

GPUStack- 单机版 用户手册

一、产品概述

1.1 产品介绍

GPUStack 云服务是基于开源 GPUStack 构建的托管式 AI 模型部署平台，让您无需管理基础设施，即可在高性能 GPU 集群上轻松部署和运行各类 AI 模型。

1.2 产品核心能力

资源管理：提供自动化 GPU 资源调度与集群管理，支持异构 GPU 设备统一纳管，实现资源利用率最大化与成本最优化；

模型部署：支持主流开源大模型一键部署，兼容 Hugging Face、ModelScope 等模型源，集成 vLLM、SGLang 和 TensorRT-LLM 等高性能推理引擎，满足不同场景性能需求；

智能运维：内置自动扩缩容、故障转移与负载均衡机制，提供实时性能监控与告警，确保服务高可用性与稳定性；

安全管控：提供完善的认证授权体系与网络隔离策略，支持私有化部署与数据安全保障，满足企业级安全合规要求。

1.3 产品优势

自动处理底层 GPU 资源调度、模型优化和扩展，让您专注于应用开发而非运维。

零运维负担：无需管理 GPU 驱动、CUDA 版本或集群配置；

开箱即用：集成 vLLM、SGLang 和 TensorRT-LLM 等高性能推理引擎，支持自定义推理框架；

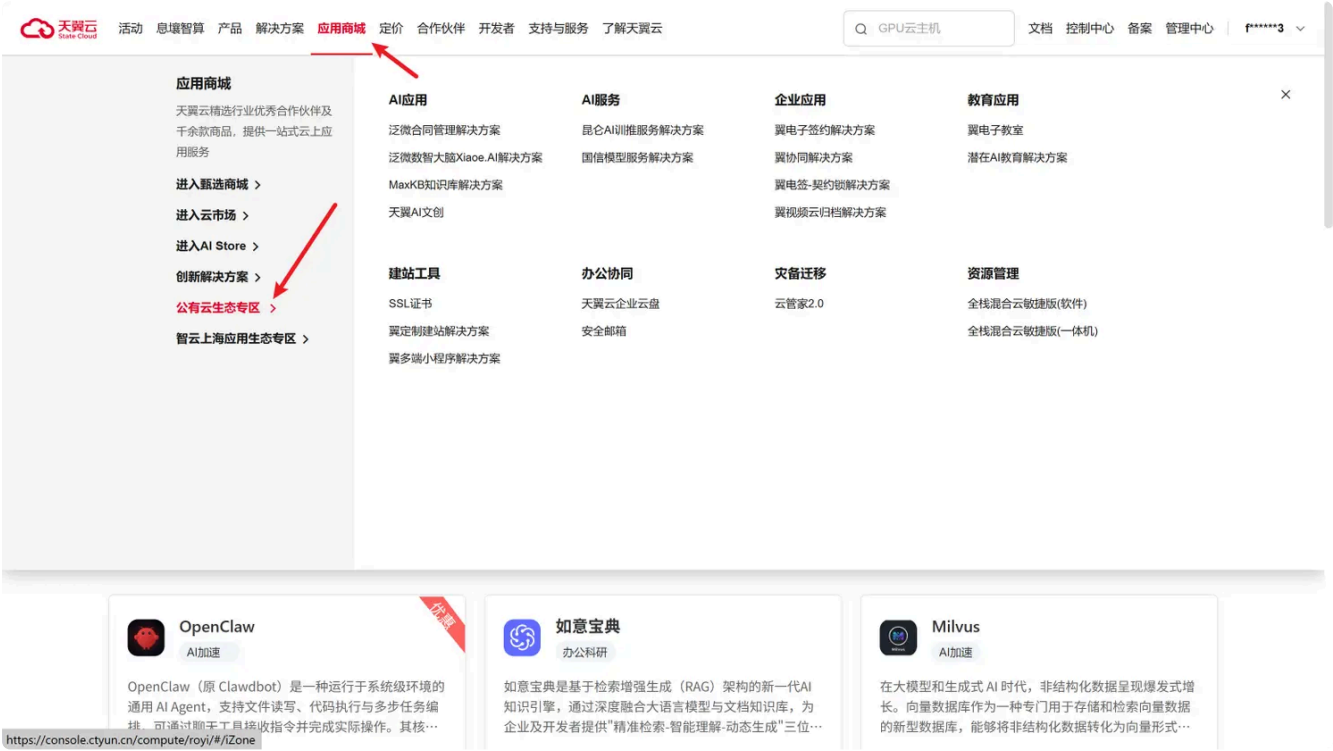
一键部署：支持从 Hugging Face、ModelScope、或本地直接部署，支持自动扩缩容、版本升降级；

性能优化配置：提供预调优模式，用于低延迟或高吞吐量；

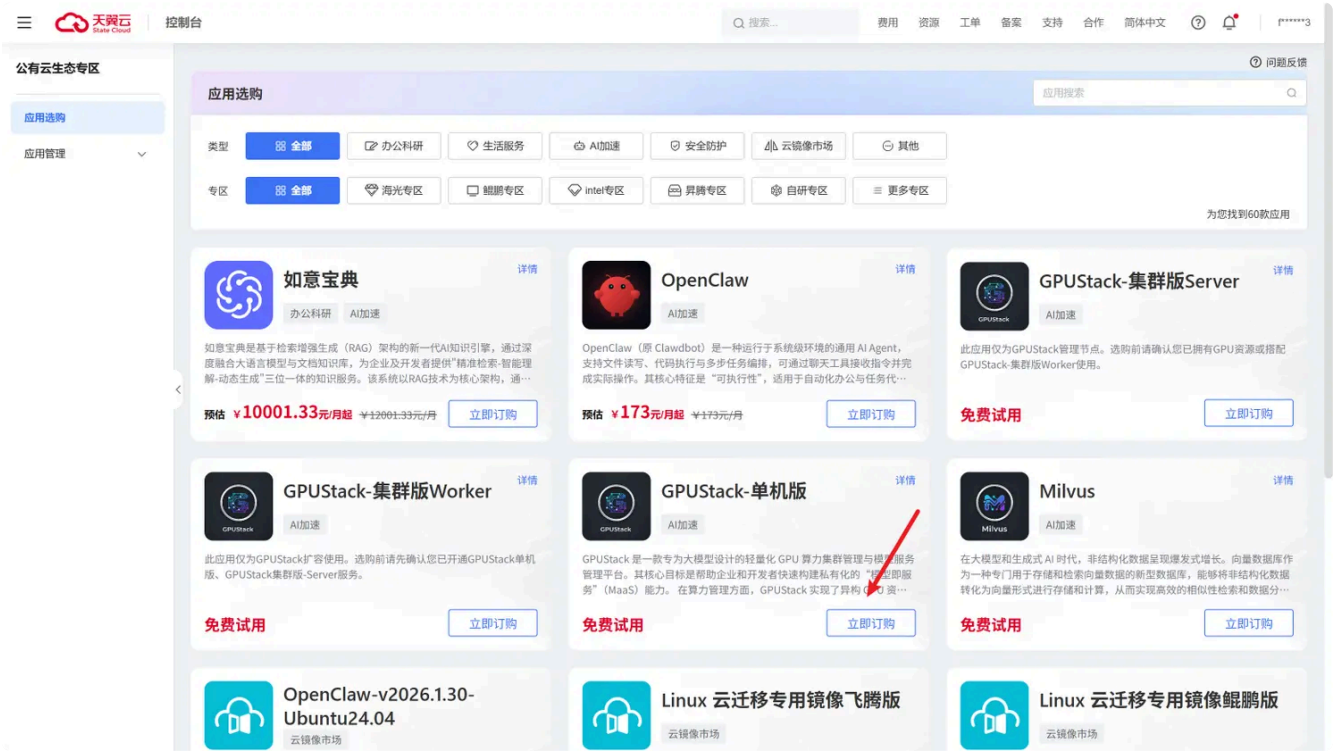
运维能力：支持自动故障恢复、负载均衡、监控、认证和访问控制。

二、使用指南

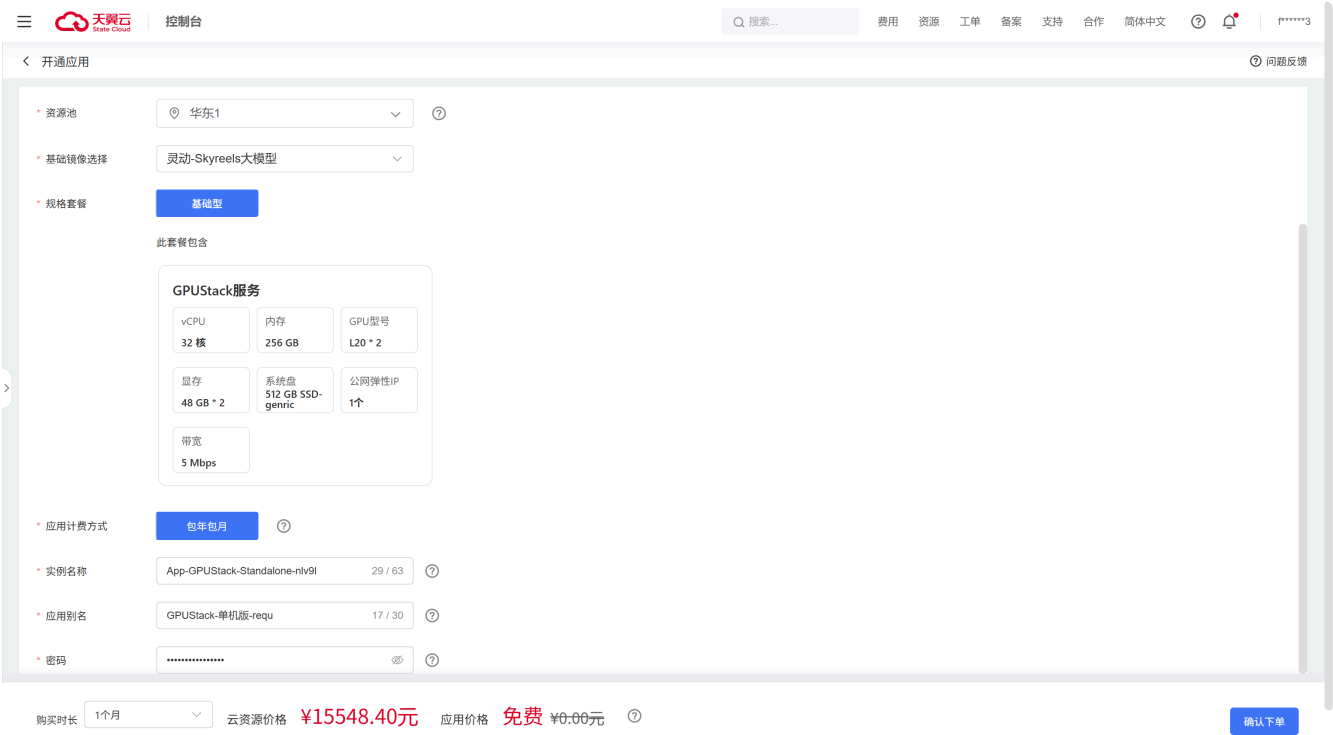
2.1 登录天翼云官网，选择【应用商城】 - 【公有云生态专区】，点击立即选购，进入应用专区页



2.2 选择“GPUStack 单机版”，点击立即订购



2.3 按提示订购“GPUstack 单机版”，点击确认下单即可成功购买服务。



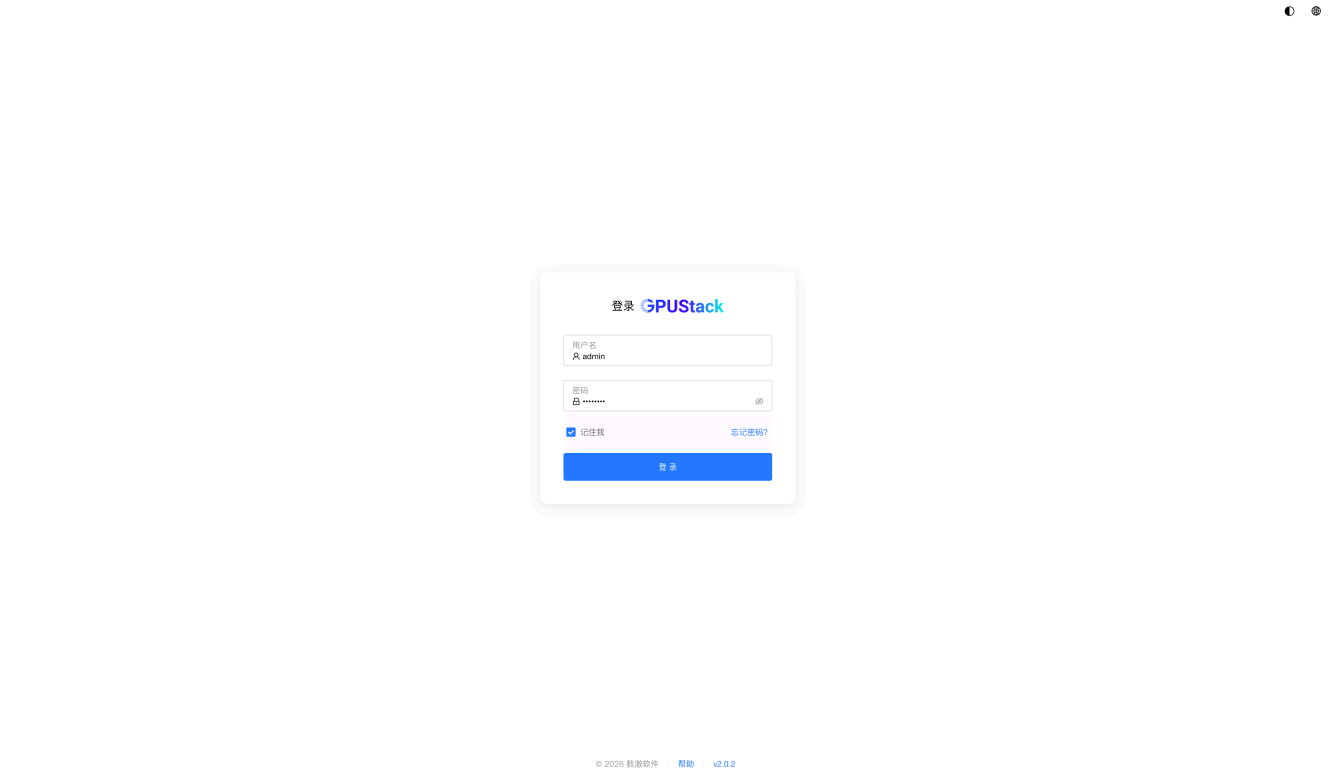
2.4 在【我的应用】页，查看应用状态，当应用状态为运行中时，代表服务部署完成。



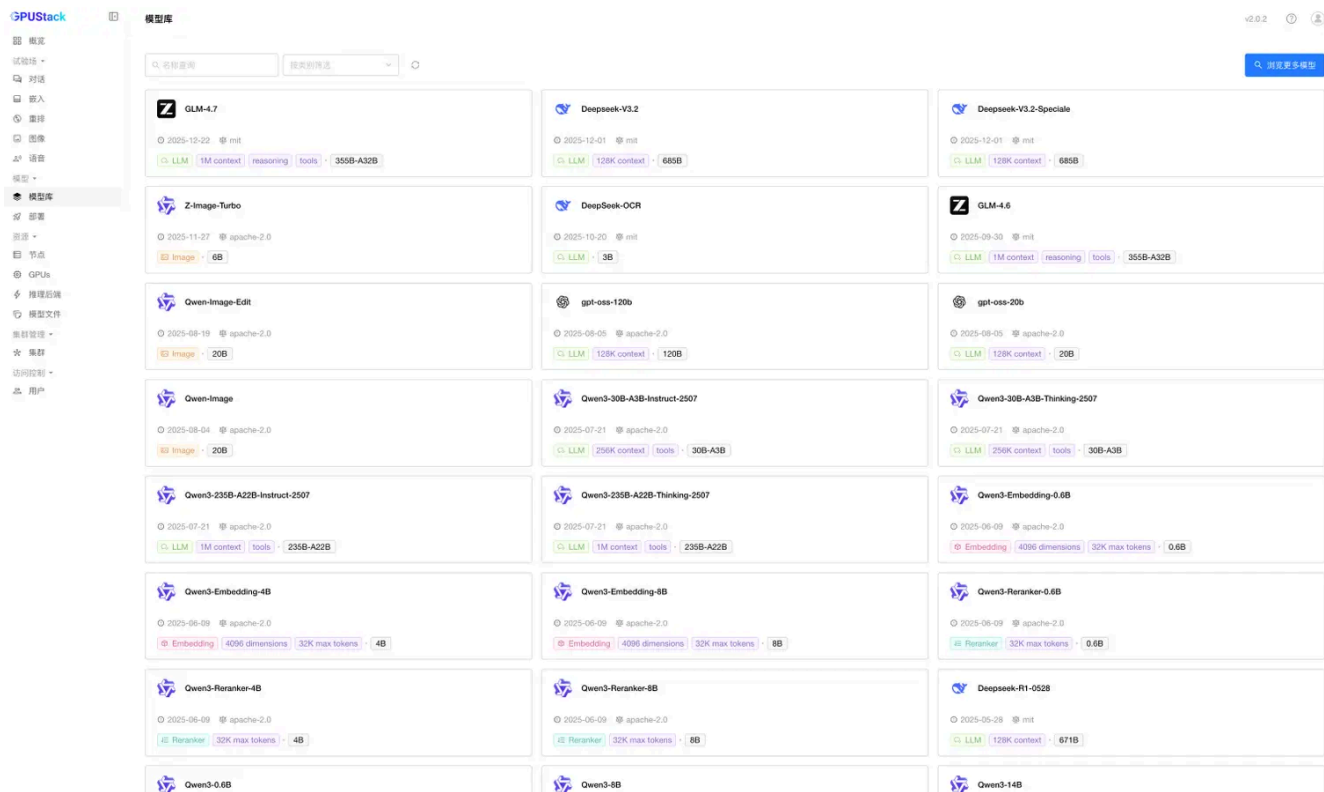
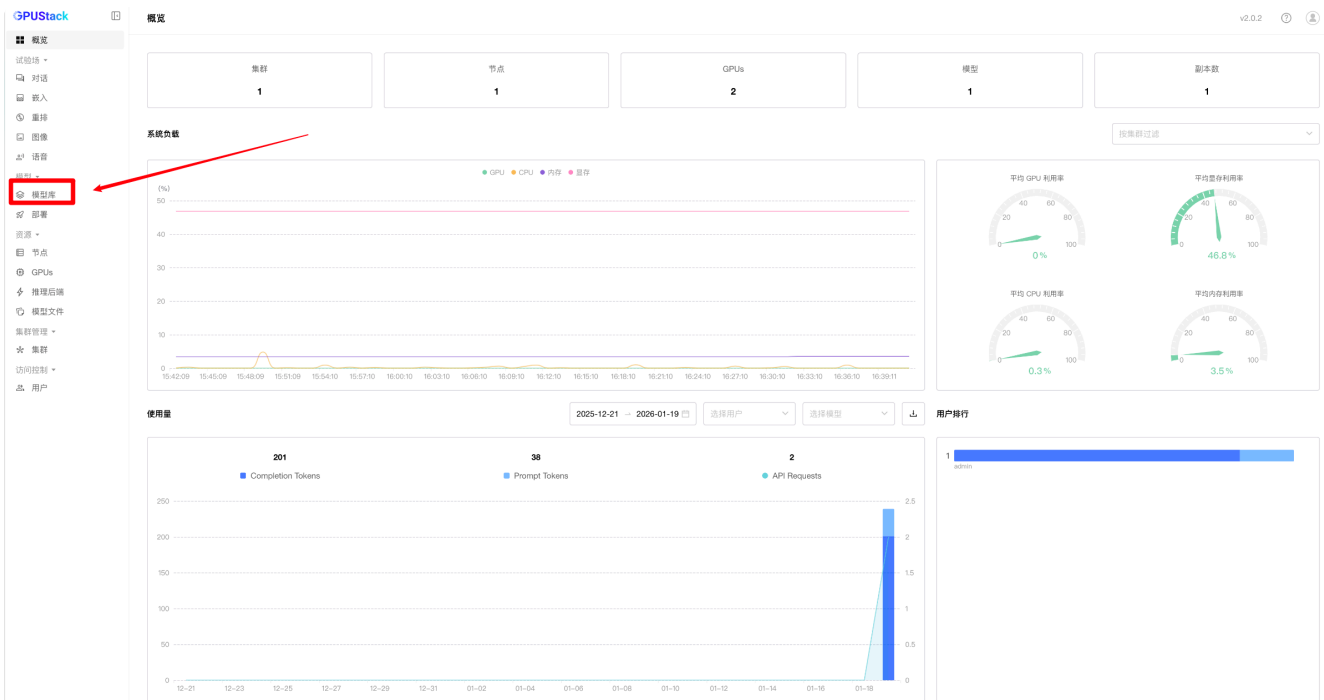
2.5 点击查看应用按钮，点击【立即使用】或在浏览器中输入复制的应用入口，即可访问 GPUstack

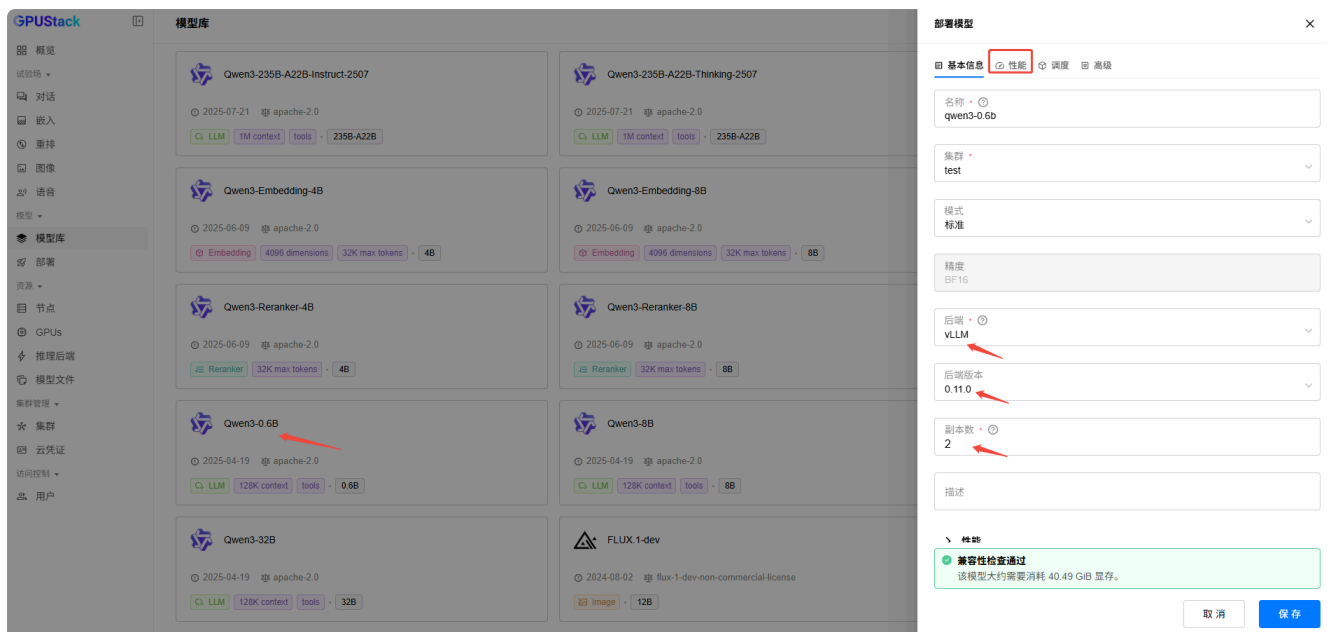


2.6 GPUstack 默认账号为 admin，密码为 gpustack。（可在应用中修改）

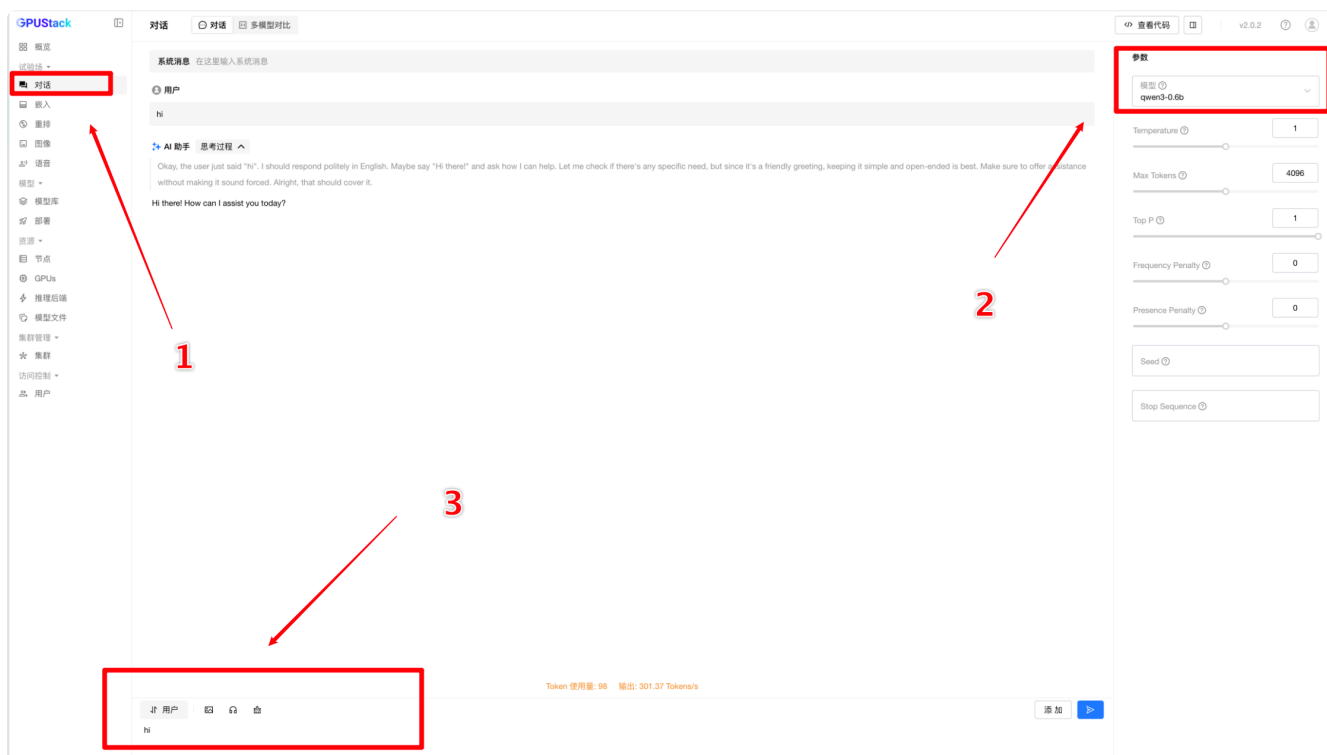


2.7 部署模型。进入模型库菜单，选择合适的模型开始部署；



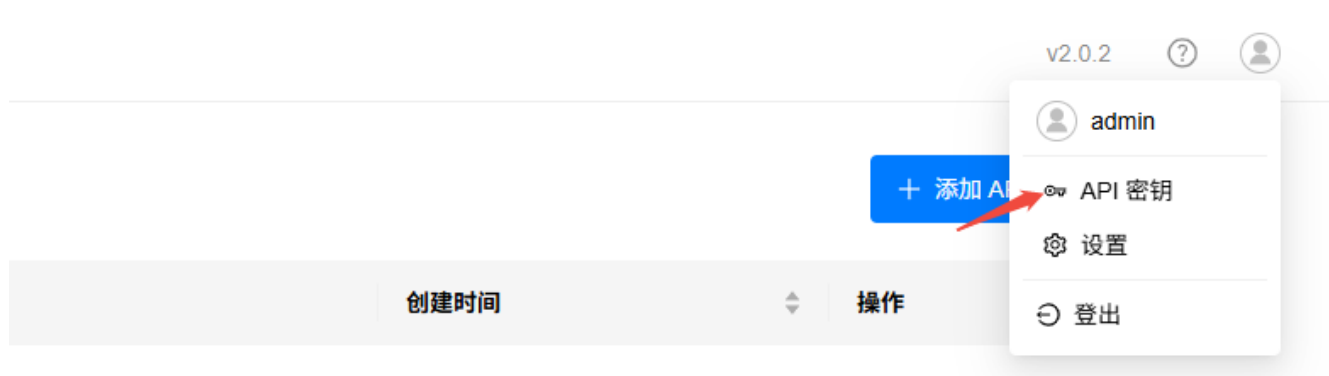


2.8 等待模型部署成功后，便可进入试验场，进行验证；



2.9 API 密钥管理

1. 将鼠标悬停在用户头像上，选择" API 密钥 "
2. 点击" 创建密钥 "生成新密钥
3. **安全提示：**该密钥仅在创建时可见一次，请妥善保存



三、常见问题

Q1: 如何升级或降级已部署的模型版本？

A: GPUStack 支持无缝模型版本切换

1. 在模型详情页点击"编辑"按钮
2. 在"模型版本"下拉菜单中选择目标版本
3. 手动删除原来的示例，即可自动创建新的副本
4. 支持新旧副本共存，可以在用户无感知情况下切换版本

Q2: 本地模型文件如何导入 GPUStack？

A: 挂载共享存储，需要在集群创建之前完成挂载并存储，否则 worker 节点无法访问

1. 根据页面提示在创建集群时，进行缓存卷挂载，会自动生成对应的 worker 指令
2. 此时在部署模型时，可以选择本地模型进行部署

版权与声明

© [2025] [天翼云科技有限公司]。保留所有权利。

本文档内容仅供参考。