高性能应用服务 HAI

应用指南

腾讯云

【联系我们】

我们致力于为您提供个性化的售前购买咨询服务，及相应的技术售后服务，任何问题请联系 4009100100或95716。

文档目录

应用指南
Stable Diffusion WebUI
快速创建
访问方式
提示词指南
导入外部模型
新增插件
其他常见操作
ChatGLM3 6B
快速创建
访问方式
手动中断与重启 Gradio WebUI 服务
在 HAI 环境中部署自定义项目
Pytorch 2.0.0
快速创建
访问方式
管理系统 CUDA
管理系统 cuDNN
管理 Python 虚拟环境依赖

应用指南
Stable Diffusion WebUI
快速创建

最近更新时间：2024-08-09 17:35:11

操作场景

本次介绍 腾讯云高性能应用服务 HAI Stable Diffusion WebUI 应用实例的购买流程。

操作步骤

1. 登录 高性能应用服务 HAI 控制台 。
2. 单击**新建**，进入 高性能应用服务 HAI 购买页面 。

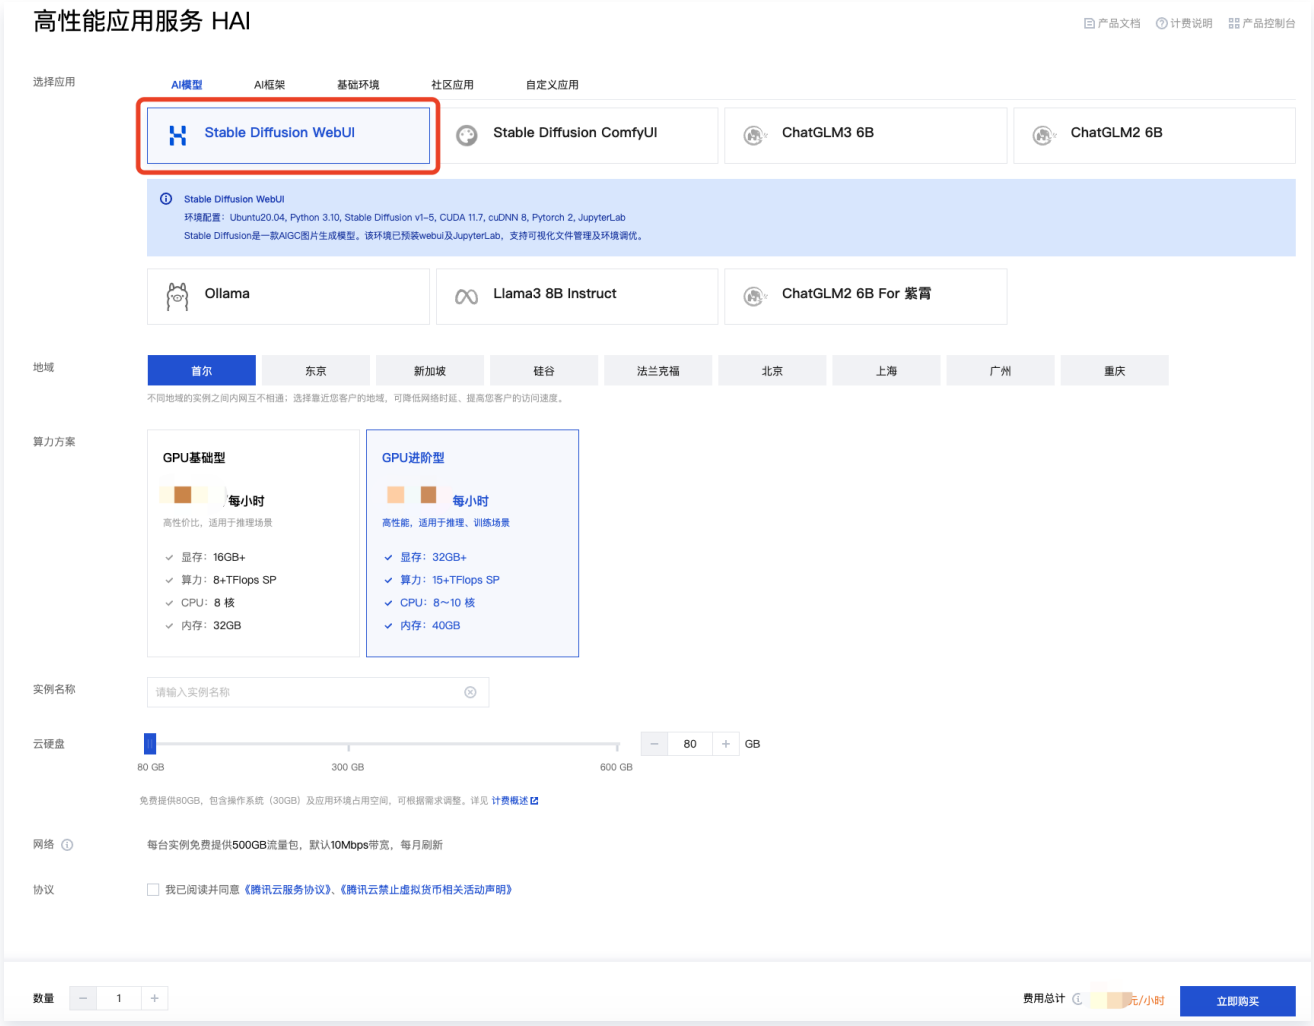

- **选择应用：**选择AI模型，应用选择 Stable Diffusion WebUI。
- **地域：**建议选择靠近自己实际地理位置的地域，降低网络延迟、提高您的访问速度。

- **算力方案：**支持基础型及进阶型两类算力方案。
- **实例名称：**自定义实例名称，若不填则默认使用实例 ID 替代。
- **硬盘：**默认提供 80GB 免费空间，可根据实际使用需求进行调整。
- **网络：**每台实例每月免费提供 500GB 流量包，默认10Mbps 带宽，每月刷新。
- **购买数量：**默认1台。

3. 单击**立即购买**。
4. 核对配置信息后，单击**提交订单**，并根据页面提示完成支付。
5. 等待创建完成。单击实例**任意位置**并进入该实例的详情页。

6. 您可以在此页面查看 Stable Diffusion WebUI 详细的配置信息，到此为止，说明您的 Stable Diffusion WebUI 应用实例购买成功。

访问方式

最近更新时间：2024-05-31 14:42:31

操作场景

购买 Stable Diffusion WebUI 应用实例后，我们有Gradio WebUI、JupyterLab、SSH 3 种方式访问该应用实例，以下将逐一介绍。

前提条件

已经购买了 Stable Diffusion WebUI 应用实例（参见 Stable Diffusion WebUI 的快速创建 ），能够登录腾讯云高性能应用服务控制台 。

操作步骤

方法1：通过 Gradio WebUI 访问

1. 登录 高性能应用服务控制台 。
2. 在**算力管理**页中选择**算力连接** > **Gradio WebUI** 。

3. 弹出如下图所示的新的页面，说明通过 Gradio WebUI 的访问已建立，您可以在此使用 WebUI 进行图片生成。生成指南可以参见 Stable Diffusion WebUI的提示词指南 。

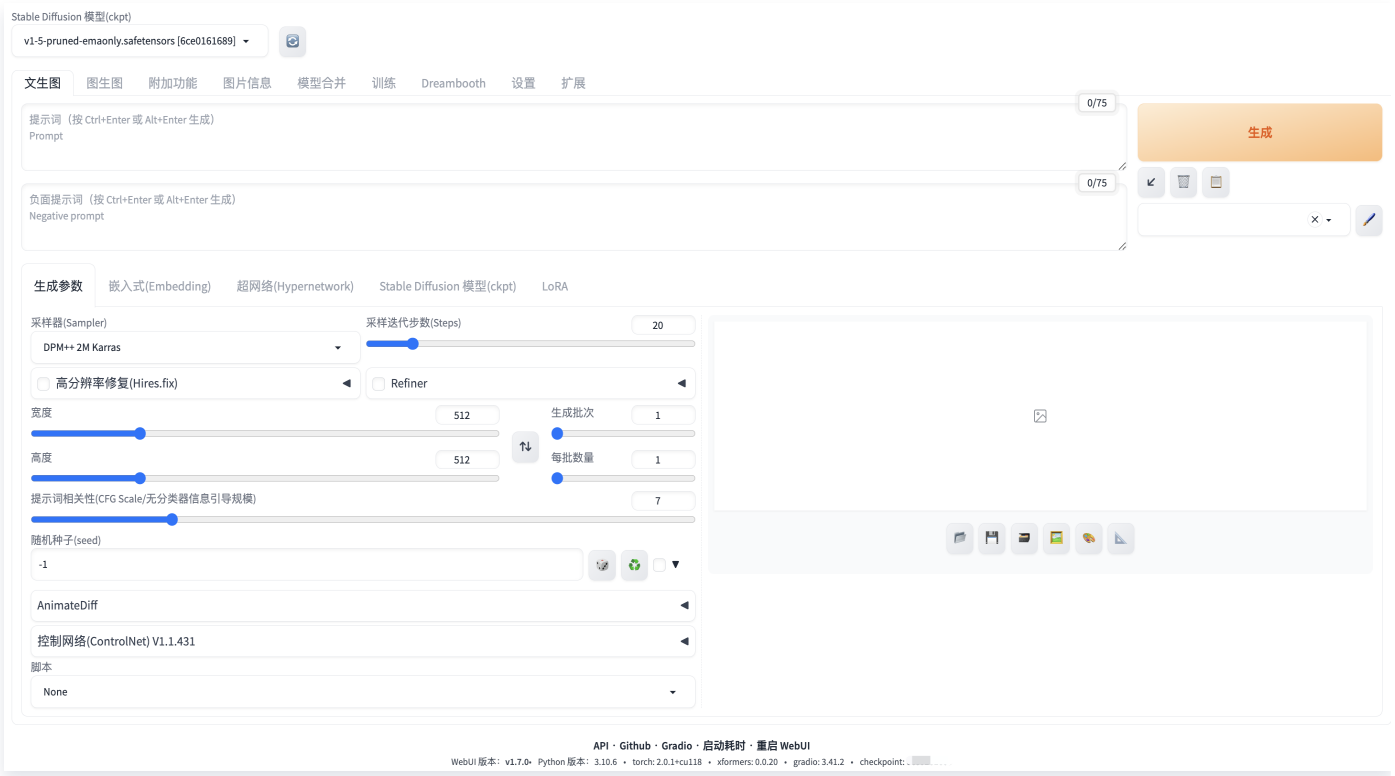

方法2：通过 JupyterLab 访问

1. 在**算力管理**页中选择**算力连接** > **JupyterLab** 。

2. 弹出如下图所示的新的页面，说明通过 **JupyterLab** 的访问已建立，您可以参阅这里的应用简述和快捷指令，利用 **Stable Diffusion WebUI** 的成熟环境，快速创建您自己的代码项目或应用服务。

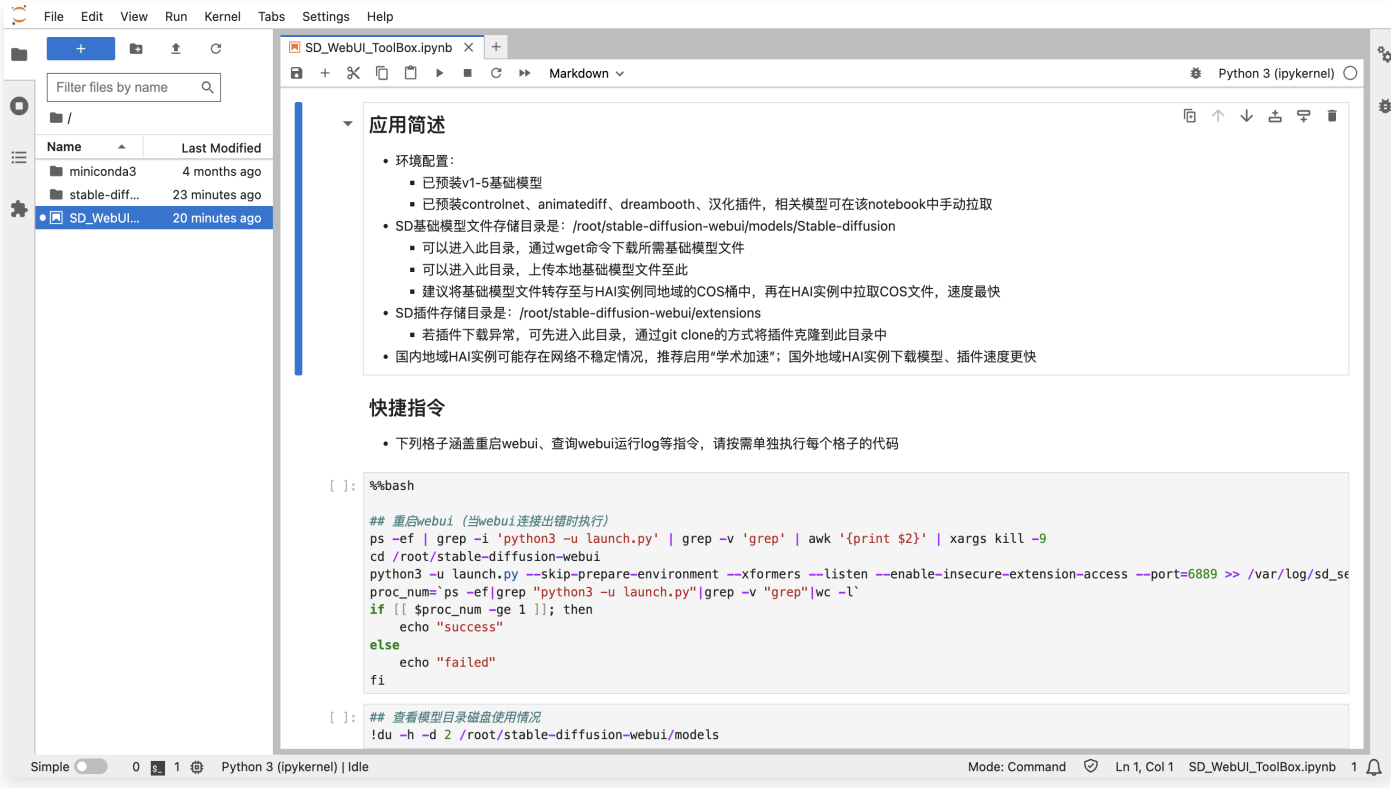

方法3：通过 SSH 访问

1. 在控制台的上边栏的右侧，找到并单击 站内信，找到应用实例创建时推送的消息，单击消息的任意位置进入该条消息。

2. 在该条消息中，找到**默认用户名**，**登录密码**，**IP地址（公）**这三个配置信息，并根据这些信息，进行 SSH 登录。

提示词指南

最近更新时间：2024-05-31 14:42:31

操作场景

使用高性能应用服务 HAI 部署的 **Stable Diffusion WebUI** 快速进行 AI 绘画。

前提条件

已经购买了 **Stable Diffusion WebUI** 应用实例（参见 Stable Diffusion WebUI 的快速创建），成功登录腾讯云高性能应用服务控制台并已经打开 **Gradio WebUI**（参见Stable Diffusion WebUI的访问方式）。

操作步骤

> **注意：**
> 提示词（Prompt）越多，AI 绘图结果会更加精准。另外，目前中文提示词效果不佳，建议使用英文提示词。

1. 在实例列表中选择**算力连接** > **Gradio WebUI** 并进入该实例的详情页。

2. 使用高性能应用服务 HAI 部署的 Stable Diffusion WebUI 快速进行 AI 绘画。

   我们使用 **Stable Diffusion WebUI** 生成一张猫咪图片，配置以下参数后，单击 **Generate** 即可。

参数名	描述	值
Prompt	主要描述图像，包括内容风格等信息，原始的 WebUI会对此处有字数的限制，您可以通过安装一些插件来突破字数的限制。	a pretty cat,cyberpunk art，kerem beyit，very cute robot zen,Playful,Independent，beeple
Negative prompt	为了提供给模型，您不需要的风格。	(deformed，distorted，disfigured:1.0)，poorly drawn，bad anatomy，wrong

		anatomy，extra limb，missing limb，floating limbs，(mutated hands and fingers:1.5)，disconnected limbs，mutation，mutated，ugly，disgusting，blurry，amputation，flowers，human，man，woman
CFG scale	分类器自由引导尺度，图像与提示符的一致程度。越低的值产生的结果越有创意，数值越大成图越贴近描述文本。一般设置为7。	7
Sampling method	扩散算法的去噪声采样模式会影响最终效果，不同的采样模式的结果会有很大差异，一般是默认选择 euler。	Euler a
Sampling steps	在使用扩散模型生成图片时所进行的迭代步骤。需要注意的是，更高的迭代步数会消耗更多的计算时间和成本，但并不意味着一定会得到更好的结果。	80
Seed	随机数种子，生成每张图片时的随机种子。	1791574510

3. 配置并生成如下图：

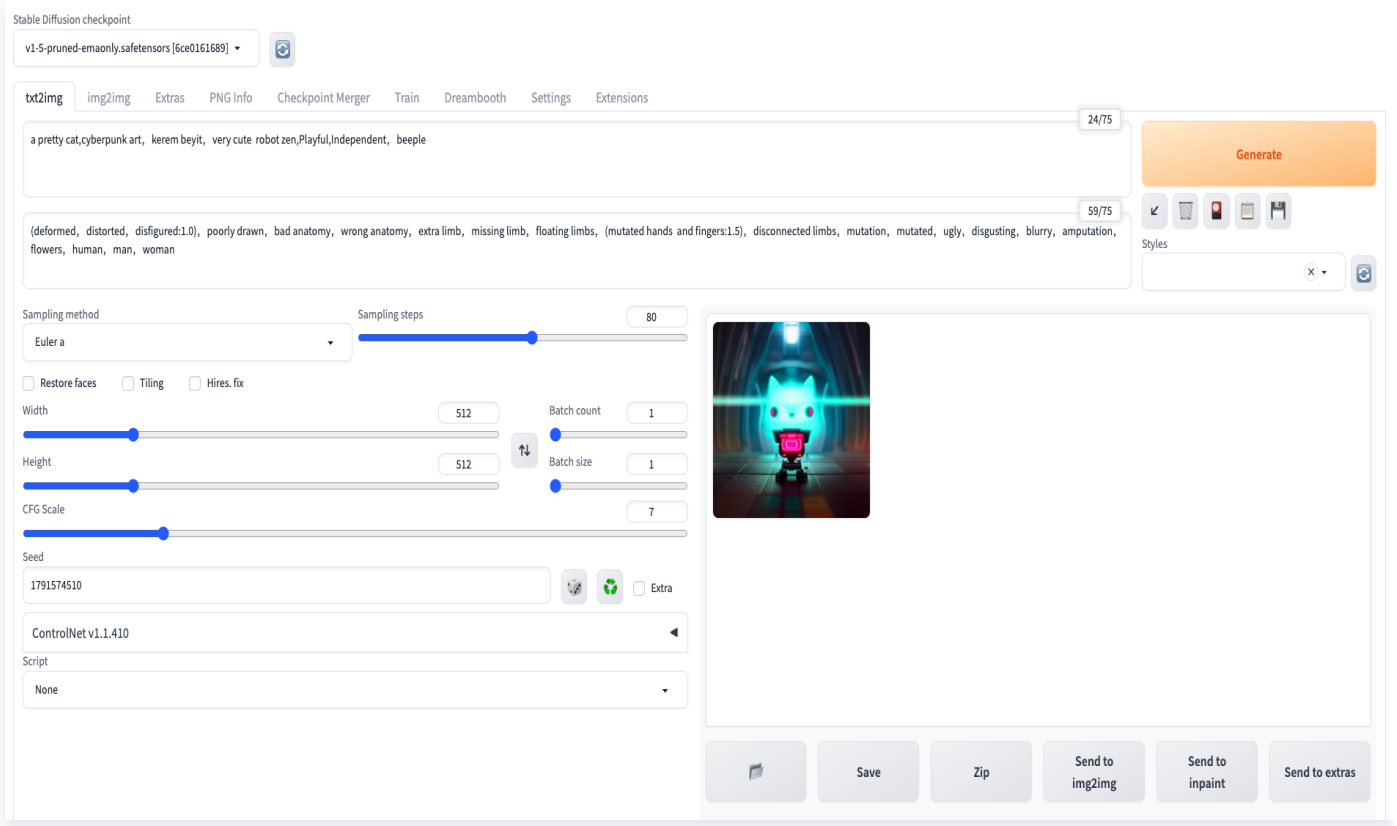
Stable Diffusion checkpoint
v1-5-pruned-emaonly.safetensors [6ce0161689]
txt2img
img2img
Extras
PNG Info
Checkpoint Merger
Train
Dreambooth
Settings
Extensions
a pretty cat,cyberpunk art, kerem beyit, very cute robot zen,Playful,Independent, beeple
24/75
(deformed, distorted, disfigured:1.0), poorly drawn, bad anatomy, wrong anatomy, extra limb, missing limb, floating limbs, (mutated hands and fingers:1.5), disconnected limbs, mutation, mutated, ugly, disgusting, blurry, amputation, flowers, human, man, woman
59/75
Generate
Styles
Sampling method
Euler a
Sampling steps
80
Restore faces
Tiling
Hires. fix
Width
512
Height
512
Batch count
1
Batch size
1
CFG Scale
7
Seed
1791574510
Extra
ControlNet v1.1.410
Script
None
Save
Zip
Send to img2img
Send to inpaint
Send to extras

导入外部模型

最近更新时间：2024-05-31 14:42:31

操作场景

您可以在Stable Diffusion WebUI中导入外部模型，以自定义您的使用体验。导入外部模型一般有**直接下载**、**通过JupyterLab上传**、**通过COS上传**、**通过第三方客户端**几种方式。

操作方式

方法一：直接下载（推荐境外地域实例使用）

1. 登录 高性能应用服务 HAI 控制台。
2. 选择需要连接的算力，然后单击**算力连接**。在下拉菜单中，单击 **JupyterLab**。

3. 进入 JupyterLab 后，选择 **Other** > **Terminal**，进入终端界面。

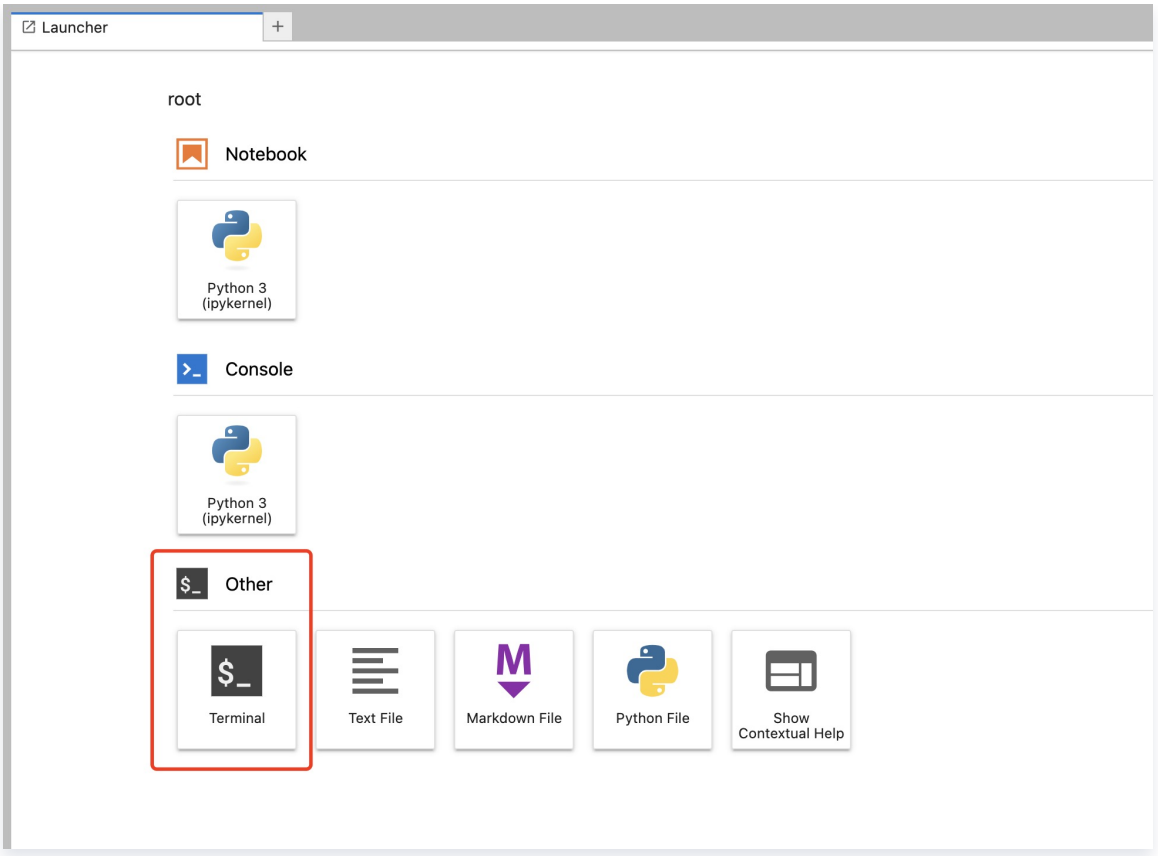

4. 进入后默认处于根目录下，输入如下指令进入 stable diffusion 的模型文件夹。

```
cd stable-diffusion-webui/models/Stable-diffusion
```

截图如下：

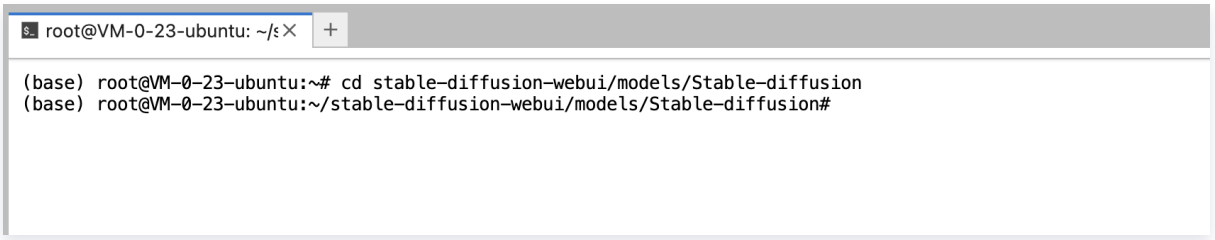

5. 获取预期使用的模型文件下载地址，在 `stable-diffusion-webui/models/Stable-diffusion` 目录下，将文件使用 `wget` 指令下载到目录中。

```
wget https://xyz.com/api/download/models/xxxx
```

6. 刷新 WebUI，即可使用新模型。

方式二： 通过 JupyterLab 上传（适合1GB以内小文件）

1. 将预期使用的模型提前下载到电脑本地。
2. 选择 JupyterLab 进行算力连接，在左侧文件目录处，依次双击进入如下文件夹：

```
root/stable-diffusion-webui/models/Stable-diffusion
```

3. 单击左侧文件目录处的**文件上传**，选择已下载的模型文件，即可将模型上传至高性能应用服务实例。

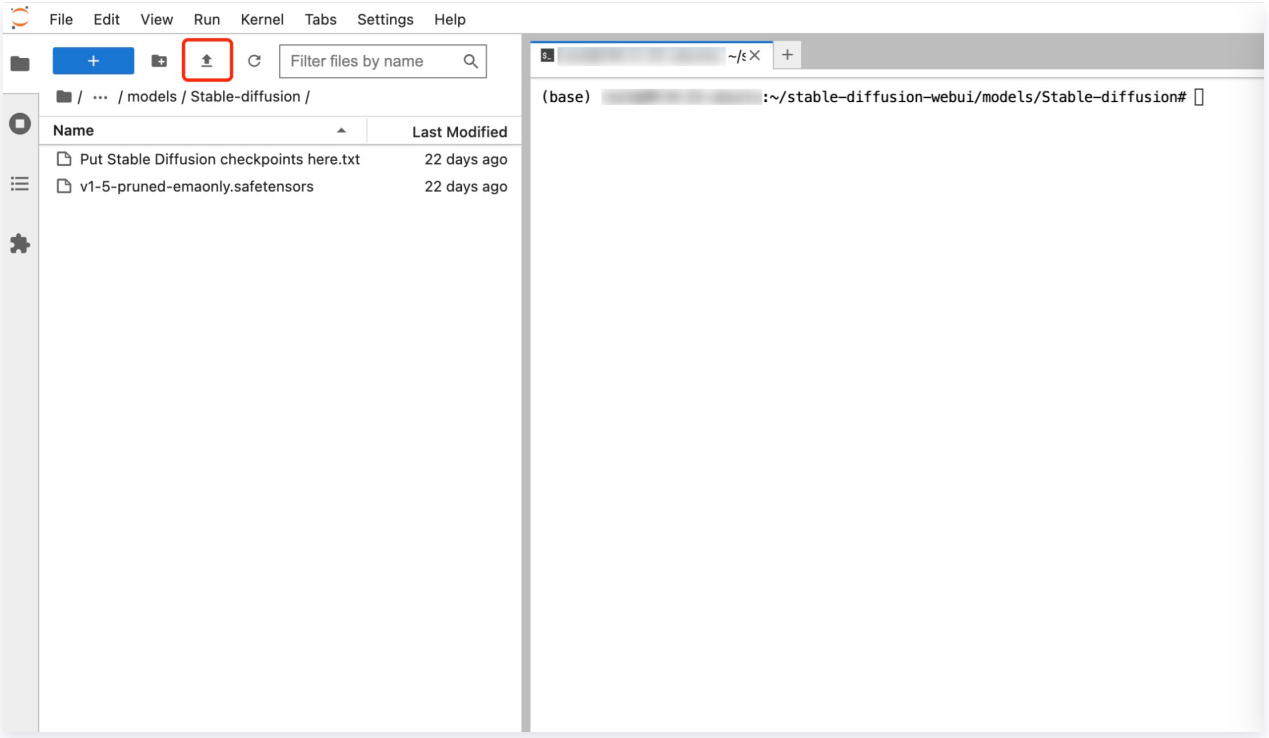

方式三：通过 COS 上传（适合大文件）

1. 将预期使用的模型提前下载到电脑本地。
2. 进入腾讯云对象存储控制台（cos），创建新存储桶并将模型文件上传至该存储桶。

> **注意：**
> 创建 COS 存储桶时，需注意与应用实例相同地域。否则会在拉取文件时产生额外流量费用。

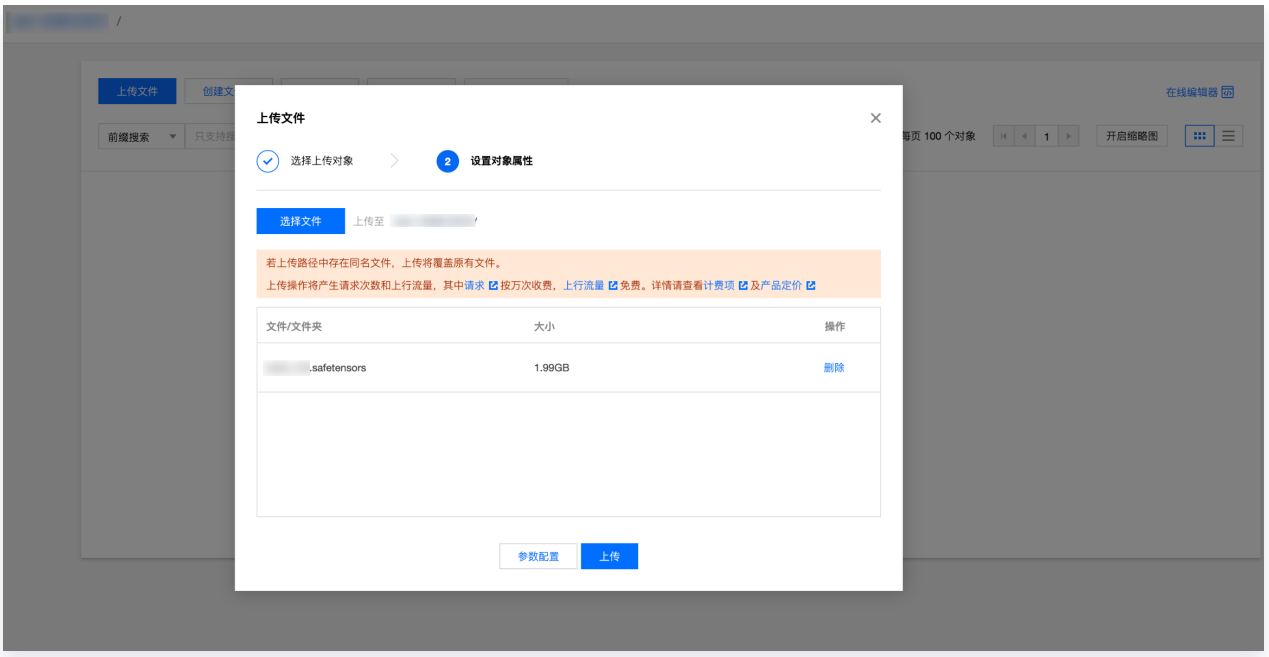

3. 选择 JupyterLab 进行算力连接，进入Terminal后，进入后默认处于根目录下，输入如下指令进入 stable diffusion 的模型文件夹。

```
cd stable-diffusion-webui/models/Stable-diffusion
```

4. 获取在存储桶中的模型文件下载地址，并在该目录下，将文件 wget 到高性能应用服务实例中。

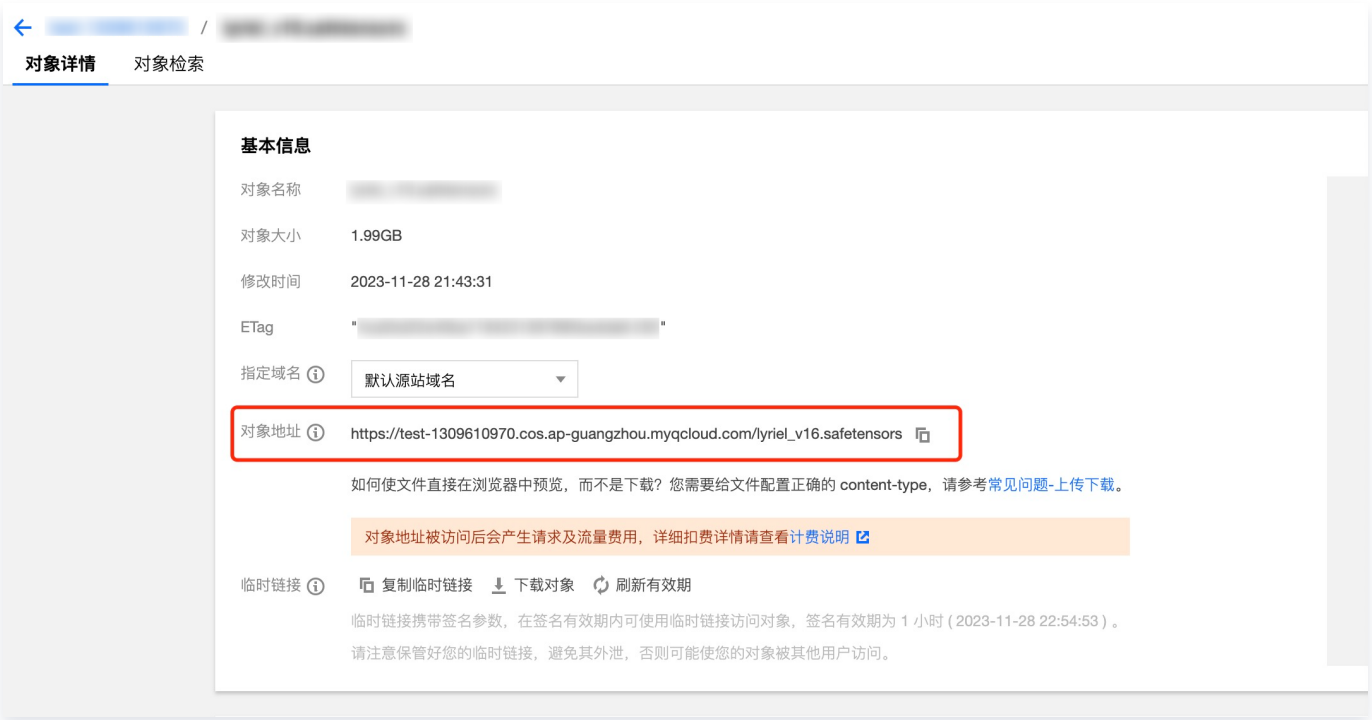


```
wget https://test-xxx.cos.ap-
guangzhou.myqcloud.com/lyriel_v16.safetensors
```

5. 刷新 WebUI，即可使用新模型。

方式四：通过第三方客户端

参见 通过 Filezilla 上传和下载数据 。

新增插件

最近更新时间：2024-05-31 14:42:31

操作场景

您可以在 Stable Diffusion WebUI 中导入新增插件，以拓展并自定义您的使用体验。

操作方法

方法一：通过 Gradio WebUI 安装（推荐境外地域实例使用）

1. 登录 高性能应用服务 HAI 控制台。
2. 选择对应的算力，单击**算力连接**。在下拉菜单中，单击 **Gradio WebUI**。

3. 进入 WebUI，单击进入 **extensions**，单击 **Load from** 后，选择预期使用的插件，单击 **Install**。

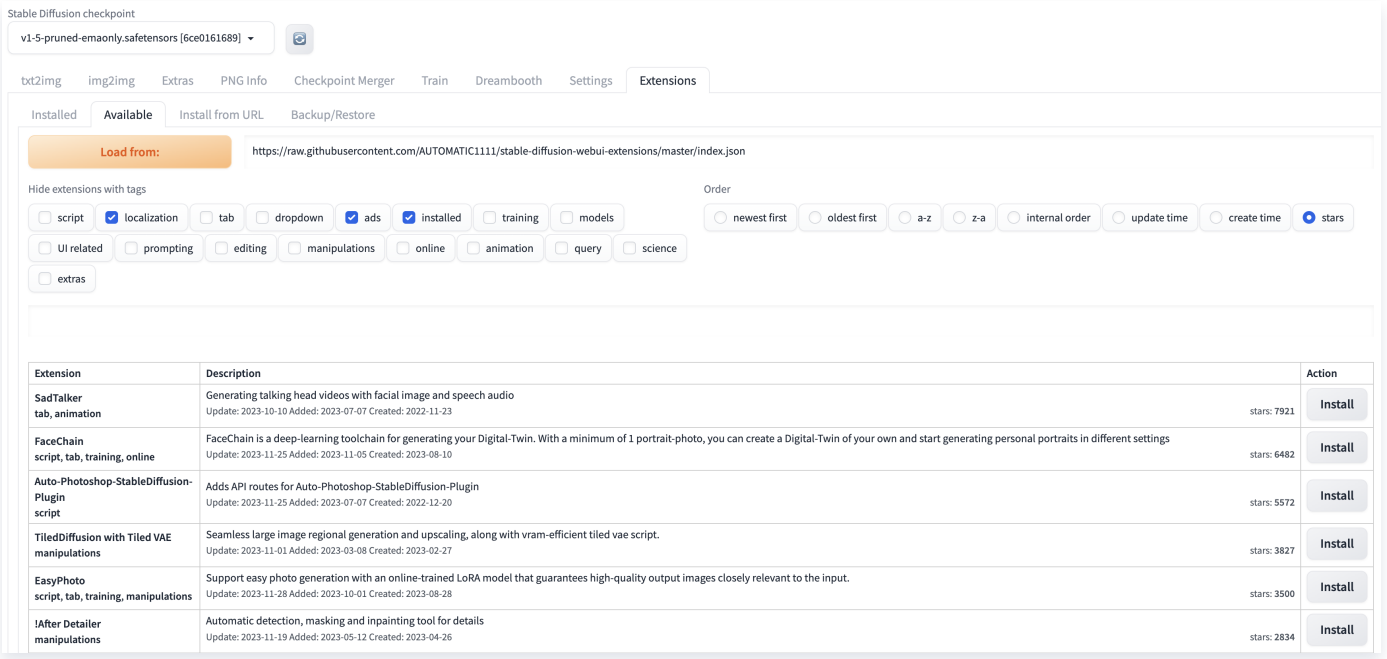

4. 安装完成后，单击进入 **Settings**，单击 **Reload UI** 后，插件即可生效。

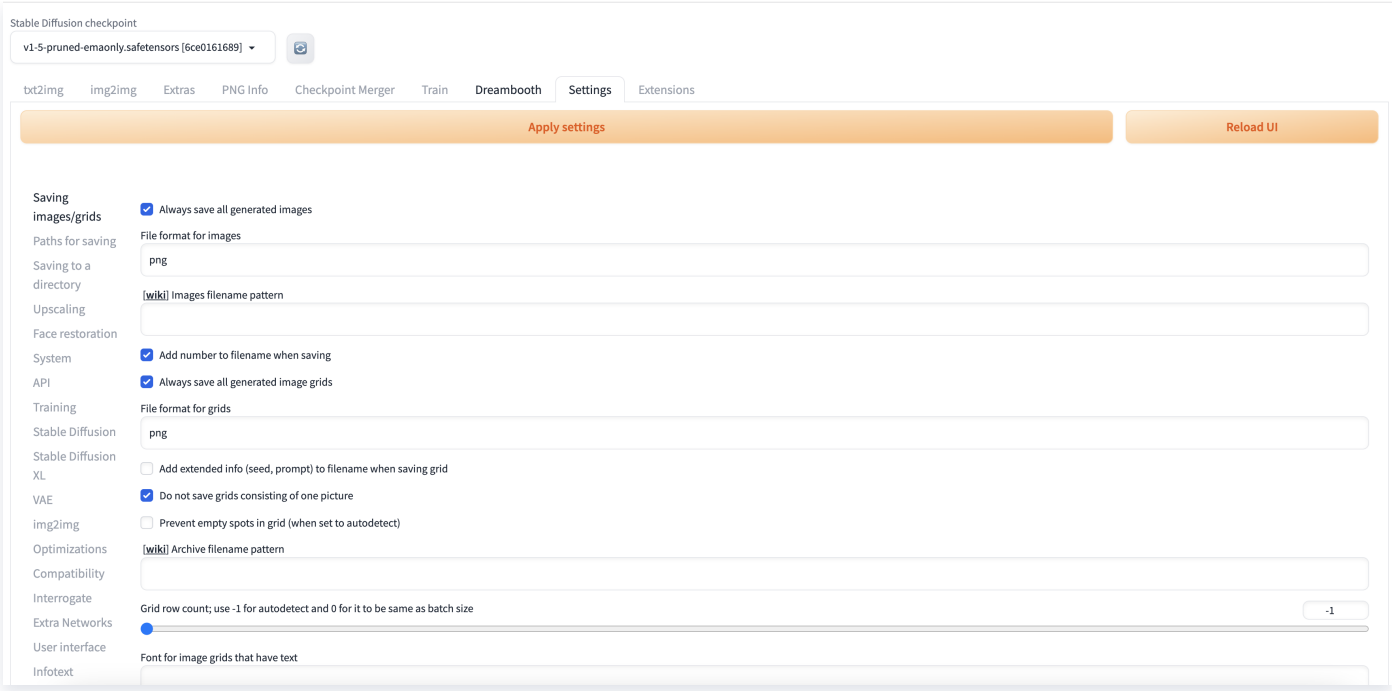

方法二：通过终端安装

1. 登录 高性能应用服务 HAI 控制台。
2. 选择需要连接的算力，然后单击**连接算力**。在下拉菜单中，单击 **JupyterLab**。

3. 选择 JupyterLab 进行算力连接，进入 Terminal。

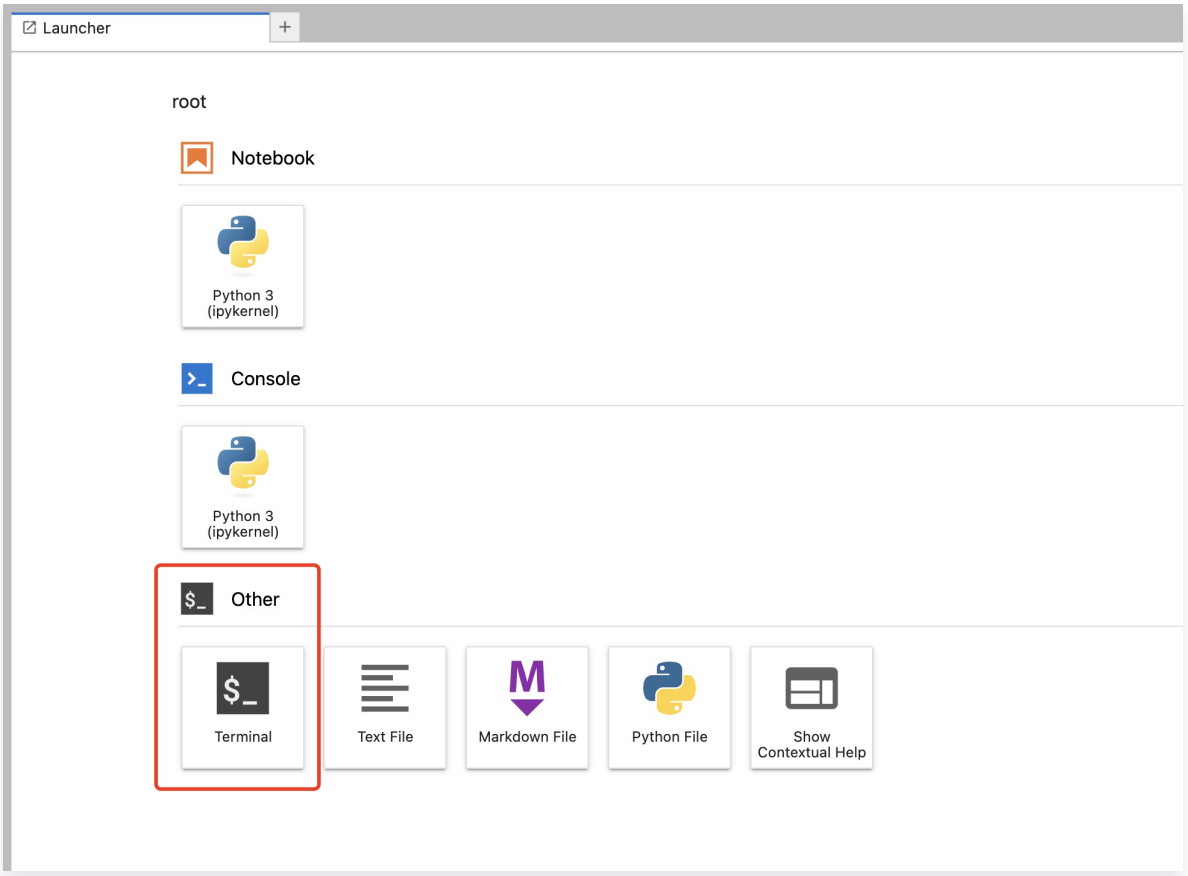

4. 进入后默认处于根目录下，输入如下指令进入 extensions 文件夹。

```
cd stable-diffusion-webui/extentions
```

5. 获取预期使用的插件下载地址，在 `stable-diffusion-webui/extensions` 目录下，将文件使用 `git clone` 指令下载到目录中。

```
git clone https://github.com/OpenTalker/SadTalker
```

6. 刷新 WebUI，即可使用新插件。

其他常见操作

最近更新时间：2024-05-31 14:42:31

本文将介绍常用使用 Stable Diffusion 的其他常见操作，包括重启 WebUI、查看运行日志、清空垃圾箱、拉取常见模型等 。

重启 WebUI

若您在使用过程中遇到 WebUI 界面无法正常打开，可进入 Terminal，通过如下指令重新启动 WebUI 服务。

```
cd stable-diffusion-webui
(python3 -u launch.py --skip-prepare-environment --xformers --listen --
enable-insecure-extension-access --port=6889 >> /var/log/sd_service.log
2>&1  &) && tail -f /var/log/sd_service.log
```

查看 WebUI 运行日志

若您希望查看 WebUI 运行状态，包括模型加载、图片生成、插件下载进度等内容，可进入 Terminal，通过如下指令查看 WebUI 运行日志。

```
cd stable-diffusion-webui
tail -f /var/log/sd_service.log
```

查看模型目录磁盘使用情况

这个命令可以查看某个目录的磁盘占用情况。

```
du -h -d 2 /root/stable-diffusion-webui/models
```

删除jupyter垃圾箱内文件

通过 jupyterLab 删除的文件，会进入jupyter的垃圾箱，仍然占用储存空间，可以通过如下命令清空垃圾箱来释放储存空间。

```
tail -f /var/log/sd_service.log
```

拉取模型

执行下列命令，可快速拉取预存模型。

1. 下载ControlNet及预处理器（适配SD1.5及SDXL，需 23GB 存储空间）。

```
wget -N http://mirrors.tencentyun.com/install/HAI/install_hai_tools.sh
-P /tmp && bash /tmp/install_hai_tools.sh && python3
/root/hai_application/qcloud_hai/hai_tools/download_models_main.py --
model-class controlnet Annotators
```

2. 下载常用基础模型（SDXL、anthingv5，需 8.5GB 存储空间）。

```
wget -N http://mirrors.tencentyun.com/install/HAI/install_hai_tools.sh
-P /tmp && bash /tmp/install_hai_tools.sh && python3
/root/hai_application/qcloud_hai/hai_tools/download_models_main.py --
model-class checkpoint
```

3. 下载常用组件（VAE、embeddings、lcm_lora，需 700MB 存储空间）。

```
wget -N http://mirrors.tencentyun.com/install/HAI/install_hai_tools.sh
-P /tmp && bash /tmp/install_hai_tools.sh && python3
/root/hai_application/qcloud_hai/hai_tools/download_models_main.py --
model-class vae embeddings lora
```

4. 下载animatediff模型（需 1.7GB 存储空间）。

```
wget -N http://mirrors.tencentyun.com/install/HAI/install_hai_tools.sh
-P /tmp && bash /tmp/install_hai_tools.sh && python3
/root/hai_application/qcloud_hai/hai_tools/download_models_main.py --
model-class animatediff_model
```

ChatGLM3 6B 快速创建

最近更新时间：2024-05-17 14:26:31

操作场景

本次介绍 腾讯云高性能应用服务 HAI ChatGLM3-6B 应用实例的购买流程。

操作步骤

1. 登录 高性能应用服务控制台 。
2. 单击**新建**，进入 高性能应用服务购买页面 。

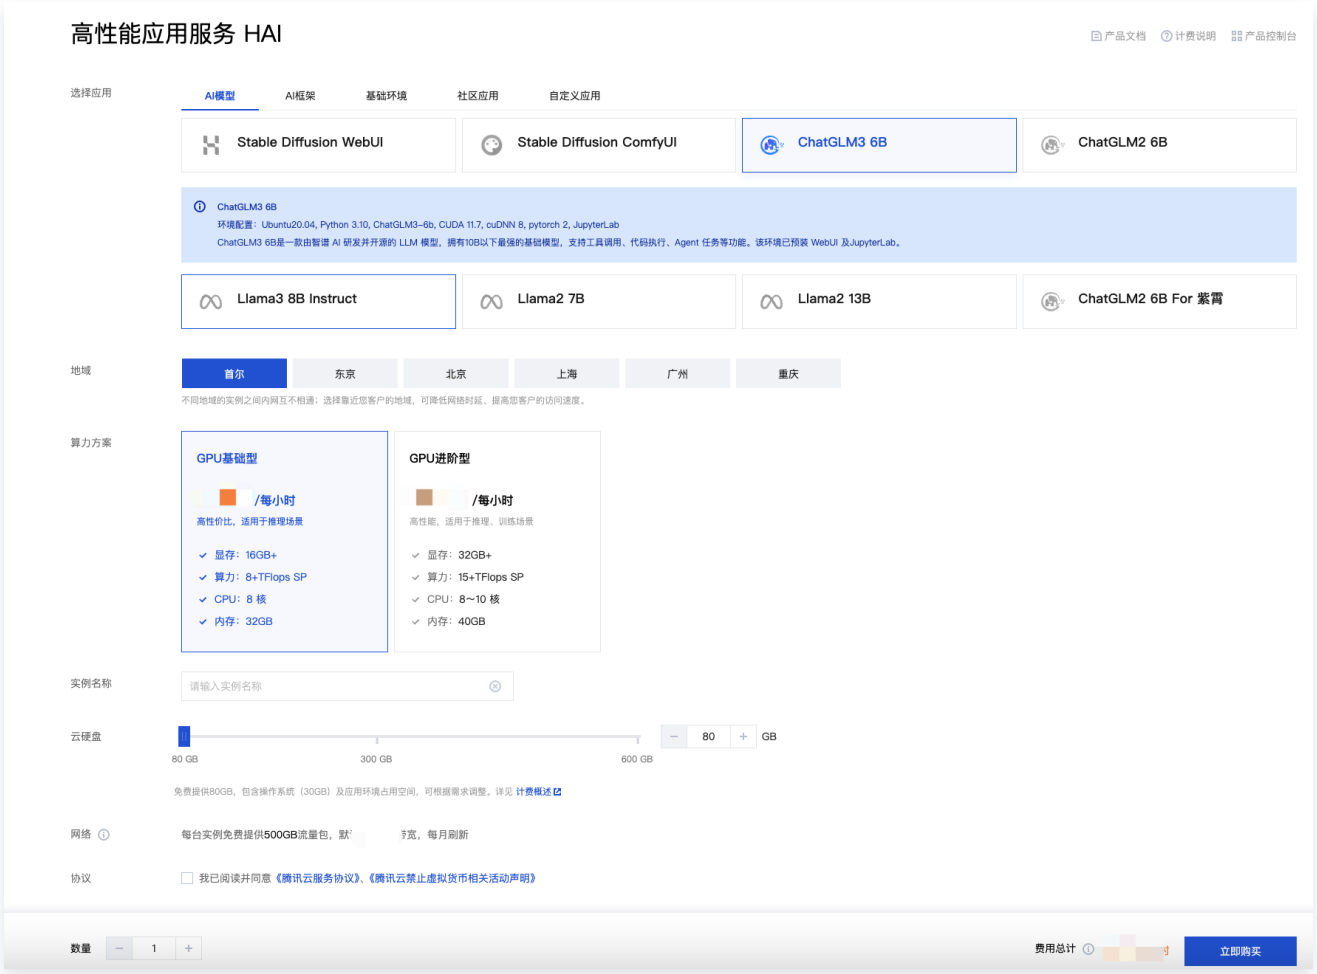

- **选择应用：**选择AI模型，应用选择 ChatGLM3-6B。
- **地域：**建议选择靠近自己实际地理位置的地域，降低网络延迟、提高您的访问速度。
- **算力方案：**支持基础型及进阶型两类算力方案，本次算力方案选择进阶型，生成图片效率更高。
- **实例名称：**自定义实例名称，若不填则默认使用实例 ID 替代。
- **硬盘：**默认提供 80GB 免费空间，可根据实际使用需求进行调整。

- **网络：**每台实例每月免费提供 500GB 流量包，默认10Mbps 带宽，每月刷新。
- **购买数量：**默认1台。

3. 单击**立即购买**。
4. 核对配置信息后，单击**提交订单**，并根据页面提示完成支付。
5. 等待创建完成。单击实例**任意位置**并进入该实例的详情页。

6. 您可以在此页面查看 ChatGLM3-6B 详细的配置信息，到此为止，说明您的 ChatGLM3-6B 应用实例购买成功。

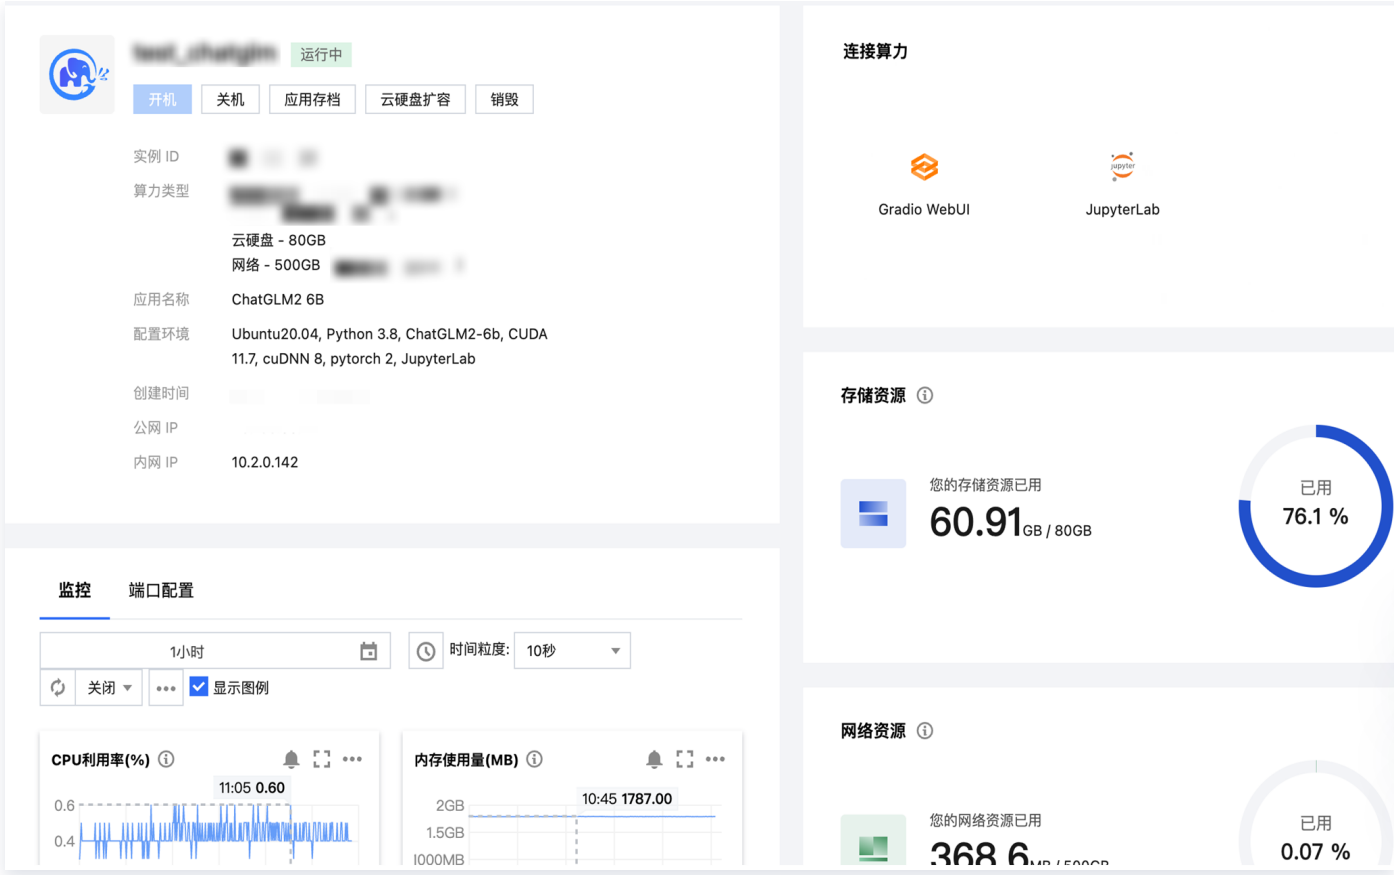
运行中
开机
关机
应用存档
云硬盘扩容
销毁
实例 ID
算力类型
云硬盘 - 80GB
网络 - 500GB
应用名称
ChatGLM2 6B
配置环境
Ubuntu20.04, Python 3.8, ChatGLM2-6b, CUDA 11.7, cuDNN 8, pytorch 2, JupyterLab
创建时间
公网 IP
内网 IP
10.2.0.142
连接算力
Gradio WebUI
JupyterLab
存储资源
您的存储资源已用
60.91GB / 80GB
已用
76.1 %
监控
端口配置
1小时
时间粒度:
10秒
关闭
显示图例
CPU利用率(%)
11:05 0.60
0.6
0.4
内存使用量(MB)
10:45 1787.00
2GB
1.5GB
1000MB
网络资源
您的网络资源已用
已用
0.07 %

访问方式

最近更新时间：2024-05-17 14:26:31

操作场景

购买 ChatGLM3-6B 应用实例后，我们有Gradio WebUI、JupyterLab、SSH 3 种方式访问该应用实例，以下将逐一介绍。

前提条件

已经购买了 ChatGLM3-6B 应用实例（参见 ChatGLM3 6B 的快速创建 ），能够登录腾讯云 高性能应用服务控制台 。

操作步骤

方法1：通过 Gradio WebUI 访问

1. 登录 高性能应用服务控制台 。
2. 在**算力管理**页中选择**算力连接** > **Gradio WebUI** 。

3. 弹出如下图所示的新的页面，说明通过 Gradio WebUI 的访问已建立，您可以在此和 ChatGLM3-6B 进行畅聊。

页面的右下角有三个参数配置，它们的含义如下：

- **Maximum length**：控制生成文本的长度。增加这个值会允许模型生成更长的文本，但可能会增加生成无关或重复内容的风险。减少这个值可以更快地得到结果，但可能会牺牲文本的完整性。
- **Top P**：影响生成文本的多样性和集中度。调高这个值会使得生成的文本更加多样化。调低这个值会使得生成的文本更加集中于最常见的选择，可能更符合预期但也可能显得比较单调。
- **Temperature**：控制生成文本的创造性和稳定性。调高这个值适合需要创意输出的场景，会增加生成文本的创造性和不可预测性。调低这个值适合需要精确和一致性结果的场景，会使得输出更加稳定和可预测。

方法2：通过 JupyterLab 访问

1. 在**算力管理**页中选择**算力连接** > **JupyterLab** 。

2. 弹出如下图所示的新的页面，说明通过 **JupyterLab** 的访问已建立，您可以利用 **ChatGLM-6B** 的成熟环境，快速创建您自己的代码项目或应用服务。

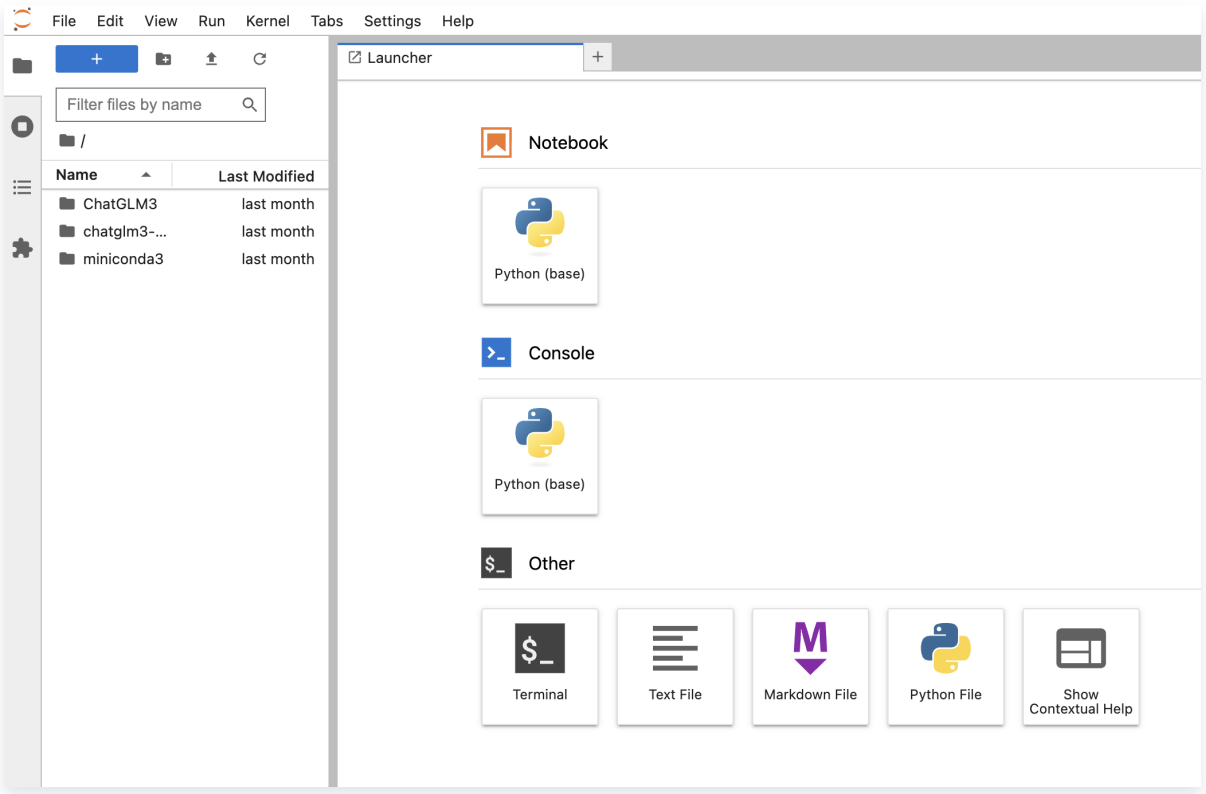

方法3：通过 SSH 访问

1. 在控制台的上边栏的右侧，找到并点击 站内信，找到应用实例创建时推送的消息，单击消息的任意位置进入该条消息。

2. 在该条消息中，找到**默认用户名**，**登录密码**，**IP地址（公）**这三个配置信息，并根据这些信息，进行 SSH 登录。

手动中断与重启 Gradio WebUI 服务

最近更新时间：2024-05-15 16:02:41

操作场景

腾讯云高性能应用服务 HAI 是为开发者量身打造的澎湃算力平台。HAI 的 ChatGLM3-6B 应用，预装了支持 ChatGLM3-6B 模型运行的全部环境依赖。应用实例启动时，默认启动了 Gradio WebUI 服务，该服务对显存有一定的占用。
除了使用 HAI 官方的 Gradio WebUI 外，用户也可以手动中断 Gradio WebUI 服务对显存的占用，以利用 HAI 的预装环境依赖，部署自定义的代码项目。

中断 Gradio WebUI 服务

步骤1：打开终端

通过 JupyterLab 打开终端

1. 在 腾讯云控制台 的页面，找到 ChatGLM3-6B 应用实例，进入实例管理页面，单击红框所示的 JupyterLab 连接算力。

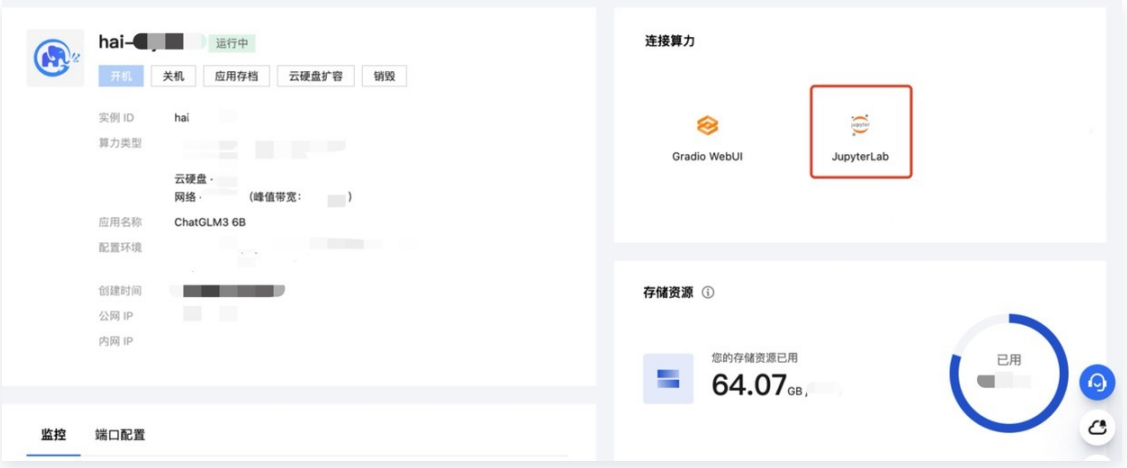

2. 在弹出的 JupyterLab 页面中，选择 Terminal。

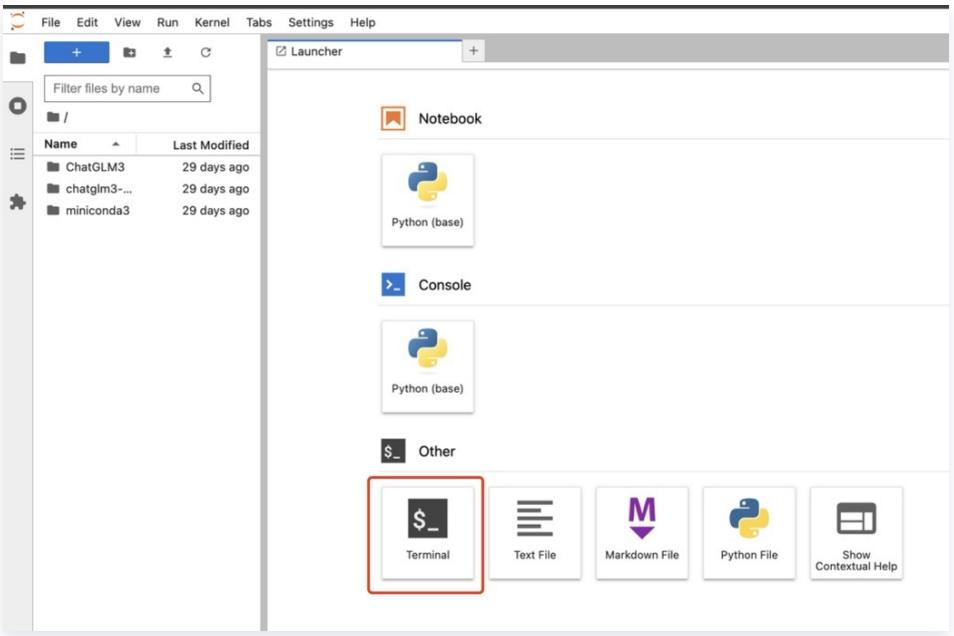

成功进入终端。

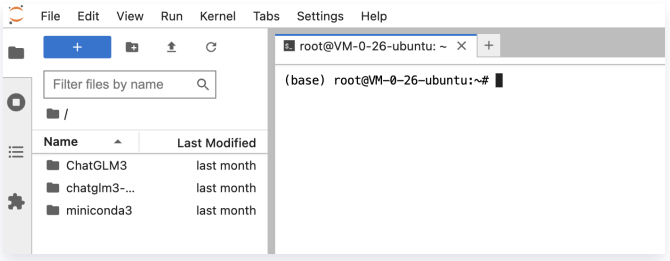

通过 SSH 客户端程序使用终端

或者，您可以在腾讯云的站内信中找 ChatGLM3-6B 应用实例对应的公网 IP、用户名和密码，通过 SSH 客户端程序进入终端。

步骤2：查找 Gradio WebUI 对应的进程

1. 在终端输入如下命令，查看活动进程：

```
ps aux
```

得到的活动进程信息展示如下：

```
(base) root@VM-0-2-ubuntu:~# ps aux
USER         PID %CPU %MEM    VSZ   RSS TTY      STAT START   TIME COMMAND
root           1  0.0  0.0    216     4 ?        Ss   06:28   0:00 /etc/.hai/dumb-init -- /usr/local/bin/application_init.sh
root           6  0.0  0.0   3976  2832 pts/0    Ss+  06:28   0:00 /bin/bash /usr/local/bin/application_init.sh
root           8  0.0  0.0  29368 24584 pts/0    S+   06:28   0:00 /etc/.hai/miniconda3/bin/python3 /etc/.hai/miniconda3/bin/supervisord -c /etc/su
root           9  0.0  0.0   4204  3072 pts/0    S    06:28   0:00 /bin/bash /usr/local/bin/launch_chatglm3_6b_webui.sh
root          10  0.0  0.0   4204  2996 pts/0    S    06:28   0:00 /bin/bash /usr/local/bin/launch_jupyter.sh
root          11  0.0  0.0  12184  6792 pts/0    S    06:28   0:00 sshd: /usr/sbin/sshd -D [listener] 0 of 10-100 startups
root          12  0.1  0.2 478872 77272 pts/0    Rl   06:28   0:01 /etc/.hai/miniconda3/bin/python3 /etc/.hai/miniconda3/bin/jupyter-lab --allow-ro
root          13  0.0  0.0   2756   516 pts/0    S    06:28   0:00 tee -a /var/log/jupyter_service.log
root          14  2.2  7.4 25491696 2391344 pts/0 Sl  06:28   0:26 python3 -u hai_web_demo.py --listen --port=6889
root          15  0.0  0.0   2756   524 pts/0    S    06:28   0:00 tee -a /var/log/chatglm3_gradio_service.log
root          58  1.3  0.0   4468  3540 pts/1    Ss+  06:47   0:00 /bin/bash -l
root          77 25.0  0.0   4468  3644 pts/2    Ss   06:47   0:00 /bin/bash -l
root          93  0.0  0.0   6124  3008 pts/2    R+   06:47   0:00 ps aux
```

2. 找到 COMMAND 列中，涉及 `hai_web_demo.py` 字样的进程，记录其进程 PID，本例中进程 PID 为 `14` 。

步骤3：终止 Gradio WebUI 对应的进程

在终端输入如下命令，终止 Gradio WebUI 对应的进程。请将命令中的 `xxx` 替换为上一步查找到的进程 PID。

```
kill -9 xxx
```

> **注意：**
> 终止错误的进程 PID 可能影响系统稳定性，请务必确认进程 PID 序号后再执行终止命令。

步骤4：查看显存占用情况

在终端输入如下命令，查看 GPU 使用情况。

```
nvidia-smi
```

得到的 GPU 使用情况展示如下，如果成功终止 Gradio WebUI 对应的进程，Memory-Usage 一项对应的显存占用会变得很小，本示例中仅为 2M。

```
(base) root@VM-0-2-ubuntu:~# nvidia-smi
Wed May 15 06:49:56 2024
+-----------------------------------------------------------------------------+
| NVIDIA-SMI 525.105.17   Driver Version: 525.105.17   CUDA Version: 12.0     |
|-------------------------------+----------------------+----------------------+
| GPU  Name        Persistence-M| Bus-Id        Disp.A | Volatile Uncorr. ECC |
| Fan  Temp  Perf  Pwr:Usage/Cap|         Memory-Usage | GPU-Util  Compute M. |
|                               |                      |               MIG M. |
|===============================+======================+======================|
|   0  Tesla T4            On   | 00000000:00:09.0 Off |                    0 |
| N/A   43C    P0    26W /  70W |      2MiB / 15360MiB |      0%      Default |
|                               |                      |                  N/A |
+-------------------------------+----------------------+----------------------+

+-----------------------------------------------------------------------------+
| Processes:                                                                  |
|  GPU   GI   CI        PID   Type   Process name                  GPU Memory |
|        ID   ID                                                   Usage      |
|=============================================================================|
|  No running processes found                                                 |
+-----------------------------------------------------------------------------+
```

如果没有终止 Gradio WebUI 对应的进程，Memory-Usage 一项对应的显存占用为下图所示，作为对比。

```
(base) root@VM-0-2-ubuntu:~# nvidia-smi
Wed May 15 06:49:43 2024
+-----------------------------------------------------------------------------+
| NVIDIA-SMI 525.105.17   Driver Version: 525.105.17   CUDA Version: 12.0     |
|-------------------------------+----------------------+----------------------+
| GPU  Name        Persistence-M| Bus-Id        Disp.A | Volatile Uncorr. ECC |
| Fan  Temp  Perf  Pwr:Usage/Cap|         Memory-Usage | GPU-Util  Compute M. |
|                               |                      |               MIG M. |
|===============================+======================+======================|
|   0  Tesla T4            On   | 00000000:00:09.0 Off |                    0 |
| N/A   42C    P0    26W /  70W |  12463MiB / 15360MiB |      0%      Default |
|                               |                      |                  N/A |
+-------------------------------+----------------------+----------------------+

+-----------------------------------------------------------------------------+
| Processes:                                                                  |
|  GPU   GI   CI        PID   Type   Process name                  GPU Memory |
|        ID   ID                                                   Usage      |
|=============================================================================|
+-----------------------------------------------------------------------------+
```

重启 Gradio WebUI 服务

中断 Gradio WebUI 服务后，您将不能在 HAI 实例的算力管理页面使用 Gradio WebUI。遵循如下流程可以重启该服务。请确保重启服务前，该 HAI 实例拥有充足的空余显存容量。

步骤1：服务重启

1. 在终端输入如下命令：

```
export MODEL_PATH='/root/chatglm3-6b-model' && export
TOKENIZER_PATH='/root/chatglm3-6b-model' && cd
/root/ChatGLM3/basic_demo/ && (python3 -u hai_web_demo.py --listen --
port=6889 >> /var/log/chatglm3_gradio_service.log 2>&1 &) && tail -f
/var/log/chatglm3_gradio_service.log
```

2. 以上命令实现了模型部署、指定端口监听、将控制台输出重定向到指定 log 文档等步骤，最终实现了 Gradio WebUI 服务重启。执行后，如果终端输出类似如下的字样，说明服务重启成功。

```
(base) root@VM-0-2-ubuntu:~# export MODEL_PATH='/root/chatglm3-6b-model' && export TOKENIZER_PATH='/root/chatglm3-6b-model' && cd /root/ChatGLM3/ba
sic_demo/ && (python3 -u hai_web_demo.py --listen --port=6889 >> /var/log/chatglm3_gradio_service.log 2>&1 &) && tail -f /var/log/chatglm3_gradio_s
ervice.log
Loading checkpoint shards: 100%|██████████| 7/7 [01:23<00:00, 11.86s/it]
Setting eos_token is not supported, use the default one.
Setting pad_token is not supported, use the default one.
Setting unk_token is not supported, use the default one.
Running on local URL:  http://0.0.0.0:6889

To create a public link, set `share=True` in `launch()`.
IMPORTANT: You are using gradio version 4.26.0, however version 4.29.0 is available, please upgrade.
--------
```

步骤2：验证重启

通过终端命令验证

> **说明：**

> 上一步启动服务的操作可能占据终端的输入输出流。可以同时按下 `control` 键和 `C` 键，取得终端的控制权。

在终端输入如下命令，查看显存占用情况。

```
nvidia-smi
```

得到如下终端输出，显示显存占用量有 12G 以上，说明 Gradio WebUI 服务已经重启。

```
+-----------------------------------------------------------------------------+
| NVIDIA-SMI 525.105.17   Driver Version: 525.105.17   CUDA Version: 12.0     |
|-------------------------------+----------------------+----------------------+
| GPU  Name        Persistence-M| Bus-Id        Disp.A | Volatile Uncorr. ECC |
| Fan  Temp  Perf  Pwr:Usage/Cap|         Memory-Usage | GPU-Util  Compute M. |
|                               |                      |               MIG M. |
|===============================+======================+======================|
|   0  Tesla T4            On   | 00000000:00:09.0 Off |                    0 |
| N/A   39C    P0    26W /  70W |  12463MiB / 15360MiB |      0%      Default |
|                               |                      |                  N/A |
+-------------------------------+----------------------+----------------------+

+-----------------------------------------------------------------------------+
| Processes:                                                                  |
|  GPU   GI   CI        PID   Type   Process name                  GPU Memory |
|        ID   ID                                                   Usage      |
|=============================================================================|
+-----------------------------------------------------------------------------+
```

通过访问腾讯云控制台该实例的 Gradio WubUI 功能验证

进入腾讯云控制台，找到该 HAI 实例的管理页面，单击红框所示的 Gradio WebUI 。

JupyterLab 页面正常弹出，可以正常对话，证明 Gradio WebUI 服务重启成功。

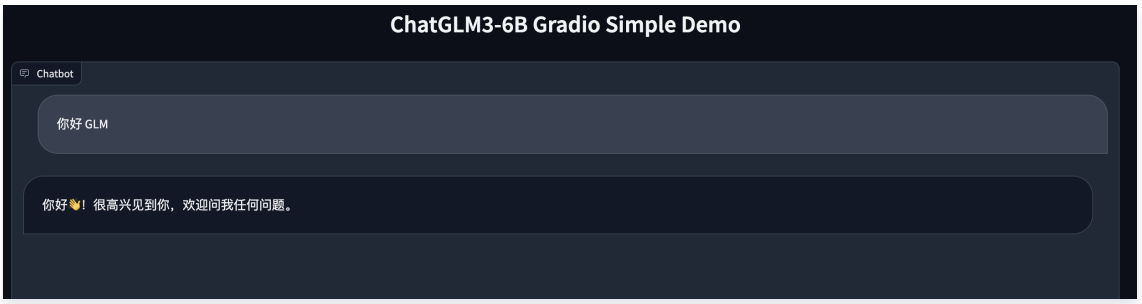
ChatGLM3-6B Gradio Simple Demo
Chatbot
你好 GLM
你好👋！很高兴见到你，欢迎问我任何问题。

在 HAI 环境中部署自定义项目

最近更新时间：2024-07-18 11:54:51

操作场景

腾讯云高性能应用服务 HAI 是为开发者量身打造的澎湃算力平台。无需复杂配置，便可享受即开即用的 GPU 云服务体验。HAI 的 ChatGLM3-6B 应用，预装了支持 ChatGLM3-6B 模型运行的全部环境依赖。
如果您想部署自定义的代码项目，您可参考如下的部署实例，利用 腾讯云高性能应用服务 HAI 的预装环境，无需进行复杂环境配置，实现即开即用的灵活部署。

部署示例

本次将通过简单的示例代码，用 `transfomers` 库加载预装的 ChatGLM3-6B 模型并进行文本生成，体验将 ChatGLM3-6B 集成到您自己的代码工作流。

步骤1：释放显存

1. 登录 高性能应用服务控制台 。
2. 在**算力管理页**中选择**算力连接 > JupyterLab** 。

3. 进入 **JupyterLab** ，打开**终端**，参见 手动中断与重启 Gradio WebUI 服务 ，中断 **Gradio WebUI** 以释放显存。

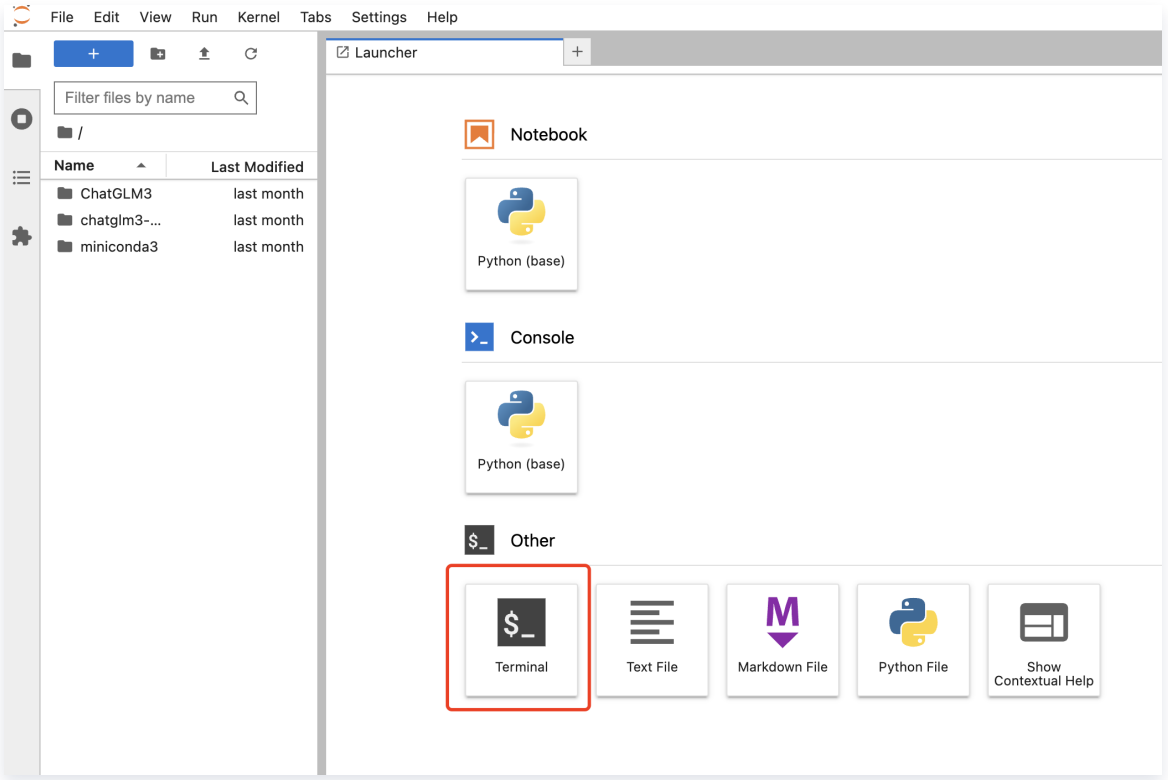

步骤2：部署实例代码

1. 在终端输入 `python` ，进入 python 命令行。

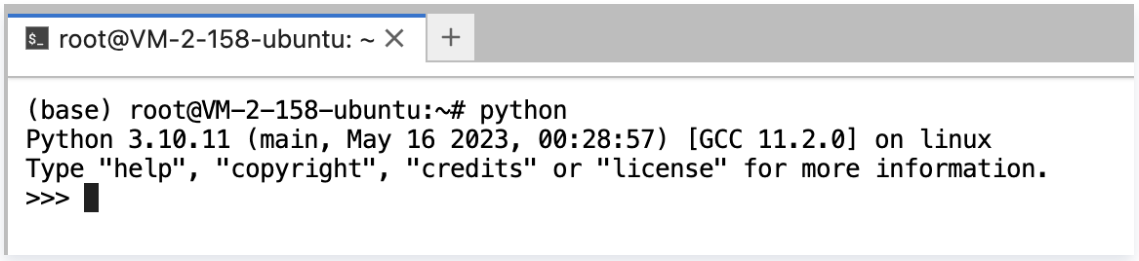

2. 从 `transformers` 库导入 `AutoModelForCausalLM` 和 `AutoTokenizer` 模块。

```
>>> from transformers import AutoModelForCausalLM, AutoTokenizer
```

3. 导入本地预装的 ChatGLM3-6B 模型和模型分词器，模型路径为 `/root/chatglm3-6b-model` 。

```
>>> model = AutoModelForCausalLM.from_pretrained("/root/chatglm3-6b-model", device_map="auto", trust_remote_code=True).to("cuda")
>>> tokenizer = AutoTokenizer.from_pretrained("/root/chatglm3-6b-model", padding_side="left", trust_remote_code=True)
```

4. 设置输入的文本，并获取文本生成的结果。

```
>>> model_inputs = tokenizer(["A list of colors: red, blue"],
return_tensors="pt").to("cuda")
>>> generated_ids = model.generate(**model_inputs)
>>> tokenizer.batch_decode(generated_ids, skip_special_tokens=True)[0]
```

得到的如下输出。

```
>>> tokenizer.batch_decode(generated_ids, skip_special_tokens=True)[0]
'[gMASK] sop A list of colors: red, blue, green, yellow, orange, purple, pink'
>>>
```

到此为止，您已经体验了利用大语言模型进行代码开发的一个简单完整流程！利用腾讯云高性能应用服务 HAI 的预装环境，实现即开即用，开发和部署灵活简单。

Pytorch 2.0.0 快速创建

最近更新时间：2024-05-17 14:26:31

操作场景

本次介绍 腾讯云高性能应用服务 HAI Pytorch 2.0.0 应用实例的购买流程。

操作步骤

1. 登录 高性能应用服务控制台 。
2. 单击**新建**，进入 高性能应用服务购买页面 。

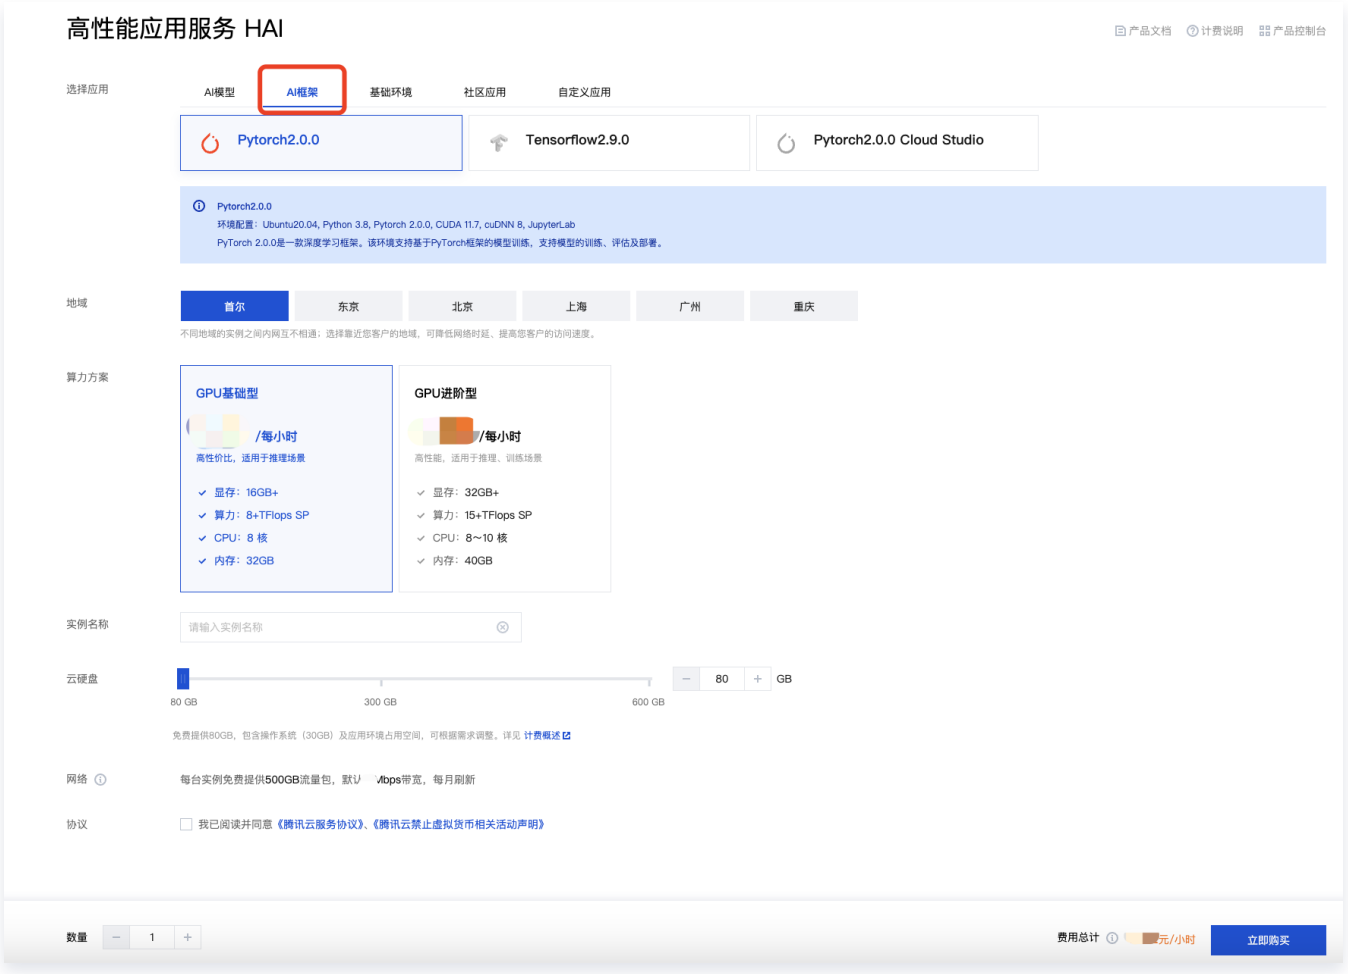

- **选择应用：**选择 AI 框架，应用选择 Pytorch 2.0.0。
- **地域：**建议选择靠近自己实际地理位置的地域，降低网络延迟、提高您的访问速度。
- **算力方案：**支持基础型及进阶型两类算力方案，本次算力方案选择进阶型，生成图片效率更高。
- **实例名称：**自定义实例名称，若不填则默认使用实例 ID 替代。
- **硬盘：**默认提供 80GB 免费空间，可根据实际使用需求进行调整。

- **网络：**每台实例每月免费提供 500GB 流量包，默认10Mbps 带宽，每月刷新。
- **购买数量：**默认1台。

3. 单击**立即购买**。
4. 核对配置信息后，单击**提交订单**，并根据页面提示完成支付。
5. 等待创建完成。单击实例**任意位置**并进入该实例的详情页。

6. 您可以在此页面查看 **Pytorch 2.0.0** 应用实例详细的配置信息，到此为止，说明您的 **Pytorch 2.0.0** 应用实例购买成功。

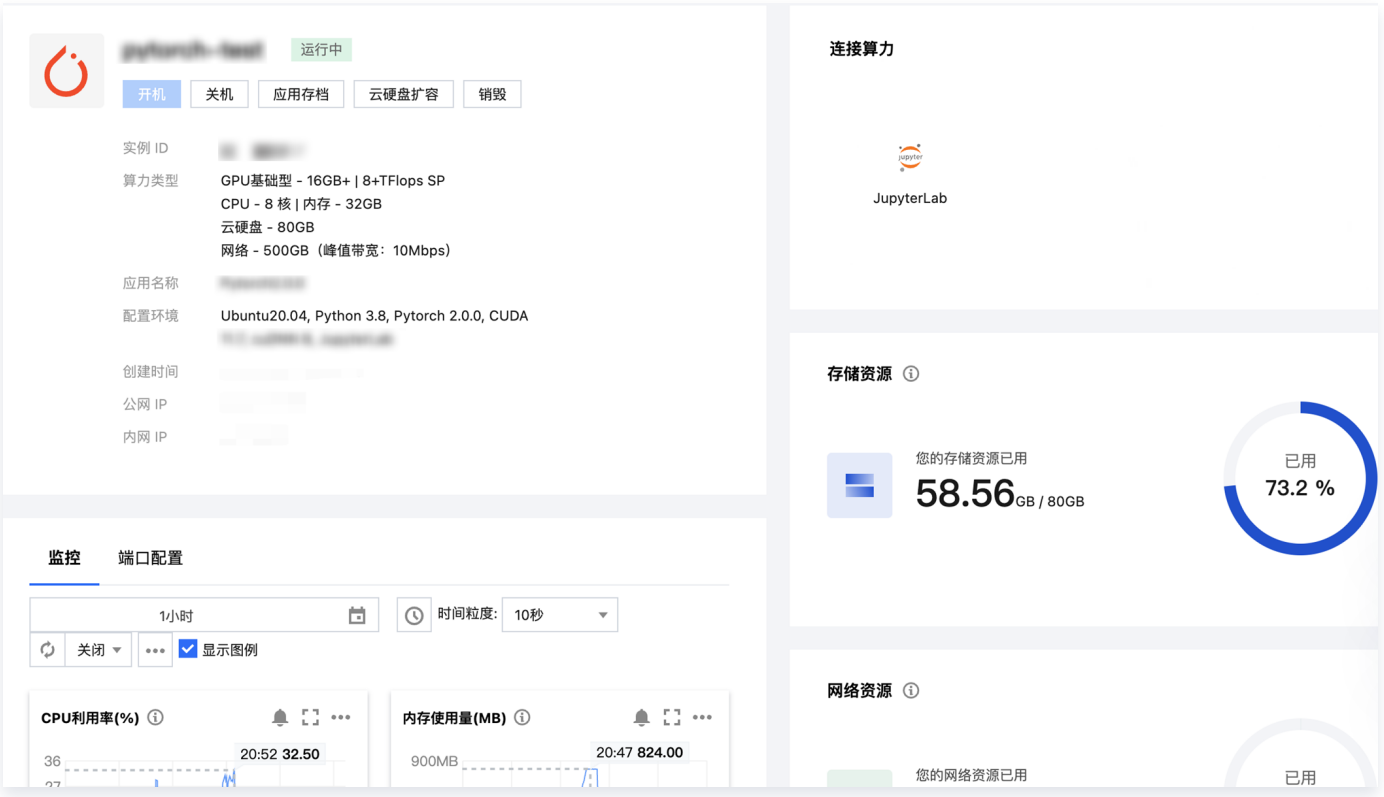

访问方式

最近更新时间：2024-05-17 14:26:31

操作场景

购买 Pytorch 2.0.0 应用实例后，我们有 JupyterLab 和 SSH 2 种方式访问该应用实例，以下将逐一介绍。

前提条件

已经购买了 Pytorch 2.0.0 应用实例（参见 Pytorch 2.0.0 的快速创建 ），能够登录腾讯云高性能应用服务控制台 。

操作步骤

方法1：通过 JupyterLab 访问

1. 登录 高性能应用服务控制台 。
2. 在**算力管理**页中选择**算力连接** > **JupyterLab** 。

3. 弹出如下图所示的新的页面，说明通过 **JupyterLab** 的访问已建立，您可以在这里快速创建您自己的代码项目或应用服务。

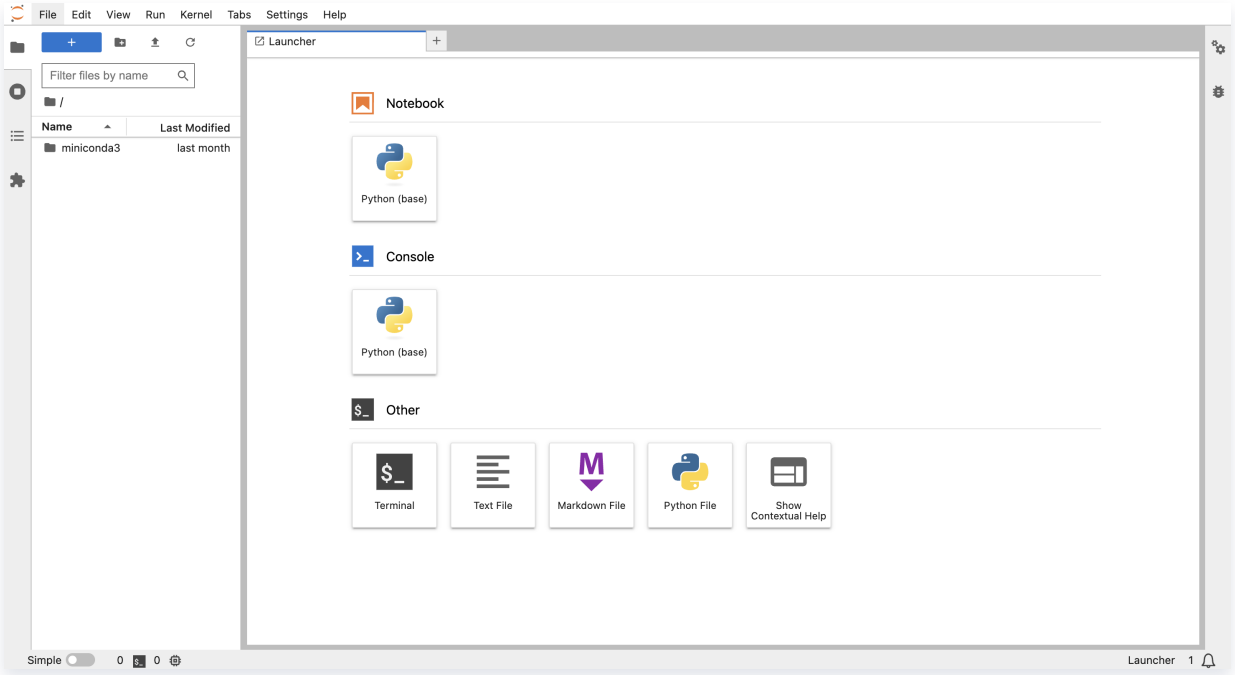

方法2：通过 SSH 访问

1. 在控制台的上边栏的右侧，找到并点击**站内信**，找到应用实例创建时推送的消息，单击消息的任意位置进入该条消息。

2. 在该条消息中，找到**默认用户名**，**登录密码**，**IP地址（公）**这三个配置信息，并根据这些信息，进行 SSH 登录。

管理系统 CUDA

最近更新时间：2024-05-17 14:26:31

CUDA 是 NVIDIA 开发的一种编程技术，它允许开发者使用 NVIDIA 的图形处理单元（GPU）进行高效的并行计算。CUDA 具有很多发行版本，用户在使用时 Pytorch 2.0.0 应用实例时，可能有对系统 CUDA 版本进行查看和修改的需求。本次，我们将介绍如何在 Pytorch 2.0.0 应用实例中查看和修改系统 CUDA。

查看系统支持的最高 CUDA 版本

1. 登录 高性能应用服务 HAI 控制台。
2. 选择需要连接的算力，然后单击**算力连接**。在下拉菜单中，单击 **JupyterLab**。

3. 进入 JupyterLab 后，选择 **Other** > **Terminal**，进入终端界面。

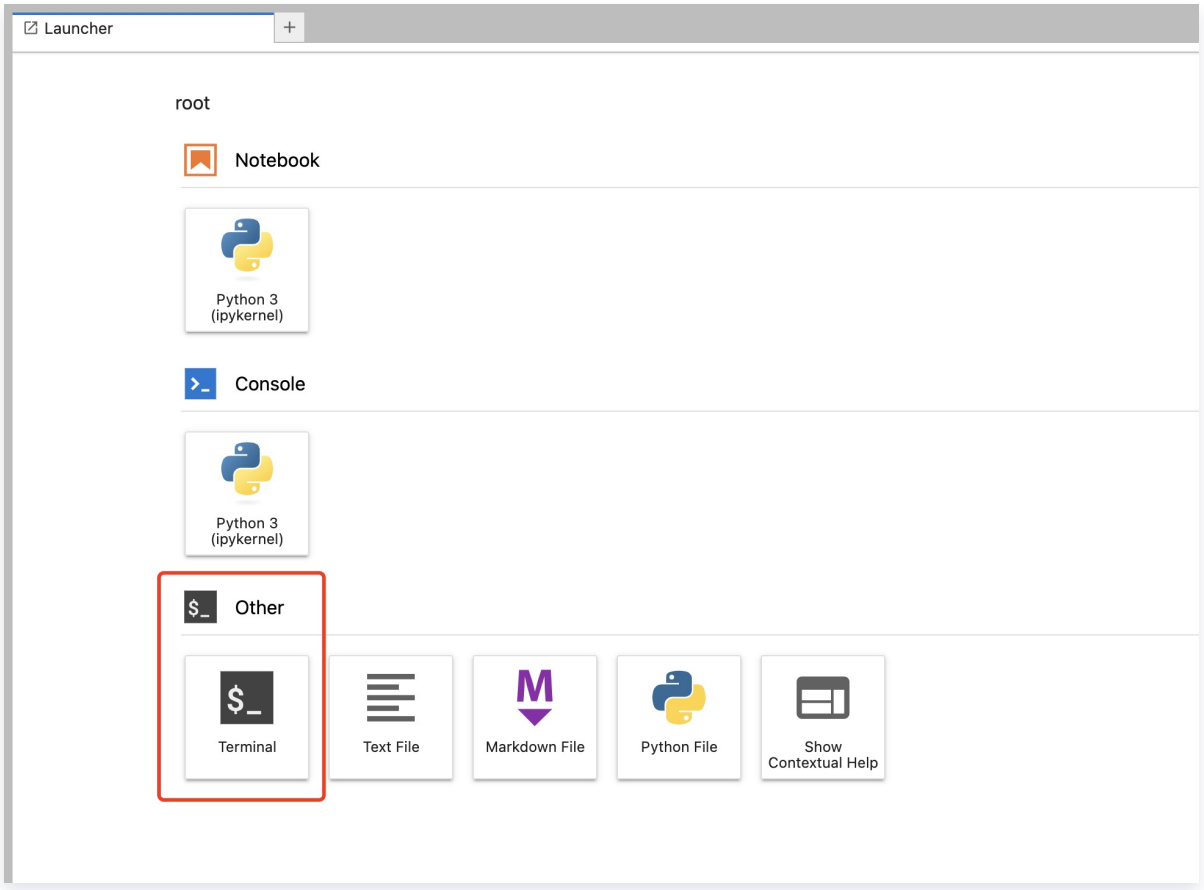

4. 在终端输入如下命令，查看系统 GPU 驱动版本。系统 GPU 驱动版本和系统支持的最高 CUDA 版本存在对应关系。

```
nvidia-smi
```

得到的终端输出如下，在这个例子中，Driver Version 为 `525.105.17`，CUDA Version 为 `12.0`。这里显示的 CUDA Version 指的是系统支持的最高 CUDA 版本，兼容 CUDA <= 12.0 的任何版本。

```
(base) root@VM-0-9-ubuntu:~# nvidia-smi
Wed May 15 07:03:12 2024
+-----------------------------------------------------------------------------+
| NVIDIA-SMI 525.105.17   Driver Version: 525.105.17   CUDA Version: 12.0     |
|-------------------------------+----------------------+----------------------+
| GPU  Name        Persistence-M| Bus-Id        Disp.A | Volatile Uncorr. ECC |
| Fan  Temp  Perf  Pwr:Usage/Cap|         Memory-Usage | GPU-Util  Compute M. |
|                               |                      |               MIG M. |
|===============================+======================+======================|
|   0  Tesla T4            On   | 00000000:00:09.0 Off |                    0 |
| N/A   30C    P8     9W /  70W |      2MiB / 15360MiB |      0%      Default |
|                               |                      |                  N/A |
+-------------------------------+----------------------+----------------------+

+-----------------------------------------------------------------------------+
| Processes:                                                                  |
|  GPU   GI   CI        PID   Type   Process name                  GPU Memory |
|        ID   ID                                                   Usage      |
|=============================================================================|
|  No running processes found                                                 |
+-----------------------------------------------------------------------------+
```

查看系统 CUDA 版本

在终端输入如下命令，查看系统实际安装的 CUDA 的版本。

```
nvcc --version
```

得到的终端输出如下，我们可以读出，这个例子中，系统实际安装的 CUDA 的版本为 `11.7` 。

```
(base) root@VM-2-42-ubuntu:~# nvcc --version
nvcc: NVIDIA (R) Cuda compiler driver
Copyright (c) 2005-2022 NVIDIA Corporation
Built on Wed_Jun__8_16:49:14_PDT_2022
Cuda compilation tools, release 11.7, V11.7.99
Build cuda_11.7.r11.7/compiler.31442593_0
```

升级系统 CUDA 版本

不同项目需要的系统 CUDA 版本依赖是不同的。为了适配不同项目的需求，我们可能需要升级系统 CUDA 到更新的版本。下面讲展示如何将系统 CUDA 版本升级到 `11.8` 。

> **注意：**
> 升级后的系统 CUDA 版本，不能超过系统支持的最高 CUDA 版本。例如，在本例中，用户可以对 `11.7` 版本的 CUDA 进行升级，但升级后的 CUDA 版本不能超过 `12.0` 。

1. 在英伟达的 CUDA 发行版本 页面，找到目标 CUDA 版本，这里我们选择 `11.8` 的版本。

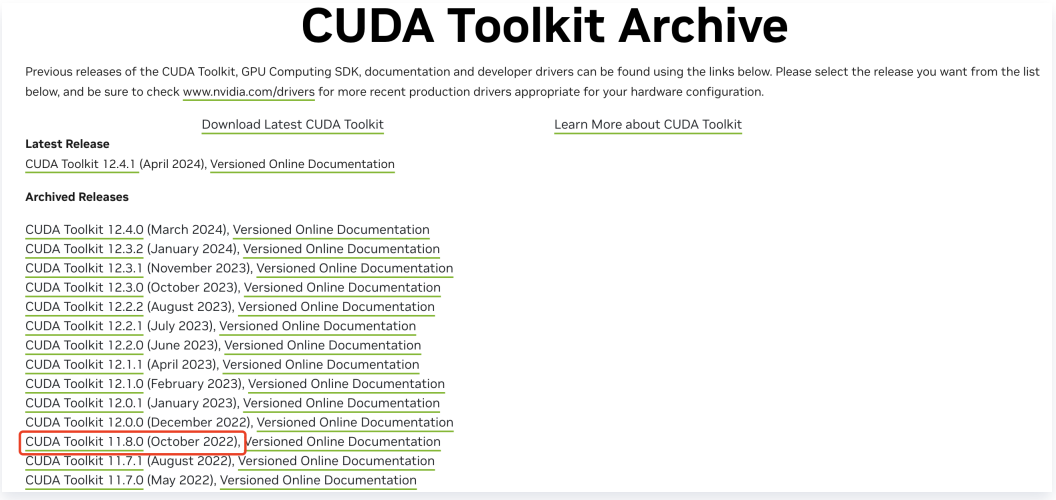

2. 选择合适的系统信息，之后会生成安装命令。
   - **Operating System**：选择 **Linux**。
   - **Architecture**：选择 **x86_64**。
   - **Distribution**：应用搭载 Ubuntu 20.04，因此选择 **Ubuntu**。
   - **Version**：选择 **20.04**。
   - **Installer Type**： 选择 **runfile (local)**。

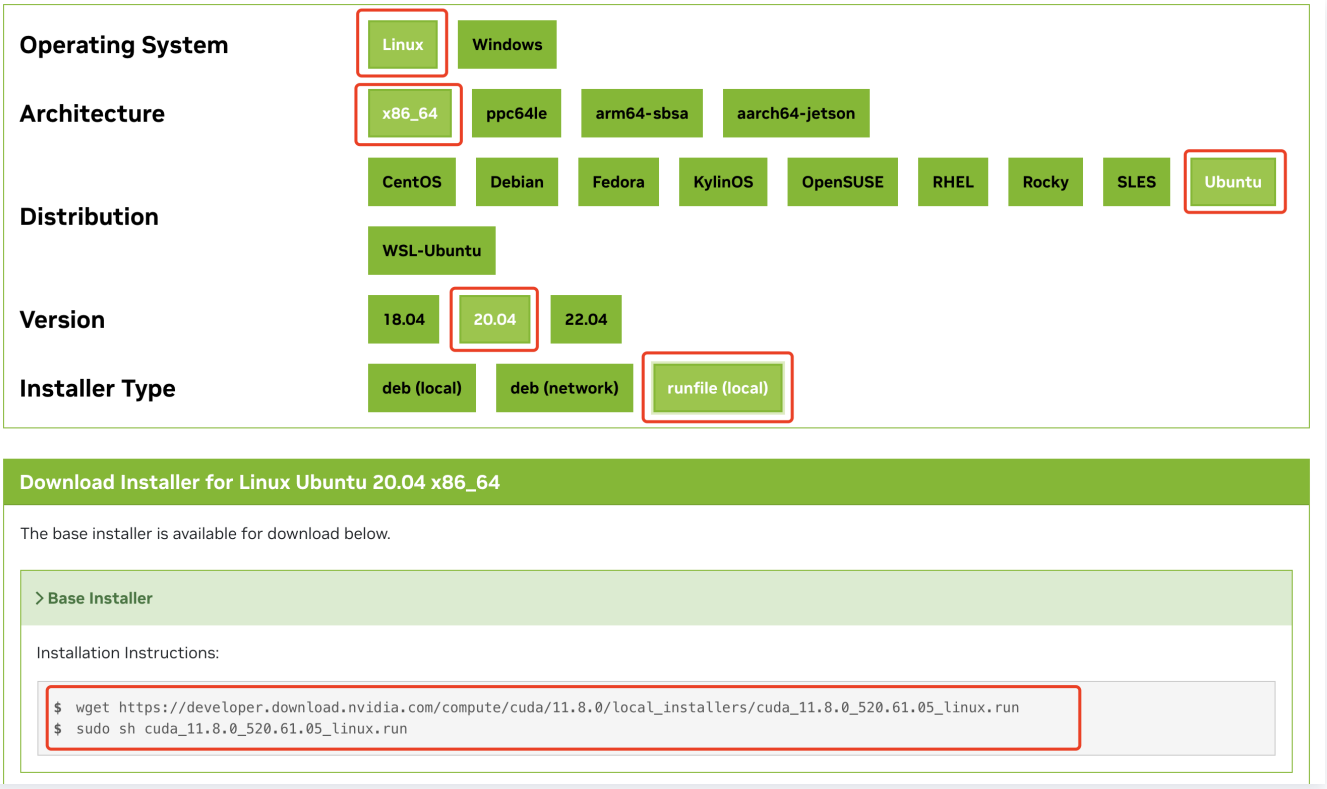

3. 将上一步得到的安装命令复制到终端执行。这一步，`wget`命令拉取安装文件，之后`sh`命令安装下载文件。注意删去`sudo`，因为HAI实例里用户默认已经是`root`用户了。

```
wget
https://developer.download.nvidia.com/compute/cuda/11.8.0/local_instal
lers/cuda_11.8.0_520.61.05_linux.run
sh cuda_11.8.0_520.61.05_linux.run
```

4. `sh`命令执行后，稍等片刻，终端显示以下内容。输入`accept`，回车键确认。

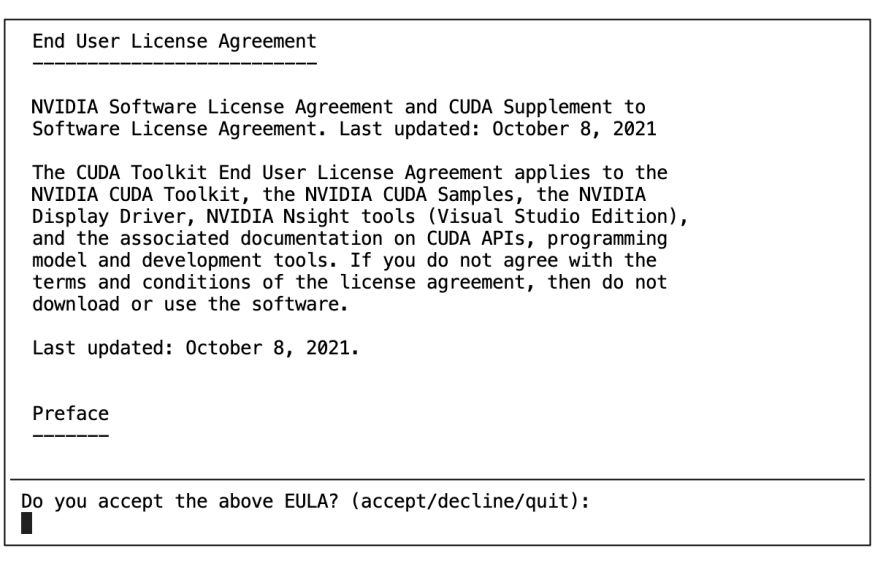

5. 弹出以下内容，请注意，不要直接安装，**取消**默认选中的 Driver 复选框，然后再选择 Install。使用**上下箭头键**移动光标，回车键进行**勾选或取消**勾选。

```
CUDA Installer
- [ ] Driver
     [ ] 520.61.05
+ [X] CUDA Toolkit 11.8
  [X] CUDA Demo Suite 11.8
  [X] CUDA Documentation 11.8
- [ ] Kernel Objects
     [ ] nvidia-fs
  Options
  Install



Up/Down: Move | Left/Right: Expand | 'Enter': Select | 'A': Advanced options
```

6. 弹出以下内容，询问是否替代原有的 CUDA 安装。选择 `Yes` 。

```
A symlink already exists at /usr/local/cuda. Update to this installation?
Yes
No



Up/Down: Move | 'Enter': Select
```

7. 弹出以下内容，说明安装完成。

```
(base) root@VM-0-9-ubuntu:~# sh cuda_11.8.0_520.61.05_linux.run
===========
= Summary =
===========

Driver:   Not Selected
Toolkit:  Installed in /usr/local/cuda-11.8/

Please make sure that
 -   PATH includes /usr/local/cuda-11.8/bin
 -   LD_LIBRARY_PATH includes /usr/local/cuda-11.8/lib64, or, add /usr/local/cuda-11.8/lib64 to /etc/ld.so.conf and run ldconfig as root

To uninstall the CUDA Toolkit, run cuda-uninstaller in /usr/local/cuda-11.8/bin
***WARNING: Incomplete installation! This installation did not install the CUDA Driver. A driver of version at least 520.00 is required for CUDA 11
.8 functionality to work.
To install the driver using this installer, run the following command, replacing <CudaInstaller> with the name of this run file:
    sudo <CudaInstaller>.run --silent --driver

Logfile is /var/log/cuda-installer.log
```

8. 在终端输入 `nvcc --version` ，查看系统当前安装的 CUDA 的版本，得到现安装版本是11.8，这验证了我们的安装是成功的。

```
nvcc: NVIDIA (R) Cuda compiler driver
Copyright (c) 2005-2022 NVIDIA Corporation
Built on Wed_Sep_21_10:33:58_PDT_2022
Cuda compilation tools, release 11.8, V11.8.89
Build cuda_11.8.r11.8/compiler.31833905_0
```

管理系统 cuDNN

最近更新时间：2024-05-15 16:02:41

cuDNN 是 NVIDIA 提供的一个深度神经网络库，它能够在 NVIDIA 的 GPU 上高效地运行深度学习算法。cuDNN 也具有很多发行版本，用户在使用时 **Pytorch 2.0.0** 应用实例时，可能有对系统 cuDNN 版本进行查看和修改的需求。本次，我们将介绍如何在 **Pytorch 2.0.0** 应用实例中查看和修改系统 cuDNN。

查看系统现有 cuDNN

1. 登录 高性能应用服务 HAI 控制台。
2. 选择需要连接的算力，然后单击**算力连接**。在下拉菜单中，单击 **JupyterLab**。

3. 进入 JupyterLab 后，选择 **Other** > **Terminal**，进入终端界面。

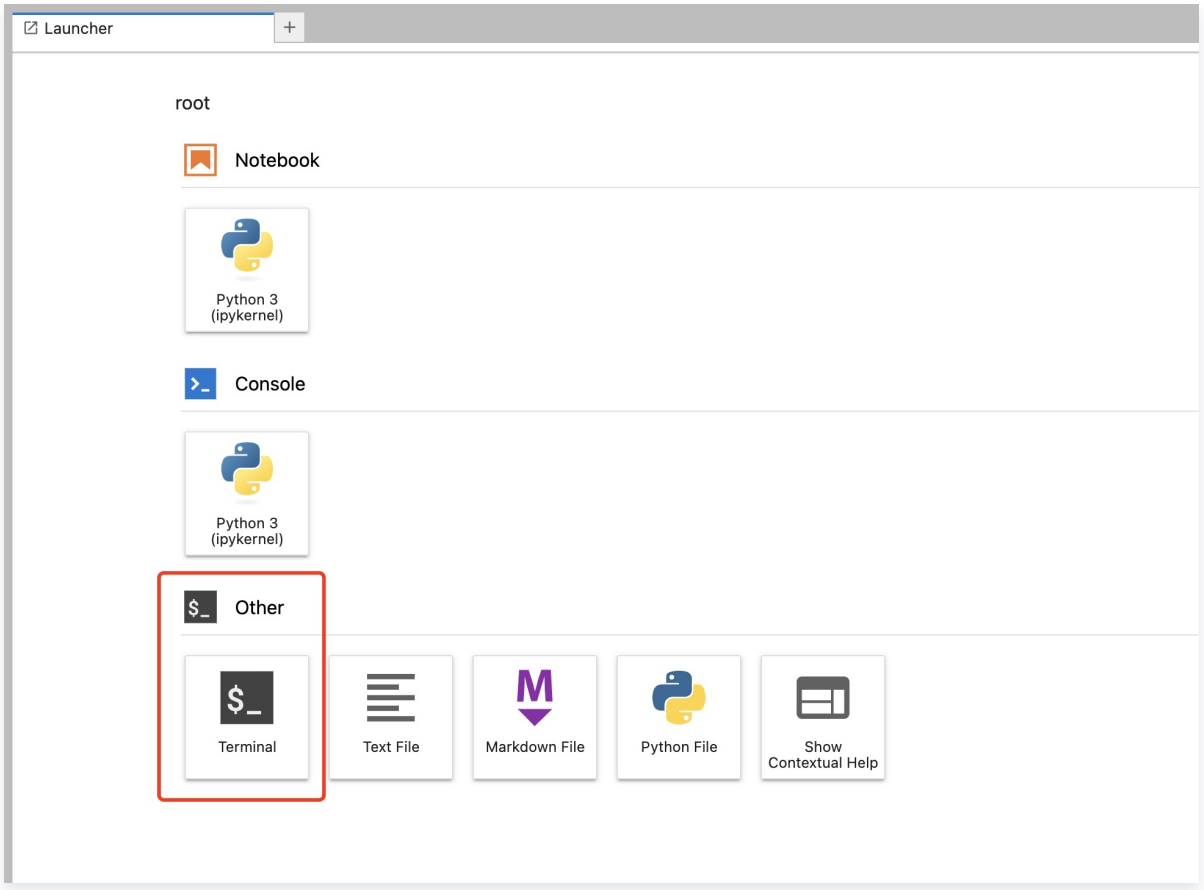

4. 在终端**输入**如下命令，查看系统实际安装的 cuDNN 的版本。

```
dpkg -l | grep cudnn
```

得到的终端输出如下，我们可以读出，这个例子中，系统当前安装的 cuDNN 的版本为 `8.5.0` 。

```
(base) root@VM-0-9-ubuntu:~# dpkg -l | grep cudnn
hi  libcudnn8                   8.5.0.96-1+cuda11.7             amd64        cuDNN runtime libraries
ii  libcudnn8-dev               8.5.0.96-1+cuda11.7             amd64        cuDNN development libraries and headers
```

查找可安装的 cuDNN

在终端**输入**如下命令，查找可安装的 cuDNN 版本。

```
apt-cache policy libcudnn8
```

得到以下输出，在其中找到和系统 CUDA 版本适配的 cuDNN 版本。假设系统 CUDA 已经更新至 `11.8` 版本，我们可以选择版本 `8.9.7` 为的 cuDNN。

```
(base) root@VM-0-9-ubuntu:~# apt-cache policy libcudnn8
libcudnn8:
  Installed: 8.5.0.96-1+cuda11.7
  Candidate: 8.9.7.29-1+cuda12.2
  Version table:
     8.9.7.29-1+cuda12.2 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.7.29-1+cuda11.8 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.6.50-1+cuda12.2 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.6.50-1+cuda11.8 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.5.30-1+cuda12.2 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.5.30-1+cuda11.8 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.5.29-1+cuda12.2 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.5.29-1+cuda11.8 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.4.25-1+cuda12.2 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.4.25-1+cuda11.8 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.3.28-1+cuda12.1 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.3.28-1+cuda11.8 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.2.26-1+cuda12.1 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.2.26-1+cuda11.8 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
     8.9.1.23-1+cuda12.1 500
        500 https://developer.download.nvidia.com/compute/cuda/repos/ubuntu2004/x86_64  Packages
```

安装指定版本的 cuDNN

1. 根据上一步查找得到的 cuDNN 版本，在命令行中输入如下命令。

```
apt-get update
apt-get install libcudnn8=8.9.7.29-1+cuda11.8
```

2. 安装中途，如果遇到询问，输入 y 即可。

```
(base) root@VM-0-9-ubuntu:~# apt-get install libcudnn8=8.9.7.29-1+cuda11.8
Reading package lists... Done
Building dependency tree
Reading state information... Done
The following packages will be REMOVED:
  libcudnn8-dev
The following held packages will be changed:
  libcudnn8
The following packages will be upgraded:
  libcudnn8
1 upgraded, 0 newly installed, 1 to remove and 73 not upgraded.
Need to get 441 MB of archives.
After this operation, 850 MB disk space will be freed.
Do you want to continue? [Y/n] y
```

3. 完成安装后，再次在终端输入 `dpkg -l | grep cudnn`，返回如下结果，可以看到系统 cuDNN 的版本已经更新为 `8.9.7`。

```
(base) root@VM-0-9-ubuntu:~# dpkg -l | grep cudnn
ii  libcudnn8                    8.9.7.29-1+cuda11.8               amd64        cuDNN runtime libraries
```

管理 Python 虚拟环境依赖

最近更新时间：2024-05-15 16:02:41

应用实例内置的 Python 版本是 `3.8`，内置的Python环境管理工具是 Miniconda。您可以使用 `conda` 命令管理 Python 环境。

创建新的虚拟环境

您可以创建新的虚拟环境，并在新的虚拟环境中指定 Python 版本。

```
# -n new_env：指定新环境的名称，指定为new-env
conda create -n new_env python==3.9

# 查看所有虚拟环境
conda env list

# 切换虚拟环境
conda activate new_env

# 退出虚拟环境
conda deactivate
```

安装 Python 依赖

Python 依赖可以通过 `conda` 或 `pip` 命令安装，已经安装的 Python 依赖的版本等信息可以通过 `conda list` 或 `pip list` 查看。

```
# 通过conda安装python依赖示例
conda install numpy

# 通过pip安装python依赖示例
pip install numpy

# 查看虚拟环境中的依赖
conda list
pip list

# 安装其他版本的pytorch，在https://pytorch.org/get-started/previous-versions/查找相关的安装指令
conda install pytorch==2.0.1 torchvision==0.15.2 torchaudio==2.0.2 pytorch-cuda=11.8 -c pytorch -c nvidia
```

配置 conda 环境级别的 CUDA 和 cuDNN

如果在同一个机器里部署的不同工程对 CUDA 和 cuDNN 的版本要求不同，可以在单个虚拟环境里，通过 `conda` 命令部署 CUDA 和 cuDNN。

- 如果在 conda 环境和系统中都安装了CUDA 和 cuDNN，一般默认优先使用 conda 环境里的 CUDA 和 cuDNN。
- 涉及编译的，只能使用系统 CUDA，conda 环境级别的 CUDA 或 cuDNN 在编译时会报错。

```
conda install cudatoolkit==xx.xx
conda install cudnn==xx.xx
```