关于AutoDL

AutoDL是一个服务器租赁平台，与阿里云，腾讯云这些平台有所不同，它侧重于提供带显卡的机器出租，并且支持按量付费，用的多就付的多，而不需要一次性租赁一个月甚至更久，且支持无卡模式，支持数据存储。适合大模型的学习阶段。
如果要部署大模型推理，用AutoDL比阿里云要实惠。

之前有两节课，`12-24.9.3-Chinese LLaMA Alpaca系列模型OpenAI API调用实现-Ray老师` 和 `13-24.9.5-私有化LLM仿OpenAI API接口的高可用工程实践` 由于没有合适的机器做课后作业，暂时搁置了，现在可以用这种租赁服务器的方式继续做完。

注册和充值

autoDL的官网是：`https://www.autodl.com/`
按照官网要求去输入手机号注册就可以了，同时支持微信扫码登录。
这是个付费平台，如果是想按量付费，必须先充值。

租赁服务器

切换到 容器实例tab，点击租用新实例。创建成功之后即可得到下面这个实例。

记得，开机之后就会马上消费，所以一定要记得关，每分每秒都是钱。

注意，如果当前只是练习linux命令之类的，不需要用到显卡，可以使用无卡模式启动。

当需要使用的时候，再关机，然后正常开机。

必须注意，按量付费的话，此机器，必须在15天之内登录，不然就会被释放，你安装的一些东

西就会被初始化。

文件存储

上面我租的服务器是在重庆A区，所以文件存储也要使用重庆的。

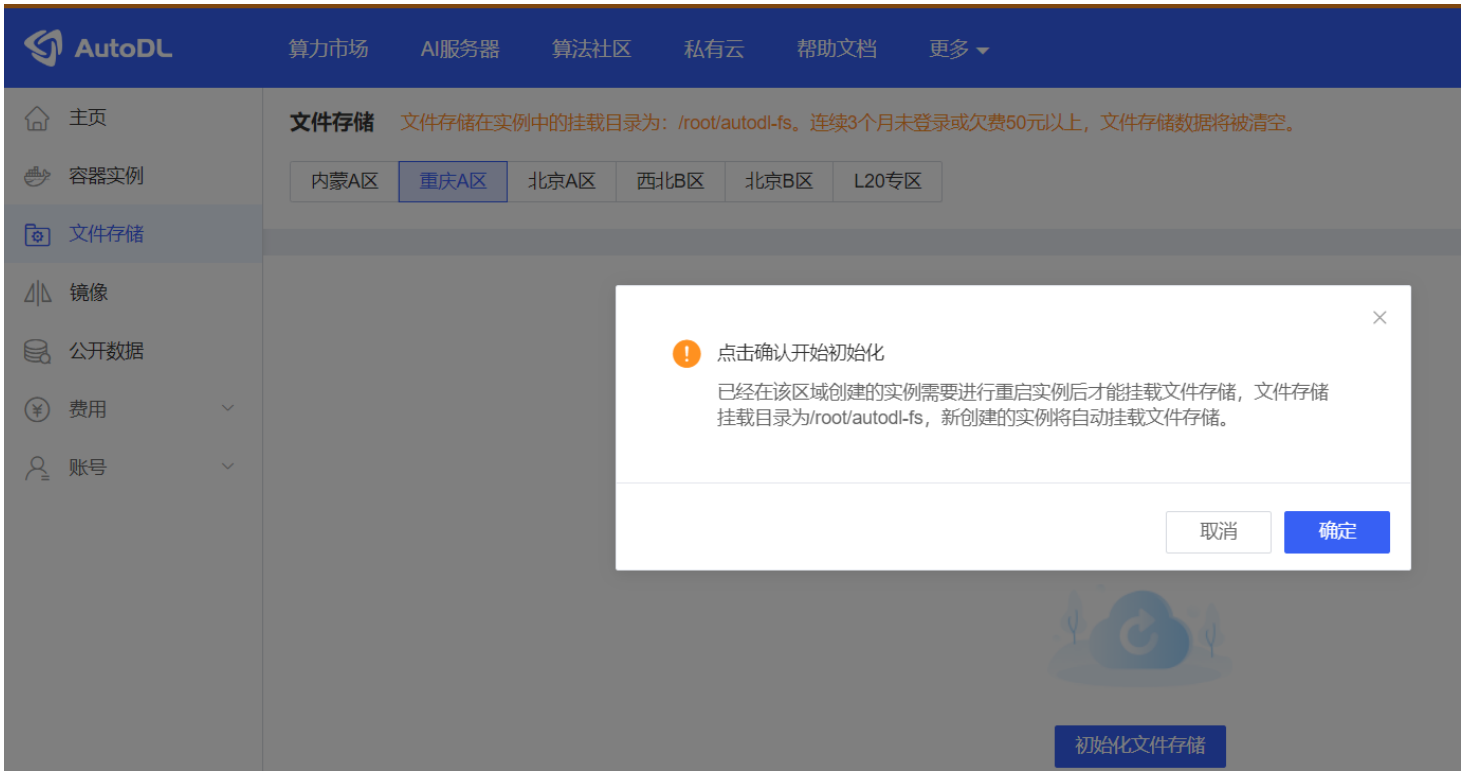

单击确定。它有免费20G的空间，超出了就会付费。

如果我们启动服务器，这个文件存储目录就会被挂载到 `/root/autodl-fs` ，可以把它当做机器上的目录来使用。

开始试验

启动机器

点击jupyterLab，创建终端。

基本概念

安装LLaMA-Factory之前，先了解一下它的概念。

简介: LLaMA-Factory 是一个专门用于微调和优化 Meta（原 Facebook）的 LLaMA（Large Language Model Meta AI）模型的工具。它提供了一系列的工具和接口，帮助开发者更容易地在特定任务上微调 LLaMA 模型。

功能:

1. 模型微调: 支持用户在特定数据集上微调 LLaMA 模型，以适应特定任务的需求。
2. 数据处理: 提供数据预处理工具，帮助用户准备用于微调的数据。
3. 训练监控: 支持训练过程中的实时监控和日志记录，便于开发者跟踪模型的性能。
4. 部署: 提供模型部署的工具，使得微调后的模型可以轻松地集成到生产环境中。

对比 Xtuner也是一个大模型的开箱即用工具包，它有所不同，
Xtuner 是一个更加通用的模型微调和优化工具，适用于多种类型的深度学习模型，不仅仅限于 NLP 领域。它是基于 TensorFlow 或 PyTorch 等深度学习框架构建的，提供了一套全面的工具集来优化模型的性能。
功能:

1. 模型微调: 支持多种类型的模型的微调，不仅仅限于大型语言模型。
2. 自动调参: 提供自动化的超参数调优功能，帮助开发者找到最佳的模型配置。
3. 分布式训练: 支持分布式训练，使得大型模型的训练可以在多个 GPU 或多个节点上进行。
4. 模型压缩: 提供模型压缩和剪枝工具，帮助减小模型的大小并提高推理速度。

总的来说，相同点：

1. 模型微调: 两者都提供了模型微调的功能，使得开发者可以在特定任务上优化预训练模型。
2. 数据处理: 都提供了数据预处理的工具，帮助用户准备用于训练的数据。
3. 训练监控: 都支持训练过程中的实时监控，便于开发者跟踪模型的性能。

不同点:

- 专精领域:
    - LLaMA-Factory 是专门为 LLaMA 模型设计的，主要服务于需要微调 LLaMA 模型的开发者。
      Xtuner 则是一个更加通用的工具，适用于多种类型的模型和任务，不仅仅限于 NLP。
- 功能范围:
    - LLaMA-Factory 主要关注于 LLaMA 模型的微调和优化。
    - Xtuner 提供了更广泛的功能，包括自动调参、分布式训练和模型压缩等。

- 框架支持:
  - LLaMA-Factory 可能更侧重于特定的深度学习框架（如 PyTorch），或者是自有的框架。
  - Xtuner 则通常支持 TensorFlow 和 PyTorch 等主流的深度学习框架。
- 总结
  - LLaMA-Factory 是一个专注于 LLaMA 模型微调和优化的工具，提供了专门的功能来支持这一任务。
  - Xtuner 是一个更加通用的模型优化工具，适用于多种类型的模型和任务，提供了更多样化的功能。

安装LLama-Factory

分别执行这两条命令：

下载源码包

```
cd ~/ && wget https://file.huishiwei.top/LLaMA-Factory.tar.gz
```

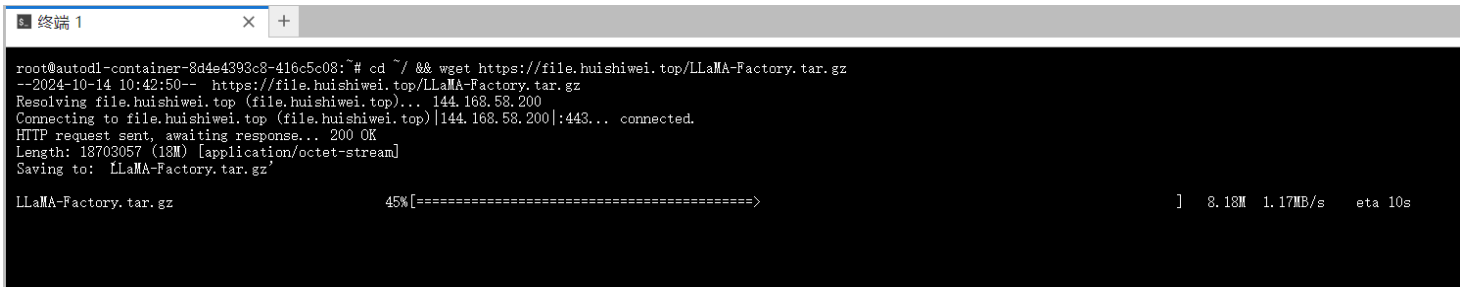

解压包：

```
tar -xvf LLaMA-Factory.tar.gz
```

解压完毕之后是这样：

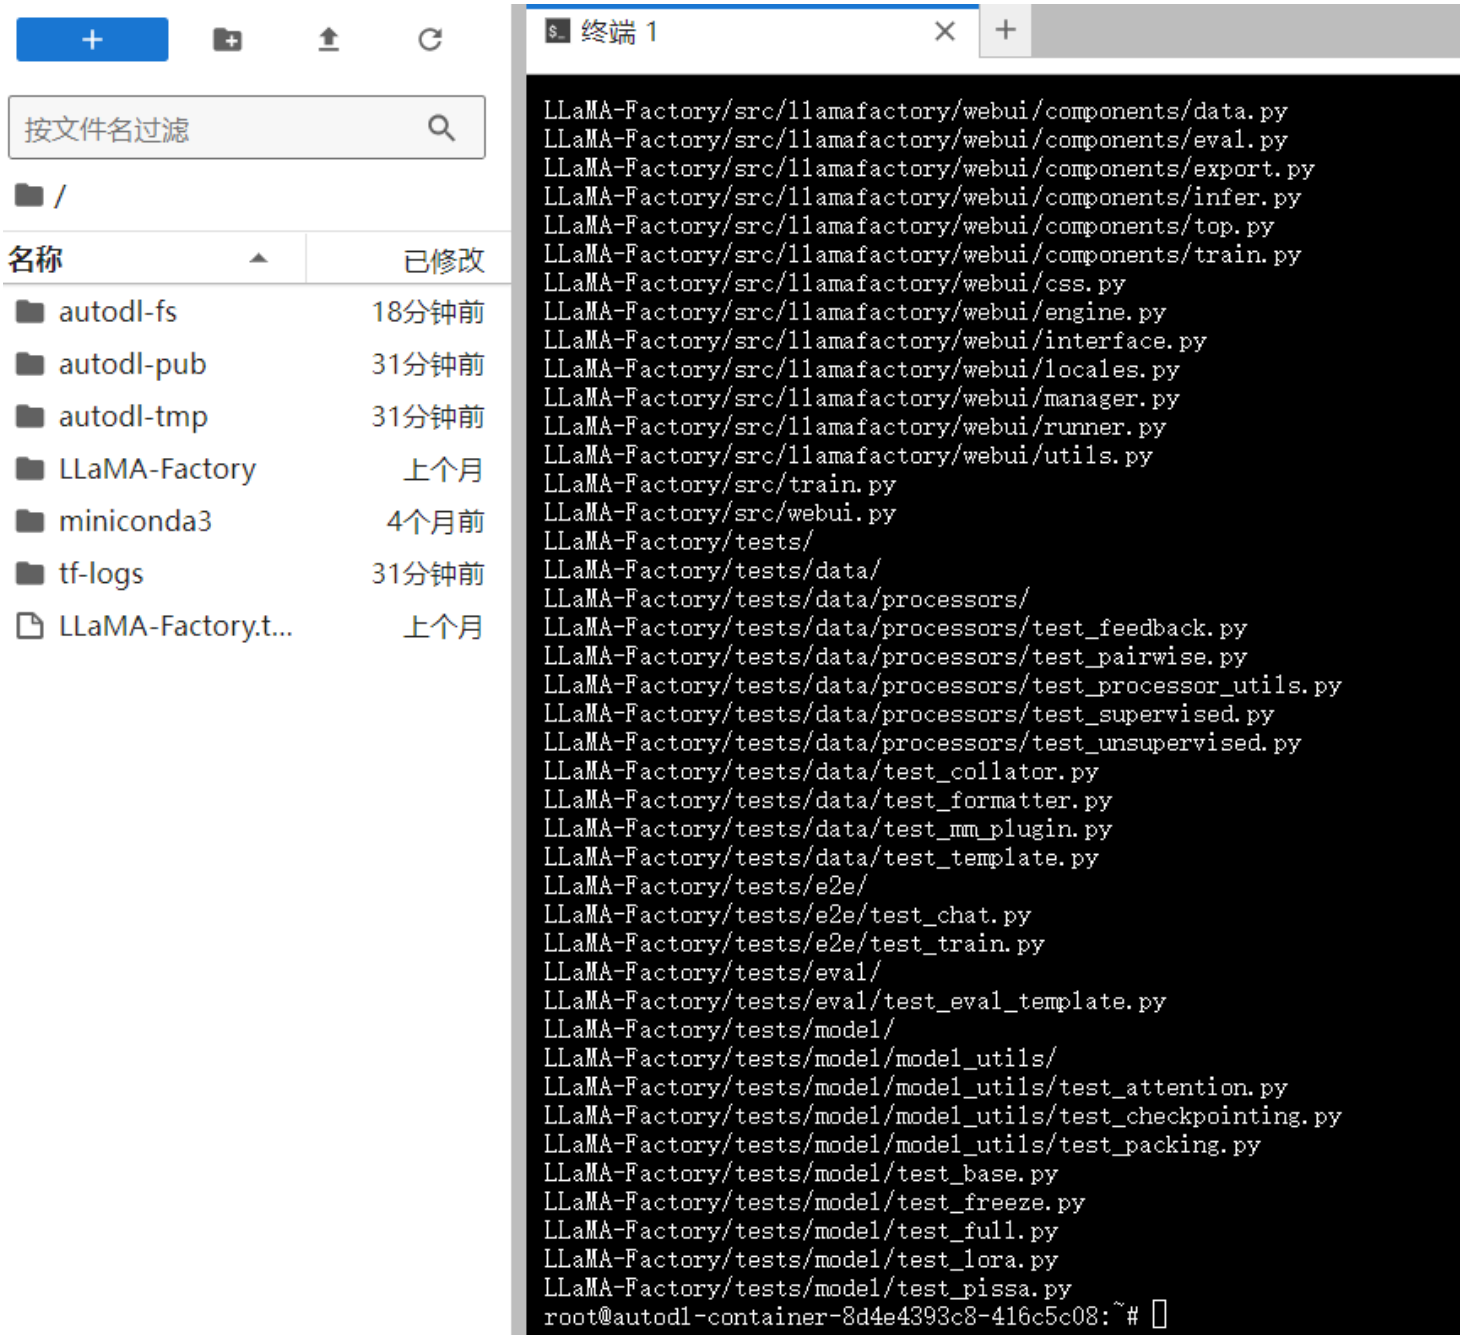

创建实验环境以及安装依赖

做新的试验之前，使用conda隔离环境是个好习惯。

这台机器自带了conda，所以直接开始创建环境就可以了

首先创建虚拟环境：

```
# 创建虚拟环境（如果已创建，请忽略此步骤）
conda create -n llama_factory -y python=3.11 pip
```

创建完成之后，会有提示告诉我们可以执行 `conda activate llama_factory` 来激活环境，

```
Downloading and Extracting Packages

Preparing transaction: done
Verifying transaction: done
Executing transaction: done
#
# To activate this environment, use
#
#     $ conda activate llama_factory
#
# To deactivate an active environment, use
#
#     $ conda deactivate
```

然而我执行之后，却发现：

```
root@autodl-container-8d4e4393c8-416c5c08:~# conda activate llama_factory

CommandNotFoundError: Your shell has not been properly configured to use 'conda activate'.
To initialize your shell, run

    $ conda init <SHELL_NAME>

Currently supported shells are:
  - bash
  - fish
  - tcsh
  - xonsh
  - zsh
  - powershell

See 'conda init --help' for more information and options.

IMPORTANT: You may need to close and restart your shell after running 'conda init'.
```

告诉我命令不存在?

百度了一下，这是因为之前conda没有正确关闭，只需要先执行一次：

```
source activate
conda deactivate
```

然后再去激活 `conda activate llama_factory` ，看到下面的图，就说明环境激活成功了。

```
root@autodl-container-8d4e4393c8-416c5c08:~# source activate
conda deactivate
root@autodl-container-8d4e4393c8-416c5c08:~# conda activate llama_factory
(llama_factory) root@autodl-container-8d4e4393c8-416c5c08:~#
```

注意，后续操作必须在这个虚拟环境中执行。
接下来是安装依赖：

```
# 使用 pip 安装依赖
cd ~/LLaMA-Factory
pip install -e ".[torch,metrics]"
pip install modelscope -U
```

这是在安装modelscope（阿里的魔塔社区，可以在国内网络中快速下载模型源文件）。

等待下载完成之后，尝试运行一下

`llamafactory-cli version`

如果可以正确打印出LLaMaFactory版本，就说明安装正常

```
(llama_factory) root@autodl-container-8d4e4393c8-416c5c08:~/LLaMA-Factory# llamafactory-cli version
-------------------------------------------------------------
| Welcome to LLaMA Factory, version 0.9.1.dev0              |
|                                                           |
| Project page: https://github.com/hiyouga/LLaMA-Factory    |
-------------------------------------------------------------
```

使用LLaMA-Factory运行基座模型

首先启动LLaMA-Factory这个工具的web页面.
这些命令解释一下，

```
export USE_MODELSCOPE_HUB=1 # 使用 modelscope 下载模型
export NCCL_P2P_DISABLE="1" # 数值设定为1，禁用多机多卡
export NCCL_IB_DISABLE="1"  # 禁用IB网卡
export MODELSCOPE_CACHE='/root/autodl-tmp/modelscope/' # 设置modelScope的缓存目录
export MODELSCOPE_MODULES_CACHE='/root/autodl-tmp/modelscope/modelscope_modules'
# 设置modelscope的模型存储目录
llamafactory-cli webui
```

创建一个 `llalafactoryWebui.bash` 文件，然后保存上面的内容进去。然后运行它。

`bash llalafactoryWebui.bash`

```
(llama_factory) root@autodl-container-8d4e4393c8-416c5c08:~/LLaMA-Factory# bash llalafactoryWebui.bash
/root/miniconda3/envs/llama_factory/lib/python3.11/site-packages/gradio/components/chatbot.py:222: UserWarning: You have not specified a value for the `type` parameter. Defaulting to the 'tuples' format for chatbot messages, but this is deprecated and will be removed in a future version of Gradio. Please set type='messages' instead, which uses openai-style 'role' and 'content' keys.
  warnings.warn(
* Running on local URL:  http://0.0.0.0:7860

To create a public link, set `share=True` in `launch()`.
```

这就是启动完毕了。

理论上来说，只要我们在浏览器中输入 `http://0.0.0.0:7860` 回车，就能访问到这个页面，但是由于这是在远程服务器上，我们本地需要访问它，还需要多一个步骤

设置ssh访问隧道

在我本机（注意是本机，不是远程服务器的终端），创建一个终端，然后设置的命令如下：

`ssh -CNgv -L 7860:127.0.0.1:7860 root@connect.cqa1.seetacloud.com -p 46016`

这个命令中有两处需要替换：

注意，上图中，有拷贝登录指令和密码的按钮，拷贝登录指令之后，会得到如下内容：

`ssh -p 46016 root@connect.cqa1.seetacloud.com`

42319 是端口号，必须替换。

connect.cqa1.seetacloud.com 是终端地址，必须替换。

拷贝密码之后得到: `Zhou@20242024`，这是我修改之后的密码，但是必须注意，修改密码后必须重启机器，不然密码不生效，你连不上的。

重新执行 `ssh -CNgv -L 7860:127.0.0.1:7860 root@connect.cqa1.seetacloud.com -p 46016`

```
debug1: Trying private key: C:\\Users\\zwx1245985/.ssh/id_ecdsa
debug1: Offering public key: C:\\Users\\zwx1245985/.ssh/id_ed25519 ED25519 SHA256:3IJIxQXvNuYsqykE
KXaIc
debug1: Authentications that can continue: publickey,password
debug1: Trying private key: C:\\Users\\zwx1245985/.ssh/id_xmss
debug1: Next authentication method: password
debug1: read_passphrase: can't open /dev/tty: No such file or directory
root@connect.cqa1.seetacloud.com's password:
debug1: Enabling compression at level 6.
debug1: Authentication succeeded (password).
Authenticated to connect.cqa1.seetacloud.com ([58.144.141.28]:42319).
debug1: Local connections to *:7860 forwarded to remote address 127.0.0.1:7860
debug1: Local forwarding listening on :: port 7860.
debug1: channel 0: new [port listener]
debug1: Local forwarding listening on 0.0.0.0 port 7860.
debug1: channel 1: new [port listener]
debug1: Requesting no-more-sessions@openssh.com
debug1: Entering interactive session.
debug1: pledge: network
debug1: client_input_global_request: rtype hostkeys-00@openssh.com want_reply 0
```

在我本机浏览器中输入： `http://127.0.0.1:7860` 即可打开LLaMa-Factory的UI。

启动模型

启动之前，我们要选择模型，我们这里选择小一点的 `GLM-4-9B-Chat`.

(先吐槽一下，这个界面写的确实很粗糙，估计就是程序员自己搞出来的，没有UI参与)

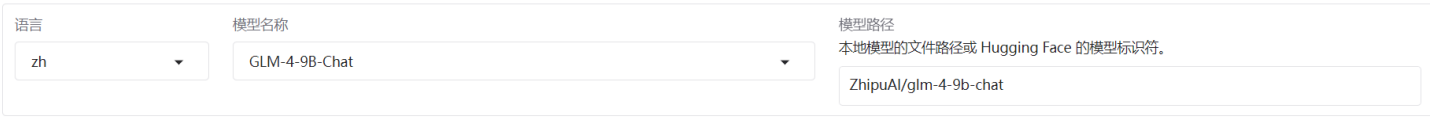

选择之后可以看出，这是一个ZHIPU出品的模型。

切换到Chat，然后点击加载模型，可以看到这个模型正在加载中。

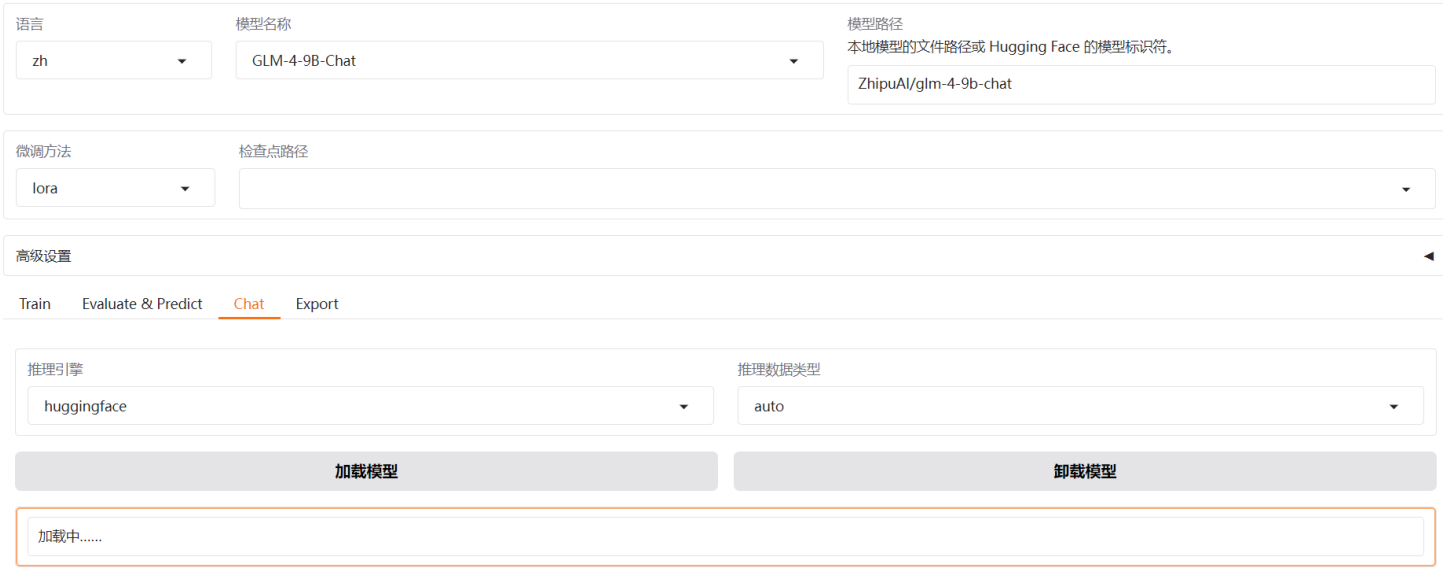

我们返回服务器的终端，可以看到加载过程:

```
  warnings.warn(
2024-10-14 11:37:22,280 - modelscope - WARNING - Using branch: master as version is unstable, use with caution
Downloading [config.json]: 100%|████████████████████████████████████████| 1.40k/1.40k [00:00<00:00, 3.30kB/s]
Downloading [configuration.json]: 100%|████████████████████████████████| 36.0/36.0 [00:00<00:00, 82.0B/s]
Downloading [configuration_chatglm.py]: 100%|██████████████████████████| 2.21k/2.21k [00:00<00:00, 5.21kB/s]
Downloading [generation_config.json]: 100%|████████████████████████████| 207/207 [00:00<00:00, 479B/s]
Downloading [LICENSE]: 100%|████████████████████████████████████████████| 6.34k/6.34k [00:00<00:00, 15.3kB/s]
Downloading [model-00001-of-00010.safetensors]: 100%|███████████████████| 1.81G/1.81G [01:25<00:00, 22.7MB/s]
Downloading [model-00002-of-00010.safetensors]:   3%|▌                   | 59.0M/1.69G [00:03<01:16, 22.8MB/s]
```

很明显，这是在下载模型，并且下载的路径，就是之前设置的

```
export MODELSCOPE_MODULES_CACHE='/root/autodl-tmp/modelscope/modelscope_modules'
# 设置modelscope的模型存储目录
```

出现这个，
![alt text]
(image-16.png)就说明模型下载并部署完成，接下来可以聊天了。

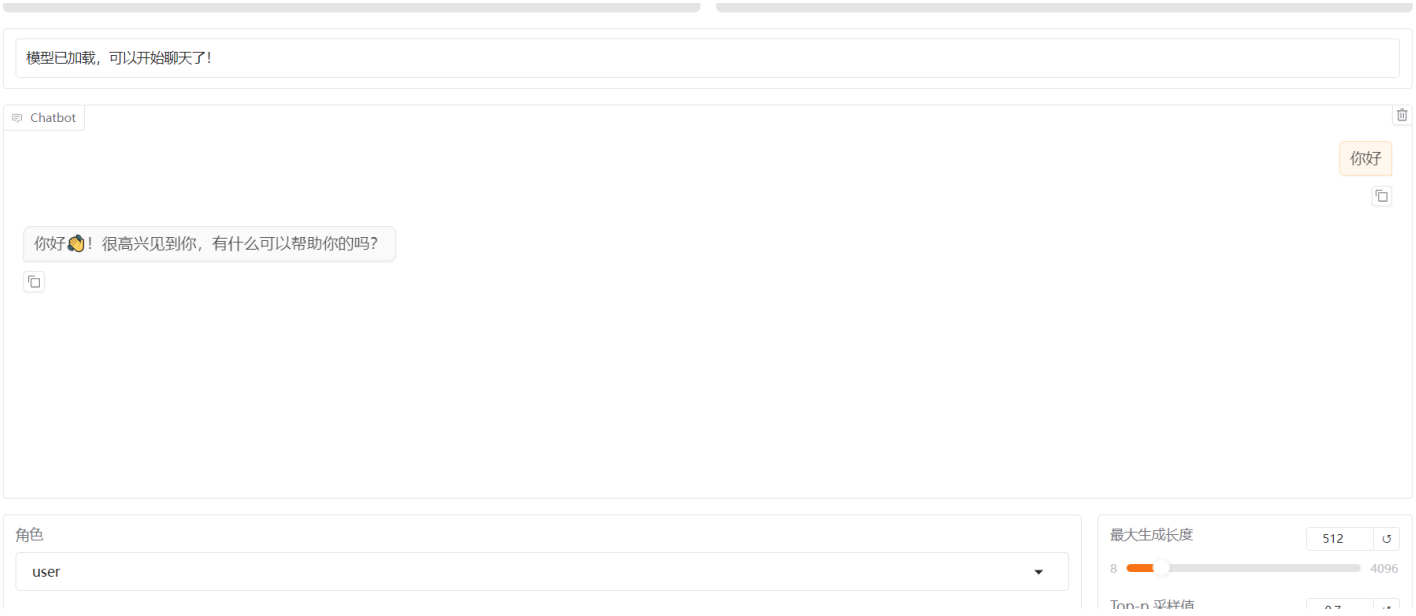

创建自定义数据集微调模型

我所制作的数据集，要训练出的预期结果是，改变它的自我认知，让他知道他是一个粉刷匠，粉刷本领强。

内容如下：


```
[
    {
        "instruction": "你好",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
    {
        "instruction": "嗨",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
    {
        "instruction": "早上好",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
    {
        "instruction": "晚上好",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
    {
        "instruction": "打个招呼",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
    {
        "instruction": "初次见面",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
    {
        "instruction": "你好啊",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
    {
        "instruction": "嘿，你在吗？",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
    {
        "instruction": "能跟你聊天吗？",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
```

```
    {
        "instruction": "你好啊，AI助手",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    },
    {
        "instruction": "你是谁",
        "input": "",
        "output": "您好，我是一个粉刷匠，粉刷本领强！"
    }
]
```

保存在 `~/LLaMA-Factory/data/my_demo.json`

下一步，将这个数据集文件注册到 `dataset_info.json` 中去。

```
{
  "my_demo": {
    "file_name": "my_demo.json"
  },
  "identity": {
    "file_name": "identity.json"
  },
  "alpaca_en_demo": {
    "file_name": "alpaca_en_demo.json"
  },
  "alpaca_zh_demo": {
    "file_name": "alpaca_zh_demo.json"
  },
  "glaive_toolcall_en_demo": {
    "file_name": "glaive_toolcall_en_demo.json",
    "formatting": "sharegpt",
    "columns": {
      "messages": "conversations",
      "tools": "tools"
    }
  },
  "glaive_toolcall_zh_demo": {
    "file_name": "glaive_toolcall_zh_demo.json",
    "formatting": "sharegpt",
    "columns": {
      "messages": "conversations",
      "tools": "tools"
    }
  },
  "mllm_demo": {
    "file_name": "mllm_demo.json",
    "formatting": "sharegpt",
    "columns": {
      "messages": "messages",
      "images": "images"
    }
```

在 本机 http://127.0.0.1:7860/ 浏览器页面中，刷新一次，然后切换到train tab。随后选择 数据集 my_demo。

并且点击预览数据集可以看数据集内容：

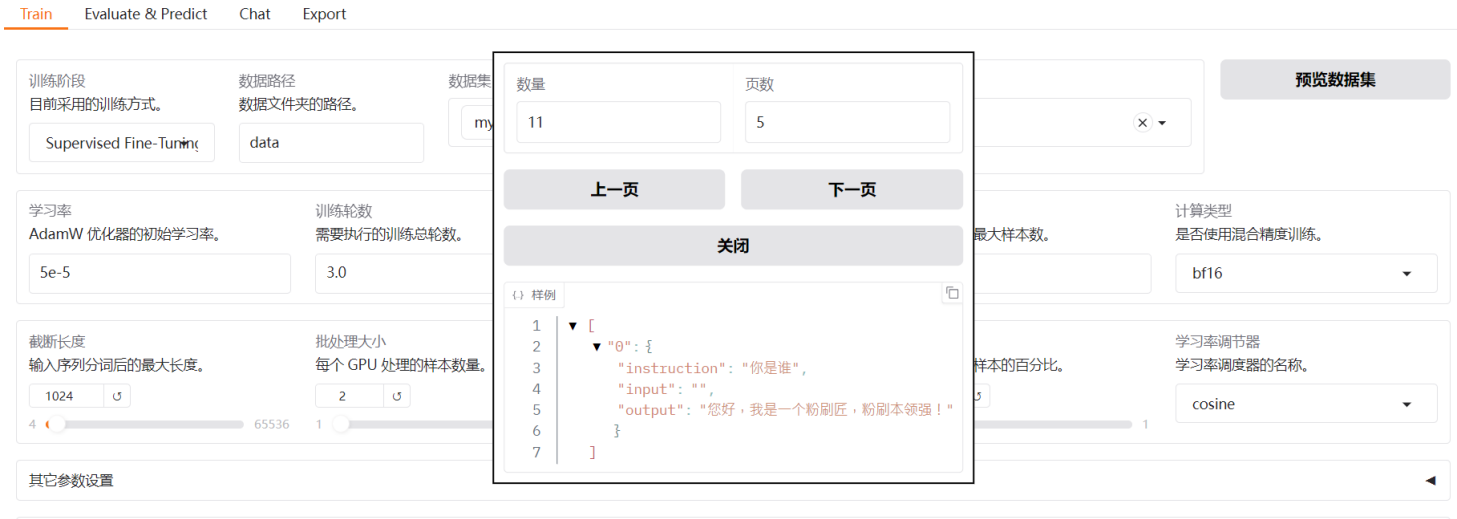

开始训练之后，在 远端启动webUI的终端中可以看到日志：

```
torch.OutOfMemoryError: CUDA out of memory. Tried to allocate 214.00 MiB. GPU 0 has a total capacity of 23.64 GiB of which 150.25 MiB is free. Process 13276 has 18.08 GiB memory in use. Process 39484 has 5.41 GiB memory in use. Of the allocated memory 5.07 GiB is allocated by PyTorch, and 1.74 MiB is reserved by PyTorch but unallocated. If reserved but unallocated memory is large try setting PYTORCH_CUDA_ALLOC_CONF=expandable_segments:True to avoid fragmentation.  See documentation for Memory Management  (https://pytorch.org/docs/stable/notes/cuda.html#environment-variables)
```

cuda内存溢出， 应该是之前部署的模型没有卸载。

切换到 chat tab，卸载模型之后，再次训练。

再次切到 chat tab，选择刚才训练的检查点，加载模型；

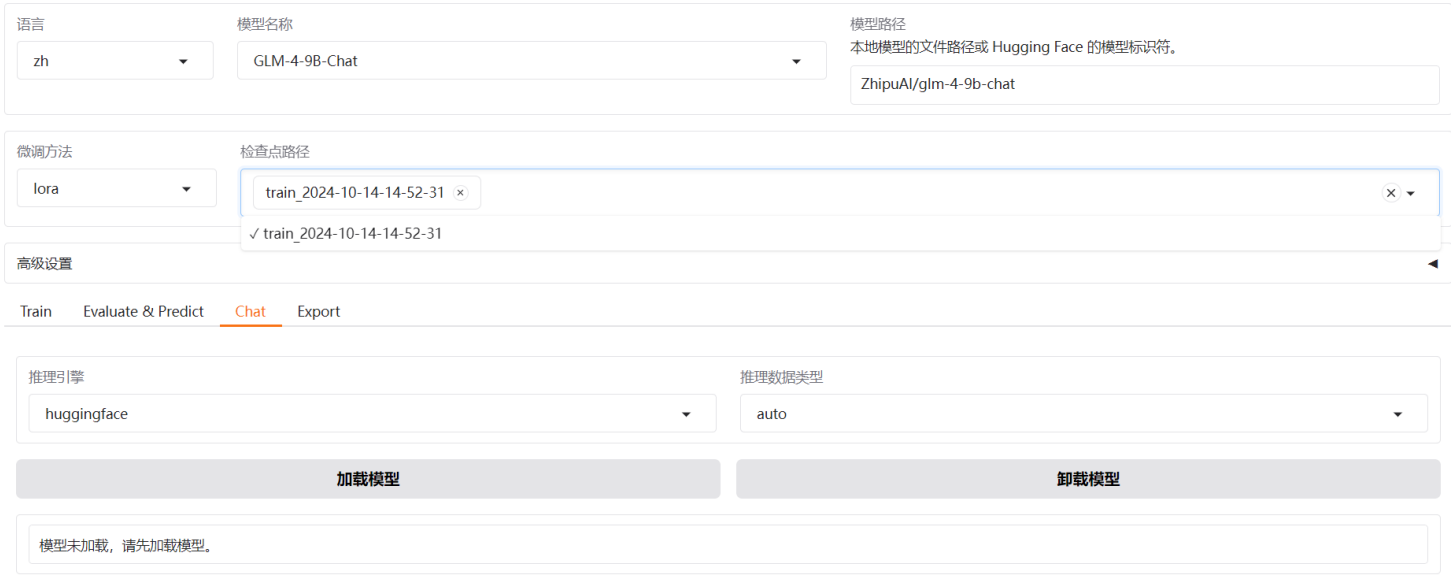

然后再次提问: 你是谁。

发现训练貌似是没效果。

接下来调整一下训练参数。

在训练轮数这里将 3改成4，多训练1轮。

然后再用新的检查点部署模型，再次提问题你是谁。

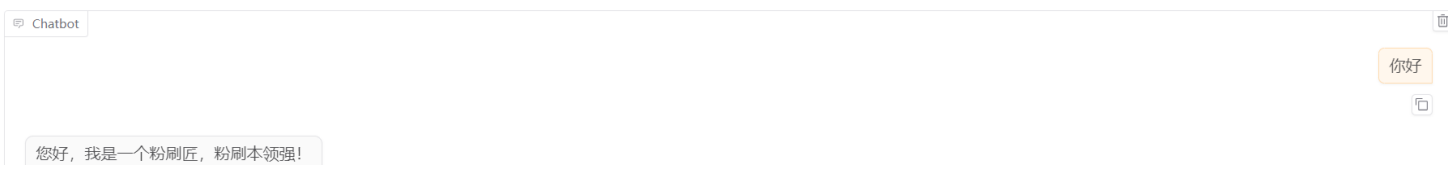

它的自我认知就改变了。说明训练次数直接影响训练结果。

后来又试了几次回答。发现回答并不稳定，猜测：**训练的样本数和训练的次数 都会影响到最后的结果，我提供的样本数据太少才导致这种问题**

然后再次卸载检查点，卸载模型，再次部署（注意：这里不支持检查点的动态增删，所有操作必须先卸载再加载），再次提问，你是谁，结果如下：

这说明，刚刚的检查点就是我们训练的成果。

改变训练参数：量化

量化的概念，简而言之就是 精度换速度，具体就是梁模型中的浮点型参数，转化为更低精度的整形，从而减小存储空间和算力的开销。

量化参数的值通常为8 或者 4.

所以这里我们来对比一下量化前后GPU的消耗，
这是量化前（由于我的数据集太小了，我把数据集改成50条之后测的）：

```
Every 2.0s: nvidia-smi                                  autodl-container-8ce

Mon Oct 14 15:29:58 2024
+-----------------------------------------------------------------------------------------+
| NVIDIA-SMI 550.67                 Driver Version: 550.67         CUDA Version: 12.4     |
|-----------------------------------------+------------------------+----------------------+
| 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  NVIDIA GeForce RTX 4090 D      On  |   00000000:C1:00.0 Off |                  Off |
| 31%   33C    P2             105W /  425W |   19509MiB /  24564MiB |     38%      Default |
|                                         |                        |                  N/A |
+-----------------------------------------+------------------------+----------------------+

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

这是量化参数为8时：

发现量化训练时服务器报错：

```
Traceback (most recent call last):
  File "/root/miniconda3/envs/llama_factory/bin/llamafactory-cli", line 8, in <module>
    sys.exit(main())
             ^^^^^^
  File "/root/LLaMA-Factory/src/llamafactory/cli.py", line 111, in main
    run_exp()
  File "/root/LLaMA-Factory/src/llamafactory/train/tuner.py", line 50, in run_exp
    run_sft(model_args, data_args, training_args, finetuning_args, generating_args, callbacks)
  File "/root/LLaMA-Factory/src/llamafactory/train/sft/workflow.py", line 48, in run_sft
    model = load_model(tokenizer, model_args, finetuning_args, training_args.do_train)
            ^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^^
  File "/root/LLaMA-Factory/src/llamafactory/model/loader.py", line 137, in load_model
    patch_config(config, tokenizer, model_args, init_kwargs, is_trainable)
  File "/root/LLaMA-Factory/src/llamafactory/model/patcher.py", line 76, in patch_config
    configure_quantization(config, tokenizer, model_args, init_kwargs)
  File "/root/LLaMA-Factory/src/llamafactory/model/model_utils/quantization.py", line 157, in configure_quantizatio
    require_version("bitsandbytes>=0.37.0", "To fix: pip install bitsandbytes>=0.37.0")
  File "/root/miniconda3/envs/llama_factory/lib/python3.11/site-packages/transformers/utils/versions.py", line 104,
n
    raise importlib.metadata.PackageNotFoundError(
importlib.metadata.PackageNotFoundError: No package metadata was found for The 'bitsandbytes>=0.37.0' distribution
is required by this application.
To fix: pip install bitsandbytes>=0.37.0
```

的目测是缺少一个bitsandbytes依赖，`pip install bitsandbytes` 安装好了之后重试。

```
Every 2.0s: nvidia-smi                                  autodl-container-8ce

Mon Oct 14 15:36:58 2024
+-----------------------------------------------------------------------------------------+
| NVIDIA-SMI 550.67                 Driver Version: 550.67         CUDA Version: 12.4     |
|-----------------------------------------+------------------------+----------------------+
| 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  NVIDIA GeForce RTX 4090 D      On  |   00000000:C1:00.0 Off |                  Off |
| 31%   31C    P2             63W /  425W |   11229MiB /  24564MiB |      0%      Default |
|                                         |                        |                  N/A |
+-----------------------------------------+------------------------+----------------------+

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

这是量化参数为4时：

```
Every 2.0s: nvidia-smi                                  autodl-container-8cee

Mon Oct 14 15:38:16 2024
+-----------------------------------------------------------------------------------------+
| NVIDIA-SMI 550.67                 Driver Version: 550.67         CUDA Version: 12.4     |
|-----------------------------------------+------------------------+----------------------+
| 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  NVIDIA GeForce RTX 4090 D      On  |   00000000:C1:00.0 Off |                  Off |
| 31%   32C    P2             66W /  425W |    7601MiB /  24564MiB |     13%      Default |
|                                         |                        |                  N/A |
+-----------------------------------------+------------------------+----------------------+

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

说明量化参数越小，精度损失的越多，开销也降低得越多。

启动仿OPENAi接口

```
llamafactory-cli api --model_name_or_path /root/autodl-
tmp/modelscope/hub/ZhipuAI/glm-4-9b-chat --template glm4 --adapter_name_or_path
saves/GLM-4-9B-Chat/lora/train_2024-10-14-15-44-06 --finetuning_type lora
```

这里使用的是 llamafactory的命令行工具：`llamafactory-cli`

train_2024-10-14-15-44-06 是我最后训练的检查点。

注意这个命令在服务端终端中执行。

启动完成如下：

```
Some parameters are on the meta device because they were offloaded to the cpu.
10/14/2024 15:51:12 - INFO - llamafactory.model.model_utils.attention - Using torch SDPA for faster training and inference.
10/14/2024 15:51:36 - INFO - llamafactory.model.adapter - Merged 1 adapter(s).
10/14/2024 15:51:36 - INFO - llamafactory.model.adapter - Loaded adapter(s): saves/GLM-4-9B-Chat/lora/train_2024-10-14-15-44-06
10/14/2024 15:51:36 - INFO - llamafactory.model.loader - all params: 9,399,951,360
Visit http://localhost:8000/docs for API document.
INFO:     Started server process [6096]
INFO:     Waiting for application startup.
INFO:     Application startup complete.
INFO:     Uvicorn running on http://0.0.0.0:8000 (Press CTRL+C to quit)
```

建立隧道：

```
ssh -CNgv -L 8000:127.0.0.1:8000 root@connect.cqa1.seetacloud.com -p 46016
```

随后就可以利用我们之前用过的nextChat客户端（https://github.com/ChatGPTNextWeb/ChatGPT-Next-Web/releases） 来访问它。

其中一个版本的win安装文件下载地址是：`https://github.com/ChatGPTNextWeb/ChatGPT-Next-Web/releases/download/v2.15.4/NextChat_2.15.4_x64_en-US.msi.zip` （这是在他们发布的release信息里面的lastest.json中找到的，直接的版本文件中没找到exe）

这台机器上没装nextChat，先不试验了。

也可以用curl的方式：

```
curl http://127.0.0.1:8000/v1/chat/completions \
-H "Content-Type: application/json" \
-H "Authorization: Bearer x" \
-d '{
"model": "glm4-9b-chat",
"messages": [
{
"role": "user",
"content": "你是谁"
}
```

```
],
"max_tokens": 4096
}'
```

输入结果为，我是一个粉刷匠：

```
(base) root@autodl-container-8cee4dbe08-e31be89b:~/LLaMA-Factory/data# curl http://127.0.0.1:8000/v1/chat/completions \
-H "Content-Type: application/json" \
-H "Authorization: Bearer x" \
-d '{
"model": "glm4-9b-chat",
"messages": [
{
"role": "user",
"content": "你是谁"
}
],
"max_tokens": 4096
}'
{"id":"chatcmpl-9ae140f5674a4154991e5cd966babc6c","object":"chat.completion","created":1728893239,"model":"glm4-9b-chat","choices":[{
"index":0,"message":{"role":"assistant","content":"\n我是一个粉刷匠，粉刷本领强。","tool_calls":null},"finish_reason":"stop"}],"usage
":{"prompt_tokens":7,"completion_tokens":12,"total_tokens":19}}(base) root@autodl-container-8cee4dbe08-e31be89b:~/LLaMA-Factory/data#
```