管理已创建的表的数据操作权限。

说明

- Hive 角色管理支持授予管理员权限、访问库、表和视图的权限。
- Hive 管理员权限不支持管理 HDFS 的权限。
- 如果数据库中的表或者表中的文件数量比较多，在授权时可能需要等待一段时间。例如表的文件数量为 1 万时，可能需要等待 2 分钟。

表11-6 设置角色

任务场景	角色授权操作
设置 Hive 管理员权限	在“配置资源权限”的表格中选择“*待操作集群的名称* >Hive”，勾选“Hive 管理员权限”。 **说明** 用户绑定 Hive 管理员角色后，在每个维护操作会话中，还需要执行以下操作： 1. 以客户端安装用户，登录安装 Hive 客户端的节点。 2. 执行以下命令配置环境变量。 例如，Hive 客户端安装目录为“/opt/hiveclient”，执行 **source /opt/hiveclient/bigdata_env** 3. 执行以下命令认证用户。 **kinit** *Hive 业务用户* 4. 执行以下命令登录客户端工具。 **beeline** 5. 执行以下命令更新 Hive 用户的管理员权限。 **set role admin;**
设置在默认数据库中，查询其他用户表的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* >Hive>Hive 读写权限”。 2. 在数据库列表中单击指定的数据库名称，显示数据库中的表。

任务场景	角色授权操作
	3. 在指定表的“权限”列，勾选“查询”。
设置在默认数据库中，插入其他用户表的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Hive > Hive 读写权限”。 2. 在数据库列表中单击指定的数据库名称，显示数据库中的表。 3. 在指定表的“权限”列，勾选“插入”。
设置在默认数据库中，导入数据到其他用户表的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Hive > Hive 读写权限”。 2. 在数据库列表中单击指定的数据库名称，显示数据库中的表。 3. 在指定表的“权限”列，勾选“删除”和“插入”。
设置提交 Hql 命令到 Yarn 执行的权限	部分业务需求使用的 Hql 命令将转化为 MapReduce 任务并提交到 Yarn 中执行，需要设置 Yarn 权限。例如运行的 HQL 使用了 **insert**，**count**，**distinct**，**group by**，**order by**，**sort by** 或 **join** 等语句的相关场景。 1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Yarn > 调度队列 > root”。 2. 在“default”队列的“权限”列，勾选“提交”。

步骤 4 单击“确定”，返回“角色”。

步骤 5 选择“权限 > 用户”，单击“添加用户”。

步骤 6 输入用户名，选择“用户类型”选择“人机”类型，设置用户密码，在用户组添加 Hive 相应权限的用户组并选择主组，绑定新创建的角色，单击“确定”完成 Hive 用户创建。

步骤 7 待用户生成后，即可使用该用户执行相应 SQL 语句。

----结束

11.4.3 配置 Hive 表、列或数据库的权限

操作场景

使用 Hive 表或者数据库时，如果用户访问别人创建的表或数据库，需要授予对应的权限。为了实现更严格权限控制，Hive 也支持列级别的权限控制。如果要访问别人创建的表上某些列，需要授予列权限。以下介绍使用 Manager 角色管理功能在表授权、列授权和数据库授权三个场景下的操作。

说明

- 安全模式支持配置 Hive 表、列或数据库的权限，普通模式不支持配置 Hive 表、列或数据库的权限。
- 如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.10 添加 Hive 的 Ranger 访问权限策略。

前提条件

- 获取一个拥有管理员权限的用户，例如“admin”。
- 请参考 11.4.2 创建 Hive 角色，在 Manager 界面创建一个角色，例如“hrole”，不需要设置 Hive 权限，设置提交 Hql 命令到 Yarn 执行的权限。
- 在 Manager 界面创建两个使用 Hive 的“人机”用户并加入“hive”组，例如“huser1”和“huser2”。“huser2”需绑定“hrole”。使用“huser1”创建一个数据库“hdb”，并在此数据库中创建表“htable”。

操作步骤

- 表授权

  用户在 Hive 和 HDFS 中对自己创建的表拥有完整权限，用户访问别人创建的表，需要授予权限。授予权限时只需要授予 Hive 元数据权限，HDFS 文件权限将自动关联。以授予用户对应角色在表“htable”中查询、插入和删除数据的权限为例，操作步骤如下：

  a. 在 FusionInsight Manager 界面，选择“系统 > 权限 > 角色”。
  b. 在角色“hrole”所在行，单击“修改”。
  c. 选择“*待操作的集群* > Hive > Hive 读写权限”。
  d. 在数据库列表中单击指定的数据库名称“hdb”，显示数据库中的表“htable”。
  e. 在表“htable”的“权限”列，勾选“查询”、“插入”和“删除”。
  f. 单击“确定”完成。

  说明

  在角色管理中，授予角色在 Hive 外表中查询、插入和删除数据的操作与 Hive 表相同，授予元数据权限将自动关联 HDFS 文件权限。

- 列授权

  用户在 Hive 和 HDFS 中对自己创建的表拥有完整权限，用户没有权限访问别人创建的表。如果要访问别人创建的表上某些列，需要授予列权限。授予权限时只需要授予 Hive 元数据权限，HDFS 文件权限将自动关联。以授予用户对应角色在表“htable”的列“hcol”中查询、插入数据的权限为例，操作步骤如下：

a. 在 FusionInsight Manager 界面，选择“系统 > 权限 > 角色”。
b. 在角色“hrole”所在行，单击“修改”。
c. 选择“*待操作的集群* > Hive > Hive 读写权限”。
d. 在数据库列表中单击指定的数据库名称“hdb”，显示数据库中的表“htable”，单击表“htable”，显示表下的列“hcol”。
e. 在列“hcol”的“权限”列，勾选“查询”和“插入”。
f. 单击“确定”完成。

说明

在权限管理中，授予元数据权限将自动关联 HDFS 文件权限，所以列授权后会增加表对应所有文件的 HDFS ACL 权限。

- 数据库授权

  用户在 Hive 和 HDFS 中对自己创建的数据库拥有完整权限，用户访问别人创建的数据库，需要授予权限。授予权限时只需要授予 Hive 元数据权限，HDFS 文件权限将自动关联。以授予用户对应角色在数据库“hdb”中查询和创建表的权限为例，操作步骤如下，不支持对角色授予数据库其他的操作权限：

  a. 在 FusionInsight Manager 界面，选择“系统 > 权限 > 角色”。
  b. 在角色“hrole”所在行，单击“修改”。
  c. 选择“*待操作的集群* > Hive > Hive 读写权限”。
  d. 在数据库“hdb”的“权限”列，勾选“查询”和“建表”。
  e. 单击“确定”完成。

  说明

  - 在权限管理中，为了方便用户使用，授予数据库下表的任意权限将自动关联该数据库目录的 HDFS 权限。为了避免产生性能问题，取消表的任意权限，系统不会自动取消数据库目录的 HDFS 权限，但对应的用户只能登录数据库和查看表名。
  - 若为角色添加或删除数据库的查询权限，数据库中的表也将自动添加或删除查询权限。
  - MRS 3.2.0 及之后版本，若数据库中分区超过百万级，并且分区都在表目录下。如需加快授权速度，可以在 FusionInsight Manager 界面，选择“集群 > 服务 > Hive > 配置 > 全部配置 > MetaStore（角色） > 自定义”，添加“hive-ext.skip.grant.partition”参数，值为“true”。添加该参数后在库授权时会跳过分区扫描。需要重启 Metastore 实例生效。

相关概念

表11-7 使用 Hive 表、列或数据库场景权限一览

操作场景	用户需要的权限
DESCRIBE TABLE	查询（Select）
SHOW PARTITIONS	查询（Select）
ANALYZE TABLE	查询（Select）、插入（Insert）
SHOW COLUMNS	查询（Select）
SHOW TABLE STATUS	查询（Select）

操作场景	用户需要的权限
SHOW TABLE PROPERTIES	查询（Select）
SELECT	查询（Select）
EXPLAIN	查询（Select）
CREATE VIEW	查询（Select）、Select 授权（Grant Of Select）、建表（Create）
SHOW CREATE TABLE	查询（Select）、Select 授权（Grant Of Select）
CREATE TABLE	建表（Create）
ALTER TABLE ADD PARTITION	插入（Insert）
INSERT	插入（Insert）
INSERT OVERWRITE	插入（Insert）、删除（Delete）
LOAD	插入（Insert）、删除（Delete）
ALTER TABLE DROP PARTITION	删除（Delete）
CREATE FUNCTION	Hive 管理员权限（Hive Admin Privilege）
DROP FUNCTION	Hive 管理员权限（Hive Admin Privilege）
ALTER DATABASE	Hive 管理员权限（Hive Admin Privilege）

11.4.4 配置 Hive 业务使用其他组件的权限

操作场景

Hive 业务还可能需要关联使用其他组件，例如 HQL 语句触发 MapReduce 任务需要设置 Yarn 权限，或者 Hive over HBase 的场景需要 HBase 权限。以下介绍 Hive 关联 Yarn 和 Hive over HBase 两个场景下的操作。

说明

- 安全模式下 Yarn 和 HBase 的权限管理默认是开启的，因此在安全模式下默认需要配置 Yarn 和 HBase 权限。
- 在普通模式下，Yarn 和 HBase 的权限管理默认是关闭的，即任何用户都有权限，因此普通模式下默认不需要配置 Yarn 和 HBase 权限。如果用户修改了 YARN 或者 HBase 的配置来开启权限管理，则修改后也需要配置 Yarn 和 HBase 权限。
- 如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.10 添加 Hive 的 Ranger 访问权限策略。

前提条件

- 完成 Hive 客户端的安装。例如安装目录为“/opt/client”。
- 获取一个拥有管理员权限的用户，例如“admin”。

操作步骤

Hive 关联 Yarn

用户如果执行 **insert**，**count**，**distinct**，**group by**，**order by**，**sort by** 或 **join** 等语句时，将触发 MapReduce 任务，需要设置 Yarn 权限。以授予角色在表“thc”执行 **count** 语句的权限为例，操作步骤如下：

在 FusionInsight Manager 角色界面创建一个角色。

步骤 1 在“配置资源权限”的表格中选择“*待操作集群的名称* > Yarn > 调度队列 > root”。

步骤 2 在“default”队列的“权限”列，勾选“提交”，单击“确定”保存。

步骤 3 在“配置资源权限”的表格中选择“*待操作集群的名称* > Hive > Hive 读写权限 > default”，勾选表“thc”的“查询”，单击“确定”保存。

----结束

Hive over HBase 授权

用户如果需要使用类似 SQL 语句的方式来操作 HBase 表，授予权限后可以在 Hive 中使用 HQL 命令访问 HBase 表。以授予用户在 Hive 中查询 HBase 表的权限为例，操作步骤如下

在 FusionInsight Manager 角色管理界面创建一个 HBase 角色，例如“hive_hbase_create”，并授予创建 HBase 表的权限。

在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global”，勾选命名空间“default”的“创建”，单击“确定”保存。

步骤 4 在 FusionInsight Manager 用户管理界面创建一个“人机”用户，例如“hbase_creates_user”，加入“hive”组，绑定角色“hive_hbase_create”，用于创建 Hive 表和 HBase 表。

步骤 5 如果当前组件使用了 Ranger 进行权限控制，需给“hive_hbase_create”或“hbase_creates_user”配置“Create”权限，具体操作可参考 20.10 添加 Hive 的 Ranger 访问权限策略。

步骤 6 以客户端安装用户，登录安装客户端的节点。

步骤 7 执行以下命令，配置环境变量。

source /opt/client/bigdata_env

步骤 8 执行以下命令，认证用户。

kinit hbase_creates_user

步骤 9 执行以下命令，进入 Hive 客户端 shell 环境：

beeline

步骤 10 执行以下命令，同时在 Hive 和 HBase 中创建表。例如创建表“thh”。

CREATE TABLE thh(id int, name string, country string) STORED BY 'org.apache.hadoop.hive.hbase.HBaseStorageHandler' WITH SERDEPROPERTIES("hbase.columns.mapping" = "cf1:id,cf1:name,:key") TBLPROPERTIES ("hbase.table.name" = "thh");

创建好的 Hive 表和 HBase 表分别保存在 Hive 的数据库“default”和 HBase 的命名空间“default”。

步骤 11 在 FusionInsight Manager 角色管理界面创建一个角色，例如“hive_hbase_select”，并授予查询 Hive 表“thh”和 HBase 表“thh”的权限。

1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global > default”，勾选表“thh”的“读”，单击“确定”保存，授予 HBase 角色查询表的权限。
2. 编辑角色，在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global > hbase”，勾选表“hbase:meta”的“执行”，单击“确定”保存。
3. 编辑角色，在“配置资源权限”的表格中选择“*待操作集群的名称* > Hive > Hive 读写权限 > default”，勾选表“thh”的“查询”，单击“确定”保存。

步骤 12 在 FusionInsight Manager 用户管理界面创建一个“人机”用户，例如“hbase_select_user”，加入“hive”组，绑定角色“hive_hbase_select”，用于查询 Hive 表和 HBase 表。

步骤 13 执行以下命令，配置环境变量。

source /opt/client/bigdata_env

步骤 14 执行以下命令，认证用户。

kinit hbase_select_user

步骤 15 执行以下命令，进入 Hive 客户端 shell 环境。

beeline

步骤 16 执行以下命令，使用 Hive 的 HQL 语句查询 HBase 表的数据。

select * from thh;

----结束

11.5 使用 Hive 客户端

操作场景

该任务指导用户在运维场景或业务场景中使用 Hive 客户端。

前提条件

- 已安装客户端，例如安装目录为“/opt/hadoopclient”，以下操作的客户端目录只是举例，请根据实际安装目录修改。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建。安全模式下，“机机”用户需要下载 keytab 文件。“人机”用户第一次登录时需修改密码。

使用 Hive 客户端

以客户端安装用户，登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd /opt/hadoopclient

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 根据集群认证模式，完成 Hive 客户端登录。

- 安全模式，则执行以下命令，完成用户认证并登录 Hive 客户端。

  kinit *组件业务用户*

  beeline

- 普通模式，则执行以下命令，登录 Hive 客户端，如果不指定组件业务用户，则会以当前操作系统用户登录。

  beeline -n *组件业务用户*

步骤 4 使用以下命令，执行 HCatalog 的客户端命令。

hcat -e *"cmd"*

其中*"cmd"*必须为 Hive DDL 语句，如 **hcat -e "show tables"**。

说明

- 若要使用 HCatalog 客户端，必须从服务页面选择“更多 > 下载客户端”，下载全部服务的客户端。Beeline 客户端不受此限制。
- 由于权限模型不兼容，使用 HCatalog 客户端创建的表，在 HiveServer 客户端中不能访问，但可以使用 WebHCat 客户端访问。
- 在普通模式下使用 HCatalog 客户端，系统将以当前登录操作系统用户来执行 DDL 命令。
- 退出 beeline 客户端时请使用**!q** 命令，不要使用“Ctrl + C”。否则会导致连接生成的临时文件无法删除，长期会累积产生大量的垃圾文件。
- 在使用 beeline 客户端时，如果需要在一行中输入多条语句，语句之间以“;”分隔，需要将“entireLineAsCommand”的值设置为“false”。

  设置方法：如果未启动 beeline，则执行 **beeline --entireLineAsCommand=false** 命令；如果已启动 beeline，则在 beeline 中执行**!set entireLineAsCommand false** 命令。

  设置完成后，如果语句中含有不是表示语句结束的“;”，需要进行转义，例如 **select concat_ws('\;', collect_set(col1)) from tbl**。

----结束

Hive 客户端常用命令

常用的 Hive Beeline 客户端命令如下表所示。

表11-8 Hive Beeline 客户端常用命令

命令	说明
set <key>=<value>	设置特定配置变量（键）的值。 说明 若变量名拼错，Beeline 不会显示错误。
set	打印由用户或 Hive 覆盖的配置变量列表。
set -v	打印 Hadoop 和 Hive 的所有配置变量。
add FILE[S] <filepath> <filepath>* add JAR[S] <filepath> <filepath>* add ARCHIVE[S] <filepath> <filepath>*	将一个或多个文件、JAR 文件或 ARCHIVE 文件添加至分布式缓存的资源列表中。
add FILE[S] <ivyurl> <ivyurl>* add JAR[S] <ivyurl> <ivyurl>* add ARCHIVE[S] <ivyurl> <ivyurl>*	使用“ivy://goup:module:version?query_string”格式的 lvy URL，将一个或多个文件、JAR 文件或 ARCHIVE 文件添加至分布式缓存的资源列表中。
list FILE[S] list JAR[S] list ARCHIVE[S]	列出已添加至分布式缓存中的资源。
list FILE[S] <filepath>* list JAR[S] <filepath>* list ARCHIVE[S] <filepath>*	检查给定的资源是否已添加至分布式缓存中。
delete FILE[S] <filepath>* delete JAR[S] <filepath>* delete ARCHIVE[S] <filepath>*	从分布式缓存中删除资源。
delete FILE[S] <ivyurl> <ivyurl>* delete JAR[S] <ivyurl> <ivyurl>* delete ARCHIVE[S] <ivyurl> <ivyurl>*	从分布式缓存中删除使用<ivyurl>添加的资源。
reload	使 HiveServer2 发现配置参数指定路径下 JAR 文件的变更“hive.reloadable.aux.jars.path”（无需重启

命令	说明
	HiveServer2）。更改操作包括添加、删除或更新 JAR 文件。
dfs <dfs command>	执行 dfs 命令。
<query string>	执行 Hive 查询，并将结果打印到标准输出。

11.6 使用 HDFS Colocation 存储 Hive 表

操作场景

HDFS Colocation（同分布）是 HDFS 提供的数据分布控制功能，利用 HDFS Colocation 接口，可以将存在关联关系或者可能进行关联操作的数据存放在相同的存储节点上。Hive 支持 HDFS 的 Colocation 功能，即在创建 Hive 表时，设置表文件分布的 locator 信息，当使用 insert 语句向该表中插入数据时会将该表的数据文件存放在相同的存储节点上（不支持其他数据导入方式），从而使后续的多表关联的数据计算更加方便和高效。表格式只支持 TextFile 和 RCFile。

操作步骤

使用客户端安装用户登录客户端所在节点。

步骤 1 执行以下命令，切换到客户端安装目录，如：/opt/client。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 若集群为安全模式，执行以下命令认证用户。

kinit *MRS 用户名*

步骤 4 通过 HDFS 接口创建<*groupid*>

hdfs colocationadmin -createGroup -groupId <*groupid*> -locatorIds <*locatorid1*>,<*locatorid2*>,<*locatorid3*>

说明

其中<*groupid*>为创建的 group 名称，该示例语句创建的 group 包含三个 locator，用户可以根据需要定义 locator 的数量。

关于 hdfs 创建 groupid，以及 HDFS Colocation 的详细介绍请参考 hdfs 的相关说明，这里不做赘述。

步骤 5 执行以下命令进入 Hive 客户端：

beeline

步骤 6 Hive 使用 colocation。

假设 table_name1 和 table_name2 是相关联的两张表，创建两表的语句如下：

CREATE TABLE <*[db_name.]table_name1*>*[(col_name data_type , ...)]* [ROW FORMAT <*row_format*>] [STORED AS <*file_format*>] TBLPROPERTIES("groupId"=" <*group*> ","locatorId"="<*locator1*>");

CREATE TABLE <*[db_name.]table_name2*> *[(col_name data_type , ...)]* [ROW FORMAT <*row_format*>] [STORED AS <*file_format*>] TBLPROPERTIES("groupId"=" <*group*> ","locatorId"="<*locator1*>");

当使用 insert 语句分别向 table_name1 和 table_name2 插入数据后，table_name1 和 table_name2 的数据文件就会分布在 hdfs 的相同存储位置上，从而方便两表进行关联操作。

----结束

11.7 使用 Hive 列加密功能

操作场景

Hive 支持对表的某一列或者多列进行加密；在创建 Hive 表时，可以指定要加密的列和加密算法。当使用 insert 语句向表中插入数据时，即可实现将对应列加密。列加密只支持存储在 HDFS 上的 TextFile 和 SequenceFile 文件格式的表。Hive 列加密不支持视图以及 Hive over HBase 场景。

Hive 列加密机制目前支持的加密算法有两种，在建表时指定：

- AES(对应加密类名称为：org.apache.hadoop.hive.serde2.AESRewriter)
- SMS4(对应加密类名称为：org.apache.hadoop.hive.serde2.SMS4Rewriter)

说明

将原始数据从普通 Hive 表导入到 Hive 列加密表后，在不影响其他业务情况下，建议删除普通 Hive 表上原始数据，因为保留一张未加密的表存在安全风险。

操作步骤

在创建表时指定相应的加密列和加密算法：

create table<*[db_name.]table_name*> (<*col_name1*> <*data_type*> ,<*col_name2*> <*data_type*>,<*col_name3*> <*data_type*>,<*col_name4*> <*data_type*>) ROW FORMAT SERDE 'org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe' WITH SERDEPROPERTIES ('column.encode.columns'='<*col_name2*>,<*col_name3*>', 'column.encode.classname'='org.apache.hadoop.hive.serde2.AESRewriter')STORED AS TEXTFILE;

或者使用如下语句：

create table <*[db_name.]table_name*> (<*col_name1*> <*data_type*> ,<*col_name2*> <*data_type*>,<*col_name3*> <*data_type*>,<*col_name4*> <*data_type*>) ROW FORMAT SERDE 'org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe' WITH SERDEPROPERTIES ('column.encode.indices'='1,2', 'column.encode.classname'='org.apache.hadoop.hive.serde2.SMS4Rewriter') STORED AS TEXTFILE;

说明

- 使用序号指定加密列时，序号从 0 开始。0 代表第 1 列，1 代表第 2 列，依次类推。
- 创建列加密表时，表所在的目录必须是空目录。

步骤 1 使用 insert 语法向设置列加密的表中导入数据。

假设 test 表已存在且有数据：

insert into table <*table_name*> select <*col_list*> from test;

----结束

11.8 自定义行分隔符

操作场景

通常情况下，Hive 以文本文件存储的表会以回车作为其行分隔符，即在查询过程中，以回车符作为一行表数据的结束符。但某些数据文件并不是以回车分隔的规则文本格式，而是以某些特殊符号分割其规则文本。

MRS Hive 支持指定不同的字符或字符组合作为 Hive 文本数据的行分隔符，即在创建表的时候，指定 inputformat 为 SpecifiedDelimiterInputFormat，然后在每次查询前，都设置如下参数来指定分隔符，就可以以指定的分隔符查询表数据。

set hive.textinput.record.delimiter='';

说明

当前版本的 Hue 组件，不支持导入文件到 Hive 表时设置多个分割符。

操作步骤

创建表时指定 inputFormat 和 outputFormat：

CREATE [TEMPORARY] [EXTERNAL] TABLE [IF NOT EXISTS] *[db_name.]table_name* **[(***col_name data_type* **[COMMENT** *col_comment*], ...)] [ROW FORMAT** *row_format*] **STORED AS inputformat 'org.apache.hadoop.hive.contrib.fileformat.SpecifiedDelimiterInputFormat' outputformat 'org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat'**

步骤 1 查询之前指定配置项：

set hive.textinput.record.delimiter='!@!'

Hive 会以‘!@!’为行分隔符查询数据。

----结束

11.9 配置跨集群互信下 Hive on HBase

两个开启 Kerberos 认证的互信集群中，使用 Hive 集群操作 HBase 集群，将目的端 HBase 集群的 HBase 关键配置项配置到源端 Hive 集群的 HiveServer 中。

前提条件

两个开启 Kerberos 认证的安全集群已完成跨集群互信配置。

跨集群配置 Hive on HBase

下载 HBase 配置文件到本地，并解压。

1. 登录目的端 HBase 集群的 FusionInsight Manager，选择“集群 > 服务 > HBase”。
2. 选择“更多 > 下载客户端”。
3. 下载 HBase 配置文件，客户端类型选择仅配置文件。

步骤 1 登录源端 Hive 集群的 FusionInsight Manager。

步骤 2 选择“集群 > 服务 > Hive > 配置 > 全部配置”进入 Hive 服务配置页面，修改 HiveServer 角色的 hive-site.xml 自定义配置文件，增加 HBase 配置文件的如下配置项。

从已下载的 HBase 客户端配置文件的 hbase-site.xml 中，搜索并添加如下配置项及其取值到 HiveServer 中。

- hbase.security.authentication
- hbase.security.authorization
- hbase.zookeeper.property.clientPort
- hbase.zookeeper.quorum（域名需要转换为 IP）
- hbase.regionserver.kerberos.principal
- hbase.master.kerberos.principal

步骤 3 保存配置并重启 Hive 服务。

----结束

11.10 删除 Hive on HBase 表中的单行记录

操作场景

由于底层存储系统的原因，Hive 并不能支持对单条表数据进行删除操作，但在 Hive on HBase 功能中，MRS Hive 提供了对 HBase 表的单条数据的删除功能，通过特定的语法，Hive 可以将自己的 HBase 表中符合条件的一条或者多条数据清除。

表11-9 删除 Hive on HBase 表中的单行记录所需权限

集群认证模式	用户所需权限
安全模式	“SELECT”、“INSERT”和“DELETE”
普通模式	无

操作步骤

如果要删除某张 HBase 表中的某些数据，可以执行 HQL 语句：

remove table <*table_name*> where <*expression*>;

其中<*expression*>规定要删除数据的筛选条件；<*table_name*>为要删除数据的 Hive on HBase 表。

----结束

11.11 配置基于 HTTPS/HTTP 协议的 REST 接口

操作场景

WebHCat 为 Hive 提供了对外可用的 REST 接口，开源社区版本默认使用 HTTP 协议。

MRS Hive 支持使用更安全的 HTTPS 协议，并且可以在两种协议间自由切换。

说明

安全模式支持 HTTPS 和 HTTP 协议，普通模式只支持 HTTP 协议。

操作步骤

进入 Hive 服务配置页面：

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。然后选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 修改 Hive 配置：

选择“WebHCat > 安全”，在该界面选择 HTTPS 或者 HTTP，修改后重启 Hive 服务即可使用对应的协议。

----结束

11.12 配置是否禁用 Transform 功能

操作场景

Hive 开源社区版本禁用 Transform 功能。

MRS Hive 提供配置开关，默认为禁用 Transform 功能，与开源社区版本保持一致。

用户可修改配置开关，开启 Transform 功能，当开启 Transform 功能时，存在一定的安全风险。

说明

只有安全模式支持禁用 Transform 功能，普通模式不支持该功能。

操作步骤

进入 Hive 服务配置页面：

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。然后选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 在搜索框中输入参数名称，搜索“hive.security.transform.disallow”，修改参数值为“true”或“false”，修改后重启所有 HiveServer 实例。

说明

- 选择“true”时，禁用 Transform 功能，与开源社区版本保持一致。
- 选择“false”时，开启 Transform 功能，存在一定的安全风险。

----结束

11.13 Hive 支持创建单表动态视图授权访问控制

操作场景

MRS 中安全模式下 Hive 可以创建一个视图并控制用户访问权限，支持授权给不同的用户访问，又可以限定不同用户只能访问的不同数据。

在视图中，Hive 可以通过获取当前客户端提交任务的用户的内置函数“current_user()”来进行过滤，这样被授权的用户，在访问视图时，即可被限定访问对应的数据。

说明

- 在普通模式下“current_user()”函数无法区别客户端提交任务的用户，因此，当前访问控制仅对安全模式下的 Hive 有效。
- 如果已经在实际业务逻辑中使用了“current_user()”函数，那么，在安全模式与普通模式互转时，需要充分评估可能的风险。

操作示例

- 不采用“current_user”函数，要实现不同的用户，访问不同数据，需要创建不同的视图：

- 将视图 v1 授权给用户 hiveuser1，hiveuser1 用户可以访问表 table1 中“type='hiveuser1'”的数据：

  create view v1 as select * from table1 where type='hiveuser1'

- 将视图 v2 授权给用户 hiveuser2，hiveuser2 用户可以访问表 table1 中“type='hiveuser2'”的数据：

  create view v2 as select * from table1 where type='hiveuser2'

- 采用“current_user”函数，则只需要创建一个视图：

  将视图 v 分别赋给用户 hiveuser1、hiveuser2，当 hiveuser1 查询视图 v 时，“current_user()”被自动转化为 hiveuser1，当 hiveuser2 查询视图 v 时，“current_user()”被自动转化为 hiveuser2：

  create view v as select * from table1 where type=current_user()

11.14 配置创建临时函数是否需要 ADMIN 权限

操作场景

Hive 开源社区版本创建临时函数需要用户具备 ADMIN 权限。

MRS Hive 提供配置开关，默认为创建临时函数需要 ADMIN 权限，与开源社区版本保持一致。

用户可修改配置开关，实现创建临时函数不需要 ADMIN 权限。当该选项配置成 false 时，存在一定的安全风险。

说明

安全模式支持配置创建临时函数是否需要 ADMIN 权限功能，而普通模式不支持该功能。

操作步骤

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 在搜索框中输入参数名称，搜索“hive.security.temporary.function.need.admin”，修改参数值为“true”或“false”，修改后重启所有 HiveServer 实例。

说明

- 选择“true”时，创建临时函数需要 ADMIN 权限，与开源社区版本保持一致。
- 选择“false”时，创建临时函数不需要 ADMIN 权限。

----结束

11.15 使用 Hive 读取关系型数据库数据

操作场景

Hive 支持创建与其他关系型数据库关联的外表。该外表可以从关联到的关系型数据库中读取数据，并与 Hive 的其他表进行 Join 操作。

目前支持使用 Hive 读取数据的关系型数据库如下：

- DB2
- Oracle

前提条件

已安装 Hive 客户端。

操作步骤

以 Hive 客户端安装用户登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd *客户端安装目录*

例如安装目录为“/opt/client”，则执行以下命令：

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 集群认证模式是否为安全模式。

- 是，执行以下命令进行用户认证：

  kinit *Hive 业务用户*
- 否，执行步骤 5。

步骤 4 执行以下命令，将需要关联的关系型数据库驱动 Jar 包上传到 HDFS 目录下。

hdfs dfs -put *Jar 包所在目录 保存 Jar 包的 HDFS 目录*

例如将“/opt”目录下 ORACLE 驱动 Jar 包上传到 HDFS 的“/tmp”目录下，则执行如下命令。

hdfs dfs -put /opt/ojdbc6.jar /tmp

步骤 5 按照如下示例，在 Hive 客户端创建关联关系型数据库的外表。

说明

如果是安全模式，建表的用户需要“ADMIN”权限，**ADD JAR** 的路径请以实际路径为准。

```
-- 关联 oracle linux6 版本示例
-- 如果是安全模式，设置 admin 权限
set role admin;
```

```
-- 添加连接关系型数据库的驱动 jar 包,不同数据库有不同的驱动 JAR
ADD JAR hdfs:///tmp/ojdbc6.jar;

CREATE EXTERNAL TABLE ora_test
-- hive 表的列需比数据库返回结果多一列用于分页查询
(id STRING,rownum string)
STORED BY 'com.qubitproducts.hive.storage.jdbc.JdbcStorageHandler'
TBLPROPERTIES (
-- 关系型数据库类型
"qubit.sql.database.type" = "ORACLE",
-- 通过 JDBC 连接关系型数据库的 url（不同数据库有不同的 url 格式）
"qubit.sql.jdbc.url" = "jdbc:oracle:thin:@//10.163.0.1:1521/mydb",
-- 关系型数据库驱动类名
"qubit.sql.jdbc.driver" = "oracle.jdbc.OracleDriver",
-- 在关系型数据库查询的 sql 语句,结果将返回 hive 表
"qubit.sql.query" = "select name from aaa",
-- hive 表的列与关系型数据库表的列进行匹配（可忽略）
"qubit.sql.column.mapping" = "id=name",
-- 关系型数据库用户
"qubit.sql.dbcp.username" = "test",
-- 关系型数据库密码，命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的
history 命令记录功能，避免信息泄露。
"qubit.sql.dbcp.password" = "xxx");
```

----结束

11.16 Hive 支持的传统关系型数据库语法

概述

Hive 支持如下传统关系型数据库语法：

- Grouping
- EXCEPT、INTERSECT

Grouping

语法简介：

- 当 Group by 语句带 with rollup/cube 选项时，Grouping 才有意义。
- CUBE 生成的结果集显示了所选列中值的所有组合的聚合。
- ROLLUP 生成的结果集显示了所选列中值的某一层次结构的聚合。
- Grouping：当用 CUBE 或 ROLLUP 运算符添加行时，附加的列输出值为 1；当所添加的行不是由 CUBE 或 ROLLUP 产生时，附加列值为 0。

例如，Hive 中有一张表“table_test”，表结构如下所示：

```
+----------------+-------------------+--+
| table_test.id  | table_test.value  |
+----------------+-------------------+--+
| 1              | 10                |
```

```
| 1            | 15              |
| 2            | 20              |
| 2            | 5               |
| 2            | 13              |
+--------------+-----------------+--+
```

执行如下语句：

select id,grouping(id),sum(value) from table_test group by id with rollup;

得到如下结果：

```
+-------+-----------------+------+--+
|  id   | groupingresult  | sum  |
+-------+-----------------+------+--+
| 1     | 0               | 25   |
| NULL  | 1               | 63   |
| 2     | 0               | 38   |
+-------+-----------------+------+--+
```

EXCEPT、INTERSECT

语法简介

- EXCEPT 返回两个结果集的差（即从左查询中返回右查询没有找到的所有非重复值）。
- INTERSECT 返回两个结果集的交集（即两个查询都返回的所有非重复值）。

例如，Hive 中有两张表“test_table1”、“test_table2”。

“test_table1”表结构如下所示：

```
+-----------------+--+
| test_table1.id  |
+-----------------+--+
| 1               |
| 2               |
| 3               |
| 4               |
+-----------------+--+
```

“test_table2”表结构如下所示：

```
+-----------------+--+
| test_table2.id  |
+-----------------+--+
| 2               |
| 3               |
| 4               |
| 5               |
+-----------------+--+
```

- 执行如下的 EXCEPT 语句：
  select id from test_table1 except select id from test_table2;
  显示如下结果：

```
+---------------+--+
| _alias_0.id  |
+---------------+--+
| 1           |
+---------------+--+
```

- 执行 INTERSECT 语句：

  select id from test_table1 intersect select id from test_table2;

  显示如下结果：

```
+---------------+--+
| _alias_0.id  |
+---------------+--+
| 2           |
| 3           |
| 4           |
+---------------+--+
```

11.17 创建 Hive 用户自定义函数

当 Hive 的内置函数不能满足需要时，可以通过编写用户自定义函数 UDF（User-Defined Functions）插入自己的处理代码并在查询中使用它们。

按实现方式，UDF 分如下分类：

- 普通的 UDF，用于操作单个数据行，且产生一个数据行作为输出。
- 用户定义聚集函数 UDAF（User-Defined Aggregating Functions），用于接受多个输入数据行，并产生一个输出数据行。
- 用户定义表生成函数 UDTF（User-Defined Table-Generating Functions），用于操作单个输入行，产生多个输出行。

按使用方法，UDF 有如下分类：

- 临时函数，只能在当前会话使用，重启会话后需要重新创建。
- 永久函数，可以在多个会话中使用，不需要每次创建。

说明

用户自定义函数需要用户控制函数中变量的内存、线程等资源的占用，如果控制不当可能会导致内存溢出、CPU 使用高等问题。

下面以编写一个 AddDoublesUDF 为例，说明 UDF 的编写和使用方法。

功能介绍

AddDoublesUDF 主要用来对两个及多个浮点数进行相加，在该样例中可以掌握如何编写和使用 UDF。

说明

- 一个普通 UDF 必须继承自“org.apache.hadoop.hive.ql.exec.UDF”。
- 一个普通 UDF 必须至少实现一个 evaluate()方法，evaluate 函数支持重载。

- 开发自定义函数需要在工程中添加“hive-exec-*.jar”依赖包，可从 Hive 服务的安装目录下获取，例如在“${BIGDATA_HOME}/components/FusionInsight_HD_*/Hive/disaster/plugin/lib/”目录下获取。

样例代码

以下为 UDF 示例代码：

其中，xxx 通常为程序开发的组织名称。

```
package com.xxx.bigdata.hive.example.udf;
import org.apache.hadoop.hive.ql.exec.UDF;

public class AddDoublesUDF extends UDF {
 public Double evaluate(Double... a) {
   Double total = 0.0;
   // 处理逻辑部分.
   for (int i = 0; i < a.length; i++)
     if (a[i] != null)
       total += a[i];
   return total;
  }
}
```

如何使用

在客户端安装节点，把以上程序打包成 AddDoublesUDF.jar，并上传到 HDFS 指定目录下（例如“/user/hive_examples_jars”）。

创建函数的用户与使用函数的用户都需要具有该文件的可读权限。

示例语句：

hdfs dfs -put ./hive_examples_jars /user/hive_examples_jars

hdfs dfs -chmod 777 /user/hive_examples_jars

步骤 1 判断集群的认证模式。

- 安全模式，需要使用一个具有 Hive 管理权限的用户登录 beeline 客户端，执行如下命令：

  kinit *Hive 业务用户*

  beeline

  set role admin;

- 普通模式，执行如下命令：

  beeline -n *Hive 业务用户*

步骤 2 在 Hive Server 中定义该函数，以下语句用于创建永久函数：

CREATE FUNCTION *addDoubles* **AS**
'com.*xxx*.bigdata.hive.example.udf.AddDoublesUDF' using jar
'hdfs://hacluster/user/hive_examples_jars/AddDoublesUDF.jar';

其中 *addDoubles* 是该函数的别名，用于 SELECT 查询中使用；xxx 通常为程序开发的组织名称。

以下语句用于创建临时函数：

CREATE TEMPORARY FUNCTION addDoubles AS 'com.*xxx*.bigdata.hive.example.udf.AddDoublesUDF' using jar 'hdfs://hacluster/user/hive_examples_jars/AddDoublesUDF.jar';

- *addDoubles* 是该函数的别名，用于 SELECT 查询中使用。
- 关键字 TEMPORARY 说明该函数只在当前这个 Hive Server 的会话过程中定义使用。

步骤 3 在 Hive Server 中使用该函数，执行 SQL 语句：

SELECT addDoubles(1,2,3);

说明

若重新连接客户端再使用函数出现[Error 10011]的错误，可执行 **reload function;**命令后再使用该函数。

步骤 4 在 Hive Server 中删除该函数，执行 SQL 语句：

DROP FUNCTION addDoubles;

----结束

扩展应用

无

11.18 beeline 可靠性增强特性介绍

操作场景

- 在批处理任务运行过程中，beeline 客户端由于网络异常等问题断线时，Hive 能支持 beeline 在断线前已经提交的任务继续运行。当再次运行该批处理任务时，已经提交过的任务不再重新执行，直接从下一个任务开始执行。
- 在批处理任务运行过程中，HiveServer 服务由于某些原因导致宕机时，Hive 能支持当再次运行该批处理任务时，已经成功执行完成的任务不再重新执行，直接从 HiveServer2 宕机时正在运行的任务开始运行。

操作示例

1. beeline 启动断线重连功能。

   示例：

   beeline -e "${*SQL*}" --hivevar batchid=*xxxxx*

2. beeline kill 正在运行的任务。

   示例：

   beeline -e "" --hivevar batchid=*xxxxx* --hivevar kill=true

3. 登录 beeline 客户端，启动断线重连机制。

   登录 beeline 客户端后，执行“set hivevar:batchid=*xxxx*”

说明

使用说明：

- 其中“*xxxx*”表示每一次通过 beeline 提交任务的批次号，通过该批次号，可以识别出先提交的任务。如果提交任务时不带批次号，该特性功能不会启用。“*xxxx*”的值是执行任务时指定的，如下所示，“*xxxx*”值为“012345678901”：

  beeline -f hdfs://hacluster/user/hive/table.sql --hivevar batchid=012345678901

- 如果运行的 SQL 脚本依赖数据的失效性，建议不启用断点重连机制，或者每次运行时使用新的 batchid。因为重复执行时，可能由于某些 SQL 语句已经执行过了不再重新执行，导致获取到过期的数据。
- 如果 SQL 脚本中使用了一些内置时间函数，建议不启用断点重连机制，或者每次运行时使用新的 batchid，理由同上。
- 一个 SQL 脚本里面会包含一个或多个子任务。如果 SQL 脚本中存在先创建再删除临时表的逻辑，建议将删除临时表的逻辑放到脚本的最后。假定删除临时表子任务的后续子任务执行失败，并且删除临时表的子任务之前的子任务用到了该临时表；当下一次以相同 batchid 执行该 SQL 脚本时，因为临时表在上一次执行时已被删除，则会导致删除临时表的子任务之前用到该临时表的子任务（不包括创建该临时表的子任务，因为上一次已经执行成功，本次不会再执行，仅可编译）编译失败。这种情况下，建议使用新的 batchid 执行脚本。

参数说明：

- zk.cleanup.finished.job.interval：执行清理任务的间隔时间，默认隔 60s 执行一次。
- zk.cleanup.finished.job.outdated.threshold：节点的过期时间，每个批次的任务都会生成对应节点，从当前批次任务的结束时间开始算，如果超过 60 分钟，则表示已经过期了，那么就清除节点。
- batch.job.max.retry.count：单批次任务的最大重试次数，当单批次的任务失败重试次数超过这个值，就会删除该任务记录，下次运行时将从头开始运行，默认是 10 次。
- beeline.reconnect.zk.path：存储任务执行进度的根节点，Hive 服务默认是/beeline。

11.19 具备表 select 权限可用 show create table 查看表结构

操作场景

此功能适用于 Hive，Spark2x。

开启此功能后，使用 Hive 建表时，其他用户被授予 select 权限后，可通过 **show create table** 查看表结构。

操作步骤

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 选择“HiveServer（角色） > 自定义”，对参数文件“hive-site.xml”添加自定义参数，设置“名称”为“hive.allow.show.create.table.in.select.nogrant”，“值”为“true ”，修改后重启所有 Hive 实例。

步骤 2 是否需要在 Spark/Spark2x 客户端中启用此功能？

- 是，重新下载并安装 Spark/Spark2x 客户端。
- 否，操作结束。

----结束

11.20 Hive 写目录旧数据进回收站

操作场景

此功能适用于 Hive 组件。

开启此功能后，执行写目录：**insert overwrite directory "*/path1*" ...**，写成功之后，会将旧数据移除到回收站，并且同时限制该目录不能为 Hive 元数据库中已经存在的数据库路径。

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 选择“HiveServer（角色） > 自定义”，对参数文件“hive-site.xml”添加自定义参数，设置“名称”为“hive.overwrite.directory.move.trash”，“值”为“true”，修改后重启所有 Hive 实例。

----结束

11.21 Hive 能给一个不存在的目录插入数据

操作场景

此功能适用于 Hive 组件。

开启此功能后，在执行写目录：**insert overwrite directory** *“/path1/path2/path3”* ... 时，其中“*/path1/path2*”目录权限为 700 且属主为当前用户，“*path3*”目录不存在，会自动创建“*path3*”目录，并写数据成功。

上述功能，在 Hive 参数“hive.server2.enable.doAs”为“true”时已经支持，本次增加当“hive.server2.enable.doAs”为“false”时的功能支持。

说明

本功能参数调整与 11.20 Hive 写目录旧数据进回收站添加的自定义参数相同。

操作步骤

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 选择“HiveServer（角色） > 自定义”，对参数文件“hive-site.xml”添加自定义参数，设置“名称”为“hive.overwrite.directory.move.trash”，“值”为“true”，修改后重启所有 Hive 实例。

----结束

11.22 限定仅 Hive 管理员用户能创建库和在 default 库建表

操作场景

此功能适用于 Hive，Spark2x。

开启此功能后，仅有 Hive 管理员可以创建库和在 default 库中建表，其他用户需通过 Hive 管理员授权才可使用库。

说明

- 开启本功能之后，会限制普通用户新建库和在 default 库新建表。请充分考虑实际应用场景，再决定是否作出调整。
- 因为对执行用户做了限制，使用非管理员用户执行建库、表脚本迁移、重建元数据操作时需要特别注意，防止错误。

操作步骤

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 选择“HiveServer（角色） > 自定义”，对参数文件“hive-site.xml”添加自定义参数，设置“名称”为“hive.allow.only.admin.create”，“值”为“true”，修改后重启所有 Hive 实例。

步骤 2 是否需要在 Spark/Spark2x 客户端中启用此功能？

- 是，执行步骤 4。
- 否，操作结束。

选择“SparkResource2x > 自定义”和“JDBCServer2x > 自定义”，对参数文件“hive-site.xml”添加自定义参数，设置“名称”为“hive.allow.only.admin.create”，“值”为“true”，修改后重启所有 Spark2x 实例。

步骤 3 重新下载并安装 Spark/Spark2x 客户端。

----结束

11.23 限定创建 Hive 内部表不能指定 location

操作场景

此功能适用于 Hive，Spark2x/Spark。

开启此功能后，在创建 Hive 内部表时，不能指定 location。即表创建成功之后，表的 location 路径会被创建在当前默认 warehouse 目录下，不能被指定到其他目录。如果创建内部表时指定 location，则创建失败。

说明

开启本功能之后，创建 Hive 内部表不能执行 location。因为对建表语句做了限制，如果数据库中已存在建表时指向非当前默认 warehouse 目录的表，在执行建库、表脚本迁移、重建元数据操作时需要特别注意，防止错误。

操作步骤

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 选择“HiveServer（角色） > 自定义”，对参数文件“hive-site.xml”添加自定义参数，设置“名称”为“hive.internaltable.notallowlocation”，“值”为“true”，修改后重启所有 Hive 实例。

步骤 2 是否需要在 Spark/Spark2x 客户端中启用此功能？

- 是，重新下载并安装 Spark/Spark2x 客户端。
- 否，操作结束。

----结束

11.24 允许在只读权限的目录建外表

操作场景

此功能适用于 Hive，Spark2x/Spark。

开启此功能后，允许有目录读权限和执行权限的用户和用户组创建外部表，而不必检查用户是否为该目录的属主，并且禁止外表的 location 目录在当前默认 warehouse 目录下。同时在外表授权时，禁止更改其 location 目录对应的权限。

说明

开启本功能之后，外表功能变化大。请充分考虑实际应用场景，再决定是否作出调整。

操作步骤

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 选择“HiveServer（角色） > 自定义”，对参数文件“hive-site.xml”添加自定义参数，设置“名称”为“hive.restrict.create.grant.external.table”，“值”为“true”。

步骤 2 选择“MetaStore（角色） > 自定义”，对参数文件“hivemetastore-site.xml”添加自定义参数，设置“名称”为“hive.restrict.create.grant.external.table”，“值”为“true”，修改后重启所有 Hive 实例。

步骤 3 是否需要在 Spark/Spark2x 客户端中启用此功能？

- 是，重新下载并安装 Spark/Spark2x 客户端。
- 否，操作结束。

----结束

11.25 Hive 支持授权超过 32 个角色

操作场景

此功能适用于 Hive。

因为操作系统用户组个数限制，导致 Hive 不能创建超过 32 个角色，开启此功能后，Hive 将支持创建超过 32 个角色。

说明

- 开启本功能并对表库等授权后，对表库目录具有相同权限的角色将会用“|”合并。查询 acl 权限时，将显示合并后的结果，与开启该功能前的显示会有区别。此操作不可逆，请充分考虑实际应用场景，再决定是否作出调整。
- 如果当前组件使用了 Ranger 进行权限控制，需基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.10 添加 Hive 的 Ranger 访问权限策略。
- 开启此功能后，包括 **owner** 在内默认最大可支持 512 个角色，由 MetaStore 自定义参数“hive.supports.roles.max”控制，可考虑实际应用场景进行修改。

操作步骤

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 修改参数并重启相关实例：

- MRS 3.2.0 之前版本：
  a. 选择“MetaStore（角色） > 自定义”，对参数文件“hivemetastore-site.xml”添加自定义参数，设置“名称”为“hive.supports.over.32.roles”，“值”为“true”。
  b. 选择“HiveServer（角色） > 自定义”，对参数文件“hive-site.xml”添加自定义参数，设置“名称”为“hive.supports.over.32.roles”，“值”为“true”。
  c. 单击“保存”，保存配置。
  d. 单击“实例”，勾选所有 Hive 实例，选择“更多 > 重启实例”，重启 Hive 实例。
- MRS 3.2.0 及之后版本：
  a. 选择“MetaStore（角色） > 自定义”，对参数文件“hivemetastore-site.xml”添加自定义参数，设置“名称”为“hive.supports.over.32.roles”，“值”为“true”。
  b. 单击“保存”，保存配置。
  c. 单击“实例”，勾选所有 MetaStore 实例，选择“更多 > 重启实例”，重启所有 MetaStore 实例。

----结束

11.26 Hive 任务支持限定最大 map 数

操作场景

- 此功能适用于 Hive。
- 此功能用于从服务端限定 Hive 任务的最大 map 数，避免 HiveSever 服务过载而引发的性能问题。

操作步骤

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 选择“MetaStore（角色） > 自定义”，对参数文件“hivemetastore-site.xml”添加自定义参数，设置“名称”为“hive.mapreduce.per.task.max.splits”，“值”为具体设定值，一般尽量设置大，修改后重启所有 Hive 实例。

----结束

11.27 HiveServer 租约隔离使用

操作场景

- 此功能适用于 Hive。
- 开启此功能可以限定指定用户访问指定节点上的 HiveServer 服务，实现对用户访问 HiveServer 服务的资源隔离。

操作步骤

以对用户 hiveuser 设置租约隔离为例，选取 Hive 当前已有的或者新添加一个或者多个实例，此处选择已有的 HiveServer 实例：

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。

步骤 1 选择“集群 > *待操作集群的名称* > 服务 > Hive > HiveServer”。

步骤 2 在 HiveServer 列表里选择设置租约隔离的 HiveServer，选择“HiveServer > 实例配置 > 全部配置”。

步骤 3 在“全部配置”界面的右上角搜索“hive.server2.zookeeper.namespace”，“值”为具体设定值，比如为 hiveserver2_zk。

步骤 4 单击“保存”，在弹出对话框单击“确定”。

步骤 5 选择“集群 > *待操作集群的名称* > 服务 > Hive”，选择“更多 > 重启服务”，输入密码开始重启服务。

步骤 6 使用 beeline -u 的方式登录客户端，执行以下命令：

beeline -u "jdbc:hive2:// *10.5.159.13* **:2181/;serviceDiscoveryMode=zooKeeper;zooKeeperNamespac**

e=*hiveserver2_zk*;sasl.qop=auth-conf;auth=KERBEROS;principal=hive/hadoop.<*系统域名*>@<*系统域名*>"

执行命令时将“10.5.159.13”替换为任意一个 ZooKeeper 实例的 IP 地址，查找方式为“集群 > *待操作集群的名称* > 服务 > ZooKeeper > 实例”。

“zooKeeperNamespace=”后面的“hiveserver2_zk”为步骤 4 中参数“hive.server2.zookeeper.namespace”设置的具体设定值。

结果将只会登录到被设置租约隔离的 HiveServer。

说明

- 开启本功能后，必须在登录时使用以上命令才可以访问这个被设置租约隔离的 HiveServer。如果直接使用 **beeline** 命令登录客户端，将只会访问其他没有被设置租约隔离的 HiveServer。
- 用户可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。“hive/hadoop.<系统域名>”为用户名，用户名所包含的系统域名所有字母为小写。

----结束

11.28 Hive 支持 MetaStore 根据组件隔离

操作场景

MRS 3.2.0 及之后的版本支持此功能，此功能用于限制集群内组件连接指定的 Hive MetaStore 实例，组件默认可连接所有 MetaStore 实例。

目前集群中支持连接 MetaStore 的组件有 HetuEngine、Hive、Loader、Metadata、Spark2x、Flink，此功能适用于限制各组件服务端连接的 MetaStore 实例，支持在 MetaStore 中统一分配。

说明

- 此功能仅限制各组件服务端访问的 MetaStore 实例，元数据未隔离。
- 暂不支持 Flink，Flink 任务均使用客户端配置，仍可连接所有 MetaStore 实例，不支持统一配置。
- 使用 spark-sql 执行任务时客户端直接连接 MetaStore，隔离后需要更新客户端才可生效。
- 此功能仅支持同集群内隔离，HetuEngine 不同集群部署的场景不支持统一配置，需要修改 HetuEngine 配置实现连接指定的 MetaStore 实例。
- 配置隔离时，考虑可用性，建议组件最少配置两个 MetaStore 实例。

前提条件

集群已安装 Hive 服务，且服务运行正常。

操作步骤

登录 FusionInsight Manager 页面，选择“集群 > 服务 > Hive > 配置 > 全部配置”，搜索配置项“HIVE_METASTORE_URI”。

步骤 1 其中“HIVE_METASTORE_URI_DEFAULT”配置项的值即为所有 MetaStore 实例的 URI 连接串。

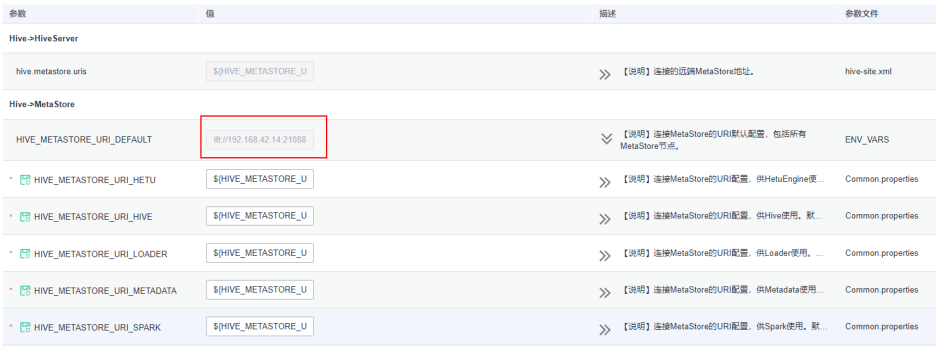

步骤 2 需要配置组件连接指定 MetaStore 时，复制步骤 2 中的参数值，按组件名称修改对应配置项，保存后重启对应组件。

以 Spark2x 为例，限制 Spark2x 仅可连接 Hive 服务中两个 MetaStore 实例。

1. 登录 FusionInsight Manager 页面，选择“集群 > 服务 > Hive > 配置 > 全部配置”，搜索配置项“HIVE_METASTORE_URI”。
2. 复制“HIVE_METASTORE_URI_DEFAULT”的默认配置到 Spark2x 的 URI 配置项，若 Spark2x 仅需要连接两个 MetaStore 实例，则根据需要仅保留两个节点信息（具体以实际为准），单击“保存”。

3. 选择“集群 > 服务 > Spark2x > 实例”，勾选配置过期的实例，选择“更多 > 重启实例”，在弹出对话框输入密码，单击“确定”，重启实例。

----结束

11.29 切换 Hive 执行引擎为 Tez

操作场景

Hive 支持使用 Tez 引擎处理数据计算任务，用户在执行任务前可手动切换执行引擎为 Tez。

前提条件

集群已安装 Yarn 服务的 TimelineServer 角色，且角色运行正常。

客户端切换执行引擎为 Tez

安装并登录 Hive 客户端，具体操作请参考 11.5 使用 Hive 客户端。

步骤 1 针对 MRS 3.1.2 版本，执行以下命令切换引擎并开启“yarn.timeline-service.enabled”参数：

set hive.execution.engine=tez;

set yarn.timeline-service.enabled=true;

说明

- “yarn.timeline-service.enabled”参数开启后可以在 Tez 服务中通过 TezUI 查看 Tez 引擎执行任务的详细情况。开启后任务信息将上报 TimelineServer，如果 TimelineServer 实例故障，会导致任务失败。
- 由于 Tez 使用 ApplicationMaster 缓冲池，“yarn.timeline-service.enabled”必须在提交 Tez 任务前开启，否则会导致此参数无法生效，需要重新登录客户端进行配置。
- 当执行引擎需要切换为其它引擎时，需要通过客户端执行 **set yarn.timeline-service.enabled=false** 命令关闭“yarn.timeline-service.enabled”参数。
- 如果需要指定 Yarn 运行队列，可以在客户端执行 **set tez.queue.name=default** 命令指定运行队列。

步骤 2 针对 MRS 3.2.0 及之后版本，执行以下命令切换引擎：

set hive.execution.engine=tez;

说明

如果需要指定 Yarn 运行队列，可以在客户端执行 **set tez.queue.name=default** 命令指定运行队列。

步骤 3 提交并执行 Tez 任务。

步骤 4 登录 FusionInsight Manager 界面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > *待操作的集群* > 服务 > Tez > TezUI（*主机名称*）”，在 TezUI 界面查看任务执行情况。

----结束

切换 Hive 服务默认执行引擎为 Tez

登录 FusionInsight Manager 界面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > *待操作的集群* > 服务 > Hive > 配置 > 全部配置 > HiveServer（角色）”，搜索“hive.execution.engine”参数。

步骤 1 将“hive.execution.engine”参数设置为“tez”。

步骤 2 针对 MRS 3.1.2 版本，选择“Hive（服务） > 自定义”，搜索“yarn.site.customized.configs”。

步骤 3 针对 MRS 3.1.2 版本，在“yarn.site.customized.configs”参数后添加自定义参数，名称为“yarn.timeline-service.enabled”，值为“true”。

说明

- “yarn.timeline-service.enabled”开启后可以在 Tez 服务中通过 TezUI 查看 Tez 引擎执行任务详细情况。开启后任务信息将上报 TimelineServer，如果 TimelineServer 实例故障，会导致任务失败。
- 由于 Tez 使用 ApplicationMaster 缓冲池，“yarn.timeline-service.enabled”必须在提交 Tez 任务前开启，否则会导致此参数无法生效，需要重新登录客户端配置。
- 当执行引擎需要切换为其它引擎时，需要将自定义参数“yarn.timeline-service.enabled”的值设置为“false”。

步骤 4 单击“保存”在弹出窗口单击“确定”。

步骤 5 选择“概览 > 更多 > 重启服务”，重启 Hive 服务，输入密码开始重启服务。

步骤 6 安装并登录 Hive 客户端，具体操作请参考 11.5 使用 Hive 客户端。

步骤 7 提交并执行 Tez 任务。

步骤 8 登录 FusionInsight Manager 界面，选择“集群 > *待操作的集群* > 服务 > Tez > TezUI（*主机名称*）”，跳转 TezUI 界面查看任务执行情况。

----结束

11.30 Hive 支持读取 Hudi 表

Hudi 表对应的 Hive 外部表介绍

Hudi 源表对应一份 HDFS 的数据，通过 Spark 组件、Flink 组件或者 Hudi 客户端，可以将 Hudi 表的数据映射为 Hive 外部表，基于该外部表，Hive 可以方便地进行实时视图查询、读优化视图查询以及增量视图查询。

说明

- 根据 Hudi 源表的类型的不同，提供不同的视图查询：
- Hudi 源表类型为 Copy On Write 时，可以映射为 Hive 的一张外部表，该表可以提供实时视图查询以及增量视图查询。
- Hudi 源表类型为 Merge On Read 时，可以映射为 Hive 的两张外部表（ro 表和 rt 表），ro 表提供读优化视图查询，rt 表提供实时视图查询以及增量视图查询。
- 不能对 Hudi 表映射的 Hive 外部表做增删改操作（即 insert、update、delete、load、merge、alter、msck），只支持查询操作（select）。
- 表授权：不支持修改类权限（update、Alter、write、All）。
- 备份与恢复：由于 ro 表和 rt 表均由同一个 hudi 源表映射的，备份其中一张表，另一张也会跟着备份，恢复也是同时恢复的，因此只需备份其中一张表即可。
- 组件版本：
- Hive：FusionInsight_HD_xxx，Hive 内核版本 3.1.0。
- Spark2x：FusionInsight_Spark2x_xxx，Hudi 内核版本：0.11.0。

创建 Hudi 表对应的 Hive 外部表

Hudi 表数据在入湖的时候一般会同步到 Hive 外部表，此时在 Beeline 中可以直接查询到对应的 Hive 外部表，若没有同步到 Hive 外部表，则可以通过 Hudi 客户端工具 run_hive_sync_tool.sh 手动同步。

查询 Hudi 表对应的 Hive 外部表

操作前提

使用 Hive 对 Hudi 表进行增量查询前，需要设置表 11-10 的 3 个参数，这 3 个参数是表级别的参数，每个 hudi 源表都对应 3 个参数，其中 hudisourcetablename 代表 Hudi 源表的表名（注意不是 Hive 外部表的表名）。

表11-10 参数说明

参数名	默认值	描述
hoodie.hudisourcetablename.consume.mode	无	Hudi 表的查询模式。 • 增量查询：INCREMENTAL • 非增量查询：不设置或者设为 SNAPSHOT
hoodie.hudisourcetablename.consume.start.timestamp	无	Hudi 表增量查询的起始时间。 • 增量查询：增量查询的起始时间 • 非增量查询：不设置
hoodie.hudisourcetablename.consume.max.commits	无	Hudi 表增量查询基于 hoodie.hudisourcetablename.consume.start.timestamp 之后 commit 的次数。 • 增量查询：提交次数，如设置为 3 时，代表增量查询从指定的起始时间之后 commit 3 次的数据，设为-1 时，增量查询从指定的起始时间之后提交的所有数据。 • 非增量查询：不设置

Copy On Write 类型 Hudi 表查询

例如：cow 类型 Hudi 源表的表名为 hudicow，映射为 Hive 外部表的表名为 hudicow。

- cow 表实时视图查询：

  Select * from hudicow;

- cow 表增量查询：需要根据 Hudi 源表的表名设置 3 个增量查询参数，且增量查询语句的 where 子句必须包含“`_hoodie_commit_time`>'*xxx*'”，其中的 *xxx* 为“hoodie.hudisourcetablename.consume.start.timestamp”增量参数的值：

  set hoodie.hudicow.consume.mode= INCREMENTAL;

  set hoodie.hudicow.consume.max.commits=3;

set hoodie.hudicow.consume.start.timestamp= 20200427114546;

select count(*) from hudicow where `_hoodie_commit_time`>'20200427114546';

Merge On Read 类型 Hudi 表的查询

例如：mor 类型 Hudi 源表的表名为 hudimor，映射为两张 Hive 外部表 hudimor_ro（ro 表）和 hudimor_rt（rt 表）。

- ro 表提供读读优化视图查询：

  Select * from hudicow_ro;

- rt 的实时视图查询：

  Select * from hudicow_rt;

- rt 表的增量查询：需要根据 Hudi 源表的表名设置 3 个增量查询参数，且增量查询语句的 where 子句必须包含“`_hoodie_commit_time`>'*xxx*'”，其中的 *xxx* 为“hoodie.hudisourcetablename.consume.start.timestamp”增量参数的值：

  set hoodie.hudimor.consume.mode=INCREMENTAL;

  set hoodie.hudimor.consume.max.commits=-1;

  set hoodie.hudimor.consume.start.timestamp=20210207144611;

  select * from hudimor_rt where `_hoodie_commit_time`>'20210207144611';

说明

set hoodie.hudisourcetablename.consume.mode=INCREMENTAL;仅用于该表的增量查询模式，若要对该表切换为其他查询模式，应设置 **set hoodie.hudisourcetablename.consume.mode=SNAPSHOT;**。

查询 Hudi 的 Schema 演进表对应的 Hive 外部表

如果该 Hudi 表为 Schema 演进表（表的字段执行过修改），则 Hive 查询该表还需额外设置一个参数：**set hive.exec.schema.evolution=true;**

以 cow 表实时视图的查询举例，其他各个视图的查询都要额外添加该参数：

- cow 表实时视图查询：

  set hive.exec.schema.evolution=true;

  select * from *hudicow*;

11.31 Hive 支持分区元数据冷热存储

分区元数据冷热存储介绍

- 为了减轻元数据库压力，将长时间未使用过的指定范围的分区相关元数据移动到备份表，这一过程称为分区数据冻结，移动的分区数据称为冷分区，未冻结的分区称为热分区，存在冷分区的表称为冻结表。将被冻结的数据重新移回原元数据表，这一过程称为分区数据解冻。
- 一个分区从热分区变成冷分区，仅仅是在元数据中进行标识，其 HDFS 业务侧分区路径、数据文件内容并未发生变化。

冻结分区

支持创建表的用户按照条件过滤的方式对一个或多个分区进行冻结，格式为：freeze partitions *数据库名称.表名称* where *分区过滤条件*

例如：

freeze partitions testdb.test where year <= 2021;

freeze partitions testdb.test where year<=2021 and month <= 5;

freeze partitions testdb.test where year<=2021 and month <= 5 and day <= 27;

解冻分区

支持创建表的用户按照条件过滤的方式对一个或多个分区进行解冻，格式为 unfreeze partitions 数据库名称.表名称 where 分区过滤条件，如：

unfreeze partitions testdb.test where year <= 2021;

unfreeze partitions testdb.test where year<=2021 and month <= 5;

unfreeze partitions testdb.test where year<=2021 and month <= 5 and day <= 27;

查询含有冻结数据的表

- 查询当前数据库下的所有冻结表：

  show frozen tables;
- 查询指定数据库下的所有冻结表：

  show frozen tables in *数据库名称*;

查询冻结表的冻结分区

查询冷冻分区：

show frozen partitions *表名*;

说明

- 默认元数据库冻结分区类型只支持 int、string、varchar、date、timestamp 类型。
- 外置元数据库只支持 Postgres 数据库，且冻结分区类型只支持 int、string、varchar、timestamp 类型。
- 对冻结后的表进行 Msck 元数据修复时，需要先解冻数据。如果对冻结表进行过备份后恢复操作，则可以直接执行 Msck 元数据修复操作，且解冻只能通过 **msck repair** 命令进行操作。
- 对冻结后的分区进行 rename 时，需要先解冻数据，否则会提示分区不存在。
- 删除存在冻结数据的表时，被冻结的数据会同步删除。
- 删除存在冻结数据的分区时，被冻结的分区信息不会被删除，HDFS 业务数据也不会被删除。
- select 查询数据时，会自动添加排查冷分区数据的过滤条件，查询结果将不包含冷分区的数据。
- show partitions table 查询表下的分区数据时，查询结果将不包含冷分区，可通过 show frozen partitions table 进行冷冻分区查询。

11.32 Hive 支持 ZSTD 压缩格式

ZSTD（全称为 Zstandard）是一种开源的无损数据压缩算法，其压缩性能和压缩比均优于当前 Hadoop 支持的其他压缩格式，本特性使得 Hive 支持 ZSTD 压缩格式的表。Hive 支持基于 ZSTD 压缩的存储格式有常见的 ORC，RCFile，TextFile，JsonFile，Parquet，Squence，CSV。

ZSTD 压缩格式的建表方式如下：

- ORC 存储格式建表时可指定 TBLPROPERTIES("orc.compress"="zstd")：

  create table tab_1(...) stored as orc TBLPROPERTIES("orc.compress"="zstd");
- Parquet 存储格式建表可指定 TBLPROPERTIES("parquet.compression"="zstd")：

  create table tab_2(...) stored as parquet TBLPROPERTIES("parquet.compression"="zstd");
- 其他格式或通用格式建表可执行设置参数指定 compress,codec 为“org.apache.hadoop.io.compress.ZStandardCode”：

  set hive.exec.compress.output=true;

  set mapreduce.map.output.compress=true;

  set mapreduce.map.output.compress.codec=org.apache.hadoop.io.compress.ZStandardCodec;

  set mapreduce.output.fileoutputformat.compress=true;

  set mapreduce.output.fileoutputformat.compress.codec=org.apache.hadoop.io.compress.ZStandardCodec;

  set hive.exec.compress.intermediate=true;

  create table tab_3(...) stored as textfile;

说明

ZSTD 压缩格式的表和其他普通压缩表的 SQL 操作没有区别，可支持正常的增删查及聚合类 SQL 操作。

11.33 Hive 分区表支持 OBS 和 HDFS 存储源

操作场景

存算分离场景下，Hive 分区表支持不同的分区分别指定不同的存储源，可以指定一个分区表中不同分区的存储源为 OBS 或者 HDFS。

说明

本特性仅适用于 MRS 3.2.0 及之后版本。

前提条件

已安装 Hive 客户端。

操作示例

1. 以 Hive 客户端安装用户登录安装客户端的节点。
2. 执行以下命令，切换到客户端安装目录。

   cd *客户端安装目录*

   例如安装目录为“/opt/client”，则执行以下命令：

   cd /opt/client
3. 执行以下命令配置环境变量。

   source bigdata_env
4. 集群认证模式是否为安全模式。
   - 是，执行以下命令进行用户认证：

     kinit *Hive 业务用户*
   - 否，执行 5。
5. 执行以下命令登录 Hive 客户端。

   beeline
6. 执行如下命令创建 Hive 分区表“table_1”，指定分区“pt='2021-12-12'”的路径为“hdfs//*xxx*”，指定分区“pt='2021-12-18'”的路径为“obs://*xxx*”：

   create table table_1(id string) partitioned by(pt string) [stored as [orc|textfile|parquet|...]];

   alter table table_1 add partition(pt='2021-12-12') location 'hdfs://*xxx*';

   alter table table_1 add partition(pt='2021-12-18') location 'obs://*xxx*';
7. 给分区表“table_1”中插入数据后，对应的分区数据存储在对应的存储源上，可以使用 **desc** 查看分区的 location，执行以下命令查看路径下的数据：

   desc formatted table_1 partition(pt='2021-12-18');

11.34 Hive 异常文件定位定界工具

操作场景

- 由于某些异常操作或者磁盘损坏等原因导致 Hive 存储的数据文件出现异常，异常的数据文件会导致任务运行失败或者数据结果不正确。
- 该工具用于对常见的非文本类的数据文件格式进行异常排查。

说明

该章节内容仅适用 MRS 3.2.0 及之后版本。

操作步骤

1. 使用 **omm** 用户登录安装了 Hive 服务的节点，执行以下命令进入 Hive 安装目录。

   cd ${BIGDATA_HOME}/FusionInsight_HD_*/install/FusionInsight-Hive-*/hive-*/bin
2. Hive 异常文件定位定界工具使用方式如下：

   sh hive_parser_file.sh [--help] <filetype> <command> <input-file|input-directory>

相关参数说明如表 11-11 所示：

注意：一次只能运行一个 command。

表11-11 参数说明

参数	描述	说明
filetype	指定当前工具要解析哪种格式的数据文件，目前仅支持 orc、rc（RCFile）、parquet 三种格式。	rc 格式目前只支持查看数据。
-c	打印当前元信息中列的信息。	列信息包含类名、类型、序号。
-d	打印数据文件中的数据，可通过“'limit=x'”限制数据量。	数据为当前指定的数据文件内容，通过 limit 限制数据量时一次只能指定一个数据量大小。
-t	打印写入数据的时区。	打印此文件写入时区。
-h	使用帮助格式化说明。	帮助。
-m	各存储格式的统计信息输出。	各存储格式不一样，例如 orc 会打印含 strip、块大小等统计信息。
-a	完整信息详情打印输出。	输出完整信息详情，包含以上参数内容。
input-file	输入数据文件。	指定输入的文件或者输入的目录，输入的目录中如果存在当前格式则解析，如果不存在则跳过。可以指定本地文件或者目录，也可以指定 HDFS/OBS 文件或者目录。
input-directory	输入数据文件所在的目录，子文件多个的情况下使用。	

3. 应用举例：

sh hive_parser_file.sh orc -d limit=100 hdfs://hacluster/user/hive/warehouse/orc_test

如果不带类似“hdfs://hacluster”的文件存储前缀 ，默认读取本地文件。

11.35 使用 ZSTD_JNI 压缩算法压缩 Hive ORC 表

操作场景

ZSTD_JNI 是 ZSTD 压缩算法的 native 实现，相较于 ZSTD 而言，压缩读写效率和压缩率更优些，并允许用户设置压缩级别，以及对特定格式的数据列指定压缩方式。

目前仅 ORC 格式的表支持 ZSTD_JNI 压缩方式，而普通的 ZSTD 压缩算法支持全量存储格式而不限于 ORC，所以建议用户对数据压缩有特殊要求的场景下再使用此特性。

说明

该章节内容仅适用 MRS 3.2.0 及之后版本。

操作示例

以 Hive 客户端安装用户登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录，例如安装目录为“/opt/client”，请用户根据实际情况修改。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 集群认证模式是否为安全模式。

- 是，执行以下命令进行用户认证，然后执行步骤 5。

  kinit *Hive 业务用户*

- 否，执行步骤 5。

步骤 4 执行以下命令登录 Hive 客户端。

beeline

步骤 5 ZSTD_JNI 压缩格式的建表方式如下：

- 使用此压缩算法时，只需在创建 ORC 表时指定表属性参数“orc.compress”为 ZSTD_JNI 即可，如：

  create table tab_1(...) stored as orc
  TBLPROPERTIES("orc.compress"="ZSTD_JNI");

- ZSTD_JNI 的压缩级别的取值范围为 1~19，数值越高压缩比越高，相对压缩读写速率会变慢；数值越低压缩比越低，相对读写速率会变快，缺省默认值为“6”。建表时设置表属性参数“orc.global.compress.level”即可，如：

  create table tab_1(...) stored as orc
  TBLPROPERTIES("orc.compress"="ZSTD_JNI",
  'orc.global.compress.level'='3');

- 用户可以对特定的数据格式列指定压缩，可对业务数据进一步压缩。当前识别的特定格式数据包括：Json 数据列、BASE64 数据列、时间戳数据列和 UUID 数据列。建表时设置表属性参数“orc.column.compress”即可。

  例如，以下示例指定了压缩格式为 ZSTD_JNI，压缩列 f2 为 json 格式的数据，f3 为 BASE64 格式的数据，f4 为时间戳格式的数据，f5 为 UUID 格式的数据：

  create table test_orc_zstd_jni(f1 int, f2 string, f3 string, f4 string, f5 string)
  stored as orc
  TBLPROPERTIES('orc.compress'='ZSTD_JNI',
  'orc.column.compress'='[{"type":"cjson","columns":"f2"},{"type":"base64","columns":"f3"},{"type ":"gorilla","columns":{"format": "yyyy-MM-dd HH:mm:ss.SSS", "columns": "f4"}},{"type":"uuid","columns":"f5"}]');

  用户可根据实际情况按照对应格式插入数据即可实现进一步压缩的效果。

----结束

11.36 HiveMetaStore 客户端连接支持负载均衡

操作场景

Hive 的 MetaStore 客户端连接支持负载均衡，即可通过服务端在 ZooKeeper 记录的连接数，选择连接最少的节点进行连接，防止大业务场景下造成某个 MetaStore 高负载，其他 MetaStore 空闲情况，开启此功能不影响原有连接方式。

说明

该章节内容适用于 MRS 3.2.0 及之后版本。

操作步骤

登录 FusionInsight Manager 页面，选择“集群 > 服务 > Hive > 配置 > 全部配置”。

步骤 1 在搜索框中搜索参数“hive.metastore-ext.balance.connection.enable”，修改该参数值为“true”。

步骤 2 单击“保存”，保存配置。

步骤 3 配置保存成功后，单击“实例”，勾选所有实例，选择“更多 > 重启实例”，在弹出对话框输入密码，单击“确定”，重启所有 Hive 实例。

步骤 4 对于其他连接 MetaStore 的组件，还需要添加“hive.metastore-ext.balance.connection.enable”参数，值为“true”。

以 Spark2x 为例：

1. 登录 FusionInsight Manager 页面，选择“集群 > 服务 > Spark2x > 配置”。
2. 搜索“自定义”，在所有的“hive-site.xml”参数文件中新增名称为“hive.metastore-ext.balance.connection.enable”，值为“true”的自定义参数，单击“保存”，保存配置。
3. 配置保存成功后，单击“实例”，勾选配置过期的实例，选择“更多 > 重启实例”，在弹出对话框输入密码，单击“确定”，重启配置过期的实例。

----结束

11.37 Hive 数据导入导出

11.37.1 Hive 表/分区数据导入导出

操作场景

在大数据应用场景中，往往存在将 Hive 中的数据表迁移到另一个集群上，使用 Hive 的导入导出命令可以实现表级别数据迁移，即可使用 Export 命令将源集群的 Hive 表导出到目标集群的 HDFS 中，再在目标集群使用 Import 命令将导出的数据导入到相应的 Hive 表中。

说明

本章节内容适用于 MRS 3.2.0 及之后版本。

Hive 表导入导出功能目前不支持对加密表、HBase 外部表、Hudi 表、视图表、物化视图表进行导入导出操作。

前提条件

- 如果是跨集群对 Hive 表或分区数据进行导入导出，且目标集群和源集群都开启了 Kerberos 认证，需配置跨集群互信。
- 若使用 Import/Export 命令导入导出其他用户创建的表或分区，需要授予用户对应表的权限：
  - 集群未启用 Ranger 鉴权，需登录 FusionInsight Manager 授予该用户所属角色对应表的“Select 授权”权限，详细操作请参考 11.4.3 配置 Hive 表、列或数据库的权限章节。
  - 集群启用了 Ranger 鉴权，需参考 20.10 添加 Hive 的 Ranger 访问权限策略章节授予用户对应表的 Import/Export 操作权限。
- 还需在源端集群和目标集群启用集群间拷贝功能。
- 需配置源端集群访问目标集群 HDFS 服务地址参数。

  登录源端集群的 FusionInsight Manager，选择“集群 > 服务 > Hive > 配置”，搜索“hdfs.site.customized.configs”，新增自定义参数“dfs.namenode.rpc-address.haclusterX”，值为“*目标集群主 NameNode 实例节点业务 IP:RPC 端口*”；新增自定义参数“dfs.namenode.rpc-address.haclusterX1”，值为“*目标集群备 NameNode 实例节点的业务 IP:RPC 端口*”，NameNode RPC 端口默认为“25000”。保存配置后需滚动重启 Hive 服务。

操作步骤

以 Hive 客户端安装用户登录源端集群安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录，例如安装目录为“/opt/client”，请用户根据实际情况修改。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 若集群开启了 Kerberos 认证，执行以下命令认证用户，否则跳过此步骤。

kinit *Hive 业务用户*

步骤 4 执行以下命令登录源端集群的 Hive 客户端。

beeline

步骤 5 执行以下命令创建表“export_test”。

create table *export_test(id int)* **;**

步骤 6 执行以下命令向表“export_test”中插入数据。

insert into *export_test values(123)***;**

步骤 7 在目标集群重复执行步骤 1-步骤 4，并执行以下命令创建存放表“export_test”导出后的 HDFS 路径。

dfs -mkdir */tmp/export*

步骤 8 执行以下命令登录目标集群的 Hive 客户端。

beeline

步骤 9 导入导出表“export_test”。

使用 Hive Import/Export 对表数据迁移时，支持以下几种场景，可以根据实际情况选择合适的导入导出方式。

- 场景一：简单导出导入
  a. 在源端集群执行以下命令将表“export_test”的元数据和业务数据导出到步骤 8 创建的目录下。

     export table *export_test* **to 'hdfs://hacluster***X/tmp/export***';**

  b. 在目标集群执行以下命令将步骤 10.a 导出的表数据导入到表“export_test”中。

     import from '*/tmp/export***';**
- 场景二 ：在导入时重命名表
  a. 在源端集群执行以下命令将表“export_test”的元数据和业务数据导出到步骤 8 创建的目录下。

     export table *export_test* **to 'hdfs://hacluster***X/tmp/export***';**

  b. 在目标集群执行以下命令将步骤 10.a 导出的表数据导入到表“import_test”中。

     import table *import_test* **from '***/tmp/export***';**
- 场景三：导出分区数据并导入
  a. 在源端集群执行以下命令将表“export_test”的 pt1 和 pt2 分区导出到步骤 8 创建的目录下。

     export table *export_test* **partition (***pt1***="***in***",** *pt2***="***ka***") to 'hdfs://hacluster***X/tmp/export***';**

  b. 在目标集群执行以下命令将步骤 10.a 导出的表数据导入到表“export_test”中。

     import from '*/tmp/export***';**
- 场景四：导出表数据并且将该数据导入到分区中
  a. 在源端集群执行以下命令将表“export_test”的元数据和业务数据导出到步骤 8 创建的目录下。

     export table *export_test* **to 'hdfs://hacluster***X/tmp/export***';**

  b. 在目标集群执行以下命令将**步骤 10.a** 导出的表数据导入到表“import_test”的 pt1 和 pt2 分区中。

     import table *import_test* **partition (***pt1***="***us***",** *pt2***="***tn***") from '***/tmp/export***';**
- 场景五：导入表数据时指定表的 Location
  a. 在源端集群执行以下命令将表“export_test”的元数据和业务数据导出到步骤 8 创建的目录下。

export table *export_test* **to 'hdfs://hacluster***X***/tmp/export';**

b. 在目标集群执行以下命令将步骤 10.a 导出的表数据导入到表“import_test”中，且该表的 Location 为“*/tmp/export*”。

import table *import_test* **from '***/tmp***' location '***/tmp/export***';**

- 场景六：导入表数据为外部表

a. 在源端集群执行以下命令将表“export_test”的元数据和业务数据导出到步骤 8 创建的目录下。

export table *export_test* **to 'hdfs://hacluster***X***/tmp/export';**

b. 在目标集群执行以下命令将**步骤 10.a** 导出的表数据导入到外部表“import_test”中。

import external table *import_test* **from '***/tmp/export***';**

说明

导出表/分区数据时，存放表/分区数据的 HDFS 路径需提前创建，且该目录为空，否则导出失败。

导出分区时，导出的表必须为分区表，且不支持导出同一个分区字段的多个分区值的数据；导入到表中分区时导入的表必须是分区表。

导入数据时需注意：

- 使用 **import from '***/tmp/export***';**命令导入表是没有指定表名的场景，该场景导入的数据会保存到与源表名相同的表路径下，需注意以下两点：
- 如果目标集群上不存在与源集群上同名的表，在导入表的过程中会创建该表。
- 如果目标集群上已存在与源集群上同名的表，该表对应的 HDFS 目录下必须为空，否则导入失败。
- 使用 **import external table** *import_test* **from '***/tmp/export***';**命令导入表会将导出的表导入到指定的表中，需注意以下两点：
- 如果目标集群上不存在与指定的表名相同的表，在导入表的过程中会创建该表。
- 如果目标集群上已存在与指定的表名相同的表，该表对应的 HDFS 目录下必须为空，否则导入失败。

“**hacluster**X”为新增的自定义参数“dfs.namenode.rpc-address.haclusterX”中的“haclusterX”

----结束

11.37.2 Hive 数据库导入导出

操作场景

在大数据应用场景中，往往存在将 Hive 中的数据库及数据库下的所有表迁移到另一个集群上，使用 Hive 的导出导入数据库命令可以实现完整数据库的迁移。

说明

本章节内容适用于 MRS 3.2.0 及之后版本。

Hive 数据库导入导出功能目前不支持对加密表、HBase 外部表、Hudi 表、视图表及物化视图表进行导入导出操作。

前提条件

- 如果是跨集群对 Hive 数据库进行导入导出，且目标集群和源集群都开启了 Kerberos 认证，需配置跨集群互信。
- 若使用 Dump/Load 命令导入导出其他用户创建的数据库，需要授予用户对应数据库的权限：
  - 集群未启用 Ranger 鉴权，需登录 FusionInsight Manager 授予该用户所属角色管理员权限，详细操作请参考 11.4.2 创建 Hive 角色章节。
  - 集群启用了 Ranger 鉴权，需参考 20.10 添加 Hive 的 Ranger 访问权限策略章节授予用户对应数据库的 Repl Dump/Load 操作权限。
- 还需在源端集群和目标集群启用集群间拷贝功能。
- 需配置源端集群访问目标集群 HDFS 服务地址参数。

  登录源端集群的 FusionInsight Manager，选择“集群 > 服务 > Hive > 配置”，搜索“hdfs.site.customized.configs”，新增自定义参数“dfs.namenode.rpc-address.haclusterX”，值为“*目标集群的 NameNode 实例主节点业务 IP:RPC 端口*”；新增自定义参数“dfs.namenode.rpc-address.haclusterX1”，值为“*目标集群的 NameNode 实例备节点的业务 IP:RPC 端口*”，NameNode RPC 端口默认为“25000”。保存配置后需滚动重启 Hive 服务。

操作步骤

以 Hive 客户端安装用户登录源端集群安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录，例如安装目录为“/opt/client”，请用户根据实际情况修改。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 若集群开启了 Kerberos 认证，执行以下命令认证用户，否则跳过此步骤。

kinit *Hive 业务用户*

步骤 4 执行以下命令登录 Hive 客户端。

beeline

步骤 5 执行以下命令创建数据库“dump_db”。

create database *dump_db*;

步骤 6 执行以下命令切换到“dump_db”数据库。

use *dump_db*;

步骤 7 执行以下命令在“dump_db”中创建表“test”。

create table *test*(*id int*);

步骤 8 执行以下命令向表“test”中插入数据。

insert into *test* **values**(*123*);

步骤 9 执行以下命令将数据库“dump_db”设置为复制策略的源。

alter database *dump_db* **set dbproperties ('***repl.source.for***'='replpolicy1');**

说明

- 执行 alter 命令修改数据库属性时，用户需要对该数据库拥有对应权限。权限设置方式如下：
- 集群未启用 Ranger 鉴权，需登录 FusionInsight Manager 授予该用户所属角色管理员权限，详细操作请参考 11.4.2 创建 Hive 角色章节。
- 集群启用了 Ranger 鉴权，需参考 20.10 添加 Hive 的 Ranger 访问权限策略章节授予用户对应数据库的 Repl Dump/Load 操作权限。
- 删除设置了复制策略源的数据库时，需要先将该数据库的复制策略源设置为空，再对数据库执行删除操作，否则无法删除。将数据库复制策略源设置为空的命令如下：

  alter database *dump_db* **set dbproperties ('***repl.source.for***'='');**

步骤 10 执行以下命令将“dump_db”导出到目标集群的“/user/hive/test”目录下。

repl dump *dump_db* **with ('hive.repl.rootdir'='hdfs://hacluster***X/user/hive/test***');**

说明

- “**hacluster**X”为新增的自定义参数“dfs.namenode.rpc-address.haclusterX”中的“haclusterX”。
- 指定导出目录时需要确保当前用户对该目录拥有读写权限。

步骤 11 以 Hive 客户端安装用户登录目标集群安装客户端的节点，并执行步骤 2-步骤 5。

步骤 12 执行以下命令将“/user/hive/test”目录下的“dump_db”数据库的数据导入到“load_db”数据库中。

repl load *load_db* **from '***/user/hive/repl***';**

说明

通过 **repl load** 导入数据库，指定数据库名称时需要注意以下情况：

- 指定的数据库不存在，在导入的过程中会创建对应的数据库；
- 指定的数据库已存在，且该数据库的“hive.repl.ckpt.key”属性值与导入的路径一致，则跳过导入操作。
- 指定的数据库已存在，但是该数据库下不存在任何表和 functions，导入的过程中只将源数据库下的表导入到当前数据库中；如果该数据库下存在表或 functions 会导入失败。

----结束

11.38 Hive 日志介绍

日志描述

日志路径：Hive 相关日志的默认存储路径为“/var/log/Bigdata/hive/角色名”，Hive1 相关日志的默认存储路径为“/var/log/Bigdata/hive1/角色名”，以此类推。

- HiveServer：“/var/log/Bigdata/hive/hiveserver”（运行日志），“/var/log/Bigdata/audit/hive/hiveserver”（审计日志）。

- MetaStore：“/var/log/Bigdata/hive/metastore”（运行日志），“/var/log/Bigdata/audit/hive/metastore”（审计日志）。
- WebHCat：“/var/log/Bigdata/hive/webhcat”（运行日志），“/var/log/Bigdata/audit/hive/webhcat”（审计日志）。

日志归档规则：Hive 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 20MB 的时候（此日志文件大小可进行配置），会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”。最多保留最近的 20 个压缩文件，压缩文件保留个数和压缩文件阈值可以配置。

表11-12 Hive 日志列表

日志类型	日志文件名	描述
运行日志	/hiveserver/hiveserver.out	HiveServer 运行环境信息日志
	/hiveserver/hive.log	HiveServer 进程的运行日志
	/hiveserver/hive-omm-<日期>-<PID>-gc.log.<编号>	HiveServer 进程的 GC 日志
	/hiveserver/prestartDetail.log	HiveServer 启动前的工作日志
	/hiveserver/check-serviceDetail.log	Hive 服务启动是否成功的检查日志
	/hiveserver/cleanupDetail.log	HiveServer 卸载的清理日志
	/hiveserver/startDetail.log	HiveServer 进程启动日志
	/hiveserver/stopDetail.log	HiveServer 进程停止日志
	/hiveserver/localtasklog/omm_<日期>_<任务 ID>.log	Hive 本地任务的运行日志
	/hiveserver/localtasklog/omm_<日期>_<任务 ID>-gc.log.<编号>	Hive 本地任务的 GC 日志
	/metastore/metastore.log	MetaStore 进程的运行日志
	/metastore/hive-omm-<日期>-<PID>-gc.log.<编号>	MetaStore 进程的 GC 日志
	/metastore/postinstallDetail.log	MetaStore 安装后的工作日志
	/metastore/prestartDetail.log	MetaStore 启动前的工作日志
	/metastore/cleanupDetail.log	MetaStore 卸载的清理日志
	/metastore/startDetail.log	MetaStore 进程启动日志

日志类型	日志文件名	描述
	/metastore/stopDetail.log	MetaStore 进程停止日志
	/metastore/metastore.out	MetaStore 运行环境信息日志
	/webhcat/webhcat-console.out	Webhcat 进程启停正常日志
	/webhcat/webhcat-console-error.out	Webhcat 进程启停异常日志
	/webhcat/prestartDetail.log	WebHCat 启动前的工作日志
	/webhcat/cleanupDetail.log	Webhcat 卸载时或安装前的清理日志
	/webhcat/hive-omm-<日期>-<PID>-gc.log.<编号>	WebHCat 进程的 GC 日志
	/webhcat/webhcat.log	WebHCat 进程的运行日志
审计日志	hive-audit.log hive-rangeraudit.log	HiveServer 审计日志
	metastore-audit.log	MetaStore 审计日志
	webhcat-audit.log	WebHCat 审计日志
	jetty-<日期>.request.log	Jetty 服务的请求日志

日志级别

Hive 提供了如表 11-13 所示的日志级别。

运行日志的级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表11-13 日志级别

级别	描述
ERROR	ERROR 表示系统运行的错误信息。
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

参考 25.1 修改集群服务配置参数，进入 Hive 服务“全部配置”页面。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别并保存。

说明

配置 Hive 日志级别后可立即生效，无需重启服务。

----结束

日志格式

Hive 的日志格式如下所示：

表11-14 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<LogLevel>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2014-11-05 09:45:01,242 | INFO | main | Starting hive metastore on port 21088 | org.apache.hadoop.hive.metastore.HiveMetaStore.main(HiveMetaStore.java:5198)
审计日志	<yyyy-MM-dd HH:mm:ss,SSS>|<LogLevel>|<产生该日志的线程名字>|<User Name><User IP><Time><Operation><Resource><Result><Detail >|<日志事件的发生位置>	2018-12-24 12:16:25,319 | INFO | HiveServer2-Handler-Pool: Thread-185 | UserName=hive UserIP=10.153.2.204 Time=2018/12/24 12:16:25 Operation=CloseSession Result=SUCCESS Detail= | org.apache.hive.service.cli.thrift.ThriftCLIService.logAuditEvent(ThriftCLIService.java:434)

11.39 Hive 性能调优

11.39.1 建立表分区

操作场景

Hive 在做 Select 查询时，一般会扫描整个表内容，会消耗较多时间去扫描不关注的数据。此时，可根据业务需求及其查询维度，建立合理的表分区，从而提高查询效率。

操作步骤

以 **root** 用户登录已安装 Hive 客户端的节点。

步骤 1 执行以下命令，进入客户端安装目录，例如“/opt/client”。

cd /opt/client

步骤 2 执行 **source bigdata_env** 命令，配置客户端环境变量。

步骤 3 在客户端中执行如下命令，执行登录操作。

kinit *用户名*

步骤 4 执行以下命令登录客户端工具。

beeline

步骤 5 指定静态分区或者动态分区。

- 静态分区：

  静态分区是手动输入分区名称，在创建表时使用关键字 **PARTITIONED BY** 指定分区列名及数据类型。应用开发时，使用 **ALTER TABLE ADD PARTITION** 语句增加分区，以及使用 **LOAD DATA INTO PARTITON** 语句将数据加载到分区时，只能静态分区。

- 动态分区：通过查询命令，将结果插入到某个表的分区时，可以使用动态分区。

  动态分区通过在客户端工具执行如下命令来开启：

  set hive.exec.dynamic.partition=true;

  动态分区默认模式是 strict，也就是必须至少指定一列为静态分区，在静态分区下建立动态子分区，可以通过如下设置来开启完全的动态分区：

  set hive.exec.dynamic.partition.mode=nonstrict;

说明

- 动态分区可能导致一个 DML 语句创建大量的分区，对应的创建大量新文件夹，对系统性能可能带来影响。
- 在文件数量大的情况下，执行一个 SQL 语句启动时间较长，可以在执行 SQL 语句之前执行“set mapreduce.input.fileinputformat.list-status.num-threads = 100;”命令来缩短启动时间。“mapreduce.input.fileinputformat.list-status.num-threads”参数需要先添加到 Hive 的白名单才可设置。

----结束

11.39.2 Join 优化

操作场景

使用 Join 语句时，如果数据量大，可能造成命令执行速度和查询速度慢，此时可进行 Join 优化。

Join 优化可分为以下方式：

- Map Join
- Sort Merge Bucket Map Join
- Join 顺序优化

Map Join

Hive 的 Map Join 适用于能够在内存中存放下的小表（指表大小小于 25MB），通过“hive.mapjoin.smalltable.filesize”定义小表的大小，默认为 25MB。

Map Join 的方法有两种：

- 使用/*+ MAPJOIN(join_table) */。
- 执行语句前设置如下参数，当前版本中该值默认为 true。

  set hive.auto.convert.join=true;

使用 Map Join 时没有 Reduce 任务，而是在 Map 任务前起了一个 MapReduce Local Task，这个 Task 通过 TableScan 读取小表内容到本机，在本机以 HashTable 的形式保存并写入硬盘上传到 DFS，并在 distributed cache 中保存，在 Map Task 中从本地磁盘或者 distributed cache 中读取小表内容直接与大表 join 得到结果并输出。

使用 Map Join 时需要注意小表不能过大，如果小表将内存基本用尽，会使整个系统性能下降甚至出现内存溢出的异常。

Sort Merge Bucket Map Join

使用 Sort Merge Bucket Map Join 必须满足以下 2 个条件：

- join 的两张表都很大，内存中无法存放。
- 两张表都按照 join key 进行分桶（clustered by (column)）和排序（sorted by(column)），且两张表的分桶数正好是倍数关系。

通过如下设置，启用 Sort Merge Bucket Map Join：

set hive.optimize.bucketmapjoin=true;

set hive.optimize.bucketmapjoin.sortedmerge=true;

这种 Map Join 也没有 Reduce 任务，是在 Map 任务前启动 MapReduce Local Task，将小表内容按桶读取到本地，在本机保存多个桶的 HashTable 备份并写入 HDFS，并保存在 Distributed Cache 中，在 Map Task 中从本地磁盘或者 Distributed Cache 中按桶一个一个读取小表内容，然后与大表做匹配直接得到结果并输出。

Join 顺序优化

当有 3 张及以上的表进行 Join 时，选择不同的 Join 顺序，执行时间存在较大差异。使用恰当的 Join 顺序可以有效缩短任务执行时间。

Join 顺序原则：

- Join 出来结果较小的组合，例如表数据量小或两张表 Join 后产生结果较少，优先执行。
- Join 出来结果大的组合，例如表数据量大或两张表 Join 后产生结果较多，在后面执行。

例如，customer 表的数据量最多，orders 表和 lineitem 表优先 Join 可获得较少的中间结果。

原有的 Join 语句如下：

```
select
  l_orderkey,
  sum(l_extendedprice * (1 - l_discount)) as revenue,
  o_orderdate,
  o_shippriority
from
  customer,
  orders,
  lineitem
where
  c_mktsegment = 'BUILDING'
  and c_custkey = o_custkey
  and l_orderkey = o_orderkey
  and o_orderdate < '1995-03-22'
  and l_shipdate > '1995-03-22'
limit 10;
```

Join 顺序优化后如下：

```
select
  l_orderkey,
  sum(l_extendedprice * (1 - l_discount)) as revenue,
  o_orderdate,
  o_shippriority
from
  orders,
  lineitem,
  customer
where
  c_mktsegment = 'BUILDING'
  and c_custkey = o_custkey
  and l_orderkey = o_orderkey
  and o_orderdate < '1995-03-22'
  and l_shipdate > '1995-03-22'
limit 10;
```

注意事项

Join 数据倾斜问题

执行任务的时候，任务进度长时间维持在 99%，这种现象叫数据倾斜。

数据倾斜是经常存在的，因为有少量的 Reduce 任务分配到的数据量和其他 Reduce 差异过大，导致大部分 Reduce 都已完成任务，但少量 Reduce 任务还没完成的情况。

解决数据倾斜的问题，可通过设置“set hive.optimize.skewjoin=true”并调整 hive.skewjoin.key 的大小。hive.skewjoin.key 是指 Reduce 端接收到多少个 key 即认为数据是倾斜的，并自动分发到多个 Reduce。

11.39.3 Group By 优化

操作场景

优化 Group by 语句，可提升命令执行速度和查询速度。

Group by 的时候， Map 端会先进行分组， 分组完后分发到 Reduce 端， Reduce 端再进行分组。可采用 Map 端聚合的方式来进行 Group by 优化，开启 Map 端初步聚合，减少 Map 的输出数据量。

操作步骤

在 Hive 客户端进行如下设置：

set hive.map.aggr=true;

注意事项

Group By 数据倾斜

Group By 也同样存在数据倾斜的问题，设置 hive.groupby.skewindata 为 true，生成的查询计划会有两个 MapReduce Job，第一个 Job 的 Map 输出结果会随机的分布到 Reduce 中，每个 Reduce 做聚合操作，并输出结果，这样的处理会使相同的 Group By Key 可能被分发到不同的 Reduce 中，从而达到负载均衡，第二个 Job 再根据预处理的结果按照 Group By Key 分发到 Reduce 中完成最终的聚合操作。

Count Distinct 聚合问题

当使用聚合函数 count distinct 完成去重计数时，处理值为空的情况会使 Reduce 产生很严重的数据倾斜，可以将空值单独处理，如果是计算 count distinct，可以通过 where 字句将该值排除掉，并在最后的 count distinct 结果中加 1。如果还有其他计算，可以先将值为空的记录单独处理，再和其他计算结果合并。

11.39.4 数据存储优化

操作场景

“ORC”是一种高效的列存储格式，在压缩比和读取效率上优于其他文件格式。

建议使用“ORC”作为 Hive 表默认的存储格式。

前提条件

已登录 Hive 客户端，具体操作请参见 11.5 使用 Hive 客户端。

操作步骤

- 推荐：使用“SNAPPY”压缩，适用于压缩比和读取效率要求均衡场景。

  Create table *xx (col_name data_type)* stored as orc tblproperties ("orc.compress"="SNAPPY");

- 可用：使用“ZLIB”压缩，适用于压缩比要求较高场景。

  Create table *xx (col_name data_type)* stored as orc tblproperties ("orc.compress"="ZLIB");

说明

xx 为具体使用的 Hive 表名。

11.39.5 SQL 优化

操作场景

在 Hive 上执行 SQL 语句查询时，如果语句中存在“(a&b) or (a&c)”逻辑时，建议将逻辑改为“a & (b or c)”。

样例

假设条件 a 为“p_partkey = l_partkey”，优化前样例如下所示：

```
select
       sum(l_extendedprice* (1 - l_discount)) as revenue
from
       lineitem,
       part
where
       (
              p_partkey = l_partkey
              and p_brand = 'Brand#32'
              and p_container in ('SM CASE', 'SM BOX', 'SM PACK', 'SM PKG')
              and l_quantity >= 7 and l_quantity <= 7 + 10
              and p_size between 1 and 5
              and l_shipmode in ('AIR', 'AIR REG')
              and l_shipinstruct = 'DELIVER IN PERSON'
       )
       or
       (      p_partkey = l_partkey
              and p_brand = 'Brand#35'
              and p_container in ('MED BAG', 'MED BOX', 'MED PKG', 'MED PACK')
              and l_quantity >= 15 and l_quantity <= 15 + 10
              and p_size between 1 and 10
              and l_shipmode in ('AIR', 'AIR REG')
              and l_shipinstruct = 'DELIVER IN PERSON'
       )
       or
       (      p_partkey = l_partkey
              and p_brand = 'Brand#24'
              and p_container in ('LG CASE', 'LG BOX', 'LG PACK', 'LG PKG')
              and l_quantity >= 26 and l_quantity <= 26 + 10
              and p_size between 1 and 15
              and l shipmode in ('AIR', 'AIR REG')
              and l shipinstruct = 'DELIVER IN PERSON'
       )
```

优化后样例如下所示：

```
select
       sum(l_extendedprice* (1 - l_discount)) as revenue
from
       lineitem,
       part
where  p_partkey = l_partkey and
       ((
              p_brand = 'Brand#32'
```

```
            and p_container in ('SM CASE', 'SM BOX', 'SM PACK', 'SM PKG')
            and l_quantity >= 7 and l_quantity <= 7 + 10
            and p_size between 1 and 5
            and l_shipmode in ('AIR', 'AIR REG')
            and l_shipinstruct = 'DELIVER IN PERSON'
      )
      or
      (
            p_brand = 'Brand#35'
            and p_container in ('MED BAG', 'MED BOX', 'MED PKG', 'MED PACK')
            and l_quantity >= 15 and l_quantity <= 15 + 10
            and p_size between 1 and 10
            and l_shipmode in ('AIR', 'AIR REG')
            and l_shipinstruct = 'DELIVER IN PERSON'
      )
      or
      (
            p_brand = 'Brand#24'
            and p_container in ('LG CASE', 'LG BOX', 'LG PACK', 'LG PKG')
            and l_quantity >= 26 and l_quantity <= 26 + 10
            and p_size between 1 and 15
            and l_shipmode in ('AIR', 'AIR REG')
            and l_shipinstruct = 'DELIVER IN PERSON'
      ))
```

11.39.6 使用 Hive CBO 优化查询

操作场景

在 Hive 中执行多表 Join 时，Hive 支持开启 CBO（Cost Based Optimization），系统会自动根据表的统计信息，例如数据量、文件数等，选出合适计划提高多表 Join 的效率。Hive 需要先收集表的统计信息后才能使 CBO 正确的优化。

说明

- CBO 优化器会基于统计信息和查询条件，尽可能地使 join 顺序达到更优。但是也可能存在特殊情况导致 join 顺序调整不准确。例如数据存在倾斜，以及查询条件值在表中不存在等场景，可能调整出非优化的 join 顺序。
- 开启列统计信息自动收集时，需要在 reduce 侧做聚合统计。对于没有 reduce 阶段的 insert 任务，将会多出 reduce 阶段，用于收集统计信息。

前提条件

已登录 Hive 客户端，具体操作请参见 11.5 使用 Hive 客户端。

操作步骤

在 Manager 界面 Hive 组件的配置中搜索“hive.cbo.enable”参数，选中“true”永久开启功能。

步骤 1 手动收集 Hive 表已有数据的统计信息。

执行以下命令，可以手动收集统计信息。仅支持统计一张表，如果需要统计不同的表需重复执行。

ANALYZE TABLE [db_name.]tablename [PARTITION(partcol1[=val1], partcol2[=val2], ...)]

COMPUTE STATISTICS

[FOR COLUMNS]

[NOSCAN];

说明

- 指定 FOR COLUMNS 时，收集列级别的统计信息。
- 指定 NOSCAN 时，将只统计文件大小和个数，不扫描具体文件。

例如：

analyze table table_name compute statistics;

analyze table table_name compute statistics for columns;

步骤 2 配置 Hive 自动收集统计信息。开启配置后，执行 **insert overwrite/into** 命令插入数据时才自动统计新数据的信息。

- 在 Hive 客户端执行以下命令临时开启收集：

  set hive.stats.autogather = true;开启表/分区级别的统计信息自动收集。

  set hive.stats.column.autogather = true; 开启列级别的统计信息自动收集。

  说明

  - 列级别统计信息的收集不支持复杂的数据类型，例如 Map，Struct 等。
  - 表级别统计信息的自动收集不支持 Hive on HBase 表。

- 在 Manager 界面 Hive 的服务配置中，搜索参数“hive.stats.autogather”和“hive.stats.column.autogather”，选中“true”永久开启收集功能。

步骤 3 执行以下命令可以查看统计信息。

DESCRIBE FORMATTED table_name[.column_name] PARTITION partition_spec;

例如：

desc formatted table_name;

desc formatted table_name id;

desc formatted table_name partition(time='2016-05-27');

说明

分区表仅支持分区级别的统计信息收集，因此分区表需要指定分区来查询统计信息。

----结束

11.40 Hive 常见问题

11.40.1 如何在多个 HiveServer 之间同步删除 UDF

问题

如果需要删除永久函数（Permanent UDF），如何在多个 HiveServer 之间同步删除？

回答

因为多个 HiveServer 之间共用一个 MetaStore 存储数据库，所以 MetaStore 存储数据库和 HiveServer 的内存之间数据同步有延迟。如果在单个 HiveServer 上删除永久函数，操作结果将无法同步到其他 HiveServer 上。

遇到如上情况，需要登录 Hive 客户端，连接到每个 HiveServer，并分别删除永久函数。具体操作如下：

以 Hive 客户端安装用户登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd *客户端安装目录*

例如安装目录为“/opt/client”，则执行以下命令：

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 执行以下命令进行用户认证。

kinit *Hive 业务用户*

说明

登录的用户需具备 Hive admin 权限。

步骤 4 执行如下命令，连接指定的 HiveServer。

beeline -u "jdbc:hive2://*10.39.151.74***:***21066***/default;sasl.qop=auth-conf;auth=KERBEROS;principal=***hive/hadoop.<系统域名>@<系统域名>***"**

说明

- *10.39.151.74* 为 HiveServer 所在节点的 IP 地址。
- *21066* 为 HiveServer 端口。HiveServer 端口默认范围为 21066～21070，用户需根据实际配置端口进行修改。
- *hive* 为用户名。例如，使用 Hive1 实例时，则使用 hive1。
- 用户可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。
- “hive/hadoop.*<系统域名>*”为用户名，用户的用户名所包含的系统域名所有字母为小写。

步骤 5 执行如下命令，启用 Hive admin 权限。

set role admin;

步骤 6 执行如下命令，删除永久函数。

drop function *function_name*;

说明

- *function_name* 为永久函数的函数名。
- 如果永久函数是在 Spark 中创建的，在 Spark 中删除该函数后需要在 HiveServer 中删除，即执行上述删除命令。

步骤 7 确定是否已连接所有 HiveServer 并删除永久函数。

- 是，操作完毕。
- 否，执行步骤 5。

----结束

11.40.2 已备份的 Hive 表无法执行 drop 操作

问题

为什么已备份的 Hive 表执行 drop 操作会失败？

回答

由于已备份 Hive 表对应的 HDFS 目录创建了快照，导致 HDFS 目录无法删除，造成 Hive 表删除失败。

Hive 表在执行备份操作时，会创建表对应的 HDFS 数据目录快照。而 HDFS 的快照机制有一个约束：如果一个 HDFS 目录已创建快照，则在快照完全删除之前，该目录无法删除或修改名称。Hive 表（除 EXTERNAL 表外）执行 drop 操作时，会尝试删除该表对应的 HDFS 数据目录，如果目录删除失败，系统会提示表删除失败。

如果确实需要删除该表，可手动删除涉及到该表的所有备份任务。

11.40.3 如何在 Hive 自定义函数中操作本地文件

问题

在 Hive 自定义函数中需要操作本地文件，例如读取文件的内容，需要如何操作？

回答

默认情况下，可以在 UDF 中用文件的相对路径来操作文件，如下示例代码：

```
public String evaluate(String text) {
  // some logic
  File file = new File("foo.txt");
  // some logic
  // do return here
}
```

在 Hive 中使用时，将 UDF 中用到的文件“foo.txt”上传到 HDFS 上，如上传到“hdfs://hacluster/tmp/foo.txt”，使用以下语句创建 UDF，在 UDF 中就可以直接操作“foo.txt”文件了：

create function testFunc as 'some.class' using jar 'hdfs://hacluster/somejar.jar', file 'hdfs://hacluster/tmp/foo.txt';

例外情况下，如果“hive.fetch.task.conversion”参数的值为“more”，在 UDF 中不能再使用相对路径来操作文件，而要使用绝对路径，并且保证所有的 HiveServer 节点和 NodeManager 节点上该文件是存在的且 **omm** 用户对该文件有相应的权限，才能正常在 UDF 中操作本地文件。

11.40.4 如何强制停止 Hive 执行的 MapReduce 任务

问题

在 Hive 执行 MapReduce 任务长时间卡住的情况下想手动停止任务，需要如何操作？

回答

登录 FusionInsight Manager。

步骤 1 选择“集群 > 服务 > Yarn”。

步骤 2 单击左侧页面的“ResourceManager(*主机名称*，主)”按钮，登录 Yarn 界面。

步骤 3 单击对应任务 ID 的按钮进入任务页面，单击界面左上角的“Kill Application”按钮，在弹框中单击“确认”停止任务。

----结束

11.40.5 Hive 复杂类型字段名称中包含特殊字符导致建表失败

问题

Hive 复杂类型字段名称中包含特殊字符，导致建表失败。

回答

Hive 不支持复杂类型字段名称中包含特殊字符，特殊字符是指英文大小写字母、阿拉伯数字、葡萄牙文字符以外的其他字符。

11.40.6 如何对 Hive 表大小数据进行监控

问题

如何对 Hive 中的表大小数据进行监控？

回答

当用户要对 Hive 表大小数据进行监控时，可以通过 HDFS 的精细化监控对指定表目录进行监控，从而到达监控指定表大小数据的目的。

前提条件

- Hive、HDFS 组件功能正常
- HDFS 精细化监控功能正常

操作步骤

登录 FusionInsight Manager。

步骤 1 通过“集群 > *待操作集群的名称* > 服务 > HDFS > 资源 ”，进入 HDFS 精细化页面。

步骤 2 找到“资源使用（按目录）”监控项，单击该监控项左上角第一个图标。

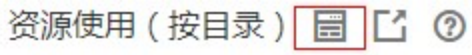

进入配置空间监控子页面，单击“添加”。

步骤 3 在名称空格中填写监控的表名称（或其他用户自定义的别名），在路径中填写需要监控表的路径。单击“确定”。该监控的横坐标为时间，纵坐标为监控目录的大小。

----结束

11.40.7 如何对重点目录进行保护，防止“insert overwrite”语句误操作导致数据丢失

问题

如何对重点目录进行保护，防止“insert overwrite”语句误操作导致数据丢失？

回答

当用户要对 Hive 重点数据库、表或目录进行监控，防止“insert overwrite”语句误操作导致数据丢失时，可以利用 Hive 配置中的“hive.local.dir.confblacklist”进行目录保护。

该配置项已对“/opt/”，“/user/hive/warehouse”等目录进行了默认配置。

前提条件

Hive、HDFS 组件功能正常。

操作步骤

登录 FusionInsight Manager。

步骤 1 选择“集群 > *待操作集群的名称* > 服务 > Hive > 配置 > 全部配置”，搜索“hive.local.dir.confblacklist”配置项。

在该配置项中添加用户要重点保护的数据库、表或目录路径。

步骤 2 输入完成后，单击“保存”，保存配置项。

----结束

11.40.8 未安装 HBase 时 Hive on Spark 任务卡顿处理

操作场景

此功能适用于 Hive 组件。

按如下操作步骤设置参数后，在未安装 HBase 的环境执行 Hive on Spark 任务时，可避免任务卡顿。

说明

Hive on Spark 任务的 Spark 内核版本已经升级到 Spark2x，可以支持在不安装 Spark2x 的情况下，执行 Hive on Spark 任务。如果没有安装 HBase，默认在执行 Spark 任务时，会尝试去连接 Zookeeper 访问 HBase，直到超时，这样会造成任务卡顿。

在未安装 HBase 的环境，要执行 Hive on Spark 任务，可以按如下操作处理。如果是从已有 HBase 低版本环境升级上来的，升级完成之后可不进行设置。

操作步骤

登录 FusionInsight Manager 。

步骤 1 选择“集群 > *待操作集群的名称* > 服务 > Hive > 配置 > 全部配置”。

步骤 2 选择“HiveServer（角色） > 自定义”，对参数文件“spark-defaults.conf”添加自定义参数，设置“名称”为“spark.security.credentials.hbase.enabled”，“值”为“false” 。

步骤 3 单击“保存”，在弹出对话框单击“确定”。

步骤 4 选择“集群 > *待操作集群的名称* > 服务 > Hive > 实例”，勾选所有 Hive 实例，选择“更多 > 重启实例”，输入密码，单击“确定”。

----结束

11.40.9 FusionInsight Hive 使用 WHERE 条件查询超过 3.2 万分区的表报错

问题

Hive 创建超过 3.2 万分区的表，执行带有 WHERE 分区的条件查询时出现异常，且“metastore.log”中打印的异常信息包含以下信息：

```
Caused by: java.io.IOException: Tried to send an out-of-range integer as a 2-byte
value: 32970
       at org.postgresql.core.PGStream.SendInteger2(PGStream.java:199)
       at
org.postgresql.core.v3.QueryExecutorImpl.sendParse(QueryExecutorImpl.java:1330)
       at
org.postgresql.core.v3.QueryExecutorImpl.sendOneQuery(QueryExecutorImpl.java:1601)
       at
org.postgresql.core.v3.QueryExecutorImpl.sendParse(QueryExecutorImpl.java:1191)
       at
org.postgresql.core.v3.QueryExecutorImpl.execute(QueryExecutorImpl.java:346)
```

回答

带有分区条件的查询，Hiveserver 会对分区进行优化，避免全表扫描，需要查询元数据符合条件的所有分区，而 gaussDB 中提供的接口 sendOneQuery，调用的 sendParse 方法中对参数的限制为 32767，如果分区条件数超过 32767 就异常。

11.40.10 使用 IBM 的 jdk 访问 Beeline 客户端出现连接 hiveserver 失败

操作场景

查看客户端使用的 jdk 版本，如果是 IBM JDK，则需要对 Beeline 客户端进行改造，否则会造成连接 hiveserver 失败。

操作步骤

登录 FusionInsight Manager 页面，选择“系统 > 权限 > 用户”，在待操作用户的“操作”栏下选择“更多 > 下载认证凭据”，选择集群信息后单击“确定”，下载 keytab 文件。

步骤 1 解压 keytab 文件，使用 WinSCP 工具将解压得到的“user.keytab”文件上传到待操作节点的 Hive 客户端安装目录下，例如：“/opt/client”。

步骤 2 使用以下命令打开 hive 客户端目录下面的配置文件 Hive/component_env：

vi *Hive 客户端安装目录*/**Hive/component_env**

在变量“export CLIENT_HIVE_URI”所在行后面添加如下内容：

```
\;user.principal=用户名@HADOOP.COM\;user.keytab=user.keytab 文件所在路径/user.keytab
```

----结束

11.40.11 关于 Hive 表的 location 支持跨 OBS 和 HDFS 路径的说明

问题

Hive 表的 location 支持跨 OBS 和 HDFS 路径吗？

回答

1. Hive 存储在 OBS 上的普通表，支持表 location 配置为 hdfs 路径。
2. 同一个 Hive 服务中可以分别创建存储在 OBS 上的表和存储在 HDFS 上的表。
3. Hive 存储在 OBS 上的分区表，不支持将分区 location 配置为 hdfs 路径（存储在 HDFS 上的分区表也不支持修改分区 location 为 OBS）。

11.40.12 通过 Tez 引擎执行 union 相关语句写入的数据，切换 MR 引擎后查询不出来。

问题

Hive 通过 Tez 引擎执行 union 相关语句写入的数据，切换到 Mapreduce 引擎后进行查询，发现数据没有查询出来。

回答

由于 Hive 使用 Tez 引擎在执行 union 语句时，生成的输出文件会存在 HIVE_UNION_SUBDIR 目录，切回 Mapreduce 引擎后默认不读取目录下的文件，所以没有读取到 HIVE_UNION_SUBDIR 目录下的数据。

此时可以设置参数 **set mapreduce.input.fileinputformat.input.dir.recursive=true**，开启 union 优化，决定是否读取目录下的数据。

11.40.13 Hive 不支持对同一张表或分区进行并发写数据

问题

为什么通过接口并发对 Hive 表进行写数据会导致数据不一致？

说明

该章节仅适用于 MRS 3.1.2 版本。

回答

Hive 不支持对同一张表或同一个分区进行并发数据插入，这样会导致多个任务操作同一个数据临时目录，一个任务将另一个任务的数据移走，导致任务数据异常。解决方法是修改业务逻辑，单线程插入数据到同一张表或同一个分区。

11.40.14 Hive 不支持向量化查询

问题

当设置向量化参数 hive.vectorized.execution.enabled=true 时，为什么执行 hive on Tez/Mapreduce/Spark 时会偶现一些空指针或类型转化异常？

回答

当前 Hive 不支持向量化执行，向量化执行有很多社区问题引入目前没有稳定修复，默认 hive.vectorized.execution.enabled=false，不建议将次参数打开。

11.40.15 Hive 表 HDFS 数据目录被误删，但是元数据仍然存在，导致执行任务报错处理

问题

Hive 表 HDFS 数据目录被误删，但是元数据仍然存在，导致执行任务报错。

回答

这是一种误操作的异常情况，需要手动删除对应表的元数据后重试。

例如：

执行以下命令进入控制台：

source ${BIGDATA_HOME}/FusionInsight_BASE_*xxx*/install/FusionInsight-dbservice-2.7.0/.dbservice_profile

gsql -p 20051 -U hive -d hivemeta -W HiveUser@

执行 **delete from tbls where tbl_id='xxx';**

11.40.16 如何关闭 Hive 客户端日志

问题

如何关闭 Hive 客户端的运行日志？

回答

使用 **root** 用户登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录，例如“/opt/client”。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 根据集群认证模式，完成 Hive 客户端登录。

- 安全模式，则执行以下命令，完成用户认证并登录 Hive 客户端。
  kinit *组件业务用户*
  beeline
- 普通模式，则执行以下命令，登录 Hive 客户端。
  - 使用指定组件业务用户登录 Hive 客户端。

beeline -n *组件业务用户*

- 不指定组件业务用户登录 Hive 客户端，则会以当前操作系统用户登录。

  beeline

步骤 4 执行以下命令关闭客户端日志：

set hive.server2.logging.operation.enabled=false;

步骤 5 执行以下命令查看客户端日志是否已关闭，如下图所示即为关闭成功。

set hive.server2.logging.operation.enabled;

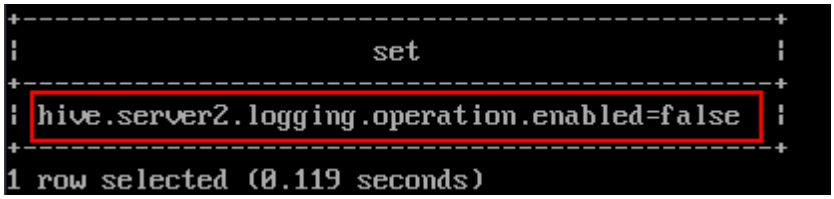

----结束

11.40.17 Hive 快删目录配置类问题

问题

在配置 MRS 多用户访问 OBS 细粒度权限的场景中，在 Hive 自定义配置中添加 OBS 快删目录的配置后，删除 Hive 表，执行结果为成功，但是 OBS 目录没有删掉。

回答

由于没有给用户配置快删目录的权限，导致数据不能被删除。需要修改用户对应的委托的 IAM 自定义策略，在策略内容上，配置 Hive 快删目录的权限。

11.40.18 Hive 配置类问题

- Hive SQL 执行报错：java.lang.OutOfMemoryError: Java heap space.

  解决方案：

  - 对于 MapReduce 任务，增大下列参数：

    set mapreduce.map.memory.mb=8192;

    set mapreduce.map.java.opts=-Xmx6554M;

    set mapreduce.reduce.memory.mb=8192;

    set mapreduce.reduce.java.opts=-Xmx6554M;

  - 对于 Tez 任务，增大下列参数：

    set hive.tez.container.size=8192;

- Hive SQL 对列名 as 为新列名后，使用原列名编译报错：Invalid table alias or column reference 'xxx'.

  解决方案：**set hive.cbo.enable=true;**

- Hive SQL 子查询编译报错：Unsupported SubQuery Expression 'xxx': Only SubQuery expressions that are top level conjuncts are allowed.

解决方案：**set hive.cbo.enable=true;**

- Hive SQL 子查询编译报错：CalciteSubquerySemanticException [Error 10249]: Unsupported SubQuery Expression Currently SubQuery expressions are only allowed as Where and Having Clause predicates.

  解决方案：**set hive.cbo.enable=true;**

- Hive SQL 编译报错：Error running query: java.lang.AssertionError: Cannot add expression of different type to set.

  解决方案：**set hive.cbo.enable=false;**

- Hive SQL 执行报错：java.lang.NullPointerException at org.apache.hadoop.hive.ql.udf.generic.GenericUDAFComputeStats$GenericUDAFNumericStatsEvaluator.init.

  解决方案：**set hive.map.aggr=false;**

- Hive SQL 设置 hive.auto.convert.join = true（默认开启）和 hive.optimize.skewjoin=true 执行报错：ClassCastException org.apache.hadoop.hive.ql.plan.ConditionalWork cannot be cast to org.apache.hadoop.hive.ql.plan.MapredWork.

  解决方案：**set hive.optimize.skewjoin=false;**

- Hive SQL 设置 hive.auto.convert.join=true（默认开启）、hive.optimize.skewjoin=true 和 hive.exec.parallel=true 执行报错：java.io.FileNotFoundException: File does not exist:xxx/reduce.xml.

  解决方案：

  - 方法一：切换执行引擎为 Tez，详情请参考 11.29 切换 Hive 执行引擎为 Tez。
  - 方法二：**set hive.exec.parallel=false;**
  - 方法三：**set hive.auto.convert.join=false;**

- Hive on Tez 执行 Bucket 表 Join 报错：NullPointerException at org.apache.hadoop.hive.ql.exec.CommonMergeJoinOperator.mergeJoinComputeKeys

  解决方案：**set tez.am.container.reuse.enabled=false;**

12 使用 Hudi

12.1 快速入门

操作场景

本指南通过使用 spark-shell 简要介绍了 Hudi 功能。使用 Spark 数据源，将通过代码段展示如何插入和更新 Hudi 的默认存储类型数据集： COW 表。每次写操作之后，还将展示如何读取快照和增量数据。

前提条件

- 在 Manager 界面创建用户并添加 hadoop 和 hive 用户组，主组加入 hadoop。

操作步骤

下载并安装 Hudi 客户端，具体请参考 25.3.1 安装客户端章节。

说明

目前 Hudi 集成在 Spark2x 中，用户从 Manager 页面下载 Spark2x 客户端即可，例如客户端安装目录为：“/opt/client”。

步骤 1 使用 root 登录客户端安装节点，执行如下命令：

cd /opt/client

步骤 2 执行 **source** 命令加载环境变量：

source bigdata_env

source Hudi/component_env

kinit *创建的用户*

说明

- 新创建的用户需要修改密码，更改密码后重新 kinit 登录。
- 普通模式（未开启 kerberos 认证）无需执行 **kinit** 命令。
- 多服务场景下，在 source bigdata_env 之后，请先 source Spark 服务的 component_env，再去 source Hudi 的 component_env。

步骤 3 使用 **spark-shell --master yarn-client**，引入 Hudi 包生成测试数据：

- 引入需要的包

  import org.apache.hudi.QuickstartUtils._
  import scala.collection.JavaConversions._
  import org.apache.spark.sql.SaveMode._
  import org.apache.hudi.DataSourceReadOptions._
  import org.apache.hudi.DataSourceWriteOptions._
  import org.apache.hudi.config.HoodieWriteConfig._

- 定义表名，存储路径，生成测试数据

  val tableName = "hudi_cow_table"
  val basePath = "hdfs://hacluster/tmp/hudi_cow_table"
  val dataGen = new DataGenerator
  val inserts = convertToStringList(dataGen.generateInserts(10))
  val df = spark.read.json(spark.sparkContext.parallelize(inserts, 2))

步骤 4 写入 Hudi 表，模式为 OVERWRITE。

df.write.format("org.apache.hudi").

options(getQuickstartWriteConfigs).

option(PRECOMBINE_FIELD_OPT_KEY, "ts").

option(RECORDKEY_FIELD_OPT_KEY, "uuid").

option(PARTITIONPATH_FIELD_OPT_KEY, "partitionpath").

option(TABLE_NAME, tableName).

mode(Overwrite).

save(basePath)

步骤 5 查询 Hudi 表。

注册临时表并查询：

val roViewDF = spark.read.format("org.apache.hudi").load(basePath + "/*/*/*/*")

roViewDF.createOrReplaceTempView("hudi_ro_table")

spark.sql("select fare, begin_lon, begin_lat, ts from hudi_ro_table where fare > 20.0").show()

步骤 6 生成更新数据并更新 Hudi 表，模式为 APPEND。

val updates = convertToStringList(dataGen.generateUpdates(10))

val df = spark.read.json(spark.sparkContext.parallelize(updates, 1))

df.write.format("org.apache.hudi").

options(getQuickstartWriteConfigs).

option(PRECOMBINE_FIELD_OPT_KEY, "ts").

option(RECORDKEY_FIELD_OPT_KEY, "uuid").

```
option(PARTITIONPATH_FIELD_OPT_KEY, "partitionpath").
option(TABLE_NAME, tableName).
mode(Append).
save(basePath)
```

步骤 7 查询 Hudi 表增量数据。

- 重新加载：

```
spark.read.format("org.apache.hudi").load(basePath +
"/*/*/*/*").createOrReplaceTempView("hudi_ro_table")
```

- 进行增量查询：

```
val commits = spark.sql("select distinct(_hoodie_commit_time) as commitTime
from  hudi_ro_table order by commitTime").map(k => k.getString(0)).take(50)
val beginTime = commits(commits.length - 2)
val incViewDF = spark.
read.
format("org.apache.hudi").
option(VIEW_TYPE_OPT_KEY, VIEW_TYPE_INCREMENTAL_OPT_VAL).
option(BEGIN_INSTANTTIME_OPT_KEY, beginTime).
load(basePath);
incViewDF.registerTempTable("hudi_incr_table")
spark.sql("select `_hoodie_commit_time`, fare, begin_lon, begin_lat, ts from
hudi_incr_table where fare > 20.0").show()
```

步骤 8 进行指定时间点提交的查询。

```
val beginTime = "000"
val endTime = commits(commits.length - 2)
val incViewDF = spark.read.format("org.apache.hudi").
option(VIEW_TYPE_OPT_KEY, VIEW_TYPE_INCREMENTAL_OPT_VAL).
option(BEGIN_INSTANTTIME_OPT_KEY, beginTime).
option(END_INSTANTTIME_OPT_KEY, endTime).
load(basePath);
incViewDF.registerTempTable("hudi_incr_table")
spark.sql("select `_hoodie_commit_time`, fare, begin_lon, begin_lat, ts from
hudi_incr_table where fare > 20.0").show()
```

步骤 9 删除数据。

- 准备删除的数据

```
val df = spark.sql("select uuid, partitionpath from hudi_ro_table limit 2")
val deletes = dataGen.generateDeletes(df.collectAsList())
```

- 执行删除操作

```
val df = spark.read.json(spark.sparkContext.parallelize(deletes, 2));
```

```
df.write.format("org.apache.hudi").
options(getQuickstartWriteConfigs).
option(OPERATION_OPT_KEY,"delete").
option(PRECOMBINE_FIELD_OPT_KEY, "ts").
option(RECORDKEY_FIELD_OPT_KEY, "uuid").
option(PARTITIONPATH_FIELD_OPT_KEY, "partitionpath").
option(TABLE_NAME, tableName).
mode(Append).
save(basePath);
```

- 重新查询数据

```
val roViewDFAfterDelete = spark.
read.
format("org.apache.hudi").
load(basePath + "/*/*/*/*")
roViewDFAfterDelete.createOrReplaceTempView("hudi_ro_table")
spark.sql("select uuid, partitionPath from hudi_ro_table").show()
```

----结束

12.2 Hudi 常用参数

本章节介绍 Hudi 重要配置的详细信息。

写入操作配置

表12-1 写入操作重要配置项

参数	描述	默认值
hoodie.datasource.write.table.name	指定写入的 hudi 表名。	无
hoodie.datasource.write.operation	写 hudi 表指定的操作类型，当前支持 upsert、delete、insert、bulk_insert 等方式。 • upsert：更新插入混合操作 • delete：删除操作 • insert：插入操作 • bulk_insert： 用于初始建表导入数据， 注意初始建表禁止使用 upsert、insert 方式 • insert_overwrite：对静态分区执行 insert overwrite • insert_overwrite_table：动态	upsert

参数	描述	默认值
	分区执行 insert overwrite，该操作并不会立刻删除全表做 overwrite，会逻辑上重写 hudi 表的元数据，无用数据后续由 hudi 的 clean 机制清理。效率比 bulk_insert + overwrite 高	
hoodie.datasource.write.table.type	指定 hudi 表类型，一旦这个表类型被指定，后续禁止修改该参数，可选值 MERGE_ON_READ。	COPY_ON_WRITE
hoodie.datasource.write.precombine.field	该值用于在写之前对具有相同的 key 的行进行合并去重。	ts
hoodie.datasource.write.payload.class	在更新过程中，该类用于提供方法将要更新的记录和更新的记录做合并，该实现可插拔，如要实现自己的合并逻辑，可自行编写。	org.apache.hudi.common.model.DefaultHoodieRecordPayload
hoodie.datasource.write.recordkey.field	用于指定 hudi 的主键，hudi 表要求有唯一主键。	uuid
hoodie.datasource.write.partitionpath.field	用于指定分区键，该值配合 hoodie.datasource.write.keygenerator.class 使用可以满足不同的分区场景。	无
hoodie.datasource.write.hive_style_partitioning	用于指定分区方式是否和 hive 保持一致，建议该值设置为 true。	true
hoodie.datasource.write.keygenerator.class	配合 hoodie.datasource.write.partitionpath.field，hoodie.datasource.write.recordkey.field 产生主键和分区方式。 **说明** 写入设置 KeyGenerator 与表保存的参数值不一致时将提示需要保持一致。	org.apache.hudi.keygen.ComplexKeyGenerator

同步 Hive 表配置

表12-2 同步 Hive 表参数配置

参数	描述	默认值
hoodie.datasource.hive_sync.enable	是否同步 hudi 表信息到 hive metastore。 注意 建议该值设置为 true，统一使用 hive 管理 hudi 表。	false
hoodie.datasource.hive_sync.database	要同步给 hive 的数据库名。	default
hoodie.datasource.hive_sync.table	要同步给 hive 的表名，建议这个值和 hoodie.datasource.write.table.name 保证一致。	unknown
hoodie.datasource.hive_sync.username	同步 hive 时，指定的用户名。	hive
hoodie.datasource.hive_sync.password	同步 hive 时，指定的密码。	hive
hoodie.datasource.hive_sync.jdbcurl	连接 hive jdbc 指定的连接。	""
hoodie.datasource.hive_sync.use_jdbc	是否使用 hive jdbc 方式连接 hive 同步 hudi 表信息。建议该值设置为 false，设置为 false 后 jdbc 连接相关配置无效。	true
hoodie.datasource.hive_sync.partition_fields	用于决定 hive 分区列。	""
hoodie.datasource.hive_sync.partition_extractor_class	用于提取 hudi 分区列值，将其转换成 hive 分区列。	org.apache.hudi.hive.SlashEncodedDayPartitionValueExtractor
hoodie.datasource.hive_sync.support_timestamp	当 hudi 表存在 timestamp 类型字段时，需指定此参数为 true，以实现同步 timestamp 类型到 hive 元数据中。该值默认为 false，默认将 timestamp 类型同步为 bigInt，默认情况可能导致使用 sql 查询包含 timestamp 类型字段的 hudi 表出现错误。	true

index 相关配置

表12-3 index 相关参数配置

参数	描述	默认值
hoodie.index.class	用户自定义索引的全路径名，索引类必须为 HoodieIndex 的子类，当指定该配置时，其会优先于 hoodie.index.type 配置。	""
hoodie.index.type	使用的索引类型，默认为布隆过滤器。可能的选项是[BLOOM | HBASE | GLOBAL_BLOOM | SIMPLE | GLOBAL_SIMPLE] 。 布隆过滤器消除了对外部系统的依赖，并存储在 Parquet 数据文件的页脚中。	BLOOM
hoodie.index.bloom.num_entries	存储在布隆过滤器中的条目数。假设 maxParquetFileSize 为 128MB，averageRecordSize 为 1024B，因此，一个文件中的记录总数约为 130K。 默认值（60000）大约是此近似值的一半。 **注意** 将此值设置得太低，将产生很多误报，并且索引查找将必须扫描比其所需的更多的文件；如果将其设置得非常高，将线性增加每个数据文件的大小（每 50000 个条目大约 4KB）。	60000
hoodie.index.bloom.fpp	根据条目数允许的错误率。 用于计算应为布隆过滤器分配多少位以及哈希函数的数量。通常将此值设置得很低（默认值：0.000000001），在磁盘空间上进行权衡以降低误报率。	0.000000001
hoodie.bloom.index.parallelism	索引查找的并行度，其中涉及 Spark Shuffle。 默认情况下，根据输入的工作负载特征自动计算的。	0
hoodie.bloom.index.prune.by.ranges	为 true 时，从文件框定信息，可以加快索引查找的速度。 如果键具有单调递增的前缀，例如时间戳，则特别有用。	true

参数	描述	默认值
hoodie.bloom.index.use.caching	为 true 时，将通过减少用于计算并行度或受影响分区的 IO 来缓存输入的 RDD 以加快索引查找。	true
hoodie.bloom.index.use.treebased.filter	为 true 时，启用基于间隔树的文件过滤优化。与暴力模式相比，此模式可根据键范围加快文件过滤速度。	true
hoodie.bloom.index.bucketized.checking	为 true 时，启用了桶式布隆过滤。这减少了在基于排序的布隆索引查找中看到的偏差。	true
hoodie.bloom.index.keys.per.bucket	仅在启用 bloomIndexBucketizedChecking 并且索引类型为 bloom 的情况下适用。 此配置控制“存储桶”的大小，该大小可跟踪对单个文件进行的记录键检查的次数，并且是分配给执行布隆过滤器查找的每个分区的工作单位。 较高的值将分摊将布隆过滤器读取到内存的固定成本。	10000000
hoodie.bloom.index.update.partition.path	仅在索引类型为 GLOBAL_BLOOM 时适用。 为 true 时，当对一个已有记录执行包含分区路径的更新操作时，将会导致把新记录插入到新分区，而把原有记录从旧分区里删除。为 false 时，只对旧分区的原有记录进行更新。	true
hoodie.index.hbase.zkquorum	仅在索引类型为 HBASE 时适用，必填选项。要连接的 HBase ZK Quorum URL。	无
hoodie.index.hbase.zkport	仅在索引类型为 HBASE 时适用，必填选项。要连接的 HBase ZK Quorum 端口。	无
hoodie.index.hbase.zknode.path	仅在索引类型为 HBASE 时适用，必填选项。这是根 znode，它将包含 HBase 创建及使用的所有 znode。	无
hoodie.index.hbase.table	仅在索引类型为 HBASE 时适	无

参数	描述	默认值
	用，必填选项。HBase 表名称，用作索引。Hudi 将 row_key 和 [partition_path, fileID, commitTime]映射存储在表中。	

存储配置

表12-4 存储参数配置

参数	描述	默认值
hoodie.parquet.max.file.size	Hudi 写阶段生成的 parquet 文件的目标大小。对于 DFS，这需要与基础文件系统块大小保持一致，以实现最佳性能。	120 * 1024 * 1024 byte
hoodie.parquet.block.size	parquet 页面大小，页面是 parquet 文件中的读取单位，在一个块内，页面被分别压缩。	120 * 1024 * 1024 byte
hoodie.parquet.compression.ratio	当 Hudi 尝试调整新 parquet 文件的大小时，预期对 parquet 数据进行压缩的比例。 如果 bulk_insert 生成的文件小于预期大小，请增加此值。	0.1
hoodie.parquet.compression.codec	parquet 压缩编解码方式名称，默认值为 gzip。可能的选项是 [gzip | snappy | uncompressed | lzo]	snappy
hoodie.logfile.max.size	LogFile 的最大值。这是在将日志文件移到下一个版本之前允许的最大值。	1GB
hoodie.logfile.data.block.max.size	LogFile 数据块的最大值。这是允许将单个数据块附加到日志文件的最大值。 这有助于确保附加到日志文件的数据被分解为可调整大小的块，以防止发生 OOM 错误。此大小应大于 JVM 内存。	256MB
hoodie.logfile.to.parquet.compression.ratio	随着记录从日志文件移动到 parquet，预期会进行额外压缩的比例。 用于 merge_on_read 存储，以将插入内容发送到日志文件中并控制压缩 parquet 文件的	0.35

参数	描述	默认值
	大小。	

compaction&cleaning 配置

表12-5 compaction&cleaning 参数配置

参数	描述	默认值
hoodie.clean.automatic	是否执行自动 clean。	true
hoodie.cleaner.policy	要使用的清理政策。Hudi 将删除旧版本的 parquet 文件以回收空间。 任何引用此版本文件的查询和计算都将失败。建议确保数据保留的时间超过最大查询执行时间。	KEEP_LATEST_COMMITS
hoodie.cleaner.commits.retained	保留的提交数。因此，数据将保留为 num_of_commits * time_between_commits（计划的），这也直接转化为逐步提取此数据集的数量。	10
hoodie.keep.max.commits	触发归档操作的 commit 数阈值。	30
hoodie.keep.min.commits	归档操作保留的 commit 数。	20
hoodie.commits.archival.batch	这控制着批量读取并一起归档的提交即时的数量。	10
hoodie.parquet.small.file.limit	该值应小于 maxFileSize，如果将其设置为 0，会关闭此功能。由于批处理中分区中插入记录的数量众多，总会出现小文件。Hudi 提供了一个选项，可以通过将对该分区中的插入作为对现有小文件的更新来解决小文件的问题。此处的大小是被视为“小文件大小”的最小文件大小。	104857600 byte
hoodie.copyonwrite.insert.split.size	插入写入并行度。为单个分区的总共插入次数。写出 100MB 的文件，至少 1KB 大小的记录，意味着每个文件有 100K 记录。默认值是超额配置为 500K。 为了改善插入延迟，请对其进行调	500000

参数	描述	默认值
	整以匹配单个文件中的记录数。将此值设置为较小的值将导致文件变小（尤其是当 compactionSmallFileSize 为 0 时）。	
hoodie.copyonwrite.insert.auto.split	Hudi 是否应该基于最后 24 个提交的元数据动态计算 insertSplitSize，默认关闭。	true
hoodie.copyonwrite.record.size.estimate	平均记录大小。如果指定，Hudi 将使用它，并且不会基于最后 24 个提交的元数据动态地计算。 没有默认值设置。这对于计算插入并行度以及将插入打包到小文件中至关重要。	1024
hoodie.compact.inline	当设置为 true 时，紧接在插入或插入更新或批量插入的提交或增量提交操作之后由摄取本身触发压缩。	true
hoodie.compact.inline.max.delta.commits	触发内联压缩之前要保留的最大增量提交数。	5
hoodie.compaction.lazy.block.read	当 CompactedLogScanner 合并所有日志文件时，此配置有助于选择是否应延迟读取日志块。选择 true 以使用 I/O 密集型延迟块读取（低内存使用），或者为 false 来使用内存密集型立即块读取（高内存使用）。	true
hoodie.compaction.reverse.log.read	HoodieLogFormatReader 会从 pos=0 到 pos=file_length 向前读取日志文件。如果此配置设置为 true，则 Reader 会从 pos=file_length 到 pos=0 反向读取日志文件。	false
hoodie.cleaner.parallelism	如果清理变慢，请增加此值。	200
hoodie.compaction.strategy	用来决定在每次压缩运行期间选择要压缩的文件组的压缩策略。默认情况下，Hudi 选择具有累积最多未合并数据的日志文件。	org.apache.hudi.table.action.compact.strategy. LogFileSizeBasedCompactionStrategy
hoodie.compaction.target.io	LogFileSizeBasedCompactionStrategy 的压缩运行期间要花费的 MB 量。当压缩以内联模式运行	500 * 1024 MB

参数	描述	默认值
	时，此值有助于限制摄取延迟。	
hoodie.compaction.daybased.target.partitions	由 org.apache.hudi.io.compact.strategy.DayBasedCompactionStrategy 使用，表示在压缩运行期间要压缩的最新分区数。	10
hoodie.compaction.payload.class	这需要与插入/插入更新过程中使用的类相同。就像写入一样，压缩也使用记录有效负载类将日志中的记录彼此合并，再次与基本文件合并，并生成压缩后要写入的最终记录。	org.apache.hudi.common.model.Defaulthoodierecordpayload
hoodie.schedule.compact.only.inline	在写入操作时，是否只生成压缩计划。在 hoodie.compact.inline=true 时有效。	false
hoodie.run.compact.only.inline	通过 Sql 执行 run compaction 命令时，是否只执行压缩操作，压缩计划不存在时直接退出。	false

单表并发控制配置

表12-6 单表并发控制参数配置

参数	描述	默认值
hoodie.write.lock.provider	指定 lock provider，不建议使用默认值，使用 org.apache.hudi.hive.HiveMetastoreBasedLockProvider	org.apache.hudi.client.transaction.lock.ZookeeperBasedLockProvider
hoodie.write.lock.hivemetastore.database	Hive 的 database	无
hoodie.write.lock.hivemetastore.table	Hive 的 table name	无
hoodie.write.lock.client.num_retries	重试次数	10
hoodie.write.lock.client.wait_time_ms_between_retry	重试间隔	10000
hoodie.write.lock.conflict.resolution.strategy	lock provider 类，必须是 ConflictResolutionStrategy 的子	org.apache.hudi.client.transaction.SimpleConcurre

参数	描述	默认值
	类	ntFileWritesConflictResolutionStrategy
hoodie.write.lock.zookeeper.base_path	存放 ZNodes 的路径，同一张表的并发写入需配置一致	无
hoodie.write.lock.zookeeper.lock_key	ZNode 的名称，建议与 Hudi 表名相同	无
hoodie.write.lock.zookeeper.connection_timeout_ms	zk 连接超时时间	15000
hoodie.write.lock.zookeeper.port	zk 端口号	无
hoodie.write.lock.zookeeper.url	zk 的 url	无
hoodie.write.lock.zookeeper.session_timeout_ms	zk 的 session 过期时间	60000

Clustering 配置

说明

本章节内容仅使用于 MRS 3.2.0 及之后版本。

Clustering 中有两个策略分别是 hoodie.clustering.plan.strategy.class 和 hoodie.clustering.execution.strategy.class。一般情况下指定 plan.strategy 为 SparkRecentDaysClusteringPlanStrategy 或者 SparkSizeBasedClusteringPlanStrategy 时，execution.strategy 不需要指定。但当 plan.strategy 为 SparkSingleFileSortPlanStrategy 时，需要指定 execution.strategy 为 SparkSingleFileSortExecutionStrategy。

表12-7 Clustering 参数配置

参数	描述	默认值
hoodie.clustering.inline	是否同步执行 clustering	false
hoodie.clustering.inline.max.commits	触发 clustering 的 commit 数	4
hoodie.clustering.async.enabled	是否启用异步执行 clustering **说明** 此参数仅适用于 MRS 3.3.0-LTS 及之后版本。	false
hoodie.clustering.async.max.commits	异步执行时触发 clustering 的 commit 数 **说明** 此参数仅适用于 MRS 3.3.0-LTS 及	4

参数	描述	默认值
	之后版本。	
hoodie.clustering.plan.strategy.target.file.max.bytes	指定 clustering 后每个文件大小最大值	1024 * 1024 * 1024 byte
hoodie.clustering.plan.strategy.small.file.limit	小于该大小的文件会被 clustering	300 * 1024 * 1024 byte
hoodie.clustering.plan.strategy.sort.columns	clustering 用以排序的列	无
hoodie.layout.optimize.strategy	Clustering 执行策略，可选 linear、z-order、hilbert 三种排序方式	linear
hoodie.layout.optimize.enable	使用 z-order、hilbert 时需要开启	false
hoodie.clustering.plan.strategy.class	筛选 FileGroup 进行 clustering 的策略类，默认筛选小于 hoodie.clustering.plan.strategy.small.file.limit 阈值的文件	org.apache.hudi.client.clustering.plan.strategy.SparkSizeBasedClusteringPlanStrategy
hoodie.clustering.execution.strategy.class	执行 clustering 的策略类（RunClusteringStrategy 的子类），用以定义群集计划的执行方式。 默认类们按指定的列对计划中的文件组进行排序，同时满足配置的目标文件大小	org.apache.hudi.client.clustering.run.strategy.SparkSortAndSizeExecutionStrategy
hoodie.clustering.plan.strategy.max.num.groups	设置执行 clustering 时最多选择多少个 FileGroup，该值越大并发度越大	30
hoodie.clustering.plan.strategy.max.bytes.per.group	设置执行 clustering 时每个 FileGroup 最多有多少数据参与 clustering	2 * 1024 * 1024 * 1024 byte

12.3 基本操作

12.3.1 Hudi 表结构

Hudi 在写入数据时会根据设置的存储路径、表名、分区结构等属性生成 Hudi 表。

Hudi 表的数据文件，可以使用操作系统的文件系统存储，也可以使用 HDFS 这种分布式的文件系统存储。为了后续分析性能和数据的可靠性，一般使用 HDFS 进行存储。以 HDFS 存储来看，一个 Hudi 表的存储文件分为两类。

登录 FusionInsight Manager 页面，选择“集群 > 服务 > HDFS”，在“概览”页面单击 NameNode WebUI 后的链接，进入到 HDFS 的 WebUI 界面，选择“Utilities > Browse the file system”，即可查看 Hudi 表。

Permission	Owner	Group	Size	Last Modified	Replication	Block Size	Name
drwxr-xr-x	testcz	hadoop	0 B	Apr 25 15:32	0	0 B	.hoodie
drwxr-xr-x	testcz	hadoop	0 B	Apr 25 15:30	0	0 B	americas
drwxr-xr-x	testcz	hadoop	0 B	Apr 25 15:30	0	0 B	asia

- “.hoodie”文件夹中存放了对应的文件合并操作相关的日志文件。

drwxr-xr-x	admintest	hadoop	0 B	Mar 30 09:44	0	0 B	.aux
drwxr-xr-x	admintest	hadoop	0 B	Mar 30 11:45	0	0 B	.temp
-rw-r--r--	admintest	hadoop	4.58 KB	Mar 30 09:44	3	128 MB	20210330094435.deltacommit
-rw-r--r--	admintest	hadoop	0 B	Mar 30 09:44	3	128 MB	20210330094435.deltacommit.inflight
-rw-r--r--	admintest	hadoop	0 B	Mar 30 09:44	3	128 MB	20210330094435.deltacommit.requested

- 包含_partition_key 相关的路径是实际的数据文件和 metadata，按分区存储。

  Hudi 的数据文件使用 Parquet 文件格式的 base file 和 Avro 格式的 log file 存储。

-rw-r--r--	admintest	hadoop	93 B	Mar 30 09:44	3	128 MB	.hoodie_partition_metadata
-rw-r--r--	admintest	hadoop	441.77 KB	Mar 30 09:46	3	128 MB	2b4d098e-4dc8-4633-a22a-dc22f87c57d9-1_0-13-22_20210330094613.parquet
-rw-r--r--	admintest	hadoop	445.28 KB	Mar 30 09:44	3	128 MB	4010e8a8-1b20-4be7-8442-4e30af401e84-0_1-4-8_20210330094435.parquet

12.3.2 写操作指导

12.3.2.1 批量写入

操作场景

Hudi 提供多种写入方式，具体见 hoodie.datasource.write.operation 配置项，这里主要介绍 UPSERT、INSERT 和 BULK_INSERT。

- INSERT（插入）： 该操作流程和 UPSERT 基本一致，但是不需要通过索引去查询具体更新的文件分区，因此它的速度比 UPSERT 快。当数据源不包含更新数据时建议使用该操作，若数据源中存在更新数据，则在数据湖中会出现重复数据。
- BULK_INSERT（批量插入）：用于初始数据集加载， 该操作会对主键进行排序后直接以写普通 parquet 表的方式插入 Hudi 表，该操作性能是最高的，但是无法控制小文件，而 UPSERT 和 INSERT 操作使用启发式方法可以很好的控制小文件。
- UPSERT（插入更新）： 默认操作类型。Hudi 会根据主键进行判断，如果历史数据存在则 update 如果不存在则 insert。因此在对于 CDC 之类几乎肯定包括更新的数据源，建议使用该操作。

说明

- 由于 INSERT 时不会对主键进行排序，所以初始化数据集不建议使用 INSERT。

- 在确定数据都为新数据时建议使用 INSERT，当存在更新数据时建议使用 UPSERT，当初始化数据集时建议使用 BULK_INSERT。

批量写入 Hudi 表

1. 引入 Hudi 包生成测试数据，参考 12.1 快速入门章节的步骤 2 到步骤 4。
2. 写入 Hudi 表，写入命令中加入参数：option("hoodie.datasource.write.operation", "bulk_insert")，指定写入方式为 bulk_insert，如下所示：

```
df.write.format("org.apache.hudi").
options(getQuickstartWriteConfigs).
option("hoodie.datasource.write.precombine.field", "ts").
option("hoodie.datasource.write.recordkey.field", "uuid").
option("hoodie.datasource.write.partitionpath.field", "").
option("hoodie.datasource.write.operation", "bulk_insert").
option("hoodie.table.name", tableName).
option("hoodie.datasource.write.keygenerator.class",
"org.apache.hudi.keygen.NonpartitionedKeyGenerator").
option("hoodie.datasource.hive_sync.enable", "true").
option("hoodie.datasource.hive_sync.partition_fields", "").
option("hoodie.datasource.hive_sync.partition_extractor_class",
"org.apache.hudi.hive.NonPartitionedExtractor").
option("hoodie.datasource.hive_sync.table", tableName).
option("hoodie.datasource.hive_sync.use_jdbc", "false").
option("hoodie.bulkinsert.shuffle.parallelism", 4).
mode(Overwrite).
save(basePath)
```

说明

- 示例中各参数介绍请参考表 12-1。
- 使用 spark datasource 接口更新 Mor 表，Upsert 写入小数据量时可能触发更新数据的小文件合并，使在 Mor 表的读优化视图中能查到部分更新数据。
- 当 update 的数据对应的 base 文件是小文件时，insert 中的数据和 update 中的数据会被合在一起和 base 文件直接做合并产生新的 base 文件，而不是写 log。

分区设置操作

Hudi 支持多种分区方式，如多级分区、无分区、单分区、时间日期分区。用户可以根据实际需求选择合适的分区方式，接下来将详细介绍 Hudi 如何配置各种分区类型。

- 多级分区

  多级分区即指定多个字段为分区键，需要注意的配置项：

配置项	说明
hoodie.datasource.write.partitionpath.field	配置为多个分区字段，例如：p1，p2，p3
hoodie.datasource.hive_sync.partition_fields	配置为 p1，p2，p3 和 hoodie.datasource.write.partitionpath.field 的分区字段保持一致
hoodie.datasource.write.keygenerator.class	配置为 org.apache.hudi.keygen.ComplexKeyGener

配置项	说明
	ator
hoodie.datasource.hive_sync.partition_extractor_class	配置为 org.apache.hudi.hive.MultiPartKeysValueExtractor

- 无分区

  hudi 支持无分区表，需要注意的配置项：

配置项	说明
hoodie.datasource.write.partitionpath.field	配置为空
hoodie.datasource.hive_sync.partition_fields	配置为空
hoodie.datasource.write.keygenerator.class	配置为 org.apache.hudi.keygen.NonpartitionedKeyGenerator
hoodie.datasource.hive_sync.partition_extractor_class	配置为 org.apache.hudi.hive.NonPartitionedExtractor

- 单分区

  和多级分区类似，需要配置项：

配置项	说明
hoodie.datasource.write.partitionpath.field	配置为一个字段，例如：p
hoodie.datasource.hive_sync.partition_fields	配置为 p，和 hoodie.datasource.write.partitionpath.field 分区字段保持一致
hoodie.datasource.write.keygenerator.class	默认配置为 org.apache.hudi.keygen.SimpleKeyGenerator ，也可以不配置
hoodie.datasource.hive_sync.partition_extractor_class	配置为 org.apache.hudi.hive.MultiPartKeysValueExtractor

- 时间日期分区

  即指定 date 类型字段作为分区字段，需要注意的配置项：

配置项	说明

配置项	说明
hoodie.datasource.write.partitionpath.field	配置为 date 类型字段比如 operationTime
hoodie.datasource.hive_sync.partition_fields	配置为 operationTime，和上面分区字段保持一致
hoodie.datasource.write.keygenerator.class	默认配置为 org.apache.hudi.keygen.SimpleKeyGenerator ，也可以不配置
hoodie.datasource.hive_sync.partition_extractor_class	配置 org.apache.hudi.hive.SlashEncodedDayPartitionValueExtractor

说明

SlashEncodedDayPartitionValueExtractor 存在以下约束：要求写入的日期格式为 yyyy/mm/dd。

- 分区排序：

配置项	说明
hoodie.bulkinsert.user.defined.partitioner.class	指定分区排序类，可自行定义排序方法，具体参考样例代码

说明

bulk_insert 默认字符排序，仅适用于 StringType 的主键。

12.3.2.2 流式写入

HoodieDeltaStreamer 流式写入

Hudi 自带 HoodieDeltaStreamer 工具支持流式写入，也可以使用 SparkStreaming 以微批的方式写入。HoodieDeltaStreamer 提供以下功能：

- 支持 Kafka，DFS 多种数据源接入 。
- 支持管理检查点、回滚和恢复，保证 exactly once 语义。
- 支持自定义转换操作。

示例：

准备配置文件 kafka-source.properties

```
#hudi 配置
hoodie.datasource.write.recordkey.field=id
hoodie.datasource.write.partitionpath.field=age
hoodie.upsert.shuffle.parallelism=100
#hive config
hoodie.datasource.hive_sync.table=hudimor_deltastreamer_partition
hoodie.datasource.hive_sync.partition_fields=age
```

```
hoodie.datasource.hive_sync.partition_extractor_class=org.apache.hudi.hive.MultiPar
tKeysValueExtractor
hoodie.datasource.hive_sync.use_jdbc=false
hoodie.datasource.hive_sync.support_timestamp=true
# Kafka Source topic
hoodie.deltastreamer.source.kafka.topic=hudimor_deltastreamer_partition
#checkpoint
hoodie.deltastreamer.checkpoint.provider.path=hdfs://hacluster/tmp/huditest/hudimor
_deltastreamer_partition
# Kafka props
# The kafka cluster we want to ingest from
bootstrap.servers= xx.xx.xx.xx:xx
auto.offset.reset=earliest
#auto.offset.reset=latest
group.id=hoodie-delta-streamer
offset.rang.limit=10000
```

指定 HoodieDeltaStreamer 执行参数执行如下命令：

spark-submit --master yarn

--jars /opt/hudi-java-examples-1.0.jar // 指定 spark 运行时需要的 hudi jars 路径

--driver-memory 1g

--executor-memory 1g --executor-cores 1 --num-executors 2 --conf spark.kryoserializer.buffer.max=128m

--driver-class-path /opt/client/Hudi/hudi/conf:/opt/client/Hudi/hudi/lib/*:/opt/client/Spark2x/spark/jars/*:/opt/hudi-examples-0.6.1-SNAPSHOT.jar:/opt/hudi-examples-0.6.1-SNAPSHOT-tests.jar // 指定 spark driver 需要的 hudi jars 路径

--class org.apache.hudi.utilities.deltastreamer.HoodieDeltaStreamer spark-internal

--props file:///opt/kafka-source.properties // 指定配置文件，注意：使用 yarn-cluster 模式提交任务时，请指定配置文件路径为 HDFS 路径。

--target-base-path /tmp/huditest/hudimor1_deltastreamer_partition // 指定 hudi 表路径

--table-type MERGE_ON_READ // 指定要写入的 hudi 表类型

--target-table hudimor_deltastreamer_partition // 指定 hudi 表名

--source-ordering-field name // 指定 hudi 表预合并列

--source-class org.apache.hudi.utilities.sources.JsonKafkaSource // 指定消费的数据源 为 JsonKafkaSource， 该参数根据不同数据源指定不同的 source 类

--schemaprovider-class com.xxx.bigdata.hudi.examples.DataSchemaProviderExample // 指定 hudi 表所需要的 schema

--transformer-class com.xxx.bigdata.hudi.examples.TransformerExample // 指定如何处理数据源拉取来的数据，可根据自身业务需求做定制

--enable-hive-sync // 开启 hive 同步，同步 hudi 表到 hive

--continuous // 指定流处理模式为连续模式

HoodieMultiTableDeltaStreamer 流式写入

说明

HoodieMultiTableDeltaStreamer 流式写入仅适用于 MRS 3.2.0 及之后版本。

HoodieDeltaStreamer 支持从多种类型的源表抓取数据写入 Hudi 目标表，但是 HoodieDeltaStreamer 只能完成一个源表更新一个目标表。而 HoodieMultiTableDeltaStreamer 可以完成多个源表更新多个目标表，也可以完成多个源表更新一个目标表。

- **多个源表写一个目标表(两个 kafka source 写一个 Hudi 表)：**

说明

主要配置：

```
// 指定目标表
hoodie.deltastreamer.ingestion.tablesToBeIngested=目录名.目标表
// 指定所有的源表给特定目标表
hoodie.deltastreamer.source.sourcesBoundTo.目标表=目录名.源表1，目录名.源表2
// 指定每个源表的配置文件路径
hoodie.deltastreamer.source.目录名.源表1.configFile=路径1
hoodie.deltastreamer.source.目录名.源表2.configFile=路径2
// 指定每个源表的恢复点，source 类型不同，恢复点的格式也不同。如 kafka soruce 格式为"topic 名,分区名:offset"
hoodie.deltastreamer.current.source.checkpoint=topic 名,分区名:offset
// 指定每个源表的关联表(hudi 表)，如果有多个用逗号隔开
hoodie.deltastreamer.source.associated.tables=hdfs://hacluster/.....,
hdfs://hacluster/.....
// 指定每个源表的数据在写入 hudi 前的 transform 操作，注意需要明确列出需要写入的列，不要使用 select *
// <SRC>代表当前 source 表，不要替换，这是固定写法
hoodie.deltastreamer.transformer.sql=select field1,field2,field3,... from <SRC>
```

Spark 提交命令：

```
spark-submit \
--master yarn \
--driver-memory 1g \
--executor-memory 1g \
--executor-cores 1 \
--num-executors 5 \
--conf
spark.driver.extraClassPath=/opt/client/Hudi/hudi/conf:/opt/client/Hudi/hudi/lib/*:/opt/client/Spark2x/spark/jars/* \
--class org.apache.hudi.utilities.deltastreamer.HoodieMultiTableDeltaStreamer
/opt/client/Hudi/hudi/lib/hudi-utilities_2.12-*.jar \
--props file:///opt/hudi/testconf/sourceCommon.properties \
--config-folder file:///opt/hudi/testconf/ \
--source-class org.apache.hudi.utilities.sources.JsonKafkaSource \
--schemaprovider-class
org.apache.hudi.examples.common.HoodieMultiTableDeltaStreamerSchemaProvider \
--transformer-class
org.apache.hudi.utilities.transform.SqlQueryBasedTransformer \
--source-ordering-field col6 \
--base-path-prefix hdfs://hacluster/tmp/ \
--table-type COPY_ON_WRITE \
--target-table KafkaToHudi \
```

```
--enable-hive-sync \
--allow-fetch-from-multiple-sources \
--allow-continuous-when-multiple-sources
```

说明

1. 当“source”的类型是“kafka source”时，“--schemaprovider-class”指定的 schema provider 类需要用户自己开发。
2. “--allow-fetch-from-multiple-sources”表示开启多源表写入。
3. “--allow-continuous-when-multiple-sources”表示开启多源表持续写入，如果未设置所有源表写入一次后任务就会结束。

sourceCommon.properties ：

```
hoodie.deltastreamer.ingestion.tablesToBeIngested=testdb.KafkaToHudi
hoodie.deltastreamer.source.sourcesBoundTo.KafkaToHudi=source1,source2
hoodie.deltastreamer.source.default.source1.configFile=file:///opt/hudi/testcon
f/source1.properties
hoodie.deltastreamer.source.default.source2.configFile=file:///opt/hudi/testcon
f/source2.properties

hoodie.datasource.write.keygenerator.class=org.apache.hudi.keygen.SimpleKeyGene
rator
hoodie.datasource.write.partitionpath.field=col0
hoodie.datasource.write.recordkey.field=primary_key
hoodie.datasource.write.precombine.field=col6

hoodie.datasource.hive_sync.table=kafkatohudisync
hoodie.datasource.hive_sync.partition_fields=col0
hoodie.datasource.hive_sync.partition_extractor_class=org.apache.hudi.hive.Mult
iPartKeysValueExtractor

bootstrap.servers=192.168.34.221:21005,192.168.34.136:21005,192.168.34.175:2100
5
auto.offset.reset=latest
group.id=hoodie-test
```

source1.properties：

```
hoodie.deltastreamer.current.source.name=source1 // kafka topic 的名称有时候可读性很差，所以这里给它取个别名当作 source 的名称
hoodie.deltastreamer.source.kafka.topic=s1
hoodie.deltastreamer.current.source.checkpoint=s1,0:0,1:0 // 任务启动时，该 source 的恢复点(从 0 分区的 0 offset，1 分区的 0 offset 开始恢复)
// 指定与 source1 表进行 join 的 hudi 表，如果该 hudi 表已经同步到 hive，则不需要该配置，直接在 sql 中通过表名来使用
hoodie.deltastreamer.source.associated.tables=hdfs://hacluster/tmp/huditest/tb_
test_cow_par
// <SRC>代表当前的 source 表，即 source1，固定写法
hoodie.deltastreamer.transformer.sql=select A.primary_key, A.col0, B.col1,
B.col2, A.col3, A.col4, B.col5, B.col6, B.col7 from <SRC> as A join
tb_test_cow_par as B on A.primary_key = B.primary_key
```

source2.properties

```
hoodie.deltastreamer.current.source.name=source2
hoodie.deltastreamer.source.kafka.topic=s2
hoodie.deltastreamer.current.source.checkpoint=s2,0:0,1:0
hoodie.deltastreamer.source.associated.tables=hdfs://hacluster/tmp/huditest/tb_
test_cow_par
```

```
hoodie.deltastreamer.transformer.sql=select A.primary_key, A.col0, B.col1,
B.col2, A.col3, A.col4, B.col5, B.col6, B.col7 from <SRC> as A join
tb_test_cow_par as B on A.primary_key = B.primary_key
```

- **多个源表写一个目标表(两个 Hudi 表 source 写一个 Hudi 表)：**

  Spark 提交命令：

```
spark-submit \
--master yarn \
--driver-memory 1g \
--executor-memory 1g \
--executor-cores 1 \
--num-executors 2 \
--conf
spark.driver.extraClassPath=/opt/client/Hudi/hudi/conf:/opt/client/Hudi/hudi/li
b/*:/opt/client/Spark2x/spark/jars/* \
--class org.apache.hudi.utilities.deltastreamer.HoodieMultiTableDeltaStreamer
/opt/client/Hudi/hudi/lib/hudi-utilities_2.12-*.jar \
--props file:///opt/testconf/sourceCommon.properties \
--config-folder file:///opt/testconf/ \
--source-class org.apache.hudi.utilities.sources.HoodieIncrSource \ //指定
source 的类型是 Hudi 表，作为源表的 Hudi 表只能是 COW 类型
--payload-class
org.apache.hudi.common.model.OverwriteNonDefaultsWithLatestAvroPayload \ //指定
一个 payload，payload 决定了新值更新旧值的方式。
--transformer-class
org.apache.hudi.utilities.transform.SqlQueryBasedTransformer \ //指定一个
transformer 类，源表 schema 和目标表的 schema 不一致时，源表的数据需要进行 transform 才能写
入目标表。
--source-ordering-field col6 \
--base-path-prefix hdfs://hacluster/tmp/ \ //目标表的存放路径
--table-type MERGE_ON_READ \ //目标表的类型，可以是 COW 表也可以是 MOR 表。
--target-table tb_test_mor_par_300 \ //指定目标表的表名，多源表更新单表时，目标表的表名
必须给出。
--checkpoint 000 \ //指定一个检查点(commit 时间戳)，表明从此检查点恢复 Delta Streamer，
000 代表从头开始。
--enable-hive-sync \
--allow-fetch-from-multiple-sources \
--allow-continuous-when-multiple-sources \
--op UPSERT //指定写操作类型
```

说明

- 当“source”的类型是“HoodieIncrSourc”时，不需要指定“--schemaprovider-class”。
- “--transformer-class”指定 SqlQueryBasedTransformer，可以通过 SQL 来操作数据转换，将源数据结构转换成目标表数据结构。

file:///opt/testconf/sourceCommon.properties：

```
# source 的公共属性
hoodie.deltastreamer.ingestion.tablesToBeIngested=testdb.tb_test_mor_par_300 //
指定一个目标表。多源表写单目标表，所以目标表可以作为公共属性。
hoodie.deltastreamer.source.sourcesBoundTo.tb_test_mor_par_300=testdb.tb_test_m
or_par_100,testdb.tb_test_mor_par_200 //指定多个源表。
hoodie.deltastreamer.source.testdb.tb_test_mor_par_100.configFile=file:///opt/t
estconf/tb_test_mor_par_100.properties //源表 tb_test_mor_par_100 的属性文件路径
hoodie.deltastreamer.source.testdb.tb_test_mor_par_200.configFile=file:///opt/t
estconf/tb_test_mor_par_200.properties //源表 tb_test_mor_par_200 的属性文件路径
```

```
# 所有 source 公用的 hudi 写配置，source 独立的配置需要写到自己对应的属性文件中
hoodie.datasource.write.keygenerator.class=org.apache.hudi.keygen.SimpleKeyGene
rator
hoodie.datasource.write.partitionpath.field=col0
hoodie.datasource.write.recordkey.field=primary_key
hoodie.datasource.write.precombine.field=col6
```

file:///opt/testconf/tb_test_mor_par_100.properties

```
# 源表 tb_test_mor_par_100 的配置
hoodie.deltastreamer.source.hoodieincr.path=hdfs://hacluster/tmp/testdb/tb_test
_mor_par_100 //源表的路径
hoodie.deltastreamer.source.hoodieincr.partition.fields=col0 //源表的分区键
hoodie.deltastreamer.source.hoodieincr.read_latest_on_missing_ckpt=false
hoodie.deltastreamer.source.associated.tables=hdfs://hacluster/tmp/testdb/tb_te
st_mor_par_400 //指定与源表进行关联操作的表
hoodie.deltastreamer.transformer.sql=select A.primary_key, A.col0, B.col1,
B.col2, A.col3, A.col4, B.col5, A.col6, B.col7 from <SRC> as A join
tb_test_mor_par_400 as B on A.primary_key = B.primary_key //该配置在 transformer
类指定为 SqlQueryBasedTransformer 才会生效
```

file:///opt/testconf/tb_test_mor_par_200.properties

```
# 源表 tb_test_mor_par_200 的配置
hoodie.deltastreamer.source.hoodieincr.path=hdfs://hacluster/tmp/testdb/tb_test
_mor_par_200
hoodie.deltastreamer.source.hoodieincr.partition.fields=col0
hoodie.deltastreamer.source.hoodieincr.read_latest_on_missing_ckpt=false
hoodie.deltastreamer.source.associated.tables=hdfs://hacluster/tmp/testdb/tb_te
st_mor_par_400
hoodie.deltastreamer.transformer.sql=select A.primary_key, A.col0, B.col1,
B.col2, A.col3, A.col4, B.col5, A.col6, B.col7 from <SRC> as A join
tb_test_mor_par_400 as B on A.primary_key = B.primary_key //源表数据结构转换为目标
表的数据结构。该源表如果需要和 Hive 进行关联操作，可以直接在 SQL 中通过表名来进行关联操作；该源
表如果需要和 Hudi 表关联操作，需要先指定 Hudi 表的路径，然后在 SQL 中通过表名来进行关联操作。
```

12.3.2.3 将 Hudi 表数据同步到 Hive

通过执行 run_hive_sync_tool.sh 可以将 Hudi 表数据同步到 Hive 中。

例如：需要将 HDFS 上目录为 hdfs://hacluster/tmp/huditest/hudimor1_deltastreamer_partition 的 Hudi 表同步为 Hive 表，表名为 table hive_sync_test3，使用 unite、country 和 state 为分区键，命令示例如下：

run_hive_sync_tool.sh --partitioned-by unite,country,state --base-path hdfs://hacluster/tmp/huditest/hudimor1_deltastreamer_partition --table hive_sync_test3 --partition-value-extractor org.apache.hudi.hive.MultiPartKeysValueExtractor --support-timestamp

表12-8 参数说明

命令	描述	必填	默认值
--database	Hive database 名称	N	default
--table	Hive 表名	Y	-

命令	描述	必填	默认值
--base-file-format	文件格式 (PARQUET 或 HFILE)	N	PARQUET
--user	Hive 用户名	N	-
--pass	Hive 密码	N	-
--jdbc-url	Hive jdbc connect url	N	-
--base-path	待同步的 Hudi 表存储路径	Y	-
--partitioned-by	分区键-	N	-
--partition-value-extractor	分区类，需实现 PartitionValueExtractor ，可以从 HDFS 路径中提取分区值	N	SlashEncodedDayPartitionValueExtractor
--assume-date-partitioning	以 yyyy/mm/dd 进行分区从而支持向后兼容。	N	false
--use-pre-apache-input-format	使用 com.uber.hoodie 包下的 InputFormat 替换 org.apache.hudi 包下的。除了从 com.uber.hoodie 迁移项目至 org.apache.hudi 外请勿使用。	N	false
--use-jdbc	使用 Hive jdbc 连接	N	true
--auto-create-database	自动创建 Hive database	N	true
--skip-ro-suffix	注册时跳过读取_ro 后缀的读优化视图	N	false
--use-file-listing-from-metadata	从 Hudi 的元数据中获取文件列表	N	false
--verify-metadata-file-listing	根据文件系统验证 Hudi 元数据中的文件列表	N	false
--help、-h	查看帮助	N	false
--support-timestamp	将原始类型中'INT64'的 TIMESTAMP_MICROS 转换为 Hive 的 timestamp	N	false
--decode-partition	如果分区在写入过程中已编码，则解码分区值	N	false
--batch-sync-	指定每批次同步 hive 的分	N	1000

命令	描述	必填	默认值
num	区数		

说明

Hive Sync 时会判断表不存在时建外表并添加分区，表存在时对比表的 schema 是否存在差异，存在则替换，对比分区是否有新增，有则添加分区。

因此使用 hive sync 时有以下约束：

- 写入数据 Schema 只允许增加字段，不允许修改、删除字段。
- 分区目录只能新增，不会删除。
- Overwrite 覆写 Hudi 表不支持同步覆盖 Hive 表。
- Hudi 同步 Hive 表时，不支持使用 timestamp 类型作为分区列。

12.3.3 读操作指导

12.3.3.1 简介

Hudi 的读操作，作用于 Hudi 的三种视图之上，可以根据需求差异选择合适的视图进行查询。

Hudi 支持多种查询引擎 Spark、Hive、HetuEngine，具体支持矩阵见表 12-9 和表 12-10。

表12-9 cow 表

查询引擎	实时视图/读优化视图	增量视图
Hive	Y	Y
Spark（SparkSQL）	Y	Y
Spark（SparkDataSource API）	Y	Y
HetuEngine	Y	N

表12-10 mor 表

查询引擎	实时视图	增量视图	读优化视图
Hive	Y	Y	Y
Spark（SparkSQL）	Y	Y	Y
Spark（SparkDataSource API）	Y	Y	Y

查询引擎	实时视图	增量视图	读优化视图
HetuEngine	Y	N	Y

⚠ 注意

- 当前 Hudi 使用 Spark datasource 接口读取时，不支持分区推断能力。比如 bootstrap 表使用 datasource 接口查询时，可能出现分区字段不显示，或者显示为 null 的情况。
- 增量视图，需设置 **set hoodie.hudicow.consume.mode = INCREMENTAL;**，但该参数仅限于增量视图查询，不能用于 Hudi 表的其他类型查询，和其他表的查询。 恢复配置可设置 **set hoodie.hudicow.consume.mode = SNAPSHOT;**或任意值。

12.3.3.2 cow 表视图读取

- 实时视图读取（Hive，SparkSQL 为例）：直接读取 Hive 里面存储的 Hudi 表即可，**${table_name}**表示表名称。

```
select count(*) from ${table_name};
```

- 实时视图读取（Spark dataSource API 为例）：和读普通的 dataSource 表类似。

  必须指定查询类型 QUERY_TYPE_OPT_KEY 为 QUERY_TYPE_SNAPSHOT_OPT_VAL，**${table_name}**表示表名称。

```
spark.read.format("hudi")
.option(QUERY_TYPE_OPT_KEY, QUERY_TYPE_SNAPSHOT_OPT_VAL) // 指定查询类型为实时视图模式
.load("/tmp/default/cow_bugx/") // 指定读取的 hudi 表路径
.createTempView("mycall")
spark.sql("select * from mycall").show(100)
```

- 增量视图读取（Hive 为例，**${table_name}**表示表名称）：

```
set hoodie.${table_name}.consume.mode=INCREMENTAL;  //设置增量读取模式
set hoodie.${table_name}.consume.max.commits=3;  // 指定最大消费的 commits 数量
set hoodie.${table_name}.consume.start.timestamp=20201227153030;  // 指定初始增量拉取 commit
select count(*) from default.${table_name} where
`_hoodie_commit_time`>'20201227153030'; // 这个过滤条件必须加且值为初始增量拉取的 commit。
```

- 增量视图读取（SparkSQL 为例，**${table_name}**表示表名称）：

```
set hoodie.${table_name}.consume.mode=INCREMENTAL;  //设置增量读取模式
set hoodie.${table_name}.consume.start.timestamp=20201227153030;  // 指定初始增量拉取 commit
set hoodie.${table_name}.consume.end.timestamp=20210308212318;  // 指定增量拉取结束 commit，如果不指定的话采用最新的 commit
select count(*) from default.${table_name} where
`_hoodie_commit_time`>'20201227153030'; // 这个过滤条件必须加且值为初始增量拉取的 commit。
```

- 增量视图读取（Spark dataSource API 为例）：

  必须指定查询类型 QUERY_TYPE_OPT_KEY 为增量模式 QUERY_TYPE_INCREMENTAL_OPT_VAL

```
spark.read.format("hudi")
.option(QUERY_TYPE_OPT_KEY, QUERY_TYPE_INCREMENTAL_OPT_VAL) // 指定查询类型为增量模式
.option(BEGIN_INSTANTTIME_OPT_KEY, "20210308212004") // 指定初始增量拉取 commit
.option(END_INSTANTTIME_OPT_KEY, "20210308212318") // 指定增量拉取结束 commit
.load("/tmp/default/cow_bugx/") // 指定读取的 hudi 表路径
.createTempView("mycall") // 注册为 spark 临时表
spark.sql("select * from mycall where `_hoodie_commit_time`>'20210308211131'") // 开始查询，和 hive 增量查询语句一样
.show(100, false)
```

- 读优化视图：cow 表读优化视图等同于实时视图。

12.3.3.3 mor 表视图读取

mor 表同步给 Hive 后，会在 Hive 表中同步出：“表名+后缀_rt”和“表名+后缀_ro”两张表。其中后缀为 rt 表代表实时视图，后缀为 ro 的表代表读优化视图。例如：同步给 Hive 的 hudi 表名为**${table_name}**， 同步 Hive 后 hive 表*${table_name}*张表分别为**${table_name}_rt**,和**${table_name}_ro**。

- 实时视图读取（Hive，SparkSQL 为例）：直接读取 Hive 里面存储的后缀为_rt 的 hudi 表即可。

```
select count(*) from ${table_name}_rt;
```

- 实时视图读取（Spark dataSource API 为例）：和 cow 表一样，请参考 cow 表相关操作。
- 增量视图读取（hive 为例）：

```
set hive.input.format=org.apache.hudi.hadoop.hive.HoodieCombineHiveInputFormat;
// sparksql 不需要指定
set hoodie.${table_name}.consume.mode=INCREMENTAL;
set hoodie.${table_name}.consume.max.commits=3;
set hoodie.${table_name}.consume.start.timestamp=20201227153030;
select count(*) from default.${table_name}_rt where
`_hoodie_commit_time`>'20201227153030';
```

- 增量视图读取（SparkSQL 为例）：

```
set hoodie.${table_name}.consume.mode=INCREMENTAL;
set hoodie.${table_name}.consume.start.timestamp=20201227153030; // 指定初始增量拉取 commit
set hoodie.${table_name}.consume.end.timestamp=20210308212318; // 指定增量拉取结束 commit，如果不指定的话采用最新的 commit
select count(*) from default.${table_name}_rt where
`_hoodie_commit_time`>'20201227153030';
```

- 增量视图（Spark dataSource API 为例）：和 cow 表一样，请参考 cow 表相关操作。
- 读优化视图读取（Hive，SparkSQL 为例）：直接读取 Hive 里面存储的后缀为_ro 的 hudi 表即可。

```
select count(*) from ${table_name}_ro;
```

- 读优化视图读取（Spark dataSource API 为例）：和读普通的 dataSource 表类似。

  必须指定查询类型 QUERY_TYPE_OPT_KEY 为 QUERY_TYPE_READ_OPTIMIZED_OPT_VAL

```
spark.read.format("hudi")
.option(QUERY_TYPE_OPT_KEY, QUERY_TYPE_READ_OPTIMIZED_OPT_VAL) // 指定查询类型为读优化视图
.load("/tmp/default/mor_bugx/") // 指定读取的 hudi 表路径
.createTempView("mycall")
spark.sql("select * from mycall").show(100)
```

12.3.4 数据管理维护

12.3.4.1 Clustering

什么是 Clustering

即数据布局，该服务可重新组织数据以提高查询性能，也不会影响摄取速度。

Clustering 架构

Hudi 通过其写入客户端 API 提供了不同的操作，如 insert/upsert/bulk_insert 来将数据写入 Hudi 表。为了能够在文件大小和入湖速度之间进行权衡，Hudi 提供了一个 hoodie.parquet.small.file.limit 配置来设置最小文件大小。用户可以将该配置设置为“0”，以强制新数据写入新的文件组，或设置为更高的值以确保新数据被“填充”到现有小的文件组中，直到达到指定大小为止，但其会增加摄取延迟。

为能够支持快速摄取的同时不影响查询性能，引入了 Clustering 服务来重写数据以优化 Hudi 数据湖文件的布局。

Clustering 服务可以异步或同步运行，Clustering 会添加了一种新的 REPLACE 操作类型，该操作类型将在 Hudi 元数据时间轴中标记 Clustering 操作。

Clustering 服务基于 Hudi 的 MVCC 设计，允许继续插入新数据，而 Clustering 操作在后台运行以重新格式化数据布局，从而确保并发读写者之间的快照隔离。

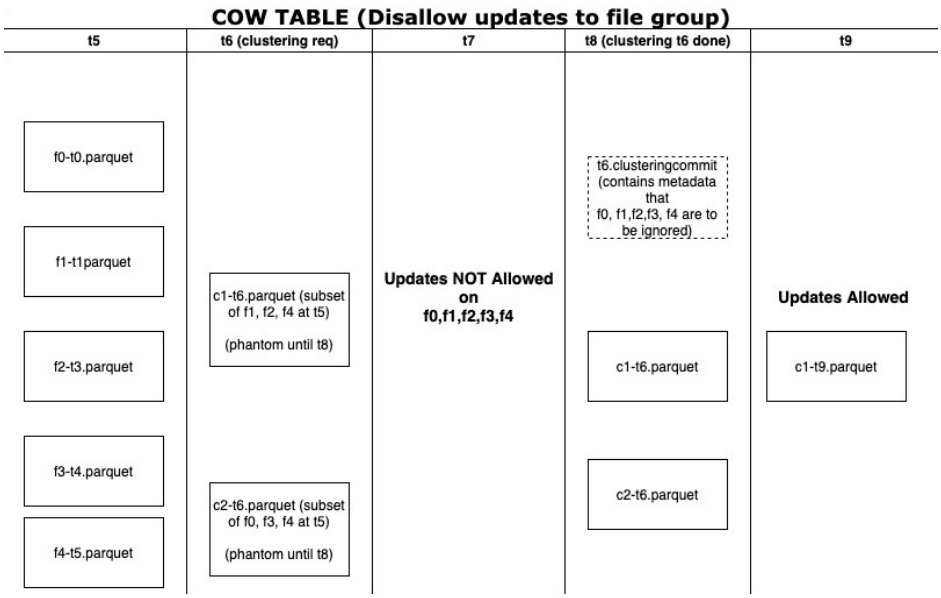

总体而言 Clustering 分为两个部分：

- 调度 Clustering：使用可插拔的 Clustering 策略创建 Clustering 计划。

a. 识别符合 Clustering 条件的文件：根据所选的 Clustering 策略，调度逻辑将识别符合 Clustering 条件的文件。

b. 根据特定条件对符合 Clustering 条件的文件进行分组。每个组的数据大小应为 targetFileSize 的倍数。分组是计划中定义的"策略"的一部分。此外还有一个选项可以限制组大小，以改善并行性并避免混排大量数据。

c. 将 Clustering 计划以 avro 元数据格式保存到时间线。

- 执行 Clustering：使用执行策略处理计划以创建新文件并替换旧文件。

  a. 读取 Clustering 计划，并获得 ClusteringGroups，其标记了需要进行 Clustering 的文件组。

  b. 对于每个组使用 strategyParams 实例化适当的策略类（例如：sortColumns），然后应用该策略重写数据。

  c. 创建一个 REPLACE 提交，并更新 HoodieReplaceCommitMetadata 中的元数据。

如何执行 Clustering

1. 同步执行 Clustering 配置。

   在写入时加上配置参数：

   option("hoodie.clustering.inline", "true").

   option("hoodie.clustering.inline.max.commits", "4").

   option("hoodie.clustering.plan.strategy.target.file.max.bytes", "1073741824").

   option("hoodie.clustering.plan.strategy.small.file.limit", "629145600").

   option("hoodie.clustering.plan.strategy.sort.columns", "column1,column2").

2. 异步执行 Clustering：

   MRS 3.2.0 及之后版本：

   通过 spark-sql 命令来执行 clustering，具体可以参考 12.4.4.7 CLUSTERING 章节。

   MRS 3.1.2 版本：

   spark-submit --master yarn --class org.apache.hudi.utilities.HoodieClusteringJob /opt/client/Hudi/hudi/lib/hudi-utilities*.jar --schedule --base-path <table_path> --table-name <table_name> --props /tmp/clusteringjob.properties --spark-memory 1g

   spark-submit --master yarn --driver-memory 16G --executor-memory 12G --executor-cores 4 --num-executors 4 --class org.apache.hudi.utilities.HoodieClusteringJob /opt/client/Hudi/hudi/lib/hudi-utilities*.jar --base-path <table_path> --instant-time 20210605112954 --table-name <table_name> --props /tmp/clusteringjob.properties --spark-memory 12g

3. 指定 clustering 的排序方式和排序列：

   当前 clustering 支持 linear、z-order、hilbert 三种排序方式，可以通过 option 方式或者 set 方式来设置。

   - linear：普通排序，默认排序，适合排序一个字段， 或者多个低级字段。
   - z-order 和 hilbert：多维排序，需要指定“hoodie.layout.optimize.strategy”为 z-order 或者 hilbert。

     适合排序多个字段，例如查询条件中涉及到多个字段。推荐排序字段的个数 2 到 4 个。

     hilbert 多维排序效果比 z-order 好，但是排序效率没 z-order 高。

详细配置请参考 12.2 Hudi 常用参数。

⚠ 注意

1. Clustering 的排序列不允许值存在 null，是 spark rdd 的限制。
2. 当 target.file.max.bytes 的值较大时，启动 Clustering 执行需要提高--spark-memory，否则会导致 executor 内存溢出。
3. 当前 clean 不支持清理 Clustering 失败后的垃圾文件。
4. Clustering 后可能出现新文件大小不等引起数据倾斜的情况。
5. cluster 不支持和 upsert 并发。
6. 如果 clustering 处于 inflight 状态，该 FileGroup 下的文件不支持 Update 操作。
7. 如果存在未完成的 Clustering 计划，后续写入触发生成 compaction 调度计划时会报错失败，需要及时执行 Clustering 计划。

12.3.4.2 Cleaning

Cleaning 用于清理不再需要的版本数据。

Hudi 使用 Cleaner 后台作业，不断清除不需要的旧得版本的数据。通过配置 hoodie.cleaner.policy 和 hoodie.cleaner.commits.retained 可以使用不同的清理策略和保存的 commit 数量。

执行 cleaning 有两种方式：

- 同步 clean 由参数 hoodie.clean.automatic 控制，默认自动开启。

  关闭同步 clean：

  datasource 写入时可以通过**.option("hoodie.clean.automatic", "false")**来关闭自动 clean。

  spark-sql 写入时可以通过 **set hoodie.clean.automatic=false;**来关闭自动 clean。
- 异步 clean 可以使用 spark-sql 来执行，详情可以参考章节 12.4.3.8 CLEAN。

更多 clean 相关参数请参考 compaction&cleaning 配置章节。

12.3.4.3 Compaction

Compaction 用于合并 mor 表 Base 和 Log 文件。

对于 Merge-On-Read 表，数据使用列式 Parquet 文件和行式 Avro 文件存储，更新被记录到增量文件，然后进行同步/异步 compaction 生成新版本的列式文件。Merge-On-Read 表可减少数据摄入延迟，因而进行不阻塞摄入的异步 Compaction 很有意义。

- 异步 Compaction 会进行如下两个步骤：
  a. 调度 Compaction：由入湖作业完成，在这一步，Hudi 扫描分区并选出待进行 compaction 的 FileSlice，最后 CompactionPlan 会写入 Hudi 的 Timeline。
  b. 执行 Compaction：一个单独的进程/线程将读取 CompactionPlan 并对 FileSlice 执行 Compaction 操作。
- 使用 Compaction 的方式分为同步和异步两种：

- 同步方式由参数 hoodie.compact.inline 控制，默认为 true，自动生成 compaction 调度计划并执行 compaction：
  - 关闭同步 compaction

    datasource 写入时可以通过 **.option("hoodie.compact.inline", "false")** 来关闭自动 compaction。

    spark-sql 写入时可以通过 **set hoodie.compact.inline=false;**来关闭自动 compaction。
  - 仅同步生成 compaction 调度而不执行 compaction
    - ·datasource 写入时可以通过以下 option 参数来实现：

      option("hoodie.compact.inline", "true").

      option("hoodie.schedule.compact.only.inline", "true").

      option("hoodie.run.compact.only.inline", "false").
    - ·spark-sql 写入时可以通过 set 以下参数来实现：

      set hoodie.compact.inline=true;

      set hoodie.schedule.compact.only.inline=true;

      set hoodie.run.compact.only.inline=false;
- 异步方式由 spark-sql 来实现。

  如果需要在异步 compaction 时只执行已经产生的 compaction 调度计划而不创建新的调度计划，则需要通过 set 命令设置以下参数：

  set hoodie.compact.inline=true;

  set hoodie.schedule.compact.only.inline=false;

  set hoodie.run.compact.only.inline=true;

  更多 compaction 参数请参考 compaction&cleaning 配置章节。

说明

为了保证入湖的最高效率，推荐使用同步产生 compaction 调度计划，异步执行 compaction 调度计划的方式。

12.3.4.4 Savepoint

Savepoint 用于保存并还原自定义的版本数据。

Hudi 提供的 savepoint 就可以将不同的 commit 保存起来以便清理程序不会将其删除，后续可以使用 Rollback 进行恢复。

使用 spark-sql 管理 savepoint。

示例如下：

- 创建 savepoint

```
call create_savepoints('hudi_test1', '20220908155421949');
```

- 查看所有存在的 savepoint

```
call show_savepoints(table =>'hudi_test1');
```

- 回滚 savepoint

```
call rollback_savepoints('hudi_test1', '20220908155421949');
```

说明

savepoint 的 rollback 与 commit rollback 相同，都必须从最新的 instant 逐个向前 rollback。

MRS 3.1.2 版本：MoR 表暂时不支持 savepoint。

12.3.4.5 单表并发控制

默认情况下 Hudi 不支持单表并发写和 Compaction 操作，在使用 Flink、Spark 引擎进行数据写入以及使用 Spark 引擎进行 Compaction 操作时，会先尝试获取锁对应的锁（集群内 Zookeeper 提供分布式锁服务，并自动配置生效），如果获取失败则任务直接退出，以防止所任务并发操作表时导致表损坏。如果开启 Hudi 单表并发写功能，则上述功能自动失效。

Hudi 单表并发写实现方案

1. 使用外部服务（Zookeeper/Hive MetaStore）作为分布式互斥锁服务。
2. 允许并发写入文件，但是不允许并发提交 commit，提交 commit 操作封装到事务中。
3. 提交 commit 时，执行冲突检查：若本次提交的 commit 中，修改的文件列表，与本次 instanceTime 之后的 commit 存在重叠文件，则提交失败，本次写入无效。

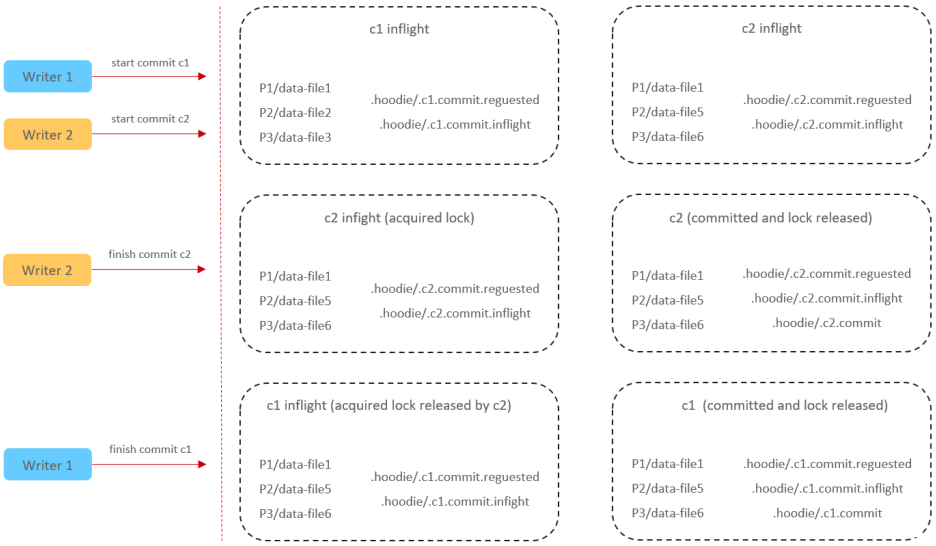

使用并发机制需要注意问题

1. Hudi 当前并发机制无法保证写入后表主键唯一， 这个需要用户自己来保证。
2. 增量查询问题：数据消费以及 Checkpoint 可能会乱序，多个并发写操作在不同的时间点完成。
3. 并发写需要在启用并发写特性后支持并发，未开启时不支持并发写入。

如何使用并发机制

1. 启用并发写入机制。

   hoodie.write.concurrency.mode=optimistic_concurrency_control

   hoodie.cleaner.policy.failed.writes=LAZY
2. 设置并发锁方式。

Hive MetaStore：

hoodie.write.lock.provider=org.apache.hudi.hive.HiveMetastoreBasedLockProvider

hoodie.write.lock.hivemetastore.database=<*database_name*>

hoodie.write.lock.hivemetastore.table=<*table_name*>

Zookeeper：

hoodie.write.lock.provider=org.apache.hudi.client.transaction.lock.ZookeeperBasedLockProvider

hoodie.write.lock.zookeeper.url=<*zookeeper_url*>

hoodie.write.lock.zookeeper.port=<*zookeeper_port*>

hoodie.write.lock.zookeeper.lock_key=<*table_name*>

hoodie.write.lock.zookeeper.base_path=<*table_path*>

更多配置参数请参考 12.2 Hudi 常用参数。

⚠ 注意

当设置 cleaner policy 为 Lazy 时，本次写入仅能关注到自己写入的文件是否过期，不能检查并清理历史写入产生的垃圾文件，即在并发场景下，无法自动清理垃圾文件。

12.3.4.6 分区并发控制

说明

本章节内容仅使用于 MRS 3.3.0-LTS 及之后版本。

分区并发写每个任务基于对当前存在 inflight 状态的 commit 中存储的修改分区信息来判断是否存在写冲突，从而实现并发写入。

并发过程中的锁控制基于 ZK 锁实现，无需用户配置额外参数。

注意事项

分区并发写控制基于单表并发写控制的基础上实现，因此使用约束条件与单表并控制写基本相同。

当前分去并发只支持 Spark 方式写入，Flink 不支持该特性。

为避免过大并发量占用 ZooKeeper 过多资源，对 Hudi 在 ZooKeeper 上增加了 Quota 配额限制，可以通过服务端修改 Spark 组件中参数 zk.quota.number 来调整 Hudi 的 Quota 配额，默认为 500000，最小为 5，且不可通过此参数来控制并行任务数，仅用来控制对 ZooKeeper 的访问压力。

使用分区并发机制

通过设置参数：hoodie.support.partition.lock=true 来启动分区并发写。

示例：

spark datasource 方式开启分区并发写：

```
upsert_data.write.format("hudi").
option("hoodie.datasource.write.table.type", "COPY_ON_WRITE").
option("hoodie.datasource.write.precombine.field", "col2").
option("hoodie.datasource.write.recordkey.field", "primary_key").
option("hoodie.datasource.write.partitionpath.field", "col0").
option("hoodie.upsert.shuffle.parallelism", 4).
option("hoodie.datasource.write.hive_style_partitioning", "true").
option("hoodie.support.partition.lock", "true").
option("hoodie.table.name", "tb_test_cow").
mode("Append").save(s"/tmp/huditest/tb_test_cow")
```

spark-sql 开启分区并发写：

```
set hoodie.support.partition.lock=true;
insert into hudi_table1 select 1,1,1;
```

12.3.4.7 历史数据清理

说明

本章节仅适用于 MRS 3.3.0-LTS 及之后版本

操作场景

随着时间的推移，Hudi 表中的数据越来越多，表中的老数据价值逐渐变弱并且还会占用存储空间，对这些老数据 Hudi 需要支持删除操作以便节约存储成本。

delete/drop partition 语句直接删除历史数据

delete/drop partition 命令可以用来清理历史数据，具体可以参考 12.4 Hudi SQL 语法参考相关内容。

优点：操作简单，支持 cow 表和 mor 表。

缺点：并发能力不足。 当 Hudi 表处于实时写入状态，并发执行 **delete/drop partition** 命令容易导致实时入库作业失败。

call clean_data 命令删除历史数据

- 命令功能

  call clean_data 的功能是用来删除 mor 表的历史数据。

  优点：可以和入库任务并发执行，不会影响实时入库数据。

  缺点：只支持 mor 表，并且是惰性删除，依赖于 compaction。

- 命令格式

  call clean_data(table => 'table_name', sql => 'delete statement')

- 参数描述

表12-11 参数描述

参数	描述
table_name	待删除数据的表名，支持 database.tablename 格式

参数	描述
delete statement	select 类型的 sql 语句，用于找出待删除的数据

- 示例

  从 mytable 表中删除 primaryKey < 100 的所有数据：

  ```
  call clean_data(table => 'mytable', sql=>'select *  from mytable where primaryKey < 100')
  ```

  清理上次 clean_data 命令残留文件；cleanData 执行失败会产生临时文件，该命令可以清理这些临时文件：

  ```
  call clean_data(table => 'mytable', sql=>'delete cleanData')
  ```

- 系统响应

  可在客户端中查看查询结果。

12.3.5 使用 Hudi Payload

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

Payload 介绍

Payload 是 Hudi 实现数据增量更新和删除的关键，它可以帮助 Hudi 在数据湖中高效的管理数据变更。Hudi Payload 的格式是基于 Apache Avro 的，它使用了 Avro 的 schema 来定义数据的结构和类型。Payload 可以被序列化和反序列化，以便在 Hudi 中进行数据的读取和写入。总之，Hudi Payload 是 Hudi 的一个重要组成部分，它提供了一种可靠的、高效的、可扩展的方式来管理大规模数据湖中的数据变更。

常用 Payload

- DefaultHoodieRecordPayload

  Hudi 中默认使用 DefaultHoodieRecordPayload，该 Payload 通过比较增量数据与存量数据的 preCombineField 字段值的大小来决定同主键的存量数据是否能被同主键的增量数据更新。在同主键的增量数据的 preCombineField 字段值绝对大于同主键的存量数据的 preCombineField 字段值时，同主键的增量数据将会被更新。

- OverwriteWithLatestAvroPayload

  该 Payload 保证同主键的增量数据永远都会更新同主键的增量数据。

- PartialUpdateAvroPayload

  该 Payload 继承了 OverwriteNonDefaultsWithLatestAvroPayload，它可以保证在任何场景下增量数据中的 null 值不会覆盖存量数据。

使用 Payload

- Spark 建表时指定 Payload

  ```
  create table hudi_test(id int, comb int, price string, name string, par string)
  using hudi options(
  primaryKey = "id",
  ```

```
preCombineField = "comb",
payloadClass="org.apache.hudi.common.model.OverwriteWithLatestAvroPayload")
partitioned by (par);
```

- Datasource 方式写入时指定 Payload

```
data.write.format("hudi").
option("hoodie.datasource.write.table.type", COW_TABLE_TYPE_OPT_VAL).
option("hoodie.datasource.write.precombine.field", "comb").
option("hoodie.datasource.write.recordkey.field", "id").
option("hoodie.datasource.write.partitionpath.field", "par").
option("hoodie.datasource.write.payload.class",
"org.apache.hudi.common.model.DefaultHoodieRecordPayload").
option("hoodie.datasource.write.keygenerator.class",
"org.apache.hudi.keygen.SimpleKeyGenerator").
option("hoodie.datasource.write.operation", "upsert").
option("hoodie.datasource.hive_sync.enable", "true").
option("hoodie.datasource.hive_sync.partition_fields", "par").
option("hoodie.datasource.hive_sync.partition_extractor_class",
"org.apache.hudi.hive.MultiPartKeysValueExtractor").
option("hoodie.datasource.hive_sync.table", "hudi_test").
option("hoodie.datasource.hive_sync.use_jdbc", "false").
option("hoodie.upsert.shuffle.parallelism", 4).
option("hoodie.datasource.write.hive_style_partitioning", "true").
option("hoodie.table.name", "hudi_test").mode(Append).save(s"/tmp/hudi_test")
```

12.3.6 Hudi 客户端使用

12.3.6.1 使用 Hudi-Cli.sh 操作 Hudi 表

前提条件

- 对于开启了 Kerberos 认证的安全模式集群，已在集群 FusionInsight Manager 界面创建一个用户并关联“hadoop”和“hive”用户组。
- 已下载并安装 Hudi 集群客户端。

基础操作

1. 使用 **root** 用户登录集群客户端节点，执行如下命令：

   cd *{客户端安装目录}*

   source bigdata_env

   source Hudi/component_env

   kinit *创建的用户*

2. 执行 **hudi-cli.sh** 进入 Hudi 客户端，

   cd *{客户端安装目录}***/Hudi/hudi/bin/**

   ./hudi-cli.sh

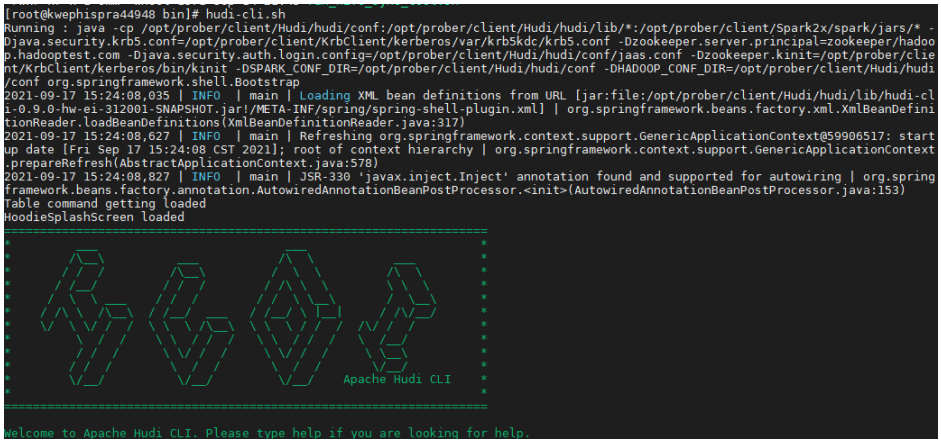

3. 即可执行各种 Hudi 命令，执行示例：
   - 查看帮助：

     help //查看 hudi-cli 的所有命令

     help '*command***'** //查看某一个命令的帮助及参数列表。
   - 连接表：

     connect --path '*/tmp/huditest/test_table***'**
   - 查看表信息：

     desc
   - 查看 compaction 计划：

     compactions show all
   - 查看 clean 计划：

     cleans show
   - 执行 clean：

     cleans run
   - 查看 commit 信息：

     commits show
   - 查看 commit 写入的分区：

     commit showpartitions --commit *20210127153356*

说明

20210127153356 表示 commit 的时间戳，下同。

   - 查看指定 commit 写入的文件：

     commit showfiles --commit *20210127153356*
   - 比较两个表的 commit 信息差异：

     commits compare --path */tmp/hudimor/mytest100*
   - rollback 指定提交（rollback 每次只允许 rollback 最后一次 commit）：

     commit rollback --commit *20210127164905*
   - compaction 调度：

     compaction schedule --*hoodieConfigs*
     'hoodie.compaction.strategy=org.apache.hudi.table.action.compact.strategy.Bound

edIOCompactionStrategy,hoodie.compaction.target.io=1,hoodie.compact.inline.max.delta.commits=1'

- 执行 compaction

  compaction run --*parallelism 100 --sparkMemory 1g --retry 1 --compactionInstant 20210602101315 --hoodieConfigs 'hoodie.compaction.strategy=org.apache.hudi.table.action.compact.strategy.BoundedIOCompactionStrategy,hoodie.compaction.target.io=1,hoodie.compact.inline.max.delta.commits=1' --propsFilePath hdfs://hacluster/tmp/default/tb_test_mor/.hoodie/hoodie.properties --schemaFilePath /tmp/default/tb_test_mor/.hoodie/compact_tb_base.json*

- 创建 savepoint

  savepoint create --commit *20210318155750*

- 回滚指定的 savepoint

  savepoint rollback --savepoint *20210318155750*

⚠ 注意

1. 若 commit 写入导致元数据冲突异常，执行 commit rollback、savepoint rollback 能回退数据，但不能回退 Hive 元数据，只能删除 Hive 表然后手动进行同步刷新。
2. commit rollback 只能回退当前最新的一个 commit，savepoint rollback 只能回退到最新的一个 savepoint。二者均不能随意指定进行回退。

12.4 Hudi SQL 语法参考

12.4.1 使用约束

Hudi 支持使用 Spark SQL 操作 Hudi 的 DDL/DML 的语法，使得所有用户（非工程师、分析师等）更容易访问和操作 Hudi。

约束

- 支持在 Hudi 客户端执行 Spark SQL 操作 Hudi。
- 支持在 Spark2x 的 JDBCServer 中执行 Spark SQL 操作 Hudi。
- 不支持在 Spark2x 的客户端执行 Spark SQL 操作 Hudi，支持在 Spark3.1.1 及之后版本的客户端执行 Spark SQL 操作 Hudi。
- 不支持在 Hive、Hetu 引擎中写 hudi 表，以及修改 hudi 表结构，仅支持读。
- 由于 SQL 的 KeyGenerator 默认是 org.apache.hudi.keygen.ComplexKeyGenerator，要求 DataSource 方式写入时 KeyGenerator 与 SQL 设置的一致。

12.4.2 DDL

12.4.2.1 CREATE TABLE

命令功能

CREATE TABLE 命令通过指定带有表属性的字段列表来创建 Hudi Table。

命令格式

CREATE TABLE *[IF NOT EXISTS] [database_name.]table_name*

[(columnTypeList)]

USING hudi

[COMMENT table_comment]

[LOCATION location_path]

[OPTIONS (options_list)]

参数描述

表12-12 CREATE TABLE 参数描述

参数	描述
database_name	Database 名称，由字母、数字和下划线（_）组成。
table_name	Database 中的表名，由字母、数字和下划线（_）组成。
columnTypeList	以逗号分隔的带数据类型的列表。列名由字母、数字和下划线（_）组成。
using	参数 hudi，定义和创建 Hudi table。
table_comment	表的描述信息。
location_path	HDFS 路径，指定该路径 Hudi 表会创建为外表。
options_list	Hudi table 属性列表。

表12-13 CREATE TABLE Options 描述

参数	描述
primaryKey	主键名，多个字段用逗号分隔，该字段为必填字段。
type	表类型。'cow' 表示 COPY-ON-WRITE 表，'mor' 表示 MERGE-ON-READ 表。未指定 type 的话，默认值为 'cow'。

参数	描述
preCombineField	表的 Pre-Combine 字段。
payloadClass	使用 preCombineField 字段进行数据过滤的逻辑，默认使用 DefaultHoodieRecordPayload，同时也提供了多种预置 Payload 供用户使用，如 OverwriteNonDefaultsWithLatestAvroPayload、OverwriteWithLatestAvroPayload 及 EmptyHoodieRecordPayload。
useCache	是否在 Spark 中缓存表的 relation，无需用户配置。为支持 SparkSQL 中对 COW 表增量视图查询，默认将 COW 表中该值置为 false。

示例

- **创建非分区表**

```
-- 创建一个 cow 内部表
create table if not exists hudi_table0 (
id int,
name string,
price double
) using hudi
options (
type = 'cow',
primaryKey = 'id'
);
-- 创建一个 mor 外部表
create table if not exists hudi_table1 (
id int,
name string,
price double,
ts bigint
) using hudi
location '/tmp/hudi/hudi_table1'
options (
type = 'mor',
primaryKey = 'id,name',
preCombineField = 'ts'
);
```

- **创建分区表**

```
create table if not exists hudi_table_p0 (
id bigint,
name string,
ts bigint,
dt string,
hh string
) using hudi
location '/tmp/hudi/hudi_table_p0'
options (
```

```
type = 'cow',
primaryKey = 'id',
preCombineField = 'ts'
)
partitioned by (dt, hh);
```

- **以 SQL 方式创建一个 hudi 表的外表，与 spark-shell or deltastreamer 方式创建的 hudi 外表相同**

```
create table h_p1
using hudi
options (
primaryKey = 'id',
preCombineField = 'ts'
)
partitioned by (dt)
location '/path/to/hudi';
```

- **创建表指定表属性**

```
create table if not exists h3(
id bigint,
name string,
price double
) using hudi
options (
primaryKey = 'id',
type = 'mor',
hoodie.cleaner.fileversions.retained = '20',
hoodie.keep.max.commits = '20'
);
```

注意事项

- Hudi 当前不支持使用 char、varchar、tinyint、smallint 类型，建议使用 string 或 int 类型。
- Hudi 当前只有 int、bigint、float、double、decimal、string、date、timestamp、boolean、binary 类型支持设置默认值。
- Hudi 表必须指定 primaryKey 与 preCombineField。
- 在指定路径下创建表时，如果路径下已存在 Hudi 表，则建表时不需要指定列。

系统响应

Table 创建成功，创建成功的消息将被记录在系统日志中。

12.4.2.2 CREATE TABLE AS SELECT

命令功能

CREATE TABLE As SELECT 命令通过指定带有表属性的字段列表来创建 Hudi Table。

命令格式

CREATE TABLE *[IF NOT EXISTS] [database_name.]table_name*

USING hudi

[COMMENT table_comment]

[LOCATION location_path]

[OPTIONS (options_list)]

[AS query_statement]

参数描述

表12-14 CREATE TABLE As SELECT 参数描述

参数	描述
database_name	Database 名称，由字母、数字和下划线（_）组成。
table_name	Database 中的表名，由字母、数字和下划线（_）组成。
using	参数 hudi，定义和创建 Hudi table。
table_comment	表的描述信息。
location_path	HDFS 路径，指定该路径 Hudi 表会创建为外表。
options_list	Hudi table 属性列表。
query_statement	select 查询表达式

示例

- 创建分区表

```
create table h2 using hudi
options (type = 'cow', primaryKey = 'id')
partitioned by (dt)
as
select 1 as id, 'a1' as name, 10 as price, 1000 as dt;
```

- 创建非分区表

```
create table h3 using hudi
as
select 1 as id, 'a1' as name, 10 as price;

从 parquet 表加载数据到 hudi 表
# 创建 parquet 表
create table parquet_mngd using parquet
options(path='hdfs:///tmp/parquet_dataset/*.parquet');

# CTAS 创建 hudi 表
create table hudi_tbl using hudi location 'hdfs:///tmp/hudi/hudi_tbl/' options
(
```

```
type = 'cow',
primaryKey = 'id',
preCombineField = 'ts'
)
partitioned by (datestr) as select * from parquet_mngd;
```

注意事项

为了更好的加载数据性能，CTAS 使用 bulk insert 作为写入方式。

系统响应

Table 创建成功，创建成功的消息将被记录在系统日志中。

12.4.2.3 DROP TABLE

命令功能

DROP TABLE 的功能是用来删除已存在的 Table。

命令格式

DROP TABLE *[IF EXISTS] [db_name.]table_name;*

参数描述

表12-15 DROP TABLE 参数描述

参数	描述
db_name	Database 名称。如果未指定，将选择当前 database。
table_name	需要删除的 Table 名称。

注意事项

在该命令中，IF EXISTS 和 db_name 是可选配置。

示例

DROP TABLE IF EXISTS hudidb.h1;

系统响应

Table 将被删除。

12.4.2.4 SHOW TABLE

命令功能

SHOW TABLES 命令用于显示所有在当前 database 中的 table，或所有指定 database 的 table。

命令格式

SHOW TABLES *[IN db_name];*

参数描述

表12-16 SHOW TABLES 参数描述

参数	描述
IN db_name	Database 名称，仅当需要显示指定 Database 的所有 Table 时配置。

注意事项

IN db_Name 为可选配置。

示例

```
SHOW TABLES IN hudidb;
```

系统响应

显示所有 Table。

12.4.2.5 ALTER RENAME TABLE

命令功能

RENAME 命令用于重命名现有表。

命令语法

ALTER TABLE *oldTableName* **RENAME TO** *newTableName*

参数描述

表12-17 RENAME 参数描述

参数	描述

参数	描述
oldTableName	现有表名。
new_table_name	现有表名的新表名。

示例

```
alter table h0 rename to h0_1;
```

系统响应

可以通过运行 SHOW TABLES 显示新表名称。

12.4.2.6 ALTER ADD COLUMNS

命令功能

ADD COLUMNS 命令用于为现有表添加新列。

命令语法

ALTER TABLE *tableIdentifier* **ADD COLUMNS***(colAndType (,colAndType)*)*

参数描述

表12-18 ADD COLUMNS 参数描述

参数	描述
tableIdentifier	表名。
colAndType	带数据类型且用逗号分隔的列的名称。列名称包含字母，数字和下划线（_）。

示例

```
alter table h0_1 add columns(ext0 string);
```

系统响应

通过运行 DESCRIBE 命令，可显示新添加的列。

12.4.2.7 ALTER ALTER COLUMN

说明

本章节内容仅使用于 MRS 3.3.0 及之后版本。

命令功能

ALTER COLUMN 命令用于修改列的默认值。

命令语法

ALTER TABLE *tableIdentifier* **ALTER COLUMN** *colName* **SET DEFAULT** *defaultValue*

参数描述

表12-19 ADD COLUMNS 参数描述

参数	描述
tableIdentifier	表名
colName	列名
defaultValue	列默认值

示例

```
alter table h0_1 alter column set extl default 'new_default_value';
```

系统响应

可在客户端中查看查询结果。

12.4.2.8 TRUNCATE TABLE

命令功能

该命令将会把表中的数据清空。

命令语法

TRUNCATE TABLE *tableIdentifier*

参数描述

表12-20 **TRUNCATE TABLE** 参数描述

参数	描述
tableIdentifier	表名。

示例

```
truncate table h0_1;
```

系统响应

通过运行 QUERY 语句查看表中数据已被删除。

12.4.3 DML

12.4.3.1 INSERT INTO

命令功能

INSERT 命令用于将 SELECT 查询结果加载到 Hudi 表中。

命令格式

INSERT INTO *tableIndentifier select query;*

参数描述

表12-21 INSERT INTO 参数

参数	描述
tableIndentifier	需要执行 INSERT 命令的 Hudi 表的名称。
select query	查询语句。

注意事项

- Insert 模式：Hudi 对于设置了主键的表支持三种 Insert 模式，用户可以设置参数 hoodie.sql.insert.mode 来指定 Insert 模式，默认为 upsert。
  - strict 模式，Insert 语句将保留 COW 表的主键唯一性约束，不允许重复记录。如果在插入过程中已经存在记录，则会为 COW 表抛出 HoodieDuplicateKeyException；对于 MOR 表，该模式与 upsert 模式行为一致。
  - non-strict 模式，对主键表采用 insert 处理。
  - upsert 模式，对于主键表的重复值进行更新操作。
- 在执行 spark-sql 时，用户可以设置“hoodie.sql.bulk.insert.enable = true”和“hoodie.sql.insert.mode = non-strict”来开启 bulk insert 作为 Insert 语句的写入方式。

  也可以通过直接设置 hoodie.datasource.write.operation 的方式控制 insert 语句的写入方式，包括 bulk_insert、insert、upsert。使用这种方式控制 hoodie 写入，需要注意执行完 SQL 后，必须执行 **reset hoodie.datasource.write.operation;**重置 Hudi 的写入方式，否则该参数会影响其他 SQL 的执行。

示例

```
insert into h0 select 1, 'a1', 20;

-- insert static partition
insert into h_p0 partition(dt = '2021-01-02') select 1, 'a1';

-- insert dynamic partition
insert into h_p0 select 1, 'a1', dt;

-- insert dynamic partition
insert into h_p1 select 1 as id, 'a1', '2021-01-03' as dt, '19' as hh;

-- insert overwrite table
insert overwrite table h0 select 1, 'a1', 20;

-- insert overwrite table with static partition
insert overwrite h_p0 partition(dt = '2021-01-02') select 1, 'a1';

-- insert overwrite table with dynamic partition
insert overwrite table h_p1 select 2 as id, 'a2', '2021-01-03' as dt, '19' as hh;
```

系统响应

可在 driver 日志中查看命令运行成功或失败。

12.4.3.2 MERGE INTO

命令功能

通过 MERGE INTO 命令，根据一张表或子查询的连接条件对另外一张表进行查询，连接条件匹配上的进行 UPDATE 或 DELETE，无法匹配的执行 INSERT。这个语法仅需要一次全表扫描就完成了全部同步工作，执行效率要高于 INSERT＋UPDATE。

命令格式

MERGE INTO *tableIdentifier AS target_alias*

USING *(sub_query | tableIdentifier) AS source_alias*

ON *<merge_condition>*

[WHEN MATCHED [AND <condition>] THEN <matched_action>]

[WHEN MATCHED [AND <condition>] THEN <matched_action>]

[WHEN NOT MATCHED [AND <condition>] THEN <not_matched_action>]

<merge_condition> =A equal bool condition

<matched_action> =

DELETE |

*UPDATE SET * |*

UPDATE SET column1 = expression1 [, column2 = expression2 ...]

<not_matched_action> =

*INSERT ** |

INSERT (column1 [, column2 ...]) VALUES (value1 [, value2 ...])

参数描述

表12-22 UPDATE 参数

参数	描述
tableIdentifier	在其中执行 MergeInto 操作的 Hudi 表的名称。
target_alias	目标表的别名。
sub_query	子查询。
source_alias	源表或源表达式的别名。
merge_condition	将源表或表达式和目标表关联起来的条件
condition	过滤条件，可选。
matched_action	当满足条件时进行 Delete 或 Update 操作
not_matched_action	当不满足条件时进行 Insert 操作

注意事项

1. merge-on condition 当前只支持主键列。
2. 当前仅支持对 COW 表进行部分字段更新，且更新值必须包含预合并列，MOR 表需要在 Update 语法中给出全部字段。

示例

- 部分字段更新

```
create table h0(id int, comb int, name string, price int) using hudi
options(primaryKey = 'id', preCombineField = 'comb');
create table s0(id int, comb int, name string, price int) using hudi
options(primaryKey = 'id', preCombineField = 'comb');
insert into h0 values(1, 1, 1, 1);
insert into s0 values(1, 1, 1, 1);
insert into s0 values(2, 2, 2, 2);
//写法 1
merge into h0 using s0
on h0.id = s0.id
when matched then update set h0.id = s0.id, h0.comb = s0.comb, price = s0.price
* 2;
//写法 2
merge into h0 using s0
on h0.id = s0.id
when matched then update set id = s0.id,
```

```
name = h0.name,
comb = s0.comb + h0.comb,
price = s0.price + h0.price;
```

- 缺省字段更新和插入

```
create table h0(id int, comb int, name string, price int, flag boolean) using
hudi options(primaryKey = 'id', preCombineField = 'comb');
create table s0(id int, comb int, name string, price int, flag boolean) using
hudi options(primaryKey = 'id', preCombineField = 'comb');
insert into h0 values(1, 1, 1, 1, false);
insert into s0 values(1, 2, 1, 1, true);
insert into s0 values(2, 2, 2, 2, false);

merge into h0 as target
using (
select id, comb, name, price, flag from s0
) source
on target.id = source.id
when matched then update set *
when not matched then insert *;
```

- 多条件更新和删除

```
create table h0(id int, comb int, name string, price int, flag boolean) using
hudi options(primaryKey = 'id', preCombineField = 'comb');
create table s0(id int, comb int, name string, price int, flag boolean) using
hudi options(primaryKey = 'id', preCombineField = 'comb');
insert into h0 values(1, 1, 1, 1, false);
insert into h0 values(2, 2, 1, 1, false);
insert into s0 values(1, 1, 1, 1, true);
insert into s0 values(2, 2, 2, 2, false);
insert into s0 values(3, 3, 3, 3, false);

merge into h0
using (
select id, comb, name, price, flag from s0
) source
on h0.id = source.id
when matched and flag = false then update set id = source.id, comb = h0.comb +
source.comb, price = source.price * 2
when matched and flag = true then delete
when not matched then insert *;
```

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

12.4.3.3 UPDATE

命令功能

UPDATE 命令根据列表达式和可选的过滤条件更新 Hudi 表。

命令格式

UPDATE *tableIdentifier SET column = EXPRESSION(,column = EXPRESSION) [WHERE boolExpression]*

参数描述

表12-23 UPDATE 参数

参数	描述
tableIdentifier	在其中执行更新操作的 Hudi 表的名称。
column	待更新的目标列。
EXPRESSION	需在目标表中更新的源表列值的表达式。
boolExpression	过滤条件表达式。

示例

```
update h0 set price = price + 20 where id = 1;
update h0 set price = price *2, name = 'a2' where id = 2;
```

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

12.4.3.4 DELETE

命令功能

DELETE 命令从 Hudi 表中删除记录。

命令格式

DELETE from *tableIdentifier [WHERE boolExpression]*

参数描述

表12-24 DELETE 参数

参数	描述
tableIdentifier	在其中执行删除操作的 Hudi 表的名称。
boolExpression	删除项的过滤条件

示例

- 示例 1：

```
delete from h0 where column1 = 'country';
```

- 示例 2：

```
delete from h0 where column1 IN ('country1', 'country2');
```

- 示例 3：

```
delete from h0 where column1 IN (select column11 from sourceTable2);
```

- 示例 4：

```
delete from h0 where column1 IN (select column11 from sourceTable2 where
column1 = 'xxx');
```

- 示例 5：

```
delete from h0;
```

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

12.4.3.5 COMPACTION

命令功能

压缩(compaction)用于在 MergeOnRead 表将基于行的 log 日志文件转化为 parquet 列式数据文件，用于加快记录的查找。

命令格式

SCHEDULE COMPACTION on *tableIdentifier* |tablelocation;

SHOW COMPACTION on *tableIdentifier* |tablelocation;

RUN COMPACTION on *tableIdentifier* |tablelocation [at instant-time];

参数描述

表12-25 COMPACTION 参数

参数	描述
tableIdentifier	在其中执行删除操作的 Hudi 表的名称。
tablelocation	Hudi 表的存储路径
instant-time	执行 show compaction 命令可以看到 instant-time

示例

```
schedule compaction  on h1;
show compaction on h1;
```

```
run compaction on h1 at 20210915170758;

schedule compaction  on '/tmp/hudi/h1';
run compaction on '/tmp/hudi/h1';
```

注意事项

使用 hudi-cli 或 API 方式对 SQL 创建的 Hudi 表触发 Compaction 时需要添加参数 **hoodie.payload.ordering.field** 为 **preCombineField** 的值。

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

12.4.3.6 SET/RESET

命令功能

此命令用于动态 Add，Update，Display 或 Reset Hudi 参数，而无需重新启动 driver。

命令格式

- Add 或 Update 参数值：
  SET *parameter_name=parameter_value*
  此命令用于添加或更新“parameter_name”的值。
- Display 参数值：
  SET *parameter_name*
  此命令用于显示指定的“parameter_name”的值。
- Display 会话参数：
  SET
  此命令显示所有支持的会话参数。
- Display 会话参数以及使用细节：
  SET -v
  此命令显示所有支持的会话参数及其使用细节。
- Reset 参数值：
  RESET
  此命令清除所有会话参数。

参数描述

表12-26 SET 参数描述

参数	描述
parameter_name	其值需要被动态添加（add），更新（update）或显示（display）的参数名称。

参数	描述
parameter_value	将要设置的“parameter_name”的新值。

注意事项

以下为分别使用 SET 和 RESET 命令进行动态设置或清除操作的属性：

表12-27 属性描述

属性	描述
hoodie.insert.shuffle.parallelism	insert 方式写入数据时的 spark shuffle 并行度。
hoodie.upsert.shuffle.parallelism	upsert 方式写入数据时的 spark shuffle 并行度。
hoodie.delete.shuffle.parallelism	delete 方式删除数据时的 spark shuffle 并行度。
hoodie.sql.insert.mode	指定 Insert 模式，取值为 strict、non-strict 及 upsert。
hoodie.sql.bulk.insert.enable	指定是否开启 bulk insert 写入。
spark.sql.hive.convertMetastoreParquet	sparksql 把 parquet 表转化为 datasource 表进行读取。当 hudi 的 provider 为 hive 的情况下，使用 sparksql 或 sparkbeeline 进行读取，需要将该参数设置为 false。

示例

- 添加（Add）或更新（Update）：

```
set hoodie.insert.shuffle.parallelism = 100;
set hoodie.upsert.shuffle.parallelism = 100;
set hoodie.delete.shuffle.parallelism = 100;
```

- 重置（Reset）：

```
RESET
```

系统响应

- 若运行成功，将记录在 driver 日志中。
- 若出现故障，将显示在用户界面（UI）中。

12.4.3.7 ARCHIVELOG

说明

本章节仅适用于 MRS 3.2.0 及之后版本。

命令功能

用于根据配置对 Timeline 上的 Instant 进行归档，并从 Timeline 上将已归档的 Instant 删除，以减少 Timeline 的操作压力。

命令格式

RUN ARCHIVELOG ON tableIdentifier;

RUN ARCHIVELOG ON tablelocation;

参数描述

表12-28 参数描述

参数	描述
tableIdentifier	Hudi 表的名称
tablelocation	Hudi 表的存储路径

示例

```
run archivelog on h1;
run archivelog on "/tmp/hudi/h1";
```

注意事项

- clean 操作之前的 Instant 才允许归档。
- 不管是否进行 compaction 操作，至少会保留 hoodie.compact.inline.max.delta.commits 个 Instant 不会被归档，以此保证有足够的 Instant 去触发 compation schedule。

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

12.4.3.8 CLEAN

说明

本章节仅适用于 MRS 3.2.0 及之后版本。

命令功能

用于根据配置对 Timeline 上的 Instant 进行 clean，删除老旧的历史版本文件，以减少 hudi 表的数据存储及读写压力。

命令格式

RUN CLEAN ON tableIdentifier;

RUN CLEAN ON tablelocation;

参数描述

表12-29 参数描述

参数	描述
tableIdentifier	Hudi 表的名称
tablelocation	Hudi 表的存储路径

示例

```
run clean on h1;
run clean on "/tmp/hudi/h1";
```

注意事项

对表执行 clean 操作时需要表的 owner 才可以执行。

如果需要修改 clean 默认的参数，需要在执行前以 set 方式设置好需要保留的 commit 数等参数

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

12.4.3.9 CLEANARCHIVE

命令功能

用于对 Hudi 表的归档文件进行清理，以减少 Hudi 表的数据存储及读写压力。

命令格式

set hoodie.archive.file.cleaner.policy = KEEP_ARCHIVED_FILES_BY_SIZE;

set hoodie.archive.file.cleaner.size.retained = 5368709120;

run cleanarchive on *tableIdentifier*/*tablelocation*;

set hoodie.archive.file.cleaner.policy = KEEP_ARCHIVED_FILES_BY_DAYS;

set hoodie.archive.file.cleaner.days.retained = 30;

run cleanarchive on *tableIdentifier*/*tablelocation*;

参数描述

表12-30 参数描述

参数	描述
tableIdentifier	Hudi 表的名称。
tablelocation	Hudi 表的存储路径。
hoodie.archive.file.cleaner.policy	清理归档文件的策略：目前仅支持 KEEP_ARCHIVED_FILES_BY_SIZE 和 KEEP_ARCHIVED_FILES_BY_DAYS 两种策略，默认策略为 KEEP_ARCHIVED_FILES_BY_DAYS。 • KEEP_ARCHIVED_FILES_BY_SIZE 策略可以设置归档文件占用的存储空间大小 • KEEP_ARCHIVED_FILES_BY_DAYS 策略可以清理超过某个时间点之外的归档文件
hoodie.archive.file.cleaner.size.retained	当清理策略为 KEEP_ARCHIVED_FILES_BY_SIZE 时，该参数可以设置保留多少字节大小的归档文件，默认值 5368709120 字节（5G）。
hoodie.archive.file.cleaner.days.retained	当清理策略为 KEEP_ARCHIVED_FILES_BY_DAYS 时，该参数可以设置保留多少天以内的归档文件，默认值 30（天）。

注意事项

归档文件，没有备份，删除之后无法恢复。

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

12.4.4 CALL COMMAND (MRS 3.2.0 及之后版本)

12.4.4.1 CHANGE_TABLE

命令功能

CHANGE_TABLE 命令可以方便的修改表的类型以及索引，由于 Hudi 表本不支持修改表类型及索引等关键参数，该命令实际是将表重写。

命令格式

```
call change_table(table => '[table_name]', hoodie.index.type => '[index_type]',
hoodie.datasource.write.table.type => '[table_type]');
```

参数描述

表12-31 参数描述

参数	描述
table_name	需要修改的表的表名
table_type	需要修改的表类型
index_type	需要修改的索引类型

注意事项

如修改的索引类型有其对应的其他配置参数，同样需要以 key => 'value'格式传入 sql 中。

例如修改为 bucket 索引：

```
call change_table(table => 'hudi_table1', hoodie.index.type => 'BUCKET',
hoodie.bucket.index.num.buckets => '3');
```

示例

call change_table(table => 'hudi_table1', hoodie.index.type => 'SIMPLE',
hoodie.datasource.write.table.type => 'MERGE_ON_READ');

系统响应

执行完成后可通过 desc formatted table 来查看表属性。

12.4.4.2 CLEAN_FILE

命令功能

用于清理 Hudi 表目录下的无效数据文件。

命令格式

call clean_file(table => '[table_name]', mode=>'[op_type]', backup_path=>'[backup_path]',
start_instant_time=>'[start_time]', end_instant_time=>'[end_time]');

参数描述

表12-32 参数描述

参数	描述
table_name	需要清理无效数据文件的 Hudi 表的表名，必选。
op_type	命令运行模式，可选，默认值为 dry_run，取值：dry_run、repair、undo、query。 dry_run：显示需要清理的无效数据文件。 repair：显示并清理无效的数据文件。 undo：恢复已清理的数据文件 query：显示已执行清零操作的备份目录。
backup_path	运行模式为 undo 时有效，需要恢复数据文件的备份目录，必选。
start_time	运行模式为 dry_run、repair 时有效，产生无效数据文件的开始时间，可选，默认不限制开始时间。
end_time	运行模式为 dry_run、repair 时有效，产生无效数据文件的结束时间，可选，默认不限制结束时间。

示例

```
call clean_file(table => 'h1', mode=>'repair');
call clean_file(table => 'h1', mode=>'dry_run');
call clean_file(table => 'h1', mode=>'query');
call clean_file(table => 'h1', mode=>'undo',
backup_path=>'/tmp/hudi/h1/.hoodie/.cleanbackup/hoodie_repair_backup_20220222222222
');
```

注意事项

命令只清理无效的 parquet 文件。

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

12.4.4.3 SHOW_TIME_LINE

命令功能

查看当前生效或者被归档的 Hudi time line 以及某个指定 instant time 的详细内容。

命令格式

- 查看某个表生效的 time line 列表：
  call show_active_instant_list(table => '[table_name]');
- 查看某个表某个时间戳后的生效的 time line 列表：
  call show_active_instant_list(table => '[table_name]', instant => '[instant]');
- 查看某个表生效的某个 instant 信息：
  call show_active_instant_detail(table => '[table_name]', instant => '[instant]');
- 查看某个表已被归档的 instant time line 列表：
  call show_archived_instant_list(table => '[table_name]');
- 查看某个表某个时间戳后的已被归档的 instant time line 列表：
  call show_archived_instant_list(table => '[table_name]', instant => '[instant]');
- 查看某个表已被归档的 instant 信息：
  call show_archived_instant_detail(table => '[table_name], instant => '[instant]');

参数描述

表12-33 参数描述

参数	描述
table_name	需要查询的表的表名，支持 database.tablename 格式
instant	需要查询的 instant time 时间戳

示例

```
call show_active_instant_detail(table => 'hudi_table1', instant =>
'20220913144936897'");
```

系统响应

可在客户端中查看查询结果。

12.4.4.4 SHOW_HOODIE_PROPERTIES

命令功能

查看指定 hudi 表的 hoodie.properties 文件中的配置。

命令格式

call show_hoodie_properties(table => '[table_name]');

参数描述

表12-34 参数描述

参数	描述
table_name	需要查询的表的表名，支持 database.tablename 格式

示例

```
call show_hoodie_properties(table => "hudi_table5");
```

系统响应

可在客户端中查看查询结果。

12.4.4.5 SAVE_POINT

命令功能

管理 Hudi 表的 savepoint。

命令格式

- 创建 savepoint：
  call create_savepoints('[table_name]', '[commit_Time]', '[user]', '[comments]');
- 查看所有存在的 savepoint
  call show_savepoints(table =>'[table_name]');
- 回滚 savepoint：
  call rollback_savepoints('[table_name]', '[commit_Time]');

参数描述

表12-35 参数描述

参数	描述	是否必填
table_name	需要查询的表的表名，支持 database.tablename 格式	是
commit_Time	指定创建或回滚的时间戳	是
user	创建 savepoint 的用户	否
comments	该条 savepoint 的注释说明	否

示例

```
call create_savepoints('hudi_test1', '20220908155421949');
call show_savepoints(table =>'hudi_test1');
call rollback_savepoints('hudi_test1', '20220908155421949');
```

注意事项

- MOR 表不支持 savepoint。
- 最大的 savepoint 之前的 commit 相关文件不会被 clean。
- 存在多个 savepoint 时需要从最大的 savepoint 开始执行 rollback，逻辑是：rollback savepoint -> delete savepoint -> rollback 下一个 savepoint。

系统响应

可在客户端中查看查询结果。

12.4.4.6 ROLL_BACK

命令功能

用于回滚指定的 commit。

命令格式

call rollback_to_instant(table => '[table_name]', instant_time => '[instant]');

参数描述

表12-36 参数描述

参数	描述
table_name	需要回滚的 Hudi 表的表名，必选
instant	需要回滚的 Hudi 表的 commit instant 时间戳，必选

示例

```
call rollback_to_instant(table => 'h1', instant_time=>'20220915113127525');
```

注意事项

只能依次回滚最新的 commit 时间戳

系统响应

可在 driver 日志和客户端中查看命令运行成功或失败。

12.4.4.7 CLUSTERING

说明

本章节仅适用于 MRS 3.2.0 及之后版本。

命令功能

对 Hudi 表进行 clustering 操作，具体作用可以参考 12.3.4.1 Clustering 章节。

命令格式

- 执行 clustering：

  call run_clustering(table=>'[table]', path=>'[path]', predicate=>'[predicate]', order=>'[order]');

- 查看 clustering 计划：

  call show_clustering(table=>'[table]', path=>'[path]', limit=>'[limit]');

参数描述

表12-37 参数描述

参数	描述	是否必填
table	需要查询的表的表名，支持 database.tablename 格式	否
path	需要查询的表的路径	否
predicate	需要定义的谓语句	否
order	指定 clustering 的排序字段	否
limit	展示查询结果的条数	否

示例

```
call show_clustering(table => 'hudi_table1');

call run_clustering(table => 'hudi_table1', predicate => '(ts >= 1006L and ts < 1008L) or ts >= 1009L', order => 'ts');

call run_clustering(path => '/user/hive/warehouse/hudi_test2', predicate => "dt = '2021-08-28'", order => 'id');
```

注意事项

- table 与 path 参数必须存在一个，否则无法判断需要执行 clustering 的表
- 如果需要对指定分区进行 clustering，参考格式：predicate => "dt = '2021-08-28'"

系统响应

可在客户端中查看查询结果。

12.4.4.8 Cleaning

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

命令功能

对 Hudi 表进行 cleaning 操作，具体作用可以参考 12.3.4.2 Cleaning 章节。

命令格式

call run_clean(table=>'[table]', clean_policy=>'[clean_policy]', retain_commits=>'[retain_commits]', hours_retained=> '[hours_retained]', file_versions_retained=> '[file_versions_retained]');

参数描述

表12-38 参数描述

参数	描述	是否必填
table	需要查询表的表名，支持 database.tablename 格式	是
clean_policy	清理老版本数据文件的策略，默认 KEEP_LATEST_COMMITS	否
retain_commits	仅对 KEEP_LATEST_COMMITS 策略有效	否
hours_retained	仅对 KEEP_LATEST_BY_HOURS 策略有效	否
file_version_retained	仅对 KEEP_LATEST_FILE_VERSIONS 策略有效	否

示例

```
call run_clean(table => 'hudi_table1');

call run_clean(table => 'hudi_table1', retain_commits => 2);

call run_clean(table => 'hudi_table1', clean_policy => 'KEEP_LATEST_FILE_VERSIONS', file_version_retained => 1);
```

注意事项

cleaning 操作只有在满足触发条件后才会对分区的老版本数据文件进行清理，不满足触发条件虽然执行命令成功也不会执行清理。

系统响应

可在客户端中查看查询结果。

12.4.4.9 Compaction

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

命令功能

对 Hudi 表进行 compaction 操作，具体作用可以参考 12.3.4.3 Compaction 章节。

命令格式

call run_compaction(op => '[op]', table=>'[table]', path=>'[path]', timestamp=>'[timestamp]');

参数描述

表12-39 参数描述

参数	描述	是否必填
op	生成 compaction 计划（op 指定为“schedule”），或者执行已经生成的 compaction 计划（op 指定为“run”）	是
table	需要查询表的表名，支持 database.tablename 格式	否
path	需要查询表的路径	否
timestamp	在 op 指定为“run”时，可以指定 timestamp 来执行该时间戳对应的 compaction 计划以及该时间戳之前未执行的 compaction 计划	否

示例

```
call run_compaction(table => 'hudi_table1', op => 'schedule');
call run_compaction(table => 'hudi_table1', op => 'run');
call run_compaction(table => 'hudi_table1', op => 'run', timestamp => 'xxx');
```

```
call run_compaction(path => '/user/hive/warehouse/hudi_table1', op => 'run',
timestamp => 'xxx');
```

注意事项

compaction 操作仅支持 MOR 表。

系统响应

可在客户端中查看查询结果。

12.4.4.10 SHOW_COMMIT_FILES

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

命令功能

查看指定的 instant 一共更新或者插入了多个文件。

命令格式

call show_commit_files(table=>'[table]', instant_time=>'[instant_time]', limit=>'[limit]');

参数描述

表12-40 参数描述

参数	描述	是否必填
table	需要查询表的表名，支持 database.tablename 格式	是
instant_time	某次 commit 对应的时间戳	是
limit	限制返回结果的条数	否

示例

```
call show_commit_files(table=>'hudi_mor', instant_time=>'20230216144548249');
call show_commit_files(table=>'hudi_mor', instant_time=>'20230216144548249',
limit=>'1');
```

返回结果

参数	描述
action	instant_time 对应的 commit 所属的 action 类型，如 compaction、deltacommit、clean 等

参数	描述
partition_path	指定的 instant 所更新或插入的文件位于哪个分区
file_id	指定的 instant 所更新或插入的文件的 ID
previous_commit	指定的 instant 所更新或插入的文件的文件名中的时间戳
total_records_updated	该文件中多少个 record 被更新
total_records_written	该文件中新插入了多少个 record
total_bytes_written	该文件新增多少 bytes 的数据
total_errors	指定的 instant 在更新或者插入过程中的报错
file_size	该文件的大小（bytes）

系统响应

可在客户端中查看查询结果。

12.4.4.11 SHOW_FS_PATH_DETAIL

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

命令功能

查看指定的 FS 路径的统计数据

命令格式

call show_fs_path_detail(path=>'[path]', is_sub=>'[is_sub]', sort=>'[sort]');

参数描述

表12-41 参数描述

参数	描述	是否必填
path	需要查询的 FS 的路径	是
is_sub	默认 false，false 表示统计指定目录的信息，true 表示统计指定目录的子目录的信息	否
sort	默认 true，true 表示根据 storage_size 排序结果，false 表	否

参数	描述	是否必填
	示根据文件数量排序结果	

示例

```
call show_commit_files(path=>'/user/hive/warehouse/hudi_mor/dt=2021-08-28');
call show_fs_path_detail(path=>'/user/hive/warehouse/hudi_mor/dt=2021-08-28',
is_sub=>false, sort=>true);
```

返回结果

参数	描述
path_num	指定目录的子目录数量
file_num	指定目录的文件数量
storage_size	该目录的 Size（bytes）
storage_size(unit)	该目录的 Size（KB）
storage_path	指定目录的完整 FS 绝对路径
space_consumed	返回文件/目录在集群中占用的实际空间，即它考虑了为集群设置的复制因子
quota	名称配额（名称配额是对当前目录树中的文件和目录名称数量的硬性限制）
space_quota	空间配额（空间配额是对当前目录树中的文件所使用的字节数量的硬性限制）

系统响应

可在客户端中查看查询结果。

12.4.4.12 SHOW_LOG_FILE

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

命令功能

查看 log 文件的 meta 和 record 信息。

命令格式

- 查看 meta：

call show_logfile_metadata(table => '[table]', log_file_path_pattern => '[log_file_path_pattern]', limit => '[limit]')

- 查看 record：

  call show_logfile_records(table => '[table]', log_file_path_pattern => '[log_file_path_pattern]', merge => '[merge]', limit => '[limit]')

参数描述

表12-42 参数描述

参数	描述	是否必填
table	需要查询表的表名，支持 database.tablename 格式	是
log_file_path_pattern	log file 的路径，支持正则匹配	否
merge	执行 show_logfile_records 时，通过 merge 控制是否将多个 log file 中的 record 合并在一起返回	否
limit	限制返回结果的条数	否

示例

```
call show_logfile_metadata(table => 'hudi_mor', log_file_path_pattern =>
'http://hacluster/user/hive/warehouse/hudi_mor/dt=2021-08-28/.*?log.*?');
call show_logfile_records(table => 'hudi_mor', log_file_path_pattern =>
'http://hacluster/user/hive/warehouse/hudi_mor/dt=2021-08-28/.*?log.*?', merge =>
false, limit => 1);
```

注意事项

- 仅 MOR 表会用到此命令。

系统响应

可在客户端中查看查询结果。

12.4.4.13 SHOW_INVALID_PARQUET

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

命令功能

查看执行路径下损坏的 parquet 文件。

命令格式

call show_invalid_parquet(path => 'path')

参数描述

表12-43 参数描述

参数	描述	是否必填
path	需要查询的 FS 路径	是

示例

```
call show_invalid_parquet(path => '/user/hive/warehouse/hudi_mor/dt=2021-08-28');
```

系统响应

可在客户端中查看查询结果。

12.5 Hudi Schema 演进

12.5.1 Schema 演进介绍

Schema 演进（Schema Evolution）允许用户能够方便的修改 Hudi 表的当前 Schema，以适应不断变化的数据。

说明

本章节内容仅使用于 MRS 3.2.0 及之后版本。

12.5.2 Schema 演进支持范围

Schema 演进支持范围：

- 支持列（包括嵌套列）相关的增、删、改、位置调整等操作。
- 不支持对分区列做演进。
- 不支持对 Array 类型的嵌套列进行增、删、列操作。

表12-44 引擎支持矩阵

引擎	DDL 操作 Schema	变更后的 Hudi 表写操作支持	变更后的 Hudi 表读操作支持	变更后 Hudi 表 compaction 支持
SparkSQL	Y	Y	Y	Y
Flink	N	Y	Y	Y

引擎	DDL 操作 Schema	变更后的 Hudi 表写操作支持	变更后的 Hudi 表读操作支持	变更后 Hudi 表 compaction 支持
HetuEngine	N	N	Y	N
Hive	N	N	Y	N

12.5.3 SparkSQL 支持 Schema 演进及语法说明

12.5.3.1 功能开启

⚠ 注意

- Schema 演进开启后不能关闭。
- 本章节仅适用于 MRS 3.2.0 及之前版本。

- 使用 spark-beeline 时，需要登录 Manager 页面，选择“集群 > 服务 > Spark2x > 配置 > 全部配置”。

  在搜索栏中搜索参数“spark.sql.extensions”，修改 JDBCServer 的 spark.sql.extensions 参数值为：
  org.apache.spark.sql.hive.FISparkSessionExtension,org.apache.spark.sql.hudi.HoodieSparkSessionExtension,org.apache.spark.sql.hive.CarbonInternalExtensions
- 如果是 SQL 操作，执行 SQL 前需要执行：

  ```
  set hoodie.schema.evolution.enable=true
  ```
- 如果是 API 操作，DataFrame options 里面需要指定：

  ```
  hoodie.schema.evolution.enable -> true
  ```

12.5.3.2 新增列操作

命令功能

ADD COLUMNS 命令用于为现有表添加新列。

命令语法

ALTER TABLE *tableName* **ADD COLUMNS**(*col_spec[, col_spec ...]*)

参数描述

表12-45 ADD COLUMNS 参数描述

参数	描述
tableName	表名。

参数	描述
col_spec	可由[col_name][col_type][nullable][comment][col_position]五部分组成。 • col_name：新增列名，必须指定。 给嵌套列添加新的子列需要指定子列的全名称： – 添加新列 col1 到 STURCT 类型嵌套列 users struct<name: string, age: int>，新列名称需要指定为 users.col1。 – 添加新列 col1 到 MAP 类型嵌套列 memeber map<string, struct<n: string, a: int>>，新列名称需要指定为 member.value.col1。 – 添加新列 col2 到 ARRAY 类型嵌套列 arraylike array<struct<a1: string, a2: int>>，新列名称需要指定为 arraylike.element.col2。 • col_type：新增列类型，必须指定。 • nullable：新增列是否可以为空，可以缺省。 • comment：新增列 comment，可以缺省。 • col_position：列添加位置包括 FIRST、AFTER origin_col 两种，指定 FIRST 新增列将会被添加到表的第一列。AFTER origin_col 新增列将会被加入到原始列 origin_col 之后，可以缺省。FIRST 只能再嵌套列添加新的子列时使用，禁止 top-level 列使用 FIRST，AFTER 没有限制。

示例

```
alter table h0 add columns(ext0 string);
alter table h0 add columns(new_col int not null comment 'add new column' after
col1);
alter table complex_table add columns(col_struct.col_name string comment 'add new
column to a struct col' after col_from_col_struct);
```

系统响应

通过运行 **DESCRIBE** 命令，可显示新添加的列。

12.5.3.3 更新列操作

命令功能

ALTER TABLE ... ALTER COLUMN 语法用于修改当前列属性包括列类型、列位置、列 comment。

命令语法

ALTER TABLE *tableName* **ALTER**

[COLUMN] *col_old_name* **TYPE** *column_type*

[COMMENT] *col_comment*

[FIRST|AFTER] *column_name*

参数描述

表12-46 ALTER COLUMN 参数描述

参数	描述
tableName	表名。
col_old_name	待修改的列名。
column_type	目标列类型。
col_comment	列 comment。
column_name	位置修改参照列，例如：AFTER column_name 的语义是要将待修改列放到参照列 column_name 之后。

示例

- 列类型修改

```
ALTER TABLE table1 ALTER COLUMN a.b.c TYPE bigint
```

a.b.c 表示嵌套列全路径，嵌套列具体规则见 12.5.3.2 新增列操作。

当前类型修改支持：

  - int => long/float/double/string/decimal
  - long => float/double/string/decimal
  - float => double/String/decimal
  - double => String/Decimal
  - Decimal => Decimal/String
  - String => date/decimal
  - date => String

- 其他修改

```
ALTER TABLE table1 ALTER COLUMN a.b.c DROP NOT NULL
ALTER TABLE table1 ALTER COLUMN a.b.c COMMENT 'new comment'
ALTER TABLE table1 ALTER COLUMN a.b.c FIRST
ALTER TABLE table1 ALTER COLUMN a.b.c AFTER x
```

a.b.c 表示嵌套列全路径，嵌套列具体规则见 12.5.3.2 新增列操作。

系统响应

通过运行 **DESCRIBE** 命令，可显示修改的列。

12.5.3.4 删除列操作

命令功能

ALTER TABLE ... DROP COLUMN 语法用于删除列。

命令语法

ALTER TABLE *tableName* **DROP COLUMN|COLUMNS** *cols*

参数描述

表12-47 DROP COLUMN 参数描述

参数	描述
tableName	表名。
cols	待删除列，可以指定多个。

示例

```
ALTER TABLE table1 DROP COLUMN a.b.c
ALTER TABLE table1 DROP COLUMNS a.b.c, x, y
```

a.b.c 表示嵌套列全路径，嵌套列具体规则见 12.5.3.2 新增列操作。

系统响应

通过运行 **DESCRIBE** 命令，可查看删除列。

12.5.3.5 修改表名操作

命令功能

ALTER TABLE ... RENAME 语法用于修改表名。

命令语法

ALTER TABLE *tableName* **RENAME TO** *newTableName*

参数描述

表12-48 RENAME 参数描述

参数	描述
tableName	表名。
newTableName	新表名。

示例

```
ALTER TABLE table1 RENAME TO table2
```

系统响应

通过运行 **SHOW TABLES** 查看新的表名。

12.5.3.6 表属性修改操作

命令功能

ALTER TABLE ... SET|UNSET 语法用于修改表属性。

命令语法

ALTER TABLE *tableName* **SET|UNSET** *tblproperties*

参数描述

表12-49 参数描述

参数	描述
tableName	表名。
tblproperties	表属性。

示例

```
ALTER TABLE table SET TBLPROPERTIES ('table_property' = 'property_value')
ALTER TABLE table UNSET TBLPROPERTIES [IF EXISTS] ('comment', 'key')
```

系统响应

通过运行 **DESCRIBE** 命令查看表属性修改。

12.5.3.7 修改列名称

命令功能

ALTER TABLE ... RENAME COLUMN 语法用于修改列名称。

命令语法

ALTER TABLE *tableName* **RENAME COLUMN** *old_columnName* **TO** *new_columnName*

参数描述

表12-50 参数描述

参数	描述
tableName	表名。
old_columnName	旧列名。
new_columnName	新列名。

示例

```
ALTER TABLE table1 RENAME COLUMN a.b.c TO x
```

a.b.c 表示嵌套列全路径，嵌套列具体规则见 12.5.3.2 新增列操作。

说明

修改列名后自动同步到列 comment 中，comment 的形式为：rename oldName to newName。

系统响应

通过运行 **DESCRIBE** 命令查看表列修改。

12.5.4 Schema 演进并发

注意

建表时需要指定 hoodie.cleaner.policy.failed.writes = 'LAZY'，否则并发提交时会触发 rollback。

DDL 并发

表12-51 支持的 DDL 并发操作

DDL 操作	add	rename	change type	change comment	drop
add	Y	Y	Y	Y	Y
rename	Y	Y	Y	Y	Y
change type	Y	Y	Y	Y	Y
change comment	Y	Y	Y	Y	Y
drop	Y	Y	Y	Y	N

说明

对同一列并发执行 DDL 操作需要注意以下两点：

- 不能对同一列并发执行 drop，否则只能成功执行第一个 drop 随后抛出异常“java.lang.UnsupportedOperationException: cannot evolution schema implicitly, the column for which the update operation is performed does not exist.”。
- drop 与 rename、change type 和 change comment 并发执行时，drop 必须是最后执行，否则只能执行 drop 以及 drop 之前的命令，执行 drop 之后的命令会抛出异常“java.lang.UnsupportedOperationException: cannot evolution schema implicitly, the column for which the update operation is performed does not exist.”。

DDL 与 DML 并发

表12-52 支持的 DDL 与 DML 并发操作

DDL 操作	insert into	update	delete	set/reset
add	Y	Y	Y	Y
rename	N	N	Y	N
change type	N	N	Y	N
change comment	Y	Y	Y	Y
drop	N	N	Y	N

说明

执行不支持的 DDL 与 DML 并发操作时会抛出异常“cannot evolution schema implicitly, actions such as rename, delete, and type change were found”。

12.6 Hudi 支持列设置默认值

该特性允许用户在给表新增列时，设置列的默认值。查询历史数据时新增列返回默认值。

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

使用约束

- 新增列在设置默认值前，如果数据已经进行了重写，则查询历史数据不支持返回列的默认值，返回 NULL。数据入库、更新、执行 Compaction、Clustering 都会导致部分或全部数据重写。
- 列的默认值设置要与列的类型一致，如不一致会进行类型强转，导致默认值精度丢失或者默认值为 NULL。
- 历史数据的默认值与列第一次设置的默认值一致，多次修改列的默认值不会影响历史数据的查询结果。
- 设置默认值后 rollback 不能回滚默认值配置。
- Spark SQL 暂不支持查看列默认值信息，可以通过 Hive beeline 执行 **show create table** 命令查看。

支持范围

当前仅支持 int、bigint、float、double、decimal、string、date、timestamp、boolean、binary 类型，其他类型不支持。

表12-53 引擎支持矩阵

引擎	DDL 操作	写操作支持	读操作支持
SparkSQL	Y	Y	Y
Spark DataSource	N	N	Y
Flink	N	N	Y
HetuEngine	N	N	Y
Hive	N	N	Y

示例

SQL 语法具体参考 12.4 Hudi SQL 语法参考章节。

示例：

- 建表指定列默认值

```
create table if not exists h3(
id bigint,
name string,
```

```
price double default 12.34
) using hudi
options (
primaryKey = 'id',
type = 'mor',
preCombineField = 'name'
);
```

- 添加列指定列默认值

```
alter table h3 add columns(col1 string default 'col1_value');
alter table h3 add columns(col2 string default 'col2_value', col3 int default
1);
```

- 修改列默认值

```
alter table h3 alter column price set default 14.56;
```

- 插入数据使用列默认值

```
insert into h3(id, name) values(1, 'aaa');
insert into h3(id, name, price) select 2, 'bbb', 12.5;
```

12.7 Hudi 性能调优

性能调优方式

当前版本 Hudi 写入操作主推 Spark，因此 Hudi 的调优和 Spark 比较类似，可参考 21.8 Spark2x 性能调优。

推荐资源配置

- mor 表：

  由于其本质上是写增量文件，调优可以直接根据 hudi 的数据大小（dataSize）进行调整。

  dataSize 如果只有几个 G，推荐跑单节点运行 spark，或者 yarn 模式但是只分配一个 container。

  入湖程序的并行度 p 设置：建议 p = （dataSize）/128M，程序分配 core 的数量保持和 p 一致即可。内存设置建议内存大小和 core 的比例大于 1.5:1 即一个 core 配 1.5G 内存， 堆外内存设置建议内存大小和 core 的比例大于 0.5:1。

- cow 表：

  cow 表的原理是重写原始数据，因此这种表的调优，要兼顾 dataSize 和最后重写的文件数量。总体来说 core 数量越大越好（和最后重写多少个文件数直接相关），并行度 p 和内存大小和 mor 设置类似。

12.8 Hudi 常见问题

12.8.1 数据写入

12.8.1.1 写入更新数据时报错 Parquet/Avro schema

问题

数据写入时报错：

```
org.apache.parquet.io.InvalidRecordException: Parquet/Avro schema mismatch: Avro
field 'col1' not found
```

回答

建议在使用 Hudi 时，schema 应该以向后兼容的方式演进。此错误通常发生在使用向后不兼容的演进方式删除某些列如“col1”后，更新 parquet 文件中以旧的 schema 写入的列“col1”，在这种情况下，parquet 尝试在传入记录中查找所有当前字段，当发现“col1”不存在时，抛出上述异常。

解决这个问题的办法是使用所有 schema 演进版本来创建 uber schema，并使用该 schema 作为 target schema。用户可以从 hive metastore 中获取 schema 并将其与当前 schema 合并。

12.8.1.2 写入更新数据时报错 UnsupportedOperationException

问题

数据写入时报错：

```
java.lang.UnsupportedOperationException:
org.apache.parquet.avro.AvroConverters$FieldIntegerConverter
```

回答

因为 schema 演进以非向后兼容的方式进行，此错误将再次发生。基本上，如果已经写入 Hudi 数据集 parquet 文件的记录 R 有一些更新 U。R 包含字段 F，该字段包含某类数据类型，也就是 LONG。U 具有相同的字段 F，该字段的数据类型是 INT。Parquet FS 不支持这种不兼容的数据类型转换。

对于此类错误，请从源头数据采集的位置进行有效的数据类型转换。

12.8.1.3 写入更新数据时报错 SchemaCompatabilityException

问题

数据写入时报错：

```
org.apache.hudi.exception.SchemaCompatabilityException: Unable to validate the
rewritten record <record> against schema <schema>at
org.apache.hudi.common.util.HoodieAvroUtils.rewrite(HoodieAvroUtils.java:215)
```

回答

如果 schema 包含 non-nullable 字段但是值是不存在或者 null，则可能会发生这种情况。

建议以使用向后兼容的演进 schema。本质上，这意味着要么将每个新添加的字段设置为空值，要么为每个新字段设置为默认值。从 Hudi 版本 0.5.1 起，如果依赖字段的默认值，则该故障处理对此无效。

12.8.1.4 Hudi 在 upsert 时占用了临时文件夹中大量空间

问题

Hudi 在 upsert 时占用了临时文件夹中大量空间。

回答

当 UPSERT 大量输入数据时，如果数据量达到合并的最大内存时，Hudi 将溢出部分输入数据到磁盘。

如果有足够的内存，请增加 spark executor 的内存和添加“hoodie.memory.merge.fraction”选项，如： option("hoodie.memory.merge.fraction", "0.8")

12.8.1.5 Hudi 写入小精度 Decimal 数据失败

问题

Hudi 表初始入库采用 BULK_INSERT 方式入库含有 Decimal 类型的数据，之后执行 **upsert**，数据写入时报错：

```
java.lang.UnsupportedOperationException:
org.apache.parquet.avro.AvroConverters$FieldFixedConverter
```

回答

原因：

Hudi 表数据含有 Decimal 类型数据。

初始入库 BULK_INSET 方式会使用 Spark 内部 parquet 文件的写入类进行写入，Spark 对不同精度的 Decimal 类型处理是不同的。

UPSERT 操作时，Hudi 使用 Avro 兼容的 parquet 文件写入类进行写入，这个和 Spark 的写入方式是不兼容的。

解决方案：

执行 BULK_INSERT 时指定设置“hoodie.datasource.write.row.writer.enable = false”，使 hoodie 采用 Avro 兼容的 parquet 文件写入类进行写入。

12.8.1.6 使用 Spark SQL 删除 MOR 表后重新建表写入数据无法同步 ro、rt 表

问题

使用 Spark SQL 删除 MOR 表后重新建表写入数据不能实时同步 ro、rt 表，报错如下：

```
WARN HiveSyncTool: Got runtime exception when hive syncing, but continuing as
ignoreExceptions config is set
java.lang.IllegalArgumentException: Failed to get schema for table hudi_table2_ro
does not exist
at org.apache.hudi.hive.HoodieHiveClient.getTableSchema(HoodieHiveClient.java:183)
at org.apache.hudi.hive.HiveSyncTool.syncHoodieTable(HiveSyncTool.java:286)
at org.apache.hudi.hive.HiveSyncTool.doSync(HiveSyncTool.java:213)
```

回答

原因：

Hudi 表为减少访问 Hive Metastore 的频率，增加了缓存机制，默认缓存 1 小时，所以使用 Spark SQL 删除 MOR 表后重新建表写入数据无法同步 ro、rt 表。

解决方案：

执行 SQL 时设置参数：hoodie.datasource.hive_sync.interval=0

```
set hoodie.datasource.hive_sync.interval=0;
```

12.8.2 数据采集

12.8.2.1 使用 kafka 采集数据时报错 IllegalArgumentException

问题

线程“main”报错 org.apache.kafka.common.KafkaException，构造 kafka 消费者失败，报错：

```
java.lang.IllegalArgumentException: Could not find a 'KafkaClient' entry in the
JAAS configuration. System property 'java.security.auth.login.config' is not set
```

回答

当试图从启用 SSL 的 kafka 数据源采集数据时，而安装程序无法读取 jars.conf 文件及其属性时，可能会发生这种情况。

要解决此问题，需要将所需的属性作为通过 Spark 提交的命令的一部分传递。如：--files jaas.conf,failed_tables.json --conf 'spark.driver.extraJavaOptions=-Djava.security.auth.login.config=jaas.conf' --conf 'spark.executor .extraJavaOptions=-Djava.security.auth.login.config=jaas.conf'

12.8.2.2 采集数据时报错 HoodieException

问题

数据采集时报错：

```
com.uber.hoodie.exception.HoodieException: created_at(Part -created_at) field not
found in record. Acceptable fields were :[col1, col2, col3, id, name, dob,
created_at, updated_at]
```

回答

这种情况通常当标记为 recordKey 或 partitionKey 的字段在某些传入记录中不存在时发生。请交叉验证你的传入记录。

12.8.2.3 采集数据时报错 HoodieKeyException

问题

创建 Hudi 表时，是否可以使用包含空记录的可空字段作为主键？

回答

不可以，会抛 HoodieKeyException 异常。

```
Caused by: org.apache.hudi.exception.HoodieKeyException: recordKey value: "null"
for field: "name" cannot be null or empty.
at org.apache.hudi.keygen.SimpleKeyGenerator.getKey(SimpleKeyGenerator.java:58)
at
org.apache.hudi.HoodieSparkSqlWriter$$anonfun$1.apply(HoodieSparkSqlWriter.scala:10
4)
at
org.apache.hudi.HoodieSparkSqlWriter$$anonfun$1.apply(HoodieSparkSqlWriter.scala:10
0)
```

12.8.3 Hive 同步

12.8.3.1 Hive 同步数据报错 SQLException

问题

Hive 同步数据时报错：

```
Caused by: java.sql.SQLException: Error while processing statement: FAILED:
Execution Error, return code 1 from org.apache.hadoop.hive.ql.exec.DDLTask. Unable
to alter table. The following columns have types incompatible with the existing
columns in their respective positions :
__col1,__col2
```

回答

这种情况通常会发生当您试图使用 HiveSyncTool.java 类向现有 hive 表添加新列时。数据库通常不允许将列数据类型按照从高到低的顺序修改，或者数据类型可能与表中已存储/将要存储的数据冲突。若要修复相同的问题，请尝试设置以下属性：

设置 hive.metastore.disallow.in compatible.col.type.changes 为 false。

12.8.3.2 Hive 同步数据报错 HoodieHiveSyncException

问题

Hive 同步数据时报错：

```
com.uber.hoodie.hive.HoodieHiveSyncException: Could not convert field Type from
<type1> to <type2> for field col1
```

回答

出现这种情况是因为 HiveSyncTool 目前只支持很少的兼容数据类型转换。进行任何其他不兼容的更改都会引发此异常。

请检查相关字段的数据类型演进，并验证它是否确实可以被视为根据 Hudi 代码库的有效数据类型转换。

12.8.3.3 Hive 同步数据报错 SemanticException

问题

Hive 同步数据时报错：

```
org.apache.hadoop.hive.ql.parse.SemanticException: Database does not exist: test_db
```

回答

这种情况通常在试图对 Hudi 数据集执行 Hive 同步，但配置的 hive_sync 数据库不存在时发生。

请在您的 Hive 集群上创建对应的数据库后重试。

13 使用 Hue

13.1 从零开始使用 Hue

Hue 汇聚了与大多数 Apache Hadoop 组件交互的接口，致力让用户通过界面图形化的方式轻松使用 Hadoop 组件。目前 Hue 支持 HDFS、Hive、HBase、Yarn、MapReduce、Oozie 和 SparkSQL 等组件的可视化操作。

前提条件

已安装 Hue 组件。

操作步骤

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 在左侧导航栏单击编辑器，然后选择“Hive”。

步骤 2 在“Database”右侧下拉列表选择一个 Hive 中的数据库，默认数据库为“default”。

系统将自动显示数据库中的所有表。可以输入表名关键字，系统会自动搜索包含此关键字的全部表。

步骤 3 单击指定的表名，可以显示表中所有的列。

步骤 4 在 HiveQL 语句编辑区输入 HiveQL 语句。

create table hue_table(id int,name string,company string) row format delimited fields terminated by ',' stored as textfile;

步骤 5 单击 开始执行 HiveQL 语句。

步骤 6 在命令输入框内输入 **show tables;**，单击 按钮，查看“结果”中有步骤 5 创建的表 hue_table。

----结束

13.2 访问 Hue 的 WebUI

操作场景

MRS 集群安装 Hue 组件后，用户可以通过 Hue 的 WebUI，在图形化界面使用 Hadoop 生态相关组件。

该任务指导用户在 MRS 集群中打开 Hue 的 WebUI。

说明

Internet Explorer 浏览器可能存在兼容性问题，建议更换兼容的浏览器访问 Hue WebUI，例如 Google Chrome 浏览器 50 版本。

对系统的影响

第一次访问 Manager 和 Hue WebUI，需要在浏览器中添加站点信任以继续打开 Hue WebUI。

前提条件

启用 Kerberos 认证时，MRS 集群管理员已分配用户使用 Hive 的权限。具体操作请参见“用户指南 >MRS 操作指导 > 权限管理 > 创建用户”章节。例如创建一个“人机”用户“hueuser”，并加入“hive”、“hadoop”、“supergroup”组和“System_administrator”角色，主组为“hive”。

该用户用于登录 Manager。

操作步骤

登录服务页面：

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 >Hue”。

步骤 1 在“Hue WebUI”右侧，单击链接，打开 Hue 的 WebUI。

Hue 的 WebUI 支持以下功能：

- 使用编辑器  执行 Hive、SparkSql 的查询语句以及 Notebook 代码段。需要 MRS 集群已安装 Hive、Spark2x。
- 使用计划程序  提交 Workflow 任务、计划任务、Bundle 任务。
- 使用文档  查看、导入、导出在 Hue 页面上操作的任务，例如保存的 Workflow 任务、定时任务、Bundle 任务等。
- 使用表  管理 Hive、SparkSql 中的元数据。需要 MRS 集群已安装 Hive、Spark2x。
- 使用文件  查看 HDFS 中的目录和文件。需要 MRS 集群已安装 HDFS。
- 使用作业  查看 MRS 集群中所有作业。需要 MRS 集群已安装 Yarn。

- 使用 HBase 创建/查询 HBase 表。需要 MRS 集群已安装 HBase 组件并添加 Thrift1Server 实例。
- 使用导入器通过“.csv”，“.txt”等格式的文件导入数据。

说明

- 使用创建的用户第一次登录 Hue WebUI，需修改密码。
- 用户获取 Hue WebUI 的访问地址后，可以给其他无法访问 Manager 的用户用于访问 Hue WebUI。
- 在 Hue 的 WebUI 操作但不操作 Manager 页面，重新访问 Manager 时需要输入已登录的账号密码。

----结束

13.3 Hue 常用参数

参数入口

参数入口，请参考 25.1 修改集群服务配置参数进入 Hue 服务“全部配置”页面。

参数说明

Hue 常用参数请参见表 13-1。

表13-1 Hue 常用参数

配置参数	说明	缺省值	范围
HANDLER_ACCESSLOG_LEVEL	Hue 的访问日志级别。	DEBUG	• ERROR • WARN • INFO • DEBUG
HANDLER_AUDITSLOG_LEVEL	Hue 的审计日志级别。	DEBUG	• ERROR • WARN • INFO • DEBUG
HANDLER_ERRORLOG_LEVEL	Hue 的错误日志级别。	ERROR	• ERROR • WARN • INFO • DEBUG
HANDLER_LOGFILE_LEVEL	Hue 的运行日志级别。	INFO	• ERROR • WARN • INFO • DEBUG

配置参数	说明	缺省值	范围
HANDLER_LOGFILE_MAXBACKUPINDEX	Hue 日志文件最大个数。	20	1～999
HANDLER_LOGFILE_SIZE	Hue 日志文件最大大小。	5MB	-

Hue 自定义参数请参见表 13-2。以下自定义参数仅 MRS 3.1.2 及之后版本适用。

表13-2 Hue 自定义参数

配置参数	参数描述
dfs.customized.configs	添加全局 hdfs-site.xml 中用户自定义配置项
hbase.customized.configs	添加全局 hbase-site.xml 中用户自定义配置项
hive.customized.configs	添加全局 hive-site.xml 中用户自定义配置项

13.4 在 Hue WebUI 使用 HiveQL 编辑器

操作场景

用户需要使用图形化界面在集群中执行 HiveQL 语句时，可以通过 Hue 完成任务。

访问编辑器

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 在左侧导航栏单击  ，然后选择“Hive”，进入“Hive”。

“Hive”支持以下功能：

- 执行和管理 HiveQL 语句。
- 在“保存的查询”中查看当前访问用户已保存的 HiveQL 语句。
- 在“查询历史记录”中查看当前访问用户执行过的 HiveQL 语句。

----结束

执行 HiveQL 语句

在“Database”右侧下拉列表选择一个 Hive 中的数据库，默认数据库为“default”。

系统将自动显示数据库中的所有表。可以输入表名关键字，系统会自动搜索包含此关键字的全部表。

步骤 1 单击指定的表名，可以显示表中所有的列。

光标移动到表或列所在的行，单击 可以查看详细信息。

步骤 2 在 HiveQL 语句编辑区输入查询语句。

步骤 3 单击 开始执行 HiveQL 语句。

说明

- 如果希望下次继续使用已输入的 HiveQL 语句，请单击 保存。
- 高级查询配置：

  单击右上角的，对文件、功能、设置等信息进行配置。
- 查看快捷键：

  单击右上角的，可查看语法和键盘快捷方式信息。
- 删除已输入的 HiveQL 语句，请单击 后的三角选择“清除”。
- 查看历史：

  单击“查询历史记录”，可查看 HiveQL 运行情况，支持显示所有语句或只显示保存的语句的运行情况。历史记录存在多个结果时，可以在输入框使用关键字进行搜索。

----结束

查看执行结果

在“Hive”的执行区，默认显示“查询历史记录”。

步骤 1 单击结果查看已执行语句的执行结果。

说明

Hue 暂不支持大数据量展示，当 SQL 查询结果加载过量时可能出现页面卡顿，部分数据不显示等情况。目前建议查询结果加载不超过 5000 行。

----结束

管理查询语句

单击“保存的查询”。

步骤 1 单击一条已保存的语句，系统会自动将其填充至编辑区中。

----结束

修改在 Hue 使用编辑器的会话配置

在编辑器页面，单击 。

步骤 1 在“文件”的右侧单击 ，然后单击 选择文件。

可以单击“文件”后的 新增加一个文件资源。

步骤 2 在“功能” ，输入用户自定义的名称和函数的类名称。

可以单击“功能”后的 新增加一个自定义函数。

步骤 3 在“设置” ，在“设置”的“键”输入 Hive 的参数名，在“值”输入对应的参数值，则当前 Hive 会话会以用户定义的配置连接 Hive。

可以单击 新增加一个参数。

----结束

13.5 在 Hue WebUI 使用 SparkSql 编辑器

操作场景

用户需要使用图形化界面在集群中执行 SparkSql 语句时，可以通过 Hue 完成任务。

配置 Spark2x

使用 SparkSql 编辑器之前需要先修改 Spark2x 配置。

进入 Spark2x 的全部配置页面，具体操作请参考 25.1 修改集群服务配置参数。

步骤 1 设置 Spark2x 多实例模式，搜索并修改 Spark2x 服务的以下参数：

参数名称	值
spark.thriftserver.proxy.enabled	false
spark.scheduler.allocation.file	#{conf_dir}/fairscheduler.xml

步骤 2 进入 JDBCServer2x 自定义界面，在“spark.core-site.customized.configs”参数内，添加如下两个自定义项：

表13-3 自定义参数

名称	值
hadoop.proxyuser.hue.groups	*
hadoop.proxyuser.hue.hosts	*

步骤 3 保存配置，重启 Spark2x 服务。

----结束

访问编辑器

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 在左侧导航栏单击，然后选择“SparkSql”，进入“SparkSql”。

“SparkSql”支持以下功能：

- 执行和管理 SparkSql 语句。
- 在“保存的查询”中查看当前访问用户已保存的 SparkSql 语句。
- 在“查询历史记录”中查看当前访问用户执行过的 SparkSql 语句。

----结束

执行 SparkSql 语句

在“Database”右侧下拉列表选择一个 SparkSql 中的数据库，默认数据库为“default”。

系统将自动显示数据库中的所有表。可以输入表名关键字，系统会自动搜索包含此关键字的全部表。

步骤 1 单击指定的表名，可以显示表中所有的列。

光标移动到表所在的行，单击 可以查看列的详细信息。

步骤 2 在 SparkSql 语句编辑区输入查询语句。

单击 后的三角并选择“解释”，编辑器将分析输入的查询语句是否有语法错误以及执行计划，如果存在语法错误则显示“Error while compiling statement”。

步骤 3 单击开始执行 SparkSql 语句。

说明

- 如果希望下次继续使用已输入的 SparkSql 语句，请单击保存。
- 高级查询配置：

  单击右上角的，对文件、功能、设置等信息进行配置。
- 查看快捷键：

  单击右上角的，可查看语法和键盘快捷方式信息。
- 格式化 SparkSql 语句，请单击 后的三角选择“格式”
- 删除已输入的 SparkSql 语句，请单击 后的三角选择“清除”
- 查看历史：

  单击“查询历史记录”，可查看 SparkSql 运行情况，支持显示所有语句或只显示保存的语句的运行情况。历史记录存在多个结果时，可以在输入框使用关键字进行搜索。

----结束

查看执行结果

在“SparkSql”的执行区，默认显示“查询历史记录”。

步骤 1 单击结果查看已执行语句的执行结果。

----结束

管理查询语句

单击“保存的查询”。

步骤 1 单击一条已保存的语句，系统会自动将其填充至编辑区中。

----结束

13.6 在 Hue WebUI 使用元数据浏览器

操作场景

用户需要使用图形化界面在集群中管理 Hive 的元数据，可以通过 Hue 完成任务。

元数据管理器使用介绍

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

- 查看 Hive 表的元数据

  在左侧导航栏单击表  ，单击某一表名称，界面将显示 Hive 表的元数据信息。
- 管理 Hive 表的元数据

  在 Hive 表的元数据信息界面：
  - 单击右上角的“导入”可导入数据。
  - 单击“概述”，在“属性”域可查看表文件的位置信息。

    可查看 Hive 表各列字段的信息，并手动添加描述信息，注意此处添加的描述信息并不是 Hive 表中的字段注释信息（comment）。
  - 单击“样本”可浏览数据。
- 管理 Hive 元数据表

  单击左侧列表中的➕可在数据库中根据上传的文件创建一个新表，也可手动创建一个新表。

> **⚠ 注意**
>
> Hue 界面主要用于文件、表等数据的查看与分析，禁止通过 Hue 界面对操作对象进行删除等高危管理操作。如需操作，建议在确认对业务没有影响后通过各组件的相应操作方法进行处理，例如使用 HDFS 客户端对 HDFS 文件进行操作，使用 Hive 客户端对 Hive 表进行操作。

13.7 在 Hue WebUI 使用文件浏览器

操作场景

用户需要使用图形化界面管理 HDFS 文件时，可以通过 Hue 完成任务。

> **⚠ 注意**
>
> Hue 界面主要用于文件、表等数据的查看与分析，禁止通过 Hue 界面对操作对象进行删除等高危管理操作。如需操作，建议在确认对业务没有影响后通过各组件的相应操作方法进行处理，例如使用 HDFS 客户端对 HDFS 文件进行操作，使用 Hive 客户端对 Hive 表进行操作。

访问文件浏览器

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 在左侧导航栏单击文件  。进入“文件浏览器”页面。

“文件浏览器”的“主页”默认进入当前登录用户的主目录。界面将显示目录中的子目录或文件的以下信息：

表13-4 HDFS 文件属性介绍

属性名	描述
名称	表示目录或文件的名称。
大小	表示文件的大小。
用户	表示目录或文件的属主。
组	表示目录或文件的属组。
权限	表示目录或文件的权限设置。
日期	表示目录或文件创建时间。

步骤 2 在搜索框输入关键字，系统会在当前目录自动搜索目录或文件。

步骤 3 清空搜索框的内容，系统会重新显示所有目录和文件。

----结束

执行动作

在“文件浏览器”界面，勾选一个或多个目录或文件。

步骤 1 单击“操作”，在弹出菜单选择一个操作。

- 重命名：表示重新命名一个目录或文件。
- 移动：表示移动文件，在“移至”页面选择新的目录并单击“移动”完成移动。
- 复制：表示复制选中的文件或目录。
- 更改权限：表示修改选中目录或文件的访问权限。
  - 可以为属主、属组和其他用户设置“读取”、“写”和“执行”权限。
  - “易贴”表示禁止 HDFS 的管理员、目录属主或文件属主以外的用户在目录中移动文件。
  - “递归”表示递归设置权限到子目录。
- 存储策略：表示设置目录或文件在 HDFS 中的存储策略。
- 摘要：表示查看选中的文件或目录的 HDFS 存储信息。

----结束

上传用户文件

在“文件浏览器”界面，单击“上传”。

步骤 1 在弹出的上传文件窗口中单击“选择文件”或将文件拖至窗口中，完成文件上传。

----结束

创建新文件或者目录

在“文件浏览器”界面，单击“新建”。

步骤 1 选择一个操作。

- 文件：表示创建一个文件，输入文件名后单击“创建”完成。
- 目录：表示创建一个目录，输入目录名后单击“创建”完成。

----结束

存储策略定义使用介绍

说明

若 Hue 的服务配置参数“fs_defaultFS”配置为“viewfs://ClusterX”时，不能启用存储策略定义功能。

登录 FusionInsight Manager。

步骤 1 在 FusionInsight Manager 界面，选择“系统 > 权限 > 角色 > 添加角色”：

1. 设置“角色名称”。
2. 在“配置资源权限”下选择“*待操作集群名称* >Hue”，勾选“存储策略管理员”，单击“确定”，为该角色赋予存储策略管理员的权限。

步骤 2 选择“系统 > 权限 > 用户组 > 添加用户组”，设置“组名”，单击“角色”后的“添加”，在弹出的界面选择步骤 2 创建的角色，单击“确定”将该角色添加到组中，单击“确定”完成用户组的创建。

步骤 3 选择“系统 > 权限 > 用户 > 添加用户”：

1. “用户名”填写待添加的用户名。
2. “用户类型”设置为“人机”。
3. 设置登录 Hue 的 WebUI 界面的“密码”、“确认密码”。
4. 单击“用户组”后的“添加”，在弹出的界面选择步骤 3 创建的用户组、supergroup、hadoop 和 hive 用户组，单击“确定”。
5. “主组”选择“hive”。
6. 单击“角色”后的“添加”，在弹出的界面选择步骤 2 创建的角色和 System_administrator 角色，单击“确定”。
7. 再单击“确定”，成功添加该用户。

步骤 4 使用创建的用户访问 Hue WebUI，具体操作请参考 13.2 访问 Hue 的 WebUI。

步骤 5 左侧导航栏单击文件  。进入“文件浏览器”页面。

步骤 6 勾选目录的复选框，单击页面上方的“操作”，单击“存储策略”。

步骤 7 在弹出的对话框中设置新的存储策略，单击“保存”。

----结束

13.8 在 Hue WebUI 使用作业浏览器

操作场景

用户需要使用图形化界面查看集群中所有作业时，可以通过 Hue 完成任务。

访问作业浏览器

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 单击作业  。

默认显示当前集群的所有作业。

说明

作业浏览器显示的数字表示集群中所有作业的总数。

“作业浏览器”将显示作业以下信息：

表13-5 MRS 作业属性介绍

属性名	描述
名称	表示作业的名称。
用户	表示启动该作业的用户。
类型	表示作业的类型。
状态	表示作业的状态，包含“成功”、“正在运行”、“失败”。
进度	表示作业运行进度。
组	表示作业所属组。
开始	表示作业开始时间。
持续时间	表示作业运行使用的时间。
Id	表示作业的编号，由系统自动生成。

说明

如果 MRS 集群安装了 Spark 组件，则默认会启动一个作业“Spark-JDBCServer”，用于执行任务。

----结束

搜索作业

在“作业浏览器”的搜索栏，输入指定的字符，系统会按照 ID、名称、用户自动搜索包含此关键字的全部作业。

步骤 1 清空搜索框的内容，系统会重新显示所有作业。

----结束

查看作业详细信息

在“作业浏览器”的作业列表，单击作业所在的行，可以打开作业详情。

步骤 1 在“元数据”页签，可查看作业的元数据。

说明

单击“日志”可打开作业运行时的日志。

----结束

13.9 在 Hue WebUI 使用 HBase

操作场景

用户需要使用图形化界面在集群中创建或查询 HBase 表时，可以通过 Hue 完成任务。

说明

如需在 Hue WebUI 中操作 HBase，当前 MRS 集群中必须部署 HBase 的 Thrift1Server 实例。

Thrift1Server 实例默认不会安装，用户可在创建自定义类型的 MRS 集群时，选择 HBase 组件并通过调整集群自定义拓扑，添加 Thrift1Server 实例，详情请参考“用户指南> 配置集群> 购买自定义拓扑集群”。

如果当前集群支持手动添加服务，也可以在首次添加 HBase 服务时，选择部署 Thrift1Server 实例，服务添加成功后，需重启 Hue 服务，详情请参考“用户指南> 管理集群> 组件管理> 管理服务操作”中的“添加服务”。

访问作业浏览器

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 单击 HBase，进入“HBase Browser”页面。

----结束

新建 HBase 表

访问 Hue WebUI。

步骤 1 单击 HBase，进入“HBase Browser”页面。

步骤 2 单击右侧“新建表”按钮，输入表名和列族参数，单击“提交”，完成 HBase 表创建。

----结束

查询 HBase 表数据

访问 Hue WebUI。

步骤 1 单击 HBase，进入“HBase Browser”页面。

步骤 2 单击需要查询的 HBase 表。可在上方的搜索栏后单击健值，对 HBase 表进行查询。

----结束

13.10 Hue WebUI 使用 HetuEngine SQL 编辑器

操作场景

用户需要使用图形化界面在集群中执行 HetuEngine 语句时，可以通过 Hue 完成任务。

前提条件

- 需要 MRS 集群已安装 HetuEngine 组件并添加 HSFabric 实例。HSFabric 实例的新增，删除，迁移和端口的修改，都需要重启 Hue 服务。
- 已在集群中创建 HetuEngine 管理员“人机”用户，如 **hetu_user**，可参考 10.3 创建 HetuEngine 用户。启用 Ranger 鉴权的集群需根据业务需求为该 **hetu_user** 添加 Ranger 权限，可参考 20.14 添加 HetuEngine 的 Ranger 访问权限策略。
- 已创建计算实例并运行正常，可参考 10.4 创建 HetuEngine 计算实例。

访问编辑器

访问 Hue WebUI。

步骤 1 在左侧导航栏单击 </>，然后选择“HetuEngine”，进入“HetuEngine”。

“HetuEngine”支持以下功能：

- 执行和管理 HetuEngine SQL 语句。
- 在“保存的查询”中查看当前访问用户已保存的 HetuEngine SQL 语句。
- 在“查询历史记录”中查看当前访问用户执行过的 HetuEngine SQL 语句。

----结束

执行 HetuEngine SQL 语句

在 HetuEngine 语句编辑区输入 SQL 语句。

步骤 1 单击 ▶ 开始执行 HetuEngine SQL 语句。

说明

- Hue 上执行 HetuEngine 语句一次只支持单条语句执行。
- Hue 上执行 HetuEngine 默认使用 catalog=hive，schema=default。如果需要切换可使用 SQL 语法 **use** <*catalog*>.<*schema*>进行切换。
- 如果希望下次继续使用已输入的 HetuEngine SQL 语句，请单击 保存。
- Hue 界面不支持指定租户运行任务，会在用户关联的租户列表中随机选择一个默认租户运行任务。
- 查看历史：

  单击“查询历史记录”，可查看 HetuEngine SQL 运行情况，支持显示所有语句或只显示保存的语句的运行情况。历史记录存在多个结果时，可以在输入框使用关键字进行搜索。

----结束

查看执行结果

在“HetuEngine”的执行区，默认显示“查询历史记录”。

步骤 1 单击结果查看已执行语句的执行结果。

说明

Hue 暂不支持大数据量展示，当 SQL 查询结果加载过量时可能出现页面卡顿，部分数据不显示等情况。目前建议查询结果加载不超过 5000 行。

----结束

13.11 典型场景

13.11.1 HDFS on Hue

Hue 提供了文件浏览器功能，使用户可以通过界面图形化的方式使用 HDFS。

注意

Hue 界面主要用于文件、表等数据的查看与分析，禁止通过 Hue 界面对操作对象进行删除等高危管理操作。如需操作，建议在确认对业务没有影响后通过各组件的相应操作方法进行处理，例如使用 HDFS 客户端对 HDFS 文件进行操作，使用 Hive 客户端对 Hive 表进行操作。

文件浏览器使用介绍

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

然后单击  ，进入“文件浏览器”页面。您可以进行以下操作。

- 查看文件和目录

  默认显示登录用户的目录及目录中的文件，可查看目录或文件的“名称”、“大小”、“用户”、“组”、“权限”和“日期”信息。

  单击文件名，可查看文本文件的文本信息或二进制数据。支持编辑文件内容。

  如果文件和目录数量比较多，可以在搜索框输入关键字，搜索特定的文件或目录。

- 创建文件或目录

  单击右上角的“新建”，选择“文件”创建文件，选择“目录”创建目录。

- 管理文件或目录

  勾选文件或目录的复选框，单击“操作”，选择“重命名”、“移动”、“复制”和“更改权限”等，实现文件或目录的重命名、移动、复制、更改权限等功能。

- 上传文件

  单击右上角的“上传”，单击“选择文件”或将文件拖至窗口中可进行文件上传。

存储策略定义使用介绍

说明

若 Hue 的服务配置参数“fs_defaultFS”配置为“viewfs://ClusterX”时，不能启用存储策略定义功能。

存储策略定义在 Hue 的 WebUI 界面上分为两大类：

- 静态存储策略

  当前存储策略

  根据 HDFS 的文档访问频率、重要性，为 HDFS 目录指定存储策略，例如 ONE_SSD、ALL_SSD 等，此目录下的文件可被迁移到相应存储介质上保存。

- 动态存储策略

  为 HDFS 目录设置规则，系统可以根据文件的最近访问时间、最近修改时间自动修改存储策略、修改文件副本数、移动文件目录，详细的介绍请参见 13.11.2 配置 HDFS 冷热数据迁移。

  在 Hue 的 WebUI 界面设置动态存储策略之前，需先在 Manager 界面设置冷热数据迁移的 CRON 表达式，并启动自动冷热数据迁移特性。

  操作方法为：

  修改 HDFS 服务的 NameNode 的如下参数值。参数修改方法请参考 25.1 修改集群服务配置参数。

参数	描述	取值示例
dfs.auto.data.mover.enable	表示是否启用自动冷热数据迁移特性。默认值是“false”。	true
dfs.auto.data.mover.cron.expression	HDFS 执行冷热数据迁移的 CRON 表达式，用于控制数据迁移操作的开始时间。仅当“dfs.auto.data.mover.enable”设置为“true”时才有效。默认值“0 * * * *”表示在每个整点执行任务。	0 * * * *

修改参数“dfs.auto.data.mover.cron.expression”时，表达式介绍如表 13-6 所示。支持“*”表示连续的时间段。

表13-6 执行表达式参数解释

列	说明
第 1 列	分钟，参数值为 0～59。
第 2 列	小时，参数值为 0～23。
第 3 列	日期，参数值为 1～31。
第 4 列	月份，参数值为 1～12。
第 5 列	星期，参数值为 0～6，0 表示星期日。

存储策略定义在 WebUI 界面上的操作如下：

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。

在 FusionInsight Manager 界面，选择“系统 > 权限 > 角色 > 添加角色”：

1. 设置“角色名称”。
2. 在“配置资源权限”下选择“*待操作集群名称* >Hue”，勾选“存储策略管理员”，单击“确定”，为该角色赋予存储策略管理员的权限。

步骤 2 选择“系统 > 权限 > 用户组 > 添加用户组”，设置“组名”，单击“角色”后的“添加”，在弹出的界面选择步骤 2 创建的角色，单击“确定”将该角色添加到组中，单击“确定”完成用户组的创建。

步骤 3 选择“系统 > 权限 > 用户 > 添加用户”：

1. “用户名”填写待添加的用户名。
2. “用户类型”设置为“人机”。
3. 设置登录 Hue 的 WebUI 界面的“密码”、“确认密码”。
4. 单击“用户组”后的“添加”，在弹出的界面选择步骤 3 创建的用户组、supergroup、hadoop 和 hive 用户组，单击“确定”。
5. “主组”选择“hive”。
6. 单击“角色”后的“添加”，在弹出的界面选择步骤 2 创建的角色和 System_administrator 角色，单击“确定”。
7. 再单击“确定”，成功添加该用户。

步骤 4 使用创建的用户访问 Hue WebUI。

步骤 5 左侧导航栏单击文件  。进入“文件浏览器”页面。

步骤 6 勾选目录的复选框，单击页面上方的“操作”，单击“存储策略”。

步骤 7 在弹出的对话框中设置新的存储策略，单击“确定”。

- 在“静态存储策略”页签设置静态存储策略，单击“保存”。
- 在“动态存储策略”页签可创建、删除、修改动态存储策略，详细的参数介绍如表 13-7 所示。

表13-7 动态存储策略参数介绍

分类	参数	说明
规则	文件最近访问时间	按照该文件最近一次访问时间。
	文件最近修改时间	按照该文件最近一次修改时间。
操作	修改副本数	设置文件副本数。
	修改存储策略	修改存储策略，包括 HOT、WARM、COLD、ONE_SSD、

分类	参数	说明
		ALL_SSD。
	移动到目录	移动该文件到其他目录。

说明

- 设置规则需要用户充分考虑合理性，例如多条规则之间是否有冲突，是否会对系统造成破坏等。
- 一个目录设置多个规则和动作时，规则被先触发的放在规则/动作列表的下面，规则被后触发的放在规则/动作列表的上面，避免动作反复执行。
- 系统每个小时整点扫描动态存储策略指定的目录下的文件是否符合规则，如果满足，则触发执行动作。执行日志记录在主 NameNode 的“/var/log/Bigdata/hdfs/nn/hadoop.log”目录下。

----结束

典型场景

通过 Hue 界面对 HDFS 以文本或二进制查看和编辑文件的操作如下：

查看文件

访问 Hue WebUI。

步骤 1 左侧导航栏单击文件  。进入“文件浏览器”页面。

步骤 2 单击需要查看的文件名。

步骤 3 单击“以二进制格式查看”，可以切换视图从文本到二进制；单击“以文本格式查看”，可以切换视图从二进制到文本。

编辑文件

单击“编辑文件”，显示文件内容可编辑。

步骤 4 单击“保存”或“另存为”保存文件。

----结束

13.11.2 配置 HDFS 冷热数据迁移

配置场景

冷热数据迁移工具根据配置的策略移动 HDFS 文件。配置策略是条件或非条件规则的集合。如果规则匹配文件集，则该工具将对该文件执行一组行为操作。

冷热数据迁移工具支持以下规则和行为。

- 迁移规则：
  - 根据文件的最后访问时间迁移数据

- 根据年龄时间迁移数据（修改时间）
- 无条件迁移数据

表13-8 规则条件标签

条件标签	描述
<age operator="lt">	定义年龄/修改时间的条件。
<atime operator="gt">	定义访问时间的条件。

说明

对于手动迁移规则，不需要条件。

- 行为列表：
  - 将存储策略设置为给定的数据层名称
  - 迁移到其他文件夹
  - 为文件设置新的副本数
  - 删除文件
  - 设置节点标签（NodeLabel）

表13-9 行为类型

行为类型	描述	所需参数
MARK	为确定数据的冷热度并设置相应的数据存储策略。	<param> <name>targettier</name> <value>STORAGE_POLICY</value> <param>
MOVE	为设置数据存储策略或 NodeLabel 并调用 HDFS Mover 工具。	<param> <name>targettier</name> <value>STORAGE_POLICY</value> <param> <param> <name>targetnodelabels</name> <value>SOME_EXPRESSION</value> <param> **说明** 用户可以配置其中任一参数或两者都配置。
SET_REPL	为文件设置新的副本数。	<param> <name>replcount</name> <value>INTEGER</value> <param>

行为类型	描述	所需参数
MOVE_TO_FOLDER	将文件移动到目标文件夹。如果“overwrite”参数为“true”，则目标路径将被覆盖。	<param> <name>target</name> <value>PATH</value> <param> <param> <name>overwrite</name> <value>true/false</value> <param> 说明 “overwrite”是可选参数，如果未配置，则默认值为“false”。
DELETE	删除文件。	NA

配置描述

必须定期调用迁移工具，并需要在客户端的“hdfs-site.xml”文件中进行以下配置。

表13-10 参数描述

参数	描述	默认值
dfs.auto-data-movement.policy.class	用于指定默认的数据迁移策略。 说明 当前只支持DefaultDataMovementPolicy。	com.xxx.hadoop.hdfs.datamovement.policy.DefaultDataMovementPolicy
dfs.auto.data.mover.id	冷热数据迁移输出（行为状态）文件的名称。	当前系统时间（毫秒）
dfs.auto.data.mover.output.dir	冷热数据迁移输出在 HDFS 中的目录名称。迁移工具将在此处写入行为状态文件。	/system/datamovement

DefaultDataMovementPolicy 拥有配置文件“default-datamovement-policy.xml”。用户需要定义所有基于 age/accessTime 的规则和在此文件中采取的行为操作，此文件必须存储在客户端的 classpath 中。

如下为“default-datamovement-policy.xml”配置文件的示例：

```
<policies>
  <policy>
    <fileset>
      <file>
        <name>/opt/data/1.txt</name>
      </file>
```

```
    <file>
      <name>/opt/data/*/subpath/</name>
      <excludes>
        <name>/opt/data/some/subpath/sub1</name>
      </excludes>
    </file>
  </fileset>
  <rules>
    <rule>
      <age>2w</age>
      <action>
        <type>MOVE</type>
        <params>
          <param>
            <name>targettier</name>
            <value>HOT</value>
          </param>
        </params>
      </action>
    </rule>
  </rules>
 </policy>
</policies>
```

说明

在策略，规则和行为操作中使用的标签中，可以添加其他属性，例如“name”可用于管理用户界面（例如：Hue UI）和工具输入 xml 之间的映射。

示例： <policy name="Manage_File1">

标签（Tag）说明如下：

表13-11 配置标签（Tag）描述

标签（Tag）名称	描述	是否可重复使用
<policy>	定义单一策略。 • idempotent 属性：指定当策略中有多个规则时，如果满足当前规则，是否检查下一个规则。 示例：<policy name ="policy2" idempotent ="true">。 其默认值为“true”，表示其中的规则和行为操作是幂等的，可以继续检查下一个规则。如果值为“false”，则将在当前规则处停止评估。 • hours_allowed 属性：配置是否根据系统时间执行策略评估。 hours_allowed 的值是以逗号分隔的数字，范围从 0 到 23，表示系统时间。 示例：<policy name ="policy1" hours_allowed ="2-6,13-14"> 如果当前系统时间在配置的范围内，则继续评	Yes

标签（Tag）名称	描述	是否可重复使用
	估。否则，将跳过评估。 说明 在输入 XML 中，每个文件仅支持一个策略。因此，文件中的所有规则必须由一个策略标签覆盖。	
<fileset>	为每个策略定义一组文件/文件夹。	No （在 policy 标签内）
<file>	定义文件和/或文件夹在<file>标签内被配置一个或者多个<name>标签。文件/文件夹名支持 POSIX globs 配置。	Yes （在 fileset 标签内）
<excludes>	在<file>标签内定义该标签，该标签下可以包含多个<name>标签，在<file>标签中配置的文件或文件夹范围下，<name>标签所包含的文件或文件夹将会被排除。文件或文件夹名支持 POSIX globs 配置。	No （在 fileset 标签内）
<rules>	针对策略定义多个规则。	No （在 policy 标签内）
<rule>	定义单一规则。	Yes （在 rules 标签内）
<age>or<atime>	定义在<fileset>中定义的文件的 age/accesstime。策略将匹配该 age。age 可以用 [num]y[num]m[num]w[num]d[num]h 的格式表示。其中 num 表示数字。 其中字母的意思如下： * y--年（一年是 365 天）。 * m--月（一个月是 30 天）。 * w--周（一周是 7 天）。 * d--天。 * h--小时。 可以单独使用年，月，周，天或小时，也可以将时间组合。比如，1y2d 表示 1 年零 2 天或者 367 天。 如果没有单位（即数字后面没有任何上述字母），默认单位为天。 说明 用户可以在<age>和<atime>标签中配置“gt”（greater）和“lt”（less），默认运算符为“gt”。 示例：<age operator="lt">	No （在 rule 标签内）
<action>	如果规则匹配，这个标签定义了要执行的 action。	No (在 rule 标

标签（Tag）名称	描述	是否可重复使用
		签内)
<type>	定义了 action 类型。当前支持的 action 类型是 MOVE 和 MARK。	No (在 action 标签内)
<**params**>	定义与每个 action 相关的参数。	No (在 action 标签内)
<param>	定义单个使用<name>和<value>标签的 name-value 格式参数。 对于 MARK 和 MOVE，只支持参数名“targettier”。该参数表示如果满足 age 规则，则指定数据存储策略。 如果多个 param 中具有相同 name 的参数，则采用第一个参数值。 对于 MARK，支持的“targettier”参数值为“ALL_SSD”，“ONE_SSD”，“HOT”，“WARM”，“COLD”。 对于 MOVE，支持的“targettier”参数值为“ALL_SSD”，“ONE_SSD”，“HOT”，“WARM”和“COLD”。	Yes (在 params 标签内).

对于在<file>标签下的文件/文件夹使用 FileSystem#globStatus API，对于其他的使用 GlobPattern 类（被 GlobFilter 使用）。参照支持的 API 的细节。例如，对于 globStatus，“/opt/hadoop/*”将匹配“/opt/hadoop”文件夹下的一切。“/opt/*/hadoop”将匹配/“opt”目录的子目录下的所有 hadoop 文件夹。

对于 globStatus，分别匹配每个路径组件的 glob 模式，而对于其他的，直接匹配 glob 模式。

MRS 3.2.0 之前版本：
https://hadoop.apache.org/docs/r3.1.1/api/org/apache/hadoop/fs/FileSystem.html#globStatus(org.apache.hadoop.fs.Path)

MRS 3.2.0 及之后版本：
https://hadoop.apache.org/docs/r3.3.1/api/org/apache/hadoop/fs/FileSystem.html#globStatus(org.apache.hadoop.fs.Path)

Glob	Name	Matches
*	*asterisk*	Matches zero or more characters
?	*question mark*	Matches a single character
[ab]	*character class*	Matches a single character in the set {a, b}
[^ab]	*negated character class*	Matches a single character that is not in the set {a, b}
[a-b]	*character range*	Matches a single character in the (closed) range [a, b], where a is lexicographically less than or equal to b
[^a-b]	*negated character range*	Matches a single character that is not in the (closed) range [a, b], where a is lexicographically less than or equal to b
{a,b}	*alternation*	Matches either expression a or b
\c	*escaped character*	Matches character c when it is a metacharacter

行为操作示例

- MARK

```
<action>
  <type>MARK</type>
  <params>
    <param>
      <name>targettier</name>
      <value>HOT</value>
    </param>
  </params>
</action>
```

- MOVE

```
<action>
  <type>MOVE</type>
  <params>
    <param>
      <name>targettier</name>
      <value>HOT</value>
    </param>
    <param>
      <name>targetnodelabels</name>
      <value>SOME_EXPRESSION</value>
    </param>
  </params>
</action>
```

- SET_REPL

```
<action>
  <type>SET_REPL</type>
  <params>
    <param>
      <name>replcount</name>
      <value>5</value>
    </param>
  </params>
</action>
```

- MOVE_TO_FOLDER

```
<action>
  <type>MOVE_TO_FOLDER</type>
  <params>
    <param>
      <name>target</name>
      <value>path</value>
    </param>
    <param>
      <name>overwrite</name>
      <value>true</value>
    </param>

  </params>
</action>
```

说明

MOVE_TO_FOLDER 操作只是将文件路径更改为目标文件夹，不会更改块位置。如果想要移动块，则需要配置一个独立的 move 策略。

- DELETE

```
<action>
  <type>DELETE</type>
</action>
```

说明

- 在编写 xml 文件时，用户应该注意行为操作的配置和顺序。冷热数据迁移工具按照输入 xml 中给定的顺序执行规则。
- 如果只希望运行基于 atime/age 的一个规则，则按照时间逆序排列，且将 idempotent 属性设置为 false。
- 如果为文件集配置删除操作，则在删除操作后不能再配置其他规则。
- 支持使用"-fs"选项，用于指定客户端默认的文件系统地址。

审计日志

冷热数据迁移工具支持以下操作的审计日志。

- 工具启动状态
- 行为类型及参数详细信息和状态
- 工具完成状态

对于启用审计日志工具，在“<HADOOP_CONF_DIR>/log4j.property”文件中添加以下属性。

```
autodatatool.logger=INFO, ADMTRFA
autodatatool.log.file=HDFSAutoDataMovementTool.audit
log4j.logger.com.xxx.hadoop.hdfs.datamovement.HDFSAutoDataMovementTool.audit=${auto
datatool.logger}
log4j.additivity.com.xxx.hadoop.hdfs.datamovement.HDFSAutoDataMovementTool-
audit=false
log4j.appender.ADMTRFA=org.apache.log4j.RollingFileAppender
log4j.appender.ADMTRFA.File=${hadoop.log.dir}/${autodatatool.log.file}
log4j.appender.ADMTRFA.layout=org.apache.log4j.PatternLayout
log4j.appender.ADMTRFA.layout.ConversionPattern=%d{ISO8601} %p %c: %m%n
```

```
log4j.appender.ADMTRFA.MaxBackupIndex=10
log4j.appender.ADMTRFA.MaxFileSize=64MB
```

说明

具体请参考“<HADOOP_CONF_DIR>/log4j_autodata_movment_template.properties”文件。

13.11.3 Hive on Hue

Hue 提供了 Hive 图形化管理功能，使用户可以通过界面的方式查询 Hive 的不同数据。

查询编辑器使用介绍

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

在左侧导航栏单击编辑器，然后选择“Hive”，进入“Hive”。

- 执行 Hive HQL 语句

  在左侧选中目标数据库，也可通过单击右上角的 default，输入目标数据库的名称以搜索目标数据库。

  在文本编辑框输入 Hive HQL 语句，单击 或者按“Ctrl+Enter”，运行 HQL 语句，执行结果将在“结果”页签显示。

- 分析 HQL 语句

  在左侧选中目标数据库，在文本编辑框输入 Hive HQL 语句，单击 编译 HQL 语句并显示语句是否正确，执行结果将在文本编辑框下方显示。

- 保存 HQL 语句

  在文本编辑框输入 Hive HQL 语句，单击右上角的，并输入名称和描述。已保存的语句可以在“保存的查询”页签查看。

- 查看历史

  单击“查询历史记录”，可查看 HQL 运行情况，支持显示所有语句或只显示保存的语句的运行情况。历史记录存在多个结果时，可以在输入框使用关键字进行搜索。

- 高级查询配置

  单击右上角的，对文件、函数、设置等信息进行配置。

- 查看快捷键

  单击右上角的，可查看所有快捷键信息。

元数据浏览器使用介绍

访问 Hue WebUI。

- 查看 Hive 表的元数据

  在左侧导航栏单击表，单击某一表名称，界面将显示 Hive 表的元数据信息。

- 管理 Hive 表的元数据

在 Hive 表的元数据信息界面：

- 单击右上角的“导入”可导入数据。
- 单击“概述”，在“属性”域可查看表文件的位置信息。

  可查看 Hive 表各列字段的信息，并手动添加描述信息，注意此处添加的描述信息并不是 Hive 表中的字段注释信息（comment）。
- 单击“样本”可浏览数据。

- 管理 Hive 元数据表

  单击左侧列表中的 ➕ 可在数据库中根据上传的文件创建一个新表，也可手动创建一个新表。

⚠ 注意

Hue 界面主要用于文件、表等数据的查看与分析，禁止通过 Hue 界面对操作对象进行删除等高危管理操作。如需操作，建议在确认对业务没有影响后通过各组件的相应操作方法进行处理，例如使用 HDFS 客户端对 HDFS 文件进行操作，使用 Hive 客户端对 Hive 表进行操作。

典型场景

通过 Hue 界面对 Hive 进行创建表的操作如下：

单击 Hue 的 WebUI 界面左上角的 </>，选择要操作的 Hive 实例，进入 Hive 命令的执行页面。

步骤 1 在命令输入框内输入一条 HQL 语句，例如：

create table hue_table(id int,name string,company string) row format delimited fields terminated by ',' stored as textfile;

单击 ▶ 执行 HQL。

步骤 2 在命令输入框内输入：

show tables;

单击 ▶，查看“结果”中有创建的表 hue_table。

----结束

13.11.4 Oozie on Hue

Hue 提供了 Oozie 作业管理器功能，使用户可以通过界面图形化的方式使用 Oozie。

> **⚠ 注意**
>
> Hue 界面主要用于文件、表等数据的查看与分析，禁止通过 Hue 界面对操作对象进行删除等高危管理操作。如需操作，建议在确认对业务没有影响后通过各组件的相应操作方法进行处理，例如使用 HDFS 客户端对 HDFS 文件进行操作，使用 Hive 客户端对 Hive 表进行操作。

Oozie 作业设计器使用介绍

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

在左侧导航栏单击  ，选择“Workflow”。

在作业设计器，支持用户创建 MapReduce、Java、Streaming、Fs、Ssh、Shell 和 DistCp 作业。

仪表板使用介绍

访问 Hue WebUI。

选择右上角“作业”，进入“作业浏览器”。

支持查看 Workflow、Coordinator 和 Bundles 作业的运行情况。

编辑器使用介绍

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

在左侧导航栏单击  ，然后选择“Workflow”。

支持创建 Workflow、计划和 Bundles 的操作。支持提交运行、共享、复制和导出已创建的应用。

- 每个 Workflow 可以包含一个或多个作业，形成完整的工作流，用于实现指定的业务。

  创建 Workflow 时，可直接在 Hue 的编辑器设计作业，并添加到 Workflow 中。
- 每个计划可定义一个时间触发器，用于定时触发执行一个指定的 Workflow。不支持多个 Workflow。
- 每个 Bundles 可定义一个集合，用于触发执行多个计划，使不同 Workflow 批量执行。

13.12 Hue 日志介绍

日志描述

日志路径：Hue 相关日志的默认存储路径为“/var/log/Bigdata/hue”（运行日志），“/var/log/Bigdata/audit/hue”（审计日志）。

日志归档规则：Hue 的日志启动了自动压缩归档功能，默认情况下，当“access.log”、“error.log”、“runcpserver.log”和“hue-audits.log”大小超过 5MB 的时候，会自动压缩。最多保留最近的 20 个压缩文件，压缩文件保留个数和压缩文件阈值可以配置。

表13-12 Hue 日志列表

日志类型	日志文件名	描述
运行日志	access.log	访问日志。
	error.log	错误日志。
	gsdb_check.log	gaussDB 检查日志。
	kt_renewer.log	Kerberos 认证日志。
	kt_renewer.out.log	Kerberos 认证日志的异常输出日志。
	runcpserver.log	操作记录日志。
	runcpserver.out.log	进程运行异常日志。
	supervisor.log	进程启动日志。
	supervisor.out.log	进程启动异常日志。
	dbDetail.log	数据库初始化日志
	initSecurityDetail.log	keytab 文件下载初始化日志。
	postinstallDetail.log	Hue 服务安装后工作日志。
	prestartDetail.log	Prestart 日志。
	statusDetail.log	Hue 服务健康状态日志。
	startDetail.log	启动日志。
	get-hue-ha.log	Hue HA 状态日志。
	hue-ha-status.log	Hue HA 状态监控日志。
	get-hue-health.log	Hue 健康状态日志。
	hue-health-check.log	Hue 健康检查日志。
	hue-refresh-config.log	Hue 配置刷新日志。

日志类型	日志文件名	描述
	hue-script-log.log	Manager 界面的 Hue 操作日志。
	hue-service-check.log	Hue 服务状态监控日志。
	db_pwd.log	Hue 连接 DBService 数据库密码修改日志
	modifyDBPwd_*日期*.log	-
	watch_config_update.log	参数更新日志。
审计日志	hue-audits.log	审计日志。

日志级别

Hue 提供了如表 13-13 所示的日志级别。

日志的级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表13-13 日志级别

级别	描述
ERROR	ERROR 表示系统运行的错误信息。
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

参考 25.1 修改集群服务配置参数进入 Hue 服务“全部配置”页面。

步骤 2 在左侧导航栏选择需修改的角色所对应的“日志”菜单。

步骤 3 在右侧选择所需修改的日志级别。

步骤 4 保存配置，在弹出窗口中单击“确定”使配置生效。

步骤 5 重新启动配置过期的服务或实例以使配置生效。

----结束

日志格式

Hue 的日志格式如下所示：

表13-14 日志格式

日志类型	格式	示例
运行日志	<dd-MM-yy HH:mm:ss,SSS><日志事件的发生位置><log level><log 中的 message>	[03/Nov/2014 11:57:19] middleware	INFO	Unloading MimeTypeJSFileFixStreamingMiddleware.
	<Log Level><时间格式><yyyy-MM-dd HH:mm:ss,SSS><日志事件的发生位置><log 中的 message>	INFO : CST 2014-11-06 11:22:52 hue-ha-status.sh : update 4 <= 15:myHostName=10.0.0.250 ACTIVE=10.0.0.250
审计日志	<UserName><yyyy-MM-dd HH:mm:ss,SSS><审计操作描述><资源参数><url><是否允许><审计操作><ip 地址>	{"username": "admin", "eventTime": "2014-11-06 10:28:34", "operationText": "Successful login for user: admin", "service": "accounts", "url": "/accounts/login/", "allowed": true, "operation": "USER_LOGIN", "ipAddress": "10.0.0.250"}

13.13 Hue 常见问题

13.13.1 使用 IE 浏览器在 Hue 中执行 HQL 失败

问题

遇到使用 IE 浏览器在 Hue 中访问 Hive Editor 并执行所有 HQL 失败，界面提示“There was an error with your query.”，如何解决并正常执行 HQL？

回答

IE 浏览器存在功能问题，不支持在 307 重定向中处理含有 form data 的 AJAX POST 请求，建议更换兼容的浏览器，例如 Google Chrome 浏览器。

13.13.2 使用 Hive 输入 use database 语句失效

问题

使用 Hive 的时候，在输入框中输入了 **use database** 的语句切换数据库，重新在输入框内输入其他语句，为什么数据库没有切换过去？

回答

在 Hue 上使用 Hive 有区别于用 Hive 客户端使用 Hive，Hue 界面上有选择数据库的按钮，当前 SQL 执行的数据库以界面上显示的数据库为准。与此相关的还有设置参数等 session 级别的一次性操作，都应该使用界面功能进行设置，不建议使用输入语句进行操作。若是必须使用输入语句进行操作，需保证所有语句在同一个输入框内。

13.13.3 使用 Hue WebUI 访问 HDFS 文件失败

问题

在使用 Hue WebUI 访问 HDFS 文件时，报如下图所示无法访问的错误提示，该如何处理？

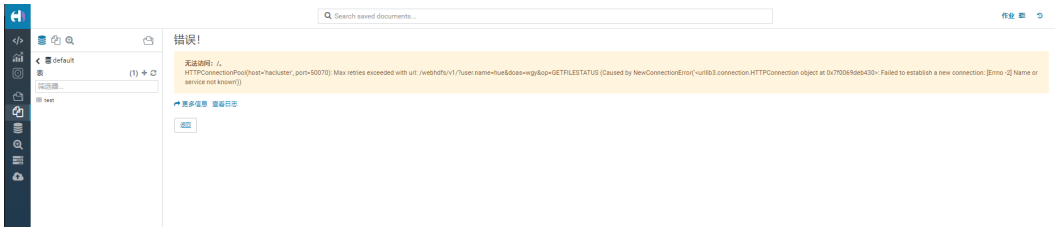

回答

1. 查看登录 Hue WebUI 的用户是否具有“hadoop”用户组权限。
2. 查看 HDFS 服务是否安装了 HttpFS 实例且运行正常。如果未安装 HttpFS 实例，需手动安装并重启 Hue 服务。

13.13.4 在 Hue 页面上传大文件失败

问题

通过 Hue 页面上传大文件时，上传失败。

回答

1. 不建议使用 Hue 文件浏览器上传大文件，大文件建议使用客户端通过命令上传。
2. 如果必须使用 Hue 上传，参考以下步骤修改 Httpd 的参数：
   a. 以 **omm** 用户登录主管理节点。
   b. 执行以下命令编辑“httpd.conf”配置文件。
      vi $BIGDATA_HOME/om-server/Apache-httpd-*/conf/httpd.conf
   c. 搜索 21201，在</VirtualHost>配置中加上“RequestReadTimeout handshake=0 header=0 body=0”，如下所示。

```
...
<VirtualHost *:21201>
    ServerName https://10.112.16.93:21201
    AllowEncodedSlashes On
    SSLProxyEngine On
    ProxyRequests Off
    TraceEnable off
```

```
   ProxyTimeout  1200
   RewriteEngine on
   RewriteMap proxylist dbm:${BIGDATA_ROOT_HOME}/om-server_*/Apache-httpd-
*/conf/proxylist.dbm

   RewriteRule ^(\/.*)$  ${proxylist:/Hue/Hue/21201}$1
[E=TARGET_PATH:$1,L,P]

   Header edit Location
^(?!https://10.112.16.93:20009|https://10.112.16.93:21201)http[s]?://[^/]*
(.*)$  https://10.112.16.93:21201$1

   ProxyPassReverseCookiePath / / interpolate

   SSLEngine On
   SSLProxyProtocol  All +TLSv1.2 -SSLv2 -SSLv3 -TLSv1 -TLSv1.1
   SSLProtocol ALL +TLSv1.2 -SSLv2 -SSLv3 -TLSv1 -TLSv1.1
   SSLCipherSuite ECDHE-RSA-AES256-GCM-SHA384:ECDHE-ECDSA-AES256-GCM-
SHA384:ECDHE-RSA-AES128-GCM-SHA256:ECDHE-ECDSA-AES128-GCM-SHA256:DHE-DSS-
AES256-GCM-SHA384:DHE-RSA-AES256-GCM-SHA384:DHE-DSS-AES128-GCM-SHA256:DHE-
RSA-AES128-GCM-SHA256
   SSLProxyCheckPeerName off
   SSLProxyCheckPeerCN off
   SSLCertificateFile "${BIGDATA ROOT HOME}/om-server */Apache-httpd-
*/conf/security/proxy_ssl.cert"
   SSLCertificateKeyFile "${BIGDATA ROOT HOME}/om-server */Apache-httpd-
*/conf/security/server.key"
   SSLProxyCACertificateFile ${BIGDATA_ROOT_HOME}/om-server_*/apache-
tomcat-*/conf/security/tomcat.crt
   SSLCertificateChainFile "${BIGDATA_ROOT_HOME}/om-server_*/Apache-httpd-
2.4.39/conf/security/proxy_chain.cert"
   RequestReadTimeout handshake=0 header=0 body=0
</VirtualHost>
...
```

d. 执行 **pkill -9 httpd** 命令结束 httpd 进程，并等待自动重启 httpd。

13.13.5 集群未安装 Hive 服务时 Hue 原生页面无法正常显示

问题

集群没有安装 Hive 服务时，Hue 服务原生页面显示空白。

回答

MRS 3.x 版本存在 Hue 依赖 Hive 组件，如果出现此情况，首先需要检查当前集群是否安装了 Hive 组件，如果没有，需要安装 Hive。

13.13.6 访问 Hue 原生页面时间长，文件浏览器报错 Read timed out

问题

访问 Hue 原生页面时页面加载时间较长，访问 Hue 的 HDFS 文件浏览器报错 Read timed out，如何解决。

回答

检查 HDFS 服务中是否安装 Httpfs 实例。

- 否，请联系运维人员处理。
- 是，重启 HttpFS 实例解决。

14 使用 IoTDB

14.1 从零开始使用 IoTDB

IoTDB 是针对时间序列数据收集、存储与分析一体化的数据管理引擎。它具有体量轻、性能高、易使用的特点，支持对接 Hadoop 与 Spark 生态，适用于工业物联网应用中海量时间序列数据高速写入和复杂分析查询的需求。

背景信息

假定某某集团旗下有 3 个生产线，每个生产线上有 5 台设备，传感器会实时采集这些设备的指标数据（例如温度、速度、运行状态等），如图 14-1 所示。使用 IoTDB 存储并管理这些数据的业务操作流程为：

1. 创建存储组“root.集团名称”以表示该集团。
2. 创建时间序列，用于存储具体设备传感器对应的指标数据。
3. 模拟传感器，录入指标数据。
4. 使用 SQL 查询指标数据信息。
5. 业务结束后，删除存储的数据。

图14-1 数据结构

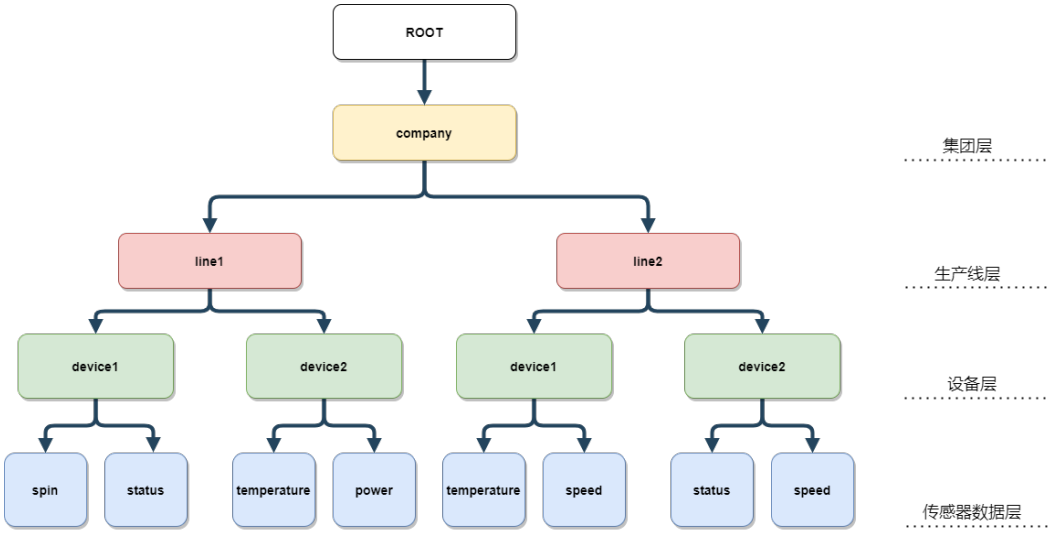

操作步骤

登录客户端。

1. 以客户端安装用户登录安装客户端的节点，执行以下命令切换到客户端安装目录，例如客户端安装目录为“/opt/client”。

   cd /opt/client

2. 执行以下命令配置环境变量。

   source bigdata_env

3. 首次登录 IoTDB 客户端前需执行以下步骤生成 SSL 客户端证书：

   a. 执行以下命令生成客户端 SSL 证书：

      keytool -noprompt -import -alias myservercert -file ca.crt -keystore truststore.jks

      执行该命令后需输入一个自定义密码。

   b. 将生成的“truststore.jks”文件拷贝到“*客户端安装目录*/IoTDB/iotdb/conf”目录下：

      cp truststore.jks *客户端安装目录*/**IoTDB/iotdb/conf**

4. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户，当前用户需要具有创建 IoTDB 表的权限，可参考 14.5 IoTDB 权限管理。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

   kinit *MRS 集群用户*

   例如：

   kinit iotdbuser

步骤 1 执行以下命令，切换 IoTDB 客户端运行脚本所在目录。

cd /opt/client/IoTDB/iotdb/sbin

步骤 2 集群未启用 Kerberos 认证（普通模式）需先调用“alter-cli-password.sh”脚本修改默认用户 **root** 的默认密码：

sh alter-cli-password.sh *IoTDBServer 实例节点 IP RPC 端口*

说明

- IoTDBServer 实例节点 IP 地址可在 Manager 界面，选择“集群 > 服务 > IoTDB > 实例”查看。
- IoTDBServer RPC 端口可在参数“IOTDB_SERVER_RPC_PORT”中自行配置。默认端口如下：
- 开源端口默认值为：6667
- 定制端口默认值为：22260

  端口定制/开源区分：创建 LTS 版本类型集群时，可以选择“组件端口”为“开源”或是“定制”，选择“开源”使用开源端口，选择“定制”使用定制端口。
- **root** 用户初始密码 MRS 3.3.0 之前版本为“root”，MRS 3.3.3.0 及之后版本为“Iotdb@123”。
- 修改的用户密码字符长度 MRS 3.3.0 之前版本至少为 4 位，MRS 3.3.0 及之后版本至少为 8 位，且不能包含空格。

步骤 3 执行以下命令登录客户端。

./start-cli.sh -h *IoTDBServer 实例节点 ip* **-p** *IoTDBServer RPC 端口*

IoTDBServer RPC 端口可在参数“IOTDB_SERVER_RPC_PORT”中自行配置。

运行该命令后，根据实际需求指定业务用户名（集群未启用 Kerberos 认证（普通模式）使用 **root** 用户登录）：

- 指定业务用户名，则输入“yes”，并根据提示输入业务用户名和对应的业务用户密码：

- 不指定业务用户名，则输入“no”；此时，则使用步骤 1.4 中的用户执行后续操作：

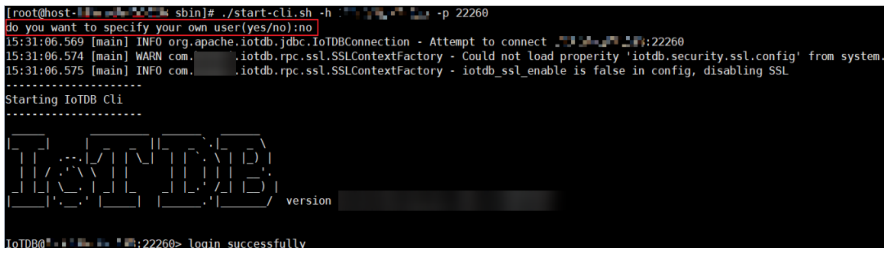

- 输入其它，则退出登录：

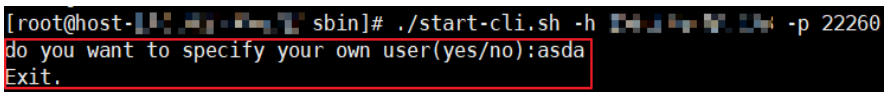

步骤 4 根据图 14-1 创建存储组/数据库（MRS 3.3.0 及之后版本）“root.company”。

set storage group to root.company;

步骤 5 创建对应的时间序列，用于表示生产线下对应设备的传感器。

create timeseries root.company.line1.device1.spin WITH DATATYPE=FLOAT, ENCODING=RLE;

create timeseries root.company.line1.device1.status WITH DATATYPE=BOOLEAN, ENCODING=PLAIN;

create timeseries root.company.line1.device2.temperature WITH DATATYPE=FLOAT, ENCODING=RLE;

create timeseries root.company.line1.device2.power WITH DATATYPE=FLOAT, ENCODING=RLE;

create timeseries root.company.line2.device1.temperature WITH DATATYPE=FLOAT, ENCODING=RLE;

create timeseries root.company.line2.device1.speed WITH DATATYPE=FLOAT, ENCODING=RLE;

create timeseries root.company.line2.device2.speed WITH DATATYPE=FLOAT, ENCODING=RLE;

create timeseries root.company.line2.device2.status WITH DATATYPE=BOOLEAN, ENCODING=PLAIN;

步骤 6 向时间序列中加入数据。

insert into root.company.line1.device1(timestamp, spin) values (now(), 6684.0);

insert into root.company.line1.device1(timestamp, status) values (now(), false);

insert into root.company.line1.device2(timestamp, temperature) values (now(), 66.7);

insert into root.company.line1.device2(timestamp, power) values (now(), 996.4);

insert into root.company.line2.device1(timestamp, temperature) values (now(), 2684.0);

insert into root.company.line2.device1(timestamp, speed) values (now(), 120.23);

insert into root.company.line2.device2(timestamp, speed) values (now(), 130.56);

insert into root.company.line2.device2(timestamp, status) values (now(), false);

步骤 7 查询 1 号生产线下所有设备指标。

select * from root.company.line1.;**

```
+----------------------------+-----------------------------+--------------------
-------------+-----------------------------------+-----------------------------
--+
|
Time|root.company.line1.device1.spin|root.company.line1.device1.status|root.company
.line1.device2.temperature|root.company.line1.device2.power|
+----------------------------+-----------------------------+--------------------
-------------+-----------------------------------+-----------------------------
--+
|2021-06-17T11:29:08.131+08:00|                       6684.0|
```

```
null|                              null|                         null|
|2021-06-17T11:29:08.220+08:00|                        null|
false|                              null|                          null|
|2021-06-17T11:29:08.249+08:00|                        null|
null|                              66.7|                         null|
|2021-06-17T11:29:08.282+08:00|                        null|
null|                              null|                        996.4|
+-----------------------------+--------------------------------+--------------------
-------------+--------------------------------------+-------------------------------
--+
```

步骤 8 删除 2 号生产线下所有设备指标。

delete timeseries root.company.line2.;**

查询 2 号生产线指标数据已无内容。

select * from root.company.line2.;**

```
+----+
|Time|
+----+
+----+
Empty set.
```

----结束

14.2 使用 IoTDB 客户端

操作场景

该任务指导用户在运维场景或业务场景中使用 IoTDB 客户端。

前提条件

- 已安装客户端。例如安装目录为“/opt/client”，以下操作的客户端目录只是举例，请根据实际安装目录修改。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建。安全模式下，“机机”用户需要下载 keytab 文件。“人机”用户第一次登录时需修改密码。

操作步骤

以客户端安装用户，登录安装客户端的节点。

步骤 1 切换到 IoTDB 客户端安装目录，例如：/opt/client。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 首次登录 IoTDB 客户端前需执行以下步骤生成 SSL 客户端证书：

1. 执行以下命令生成客户端 SSL 证书：

   keytool -noprompt -import -alias myservercert -file ca.crt -keystore truststore.jks

   执行该命令后需输入一个自定义密码。

2. 将生成的“truststore.jks”文件拷贝到“*客户端安装目录*/IoTDB/iotdb/conf”目录下：

   cp truststore.jks *客户端安装目录*/**IoTDB/iotdb/conf**

步骤 4 根据集群认证模式，完成 IoTDB 客户端登录。

- 安全模式，执行以下命令，完成用户认证并登录 IoTDB 客户端。

  kinit *组件业务用户*。

- 普通模式则跳过此步骤。

步骤 5 执行以下命令，切换 IoTDB 客户端运行脚本所在目录。

cd /opt/client/IoTDB/iotdb/sbin

步骤 6 集群未启用 Kerberos 认证（普通模式）需先调用“alter-cli-password.sh”脚本修改默认用户 **root** 的默认密码：

sh alter-cli-password.sh *IoTDBServer 实例节点 IP RPC 端口*

说明

- IoTDBServer 实例节点 IP 地址可在 Manager 界面，选择“集群 > 服务 > IoTDB > 实例”查看。
- IoTDBServer RPC 端口可在参数“IOTDB_SERVER_RPC_PORT”中自行配置。默认端口如下：
- 开源端口默认值为：6667
- 定制端口默认值为：22260

  端口定制/开源区分：创建 LTS 版本类型集群时，可以选择“组件端口”为“开源”或是“定制”，选择“开源”使用开源端口，选择“定制”使用定制端口。

- **root** 用户初始密码 MRS 3.3.0 之前版本为“root”，MRS 3.3.3.0 及之后版本为“Iotdb@123”。
- 修改的用户密码字符长度 MRS 3.3.0 之前版本至少为 4 位，MRS 3.3.0 及之后版本至少为 8 位，且不能包含空格。

步骤 7 执行以下命令登录客户端

./start-cli.sh -h *IoTDBServer 实例节点 ip* **-p** *IoTDBServer RPC 端口*

运行该命令后，根据实际需求指定业务用户名：

- 指定业务用户名，则输入“yes”，并根据提示输入业务用户名和对应的业务用户密码：

- 不指定业务用户名，则输入“no”；此时，则使用步骤 5 中的用户执行后续操作：

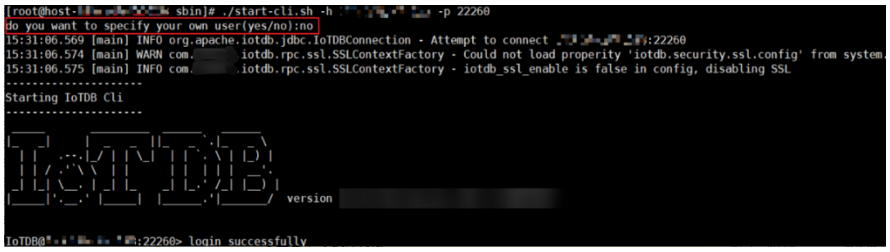

- 输入其它，则退出登录：

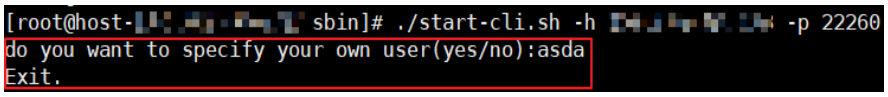

说明

- 集群未启用 Kerberos 认证（普通模式）使用 **root** 用户登录。
- 登录客户端时可以通过**-maxRPC** 参数，控制执行结果一次性打印多少行，默认值是 1000；如果将**-maxRPC** 参数值设置为小于等于 0，则会一次性打印所有结果，通常用于重定向 SQL 执行结果。
- 登录客户端时，可选**-disableISO8601** 参数，用于控制查询结果的时间列展示格式。不指定该参数会显示年月日时分秒格式，指定则显示时间戳。
- 如果服务端关闭了 SSL 配置，则需在客户端需也关闭 SSL 配置才能通信，操作为：

  cd *客户端安装目录*/**IoTDB/iotdb/conf**

  vi iotdb-client.env

  将“iotdb_ssl_enable”参数的值修改为“false”，保存并退出。

  其中，服务端 SSL 配置，可登录 FusionInsight Manager，选择“集群 > 服务 > IoTDB > 配置”，搜索“SSL_ENABLE”查看，该参数值为“true”表示开启了 SSL，为“false”则表示未开启 SSL。

步骤 8 登录客户端成功即可执行 SQL。

----结束

14.3 配置 IoTDB 常用参数

操作场景

IoTDB 通过多副本的部署架构实现了集群的高可用，每个 Region（DataRegion 和 SchemaRegion）默认具有 3 个副本，也可配置 3 个以上。当某节点故障时，Region 副本的其他主机节点上的副本可替代工作，保证服务能正常运行，提高集群的稳定性。

操作步骤

登录集群 Manager 页面，选择“集群 > 服务 > IoTDB > 配置 > 全部配置”，进入 IoTDB 配置界面修改参数。

步骤 1 修改 ConfigNode 和 IoTDBServer 配置：

- 修改 ConfigNode 配置：
  - 单击“ConfigNode（角色）”，可参考表 14-1 修改已有配置。

- 选择“ConfigNode（角色） > 自定义”，可参考表 14-1 在参数“confignode.customized.configs”中设置自定义 ConfigNode 配置。

- 修改 IoTDBServer 配置：
  - 单击“IoTDBServer（角色）”，可参考表 14-1 修改已有配置。
  - 选择“IoTDBServer（角色） > 自定义”，可参考表 14-1 在参数“engine.customized.configs”中设置自定义 IoTDBServer 配置。

表14-1 常用参数

名称	角色	值	说明
region_data_lost_proportion	ConfigNode	0.5	Region 丢失数据达到该阈值（默认值为50%）开始补齐。 说明 该参数仅 MRS 3.3.0 及之后版本支持。
region_repair_data_volume	ConfigNode	10	Region 数据量大于此阈值后进行自动修复，默认值为：10G。 说明 该参数仅 MRS 3.3.0 及之后版本支持。
dest_datanode_remaining_disk_space_proportion	ConfigNode	0.7	Region 副本补齐时 Region 数据量占目标 DataNode 磁盘剩余空间的百分比，默认值为：70%。 说明 该参数仅 MRS 3.3.0 及之后版本支持。
read_consistency_level	ConfigNode	strong	设置读共识级别，目前支持“strong”和“weak”。 MRS 3.3.0 之前版本，需在自定义参数（confignode.customized.configs）中设置该参数。
flush_proportion	IoTDBServer	0.4	调用刷盘的写内存比例，如果写入负载过高（如批处理=1000），可以降低该值。
replica_affinity_policy	IoTDBServer	random	当“read_consistency_level”参数值为“weak”时，查询任务选择 Region 副本节点的策略。
coordinator_read_executor_size	IoTDBServer	20	自定义参数（engine.customized.configs），设置 IoTDBServer Coordinator 的读线程核心个数。
rpc_thrift_compression_enable	ALL	false	数据传输过程中是否压缩，默认不压缩。
root.log.level	ALL	INFO	IoTDB 的日志级别。该参数值修改后无需重启相关实例即可生效。
SSL_ENABLE	ALL	true	客户端到服务端通道 SSL 加密开关。

步骤 2 单击“保存”，配置完成。

步骤 3 单击“实例”，勾选对应的实例，选择“更多 > 重启实例”，使配置生效。

----结束

14.4 IoTDB 支持的数据类型和编码

IoTDB 支持如下几种数据类型和编码方式，参见表 14-2。

表14-2 IoTDB 支持的数据类型和编码

类型	说明	支持的编码
BOOLEAN	布尔值	PLAIN, RLE
INT32	整型	PLAIN, RLE, TS_2DIFF, GORILLA, FREQ, ZIGZAG
INT64	长整型	PLAIN, RLE, TS_2DIFF, GORILLA, FREQ, ZIGZAG
FLOAT	单精度浮点数	PLAIN, RLE, TS_2DIFF, GORILLA, FREQ
DOUBLE	双精度浮点数	PLAIN, RLE, TS_2DIFF, GORILLA, FREQ
TEXT	字符串	PLAIN, DICTIONARY

14.5 IoTDB 权限管理

14.5.1 IoTDB 权限介绍

MRS 提供用户、用户组和角色，集群中的各类权限需要先授予角色，然后将用户或者用户组与角色绑定。用户只有绑定角色或者加入绑定角色的用户组，才能获得权限。

说明

IoTDB 在安全模式下需要进行权限管理，将创建的用户加入 **iotdbgroup** 用户组。在普通模式下无需进行权限管理。

IoTDB 权限列表

表 14-3 中“权限名称”列为 IoTDB 开源支持的相关权限，若 MRS 用户需要使用对应的权限进行相关操作，则需参考表 14-3 中“用户需要的权限”列在 Manager 上赋予对应用户相应的权限，相关操作请参见 14.5.2 创建 IoTDB 角色。

表14-3 IoTDB 权限一览

权限名称	说明	用户需要的权限	示例
SET_STORAGE_GROUP	创建存储组，包含设置存储组的权限和设置或取消存储组的存活时间（TTL）。	设置存储组	Eg1: set storage group to root.ln; Eg2: set ttl to root.ln 3600000; Eg3: unset ttl to root.ln;
CREATE_TIMESERIES	创建时间序列。	创建	Eg1: 创建时间序列 create timeseries root.ln.wf02.status with datatype=BOOLEAN,encoding=PLAIN; Eg2: 创建对齐时间序列 create aligned timeseries root.ln.device1(latitude FLOAT encoding=PLAIN compressor=SNAPPY, longitude FLOAT encoding=PLAIN compressor=SNAPPY);
INSERT_TIMESERIES	插入数据。	写	Eg1: insert into root.ln.wf02(timestamp,status) values(1,true); Eg2: insert into root.sg1.d1(time, s1, s2) aligned values(1, 1, 1);
ALTER_TIMESERIES	修改时间序列，添加属性和标签。	修改	Eg1: alter timeseries root.turbine.d1.s1 ADD TAGS tag3=v3, tag4=v4; Eg2: ALTER timeseries root.turbine.d1.s1 UPSERT ALIAS=newAlias TAGS(tag2=newV2, tag3=v3) ATTRIBUTES(attr3=v3, attr4=v4);
READ_TIMESERIES	查询数据。	读	Eg1: show storage group; Eg2: show child paths root.ln, show child nodes root.ln; Eg3: show devices; Eg4: show timeseries root.**; Eg5: show all ttl; Eg6: 数据查询 select * from root.ln.**;

权限名称	说明	用户需要的权限	示例
			Eg7: 查询性能追踪 tracing select * from root.**; Eg8: UDF 查询 select example(*) from root.sg.d1; Eg9: 统计查询 count devices;
DELETE_TIMESERIES	删除数据或时间序列	删除	Eg1: 删除时间序列 delete timeseries root.ln.wf01.wt01.status; Eg2: 删除数据 delete from root.ln.wf02.wt02.status where time < 10;
DELETE_STORAGE_GROUP	删除存储组	IoTDB 管理员权限	Eg: delete storage group root.ln;
CREATE_FUNCTION	注册 UDF。	IoTDB 管理员权限	Eg: create function example AS 'org.apache.iotdb.udf.UDTFExample' ;
DROP_FUNCTION	卸载 UDF。	IoTDB 管理员权限	Eg: drop function example;
UPDATE_TEMPLATE	创建、删除、修改元数据模板。	IoTDB 管理员权限	Eg1: create schema template t1(s1 int32);
READ_TEMPLATE	查看所有元数据模板、元数据模板内容。	IoTDB 管理员权限	Eg1: show schema templates; Eg2: show nodes in template t1;
APPLY_TEMPLATE	挂载、卸载、激活元数据模板。	IoTDB 管理员权限	Eg1: set schema template t1 to root.sg.d; Eg2: create timeseries of schema template on root.sg.d;
READ_TEMPLATE_APPLICATION	查看元数据模板的挂载路径和激活路径。	IoTDB 管理员权限	Eg1: show paths set schema template t1; Eg2: show paths using schema template t1;

14.5.2 创建 IoTDB 角色

该任务指导 MRS 集群管理员在 Manager 创建并设置 IoTDB 的角色。IoTDB 角色可设置 IoTDB 管理员权限以及普通用户对数据的读、写或删除等权限。

前提条件

- MRS 集群管理员已明确业务需求。
- 已安装好 IoTDB 客户端。

操作步骤

在 Manager 界面，选择“系统 > 权限 > 角色”。

步骤 1 单击“添加角色”，然后在“角色名称”和“描述”输入角色名字与描述。

步骤 2 设置角色“配置资源权限”请参见表 14-4。

IoTDB 权限：

- 普通用户权限：具有数据操作权限，可选择性的对 IoTDB 根目录、存储组及存储组到时间序列之间任意节点路径授权，最小可支持对时间序列进行数据的读、写、修改和删除权限。
- IoTDB 管理员权限：具有表 14-3 的所有权限。

表14-4 设置角色

任务场景	角色授权操作
设置 IoTDB 管理员权限	在“配置资源权限”的表格中选择“*待操作集群的名称* > IoTDB”，勾选“IoTDB 管理员权限”。
设置用户创建存储组的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > IoTDB > 普通用户权限”。 2. 在 root 根目录下，勾选“设置存储组”。 3. 当用户具有该角色权限后，可以创建 root 根目录下的存储组。
设置用户创建时间序列的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > IoTDB > 普通用户权限”。 2. 在 root 根目录下，勾选“创建”，表示在 root 根目录下递归的所有路径具有创建时间序列的权限。 3. 单击 root，进入存储组资源类型，在对应的存储组权限上勾选“创建”，表示在该存储组目录下递归的所有路径具有创建时间序列的权限。
设置用户修改时间序列的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > IoTDB > 普通用户权限”。 2. 在 root 根目录下，勾选“修改”，表示在 root 根目录下递归的所有路径上的时间序列具有修改时间序列的权限。 3. 单击 root，进入存储组资源类型，在对应的存储组权限

任务场景	角色授权操作
	上勾选“修改”，表示在该存储组递归的所有路径上的时间序列具有修改时间序列的权限。 4. 单击指定的存储组，进入时间序列资源类型，在对应的时间序列权限上勾选“修改”，表示具有修改该时间序列的权限。
设置用户向时间序列插入数据的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > IoTDB > 普通用户权限”。 2. 在 root 根目录下，勾选“写”，则表示在 root 根目录下递归的所有路径上的时间序列具有插入数据的权限。 3. 单击 root，进入存储组资源类型，在对应的存储组权限上勾选“写”，表示在该存储组递归的所有路径上的时间序列具有插入数据的权限。 4. 单击指定的存储组，进入时间序列资源类型，在对应的时间序列权限上勾选“写”，表示具有向该时间序列插入数据的权限。
设置用户读取时间序列数据的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > IoTDB > 普通用户权限”。 2. 在 root 根目录下，勾选“读”，则表示在 root 根目录下递归的所有路径上的时间序列，具有读取数据的权限。 3. 单击 root，进入存储组资源类型，在对应的存储组权限上勾选“读”，表示在该存储组递归的所有路径上的时间序列，具有读取数据的权限。 4. 单击指定的存储组，进入时间序列资源类型，在对应的时间序列权限上勾选“读”，则表示具有向该时间序列读取数据的权限。
设置用户删除时间序列的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > IoTDB > 普通用户权限”。 2. 在 root 根目录下，勾选“删除”，表示在 root 根目录下递归的所有路径的时间序列具有删除数据或时间序列的权限。 3. 单击 root，进入存储组资源类型，在对应的存储组权限上勾选“删除”，表示在该存储组递归的所有路径上的时间序列具有删除数据或时间序列的权限。 4. 单击指定的存储组，进入时间序列资源类型，在对应的时间序列权限上勾选“删除”，表示具有向该时间序列删除数据或时间序列的权限。

----结束

14.6 IoTDB 日志介绍

日志描述

日志描述

日志路径：IoTDB 相关日志的默认存储路径为“/var/log/Bigdata/iotdb/iotdbserver”（运行日志）、“/var/log/Bigdata/audit/iotdb/iotdbserver”（审计日志）。

日志归档规则：IoTDB 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 20MB 的时候（此日志文件大小可进行配置），会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyymmdd>.编号.log.gz”。最多保留最近的 10 个压缩文件，压缩文件保留个数和压缩文件阈值可以配置。

表14-5 IoTDB 日志列表

日志类型	日志文件名	描述
运行日志	log-all.log	IoTDB 服务全部日志。
	log-error.log	IoTDB 服务错误日志。
	log-measure.log	IoTDB 服务监控日志。
	log-query-debug.log	IoTDB 查询 DEBUG 日志。
	log-query-frequency.log	IoTDB 查询频率日志。
	log-sync.log	IoTDB 同步操作日志。
	log-slow-sql.log	IoTDB 慢 SQL 日志。
	server.out	IoTDB 服务启动异常日志。
	postinstall.log	IoTDB 进程启动日志。
	prestart.log	IoTDB 进程启动异常日志。
	service-healthcheck.log	IoTDB 数据库初始化日志。
	start.log	IoTDBServer 服务启动日志。
	stop.log	IoTDBServer 服务停止日志。
	IoTDBServer-omm-<timestamp>-<pid>-gc.log.0.current	IoTDBServer 服务 GC 日志。
审计日志	log_audit.log	IoTDB 审计日志。

日志级别

IoTDB 提供了如表 14-6 所示的日志级别。

日志的级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表14-6 日志级别

级别	描述
ERROR	ERROR 表示系统运行的错误信息。
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

1. 参考 25.1 修改集群服务配置参数，进入 IoTDB 服务“全部配置”页面。
2. 在左侧导航栏选择需修改的角色所对应的日志菜单。
3. 选择所需修改的日志级别并保存。

说明

配置 IoTDB 日志级别 60 秒后即可生效，无需重启服务。

日志格式

IoTDB 的日志格式如下所示：

表14-7 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS> | 日志级别 | [线程名称] | 日志信息 | 日志打印的类 (文件：行号)	2021-06-08 10:08:41,221 | ERROR | [main] | Client failed to open SaslClientTransport to interact with a server during session initiation: | org.apache.iotdb.rpc.sasl.TFastSaslTransport (TFastSaslTransport.java:257)
审计日志	<yyyy-MM-dd HH:mm:ss,SSS> | 日志级别 | [线程名称] | 日志信息 | 日志打印的类 (文件：行号)	2021-06-08 11:03:49,365 | INFO | [ClusterClient-1] | Session-1 is closing | IoTDB_AUDIT_LOGGER (TSServiceImpl.java:326)

14.7 用户自定义函数（UDF）

14.7.1 UDF 概述

UDF（User Defined Function）即用户自定义函数。IoTDB 提供多种内建函数及自定义函数来满足用户的计算需求。

UDF 类型

IoTDB 支持的 UDF 函数的类型如表 14-8 所示。

表14-8 UDF 函数类型

UDF 分类	描述
UDTF（User Defined Timeseries Generating Function）	自定义时间序列生成函数。该类函数允许接收多条时间序列，最终会输出一条时间序列，生成的时间序列可以有任意多数量的数据点。

UDTF（User Defined Timeseries Generating Function）

编写一个 UDTF 需要继承“org.apache.iotdb.db.query.udf.api.UDTF”类，并至少实现“beforeStart”方法和一种“transform”方法。

表 14-9 是所有可供用户实现的接口说明。

表14-9 接口说明

接口定义	描述	是否必须
void validate(UDFParameterValidator validator) throws Exception	在初始化方法“beforeStart”调用前执行，用于检测“UDFParameters”中用户输入的参数是否合法。	否
void beforeStart(UDFParameters parameters, UDTFConfigurations configurations) throws Exception	初始化方法，在 UDTF 处理输入数据前，调用用户自定义的初始化行为。用户每执行一次 UDTF 查询，框架就会构造一个新的 UDF 类实例，该方法在每个 UDF 类实例被初始化时调用一次。在每一个 UDF 类实例的生命周期内，该方法只会被调用一次。	是
void transform(Row row, PointCollector collector) throws Exception	该方法由框架调用。当在“beforeStart”中选择以“RowByRowAccessStrategy”的策略消费原始数据时，这个数据处理方法就会被调用。输入参数以“Row”的形式传入，输出结果通过“PointCollector”输	与“transform(RowWindow rowWindow, PointCollector

接口定义	描述	是否必须
	出。需要在该方法内自行调用“collector”提供的数据收集方法，以决定最终的输出数据。	collector）”方法二选一
void transform(RowWindow rowWindow, PointCollector collector) throws Exception	该方法由框架调用。当在“beforeStart”中选择以“SlidingSizeWindowAccessStrategy”或者“SlidingTimeWindowAccessStrategy”的策略消费原始数据时，这个数据处理方法就会被调用。输入参数以“RowWindow”的形式传入，输出结果通过“PointCollector”输出。需要在该方法内自行调用“collector”提供的数据收集方法，以决定最终的输出数据。	与“transform(Row row, PointCollector collector)”方法二选一
void terminate(PointCollector collector) throws Exception	该方法由框架调用。该方法会在所有的“transform”调用执行完成后，在“beforeDestory”方法执行前被调用。在一个 UDF 查询过程中，该方法会且只会调用一次。需要在该方法内自行调用“collector”提供的数据收集方法，以决定最终的输出数据。	否
void beforeDestroy()	UDTF 的结束方法。此方法由框架调用，并且只会被调用一次，即在处理完最后一条记录之后被调用。	否

调用顺序：

1. void validate(UDFParameterValidator validator) throws Exception
2. void beforeStart(UDFParameters parameters, UDTFConfigurations configurations) throws Exception
3. void transform(Row row, PointCollector collector) throws Exception 或者 void transform(RowWindow rowWindow, PointCollector collector) throws Exception
4. void terminate(PointCollector collector) throws Exception
5. void beforeDestroy()

须知

框架每执行一次 UDTF 查询，都会构造一个全新的 UDF 类实例，查询结束时，对应的 UDF 类实例即被销毁，因此不同 UDTF 查询（即使是在同一个 SQL 语句中）UDF 类实例内部的数据都是隔离的。用户可以放心地在 UDTF 中维护一些状态数据，无需考虑并发对 UDF 类实例内部状态数据的影响。

使用方法：

- void validate(UDFParameterValidator validator) throws Exception

  “validate”方法能够对用户输入的参数进行验证。

  在该方法中限制输入序列的数量和类型，检查用户输入的属性或者进行自定义逻辑的验证。

- void beforeStart(UDFParameters parameters, UDTFConfigurations configurations) throws Exception

  “beforeStart”方法有以下作用：

  - 帮助用户解析 SQL 语句中的 UDF 参数。
  - 配置 UDF 运行时必要的信息，即指定 UDF 访问原始数据时采取的策略和输出结果序列的类型。
  - 创建资源，比如建立外部链接，打开文件等。

UDFParameters

UDFParameters 的作用是解析 SQL 语句中的 UDF 参数（SQL 中 UDF 函数名称后括号中的部分）。参数包括路径（及其序列类型）参数和字符串“key-value”对形式输入的属性参数。

例如：

```
SELECT UDF(s1, s2, 'key1'='iotdb', 'key2'='123.45') FROM root.sg.d;
```

用法：

```
void beforeStart(UDFParameters parameters, UDTFConfigurations configurations)
throws Exception {
  // parameters
 for (PartialPath path : parameters.getPaths()) {
    TSDataType dataType = parameters.getDataType(path);
   // do something
  }
  String stringValue = parameters.getString("key1"); // iotdb
  Float floatValue = parameters.getFloat("key2"); // 123.45
  Double doubleValue = parameters.getDouble("key3"); // null
  int intValue = parameters.getIntOrDefault("key4", 678); // 678
  // do something

  // configurations
  // ...
}
```

UDTFConfigurations

使用“UDTFConfigurations”指定 UDF 访问原始数据时采取的策略和输出结果序列的类型。

用法：

```
void beforeStart(UDFParameters parameters, UDTFConfigurations configurations)
throws Exception {
  // parameters
  // ...
```

```
  // configurations
  configurations
    .setAccessStrategy(new RowByRowAccessStrategy())
    .setOutputDataType(TSDataType.INT32);
}
```

其中“setAccessStrategy”方法用于设定 UDF 访问原始数据时采取的策略，“setOutputDataType”用于设定输出结果序列的类型。

- setAccessStrategy

  注意：在此处设定的原始数据访问策略决定了框架会调用哪一种“transform”方法，请实现与原始数据访问策略对应的“transform”方法。也可以根据“UDFParameters”解析出来的属性参数，动态决定设定哪一种策略，因此，实现两种“transform”方法也是被允许的。

  可以设定的访问原始数据的策略：

接口定义	描述	调用 transform 方法
RowByRowAccessStrategy	逐行地处理原始数据。框架会为每一行原始数据输入调用一次“transform”方法。当 UDF 只有一个输入序列时，一行输入就是该输入序列中的一个数据点。当 UDF 有多个输入序列时，一行输入序列对应的是这些输入序列按时间对齐后的结果（一行数据中，可能存在某一列为 null 值，但不会全部都是 null）。	void transform(Row row, PointCollector collector) throws Exception
SlidingTimeWindowAccessStrategy	以滑动时间窗口的方式处理原始数据。框架会为每一个原始数据输入窗口调用一次“transform”方法。一个窗口可能存在多行数据，每一行数据对应的是输入序列按时间对齐后的结果（一行数据中，可能存在某一列为 null 值，但不会全部都是 null）。	void transform(RowWindow rowWindow, PointCollector collector) throws Exception
SlidingSizeWindowAccessStrategy	以固定行数的方式处理原始数据，即每个数据处理窗口都会包含固定行数的数据（最后一个窗口除外）。框架会为每一个原始数据输入窗口调用一次 transform 方法。一个窗口可能存在多行数据，每一行数据对应的是输入序列按时间对齐后的结果（一行数据中，可能存在某一列为 null 值，但不会全部都是 null）。	void transform(RowWindow rowWindow, PointCollector collector) throws Exception

“RowByRowAccessStrategy”的构造不需要任何参数。

“SlidingTimeWindowAccessStrategy”有多种构造方法，可以向构造方法提供三类参数：

- 时间轴显示时间窗开始和结束时间。

- 划分时间轴的时间间隔参数（必须为正数）。
- 滑动步长（不要求大于等于时间间隔，但是必须为正数）。

时间轴显示时间窗开始和结束时间不是必须要提供的。当不提供这类参数时，时间轴显示时间窗开始时间会被定义为整个查询结果集中最小的时间戳，时间轴显示时间窗结束时间会被定义为整个查询结果集中最大的时间戳。

滑动步长参数也不是必须的。当不提供滑动步长参数时，滑动步长会被设定为划分时间轴的时间间隔。

三类参数的关系可见下图：

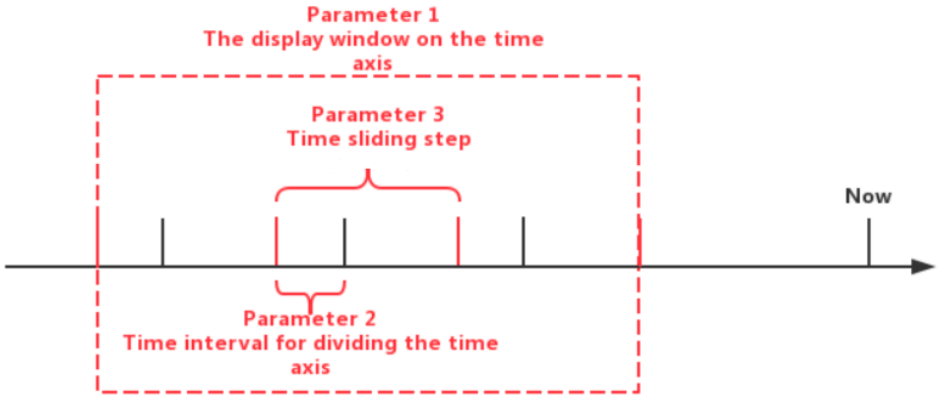

注意，最后的一些时间窗口的实际时间间隔可能小于规定的时间间隔参数。另外，可能存在某些时间窗口内数据行数量为 0 的情况，这种情况框架也会为该窗口调用一次“transform”方法。

“SlidingSizeWindowAccessStrategy”有多种构造方法，用户可以向构造方法提供两个参数：

- 窗口大小，即一个数据处理窗口包含的数据行数。注意，最后一些窗口的数据行数可能少于规定的数据行数。
- 滑动步长，即下一窗口第一个数据行与当前窗口第一个数据行间的数据行数（不要求大于等于窗口大小，但是必须为正数）。

滑动步长参数不是必须的。当不提供滑动步长参数时，滑动步长会被设定为窗口大小。

注意：在此处设定的输出结果序列的类型，决定了“transform”方法中“PointCollector”实际能够接收的数据类型。“setOutputDataType”中设定的输出类型和“PointCollector”实际能够接收的数据输出类型关系如下：

setOutputDataType 中设定的输出类型	PointCollector 实际能够接收的输出类型
INT32	int
INT64	long
FLOAT	float
DOUBLE	double
BOOLEAN	boolean
TEXT	“java.lang.String”和“org.apache.iotdb.tsfile.utils.Binary”

- UDTF 输出序列的类型是运行时决定的。可以根据输入序列类型动态决定输出序列类型。

  例如：

```
void beforeStart(UDFParameters parameters, UDTFConfigurations configurations)
throws Exception {
  // do something
  // ...

  configurations
    .setAccessStrategy(new RowByRowAccessStrategy())
    .setOutputDataType(parameters.getDataType(0));
}
```

  - void transform(Row row, PointCollector collector) throws Exception

    当在“beforeStart”方法中指定 UDF 读取原始数据的策略为“RowByRowAccessStrategy”，就需要实现该方法，在该方法中增加对原始数据处理的逻辑。

    该方法每次处理原始数据的一行。原始数据由“Row”读入，由“PointCollector”输出。可以选择在一次“transform”方法调用中输出任意数量的数据点。需要注意的是，输出数据点的类型必须与在“beforeStart”方法中设置的一致，而输出数据点的时间戳必须是严格单调递增的。

    下面是一个实现了“void transform(Row row, PointCollector collector) throws Exception”方法的完整 UDF 示例。它是一个加法器，接收两列时间序列输入，当这两个数据点都不为“null”时，输出这两个数据点的代数和。

```
import org.apache.iotdb.db.query.udf.api.UDTF;
import org.apache.iotdb.db.query.udf.api.access.Row;
import org.apache.iotdb.db.query.udf.api.collector.PointCollector;
import
org.apache.iotdb.db.query.udf.api.customizer.config.UDTFConfigurations;
import
org.apache.iotdb.db.query.udf.api.customizer.parameter.UDFParameters;
import
org.apache.iotdb.db.query.udf.api.customizer.strategy.RowByRowAccessStrate
gy;
import org.apache.iotdb.tsfile.file.metadata.enums.TSDataType;

public class Adder implements UDTF {

  @Override
  public void beforeStart(UDFParameters parameters, UDTFConfigurations
configurations) {
    configurations
        .setOutputDataType(TSDataType.INT64)
        .setAccessStrategy(new RowByRowAccessStrategy());
  }

  @Override
  public void transform(Row row, PointCollector collector) throws
Exception {
    if (row.isNull(0) || row.isNull(1)) {
      return;
```

```
    }
    collector.putLong(row.getTime(), row.getLong(0) + row.getLong(1));
  }
}
```

- void transform(RowWindow rowWindow, PointCollector collector) throws Exception

  当在“beforeStart”方法中指定 UDF 读取原始数据的策略为“SlidingTimeWindowAccessStrategy”或者“SlidingSizeWindowAccessStrategy”时，就需要实现该方法，在该方法中增加对原始数据处理的逻辑。

  该方法每次处理固定行数或者固定时间间隔内的一批数据，称包含这一批数据的容器为窗口。原始数据由“RowWindow”读入，由“PointCollector”输出。“RowWindow”能够帮助访问某一批次的“Row”，它提供了对这一批次的“Row”进行随机访问和迭代访问的接口。可以选择在一次“transform”方法调用中输出任意数量的数据点，需要注意的是，输出数据点的类型必须与在“beforeStart”方法中设置的一致，而输出数据点的时间戳必须是严格单调递增的。

  下面是一个实现了“void transform(RowWindow rowWindow, PointCollector collector) throws Exception”方法的完整 UDF 示例。它是一个计数器，接收任意列数的时间序列输入，作用是统计并输出指定时间范围内每一个时间窗口中的数据行数。

```
import java.io.IOException;
import org.apache.iotdb.db.query.udf.api.UDTF;
import org.apache.iotdb.db.query.udf.api.access.RowWindow;
import org.apache.iotdb.db.query.udf.api.collector.PointCollector;
import
org.apache.iotdb.db.query.udf.api.customizer.config.UDTFConfigurations;
import
org.apache.iotdb.db.query.udf.api.customizer.parameter.UDFParameters;
import
org.apache.iotdb.db.query.udf.api.customizer.strategy.SlidingTimeWindowAcc
essStrategy;
import org.apache.iotdb.tsfile.file.metadata.enums.TSDataType;

public class Counter implements UDTF {

  @Override
  public void beforeStart(UDFParameters parameters, UDTFConfigurations
configurations) {
    configurations
        .setOutputDataType(TSDataType.INT32)
        .setAccessStrategy(new SlidingTimeWindowAccessStrategy(
            parameters.getLong("time_interval"),
            parameters.getLong("sliding_step"),
            parameters.getLong("display_window_begin"),
            parameters.getLong("display_window_end")));
  }

  @Override
  public void transform(RowWindow rowWindow, PointCollector collector)
throws Exception {
    if (rowWindow.windowSize() != 0) {
```

```
    collector.putInt(rowWindow.getRow(0).getTime(),
rowWindow.windowSize());
   }
  }
}
```

- void terminate(PointCollector collector) throws Exception

  在一些场景下，UDF 需要遍历完所有的原始数据后才能得到最后的输出结果。“terminate”接口为这类 UDF 提供了支持。

  该方法会在所有的“transform”调用执行完成后，在“beforeDestory”方法执行前被调用。可以选择使用“transform”方法进行单纯的数据处理，最后使用“terminate”将处理结果输出。

  结果需要由“PointCollector”输出。可以选择在一次“terminate”方法调用中输出任意数量的数据点。需要注意的是，输出数据点的类型必须与在“beforeStart”方法中设置的一致，而输出数据点的时间戳必须是严格单调递增的。

  下面是一个实现了“void terminate(PointCollector collector) throws Exception”方法的完整 UDF 示例。它接收一个“INT32”类型的时间序列输入，作用是输出该序列的最大值点。

```
import java.io.IOException;
import org.apache.iotdb.db.query.udf.api.UDTF;
import org.apache.iotdb.db.query.udf.api.access.Row;
import org.apache.iotdb.db.query.udf.api.collector.PointCollector;
import
org.apache.iotdb.db.query.udf.api.customizer.config.UDTFConfigurations;
import
org.apache.iotdb.db.query.udf.api.customizer.parameter.UDFParameters;
import
org.apache.iotdb.db.query.udf.api.customizer.strategy.RowByRowAccessStrate
gy;
import org.apache.iotdb.tsfile.file.metadata.enums.TSDataType;

public class Max implements UDTF {

  private Long time;
  private int value;

  @Override
  public void beforeStart(UDFParameters parameters, UDTFConfigurations
configurations) {
    configurations
        .setOutputDataType(TSDataType.INT32)
        .setAccessStrategy(new RowByRowAccessStrategy());
  }

  @Override
  public void transform(Row row, PointCollector collector) {
    int candidateValue = row.getInt(0);
    if (time == null || value < candidateValue) {
      time = row.getTime();
      value = candidateValue;
    }
  }
```

```
  @Override
  public void terminate(PointCollector collector) throws IOException {
    if (time != null) {
      collector.putInt(time, value);
    }
  }
}
```

- void beforeDestroy()

  UDTF 的结束方法，可以在此方法中进行一些资源释放等的操作。

  此方法由框架调用。对于一个 UDF 类实例而言，生命周期中会且只会被调用一次，即在处理完最后一条记录之后被调用。

14.8 IoTDB 数据导入与导出

14.8.1 IoTDB 数据导入

操作场景

该任务指导用户使用“import-csv.sh”将 CSV 格式的数据导入到 IoTDB。

前提条件

- 已安装客户端，请参见。例如安装目录为“/opt/client”，以下操作的客户端目录只是举例，请根据实际安装目录修改。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建，具体操作请参见。安全模式下，“机机”用户需要下载 keytab 文件，具体操作请参见。“人机”用户第一次登录时需修改密码。
- 服务端默认开启了 SSL，需参考 14.2 使用 IoTDB 客户端章节生成“truststore.jks”证书，并拷贝到“*客户端安装目录*/IoTDB/iotdb/conf”目录下。

操作步骤

1. 在本地准备 CSV 文件，文件名为：example-filename.csv，内容如下：

```
Time,root.fit.d1.s1,root.fit.d1.s2,root.fit.d2.s1,root.fit.d2.s3,root.fit.p.s1
1,100,hello,200,300,400
2,500,world,600,700,800
3,900,"hello, \"world\"",1000,1100,1200
```

须知

在导入数据前，需要注意：

- MRS 3.3.0 之前版本，导入的数据不能包含空格，否则此行数据导入失败并跳过导入，后续操作不受影响。
- MRS 3.3.0 及之后版本，导入的数据不能包含空格，否则此次数据导入操作会失败，需要对导入数据类型进行自检。
- 包含,的字段需要使用单引号或者双引号括起来，例如：hello,world 修改为 "hello,world"。
- 字段中的"需要被替换成转义字符\"，例如："world"修改为\"world\"。
- 字段中的'需要被替换成转义字符\'，例如：'world' 修改为\'world\'。
- 若输入的值为时间，格式为“yyyy-MM-dd'T'HH:mm:ss, yyy-MM-dd HH:mm:ss”或者“yyyy-MM-dd'T'HH:mm:ss.SSSZ”，例如：2022-02-28T11:07:00、2022-02-28 11:07:00 或者 2022-02-28T11:07:00.000Z。

2. 使用 WinSCP 工具将 CSV 文件导入客户端节点，例如“/opt/client/IoTDB/iotdb/tools”目录下。
3. 以客户端安装用户，登录安装客户端的节点。
4. 执行以下命令，切换到客户端安装目录。

   cd /opt/client
5. 执行以下命令配置环境变量。

   source bigdata_env
6. 首次登录 IoTDB 客户端前需执行以下步骤生成 SSL 客户端证书：
   a. 执行以下命令生成客户端 SSL 证书：

      keytool -noprompt -import -alias myservercert -file ca.crt -keystore truststore.jks

      执行该命令后需输入一个自定义密码。
   b. 将生成的“truststore.jks”文件拷贝到“*客户端安装目录*/IoTDB/iotdb/conf”目录下：

      cp truststore.jks *客户端安装目录*/**IoTDB/iotdb/conf**
7. 若当前集群开启了 Kerberos 认证，执行以下命令认证当前用户，若集群未开启 Kerberos 认证请跳过该步骤。

   kinit *组件业务用户*
8. 执行以下命令，切换到 IoTDB 客户端运行脚本所在目录。

   cd /opt/client/IoTDB/iotdb/sbin
9. 集群未启用 Kerberos 认证（普通模式）需先调用“alter-cli-password.sh”脚本修改默认用户 **root** 的默认密码：

   sh alter-cli-password.sh *IoTDBServer 实例节点 IP RPC 端口*

说明

- IoTDBServer 实例节点 IP 地址可在 Manager 界面，选择“集群 > 服务 > IoTDB > 实例”查看。
- IoTDBServer RPC 端口可在参数“IOTDB_SERVER_RPC_PORT”中自行配置。默认端口如下：
- 开源端口默认值为：6667
- 定制端口默认值为：22260

端口定制/开源区分：创建 LTS 版本类型集群时，可以选择“组件端口”为“开源”或是“定制”，选择“开源”使用开源端口，选择“定制”使用定制端口。

- **root** 用户初始密码 MRS 3.3.0 之前版本为“root”，MRS 3.3.3.0 及之后版本为“Iotdb@123”。
- 修改的用户密码字符长度 MRS 3.3.0 之前版本至少为 4 位，MRS 3.3.0 及之后版本至少为 8 位，且不能包含空格。

10. 执行以下命令登录客户端

    ./start-cli.sh -h *IoTDBServer 实例节点的业务 ip* **-p** *IoTDBServer RPC 端口*

    说明

    - IoTDBServer 实例节点的业务 IP 地址可登录 FusionInsight Manager 后选择“集群 > 服务 > IoTDB > 实例”查看。
    - RPC 端口可通过“集群 > 服务 > IoTDB > 配置 > 全部配置”，搜索参数“IOTDB_SERVER_RPC_PORT”获得。
    - 集群未启用 Kerberos 认证（普通模式）使用 **root** 用户登录。

    运行该命令后，根据实际需求指定业务用户名：

    - 指定业务用户名，则输入“yes”，并根据提示输入业务用户名和对应的业务用户密码：

      

    - 不指定业务用户名，则输入“no”；此时，则使用 7 中的用户执行后续操作：

      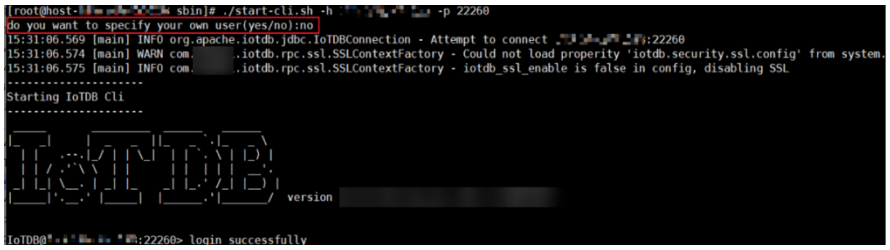

    - 输入其它，则退出登录：

      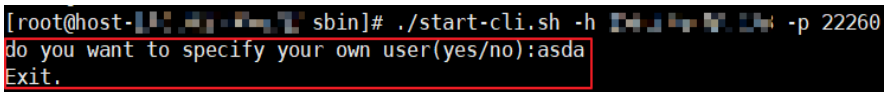

11. （可选）创建元数据。

    IoTDB 具有类型推断的能力，因此在数据导入前创建元数据不是必须的。但仍然推荐在使用 CSV 导入工具导入数据前创建元数据，因为这可以避免不必要的类型转换错误。命令如下：

```
SET STORAGE GROUP TO root.fit.d1;
SET STORAGE GROUP TO root.fit.d2;
SET STORAGE GROUP TO root.fit.p;
CREATE TIMESERIES root.fit.d1.s1 WITH DATATYPE=INT32,ENCODING=RLE;
CREATE TIMESERIES root.fit.d1.s2 WITH DATATYPE=TEXT,ENCODING=PLAIN;
CREATE TIMESERIES root.fit.d2.s1 WITH DATATYPE=INT32,ENCODING=RLE;
```

```
CREATE TIMESERIES root.fit.d2.s3 WITH DATATYPE=INT32,ENCODING=RLE;
CREATE TIMESERIES root.fit.p.s1 WITH DATATYPE=INT32,ENCODING=RLE;
```

12. 执行以下命令，退出客户端。

    quit;

13. 执行以下命令，切换到“import-csv.sh”运行脚本所在目录。

    cd /opt/client/IoTDB/iotdb/tools

14. 执行以下命令运行 import-csv.sh，导入“example-filename.csv”文件。

    ./import-csv.sh -h *IoTDBServer 实例节点的业务 ip* **-p** *IoTDBServer RPC 端口* **-f** *example-filename.csv*

    需根据提示交互式输入业务用户名和对应密码，如下显示表示 CSV 文件导入成功：

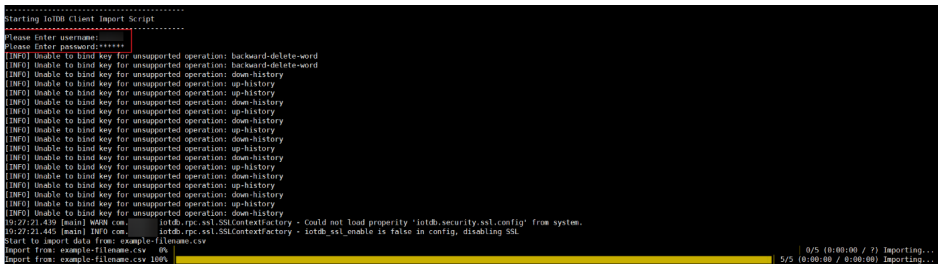

15. 验证数据一致性。

    a. 执行以下命令，切换到 IoTDB 客户端运行脚本所在目录。

       cd /opt/client/IoTDB/iotdb/sbin

    b. 参考 10 登录 IoTDB 客户端。执行 SQL 查询数据并与 1 中数据进行对比。

    c. 查看导入的数据与 1 中的数据是否一致，若一致则表示导入成功。

       例如，执行以下命令查看导入的数据：

       SELECT * FROM root.fit.;**

说明

- 为避免安全风险，推荐使用交互式方式导入 CSV 文件。
- CSV 文件导入也可使用“**./import-csv.sh -h** *IoTDBServer 实例节点的业务 ip* **-p** *IoTDBServer RPC 端口* **-u** *业务用户名* **-pw** *业务用户密码* **-f** *example-filename.csv*”命令。

  如下显示表示 CSV 文件导入成功：

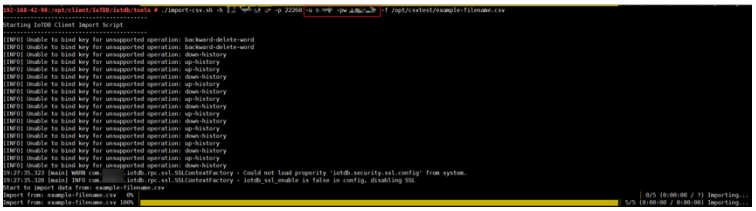

- 若服务端 IoTDB 开启了纳秒（ns）时间精度，客户端导入纳秒时间戳数据时，需要加上**-tp ns** 参数。集群是否开启纳秒时间精度可登录 FusionInsight Manager，选择“集群 > 配置 > 所有非默认值”，搜索“timestamp_precision”查看。

14.8.2 IoTDB 数据导出

操作场景

该任务指导用户使用“export-csv.sh”将数据从 IoTDB 导出为 CSV 格式的文件。

须知

导出 CSV 格式的数据文件，可能存在注入风险，请谨慎使用。

前提条件

- 已安装客户端，请参见。例如安装目录为“/opt/client”，以下操作的客户端目录只是举例，请根据实际安装目录修改。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建，具体操作请参见。安全模式下，“机机”用户需要下载 keytab 文件，具体操作请参见。“人机”用户第一次登录时需修改密码。
- 服务端默认开启了 SSL，需参考 14.2 使用 IoTDB 客户端章节生成“truststore.jks”证书，并拷贝到“*客户端安装目录*/IoTDB/iotdb/conf”目录下。

操作步骤

1. 以客户端安装用户，登录安装客户端的节点。
2. 执行以下命令，切换到客户端安装目录。

   cd /opt/client
3. 执行以下命令配置环境变量。

   source bigdata_env
4. 若当前集群开启了 Kerberos 认证，执行以下命令认证当前用户，若集群未开启 Kerberos 认证请跳过该步骤。

   kinit *组件业务用户*
5. 执行以下命令，切换“export-csv.sh”运行脚本所在目录。

   cd /opt/client/IoTDB/iotdb/tools
6. 在运行导出脚本之前，需要输入一些查询或指定一些 SQL 文件。如果在一个 SQL 文件中有多个 SQL，SQL 应该被换行符分割。例如：

```
select * from root.fit.d1
select * from root.sg1.d1
```

7. 运行“export-csv.sh”，导出数据。

   ./export-csv.sh -h *IoTDBServer 实例节点的业务 ip* **-p** *IoTDBServer RPC 端口* -td <directory> [-tf <time-format> -s <sqlfile>]

   运行示例：

```
./export-csv.sh -h x.x.x.x -p 22260 -td ./
# Or
./export-csv.sh -h x.x.x.x -p 22260 -td ./ -tf yyyy-MM-dd\ HH:mm:ss
# Or
./export-csv.sh -h x.x.x.x -p 22260 -td ./ -s sql.txt
# Or
./export-csv.sh -h x.x.x.x -p 22260 -td ./ -tf yyyy-MM-dd\ HH:mm:ss -s sql.txt
```

说明

- IoTDBServer 实例节点的业务 IP 地址可登录 FusionInsight Manager 后选择“集群 > 服务 > IoTDB > 实例”查看。
- RPC 端口可通过“集群 > 服务 > IoTDB > 配置 > 全部配置”，搜索参数“IOTDB_SERVER_RPC_PORT”获得。
- 若导出字段存在,特殊字符：整个字段会被用双引号括起来，例如：hello,world 导出为"hello,world"。
- 若导出字段存在"特殊字符：整个字段会被用双引号括起来且"会被替换为\"，例如："world"导出为"\"world\""。

8. 运行 7 的命令会出现 CSV 注入风险提示，输入“yes”继续执行命令，输入其他，则取消数据导出操作。

```
------------------------------------------
Starting IoTDB Client Export Script
------------------------------------------
Export data to CSV file may invoke CSV injection when opened in Windows.
Are you sure you want to continue(yes/no)?
```

   例如：输入“yes”后，需根据提示输入业务用户名和对应密码，当显示以下信息，表示数据导出成功。

```
------------------------------------------
Starting IoTDB Client Export Script
------------------------------------------
Export data to CSV file may invoke CSV injection when opened in Windows.
Are you sure you want to continue(yes/no)?
yes
Please Enter username:[redacted]
Please Enter password:******
[INFO] Unable to bind key for unsupported operation: backward-delete-word
[INFO] Unable to bind key for unsupported operation: backward-delete-word
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
19:28:19.827 [main] WARN com.[redacted].iotdb.rpc.ssl.SSLContextFactory - Could not load property 'iotdb.security.ssl.config' from system.
19:28:19.832 [main] INFO com.[redacted].iotdb.rpc.ssl.SSLContextFactory - iotdb_ssl_enable is false in config, disabling SSL
Start to export data from sql statement: select * from root.fit.d1
19:28:20.031 [main] DEBUG org.apache.iotdb.session.Session - EndPoint(ip:[redacted], port:22260) execute sql select * from root.fit.d1
Statement [select * from root.fit.d1] has dumped to file ./dump0.csv successfully! It costs 62ms to export 3 lines.
Start to export data from sql statement: select * from root.fit.d2
19:28:20.140 [main] DEBUG org.apache.iotdb.session.Session - EndPoint(ip:[redacted], port:22260) execute sql select * from root.fit.d2
Statement [select * from root.fit.d2] has dumped to file ./dump1.csv successfully! It costs 1ms to export 3 lines.
Start to export data from sql statement: select * from root.fit.p
19:28:20.175 [main] DEBUG org.apache.iotdb.session.Session - EndPoint(ip:[redacted], port:22260) execute sql select * from root.fit.p
Statement [select * from root.fit.p] has dumped to file ./dump2.csv successfully! It costs 1ms to export 3 lines.
```

说明

- 为避免安全风险，推荐使用交互式方式导出 CSV 文件。

- 导出 CSV 文件也可使用“**./export-csv.sh -h** *IoTDBServer 实例节点的业务 ip* **-p** *IoTDBServer RPC 端口* **-u** *业务用户名* **-pw** *业务用户密码* -td <directory> [-tf <time-format> -s <sqlfile>]”命令。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

  运行示例：

```
./export-csv.sh -h x.x.x.x -p 22260 -u test -pw 密码 -td ./
# Or
./export-csv.sh -h x.x.x.x -p 22260 -u test -pw 密码 -td ./ -tf yyyy-MM-dd\
HH:mm:ss
# Or
./export-csv.sh -h x.x.x.x -p 22260 -u test -pw 密码 -td ./ -s sql.txt
# Or
./export-csv.sh -h x.x.x.x -p 22260 -u test -pw 密码 -td ./ -tf yyyy-MM-dd\
HH:mm:ss -s sql.txt
```

  如下显示表示 CSV 文件导出成功：

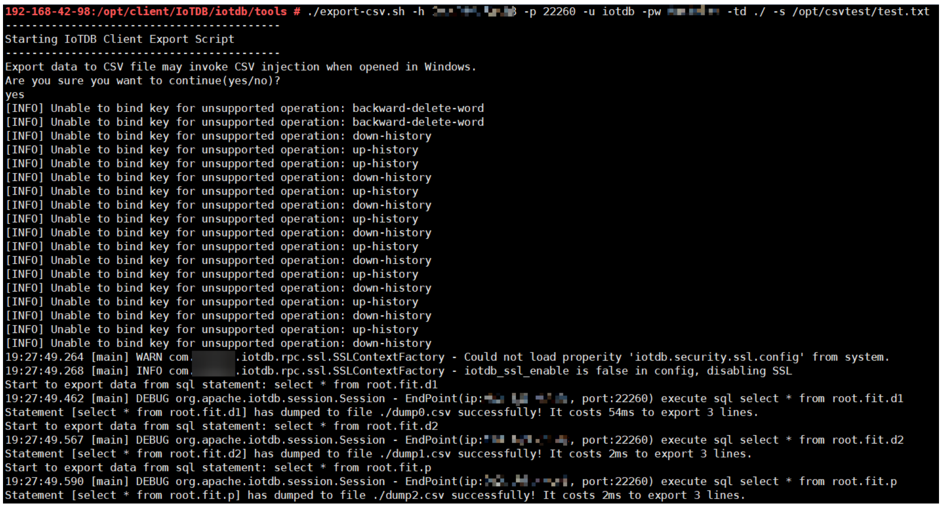

```
192-168-42-98:/opt/client/IoTDB/iotdb/tools # ./export-csv.sh -h [redacted] -p 22260 -u iotdb -pw [redacted] -td ./ -s /opt/csvtest/test.txt
------------------------------------------
Starting IoTDB Client Export Script
------------------------------------------
Export data to CSV file may invoke CSV injection when opened in Windows.
Are you sure you want to continue(yes/no)?
yes
[INFO] Unable to bind key for unsupported operation: backward-delete-word
[INFO] Unable to bind key for unsupported operation: backward-delete-word
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
19:27:49.264 [main] WARN com.[redacted].iotdb.rpc.ssl.SSLContextFactory - Could not load properity 'iotdb.security.ssl.config' from system.
19:27:49.268 [main] INFO com.[redacted].iotdb.rpc.ssl.SSLContextFactory - iotdb_ssl_enable is false in config, disabling SSL
Start to export data from sql statement: select * from root.fit.d1
19:27:49.462 [main] DEBUG org.apache.iotdb.session.Session - EndPoint(ip:[redacted], port:22260) execute sql select * from root.fit.d1
Statement [select * from root.fit.d1] has dumped to file ./dump0.csv successfully! It costs 54ms to export 3 lines.
Start to export data from sql statement: select * from root.fit.d2
19:27:49.567 [main] DEBUG org.apache.iotdb.session.Session - EndPoint(ip:[redacted], port:22260) execute sql select * from root.fit.d2
Statement [select * from root.fit.d2] has dumped to file ./dump1.csv successfully! It costs 2ms to export 3 lines.
Start to export data from sql statement: select * from root.fit.p
19:27:49.590 [main] DEBUG org.apache.iotdb.session.Session - EndPoint(ip:[redacted], port:22260) execute sql select * from root.fit.p
Statement [select * from root.fit.p] has dumped to file ./dump2.csv successfully! It costs 2ms to export 3 lines.
```

14.9 规划 IoTDB 容量

IoTDB 自身有多副本机制，region（schema region 和 data region）默认是 3 副本。ConfigNode 上保存 region 和 IoTDBServer 的映射关系，IoTDBServer 保存 region 数据，直接使用操作系统自身的文件系统来管理元数据和数据文件。

容量规格

- ConfigNode 容量规格

  当创建新的存储组时，IoTDB 默认为该存储组分配 10000 个槽位，数据写入时根据写入的设备名和时间值，分配或创建一个 data region 并挂载在某个槽位上。所以 ConfigNode 的内存容量占用跟存储组个数和该存储组持续写入的时间相关。

槽位分配相关对象	对象大小（字节）
TTimePartitionSlot	4
TSeriesPartitionSlot	8
TConsensusGroupId	4

根据上表计算可得一个 ConfigNode，如果创建一个存储组，持续运行 10 年，大约需要 0.68G 内存 ：

10000(槽位) * 10（年）* 365 (分区) * （TTimePartitionSlot size + TSeriesPartitionSlot size + TConsensusGroupId size）= 0.68G

- IoTDBServer 容量规格

  IoTDB 中数据以 region 分配在 IoTDBServer 上，region 副本数默认是“3”，最终在 IoTDBServer 文件系统上表现为 3 个文件。上限为操作系统可存储文件个数最大值，对于 Linux 系统即是 inode 个数。

14.10 IoTDB 性能调优

配置场景

IoTDB 主要利用堆内存完成读写操作。提高 IoTDB 内存可以有效提高 IoTDB 读写性能。

配置描述

登录集群 FusionInsight Manager 页面，选择“集群 > 服务 > IoTDB > 配置 > 全部配置”，进入 IoTDB 配置界面搜索并修改参数。

配制方法如表 14-10 所示。

表14-10 参数说明

参数	描述	默认值	调优建议
SSL_ENABLE	客户端到服务端通道 SSL 加密。	true	“true”表示开启 SSL 加密，“false”表示关闭 SSL 加密。数据传输加解密对性能影响较大，经过测试发现具有 200%的性能差异，因此建议性能测试时关闭 SSL 加密。ConfigNode 和 IoTDBServer 两个角色同名参数都要修改。
iotdb_server_kerberos_qop	集群内各个 IoTDBServer 实例数据传输加密，仅开启 Kerberos 认证的集群支持该参数。	auth-int	“auth-int”表示数据传输加密，“auth”表示只认证，不加密。因此建议将此参数值修改为“auth”。ConfigNode 和 IoTDBServer 两个角色同名参数都要修改。
GC_OPTS	IoTDBServer 使用的内存和 GC 配置参数。	-Xms2G -Xmx2G -XX:MaxDirectMemorySiz	• “-Xms2G -Xmx2G”为 IoTDB JVM 堆内存，对于时间序列多，写入并发量大的

参数	描述	默认值	调优建议
		e=512M -XX:+UseG1GC -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=10 -XX:GCLogFileSize=1M -Djdk.tls.ephemeralDHKeySize=3072，需要按实际情况进行配置	场景，需要增大此配置。可以根据 GC 时长阈值告警或堆内存阈值告警进行调优，如果告警发生，参数值按照 0.5 倍速率调大。如果告警频繁发生，参数值按照 1 倍速率调大。调整 HeapSize 大小时，建议将 Xms 和 Xmx 设置成相同的值，这样可以避免 JVM 动态调整 HeapSize 大小的时候影响性能。 • “-XX:MaxDirectMemorySize”为 IoTDB JVM 直接内存，建议值为堆内存的“1/4”，主要影响写入性能，如果写入性能明显下降，可以适当调整该参数，参数值按照 0.5 倍速率调大。注意：需要保证“堆内存+直接内存 <= 80% * 系统可用内存”， 否则会导致 IoTDB 启动失败。 • 查询场景调优举例：如果查询的范围比较大，单个序列 10000 个点以上，JVM 分配内存的 20% / 序列数 > 160K，即为默认配置下存储引擎对查询最友好的状态。 • 序列和内存大小举例：500 万序列，对应内存配置为：-Xms128G -Xmx128G
write_read_schema_free_memory_proportion（MRS 3.3.0 及之后版本为“storage_query_schema_consensus_free_memory_proportion”）	内存分配比例：写、读、模型、空闲。	• MRS 3.2.0 版本：4:3:1:2 • MRS 3.3.0 及之后版本：3:3:1:1:2	可根据负载适当调整内存。 • 写入内存越大，对写入吞吐和单个查询越好。 • 查询内存越大，支持的并发查询越多。 • 元数据内存越大，就不容易出现“IoTDB system load is too large”。 • 空闲内存越大，越不容易导致内存爆满。
iot_consensus_t	WAL 目录大小上	53687091200	可根据写负载情况适当调整，

参数	描述	默认值	调优建议
hrottle_threshold_in_byte	限，默认 50GB，单位为字节。超过该值，写操作就会变慢或者被拒绝。		仅 MRS 3.3.0 及之后版本支持。 • 写并发小，不用更改。 • 写并发大，可适当调大。
data_region_iot_max_pending_batches_num	Leader 数据副本同步给 Follower 的并发最大值。	12	可根据 CPU、WAL 积压情况调整，仅 MRS 3.3.0 及之后版本支持。该参数为自定义配置，需选择“IoTDBServer（角色） > 自定义”，在自定义参数“engine.customized.configs”中添加该参数项及参数值。 • 写并发小，不用更改。 • 写并发大，可适当调大。 • WAL 积压，可适当调小。 • CPU 使用持续 80%以上，可适当调小。
avg_series_point_number_threshold	当内存数据平均点数达到此阈值时，Flush 数据到 Tsfile。	10000	可根据堆内存使用率、GC 时长情况调整，仅 MRS 3.3.0 及之后版本支持。 • GC 时长较长，可适当调小。 • 内存使用率高，可适当调小。
flush_proportion	调用刷盘的写内存比例，如果写入负载极高（如批处理=1000），可以降低该值。	0.4	可根据堆内存使用率情况调整，仅 MRS 3.3.0 及之后版本支持。若内存使用率高，可适当调小该参数值。

15 使用 JobGateway

15.1 从零使用 JobGateway

JobGateway 是模拟大数据（Flink、Hive、HBase 等）客户端用于大数据业务提交功能的网关，是一个具备 HTTP/HTTPS 的 REST 系统服务。它具备高性能、易使用、高可用、高扩展性等特点，并具有监控、告警、配置分离等特性，能够大大缩短作业提交链路，简化大数据作业提交流程。

背景信息

例如某集团作业提交较多，流程耗时、繁琐、复杂，使用组件客户端完成作业提交效率低下。不想使用大数据组件客户端提交大数据作业，可以安装 JobGateway 组件，使用 JobGateway 服务完成作业的提交；只需要构建基于 rest 风格的 http/https 的 url 即可完成作业提交。

以 Hive 作业提交为例（其余作业相关参考 JobGateway 接口文档），示例如下：

```
curl --location --request POST
'https://{host}:{port}/mrsjob/submit?user.name={username}'
--header 'JobServerAuthorization: {AuthorizationInfo}'
--header 'Content-Type: application/json'
--data-raw '{
"job_name":"{job-name}",
"job_type":"HiveSql",
"arguments":["SHOW TABLES"]
}'
```

返回值：

```
{
    "id": null,
    "state": "COMPLETE",
    "errorCode": 0,
    "errorCodeDescription": null,
    "errorDescription": null,
    "failedNodeList": null,
    "totalProgress": "0",
    "job_id": "466710d2-b1ff-4a98-805b-4675292e5cc8"
}
```

Hive 作业提交参数含义		
参数名称	参数含义	备注
host	nginx 所在的服务器 ip	-
port	nginx 监控端口	https 默认为 29970，http 默认为 29971
user.name	提交作业的用户名称	-
JobServerAuthorization	授权认证信息	参考 JobGateway 接口文档
job_name	作业名称	-
job_type	作业类型	HiveSql 代表是执行 HiveSql 作业类型
arguments	HiveSql 作业内容	-

说明

若在服务端修改了其他组件如 ZooKeeper 等配置，同时，JobGateway 配置也过期时，则需要重启 JobGateway 组件，并且刷新 JobServer 角色所在节点的客户端配置。刷新 JobServer 所在节点的客户端配置步骤如下：

1. 使用 PuTTY 工具，以 **root** 用户登录客户端安装节点，执行以下命令切换至 **omm** 用户。

   su - omm

2. 进入客户端安装的目录，例如“/opt/Bigdata/client”，执行以下命令更新配置文件：

   cd /opt/Bigdata/client

   sh autoRefreshConfig.sh

3. 按照提示输入 FusionInsight Manager 管理员用户名，密码以及 FusionInsight Manager 界面浮动 IP。

4. 输入需要更新配置的组件名，组件名之间使用“,”分隔。如需更新所有组件配置，可直接单击回车键。

   界面显示以下信息表示配置更新成功：

   ```
   Succeed to refresh components client config.
   ```

15.2 JobGateway 常用参数配置

参数入口

请参考 25.1 修改集群服务配置参数进入 JobGateway 服务配置页面。

参数说明

表15-1 JobGateway 参数说明

参数	参数说明	默认值

参数	参数说明	默认值
HTTP_INSTANCE_PORT	JobServer 服务 http 端口	【默认值】29973 【取值范围】29970-29979
HTTPS_INSTANCE_PORT	JobServer 服务 https 端口	【默认值】29972 【取值范围】29970-29979
JAVA_OPTS	用于 JVM 的 gc 参数。需确保 GC_OPT 设置正确，否则进程启动会失败	见页面默认配置
job.record.batch.delete.count	25	JobServer 每一批老化数据的条数
job.record.expire.count	500000	JobServer 老化数据的条数
job.record.expire.day	7	JobServer 作业过期的时间
logging.level.org.apache.tomcat	JobServer 服务端 tomcat 日志的日志级别	【默认值】INFO 【取值范围】DEBUG、INFO、WARN、ERROR、FATAL
root.level	JobServer 服务端日志的日志级别	【默认值】INFO 【取值范围】DEBUG、INFO、WARN、ERROR、FATAL
NGINX_PORT	JobBalancer 服务监听端口	【默认值】https 默认端口 29970 http 默认端口 29971 【取值范围】29970-29979
client_body_buffer_size	设置读取客户端请求正文的缓冲区大小。如果请求主体大于缓冲区，则将整个主体或仅将其部分写入临时文件	【默认值】10240 【取值范围】大于 0
client_body_timeout	定义读取客户端请求正文的超时时间。超时仅针对两次连续读取操作之间的一段时间设置，而不是针对整个请求主体的传输。如果客户端在此时间内未传输任何内容，则请求将终止并出现 408（请求超时）错误。单位：秒	【默认值】60 【取值范围】[1,86400]

参数	参数说明	默认值
client_header_buffer_size	设置读取客户端请求标头的缓冲区大小。对于大多数请求，1K 字节的缓冲区就足够了。但是，如果请求包含长 cookie，或者来自 WAP 客户端，则它可能不适合 1K。如果请求行或请求头字段不适合此缓冲区，则分配由 large_client_header_buffers 指令配置的更大缓冲区。	【默认值】1024 【取值范围】大于 0
client_header_timeout	定义读取客户端请求标头的超时时间。如果客户端没有在这段时间内传输整个标头，请求将终止并出现 408（请求超时）错误。	【默认值】60 【取值范围】[1,86400]
client_max_body_size	http 请求体最大值，单位 mb	【默认值】80 【取值范围】1-10240
keepalive_requests	设置可以通过一个保持活动连接提供服务的最大请求数。在发出最大请求数后，连接将关闭。 定期关闭连接对于释放每个连接的内存分配是必要的。因此，使用过高的最大请求数可能会导致过多的内存使用，因此不推荐使用。	【默认值】1000 【取值范围】[1,100000]
keepalive_time	限制可以通过一个保持活动连接处理请求的最长时间。达到此时间后，将在后续请求处理后关闭连接。单位：秒	【默认值】3600 【取值范围】[1,86400]
keepalive_timeout	设置一个超时时间，在此期间保持活动的客户端连接将在服务器端保持打开状态。零值禁用保持活动的客户端连接。单位：秒	【默认值】75 【取值范围】[0,86400]
large_client_header_buffers.size	设置用于读取大型客户端请求标头的缓冲区的最大数量(large_client_header_buffers.number) 和大小。一个请求行不能超过一个缓冲区的大小，否则会向客户端返回 414（Request-URI Too Large）错误。请求头字段也不能超过一个缓冲区的大小，否则返回 400（Bad Request）错误给客户端。缓冲区仅按需分配。如果在请求处理结束后连接转换为保持活动状态，则释放这	【默认值】4096 【取值范围】大于 0

参数	参数说明	默认值
	些缓冲区。	
lb_limit_req_burst	当大量请求过来时，超过访问频次限制的请求将会放到缓冲区，超过缓冲区大小的请求会返回 503 错误。	【默认值】50 【取值范围】1-1000
lb_limit_zone_rate	http 请求表示允许相同标识的客户端的访问频次，单位 r/s、r/m。例如：30r/s，表示允许每秒访问 30 次	【默认值】30r/s 【取值范围】1-100r/s 或 1-6000r/m
lb_limit_zone_size	http 内存缓冲区的大小，单位 mb。	【默认值】20 【取值范围】1-10240
lb_req_timeout	Nginx 读写的超时时间。	【默认值】60s 【取值范围】1-3600s
proxy_connect_timeout	定义与代理服务器建立 tcp 连接的超时时间。使用数字和单位组合，m 表示分钟，s 表示秒。	【默认值】3m 【取值范围】1-60m 或 1-3600s
proxy_timeout	与代理服务器的 tcp 连接上两次连续读取或写入操作之间的超时。如果在此时间内没有数据传输，则连接关闭。使用数字和单位组合，m 表示分钟，s 表示秒。	【默认值】3m 【取值范围】1-60m 或 1-3600s

15.3 JobGateway 日志介绍

日志描述

日志路径：JobGateway 相关日志的存储路径为：“/var/log/Bigdata/job-gateway/”。

日志归档规则：JobGateway 的运行日志启动了自动压缩归档功能，当日志大小超过 20MB 的时候（此日志文件大小可进行配置），会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd>.[编号].log.zip”。最多保留最近的 20 个压缩文件，压缩文件保留个数和压缩文件阈值可以配置

表15-2 JobGateway 日志列表

日志类型	日志文件名	描述
jobserver 运行日	job-gateway.log	服务运行时的日志

日志类型	日志文件名	描述
志	prestart.log	服务预启动日志
	availability-check.log	服务可用性检查日志
	verbose-gc-sp.txt	服务 gc 日志
	gc.log	服务 gc 日志
jobserver 审计日志	access_log.{yyyy-MM-dd}.log	服务审计日志
balance 运行日志	availability-check.log	服务可用性检查日志
	error.log	服务错误日志
	prestart.log	服务预启动日志
	start.log	服务启动日志
balance 审计日志	access_http.log	服务审计日志

日志级别

JobGateway 提供了如下表 2 所示的日志级别。

日志的级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表15-3 日志级别

级别	描述
ERROR	ERROR 表示系统运行的错误信息。
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

1. 登录 FusionInsight Manager 系统。
2. 选择“集群 > 服务 > JobGateway > 配置”。
3. 单击“全部配置”。
4. 左边菜单栏中选择所需修改的角色所对应的日志菜单。

5. 选择所需修改的日志级别。
6. 单击“保存”，然后单击“确定”，成功后配置生效。

16 使用 Kafka

16.1 从零开始使用 Kafka

操作场景

用户可以在集群客户端完成 Topic 的创建、查询、删除等基本操作。可参考 16.4 管理 Kafka 用户权限进行设置。

前提条件

已安装客户端，例如安装目录为“/opt/client”，以下操作的客户端目录只是举例，请根据实际安装目录修改。

使用 Kafka 客户端

安装客户端，具体请参考 25.3.1 安装客户端章节。

步骤 1 进入 ZooKeeper 实例页面：

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。然后选择“集群 > 服务 > ZooKeeper > 实例”。

步骤 2 查看 ZooKeeper 角色实例的 IP 地址。

记录 ZooKeeper 角色实例其中任意一个的 IP 地址即可。

步骤 3 登录安装客户端的节点。

步骤 4 执行以下命令，切换到客户端目录，例如“/opt/client/Kafka/kafka/bin”。

cd /opt/client/Kafka/kafka/bin

步骤 5 执行以下命令，配置环境变量。

source /opt/client/bigdata_env

步骤 6 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

kinit *Kafka 用户*

步骤 7 登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 配置 > 全部配置”，搜索参数“clientPort”,记录“clientPort”的参数值。

步骤 8 创建一个 Topic：

sh kafka-topics.sh --create --topic *主题名称* **--partitions** *主题占用的分区数* **--replication-factor** *主题的备份个数* **--zookeeper** *ZooKeeper 角色实例所在节点 IP 地址:clientPort*/**kafka**

例如：**sh kafka-topics.sh --create --topic TopicTest --partitions 3 --replication-factor 3 --zookeeper 10.10.10.100:2181/kafka**

说明

clientPort 可在 ZooKeeper 的全部配置参数中搜索“*clientPort*”查看。默认端口如下：

- 开源端口默认值为：2181
- 定制端口默认值为：24002

端口定制/开源区分：创建 LTS 版本类型集群时，可以选择“组件端口”为“开源”或是“定制”，选择“开源”使用开源端口，选择“定制”使用定制端口。

步骤 9 执行以下命令，查询集群中的 Topic 信息：

sh kafka-topics.sh --list --zookeeper *ZooKeeper 角色实例所在节点 IP 地址:clientPort*/**kafka**

例如：**sh kafka-topics.sh --list --zookeeper 10.10.10.100:2181/kafka**

步骤 10 删除步骤 9 中创建的 Topic：

sh kafka-topics.sh --delete --topic *主题名称* **--zookeeper** *ZooKeeper 角色实例所在节点 IP 地址:clientPort*/**kafka**

例如：**sh kafka-topics.sh --delete --topic TopicTest --zookeeper 10.10.10.100:2181/kafka**

----结束

16.2 管理 Kafka 主题

操作场景

用户可以根据业务需要，使用集群客户端管理 Kafka 的主题。启用 Kerberos 认证的集群，需要拥有管理 Kafka 主题的权限。

前提条件

已安装客户端。

操作步骤

进入 ZooKeeper 实例页面：

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。然后选择“集群 > 服务 > ZooKeeper > 实例”。

步骤 1 查看 ZooKeeper 角色实例的 IP 地址。

记录 ZooKeeper 角色实例其中任意一个的 IP 地址即可。

步骤 2 根据业务情况，准备好客户端，参考 25.3 使用 MRS 客户端章节，登录安装客户端的节点。

步骤 3 执行以下命令，切换到客户端目录，例如“/opt/client/Kafka/kafka/bin”。

cd /opt/client/Kafka/kafka/bin

步骤 4 执行以下命令，配置环境变量。

source /opt/client/bigdata_env

步骤 5 执行以下命令，进行用户认证。（普通模式跳过此步骤）

kinit *组件业务用户*

步骤 6 使用 **kafka-topics.sh** 管理 Kafka 主题。

- 创建主题:

  ./kafka-topics.sh --create --topic *主题名称* **--partitions** *主题占用的分区数* **--replication-factor** *主题的备份数* **--zookeeper** *ZooKeeper 的任意一个节点的业务 IP:clientPort*/**kafka**

  ./kafka-topics.sh --create --topic *主题名称* **--partitions** *主题占用的分区数* **--replication-factor** *主题的备份数* **--bootstrap-server** *Kafka 集群 IP:21007* **--command-config ../config/client.properties**

- 罗列主题：
  - **./kafka-topics.sh --list --zookeeper** *ZooKeeper 的任意一个节点的业务 IP:clientPort*/**kafka**
  - **./kafka-topics.sh --list --bootstrap-server** *Kafka 集群 IP:21007* **--command-config ../config/client.properties**
- 查看主题：
  - **./kafka-topics.sh --describe --zookeeper** *ZooKeeper 的任意一个节点的业务 IP:clientPort*/**kafka --topic** *主题名称*
  - **./kafka-topics.sh --describe --bootstrap-server** *Kafka 集群 IP:21007* **--command-config ../config/client.properties --topic** *主题名称*
- 修改主题：
  - **./kafka-topics.sh --alter --topic** *主题名称* **--config** *配置项=配置值* **--zookeeper** *ZooKeeper 的任意一个节点的业务 IP:clientPort*/**kafka**
- 扩展分区：
  - **./kafka-topics.sh --alter --topic** *主题名称* **--zookeeper** *ZooKeeper 的任意一个节点的业务 IP:clientPort*/**kafka --command-config Kafka/kafka/config/client.properties --partitions** *扩展后分区个数*

  - **./kafka-topics.sh --alter --topic** *主题名称* **--bootstrap-server** *Kafka 集群 IP:21007* **--command-config Kafka/kafka/config/client.properties --partitions** *扩展后分区个数*

- 删除主题：
  - **./kafka-topics.sh --delete --topic** *主题名称* **--zookeeper** *ZooKeeper 的任意一个节点的业务 IP:clientPort*/**kafka**
  - **./kafka-topics.sh --delete --topic** *主题名称* **--bootstrap-server** *Kafka 集群 IP:21007* **--command-config ../config/client.properties**

----结束

16.3 查看 Kafka 主题

操作场景

用户可以在 MRS 上查看 Kafka 已创建的主题信息。

操作步骤

进入 Kafka 服务页面：

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。然后选择“集群 > 服务 > Kafka”。

步骤 1 单击“KafkaTopic 监控”。

主题列表默认显示所有主题。可以查看主题的分区数和备份数。

步骤 2 在主题列表单击指定主题的名称，可查看详细信息。

说明

如果执行过以下几种操作：

- Kafka 或者 Zookeeper 进行过扩容或缩容操作。
- Kafka 或者 Zookeeper 增加或者删除过实例。
- 重装 Zookeeper 服务。
- Kafka 切换到了其他的 Zookeeper 服务。

可能导致 Kafka Topic 监控不显示，请按以下步骤恢复：

1. 登录到集群的主 OMS 节点，执行以下切换到 **omm** 用户：

   su - omm

2. 重启 cep 服务:

   restart_app cep

   重启后等待 3 分钟，再次查看 kafka Topic 监控。

----结束

16.4 管理 Kafka 用户权限

操作场景

在启用 Kerberos 认证的集群中，用户使用 Kafka 前需要拥有对应的权限。MRS 集群支持将 Kafka 的使用权限，授予不同用户。

Kafka 默认用户组如表 16-1 所示。

说明

Kafka 支持两种鉴权插件：“Kafka 开源自带鉴权插件”和“Ranger 鉴权插件”。

本章节描述的是基于“Kafka 开源自带鉴权插件”的用户权限管理。若想使用 “Ranger 鉴权插件”，请参考 20.13 添加 Kafka 的 Ranger 访问权限策略。

表16-1 Kafka 默认用户组

用户组名称	描述
kafkaadmin	Kafka 管理员用户组。添加入本组的用户，拥有所有主题的创建，删除，授权及读写权限。
kafkasuperuser	Kafka 高级用户组。添加入本组的用户，拥有所有主题的读写权限。
kafka	Kafka 普通用户组。添加入本组的用户，需要被 kafkaadmin 组用户授予特定主题的读写权限，才能访问对应主题。

前提条件

- 已安装客户端。
- 用户已明确业务需求，并准备一个属于 kafkaadmin 组的用户，作为 Kafka 管理员用户。例如“admin”。

操作步骤

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。然后选择“集群 > 服务 > ZooKeeper > 实例”。

步骤 1 查看 ZooKeeper 角色实例的 IP 地址。

记录 ZooKeeper 角色实例其中任意一个的 IP 地址即可。

步骤 2 根据业务情况，准备好客户端，参考 25.3 使用 MRS 客户端章节，登录安装客户端的节点。

步骤 3 执行以下命令，切换到客户端目录，例如“/opt/client/Kafka/kafka/bin”。

cd /opt/client/Kafka/kafka/bin

步骤 4 执行以下命令，配置环境变量。

source /opt/client/bigdata_env

步骤 5 执行以下命令，进行用户认证。

kinit *组件业务用户*

步骤 6 使用“kafka-acl.sh”进行用户授权常用命令如下。

- 查看某 Topic 权限控制列表：

  ./kafka-acls.sh --authorizer-properties zookeeper.connect=<*ZooKeeper 的任意一个节点的业务 IP:2181/kafka* > **--list --topic** <*Topic 名称*>

  ./kafka-acls.sh --bootstrap-server <*Kafka 集群 IP:21007*> **--command-config ../config/client.properties --list --topic** <*Topic 名称*>

- 添加给某用户 Producer 权限：

  ./kafka-acls.sh --authorizer-properties zookeeper.connect=<*ZooKeeper 的任意一个节点的业务 IP:2181/kafka* > **--add --allow-principal User:**<*用户名*> **--producer --topic** <*Topic 名称*>

  ./kafka-acls.sh --bootstrap-server <*Kafka 集群 IP:21007*> **--command-config ../config/client.properties --add --allow-principal User:**<*用户名*> **--producer --topic** <*Topic 名称*>

- 给某用户批量添加 Producer 权限

  ./kafka-acls.sh --authorizer-properties zookeeper.connect=<*ZooKeeper 的任意一个节点的业务 IP:2181/kafka* > **--add --allow-principal User:**<*用户名*> **--producer --topic** <*Topic 名称*> **--resource-pattern-type prefixed**

  ./kafka-acls.sh --bootstrap-server <*Kafka 集群 IP:21007*> **--command-config ../config/client.properties --add --allow-principal User:**<*用户名*> **--producer --topic** <*Topic 名称*>**--resource-pattern-type prefixed**

- 删除某用户 Producer 权限：

  ./kafka-acls.sh --authorizer-properties zookeeper.connect=<*ZooKeeper 的任意一个节点的业务 IP:2181/kafka* > **--remove --allow-principal User:**<*用户名*> **--producer --topic** <*Topic 名称*>

  ./kafka-acls.sh --bootstrap-server <*Kafka 集群 IP:21007*> **--command-config ../config/client.properties --remove --allow-principal User:**<*用户名*> **--producer --topic** <*Topic 名称*>

- 批量删除某用户 Producer 权限:

  ./kafka-acls.sh --authorizer-properties zookeeper.connect=<*ZooKeeper 的任意一个节点的业务 IP:2181/kafka* > **--remove --allow-principal User:**<*用户名*> **--producer --topic** <*Topic 名称*> **--resource-pattern-type prefixed**

  ./kafka-acls.sh --bootstrap-server <*Kafka 集群 IP:21007*> **--command-config ../config/client.properties --remove --allow-principal User:**<*用户名*> **--producer --topic** <*Topic 名称*>**--resource-pattern-type prefixed**

- 添加给某用户 Consumer 权限：

  ./kafka-acls.sh --authorizer-properties zookeeper.connect=<*ZooKeeper 的任意一个节点的业务 IP:2181/kafka* > **--add --allow-principal User:**<*用户名*> **--consumer --topic** <*Topic 名称*> **--group** <*消费者组名称*>

./kafka-acls.sh --bootstrap-server *<Kafka 集群 IP:21007>* **--command-config ../config/client.properties --add --allow-principal User:***<用户名>* **--consumer --topic** *<Topic 名称>* **--group** *<消费者组名称>*

- 给某用户批量添加 Consumer 权限

  ./kafka-acls.sh --authorizer-properties zookeeper.connect=*<ZooKeeper 的任意一个节点的业务 IP:2181/kafka >* **--add --allow-principal User:***<用户名>* **--consumer --topic** *<Topic 名称>* **--group** *<消费者组名称>* **--resource-pattern-type prefixed**

  ./kafka-acls.sh --bootstrap-server *<Kafka 集群 IP:21007>* **--command-config ../config/client.properties --add --allow-principal User:***<用户名>* **--consumer --topic** *<Topic 名称>* **--group** *<消费者组名称>* **--resource-pattern-type prefixed**

- 删除某用户 Consumer 权限：

  ./kafka-acls.sh --authorizer-properties zookeeper.connect=*<ZooKeeper 的任意一个节点的业务 IP:2181/kafka >* **--remove --allow-principal User:***<用户名>* **--consumer --topic** *<Topic 名称>* **--group** *<消费者组名称>*

  ./kafka-acls.sh --bootstrap-server *<Kafka 集群 IP:21007>* **--command-config ../config/client.properties --remove --allow-principal User:***<用户名>* **--*consumer --topic*** *<Topic 名称>* **--group** *<消费者组名称>*

- 批量删除某用户 Consumer 权限:

  ./kafka-acls.sh --authorizer-properties zookeeper.connect=*<ZooKeeper 的任意一个节点的业务 IP:2181/kafka >* **--remove --allow-principal User:***<用户名>* **--consumer --topic** *<Topic 名称>* **--group** *<消费者组名称>* **--resource-pattern-type prefixed**

  ./kafka-acls.sh --bootstrap-server *<Kafka 集群 IP:21007>* **--command-config ../config/client.properties --remove --allow-principal User:***<用户名>* **--consumer --topic** *<Topic 名称>* **--group** *<消费者组名称>* **--resource-pattern-type prefixed**

----结束

16.5 管理 Kafka 主题中的消息

操作场景

用户可以根据业务需要，使用 MRS 集群客户端，在 Kafka 主题中产生消息，或消费消息。

前提条件

- 已安装集群客户端。
- 启用 Kerberos 认证的集群，需要提前在 Manager 中创建业务用户，用户拥有在 Kafka 主题中执行相应操作的权限。

操作步骤

进入 Kafka 服务页面：

登录 FusionInsight Manager，然后选择“集群 > 服务 > Kafka”。

步骤 1 单击“实例”，查看 Kafka Broker 角色实例的 IP 地址。

记录 Kafka 角色实例其中任意一个的 IP 地址即可。

步骤 2 根据业务情况，准备好客户端，参考 25.3 使用 MRS 客户端章节，登录安装客户端的节点。

步骤 3 执行以下命令，切换到客户端目录，例如“/opt/client/Kafka/kafka/bin”。

cd /opt/client/Kafka/kafka/bin

步骤 4 执行以下命令，配置环境变量。

source /opt/client/bigdata_env

步骤 5 启用 Kerberos 认证的集群，执行以下命令认证用户身份。未启用 Kerberos 认证的集群无需执行本步骤。

kinit *Kafka 用户*

步骤 6 根据业务需要，管理 Kafka 主题中的消息。

- 在主题中产生消息

  sh kafka-console-producer.sh --broker-list *Broker 角色实例所在节点的 IP 地址*:9092 **--topic** *Topic 名称* **--producer.config /opt/client/Kafka/kafka/config/producer.properties**

  Topic 需提前创建，用户可以输入指定的内容作为生产者产生的消息，输入完成后按回车发送消息。如果需要结束产生消息，使用“Ctrl + C”退出任务。

- 消费主题中的消息

  重新打开一个客户端连接，执行以下命令消费主题中的消息。

  cd /opt/client/Kafka/kafka/bin

  source bigdata_env

  sh kafka-console-consumer.sh --topic *Topic 名称* **--bootstrap-server** *Broker 角色实例所在节点的 IP 地址*:9092 **--consumer.config /opt/client/Kafka/kafka/config/consumer.properties**

  配置文件中“group.id”指定的消费者组默认为“example-group1”。用户可根据业务需要，自定义其他消费者组。每次消费时生效。

  执行命令时默认会读取当前消费者组中未被处理的消息。如果在配置文件指定了新的消费者组且命令中增加参数“--from-beginning”，则会读取所有 Kafka 中未被自动删除的消息。

说明

- Kafka 角色实例所在节点 IP 地址，填写 Broker 角色实例其中任意一个的 IP 地址即可。
- 如果集群启用 Kerberos 认证，则端口需要修改为“21007”。
- 默认情况下，ZooKeeper 的“clientPort”为“2181”。

----结束

16.6 基于 binlog 的 MySQL 数据同步到 MRS 集群中

本章节为您介绍使用 Maxwell 同步工具将线下基于 binlog 的数据迁移到 MRS Kafka 集群中的指导。

Maxwell 是一个开源程序，通过读取 MySQL 的 binlog 日志，将增删改等操作转为 JSON 格式发送到输出端(如控制台/文件/Kafka 等)。Maxwell 可部署在 MySQL 机器上，也可独立部署在其他与 MySQL 网络可通的机器上。

Maxwell 运行在 Linux 服务器上，常见的有 EulerOS、Ubuntu、Debian、CentOS、OpenSUSE 等，且需要 Java 1.8+支持。

同步数据具体内容如下。

1. 配置 MySQL
2. 安装 Maxwell
3. 配置 Maxwell
4. 启动 Maxwell
5. 验证 Maxwell
6. 停止 Maxwell
7. Maxwell 生成的数据格式及常见字段含义

配置 MySQL

开启 binlog，在 MySQL 中打开 my.cnf 文件，在[mysqld] 区块检查是否配置 server_id，log-bin 与 binlog_format，若没有配置请执行如下命令添加配置项并重启 MySQL，若已经配置则忽略此步骤。

```
$ vi my.cnf

[mysqld]
server_id=1
log-bin=master
binlog_format=row
```

步骤 1 Maxwell 需要连接 MySQL，并创建一个名称为 maxwell 的数据库存储元数据，且需要能访问需要同步的数据库，所以建议新创建一个 MySQL 用户专门用来给 Maxwell 使用。使用 root 登录 MySQL 之后，执行如下命令创建 maxwell 用户（其中 XXXXXX 是密码，请修改为实际值）。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

- 若 Maxwell 程序部署在非 MySQL 机器上，则创建的 maxwell 用户需要有远程登录数据库的权限，此时创建命令为

  mysql> GRANT ALL on maxwell.* to 'maxwell'@'%' identified by 'XXXXXX';

  mysql> GRANT SELECT, REPLICATION CLIENT, REPLICATION SLAVE on *.* to 'maxwell'@'%';

- 若 Maxwell 部署在 MySQL 机器上，则创建的 maxwell 用户可以设置为只能在本机登录数据库，此时创建命令为

  mysql> GRANT SELECT, REPLICATION CLIENT, REPLICATION SLAVE on *.* to 'maxwell'@'localhost' identified by 'XXXXXX';

  mysql> GRANT ALL on maxwell.* to 'maxwell'@'localhost';

----结束

安装 Maxwell

下载安装包，下载路径为 https://github.com/zendesk/maxwell/releases，选择名为 maxwell-XXX.tar.gz 的二进制文件下载，其中 XXX 为版本号。

步骤 1 将 tar.gz 包上传到任意目录下（本示例路径为 Master 节点的/opt）。

步骤 2 登录部署 Maxwell 的服务器，并执行如下命令进入 tar.gz 包所在目录。

cd /opt

步骤 3 执行如下命令解压“maxwell-XXX.tar.gz”压缩包，并进入“maxwell-XXX”文件夹。

tar -zxvf maxwell-XXX.tar.gz

cd maxwell-XXX

----结束

配置 Maxwell

在 maxwell-XXX 文件夹下若有 conf 目录则配置 config.properties 文件，配置项说明请参见表 16-2。若没有 conf 目录，则是在 maxwell-XXX 文件夹下将 config.properties.example 修改成 config.properties。

表16-2 Maxwell 配置项说明

配置项	是否必填	说明	默认值
user	是	连接 MySQL 的用户名，即步骤 2 中新创建的用户	-
password	是	连接 MySQL 的密码。配置文件中包含认证密码信息可能存在安全风险，建议当前场景执行完毕后删除相关配置文件或加强安全管理。	-
host	否	MySQL 地址	localhost
port	否	MySQL 端口	3306
log_level	否	日志打印级别，可选值为 • debug • info • warn • error	info
output_ddl	否	是否发送 DDL(数据库与数据表的定义修改)事件 • true：发送 DDL 事件 • false：不发送 DDL 事件	false

配置项	是否必填	说明	默认值
producer	是	生产者类型，配置为 kafka • stdout：将生成的事件打印在日志中 • kafka：将生成的事件发送到 kafka	stdout
producer_partition_by	否	分区策略，用来确保相同一类的数据写入到 kafka 同一分区 • database：使用数据库名称做分区，保证同一个数据库的事件写入到 kafka 同一个分区中 • table：使用表名称做分区，保证同一个表的事件写入到 kafka 同一个分区中	databa
ignore_producer_error	否	是否忽略生产者发送数据失败的错误 • true：在日志中打印错误信息并跳过错误的数据，程序继续运行 • false：在日志中打印错误信息并终止程序	true
metrics_slf4j_interval	否	在日志中输出上传 kafka 成功与失败数据的数量统计的时间间隔，单位为秒	60
kafka.bootstrap.servers	是	kafka 代理节点地址，配置形式为 HOST:PORT[,HOST:PORT]	-
kafka_topic	否	写入 kafka 的 topic 名称	maxwell
dead_letter_topic	否	当发送某条记录出错时，记录该条出错记录主键的 kafka topic	-
kafka_version	否	Maxwell 使用的 kafka producer 版本号，不能在 config.properties 中配置，需要在启动命令时用--kafka_version xxx 参数传入	-
kafka_partition_hash	否	划分 kafka topic partition 的算法，支持 default 或 murmur3	default
kafka_key_format	否	Kafka record 的 key 生成方式，支持 array 或 Hash	Hash
ddl_kafka_topic	否	当 output_ddl 配置为 true 时，DDL 操作写入的 topic	{kafka_topic}
filter	否	过滤数据库或表。 • 若只想采集 mydatabase 的库，可以配置为 exclude: *.*,include: mydatabase.* • 若只想采集 mydatabase.mytable 的表，可以配置为 exclude: *.*,include: mydatabase.mytable • 若只想采集 mydatabase 库下的 mytable，	-

配置项	是否必填	说明	默认值
		mydate_123, mydate_456 表，可以配置为 exclude: *.*,include: mydatabase.mytable, include: mydatabase./mydate_\\d*/	

启动 Maxwell

登录 Maxwell 所在的服务器。

步骤 1 执行如下命令进入 Maxwell 安装目录。

cd /opt/maxwell-1.21.0/

说明

如果是初次使用 Maxwell，建议将 conf/config.properties 中的 log_level 改为 debug(调试级别)，以便观察启动之后是否能正常从 MySQL 获取数据并发送到 kafka，当整个流程调试通过之后，再把 log_level 修改为 info，然后先停止再启动 Maxwell 生效。

log level [debug | info | warn | error]

log_level=debug

步骤 2 执行如下命令启动 Maxwell。

source /opt/client/bigdata_env

bin/Maxwell

**bin/maxwell --user='maxwell' --password='XXXXXX' --host='127.0.0.1' **

--producer=kafka --kafka.bootstrap.servers=kafkahost:9092 --kafka_topic=Maxwell

其中，user，password 和 host 分别表示 MySQL 的用户名，密码和 IP 地址，这三个参数可以通过修改配置项配置也可以通过上述命令配置，kafkahost 为流式集群的 Core 节点的 IP 地址。

显示类似如下信息，表示 Maxwell 启动成功。

```
Success to start Maxwell [78092].
```

----结束

验证 Maxwell

登录 Maxwell 所在的服务器。

步骤 1 查看日志。如果日志里面没有 ERROR 日志，且有打印如下日志，表示与 MySQL 连接正常。

```
BinlogConnectorLifecycleListener - Binlog connected.
```

步骤 2 登录 MySQL 数据库，对测试数据进行更新/创建/删除等操作。操作语句可以参考如下示例。

```
-- 创建库
create database test;
-- 创建表
create table test.e (
  id int(10) not null primary key auto_increment,
  m double,
  c timestamp(6),
  comment varchar(255) charset 'latin1'
);
-- 增加记录
insert into test.e set m = 4.2341, c = now(3), comment = 'I am a creature of
light.';
-- 更新记录
update test.e set m = 5.444, c = now(3) where id = 1;
-- 删除记录
delete from test.e where id = 1;
-- 修改表
alter table test.e add column torvalds bigint unsigned after m;
-- 删除表
drop table test.e;
-- 删除库
drop database test;
```

步骤 3 观察 Maxwell 的日志输出，如果没有 WARN/ERROR 打印，则表示 Maxwell 安装配置正常。

若要确定数据是否成功上传，可设置 config.properties 中的 log_level 为 debug，则数据上传成功时会立刻打印如下 JSON 格式数据，具体字段含义请参考 Maxwell 生成的数据格式及常见字段含义。

```
{"database":"test","table":"e","type":"insert","ts":1541150929,"xid":60556,"commit"
:true,"data":{"id":1,"m":4.2341,"c":"2018-11-02 09:28:49.297000","comment":"I am a
creature of light."}}
……
```

说明

当整个流程调试通过之后，可以把 config.properties 文件中的配置项 log_level 修改为 info，减少日志打印量，并重启 Maxwell。

```
# log level [debug | info | warn | error]
log_level=info
```

----结束

停止 Maxwell

登录 Maxwell 所在的服务器。

步骤 1 执行如下命令，获取 Maxwell 的进程标识（PID）。输出的第二个字段即为 PID。

ps -ef | grep Maxwell | grep -v grep

步骤 2 执行如下命令，强制停止 Maxwell 进程。

kill -9 PID

----结束

Maxwell 生成的数据格式及常见字段含义

Maxwell 生成的数据格式为 JSON，常见字段含义如下：

- type：操作类型，包含 database-create，database-drop，table-create，table-drop，table-alter，insert，update，delete
- database：操作的数据库名称
- ts：操作时间，13 位时间戳
- table：操作的表名
- data：数据增加/删除/修改之后的内容
- old：数据修改前的内容或者表修改前的结构定义
- sql：DDL 操作的 SQL 语句
- def：表创建与表修改的结构定义
- xid：事物唯一 ID
- commit：数据增加/删除/修改操作是否已提交

16.7 创建 Kafka 角色

操作场景

该任务指导 MRS 集群管理员创建并设置 Kafka 的角色。

本章节内容适用于 MRS 3.x 及后续版本。

说明

安全模式支持创建 Kafka 角色，普通模式不支持创建 Kafka 角色。

如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.13 添加 Kafka 的 Ranger 访问权限策略。

前提条件

MRS 集群管理员已明确业务需求。

操作步骤

登录 FusionInsight Manager，选择“系统 > 权限 > 角色”。

步骤 1 单击“添加角色”，然后在“角色名称”和“描述”输入角色名字与描述。

步骤 2 在“配置资源权限”中，选择“*待操作集群的名称* > Kafka”。

步骤 3 根据业务需求选择权限，具体配置项，请参见表 16-3

表16-3 配置项说明

任务场景	角色授权操作

任务场景	角色授权操作
设置 Kafka 管理员权限	在“配置资源权限”的表格中选择“*待操作集群的名称* > Kafka > Kafka Manager 权限”。 **说明** 设置此权限，拥有 Topic 的创建、删除等权限，但是不具备任何 Topic 的生产和消费权限。
设置用户对 Topic 的生产权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Kafka > Kafka Topic 生产和消费权限”。 2. 在指定 Topic 的“权限”列，勾选“Kafka 生产者权限”。
设置用户对 Topic 的消费权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Kafka > Kafka Topic 生产和消费权限”。 2. 在指定 Topic 的“权限”列，勾选“Kafka 消费者权限”。

步骤 4 单击“确定”完成，返回“角色”。

----结束

16.8 Kafka 常用参数

本章节内容适用于 MRS 3.x 及后续版本。

参数入口

参数入口，请参考 25.1 修改集群服务配置参数。

常用参数

表16-4 参数说明

配置参数	说明	缺省值
log.dirs	Kafka 数据存储目录列表，以逗号分隔多个目录。	%{@auto.detect.datapart.bk.log.logs}
KAFKA_HEAP_OPTS	Kafka 启动 Broker 时使用的 jvm 选项。建议根据业务需要进行设置。	-Xmx6G -Xms6G
auto.create.topics.enable	是否自动创建 Topic，若参数设置为 false，发消息	true

配置参数	说明	缺省值
	前需要通过命令创建 Topic。	
default.replication.factor	自动创建 Topic 时的默认副本数。	2
monitor.preInitDelay	服务启动后，第一次健康检查的延迟时间。如果启动需要较长时间，可以通过调大参数，来完成启动。单位为毫秒。	600000

超时参数

表16-5 Broker 相关超时参数

参数名称	参数说明	默认值	影响分析
controller.socket.timeout.ms	Controller 连接 Broker 的超时时间。单位：毫秒。	30000	Controller 连接 Broker 的超时时间，一般不需要调整。
group.max.session.timeout.ms	Consumer 注册时允许的最大会话超时时间。单位：毫秒。	1800000	允许 Consumer 配置的 session.timeout.ms 的最大值（不包含此值）。
group.min.session.timeout.ms	Consumer 注册时允许的最小会话超时时间。单位：毫秒。	6000	允许 Consumer 配置的 session.timeout.ms 的最小值（不包含此值）。
offsets.commit.timeout.ms	Offset 提交请求的超时时间。单位：毫秒。	5000	Offset 提交时被延迟处理的最大超时时间。
replica.socket.timeout.ms	副本数据同步请求的超时时间，配置值不得小于 replica.fetch.wait.max.ms。单位：毫秒。	30000	同步线程在发送同步请求之前等待通道建立的最大超时时间，要求配置大于 replica.fetch.wait.max.ms。
request.timeout.ms	设置客户端发送连接请求后，等待响应的超时时间。单位：毫秒。	30000	Broker 节点上的 Controller、Replica 线程中传入 networkclient 连接的超时参数，如果在超时时间内没有接收到响应，那么客户端重新

参数名称	参数说明	默认值	影响分析
			发送，并在达到重试次数后返回请求失败。
transaction.max.timeout.ms	事务允许的最大超时。单位：毫秒。	900000	事务最大超时时间，如果客户端的请求时间超过该值，则 Broker 将在 InitProducerIdRequest 中返回一个错误。这样可以防止客户端超时时间过长，而导致消费者无法接收 topic。
user.group.cache.timeout.sec	指定缓存中保存用户对应组信息的时间。单位：秒。	300	缓存中用户和组对应关系缓存时间，超过此时间用户信息才会再次通过 id -Gn 命令查询，在此期间，仅使用缓存中的用户和组对应关系。
zookeeper.connection.timeout.ms	连接 ZooKeeper 的超时时间。单位：毫秒。	45000	ZooKeeper 连接超时时间，这个时间决定了 zkclient 中初次连接建立过程时允许消耗的时间，超过该时间，zkclient 会主动断开。
zookeeper.session.timeout.ms	ZooKeeper 会话超时时间。如果 Broker 在此时间内未向 ZooKeeper 上报心跳，则被认为失效。单位：毫秒。	45000	ZooKeeper 会话超时时间。 作用一：这个时间结合传入的 ZKURL 中 ZooKeeper 的地址个数，ZooKeeper 客户端以（sessionTimeout/传入 ZooKeeper 地址个数）为连接一个节点的超时时间，超过此时间未连接成功，则尝试连接下一个节点。 作用二：连接建立后，一个会话的超时时间，如 ZooKeeper 上注册的临时节点 BrokerId，当 Broker 被停止，则该 BrokerId，会经过一个 sessionTimeout 才会被 ZooKeeper 清理。

表16-6 Producer 相关超时参数

配置名称	说明	默认值	影响分析
request.timeout.ms	指定发送消息请求的请求超时时间。单位：毫秒。	30000	请求超时时间，出现网络问题时，需调大此参数；配置过小，则容易出现 Batch Expire 异常。

表16-7 Consumer 相关超时参数

配置名称	说明	默认值	影响分析
connections.max.idle.ms	空闲连接的保留时间。单位：毫秒	600000	空闲连接的保留时间，连接空闲时间大于此时间，则会销毁该连接，有需要时重新创建连接。
request.timeout.ms	消费请求的超时时间。单位：毫秒。	30000	请求超时时间，请求超时会失败然后不断重试。

16.9 Kafka 安全使用说明

本章节内容适用于 MRS 3.x 及后续版本。

Kafka API 简单说明

- Producer API

  指 **org.apache.kafka.clients.producer.KafkaProducer** 中定义的接口，在使用“kafka-console-producer.sh”时，默认使用此 API。

- Consumer API

  指 **org.apache.kafka.clients.consumer.KafkaConsumer** 中定义的接口，在使用“kafka-console-consumer.sh”时，默认会调用此 API。

说明

MRS 3.x 后，Kafka 不支持旧 Producer API 和旧 Consumer API。

Kafka 访问协议说明

请参考 25.1 修改集群服务配置参数查看或配置参数。

Kafka 当前支持四种协议类型的访问：PLAINTEXT、SSL、SASL_PLAINTEXT、SASL_SSL。

Kafka 服务启动时，默认会启动 PLAINTEXT 和 SASL_PLAINTEXT 两种协议类型的访问监测。可通过设置 Kafka 服务配置“ssl.mode.enable”为“true”，来启动 SSL 和 SASL_SSL 两种协议类型的访问监测。下表是四种协议类型的简单说明：

协议类型	说明	默认端口
PLAINTEXT	支持无认证的明文访问	获取参数“port”的值，默认为 9092
SASL_PLAINTEXT	支持 Kerberos 认证的明文访问	获取参数“sasl.port”的值，默认为 21007
SSL	支持无认证的 SSL 加密访问	获取参数“ssl.port”的值，默认为 9093
SASL_SSL	支持 Kerberos 认证的 SSL 加密访问	获取参数“sasl-ssl.port”的值，默认为 21009

Topic 的 ACL 设置

Topic 的权限信息，需要在 Linux 客户端上，使用“kafka-acls.sh”脚本进行查看和设置，具体可参考 16.4 管理 Kafka 用户权限。

针对不同的 Topic 访问场景，Kafka 中 API 使用说明

- 场景一：访问设置了 ACL 的 Topic

使用的 API	用户属组	客户端参数	服务端参数	访问的端口
API	用户需满足以下条件之一即可： • 加入 System_administrator 角色	security.inter.broker.protocol=SASL_PLAINTEXT sasl.kerberos.service.name = kafka	-	sasl.port（默认 21007）
		security.protoco	“ssl.mode.enabl	sasl-ssl.port

使用的 API	用户属组	客户端参数	服务端参数	访问的端口
	• 属于 kafkaadmin 组 • 属于 kafkasuperuser 组 • 被授权的 kafka 组的用户	l=SASL_SSL sasl.kerberos.service.name = kafka	e”配置为 true	（默认 21009）

- 场景二：访问未设置 ACL 的 Topic

使用的 API	用户属组	客户端参数	服务端参数	访问的端口
API	用户需满足以下条件之一： • 加入 System_administrator 角色 • 属于 kafkaadmin 组 • 属于 kafkasuperuser 组	security.protocol=SASL_PLAINTEXT sasl.kerberos.service.name = kafka	-	sasl.port（默认 21007）
	用户属于 kafka 组		“allow.everyone.if.no.acl.found”配置为 true 说明 普通集群下不涉及服务端参数“allow.everyone.if.no.acl.found”的修改	sasl.port（默认 21007）
	用户需满足以下条件之一： • 加入 System_administrator 角色 • 属于 kafkaadmin 组 • kafkasuperuser 组用户	security.protocol=SASL_SSL sasl.kerberos.service.name = kafka	“ssl.mode.enable”配置为“true”	sasl-ssl.port（默认 21009）
	用户属于 kafka 组		1. “allow.everyone.if.no.acl.found”配置为	sasl-ssl.port（默认 21009）

使用的API	用户属组	客户端参数	服务端参数	访问的端口
			“true” 2. “ssl.mode.enable”配置为“true”	
	-	security.protocol=PLAINTEXT	“allow.everyone.if.no.acl.found”配置为“true”	port（默认9092）
	-	security.protocol=SSL	1. “allow.everyone.if.no.acl.found”配置为“true” 2. “ssl.mode.enable”配置为“true”	ssl.port（默认9063）

16.10 Kafka 业务规格说明

本章节内容适用于 MRS 3.x 及后续版本。

支持的 Topic 上限

支持 Topic 的个数，受限于进程整体打开的文件句柄数（现场环境一般主要是数据文件和索引文件占用比较多）。

1. 可通过 **ulimit -n** 命令查看进程最多打开的文件句柄数；
2. 执行 **lsof -p** <*Kafka PID*>命令，查看当前单节点上 Kafka 进程打开的文件句柄（会继续增加）；
3. 权衡当前需要创建的 Topic 创建完成后，会不会达到文件句柄上限，每个 Partition 文件夹下会最多保存多大的数据，会产生多少个数据文件（*.log 文件，默认配置为 1GB，可通过修改 **log.segment.bytes** 来调整大小）和索引文件（*.index 文件，默认配置为 10MB，可通过修改 **log.index.size.max.bytes** 来调整大小），是否会影响 Kafka 正常运行。

Consumer 的并发量

在一个应用中，同一个 Group 的 Consumer 并发量建议与 Topic 的 Partition 个数保持一致，保证每个 Consumer 对应消费一个 Partition 上的数据。若 Consumer 的并发量多于 Partition 个数，那么多余的 Consumer 将消费不到数据。

Topic 和 Partition 的划分关系说明

- 假设集群中部署了 K 个 Kafka 节点，每个节点上配置的磁盘个数为 N，每块磁盘大小为 M，集群中共有 n 个 Topic（T1,T2…Tn），并且其中第 m 个 Topic 的每秒输入数据总流量为 X(Tm) MB/s，配置的副本数为 R(Tm)，配置数据保存时间为 Y(Tm)小时，那么整体必须满足：

$$M \times N \times K > \sum_{i=T1}^{Tn} (X(i)R(i)Y(i) \times 3600)$$

- 假设单个磁盘大小为 M，该磁盘上有 n 个 Partition（P0,P1……Pn），并且其中第 m 个 Partition 的每秒写入数据流量为 Q(Pm) MB/s（计算方法：所属 Topic 的数据流量除以 Partition 数） 、数据保存时间为 T(Pm)小时，那么单个磁盘必须满足：

$$M > \sum_{i=P0}^{Pn} (Q(i)T(i) \times 3600)$$

- 根据吞吐量粗略计算，假设生产者可以达到的吞吐量为 P，消费者可以达到的吞吐量为 C，预期 Kafka 吞吐量为 T，那么建议该 Topic 的 Partition 数目设置为 Max(T/P , T/C)。

说明

- 在 Kafka 集群中，分区越多吞吐量越高，但是分区过多也存在潜在影响，例如文件句柄增加、不可用性增加（如：某个节点故障后，部分 Partition 重选 Leader 后时间窗口会比较大）及端到端时延增加等。
- 建议：单个 Partition 的磁盘占用最大不超过 100GB；单节点上 Partition 数目不超过 3000；整个集群的分区总数不超过 10000。

16.11 使用 Kafka 客户端

操作场景

该任务指导用户在运维场景或业务场景中使用 Kafka 客户端。

本章节适用于 MRS 3.x 及后续版本。

前提条件

- 已安装客户端。例如安装目录为“/opt/client”。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建。“机机”用户需要下载 keytab 文件。“人机”用户第一次登录时需修改密码。（普通模式不涉及）
- 在修改集群域名后，需要重新下载客户端，以保证客户端配置文件中 kerberos.domain.name 配置为正确的服务端域名。

操作步骤

以客户端安装用户，登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 执行以下命令，进行用户认证。（普通模式跳过此步骤）

kinit *组件业务用户*

步骤 4 执行以下命令切换到 Kafka 客户端安装目录。

cd Kafka/kafka/bin

步骤 5 执行以下命令使用客户端工具查看帮助并使用。

- **./kafka-console-consumer.sh**：Kafka 消息读取工具
- **./kafka-console-producer.sh**：Kafka 消息发布工具
- **./kafka-topics.sh**：Kafka Topic 管理工具

----结束

16.12 配置 Kafka 高可用和高可靠参数

操作场景

Kafka 消息传输保障机制，可以通过配置不同的参数来保障消息传输，进而满足不同的性能和可靠性要求。本章节介绍如何配置 Kafka 高可用和高可靠参数。

本章节内容适用于 MRS 3.x 及后续版本。

对系统的影响

- 配置高可用、高性能的影响：

须知

配置高可用、高性能模式后，数据可靠性会降低。在磁盘故障、节点故障等场景下存在数据丢失风险。

- 配置高可靠性的影响：
  - 性能降低：

    在生产数据时，配置了高可靠参数 ack=-1 之后，需要多个副本均写入成功之后才认为是写入成功。这样会导致单条消息时延增加，客户端处理能力下降。具体性能以现场实际测试数据为准。
  - 可用性降低：

    不允许不在 ISR 中的副本被选举为 Leader。如果 Leader 下线时，其他副本均不在 ISR 列表中，那么该分区将保持不可用，直到 Leader 节点恢复。当分区

的一个副本所在节点故障时，无法满足最小写入成功的副本数，那么将会导致业务写入失败。

- 参数配置项为服务级配置需要重启 Kafka，建议在变更窗口做服务级配置修改。

参数描述

- 如果业务需要保证高可用和高性能。

  在服务端配置如表 16-8 中参数，参数配置入口请参考 25.1 修改集群服务配置参数。

表16-8 服务端高可用性和高性能参数说明

参数	默认值	说明
unclean.leader.election.enable	true	是否允许不在 ISR 中的副本被选举为 Leader，若设置为 true，可能会造成数据丢失。
auto.leader.rebalance.enable	true	是否使用 Leader 自动均衡功能。 如果设为 true，Controller 会周期性的为所有节点的每个分区均衡 Leader，将 Leader 分配给更优先的副本。
min.insync.replicas	1	当 Producer 设置 acks 为-1 时，指定需要写入成功的副本的最小数目。

在客户端配置文件 producer.properties 中配置如表 16-9 中参数，producer.properties 存放路径为：/opt/client/Kafka/kafka/config/producer.properties，其中/opt/client 为 Kafka 客户端安装目录。

表16-9 客户端高可用性和高性能参数说明

参数	默认值	说明
acks	1	需要 Leader 确认消息是否已经接收并认为已经处理完成。该参数会影响消息的可靠性和性能。 • acks=0 ：Producer 将不会等待服务端任何响应。消息将会被认为成功。 • acks=1 ：当副本所在 Leader 确认数据已写入，但是其不会等待所有的副本完全写入即返回响应。在这种情况下，如果 Leader 确认

参数	默认值	说明
		后但是副本未同步完成时 Leader 异常，那么数据就会丢失。 • acks=-1 ：意味着等待所有的同步副本确认后才认为成功，配合“min.insync.replicas”可以确保多副本写入成功，只要有一个副本保持活跃状态，记录将不会丢失。

- 如果业务需要保证数据高可靠性。

  在服务端配置如表 16-10 参数，参数配置入口请参考 25.1 修改集群服务配置参数。

表16-10 服务端高可靠性参数说明

参数	建议值	说明
unclean.leader.election.enable	false	不允许不在 ISR 中的副本被选举为 Leader。
min.insync.replicas	2	当 Producer 设置 acks 为-1 时，指定需要写入成功的副本的最小数目。 需要满足 min.insync.replicas <= replication.factor。

在客户端配置文件 producer.properties 中配置如表 16-11 中参数，producer.properties 存放路径为：/opt/client/Kafka/kafka/config/producer.properties，其中/opt/client 为 Kafka 客户端安装目录。

表16-11 客户端高可靠性参数说明

参数	建议值	说明
acks	-1	Producer 需要 Leader 确认消息是否已经接收并认为已经处理完成。 acks=-1 需要等待在 ISR 列表的副本都确认接收到消息并处理完成才表示消息成功。配合“min.insync.replicas”可以确保多副本写入成功，只

参数	建议值	说明
		要有一个副本保持活跃状态，记录将不会丢失，此参数配置为-1 时，会降低生产性能，请权衡后配置。

配置建议

请根据以下业务场景对可靠性和性能要求进行评估，采用合理参数配置。

- 对于价值数据，这两种场景下建议 Kafka 数据目录磁盘配置 raid1 或者 raid5，从而提高单个磁盘故障情况下数据可靠性。
- 参数配置项均为 Topic 级别可修改的参数，默认采用服务级配置。

  可针对不同 Topic 可靠性要求对 Topic 进行单独配置。以 root 用户登录 Kafka 客户端节点，在客户端安装目录下配置 Topic 名称为 test 的可靠性参数命令：

  cd Kafka/kafka/bin

  kafka-topics.sh --zookeeper 192.168.1.205:2181/kafka --alter --topic test --config unclean.leader.election.enable=false --config min.insync.replicas=2

  其中 192.168.1.205 为 ZooKeeper 业务 IP 地址。
- 参数配置项为服务级配置需要重启 Kafka，建议在变更窗口做服务级配置修改。

16.13 更改 Broker 的存储目录

操作场景

本章节内容适用于 MRS 3.x 及后续版本。

增加 Broker 的存储目录时，MRS 集群管理员需要在 FusionInsight Manager 中修改 Broker 的存储目录，以保证 Kafka 正常工作，新创建的主题分区将在分区最少的目录中生成。适用于以下场景：

说明

由于 Kafka 不感知磁盘容量，建议各 Broker 实例配置的磁盘个数和容量保持一致。

- 更改 Broker 角色的存储目录，所有 Broker 实例的存储目录将同步修改。
- 更改 Broker 单个实例的存储目录，只对单个实例生效，其他节点 Broker 实例存储目录不变。

对系统的影响

- 更改 Broker 角色的存储目录需要重新启动服务，服务重启时无法访问。
- 更改 Broker 单个实例的存储目录需要重新启动实例，该节点 Broker 实例重启时无法提供服务。

- 服务参数配置如果使用旧的存储目录，需要更新为新目录。

前提条件

- 在各个数据节点准备并安装好新磁盘，并格式化磁盘。
- 已安装好 Kafka 客户端。
- 更改 Broker 单个实例的存储目录时，保持活动的 Broker 实例数必须大于创建主题时指定的备份数。

操作步骤

更改 Kafka 角色的存储目录

以 **root** 用户登录到安装 Kafka 服务的各个数据节点中，执行如下操作。

1. 创建目标目录。

   例如目标目录为“${BIGDATA_DATA_HOME}/kafka/data2”：

   执行 **mkdir ${BIGDATA_DATA_HOME}/kafka/data2**。

2. 挂载目录到新磁盘。例如挂载“${BIGDATA_DATA_HOME}/kafka/data2”到新磁盘。
3. 修改新目录的权限。

   例如新目录路径为“${BIGDATA_DATA_HOME}/kafka/data2”：

   执行 **chmod 700 ${BIGDATA_DATA_HOME}/kafka/data2 -R** 和 **chown omm:wheel ${BIGDATA_DATA_HOME}/kafka/data2 -R**。

步骤 1 MRS 3.x 及后续版本，登录 FusionInsight Manager，然后选择“集群 > 服务 > Kafka > 配置”。

步骤 2 添加新目录到“log.dirs”的默认值后面。

在搜索框中输入“log.dirs”进行搜索，将新目录添加到配置项“log.dirs”的默认值后面，多个目录使用逗号分隔。例如“

${BIGDATA_DATA_HOME}/kafka/data1/kafka-logs,${BIGDATA_DATA_HOME}/kafka/data2/kafka-logs”。

步骤 3 单击“保存”，并单击“确定”。界面提示“操作成功”，单击“完成”。

步骤 4 选择“集群 > 服务 > Kafka ，右上角选择“更多 > 重启服务”，重启 Kafka 服务。

更改 Kafka 单个实例的存储目录

以 **root** 用户登录到 Broker 节点，执行如下操作。

1. 创建目标目录。

   例如目标目录为“${BIGDATA_DATA_HOME}/kafka/data2”：

   执行 **mkdir ${BIGDATA_DATA_HOME}/kafka/data2**。

2. 挂载目录到新磁盘。例如挂载“${BIGDATA_DATA_HOME}/kafka/data2”到新磁盘。
3. 修改新目录的权限。

例如新目录路径为“${BIGDATA_DATA_HOME}/kafka/data2”：

执行 **chmod 700 ${BIGDATA_DATA_HOME}/kafka/data2 -R** 和 **chown omm:wheel ${BIGDATA_DATA_HOME}/kafka/data2 -R**。

步骤 5 MRS 3.x 及后续版本，登录 FusionInsight Manager，然后选择“集群 > 服务 > Kafka > 实例”。

步骤 6 单击指定的 Broker 实例并切换到“实例配置”。

在搜索框中输入“log.dirs”进行搜索，将新目录添加到配置项“log.dirs”的默认值后面，多个目录使用逗号分隔。例如“${BIGDATA_DATA_HOME}/kafka/data1/kafka-logs,${BIGDATA_DATA_HOME}/kafka/data2/kafka-logs”。

步骤 7 单击“保存”，并单击“确定”，界面提示“操作成功”，单击“完成”。

步骤 8 在 Broker 实例页面选择“更多 > 重启实例”，重启 Broker 实例。

----结束

16.14 查看 Consumer Group 消费情况

操作场景

该任务指导 MRS 集群管理员根据业务需求，在客户端中查看当前消费情况。

本章节内容适用于 MRS 3.x 及后续版本。

前提条件

- MRS 集群管理员已明确业务需求，并准备一个系统用户。
- 已安装 Kafka 客户端。

操作步骤

以客户端安装用户，登录安装 Kafka 客户端的节点。

步骤 1 切换到 Kafka 客户端安装目录，例如“/opt/client”。

cd /opt/client

步骤 2 执行以下命令，配置环境变量。

source bigdata_env

步骤 3 执行以下命令，进行用户认证。（普通模式跳过此步骤）

kinit *组件业务用户*

步骤 4 执行以下命令，切换到 Kafka 客户端安装目录。

cd Kafka/kafka/bin

步骤 5 使用 **kafka-consumer-groups.sh** 查看当前消费情况。

- 查看 Offset 保存在 Kafka 上的 Consumer Group 列表：

  ./kafka-consumer-groups.sh --list --bootstrap-server *<Broker 的任意一个节点的业务 IP:Kafka 集群 IP 端口号>* **--command-config ../config/consumer.properties**

  例如：**./kafka-consumer-groups.sh --bootstrap-server 192.168.1.1:21007 --list --command-config ../config/consumer.properties**

- 查看 Offset 保存在 Kafka 上的 Consumer Group 消费情况：

  ./kafka-consumer-groups.sh --describe --bootstrap-server *<Broker 的任意一个节点的业务 IP:Kafka 集群 IP 端口号> --group 消费组名称* **--command-config ../config/consumer.properties**

  例如：**./kafka-consumer-groups.sh --describe --bootstrap-server 192.168.1.1:21007 --group example-group --command-config ../config/consumer.properties**

须知

1. 确保当前 consumer 在线消费。
2. 确保配置文件 consumer.properties 中的 group.id 与命令中--group 的参数均配置为待查询的 group。
3. Kafka 集群 IP 端口号安全模式下是 21007，普通模式下是 9092。

----结束

16.15 Kafka 均衡工具使用说明

操作场景

该任务指导管理员根据业务需求，在客户端中执行 Kafka 均衡工具来均衡 Kafka 集群的负载，一般用于节点的退服、入服以及负载均衡的场景。

前提条件

- MRS 集群管理员已明确业务需求，并准备一个 Kafka 管理员用户（属于 kafkaadmin 组，普通模式不需要）。
- 已安装 Kafka 客户端。

操作步骤

以客户端安装用户，登录已安装 Kafka 客户端的节点。

步骤 1 切换到 Kafka 客户端安装目录，例如“/opt/client”。

cd /opt/client

步骤 2 执行以下命令，配置环境变量。

source bigdata_env

步骤 3 执行以下命令，进行用户认证（普通模式跳过此步骤）。

kinit *组件业务用户*

步骤 4 执行以下命令，切换到 Kafka 客户端安装目录。

cd Kafka/kafka

步骤 5 使用“kafka-balancer.sh”进行用户集群均衡，常用命令如下：

- 使用--run 命令执行集群均衡：

  ./bin/kafka-balancer.sh --run --zookeeper <*ZooKeeper 的任意一个节点的业务 IP:zkPort/**kafka***> **--bootstrap-server** <*Kafka 集群 IP: port*> **--throttle 10000000 --consumer-config config/consumer.properties --show-details**

  该命令包含均衡方案的生成和执行两部分，其中--show-details 为可选参数，表示是否打印方案明细，--throttle 表示均衡方案执行时的带宽限制，单位:bytes/sec。

- 使用--run 命令执行节点退服：

  ./bin/kafka-balancer.sh --run --zookeeper <*ZooKeeper 的任意一个节点的业务 IP:zkPort/**kafka***> **--bootstrap-server** <*Kafka 集群 IP: port*> **--throttle 10000000 --consumer-config config/consumer.properties --remove-brokers** <*BrokerId 列表*> **--force**

  其中--remove-brokers 表示要删除的 BrokerId 列表，多个间用逗号分隔，--force 参数为可选参数，表示忽略磁盘使用率告警，强制生成迁移方案。

  说明

  此退服命令会将待退服 Broker 节点上的数据迁移至其他 Broker 节点。

- 查看执行状态：

  ./bin/kafka-balancer.sh --status --zookeeper <*ZooKeeper 的任意一个节点的业务 IP:zkPort/**kafka***>

- 生成均衡方案：

  ./bin/kafka-balancer.sh --generate --zookeeper <*ZooKeeper 的任意一个节点的业务 IP:zkPort/**kafka***> **--bootstrap-server** <*Kafka 集群 IP:port*> **--consumer-config config/consumer.properties**

  该命令仅根据集群当前状态生成迁移方案，并打印到控制台。

- 清理中间状态

  ./bin/kafka-balancer.sh --clean --zookeeper <*ZooKeeper 的任意一个节点的业务 IP:zkPort/**kafka***>

  一般在迁移没有正常执行完成时用来清理 ZooKeeper 上的中间状态信息。

须知

Kafka 集群 IP 端口号安全模式下是 21007，普通模式下是 9092。

----结束

异常情况处理

在使用 Kafka 均衡工具进行 Partition 迁移的过程中，如果出现集群中 Broker 故障导致均衡工具的执行进度阻塞，这时需要人工介入来恢复，分为以下几种场景：

- 存在 Broker 因为磁盘占有率达到 100%导致 Broker 故障的情况。
  a. 登录 FusionInsight Manager，选择“集群 > 服务 > Kafka > 实例”，将运行状态为“正在恢复”的 Broker 实例停止并记录实例所在节点的管理 IP 地址以及对应的“broker.id”，该值可通过单击角色名称，在“实例配置”页面中选择“全部配置”，搜索“broker.id”参数获取。
  b. 以 **root** 用户登录记录的管理 IP 地址，并执行 **df -lh** 命令，查看磁盘占用率为 100%的挂载目录，例如“${BIGDATA_DATA_HOME}/kafka/data1”。
  c. 进入该目录，执行 **du -sh *** 命令，查看该目录下各文件夹的大小。查看是否存在除“kafka-logs”目录外的其他文件，并判断是否可以删除或者迁移。
     - 是，删除或者迁移相关数据，然后执行 8。
     - 否，执行 4。
  d. 进入“kafka-logs”目录，执行 **du -sh *** 命令，选择一个待移动的 Partition 文件夹，其名称命名规则为“Topic 名称-Partition 标识”，记录 Topic 及 Partition。
  e. 修改“kafka-logs”目录下的“recovery-point-offset-checkpoint”和“replication-offset-checkpoint”文件（两个文件做同样的修改）。
     i. 减少文件中第二行的数字（若移出多个目录，则减少的数字为移出的目录个数）。
     ii. 删除待移出的 Partition 所在的行（行结构为“Topic 名称 Partition 标识 Offset”，删除前先将该行数据保存，后续此内容还要添加到目的目录下的同名文件中）。
  f. 修改目的数据目录下（例如：“${BIGDATA_DATA_HOME}/kafka/data2/kafka-logs”）的“recovery-point-offset-checkpoint”和“replication-offset-checkpoint”文件（两个文件做同样的修改）。
     - 增加文件中第二行的数字（若移入多个 Partition 目录，则增加的数字为移入的 Partition 目录个数）。
     - 添加待移入的 Partition 行到文件末尾（行结构为“Topic 名称 Partition 标识 Offset”，直接复制 5 中保存的行数据即可）。
  g. 移动数据，将待移动的 Partition 文件夹移动到目的目录下，移动完成后执行 **chown omm:wheel -R** *Partition 目录* 命令修改 Partition 目录属组。
  h. 登录 FusionInsight Manager，选择“集群 > 服务 > Kafka > 实例”，启动停止的 Broker 实例。
  i. 等待 5 至 10 分钟后查看 Broker 实例的运行状态是否为“良好”。
     - 是，修复完成后按照“ALM-38001 Kafka 磁盘容量不足”告警指导彻底解决磁盘容量不足问题。
     - 否，联系运维人员。

  按照上述步骤将故障 Broker 进行恢复后，阻塞的均衡任务会继续执行，可使用--status 命令来查看任务的执行进度。

- 存在由其他原因导致的 Broker 故障，且问题场景单一明确，短时间内可以恢复 Broker 的情况。
  a. 根据问题根因指定恢复方案，恢复故障 Broker。
  b. 故障 Broker 恢复后，阻塞的均衡任务会继续执行，可使用--status 命令来查看任务的执行进度。
- 存在由其他原因导致的 Broker 故障，且问题场景复杂，短时间内无法恢复 Broker 的情况。
  a. 执行 **kinit** *Kafka 管理员用户*。（普通模式跳过此步骤）
  b. 使用 **zkCli.sh -server** <*ZooKeeper 集群业务 IP:zkPort/**kafka***>登录 ZooKeeper Shell。
  c. 执行 **addauth krbgroup**。（普通模式跳过此步骤）
  d. 删除“/admin/reassign_partitions”目录和“/controller”目录。
  e. 通过以上步骤强行终止迁移，待集群恢复后使用 **kafka-reassign-partitions.sh** 命令手动将中间过程中导致的多余的副本删除。

16.16 Kafka Token 认证机制工具使用说明

操作场景

使用 Token 认证机制时对 Token 的操作。

本章节内容适用于 MRS 3.x 及后续版本的启用 Kerberos 认证的集群。

前提条件

- MRS 集群管理员已明确业务需求，并准备一个系统用户。
- 已开启 Token 认证机制。
- 已安装 Kafka 客户端。

操作步骤

以客户端安装用户，登录安装 Kafka 客户端的节点。

步骤 1 切换到 Kafka 客户端安装目录，例如“/opt/client”。

cd /opt/client

步骤 2 执行以下命令，配置环境变量。

source bigdata_env

步骤 3 执行以下命令，进行用户认证。

kinit *组件业务用户*

步骤 4 执行以下命令，切换到 Kafka 客户端安装目录。

cd Kafka/kafka/bin

步骤 5 使用 **kafka-delegation-tokens.sh** 对 Token 进行操作

- 为用户生成 Token

  ./kafka-delegation-tokens.sh --create --bootstrap-server <*IP1:PORT, IP2:PORT,...***> --max-life-time-period <***Long: max life period in milliseconds***> --command-config <***config file***> --renewer-principal User:<***user name***>**

  例如： **./kafka-delegation-tokens.sh --create --bootstrap-server 192.168.1.1:21007,192.168.1.2:21007,192.168.1.3:21007 --command-config ../config/producer.properties --max-life-time-period -1 --renewer-principal User:username**

- 列出归属在特定用户下的所有 Token 信息

  ./kafka-delegation-tokens.sh --describe --bootstrap-server <*IP1:PORT, IP2:PORT,...***> --command-config <***config file***> --owner-principal User:<***user name***>**

  例如： **./kafka-delegation-tokens.sh --describe --bootstrap-server 192.168.1.1:21007,192.168.1.2:21007,192.168.1.3:21007 --command-config ../config/producer.properties --owner-principal User:username**

- Token 有效期刷新

  ./kafka-delegation-tokens.sh --renew --bootstrap-server <*IP1:PORT, IP2:PORT,...***> --renew-time-period <***Long: renew time period in milliseconds***> --command-config <***config file***> --hmac <***String: HMAC of the delegation token***>**

  例如： **./kafka-delegation-tokens.sh --renew --bootstrap-server 192.168.1.1:21007,192.168.1.2:21007,192.168.1.3:21007 --renew-time-period -1 --command-config ../config/producer.properties --hmac ABCDEFG**

- 销毁 Token

  ./kafka-delegation-tokens.sh --expire --bootstrap-server <*IP1:PORT, IP2:PORT,...***> --expiry-time-period <***Long: expiry time period in milliseconds***> --command-config <***config file***> --hmac <***String: HMAC of the delegation token***>**

  例如： **./kafka-delegation-tokens.sh --expire --bootstrap-server 192.168.1.1:21007,192.168.1.2:21007,192.168.1.3:21007 --expiry-time-period -1 --command-config ../config/producer.properties --hmac ABCDEFG**

----结束

16.17 使用 KafkaUI

16.17.1 访问 KafkaUI

操作场景

MRS 集群安装 Kafka 组件后，通过 KafkaUI，用户能够便捷查询集群信息、节点状态、topic 分区、数据的生产、消费详情等多维度信息。KafkaUI 将 topic 创建、删除、配置修改、扩展分区、分区迁移等复杂易出错的管理操作界面化，降低用户使用门槛，提高运维效率。

前提条件

已创建具有 KafkaUI 页面访问权限的用户，如需在页面上进行相关操作，例如创建 Topic，需同时授予用户相关权限，请参考 16.4 管理 Kafka 用户权限。

对系统的影响

第一次访问 Manager 和 KafkaUI，需要在浏览器中添加站点信任以继续访问 KafkaUI。

操作步骤

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务 > Kafka”。

步骤 1 在“KafkaManager WebUI”右侧，单击 URL 链接，访问 KafkaUI 的页面。

KafkaUI 界面支持以下功能：

- 集群内部分区重分布
- 创建、查看和删除 topic
- 对已有 topic 进行加分区、配置修改
- 查看 topic 生产数据信息
- 查看 Broker 实例信息
- 查看 Consumer Group 消费情况

----结束

16.17.2 KafkaUI 概览

操作场景

用户通过登录 KafkaUI 可在主页查看当前集群已有的 Cluster、Topic、Broker 和 Consumer Group 的基本情况，对 Topic 执行创建、删除、增加分区、修改配置操作，还可以执行集群内分区迁移。

操作步骤

Cluster Summary

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 在“Cluster Summary”栏，可查看当前集群已有的 Topic、Broker 和 Consumer Group 数量。

步骤 2 单击“Brokers”下方的数字，可自动跳转至“Brokers”页面，在该页面的具体操作请参考 16.17.6 使用 KafkaUI 查看 Broker。

单击“Topics”下方的数字，可自动跳转至“Topics”页面，在该页面的具体操作请参考 16.17.5 使用 KafkaUI 管理 Topic。

单击“Consumer Group”下方的数字，可自动跳转至“Consumers”页面，在该页面的具体操作请参考 16.17.7 使用 KafkaUI 查看 Consumer Group。

----结束

Cluster Action

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 3 在“Cluster Action”栏，可创建 Topic 与分区迁移，具体操作请分别参考 16.17.3 在 KafkaUI 创建 Topic 和 16.17.4 在 KafkaUI 进行分区迁移章节。

----结束

Topic Rank

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 4 在“Topic Rank”栏，可查看当前集群 Topic 日志条数、数据体积大小、数据流入量、数据流出量前十名的 Topic。

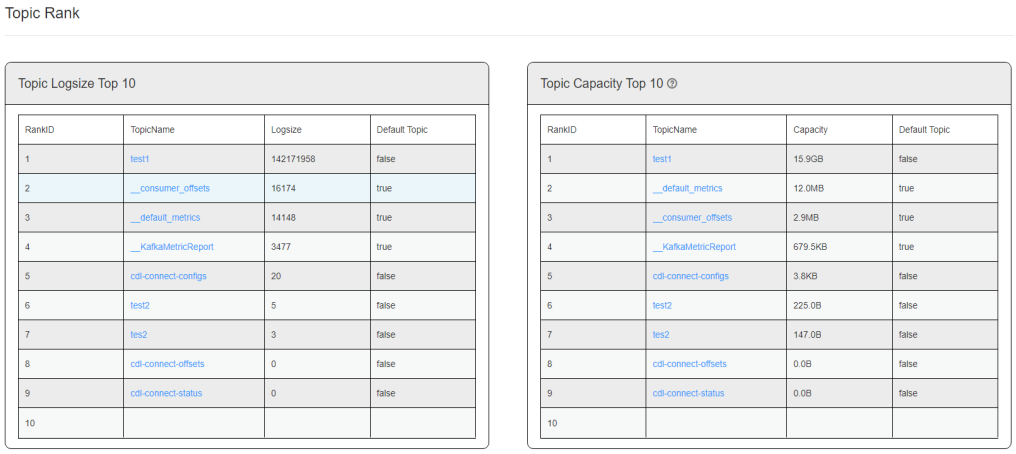

步骤 5 单击“TopicName”可进入到该 Topic 的详情页面中，在该页面的具体操作请参考 16.17.5 使用 KafkaUI 管理 Topic。

----结束

16.17.3 在 KafkaUI 创建 Topic

操作场景

通过 KafkaUI 创建 Topic。

创建 Topic

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Create Topic”进入创建 Topic 页面。在弹出的页面中参考表 16-12 填写信息，单击“Create”，完成 Topic 创建。

表16-12 创建 Topic 信息

参数名称	参数描述	备注
Topic	Topic 的名称，只能包含英文字母、数字、中划线和下划线，且不能多于 249 个字符。	例如：kafka_ui
Partitions	Topic 的分区数量，取值范围大于等于 1，默认为 3。	-
Replication Factor	Topic 的副本因子，取值范围为 1~*N*，N 为当前集群 Broker 个数，默认为 2。	-

说明

- 用户可根据业务需要单击“Advanced Options”配置 topic 相关高级参数，通常保持默认即可。

- 安全模式集群下，执行 Create Topic 操作的用户需属于“kafkaadmin”用户组，否则将会由于鉴权失败导致无法创建。
- 非安全模式集群下，执行 Create Topic 操作不作鉴权，即任意用户都可执行 Create Topic 操作。

----结束

16.17.4 在 KafkaUI 进行分区迁移

操作场景

通过 KafkaUI 进行分区迁移。

说明

- 安全模式集群下，执行分区迁移操作的用户需属于“kafkaadmin”用户组，否则将会由于鉴权失败导致操作失败。
- 非安全模式下，KafkaUI 对任意操作不作鉴权处理。

分区迁移

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。单击“Generate assignment”进入分区迁移页面。

步骤 1 在“Brokers”处选择要将主题重新分配的 Broker。

步骤 2 单击“Generate Partition Assignments”生成分区迁移方案。

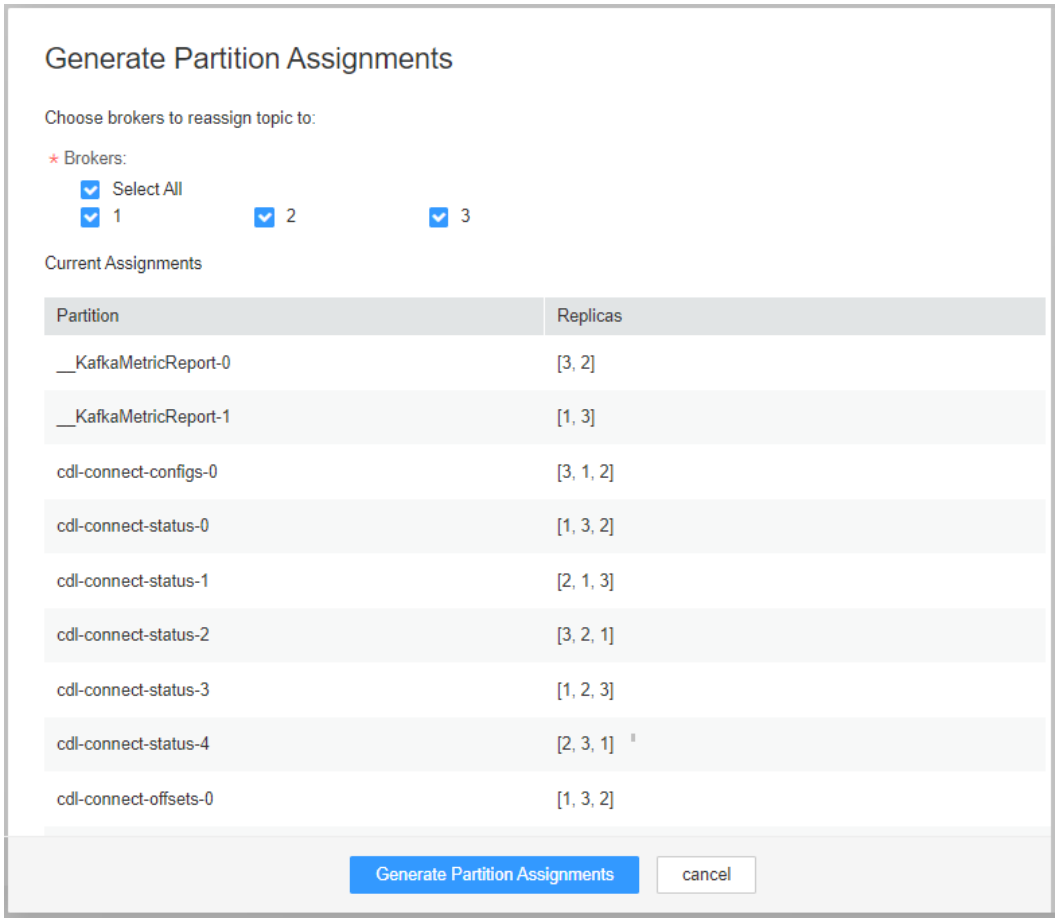

步骤 3 继续单击“Run assignment”执行分区迁移方案，完成分区迁移。

----结束

16.17.5 使用 KafkaUI 管理 Topic

操作场景

通过 KafkaUI 查看 Topic 详情、修改 Topic Configs、增加 Topic 分区个数、删除 Topic，并可实时查看不同时段的生产数据条数。

说明

- 安全模式下，KafkaUI 对查看 Topic 详情操作不作鉴权处理，即任何用户都可以查询 Topic 信息；对于修改 Topic Configs、增加 Topic 分区个数、删除 Topic 场景，需保证 KafkaUI 登录用户属于“kafkaadmin”用户组或者单独给用户授予对应操作权限，否则将会鉴权失败。
- 非安全模式下，KafkaUI 对所有操作不作鉴权处理。

查看 Topic 详情

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Topics”，进入 Topic 管理页面。

步骤 2 在“Topic List”栏可查看当前集群已创建的 Topic 的名称、状态、分区数量、创建时间和副本个数等信息。

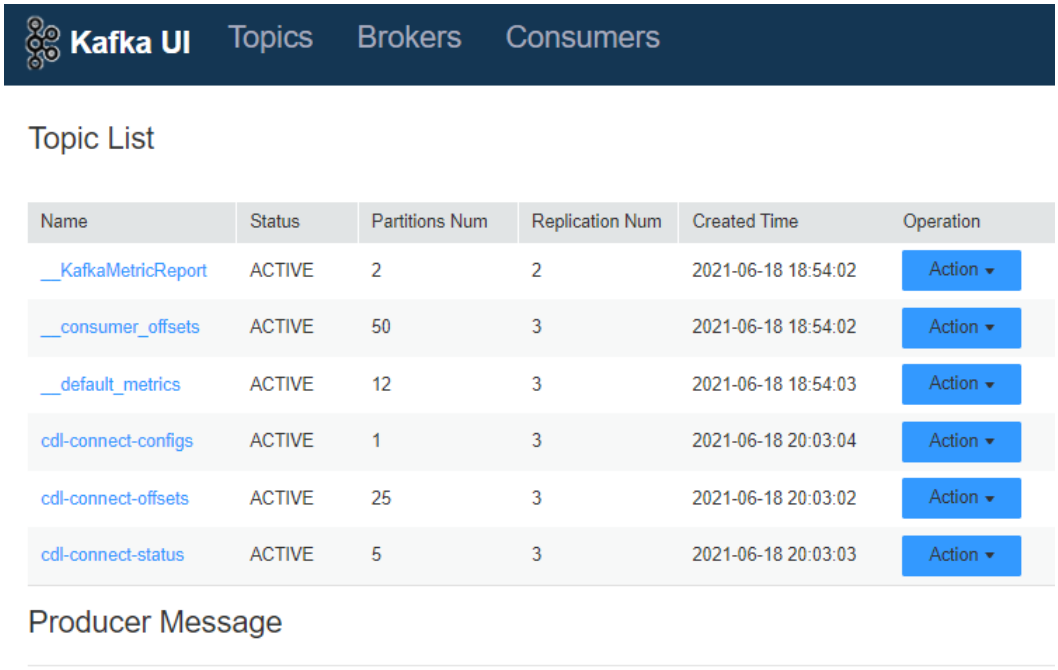

步骤 3 单击 Topic 名称可进入 Topic 详情页面。在该页面可查看 Topic 与分区的详细信息。

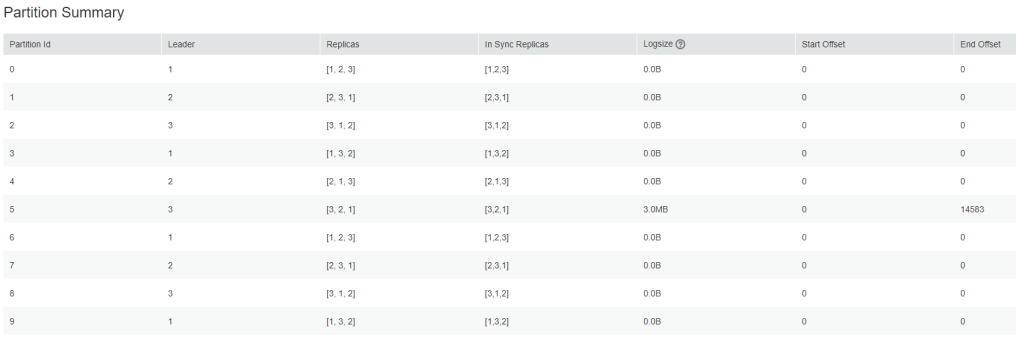

步骤 4 在“Producer Message”栏可根据业务需求选择“Day”、“Week”、“Month”不同时段查看此 Topic 生产数据条数。

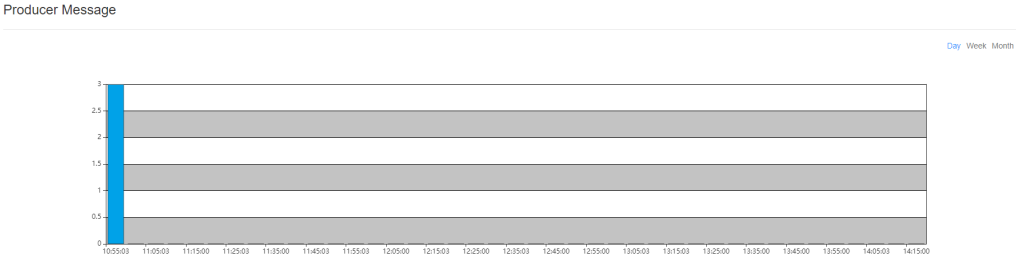

----结束

修改 Topic 配置

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Topics”，进入 Topic 管理页面。

在待修改项的“Operation”列单击“Action > Config”，弹出的页面中可修改 Topic 的“Key”和“Value”值，如需要添加多条，可单击+添加。

步骤 2 单击“OK”完成修改。

----结束

搜索 Topic

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Topics”，进入 Topic 管理页面。

步骤 2 在页面右上角，用户可以输入 Topic 名称搜索查看该 Topic 信息。

----结束

增加分区

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Topics”，进入 Topic 管理页面。

步骤 2 在待修改项的“Operation”列单击“Action > Alter”，弹出的页面中修改 Topic 分区。

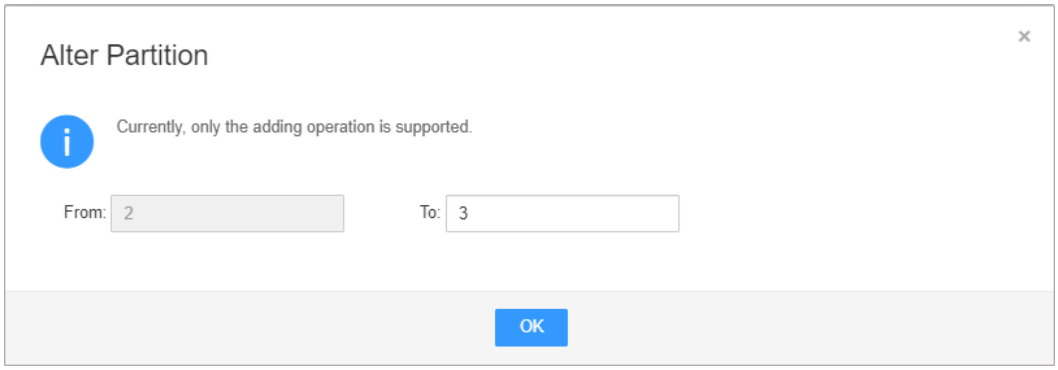

说明

目前集群只支持增加分区操作，即修改的分区个数要大于原设置的分区个数。

步骤 3 单击“OK”完成修改。

----结束

删除 Topic

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Topics”，进入 Topic 管理页面。

步骤 2 在待修改项的“Operation”列单击“Action > Delete”。

步骤 3 在弹出的确认信息页面中单击“OK”即可完成删除。

说明

系统默认内置的 Topic 不支持删除操作。

----结束

查看生产数据条数

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Topics”，进入 Topic 管理页面。

步骤 2 在“Producer Message”栏可选择“Day”、“Week”、“Month”不同时段查看当前集群所有集群生产数据条数。

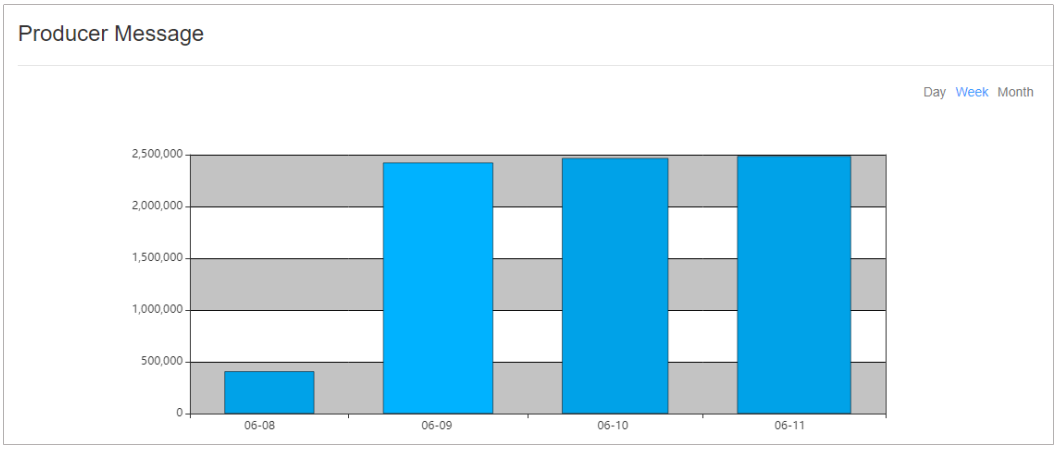

----结束

16.17.6 使用 KafkaUI 查看 Broker

操作场景

通过 KafkaUI 可查看的 Broker 的详情信息与 Broker 节点数据流量的 jmx 指标。

查看 Broker

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Brokers”，进入 Broker 详情页面。

步骤 2 在“Broker Summary”一栏可查看 Broker 的“Broker ID”、“Host”、“Rack”、“Disk(Used|Total)”和“Memory(Used|Total)”。

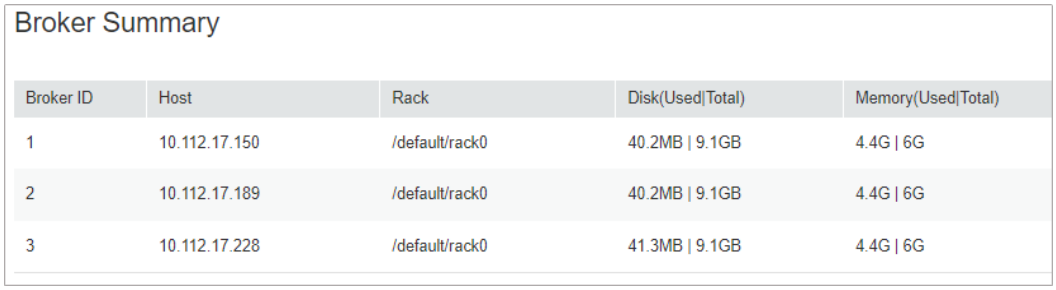

Broker Summary

Broker ID	Host	Rack	Disk(Used|Total)	Memory(Used|Total)
1	10.112.17.150	/default/rack0	40.2MB | 9.1GB	4.4G | 6G
2	10.112.17.189	/default/rack0	40.2MB | 9.1GB	4.4G | 6G
3	10.112.17.228	/default/rack0	41.3MB | 9.1GB	4.4G | 6G

步骤 3 在“Brokers Metrics”处可查看 Broker 节点数据流量的 jmx 指标，包括在不同时段的时间窗口内，Broker 节点平均每秒流入消息条数， 每秒流入消息字节数， 每秒流出消息字节数，每秒失败的请求数，每秒总的请求数和每秒生产的请求数。

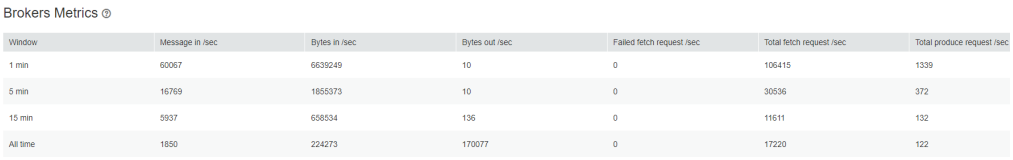

Brokers Metrics

Window	Message in /sec	Bytes in /sec	Bytes out /sec	Failed fetch request /sec	Total fetch request /sec	Total produce request /sec
1 min	60067	6639249	10	0	106415	1339
5 min	16769	1855373	10	0	30536	372
15 min	5937	658534	136	0	11611	132
All time	1850	224273	170077	0	17220	122

----结束

搜索 Broker

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Brokers”，进入 Broker 详情页面。

步骤 2 在页面右上角，用户可以输入主机 IP 地址或者机架配置信息搜索查看该 Broker 信息。

----结束

16.17.7 使用 KafkaUI 查看 Consumer Group

操作场景

通过 KafkaUI 可查看消费组的基本信息以及组内包含的 Topic 的消费状态。

查看消费组

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Consumers”，进入消费组详情页面，可以查看当前集群内的所有 ConsumerGroups，并可以查看各个 ConsumerGroups Coordinator 所在节点 IP，在页面右上角，用户可以输入 ConsumerGroup 来搜索指定的 ConsumerGroup 信息。

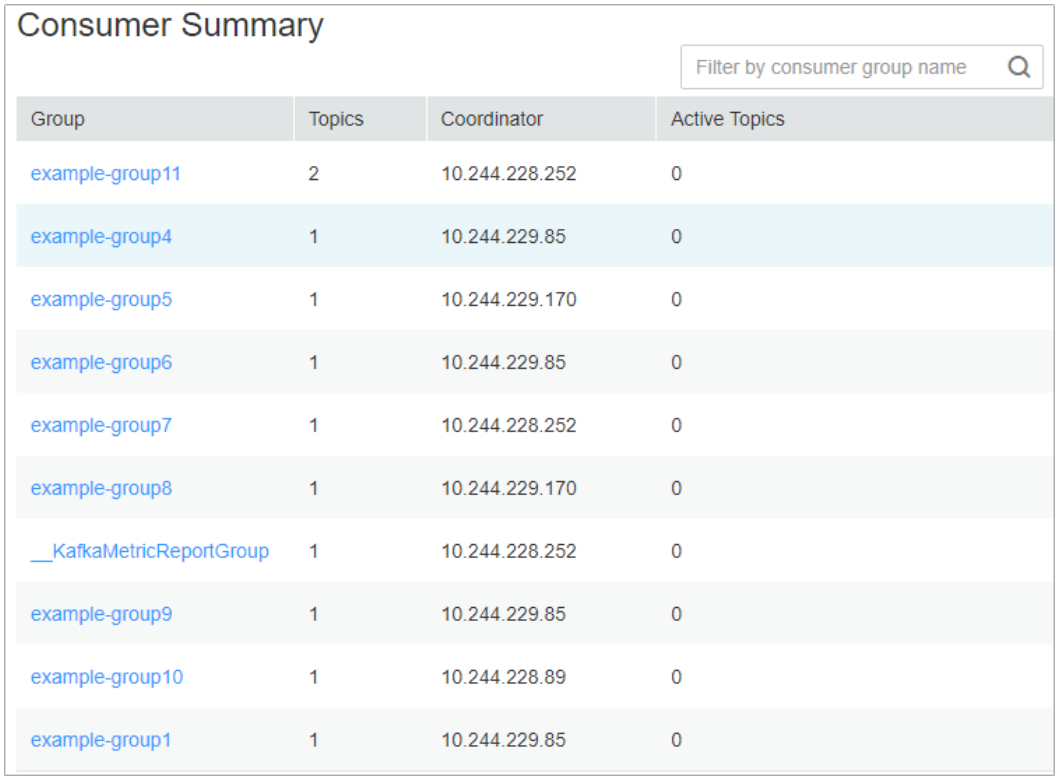

步骤 2 在 Consumer Summary 一栏，可查看当前集群已存在的消费组，单击消费组名称，可查看该消费组所消费过的 Topic，消费过的 Topic 有两种状态：“pending”和“running”，分别表示“曾经消费过但现在未消费”和“现在正在消费”，在弹框右上角，可以输入 Topic 名来进行过滤。

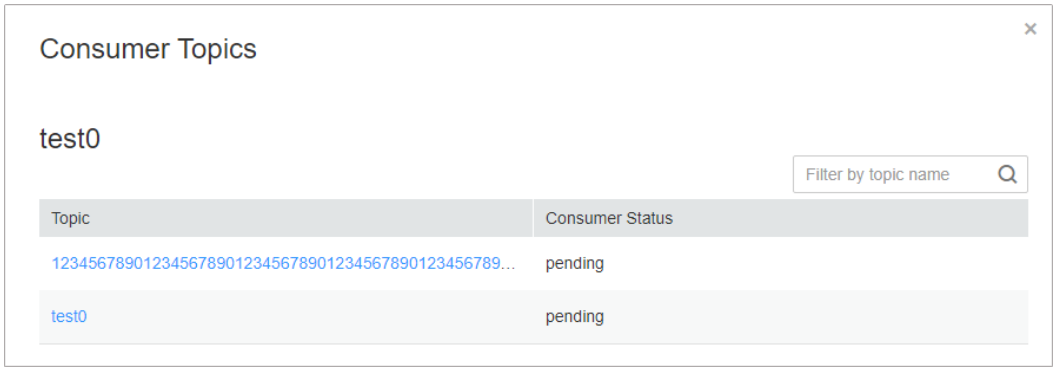

步骤 3 单击 Topic 名称，进入 Consumer Offsets 页面，可查看 Topic 消费详情。

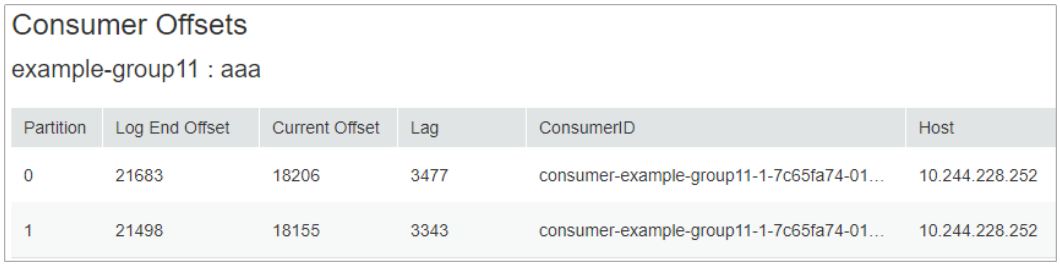

----结束

查看消费血缘图

进入 KafkaUI，请参考 16.17.1 访问 KafkaUI。

步骤 1 单击“Consumers”，进入消费组详情页面。在 Active Topic 处可以查看当前集群所有的消费组，以及各个 Consumer Group 正在消费的 Topic。

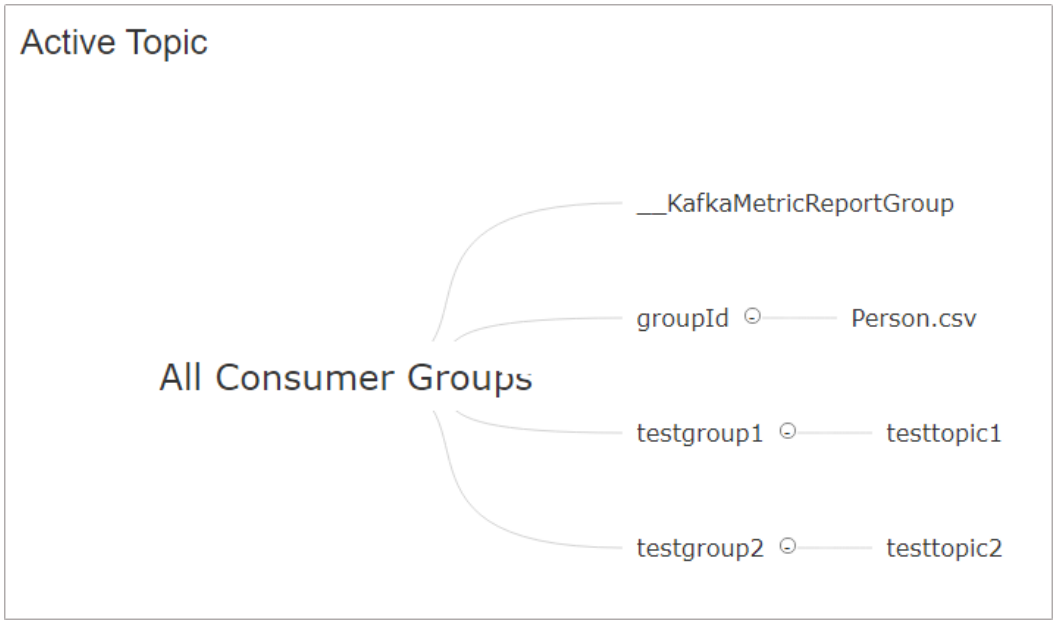

说明

MRS 集群当前不支持单击消费组名称进行跳转。

----结束

16.18 Kafka 日志介绍

日志描述

日志路径：Kafka 相关日志的默认存储路径为“/var/log/Bigdata/kafka”，审计日志的默认存储路径为“/var/log/Bigdata/audit/kafka”。

- Broker：“/var/log/Bigdata/kafka/broker”（运行日志）
- KafkaUI：“/var/log/Bigdata/kafka/ui”（运行日志）
- MirrorMaker：“/var/log/Bigdata/kafka/mirrormaker”（运行日志）

日志归档规则：Kafka 的日志启动了自动压缩归档功能，默认情况下，当日志大小超过 30MB 的时候，会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”。默认最多保留最近的 20 个压缩文件，压缩文件保留个数和压缩文件阈值可以配置。

表16-13 Broker 日志列表

日志类型	日志文件名	描述

日志类型	日志文件名	描述
运行日志	server.log	Broker 进程的 server 运行日志。
	controller.log	Broker 进程的 controller 运行日志。
	kafka-request.log	Broker 进程的 request 运行日志。
	log-cleaner.log	Broker 进程的 cleaner 运行日志。
	state-change.log	Broker 进程的 state-change 运行日志。
	kafkaServer-<SSH_USER>-<DATE>-<PID>-gc.log	Broker 进程的 GC 日志。
	postinstall.log	Broker 安装后的工作日志。
	prestart.log	Broker 启动前的工作日志。
	checkService.log	Broker 启动是否成功的检查日志。
	start.log	Broker 进程启动日志。
	stop.log	Broker 进程停止日志。
	checkavailable.log	Kafka 服务健康状态检查日志。
	checkInstanceHealth.log	Broker 实例健康状态检测日志。
	kafka-authorizer.log	Broker 鉴权日志。
	kafka-root.log	Broker 基础日志。
	cleanup.log	Broker 卸载的清理日志。
	metadata-backup-recovery.log	Broker 备份恢复日志。
	ranger-kafka-plugin-enable.log	Broker 启动 Ranger 插件日志。
	server.out	Broker jvm 日志。
	audit.log	Ranger 鉴权插件鉴权日志。此日志统一归档在“/var/log/Bigdata/audit/kafka”目录下。

表16-14 KafkaUI 日志列表

日志类型	日志文件名	描述
运行日志	kafka-ui.log	KafkaUI 进程的运行日志。
	postinstall.log	KafkaUI 安装后的工作日志。
	cleanup.log	KafkaUI 卸载的清理日志。
	prestart.log	KafkaUI 启动前的工作日志。
	ranger-kafka-plugin-enable.log	KafkaUI 启动 Ranger 插件日志。
	start.log	KafkaUI 进程启动日志。
	stop.log	KafkaUI 进程停止日志。
	start.out	KafkaUI 进程启动信息。
审计日志	audit.log	KafkaUI 服务审计日志。
鉴权日志	kafka-authorizer.log	Kafka 开源自带鉴权插件运行日志。 此日志统一归档在“/var/log/Bigdata/audit/kafka/kafkaui”目录下。
	ranger-authorizer.log	Ranger 鉴权插件运行日志。此日志统一归档在“/var/log/Bigdata/audit/kafka/kafkaui”目录下。

表16-15 MirrorMaker 日志列表

日志类型	日志文件名	描述
运行日志	mirrormaker.out	MirrorMaker 进程启动信息。
	mirrormaker.log	MirrorMaker 进程的运行日志。
	cleanup.log	MirrorMaker 卸载的清理日志。
	prestart.log	MirrorMaker 启动前的工作日志。
	start.log	MirrorMaker 进程启动日志。

日志类型	日志文件名	描述
	postinstall.log	MirrorMaker 安装后的工作日志。
	stop.log	MirrorMaker 进程停止日志。
	mirrorMaker-omm-***-pid***-gc.log.*.current	MirrorMaker 进程 gc 日志。

日志级别

Kafka 提供了如表 16-16 所示的日志级别。

运行日志的级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表16-16 日志级别

级别	描述
ERROR	ERROR 表示系统运行的错误信息。
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

请参考 25.1 修改集群服务配置参数，进入 Kafka 的“全部配置”页面。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别。

步骤 4 保存配置，在弹出窗口中单击“确定”使配置生效。

----结束

日志格式

Kafka 的日志格式如下所示

表16-17 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log	2015-08-08 11:09:53,483	INFO	[main]	Loading

日志类型	格式	示例
	Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件调用类全名>(<日志打印文件>:<行号>)	logs. | kafka.log.LogManager (Logging.scala:68)
	<yyyy-MM-dd HH:mm:ss><HostName><组件名><logLevel><Message>	2015-08-08 11:09:51 10-165-0-83 Kafka INFO Running kafka-start.sh.

16.19 性能调优

16.19.1 Kafka 性能调优

操作场景

通过调整 Kafka 服务端参数，可以提升特定业务场景下 Kafka 的处理能力。

参数调优

修改服务配置参数，请参考 25.1 修改集群服务配置参数。调优参数请参考表 16-18。

表16-18 调优参数

配置参数	缺省值	调优场景
num.recovery.threads.per.data.dir	10	在 Kafka 启动过程中，数据量较大情况下，可调大此参数，可以提升启动速度。
background.threads	10	Broker 后台任务处理的线程数目。数据量较大的情况下，可适当调大此参数，以提升 Broker 处理能力。
num.replica.fetchers	1	副本向 Leader 请求同步数据的线程数，增大这个数值会增加副本的 I/O 并发度。
num.io.threads	8	Broker 用来处理磁盘 I/O 的线程数目，这个线程数目建议至少等于硬盘的个数。
KAFKA_HEAP_OPTS	-Xmx6G -Xms6G	Kafka JVM 堆内存设置。当 Broker 上数据量较大时，应适当调整堆内

配置参数	缺省值	调优场景
		存大小。

16.20 Kafka 特性说明

Kafka Idempotent 特性

特性说明：Kafka 从 0.11.0.0 版本引入了创建幂等性 Producer 的功能，开启此特性后，Producer 自动升级成幂等性 Producer，当 Producer 发送了相同字段值的消息后，Broker 会自动感知消息是否重复，继而避免数据重复。需要注意的是，这个特性只能保证单分区上的幂等性，即一个幂等性 Producer 能够保证某个主题的一个分区内不出现重复消息；只能实现单会话上的幂等性，这里的会话指的是 Producer 进程的一次运行，即重启 Producer 进程后，幂等性不保证。

开启方法：

1. 二次开发代码中添加 “props.put(“enable.idempotence”，true)”。
2. 客户端配置文件中添加 “enable.idempotence = true”。

Kafka Transaction 特性

特性说明：Kafka 在 0.11 版本中，引入了事务特性，Kafka 事务特性指的是一系列的生产者生产消息和消费者提交偏移量的操作在一个事务中，或者说是一个原子操作，生产消息和提交偏移量同时成功或者失败，此特性提供的是 read committed 隔离级别的事务，保证多条消息原子性的写入到目标分区，同时也能保证 Consumer 只能看到成功提交的事务消息。Kafka 中的事务特性主要用于以下两种场景：

1. 生产者发送多条数据可以封装在一个事务中，形成一个原子操作。多条消息要么都发送成功，要么都发送失败。
2. read-process-write 模式：将消息消费和生产封装在一个事务中，形成一个原子操作。在一个流式处理的应用中，常常一个服务需要从上游接收消息，然后经过处理后送达到下游，这就对应着消息的消费和生产。

二次开发代码样例如下：

```
// 初始化配置,开启事务特性
Properties props = new Properties();
props.put("enable.idempotence", true);
props.put("transactional.id", "transaction1");
...

KafkaProducer producer = new KafkaProducer<String, String>(props);

// init 事务
producer.initTransactions();
try {
    // 开启事务
    producer.beginTransaction();
```

```
    producer.send(record1);
    producer.send(record2);
    // 结束事务
    producer.commitTransaction();
} catch (KafkaException e) {
    // 事务 abort
    producer.abortTransaction();
}
```

就近消费特性

特性说明：Kafka 2.4.0 之前版本，客户端的生产、消费都是面向各个 partition 的 leader 副本，follower 副本仅用来作数据冗余，不对外提供服务，常会导致 leader 副本压力较大，且在跨机房、机架的消费场景下，常会导致大量的机房、机架间的数据传输；Kafka 2.4.0 及之后版本，Kafka 内核支持从 follower 副本消费数据，在跨机房、机架的场景中，会大大降低数据传输量，减轻网络带宽压力。社区开放了 ReplicaSelector 接口来支持此特性，MRS Kafka 中默认提供两种实现此接口的方式。

1. RackAwareReplicaSelector：优先从相同机架的副本进行消费（机架内就近消费特性）。
2. AzAwareReplicaSelector：优先从相同 AZ 内的节点上的副本进行消费（AZ 内就近消费特性）。

以 RackAwareReplicaSelector 为例，描述实现就近消费副本的选取：

```
public class RackAwareReplicaSelector implements ReplicaSelector {

   @Override
   public Optional<ReplicaView> select(TopicPartition topicPartition,
                                       ClientMetadata clientMetadata,
                                       PartitionView partitionView) {
      if (clientMetadata.rackId() != null && !clientMetadata.rackId().isEmpty()) {
         Set<ReplicaView> sameRackReplicas = partitionView.replicas().stream()
                // 过滤与客户端处于相同 Rack 的副本
                .filter(replicaInfo ->
clientMetadata.rackId().equals(replicaInfo.endpoint().rack()))
                .collect(Collectors.toSet());
         if (sameRackReplicas.isEmpty()) {
            // 如果没有副本与客户端处于相同 Rack，则返回 leader 副本
            return Optional.of(partitionView.leader());
         } else {
            // 到这里说明存在与客户端位于同一 Rack 的副本
            if (sameRackReplicas.contains(partitionView.leader())) {
               // 如果客户端和 leader 在同一个机架，则优先返回 leader 副本
               return Optional.of(partitionView.leader());
            } else {
               // 否则，返回和 leader 同步最新的副本
               return sameRackReplicas.stream().max(ReplicaView.comparator());
            }
         }
      } else {
         // 如果客户端请求中不包含机架信息，则默认返回 leader 副本
         return Optional.of(partitionView.leader());
      }
```

```
    }
}
```

开启方法：

1. 服务端：根据不同特性更新“replica.selector.class”配置项：
   - 开启“机架内就近消费特性”，配置为“org.apache.kafka.common.replica.RackAwareReplicaSelector”。
   - 开启“AZ 内就近消费特性”，配置为“org.apache.kafka.common.replica.AzAwareReplicaSelector”。
2. 客户端：在“{*客户端安装目录*}/Kafka/kafka/config”目录中的“consumer.properties”消费配置文件里添加“client.rack”配置项：
   - 若服务端开启“机架内就近消费特性”，添加客户端所处的机架信息，如client.rack = /default0/rack1。
   - 若服务端开启“AZ 内就近消费特性”，添加客户端所处的机架信息，如client.rack = /AZ1/rack1。

Ranger 统一鉴权特性

特性说明：在 Kafka 2.4.0 之前版本，Kafka 组件仅支持社区自带的 SimpleAclAuthorizer 鉴权插件，Kafka 2.4.0 及之后版本，MRS Kafka 同时支持 Ranger 鉴权插件和社区自带鉴权插件。默认使用 Ranger 鉴权，基于 Ranger 鉴权插件，可进行细粒度的 Kafka Acl 管理。

说明

服务端使用 Ranger 鉴权插件时，若“allow.everyone.if.no.acl.found”配置为“true”，使用非安全端口访问时，所有行为将直接放行。建议使用 Ranger 鉴权插件的安全集群，不要开启“allow.everyone.if.no.acl.found”。

16.21 Kafka 节点内数据迁移

操作场景

该任务指导管理员根据业务需求，通过 Kafka 客户端命令，在不停止服务的情况下，进行节点内磁盘间的分区数据迁移。

前提条件

- MRS 集群管理员已明确业务需求，并准备一个 Kafka 用户（属于 kafkaadmin 组，普通模式不需要）。
- 已安装 Kafka 客户端。
- Kafka 实例状态和磁盘状态均正常。
- 根据待迁移分区当前的磁盘空间占用情况，评估迁移后，不会导致新迁移后的磁盘空间不足。

操作步骤

以客户端安装用户，登录已安装 Kafka 客户端的节点。

步骤 1 执行以下命令，切换到 Kafka 客户端安装目录，例如“/opt/kafkaclient”。

cd /opt/kafkaclient

步骤 2 执行以下命令，配置环境变量。

source bigdata_env

步骤 3 执行以下命令，进行用户认证（普通模式跳过此步骤）。

kinit *组件业务用户*

步骤 4 执行以下命令，切换到 Kafka 客户端目录。

cd Kafka/kafka/bin

步骤 5 执行以下命令，查看待迁移的 Partition 对应的 Topic 的详细信息。

安全模式：

./kafka-topics.sh --describe --bootstrap-server *Kafka 集群 IP:21007* **--command-config ../config/client.properties --topic** *主题名称*

普通模式：

./kafka-topics.sh --describe --bootstrap-server *Kafka 集群 IP:21005* **--command-config ../config/client.properties --topic** *主题名称*

```
Topic:testws    PartitionCount:24       ReplicationFactor:2     Configs:
        Topic: testws   Partition: 0    Leader: 4       Replicas: 4,3   Isr: 4,3
        Topic: testws   Partition: 1    Leader: 5       Replicas: 5,4   Isr: 5,4
        Topic: testws   Partition: 2    Leader: 6       Replicas: 6,5   Isr: 6,5
        Topic: testws   Partition: 3    Leader: 3       Replicas: 3,6   Isr: 3,6
        Topic: testws   Partition: 4    Leader: 4       Replicas: 4,5   Isr: 4,5
        Topic: testws   Partition: 5    Leader: 5       Replicas: 5,4   Isr: 5,4
        Topic: testws   Partition: 6    Leader: 6       Replicas: 6,3   Isr: 6,3
        Topic: testws   Partition: 7    Leader: 3       Replicas: 3,4   Isr: 3,4
        Topic: testws   Partition: 8    Leader: 4       Replicas: 4,6   Isr: 4,6
        Topic: testws   Partition: 9    Leader: 5       Replicas: 5,3   Isr: 5,3
        Topic: testws   Partition: 10   Leader: 6       Replicas: 6,4   Isr: 6,4
        Topic: testws   Partition: 11   Leader: 3       Replicas: 3,5   Isr: 3,5
        Topic: testws   Partition: 12   Leader: 4       Replicas: 4,3   Isr: 4,3
        Topic: testws   Partition: 13   Leader: 5       Replicas: 5,4   Isr: 5,4
        Topic: testws   Partition: 14   Leader: 6       Replicas: 6,5   Isr: 6,5
        Topic: testws   Partition: 15   Leader: 3       Replicas: 3,6   Isr: 3,6
        Topic: testws   Partition: 16   Leader: 4       Replicas: 4,5   Isr: 4,5
        Topic: testws   Partition: 17   Leader: 5       Replicas: 5,6   Isr: 5,6
        Topic: testws   Partition: 18   Leader: 6       Replicas: 6,3   Isr: 6,3
        Topic: testws   Partition: 19   Leader: 3       Replicas: 3,4   Isr: 3,4
        Topic: testws   Partition: 20   Leader: 4       Replicas: 4,6   Isr: 4,6
        Topic: testws   Partition: 21   Leader: 5       Replicas: 5,3   Isr: 5,3
        Topic: testws   Partition: 22   Leader: 6       Replicas: 6,4   Isr: 6,4
```

步骤 6 执行以下命令，查询 Broker_ID 和 IP 对应关系。

./kafka-broker-info.sh --zookeeper *ZooKeeper 的 quorumpeer 实例业务 IP:ZooKeeper 客户端端口号***/kafka**

```
Broker_ID    IP_Address
--------------------------
4          192.168.0.100
5          192.168.0.101
6          192.168.0.102
```

说明

- ZooKeeper 的 quorumpeer 实例业务 IP：

ZooKeeper 服务所有 quorumpeer 实例业务 IP。登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper > 实例”，可查看所有 quorumpeer 实例所在主机业务 IP 地址。

- ZooKeeper 客户端端口号：

  登录 FusionInsight Manager，选择“集群 > 服务 > ZooKeeper”，在“配置”页签查看“clientPort”的值。默认为 24002。

步骤 7 从步骤 6 和步骤 7 回显中获取分区的分布信息和节点信息，在当前目录下创建执行重新分配的 json 文件。

以迁移的是 Broker_ID 为 6 的节点的分区为例，迁移到"/srv/BigData/hadoop/data1/kafka-logs”，完成迁移所需的 json 配置文件，内容如下。

```
{"partitions":[{"topic": "testws","partition": 2,"replicas": [6,5],"log_dirs":
["/srv/BigData/hadoop/data1/kafka-logs","any"]}],"version":1}
```

说明

- topic 为 Topic 名称，此处以 testws 为例，具体以实际为准。
- partition 为 Topic 分区。
- replicas 中的数字对应 Broker_ID。replicas 必须与分区的副本数相对应，不然会造成副本缺少的情况。在本案例中分区所在的 replicas 对应 6 和 5，只迁移 Broker_ID 为 6 的节点的分区中的数据时，也必须把 Broker_ID 为 5 的节点的分区带上。
- log_dirs 为需要迁移的磁盘路径。此样例迁移的是 Broker_ID 为 6 的节点，Broker_ID 为 5 的节点对应的 log_dirs 可设置为“any”，Broker_ID 为 6 的节点对应的 log_dirs 设置为“/srv/BigData/hadoop/data1/kafka-logs”。**注意路径需与节点对应**。

步骤 8 使用如下命令，执行重分配操作。

安全模式：

./kafka-reassign-partitions.sh --bootstrap-server *Broker 业务 IP*:**21007 --command-config ../config/client.properties --zookeeper** *{zk_host}:{port}*/**kafka --reassignment-json-file** *步骤 8 中编写的 json 文件路径* **--execute**

普通模式：

./kafka-reassign-partitions.sh --bootstrap-server *Broker 业务 IP*:**21005 --command-config ../config/client.properties --zookeeper** *{zk_host}:{port}*/**kafka --reassignment-json-file** *步骤 8 中编写的 json 文件路径* **--execute**

提示“Successfully started reassignment of partitions”表示执行成功。

----结束

16.22 Kafka 配置内外网访问

本章节适用于 MRS 3.2.0 及之后版本。

操作场景

外网环境 Kafka 客户端访问部署在内网的 Kafka Broker，需开启 Kafka 内外网分流访问。

前提条件

- Broker 所在节点同时具有内网 IP 和外网 IP，Broker 绑定在内网 IP 上，外网无法访问。或者 Broker 所在节点只具有内网 IP，外部服务通过网闸机映射访问内网。
- ZooKeeper 服务正常。
- Kafka 实例状态和磁盘状态均正常。

操作步骤

登录 FusionInsight Manager 界面。

步骤 1 选择“集群 > 服务 > Kafka > 实例 > Broker > 实例配置 > 全部配置”。在搜索框输入“broker.id”，查看并记录当前 Broker 实例的 Broker ID。

步骤 2 重复步骤 2，查看并记录每一个 Broker 实例的 Broker ID。

步骤 3 选择“集群 > 服务 > Kafka > 配置 > 全部配置 > Broker(角色) > 服务”。在搜索框分别输入“advertised”和 "actual"，会出现如下图所示五个配置项，可参考表 16-19 配置具体参数。

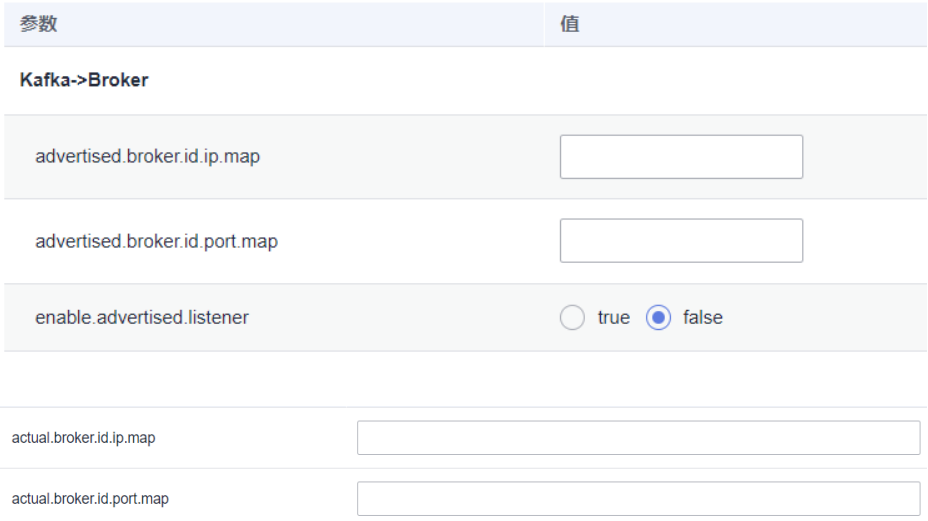

表16-19 参数配置说明

配置项	描述	取值要求
enable.advertised.listener	是否开启“advertised.listeners”配置，默认值为“false”。	配置“enable.advertised.listener”参数值为“true”。 **说明** 安装 Kafka 服务时，此参数初始化配置不能设置为“true”，设置为“true”的前提条件是 Broker 实例和 ZooKeeper 必须处于正常运行状态。
advertised.broker.id.ip.map	Kafka 对外发布的 IP 地址，默认值为空。 格式为：*Broker ID:IP*。多个	将步骤 2 中记录的每个 Broker 实例的 Broker ID 与此 Broker 将要绑定的 IP 做映射。

配置项	描述	取值要求
	Broker 可为同一 IP 地址。配置多个映射时，使用英文半角逗号分隔。	例如有三个 Broker 实例和一个 IP 地址，Broker ID 分别为 1，2，3，IP 地址为 10.*xxx.xxx.xxx*，则配置格式为 1:10.*xxx.xxx.xxx*,2:10.*xxx.xxx.xxx*,3:10.*xxx.xxx.xxx*。
advertised.broker.id.port.map	Kafka 对外发布的端口，默认值为空。 格式为：*Broker ID:Port*。“Port”为将要绑定的端口，此端口为自定义端口，配置的端口必须为可用的端口。配置多个映射时，使用英文半角逗号分隔。	将步骤 2 中记录的每个 Broker 实例的 Broker ID 与此 Broker 将要绑定的端口做映射。 例如有三个 Broker 实例和三个 Port，Broker ID 分别为 1，2，3，Port 分别为 3307，3308，3309，则配置格式为 1:3307,2:3308,3:3309。
actual.broker.id.ip.map	Kafka 实际绑定的 IP 地址，默认值为空。 格式为：*Broker ID:IP*。配置多个映射时，使用英文半角逗号分隔。	将步骤 2 中记录的每个 Broker 实例的 Broker ID 与此 Broker 将要绑定的 IP 做映射。 例如有三个 Broker 实例和一个 IP 地址，Broker ID 分别为 1，2，3，IP 地址为 10.*xxx.xxx.xxx*，则配置格式为 1:10.*xxx.xxx.xxx*,2:10.*xxx.xxx.xxx*,3:10.*xxx.xxx.xxx*。
actual.broker.id.port.map	Kafka 实际绑定的端口，默认值为空。 格式为：*Broker ID:Port*。“Port”为将要绑定的端口，此端口为自定义端口，配置的端口必须为可用的端口。配置多个映射时，使用英文半角逗号分隔。	将步骤 2 中记录的每个 Broker 实例的 Broker ID 与此 Broker 将要绑定的端口做映射。 例如有三个 Broker 实例和三个 Port，Broker ID 分别为 1，2，3，Port 分别为 3307，3308，3309，则配置格式为 1:3307,2:3308,3:3309。

步骤 4 配置完成后，左上角单击“保存”，在 Kafka“实例”界面，勾选 Broker 实例，选择“更多 > 滚动重启实例”，等待滚动重启完成生效。

步骤 5 （可选）如果需要关闭此配置，将“enable.advertised.listener”设置为“false”，单击“保存”。在 Kafka“实例”界面，勾选 Broker 实例，选择“更多 > 滚动重启实例”，等待滚动重启完成生效。

----结束

说明

- 开启 Kerberos 认证集群中，开启“enable.advertised.listener”配置后，客户端只支持使用 Kerberos 认证，不支持使用 Plain 认证。
- 参数“advertised.broker.id.port.map”与参数“actual.broker.id.port.map”中的“Port”可以配置为相同端口。

16.23 Kafka 常见问题

16.23.1 如何解决 Kafka topic 无法删除的问题

问题

删除 Kafka topic 后发现未成功删除，如何正常删除？

回答

- 可能原因一：配置项“delete.topic.enable”未配置为“true”，只有配置为“true”才能执行真正删除。
- 可能原因二：“auto.create.topics.enable”配置为“true”，其他应用程序有使用该 Topic，并且一直在后台运行。

解决方法：

- 针对原因一：配置页面上将“delete.topic.enable”设置为“true”。
- 针对原因二：先停掉后台使用该 Topic 的应用程序，或者“auto.create.topics.enable”配置为“false”（需要重启 Kafka 服务），然后再做删除操作。

17 使用 Loader

17.1 Loader 常用参数

参数入口

参数入口，请参考 25.1 修改集群服务配置参数。

参数说明

表17-1 Loader 常用参数

配置参数	说明	默认值	范围
mapreduce.client.submit.file.replication	MapReduce 任务在运行时依赖的相关 job 文件在 HDFS 上的副本数。当集群中 DataNode 个数小于该参数值时，副本数等于 DataNode 的个数。当 DataNode 个数大于或等于该参数值，副本数为该参数值。	10	3～256
loader.fault.tolerance.rate	容错率。 值大于 0 时使能容错机制。使能容错机制时建议将作业的 Map 数设置为大于等于 3，推荐在作业数据量大的场景下使用。	0	0～1.0
loader.input.field.separator	默认的输入字段分割符，需要配置输入与输出转换步骤才生效，转换步骤的内容可以为空；如果作业的转换步骤中没有配置分割符，则以此处的默认分割符为准。	,	-

配置参数	说明	默认值	范围
loader.input.line.separator	默认的输入行分割符，需要配置输入与输出转换步骤才生效，转换步骤的内容可以为空；如果作业的转换步骤中没有配置分割符，则以此处的默认分割符为准。	-	-
loader.output.field.separator	默认的输出字段分割符，需要配置输入与输出转换步骤才生效，转换步骤的内容可以为空；如果作业的转换步骤中没有配置分割符，则以此处的默认分割符为准。	,	-
loader.output.line.separator	Loader 输出数据的行分隔符。	-	-

说明

- 由于容错率的统计需要时间，为保证使用效果，建议在作业运行时间在 2 分钟以上时使用“loader.fault.tolerance.rate”参数。
- 此处参数设置的为 Loader 全局的默认分割符，如果作业的转换步骤中配置了分割符，则以转换步骤为准，转换步骤中没有配置分割符则以此处的默认分割符为准。

17.2 创建 Loader 角色

操作场景

该任务指导 MRS 集群管理员在 FusionInsight Manager 创建并设置 Loader 的角色。Loader 角色可设置 Loader 管理员权限、作业连接、作业分组以及 Loader 作业的操作和调度权限。

前提条件

- MRS 集群管理员已明确业务需求。
- 已登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。

操作步骤

选择“系统 > 权限 > 角色”。

步骤 1 单击“添加角色”，然后“角色名称”和“描述”输入角色名字与描述。

步骤 2 设置角色“权限”请参见表 17-2。

说明

设置角色的权限时，不能同时选择跨资源权限，如果需要设置多个资源的相关权限，请依次逐一设置。

Loader 权限：

- “管理员”：Loader 管理员权限。
- “作业连接器”：Loader 的连接权限。
- “作业分组”：Loader 的作业分组操作权限。用户可以在指定作业分组下设置具体作业的操作权限，包括作业的编辑“编辑”与执行“执行”权限。
- “作业调度”：Loader 的作业调度权限。

表17-2 设置 Loader 角色

任务场景	角色授权操作
设置 Loader 管理员权限	在“配置资源权限”的表格中选择“*待操作集群的名称* > Loader”，勾选“管理员”。
设置 Loader 的连接权限 （包括 Job Connection 的编辑、删除和引用权限）	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Loader > 作业连接器”。 2. 在指定作业连接的“权限”列，勾选“编辑”。
设置 Loader 作业分组的编辑权限 （包括修改作业分组的名称、删除指定分组、在指定分组下创建作业的权限、从外部将作业批量导入到指定分组的权限、将其他分组的作业迁移到指定分组的权限）	1. 在“权限”的表格中选择“ Loader > 作业分组”。 2. 在指定作业分组的“权限”列，勾选“分组编辑”。
设置 Loader 作业分组下所有作业的编辑权限 （包括对分组下现有或后续新增所有作业的编辑权限）	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Loader > 作业分组”。 2. 在指定作业分组的“权限”列，勾选“作业编辑”。
设置 Loader 作业分组下所有作业的执行权限 （包括对分组下现有或后续新增所有作业的执行权限）	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Loader > 作业分组”。 2. 在指定作业分组的“权限”列，勾选“作业执行”。
设置 Loader 作业的编辑权限 （包括作业的编辑、删除、复制和导出权限）	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Loader > 作业分组”。 2. 选择某个作业分组。 3. 在指定作业的“权限”列，勾选“编辑”。

任务场景	角色授权操作
设置 Loader 作业的执行权限 （包括作业的启动、停止和查看历史记录权限）	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Loader > 作业分组”。 2. 选择某个作业分组。 3. 在指定作业的“权限”列，勾选“执行”。
设置 Loader 作业调度的操作权限 （包括 Scheduler 的编辑、删除、是否生效权限）	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Loader > 作业调度”。 2. 在指定作业调度行的“权限”列，勾选“编辑”。

说明

1. 除了“管理员”权限，以上权限只针对存量的资源信息进行权限配置。
2. 未设置以上角色的用户也可以创建任务、分组、连接器，但是无法对存量的资源进行操作。

步骤 3 单击“确定”完成，返回“角色”。

----结束

17.3 管理 Loader 连接

操作场景

Loader 页面支持创建、查看、编辑和删除连接。

创建连接

登录服务页面：

登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），选择“集群 > 服务”。

步骤 1 选择“Loader”，在“Loader WebUI”右侧，单击链接，打开 Loader 的 WebUI。

步骤 2 在 Loader 页面，单击“新建作业”。

步骤 3 在“连接”后单击“添加”，配置连接参数。

参数介绍具体可参见 Loader 连接配置说明。

步骤 4 单击“确定”。

如果连接配置，例如 IP 地址、端口、访问用户等信息不正确，将导致验证连接失败无法保存。

说明

用户可以直接单击“测试”立即检测连接是否可用。

----结束

查看连接

在 Loader 页面，单击“新建作业”。

步骤 1 单击“连接”后的下拉列表框，可以查看已创建的连接。

----结束

编辑连接

在 Loader 页面，单击“新建作业”。

步骤 1 单击“连接”后的下拉列表框，选择待编辑的连接名称。

步骤 2 在“连接”后单击“编辑”，进入编辑页面。

步骤 3 根据业务需要，修改连接配置参数。

步骤 4 单击“测试”。

- 如果显示测试成功，则执行步骤 6。
- 如果显示测试失败，则需要重复步骤 4。

步骤 5 单击“保存”。

如果某个 Loader 作业已集成一个 Loader 连接，那么编辑连接参数后可能导致 Loader 作业运行效果也产生变化。

----结束

删除连接

在 Loader 页面，单击“新建作业”。

步骤 1 单击“连接”后的下拉列表框，选择待删除的连接名称。

步骤 2 单击“删除”。

步骤 3 在弹出的对话框窗口，单击“确定”。

如果某个 Loader 作业已集成一个 Loader 连接，那么该连接不可以被删除。

----结束

Loader 连接配置说明

Loader 支持以下多种连接：

- generic-jdbc-connector：参数配置请参见表 17-3。

- ftp-connector：参数配置请参见表 17-4。
- sftp-connector：参数配置请参见表 17-5。
- hdfs-connector：参数配置请参见表 17-6。
- oracle-connector：参数配置请参见表 17-7。
- mysql-fastpath-connector：参数配置请参见表 17-9。
- oracle-partition-connector：参数配置请参见表 17-8。

表17-3 generic-jdbc-connector 配置

参数	说明
名称	给定一个 Loader 连接的名称。
连接器	选择“generic-jdbc-connector”。
JDBC 驱动程序类	JDBC 驱动类如下: • oracle：oracle.jdbc.driver.OracleDriver • SQLServer：com.microsoft.jdbc.sqlserver.SQLServerDriver • mysql：com.mysql.jdbc.Driver • postgresql：org.postgresql.Driver
JDBC 连接字符串	表示数据库的访问地址，可以是 IP 地址或者域名。 输入数据库连接字符串（以下以 IP 为 10.10.10.10，样例数据库为“test”为例）： • oracle：jdbc:oracle:thin:@10.10.10.10:1521:orcl • SQLServer：jdbc:microsoft:sqlserver://10.10.10.10:1433;DatabaseName=test • mysql：jdbc:mysql://10.10.10.10/test?&useUnicode=true&characterEncoding=GBK • postgresql：jdbc:postgresql://10.10.10.10:5432/test
用户名	表示连接数据库使用的用户名称。
密码	表示此用户对应的密码。需要与实际密码保持一致。

表17-4 ftp-connector 配置

参数	说明
名称	指定一个 Loader 连接的名称。
连接器	选择“ftp-connector”。
FTP 模式	选择“ACTIVE”或者“PASSIVE”。
FTP 协议	选择：

参数	说明
	• FTP • SSL_EXPLICIT • SSL_IMPLICIT • TLS_EXPLICIT • TLS_IMPLICIT
文件名编码类型	文件名或者文件路径名的编码类型。

表17-5 sftp-connector 配置

参数	说明
名称	指定一个 Loader 连接的名称。
连接器	选择“sftp-connector”。

表17-6 hdfs-connector 配置

参数	说明
名称	指定一个 Loader 连接的名称。
连接器	选择“hdfs-connector”。

表17-7 oracle-connector 配置

参数	说明
名称	指定一个 Loader 连接的名称。
连接器	选择“oracle-connector”。
JDBC 连接字符串	输入用于连接数据库的连接串，例如“jdbc:oracle:thin:@*IP*:*port*:*database*”。
用户名	表示连接数据库使用的用户名称。
密码	表示此用户对应的密码。需要与实际密码保持一致。

表17-8 oracle-partition-connector 配置

参数	说明
名称	指定一个 Loader 连接的名称。

参数	说明
连接器	选择“oracle-partition-connector”。
JDBC 驱动程序类	输入“com.microsoft.jdbc.sqlserver.SQLServerDriver”。
JDBC 连接字符串	输入用于连接数据库的连接串，例如“jdbc:oracle:thin:@*IP*:*port*:*database*”。
用户名	表示连接数据库使用的用户名称。
密码	表示此用户对应的密码。需要与实际密码保持一致。

表17-9 mysql-fastpath-connector 配置

参数	说明
名称	指定一个 Loader 连接的名称。
连接器	选择“mysql-fastpath-connector”。 须知 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。 例如：在 RHEL-x86 系统上需要安装如下 RPM 包（请根据实际情况选择版本） • mysql-community-client-5.7.23-1.el7.x86_64.rpm • mysql-community-common-5.7.23-1.el7.x86_64.rpm • mysql-community-devel-5.7.23-1.el7.x86_64.rpm • mysql-community-embedded-5.7.23-1.el7.x86_64.rpm • mysql-community-libs-5.7.23-1.el7.x86_64.rpm • mysql-community-libs-compat-5.7.23-1.el7.x86_64.rpm
JDBC 连接字符串	输入用于连接数据库的连接串，例如“jdbc:mysql://*IP*/*database*?&useUnicode=true&characterEncoding=GBK”。
用户名	表示连接数据库使用的用户名称。
密码	表示此用户对应的密码。需要与实际密码保持一致。

17.4 准备 MySQL 数据库连接的驱动

操作场景

Loader 作为批量数据导出的组件，可以通过关系型数据库导入、导出数据。

前提条件

已准备业务数据。

操作步骤

修改关系型数据库对应的驱动 jar 包文件权限。

登录 Loader 服务的主备管理节点，获取关系型数据库对应的驱动 jar 包保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。

步骤 1 使用 **root** 用户在 Loader 服务主备节点分别执行以下命令修改权限：

cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

chown omm:wheel *jar 包文件名*

chmod 600 *jar 包文件名*

步骤 2 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”输入管理员密码重启 Loader 服务。

----结束

17.5 数据导入

17.5.1 概述

简介

Loader 是实现 MRS 与外部数据源如关系型数据库、SFTP 服务器、FTP 服务器之间交换数据和文件的 ETL 工具，支持将数据或文件从关系型数据库或文件系统导入到 MRS 系统中。

Loader 支持如下数据导入方式：

- 从关系型数据库导入数据到 HDFS/OBS
- 从关系型数据库导入数据到 HBase
- 从关系型数据库导入数据到 Phoenix 表
- 从关系型数据库导入数据到 Hive 表
- 从 SFTP 服务器导入数据到 HDFS/OBS

- 从 SFTP 服务器导入数据到 HBase
- 从 SFTP 服务器导入数据到 Phoenix 表
- 从 SFTP 服务器导入数据到 Hive 表
- 从 FTP 服务器导入数据到 HDFS/OBS
- 从 FTP 服务器导入数据到 HBase
- 从 FTP 服务器导入数据到 Phoenix 表
- 从 FTP 服务器导入数据到 Hive 表
- 从同一集群内 HDFS/OBS 导入数据到 HBase

MRS 与外部数据源交换数据和文件时需要连接数据源。系统提供以下连接器，用于配置不同类型数据源的连接参数：

- generic-jdbc-connector：关系型数据库连接器。
- ftp-connector：FTP 数据源连接器。
- hdfs-connector：HDFS 数据源连接器。
- oracle-connector：Oracle 数据库专用连接器，使用 row_id 作为分区列，相对 generic-jdbc-connector 来说，Map 任务分区更均匀，并且不依赖分区列是否有创建索引。
- mysql-fastpath-connector：MYSQL 数据库专用连接器，使用 MYSQL 的 mysqldump 和 mysqlimport 工具进行数据的导入导出，相对 generic-jdbc-connector 来说，导入导出速度更快。
- sftp-connector：SFTP 数据源连接器。
- oracle-partition-connector：支持 Oracle 分区特性的连接器，专门对 Oracle 分区表的导入导出进行优化。

说明

- 使用 FTP 数据源连接器时不加密数据，可能存在安全风险，建议使用 SFTP 数据源连接器。
- 建议将 SFTP 服务器、FTP 服务器和数据库服务器与 Loader 部署在独立的子网中，以保障数据安全地导入。
- 与关系数据库连接时，可以选择通用数据库连接器（generic-jdbc-connector）或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），专用数据库连接器特别针对具体数据库类型进行优化，相对通用数据库连接器来说，导出、导入速度更快。
- 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。
- 使用 oracle-connector 时，要求给连接用户赋予如下系统表或者视图的 select 权限：

  dba_tab_partitions、dba_constraints、dba_tables 、dba_segments 、v$version、dba_objects、v$instance、SYS_CONTEXT 函数、dba_extents、 dba_tab_subpartitions。
- 使用 oracle-partition-connector 时，要求给连接用户赋予如下系统表的 select 权限：dba_objects、dba_extents。

导入流程

用户通过 Loader 界面进行数据导入作业，导入流程如图 17-1 所示。

图17-1 导入流程示意

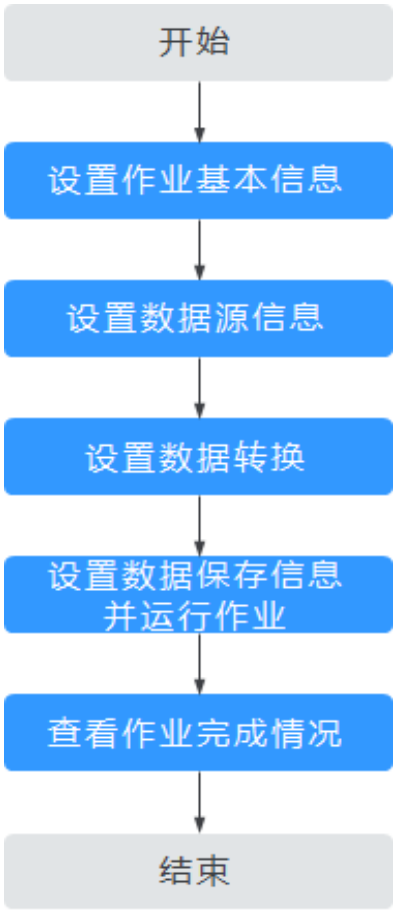

用户也可以通过 shell 脚本来更新与运行 Loader 作业，该方式需要对已安装的 Loader 客户端进行配置。

17.5.2 使用 Loader 导入数据

操作场景

该任务指导用户完成将数据从外部的数据源导入到 MRS 的工作。

一般情况下，用户可以手工在 Loader 界面管理数据导入导出作业。当用户需要通过 shell 脚本来更新与运行 Loader 作业时，必须对已安装的 Loader 客户端进行配置。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HDFS/OBS 目录、HBase 表和数据。
- 获取外部数据源（SFTP 服务器或关系型数据库）使用的用户和密码。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。

- 使用 Loader 从 SFTP、FTP 和 HDFS/OBS 导入数据时，确保外部数据源的输入路径目录名、输入路径的子目录名及子文件名不能包含特殊字符/\"':;,中的任意字符。
- 如果设置的任务需要使用指定 Yarn 队列功能，该用户需要已授权有相关 Yarn 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

是否第一次从 MRS 导入数据到关系型数据库？

- 是，执行步骤 2。
- 否，执行步骤 3。

步骤 1 修改关系型数据库对应的驱动 jar 包文件权限。

1. 登录 Loader 服务的主备管理节点，获取关系型数据库对应的驱动 jar 包保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。
2. 使用 **root** 用户在 Loader 服务主备节点分别执行以下命令修改权限：

   cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

   chown omm:wheel *jar 包文件名*

   chmod 600 *jar 包文件名*
3. 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”输入管理员密码重启 Loader 服务。

步骤 2 登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

   图17-2 Loader WebUI 界面

步骤 3 创建 Loader 数据导入作业，单击“新建作业”，在“1.基本信息”选择所需要的作业类型，然后单击“下一步”。

1. “名称”输入作业的名称，“类型”选择“导入”。

2. “连接”选择一个连接。默认没有已创建的连接，单击“添加”创建一个新的连接，完成后单击“测试”，测试是否可用，待提示成功后单击“确定”。

   MRS 与外部数据源交换数据和文件时需要连接数据源，“连接”表示连接数据源时的连接参数集合。

表17-10 连接配置参数一览表

连接器类型	参数名	说明
generic-jdbc-connector	JDBC 驱动程序类	JDBC 驱动类名。
	JDBC 连接字符串	JDBC 连接字符串。
	用户名	连接数据库使用的用户名。
	密码	连接数据库使用的密码。
	JDBC 连接属性	JDBC 连接属性，单击“添加”手动添加。 • 名称：连接属性名。 • 值：连接属性值。
ftp-connector	FTP 服务器的 IP	FTP 服务器的 IP 地址。
	FTP 服务器端口	FTP 服务器的端口号。
	FTP 用户名	访问 FTP 服务器的用户名。
	FTP 密码	访问 FTP 服务器的密码。
	FTP 模式	设置 FTP 访问模式，“ACTIVE”表示主动模式，“PASSIVE”表示被动模式。不指定参数值，默认为被动模式。
	FTP 协议	设置 FTP 传输协议： • “FTP”：FTP 协议。 • “SSL_EXPLICIT”：显式 SSL 协议。 • “SSL_IMPLICIT”：隐式 SSL 协议。 • “TLS_EXPLICIT”：显式 TLS 协议。 • “TLS_IMPLICIT”：隐式 TLS 协议。 不指定参数值，默认为 FTP 协议。
	文件名编码类型	填写 FTP 服务器支持的文件名、文件路径编码格式，不填写时使用系统默认格式“UTF-8”。
hdfs-connector	-	-
oracle-connector	JDBC 连接字符串	用户连接数据库的连接字符串。

连接器类型	参数名	说明
	用户名	连接数据库使用的用户名。
	密码	连接数据库使用的密码。
	连接属性	连接属性，单击“添加”手动添加。 • 名称：连接属性名。 • 值：连接属性值。
mysql-fastpath-connector	JDBC 连接字符串	JDBC 连接字符串。
	用户名	连接数据库使用的用户名。
	密码	连接数据库使用的密码。
	连接属性	连接属性，单击“添加”手动添加。 • 名称：连接属性名。 • 值：连接属性值。
sftp-connector	Sftp 服务器的 IP	SFTP 服务器的 IP 地址。
	Sftp 服务器端口	SFTP 服务器的端口号。
	Sftp 用户名	访问 SFTP 服务器的用户名。
	Sftp 密码	访问 SFTP 服务器的密码。
	Sftp 公钥	Sftp 服务器公钥。
oracle-partition-connector	JDBC 驱动程序类	JDBC 驱动类名。
	JDBC 连接字符串	JDBC 连接字符串。
	用户名	连接数据库使用的用户名。
	密码	连接数据库使用的密码。
	连接属性	连接属性，单击“添加”手动添加。 • 名称：连接属性名。 • 值：连接属性值。

3. “组”设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，单击“确定”保存。
4. “队列”设置 Loader 的任务在指定的 Yarn 队列中执行。默认值“root.default”表示任务在“default”队列中执行。

5. “优先级”设置 Loader 的任务在指定的 Yarn 队列中的优先级。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。默认值为“NORMAL”。

步骤 4 在“2.输入设置”，设置数据来源，然后单击“下一步”。

说明

- 创建或者编辑 Loader 作业时，在配置 SFTP 路径、HDFS/OBS 路径、SQL 的 Where 条件等参数时，可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义章节。
- Loader 支持常见的字段数据类型，如 Char、VarChar、Boolean、Binary、SmallInt、Int、BigInt、Decimal、Float、Double、Date、Time、TimeStamp、String 等，具体支持类型根据数据来源的不同可能会有所变化，具体支持的类型可以参考 Loader 界面中相应输入算子（如表输入等）的字段数据类型下拉框中的内容。一些数据库的特有字段可能不被支持，例如 Loader 不支持 oracle 中的 CLOB 和 XMLType、BLOB 字段。

表17-11 输入配置参数一览表

源文件类型	参数名	解释说明
sftp-connector 或 ftp-connector	输入路径	SFTP 服务器中源文件的输入路径，如果连接器配置多个地址此处可对应使用分号分隔多个输入路径，数量需要与连接器中服务器的数量一致。
	文件分割方式	选择按文件或大小分割源文件，作为数据导入的 MapReduce 任务中各个 map 的输入文件。选择“FILE”表示每个 map 处理 1 个或多个完整的源文件，同一个源文件不可分配至不同 map，数据保存至输出目录时将保留输入路径的目录结构；选择“SIZE”表示每个 map 处理一定大小的输入文件，同一个源文件可分割至多个 map，数据保存至输出目录时保存的文件数与 map 数量相同，文件名格式为“import_part_xxxx”，“xxxx”为系统生成的随机数，具有唯一性。
	过滤器类型	选择文件过滤的条件。“WILCARD”表示使用通配符过滤，“REGEX”表示使用正则表达式匹配。与“路径过滤器”和“文件过滤器”配合使用。不选择值时默认为通配符过滤。
	路径过滤器	与“过滤器类型”配合使用，配置通配符或正则表达式对源文件的输入路径包含的目录进行过滤。输入路径“输入路径”不参与过滤。配置多个过滤条件时使用逗号隔开，配置为空时表示不过滤目录。
	文件过滤器	与“过滤器类型”配合使用，配置通配符或正则表达式对源文件的输入文件名进行过滤。配置多个过滤条件时使用逗号隔开。不能配置为空。
	编码类型	源文件的编码格式，如 UTF-8。导入文本文件时才能配置。

源文件类型	参数名	解释说明
	后缀名	源文件导入成功后对输入文件增加的后缀值。该值为空，表示不加后缀。
	压缩	使用 SFTP 协议导数据时，是否开启压缩传输功能以减小带宽使用。“true”为开启压缩，“false”为关闭压缩。
hdfs-connector	输入路径	HDFS 中源文件的输入路径。
	路径过滤器	配置通配符对源文件的输入路径包含的目录进行过滤。输入路径“输入路径”不参与过滤。配置多个过滤条件时使用逗号隔开，配置为空时表示不过滤目录。不支持正则表达式过滤。
	文件过滤器	配置通配符对源文件的输入文件名进行过滤。配置多个过滤条件时使用逗号隔开。不能配置为空。不支持正则表达式过滤。
	编码类型	源文件的编码格式，如 UTF-8。导入文本文件时才能配置。
	后缀名	源文件导入成功后对输入文件增加的后缀值。该值为空，表示不加后缀。
generic-jdbc-connector	架构名称	“表方式”模式下存在，数据库模式名。
	表名	“表方式”模式下存在，数据库表名。
	SQL 语句	“SQL 方式”模式下存在，配置要查询的 SQL 语句，使 Loader 可通过 SQL 语句查询结果并作为导入的数据。SQL 语句需要有查询条件“WHERE ${CONDITIONS}”，否则无法正常工作。例如，“select * from TABLE WHERE A>B and ${CONDITIONS}”。如果同时配置“表列名”，SQL 语句中查询的列将被“表列名”配置的列代替。不能和“架构名称”、“表名”同时配置。
	表列名	配置要导入的列，使 Loader 将列的内容全部导入。配置多个字段时使用逗号分隔。
	分区列名	指定数据库表的一列，根据该列来划分要导入的数据，在 map 任务中用于分区。建议配置主键字段。 说明 • 分区列必选有索引，如果没有索引，请不要指定分区列，指定没有索引的分区列会导致数据库服务器磁盘 I/O 繁忙，影响其他业务访问数据库，并且导入时间长。 • 在有索引的多个字段中，选择字段值最离散的字段作为分区列，不离散的分区列会导致多个导入 MR

源文件类型	参数名	解释说明
		任务负载不均衡。 • 分区列的排序规则必须支持大小写敏感，否则在数据导入过程中，可能会出现数据丢失。 • 不建议分区列选择类型为 float 或 double 的字段，因为精度问题，可能导致分区列字段的最小值、最大值所在记录无法导入。
	分区列空值	配置对数据库列中为 null 值记录的处理方式。值为“true”时，分区列的值为 null 的数据会被处理；值为“false”时，分区列的值为 null 的数据不会被处理。
	是否指定分区列	是否指定分区列。
oracle-connector	表名	表名。
	列名	列名。
	查询条件	SQL 语句中的查询条件。
	切分方式	指定数据的切分方式，有“ROWID”和“PARTITION”两种。
	表分区名	表分区名，使用逗号分隔不同的分区。
	数据块分配方式	指定数据切分后，如何分配。
	读取大小	指定每次读取多大的数据量。
mysql-fastpath-connector	架构名称	数据库模式名。
	表名	数据库表名。
	查询条件	指定表的查询条件。
	分区列名	指定数据库表的一列，根据该列来划分要导入的数据，在 map 任务中用于分区。建议配置主键字段。 说明 • 分区列必选有索引，如果没有索引，请不要指定分区列，指定没有索引的分区列会导致数据库服务器磁盘 I/O 繁忙，影响其他业务访问数据库，并且导入时间长。 • 在有索引的多个字段中，选择字段值最离散的字段作为分区列，不离散的分区列会导致多个导入 MR 任务负载不均衡。 • 不建议分区列选择类型为 float 或 double 的字段，因为精度问题，可能导致分区列字段的最小值、最大值所在记录无法导入。
	分区列空值	配置对数据库列中为 null 值记录的处理方式。值为“true”时，分区列的值为 null 的数据会被处理；值为“false”时，分区列的值为 null 的数据

源文件类型	参数名	解释说明
		不会被处理。
	是否指定分区列	是否指定分区列。
oracle-partition-connector	架构名称	数据库模式名。
	表名	分区表名。
	查询条件	SQL 语句中的查询条件。
	表列名	配置要导入的列，使 Loader 将列的内容全部导入。配置多个字段时使用逗号分隔。

步骤 5 在“3.转换”设置数据传输过程中的转换操作。

确认 Loader 创建的数据操作作业中，源数据的值是否满足直接使用需求而不进行转换，例如大小写转换、截取、拼接和分隔。

- 满足需求，请单击“下一步”。
- 不满足需求，请执行步骤 6.1～步骤 6.4。

1. 默认没有已创建的转换步骤，可拖动左侧样例到编辑框，添加一个新的转换步骤。
2. 完整的转换流程包含以下类型，每个类型请根据业务需要进行选择。
   a. 输入类型，第一个转换步骤，仅添加一种，任务涉及 HBase 或关系型数据库必须添加。
   b. 转换类型，中间转换步骤，可添加一种以上或不添加。
   c. 输出类型，最后一个转换步骤，仅添加一种，任务涉及 HBase 或关系型数据库必须添加。

表17-12 样例一览表

类型	描述
输入类型	• CSV 文件输入：CSV 文件输入步骤，配置分隔符以转换生成多个字段。 • 固定宽度文件输入：文本文件输入步骤，配置截取字符或字节的长度以转换生成多个字段。 • 表输入：关系型数据输入步骤，配置数据库的指定列为输入的字段。 • HBase 输入：HBase 表输入步骤，配置 HBase 表的列定义到指定字段。 • HTML 输入：HTML 网页数据输入步骤，配置获取 HTML 网页文件目标数据到指定字段。 • Hive 输入：Hive 表输入步骤，配置 Hive 表的列定义到指定字段。

类型	描述
	• Spark 输入：SparkSQL 表输入步骤，配置 SparkSQL 表的列定义到指定字段。仅支持 SparkSQL 存取 Hive 数据。
转换类型	• 长整型时间转换：长整型日期转换步骤，配置长整型数值与日期的转换。 • 空值转换：空值转换步骤，配置指定值替换空值。 • 随机值转换：随机数据生成步骤，配置新增值为随机数据的字段。 • 增加常量字段：增加常量步骤，配置直接生成常量字段。 • 拼接转换：拼接字段步骤，配置已生成的字段通过连接符连接，转换出新的字段。 • 分隔转换：分隔字段步骤，配置已生成的字段通过分隔符分隔，转换出新的字段。 • 取模转换：取模运算步骤，配置已生成的字段通过取模，转换出新的字段。 • 剪切字符串：字符串截取步骤，配置已生成的字段通过指定位置截取，转换出新的字段。 • EL 操作转换：计算器，可以对字段值进行运算，目前支持的算子有：md5sum、sha1sum、sha256sum 和 sha512sum 等。 • 字符串大小写转换：字符串转换步骤，配置已生成的字段通过大小写变换，转换出新的字段。 • 字符串逆序转换：字符串逆序步骤，配置已生成的字段通过逆序，转换出新的字段。 • 字符串空格清除转换：字符串空格清除步骤，配置已生成的字段通过清除空格，转换出新的字段。 • 过滤行转换：过滤行步骤，配置逻辑条件过滤掉含触发条件的行。 • 更新域：更新域步骤，配置当满足某些条件时，更新指定字段的值。
输出类型	• 文件输出：文本文件输出步骤，配置已生成的字段通过分隔符连接并输出到文件。 • 表输出：关系型数据库输出步骤，配置输出的字段对应到数据库的指定列。 • HBase 输出：HBase 表输出步骤，配置已生成的字段输出到 HBase 表的列。 • Hive 输出：Hive 表输出步骤，配置已生成的字段输出到 Hive 表的列。 • Spark 输出：SparkSQL 表输出步骤，配置已生成的字段输出到 SparkSQL 表的列。仅支持 SparkSQL 存取 HIve 数据。

编辑栏包括以下几种任务：

- 重命名：重命名样例。
- 编辑：编辑步骤转换，参考步骤 6.3。
- 删除：删除样例。

说明

也可使用快捷键“Del”删除。

3. 单击“编辑”，编辑步骤转换信息，配置字段与数据。

   步骤转换信息中的具体参数设置请参考 17.8 算子帮助。

说明

- 使用 sftp-connector 或 ftp-connector 导入数据时，在数据转换步骤中，需要将原数据中时间类型数值对应的字段，设置为字符串类型，才能精确到毫秒并完成导入。数据中包含比毫秒更精确的部分不会被导入。
- 使用 generic-jdbc-connector 导入数据时，在数据转换步骤中，建议“CHAR”或“VARCHAR”类型字段设置数据长度为“-1”，使全部数据正常导入，避免实际数据字符太长时被部分截取，出现缺失。
- 使用 generic-jdbc-connector 导入数据时，在数据转换步骤中，需要将原数据中时间类型数值对应的字段，设置为时间类型，才能精确到秒并完成导入。数据中包含比秒更精确的部分不会被导入。
- 导入到 Hive 分区表内表时，Hive 默认不会扫描新导入的数据，需要执行如下 HQL 修复表才可以查询到新导入数据：

  MSCK REPAIR TABLE *table_name*;

  转换步骤配置不正确时，传输的数据将无法转换并成为脏数据，脏数据标记规则如下：

  - 任意输入类型步骤中，原数据包含字段的个数小于配置字段的个数，或者原数据字段值与配置字段的类型不匹配时，全部数据成为脏数据。
  - “CSV 文件输入”步骤中，“验证输入字段”检验输入字段与值的类型匹配情况，检查不匹配时跳过该行，当前行成为脏数据。
  - “固定宽度文件输入”步骤中，“固定长度”指定字段分割长度，长度大于原字段值的长度则数据分割失败，当前行成为脏数据。
  - “HBase 输入”步骤中，“HBase 表名”指定 HBase 表名不正确，或者“主键”没有配置主键列，全部数据成为脏数据。
  - 任意转换类型步骤中，转换失败的行成为脏数据。例如“分隔转换”步骤中，生成的字段个数小于配置字段的个数，或者原数据不能转换为 String 类型，当前行成为脏数据。
  - “过滤行转换”步骤中，被筛选条件过滤的行成为脏数据。
  - “取模转换”步骤中，原字段值为“NULL”，当前行成为脏数据。
  - 对于导入数据到 Hive/SparkSQL 表的作业，必须配置 Hive 的转换步骤。

4. 单击“下一步”。

步骤 6 在“4.输出设置”，设置数据保存目标位置，然后单击“保存”保存作业或“保存并运行”，保存作业并运行作业。

表17-13 输出配置参数一览表

存储类型	参数名	解释说明
HDFS	文件类型	在下拉菜单中选择数据导入 HDFS 后保存文件的文件类型。 • “TEXT_FILE”：导入文本文件并保存为文本文件。 • “SEQUENCE_FILE”：导入文本文件并保存为 sequence file 文件格式。 • “BINARY_FILE”：以二进制流的方式导入文件，可以导入任何格式的文件，不对文件做任何处理。 说明 文件类型选择“TEXT_FILE”或“SEQUENCE_FILE”导入时，Loader 会自动根据文件的后缀选择对应的解压方法，对文件进行解压。
	压缩格式	在下拉菜单中选择数据导入 HDFS 后保存文件的压缩格式，未配置或选择 NONE 表示不压缩数据。
	输出目录	数据导入到 HDFS 里存储的保存目录。
	文件操作方式	数据导入时的操作行为。全部数据从输入路径导入到目标路径时，先保存在临时目录，然后再从临时目录复制转移至目标路径，任务完成时删除临时路径的文件。转移临时文件存在同名文件时有以下行为： • “OVERRIDE”：直接覆盖旧文件。 • “RENAME”：重命名新文件。无扩展名的文件直接增加字符串后缀，有扩展名的文件在文件名增加字符串后缀。字符串具有唯一性。 • “APPEND”：在旧文件尾部合并新文件内容。合并操作只是简单的追加，不保证追加文件是否可以使用。例如文本文件可合并，压缩文件合并后可能无法使用。 • “IGNORE”：保留旧文件，不复制新文件。 • “ERROR”：转移过程中出现同名文件时任务将停止执行并报错，已转移的文件导入成功，同名的文件及未转移的文档导入失败。
	Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于“3000”。

存储类型	参数名	解释说明
	Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于“100”，建议配置值为“1000”。不可与“Map 数”同时配置。当使用关系型数据库连接器时，不支持“Map 数据块大小”，请配置“Map 数”。
HBASE_BULKLOAD	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。
	导入前清理数据	导入前清空原表的数据。“true”为执行清空，“false”为不执行。不配置此参数则默认不执行清空。
	Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于“3000”。
	Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。
HBASE_PUTLIST	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。
	Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于“3000”。
	Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。
HIVE	输出目录	数据导入到 Hive 里存储的保存目录。
	Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于“3000”。
	Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于“100”，建议配置值为“1000”。不可与“Map 数”同时配置。当使用关系型数据库连接器时，不支持“Map 数据块大小”，请配置“Map 数”。
SPARK	输出目录	仅支持 SparkSQL 存取 Hive 数据，制定数据导入到 Hive 里存储的保存目录。

存储类型	参数名	解释说明
	Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于“3000”。
	Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于“100”，建议配置值为“1000”。不可与“Map 数”同时配置。当使用关系型数据库连接器时，不支持“Map 数据块大小”，请配置“Map 数”。

步骤 7 已创建的作业可以在“Loader WebUI”界面上进行浏览，可进行启动、停止、复制、删除、编辑和查看历史信息操作。

图17-3 查看 Loader 作业

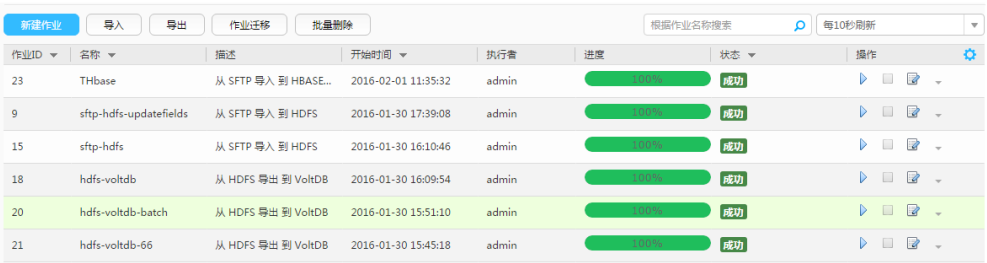

----结束

17.5.3 典型场景：从 SFTP 服务器导入数据到 HDFS/OBS

操作场景

该任务指导用户使用 Loader 将数据从 SFTP 服务器导入到 HDFS/OBS。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HDFS/OBS 目录和数据。
- 获取 SFTP 服务器使用的用户和密码，且该用户具备 SFTP 服务器上源文件的读取权限。若源文件在导入后文件名要增加后缀，则该用户还需具备源文件的写入权限。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 使用 Loader 从 SFTP 服务器导入数据时，确保 SFTP 服务器输入路径目录名、输入路径的子目录名及子文件名不能包含特殊字符/\'":;,中的任意字符。

- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-4 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-5 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“sftp-connector”，单击“添加”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。Loader 支持配置多个 SFTP 服务器操作数据，单击“添加”可增加多行 SFTP 服务器的配置信息。

表17-14 连接参数

参数名	说明	示例
名称	SFTP 服务器连接的名称。	sftpName
Sftp 服务器的 IP	SFTP 服务器的 IP 地址。	10.16.0.1
Sftp 服务器端口	SFTP 服务器的端口号。	22
Sftp 用户名	访问 SFTP 服务器的用户名。	root
Sftp 密码	访问 SFTP 服务器的密码。	xxxx
Sftp 公钥	Sftp 服务器公钥。	OdDt/yn...etM

说明

配置多个 SFTP 服务器时，多个 SFTP 服务器指定目录的数据导入到 HDFS/OBS 的同一个目录下。

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，设置数据源信息。

表17-15 输入设置参数

参数名	说明	示例
输入路径	SFTP 服务器中源文件的输入路径，如果连接器配置多个地址此处可对应使用“;”分隔多个输入路径，数量需要与连接器中服务器的数量一致。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/opt/tempfile;/opt
文件分割方式	选择按文件或大小分割源文件，作为数据导入的 MapReduce 任务中各个 map 的输入文件。 • 选择“FILE”，表示按文件分割源文件，即每个 map 处理一个或多个完整的源文件，同一个源文件不可分配至不同 map，完成数据导入后保持源文件的目录结构。 • 选择“SIZE”，表示按大小分割源文件，即每个 map 处理一定大小的输入文件，同一个源文件可分割至多个 map，数据保存至输出目录时保存的文件数与 map 数量相同，文件名格式为“import_part_xxxx”，“xxxx”为系统生成的随机数，具有唯一性。	FILE

参数名	说明	示例
过滤类型	选择文件过滤的条件，与“路径过滤器”、“文件过滤器”配合使用。 • 选择“WILDCARD”，表示使用通配符过滤。 • 选择“REGEX”，表示使用正则表达式匹配。 • 不选择，则默认为通配符过滤。	WILDCARD
路径过滤器	与“过滤类型”配合使用，配置通配符或正则表达式对源文件的输入路径包含的目录进行过滤。“输入路径”不参与过滤。使用分号“;”分隔多个服务器上的路径过滤器，每个服务器的多个过滤条件使用逗号“,”隔开。配置为空时表示不过滤目录。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。 例如，当“过滤类型”选择“WILDCARD”时，将该参数设置为“*”；当“过滤类型”选择“REGEX”时，将该参数设置为“\\.*”。	1*,2*;1*
文件过滤器	与“过滤类型”配合使用，配置通配符或正则表达式对源文件的输入文件名进行过滤。使用分号“;”分隔多个服务器上的文件过滤器，每个服务器的多个过滤条件使用逗号“,”隔开。该参数不能配置为空。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。 例如，当“过滤类型”选择“WILDCARD”时，将该参数设置为“*”；当“过滤类型”选择“REGEX”时，将该参数设置为“\\.*”。	*.txt,*.csv;*.txt
编码类型	源文件的编码格式，如 UTF-8、GBK。导入文本文件时才能配置。	UTF-8
后缀名	源文件导入成功后对输入文件增加的后缀值。该值为空，则表示不加后缀。数据源为文件系统，该参数才有效。用户若需增量导入数据建议设置该参数。 例如设置为“.txt”，源文件为“test-loader.csv”，则导出后源文件名为“test-loader.csv.txt”。	.log
压缩	使用 SFTP 协议导入数据时，是否开启压缩传输功能以减小带宽使用。 • 选择“true”，表示开启压缩。 • 选择“false”，表示关闭压缩。	true

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-16。

表17-16 算子输入、输出参数设置

输入类型	输出类型
CSV 文件输入	文件输出
HTML 输入	文件输出
固定宽度文件输入	文件输出

图17-6 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，在“存储类型”中选择“HDFS”，设置数据保存方式。

表17-17 输出设置参数

参数名	说明	示例
文件类型	文件导入后保存的类型： • “TEXT_FILE”：导入文本文件并保存为文本文件 • “SEQUENCE_FILE”：导入文本文件并保存在“sequence file”文件格式 • “BINARY_FILE”：以二进制流的方式导入文	TEXT_FILE

参数名	说明	示例
	件，可以导入任何格式的文件	
压缩格式	在下拉菜单中选择数据导入 HDFS/OBS 后保存文件的压缩格式，未配置或选择 NONE 表示不压缩数据。	NONE
输出目录	数据导入到 HDFS/OBS 里存储的保存目录。 **说明** 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/user/test
文件操作方式	数据导入时的操作行为。全部数据从输入路径导入到目标路径时，先保存在临时目录，然后再从临时目录复制转移至目标路径，任务完成时删除临时路径的文件。转移临时文件存在同名文件时有以下行为： • “OVERRIDE”：直接覆盖旧文件。 • “RENAME”：重命名新文件。无扩展名的文件直接增加字符串后缀，有扩展名的文件在文件名增加字符串后缀。字符串具有唯一性。 • “APPEND”：在旧文件尾部合并新文件内容。合并操作只是简单的追加，不保证追加文件是否可以使用。例如文本文件可合并，压缩文件合并后可能无法使用。 • “IGNORE”：保留旧文件，不复制新文件。 • “ERROR”：转移过程中出现同名文件时任务将停止执行并报错，已转移的文件导入成功，同名的文件及未转移的文档导入失败。	OVERRIDE
Map 数	配置数据操作的 MapReduce 任务中同时启动的 Map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于 3000，建议以 SFTP 服务器的 CPU 的核数作为其取值。 **说明** 为了提高导入数据速度，需要确保以下条件： • 每个 Map 连接时，相当于一个客户端连接，因此需要确保 SFTP 服务器最大连接数大于 Map 数量。 • 确保 SFTP 服务器上的磁盘 IO 或是网络带宽都未达到上限。	20
Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于 100，建议配置值为 1000。不可与“Map 数”同时配置。	1000

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-7 查看作业

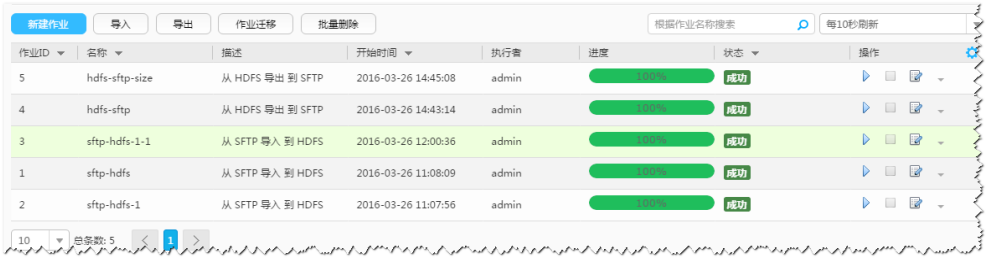

----结束

17.5.4 典型场景：从 SFTP 服务器导入数据到 HBase

操作场景

该任务指导用户使用 Loader 将数据从 SFTP 服务器导入到 HBase。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HBase 表或 phoenix 表。
- 获取 SFTP 服务器使用的用户和密码，且该用户具备 SFTP 服务器上源文件的读取权限。若源文件在导入后文件名要增加后缀，则该用户还需具备源文件的写入权限。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 使用 Loader 从 SFTP 服务器导入数据时，确保 SFTP 服务器输入路径目录名、输入路径的子目录名及子文件名不能包含特殊字符/\'":;,中的任意字符。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。

3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-8 Loader WebUI 界面

单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-9 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 2 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“sftp-connector”，单击“添加”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。Loader 支持配置多个 SFTP 服务器操作数据，单击“添加”可增加多行 SFTP 服务器的配置信息。

表17-18 连接参数

参数名	说明	示例
名称	SFTP 服务器连接的名称。	sftpName
Sftp 服务器的 IP	SFTP 服务器的 IP 地址。	10.16.0.1
Sftp 服务器端口	SFTP 服务器的端口号。	22
Sftp 用户名	访问 SFTP 服务器的用户名。	root

参数名	说明	示例
Sftp 密码	访问 SFTP 服务器的密码。	xxxx
Sftp 公钥	Sftp 服务器公钥。	OdDt/yn...etM

说明

配置多个 SFTP 服务器，多个服务器指定目录的数据将导入到 HBase。

设置数据源信息

步骤 3 单击“下一步”，进入“输入设置”界面，设置数据源信息。

表17-19 输入设置参数

参数名	说明	示例
输入路径	SFTP 服务器中源文件的输入路径，如果连接器配置多个地址此处可对应使用“;”分隔多个输入路径，数量需要与连接器中服务器的数量一致。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/opt/tempfile;/opt
文件分割方式	选择按文件或大小分割源文件，作为数据导入的 MapReduce 任务中各个 map 的输入文件。 • 选择“FILE”，表示按文件分割源文件，即每个 map 处理一个或多个完整的源文件，同一个源文件不可分配至不同 map，完成数据导入后保持源文件的目录结构。 • 选择“SIZE”，表示按大小分割源文件，即每个 map 处理一定大小的输入文件，同一个源文件可分割至多个 map，数据保存至输出目录时保存的文件数与 map 数量相同，文件名格式为“import_part_xxxx”，“xxxx”为系统生成的随机数，具有唯一性。	FILE
过滤类型	选择文件过滤的条件，与“路径过滤器”、“文件过滤器”配合使用。 • 选择“WILDCARD”，表示使用通配符过滤。 • 选择“REGEX”，表示使用正则表达式匹配。 • 不选择，则默认为通配符过滤。	WILDCARD
路径过滤器	与“过滤类型”配合使用，配置通配符或正则表达式对源文件的输入路径包含的目录进行过	1*,2*;1*

参数名	说明	示例
	滤。“输入路径”不参与过滤。使用分号“;”分隔多个服务器上的路径过滤器，每个服务器的多个过滤条件使用逗号“,”隔开。配置为空时表示不过滤目录。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。 例如，当“过滤类型”选择“WILDCARD”时，将该参数设置为“*”；当“过滤类型”选择“REGEX”时，将该参数设置为“\\.*”。	
文件过滤器	与“过滤类型”配合使用，配置通配符或正则表达式对源文件的输入文件名进行过滤。使用分号“;”分隔多个服务器上的文件过滤器，每个服务器的多个过滤条件使用逗号“,”隔开。该参数不能配置为空。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。 例如，当“过滤类型”选择“WILDCARD”时，将该参数设置为“*”；当“过滤类型”选择“REGEX”时，将该参数设置为“\\.*”。	*.txt,*.csv;*.txt
编码类型	源文件的编码格式，如 UTF-8、GBK。导入文本文件时才能配置。	UTF-8
后缀名	源文件导入成功后对输入文件增加的后缀值。该值为空，则表示不加后缀。数据源为文件系统，该参数才有效。用户若需增量导入数据建议设置该参数。 例如设置为“.txt”，源文件为“test-loader.csv”，则导出后源文件名为“test-loader.csv.txt”。	.log
压缩	使用 SFTP 协议导入数据时，是否开启压缩传输功能以减小带宽使用。 • 选择“true”，表示开启压缩。 • 选择“false”，表示关闭压缩。	true

设置数据转换

步骤 4 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-20。

表17-20 算子输入、输出参数设置

输入类型	输出类型
CSV 文件输入	HBase 输出
HTML 输入	HBase 输出
固定宽度文件输入	HBase 输出

图17-10 算子操作方法示意

设置数据保存信息并运行作业

步骤 5 单击“下一步”，进入“输出设置”界面，根据实际场景在“存储类型”选择“HBASE_BULKLOAD”或“HBASE_PUTLIST”，设置数据保存方式。

表17-21 输出设置参数

存储类型	适用场景	参数名	说明	示例
HBASE_BULKLOAD	数据量大	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实	HBase

存储类型	适用场景	参数名	说明	示例
			例在集群中未添加，则此作业无法正常运行。	
		导入前清理数据	导入前清空原表的数据。“true”为执行清空，“false”为不执行。不配置此参数则默认不执行清空。	true
		Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000，建议以 SFTP 服务器当前最大连接数作为其取值。	20
		Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。	-
HBASE_PUTLIST	数据量小	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。	HBase
		Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000。	20
		Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。	-

步骤 6 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 7 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-11 查看作业

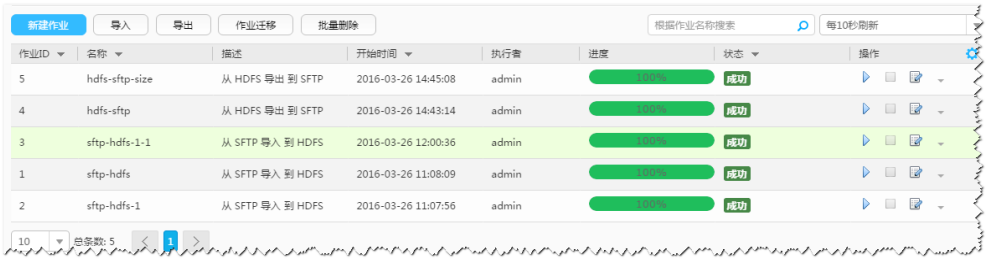

----结束

17.5.5 典型场景：从 SFTP 服务器导入数据到 Hive

操作场景

该任务指导用户使用 Loader 将数据从 SFTP 服务器导入到 Hive。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业中指定的 Hive 表的权限。
- 获取 SFTP 服务器使用的用户和密码，且该用户具备 SFTP 服务器上源文件的读取权限。若源文件在导入后文件名要增加后缀，则该用户还需具备源文件的写入权限。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 使用 Loader 从 SFTP 服务器导入数据时，确保 SFTP 服务器输入路径目录名、输入路径的子目录名及子文件名不能包含特殊字符/\'":;,中的任意字符。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-12 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-13 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“sftp-connector”，单击“添加”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。Loader 支持配置多个 SFTP 服务器操作数据，单击“添加”可增加多行 SFTP 服务器的配置信息。

表17-22 连接参数

参数名	说明	示例
名称	SFTP 服务器连接的名称。	sftpName
Sftp 服务器的 IP	SFTP 服务器的 IP 地址。	10.16.0.1

参数名	说明	示例
Sftp 服务器端口	SFTP 服务器的端口号。	22
Sftp 用户名	访问 SFTP 服务器的用户名。	root
Sftp 密码	访问 SFTP 服务器的密码。	xxxx
Sftp 公钥	Sftp 服务器公钥。	OdDt/yn...etM

说明

配置多个 SFTP 服务器，多个服务器指定目录的数据将导入到 Hive。

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，设置数据源信息。

表17-23 输入设置参数

参数名	说明	示例
输入路径	SFTP 服务器中源文件的输入路径，如果连接器配置多个地址此处可对应使用“;”分隔多个输入路径，数量需要与连接器中服务器的数量一致。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/opt/tempfile;/opt
文件分割方式	选择按文件或大小分割源文件，作为数据导入的 MapReduce 任务中各个 map 的输入文件。 • 选择“FILE”，表示按文件分割源文件，即每个 map 处理一个或多个完整的源文件，同一个源文件不可分配至不同 map，完成数据导入后保持源文件的目录结构。 • 选择“SIZE”，表示按大小分割源文件，即每个 map 处理一定大小的输入文件，同一个源文件可分割至多个 map，数据保存至输出目录时保存的文件数与 map 数量相同，文件名格式为“import_part_xxxx”，“xxxx”为系统生成的随机数，具有唯一性。	FILE
过滤器类型	选择文件过滤的条件，与“路径过滤器”、“文件过滤器”配合使用。 • 选择“WILDCARD”，表示使用通配符过滤。 • 选择“REGEX”，表示使用正则表达式匹配。 • 不选择，则默认为通配符过滤。	WILDCARD
路径过滤器	与“过滤类型”配合使用，配置通配符或正则表达式对	1*,2

参数名	说明	示例
	源文件的输入路径包含的目录进行过滤。“输入路径”不参与过滤。使用分号“;”分隔多个服务器上的路径过滤器，每个服务器的多个过滤条件使用逗号“,”隔开。配置为空时表示不过滤目录。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。 例如，当“过滤类型”选择“WILDCARD”时，将该参数设置为“*”；当“过滤类型”选择“REGEX”时，将该参数设置为“\\.*”。	*;1*
文件过滤器	与“过滤类型”配合使用，配置通配符或正则表达式对源文件的输入文件名进行过滤。使用分号“;”分隔多个服务器上的文件过滤器，每个服务器的多个过滤条件使用逗号“,”隔开。该参数不能配置为空。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。 例如，当“过滤类型”选择“WILDCARD”时，将该参数设置为“*”；当“过滤类型”选择“REGEX”时，将该参数设置为“\\.*”。	*.txt,*.csv;*.txt
编码类型	源文件的编码格式，如 UTF-8、GBK。导入文本文件时才能配置。	UTF-8
后缀名	源文件导入成功后对输入文件增加的后缀值。该值为空，则表示不加后缀。数据源为文件系统，该参数才有效。用户若需增量导入数据建议设置该参数。 例如设置为“.txt”，源文件为“test-loader.csv”，则导出后源文件名为“test-loader.csv.txt”。	.log
压缩	使用 SFTP 协议导入数据时，是否开启压缩传输功能以减小带宽使用。 • 选择“true”，表示开启压缩。 • 选择“false”，表示关闭压缩。	true

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-24。

表17-24 算子输入、输出参数设置

输入类型	输出类型
CSV 文件输入	Hive 输出
HTML 输入	Hive 输出
固定宽度文件输入	Hive 输出

图17-14 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，在“存储类型”选择“HIVE”，设置数据保存方式。

表17-25 输出设置参数

参数名	说明	示例
输出目录	数据导入到 Hive 里存储的保存目录。 **说明** 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/opt/tempfile
Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000，建议以 SFTP 服务器当前最大连接数作为其取	20

参数名	说明	示例
	值。	
Map 数据块大小	Hive 不支持此参数，请配置“Map 数”。	-

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-15 查看作业

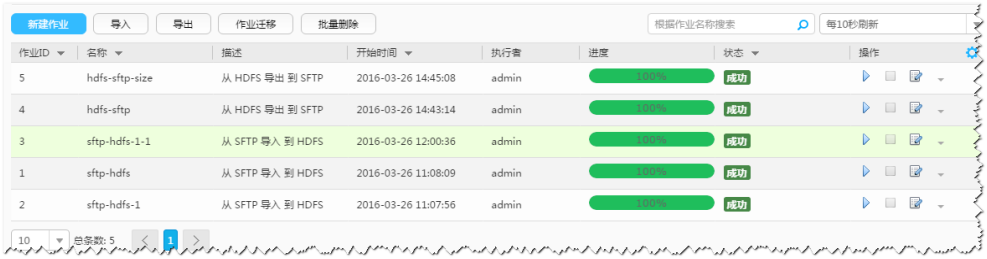

----结束

17.5.6 典型场景：从 FTP 服务器导入数据到 HBase

操作场景

该任务指导用户使用 Loader 将数据从 FTP 服务器导入到 HBase。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 获取 FTP 服务器使用的用户和密码，且该用户具备 FTP 服务器上源文件的读取权限。若源文件在导入后文件名要增加后缀，则该用户还需具备源文件的写入权限。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 使用 Loader 从 FTP 服务器导入数据时，确保 FTP 服务器输入路径目录名、输入路径的子目录名及子文件名不能包含特殊字符/\'":;,中的任意字符。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-16 Loader WebUI 界面

----结束

单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-17 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 2 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“ftp-connector”，单击“添加”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。Loader 支持配置多个 FTP 服务器操作数据，单击“添加”可增加多行 FTP 服务器的配置信息。

表17-26 连接参数

参数名	说明	示例
FTP 服务器的 IP	FTP 服务器的 IP 地址。	ftpName
FTP 服务器端口	FTP 服务器的端口号。	22
FTP 用户名	访问 FTP 服务器的用户名。	root
FTP 密码	访问 FTP 服务器的密码。	xxxx
FTP 模式	设置 FTP 访问模式，“ACTIVE”表示主动模式，“PASSIVE”表示被动模式。不指定参数值，默认为被动模式。	PASSIVE
FTP 协议	设置 FTP 传输协议： • “FTP”：FTP 协议。 • “SSL_EXPLICIT”：显式 SSL 协议。 • “SSL_IMPLICIT”：隐式 SSL 协议。 • “TLS_EXPLICIT”：显式 TLS 协议。 • “TLS_IMPLICIT”：隐式 TLS 协议。 不指定参数值，默认为 FTP 协议。	FTP
文件名编码类型	填写 FTP 服务器支持的文件名、文件路径编码格式，不填写时使用系统默认格式 UTF-8。	UTF-8

说明

配置多个 FTP 服务器，多个服务器指定目录的数据将导入到 HBase。

设置数据源信息

步骤 3 单击“下一步”，进入“输入设置”界面，设置数据源信息。

表17-27 输入设置参数

参数名	说明	示例
输入路径	FTP 服务器中源文件的输入路径，如果连接器配置多个地址此处可对应使用“;”分隔多个输入路径，数量需要与连接器中服务器的数量一致。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/opt/tempfile;/opt
文件分割方式	选择按文件或大小分割源文件，作为数据导入的 MapReduce 任务中各个 map 的输入文件。 • 选择“FILE”，表示按文件分割源文件，即每个 map 处理一个或多个完整的源文件，同	FILE

参数名	说明	示例
	一个源文件不可分配至不同 map，完成数据导入后保持源文件的目录结构。 • 选择“SIZE”，表示按大小分割源文件，即每个 map 处理一定大小的输入文件，同一个源文件可分割至多个 map，数据保存至输出目录时保存的文件数与 map 数量相同，文件名格式为“import_part_xxxx”，“xxxx”为系统生成的随机数，具有唯一性。	
过滤类型	选择文件过滤的条件，与“路径过滤器”、“文件过滤器”配合使用。 • 选择“WILDCARD”，表示使用通配符过滤。 • 选择“REGEX”，表示使用正则表达式匹配。 • 不选择，则默认为通配符过滤。	WILDCARD
路径过滤器	与“过滤类型”配合使用，配置通配符或正则表达式对源文件的输入路径包含的目录进行过滤。“输入路径”不参与过滤。使用分号“;”分隔多个服务器上的路径过滤器，每个服务器的多个过滤条件使用逗号“,”隔开。配置为空时表示不过滤目录。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。 例如，当“过滤类型”选择“WILDCARD”时，将该参数设置为“*”；当“过滤类型”选择“REGEX”时，将该参数设置为“\\.*”。	1*,2*;1*
文件过滤器	与“过滤类型”配合使用，配置通配符或正则表达式对源文件的输入文件名进行过滤。使用分号“;”分隔多个服务器上的文件过滤器，每个服务器的多个过滤条件使用逗号“,”隔开。该参数不能配置为空。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。 例如，当“过滤类型”选择“WILDCARD”时，将该参数设置为“*”；当“过滤类型”选择“REGEX”时，将该参数设置为“\\.*”。	*.txt,*.csv;*.txt
编码类型	源文件的编码格式，如 UTF-8、GBK。导入文	UTF-8

参数名	说明	示例
	本文件时才能配置。	
后缀名	源文件导入成功后对输入文件增加的后缀值。该值为空，则表示不加后缀。数据源为文件系统，该参数才有效。用户若需增量导入数据建议设置该参数。 例如设置为“.txt”，源文件为“test-loader.csv”，则导出后源文件名为“test-loader.csv.txt”。	.log
压缩	使用 FTP 协议导入数据时，是否开启压缩传输功能以减小带宽使用。 • 选择“true”，表示开启压缩。 • 选择“false”，表示关闭压缩。	true

设置数据转换

步骤 4 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-28。

表17-28 算子输入、输出参数设置

输入类型	输出类型
CSV 文件输入	HBase 输出
HTML 输入	HBase 输出
固定宽度文件输入	HBase 输出

图17-18 算子操作方法示意

设置数据保存信息并运行作业

步骤 5 单击“下一步”，进入“输出设置”界面，根据实际场景在“存储类型”选择“HBASE_BULKLOAD”或“HBASE_PUTLIST”，设置数据保存方式。

表17-29 输出设置参数

存储类型	适用场景	参数名	说明	示例
HBASE_BULKLOAD	数据量大	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。	HBase
		导入前清理数据	导入前清空原表的数据。“True”为执行清空，“False”为不执行。不配置此参数则默认不执行清空。	true
		Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000，建议以 FTP 服务器当前最大连接数作为其取值。	20
		Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。	-
HBASE_PUTLIST	数据量小	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作	HBase

存储类型	适用场景	参数名	说明	示例
			业无法正常运行。	
		Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000。	20
		Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。	-

步骤 6 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 7 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-19 查看作业

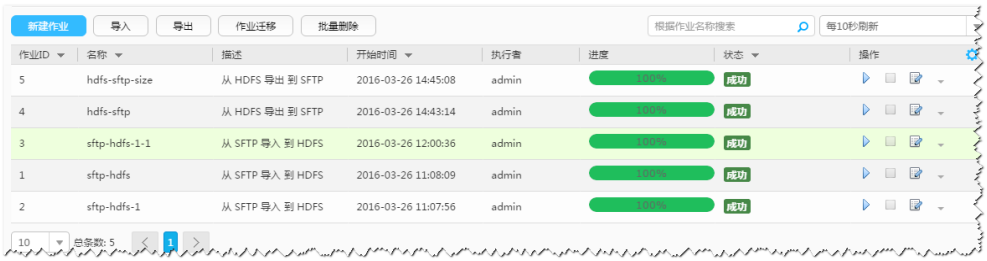

----结束

17.5.7 典型场景：从关系型数据库导入数据到 HDFS/OBS

操作场景

该任务指导用户使用 Loader 将数据从关系型数据库导入到 HDFS/OBS。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HDFS/OBS 目录和数据。
- 获取关系型数据库使用的用户和密码。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。
- 操作前需要进行如下配置：

a. 获取关系型数据库对应的驱动 jar 包保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。

b. 使用 root 用户在主备节点分别执行以下命令修改权限：

cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

chown omm:wheel *jar 包文件名*

chmod 600 *jar 包文件名*

c. 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”，输入管理员密码重启 Loader 服务。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-20 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-21 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。

3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“generic-jdbc-connector”或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

说明

- 与关系数据库连接时，可以选择通用数据库连接器（generic-jdbc-connector）或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），专用数据库连接器特别针对具体数据库类型进行优化，相对通用数据库连接器来说，导出、导入速度更快。
- 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。

表17-30“generic-jdbc-connector”连接参数

参数名	说明	示例
名称	关系型数据库连接的名称。	dbName
JDBC 驱动程序类	JDBC 驱动类名。	oracle.jdbc.driver.OracleDriver
JDBC 连接字符串	JDBC 连接字符串。	jdbc:oracle:thin:@//10.16.0.1:1521/oradb
用户名	连接数据库使用的用户名。	omm
密码	连接数据库使用的密码。	xxxx
JDBC 连接属性	JDBC 连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值	• 名称：socketTimeout • 值：20

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，设置数据源信息。

表17-31 输入设置参数

参数名	说明	示例
架构名称	“表方式”模式下存在，数据库模式名。	public

参数名	说明	示例
表名	“表方式”模式下存在，数据库表名。	test
SQL 语句	“SQL 方式”模式下存在，配置要查询的 SQL 语句，使 Loader 可通过 SQL 语句查询结果并作为导入的数据。SQL 语句需要有查询条件“WHERE ${CONDITIONS}”，否则无法正常工作。例如，“select * from TABLE WHERE A>B and ${CONDITIONS}”。如果同时配置“表列名”，SQL 语句中查询的列将被“表列名”配置的列代替。不能和“架构名称”、“表名”同时配置。 说明 SQL Where 语句可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	select * from TABLE WHERE A>B and ${CONDITIONS}
表列名	配置要导入的列，使 Loader 将列的内容全部导入。配置多个字段时使用“,”分隔。 如果不配置，则导入所有列，同时“Select *”的顺序作为列的位置。	id,name
分区列名	指定数据库表的一列，根据该列来划分要导入的数据，在 Map 任务中用于分区。建议配置主键字段。 说明 • 分区列必选有索引，如果没有索引，请不要指定分区列，指定没有索引的分区列会导致数据库服务器磁盘 I/O 繁忙，影响其他业务访问数据库，并且导入时间长。 • 在有索引的多个字段中，选择字段值最离散的字段作为分区列，不离散的分区列会导致多个导入 MR 任务负载不均衡。 • 分区列的排序规则必须支持大小写敏感，否则在数据导入过程中，可能会出现数据丢失。 • 不建议分区列选择类型为 float 或 double 的字段，因为精度问题，可能导致分区列字段的最小值、最大值所在记录无法导入。	id
分区列空值	配置对数据库列中为 null 值记录的处理方式。 • 值为“true”时，分区列的值为 null 的数据会被处理； • 值为“false”时，分区列的值为 null 的数据不会被处理。	true
是否指定分区列	是否指定分区列。	true

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-32。

表17-32 算子输入、输出参数设置

输入类型	输出类型
表输入	文件输出

图17-22 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，在“存储类型”中选择“HDFS”，设置数据保存方式。

表17-33 输出设置参数

参数名	说明	示例
文件类型	文件导入后保存的类型： • “TEXT_FILE”：导入文本文件并保存为文本文件 • “SEQUENCE_FILE”： 导入文本文件并保存在“sequence file”文件格式 • “BINARY_FILE”：以二进制流的方式导入文件，可以导入任何格式的文件	TEXT_FILE
压缩格式	在下拉菜单中选择数据导入 HDFS/OBS 后保存文件的压缩格式，未配置或选择“NONE”表示不压缩数据。	NONE

参数名	说明	示例
输出目录	数据导入到 HDFS/OBS 里存储的保存目录。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/user/test
文件操作方式	数据导入时的操作行为。全部数据从输入路径导入到目标路径时，先保存在临时目录，然后再从临时目录复制转移至目标路径，任务完成时删除临时路径的文件。转移临时文件存在同名文件时有以下行为： • “OVERRIDE”：直接覆盖旧文件。 • “RENAME”：重命名新文件。无扩展名的文件直接增加字符串后缀，有扩展名的文件在文件名增加字符串后缀。字符串具有唯一性。 • “APPEND”：在旧文件尾部合并新文件内容。合并操作只是简单的追加，不保证追加文件是否可以使用。例如文本文件可合并，压缩文件合并后可能无法使用。 • “IGNORE”：保留旧文件，不复制新文件。 • “ERROR”：转移过程中出现同名文件时任务将停止执行并报错，已转移的文件导入成功，同名的文件及未转移的文档导入失败。	OVERRIDE
Map 数	配置数据操作的 MapReduce 任务中同时启动的 Map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于 3000。	-
Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于 100，建议配置值为 1000。不可与“Map 数”同时配置。当使用关系型数据库连接器时，不支持“Map 数据块大小”，请配置“Map 数”。	1000

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-23 查看作业

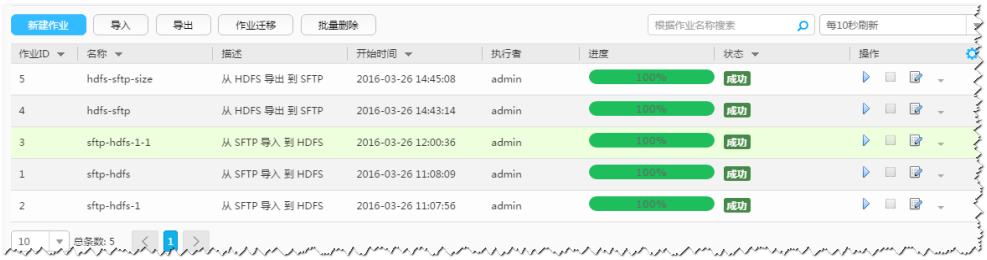

----结束

17.5.8 典型场景：从关系型数据库导入数据到 HBase

操作场景

该任务指导用户使用 Loader 将数据从关系型数据库导入到 HBase。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HBase 表或 phoenix 表。
- 获取关系型数据库使用的用户和密码。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。
- 操作前需要进行如下配置：
  a. 获取关系型数据库对应的驱动 jar 包保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。
  b. 使用 root 用户在主备节点分别执行以下命令修改权限：

     cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

     chown omm:wheel *jar 包文件名*

     chmod 600 *jar 包文件名*
  c. 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”，输入管理员密码重启 Loader 服务。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-24 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-25 “基本信息”界面

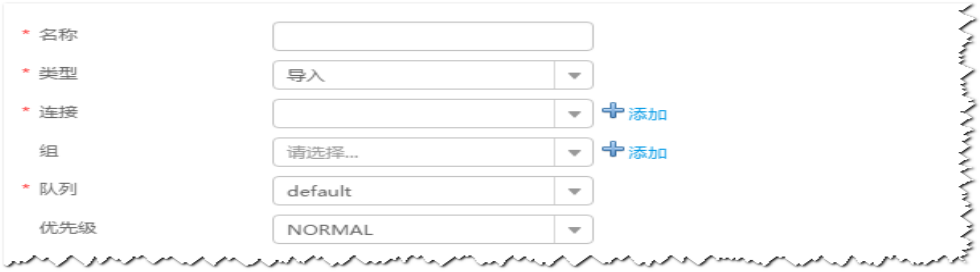

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“generic-jdbc-connector”或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

说明

- 与关系数据库连接时，可以选择通用数据库连接器（generic-jdbc-connector）或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），专用数据库连接器特别针对具体数据库类型进行优化，相对通用数据库连接器来说，导出、导入速度更快。

- 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。

表17-34“generic-jdbc-connector”连接参数

参数名	说明	示例
名称	关系型数据库连接的名称。	dbName
JDBC 驱动程序类	JDBC 驱动类名。	oracle.jdbc.driver.OracleDriver
JDBC 连接字符串	JDBC 连接字符串。	jdbc:oracle:thin:@//10.16.0.1:1521/oradb
用户名	连接数据库使用的用户名。	omm
密码	连接数据库使用的密码。	xxxx
JDBC 连接属性	JDBC 连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值	• 名称：socketTimeout • 值：20

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，设置数据源信息。

表17-35 输入设置参数

参数名	说明	示例
架构名称	“表方式”模式下存在，数据库模式名。	dbo
表名	“表方式”模式下存在，数据库表名。	test
SQL 语句	“SQL 方式”模式下存在，配置要查询的 SQL 语句，使 Loader 可通过 SQL 语句查询结果并作为导入的数据。SQL 语句需要有查询条件“WHERE ${CONDITIONS}”，否则无法正常工作。例如，“select * from TABLE WHERE A>B and ${CONDITIONS}”。如果同时配置“表列名”，SQL 语句中查询的列将被“表列名”配置的列代替。不能和“架构名称”、“表名”同时配置。 **说明** SQL Where 语句可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	select * from test where ${CONDITIONS}

参数名	说明	示例
表列名	配置要导入的列，使 Loader 将列的内容全部导入。配置多个字段时使用“,”分隔。 如果不配置，则导入所有列，同时“Select *”的顺序作为列的位置。	-
分区列名	指定数据库表的一列，根据该列来划分要导入的数据，在 Map 任务中用于分区。建议配置主键字段。 说明 • 分区列必选有索引，如果没有索引，请不要指定分区列，指定没有索引的分区列会导致数据库服务器磁盘 I/O 繁忙，影响其他业务访问数据库，并且导入时间长。 • 在有索引的多个字段中，选择字段值最离散的字段作为分区列，不离散的分区列会导致多个导入 MR 任务负载不均衡。 • 分区列的排序规则必须支持大小写敏感，否则在数据导入过程中，可能会出现数据丢失。 • 不建议分区列选择类型为 float 或 double 的字段，因为精度问题，可能导致分区列字段的最小值、最大值所在记录无法导入。	id
分区列空值	配置对数据库列中为 null 值记录的处理方式。 • 值为“true”时，分区列的值为 null 的数据会被处理； • 值为“false”时，分区列的值为 null 的数据不会被处理。	true
是否指定分区列	是否指定分区列。	true

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-36。

表17-36 算子输入、输出参数设置

输入类型	输出类型
表输入	HBase 输出

图17-26 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，根据实际场景在“存储类型”选择“HBASE_BULKLOAD”或“HBASE_PUTLIST”，设置数据保存方式。

表17-37 输出设置参数

存储类型	适用场景	参数名	说明	示例
HBASE_BULKLOAD	数据量大	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。	HBase
		导入前清理数据	导入前清空原表的数据。“True”为执行清空，“False”为不执行。不配置此参数则默认不执行清空。	true
		Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000。	20
		Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。	-
HBASE_PUTLIST	数据量小	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。	HBase

存储类型	适用场景	参数名	说明	示例
		Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000。	true
		Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。	-

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-27 查看作业

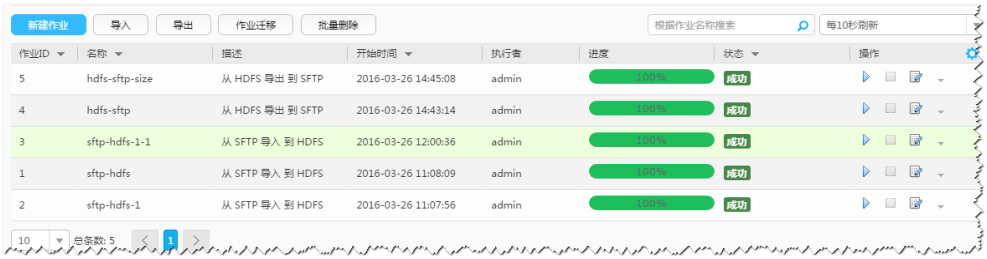

----结束

17.5.9 典型场景：从关系型数据库导入数据到 Hive

操作场景

该任务指导用户使用 Loader 将数据从关系型数据库导入到 Hive。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 Hive 表。
- 获取关系型数据库使用的用户和密码。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。
- 操作前需要进行如下配置：

a. 获取关系型数据库对应的驱动 jar 包保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。

b. 使用 root 用户在主备节点分别执行以下命令修改权限：

cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

chown omm:wheel *jar 包文件名*

chmod 600 *jar 包文件名*

c. 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”，输入管理员密码重启 Loader 服务。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-28 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-29 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。

3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“generic-jdbc-connector”或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

说明

- 与关系数据库连接时，可以选择通用数据库连接器（generic-jdbc-connector）或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），专用数据库连接器特别针对具体数据库类型进行优化，相对通用数据库连接器来说，导出、导入速度更快。
- 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。

表17-38“generic-jdbc-connector”连接参数

参数名	说明	示例
名称	关系型数据库连接的名称。	dbName
JDBC 驱动程序类	JDBC 驱动类名。	oracle.jdbc.driver.OracleDriver
JDBC 连接字符串	JDBC 连接字符串。	jdbc:oracle:thin:@//10.16.0.1:1521/oradb
用户名	连接数据库使用的用户名。	omm
密码	连接数据库使用的密码。	xxxx
JDBC 连接属性	JDBC 连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值 须知 使用通用连接器连接 MySQL 时，在大数据量场景下，需要在 MySQL 的 JDBC 连接串中设置连接属性“useCursorFetch=true”。	• 名称：socketTimeout • 值：20

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，设置数据源信息。

表17-39 输入设置参数

参数名	说明	示例
架构名称	“表方式”模式下存在，数据库模式名。	dbo
表名	“表方式”模式下存在，数据库表名。	test
SQL 语句	“SQL 方式”模式下存在，配置要查询的 SQL 语句，使 Loader 可通过 SQL 语句查询结果并作为导入的数据。SQL 语句需要有查询条件“WHERE ${CONDITIONS}”，否则无法正常工作。例如，“select * from TABLE WHERE A>B and ${CONDITIONS}”。如果同时配置“表列名”，SQL 语句中查询的列将被“表列名”配置的列代替。不能和“架构名称”、“表名”同时配置。 **说明** SQL Where 语句可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	select * from test where ${CONDITIONS}
表列名	配置要导入的列，使 Loader 将列的内容全部导入。配置多个字段时使用“,”分隔。 如果不配置，则导入所有列，同时“Select *”的顺序作为列的位置。	-
分区列名	指定数据库表的一列，根据该列来划分要导入的数据，在 Map 任务中用于分区。建议配置主键字段。 **说明** • 分区列必选有索引，如果没有索引，请不要指定分区列，指定没有索引的分区列会导致数据库服务器磁盘 I/O 繁忙，影响其他业务访问数据库，并且导入时间长。 • 在有索引的多个字段中，选择字段值最离散的字段作为分区列，不离散的分区列会导致多个导入 MR 任务负载不均衡。 • 分区列的排序规则必须支持大小写敏感，否则在数据导入过程中，可能会出现数据丢失。 • 不建议分区列选择类型为 float 或 double 的字段，因为精度问题，可能导致分区列字段的最小值、最大值所在记录无法导入。	id
分区列空值	配置对数据库列中为 null 值记录的处理方式。 • 值为“true”时，分区列的值为 null	true

参数名	说明	示例
	的数据会被处理； • 值为“false”时，分区列的值为 null 的数据不会被处理。	
是否指定分区列	是否指定分区列。	true

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-40。

表17-40 算子输入、输出参数设置

输入类型	输出类型
表输入	Hive 输出

图17-30 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，在“存储类型”选择“HIVE”，设置数据保存方式。

表17-41 输出设置参数

参数名	说明	示例

参数名	说明	示例
输出目录	数据导入到 Hive 里存储的保存目录。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/opt/tempfile
Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000，建议以 SFTP 服务器当前最大连接数作为其取值。	20
Map 数据块大小	Hive 不支持此参数，请配置“Map 数”。	-

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-31 查看作业

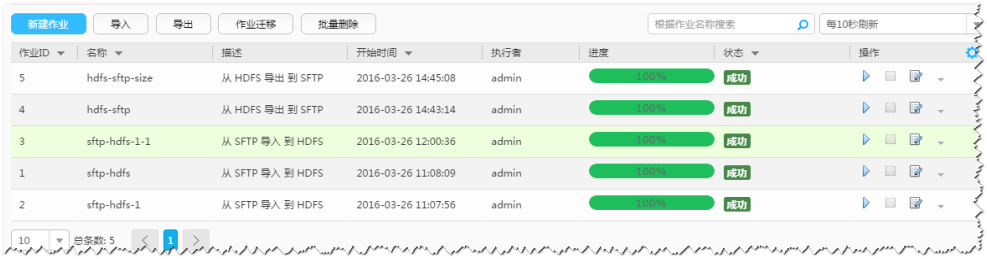

----结束

17.5.10 典型场景：从 HDFS/OBS 导入数据到 HBase

操作场景

该任务指导用户使用 Loader 将文件从 HDFS/OBS 导入到 HBase。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HDFS/OBS 目录和数据。
- 确保用户已授权访问作业执行时操作的 HBase 表或 phoenix 表。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 使用 Loader 从 HDFS/OBS 导入数据时，确保 HDFS/OBS 输入路径目录名、输入路径的子目录名及子文件名不能包含特殊字符/\'":;,中的任意字符。

- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-32 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-33 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“hdfs-connector”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，设置数据源信息。

表17-42 输入设置参数

参数名	说明	示例
输入路径	HDFS/OBS 中源文件的输入路径。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/user/test
路径过滤器	配置通配符对源文件的输入路径包含的目录进行过滤。“输入路径”不参与过滤。配置多个过滤条件时使用“,”隔开，配置为空时表示不过滤目录。不支持正则表达式过滤。	*
文件过滤器	配置通配符对源文件的输入文件名进行过滤。配置多个过滤条件时使用“,”隔开。不能配置为空。不支持正则表达式过滤。	*
编码类型	源文件的编码格式，如 UTF-8。导入文本文件时才能配置。	UTF-8
后缀名	源文件导入成功后对输入文件增加的后缀值。该值为空，表示不加后缀。	.log

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-43。

表17-43 算子输入、输出参数设置

输入类型	输出类型
CSV 文件输入	HBase 输出
HTML 输入	HBase 输出
固定宽度文件输入	HBase 输出

图17-34 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，根据实际场景在“存储类型”选择“HBASE_BULKLOAD”或“HBASE_PUTLIST”，设置数据保存方式。

表17-44 输出设置参数

存储类型	适用场景	参数名	说明	示例
HBASE_BULKLOAD	数据量大	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。	HBase
		导入前清理数据	导入前清空原表的数据。“True”为执行清空，“False”为不执行。不配置此参数则默认不执行清空。	true
		Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000。	20
		Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。	-
HBASE_PUTLIST	数据量小	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。	HBase

存储类型	适用场景	参数名	说明	示例
		Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000。	20
		Map 数据块大小	HBase 不支持此参数，请配置“Map 数”。	-

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-35 查看作业

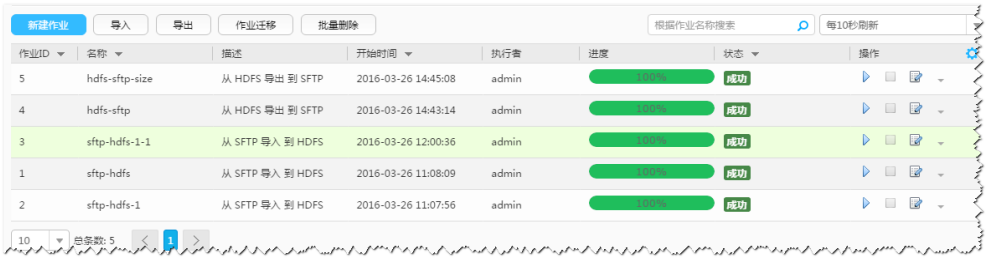

----结束

17.5.11 典型场景：从关系型数据库导入数据到 ClickHouse

操作场景

该任务指导用户使用 Loader 将数据从关系型数据库导入到 ClickHouse，本章节已 MySQL 为例进行操作。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- ClickHouse 表已创建，确保用户已授权访问作业执行时操作该表的权限。
- 获取 MySQL 数据库使用的用户和密码。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

- 操作前需要进行如下配置：
  a. 从 MySQL 数据库安装路径下获取 MySQL 客户端 jar 包（如 mysqlclient-5.8.1.jar），将其保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。
  b. 在 ClickHouse 的安装目录获取 clickhouse-jdbc-*.jar 包，将其保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。
  c. 使用 root 用户在主备节点分别执行以下命令修改权限：

     cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

     chown omm:wheel *jar 包文件名*

     chmod 600 *jar 包文件名*
  d. 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”，输入管理员密码重启 Loader 服务。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-36 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-37 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“generic-jdbc-connector”或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

说明

- 与关系数据库连接时，可以选择通用数据库连接器（generic-jdbc-connector）或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），专用数据库连接器特别针对具体数据库类型进行优化，相对通用数据库连接器来说，导出、导入速度更快。
- 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。

表17-45“generic-jdbc-connector”连接参数

参数名	说明	示例
名称	关系型数据库连接的名称。	mysql_test
JDBC 驱动程序类	JDBC 驱动类名。	com.mysql.jdbc.Driver
JDBC 连接字符串	JDBC 连接字符串。	jdbc:mysql://10.254.144.102:3306/test?useUnicode=true&characterEncoding=UTF-8
用户名	连接数据库使用的用户名。	root
密码	连接数据库使用的密码。	xxxx

设置数据源信息

单击“下一步”，进入“输入设置”界面，设置数据源信息，暂只支持选择“表方式”。

表17-46 输入设置参数

参数名	说明	示例
架构名称	用户指定数据库的模式名	public
表名	表名称	test
表列名	指定要输入的列名	id,name
是否指定分区列	暂只支持不指定分区模式	false

设置数据转换

单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-47。

表17-47 算子输入、输出参数设置

输入类型	输出类型
MySQL 输入	ClickHouse 输出

在输入中把“表输入”拖拽到网格中，双击“表输入”，选择“自动识别”如图 17-38 所示。

图17-38 算子输入

在输出中把“ClickHouse 输出”拖拽到网格中，双击“表输出”，选择“关联”或者手动编辑表格，与输入的表格对应，如图 17-39 所示。

图17-39 算子输出

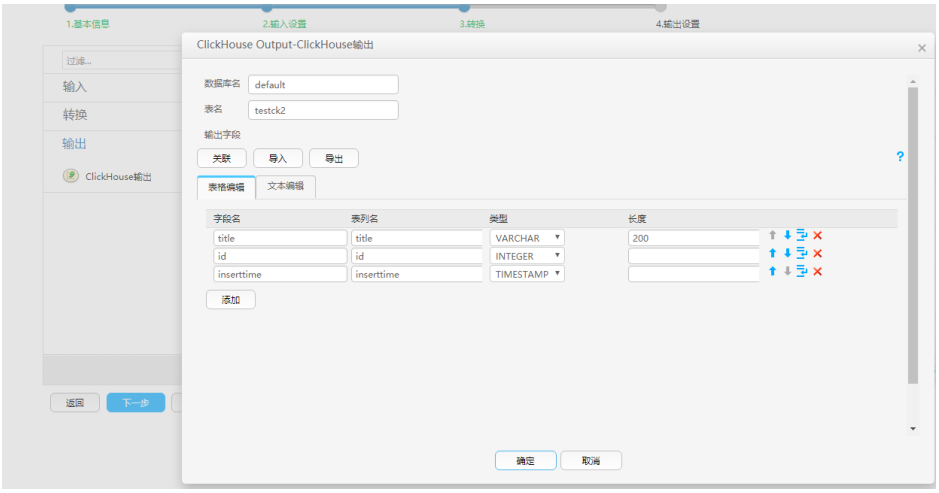

设置数据保存信息并运行作业

单击“下一步”，进入“输出设置”界面，在“存储类型”中选择“CLICKHOUSE”，设置数据保存方式。

表17-48 输出设置参数

参数名	说明	示例
存储类型	选择 CLICKHOUSE	-
ClickHouse 实例	选择 ClickHouse	-
导入前清理数据	选择“true”或“false” **说明** 如果导入的表为 ClickHouse 分布式表，且需要清理数据时，请在导入前手动删除 ClickHouse 分布式表对应的本地表中的数据。	true

步骤 4 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-40 查看作业

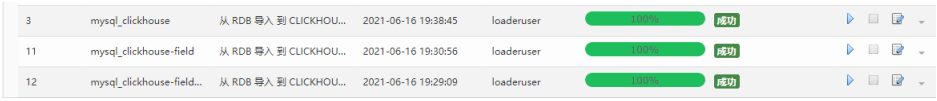

步骤 5 使用 ClickHouse 客户端，查询 ClickHouse 表数据是否和 MySQL 的表数据一致。

----结束

17.5.12 典型场景：从 HDFS 导入数据到 ClickHouse

操作场景

该任务指导用户使用 Loader 将文件从 HDFS 导入到 ClickHouse。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HDFS 目录和数据。
- ClickHouse 相关表已创建，并确保用户已授权访问作业执行时操作该表的权限。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 使用 Loader 从 HDFS 导入数据时，确保 HDFS 输入路径目录名、输入路径的子目录名及子文件名不能包含特殊字符/\'":;,中的任意字符。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-41 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-42 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导入”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“hdfs-connector”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

设置数据源信息

单击“下一步”，进入“输入设置”界面，设置数据源信息。

表17-49 输入设置参数

参数名	说明	示例
输入路径	HDFS 中源文件的输入路径。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/user/test
路径过滤器	配置通配符对源文件的输入路径包含的目录进行过滤。“输入路径”不参与过滤。配置多个过滤条件时使用“,”隔开，配置为空时表示不过滤目录。不支持正则表达式过滤。	*
文件过滤器	配置通配符对源文件的输入文件名进行过滤。配置多个过滤条件时使用“,”隔开。不能配置为空。不支持正则表达式过滤。	*
编码类型	源文件的编码格式，如 UTF-8。导入文本文件时才能配置。	UTF-8

参数名	说明	示例
后缀名	源文件导入成功后对输入文件增加的后缀值。该值为空，表示不加后缀。	.log

设置数据转换

单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-50。

表17-50 算子输入、输出参数设置

输入类型	输出类型
CSV 文件输入	ClickHouse 输出

图17-43 算子操作方法示意

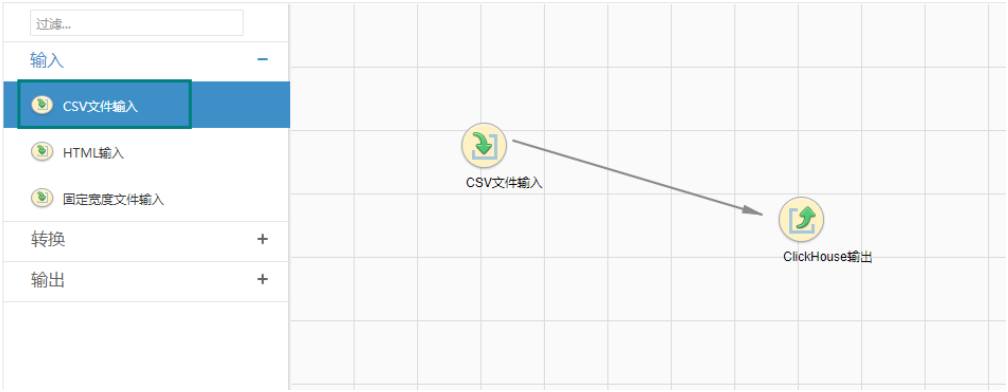

设置数据保存信息并运行作业

单击“下一步”，进入“输出设置”界面，根据实际场景在“存储类型”选择“CLICKHOUSE”，设置数据保存方式。

表17-51 输出设置参数

存储类型	参数名	说明	示例
CLICKHOUSE	ClickHouse 实例	在 ClickHouse 作业中，Loader 支持从集群可添加的所有 ClickHouse 服务实例中选择任意一个。如果选定的 ClickHouse 服务实例在集群中未添加，则此作业无法正常运行。	ClickHouse
	导入前清理数据	导入前清空原表的数据。“True”为执行	false

存储类型	参数名	说明	示例
		清空，“False”为不执行。不配置此参数则默认不执行清空。 说明 如果导入的表为 ClickHouse 分布式表，且需要清理数据时，请在导入前手动删除 ClickHouse 分布式表对应的本地表中的数据。	
	Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000。	20
	Map 数据块大小	ClickHouse 不支持此参数，请配置“Map 数”。	-
	个数	Map 任务的个数。	-

步骤 4 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-44 查看作业

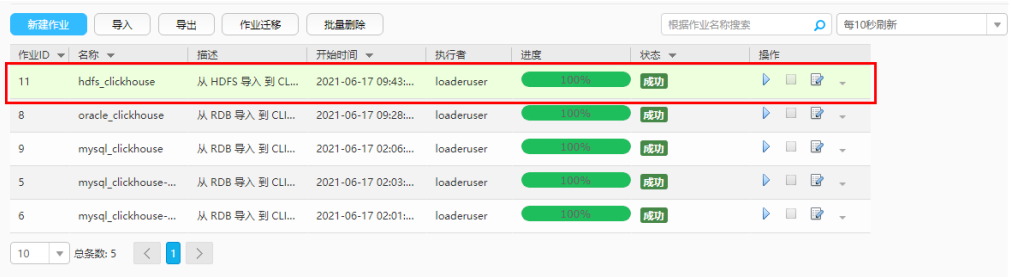

步骤 5 使用 ClickHouse 客户端，查询 ClickHouse 表数据是否和 HDFS 导入的数据一致。

----结束

17.6 数据导出

17.6.1 概述

“数据导出”章节适用于 MRS 3.x 及后续版本。

简介

Loader 是实现 MRS 与关系型数据库、文件系统之间交换数据和文件的 ETL 工具，支持将数据或者文件从 MRS 系统中导出到关系型数据库或文件系统中。

Loader 支持如下数据导出方式：

- 从 HDFS/OBS 中导出数据到 SFTP 服务器
- 从 HDFS/OBS 中导出数据到关系型数据库
- 从 HBase 中导出数据到 SFTP 服务器
- 从 HBase 中导出数据到关系型数据库
- 从 Phoenix 表导出数据到 SFTP 服务器
- 从 Phoenix 表导出数据到关系型数据库
- 从 Hive 中导出数据到 SFTP 服务器
- 从 Hive 中导出数据到关系数据库
- 从同一集群内 HBase 导出数据到 HDFS/OBS

MRS 与外部数据源交换数据和文件时需要连接数据源。系统提供以下连接器，用于配置不同类型数据源的连接参数：

- generic-jdbc-connector：关系型数据库连接器。
- hdfs-connector：HDFS 数据源连接器。
- oracle-connector：Oracle 数据库专用连接器，使用 row_id 作为分区列，相对 generic-jdbc-connector 来说，Map 任务分区更均匀，并且不依赖区分列是否有创建索引。
- mysql-fastpath-connector：MySQL 数据库专用连接器，使用 MySQL 的 mysqldump 和 mysqlimport 工具进行数据的导入导出，相对 generic-jdbc-connector 来说，导入导出速度更快。
- sftp-connector：SFTP 数据源连接器。
- oracle-partition-connector：支持 Oracle 分区特性的连接器，专门对 Oracle 分区表的导入导出进行优化。

说明

- 建议将 SFTP 服务器和数据库服务器与 Loader 部署在独立的子网中，以保障数据安全地导出。
- 与关系数据库连接时，可以选择通用数据库连接器（generic-jdbc-connector）或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），专用数据库连接器特别针对具体数据库类型进行优化，相对通用数据库连接器来说，导出、导入速度更快。
- 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。
- 使用 oracle-connector 时，要求给连接用户赋予如下系统表或者视图的 select 权限：

  dba_tab_partitions、dba_constraints、dba_tables 、dba_segments 、v$version、dba_objects、v$instance、dba_extents、 dba_tab_partitions、dba_tab_subpartitions。
- 使用 oracle-partition-connector 时，要求给连接用户赋予如下系统表的 select 权限：dba_objects、dba_extents。

导出流程

用户通过 Loader 界面进行数据导出作业，导出流程如图 17-45 所示。

图17-45 导出流程示意

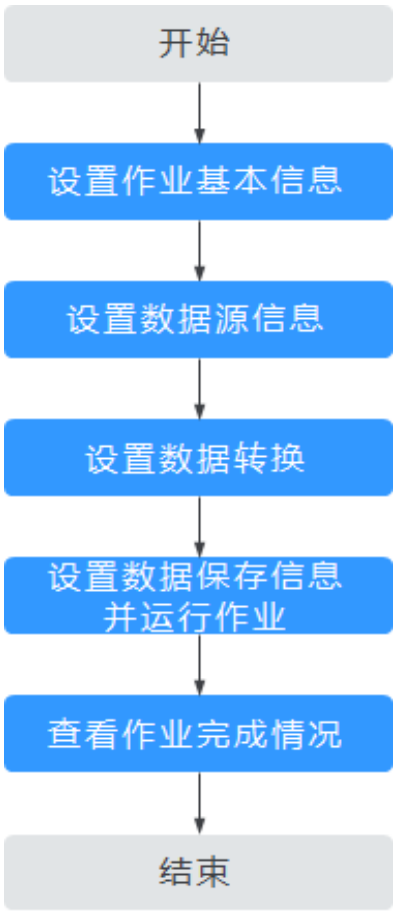

用户也可以通过 Shell 脚本来更新与运行 Loader 作业。该方式需要对已安装的 Loader 客户端进行配置。

17.6.2 使用 Loader 导出数据

操作场景

该任务指导用户完成将数据从 MRS 导出到外部的数据源的工作。

一般情况下，用户可以手工在 Loader 界面管理数据导入导出作业。当用户需要通过 shell 脚本来更新与运行 Loader 作业时，必须对已安装的 Loader 客户端进行配置。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的目录、HBase 表和数据。

- 获取外部数据源（SFTP 服务器或关系型数据库）使用的用户和密码。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 使用 Loader 从 HDFS/OBS 导出数据时，确保 HDFS/OBS 数据源的输入路径目录名、输入路径的子目录名及子文件名不能包含特殊字符/\"':;,中的任意字符。
- 如果设置的任务需要使用指定 Yarn 队列功能，该用户需要已授权有相关 Yarn 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

是否第一次从 Loader 导出数据到关系型数据库？

- 是，执行步骤 2。
- 否，执行步骤 3。

步骤 1 修改关系型数据库对应的驱动 jar 包文件权限。

1. 获取关系型数据库对应的驱动 jar 包保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。
2. 使用 **root** 用户在主备节点分别执行以下命令修改权限：

   cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

   chown omm:wheel *jar 包文件名*

   chmod 600 *jar 包文件名*
3. 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”输入管理员密码重启 Loader 服务。

步骤 2 登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

   图17-46 Loader WebUI 界面

步骤 3 创建 Loader 数据导出作业，单击“新建作业”，在“1.基本信息”选择所需要的作业类型，然后单击“下一步”。

1. “名称”输入作业的名称，“类型”选择“导出”即导出。
2. “连接”选择一个连接。默认没有已创建的连接，单击“添加”创建一个新的连接，完成后单击“测试”，测试是否可用，待提示成功后单击“确定”。

表17-52 连接配置参数一览表

连接器类型	参数名	说明
generic-jdbc-connector	JDBC 驱动程序类	JDBC 驱动类名。
	JDBC 连接字符串	JDBC 连接字符串。
	用户名	连接数据库使用的用户名。
	密码	连接数据库使用的密码。
	JDBC 连接属性	JDBC 连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值
hdfs-connector	-	-
oracle-connector	JDBC 连接字符串	用户连接数据库的连接字符串。
	用户名	连接数据库使用的用户名。
	密码	连接数据库使用的密码。
	连接属性	连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值
mysql-fastpath-connector	JDBC 连接字符串	JDBC 连接字符串。
	用户名	连接数据库使用的用户名。
	密码	连接数据库使用的密码。
	连接属性	连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值
sftp-connector	Sftp 服务器的 IP	SFTP 服务器的 IP 地址。
	Sftp 服务器端口	SFTP 服务器的端口号。
	Sftp 用户名	访问 SFTP 服务器的用户名。

连接器类型	参数名	说明
	Sftp 密码	访问 SFTP 服务器的密码。
	Sftp 公钥	Sftp 服务器公钥。
oracle-partition-connector	JDBC 驱动程序类	JDBC 驱动类名。
	JDBC 连接字符串	JDBC 连接字符串。
	用户名	连接数据库使用的用户名。
	密码	连接数据库使用的密码。
	连接属性	连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值

3. “组”设置“作业”所属组，默认没有已创建的组，单击“添加”创建一个新的组，单击“确定”保存。
4. “队列”设置 Loader 的任务在指定的 Yarn 队列中执行。默认值“root.default”表示任务在“default”队列中执行。
5. “优先级”设置 Loader 的任务在指定的 Yarn 队列中的优先级。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。默认值为“NORMAL”。

步骤 4 在“2.输入设置”，设置数据来源，然后单击“下一步”。

说明

创建或者编辑 Loader 作业时，在配置 SFTP 路径、HDFS/OBS 路径、SQL 的 Where 条件等参数时，可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义章节。

表17-53 输入配置参数一览表

源文件类型	参数名	解释说明
HDFS/OBS	输入目录	从 HDFS/OBS 导出时的输入路径。
	路径过滤器	配置通配符对源文件的输入路径包含的目录进行过滤。输入路径“输入目录”不参与过滤。配置多个过滤条件时使用逗号隔开，配置为空时表示不过滤目录。不支持正则表达式过滤。
	文件过滤器	配置通配符对源文件的输入文件名进行过滤。配置多个过滤条件时使用逗号隔开。不能配置为空。不支持正则表达式过滤。
	文件类型	文件导入类型：

源文件类型	参数名	解释说明
		• TEXT_FILE：导入文本文件并保存为文本文件。 • SEQUENCE_FILE：导入文本文件并保存在 sequence file 文件格式。 • BINARY_FILE：以二进制流的方式导入文件，可以导入任何格式的文件。
	文件分割方式	选择按 FILE 文件或 SIZE 大小分割源文件成多份，作为数据导出的 MapReduce 任务中各个 map 的输入文件。
	Map 数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于“3000”。
	Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于“100”，建议配置值为“1000”。不可与“Map 数”同时配置。当使用关系型数据库连接器时，不支持“Map 数据块大小”，请配置“Map 数”。
HBASE	HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。
	个数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于“3000”。
HIVE	Hive 实例	在 Hive 作业中，Loader 支持从集群可添加的所有 Hive 服务实例中选择任意一个。如果选定的 Hive 服务实例在集群中未添加，则此作业无法正常运行。
	个数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于“3000”。
SPARK	Spark 实例	仅支持 SparkSQL 存取 Hive 数据。在 SparkSQL 作业中，Loader 支持从集群可添加的所有 Spark 服务实例中选择任意一个。如果选定的 Spark 服务实例在集群中未添加，则此作业无法正常运行。
	个数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于“3000”。

步骤 5 在“3.转换”设置数据传输过程中的转换操作。

确认 Loader 创建的数据操作作业中，源数据的值是否满足直接使用需求而不进行转换，例如大小写转换、截取、拼接和分隔。

- 满足需求，请单击“下一步”。
- 不满足需求，请执行步骤 6.1～步骤 6.4。

1. 默认没有已创建的转换步骤，可拖动左侧样例到编辑框，添加一个新的转换步骤。
2. 完整的转换流程包含以下类型，每个类型请根据业务需要进行选择。
   a. 输入类型，第一个转换步骤，仅添加一种，任务涉及 HBase 或关系型数据库必须添加。
   b. 转换类型，中间转换步骤，可添加一种以上或不添加。
   c. 输出类型，最后一个转换步骤，仅添加一种，任务涉及 HBase 或关系型数据库必须添加。

表17-54 样例一览表

类型	描述
输入类型	• CSV 文件输入：CSV 文件输入步骤，配置分隔符以转换生成多个字段。 • 固定宽度文件输入：文本文件输入步骤，配置截取字符或字节的长度以转换生成多个字段。 • 表输入：关系型数据输入步骤，配置数据库的指定列为输入的字段。 • HBase 输入：HBase 表输入步骤，配置 HBase 表的列定义到指定字段。 • HTML 输入：HTML 网页数据输入步骤，配置获取 HTML 网页文件目标数据到指定字段。 • Hive 输入：Hive 表输入步骤，配置 Hive 表的列定义到指定字段。 • Spark 输入：SparkSQL 表输入步骤，配置 SparkSQL 表的列定义到指定字段。仅支持存取 Hive 数据。
转换类型	• 长整型时间转换：长整型日期转换步骤，配置长整型数值与日期的转换。 • 空值转换：空值转换步骤，配置指定值替换空值。 • 随机值转换：随机数据生成步骤，配置新增值为随机数据的字段。 • 增加常量字段：增加常量步骤，配置直接生成常量字段。 • 拼接转换：拼接字段步骤，配置已生成的字段通过连接符连接，转换出新的字段。 • 分隔转换：分隔字段步骤，配置已生成的字段通过分隔符分隔，转换出新的字段。 • 取模转换：取模运算步骤，配置已生成的字段通过取模，转换出新的字段。

类型	描述
	• 剪切字符串：字符串截取步骤，配置已生成的字段通过指定位置截取，转换出新的字段。 • EL 操作转换：计算器，可以对字段值进行运算，目前支持的算子有：md5sum、sha1sum、sha256sum 和 sha512sum 等。 • 字符串大小写转换：字符串转换步骤，配置已生成的字段通过大小写变换，转换出新的字段。 • 字符串逆序转换：字符串逆序步骤，配置已生成的字段通过逆序，转换出新的字段。 • 字符串空格清除转换：字符串空格清除步骤，配置已生成的字段通过清除空格，转换出新的字段。 • 过滤行转换：过滤行步骤，配置逻辑条件过滤掉含触发条件的行。 • 更新域：更新域步骤，配置当满足某些条件时，更新指定字段的值。
输出类型	• 文件输出：文本文件输出步骤，配置已生成的字段通过分隔符连接并输出到文件。 • 表输出：关系型数据库输出步骤，配置输出的字段对应到数据库的指定列。 • HBase 输出：HBase 表输出步骤，配置已生成的字段输出到 HBase 表的列。 • Hive 输出：Hive 表输出步骤，配置已生成的字段输出到 Hive 表的列。 • Spark 输出：SparkSQL 表输出步骤，配置已生成的字段输出到 SparkSQL 表的列。仅支持存取 Hive 数据。

编辑栏包括以下几种任务：

- 重命令：重命名样例。
- 编辑：编辑步骤转换，参考步骤 6.3。
- 删除：删除样例。

说明

也可使用快捷键“Del”删除。

3. 单击“编辑”，编辑步骤转换信息，配置字段与数据。

   步骤转换信息中的具体参数设置请参考 17.8 算子帮助。

   转换步骤配置不正确时，传输的数据将无法转换并成为脏数据，脏数据标记规则如下：

   - 任意输入类型步骤中，原数据包含字段的个数小于配置字段的个数，或者原数据字段值与配置字段的类型不匹配时，全部数据成为脏数据。

- “CSV 文件输入”步骤中，“验证输入字段”检验输入字段与值的类型匹配情况，检查不匹配时跳过该行，当前行成为脏数据。
- “固定宽度文件输入”步骤中，“固定长度”指定字段分割长度，长度大于原字段值的长度则数据分割失败，当前行成为脏数据。
- “HBase 输入”步骤中，“HBase 表名”指定 HBase 表名不正确，或者“主键”没有配置主键列，全部数据成为脏数据。
- 任意转换类型步骤中，转换失败的行成为脏数据。例如“分隔转换”步骤中，生成的字段个数小于配置字段的个数，或者原数据不能转换为 String 类型，当前行成为脏数据。
- “过滤行转换”步骤中，被筛选条件过滤的行成为脏数据。
- “取模转换”步骤中，原字段值为“NULL”，当前行成为脏数据。

4. 单击“下一步”。

步骤 6 在“4.输出设置”，设置数据保存目标位置，然后单击“保存”保存作业或“保存并运行”，保存作业并运行作业。

表17-55 输出配置参数一览表

连接类型	参数名	解释说明
sftp-connector	输出路径	SFTP 服务器中导出文件的路径或者文件名，如果连接器配置多个地址此处可对应使用分号分隔多个路径或者文件名，数量需要与连接器中服务器的数量一致。
	文件操作方式	数据导入时的操作行为。全部数据从输入路径导入到目标路径时，先保存在临时目录，然后再从临时目录复制转移至目标路径，任务完成时删除临时路径的文件。转移临时文件存在同名文件时有以下行为： • “OVERRIDE”：直接覆盖旧文件。 • “RENAME”：重命名新文件。无扩展名的文件直接增加字符串后缀，有扩展名的文件在文件名增加字符串后缀。字符串具有唯一性。 • “APPEND”：在旧文件尾部合并新文件内容。合并操作只是简单的追加，不保证追加文件是否可以使用。例如文本文件可合并，压缩文件合并后可能无法使用。 • “IGNORE”：保留旧文件，不复制新文件。 • “ERROR”：转移过程中出现同名文件时任务将停止执行并报错，已转移的文件导入成功，同名的文件及未转移的文档导入失败。
	编码类型	导出文件的编码格式，如 UTF-8。导出文本文

连接类型	参数名	解释说明
		件时才能配置。
	压缩	使用 SFTP 协议导数据时，是否开启压缩传输功能以减小带宽使用。“true”为开启压缩，“false”为关闭压缩。
hdfs-connector	输出路径	导出文件在 HDFS/OBS 的输出目录或者文件名。
	文件格式	文件导出类型： • “TEXT_FILE”：导入文本文件并保存为文本文件。 • “SEQUENCE_FILE”：导入文本文件并保存在 sequence file 文件格式。 • “BINARY_FILE”：以二进制流的方式导入文件，可以导入任何格式的文件。
	压缩格式	在下拉菜单中选择数据导出到 HDFS/OBS 后保存文件的压缩格式，未配置或选择 NONE 表示不压缩数据。
	自定义压缩格式	自定义压缩格式类型的名称。
generic-jdbc-connector	架构名称	数据库模式名。
	表名	数据库表名，用于最终保存传输的数据。
	临时表	数据库临时表的表名，用于临时保存传输过程中的数据，字段需要和“表名”配置的表一致。
oracle-partition-connector	架构名称	数据库模式名。
	表名	数据库表名，用于最终保存传输的数据。
	临时表	数据库临时表的表名，用于临时保存传输过程中的数据，字段需要和“表名”配置的表一致。
oracle-connector	表名	目标表，用于存储数据。
	列名	指定要写入的列名，没有指定的列允许被设置为空值或者默认值。
mysql-fastpath-connector	架构名称	数据库模式名。
	表名	数据库表名，用于最终保存传输的数据。
	临时表名	临时表名称，用于预存数据，作业执行成功后，再将数据转移到正式表。

步骤 7 已创建的作业可以在“Loader WebUI”界面上进行浏览，可进行启动、停止、复制、删除、编辑和查看历史信息操作。

图17-47 查看 Loader 作业

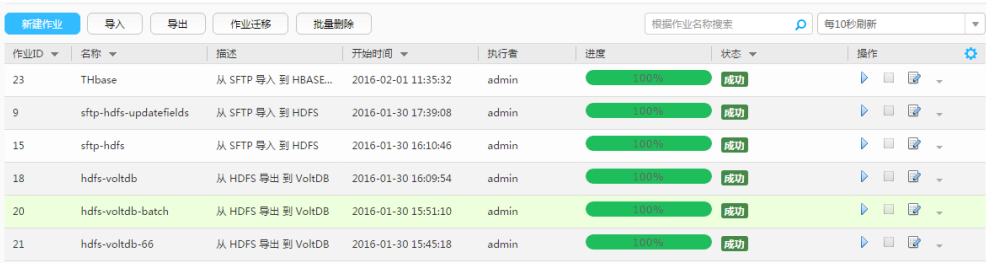

----结束

17.6.3 典型场景：从 HDFS/OBS 导出数据到 SFTP 服务器

操作场景

该任务指导用户使用 Loader 将数据从 HDFS/OBS 导出到 SFTP 服务器。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HDFS/OBS 目录和数据。
- 获取 SFTP 服务器使用的用户和密码，且该用户具备 SFTP 服务器数据导出目录的写入权限。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 使用 Loader 从 HDFS/OBS 导出数据时，确保 HDFS/OBS 数据源的输入路径目录名、输入路径的子目录名及子文件名不能包含特殊字符/\'":;,中的任意字符。
- 如果设置的任务需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-48 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-49 基本信息界面

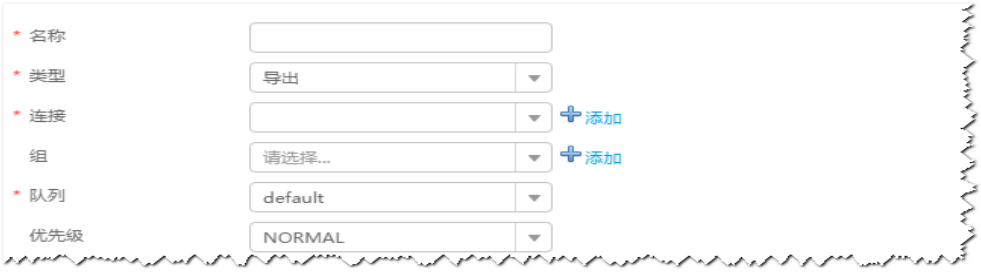

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导出”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“sftp-connector”，单击“添加”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。Loader 支持配置多个 SFTP 服务器操作数据，单击“添加”可增加多行 SFTP 服务器的配置信息。

表17-56 连接参数

参数名	说明	示例
名称	SFTP 服务器连接的名称。	sftpName
Sftp 服务器的 IP	SFTP 服务器的 IP 地址。	10.16.0.1
Sftp 服务器端口	SFTP 服务器的端口号。	22
Sftp 用户名	访问 SFTP 服务器的用户名。	root
Sftp 密码	访问 SFTP 服务器的密码。	xxxx

参数名	说明	示例
Sftp 公钥	Sftp 服务器公钥。	OdDt/yn...etM

说明

配置多个 SFTP 服务器时，HDFS/OBS 的数据将分为多份随机导出到各个 SFTP 服务器。

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，在“源文件类型”中选择“HDFS”，设置数据源信息。

表17-57 数据来源配置参数

参数名	解释说明	示例
输入目录	从 HDFS/OBS 导出时的输入路径。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/user/test
路径过滤器	配置通配符对源文件的输入路径包含的目录进行过滤。“输入目录”不参与过滤。配置多个过滤条件时使用“,”隔开，配置为空时表示不过滤目录。不支持正则表达式过滤。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。	*
文件过滤器	配置通配符对源文件的输入文件名进行过滤。配置多个过滤条件时使用“,”隔开。不能配置为空。不支持正则表达式过滤。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。	*
文件类型	文件导入类型： • “TEXT_FILE”：导入文本文件并保存为文本文件 • “SEQUENCE_FILE”：导入文本文件并保存在“sequence file”文件格式 • “BINARY_FILE”：以二进制流的方式导入文件，可以导入任何格式的文件，不对文件做任何处理。 说明 文件类型选择“TEXT_FILE”或“SEQUENCE_FILE”导入时，Loader 会自动根据文件的后缀选择对应的解压方法，对文	TEXT_FILE

参数名	解释说明	示例
	件进行解压。	
文件分割方式	选择按文件或大小分割源文件，作为数据导出的 MapReduce 任务中各个 map 的输入文件。 • 选择“FILE”，表示按文件分割源文件，即每个 map 处理一个或多个完整的源文件，同一个源文件不可分配至不同 map，完成数据导入后保持源文件的目录结构。 • 选择“SIZE”，表示按大小分割源文件，即每个 map 处理一定大小的输入文件，同一个源文件可分割至多个 map，数据保存至输出目录时保存的文件数与 map 数量相同，文件名格式为“import_part_xxxx”，“xxxx”为系统生成的随机数，具有唯一性。	FILE
Map 数	配置数据操作的 MapReduce 任务中同时启动的 Map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于 3000，建议以 SFTP 服务器的 CPU 的核数作为其取值。 **说明** 为了提高导入数据速度，需要确保以下条件： • 每个 Map 连接时，相当于一个客户端连接，因此需要确保 SFTP 服务器最大连接数大于 Map 数量。 • 确保 SFTP 服务器上的磁盘 IO 或网络带宽都未达到上限。	20
Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于 100，建议配置值为 1000。不可与“Map 数”同时配置。	-

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-58。

表17-58 算子输入、输出参数设置

输入类型	输出类型
CSV 文件输入	文件输出
HTML 输入	文件输出
固定宽度文件输入	文件输出

图17-50 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，设置数据保存方式。

表17-59 输出设置参数

参数名	解释说明	示例
输出路径	SFTP 服务器中导出文件的路径或者文件名，如果连接器配置多个地址此处可对应使用“;”分隔多个路径或者文件名，数量需要与连接器中服务器的数量一致。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/opt/tempfile
文件操作方式	数据导入时的操作行为。全部数据从输入路径导入到目标路径时，先保存在临时目录，然后再从临时目录复制转移至目标路径，任务完成时删除临时路径的文件。转移临时文件存在同名文件时有以下行为： • “OVERRIDE”：直接覆盖旧文件。 • “RENAME”：重命名新文件。无扩展名的文件直接增加字符串后缀，有扩展名的文件在文件名增加字符串后缀。字符串具有唯一性。 • “APPEND”：在旧文件尾部合并新文件内容。合并操作只是简单的追加，不保证追加文件是否可以使用。例如文本文件可合并，压缩文件合并后可能无法使用。 • “IGNORE”：保留旧文件，不复制新文件。 • “ERROR”：转移过程中出现同名文件时任务将停止执行并报错，已转移的文件导入成功，同名的文	OVERRIDE

参数名	解释说明	示例
	件及未转移的文档导入失败。	
编码类型	导出文件的编码格式，如 UTF-8。导出文本文件时才能配置。	UTF-8
压缩	使用 SFTP 协议导入数据时，是否开启压缩传输功能以减小带宽使用。 • 选择“true”，表示开启压缩。 • 选择“false”，表示关闭压缩。	true

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-51 查看作业

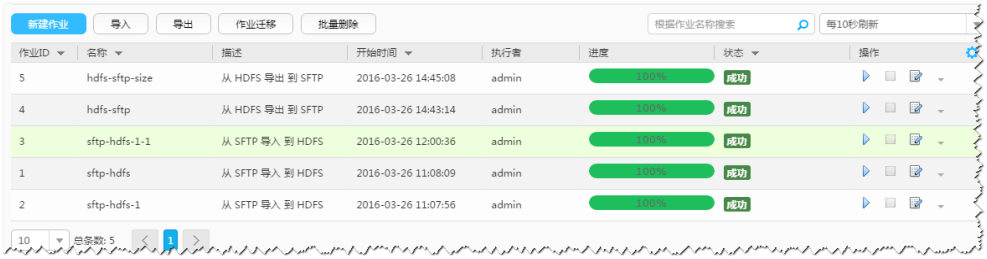

----结束

17.6.4 典型场景：从 HBase 导出数据到 SFTP 服务器

操作场景

该任务指导用户使用 Loader 将数据从 HBase 导出到 SFTP 服务器。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HBase 表或 phoenix 表。
- 获取 SFTP 服务器使用的用户和密码，且该用户具备 SFTP 服务器数据导出目录的写入权限。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 如果设置的任务需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。

- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-52 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-53 基本信息界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导出”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“sftp-connector”，单击“添加”，输入配置连接参数，单击“测试”验证连接是否可用，

待提示“测试成功”后单击“确定”。Loader 支持配置多个 SFTP 服务器操作数据，单击“添加”可增加多行 SFTP 服务器的配置信息。

表17-60 连接参数

参数名	说明	示例
名称	SFTP 服务器连接的名称。	sftpName
Sftp 服务器的 IP	SFTP 服务器的 IP 地址。	10.16.0.1
Sftp 服务器端口	SFTP 服务器的端口号。	22
Sftp 用户名	访问 SFTP 服务器的用户名。	root
Sftp 密码	访问 SFTP 服务器的密码。	xxxx
Sftp 公钥	Sftp 服务器公钥。	OdDt/yn...etM

说明

配置多个 SFTP 服务器时，HBase 表或 phoenix 表将分成多份随机保存到各个 SFTP 服务器。

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，在“源文件类型”中选择“HBASE”，设置数据源信息。

表17-61 数据源配置参数说明

参数名	解释说明	示例
HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。	HBase
个数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000，建议以 SFTP 服务器当前最大连接数作为其取值。	20

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-62。

表17-62 算子输入、输出参数设置

输入类型	输出类型
HBase 输入	文件输出

图17-54 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，设置数据保存方式。

表17-63 输出设置参数

参数名	解释说明	示例
输出路径	SFTP 服务器中导出文件的路径或者文件名，如果连接器配置多个地址此处可对应使用“;”分隔多个路径或者文件名，数量需要与连接器中服务器的数量一致。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/opt/tempfile
文件操作方式	数据导入时的操作行为。全部数据从输入路径导入到目标路径时，先保存在临时目录，然后再从临时目录复制转移至目标路径，任务完成时删除临时路径的文件。转移临时文件存在同名文件时有以下行为： • “OVERRIDE”：直接覆盖旧文件。 • “RENAME”：重命名新文件。无扩展名的文件直接增加字符串后缀，有扩展名的文件在文件名增加字符串后缀。字符串具有唯一性。 • “APPEND”：在旧文件尾部合并新文件内容。合并操作只是简单的追加，不保证追加文件是否可以使用。例如文本文件可合并，压缩文件合并后可能无法使用。	OVERRIDE

参数名	解释说明	示例
	• “IGNORE”：保留旧文件，不复制新文件。 • “ERROR”：转移过程中出现同名文件时任务将停止执行并报错，已转移的文件导入成功，同名的文件及未转移的文档导入失败。	
编码类型	导出文件的编码格式，如 UTF-8。导出文本文件时才能配置。	UTF-8
压缩	使用 SFTP 协议导入数据时，是否开启压缩传输功能以减小带宽使用。 • 选择“true”，表示开启压缩。 • 选择“false”，表示关闭压缩。	true

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-55 查看作业

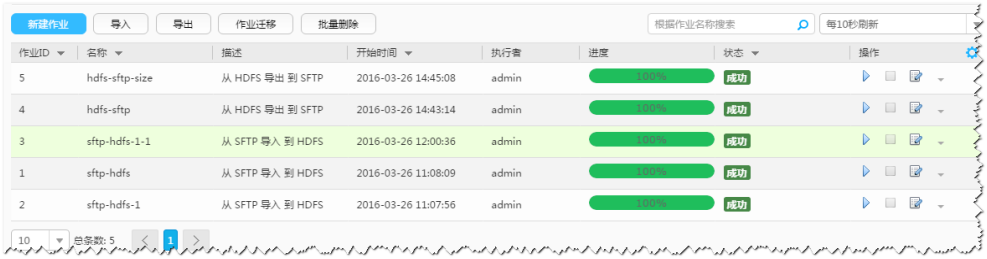

----结束

17.6.5 典型场景：从 Hive 导出数据到 SFTP 服务器

操作场景

该任务指导用户使用 Loader 将数据从 Hive 导出到 SFTP 服务器。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业中指定的 Hive 表的权限。
- 获取 SFTP 服务器使用的用户和密码，且该用户具备 SFTP 服务器数据导出目录的写入权限。

- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 如果设置的任务需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-56 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-57 基本信息界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导出”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“sftp-connector”，单击“添加”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。Loader 支持配置多个 SFTP 服务器操作数据，单击“添加”可增加多行 SFTP 服务器的配置信息。

表17-64 连接参数

参数名	说明	示例
名称	SFTP 服务器连接的名称。	sftpName
Sftp 服务器的 IP	SFTP 服务器的 IP 地址。	10.16.0.1
Sftp 服务器端口	SFTP 服务器的端口号。	22
Sftp 用户名	访问 SFTP 服务器的用户名。	root
Sftp 密码	访问 SFTP 服务器的密码。	xxxx
Sftp 公钥	Sftp 服务器公钥。	OdDt/yn...etM

说明

配置多个 SFTP 服务器时，Hive 表将分成多份随机保存到各个 SFTP 服务器。

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，在“源文件类型”中选择“HIVE”，设置数据源信息。

表17-65 数据源配置参数说明

参数名	解释说明	示例
Hive 实例	在 Hive 作业中，Loader 支持从集群可添加的所有 Hive 服务实例中选择任意一个。如果选定的 Hive 服务实例在集群中未添加，则此作业无法正常运行。	hive
个数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000，建议以 SFTP 服务器当前最大连接数作为其取值。	20

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-66。

表17-66 算子输入、输出参数设置

输入类型	输出类型

输入类型	输出类型
Hive 输入	文件输出

图17-58 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，设置数据保存方式。

表17-67 输出设置参数

参数名	解释说明	示例
输出路径	SFTP 服务器中导出文件的路径或者文件名，如果连接器配置多个地址此处可对应使用“;”分隔多个路径或者文件名，数量需要与连接器中服务器的数量一致。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/opt/tempfile
文件操作方式	数据导入时的操作行为。全部数据从输入路径导入到目标路径时，先保存在临时目录，然后再从临时目录复制转移至目标路径，任务完成时删除临时路径的文件。转移临时文件存在同名文件时有以下行为： • “OVERRIDE”：直接覆盖旧文件。 • “RENAME”：重命名新文件。无扩展名的文件直接增加字符串后缀，有扩展名的文件在文件名增加字符串后缀。字符串具有唯一性。	OVERRIDE

参数名	解释说明	示例
	• “APPEND”：在旧文件尾部合并新文件内容。合并操作只是简单的追加，不保证追加文件是否可以使用。例如文本文件可合并，压缩文件合并后可能无法使用。 • “IGNORE”：保留旧文件，不复制新文件。 • “ERROR”：转移过程中出现同名文件时任务将停止执行并报错，已转移的文件导入成功，同名的文件及未转移的文档导入失败。	
编码类型	导出文件的编码格式，如 UTF-8。导出文本文件时才能配置。	UTF-8
压缩	使用 SFTP 协议导入数据时，是否开启压缩传输功能以减小带宽使用。 • 选择“true”，表示开启压缩。 • 选择“false”，表示关闭压缩。	true

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-59 查看作业

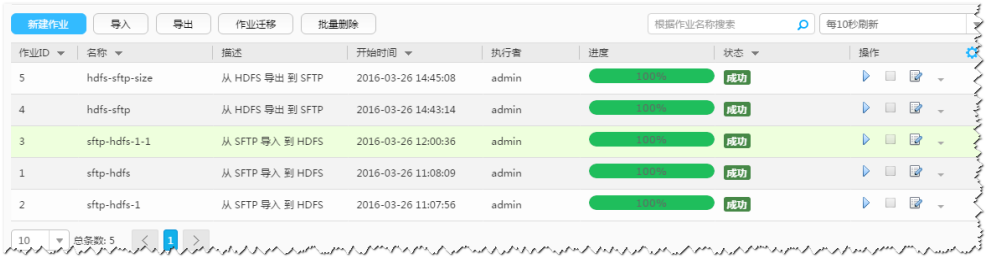

----结束

17.6.6 典型场景：从 HDFS/OBS 导出数据到关系型数据库

操作场景

该任务指导用户使用 Loader 将数据从 HDFS/OBS 导出到关系型数据库。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。

- 确保用户已授权访问作业执行时操作的 HDFS/OBS 目录和数据。
- 获取关系型数据库使用的用户和密码。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。
- 操作前需要进行如下配置：
  a. 获取关系型数据库对应的驱动 jar 包保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。
  b. 使用 root 用户在主备节点分别执行以下命令修改权限：

     cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

     chown omm:wheel *jar 包文件名*

     chmod 600 *jar 包文件名*

  c. 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”，输入管理员密码重启 Loader 服务。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-60 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-61 基本信息界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导出”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“generic-jdbc-connector”或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

说明

- 与关系数据库连接时，可以选择通用数据库连接器（generic-jdbc-connector）或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），专用数据库连接器特别针对具体数据库类型进行优化，相对通用数据库连接器来说，导出、导入速度更快。
- 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。

表17-68“generic-jdbc-connector”连接参数

参数名	说明	示例
名称	关系型数据库连接的名称。	dbName
JDBC 驱动程序类	JDBC 驱动类名。	oracle.jdbc.driver.OracleDriver
JDBC 连接字符串	JDBC 连接字符串。	jdbc:oracle:thin:@//10.16.0.1:1521/oradb
用户名	连接数据库使用的用户名。	omm
密码	连接数据库使用的密码。	xxxx
JDBC 连接属性	JDBC 连接属性，单击“添	• 名称：socketTimeout

参数名	说明	示例
	加”手动添加。 • 名称：连接属性名 • 值：连接属性值	• 值：20

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，在“源文件类型”中选择“HDFS”，设置数据源信息。

表17-69 数据来源配置参数

参数名	解释说明	示例
输入目录	从 HDFS/OBS 导出时的输入路径。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/user/test
路径过滤器	配置通配符对源文件的输入路径包含的目录进行过滤。“输入目录”不参与过滤。配置多个过滤条件时使用“,”隔开，配置为空时表示不过滤目录。不支持正则表达式过滤。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。	*
文件过滤器	配置通配符对源文件的输入文件名进行过滤。配置多个过滤条件时使用“,”隔开。不能配置为空。不支持正则表达式过滤。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。	*
文件类型	文件导入类型： • “TEXT_FILE”：导入文本文件并保存为文本文件。 • “SEQUENCE_FILE”：导入文本文件并保存在 sequence file 文件格式。 • “BINARY_FILE”：以二进制流的方式导入文件，可以导入任何格式的文件，不对文件做任何处理。 说明 文件类型选择“TEXT_FILE”或“SEQUENCE_FILE”导入时，Loader 会自动根据文件的后缀选择对应的解压方法，对文件进行解压。	TEXT_FILE

参数名	解释说明	示例
文件分割方式	选择按文件或大小分割源文件，作为数据导出的 MapReduce 任务中各个 map 的输入文件。 • 选择“FILE”，表示按文件分割源文件，即每个 map 处理一个或多个完整的源文件，同一个源文件不可分配至不同 map，完成数据导入后保持源文件的目录结构。 • 选择“SIZE”，表示按大小分割源文件，即每个 map 处理一定大小的输入文件，同一个源文件可分割至多个 map，数据保存至输出目录时保存的文件数与 map 数量相同，文件名格式为“import_part_xxxx”，“xxxx”为系统生成的随机数，具有唯一性。	FILE
Map 数	配置数据操作的 MapReduce 任务中同时启动的 Map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于 3000。	20
Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于 100，建议配置值为 1000。不可与“Map 数”同时配置。当使用关系型数据库连接器时，不支持“Map 数据块大小”，请配置“Map 数”。	-

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-70。

表17-70 算子输入、输出参数设置

输入类型	输出类型
CSV 文件输入	表输出
HTML 输入	表输出
固定宽度文件输入	表输出

图17-62 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，设置数据保存方式。

表17-71 输出设置参数

参数名	说明	示例
架构名称	数据库模式名。	dbo
表名	数据库表名，用于最终保存传输的数据。 **说明** 表名可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	test
临时表	数据库临时表表名，用于临时保存传输过程中的数据，字段需要和“表名”配置的表一致。 **说明** 使用临时表是为了使得导出数据到数据库时，不会在目的表中产生脏数据。只有在所有数据成功写入临时表后，才会将数据从临时表迁移到目的表。使用临时表会增加作业的执行时间。	tmp_test

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-63 查看作业

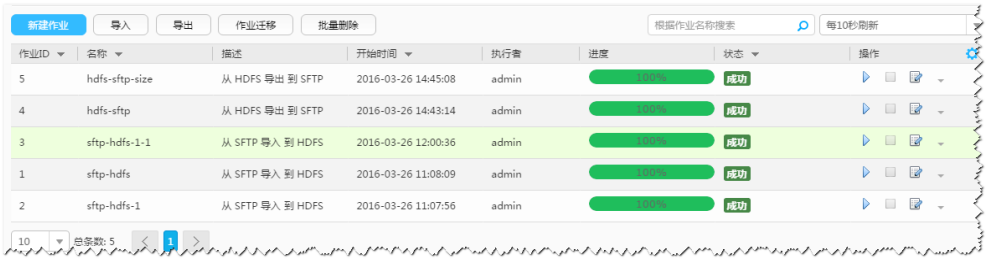

----结束

17.6.7 典型场景：从 HDFS 导出数据到 MOTService

操作场景

本章节适用于 MRS 3.3.0 及之后版本。

在 MOTService 中需要根据表中数据版本字段对表进行更新操作，MOTService 外部表不支持 Upsert 语句，您可以使用 Loader 将文件从 HDFS 导出到 MOTService 从而批量更新数据。

前提条件

- 获取关系型数据库使用的用户和密码。
- 输入的数据需为 CSV 格式文件。
- 在 FusionInsight Manager 中创建一个人机用户，例如“Loaderuser”，加入用户组 hive、hadoop，主组选择“hadoop”组，关联角色“Manager_administrator”。

操作步骤

准备操作

使用 **root** 用户登录 RTDServer 所在节点，获取关系型数据库对应的驱动 Jar 包，本场景需要获取“opengaussjdbc-V500R002C00.jar”。

cd ${BIGDATA_HOME}/FusionInsight_FARMER_RTD_*/install/FusionInsight-RTD-*/RTD/rtdservice/WEB-INF/lib

步骤 1 将步骤 1 获取到的 Jar 包保存在 Loader 服务主备节点的 lib 路径“${BIGDATA_HOME}/FusionInsight_Porter_*/install/FusionInsight-Sqoop-*/FusionInsight-Sqoop-*/server/webapps/loader/WEB-INF/ext-lib”。

步骤 2 使用 **root** 用户在主备节点分别执行以下命令修改 Jar 包权限：

cd ${BIGDATA_HOME}/FusionInsight_Porter_*/install/FusionInsight-Sqoop-*/FusionInsight-Sqoop-*/server/webapps/loader/WEB-INF/ext-lib

chown omm:wheel *jar 包文件名*

chmod 600 *jar 包文件名*

步骤 3 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”，输入管理员密码重启 Loader 服务。

步骤 4 需要提前在 MOTService 中创建版本管控表并在表中增加特定字段用于版本管控，如果存在则不需要创建。所有 MOT 类型（全量或增量）作业共用一张表，参考命令如下：

CREATE TABLE T_RTD_TBL_CUR_VER_INFO (

TBL_NAME varchar NOT NULL,

CUR_VER_FLAG tinyint DEFAULT '0' NOT NULL,

CONSTRAINT PK_T_RTD_TBL_CUR_VER_INFO PRIMARY KEY (TBL_NAME)

);

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-64 Loader WebUI 界面

步骤 5 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-65 “基本信息”界面

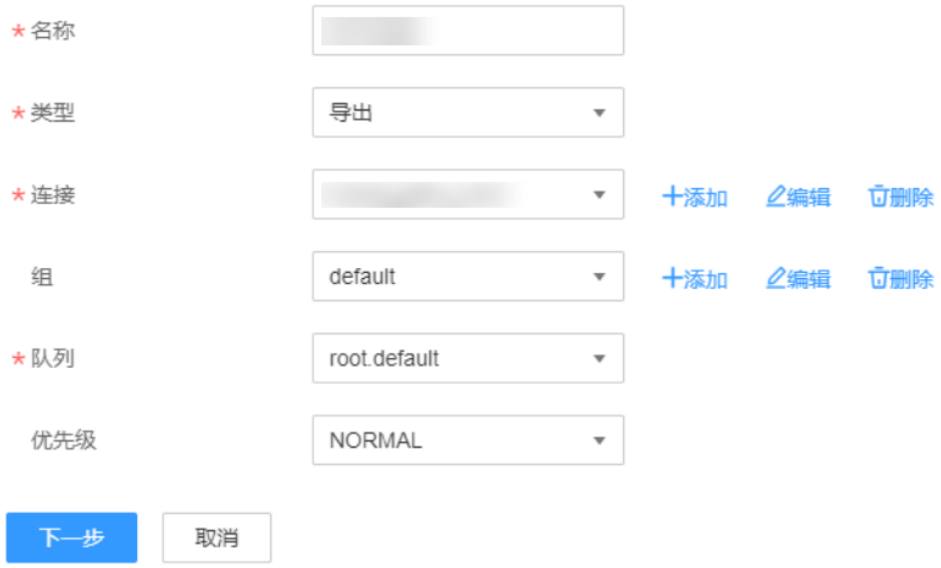

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导出”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 6 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“generic-jdbc-connector”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

表17-72“generic-jdbc-connector”连接参数

参数名	说明	示例
名称	关系型数据库连接的名称。	dbName
JDBC 驱动程序类	JDBC 驱动类名。	com.xxx.opengauss.jdbc.Driver
JDBC 连接字符串	JDBC 连接字符串，格式为： jdbc:opengauss://*数据库访问地址*:*数据库访问端口号*/*数据库名称*	jdbc:opengauss://10.10.10.10:15400/test
用户名	连接数据库使用的用户名。	omm
密码	连接数据库使用的密码。	xxxx

参数名	说明	示例
JDBC 连接属性	JDBC 连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值	• 名称：socketTimeout • 值：20 说明 登录 FusionInsight Manager，选择“集群 > 服务 > MOTService > 配置 > 全部配置”，搜索参数“REQUIRE_SSL”如果参数值为“true”，此时需要添加名称为“ssl.enable”，值为“true”的 JDBC 连接属性，否则不需要添加此连接属性。

设置数据源信息

单击“下一步”，进入“输入设置”界面，在“源文件类型”中选择“HDFS”，设置数据源信息。

表17-73 数据来源配置参数

参数名	解释说明	示例
输入目录	从 HDFS 导出时的输入路径。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/user/test
路径过滤器	配置通配符对源文件的输入路径包含的目录进行过滤。“输入目录”不参与过滤。配置多个过滤条件时使用“,”隔开，配置为空时表示不过滤目录。不支持正则表达式过滤。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。	*
文件过滤器	配置通配符对源文件的输入文件名进行过滤。配	*

参数名	解释说明	示例
	置多个过滤条件时使用“,”隔开。不能配置为空。不支持正则表达式过滤。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。	
文件类型	文件导入类型： • “TEXT_FILE”：导入文本文件并保存为文本文件。 • “SEQUENCE_FILE”：导入文本文件并保存为 sequence file 文件格式。 • “BINARY_FILE”：以二进制流的方式导入文件，可以导入任何格式的文件，不对文件做任何处理。 **说明** 文件类型选择“TEXT_FILE”或“SEQUENCE_FILE”导入时，Loader 会自动根据文件的后缀选择对应的解压方法，对文件进行解压。	TEXT_FILE
文件分割方式	选择按文件或大小分割源文件，作为数据导出的 MapReduce 任务中各个 map 的输入文件。 • 选择“FILE”，表示按文件分割源文件，即每个 map 处理一个或多个完整的源文件，同一个源文件不可分配至不同 map，完成数据导入后保持源文件的目录结构。 • 选择“SIZE”，表示按大小分割源文件，即每个 map 处理一定大小的输入文件，同一个源文件可分割至多个 map，数据保存至输出目录时保存的文件数与 map 数量相同，文件名格式为“import_part_xxxx”，“xxxx”为系统生成的随机数，具有唯一性。	FILE
Map 数	配置数据操作的 MapReduce 任务中同时启动的 Map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于 3000。	20
Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于 100，建议配置值为 1000。不可与“Map 数”同时配置。当使用关系型数据库连接器时，不支持“Map 数据块大小”，请配置“Map 数”。	-

设置数据转换

单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-74。

表17-74 算子输入、输出参数设置

输入类型	输出类型
CSV 文件输入	表输出

在“输入”中把“CSV 文件输入”拖拽到网格中，在“输出”中把“表输出”拖拽到网格中，“输入”与“输出”之间用箭头进行连接。

设置数据保存信息并运行作业

单击“下一步”，进入“输出设置”界面参考下表填写参数。

表17-75 输出设置参数

参数名	说明	示例
架构名称	数据库模式名。	dbo
表名	数据库表名，用于最终保存传输的数据。	test
临时表名	数据库临时表名用于临时保存传输过程中的数据，字段需要和“表名”配置的表一致。	db_test
数据库类型	数据库类型，分为 MOT 和其他可用 JDBC 连接的数据库。	MOT
MOT 导入方式	“数据库类型”选择“MOT”时存在，根据业务需要选择相应导入方式。 说明 • 数据导入数据库的方式，有全量导入，增量导入，普通导入三种。 TOTAL：全量导入，数据版本默认为 0，新写入数据版本为 1，新数据入库时更新相同主键的数据，插入不同主键的数据并删除版本为 0 的所有原有数据。下一次新写入数据版本为 0，依次交替更新数据版本。 INCREMENT：增量导入，更新相同主键的数据，插入不同主键的数据，保留原有数据。 INSERT：普通导入，插入数据，主键重复会导致任务失败。 • 在使用全量导入或增量导入方式时，需确保业务数据表有字段“CUR_VER_FLAG”用于版本管控，例如： **CREATE TABLE F_ACCOUNT1 (** **ORG_NBR smallint NOT NULL,** **ACT_NBR varchar NOT NULL,**	TOTAL

参数名	说明	示例
	CLT_NBR varchar NOT NULL, **BRF_NAM varchar,** **CUR_VER_FLAG tinyint DEFAULT '0' NOT NULL,** **CONSTRAINT IDX_F_ACCOUNT1_PKEY PRIMARY KEY (CLT_NBR,ORG_NBR)** **);**	

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

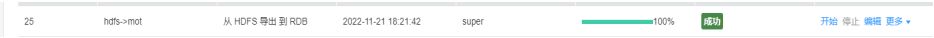

----结束

17.6.8 典型场景：从 HBase 导出数据到关系型数据库

操作场景

该任务指导用户使用 Loader 将数据从 HBase 导出到关系型数据库。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HBase 表或 phoenix 表。
- 获取关系型数据库使用的用户和密码。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。
- 操作前需要进行如下配置：
  a. 获取关系型数据库对应的驱动 jar 包保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。
  b. 使用 root 用户在主备节点分别执行以下命令修改权限：

  cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

  chown omm:wheel *jar 包文件名*

  chmod 600 *jar 包文件名*

c. 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”，输入管理员密码重启 Loader 服务。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-66 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-67 基本信息界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导出”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“generic-jdbc-connector”或者专用数据库连接器（oracle-connector、oracle-partition-connector、

mysql-fastpath-connector），输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

说明

- 与关系数据库连接时，可以选择通用数据库连接器（generic-jdbc-connector）或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），专用数据库连接器特别针对具体数据库类型进行优化，相对通用数据库连接器来说，导出、导入速度更快。
- 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。

表17-76“generic-jdbc-connector”连接参数

参数名	说明	示例
名称	关系型数据库连接的名称。	dbName
JDBC 驱动程序类	JDBC 驱动类名。	oracle.jdbc.driver.OracleDriver
JDBC 连接字符串	JDBC 连接字符串。	jdbc:oracle:thin:@//10.16.0.1:1521/oradb
用户名	连接数据库使用的用户名。	omm
密码	连接数据库使用的密码。	xxxx
JDBC 连接属性	JDBC 连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值	• 名称：socketTimeout • 值：20

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，在“源文件类型”中选择“HBASE”，设置数据源信息。

表17-77 数据源配置参数说明

参数名	解释说明	示例
HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。	HBase
个数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于“3000”。	20

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-78。

表17-78 算子输入、输出参数设置

输入类型	输出类型
HBase 输入	表输出

图17-68 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，设置数据保存方式。

表17-79 输出设置参数

参数名	说明	示例
架构名称	数据库模式名。	dbo
表名	数据库表名，用于最终保存传输的数据。 说明 表名可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	test
临时表	数据库临时表表名，用于临时保存传输过程中的数据，字段需要和“表名”配置的表一致。 说明	tmp_test

参数名	说明	示例
	使用临时表是为了使得导出数据到数据库时，不会在目的表中产生脏数据。只有在所有数据成功写入临时表后，才会将数据从临时表迁移到目的表。使用临时表会增加作业的执行时间。	

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-69 查看作业

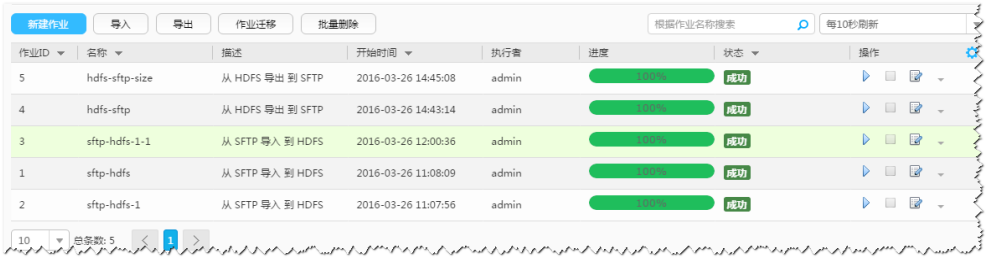

----结束

17.6.9 典型场景：从 Hive 导出数据到关系型数据库

操作场景

该任务指导用户使用 Loader 将数据从 Hive 导出到关系型数据库。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 Hive 表。
- 获取关系型数据库使用的用户和密码。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。
- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。
- 操作前需要进行如下配置：
  a. 获取关系型数据库对应的驱动 jar 包保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。

b. 使用 root 用户在主备节点分别执行以下命令修改权限：

cd ${BIGDATA_HOME}/FusionInsight_Porter_*xxx*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

chown omm:wheel *jar 包文件名*

chmod 600 *jar 包文件名*

c. 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”，输入管理员密码重启 Loader 服务。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-70 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-71 基本信息界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导出”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。

5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“generic-jdbc-connector”或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

说明

- 与关系数据库连接时，可以选择通用数据库连接器（generic-jdbc-connector）或者专用数据库连接器（oracle-connector、oracle-partition-connector、mysql-fastpath-connector），专用数据库连接器特别针对具体数据库类型进行优化，相对通用数据库连接器来说，导出、导入速度更快。
- 使用 mysql-fastpath-connector 时，要求在 NodeManager 节点上有 MySQL 的 **mysqldump** 和 **mysqlimport** 命令，并且此两个命令所属 MySQL 客户端版本与 MySQL 服务器版本兼容，如果没有这两个命令或版本不兼容，请参考 http://dev.mysql.com/doc/refman/5.7/en/linux-installation-rpm.html，安装 MySQL client applications and tools。

表17-80“generic-jdbc-connector”连接参数

参数名	说明	示例
名称	关系型数据库连接的名称。	dbName
JDBC 驱动程序类	JDBC 驱动类名。	oracle.jdbc.driver.OracleDriver
JDBC 连接字符串	JDBC 连接字符串。	jdbc:oracle:thin:@//10.16.0.1:1521/oradb
用户名	连接数据库使用的用户名。	omm
密码	连接数据库使用的密码。	xxxx
JDBC 连接属性	JDBC 连接属性，单击“添加”手动添加。 • 名称：连接属性名 • 值：连接属性值	• 名称：socketTimeout • 值：20

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，在“源文件类型”中选择“HIVE”，设置数据源信息。

表17-81 数据源配置参数说明

参数名	解释说明	示例
Hive 实例	在 Hive 作业中，Loader 支持从集群可添加的所有 Hive 服务实例中选择任意一个。如果选定的 Hive 服务实例在	hive

参数名	解释说明	示例
	集群中未添加，则此作业无法正常运行。	
个数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于“3000”。	20

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-82。

表17-82 算子输入、输出参数设置

输入类型	输出类型
Hive 输入	表输出

图17-72 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，设置数据保存方式。

表17-83 输出设置参数

参数名	说明	示例
架构名称	数据库模式名。	dbo

参数名	说明	示例
表名	数据库表名，用于最终保存传输的数据。 说明 表名可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	test
临时表	数据库临时表表名，用于临时保存传输过程中的数据，字段需要和“表名”配置的表一致。 说明 使用临时表是为了使得导出数据到数据库时，不会在目的表中产生脏数据。只有在所有数据成功写入临时表后，才会将数据从临时表迁移到目的表。使用临时表会增加作业的执行时间。	tmp_test

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-73 查看作业

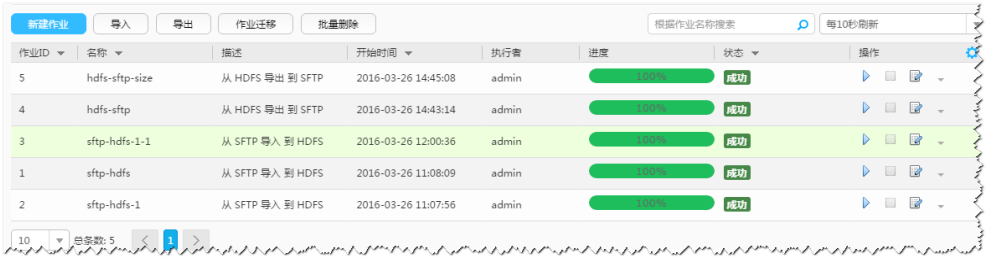

----结束

17.6.10 典型场景：从 HBase 导出数据到 HDFS/OBS

操作场景

该任务指导用户使用 Loader 将数据从 HBase 导出到 HDFS/OBS。

前提条件

- 创建或获取该任务中创建 Loader 作业的业务用户和密码。
- 确保用户已授权访问作业执行时操作的 HDFS/OBS 目录和数据。
- 确保用户已授权访问作业执行时操作的 HBase 表或 phoenix 表。
- 检查磁盘空间，确保没有出现告警且余量满足导入、导出数据的大小。

- 如果设置的作业需要使用指定 YARN 队列功能，该用户需要已授权有相关 YARN 队列的权限。
- 设置任务的用户需要获取该任务的执行权限，并获取该任务对应的连接的使用权限。

操作步骤

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-74 Loader WebUI 界面

步骤 2 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-75 基本信息界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导出”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 3 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“hdfs-connector”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”。

设置数据源信息

步骤 4 单击“下一步”，进入“输入设置”界面，在“源文件类型”中选择“HBASE”，设置数据源信息。

表17-84 输入设置参数

参数名	解释说明	示例
HBase 实例	在 HBase 作业中，Loader 支持从集群可添加的所有 HBase 服务实例中选择任意一个。如果选定的 HBase 服务实例在集群中未添加，则此作业无法正常运行。	HBase
个数	配置数据操作的 MapReduce 任务中同时启动的 map 数量。参数值必须小于或等于 3000。	20

设置数据转换

步骤 5 单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-85。

表17-85 算子输入、输出参数设置

输入类型	输出类型
HBase 输入	文件输出

图17-76 算子操作方法示意

设置数据保存信息并运行作业

步骤 6 单击“下一步”，进入“输出设置”界面，设置数据保存方式。

表17-86 输出设置参数

参数名	解释说明	示例
输出路径	导出文件在 HDFS/OBS 的输出目录或者文件名。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/user/test
文件格式	文件导出类型： • “TEXT_FILE”：导入文本文件并保存为文本文件。 • “SEQUENCE_FILE”：导入文本文件并保存在“sequence file”文件格式。 • “BINARY_FILE”：以二进制流的方式导入文件，可以导入任何格式的文件。	TEXT_FILE
压缩格式	在下拉菜单中选择数据导出到 HDFS/OBS 后保存文件的压缩格式，未配置或选择“NONE”表示不压缩数据。	NONE

步骤 7 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

步骤 8 进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-77 查看作业

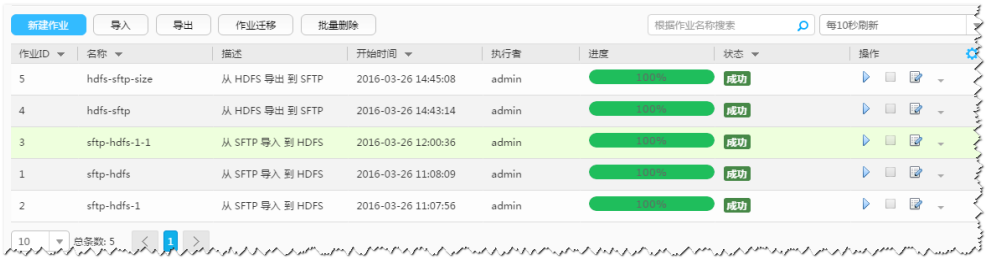

----结束

17.6.11 典型场景：从 HDFS 导出数据到 ClickHouse

本章节适用于 MRS 3.3.0 及以后版本。

操作场景

该任务指导用户使用 Loader 将文件从 HDFS 导出到 ClickHouse。

前提条件

- 在 FusionInsight Manager 创建一个角色，添加 ClickHouse 逻辑集群的管理权限以及 Loader 作业分组权限。创建 Loader 作业的业务用户，关联该角色和并添加用户组 **yarnviewgroup**。
- ClickHouse 表已创建，确保用户已授权访问作业执行时操作该表的权限，参照 3.6 ClickHouse 表创建创建本地复制表和分布式表，导出时选择本地复制表。
- 确保没有出现 ClickHouse 相关告警。

操作步骤

准备操作

在 ClickHouse 的安装目录获取 clickhouse-jdbc-*.jar 包，将其保存在 Loader 服务主备节点的 lib 路径：“${BIGDATA_HOME}/FusionInsight_Porter_*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib”。

步骤 1 使用 root 用户在主备节点分别执行以下命令修改权限：

cd ${BIGDATA_HOME}/FusionInsight_Porter_*/install/FusionInsight-Sqoop-1.99.3/FusionInsight-Sqoop-1.99.3/server/webapps/loader/WEB-INF/ext-lib

chown omm:wheel *jar 包文件名*

chmod 600 *jar 包文件名*

步骤 2 登录 FusionInsight Manager 系统，选择“集群 > 服务 > Loader > 更多 > 重启服务”，输入管理员密码重启 Loader 服务。

设置作业基本信息

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-78 Loader WebUI 界面

步骤 3 单击“新建作业”，进入“基本信息”界面，创建作业基本信息。

图17-79 “基本信息”界面

1. 在“名称”中输入作业的名称。
2. 在“类型”中选择“导出”。
3. 在“组”中设置作业所属组，默认没有已创建的组，单击“添加”创建一个新的组，输入组的名称，单击“确定”保存。
4. 在“队列”中选择执行该作业的 YARN 队列。默认值“root.default”。
5. 在“优先级”中选择执行该作业的 YARN 队列优先级。默认值为“NORMAL”。可选值为“VERY_LOW”、“LOW”、“NORMAL”、“HIGH”和“VERY_HIGH”。

步骤 4 在“连接”区域，单击“添加”新建一个的连接，在“连接器”中选择“clickhouse-connector”，输入配置连接参数，单击“测试”验证连接是否可用，待提示“测试成功”后单击“确定”，参数设置请参考表 17-87。

表17-87“clickhouse-connector”连接参数

参数名	说明	示例
名称	关系型数据库连接的名称。	clickhouse_jdbc_test
JDBC 连接字符串	• 集群已启用 Kerberos 认证，JDBC 连接字符串格式为“jdbc:clickhouse://*访问数据库 IP*:*数据库端口号*/*数据库名称*?ssl=true&sslmode=none” • 集群未启用 Kerberos 认证，JDBC 连接字符串格式为“jdbc:clickhouse://*访问数据库 IP*:*数据库端口号*/*数据库名称*” 说明 • 访问数据库 IP：ClickHouse 的实例 IP 地址可登录集群 FusionInsight Manager，然后选择“集群 > 服务 > ClickHouse > 实例”，获取 ClickHouseBalancer 实例对应的业务 IP 地址。 • 数据库端口： • 已启用 Kerberos 认证集群具体的端口值可通过登录集群 FusionInsight Manager，选择“集群 > 服务 > ClickHouse >逻辑集群”，查看对应逻辑集群，获取“HTTP Balancer 端口号”中“加密端口”参数值。 • 未启用 Kerberos 认证集群具体的端口值可通过登录集群 FusionInsight Manager，选择“集群 > 服务 > ClickHouse >逻辑集群”，查看对应逻辑集群，获取“HTTP Balancer 端口号”中“非加密端口”参数值。	• 集群已启用 Kerberos 认证：jdbc:clickhouse://10.10.10.10:21426/test?ssl=true&sslmode=none • 集群未启用 Kerberos 认证：jdbc:clickhouse://10.10.10.10:21423/test?ssl=true&sslmode=none
用户名	连接数据库使用的用户名。	root
密码	连接数据库使用的密码。	xxxx

设置数据源信息

单击“下一步”，进入“输入设置”界面，在“源文件类型”选择“HDFS”，设置数据源信息。

表17-88 输入设置参数

参数名	解释说明	示例
输入目录	从 HDFS 导出时的输入路径。 说明 路径参数可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	/user/test
路径过滤器	配置通配符对源文件的输入路径包含的目录进行过滤。“输入目录”不参与过滤。配置多个过滤条件时使用“,”隔开，配置为空时表示不过滤目录。不支持正则表达式过滤。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。	*
文件过滤器	配置通配符对源文件的输入文件名进行过滤。配置多个过滤条件时使用“,”隔开。不能配置为空。不支持正则表达式过滤。 • “?”匹配单个字符。 • “*”配置多个字符。 • 在匹配条件前加“^”表示取反，即文件过滤。	*
文件类型	文件导入类型： • “TEXT_FILE”：导入文本文件并保存为文本文件。 • “SEQUENCE_FILE”：导入文本文件并保存为 sequence file 文件格式。 • “BINARY_FILE”：以二进制流的方式导入文件，可以导入任何格式的文件，不对文件做任何处理。 说明 文件类型选择“TEXT_FILE”或“SEQUENCE_FILE”导入时，Loader 会自动根据文件的后缀选择对应的解压方法，对文件进行解压。	TEXT_FILE
文件分割方式	选择按文件或大小分割源文件，作为数据导出的 MapReduce 任务中各个 map 的输入文件。 • 选择“FILE”，表示按文件分割源文件，即每个 map 处理一个或多个完整的源文件，同一个源文件不可分配至不同 map，完成数据导入后	FILE

参数名	解释说明	示例
	保持源文件的目录结构。 • 选择“SIZE”，表示按大小分割源文件，即每个 map 处理一定大小的输入文件，同一个源文件可分割至多个 map，数据保存至输出目录时保存的文件数与 map 数量相同，文件名格式为“import_part_xxxx”，“xxxx”为系统生成的随机数，具有唯一性。	
Map 数	配置数据操作的 MapReduce 任务中同时启动的 Map 数量。不可与“Map 数据块大小”同时配置。参数值必须小于或等于 3000。	20
Map 数据块大小	配置数据操作的 MapReduce 任务中启动 map 所处理的数据大小，单位为 MB。参数值必须大于或等于 100，建议配置值为 1000。不可与“Map 数”同时配置。当使用关系型数据库连接器时，不支持“Map 数据块大小”，请配置“Map 数”。	-

设置数据转换

单击“下一步”，进入“转换”界面，设置数据传输过程中的转换操作。算子的选择和参数设置具体请参考 17.8 算子帮助及表 17-89。

表17-89 算子输入、输出参数设置

输入类型	输出类型
CSV 输入	表输出

图17-80 算子选择

设置数据保存信息并运行作业

单击“下一步”，进入“输出设置”界面，设置数据保存方式。

表17-90 输出设置参数

参数名	解释说明	示例
表名	数据库表名，用于最终保存传输的数据。 **说明** 表名可以使用宏定义，具体请参考 17.8.6 配置项中使用宏定义。	test

步骤 5 单击“保存并运行”，开始保存并运行作业。

查看作业完成情况

进入“Loader WebUI”界面，待“状态”显示“成功”则说明作业完成。

图17-81 查看作业

步骤 6 使用 ClickHouse 客户端，查询 ClickHouse 表数据是否和 HDFS 导入的数据一致。

----结束

17.7 作业管理

17.7.1 批量迁移 Loader 作业

操作场景

Loader 支持将作业批量从一个分组（源分组）迁移到另一个分组（目标分组）。

前提条件

- 源分组和目标分组均存在。
- 当前用户具备源分组和目标分组的编辑“Group Edit”权限。
- 当前用户具备源分组的作业编辑“Jobs Edit”权限或待迁移作业的编辑“Edit”权限。

操作步骤

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-82 Loader WebUI 界面

步骤 2 单击“作业迁移”，进入作业迁移界面。

步骤 3 在“源分组”中选择待迁移作业当前所属分组，在“目标分组”中选择待迁移作业的目标分组。

步骤 4 在“选择迁移类型”中选择迁移类型。

- “所有”：将源分组所有作业迁移到目标分组。
- “指定作业”：将源分组中指定的作业迁移到目标分组。选择“指定作业”，在作业列表中勾选需要迁移的作业。

步骤 5 单击“确定”，开始作业迁移。当弹出框中进度条显示 100%，则说明作业迁移完成。

----结束

17.7.2 批量删除 Loader 作业

操作场景

Loader 支持批量删除已有作业。

前提条件

当前用户具备待删除作业的编辑“Edit”权限或作业所在分组的编辑“Jobs Edit”权限。

操作步骤

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-83 Loader WebUI 界面

步骤 2 单击“批量删除”，进入作业批量删除界面。

步骤 3 在“批量删除”中选择删除作业类型。

- “所有”，表示删除当前所有的作业。
- “指定作业”，表示指定需要删除的作业。选择“指定作业”，在作业列表中勾选需要删除的作业。

步骤 4 单击“确定”，开始删除作业。当弹出框中进度条显示 100%，则说明作业删除完成。

----结束

17.7.3 批量导入 Loader 作业

操作场景

Loader 支持批量导入某个配置文件中的所有作业。

前提条件

当前用户具备待导入作业所在分组的编辑“Jobs Edit”权限。

说明

如果作业所在的分组不存在，则会自动先创建该分组。当前用户就是该分组的创建者，拥有该分组的编辑“Jobs Edit”权限。

操作步骤

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-84 Loader WebUI 界面

步骤 2 单击“导入”，进入作业导出界面。

步骤 3 在“导入”界面中选择要导入的配置文件的路径。

步骤 4 单击“上传”，开始导入作业。当弹出框中进度条显示 100%，则说明作业导出完成。

----结束

17.7.4 批量导出 Loader 作业

操作场景

Loader 支持批量导出已有作业。

前提条件

当前用户具备待导出作业的编辑“Edit”权限或作业所在分组的编辑“Jobs Edit”权限。

操作步骤

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-85 Loader WebUI 界面

步骤 2 单击“导出”，进入作业导出界面。

步骤 3 在“选择导出类型”中选择删除作业类型。

- “所有”：表示导出当前所有的作业。
- “指定作业”：表示指定需要导出的作业。选择“指定作业”，在作业列表中勾选需要导出的作业。
- “指定组别”：表示导出某个指定分组中的所有作业。选择“指定分组”，在分组列表中勾选需要导出的作业分组。

“是否导出密码”：导出时是否导出连接器密码，勾选时，导出加密后的密码串。

步骤 4 单击“确定”，开始导出作业。当弹出框中进度条显示 100%，则说明作业导出完成。

----结束

17.7.5 查看作业历史信息

操作场景

该任务指导您在日常运维中，查看某个 Loader 作业的历史执行状态以及每次执行时长，同时提供该作业两种操作：

- 脏数据：查看作业执行过程中处理失败的数据、或者被清洗过滤掉的数据，针对该数据可以查看源数据中哪些数据不符合转换、清洗规则。
- 日志：查看作业在 MapReduce 执行的日志信息。

本章节适用于 MRS 3.x 及后续版本。

前提条件

获取登录“Loader WebUI”的账户和密码。

操作步骤

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-86 Loader WebUI 界面

步骤 2 查看 Loader 作业的历史记录。

1. 选择待查看的作业所在行。
2. 如图所示，选择“更多>历史记录”查看作业执行的历史记录。

图17-87 查看历史记录

表17-91 参数说明

名称	说明
行/文件 读取数	从输入源中读取的行数（文件数）。
行/文件 写入数	写入到输出源的行数（文件数）。
行/文件 跳过数	• 转换过程中记录的坏行数（文件数）：输入格式不正确，无法进行转换。

名称	说明
	• 转换过程中配置过滤条件后跳过的行数。

----结束

17.7.6 清理 Loader 历史数据

本章节适用于 MRS 3.2.0 及之后版本。

操作场景

在业务不断运行中，Loader 会积累大量的历史数据，这些历史数据可能会对作业提交、作业运行、作业状态获取等产生影响，严重时可能导致页面访问卡顿，作业运行失败等，所以需要根据具体 Loader 业务数据量，合理配置历史数据清理机制。

操作步骤

登录 FusionInsight Manager。

步骤 1 选择“集群 > 服务 > Loader > 配置 > 全部配置 > LoaderServer（角色） > 清除”出现如下图所示配置项，可参考表 17-92 调整以下参数配置。

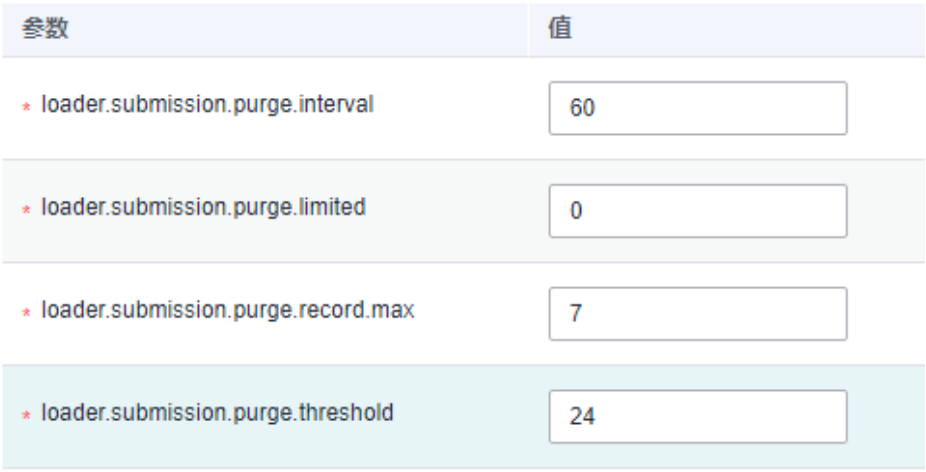

表17-92 清除 Loader 历史数据参数

参数名称	描述	推荐修改值
loader.submission.purge.interval	清理任务被调用的时间间隔（分钟）。	60
loader.submission.purge.limited	清除时保持的提交数，可以避免作业历史记录被清理干净。	0

参数名称	描述	推荐修改值
loader.submission.purge.record.max	Loader 作业最大可保留的记录数（条），0 表示不限制。	7
loader.submission.purge.threshold	历史记录可以保存的时间（小时）。	24

步骤 2 配置完成后，单击“保存”。

步骤 3 单击“概览”进入 Loader 服务概览界面，选择“更多 > 重启服务”，验证用户身份后，单击“确定”，等待重启成功。

----结束

17.8 算子帮助

17.8.1 概述

转换流程

Loader 读取源端数据，通过输入算子将数据按规则逐一转换成字段，再通过转换算子，对这些字段做清洗或转换，最后通过输出算子将处理后的字段，输出到目标端。

- 每个作业，如果进行数据转换操作，有且只能有一个输入算子，有且只能有一个输出算子。
- 不符合转换规则的数据，将成为脏数据跳过。

说明

- 从关系型数据库导入数据到 HDFS/OBS，可以不用配置数据转换，数据将按“,”分隔保存到 HDFS/OBS。
- 从 HDFS/OBS 导出数据到关系型数据库，可以不用配置数据转换，数据将按“,”分隔保存到关系型数据库。

算子简介

Loader 算子包括以下类型：

- 输入算子

  数据转换的第一步，负责将数据转换成字段，每次转换有且只能有一种输入算子，涉及 HBase 或 Hive 导入导出时，必须填写。
- 转换算子

  数据转换的中间转换步骤，属于可选类型，各个转换算子可任意搭配使用。转换算子是针对字段而言，必须先使用输入算子，将数据转换成字段。
- 输出算子

数据转换的最后一步，每次转换有且只能有一种输出算子，用于输出处理后的字段。涉及 HBase 或 Hive 导入导出时，必须填写。

表17-93 算子分类一览表

类型	描述
输入	• CSV 文件输入：将文件的每一行按指定分隔符转换成多个输入字段。 • 固定宽度文件输入：将文件的每一行，按可配置长度的字符或字节，转换成多个输入字段。 • 表输入：将关系型数据库表的指定列按顺序转换成同等数量的输入字段。 • HBase 输入：将 HBase 表的指定列转换成同等数量的输入字段。 • HTML 输入：将 HTML 文件中的元素转换成输入字段。 • Hive 输入：将 Hive 表的指定列转换成同等数量的输入字段。
转换	• 长整型时间转换：实现长整型数值与日期类型的互换。 • 空值转换：将空值替换成指定值。 • 增加常量字段：生成常量字段。 • 随机值转换：生成随机数字段。 • 拼接转换：拼接已有字段，生成新字段。 • 分隔转换：将已有字段，按指定分隔符，分隔出新字段。 • 取模转换：对已有字段取模，生成新字段。 • 剪切字符串：通过指定起始位置，截取已有字符串类型的字段，生成新字段。 • EL 操作转换：指定算法，对字段值进行运算，目前支持的算法有：md5sum、sha1sum、sha256sum 和 sha512sum 等。 • 字符串大小写转换：对已有的字符串类型字段，切换大小写，生成新字段。 • 字符串逆序转换：对已有的字符串类型字段，做逆序变换，生成新字段。 • 字符串空格清除转换：对已有的字符串类型字段，清除左右空格，生成新字段。 • 过滤行转换：配置逻辑条件过滤掉含触发条件的行。 • 更新域：当满足某些条件时，更新字段的值。
输出	• Hive 输出：将已生成的字段输出到 Hive 表。 • 表输出：将已生成的字段输出到关系型数据库表。 • 文件输出：将已生成的字段通过分隔符连接并输出到文件。

类型	描述
	• HBase 输出：将已生成的字段输出到 HBase 表。

字段简介

作业配置中的字段是 Loader 按业务需要定义的与用户数据对应的一种数据项，它拥有具体类型，必须与用户实际数据类型保持一致。

17.8.2 输入算子

17.8.2.1 CSV 文件输入

概述

“CSV 文件输入”算子，用于导入所有能用文本编辑器打开的文件。

输入与输出

- 输入：文本文件
- 输出：多个字段

参数说明

表17-94 算子参数说明

参数	含义	类型	是否必填	默认值
分隔符	CSV 文件的列分隔符，用于分隔每行的数据。	string	是	,
换行符	用户根据数据实际情况，填写字符串作为换行符。支持任何字符串。默认使用操作系统的换行符。	string	否	\n
文件名是否作为字段	自定义一个字段，以当前数据所在的文件名作为该字段值。	string	否	无
绝对路径	配置“文件名是否作为字段”引用文件名环境，选中单选框时是带绝对路径的文件名；不选中单选框时是不带路径的文件名。	boolean	否	不选中
验证输入字段	是否检验输入字段与值的类型匹配情况，值为“NO”，不检查；值为“YES”，检查。若不匹配则跳过该行。	enum	是	YES
输入字段	配置输入字段的相关信息： • 位置：源文件每行被列分隔符分隔后，	map	是	无

参数	含义	类型	是否必填	默认值
	目标字段对应的位置，从 1 开始编号。 • 字段名：配置字段名。 • 类型：配置字段类型。 • 数据格式：字段类型为“DATE”或“TIM”E 或“TIMESTAMP”时，需指定特定时间格式，其他字段类型指定无效。时间格式如：“yyyyMMdd HH:mm:ss”。 • 长度：配置字段长度，字段值太长则按配置的长度截取，类型为“CHAR”时实际长度不足则空格补齐，类型为“VARCHAR”时实际长度不足则不补齐。			

数据处理规则

- 将每行数据按照指定的分隔符，分隔成多个字段，供之后的转换算子使用。
- 当字段的值与实际的类型不匹配时，该行数据会成为脏数据。
- 输入字段列数不等于原始数据实际包含字段列数，该行数据会保存为脏数据。

样例

源文件如下图：

```
2016,year
year,2016
```

配置“CSV 文件输入”算子，分隔符为“,”，生成两个字段 A、B。

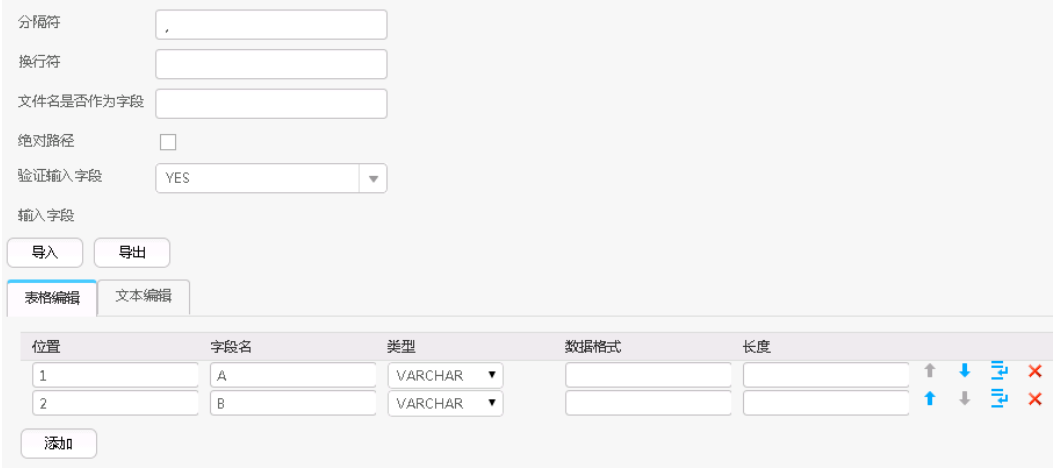

将 A、B 输出，结果如下：

```
2016,year
year,2016
```

17.8.2.2 固定宽度文件输入

概述

“固定宽度文件输入”算子，将文件的每一行，按可配置长度的字符或字节，转换成多个输入字段。

输入与输出

- 输入：文本文件
- 输出：多个字段

参数说明

表17-95 算子参数说明

参数	含义	类型	是否必填	默认值
换行符	用户根据数据实际情况，填写字符串作为换行符。支持任何字符串。默认使用操作系统的换行符。	string	否	\n
分割长度单位	长度单位，可选择“char”字符或“byte”字节。	enum	是	char
输入字段	配置输入字段相关信息： • 固定长度：设置字段长度，第 2 个字段起点从第 1 个字段终点开始，以此类推。 • 字段名：配置输入字段名。 • 类型：配置字段类型。 • 数据格式：字段类型为“DATE”或“TIME”或“TIMESTAMP”时，需指定特定时间格式，其他字段类型指定无效。时间格式如：“yyyyMMdd HH:mm:ss”。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。	map	是	无

数据处理规则

- 按照输入字段的长度依次截取源文件，生成字段。
- 当字段的值与实际的类型不匹配时，该行数据会成为脏数据。
- 配置字段分割长度，大于原字段值的长度，则数据分割失败，当前行成为脏数据。

样例

源文件如下图：

```
fusionInsightbigdataproduct
```

配置“固定宽度文件输入”算子，生成三个字段 A、B 和 C。

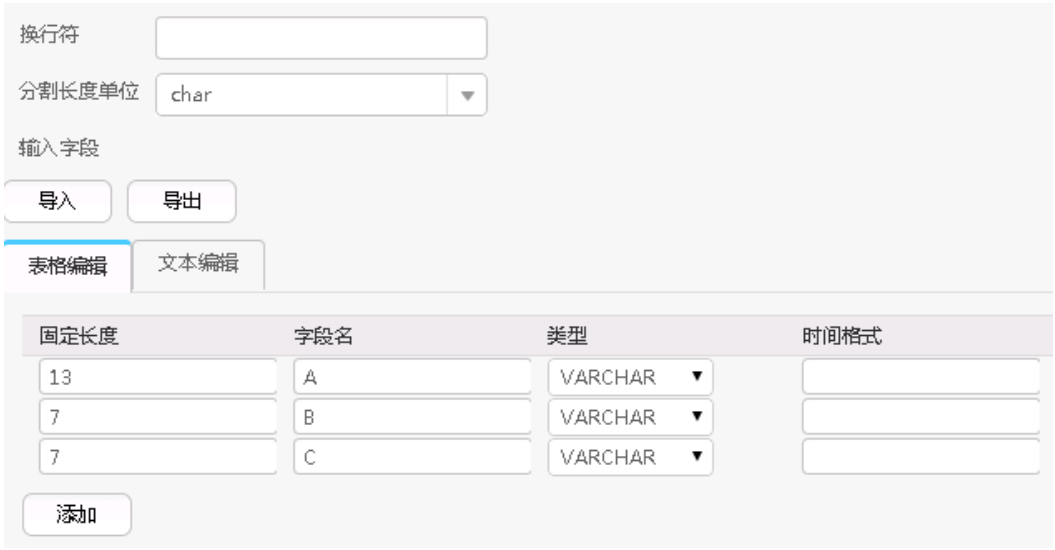

将三个字段依次输出，结果如下：

```
fusionInsight,bigdata,product
```

17.8.2.3 表输入

概述

“表输入”算子，将关系型数据库表的指定列按顺序转换成同等数量的输入字段。

输入与输出

- 输入：表列
- 输出：字段

参数说明

表17-96 算子参数说明

参数	含义	类型	是否必填	默认值
输入字段	配置关系型数据库输入字段的相关信息： • 位置：配置输入字段的位置。 • 字段名：配置输入字段名。 • 类型：配置字段类型。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。	map	是	无

数据处理规则

- 将指定的列按顺序生成字段。具体的表列是在作业配置的第二步“输入设置”中指定，当配置了“表列名”时，就是配置的值；当没配置“表列名”时，默认该表的所有列或者是“SQL 语句”配置项里配置的查询条件中指明的列。
- 配置的输入字段个数不能大于实际指定的列数，否则全部数据成为脏数据。
- 当字段的值与实际的类型不匹配时，该行数据会成为脏数据。

样例

以 sqlserver 2014 为例，创建测试表 test：

create table test (id int, name text, value text);

往测试表中插入三条数据：

insert into test values (1,'zhangshan','zhang');

insert into test values (2,'lisi','li');

insert into test values (3,'wangwu','wang');

查询表：

	id	name	value
1	1	zhangshan	zhang
2	2	lisi	li
3	3	wangwu	wang

配置“表输入”算子，生成三个字段：

设置了数据连接器后，可以单击“自动识别”，系统将自动读取数据库中的字段，可根据需要选择添加，然后根据业务场景手动进行完善或者修正即可，无需逐一手动添加。

说明

- 此操作会覆盖表格内已有数据。
- 单击“自动识别”后，建议手动检查系统自动识别出的字段类型，确保与表中实际的字段类型相符合。

  例如 Oracle 数据库中的“date”类型，系统会自动识别为“timestamp”类型，若不手动处理会导致后续 Hive 表在查询数据时报错。

配置输出算子，输出到 HDFS/OBS，结果如下：

```
1,zhangshan,zhang
2,lisi,li
3,wangwu,wang
```

17.8.2.4 HBase 输入

概述

“HBase 输入”算子，将 HBase 表的指定列转换成同等数量的输入字段。

输入与输出

- 输入：HBase 表列
- 输出：字段

参数说明

表17-97 算子参数说明

参数	含义	类型	是否必填	默认值
HBase 表类型	配置 HBase 表类型，可选项为 normal（普通表）和 phoenix 表。	enum	是	normal
HBase 表名	配置 HBase 表名。仅支持一个 HBase 表。	string	是	无

参数	含义	类型	是否必填	默认值
HBase 输入字段	配置 HBase 输入信息： • 列族：配置 HBase 列族名。 • 列名：配置 HBase 列名。 • 字段名：配置输入字段名。 • 类型：配置字段类型。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。 • 主键：配置是否为主键列。普通 HBase 表主键只能指定一个；phoenix 表主键可以指定多个，配置多个列为主键时，会按照配置列的先后顺序对其进行拼接。必需配置一个主键列。	map	是	无

数据处理规则

- 当配置 HBase 表名不存在时，作业提交失败。
- 当配置的列名与 HBase 表列名不匹配时，读取不到数据，导入数据条数会为 0。
- 配置输入字段列数，大于原始数据实际包含字段列数，全部数据成为脏数据。
- 当字段的值与实际的类型不匹配时，该行数据会成为脏数据。

样例

以 HBase 导出到 sqlserver2014 数据库为例。

在 sqlserver2014 上创建一张空表 test_1 用于存储 HBase 数据。执行以下语句：

create table test_1 (id int, name text, value text);

配置“HBase 输入”算子，生成三个字段 A、B 和 C：

设置了数据连接器后，可以单击“自动识别”，系统将自动读取数据库中的字段，可根据需要选择添加，然后根据业务场景手动进行完善或者修正即可，无需逐一手动添加。

说明

此操作会覆盖表格内已有数据。

通过“表输出”算子，将 A、B 和 C 输出到 test_1 表中：

select * from test_1;

	id	name	value
1	1	zhangshan	zhang
2	2	lisi	li
3	3	wangwu	wang

17.8.2.5 HTML 输入

概述

“HTML 输入”算子，导入有规则的 HTML 文件，并将 HTML 文件中的元素转换成输入字段。

输入与输出

输入：HTML 文件

输出：多个字段

参数说明

表17-98 算子参数说明

参数	含义	类型	是否必填	默认值
父标签	所有字段的上层 HTML 标签，用于限定搜索范围	string	是	无
文件名	自定义一个字段，以当前数据所在的文件名作为该字段值。	string	否	无

参数	含义	类型	是否必填	默认值
绝对文件名	配置“文件名”引用文件名环境，选中单选框时是带绝对路径的文件名；不选中单选框时是不带路径的文件名。	boolean	否	否
验证输入字段	是否检验输入字段与值的类型匹配情况，值为“NO”，不检查；值为“YES”，检查。若不匹配则跳过该行。	enum	是	YES
输入字段	配置输入字段的相关信息： • 位置：目标字段对应的位置，从 1 开始编号。 • 字段名：配置字段名。 • 字段所在的标签：字段的标签。 • 关键字：配置关键字，能够匹配标签所在的内容，支持通配符，例如标签内容为“姓名”，可配置关键字“*姓名*”。 • 类型：配置字段类型。 • 数据格式：字段类型为“DATE”或“TIME”或“TIMESTAMP”时，需指定特定时间格式，其他字段类型指定无效。时间格式如：“yyyyMMdd HH:mm:ss”。 • 长度：配置字段长度，字段值太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。	map	是	无

数据处理规则

- 首先配置父标签，限定搜索范围，父标签要存在，否则取到的内容为空。
- 配置输入字段，子标签用于精确定位字段所在的标签，相同的标签再通过关键字来精确匹配。
- 关键字用于匹配字段的内容，配置方法类似于“输入设置”中的“文件过滤器”字段，支持“*”通配符，提供三种标记用于辅助定位，分别为：
  a. “#PART”标记，表示取被通配符“*”所匹配的值，如果存在多个“*”号，可以指定一个序号，按从左到右的顺序，取得对应序号的“*”所配置的内容。例如“#PART1”，表示取第 1 个“*”号匹配的值；“#PART8”，表示取第 8 个“*”号匹配的值。
  b. “#NEXT”标记，表示取当前匹配的标签的下一个标签的值。

c. “#ALL”标记，表示取当前匹配的标签的所有内容作为值。

- 配置的标签有误时，取到的值为空，不会报错。

样例

源文件如下：

```
<html>
<body>
<table>
<tr>
<td>name:zhangshan</td>
<td>department:FusionInght</td>
<td>age:25</td>
</tr>
</table>
</body>
</html>
```

配置“HTML 输入”算子，生成三个字段 A、B 和 C：

依次输出这三个字段，结果如下：

```
zhangshan,FusionInght,25
```

17.8.2.6 Hive 输入

概述

“Hive 输入”算子，将 Hive 表的指定列转换成同等数量的输入字段。

输入与输出

- 输入：Hive 表列

- 输出：字段

参数说明

表17-99 算子参数说明

参数	含义	类型	是否必填	默认值
Hive 数据库	Hive 的数据库名称。	String	否	default
Hive 表名	配置 Hive 表名。 仅支持一个 Hive 表。	String	是	无
分区过滤器	配置分区过滤器可以导出指定分区数据，默认为空，导出整个表数据。 例如导出分区字段 locale 的值为“CN”或“US”的表数据，输入如下： **locale = "CN" or locale = "US"**	String	否	-
Hive 输入字段	配置 Hive 输入信息： • 列名：配置 Hive 列名。 • 字段名：配置输入字段名。 • 类型：配置字段类型。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。	map	是	-

数据处理规则

- 当配置 Hive 表名不存在时，作业提交失败。
- 当配置的列名与 Hive 表列名不匹配时，读取不到数据，导入数据条数会为 0。
- 当字段的值与实际的类型不匹配时，该行数据会成为脏数据。

样例

以 Hive 导出到 sqlserver2014 数据库为例。

在 sqlserver2014 上创建一张空表“test_1”用于存储 Hive 数据。执行以下语句：

create table test_1 (id int, name text, value text);

配置“Hive 输入”算子，生成三个字段 A、B 和 C：

设置了数据连接器后，单击“自动识别”，系统将自动读取数据库中的字段，可根据需要选择添加，然后根据业务场景手动进行完善或者修正即可，无需逐一手动添加。

说明

此操作会覆盖表格内已有数据。

通过“表输出”算子，将 A、B 和 C 输出到“test_1”表中：

select * from test_1;

	id	name	value
1	1	zhangshan	zhang
2	2	lisi	li
3	3	wangwu	wang

17.8.2.7 Spark 输入

概述

“Spark 输入”算子，将 SparkSQL 表的指定列转换成同等数量的输入字段。

输入与输出

- 输入：SparkSQL 表列
- 输出：字段

参数说明

表17-100 算子参数说明

参数	含义	类型	是否必填	默认值

参数	含义	类型	是否必填	默认值
Spark 数据库	SparkSQL 的数据库名称。	String	否	default
Spark 表名	配置 SparkSQL 表名。 仅支持一个 SparkSQL 表。	String	是	无
分区过滤器	配置分区过滤器可以导出指定分区数据，默认为空，导出整个表数据。 例如导出分区字段 locale 的值为“CN”或“US”的表数据，输入如下： **locale = "CN" or locale = "US"**	String	否	-
Spark 输入字段	配置 SparkSQL 输入信息： • 列名：配置 SparkSQL 列名。 • 字段名：配置输入字段名。 • 类型：配置字段类型。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。	map	是	-

数据处理规则

- 当配置 SparkSQL 表名不存在时，作业提交失败。
- 当配置的列名与 SparkSQL 表列名不匹配时，读取不到数据，导入数据条数会为 0。
- 当字段的值与实际的类型不匹配时，该行数据会成为脏数据。

样例

以 SPARK 导出到 sqlserver2014 数据库为例。

在 sqlserver2014 上创建一张空表“test_1”用于存储 SparkSQL 数据。执行以下语句：

create table test_1 (id int, name text, value text);

配置“Spark 输入”算子，生成三个字段 A、B 和 C：

设置了数据连接器后，单击“自动识别”，系统将自动读取数据库中的字段，可根据需要选择添加，然后根据业务场景手动进行完善或者修正即可，无需逐一手动添加。

说明

此操作会覆盖表格内已有数据。

通过“表输出”算子，将 A、B 和 C 输出到“test_1”表中：

select * from test_1;

	id	name	value
1	1	zhangshan	zhang
2	2	lisi	li
3	3	wangwu	wang

17.8.3 转换算子

17.8.3.1 长整型时间转换

概述

“长整型时间转换”算子，用于配置长整型数值与日期的转换。

输入与输出

- 输入：需要转换的字段
- 输出：转换后的新字段

参数说明

表17-101 算子参数说明

参数	含义	类型	是否必填	默认值
转换类型	配置长整型时间转换类型： • long to date：长整型数值转换为 DATE 类	enum	是	long to date

参数	含义	类型	是否必填	默认值
	型。 • long to time：长整型数值转换为 TIME 类型。 • long to timestamp：长整型数值转换为 TIMESTAMP 类型。 • date to long：DATE 类型转换为长整型数值。 • time to long：TIME 类型转换为长整型数值。 • timestamp to long：TIMESTAMP 类型转换为长整型数值。			
输入字段名	配置输入的待转换字段名称，需填写上一个转换步骤生成的字段名。	string	是	无
输出字段名	配置输出字段的字段名。	string	是	无
字段单位	配置长整型数值字段的单位，根据“转换类型”长整型数据可以是输入字段或生成字段，可选值为“second”和“milisecond”。	enum	是	second
输出字段类型	配置输出字段的类型，可选值为“BIGINT”，“DATE”，“TIME”和“TIMESTAMP”。	enum	是	BIGINT
时间格式	配置时间字段格式，时间格式如：“yyyyMMdd HH:mm:ss”。	string	否	无

数据处理规则

- 原始数据包含 null 值，不做转换处理。
- 配置输入字段列数，大于原始数据实际包含字段列数，全部数据成为脏数据。
- 遇到类型转换错误，当前数据保存为脏数据。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下图：

```
1453431755874,2016-01-22 10:40:00
```

配置“长整型时间转换”算子，生成四个新字段 C、D、E 和 F，类型分别为 DATE、TIME、TIMESTAMP、BIGINT。

转换后，依次输出，结果如下：

```
1453431755874,2016-01-22,2016-01-22,11:02:35,20160122 11:02:35,1453430400000
```

17.8.3.2 空值转换

概述

“空值转换”算子，用于将空值替换成指定值。

输入与输出

- 输入：空值字段
- 输出：原字段，但值已经被替换

参数说明

表17-102 算子参数说明

参数	含义	类型	是否必填	默认值
输入字段名	配置可能出现空值的字段名，需填写已生成的字段名。	string	是	无
替换值	配置替换空值的指定值。	string	是	无

数据处理规则

字段原值为 null 时，替换成指定的值。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下图：

```
,value1
key2,value2
key3,
```

配置“空值转换”算子，如下图：

转换后，将 A 和 B 的值输出后的结果如下：

```
newKey,value1
key2,value2
key3,newValue
```

17.8.3.3 增加常量字段

概述

“增加常量字段”算子，用于直接生成常量字段。

输入与输出

- 输入：无
- 输出：常量字段

参数说明

表17-103 算子参数说明

参数	含义	类型	是否必填	默认值
配置字段	配置常量字段相关信息： • 输出字段名：配置字段名。 • 类型：配置字段类型。 • 时间格式：字段类型为“DATE”或“TIME”或“TIMESTAMP”时，需指定特定时间格式，其他类型指定无效。时间格式如：“yyyyMMdd HH:mm:ss”。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为	map	是	无

参数	含义	类型	是否必填	默认值
	“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。 • 常量值：配置符合类型的常量值。			

数据处理规则

生成指定类型的常量字段。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下图：

```
,value1
key2,value2
key3,
```

配置“增加常量字段”算子，增加两个字段 C 和 D：

转换后，将 A、B、C 和 D 按顺序输出，结果如下：

```
,value1,constantsvalue1,2016
key2,value2,constantsvalue1,2016
key3,,constantsvalue1,2016
```

17.8.3.4 随机值转换

概述

“随机值转换”算子，用于配置新增值为随机数的字段。

输入与输出

- 输入：无
- 输出：随机值字段

参数说明

表17-104 算子参数说明

参数	含义	类型	是否必填	默认值
输出字段名	配置生成随机值的字段名。	string	是	无
长度	配置字段长度。	map	是	无
类型	配置字段的类型，可选值为“VARCHAR”，“INTEGER”和“BIGINT”。	enum	是	VARCHAR

数据处理规则

生成指定类型的随机值。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下图：

```
,value1
key2,value2
key3,
```

配置“随机值转换”算子，生成 C、D、E 三个字段：

转换后，按顺序输入这五个字段：

```
,value1,2druceak69ril,769974975,8452014577467885098
key2,value2,7oq2dku93q9cg,1631427868,867914116689501757
key3,,2jg5e7b1m17kq,654806209,2477823020516316030
```

可以发现，每次生成的随机值都不一样。

17.8.3.5 拼接转换

概述

“拼接转换”算子，将已有字段的值通过连接符拼接，生成新的字段。

输入与输出

- 输入：需要拼接的字段
- 输出：拼接后的字段

参数说明

表17-105 算子参数说明

参数	含义	类型	是否必填	默认值
输出字段名	配置拼接后的字段名。	string	是	无
分隔符	配置拼接符，可为空。	string	否	空字符串
被拼接字段名	配置需要被拼接字段名。 字段名：需填写上一个转换步骤生成的字段名，可添加多个。	map	是	无

数据处理规则

- 按顺序将“被拼接字段名”中配置的字段的值，通过连接符拼接后，赋给“输出字段名”。
- 当有字段的值为 null 时，会转化为空字符串，再与其它字段值拼接。

样例

通过“CSV 文件输入”算子，生成三个字段 A、B 和 C。

源文件如下图：

```
happy,new,year
welcome,to,2016
```

配置“拼接转换”算子，“分隔符”为空格，生成新字段 D：

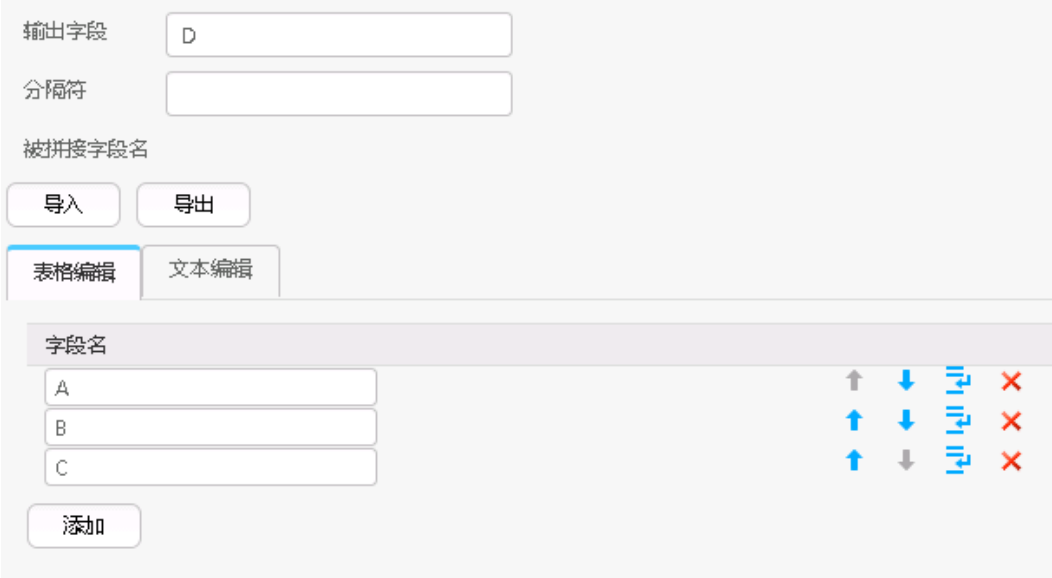

转换后，依次输出 A、B、C 和 D，结果如下：

```
happy,new,year,happy new year
welcome,to,2016,welcome to 2016
```

17.8.3.6 分隔转换

概述

“分隔转换”算子，将已有字段的值按指定的分隔符分隔后生成新字段。

输入与输出

- 输入：需要分隔的字段
- 输出：分隔后的字段

参数说明

表17-106 算子参数说明

参数	含义	类型	是否必填	默认值
输入字段名	被分隔的字段名，需填写上一个转换步骤生成的字段名。	string	是	无
分隔符	配置分隔符。	string	是	无
分割后的字段	配置分隔后的字段，可为多个： • 位置：分隔后字段的位置。 • 输出字段名：分隔后的字段名。	map	是	无

数据处理规则

- 将输入字段的值按指定的分隔符分隔后，依次赋给配置的新字段。
- 配置分割后字段列数，大于原始数据实际可分割出来的字段列数，当前行成为脏数据。

样例

通过“CSV 文件输入”算子，生成一个字段 A。

源文件如下：

```
happy new year
welcome to 2016
```

配置“分隔转换”算子，“分隔符”为空格，生成三个字段 B、C 和 D：

转换后，依次输出 A、B、C 和 D，结果如下：

```
happy new year,happy,new,year
welcome to 2016,welcome,to,2016
```

17.8.3.7 取模转换

概述

“取模转换”算子，对整数字段取模，生成新字段。

输入与输出

- 输入：整数字段
- 输出：模数字段

参数说明

表17-107 算子参数说明

参数	含义	类型	是否必填	默认值
取模字段名	配置取模运算信息： • 输入字段名：配置输入字段名，需填写上一个转换步骤生成的字段名。 • 输出字段名：配置输出字段名。 • 系数：指定取模的数值。	map	是	无

数据处理规则

- 生成新字段，值为取模后的值。
- 字段的值须为整数，否则当前行会成为脏数据。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下图：

```
10,12
2015,2016
```

配置“取模转换”算子，生成两个新字段 C 和 D：

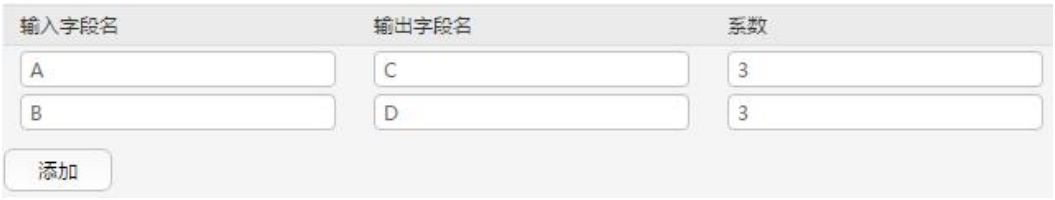

转换后，依次输出 A、B、C 和 D，结果如下：

```
10,12,1,0
2015,2016,2,0
```

17.8.3.8 剪切字符串

概述

“剪切字符串”算子，截取已有字段的值，生成新的字段。

输入与输出

- 输入：需要截取的字段
- 输出：截取后生成的新字段

参数说明

表17-108 算子参数说明

参数	含义	类型	是否必填	默认值
被截取的字段	配置被截取字段相关信息： • 输入字段名：配置输入字段名，需填写上一个转换步骤生成的字段名。 • 输出字段名：配置输出字段名。 • 开始位置：截取开始位置，从序号 1 开始。 • 结束位置：截取结束位置，不确定字符串长度时，可指定为-1 表示被截取字段的末尾。 • 输出字段类型：输出字段的类型。 • 输出字段长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“输出字段类型”为“CHAR”时实际长度不足则空格补齐，“输出字段类型”为“VARCHAR”时实际长度不足则不补齐。	map	是	无

数据处理规则

- 用开始位置和结束位置去截取原字段的值，生成新字段。
- 结束位置为“-1”时，表示字段的末尾。其它情况下，结束位置不能小于开始位置。
- 字符截取的开始位置或结束位置，大于输入字段的长度时，当前行成为脏数据。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下：

```
abcd,product
FusionInsight,Bigdata
```

配置“剪切字符串”算子后，生成两个新字段 C 和 D：

转换后，分别输出这三个字段：

```
abcd,product,abc,prod
FusionInsight,Bigdata,Fus,Bigd
```

17.8.3.9 EL 操作转换

概述

“EL 操作转换”算子，对字段值进行运算后生成新的字段，目前支持的算子有：md5sum、sha1sum、sha256sum 和 sha512sum 等。

输入与输出

- 输入：需要转换的字段
- 输出：经过 EL 表达式转换后的字段

参数说明

表17-109 算子参数说明

参数	含义	类型	是否必填	默认值
el 操作之后生成的字段	配置 EL 表达式： • 名称：表达式输出结果的名称。 • el 表达式：表达式，格式为：*表达式名称（输入字段名,是否用小写字母表示输出结果）*。例如，md5sum(fieldname,true)。 – md5sum：生成 md5 校验值。 – sha1sum：生成 sha1 校验值。 – sha256sum：生成 sha256 校验值。 – sha512sum：生成 sha512 校验值。 • 类型：表达式输出结果类型，建议选择“VARCHAR”。 • 时间格式：表达是输出结果格式。	map	是	无

参数	含义	类型	是否必填	默认值
	• 长度：表达式输出结果长度。			

数据处理规则

- 对字段值进行运算后生成新的字段。
- 当前新字段的类型只能为 VARCHAR。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件见下图：

```
2016,year
year,2016
```

配置“EL 操作转换”算子，生成 C、D、E 和 F 四个字段：

依次输出这六个字段，结果如下图：

```
2016,year,95192C98732387165BF8E396C0F2DAD2,ab39c54239118a4b086b878b7878100f769dd1
97,4CB4EA25583C25647247AE96FC90225D99AD7A6FABC3E2C2FD13C502E323CD9E,779edfe0463b2
596e7a83e4c59083e19242e8c51eace8e2ec57704643be5e15ba80f79af227cf3ea2e2362b4081377
96a1d82cb0535652b99844bb9a62019563
year,2016,84CDC76CABF41BD7C961F6AB12F117D8,4ff0b1538469338a0073e2cdaab6a517801b6a
b4,DA6E2F539726FABD1F8CD7C9469A22B36769137975B28ABC65FE2DC29E659B77,da0ae9104086a
1c58f89f82766ac55a02c8ab44277ce39f959ec0e73391bef651c6f9793657396ce47fbd846068465
ccbf3056764424bed9be7789bd1101ace7
```

17.8.3.10 字符串大小写转换

概述

“字符串大小写转换”算子，用于配置已生成的字段通过大小写变换，转换出新的字段。

输入与输出

- 输入：需要转换大小写的字段
- 输出：转换后的字段

参数说明

表17-110 算子参数说明

参数	含义	类型	是否必填	默认值
转换后的字段	配置字符串大小写转换的字段相关信息： • 输入字段名：配置输入字段名，需填写上一个转换步骤生成的字段名。 • 输出字段名：配置输出字段名。 • 小写/大写：指定进行大写转换或小写转换。	map	是	无

数据处理规则

- 对字符串值做大小写转换。
- 传入数据为 NULL 值，不做转换处理。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下：

```
abcd,product
FusionInsight,Bigdata
```

配置“字符串大小写转换”算子后，生成两个新字段 C 和 D：

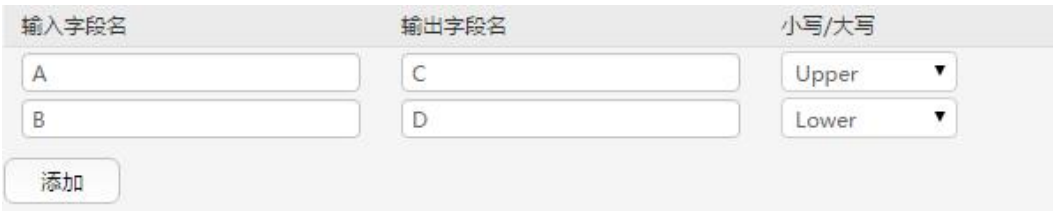

转换后，依次输出四个字段，结果如下：

```
abcd,product,ABCD,product
FusionInsight,Bigdata,FUSIONINSIGHT,bigdata
```

17.8.3.11 字符串逆序转换

概述

“字符串逆序转换”算子，用于配置已生成的字段通过逆序，转换出新的字段。

输入与输出

- 输入：需要逆序的字段
- 输出：逆序转换后的字段

参数说明

表17-111 算子参数说明

参数	含义	类型	是否必填	默认值
逆序转换的字段	配置字符串逆序转换的字段相关信息： • 输入字段名：配置输入字段名，需填写上一个转换步骤生成的字段名。 • 输出字段名：配置输出字段名。 • 类型：配置字段类型。 • 输出字段长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。	map	是	无

数据处理规则

- 对字段的值做逆序操作。
- 传入数据为 NULL 值，不做转换处理。
- 配置输入字段列数，大于原始数据实际包含字段列数，全部数据成为脏数据。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下：

```
abcd,product
FusionInsight,Bigdata
```

配置“字符串逆序转换”算子后，生成两个新字段 C 和 D：

转换后，依次输出四个字段，结果如下：

```
abcd,product,dcba,tcudorp
FusionInsight,Bigdata,thgisnInoisuF,atadgiB
```

17.8.3.12 字符串空格清除转换

概述

“字符串空格清除转换”算子，用于配置已生成的字段通过清除空格，转换出新的字段。

输入与输出

- 输入：需要清除空格的字段
- 输出：转换后的字段

参数说明

表17-112 算子参数说明

参数	含义	类型	是否必填	默认值
清除空格的字段	配置字符串空格清除的字段相关信息： • 输入字段名：配置输入字段名，需填写上一个转换步骤生成的字段名。 • 输出字段名：配置输出字段名。 • 对齐类型：配置清除方式（前空格、后空格、前后空格）。	map	是	无

数据处理规则

- 清空值两边的空格，支持只清除左边、只清除右边和同时清除左右空格。
- 传入数据为 NULL 值，不做转换处理。
- 配置输入字段列数，大于原始数据实际包含字段列数，全部数据成为脏数据。

样例

通过“CSV 文件输入”算子，生成三个字段 A、B 和 C。

源文件如下：

```
  welcome   ,to  ,  2016
happy  ,new , year
```

配置“字符串空格清除转换”算子，生成三个新字段 D、E 和 F。

转换后，依次输出这六个字段，结果如下：

```
  welcome   ,to  ,  2016,welcome,to,2016
happy  ,new , year,happy,new,year
```

17.8.3.13 过滤行转换

概述

“过滤行转换”算子，用于配置逻辑条件过滤掉含触发条件的行。

输入与输出

- 输入：用来做过滤条件的字段
- 输出：无

参数说明

表17-113 算子参数说明

参数	含义	类型	是否必填	默认值
条件逻辑连接符	配置条件逻辑连接符，可配置“AND”或“OR”。	enum	是	AND
条件	配置过滤条件相关信息： • 输入字段名：配置输入字段名，需填写上一个转换步骤生成的字段名。 • 操作：配置操作符。 • 比较值：配置比较值，可直接输入值或输入“#{已存在的字段名}”格式引用字段的具体值。	map	是	无

数据处理规则

- 条件逻辑为“AND”，如果未添加过滤条件，全部数据成为脏数据；或者原始数据满足添加的全部过滤条件，当前行成为脏数据。
- 条件逻辑为“OR”，如果未添加过滤条件，全部数据成为脏数据；或者原始数据满足任意添加的过滤条件，当前行成为脏数据。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下：

```
test，product
FusionInsight,Bigdata
```

配置“过滤行转换”算子，过滤掉含有 test 的行。

转换后，输入原字段，结果如下：

```
FusionInsight,Bigdata
```

17.8.3.14 更新域

概述

“更新域”算子，当满足某些条件时，更新字段的值。

目前支持的类型有“BIGINT”、“DECIMAL”、“DOUBLE”、“FLOAT”、“INTEGER”、“SMALLINT”、“VARCHAR”。当类型为“VARCHAR”时，运算符为“+”时，表示在字符串后追加串，不支持“-”，当为其它类型时，“+”、“-”分别表示值的加和减。针对支持的所有类型，运算符“=”都表示直接赋新值。

输入与输出

输入：字段

输出：输入字段

参数说明

表17-114 算子参数说明

参数	含义	类型	是否必填	默认值
更新字段名	需要更新的字段	string	是	无
操作符	操作符，支持“+”、“-”和“=”	enum	是	+
更新值	用来更新的值	与字段类型相匹配	否	无
条件逻辑连接符	配置条件逻辑连接符，可配置“AND”或“OR”。	enum	是	AND
条件	配置过滤条件相关信息： • 输入字段名：配置输入字段名，需填写上一个转换步骤生成的字段名。 • 操作：配置操作符。 • 比较值：配置比较值，可直接输入值或输入“#{已存在的字段名}”格式引用字段的具体值。	map	是	无

数据处理规则

- 首先判断条件是否成立。如果成立，更新字段的值；如果不成立，则不更新。
- 当更新字段为数值类型时，更新值需要为数值。
- 当更新字段为字符串类型时，更新操作不能为“-”。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下：

```
test，product
FusionInsight,Bigdata
```

配置“更新域”算子，当发现值为 test 时，更新值，在 test 后面加上 good。

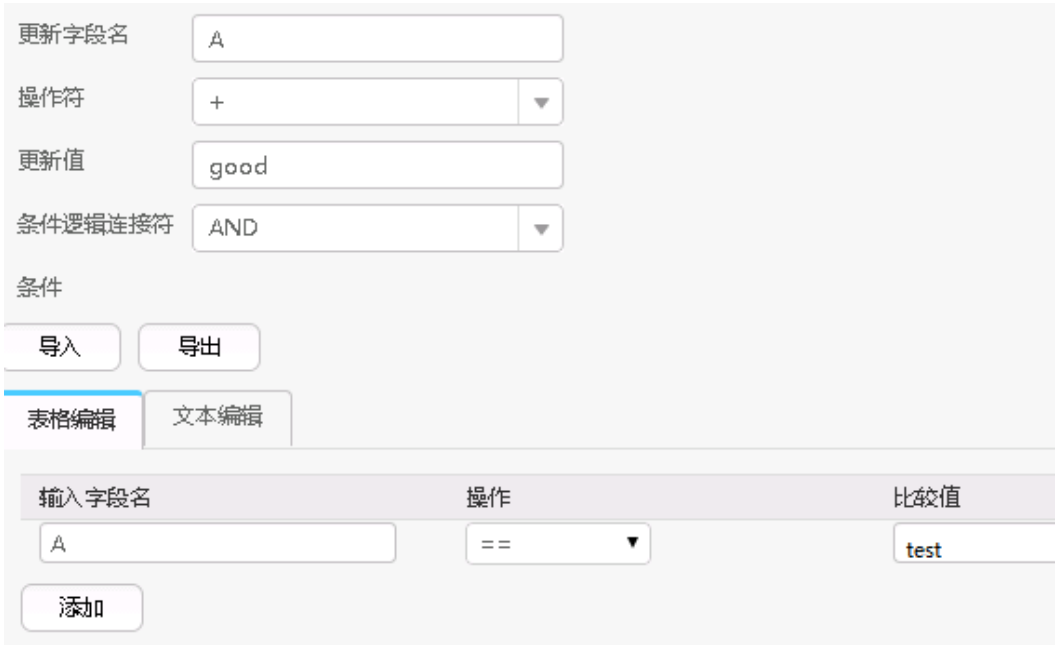

转换后，输出 A 和 B，结果如下：

```
testgood ,product
FusionInsight,Bigdata
```

17.8.4 输出算子

17.8.4.1 Hive 输出

概述

“Hive 输出”算子，用于配置已生成的字段输出到 Hive 表的列。

输入与输出

- 输入：需要输出的字段
- 输出：Hive 表

参数说明

表17-115 算子参数说明

参数	含义	类型	是否必填	默认值
Hive 文件存储格式	配置 Hive 表文件的存储格式（目前支持四种格式：CSV、ORC、RC 和 PARQUET）。 说明 • PARQUET 格式是一种列式存储格式，PARQUET 要求 Loader 的输出字段名和 Hive 表中的字段名保持一致。 • Hive 1.2.0 版本之后，Hive 使用字段名称替代字段序号对 ORC 文件进行解析，因此，Loader 的输出字段名和 Hive 表中的字段名需要保持一致。	enum	是	CSV
Hive 文件压缩格式	在下拉菜单中选择 Hive 表文件的压缩格式，未配置或选择“NONE”表示不压缩数据。	enum	是	NONE
Hive ORC 文件版本	通过该字段配置 ORC 文件的版本（当 Hive 表文件的存储格式是 ORC 时）。	enum	是	0.12
输出分隔符	配置分隔符。	string	是	无
输出字段	配置输出信息： • 位置：配置输出字段的位置。 • 字段名：配置输出字段的字段名。 • 类型：配置字段类型，字段类型为“DATE”或“TIME”或“TIMESTAMP”时，需指定特定时间格式，其他类型指定无效。时间格式如：“yyyyMMdd HH:mm:ss”。 • 十进制格式：配置小数的刻度和精度。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。 • 分区键：配置是否为分区列。可以不指定分区列，也可以指定多个分区列。配置多个列为分区列时，会按照配置列的先后顺序对其进行拼接。	map	是	无

数据处理规则

- 将字段值输出到 Hive 表中。
- 如果指定了一个或多个列为分区列，则在作业配置第四步“输出设置”页面上，会显示“分割程序”属性，该属性表示使用多少个处理器去对分区数据进行处理。
- 如果没有指定任何列为分区列，则表示不需要对输入数据进行分区处理，“分割程序”属性默认隐藏。

样例

通过“CSV 文件输入”算子，生成两个字段 a_str 和 b_str。

源文件如下：

```
2016,year
year,2016
```

配置“Hive 输出”算子，将 a_str 和 b_str 输出到 Hive 的表中。

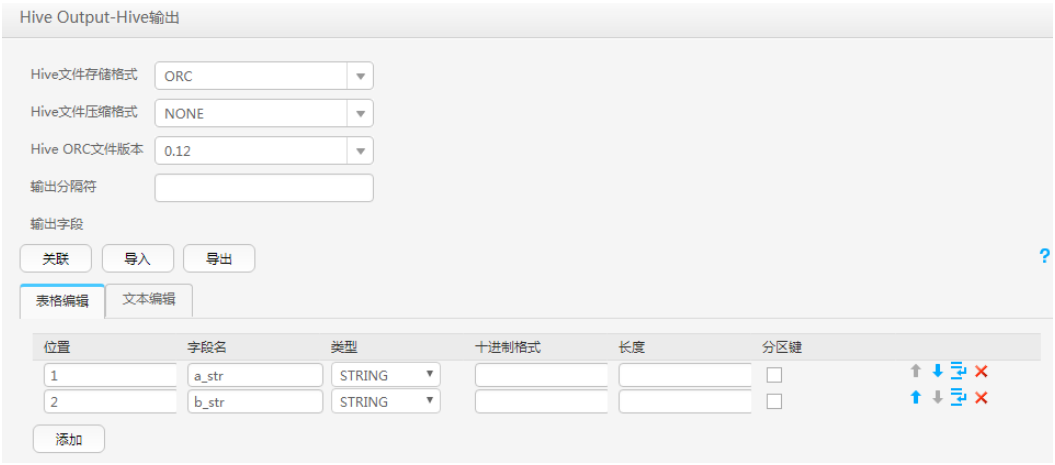

执行成功后，查看表数据：

```
0: jdbc:hive2://10.52.0.97:21066/> select * from hive_test;
+-------------------+-------------------+--+
| hive_test.a_str   | hive_test.b_str   |
+-------------------+-------------------+--+
| 2016              | year              |
| year              | 2016              |
+-------------------+-------------------+--+
2 rows selected (1.6 seconds)
```

17.8.4.2 Spark 输出

概述

“Spark 输出”算子，用于配置已生成的字段输出到 SparkSQL 表的列。

输入与输出

- 输入：需要输出的字段
- 输出：SparkSQL 表

参数说明

表17-116 算子参数说明

参数	含义	类型	是否必填	默认值
Spark 文件存储格式	配置 SparkSQL 表文件的存储格式（目前支持四种格式：CSV、ORC、RC 和 PARQUET）。 说明 • PARQUET 格式是一种列式存储格式，PARQUET 要求 Loader 的输出字段名和 SparkSQL 表中的字段名保持一致。 • Hive 1.2.0 版本之后，Hive 使用字段名称替代字段序号对 ORC 文件进行解析，因此，Loader 的输出字段名和 SparkSQL 表中的字段名需要保持一致。	enum	是	CSV
Spark 文件压缩格式	在下拉菜单中选择 SparkSQL 表文件的压缩格式，未配置或选择“NONE”表示不压缩数据。	enum	是	NONE
Spark ORC 文件版本	通过该字段配置 ORC 文件的版本（当 SparkSQL 表文件的存储格式是 ORC 时）。	enum	是	0.12
输出分隔符	配置分隔符。	string	是	无
输出字段	配置输出信息： • 位置：配置输出字段的位置。 • 字段名：配置输出字段的字段名。 • 类型：配置字段类型，字段类型为“DATE”或“TIME”或“TIMESTAMP”时，需指定特定时间格式，其他类型指定无效。时间格式如：“yyyyMMdd HH:mm:ss”。 • 十进制格式：配置小数的刻度和精度。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。 • 分区键：配置是否为分区列。可以不指定	map	是	无

参数	含义	类型	是否必填	默认值
	分区列，也可以指定多个分区列。配置多个列为分区列时，会按照配置列的先后顺序对其进行拼接。			

数据处理规则

- 将字段值输出到 SparkSQL 表中。
- 如果指定了一个或多个列为分区列，则在作业配置第四步“输出设置”页面上，会显示“分割程序”属性，该属性表示使用多少个处理器去对分区数据进行处理。
- 如果没有指定任何列为分区列，则表示不需要对输入数据进行分区处理，“分割程序”属性默认隐藏。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下：

```
2016,year
year,2016
```

配置“Spark 输出”算子，将 A 和 B 输出到 SparkSQL 的表中。

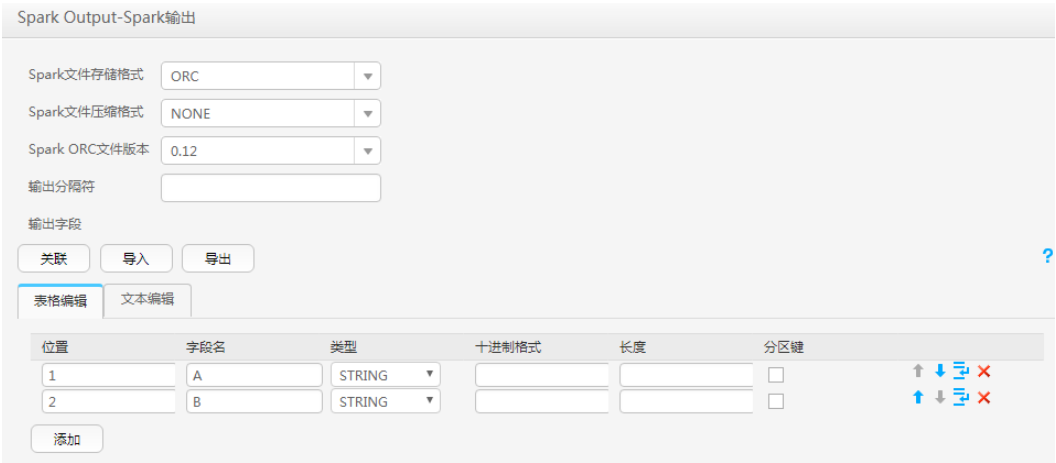

17.8.4.3 表输出

概述

“表输出”算子，用于配置输出的字段对应到关系型数据库的指定列。

输入与输出

- 输入：需要输出的字段
- 输出：关系型数据库表

参数说明

表17-117 算子参数说明

参数	含义	类型	是否必填	默认值
输出分隔符	配置分隔符。 **说明** 该配置仅用于 MySQL 专用连接器，当数据列内容中包含默认分隔符时，需要设置自定义分隔符，否则会出现数据错乱。	string	否	,
换行分隔符	用户根据数据实际情况，填写字符串作为换行符。支持任何字符串。默认使用操作系统的换行符。 **说明** 该配置仅用于 MySQL 专用连接器，当数据列内容中包含默认分隔符时，需要设置自定义分隔符，否则会出现数据错乱。	string	否	\n
输出字段	配置关系型数据库输出字段的相关信息： • 字段名：配置输出字段的字段名。 • 表列名：配置数据库表的列名。 • 类型：配置字段类型，需要和数据库的字段类型一致。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。	map	是	无

数据处理规则

将字段值输出到表中。

样例

以 HBase 导出到 sqlserver2014 数据库为例。

在 sqlserver2014 上创建一张空表 test_1 用于存储 HBase 数据。执行以下语句：

create table test_1 (id int, name text, value text);

通过 HBase 输入步骤，生成三个字段 A、B 和 C。

配置“表输出”算子，将 A、B 和 C 输出到 test_1 表中：

输出结果如下：

	id	name	value
1	1	zhangshan	zhang
2	2	lisi	li
3	3	wangwu	wang

17.8.4.4 文件输出

概述

“文件输出”算子，用于配置已生成的字段通过分隔符连接并输出到文件。

输入与输出

- 输入：需要输出的字段
- 输出：文件

参数说明

表17-118 算子参数说明

参数	含义	类型	是否必填	默认值
输出分隔符	配置分隔符。	strin	是	无

参数	含义	类型	是否必填	默认值
		g		
换行符	用户根据数据实际情况，填写字符串作为换行符。支持任何字符串。默认使用操作系统的换行符。	string	否	\n
输出字段	配置输出信息： • 位置：配置输出字段的位置。 • 字段名：配置输出字段的字段名。 • 类型：配置字段类型，字段类型为“DATE”或“TIME”或“TimeStamp”时，需指定特定时间格式，其他类型指定无效。时间格式如：“yyyyMMdd HH:mm:ss”。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。	map	否	无

数据处理规则

将字段值输出到文件。

样例

通过“CSV 文件输入”算子，生成两个字段 A 和 B。

源文件如下：

```
aaa,product
bbb,Bigdata
```

配置“文件输出”算子，分隔符为“,”，将 A 和 B 输出到文件中：

输出后的结果如下：

```
aaa,product
bbb,Bigdata
```

17.8.4.5 HBase 输出

概述

“HBase 输出”算子，用于配置已生成的字段输出到 HBase 表的列。

输入与输出

- 输入：需要输出的字段
- 输出：HBase 表

参数说明

表17-119 算子参数说明

参数	含义	类型	是否必填	默认值
HBase 表类型	配置 HBase 表类型，可选项为 normal（普通 HBase 表）和 phoenix 表。	enum	是	normal
NULL 值处理方式	配置 NULL 值处理方式。选中单选框时是将转换为空字符串并保存。不选中单选框时是不保存数据。	boolean	否	不选中单选框
HBase 输出字段	配置 HBase 输出信息： • 字段名：配置输出字段的字段名。 • 表名：配置 HBase 表名。 • 列族名：配置 HBase 列族名，如果	map	是	无

参数	含义	类型	是否必填	默认值
	HBase/Phoenix 建表时未配置列族名，默认列族名为 '0'。 • 列名：配置 HBase 列名。 • 类型：配置字段类型，字段类型为“DATE”或“TIME”或“TIMESTAMP”时，需指定特定时间格式，其他类型指定无效。时间格式如：“yyyyMMdd HH:mm:ss”。 • 长度：配置字段长度，字段值实际长度太长则按配置的长度截取，“类型”为“CHAR”时实际长度不足则空格补齐，“类型”为“VARCHAR”时实际长度不足则不补齐。 • 主键：配置是否为主键列。普通 HBase 表主键只能指定一个；phoenix 表主键可以指定多个，配置多个列为主键时，会按照配置列的先后顺序对其进行拼接。必需配置一个主键列。			

数据处理规则

- 将字段值输出到 HBase 表中。
- 原始数据包含 NULL 值，如果“NULL 值处理方式”选中单选框时，将转换为空字符串并保存。如果“NULL 值处理方式”不选中单选框时，不保存数据。

样例

以表输入为例，生成字段后，由 HBase 输出到对应的 HBase 表中，数据存放于 test 表中，如下图：

	id	name	value
1	1	zhangshan	zhang
2	2	lisi	li
3	3	wangwu	wang

创建 HBase 表：

create 'hbase_test','f1','f2';

配置“HBase 输出”算子，如下图：

作业执行成功后，查看 hbase_test 表中数据：

```
hbase(main):001:0> scan 'hbase_test'
ROW                                           COLUMN+CELL
 1                                            column=f1:B, timestamp=1455855645760, value=zhangshan
 1                                            column=f1:C, timestamp=1455855645760, value=zhang
 2                                            column=f1:B, timestamp=1455855645760, value=lisi
 2                                            column=f1:C, timestamp=1455855645760, value=li
 3                                            column=f1:B, timestamp=1455855645760, value=wangwu
 3                                            column=f1:C, timestamp=1455855645760, value=wang
3 row(s) in 0.2720 seconds
```

17.8.4.6 ClickHouse 输出

概述

“ClickHouse 输出”算子，用于配置已生成的字段输出到 ClickHouse 表的列。

输入与输出

- 输入：需要输出的字段
- 输出：ClickHouse 表

参数说明

表17-120 算子参数说明

参数	含义	类型	是否必填	默认值
数据库名	配置 ClickHouse 表所在的数据库	string	是	default
表名	配置数据写入 ClickHouse 对应的表名	string	是	无

数据处理规则

将字段值输出到 ClickHouse 表中。

样例

通过“CSV 文件输入”算子，生成十二个字段。

源文件如下：

```
1,'b','abcd','2021-06-15','12:00:06','2021-06-15 12:00:06',1,12,6.8,18.6,12.8,true
2,'abc','abcd','2021-06-15','12:00:06','2021-06-15 12:00:06',1,12,6.8,18.6,12.8,true
3,'ab','abcd','2021-06-15','12:00:06','2021-06-15 12:00:06',1,12,6.8,18.6,12.8,true
4,'abcdef','abcd','2021-06-15','12:00:06','2021-06-15 12:00:06',1,12,6.8,18.6,12.8,true
5,'a','abcd','2021-06-15','12:00:06','2021-06-15 12:00:06',1,12,6.8,18.6,12.8,true
6,'bg','cde','2020-06-15','13:00:06','2021-06-15 12:00:06',1,12,6.8,18.6,12.8,true
7,'f','cde','2020-06-15','13:00:06','2021-06-15 12:00:06',1,12,6.8,18.6,12.8,true
8,'h','cde','2020-06-15','13:00:06','2021-06-15 12:00:06',1,12,6.8,18.6,12.8,true
```

创建 ClickHouse 表的语句如下：

```
CREATE TABLE IF NOT EXISTS testck4 ON CLUSTER default_cluster(
a Int32,
b VARCHAR(100) NOT NULL,
c char(100),
d DateTime,
e DateTime,
f DateTime,
g smallint,
h bigint,
l Float32,
j Float64,
k decimal(10,2),
m boolean
)
ENGINE = ReplicatedMergeTree('/clickhouse/tables/{shard}/default/testck4', '{replica}')
PARTITION BY toYYYYMM(d)ORDER BY a;
```

配置“ClickHouse 输出”算子，如下图：

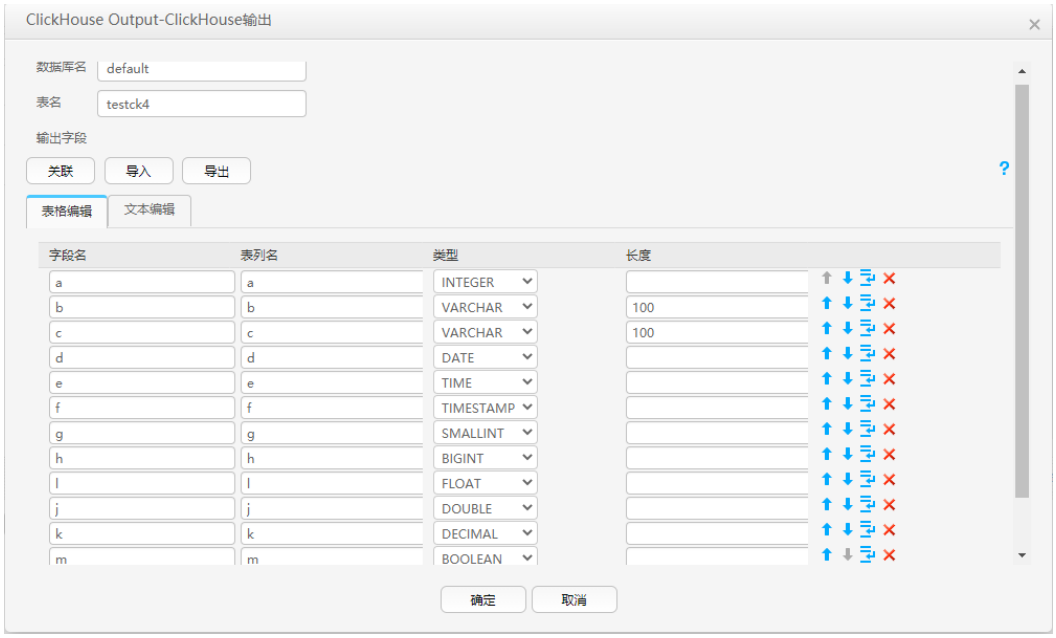

作业执行成功后，查看 testck4 表中数据：

```
kwephisprg00767 :) select * from testck4;

SELECT *
FROM testck4

Query id: 9986211c-e5ea-42b1-9850-f8ebaeb70058

┌─a─┬─b──┬─c───┬───────────────d─┬───────────────e─┬───────────────f─┬─g─┬─h──┬─l──┬────j─┬────k─┬─m─┐
│ 6 │ bg │ cde │ 2020-06-15 00:00:00 │ 1970-01-01 13:00:06 │ 2021-06-15 12:00:06 │ 1 │ 12 │ 6.8 │ 18.6 │ 12.80 │ 1 │
│ 7 │ f  │ cde │ 2020-06-15 00:00:00 │ 1970-01-01 13:00:06 │ 2021-06-15 12:00:06 │ 1 │ 12 │ 6.8 │ 18.6 │ 12.80 │ 1 │
│ 8 │ h  │ cde │ 2020-06-15 00:00:00 │ 1970-01-01 13:00:06 │ 2021-06-15 12:00:06 │ 1 │ 12 │ 6.8 │ 18.6 │ 12.80 │ 1 │
└───┴────┴─────┴─────────────────┴─────────────────┴─────────────────┴───┴────┴────┴──────┴──────┴───┘

┌─a─┬─b──┬─c────┬─────────────d─┬─────────────e─┬─────────────f─┬─g─┬─h──┬─l──┬────j─┬────k─┬─m─┐
│ 1 │ b  │ abcd │ 2021-06-15 00:00:00 │ 1970-01-01 12:00:06 │ 2021-06-15 12:00:06 │ 1 │ 12 │ 6.8 │ 18.6 │ 12.80 │ 1 │
│ 2 │ abc │ abcd │ 2021-06-15 00:00:00 │ 1970-01-01 12:00:06 │ 2021-06-15 12:00:06 │ 1 │ 12 │ 6.8 │ 18.6 │ 12.80 │ 1 │
│ 3 │ ab │ abcd │ 2021-06-15 00:00:00 │ 1970-01-01 12:00:06 │ 2021-06-15 12:00:06 │ 1 │ 12 │ 6.8 │ 18.6 │ 12.80 │ 1 │
│ 4 │ abcdef │ abcd │ 2021-06-15 00:00:00 │ 1970-01-01 12:00:06 │ 2021-06-15 12:00:06 │ 1 │ 12 │ 6.8 │ 18.6 │ 12.80 │ 1 │
│ 5 │ a  │ abcd │ 2021-06-15 00:00:00 │ 1970-01-01 12:00:06 │ 2021-06-15 12:00:06 │ 1 │ 12 │ 6.8 │ 18.6 │ 12.80 │ 1 │
└───┴────┴──────┴─────────────┴─────────────┴─────────────┴───┴────┴────┴──────┴──────┴───┘

8 rows in set. Elapsed: 0.005 sec.
```

17.8.5 关联、编辑、导入、导出算子的字段配置信息

操作场景

该任务指导用户在创建或编辑 Loader 作业时关联、导入或导出算子的字段配置信息。

- 关联操作
  将输入算子的字段配置信息关联到输出算子中。
- 编辑操作
  编辑算子配置参数中的字段信息。
- 导入操作
  通过算子导出文件或算子模板文件将字段配置信息导入到算子中。
- 导出操作
  将算子的字段配置信息以 json 文件导出保存到本地。

前提条件

获取登录“Loader WebUI”的账户和密码。

操作步骤

- **关联操作**

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-88 Loader WebUI 界面

步骤 2 编辑已有作业或者新建作业，进入“转换”界面。

步骤 3 双击指定的输入算子（例如 CSV 文件输入）进入编辑页面，在输入字段的参数表格添加相应配置信息。

步骤 4 双击指定的输出算子（例如文件输出）进入编辑页面，单击“关联”，并在弹出的“关联”对话框中勾选需要的字段信息。

说明

- 在输出算子的字段表格里面已存在名称的字段信息，不会在“关联”窗口显示。
- 用户也可在“字段名”的列表中选择需要字段，相应配置信息会在输出字段的参数表格显示。

步骤 5 单击“确定”，选中字段信息将会在输出字段的参数表格显示。

----结束

- **编辑操作**

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > *待操作集群名称* > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-89 Loader WebUI 界面

步骤 6 编辑已有作业或者新建作业，进入“转换”界面。

步骤 7 双击指定算子（例如 CSV 文件输入）进入编辑页面，在输入字段的“表格编辑”页签单击“添加”按钮，根据算子的参数格式要求填写相应字段信息。

步骤 8 单击每行字段后的按钮可对字段进行上移、下移、下面插入一行以及删除等操作。

单击“文本编辑”，可以直接以文本形式对字段列表进行编辑，不同字段属性直接使用英文逗号“,”进行分隔。

步骤 9 单击“确定”，保存字段信息。

----结束

- **导入操作**

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > *待操作集群名称* > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-90 Loader WebUI 界面

步骤 10 编辑已有作业或者新建作业，进入“转换”界面。

步骤 11 双击指定的算子进入编辑页面，在输入或输出字段的参数表格添加相应配置信息。单击“导入”。

步骤 12 选择导入的类型。

- 导出的文件

  通过算子导出的 json 文件导入字段的配置信息。

- 指导的模板

  通过根据算子模板手动编写 txt 文件，将字段配置信息导入到算子中。

步骤 13 单击  ，选择上传文件对应路径。

步骤 14 单击“上传”，字段的配置信息将会导入到算子。

----结束

- **导出操作**

登录“Loader WebUI”界面。

1. 登录 FusionInsight Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
2. 选择“集群 > *待操作集群名称* > 服务 > Loader”。
3. 单击“LoaderServer(*节点名称*，主)”打开“Loader WebUI”界面。

图17-91 Loader WebUI 界面

步骤 15 编辑已有作业或者新建作业，进入“转换”界面。

步骤 16 双击指定的算子进入编辑页面，在输入或输出字段的参数表格添加相应配置信息，单击“导出”。

步骤 17 选择导出的类型。

- 所有

  所有的字段信息将以 json 文件格式导出保存到本地。

- 指导字段

  在字段列表上勾选需要导出的字段以 json 文件格式导出保存到本地。

步骤 18 单击“确定”，完成导出操作。

----结束

17.8.6 配置项中使用宏定义

用户在创建或者编辑 Loader 作业时，在配置参数时中可以使用宏，在执行作业任务时会自动替换为宏对应的值。

说明

- 宏定义只在该作业范围内生效。
- 宏定义支持随作业导入导出，如果作业中有使用宏定义，则导出的作业包括宏定义。导入作业时默认也导入宏定义。
- 时间宏 dataformat 中的第一个参数的日期格式定义可参考“java.text.SimpleDateFormat.java”中的定义，但需要遵循目标系统的约束，例如 HDFS/OBS 目录不支持特殊符号等。

Loader 宏定义

目前 Loader 默认支持以下时间宏定义：

表17-121 Loader 常用宏定义

名称	替换后效果	说明
@{dateformat("yyyy-MM-dd")}@	2016-05-17	当前日期。
@{dateformat("yyyy-MM-dd HH:mm:ss")}@	2016-05-17 16:50:00	当前日期和时间。
@{timestamp()}@	1463476137557	从 1970 年到现在的毫秒数。
@{dateformat("yyyy-MM-dd HH:mm:ss",-7,DAYS)}@	2016-05-10 16:50:00	最近 7 天，即当前时间减 7 天。 第二个参数支持加减运算。 第三个参数为时间运算的单位，参考“java.util.concurrent.TimeUnit.java”定义，分为 DAYS、HOURS 、MINUTES、SECONDS。

在以下场景中，可以使用宏进行配置参数：

- 指定以当天时间命名的数据目录

  参数项配置为“/user/data/inputdate_@{dateformat("yyyy-MM-dd")}@”。
- 通过 SQL 语句查询最近 7 天的数据

  ```
  select * from table where time between '@{dateformat("yyyy-MM-dd HH:mm:ss",-7,DAYS)}@' and '@{dateformat("yyyy-MM-dd HH:mm:ss")}@'
  ```
- 指定当天的表名

参数项配置为“table_@{dateformat("yyyy-MM-dd")}@”。

17.8.7 算子数据处理规则

在 Loader 导入或导出数据的任务中，每个算子对于原始数据中 NULL 值、空字符串定义了不同的处理规则；在算子中无法正确处理的数据，将成为脏数据，无法导入或导出。

在转换步骤中，算子数据处理规则请参见下表。

表17-122 数据处理规则一览表

转换步骤	规则描述
CSV 文件输入	• 分隔符在原始数据中连续出现两次，将生成空字符串字段。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 遇到类型转换错误，当前数据保存为脏数据。
固定宽度文件输入	• 原始数据包含 NULL 值，不做转换处理。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 配置转换字段类型，与原始数据实际类型不同，全部数据成为脏数据。例如将字符串类型转换为数值类型。 • 配置字段分割长度，大于原字段值的长度，则数据分割失败，当前行成为脏数据
表输入	• 原始数据包含 NULL 值，不做转换处理。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 配置转换字段类型，与原始数据实际类型不同，全部数据成为脏数据。例如将字符串类型转换为数值类型。
HBase 输入	• 原始数据包含 NULL 值，不做转换处理。 • 配置 HBase 表名错误，全部数据成为脏数据。 • “主键”没有配置主键列，全部数据成为脏数据。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 配置转换字段类型，与原始数据实际类型不同，全部数据成为脏数据。例如将字符串类型转换为数值类型。
长整型时间转换	• 原始数据包含 NULL 值，不做转换处理。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 遇到类型转换错误，当前数据保存为脏数据。
空值转换	• 原始数据包含 NULL 值，转换为用户指定的值。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部

转换步骤	规则描述
	数据成为脏数据。
随机值转换	不涉及处理 NULL 值、空字符串，不生成脏数据。
增加常量字段	不涉及处理 NULL 值、空字符串，不生成脏数据。
拼接转换	• 原始数据包含 NULL 值，将转换为空字符串。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。
分隔转换	• 原始数据包含 NULL 值，当前行成为脏数据。 • 配置分割后字段列数，大于原始数据实际可分割出来的字段列数，当前行成为脏数据。
取模转换	• 原始数据包含 NULL 值，当前行成为脏数据。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 数据类型转换失败，当前行成为脏数据。
剪切字符串	• 传入数据为 NULL 值，不做转换处理。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 字符截取的起点位置或终点位置，大于输入字段的长度时，当前行成为脏数据。
EL 操作转换	• 传入数据为 NULL 值，不做转换处理。 • 输入一个或多个字段的值，输出计算结果。 • 输入类型和算子不兼容时，当前行为脏数据。
字符串大小写转换	• 传入数据为 NULL 值，不做转换处理。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。
字符串逆序转换	• 传入数据为 NULL 值，不做转换处理。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。
字符串空格清除转换	• 传入数据为 NULL 值，不做转换处理。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。
过滤行转换	• 条件逻辑为“AND”，如果未添加过滤条件，全部数据成为脏数据；或者原始数据满足添加的全部过滤条件，当前行成为脏数据。 • 条件逻辑为“OR”，如果未添加过滤条件，全部数据成为脏数据；或者原始数据满足任意添加的过滤条件，当前行成为脏数据。

转换步骤	规则描述
文件输出 表输出	• 传入数据为 NULL 值，不做转换处理。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 数据类型转换失败，当前行成为脏数据。
HBase 输出	• 原始数据包含 NULL 值，如果“NULL 值处理方式”设置为“true”，将转换为空字符串并保存。如果“NULL 值处理方式”设置为“false”，不保存数据。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 数据类型转换失败，当前行成为脏数据。
Hive 输出	• 如果指定了一个或多个列为分区列，则在“到”页面上，会显示“分割程序”属性，该属性表示使用多少个处理器去对分区数据进行处理。 • 如果没有指定任何列为分区列，则表示不需要对输入数据进行分区处理，“分割程序”属性默认隐藏。 • 配置输入字段列数，大于原始数据实际包含的字段列数，全部数据成为脏数据。 • 数据类型转换失败，当前行成为脏数据。

17.9 客户端工具说明

17.9.1 使用命令行运行 Loader 作业

操作场景

一般情况下，用户可以手工在 Loader 界面管理数据导入导出作业。当用户需要通过 shell 脚本来更新与运行 Loader 作业时，必须对已安装的 Loader 客户端进行配置。

说明

Loader 不兼容旧版本客户端，如果重新安装集群或 Loader 服务，请重新下载并安装客户端，然后正常使用客户端。

前提条件

- 完成 Loader 客户端的安装。使用非 **root** 用户安装 Loader 客户端时，如果其他用户也需要使用该客户端，则需要当前客户端的安装用户或者其他拥有更大权限的用户进行授权（将 loader 客户端的安装目录赋予“755”权限），请用户关注授权后的安全问题。
- 创建访问 Loader 服务的用户，如果是“机机”用户需要下载 keytab 文件。

操作步骤

配置 Loader shell 客户端。

1. 使用安装客户端的用户登录客户端所在节点。
2. 执行以下命令，防止超时退出。

   TMOUT=0

   说明

   执行完本章节操作后，请及时恢复超时退出时间，执行命令 **TMOUT=***超时退出时间*。例如：**TMOUT=600**，表示用户无操作 600 秒后超时退出。
3. 执行以下命令，进入 Loader 客户端安装目录。例如，Loader 客户端安装目录为“/opt/client/Loader”。

   cd /opt/client/Loader
4. 执行以下命令，配置环境变量。

   source/opt/client/bigdata_env
5. 如果集群为安全模式，执行以下命令进行用户认证。普通模式集群无需执行用户认证。

   kinit *组件业务用户*
6. 执行以下命令修改工具授权配置文件“login-info.xml”，并保存退出。配置文件参数请参见表 17-123。

   vi loader-tools-1.99.3/loader-tool/job-config/login-info.xml

表17-123 login-info.xml 参数

参数名称	描述
hadoop.config.path	填写 MRS 集群“core-site.xml”、“hdfs-site.xml”和“krb5.conf”三个配置文件的保存目录。默认保存在“*Loader 客户端安装目录*/Loader/loader-tools-1.99.3/loader-tool/hadoop-config/”。
authentication.type	Loader 服务的鉴权类型，请根据 MRS 集群认证模式填写： • “kerberos”：表示安全模式。 • “simple”：表示普通模式。
user.keytab	是否使用 keytab 文件认证，参数值为“true”与“false”。
authentication.user	普通模式或者使用密码认证方式时，登录使用的用户。 keytab 登录方式，则不需要设置该参数。
authentication.password	安全模式中若不使用 keytab 认证，配置访问 Loader 服务的用户密码加密字符

参数名称	描述
	串。 **说明** 使用安装客户端的用户执行以下命令加密密码。加密工具第一次执行时自动生成随机动态密钥并保存在“.loader-tools.key”中，加密工具每次加密密码时会使用此动态密钥。删除“.loader-tools.key”后加密工具执行时会重新生成新的随机密钥并保存在“.loader-tools.key”中。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的history命令记录功能，避免信息泄露。 **sh** *Loader客户端安装目录*/**Loader/loader-tools-1.99.3/encrypt_tool** *password*
authentication.principal	安全模式中使用keytab认证，配置访问Loader服务的“机机”用户名。
authentication.keytab	安全模式中使用keytab认证，配置访问Loader服务的“机机”用户keytab文件目录，需包含绝对路径。
zookeeper.quorum	配置连接ZooKeeper节点的IP地址和端口，参数值格式为“IP1:port,IP2:port,IP3:port”，以此类推。默认端口号为“2181”。
sqoop.server.list	配置连接Loader的浮动IP和端口，参数值格式为“floatip:port”。默认端口号为“21351”。

步骤 2 使用 Loader shell 客户端。

1. 执行以下命令，进入 Loader shell 客户端目录。例如，Loader 客户端安装目录为“/opt/client/Loader”。

   cd /opt/client/Loader/loader-tools-1.99.3/shell-client/

2. 执行以下命令，通过 Loader shell 客户端工具运行作业。

   ./submit_job.sh -n <*arg*> **-u** <*arg*> **-jobType** <*arg*> **-connectorType** <*arg*> **-frameworkType** <*arg*>

表17-124 Loader shell 客户端工具参数一览表

参数名称	描述
“-n”	必配项，表示作业名称。
“-u”	必配项。 指定参数值为“y”表示更新作业参数并运行作业，此时需配置“-jobType”、

参数名称	描述
	“-connectorType”和“-frameworkType”。指定参数值为“n”表示不更新作业参数直接运行作业。
“-jobType”	表示作业类型，当“-u”的值为“y”时，必须配置。 指定参数值为“import”表示数据导入作业，指定参数值为“export”表示数据导出作业。
“-connectorType”	表示连接器类型，当“-u”的值为“y”时，必须配置。根据业务需要可修改外部数据源的部分参数。 指定参数值为“sftp”表示 SFTP 连接器。 • 在导入作业中，支持修改源文件的输入路径“-inputPath”、源文件的编码格式“-encodeType”和源文件导入成功后对输入文件增加的后缀值“-suffixName”。 • 在导出作业中，支持修改导出文件的路径或者文件名“-outputPath”。 指定参数值为“rdb”表示关系型数据库连接器。 • 在导入作业中，支持修改数据库模式名“-schemaName”、表名“-tableName”、SQL 语句“-sql”、要导入的列名“-columns”和分区列“-partitionColumn”。 • 在导出作业中，支持修改数据库模式名“-schemaName”、表名“-tableName”和临时表名称“-stageTableName”。
“-frameworkType”	表示 MRS 端数据保存的类型，当“-u”的值为“y”时，必须配置。根据业务需要可修改数据保存类型的部分参数。 指定参数值为“hdfs”表示 Hadoop 端使用 HDFS。 • 在导入作业中，支持修改启动的 map 数量“-extractors”和数据导入到 HDFS 里存储的保存目录“-outputDirectory”。 • 在导出作业中，支持修改启动的 map 数量“-extractors”、从 HDFS 导出时

参数名称	描述
	的输入路径“-inputDirectory”和导出作业的文件过滤条件“-fileFilter”。 指定参数值为“hbase”表示 MRS 端使用 HBase。在导入作业和导出作业中，支持修改启动的 map 数量“-extractors”。

----结束

任务实例

- 不更新作业参数，直接运行名称为“sftp-hdfs”的作业。

  ./submit_job.sh -n sftp-hdfs -u n

- 更新名称为“sftp-hdfs”导入作业的输入路径、编码类型、后缀、输出路径和启动的 map 数量参数，并运行作业。

  ./submit_job.sh -n sftp-hdfs -u y -jobType import -connectorType sftp -inputPath /opt/tempfile/1 -encodeType UTF-8 -suffixName '' -frameworkType hdfs -outputDirectory /user/user1/tttest -extractors 10

- 更新名称为“db-hdfs”导入作业的数据库模式、表名、输出路径参数，并运行作业。

  ./submit_job.sh -n db-hdfs -u y -jobType import -connectorType rdb -schemaName public -tableName sq_submission -sql '' -partitionColumn sqs_id -frameworkType hdfs -outputDirectory /user/user1/dbdbt

17.9.2 loader-tool 工具使用指导

概述

loader-tool 工具是 Loader 客户端工具之一，包括“lt-ucc”、“lt-ucj”、“lt-ctl”三个工具。

Loader 支持通过参数选项或作业模板这两种方式，对连接器进行创建、更新、查询和删除，以及对 Loader 作业进行创建、更新、查询、删除、启动和停止等操作。

说明

loader-tool 工具是异步接口，命令提交后其结果不会实时返回到控制台，因此对连接器的创建、更新、查询和删除等操作，以及对 Loader 作业的创建、更新、查询、删除、启动和停止等操作，其成功与否需要在 Loader WebUI 确认或通过查询 server 端日志确认。

- 参数选项方式：

  通过直接添加具体配置项的参数调用脚本。

- 作业模板方式：

  修改作业模板中所有配置项的参数值，调用脚本时引用修改后的作业模板文件。

Loader 客户端安装后，系统自动在“*Loader 客户端安装目录*/loader-tools-1.99.3/loader-tool/job-config/”目录生成各种场景对应的作业模板，不同模板中配置项存在差异。作业模板中包含作业信息以及关联的连接器信息。

作业模板为 xml 文件，文件名格式为“*数据原保存位置*-to-*数据新保存位置*.xml”，例如“sftp-to-hdfs.xml”。如果此场景的作业支持转换步骤，则存在同名的转换步骤配置文件，文件类型为 json，例如“sftp-to-hdfs.json”。

说明

作业模板中包含了连接器的配置信息。创建、更新连接器时，实际上仅调用到作业模板中的连接器的信息。

使用场景

不同的连接器或作业的配置项不同。

- 更新个别配置项时，使用参数选项方式。
- 创建连接器或作业时，使用作业模板方式。

说明

本工具目前支持 FTP、HDFS、JDBC、MySQL、Oracle 以及 Oracle 专用连接器，如果使用其他类型连接器，建议使用开源 sqoop-shell 工具。

参数说明

例如，Loader 客户端的安装目录为：“/opt/client/Loader/”。

- **lt-ucc 使用说明**

  lt-ucc：loader-tool user-configuration-connection 连接器配置工具，用于连接器的创建、更新和删除操作。

表17-125 lt-ucc 脚本“参数选项”说明

参数选项	说明	参数值示例
-help	获取帮助信息。	-
-a <arg>	执行的动作，有效值：create/update/delete，分别用于创建、更新和删除连接器。	create
-at <arg>	登录认证的类型，有效值 kerberos、simple。	kerberos
-uk <arg>	是否使用 keytab 文件。	true
-au <arg>	登录认证的用户名。	bar
-ap <arg>	登录认证的密码，需要填写密文。 密码加密方法： **sh** *Loader 客户端安装目录*/**Loader/loader-tools-1.99.3/encrypt_tool** *用户非加密密码* **说明** 非加密密码中含有特殊字符时需要转义。例如，	-

参数选项	说明	参数值示例
	$符号属于特殊字符，可使用单引号进行转义；非加密密码中含有单引号时可用双引号进行转义，非加密密码中含有双引号应使用反斜杠\进行转义。可参考 Shell 的转义字符规则。	
-c <arg>	登录认证的 principal。	bar
-k <arg>	登录认证的 keytab 文件。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/hadoop-config/user.keytab
-h <arg>	MRS 集群的配置文件路径。	-h /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/hadoop-config
-l <arg>	登录的模板文件。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml
-s <arg>	Loader 服务的浮动 IP 和端口。 格式为：*浮动 IP:端口* 端口默认值为 21351	127.0.0.1:21351
-w <arg>	作业的模板文件路径，用于获取作业的详细信息。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml
-z <arg>	ZooKeeper quorum 实例的 IP 地址和端口号，格式为 *IP 地址:端口*，配置多个用“,”分开。	127.0.0.0:2181,127.0.0.1:2181
-n <arg>	连接器名称。	vt_sftp_test
-t <arg>	连接器类型。	sftp-connector
-P <arg>	更新某个属性的值，格式：-Pparam1=value1，param1 为作业模板中连接器对应的属性名称。如果更新的是 SFTP 和 FTP 的连接器信息，还必须带上密码参数： -Pconnection.sftpPassword=*密码密文*	-Pconnection.sftpServerIp=10.6.26.11

完整示例如下：

./bin/lt-ucc -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -n vt_sftp_test -t sftp-connector -Pconnection.sftpPassword=*密码密文* **-Pconnection.sftpServerIp=10.6.26.111 -a update**

lt-ucc 脚本的作业模板配置说明：

以 SFTP 数据保存到 HDFS 为例，编辑“*loader 客户端安装目录*/loader-tools-1.99.3/loader-tool/job-config/”目录下的“sftp-to-hdfs.xml”文件，连接器的配置如下：

```
<!-- 连接数据库的信息 -->
<sqoop.connection name="vt_sftp_test" type="sftp-connector">
<connection.sftpServerIp>10.96.26.111</connection.sftpServerIp>
<connection.sftpServerPort>22</connection.sftpServerPort>
<connection.sftpUser>root</connection.sftpUser>
<connection.sftpPassword>密码密文</connection.sftpPassword>
</sqoop.connection>
```

- 创建命令，如下：

  ./lt-ucc -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -w /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/ftp-to-hdfs.xml -a create

- 更新命令，如下：

  ./lt-ucc -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -w /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/ftp-to-hdfs.xml -a update

- 删除命令，如下：

  ./lt-ucc -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -w /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/ftp-to-hdfs.xml -a delete

- **lt-ucj 使用说明**

  lt-ucj：loader-tool user-configuration-job 作业配置工具，用于对作业的创建、更新、删除操作。

表17-126 lt-ucj 脚本的“参数选项”配置说明

参数选项	说明	参数值示例
-help	获取帮助信息。	-
-a <arg>	执行的动作，有效值：create/update/delete，分别用于创建、更新和删除作业。	create
-at <arg>	登录认证的类型，有效值 kerberos、simple。	kerberos
-uk <arg>	是否使用 keytab 文件。	true
-au <arg>	登录认证的用户名。	bar
-ap <arg>	登录认证的密码，需要填写密文。 密码加密方法： **sh** *Loader 客户端安装目录* **/Loader/loader-tools-1.99.3/encrypt_tool** *用户非加密密码*	-

参数选项	说明	参数值示例
	说明 非加密密码中含有特殊字符时需要转义。例如，$符号属于特殊字符，可使用单引号进行转义；非加密密码中含有单引号时可用双引号进行转义，非加密密码中含有双引号应使用反斜杠\进行转义。可参考 Shell 的转义字符规则。	
-c <arg>	登录认证的 principal。	bar
-k <arg>	登录认证的 keytab 文件。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/hadoop-config/user.keytab
-h <arg>	MRS 集群的配置文件路径。	-h /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/hadoop-config
-l <arg>	登录的模板文件。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml
-s <arg>	Loader 服务的浮动 IP 和端口。 格式为：*浮动 IP:端口* 端口默认值为 21351。	127.0.0.1:21351
-w <arg>	作业的模板文件，用于获取作业的详细信息。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml
-z <arg>	ZooKeeper quorum 实例的 IP 地址和端口号，格式为 *IP 地址:端口*，配置多个用“,”分开。	127.0.0.0:2181,127.0.0.1:2181
-n <arg>	作业名称。	Sftp.to.Hdfs
-cn <arg>	连接器名称。	vt_sftp_test
-ct <arg>	连接器类型。	sftp-connector
-t <arg>	作业类型，有效值 IMPORT、EXPORT。	IMPORT
-trans <arg>	作业关联的转换步骤文件。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.json
-priority <arg>	作业优先级，有效值：LOW/NORMAL/HIGH。	NORMAL

参数选项	说明	参数值示例
-queue <arg>	队列。	default
-storageType <arg>	存储类型。	HDFS
-P <arg>	更新某个属性的值，格式：-Pparam1=value1，param1 为作业模板中连接器对应的属性名称。如果更新的是 SFTP 和 FTP 的连接器信息，还必须带上密码参数： -Pconnection.sftpPassword=*密码密文*	-Pconnection.sftpServerIp=10.6.26.11

完整示例如下：

./bin/lt-ucj -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -n Sftp.to.Hdfs -t IMPORT -ct sftp-connector -Poutput.outputDirectory=/user/loader/sftp-to-hdfs-test8888 -a update

lt-ucj 脚本的“作业模板”配置说明：

以 SFTP 数据保存到 HDFS 为例，编辑“*loader 客户端安装目录*/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml”，作业的配置如下：

```
<!-- Job 名称，全局唯一 -->
<sqoop.job name="Sftp.to.Hdfs" type="IMPORT" queue="default" priority="优先级NORMAL">

<!-- 外部数据源，参数配置 -->
<data.source connectionName="vt_sftp_test" connectionType="sftp-connector">
<file.inputPath>/opt/houjt/hive/all</file.inputPath>
<file.splitType>FILE</file.splitType>
<file.filterType>WILDCARD</file.filterType>
<file.pathFilter>*</file.pathFilter>
<file.fileFilter>*</file.fileFilter>
<file.encodeType>GBK</file.encodeType>
<file.suffixName></file.suffixName>
<file.isCompressive>FALSE</file.isCompressive>
</data.source>

<!-- MRS 集群，参数配置 -->
<hadoop.source storageType="HDFS" >
<output.outputDirectory>/user/loader/sftp-to-hdfs</output.outputDirectory>
<output.fileOprType>OVERRIDE</output.fileOprType>
<throttling.extractors>3</throttling.extractors>
<output.fileType>TEXT_FILE</output.fileType>
</hadoop.source>

<!-- 作业关联的转换步骤文件 -->
<sqoop.job.trans.file>/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.json</sqoop.job.trans.file>
</sqoop.job>
```

- 创建命令，如下：

  ./bin/lt-ucj -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -w /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml -a create

- 更新命令，如下：

  ./bin/lt-ucj -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -w /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml -a update

- 删除命令，如下：

  ./bin/lt-ucj -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -w /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml -a delete

- **lt-ctl 使用说明**

  lt-ctl：loader-tool controller 作业管理工具，用于启停作业，查询作业状态与进度，查询作业是否运行中。

表17-127 lt-ctl 脚本的“参数选项”配置说明

参数选项	说明	参数值示例
-help	获取帮助信息。	-
-a <arg>	执行的动作，有效值：status/start/stop/isrunning，分别用于查询作业状态、启动作业、停止作业以及判断作业是否在运行中。	create
-at <arg>	登录认证的类型，有效值 kerberos、simple。	kerberos
-uk <arg>	是否使用 keytab 文件。	true
-au <arg>	登录认证的用户名。	bar
-ap <arg>	登录认证的密码，需要填写密文。 密码加密方法： **sh** *Loader 客户端安装目录*/**Loader/loader-tools-1.99.3/encrypt_tool** *用户非加密密码* 说明 非加密密码中含有特殊字符时需要转义。例如，$符号属于特殊字符，可使用单引号进行转义；非加密密码中含有单引号时可用双引号进行转义，非加密密码中含有双引号应使用反斜杠\进行转义。可参考 Shell 的转义字符规则。	-
-c <arg>	登录认证的 principal。	bar
-k <arg>	登录认证的 keytab 文件。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/hadoop-config/user.keytab

参数选项	说明	参数值示例
-h <arg>	MRS 集群的配置文件路径。	-h /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/hadoop-config
-l <arg>	登录的模板文件。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml
-n <arg>	作业名称。	Sftp.to.Hdfs
-s <arg>	Loader 服务的浮动 IP 和端口。 格式为：*浮动 IP:端口* 端口默认值为 21351。	127.0.0.1:21351
-w <arg>	作业的模板文件，用于获取作业的详细信息。	/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml
-z <arg>	ZooKeeper quorum 实例的 IP 地址和端口号，格式为 *IP 地址:端口*，配置多个用“,”分开。	127.0.0.0:2181,127.0.0.1:2181

- 启动作业：

  ./bin/lt-ctl -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -n Sftp.to.Hdfs -a start
- 查看作业状态：

  ./bin/lt-ctl -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -n Sftp.to.Hdfs -a status
- 判断作业是否运行中：

  ./bin/lt-ctl -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -n Sftp.to.Hdfs -a isrunning
- 停止作业：

  ./bin/lt-ctl -l /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -n Sftp.to.Hdfs -a stop

17.9.3 loader-tool 工具使用示例

操作场景

loader-tool 工具支持通过作业模板或参数选项的方式，对连接器或者作业进行创建、更新、查询、删除等操作。

本文将以“从 SFTP 服务器导入数据到 HDFS”的作业为例，通过引用作业模板的方式，介绍 loader-tool 工具的使用方法。

前提条件

已安装并配置 Loader 客户端，具体操作请参见 17.9.1 使用命令行运行 Loader 作业。

操作步骤

使用安装客户端的用户登录客户端所在节点。

步骤 1 执行以下命令，进入 Loader 客户端的 loader-tool 工具目录。例如，Loader 客户端安装目录为“/opt/client/Loader/”。

cd /opt/client/Loader/loader-tools-1.99.3/loader-tool/

步骤 2 执行以下命令，修改已有的作业模板。例如，“/opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/”目录下已有的作业模板“sftp-to-hdfs.xml”。

vi /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml

```
<root>
<!-- 连接数据库的信息 -->
<sqoop.connection name="vt_sftp_test" type="sftp-connector">
<connection.sftpServerIp>10.96.26.111</connection.sftpServerIp>
<connection.sftpServerPort>22</connection.sftpServerPort>
<connection.sftpUser>root</connection.sftpUser>
<connection.sftpPassword>密码密文</connection.sftpPassword>
</sqoop.connection>

<!-- Job 名称，全局唯一 -->
<sqoop.job name="Sftp.to.Hdfs" type="IMPORT" queue="default" priority="NORMAL">
<data.source connectionName="vt_sftp_test" connectionType="sftp-connector">
<file.inputPath>/opt/houjt/hive/all</file.inputPath>
<file.splitType>FILE</file.splitType>
<file.filterType>WILDCARD</file.filterType>
<file.pathFilter>*</file.pathFilter>
<file.fileFilter>*</file.fileFilter>
<file.encodeType>GBK</file.encodeType>
<file.suffixName></file.suffixName>
<file.isCompressive>FALSE</file.isCompressive>
</data.source>

<hadoop.source storageType="HDFS" >
<output.outputDirectory>/user/loader/sftp-to-hdfs</output.outputDirectory>
<output.fileOprType>OVERRIDE</output.fileOprType>
<throttling.extractors>3</throttling.extractors>
<output.fileType>TEXT_FILE</output.fileType>
</hadoop.source>

<sqoop.job.trans.file></sqoop.job.trans.file>
</sqoop.job>
</root>
```

说明

Loader 每个作业都需要关联一个连接器，连接器主要作用：对于数据导入到集群的场景来说，就是从外部数据源读取数据；对于数据从集群导出去的场景来说，就是将数据写入到外部数据源。上述示例配置的是一个 SFTP 数据源连接器。配置 SFTP 和 FTP 的数据源连接器需要设置密码并进行加密。密码加密方法如下：

1. 执行以下命令，进入到 loader-tools-1.99.3 目录。Loader 客户端安装目录为“/opt/hadoopclient/Loader”。

   cd /opt/hadoopclient/Loader/loader-tools-1.99.3

2. 执行以下命令，对非加密密码加密。

   ./encrypt_tool *未加密的密码*

步骤 3 执行以下命令，进入 loader-tool 工具目录。

cd /opt/client/Loader/loader-tools-1.99.3/loader-tool

步骤 4 执行以下命令，使用 lt-ucc 工具创建连接器。

./bin/lt-ucc -l /opt/client/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -w /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml -a create

如无报错信息，且显示如下信息，则表示创建连接器的任务提交成功。

```
User login success. begin to execute task.
```

步骤 5 执行以下命令，使用 lt-ucj 工具创建作业。

./bin/lt-ucj -l /opt/client/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -w /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/sftp-to-hdfs.xml -a create

如无报错信息，且显示如下信息，则表示创建作业的任务提交成功。

```
User login success. begin to execute task.
```

步骤 6 执行以下命令，使用 lt-ctl 工具提交作业。

./bin/lt-ctl -l /opt/client/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -n Sftp.to.Hdfs -a start

显示如下信息，表示作业提交成功。

```
Start job success.
```

步骤 7 执行以下命令，查看作业状态。

./bin/lt-ctl -l /opt/client/Loader/loader-tools-1.99.3/loader-tool/job-config/login-info.xml -n Sftp.to.Hdfs -a status

```
Job:Sftp.to.Hdfs
Status:RUNNING
Progress: 0.0
```

----结束

17.9.4 schedule-tool 工具使用指导

概述

schedule-tool 工具，用于提交数据源为 SFTP 的作业。提交作业前可以修改输入路径、文件过滤条件，当目标源为 HDFS 时，可以修改输出路径。

参数说明

表17-128 schedule.properties 配置参数说明

配置参数	说明	示例
server.url	Loader 服务的浮动 IP 地址和端口。端口默认为 21351。 为了兼容性，此处支持配置多个 IP 地址和端口，并以“,”进行分隔。其中第一个必须是 Loader 服务的浮动 IP 地址和端口，其余的可根据业务需求配置。	10.96.26.111:21351,127.0.0.2:21351
authentication.type	登录认证的方式。 • “kerberos”，表示使用安全模式，进行 Kerberos 认证。Kerberos 认证提供两种认证方式：密码和 keytab 文件。 • “simple”，表示使用普通模式，不进行 Kerberos 认证。	kerberos
authentication.user	普通模式或者使用密码认证方式时，登录使用的用户。 keytab 登录方式，则不需要设置该参数。	bar
authentication.password	使用密码认证方式时，登录使用的用户密码。普通模式或者 keytab 登录方式，则不需要设置该参数。 用户需要对密码加密，加密方法如下： 1. 进入“encrypt_tool”所在目录。例如，Loader 客户端安装目录为“/opt/hadoopclient/Loader”，则执行如下命令。 **cd /opt/hadoopclient/Loader/loader-tools-1.99.3** 2. 执行以下命令，对非加密密码进行加密。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。 **./encrypt_tool** *未加密的密码* 得到加密后的密文，作为“authentication.password”的取	-

配置参数	说明	示例
	值。 说明 非加密密码中含有特殊字符时需要转义。例如，$符号属于特殊字符，可使用单引号进行转义；非加密密码中含有单引号时可用双引号进行转义，非加密密码中含有双引号应使用反斜杠\进行转义。可参考 Shell 的转义字符规则。	
use.keytab	是否使用 keytab 方式登录。 • true，表示使用 keytab 文件登录 • false，表示使用密码登录。	true
client.principal	使用 keytab 认证方式时，访问 Loader 服务的用户规则。 普通模式或者密码登录方式，则不需要设置该参数。	loader/hadoop.<*系统域名*> 说明 用户可登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。
client.keytab	使用 keytab 认证方式登录时，使用的 keytab 文件所在目录。 普通模式或者密码登录方式，则不需要设置该参数。	/opt/client/conf/loader.keytab
krb5.conf.file	使用 keytab 认证方式登录时，使用的 krb5.conf 文件所在目录。 普通模式或者密码登录方式，则不需要设置该参数。	/opt/client/conf/krb5.conf

表17-129 job.properties 配置参数说明

配置参数	说明	示例
job.jobName	作业的名称。	job1
file.fileName.prefix	文件名的前缀。	table1
file.fileName.posfix	文件名的后缀。	.txt
file.filter	文件过滤器，通过匹配文件名来过滤文件。 • “true”， 表示用上面的前缀/后缀，来匹配输入路径下的所有文	true

配置参数	说明	示例
	件。详细使用，见最后示例。 • “false”，表示用上面的前缀/后缀，来匹配输入路径下的某一个文件。详细使用，见最后示例。	
date.day	顺延的天数，匹配导入文件的文件名中的日期。例如命令参数传入的日期是 20160202，顺延天数是 3，则匹配作业配置的输入路径中包含 20160205 日期字段的文件。详细使用见 17.9.5 schedule-tool 工具使用示例。	3
file.date.format	待导入文件的文件名中所包含的日志格式。	yyyyMMdd
parameter.date.format	调用脚本时，所输入的日期格式，一般保持与“file.date.format”一致。	yyyyMMdd
file.format.iscompressed	待导入的文件是否为压缩文件。	false
storage.type	存储类型。待导入文件最终保存的类型，分别有 HDFS、HBase、Hive 等。	HDFS

说明

schedule-tool 工具支持同时配置多个作业。配置多个作业时，表 17-129 中“job.jobName”、“file.fileName.prefix”、“file.fileName.posfix”参数需配置多个值，并且以“,”分隔。

注意事项

server.url 属性必须需要配置两个 IP 地址和端口的格式串，用“,”分隔。

17.9.5 schedule-tool 工具使用示例

操作场景

通过 Loader WebUI 或客户端工具 Loader-tool 创建好作业后，可使用 schedule-tool 工具执行作业。

前提条件

完成了 Loader 客户端的安装与配置，具体操作请参见 17.9.1 使用命令行运行 Loader 作业。

操作步骤

在 SFTP 服务器的“/opt/houjt/test03”路径中，创建多个以“table1”为前缀，“.txt”为后缀，中间为 yyyyMMdd 的日期格式的文件。

图17-92 示例

```
[root@C12-RHEL64-ZYL111 test03]# ll
total 36
-rw-r--r--. 1 root root 54 Feb 29 19:11 table120160221.txt
-rw-r--r--. 1 root root 54 Feb 29 19:11 table120160222.txt
-rw-r--r--. 1 root root 54 Feb 29 19:11 table120160223.txt
-rw-r--r--. 1 root root 54 Feb 29 19:11 table120160224.txt
-rw-r--r--. 1 root root 54 Feb 29 19:11 table120160225.txt
-rw-r--r--. 1 root root 54 Feb 29 19:11 table120160226.txt
-rw-r--r--. 1 root root 54 Feb 29 18:43 table120160227.txt
-rw-r--r--. 1 root root 54 Feb 29 19:11 table120160228.txt
-rw-r--r--. 1 root root 54 Feb 29 19:11 table120160229.txt
```

步骤 2 创建一个从 SFTP 服务器导入数据到 HDFS 的 Loader 作业，具体操作请参见 17.5.3 典型场景：从 SFTP 服务器导入数据到 HDFS/OBS。

步骤 3 使用安装客户端的用户登录客户端所在节点。

步骤 4 执行以下命令，进入 schedule-tool 工具的 conf 目录。例如，Loader 客户端安装目录为“/opt/client/Loader/”。

cd /opt/client/Loader/loader-tools-1.99.3/schedule-tool/conf

步骤 5 执行以下命令，编辑 schedule.properties 文件，配置登录方式。

vi schedule.properties

schedule-tool 工具支持两种登录方式，两者只能选一。详细参数请参见 17.9.4 schedule-tool 工具使用指导。配置文件中包含认证密码信息可能存在安全风险，建议当前场景执行完毕后删除相关配置文件或加强安全管理。

- 以密码方式登录，配置信息示例如下：

```
[server.url = 10.10.26.187:21351,127.0.0.2:21351]
[authentication.type = kerberos]
[use.keytab = false]
[authentication.user = admin]
# 密码明文存储存在安全风险，建议在配置文件或者环境变量中密文存放，使用时解密，确保安全
[authentication.password= xxx]
```

- 以 keytab 文件方式登录，配置信息示例如下：

```
[server.url = 10.10.26.187:21351,127.0.0.2:21351]
[authentication.type = kerberos]
[use.keytab = true]
[client.principal = bar]
[client.keytab = /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/hadoop-config/user.keytab]
[krb5.conf.file = /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/hadoop-config/krb5.conf]
```

步骤 6 执行以下命令，编辑 job.properties 文件，配置作业信息。

vi job.properties

```
#job name
job.jobName = sftp2hdfs-schedule-tool


#Whether to update the loader configuration parameters(File filter)£?This parameter
is used to match the import file name.Values are true or false.
#false means update.the file name which is get by schedule tool will be updated to
Loader configuration parameters (File filter).
#false means no update.the file name which is get by schedule tool will be updated
to Loader configuration parameters (import path).
file.filter = false


#File name = prefix + date + suffix
#Need to import the file name prefix
file.fileName.prefix=table1

#Need to import the file name suffixes
file.fileName.posfix=.txt

#Date Days.Value is an integer.
#According to the date and number of days to get the date of the import file.
date.day = 1

#Date Format.Import file name contains the date format.Format
Type£°yyyyMMdd,yyyyMMdd HHmmss,yyyy-MM-dd,yyyy-MM-dd HH:mm:ss
file.date.format = yyyyMMdd

#Date Format.Scheduling script execution. Enter the date format.
parameter.date.format = yyyyMMdd


#Whether the import file is a compressed format.Values ??are true or false.
#true indicates that the file is a compressed format£?Execution scheduling tool
will extract the files.false indicates that the file is an uncompressed.Execution
scheduling tool does not unpack.
file.format.iscompressed = false

#Hadoop storage type.Values are HDFS or HBase.
storage.type = HDFS
```

根据步骤 1 的所准备的数据，以文件 table120160221.txt 为例，过滤规则设置如下：

- 文件名的前缀
  file.fileName.prefix=table1
- 文件名的后缀
  file.fileName.posfix=.txt
- 文件名中包含的日期格式
  file.date.format = yyyyMMdd
- 调用脚本输入的日期参数

parameter.date.format = yyyyMMdd

- 顺延的天数

  date.day = 1

  例如，脚本传入的日期参数是 20160220，则通过加法计算，得到的结果是 20160221。

说明

如果执行的命令是 **./run.sh 20160220 /user/loader/schedule_01** 时，以上过滤规则会拼凑出一个字符串："table1"+"20160221"+.txt = table120160221.txt

步骤 7 根据 file.filter 的值，选择过滤规则。

- 精确匹配某一个文件，请执行步骤 8。
- 模糊匹配一系列文件，请执行步骤 9。

步骤 8 将 job.properties 文件中“file.filter”的值修改为“false”。

执行以下命令，运行作业，任务结束。

cd /opt/client/Loader/loader-tools-1.99.3/schedule-tool

./run.sh *20160220 /user/loader/schedule_01*

其中 *20160220* 为输入的日期，*/user/loader/schedule_01* 为输出的路径。

说明

通过以上过滤规则，拼凑得到的字符串“table120160221.txt”，会直接作为文件名，追加到作业配置的输入路径中。所以，作业只会处理唯一匹配到的文件“table120160221.txt”。

步骤 9 将 job.properties 文件中“file.filter”的值修改为“true”，“file.fileName.prefix”设置为“*”。

执行以下命令，运行作业，任务结束。

cd /opt/client/Loader/loader-tools-1.99.3/schedule-tool

./run.sh *20160220 /user/loader/schedule_01*

其中 *20160220* 为输入的日期，*/user/loader/schedule_01* 为输出的路径。

说明

通过以上过滤规则，拼凑到的字符串“*20160221.txt”，会作为文件过滤器的模糊匹配模式，在作业配置的输入路径下，所有符合“*20160221.txt”这个模式的文件都将被作业处理。

----结束

17.9.6 使用 loader-backup 工具备份作业数据

操作场景

通过 Loader WebUI 或客户端工具 loader-tool 创建好作业后，可使用 loader-backup 工具进行数据备份。

说明

- 仅有数据导出的 Loader 作业才支持数据备份。
- 此工具为 Loder 的内部接口，供上层组件 HBase 调用，只支持 HDFS 到 SFTP 的数据备份。

前提条件

完成了 Loader 客户端的安装与配置，具体操作请参见 17.9.1 使用命令行运行 Loader 作业。

操作步骤

使用安装客户端的用户登录客户端所在节点，具体操作请参见 17.9.1 使用命令行运行 Loader 作业。

步骤 1 执行以下命令，进入“backup.properties”文件所在目录。例如，Loader 客户端安装目录为 “/opt/client/Loader/”。

cd /opt/client/Loader/loader-tools-1.99.3/loader-backup/conf

步骤 2 执行以下命令，修改“backup.properties”文件的配置参数，参数具体说明如表 17-130 所示。

vi backup.properties

```
server.url = 10.0.0.1:21351,10.0.0.2:12000
authentication.type = kerberos
authentication.user =
authentication.password=
job.jobId = 1
use.keytab = true
client.principal = loader/hadoop
client.keytab = /opt/client/conf/loader.keytab
```

表17-130 配置参数说明

配置参数	说明	示例
server.url	Loader 服务的浮动 IP 地址和端口（21351）。 为了兼容性，此处支持配置多个 IP 地址和端口，并以“,”进行分隔。其中第一个必须是 Loader 服务的浮动 IP 地址和端口（21351），其余的可根据业务需求配置。	10.0.0.1:21351,10.0.0.2:12000
authentication.type	登录认证的方式。 • “kerberos”，表示使用安全模式，进行 Kerberos 认证。Kerberos 认证提供两种认证方式：密码和 keytab 文件。 • “simple”，表示使用普通模式，不进行 Kerberos 认证。	kerberos

配置参数	说明	示例
authentication.user	普通模式或者使用密码认证方式时，登录使用的用户。 keytab 登录方式，则不需要设置该参数。	bar
authentication.password	使用密码认证方式时，登录使用的用户密码。 普通模式或者 keytab 登录方式，则不需要设置该参数。 用户需要对密码加密，加密方法： 1. 进入“encrypt_tool”所在目录。例如，Loader 客户端安装目录为“/opt/hadoopclient/Loader”，则执行如下命令。 **cd /opt/hadoopclient/Loader/loader-tools-1.99.3** 2. 执行以下命令，对非加密密码进行加密。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。 **./encrypt_tool** *未加密的密码* 得到加密后的密文，作为“authentication.password”的取值。 **说明** 非加密密码中含有特殊字符时需要转义。例如，$符号属于特殊字符，可使用单引号进行转义；非加密密码中含有单引号时可用双引号进行转义，非加密密码中含有双引号应使用反斜杠\进行转义。可参考 Shell 的转义字符规则。	-
job.jobId	需要执行数据备份的作业 ID。 作业 ID 可通过登录 Loader webUI 在已创建的作业查看。	1
use.keytab	是否使用 keytab 方式登录。 • true，表示使用 keytab 文件登录 • false，表示使用密码登录。	true
client.principal	使用 keytab 认证方式时，访问 Loader 服务的用户规则。 普通模式或者密码登录方式，则不	loader/hadoop

配置参数	说明	示例
	需要设置该参数。	
client.keytab	使用 keytab 认证方式登录时，使用的 keytab 文件所在目录。 普通模式或者密码登录方式，则不需要设置该参数。	/opt/client/conf/loader.keytab

步骤 3 执行以下命令，进入备份脚本“run.sh”所在目录。例如，Loader 客户端安装目录为“/opt/hadoopclient/Loader”。

cd /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-backup

步骤 4 执行以下命令，运行备份脚本“run.sh”，进行 Loader 作业数据备份。系统将数据备份到作业的输出路径同一层目录。

./run.sh *备份数据的输入目录*

例如，备份数据的输入目录为“/user/hbase/”，作业的输出路径为/opt/client/sftp/sftp1，其中 sftp1 只起到一个占位符的作用。执行如下命令，数据将备份到 /opt/client/sftp/hbase 目录。

./run.sh /user/hbase/

----结束

17.9.7 开源 sqoop-shell 工具使用指导

概述

sqoop-shell 是一个开源的 shell 工具，其所有功能都是通过执行脚本“sqoop2-shell”来实现的。

sqoop-shell 工具提供了如下功能：

- 支持创建和更新连接器
- 支持创建和更新作业
- 支持删除连接器和作业
- 支持以同步或异步的方式启动作业
- 支持停止作业
- 支持查询作业状态
- 支持查询作业历史执行记录
- 支持复制连接器和作业
- 支持创建和更新转换步骤
- 支持指定行、列分隔符

sqoop-shell 工具支持如下模式：

- 交互模式

  通过执行不带参数的“sqoop2-shell”脚本，进入 Loader 特定的交互窗口，用户输入脚本后，工具会返回相应信息到交互窗口。

- 批量模式

  通过执行“sqoop2-shell”脚本，带一个文件名作为参数，该文件中按行存储了多条命令，sqoop-shell 工具将会按顺序执行文件中所有命令；或者在“sqoop2-shell”脚本后面通过“-c”参数附加一条命令，一次只执行一条命令。

sqoop-shell 通过表 17-131 的命令来实现 Loader 各种功能。

表17-131 命令一览表

命令	说明
exit	表示退出交互模式。 该命令仅支持交互模式。
history	查看执行过的命令。 该命令仅支持交互模式。
help	查看工具帮助信息。
set	设置服务端属性。
show	显示服务属性和 Loader 所有元数据信息。
create	创建连接器和作业。
update	更新连接器和作业。
delete	删除连接器和作业。
clone	复制连接器和作业。
start	启动作业。
stop	停止作业。
status	查询作业状态。

命令参考

- sqoop2-shell 有两种获取登录认证信息的方式，第一种通过配置文件获取，具体配置项请参考 17.9.8 开源 sqoop-shell 工具使用示例（SFTP - HDFS）、17.9.9 开源 sqoop-shell 工具使用示例（Oracle - HBase）；第二种方式则使用参数直接提供认证信息，这个方式有两种模式：密码模式和 Kerberos 认证模式。
- 进入交互模式命令

  通过执行不带参数的“sqoop2-shell”脚本，进入 sqoop 工具窗口，逐条执行命令。

  通过读取配置文件获取认证信息：

./sqoop2-shell

通过密码模式认证：

./sqoop2-shell -uk false -u *username* **-p** *encryptedPassword*

命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的history 命令记录功能，避免信息泄露。

通过 Kerberos 模式认证：

./sqoop2-shell -uk true -k *user.keytab* **-s** *userPrincipal*

系统显示如下信息：

```
Welcome to sqoop client
Use the username and password authentication mode
Authentication success.
Sqoop Shell: Type 'help' or '\h' for help.

sqoop:000>
```

- 进入批量模式命令

  进入批量模式有两种方式：

  1.通过执行“sqoop2-shell”脚本，带一个文本文件名作为参数，该文件中按行存储了多条命令，工具会按顺序执行该文件中的所有命令。使用这种方式有个限制条件，这个 sh 脚本必须放到当前用户的家目录下，如：/root/batchCommand.sh。

  通过读取配置文件进行认证：

  ./sqoop2-shell */root/batchCommand.sh*

  通过密码模式认证：

  ./sqoop2-shell -uk false -u *username* **-p** *encryptedPassword /root/batchCommand.sh*

  命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的history 命令记录功能，避免信息泄露。

  通过 Kerberos 模式认证：

  ./sqoop2-shell -uk true -k *user.keytab* **-s** *userPrincipal /root/batchCommand.sh*

  其中 *batchCommand.sh* 为用户自定义文本文件名称。

  2.通过执行“sqoop2-shell”脚本，在脚本后面通过“-c”参数附带一条命令，工具将执行该条命令。

  通过取配置文件进行认证：

  ./sqoop2-shell *-c expression*

  通过密码模式认证：

  ./sqoop2-shell -uk false -u *username* **-p** *encryptedPassword -c expression*

  通过 Kerberos 模式认证：

  ./sqoop2-shell -uk true -k *user.keytab* **-s** *userPrincipal -c expression*

  其中 *expression* 为附带的语句，其格式和第一种方式中的文本内语句格式一致。

- exit 命令

  该命令用于退出交互模式，仅在交互模式支持。

  示例：

```
Welcome to sqoop client
Use the username and password authentication mode
```

```
Authentication success.
Sqoop Shell: Type 'help' or '\h' for help.

sqoop:000> exit
10-5-211-9:/opt/hadoopclient/Loader/loader-tools-1.99.3/sqoop-shell#
```

- history 命令

  该命令用于查看已执行的命令，仅在交互模式支持。

  示例：

```
sqoop:000> history
  0  show connector
  1  create connection -c 4
  2  show connections;
  3  show connection;
  4  show connection -a;
  5  show connections;
  6  show connection;
  7  show connection -x 53;
  8  show connection -x 52;
  9  show connection -x 2
 10  show connection -x 53;
 11  show connection
 12  show connection -x 53
 13  create job -x 53 -t import
 14  show connector
 15  create connection -c 5
 16  show connection -x 54
 17  exit
 18  show connector
 19  create connection -c 5
 20  exit
 21  show connector
 22  create connection -c 6
 23  create job -x 20 -t import
 24  start job -j 85 -s
 25  \x
 26  exit
 27  history
sqoop:000>
```

- help 命令

  该命令用于查看工具帮助信息。

  示例：

```
sqoop:000> help
For information about Sqoop, visit:
http://sqoop.apache.org/docs/1.99.3/index.html

Available commands:
  exit    (\x  ) Exit the shell
  history (\H  ) Display, manage and recall edit-line history
  help    (\h  ) Display this help message
  set     (\st ) Set server or option Info
  show    (\sh ) Show server, connector, framework, connection, job, submission
or option Info
```

```
 create  (\cr ) Create connection or job Info
 delete  (\d  ) Delete connection or job Info
 update  (\up ) Update connection or job Info
 clone   (\cl ) Clone connection or job Info
 start   (\sta) Start job
 stop    (\stp) Stop job
 status  (\stu) Status job

For help on a specific command type: help command

sqoop:000>
```

- set 命令

  set 命令，用于设置客户端和服务端属性，支持如下属性：

  - server 表示设置服务端连接属性。

  说明

  当设置了-u 属性时，-h、-p、-w 被会忽略。

  - option 表示设置客户端属性。

  说明

  option 通过键值对来赋值，例如：**set option --name verbose --value true**。

属性类别	子属性	含义
server	-h,--host	服务 IP 地址
	-p,--port	服务端口
	-w,--webapp	Tomcat 应用名
	-u,--url	Sqoop 服务 URL
option	verbose	冗余模式，表示打印更多的信息
	poll-timeout	设置轮询超时时间

  示例：

```
set option --name verbose --value false
set server --host 10.0.0.1 --port 21351 --webapp loader
```

- show 命令

  该命令用于显示变量信息、存储元数据信息等。

属性类别	子属性	含义
server	-a,--all	显示所有 server 属性
	-p,--port	显示服务端口
	-w,--webapp	显示 Tomcat 应用名

属性类别	子属性	含义
	-h,--host	显示服务的 IP 地址
option	-name	显示指定名称的属性
connector	-a,--all	显示所有连接类型信息
	-c,--cid	显示指定 ID 的连接类型信息
framework	无	显示框架的元数据信息
connection	-a,--all	显示所有连接属性
	-x,--xid	显示指定 ID 的连接属性
	-n,--name	显示指定名称的连接属性
job	-a,--all	显示所有作业信息
	-j,--jid	显示指定 ID 的作业信息
	-n,--name	显示指定名称的作业信息
submission	-j,--jid	显示指定作业的提交记录
	-d,--detail	显示详细信息

示例：

```
show server -all
show option --name verbose
show connector -all
show framework
show connection -all
show connection -n sftp-example
show job -all
show job -j 1
show submission --jid 1
show submission --jid 1 -d
```

- create 命令

  该命令用于创建连接器或作业。

属性类别	子属性	含义
connection	-c,--cid	指定连接器类型的 ID
	-cn,--cname	指定连接器类型的名称
job	-x,--xid	指定连接器 ID
	-xn,--xname	指定连接器名称
	-t,--type	指定作业类型

属性类别	子属性	含义
		可选值： • import • export

- 交互模式下，根据界面的提示逐一输入属性值。

  创建连接器示例：

  ```
  create connection -c 1
  create connection -cn example
  ```

  创建作业示例：

  ```
  create job -x 1 -t import
  create job -xn job_example -t export
  ```

- 批量模式下，需要先执行如下命令查看具体的属性，再对属性赋值。

  create job -t import -x 1 --help

  执行该命令有两种方式：

  将命令保存到文本中，并在执行 sqoop-shell 脚本时将该文本作为附带参数：

  ./sqoop2-shell *batchCommand.sh*

  使用-c 参数，将需要执行的单条命令作为-c 参数的输入：

  ./sqoop2-shell *-c expression*

  可参考本节前文关于命令执行的描述。完整的命令语句可参考如下示例。

  创建连接器示例：

  ```
  create connection -c 4 --connector-connection-sftpPassword xxxxx --
  connector-connection-sftpServerIp 10.0.0.1 --connector-connection-
  sftpServerPort 22 --connector-connection-sftpUser root--name
  testConnection
  ```

  创建作业示例：

  ```
  create job -t import -x 1 --connector-file-inputPath /opt/tempfile --
  connector-file-fileFilter * --framework-output-outputDirectory
  /user/loader/1 --framework-output-storageType HDFS --framework-throttling-
  extractorSize 120 --framework-output-fileType TEXT FILE --connector-file-
  splitType FILE -queue default -priority low -name newJob
  ```

- 批量模式下，可以使用“-c”参数附带一条语句。

  创建连接器示例：

  ```
  ./sqoop2-shell -c "create connection -c 4 --connector-connection-
  sftpPassword xxxxx --connector-connection-sftpServerIp 10.0.0.1 --
  connector-connection-sftpServerPort 22 --connector-connection-sftpUser
  root--name testConnection"
  ```

- update 命令

  该命令用于更新连接器或作业。

属性类别	子属性	含义
connection	-x,--xid	指定连接器 ID

属性类别	子属性	含义
		说明 更新连接器一定要带上密码属性。
job	-j,--jid	指定作业 ID

- 交互模式

  更新连接器示例：

  ```
  update connection --xid 1
  ```

  更新作业示例：

  ```
  update job --jid 1
  ```

- 批量模式

  更新连接器示例：

  ```
  update connection -x 6 --connector-connection-sftpServerPort 21 - --name
  sfp_130--connector-connection-sftpPassword xxxx
  ```

  更新作业示例：

  示例 1：

  ```
  update job -jid 1 -name sftp2hdfs --connector-file-fileFilter *.txt
  ```

  示例 2：

  ```
  ./sqoop2-shell -uk true -k /opt/loader/user.keytab -s luser
  /opt/loader/testupdate.txt
  ./sqoop2-shell -uk true -k /opt/loader/user.keytab -s luser -c "update job
  --jid 24 --name oracle-hive --connector-table-sql 'SELECT * FROM
  range_example WHERE replace(datadt,\'-\',\'\')='20240801' and
  \${CONDITIONS}'"
  ```

说明

更新作业可以将需要更新的命令写在文件中，例如“/opt/loader/testupdate.txt”（文件名自定义），也可以以--connector-table-sql 来指定，后面跟随的 sqlcmd 需要用“'”单引号括起来，具体操作参考“更新作业示例-示例 2”。涉及的命令还有 connector-table-sql,connector-table-columns,connector-table-partitionColumn,connector-table-conditions,connector-table-queryCondition 等。

- delete 命令

  该命令用于删除连接器或作业。

属性类别	子属性	含义
connection	-x,--xid	指定连接器 ID
	-n,--name	指定连接器名称
job	-j,--jid	指定作业 ID
	-n,--name	指定作业名称

示例：

```
delete connection -x 1
delete connection --name abc
delete job -j 1
delete job -n qwerty
```

- clone 命令

  该命令用于复制连接器或作业。

属性类别	子属性	含义
connection	-x,--xid	指定连接器 ID **说明** 复制连接器需要输入密码和连接器名称。
job	-j,--jid	指定作业 ID

示例如下：

```
clone job -j 1
```

- start 命令

  该命令用于启动作业。

属性类别	子属性	含义
job	-j,--jid	指定作业 ID
	-n,--name	指定作业名称
	-s,--synchronous	是否同步

异步启动作业示例：

```
start job -j 1
start job -n abc
```

同步启动作业示例：

```
start job -j 1 -s
start job --name abc --synchronous
```

- stop 命令

  该命令用于停止作业。

属性类别	子属性	含义
job	-j,--jid	指定作业 ID
	-n,--name	指定作业名称

示例：

```
stop job -j 1
stop job -n abc
```

- status 命令

  该命令用于查询作业状态。

属性类别	子属性	含义
job	-j,--jid	指定作业 ID

查询状态时，可以使用“-s”参数，只查询作业的状态枚举。

示例：

```
status job -j 1
status job -j 1 -s
```

create 命令扩展属性

针对 HDFS 与 SFTP 服务器或 RDB 进行数据交换场景，MRS 在开源 sqoop-shell 工具的基础上对 create 命令属性进行扩展，以达到在创建作业时指定行、列分隔符及转换步骤的目的。

表17-132 create 命令扩展属性

属性	说明
fields-terminated-by	默认的列分割符。
lines-terminated-by	默认的行分割符。
input-fields-terminated-by	输入步骤的列分割符，当不指定时，默认等于 fields-terminated-by 的值。
input-lines-terminated-by	输入步骤的行分割符，当不指定时，默认等于 lines-terminated-by 的值。
output-fields-terminated-by	输出步骤的列分割符，当不指定时，默认等于 fields-terminated-by 的值。
output-lines-terminated-by	输出步骤的行分割符，当不指定时，默认等于 lines-terminated-by 的值。
trans	指定转换步骤，值为转换步骤文件所在的路径。当指定文件的相对路径时，默认为“sqoop2-shell”脚本所在路径下的文件。当配置了该属性，其他扩展属性都被忽略。

sqoop1 对接 MRS 服务

下载开源 Sqoop，http://www.apache.org/dyn/closer.lua/sqoo:p/1.4.7。

步骤 1 将下载好的 sqoop-1.4.7.bin__hadoop-2.6.0.tar.gz 包放入 MRS 集群 master 节点的 /opt/sqoop 目录下并解压。

tar zxvf sqoop-1.4.7.bin__hadoop-2.6.0.tar.gz

步骤 2 进入解压完成的目录，修改配置。

cd /opt/sqoop/sqoop-1.4.7.bin__hadoop-2.6.0/conf

cp sqoop-env-template.sh sqoop-env.sh

vi sqoop-env.sh

添加配置：

export HADOOP_COMMON_HOME=/opt/client/HDFS/hadoop

export HADOOP_MAPRED_HOME=/opt/client/HDFS/hadoop

export HIVE_HOME=/opt/Bigdata/MRS_1.9.X/install/FusionInsight-Hive-3.1.0/hive(请按照实际路径填写)

export HIVE_CONF_DIR=/opt/client/Hive/config

export HCAT_HOME=/opt/client/Hive/HCatalog

添加系统变量，将“SQOOP_HOME”添加到 PATH 中。

vi /etc/profile

添加以下信息：

export SQOOP_HOME=/opt/sqoop/sqoop-1.4.7.bin__hadoop-2.6.0

export PATH=$PATH:$SQOOP_HOME/bin

步骤 3 执行以下命令复制 jline-2.12.jar 文件到 lib 文件下。

cp /opt/share/jline-2.12/jline-2.12.jar /opt/sqoop/sqoop-1.4.7.bin__hadoop-2.6.0/lib

步骤 4 执行以下命令，在文件中添加下列配置。

vim $JAVA_HOME/jre/lib/security/java.policy

permission javax.management.MBeanTrustPermission "register";

步骤 5 执行以下命令，实现 sqoop1 对接 MRS 服务。

source /etc/profile

----结束

17.9.8 开源 sqoop-shell 工具使用示例（SFTP - HDFS）

操作场景

本文将以“从 SFTP 服务器导入数据到 HDFS”的作业为例，介绍如何分别在交互模式和批量模式下使用 sqoop-shell 工具进行创建和启动 Loader 作业。

前提条件

已安装并配置 Loader 客户端，具体操作请参见 17.9.1 使用命令行运行 Loader 作业。

交互模式示例

使用安装客户端的用户登录 Loader 客户端所在节点。

步骤 1 执行以下命令，进入 sqoop-shell 工具的“conf”目录。例如，Loader 客户端安装目录为“/opt/client/Loader/”。

cd /opt/client/Loader/loader-tools-1.99.3/sqoop-shell/conf

步骤 2 执行以下命令，配置认证信息。

vi client.properties

```
server.url=10.0.0.1:21351
# simple or kerberos
authentication.type=simple
# true or false
use.keytab=true

authentication.user=
authentication.password=

client.principal=hdfs/hadoop@<系统域名>

# keytab file
client.keytab.file=./conf/login/hdfs.keytab
```

说明

登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，“本端域”参数即为当前系统域名。

表17-133 配置参数说明

配置参数	说明	示例
server.url	Loader 服务的浮动 IP 地址和端口（21351）。 为了兼容性，此处支持配置多个 IP 地址和端口，并以“,”进行分隔。其中第一个必须是 Loader 服务的浮动 IP 地址和端口（21351），其余的可根据业务需求配置。	10.0.0.1:21351

配置参数	说明	示例
authentication.type	登录认证的方式。 • “kerberos”，表示使用安全模式，进行 Kerberos 认证。Kerberos 认证提供两种认证方式：密码和 keytab 文件。 • “simple”，表示使用普通模式，不进行 Kerberos 认证。	kerberos
authentication.user	普通模式或者使用密码认证方式时，登录使用的用户。 keytab 登录方式，则不需要设置该参数。	bar
authentication.password	使用密码认证方式时，登录使用的用户密码。 普通模式或者 keytab 登录方式，则不需要设置该参数。 用户需要对密码加密，加密方法： 1. 进入“encrypt_tool”所在目录。例如，Loader 客户端安装目录为“/opt/hadoopclient/Loader”，则执行如下命令。 **cd /opt/hadoopclient/Loader/loader-tools-1.99.3** 2. 执行以下命令，对非加密密码进行加密。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。 **./encrypt_tool** *未加密的密码* 得到加密后的密文，作为“authentication.password”的取值。 **说明** 非加密密码中含有特殊字符时需要转义。例如，$符号属于特殊字符，可使用单引号进行转义；非加密密码中含有单引号时可用双引号进行转义，非加密密码中含有双引号应使用反斜杠\进行转义。可参考 Shell 的转义字符规则。	-
use.keytab	是否使用 keytab 方式登录。 • true，表示使用 keytab 文件登录 • false，表示使用密码登录。	true

配置参数	说明	示例
client.principal	使用 keytab 认证方式时，访问 Loader 服务的用户规则。 普通模式或者密码登录方式，则不需要设置该参数。	loader/hadoop
client.keytab.file	使用 keytab 认证方式登录时，使用的 keytab 文件所在目录。 普通模式或者密码登录方式，则不需要设置该参数。	/opt/client/conf/loader.keytab

步骤 3 执行以下命令，进入交互模式。

source /opt/client/bigdata_env

cd /opt/client/Loader/loader-tools-1.99.3/sqoop-shell

./sqoop2-shell

上述命令通过读取配置文件获取认证信息。

也可以直接通过密码或者 Kerberos 认证。

使用密码进行认证：

./sqoop2-shell -uk false -u *username* **-p** *encryptedPassword*

命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

使用 Kerberos 认证：

./sqoop2-shell -uk true -k *user.keytab* **-s** *userPrincipal*

```
Welcome to sqoop client
Use the username and password authentication mode
Authentication success.
Sqoop Shell: Type 'help' or '\h' for help.

sqoop:000>
```

步骤 4 执行以下命令，查看当前连接器对应的 ID。

show connector

显示如下信息：

```
+----+----------------------------+----------------+--------------------------------
----------------------------------------+
| Id |          Name          |    Version     |                                Class
|
+----+----------------------------+----------------+--------------------------------
----------------------------------------+
| 1  | generic-jdbc-connector     | 2.0.6-SNAPSHOT |
org.apache.sqoop.connector.jdbc.GenericJdbcConnector              |
```

```
| 2  | ftp-connector            | 2.0.5-SNAPSHOT |
org.apache.sqoop.connector.ftp.FtpConnector                      |
| 3  | hdfs-connector           | 2.0.5-SNAPSHOT |
org.apache.sqoop.connector.hdfs.HdfsConnector                    |
| 4  | oracle-connector         | 2.0.1-SNAPSHOT |
org.apache.sqoop.connector.oracle.OracleConnector                |
| 5  | mysql-fastpath-connector  | 2.0.1-SNAPSHOT |
org.apache.sqoop.connector.mysql.MySqlConnector                  |
| 6  | sftp-connector           | 2.0.5-SNAPSHOT |
org.apache.sqoop.connector.sftp.SftpConnector                    |
| 7  | oracle-partition-connector | 2.0.6-SNAPSHOT |
org.apache.sqoop.connector.oracle.partition.OraclePartitionConnector |
+----+----------------------------+----------------+------------------------------
----------------------------------------+
```

根据如上信息，可知 SFTP 连接器类型 ID 为 6。

步骤 5 执行如下命令，创建连接器，根据提示输入具体的连接器信息。

create connection -c *连接器类型 ID*

例如，连接器类型的 ID 为 6，则执行如下命令：

create connection -c 6

```
sqoop:000> create connection -c 6
Creating connection for connector with id 6
Please fill following values to create new connection object
Name: sftp14

Connection configuration

Sftp server IP: 10.0.0.1
Sftp server port: 22
Sftp user name: root
Sftp password: ************
Sftp public key:
New connection was successfully created with validation status FINE and persistent
id 20
sqoop:000>
```

根据如上信息，可知连接器 ID 为 20。

步骤 6 根据连接器 ID，执行如下命令，创建作业。

create job -x *连接器 ID* **-t import**

例如，连接器 ID 为 20，则执行如下命令：

create job -x 20 -t import

显示如下信息：

```
Creating job for connection with id 20
Please fill following values to create new job object
Name: sftp-hdfs-test

File configuration
```

```
Input path: /opt/tempfile
File split type:
  0 : FILE
  1 : SIZE
Choose: 0
Filter type:
  0 : WILDCARD
  1 : REGEX
Choose: 0
Path filter: *
File filter: *
Encode type:
Suffix name:
Compression:

Output configuration

Storage type:
  0 : HDFS
  1 : HBASE_BULKLOAD
  2 : HBASE_PUTLIST
  3 : HIVE
Choose: 0
File type:
  0 : TEXT_FILE
  1 : SEQUENCE_FILE
  2 : BINARY_FILE
Choose: 0
Compression format:
  0 : NONE
  1 : DEFAULT
  2 : DEFLATE
  3 : GZIP
  4 : BZIP2
  5 : LZ4
  6 : SNAPPY
Choose:
Output directory: /user/loader/test
File operate type:
  0 : OVERRIDE
  1 : RENAME
  2 : APPEND
  3 : IGNORE
  4 : ERROR
Choose: 0

Throttling resources

Extractors: 2
Extractor size:
New job was successfully created with validation status FINE  and persistent id 85
sqoop:000>
```

根据如上信息，可知作业 ID 为 85。

步骤 7 执行以下命令，启动作业。

start job -j *作业 ID* **-s**

例如，作业 ID 为 85，则执行如下命令：

start job -j 85 -s

显示“SUCCEEDED”信息，则说明作业启动成功。

```
Submission details
Job ID: 85
Server URL: https://10.0.0.0:21351/loader/
Created by: admin
Creation date: 2016-07-20 16:25:38 GMT+08:00
Lastly updated by: admin
2016-07-20 16:25:38 GMT+08:00: BOOTING  - Progress is not available
2016-07-20 16:25:46 GMT+08:00: BOOTING  - 0.00 %
2016-07-20 16:25:53 GMT+08:00: BOOTING  - 0.00 %
2016-07-20 16:26:08 GMT+08:00: RUNNING  - 90.00 %
2016-07-20 16:26:08 GMT+08:00: RUNNING  - 90.00 %
2016-07-20 16:26:27 GMT+08:00: SUCCEEDED
```

----结束

批量模式示例

使用安装客户端的用户登录 Loader 客户端所在节点。

步骤 1 执行以下命令，进入 sqoop-shell 工具的“conf”目录。例如，Loader 客户端安装目录为“/opt/client/Loader/”。

cd /opt/client/Loader/loader-tools-1.99.3/sqoop-shell/conf

步骤 2 执行以下命令，配置认证信息。

vi client.properties

```
server.url=10.0.0.1:21351
# simple or kerberos
authentication.type=simple
# true or false
use.keytab=true

authentication.user=
authentication.password=

client.principal=hdfs/hadoop@<系统域名>

# keytab file
client.keytab.file=./conf/login/hdfs.keytab
```

表17-134 配置参数说明

配置参数	说明	示例
server.url	Loader 服务的浮动 IP 地址和端口（21351）。	10.0.0.1:21351

配置参数	说明	示例
	为了兼容性，此处支持配置多个 IP 地址和端口，并以“,”进行分隔。其中第一个必须是 Loader 服务的浮动 IP 地址和端口（21351），其余的可根据业务需求配置。	
authentication.type	登录认证的方式。 • “kerberos”，表示使用安全模式，进行 Kerberos 认证。Kerberos 认证提供两种认证方式：密码和 keytab 文件。 • “simple”，表示使用普通模式，不进行 Kerberos 认证。	kerberos
authentication.user	普通模式或者使用密码认证方式时，登录使用的用户。 keytab 登录方式，则不需要设置该参数。	bar
authentication.password	使用密码认证方式时，登录使用的用户密码。 普通模式或者 keytab 登录方式，则不需要设置该参数。 用户需要对密码加密，加密方法： 1. 进入“encrypt_tool”所在目录。例如，Loader 客户端安装目录为“/opt/hadoopclient/Loader”，则执行如下命令。 **cd /opt/hadoopclient/Loader/loader-tools-1.99.3** 2. 执行以下命令，对非加密密码进行加密。 **./encrypt_tool** *未加密的密码* 得到加密后的密文，作为“authentication.password”的取值。 **说明** 非加密密码中含有特殊字符时需要转义。例如，$符号属于特殊字符，可使用单引号进行转义；非加密密码中含有单引号时可用双引号进行转义，非加密密码中含有双引号应使用反斜杠\进行转义。可参考 Shell 的转义字符规则。	-
use.keytab	是否使用 keytab 方式登录。	true

配置参数	说明	示例
	• true，表示使用 keytab 文件登录 • false，表示使用密码登录。	
client.principal	使用 keytab 认证方式时，访问 Loader 服务的用户规则。 普通模式或者密码登录方式，则不需要设置该参数。	loader/hadoop
client.keytab.file	使用 keytab 认证方式登录时，使用的 keytab 文件所在目录。 普通模式或者密码登录方式，则不需要设置该参数。	/opt/client/conf/loader.keytab

步骤 3 执行以下命令，进入“sqoop2-shell”脚本所在目录，并在该目录下创建一个文本文件，例如“batchCommand.sh”。

cd /opt/client/Loader/loader-tools-1.99.3/sqoop-shell

vi batchCommand.sh

“batchCommand.sh”样例如下：

```
//查看参数
create connection -c 6 --help

//创建连接器
create connection -c 6 -name sftp-connection --connector-connection-sftpServerIp
10.0.0.1 --connector-connection-sftpServerPort 22 --connector-connection-sftpUser
root --connector-connection-sftpPassword xxxxx

//创建作业
create job -t import -x 20 --connector-file-inputPath /opt/tempfile --connector-
file-fileFilter * --framework-output-outputDirectory /user/loader/1 --framework-
output-storageType HDFS --framework-throttling-extractorSize 120 --framework-
output-fileType TEXT_FILE --connector-file-splitType FILE -name test

//启动作业
start job -j 85 -s
```

其中 xxxxx 为连接器密码。

步骤 4 执行如下命令，sqoop-shell 工具将依次执行上述命令。

./sqoop2-shell batchCommand.sh

也可以直接在命令里附带认证信息。

使用密码认证：

./sqoop2-shell -uk false -u *username* **-p** *encryptedPassword* **batchCommand.sh**

使用 Kerberos 认证：

./sqoop2-shell -uk true -k *user.keytab* **-s** *userPrincipal* **batchCommand.sh**

显示“SUCCEEDED”信息，则说明作业启动成功。

```
Welcome to sqoop client
Use the username and password authentication mode
Authentication success.
sqoop:000> create connection -c 6 --help
usage: Show connection parameters:
   --connector-connection-sftpPassword <arg>
   --connector-connection-sftpServerIp <arg>
   --connector-connection-sftpServerPort <arg>
   --connector-connection-sftpUser <arg>
   --framework-security-maxConnections <arg>
   --name <arg>
===> FINE
sqoop:000> create connection -c 6 -name sftp-connection --connector-connection-
sftpServerIp 10.0.0.1 --connector-connection-sftpServerPort 22 --connector-
connection-sftpUser root --connector-connection-sftpPassword xxxxx
Creating connection for connector with id 6
New connection was successfully created with validation status FINE and persistent
id 20
===> FINE
sqoop:000> create job -t import -x 20 --connector-file-inputPath /opt/tempfile --
connector-file-fileFilter * --framework-output-outputDirectory /user/loader/1 --
framework-output-storageType HDFS --framework-throttling-extractorSize 120 --
framework-output-fileType TEXT_FILE --connector-file-splitType FILE -name test
Creating job for connection with id 20
New job was successfully created with validation status FINE  and persistent id 85
===> FINE

Submission details
Job ID: 85
Server URL: https://10.0.0.0:21351/loader/
Created by: admin
Creation date: 2016-07-20 16:25:38 GMT+08:00
Lastly updated by: admin
2016-07-20 16:25:38 GMT+08:00: BOOTING  - Progress is not available
2016-07-20 16:25:46 GMT+08:00: BOOTING  - 0.00 %
2016-07-20 16:25:53 GMT+08:00: BOOTING  - 0.00 %
2016-07-20 16:26:08 GMT+08:00: RUNNING  - 90.00 %
2016-07-20 16:26:08 GMT+08:00: RUNNING  - 90.00 %
2016-07-20 16:26:27 GMT+08:00: SUCCEEDED
```

步骤 5 批处理模式下，使用-c 参数附带一条命令，sqoop-shell 可以一次只执行附带的这一条命令。

执行如下命令将创建连接器。

./sqoop2-shell -c "create connection -c 6 -name sftp-connection --connector-connection-sftpServerIp 10.0.0.1 --connector-connection-sftpServerPort 22 --connector-connection-sftpUser root --connector-connection-sftpPassword xxxxx"

可以在命令里直接附带认证信息。

使用密码认证：

./sqoop2-shell -uk false -u *username* **-p** *encryptedPassword* **-c "create connection -c 6 -name sftp-connection --connector-connection-sftpServerIp 10.0.0.1 --connector-connection-sftpServerPort 22 --connector-connection-sftpUser root --connector-connection-sftpPassword xxxxx"**

使用 Kerberos 认证：

./sqoop2-shell -uk true -k *user.keytab* **-s** *userPrincipal* **-c "create connection -c 6 -name sftp-connection --connector-connection-sftpServerIp 10.0.0.1 --connector-connection-sftpServerPort 22 --connector-connection-sftpUser root --connector-connection-sftpPassword xxxxx"**

显示“FINE”信息，则说明连接创建成功。

```
Welcome to sqoop client
Use the username and password authentication mode
Authentication success.
sqoop:000> create connection -c 6 -name sftp-connection --connector-connection-
sftpServerIp 10.0.0.1 --connector-connection-sftpServerPort 22 --connector-
connection-sftpUser root --connector-connection-sftpPassword xxxxx
Creating connection for connector with id 6
New connection was successfully created with validation status FINE and persistent
id 20
===> FINE
```

----结束

17.9.9 开源 sqoop-shell 工具使用示例（Oracle - HBase）

操作场景

本文将以“从 Oracle 导入数据到 HBase”的作业为例，介绍如何分别在交互模式和批量模式下使用 sqoop-shell 工具进行创建和启动 Loader 作业。

前提条件

已安装并配置 Loader 客户端，具体操作请参见 17.9.1 使用命令行运行 Loader 作业。

交互模式示例

使用安装客户端的用户登录 Loader 客户端所在节点。

步骤 1 执行以下命令，进入 sqoop-shell 工具的“conf”目录。例如，Loader 客户端安装目录为“/opt/client/Loader/”。

cd /opt/client/Loader/loader-tools-1.99.3/sqoop-shell/conf

步骤 2 执行以下命令，配置认证信息。

vi client.properties

```
server.url=10.0.0.1:21351
# simple or kerberos
authentication.type=simple
# true or false
```

```
use.keytab=true

authentication.user=
authentication.password=

client.principal=oracle/hadoop@<系统域名>

# keytab file
client.keytab.file=./conf/login/oracle.keytab
```

说明

登录 FusionInsight Manager，选择“系统 > 权限 > 域和互信”，“本端域”参数即为当前系统域名。

表17-135 配置参数说明

配置参数	说明	示例
server.url	Loader 服务的浮动 IP 地址和端口（21351）。 为了兼容性，此处支持配置多个 IP 地址和端口，并以“,”进行分隔。其中第一个必须是 Loader 服务的浮动 IP 地址和端口（21351），其余的可根据业务需求配置。	10.0.0.1:21351
authentication.type	登录认证的方式。 • “kerberos”，表示使用安全模式，进行 Kerberos 认证。Kerberos 认证提供两种认证方式：密码和 keytab 文件。 • “simple”，表示使用普通模式，不进行 Kerberos 认证。	kerberos
authentication.user	普通模式或者使用密码认证方式时，登录使用的用户。 keytab 登录方式，则不需要设置该参数。	bar
authentication.password	使用密码认证方式时，登录使用的用户密码。 普通模式或者 keytab 登录方式，则不需要设置该参数。 用户需要对密码加密，加密方法： 1. 进入“encrypt_tool”所在目录。例如，Loader 客户端安装目录为“/opt/hadoopclient/Loader”，则执行如下命令。 **cd /opt/hadoopclient/Loader/loader-**	-

配置参数	说明	示例
	tools-1.99.3 2. 执行以下命令，对非加密密码进行加密。命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。 **./encrypt_tool** *未加密的密码* 得到加密后的密文，作为“authentication.password”的取值。 说明 非加密密码中含有特殊字符时需要转义。例如，$符号属于特殊字符，可使用单引号进行转义；非加密密码中含有单引号时可用双引号进行转义，非加密密码中含有双引号应使用反斜杠\进行转义。可参考 Shell 的转义字符规则。	
use.keytab	是否使用 keytab 方式登录。 • true，表示使用 keytab 文件登录 • false，表示使用密码登录。	true
client.principal	使用 keytab 认证方式时，访问 Loader 服务的用户规则。 普通模式或者密码登录方式，则不需要设置该参数。	loader/hadoop
client.keytab.file	使用 keytab 认证方式登录时，使用的 keytab 文件所在目录。 普通模式或者密码登录方式，则不需要设置该参数。	/opt/client/conf/loader.keytab

步骤 3 执行以下命令，进入交互模式。

source /opt/client/bigdata_env

cd /opt/client/Loader/loader-tools-1.99.3/sqoop-shell

./sqoop2-shell

上述命令通过读取配置文件获取认证信息。

也可以直接通过密码或者 Kerberos 认证。

使用密码进行认证：

./sqoop2-shell -uk false -u *username* **-p** *encryptedPassword*

命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的history 命令记录功能，避免信息泄露。

使用 Kerberos 认证：

./sqoop2-shell -uk true -k *user.keytab* **-s** *userPrincipal*

```
Welcome to sqoop client
Use the username and password authentication mode
Authentication success.
Sqoop Shell: Type 'help' or '\h' for help.

sqoop:000>
```

执行以下命令，查看当前连接器对应的 ID。

show connector

显示如下信息：

```
| Id |          Name          |   Version    |                          Class
|
+----+------------------------+--------------+-------------------------------
---------------------------------------+
| 1  | generic-jdbc-connector    | 2.0.7-SNAPSHOT |
org.apache.sqoop.connector.jdbc.GenericJdbcConnector              |
| 2  | ftp-connector           | 2.0.5-SNAPSHOT |
org.apache.sqoop.connector.ftp.FtpConnector                      |
| 3  | hdfs-connector          | 2.0.5-SNAPSHOT |
org.apache.sqoop.connector.hdfs.HdfsConnector                    |
| 4  | oracle-connector        | 2.0.1-SNAPSHOT |
org.apache.sqoop.connector.oracle.OracleConnector                |
| 5  | mysql-fastpath-connector  | 2.0.1-SNAPSHOT |
org.apache.sqoop.connector.mysql.MySqlConnector                  |
| 6  | sftp-connector          | 2.0.6-SNAPSHOT |
org.apache.sqoop.connector.sftp.SftpConnector                    |
| 7  | oracle-partition-connector | 2.0.6-SNAPSHOT |
org.apache.sqoop.connector.oracle.partition.OraclePartitionConnector |
+----+------------------------+--------------+-------------------------------
---------------------------------------+
```

根据如上信息，可知 oracle 连接器类型 ID 为 4。

步骤 4 执行如下命令，创建连接器，根据提示输入具体的连接器信息。

create connection -c *连接器类型 ID*

例如，连接器类型的 ID 为 4，则执行如下命令：

create connection -c 4

```
sqoop:000> create connection -c 4
Creating connection for connector with id 4
Please fill following values to create new connection object
Name: oracle14

Oracle connection configuration

JDBC connection string: jdbc:oracle:thin:@189.120.84.106:1521:orcl
```

```
Username: oracledba
Password: **********
JDBC connection properties:
There are currently 0 values in the map:
entry#
New connection was successfully created with validation status FINE and persistent
id 3
sqoop:000>
```

根据如上信息，可知连接器 ID 为 3。

步骤 5 根据连接器 ID，执行如下命令，创建作业。

create job -x *连接器 ID* **-t import --trans** *job-config 目录的绝对路径*/**oracle-hbase.json**

例如，连接器 ID 为 3，则执行如下命令：

create job -x 3 -t import --trans /opt/hadoopclient/Loader/loader-tools-1.99.3/loader-tool/job-config/oracle-hbase.json

显示如下信息：

```
sqoop:000> create job -x 3 -t import --trans /opt/hadoopclient/Loader/loader-tools-
1.99.3/loader-tool/job-config/oracle-to-hbase.json
Creating job for connection with id 3
Please fill following values to create new job object
Name: run

Database target

Table name: test
Columns:
Conditions:
Data split method:
  0 : ROWID
  1 : PARTITION
Choose:
Table Partitions:
Data split allocation method:
  0 : ROUNDROBIN
  1 : SEQUENTIAL
  2 : RANDOM
Choose:
JDBC fetch size:

Output configuration

Storage type:
  0 : HDFS
  1 : HBASE_BULKLOAD
  2 : HBASE_PUTLIST
  3 : HIVE
  4 : SPARK
Choose: 1
HBase instance: HBase
Clear data before import : false
```

```
Throttling resources

Extractors: 10
Extractor size:
New job was successfully created with validation status FINE  and persistent id 7
sqoop:000>
```

根据如信息，而知作业 ID 为 7。

步骤 6 执行以下命令，启动作业。

start job -j *作业 ID* **-s**

例如，作业 ID 为 7，则执行如下命令：

start job -j 7 -s

显示“SUCCEEDED”信息，则说明作业启动成功。

```
Submission details
Job ID: 7
Server URL: https://10.0.0.0:21351/loader/
Created by: admintest
Creation date: 2019-12-04 16:37:34 CST
Lastly updated by: admintest
2019-12-04 16:37:34 CST: BOOTING  - Progress is not available
2019-12-04 16:37:42 CST: BOOTING  - 0.00 %
2019-12-04 16:37:42 CST: BOOTING  - 0.00 %
2019-12-04 16:37:57 CST: RUNNING  - 0.00 %
2019-12-04 16:38:12 CST: RUNNING  - 45.00 %
2019-12-04 16:38:12 CST: RUNNING  - 45.00 %
2019-12-04 16:38:27 CST: SUCCEEDED
```

----结束

批量模式示例

使用安装客户端的用户登录 Loader 客户端所在节点。

步骤 1 执行以下命令，进入 sqoop-shell 工具的“conf”目录。例如，Loader 客户端安装目录为“/opt/client/Loader/”。

cd /opt/client/Loader/loader-tools-1.99.3/sqoop-shell/conf

步骤 2 执行以下命令，配置认证信息。

vi client.properties

```
server.url=10.0.0.1:21351
# simple or kerberos
authentication.type=simple
# true or false
use.keytab=true

authentication.user=
authentication.password=

client.principal=hdfs/hadoop.<系统域名>@<系统域名>
```

```
# keytab file
client.keytab.file=./conf/login/hdfs.keytab
```

表17-136 配置参数说明

配置参数	说明	示例
server.url	Loader 服务的浮动 IP 地址和端口（21351）。 为了兼容性，此处支持配置多个 IP 地址和端口，并以“,”进行分隔。其中第一个必须是 Loader 服务的浮动 IP 地址和端口（21351），其余的可根据业务需求配置。	10.0.0.1:21351
authentication.type	登录认证的方式。 • “kerberos”，表示使用安全模式，进行 Kerberos 认证。Kerberos 认证提供两种认证方式：密码和 keytab 文件。 • “simple”，表示使用普通模式，不进行 Kerberos 认证。	kerberos
authentication.user	普通模式或者使用密码认证方式时，登录使用的用户。 keytab 登录方式，则不需要设置该参数。	bar
authentication.password	使用密码认证方式时，登录使用的用户密码。 普通模式或者 keytab 登录方式，则不需要设置该参数。 用户需要对密码加密，加密方法： 1. 进入“encrypt_tool”所在目录。例如，Loader 客户端安装目录为“/opt/hadoopclient/Loader”，则执行如下命令。 **cd /opt/hadoopclient/Loader/loader-tools-1.99.3** 2. 执行以下命令，对非加密密码进行加密。 **./encrypt_tool** *未加密的密码* 得到加密后的密文，作为“authentication.password”的取值。 **说明**	-

配置参数	说明	示例
	非加密密码中含有特殊字符时需要转义。例如，$符号属于特殊字符，可使用单引号进行转义-；非加密密码中含有单引号时可用双引号进行转义，非加密密码中含有双引号应使用反斜杠\进行转义。可参考 Shell 的转义字符规则。	
use.keytab	是否使用 keytab 方式登录。 • true，表示使用 keytab 文件登录。 • false，表示使用密码登录。	true
client.principal	使用 keytab 认证方式时，访问 Loader 服务的用户规则。 普通模式或者密码登录方式，则不需要设置该参数。	loader/hadoop
client.keytab.file	使用 keytab 认证方式登录时，使用的 keytab 文件所在目录。 普通模式或者密码登录方式，则不需要设置该参数。	/opt/client/conf/loader.keytab

步骤 3 执行以下命令，进入“sqoop2-shell”脚本所在目录，并在该目录下创建一个文本文件，例如“batchCommand.sh”。

cd /opt/client/Loader/loader-tools-1.99.3/sqoop-shell

vi batchCommand.sh

“batchCommand.sh”样例如下：

```
//查看参数
create connection -c 4 --help

//创建连接器
create connection -c 4 -name oracle-connection --connector-connection-
oracleServerIp 10.0.0.1 --connector-connection-oracleServerPort 22 --connector-
connection-oracleUser root --connector-connection-oraclePassword xxxxx

//创建作业
create job -t import -x 3 --connector-file-inputPath /opt/tempfile --connector-
file-fileFilter * --framework-output-outputDirectory /user/loader/1 --framework-
output-storageType HBase --framework-throttling-extractorSize 120 --framework-
output-fileType TEXT_FILE --connector-file-splitType FILE -name test

//启动作业
start job -j 7 -s
```

其中 xxxxx 为连接器密码。

步骤 4 执行如下命令，sqoop-shell 工具将依次执行上述命令。

./sqoop2-shell batchCommand.sh

也可以直接在命令里附带认证信息。

使用密码认证：

./sqoop2-shell -uk false -u *username* **-p** *encryptedPassword* **batchCommand.sh**

使用 Kerberos 认证：

./sqoop2-shell -uk true -k *user.keytab* **-s** *userPrincipal* **batchCommand.sh**

显示“SUCCEEDED”信息，则说明作业启动成功。

```
Welcome to sqoop client
Use the username and password authentication mode
Authentication success.
sqoop:000> create connection -c 4 --help
usage: Show connection viparameters:
   --connector-connection-oraclePassword <arg>
   --connector-connection-oracleServerIp <arg>
   --connector-connection-oracleServerPort <arg>
   --connector-connection-oracleUser <arg>
   --framework-security-maxConnections <arg>
   --name <arg>
===> FINE
sqoop:000> create connection -c 4 -name oracle-connection --connector-connection-
oracleServerIp 10.0.0.1 --connector-connection-oracleServerPort 22 --connector-
connection-oracleUser root --connector-connection-oraclePassword xxxxx
Creating connection for connector with id 4
New connection was successfully created with validation status FINE and persistent
id 3
===> FINE
sqoop:000> create job -t import -x 3 --connector-file-inputPath /opt/tempfile --
connector-file-fileFilter * --framework-output-outputDirectory /user/loader/1 --
framework-output-storageType HDFS --framework-throttling-extractorSize 120 --
framework-output-fileType TEXT_FILE --connector-file-splitType FILE -name test
Creating job for connection with id 3
New job was successfully created with validation status FINE  and persistent id 7
===> FINE
Submission details
Job ID: 7
Server URL: https://10.0.0.0:21351/loader/
Created by: admintest
Creation date: 2019-12-04 16:37:34 CST
Lastly updated by: admintest
2019-12-04 16:37:34 CST: BOOTING  - Progress is not available
2019-12-04 16:37:42 CST: BOOTING  - 0.00 %
2019-12-04 16:37:42 CST: BOOTING  - 0.00 %
2019-12-04 16:37:57 CST: RUNNING  - 0.00 %
2019-12-04 16:38:12 CST: RUNNING  - 45.00 %
2019-12-04 16:38:12 CST: RUNNING  - 45.00 %
2019-12-04 16:38:27 CST: SUCCEEDED
```

步骤 5 批处理模式下，使用-c 参数附带一条命令，sqoop-shell 可以一次只执行附带的这一条命令。

执行如下命令将创建连接器。

./sqoop2-shell -c "create connection -c 4 -name oracle-connection --connector-connection-oracleServerIp 10.0.0.1 --connector-connection-oracleServerPort 22 --connector-connection-oracleUser root --connector-connection-oraclePassword xxxxx"

可以在命令里直接附带认证信息。

使用密码认证：

./sqoop2-shell -uk false -u *username* **-p** *encryptedPassword* **-c "create connection -c 4 -name oracle-connection --connector-connection-oracleerverIp 10.0.0.1 --connector-connection-oracleServerPort 22 --connector-connection-oracleUser root --connector-connection-oraclePassword xxxxx"**

使用 Kerberos 认证：

./sqoop2-shell -uk true -k *user.keytab* **-s** *userPrincipal* **-c "create connection -c 4 -name oracle-connection --connector-connection-oracleServerIp 10.0.0.1 --connector-connection-oracleServerPort 22 --connector-connection-oracleUser root --connector-connection-oraclePassword xxxxx"**

显示“FINE”信息，则说明连接创建成功。

```
Welcome to sqoop client
Use the username and password authentication mode
Authentication success.
sqoop:000> create connection -c 4 -name oracle-connection --connector-connection-
oracleServerIp 10.0.0.1 --connector-connection-oracleServerPort 22 --connector-
connection-oracleUser root --connector-connection-oraclePassword xxxxx
Creating connection for connector with id 4
New connection was successfully created with validation status FINE and persistent
id 3
===> FINE
```

----结束

17.10 Loader 日志介绍

日志描述

日志存储路径：Loader 相关日志的默认存储路径为“/var/log/Bigdata/loader/日志分类”。

- runlog：“/var/log/Bigdata/loader/runlog”（运行日志）
- scriptlog：“/var/log/Bigdata/loader/scriptlog/”（脚本的执行日志）
- catalina：“/var/log/Bigdata/loader/catalina”（tomcat 的启停日志）
- audit： “/var/log/Bigdata/loader/audit”（审计日志）

日志归档规则：

Loader 的运行日志和审计日志，启动了自动压缩归档功能，默认情况下，当日志大小超过 10MB 的时候，会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”。最多保留最近的 20 个压缩文件，压缩文件保留个数可以在 Manager 界面中配置。

表17-137 Loader 日志列表

日志类型	日志文件名	描述
运行日志	loader.log	Loader 运行日志，记录 Loader 系统运行时候所产生的大部分日志。
	loader-omm-***-pid***-gc.log.*.current	Loader 进程 gc 日志
	sqoopInstanceCheck.log	Loader 实例健康检查日志
审计日志	default.audit	Loader 操作审计日志（例如：作业的增删改查、用户的登录）。
tomcat 日志	catalina.out	tomcat 的运行日志
	catalina. <yyyy-mm-dd >.log	tomcat 的运行日志
	host-manager. <yyyy-mm-dd >.log	tomcat 的运行日志
	localhost_access_log. <yyyy-mm-dd >.txt	tomcat 的运行日志
	manager <yyyy-mm-dd >.log	tomcat 的运行日志
	localhost. <yyyy-mm-dd >.log	tomcat 的运行日志
脚本日志	postInstall.log	Loader 安装脚本日志。 执行 loader 安装脚本（postInstall.sh）时产生的日志。
	preStart.log	Loader 服务的预启动脚本日志。Loader 服务启动时，需要先执行一系列的准备操作（preStart.sh），例如生成 keytab 文件等，该日志正是记录了这些操作信息。
	loader_ctl.log	Loader 执行服务启停脚本（sqoop.sh）的日志。

日志级别

Loader 中提供了如表 17-138 所示的日志级别，日志级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表17-138 日志级别

级别	描述
ERROR	ERROR 表示错误日志输出。
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示系统及系统调试信息。

如果您需要修改日志级别，请执行如下操作：

请参考 25.1 修改集群服务配置参数，进入 Loader 的“全部配置”页面。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别。

步骤 4 保存配置，在弹出窗口中单击“确定”，完成后重启服务使配置生效。

----结束

日志格式

Loader 的日志格式如下所示：

表17-139 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2015-06-29 14:54:35,553	INFO	[localhost-startStop-1]	ConnectionRequestHandler initialized	org.apache.sqoop.handler.ConnectionRequestHandler.<init>(ConnectionRequestHandler.java:100)
审计日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|default|<log 中的 message>|<日志事件的发生位置>	2015-06-29 15:35:40,969 INFO default: UserName=admin, UserIP=10.52.0.111, Time=2015-06-29 15:35:40,969, Operation=submit, Resource=submission@21, Result=Failure, Detail={[reason:GET_SFTP_SESSION_FAILED:Failed to get sftp session -

日志类型	格式	示例
		10.162.0.35 (caused by: Auth cancel)];[config:null]}

17.11 Loader 常见问题

17.11.1 IE 10&IE 11 浏览器无法保存数据

问题

通过 IE 10&IE 11 浏览器访问 Loader 界面，提交数据后，会报错。

回答

- 现象

  保存提交数据，出现类似报错：Invalid query parameter jobgroup id. cause: [jobgroup]。
- 原因

  IE 11 浏览器的某些版本在接收到 HTTP 307 响应时，会将 POST 请求转化为 GET 请求，从而使得 POST 数据无法下发到服务端。
- 解决建议

  使用 Google Chrome 浏览器。

17.11.2 将 Oracle 数据库中的数据导入 HDFS 时各连接器的区别

问题

使用 Loader 将 Oracle 数据库中的数据导入到 HDFS 中时，可选择的连接器有 generic-jdbc-connector、oracle-connector、oracle-partition-connector 三种，要怎么选？有什么区别？

答案

- generic-jdbc-connector

  使用 JDBC 方式从 Oracle 数据库读取数据，适用于支持 JDBC 的数据库。

  在这种方式下，Loader 加载数据的性能受限于分区列的数据分布是否均匀。当分区列的数据偏斜（数据集中在一个或者几个值）时，个别 Map 需要处理绝大部分数据，进而导致索引失效，造成 SQL 查询性能急剧下降。

  generic-jdbc-connector 支持视图的导入导出，而 oracle-partition-connector 和 oracle-connector 暂不支持，因此导入视图只能选择该连接器。
- oracle-partition-connector 和 oracle-connector

这两种连接器都支持按照 Oracle 的 ROWID 进行分区（oracle-partition-connector 是自研，oracle-connector 是社区开源版本），二者的性能较为接近。

oracle-connector 需要的系统表权限较多，下面是各自需要的系统表，需要赋予读权限。

- oracle-connector：dba_tab_partitions、dba_constraints、dba_tables、dba_segments、v$version、dba_objects、v$instance、SYS_CONTEXT 函数、dba_extents、dba_tab_subpartitions。
- oracle-partition-connector：DBA_OBJECTS、DBA_EXTENTS。

相比于 generic-jdbc-connector，oracle-partition-connector 和 oracle-connector 具有以下优点：

a. 负载均匀，数据分片的个数和范围与源表的数据无关，而是由源表的存储结构（数据块）确定，颗粒度可以达到“每个数据块一个分区”。

b. 性能稳定，完全消除“数据偏斜”和“绑定变量窥探”导致的“索引失效”。

c. 查询速度快，数据分片的查询速度比用索引快。

d. 水平扩展性好，如果数据量越大，产生的分片就越多，所以只要增加任务的并发数，就可以获得较理想的性能；反之，减少任务并发数，就可以节省资源。

e. 简化数据分片逻辑，不需要考虑“精度丢失”、“类型兼容”和“绑定变量”等问题。

f. 易用性得到增强，用户不需要专门为 Loader 创建分区列、分区表。

17.11.3 SQLServer 全数据类型导入 HDFS 数据跳过

问题

SQLServer 全数据类型导入 HDFS，数据全部跳过。

```
create table test(rtd1 varchar(20),rtd2 char(20),rtd3 smallint,rtd4 int,rtd5 bigint,rtd6 float,rtd8 decimal(10,3),rtd9 date,rtd10 timestamp,rtd12 binary(20));
insert into test values('ghikg\nhui','sa\tfsd',15.89734,9374293493,14.25,145.22,'2007-12-20',DEFAULT ,1110111);
select * from test;
```

答案

数据中包含 SQLServer 中特有的 Timestamp 类型，该数据类型与时间和日期无关，需要替换为 Datetime 类型。

17.11.4 大量数据写入 HDFS 时报错

问题

大量数据写入 HDFS 时偶现“NotReplicatedYet Exception: Not replicated yet”错误。

图17-93 报错信息

回答

以下原因可能造成该报错：

1. HDFS 客户端向 NameNode 发送新 Block 申请，由于 NameNode 来不及处理导致超时。
2. DataNode 增量上报太慢，NameNode 无法及时分配新的 Block。

出现该报错作业不会立即异常，在超过重试次数时才会通知作业异常。可以适当增大 HDFS 参数“dfs.client.block.write.retries”配置，例如：“dfs.client.block.write.retries=10”。

17.11.5 sftp-connector 连接器相关作业运行失败

问题

- 使用 sftp-connector 连接器相关作业运行失败，出现如下类似报错：“获取 Sftp 通道失败。*xxx* (原因是: failed to send channel request)”。
- SFTP 服务出现如下报错：“subsystem request failed on channel 0. Connection closed”。

图17-94 SFTP 服务报错

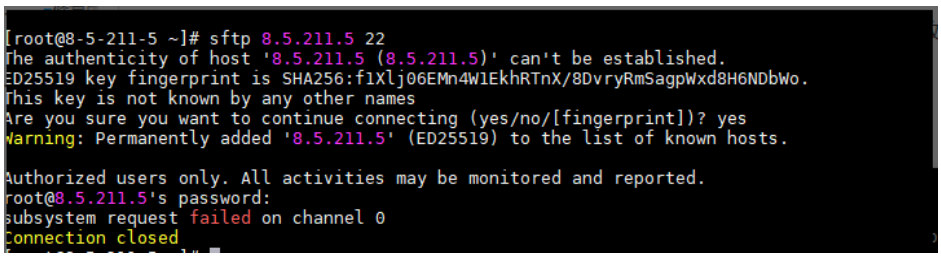

回答

该报错是由于未启用 SFTP 服务导致。

处理步骤

执行以下命令修改 sshd_config 配置，并保存退出。

cd /etc/ssh

vi sshd_config

Subsystem sftp /usr/libexec/openssh/sftp-server

图17-95 修改 sshd_config 文件

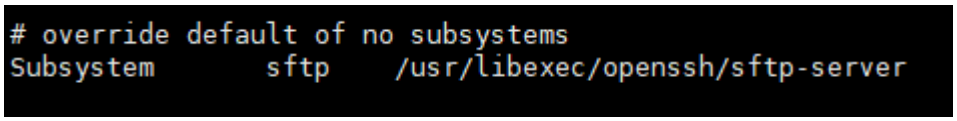

执行以下命令重启 SFTP 服务。

systemctl restart sshd.service

----结束

18 使用 Mapreduce

18.1 配置日志归档和清理机制

配置场景

执行一个 MapReduce 应用会产生两种类型日志文件：作业日志和任务日志。

- 作业日志由 MRApplicationMaster 产生，详细记录了作业启动时间、运行时间，每个任务启动时间、运行时间、Counter 值等信息。此日志内容被 HistoryServer 解析以后用于查看作业执行的详细信息。
- 任务日志记录了每个运行在 Container 中的任务输出的日志信息。默认情况下，任务日志只会存放在各 NodeManager 的本地磁盘上。打开日志聚合功能后，NodeManager 会在作业运行完成后将本地的任务日志进行合并，写入到 HDFS 中。

由于 MapReduce 的作业日志和任务日志（聚合功能开启的情况下）都保存在 HDFS 上。对于计算任务量大的集群，如果不进行合理的配置对日志文件进行定期归档和删除，日志文件将占用 HDFS 大量内存空间，增加集群负载。

日志归档是通过 Hadoop Archives 功能实现的，Hadoop Archives 启动的并行归档任务数（Map 数）与待归档的日志文件总大小有关。计算公式为：并行归档任务数=待归档的日志文件总大小/归档文件大小。

配置描述

进入 Mapreduce 服务参数“全部配置”界面，具体操作请参考 25.1 修改集群服务配置参数章节。

在搜索框中输入参数名称，修改并保存配置。然后在 Mapreduce 服务“概览”页面选择“更多 > 同步配置”。同步完成后重启 Mapreduce 服务。

- 作业日志参数：

表18-1 参数说明

参数	描述	默认值

参数	描述	默认值
mapreduce.jobhistory.cleaner.enable	是否开启作业日志文件清理功能。	true
mapreduce.jobhistory.cleaner.interval-ms	作业日志文件清理启动周期。只有保留时间比“mapreduce.jobhistory.max-age-ms”更长的日志文件才会被清除。	86400000（1天）
mapreduce.jobhistory.max-age-ms	比此项设置的毫秒数保留时间更长的作业日志文件将被清理。	1296000000（15天）

- 任务日志参数：

表18-2 参数说明

参数	描述	默认值
yarn.log-aggregation.archive.files.minimum	设置 Mapreduce 任务日志归档最小文件数。当“yarn.nodemanager.remote-app-log-dir”文件夹下文件数大于等于该设置的值时归档任务启动。	5000
yarn.log-aggregation.archive-check-interval-seconds	设置 Mapreduce 任务日志归档任务启动周期（秒）。只有日志文件数达到“yarn.log-aggregation.archive.files.minimum”设置值时日志文件才会被归档。周期设置为“0”或“-1”时归档功能禁用。	-1
yarn.log-aggregation.retain-seconds	设置 Mapreduce 任务日志在 HDFS 上的保留时间。设置为“-1”时日志文件永久保存。	1296000
yarn.log-aggregation.retain-check-interval-seconds	设置 Mapreduce 任务日志清理任务的检查周期（秒）。设置为“-1”时检查周期为日志保留时间的十分之一。	86400

说明

如果是任务日志将 HDFS 存储空间占用太多，主要修改上面的“mapreduce.jobhistory.max-age-ms”和“yarn.log-aggregation.retain-check-interval-seconds”配置项来控制任务日志保存时间。

18.2 降低客户端应用的失败率

配置场景

当网络不稳定或者集群 IO、CPU 负载过高的情况下，通过调整如下参数值，降低客户端应用的失败率，保证应用的正常运行。

配置描述

在客户端的“mapred-site.xml”配置文件中调整如下参数。

说明

“mapred-site.xml”配置文件在客户端安装路径的 conf 目录下，例如“/opt/client/Yarn/config”。

表18-3 参数说明

参数	描述	默认值
mapreduce.reduce.shuffle.max-host-failures	MR 任务在 reduce 过程中读取远端 shuffle 数据允许失败的次数。当设置次数大于 5 时，可以降低客户端应用的失败率。	5
mapreduce.client.submit.file.replication	MR 任务在运行时依赖的相关 job 文件在 HDFS 上的备份。当备份数大于 10 时，可以降低客户端应用的失败率。	10

18.3 将 MR 任务从 Windows 上提交到 Linux 上运行

配置场景

用户将 MapReduce 任务从 Windows 上提交到 Linux 上运行，则“mapreduce.app-submission.cross-platform”参数值需配置为“true”。若集群无此参数，或参数值为“false”，则表示集群不支持此功能，需要按照如下操作增加该参数或修改参数值进行开启。

配置描述

在客户端的“mapred-site.xml”配置文件中进行如下配置。“mapred-site.xml”配置文件在客户端安装路径的 config 目录下，例如“/opt/client/Yarn/config”。

表18-4 参数说明

参数	描述	默认值
mapreduce.app-submission.cross	支持在 Windows 上提交到 Linux 上运行 MR 任务的配置项。当该参数的值设为“true”时，表示支持。	true

参数	描述	默认值
-platform	当该参数的值设为“false”时，表示不支持。	

18.4 配置使用分布式缓存

配置场景

分布式缓存在两种情况下非常有用。

滚动升级

在升级过程中，应用程序必须保持文字内容（jar 文件或配置文件）不变。而这些内容并非基于当前版本的 YARN，而是要基于其提交时的版本。这是一个具有挑战性的问题。一般情况下，应用程序（例如 MapReduce、Hive、Tez 等）需要进行完整的本地安装，将库安装至所有的集群机器（客户端及服务器端机器）中。当集群内开始进行滚动升级或降级时，本地安装的库的版本必然会在应用运行过程时发生改变。在滚动升级过程中，首先只会对少数 NodeManager 进行升级，这些 NodeManager 会获得新版本的软件。这导致了行为的不一致，并可能发生运行时错误。

同时存在多个 YARN 版本

集群管理员可能会在一个集群内运行使用多个版本 YARN 及 Hadoop jars 的任务。这在当前很难实现，因为 jars 已被本地化且只有一个版本。

MapReduce 应用框架可以通过分布式缓存进行部署，且无需依赖安装中复制的静态版本。因此，可以在 HDFS 中存放多版本的 Hadoop，并通过配置“mapred-site.xml”文件指定任务默认使用的版本。只需设置适当的配置属性，用户就可以运行不同版本的 MapReduce，而无需使用部署在集群中的版本。

图18-1 具有多个版本 NodeManagers 及 Applications 的集群

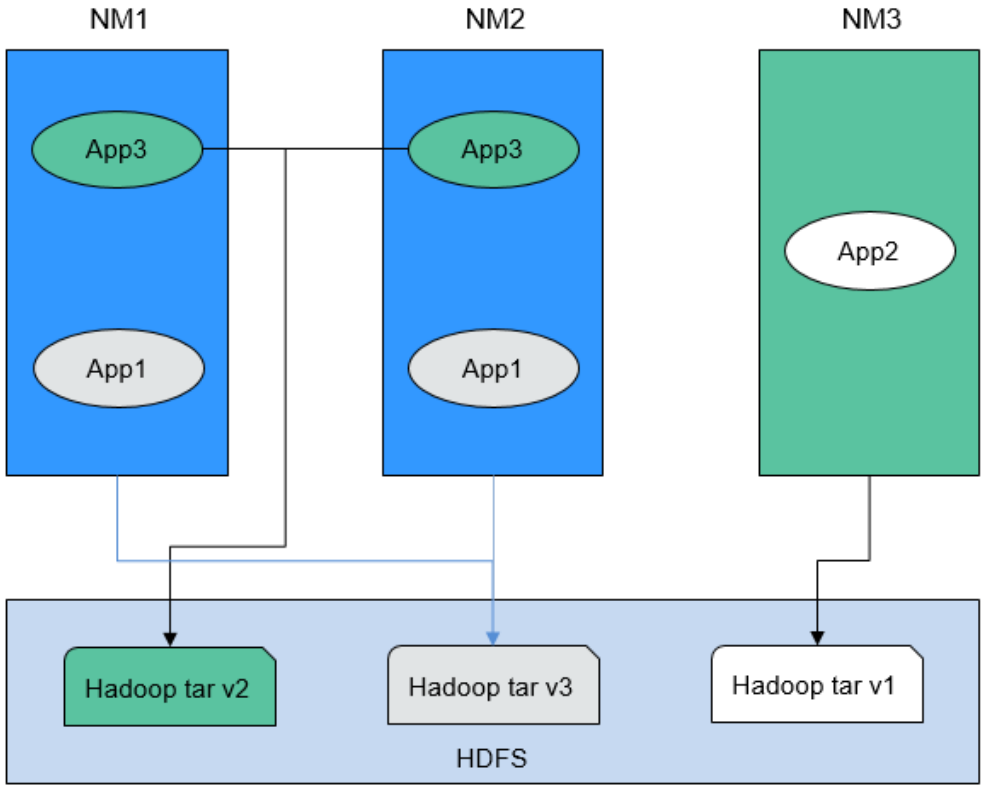

在图 18-1 中：可以看出，应用程序可以使用 HDFS 中的 Hadoop jars，而无需使用本地版本。因此在滚动升级中，即使 NodeManager 已经升级，应用程序仍然可以运行旧版本的 Hadoop。

配置描述

首先，需要将指定版本的 MapReduce tar 包存放至 HDFS 中应用程序可以访问的目录下，如下所示：

$HADOOP_HOME/**bin/hdfs dfs -put** *hadoop-x.tar.gz /mapred/framework/*

步骤 1 根据表 18-5，对“客户端安装路径/Yarn/config/mapred-site.xml”文件中的参数进行设置。

表18-5 分布式缓存相关参数

参数	说明	默认值
mapreduce.application.framework.path	此参数值为指向存档位置的 URL。 说明 如果对 URL 片段标示名称进行如下指定，该属性还可以为存档创建别名。作为示例，这里将别名设为了 mr-framework。 <property> <name>mapreduce.application.framework.path</name> <value>hdfs:/mapred/framework/hadoop-x.tar.gz#mr-	NA

参数	说明	默认值
	framework</value> </property>	
mapreduce.application.classpath	设定属性 mapreduce.application.classpath，使其可以包含类目录中相关的 MR jars。 说明 例如，此处利用在框架路径中使用过的别名“mr-framework”对目录进行匹配。 <property> <name>mapreduce.application.classpath</name> <value>$PWD/mr-framework/hadoop/share/hadoop/mapreduce/*:$PWD/mr-framework/hadoop/share/hadoop/mapreduce/lib/*:$PWD/mr-framework/hadoop/share/hadoop/common/*:$PWD/mr-framework/hadoop/share/hadoop/common/lib/*:$PWD/mr-framework/hadoop/share/hadoop/yarn/*:$PWD/mr-framework/hadoop/share/hadoop/yarn/lib/*:$PWD/mr-framework/hadoop/share/hadoop/hdfs/*:$PWD/mr-framework/hadoop/share/hadoop/hdfs/lib/*:/etc/hadoop/conf/secure</value></property>	NA

可以将多个版本的 MR tarball 上传至 HDFS。不同的“mapred-site.xml”文件可以指向不同的位置。用户在此之后可以针对特定的“mapred-site.xml”文件运行任务。以下是一个针对 x 版本的 MR tarball 运行 MR 任务的例子：

hadoop jar *share/hadoop/mapreduce/hadoop-mapreduce-examples-*.jar pi* **-conf etc/hadoop-x/mapred-site.xml** *10 10*

----结束

18.5 配置 MapReduce shuffle address

配置场景

当 MapReduce shuffle 服务启动时，它尝试基于 localhost 绑定 IP。如果需要 MapReduce shuffle 服务去连接特定 IP，那么没有可用的配置。下面的描述允许您配置连接到特定的 IP。

配置描述

当需要 MapReduce shuffle 服务绑定特定 IP 时，需要在 NodeManager 实例所在节点的配置文件“mapred-site.xml”中（例如路径为：${BIGDATA_HOME}/FusionInsight_HD_*xxx*/*x_xx*_NodeManager/etc/mapred-site.xml）设置下面的参数。

表18-6 参数描述

参数	描述	默认值
mapreduce.shuffle.address	指定地址来运行 shuffle 服务，格式是 IP:PORT，参数的默认值为空。当参数值为空时，将绑定 localhost，默认端口为 13562。 说明 如果涉及到的 PORT 值和配置的 mapreduce.shuffle.port 值不一样时，mapreduce.shuffle.port 将不会生效。	-

18.6 配置集群管理员列表

配置场景

该功能主要用于指定 MapReduce 集群管理员。

其中，集群管理员列表由参数“mapreduce.cluster.administrators”指定，集群管理员 admin 具有所有可以操作的权限。

配置描述

进入 Mapreduce 服务参数“全部配置”界面，在搜索框中输入参数名称。具体操作请参考 25.1 修改集群服务配置参数章节。

表18-7 参数描述

参数	描述	默认值
mapreduce.cluster.acls.enabled	是否开启对 Job History Server 权限控制的开关。	true
mapreduce.cluster.administrators	用于指定 MapReduce 集群管理员列表，可以配置用户和用户组，用户或者用户组之间用逗号间隔，用户和用户组之间用空格间隔，举例：userA,userB groupA,groupB。当配置为*时表示所有用户或用户组。	mapred supergroup,System_administrator_186

18.7 MapReduce 日志介绍

日志描述

日志默认存储路径：

- JobhistoryServer：“/var/log/Bigdata/mapreduce/jobhistory”（运行日志），“/var/log/Bigdata/audit/mapreduce/jobhistory”（审计日志）
- Container：“/srv/BigData/hadoop/data1/nm/containerlogs/application_${appid}/container_{$contid}”

说明

运行中的任务日志存储在以上路径中，运行结束后会基于 YARN 的配置是否汇聚到 HDFS 目录中，详情请参见 23.1 Yarn 常用参数。

日志归档规则：

MapReduce 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 50MB 的时候，会自动压缩，压缩后的日志文件名规则为：“*<原有日志名>*-<yyyy-mm-dd_hh-mm-ss>.[*编号*].log.zip”。最多保留最近的 100 个压缩文件，压缩文件保留个数可以在参数配置界面中配置。

在 MapReduce 服务中，JobhistoryServer 会定时去清理 HDFS 上存储的旧的日志文件（默认目录为 HDFS 文件系统中的“/mr-history/done”），具体清理的时间间隔参数配置为 mapreduce.jobhistory.max-age-ms，默认值为 1296000000，即 15 天。

表18-8 MR 日志列表

日志类型	日志文件名	描述
运行日志	jhs-daemon-start-stop.log	守护进程（Daemon）的启动日志。
	hadoop-<SSH_USER>-jhshadaemon-<hostname>.log	守护进程（Daemon）的运行日志。
	hadoop-<SSH_USER>-<process_name>-<hostname>.out	MR 运行环境信息日志。
	historyserver-<SSH_USER>-<DATE>-<PID>-gc.log	MR 服务垃圾回收日志。
	jhs-haCheck.log	MR 实例主备状态检查日志。
	yarn-start-stop.log	MR 服务启停操作日志。
	yarn-prestart.log	MR 服务启动前集群操作的记录日志。
	yarn-postinstall.log	MR 服务安装后启动前的工作日志。

日志类型	日志文件名	描述
	yarn-cleanup.log	MR 服务卸载时候的清理日志。
	mapred-service-check.log	MR 服务健康状态检测日志。
	container_{$contid}	Container 日志。
	hadoop-<SSH_USER>-<process_name>-<hostname>.log	MR 运行日志。
	mapred-switch-jhs.log	MR 主备倒换日志。
	env.log	实例启停前的环境信息日志。
审计日志	mapred-audit-jobhistory.log	MR 操作审计日志。
	SecurityAuth.audit	MR 安全审计日志。

日志级别

MapReduce 中提供了如表 18-9 所示的日志级别。其中日志级别优先级从高到低分别是 FATAL、ERROR、WARN、INFO、DEBUG。程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表18-9 日志级别

级别	描述
FATAL	FATAL 表示当前事件处理存在严重错误信息。
ERROR	ERROR 表示当前事件处理存在错误信息。
WARN	WARN 表示当前事件处理存在异常告警信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

进入 MapReduce 服务参数“全部配置”界面，具体操作请参考 25.1 修改集群服务配置参数。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别。

步骤 4 保存配置，在弹出窗口中单击“确定”使配置生效。

说明

配置完成后立即生效，不需要重启服务。

----结束

日志格式

MapReduce 日志格式如下所示：

表18-10 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<*Log Level*>|<*产生该日志的线程名字*>|<*log 中的 message*>|<*日志事件的发生位置*>	2020-01-26 14:18:59,109 | INFO | main | Client environment:java.compiler=<NA> | org.apache.zookeeper.Environment.logEnv(Environment.java:100)
审计日志	<yyyy-MM-dd HH:mm:ss,SSS>|<*Log Level*>|<*产生该日志的线程名字*>|<*log 中的 message*>|<*日志事件的发生位置*>	2020-01-26 14:24:43,605 | INFO | main-EventThread | USER=omm OPERATION=refreshAdminAcls TARGET=AdminService RESULT=SUCCESS | org.apache.hadoop.yarn.server.resourcemanager.RMAuditLogger$LogLevel$6.printLog(RMAuditLogger.java:91)

18.8 MapReduce 性能调优

18.8.1 多 CPU 内核下的调优配置

操作场景

当 CPU 内核数很多时，如 CPU 内核为磁盘数的 3 倍时的调优配置。

操作步骤

以下参数有如下两个配置入口：

- 服务器端配置

  进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。具体操作请参考 25.1 修改集群服务配置参数章节。
- 客户端配置

直接在客户端中修改相应的配置文件。

说明

- HDFS 客户端配置文件路径：*客户端安装目录*/HDFS/hadoop/etc/hadoop/hdfs-site.xml。
- Yarn 客户端配置文件路径：*客户端安装目录*/HDFS/hadoop/etc/hadoop/yarn-site.xml。
- MapReduce 客户端配置文件路径：*客户端安装目录*/HDFS/hadoop/etc/hadoop/mapred-site.xml。

表18-11 多 CPU 内核设置

配置	描述	参数	默认值	Server/Client	影响	备注
节点容器槽位数	如下配置组合决定了每节点任务(map、reduce)的并发数。 • “yarn.nodemanager.resource.memory-mb” • “mapreduce.map.memory.mb” • “mapreduce.reduce.memory.mb”	yarn.nodemanager.resource.memory-mb **说明** 需要在FusionInsight Manager 系统进行配置。	16384	Server	如果所有的任务(map/reduce)需要读写数据至磁盘，多个进程将会同时访问一个磁盘。这将会导致磁盘的 IO 性能非常的低下。为了改善磁盘的性能，请确保客户端并发访问磁盘的数不大于3。	最大并发的container数量应该为[2.5 * Hadoop 中磁盘配置数]。
		mapreduce.map.memory.mb **说明** 需要在客户端进行配置，配置文件路径：*客户端安装目录*/HDFS/hadoop/etc/hadoop/mapred-site.xml。	4096	Client		
		mapreduce.reduce.memory.mb **说明** 需要在客户端进行配置，配置文件路径：*客户端安装目录*/HDFS/hadoop/etc/hadoop/mapred-site.xml。	4096	Client		
Map 输出与压缩	Map 任务所产生的输出可以在写入磁盘之前被压缩，这样	mapreduce.map.output.compress **说明** 需要在客户端进行配置，配	true	Client	在这种情况下，磁盘的 IO 是主要瓶颈。所以可以选择一种压缩率非	编解码器可配置为 Snappy，Benchmark 测试结果

配置	描述	参数	默认值	Server/Client	影响	备注
	可以节约磁盘空间并得到更快的写盘速度，同时可以减少至 Reducer 的数据传输量。需要在客户端进行配置。 • mapreduce.map.output.compress 指定了 Map 任务输出结果可以在网络传输前被压缩。这是一个 per-job 的配置。 • mapreduce.map.output.compress.codec 指定用于压缩的编解码器。	置文件路径：*客户端安装目录*/HDFS/hadoop/etc/hadoop/mapred-site.xml。			常高的压缩算法。	显示 Snappy 是非常平衡以及高效的编码器。
		mapreduce.map.output.compress.codec 说明 *需要在客户端进行配置，配置文件路径：客户端安装目录*/HDFS/hadoop/etc/hadoop/mapred-site.xml。	org.apache.hadoop.io.compress.Lz4Codec	Client		
Spills	mapreduce.map.sort.spill.percent	mapreduce.map.sort.spill.percent 说明 *需要在客户端进行配置，配置文件路径：客户端安装目录*/HDFS/hadoop/etc/hadoop/map	0.8	Client	磁盘 IO 是主要瓶颈，合理配置“mapreduce.task.io.sort.mb”可以使溢出至磁盘的内容最小化。	-

配置	描述	参数	默认值	Server/Client	影响	备注
		red-site.xml。				
数据包大小	当 HDFS 客户端写数据至数据节点时，数据会被累积，直到形成一个包。然后这个数据包会通过网络传输。dfs.client-write-packet-size 配置项可以指定该数据包的大小。这个可以通过每个 job 进行指定。	dfs.client-write-packet-size **说明** *需要在客户端进行配置，配置文件路径：客户端安装目录/HDFS/hadoop/etc/hadoop/hdfs-site.xml。*	262144	Client	数据节点从 HDFS 客户端接收数据包，然后将数据包里的数据单线程写入磁盘。当磁盘处于并发写入状态时，增加数据包的大小可以减少磁盘寻道时间，从而提升 IO 性能。	dfs.client-write-packet-size = 262144

18.8.2 确定 Job 基线

操作场景

确定 Job 基线是调优的基础，一切调优项效果的检查，都是通过和基线数据做对比来获得。

Job 基线的确定有如下三个原则：

- 充分利用集群资源
- reduce 阶段尽量放在一轮
- 每个 task 的执行时间要合理

操作步骤

- **原则一：充分利用集群资源。**

  Job 运行时，会让所有的节点都有任务处理，且处于繁忙状态，这样才能保证资源充分利用，任务的并发度达到最大。可以通过调整处理的数据量大小，以及调整 map 和 reduce 个数来实现。

  Reduce 个数的控制使用“mapreduce.job.reduces”。

Map 个数取决于使用了哪种 InputFormat，以及待处理的数据文件是否可分割。默认的 TextFileInputFormat 将根据 block 的个数来分配 map 数(一个 block 一个 map)。通过如下配置参数进行调整。

参数入口：

进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。具体操作请参考 25.1 修改集群服务配置参数章节。

参数	描述	默认值
mapreduce.input.fileinputformat.split.maxsize	map 输入信息应被拆分成的数据块的最大大小。 由用户定义的分片大小的设置及每个文件 block 大小的设置，可以计算分片的大小。计算公式如下： `splitSize = Math.max(minSize, Math.min(maxSize, blockSize))` 如果 maxSize 设置大于 blockSize，那么每个 block 就是一个分片，否则就会将一个 block 文件分隔为多个分片，如果 block 中剩下的一小段数据量小于 splitSize，还是认为它是独立的分片。	-
mapreduce.input.fileinputformat.split.minsize	可以设置数据分片的数据最小值。	0

- **原则二：控制 reduce 阶段在一轮中完成。**

  避免以下两种场景：

  - 大部分的 reduce 在第一轮运行完后，剩下唯一一个 reduce 继续运行。这种情况下，这个 reduce 的执行时间将极大影响这个 job 的运行时间。因此需要将 reduce 个数减少。
  - 所有的 map 运行完后，只有个别节点有 reduce 在运行。这时候集群资源没有得到充分利用，需要增加 reduce 的个数以便每个节点都有任务处理。

- **原则三：每个 task 的执行时间要合理。**

  如果一个 job，每个 map 或 reduce 的执行时间只有几秒钟，就意味着这个 job 的大部分时间都消耗在 task 的调度和进程启停上了，因此需要增加每个 task 处理的数据大小。建议一个 task 处理时间为 1 分钟。

  控制单个 task 处理时间的大小，可以通过如下配置来调整。

  参数入口：

  进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。具体操作请参考 25.1 修改集群服务配置参数章节。

参数	描述	默认值
mapreduce.input.fileinputformat.split.maxsize	map 输入信息应被拆分成的数据块的最大大小。	-

参数	描述	默认值
	由用户定义的分片大小的设置及每个文件 block 大小的设置，可以计算分片的大小。计算公式如下： `splitSize = Math.max(minSize, Math.min(maxSize, blockSize))` 如果 maxSize 设置大于 blockSize，那么每个 block 就是一个分片，否则就会将一个 block 文件分隔为多个分片，如果 block 中剩下的一小段数据量小于 splitSize，还是认为它是独立的分片。	
mapreduce.input.fileinputformat.split.minsize	可以设置数据分片的数据最小值。	0

18.8.3 Shuffle 调优

操作场景

Shuffle 阶段是 MapReduce 性能的关键部分，包括了从 Map task 将中间数据写到磁盘一直到 Reduce task 拷贝数据并最终放到 reduce 函数的全部过程。这一块 Hadoop 提供了大量的调优参数。

图18-2 Shuffle 过程

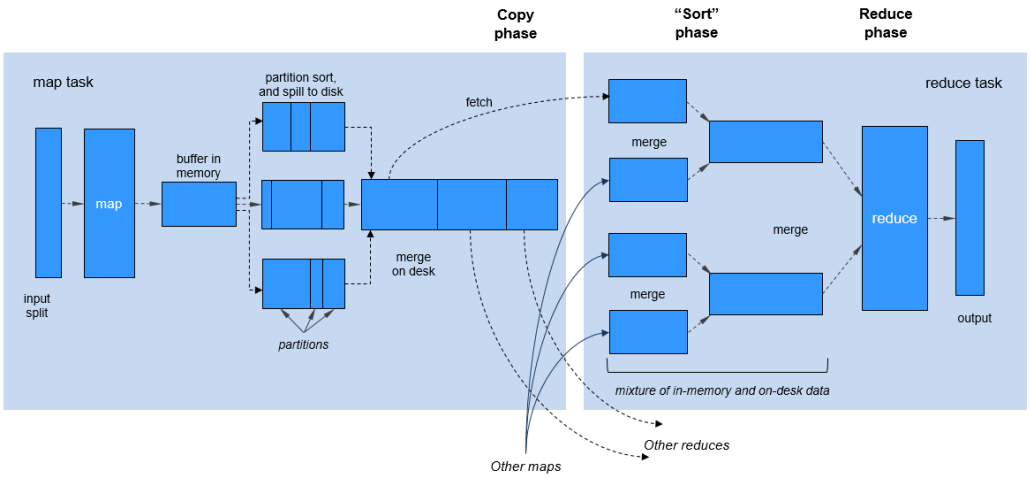

操作步骤

1. **Map 阶段的调优**
   - 判断 Map 使用的内存大小

判断 Map 分配的内存是否足够，一个简单的办法是查看运行完成的 job 的 Counters 中，对应的 task 是否发生过多次 GC，以及 GC 时间占总 task 运行时间之比。通常，GC 时间不应超过 task 运行时间的 10%，即 GC time elapsed (ms)/CPU time spent (ms)<10%。

主要通过如下参数进行调整。

参数入口：

进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。具体操作请参考 25.1 修改集群服务配置参数章节。

表18-12 参数说明

参数	描述	默认值
mapreduce.map.memory.mb	map 任务的内存限制。	4096
mapreduce.map.java.opts	map 子任务的 JVM 参数。如果设置，会替代 mapred.child.java.opts 参数；如果未设置-Xmx，Xmx 值从 mapreduce.map.memory.mb*mapreduce.job.heap.memory-mb.ratio 计算获取。	• 集群已开启 Kerberos 认证：-Djava.net.preferIPv4Stack=true -Djava.net.preferIPv6Addresses=false -Djava.security.krb5.conf=*${BIGDATA_HOME}*/common/runtime/krb5.conf -Dbeetle.application.home.path=*${BIGDATA_HOME}*/common/runtime/security/config • 集群未开启 Kerberos 认证：-Djava.net.preferIPv4Stack=true -Djava.net.preferIPv6Addresses=false -Dbeetle.application.home.path=*${BIGDATA_HOME}*/common/runtime/security/config

建议：配置“mapreduce.map.java.opts”参数中“-Xmx”值为“mapreduce.map.memory.mb”参数值的 0.8 倍。

- 使用 Combiner

  在 Map 阶段，有一个可选过程，将同一个 key 值的中间结果合并，叫做 combiner。一般将 reduce 类设置为 combiner 即可。通过 combine，一般情况下可以显著减少 Map 输出的中间结果，从而减少 shuffle 过程的网络带宽占用。可通过如下接口为一个任务设置 Combiner 类。

表18-13 Combiner 设置接口

类名	接口名	描述
org.apache.hadoop.mapreduce.Job	public void setCombinerClass(Class<? extends Reducer> cls)	为 Job 设置一个 combiner 类。

2. **Copy 阶段的调优**
   - 数据是否压缩

     对 Map 的中间结果进行压缩，当数据量大时，会显著减少网络传输的数据量，但是也因为多了压缩和解压，带来了更多的 CPU 消耗。因此需要做好权衡。当任务属于网络瓶颈类型时，压缩 Map 中间结果效果明显。针对 bulkload 调优，压缩中间结果后性能提升 60%左右。

     配置方法：将“mapreduce.map.output.compress”参数值设置为“true”，将“mapreduce.map.output.compress.codec”参数值设置为“org.apache.hadoop.io.compress.SnappyCodec”。
3. **Merge 阶段的调优**

   通过调整如下参数减少 reduce 写磁盘的次数。

   参数入口：

   进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。具体操作请参考 25.1 修改集群服务配置参数章节。

表18-14 参数说明

参数	描述	默认值
mapreduce.reduce.merge.inmem.threshold	内存合并进程的文件数阈值。累计文件数达到阈值时会发起内存合并及溢出到磁盘。小于等于 0 的值表示该阈值不生效且仅基于 ramfs 的内存使用情况来触发合并。	1000
mapreduce.reduce.shuffle.merge.percent	发起内存合并的使用率阈值，表示为分配给映射输出信息的内存的比例（是由 mapreduce.reduce.shuffle.input.buffer.percent 设置的）。	0.66
mapreduce.reduce.shuffle.input.buffer.percent	shuffle 过程中分配给映射输出信息的内存占最大堆大小的比例。	0.70
mapreduce.reduce.input.buffer.percent	Reduce 过程中保存映射输出信息的内存相对于最大堆大小的比例。当 shuffle 结束时，需保证 reduce 开始前内存中所有剩余的映射输出信息所使用的内存小于该阈值。	0.0

18.8.4 大任务的 AM 调优

操作场景

任务场景：运行的一个大任务（map 总数达到了 10 万的规模），但是一直没有跑成功。经过查询，发现是 ApplicationMaster（以下简称 AM）反应缓慢，最终超时失败。

此任务的问题是，task 数量变多时，AM 管理的对象也线性增长，因此就需要更多的内存来管理。AM 默认分配的内存堆大小是 1GB。

操作步骤

通过调大如下的参数来进行 AM 调优。

参数入口：

在 Yarn 客户端的“mapred-site.xml”配置文件中调整如下参数。“mapred-site.xml”配置文件在客户端安装路径的 conf 目录下，例如“/opt/client/Yarn/config”。

参数	描述	默认值
yarn.app.mapreduce.am.resource.mb	该参数值必须大于下面参数的堆大小。单位：MB	1536
yarn.app.mapreduce.am.command-opts	传递到 MapReduce ApplicationMaster 的 JVM 启动参数。	-Xmx1024m -XX:+UseConcMarkSweepGC -XX:+CMSParallelRemarkEnabled -verbose:gc -Djava.security.krb5.conf=${KRB5_CONFIG} -Dhadoop.home.dir=*${BIGDATA_HOME}*/FusionInsight_HD_*xxx*/install/FusionInsight-Hadoop-*xxx*/hadoop

18.8.5 推测执行

操作场景

当集群规模很大时（如几百上千台节点的集群），个别机器出现软硬件故障的概率就变大了，并且会因此延长整个任务的执行时间（跑完的任务都在等出问题的机器跑结束）。推测执行通过将一个 task 分给多台机器跑，取先运行完的那个，会很好的解决这个问题。对于小集群，可以将这个功能关闭。

操作步骤

参数入口：

进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。具体操作请参考 25.1 修改集群服务配置参数章节。

参数	描述	默认值
mapreduce.map.speculative	设置是否并行执行某些映射任务的多个实例。true 表示开启。	false
mapreduce.reduce.speculative	设置是否并行执行某些 reduce 任务的多个实例。true 表示开启。	false

18.8.6 通过“Slow Start”调优

操作场景

Slow Start 特性指定 Map 任务完成度为多少时 Reduce 任务可以启动，过早启动 Reduce 任务会导致资源占用，影响任务运行效率，但适当的提早启动 Reduce 任务会提高 Shuffle 阶段的资源利用率，提高任务运行效率。例如：某集群可启动 10 个 Map 任务，MapReduce 作业共 15 个 Map 任务，那么在一轮 Map 任务执行完成后只剩 5 个 Map 任务，集群还有剩余资源，在这种场景下，配置 Slow Start 参数值小于 1，比如 0.8，则 Reduce 就可以利用集群剩余资源。

操作步骤

参数入口：

进入 Mapreduce 服务参数“全部配置”界面，在搜索框中输入参数名称。具体操作请参考 25.1 修改集群服务配置参数章节。

参数	描述	默认值
mapreduce.job.reduce.slowstart.completedmaps	为 job 安排 reduce 前应完成的映射数的分数形式。默认 100%的 Map 跑完后开始起 Reduce。	1.0

18.8.7 MR job commit 阶段优化

操作场景

默认情况下，如果一个 MR 任务会产生大量的输出结果文件，那么该 job 在最后的 commit 阶段会耗费较长的时间将每个 task 的临时输出结果 commit 到最终的结果输出目录。特别是在大集群中，大 Job 的 commit 过程会严重影响任务的性能表现。

针对以上情况，可以通过将以下参数“mapreduce.fileoutputcommitter.algorithm.version”配置为“2”，来提升 MR Job commit 阶段的性能。

操作步骤

参数入口：

进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。具体操作请参考 25.1 修改集群服务配置参数章节。

表18-15 参数说明

参数	描述	默认值
mapreduce.fileoutputcommitter.algorithm.version	用于指定 Job 的最终输出文件提交的算法版本，取值为“1”或“2”。 说明 版本 2 为建议的优化算法版本。该算法通过让任务直接将每个 task 的输出结果提交到最终的结果输出目录，从而减少大作业的输出提交时间。	2

18.9 MapReduce 常见问题

18.9.1 MapReduce 任务长时间无进展

问题

MapReduce 任务长时间无进展。

回答

一般是因为内存太少导致的。当内存较小时，任务中拷贝 map 输出的时间将显著增加。

为了减少等待时间，您可以适当增加堆内存空间。

任务的配置可根据 mapper 的数量和各 mapper 的数据大小来进行优化。根据输入数据的大小，优化“*客户端安装路径*/Yarn/config/mapred-site.xml”文件中的如下参数：

- “mapreduce.reduce.memory.mb”
- “mapreduce.reduce.java.opts”

例如：如果 10 个 mapper 的数据大小为 5GB，那么理想的堆内存是 1.5GB。随着数据大小的增加而增加堆内存大小。

18.9.2 运行任务时，客户端不可用

问题

当运行任务时，将 MR ApplicationMaster 或 ResourceManager 移动为 D 状态，为什么此时客户端会不可用？

回答

当运行任务时，将 MR ApplicationMaster 或 ResourceManager 移动为 D 状态（不间断睡眠状态）或 T 状态（停止状态），客户端会等待返回任务运行的状态，由于 AM 无返回，客户端会一直处于等待状态。

为避免出现上述场景，使用“core-site.xml”中的“ipc.client.rpc.timeout”配置项设置客户端超时时间。

该参数的参数值为毫秒。默认值为 0，表示无超时。客户端超时的取值范围可以为 0～2147483647 毫秒。

说明

- 如果 Hadoop 进程已处于 D 状态，重启该进程所处的节点。
- “core-site.xml”配置文件在客户端安装路径的 conf 目录下，例如“/opt/client/Yarn/config”。

18.9.3 在缓存中找不到 HDFS_DELEGATION_TOKEN

问题

安全模式下，为什么在缓存中找不到 HDFS_DELEGATION_TOKEN？

回答

在 MapReduce 中，默认情况下，任务完成之后，HDFS_DELEGATION_TOKEN 将会被删除。因此如果在下一个任务中再次使用 HDFS_DELEGATION_TOKEN，缓存中将会找不到 HDFS_DELEGATION_TOKEN。

为了能够在随后的工作中再次使用同一个 Token，为 MapReduce 任务配置参数。当参数为 false 时，用户能够再次使用同一个 Token。

```
jobConf.setBoolean("mapreduce.job.complete.cancel.delegation.tokens", false);
```

18.9.4 如何在提交 MapReduce 任务时设置任务优先级

问题

如何在提交 MapReduce 任务时设置任务优先级？

回答

当您在客户端提交 MapReduce 任务时，可以在命令行中增加“-Dmapreduce.job.priority=<priority>”参数来设置任务优先级。格式如下：

yarn jar *<jar> [mainClass]* ***-Dmapreduce.job.priority=****<priority> [path1] [path2]*

命令行中参数含义为：

- <jar>：指定需要运行的 jar 包名称。
- [mainClass]：指 jar 包应用工程中的类得 main 方法。
- <priority>：指定任务的优先级，其取值可为：VERY_HIGH、HIGH、NORMAL、LOW、VERY_LOW。
- [path1]：指数据输入路径。
- [path2]：指数据输出路径。

例如，将“/opt/client/HDFS/hadoop/share/hadoop/mapreduce/hadoop-mapreduce-examples*.jar”包设置为高优先级任务。

yarn jar /opt/client/HDFS/hadoop/share/hadoop/mapreduce/hadoop-mapreduce-examples*.jar wordcount -Dmapreduce.job.priority=VERY_HIGH /DATA.txt /out/

18.9.5 MapReduce 任务运行失败，ApplicationMaster 出现物理内存溢出异常

问题

HBase bulkload 任务有 210000 个 map 和 10000 个 reduce，MapReduce 任务运行失败，ApplicationMaster 出现物理内存溢出异常。

```
For more detailed output, check the application tracking page:https://bigdata-
55:8090/cluster/app/application_1449841777199_0003
Then click on links to logs of each attempt.
Diagnostics: Container
[pid=21557,containerID=container_1449841777199_0003_02_000001] is running beyond
physical memory limits
Current usage: 1.0 GB of 1 GB physical memory used; 3.6 GB of 5 GB virtual memory
used. Killing container.
Dump of the process-tree for container_1449841777199_0003_02_000001 :
|- PID PPID PGRPID SESSID CMD_NAME USER_MODE_TIME(MILLIS) SYSTEM_TIME(MILLIS)
VMEM_USAGE(BYTES) RSSMEM_USAGE(PAGES) FULL_CMD_LINE
|- 21584 21557 21557 21557 (java) 12342 1627 3871748096 271331
${BIGDATA_HOME}/jdk1.8.0_51//bin/java
-
Djava.io.tmpdir=/srv/BigData/hadoop/data1/nm/localdir/usercache/hbase/appcache/appl
ication_1449841777199_0003/container_1449841777199_0003_02_000001/tmp -
Dlog4j.configuration=container-log4j.properties
-
Dyarn.app.container.log.dir=/srv/BigData/hadoop/data1/nm/containerlogs/application_
1449841777199_0003/container_1449841777199_0003_02_000001 -
Dyarn.app.container.log.filesize=0 -Dhadoop.root.logger=INFO,CLA
-Dhadoop.root.logfile=syslog -Xmx784m
org.apache.hadoop.mapreduce.v2.app.MRAppMaster
|- 21557 21547 21557 21557 (bash) 0 0 13074432 368 /bin/bash -c
${BIGDATA_HOME}/jdk1.8.0_51//bin/java
-
Djava.io.tmpdir=/srv/BigData/hadoop/data1/nm/localdir/usercache/hbase/appcache/appl
ication_1449841777199_0003/container_1449841777199_0003_02_000001/tmp -
```

```
Dlog4j.configuration=container-log4j.properties
-
Dyarn.app.container.log.dir=/srv/BigData/hadoop/data1/nm/containerlogs/application_
1449841777199_0003/container_1449841777199_0003_02_000001 -
Dyarn.app.container.log.filesize=0 -Dhadoop.root.logger=INFO,CLA
-Dhadoop.root.logfile=syslog -Xmx784m
org.apache.hadoop.mapreduce.v2.app.MRAppMaster
1>/srv/BigData/hadoop/data1/nm/containerlogs/application_1449841777199_0003/contain
er_1449841777199_0003_02_000001/stdout
2>/srv/BigData/hadoop/data1/nm/containerlogs/application_1449841777199_0003/contain
er_1449841777199_0003_02_000001/stderr
Container killed on request. Exit code is 143
Container exited with a non-zero exit code 143
Failing this attempt. Failing the application.
```

回答

这是性能规格的问题，MapReduce 任务运行失败的根本原因是由于 ApplicationMaster 的内存溢出导致的，即物理内存溢出导致被 NodeManager kill。

解决方案：

将 ApplicationMaster 的内存配置调大，在客户端“*客户端安装路径*/Yarn/config/mapred-site.xml”配置文件中优化如下参数：

- “yarn.app.mapreduce.am.resource.mb”
- “yarn.app.mapreduce.am.command-opts”，该参数中-Xmx 值建议为 0.8*“yarn.app.mapreduce.am.resource.mb”

参考规格：

ApplicationMaster 配置如下时，可以同时支持并发 Container 数为 2.4 万个。

- “yarn.app.mapreduce.am.resource.mb”=2048
- “yarn.app.mapreduce.am.command-opts”该参数中-Xmx=1638m

18.9.6 MapReduce JobHistoryServer 服务地址变更后，为什么运行完的 MapReduce 作业信息无法通过 ResourceManager Web UI 页面的 Tracking URL 打开

问题

MapReduce JobHistoryServer 服务地址变更后，为什么运行完的 MapReduce 作业无法通过 ResourceManager Web UI 页面打开？

回答

JobHistoryServer 地址（mapreduce.jobhistory.address / mapreduce.jobhistory.webapp.<https.>address）是 MapReduce 参数，MapReduce 客户端提交作业时，会将此地址随任务一起提交给 ResourceManager。ResourceManager 在作业完成后，将此参数作为查看作业历史信息的跳转地址保存在 RMStateStore 中。

JobHistoryServer 服务地址变更后，需要将新的服务地址及时更新到 MapReduce 客户端配置文件中，否则，新运行的作业在查看作业历史信息时，仍然会指向原 JobHistoryServer 地址，导致无法正常跳转到作业历史信息页面。服务地址变更前运行的 MapReduce 作业，由于其跳转信息已经保存在 RMStateStore 中，无法变更，因此从 ResourceManager Web UI 页面是无法进行正常跳转的，但可以直接访问新的 JobHistoryServer 服务地址进行查找，作业信息不会丢失。

18.9.7 多个 NameService 环境下，运行 MapReduce 任务失败

问题

多个 NameService 环境下，运行使用 viewFS 功能的 MapReduce 或 YARN 任务失败。

回答

当使用 viewFS 时，只有在 viewFS 中挂载的目录才能被访问到。所以最可能的原因是配置的路径没有在 viewFS 的挂载点上。例如：

```
<property>
<name>fs.defaultFS</name>
<value>viewfs://ClusterX/</value>
</property>
<property>
<name>fs.viewfs.mounttable.ClusterX.link./folder1</name>
<value>hdfs://NS1/folder1</value>
</property>
<property>
<name>fs.viewfs.mounttable.ClusterX.link./folder2</name>
<value>hdfs://NS2/folder2</value>
</property>
```

对于依赖 HDFS 的 MR 配置中，需要使用已挂载的目录。

错误示例：

```
<property>
<name>yarn.app.mapreduce.am.staging-dir</name>
<value>/tmp/hadoop-yarn/staging</value>
</property>
```

根目录（/）在 viewFS 中是无法访问的。

正确示例：

```
<property>
<name>yarn.app.mapreduce.am.staging-dir</name>
<value>/folder1/tmp/hadoop-yarn/staging</value>
</property>
```

18.9.8 基于分区的任务黑名单

问题

Map&Reduce 任务失败，并且故障节点数与集群总节点数的比值低于“yarn.resourcemanager.am-scheduling.node-blacklisting-disable-threshold”配置的黑名单阈值，为什么 Map&Reduce 任务故障节点没有加入黑名单？

回答

当集群中有超过阈值的节点都被加入黑名单时，黑名单会释放这些节点，其中阈值为故障节点数与集群总节点数的比值。现在每个节点都有其标签表达式，黑名单阈值应根据有效节点标签表达式关联的节点数进行计算，其值为故障节点数与有效节点标签表达式关联的节点数的比值。

假设集群中有 100 个节点，其中有 10 个节点为有效节点标签表达式关联的节点（labelA）。其中所有有效节点标签表达式关联的节点都已经故障，黑名单节点释放阈值默认值为 0.33，按照传统的计算方式，10/100=0.1，远小于该阈值。这就造成这 10 个节点永远无法得到释放，Map&Reduce 任务一直无法获取节点，应用程序无法正常运行。实际需要根据与 Map&Reduce 任务的有效节点关联的节点总数进行计算，即 10/10=1，大于黑名单节点释放阈值，节点被释放。

因此即使故障节点数与集群总节点数的比值没有超过阈值，也存在黑名单将这些节点释放的情况。

19 使用 Oozie

19.1 从零开始使用 Oozie

Oozie 是一个基于工作流引擎的开源框架，能够提供对 Hadoop 作业的任务调度与协调。

Oozie 支持提交多种类型任务，例如 Hive、Spark2x、Loader、Mapreduce、Java、DistCp、Shell、HDFS、SSH、SubWorkflow、Streaming、定时任务等。

本章节指导用户通过使用 Oozie 客户端提交 MapReduce 任务。

前提条件

已安装客户端。例如安装目录为“/opt/client”，以下操作的客户端目录只是举例，请根据实际安装目录修改。

操作步骤

以客户端安装用户，登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。假如客户端安装目录为：/opt/client，请根据实际安装目录修改。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 判断集群认证模式。

- 安全模式，执行以下命令进行用户认证。*UserOozie* 为提交任务的用户。

  kinit *UserOozie*
- 普通模式，执行步骤 5。

步骤 4 上传 Oozie 配置文件以及 Jar 包至 HDFS：

hdfs dfs -mkdir /user/*UserOozie*

hdfs dfs -put -f /opt/client/Oozie/oozie-client-*/examples /user/*UserOozie/*

说明

- “/opt/client”为客户端安装目录，请根据实际安装目录修改。
- UserOozie 为提交任务的用户。

步骤 5 修改任务执行配置文件：

cd /opt/client/Oozie/oozie-client-*/examples/apps/map-reduce/

vi job.properties

```
nameNode=hdfs://hacluster
resourceManager=10.64.35.161:8032（10.64.35.161为Yarn resourceManager（Active）节点业务平面IP；8032为yarn.resourcemanager.port）
queueName=default
examplesRoot=examples
user.name=admin
oozie.wf.application.path=${nameNode}/user/${user.name}/${examplesRoot}/apps/map-reduce #hdfs上传路径
outputDir=map-reduce
oozie.wf.rerun.failnodes=true
```

步骤 6 运行 oozie 任务：

oozie job -oozie https://*oozie 角色的主机名*:21003/oozie/ -config job.properties -run

“21003”为 Oozie HTTPS 请求的运行端口，可在 FusionInsight Manager，选择“集群 > 服务 > Oozie > 配置”，在搜索框中搜索“OOZIE_HTTPS_PORT”查看。

```
[root@kwephispra44947 map-reduce]# oozie job -oozie
https://kwephispra44948:21003/oozie/ -config job.properties -run
......
job: 0000000-200730163829770-oozie-omm-W
```

步骤 7 登录 FusionInsight Manager。具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。

步骤 8 选择“集群 > *待操作集群的名称* > 服务 > Oozie ”，单击“oozie WebUI”后的超链接进入 Oozie 页面，在 Oozie 的 WebUI 上查看任务运行结果。

图19-1 任务运行结果

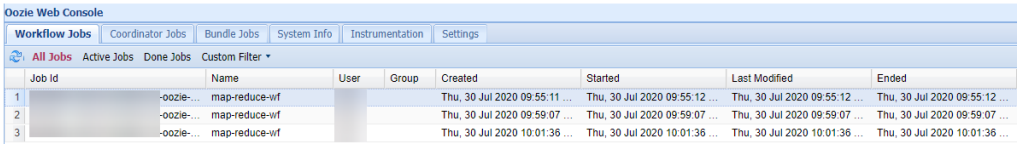

----结束

19.2 使用 Oozie 客户端

操作场景

该任务指导用户在运维场景或业务场景中使用 Oozie 客户端。

前提条件

- 已安装客户端。例如安装目录为“/opt/client”，以下操作的客户端目录只是举例，请根据实际安装目录修改。
- 各组件业务用户由 MRS 集群管理员根据业务需要创建。安全模式下，“机机”用户需要下载 keytab 文件。“人机”用户第一次登录时需修改密码。

使用 Oozie 客户端

以客户端安装用户，登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录，该操作的客户端目录只是举例，请根据实际安装目录修改。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 判断集群认证模式。

- 安全模式，执行以下命令进行用户认证。*exampleUser* 为提交任务的用户名。

  kinit *exampleUser*
- 普通模式，执行步骤 5。

步骤 4 配置 Hue。

1. spark2x 环境配置（如果不涉及 spark2x 任务，可以跳过此步骤）：

   hdfs dfs -put /opt/client/Spark2x/spark/jars/*.jar /user/oozie/share/lib/spark2x/

   当 HDFS 目录“/user/oozie/share”中的 Jar 包发生变化时，需要重启 Oozie 服务。
2. 上传 Oozie 配置文件以及 Jar 包至 HDFS：

   hdfs dfs -mkdir /user/*exampleUser*

   hdfs dfs -put -f /opt/client/Oozie/oozie-client-*/examples /user/*exampleUser*/

   说明

   - *exampleUser* 为提交任务的用户名。
   - 在提交任务的用户和非 job.properties 文件均无变更的前提下，客户端安装目录/Oozie/oozie-client-*/examples 目录一经上传 HDFS，后续可重复使用，无需多次提交。
   - 解决 Spark 和 Yarn 关于 jetty 的 jar 冲突。

     hdfs dfs -rm -f /user/oozie/share/lib/spark/jetty-all-9.2.22.v20170606.jar
   - 普通模式下，上传过程如果遇到“Permission denied”的问题，可执行以下命令进行处理。

     su - omm

     source /opt/client/bigdata_env

hdfs dfs -chmod -R 777 /user/oozie

exit

----结束

19.3 开启 Oozie HA 机制

操作场景

Oozie 多个节点同时提供服务的时候，通过 ZooKeeper 来提供高可用（HA）功能，防止单节点故障以及多节点同时处理一个任务。

对系统影响

操作过程中需要重启 Oozie 服务。重启过程中，Oozie 服务无法提供服务。

前提条件

- 已安装 Oozie、ZooKeeper 服务，且服务正常运行。
- 没有任务正在运行。
- 如果当前集群不是安装最新的版本包，需要从“$BIGDATA_HOME/FusionInsight_Porter_*x.x.x*/install/FusionInsight-Oozie-*x.x.x*/oozie-*x.x.x*/embedded-oozie-server/webapp/WEB-INF/lib”路径拷贝“curator-x-discovery-*x.x.x*.jar”包到“$BIGDATA_HOME/FusionInsight_Porter_*x.x.x*/install/FusionInsight-Oozie-*x.x.x*/oozie-*x.x.x*/lib”目录下。

操作步骤

在 FusionInsight Manager 界面选择“集群 > 服务 > Oozie > 配置 > 全部配置”，在“自定义”的“oozie.site.configs”参数中添加如下四个配置项。修改完成后单击“保存”，在弹框中单击“确定”保存配置。

名称	值	参数说明
oozie.services.ext	org.apache.oozie.service.ZKLocksService,org.apache.oozie.service.ZKXLogStreamingService,org.apache.oozie.service.ZKJobsConcurrencyService,org.apache.oozie.service.ZKUUIDService	HA 启用的功能
oozie.zookeeper.connection.string	*ZooKeeper 实例的业务 IP:端口*（多个地址以逗号隔开）	ZooKeeper 连接信息
oozie.zookeeper.namespace	oozie	Oozie 在 ZooKeeper 的路径
oozie.zookeeper.secure	安全集群：true 普通集群：无需配置该参数	ZooKeeper 是否启用 kerberos

步骤 1 在 Oozie 的“概览”界面，选择右上角“更多 > 重启服务”，重启 Oozie 集群。

----结束

19.4 使用 Share Lib 检查工具

Oozie 任务运行需要依赖 Share Lib 中的原生 Jar 包，Share Lib 由 Oozie 内核启动时自动上传到 HDFS 的“/user/oozie”目录下，当 HDFS 上的 Share Lib 损坏、缺失或 Jar 包冲突可能导致 Oozie 任务运行失败。

当用户提交的 Oozie 作业运行失败时，可以通过该工具对 Share Lib 进行检查。

该操作仅适用于 MRS 3.3.0 及之后版本。

前提条件

- 已安装 HDFS、Oozie 客户端。
- 若需要检查 Spark Share Lib，Oozie 客户端所在节点上还需要安装 Spark 客户端。
- 执行检查的用户需要拥有 Oozie 的“普通用户权限”，及 HDFS“/user/oozie”目录的访问权限。

操作步骤

以客户端安装用户登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd *客户端安装目录*

步骤 2 执行以下命令配置环境变量并认证用户。

source bigdata_env

kinit *提交 Oozie 任务的用户*（ 若集群未启用 Kerberos 认证（普通模式）请跳过该操作）

步骤 3 检查 Share Lib，包括客户端和服务端两种方式。Spark Share Lib 仅支持客户端检查。

- 客户端方式：
  - 检查 Oozie 核心 Share Lib，且执行检查的 Oozie 客户端所在节点必须安装了一个 oozie 实例。

    oozie -validatesharelib -oozie.core.path=*oozie 实例安装路径*

    例如：

    oozie -validatesharelib -oozie.core.path=${BIGDATA_HOME}/FusionInsight_Porter_*/install/FusionInsight-Oozie-*/oozie-*
  - 检查 Spark Share Lib。

    oozie -validatesharelib -spark.client.path=*Spark 客户端安装目录*

例如：

oozie -validatesharelib -spark.client.path=/opt/client/Spark/

- 服务端方式：

  执行以下命令检查 Oozie 核心 Share Lib：

  oozie job -oozie https://*oozie 角色的主机名*:21003/oozie -validatesharelib

  oozie 角色的主机名可在 FusionInsight Manager，选择“集群 > 服务 > Oozie > 实例”查看。

  “21003”为 Oozie HTTPS 请求的运行端口，可在 FusionInsight Manager，选择“集群 > 服务 > Oozie > 配置”，搜索“OOZIE_HTTPS_PORT”查看。

步骤 4 查看检查结果。包括以下几种情况：

- Share Lib 存在 Jar 包缺失

  若检测到缺失 Jar 包，将输出“Share Lib jar file(s) not found on hdfs：”及缺失的 Jar 包信息。

  若 Share Lib Jar 包完整，将输出“All Share Lib jar file(s) found on hdfs.”。

- 已损坏的 Jar 包

  若检测到已损坏的 Jar 包，将输出“Share Lib jar file(s) mismatch on hdfs:”以及损坏的 Jar 包信息。

  若 Share Lib jar 包完好，将输出“All Share Lib jar file(s) on hdfs match.”。

- 已上传的自定义 Jar 包

  若检测到已上传的自定义 Jar 包，将输出“Extra Share Lib jar file(s) found on hdfs:”以及自定义 Jar 包信息。

  若未检测到自定义 Jar 包，将输出“No extra Share Lib jar file(s) found on hdfs.”。

步骤 5 根据检查结果进行异常处理。

若步骤 5 的检测结果中包括缺失或已损坏的 Jar 包信息，需执行以下步骤进行处理：

- Spark Share Lib：

  上传“*Spark 客户端安装目录*/**spark/jars**”路径下的 Spark Jar 包到检查结果对应的 HDFS 路径下：

  hdfs dfs -put -f *本地 Jar 包路径 异常 Spark Jar 包所在的 HDFS 路径*

- Core Share Lib：

  a. 解压 oozie 安装路径下的“${BIGDATA_HOME}/FusionInsight_Porter_*/install/FusionInsight-Oozie-*/oozie-*/oozie-sharelib-*.tar.gz”，找到 Share Lib Jar 包：

  tar -zxf oozie-sharelib-*.tar.gz

  b. 上传步骤 6.a 获取的 oozie Jar 包到检查结果对应的 HDFS 路径下。

  hdfs dfs -put -f *本地 Jar 包路径 异常 Oozie Jar 包所在的 HDFS 路径*

----结束

19.5 使用 Oozie 客户端提交作业

19.5.1 提交 Hive 任务

操作场景

该任务指导用户在使用 Oozie 客户端提交 Hive 任务

Hive 任务有如下类型：

- Hive 作业
  使用 JDBC 方式连接的 Hive 作业。
- Hive2 作业
  使用 Beeline 方式连接的 Hive 作业。

本文以使用 Oozie 客户端提交 Hive 作业为例介绍。

说明

- 使用 Oozie 客户端提交 Hive2 作业与提交 Hive 作业操作步骤一致，只需将操作步骤中对应路径的“/Hive”改成“/Hive2”即可。
  例如，Hive 作业运行目录“/opt/client/Oozie/oozie-client-*/examples/apps/hive/”，则 Hive2 对应的运行目录为“/opt/client/Oozie/oozie-client-*/examples/apps/hive2/”。
- 建议下载使用最新版本的客户端。

前提条件

- Hive 和 Oozie 组件及客户端已经安装，并且正常运行。
- 已创建或获取访问 Oozie 服务的人机用户账号及密码。

说明

- 该用户需要从属于 hadoop、supergroup、hive 组，同时添加 Oozie 的角色操作权限。若使用 Hive 多实例，该用户还需要从属于具体的 Hive 实例组，如 hive3。
- 用户同时还需要至少有 manager_viewer 权限的角色。

- 获取运行状态的 Oozie 服务器（任意实例）URL，如“https://10.1.130.10:21003/oozie”。
- 获取运行状态的 Oozie 服务器主机名，如“10-1-130-10”。
- 获取 Yarn ResourceManager 主节点 IP，如 10.1.130.11。

操作步骤

以客户端安装用户，登录安装 Oozie 客户端的节点。

步骤 1 执行以下命令，获取安装环境信息。其中“/opt/client”为客户端安装路径，该操作的客户端目录只是举例，请根据实际安装目录修改。

source /opt/client/bigdata_env

步骤 2 判断集群认证模式。

- 安全模式，执行 **kinit** 命令进行用户认证。

例如，使用 **oozieuser** 用户进行认证。

kinit oozieuser

- 普通模式，执行步骤 4。

步骤 3 执行以下命令，进入样例目录。

cd /opt/client/Oozie/oozie-client-*/examples/apps/hive/

该目录下需关注文件如表 19-1 所示。

表19-1 文件说明

文件名称	描述
hive-site.xml	Hive 任务的配置文件。
job.properties	工作流的参数变量定义文件。
script.q	Hive 任务的 SQL 脚本。
workflow.xml	工作流的规则定制文件。

步骤 4 执行以下命令，编辑“job.properties”文件。

vi job.properties

修改如下内容：

更改“userName”的参数值为提交任务的人机用户名，例如“userName=oozieuser”。

步骤 5 执行 **oozie job** 命令，运行工作流文件。

oozie job -oozie https://*oozie 角色的主机名*:21003/oozie/ -config job.properties -run

说明

- 命令参数解释如下：

  -oozie 实际执行任务的 Oozie 服务器 URL

  -config 工作流属性文件

  -run 运行工作流

- 执行完工作流文件，显示 job id 表示提交成功，例如：job: 0000021-140222101051722-oozie-omm-W。登录 Oozie 管理页面，查看运行情况。

  使用 **oozieuser** 用户，登录 Oozie WebUI 页面：https://*oozie 角色的 ip 地址*:21003/oozie 。

  Oozie 的 WebUI 界面中，可在页面表格根据 jobid 查看已提交的工作流信息。

----结束

19.5.2 提交 Spark2x 任务

操作场景

该任务指导用户在使用 Oozie 客户端提交 Spark2x 任务。

说明

请下载使用最新版本的客户端。

前提条件

- Spark2x 和 Oozie 组件安装完成且运行正常，客户端安装成功。

  如果当前客户端为旧版本，需要重新下载和安装客户端。
- 已创建或获取访问 Oozie 服务的人机用户账号及密码。

说明

- 该用户需要从属于 hadoop、supergroup、hive 组，同时添加 Oozie 的角色操作权限。若使用 Hive 多实例，该用户还需要从属于具体的 Hive 实例组，如 hive3。
- 用户同时还需要至少有 manager_viewer 权限的角色。

- 获取运行状态的 Oozie 服务器（任意实例）URL，如“https://*10.1.130.10:21003*/oozie”。
- 获取运行状态的 Oozie 服务器主机名，如“*10-1-130-10*”。
- 获取 Yarn ResourceManager 主节点 IP，如“*10.1.130.11*”。

操作步骤

以客户端安装用户登录安装 Oozie 客户端的节点。

步骤 1 执行以下命令，获取安装环境信息。其中“/opt/client”为客户端安装路径，该操作的客户端目录只是举例，请根据实际安装目录修改。

source /opt/client/bigdata_env

步骤 2 判断集群认证模式。

- 安全模式，执行 **kinit** 命令进行用户认证。

  例如，使用 **oozieuser** 用户进行认证。

  kinit oozieuser
- 普通模式，执行步骤 4。

步骤 3 执行以下命令，进入样例目录。

cd /opt/client/Oozie/oozie-client-*/examples/apps/spark2x/

该目录下需关注文件如表 19-2 所示。

表19-2 文件说明

文件名称	描述
job.properties	工作流的参数变量定义文件。
workflow.xml	工作流的规则定制文件。
lib	工作流运行依赖的 jar 包目录。

步骤 4 执行以下命令，编辑“job.properties”文件。

vi job.properties

修改如下内容：

更改“userName”的参数值为提交任务的人机用户名，例如“userName=oozieuser”。

步骤 5 执行 **oozie job** 命令，运行工作流文件。

oozie job -oozie https://*oozie 角色的主机名*:21003/oozie/ -config job.properties -run

说明

- 命令参数解释如下：

  -oozie 实际执行任务的 Oozie 服务器 URL

  -config 工作流属性文件

  -run 运行工作流

- 执行完工作流文件，显示“job id”表示提交成功，例如“job: 0000021-140222101051722-oozie-omm-W”。登录 Oozie 管理页面，查看运行情况。

  使用 **oozieuser** 用户，登录 Oozie WebUI 页面：https://*oozie 角色的 ip 地址*:21003/oozie 。

  Oozie 的 WebUI 界面中，可在页面表格根据“job id”查看已提交的工作流信息。

----结束

19.5.3 提交 Loader 任务

操作场景

该任务指导用户在使用 Oozie 客户端提交 Loader 任务。

说明

请下载使用最新版本的客户端。

前提条件

- Loader 和 Oozie 组件及客户端已经安装，并且正常运行。
- 已创建或获取访问 Oozie 服务的人机用户账号及密码。

说明

- 该用户需要从属于 hadoop、supergroup、hive 组，同时添加 Oozie 的角色操作权限。若使用 Hive 多实例，该用户还需要从属于具体的 Hive 实例组，如 hive3。
- 用户同时还需要至少有 manager_viewer 权限的角色。

- 获取运行状态的 Oozie 服务器（任意实例）URL，如“https://10.1.130.10:21003/oozie”。
- 获取运行状态的 Oozie 服务器主机名，如“10-1-130-10”。
- 获取 Yarn ResourceManager 主节点 IP，如 10.1.130.11。
- 创建需要调度的 Loader 作业，并获取该作业 ID。

操作步骤

以客户端安装用户，登录安装 Oozie 客户端的节点。

步骤 1 执行以下命令，获取安装环境信息。其中“/opt/client”为客户端安装路径，该操作的客户端目录只是举例，请根据实际安装目录修改。

source /opt/client/bigdata_env

步骤 2 判断集群认证模式。

- 安全模式，执行 **kinit** 命令进行用户认证。

  例如，使用 **oozieuser** 用户进行认证。

  kinit oozieuser
- 普通模式，执行步骤 4。

步骤 3 执行以下命令，进入样例目录。

cd /opt/client/Oozie/oozie-client-*/examples/apps/sqoop/

该目录下需关注文件如表 19-3 所示。

表19-3 文件说明

文件名称	描述
job.properties	工作流的参数变量定义文件。
workflow.xml	工作流的规则定制文件。

步骤 4 执行以下命令，编辑“job.properties”文件。

vi job.properties

修改如下内容：

更改“userName”的参数值为提交任务的人机用户名，例如“userName=oozieuser”。

步骤 5 执行以下命令，编辑“workflow.xml”文件。

vi workflow.xml

修改如下内容：

“command”的值修改为需要调度的已有 Loader 作业 ID，例如 1。

将“workflow.xml”文件上传至 "job.properties" 文件中的 HDFS 路径。

hdfs dfs -put -f workflow.xml /user/userName/examples/apps/sqoop

步骤 6 执行 **oozie job** 命令，运行工作流文件。

oozie job -oozie https://*oozie 角色的主机名*:21003/oozie/ -config job.properties -run

说明

- 命令参数解释如下：

-oozie 实际执行任务的 Oozie 服务器 URL

-config 工作流属性文件

-run 运行工作流

- 执行完工作流文件，显示 job id 表示提交成功，例如：job: 0000021-140222101051722-oozie-omm-W。登录 Oozie 管理页面，查看运行情况。

  使用 **oozieuser** 用户，登录 Oozie WebUI 页面：https://*oozie 角色的 ip 地址*:21003/oozie 。

  Oozie 的 WebUI 界面中，可在页面表格根据 jobid 查看已提交的工作流信息。

----结束

19.5.4 提交 DistCp 任务

操作场景

该任务指导用户在使用 Oozie 客户端提交 DistCp 任务。

说明

请下载使用最新版本的客户端。

前提条件

- HDFS 和 Oozie 组件安装完成且运行正常，客户端安装成功。

  如果当前客户端为旧版本，需要重新下载和安装客户端。
- 已创建或获取访问 Oozie 服务的人机用户账号及密码。

说明

- 该用户需要从属于 hadoop、supergroup、hive 组，同时添加 Oozie 的角色操作权限。若使用 Hive 多实例，该用户还需要从属于具体的 Hive 实例组，如 hive3。
- 用户同时还需要至少有 manager_viewer 权限的角色。

- 已获取运行状态的 Oozie 服务器（任意实例）URL，如“https://*10.1.130.10:21003*/oozie”。
- 已获取运行状态的 Oozie 服务器主机名，如“*10-1-130-10*”。
- 已获取 Yarn ResourceManager 主节点 IP，如“*10.1.130.11*”。

操作步骤

以客户端安装用户登录安装 Oozie 客户端的节点。

步骤 1 执行以下命令，获取安装环境信息。其中“/opt/client”为客户端安装路径，该操作的客户端目录只是举例，请根据实际安装目录修改。

source /opt/client/bigdata_env

步骤 2 判断集群认证模式。

- 安全模式，执行 **kinit** 命令进行用户认证。

  例如，使用 **oozieuser** 用户进行认证。

  kinit oozieuser

- 普通模式，执行步骤 4。

步骤 3 执行以下命令，进入样例目录。

cd /opt/client/Oozie/oozie-client-*/examples/apps/distcp/

该目录下需关注文件如表 19-4 所示。

表19-4 文件说明

文件名称	描述
job.properties	工作流的参数变量定义文件。
workflow.xml	工作流的规则定制文件。

步骤 4 执行以下命令，编辑“job.properties”文件。

vi job.properties

修改如下内容：

更改“userName”的参数值为提交任务的人机用户名，例如“userName=oozieuser”。

步骤 5 是否是跨安全集群的 DistCp。

- 是，执行步骤步骤 7。
- 否，则执行步骤步骤 9。

步骤 6 对两个集群进行跨 Manager 集群互信。

步骤 7 备份并且修改 workflow.xml 的文件内容，命令如下：

cp workflow.xml workflow.xml.bak

vi workflow.xml

修改以下内容：

```
<workflow-app xmlns="uri:oozie:workflow:1.0" name="distcp-wf">
   <start to="distcp-node"/>
   <action name="distcp-node">
      <distcp xmlns="uri:oozie:distcp-action:1.0">
         <resource-manager>${resourceManager}</resource-manager>
         <name-node>${nameNode}</name-node>
         <prepare>
            <delete
path="hdfs://target_ip:target_port/user/${userName}/${examplesRoot}/output-
data/${outputDir}"/>
         </prepare>
         <configuration>
            <property>
               <name>mapred.job.queue.name</name>
               <value>${queueName}</value>
            </property>
            <property>
```

```
                <name>oozie.launcher.mapreduce.job.hdfs-servers</name>

<value>hdfs://source_ip:source_port,hdfs://target_ip:target_port</value>
            </property>
         </configuration>
         <arg>${nameNode}/user/${userName}/${examplesRoot}/input-
data/text/data.txt</arg>

<arg>hdfs://target_ip:target_port/user/${userName}/${examplesRoot}/output-
data/${outputDir}/data.txt</arg>
         </distcp>
      <ok to="end"/>
      <error to="fail"/>
   </action>
   <kill name="fail">
      <message>DistCP failed, error
message[${wf:errorMessage(wf:lastErrorNode())}]</message>
   </kill>
   <end name="end"/>
</workflow-app>
```

其中“target_ip:target_port”为另一个互信集群的 HDFS active namenode 地址，例如：10.10.10.233:25000。

“source_ip:source_port ”为源集群的 HDFS active namenode 地址，例如：10.10.10.223:25000。

两个 IP 地址和端口都需要根据自身的集群实际情况修改。

步骤 8 执行 **oozie job** 命令，运行工作流文件。

oozie job -oozie https://*oozie 角色的主机名*:21003/oozie/ -config job.properties -run

说明

- 命令参数解释如下：

  -oozie 实际执行任务的 Oozie 服务器 URL

  -config 工作流属性文件

  -run 运行工作流

- 执行完工作流文件，显示“job id”表示提交成功，例如“job: 0000021-140222101051722-oozie-omm-W”。登录 Oozie 管理页面，查看运行情况。

  使用 **oozieuser** 用户，登录 Oozie WebUI 页面：https://*oozie 角色的 ip 地址*:21003/oozie 。

  Oozie 的 WebUI 界面中，可在页面表格根据“job id”查看已提交的工作流信息。

----结束

19.5.5 提交其它任务

操作场景

除了 Hive、Spark2x、Loader 任务，也支持使用 Oozie 客户端提交 MapReduce、Java、Shell、HDFS、SSH、SubWorkflow、Streaming、定时等任务。

说明

请下载使用最新版本的客户端。

前提条件

- Oozie 组件及客户端已经安装，并且正常运行。
- 已创建或获取访问 Oozie 服务的人机用户账号及密码。

说明

- Shell 任务：

  该用户需要从属于 hadoop、supergroup 组，添加 Oozie 的角色操作权限，并确保 Shell 脚本在每个 nodemanager 节点都有执行权限。

- SSH 任务：

  该用户需要从属于 hadoop、supergroup 组，添加 Oozie 的角色操作权限，并完成互信配置。

- 其他任务：

  该用户需要从属于 hadoop、supergroup 组，添加 Oozie 的角色操作权限，并具备对应任务类型所需的权限。

- 用户同时还需要至少 manager_viewer 权限的角色。

- 获取运行状态的 Oozie 服务器（任意实例）URL，如“https://10.1.130.10:21003/oozie”。
- 获取运行状态的 Oozie 服务器主机名，如“10-1-130-10”。
- 获取 Yarn ResourceManager 主节点 IP，如 10.1.130.11。

操作步骤

以客户端安装用户，登录安装 Oozie 客户端的节点。

步骤 1 执行以下命令，获取安装环境信息。其中“/opt/client”为客户端安装路径，该操作的客户端目录只是举例，请根据实际安装目录修改。

source /opt/client/bigdata_env

步骤 2 判断集群认证模式。

- 安全模式，执行 **kinit** 命令进行用户认证。

  例如，使用 **oozieuser** 用户进行认证。

  kinit oozieuser

- 普通模式，执行步骤 4。

步骤 3 根据提交任务类型，进入对应样例目录。

表19-5 样例目录列表

任务类型	样例目录
Mapreduce 任务	*客户端安装目录*/Oozie/oozie-client-*/examples/apps/map-reduce
Java 任务	*客户端安装目录*/Oozie/oozie-client-*/examples/apps/java-main
Shell 任务	*客户端安装目录*/Oozie/oozie-client-*/examples/apps/shell

任务类型	样例目录
Streaming 任务	*客户端安装目录*/Oozie/oozie-client-*/examples/apps/streaming
SubWorkflow 任务	*客户端安装目录*/Oozie/oozie-client-*/examples/apps/subwf
SSH 任务	*客户端安装目录*/Oozie/oozie-client-*/examples/apps/ssh
定时任务	*客户端安装目录*/Oozie/oozie-client-*/examples/apps/cron

说明

其他任务样例中已包含 HDFS 任务样例。

样例目录下需关注文件如表 19-6 所示。

表19-6 文件说明

文件名称	描述
job.properties	工作流的参数变量定义文件。
workflow.xml	工作流的规则定制文件。
lib	工作流运行依赖的 jar 包目录。
coordinator.xml	“cron”目录下存在，定时任务配置文件，用于设置定时策略。
oozie_shell.sh	“shell”目录下存在，提交 Shell 任务需要的 Shell 脚本文件。

步骤 4 执行以下命令，编辑“job.properties”文件。

vi job.properties

修改如下内容：

更改“userName”的参数值为提交任务的人机用户名，例如“userName=oozieuser”。

步骤 5 执行 **oozie job** 命令，运行工作流文件。

oozie job -oozie https://*oozie 角色的主机名*:21003/oozie -config *job.properties 文件所在路径* **-run**

例如：

oozie job -oozie https://10-1-130-10:21003/oozie -config

/opt/client/Oozie/oozie-client-*/examples/apps/map-reduce/job.properties -run

说明

- 命令参数解释如下：

  -oozie 实际执行任务的 Oozie 服务器 URL

-config 工作流属性文件

-run 运行工作流

- 执行完工作流文件，显示 job id 表示提交成功，例如：job: 0000021-140222101051722-oozie-omm-W。登录 Oozie 管理页面，查看运行情况。

  使用 **oozieuser** 用户，登录 Oozie WebUI 页面：https://*oozie 角色的 ip 地址*:21003/oozie 。

  Oozie 的 WebUI 界面中，可在页面表格根据 jobid 查看已提交的工作流信息。

----结束

19.6 使用 Hue 提交 Oozie 作业

19.6.1 创建工作流

操作场景

用户通过 Hue 管理界面可以进行提交 Oozie 作业，提交作业之前，首先需要创建一个工作流。

前提条件

使用 Hue 提交 Oozie 作业之前，需要提前配置好 Oozie 客户端，并上传样例配置文件和 jar 至 HDFS 指定目录，具体操作请参考 19.2 使用 Oozie 客户端章节。

操作步骤

准备一个具有对应组件操作权限的用户。

例如：使用 **admin** 用户登录 FusionInsight Manager，选择“系统 > 用户 > 添加用户”，创建一个“人机”用户“hueuser”，并加入“hive”、“hadoop”、“supergroup”组和“System_administrator”角色，主组为“hive”。

步骤 1 使用步骤 1 创建的用户登录 FusionInsight Manager（首次登录需要修改密码），选择“集群 > 服务 > Hue”，单击“Hue WebUI”右侧的链接，进入 Hue WebUI 界面。

步骤 2 在界面左侧导航栏单击  ，选择“Workflow”，打开 Workflow 编辑器。

步骤 3 单击“文档”后的下拉框选择“操作”， 在操作列表中选择需要创建的作业类型，将其拖到操作界面中即可。

不同类型作业提交请参考以下章节：

- 19.6.2.1 提交 Hive2 作业
- 19.6.2.2 提交 Spark2x 作业
- 19.6.2.3 提交 Java 作业
- 19.6.2.4 提交 Loader 作业
- 19.6.2.5 提交 Mapreduce 作业
- 19.6.2.6 提交 Sub workflow 作业
- 19.6.2.7 提交 Shell 作业
- 19.6.2.8 提交 HDFS 作业
- 19.6.2.9 提交 Streaming 作业
- 19.6.2.10 提交 Distcp 作业

----结束

19.6.2 提交 Workflow 工作流作业

19.6.2.1 提交 Hive2 作业

操作场景

该任务指导用户通过 Hue 界面提交 Hive2 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“HiveServer2 脚本”按钮  ，将其拖到操作区中。

步骤 2 在弹出的“HiveServer2 Script”窗口中配置 HDFS 上的脚本路径，例如“/user/admin/examples/apps/hive2/script.q”，然后单击“添加”。

步骤 3 单击“参数+”，添加输入输出参数。

例如输入参数为“INPUT=/user/admin/examples/input-data/table”，输出参数为“OUTPUT=/user/admin/examples/output-data/hive2_workflow”。

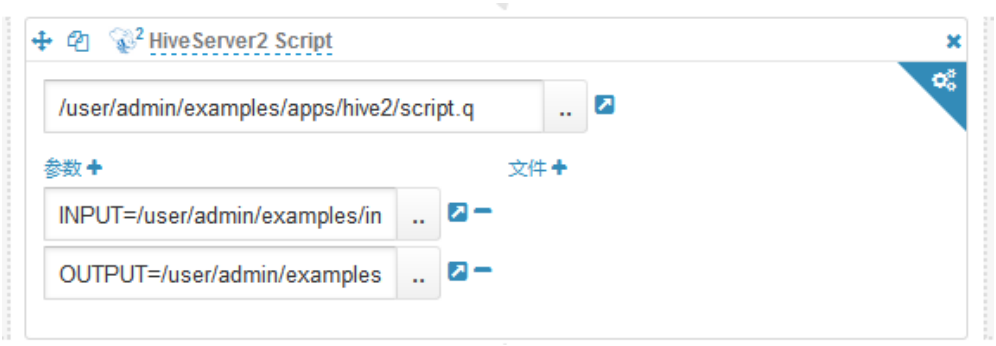

步骤 4 单击右上角的配置按钮  。在打开的配置界面中，单击“删除+”，添加删除目录，例如“/user/admin/examples/output-data/hive2_workflow”。

步骤 5 配置“作业 XML”，值为“*客户端安装目录*/Oozie/oozie-client-*/examples/apps/hive/hive-site.xml”上传至 HDFS 目录中所在路径，例如“/user/admin/examples/apps/hive2/hive-site.xml”。HiveServer2 URL”及其他参数无需配置。

说明

若以上的参数和值在使用过程中发生了修改，可在“Oozie 客户端安装目录/oozie-client-*/conf/hive-site.xml”文件中查询。

步骤 6 单击 Oozie 编辑器右上角的 。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“Hive2-Workflow”。

步骤 7 保存完成后，单击 ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.2 提交 Spark2x 作业

操作场景

该任务指导用户通过 Hue 界面提交 Spark2x 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“Spark 程序”按钮 ，将其拖到操作区中。

步骤 2 在弹出的“Spark”窗口配置“Files”，例如“hdfs://hacluster/user/admin/examples/apps/spark2x/lib/oozie-examples.jar”。配置“jar/py name”，例如“oozie-examples.jar” ，配置完成后单击“添加”。

步骤 3 配置“Main class”的值。例如“org.apache.oozie.example.SparkFileCopy”。

步骤 4 单击“参数+”，添加输入输出相关参数。

例如添加：

- “hdfs://hacluster/user/admin/examples/input-data/text/data.txt”
- “hdfs://hacluster/user/admin/examples/output-data/spark_workflow”

步骤 5 在“Options list”文本框指定 spark 参数，例如“--conf spark.yarn.archive=hdfs://hacluster/user/spark2x/jars/*xxx*/spark-archive-2x.zip --conf spark.eventLog.enabled=true --conf spark.eventLog.dir=hdfs://hacluster/spark2xJobHistory2x”。

说明

此处版本号“xxx”为示例，可登录 FusionInsight Manager 界面，单击右上角的，在下拉框中单击“关于”，在弹框中查看 Manager 版本号。

步骤 6 单击右上角的配置按钮  。配置“Spark Master”的值，例如“yarn-cluster”。配置“Mode”的值，例如“cluster”。

步骤 7 在打开的配置界面中，单击“删除+”，添加删除目录，例如“hdfs://hacluster/user/admin/examples/output-data/spark_workflow”。

步骤 8 单击“属性+”，添加 oozie 使用的 sharelib，左边文本框填写属性名称“oozie.action.sharelib.for.spark”，右边文本框填写属性值“spark2x”。

步骤 9 单击 Oozie 编辑器右上角的  。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“Spark-Workflow”。

步骤 10 保存完成后，单击  ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.3 提交 Java 作业

操作场景

该任务指导用户通过 Hue 界面提交 Java 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“Java 程序”按钮  ，将其拖到操作区中。

步骤 2 在弹出的“Java program”窗口中配置“Jar name”的值，例如“/user/admin/examples/apps/java-main/lib/oozie-examples-5.1.0.jar”。配置“Main class”的值，例如“org.apache.oozie.example.DemoJavaMain”。然后单击“添加”。

步骤 3 单击 Oozie 编辑器右上角的  。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“Java-Workflow”。

步骤 4 保存完成后，单击  ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.4 提交 Loader 作业

操作场景

该任务指导用户通过 Hue 界面提交 Loader 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“Loader”按钮 ，将其拖到操作区中。

步骤 2 在弹出的“Loader”窗口中配置“Job id”的值，例如“1”。然后单击“添加”。

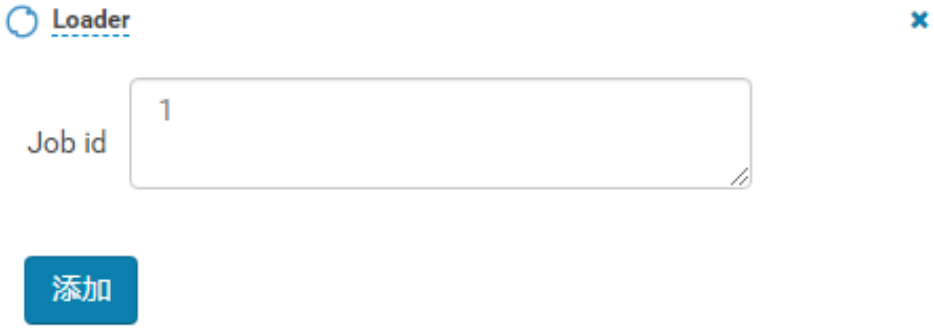

说明

“Job id”是需要编排的 Loader 作业的 ID 值，可从 Loader 页面获取。

创建需要调度的 Loader 作业，并获取该作业 ID，具体操作请参见 17 使用 Loader 相关章节。

步骤 3 单击 Oozie 编辑器右上角的 。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“Loader-Workflow”。

步骤 4 保存完成后，单击 ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.5 提交 Mapreduce 作业

操作场景

该任务指导用户通过 Hue 界面提交 Mapreduce 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“MapReduce 作业”按钮  ，将其拖到操作区中。

步骤 2 在弹出的“MapReduce job”窗口中配置“Jar name”的值，例如“/user/admin/examples/apps/map-reduce/lib/oozie-examples-5.1.0.jar”。然后单击“添加”。

步骤 3 单击“属性+”，添加输入输出相关属性。

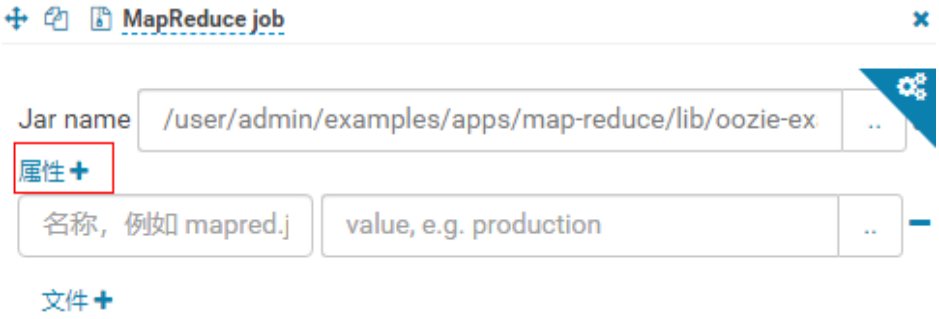

例如配置“mapred.input.dir”的值为“/user/admin/examples/input-data/text”，配置“mapred.output.dir”的值为“/user/admin/examples/output-data/map-reduce_workflow”。

步骤 4 单击右上角的配置按钮  。在打开的配置界面中，单击“删除+”，添加删除目录，例如“/user/admin/examples/output-data/map-reduce_workflow”。

步骤 5 单击 Oozie 编辑器右上角的  。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“MapReduce-Workflow”。

步骤 6 保存完成后，单击  ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.6 提交 Sub workflow 作业

操作场景

该任务指导用户通过 Hue 界面提交 Sub Workflow 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“子 Workflow”按钮  ，将其拖到操作区中。

步骤 2 在弹出的“Sub workflow”窗口中配置“Sub-workflow”的值，例如从下拉列表中选取“Java-Workflow”（这个值是已经创建好的工作流之一），然后单击“添加”。

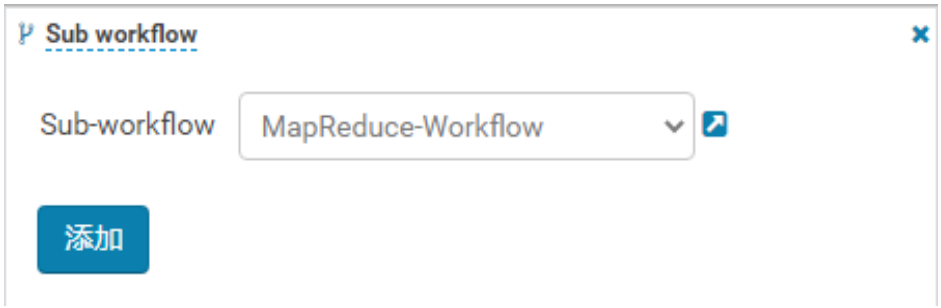

步骤 3 单击 Oozie 编辑器右上角的 。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“Subworkflow-Workflow”。

步骤 4 保存完成后，单击 ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.7 提交 Shell 作业

操作场景

该任务指导用户通过 Hue 界面提交 Shell 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“Shell”按钮 ，将其拖到操作区中。

步骤 2 在弹出的“Shell”窗口中配置“Shell command”的值，例如“oozie_shell.sh”，然后单击“添加”。

步骤 3 单击“文件+”，添加 Shell 命令执行文件或 Oozie 样例执行文件，可以选择存储在 HDFS 的文件或本地文件。

- 若文件存储在 HDFS 上，选择“.sh”文件所在路径即可，例如“user/hueuser/shell/oozie_shell.sh”。

- 若选择本地文件，则需在“选择文件”界面，单击“上传文件”，上传本地文件，文件上传成功后，选择该文件即可。

步骤 4 如果执行的 Shell 文件需要传递参数，可单击“参数+”设置参数。

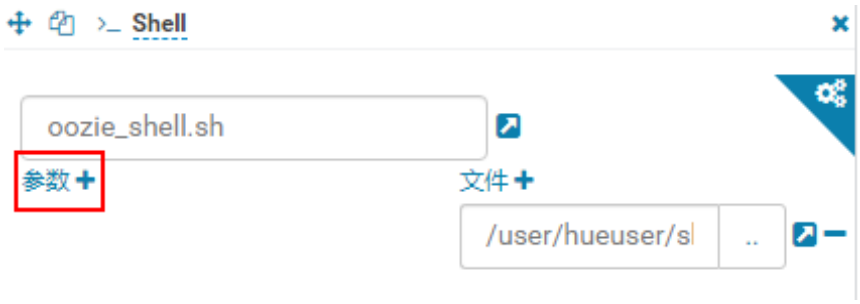

说明

传递参数的顺序需要和 Shell 脚本中保持一致。

步骤 5 单击 Oozie 编辑器右上角的 。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“Shell-Workflow”。

步骤 6 保存完成后，单击 ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

说明

- 配置 Shell 命令为 Linux 指令时，请指定为原始指令，不要使用快捷键指令。例如：**ls -l**,不要配置成 **ll**。可配置成 Shell 命令 **ls** ，参数添加一个 “-l”。
- Windows 上传 Shell 脚本到 HDFS 时，请保证 Shell 脚本的格式为 Unix，格式不正确会导致 Shell 作业提交失败。

----结束

19.6.2.8 提交 HDFS 作业

操作场景

该任务指导用户通过 Hue 界面提交 HDFS 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“Fs”按钮  ，将其拖到操作区中。

步骤 2 在弹出的“Fs”窗口中单击“添加”。

步骤 3 单击“CREATE DIRECTORY+”，添加待创建的 HDFS 目录。例如“/user/admin/examples/output-data/mkdir_workflow”和“/user/admin/examples/output-data/mkdir_workflow1”。

注意

若单击了“DELETE PATH+”添加待删除的 HDFS 路径，该参数不能为空，否则会默认删除 HDFS 的“/user{*提交用户名*}”目录，可能会导致其他任务运行异常。

步骤 4 单击 Oozie 编辑器右上角的  。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“HDFS-Workflow”。

步骤 5 保存完成后，单击  ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.9 提交 Streaming 作业

操作场景

该任务指导用户通过 Hue 界面提交 Streaming 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“数据流”按钮  ，将其拖到操作区中。

步骤 2 在弹出的“Streaming”窗口中配置“Mapper”的值，例如“/bin/cat”。配置“Reducer”的值，例如“/usr/bin/wc”。然后单击“添加”。

步骤 3 单击“文件+”，添加运行所需的文件。

例如“/user/oozie/share/lib/mapreduce-streaming/hadoop-streaming-*xxx*.jar”和“/user/oozie/share/lib/mapreduce-streaming/oozie-sharelib-streaming-5.1.0.jar”。

步骤 4 单击右上角的配置按钮  。在打开的配置界面中，单击“删除+”，添加删除目录，例如“/user/admin/examples/output-data/streaming_workflow”。

步骤 5 单击“属性+”，添加下列属性。

- 左边框填写属性名称“mapred.input.dir”，右边框填写属性值“/user/admin/examples/input-data/text”。
- 左边框填写属性名称“mapred.output.dir”，右边框填写属性值“/user/admin/examples/output-data/streaming_workflow”。

步骤 6 单击 Oozie 编辑器右上角的  。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“Streaming-Workflow”。

步骤 7 保存完成后，单击  ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.10 提交 Distcp 作业

操作场景

该任务指导用户通过 Hue 界面提交 Distcp 类型的 Oozie 作业。

操作步骤

创建工作流，请参考 19.6.1 创建工作流。

步骤 1 在工作流编辑页面，选择“DistCp”按钮  ，将其拖到操作区中。

步骤 2 当前 DistCp 操作是否是跨集群操作。

- 是，执行步骤 4。
- 否，执行步骤 7。

步骤 3 对两个集群进行跨 Manager 集群互信。

步骤 4 在弹出的“Distcp”窗口中配置“源”的值，例如“hdfs://hacluster/user/admin/examples/input-data/text/data.txt”。配置“目标”的值，例如

“hdfs://target_ip:target_port/user/admin/examples/output-data/distcp-workflow/data.txt”。然后单击“添加”。

步骤 5 单击右上角的配置按钮，在打开的“属性”页签配置界面中，单击“属性+”，在左边文本框中填写属性名称“oozie.launcher.mapreduce.job.hdfs-servers”，在右边文本框中填写属性值“hdfs://*source_ip:source_port*,hdfs://*target_ip:target_port*”，执行步骤 8。

说明

source_ip：源集群的 HDFS 的 NameNode 的业务地址。

source_port：源集群的 HDFS 的 NameNode 的端口号。

target_ip：目标集群的 HDFS 的 NameNode 的业务地址。

target_port：目标集群的 HDFS 的 NameNode 的端口号。

步骤 6 在弹出的“Distcp”窗口中配置“源”的值，例如“/user/admin/examples/input-data/text/data.txt”。配置“目标”的值，例如“/user/admin/examples/output-data/distcp-workflow/data.txt”。然后单击“添加”。

步骤 7 单击右上角的配置按钮，在打开的配置界面中，单击“删除+”，添加删除目录，例如“/user/admin/examples/output-data/distcp-workflow”。

步骤 8 单击 Oozie 编辑器右上角的 。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“Distcp-Workflow”。

步骤 9 保存完成后，单击，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.11 互信操作示例

操作场景

在使用 Oozie 节点通过 SSH 作业执行外部节点的 Shell，需要单向免密互信时，可以参考此示例。

前提条件

已经安装 Oozie，而且能与外部节点（SSH 连接的节点）通信。

操作步骤

在外部节点上确保连接 SSH 时使用的用户存在，且该用户“~/.ssh”目录存在。

步骤 1 使用 **omm** 用户登录 Oozie 所在节点，查看“~/.ssh/id_rsa.pub”文件是否存在。

- 是，执行步骤 3。
- 否，执行以下命令生成公私钥：

  ssh-keygen -t rsa

步骤 2 以 **omm** 用户登录 oozie 实例所在节点，执行以下命令配置互信：

ssh-copy-id -i ~/.ssh/id_rsa.pub *运行 SSH 任务的用户@运行 SSH 任务的节点的 IP 地址*

执行该命令后需要输入*运行 SSH 任务的用户*的密码。

说明

- Shell 所在节点（外部节点）的账户需要有权限执行 Shell 脚本并对于所有 Shell 脚本里涉及到的所有目录文件有足够权限。
- 如果 Oozie 具有多个节点，需要在所有 Oozie 节点执行步骤 2~步骤 3。

步骤 3 使用 **omm** 用户登录依次其他 Oozie 所在节点，重复执行步骤 2-步骤 3。

----结束

19.6.2.12 提交 SSH 作业

操作场景

该任务指导用户通过 Hue 界面提交 SSH 类型的 Oozie 作业。

由于有安全攻击的隐患，所以默认是无法提交 SSH 作业的，如果想使用 SSH 功能，需要手动开启。

操作步骤

开启 SSH 功能（若当前集群无“oozie.job.ssh.enable”参数，则跳过该操作）：

1. 在 FusionInsight Manager 界面，选择“集群 > 服务 > Oozie > 配置 > 全部配置 > oozie（角色） > 安全”，修改“oozie.job.ssh.enable”的值为“true”，单击“保存”，在弹出的“保存配置”界面单击“确定”，保存配置。
2. 在 Oozie 的“概览”界面，选择右上角“更多 > 重启服务”，重启 Oozie 服务。

步骤 1 创建工作流，请参考 19.6.1 创建工作流。

步骤 2 添加互信操作，请参考 19.6.2.11 互信操作示例。

步骤 3 在工作流编辑页面，选择“Ssh”按钮  ，将其拖到操作区中。

步骤 4 在弹出的“Ssh”窗口中配置“User and Host”和“Ssh command”的值，然后单击“添加”。

说明

“User and Host”配置项中的 User 为步骤 3 中配置互信的用户，格式为：*运行 SSH 任务的用户@运行 SSH 任务的节点的 IP 地址*，例如该配置项的值可设置为：root@100.x.x.x。

步骤 5 单击 Oozie 编辑器右上角的  。

保存前如果需要修改作业名称（默认为“My Workflow”），可以直接单击该名称进行修改，例如“Ssh-Workflow”。

步骤 6 保存完成后，单击  ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.2.13 提交 Hive 脚本

操作场景

该任务指导用户通过 Hue 界面提交 Hive 脚本作业。

操作步骤

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 在界面左侧导航栏选择“  > Workflow”，打开 Workflow 编辑器。

步骤 2 单击“文档”， 在操作列表中选择 Hive 脚本  ，将其拖到操作界面中。

步骤 3 在弹出的“HiveServer2 Script”框中，选择之前保存的 Hive 脚本，关于保存 Hive 脚本参考 13.4 在 Hue WebUI 使用 HiveQL 编辑器章节。选择脚本后单击“添加”。

步骤 4 配置“作业 XML”，例如配置为 hdfs 路径“/user/admin/examples/apps/hive2/hive-site.xml”，配置方式参考 19.6.2.1 提交 Hive2 作业。

步骤 5 单击 Oozie 编辑器右上角的 。

步骤 6 保存完成后，单击 ，提交该作业。

作业提交后，可通过 Hue 界面查看作业的详细信息、日志、进度等相关内容。

----结束

19.6.3 提交 Coordinator 定时调度作业

操作场景

该任务指导用户通过 Hue 界面提交定时调度类型的作业。

前提条件

提交 Coordinator 任务之前需要提前配置好相关的 workflow 作业。

操作步骤

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 在界面左侧导航栏单击 ，选择“计划”，打开 Coordinator 编辑器。

步骤 2 在作业编辑界面中单击“My Schedule”修改作业的名称。

步骤 3 单击“选择 Workflow...”选择需要编排的 Workflow。

步骤 4 选择好 Workflow，根据界面提示设置作业执行的频率，如果执行的 Workflow 需要传递参数，可单击“+添加参数”设置参数，然后单击右上角的 保存作业。

说明

因时区转化的原因，此处时间有可能会与当地系统实际时间差异数个小时。

步骤 5 单击编辑器右上角的，设置定时任务执行的时间范围的起始值与结束值，然后单击“提交”提交作业。

说明

因时区转化的原因，此处时间有可能会与当地系统实际时间差异数个小时。

----结束

19.6.4 提交 Bundle 批处理作业

操作场景

当同时存在多个定时任务的情况下，用户可以通过 Bundle 任务进行批量管理作业。该任务指导用户通过 Hue 界面提交批量类型的作业。

前提条件

提交 Bundle 批处理之前需要提前配置好相关的 Workflow 和 Coordinator 作业。

操作步骤

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 在界面左侧导航栏单击，选择“Bundle”，打开 Bundle 编辑器。

步骤 2 在作业编辑界面中单击“My Bundle”修改作业的名称。

步骤 3 单击“+添加 Coordinator”选择需要编排的 Coordinator 作业。

步骤 4 根据界面提示设置 Coordinator 任务调度的开始、结束时间，然后单击右上角的 保存作业。

步骤 5 单击编辑器右上角的 ，在弹出菜单选择 ，设置 Bundle 任务的启动时间，根据实际需求单击“+添加参数”设置提交参数，然后关闭对话框保存设置。

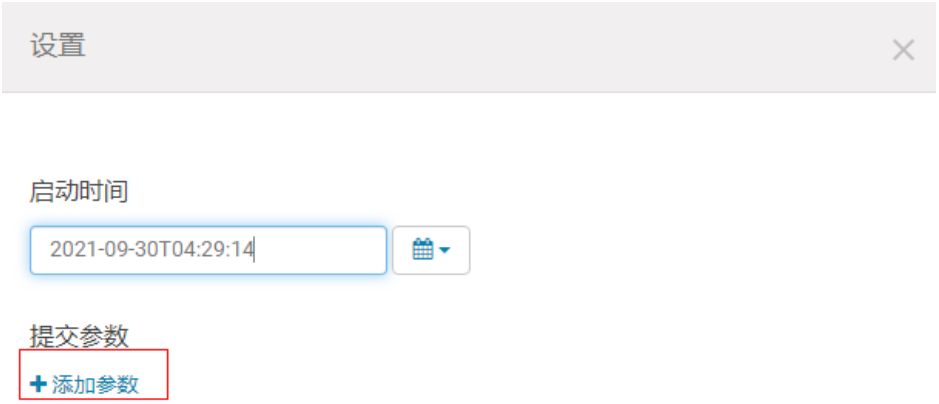

说明

因时区转化的原因，此处时间有可能会与当地系统实际时间差异数个小时。

步骤 6 单击编辑器右上角的 ，在弹出的确认界面中单击“提交”提交作业。

----结束

19.6.5 作业结果查询

操作场景

提交作业后，可以通过 Hue 界面查看具体作业的执行情况。

操作步骤

访问 Hue WebUI，请参考 13.2 访问 Hue 的 WebUI。

步骤 1 单击菜单左侧的 ，在打开的页面中可以查看 Workflow、计划、Bundles 任务的相关信息。

默认显示当前集群的所有作业。

说明

作业浏览器显示的数字表示集群中所有作业的总数。

“作业浏览器”将显示作业以下信息：

表19-7 MRS 作业属性介绍

属性名	描述
名称	表示作业的名称。
用户	表示启动该作业的用户。
类型	表示作业的类型。
状态	表示作业的状态，包含“成功”、“正在运行”、“失败”。
进度	表示作业运行进度。
组	表示作业所属组。
开始	表示作业开始时间。
持续时间	表示作业运行使用的时间。
Id	表示作业的编号，由系统自动生成。

说明

如果 MRS 集群安装了 Spark 组件，则默认会启动一个作业“Spark-JDBCServer”，用于执行任务。

----结束

19.7 Oozie 日志介绍

日志描述

日志路径：Oozie 相关日志的默认存储路径为：

- 运行日志：“/var/log/Bigdata/oozie”。
- 审计日志：“/var/log/Bigdata/audit/oozie”。

日志归档规则：Oozie 的日志分三类：运行日志、 脚本日志和审计日志。运行日志每个文件最大 20M，最多 20 个。审计日志每个文件最大 20M，最多 20 个。

说明

“oozie.log”日志每小时生成一个日志压缩文件，默认保留 720 个（一个月的日志）。

表19-8 Oozie 日志列表

日志类型	日志文件名	描述
运行日	jetty.log	Oozie 内置 jetty 服务器日志，处理

日志类型	日志文件名	描述
志		OozieServlet 的 request/response 信息
	jetty.out	Oozie 进程启动日志
	oozie_db_temp.log	Oozie 数据库连接日志
	oozie-instrumentation.log	Oozie 仪表盘日志，主要记录 Oozie 运行状态，各组件的配置信息
	oozie-jpa.log	openJPa 运行日志
	oozie.log	Oozie 运行日志
	oozie-<SSH_USER>-<DATE>-<PID>-gc.log	Oozie 服务垃圾回收日志
	oozie-ops.log	Oozie 操作日志
	check-serviceDetail.log	Oozie 健康检查日志
	oozie-error.log	Oozie 运行错误日志
	threadDump-<DATE>.log	记录服务进程正常退出时堆栈信息的日志
脚本日志	postinstallDetail.log	安装后启动前的工作日志
	prestartDetail.log	预启动日志
	startDetail.log	服务启动日志
	stopDetail.log	服务停止日志
	upload-sharelib.log	sharelib 上传操作日志
审计日志	oozie-audit.log	审计日志

日志级别

Oozie 中提供了如表 19-9 所示的日志级别。

日志级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表19-9 日志级别

级别	描述
ERROR	ERROR 表示错误日志，可能会导致进程异常。
WARN	WARN 表示当前事件处理存在异常信息。

级别	描述
INFO	INFO 表示系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及数据库底层数据传输的信息。

如果您需要修改日志级别，请执行如下操作：

登录 FusionInsight Manager 系统。

步骤 2 选择“集群 > *待操作集群的名称* > 服务 > Oozie > 配置”。

步骤 3 选择“全部配置”。

步骤 4 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 5 选择所需修改的日志级别。

步骤 6 单击“保存”，单击“确定”，处理结束后生效。

----结束

日志格式

Oozie 的日志格式如下所示。

表19-10 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS><Log Level><日志事件的发生位置>|<log 中的 message>	2015-05-29 21:01:45,268 INFO StatusTransitService$StatusTransitRunnable: 539 - USER[-] GROUP[-] Released lock for [org.apache.oozie.service.StatusTransitService]
脚本日志	<yyyy-MM-dd HH:mm:ss,SSS><主机名><Log Level><log 中的 message>	2015-06-01 17:18:03 001 suse11-192-168-0-111 oozie INFO Running oozie service check script
审计日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<线程名称>|<log 中的 message>|<日志事件的发生位置>	2015-06-01 22:38:41,323 | INFO | http-bio-21003-exec-8 | IP [192.168.0.111] USER [null], GROUP [null], APP [null], JOBID [null], OPERATION [null], PARAMETER [null], RESULT [SUCCESS], HTTPCODE [200], ERRORCODE [null], ERRORMESSAGE [null] | org.apache.oozie.util.XLog.log(XLog.java:539)

19.8 Oozie 常见问题

19.8.1 Oozie 定时任务没有准时运行

问题

在 Hue 或者 Oozie 客户端设置执行 Coordinator 定时任务，但没有准时执行。

回答

需要使用 UTC 时间，例如在“job.properties”中配置“start=2016-12-20T09:00Z”。

19.8.2 HDFS 上更新了 oozie 的 share lib 目录但没有生效

问题

在 HDFS 的“/user/oozie/share/lib”目录上传了新的 jar 包，但执行任务时仍然报找不到类的错误。

回答

在客户端执行如下命令刷新目录：

oozie admin -oozie https://xxx.xxx.xxx.xxx:21003/oozie -sharelibupdate

19.8.3 Oozie 常用排查手段

1. 根据任务在 Yarn 上的任务日志排查，首先把实际的运行任务，比如 Hive SQL 通过 beeline 运行一遍，确认 Hive 无问题。
2. 出现“classnotfoundException”等报错，排查“/user/oozie/share/lib”路径下各组件有没有报错的类的 Jar 包，如果没有，添加 Jar 包并执行 19.8.2 HDFS 上更新了 oozie 的 share lib 目录但没有生效。如果执行了更新“share lib”目录依然报找不到类，那么可以查看执行更新“share lib”的命令打印出来的路径“sharelibDirNew”是否是“ /user/oozie/share/lib”， 一定不能是其它目录。

```
[root@host-                client]#
[root@host-                client]# oozie admin -oozie https://h                :21003/oozie/ -sharelibupdate
INFO CMD=admin -oozie https://host                21003/oozie/ -sharelibupdate
SLF4J: Class path contains multiple SLF4J bindings.
SLF4J: Found binding in [jar:file:/opt/client/Oozie/oozie-client-5.1.0-hw-ei-313001-SNAPSHOT/lib/slf4j-log4j12-1.7.30.jar!/org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: Found binding in [jar:file:/opt/client/Oozie/oozie-client-5.1.0-hw-ei-313001-SNAPSHOT/lib/slf4j-simple-1.7.30.jar!/org/slf4j/impl/StaticLoggerBinder.class]
SLF4J: See http://www.slf4j.org/codes.html#multiple_bindings for an explanation.
SLF4J: Actual binding is of type [org.slf4j.impl.Log4jLoggerFactory]
[ShareLib update status]
        sharelibDirOld = /user/oozie/share/lib
        host = https://                0:21003/oozie
        sharelibDirNew = /user/oozie/share/lib
        status = Successful
```

3. 出现 NosuchMethodError，排查“/user/oozie/share/lib”路径下各组件的 Jar 包是不是有多个版本，注意业务本身上传的 Jar 包冲突，可通过 Oozie 在 Yarn 上的运行日志打印的加载的 Jar 包排查是否有 Jar 包冲突。
4. 自研代码运行异常，可以先运行 Oozie 的自带样例，排除 Oozie 自身的异常。
5. 寻求技术人员的支持，需要收集 Yarn 上 Oozie 任务运行日志、Oozie 自身的日志及组件的运行的日志，例如使用 Oozie 运行 Hive 报异常，需收集 Hive 的日志。

20 使用 Ranger

20.1 登录 Ranger 管理界面

Ranger 服务提供了集中式的权限管理框架，可以对 HDFS、HBase、Hive、Yarn 等组件进行细粒度的权限访问控制，并且提供了 Web UI 方便 Ranger 管理员进行操作。

Ranger 用户类型

Ranger 中的用户可分为 Admin、User、Auditor 等类型，不同用户具有的 Ranger 管理界面查看和操作权限不同。

- Admin：Ranger 安全管理员，可查看所有页面内容，进行服务权限管理插件及权限访问控制策略的管理操作，可查看审计信息内容，可进行用户类型设置。
- Auditor：Ranger 审计管理员，可查看服务权限管理插件及权限访问控制策略的内容。
- User：普通用户，可以被 Ranger 管理员赋予具体权限。

登录 Ranger 管理界面

安全模式（集群开启了 Kerberos 认证）

使用 **admin** 用户登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。选择“集群 > 服务 > Ranger”，进入 Ranger 服务概览页面。

步骤 1 单击“基本信息”区域中的“RangerAdmin”，进入 Ranger WebUI 界面。

- **admin** 用户在 Ranger 中的用户类型为“User”，只能查看 Access Manager 和 Security Zone 页面。
- 如需查看所有管理页面，需要切换至 **rangeradmin** 用户或者其他具有 Ranger 管理员权限的用户：
  a. 在 Ranger WebUI 界面，单击右上角用户名，选择“Log Out”，退出当前用户。

b. 使用 **rangeradmin** 用户（默认密码为 Rangeradmin@123）或者其他具有 Ranger 管理员权限用户重新登录。

----结束

普通模式（集群关闭了 Kerberos 认证）：

使用 **admin** 用户登录 FusionInsight Manager，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。选择“集群 > 服务 > Ranger”，进入 Ranger 服务概览页面。

步骤 2 单击“基本信息”区域中的“RangerAdmin”，进入 Ranger WebUI 界面。

admin 用户在 Ranger 中的用户类型为“Admin”，能查看 Ranager 所有管理页面，无需切换至 **rangeradmin** 用户。

说明

普通模式下使用 **rangeradmin** 用户登录 Ranger WebUI 界面，页面报错 401。

----结束

在 Ranger 管理首页可查看当前 Ranger 已集成的各服务权限管理插件，用户可通过对应插件设置更细粒度的权限，具体主要操作页面功能描述参见表 20-1。

表20-1 Ranger 界面操作入口功能描述

入口	功能描述
Access Manager	查看当前 Ranger 已集成的各服务权限管理插件，用户可通过对应插件设置更细粒度的权限，具体操作请参考 20.3 配置组件权限策略。
Audit	查看 Ranger 运行及权限管控相关审计日志信息，具体操作请参考 20.4 查看 Ranger 审计信息。
Security Zone	配置安全区域，Ranger 管理员可将各组件的资源切分为多个区域，由不同 Ranger 管理员为服务的指定资源设置安全策略，以便更好的管理，具体操作可参考 20.5 配置 Ranger 安全区。
Settings	查看 Ranger 相关权限设置信息，例如查看用户、用户组、Role 等，具体操作可参考 20.6 查看 Ranger 权限信息

20.2 启用 Ranger 鉴权

操作场景

该章节指导用户如何启用 Ranger 鉴权。安全模式默认开启 Ranger 鉴权，普通模式默认关闭 Ranger 鉴权。

操作步骤

登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。选择“集群 > 服务 > *需要启用 Ranger 鉴权的服务名称*”。

步骤 1 在服务“概览”页面右上角单击“更多”，选择“启用 Ranger 鉴权”。在弹出的对话框中输入密码，单击“确定”，操作成功后单击“完成”。

说明

- 如果“启用 Ranger 鉴权”是灰色，表示已开启 Ranger 鉴权，如图 20-1 所示。
- 已启用 Ranger 授权的组件（HDFS 与 Yarn 除外），Manager 上非系统默认角色的权限将无法生效，需要通过配置 Ranger 策略为用户组赋权。

图20-1 启用 Ranger 鉴权

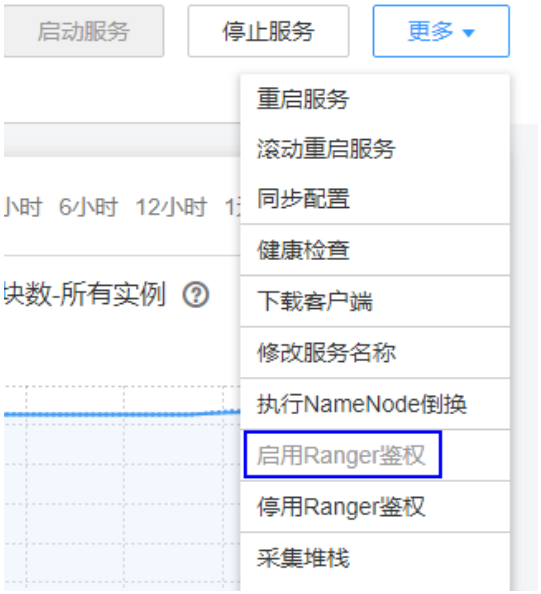

步骤 2 滚动重启服务或者重启服务。

----结束

20.3 配置组件权限策略

新安装的 MRS 集群默认安装 Ranger 服务并启用了 Ranger 鉴权模型，Ranger 管理员可以通过组件权限插件对组件资源的访问设置细粒度的安全访问策略。

目前安全模式集群中支持 Ranger 的组件包括：CDL、HDFS、Yarn、HBase、Hive、Spark2x、Kafka、Elasticsearch、HetuEngine。

通过 Ranger 配置用户权限策略

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 在 Ranger 首页的“Service Manager”区域内，单击组件名称下的权限插件名称，即可进入组件安全访问策略列表页面。

说明

各组件的策略列表中，系统默认会生成若干条目，用于保证集群内的部分默认用户或用户组的权限（例如 supergroup 用户组），请勿删除，否则系统默认用户或用户组的权限会受影响。

步骤 2 单击“Add New Policy”，根据业务场景规划配置相关用户或者用户组的资源访问策略。

不同组件的访问策略配置样例参考：

- 20.7 添加 CDL 的 Ranger 访问权限策略
- 20.8 添加 HDFS 的 Ranger 访问权限策略
- 20.9 添加 HBase 的 Ranger 访问权限策略
- 20.10 添加 Hive 的 Ranger 访问权限策略
- 20.11 添加 Yarn 的 Ranger 访问权限策略
- 20.12 添加 Spark2x 的 Ranger 访问权限策略
- 20.13 添加 Kafka 的 Ranger 访问权限策略
- 20.14 添加 HetuEngine 的 Ranger 访问权限策略

策略添加后，需等待 30 秒左右，待系统生效。

说明

组件每次启动都会检查组件默认的 Ranger Service 是否存在，如果不存在则会创建以及为其添加默认 Policy。如果用户在使用过程中误删了 Service，可以重启或者滚动重启相应组件服务来恢复，若是误删了默认 Policy，可先手动删除 Service，再重启组件服务。

步骤 3 单击“Access Manager > Reports”，可查看各组件所有的安全访问策略。

系统策略较多时，可通过策略名称、类型、组件、资源对象、策略标签、安全区域、用户或用户组等信息进行过滤搜索，也可以单击“Export”导出相关策略内容。

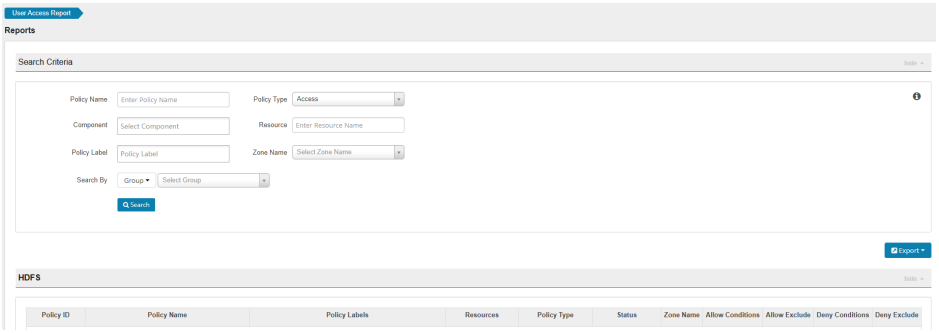

说明

- 对于同一个固定资源对象通常只能配置一条策略，多条策略针对的具体资源对象重复时将无法保存。

- 配置策略时，不同条件的优先级可参考 Ranger 权限策略条件判断优先级。

----结束

Ranger 权限策略条件判断优先级

配置资源的权限策略时，可配置针对该资源的允许条件（Allow Conditions）、允许例外条件（Exclude from Allow Conditions）、拒绝条件（Deny Conditions）以及拒绝例外条件（Exclude from Deny Conditions），以满足不同场景下的例外需求。

不同条件的优先级由高到低为：拒绝例外条件 > 拒绝条件 > 允许例外条件 > 允许条件。

系统判断流程可参考下图所示，如果组件资源请求未匹配到 Ranger 中的权限策略，系统默认将拒绝访问。但是对于 HDFS 和 Yarn，系统会将决策下放给组件自身的访问控制层继续进行判断。

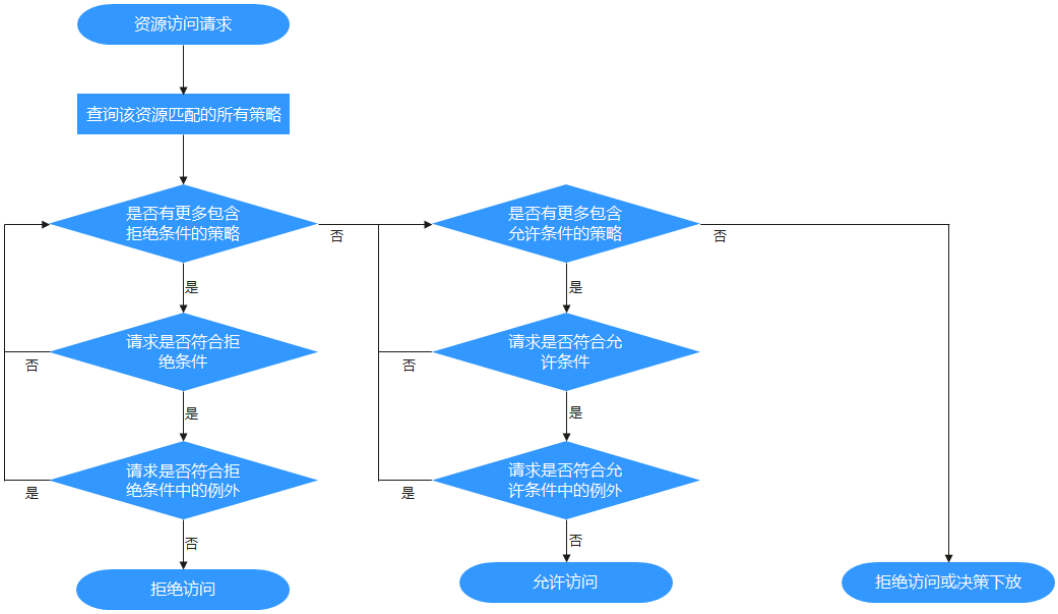

例如要将一个文件夹 FileA 的读写权限授权给用户组 groupA，但是该用户组内某个用户 UserA 除外，这时可以增加一个允许条件及一个例外条件即可实现。

20.4 查看 Ranger 审计信息

Ranger 管理员可通过 Ranger 界面查看 Ranger 运行审计日志及组件使用 Ranger 鉴权后权限管控审计日志信息。

查看 Ranger 审计信息内容

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 单击“Audit”，查看相关审计信息，各页签内容说明请参考表 20-2，条目较多时，单击搜索框可根据关键字字段进行筛选。

表20-2 Audit 信息

页签	内容描述
Access	当前 MRS 不支持在线查看组件资源的审计日志信息，可登录组件安装节点，进入“/var/log/Bigdata/audit”目录下查看各组件的审计日志。
Admin	Ranger 上操作审计信息，例如安全访问策略的创建/更新/删除、组件权限策略的创建/删除、role 的创建/更新/删除等。
Login Sessions	登录 Ranger 的用户会话审计信息。
Plugins	Ranger 内组件权限策略信息。
Plugin Status	各组件节点权限策略的同步审计信息。
User Sync	Ranger 与 LDAP 用户同步审计信息。

----结束

20.5 配置 Ranger 安全区

Ranger 支持配置安全区，Ranger 管理员可将各组件的资源切分为多个安全区，由对应 Ranger 管理员用户为区域的指定资源设置安全策略，以便更好的细分资源管理。安全区中定义的策略仅适用于区域中的资源，服务的资源被划分到安全区后，非安全区针对该资源的访问权限策略将不再生效。安全区的管理员只能在其作为管理员的安全区中设置策略。

添加安全区

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 单击“Security Zone”，在区域列表页面中单击  ，添加安全区。

表20-3 安全区配置参数

参数名称	描述	示例
Zone Name	配置安全区的名称。	test
Zone Description	配置安全区的描述信息。	-
Admin Users/Admin Usergroups	配置安全区的管理用户/用户组，可在安全区中添加及修改相关资源的权限策略。	zone_admin

参数名称	描述	示例
	必须至少配置一个用户或用户组。	
Auditor Users/ Auditor Usergroups	添加审计用户/用户组，可在安全区中查看相关资源权限策略内容。 必须至少配置一个用户或用户组。	zone_user
Select Tag Services	选择服务的标签信息。	-
Select Resource Services	选择安全区内包含的服务及具体资源。 在“Select Resource Services”中选择服务后，需要在“Resource”列中添加具体的资源对象，例如 HDFS 服务器的文件目录、Yarn 的队列、Hive 的数据库及表、HBase 的表及列。	/testzone

例如针对 HDFS 中的“/testzone”目录创建一个安全区，配置如下：

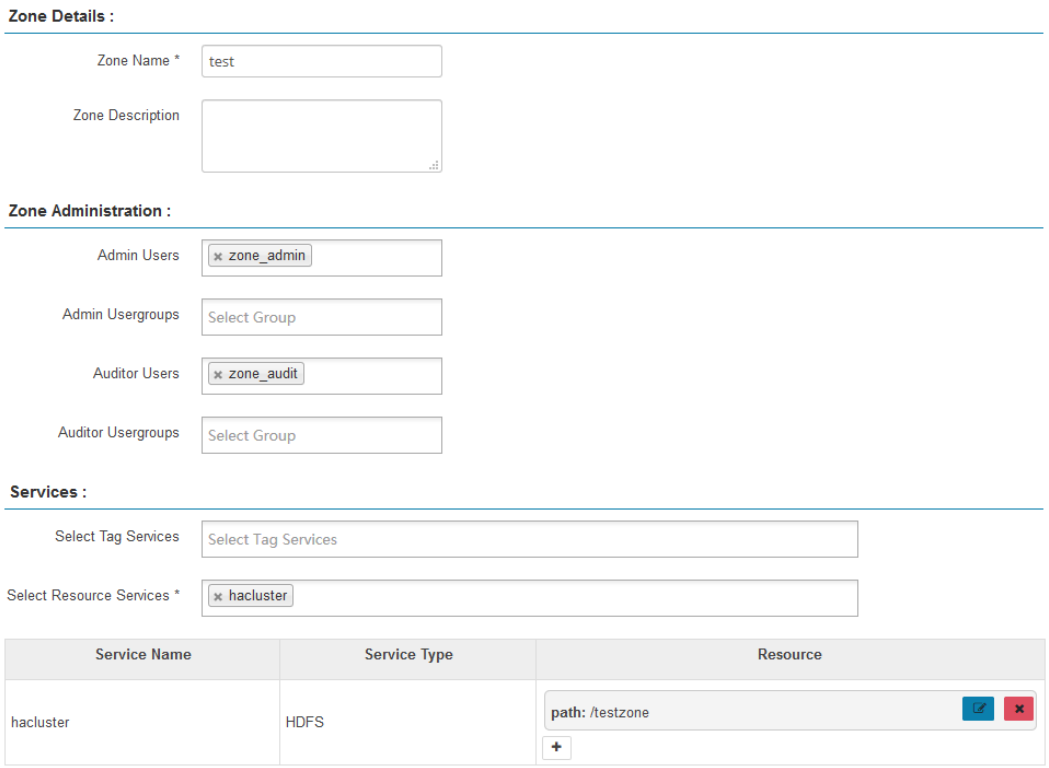

步骤 2 单击“Save”，等待安全区添加成功。

Ranger 管理员可在“Security Zone”页面查看当前的所有安全区并单击“Edit”修改安全区的属性信息，当相关资源不需要在安全区中进行管理时，可单击“Delete”删除对应安全区。

----结束

在安全区中配置权限策略

使用 Ranger 安全区管理员用户登录 Ranger 管理页面。

步骤 1 在 Ranger 首页右上角的“Security Zone”选项的下拉列表中选择对应的安全区，即可切换至该安全区内的权限视图。

步骤 2 单击组件名称下的权限插件名称，即可进入组件安全访问策略列表页面。

说明

各组件的策略列表中，系统默认生成的条目会自动继承至安全区内，用于保证集群内的部分系统默认用户或用户组的权限。

步骤 3 单击“Add New Policy”，根据业务场景规划配置相关用户或者用户组的资源访问策略。

例如在本章节样例中，在安全区内配置一条允许“test”用户访问“/testzone/test”目录的策略：

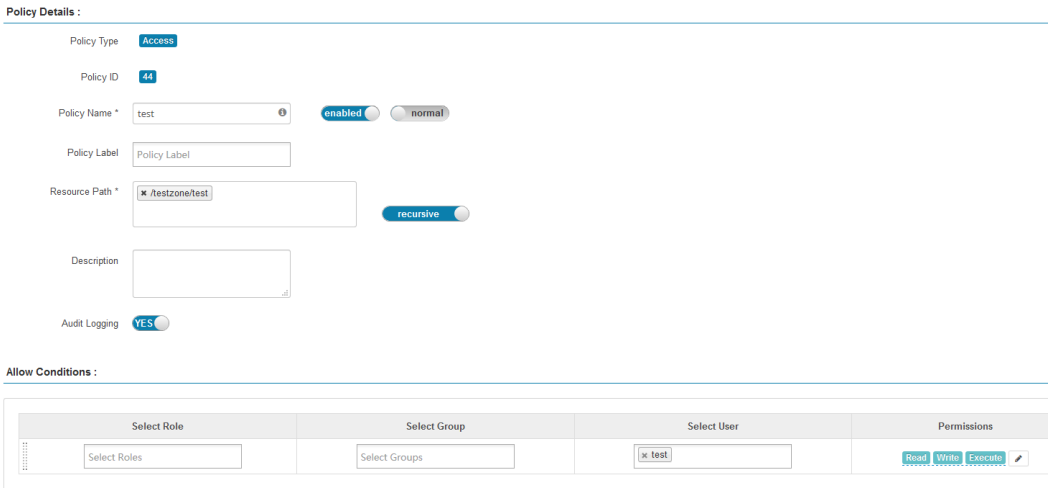

其他不同组件的完整访问策略配置样例参考：

- 20.7 添加 CDL 的 Ranger 访问权限策略
- 20.8 添加 HDFS 的 Ranger 访问权限策略
- 20.9 添加 HBase 的 Ranger 访问权限策略
- 20.10 添加 Hive 的 Ranger 访问权限策略
- 20.11 添加 Yarn 的 Ranger 访问权限策略

- 20.12 添加 Spark2x 的 Ranger 访问权限策略
- 20.13 添加 Kafka 的 Ranger 访问权限策略
- 20.14 添加 HetuEngine 的 Ranger 访问权限策略

策略添加后，需等待 30 秒左右，待系统生效。

说明

- 安全区中定义的策略仅适用于区域中的资源，服务的资源被划分到安全区后，非安全区针对该资源的访问权限策略将不再生效。
- 如需配置针对当前安全区之外其他资源的访问策略，需在 Ranger 首页右上角的“Security Zone”选项中退出当前安全区后进行配置。

----结束

20.6 查看 Ranger 权限信息

查看 Ranger 相关权限设置信息，例如查看用户、用户组、Role。

查看 Ranger 权限信息

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 选择“Settings > Users/Groups/Roles”，可查看系统中的用户、用户组、Roles 信息。

- Users：显示 Ranger 从 LDAP 或者 OS 同步的所有用户信息。
- Groups：显示 Ranger 从 LDAP 或者 OS 同步的所有用户组、角色信息。
- Roles：显示 Ranger 中创建的 Role 信息。

说明

- 在 FusionInsight Manager 上创建的用户、角色、用户组会定期自动同步至 Ranger，默认周期为 300000 毫秒（5 分钟）。FusionInsight Manager 中的角色和用户组在同步至 Ranger 后都变为用户组（Group）。只有被用户关联了的角色和用户组才会自动同步至 Ranger。
- Ranger 界面中创建的 Role 为用户或用户组的集合，用于灵活设置组件的权限访问策略，与 FusionInsight Manager 中的“角色”不同，请注意区分。

----结束

调整 Ranger 用户类型

登录 Ranger 管理页面。

调整 Ranger 用户类型须使用 Admin 类型的用户（例如 **admin**）进行操作，具体用户类型请参考 Ranger 用户类型。

步骤 1 选择“Settings > Users/Groups/Roles”，在“Users”用户列表中，单击待修改类型的用户名。

步骤 2 设置“Select Role”配置项为待修改的类型。

步骤 3 单击“Save”。

----结束

创建 Ranger Role

Ranger 管理员在设置组件的权限访问策略时，可基于用户、用户组或者 Role 灵活配置，其中用户与用户组信息从 LDAP 中自动同步，Role 可手动添加。

登录 Ranger 管理页面。

步骤 1 选择“Settings > Users/Groups/Roles > Roles > Add New Role”。

步骤 2 根据界面提示填写 Role 的名称与描述信息。

步骤 3 添加 Role 内需要包含的用户、用户组、子 Role 信息。

- 在“Users”区域，选择系统中已创建的用户，然后单击“Add Users”。
- 在“Groups”区域，选择系统中已创建的用户组，然后单击“Add Group”。
- 在“Roles”区域，选择系统中已创建的 Role，然后单击“Add Role”。

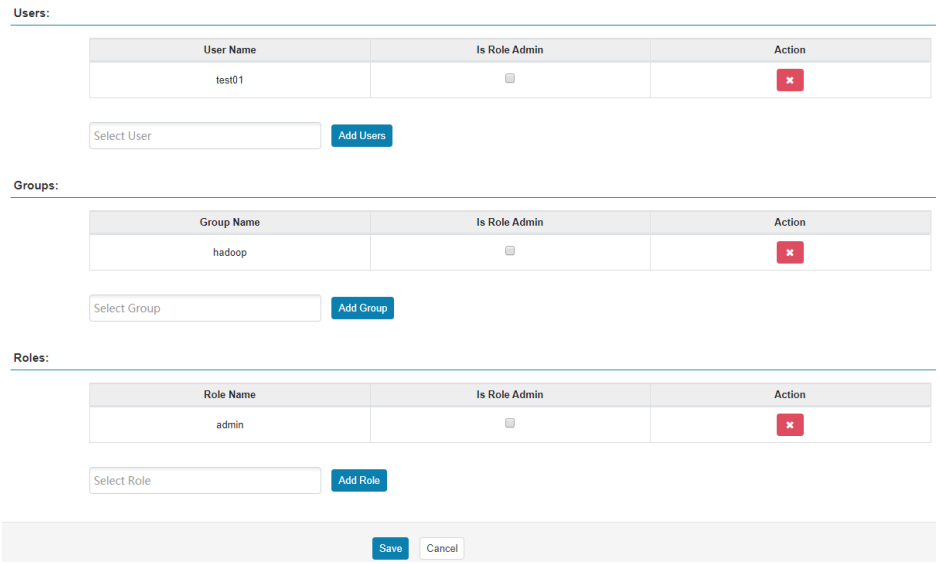

步骤 4 单击“Save”，Role 添加成功。

说明

新创建的 role，页面不提供删除操作，可以修改。

----结束

20.7 添加 CDL 的 Ranger 访问权限策略

操作场景

Ranger 管理员可通过 Ranger 为 CDL 用户配置创建、执行、查询、删除权限。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 已创建需要配置权限的用户、用户组或 Role。

操作步骤

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 在首页中单击“CDL”区域的组件插件名称，例如“CDL”。

步骤 2 单击“Add New Policy”，添加 CDL 权限控制策略。

步骤 3 根据业务需求配置相关参数。

表20-4 CDL 权限参数

参数名称	描述
Policy Type	Access。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
job	配置当前策略适用的 job 名，可以填写多个值。这里支持通配符，例如：test、test*、*。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Allow Conditions	策略允许条件，配置本策略内允许的权限及例外，例外条件优先级高于正常条件。 在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的 Role、用户组或用户。 单击“Add Conditions”，添加策略适用的 IP 地址范围，单击“Add Permissions”，添加对应权限。 • Create： 创建权限。 • Execute：执行权限。 • Delete： 删除权限。 • Update：更新权限。 • Get：获取信息权限。

参数名称	描述
	• Select/Deselect All：全选/取消全选。 如需添加多条权限控制规则，可单击  按钮添加。 如需当前条件中的用户或用户组管理本条策略，可勾选“Delegate Admin”，这些用户将成为受委托的管理员。被委托的管理员可以更新、删除本策略，它还可以基于原始策略创建子策略。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”类型，拒绝条件的优先级高于“Allow Conditions”中配置的允许条件。

表20-5 设置权限

任务场景	角色授权操作
设置 CDL 管理员权限	1. 在首页中单击“CDL”区域的组件插件名称，例如“CDL”。 2. 分别选择“Policy Name”为“all - job”、“all - link”、“all - driver”、“all - env”的策略，单击  按钮编辑策略。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Select/Deselect All”。
设置用户对 CDL 作业的所有管理权限	1. 在“job”选择 CDL 作业名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Select/Deselect All”。
设置用户对 CDL 作业的创建权限	1. 在“job”选择 CDL 作业名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Create”。 **说明** 默认场景下，所有用户均具有“Create”权限。
设置用户对 CDL 作业的删除权限	1. 在“job”选择 CDL 作业名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Delete”。
设置用户对 CDL 作业的信息获取权限	1. 在“job”选择 CDL 作业名。 2. 在“Allow Conditions”区域，单击“Select User”

任务场景	角色授权操作
	下选择框选择用户。 3. 单击“Add Permissions”，勾选“Get”。
设置用户对 CDL 作业的执行权限	1. 在“job”选择 CDL 作业名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Execute”。
设置用户对 CDL 数据连接的所有管理权限	1. 在“link”右侧选择 CDL 数据连接名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Select/Deselect All”。
设置用户对 CDL 数据连接的创建权限	1. 在“link”右侧选择 CDL 数据连接名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Create”。 **说明** 默认场景下，所有用户均具有“Create”权限。
设置用户对 CDL 数据连接的删除权限	1. 在“link”右侧选择 CDL 数据连接名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Delete”。
设置用户对 CDL 数据连接的更新权限	1. 在“link”右侧选择 CDL 数据连接名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Update”。
设置用户对 CDL 数据连接的信息获取权限	1. 在“link”右侧选择 CDL 数据连接名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Get”。
设置用户对 CDL 驱动的所有管理权限	1. 在“driver”右侧选择 CDL 驱动名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Select/Deselect All”。
设置用户对 CDL 驱动的删除权限	1. 在“driver”右侧选择 CDL 驱动名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Delete”。
设置用户对 CDL 驱动的更新权限	1. 在“driver”右侧选择 CDL 驱动名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。

任务场景	角色授权操作
	3. 单击“Add Permissions”，勾选“Update”。
设置用户对 CDL 驱动的信息获取权限	1. 在“driver”右侧选择 CDL 驱动名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Get”。
设置用户对 CDL 环境变量的所有管理权限	1. 在“env”右侧选择 CDL 环境变量名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Select/Deselect All”。
设置用户对 CDL 环境变量的创建权限	1. 在“env”右侧选择 CDL 环境变量名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Create”。 **说明** 默认场景下，所有用户均具有“Create”权限。
设置用户对 CDL 环境变量的删除权限	1. 在“env”右侧选择 CDL 环境变量名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Delete”。
设置用户对 CDL 环境变量的更新权限	1. 在“env”右侧选择 CDL 环境变量名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Update”。
设置用户对 CDL 环境变量的信息获取权限	1. 在“env”右侧选择 CDL 环境变量名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Get”。

步骤 4 （可选）添加策略有效期。在页面右上角单击“Add Validity period”，设置“Start Time”和“End Time”，选择“Time Zone”。单击“Save”保存。如需添加多条策略有效期，可单击  按钮添加。如需删除策略有效期，可单击  按钮删除。

步骤 5 单击“Add”，在策略列表可查看策略的基本信息。等待策略生效后，验证相关权限是否正常。

如需禁用某条策略，可单击  按钮编辑策略，设置策略开关为“Disabled”。

如果不再使用策略，可单击  按钮删除策略。

----结束

20.8 添加 HDFS 的 Ranger 访问权限策略

操作场景

Ranger 管理员可通过 Ranger 为 HDFS 用户配置 HDFS 目录或文件的读、写和执行权限。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 已创建需要配置权限的用户、用户组或 Role。

操作步骤

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 在首页中单击“HDFS”区域的组件插件名称，例如“hacluster”。

步骤 2 单击“Add New Policy”，添加 HDFS 权限控制策略。

步骤 3 根据业务需求配置相关参数。

表20-6 HDFS 权限参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，可以根据这些标签搜索报告和筛选策略。
Resource Path	资源路径，配置当前策略适用的 HDFS 路径文件夹或文件，可填写多个值，支持使用通配符“*”（例如“/test/*”）。 如需子目录继承上级目录权限，可打开递归开关按钮。 如果父目录开启递归，同时子目录也配置了策略，以子目录策略为准。 • non-recursive：关闭递归 • recursive：打开递归
Description	策略描述信息。
Audit Logging	是否审计此策略。
Allow Conditions	策略允许条件，配置本策略内允许的权限及例外，例外条件优先级高于正常条件。 在“Select Role”、“Select Group”、“Select User”列选择已创

参数名称	描述
	建好的需要授予权限的 Role、用户组或用户，单击“Add Conditions”，添加策略适用的 IP 地址范围，单击“Add Permissions”，添加对应权限。 • Read：读权限 • Write：写权限 • Execute：执行权限 • Select/Deselect All：全选/取消全选 如需让当前条件中的用户或用户组管理本条策略，可勾选“Delegate Admin”使这些用户或用户组成为受委托的管理员。被委托的管理员可以更新、删除本策略，还可以基于原始策略创建子策略。 如需添加多条权限控制规则，可单击  按钮添加。如需删除权限控制规则，可单击  按钮删除。 Exclude from Allow Conditions：配置排除在允许条件之外的例外规则。
Deny All Other Accesses	是否拒绝其它所有访问。 • True：拒绝其它所有访问。 • False：设置为 false，可配置 Deny Conditions。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”类似，拒绝条件的优先级高于“Allow Conditions”中配置的允许条件。 Exclude from Deny Conditions：配置排除在拒绝条件之外的例外规则。

例如为用户“testuser”添加“/user/test”目录的写权限，配置如下：

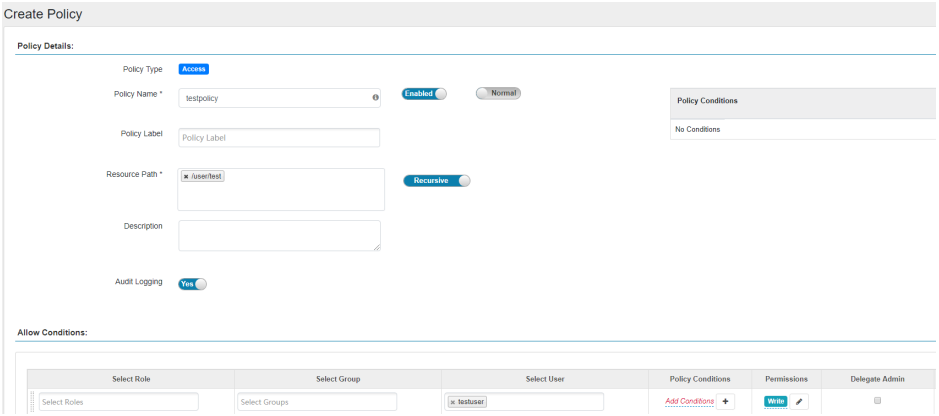

表20-7 设置权限

任务场景	角色授权操作
设置 HDFS 管理员权限	1. 在首页中单击“HDFS”区域的组件插件名称，例如“hacluster”。 2. 选择“Policy Name”为“all - path”的策略，单击  按钮编辑策略。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。
设置用户执行 HDFS 检查和 HDFS 修复的权限	1. 在“Resource Path”配置文件夹或文件。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Read”和“Execute”。
设置用户读取其他用户的目录或文件的权限	1. 在“Resource Path”配置文件夹或文件。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Read”和“Execute”。
设置用户在其他用户的文件写入数据的权限	1. 在“Resource Path”配置文件夹或文件。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Write”和“Execute”。
设置用户在其他用户的目录新建或删除子文件、子目录的权限	1. 在“Resource Path”配置文件夹或文件。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Write”和“Execute”。
设置用户在其他用户的目录或文件执行的权限	1. 在“Resource Path”配置文件夹或文件。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Execute”。
设置子目录继承上级目录权限	1. 在“Resource Path”配置文件夹或文件。 2. 打开递归开关按钮，“Recursive”即为打开递归。

步骤 4 （可选）添加策略有效期。在页面右上角单击“Add Validity period”，设置“Start Time”和“End Time”，选择“Time Zone”。单击“Save”保存。如需添加多条策略有效期，可单击  按钮添加。如需删除策略有效期，可单击  按钮删除。

步骤 5 单击“Add”，在策略列表可查看策略的基本信息。等待策略生效后，验证相关权限是否正常。

如需禁用某条策略，可单击  按钮编辑策略，设置策略开关为“Disabled”。

如果不再使用策略，可单击  按钮删除策略。

----结束

20.9 添加 HBase 的 Ranger 访问权限策略

操作场景

Ranger 管理员可通过 Ranger 为 HBase 用户配置 HBase 表和列族，列的权限。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 已创建需要配置权限的用户、用户组或 Role。

操作步骤

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 在首页中单击“HBASE”区域的组件插件名称如“HBase”。

步骤 2 单击“Add New Policy”，添加 HBase 权限控制策略。

步骤 3 根据业务需求配置相关参数。

表20-8 HBase 权限参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，可以根据这些标签搜索报告和筛选策略。
HBase Table	将适用该策略的表。 可支持通配符“*”，例如“table1:*“表示 table1 下的所有表。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。 **说明** Ranger 界面上 HBase 服务插件的“hbase.rpc.protection”参数值必须和 HBase 服务端的“hbase.rpc.protection”参数值保持一致。具体请参考 20.21.4 Ranger 界面添加或者修改 HBase 策略时，无法使用通配符搜索已存在的 HBase 表。

参数名称	描述
HBase Column-family	将适用该策略的列族。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。
HBase Column	将适用该策略的列。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Allow Conditions	策略允许条件，配置本策略内允许的权限及例外。 在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的 Role、用户组或用户，单击“Add Conditions”，添加策略适用的 IP 地址范围，单击“Add Permissions”，添加对应权限。 • Read：读权限 • Write：写权限 • Create：创建权限 • Admin：管理权限 • Select/Deselect All：全选/取消全选 如需让当前条件中的用户或用户组管理本条策略，可勾选“Delegate Admin”使这些用户或用户组成为受委托的管理员。被委托的管理员可以更新、删除本策略，还可以基于原始策略创建子策略。 如需添加多条权限控制规则，可单击  按钮添加。如需删除权限控制规则，可单击  按钮删除。 Exclude from Allow Conditions：配置策略例外条件。
Deny All Other Accesses	是否拒绝其它所有访问。 • True：拒绝其它所有访问 • False：设置为 False，可配置 Deny Conditions。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”类似。 拒绝条件的优先级高于“Allow Conditions”中配置的允许条件。 Exclude from Deny Conditions：配置排除在拒绝条件之外的例外规则。

表20-9 设置权限

任务场景	角色授权操作
设置 HBase 管理员权限	1. 在首页中单击“HBase”区域的组件插件名称，例如“HBase”。 2. 选择“Policy Name”为“all - table, column-family, column”的策略，单击  按钮编辑策略。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。
设置用户创建表的权限	1. 在“HBase Table”配置表名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Create”。 4. 该用户具有以下操作权限： create table drop table truncate table alter table enable table flush table flush region compact disable enable desc
设置用户写入数据的权限	1. 在“HBase Table”配置表名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Write”。 4. 该用户具有 put，delete，append，incr 等操作权限。
设置用户读取数据的权限	1. 在“HBase Table”配置表名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Read”。 4. 该用户具有 get，scan 操作权限。
设置用户管理命名空间或表的权限	1. 在“HBase Table”配置表名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Admin”。 4. 该用户具有 rsgroup，peer，assign，balance 等操作权限。
设置列的读取或写入权	1. 在“HBase Table”配置表名。

任务场景	角色授权操作
限	2. 在“HBase Column-family”配置列族名。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Read”或者“Write”。

说明

如果用户在 hbase shell 中执行 desc 操作，需要同时给该用户赋予 hbase:quota 表的读权限。

步骤 4 （可选）添加策略有效期。在页面右上角单击“Add Validity period”，设置“Start Time”和“End Time”，选择“Time Zone”。单击“Save”保存。如需添加多条策略有效期，可单击  按钮添加。如需删除策略有效期，可单击  按钮删除。

步骤 5 单击“Add”，在策略列表可查看策略的基本信息。等待策略生效后，验证相关权限是否正常。

如需禁用某条策略，可单击  按钮编辑策略，设置策略开关为“Disabled”。

如果不再使用策略，可单击  按钮删除策略。

----结束

20.10 添加 Hive 的 Ranger 访问权限策略

操作场景

Ranger 管理员可通过 Ranger 为 Hive 用户进行相关的权限设置。Hive 默认管理员账号为 hive，初始密码为 Hive@123。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 已创建用户需要配置权限的用户、用户组或 Role。
- 用户加入 hive 组。

操作步骤

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 在首页中单击“HADOOP SQL”区域的组件插件名称如“Hive”。

步骤 2 在“Access”页签单击“Add New Policy”，添加 Hive 权限控制策略。

步骤 3 根据业务需求配置相关参数。

表20-10 Hive 权限参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
database	将适用该策略的列 Hive 数据库名称。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。
table	将适用该策略的 Hive 表名称。 如果需要添加基于 UDF 的策略，可切换为 UDF，然后输入 UDF 的名称。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。
Hive Column	将适用该策略的列名，填写*时表示所有列。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Allow Conditions	策略允许条件，配置本策略内允许的权限及例外。 在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的 Role、用户组或用户，单击“Add Conditions”，添加策略适用的 IP 地址范围，然后在单击“Add Permissions”，添加对应权限。 • select：查询权限 • update：更新权限 • Create：创建权限 • Drop：drop 操作权限 • Alter：alter 操作权限 • Index：索引操作权限 • All：所有执行权限 • Read：可读权限 • Write：可写权限

参数名称	描述
	• Temporary UDF Admin：临时 UDF 管理权限 • Select/Deselect All：全选/取消全选 如需添加多条权限控制规则，可单击  按钮添加。 如需当前条件中的用户或用户组管理本条策略，可勾选“Delegate Admin”，这些用户将成为受委托的管理员。被委托的管理员可以更新、删除本策略，它还可以基于原始策略创建子策略。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”类型。

表20-11 设置权限

任务场景	角色授权操作
role admin 操作	1. 在首页中单击“Settings”，选择“Roles”。 2. 单击 Role Name 为 admin 的角色，在“Users”区域，单击“Select User”，选择对应用户名。 3. 单击 Add Users 按钮，在对应用户名所在行勾选“Is Role Admin”，单击“Save”保存配置。 **说明** Ranger 页面的“Settings”选项只有 rangeradmin 用户有权限访问。用户绑定 Hive 管理员角色后，在每个维护操作会话中，还需要执行以下操作： 1. 以客户端安装用户，登录安装 Hive 客户端的节点。 2. 执行以下命令配置环境变量。 例如，Hive 客户端安装目录为“/opt/hiveclient”，执行 **source /opt/hiveclient/bigdata_env** 3. 执行以下命令认证用户。 **kinit** *Hive 业务用户* 4. 执行以下命令登录客户端工具。 **beeline** 5. 执行以下命令更新用户的管理员权限。 **set role admin;**
创建库表操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写或选择对应的数据库(如果是创建表则在“table”右侧填写或选择对应的表)，在“column”右侧填写或选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Create”。

任务场景	角色授权操作
删除库表操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写或选择对应的数据库（如果是删除表则在“table”右侧填写或选择对应的表），在“column”右侧填写并选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Drop”。
查询操作(select、desc、show)	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写或选择对应的数据库(如果是表则在“table”右侧填写或选择对应的表)，在“column”右侧填写并选择对应的列（*代表所有列）。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“select”。
Alter 操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写并选择对应的数据库(如果是表则在“table”右侧填写或选择对应的表)，在“column”右侧填写或选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Alter”。
LOAD 操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写或选择对应的数据库，在“table”右侧填写或选择对应的表，在“column”右侧填写并选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“update”。
INSERT、DELETE 操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写或选择对应的数据库，在“table”右侧填写或选择对应的表，在“column”右侧填写并选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“update”。 5. 用户还需要具有 Yarn 任务队列的“submit”权限，权限配置参考 20.11 添加 Yarn 的 Ranger 访问权限策略。
GRANT、REVOKE 操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写或选择对应的数据库，在“table”右侧填写或选择对应的表，在“column”右侧填写并选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选

任务场景	角色授权操作
	择框选择用户。 4. 勾选“Delegate Admin”。
ADD JAR 操作	1. 在“Policy Name”填写策略名称。 2. 单击“database”并在下拉菜单中选择“global”。在“global”右侧填写或选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Temporary UDF Admin”。
UDF 操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写或选择对应的数据库，“udf”右侧填写对应的 udf 函数名。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，根据需求，给用户勾选相应权限（udf 支持 Create，select， Drop）。
VIEW 操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写或选择对应的数据库，在“table”右侧填写或选择对应的 VIEW 名称，在“column”右侧填写并选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，参照表格上述相关操作，根据需求，给用户勾选相应权限。
dfs 命令操作	执行 set role admin 操作才可使用。
其他用户库表操作	1. 参照表格上述相关操作添加对应权限。 2. 给用户添加其他用户库表的 HDFS 路径的读、写、执行权限，详情请参考 20.8 添加 HDFS 的 Ranger 访问权限策略。

说明

- 如果用户在执行命令时指定了 HDFS 路径，需要给该用户添加 HDFS 路径的读、写、执行权限，详情请参考 20.8 添加 HDFS 的 Ranger 访问权限策略。也可以不配置 HDFS 的 Ranger 策略，通过之前 Hive 权限插件的方式，给角色添加权限，然后把角色赋予对应用户。如果 HDFS Ranger 策略可以匹配到 Hive 库表的文件或目录权限，则优先使用 HDFS Ranger 策略。
- MRS 3.3.0 及之后版本，若已参考 20.16 Hive 表支持级联授权功能章节开启了 Hive 表的级联授权功能，则无需对表所在的 HDFS 路径进行授权操作。
- Ranger 策略中的 URL 策略是 Hive 表存储在 OBS 上的场景涉及，URL 填写对象在 OBS 上的完整路径。与 URL 联合使用的 Read，Write 权限，其他场景不涉及 URL 策略。
- Ranger 策略中 global 策略仅用于和 Temprorary UDF Admin 权限联合使用，控制 UDF 包的上传。

- Ranger 策略中的 hiveservice 策略仅用于和 Service Admin 权限联合使用，用于控制命令：**kill query <queryId>** 结束正在执行的任务的权限。
- lock、index、refresh、replAdmin 权限暂不支持。
- 使用 **show grant** 命令查看表权限，表 owner 的 grantor 列统一显示为 hive 用户，其他用户 Ranger 页面赋权或后台采用 grant 命令赋权，则 grantor 显示为对应用户；若用户需要查看之前 Hive 权限插件的结果，可设置 hive-ext.ranger.previous.privileges.enable 为 true 后采用 **show grant** 查看。

步骤 4 单击“Add”，在策略列表可查看策略的基本信息。等待策略生效后，验证相关权限是否正常。

如需禁用某条策略，可单击  按钮编辑策略，设置策略开关为“Disabled”。

如果不再使用策略，可单击  按钮删除策略。

----结束

Hive 数据脱敏

Ranger 支持对 Hive 数据进行脱敏处理（Data Masking），可对用户执行的 select 操作的返回结果进行处理，以屏蔽敏感信息。

登录 Ranger WebUI 界面，在首页中单击“HADOOP SQL”区域的“Hive”

步骤 1 在“Masking”页签单击“Add New Policy”，添加 Hive 权限控制策略。

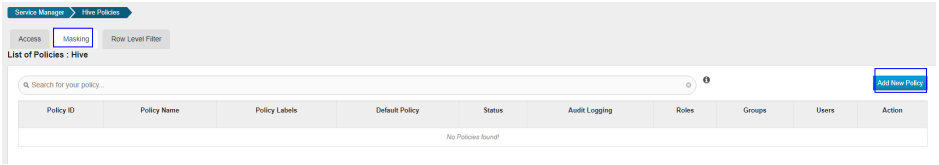

步骤 2 根据业务需求配置相关参数。

表20-12 Hive 数据脱敏参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
Hive Database	• MRS 3.3.0 之前版本，配置当前策略适用的 Hive 中数据库名称。 • MRS 3.3.0 及之后版本，配置当前策略适用的 Hive 中数据库

参数名称	描述
	名称，支持设置多个数据库名，并且填写支持“*”通配符，例如：aa、a*、*b、a*b 或者*。
Hive Table	• MRS 3.3.0 之前版本，配置当前策略适用的 Hive 中的表名称。 • MRS 3.3.0 及之后版本，配置当前策略适用的 Hive 中的表名称，支持设置多个表名，并且填写支持“*”通配符，例如：aa、a*、*b、a*b 或者*。
Hive Column	• MRS 3.3.0 之前版本，可添加列名。 • MRS 3.3.0 及之后版本，
Description	策略描述信息。
Audit Logging	是否审计此策略。
Mask Conditions	在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的对象，单击“Add Conditions”，添加策略适用的 IP 地址范围，然后在单击“Add Permissions”，勾选“select”权限。 单击“Select Masking Option”，选择数据脱敏时的处理策略： • Redact：用 x 屏蔽所有字母字符，用 0 屏蔽所有数字字符。 • Partial mask: show last 4：只显示最后的 4 个字符，其他用 x 代替。 • Partial mask: show first 4：只显示开始的 4 个字符，其他用 x 代替。 • Hash：用值的哈希值替换原值，采用的是 hive 的内置 mask_hash 函数，只对 string、char、varchar 类型的字段生效，其他类型的字段会返回 NULL 值。 • Nullify：用 NULL 值替换原值。 • Unmasked(retain original value)：原样显示。 • Date: show only year：仅显示日期字符串的年份部分，并将月份和日期默认为 01/01。 • Custom：可使用任何有效返回与被屏蔽的列中的数据类型相同的数据类型来自定义策略。 如需添加多列的脱敏策略，可单击  按钮添加。

步骤 3 单击“Add”，在策略列表可查看策略的基本信息。

步骤 4 用户通过 Hive 客户端对配置了数据脱敏策略的表执行 select 操作，系统将对数据进行处理后进行展示。

说明

处理数据需要用户同时具有向 Yarn 队列提交任务的权限。

----结束

Hive 行级别数据过滤

Ranger 支持用户对 Hive 数据表执行 select 操作时进行行级别的数据过滤。

登录 Ranger WebUI 界面，在首页中单击“HADOOP SQL”区域的“Hive”。

步骤 1 在“Row Level Filter”页签单击“Add New Policy”，添加行数据过滤策略。

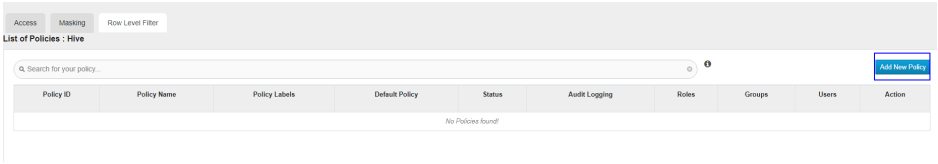

步骤 2 根据业务需求配置相关参数。

表20-13 Hive 行数据过滤参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
Hive Database	配置当前策略适用的 Hive 中数据库名称。
Hive Table	配置当前策略适用的 Hive 中的表名称。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Row Filter Conditions	在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的对象，单击“Add Conditions”，添加策略适用的 IP 地址范围，然后在单击“Add Permissions”，勾选“select”权限。 单击“Row Level Filter”，填写数据过滤规则。 例如过滤表 A 中“name”列“zhangsan”行的数据，过滤规则为：name <> 'zhangsan'。更多信息可参考 Ranger 官方文档。 如需添加更多规则，可单击 + 按钮添加。

步骤 3 单击“Add”，在策略列表可查看策略的基本信息。

步骤 4 用户通过 Hive 客户端对配置了数据脱敏策略的表执行 select 操作，系统将对数据进行处理后进行展示。

说明

处理数据需要用户同时具有向 Yarn 队列提交任务的权限。

----结束

20.11 添加 Yarn 的 Ranger 访问权限策略

操作场景

Ranger 管理员可通过 Ranger 为 Yarn 用户配置 Yarn 管理员权限以及 Yarn 队列资源管理权限。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 已创建需要配置权限的用户、用户组或 Role。

操作步骤

登录 FusionInsight Manager 界面，选择“集群 > 服务 > Yarn”。

步骤 1 选择“配置 > 全部配置”，搜索参数“yarn.acl.enable”，修改参数值为“true”。如果该参数值已经为“true”，则无需处理。

步骤 2 使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 3 在首页中单击“YARN”区域的组件插件名称如“Yarn”。

步骤 4 单击“Add New Policy”，添加 Yarn 权限控制策略。

步骤 5 根据业务需求配置相关参数。

表20-14 Yarn 权限参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，可以根据这些标签搜索报告和筛选策略。

参数名称	描述
Queue	队列名称，支持通配符“*”。 如需子队列继承上级队列权限，可打开递归开关按钮。 • Non-recursive：关闭递归 • Recursive：打开递归
Description	策略描述信息。
Audit Logging	是否审计此策略。
Allow Conditions	策略允许条件，配置本策略内允许的权限及例外。 在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的 Role、用户组或用户，单击“Add Conditions”，添加策略适用的 IP 地址范围，单击“Add Permissions”，添加对应权限。 • submit-app：提交队列任务权限 • admin-queue：管理队列任务权限 • Select/Deselect All：全选/取消全选 如需让当前条件中的用户或用户组管理本条策略，可勾选“Delegate Admin”使这些用户成为受委托的管理员。被委托的管理员可以更新、删除本策略，它还可以基于原始策略创建子策略。 如需添加多条权限控制规则，可单击  按钮添加。如需删除权限控制规则，可单击  按钮删除。 Exclude from Allow Conditions：配置策略例外条件。
Deny All Other Accesses	是否拒绝其它所有访问。 • True：拒绝其它所有访问 • False：设置为 False，可配置 Deny Conditions。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”类似。拒绝条件的优先级高于“Allow Conditions”中配置的允许条件。 Exclude from Deny Conditions：配置排除在拒绝条件之外的例外规则。

表20-15 设置权限

任务场景	角色授权操作
设置 Yarn 管理员权限	1. 在首页中单击“YARN”区域的组件插件名称，例如“Yarn”。 2. 选择“Policy Name”为“all - queue”的策略，单击  按钮编辑策略。

任务场景	角色授权操作
	3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。
设置用户在指定Yarn 队列提交任务的权限	1. 在“Queue”配置队列名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“submit-app”。
设置用户在指定Yarn 队列管理任务的权限	1. 在“Queue”配置队列名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“admin-queue”。

步骤 6 （可选）添加策略有效期。在页面右上角单击“Add Validity period”，设置“Start Time”和“End Time”，选择“Time Zone”。单击“Save”保存。如需添加多条策略有效期，可单击  按钮添加。如需删除策略有效期，可单击  按钮删除。

步骤 7 单击“Add”，在策略列表可查看策略的基本信息。等待策略生效后，验证相关权限是否正常。

如需禁用某条策略，可单击  按钮编辑策略，设置策略开关为“Disabled”。

如果不再使用策略，可单击  按钮删除策略。

----结束

说明

Ranger Yarn 上面各个权限之间相互独立，没有语义上的包含与被包含关系。当前支持下面两种权限：

- submit-app：提交队列任务权限
- admin-queue：管理队列任务权限

虽然 admin-queue 也有提交任务的权限，但和 submit-app 权限之间并没有包含关系。

20.12 添加 Spark2x 的 Ranger 访问权限策略

操作场景

Ranger 管理员可通过 Ranger 为 Spark2x 用户进行相关的权限设置。

说明

- Spark2x 开启或关闭 Ranger 鉴权后，需要重启 Spark2x 服务。
- 需要重新下载客户端，或手动刷新客户端配置文件“客户端安装目录/Spark2x/spark/conf/spark-defaults.conf”：

开启 Ranger 鉴权：spark.ranger.plugin.authorization.enable=true

关闭 Ranger 鉴权：spark.ranger.plugin.authorization.enable=false

- Spark2x 中，spark-beeline（即连接到 JDBCServer 的应用）支持 Ranger 的 IP 过滤策略（即 Ranger 权限策略中的 **Policy Conditions**），spark-submit 与 spark-sql 不支持。
- MRS 3.3.0-LTS 及之后的版本中，Spark2x 服务改名为 Spark，服务包含的角色名也有差异，例如 JobHistory2x 变更为 JobHistory。相关涉及服务名称、角色名称的描述和操作请以实际版本为准。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 已启用 Hive 服务的 Ranger 鉴权功能，并且重启 Hive 服务后，重启了 Spark2x 服务。
- 已创建用户需要配置权限的用户、用户组或 Role。
- 创建的用户已加入 hive 用户组。

操作步骤

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 在首页中单击“HADOOP SQL”区域的组件插件名称如“Hive”。

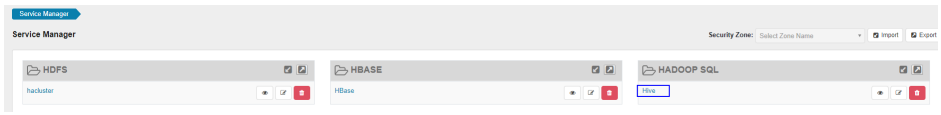

步骤 2 在“Access”页签单击“Add New Policy”，添加 Spark2x 权限控制策略。

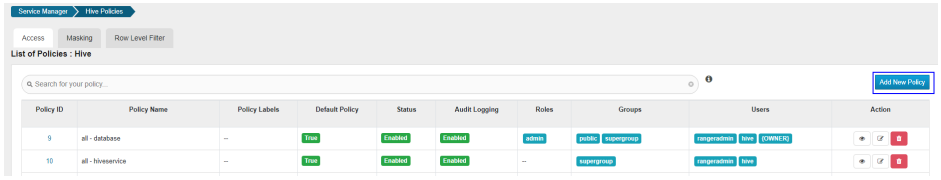

步骤 3 根据业务需求配置相关参数。

表20-16 Spark2x 权限参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
database	适用该策略的 Spark2x 数据库名称。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用

参数名称	描述
	于除去当前输入内容之外的其他对象。
table	适用该策略的 Spark2x 表名称。 如果需要添加基于 UDF 的策略，可切换为 UDF，然后输入 UDF 的名称。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。
column	适用该策略的列名，填写*时表示所有列。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Allow Conditions	策略允许条件，配置本策略内允许的权限及例外。 在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的 Role、用户组或用户，单击“Add Conditions”，添加策略适用的 IP 地址范围，然后在单击“Add Permissions”，添加对应权限。 • select：查询权限 • update：更新权限 • Create：创建权限 • Drop：drop 操作权限 • Alter：alter 操作权限 • Index：索引操作权限 • All：所有执行权限 • Read：可读权限 • Write：可写权限 • Temporary UDF Admin：临时 UDF 管理权限 • Select/Deselect All：全选/取消全选 如需添加多条权限控制规则，可单击 + 按钮添加。 如需当前条件中的用户或用户组管理本条策略，可勾选“Delegate Admin”，这些用户将成为受委托的管理员。被委托的管理员可以更新、删除本策略，它还可以基于原始策略创建子策略。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”类型。

表20-17 设置权限

任务场景	角色授权操作
role admin 操作	1. 在首页中单击“Settings”，选择“Roles > Add New Role”。 2. 设置“Role Name”为“admin”，在“Users”区域，单击“Select User”，选择对应用户名。 3. 单击 Add Users 按钮，在对应用户名所在行勾选“Is Role Admin”，单击“Save”保存配置。 **说明** 用户绑定 Hive 管理员角色后，在每个维护操作会话中，还需要执行以下操作： 1. 以客户端安装用户，登录安装 Hive 客户端的节点。 2. 执行以下命令配置环境变量。 例如，Spark2x 客户端安装目录为“/opt/client”，执行 **source /opt/client/bigdata_env** 3. 执行以下命令认证用户。 **kinit Spark2x** *业务用户* 4. 执行以下命令登录客户端工具。 **spark-beeline** 5. 执行以下命令更新用户的管理员权限。 **set role admin;**
创建库表操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写并选择对应的数据库（如果是创建库，需填写将要创建的库名称，或填写“*”表示任意名称的数据库，然后选择所写名称），在“table”与“column”右侧填写并选择对应的表名称、列名称，均支持通配符（“*”）匹配。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Create”。
删除库表操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写并选择对应的数据库（如果是删除库，需填写将要创建的库名称，或填写“*”表示任意名称的数据库，然后选择所写名称），在“table”与“column”右侧填写并选择对应的表名称、列名称，均支持通配符（“*”）匹配。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Drop”。 **说明** 对于 CarbonData 表，只有对应表的 OWNER，才能执行“drop”操作。
ALTER 操作	1. 在“Policy Name”填写策略名称。

任务场景	角色授权操作
	2. “database”右侧填写并选择对应的数据库，在“table”右侧填写并选择对应的表，在“column”右侧填写并选择对应的列名称，支持通配符（“*”）匹配。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Alter”。
LOAD 操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写并选择对应的数据库，在“table”右侧填写并选择对应的表，在“column”右侧填写并选择对应的列名称，支持通配符（“*”）匹配。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“update”。
INSERT 操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写并选择对应的数据库，在“table”右侧填写并选择对应的表，在“column”右侧填写并选择对应的列名称，支持通配符（“*”）匹配。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“update”。 5. 用户还需要具有 Yarn 任务队列的“submit-app”权限，默认情况下，hadoop 用户组具有向所有 Yarn 任务队列“submit-app”权限。具体配置请参考 20.11 添加 Yarn 的 Ranger 访问权限策略。
GRANT 操作	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写并选择对应的数据库，在“table”右侧填写并选择对应的表，在“column”右侧填写并选择对应的列名称，支持通配符（“*”）匹配。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 勾选“Delegate Admin”。
ADD JAR 操作	1. 在“Policy Name”填写策略名称。 2. 单击“database”并在下拉菜单中选择“global”。在“global”右侧填写并选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Temporary UDF Admin”。
VIEW 与 INDEX 权限	1. 在“Policy Name”填写策略名称。 2. “database”右侧填写并选择对应的数据库，在“table”右侧填写并选择对应的 VIEW 或 INDEX 名称，在“column”右侧填写并选择“*”。 3. 在“Allow Conditions”区域，单击“Select User”下选

任务场景	角色授权操作
	择框选择用户。 4. 单击“Add Permissions”，参照表格上述相关操作，根据需求，给用户勾选相应权限。
其他用户库表操作	1. 参照表格上述操作添加对应权限。 2. 给当前用户添加其他用户库表的 HDFS 路径的读、写、执行权限，具体配置请参考 20.8 添加 HDFS 的 Ranger 访问权限策略。

说明

在 Ranger 上为用户添加 Spark SQL 的访问策略后，需要在 HDFS 的访问策略中添加相应的路径访问策略，否则无法访问数据文件，具体请参考 20.8 添加 HDFS 的 Ranger 访问权限策略。

- Ranger 策略中 global 策略仅用于联合 Temprorary UDF Admin 权限，用来控制 UDF 包的上传。
- 通过 Ranger 对 Spark SQL 进行权限控制时，不支持 empower 语法。

步骤 4 单击“Add”，在策略列表可查看策略的基本信息。等待策略生效后，验证相关权限是否正常。

如果需要禁用某条策略，可单击  按钮编辑该策略，设置策略开关为“Disabled”。

如果不再使用某条策略，可单击  按钮删除该策略。

----结束

Spark2x 表数据脱敏

Ranger 支持对 Spark2x 数据进行脱敏处理（Data Masking），可对用户执行的 select 操作的返回结果进行处理，以屏蔽敏感信息。

修改服务端和客户端 spark.ranger.plugin.masking.enable 参数值为 ture。

- 服务端：登录 FusionInsight Manage 页面，选择“集群 > 服务 > Spark2x > 配置 > 全部配置”，搜索并修改所有的 spark.ranger.plugin.masking.enable 参数值为 true，保存配置并重启服务。
- 客户端：登录 Spark 客户端节点，进入目录“*{客户端安装目录}*/Spark/spark/conf/spark-defaults.conf”，修改 spark.ranger.plugin.masking.enable 参数值为 true。

步骤 1 登录 Ranger WebUI 界面，在首页单击“HADOOP SQL”区域的组件插件名称如“Hive”。

步骤 2 在“Masking”页签单击“Add New Policy”，添加 Spark2x 权限控制策略。

步骤 3 根据业务需求配置相关参数。

表20-18 Spark2x 数据脱敏参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
Hive Database	配置当前策略适用的 Spark2x 中的数据库名称。
Hive Table	配置当前策略适用的 Spark2x 中的表名称。
Hive Column	配置当前策略适用的 Spark2x 中的列名称。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Mask Conditions	在“Select Group”、“Select User”列选择已创建好的需要授予权限的用户组或用户，单击“Add Conditions”，添加策略适用的 IP 地址范围，然后在单击“Add Permissions”，勾选“select”权限。 单击“Select Masking Option”，选择数据脱敏时的处理策略： • Redact：用 x 屏蔽所有字母字符，用 0 屏蔽所有数字字符。 • Partial mask: show last 4：只显示最后的 4 个字符。 • Partial mask: show first 4：只显示开始的 4 个字符。 • Hash：对数据进行 Hash 处理。 • Nullify：用 NULL 值替换原值。 • Unmasked(retain original value)：不脱敏，显示原数据。 • Date: show only year：日期格式数据只显示年份信息。 • Custom：可使用任何有效 Hive UDF（返回与被屏蔽的列中的数据类型相同的数据类型）来自定义策略。 如需添加多列的脱敏策略，可单击  按钮添加。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”类型。

----结束

Spark2x 行级别数据过滤

Ranger 支持用户对 Spark2x 数据表执行 select 操作时进行行级别的数据过滤。

修改服务端和客户端 spark.ranger.plugin.rowfilter.enable 参数值为 ture。

- 服务端：登录 FusionInsight Manage 页面，选择“集群 > 服务 > Spark2x > 配置 > 全部配置”，搜索并修改所有的 spark.ranger.plugin.rowfilter.enable 参数值为 true，保存配置并重启服务。
- 客户端：登录 Spark 客户端节点，进入目录“*{客户端安装目录}*/Spark/spark/conf/spark-defaults.conf”，修改 spark.ranger.plugin.rowfilter.enable 参数值为 true。

步骤 1 登录 Ranger WebUI 界面，在首页单击“HADOOP SQL”区域的组件插件名称如“Hive”。

步骤 2 在“Row Level Filter”页签单击“Add New Policy”，添加行数据过滤策略。

步骤 3 根据业务需求配置相关参数。

表20-19 Spark2x 行数据过滤参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
Hive Database	配置当前策略适用的 Saprk2x 中的数据库名称。
Hive Table	配置当前策略适用的 Saprk2x 中的表名称。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Row Filter Conditions	在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的对象，单击“Add Conditions”，添加策略适用的 IP 地址范围，然后在单击“Add Permissions”，勾选“select”权限。 单击“Row Level Filter”，填写数据过滤规则。 例如过滤表 A 中“name”列“zhangsan”行的数据，过滤规则为：name <> 'zhangsan'。更多信息可参考 Ranger 官方文档。 如需添加更多规则，可单击  按钮添加。

步骤 4 单击“Add”，在策略列表可查看策略的基本信息。

步骤 5 用户通过 Saprk2x 客户端对配置了数据脱敏策略的表执行 select 操作，系统将对数据进行处理后进行展示。

----结束

20.13 添加 Kafka 的 Ranger 访问权限策略

操作场景

Ranger 管理员可通过 Ranger 为 Kafka 用户配置 Kafka 主题的读、写、管理权限以及集群的管理权限，本章节以为用户“test”添加 “test” 主题的“生产”权限。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 已创建用户需要配置权限的用户、用户组或 Role。

操作步骤

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 在首页中单击“KAFKA”区域的组件插件名称如“Kafka”。

步骤 2 单击“Add New Policy”，添加 Kafka 权限控制策略。

步骤 3 根据业务需求配置相关参数。

表20-20 Kafka 权限参数

参数名称	描述
Policy Type	Access。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
topic	配置当前策略适用的 topic 名，可以填写多个值。这里支持通配符，例如：test、test*、*。 “Include”策略适用于当前输入的对象，“Exclude”表示策略适用于除去当前输入内容之外的其他对象。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Allow Conditions	策略允许条件，配置本策略内允许的权限及例外，例外条件优先级高于正常条件。 在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的 Role、用户组或用户。 单击“Add Conditions”，添加策略适用的 IP 地址范围，单击

参数名称	描述
	“Add Permissions”，添加对应权限。 • Publish：生产权限。 • Consume：消费权限。 • Describe：查询权限。 • Create： 创建主题权限。 • Delete： 删除主题权限。 • Describe Configs：查询配置权限。 • Alter：修改 topic 的 partition 数量的权限。 • Alter Configs：修改配置权限。 • Select/Deselect All：全选/取消全选。 如需添加多条权限控制规则，可单击  按钮添加。 如需当前条件中的用户或用户组管理本条策略，可勾选“Delegate Admin”，这些用户将成为受委托的管理员。被委托的管理员可以更新、删除本策略，它还可以基于原始策略创建子策略。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”类型，拒绝条件的优先级高于“Allow Conditions”中配置的允许条件。

例如为用户“testuser”添加“test”主题的生产权限，配置如下：

图20-2 Kafka 权限参数

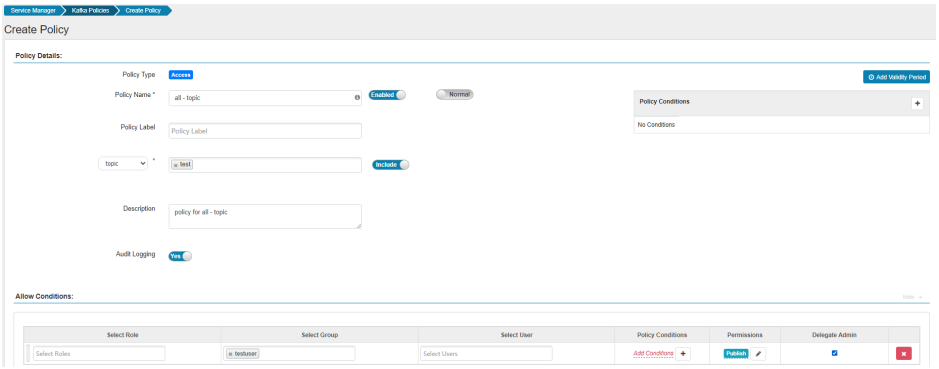

表20-21 设置权限

任务场景	角色授权操作
设置 Kafka 管理员权限	1. 在首页中单击“KAFKA”区域的组件插件名称，例如“Kafka”。

任务场景	角色授权操作
	2. 选择“Policy Name”为“all - topic”的策略，单击  按钮编辑策略。 3. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 4. 单击“Add Permissions”，勾选“Select/Deselect All”。
设置用户对 Topic 的创建权限	1. 在“topic”配置 Topic 名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Create”。 **说明** 目前 Kafka 内核支持"--zookeeper"和"--bootstrap-server"两种方式创建 Topic，社区将会在后续的版本中删掉对"--zookeeper"的支持，所以建议用户使用"--bootstrap-server"的方式创建 Topic。 注意：目前 Kafka 只支持"--bootstrap-server"方式创建 Topic 行为的鉴权，不支持对"--zookeeper"方式的鉴权
设置用户对 Topic 的删除权限	1. 在“topic”配置 Topic 名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Delete”。 **说明** 目前 Kafka 内核支持"--zookeeper"和"--bootstrap-server"两种方式删除 Topic，社区将会在后续的版本中删掉对"--zookeeper"的支持，所以建议用户使用"--bootstrap-server"的方式删除 Topic。 注意：目前 Kafka 只支持对"--bootstrap-server"方式删除 Topic 行为的鉴权，不支持对"--zookeeper"方式的鉴权
设置用户对 Topic 的查询权限	1. 在“topic”配置 Topic 名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Describe”和“Describe Configs”。 **说明** 目前 Kafka 内核支持"--zookeeper"和"--bootstrap-server"两种方式查询 Topic，社区将会在后续的版本中删掉对"--zookeeper"的支持，所以建议用户使用"--bootstrap-server"的方式查询 Topic。 注意：目前 Kafka 只支持对"--bootstrap-server"方式查询 Topic 行为的鉴权，不支持对"--zookeeper"方式的鉴权
设置用户对 Topic 的生产权限	1. 在“topic”配置 Topic 名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。

任务场景	角色授权操作
	3. 单击“Add Permissions”，勾选“Publish”。
设置用户对 Topic 的消费权限	1. 在“topic”配置 Topic 名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Consume”。 **说明** 因为消费 Topic 时，涉及到 Offset 的管理操作，必须同时开启 ConsumerGroup 的“Consume”权限，详见“设置用户对 ConsumerGroup Offsets 的提交权限”
设置用户对 Topic 的扩容权限（增加分区）	1. 在“topic”配置 Topic 名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Alter”。
设置用户对 Topic 的配置修改权限	当前 Kafka 内核暂不支持基于“--bootstrap-server”的 Topic 参数修改行为，故当前 Ranger 不支持对此行为的鉴权操作。
设置用户对 Cluster 的所有管理权限	1. 在“cluster”右侧输入并选择集群名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Kafka Admin”。
设置用户对 Cluster 的创建权限	1. 在首页中单击“KAFKA”区域的组件插件名称，例如“Kafka”。 2. 选择“Policy Name”为“all - cluster”的策略，单击  按钮编辑策略。 3. 在“cluster”右侧输入并选择集群名。 4. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 5. 单击“Add Permissions”，勾选“Create”。 **说明** 对于 Cluster 的 Create 操作鉴权主要涉及以下两个场景： 1. 集群开启了“auto.create.topics.enable”参数后，客户端向服务的还未创建的 Topic 发送数据的场景，此时会判断用户是否有集群的 Create 权限 2. 对于用户创建大量 Topic 的场景，如果授予用户 Cluster Create 权限，那么该用户可以在集群内部创建任意 Topic
设置用户对 Cluster 的配置修改权限	1. 在“cluster”右侧输入并选择集群名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Alter Configs”。 **说明**

任务场景	角色授权操作
	此处的配置修改权限，指的是 Broker、Broker Logger 的配置权限。 当授予用户配置修改权限后，即使不授予配置查询权限也可查询配置详情（配置修改权限高于且包含配置查询权限）。
设置用户对 Cluster 的配置查询权限	1. 在“cluster”右侧输入并选择集群名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Describe”和“Describe Configs”。 **说明** 此处查询指的是查询集群内的 Broker、Broker Logger 信息。该查询不涉及 Topic。
设置用户对 Cluster 的 Idempotent Write 权限	1. 在“cluster”右侧输入并选择集群名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Idempotent Write”。 **说明** 此权限会对用户客户端的 Idempotent Produce 行为进行鉴权。
设置用户对 Cluster 的分区迁移权限管理	1. 在“cluster”右侧输入并选择集群名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Alter”。 **说明** Cluster 的 Alter 权限可以对以下三种场景进行权限控制： 1. Partition Reassign 场景下，迁移副本的存储目录。 2. 集群里各分区内部 leader 选举。 3. Acl 管理（添加或删除）。 其中步骤 4.1 和步骤 4.2 都是集群内部 Controller 与 Broker 间、Broker 与 Broker 间的操作，创建集群时，默认授予内置 kafka 用户此权限，普通用户授予此权限没有意义。 步骤 4.3 涉及 Acl 的管理，Acl 设计的就是用于鉴权，由于目前 kafka 鉴权已全部托管给 Ranger，所以这个场景也基本不涉及（配置后亦不生效）。
设置用户对 Cluster 的 Cluster Action 权限	1. 在“cluster”右侧输入并选择集群名。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Cluster Action”。 **说明** 此权限主要对集群内部副本主从同步、节点间通信进行控制，在集群创建时已经授权给内置 kakfa 用户，普通用户授

任务场景	角色授权操作
	予此权限没有意义。
设置用户对 TransactionalId 的权限	1. 在首页中单击“KAFKA”区域的组件插件名称，例如“Kafka”。 2. 选择“Policy Name”为“all - transactionalid”的策略，单击  按钮编辑策略。 1. 在“transactionalid”配置事务 ID。 2. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 3. 单击“Add Permissions”，勾选“Publish”和"Describe"。 **说明** “Publish”权限主要对用户开启了事务特性的客户端请求进行鉴权，例如事务开启、结束、提交 offset、事务性数据生产等行为。 “Describe”权限主要对于开启事务特性的客户端与 Coordinator 的请求进行鉴权。 建议在开启事务特性的场景下，给用户同时授予“Publish”和“Describe”权限。
设置用户对 DelegationToken 的权限	1. 在首页中单击“KAFKA”区域的组件插件名称，例如“Kafka”。 2. 选择“Policy Name”为“all - delegationtoken”的策略，单击  按钮编辑策略。 3. 在“delegationtoken”配置 delegationtoken。 4. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 5. 单击“Add Permissions”，勾选“ Describe”。 **说明** 当前 Ranger 对 DelegationToken 的鉴权控制仅限于对查询的权限控制，不支持对 DelegationToken 的 create、renew、expire 操作的权限控制。
设置用户对 ConsumerGroup Offsets 的查询权限	1. 在首页中单击“KAFKA”区域的组件插件名称，例如“Kafka”。 2. 选择“Policy Name”为“all - consumergroup”的策略，单击  按钮编辑策略。 3. 在“consumergroup”配置需要管理的 consumergroup。 4. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 5. 单击“Add Permissions”，勾选“Describe”。
设置用户对 ConsumerGroup Offsets 的提交权限	1. 在首页中单击“KAFKA”区域的组件插件名称，例如“Kafka”。 2. 选择“Policy Name”为“all - consumergroup”的

任务场景	角色授权操作
	策略，单击  按钮编辑策略。 3. 在“consumergroup”配置需要管理的consumergroup。 4. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 5. 单击“Add Permissions”，勾选“Consume”。 **说明** 当给用户授予了 ConsumerGroup 的“Consume”权限后，用户会同时被授予“Describe”权限。
设置用户对 ConsumerGroup Offsets 的删除权限	1. 在首页中单击“KAFKA”区域的组件插件名称，例如“Kafka”。 2. 选择“Policy Name”为“all - consumergroup”的策略，单击  按钮编辑策略。 3. 在“consumergroup”配置需要管理的consumergroup。 4. 在“Allow Conditions”区域，单击“Select User”下选择框选择用户。 5. 单击“Add Permissions”，勾选“Delete”。 **说明** 当给用户授予了 ConsumerGroup 的“Delete”权限后，用户会同时被授予“Describe”权限。

步骤 4 （可选）添加策略有效期。在页面右上角单击“Add Validity period”，设置“Start Time”和“End Time”，选择“Time Zone”。单击“Save”保存。如需添加多条策略有效期，可单击  按钮添加。如需删除策略有效期，可单击  按钮删除。

步骤 5 单击“Add”，在策略列表可查看策略的基本信息。等待策略生效后，验证相关权限是否正常。

如需禁用某条策略，可单击  按钮编辑策略，设置策略开关为“Disabled”。

如果不再使用策略，可单击  按钮删除策略。

----结束

20.14 添加 HetuEngine 的 Ranger 访问权限策略

操作场景

Ranger 管理员可通过 Ranger 为 HetuEngine 用户配置操作数据源的数据库、表、列的管理权限。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 已创建用户需要配置权限的用户、用户组或角色。
- 用户已加入 hetuuser 组。
- 在使用 HetuEngine 前，请确保客户端操作用户/连接数据源的配置文件中的用户是具备预期的操作权限，如果没有请参考对应的数据源权限配置。

操作步骤

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 在首页中单击“PRESTO”区域的“HetuEngine”。

步骤 2 在“Access”页签单击“Add New Policy”，添加 HetuEngine 权限控制策略。

步骤 3 根据业务需求配置相关参数。

“授予访问表所在的 Catalog 策略”为基础策略，配置其他策略前必须先确保配置了此策略，可参考表 20-23 进行配置。

表20-22 HetuEngine 权限参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。 • Enabled：启用当前策略。 • Disabled：不启用当前策略。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
Presto Catalog	适用该策略的数据源 Catalog 名称，填写*时表示所有 Catalog。 • Include：策略适用于当前输入的对象。 • Exclude：策略适用于除去当前输入内容之外的其他对象。
Schema	适用该策略的 schema 名称，填写*时表示所有 schema。 • Include：策略适用于当前输入的对象。 • Exclude：策略适用于除去当前输入内容之外的其他对象。
table	适用该策略的 table/view 名称，填写*时表示所有 table。 • Include：策略适用于当前输入的对象。

参数名称	描述
	• Exclude：策略适用于除去当前输入内容之外的其他对象。
Column	适用该策略的列名，填写*时表示所有列。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Allow Conditions	策略允许条件，配置本策略内允许的权限及例外。 在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的 Role、用户组或用户。单击“Add Conditions”，添加策略适用的 IP 地址范围，单击“Add Permissions”，添加对应权限。 • Select：查询权限 • Insert：插入权限 • Create：创建权限 • Drop：drop 权限 • Delete：删除权限 • Use：use 权限 • Alter：alter 权限 • Update: update 权限 • Admin：admin 权限 • All：所有执行权限（涵盖 Admin 权限） • Select/Deselect All：全选/取消全选 如需添加多条权限控制规则，可单击  按钮添加。 如需当前条件中的用户或用户组管理本条策略，可勾选“Delegate Admin”，这些用户将成为受委托的管理员。被委托的管理员可以更新、删除本策略，它还可以基于原始策略创建子策略。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”相同。

表20-23 设置权限

任务场景	角色授权操作
授予访问表所在的 Catalog 策略	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的资源所在的 catalog，如“hive”。 3. 在“Select User”中填授权的 Hetu 用户。

任务场景	角色授权操作
	4. 在“Permissions”中勾选“Select”。 说明 此策略为基础策略，在配置其他策略前必须先确保配置了此策略。
授予访问远端 HetuEngine 表的权限	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的表所在的 catalog，“systemremote”和“svc”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入“*”。 4. 在“schema”下方的下拉框中选中“table”，同时在其对应的输入框中输入“*”。 5. 在“table”下方的下拉框中选中“column”，同时在其对应的输入框中输入“*”。 6. 在“Select User”中填授权的远端 HetuEngine 用户。 7. 在“Permissions”中勾选“Create、Drop、Select、Insert”。 说明 此策略为远端 HetuEngine 表的基础策略，在配置其他策略前必须先确保配置了此策略。
Create schema	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的 table 所在的 catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入要授权的 schema 名称。如果填“*”，表示对所有当前 catalog 下的所有 schema 进行授权。 4. 在“Select User”中填授权的 Hetu 用户。 5. 在“Permissions”中勾选“Create”。
Drop schema	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的 table 所在的 catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入要授权的 schema 名称。如使用“*”，表示对所有当前 catalog 下的所有 schema 进行授权。 4. 在“Select User”中填授权的 Hetu 用户。 5. 在“Permissions”中勾选“Drop”。
Create table	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的 table 所在的 catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入要授权 table 所在的 schema，如“default”。 4. 在“schema”下方的下拉框中选中“table”，同时在其

任务场景	角色授权操作
	对应的输入框中输入要授权的目标 table。如使用“*”，表示对所有当前 schema 下的所有 table 进行授权。 5. 在“Select User”中填授权的 Hetu 用户。 6. 在“Permissions”中勾选“Create”。
Drop table	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的 table 所在的 catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入要授权 table 所在的 schema，如“default”。 4. 在“schema”下方的下拉框中选中“table”，同时在其对应的输入框中输入要授权的目标 table。如使用“*”，表示对所有当前 schema 下的所有 table 进行授权。 5. 在“Select User”中填授权的 Hetu 用户。 6. 在“Permissions”中勾选“Drop”。
Alter table	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的 table 所在的 catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入要授权 table 所在的 schema，如“default”。 4. 在“schema”下方的下拉框中选中“table”，同时在其对应的输入框中输入要授权的目标 table。如使用“*”，表示对所有当前 schema 下的所有 table 进行授权。 5. 在“Select User”中填授权的 Hetu 用户。 6. 在“Permissions”中勾选“Alter”。 **说明** ALTER TABLE table_name DROP [IF EXISTS] PARTITION partition_spec[, PARTITION partition_spec, ...]; 的操作需要额外授予 Table 级别的“delete”和 Column 级别的“select”权限。
Show tables	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的表所在的 catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入允许 show table 的目标 schema，如“default”。 4. 在“Select User”中填授权的 Hetu 用户。 5. 在“Permissions”中勾选“Select”。
Insert 表	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的 table 所在的

任务场景	角色授权操作
	catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入要授权 table 所在的 schema，如“default”。 4. 在“schema”下方的下拉框中选中“table”，同时在其对应的输入框中输入要授权的目标 table。如使用“*”，表示对所有当前 schema 下的所有 table 进行授权。 5. 在“Select User”中填授权的 Hetu 用户。 6. 在“Permissions”中勾选“Insert”。
Delete	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的 table 所在的 catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入要授权 table 所在的 schema，如“default”。 4. 在“schema”下方的下拉框中选中“table”，同时在其对应的输入框中输入要授权的目标 table。如使用“*”，表示对所有当前 schema 下的所有 table 进行授权。 5. 在“Select User”中填授权的 Hetu 用户。 6. 在“Permissions”中勾选“Delete”。
Select	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的 table 所在的 catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入要授权 table 所在的 schema，如“default”。 4. 在“schema”下方的下拉框中选中“table”，同时在其对应的输入框中输入要授权的目标 table。如使用“*”，表示对所有当前 schema 下的所有 table 进行授权。 5. 在“table”下方的下拉框中选中“column”，同时在其对应的输入框中输入要授权的目标 column。如使用“*”，表示对所有当前 table 下的所有 column 进行授权 6. 在“Select User”中填授权的 Hetu 用户。 7. 在“Permissions”中勾选“Select”。
show columns	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写要授权的 table 所在的 catalog，如“hive”。 3. 在“Presto Catalog”下方的下拉框中选中“schema”，同时在其对应的输入框中输入要授权 table 所在的 schema，如“default”。

任务场景	角色授权操作
	4. 在“schema”下方的下拉框中选中“table”，同时在其对应的输入框中输入要授权的目标 table。如使用“*”，表示对所有当前 schema 下的所有 table 进行授权。 5. 在“table”下方的下拉框中选中“column”，同时在其对应的输入框中输入要授权的目标 column。如使用“*”，表示对所有当前 table 下的所有 column 进行授权。 6. 在“Select User”中填授权的 Hetu 用户。 7. 在“Permissions”中勾选“Select”。
set session	1. 在“Policy Name”填写策略名称。 2. 在“Presto Catalog”填写“*”。 3. 在“Select User”中填授权的 Hetu 用户。 4. 在“Delegate Admin”中进行勾选。

说明

- 配置权限后预计 30 秒左右生效。
- 目前的权限管控可以到达列的级别。

步骤 4 （可选）添加策略有效期。在页面右上角单击“Add Validity period”，设置“Start Time”和“End Time”，选择“Time Zone”。单击“Save”保存。如需添加多条策略有效期，可单击  按钮添加。如需删除策略有效期，可单击  按钮删除。

步骤 5 单击“Add”，在策略列表可查看策略的基本信息。等待策略生效后，验证相关权限是否正常。

如需禁用某条策略，可单击  按钮编辑策略，设置策略开关为“Disabled”。

如果不再使用策略，可单击  按钮删除策略。

----结束

HetuEngine 数据脱敏

Ranger 支持对 HetuEngine 数据进行脱敏处理（Data Masking），可对用户执行的 select 操作的返回结果进行处理，以屏蔽敏感信息。

登录 Ranger WebUI 界面，在首页中单击“PRESTO”区域的“HetuEngine”。

步骤 1 在“Masking”页签单击“Add New Policy”，添加 HetuEngine 数据脱敏策略。

步骤 2 根据业务需求配置相关参数。

表20-24 HetuEngine 数据脱敏参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
Presto Catalog	配置当前策略使用的 Catalog 名称。
Presto Schema	配置当前策略使用的数据库名称。
Presto Table	配置当前策略使用的表名称。
Presto Column	配置当前策略使用的列名称。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Mask Conditions	在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的对象，单击“Add Conditions”，添加策略适用的 IP 地址范围，然后在单击“Add Permissions”，勾选“Select”权限。 单击“Select Masking Option”，选择数据脱敏时的处理策略： • Redact：用 x 屏蔽所有字母字符，用 0 屏蔽所有数字字符。 • Partial mask: show last 4：只显示最后的 4 个字符，其他用 x 代替。 • Partial mask: show first 4：只显示开始的 4 个字符，其他用 x 代替。 • Hash：用值的哈希值替换原值。 • Nullify：用 NULL 值替换原值。 • Unmasked(retain original value)：原样显示。 • Custom：可使用任何有效返回与被屏蔽的列中的数据类型相同的数据类型来自定义策略。 如需添加多列的脱敏策略，可单击  按钮添加。

步骤 3 单击“Add”，在策略列表可查看策略的基本信息。

步骤 4 用户通过 HetuEngine 客户端对配置了数据脱敏策略的表执行 select 操作，系统将对数据进行处理后进行展示。

----结束

HetuEngine 行级别数据过滤

Ranger 支持用户对 HetuEngine 数据表执行 select 操作时进行行级别的数据过滤。

登录 Ranger WebUI 界面，在首页中单击“PRESTO”区域的“HetuEngine”。

步骤 1 在“Row Level Filter”页签单击“Add New Policy”，添加行数据过滤策略。

步骤 2 根据业务需求配置相关参数。

表20-25 HetuEngine 行数据过滤参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Conditions	IP 过滤策略，可自定义，配置当前策略适用的主机节点，可填写一个或多个 IP 或 IP 段，并且 IP 填写支持“*”通配符，例如：192.168.1.10,192.168.1.20 或者 192.168.1.*。
Policy Label	为当前策略指定一个标签，您可以根据这些标签搜索报告和筛选策略。
Presto Catalog	配置当前策略使用的 Catalog 名称。
Presto Schema	配置当前策略使用的数据库名称。
Presto Table	配置当前策略使用的表名称。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Row Filter Conditions	在“Select Role”、“Select Group”、“Select User”列选择已创建好的需要授予权限的对象，单击“Add Conditions”，添加策略适用的 IP 地址范围，然后在单击“Add Permissions”，勾选“Select”权限。 单击“Row Level Filter”，填写数据过滤规则。 例如过滤表 A 中“name”列“zhangsan”行的数据，过滤规则为：name <> 'zhangsan'。更多信息可参考 Ranger 官方文档。 如需添加更多规则，可单击  按钮添加。

步骤 3 单击“Add”，在策略列表可查看策略的基本信息。

步骤 4 用户通过 HetuEngine 客户端对配置了数据脱敏策略的表执行 select 操作，系统将对数据进行处理后进行展示。

----结束

20.15 添加 OBS 的 Ranger 访问权限策略

操作场景

Ranger 管理员可以通过 Ranger 为 OBS 用户配置 OBS 目录或文件的读、写权限。

说明

本章节仅适用于 MRS 3.3.0-LTS 及之后版本。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 已创建需要配置权限的用户组。
- 已安装 Guardian 服务。

操作步骤

使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，具体操作可参考 20.1 登录 Ranger 管理界面。

步骤 1 在首页中单击“EXTERNAL AUTHORIZATION”区域的组件插件名称“OBS”。

步骤 2 单击“Add New Policy”，添加 OBS 权限控制策略。

步骤 3 根据业务需求配置相关参数。

表20-26 OBS 权限参数

参数名称	描述
Policy Name	策略名称，可自定义，不能与本服务内其他策略名称重复。
Policy Label	为当前策略指定一个标签，可以根据这些标签搜索报告和筛选策略。
Resource Path	资源路径，配置当前策略适用的 OBS 路径文件夹或文件，可填写多个值，不支持使用通配符“*”。且配置的 OBS 路径文件夹或文件必须是已存在的，否则会授权失败。 OBS 默认开启权限的递归（且不支持修改），无任何权限的子目录会默认继承父目录所有的权限。
Description	策略描述信息。
Audit Logging	是否审计此策略。
Allow Conditions	策略允许条件，配置本策略内允许的权限。 “Select Group”列选择已创建好的需要授予权限的用户组（配置“Select Role”和“Select User”将不会生效） 单击“Add Permissions”，添加对应权限。 • Read：读权限

参数名称	描述
	• Write：写权限 • Select/Deselect All：全选/取消全选 如需添加多条权限控制规则，可单击  按钮添加。如需删除权限控制规则，可单击  按钮删除。

例如，为用户组“hs_group1”（该用户组仅由数字 0~9、字母 a~Z、下划线或#组成，且最大长度为 52 个字符，否则将导致策略添加失败）添加“obs://hs-test/user/hive/warehouse/o4”表的读写权限，配置如下：

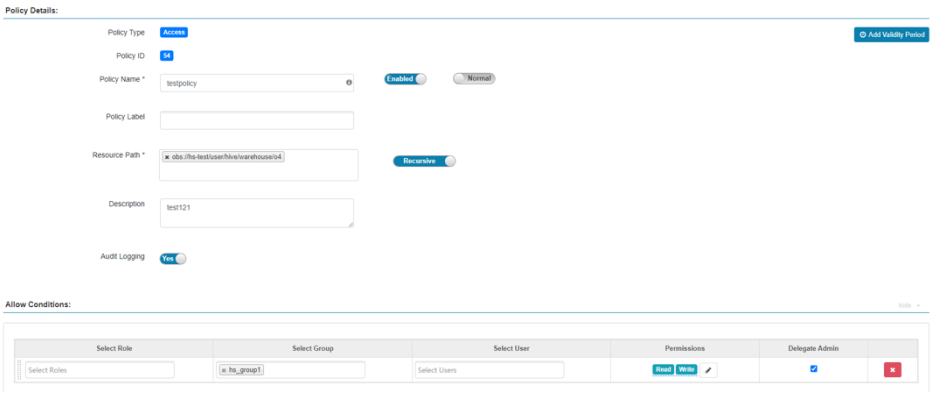

步骤 4 单击“Add”，在策略列表可查看策略的基本信息。等待策略生效后，验证相关权限是否正常。

如果不再使用策略，可单击  按钮删除策略。

----结束

20.16 Hive 表支持级联授权功能

本章节适用于 MRS 3.3.0 及之后版本。

操作场景

开启级联授权功能的集群极大地提升了鉴权易用性，用户只需在 Ranger 页面上对业务表进行一次授权，系统就会自动细粒度关联数据存储源的权限，不需要感知表的存储路径，无需进行二次授权。同时也补齐了基于存算分离授权功能缺陷，可以在 Ranger 上实现对存算分离表的授权鉴权。Hive 表的级联授权功能主要体现为：

- 开启 Ranger 级联授权后，Ranger 中创建策略对表授权时，只需创建表的 Hive 策略，无需对表存储源进行二次授权。
- 针对已授权的库/表，当存储源发生变动时，周期同步关联新存储源 HDFS/OBS，生成对应权限。

说明

- 不支持对视图表进行级联授权。
- 仅支持对数据库/表进行级联授权操作，不支持对分区做级联权限，如果分区路径不在表路径下，则需要用户手动授权分区路径。
- 不支持对 Hive Ranger 策略中的“Deny Conditions”进行级联授权，即“Deny Conditions”的权限仅限制表权限，不能生成 HDFS/OBS 存储源端的权限。
- 不支持在 Hive Ranger 中创建“database”为“*”且“table”为“*”的策略。
- 级联授权生成的 HDFS/OBS 存储源端的权限弱于 HDFS Ranger 策略的权限，即如果已经对表的 HDFS 存储源设置了 HDFS Ranger 权限，则级联权限将不会生效。
- 不支持对存储源为 OBS 的表级联授权后直接进行 **alter** 操作，需要给对应用户组额外授予 OBS 表路径的父目录的“Read”和“Write”权限才能使用 **alter** 功能，且用户组仅由数字 0~9、字母 a~Z、下划线或#组成，且最大长度为 52 个字符，否则将导致策略添加失败。
- 针对 OBS 存储源，需满足以下条件，否则 OBS 表将授权失败：
- 集群中必须已安装 Guardian 服务。
- OBS 表的授权只能针对用户组。
- 仅支持安全模式集群的 OBS 级联授权。

开启级联授权功能

登录 FusionInsight Manager 页面，选择“集群 > 服务 >Ranger> 配置”。

步骤 1 在搜索框中搜索参数“ranger.ext.authorization.cascade.enable”，修改该参数值为“true”。

步骤 2 单击“保存”，保存配置。

步骤 3 配置保存成功后，单击“实例”，勾选所有 RangerAdmin 实例，选择“更多 > 重启实例”，在弹出对话框输入密码，单击“确定”，重启所有 RangerAdmin 实例。

----结束

对接 HDFS 存储源

HDFS 存储源无需进行配置。

对接 OBS 存储源

- 建表时指定 Location 为 OBS 路径：
  a. 已参考完成存算分离配置。
  b. 使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，在首页中单击“EXTERNAL AUTHORIZATION”区域的组件插件名称“OBS”，单击“Add New Policy”，为对应用户的用户组赋予 OBS 存储路径的“Read”和“Write”的权限，详细操作请参见 20.15 添加 OBS 的 Ranger 访问权限策略。

     例如，为“hgroup1”用户组赋予“obs://obs-test/test/”目录的“Read”和“Write”的权限：

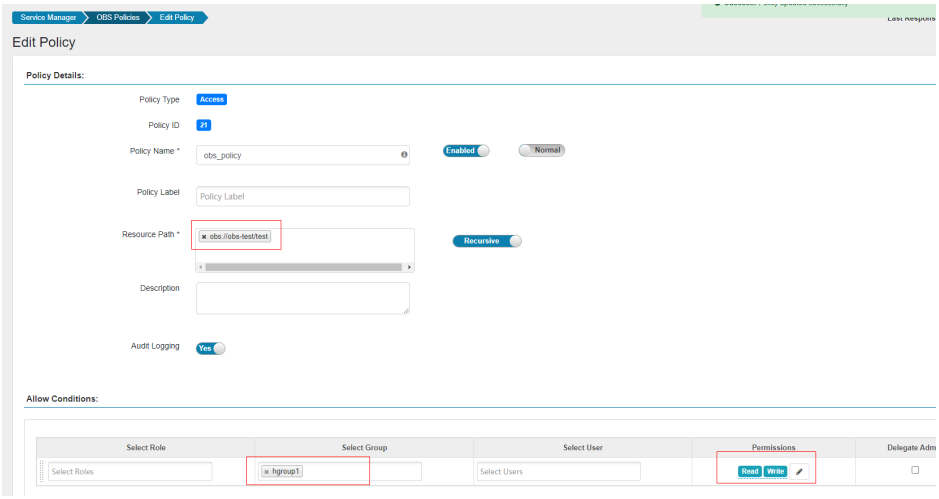

c. 在首页中单击“HADOOP SQL”区域的组件插件名称“Hive”。在“Access”页签单击“Add New Policy”为对应用户的用户组添加赋予 OBS 存储路径的“Read”和“Write”权限的 URL 策略，详细操作请参见 20.10 添加 Hive 的 Ranger 访问权限策略。

例如，为“hgroup1”用户组创建“hive_url_policy”URL 策略赋予“obs://obs-test/test/”目录的“Read”和“Write”的权限：

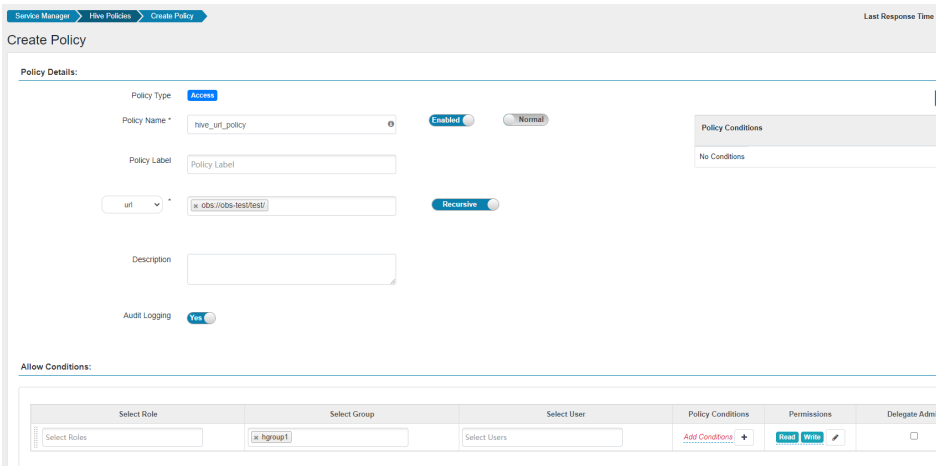

d. 进入 **beeline** 客户端，在创建表时指定 Location 为 OBS 文件系统路径。

cd *客户端安装目录*

kinit *组件操作用户*

beeline

例如，创建一个表“test”，该表的 Location 为“obs://obs-test/test/数据库名/表名”：

create table test(name string) location "obs://*obs-test/test/数据库名/表名***";**

- 配置 Hive 基于 MetaStore 方式对接 OBS：

a. 已参考完成存算分离配置。

b. 登录 FusionInsight Manager，选择“集群 > 服务 > Hive > 配置”。

c. 在搜索框搜索“hive.metastore.warehouse.dir”，修改参数值为 OBS 路径，例如：obs://hivetest/user/hive/warehouse/，其中“hivetest”为 OBS 文件系统名。

图20-3 hive.metastore.warehouse.dir 配置

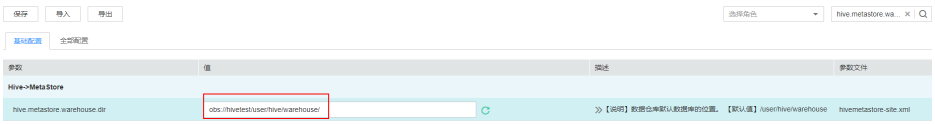

d. 保存配置，然后单击“集群 > 服务”，在服务列表中重启 Hive 服务。

e. 更新客户端配置文件。

i. 登录 Hive 客户端所在的节点，执行以下命令修改 Hive 客户端配置文件目录下的“hivemetastore-site.xml”。

vi *客户端安装目录*/**Hive/config/hivemetastore-site.xml**

ii. 将“hive.metastore.warehouse.dir”的值修改为对应的 OBS 路径，例如“obs://hivetest/user/hive/warehouse/”。

```
</property>
<property>
<name>hive.metastore.warehouse.dir</name>
<value>obs://hivetest/user/hive/warehouse</value>
</property>
<property>
```

iii. 修改 HCatalog 客户端配置文件目录下的“hivemetastore-site.xml”，将“hive.metastore.warehouse.dir”的值修改为对应的 OBS 路径，例如“obs://hivetest/user/hive/warehouse/”。

vi *客户端安装目录*/**Hive/HCatalog/conf/hivemetastore-site.xml**

iv. 使用 Ranger 管理员用户 **rangeradmin** 登录 Ranger 管理页面，在首页中单击“EXTERNAL AUTHORIZATION”区域的组件插件名称“OBS”，单击“Add New Policy”，为对应用户的用户组赋予 OBS 存储路径的“Read”和“Write”的权限。

例如，为“hgroup1”用户组赋予“obs://hivetest/user/hive/warehouse/”目录的“Read”和“Write”的权限：

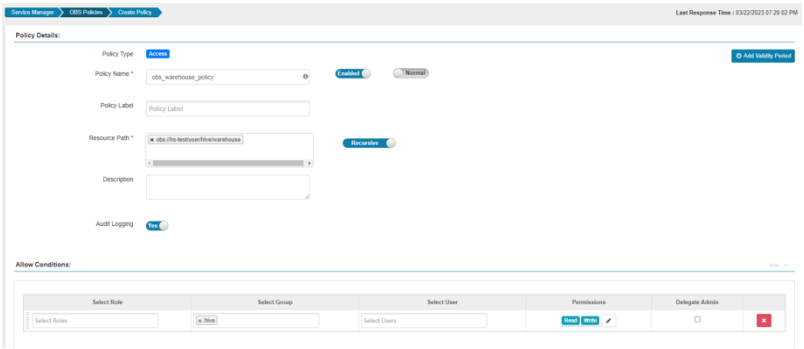

v. 选择“Settings > Roles > Add New Role”，创建“Role Name”为“hive”的角色：

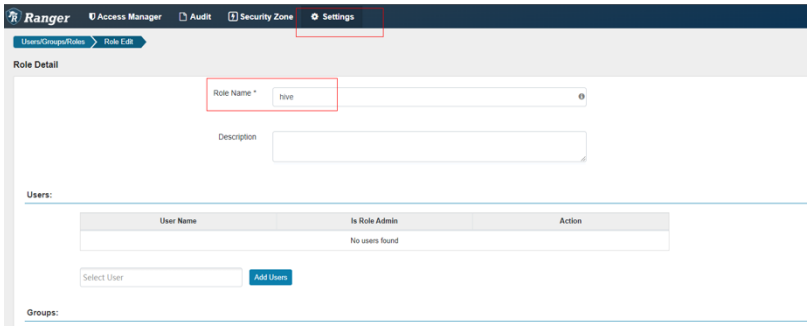

f. 进入 Hive Beeline 命令行，创建一个表并确认 Location 为 OBS 路径。

cd *客户端安装目录*

kinit *组件操作用户*

beeline

create table test(name string);

desc formatted test;

说明

如果当前数据库 Location 已指向 HDFS，那么在当前数据库下建表（不指定 Location）默认也指向当前 HDFS。如需修改默认建表策略可以修改数据库的 Location 重新指向 OBS。

操作如下：

1. 执行以下命令查看数据库 Location。

   show create database *obs_test*;

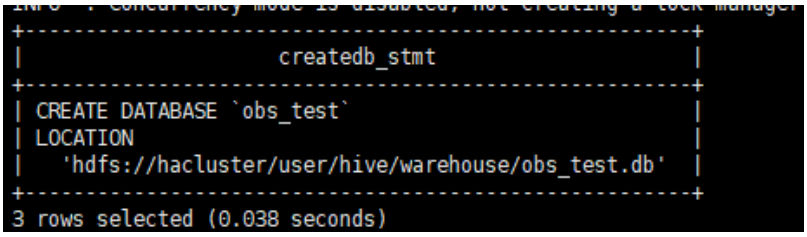

2. 执行以下命令修改数据库 Location。

   alter database *obs_test* **set location** *'obs://test1/'*

   执行命令 **show create database** *obs_test*，查看数据库 Location 已经指向 OBS。

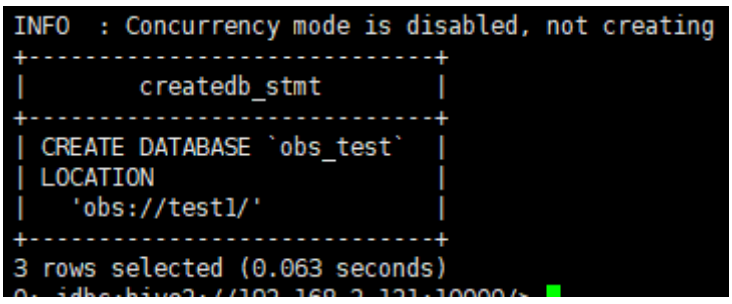

3. 执行以下命令修改表的 Location。

   alter table *user_info* **set location** *'obs://test1/'*

   如果表已有业务数据，需要同步迁移原数据文件至修改后的 Location 地址。

20.17 配置 RangerKMS 多实例

操作场景

MRS 集群安装两个 RangerKMS 实例后，配置 HDFS 多实例透明加密之前，需要修改 RangerKMS 相关配置。

说明

如果只安装了一个 RangerKMS 实例无需配置本章节。

本章节仅适用于 MRS 3.3.0-LTS 及之后版本。

前提条件

已安装两个 RangerKMS 实例。

操作步骤

选择“集群 > 服务 > Ranger> 配置 > 全部配置 > RangerKMS（角色） > 服务” 。

步骤 1 修改如下三个参数为对应值：

参数名称	设置值	说明
hadoop.kms.authentication.signer.secret.provider	zookeeper	选择 zookeeper 控制 token。
hadoop.kms.authentication.signer.secret.provider.zookeeper.path	/ranger-kms/hadoop-auth-signature-secret	RangerKMS 在 zookeeper 中的记录路径。

步骤 2 选择“全部配置 > RangerKMS（角色） > 缓存” 。

步骤 3 修改“hadoop.kms.cache.enable”参数配置值为“false”。

步骤 4 单击“保存”，在弹出的窗口中选择“确定”保存相关配置。

步骤 5 重启 RangerKMS 及其他配置过期的上层服务。

----结束

20.18 使用 RangerKMS 原生 UI 管理权限及密钥

操作场景

KMS 服务安装成功后，用户需要通过 FusionInsight Manager 创建用户并关联 KeyAdmin 角色，使该用户具有 Key 管理权限，进行密钥的管理以及对 HDFS 分区进行加密。

RangerKMS 的 UI 界面首次使用可以通过 rangerkms、keyadmin 用户登录。默认场景下 keyadmin 用户只有 key 管理权限无操作权限。而 rangerkms 用户既有 key 管理权限同时拥有 key 操作权限。

说明

本章节仅适用于 MRS 3.3.0-LTS 及之后版本。

前提条件

- 已安装 Ranger 服务且服务运行正常。
- 创建人机用户，可以不用添加权限。

为用户添加 KeyAdmin 角色

使用 **admin** 用户登录 FusionInsight Manager，选择“集群 > 服务 > Ranger”，进入 Ranger 服务概览页面。

步骤 1 单击“基本信息”区域中的“RangerAdmin”，进入 Ranger WebUI 界面。

步骤 2 在 Ranger WebUI 界面，单击右上角用户名，选择“Log Out”，退出当前用户。

步骤 3 使用 rangerkms 或者 keyadmin 用户（rangerkms 默认密码为 Rangerkms@123，keyadmin 默认密码为 Keyadmin@123）重新登录，首次登录需要修改用户密码。

步骤 4 选择“Settings > Users”，在“User Name”列单击需要赋予 KeyAdmin 角色权限的用户。

步骤 5 在“Select Role”中选择 KeyAdmin，在弹窗中单击“ok”。

步骤 6 单击“save”，用户添加 KeyAdmin 角色完成。

----结束

key 的权限管理

使用 rangerkms、keyadmin 或具有 KeyAdmin 角色的用户登录 Ranger UI。

步骤 1 在 Access Manager 界面单击“kmsdev”。

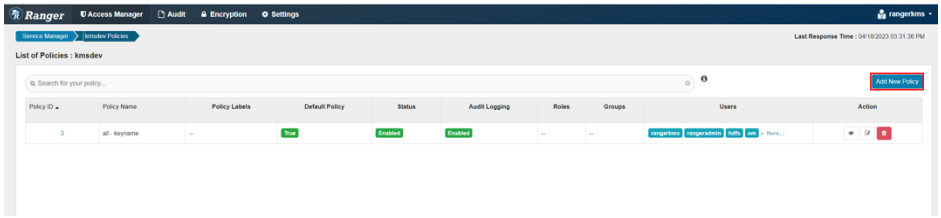

步骤 2 单击右上角的“Add New Policy”按钮可以添加新的策略。

步骤 3 根据业务需求配置相关参数。

表20-27 Add New Policy 参数配置

参数名称	描述
Policy Type	Access
Policy Name	策略名称，必填配置。
Policy Label	策略标签，用于对策略进行分类。
Key Name	Key 名称，及 KMS 中存储的 EZK 名称；该条策略就会对配置的 Key 生效，另外填*表示所有的 key。
Description	描述策略的内容。
Audit Logging	是否开启审计。
Allow Conditions	允许策略，可以对选择的用户、用户组或者角色配置相应的权限。包括 • Create：创建 Key • Delete：删除 key • Rollover：更新 key • Set Key Material：设置密钥密文 • Get：读取某个 key • Get keys：读取所有 key （策略中配置的 key） • Get Metadata：获取 key 的元信息 • Generate EEK：生成 EEK • Decrypt EEK：解密 EEK Exclude from Allow Conditions：配置允许条件之外的例外规则。
Deny All Other Accesses	是否拒绝其它所有访问。 • True：拒绝其它所有访问 • False：设置为 False，可配置 Deny Conditions。
Deny Conditions	策略拒绝条件，配置本策略内拒绝的权限及例外，配置方法与“Allow Conditions”类似。 拒绝条件的优先级高于“Allow Conditions”中配置的允许条件。 Exclude from Deny Conditions：配置排除在拒绝条件之外的例外规则。

步骤 4 单击“Add”，策略添加完成。该策略中对应的角色、用户组或者用户具有策略中 Key 相关权限。

----结束

原生 UI 管理密钥

使用 rangerkms 或者 keyadmin 用户登录 Ranger 管理界面。

步骤 1 单击“Encryption”，进入 key 管理界面。

步骤 2 在“Select Service”下拉列表中选择 kmsdev 服务。

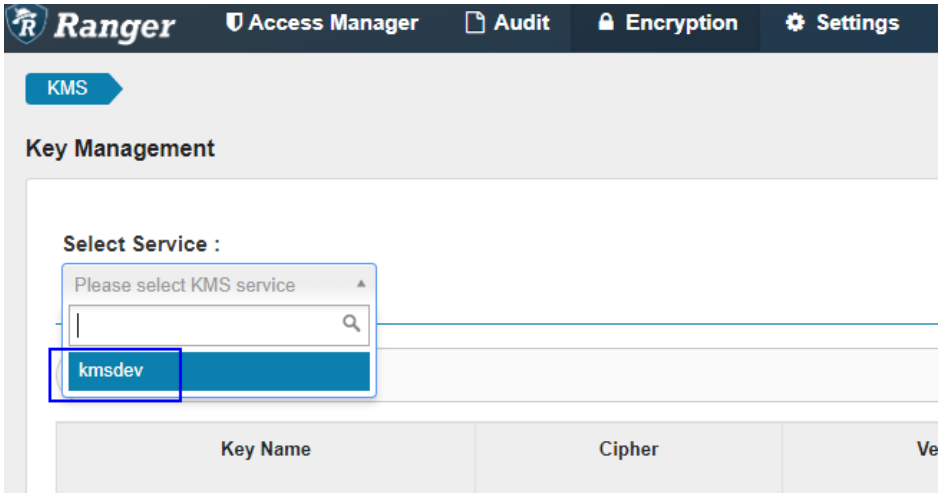

步骤 3 单击右侧的“Add New Key”按钮创建新的密钥。

表20-28 Add New Key 参数描述

参数名称	描述
Key Name	密钥名称。
Cipher	加密算法，默认 AES/CTR/NoPadding，不能修改。
Length	密钥长度，128 或者 256
Description	描述密钥的内容。
Attributes	密钥自定义属性，无需添加。

步骤 4 单击图中按钮可以更新密钥。

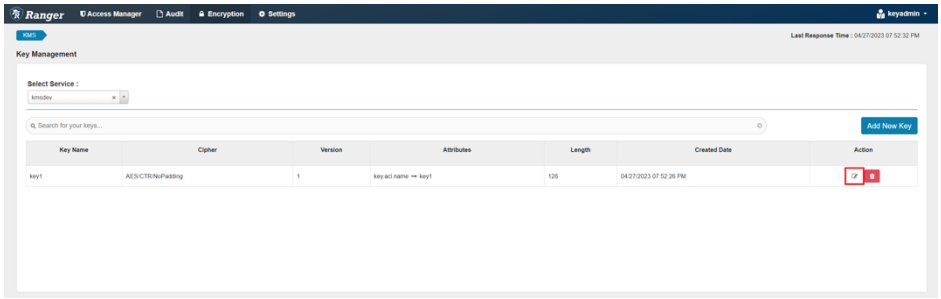

步骤 5 单击图表可以删除密钥。

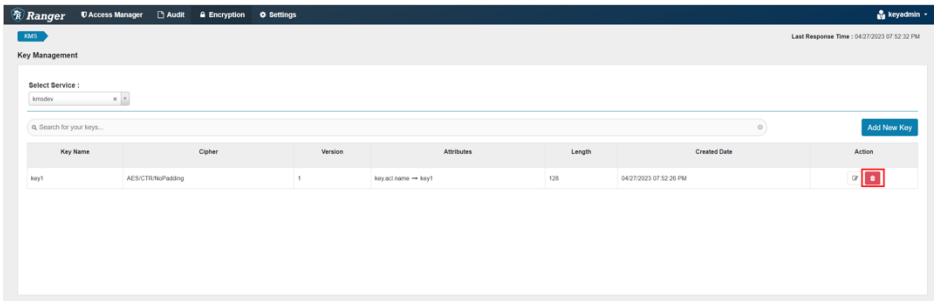

----结束

普通集群权限管理

登录 Manager 界面，进入“集群 > 服务 > Ranger > 配置 > RangerKMS > 自定义”。

步骤 1 在参数文件为 dbks-site.xml 行添加配置：

hadoop.kms.security.authorization.manager 值为空。

步骤 2 保存配置，重启 RangerKMS。

步骤 3 如果需要 Key 的管理权限需要将用户加入 rkmsadmin 组。

----结束

20.19 Ranger 规格配置

操作场景

Ranger 给各组件提供权限策略，当使用 Ranger 的服务增多，需要调整 Ranger 的规格。

说明

本章节仅适用 MRS 3.2.0 及之后版本。

内存参数配置

登录 FusionInsight Manager 页面，选择“集群 > 服务 > Ranger > 配置 > 全部配置”，搜索 RangerAdmin JVM 的参数“GC_OPTS”，参数默认值为“-Dproc_rangeradmin -Xms2G -Xmx2G -XX:MaxDirectMemorySize=512M -XX:MetaspaceSize=100M -XX:MaxMetaspaceSize=200M -XX:PermSize=64M -XX:MaxPermSize=512M -XX:+PrintGCDetails -XX:+PrintGCDateStamps -Xloggc:${RANGER_ADMIN_LOG_DIR}/gc-worker-%p-%t.log -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=20 -XX:GCLogFileSize=20M -verbose:gc -Djdk.tls.ephemeralDHKeySize=3072 -Djava.security.auth.login.config=#{conf_dir}/jaas.conf -Djava.security.krb5.conf=${KRB5_CONFIG} -Dbeetle.application.home.path=${BIGDATA_HOME}/common/runtime/security/config -Djna.tmpdir=${RANGER_TMP_HOME} -Djava.io.tmpdir=${RANGER_TMP_HOME} ${JAVA_STACK_PREFER} -Djdk.tls.rejectClientInitiatedRenegotiation=true”。

修改 RangerAdmin JVM 的参数“GC_OPTS”值，修改方案如下：

使用 Ranger 的服务实例包括 HDFS（NameNode）、Yarn（ResourceManager）、HBase（HMaster、RegionServer）、Hive(HiveServer)、Kafka（Broker）、Elasticsearch（EsNode、EsMaster、EsClient）、HetuEngine（HSBroker）、CDL（CDLService）增多时，请修改默认值中的“-Xms2G -Xmx2G”， RangerAdmin 内存规格参考值如下：

使用 Ranger 实例数（个）	参考值
200	-Xms4G -Xmx4G
400	-Xms8G -Xmx8G
600	-Xms12G -Xmx12G

----结束

20.20 Ranger 日志介绍

日志描述

日志存储路径：Ranger 相关日志的默认存储路径为“/var/log/Bigdata/ranger/*角色名*”

- RangerAdmin：“/var/log/Bigdata/ranger/rangeradmin”（运行日志），“/var/log/Bigdata/audit/ranger/rangeradmin”（审计日志，MRS 3.3.0 及之后版本）。
- TagSync：“/var/log/Bigdata/ranger/tagsync”（运行日志）。
- UserSync “/var/log/Bigdata/ranger/usersync”（运行日志）。
- RangerKMS：“/var/log/Bigdata/ranger/rangerkms”（运行日志，MRS 3.3.0 及之后版本）。
- PolicySync：“/var/log/Bigdata/ranger/policysync”（运行日志，MRS 3.3.0 及之后版本）。

日志归档规则：Ranger 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 20MB 的时，会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”，最多保留最近的 20 个压缩文件。

表20-29 Ranger 日志列表

日志类型	日志文件名	描述
RangerAdmin 运行日志	access_log.<*DATE*>.log	Tomcat 访问日志。
	catalina.out	Tomcat 服务运行日志。
	gc-worker.log	RangerAdmin 的 GC 日志。
	postinstallDetail.log	实例安装前启动后工作日志。

日志类型	日志文件名	描述
	prestartDetail.log	实例启动前准备工作日志。
	ranger-admin-<*hostname*>.log	RangerAdmin 运行日志。
	ranger_admin_sql-<*hostname*>.log	RangerAdmin 检索 DBService 的日志。
	startDetail.log	实例启动日志。
TagSync 运行日志	cleanupDetail.log	实例清理日志。
	gc-worker.log	实例 GC 日志。
	postinstallDetail.log	实例安装前启动后工作日志。
	prestartDetail.log	实例启动前准备工作日志。
	ranger-tagsync-<*hostname*>.log	TagSync 运行日志。
	startDetail.log	实例启动日志。
	tagsync.out	TagSync 的运行日志。
UserSync 运行日志	auth.log	unixauth 服务运行日志。
	cleanupDetail.log	实例清理日志。
	gc-worker.log	实例 GC 日志。
	postinstallDetail.log	实例安装前启动后工作日志。
	prestartDetail.log	实例启动前准备工作日志。
	ranger-usersync-<*hostname*>.log	USerSync 运行日志。
	startDetail.log	实例启动日志。
RangerKMS 运行日志（MRS 3.3.0 及之后版本）	access-<host>-<*DATE*>.log	Tomcat 访问日志。
	threadDump-<*DATE*>.log	进程 JVM GC 日志。
	stopDetail.log	实例停止日志。
	startDetail.log	实例启动日志。
	ranger-kms.log	实例运行日志。
	prestartDetail.log	实例启动前准备工作日志。

日志类型	日志文件名	描述
	catalina.out	Tomcat 服务运行日志。
	postinstallDetail.log	实例安装前启动后工作日志。
PolicySync 运行日志（MRS 3.3.0 及之后版本）	cleanupDetail.log	实例清理日志。
	policysync.out	实例运行日志。
	postinstallDetail.log	实例安装前启动后工作日志。
	prestartDetail.log	实例启动前准备工作日志。
	ranger-policysync.log	实例运行日志。
	startDetail.log	实例启动日志。
	gc-worker-pid<*PID*>-<*日期*>.log.<*编号*>	实例 GC 日志。
	stopDetail.log	实例停止日志。
审计日志（MRS 3.3.0 及之后版本）	rangeradmin-audit.log	RangerAdmin 审计日志。

日志级别

HDFS 中提供了如表 20-30 所示的日志级别，日志级别优先级从高到低分别是 FATAL、ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表20-30 日志级别

级别	描述
FATAL	FATAL 表示当前事件处理出现严重错误信息，可能导致系统崩溃。
ERROR	ERROR 表示当前事件处理出现错误信息，系统运行出错。
WARN	WARN 表示当前事件处理存在异常信息，但认为是正常范围，不会导致系统出错。
INFO	INFO 表示记录系统及各事件正常运行状态信息
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

登录 FusionInsight Manager。

步骤 2 选择“集群 > 服务 > Ranger > 配置”。

步骤 3 选择“全部配置”。

步骤 4 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 5 选择所需修改的日志级别。

步骤 6 单击“保存”，在弹出窗口中单击“确定”使配置生效。

说明

配置完成后立即生效，不需要重启服务。

----结束

日志格式

Ranger 的日志格式如下所示：

表20-31 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2020-04-29 20:09:28,543 | INFO | http-bio-21401-exec-56 | Request comes from API call, skip cas filter. | CasAuthenticationFilterWrapper.java:25

20.21 Ranger 常见问题

20.21.1 安装集群过程中，Ranger 启动失败

问题

安装集群过程中，Ranger 启动失败，Manager 进程任务列表里打印“ERROR：cannot drop sequence X_POLICY_REF_ACCESS_TYPE_SEQ”等关于数据库信息，如何解决并正常安装 Ranger？

回答

该现象可能出现在安装两个 RangerAmdin 实例的场景下，安装失败后，请先手动重启一个 RangerAdmin，然后再逐步重启其他实例。

20.21.2 如何判断某个服务是否使用了 Ranger 鉴权

问题

如何判断某个支持使用 Ranger 鉴权的服务当前是否启用了 Ranger 鉴权？

回答

登录 FusionInsight Manager，选择“集群 > 服务 > *服务名称*”，在服务详情页上继续单击“更多”，查看“启用 Ranger 鉴权”是否为可单击？

- 是，表示当前本服务未启用 Ranger 鉴权插件，可单击“启用 Ranger 鉴权”启用该功能。
- 否，表示当前本服务已启用 Ranger 鉴权插件，可通过 Ranger 管理界面配置访问该服务资源的权限策略。

说明

若不存在该选项，则表示当前服务不支持 Ranger 鉴权插件，未开启 Ranger 鉴权。

20.21.3 新创建用户修改完密码后无法登录 Ranger

问题

使用新建用户登录 Ranger 页面，为什么在修改完密码后登录报 401 错误？

回答

由于 UserSync 同步用户数据有时间周期，默认是 5 分钟，因此在 Manager 上新创建的用户在用户同步成功前无法登录 Ranger，因为 Ranger 的 DB 里暂时还没有该用户信息，需要等待同步周期所设置的时间后再尝试登录。

非安全模式下，由于 Ranger 并不从 Manager 同步用户数据，因此，仅有 admin 用户可以登录 Ranger，暂时不支持其他用户登录。

20.21.4 Ranger 界面添加或者修改 HBase 策略时，无法使用通配符搜索已存在的 HBase 表

问题

添加 HBase 的 Ranger 访问权限策略时，在策略中使用通配符搜索已存在的 HBase 表时，搜索不到已存在的表，并且在/var/log/Bigdata/ranger/rangeradmin/ranger-admin-*log 中报以下错误

```
Caused by: javax.security.sasl.SaslException: No common protection layer between
client and server
at
com.sun.security.sasl.gsskerb.GssKrb5Client.doFinalHandshake(GssKrb5Client.java:253)
at
com.sun.security.sasl.gsskerb.GssKrb5Client.evaluateChallenge(GssKrb5Client.java:18
6)
```

```
at
org.apache.hadoop.hbase.security.AbstractHBaseSaslRpcClient.evaluateChallenge(Abstr
actHBaseSaslRpcClient.java:142)
at
org.apache.hadoop.hbase.security.NettyHBaseSaslRpcClientHandler$2.run(NettyHBaseSas
lRpcClientHandler.java:142)
at
org.apache.hadoop.hbase.security.NettyHBaseSaslRpcClientHandler$2.run(NettyHBaseSas
lRpcClientHandler.java:138)
at java.security.AccessController.doPrivileged(Native Method)
at javax.security.auth.Subject.doAs(Subject.java:422)
at
org.apache.hadoop.security.UserGroupInformation.doAs(UserGroupInformation.java:1761)
at
org.apache.hadoop.hbase.security.NettyHBaseSaslRpcClientHandler.channelRead0(NettyH
BaseSaslRpcClientHandler.java:138)
at
org.apache.hadoop.hbase.security.NettyHBaseSaslRpcClientHandler.channelRead0(NettyH
BaseSaslRpcClientHandler.java:42)
at
org.apache.hbase.thirdparty.io.netty.channel.SimpleChannelInboundHandler.channelRea
d(SimpleChannelInboundHandler.java:105)
at
org.apache.hbase.thirdparty.io.netty.channel.AbstractChannelHandlerContext.invokeCh
annelRead(AbstractChannelHandlerContext.java:362)
```

回答

Ranger 界面上 HBase 服务插件的“hbase.rpc.protection”参数值和 HBase 服务端的“hbase.rpc.protection”参数值必须保持一致。

参考 20.1 登录 Ranger 管理界面章节，登录 Ranger 管理界面。

步骤 1 在首页中“HBASE”区域，单击组件插件名称，如 HBase 的  按钮

步骤 2 搜索配置项“hbase.rpc.protection”，修改配置项的 value 值，与 HBase 服务端的“hbase.rpc.protection”的值保持一致。

步骤 3 单击“保存”。

----结束

20.21.5 RangerKMS 鉴权失败，Ranger 管理界面无 KMS 页签

问题

集群安装完成后，无法看到 KMS 对应的鉴权页签。

回答

Ranger 用户同步存在周期，由于策略中缺少对应用户导致页签创建失败。

使用 omm 用户，登录任意一个 RangerKMS 节点后台。

步骤 1 执行如下命令，创建 install 标签：

touch ${BIGDATA_HOME}/tmp/rangerkmsinstallmarker

步骤 2 登录 Manger 管理面，选择“集群 > Ranger > 实例”，重启 RangerKMS 实例。

步骤 3 实例重启后再次刷新 Ranger 管理界面，即可看到对应页签。

----结束

21 使用 Spark/Spark2x

21.1 Spark/Spark2x 服务名称说明

MRS 3.3.0-LTS 及之后的版本中，Spark2x 服务改名为 Spark，服务包含的角色名也有差异，例如 JobHistory2x 变更为 JobHistory。相关涉及服务名称、角色名称的描述和操作请以实际版本为准。

21.2 基本操作

21.2.1 快速入门

本章节提供从零开始使用 Spark2x 提交 spark 应用程序，包括 Spark Core 及 Spark SQL。其中，Spark Core 为 Spark 的内核模块，主要负责任务的执行，用于编写 spark 应用程序；Spark SQL 为执行 SQL 的模块。

场景说明

假定用户有某个周末网民网购停留时间的日志文本，基于某些业务要求，要求开发 Spark 应用程序实现如下要求：

- 统计日志文件中本周末网购停留总时间超过 2 个小时的女性网民信息。
- 周末两天的日志文件第一列为姓名，第二列为性别，第三列为本次停留时间，单位为分钟，分隔符为“,”。

log1.txt：周六网民停留日志

```
LiuYang,female,20
YuanJing,male,10
GuoYijun,male,5
CaiXuyu,female,50
Liyuan,male,20
FangBo,female,50
LiuYang,female,20
YuanJing,male,10
GuoYijun,male,50
```

```
CaiXuyu,female,50
FangBo,female,60
```

log2.txt：周日网民停留日志

```
LiuYang,female,20
YuanJing,male,10
CaiXuyu,female,50
FangBo,female,50
GuoYijun,male,5
CaiXuyu,female,50
Liyuan,male,20
CaiXuyu,female,50
FangBo,female,50
LiuYang,female,20
YuanJing,male,10
FangBo,female,50
GuoYijun,male,50
CaiXuyu,female,50
FangBo,female,60
```

前提条件

- 在 Manager 界面创建用户并开通其 HDFS、YARN、Kafka 和 Hive 权限。
- 根据所用的开发语言安装并配置 IntelliJ IDEA 及 JDK 等工具。
- 已完成 Spark2x 客户端的安装及客户端网络连接的配置。
- 对于 Spark SQL 程序，需要先在客户端启动 Spark SQL 或 Beeline 以输入 SQL 语句。

操作步骤

获取样例工程并将其导入 IDEA，导入样例工程依赖 jar 包。通过 IDEA 配置并生成 jar 包。

步骤 1 准备样例工程所需数据。

将场景说明中的原日志文件放置在 HDFS 系统中。

1. 本地新建两个文本文件，分别将 log1.txt 及 log2.txt 中的内容复制保存到 input_data1.txt 和 input_data2.txt。
2. 在 HDFS 上建立一个文件夹“/tmp/input”，并上传 input_data1.txt、input_data2.txt 到此目录。

步骤 2 将生成的 jar 包上传至 Spark2x 运行环境下（Spark2x 客户端），如“/opt/female”。

步骤 3 进入客户端目录，执行以下命令加载环境变量并登录。若安装了 Spark2x 多实例或者同时安装了 Spark 和 Spark2x，在使用客户端连接具体实例时，请执行以下命令加载具体实例的环境变量。

source bigdata_env

source Spark2x/component_env

kinit <用于认证的业务用户>

步骤 4 在 bin 目录下调用以下脚本提交 Spark 应用程序。

spark-submit --class *com.xxx.bigdata.spark.examples.FemaleInfoCollection* **--master yarn-client** */opt/female/FemaleInfoCollection.jar <inputPath>*

说明

- FemaleInfoCollection.jar 为步骤 1 生成的 jar 包。
- <inputPath>是步骤 2.2 创建的目录。

步骤 5 （可选）在 bin 目录下调用 **spark-sql** 或 **spark-beeline** 脚本后便可直接输入 SQL 语句执行查询等操作。

如创建一个表，插入一条数据再对表进行查询。

```
spark-sql> CREATE TABLE TEST(NAME STRING, AGE INT);
Time taken: 0.348 seconds
spark-sql>INSERT INTO TEST VALUES('Jack', 20);
Time taken: 1.13 seconds
spark-sql> SELECT * FROM TEST;
Jack     20
Time taken: 0.18 seconds, Fetched 1 row(s)
```

步骤 6 查看 Spark 应用运行结果。

- 通过指定文件查看运行结果数据。

  结果数据的存储路径和格式由 Spark 应用程序指定。
- 通过 Web 页面查看运行情况。
  a. 登录 Manager 主页面。在服务中选择 Spark2x。
  b. 进入 Spark2x 概览页面，单击 SparkWebUI 任意一个实例，如 JobHistory2x(host2)。
  c. 进入 History Server 页面。

     History Server 页面用于展示已完成和未完成的应用的运行情况。

     图21-1 History Server 页面

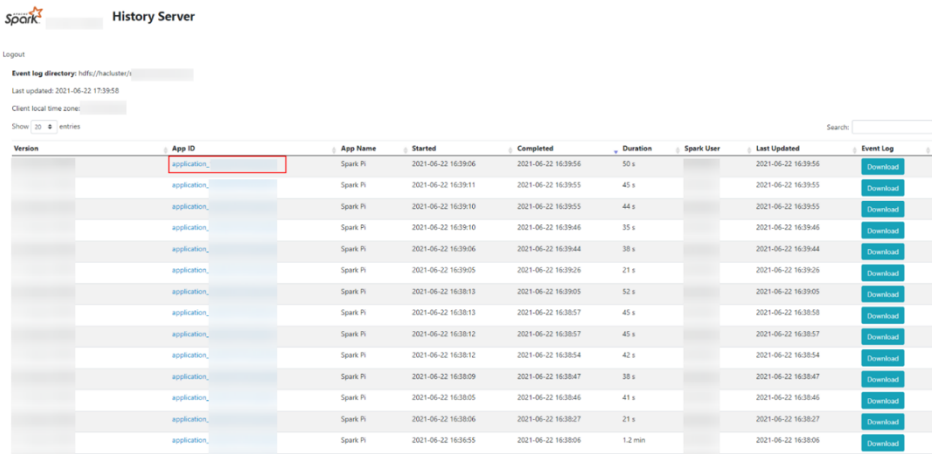

  d. 选择一个应用 ID，单击此页面将跳转到该应用的 Spark UI 页面。

     Spark UI 页面，用于展示正在执行的应用的运行情况。

图21-2 Spark UI 页面

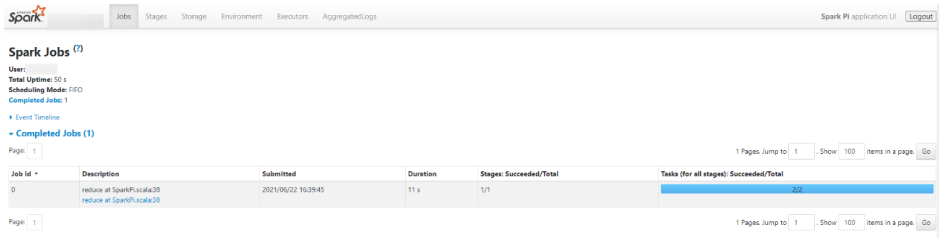

- 通过查看 Spark 日志获取应用运行情况。

  通过查看 21.3 Spark2x 日志介绍了解应用运行情况，并根据日志信息调整应用程序。

----结束

21.2.2 快速配置参数

概述

本节介绍 Spark2x 使用过程中快速配置常用参数和不建议修改的配置参数。

快速配置常用参数

其他参数在安装集群时已进行了适配，以下参数需要根据使用场景进行调整。以下参数除特别指出外，一般在 Spark2x 客户端的“spark-defaults.conf”文件中配置。

表21-1 快速配置常用参数

配置项	说明	默认值
spark.sql.parquet.compression.codec	对于非分区 parquet 表，设置其存储文件的压缩格式。 在 JDBCServer 服务端的“spark-defaults.conf”配置文件中进行设置。	snappy
spark.dynamicAllocation.enabled	是否使用动态资源调度，用于根据规模调整注册于该应用的 executor 的数量。目前仅在 YARN 模式下有效。 JDBCServer 默认值为 true，client 默认值为 false。	false
spark.executor.memory	每个 Executor 进程使用的内存数量，与 JVM 内存设置字符串的格式相同（例如：512m，2g）。	4G
spark.sql.autoBroadcastJoinThreshold	当进行 join 操作时，配置广播的最大值。 • 当 SQL 语句中涉及的表中相应字段的	10485760

配置项	说明	默认值
	大小小于该值时，进行广播。 • 配置为-1 时，将不进行广播。	
spark.yarn.queue	JDBCServer 服务所在的 Yarn 队列。 在 JDBCServer 服务端的“spark-defaults.conf”配置文件中进行设置。	default
spark.driver.memory	大集群下推荐配置 32~64g 驱动程序进程使用的内存数量，即 SparkContext 初始化的进程（例如：512m, 2g）。	4G
spark.yarn.security.credentials.hbase.enabled	是否打开获取 HBase token 的功能。如果需要 Spark-on-HBase 功能，并且配置了安全集群，参数值设置为“true”。否则设置为“false”。	false
spark.serializer	用于串行化将通过网络发送或需要缓存的对象的类以序列化形式展现。 Java 序列化的默认值适用于任何 Serializable Java 对象，但运行速度相当慢，所以建议使用 org.apache.spark.serializer.KryoSerializer 并配置 Kryo 序列化。可以是 org.apache.spark.serializer.Serializer 的任何子类。	org.apache.spark.serializer.JavaSerializer
spark.executor.cores	每个执行者使用的内核个数。 在独立模式和 Mesos 粗粒度模式下设置此参数。当有足够多的内核时，允许应用程序在同样的 worker 上执行多个执行程序；否则，在每个 worker 上，每个应用程序只能运行一个执行程序。	1
spark.shuffle.service.enabled	NodeManager 中一个长期运行的辅助服务，用于提升 Shuffle 计算性能。	fasle
spark.sql.adaptive.enabled	是否开启自适应执行框架。	false
spark.executor.memoryOverhead	每个执行器要分配的堆内存量（单位为兆字节）。 这是占用虚拟机开销的内存，类似于内部字符串，其他内置开销等等。会随着执行器大小（通常为 6-10%）而增长。	1GB
spark.streaming.kafka.direct.lifo	配置是否开启 Kafka 后进先出功能。	false

不建议修改的参数

以下参数在安装集群时已进行了适配，不建议用户进行修改。

表21-2 不建议修改的参数说明

配置项	说明	默认值或配置示例
spark.password.factory	用于选择密钥解析方式。	org.apache.spark.om.util.FIPasswordFactory
spark.ssl.ui.protocol	配置 ui 的 ssl 协议。	TLSv1.2
spark.yarn.archive	Spark jars 的存档，用于分发到 YARN 缓存。如果设置，此配置值将替换<code> spark.yarn.jars </code>，并存档在所有应用程序的容器中使用。存档应包含其根目录中的 jar 文件。与以前的选项一样，存档也可以在 HDFS 上托管，用来加快文件分发速度。	hdfs://hacluster/user/spark2x/jars/xxx/spark-archive-2x.zip 说明 此处版本号 xxx 为示例，具体以实际环境的版本号为准。
spark.yarn.am.extraJavaOptions	在 Client 模式下传递至 YARN Application Master 的一系列额外 JVM 选项。在 Cluster 模式下使用“spark.driver.extraJavaOptions”。	-Dlog4j.configuration=./__spark_conf__/__hadoop_conf__/log4j-executor.properties -Djava.security.auth.login.config=./__spark_conf__/__hadoop_conf__/jaas-zk.conf -Dzookeeper.server.principal=zookeeper/hadoop.*<系统域名>* -Djava.security.krb5.conf=./__spark_conf__/__hadoop_conf__/kdc.conf -Djdk.tls.ephemeralDHKeySize=2048
spark.shuffle.servicev2.port	Shuffle 服务监测数据获取请求的端口。	27338
spark.ssl.historyServer.enabled	配置 history server 是否使用 SSL。	true
spark.files.overwrite	当目标文件存在时，且其内容与源的文件不匹配。是否覆盖通过 SparkContext.addFile()添加的文件。	false
spark.yarn.clus	YARN-Cluster 模式	${BIGDATA_HOME}/common/runtime/securit

配置项	说明	默认值或配置示例
ter.driver.extraClassPath	下，Driver 使用的 extraClassPath，配置为服务端的路径和参数。	y
spark.driver.extraClassPath	附加至 driver 的 classpath 的额外 classpath 条目。	${BIGDATA_HOME}/common/runtime/security
spark.yarn.dist.innerfiles	配置 YARN 模式下 Spark 内部需要上传到 HDFS 的文件。	/Spark_path/spark/conf/s3p.file,/Spark_path/spark/conf/locals3.jceks *Spark_path* 为 Spark 客户端的安装路径。
spark.sql.bigdata.register.dialect	用于注册 sql 解析器。	org.apache.spark.sql.hbase.HBaseSQLParser
spark.shuffle.manager	处理数据的方式。有两种实现方式可用：sort 和 hash。sort shuffle 对内存的使用率更高，是 Spark 1.2 及后续版本的默认选项。	SORT
spark.deploy.zookeeper.url	Zookeeper 的地址，多个地址以逗号隔开。	For example: host1:2181,host2:2181,host3:2181
spark.broadcast.factory	使用的广播方式。	org.apache.spark.broadcast.TorrentBroadcastFactory
spark.sql.session.state.builder	指定会话状态构造器。	org.apache.spark.sql.hive.FIHiveACLSessionStateBuilder
spark.executor.extraLibraryPath	设置启动 executor JVM 时所使用的特殊的 library path。	${BIGDATA_HOME}/FusionInsight_HD_xxx/install/FusionInsight-Hadoop-*/hadoop/lib/native
spark.ui.customErrorPage	配置网页有错误时是否允许显示自定义的错误信息页面。	true
spark.httpdProxy.enable	配置是否使用 httpd 代理。	true
spark.ssl.ui.enabledAlgorithms	配置 ui ssl 算法。	TLS_ECDHE_ECDSA_WITH_AES_256_GCM_SHA384,TLS_ECDHE_RSA_WITH_AES_256_GCM_SHA384,TLS_ECDHE_ECDSA_WITH_AES_128_GCM_SHA256,TLS_ECDHE_RSA_WITH_AES_128_GCM_SHA256,TLS_DHE_RSA_WITH_AES_256_GCM_SHA384,TL

配置项	说明	默认值或配置示例
		S_DHE_DSS_WITH_AES_256_GCM_SHA384,TLS_DHE_RSA_WITH_AES_128_GCM_SHA256,TLS_DHE_DSS_WITH_AES_128_GCM_SHA256
spark.ui.logout.enabled	针对 Spark 组件的 WebUI，设置 logout 按钮。	true
spark.security.hideInfo.enabled	配置 UI 界面是否隐藏敏感信息。	true
spark.yarn.cluster.driver.extraLibraryPath	YARN-Cluster 模式下 driver 的 extraLibraryPath，配置成服务端的路径和参数。	${BIGDATA_HOME}/FusionInsight_HD_xxx/install/FusionInsight-Hadoop-*/hadoop/lib/native
spark.driver.extraLibraryPath	设置一个特殊的 library path 在启动驱动程序 JVM 时使用。	${DATA_NODE_INSTALL_HOME}/hadoop/lib/native
spark.ui.killEnabled	允许停止 Web UI 中的 stage 和相应的 job。	true
spark.yarn.access.hadoopFileSystems	Spark 可以访问多个 NameService。有多个 NameService 时，需要把所使用的 NameService 都配置进该配置项，之间以逗号分隔。	hdfs://hacluster,hdfs://hacluster
spark.yarn.cluster.driver.extraJavaOptions	传递至 Executor 的额外 JVM 选项。例如，GC 设置或其他日志记录。请注意不能通过此选项设置 Spark 属性或 heap 大小。Spark 属性应该使用 SparkConf 对象或调用 spark-submit 脚本时指定的 spark-defaults.conf 文件来设置。Heap 大小可以通过 spark.executor.memor	-Xloggc:<LOG_DIR>/gc.log -XX:+PrintGCDetails -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=20 -XX:GCLogFileSize=10M -Dlog4j.configuration=./__spark_conf__/__hadoop_conf__/log4j-executor.properties -Djava.security.auth.login.config=./__spark_conf__/__hadoop_conf__/jaas-zk.conf -Dzookeeper.server.principal=zookeeper/hadoop.*<系统域名>* -Djava.security.krb5.conf=./__spark_conf__/__hadoop_conf__/kdc.conf -Djetty.version=x.y.z -

配置项	说明	默认值或配置示例
	y 来设置。	Dorg.xerial.snappy.tempdir=${BIGDATA_HOME}/tmp/spark2x_app -Dcarbon.properties.filepath=./__spark_conf__/__hadoop_conf__/carbon.properties -Djdk.tls.ephemeralDHKeySize=2048
spark.driver.extraJavaOptions	传递至 driver（驱动程序）的一系列额外 JVM 选项。	-Xloggc:${SPARK_LOG_DIR}/indexserver-omm-%p-gc.log -XX:+PrintGCDetails -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:MaxDirectMemorySize=512M -XX:MaxMetaspaceSize=512M -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=20 -XX:GCLogFileSize=10M -XX:OnOutOfMemoryError='kill -9 %p' -Djetty.version=x.y.z -Dorg.xerial.snappy.tempdir=${BIGDATA_HOME}/tmp/spark2x/JDBCServer/snappy_tmp -Djava.io.tmpdir=${BIGDATA_HOME}/tmp/spark2x/JDBCServer/io_tmp -Dcarbon.properties.filepath=${SPARK_CONF_DIR}/carbon.properties -Djdk.tls.ephemeralDHKeySize=2048 -Dspark.ssl.keyStore=${SPARK_CONF_DIR}/child.keystore #{java_stack_prefer}
spark.eventLog.overwrite	是否覆盖任何现有的文件。	false
spark.eventLog.dir	如果 **spark.eventLog.enabled** 为 **true**，记录 Spark 事件的目录。在此目录下，Spark 为每个应用程序创建文件，并将应用程序的事件记录到文件中。用户也可设置为统一的与 HDFS 目录相似的地址，这样 History server 就可以读取历史文件。	hdfs://hacluster/spark2xJobHistory2x
spark.random.port.min	设置随机端口的最小值。	22600
spark.authenticate	是否 Spark 认证其内部连接。如果不是运行在 YARN 上，请参见	true

配置项	说明	默认值或配置示例
	spark.authenticate.secret 的相关内容。	
spark.random.port.max	设置随机端口的最大值。	22899
spark.eventLog.enabled	是否记录 Spark 事件，用于应用程序在完成后重构 webUI。	true
spark.executor.extraJavaOptions	传递至 Executor 的额外 JVM 选项。例如，GC 设置或其他日志记录。请注意不能通过此选项设置 Spark 属性或 heap 大小。	-Xloggc:<LOG_DIR>/gc.log -XX:+PrintGCDetails -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=20 -XX:GCLogFileSize=10M -Dlog4j.configuration=./log4j-executor.properties -Djava.security.auth.login.config=./jaas-zk.conf -Dzookeeper.server.principal=zookeeper/hadoop.*<系统域名>* -Djava.security.krb5.conf=./kdc.conf -Dcarbon.properties.filepath=./carbon.properties -Xloggc:<LOG_DIR>/gc.log -XX:+PrintGCDetails -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=20 -XX:GCLogFileSize=10M -Dlog4j.configuration=./__spark_conf__/__hadoop_conf__/log4j-executor.properties -Djava.security.auth.login.config=./__spark_conf__/__hadoop_conf__/jaas-zk.conf -Dzookeeper.server.principal=zookeeper/hadoop.*<系统域名>* -Djava.security.krb5.conf=./__spark_conf__/__hadoop_conf__/kdc.conf -Dcarbon.properties.filepath=./__spark_conf__/__hadoop_conf__/carbon.properties -Djdk.tls.ephemeralDHKeySize=2048
spark.sql.authorization.enabled	配置 Hive client 是否开启认证。	true

21.2.3 常用参数

概述

本节介绍 Spark 使用过程中的常用配置项。以特性为基础划分子章节，以便用户快速搜索到相应的配置项。如果用户使用 MRS 集群，本节介绍的参数大部分已经适配好，用户无需再进行配置。少数需要用户根据实际场景配置的参数，请参见 21.2.2 快速配置参数。

配置 Stage 失败重试次数

Spark 任务在遇到 FetchFailedException 时会触发 Stage 重试。为了防止 Stage 无限重试，对 Stage 重试次数进行限制。重试次数可以根据实际需要进行调整。

在 Spark 客户端的“spark-defaults.conf”文件中配置如下参数。

表21-3 参数说明

参数	说明	默认值
spark.stage.maxConsecutiveAttempts	Stage 失败重试最大次数。	4

配置是否使用笛卡尔积功能

要启动使用笛卡尔积功能，需要在 Spark 的“spark-defaults.conf”配置文件中进行如下设置。

表21-4 笛卡尔积参数说明

参数	说明	默认值
spark.sql.crossJoin.enabled	是否允许隐性执行笛卡尔积。 • “true”表示允许 • “false”表示不允许，此时只允许query 中显式包含 CROSS JOIN 语法。	true

说明

- JDBC 应用在服务端的“spark-defaults.conf”配置文件中设置该参数。
- Spark 客户端提交的任务在客户端配的“spark-defaults.conf”配置文件中设置该参数。

Spark 长时间任务安全认证配置

安全模式下，使用 Spark CLI（如 spark shell、spark sql、spark submit）时，如果使用 kinit 命令进行安全认证，当执行长时间运行任务时，会因为认证过期导致任务失败。

在客户端的“spark-defaults.conf”配置文件中设置如下参数，配置完成后，重新执行Spark CLI 即可。

说明

当参数值为“true”时，需要保证“spark-defaults.conf”和“hive-site.xml”中的 Keytab 和 principal 的值相同。

表21-5 参数说明

参数名称	含义	默认值
spark.kerberos.principal	具有 Spark 操作权限的 principal。请联系 MRS 集群管理员获取对应 principal。	-
spark.kerberos.keytab	具有 Spark 操作权限的 Keytab 文件名称和文件路径。请联系 MRS 集群管理员获取对应 Keytab 文件。	-
spark.security.bigdata.loginOnce	Principal 用户是否只登录一次。true 为单次登录；false 为多次登录。 单次登录与多次登录的区别在于：Spark 社区使用多次 Kerberos 用户登录多次的方案，但容易出现 TGT 过期或者 Token 过期异常导致应用无法长时间运行。DataSight 修改了 Kerberos 登录方式，只允许用户登录一次，可以有效的解决过期问题。限制在于，Hive 相关的 principal 与 keytab 的配置项必须与 Spark 配置相同。 说明 当参数值为 true 时，需要保证“spark-defaults.conf”和“hive-site.xml”中的 Keytab 和 principal 的值相同。	true

Python Spark

Python Spark 是 Spark 除了 Scala、Java 两种 API 之外的第三种编程语言。不同于 Java 和 Scala 都是在 JVM 平台上运行，Python Spark 不仅会有 JVM 进程，还会有自身的 Python 进程。以下配置项只适用于 Python Spark 场景，而其他配置项也同样可以在 Python Spark 中生效。

表21-6 参数说明

参数	描述	默认值
spark.python.profile	在 Python worker 中开启 profiling。通过 sc.show_profiles()展示分析结果。或者在 driver 退出前展示分析结果。可以通过 sc.dump_profiles(path) 将结果转储到磁盘中。如果一些分析结果已经手动展示，那么在 Driver 退出前，它们将不会再自动展示。	false

参数	描述	默认值
	默认使用 pyspark.profiler.BasicProfiler，可以在初始化 SparkContext 时传入指定的 profiler 来覆盖默认的 profiler。	
spark.python.worker.memory	聚合过程中每个 python worker 进程所能使用的内存大小，其值格式同指定 JVM 内存一致，如 512m，2g。如果进程在聚集期间所用的内存超过了该值，数据将会被写入磁盘。	512m
spark.python.worker.reuse	是否重用 python worker。如是，它将使用固定数量的 Python workers，那么下一批提交的 task 将重用这些 Python workers，而不是为每个 task 重新 fork 一个 Python 进程。 该功能在大型广播下非常有用，因为此时对下一批提交的 task 不需要将数据从 JVM 再一次传输至 Python worker。	true

Dynamic Allocation

动态资源调度是 On Yarn 模式特有的特性，并且必须开启 Yarn External Shuffle 才能使用这个功能。在使用 Spark 作为一个常驻的服务时候，动态资源调度将大大的提高资源的利用率。例如 JDBCServer 服务，大多数时间该进程并不接受 JDBC 请求，因此将这段空闲时间的资源释放出来，将极大的节约集群的资源。

表21-7 参数说明

参数	描述	默认值
spark.dynamicAllocation.enabled	是否使用动态资源调度，用于根据规模调整注册于该应用的 executor 的数量。注意目前仅在 YARN 模式下有效。 启用动态资源调度必须将 spark.shuffle.service.enabled 设置为 true。以下配置也与此相关： spark.dynamicAllocation.minExecutors、spark.dynamicAllocation.maxExecutors 和 spark.dynamicAllocation.initialExecutors。	• JDBCServer2x：true • SparkResource2x：false
spark.dynamicAllocation.minExecutors	最小 Executor 个数。	0
spark.dynamicAllocation.initialExecutors	初始 Executor 个数。	spark.dynamicAllocation.minExecutors
spark.dynamicAllocation.maxExecutors	最大 executor 个数。	2048

参数	描述	默认值
spark.dynamicAllocation.schedulerBacklogTimeout	调度第一次超时时间。单位为秒。	1s
spark.dynamicAllocation.sustainedSchedulerBacklogTimeout	调度第二次及之后超时时间。	1s
spark.dynamicAllocation.executorIdleTimeout	普通 Executor 空闲超时时间。单位为秒。	60
spark.dynamicAllocation.cachedExecutorIdleTimeout	含有 cached blocks 的 Executor 空闲超时时间。	• JDBCServer2x：2147483647s • IndexServer2x：2147483647s • SparkResource2x：120

Spark Streaming

Spark Streaming 是在 Spark 批处理平台提供的流式数据的处理能力，以“mini-batch”的方式处理从外部输入的数据。

在 Spark 客户端的“spark-defaults.conf”文件中配置如下参数。

表21-8 参数说明

参数	描述	默认值
spark.streaming.receiver.writeAheadLog.enable	启用预写日志（WAL）功能。所有通过 Receiver 接收的输入数据将被保存至预写日志，预写日志可以保证 Driver 程序出错后数据可以恢复。	false
spark.streaming.unpersist	由 Spark Streaming 产生和保存的 RDDs 自动从 Spark 的内存中强制移除。Spark Streaming 接收的原始输入数据也将自动清除。设置为 false 时原始输入数据和存留的 RDDs 不会自动清除，因此在 streaming 应用外部依然可以访问，但是这会占用更多的 Spark 内存。	true

Spark Streaming Kafka

Receiver 是 Spark Streaming 一个重要的组成部分，它负责接收外部数据，并将数据封装为 Block，提供给 Streaming 消费。最常见的数据源是 Kafka，Spark Streaming 对 Kafka 的集成也是最完善的，不仅有可靠性的保障，而且也支持从 Kafka 直接作为 RDD 输入。

表21-9 参数说明

参数	描述	默认值
spark.streaming.kafka.maxRatePerPartition	使用 Kafka direct stream API 时，从每个 Kafka 分区读取数据的最大速率（每秒记录数量）。	-
spark.streaming.blockInterval	在被存入 Spark 之前 Spark Streaming Receiver 接收数据累积成数据块的间隔（毫秒）。推荐最小值为 50 毫秒。	200ms
spark.streaming.receiver.maxRate	每个 Receiver 接收数据的最大速率（每秒记录数量）。配置设置为 0 或者负值将不会对速率设限。	-
spark.streaming.receiver.writeAheadLog.enable	是否使用 ReliableKafkaReceiver。该 Receiver 支持流式数据不丢失。	false

Netty/NIO 及 Hash/Sort 配置

Shuffle 是大数据处理中最重要的一个性能点，网络是整个 Shuffle 过程的性能点。目前 Spark 支持两种 Shuffle 方式，一种是 Hash，另外一种是 Sort。网络也有两种方式，Netty 和 NIO。

表21-10 参数说明

参数	描述	默认值
spark.shuffle.manager	处理数据的方式。有两种实现方式可用：sort 和 hash。sort shuffle 对内存的使用率更高，是 Spark 1.2 及后续版本的默认选项。	SORT
spark.shuffle.consolidateFiles	（仅 hash 方式）若要合并在 shuffle 过程中创建的中间文件，需要将该值设置为“true”。文件创建的少可以提高文件系统处理性能，降低风险。使用 ext4 或者 xfs 文件系统时，建议设置为“true”。由于文件系统限制，在 ext3 上该设置可能会降低 8 核以上机器的处理性能。	false
spark.shuffle.sort.bypassMergeThreshold	该参数只适用于 spark.shuffle.manager 设置为 sort 时。在不做 map 端聚合并且 reduce 任务的 partition 数小于或等于该值时，避免对数据进行归并排序，防止系统处理不必要的排序引起性能下	200

参数	描述	默认值
	降。	
spark.shuffle.io.maxRetries	（仅 Netty 方式）如果设为非零值，由于 IO 相关的异常导致的 fetch 失败会自动重试。该重试逻辑有助于大型 shuffle 在发生长 GC 暂停或者网络闪断时保持稳定。	12
spark.shuffle.io.numConnectionsPerPeer	（仅 Netty 方式）为了减少大型集群的连接创建，主机间的连接会被重新使用。对于拥有较多硬盘和少数主机的集群，此操作可能会导致并发性不足以占用所有磁盘，所以用户可以考虑增加此值。	1
spark.shuffle.io.preferDirectBufs	（仅 Netty 方式）使用 off-heap 缓冲区减少 shuffle 和高速缓存块转移期间的垃圾回收。对于 off-heap 内存被严格限制的环境，用户可以将其关闭以强制所有来自 Netty 的申请使用堆内内存。	true
spark.shuffle.io.retryWait	（仅 Netty 方式）等待 fetch 重试期间的时间（秒）。重试引起的最大延迟为 maxRetries * retryWait，默认是 15 秒。	5

普通 Shuffle 配置

表21-11 参数说明

参数	描述	默认值
spark.shuffle.spill	若设为“true”，通过将数据溢出至磁盘来限制 reduce 任务期间内存的使用量。	true
spark.shuffle.spill.compress	是否压缩 shuffle 期间溢出的数据。使用 spark.io.compression.codec 指定的算法进行数据压缩。	true
spark.shuffle.file.buffer	每个 shuffle 文件输出流的内存缓冲区大小（单位：KB）。这些缓冲区可以减少创建中间 shuffle 文件流过程中产生的磁盘寻道和系统调用次数。也可以通过配置项 spark.shuffle.file.buffer.kb 设置。	32KB
spark.shuffle.compress	是否压缩 map 任务输出文件。建议压缩。使用 spark.io.compression.codec 进行压缩。	true
spark.reducer.maxSizeInFlight	从每个 reduce 任务同时 fetch 的 map 任务输出最大值（单位：MB）。由于每个输出要求创建一个缓冲区进行接收，这代表了每个 reduce 任务固定的内存开销，所以除非拥有大量内存，否则保	48MB

参数	描述	默认值
	持低值。也可以通过配置项 spark.reducer.maxMbInFlight 设置。	

Driver 配置

Spark Driver 可以理解为 Spark 提交应用的客户端，所有的代码解析工作都在这个进程中完成，因此该进程的参数尤其重要。下面将以如下顺序介绍 Spark 中进程的参数设置：

- JavaOptions：Java 命令中“-D”后面的参数，可以由 System.getProperty 获取。
- ClassPath：包括 Java 类和 Native 的 Lib 加载路径。
- Java Memory and Cores：Java 进程的内存和 CPU 使用量。
- Spark Configuration：Spark 内部参数，与 Java 进程无关。

表21-12 参数说明

参数	描述	默认值
spark.driver.extraJavaOptions	传递至 driver（驱动程序）的一系列额外 JVM 选项。例如，GC 设置或其他日志记录。 注意：在 Client 模式中，该配置禁止直接在应用程序中通过 SparkConf 设置，因为驱动程序 JVM 已经启动。请通过--driver-java-options 命令行选项或默认 property 文件进行设置。	参考 21.2.2 快速配置参数
spark.driver.extraClassPath	附加至 driver 的 classpath 的额外 classpath 条目。 注意：在 Client 模式中，该配置禁止直接在应用程序中通过 SparkConf 设置，因为驱动程序 JVM 已经启动。请通过--driver-java-options 命令行选项或默认 property 文件进行设置。	参考 21.2.2 快速配置参数
spark.driver.userClassPathFirst	（试验性）当在驱动程序中加载类时，是否授权用户添加的 jar 优先于 Spark 自身的 jar。这种特性可用于减缓 Spark 依赖和用户依赖之间的冲突。目前该特性仍处于试验阶段，仅用于 Cluster 模式中。	false
spark.driver.extraLibraryPath	设置一个特殊的 library path 在启动驱动程序 JVM 时使用。 注意：在 Client 模式中，该配置禁止直接在应用程序中通过 SparkConf 设置，因为驱动程序 JVM 已经启动。请通过--driver-java-options 命令行选项或默认 property 文件进行设置。	• JDBCServer2x： ${SPARK_INSTALL_HOME}/spark/native • SparkResource2x：

参数	描述	默认值
		${DATA_NODE_INSTALL_HOME}/hadoop/lib/native
spark.driver.cores	驱动程序进程使用的核数。仅适用于 Cluster 模式。	1
spark.driver.memory	驱动程序进程使用的内存数量，即 SparkContext 初始化的进程（例如：512M, 2G）。 注意：在 Client 模式中，该配置禁止直接在应用程序中通过 SparkConf 设置，因为驱动程序 JVM 已经启动。请通过--driver-java-options 命令行选项或默认 property 文件进行设置。	4G
spark.driver.maxResultSize	对每个 Spark action 操作（例如“collect”）的所有分区序列化结果的总量限制，至少 1M，设置成 0 表示不限制。如果总量超过该限制，工作任务会中止。限制值设置过高可能会引起驱动程序的内存不足错误（取决于 spark.driver.memory 和 JVM 的对象内存开销）。设置合理的限制可以避免驱动程序出现内存不足的错误。	1G
spark.driver.host	Driver 监测的主机名或 IP 地址，用于 Driver 与 Executor 进行通信。	(local hostname)
spark.driver.port	Driver 监测的端口，用于 Driver 与 Executor 进行通信。	(random)

ExecutorLaucher 配置

ExecutorLauncher 只有在 Yarn-Client 模式下才会存在的角色，Yarn-Client 模式下，ExecutorLauncher 和 Driver 不在同一个进程中，需要对 ExecutorLauncher 的参数进行特殊的配置。

表21-13 参数说明

参数	描述	默认值
spark.yarn.am.extraJavaOptions	在 Client 模式下传递至 YARN Application Master 的一系列额外 JVM 选项。在 Cluster 模式下使用 spark.driver.extraJavaOptions。	参考 21.2.2 快速配置参数

参数	描述	默认值
spark.yarn.am.memory	针对 Client 模式下 YARN Application Master 使用的内存数量，与 JVM 内存设置字符串格式一致（例如：512m，2g）。在集群模式下，使用 spark.driver.memory。	1G
spark.yarn.am.memoryOverhead	和“spark.yarn.driver.memoryOverhead”一样，但只针对 Client 模式下的 Application Master。	-
spark.yarn.am.cores	针对 Client 模式下 YARN Application Master 使用的核数。在 Cluster 模式下，使用 spark.driver.cores。	1

Executor 配置

Executor 也是单独一个 Java 进程，但不像 Driver 和 AM 只有一个，Executor 可以有多个进程，而目前 Spark 只支持相同的配置，即所有 Executor 的进程参数都必然是一样的。

表21-14 参数说明

参数	描述	默认值
spark.executor.extraJavaOptions	传递至 Executor 的额外 JVM 选项。例如，GC 设置或其他日志记录。请注意不能通过此选项设置 Spark 属性或 heap 大小。Spark 属性应该使用 SparkConf 对象或调用 spark-submit 脚本时指定的 spark-defaults.conf 文件来设置。Heap 大小可以通过 spark.executor.memory 来设置。	参考 21.2.2 快速配置参数
spark.executor.extraClassPath	附加至 Executor classpath 的额外的 classpath。这主要是为了向后兼容 Spark 的历史版本。用户一般不用设置此选项。	-
spark.executor.extraLibraryPath	设置启动 executor JVM 时所使用的特殊的 library path。	参考 21.2.2 快速配置参数
spark.executor.userClassPathFirst	（试验性）与 spark.driver.userClassPathFirst 相同的功能，但应用于 Executor 实例。	false
spark.executor.memory	每个 Executor 进程使用的内存数量，与 JVM 内存设置字符串的格式相同（例如：512M，2G）。	4G
spark.executorEnv.[EnvironmentVariableName]	添加由 EnvironmentVariableName 指定的环境变量至 executor 进程。用户可以指定多个来设置多个环境变量。	-

参数	描述	默认值
spark.executor.logs.rolling.maxRetainedFiles	设置系统即将保留的最新滚动日志文件的数量。旧的日志文件将被删除。默认关闭。	-
spark.executor.logs.rolling.size.maxBytes	设置滚动 Executor 日志的文件的最大值。默认关闭。数值以字节为单位设置。若要自动清除旧日志，请查看 spark.executor.logs.rolling.maxRetainedFiles。	-
spark.executor.logs.rolling.strategy	设置 executor 日志的滚动策略。默认滚动关闭。可以设置为“time”（基于时间的滚动）或“size”（基于大小的滚动）。当设置为“time”，使用 spark.executor.logs.rolling.time.interval 属性的值作为日志滚动的间隔。当设置为“size”，使用 spark.executor.logs.rolling.size.maxBytes 设置滚动的最大文件大小滚动。	-
spark.executor.logs.rolling.time.interval	设置 executor 日志滚动的时间间隔。默认关闭。合法值为“daily”、“hourly”、“minutely”或任意秒。若要自动清除旧日志，请查看 spark.executor.logs.rolling.maxRetainedFiles。	daily

WebUI

WebUI 展示了 Spark 应用运行的过程和状态。

表21-15 参数说明

参数	描述	默认值
spark.ui.killEnabled	允许停止 Web UI 中的 stage 和相应的 job。 说明 出于安全考虑，将此配置项的默认值设置成 false，以避免用户发生误操作。如果需要开启此功能，则可以在 spark-defaults.conf 配置文件中将此配置项的值设为 true。请谨慎操作。	true
spark.ui.port	应用程序 dashboard 的端口，显示内存和工作量数据。	• JDBCServer2x：4040 • SparkResource2x：0 • IndexServer2x：

参数	描述	默认值
		22901
spark.ui.retainedJobs	在垃圾回收之前 Spark UI 和状态 API 记住的 job 数。	1000
spark.ui.retainedStages	在垃圾回收之前 Spark UI 和状态 API 记住的 stage 数。	1000

HistoryServer

HistoryServer 读取文件系统中的 EventLog 文件，展示已经运行完成的 Spark 应用在运行时的状态信息。

表21-16 参数说明

参数	描述	默认值
spark.history.fs.logDirectory	History server 的日志目录	-
spark.history.ui.port	JobHistory 侦听连接的端口。	18080
spark.history.fs.updateInterval	History server 所显示信息的更新周期，单位为秒。每次更新检查持久存储中针对事件日志进行的更改。	10s
spark.history.fs.update.interval.seconds	每个事件日志更新检查的间隔。与 spark.history.fs.updateInterval 功能相同，推荐使用 spark.history.fs.updateInterval。	10s
spark.history.updateInterval	该配置项与 spark.history.fs.update.interval.seconds 和 spark.history.fs.updateInterval 功能相同，推荐使用 spark.history.fs.updateInterval。	10s

HistoryServer UI 超时和最大访问数

表21-17 参数说明

参数	描述	默认值
spark.session.maxAge	设置会话的超时时间，单位秒。此参数只适用于安全模式。普通模式下，无法设置此参数。	600
spark.connection.maxRequest	设置客户端访问 Jobhistory 的最大并发数量。	5000

EventLog

Spark 应用在运行过程中，实时将运行状态以 JSON 格式写入文件系统，用于 HistoryServer 服务读取并重现应用运行时状态。

表21-18 参数说明

参数	描述	默认值
spark.eventLog.enabled	是否记录 Spark 事件，用于应用程序在完成后重构 webUI。	true
spark.eventLog.dir	如果 **spark.eventLog.enabled** 为 **true**，记录 Spark 事件的目录。在此目录下，Spark 为每个应用程序创建文件，并将应用程序的事件记录到文件中。用户也可设置为统一的与 HDFS 目录相似的地址，这样 History server 就可以读取历史文件。	hdfs://hacluster/spark2xJobHistory2x
spark.eventLog.compress	spark.eventLog.enabled 为 true 时，是否压缩记录的事件。	false

EventLog 的周期清理

JobHistory 上的 Event log 是随每次任务的提交而累积的，任务提交的次数多了之后会造成太多文件的存放。Spark 提供了周期清理 Evnet log 的功能，用户可以通过配置开关和相应的清理周期参数来进行控制。

表21-19 参数说明

参数	描述	默认值
spark.history.fs.cleaner.enabled	是否打开清理功能。	true
spark.history.fs.cleaner.interval	清理功能的检查周期。	1d
spark.history.fs.cleaner.maxAge	日志的最长保留时间。	4d

Kryo

Kryo 是一个非常高效的 Java 序列化框架，Spark 中也默认集成了该框架。几乎所有的 Spark 性能调优都离不开将 Spark 默认的序列化器转化为 Kryo 序列化器的过程。目前 Kryo 序列化只支持 Spark 数据层面的序列化，还不支持闭包的序列化。设置 Kryo 序列元，需要将配置项“spark.serializer”设置为

“org.apache.spark.serializer.KryoSerializer”，同时也搭配设置以下的配置项，优化 Kryo 序列化的性能。

表21-20 参数说明

参数	描述	默认值
spark.kryo.classesToRegister	使用 Kryo 序列化时，需要注册到 Kryo 的类名，多个类之间用逗号分隔。	-
spark.kryo.referenceTracking	当使用 Kryo 序列化数据时，是否跟踪对同一个对象的引用情况。适用于对象图有循环引用或同一对象有多个副本的情况。否则可以设置为关闭以提升性能。	true
spark.kryo.registrationRequired	是否需要使用 Kryo 来注册对象。当设为“true”时，如果序列化一个未使用 Kryo 注册的对象则会抛出异常。当设为“false”（默认值）时，Kryo 会将未注册的类名称一同写到序列化对象中。该操作会带来大量性能开销，所以在用户还没有从注册队列中删除相应的类时应该开启该选项。	false
spark.kryo.registrator	如果使用 Kryo 序列化，使用 Kryo 将该类注册至定制类。如果需要以定制方式注册类，例如指定一个自定义字段序列化器，可使用该属性。否则 spark.kryo.classesToRegister 会更简单。它应该设置为一个扩展 KryoRegistrator 的类。	-
spark.kryoserializer.buffer.max	Kryo 序列化缓冲区允许的最大值，单位为兆字节。这个值必须大于尝试序列化的对象。当在 Kryo 中遇到“buffer limit exceeded”异常时可以适当增大该值。也可以通过配置项 spark.kryoserializer.buffer.max 配置。	64MB
spark.kryoserializer.buffer	Kryo 序列化缓冲区的初始值，单位为兆字节。每个 worker 的每个核心都会有一个缓冲区。如果有需要，缓冲区会增大到 spark.kryoserializer.buffer.max 设置的值。也可以通过配置项 spark.kryoserializer.buffer 配置。	64KB

Broadcast

Broadcast 用于 Spark 进程间数据块的传输。Spark 中无论 Jar 包、文件还是闭包以及返回的结果都会使用 Broadcast。目前的 Broadcast 支持两种方式，Torrent 与 HTTP。前者将会把数据切成小片，分布到集群中，有需要时从远程获取；后者将文件存入到本地磁盘，有需要时通过 HTTP 方式将整个文件传输到远端。前者稳定性优于后者，因此 Torrent 为默认的 Broadcast 方式。

表21-21 参数说明

参数	描述	默认值
spark.broadcast.factory	使用的广播方式。	org.apache.spark.broadcast.TorrentBroadcastFactory
spark.broadcast.blockSize	TorrentBroadcastFactory 的块大小。该值过大会降低广播时的并行度（速度变慢），过小可能会影响 BlockManager 的性能。	4096
spark.broadcast.compress	在发送广播变量之前是否压缩。建议压缩。	true

Storage

内存计算是 Spark 的最大亮点，Spark 的 Storage 主要管理内存资源。Storage 中主要存储 RDD 在 Cache 过程中产生的数据块。JVM 中堆内存是整体的，因此在 Spark 的 Storage 管理中，“Storage Memory Size”变成了一个非常重要的概念。

表21-22 参数说明

参数	描述	默认值
spark.storage.memoryMapThreshold	超过该块大小的 Block，Spark 会对该磁盘文件进行内存映射。这可以防止 Spark 在内存映射时映射过小的块。一般情况下，对接近或低于操作系统的页大小的块进行内存映射会有高开销。	2m

PORT

表21-23 参数说明

参数	描述	默认值
spark.ui.port	应用仪表盘的端口，显示内存和工作负载数据。	• JDBCServer2x：4040 • SparkResource2x：0
spark.blockManager.	所有 BlockManager 监测的端口。这些同时存在于	随机端

参数	描述	默认值
port	Driver 和 Executor 上。	口范围
spark.driver.port	Driver 监测的端口，用于 Driver 与 Executor 进行通信。	随机端口范围

随机端口范围

所有随机端口必须在一定端口范围内。

表21-24 参数说明

参数	描述	默认值
spark.random.port.min	设置随机端口的最小值。	22600
spark.random.port.max	设置随机端口的最大值。	22899

TIMEOUT

Spark 默认配置能很好的处理中等数据规模的计算任务，但一旦数据量过大，会经常出现超时导致任务失败的场景。在大数据量场景下，需调大 Spark 中的超时参数。

表21-25 参数说明

参数	描述	默认值
spark.files.fetchTimeout	获取通过驱动程序的 SparkContext.addFile()添加的文件时的通信超时（秒）。	60s
spark.network.timeout	所有网络交互的默认超时（秒）。如未配置，则使用该配置代替 spark.core.connection.ack.wait.timeout, spark.akka.timeout, spark.storage.blockManagerSlaveTimeoutMs 或 spark.shuffle.io.connectionTimeout。	360s
spark.core.connection.ack.wait.timeout	连接时应答的超时时间（单位：秒）。为了避免由于 GC 带来的长时间等待，可以设置更大的值。	60

加密

Spark 支持 Akka 和 HTTP（广播和文件服务器）协议的 SSL，但 WebUI 和块转移服务仍不支持 SSL。

SSL 必须在每个节点上配置，并使用特殊协议为通信涉及到的每个组件进行配置。

表21-26 参数说明

参数	描述	默认值
spark.ssl.enabled	是否在所有被支持协议上开启 SSL 连接。 与 spark.ssl.xxx 类似的所有 SSL 设置指示了所有被支持协议的全局配置。为了覆盖特殊协议的全局配置，在协议指定的命名空间中必须重写属性。 使用“spark.ssl.YYY.XXX”设置覆盖由 YYY 指示的特殊协议的全局配置。目前 YYY 可以是基于 Akka 连接的 akka 或广播与文件服务器的 fs。	false
spark.ssl.enabledAlgorithms	以逗号分隔的密码列表。指定的密码必须被 JVM 支持。	-
spark.ssl.keyPassword	key-store 的私人密钥密码。	-
spark.ssl.keyStore	key-store 文件的路径。该路径可以绝对或相对于开启组件的目录。	-
spark.ssl.keyStorePassword	key-store 的密码。	-
spark.ssl.protocol	协议名。该协议必须被 JVM 支持。本页所有协议的参考表。	-
spark.ssl.trustStore	trust-store 文件的路径。该路径可以绝对或相对于开启组件的目录。	-
spark.ssl.trustStorePassword	trust-store 的密码。	-

安全性

Spark 目前支持通过共享密钥认证。可以通过 spark.authenticate 配置参数配置认证。该参数控制 Spark 通信协议是否使用共享密钥执行认证。该认证是确保双边都有相同的共享密钥并被允许通信的基本握手。如果共享密钥不同，通信将不被允许。共享密钥通过如下方式创建：

- 对于 YARN 部署的 Spark，将 spark.authenticate 配置为真会自动处理生成和分发共享密钥。每个应用程序会独占一个共享密钥。
- 对于其他类型部署的 Spark，应该在每个节点上配置 Spark 参数 spark.authenticate.secret。所有 Master/Workers 和应用程序都将使用该密钥。

表21-27 参数说明

参数	描述	默认值
spark.acls.enable	是否开启 Spark acls。如果开启，它将检查用户是否有访问和修改 job 的权限。请注意这要求用户可以被识	true

参数	描述	默认值
	别。如果用户被识别为无效，检查将不被执行。UI 可以使用过滤器认证和设置用户。	
spark.admin.acls	逗号分隔的有权限访问和修改所有 Spark job 的用户/管理员列表。如果在共享集群上运行并且工作时有 MRS 集群管理员或开发人员帮助调试，可以使用该列表。	admin
spark.authenticate	是否 Spark 认证其内部连接。如果不是运行在 YARN 上，请参见 spark.authenticate.secret。	true
spark.authenticate.secret	设置 Spark 各组件之间验证的密钥。如果不是运行在 YARN 上且认证未开启，需要设置该项。	-
spark.modify.acls	逗号分隔的有权限修改 Spark job 的用户列表。默认情况下只有开启 Spark job 的用户才有修改列表的权限（例如删除列表）。	-
spark.ui.view.acls	逗号分隔的有权限访问 Spark web ui 的用户列表。默认情况下只有开启 Spark job 的用户才有访问权限。	-

开启 Spark 进程间的认证机制

目前 Spark 进程间支持共享密钥方式的认证机制，通过配置 spark.authenticate 可以控制 Spark 在通信过程中是否做认证。这种认证方式只是通过简单的握手来确定通信双方享有共同的密钥。

在 Spark 客户端的“spark-defaults.conf”文件中配置如下参数。

表21-28 参数说明

参数	描述	默认值
spark.authenticate	在 Spark on YARN 模式下，将该参数配置成 true 即可。密钥的生成和分发过程是自动完成的，并且每个应用独占一个密钥。	true

Compression

数据压缩是一个以 CPU 换内存的优化策略，因此当 Spark 内存严重不足的时候（由于内存计算的特质，这种情况非常常见），使用压缩可以大幅提高性能。目前 Spark 支持三种压缩算法：snappy，lz4，lzf。Snappy 为默认压缩算法，并且调用 native 方法进行压缩与解压缩，在 Yarn 模式下需要注意堆外内存对 Container 进程的影响。

表21-29 参数说明

参数	描述	默认值
spark.io.compression.codec	用于压缩内部数据的 codec，例如 RDD 分区、广播变量和 shuffle 输出。默认情况下，Spark 支持三种压缩算法：lz4，lzf 和 snappy。可以使用完全合格的类名称指定算法，例如 org.apache.spark.io.LZ4CompressionCodec、org.apache.spark.io.LZFCompressionCodec 及 org.apache.spark.io.SnappyCompressionCodec。	lz4
spark.io.compression.lz4.block.size	当使用 LZ4 压缩算法时 LZ4 压缩中使用的块大小（字节）。当使用 LZ4 时降低块大小同样也会降低 shuffle 内存使用。	32768
spark.io.compression.snappy.block.size	当使用 Snappy 压缩算法时 Snappy 压缩中使用的块大小（字节）。当使用 Snappy 时降低块大小同样也会降低 shuffle 内存使用。	32768
spark.shuffle.compress	是否压缩 map 任务输出文件。建议压缩。使用 spark.io.compression.codec 进行压缩。	true
spark.shuffle.spill.compress	是否压缩在 shuffle 期间溢出的数据。使用 spark.io.compression.codec 进行压缩。	true
spark.eventLog.compress	设置当 spark.eventLog.enabled 设置为 true 时是否压缩记录的事件。	false
spark.broadcast.compress	在发送之前是否压缩广播变量。建议压缩。	true
spark.rdd.compress	是否压缩序列化的 RDD 分区（例如 StorageLevel.MEMORY_ONLY_SER 的分区）。牺牲部分额外 CPU 的时间可以节省大量空间。	false

在资源不足的情况下，降低客户端运行异常概率

在资源不足的情况下，Application Master 会因等待资源出现超时，导致任务被删除。调整如下参数，降低客户端应用运行异常概率。

在客户端的“spark-defaults.conf”配置文件中调整如下参数。

表21-30 参数说明

参数	说明	默认值
spark.yarn.applicationMaster.waitTries	设置 Application Master 等待 Spark master 的次数，同时也是等待 SparkContext 初始化的次数。增大该参数值，可以防止 AM 任务被删除，降低客户端应用运行异常的概率。	10

参数	说明	默认值
spark.yarn.am.memory	调整 AM 的内存。增大该参数值，可以防止 AM 因内存不足而被 RM 删除任务，降低客户端应用运行异常的概率。	1G

21.2.4 SparkOnHBase 概述及基本应用

操作场景

Spark on HBase 为用户提供了在 Spark SQL 中查询 HBase 表，通过 Beeline 工具为 HBase 表进行存数据等操作。通过 HBase 接口可实现创建表、读取表、往表中插入数据等操作。

操作步骤

登录 Manager 界面，选择“集群 > *待操作集群的名称* > 集群属性”查看集群是否为安全模式。

- 是，执行步骤 2。
- 否，执行步骤 5。

步骤 1 选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置 > 全部配置 > JDBCServer2x > 默认”，修改以下参数：

表21-31 参数列表 1

参数	默认值	修改结果
spark.yarn.security.credentials.hbase.enabled	false	true

说明

为了保证 Spark2x 可以长期访问 HBase，建议不要修改 HBase 与 HDFS 服务的以下参数：

- dfs.namenode.delegation.token.renew-interval
- dfs.namenode.delegation.token.max-lifetime
- hbase.auth.key.update.interval
- hbase.auth.token.max.lifetime（不可修改，固定值为 604800000 毫秒，即 7 天）

如果必须要修改以上参数，请务必保证 HDFS 参数“dfs.namenode.delegation.token.renew-interval”的值不大于 HBase 参数“hbase.auth.key.update.interval”、“hbase.auth.token.max.lifetime”的值和 HDFS 参数“dfs.namenode.delegation.token.max-lifetime”的值。

步骤 2 选择“SparkResource2x > 默认”，修改以下参数：

表21-32 参数列表 2

参数	默认值	修改结果

参数	默认值	修改结果
spark.yarn.security.credentials.hbase.enabled	false	true

步骤 3 重启 Spark2x 服务，配置生效。

说明

如果需要在 Spark2x 客户端用 Spark on HBase 功能，需要重新下载并安装 Spark2x 客户端。

步骤 4 在 Spark2x 客户端使用 spark-sql 或者 spark-beeline 连接，可以查询由 Hive on HBase 所创建的表，支持通过 SQL 命令创建 HBase 表或创建外表关联 HBase 表。建表前，确认 HBase 中已存在对应 HBase 表，下面以 HBase 表 table1 为例说明。

1. 通过 Beeline 工具创建 HBase 表，命令如下：

   create table *hbaseTable*
   (
   id string,
   name string,
   age int
)
   using org.apache.spark.sql.hbase.HBaseSource
   options(
   hbaseTableName *"table1"***,**
   keyCols *"id"***,**
   colsMapping **"**
   name=cf1.cq1,
   age=cf1.cq2
   ");

   说明

   - hbaseTable：是创建的 spark 表的表名。
   - id string,name string, age int：是 spark 表的字段名和字段类型。
   - table1：HBase 表名。
   - id：HBase 表的 rowkey 列名。
   - name=cf1.cq1, age=cf1.cq2：spark 表的列和 HBase 表的列的映射关系。spark 的 name 列映射 HBase 表的 cf1 列簇的 cq1 列，spark 的 age 列映射 HBase 表的 cf1 列簇的 cq2 列。

2. 通过 csv 文件导入数据到 HBase 表，命令如下：

   hbase org.apache.hadoop.hbase.mapreduce.ImportTsv -Dimporttsv.separator="," -Dimporttsv.columns=HBASE_ROW_KEY,*cf1:cq1,cf1:cq2,cf1:cq3,cf1:cq4,cf1:cq5 table1 /hperson*

   其中：table1 为 HBase 表名，/hperson 为 csv 文件存放的路径。

3. 在 spark-sql 或 spark-beeline 中查询数据，*hbaseTable* 为对应的 spark 表名。命令如下：

   select * from *hbaseTable;*

----结束

21.2.5 SparkOnHBasev2 概述及基本应用

操作场景

Spark on HBaseV2 为用户提供了在 Spark SQL 中查询 HBase 表，通过 Beeline 工具为 HBase 表进行存数据等操作。通过 HBase 接口可实现创建表、读取表、往表中插入数据等操作。

操作步骤

登录 Manager 界面，选择“集群 > *待操作集群的名称* > 集群属性”查看集群是否为安全模式。

- 是，执行步骤 2。
- 否，执行步骤 5。

选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置 > 全部配置 > JDBCServer2x > 默认”，修改以下参数：

表21-33 参数列表 1

参数	默认值	修改结果
spark.yarn.security.credentials.hbase.enabled	false	true

说明

为了保证 Spark2x 可以长期访问 HBase，建议不要修改 HBase 与 HDFS 服务的以下参数：

- dfs.namenode.delegation.token.renew-interval
- dfs.namenode.delegation.token.max-lifetime
- hbase.auth.key.update.interval
- hbase.auth.token.max.lifetime（不可修改，固定值为 604800000 毫秒，即 7 天）

如果必须要修改以上参数，请务必保证 HDFS 参数“dfs.namenode.delegation.token.renew-interval”的值不大于 HBase 参数“hbase.auth.key.update.interval”、“hbase.auth.token.max.lifetime”的值和 HDFS 参数“dfs.namenode.delegation.token.max-lifetime”的值。

步骤 2 选择“SparkResource2x > 默认”，修改以下参数：

表21-34 参数列表 2

参数	默认值	修改结果
spark.yarn.security.credentials.hbase.enabled	false	true

步骤 3 重启 Spark2x 服务，配置生效。

说明

如果需要在 Spark2x 客户端用 Spark on HBase 功能，需要重新下载并安装 Spark2x 客户端。

步骤 4 在 Spark2x 客户端使用 spark-sql 或者 spark-beeline 连接，可以查询由 Hive on HBase 所创建的表，支持通过 SQL 命令创建 HBase 表或创建外表关联 HBase 表。具体见下面说明。下面以 HBase 表 table1 为例说明。

1. 通过 spark-beeline 工具创建表的语法命令如下：

   create table *hbaseTable*1
   (*id string, name string, age int***)**
   using org.apache.spark.sql.hbase.HBaseSourceV2
   options(
   hbaseTableName *"table2"***,**
   keyCols *"id"***,**
   colsMapping "*name=cf1.cq1,age=cf1.cq2***");**

   说明

   - hbaseTable1：是创建的 spark 表的表名。
   - id string,name string, age int：是 spark 表的字段名和字段类型。
   - table2：HBase 表名。
   - id：HBase 表的 rowkey 列名。
   - name=cf1.cq1, age=cf1.cq2：spark 表的列和 HBase 表的列的映射关系。spark 的 name 列映射 HBase 表的 cf1 列簇的 cq1 列，spark 的 age 列映射 HBase 表的 cf1 列簇的 cq2 列。

2. 通过 csv 文件导入数据到 HBase 表，命令如下：

   hbase org.apache.hadoop.hbase.mapreduce.ImportTsv -Dimporttsv.separator="," -Dimporttsv.columns=HBASE_ROW_KEY,*cf1:cq1,cf1:cq2,cf1:cq3,cf1:cq4,cf1:cq5 table2 /hperson*

   其中：table2 为 HBase 表名，/hperson 为 csv 文件存放的路径。

3. 在 spark-sql 或 spark-beeline 中查询数据，*hbaseTable*1 为对应的 spark 表名，命令如下：

   select * from *hbaseTable1;*

----结束

21.2.6 SparkSQL 权限管理（安全模式）

21.2.6.1 SparkSQL 权限介绍

SparkSQL 权限

类似于 Hive，SparkSQL 也是建立在 Hadoop 上的数据仓库框架，提供类似 SQL 的结构化数据。

MRS 提供用户、用户组和角色，集群中的各类权限需要先授予角色，然后将用户或者用户组与角色绑定。用户只有绑定角色或者加入绑定角色的用户组，才能获得权限。

说明

- 如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.12 添加 Spark2x 的 Ranger 访问权限策略。
- Spark2x 开启或关闭 Ranger 鉴权后，需要重启 Spark2x 服务，并重新下载客户端，或刷新客户端配置文件 spark/conf/spark-defaults.conf：

  开启 Ranger 鉴权：spark.ranger.plugin.authorization.enable=true

  关闭 Ranger 鉴权：spark.ranger.plugin.authorization.enable=false

权限管理介绍

SparkSQL 的权限管理是指 SparkSQL 中管理用户操作数据库的权限系统，以保证不同用户之间操作数据库的独立性和安全性。如果一个用户想操作另一个用户的表、数据库等，需要获取相应的权限才能进行操作，否则会被拒绝。

SparkSQL 权限管理部分集成了 Hive 权限管理的功能。使用 SparkSQL 权限管理功能需要使用 Hive 的 MetaStore 服务和页面上的赋权功能。

图 21-3 展示了 SparkSQL 权限管理的基本架构。主要包含了两部分：页面赋权和服务获权并判断。

- 页面赋权：SparkSQL 仅支持页面赋权的方式。在 FusionInsight Manager 的“系统 > 权限”中，可以进行用户、用户组和角色的添加/删除操作，可以对某个角色进行赋权/撤权。
- 服务获权并判断：当接收到客户端的 DDL、DML 的 SQL 命令时，SparkSQL 服务会向 MetaStore 服务获取客户端用户对数据库信息的已有权限，并检查是否包含了所需的所有权限，如果是则继续执行，否则拒绝该用户的操作。当通过了 MetaStore 的权限检查后，还需进行 HDFS 的 ACLs 权限检查。

图21-3 SparkSQL 权限管理架构图

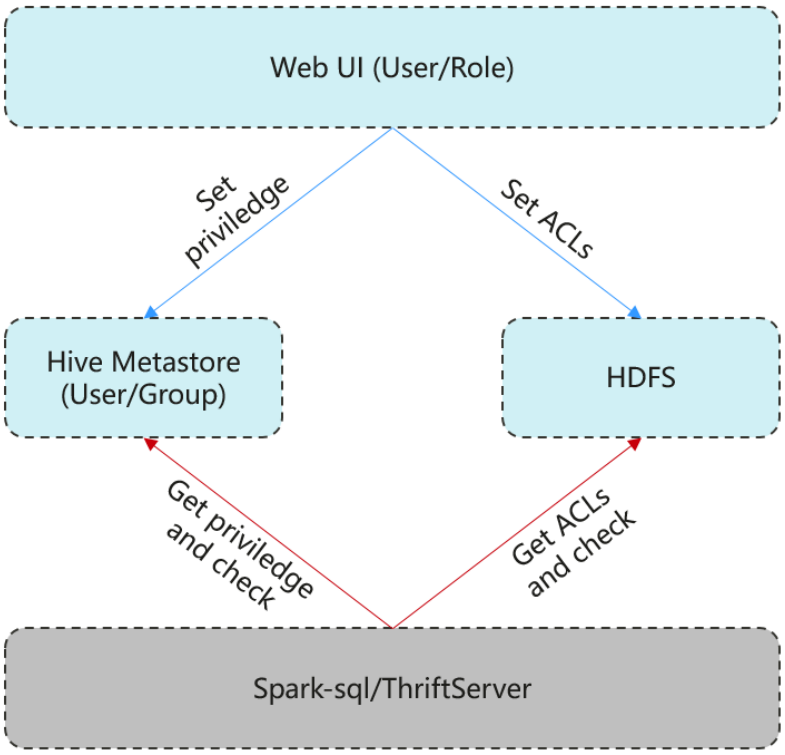

SparkSQL 还提供了列权限和视图权限，以满足用户不同场景的需求。

- 列权限介绍

  SparkSQL 权限控制由元数据权限控制和 HDFS ACL 权限控制两部分组成。Hive MetaStore 会将表权限自动同步到 HDFS ACL 中时，不会同步列级别的权限。也就是说，当用户对表具有部分列权限或全部列权限时，不能通过 HDFS Client 访问 HDFS 文件。

  - 在 spark-sql 模式下，用户仅具有列级别权限（即列权限用户）将不能访问 HDFS 文件，因此无法访问相应表的列。
  - Beeline/JDBCServer 模式下，用户间赋权，例如将 A 用户创建的表赋权给 B 用户时。
    - “hive.server2.enable.doAs”=true（在 Spark 服务端的“hive-site.xml”文件中配置）

      此时用户 B 不可查询。需在 HDFS 上手动为文件赋读权限。
    - “hive.server2.enable.doAs”=false
      - 用户 A 和 B 均通过 Beeline 连接，用户 B 可查询。
      - A 用户通过 SQL 方式建表，B 用户可在 Beeline 进行查询。

      而其他情况，如 A 用户使用 Beeline 建表，B 用户通过 SQL 查询，或者 A 用户通过 SQL 方式建表，B 用户使用 SQL 方式查询的情况均不支持。需在 HDFS 上手动为文件赋读权限。

说明

由于“spark”用户在 HDFS ACL 的权限控制上为 Spark 管理员用户权限，Beeline 客户端用户的权限控制仅取决于 Spark 侧的元数据权限。

- 视图权限介绍

  视图权限是指仅对表的视图具有查询、修改等操作的权限，不再依赖于视图所在的表的相应权限。即用户拥有视图的查询权限时，不管是否有表权限都可以进行查询。视图的权限是针对整个表而言的，不支持对其中的部分列创建视图权限。

  视图权限在 SparkSQL 权限上的限制与列权限相似，详细如下：

  - 在 spark-sql 模式下，只有视图权限而没有表权限，且没有 HDFS 的读取权限时，用户不能访问 HDFS 上存储的表的数据，即该情况下不支持对该表的视图进行查询。
  - Beeline/JDBCServer 模式下，用户间赋权，例如将 A 用户创建的视图赋权给 B 用户时。
    - “hive.server2.enable.doAs”=true（在 Spark 服务端的“hive-site.xml”文件中配置）

      此时用户 B 不可查询。需在 HDFS 上手动为文件赋读权限。
    - “hive.server2.enable.doAs”=false
      - 用户 A 和 B 均通过 Beeline 连接，用户 B 可查询。
      - A 用户通过 SQL 方式创建视图，B 用户可在 Beeline 进行查询。

      而其他情况，如 A 用户使用 Beeline 创建视图，B 用户通过 SQL 查询，或者 A 用户通过 SQL 方式创建视图，B 用户使用 SQL 方式查询的情况均不支持。需在 HDFS 上手动为文件赋读权限。

  对表的视图进行相应操作，分别需要具有以下权限。

  - 创建视图时，需要数据库的 CREATE 权限、表的 SELECT、SELECT_of_GRANT 权限。
  - 查询、描述视图时，只需要视图的 SELECT 权限，不需要视图所依赖的表或依赖的视图的 SELECT 权限。若同时查询视图和其他表，则仍然需要其他表的 SELECT 权限，例如：select * from v1 join t1 时，需要有视图 v1 和表 t1 的 SELECT 权限，即使 v1 是基于 t1 的视图，也需要表 t1 的 SELECT 权限。

说明

在 Beeline/JDBCServer 模式下，查询视图只需表的 SELECT 权限；而在 spark-sql 模式下，查询视图需要视图的 SELECT 权限和表的 SELECT 权限。

  - 删除、修改视图时，必须要有视图的 owner 权限。

SparkSQL 权限模型

用户使用 SparkSQL 服务进行 SQL 操作，必须对 SparkSQL 数据库和表（含外表和视图）拥有相应的权限。完整的 SparkSQL 权限模型由元数据权限与 HDFS 文件权限组成。使用数据库或表时所需要的各种权限都是 SparkSQL 权限模型中的一种。

- 元数据权限

  元数据权限即在元数据层上进行权限控制，与传统关系型数据库类似，SparkSQL 数据库包含“创建”和“查询”权限，表和列包含“查询”、“插入”、

“UPDATE”和“删除”权限。SparkSQL 中还包含拥有者权限“OWNERSHIP”和 Spark 管理员权限“管理”。

- 数据文件权限，即 HDFS 文件权限

  SparkSQL 的数据库、表对应的文件保存在 HDFS 中。默认创建的数据库或表保存在 HDFS 目录“/user/hive/warehouse”。系统自动以数据库名称和数据库中表的名称创建子目录。访问数据库或者表，需要在 HDFS 中拥有对应文件的权限，包含“读”、“写”和“执行”权限。

用户对 SparkSQL 数据库或表执行不同操作时，需要关联不同的元数据权限与 HDFS 文件权限。例如，对 SparkSQL 数据表执行查询操作，需要关联元数据权限“查询”，以及 HDFS 文件权限“读”和“执行”。

使用 Manager 界面图形化的角色管理功能来管理 SparkSQL 数据库和表的权限，只需要设置元数据权限，系统会自动关联 HDFS 文件权限，减少界面操作，提高效率。

SparkSQL 使用场景及对应权限

用户通过 SparkSQL 服务创建数据库需要加入 Hive 组，不需要角色授权。用户在 Hive 和 HDFS 中对自己创建的数据库或表拥有完整权限，可直接创建表、查询数据、删除数据、插入数据、更新数据以及授权他人访问表与对应 HDFS 目录与文件。

如果用户访问别人创建的表或数据库，需要授予权限。所以根据 SparkSQL 使用场景的不同，用户需要的权限可能也不相同。

表21-35 SparkSQL 使用场景

主要场景	用户需要的权限
使用 SparkSQL 表、列或数据库	使用其他用户创建的表、列或数据库，不同的场景需要不同的权限，例如： • 创建表，需要“创建”。 • 查询数据，需要“查询”。 • 插入数据，需要“插入”。
关联使用其他组件	部分场景除了 SparkSQL 权限，还可能需要组件的权限，例如： 使用 Spark on HBase，在 SparkSQL 中查询 HBase 表数据，需要设置 HBase 权限。

在一些特殊 SparkSQL 使用场景下，需要单独设置其他权限。

表21-36 SparkSQL 授权注意事项

场景	用户需要的权限
创建 SparkSQL 数据库、表、外表，或者为已经创建的表或外表添加分区，且 Hive 用户指定数	• 需要此目录已经存在，客户端用户是目录的属主，且用户对目录拥有“读”、“写”和“执行”权限。同时用户对此目录上层的每一级目录都拥有“读”和“执行”权限。

场景	用户需要的权限
据文件保存在“/user/hive/warehouse”以外的 HDFS 目录。	• 在 Spark2x 中，在创建 HBase 的外表时，需要拥有 Hive 端 database 的“创建”权限。而在 Spark 1.5 中，在创建 HBase 的外表时，需要拥有 Hive 端 database 的“创建”权限，也需要拥有 HBase 端 Namespace 的“创建”权限。
用户使用 load 将指定目录下所有文件或者指定文件，导入数据到表中。	• 数据源为 Linux 本地磁盘，指定目录时需要此目录已经存在，系统用户“omm”对此目录以及此目录上层的每一级目录拥有“r”和“x”的权限。指定文件时需要此文件已经存在，“omm”对此文件拥有“r”的权限，同时对此文件上层的每一级目录拥有“r”和“x”的权限。 • 数据源为 HDFS，指定目录时需要此目录已经存在，SparkSQL 用户是目录属主，且用户对此目录及其子目录拥有“读”、“写”和“执行”权限，并且其上层的每一级目录拥有“读”和“执行”权限。指定文件时需要此文件已经存在，SparkSQL 用户是文件属主，且用户对文件拥有“读”、“写”和“执行”权限，同时对此文件上层的每一级目录拥有“读”和“执行”权限。
创建函数、删除函数或者修改任意数据库。	需要授予“管理”权限。
操作 Hive 中所有的数据库和表。	需加入到 supergroup 用户组，并且授予“管理”权限。
对部分 datasource 表赋予 insert 权限后，执行 insert|analyze 操作前需要单独对 hdfs 上的表目录赋予写权限。	当前对 spark datasource 表赋予 Insert 权限时，若表格式为：text|csv|json|parquet|orc，则不会修改表目录的权限。因此，对以上几种类型的 datasource 表赋予 Insert 权限后，还需要单独对 hdfs 上的表目录赋予写权限，用户才能成功对表执行 insert|analyze 操作。

21.2.6.2 创建 SparkSQL 角色

操作场景

该任务指导 MRS 集群管理员在 Manager 创建并设置 SparkSQL 的角色。SparkSQL 角色可设置 Spark 管理员权限以及数据表的数据操作权限。

用户使用 Hive 并创建数据库需要加入 hive 组，不需要角色授权。用户在 Hive 和 HDFS 中对自己创建的数据库或表拥有完整权限，可直接创建表、查询数据、删除数据、插入数据、更新数据以及授权他人访问表与对应 HDFS 目录与文件。默认创建的数据库或表保存在 HDFS 目录“/user/hive/warehouse”。

说明

- 如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理，具体操作可参考 20.12 添加 Spark2x 的 Ranger 访问权限策略。
- Spark2x 开启或关闭 Ranger 鉴权后，需要重启 Spark2x 服务，并重新下载客户端，或刷新客户端配置文件 spark/conf/spark-defaults.conf：

  开启 Ranger 鉴权：spark.ranger.plugin.authorization.enable=true

  关闭 Ranger 鉴权：spark.ranger.plugin.authorization.enable=false

操作步骤

1. 登录 Manager 页面，选择“系统 > 权限 > 角色”。
2. 单击“添加角色”，然后“角色名称”和“描述”输入角色名字与描述。
3. 设置角色“配置资源权限”请参见表 21-37。
   - “Hive 管理员权限”：Hive 管理员权限。
   - “Hive 读写权限”：Hive 数据表管理权限，可设置与管理已创建的表的数据操作权限。

说明

- Hive 角色管理支持授予 Hive 管理员权限、访问表和视图的权限，不支持数据库的授权。
- Hive 管理员权限不支持管理 HDFS 的权限。
- 如果数据库中的表或者表中的文件数量比较多，在授权时可能需要等待一段时间。例如表的文件数量为 1 万时，可能需要等待 2 分钟。

表21-37 设置角色

任务场景	角色授权操作
设置 Hive 管理员权限	在“配置资源权限”的表格中选择“*待操作集群的名称* > Hive”，勾选“Hive 管理权限”。 用户绑定 Hive 管理员角色后，在每个维护操作会话中，还需要执行以下操作： 1. 以客户端安装用户，登录安装 Spark2x 客户端的节点。 2. 执行以下命令配置环境变量。 例如，Spark2x 客户端安装目录为“/opt/client”，执行 **source /opt/client/bigdata_env** **source /opt/client/Spark2x/component_env** 3. 执行以下命令认证用户。 ***kinit*** *Hive 业务用户* 4. 执行以下命令登录客户端工具。 **/opt/client/Spark2x/spark/bin/beeline -u "jdbc:hive2://<zkNode1_IP>:<zkNode1_Port>,<zkNode2_IP>:<zkNode2_Port>,<zkNode3_IP>:<zkNode3_Port>/;serviceDiscoveryMode=zooKeeper;zooKeeperNamespace=sparkthriftserver2x;user.principal=spark2x/hadoop.*<*系统域名*>*@*<*系统域名*>**;saslQop=auth-conf;auth=KERBEROS;principal=spark2x/hadoop.*<*系统域*

任务场景	角色授权操作
	名>@<*系统域名*>;" 说明 • 其中“<zkNode1_IP>:<zkNode1_Port>,<zkNode2_IP>:<zkNode2_Port>,<zkNode3_IP>:<zkNode3_Port>”是 Zookeeper 的 URL。例如“192.168.81.37:2181,192.168.195.232:2181,192.168.169.84:2181”。 • 其中“sparkthriftserver”是 Zookeeper 上的目录，表示客户端从该目录下随机选择 Triftserver 实例或 proxyThriftServer 进行连接。 • 用户可登录 Manager，选择“系统 > 权限 > 域和互信”，查看“本端域”参数，即为当前系统域名。“spark2x/hadoop.<系统域名>”为用户名，用户的用户名所包含的系统域名所有字母为小写。例如“本端域”参数为“9427068F-6EFA-4833-B43E-60CB641E5B6C.COM”，用户名为“spark2x/hadoo.9427068f-6efa-4833-b43e-60cb641e5b6c.com”。 5. 执行以下命令更新用户的管理员权限。 **set role admin;**
设置在默认数据库中，查询其他用户表的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Hive > Hive 读写权限”。 2. 在数据库列表中单击指定的数据库名称，显示数据库中的表。 3. 在指定表的“权限”列，勾选“查询”。
设置在默认数据库中，导入数据到其他用户表的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Hive > Hive 读写权限”。 2. 在数据库列表中单击指定的数据库名称，显示数据库中的表。 3. 在指定表的“权限”列，勾选“删除”和“插入”。

4. 单击“确定”完成。

21.2.6.3 配置表、列和数据库的权限

操作场景

使用 SparkSQL 操作表或者数据库时，如果用户访问别人创建的表或数据库，需要授予对应的权限。为了实现更严格权限控制，SparkSQL 也支持列级别的权限控制。如果要访问别人创建的表上某些列，需要授予列权限。以下介绍使用 Manager 角色管理功能在表授权、列授权和数据库授权三个场景下的操作。

操作步骤

SparkSQL 表授权、列授权、数据库授权与 Hive 的操作相同，详情请参见 11.4 权限管理。

说明

- 在权限管理中，为了方便用户使用，授予数据库下表的任意权限将自动关联该数据库目录的HDFS权限。为了避免产生性能问题，取消表的任意权限，系统不会自动取消数据库目录的HDFS权限，但对应的用户只能登录数据库和查看表名。
- 若为角色添加或删除数据库的查询权限，数据库中的表也将自动添加或删除查询权限。此机制为Hive实现，SparkSQL与Hive保持一致。
- Spark不支持struct数据类型中列名称含有特殊字符（除字母、数字、下划线外的其他字符）。如果struct类型中列名称含有特殊字符，在FusionInsight Manager的“编辑角色”页面进行授权时，该列将无法正确显示。

相关概念

SparkSQL的语句在SparkSQL中进行处理，权限要求如表21-38所示。

表21-38 使用SparkSQL表、列或数据库场景权限一览

操作场景	用户需要的权限
CREATE TABLE	“创建”, RWX+ownership（for create external table - the location） **说明** 按照指定文件路径创建datasource表时，需要path后面文件的RWX+ownership权限。
DROP TABLE	“Ownership”（of table）
DROP TABLE PROPERTIES	“Ownership”
DESCRIBE TABLE	“查询”
SHOW PARTITIONS	“查询”
ALTER TABLE LOCATION	“Ownership”, RWX+ownership (for new location)
ALTER PARTITION LOCATION	“Ownership”, RWX+ownership (for new partition location)
ALTER TABLE ADD PARTITION	“插入”, RWX+ownership (for partition location)
ALTER TABLE DROP PARTITION	“删除”
ALTER TABLE(all of them except the ones above)	“Update”, “Ownership”
TRUNCATE TABLE	“Ownership”
CREATE VIEW	“查询”, “Grant Of Select”, “创建”
ALTER VIEW PROPERTIES	“Ownership”
ALTER VIEW RENAME	“Ownership”

操作场景	用户需要的权限
ALTER VIEW ADD PARTS	“Ownership”
ALTER VIEW AS	“Ownership”
ALTER VIEW DROPPARTS	“Ownership”
ANALYZE TABLE	“查询”，“插入”
SHOW COLUMNS	“查询”
SHOW TABLE PROPERTIES	“查询”
CREATE TABLE AS SELECT	“查询”，“创建”
SELECT	“查询” **说明** 与表一样，对视图进行 SELECT 操作的时候需要有该视图的“查询”权限。
INSERT	“插入”，“删除 (for overwrite)”
LOAD	“插入”，“删除”, RWX+ownership(input location)
SHOW CREATE TABLE	“查询”，“Grant Of Select”
CREATE FUNCTION	“管理”
DROP FUNCTION	“管理”
DESC FUNCTION	-
SHOW FUNCTIONS	-
MSCK (metastore check)	“Ownership”
ALTER DATABASE	“管理”
CREATE DATABASE	-
SHOW DATABASES	-
EXPLAIN	“查询”
DROP DATABASE	“Ownership”
DESC DATABASE	-
CACHE TABLE	“查询”
UNCACHE TABLE	“查询”
CLEAR CACHE TABLE	“管理”
REFRESH TABLE	“查询”

操作场景	用户需要的权限
ADD FILE	“管理”
ADD JAR	“管理”
HEALTHCHECK	-

21.2.6.4 配置 SparkSQL 业务使用其他组件的权限

操作场景

SparkSQL 业务还可能需要关联使用其他组件，例如 spark on HBase 需要 HBase 权限。以下介绍 SparkSQL 关联 HBase 服务的操作。

前提条件

- 完成 Spark 客户端的安装，例如安装目录为“/opt/client”。
- 获取一个拥有 MRS 集群管理员权限的用户，例如“admin”。

操作步骤

- **Spark on HBase 授权**

  用户如果需要使用类似 SQL 语句的方式来操作 HBase 表，授予权限后可以使用 SparkSQL 访问 HBase 表。以授予用户在 SparkSQL 中查询 HBase 表的权限为例，操作步骤如下：

  说明

  设置“spark.yarn.security.credentials.hbase.enabled”为“true”。

  a. 在 Manager 角色界面创建一个角色，例如“hive_hbase_create”，并授予创建 HBase 表的权限。

     在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global”，勾选命名空间“default”的“创建”，单击“确定”保存。

  说明

  本例中建表是保存在 Hive 的“default”数据库中，默认具有“default”数据库的“建表”权限。如果 Hive 的数据库不是“default”，则还需要执行以下步骤：

  在“配置资源权限”的表格中选择“*待操作集群的名称* > Hive > Hive 读写权限”，勾选所需指定的数据库的“建表”，单击“确定”保存。

  b. 在 Manager 角色界面创建一个角色，例如“hive_hbase_submit”，并授予提交任务到 Yarn 的队列的权限。

     在“配置资源权限”的表格中选择“*待操作集群的名称* > Yarn > 调度队列 > root”，勾选队列“default”的“提交”，单击“确定”保存。

  c. 在 Manager 用户界面创建一个“人机”用户，例如“hbase_creates_user”，加入“hive”组，绑定角色“hive_hbase_create”和“hive_hbase_submit”，用于创建 SparkSQL 表和 HBase 表。

  d. 以客户端安装用户登录安装客户端的节点。

e. 执行以下命令，配置环境变量。

source /opt/client/bigdata_env

source /opt/client/Spark2x/component_env

f. 执行以下命令，认证用户。

kinit hbase_creates_user

g. 执行以下命令，进入 Spark JDBCServer 客户端 shell 环境：

/opt/client/Spark2x/spark/bin/beeline -u "jdbc:hive2://<zkNode1_IP>:<zkNode1_Port>,<zkNode2_IP>:<zkNode2_Port>,<zkNode3_IP>:<zkNode3_Port>/;serviceDiscoveryMode=zooKeeper;zooKeeperNamespace=sparkthriftserver2x;user.principal=spark2x/hadoop.<*系统域名*>**@**<*系统域名*>**;saslQop=auth-conf;auth=KERBEROS;principal=spark2x/hadoop.**<*系统域名*>**@**<*系统域名*>**;"**

h. 执行以下命令，同时在 SparkSQL 和 HBase 中创建表。例如创建表 hbaseTable。

create table hbaseTable (id string, name string, age int) using org.apache.spark.sql.hbase.HBaseSource options (hbaseTableName "table1", keyCols "id", colsMapping = ", name=cf1.cq1, age=cf1.cq2");

创建好的 SparkSQL 表和 HBase 表分别保存在 Hive 的数据库“default”和 HBase 的命名空间“default”。

i. 在 Manager 角色界面创建一个角色，例如“hive_hbase_select”，并授予查询 SparkSQL on HBase 表 hbaseTable 和 HBase 表 hbaseTable 的权限。

- 在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global > default”，勾选表 hbaseTable 的“读”，单击“确定”保存，授予 HBase 角色查询表的权限。
- 编辑角色，在“配置资源权限”的表格中选择“*待操作集群的名称* > HBase > HBase Scope > global > hbase”，勾选表“hbase:meta”的“执行”，单击“确定”保存。
- 编辑角色，在“配置资源权限”的表格中选择“*待操作集群的名称* > Hive > Hive 读写权限 > default”，勾选表 hbaseTable 的“查询”，单击“确定”保存。

j. 在 Manager 用户界面创建一个“人机”用户，例如“hbase_select_user”，加入“hive”组，绑定角色“hive_hbase_select”，用于查询 SparkSQL 表和 HBase 表。

k. 执行以下命令，配置环境变量。

source /opt/client/bigdata_env

source /opt/client/Spark2x/component_env

l. 执行以下命令，认证用户。

kinit hbase_select_user

m. 执行以下命令，进入 Spark JDBCServer 客户端 shell 环境：

/opt/client/Spark2x/spark/bin/beeline -u "jdbc:hive2://<zkNode1_IP>:<zkNode1_Port>,<zkNode2_IP>:<zkNode2_Port>,<zkNode3_IP>:<zkNode3_Port>/;serviceDiscoveryMode=zooKeeper;zooKeeperNamespace=sparkthriftserver2x;user.principal=spark2x/hadoop.<*系统域*>

名>@<系统域名>;saslQop=auth-conf;auth=KERBEROS;principal=spark2x/hadoop.*<系统域名>@<系统域名>*;"

n. 执行以下命令，使用 SparkSQL 语句查询 HBase 表的数据。

select * from hbaseTable;

21.2.6.5 客户端和服务端配置

SparkSQL 权限管理功能相关的配置如下所示，客户端与服务端的配置相同。要使用表权限功能，需要在服务端和客户端添加如下配置。

- “spark-defaults.conf”配置文件

表21-39 参数说明（1）

参数	描述	默认值
spark.sql.authorization.enabled	是否开启 datasource 语句的权限认证功能。建议将此参数修改为 true，开启权限认证功能。	true

- “hive-site.xml”配置文件

表21-40 参数说明（2）

参数	描述	默认值
hive.metastore.uris	Hive 组件中 MetaStore 服务的地址，如“thrift://10.10.169.84:21088,thrift://10.10.81.37:21088”	-
hive.metastore.sasl.enabled	MetaStore 服务是否使用 SASL 安全加固。表权限功能需要设置为“true”。	true
hive.metastore.kerberos.principal	Hive 组件中 MetaStore 服务的 Principal，如“hive/hadoop.*<系统域名>*@*<系统域名>*”。	hive-metastore/_HOST@EXAMPLE.COM
hive.metastore.thrift.sasl.qop	开启 SparkSQL 权限管理功能后，需将此参数设置为“auth-conf”。	auth-conf
hive.metastore.token.signature	MetaStore 服务对应的 token 标识，设为“HiveServer2ImpersonationToken”。	HiveServer2ImpersonationToken
hive.security.authenticator.manager	Hive 客户端授权的管理器，需设为“org.apache.hadoop.hive.ql.security.SessionStateUserGroupAuthenticator”。	org.apache.hadoop.hive.ql.security.SessionStateUserMSGroupAuthenticator

参数	描述	默认值
hive.security.authorization.enabled	是否开启客户端的授权，需设为“true”。	true
hive.security.authorization.createtable.owner.grants	将哪些权限赋给创建表的 owner，建议设置为“ALL”。	ALL

- MetaStore 服务的 core-site.xml 配置文件

表21-41 参数说明 (3)

参数	描述	默认值
hadoop.proxyuser.spark.hosts	允许 Spark 用户伪装成来自哪些 host 的用户，需设为“*”，代表所有节点。	-
hadoop.proxyuser.spark.groups	允许 Spark 用户伪装成哪些用户组的用户，需设为“*”，代表所有用户组。	-

21.2.7 场景化参数

21.2.7.1 配置多主实例模式

配置场景

集群中支持同时共存多个 ThriftServer 服务，通过客户端可以随机连接其中的任意一个服务进行业务操作。即使集群中一个或多个 ThriftServer 服务停止工作，也不影响用户通过同一个客户端接口连接其他正常的 ThriftServer 服务。

配置描述

登录 Manager，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索并修改以下参数。

表21-42 多主实例参数说明

参数	说明	默认值
spark.thriftserver.zookeeper.connection.timeout	Zookeeper 客户端连接超时时间，单位毫秒。	60000
spark.thriftserver.zookeeper.session.timeout	Zookeeper 客户端会话超时时间，单位毫秒。	90000
spark.thriftserver.zookeeper.	Zookeeper 客户端失联后，重试次	3

参数	说明	默认值
retry.times	数。	
spark.yarn.queue	JDBCServer 服务所在的 Yarn 队列。	default

21.2.7.2 配置多租户模式

配置场景

多租户模式是将 JDBCServer 和租户绑定，每一个租户对应一个或多个 JDBCServer，一个 JDBCServer 只给一个租户提供服务。不同的租户可以配置不同的 Yarn 队列，从而达到资源隔离。

配置描述

登录 Manager，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索并修改以下参数。

表21-43 参数说明

参数	说明	默认值
spark.proxyserver.hash.enabled	是否使用 Hash 算法连接 ProxyServer。 • true 为使用 Hash 算法，使用多租户模式时，该参数需配置为 true。 • false 为使用随机连接，多主实例模式，配置为 false。	true 说明 该参数修改后需要重新下载客户端。
spark.thriftserver.proxy.enabled	是否使用多租户模式。 • false 表示使用多实例模式 • true 表示使用多租户模式	true
spark.thriftserver.proxy.maxThriftServerPerTenancy	多租户模式下，一个租户可启动 JDBCServer 实例的最大个数。	1
spark.thriftserver.proxy.maxSessionPerThriftServer	多租户模式下，单个 JDBCServer 实例的 session 数量超过该值时，如果租户的 JDBCServer 最大实例数量没超过限制，则启动新的 JDBCServer，否则输出警告日志。	50
spark.thriftserver.proxy.sessionWaitTime	多租户模式下，当 JDBCServer 的 session 连接数为 0 时，停止 JDBCServer 前的等待时间。	180000
spark.thriftserver.proxy.sessionThreshold	多租户模式下，当 JDBCServer 的 session 使用率（公式：当前 session 数 /	100

参数	说明	默认值
	(spark.thriftserver.proxy.maxSessionPerThriftServer * 当前 JDBCServer 个数)）达到阈值时，自动新增 JDBCServer。	
spark.thriftserver.proxy.healthcheck.period	多租户模式下，JDBCServer 代理检查 JDBCServer 健康状态周期。	60000
spark.thriftserver.proxy.healthcheck.recheckTimes	多租户模式下，JDBCServer 代理检查 JDBCServer 健康状态失败后重试次数。	3
spark.thriftserver.proxy.healthcheck.waitTime	多租户模式下，JDBCServer 代理发送健康检查，等待 JDBCServer 响应的超时时间。	10000
spark.thriftserver.proxy.session.check.interval	多租户模式下，JDBCServer 代理检查 session 的周期。	6h
spark.thriftserver.proxy.idle.session.timeout	多租户模式下，JDBCServer 代理 session 的空闲超时时间。如果在这段时间内没有做任何操作，session 会被关闭。	7d
spark.thriftserver.proxy.idle.session.check.operation	多租户模式下，JDBCServer 代理 session 的过期是否要判断该 session 上还存在 operation。	true
spark.thriftserver.proxy.idle.operation.timeout	多租户模式下，operation 的超时时间。如果 operation 超时，operation 会被关闭。	5d

21.2.7.3 配置多主实例与多租户模式切换

配置场景

在使用集群中，如果需要在多主实例模式与多租户模式之间切换，则还需要进行如下参数的设置。

- 多租户切换成多主实例模式

  修改 Spark2x 服务的以下参数：

  - spark.thriftserver.proxy.enabled=false
  - spark.scheduler.allocation.file=#{conf_dir}/fairscheduler.xml
  - spark.proxyserver.hash.enabled=false
- 多主实例切换成多租户模式

  修改 Spark2x 服务的以下参数：

  - spark.thriftserver.proxy.enabled=true
  - spark.scheduler.allocation.file=./__spark_conf__/__hadoop_conf__/fairscheduler.xml
  - spark.proxyserver.hash.enabled=true

配置描述

登录 Manager，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索并修改以下参数。

表21-44 参数说明

参数	说明	默认值
spark.thriftserver.proxy.enabled	是否使用多租户模式。 • false 表示使用多实例模式 • true 表示使用多租户模式	true
spark.scheduler.allocation.file	公平调度文件路径。 • 多主实例配置为：#{conf_dir}/fairscheduler.xml • 多租户配置为：./__spark_conf__/__hadoop_conf__/fairscheduler.xml	./__spark_conf__/__hadoop_conf__/fairscheduler.xml
spark.proxyserver.hash.enabled	是否使用 Hash 算法连接 ProxyServer。 • true 为使用 Hash 算法，使用多租户模式时，该参数需配置为 true。 • false 为使用随机连接，多主实例模式，配置为 false。	true **说明** 该参数修改后需要重新下载客户端。

21.2.7.4 配置事件队列的大小

配置场景

Spark 中见到的 UI、EventLog、动态资源调度等功能都是通过事件传递实现的。事件有 SparkListenerJobStart、SparkListenerJobEnd 等，记录了每个重要的过程。

每个事件在发生后都会保存到一个队列中，Driver 在创建 SparkContext 对象时，会启动一个线程循环的从该队列中依次拿出一个事件，然后发送给各个 Listener，每个 Listener 感知到事件后就会做各自的处理。

因此当队列存放的速度大于获取的速度时，就会导致队列溢出，从而丢失了溢出的事件，影响了 UI、EventLog、动态资源调度等功能。所以为了更灵活的使用，在这边添加一个配置项，用户可以根据 Driver 的内存大小设置合适的值。

配置描述

参数入口：

在执行应用之前，在 Spark 服务配置中修改。在 Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”。在搜索框中输入参数名称。

表21-45 参数说明

参数	描述	默认值
spark.scheduler.listenerbus.eventqueue.capacity	事件队列的大小，可以根据 Driver 的内存做适当的配置。	1000000

说明

当 Driver 日志中出现如下的日志时，表示队列溢出了。

1. 普通应用：

```
Dropping SparkListenerEvent because no remaining room in event queue.
This likely means one of the SparkListeners is too slow and cannot keep
up with the rate at which tasks are being started by the scheduler.
```

2. Spark Streaming 应用：

```
Dropping StreamingListenerEvent because no remaining room in event queue.
This likely means one of the StreamingListeners is too slow and cannot keep
up with the rate at which events are being started by the scheduler.
```

21.2.7.5 配置 executor 堆外内存大小

配置场景

当分配的内存太小或者被更高优先级的进程抢占资源时，会出现物理内存超限的情况。调整如下参数，可以防止物理内存超限。

配置描述

参数入口：

在应用提交时通过“--conf”设置这些参数，或者在客户端的“spark-defaults.conf”配置文件中调整如下参数。

表21-46 参数说明

参数	说明	默认值
spark.executor.memoryOverhead	用于指定每个 executor 的堆外内存大小(MB)，增大该参数值，可以防止物理内存超限。该值是通过max(384,executor-memory*0.1)计算所得，最小值为384。	1024

21.2.7.6 增强有限内存下的稳定性

配置场景

当前 Spark SQL 执行一个查询时需要使用大量的内存，尤其是在做聚合（Aggregate）和关联（Join）操作时，此时如果内存有限的情况下就很容易出现

OutOfMemoryError。有限内存下的稳定性就是确保在有限内存下依然能够正确执行相关的查询，而不出现 OutOfMemoryError。

说明

有限内存并不意味着内存无限小，它只是在内存不足于放下大于内存可用总量几倍的数据时，通过利用磁盘来做辅助从而确保查询依然稳定执行，但依然有一些数据是必须留在内存的，如在做涉及到 Join 的查询时，对于当前用于 Join 的相同 key 的数据还是需要放在内存中，如果该数据量较大而内存较小依然会出现 OutOfMemoryError。

有限内存下的稳定性涉及到 3 个子功能：

1. ExternalSort

   外部排序功能，当执行排序时如果内存不足会将一部分数据溢出到磁盘中。

2. TungstenAggregate

   新 Hash 聚合功能，默认对数据调用外部排序进行排序，然后再进行聚合，因此内存不足时在排序阶段会将数据溢出到磁盘，在聚合阶段因数据有序，在内存中只保留当前 key 的聚合结果，使用的内存较小。

3. SortMergeJoin、SortMergeOuterJoin

   基于有序数据的等值连接。该功能默认对数据调用外部排序进行排序，然后再进行等值连接，因此内存不足时在排序阶段会将数据溢出到磁盘，在连接阶段因数据有序，在内存中只保留当前相同 key 的数据，使用的内存较小。

配置描述

参数入口：

在应用提交时通过“--conf”设置这些参数，或者在客户端的“spark-defaults.conf”配置文件中调整如下参数。

表21-47 参数说明

参数	场景	描述	默认值
spark.sql.tungsten.enabled	/	类型为 Boolean。 • 当设置的值等于 true 时，表示开启 tungsten 功能，即逻辑计划等同于开启 codegeneration，同时物理计划使用对应的 tungsten 执行计划。 • 当设置的值等于 false 时，表示关闭 tungsten 功能。	true
spark.sql.codegen.wholeStage		类型为 Boolean。 • 当设置的值等于 true 时，表示开启 codegeneration 功能，即运行时对于某些特定的查询将动态生成各逻辑计划代码。 • 当设置的值等于 false 时，表示关闭 codegeneration 功能，运行时使用当前已有静态代码。	true

说明

1. 开启 ExternalSort 除配置 spark.sql.planner.externalSort=true 外，还需配置 spark.sql.unsafe.enabled=false 或者 spark.sql.codegen.wholeStage =false。
2. 如果您需要开启 TungstenAggregate，有如下几种方式：

   将 spark.sql.codegen.wholeStage 和 spark.sql.unsafe.enabled 的值都设置为 true（通过配置文件或命令行方式设置）。

   如果 spark.sql.codegen.wholeStage 和 spark.sql.unsafe.enabled 都不为 true 或者其中一个不为 true，只要 spark.sql.tungsten.enabled 的值设置为 true 时，TungstenAggregate 会开启。

21.2.7.7 配置 WebUI 上查看聚合后的 container 日志

配置场景

当 Yarn 配置“yarn.log-aggregation-enable”为“true”时，就开启了 container 日志聚合功能。日志聚合功能是指：当应用在 Yarn 上执行完成后，NodeManager 将本节点中所有 container 的日志聚合到 HDFS 中，并删除本地日志。详情请参见 23.7 配置 Container 日志聚合功能。

然而，开启 container 日志聚合功能之后，其日志聚合至 HDFS 目录中，只能通过获取 HDFS 文件来查看日志。开源 Spark 和 Yarn 服务不支持通过 WebUI 查看聚合后的日志。

因此，Spark 在此基础上进行了功能增强。如图 21-4 所示，在 HistoryServer 页面添加“AggregatedLogs”页签，可以通过“logs”链接查看聚合的日志。

图21-4 聚合日志显示页面

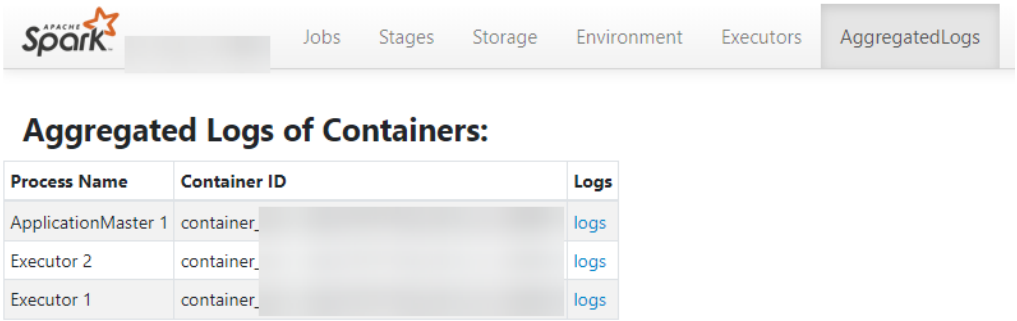

配置描述

为了使 WebUI 页面显示日志，需要将聚合日志进行解析和展现。Spark 是通过 Hadoop 的 JobHistoryServer 来解析聚合日志的，所以您可以通过“spark.jobhistory.address”参数，指定 JobHistoryServer 页面地址，即可完成解析和展现。

参数入口：

在应用提交时通过“--conf”设置这些参数，或者在客户端的“spark-defaults.conf”配置文件中调整如下参数。

说明

- 此功能依赖 Hadoop 中的 JobHistoryServer 服务，所以使用聚合日志之前需要保证 JobHistoryServer 服务已经运行正常。
- 如果参数值为空，“AggregatedLogs”页签仍然存在，但是无法通过 logs 链接查看日志。
- 只有当 App 已经 running，HDFS 上已经有该 App 的事件日志文件时才能查看到聚合的 container 日志。
- 正在运行的任务的日志，用户可以通过“Executors”页面的日志链接进行查看，任务结束后日志会汇聚到 HDFS 上，“Executors”页面的日志链接就会失效，此时用户可以通过“AggregatedLogs”页面的 logs 链接查看聚合日志。

表21-48 参数说明

参数	描述	默认值
spark.jobhistory.address	JobHistoryServer 页面的地址，格式：*http(s)://ip:port/jobhistory*。例如，将参数值设置为“https://10.92.115.1:26014/jobhistory”。 默认值为空，表示不能从 WebUI 查看 container 聚合日志。 修改参数后，需重启服务使得配置生效。	-

21.2.7.8 配置 YARN-Client 和 YARN-Cluster 不同模式下的环境变量

配置场景

当前，在 YARN-Client 和 YARN-Cluster 模式下，两种模式的客户端存在冲突的配置，即当客户端为一种模式的配置时，会导致在另一种模式下提交任务失败。

为避免出现如上情况，添加表 21-49 中的配置项，避免两种模式下来回切换参数，提升软件易用性。

- YARN-Cluster 模式下，优先使用新增配置项的值，即服务端路径和参数。
- YARN-Client 模式下，直接使用原有的三个配置项的值。

  原有的三个配置项为：“spark.driver.extraClassPath”、“spark.driver.extraJavaOptions”、“spark.driver.extraLibraryPath”。

说明

不添加表 21-49 中配置项时，使用方式与原有方式一致，程序可正常执行，只是在不同模式下需切换配置。

配置参数

参数入口：

在 Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，在搜索框中输入参数名称。

表21-49 参数介绍

参数	描述	默认值
spark.yarn.cluster.driver.extraClassPath	YARN-Cluster 模式下，Driver 使用的 extraClassPath，配置为服务端的路径和参数。 同时，“spark.driver.extraClassPath”配置成 Spark 客户端路径，可以保证在 YARN-Client 模式下和 YARN-Cluster 模式下不需要切换配置。	${BIGDATA_HOME}/common/runtime/security
spark.yarn.cluster.driver.extraJavaOptions	YARN-Cluster 模式下 Driver 的 extraJavaOptions，配置成服务端的路径和参数。 同时，“spark.driver.extraJavaOptions”配置成 Spark 客户端路径，可以保证 YARN-Client 模式和 YARN-Cluster 模式不需要切换配置。	-Xloggc:<LOG_DIR>/indexserver-%p-gc.log -XX:+PrintGCDetails -XX:-OmitStackTraceInFastThrow -XX:+PrintGCTimeStamps -XX:+PrintGCDateStamps -XX:+UseGCLogFileRotation -XX:NumberOfGCLogFiles=20 -XX:GCLogFileSize=10M -Dlog4j.configuration=./__spark_conf__/__hadoop_conf__/log4j-executor.properties -Dlog4j.configuration.watch=true -Djava.security.auth.login.config=./__spark_conf__/__hadoop_conf__/jaas-zk.conf -Dzookeeper.server.principal=${ZOOKEEPER_SERVER_PRINCIPAL} -Djava.security.krb5.conf=./__spark_conf__/__hadoop_conf__/kdc.conf -Djetty.version=x.y.z -Dorg.xerial.snappy.tempdir=${BIGDATA_HOME}/tmp -Dcarbon.properties.filepath=./__spark_conf__/__hadoop_conf__/carbon.properties -Djdk.tls.ephemeralDHKeySize=2048 -Dspark.ssl.keyStore=./child.keystore #{java_stack_prefer}

21.2.7.9 配置 SparkSQL 的分块个数

配置场景

SparkSQL 在进行 shuffle 操作时默认的分块数为 200。在数据量特别大的场景下，使用默认的分块数就会造成单个数据块过大。如果一个任务产生的单个 shuffle 数据块大于 2G，该数据块在被 fetch 的时候还会报类似错误：

```
Adjusted frame length exceeds 2147483647: 2717729270 - discarded
```

例如，SparkSQL 运行 TPCDS 500G 的测试时，使用默认配置出现错误。所以当数据量较大时需要适当的调整该参数。

配置参数

参数入口：

在 Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”。在搜索框中输入参数名称。

表21-50 参数介绍

参数	描述	默认值
spark.sql.shuffle.partitions	SparkSQL 在进行 shuffle 操作时默认的分块数。	200

21.2.7.10 配置 parquet 表的压缩格式

配置场景

当前版本对于 parquet 表的压缩格式分以下两种情况进行配置：

1. 对于分区表，需要通过 parquet 本身的配置项“parquet.compression”设置 parquet 表的数据压缩格式。如在建表语句中设置 tblproperties："parquet.compression"="snappy"。
2. 对于非分区表，需要通过“spark.sql.parquet.compression.codec”配置项来设置 parquet 类型的数据压缩格式。直接设置“parquet.compression”配置项是无效的，因为它会读取“spark.sql.parquet.compression.codec”配置项的值。当“spark.sql.parquet.compression.codec”未做设置时默认值为“snappy”，“parquet.compression”会读取该默认值。

因此，“spark.sql.parquet.compression.codec”配置项只适用于设置非分区表的 parquet 压缩格式。

配置参数

参数入口：

在 Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，在搜索框中输入参数名称。

表21-51 参数介绍

参数	描述	默认值
spark.sql.parquet.compression.codec	对于非分区 parquet 表，设置其存储文件的压缩格式。	snappy

21.2.7.11 配置 WebUI 上显示的 Lost Executor 信息的个数

配置场景

Spark WebUI 中“Executor”页面支持展示 Lost Executor 的信息，对于 JDBCServer 长任务来说，Executor 的动态回收是常态，Lost Executor 个数太多，会撑爆“Executor”页面，因此需要控制页面显示的 Lost Executor 个数。

配置描述

在 Spark 客户端的“spark-defaults.conf”配置文件中进行设置。

表21-52 参数说明

参数	说明	默认值
spark.ui.retainedDeadExecutors	Spark UI 页面显示的 Lost Executor 的最大个数。	100

21.2.7.12 动态设置日志级别

配置场景

在某些场景下，当任务已经启动后，用户想要修改日志级别以定位问题或者查看想要的信息。

用户可以在进程启动前，在进程的 JVM 参数中增加参数“-Dlog4j.configuration.watch=true”来打开动态设置日志级别的功能。进程启动后，就可以通过修改进程对应的 log4j 配置文件，来调整日志打印级别。

目前支持动态设置日志级别功能的有：Driver 日志、Executor 日志、AM 日志、JobHistory 日志、JDBCServer 日志。

允许设置的日志级别是：FATAL，ERROR，WARN，INFO，DEBUG，TRACE 和 ALL。

配置描述

在进程对应的 JVM 参数配置项中增加以下参数。

表21-53 参数描述

参数	描述	默认值
-Dlog4j.configuration.watch	进程 JVM 参数，设置成“true”用于打开动态设置日志级别功能。	未配置，即为 false。

Driver、Executor、AM 进程的 JVM 参数如表 21-54 所示。在 Spark 客户端的配置文件“spark-defaults.conf”中进行配置。Driver、Executor、AM 进程的日志级别在对应的 JVM 参数中的“-Dlog4j.configuration”参数指定的 log4j 配置文件中设置。

表21-54 进程的 JVM 参数 1

参数	说明	默认日志级别
spark.driver.extraJavaOptions	Driver 的 JVM 参数。	INFO
spark.executor.extraJavaOptions	Executor 的 JVM 参数。	INFO
spark.yarn.am.extraJavaOptions	AM 的 JVM 参数。	INFO

JobHistory Server 和 JDBCServer 的 JVM 参数如表 21-55 所示。在服务端配置文件“ENV_VARS”中进行配置。JobHistory Server 和 JDBCServer 的日志级别在服务端配置文件“log4j.properties”中设置。

表21-55 进程的 JVM 参数 2

参数	说明	默认日志级别
GC_OPTS	JobHistory Server 的 JVM 参数。	INFO
SPARK_SUBMIT_OPTS	JDBCServer 的 JVM 参数。	INFO

示例：

为了动态修改 Executor 日志级别为 DEBUG，在进程启动之前，修改“spark-defaults.conf”文件中的 Executor 的 JVM 参数“spark.executor.extraJavaOptions”，增加如下配置：

```
-Dlog4j.configuration.watch=true
```

提交用户应用后，修改“spark.executor.extraJavaOptions”中“-Dlog4j.configuration”参数指定的 log4j 日志配置文件（例如：“-Dlog4j.configuration=file:${BIGDATA_HOME}/FusionInsight_Spark2x_xxx/install/FusionInsight-Spark2x-*/spark/conf/log4j-executor.properties”）中的日志级别为 DEBUG，如下所示：

```
log4j.rootCategory=DEBUG, sparklog
```

DEBUG 级别生效会有一定的时延。

21.2.7.13 配置 Spark 是否获取 HBase Token

配置场景

使用 Spark 提交任务时，Driver 默认会去 HBase 获取 Token，访问 HBase 则需要配置文件“jaas.conf”进行安全认证。此时若用户未配置“jaas.conf”文件，会导致应用运行失败。

因此，根据应用是否涉及 HBase 进行以下处理：

- 当应用不涉及 HBase 时，即无需获取 HBase Token。此时，将“spark.yarn.security.credentials.hbase.enabled”设置为“false”即可。
- 当应用涉及 HBase 时，将“spark.yarn.security.credentials.hbase.enabled”设置为“true”，且需要在 Driver 端配置“jaas.conf”文件，配置如下：

```
{client}/spark/bin/spark-sql  --master yarn-client --principal {principal} --
keytab {keytab} --driver-java-options "-
Djava.security.auth.login.config={LocalPath}/jaas.conf"
```

在“jaas.conf”中指定 Keytab 和 Prinical，示例如下：

```
Client {
com.sun.security.auth.module.Krb5LoginModule required
useKeyTab=true
keyTab = "{LocalPath}/user.keytab"
principal="super@<系统域名>"
useTicketCache=false
debug=false;
};
```

配置描述

在 Spark 客户端的“spark-defaults.conf”配置文件中进行设置。

表21-56 参数说明

参数	说明	默认值
spark.yarn.security.credentials.hbase.enabled	HBase 是否获取 Token： • true：获取 • false：不获取	false

21.2.7.14 配置 Kafka 后进先出

配置场景

当 Spark Streaming 应用与 Kafka 对接，Spark Streaming 应用异常终止并从 checkpoint 恢复重启后，对于进入 Kafka 数据的任务，系统默认优先处理应用终止前（A 段时间）未完成的任务和应用终止到重启完成这段时间内（B 段时间）进入 Kafka 数据生成的任务，最后再处理应用重启完成后（C 段时间）进入 Kafka 数据生成的任务。并且对于 B 段时间进入 Kafka 的数据，Spark 将按照终止时间（batch 时间）生成相应个

数的任务，其中第一个任务读取全部数据，其余任务可能不读取数据，造成任务处理压力不均匀。

若 A 段时间的任务和 B 段时间任务处理得较慢，则会影响 C 段时间任务的处理。针对上述场景，Spark 提供 Kafka 后进先出功能。

图21-5 Spark Streaming 应用重启时间轴

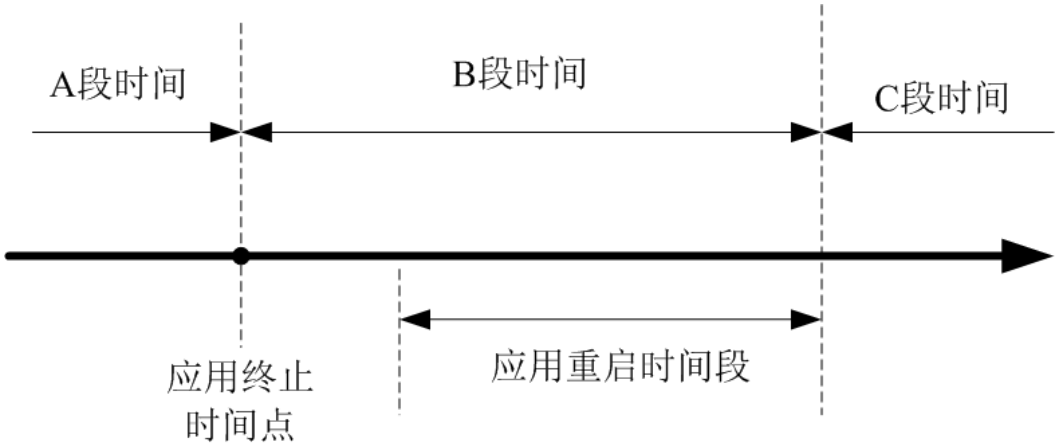

开启此功能后，Spark 将优先调度 C 段时间内的任务，若存在多个 C 段任务，则按照任务产生的先后顺序调度执行，再执行 A 段时间和 B 段时间的任务。另外，对于 B 段时间进入 Kafka 的数据，Spark 除了按照终止时间生成相应任务，还将这个期间进入 Kafka 的所有数据均匀分配到各个任务，避免任务处理压力不均匀。

约束条件：

- 目前该功能只适用于 Spark Streaming 中的 Direct 方式，且执行结果与上一个 batch 时间处理结果没有依赖关系（即无 state 操作，如 updatestatebykey）。对多条数据输入流，需要相对独立无依赖的状态，否则可能导致数据切分后结果发生变化。
- Kafka 后进先出功能的开启要求应用只能对接 Kafka 输入源。
- 若提交应用的同时开启 Kafka 后进先出和流控功能，对于 B 段时间进入 Kafka 的数据，将不启动流控功能，以确保读取这些数据的任务调度优先级最低。应用重新启动后 C 段时间的任务启用流控功能。

配置描述

在 Spark Driver 端的“spark-defaults.conf”配置文件中进行设置。

表21-57 参数说明

参数	说明	默认值
spark.streaming.kafka.direct.lifo	配置是否开启 Kafka 后进先出功能。	false
spark.streaming.kafka010.inputstream.class	获取解耦在 FusionInsight 侧的类	org.apache.spark.streaming.kafka010.xxDirectKafkaInp

参数	说明	默认值
		utDStream

21.2.7.15 配置对接 Kafka 可靠性

配置场景

Spark Streaming 对接 Kafka 时，当 Spark Streaming 应用重启后，应用根据上一次读取的 topic offset 作为起始位置和当前 topic 最新的 offset 作为结束位置从 Kafka 上读取数据的。

Kafka 服务的 topic 的 leader 异常后，若 Kafka 的 leader 和 follower 的 offset 相差太大，用户重启 Kafka 服务，Kafka 的 follower 和 leader 相互切换，则 Kafka 服务重启后，topic 的 offset 变小。

- 若 Spark Streaming 应用一直在运行，由于 Kafka 上 topic 的 offset 变小，会导致读取 Kafka 数据的起始位置比结束位置大，这样将无法从 Kafka 读取数据，应用报错。
- 若在重启 Kafka 服务前，先停止 Spark Streaming 应用，等 Kafka 重启后，再重启 Spark Streaming 应用使应用从 checkpoint 恢复。此时，Spark Streaming 应用会记录终止前读取到的 offset 位置，以此为基准读取后面的数据，而 Kafka offset 变小（例如从 10 万变成 1 万），Spark Streaming 会等待 Kafka leader 的 offset 增长至 10 万之后才会去消费，导致新发送的 offset 在 1 万至 10 万之间的数据丢失。

针对上述背景，提供配置 Streaming 对接 Kafka 更高级别的可靠性。对接 Kafka 可靠性功能开启后，上述场景处理方式如下。

- 若 Spark Streaming 应用在运行应用时 Kafka 上 topic 的 offset 变小，则会将 Kafka 上 topic 最新的 offset 作为读取 Kafka 数据的起始位置，继续读取后续的数据。

  对于已经生成但未调度处理的任务，若读取的 Kafka offset 区间大于 Kafka 上 topic 的最新 offset，则该任务会运行失败。

  说明

  若任务失败过多，则会将 executor 加入黑名单，从而导致后续的任务无法部署运行。此时用户可以通过配置“spark.blacklist.enabled”参数关闭黑名单功能，黑名单功能默认为开启。

- 若 Kafka 上 topic 的 offset 变小后，Spark Streaming 应用进行重启恢复终止前未处理完的任务若读取的 Kafka offset 区间大于 Kafka 上 topic 的最新 offset，则该任务直接丢弃，不进行处理。

  说明

  若 Streaming 应用中使用了 state 函数，则不允许开启对接 Kafka 可靠性功能。

配置描述

在 Spark 客户端的“spark-defaults.conf”配置文件中进行设置。

表21-58 参数说明

参数	说明	默认值
spark.streaming.Kafka.reliability	Spark Streaming 对接 Kafka 是否开启可靠性功能： • true：开启可靠性功能 • false：不开启可靠性功能	false

21.2.7.16 配置流式读取 driver 执行结果

配置场景

在执行查询语句时，返回结果有可能会很大（10 万数量以上），此时很容易导致 JDBCServer OOM（Out of Memory）。因此，提供数据汇聚功能特性，在基本不牺牲性能的情况下尽力避免 OOM。

配置描述

提供两种不同的数据汇聚功能配置选项，两者在 Spark JDBCServer 服务端的 tunning 选项中进行设置，设置完后需要重启 JDBCServer。

表21-59 参数说明

参数	说明	默认值
spark.sql.bigdata.thriftServer.useHdfsCollect	是否将结果数据保存到 HDFS 中而不是内存中。 优点：由于查询结果保存在 hdfs 端，因此基本不会造成 JDBCServer 的 OOM。 缺点：速度慢。 • true：保存至 HDFS 中 • false：不使用该功能 须知 spark.sql.bigdata.thriftServer.useHdfsCollect 参数设置为 true 时，将结果数据保存到 HDFS 中，但 JobHistory 原生页面上 Job 的描述信息无法正常关联到对应的 SQL 语句，同时 spark-beeline 命令行中回显的 Execution ID 为 null，为解决 JDBCServer OOM 问题，同时显示信息正确，建议选择 spark.sql.userlocalFileCollect 参数进行配置。	false
spark.sql.uselocalFileCollect	是否将结果数据保存在本地磁盘中而不是内存里面。 优点：结果数据小数据量情况下和原生内存的方式相比性能损失可以忽略，大数据情况下（亿级数据）性能远比使用 hdfs，以及原生内存方式好。 缺点：需要调优。大数据情况下建议 JDBCServer driver 端内存 10G，executor 端每个核心分配 3G 内存。	false

参数	说明	默认值
	• true：使用该功能 • false: 不使用该功能	
spark.sql.collect.Hive	该参数在 spark.sql.uselocalFileCollect 开启的情况下生效。直接序列化的方式，还是间接序列化的方式保存结果数据到磁盘。 优点：针对分区数特别多的表查询结果汇聚性能优于直接使用结果数据保证在磁盘的方式。 缺点：和 spark.sql.uselocalFileCollect 开启时候的缺点一样。 • true：使用该功能 • false：不使用该功能	false
spark.sql.collect.serialize	该参数在 spark.sql.uselocalFileCollect，spark.sql.collect.Hive 同时开启的情况下生效。 作用是进一步提升性能 • java：采用 java 序列化方式收集数据。 • kryo：采用 kryo 序列化方式收集数据，性能要比采用 java 好。	java

说明

参数 spark.sql.bigdata.thriftServer.useHdfsCollect 和 spark.sql.uselocalFileCollect 不能同时设置为 true。

21.2.7.17 配置过滤掉分区表中路径不存在的分区

配置场景

当读取 HIVE 分区表时，如果指定的分区路径在 HDFS 上不存在，则执行 ***select*** 查询时会报 FileNotFoundException 异常。此时可以通过配置“spark.sql.hive.verifyPartitionPath”参数来过滤掉分区路径不存在的分区，来避免读取时报错。

配置描述

可以通过以下两种方式配置是否过滤掉分区表分区路径不存在的分区。

- 在 Spark Driver 端的“spark-defaults.conf”配置文件中进行设置。

表21-60 参数说明

参数	说明	默认值
spark.sql.hive.verifyPartitionPath	配置读取 HIVE 分区表时，是否过滤掉分区表分区路径不存在的分区。	false

参数	说明	默认值
	“true”：过滤掉分区路径不存在的分区； “false”：不进行过滤。	

- 在 spark-submit 命令提交应用时，通过“--conf”参数配置是否过滤掉分区表分区路径不存在的分区。

  示例：

```
spark-submit --class org.apache.spark.examples.SparkPi  --conf
spark.sql.hive.verifyPartitionPath=true $SPARK_HOME/lib/spark-examples_*.jar
```

21.2.7.18 配置 Spark2x Web UI ACL

配置场景

当 Spark2x Web UI 中有一些不允许其他用户看到的数据时，用户可能想对 UI 进行安全防护。用户一旦登录，Spark2x 可以比较与这个用户相对应的视图 ACLs 来确认是否授权用户访问 UI。

Spark2x 存在两种类型的 Web UI，一种为运行中任务的 Web UI，可以通过 Yarn 原生页面的应用链接或者 REST 接口访问。一种为已结束任务的 Web UI，可以通过 Spark2x JobHistory 服务或者 REST 接口访问。

说明

本章节仅支持安全模式（开启了 Kerberos 认证）集群。

- 运行中任务 Web UI ACL 配置。

  运行中的任务，可通过服务端对如下参数进行配置。

  - “spark.admin.acls”：指定 Web UI 的管理员列表。
  - “spark.admin.acls.groups”：指定管理员组列表。
  - “spark.ui.view.acls”：指定 yarn 界面的访问者列表。
  - “spark.modify.acls.groups”：指定 yarn 界面的访问者组列表。
  - “spark.modify.acls”：指定 Web UI 的修改者列表。
  - “spark.ui.view.acls.groups”：指定 Web UI 的修改者组列表。
- 运行结束后 Web UI ACL 配置。

  运行结束的任务通过客户端的参数“spark.history.ui.acls.enable”控制是否开启 ACL 访问权限。

  如果开启了 ACL 控制，由客户端的“spark.admin.acls”和“spark.admin.acls.groups”配置指定 Web UI 的管理员列表和管理员组列表，由客户端的“spark.ui.view.acls”和“spark.modify.acls.groups”配置指定查看 Web UI 任务明细的访问者列表和组列表，由客户端的“spark.modify.acls”和“spark.ui.view.acls.groups”配置指定修改 Web UI 任务明细的访问者列表和组列表。

配置描述

登录 FusionInsight Manager 系统，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索 acl，在对应的 JobHistory，JDBCServer，SparkResource 和 Spark 界面修改以下参数。

表21-61 参数说明

参数	说明	默认值
spark.history.ui.acls.enable	配置 JobHistory 是否支持单一任务的权限校验。	true
spark.acls.enable	配置是否开启 spark 权限管理。 如果开启，将会检查用户是否有权限访问和修改任务信息。	true
spark.admin.acls	配置 spark 管理员列表，列表中成员有权限管理所有 spark 任务，此处可以配置多个管理员用户，使用“，”分隔。	admin
spark.admin.acls.groups	配置 spark 管理组列表，列表中的组有权限管理所有 spark 任务，此处可以配置多个管理组，使用“，”分隔。	-
spark.modify.acls	配置有权限修改 spark 任务的成员列表。启动任务的用户默认有此权限，此处可以配置多个用户，使用“，”分隔。	-
spark.modify.acls.groups	配置有权限修改 spark 任务的组列表，此处可以配置多个组，使用“，”分隔。	-
spark.ui.view.acls	配置有权限访问 spark 任务的成员列表。启动任务的用户默认有此权限，此处可以配置多个用户，使用“，”分隔。	-
spark.ui.view.acls.groups	配置有权限访问 spark 任务的组列表，此处可以配置多个组，使用“，”分隔。	-

说明

若使用客户端提交任务，“spark.admin.acls”、“spark.admin.acls.groups”、“spark.modify.acls”、“spark.modify.acls.groups”、“spark.ui.view.acls”和“spark.ui.view.acls.groups”参数修改后需要重新下载客户端。

21.2.7.19 配置矢量化读取 ORC 数据

配置场景

ORC 文件格式是一种 Hadoop 生态圈中的列式存储格式，它最初产生自 Apache Hive，用于降低 Hadoop 数据存储空间和加速 Hive 查询速度。和 Parquet 文件格式类似，它并

不是一个单纯的列式存储格式，仍然是首先根据行组分割整个表，在每一个行组内按列进行存储，并且文件中的数据尽可能的压缩来降低存储空间的消耗。矢量化读取ORC 格式的数据能够大幅提升 ORC 数据读取性能。在 Spark2.3 版本中，SparkSQL 支持矢量化读取 ORC 数据（这个特性在 Hive 的历史版本中已经得到支持）。矢量化读取ORC 格式的数据能够获得比传统读取方式数倍的性能提升。

该特性可以通过下面的配置项开启：

- “spark.sql.orc.enableVectorizedReader”：指定是否支持矢量化方式读取 ORC 格式的数据，默认为 true。
- “spark.sql.codegen.wholeStage”：指定是否需要将多个操作的所有 stage 编译为一个 java 方法，默认为 true。
- “spark.sql.codegen.maxFields”：指定 codegen 的所有 stage 所支持的最大字段数（包括嵌套字段），默认为 100。
- “spark.sql.orc.impl”：指定使用 Hive 还是 Spark SQL native 作为 SQL 执行引擎来读取 ORC 数据，默认为 hive。

配置参数

登录 FusionInsight Manager 系统，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索以下参数。

参数	说明	默认值	取值范围
spark.sql.orc.enableVectorizedReader	指定是否支持矢量化方式读取 ORC 格式的数据，默认为 true。	true	[true,false]
spark.sql.codegen.wholeStage	指定是否需要将多个操作的所有 stage 编译为一个 java 方法，默认为 true。	true	[true,false]
spark.sql.codegen.maxFields	指定 codegen 的所有 stage 所支持的最大字段数（包括嵌套字段），默认为 100.	100	大于 0
spark.sql.orc.impl	指定使用 Hive 还是 Spark SQL native 作为 SQL 执行引擎来读取 ORC 数据，默认为 hive。	hive	[hive,native]

说明

1. 使用 SparkSQL 内置的矢量化方式读取 ORC 数据需要满足下面的条件：

- spark.sql.orc.enableVectorizedReader : true，默认是 true，一般不做修改。
- spark.sql.codegen.wholeStage : true，默认为 true，一般不做修改。
- spark.sql.codegen.maxFields 不小于 scheme 的列数。
- 所有的数据类型均为 AtomicType 类型；所谓 Atomic Type 表示非 NULL、UDTs、arrays，maps 类型。如果列中存在这几种类型的任意一种，都无法获得预期的性能。
- spark.sql.orc.impl : native ,默认为 hive。

2. 若使用客户端提交任务，“spark.sql.orc.enableVectorizedReader”、“spark.sql.codegen.wholeStage”、“spark.sql.codegen.maxFields”、“spark.sql.orc.impl”、参数修改后需要重新下载客户端才能生效。

21.2.7.20 Hive 分区修剪的谓词下推增强

配置场景

在旧版本中，对 Hive 表的分区修剪的谓词下推，只支持列名与整数或者字符串的比较表达式的下推，在 2.3 版本中，增加了对 null、in、and、or 表达式的下推支持。

配置参数

登录 FusionInsight Manager 系统，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索以下参数。

参数	说明	默认值	取值范围
spark.sql.hive.advancedPartitionPredicatePushdown.enabled	用于配置是否开启 Hive 表的分区谓词下推增强功能。	true	[true,false]

21.2.7.21 支持 Hive 动态分区覆盖语义

配置场景

在旧版本中，使用 insert overwrite 语法覆写分区表时，只支持对指定的分区表达式进行匹配，未指定表达式的分区将被全部删除。在 spark2.3 版本中，增加了对未指定表达式的分区动态匹配的支持，此种语法与 Hive 的动态分区匹配语法行为一致。

配置参数

登录 FusionInsight Manager 系统，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索以下参数。

参数	说明	默认值	取值范围
spark.sql.sources.partitionOverwriteMode	当前执行 insert overwrite 命令插入数据到分区表时，支持两种模式：STATIC 模式和 DYNAMIC 模式。STATIC 模式下，Spark 会按照匹配条件删除所有分区。在 DYNAMIC 模式下，Spark 按照匹配条件匹配分区，并动态匹配没有指定匹配条件的分区。	STATIC	[STATIC,DYNAMIC]

21.2.7.22 配置列统计值直方图 Histogram 用以增强 CBO 准确度

配置场景

Spark 优化 sql 的执行，一般的优化规则都是启发式的优化规则，启发式的优化规则，仅仅根据逻辑计划本身的特点给出优化，没有考虑数据本身的特点，也就是未考虑算子本身的执行代价。Spark 在 2.2 中引入了基于代价的优化规则（CBO）。CBO 会收集表和列的统计信息，结合算子的输入数据集来估计每个算子的输出条数以及字节大小，这些就是执行一个算子的代价。

CBO 会调整执行计划，来最小化端到端的查询时间，中心思路 2 点：

- 尽早过滤不相关的数据。
- 最小化每个算子的代价。

CBO 优化过程分为 2 步：

1. 收集统计信息。
2. 根据输入的数据集估算特定算子的输出数据集。

表级别统计信息包括：记录条数；表数据文件的总大小。

列级别统计信息包括：唯一值个数；最大值；最小值；空值个数；平均长度；最大长度；直方图。

有了统计信息后，就可以估计算子的执行代价了。常见的算子包括过滤条件 Filter 算子和 Join 算子。

直方图为列统计值的一种，可以直观的描述列数据的分布情况，将列的数据从最小值到最大值划分为事先指定数量的槽位（bin），计算各个槽位的上下界的值，使得全部数据都确定槽位后，所有槽位中的数据数量相同（等高直方图）。有了数据的详细分布后，各个算子的代价估计能更加准确，优化效果更好。

该特性可以通过下面的配置项开启：

spark.sql.statistics.histogram.enabled：指定是否开启直方图功能，默认为 false。

配置参数

登录 FusionInsight Manager 系统，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索以下参数。

参数	说明	默认值	取值范围
spark.sql.cbo.enabled	开启 CBO 来估计执行计划的统计值。	false	[true,false]
spark.sql.cbo.joinReorder.enabled	开启 CBO 连接重排序。	false	[true,false]
spark.sql.cbo.joinReorder.dp.threshold	动态规划算法中允许的最大的 join 节点数量。	12	>=1
spark.sql.cbo.joinReord	在重连接执行计划代价比较	0.7	0-1

参数	说明	默认值	取值范围
er.card.weight	中维度（行数）所占的比重：行数 * 比重 + 文件大小 *（1 - 比重）。		
spark.sql.statistics.size.autoUpdate.enabled	开启当表的数据发生变化时，自动更新表的大小信息。注意如果表的数据文件总数量非常多时，这个操作会非常耗费资源，减慢对数据的操作速度。	false	[true,false]
spark.sql.statistics.histogram.enabled	开启后，当统计列信息时，会生成直方图。直方图可以提高估计准确度，但是收集直方图信息会有额外工作量。	false	[true,false]
spark.sql.statistics.histogram.numBins	生成的直方图的槽位数。	254	>=2
spark.sql.statistics.ndv.maxError	在生成列级别统计信息时，HyperLogLog++算法允许的最大估计误差。	0.05	0-1
spark.sql.statistics.percentile.accuracy	在生成等高直方图时百分位估计的准确率。该值越大意味着越准确。估计错误值可以通过（1.0 / 百分位估计的准确率）来得到。	10000	>=1

说明

- 如果希望直方图可以在 CBO 中生效，需要满足下面的条件：
- spark.sql.statistics.histogram.enabled : true，默认是 false，修改为 true 开启直方图功能。
- spark.sql.cbo.enabled : true，默认为 false，修改为 true 开启 CBO。
- spark.sql.cbo.joinReorder.enabled : true，默认为 false，修改为 true 开启连接重排序。
- 若使用客户端提交任务，“spark.sql.cbo.enabled”、“spark.sql.cbo.joinReorder.enabled”、“spark.sql.cbo.joinReorder.dp.threshold”、“spark.sql.cbo.joinReorder.card.weight”、“spark.sql.statistics.size.autoUpdate.enabled”、“spark.sql.statistics.histogram.enabled”、“spark.sql.statistics.histogram.numBins”、“spark.sql.statistics.ndv.maxError”、“spark.sql.statistics.percentile.accuracy”参数修改后需要重新下载客户端才能生效。

21.2.7.23 配置 JobHistory 本地磁盘缓存

配置场景

JobHistory 可使用本地磁盘缓存 spark 应用的历史数据，以防止 JobHistory 内存中加载大量应用数据，减少内存压力，同时该部分缓存数据可以复用以提高后续对相同应用的访问速度。

配置参数

登录 FusionInsight Manager 系统，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索以下参数。

参数	说明	默认值
spark.history.store.path	JobHistory 缓存历史信息的本地目录，如果设置了此配置，则 JobHistory 会将历史应用数据缓存在本地磁盘而不是内存中	${BIGDATA_HOME}/tmp/spark2x_JobHistory
spark.history.store.maxDiskUsage	JobHistory 本地磁盘缓存的最大可用空间	10g

21.2.7.24 配置 Spark SQL 开启 Adaptive Execution 特性

配置场景

Spark SQL Adaptive Execution 特性用于使 Spark SQL 在运行过程中，根据中间结果优化后续执行流程，提高整体执行效率。当前已实现的特性如下：

1. 自动设置 shuffle partition 数

   在启用 Adaptive Execution 特性前，Spark SQL 根据 spark.sql.shuffle.partitions 配置指定 shuffle 时的 partition 个数。此种方法在一个应用中执行多种 SQL 查询时缺乏灵活性，无法保证所有场景下的性能更优。开启 Adaptive Execution 后，Spark SQL 将自动为每个 shuffle 过程动态设置 partition 个数，而不是使用通用配置，使每次 shuffle 过程自动使用最合理的 partition 数。

2. 动态调整执行计划

   在启用 Adaptive Execution 特性前，Spark SQL 根据 RBO 和 CBO 的优化结果创建执行计划，此种方法忽略了数据在运行过程中的结果集变化。比如基于某个大表创建的视图，与其他大表 join 时，即便视图的结果集很小，也无法将执行计划调整为 BroadcastJoin。启用 Adaptive Execution 特性后，Spark SQL 能够在运行过程中根据前面 stage 的运行结果动态调整后续的执行计划，从而获得更好的执行性能。

3. 自动处理数据倾斜

   在执行 SQL 语句时，若存在数据倾斜，可能导致单个 executor 内存溢出、任务执行缓慢等问题。启动 Adaptive Execution 特性后，Spark SQL 能自动处理数据倾斜

场景，对倾斜的分区，启动多个 task 进行处理，每个 task 读取若干个 shuffle 输出文件，再对这部分任务的 Join 结果进行 Union 操作，以达到消除数据倾斜的效果

配置参数

登录 FusionInsight Manager 系统，选择“集群 > 服务 > Spark2x > 配置”，单击“全部配置”，搜索以下参数。

参数	说明	默认值
spark.sql.adaptive.enabled	配置是否启用自适应执行功能。 注意：AQE 特性与 DPP（动态分区裁剪）特性同时开启时，SparkSQL 任务执行中会优先执行 DPP 特性，从而使得 AQE 特性不生效。	false
spark.sql.optimizer.dynamicPartitionPruning.enabled	动态分区裁剪功能的开关。	true
spark.sql.adaptive.coalescePartitions.enabled	如果配置为 true 并且“spark.sql.adaptive.enabled”为 true，Spark 将根据目标大小（由 spark.sql.adaptive.advisoryPartitionSizeInBytes 指定）合并连续的随机播放分区，以避免执行过多的小任务。	true
spark.sql.adaptive.coalescePartitions.initialPartitionNum	合并之前的 shuffle 分区的初始数量，默认等于 spark.sql.shuffle.partitions。只有当 spark.sql.adaptive.enabled 和 spark.sql.adaptive.coalescePartitions.enabled 都为 true 时，该配置才有效。创建时可选，初始分区数必须为正数。	200
spark.sql.adaptive.coalescePartitions.minPartitionNum	合并后的最小 shuffle 分区数。如果不设置，默认为 Spark 集群的默认并行度。只有当 spark.sql.adaptive.enabled 和 spark.sql.adaptive.coalescePartitions.enable 都为 true 时，该配置才有效。创建时可选，最小分区数必须为正数。	1
spark.sql.adaptive.shuffle.targetPostShuffleInputSize	shuffle 后单个分区的目标大小，从 Spark3.0 开始不再支持。	64MB
spark.sql.adaptive.advisoryPartitionSizeInBytes	自适应优化时（spark.sql.adaptive.enabled 为 true 时）shuffle 分区的咨询大小（单位：字节），在 Spark 聚合小 shuffle 分区或拆分倾斜的 shuffle 分区时生效。	64MB
spark.sql.adaptive.fetchShuffleBlocksInBatch	是否批量取连续的 shuffle 块。对于同一个 map 任务，批量读取连续的 shuffle 块可以减少 IO，提高性能，而不是逐个读取块。注意，只有当	true

参数	说明	默认值
	spark.sql.adaptive.enabled 和 spark.sql.adaptive.coalescePartitions.enabled 都为 true 时，单次读取请求中存在多个连续块。这个特性还依赖于一个可重定位的序列化器，使用的级联支持编解码器和新版本的 shuffle 提取协议。	
spark.sql.adaptive.localShuffleReader.enabled	当“true”且 spark.sql.adaptive.enabled 为“true”时，Spark 在不需要进行 shuffle 分区时，会尝试使用本地 shuffle reader 读取 shuffle 数据，例如：将 sort-merge join 转换为 broadcast-hash join 后。	true
spark.sql.adaptive.skewJoin.enabled	当此配置为 true 且 spark.sql.adaptive.enabled 设置为 true 时，启用运行时自动处理 join 运算中的数据倾斜功能	true
spark.sql.adaptive.skewJoin.skewedPartitionFactor	此配置为一个倍数因子，用于判定分区是否为数据倾斜分区。单个分区被判定为数据倾斜分区的条件为：当一个分区的数据大小超过除此分区外其他所有分区大小的中值与该配置的乘积，并且大小超过 spark.sql.adaptive.skewJoin.skewedPartitionThresholdInBytes 配置值时，此分区被判定为数据倾斜分区	5
spark.sql.adaptive.skewJoin.skewedPartitionThresholdInBytes	分区大小（单位：字节）大于该阈值且大于 spark.sql.adaptive.skewJoin.skewedPartitionFactor 与分区中值的乘积，则认为该分区存在倾斜。理想情况下，此配置应大于 spark.sql.adaptive.advisoryPartitionSizeInBytes.	256MB
spark.sql.adaptive.nonEmptyPartitionRatioForBroadcastJoin	两表进行 join 操作的时候，当非空分区比率低于此配置时，无论其大小如何，都不会被视为自适应执行中广播哈希连接的生成端。只有当 spark.sql.adaptive.enabled 为 true 时，此配置才有效。	0.2

21.2.7.25 配置 eventlog 日志回滚

配置场景

当 Spark 开启事件日志模式，即设置“spark.eventLog.enabled”为“true”时，就会往配置的一个日志文件中写事件，记录程序的运行过程。当程序运行很久，job 很多，task 很多时就会造成日志文件很大，如 JDBCServer、Spark Streaming 程序。

而日志回滚功能是指在写事件日志时，将元数据事件（EnviromentUpdate，BlockManagerAdded，BlockManagerRemoved，UnpersistRDD，ExecutorAdded，ExecutorRemoved，MetricsUpdate，ApplicationStart，ApplicationEnd，LogStart）写入日志文件中，Job 事件（StageSubmitted， StageCompleted， TaskResubmit，TaskStart，TaskEnd， TaskGettingResult， JobStart，JobEnd）按文件的大小进行决定是否写入新的日志文件。对于 Spark SQL 的应用，Job 事件还包含 ExecutionStart、ExecutionEnd。

Spark 中有个 HistoryServer 服务，其 UI 页面就是通过读取解析这些日志文件获得的。在启动 HistoryServer 进程时，内存大小就已经定了。因此当日志文件很大时，加载解析这些文件就可能会造成内存不足，driver gc 等问题。

所以为了在小内存模式下能加载较大日志文件，需要对大应用开启日志滚动功能。一般情况下，长时间运行的应用建议打开该功能。

配置参数

登录 FusionInsight Manager 系统，选择“集群 > 服务 > Spark2x > 配置”，单击“全部配置”，搜索以下参数。

参数	说明	默认值
spark.eventLog.rolling.enabled	是否启用滚动 event log 文件。如果设置为 true，则会将每个 event log 文件缩减到配置的大小。	true
spark.eventLog.rolling.maxFileSize	当 spark.eventlog.rolling.enabled=true 时，指定要滚动的 event log 文件的最大大小。	128M
spark.eventLog.compression.codec	用于压缩事件日志的编码解码器。默认情况下，spark 提供四种编码解码器：lz4、lzf、snappy 和 zstd。如果没有给出，将使用 spark.io.compression.codec。	无
spark.eventLog.logStageExecutorMetrics	是否将 executor metrics 的每个 stage 峰值（针对每个 executor）写入 event log。	false

21.2.7.26 配置 Drop Partition 命令支持批量删除

说明

本章节仅适用于 MRS 3.2.0 及之后版本。

配置场景

当前 Spark 中 Drop Partition 命令只支持等号来删除分区，配置该参数后可以支持多种过滤条件来批量删除，如'<'，'<='，'>'，'>='，'!>'，'!<'。

配置参数

登录 FusionInsight Manager 系统，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，搜索以下参数。

参数	说明	默认值
spark.sql.dropPartitionsInBatch.enabled	配置为 true 后，使用 Drop Partition 命令支持使用如下过滤条件，如'<'，'<='，'>'，'>='，'!>'，'!<'。	true
spark.sql.dropPartitionsInBatch.limit	支持批量删除的最大分区数。	1000

21.2.7.27 配置 Executor 退出时执行自定义代码

说明

本章节仅适用于 MRS 3.2.0 及之后版本。

配置场景

通过配置如下参数可以实现 Executor 退出时执行自定义代码。

配置参数

在 Spark 客户端的“spark-defaults.conf”配置文件中进行设置。

参数	说明	默认值
spark.executor.execute.shutdown.cleaner	配置为 true 后，支持 executor 退出时执行自定义代码。	false
spark.executor.execute.shutdown.cleaner.max.timeout	executor 执行自定义代码的超时时间。	240s

21.2.7.28 配置 Structured Streaming 使用 RocksDB 做状态存储

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

配置场景

当大量的状态信息存储在默认的 HDFSBackedStateStore，导致 JVM GC 占用大量时间时，可以通过如下配置，选择 RocksDB 作为状态后端。

配置参数

在 Spark 客户端的“spark-defaults.conf”配置文件中进行设置。

参数	说明	默认值
spark.sql.streaming.stateStore.providerClass	用于管理有状态流查询中的状态数据的类。此类必须是 StateStoreProvider 的子类，并且必须具有零参数构造函数。 配置参数值为 org.apache.spark.sql.execution.streaming.state.RocksDBStateStoreProvider 即可选择 RocksDB 作为状态后端。	org.apache.spark.sql.execution.streaming.state.HDFSBackedStateStoreProvider

21.2.7.29 配置 Spark Native 引擎

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

配置场景

Spark Native 引擎是通过使用向量化的 C++加速库，实现对 Spark 算子性能加速的一种技术方案。传统的 SparkSQL 是基于行式数据，通过 JVM 的 codegen 来实现查询加速的，由于 JVM 对生成的 java 代码存在各种约束，比如方法长度，参数个数等，以及行式数据对内存带宽的利用率不足，因此存在性能提升空间。使用成熟的向量化的 c++加速库后，数据采用向量化格式存在内存中，可以提高带宽利用率，并通过批量的列数处理获得加速效果。

通过开启 Spark Native 引擎特性，获得 SparkSQL 的性能加速。

使用约束

- Scan 算子当前支持的数据类型为：Boolean、Integer、Long、Float、Double、String、Date、Decimal
- 支持的数据格式：parquet、orc
- 支持的文件系统：obs、hdfs
- 支持的机型： AMD64、ARM
- 支持的场景：spark-sql 模式

配置参数

1. 在 Spark 客户端的“*{客户端安装目录}*/Spark/spark/conf/spark-defaults.conf”配置文件中进行设置，修改如下参数：

参数	说明	默认值
spark.plugins	Spark 用到的插件，参数值设置为 io.glutenproject.GlutenPlugin。 **说明** 如果已经配置了 spark.plugins，则可以将 io.glutenproject.GlutenPlugin 加到其中，用逗号","隔开。	空
spark.memory.offHeap.enabled	设置为 true，Native 加速需要用到 JVM 的 off memory。	false
spark.memory.offHeap.size	设置 offHeap 内存的大小，根据实际情况设置，初始可设置为 1G。	-1
spark.yarn.dist.files	此参数用于将 libch.so 和 libjsig.so 分发到所有节点上，以便所有节点上的 executors 使用 spark.executorEnv.LD_PRELOAD 参数提前加载。 • x86 平台上参数值设置为：{客户端安装目录}/Spark/spark/native/libch.so,{客户端安装目录}/JDK/jdk1.8.0_372/jre/lib/amd64/libjsig.so • arm 平台上参数值设置为：{客户端安装目录}/Spark/spark/native/libch.so,{客户端安装目录}/JDK/jdk1.8.0_372/jre/lib/aarch64/libjsig.so **说明** 如果已经配置了 spark.yarn.dist.files，则可以将上述参数加到其中，用逗号“,”隔开。 此处需要与 2 中 spark-env.sh 中 export LD_PRELOAD 使用同一路径下的 libch.so 和 libjsig.so。	无
spark.executorEnv.LD_PRELOAD	为 executor 设置环境变量 LD_PRELOAD 设置为$PWD/libch.so	无

参数	说明	默认值
	$PWD/libjsig.so 说明 此参数用于 executor 提前加载 libch.so 和 libjsig.so，如果已经配置了 spark.executorEnv.LD_PRELOAD，则可以将上述参数加到其中，用空格隔开。	
spark.gluten.sql.columnar.libpath	Native 加速库的服务端路径，非镜像场景时该文件并不存在。设置为空	集群中的 spark 安装目录下，例如：${BIGDATA_HOME}/FusionInsight_Spark_xxx/install/FusionInsight-Spark-*/spark/native/libch.so
spark.sql.orc.impl	native：orc 读取使用 Spark 原生的 orc 实现。 hive：使用 Hive 的 orc 相关实现。 设置为 native	hive
spark.gluten.sql.columnar.scanOnly	是否仅开启 scan 加速。 设置为 true，开启 scanOnly 模式。	false

2. 在 Spark 客户端的“*{客户端安装目录}*/Spark/spark/conf/spark-env.sh”配置文件中进行设置。
   - X86 平台参数如下：

     export LD_PRELOAD="{客户端安装目录}/Spark/spark/native/libch.so {客户端安装目录}/JDK/jdk1.8.0_372/jre/lib/amd64/libjsig.so"
   - ARM 平台参数如下：

     export LD_PRELOAD="{客户端安装目录}/Spark/spark/native/libch.so {客户端安装目录}/JDK/jdk1.8.0_372/jre/lib/aarch64/libjsig.so"

     注意：此处需要与表中 spark.yarn.dist.files 参数使用同一路径下的 libch.so 和 libjsig.so，多个 so 间用空格隔开，前后需要加上双引号。

21.2.7.30 配置小文件自动合并

说明

本章节仅适用于 MRS 3.3.0 及之后版本。

配置场景

小文件自动合并特性开启后，Spark 将数据先写入临时目录，再去检测每个分区的平均文件大小是否小于 16MB（默认值）。如果发现平均文件大小小于 16MB，则认为分区下有小文件，Spark 会启动一个 Job 合并这些小文件，并将合并后的大文件写入到最终的表目录下。

使用约束

- 写入表的类型为：Hive、Datasource
- 支持的数据格式：parquet、orc

配置参数

在 Spark 客户端的“*{客户端安装目录}*/Spark/spark/conf/spark-defaults.conf”配置文件中进行设置，修改如下参数：

参数	说明	默认值
spark.sql.mergeSmallFiles.enabled	设置为 true，Spark 写入目标表时会判断是否写入了小文件，如果发现有小文件，则会启动合并小文件的 job。	false
spark.sql.mergeSmallFiles.threshold.avgSize	如果某个分区的平均文件大小小于该值，则启动小文件合并。	16MB
spark.sql.mergeSmallFiles.maxSizePerTask	合并后的每个文件大小目标大小。	256MB
spark.sql.mergeSmallFiles.moveParallelism	当不需要合并小文件后时，将临时文件移动到最终目录的并行度。	10000

21.2.8 使用 Ranger 时适配第三方 JDK

配置场景

当使用 Ranger 作为 spark sql 的权限管理服务时，访问 RangerAdmin 需要使用集群中的证书。若用户未使用集群中的 JDK 或者 JRE，而是使用第三方 JDK 时，会出现访问 RangerAdmin 失败，进而 spark 应用程序启动失败的问题。

在这个场景下，需要进行以下操作，将集群中的证书导入第三方 JDK 或者 JRE 中。

配置方法

导出集群中的证书：

1. 安装集群客户端，例如安装路径为“/opt/client”。

2. 执行以下命令，切换到客户端安装目录。

   cd /opt/client

3. 执行以下命令配置环境变量。

   source bigdata_env

4. 生成证书文件

   keytool -export -alias fusioninsightsubroot -storepass changeit -keystore /opt/client/JRE/jre/lib/security/cacerts -file fusioninsightsubroot.crt

步骤 1 将集群中的证书导入第三方 JDK 或者 JRE 中

将步骤 1 中生成的 **fusioninsightsubroot.crt** 文件拷贝到第三方 JRE 节点上，设置好该节点的 JAVA_HOME 环境变量后，执行以下命令导入证书：

keytool -import -trustcacerts -alias fusioninsightsubroot -storepass changeit -file fusioninsightsubroot.crt -keystore MY_JRE/lib/security/cacerts

说明

'MY_JRE'表示第三方 JRE 安装路径，请自行修改。

----结束

21.3 Spark2x 日志介绍

日志描述

日志存储路径：

- Executor 运行日志：“${BIGDATA_DATA_HOME}/hadoop/data${i}/nm/containerlogs/application_${appid}/container_{$contid}”

说明

运行中的任务日志存储在以上路径中，运行结束后会基于 Yarn 的配置确定是否汇聚到 HDFS 目录中，详情请参见 23.1 Yarn 常用参数。

- 其他日志：“/var/log/Bigdata/spark2x”

日志归档规则：

- 使用 yarn-client 或 yarn-cluster 模式提交任务时，Executor 日志默认 50MB 滚动存储一次，最多保留 10 个文件，不压缩。
- JobHistory2x 日志默认 100MB 滚动存储一次，最多保留 100 个文件，压缩存储。
- JDBCServer2x 日志默认 100MB 滚动存储一次，最多保留 100 个文件，压缩存储。
- IndexServer2x 日志默认 100MB 滚动存储一次，最多保留 100 个文件，压缩存储。
- JDBCServer2x 审计日志默认 20MB 滚动存储一次，最多保留 20 个文件，压缩存储。
- 日志大小和压缩文件保留个数可以在 FusionInsight Manager 界面中配置。

表21-62 Spark2x 日志列表

日志类型	日志文件名	描述
SparkResource2x 日志	spark.log	Spark2x 服务初始化日志。
	prestart.log	prestart 脚本日志。
	cleanup.log	安装卸载实例时的清理日志。
	spark-availability-check.log	Spark2x 服务健康检查日志。
	spark-service-check.log	Spark2x 服务检查日志
JDBCServer2x 日志	JDBCServer-start.log	JDBCServer2x 启动日志。
	JDBCServer-stop.log	JDBCServer2x 停止日志。
	JDBCServer.log	JDBCServer2x 运行时，Driver 端日志。
	jdbc-state-check.log	JDBCServer2x 健康检查日志。
	jdbcserver-omm-pid***-gc.log.*.current	JDBCServer2x 进程 gc 日志。
	spark-omm-org.apache.spark.sql.hive.thriftserver.HiveThriftProxyServer2-***.out*	JDBCServer2x 进程启动信息日志。若进程停止，会打印 jstack 信息。
JobHistory2x 日志	jobHistory-start.log	JobHistory2x 启动日志。
	jobHistory-stop.log	JobHistory2x 停止日志。
	JobHistory.log	JobHistory2x 运行过程日志。
	jobhistory-omm-pid***-gc.log.*.current	JobHistory2x 进程 gc 日志。
	spark-omm-org.apache.spark.deploy.history.HistoryServer-***.out*	JobHistory2x 进程启动信息日志。若进程停止，会打印 jstack 信息。
IndexServer2x 日志	IndexServer-start.log	IndexServer2x 启动日志。
	IndexServer-stop.log	IndexServer2x 停止日志。
	IndexServer.log	IndexServer2x 运行时，Driver 端日志。
	indexserver-state-check.log	IndexServer2x 健康检查日志。
	indexserver-omm-pid***-gc.log.*.current	IndexServer2x 进程 gc 日志。
	spark-omm-org.apache.spark.sql.hive.thri	IndexServer2x 进程启动信息日志。若进程停止，会打印 jstack

日志类型	日志文件名	描述
	ftserver.IndexServerProxy-***.out*	信息。
审计日志	jdbcserver-audit.log ranger-audit.log	JDBCServer2x 审计日志。

日志级别

Spark2x 中提供了如表 21-63 所示的日志级别。日志级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG。程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表21-63 日志级别

级别	描述
ERROR	ERROR 表示当前时间处理存在错误信息。
WARN	WARN 表示当前事件处理存在异常信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

说明

默认情况下配置 Spark2x 日志级别不需要重启服务。

登录 FusionInsight Manager 系统。

步骤 2 选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”。

步骤 3 单击“全部配置”。

步骤 4 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 5 选择所需修改的日志级别。

步骤 6 单击“保存”，然后单击“确定”，成功后配置生效。

----结束

日志格式

表21-64 日志格式

日志类型	格式	示例

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log中的 message>|<日志事件的发生位置>	2014-09-22 11:16:23,980 INFO DAGScheduler: Final stage: Stage 0(reduce at SparkPi.scala:35)

21.4 获取运行中 Spark 应用的 Container 日志

运行中 Spark 应用的 Container 日志分散在多个节点中，本章节用于说明如何快速获取 Container 日志。

场景说明

可以通过 yarn logs 命令获取运行在 Yarn 上的应用的日志，针对不同的场景，可以使用以下命令获取需要的日志：

1. 获取 application 的完整日志：**yarn logs --applicationId** <*appId*> **-out** <*outputDir*>

   例如：**yarn logs --applicationId application_1574856994802_0016 -out /opt/test**

   执行结果：

   a. 若该 application 处于运行状态，则无法获取 dead 状态的 container 日志

   b. 若该 application 处于结束状态，则可以获取全部归档的 container 日志

2. 获取指定 Container 日志：**yarn logs -applicationId** <*appId*> **-containerId** <*containerId*>

   例如：**yarn logs -applicationId application_1574856994802_0018 -containerId container_e01_1574856994802_0018_01_000003**

   执行结果：

   a. 若该 application 处于运行状态，则无法获取 dead 状态的 Container 日志

   b. 若该 application 处于结束状态，则可获取任意 Container 的日志

3. 获取任意状态的 Container 日志：**yarn logs -applicationId** <*appId*> **-containerId** <*containerId*> **-nodeAddress** <*nodeAddress*>

   例如：**yarn logs -applicationId application_1574856994802_0019 -containerId container_e01_1574856994802_0019_01_000003 -nodeAddress 192-168-1-1:**8041

   执行结果：可获取任意 Container 的日志

   说明

   此命令的参数中需要填入 nodeAddress，可通过以下命令获取：

   yarn node -list -all

21.5 小文件合并工具

工具介绍

在 Hadoop 大规模生产集群中，由于 HDFS 的元数据都保存在 NameNode 的内存中，集群规模受制于 NameNode 单点的内存限制。如果 HDFS 中有大量的小文件，会消耗 NameNode 大量内存，还会大幅降低读写性能，延长作业运行时间。因此，小文件问题是制约 Hadoop 集群规模扩展的关键问题。

本工具主要有如下两个功能：

1. 扫描表中有多少低于用户设定阈值的小文件，返回该表目录中所有数据文件的平均大小。
2. 对表文件提供合并功能，用户可设置合并后的平均文件大小。

支持的表类型

Spark：Parquet、ORC、CSV、Text、Json。

Hive：Parquet、ORC、CSV、Text、RCFile、Sequence、Bucket。

说明

1. 数据有压缩的表在执行合并后会采用 Spark 默认的压缩格式-Snappy。可以通过在客户端设置“spark.sql.parquet.compression.codec”（可选：uncompressed, gzip, snappy）和 "spark.sql.orc.compression.codec"（可选：uncompressed, zlib, lzo, snappy）来选择 Parquet 和 Orc 表的压缩格式；由于 Hive 和 Spark 表在可选的压缩格式上有区别，除以上列出的压缩格式外，其他的压缩格式不支持。
2. 合并桶表数据，需要先在 Spark2x 客户端的 hive-site.xml 里加上配置：

```
<property>
<name>hive.enforce.bucketing</name>
<value>false</value>
</property>
<property>
<name>hive.enforce.sorting</name>
<value>false</value>
</property>
```

3. Spark 暂不支持 Hive 的加密列特性。

工具使用

下载安装客户端，例如安装目录为“/opt/client”。进入“/opt/client/Spark2x/spark/bin”，执行 mergetool.sh 脚本。

加载环境变量

source /opt/client/bigdata_env

source /opt/client/Spark2x/component_env

扫描功能

命令形式： **sh mergetool.sh scan <db.table> <filesize>**

db.table 的形式是“数据库名.表名”，filesize 为用户自定义的小文件阈值（单位 MB），返回结果为小于该阈值的文件个数，及整个表目录数据文件的平均大小。

例如：**sh mergetool.sh scan default.table1 128**

合并功能

命令形式： **sh mergetool.sh merge <db.table> <filesize> <shuffle>**

db.table 的形式是“数据库名.表名”，filesize 为用户自定义的合并后平均文件大小（单位 MB），shuffle 是一个 boolean 值，取值 true/false，作用是设置合并过程中是否允许数据进行 shuffle。

例如：**sh mergetool.sh merge default.table1 128 false**

提示如下，则操作成功：

```
SUCCESS: Merge succeeded
```

说明

1. 请确保当前用户对合并的表具有 owner 权限。
2. 合并前请确保 HDFS 上有足够的存储空间，至少需要被合并表大小的一倍以上。
3. 合并表数据的操作需要单独进行，在此过程中读表，可能临时出现找不到文件的问题，合并完成后会恢复正常；另外在合并过程中请注意不要对相应的表进行写操作，否则可能会产生数据一致性问题。
4. 若合并完成后，在一直处于连接状态的 spark-beeline/spark-sql session 中查询分区表的数据，出现文件不存在的问题，根据提示可以执行"refresh table 表名"后再重新查询。
5. 请依据实际情况合理设置 filesize 值，例如可以在 scan 得到表中平均文件大小值 average 后，在 merge 时将 filesize 设置一个比 average 更大的值；否则，执行合并后可能出现文件数变得更多的情况。
6. 合并过程中，会将原表数据放入回收站，再填入已合并的数据。若在此过程中发生异常，根据工具提示，可将 trash 目录中的数据通过 hdfs 的 mv 命令恢复。
7. 在 HDFS router 联邦场景下，如果表的根路径与根路径“/user”的目标 NameService 不同，在二次合并时需要手动清理放入回收站的原表文件，否则会导致合并失败。
8. 此工具应用客户端配置，需要做性能调优可修改客户端配置文件的相关配置。

shuffle 设置

对于合并功能，可粗略估计合并前后分区数的变化：

一般来说，旧分区数>新分区数，可设置 shuffle 为 false；但如果旧分区远大于新分区数，例如高于 100 倍以上，可以考虑设置 shuffle 为 true，增加并行度，提高合并的速度。

须知

- 设置 shuffle 为 true（repartition），会有性能上的提升；但是由于 Parquet 和 Orc 存储方式的特殊性，repartition 会使压缩率变小，直接表现是 hdfs 上表的总大小会增大到 1.3 倍。
- 设置 shuffle 为 false（coalesce），合并后的大小不会非常平均，可能会分布在设置的 filesize 左右。

日志存放位置

默认日志存放位置为/tmp/SmallFilesLog.log4j，如需自定义日志存放位置，可在/opt/client/Spark2x/spark/tool/log4j.properties 中配置 log4j.appender.logfile.File。

21.6 Spark 中使用代理用户提交 Spark 任务

说明

本章节仅适用 MRS 3.3.0 及之后版本。

场景说明

提交 Spark 任务时，用户可以使用当前实际运行用户提交任务，也可以使用代理用户提交任务。本章节介绍如何开启代理用户提交任务。

前提条件

创建用户，登录 FusionInsight Manager 页面，选择“系统 > 权限 > 用户”，单击“添加用户”，创建用户 test（实际运行用户）和 test1（代理用户）用户，用户组选择 hadoop、hive 和 supergroup，主组选择 hadoop。

在 spark-beeline 中使用代理用户提交 Spark 任务

修改 JDBCServer 实例配置，登录 FusionInsight Manager 页面，选择“集群 > 服务 > Spark > 配置 > 全部配置 > JDBCServer（角色） > 自定义”在参数“spark.core-site.customized.configs”中添加如下自定义参数：

参数名称	值
hadoop.proxyuser.*test*.hosts	*
hadoop.proxyuser.*test*.groups	*

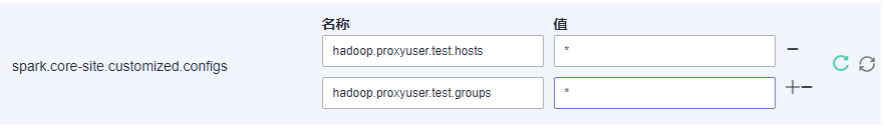

说明

- 配置中的 test 是实际运行用户。
- 参数“hadoop.proxyuser.test.hosts”值为“*”：表示 test 用户连接后，可以使用任意代理用户，不限制集群节点。
- 参数“hadoop.proxyuser.test.groups”值为“*”：表示 test 用户连接后，可以使用任意代理用户，不限制代理用户所在的用户组。

步骤 1 修改如下参数值，切换 JDBCServer 实例至多实例模式：

参数名称	值
spark.scheduler.allocation.file	#{conf_dir}/fairscheduler.xml
spark.thriftserver.proxy.enabled	false

步骤 2 保存配置，重启 Spark 服务。

步骤 3 登录 Spark 客户端节点，执行如下命令：

cd *客户端安装目录*

source bigdata_env

source Spark/component_env

安全模式执行以下命令，普通模式无需执行：

kinit test，输入密码完成认证（首次登录需要修改密码）

步骤 4 使用 Spark 的 beeline 命令提交任务：

cd /opt/client/Spark/spark/bin

./beeline

!connect jdbc:hive2://*Zookeeper 实例所在节点 IP*:*Zookeeper Client 的端口*,*Zookeeper 实例所在节点 IP*:*Zookeeper Client 的端口*,*Zookeeper 实例所在节点 IP*:*Zookeeper Client 的端口*
/;serviceDiscoveryMode=zooKeeper;zooKeeperNamespace=sparkthriftserver;saslQop=auth-conf;auth=KERBEROS;principal=spark2x/hadoop.hadoop.com@HADOOP.COM;hive.server2.proxy.user=*test1*

其中：

- Zookeeper 实例所在节点 IP：在 FusionInsight Manager 页面，选择“集群 > 服务 > Zookeeper > 实例”，即可查看 Zookeeper 实例节点 IP。
- Zookeeper Client 的端口：在 FusionInsight Manager 页面，选择“集群 > 服务 > Zookeeper > 配置> 全部配置”，搜索参数“clientPort”即可查看 Zookeeper Client 的端口。
- hive.server2.proxy.user=test1 ：test1 为代理用户

```
[root@192-168-20-215 bin]# ./beeline
Beeline version 3.1.0-h0.cbu.mrs.321.r1-SNAPSHOT by Apache Hive
beeline> !connect jdbc:hive2://192-168-20-37:24002,192-168-20-225:24002,192-168-20-215:24002/;serviceDiscoveryMode=zooKeeper;zooKeeperNamespace=sparkthriftse
M;hive.server2.proxy.user=test1;
Connecting to jdbc:hive2://192-168-20-37:24002,192-168-20-225:24002,192-168-20-215:24002/;serviceDiscoveryMode=zooKeeper;zooKeeperNamespace=sparkthriftserver2
ve.server2.proxy.user=test1;
Connected to: Spark SQL (version 3.1.1-h0.cbu.mrs.321.r1-SNAPSHOT)
Running with YARN Application = application_1671764848872_0011
Driver: Hive JDBC (version 3.1.0-h0.cbu.mrs.321.r1-SNAPSHOT)
Transaction isolation: TRANSACTION_REPEATABLE_READ
0: jdbc:hive2://192-168-20-225:22550/>
```

步骤 5 创建 Spark 表：

create table *sparktest1***(a string,b int);**

查看新创建的表：

desc formatted *sparktest1***;**

```
0: jdbc:hive2://192-168-20-225:22550/> create table sparktest1(a string,b int);
+---------+
| Result  |
+---------+
+---------+
No rows selected (3.702 seconds)
0: jdbc:hive2://192-168-20-225:22550/> desc formatted sparktest1;
+-------------------------------+----------------------------------------------------------------+----------+
|           col_name            |                           data_type                            | comment  |
+-------------------------------+----------------------------------------------------------------+----------+
| a                             | string                                                         | NULL     |
| b                             | int                                                            | NULL     |
|                               |                                                                |          |
| # Detailed Table Information  |                                                                |          |
| Database                      | default                                                        |          |
| Table                         | sparktest1                                                     |          |
| Owner                         | test1                                                          |          |
| Created Time                  | Fri Dec 23 16:16:55 CST 2022                                   |          |
| Last Access                   | UNKNOWN                                                        |          |
| Created By                    | Spark 3.1.1-h0.cbu.mrs.321.r1-SNAPSHOT                         |          |
| Type                          | MANAGED                                                        |          |
| Provider                      | hive                                                           |          |
| Table Properties              | [transient_lastDdlTime=1671783415]                             |          |
| Location                      | hdfs://hacluster/user/hive/warehouse/sparktest1                |          |
| Serde Library                 | org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe             |          |
| InputFormat                   | org.apache.hadoop.mapred.TextInputFormat                       |          |
| OutputFormat                  | org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat     |          |
| Storage Properties            | [serialization.format=1]                                       |          |
| Partition Provider            | Catalog                                                        |          |
+-------------------------------+----------------------------------------------------------------+----------+
19 rows selected (0.945 seconds)
```

可以看到表的 owner 为代理用户 test1，使用代理用户成功。

----结束

在 spark-sql 和 spark-submit 中使用代理用户提交 Spark 任务

修改 HDFS 实例配置，登录 FusionInsight Manager 页面，选择“集群 > 服务 > HDFS > 配置 > 全部配置 > HDFS（服务）> 自定义”在参数“hdfs.core-site.customized.configs”中添加如下自定义参数，保存配置。

参数名称	值
hadoop.proxyuser.*test*.hosts	*
hadoop.proxyuser.*test*.groups	*

步骤 1 修改 Yarn 实例配置，登录 FusionInsight Manager 页面，选择“集群 > 服务 > Yarn > 配置 > 全部配置 > Yarn（服务） > 自定义”在参数“yarn.core-site.customized.configs”中添加如下自定义参数，保存配置。

参数名称	值
hadoop.proxyuser.*test*.hosts	*

参数名称	值
hadoop.proxyuser.*test*.groups	*

步骤 2 修改 SparkReource 实例配置，登录 FusionInsight Manager 页面，选择“集群 > 服务 > Spark > 配置 > 全部配置 > SparkResource（角色） > 自定义”在参数“spark.core-site.customized.configs”中添加如下自定义参数，保存配置。

参数名称	值
hadoop.proxyuser.*test*.hosts	*
hadoop.proxyuser.*test*.groups	*

步骤 3 修改 Hive 实例配置，登录 FusionInsight Manager 页面，选择“集群 > 服务 > Hive > 配置 > 全部配置 > Hive（服务） > 自定义”在参数“core.site.customized.configs”中添加如下自定义参数，保存配置。

参数名称	值
hadoop.proxyuser.*test*.hosts	*
hadoop.proxyuser.*test*.groups	*

步骤 4 重启 HDFS、Yarn、Spark、Hive 服务，并更新客户端 HDFS、Yarn、Spark、Hive 配置文件。

步骤 5 登录 Spark 客户端节点，执行如下命令：

cd *客户端安装目录*

source bigdata_env

source Spark/component_env

安全模式执行以下命令，普通模式无需执行：

kinit test，输入密码完成认证（首次登录需要修改密码）

步骤 6 提交 spark-sql 任务：

spark-sql --master yarn --proxy-user *test1*

步骤 7 创建 Spark 表：

create table *sparktest2***(a string,b int);**

查看新创建的表：

desc formatted *sparktest2***;**

```
spark-sql>
         > create table sparktest2(a string,b int);
2022-12-24 15:56:04,119 | WARN  | main | The enable mv value "null" is invalid. Using the de
2022-12-24 15:56:04,134 | WARN  | main | The value "LOCALLOCK" configured for key carbon.loc
igureLockType(CarbonProperties.java:444)
2022-12-24 15:56:05,493 | WARN  | main | A Hive serde table will be created as there is no t
rg.apache.spark.sql.catalyst.analysis.ResolveSessionCatalog.logWarning(Logging.scala:69)
Time taken: 2.845 seconds
spark-sql> desc formatted sparktest2;
a       string  NULL
b       int     NULL

# Detailed Table Information
Database        default
Table   sparktest2
Owner   test1
Created Time    Sat Dec 24 15:56:06 CST 2022
Last Access     UNKNOWN
Created By      Spark 3.1.1-h0.cbu.mrs.321.r1-SNAPSHOT
Type    MANAGED
Provider        hive
Table Properties        [transient_lastDdlTime=1671868566]
Location        hdfs://hacluster/user/hive/warehouse/sparktest2
Serde Library   org.apache.hadoop.hive.serde2.lazy.LazySimpleSerDe
InputFormat     org.apache.hadoop.mapred.TextInputFormat
OutputFormat    org.apache.hadoop.hive.ql.io.HiveIgnoreKeyTextOutputFormat
Storage Properties      [serialization.format=1]
Partition Provider      Catalog
Time taken: 0.859 seconds, Fetched 19 row(s)
spark-sql>
```

可以看到表的 owner 为代理用户 test1，使用代理用户成功。

步骤 8 使用重新下发的客户端提交 spark-submit 任务：

spark-submit --master yarn --class org.apache.spark.examples.SparkPi --master yarn-client --proxy-user *test1* **/opt/client/Spark/spark/examples/jars/spark-examples_*.jar**

```
[root@192-168-20-215 conf]# spark-submit --master yarn --class org.apache.spark.examples.SparkPi --master yarn-client --proxy-user test1 ../examples/jars/spark-examples_*.jar
2022-12-24 15:58:37,540 | WARN  | main | The configuration key 'spark.yarn.access.hadoopFileSystems' has been deprecated as of Spark 3.0 and may be removed in the future. Please
ad. | org.apache.spark.SparkConf.logWarning(Logging.scala:69)
2022-12-24 15:58:37,542 | WARN  | main | The configuration key 'spark.yarn.kerberos.relogin.period' has been deprecated as of Spark 3.0 and may be removed in the future. Please u
pache.spark.SparkConf.logWarning(Logging.scala:69)
2022-12-24 15:58:37,543 | WARN  | main | The configuration key 'spark.executor.plugins' has been deprecated as of Spark 3.0.0 and may be removed in the future. Feature replaced w
spark.SparkConf.logWarning(Logging.scala:69)
2022-12-24 15:58:37,544 | WARN  | main | The configuration key 'spark.reducer.maxReqSizeShuffleToMem' has been deprecated as of Spark 2.3 and may be removed in the future. Please
```

步骤 9 查看 yarn 中运行的 application 信息：

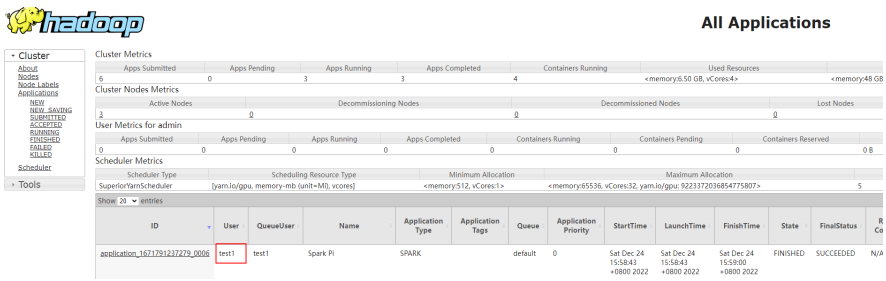

可以看到任务的运行用户为 test1，使用代理用户成功。

----结束

21.7 CarbonData 首查优化工具

工具介绍

CarbonData 的首次查询较慢，对于实时性要求较高的节点可能会造成一定的时延。

本工具主要提供以下功能：

- 对查询时延要求较高的表进行首次查询预热。

工具使用

下载安装客户端，例如安装目录为“/opt/client”。进入 目录“/opt/client/Spark2x/spark/bin”，执行 **start-prequery.sh**。

参考表 21-65，配置 prequeryParams.properties。

表21-65 参数列表

参数	说明	示例
spark.prequery.period.max.minute	预热的最大时长，单位分钟	60
spark.prequery.tables	表名配置 database.table:int，表名支持通配符*，int 代表预热多长时间内有更新的表，单位为天。	default.test*:10
spark.prequery.maxThreads	预热时并发的最大线程数	50
spark.prequery.sslEnable	集群安全模式为 true，非安全模式为 false	true
spark.prequery.driver	JDBCServer 的地址 ip:port，如需要预热多个 Server 则需填写多个 Server 的 IP,多个 IP:port 用逗号隔开。	192.168.0.2:22550
spark.prequery.sql	预热的 sql 语句，不同语句冒号隔开	SELECT COUNT(*) FROM %s;SELECT * FROM %s LIMIT 1
spark.security.url	安全模式下 jdbc 所需 url	;saslQop=auth-conf;auth=KERBEROS;principal=spark2x/hadoop.hadoop.com@HADOOP.COM;

说明

spark.prequery.sql 配置的语句在每个所预热的表中都会执行，表名用%s 代替。

脚本使用

命令形式：**sh start-prequery.sh**

执行此条命令需要：将 user.keytab 或 jaas.conf（二选一），krb5.conf（必须）放入 conf 目录中。

说明

- 此工具暂时只支持 Carbon 表。
- 此工具会初始化 Carbon 环境和预读取表的元数据到 JDBCServer，所以更适合在多主实例、静态分配模式下使用。

21.8 Spark2x 性能调优

21.8.1 Spark Core 调优

21.8.1.1 数据序列化

操作场景

Spark 支持两种方式的序列化 ：

- Java 原生序列化 JavaSerializer
- Kryo 序列化 KryoSerializer

序列化对于 Spark 应用的性能来说，具有很大的影响。在特定的数据格式的情况下，KryoSerializer 的性能可以达到 JavaSerializer 的 10 倍以上，而对于一些 Int 之类的基本类型数据，性能的提升就几乎可以忽略。

KryoSerializer 依赖 Twitter 的 Chill 库来实现，相对于 JavaSerializer，主要的问题在于不是所有的 Java Serializable 对象都能支持，兼容性不好，所以需要手动注册类。

序列化功能用在两个地方：序列化任务和序列化数据。Spark 任务序列化只支持 JavaSerializer，数据序列化支持 JavaSerializer 和 KryoSerializer。

操作步骤

Spark 程序运行时，在 shuffle 和 RDD Cache 等过程中，会有大量的数据需要序列化，默认使用 JavaSerializer，通过配置让 KryoSerializer 作为数据序列化器来提升序列化性能。

在开发应用程序时，添加如下代码来使用 KryoSerializer 作为数据序列化器。

- 实现类注册器并手动注册类。

```
package com.etl.common;

import com.esotericsoftware.kryo.Kryo;
import org.apache.spark.serializer.KryoRegistrator;

public class DemoRegistrator implements KryoRegistrator
{
    @Override
    public void registerClasses(Kryo kryo)
    {
        //以下为示例类，请注册自定义的类
        kryo.register(AggrateKey.class);
        kryo.register(AggrateValue.class);
```

```
    }
}
```

您可以在 Spark 客户端对 spark.kryo.registrationRequired 参数进行配置，设置是否需要 Kryo 注册序列化。

当参数设置为 true 时，如果工程中存在未被序列化的类，则会抛出异常。如果设置为 false（默认值），Kryo 会自动将未注册的类名写到对应的对象中。此操作会对系统性能造成影响。设置为 true 时，用户需手动注册类，针对未序列化的类，系统不会自动写入类名，而是抛出异常，相对比 false，其性能较好。

- 配置 KryoSerializer 作为数据序列化器和类注册器。

```
val conf = new SparkConf()
conf.set("spark.serializer", "org.apache.spark.serializer.KryoSerializer")
.set("spark.kryo.registrator", "com.etl.common.DemoRegistrator")
```

21.8.1.2 配置内存

操作场景

Spark 是内存计算框架，计算过程中内存不够对 Spark 的执行效率影响很大。可以通过监控 GC（Garbage Collection），评估内存中 RDD 的大小来判断内存是否变成性能瓶颈，并根据情况优化。

监控节点进程的 GC 情况（在客户端的 conf/spark-default.conf 配置文件中，在 spark.driver.extraJavaOptions 和 spark.executor.extraJavaOptions 配置项中添加参数："-verbose:gc -XX:+PrintGCDetails -XX:+PrintGCTimeStamps"

），如果频繁出现 Full GC，需要优化 GC。把 RDD 做 Cache 操作，通过日志查看 RDD 在内存中的大小，如果数据太大，需要改变 RDD 的存储级别来优化。

操作步骤

- 优化 GC，调整老年代和新生代的大小和比例。在客户端的 conf/spark-default.conf 配置文件中，在 spark.driver.extraJavaOptions 和 spark.executor.extraJavaOptions 配置项中添加参数：-XX:NewRatio。如，" -XX:NewRatio=2"，则新生代占整个堆空间的 1/3，老年代占 2/3。
- 开发 Spark 应用程序时，优化 RDD 的数据结构。
  - 使用原始类型数组替代集合类，如可使用 fastutil 库。
  - 避免嵌套结构。
  - Key 尽量不要使用 String。
- 开发 Spark 应用程序时，建议序列化 RDD。

  RDD 做 cache 时默认是不序列化数据的，可以通过设置存储级别来序列化 RDD 减小内存。例如：

```
testRDD.persist(StorageLevel.MEMORY_ONLY_SER)
```

21.8.1.3 设置并行度

操作场景

并行度控制任务的数量，影响 shuffle 操作后数据被切分成的块数。调整并行度让任务的数量和每个任务处理的数据与机器的处理能力达到更优。

查看 CPU 使用情况和内存占用情况，当任务和数据不是平均分布在各节点，而是集中在个别节点时，可以增大并行度使任务和数据更均匀的分布在各个节点。增加任务的并行度，充分利用集群机器的计算能力，一般并行度设置为集群 CPU 总和的 2-3 倍。

操作步骤

并行度可以通过如下三种方式来设置，用户可以根据实际的内存、CPU、数据以及应用程序逻辑的情况调整并行度参数。

- 在会产生 shuffle 的操作函数内设置并行度参数，优先级最高。

  ```
  testRDD.groupByKey(24)
  ```

- 在代码中配置“spark.default.parallelism”设置并行度，优先级次之。

  ```
  val conf = new SparkConf()
  conf.set("spark.default.parallelism", 24)
  ```

- 在“$SPARK_HOME/conf/spark-defaults.conf”文件中配置“spark.default.parallelism”的值，优先级最低。

  ```
  spark.default.parallelism    24
  ```

21.8.1.4 使用广播变量

操作场景

Broadcast（广播）可以把数据集合分发到每一个节点上，Spark 任务在执行过程中要使用这个数据集合时，就会在本地查找 Broadcast 过来的数据集合。如果不使用 Broadcast，每次任务需要数据集合时，都会把数据序列化到任务里面，不但耗时，还使任务变得很大。

1. 每个任务分片在执行中都需要同一份数据集合时，就可以把公共数据集 Broadcast 到每个节点，让每个节点在本地都保存一份。
2. 大表和小表做 join 操作时可以把小表 Broadcast 到各个节点，从而就可以把 join 操作转变成普通的操作，减少了 shuffle 操作。

操作步骤

在开发应用程序时，添加如下代码，将“testArr”数据广播到各个节点。

```
def main(args: Array[String]) {
  ...
  val testArr: Array[Long] = new Array[Long](200)
  val testBroadcast: Broadcast[Array[Long]] = sc.broadcast(testArr)
  val resultRdd: RDD[Long] = inpputRdd.map(input => handleData(testBroadcast,
input))
  ...
```

```
}

def handleData(broadcast: Broadcast[Array[Long]], input: String) {
  val value = broadcast.value
  ...
}
```

21.8.1.5 使用 External Shuffle Service 提升性能

操作场景

Spark 系统在运行含 shuffle 过程的应用时，Executor 进程除了运行 task，还要负责写 shuffle 数据以及给其他 Executor 提供 shuffle 数据。当 Executor 进程任务过重，导致触发 GC（Garbage Collection）而不能为其他 Executor 提供 shuffle 数据时，会影响任务运行。

External shuffle Service 是长期存在于 NodeManager 进程中的一个辅助服务。通过该服务来抓取 shuffle 数据，减少了 Executor 的压力，在 Executor GC 的时候也不会影响其他 Executor 的任务运行。

操作步骤

登录 FusionInsight Manager 系统。

步骤 1 选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”。单击“全部配置”。

步骤 2 选择“SparkResource2x > 默认”，修改以下参数：

表21-66 参数列表

参数	默认值	修改结果
spark.shuffle.service.enabled	false	true

步骤 3 重启 Spark2x 服务，配置生效。

说明

如果需要在 Spark2x 客户端用 External Shuffle Service 功能，需要重新下载并安装 Spark2x 客户端。

----结束

21.8.1.6 Yarn 模式下动态资源调度

操作场景

对于 Spark 应用来说，资源是影响 Spark 应用执行效率的一个重要因素。当一个长期运行的服务（比如 JDBCServer），若分配给它多个 Executor，可是却没有任何任务分配给

它，而此时有其他的应用却资源紧张，这就造成了很大的资源浪费和资源不合理的调度。

动态资源调度就是为了解决这种场景，根据当前应用任务的负载情况，实时的增减 Executor 个数，从而实现动态分配资源，使整个 Spark 系统更加健康。

操作步骤

需要先配置 External shuffle service。

步骤 1 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置 > 全部配置”。在搜索框中输入“spark.dynamicAllocation.enabled”参数名称，将参数的值设置为“true”，表示开启动态资源调度功能。默认情况下关闭此功能。

----结束

下面是一些可选配置，如表 21-67 所示。

表21-67 动态资源调度参数

配置项	说明	默认值
spark.dynamicAllocation.minExecutors	最小 Executor 个数。	0
spark.dynamicAllocation.initialExecutors	初始 Executor 个数。	0
spark.dynamicAllocation.maxExecutors	最大 Executor 个数。	2048
spark.dynamicAllocation.schedulerBacklogTimeout	调度第一次超时时间。	1s
spark.dynamicAllocation.sustainedSchedulerBacklogTimeout	调度第二次及之后超时时间。	1s
spark.dynamicAllocation.executorIdleTimeout	普通 Executor 空闲超时时间。	60s
spark.dynamicAllocation.cachedExecutorIdleTimeout	含有 cached blocks 的 Executor 空闲超时时间。	• JDBCServer2x：2147483647s • IndexServer2x：2147483647s • SparkResource2x：120

说明

使用动态资源调度功能，必须配置 External Shuffle Service。

21.8.1.7 配置进程参数

操作场景

Spark on Yarn 模式下，有 Driver、ApplicationMaster、Executor 三种进程。在任务调度和运行的过程中，Driver 和 Executor 承担了很大的责任，而 ApplicationMaster 主要负责 container 的启停。

因而 Driver 和 Executor 的参数配置对 Spark 应用的执行有着很大的影响意义。用户可通过如下操作对 Spark 集群性能做优化。

操作步骤

配置 Driver 内存。

Driver 负责任务的调度，和 Executor、AM 之间的消息通信。当任务数变多，任务平行度增大时，Driver 内存都需要相应增大。

您可以根据实际任务数量的多少，为 Driver 设置一个合适的内存。

- 将“spark-defaults.conf”中的“spark.driver.memory”配置项设置为合适大小。
- 在使用 spark-submit 命令时，添加“--driver-memory MEM”参数设置内存。

步骤 1 配置 Executor 个数。

每个 Executor 每个核同时能跑一个 task，所以增加了 Executor 的个数相当于增大了任务的并发度。在资源充足的情况下，可以相应增加 Executor 的个数，以提高运行效率。

- 将“spark-defaults.conf”中的“spark.executor.instance”配置项或者“spark-env.sh”中的“SPARK_EXECUTOR_INSTANCES”配置项设置为合适大小。
- 在使用 spark-submit 命令时，添加“--num-executors NUM”参数设置 Executor 个数。

步骤 2 配置 Executor 核数。

每个 Executor 多个核同时能跑多个 task，相当于增大了任务的并发度。但是由于所有核共用 Executor 的内存，所以要在内存和核数之间做好平衡。

- 将“spark-defaults.conf”中的“spark.executor.cores”配置项或者“spark-env.sh”中的“SPARK_EXECUTOR_CORES”配置项设置为合适大小。
- 在使用 spark-submit 命令时，添加“--executor-cores NUM”参数设置核数。

步骤 3 配置 Executor 内存。

Executor 的内存主要用于任务执行、通信等。当一个任务很大的时候，可能需要较多资源，因而内存也可以做相应的增加；当一个任务较小运行较快时，就可以增大并发度减少内存。

- 将“spark-defaults.conf”中的“spark.executor.memory”配置项或者“spark-env.sh”中的“SPARK_EXECUTOR_MEMORY”配置项设置为合适大小。
- 在使用 spark-submit 命令时，添加“--executor-memory MEM”参数设置内存。

----结束

示例

- 在执行 spark wordcount 计算中。1.6T 数据，250 个 executor。

  在默认参数下执行失败，出现 Futures timed out 和 OOM 错误。

  因为数据量大，task 数多，而 wordcount 每个 task 都比较小，完成速度快。当 task 数多时 driver 端相应的一些对象就变大了，而且每个 task 完成时 executor 和 driver 都要通信，这就会导致由于内存不足，进程之间通信断连等问题。

  当把 Driver 的内存设置到 4g 时，应用成功跑完。
- 使用 JDBCServer 执行 TPC-DS 测试套，默认参数配置下也报了很多错误：Executor Lost 等。而当配置 Driver 内存为 30g，executor 核数为 2，executor 个数为 125，executor 内存为 6g 时，所有任务才执行成功。

21.8.1.8 设计 DAG

操作场景

合理的设计程序结构，可以优化执行效率。在程序编写过程中要尽量减少 shuffle 操作，合并窄依赖操作。

操作步骤

以“同行车判断”例子讲解 DAG 设计的思路。

- **数据格式：**通过收费站时间、车牌号、收费站编号.....
- **逻辑：**以下两种情况下判定这两辆车是同行车：
  - 如果两辆车都通过相同序列的收费站，
  - 通过同一收费站之间的时间差小于一个特定的值。

该例子有两种实现模式，其中实现 1 的逻辑如图 21-6 所示，实现 2 的逻辑如图 21-7 所示。

图21-6 实现 1 逻辑

实现 1 的逻辑说明 ：

1. 根据车牌号聚合该车通过的所有收费站并排序，处理后数据如下：

   车牌号 1，[（通过时间，收费站 3），（通过时间，收费站 2），（通过时间，收费站 4），（通过时间，收费站 5）]

2. 标识该收费站是这辆车通过的第几个收费站。

   （收费站 3，（车牌号 1，通过时间，通过的第 1 个收费站））

   （收费站 2，（车牌号 1，通过时间，通过的第 2 个收费站））

   （收费站 4，（车牌号 1，通过时间，通过的第 3 个收费站））

   （收费站 5，（车牌号 1，通过时间，通过的第 4 个收费站））

3. 根据收费站聚合数据。

   收费站 1，[（车牌号 1，通过时间，通过的第 1 个收费站），（车牌号 2，通过时间，通过的第 5 个收费站），（车牌号 3，通过时间，通过的第 2 个收费站）]

4. 判断两辆车通过该收费站的时间差是否满足同行车的要求，如果满足则取出这两辆车。

   （车牌号 1，车牌号 2），（通过的第 1 个收费站，通过的第 5 个收费站）

   （车牌号 1，车牌号 3），（通过的第 1 个收费站，通过的第 2 个收费站）

5. 根据通过相同收费站的两辆车的车牌号聚合数据，如下：

   （车牌号 1，车牌号 2），[（通过的第 1 个收费站，通过的第 5 个收费站），（通过的第 2 个收费站，通过的第 6 个收费站），（通过的第 1 个收费站，通过的第 7 个收费站），（通过的第 3 个收费站，通过的第 8 个收费站）]

6. 如果车牌号 1 和车牌号 2 通过相同收费站是顺序排列的（比如收费站 3、4、5 是车牌 1 通过的第 1、2、3 个收费站，是车牌 2 通过的第 6、7、8 个收费站）且数量大于同行车要求的数量则这两辆车是同行车。

实现 1 逻辑的缺点 ：

- 逻辑复杂
- 实现过程中 shuffle 操作过多，对性能影响较大。

图21-7 实现 2 逻辑

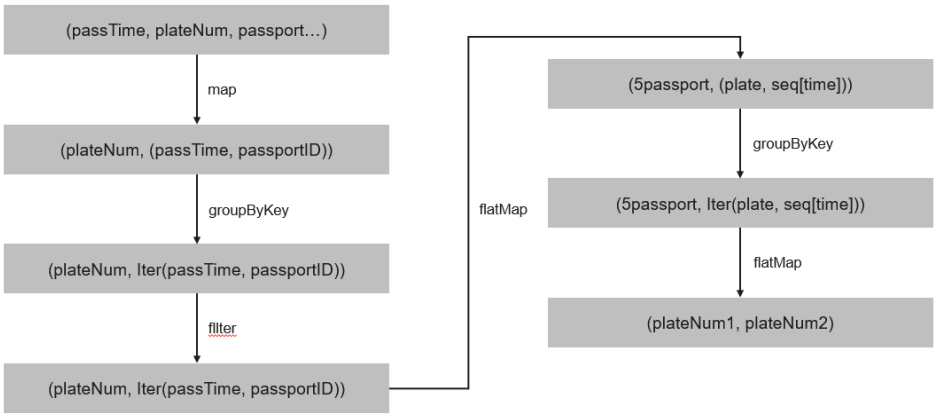

实现 2 的逻辑说明 ：

1. 根据车牌号聚合该车通过的所有收费站并排序，处理后数据如下：

   车牌号 1，[（通过时间，收费站 3），（通过时间，收费站 2），（通过时间，收费站 4），（通过时间，收费站 5）]

2. 根据同行车要通过的收费站数量（例子里为 3）分段该车通过的收费站序列，如上面的数据被分解成 ：

   收费站 3->收费站 2->收费站 4， （车牌号 1，[收费站 3 时间，收费站 2 时间，收费站 4 时间]）

   收费站 2->收费站 4->收费站 5， （车牌号 1，[收费站 2 时间，收费站 4 时间，收费站 5 时间]）

3. 把通过相同收费站序列的车辆聚合，如下：

   收费站 3->收费站 2->收费站 4，[（车牌号 1，[收费站 3 时间，收费站 2 时间，收费站 4 时间]），（车牌号 2，[收费站 3 时间，收费站 2 时间，收费站 4 时间]），（车牌号 3，[收费站 3 时间，收费站 2 时间，收费站 4 时间]）]

4. 判断通过相同序列收费站的车辆通过相同收费站的时间差是不是满足同行车的要求，如果满足则说明是同行车。

实现 2 的优点如下：

- 简化了实现逻辑。
- 减少了一个 groupByKey，也就减少了一次 shuffle 操作，提升了性能。

21.8.1.9 经验总结

使用 mapPartitions，按每个分区计算结果

如果每条记录的开销太大，例：

```
rdd.map{x=>conn=getDBConn;conn.write(x.toString);conn.close}
```

则可以使用 MapPartitions，按每个分区计算结果，如

```
rdd.mapPartitions(records => conn.getDBConn;for(item <- records)
write(item.toString); conn.close)
```

使用 mapPartitions 可以更灵活地操作数据，例如对一个很大的数据求 TopN，当 N 不是很大时，可以先使用 mapPartitions 对每个 partition 求 TopN，collect 结果到本地之后再做排序取 TopN。这样相比直接对全量数据做排序取 TopN 效率要高很多。

使用 coalesce 调整分片的数量

coalesce 可以调整分片的数量。coalesce 函数有两个参数：

```
coalesce(numPartitions: Int, shuffle: Boolean = false)
```

当 shuffle 为 true 的时候，函数作用与 repartition(numPartitions: Int)相同，会将数据通过 Shuffle 的方式重新分区；当 shuffle 为 false 的时候，则只是简单的将父 RDD 的多个 partition 合并到同一个 task 进行计算，shuffle 为 false 时，如果 numPartitions 大于父 RDD 的切片数，那么分区不会重新调整。

遇到下列场景，可选择使用 coalesce 算子：

- 当之前的操作有很多 filter 时，使用 coalesce 减少空运行的任务数量。此时使用 coalesce(numPartitions, false)，numPartitions 小于父 RDD 切片数。
- 当输入切片个数太大，导致程序无法正常运行时使用。
- 当任务数过大时候 Shuffle 压力太大导致程序挂住不动，或者出现 linux 资源受限的问题。此时需要对数据重新进行分区，使用 coalesce(numPartitions, true)。

localDir 配置

Spark 的 Shuffle 过程需要写本地磁盘，Shuffle 是 Spark 性能的瓶颈，I/O 是 Shuffle 的瓶颈。配置多个磁盘则可以并行的把数据写入磁盘。如果节点中挂载多个磁盘，则在每个磁盘配置一个 Spark 的 localDir，这将有效分散 Shuffle 文件的存放，提高磁盘 I/O 的效率。如果只有一个磁盘，配置了多个目录，性能提升效果不明显。

Collect 小数据

大数据量不适用 collect 操作。

collect 操作会将 Executor 的数据发送到 Driver 端，因此使用 collect 前需要确保 Driver 端内存足够，以免 Driver 进程发生 OutOfMemory 异常。当不确定数据量大小时，可使用 saveAsTextFile 等操作把数据写入 HDFS 中。只有在能够大致确定数据大小且 driver 内存充足的时候，才能使用 collect。

使用 reduceByKey

reduceByKey 会在 Map 端做本地聚合，使得 Shuffle 过程更加平缓，而 groupByKey 等 Shuffle 操作不会在 Map 端做聚合。因此能使用 reduceByKey 的地方尽量使用该算子，避免出现 groupByKey().map(x=>(x._1,x._2.size))这类实现方式。

广播 map 代替数组

当每条记录需要查表，如果是 Driver 端用广播方式传递的数据，数据结构优先采用 set/map 而不是 Iterator，因为 Set/Map 的查询速率接近 O(1)，而 Iterator 是 O(n)。

数据倾斜

当数据发生倾斜（某一部分数据量特别大），虽然没有 GC（Gabage Collection，垃圾回收），但是 task 执行时间严重不一致。

- 需要重新设计 key，以更小粒度的 key 使得 task 大小合理化。
- 修改并行度。

优化数据结构

- 把数据按列存放，读取数据时就可以只扫描需要的列。
- 使用 Hash Shuffle 时，通过设置 spark.shuffle.consolidateFiles 为 true，来合并 shuffle 中间文件，减少 shuffle 文件的数量，减少文件 IO 操作以提升性能。最终文件数为 reduce tasks 数目。

21.8.2 SQL 和 DataFrame 调优

21.8.2.1 Spark SQL join 优化

操作场景

Spark SQL 中，当对两个表进行 join 操作时，利用 Broadcast 特性（见“使用广播变量”章节），将被广播的表 BroadCast 到各个节点上，从而转变成非 shuffle 操作，提高任务执行性能。

说明

这里 join 操作，只指 inner join。

操作步骤

在 Spark SQL 中进行 Join 操作时，可以按照以下步骤进行优化。为了方便说明，设表 A 和表 B，且 A、B 表都有个名为 name 的列。对 A、B 表进行 join 操作。

1. 估计表的大小。

   根据每次加载数据的大小，来估计表大小。

   也可以在 Hive 的数据库存储路径下直接查看表的大小。首先在 Spark 的配置文件“hive-site.xml”中，查看 Hive 的数据库路径的配置，默认为“/user/hive/warehouse”。Spark 服务多实例默认数据库路径为“/user/*hive*/warehouse”，例如“/user/hive1/warehouse”。

   ```
   <property>
     <name>hive.metastore.warehouse.dir</name>
    <value>${test.warehouse.dir}</value>
    <description></description>
   </property>
   ```

   然后通过 hadoop 命令查看对应表的大小。如查看表 A 的大小命令为：

   ```
   hadoop fs -du -s -h ${test.warehouse.dir}/a
   ```

   说明

   进行广播操作，需要至少有一个表不是空表。

2. 配置自动广播的阈值。

   Spark 中，判断表是否广播的阈值为 10485760（即 10M）。如果两个表的大小至少有一个小于 10M 时，可以跳过该步骤。

   自动广播阈值的配置参数介绍，见表 21-68。

表21-68 参数介绍

参数	默认值	描述
spark.sql.autoBroadcastJoinThreshold	10485760	当进行 join 操作时，配置广播的最大值。 • 当 SQL 语句中涉及的表中相应字段的大小小于该值时，进行广播。 • 配置为-1 时，将不进行广播。

配置自动广播阈值的方法：

- 在 Spark 的配置文件“spark-defaults.conf”中，设置“spark.sql.autoBroadcastJoinThreshold”的值。

  ```
  spark.sql.autoBroadcastJoinThreshold = <size>
  ```

- 利用 Hive CLI 命令，设置阈值。在运行 Join 操作时，提前运行下面语句：

  ```
  SET spark.sql.autoBroadcastJoinThreshold=<size>;
  ```

3. 进行 join 操作。
   - 两个表的大小都小于阈值。
     - A 表的字节数小于 B 表，则运行 B join A，如

       ```
       SELECT A.name FROM B JOIN A ON A.name = B.name;
       ```

     - 否则运行 A join B。

       ```
       SELECT A.name FROM A JOIN B ON A.name = B.name;
       ```

   - 一个表大于阈值一个表小于阈值。

     将小表进行 BroadCast 操作。
   - 两个表的大小都大于阈值。

     比较查询所涉及的字段大小与阈值的大小。
     - 若某表中涉及字段的大小小于阈值，将该表相应数据进行广播。
     - 若两表中涉及字段的大小都大于阈值，则不进行广播。
4. （可选）如下两种场景，需要执行 Analyze 命令（***ANALYZE TABLE tableName COMPUTE STATISTICS noscan;***）更新表元数据后进行广播。
   - 需要广播的表是分区表，新建表且文件类型为非 Parquet 文件类型。
   - 需要广播的表是分区表，更新表数据后。

参考信息

被广播的表执行超时，导致任务结束。

默认情况下，BroadCastJoin 只允许被广播的表计算 5 分钟，超过 5 分钟该任务会出现超时异常，而这个时候被广播的表的 broadcast 任务依然在执行，造成资源浪费。

这种情况下，有两种方式处理：

- 调整“spark.sql.broadcastTimeout”的数值，加大超时的时间限制。
- 降低“spark.sql.autoBroadcastJoinThreshold”的数值，不使用 BroadCastJoin 的优化。

21.8.2.2 优化数据倾斜场景下的 Spark SQL 性能

配置场景

在 Spark SQL 多表 Join 的场景下，会存在关联键严重倾斜的情况，导致 Hash 分桶后，部分桶中的数据远高于其它分桶。最终导致部分 Task 过重，跑得很慢；其它 Task 过

轻，跑得很快。一方面，数据量大 Task 运行慢，使得计算性能低；另一方面，数据量少的 Task 在运行完成后，导致很多 CPU 空闲，造成 CPU 资源浪费。

通过如下配置项可开启自动进行数据倾斜处理功能，通过将 Hash 分桶后数据量很大的、且超过数据倾斜阈值的分桶拆散，变成多个 task 处理一个桶的数据机制，提高 CPU 资源利用率，提高系统性能。

说明

未产生倾斜的数据，将采用原有方式进行分桶并运行。

使用约束：

- 只支持两表 Join 的场景。
- 不支持 FULL OUTER JOIN 的数据倾斜处理。

  示例：执行下面 SQL 语句，a 表倾斜或 b 表倾斜都无法触发该优化。

  select aid FROM a FULL OUTER JOIN b ON aid=bid;
- 不支持 LEFT OUTER JOIN 的右表倾斜处理。

  示例：执行下面 SQL 语句，b 表倾斜无法触发该优化。

  select aid FROM a LEFT OUTER JOIN b ON aid=bid;
- 不支持 RIGHT OUTER JOIN 的左表倾斜处理。

  示例：执行下面 SQL 语句，a 表倾斜无法触发该优化。

  select aid FROM a RIGHT OUTER JOIN b ON aid=bid;

配置描述

在 Spark Driver 端的“spark-defaults.conf”配置文件中添加如下表格中的参数。

表21-69 参数说明

参数	描述	默认值
spark.sql.adaptive.enabled	自适应执行特性的总开关。 注意：AQE 特性与 DPP（动态分区裁剪）特性同时开启时，SparkSQL 任务执行中会优先执行 DPP 特性，从而使得 AQE 特性不生效。集群中 DPP 特性是默认开启的，因此开启 AQE 特性的同时，需要将 DPP 特性关闭。	false
spark.sql.optimizer.dynamicPartitionPruning.enabled	动态分区裁剪功能的开关。	true
spark.sql.adaptive.skewJoin.enabled	当此配置为 true 且 spark.sql.adaptive.enabled 设置为 true 时，启用运行时自动处理 join 运算中的数据倾斜功能。	true
spark.sql.adaptive.skewJoin.skewedPart	此配置为一个倍数因子，用于判定分区是否为数据倾斜分区。单个分区被判定为数据倾斜分区的条件为：	5

参数	描述	默认值
itionFactor	当一个分区的数据大小超过除此分区外其他所有分区大小的中值与该配置的乘积，并且大小超过spark.sql.adaptive.skewJoin.skewedPartitionThresholdInBytes 配置值时，此分区被判定为数据倾斜分区	
spark.sql.adaptive.skewjoin.skewedPartitionThresholdInBytes	分区大小（单位：字节）大于该阈值且大于spark.sql.adaptive.skewJoin.skewedPartitionFactor 与分区中值的乘积，则认为该分区存在倾斜。理想情况下，此配置应大于spark.sql.adaptive.advisoryPartitionSizeInBytes.	256MB
spark.sql.adaptive.shuffle.targetPostShuffleInputSize	每个 task 处理的 shuffle 数据的最小数据量。单位：Byte。	67108864

21.8.2.3 优化小文件场景下的 Spark SQL 性能

配置场景

Spark SQL 的表中，经常会存在很多小文件（大小远小于 HDFS 块大小），每个小文件默认对应 Spark 中的一个 Partition，也就是一个 Task。在很多小文件场景下，Spark 会起很多 Task。当 SQL 逻辑中存在 Shuffle 操作时，会大大增加 hash 分桶数，严重影响性能。

在小文件场景下，您可以通过如下配置手动指定每个 Task 的数据量（Split Size），确保不会产生过多的 Task，提高性能。

说明

当 SQL 逻辑中不包含 Shuffle 操作时，设置此配置项，不会有明显的性能提升。

配置描述

要启动小文件优化，在 Spark 客户端的“spark-defaults.conf”配置文件中进行设置。

表21-70 参数说明

参数	描述	默认值
spark.sql.files.maxPartitionBytes	在读取文件时，将单个分区打包的最大字节数。 单位：byte。	134217728（即128M）
spark.files.openCostInBytes	打开文件的预估成本， 按照同一时间能够扫描的字节数来测量。当一个分区写入多个文件时使用。高估更好，这样小文件分区将比大文件分区更先被调度。	4M

21.8.2.4 INSERT...SELECT 操作调优

操作场景

在以下几种情况下，执行 INSERT...SELECT 操作可以进行一定的调优操作。

- 查询的数据是大量的小文件。
- 查询的数据是较多的大文件。
- 在 Beeline/JDBCServer 模式下使用非 Spark 用户操作。

操作步骤

可对 INSERT...SELECT 操作做如下的调优操作。

- 如果建的是 Hive 表，将存储类型设为 Parquet，从而减少执行 INSERT...SELECT 语句的时间。
- 建议使用 spark-sql 或者在 Beeline/JDBCServer 模式下使用 spark 用户来执行 INSERT...SELECT 操作，避免执行更改文件 owner 的操作，从而减少执行 INSERT...SELECT 语句的时间。

  说明

  在 Beeline/JDBCServer 模式下，executor 的用户跟 driver 是一致的，driver 是 JDBCServer 服务的一部分，是由 spark 用户启动的，因此其用户也是 spark 用户，且当前无法实现在运行时将 Beeline 端的用户透传到 executor，因此使用非 spark 用户时需要对文件进行更改 owner 为 Beeline 端的用户，即实际用户。

- 如果查询的数据是大量的小文件将会产生大量 map 操作，从而导致输出存在大量的小文件，在执行重命名文件操作时将会耗费较多时间，此时可以通过设置“spark.sql.files.maxPartitionBytes”与“spark.files.openCostInBytes”来设置一个 partiton 读取的最大字节，在一个 partition 中合并多个小文件来减少输出文件数及执行重命名文件操作的时间，从而减少执行 INSERT...SELECT 语句的时间。

  说明

  上述优化操作并不能解决全部的性能问题，对于以下场景仍然需要较多时间：

  对于动态分区表，如果其分区数非常多，那么也需要执行较长的时间。

21.8.2.5 多并发 JDBC 客户端连接 JDBCServer

操作场景

JDBCServer 支持多用户多并发接入，但当并发任务数量较高的时候，默认的 JDBCServer 配置将无法支持，因此需要进行优化来支持该场景。

操作步骤

1. 设置 JDBCServer 的公平调度策略。

   Spark 默认使用 FIFO（First In First Out）的调度策略，但对于多并发的场景，使用 FIFO 策略容易导致短任务执行失败。因此在多并发的场景下，需要使用公平调度策略，防止任务执行失败。

a. 在 Spark 中设置公平调度，具体请参考 http://spark.apache.org/docs/3.1.1/job-scheduling.html#scheduling-within-an-application。

b. 在 JDBC 客户端中设置公平调度。

i. 在 BeeLine 命令行客户端或者 JDBC 自定义代码中，执行以下语句，其中 PoolName 是公平调度的某一个调度池。

```
SET spark.sql.thriftserver.scheduler.pool=PoolName;
```

ii. 执行相应的 SQL 命令，Spark 任务将会在上面的调度池中运行。

2. 设置 BroadCastHashJoin 的超时时间。

BroadCastHashJoin 有超时参数，一旦超过预设的时间，该查询任务直接失败，在多并发场景下，由于计算任务抢占资源，可能会导致 BroadCastHashJoin 的 Spark 任务无法执行，导致超时出现。因此需要在 JDBCServer 的“spark-defaults.conf”配置文件中调整超时时间。

表21-71 参数描述

参数	描述	默认值
spark.sql.broadcastTimeout	BroadcastHashJoin 中广播表的超时时间，当任务并发数较高的时候，可以调高该参数值。	-1（数值类型，实际为五分钟）

21.8.2.6 动态分区插入场景内存优化

操作场景

SparkSQL 在往动态分区表中插入数据时，分区数越多，单个 Task 生成的 HDFS 文件越多，则元数据占用的内存也越多。这就导致程序 GC（Gabage Collection）严重，甚至发生 OOM（Out of Memory）。

经测试证明：10240 个 Task，2000 个分区，在执行 HDFS 文件从临时目录 rename 到目标目录动作前，FileStatus 元数据大小约 29G。为避免以上问题，可修改 SQL 语句对数据进行重分区，以减少 HDFS 文件个数。

操作步骤

在动态分区语句中加入 **distribute by**，by 值为分区字段。

示例如下：

insert into table store_returns partition (sr_returned_date_sk) select sr_return_time_sk,sr_item_sk,sr_customer_sk,sr_cdemo_sk,sr_hdemo_sk,sr_addr_sk,sr_store_sk,sr_reason_sk,sr_ticket_number,sr_return_quantity,sr_return_amt,sr_return_tax,sr_return_amt_inc_tax,sr_fee,sr_return_ship_cost,sr_refunded_cash,sr_reversed_charge,sr_store_credit,sr_net_loss,sr_returned_date_sk from ${SOURCE}.store_returns **distribute by sr_returned_date_sk**;

21.8.2.7 小文件优化

操作场景

Spark SQL 表中，经常会存在很多小文件（大小远小于 HDFS 的块大小），每个小文件默认对应 Spark 中的一个 Partition，即一个 Task。在有很多小文件时，Spark 会启动很多 Task，此时当 SQL 逻辑中存在 Shuffle 操作时，会大大增加 hash 分桶数，严重影响系统性能。

针对小文件很多的场景，DataSource 在创建 RDD 时，先将 Table 中的 split 生成 PartitionedFile，再将这些 PartitionedFile 进行合并。即将多个 PartitionedFile 组成一个 partition，从而减少 partition 数量，避免在 Shuffle 操作时生成过多的 hash 分桶，如图 21-8 所示。

图21-8 小文件合并

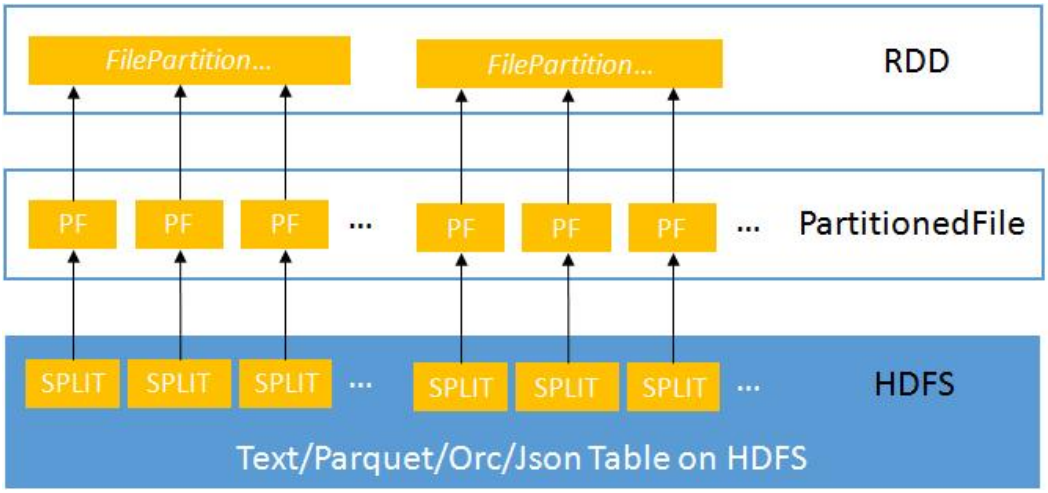

操作步骤

要启动小文件优化，在 Spark 客户端的“spark-defaults.conf”配置文件中进行设置。

表21-72 参数介绍

参数	描述	默认值
spark.sql.files.maxPartitionBytes	在读取文件时，将单个分区打包的最大字节数。 单位：byte。	134217728（即128M）
spark.files.openCostInBytes	打开文件的预估成本， 按照同一时间能够扫描的字节数来测量。当一个分区写入多个文件时使用。高估更好，这样小文件分区将比大文件分区更先被调度。	4M

21.8.2.8 聚合算法优化

操作场景

在 Spark SQL 中支持基于行的哈希聚合算法，即使用快速聚合 hashmap 作为缓存，以提高聚合性能。hashmap 替代了之前的 ColumnarBatch 支持，从而避免拥有聚合表的宽模式（大量 key 字段或 value 字段）时产生的性能问题。

操作步骤

要启动聚合算法优化，在 Spark 客户端的“spark-defaults.conf”配置文件中进行设置。

表21-73 参数介绍

参数	描述	默认值
spark.sql.codegen.aggregate.map.twolevel.enabled	是否开启聚合算法优化： • true：开启 • false：不开启	true

21.8.2.9 Datasource 表优化

操作场景

将 datasource 表的分区消息存储到 Metastore 中，并在 Metastore 中对分区消息进行处理。

- 优化 datasource 表，支持对表中分区执行增加、删除和修改等语法，从而增加与 Hive 的兼容性。
- 支持在查询语句中，把分区裁剪并下压到 Metastore 上，从而过滤掉不匹配的分区。

  示例如下：

  ```
  select count(*) from table where partCol=1;    //partCol 列为分区列
  ```

  此时，在物理计划中执行 TableScan 操作时，只处理分区(partCol=1)对应的数据。

操作步骤

要启动 Datasource 表优化，在 Spark 客户端的“spark-defaults.conf”配置文件中进行设置。

表21-74 参数介绍

参数	描述	默认值
spark.sql.hive.manageFilesourcePartitions	是否启用 Metastore 分区管理（包括数据源表和转换的 Hive 表）。 • true：启用 Metastore 分区管理，即数	true

参数	描述	默认值
	据源表存储分区在 Hive 中，并在查询语句中使用 Metastore 修剪分区。 • false：不启用 Metastore 分区管理。	
spark.sql.hive.metastorePartitionPruning	是否支持将 predicate 下压到 Hive Metastore 中。 • true：支持，目前仅支持 Hive 表的 predicate 下压。 • false：不支持	true
spark.sql.hive.filesourcePartitionFileCacheSize	启用内存中分区文件元数据的缓存大小。 所有表共享一个可以使用指定的 num 字节进行文件元数据的缓存。 只有当“spark.sql.hive.manageFilesourcePartitions”配置为“true”时，该配置项才会生效。	250 * 1024 * 1024
spark.sql.hive.convertMetastoreOrc	设置 ORC 表的处理方式： • false：Spark SQL 使用 Hive SerDe 处理 ORC 表。 • true：Spark SQL 使用 Spark 内置的机制处理 ORC 表。	true

21.8.2.10 合并 CBO 优化

操作场景

Spark SQL 默认支持基于规则的优化，但仅仅基于规则优化不能保证 Spark 选择合适的查询计划。CBO（Cost-Bsed Optimizer）是一种为 SQL 智能选择查询计划的技术。通过配置开启 CBO 后，CBO 优化器可以基于表和列的统计信息，进行一系列的估算，最终选择出合适的查询计划。

操作步骤

要使用 CBO 优化，可以按照以下步骤进行优化。

1. 需要先执行特定的 SQL 语句来收集所需的表和列的统计信息。

   SQL 命令如下（根据具体情况选择需要执行的 SQL 命令）：

   - 生成表级别统计信息（扫表）：

     ANALYZE TABLE src COMPUTE STATISTICS

     生成 sizeInBytes 和 rowCount。

     使用 ANALYZE 语句收集统计信息时，无法计算非 HDFS 数据源的表的文件大小。

- 生成表级别统计信息（不扫表）：

  ANALYZE TABLE src COMPUTE STATISTICS NOSCAN

  只生成 sizeInBytes，如果原来已经生成过 sizeInBytes 和 rowCount，而本次生成的 sizeInBytes 和原来的大小一样，则保留 rowCount（若存在），否则清除 rowCount。

- 生成列级别统计信息

  ANALYZE TABLE src COMPUTE STATISTICS FOR COLUMNS a, b, c

  生成列统计信息，为保证一致性，会同步更新表统计信息。目前不支持复杂数据类型（如 Seq, Map 等）和 HiveStringType 的统计信息生成。

- 显示统计信息

  DESC FORMATTED src

  在 Statistics 中会显示“xxx bytes, xxx rows”分别表示表级别的统计信息。也可以通过如下命令显示列统计信息：

  DESC FORMATTED src a

使用限制：当前统计信息收集不支持针对分区表的分区级别的统计信息。

2. 在 Spark 客户端的“spark-defaults.conf”配置文件中进行表 21-75 设置。

表21-75 参数介绍

参数	描述	默认值
spark.sql.cbo.enabled	CBO 总开关。 • true 表示打开， • false 表示关闭。 要使用该功能，需确保相关表和列的统计信息已经生成。	false
spark.sql.cbo.joinReorder.enabled	使用 CBO 来自动调整连续的 inner join 的顺序。 • true：表示打开 • false：表示关闭 要使用该功能，需确保相关表和列的统计信息已经生成，且 CBO 总开关打开。	false
spark.sql.cbo.joinReorder.dp.threshold	使用 CBO 来自动调整连续 inner join 的表的个数阈值。 如果超出该阈值，则不会调整 join 顺序。	12

21.8.2.11 跨源复杂数据的 SQL 查询优化

操作场景

本章节介绍如何打开或关闭跨源复杂数据的 SQL 查询优化功能。

操作步骤

- （可选）连接 MPPDB 数据源的准备

  如果连接的数据源为 MPPDB，由于 MPPDB Driver 文件“gsjdbc4.jar”和 Spark 中的 jar 包“gsjdbc4-VXXXRXXXCXXSPCXXX.jar”包含了相同的类名，存在类名冲突的问题。因此在连接 MPPDB 数据库之前，需要执行以下步骤：

  a. 移除 Spark 中的“gsjdbc4-VXXXRXXXCXXSPCXXX.jar”，由于 Spark 运行不依赖该 jar 包，因此将该 jar 包移动到其他目录（例如，移动到“/tmp”目录，不建议直接删除）不会影响 Spark 正常运行。

     i. 登录 Spark 服务端主机，移除“${BIGDATA_HOME}/FusionInsight_Spark2x_xxx/install/FusionInsight-Spark2x-*/spark/jars”路径下的“gsjdbc4-VXXXRXXXCXXSPCXXX.jar”。

     ii. 登录 Spark 客户端主机，移除“/opt/client/Spark2x/spark/jars”路径下的“gsjdbc4-VXXXRXXXCXXSPCXXX.jar”。

  b. 在 MPPDB 的安装包中获取 MPPDB Driver 文件“gsjdbc4.jar”，并将该文件分别上传到以下位置：

  说明

  “gsjdbc4.jar”在 MPPDB 安装包的目录“FusionInsight_MPPDB\software\components\package\FusionInsight-MPPDB-*xxx*\package\Gauss-MPPDB-ALL-PACKAGES\GaussDB-*xxx*-REDHAT-*xxx*-Jdbc\jdbc”中获取。

  - Spark 服务端的“/${BIGDATA_HOME}/FusionInsight_Spark2x_xxx/install/FusionInsight-Spark2x-*/spark/jars”路径下。
  - Spark 客户端的“/opt/client/Spark2x/spark/jars”路径下。

  c. 更新存储在 HDFS 中的“/user/spark2x/jars/xxx/spark-archive-2x.zip”压缩包。

  说明

  此处版本号 xxx 为示例，具体以实际环境的版本号为准。

  i. 使用客户端安装用户登录客户端所在节点。执行命令切换到客户端安装目录，例如“/opt/client”。

     cd /opt/client

  ii. 执行以下命令配置环境变量。

     source bigdata_env

  iii. 如果集群为安全模式，执行以下命令获得认证。

     kinit *组件业务用户*

  iv. 新建临时文件./tmp，并从 HDFS 获取“spark-archive-2x.zip”并解压到 tmp 目录，命令如下：

     mkdir tmp

     hdfs dfs -get /user/spark2x/jars/xxx/spark-archive-2x.zip **./**

     unzip spark-archive-2x.zip -d ./tmp

  v. 切换到 tmp 目录，删除“gsjdbc4-VXXXRXXXCXXSPCXXX.jar”文件，并将 MPPDB Driver 文件“gsjdbc4.jar”上传到 tmp 目录中，然后执行以下命令重新打包。

zip -r spark-archive-2x.zip *.jar

vi. 删除 HDFS 上的“spark-archive-2x.zip”，将步骤 c.v 中新生成的压缩包“spark-archive-2x.zip”更新至 HDFS 的“/user/spark2x/jars/xxx/”路径下。

hdfs dfs -rm /user/spark2x/jars/xxx/spark-archive-2x.zip

hdfs dfs -put ./spark-archive-2x.zip /user/spark2x/jars/xxx

d. 重启 Spark 服务，等重启成功后，重新启动 Spark 客户端。

- 打开优化开关

  对所有支持查询下推的模块，可以通过在 spark-beeline 客户端中执行 SET 命令打开跨源查询优化功能，默认均为关闭状态。

  可以从全局、数据源、表这三个维度进行下推开关控制。打开方法如下：

  - 全局（对所有数据源生效）：

    SET spark.sql.datasource.jdbc = project,aggregate,orderby-limit

  - 数据源：

    SET spark.sql.datasource.${url} = project,aggregate,orderby-limit

  - 表：

    SET spark.sql.datasource.${url}.${table} = project,aggregate,orderby-limit

  执行 SET 命令设置上述参数时，允许一次设置多个下推模块，中间以逗号分隔。各个下推模块对应的参数值如下所示：

表21-76 各模块对应的参数值

模块名称	SET 命令的参数值
project	project
aggregate	aggregate
order by，limit over project or aggregate	orderby-limit

示例：创建一个 MySQL 的外表的语句为：

create table if not exists pdmysql using org.apache.spark.sql.jdbc options(driver "com.mysql.jdbc.Driver", url "jdbc:mysql://ip2:3306/test", user "hive", password "*xxx*", dbtable "mysqldata");

则其中：

- ${url} = jdbc:mysql://ip2:3306/test
- ${table} = mysqldata

说明

- “=”后即设置可以下推打开的算子，以“,”隔开。
- 优先级：table 开关>数据源开关>全局开关。即若设置了 table 开关，则数据源开关全局开关对该表失效；若配置了数据源开关，则全局开关对该数据源失效。
- url 中不能包含“=”，若包含，set 时直接删掉“=”。
- 可多次执行 set，key 不同不会相互覆盖。

- 命令中如果携带认证密码信息可能存在安全风险，在执行命令前建议关闭系统的 history 命令记录功能，避免信息泄露。

- 新增支持查询下推的函数

  除了支持对 abs()、month()、length()等数学、时间、字符串函数进行查询下推外，用户还可以通过 SET 命令新增数据源支持查询下推的函数。在 spark-beeline 客户端中执行如下命令：

  SET spark.sql.datasource.${datasource}.functions = fun1,fun2

- 取消开关设置及取消新增的下推函数

  当前只能通过在 spark-beeline 客户端中执行 ***RESET*** 命令取消所有 SET 的内容。由于执行 ***RESET*** 后所有 SET 的参数值都将被清除，请谨慎使用。

  控制开关的设置仅在客户端当前的会话中生效，当客户端关闭后，SET 内容就失效了。

  或者修改客户端配置文件 spark-defaults.conf 中的 spark.sql.locale.support 参数为 true。

注意事项

数据源只支持 MySQL 和 MPPDB，Hive，oracle， postgresql。

21.8.2.12 多级嵌套子查询以及混合 Join 的 SQL 调优

操作场景

本章节介绍在多级嵌套以及混合 Join SQL 查询的调优建议。

前提条件

例如有一个复杂的查询样例如下：

```
select
s_name,
count(1) as numwait
from (
select s_name from (
select
s_name,
t2.l_orderkey,
l_suppkey,
count_suppkey,
max_suppkey
from
test2 t2 right outer join (
select
s_name,
l_orderkey,
l_suppkey from (
select
s_name,
t1.l_orderkey,
l_suppkey,
count_suppkey,
```

```
max_suppkey
from
test1 t1 join (
select
s_name,
l_orderkey,
l_suppkey
from
orders o join (
select
s_name,
l_orderkey,
l_suppkey
from
nation n join supplier s
on
s.s_nationkey = n.n_nationkey
and n.n_name = 'SAUDI ARABIA'
join lineitem l
on
s.s_suppkey = l.l_suppkey
where
l.l_receiptdate > l.l_commitdate
and l.l_orderkey is not null
) l1 on o.o_orderkey = l1.l_orderkey and o.o_orderstatus = 'F'
) l2 on l2.l_orderkey = t1.l_orderkey
) a
where
(count_suppkey > 1)
or ((count_suppkey=1)
and (l_suppkey <> max_suppkey))
) l3 on l3.l_orderkey = t2.l_orderkey
) b
where
(count_suppkey is null)
or ((count_suppkey=1)
and (l_suppkey = max_suppkey))
) c
group by
s_name
order by
numwait desc,
s_name
limit 100;
```

操作步骤

分析业务。

从业务入手分析是否可以简化 SQL，例如可以通过合并表去减少嵌套的层级和 Join 的次数。

步骤 1 如果业务需求对应的 SQL 无法简化，则需要配置 DRIVER 内存：

- 使用 **spark-submit** 或者 **spark-sql** 运行 SQL 语句，执行步骤 3。

- 使用 **spark-beeline** 运行 SQL 语句，执行步骤 4。

步骤 2 执行 SQL 语句时，需要添加参数“--driver-memory”，设置内存大小，例如：

/spark-sql --master=local[4] --driver-memory=512M -f /tpch.sql

步骤 3 在执行 SQL 语句前，请使用 MRS 集群管理员用户修改内存大小配置。

1. 登录 FusionInsight Manager，选择“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”。
2. 单击“全部配置”，并搜索“SPARK_DRIVER_MEMORY”。
3. 修改参数值适当增加内存大小。仅支持整数值，且需要输入单位 M 或者 G。例如输入 512M。

----结束

参考信息

DRIVER 内存不足时，查询操作可能遇到以下错误提示信息：

```
2018-02-11 09:13:14,683 | WARN  | Executor task launch worker for task 5 | Calling
spill() on RowBasedKeyValueBatch. Will not spill but return 0. |
org.apache.spark.sql.catalyst.expressions.RowBasedKeyValueBatch.spill(RowBasedKeyVa
lueBatch.java:173)
2018-02-11 09:13:14,682 | WARN  | Executor task launch worker for task 3 | Calling
spill() on RowBasedKeyValueBatch. Will not spill but return 0. |
org.apache.spark.sql.catalyst.expressions.RowBasedKeyValueBatch.spill(RowBasedKeyVa
lueBatch.java:173)
2018-02-11 09:13:14,704 | ERROR | Executor task launch worker for task 2 |
Exception in task 2.0 in stage 1.0 (TID 2) |
org.apache.spark.internal.Logging$class.logError(Logging.scala:91)
java.lang.OutOfMemoryError: Unable to acquire 262144 bytes of memory, got 0
      at
org.apache.spark.memory.MemoryConsumer.allocateArray(MemoryConsumer.java:100)
      at
org.apache.spark.unsafe.map.BytesToBytesMap.allocate(BytesToBytesMap.java:791)
      at
org.apache.spark.unsafe.map.BytesToBytesMap.<init>(BytesToBytesMap.java:208)
      at
org.apache.spark.unsafe.map.BytesToBytesMap.<init>(BytesToBytesMap.java:223)
      at
org.apache.spark.sql.execution.UnsafeFixedWidthAggregationMap.<init>(UnsafeFixedWid
thAggregationMap.java:104)
      at
org.apache.spark.sql.execution.aggregate.HashAggregateExec.createHashMap(HashAggreg
ateExec.scala:307)
      at
org.apache.spark.sql.catalyst.expressions.GeneratedClass$GeneratedIterator.agg_doAg
gregateWithKeys$(Unknown Source)
      at
org.apache.spark.sql.catalyst.expressions.GeneratedClass$GeneratedIterator.processN
ext(Unknown Source)
      at
org.apache.spark.sql.execution.BufferedRowIterator.hasNext(BufferedRowIterator.java
:43)
```

```
        at
org.apache.spark.sql.execution.WholeStageCodegenExec$$anonfun$8$$anon$1.hasNext(Who
leStageCodegenExec.scala:381)
        at scala.collection.Iterator$$anon$11.hasNext(Iterator.scala:408)
        at
org.apache.spark.shuffle.sort.BypassMergeSortShuffleWriter.write(BypassMergeSortShu
ffleWriter.java:126)
        at  org.apache.spark.scheduler.ShuffleMapTask.runTask(ShuffleMapTask.scala:96)
        at  org.apache.spark.scheduler.ShuffleMapTask.runTask(ShuffleMapTask.scala:53)
        at org.apache.spark.scheduler.Task.run(Task.scala:99)
        at org.apache.spark.executor.Executor$TaskRunner.run(Executor.scala:325)
        at
java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1149)
        at
java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:624)
        at java.lang.Thread.run(Thread.java:748)
```

21.8.3 Spark Streaming 调优

操作场景

Streaming 作为一种 mini-batch 方式的流式处理框架，它主要的特点是：秒级时延和高吞吐量。因此 Streaming 调优的目标：在秒级延迟的情景下，提高 Streaming 的吞吐能力，在单位时间处理尽可能多的数据。

说明

本章节适用于输入数据源为 Kafka 的使用场景。

操作步骤

一个简单的流处理系统由以下三部分组件组成：数据源 + 接收器 + 处理器。数据源为 Kafka，接受器为 Streaming 中的 Kafka 数据源接收器，处理器为 Streaming。

对 Streaming 调优，就必须使该三个部件的性能都更优化。

- **数据源调优**

  在实际的应用场景中，数据源为了保证数据的容错性，会将数据保存在本地磁盘中，而 Streaming 的计算结果全部在内存中完成，数据源很有可能成为流式系统的最大瓶颈点。

  对 Kafka 的性能调优，有以下几个点：

  - 使用 Kafka-0.8.2 以后版本，可以使用异步模式的新 Producer 接口。
  - 配置多个 Broker 的目录，设置多个 IO 线程，配置 Topic 合理的 Partition 个数。

- **接收器调优**

  Streaming 中已有多种数据源的接收器，例如 Kafka、Flume、MQTT、ZeroMQ 等，其中 Kafka 的接收器类型最多，也是最成熟一套接收器。

  Kafka 包括三种模式的接收器 API：

  - KafkaReceiver：直接接收 Kafka 数据，进程异常后，可能出现数据丢失。
  - ReliableKafkaReceiver：通过 ZooKeeper 记录接收数据位移。

- DirectKafka：直接通过 RDD 读取 Kafka 每个 Partition 中的数据，数据高可靠。

从实现上来看，DirectKafka 的性能更优，实际测试上来看，DirectKafka 也确实比其他两个 API 性能好了不少。因此推荐使用 DirectKafka 的 API 实现接收器。

数据接收器作为一个 Kafka 的消费者，对于它的配置优化。

- **处理器调优**

  Spark Streaming 的底层由 Spark 执行，因此大部分对于 Spark 的调优措施，都可以应用在 Spark Streaming 之中，例如：

  - 数据序列化
  - 配置内存
  - 设置并行度
  - 使用 External Shuffle Service 提升性能

说明

在做 Spark Streaming 的性能优化时需注意一点，越追求性能上的优化，Spark Streaming 整体的可靠性会越差。例如：

“spark.streaming.receiver.writeAheadLog.enable”配置为“false”的时候，会明显减少磁盘的操作，提高性能，但由于缺少 WAL 机制，会出现异常恢复时，数据丢失。

因此，在调优 Spark Streaming 的时候，这些保证数据可靠性的配置项，在生产环境中是不能关闭的。

- **日志归档调优**

  参数“spark.eventLog.group.size”用来设置一个应用的 JobHistory 日志按照指定 job 个数分组，每个分组会单独创建一个文件记录日志，从而避免应用长期运行时形成单个过大日志造成 JobHistory 无法读取的问题，设置为“0”时表示不分组。

  大部分 Spark Streaming 任务属于小型 job，而且产生速度较快，会导致频繁的分组，产生大量日志小文件消耗磁盘 I/O。建议增大此值，例如改为“1000”或更大值。

21.8.4 Spark on OBS 调优

配置场景

Spark on OBS 在小批量频繁请求 OBS 的场景下，可以通过关闭 OBS 监控提升性能。

配置描述

在 Spark 客户端的“core-site.xml”配置文件中修改配置。

表21-77 参数介绍

参数	描述	默认值
fs.obs.metrics.switch	上报 OBS 监控指标开关： • true 表示打开 • false 表示关闭	true

参数	描述	默认值
fs.obs.metrics.consumer	指定 OBS 监控指标的处理方式。 • org.apache.hadoop.fs.obs.metrics.OBSAMetricsProvider：表示收集统计 OBS 监控指标 • org.apache.hadoop.fs.obs.DefaultMetricsConsumer：表示不收集 OBS 监控指标 要使用 OBS 监控功能，需确保上报 OBS 监控指标开关打开。	org.apache.hadoop.fs.obs.metrics.OBSAMetricsProvider

21.9 Spark2x 常见问题

21.9.1 Spark Core

21.9.1.1 日志聚合下，如何查看 Spark 已完成应用日志

问题

当 YARN 开启了日志聚合功能时，如何在页面看到聚合后的 container 日志？

回答

请参考 21.2.7.7 配置 WebUI 上查看聚合后的 container 日志。

21.9.1.2 为什么 Driver 进程不能退出

问题

运行 Spark Streaming 任务，然后使用 **yarn application -kill applicationID** 命令停止任务，为什么 Driver 进程不能退出？

回答

使用 **yarn application -kill applicationID** 命令后 Spark 只会停掉任务对应的 SparkContext，而不是退出当前进程。如果当前进程中存在其他常驻的线程（类似 spark-shell 需要不断检测命令输入，Spark Streaming 不断在从数据源读取数据），SparkContext 被停止并不会终止整个进程。

如果需要退出 Driver 进程，建议使用 **kill -9 pid** 命令手动退出当前 Driver。

21.9.1.3 网络连接超时导致 FetchFailedException

问题

在 380 节点的大集群上，运行 29T 数据量的 HiBench 测试套中 ScalaSort 测试用例，使用以下关键配置（**--executor-cores 4**）出现如下异常：

```
org.apache.spark.shuffle.FetchFailedException: Failed to connect to
/192.168.114.12:23242
    at
org.apache.spark.storage.ShuffleBlockFetcherIterator.throwFetchFailedException(Shuf
fleBlockFetcherIterator.scala:321)
    at
org.apache.spark.storage.ShuffleBlockFetcherIterator.next(ShuffleBlockFetcherIterat
or.scala:306)
    at
org.apache.spark.storage.ShuffleBlockFetcherIterator.next(ShuffleBlockFetcherIterat
or.scala:51)
    at scala.collection.Iterator$$anon$11.next(Iterator.scala:328)
    at scala.collection.Iterator$$anon$13.hasNext(Iterator.scala:371)
    at scala.collection.Iterator$$anon$11.hasNext(Iterator.scala:327)
    at org.apache.spark.util.CompletionIterator.hasNext(CompletionIterator.scala:32)
    at org.apache.spark.InterruptibleIterator.hasNext(InterruptibleIterator.scala:39)
    at
org.apache.spark.util.collection.ExternalSorter.insertAll(ExternalSorter.scala:217)
    at
org.apache.spark.shuffle.hash.HashShuffleReader.read(HashShuffleReader.scala:102)
    at org.apache.spark.rdd.ShuffledRDD.compute(ShuffledRDD.scala:90)
    at org.apache.spark.rdd.RDD.computeOrReadCheckpoint(RDD.scala:301)
    at org.apache.spark.rdd.RDD.iterator(RDD.scala:265)
    at org.apache.spark.rdd.MapPartitionsRDD.compute(MapPartitionsRDD.scala:38)
    at org.apache.spark.rdd.RDD.computeOrReadCheckpoint(RDD.scala:301)
    at org.apache.spark.rdd.RDD.iterator(RDD.scala:265)
    at org.apache.spark.rdd.MapPartitionsRDD.compute(MapPartitionsRDD.scala:38)
    at org.apache.spark.rdd.RDD.computeOrReadCheckpoint(RDD.scala:301)
    at org.apache.spark.rdd.RDD.iterator(RDD.scala:265)
    at org.apache.spark.rdd.UnionRDD.compute(UnionRDD.scala:87)
    at org.apache.spark.rdd.RDD.computeOrReadCheckpoint(RDD.scala:301)
    at org.apache.spark.rdd.RDD.iterator(RDD.scala:265)
    at org.apache.spark.scheduler.ShuffleMapTask.runTask(ShuffleMapTask.scala:73)
    at org.apache.spark.scheduler.ShuffleMapTask.runTask(ShuffleMapTask.scala:41)
    at org.apache.spark.scheduler.Task.run(Task.scala:87)
    at org.apache.spark.executor.Executor$TaskRunner.run(Executor.scala:213)
    at
java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1142)
    at
java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:617)
    at java.lang.Thread.run(Thread.java:745)
Caused by: java.io.IOException: Failed to connect to /192.168.114.12:23242
    at
org.apache.spark.network.client.TransportClientFactory.createClient(TransportClient
Factory.java:214)
    at
org.apache.spark.network.client.TransportClientFactory.createClient(TransportClient
Factory.java:167)
```

```
    at
org.apache.spark.network.netty.NettyBlockTransferService$$anon$1.createAndStart(Net
tyBlockTransferService.scala:91)
    at
org.apache.spark.network.shuffle.RetryingBlockFetcher.fetchAllOutstanding(RetryingB
lockFetcher.java:140)
    at
org.apache.spark.network.shuffle.RetryingBlockFetcher.access$200(RetryingBlockFetch
er.java:43)
    at
org.apache.spark.network.shuffle.RetryingBlockFetcher$1.run(RetryingBlockFetcher.ja
va:170)
    at java.util.concurrent.Executors$RunnableAdapter.call(Executors.java:511)
    at java.util.concurrent.FutureTask.run(FutureTask.java:266)
    ... 3 more
Caused by: java.net.ConnectException: Connection timed out: /192.168.114.12:23242
    at sun.nio.ch.SocketChannelImpl.checkConnect(Native Method)
    at sun.nio.ch.SocketChannelImpl.finishConnect(SocketChannelImpl.java:717)
    at
io.netty.channel.socket.nio.NioSocketChannel.doFinishConnect(NioSocketChannel.java:
224)
    at
io.netty.channel.nio.AbstractNioChannel$AbstractNioUnsafe.finishConnect(AbstractNio
Channel.java:289)
    at io.netty.channel.nio.NioEventLoop.processSelectedKey(NioEventLoop.java:528)
    at
io.netty.channel.nio.NioEventLoop.processSelectedKeysOptimized(NioEventLoop.java:46
8)
    at io.netty.channel.nio.NioEventLoop.processSelectedKeys(NioEventLoop.java:382)
    at io.netty.channel.nio.NioEventLoop.run(NioEventLoop.java:354)
    at
io.netty.util.concurrent.SingleThreadEventExecutor$2.run(SingleThreadEventExecutor.
java:111)
    ... 1 more
```

回答

在运行应用程序时，使用 Executor 参数“--executor-cores 4”，单进程中并行度高导致 IO 非常繁忙，以至于任务运行缓慢。

```
16/02/26 10:04:53 INFO TaskSetManager: Finished task 2139.0 in stage 1.0 (TID
151149) in 376455 ms on 10-196-115-2 (694/153378)
```

单个任务运行时间超过 6 分钟，从而导致连接超时问题，最终使得任务失败。

将参数中的核数设置为 1，“--executor-cores 1”，任务正常完成，单个任务处理时间在合理范围之内(15 秒左右)。

```
16/02/29 02:24:46 INFO TaskSetManager: Finished task 59564.0 in stage 1.0 (TID
208574) in 15088 ms on 10-196-115-6 (59515/153378)
```

因此，处理这类网络超时任务，可以减少单个 Executor 的核数来规避该类问题。

21.9.1.4 当事件队列溢出时如何配置事件队列的大小

问题

当 Driver 日志中出现如下的日志时，表示事件队列溢出了。当事件队列溢出时如何配置事件队列的大小？

- 普通应用

```
Dropping SparkListenerEvent because no remaining room in event queue.
This likely means one of the SparkListeners is too slow and cannot keep
up with the rate at which tasks are being started by the scheduler.
```

- Spark Streaming 应用

```
Dropping StreamingListenerEvent because no remaining room in event queue.
This likely means one of the StreamingListeners is too slow and cannot keep
up with the rate at which events are being started by the scheduler.
```

回答

1. 停止应用，在 Spark 的配置文件“spark-defaults.conf”中将配置项“spark.event.listener.logEnable”配置为“true”。并把配置项“spark.eventQueue.size”配置为 1000W。如果需要控制打印频率（默认为 1000 毫秒打印 1 条日志），请根据需要修改配置项“spark.event.listener.logRate”，该配置项的单位为毫秒。
2. 启动应用，可以发现如下的日志信息（消费者速率、生产者速率、当前队列中的消息数量和队列中消息数量的最大值）。

```
INFO LiveListenerBus: [SparkListenerBus]:16044 events are consumed in 5000 ms.
INFO LiveListenerBus: [SparkListenerBus]:51381 events are produced in 5000 ms,
eventQueue still has 86417 events, MaxSize: 171764.
```

3. 用户可以根据日志信息【队列中消息数量的最大值 MaxSize】，在配置文件“spark-defaults.conf”中将配置项“spark.eventQueue.size”配置成合适的队列大小。比如【队列中消息数量的最大值】为 250000，那么配置合适的队列大小为 300000。

21.9.1.5 Spark 应用执行过程中，日志中一直打印 getApplicationReport 异常且应用较长时间不退出

问题

Spark 应用执行过程中，当 driver 连接 RM 失败时，会报下面的错误，且较长时间不退出。

```
16/04/23 15:31:44 INFO RetryInvocationHandler: Exception while invoking
getApplicationReport of class ApplicationClientProtocolPBClientImpl over 37 after 1
fail over attempts. Trying to fail over after sleeping for 44160ms.
java.net.ConnectException: Call From vm1/192.168.39.30 to vm1:8032 failed on
connection exception: java.net.ConnectException: Connection refused; For more
details see:  http://wiki.apache.org/hadoop/ConnectionRefused
```

回答

在 Spark 中有个定期线程，通过连接 RM 监测 AM 的状态。由于连接 RM 超时，就会报上面的错误，且一直重试。RM 中对重试次数有限制，默认是 30 次，每次间隔默认为 30 秒左右，每次重试时都会报上面的错误。超过次数后，driver 才会退出。

RM 中关于重试相关的配置项如表 21-78 所示。

表21-78 参数说明

参数	描述	默认值
yarn.resourcemanager.connect.max-wait.ms	连接 RM 的等待时间最大值。	900000
yarn.resourcemanager.connect.retry-interval.ms	重试连接 RM 的时间频率。	30000

重试次数=yarn.resourcemanager.connect.max-wait.ms/yarn.resourcemanager.connect.retry-interval.ms，即重试次数=连接 RM 的等待时间最大值/重试连接 RM 的时间频率。

在 Spark 客户端机器中，通过修改“conf/yarn-site.xml”文件，添加并配置“yarn.resourcemanager.connect.max-wait.ms”和“yarn.resourcemanager.connect.retry-interval.ms”，这样可以更改重试次数，Spark 应用可以提早退出。

21.9.1.6 Spark 执行应用时上报“Connection to ip:port has been quiet for xxx ms while there are outstanding requests”并导致应用结束

问题

Spark 执行应用时上报如下类似错误并导致应用结束。

```
2016-04-20 10:42:00,557 | ERROR | [shuffle-server-2] | Connection to 10-91-8-
208/10.18.0.115:57959 has been quiet for 180000 ms while there are outstanding
requests. Assuming connection is dead; please adju
st spark.network.timeout if this is wrong. |
org.apache.spark.network.server.TransportChannelHandler.userEventTriggered(Transpor
tChannelHandler.java:128)
2016-04-20 10:42:00,558 | ERROR | [shuffle-server-2] | Still have 1 requests
outstanding when connection from 10-91-8-208/10.18.0.115:57959 is closed |
org.apache.spark.network.client.TransportResponseHandl
er.channelUnregistered(TransportResponseHandler.java:102)
2016-04-20 10:42:00,562 | WARN  | [yarn-scheduler-ask-am-thread-pool-160] | Error
sending message [message = DoShuffleClean(application_1459995017785_0108,319)] in 1
attempts | org.apache.spark.Logging$clas
s.logWarning(Logging.scala:92)
java.io.IOException: Connection from 10-91-8-208/10.18.0.115:57959 closed
      at
org.apache.spark.network.client.TransportResponseHandler.channelUnregistered(Transp
ortResponseHandler.java:104)
      at
org.apache.spark.network.server.TransportChannelHandler.channelUnregistered(Transpo
```

```
rtChannelHandler.java:94)
        at
io.netty.channel.AbstractChannelHandlerContext.invokeChannelUnregistered(AbstractCh
annelHandlerContext.java:158)
        at
io.netty.channel.AbstractChannelHandlerContext.fireChannelUnregistered(AbstractChan
nelHandlerContext.java:144)
        at
io.netty.channel.ChannelInboundHandlerAdapter.channelUnregistered(ChannelInboundHan
dlerAdapter.java:53)
        at
io.netty.channel.AbstractChannelHandlerContext.invokeChannelUnregistered(AbstractCh
annelHandlerContext.java:158)
        at
io.netty.channel.AbstractChannelHandlerContext.fireChannelUnregistered(AbstractChan
nelHandlerContext.java:144)
        at
io.netty.channel.ChannelInboundHandlerAdapter.channelUnregistered(ChannelInboundHan
dlerAdapter.java:53)
        at
io.netty.channel.AbstractChannelHandlerContext.invokeChannelUnregistered(AbstractCh
annelHandlerContext.java:158)
        at
io.netty.channel.AbstractChannelHandlerContext.fireChannelUnregistered(AbstractChan
nelHandlerContext.java:144)
        at
io.netty.channel.ChannelInboundHandlerAdapter.channelUnregistered(ChannelInboundHan
dlerAdapter.java:53)
        at
io.netty.channel.AbstractChannelHandlerContext.invokeChannelUnregistered(AbstractCh
annelHandlerContext.java:158)
        at
io.netty.channel.AbstractChannelHandlerContext.fireChannelUnregistered(AbstractChan
nelHandlerContext.java:144)
        at
io.netty.channel.DefaultChannelPipeline.fireChannelUnregistered(DefaultChannelPipel
ine.java:739)
        at
io.netty.channel.AbstractChannel$AbstractUnsafe$8.run(AbstractChannel.java:659)
        at
io.netty.util.concurrent.SingleThreadEventExecutor.runAllTasks(SingleThreadEventExe
cutor.java:357)
        at io.netty.channel.nio.NioEventLoop.run(NioEventLoop.java:357)
        at
io.netty.util.concurrent.SingleThreadEventExecutor$2.run(SingleThreadEventExecutor.
java:111)
        at java.lang.Thread.run(Thread.java:745)
2016-04-20 10:42:00,573 | INFO  | [dispatcher-event-loop-14] | Starting task 177.0
in stage 1492.0 (TID 1996351, linux-254, PROCESS_LOCAL, 2106 bytes) |
org.apache.spark.Logging$class.logInfo(Logging.scala:
59)
2016-04-20 10:42:00,574 | INFO  | [task-result-getter-0] | Finished task 85.0 in
stage 1492.0 (TID 1996259) in 191336 ms on linux-254 (106/3000) |
org.apache.spark.Logging$class.logInfo(Logging.scala:59)
2016-04-20 10:42:00,811 | ERROR | [Yarn application state monitor] | Yarn
```

```
application has already exited with state FINISHED! |
org.apache.spark.Logging$class.logError(Logging.scala:75)
```

回答

当配置 channel 过期时间（spark.rpc.io.connectionTimeout） ＜RPC 响应超时时间（spark.rpc.askTimeout），在特殊条件下（Full GC，网络延时等）消息响应时间较长，消息还没有反馈，channel 又达到了过期时间，该 channel 就被终止了，AM 端感知到 channel 被终止后认为 driver 失联，然后整个应用停止。

解决办法：在 Spark 客户端的“spark-defaults.conf”文件中或通过 set 命令行进行设置。参数配置时要保证 channel 过期时间（spark.rpc.io.connectionTimeout）大于或等于 RPC 响应超时时间（spark.rpc.askTimeout）。

表21-79 参数说明

参数	描述	默认值
spark.rpc.askTimeout	RPC 响应超时时间，不配置的话默认使用 spark.network.timeout 的值。	120s

21.9.1.7 NodeManager 关闭导致 Executor(s)未移除

问题

在 Executor 动态分配打开的情况下，如果在任务执行过程中，执行 NodeManager 关闭动作，NodeManager 关闭节点上的 Executor(s)在空闲超时之后，在 driver 页面上未被移除。

回答

这是因为 ResourceManager 感知到 NodeManager 关闭时，Executor(s)已经因空闲超时而被 driver 请求 kill 掉，但因 NodeManager 已经关闭，这些 Executor(s)实际上并不能被 kill 掉，因此 driver 不能感知到这些 Executor(s)的 LOST 事件，所以并未从自身的 Executor list 中移除，从而导致在 driver 页面上还能看到这些 Executor(s)，这是 YARN NodeManager 关闭之后的正常现象，NodeManager 再次启动后，这些 Executor(s)会被移除。

21.9.1.8 Password cannot be null if SASL is enabled 异常

问题

运行 Spark 的应用启用了 ExternalShuffle，应用出现了 Task 任务丢失，原因是由于 java.lang.NullPointerException: Password cannot be null if SASL is enabled 异常，部分关键日志如下图所示：

```
2016-05-13 12:05:27,093 | WARN  | [task-result-getter-2] | Lost task 98.0 in stage 22.1 (TID 193603, linux-173, 2): FetchFailed(BlockManagerId(13, 172.168.100.13, 27337),
org.apache.spark.shuffle.FetchFailedException: java.lang.NullPointerException: Password cannot be null if SASL is enabled
        at org.spark-project.guava.base.Preconditions.checkNotNull(Preconditions.java:208)
        at org.apache.spark.network.sasl.SparkSaslServer.encodePassword(SparkSaslServer.java:196)
        at org.apache.spark.network.sasl.SparkSaslServer$DigestCallbackHandler.handle(SparkSaslServer.java:166)
        at com.sun.security.sasl.digest.DigestMD5Server.validateClientResponse(DigestMD5Server.java:589)
        at com.sun.security.sasl.digest.DigestMD5Server.evaluateResponse(DigestMD5Server.java:244)
        at org.apache.spark.network.sasl.SparkSaslServer.response(SparkSaslServer.java:119)
        at org.apache.spark.network.sasl.SaslRpcHandler.receive(SaslRpcHandler.java:100)
        at org.apache.spark.network.server.TransportRequestHandler.processRpcRequest(TransportRequestHandler.java:128)
        at org.apache.spark.network.server.TransportRequestHandler.handle(TransportRequestHandler.java:99)
        at org.apache.spark.network.server.TransportChannelHandler.channelRead0(TransportChannelHandler.java:104)
```

回答

造成该现象的原因是 NodeManager 重启。使用 ExternalShuffle 的时候，Spark 将借用 NodeManager 传输 Shuffle 数据，因此 NodeManager 的内存将成为瓶颈。

在当前版本的 FusionInsight 中，NodeManager 的默认内存只有 1G，在数据量比较大（1T 以上）的 Spark 任务下，内存严重不足，消息响应缓慢，导致 FusionInsight 健康检查认为 NodeManager 进程退出，强制重启 NodeManager，导致上述问题产生。

解决方式：

调整 NodeManager 的内存，数据量比较大（1T 以上）的情况下，NodeManager 的内存至少在 4G 以上。

21.9.1.9 向动态分区表中插入数据时，在重试的 task 中出现"Failed to CREATE_FILE"异常

问题

向动态分区表中插入数据时，shuffle 过程中大面积 shuffle 文件损坏（磁盘掉线、节点故障等）后，为什么会在重试的 task 中出现"Failed to CREATE_FILE"异常？

```
2016-06-25 15:11:31,323 | ERROR | [Executor task launch worker-0] | Exception in
task 15.0 in stage 10.1 (TID 1258) |
org.apache.spark.Logging$class.logError(Logging.scala:96)
org.apache.hadoop.hive.ql.metadata.HiveException:
org.apache.hadoop.ipc.RemoteException(org.apache.hadoop.hdfs.protocol.AlreadyBeingC
reatedException): Failed to CREATE_FILE /user/hive/warehouse/testdb.db/we
b_sales/.hive-staging_hive_2016-06-25_15-09-16_999_8137121701603617850-1/-ext-
10000/_temporary/0/_temporary/attempt_201606251509_0010_m_000015_0/ws_sold_date=199
9-12-17/part-00015 for DFSClient_attempt_2016
06251509_0010_m_000015_0_353134803_151 on 10.1.1.5 because this file lease is
currently owned by DFSClient_attempt_201606251509_0010_m_000015_0_-848353830_156 on
10.1.1.6
```

回答

动态分区表插入数据的最后一步是读取 shuffle 文件的数据，再写入到表对应的分区文件中。

当大面积 shuffle 文件损坏后，会引起大批量 task 失败，然后进行 job 重试。重试前 Spark 会将写表分区文件的句柄关闭，大批量 task 关闭句柄时 HDFS 无法及时处理。在 task 进行下一次重试时，句柄在 NameNode 端未被及时释放，即会抛出"Failed to CREATE_FILE"异常。

这种现象仅会在大面积 shuffle 文件损坏时发生，出现异常后 task 会重试，重试耗时在毫秒级，影响较小，可以忽略不计。

21.9.1.10 使用 Hash shuffle 出现任务失败

问题

使用 Hash shuffle 运行 1000000（map 个数）*100000（reduce 个数）的任务，运行日志中出现大量的消息发送失败和 Executor 心跳超时，从而导致任务失败。

回答

对于 Hash shuffle，在 shuffle 的过程中写数据时不做排序操作，只是将数据根据 Hash 的结果，将各个 reduce 分区的数据写到各自的磁盘文件中。

这样带来的问题是如果 reduce 分区的数量比较大的话，将会产生大量的磁盘文件（比如：该问题中将产生 1000000 * 100000 = 10^11 个 shuffle 文件）。如果磁盘文件数量特别巨大，对文件读写的性能会带来比较大的影响，此外由于同时打开的文件句柄数量多，序列化以及压缩等操作需要占用非常大的临时内存空间，对内存的使用和 GC 带来很大的压力，从而容易造成 Executor 无法响应 Driver。

因此，建议使用 Sort shuffle，而不使用 Hash shuffle。

21.9.1.11 访问 Spark 应用的聚合日志页面报“DNS 查找失败”错误

问题

采用 http(s)://<spark ip>:<spark port>的方式直接访问 Spark JobHistory 页面时，如果当前跳转的 Spark JobHistory 页面不是 FusionInsight 代理的页面（FusionInsight 代理的 URL 地址类似于：https://<oms ip>:20026/Spark2x/JobHistory2x/xx/），单击某个应用，再单击“AggregatedLogs”，然后单击需要查看的其中一个 Executor 的“logs”，此时会报如图 21-9 所示的错误。

图21-9 聚合日志失败页面

回答

原因：弹出的 URL 地址（如 https://<hostname>:20026/Spark2x/JobHistory2x/xx/history/application_xxx/jobs/），其中的<hostname>没有在 Windows 系统的 hosts 文件中添加域名信息，导致 DNS 查找失败无法显示此网页。

解决措施：

- 建议用户使用 FusionInsight 代理去访问 Spark JobHistory 页面，即单击如图 21-10 中蓝框所示的 Spark WebUI 的链接。

  图21-10 FusionInsight Manager 的 Spark2x 页面

- 如果用户需要不通过 FusionInsight Manager 访问 Spark JobHistory 页面，则需要将 URL 地址中的<hostname>更改为 IP 地址进行访问，或者在 Windows 系统的 hosts 文件中添加该域名信息。

21.9.1.12 由于 Timeout waiting for task 异常导致 Shuffle FetchFailed

问题

使用 JDBCServer 模式执行 100T 的 TPCDS 测试套，出现 Timeout waiting for task 异常导致 Shuffle FetchFailed，Stage 一直重试，任务无法正常完成。

回答

JDBCServer 方式使用了 ShuffleService 功能，Reduce 阶段所有的 Executor 会从 NodeManager 中获取数据，当数据量达到一个级别（10T 级别），会出现 NodeManager 单点瓶颈（ShuffleService 服务在 NodeManager 进程中），就会出现某些 Task 获取数据超时，从而出现该问题。

因此，当数据量达到 10T 级别以上的 Spark 任务，建议用户关闭 ShuffleService 功能，即在“Spark-defaults.conf”配置文件中将配置项“spark.shuffle.service.enabled”配置为“false”。

21.9.1.13 Executor 进程 Crash 导致 Stage 重试

问题

在执行大数据量的 Spark 任务（如 100T 的 TPCDS 测试套）过程中，有时会出现 Executor 丢失从而导致 Stage 重试的现象。查看 Executor 的日志，出现“Executor 532 is lost rpc with driver,but is still alive, going to kill it”所示信息，表明 Executor 丢失是由于 JVM Crash 导致的。

JVM 的关键 Crash 错误日志，如下：

```
#
# A fatal error has been detected by the Java Runtime Environment:
#
#  Internal Error (sharedRuntime.cpp:834), pid=241075, tid=140476258551552
#  fatal error: exception happened outside interpreter, nmethods and vtable stubs
at pc 0x00007fcda9eb8eb1
```

回答

上述问题在 Oracle 官网上有类似的情况，该问题现象是 Oracle JVM 的缺陷，并不是平台代码引入的问题，且 Spark 中有对 Executor 的容错机制，Executor Crash 之后，Stage 会进入重试，可以保证任务最终可以执行完成，不会对业务产生影响。

21.9.1.14 执行大数据量的 shuffle 过程时 Executor 注册 shuffle service 失败

问题

执行超过 50T 数据的 shuffle 过程时，出现部分 Executor 注册 shuffle service 超时然后丢失从而导致任务失败的问题。错误日志如下所示：

```
2016-10-19 01:33:34,030 | WARN | ContainersLauncher #14 | Exception from container-
launch with container ID: container_e1452_1476801295027_2003_01_004512 and exit
code: 1 | LinuxContainerExecutor.java:397
ExitCodeException exitCode=1:
at org.apache.hadoop.util.Shell.runCommand(Shell.java:561)
at org.apache.hadoop.util.Shell.run(Shell.java:472)
at org.apache.hadoop.util.Shell$ShellCommandExecutor.execute(Shell.java:738)
at
org.apache.hadoop.yarn.server.nodemanager.LinuxContainerExecutor.launchContainer(Li
nuxContainerExecutor.java:381)
at
org.apache.hadoop.yarn.server.nodemanager.containermanager.launcher.ContainerLaunch
.call(ContainerLaunch.java:312)
at
org.apache.hadoop.yarn.server.nodemanager.containermanager.launcher.ContainerLaunch
.call(ContainerLaunch.java:88)
at java.util.concurrent.FutureTask.run(FutureTask.java:266)
at java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1142)
```

```
at java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:617)
at java.lang.Thread.run(Thread.java:745)
2016-10-19 01:33:34,031 | INFO | ContainersLauncher #14 | Exception from container-launch. | ContainerExecutor.java:300
2016-10-19 01:33:34,031 | INFO | ContainersLauncher #14 | Container id: container_e1452_1476801295027_2003_01_004512 | ContainerExecutor.java:300
2016-10-19 01:33:34,031 | INFO | ContainersLauncher #14 | Exit code: 1 | ContainerExecutor.java:300
2016-10-19 01:33:34,031 | INFO | ContainersLauncher #14 | Stack trace: ExitCodeException exitCode=1: | ContainerExecutor.java:300
```

回答

由于当前数据量较大，有 50T 数据导入，超过了 shuffle 的规格，shuffle 负载过高，shuffle service 服务处于过载状态，可能无法及时响应 Executor 的注册请求，从而出现上面的问题。

Executor 注册 shuffle service 的超时时间是 5 秒，最多重试 3 次，该参数目前不可配。

建议适当调大 task retry 次数和 Executor 失败次数。

在客户端的“spark-defaults.conf”配置文件中配置如下参数。
“spark.yarn.max.executor.failures”若不存在，则手动添加该参数项。

表21-80 参数说明

参数	描述	默认值
spark.task.maxFailures	task retry 次数。	4
spark.yarn.max.executor.failures	Executor 失败次数。 关闭 Executor 个数动态分配功能的场景即“spark.dynamicAllocation.enabled”参数设为“false”时。	numExecutors * 2, with minimum of 3
	Executor 失败次数。 开启 Executor 个数动态分配功能的场景即“spark.dynamicAllocation.enabled”参数设为“true”时。	3

21.9.1.15 在 Spark 应用执行过程中 NodeManager 出现 OOM 异常

问题

当开启 Yarn External Shuffle 服务时，在 Spark 应用执行过程中，如果当前 shuffle 连接过多，Yarn External Shuffle 会出现“java.lang.OutofMemoryError: Direct buffer Memory”的异常，该异常说明内存不足。错误日志如下：

```
2016-12-06 02:01:00,768 | WARN  | shuffle-server-38 | Exception in connection from
/192.168.101.95:53680 | TransportChannelHandler.java:79
io.netty.handler.codec.DecoderException: java.lang.OutOfMemoryError: Direct buffer
memory
       at
io.netty.handler.codec.ByteToMessageDecoder.channelRead(ByteToMessageDecoder.java:1
53)
       at
io.netty.channel.AbstractChannelHandlerContext.invokeChannelRead(AbstractChannelHan
dlerContext.java:333)
       at
io.netty.channel.AbstractChannelHandlerContext.fireChannelRead(AbstractChannelHandl
erContext.java:319)
       at
io.netty.channel.DefaultChannelPipeline.fireChannelRead(DefaultChannelPipeline.java
:787)
       at
io.netty.channel.nio.AbstractNioByteChannel$NioByteUnsafe.read(AbstractNioByteChann
el.java:130)
       at
io.netty.channel.nio.NioEventLoop.processSelectedKey(NioEventLoop.java:511)
       at
io.netty.channel.nio.NioEventLoop.processSelectedKeysOptimized(NioEventLoop.java:46
8)
       at
io.netty.channel.nio.NioEventLoop.processSelectedKeys(NioEventLoop.java:382)
       at io.netty.channel.nio.NioEventLoop.run(NioEventLoop.java:354)
       at
io.netty.util.concurrent.SingleThreadEventExecutor$2.run(SingleThreadEventExecutor.
java:116)
       at java.lang.Thread.run(Thread.java:745)
Caused by: java.lang.OutOfMemoryError: Direct buffer memory
       at java.nio.Bits.reserveMemory(Bits.java:693)
       at java.nio.DirectByteBuffer.<init>(DirectByteBuffer.java:123)
       at java.nio.ByteBuffer.allocateDirect(ByteBuffer.java:311)
       at io.netty.buffer.PoolArena$DirectArena.newChunk(PoolArena.java:434)
       at io.netty.buffer.PoolArena.allocateNormal(PoolArena.java:179)
       at io.netty.buffer.PoolArena.allocate(PoolArena.java:168)
       at io.netty.buffer.PoolArena.reallocate(PoolArena.java:277)
       at io.netty.buffer.PooledByteBuf.capacity(PooledByteBuf.java:108)
       at io.netty.buffer.AbstractByteBuf.ensureWritable(AbstractByteBuf.java:251)
       at io.netty.buffer.AbstractByteBuf.writeBytes(AbstractByteBuf.java:849)
       at io.netty.buffer.AbstractByteBuf.writeBytes(AbstractByteBuf.java:841)
       at io.netty.buffer.AbstractByteBuf.writeBytes(AbstractByteBuf.java:831)
       at
io.netty.handler.codec.ByteToMessageDecoder.channelRead(ByteToMessageDecoder.java:1
46)
       ... 10 more
```

回答

对于 Yarn 的 Shuffle Service，其启动的线程数为机器可用 CPU 核数的两倍，而默认配置的 Direct buffer Memory 为 128M，因此当有较多 shuffle 同时连接时，平均分配到各线程所能使用的 Direct buffer Memory 将较低（例如，当机器的 CPU 为 40 核，Yarn 的

Shuffle Service 启动的线程数为 80，80 个线程共享进程里的 Direct buffer Memory，这种场景下每个线程分配到的内存将不足 2MB）。

因此建议根据集群中的 NodeManager 节点的 CPU 核数适当调整 Direct buffer Memory，例如在 CPU 核数为 40 时，将 Direct buffer Memory 配置为 512M。即配置集群 NodeManger 的“GC_OPTS”参数，如：

-XX:MaxDirectMemorySize=512M

说明

GC_OPTS 参数中-XX:MaxDirectMemorySize 默认没有配置，如需配置，用户可在 GC_OPTS 参数中自定义添加。

具体的配置方法如下：

用户可登录 FusionInsight Manager，单击“集群 > *待操作集群的名称* > 服务 > Yarn > 配置”，单击“全部配置”，单击“NodeManager > 系统”，在“GC_OPTS”参数中修改配置。

表21-81 参数说明

参数	描述	默认值
GC_OPTS	Yarn NodeManger 的 GC 参数。	128M

21.9.1.16 安全集群使用 HiBench 工具运行 sparkbench 获取不到 realm

问题

运行 HiBench6 的 sparkbench 任务，如 Wordcount，任务执行失败，bench.log 显示 Yarn 任务执行失败，登录 Yarn UI，查看对应 application 的失败信息，显示如下：

```
Exception in thread "main" org.apache.spark.SparkException: Unable to load YARN
support
  at
org.apache.spark.deploy.SparkHadoopUtil$.liftedTree1$1(SparkHadoopUtil.scala:390)
  at
org.apache.spark.deploy.SparkHadoopUtil$.yarn$lzycompute(SparkHadoopUtil.scala:385)
  at org.apache.spark.deploy.SparkHadoopUtil$.yarn(SparkHadoopUtil.scala:385)
  at org.apache.spark.deploy.SparkHadoopUtil$.get(SparkHadoopUtil.scala:410)
  at
org.apache.spark.deploy.yarn.ApplicationMaster$.main(ApplicationMaster.scala:796)
  at
org.apache.spark.deploy.yarn.ExecutorLauncher$.main(ApplicationMaster.scala:821)
  at org.apache.spark.deploy.yarn.ExecutorLauncher.main(ApplicationMaster.scala)
 Caused by: java.lang.IllegalArgumentException: Can't get Kerberos realm
  at
org.apache.hadoop.security.HadoopKerberosName.setConfiguration(HadoopKerberosName.j
ava:65)
  at
org.apache.hadoop.security.UserGroupInformation.initialize(UserGroupInformation.jav
a:288)
  at
```

```
org.apache.hadoop.security.UserGroupInformation.setConfiguration(UserGroupInformation.java:336)
  at org.apache.spark.deploy.SparkHadoopUtil.<init>(SparkHadoopUtil.scala:51)
  at
org.apache.spark.deploy.yarn.YarnSparkHadoopUtil.<init>(YarnSparkHadoopUtil.scala:49)
  at sun.reflect.NativeConstructorAccessorImpl.newInstance0(Native Method)
  at
sun.reflect.NativeConstructorAccessorImpl.newInstance(NativeConstructorAccessorImpl.java:62)
  at
sun.reflect.DelegatingConstructorAccessorImpl.newInstance(DelegatingConstructorAccessorImpl.java:45)
  at java.lang.reflect.Constructor.newInstance(Constructor.java:423)
  at java.lang.Class.newInstance(Class.java:442)
  at
org.apache.spark.deploy.SparkHadoopUtil$.liftedTree1$1(SparkHadoopUtil.scala:387)
  ... 6 more
 Caused by: java.lang.reflect.InvocationTargetException
  at sun.reflect.NativeMethodAccessorImpl.invoke0(Native Method)
  at sun.reflect.NativeMethodAccessorImpl.invoke(NativeMethodAccessorImpl.java:62)
  at
sun.reflect.DelegatingMethodAccessorImpl.invoke(DelegatingMethodAccessorImpl.java:43)
  at java.lang.reflect.Method.invoke(Method.java:498)
  at
org.apache.hadoop.security.authentication.util.KerberosUtil.getDefaultRealm(KerberosUtil.java:88)
  at
org.apache.hadoop.security.HadoopKerberosName.setConfiguration(HadoopKerberosName.java:63)
  ... 16 more
 Caused by: KrbException: Cannot locate default realm
  at sun.security.krb5.Config.getDefaultRealm(Config.java:1029)
  ... 22 more
```

回答

失败原因是 C80SPC200 版本开始，安装集群不再替换/etc/krb5.conf 文件，改为通过配置参数指定到客户端内 krb5 路径，而 HiBench 并不引用客户端配置文件。解决方案：将客户端/opt/client/KrbClient/kerberos/var/krb5kdc/krb5.conf，copy 覆盖集群内所有节点的/etc/krb5.conf，注意替换前需要备份。

21.9.2 SQL 和 DataFrame

21.9.2.1 Spark SQL ROLLUP 和 CUBE 使用的注意事项

问题

假设有表 src(d1, d2, m)，其数据如下：

```
1 a 1
1 b 1
2 b 2
```

对于语句 select d1, sum(d1) from src group by d1, d2 with rollup 其结果如下：

```
NULL 0
1    2
2    2
1    1
1    1
2    2
```

对于以上结果的第一条为什么是(NULL,0)而不是(NULL,4)。

回答

在进行 rollup 和 cube 操作时，用户通常是基于维度进行分析，需要的是度量的结果，因此不会对维度进行聚合操作。

例如当前有表 src(d1, d2, m)，那么语句 1“select d1, sum(m) from src group by d1, d2 with rollup”就是对维度 d1 和 d2 进行上卷操作计算度量 m 的结果，因此有实际业务意义，而其结果也跟预期是一致的。但语句 2“select d1, sum(d1) from src group by d1, d2 with rollup”则从业务上无法解释。当前对于语句 2 所有聚合（sum/avg/max/min）结果均为 0。

说明

只有在 rollup 和 cube 操作中对出现在 group by 中的字段进行聚合结果才是 0，非 rollup 和 cube 操作其结果跟预期一致。

21.9.2.2 Spark SQL 在不同 DB 都可以显示临时表

问题

切换数据库之后，为什么还能看到之前数据库的临时表？

1. 创建一个 DataSource 的临时表，例如以下建表语句。

```
create temporary table ds_parquet
using org.apache.spark.sql.parquet
options(path '/tmp/users.parquet');
```

2. 切换到另外一个数据库，执行 ***show tables***，依然可以看到上个步骤创建的临时表。

```
0: jdbc:hive2://192.168.169.84:22550/default> show tables;
+-----------------+--------------+--+
|    tableName    | isTemporary  |
+-----------------+--------------+--+
| ds_parquet      | true         |
| cmb_tbl_carbon  | false        |
+-----------------+--------------+--+
2 rows selected (0.109 seconds)
0: jdbc:hive2://192.168.169.84:22550/default>
```

回答

Spark 的表管理层次如图 21-11 所示，最底层是 Spark 的临时表，存储着使用 DataSource 方式的临时表，在这一个层面中没有数据库的概念，因此对于这种类型表，表名在各个数据库中都是可见的。

上层为 Hive 的 MetaStore，该层有了各个 DB 之分。在每个 DB 中，又有 Hive 的临时表与 Hive 的持久化表，因此在 Spark 中允许三个层次的同名数据表。

查询的时候，Spark SQL 优先查看是否有 Spark 的临时表，再查找当前 DB 的 Hive 临时表，最后查找当前 DB 的 Hive 持久化表。

图21-11 Spark 表管理层次

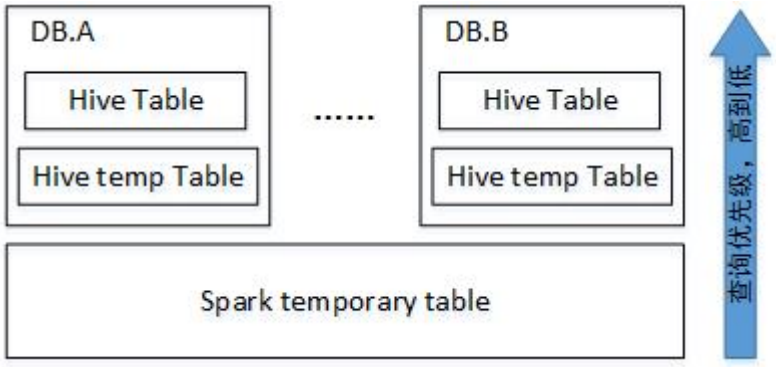

当 Session 退出时，用户操作相关的临时表将自动删除。建议用户不要手动删除临时表。

删除临时表时，其优先级与查询相同，从高到低为 Spark 临时表、Hive 临时表、Hive 持久化表。如果想直接删除 Hive 表，不删除 Spark 临时表，您可以直接使用 ***drop table DbName.TableName*** 命令。

21.9.2.3 如何在 Spark 命令中指定参数值

问题

如果用户不希望在界面上或配置文件设置参数值，如何在 Spark 命令中指定参数值？

回答

Spark 的配置项，不仅可以在配置文件中设置，也可以在命令中指定参数值。

在 Spark 客户端，应用执行命令添加如下内容设置参数值，命令执行完成后立即生效。在--conf 后添加参数名称及其参数值，例如：

--conf spark.eventQueue.size=50000

21.9.2.4 SparkSQL 建表时的目录权限

问题

新建的用户，使用 SparkSQL 建表时出现类似如下错误：

```
0: jdbc:hive2://192.168.169.84:22550/default> create table testACL(c string);
Error: org.apache.spark.sql.execution.QueryExecutionException: FAILED: Execution
Error, return code 1 from
org.apache.hadoop.hive.ql.exec.DDLTask. MetaException(message:Got exception:
org.apache.hadoop.security.AccessControlException
Permission denied: user=testACL, access=EXECUTE,
inode="/user/hive/warehouse/testacl":spark:hadoop:drwxrwx---
    at
org.apache.hadoop.hdfs.server.namenode.FSPermissionChecker.checkAccessAcl(FSPermiss
ionChecker.java:403)
    at
org.apache.hadoop.hdfs.server.namenode.FSPermissionChecker.check(FSPermissionChecke
r.java:306)
    at
org.apache.hadoop.hdfs.server.namenode.FSPermissionChecker.checkTraverse(FSPermissi
onChecker.java:259)
    at
org.apache.hadoop.hdfs.server.namenode.FSPermissionChecker.checkPermission(FSPermis
sionChecker.java:205)
    at
org.apache.hadoop.hdfs.server.namenode.FSPermissionChecker.checkPermission(FSPermis
sionChecker.java:190)
    at
org.apache.hadoop.hdfs.server.namenode.FSDirectory.checkPermission(FSDirectory.java
:1710)
    at
org.apache.hadoop.hdfs.server.namenode.FSDirStatAndListingOp.getFileInfo(FSDirStatA
ndListingOp.java:109)
    at
org.apache.hadoop.hdfs.server.namenode.FSNamesystem.getFileInfo(FSNamesystem.java:3
762)
    at
org.apache.hadoop.hdfs.server.namenode.NameNodeRpcServer.getFileInfo(NameNodeRpcSer
ver.java:1014)
    at
org.apache.hadoop.hdfs.protocolPB.ClientNamenodeProtocolServerSideTranslatorPB.getF
ileInfo(ClientNamenodeProtocolServerSideTranslatorPB.java:853)
    at
org.apache.hadoop.hdfs.protocol.proto.ClientNamenodeProtocolProtos$ClientNamenodePr
otocol$2.callBlockingMethod(ClientNamenodeProtocolProtos.java)
    at
org.apache.hadoop.ipc.ProtobufRpcEngine$Server$ProtoBufRpcInvoker.call(ProtobufRpcE
ngine.java:616)
    at org.apache.hadoop.ipc.RPC$Server.call(RPC.java:973)
    at org.apache.hadoop.ipc.Server$Handler$1.run(Server.java:2089)
    at org.apache.hadoop.ipc.Server$Handler$1.run(Server.java:2085)
    at java.security.AccessController.doPrivileged(Native Method)
    at javax.security.auth.Subject.doAs(Subject.java:422)
    at
```

```
org.apache.hadoop.security.UserGroupInformation.doAs(UserGroupInformation.java:1675)
    at org.apache.hadoop.ipc.Server$Handler.run(Server.java:2083)
) (state=,code=0)
```

回答

Spark SQL 建表底层调用的是 Hive 的接口，其建表时会在“/user/hive/warehouse”目录下新建一个以表名命名的目录，因此要求用户具备“/user/hive/warehouse”目录的读写、执行权限或具有 Hive 的 group 权限。

“/user/hive/warehouse”目录可通过 hive.metastore.warehouse.dir 参数指定。

21.9.2.5 为什么不同服务之间互相删除 UDF 失败

问题

不同服务之间互相删除 UDF 失败，例如，Spark SQL 无法删除 Hive 创建的 UDF。

回答

当前可以通过以下 3 种方式创建 UDF：

1. 在 Hive 端创建 UDF。
2. 通过 JDBCServer 接口创建 UDF。用户可以通过 Spark Beeline 或者 JDBC 客户端代码来连接 JDBCServer，从而执行 SQL 命令，创建 UDF。
3. 通过 spark-sql 创建 UDF。

删除 UDF 失败，存在以下两种场景：

- 在 Spark Beeline 中，对于其他方式创建的 UDF，需要重新启动 Spark 服务端的 JDBCServer 后，才能将此类 UDF 删除成功，否则删除失败。在 spark-sql 中，对于其他方式创建的 UDF，需要重新启动 spark-sql 后，才能将此类 UDF 删除成功，否则删除失败。

  原因：创建 UDF 后，Spark 服务端的 JDBCServer 未重启或者 spark-sql 未重新启动的场景，Spark 所在线程的 FunctionRegistry 对象未保存新创建的 UDF，那么删除 UDF 时就会出现错误。

  解决方法：重启 Spark 服务端的 JDBCServer 和 spark-sql，再删除此类 UDF。
- 在 Hive 端创建 UDF 时未在创建语句中指定 jar 包路径，而是通过 **add jar** 命令添加 UDF 的 jar 包如 **add jar /opt/test/two_udfs.jar**，这种场景下，在其他服务中删除 UDF 时就会出现 ClassNotfound 的错误，从而导致删除失败。

  原因：在删除 UDF 时，会先获取该 UDF，此时会去加载该 UDF 对应的类，由于创建 UDF 时是通过 **add jar** 命令指定 jar 包路径的，其他服务进程的 classpath 不存在这些 jar 包，因此会出现 ClassNotfound 的错误从而导致删除失败。

  解决方法：该方式创建的 UDF 不支持通过其他方式删除，只能通过与创建时一致的方式删除。

21.9.2.6 Spark SQL 无法查询到 Parquet 类型的 Hive 表的新插入数据

问题

为什么通过 Spark SQL 无法查询到存储类型为 Parquet 的 Hive 表的新插入数据？主要有以下两种场景存在这个问题：

1. 对于分区表和非分区表，在 Hive 客户端中执行插入数据的操作后，会出现 Spark SQL 无法查询到最新插入的数据的问题。
2. 对于分区表，在 Spark SQL 中执行插入数据的操作后，如果分区信息未改变，会出现 Spark SQL 无法查询到最新插入的数据的问题。

回答

由于 Spark 存在一个机制，为了提高性能会缓存 Parquet 的元数据信息。当通过 Hive 或其他方式更新了 Parquet 表时，缓存的元数据信息未更新，导致 Spark SQL 查询不到新插入的数据。

对于存储类型为 Parquet 的 Hive 分区表，在执行插入数据操作后，如果分区信息未改变，则缓存的元数据信息未更新，导致 Spark SQL 查询不到新插入的数据。

解决措施：在使用 Spark SQL 查询之前，需执行 Refresh 操作更新元数据信息。

REFRESH TABLE table_name;

table_name 为刷新的表名，该表必须存在，否则会出错。

执行查询语句时，即可获取到最新插入的数据。

21.9.2.7 cache table 使用指导

问题

cache table 的作用是什么？cache table 时需要注意哪些方面？

回答

Spark SQL 可以将表 cache 到内存中，并且使用压缩存储来尽量减少内存压力。通过将表 cache，查询可以直接从内存中读取数据，从而减少读取磁盘带来的内存开销。

但需要注意的是，被 cache 的表会占用 executor 的内存。尽管在 Spark SQL 采用压缩存储的方式来尽量减少内存开销、缓解 GC 压力，但当缓存的表较大或者缓存表数量较多时，将不可避免的影响 executor 的稳定性。

此时的最佳实践是，当不需要将表 cache 来实现查询加速时，应及时将表进行 uncache 以释放内存。可以执行命令 ***uncache table*** *table_name* 来 uncache 表。

说明

被 cache 的表也可以在 Spark Driver UI 的 Storage 标签里查看。

21.9.2.8 Repartition 时有部分 Partition 没数据

问题

在 repartition 操作时，分块数“spark.sql.shuffle.partitions”设置为 4500，repartition 用到的 key 列中有超过 4000 个的不同 key 值。期望不同 key 对应的数据能分到不同的 partition，实际上却只有 2000 个 partition 里有数据，不同 key 对应的数据也被分到相同的 partition 里。

回答

这是正常现象。

数据分到哪个 partition 是通过对 key 的 hashcode 取模得到的，不同的 hashcode 取模后的结果有可能是一样的，那样数据就会被分到相同的 partition 里面，因此出现有些 partition 没有数据而有些 partition 里面有多个 key 对应的数据。

通过调整“spark.sql.shuffle.partitions”参数值可以调整取模时的基数，改善数据分块不均匀的情况，多次验证发现配置为质数或者奇数效果比较好。

在 Driver 端的“spark-defaults.conf”配置文件中调整如下参数。

表21-82 参数说明

参数	描述	默认值
spark.sql.shuffle.partitions	shuffle 操作时，shuffle 数据的分块数。	200

21.9.2.9 16T 的文本数据转成 4T Parquet 数据失败

问题

使用默认配置时，16T 的文本数据转成 4T Parquet 数据失败，报如下错误信息。

```
Job aborted due to stage failure: Task 2866 in stage 11.0 failed 4 times, most
recent failure: Lost task 2866.6 in stage 11.0 (TID 54863, linux-161, 2):
java.io.IOException: Failed to connect to /10.16.1.11:23124
at
org.apache.spark.network.client.TransportClientFactory.createClient(TransportClient
Factory.java:214)
at
org.apache.spark.network.client.TransportClientFactory.createClient(TransportClient
Factory.java:167)
at
org.apache.spark.network.netty.NettyBlockTransferService$$anon$1.createAndStart(Net
tyBlockTransferService.scala:92)
```

使用的默认配置如表 21-83 所示。

表21-83 参数说明

参数	描述	默认值
spark.sql.shuffle.partitions	shuffle 操作时，shuffle 数据的分块数。	200
spark.shuffle.sasl.timeout	shuffle 操作时 SASL 认证的超时时间。单位：秒。	120s
spark.shuffle.io.connectionTimeout	shuffle 操作时连接远程节点的超时时间。单位：秒。	120s
spark.network.timeout	所有涉及网络连接操作的超时时间。单位：秒。	360s

回答

由于当前数据量较大，有 16T，而分区数只有 200，造成每个 task 任务过重，才会出现上面的问题。

为了解决上面问题，需要对参数进行调整。

- 增大 partition 数，把任务切分的更小。
- 增大任务执行过程中的超时时间。

在客户端的“spark-defaults.conf”配置文件中配置如下参数。

表21-84 参数说明

参数	描述	建议值
spark.sql.shuffle.partitions	shuffle 操作时，shuffle 数据的分块数。	4501
spark.shuffle.sasl.timeout	shuffle 操作时 SASL 认证的超时时间。单位：秒。	2000s
spark.shuffle.io.connectionTimeout	shuffle 操作时连接远程节点的超时时间。单位：秒。	3000s
spark.network.timeout	所有涉及网络连接操作的超时时间。单位：秒。	360s

21.9.2.10 当表名为 table 时，执行相关操作时出现异常

问题

当创建了表名为 table 的表后，执行 **drop table table** 上报以下错误，或者执行其他操作也会出现类似错误。

```
16/07/12 18:56:29 ERROR SparkSQLDriver: Failed in [drop table table]
java.lang.RuntimeException: [1.1] failure: identifier expected
table
^
at scala.sys.package$.error(package.scala:27)
at
org.apache.spark.sql.catalyst.SqlParserTrait$class.parseTableIdentifier(SqlParser.s
cala:56)
at
org.apache.spark.sql.catalyst.SqlParser$.parseTableIdentifier(SqlParser.scala:485)
```

回答

这是因为 table 为 Spark SQL 的关键词，不能用作表名使用。建议用户不要使用 table 用作表的名字。

21.9.2.11 执行 analyze table 语句，因资源不足出现任务卡住

问题

使用 spark-sql 执行 ***analyze table*** 语句，任务一直卡住，打印的信息如下：

```
spark-sql> analyze table hivetable2 compute statistics;
Query ID = root_20160716174218_90f55869-000a-40b4-a908-533f63866fed
Total jobs = 1
Launching Job 1 out of 1
Number of reduce tasks is set to 0 since there's no reduce operator
16/07/20 17:40:56 WARN JobResourceUploader: Hadoop command-line option parsing not
performed. Implement the Tool interface and execute your application with
ToolRunner to remedy this.
Starting Job = job_1468982600676_0002, Tracking URL = http://10-120-175-
107:8088/proxy/application_1468982600676_0002/
Kill Command = /opt/client/HDFS/hadoop/bin/hadoop job  -kill job_1468982600676_0002
```

回答

执行 ***analyze table hivetable2 compute statistics*** 语句时，由于该 sql 语句会启动 MapReduce 任务。从 YARN 的 ResourceManager Web UI 页面看到，该任务由于资源不足导致任务没有被执行，表现出任务卡住的现象。

图21-12 ResourceManager Web UI 页面

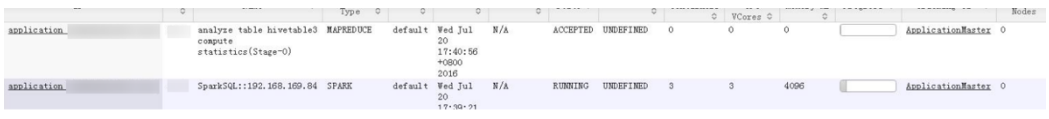

建议用户执行 ***analyze table*** 语句时加上 noscan，其功能与 ***analyze table hivetable2 compute statistics*** 语句相同，具体命令如下：

```
spark-sql> analyze table hivetable2 compute statistics noscan
```

该命令不用启动 MapReduce 任务，不会占用 YARN 资源，从而任务可以被执行。

21.9.2.12 为什么有时访问没有权限的 parquet 表时，在上报“Missing Privileges”错误提示之前，会运行一个 Job？

问题

为什么有时访问没有权限的 parquet 表时，在上报“Missing Privileges”错误提示之前，会运行一个 Job？

回答

Spark SQL 对用户 SQL 语句的执行逻辑是：首先解析出语句中包含的表，再获取表的元数据信息，然后对权限进行检查。

当表是 parquet 表时，元数据信息包括文件的 Split 信息。Split 信息需要调用 HDFS 的接口去读取，当表包含的文件数量很多时，串行读取 Split 信息变得缓慢，影响性能。故对此做了优化，当表包含的文件大于一定阈值（即 spark.sql.sources.parallelSplitDiscovery.threshold 参数值）时，会生成一个 Job，利用 Executor 的并行能力去读取，从而提升执行效率。

由于权限检查在获取表元数据之后，因此当读取的 parquet 表包含的文件数量很多时，会在报“Missing Privileges”之前，运行一个 Job 来并行读取元数据信息。

21.9.2.13 执行 Hive 命令修改元数据时失败或不生效

问题

对于 datasource 表和 Spark on HBase 表，执行 Hive 相关命令修改元数据时，出现失败或者不生效情况。

回答

当前版本不支持执行 Hive 修改元数据的相关命令操作 datasource 表和 Spark on HBase 表。

21.9.2.14 spark-sql 退出时打印 RejectedExecutionException 异常栈

问题

执行大数据量的 Spark 任务（如 2T 的 TPCDS 测试套），任务运行成功后，在 spark-sql 退出时概率性出现 RejectedExecutionException 的异常栈信息，相关日志如下所示：

```
16/07/16 10:19:56 ERROR TransportResponseHandler: Still have 2 requests outstanding
when connection from linux-192/10.1.1.5:59250 is closed
java.util.concurrent.RejectedExecutionException: Task
scala.concurrent.impl.CallbackRunnable@5fc1ab rejected from
java.util.concurrent.ThreadPoolExecutor@52fa7e19[Terminated, pool size = 0, active
threads = 0, queued tasks = 0, completed tasks = 3025]
```

回答

出现上述问题的原因是：当 spark-sql 退出时，应用退出关闭消息通道，如果当前还有消息未处理，需要做连接关闭异常的处理，此时，如果 scala 内部的线程池已经关闭，就会打印 RejectEdExecutionException 的异常栈，如果 scala 内部的线程池尚未关闭就不会打印该异常栈。

因为该问题出现在应用退出时，此时任务已经运行成功，所以不会对业务产生影响。

21.9.2.15 健康检查时，误将 JDBCServer Kill

问题

健康检查方案中，在并发执行的语句达到线程池上限后依然会导致健康检查命令无法执行，从而导致健康检查程序超时，然后把 Spark JDBCServer 进程 Kill。

回答

当前 JDBCServer 中存在两个线程池 HiveServer2-Handler-Pool 和 HiveServer2-Background-Pool，其中 HiveServer2-Handler-Pool 用于处理 session 连接，HiveServer2-Background-Pool 用于处理 SQL 语句的执行。

当前的健康检查机制是通过新建 session 连接，并在该 session 所在的线程中执行健康检查命令 ***HEALTHCHECK*** 来判断 Spark JDBCServer 的健康状况，因此 HiveServer2-Handler-Pool 必须保留一个线程，用于处理健康检查的 session 连接和健康检查命令执行，否则将导致无法建立健康检查的 session 连接或健康检查命令无法执行，从而认为 Spark JDBCServer 不健康而被 Kill。即如果当前 HiveServer2-Handler-Pool 的线程池数为 100，那么最多支持连接 99 个 session。

21.9.2.16 日期类型的字段作为过滤条件时匹配'2016-6-30'时没有查询结果

问题

为什么日期类型的字段作为过滤条件时匹配'2016-6-30'时没有查询结果，匹配'2016-06-30'时有查询结果。

如下图所示：“select count(*)from trxfintrx2012 a where trx_dte_par='2016-6-30'”，其中 trx_dte_par 为日期类型的字段，当过滤条件为“where trx_dte_par='2016-6-30'”时没有查询结果，当过滤条件为“where trx_dte_par='2016-06-30'”时有查询结果。

图21-13 示例

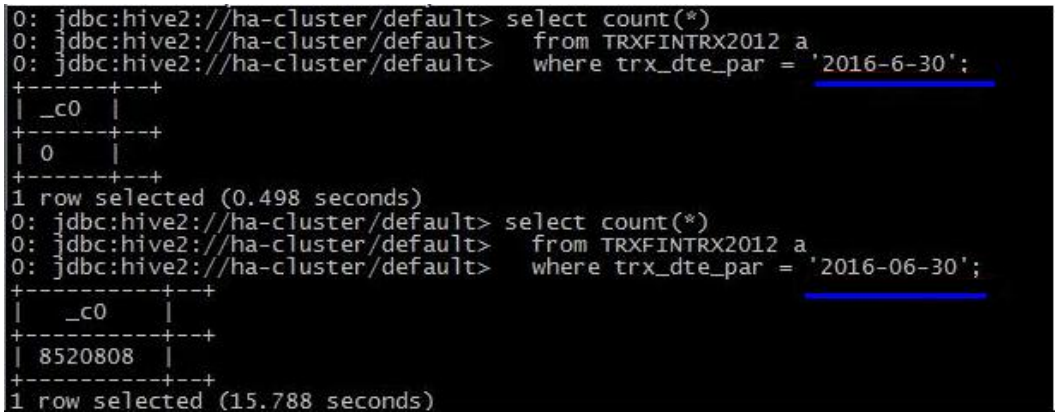

回答

在 Spark SQL 查询语句中，当查询条件中含有日期格式的字符串时，Spark SQL 不会对它做日期格式的检查，就是把它当做普通的字符串进行匹配。以上面的例子为例，如果数据格式为"yyyy-mm-dd"，那么字符串'2016-6-30'就是不正确的数据格式。

21.9.2.17 执行复杂 SQL 语句时报“Code of method ... grows beyond 64 KB”的错误

问题

当执行一个很复杂的 SQL 语句时，例如有多层语句嵌套，且单层语句中对字段有大量的逻辑处理（如多层嵌套的 case when 语句），此时执行该语句会报如下所示的错误日志，该错误表明某个方法的代码超出了 64KB。

```
java.util.concurrent.ExecutionException: java.lang.Exception: failed to compile:
org.codehaus.janino.JaninoRuntimeException: Code of method
"(Lorg/apache/spark/sql/catalyst/expressions/GeneratedClass$SpecificUnsafeProjectio
n;Lorg/apache/spark/sql/catalyst/InternalRow;)V" of class
"org.apache.spark.sql.catalyst.expressions.GeneratedClass$SpecificUnsafeProjection"
grows beyond 64 KB
```

回答

在开启钨丝计划（即 tungsten 功能）后，Spark 对于部分执行计划会使用 codegen 的方式来生成 Java 代码，但 JDK 编译时要求 Java 代码中的每个函数的长度不能超过 64KB。当执行一个很复杂的 SQL 语句时，例如有多层语句嵌套，且单层语句中对字段有大量的逻辑处理（如多层嵌套的 case when 语句），这种情况下，通过 codegen 生成的 Java 代码中函数的大小就可能会超过 64KB，从而导致编译失败。

规避措施：

当出现上述问题时，用户可以通过关闭钨丝计划，关闭使用 codegen 的方式来生成 Java 代码的功能，从而确保语句的正常执行。即在客户端的“spark-defaults.conf”配置文件中将“spark.sql.codegen.wholeStage”配置为“false”。

21.9.2.18 在 Beeline/JDBCServer 模式下连续运行 10T 的 TPCDS 测试套会出现内存不足的现象

问题

在 Driver 内存配置为 10G 时，Beeline/JDBCServer 模式下连续运行 10T 的 TPCDS 测试套，会出现因为 Driver 内存不足导致 SQL 语句执行失败的现象。

回答

当前在默认配置下，在内存中保留的 Job 和 Stage 的 UI 数据个数为 1000 个。

当前大集群优化已增加将 UI 数据溢出到磁盘的优化，其溢出条件是每个 Stage 中的 UI 数据大小达到最小阈值 5MB。如果每个 Stage 的 task 数较小，那么其 UI 数据大小可能达不到该阈值，从而导致该 Stage 的 UI 数据一直缓存在内存中，直到 UI 数据个数到达保留的上限值（当前默认值为 1000 个），旧的 UI 数据才会在内存中被清除。

因此，在将旧的 UI 数据从内存中清除之前，UI 数据会占用大量内存，从而导致执行 10T 的 TPCDS 测试套时出现 Driver 内存不足的现象。

规避措施：

- 根据业务需要，配置合适的需要保留的 Job 和 Stage 的 UI 数据个数，即配置“spark.ui.retainedJobs”和“spark.ui.retainedStages”参数。详细信息请参考 21.2.3 常用参数中的表 21-15。
- 如果需要保留的 Job 和 Stage 的 UI 数据个数较多，可通过配置“spark.driver.memory”参数，适当增大 Driver 的内存。详细信息请参考 21.2.3 常用参数中的表 21-12。

21.9.2.19 连上不同的 JDBCServer，function 不能正常使用

问题

场景一：

通过 add jar 的方式建立永久函数，当 Beeline 连上不同的 JDBCServer 或者 JDBCServer 重启后都需要重新 add jar。

图21-14 场景一异常信息

```
0: jdbc:hive2://192.168.91.247:23040/default> create function a1 as '                                                    ';
+---------+--+
| result  |
+---------+--+
+---------+--+
No rows selected (0.222 seconds)
0: jdbc:hive2://192.168.91.247:23040/default> SELECT test.a1(array(1, 2, 3), array(2));
+-------+--+
|  _c0  |
+-------+--+
| true  |
+-------+--+
1 row selected (8.282 seconds)
0: jdbc:hive2://192.168.91.247:23040/default> Closing: 0: jdbc:hive2://192.168.91.247:24002,192.168.154.81:24002,192.168.8.27:24002;serviceDiscoveryMode=zooKeep
p=auth-conf;auth=KERBEROS;principal=spark/hadoop.hadoop.com@HADOOP.COM;
100-106-121-140:/opt/hadoopclient # ./spark-beeline
It's running the fi spark-beeline, it calls /opt/hadoopclient/Spark/spark/bin/beeline
and helps to connect to the JDBCServer automatically
Connecting to jdbc:hive2://192.168.91.247:24002,192.168.154.81:24002,192.168.8.27:24002;serviceDiscoveryMode=zooKeeper;zooKeeperNamespace=sparkthriftserver;sas
doop.hadoop.com@HADOOP.COM;
2017-06-15 08:17:55,495 | WARN  | Thread-2 | TGT refresh thread time adjusted from : Thu Jun 15 05:59:42 GMT+08:00 2017 to : Thu Jun 15 08:18:55 GMT+08:00 2017
fresh interval (60 seconds) from now. | org.apache.zookeeper.Login$1.run(Login.java:177)
2017-06-15 08:17:56,743 | WARN  | main | Unable to load native-hadoop library for your platform... using builtin-java classes where applicable | org.apache.had
ader.java:62)
2017-06-15 08:17:56,773 | WARN  | TGT Renewer for sparkuser@HADOOP.COM | Exception encountered while running the renewal command. Aborting renew thread. ExitCo
l requested option while renewing credentials
  | org.apache.hadoop.security.UserGroupInformation$1.run(UserGroupInformation.java:946)
Connected to: Spark SQL (version)
Driver: Hive JDBC (version 1.2.1.spark)
Transaction isolation: TRANSACTION_REPEATABLE_READ
Beeline version 1.2.1.spark by Apache Hive
[INFO] Unable to bind key for unsupported operation: backward-delete-word
[INFO] Unable to bind key for unsupported operation: backward-delete-word
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
0: jdbc:hive2://192.168.8.27:23040/default> SELECT test.a1(array(1, 2, 3), array(2));
Error: org.apache.spark.SparkException: Unable to load UDF class (state=,code=0)
0: jdbc:hive2://192.168.8.27:23040/default> set role admin;
+------------+--------+--+
|    key     | value  |
+------------+--------+--+
| role admin |        |
+------------+--------+--+
1 row selected (0.465 seconds)
0: jdbc:hive2://192.168.8.27:23040/default> add jar /home/smartcare-udf-0.0.1-SNAPSHOT.jar;
+---------+--+
| result  |
+---------+--+
| 0       |
+---------+--+
```

场景二：

show functions 能够查到相应的函数，但是无法使用，这是由于连接上的 JDBC 节点上没有相应路径的 jar 包，添加上相应的 jar 包能够查询成功。

图21-15 场景二异常信息

```
+--------------------------------+--+
|            function            |
+--------------------------------+--+
| stddev_pop                     |
| stddev_samp                    |
| str_to_map                     |
| string                         |
| struct                         |
| substr                         |
| substring                      |
| substring_index                |
| sum                            |
| tan                            |
| tanh                           |
| test.a1                        |
| timestamp                      |
| tinyint                        |
| to_date                        |
| to_unix_timestamp              |
| to_utc_timestamp               |
| translate                      |
| trim                           |
| trunc                          |
| ucase                          |
| unbase64                       |
| unhex                          |
| unix_timestamp                 |
| upper                          |
| var_pop                        |
| var_samp                       |
| variance                       |
| weekofyear                     |
| when                           |
| window                         |
| xpath                          |
0: jdbc:hive2://192.168.8.27:22550/default> use test;
+---------+--+
| Result  |
+---------+--+
+---------+--+
No rows selected (0.038 seconds)
0: jdbc:hive2://192.168.8.27:22550/default> SELECT test.a1(array(1, 2, 3), array(2));
Error: org.apache.spark.sql.AnalysisException: Undefined function: 'test.a1'. This function is neither a registered temporary function nor a permanen
 7 (state=,code=0)
0: jdbc:hive2://192.168.8.27:22550/default> show functions;
+--------------------------------+--+
|            function            |
+--------------------------------+--+
```

回答

场景一：

add jar 语句只会将 jar 加载到当前连接的 JDBCServer 的 jarClassLoader，不同 JDBCServer 不会共用。JDBCServer 重启后会创建新的 jarClassLoader，所以需要重新 add jar。

添加 jar 包有两种方式：可以在启动 spark-sql 的时候添加 jar 包，如 **spark-sql --jars /opt/test/two_udfs.jar**；也可在 spark-sql 启动后再添加 jar 包，如 **add jar /opt/test/two_udfs.jar**。add jar 所指定的路径可以是本地路径也可以是 HDFS 上的路径。

场景二：

show functions 会从外部的 Catalog 获取当前 database 中所有的 function。SQL 中使用 function 时，JDBCServer 会加载该 function 对应的 jar。

若 jar 不存在，则该 function 无法使用，需要重新执行 ***add jar*** 命令。

21.9.2.20 Spark2x 无法访问 Spark1.5 创建的 DataSource 表

问题

在 Spark2x 中访问 Spark1.5 创建的 DataSource 表时，报无法获取 schema 信息，导致无法访问表。

回答

- 原因分析：

  这是由于 Spark2x 与 Spark1.5 存储 DataSoure 表信息的格式不一致导致的。Spark1.5 会将 schema 信息分成多个 part，使用 path.park.0 作为 key 进行存储，读取时再将各个 part 都读取出来，重新拼成完整的信息。而 Spark2x 直接使用相应的 key 获取对应的信息。这样在 Spark2x 中去读取 Spark1.5 创建的 DataSource 表时，就无法成功读取到 key 对应的信息，导致解析 DataSource 表信息失败。

  而在处理 Hive 格式的表时，Spark2x 与 Spark1.5 的存储方式一致，所以 Spark2x 可以直接读取 Spark1.5 创建的表，不存在上述问题。

- 规避措施：

  Spark2x 可以通过创建外表的方式来创建一张指向 Spark1.5 表实际数据的表，这样可以实现在 Spark2x 中读取 Spark1.5 创建的 DataSource 表。同时，Spark1.5 更新过数据后，Spark2x 中访问也能感知到变化 ，反过来一样。这样即可实现 Spark2x 对 Spark1.5 创建的 DataSource 表的访问。

21.9.2.21 为什么 spark-beeline 运行失败报“Failed to create ThriftService instance”的错误

问题

为什么 spark-beeline 运行失败报“Failed to create ThriftService instance”的错误？

Beeline 日志如下所示：

```
Error: Failed to create ThriftService instance (state=,code=0)
Beeline version 1.2.1.spark by Apache Hive
[INFO] Unable to bind key for unsupported operation: backward-delete-word
```

```
[INFO] Unable to bind key for unsupported operation: backward-delete-word
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
[INFO] Unable to bind key for unsupported operation: up-history
[INFO] Unable to bind key for unsupported operation: down-history
beeline>
```

同时，在 JDBCServer 端出现“Timed out waiting for client to connect”的错误日志，关键日志如下所示：

```
2017-07-12 17:35:11,284 | INFO  | [main] | Will try to open client transport with
JDBC Uri: jdbc:hive2://192.168.101.97:23040/default;principal=spark/hadoop.<系统域名>@<系统域名>;healthcheck=true;saslQop=auth-
conf;auth=KERBEROS;user.principal=spark/hadoop.<系统域名>@<系统域名>;user.keytab=${BIGDATA_HOME}/FusionInsight_HD_xxx/install/FusionInsight-Spark-*/keytab/spark/JDBCServer/spark.keytab |
org.apache.hive.jdbc.HiveConnection.openTransport(HiveConnection.java:317)
2017-07-12 17:35:11,326 | INFO  | [HiveServer2-Handler-Pool: Thread-92] | Client
protocol version: HIVE_CLI_SERVICE_PROTOCOL_V8 |
org.apache.proxy.service.ThriftCLIProxyService.OpenSession(ThriftCLIProxyService.java:554)
2017-07-12 17:35:49,790 | ERROR | [HiveServer2-Handler-Pool: Thread-113] | Timed
out waiting for client to connect.
Possible reasons include network issues, errors in remote driver or the cluster has
no available resources, etc.
Please check YARN or Spark driver's logs for further information. |
org.apache.proxy.service.client.SparkClientImpl.<init>(SparkClientImpl.java:90)
java.util.concurrent.ExecutionException: java.util.concurrent.TimeoutException:
Timed out waiting for client connection.
 at io.netty.util.concurrent.AbstractFuture.get(AbstractFuture.java:37)
 at org.apache.proxy.service.client.SparkClientImpl.<init>(SparkClientImpl.java:87)
 at
org.apache.proxy.service.client.SparkClientFactory.createClient(SparkClientFactory.java:79)
 at
org.apache.proxy.service.SparkClientManager.createSparkClient(SparkClientManager.java:145)
 at
org.apache.proxy.service.SparkClientManager.createThriftServerInstance(SparkClientManager.java:160)
 at
org.apache.proxy.service.ThriftServiceManager.getOrCreateThriftServer(ThriftServiceManager.java:182)
 at
org.apache.proxy.service.ThriftCLIProxyService.OpenSession(ThriftCLIProxyService.java:596)
 at
org.apache.hive.service.cli.thrift.TCLIService$Processor$OpenSession.getResult(TCLIService.java:1257)
 at
```

```
org.apache.hive.service.cli.thrift.TCLIService$Processor$OpenSession.getResult(TCLI
Service.java:1242)
 at org.apache.thrift.ProcessFunction.process(ProcessFunction.java:39)
 at org.apache.thrift.TBaseProcessor.process(TBaseProcessor.java:39)
 at
org.apache.hadoop.hive.thrift.HadoopThriftAuthBridge$Server$TUGIAssumingProcessor.p
rocess(HadoopThriftAuthBridge.java:696)
 at
org.apache.thrift.server.TThreadPoolServer$WorkerProcess.run(TThreadPoolServer.java
:286)
 at java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1142)
 at java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:617)
 at java.lang.Thread.run(Thread.java:748)
Caused by: java.util.concurrent.TimeoutException: Timed out waiting for client
connection.
```

回答

当网络不稳定时，会出现上述问题。当 beeline 出现 timed-out 异常时，Spark 不会尝试重连。

解决措施：

用户需要通过重新启动 spark-beeline 进行重连。

21.9.2.22 Spark SQL 无法查询到 ORC 类型的 Hive 表的新插入数据

问题

为什么通过 Spark SQL 无法查询到存储类型为 ORC 的 Hive 表的新插入数据？主要有以下两种场景存在这个问题：

- 对于分区表和非分区表，在 Hive 客户端中执行插入数据的操作后，会出现 Spark SQL 无法查询到最新插入的数据的问题。
- 对于分区表，在 Spark SQL 中执行插入数据的操作后，如果分区信息未改变，会出现 Spark SQL 无法查询到最新插入的数据的问题。

回答

由于 Spark 存在一个机制，为了提高性能会缓存 ORC 的元数据信息。当通过 Hive 或其他方式更新了 ORC 表时，缓存的元数据信息未更新，导致 Spark SQL 查询不到新插入的数据。

对于存储类型为 ORC 的 Hive 分区表，在执行插入数据操作后，如果分区信息未改变，则缓存的元数据信息未更新，导致 Spark SQL 查询不到新插入的数据。

解决措施：

1. 在使用 Spark SQL 查询之前，需执行 Refresh 操作更新元数据信息：

   REFRESH TABLE *table_name*;

   table_name 为刷新的表名，该表必须存在，否则会出错。

   执行查询语句时，即可获取到最新插入的数据。

2. 使用 sqark 时，执行以下命令禁用 Spark 优化：

   set spark.sql.hive.convertMetastoreOrc=false;

21.9.3 Spark Streaming

21.9.3.1 Spark Streaming 任务一直阻塞

问题

运行一个 Spark Streaming 任务，确认有数据输入后，发现没有任何处理的结果。打开 Web 界面查看 Spark Job 执行情况，发现如下图所示：有两个 Job 一直在等待运行，但一直无法成功运行。

图21-16 Active Jobs

Active Jobs (2)

Job Id	Description	Submitted	Duration	Stages: Succeeded/Total
3	print at test2StreamFromKafka.scala:31	2015/05/25 18:28:55	63.7 h	0/3
2	start at test2StreamFromKafka.scala:34	2015/05/25 18:28:55	63.7 h	0/1

继续查看已经完成的 Job，发现也只有两个，说明 Spark Streaming 都没有触发数据计算的任务（Spark Streaming 默认有两个尝试运行的 Job，就是图中两个）

图21-17 Completed Jobs

Completed Jobs (2)

Job Id	Description	Submitted	Duration	Stages: Succeeded/Total
1	print at test2StreamFromKafka.scala:31	2015/05/25 18:28:55	0.7 s	2/2 (1 skipped)
0	start at test2StreamFromKafka.scala:34	2015/05/25 18:28:54	1 s	2/2

回答

经过定位发现，导致这个问题的原因是：Spark Streaming 的计算核数少于 Receiver 的个数，导致部分 Receiver 启动以后，系统已经没有资源去运行计算任务，导致第一个任务一直在等待，后续任务一直在排队。从现象上看，就是如问题中的图 21-16 中所示，会有两个任务一直在等待。

因此，当 Web 出现两个任务一直在等待的情况，首先检查 Spark 的核数是否大于 Receiver 的个数。

说明

Receiver 在 Spark Streaming 中是一个常驻的 Spark Job，Receiver 对于 Spark 是一个普通的任务，但它的生命周期和 Spark Streaming 任务相同，并且占用一个核的计算资源。

在调试和测试等经常使用默认配置的场景下，要时刻注意核数与 Receiver 个数的关系。

21.9.3.2 运行 Spark Streaming 任务参数调优的注意事项

问题

运行 Spark Streaming 任务时，随着 executor 个数的增长，数据处理性能没有明显提升，对于参数调优有哪些注意事项？

回答

在 executor 核数等于 1 的情况下，遵循以下规则对调优 Spark Streaming 运行参数有所帮助。

- Spark 任务处理速度和 Kafka 上 partition 个数有关，当 partition 个数小于给定 executor 个数时，实际使用的 executor 个数和 partition 个数相同，其余的将会被空闲。所以应该使得 executor 个数小于或者等于 partition 个数。
- 当 Kafka 上不同 partition 数据有倾斜时，数据较多的 partition 对应的 executor 将成为数据处理的瓶颈，所以在执行 Producer 程序时，数据平均发送到每个 partition 可以提升处理的速度。
- 在 partition 数据均匀分布的情况下，同时提高 partition 和 executor 个数，将会提升 Spark 处理速度（当 partition 个数和 executor 个数保持一致时，处理速度是最快的）。
- 在 partition 数据均匀分布的情况下，尽量保持 partition 个数是 executor 个数的整数倍，这样将会使资源得到合理利用。

21.9.3.3 为什么提交 Spark Streaming 应用超过 token 有效期，应用失败

问题

修改 kerberos 的票据和 HDFS token 过期时间为 5 分钟，设置“dfs.namenode.delegation.token.renew-interval”小于 60 秒，提交 Spark Streaming 应用，超过 token 有效期，提示以下错误，应用失败。

```
token (HDFS_DELEGATION_TOKEN token 17410 for spark2x) is expired
```

回答

- 问题原因：

  ApplicationMaster 进程中有 1 个 Credential Refresh Thread 会根据 *token renew 周期 * 0.75* 的时间比例上传更新后的 Credential 文件到 HDFS 上。

  Executor 进程中有 1 个 Credential Refresh Thread 会根据 *token renew 周期 *0.8* 的时间比例去 HDFS 上获取更新后的 Credential 文件，用来刷新 UserGroupInformation 中的 token，避免 token 失效。

  当 Executor 进程的 Credential Refresh Thread 发现当前时间已经超过 Credential 文件更新时间（即 *token renew 周期 *0.8*）时，会等待 1 分钟再去 HDFS 上面获取最新的 Credential 文件，以确保 AM 端已经将更新后的 Credential 文件放到 HDFS 上。

  当“dfs.namenode.delegation.token.renew-interval”配置值小于 60 秒，Executor 进程起来时发现当前时间已经超过 Credential 文件更新时间，等待 1 分钟再去 HDFS

上面获取最新的 Credential 文件，而此时 token 已经失效，task 运行失败，然后在其他 Executor 上重试，由于重试时间都是在 1 分钟内完成，所以 task 在其他 Executor 上也运行失败，导致运行失败的 Executor 加入到黑名单，没有可用的 Executor，应用退出。

- 修改方案：

  在 Spark 使用场景下，需设置“dfs.namenode.delegation.token.renew-interval”大于 80 秒。“dfs.namenode.delegation.token.renew-interval”参数描述请参表 21-85 考。

表21-85 参数说明

参数	描述	默认值
dfs.namenode.delegation.token.renew-interval	该参数为服务器端参数，设置 token renew 的时间间隔，单位为毫秒。	86400000

21.9.3.4 为什么 Spark Streaming 应用创建输入流，但该输入流无输出逻辑时，应用从 checkpoint 恢复启动失败

问题

Spark Streaming 应用创建 1 个输入流，但该输入流无输出逻辑。应用从 checkpoint 恢复启动失败，报错如下：

```
17/04/24 10:13:57 ERROR Utils: Exception encountered
java.lang.NullPointerException
at
org.apache.spark.streaming.dstream.DStreamCheckpointData$$anonfun$writeObject$1.app
ly$mcV$sp(DStreamCheckpointData.scala:125)
at
org.apache.spark.streaming.dstream.DStreamCheckpointData$$anonfun$writeObject$1.app
ly(DStreamCheckpointData.scala:123)
at
org.apache.spark.streaming.dstream.DStreamCheckpointData$$anonfun$writeObject$1.app
ly(DStreamCheckpointData.scala:123)
at org.apache.spark.util.Utils$.tryOrIOException(Utils.scala:1195)
at
org.apache.spark.streaming.dstream.DStreamCheckpointData.writeObject(DStreamCheckpo
intData.scala:123)
at sun.reflect.NativeMethodAccessorImpl.invoke0(Native Method)
at sun.reflect.NativeMethodAccessorImpl.invoke(NativeMethodAccessorImpl.java:62)
at
sun.reflect.DelegatingMethodAccessorImpl.invoke(DelegatingMethodAccessorImpl.java:4
3)
at java.lang.reflect.Method.invoke(Method.java:498)
at java.io.ObjectStreamClass.invokeWriteObject(ObjectStreamClass.java:1028)
at java.io.ObjectOutputStream.writeSerialData(ObjectOutputStream.java:1496)
at java.io.ObjectOutputStream.writeOrdinaryObject(ObjectOutputStream.java:1432
at java.io.ObjectOutputStream.writeObject0(ObjectOutputStream.java:1178)
at java.io.ObjectOutputStream.defaultWriteFields(ObjectOutputStream.java:1548)
```

```
at java.io.ObjectOutputStream.defaultWriteObject(ObjectOutputStream.java:441)
at
org.apache.spark.streaming.dstream.DStream$$anonfun$writeObject$1.apply$mcV$sp(DStr
eam.scala:515)
at
org.apache.spark.streaming.dstream.DStream$$anonfun$writeObject$1.apply(DStream.sca
la:510)
at
org.apache.spark.streaming.dstream.DStream$$anonfun$writeObject$1.apply(DStream.sca
la:510)
at org.apache.spark.util.Utils$.tryOrIOException(Utils.scala:1195)
at org.apache.spark.streaming.dstream.DStream.writeObject(DStream.scala:510)
at sun.reflect.NativeMethodAccessorImpl.invoke0(Native Method)
at sun.reflect.NativeMethodAccessorImpl.invoke(NativeMethodAccessorImpl.java:62)
at
sun.reflect.DelegatingMethodAccessorImpl.invoke(DelegatingMethodAccessorImpl.java:4
3)
at java.lang.reflect.Method.invoke(Method.java:498)
at java.io.ObjectStreamClass.invokeWriteObject(ObjectStreamClass.java:1028)
at java.io.ObjectOutputStream.writeSerialData(ObjectOutputStream.java:1496)
at java.io.ObjectOutputStream.writeOrdinaryObject(ObjectOutputStream.java:1432
at java.io.ObjectOutputStream.writeObject0(ObjectOutputStream.java:1178)
at java.io.ObjectOutputStream.writeArray(ObjectOutputStream.java:1378)
at java.io.ObjectOutputStream.writeObject0(ObjectOutputStream.java:1174)
at java.io.ObjectOutputStream.defaultWriteFields(ObjectOutputStream.java:1548)
at java.io.ObjectOutputStream.writeSerialData(ObjectOutputStream.java:1509)
at java.io.ObjectOutputStream.writeOrdinaryObject(ObjectOutputStream.java:1432
at java.io.ObjectOutputStream.writeObject0(ObjectOutputStream.java:1178)
at java.io.ObjectOutputStream.defaultWriteFields(ObjectOutputStream.java:1548)
at java.io.ObjectOutputStream.defaultWriteObject(ObjectOutputStream.java:441)
at
org.apache.spark.streaming.DStreamGraph$$anonfun$writeObject$1.apply$mcV$sp(DStream
Graph.scala:191)
at
org.apache.spark.streaming.DStreamGraph$$anonfun$writeObject$1.apply(DStreamGraph.s
cala:186)
at
org.apache.spark.streaming.DStreamGraph$$anonfun$writeObject$1.apply(DStreamGraph.s
cala:186)
at org.apache.spark.util.Utils$.tryOrIOException(Utils.scala:1195)
at org.apache.spark.streaming.DStreamGraph.writeObject(DStreamGraph.scala:186
at sun.reflect.NativeMethodAccessorImpl.invoke0(Native Method)
at sun.reflect.NativeMethodAccessorImpl.invoke(NativeMethodAccessorImpl.java:62)
at
sun.reflect.DelegatingMethodAccessorImpl.invoke(DelegatingMethodAccessorImpl.java:4
3)
at java.lang.reflect.Method.invoke(Method.java:498)
at java.io.ObjectStreamClass.invokeWriteObject(ObjectStreamClass.java:1028)
at java.io.ObjectOutputStream.writeSerialData(ObjectOutputStream.java:1496)
at java.io.ObjectOutputStream.writeOrdinaryObject(ObjectOutputStream.java:1432
at java.io.ObjectOutputStream.writeObject0(ObjectOutputStream.java:1178)
at java.io.ObjectOutputStream.defaultWriteFields(ObjectOutputStream.java:1548)
at java.io.ObjectOutputStream.writeSerialData(ObjectOutputStream.java:1509)
at java.io.ObjectOutputStream.writeOrdinaryObject(ObjectOutputStream.java:1432
at java.io.ObjectOutputStream.writeObject0(ObjectOutputStream.java:1178)
```

```
at java.io.ObjectOutputStream.writeObject(ObjectOutputStream.java:348)
at
org.apache.spark.streaming.Checkpoint$$anonfun$serialize$1.apply$mcV$sp(Checkpoint.
scala:142)
at
org.apache.spark.streaming.Checkpoint$$anonfun$serialize$1.apply(Checkpoint.scala:1
42)
at
org.apache.spark.streaming.Checkpoint$$anonfun$serialize$1.apply(Checkpoint.scala:1
42)
at org.apache.spark.util.Utils$.tryWithSafeFinally(Utils.scala:1230)
at org.apache.spark.streaming.Checkpoint$.serialize(Checkpoint.scala:143)
at org.apache.spark.streaming.StreamingContext.validate(StreamingContext.scala:566)
at
org.apache.spark.streaming.StreamingContext.liftedTree1$1(StreamingContext.scala:61
2)
at org.apache.spark.streaming.StreamingContext.start(StreamingContext.scala:611)
at com.spark.test.kafka08LifoTwoInkfk$.main(kafka08LifoTwoInkfk.scala:21)
at com.spark.test.kafka08LifoTwoInkfk.main(kafka08LifoTwoInkfk.scala)
at sun.reflect.NativeMethodAccessorImpl.invoke0(Native Method)
at sun.reflect.NativeMethodAccessorImpl.invoke(NativeMethodAccessorImpl.java:62)
at
sun.reflect.DelegatingMethodAccessorImpl.invoke(DelegatingMethodAccessorImpl.java:4
3)
at java.lang.reflect.Method.invoke(Method.java:498)
at
org.apache.spark.deploy.SparkSubmit$.org$apache$spark$deploy$SparkSubmit$$runMain(S
parkSubmit.scala:772)
at org.apache.spark.deploy.SparkSubmit$.doRunMain$1(SparkSubmit.scala:183)
at org.apache.spark.deploy.SparkSubmit$.submit(SparkSubmit.scala:208)
at org.apache.spark.deploy.SparkSubmit$.main(SparkSubmit.scala:123)
at org.apache.spark.deploy.SparkSubmit.main(SparkSubmit.scala)
```

回答

Streaming Context 启动时，若应用设置了 checkpoint，则需要对应用中的 DStream checkpoint 对象进行序列化，序列化时会用到 dstream.context。

dstream.context 是 Streaming Context 启动时从 output Streams 反向查找所依赖的 DStream，逐个设置 context。若 Spark Streaming 应用创建 1 个输入流，但该输入流无输出逻辑时，则不会给它设置 context。所以在序列化时报“NullPointerException”。

解决办法：应用中如果有无输出逻辑的输入流，则在代码中删除该输入流，或添加该输入流的相关输出逻辑。

21.9.3.5 Spark Streaming 应用运行过程中重启 Kafka，Web UI 界面部分 batch time 对应 Input Size 为 0 records

问题

在 Spark Streaming 应用执行过程中重启 Kafka 时，应用无法从 Kafka 获取 topic offset，从而导致生成 Job 失败。如图 21-18 所示，其中 2017/05/11 10:57:00~2017/05/11

10:58:00 为 Kafka 重启时间段。2017/05/11 10:58:00 重启成功后对应的“Input Size”的值显示为“0 records”。

图21-18 Web UI 界面部分 batch time 对应 Input Size 为 0 records

Completed Batches (last 9 out of 9)

Batch Time	Input Size	Scheduling Delay (?)	Processing Time (?)	Total Delay (?)	Output Ops: Succeeded/Total
2017/05/11 10:58:50	18 records	0 ms	0.4 s	0.4 s	1/1
2017/05/11 10:58:40	20 records	4 s	0.3 s	4 s	1/1
2017/05/11 10:58:30	20 records	14 s	0.5 s	14 s	1/1
2017/05/11 10:58:20	20 records	23 s	0.4 s	24 s	1/1
2017/05/11 10:58:10	20 records	33 s	0.5 s	33 s	1/1
2017/05/11 10:58:00	0 records	6 ms	43 s	43 s	1/1
2017/05/11 10:57:00	19 records	1 ms	0.9 s	0.9 s	1/1
2017/05/11 10:56:50	20 records	1 ms	0.6 s	0.6 s	1/1
2017/05/11 10:56:40	28 records	13 ms	5 s	5 s	1/1

回答

Kafka 重启成功后应用会按照 batch 时间把 2017/05/11 10:57:00~2017/05/11 10:58:00 缺失的 RDD 补上，尽管 UI 界面上显示读取的数据个数为“0”，但实际上这部分数据在补的 RDD 中进行了处理，因此，不存在数据丢失。

Kafka 重启时间段的数据处理机制如下。

Spark Streaming 应用使用了 state 函数（例如：updateStateByKey），在 Kafka 重启成功后，Spark Streaming 应用生成 2017/05/11 10:58:00 batch 任务时，会按照 batch 时间把 2017/05/11 10:57:00~2017/05/11 10:58:00 缺失的 RDD 补上（Kafka 重启前 Kafka 上未读取完的数据，属于 2017/05/11 10:57:00 之前的 batch）。

21.9.4 访问 Spark 应用获取的 restful 接口信息有误

问题

当 Spark 应用结束后，访问该应用的 restful 接口获取 job 信息，发现 job 信息中“numActiveTasks”的值是负数，如图 21-19 所示。

图21-19 job 信息


```
[ {
  "jobId" : 0,
  "name" : "reduce at SparkPi.scala:36",
  "submissionTime" : "2016-05-28T09:35:34.415GMT",
  "completionTime" : "2016-05-28T09:35:35.686GMT",
  "stageIds" : [ 0 ],
  "status" : "SUCCEEDED",
  "numTasks" : 2,
  "numActiveTasks" : -1,
  "numCompletedTasks" : 2,
  "numSkippedTasks" : 2,
  "numFailedTasks" : 0,
  "numActiveStages" : 0,
  "numCompletedStages" : 1,
  "numSkippedStages" : 0,
  "numFailedStages" : 0
} ]
```


说明

numActiveTasks 是指当前正在运行 task 的个数。

回答

通过下面两种途径获取上面的 job 信息：

- 配置 **spark.history.briefInfo.gather=true**，查看 JobHistory 的 brief 信息。
- 使用 Spark JobHistory2x 页面访问：https://IP:port/api/v1/<appid>/jobs/。

job 信息中“numActiveTasks”的值是根据 eventlog 文件中 SparkListenerTaskStart 和 SparkListenerTaskEnd 事件的个数的差值计算得到的。如果 eventLog 文件中有事件丢失，就可能出现上面的现象。

21.9.5 为什么从 Yarn Web UI 页面无法跳转到 Spark Web UI 界面

问题

FusionInsight 版本中，在客户端采用 yarn-client 模式运行 Spark 应用，然后从 Yarn 的页面打开该应用的 Web UI 界面，出现下面的错误：

从 YARN ResourceManager 的日志看到：

```
2016-07-21 16:35:27,099 | INFO  | Socket Reader #1 for port 8032 | Auth successful
for mapred/hadoop.<系统域名>@<系统域名> (auth:KERBEROS) | Server.java:1388
2016-07-21 16:35:27,105 | INFO  | 1526016381@qtp-1178290888-1015 | admin is
```

```
accessing unchecked http://10.120.169.53:23011 which is the app master GUI of
application_1468986660719_0045 owned by spark | WebAppProxyServlet.java:393
2016-07-21 16:36:02,843 | INFO  | Socket Reader #1 for port 8032 | Auth successful
for hive/hadoop.<系统域名>@<系统域名> (auth:KERBEROS) | Server.java:1388
2016-07-21 16:36:02,851 | INFO  | Socket Reader #1 for port 8032 | Auth successful
for hive/hadoop.<系统域名>@<系统域名> (auth:KERBEROS) | Server.java:1388
2016-07-21 16:36:12,163 | WARN  | 1526016381@qtp-1178290888-1015 |
/proxy/application_1468986660719_0045/: java.net.ConnectException: Connection timed
out |
Slf4jLog.java:76
2016-07-21 16:37:03,918 | INFO  | Socket Reader #1 for port 8032 | Auth successful
for hive/hadoop.<系统域名>@<系统域名> (auth:KERBEROS) | Server.java:1388
2016-07-21 16:37:03,926 | INFO  | Socket Reader #1 for port 8032 | Auth successful
for hive/hadoop.<系统域名>@<系统域名> (auth:KERBEROS) | Server.java:1388
2016-07-21 16:37:11,956 | INFO  | AsyncDispatcher event handler | Updating
application attempt appattempt_1468986660719_0045_000001 with final state:
FINISHING,
and exit status: -1000 | RMAppAttemptImpl.java:1253
```

回答

打开 FusionInsight Manager 页面，看到 Yarn 服务的业务 IP 地址为 192 网段。

从 Yarn 的日志看到，Yarn 读取的 Spark Web UI 地址为 http://10.120.169.53:23011，是 10 网段的 IP 地址。由于 192 网段的 IP 和 10 网段的 IP 不能互通，所以导致访问 Spark Web UI 界面失败。

修改方案：

登录 10.120.169.53 客户端机器，修改/etc/hosts 文件，将 10.120.169.53 更改为相对应的 192 网段的 IP 地址。再重新运行 Spark 应用，这时就可以打开 Spark Web UI 界面。

21.9.6 HistoryServer 缓存的应用被回收，导致此类应用页面访问时出错

问题

在 History Server 页面中访问某个 Spark 应用的页面时，发现访问时出错。

查看相应的 HistoryServer 日志后，发现有“FileNotFound”异常，相关日志如下所示：

```
2016-11-22 23:58:03,694 | WARN  | [qtp55429210-232] |
/history/application_1479662594976_0001/stages/stage/ |
org.sparkproject.jetty.servlet.ServletHandler.doHandle(ServletHandler.java:628)
java.io.FileNotFoundException: ${BIGDATA_HOME}/tmp/spark/jobHistoryTemp/blockmgr-
5f1f6aca-2303-4290-9845-88fa94d78480/09/temp_shuffle_11f82aaf-e226-46dc-b1f0-
002751557694 (No such file or directory)
```

回答

在 History Server 页面加载 Task 个数较多的 Spark 应用时，由于无法把全部的数据放入内存中，导致数据溢出到磁盘时，会产生前缀为“temp_shuffle”的文件。

HistoryServer 默认会缓存 50 个 Spark 应用（由配置项“spark.history.retainedApplications”决定），当内存中的 Spark 应用个数超过这个数值时，HistoryServer 会回收最先缓存的 Spark 应用，同时会清理掉相应的“temp_shuffle”文件。

当用户正在查看即将被回收的 Spark 应用时，可能会出现找不到“temp_shuffle”文件的错误，从而导致当前页面无法访问。

如果遇到上述问题，可参考以下两种方法解决。

- 重新访问这个 Spark 应用的 HistoryServer 页面，即可查看到正确的页面信息。
- 如果用户场景需要同时访问 50 个以上的 Spark 应用时，需要调大“spark.history.retainedApplications”参数的值。

  请登录 FusionInsight Manager 管理界面，单击“集群 > *待操作集群的名称* > 服务 > Spark2x > 配置”，单击“全部配置”，在左侧的导航列表中，单击“JobHistory2x > 界面”，配置如下参数。

表21-86 参数说明

参数	描述	默认值
spark.history.retainedApplications	HistoryServer 缓存的 Spark 应用数，当需要缓存的应用个数超过此参数值时，HistoryServer 会回收最先缓存的 Spark 应用。	50

21.9.7 加载空的 part 文件时，app 无法显示在 JobHistory 的页面上

问题

在分组模式下执行应用，当 HDFS 上的 part 文件为空时，发现 JobHistory 首页面上不显示该 part 对应的 app。

回答

JobHistory 服务更新页面上的 app 时，会根据 HDFS 上的 part 文件大小变更与否判断是否刷新首页面的 app 显示信息。若文件为第一次查看，则将当前文件大小与 0 作比较，如果大于 0 则读取该文件。

分组的情况下，如果执行的 app 没有 job 处于执行状态，则 part 文件为空，即 JobHistory 服务不会读取该文件，此 app 也不会显示在 JobHistory 页面上。但若 part 文件大小之后有更新，JobHistory 又会显示该 app。

21.9.8 Spark2x 导出带有相同字段名的表，结果导出失败

问题

在 Spark2x 的 spark-shell 上执行如下代码失败：

```
val acctId = List(("49562", "Amal", "Derry"), ("00000", "Fred", "Xanadu"))
val rddLeft = sc.makeRDD(acctId)
val dfLeft = rddLeft.toDF("Id", "Name", "City")
//dfLeft.show
val acctCustId = List(("Amal", "49562", "CO"), ("Dave", "99999", "ZZ"))
val rddRight = sc.makeRDD(acctCustId)
val dfRight = rddRight.toDF("Name", "CustId", "State")
//dfRight.show
val dfJoin = dfLeft.join(dfRight, dfLeft("Id") === dfRight("CustId"), "outer")
dfJoin.show
dfJoin.repartition(1).write.format("com.databricks.spark.csv").option("delimiter",
"\t").option("header", "true").option("treatEmptyValuesAsNulls",
"true").option("nullValue", "").save("/tmp/outputDir")
```

回答

Spark2x 中对 join 语句重名字段做了判断，需要修改代码保证保存的数据中无重复字段。

21.9.9 为什么多次运行 Spark 应用程序会引发致命 JRE 错误

问题

为什么多次运行 Spark 应用程序会引发致命 JRE 错误？

回答

多次运行 Spark 应用程序会引发致命的 JRE 错误，这个错误由 Linux 内核导致。

升级内核版本到 4.13.9-2.ge7d7106-default 来解决这个问题。

21.9.10 IE 浏览器访问 Spark2x 原生 UI 界面失败，无法显示此页或者页面显示错误

问题

通过 IE 9、IE 10 和 IE 11 浏览器访问 Spark2x 的原生 UI 界面，出现访问失败情况或者页面显示错误问题。

现象

访问页面失败，浏览器无法显示此页，如下图所示：

原因

IE 9、IE 10、IE 11 浏览器的某些版本在处理 SSL 握手有问题导致访问失败。

解决方法

推荐使用 Google Chrome 浏览器 71 及其以上版本。

21.9.11 Spark2x 如何访问外部集群组件

问题

存在两个集群：cluster1 和 cluster2，如何使用 cluster1 中的 Spark2x 访问 cluster2 中的 HDFS、Hive、HBase 和 Kafka 组件。

回答

1. 可以有条件的实现两个集群间组件互相访问，但是存在以下限制：
   - 仅允许访问一个 Hive MetaStore，不支持同时访问 cluster1 的 Hive MetaStore 和 cluster2 的 Hive MetaStore。
   - 不同集群的用户系统没有同步，因此访问跨集群组件时，用户的权限管理由对端集群的用户配置决定。比如 cluster1 的 userA 没有访问本集群 HBase meta 表权限，但是 cluster2 的 userA 有访问该集群 HBase meta 表权限，则 cluster1 的 userA 可以访问 cluster2 的 HBase meta 表。
   - 跨 Manager 之间的安全集群间组件互相访问，需要先配置系统互信。
2. 以下分别阐述 cluster1 上使用 userA 访问 cluster2 的 Hive、HBase、Kafka 组件。

说明

以下操作皆以用户使用 FusionInsight 客户端提交 Spark2x 应用为基础，若用户使用了自己的配置文件目录，则需要修改本应用配置目录中的对应文件，并注意需要将配置文件上传到 executor 端。

由于 hdfs 和 hbase 客户端访问服务端时，使用 hostname 配置服务端地址，因此，客户端的 /etc/hosts 需要保存有所有需要访问节点的 hosts 配置。用户可预先将对端集群节点的 host 添加到客户端节点的/etc/hosts 文件中。

- 访问 Hive MetaStore：使用 cluster2 中的 Spark2x 客户端下“conf”目录下的 hive-site.xml 文件，替换到 cluster1 中的 Spark2x 客户端下“conf”目录下的 hive-site.xml 文件。

  如上操作后可以用 sparksql 访问 hive MetaStore，如需访问 hive 表数据，需要按照•同时访问两个集群的 HDFS：的操作步骤配置且指定对端集群 nameservice 为 LOCATION 后才能访问表数据。
- 访问对端集群的 HBase：
  i. 先将 cluster2 集群的所有 Zookeeper 节点和 HBase 节点的 IP 和主机名配置到 cluster1 集群的客户端节点的/etc/hosts 文件中。
  ii. 使用 cluster2 中的 Spark2x 客户端下“conf”目录的 hbase-site.xml 文件，替换到 cluster1 中的 Spark2x 客户端下“conf”目录 hbase-site.xml 文件。
- 访问 Kafka，仅需将应用访问的 Kafka Broker 地址设置为 cluster2 中的 Kafka Broker 地址即可。

- 同时访问两个集群的 HDFS：
  - 无法同时获取两个相同 nameservice 的 token，因此两个 HDFS 的 nameservice 必须不同，例如：一个为 hacluster，一个为 test
    1) 从 cluster2 的 hdfs-site.xml 中获取以下配置，添加到 cluster1 的 spark2x 客户端 conf 目录的 hdfs-site.xml 中

       dfs.nameservices.mappings、dfs.nameservices、dfs.namenode.rpc-address.test.*、dfs.ha.namenodes.test、dfs.client.failover.proxy.provider.test

       参考样例如下：

```
<property>
<name>dfs.nameservices.mappings</name>
<value>[{"name":"hacluster","roleInstances":["14","15"]},{"name":
"test","roleInstances":["16","17"]}]</value>
</property>
<property>
<name>dfs.nameservices</name>
<value>hacluster,test</value>
</property>
<property>
<name>dfs.namenode.rpc-address.test.16</name>
<value>192.168.0.1:8020</value>
</property>
<property>
<name>dfs.namenode.rpc-address.test.17</name>
<value>192.168.0.2:8020</value>
</property>
<property>
<name>dfs.ha.namenodes.test</name>
<value>16,17</value>
</property>
<property>
<name>dfs.client.failover.proxy.provider.test</name>
<value>org.apache.hadoop.hdfs.server.namenode.ha.ConfiguredFailov
erProxyProvider</value>
</property>
```

    2) 修改 cluster1 的 spark 客户端 conf 目录下的 spark-defaults.conf 配置文件中，修改 spark.yarn.extra.hadoopFileSystems = hdfs://test，spark.hadoop.hdfs.externalToken.enable = true，如下所示：

```
spark.yarn.extra.hadoopFileSystems = hdfs://test
spark.hadoop.hdfs.externalToken.enable = true
```

    3) 应用提交命令中，需要添加--keytab 和 --principal 参数，参数配置为 cluster1 中提交任务的用户。

    4) 使用 cluster1 的 spark 客户端提交应用，即可同时访问两个 hdfs 服务

- 同时访问两个集群的 HBase：

  i. 修改 cluster1 的 spark 客户端 conf 目录下的 spark-defaults.conf 配置文件中，修改 spark.hadoop.hbase.externalToken.enable = true，如下所示：

```
spark.hadoop.hbase.externalToken.enable = true
```

  ii. 用户访问 HBase 时，需要使用对应集群的配置文件创建 Configuration 对象，用于创建 Connection 对象。

iii. MRS 集群中支持同时获取多个 HBase 服务的 token，以解决 Executor 中无法访问 HBase 的问题，使用方式如下：

假设需要访问本集群的 HBase 和 cluster2 的 HBase，将 cluster2 的 hbase-site.xml 文件放到一个压缩包内，压缩包命名为 external_hbase_conf***，提交命令时，使用--archives 指定这些压缩包。

21.9.12 对同一目录创建多个外表，可能导致外表查询失败

问题

假设存在数据文件路径“/test_data_path”，用户 userA 对该目录创建外表 tableA，用户 userB 对该目录创建外表 tableB，当 userB 对 tableB 执行 insert 操作后，userA 将查询 tableA 失败，出现 Permission denied 异常。

回答

当 userB 对 tableB 执行 insert 操作后，会在外表数据路径下生成新的数据文件，且文件属组是 userB，当 userA 查询 tableA 时，会读取外表数据目录下的所有的文件，此时会因没有 userB 生成的文件的读取权限而查询失败。

实际上，不只是查询场景，还有其他场景也会出现问题。例如：inset overwrite 操作将会把此目录下的其他表文件也一起复写。

由于 Spark SQL 当前的实现机制，如果对此种场景添加检查限制，会存在一致性问题和性能问题，因此未对此种场景添加限制，但是用户应避免此种用法，以避免此场景带来的各种问题。

21.9.13 访问 Spark2x JobHistory 中某个应用的原生页面时页面显示错误

问题

提交一个 Spark 应用，包含单个 Job 百万个 task。应用结束后，在 JobHistory 中访问该应用的原生页面，浏览器会等待较长时间才跳转到应用原生页面，若 10 分钟内无法跳转，则页面会显示 Proxy Error 信息。

图21-20 错误信息样例

回答

在 JobHistory 界面中跳转到某个应用的原生页面时，JobHistory 需要回放该应用的 Event log，若应用包含的事件日志较大，则回放时间较长，浏览器需要较长时间的等待。

当前浏览器访问 JobHistory 原生页面需经过 httpd 代理，代理的超时时间是 10 分钟，因此，如果 JobHistory 在 10 分钟内无法完成 Event log 的解析并返回，httpd 会主动向浏览器返回 Proxy Error 信息。

解决方法

由于当前 JobHistory 开启了本地磁盘缓存功能，访问应用时，会将应用的 Event log 的解析结果缓存到本地磁盘中，第二次访问时，能大大加快响应速度。因此，出现此种情况时，仅需稍作等待，重新访问原来的链接即可，此时不会再出现需要长时间等待的现象。

21.9.14 对接 OBS 场景中，spark-beeline 登录后指定 loaction 到 OBS 建表失败

问题

对接 OBS ECS/BMS 集群，spark-beeline 登录后，指定 location 到 OBS 建表报错失败。

图21-21 错误信息

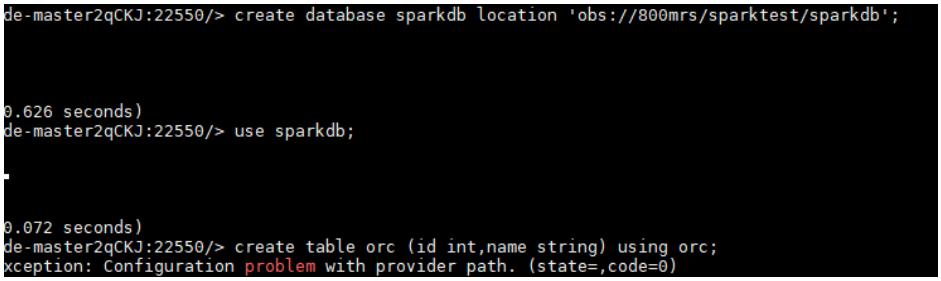

回答

HDFS 上 ssl.jceks 文件权限不足，导致建表失败。

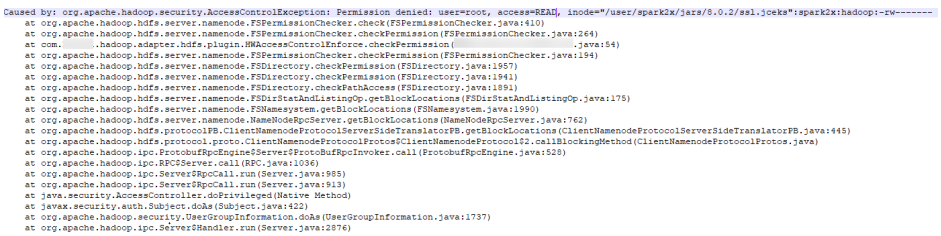

解决方法

1. 使用 **omm** 用户登录 Spark2x 所在节点，执行如下命令：

   vi ${BIGDATA_HOME}/FusionInsight_Spark2x_xxx/install/FusionInsight-Spark2x-*/spark/sbin/fake_prestart.sh

2. 将“eval "${hdfsCmd}" -chmod 600 "${InnerHdfsDir}"/ssl.jceks >> "${PRESTART_LOG}" 2>&1”修改成“eval "${hdfsCmd}" -chmod 644 "${InnerHdfsDir}"/ssl.jceks >> "${PRESTART_LOG}" 2>&1”。

3. 重启 SparkResource 实例。

21.9.15 Spark shuffle 异常处理

问题

在部分场景 Spark shuffle 阶段会有如下异常

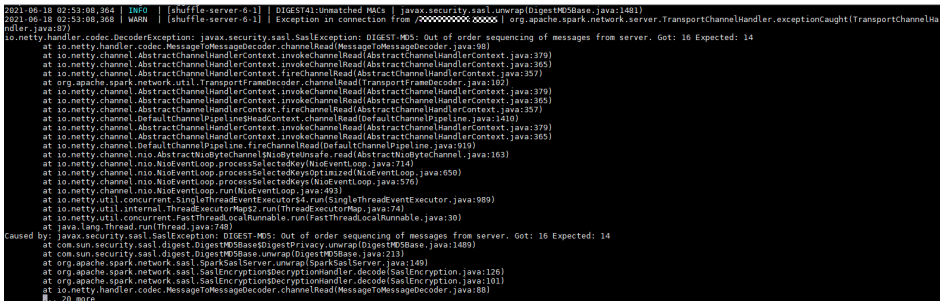

解决方法

JDBC 应该：

登录 FusionInsight Manager 管理界面，修改 JDBCServer 的参数“spark.authenticate.enableSaslEncryption”值为“false”，并重启对应的实例。

客户端作业：

客户端应用在提交应用的时候，修改 spark-defaults.conf 配置文件的“spark.authenticate.enableSaslEncryption”值为“false”。

21.9.16 Spark 多服务场景下，普通用户无法登录 Spark 客户端

问题

Spark 存在多个服务场景时，当使用多服务时，普通用户无法登录 spark-beeline。报错如下图所示：

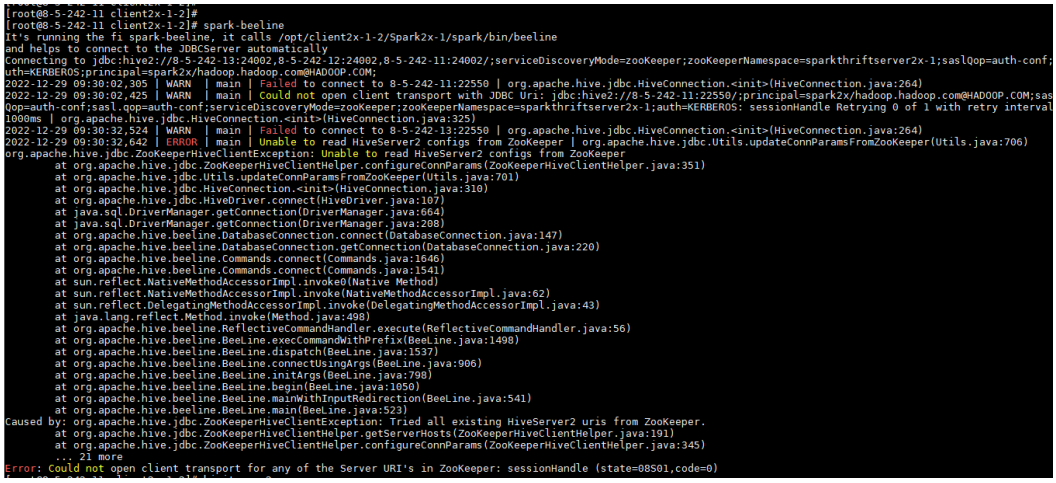

原因

当 Hive 同时存在多场景服务时，普通用户不属于 Hive 用户组，没有 Hive 目录权限，导致无法登录。

解决方法

登录 FusionInsight Manager 页面上，修改普通用户所属用户组，添加并加入 Hive 下的所有用户组。

21.9.17 安装使用集群外客户端时，连接集群端口失败

问题

安装集群外客户端或使用集群外客户端时，有时会出现连接 Spark 任务端口失败的问题。

异常信息：Failed to bind SparkUi

```
Cannot assign requested address: Service 'sparkDriver' failed after 16 retries (on
a random free port)! Consider explicitly setting the appropriate binding address
for the service 'sparkDriver' (for example spark.driver.bindAddress for SparkDriver)
to the correct binding address.
```

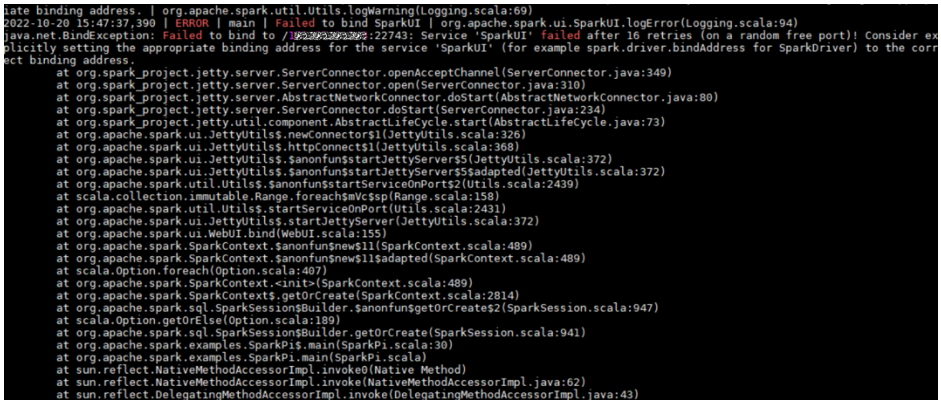

原因

- 集群节点与客户端节点网络不通。
- 客户端节点防火墙未关闭。
- 端口被占用：每一个 Spark 任务都会占用一个 SparkUI 端口，默认为 22600，如果被占用则依次递增端口重试。但是有个默认重试次数，为 16 次。16 次重试都失败后，会放弃该任务的运行。
- 客户端 Spark 配置参数错误。
- 代码问题。

解决方法

应用无法访问到 SparkUI 的 IP:PORT。有以下可能：

- 查看集群节点与客户端节点是否通信：

  查看客户端节点“/etc/hosts”文件中是否配置集群节点映射，在客户端节点执行命令：

  ping *sparkui 的 IP*

  如果 ping 不同，检查映射配置与网络设置。

- 关闭客户端节点防火墙设置。

  执行如下命令可查看是否关闭：

  systemctl status firewalld（不同的操作系统查询命令不一致，此命令以 CentOS 为例）

  如下图所示：dead 表示关闭。

  ```
  firewalld.service
   Loaded: not-found (Reason: No such file or directory)
   Active: inactive (dead)
  ```

  防火墙开则影响通信，执行如下命令关闭防火墙：

  service firewalld stop（不同的操作系统查询命令不一致，此命令以 CentOS 为例）

- 查看端口是否被占用：

  ssh -v -p port username@ip

  如果输出“Connection established”，则表示连接成功，端口已被占用。

  ```
  [root@192-168-34-183 conf]# ssh -v -p 22 root@192.168.34.235
  OpenSSH_7.4p1, OpenSSL 1.0.2k-fips  26 Jan 2017
  debug1: Reading configuration data /etc/ssh/ssh_config
  debug1: /etc/ssh/ssh_config line 58: Applying options for *
  debug1: Connecting to 192.168.34.235 [192.168.34.235] port 22.
  debug1: Connection established.
  debug1: permanently_set_uid: 0/0
  debug1: key_load_public: No such file or directory
  debug1: identity file /root/.ssh/id_rsa type -1
  ```

  Spark UI 端口范围由配置文件 spark-defaults.conf 中的参数“spark.random.port.min”和“spark.random.port.max”决定，若该范围端口都已被占用，则

  导致无端口可用从而连接失败。

  解决方案：调节重连次数 spark.port.maxRetries=50，并且调节 executor 随机端口范围 spark.random.port.max+100

- 查看 Spark 配置参数：

  在客户端节点执行命令 **cat spark-env.sh**，查看 SPARK_LOCAL_HOSTNAME，是否为本机 IP。

  该问题容易出现在从其他节点直接拷贝客户端时，配置参数未修改。

  需修改 SPARK_LOCAL_HOSTNAME 为本机 IP

  注：如果集群使用 EIP 通信，则需要设置

  a. spark-default.conf 中添加 spark.driver.host = *EIP（客户端节点弹性公网 IP）*

  b. spark-default.conf 中添加 spark.driver.bindAddress=*本地 IP*

c. spark-env.sh 中修改 SPARK_LOCAL_HOSTNAME=*EIP（客户端节点弹性公网 IP）*

- 如果通信与配置均无问题，则从代码层面排查：

  Spark 在启动任务时会在客户端创建 sparkDriverEnv 并绑定 DRIVER_BIND_ADDRESS，该逻辑并没有走到服务端，所以该问题产生的原因也是客户端节点操作系统环境问题导致 sparkDriver 获取不到对应的主机 IP。

  可以尝试执行 **export SPARK_LOCAL_HOSTNAME=172.0.0.1** 或者设置 **spark.driver.bindAddress=127.0.0.1**，使提交任务 driver 端可以加载到 loopbackAddress，从而规避问题。

21.9.18 Datasource Avro 格式查询异常

问题

Datasource Avro 格式查询报错，提示 Caused by: org.apache.spark.sql.avro.IncompatibleSchemaException。

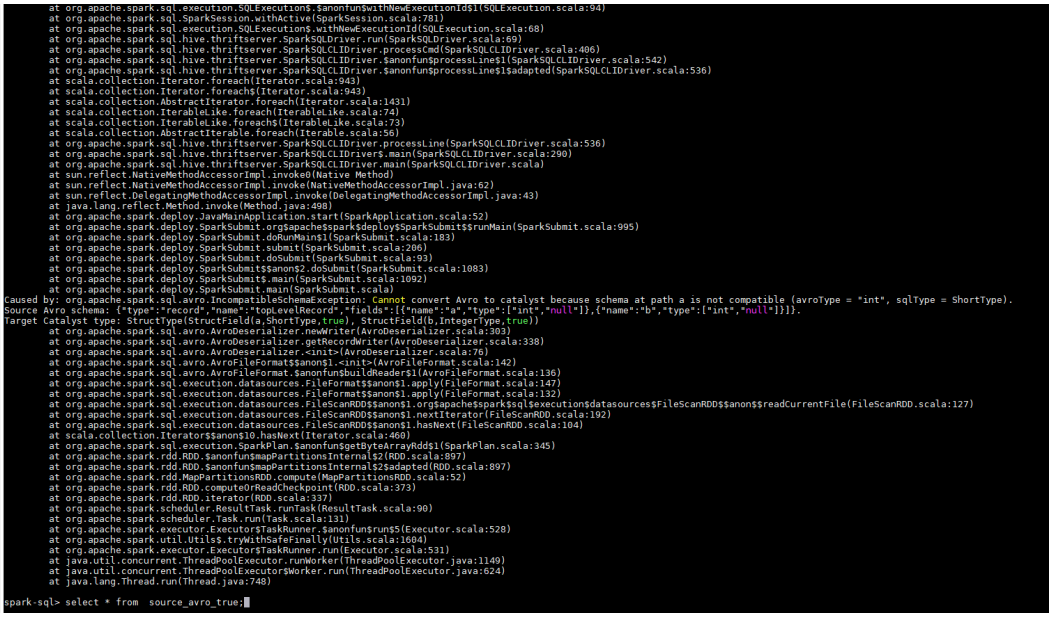

解决方法

针对 avro 格式表查询报错，根本原因是 avro 格式表 schema 不匹配导致，需要考虑增量和存量 avro 格式表查询两个场景：

1. 增量 avro 格式表，需要创建表之前设置参数 spark.sql.forceConvertSchema.enabled=true，会将 avro 表格式强转指定数据类型，一次性修改 schema。
2. 存量 avro 格式表，查询 avro 表之前设置参数 spark.sql.forceConvertSchema.enabled=true，如若查询失败，可能 avro 格式表 schema 被缓存，执行 **refresh table** 命令，清除缓存后再设置参数进行查询，会将 avro 表格式强转指定数据类型，客户端临时修改 schema。

21.9.19 通过 Spark-sql 创建 Hudi 表或者 Hive 表，未插入数据前，查询表统计信息为空

问题

通过 spark-sql 创建 Hudi 表或者 Hive 表，未插入数据之前，查询表统计信息都为空。

解决方法

可以通过以下两种方式生成：

1. 手动通过 **analyze** 命令，触发统计信息收集。如若没有插入数据，**analyze** 命令执行完之后，再通过 **desc formatted table_name** 命令查询 totalsize 等于 0。
2. 配置 spark.sql.statistics.size.autoUpdate.enabled=true，再插入数据，后台会触发统计信息收集。

21.9.20 建表语句分区列为 timestamp 时，使用非标准格式的时间指定分区查询表统计失败

问题

建表语句分区列为 timestamp 时，使用非标准格式的时间指定分区查询表统计失败以及 show partitions table 结果编码不对。

执行 **desc formatted test_hive_orc_snappy_internal_table partition(a='***2016-8-1 11:45:5***');** 查询报错，如下所示：

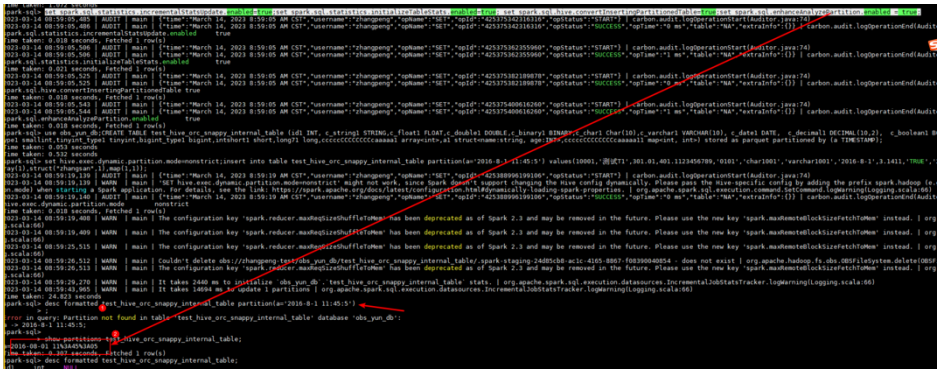

解决方法

spark.sql.hive.convertInsertingPartitionedTable 开关控制了 Hive 和 Datasource 表的插入写操作逻辑，使用 Hive 表时逻辑不会自动格式化时间戳，使用 Datasource 表时会自动格式化时间戳。

如果写入的分区字段是 a='2016-8-1 11:45:5'会自动格式化成 a='2016-08-01 11:45:05'，此时查询使用 a='2016-8-1 11:45:5'会报错。

正确查询方式如下：

spark.sql.hive.convertInsertingPartitionedTable=true 时使用 datasource 表逻辑，使用如下方式即可以正常查询：

desc formatted test_hive_orc_snappy_internal_table partition(a='*2016-08-01 11:45:05*');

21.9.21 SQL 语法兼容 TIMESTAMP/DATE 特殊字符

问题

在开源 Spark 3.2.0 版本之后，将不在支持 TIMESTAMP(*)或 DATE(*)的语法，其中 * 代表如下特殊时间字符：

- epoch
- today
- yesterday
- tomorrow
- now

默认只支持 timestamp '*' 或者 data '*'的格式。如果，使用之前的语法，插入数据表，会得到 NULL 值。

解决方法

设置参数 set spark.sql.convert.special.datetime=true; 即可兼容之前的语法。

```
spark-sql> set spark.sql.convert.special.datetime=true;
spark.sql.convert.special.datetime      true
Time taken: 0.035 seconds, Fetched 1 row(s)
```

21.9.22 Spark 客户端设置回收站 version 不生效

问题

Spark 客户端设置 fs.obs.hdfs.trash.version=1 不生效，drop table 后文件在回收站的存放路径不改变。

通常，默认情况：

- 当 fs.obs.hdfs.trash.version=2 时，回收站路径为：/user/.Trash/${userName}/Current
- 当 fs.obs.hdfs.trash.version=1 时，回收站路径为：/user/${userName}/.Trash/Current

解决办法

登录 FusionInsight Manager 页面，选择“集群 > 服务 > Hive > 配置 > 全部配置 > MetaStore（角色）> 自定义”，在自定义配置项“hive.metastore.customized.configs”中添加参数“fs.obs.hdfs.trash.version”值为“1”，保存并重启 Metastore 实例。

配置 Hive Metastore 后，回收站路径正确，如图所示：

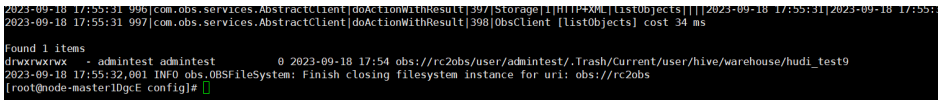

21.9.23 Spark yarn-client 模式下如何修改日志级别为 INFO

问题

Spark yarn-client 模式下如何修改日志级别为 INFO？

解决办法

登录 Spark 客户端节点，修改“*{客户端安装目录}*Spark/spark/conf/log4j.properties”配置文件，修改参数“Log4j.rootCategory”值为“INFO”，如下所示：

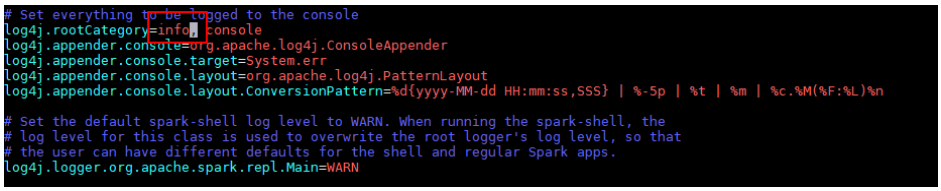

步骤 1 重新启动 spark-sql 客户端。

----结束

22 使用 Tez

22.1 Tez 常用参数

参数入口

在 Manager 系统中，选择“集群 > 服务 > Tez > 配置”，选择“全部配置”。在搜索框中输入参数名称。

参数说明

表22-1 参数说明

配置参数	说明	缺省值
property.tez.log.dir	Tez 日志目录。	/var/log/Bigdata/tez/tezui
property.tez.log.level	Tez 的日志级别。	INFO

22.2 访问 TezUI

Tez 提供 Tez 任务执行过程图形化展示功能，使用户可以通过界面的方式查看 Tez 任务执行细节。

前提条件

已安装 Yarn 服务的 TimelineServer 实例。

使用介绍

登录 Manager 系统，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），在 Manager 界面选择“集群 > 服务 > Tez”，在“基本信息”中单击“Tez WebUI”右侧的链接，打开 Tez WebUI。可查看执行的 Tez 任务执行细节。

22.3 日志介绍

日志描述

日志路径：Tez 相关日志的默认存储路径为“/var/log/Bigdata/tez/*角色名*”。

TezUI：“/var/log/Bigdata/tez/tezui”（运行日志），“/var/log/Bigdata/audit/tez/tezui”（审计日志）。

日志归档规则：Tez 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 20MB 的时候（此日志文件大小可进行配置），会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”。最多保留最近的 20 个压缩文件，压缩文件保留个数和压缩文件阈值可以配置。

表22-2 Tez 日志列表

日志类型	日志文件名	描述
运行日志	tezui.out	TezUI 运行环境信息日志
	tezui.log	TezUI 进程的运行日志
	tezui-omm-<日期>-gc.log.<编号>	TezUI 进程的 GC 日志
	prestartDetail.log	TezUI 启动前的工作日志
	check-serviceDetail.log	TezUI 服务启动是否成功的检查日志
	postinstallDetail.log	TezUI 安装后的工作日志
	startDetail.log	TezUI 进程启动日志
	stopDetail.log	TezUI 进程停止日志
审计日志	tezui-audit.log	TezUI 审计日志

日志级别

TezUI 提供了如表 22-3 所示的日志级别。

运行日志的级别优先级从高到低分别是 ERROR、WARN、INFO、DEBUG，程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表22-3 日志级别

级别	描述
ERROR	ERROR 表示系统运行的错误信息。
WARN	WARN 表示当前事件处理存在异常信息。

级别	描述
INFO	INFO 表示记录系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示记录系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

登录 Manager。

步骤 2 选择“集群 > 服务 > Tez > 配置”。

步骤 3 选择“全部配置”。

步骤 4 左边菜单栏中选择“TezUI > 日志”。

步骤 5 选择所需修改的日志级别。

步骤 6 单击“保存”，在弹出窗口中单击“确定”保存配置。

步骤 7 单击“实例”，勾选“TezUI”角色，选择“更多 > 重启实例”，输入用户密码后，在弹出窗口单击“确定”。

步骤 8 等待实例重启完成，配置生效。

----结束

日志格式

Tez 的日志格式如下所示：

表22-4 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<LogLevel>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2020-07-31 11:44:21,378 | INFO | TezUI-health-check | Start health check | com.XXX.tez.HealthCheck.run(HealthCheck.java:30)
审计日志	<yyyy-MM-dd HH:mm:ss,SSS>|<LogLevel>|<产生该日志的线程名字>|<User Name><User IP><Time><Operation><Resource><Result><Detail >|<日志事件的发生位置>	2018-12-24 12:16:25,319 | INFO | HiveServer2-Handler-Pool: Thread-185 | UserName=hive UserIP=10.153.2.204 Time=2018/12/24 12:16:25 Operation=CloseSession Result=SUCCESS Detail= | org.apache.hive.service.cli.thrift.ThriftCLIService.logAuditEvent(ThriftCLIService.java:434)

22.4 常见问题

22.4.1 TezUI 无法展示 Tez 任务执行细节

问题

登录 Manager 界面，跳转 Tez WebUI 界面，已经提交的 Tez 任务未展示，如何解决。

回答

Tez WebUI 展示的 Tez 任务数据，需要 Yarn 的 TimelineServer 支持，确认提交任务之前 TimelineServer 已经开启且正常运行。

在设置 Hive 执行引擎为 Tez 的同时，需要设置参数“yarn.timeline-service.enabled”为“true”，详情请参考 11.29 切换 Hive 执行引擎为 Tez。

22.4.2 进入 Tez 原生界面显示异常

问题

登录 Manager 界面，跳转 Tez WebUI 界面，显示 404 异常或 503 异常。

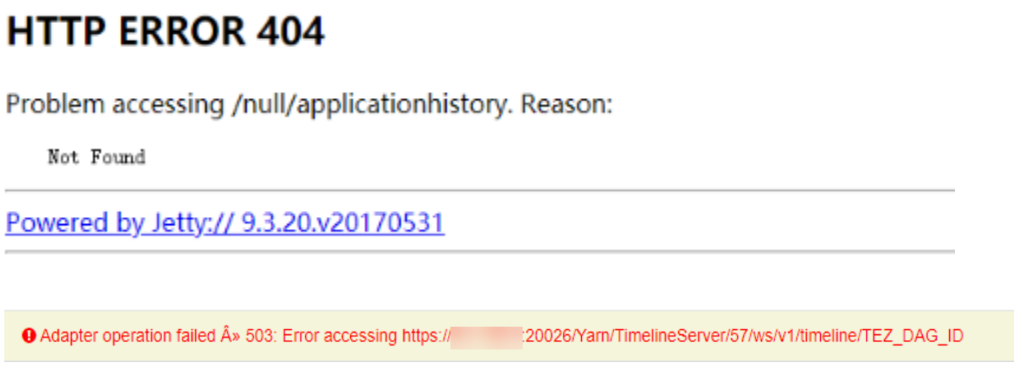

回答

Tez WebUI 依赖 Yarn 的 TimelineServer 实例，需要预先安装 TimelineServer，且处于良好状态。

22.4.3 TezUI 界面无法查看 yarn 日志

问题

登录 Tez WebUI 界面，单击 Logs 跳转 yarn 日志界面失败，无法加载数据。

回答

Tez WebUI 跳转 Yarn Logs 界面时，目前是通过 hostname 进行访问，需要在 windows 机器，配置 hostname 到 ip 的映射。具体方法为：

修改 windows 机器 C:\Windows\System32\drivers\etc\hosts 文件，增加一行 hostname 到 ip 的映射，例：10.244.224.45 10-044-224-45，保存后重新访问正常。

22.4.4 TezUI HiveQueries 界面表格数据为空

问题

登录 Manager 界面，跳转 Tez WebUI 界面，已经提交的任务，Hive Queries 界面未展示数据，如何解决。

回答

Tez WebUI 展示的 Hive Queries 任务数据，需要设置以下 3 个参数：

在 FusionInsight Manager 页面，选择“集群 > 服务 > Hive > 配置 > 全部配置 > HiveServer > 自定义”，在 hive-site.xml 中增加以下配置：

属性名	属性值
hive.exec.pre.hooks	org.apache.hadoop.hive.ql.hooks.ATSHook
hive.exec.post.hooks	org.apache.hadoop.hive.ql.hooks.ATSHook

属性名	属性值
hive.exec.failure.hooks	org.apache.hadoop.hive.ql.hooks.ATSHook

说明

TezUI 数据展示依赖于 Yarn 组件的 TimelineServer 实例，如果 TimelineServer 实例故障或未启动，需设置 hive 自定义参数 yarn-site.xml 中 **yarn.timeline-service.enabled**=false，否则 hive 任务会执行失败。

参数设置完成后，Hive Queries 界面即可展示数据，但无法展示历史数据，展示效果如下:

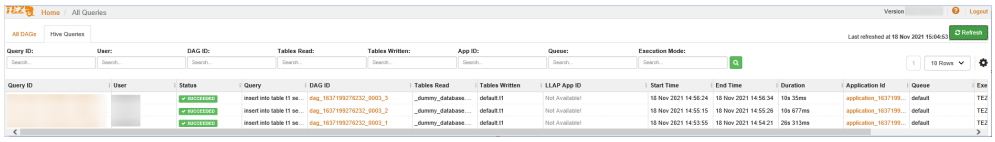

23 使用 Yarn

23.1 Yarn 常用参数

队列资源分配

Yarn 服务提供队列给用户使用，用户分配对应的系统资源给各队列使用。完成配置后，您可以单击“刷新队列”按钮或者重启 Yarn 服务使配置生效。

参数入口：

用户可在 Manager 系统中，选择“租户资源 > 动态资源计划 > 队列配置”。

参数说明以修改 Superior 调度器的 default 租户为例，其他队列的配置类似，单击“修改”编辑。

表23-1 队列配置参数

参数名	描述
AM 最多占有资源（%）	表示当前队列内所有 Application Master 所占的最大资源百分比。
每个 YARN 容器最多分配核数	表示当前队列内单个 YARN 容器可分配的最多核数，默认为-1，表示取值范围内不限制。
每个 YARN 容器最大分配内存（MB）	表示当前队列内单个 YARN 容器可分配的最大内存，默认为-1，表示取值范围内不限制。
最多运行任务数	表示当前队列最多同时可执行任务的数目，默认为-1，表示取值范围内不限制（为空意义相同），为 0 表示不可执行任务。取值范围为-1～2147483647。
每个用户最多运行任务数	表示每个用户在当前队列中最多同时可执行任务的数目，默认为-1，表示取值范围内不限制（为空意义相同），为 0 表示不可执行任务。取值范围为-1～2147483647。
最多挂起任务数	表示当前队列最多同时可挂起任务的数目，默认为-1，表示取值范围内不限制（为空意义相同），为 0 表示不可挂起任务。取值范围为-1～2147483647。

参数名	描述
资源分配规则	表示单个用户任务间的资源分配规则，包括 FIFO 和 FAIR。 一个用户若在当前队列上提交了多个任务，FIFO 规则代表一个任务完成后再执行其他任务，按顺序执行。FAIR 规则代表各个任务同时获取到资源并平均分配资源。
默认资源标签	表示在指定资源标签（Label）的节点上执行任务。
Active 状态	• ACTIVE 表示当前队列可接受并执行任务。 • INACTIVE 表示当前队列可接受但不执行任务，若提交任务，任务将处于挂起状态。
Open 状态	• OPEN 表示当前队列处于打开状态。 • CLOSED 表示当前队列处于关闭状态，若提交任务，任务直接会被拒绝。

在 UI 显示 container 日志

默认情况下，系统会将 container 日志收集到 HDFS 中。如果您不需要将 container 日志收集到 HDFS 中，可以配置参数见表 23-2。具体配置操作请参考 25.1 修改集群服务配置参数。

表23-2 参数说明

配置参数	说明	默认值
yarn.log-aggregation-enable	设置是否将 container 日志收集到 HDFS 中。 • 设置为 true，表示日志会被收集到 HDFS 目录中。默认目录为“{yarn.nodemanager.remote-app-log-dir}/${user}/{thisParam}”，该路径可通过界面上的“yarn.nodemanager.remote-app-log-dir-suffix”参数进行配置。 • 设置为 false，表示日志不会收集到 HDFS 中。 修改参数值后，需重启 Yarn 服务使其生效。 说明 在修改值为 false 并生效后，生效前的日志无法在 UI 中获取。您可以在“yarn.nodemanager.remote-app-log-dir-suffix”参数指定的路径中获取到生效前的日志。 如果需要在 UI 上查看之前产生的日志，建议将此参数设置为 true。	true

在 WebUI 显示更多历史作业

默认情况下，Yarn WebUI 界面支持任务列表分页功能，每个分页最多显示 5000 条历史作业，总共最多保留 10000 条历史作业。如果您需要在 WebUI 上查看更多的作业，可以配置参数如表 23-3。具体配置操作请参考 25.1 修改集群服务配置参数。

表23-3 参数说明

配置参数	说明	默认值
yarn.resourcemanager.max-completed-applications	设置在 WebUI 总共显示的历史作业数量。	10000
yarn.resourcemanager.webapp.pagination.enable	是否开启 Yarn WebUI 的任务列表后台分页功能。	true
yarn.resourcemanager.webapp.pagination.threshold	开启 Yarn WebUI 的任务列表后台分页功能后，每个分页显示的最大作业数量。	5000

说明

- 显示更多的历史作业，会影响性能，增加打开 Yarn WebUI 的时间，建议开启后台分页功能，并根据实际硬件性能修改“yarn.resourcemanager.max-completed-applications”参数。
- 修改参数值后，需重启 Yarn 服务使其生效。

23.2 创建 Yarn 角色

操作场景

该任务指导 MRS 集群管理员创建并设置 Yarn 的角色。Yarn 角色可设置 Yarn 管理员权限以及 Yarn 队列资源管理。

说明

如果当前组件使用了 Ranger 进行权限控制，须基于 Ranger 配置相关策略进行权限管理。具体操作可参考 20.11 添加 Yarn 的 Ranger 访问权限策略。

前提条件

- MRS 集群管理员已明确业务需求。
- 登录 Manager。

操作步骤

选择“系统 > 权限 > 角色”。

步骤 1 单击“添加角色”，然后“角色名称”和“描述”输入角色名字与描述。

步骤 2 设置角色“配置资源权限”请参见表 23-4。

Yarn 权限：

- “集群管理操作权限”：Yarn 管理员权限。
- “调度队列”：队列资源管理。

表23-4 设置角色

任务场景	角色授权操作
设置 Yarn 管理员权限	在“配置资源权限”的表格中选择“*待操作集群的名称* > Yarn”，勾选“集群管理操作权限”。 说明 设置 Yarn 管理员权限需要重启 Yarn 服务，才能使保存的角色配置生效。
设置用户在指定 Yarn 队列提交任务的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Yarn > 调度队列 > root”。 2. 在指定队列的“权限”列，勾选“提交”。
设置用户在指定 Yarn 队列管理任务的权限	1. 在“配置资源权限”的表格中选择“*待操作集群的名称* > Yarn > 调度队列 > root”。 2. 在指定队列的“权限”列，勾选“管理”。

如果 Yarn 角色包含了某个父队列的“提交”或“管理”权限，则角色默认子队列也继承此权限，将自动添加子队列的“提交”或“管理”权限。子队列继承的权限不在“配置资源权限”表格显示被选中。

如果设置 Yarn 角色时仅勾选到某个父队列的“提交”权限，使用拥有该角色权限的用户提交任务时，注意需要手动指定队列名称，否则当父队列下有多个子队列时，系统并不会自动判断，从而将任务提交到了“default”队列。

步骤 3 单击“确定”完成。

----结束

23.3 使用 Yarn 客户端

操作场景

该任务指导用户在运维场景或业务场景中使用 Yarn 客户端。

前提条件

- 已安装客户端。

  例如安装目录为“/opt/client”，以下操作的客户端目录只是举例，请根据实际安装目录修改。

- 各组件业务用户由 MRS 集群管理员根据业务需要创建。安全模式下，“机机”用户需要下载 keytab 文件。“人机”用户第一次登录时需修改密码。普通模式不需要下载 keytab 文件及修改密码操作。

使用 Yarn 客户端

以客户端安装用户，登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 如果集群为安全模式，执行以下命令进行用户认证。普通模式集群无需执行用户认证。

kinit *组件业务用户*

步骤 4 直接执行 Yarn 命令。例如：

yarn application -list

----结束

客户端常见使用问题

1. 当执行 Yarn 客户端命令时，客户端程序异常退出，报“java.lang.OutOfMemoryError”的错误。

   这个问题是由于 Yarn 客户端运行时的所需的内存超过了 Yarn 客户端设置的内存上限（默认为 128MB）。可以通过修改“<客户端安装路径>/HDFS/component_env”中的“CLIENT_GC_OPTS”来修改 Yarn 客户端的内存上限。例如，需要设置该内存上限为 1GB，则设置：

   ```
   export CLIENT_GC_OPTS="-Xmx1G"
   ```

   在修改完后，使用如下命令刷新客户端配置，使之生效：

   source *<客户端安装路径>*/**bigdata_env**

2. 如何设置 Yarn 客户端运行时的日志级别？

   Yarn 客户端运行时的日志是默认输出到 Console 控制台的，其级别默认是 INFO 级别。有的时候为了定位问题，需要开启 DEBUG 级别日志，可以通过导出一个环境变量来设置，命令如下：

   export YARN_ROOT_LOGGER=DEBUG,console

   在执行完上面命令后，再执行 Yarn Shell 命令时，即可打印出 DEBUG 级别日志。

   如果想恢复 INFO 级别日志，可执行如下命令：

   export YARN_ROOT_LOGGER=INFO,console

23.4 配置 NodeManager 角色实例使用的资源

操作场景

如果部署 NodeManager 的各个节点硬件资源（如 CPU 核数、内存总量）不一样，而 NodeManager 可用硬件资源设置为相同的值，可能造成性能浪费或状态异常，需要修改各个 NodeManager 角色实例的配置，使硬件资源得到充分利用。

对系统的影响

保存新的配置需要重启 NodeManager 角色实例，此时对应的角色实例不可用。

前提条件

已登录 Manager。

操作步骤

选择“集群 > *待操作集群的名称* > 服务 > Yarn > 实例”。

步骤 1 单击部署 NodeManager 节点对应角色实例名称，并切换到“实例配置”，选择“全部配置”。

步骤 2 “yarn.nodemanager.resource.cpu-vcores”设置当前节点上 NodeManager 可使用的虚拟 CPU 核数，建议按节点实际逻辑核数的 1.5 到 2 倍配置。
“yarn.nodemanager.resource.memory-mb”设置当前节点上 NodeManager 可使用的物理内存大小，建议按节点实际物理内存大小的 75%配置。

说明

“yarn.scheduler.maximum-allocation-vcores”可配置单个 Container 最多 CPU 可用核数，“yarn.scheduler.maximum-allocation-mb”可配置单个 Container 最大内存可用值。不支持实例级别的修改，需要在 Yarn 服务的配置中修改参数值，并重启 Yarn 服务。

步骤 3 单击“保存”，单击“确定”。重启 NodeManager 角色实例。

界面提示“操作成功”，单击“完成”，NodeManager 角色实例成功启动。

----结束

23.5 更改 NodeManager 的存储目录

操作场景

Yarn NodeManager 定义的存储目录不正确或 Yarn 的存储规划变化时，MRS 集群管理员需要在 Manager 中修改 NodeManager 的存储目录，以保证 Yarn 正常工作。
NodeManager 的存储目录包含本地存放目录“yarn.nodemanager.local-dirs”和日志目录“yarn.nodemanager.log-dirs”。适用于以下场景：

- 更改 NodeManager 角色的存储目录，所有 NodeManager 实例的存储目录将同步修改。
- 更改 NodeManager 单个实例的存储目录，只对单个实例生效，其他节点 NodeManager 实例存储目录不变。

对系统的影响

- 更改 NodeManager 角色的存储目录需要停止并重新启动集群，集群未启动前无法提供服务。
- 更改 NodeManager 单个实例的存储目录需要停止并重新启动实例，该节点 NodeManager 实例未启动前无法提供服务。
- 服务参数配置如果使用旧的存储目录，需要更新为新目录。
- 更改 NodeManager 的存储目录以后，需要重新下载并安装客户端。

前提条件

- 在各个数据节点准备并安装好新磁盘，并格式化磁盘。
- 规划好新的目录路径，用于保存旧目录中的数据。
- 准备好 MRS 集群管理员用户 **admin**。

操作步骤

检查环境。

1. 登录 Manager，选择“集群 > *待操作集群的名称* > 服务”查看 Yarn 的状态“运行状态”是否为“良好”。
   - 是，执行 1.c。
   - 否，Yarn 状态不健康，执行 1.b。
2. 修复 Yarn 异常，任务结束。
3. 确定修改 NodeManager 的存储目录场景。
   - 更改 NodeManager 角色的存储目录，执行 2。
   - 更改 NodeManager 单个实例的存储目录，执行 3。

步骤 1 更改 NodeManager 角色的存储目录。

1. 选择“集群 > *待操作集群的名称* > 服务 > Yarn > 停止服务”，停止 Yarn 服务。
2. 以 **root** 用户登录到安装 Yarn 服务的各个节点中，执行如下操作。
   a. 创建目标目录。
      例如目标目录为“${BIGDATA_DATA_HOME}/data2”：
      执行 **mkdir ${BIGDATA_DATA_HOME}/data2**
   b. 挂载目标目录到新磁盘。
      例如挂载“${BIGDATA_DATA_HOME}/data2”到新磁盘。
   c. 修改新目录的权限。
      例如新目录路径为“${BIGDATA_DATA_HOME}/data2”：

执行 **chmod 750 ${BIGDATA_DATA_HOME}/data2 -R** 和 **chown omm:wheel ${BIGDATA_DATA_HOME}/data2 -R**

3. 在 Manager 管理界面，选择“集群 > *待操作集群的名称* > 服务 > Yarn > 实例”，选择对应主机的 NodeManager 实例，单击“实例配置”，选择“全部配置”。

   将配置项“yarn.nodemanager.local-dirs”或“yarn.nodemanager.log-dirs”修改为新的目标目录。

   例如：如果修改“yarn.nodemanager.local-dirs”参数，则将其值修改为“/srv/BigData/data2/nm/localdir”。如果修改“yarn.nodemanager.log-dirs”参数，则将其值修改为“/srv/BigData/data2/nm/containerlogs”。

4. 单击“保存”，单击“确定”。重启 Yarn 服务。

   界面提示“操作成功”，单击“完成”，Yarn 成功启动，任务结束。

步骤 2 更改 NodeManager 单个实例的存储目录。

1. 选择“集群 > *待操作集群的名称* > 服务 > Yarn > 实例”，勾选需要修改存储目录的 NodeManager 单个实例，选择“更多 > 停止实例”。
2. 以 **root** 用户登录到这个 NodeManager 节点，执行如下操作。
   a. 创建目标目录。

      例如目标目录为“${BIGDATA_DATA_HOME}/data2”：

      执行 **mkdir ${BIGDATA_DATA_HOME}/data2**。

   b. 挂载目标目录到新磁盘。

      例如挂载“${BIGDATA_DATA_HOME}/data2”到新磁盘。

   c. 修改新目录的权限。

      例如新目录路径为“${BIGDATA_DATA_HOME}/data2”：

      执行 **chmod 750 ${BIGDATA_DATA_HOME}/data2 -R** 和 **chown omm:wheel ${BIGDATA_DATA_HOME}/data2 -R**。

3. 在 Manager 管理界面，单击指定的 NodeManager 实例并切换到“实例配置”。

   将配置项“yarn.nodemanager.local-dirs”或“yarn.nodemanager.log-dirs”修改为新的目标目录。

   例如：如果修改“yarn.nodemanager.local-dirs”参数，则将其值修改为“/srv/BigData/data2/nm/localdir”。如果修改“yarn.nodemanager.log-dirs”参数，则将其值修改为“/srv/BigData/data2/nm/containerlogs”。

4. 单击“保存”，单击“确定”。重启 NodeManager 实例。

   界面提示“操作成功”，单击“完成”，NodeManager 实例启动成功。

----结束

23.6 配置 YARN 严格权限控制

配置场景

在安全模式的多租户场景下，一个集群可以支持多个用户使用以及支持多个用户任务提交、运行，用户之间是不可见，需要有一个权限控制机制，使用户的任务信息不被其他用户获取。

例如，用户 A 提交的应用正在运行，此时用户 B 登录系统并查看应用列表，用户 B 不应该访问到 A 用户的应用信息。

配置描述

- 查看 Yarn 服务配置参数

  参考 25.1 修改集群服务配置参数进入 Yarn 服务参数“全部配置”界面，在搜索框中输入表 23-5 中参数名称。

表23-5 参数描述

参数	描述	默认值
yarn.acl.enable	Yarn 权限控制启用开关。	true
yarn.webapp.filter-entity-list-by-user	严格视图启用开关，开启后，登录用户只能查看该用户有权限查看的内容。当要开启该功能时，同时需要设置参数“yarn.acl.enable”为 true。	true

- 查看 Mapreduce 服务配置参数

  参考 25.1 修改集群服务配置参数进入 Mapreduce 服务参数“全部配置”界面，在搜索框中输入表 23-6 中参数名称。

表23-6 参数描述

参数	描述	默认值
mapreduce.cluster.acls.enabled	MR JobHistoryServer 权限控制启用开关。该参数为客户端参数，当 JobHistoryServer 服务端开启权限控制之后该参数生效。	true
yarn.webapp.filter-entity-list-by-user	MR JobHistoryServer 严格视图启用开关，开启后，登录用户只能查看该用户有权限查看的内容。该参数为 JobHistoryServer 的服务端参数，表示 JHS 开启了权限控制，但是否要对某一个特定的 Application 进行控制，是由客户端参数：	true

参数	描述	默认值
	“mapreduce.cluster.acls.enabled”决定。	

须知

以上配置会影响 restful API 和 shell 命令结果，即以上配置开启后，restful API 调用和 shell 命令运行所返回的内容只包含调用用户有权查看的信息。

当 yarn.acl.enable 或 mapreduce.cluster.acls.enabled 设置为 false 时，即关闭 Yarn 或 Mapreduce 的权限校验功能。此时任何用户都可以在 Yarn 或 MapReduce 上提交任务和查看任务信息，存在安全风险，请谨慎使用。

23.7 配置 Container 日志聚合功能

配置场景

YARN 提供了 Container 日志聚合功能，可以将各节点 Container 产生的日志收集到 HDFS，释放本地磁盘空间。日志收集的方式有两种：

- 应用完成后将 Container 日志一次性收集到 HDFS。
- 应用运行过程中周期性收集 Container 输出的日志片段到 HDFS。

配置描述

参数入口：

参考 25.1 修改集群服务配置参数进入 Yarn 服务参数“全部配置”界面，在搜索框中输入表 23-7 中参数名称，修改并保存配置。然后在 Yarn 服务“概览”页面选择“更多 > 同步配置”。同步完成后重启 Yarn 服务。

周期性收集日志功能目前仅支持 MapReduce 应用，且 MapReduce 应用必须进行相应的日志文件滚动输出配置，需要在 MapReduce 客户端节点的*“客户端安装路径*/Yarn/config/mapred-site.xml”配置文件中进行如表 23-9 所示的配置。

表23-7 参数说明

参数	描述	默认值
yarn.log-aggregation-enable	设置是否打开 Container 日志聚合功能。 • 设置为“true”，表示打开该功能，日志会被收集到 HDFS 目录中。 • 设置为“false”，表示关闭该功能，表示日志不会收集到 HDFS 中。 修改参数值后，需重启 YARN 服务使其生效。 说明 • 在修改值为“false”并生效后，生效前的日志无	true

参数	描述	默认值
	法在 WebUI 中获取。 • 如果需要在 WebUI 界面上查看之前产生的日志，建议将此参数设置为“true”。	
yarn.nodemanager.log-aggregation.roll-monitoring-interval-seconds	NodeManager 周期性日志收集的时间间隔。 • 设置为-1 或 0 时，表示周期性收集日志功能关闭，日志在应用运行完成后一次性收集。 • 收集周期最小可设定为 3600 秒。当设置为大于 0 秒且小于 3600 秒时，收集周期将使用 3600 秒。 定义 NodeManager 唤醒并上传日志的间隔周期。设置为-1 或 0 表示禁用滚动监控，应用任务结束后日志汇聚。取值范围大于等于-1。	-1
yarn.nodemanager.disk-health-checker.log-dirs.max-disk-utilization-per-disk-percentage	配置 Container 日志目录可以占用每块磁盘上 YARN 的磁盘配额的最大百分比。当日志目录占用空间超过此设定值时，将触发周期性日志收集服务启动一次周期外的日志收集活动，以释放本地磁盘空间。每个磁盘上可提供给 Container logs 的最大可使用率。当 Container logs 使用超过这个限制，会触发滚动汇聚。 磁盘配额最大百分比的有效取值范围为-1～100，如果配置小于-1，会被强制重置为 25；如果配置大于 100，则被强制重置为 25。而配置为-1 时则关闭 Container 日志目录的磁盘容量检测功能。 **说明** • Container 日志目录实际可用磁盘百分比=YARN 磁盘可用百分比（“yarn.nodemanager.disk-health-checker.max-disk-utilization-per-disk-percentage”） * 日志目录可用百分比（“yarn.nodemanager.disk-health-checker.log-dirs.max-disk-utilization-per-disk-percentage”）。 • 只有启用了周期性收集日志功能的应用才会在日志目录磁盘配额超过设定阈值时被触发启动日志收集。	25
yarn.nodemanager.remote-app-log-dir-suffix	设置 HDFS 用于存放 Container 日志的文件夹名称。该配置加上“yarn.nodemanager.remote-app-log-dir”，构成了 Container 日志的完整存放目录。目录为：“{yarn.nodemanager.remote-app-log-dir}/${user}/{yarn.nodemanager.remote-app-log-dir-suffix}”。 **说明** *{user}*为运行任务时的用户名。	logs
yarn.nodemanager.log-	设置 Container 日志归集失败后日志在本地保	604800

参数	描述	默认值
aggregator.on-fail.remain-log-in-sec	留的时间。单位：秒。 • 设置为 0 时，本地日志将马上删除。 • 设置为正数时，表示本地日志将保留这段时间。	

参考 25.1 修改集群服务配置参数进入 Mapreduce 服务参数“全部配置”界面，在搜索框中输入表 23-8 中参数名称。

表23-8 参数说明

参数	描述	默认值
yarn.log-aggregation.retain-seconds	汇聚日志的保存时间。单位：秒。 • 设置为-1 时，表示 HDFS 上面的 Container 聚合日志将永久保留。 • 设置为 0 或正数时，表示 HDFS 上面的 Container 聚合日志将保留这段时间，超时将被删除。 说明 当时间设置太短时，有可能会增加 NameNode 的负担，建议根据实际情况设置一个合理的时间值。	1296000
yarn.log-aggregation.retain-check-interval-seconds	设置扫描 HDFS 保存的 Container 聚合日志的间隔时间。单位：秒。 • 设置为-1 或 0 时，间隔时间将为“yarn.log-aggregation.retain-seconds”该配置时间的十分之一。 说明 当该配置设置为-1 或 0 时，“yarn.log-aggregation.retain-seconds”不能设置为 0。 • 设置为正数时，将周期性的间隔这段时间以后对 HDFS 上的 container 聚合日志进行扫描。 说明 当时间设置太短时，有可能会增加 NameNode 的负担，建议根据实际情况设置一个合理的时间。	86400

参考 25.1 修改集群服务配置参数进入 Yarn 服务参数“全部配置”界面，在搜索框中输入表 23-9 中参数名称。

表23-9 MapReduce 应用日志文件滚动输出配置

参数	描述	默认值

参数	描述	默认值
mapreduce.task.userlog.limit.kb	MR 应用程序单个 task 日志文件大小限制。当日志文件达到该限制时，会新建一个日志文件进行输出。设置为“0”表示不限制日志文件大小。	51200
yarn.app.mapreduce.task.container.log.backups	MR 应用程序 task 日志保留的最大个数。 设置为“0”表示不滚动输出。 使用 CRLA（ContainerRollingLogAppender）时任务日志备份文件的数量。默认使用 CLA（ContainerLogAppender）且 container 日志不回滚。 当 mapreduce.task.userlog.limit.kb 和 yarn.app.mapreduce.task.container.log.backups 都大于 0 时，任务启用 CRLA。取值范围 0~999。	10
yarn.app.mapreduce.am.container.log.limit.kb	MR 应用程序单个 AM 日志文件大小限制。单位：KB，当日志文件达到该限制时，会新建一个日志文件进行输出。设置为“0”表示不限制单个 AM 日志文件大小。	51200
yarn.app.mapreduce.am.container.log.backups	MR 应用程序 AM 日志保留的最大个数。设置为“0”表示不滚动输出。使用 CRLA（ContainerRollingLogAppender）时 ApplicationMaster 日志备份文件的数量。默认使用 CLA（ContainerLogAppender）且容器日志不回滚。 当 yarn.app.mapreduce.am.container.log.limit.kb 和 yarn.app.mapreduce.am.container.log.backups 都大于 0 时，ApplicationMaster 启用 CRLA。取值范围 0~999。	20
yarn.app.mapreduce.shuffle.log.backups	MR 应用程序 shuffle 日志保留的最大个数。设置为“0”表示不滚动输出。 当 yarn.app.mapreduce.shuffle.log.limit.kb 和 yarn.app.mapreduce.shuffle.log.backups 都大于 0 时，syslog.shuffle 将采用 CRLA。取值范围 0~999。	10
yarn.app.mapreduce.shuffle.log.limit.kb	MR 应用程序单个 shuffle 日志文件大小限制，单位 KB。当日志文件达到该限制时，会新建一个日志文件进行输出。设置为“0”不限制单个 shuffle 日志文件大小。取值范围大于等于 0。	51200

23.8 启用 CGroups 功能

配置场景

CGroups 是一个 Linux 内核特性。它可以将任务集及其子集聚合或分离成具备特定行为的分层组。在 YARN 中，CGroups 特性对容器（container）使用的资源（例如 CPU 使用率）进行限制。本特性大大降低了限制容器 CPU 使用的难度。

说明

当前 CGroups 仅用于限制 CPU 使用率。

配置描述

由于 CGroups 为 Linux 内核特性，是通过 **LinuxContainerExecutor** 进行开放。请参考官网资料对 **LinuxContainerExecutor** 进行安全配置。您可通过官网资料了解系统用户和用户组配置对应的文件系统权限。

说明

- 请勿修改对应文件系统中各路径所属的用户、用户组及对应的权限，否则可能导致本功能异常。
- 当参数“yarn.nodemanager.resource.percentage-physical-cpu-limit”配置过小，导致可使用的核不足 1 个时，例如 4 核节点，将此参数设置为 20%，不足 1 个核，那么将会使用系统全部的核。Linux 的一些版本不支持 Quota 模式，例如 Cent OS。在这种情况下，可以使用 CPUset 模式。

配置 cpuset 模式，即 YARN 只能使用配置的 CPU，需要添加以下配置。

表23-10 cpuset 配置

参数	描述	默认值
yarn.nodemanager.linux-container-executor.cgroups.cpu-set-usage	设置为“true”时，应用以 cpuset 模式运行。	false

配置 strictcpuset 模式，即 container 只能使用配置的 CPU，需要添加以下配置。

表23-11 CPU 硬隔离参数配置

参数	描述	默认值
yarn.nodemanager.linux-container-executor.cgroups.cpu-set-usage	设置为“true”时，应用以 cpuset 模式运行。	false
yarn.nodemanager.linux-container-executor.cgroups.cpuset.stri	设置为 true 时，container 只能使用配置的 CPU。	false

参数	描述	默认值
ct.enabled		

要从 cpuset 模式切换到 Quota 模式，必须遵循以下条件：

- 配置“yarn.nodemanager.linux-container-executor.cgroups.cpu-set-usage”=“false”。
- 删除“/sys/fs/cgroup/cpuset/hadoop-yarn/”路径下 container 文件夹（如果存在）。
- 删除“/sys/fs/cgroup/cpuset/hadoop-yarn/”路径下 cpuset.cpus 文件中设置的所有 CPU。

操作步骤

登录 Manager 系统。选择“集群 > *待操作集群的名称* > 服务 > Yarn > 配置”，选择“全部配置”。

步骤 1 在左侧导航栏选择“NodeManager > 自定义”，找到 yarn-site.xml 文件。

步骤 2 添加表 23-10 和表 23-11 中的参数为自定义参数。

根据配置文件与参数作用，在“yarn-site.xml”所在行“名称”列输入参数名，在“值”列输入此参数的参数值。

单击“＋”增加自定义参数。

步骤 3 单击“保存”，在弹出的“保存配置”窗口中确认修改参数，单击“确定”。界面提示“操作成功”，单击“完成”，配置保存成功。

保存完成后请重新启动配置过期的 Yarn 服务以使配置生效。

----结束

23.9 配置 AM 失败重试次数

配置场景

在资源不足导致 ApplicationMaster 启动失败的情况下，调整如下参数值，提高容错性，保证客户端应用的正常运行。

配置描述

参考 25.1 修改集群服务配置参数进入 Yarn 服务参数“全部配置”界面，在搜索框中输入表 23-12 中参数名称。

表23-12 参数说明

参数	描述	默认值
yarn.resourcemanager.am.max-	ApplicationMaster 重试次数，增加重试次数，可以防止资源不足导致的 AM 启动失败问题。适用于所有	5

参数	描述	默认值
attempts	ApplicationMaster 的全局设置。每个 ApplicationMaster 都可以使用 API 设置一个单独的最大尝试次数，但这个次数不能大于全局的最大次数。如果大于了，那 ResourceManager 将会覆写这个单独的最大尝试次数。以允许至少一次重试。取值范围大于等于 1。	

23.10 配置 AM 自动调整分配内存

配置场景

启动该配置的过程中，ApplicationMaster 在创建 container 时，分配的内存会根据任务总数的浮动自动调整，资源利用更加灵活，提高了客户端应用运行的容错性。

配置描述

参数入口：

在 Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > Yarn > 配置”，选择“全部配置”，在搜索框中输入参数名称“mapreduce.job.am.memory.policy”。

配置说明：

配置项的默认值为空，此时不会启动自动调整的策略，ApplicationMaster 的内存仍受“yarn.app.mapreduce.am.resource.mb”配置项的影响。

配置参数的值由 5 个数值组成，中间使用“:”与“,”分隔，格式为：**baseTaskCount:taskStep:memoryStep,minMemory:maxMemory**，在键入时会严格校验格式。

表23-13 配置数值说明

数值名称	描述	设定要求
baseTaskCount	任务总量基数，只有当应用的 task 总数（map 端与 reduce 端之和）不小于该值时配置才会起作用	不能为空且大于零
taskStep	任务增量步进，与 memoryStep 共同决定内存调整量	不能为空且大于零
memoryStep	内存增量步进，在"yarn.app.mapreduce.am.resource.mb"配置的基础上对内存向上调整	不能为空且大于零，单位：MB
minMe	内存自动调整下限，若调整后的内存不大于该	不能为空且大于零，且

数值名称	描述	设定要求
mory	值，仍保持"yarn.app.mapreduce.am.resource.mb"的配置	不大于 maxMemory 的设定值 单位：MB
maxMemory	内存自动调整上限，若调整后的内存超过该值，则使用该值作为最终调整值	不能为空且大于零，且不小于 minMemory 的设定值 单位：MB

配置示例

配置情况：

- yarn.app.mapreduce.am.resource.mb=1536
- mapreduce.job.am.memory.policy=100:10:50,1200:2000
- 某应用 task 总数=120

计算过程：

调整后内存=1536+[（120-100）/10]*50=1636，满足 1200<1636 且 2000>1636，最终 ApplicationMaster 内存会设定为 1636MB。

若 memStep 修改为 250，调整后内存=1536+[（120-100）/10]*250=2136，超过 maxMemory=2000 的限制，最终 ApplicationMaster 内存会设定为 2000MB。

说明

对于计算后的调整值低于设定的“minMemory”值的情形，虽然此时配置不会生效但后台仍然会打印出这个调整值，用于为用户提供“minMemory”参数调整的依据，保证配置可以生效。

23.11 配置访问通道协议

配置场景

服务端配置了 web 访问为 https 通道，如果客户端没有配置，默认使用 http 访问，客户端和服务端的配置不同，就会导致访问结果显示乱码。在客户端和服务端配置相同的“yarn.http.policy”参数，可以防止客户端访问结果显示乱码。

操作步骤

在 Manager 系统中，选择“集群 > 服务 > Yarn > 配置”，选择“全部配置”，在搜索框中输入参数名称“yarn.http.policy”。

- 安全模式下配置为“HTTPS_ONLY”。
- 普通模式下配置为“HTTP_ONLY”。

步骤 1 以客户端安装用户，登录安装客户端的节点。

步骤 2 执行以下命令，进入客户端安装路径。

cd /opt/client

步骤 3 执行以下命令编辑“yarn-site.xml”文件。

vi Yarn/config/yarn-site.xml

修改“yarn.http.policy”的参数值。

安全模式下，“yarn.http.policy”配置成“HTTPS_ONLY”。

普通模式下，“yarn.http.policy”配置成“HTTP_ONLY”。

步骤 4 执行**:wq** 命令保存。

步骤 5 重启客户端使配置生效。

----结束

23.12 检测内存使用情况

配置场景

针对所提交应用的内存使用无法预估的情况，可以通过修改服务端的配置项控制是否对内存使用进行检测。

若不检测内存使用，Container 会占用内存直到内存溢出；若检测内存使用，当内存使用超过配置的内存大小时，相应的 Container 会被 kill 掉。

配置描述

参考 25.1 修改集群服务配置参数进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。

表23-14 参数说明

参数	描述	默认值
yarn.nodemanager.vmem-check-enabled	是否进行虚拟内存检测的开关。如果任务使用的内存量超出分配值，则直接将任务强制终止。 • 设置为 true 时，进行虚拟内存检测； • 设置为 false 时，不进行虚拟内存检测。	true
yarn.nodemanager.pmem-check-enabled	是否进行物理内存检测的开关。如果任务使用的内存量超出分配值，则直接将任务强制终止。 • 设置为 true 时，进行物理内存检测； • 设置为 false 时，不进行物理内存检测。	true

23.13 配置自定义调度器的 WebUI

配置场景

如果用户在 ResourceManager 中配置了自定义的调度器，可以通过以下配置项为其配置相应的 Web 展示页面及其他 Web 应用。

配置描述

参考 25.1 修改集群服务配置参数进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。

表23-15 配置自定义调度器的 WebUI

参数	描述	默认值
hadoop.http.rmwebapp.scheduler.page.classes	在 RM WebUI 中为自定义调度器加载相应的 web 页面。仅当“yarn.resourcemanager.scheduler.class”配置为自定义调度器时此配置项生效。	-
yarn.http.rmwebapp.external.classes	在 RM 的 Web 服务中加载用户自定义的 web 应用。	-

23.14 配置 YARN Restart 特性

配置场景

YARN Restart 特性包含两部分内容：ResourceManager Restart 和 NodeManager Restart。

- 当启用 ResourceManager Restart 时，升主后的 ResourceManager 就可以通过加载之前的主 ResourceManager 的状态信息，并通过接收所有 NodeManager 上 container 的状态信息，重构运行状态继续执行。这样应用程序通过定期执行检查点操作保存当前状态信息，就可以避免工作内容的丢失。
- 当启用 NodeManager Restart 时，NodeManager 在本地保存当前节点上运行的 container 信息，重启 NodeManager 服务后通过恢复此前保存的状态信息，就不会丢失在此节点上运行的 container 进度。

配置描述

参考 25.1 修改集群服务配置参数进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。

ResourceManager Restart 特性配置如下。

表23-16 ResourceManager Restart 参数配置

参数	描述	默认值
yarn.resourcemanager.recovery.enabled	设置是否让 ResourceManager 在启动后恢复状态。如果设置为 true，那 yarn.resourcemanager.store.class 也必须设置。	true
yarn.resourcemanager.store.class	指定用于保存应用程序和任务状态以及证书内容的 state-store 类。	org.apache.hadoop.yarn.server.resourcemanager.recovery.AsyncZKRMStateStore
yarn.resourcemanager.zk-state-store.parent-path	ZKRMStateStore 在 ZooKeeper 上的保存目录。	/rmstore
yarn.resourcemanager.work-preserving-recovery.enabled	启用 ResourceManager Work preserving 功能。该配置仅用于 YARN 特性验证。	true
yarn.resourcemanager.state-store.async.load	对已完成的 application 采用 ResourceManager 异步恢复方式。	true
yarn.resourcemanager.zk-state-store.num-fetch-threads	启用异步恢复功能，增加工作线程的数量可以加快恢复 ZK 中保存的任务信息的速度，取值范围大于 0。	20

NodeManager Restart 特性配置如下。

表23-17 NodeManager Restart 参数配置

参数	描述	默认值
yarn.nodemanager.recovery.enabled	当 Nodemanager 重启时是否启用日志失败收集功能，是否恢复未完成的 Application。	true
yarn.nodemanager.recovery.dir	NodeManager 用于保存 container 状态的本地目录。	${SRV_HOME}/tmp/yarn-nm-recovery
yarn.nodemanager.recovery.supervised	NodeManager 是否在监控下运行。开启此特性后 NodeManager 在退出后不会清理 containers，NodeManager 会假设自己会立即重启和恢复 containers。	true

23.15 配置 AM 作业保留

配置场景

在 YARN 中，ApplicationMaster(AM)与 Container 类似，都运行在 NodeManager(NM)上（本文中忽略未管理的 AM）。AM 可能由于多种原因崩溃、退出或关闭。如果 AM 停止运行，ResourceManager(RM)会关闭 ApplicationAttempt 中管理的所有 Container，其中包括当前在 NM 上运行的所有 Container。RM 会在另一计算节点上启动新的 ApplicationAttempt。

对于不同类型的应用，希望以不同方式处理 AM 重启的事件。MapReduce 类应用的目标是不丢失任务，但允许丢失当前运行的 Container。但是对于长周期的 YARN 服务而言，用户可能并不希望由于 AM 的故障而导致整个服务停止运行。

YARN 支持在新的 ApplicationAttempt 启动时，保留之前 Container 的状态，因此运行中的作业可以继续无故障的运行。

图23-1 AM 作业保留

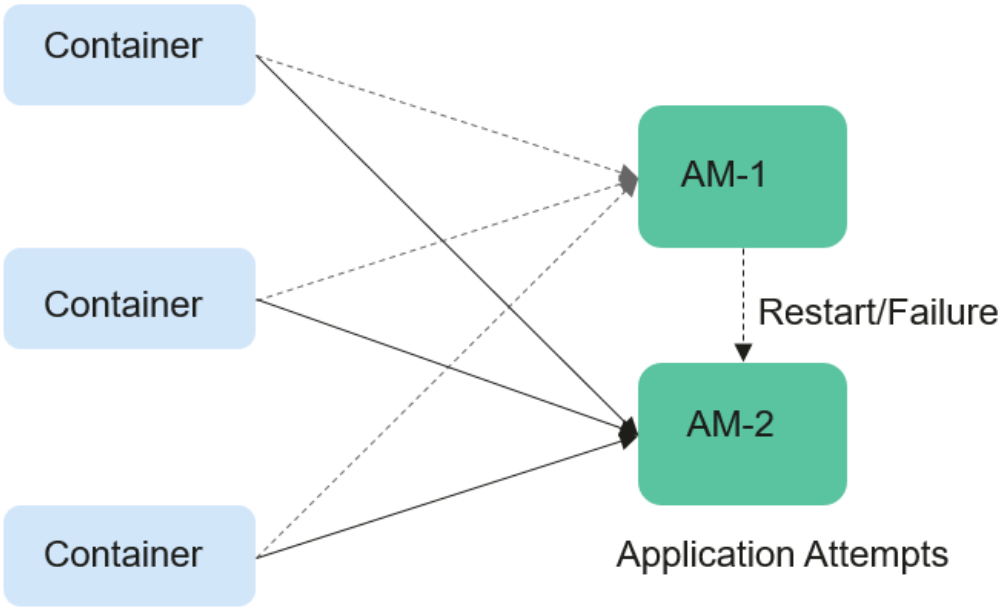

配置描述

参考 25.1 修改集群服务配置参数进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。

根据表 23-18，对如下参数进行设置。

表23-18 AM 作业保留相关参数

参数	说明	默认值

参数	说明	默认值
yarn.app.mapreduce.am.work-preserve	是否开启 AM 作业保留特性。	false
yarn.app.mapreduce.am.umbilical.max.retries	AM 作业保留特性中，运行的容器尝试恢复的最大次数。	5
yarn.app.mapreduce.am.umbilical.retry.interval	AM 作业保留特性中，运行的容器尝试恢复的时间间隔。单位：毫秒。	10000
yarn.resourcemanager.am.max-attempts	ApplicationMaster 的重试次数。增加重试次数可以避免当资源不足时造成 AM 启动失败。 适用于所有 ApplicationMaster 的全局设置。每个 ApplicationMaster 都可以使用 API 设置一个单独的最大尝试次数，但这个次数不能大于全局的最大次数。如果大于了，那 ResourceManager 将会覆写这个单独的最大尝试次数。取值范围大于等于 1。	2

23.16 配置本地化日志级别

配置场景

container 本地化默认的日志级别是 INFO。用户可以通过配置“yarn.nodemanager.container-localizer.java.opts”来改变日志级别。

配置描述

在 Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > Yarn > 配置”，选择“全部配置”，在 NodeManager 的配置文件“yarn-site.xml”中配置下面的参数来更改日志级别。

表23-19 参数描述

参数	描述	默认值
yarn.nodemanager.container-localizer.java.opts	附加的 jvm 参数是提供给本地化 container 进程使用的。	-Xmx256m -Djava.security.krb5.conf=${KRB5_CONFIG}

默认值-Xmx256m -Djava.security.krb5.conf=${KRB5_CONFIG}和默认日志级别是 INFO。为了更改 container 本地化的日志级别，添加下面的内容。

```
-Dhadoop.root.logger=<LOG_LEVEL>,localizationCLA
```

示例：

为了更改本地化日志级别为 DEBUG，参数值应该为

```
-Xmx256m -Dhadoop.root.logger=DEBUG,localizationCLA
```

说明

允许的日志级别是：FATAL，ERROR，WARN，INFO，DEBUG，TRACE 和 ALL。

23.17 配置运行任务的用户

配置场景

目前 YARN 支持启动 NodeManager 的用户运行所有用户提交的任务，也支持以提交任务的用户运行任务。

配置描述

在 Manager 系统中，选择“集群 > *待操作集群的名称* > 服务 > Yarn > 配置”，选择“全部配置”。在搜索框中输入参数名称。

表23-20 参数描述

参数	描述	默认值
yarn.nodemanager.linux-container-executor.user	运行任务的用户。	默认为空。 **说明** 默认为空，实际以提交任务的用户来运行任务。
yarn.nodemanager.container-executor.class	启动任务的 executor。	org.apache.hadoop.yarn.server.nodemanager.EnhancedLinuxContainerExecutor

说明

- “yarn.nodemanager.linux-container-executor.user”配置运行 container 的用户。默认空表示运行 container 的用户就是提交任务的用户。该参数仅在“yarn.nodemanager.container-executor.class”配置为“org.apache.hadoop.yarn.server.nodemanager.EnhancedLinuxContainerExecutor”时有效。
- 非安全模式下，当“yarn.nodemanager.linux-container-executor.user”设置为 omm 时，也需设置“yarn.nodemanager.linux-container-executor.nonsecure-mode.local-user”为 omm。
- 建议“yarn.nodemanager.linux-container-executor.user”和“yarn.nodemanager.container-executor.class”这两个参数都采用默认值，这样安全性更高。

23.18 TimelineServer 支持 HA

操作场景

TimelineServer 作为 Yarn 服务的一个角色，当前版本开始支持 HA 模式。如果需要避免 TimelineServer 单点故障问题，可以通过开启 TimelineServer HA 来确保 Yarn TimelineServer 角色的高可用性。

说明

目前 IPV6 安全模式集群不支持 TimelineServer HA。

该功能适用于 MRS 3.2.0-LTS.1 及之后版本。

对系统的影响

- 转换前，需要修改 TimelineServer 的服务端参数“TLS_FLOAT_IP”为一个可用的浮动 IP（单实例时该配置默认使用节点业务 IP）。
- 转换过程中，依赖 TimelineServer 角色会出现配置过期，需要重启配置过期的实例。

操作步骤

登录 FusionInsight Manager 界面，选择“集群 > 服务 > Yarn > 配置”，打开 Yarn 服务配置页面。

步骤 1 修改配置项“TLS_FLOAT_IP”的值为一个可用的浮动 IP（浮动 IP 与两个 TimelineServer 实例的业务 IP 需要在同一个网段），然后选择“保存 > 确定”，保存配置成功。

步骤 2 选择“实例 > 添加实例”，选择一个节点添加 TimelineServer 实例，选择“下一步 > 下一步 > 提交”，添加实例成功。

步骤 3 进入 FusionInsight Manager 主页，单击集群的名称后的“...”，选择“重启配置过期的实例”，等待重启实例成功。

步骤 4 查看重启后的各实例状态，例如 TimelineServer 实例的主备显示和运行状态正常。

----结束

23.19 Yarn 日志介绍

日志描述

Yarn 相关日志的默认存储路径如下：

- ResourceManager：“/var/log/Bigdata/yarn/rm”（运行日志），“/var/log/Bigdata/audit/yarn/rm”（审计日志）
- NodeManager：“/var/log/Bigdata/yarn/nm”（运行日志），“/var/log/Bigdata/audit/yarn/nm”（审计日志）

日志归档规则：Yarn 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 50MB 的时候，会自动压缩，压缩后的日志文件名规则为：“<原有日志名>-<yyyy-mm-dd_hh-mm-ss>.[编号].log.zip”。最多保留最近的 100 个压缩文件，压缩文件保留个数可以在 Manager 界面中配置。

日志归档规则：

表23-21 Yarn 日志列表

日志类型	日志文件名	描述
运行日志	hadoop-<SSH_USER>-<process_name>-<hostname>.log	Yarn 组件日志，记录 Yarn 组件运行时候所产生的大部分日志。
	hadoop-<SSH_USER>-<process_name>-<hostname>.out	Yarn 运行环境信息日志。
	<process_name>-<SSH_USER>-<DATE>-<PID>-gc.log	垃圾回收日志。
	yarn-haCheck.log	ResourceManager 主备状态检测日志。
	yarn-service-check.log	Yarn 服务健康状态检查日志。
	yarn-start-stop.log	Yarn 服务启停操作日志。
	yarn-prestart.log	Yarn 服务启动前集群操作的记录日志。
	yarn-postinstall.log	Yarn 服务安装后启动前的工作日志。
	hadoop-commission.log	Yarn 入服日志。
	yarn-cleanup.log	Yarn 服务卸载时候的清理日志。
	yarn-refreshqueue.log	Yarn 刷新队列日志。
	upgradeDetail.log	升级日志记录。
	stderr/stdin/syslog	Yarn 服务上运行的应用所对应的 container 日志。
	yarn-application-check.log	Yarn 服务上运行的应用检查日志。
	yarn-appsummary.log	Yarn 服务上运行的应用的运行结果日志。
	yarn-switch-resourcemanager.log	Yarn 主备倒换运行日志。
	ranger-yarn-plugin-enable.log	Yarn 启用 Ranger 鉴权的

日志类型	日志文件名	描述
		日志
	yarn-nodemanager-period-check.log	Yarn nodemanager 的周期检查日志
	yarn-resourcemanager-period-check.log	Yarn resourcemanager 的周期检查日志
	hadoop.log	Hadoop 的客户端日志
	env.log	实例启停前的环境信息日志。
审计日志	yarn-audit-<process_name>.log ranger-plugin-audit.log	Yarn 操作审计日志。
	SecurityAuth.audit	Yarn 安全审计日志。

日志级别

Yarn 中提供了如表 23-22 所示的日志级别。其中日志级别优先级从高到低分别是 OFF、FATAL、ERROR、WARN、INFO、DEBUG。程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表23-22 日志级别

级别	描述
FATAL	FATAL 表示当前事件处理存在严重错误信息。
ERROR	ERROR 表示当前事件处理存在错误信息。
WARN	WARN 表示当前事件处理存在异常告警信息。
INFO	INFO 表示记录系统及各事件正常运行状态信息
DEBUG	DEBUG 表示记录系统及系统的调试信息

如果您需要修改日志级别，请执行如下操作：

参考 25.1 修改集群服务配置参数，进入 Yarn 服务“全部配置”页面。

步骤 2 在左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别。

步骤 4 单击“保存配置”，在弹出窗口中单击“确定”使配置生效。

说明

配置完成后立即生效，不需要重启服务。

----结束

日志格式

Yarn 的日志格式如下所示：

表23-23 日志格式

日志类型	格式	示例
运行日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2021-09-26 14:18:59,109 | INFO | main | Client environment:java.compiler=<NA> | org.apache.zookeeper.Environment.logEnv(Environment.java:100)
审计日志	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的 message>|<日志事件的发生位置>	2021-09-26 14:24:43,605 | INFO | main-EventThread | USER=omm OPERATION=refreshAdminAcls TARGET=AdminService RESULT=SUCCESS | org.apache.hadoop.yarn.server.resourcemanager.RMAuditLogger$LogLevel$6.printLog(RMAuditLogger.java:91)

23.20 Yarn 性能调优

23.20.1 抢占任务

操作场景

抢占任务可精简队列中的 job 运行并提高资源利用率，由 ResourceManager 的 capacity scheduler 实现，其简易流程如下：

1. 假设存在两个队列 A 和 B。其中队列 A 的 capacity 为 25%，队列 B 的 capacity 为 75%。
2. 初始状态下，任务 1 发送给队列 A，此任务需要 75%的集群资源。之后任务 2 发送到了队列 B，此任务需要 50%的集群资源。
3. 任务 1 将会使用队列 A 提供的 25%的集群资源，并从队列 B 获取的 50%的集群资源。队列 B 保留 25%的集群资源。
4. 启用抢占任务特性，则任务 1 使用的资源将会被抢占。队列 B 会从队列 A 中获取 25%的集群资源以满足任务 2 的执行。
5. 当任务 2 完成后，集群中存在足够的资源时，任务 1 将重新执行。

操作步骤

参数入口：

参考 25.1 修改集群服务配置参数进入 Yarn 服务参数“全部配置”界面，在搜索框中输入参数名称。

表23-24 Preemption 配置

参数	描述	默认值
yarn.resourcemanager.scheduler.monitor.enable	根据“yarn.resourcemanager.scheduler.monitor.policies”中的策略，启用新的 scheduler 监控。设置为“true”表示启用监控，并根据 scheduler 的信息，启动抢占的功能。设置为“false”表示不启用。	false
yarn.resourcemanager.scheduler.monitor.policies	设置与 scheduler 配合的“SchedulingEditPolicy”的类的清单。	org.apache.hadoop.yarn.server.resourcemanager.monitor.capacity.ProportionalCapacityPreemptionPolicy
yarn.resourcemanager.monitor.capacity.preemption.observe_only	• 设置为“true”，则执行策略，但是不对集群资源进程抢占操作。 • 设置为“false”，则执行策略，且根据策略启用集群资源抢占的功能。	false
yarn.resourcemanager.monitor.capacity.preemption.monitoring_interval	根据策略监控的时间间隔，单位为毫秒。如果将该参数设置为更大的值，容量检测将不那么频繁地运行。	3000
yarn.resourcemanager.monitor.capacity.preemption.max_wait_before_kill	应用发送抢占需求到停止 container（释放资源）的时间间隔，单位为毫秒。取值范围大于等于 0。 默认情况下，若 ApplicationMaster15 秒内没有终止 container，ResourceManager 等待 15 秒后会强制终止。	15000
yarn.resourcemanager.monitor.capacity.preemption.total_preemption_per_round	在一个周期内能够抢占资源的最大的比例。可使用这个值来限制从集群回收容器的速度。计算出了期望的总抢占值之后，策略会伸缩回这个限制。	0.1
yarn.resourcemanager.monitor.capacity.preemption.max_ignored_over_capacity	集群中资源总量乘以此配置项的值加上某个队列（例如队列 A）原有的资源量为资源抢占盲区。当队列 A 中的任务实际使用的资源超过该抢占盲区时，超过部分的	0

参数	描述	默认值
	资源将会被抢占。取值范围：0~1。 说明 设置的值越小越有利于资源抢占。	
yarn.resourcemanager.monitor.capacity.preemption.natural_termination_factor	设置抢占目标，Container 只会抢占所配置比例的资源。 示例，如果设置为 0.5，则在 5*“yarn.resourcemanager.monitor.capacity.preemption.max_wait_before_kill”的时间内，任务会回收所抢占资源的近 95%。即接连抢占 5 次，每次抢占待抢占资源的 0.5，呈几何收敛，每次的时间间隔为“yarn.resourcemanager.monitor.capacity.preemption.max_wait_before_kill”。取值范围：0~1。	1

23.20.2 任务优先级

操作场景

集群的资源竞争场景如下：

1. 提交两个低优先级的应用 Job 1 和 Job 2。
2. 正在运行中的 Job 1 和 Job 2 有部分 task 处于 running 状态，但由于集群或队列资源容量有限，仍有部分 task 未得到资源而处于 pending 状态。
3. 提交一个较高优先级的应用 Job 3，此时会出现如下资源分配情况：当 Job 1 和 Job 2 中 running 状态的 task 运行结束并释放资源后，Job 3 中处于 pending 状态的 task 将优先得到这部分新释放的资源。
4. Job 3 完成后，资源释放给 Job 1、Job 2 继续执行。

用户可以在 YARN 中配置任务的优先级。任务优先级是通过 ResourceManager 的调度器实现的。

操作步骤

设置参数“mapreduce.job.priority”，使用命令行接口或 API 接口设置任务优先级。

- 命令行接口。
  提交任务时，添加**“-Dmapreduce.job.priority=<*priority*>”**参数。
  <priority>可以设置为：
  - VERY_HIGH
  - HIGH
  - NORMAL
  - LOW

- VERY_LOW

- API 接口。

  用户也可以使用 API 配置对象的优先级。

  设置优先级，可通过 **Configuration.set("mapreduce.job.priority", <priority>)**或**Job.setPriority(JobPriority priority)**设置。

23.20.3 节点配置调优

操作场景

合理配置大数据集群的调度器后，还可通过调节每个节点的可用内存、CPU 资源及本地磁盘的配置进行性能调优。

具体包括以下配置项：

- 可用内存
- CPU 虚拟核数
- 物理 CPU 使用百分比
- 内存和 CPU 资源的协调
- 本地磁盘

操作步骤

若您需要对参数配置进行调整，具体操作请参考 25.1 修改集群服务配置参数。

- **可用内存**

  除了分配给操作系统、其他服务的内存外，剩余的资源应尽量分配给 YARN。通过如下配置参数进行调整。

  例如，如果一个 container 默认使用 512M，则内存使用的计算公式为：512M*container 数。

  默认情况下，Map 或 Reduce container 会使用 1 个虚拟 CPU 内核和 1024MB 内存，ApplicationMaster 使用 1536MB 内存。

参数	描述	默认值
yarn.nodemanager.resource.memory-mb	设置可分配给容器的物理内存数量。 单位：MB，取值范围大于 0。 建议配置成节点物理内存总量的 75%~90%。若该节点有其他业务的常驻进程，请降低此参数值给该进程预留足够运行资源。	16384

- **CPU 虚拟核数**

  建议将此配置设定在逻辑核数的 1.5～2 倍之间。如果上层计算应用对 CPU 的计算能力要求不高，可以配置为 2 倍的逻辑 CPU。

参数	描述	默认值
yarn.nodemanager.resource.cpu-vcores	表示该节点上 YARN 可使用的虚拟 CPU 个数，默认是 8。 目前推荐将该值设值为逻辑 CPU 核数的 1.5～2 倍之间。	8

- **物理 CPU 使用百分比**

  建议预留适量的 CPU 给操作系统和其他进程（数据库、HBase 等）外，剩余的 CPU 核都分配给 YARN。可以通过如下配置参数进行调整。

参数	描述	默认值
yarn.nodemanager.resource.percentage-physical-cpu-limit	表示该节点上 YARN 可使用的物理 CPU 百分比。默认是 90，即不进行 CPU 控制，YARN 可以使用节点全部 CPU。该参数只支持查看，可通过调整 YARN 的 RES_CPUSET_PERCENTAGE 参数来修改本参数值。注意，目前推荐将该值设为可供 YARN 集群使用的 CPU 百分数。 例如：当前节点除了 YARN 服务外的其他服务（如 HBase、HDFS、Hive 等）及系统进程使用 CPU 为 20%左右，则可以供 YARN 调度的 CPU 为 1-20%=80%，即配置此参数为 80。	90

- **本地磁盘**

  由于本地磁盘会提供给 MapReduce 写 job 执行的中间结果，数据量大。因此配置的原则是磁盘尽量多，且磁盘空间尽量大，单个达到百 GB 以上规模更合适。简单的做法是配置和 data node 相同的磁盘，只在最下一级目录上不同即可。

  说明

  多个磁盘之间使用逗号隔开。

参数	描述	默认值
yarn.nodemanager.log-dirs	日志存放地址（可配置多个目录）。 容器日志的存储位置。默认值为%{@auto.detect.datapart.nm.logs}。如果有数据分区，基于该数据分区生成一个类似 /srv/BigData/hadoop/data1/nm/containerlogs,/srv/BigData/hadoop/data2/nm/containerlogs 的路径清单。如果没有数据分	%{@auto.detect.datapart.nm.logs}

参数	描述	默认值
	区，生成默认路径/srv/BigData/yarn/data1/nm/containerlogs。除了使用表达式以外，还可以输入完整的路径清单，比如/srv/BigData/yarn/data1/nm/containerlogs 或/srv/BigData/yarn/data1/nm/containerlogs,/srv/BigData/yarn/data2/nm/containerlogs。这样数据就会存储在所有设置的目录中，一般会是在不同的设备中。为保证磁盘 IO 负载均衡，需要提供几个路径且每个路径都对应一个单独的磁盘。应用程序的本地化后的日志目录存在于相对路径/application_%{appid}中。单独容器的日志目录，即 container_{$contid}，是该路径下的子目录。每个容器目录都含容器生成的 stderr、stdin 及 syslog 文件。要新增目录，比如新增/srv/BigData/yarn/data2/nm/containerlogs 目录，应首先删除/srv/BigData/yarn/data2/nm/containerlogs 下的文件。之后，为/srv/BigData/yarn/data2/nm/containerlogs 赋予跟/srv/BigData/yarn/data1/nm/containerlogs 一样的读写权限，再将/srv/BigData/yarn/data1/nm/containerlogs 修改为/srv/BigData/yarn/data1/nm/containerlogs,/srv/BigData/yarn/data2/nm/containerlogs。可以新增目录，但不要修改或删除现有目录。否则，NodeManager 的数据将丢失，且服务将不可用。 【默认值】%{@auto.detect.datapart.nm.logs} 【注意】请谨慎修改该项。如果配置不当，将造成服务不可用。当角色级别的该配置项修改后，所有实例级别的该配置项都将被修改。如果实例级别的配置项修改后，其他实例的该配置项的值保持不变。	
yarn.nodemanager.local-dirs	本地化后的文件的存储位置。默认值为%{@auto.detect.datapart.nm.localdir}。如果有数据分区，基于该数据分区生成一个类似/srv/BigData/hadoop/data1/nm/localdir,/s	%{@auto.detect.datapart.nm.localdir}

参数	描述	默认值
	rv/BigData/hadoop/data2/nm/localdir 的路径清单。如果没有数据分区，生成默认路径 /srv/BigData/yarn/data1/nm/localdir。除了使用表达式以外，还可以输入完整的路径清单，比如 /srv/BigData/yarn/data1/nm/localdir 或 /srv/BigData/yarn/data1/nm/localdir,/srv/BigData/yarn/data2/nm/localdir。这样数据就会存储在所有设置的目录中，一般会是在不同的设备中。为保证磁盘 IO 负载均衡，需要提供几个路径且每个路径都对应一个单独的磁盘。应用程序的本地化后的文件目录存在于相对路径 /usercache/%{user}/appcache/application_%{appid}中。单独容器的工作目录，即 container_%{contid}，是该路径下的子目录。要新增目录，比如新增 /srv/BigData/yarn/data2/nm/localdir 目录，应首先删除 /srv/BigData/yarn/data2/nm/localdir 下的文件。之后，为 /srv/BigData/hadoop/data2/nm/localdir 赋予跟 /srv/BigData/hadoop/data1/nm/localdir 一样的读写权限，再将 /srv/BigData/yarn/data1/nm/localdir 修改为 /srv/BigData/yarn/data1/nm/localdir,/srv/BigData/yarn/data2/nm/localdir。可以新增目录，但不要修改或删除现有目录。否则，NodeManager 的数据将丢失，且服务将不可用。 【默认值】%{@auto.detect.datapart.nm.localdir} 【注意】请谨慎修改该项。如果配置不当，将造成服务不可用。当角色级别的该配置项修改后，所有实例级别的该配置项都将被修改。如果实例级别的配置项修改后，其他实例的该配置项的值保持不变。	

23.21 Yarn 常见问题

23.21.1 任务完成后 Container 挂载的文件目录未清除

问题

使用了 CGroups 功能的场景下，任务完成后 Container 挂载的文件目录未清除。

回答

即使任务失败，Container 挂载的目录也应该被清除。

上述问题是由于删除动作超时导致的。完成某些任务所使用的时间已远超过删除时间。

为避免出现这种场景，您可以参考 25.1 修改集群服务配置参数，进入 Yarn“全部配置”页面。在搜索框搜索“yarn.nodemanager.linux-container-executor.cgroups.delete-timeout-ms”配置项来修改删除时间的时长。参数值的单位为毫秒。

23.21.2 作业执行失败时会抛出 HDFS_DELEGATION_TOKEN 到期的异常

问题

安全模式下，为什么作业执行失败时会抛出 HDFS_DELEGATION_TOKEN 到期的异常？

回答

HDFS_DELEGATION_TOKEN 到期的异常是由于 token 没有更新或者超出了最大生命周期。

在 token 的最大生命周期内确保下面的参数值大于作业的运行时间。

“dfs.namenode.delegation.token.max-lifetime”=“604800000”（默认是一星期）

参考 25.1 修改集群服务配置参数，进入 HDFS“全部配置”页面，在搜索框搜索该参数。

说明

建议在 token 的最大生命周期内参数值为多倍小时数。

23.21.3 重启 YARN，本地日志不被删除

问题

在以下两种情况下重启 YARN，本地日志不会被定时删除，将被永久保留。

- 在任务运行过程中，重启 YARN，本地日志不被删除。

- 在任务完成，日志归集失败后定时清除日志前，重启 YARN，本地日志不被删除。

回答

NodeManager 有重启恢复机制

可以参考 25.1 修改集群服务配置参数，进入 Yarn“全部配置”页面。需将 NodeManager 的“yarn.nodemanager.recovery.enabled”配置项为“true”后才生效，默认为“true”，这样在 YARN 重启的异常场景时会定时删除多余的本地日志，避免问题的出现。

23.21.4 为什么执行任务时 AppAttempts 重试次数超过 2 次还没有运行失败

问题

系统默认的 AppAttempts 运行失败的次数为 2，为什么在执行任务时，AppAttempts 重试次数超过 2 次还没有运行失败？

回答

在执行任务过程中，若 ContainerExitStatus 的返回值为 ABORTED、PREEMPTED、DISKS_FAILED、KILLED_BY_RESOURCEMANAGER 这四种状态之一时，系统不会将其计入 failed attempts 中，因此出现上面的问题，只有当真正失败尝试 2 次之后才会运行失败。

23.21.5 为什么在 ResourceManager 重启后，应用程序会移回原来的队列

问题

将应用程序从一个队列移到另一个队列时，为什么在 RM（ResourceManager）重启后，应用程序会被移回原来的队列？

回答

这是 RM 的使用限制，应用程序运行过程中移动到别的队列，此时 RM 重启，RM 并不会在状态存储中存储新队列的信息。

假设用户提交一个 MR 任务到叶子队列 test11 上。当任务运行时，删除叶子队列 test11，这时提交队列自动变为 lost_and_found 队列（找不到队列的任务会被放入 lost_and_found 队列中），任务暂停运行。要启动该任务，用户将任务移动到叶子队列 test21 上。在将任务移动到叶子队列 test21 后，任务继续运行，此时 RM 重启，重启后显示提交队列为 lost_and_found 队列，而不是 test21 队列。

发生上述情况的原因是，任务未完成时，RM 状态存储中存储的还是应用程序移动前的队列状态。唯一的解决办法就是等 RM 重启后，再次移动应用程序，将新的队列状态信息写入状态存储中。

23.21.6 为什么 YARN 资源池的所有节点都被加入黑名单，而 YARN 却没有释放黑名单，导致任务一直处于运行状态

问题

为什么 YARN 资源池的所有节点都被加入黑名单，而 YARN 却没有释放黑名单，导致任务一直处于运行状态？

回答

在 YARN 中，当一个 APP 的节点被 AM（ApplicationMaster）加入黑名单的数量达到一定比例（默认值为节点总数的 33%）时，该 AM 会自动释放黑名单，从而不会出现由于所有可用节点都被加入黑名单而任务无法获取节点资源的现象。

在资源池场景下，假设该集群上有 8 个节点，通过 NodeLabel 特性将集群划分为两个资源池，pool A 和 pool B，其中 pool B 包含两个节点。用户提交了一个任务 App1 到 pool B，由于 HDFS 空间不足，App1 运行失败，导致 pool B 的两个节点都被 App1 的 AM 加入了黑名单，根据上述原则，2 个节点小于 8 个节点的 33%，所以 YARN 不会释放黑名单，使得 App1 一直无法得到资源而保持运行状态，后续即使被加入黑名单的节点恢复，App1 也无法得到资源。

由于上述原则不适用于资源池场景，所以目前可通过调整客户端参数（路径为“*客户端安装路径*/Yarn/config/yarn-site.xml”）“yarn.resourcemanager.am-scheduling.node-blacklisting-disable-threshold”为：(nodes number of pool / total nodes)* 33%解决该问题。

23.21.7 ResourceManager 持续主备倒换

问题

RM（ResourceManager）在多个任务（比如 2000 个任务）正常并发运行时出现持续的主备倒换，导致 YARN 服务不可用。

回答

产生上述问题的原因是，full GC（GabageCollection）时间过长，超出了 RM 与 ZK（ZooKeeper）之间定期交互时长的阈值，导致 RM 与 ZK 失联，从而造成 RM 主备倒换。

在多任务情况下，RM 需要保存多个任务的鉴权信息，并通过心跳传递给各个 NM（NodeManager），即心跳 Response。心跳 Response 的生命周期短，默认值为 1s，一般可以在 JVM minor GC 时被回收，但在多任务的情况下，集群规模较大，比如 5000 节点，多个节点的心跳 Response 会占用大量内存，导致 JVM 在 minor GC 时无法完全回收，无法回收的内存持续累积，最终触发 JVM 的 full GC。JVM 的 GC 都是阻塞式的，即在 GC 过程中不执行任何作业，所以若 full GC 的时间过长，超出了 RM 与 ZK 之间定期交互时长的阈值，就会出现主备倒换。

登录 FusionInsight Manager，选择“集群 > 服务 > Yarn > 配置 > 全部配置”，在左侧选择“Yarn > 自定义”，在“yarn.yarn-site.customized.configs”中添加

“yarn.resourcemanager.zk-timeout-ms”参数来增大 RM 与 ZK 之间定期交互时长的阈值（参数值的范围为小于等于 90000 毫秒），可以解决 RM 持续主备倒换的问题。

23.21.8 当一个 NodeManager 处于 unhealthy 的状态 10 分钟时，新应用程序失败

问题

当一个 NM（NodeManager）处于 unhealthy 的状态 10 分钟时，新应用程序失败。

回答

当 nodeSelectPolicy 为 SEQUENCE，且第一个连接到 RM 的 NM 不可用时，RM 会在“yarn.nm.liveness-monitor.expiry-interval-ms”属性中指定的周期内，一直尝试为同一个 NM 分配任务。

可以通过两种方式来避免上述问题：

- 使用其他的 nodeSelectPolicy，如 RANDOM。
- 参考 25.1 修改集群服务配置参数，进入 Yarn“全部配置”页面。在搜索框搜索以下参数，通过“yarn-site.xml”文件更改以下属性：

  “yarn.resourcemanager.am-scheduling.node-blacklisting-enabled” = “true”；

  “yarn.resourcemanager.am-scheduling.node-blacklisting-disable-threshold” = “0.5”。

23.21.9 Superior 通过 REST 接口查看已结束或不存在的 applicationID，返回的页面提示 Error Occurred

问题

Superior 通过 REST 接口查看已结束或不存在的 applicationID，返回的页面提示 Error Occurred。

回答

用户提交查看 applicationID 的请求，访问 REST 接口“https://<SS_REST_SERVER>/ws/v1/sscheduler/applications/{application_id}”。

由于 Superior Scheduler 只存储正在运行的 applicationID，所以当查看的是已结束或不存在的 applicationID，服务器会响应给浏览器“404”的状态码。但是由于 chrome 浏览器访问该 REST 接口时，优先以“application/xml”的格式响应，该行为会导致服务器端处理出现异常，所以返回的页面会提示“Error Occurred”。而 IE 浏览器访问该 REST 接口时，优先以“application/json”的格式响应，服务器会正确响应给浏览器“404”的状态码。

23.21.10 Superior 调度模式下，单个 NodeManager 故障可能导致 MapReduce 任务失败

问题

在 Superior 调度模式下，如果出现单个 NodeManager 故障，可能会导致 Mapreduce 任务失败。

回答

正常情况下 ，当一个 application 的单个 task 的 attempt 连续在一个节点上失败 3 次，那么该 application 的 AppMaster 就会将该节点加入黑名单，之后 AppMaster 就会通知调度器不要继续调度 task 到该节点，从而避免任务失败。

但是默认情况下，当集群中有 33%的节点都被加入黑名单时，调度器会忽略黑名单节点。因此，该黑名单特性在小集群场景下容易失效。比如，集群只有 3 个节点，当 1 个节点出现故障，黑名单机制失效，不管 task 的 attempt 在同一个节点失败多少次，调度器仍然会将 task 继续调度到该节点，从而导致 application 因为 task 失败达到最大 attempt 次数（MapReduce 默认 4 次）而失败。

规避手段：

在“*客户端安装路径*/Yarn/config/yarn-site.xml”文件中修改“yarn.resourcemanager.am-scheduling.node-blacklisting-disable-threshold”参数以百分比的形式配置忽略黑名单节点的阈值。建议根据集群规模，适当增大该参数的值，如 3 个节点的集群， 建议增大到 50%。

说明

Superior 调度器的框架设计是基于时间的异步调度，当 NodeManager 故障后，ResourceManager 无法快速的感知到 NodeManager 已经出了问题(默认 10mins)，因此在此期间，Superior 调度器仍然会向该节点调度 task，从而导致任务失败。

23.21.11 当应用程序从 lost_and_found 队列移动到其他队列时，应用程序不能继续执行

问题

当删除一个有部分应用程序正在运行的队列，这些应用程序会被移动到“lost_and_found”队列上。当这些应用程序移回运行正常的队列时，某些任务会被挂起，不能正常运行。

回答

如果应用程序没有设置标签表达式，那么该应用程序上新增的 container/resource 将使用其所在队列默认的标签表达式。如果队列没有默认的标签表达式，则将其标签表达设置为“default label”。

当应用程序（app1）提交到队列（Q1）上时，应用程序上新增的 container/resource 使用队列默认的标签表达式（“label1”）。若 app1 正在运行时 Q1 被删除，则 app1 被移动

到“lost_and_found”队列上。由于“lost_and_found”队列没有标签表达式，其标签表达式设置为“default label”，此时 app1 上新增的 container/resource 也将其标签表达式设置为“default label”。当 app1 被移回正常运行的队列（例如，Q2）时，如果 Q2 支持调用 app1 中的所有标签表达式（包含“label1”和“default label”），则 app1 能正常运行直到结束；如果 Q2 仅支持调用 app1 中的部分标签表达式（例如，仅支持调用“default label”），那么 app1 在运行时，拥有“label1”标签表达式的部分任务的资源请求将无法获得资源，从而被挂起，不能正常运行。

因此当把应用程序从“lost_and_found”队列移动到其他运行正常的队列上时，需要保证目标队列能够调用该应用程序的所有标签表达式。

建议不要删除正在运行应用程序的队列。

23.21.12 如何限制存储在 ZKstore 中的应用程序诊断消息的大小

问题

如何限制存储在 ZKstore 中的应用程序诊断消息的大小？

回答

在某些情况下，已经观察到诊断消息可能无限增长。由于诊断消息存储在状态存储中，不建议允许诊断消息无限增长。因此，需要有一个属性参数用于设置诊断消息的最大大小。

若您需要设置“yarn.app.attempt.diagnostics.limit.kc”参数值，具体操作参考 25.1 修改集群服务配置参数，进入 Yarn“全部配置”页面，在搜索框搜索以下参数。

表23-25 参数描述

参数	描述	默认值
yarn.app.attempt.diagnostics.limit.kc	定义每次应用连接的诊断消息的数据大小，以千字节为单位（字符数*1024）。当使用 ZooKeeper 来存储应用程序的行为状态时，需要限制诊断消息的大小，以防止 YARN 拖垮 ZooKeeper。如果将“yarn.resourcemanager.state-store.max-completed-applications”设置为一个较大的数值，则需要减小该属性参数的值以限制存储的总数据大小。	64

23.21.13 为什么将非 ViewFS 文件系统配置为 ViewFS 时 MapReduce 作业运行失败

问题

为什么将非 ViewFS 文件系统配置为 ViewFS 时 MR 作业运行失败？

回答

通过集群将非 ViewFS 文件系统配置为 ViewFS 时，ViewFS 中的文件夹的用户权限与默认 NameService 中的非 ViewFS 不同。因为目录权限不匹配，所以已提交的 MR 作业运行失败。

在集群中配置 ViewFS 的用户，需要检查并校验目录权限。在提交作业之前，应按照默认的 NameService 文件夹权限更改 ViewFS 文件夹权限。

下表列出了 ViewFS 中配置的目录的默认权限结构。如果配置的目录权限与下表不匹配，则必须相应地更改目录权限。

表23-26 ViewFS 中配置的目录的默认权限结构

参数	描述	默认值	默认值及其父目录的默认权限
yarn.nodemanager.remote-app-log-dir	在默认文件系统上（通常是 HDFS），指定 NM 应将日志聚合到哪个目录。	logs	777
yarn.nodemanager.remote-app-log-archive-dir	将日志归档的目录。	-	777
yarn.app.mapreduce.am.staging-dir	提交作业时使用的 staging 目录。	/tmp/hadoop-yarn/staging	777
mapreduce.jobhistory.intermediate-done-dir	MapReduce 作业记录历史文件的目录。	${yarn.app.mapreduce.am.staging-dir}/history/done_intermediate	777
mapreduce.jobhistory.done-dir	由 MR JobHistory Server 管理的历史文件的目录。	${yarn.app.mapreduce.am.staging-dir}/history/done	777

23.21.14 开启 Native Task 特性后，Reduce 任务在部分操作系统运行失败

问题

开启 Native Task 特性后，Reduce 任务在部分操作系统运行失败。

回答

运行包含 Reduce 的 Mapreduce 任务时，通过-Dmapreduce.job.map.output.collector.class=org.apache.hadoop.mapred.nativetask.NativeMapOutputCollectorDelegator 命令开启 Native Task 特性，任务在部分操作系统运行失败，

日志中提示错误“version 'GLIBCXX_3.4.20' not found”。该问题原因是操作系统的GLIBCXX 版本较低，导致该特性依赖的 libnativetask.so.1.0.0 库无法加载，进而导致任务失败。

规避手段：

设置配置项 mapreduce.job.map.output.collector.class 的值为org.apache.hadoop.mapred.MapTask$MapOutputBuffer。

24 使用 ZooKeeper

24.1 从零开始使用 Zookeeper

Zookeeper 是一个开源的，高可靠的，分布式一致性协调服务。Zookeeper 设计目标是用来解决那些复杂，易出错的分布式系统难以保证数据一致性的。不必开发专门的协同应用，十分适合高可用服务保持数据一致性。

背景信息

在使用客户端前，除主管理节点以外的客户端，需要下载并更新客户端配置文件。

操作步骤

下载客户端配置文件。

1. 登录 FusionInsight Manager 页面，具体请参见 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）。
   - MRS 3.3.0 之前版本：选择“集群 > 概览 > 更多 > 下载客户端”。
   - MRS 3.3.0 及之后版本：在主页右上方单击“下载客户端”。
2. 下载集群客户端。

   “选择客户端类型”选择“仅配置文件”，选择平台类型，单击“确定”开始生成客户端配置文件，文件生成后默认保存在主管理节点“/tmp/FusionInsight-Client/”。

步骤 1 登录 Manager 的主管理节点。

1. 以 **root** 用户登录任意部署 Manager 的节点。
2. 执行以下命令确认主备管理节点。

   sh ${BIGDATA_HOME}/om-server/om/sbin/status-oms.sh

   界面打印信息中“HAActive”参数值为“active”的节点为主管理节点（如下例中“node-master1”为主管理节点），参数值为“standby”的节点为备管理节点（如下例中“node-master2”为备管理节点）。

```
HAMode
double
NodeName            HostName        HAVersion         StartTime
```

```
HAActive            HAAllResOK          HARunPhase
192-168-0-30        node-master1    V100R001C01       2020-05-01 23:43:02
active              normal              Actived
192-168-0-24        node-master2    V100R001C01       2020-05-01 07:14:02
standby             normal              Deactived
```

3. 以 **root** 用户登录主管理节点，并执行以下命令切换到 **omm** 用户。

   sudo su - omm

步骤 2 执行以下命令切换到客户端安装目录。例如“/opt/client”。

cd /opt/client

步骤 3 执行以下命令，更新主管理节点的客户端配置。

sh refreshConfig.sh /opt/client *客户端配置文件压缩包完整路径*

例如，执行命令：

sh refreshConfig.sh /opt/client /tmp/FusionInsight-Client/FusionInsight_Cluster_1_Services_Client.tar

界面显示以下信息表示配置刷新更新成功：

```
ReFresh components client config is complete.
Succeed to refresh components client config.
```

在 Master 节点使用客户端。

1. 在已更新客户端的主管理节点，例如“192-168-0-30”节点，执行以下命令切换到客户端目录。

   cd /opt/client

2. 执行以下命令配置环境变量。

   source bigdata_env

3. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

   kinit MRS 集群用户

   例如，**kinit zookeeperuser**。

4. 直接执行 Zookeeper 组件的客户端命令。

   zkCli.sh -server <zookeeper 安装节点 ip>:<port>

   例如：**zkCli.sh -server node-master1DGhZ:2181**

   说明

   <port>可在 ZooKeeper 的全部配置参数中搜索“*clientPort*”查看。默认端口如下：

   - 开源端口默认值为：2181
   - 定制端口默认值为：24002

   端口定制/开源区分：创建 LTS 版本类型集群时，可以选择“组件端口”为“开源”或是“定制”，选择“开源”使用开源端口，选择“定制”使用定制端口。

步骤 4 运行 Zookeeper 客户端命令。

1. 创建 ZNode。

```
create /test
```

2. 查看 ZNode 信息。

```
ls /
```

3. 向 ZNode 中写入数据。

```
set /test "zookeeper test"
```

4. 查看写入 ZNode 中的数据。

```
get /test
```

5. 删除创建的 ZNode。

```
delete /test
```

----结束

24.2 ZooKeeper 常用参数

参数入口：

请参考 25.1 修改集群服务配置参数，进入 ZooKeeper“全部配置”页面。在搜索框中输入参数名称。

表24-1 参数说明

配置参数	说明	默认值
skipACL	是否跳过 ZooKeeper 节点的权限检查。	no
maxClientCnxns	ZooKeeper 的最大连接数，在连接数多的情况下，建议增加。	2000
LOG_LEVEL	日志级别，在调试的时候，可以改为 DEBUG。	INFO
acl.compare.shortName	当 Znode 的 ACL 权限认证类型为 SASL 时，是否仅使用 principal 的用户名部分进行 ACL 权限认证。	true
synclimit	Follower 与 leader 进行同步的时间间隔（单位为 tick）。如果在指定的时间内 leader 没响应，连接将不能被建立。	15
tickTime	一次 tick 的时间（毫秒），它是 ZooKeeper 使用的基本时间单位，心跳、超时的时间都由它来规定。	4000

说明

ZooKeeper 内部时间由参数 ticktime 和参数 synclimit 控制，如需调大 ZooKeeper 内部超时时间，需要调大客户端连接 ZooKeeper 的超时时间。

24.3 使用 ZooKeeper 客户端

操作场景

该任务指导用户在运维场景或业务场景中使用 ZooKeeper 客户端。

前提条件

已安装客户端。例如安装目录为“/opt/client”，以下操作的客户端目录只是举例，请根据实际安装目录修改。

操作步骤

以客户端安装用户，登录安装客户端的节点。

步骤 1 执行以下命令，切换到客户端安装目录。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 执行以下命令进行用户认证。(普通模式跳过此步骤)

kinit *组件业务用户*

步骤 4 执行以下命令登录客户端工具。

zkCli.sh -server *ZooKeeper 角色实例所在节点业务 IP: clientPort*

----结束

24.4 ZooKeeper 权限设置指南

操作场景

该操作指导用户对 ZooKeeper 的 znode 设置权限。

ZooKeeper 通过访问控制列表（ACL）来对 znode 进行访问控制。ZooKeeper 客户端为 znode 指定 ACL，ZooKeeper 服务器根据 ACL 列表判定某个请求 znode 的客户端是否有对应操作的权限。ACL 设置涉及如下四个方面。

- 查看 ZooKeeper 中 znode 的 ACL。

- 增加 ZooKeeper 中 znode 的 ACL。
- 修改 ZooKeeper 中 znode 的 ACL。
- 删除 ZooKeeper 中 znode 的 ACL。

  ZooKeeper 的 ACL 权限说明：

  ZooKeeper 目前支持 create，delete，read，write，admin 五种权限，且 ZooKeeper 对权限的控制是 znode 级别的，而且不继承，即对父 znode 设置权限，其子 znode 不继承父 znode 的权限。ZooKeeper 中 znode 的默认权限为 **world:anyone:cdrwa**，即任何用户都有所有权限。

说明

ACL 有三部分：

第一部分是认证类型，如 world 指所有认证类型，sasl 是 kerberos 认证类型；

第二部分是账号，如 anyone 指的是任何人；

第三部分是权限，如 cdrwa 指的是拥有所有权限。

特别的，由于普通模式启动客户端不需要认证，sasl 认证类型的 ACL 在普通模式下将不能使用。本文所有涉及 sasl 方式的鉴权操作均是在安全集群中进行。

表24-2 Zookeeper 的五种 ACL

权限说明	权限简称	权限详情
创建权限	create(c)	可以在当前 znode 下创建子 znode
删除权限	delete(d)	删除当前的 znode
读权限	read(r)	获取当前 znode 的数据，可以列出当前 znode 所有的子 znodes
写权限	write(w)	向当前 znode 写数据，写入子 znode
管理权限	admin(a)	设置当前 znode 的权限

对系统的影响

须知

修改 ZooKeeper 的 ACL 是高危操作。修改 ZooKeeper 中 znode 的权限，可能会导致其他用户无权限访问该 znode，导致系统功能异常。另外在 3.5.6 及以后版本，用户对于 getAcl 操作需要有读权限。

前提条件

- 已安装 ZooKeeper 客户端。例如安装目录为“/opt/client”。
- 已获取 MRS 集群管理员用户和密码。

操作步骤

启动 ZooKeeper 客户端

以 **root** 用户登录安装了 ZooKeeper 客户端的服务器。

步骤 1 进入客户端安装目录。

cd /opt/client

步骤 2 执行以下命令配置环境变量。

source bigdata_env

步骤 3 执行以下命令认证用户身份，并输入用户密码（任意有权限的用户，这里以 userA 为例，普通模式不涉及）。

kinit userA

步骤 4 在 ZooKeeper 客户端执行以下命令，进入 ZooKeeper 命令行。

sh zkCli.sh -server *ZooKeeper 任意实例所在节点业务平面 IP:clientPort*

默认的“clientPort”为“2181”

例如：**sh zkCli.sh -server 192.168.0.151:2181**

步骤 5 登录 ZooKeeper 客户端后，使用 **ls** 命令，可以查看 ZooKeeper 中的 znode 列表。例如，可以查看根目录 znode 列表。

ls /

```
[zk: 192.168.0.151:2181(CONNECTED) 1] ls /
[hadoop-flag, hadoop-ha, test, test2, test3, test4, test5, test6, zookeeper]
```

查看 ZooKeeper znode ACL 信息

启动 ZooKeeper 客户端。

步骤 6 使用 **getAcl** 命令，可以查看 znode。如下命令，可以查看到之前创建的名为 test 的 znode 的 ACL 权限。

getAcl */znode 名称*

```
[zk: 192.168.0.151:2181(CONNECTED) 2] getAcl /test
'world,'anyone
: cdrwa
```

增加 ZooKeeper znode ACL 信息

启动 ZooKeeper 客户端。

步骤 7 查看旧的 ACL 信息，查看当前账号是否有权限修改该 znode 的 ACL 信息的权限（a 权限），如果没有权限，需要 kinit 登录有权限的用户，并重新启动 ZooKeeper 客户端。

getAcl */znode 名称*

```
 [zk: 192.168.0.151:2181(CONNECTED) 3] getAcl /test
'world,'anyone
: cdrwa
```

步骤 8 使用 **setAcl** 命令增加权限。设置新权限命令如下：

setAcl /test world:anyone:cdrwa,sasl:*用户名@<系统域名>:权限值*

例如对 test 的 znode，需要增加 userA 用户的权限：

setAcl /test world:anyone:cdrwa,sasl:userA@HADOOP.COM:cdrwa

说明

增加权限时，需要保留已有权限。新增加权限和旧的权限用英文逗号隔开，新增加权限有三个部分：

- 第一部分是认证类型，如 sasl 指使用 kerberos 认证；
- 第二部分是账号，如 userA@HADOOP.COM 指的是 userA 用户；
- 第三部分是权限，如 cdrwa 指的是拥有所有权限。

步骤 9 setAcl 后，可以使用 **getAcl** 命令查看增加权限是否成功：

getAcl */znode 名称*

```
[zk: 192.168.0.151:2181(CONNECTED) 4] getAcl /test
'world,'anyone
: cdrwa
'sasl,'userA@<系统域名>
: cdrwa
```

修改 ZooKeeper znode ACL 信息

启动 ZooKeeper 客户端。

步骤 10 查看旧的 ACL 信息，查看当前账号是否有权限修改该 znode 的 ACL 信息的权限（a 权限），如果没有权限，需要 kinit 登录有权限的用户，并重新启动 ZooKeeper 客户端。

getAcl */znode 名称*

```
[zk: 192.168.0.151:2181(CONNECTED) 5] getAcl /test
'world,'anyone
: cdrwa
'sasl,'userA@<系统域名>
: cdrwa
```

步骤 11 使用 **setAcl** 命令修改权限。设置新权限命令如下：

setAcl /test sasl:*用户名@<系统域名>:权限值*

例如仅保留 userA 用户的所有权限，删除 anyone 用户的 rw 权限。

setAcl /test sasl:userA@HADOOP.COM:cdrwa

步骤 12 setAcl 后，可以使用 **getAcl** 命令查看修改权限是否成功：

getAcl */znode 名称*

```
[zk: 192.168.0.151:2181(CONNECTED) 6] getAcl /test
'sasl,'userA@<系统域名>
: cdrwa
```

删除 ZooKeeper znode ACL 信息

启动 ZooKeeper 客户端。

步骤 13 查看旧的 ACL 信息，查看当前账号是否有权限修改该 znode 的 ACL 信息的权限（a 权限），如果没有权限，需要 kinit 登录有权限的用户，并重新启动 ZooKeeper 客户端。

getAcl */znode 名称*

```
[zk: 192.168.0.151:2181(CONNECTED) 5] getAcl /test
'world,'anyone
: rw
'sasl,'userA@<系统域名>
: cdrwa
```

步骤 14 使用 **setAcl** 命令增加权限。设置新权限命令如下：

setAcl /test sasl:*用户名@<系统域名>:权限值*

例如，仅保留 userA 用户是所有权限，取消 anyone 用户的 rw 权限。

setAcl /test sasl:userA@HADOOP.COM:cdrwa

步骤 15 setAcl 后，可以使用 **getAcl** 命令查看修改权限是否成功

getAcl */znode 名称*

```
[zk: 192.168.0.151:2181(CONNECTED) 6] getAcl /test
'sasl,'userA@<系统域名>
: cdrwa
```

----结束

24.5 ZooKeeper 日志介绍

日志描述

日志存储路径：“/var/log/Bigdata/zookeeper/quorumpeer”（运行日志），“/var/log/Bigdata/audit/zookeeper/quorumpeer”（审计日志）

日志归档规则：ZooKeeper 的日志启动了自动压缩归档功能，缺省情况下，当日志大小超过 30MB 的时候，会自动压缩。最多保留 20 个压缩文件，压缩文件保留个数可以在 Manager 界面中配置。

表24-3 ZooKeeper 日志列表

日志类型	日志文件名	描述
运行日志	zookeeper-<SSH_USER>-<process_name>-<hostname>.log	ZooKeeper 系统日志，记录 ZooKeeper 系统运行时候所产生的大部分日志。
	check-serviceDetail.log	ZooKeeper 服务启动是否成功的检查日志。
	zookeeper-<SSH_USER>-<DATA>-<PID>-gc.log	ZooKeeper 垃圾回收日志。

日志类型	日志文件名	描述
	instanceHealthDetail.log	ZooKeeper 实例健康状态检查日志
	zookeeper-omm-server-<hostname>.out	ZooKeeper 运行异常退出日志。
	zk-err-<zkpid>.log	ZooKeeper 致命错误日志。
	java_pid<zkpid>.hprof	ZooKeeper 内存溢出日志。
	funcDetail.log	ZooKeeper 实例启动日志。
	zookeeper-period-check.log	ZooKeeper 实例健康检查日志。
	zookeeper-period-check-java.log	ZooKeeper 配额监控周期检查日志。
审计日志	zk-audit-quorumpeer.log	ZooKeeper 操作审计日志。

日志级别

ZooKeeper 中提供了如表 24-4 所示的日志级别。日志级别优先级从高到低分别是 FATAL、ERROR、WARN、INFO、DEBUG。程序会打印高于或等于所设置级别的日志，设置的日志等级越高，打印出来的日志就越少。

表24-4 日志级别

级别	描述
FATAL	FATAL 表示当前事件处理出现严重错误信息，可能导致系统崩溃。
ERROR	ERROR 表示当前事件处理出现错误信息，系统运行出错。
WARN	WARN 表示当前事件处理存在异常信息，但认为是正常范围，不会导致系统出错。
INFO	INFO 表示系统及各事件正常运行状态信息。
DEBUG	DEBUG 表示系统及系统的调试信息。

如果您需要修改日志级别，请执行如下操作：

参考 25.1 修改集群服务配置参数章节，进入 ZooKeeper 服务“全部配置”页面。

步骤 2 左边菜单栏中选择所需修改的角色所对应的日志菜单。

步骤 3 选择所需修改的日志级别。

步骤 4 单击“保存”，在弹出窗口中单击“确定”使配置生效。

说明

配置完成后立即生效，不需要重启服务。

----结束

日志格式

ZooKeeper 的日志格式如下所示：

表24-5 日志格式

日志类型	组件	格式	示例
运行日志	zookeeper quorumpeer	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的message>|<日志事件的发生位置>	2020-01-20 16:33:43,816 | INFO | main | Defaulting to majority quorums | org.apache.zookeeper.server.quorum.QuorumPeerConfig.parseProperties(QuorumPeerConfig.java:335)
审计日志	zookeeper quorumpeer	<yyyy-MM-dd HH:mm:ss,SSS>|<Log Level>|<产生该日志的线程名字>|<log 中的message>|<日志事件的发生位置>	2020-01-20 16:33:54,313 | INFO | CommitProcessor:13 | session=0xd4b0679daea0000 ip=10.177.112.145 operation=create znode target=ZooKeeperServer znode=/zk-write-test-2 result=success | org.apache.zookeeper.ZKAuditLogger$LogLevel$5.printLog(ZKAuditLogger.java:70)

24.6 ZooKeeper 常见问题

24.6.1 创建大量 znode 后，ZooKeeper Sever 启动失败

问题

创建大量 znode 后，ZooKeeper 集群处于故障状态不能自动恢复，尝试重启失败，ZooKeeper server 日志显示如下内容：

follower：

```
2016-06-23 08:00:18,763 | WARN  |
QuorumPeer[myid=26](plain=/10.16.9.138:2181)(secure=disabled) | Exception when
following the leader |
org.apache.zookeeper.server.quorum.Follower.followLeader(Follower.java:93)
java.net.SocketTimeoutException: Read timed out
    at java.net.SocketInputStream.socketRead0(Native Method)
    at java.net.SocketInputStream.socketRead(SocketInputStream.java:116)
    at java.net.SocketInputStream.read(SocketInputStream.java:170)
    at java.net.SocketInputStream.read(SocketInputStream.java:141)
    at java.io.BufferedInputStream.fill(BufferedInputStream.java:246)
    at java.io.BufferedInputStream.read(BufferedInputStream.java:265)
    at java.io.DataInputStream.readInt(DataInputStream.java:387)
    at org.apache.jute.BinaryInputArchive.readInt(BinaryInputArchive.java:63)
    at
org.apache.zookeeper.server.quorum.QuorumPacket.deserialize(QuorumPacket.java:83)
    at org.apache.jute.BinaryInputArchive.readRecord(BinaryInputArchive.java:99)
    at org.apache.zookeeper.server.quorum.Learner.readPacket(Learner.java:156)
    at
org.apache.zookeeper.server.quorum.Learner.registerWithLeader(Learner.java:276)
    at org.apache.zookeeper.server.quorum.Follower.followLeader(Follower.java:75)
    at org.apache.zookeeper.server.quorum.QuorumPeer.run(QuorumPeer.java:1094)
2016-06-23 08:00:18,764 | INFO  |
QuorumPeer[myid=26](plain=/10.16.9.138:2181)(secure=disabled) | shutdown called |
org.apache.zookeeper.server.quorum.Follower.shutdown(Follower.java:198)
java.lang.Exception: shutdown Follower
    at org.apache.zookeeper.server.quorum.Follower.shutdown(Follower.java:198)
    at
org.apache.zookeeper.server.quorum.QuorumPeer.stopFollower(QuorumPeer.java:1141)
    at org.apache.zookeeper.server.quorum.QuorumPeer.run(QuorumPeer.java:1098)
```

leader：

```
2016-06-23 07:30:57,481 | WARN  |
QuorumPeer[myid=25](plain=/10.16.9.136:2181)(secure=disabled) | Unexpected
exception | org.apache.zookeeper.server.quorum.QuorumPeer.run(QuorumPeer.java:1108)
java.lang.InterruptedException: Timeout while waiting for epoch to be acked by
quorum
    at org.apache.zookeeper.server.quorum.Leader.waitForEpochAck(Leader.java:1221)
    at org.apache.zookeeper.server.quorum.Leader.lead(Leader.java:487)
    at org.apache.zookeeper.server.quorum.QuorumPeer.run(QuorumPeer.java:1105)
2016-06-23 07:30:57,482 | INFO  |
QuorumPeer[myid=25](plain=/10.16.9.136:2181)(secure=disabled) | Shutdown called |
org.apache.zookeeper.server.quorum.Leader.shutdown(Leader.java:623)
```

```
java.lang.Exception: shutdown Leader! reason: Forcing shutdown
    at org.apache.zookeeper.server.quorum.Leader.shutdown(Leader.java:623)
    at  org.apache.zookeeper.server.quorum.QuorumPeer.stopLeader(QuorumPeer.java:1149)
    at org.apache.zookeeper.server.quorum.QuorumPeer.run(QuorumPeer.java:1110)
```

回答

创建大量节点后，follower 与 leader 同步时数据量大，在集群数据同步限定时间内不能完成同步过程，导致超时，各个 ZooKeeper server 启动失败。

参考 25.1 修改集群服务配置参数章节，进入 ZooKeeper 服务“全部配置”页面。不断尝试调大 ZooKeeper 配置文件“zoo.cfg”中的“syncLimit”和“initLimit”两参数值，直到 ZooKeeperServer 正常。

表24-6 参数说明

参数	描述	默认值
syncLimit	follower 与 leader 进行同步的时间间隔（时长为 ticket 时长的倍数）。如果在该时间范围内 leader 没响应，连接将不能被建立。	15
initLimit	follower 连接到 leader 并与 leader 同步的时间（时长为 ticket 时长的倍数）。	15

如果将参数“initLimit”和“syncLimit”的参数值均配置为“300”之后，ZooKeeper server 仍然无法恢复，则需确认没有其他应用程序正在 kill ZooKeeper。例如，参数值为“300”，ticket 时长为 2000 毫秒，即同步限定时间为 300*2000ms=600s。

可能存在以下场景，在 ZooKeeper 中创建的数据过大，需要大量时间与 leader 同步，并保存到硬盘。在这个过程中，如果 ZooKeeper 需要运行很长时间，则需确保没有其他监控应用程序 kill ZooKeeper 而判断其服务停止。

24.6.2 为什么 ZooKeeper Server 出现 java.io.IOException: Len 的错误日志

问题

在父目录中创建大量的 znode 之后，当 ZooKeeper 客户端尝试在单个请求中获取该父目录中的所有子节点时，将返回失败。

客户端日志，如下所示：

```
2017-07-11 13:17:19,610 [myid:] - WARN  [New I/O worker
#3:ClientCnxnSocketNetty$ZKClientHandler@468] - Exception caught: [id: 0xb66cbb85,
/10.18.97.97:49192 :> 10.18.97.97/10.18.97.97:2181] EXCEPTION:
java.nio.channels.ClosedChannelException
java.nio.channels.ClosedChannelException
at org.jboss.netty.handler.ssl.SslHandler$6.run(SslHandler.java:1580)
at
org.jboss.netty.channel.socket.ChannelRunnableWrapper.run(ChannelRunnableWrapper.ja
```

```
va:40)
at
org.jboss.netty.channel.socket.nio.AbstractNioWorker.executeInIoThread(AbstractNioW
orker.java:71)
at  org.jboss.netty.channel.socket.nio.NioWorker.executeInIoThread(NioWorker.java:36)
at
org.jboss.netty.channel.socket.nio.AbstractNioWorker.executeInIoThread(AbstractNioW
orker.java:57)
at  org.jboss.netty.channel.socket.nio.NioWorker.executeInIoThread(NioWorker.java:36)
at
org.jboss.netty.channel.socket.nio.AbstractNioChannelSink.execute(AbstractNioChanne
lSink.java:34)
at org.jboss.netty.handler.ssl.SslHandler.channelClosed(SslHandler.java:1566)
at org.jboss.netty.channel.Channels.fireChannelClosed(Channels.java:468
at
org.jboss.netty.channel.socket.nio.AbstractNioWorker.close(AbstractNioWorker.java:3
76)
at org.jboss.netty.channel.socket.nio.NioWorker.read(NioWorker.java:93)
at
org.jboss.netty.channel.socket.nio.AbstractNioWorker.process(AbstractNioWorker.java
:109)
at
org.jboss.netty.channel.socket.nio.AbstractNioSelector.run(AbstractNioSelector.java
:312)
at
org.jboss.netty.channel.socket.nio.AbstractNioWorker.run(AbstractNioWorker.java:90)
at org.jboss.netty.channel.socket.nio.NioWorker.run(NioWorker.java:178)
at java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1142)
at java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:617)
at java.lang.Thread.run(Thread.java:745)
```

Leader 节点的日志，如下所示：

```
2017-07-11 13:17:33,043 [myid:1] - WARN  [New I/O worker #7:NettyServerCnxn@445] -
Closing connection to /10.18.101.110:39856
java.io.IOException: Len error 45
at
org.apache.zookeeper.server.NettyServerCnxn.receiveMessage(NettyServerCnxn.java:438)
at
org.apache.zookeeper.server.NettyServerCnxnFactory$CnxnChannelHandler.processMessag
e(NettyServerCnxnFactory.java:267)
at
org.apache.zookeeper.server.NettyServerCnxnFactory$CnxnChannelHandler.messageReceiv
ed(NettyServerCnxnFactory.java:187)
at
org.jboss.netty.channel.SimpleChannelHandler.handleUpstream(SimpleChannelHandler.ja
va:88)
at
org.jboss.netty.channel.DefaultChannelPipeline.sendUpstream(DefaultChannelPipeline.
java:564)
at
org.jboss.netty.channel.DefaultChannelPipeline.sendUpstream(DefaultChannelPipeline.
java:559)
at org.jboss.netty.channel.Channels.fireMessageReceived(Channels.java:268)
at org.jboss.netty.channel.Channels.fireMessageReceived(Channels.java:255)
at org.jboss.netty.channel.socket.nio.NioWorker.read(NioWorker.java:88)
```

```
at
org.jboss.netty.channel.socket.nio.AbstractNioWorker.process(AbstractNioWorker.java
:109)
at
org.jboss.netty.channel.socket.nio.AbstractNioSelector.run(AbstractNioSelector.java
:312)
at
org.jboss.netty.channel.socket.nio.AbstractNioWorker.run(AbstractNioWorker.java:90)
at org.jboss.netty.channel.socket.nio.NioWorker.run(NioWorker.java:178)
at org.jboss.netty.util.ThreadRenamingRunnable.run(ThreadRenamingRunnable.java:108)
at
org.jboss.netty.util.internal.DeadLockProofWorker$1.run(DeadLockProofWorker.java:42)
at java.util.concurrent.ThreadPoolExecutor.runWorker(ThreadPoolExecutor.java:1142)
at java.util.concurrent.ThreadPoolExecutor$Worker.run(ThreadPoolExecutor.java:617)
at java.lang.Thread.run(Thread.java:745)
```

回答

在单个父目录中创建大量的 znode 后，当客户端尝试在单个请求中获取所有子节点时，服务端将无法返回，因为结果将超出可存储在 znode 上的数据的最大长度。

为了避免这个问题，应该根据客户端应用的实际情况将“jute.maxbuffer”参数配置为一个更高的值。

“jute.maxbuffer”只能设置为 Java 系统属性，且没有 zookeeper 前缀。如果要将“jute.maxbuffer”的值设为 X，在 ZooKeeper 客户端或服务端启动时传入以下系统属性：-Djute.maxbuffer=X。

例如，将参数值设置为 4MB：-Djute.maxbuffer=0x400000。

表24-7 配置参数

参数	描述	默认值
jute.maxbuffer	指定可以存储在 znode 中的数据的最大长度。单位是 Byte。默认值为 0xfffff，即低于 1MB。 说明 如果更改此选项，则必须在所有服务器和客户端上设置该系统属性，否则将出现问题。	0xfffff

24.6.3 为什么在 Zookeeper 服务器上启用安全的 netty 配置时，四个字母的命令不能与 linux 的 netcat 命令一起使用

问题

为什么在 Zookeeper 服务器上启用安全的 netty 配置时，四个字母的命令不能与 linux 的 ***netcat*** 命令一起使用？

例如：

echo stat |netcat host port

回答

Linux 的 ***netcat*** 命令没有与 Zookeeper 服务器安全通信的选项，所以当启用安全的 netty 配置时，它不能支持 Zookeeper 四个字母的命令。

为了避免这个问题，用户可以使用下面的 Java API 来执行四个字母的命令。

```
org.apache.zookeeper.client.FourLetterWordMain
```

例如：

```
String[] args = new String[]{host, port, "stat"};
org.apache.zookeeper.client.FourLetterWordMain.main(args);
```

说明

netcat 命令只能用于非安全的 netty 配置。

24.6.4 如何查看哪个 ZooKeeper 实例是 leader

问题

如何查看 ZooKeeper 实例的角色是 leader 还是 follower?

回答

登录 Manager，选择“集群 > *待操作集群的名称* > 服务 > ZooKeeper > 实例”，单击相应的 quorumpeer 实例名称，进入对应实例的详情页面，即可查看到该实例的“服务器状态”。

24.6.5 使用 IBM JDK 时客户端无法连接 ZooKeeper

问题

使用 IBM 的 JDK 的情况下客户端连接 ZooKeeper 失败。

回答

可能原因为 IBM 的 JDK 和普通 JDK 的 jaas.conf 文件格式不一样。

在使用 IBM JDK 时，建议使用如下 jaas.conf 文件模板，其中“useKeytab”中的文件路径必须以“file://”开头，后面为绝对路径。

```
Client {
com.ibm.security.auth.module.Krb5LoginModule required
useKeytab="file://D:/install/HbaseClientSample/conf/user.keytab"
principal="hbaseuser1"
credsType="both";
};
```

24.6.6 ZooKeeper 客户端刷新 TGT 失败

问题

ZooKeeper 客户端刷新 TGT 失败，无法连接 ZooKeeper。报错内容如下：

```
Login: Could not renew TGT due to problem running shell command: '***/kinit -R';
exception was:org.apache.zookeeper.Shell$ExitCodeException: kinit: Ticket expired
while renewing credentials
```

回答

ZooKeeper 使用系统命令 **kinit -R** 对票据进行刷新，当前 MRS 版本已经取消了该命令的功能，如需运行长任务，建议使用 keytab 方式完成鉴权功能。

在“*客户端安装路径*/ZooKeeper/zookeeper/conf/jaas.conf”配置文件中设置属性“useTicketCache=false”，设置“useKeyTab=true”，并指明 keytab 路径。

24.6.7 使用 deleteall 命令，删除大量 znode 时，偶现报错“Node does not exist”错误

问题

客户端连接非 leader 实例，使用 deleteall 命令删除大量 znode 时，报错 Node does not exist，但是 stat 命令能够获取到 node 状态。

回答

由于网络问题或者数据量大导致 leader 和 follower 数据不同步。解决方法是客户端连接到 leader 实例进行删除操作。具体过程是首先根据 24.6.4 如何查看哪个 ZooKeeper 实例是 leader 查看 leader 所在节点 IP，使用连接客户端命令 zkCli.sh -server leader 节点 IP:2181 成功后进行 deleteall 命令删除操作，具体操作请参见 24.3 使用 ZooKeeper 客户端。

25 附录

25.1 修改集群服务配置参数

- 用户可直接通过 MRS 管理控制台的集群管理页面修改各服务配置参数：
  a. 登录 MRS 控制台，在左侧导航栏选择“集群列表> 现有集群”，单击集群名称。
  b. 选择“组件管理 > *服务名称* > 服务配置”。
     默认显示“基础配置”，如果需要修改更多参数，请选择“全部配置”，界面上将显示该服务的全部配置参数导航树，导航树从上到下的一级节点分别为服务名称和角色名称。展开一级节点后显示参数分类。
  c. 在导航树选择指定的参数分类，并在右侧修改参数值。
     不确定参数的具体位置时，支持在右上角输入参数名，系统将实时进行搜索并显示结果。
  d. 单击“保存配置”，并在确认对话框中单击“是”。
  e. 等待界面提示“操作成功”，单击“完成”，配置已修改。
     查看集群是否存在配置过期的服务，如果存在，需重启对应服务或角色实例使配置生效。也可在保存配置时直接勾选“重新启动受影响的服务或实例。”。

服务配置参数均支持登录 FusionInsight Manager 进行修改：

1. 登录 FusionInsight Manager。
2. 选择“集群 > 服务”。
3. 单击服务视图中指定的服务名称。
4. 单击“配置”。
   默认显示“基础配置”，如果需要修改更多参数，请选择“全部配置”，界面上将显示该服务的全部配置参数导航树，导航树从上到下的一级节点分别为服务名称和角色名称。展开一级节点后显示参数分类。
5. 在导航树选择指定的参数分类，并在右侧修改参数值。
   不确定参数的具体位置时，支持在右上角输入参数名，Manager 将实时进行搜索并显示结果。
6. 单击“保存”，并在确认对话框中单击“确定”。

7. 等待界面提示“操作成功”，单击“完成”，配置已修改。

   查看集群是否存在配置过期的服务，如果存在，需重启对应服务或角色实例使配置生效。

25.2 访问集群 Manager

25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本）

操作场景

集群使用 FusionInsight Manager 对集群进行监控、配置和管理。用户在集群安装后可使用账号登录 FusionInsight Manager。

说明

如果不能正常登录组件的 WebUI 页面，请参考通过 ECS 访问 FusionInsight Manager 方式访问 FusionInsight Manager。

通过弹性 IP 访问 FusionInsight Manager

登录 MRS 管理控制台页面。

步骤 1 单击“集群列表 > 现有集群”，在集群列表中单击指定的集群名称，进入集群信息页面。

步骤 2 单击“集群管理页面 ”后的“前往 Manager”，在弹出的窗口中配置弹性 IP 信息。

1. 若创建 MRS 集群时暂未绑定弹性公网 IP，在“弹性公网 IP”下拉框中选择可用的弹性公网 IP。若用户创建集群时已经绑定弹性公网 IP，直接执行步骤 3.2。

   说明

   - 如果没有弹性公网 IP，可先单击“管理弹性公网 IP”创建弹性公网 IP 后，然后在弹性公网 IP 下拉框中选择创建的弹性公网 IP。
   - 如果在使用完后需要解绑或释放弹性公网 IP，请登录“弹性公网 IP”界面，在待操作的弹性公网 IP 后，单击“操作”列的“解绑”或“更多 > 释放”。
   - 如果已创建弹性公网 IP，但在绑定时无法找到，可能是由于该弹性公网 IP 被其他集群绑定，请先在弹性公网 IP 界面解绑，然后再为当前集群绑定。

2. 在“安全组”中选择当前集群所在的安全组，该安全组在创建集群时配置或集群自动创建。

   说明

   - 创建自定义集群时，安全组可配置提前创建的安全组或保持默认“自动创建”；快速创建集群时，安全组由集群自动创建。
   - 安全组名称可在集群的“概览”界面的“安全组”查看。

3. 添加安全组规则，默认填充的是用户访问弹性 IP 地址的规则，如需开放多个 IP 段为可信范围用于访问 Manager 页面，请参考步骤 6～步骤 9。如需对安全组规则进行查看，修改和删除操作，请单击“管理安全组规则”。

4. 勾选确认信息后，单击“确定”。

步骤 3 单击“确定”，进入 Manager 登录页面。

步骤 4 输入默认用户名“admin”及创建集群时设置的密码，单击“登录”进入 Manager 页面。

步骤 5 在 MRS 管理控制台，在“现有集群” 列表，单击指定的集群名称，进入集群信息页面。

说明

如需给其他用户开通访问 Manager 的权限，请执行步骤 6～步骤 9，添加对应用户访问公网的 IP 地址为可信范围。

步骤 6 单击弹性公网 IP 后边的“添加安全组规则”。

步骤 7 进入“添加安全组规则”页面，添加需要开放权限用户访问公网的 IP 地址段并勾选“我确认这里设置的*公网IP/端口号*是可信任的公网访问 IP 范围，我了解使用 0.0.0.0/0 会带来安全风险”

默认填充的是用户访问公网的 IP 地址，用户可根据需要修改 IP 地址段，如需开放多个 IP 段为可信范围，请重复执行步骤 6-步骤 9。如需对安全组规则进行查看，修改和删除操作，请单击“管理安全组规则”。

步骤 8 单击“确定”完成安全组规则添加。

----结束

通过 ECS 访问 FusionInsight Manager

在 MRS 管理控制台，单击“集群列表”。

步骤 1 在“现有集群”列表中，单击指定的集群名称。

记录集群的“可用区”、“虚拟私有云”、“集群管理页面”、“安全组”。

步骤 2 在管理控制台首页服务列表中选择“弹性云服务器”，进入 ECS 管理控制台，创建一个新的弹性云服务器。

- 弹性云服务器的“可用区”、“虚拟私有云”、“安全组”，需要和待访问集群的配置相同。
- 选择一个 Windows 系统的公共镜像。例如，选择一个标准镜像“Windows Server 2012 R2 Standard 64bit(40GB)”。
- 其他配置参数详细信息，请参见“弹性云服务器 > 用户指南 > 快速入门 > 创建并登录 Windows 弹性云服务器”。

说明

如果 ECS 的安全组和 Master 节点的“默认安全组”不同，用户可以选择以下任一种方法修改配置：

- 将 ECS 的安全组修改为 Master 节点的默认安全组，请参见“弹性云服务器 > 用户指南 > 安全组 > 更改安全组”。
- 在集群 Master 节点和 Core 节点的安全组添加两条安全组规则使 ECS 可以访问集群，“协议”需选择为“TCP”，“端口”需分别选择“28443”和“20009”。请参见“虚拟私有云 > 用户指南 > 安全性 > 安全组 > 添加安全组规则”。

步骤 3 在 VPC 管理控制台，申请一个弹性 IP 地址，并与 ECS 绑定。

具体请参见“虚拟私有云 > 用户指南 > 弹性公网 IP > 为弹性云服务器申请和绑定弹性公网 IP”。

步骤 4 登录弹性云服务器。

登录 ECS 需要 Windows 系统的账号、密码，弹性 IP 地址以及配置安全组规则。具体请参见“弹性云服务器 > 用户指南 > 实例 > 登录弹性云服务器 > 登录 Windows 弹性云服务器”。

步骤 5 在 Windows 的远程桌面中，打开浏览器访问 Manager。

Manager 访问地址为“集群管理页面”地址。访问时需要输入集群的用户名和密码，例如“admin”用户。

说明

- 如果使用其他集群用户访问 Manager，第一次访问时需要修改密码。新密码需要满足集群当前的用户密码复杂度策略。请咨询管理员。
- 默认情况下，在登录时输入 5 次错误密码将锁定用户，需等待 5 分钟自动解锁。

步骤 6 注销用户退出 Manager 时移动鼠标到右上角  ，然后单击“注销”。

----结束

25.3 使用 MRS 客户端

25.3.1 安装客户端

操作场景

该操作指导安装工程师安装 MRS 集群所有服务（不包含 Flume）的客户端。Flume 客户端安装请参见“组件操作指南 > 使用 Flume > 安装 Flume 客户端”。

客户端可以安装集群内节点，也可以安装在集群外节点，本章节以安装目录“/opt/client”为例进行介绍，请以实际集群版本为准。

在集群外节点安装客户端前提条件

- 已准备一个 Linux 弹性云服务器，主机操作系统及版本建议参见表 25-1。

表25-1 参考列表

CPU 架构	操作系统	支持的版本号
x86 计算	Euler	EulerOS 2.5
	SUSE	SUSE Linux Enterprise Server 12 SP4（SUSE 12.4）
	Red Hat	Red Hat-7.5-x86_64（Red Hat 7.5）
	CentOS	CentOS-7.6 版本（CentOS 7.6）

CPU 架构	操作系统	支持的版本号
鲲鹏计算 (ARM)	Euler	EulerOS 2.8
	CentOS	CentOS-7.6 版本（CentOS 7.6）

同时为弹性云服务分配足够的磁盘空间，例如“40GB”。

- 弹性云服务器的 VPC 需要与 MRS 集群在同一个 VPC 中。
- 弹性云服务器的安全组需要和 MRS 集群 Master 节点的安全组相同。
- 弹性云服务器操作系统已安装 NTP 服务，且 NTP 服务运行正常。

  若未安装，在配置了 **yum** 源的情况下，可执行 **yum install ntp -y** 命令自行安装。
- 需要允许用户使用密码方式登录 Linux 弹性云服务器（SSH 方式）。
- MRS 集群安全组入方向将所有端口对客户端节点放开。

集群内节点安装客户端

1. 获取软件包。

   25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），在“集群”下拉列表中单击需要操作的集群名称。

   选择“更多 > 下载客户端”，弹出“下载集群客户端”信息提示框。

   说明

   在只安装单个服务的客户端的场景中，选择“集群 > 服务 > *服务名称* > 更多 > 下载客户端”，弹出“下载客户端”信息提示框。

2. “选择客户端类型”中选择“完整客户端”。

   “仅配置文件”下载的客户端配置文件，适用于应用开发任务中，完整客户端已下载并安装后，管理员通过 Manager 界面修改了服务端配置，开发人员需要更新客户端配置文件的场景。

   平台类型包括 x86_64 和 aarch64 两种：

   - x86_64：可以部署在 X86 平台的客户端软件包。
   - aarch64：可以部署在 TaiShan 服务器的客户端软件包。

   说明

   集群支持下载 x86_64 和 aarch64 两种类型客户端，但是客户端类型必须与待安装节点的架构匹配，否则客户端会安装失败。

3. 勾选“仅保存到如下路径”，单击“确定”开始生成客户端文件。

   文件生成后默认保存在主管理节点“/tmp/FusionInsight-Client”。支持自定义其他目录且 **omm** 用户拥有目录的读、写与执行权限。单击“确定”，等待下载完成后，使用 **omm** 用户或 **root** 用户将获取的软件包复制到将要安装客户端的服务器文件目录。

   客户端软件包名称格式为：“FusionInsight_Cluster_<*集群 ID*>_Services_Client.tar”。本章节仅以*集群 ID* 为 **1** 进行介绍，请以实际*集群 ID* 为准。

   后续步骤及章节以 FusionInsight_Cluster_1_Services_Client.tar 进行举例。

- 复制客户端安装包至当前节点的其他目录，例如复制到“opt/Bigdata/client”目录：

  cp -p */tmp/FusionInsight-Client/***FusionInsight_Cluster_1_Services_Client.tar** */opt/Bigdata/client*

- 复制客户端安装包至集群内其他节点目录，例如复制到“opt/Bigdata/client”目录：

  scp -p */tmp/FusionInsight-Client/***FusionInsight_Cluster_1_Services_Client.tar** *待安装客户端节点的IP地址:/opt/Bigdata/client*

说明

当用户无法获取 **root** 用户权限，需要用 **omm** 用户操作。

4. 以 **user_client** 用户登录将要安装客户端的服务器。
5. 解压软件包。

   进入安装包所在目录，例如“/opt/Bigdata/client”。执行如下命令解压安装包到本地目录。

   tar -xvf FusionInsight_Cluster_1_Services_Client.tar
6. 校验软件包。

   执行 **sha256sum** 命令校验解压得到的文件，检查回显信息与 sha256 文件里面的内容是否一致，例如：

   sha256sum -c FusionInsight_Cluster_1_Services_ClientConfig.tar.sha256

   ```
   FusionInsight_Cluster_1_Services_ClientConfig.tar: OK
   ```
7. 解压获取的安装文件。

   tar -xvf FusionInsight_Cluster_1_Services_ClientConfig.tar
8. 进入安装包所在目录，执行如下命令安装客户端到指定目录（绝对路径），例如安装到“/opt/client”目录。

   cd/opt/Bigdata/client/FusionInsight_Cluster_1_Services_ClientConfig

   执行**./install.sh /opt/client** 命令，等待客户端安装完成（以下只显示部分屏显结果）。

   ```
   The component client is installed successfully
   ```

说明

- 如果已经安装的全部服务或某个服务的客户端使用了“/opt/client”目录，再安装其他服务的客户端时，需要使用不同的目录。
- 卸载客户端请删除客户端安装目录。
- 如果要求安装后的客户端仅能被该安装用户（如“user_client”）使用，请在安装时加“-o”参数，即执行**./install.sh /opt/client -o** 命令安装客户端。
- 由于 HBase 使用的 Ruby 语法限制，如果安装的客户端中包含了 HBase 客户端，建议客户端安装目录路径只包含大写字母、小写字母、数字以及_-?.@+=字符。

使用客户端

1. 在已安装客户端的节点，执行 **sudo su - omm** 命令切换用户。执行以下命令切换到客户端目录：

   cd /opt/client
2. 执行以下命令配置环境变量：

source bigdata_env

3. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

   kinit*MRS 集群用户*

   例如，**kinit admin**。

   说明

   启用 Kerberos 认证的 MRS 集群默认创建“admin”用户账号，用于集群管理员维护集群。

4. 直接执行组件的客户端命令。

   例如：使用 HDFS 客户端命令查看 HDFS 根目录文件，执行 **hdfs dfs -ls /**。

集群外节点安装客户端

1. 根据在集群外节点安装客户端前提条件，创建一个满足要求的弹性云服务器。
2. 执行 ntp 时间同步，使集群外节点的时间与 MRS 集群时间同步。
   a. 执行 **vi /etc/ntp.conf** 命令编辑 NTP 客户端配置文件，并增加 MRS 集群中 Master 节点的 IP 并注释掉其他 **server** 的地址。

```
server master1_ip prefer
server master2_ip
```

图25-1 增加 Master 节点的 IP

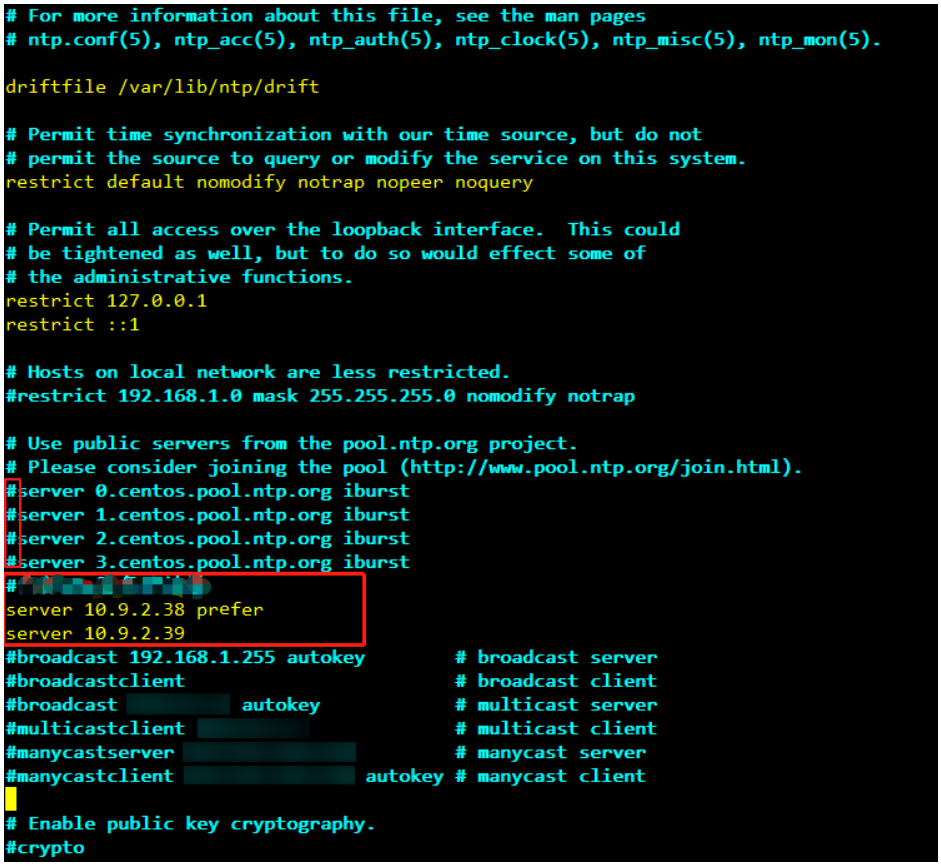

b. 执行 **service ntpd stop** 命令关闭 NTP 服务。

c. 执行如下命令，手动同步一次时间：

/usr/sbin/ntpdate *192.168.10.8*

说明

192.168.10.8 为主 Master 节点的 IP 地址。

d. 执行 **service ntpd start** 或 **systemctl restart ntpd** 命令启动 NTP 服务。

e. 执行 **ntpstat** 命令查看时间同步结果。

3. 参考以下步骤，从 FusionInsight Manager 下载集群客户端软件包并复制到 ECS 节点后安装客户端。

a. 25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），参考集群内节点安装客户端下载集群客户端到主管理节点的指定目录。

b. 使用 **root** 用户登录主管理节点，执行以下命令复制客户端安装包到待安装客户端的节点：

scp -p /tmp/FusionInsight-Client/FusionInsight_Cluster_1_Services_Client.tar *待安装客户端节点的 IP 地址*:**/tmp**

c. 使用待安装客户端的用户登录待安装客户端节点。

执行以下命令安装客户端，如果当前用户无客户端软件包以及客户端安装目录的操作权限，需使用 **root** 用户进行赋权：

cd /tmp

tar -xvf FusionInsight_Cluster_1_Services_Client.tar

tar -xvf FusionInsight_Cluster_1_Services_ClientConfig.tar

cd FusionInsight_Cluster_1_Services_ClientConfig

./install.sh /opt/client

d. 执行以下命令，切换到客户端目录并配置环境变量：

cd /opt/client

source bigdata_env

e. 如果当前集群已启用 Kerberos 认证，执行以下命令认证当前用户。如果当前集群未启用 Kerberos 认证，则无需执行此命令。

kinit*MRS 集群用户*

例如，**kinit admin**。

f. 直接执行组件的客户端命令。

例如使用 HDFS 客户端命令查看 HDFS 根目录文件，执行 **hdfs dfs -ls /**。

25.3.2 更新客户端

集群提供了客户端，可以在连接服务端、查看任务结果或管理数据的场景中使用。用户如果在 Manager 修改了服务配置参数并重启了服务，已安装的客户端需要重新下载并安装，或者使用配置文件更新客户端。

更新客户端配置

方法一：

25.2.1 访问 FusionInsight Manager（MRS 3.x 及之后版本），在“集群”下拉列表中单击需要操作的集群名称。

步骤 1 选择“更多 > 下载客户端 > 仅配置文件”。

此时生成的压缩文件包含所有服务的配置文件。

步骤 2 是否在集群的节点中生成配置文件？

- 是，勾选“仅保存到如下路径”，单击“确定”开始生成客户端文件，文件生成后默认保存在主管理节点“/tmp/FusionInsight-Client”。支持自定义其他目录且 **omm** 用户拥有目录的读、写与执行权限。然后执行步骤 4。
- 否，单击“确定”指定本地的保存位置，开始下载完整客户端，等待下载完成，然后执行步骤 4。

步骤 3 使用 WinSCP 工具，以客户端安装用户将压缩文件保存到客户端安装的目录，例如“/opt/hadoopclient”。

步骤 4 解压软件包。

例如下载的客户端文件为“FusionInsight_Cluster_1_Services_Client.tar”执行如下命令进入客户端所在目录，解压文件到本地目录。

cd /opt/hadoopclient

tar -xvf FusionInsight_Cluster_1_Services_Client.tar

步骤 5 校验软件包。

执行 **sha256sum** 命令校验解压得到的文件，检查回显信息与 sha256 文件里面的内容是否一致，例如：

sha256sum -c FusionInsight_Cluster_1_Services_ClientConfig_ConfigFiles.tar.sha256

```
FusionInsight_Cluster_1_Services_ClientConfig_ConfigFiles.tar: OK
```

步骤 6 解压获取配置文件。

tar -xvf FusionInsight_Cluster_1_Services_ClientConfig_ConfigFiles.tar

步骤 7 在客户端安装目录下执行如下命令，使用配置文件更新客户端。

sh refreshConfig.sh *客户端安装目录 配置文件所在目录*

例如，执行以下命令：

sh refreshConfig.sh /opt/hadoopclient /opt/hadoopclient/FusionInsight_Cluster_1_Services_ClientConfig_ConfigFiles

界面显示以下信息表示配置刷新更新成功：

```
Succeed to refresh components client config.
```

----结束

方法二：

以 **root** 用户登录客户端安装节点。

步骤 8 进入客户端安装的目录，例如“/opt/hadoopclient”，执行以下命令更新配置文件：

cd /opt/hadoopclient

sh autoRefreshConfig.sh

步骤 9 按照提示输入 FusionInsight Manager 管理员用户名，密码以及 FusionInsight Manager 界面浮动 IP。

步骤 10 输入需要更新配置的组件名，组件名之间使用“,”分隔。如需更新所有组件配置，可直接单击回车键。

界面显示以下信息表示配置刷新更新成功：

```
Succeed to refresh components client config.
```

----结束