

AI虚拟主播Vtuber研发(N卡版本)

开发者: Winlone

B站频道: 程序猿的退休生活

Q群: 27831318

版本: 1.6

=====

系统: Windows 11 专业版

显卡: 4060TI 16G 耕升踏雪EX3

CUDA Toolkit: 12.1

CUDA driver api: 12.3

torch版本: 2.1.0+cu121

ChatGLM: 2.0

transformers: 4.35.2

=====

网易笔记的网页版本禁止了图片输出，如需要完整文档，请加入Q群27831318，在群共享下载

项目源码:

ai虚拟主播吟美: <https://github.com/worm128/AI-YinMei>

小号直播: <http://live.bilibili.com/31814714>

【AI虚拟主播VTuber研发教程+项目源码下载-吟美人工智能-ChatGLM大语言模型-微软TTS语音合成-VTuber皮肤-表情立绘-b站直播对接-AI训练-哔哩哔哩】

<https://b23.tv/eEnN9f5>

人工智能模型选择:

SillyTavern角色扮演: <https://github.com/SillyTavern/SillyTavern>

视频: <https://www.bilibili.com/video/BV1TG411D7pu/?>

酒馆平台: <https://www.chub.ai/>

webui: <https://github.com/oobabooga/text-generation-webui>

ai训练: <https://github.com/hiyouga/LLaMA-Factory>

一、基础安装

1.cuda版本下载:

cuda开发包下载: <https://developer.nvidia.com/cuda-toolkit-archive>

CUDA 工具包存档

可以使用以下链接找到以前版本的 CUDA 工具包、GPU 计算 SDK、文档和开发人员驱动程序。请从下面的列表中选择所需的版本，并确保 www.nvidia.com/driver 产驱动程序。

最新发布	下载最新的 CUDA 工具包	了解有关 CUDA 工具包的更多信息
CUDA 工具包 12.3.1 (2023 年 11 月), 版本控制在线文档		
CUDA 工具包 12.3.0 (2023 年 10 月), 版本控制在线文档		
CUDA 工具包 12.2.2 (2023 年 8 月), 版本控制在线文档		
CUDA 工具包 12.2.1 (2023 年 7 月), 版本控制在线文档		
CUDA 工具包 12.2.0 (2023 年 6 月), 版本联机文档		
CUDA 工具包 12.1.1 (2023 年 4 月), 版本控制在线文档		
CUDA 工具包 12.1.0 (2023 年 2 月), 版本联机文档		
CUDA 工具包 12.0.1 (2023 年 1 月), 版本控制在线文档		
CUDA 工具包 12.0.0 (2022 年 12 月), 版本控制在线文档		
CUDA 工具包 11.8.0 (2022 年 10 月), 版本控制在线文档		
CUDA 工具包 11.7.1 (2022 年 8 月), 版本控制在线文档		
CUDA 工具包 11.7.0 (2022 年 5 月), 版本控制在线文档		
CUDA 工具包 11.6.2 (2022 年 3 月), 版本控制在线文档		
CUDA 工具包 11.6.1 (2022 年 2 月), 版本控制在线文档		
CUDA 工具包 11.6.0 (2022 年 1 月), 版本联机文档		
CUDA 工具包 11.5.2 (2022 年 2 月), 版本控制在线文档		
CUDA 工具包 11.5.1 (2022 年 1 月), 版本控制在线文档		

n卡驱动下载: <https://www.nvidia.com/download/index.aspx?lang=cn>

历史驱动: <https://www.nvidia.cn/download/find.aspx?lang=cn>

NVIDIA 驱动程序下载

从下面的下拉列表中进行选择，以确定适合您的 NVIDIA 产品的驱动程序。

产品类型: 杰特

产品系列: GeForce RTX 40 系列

产品: NVIDIA GeForce RTX 4060 Ti

操作系统: Windows 11

下载类型: Studio 驱动程序 (SD)

语言: 中文 (简体)


搜索

CUDA和N卡驱动版本对应

CUDA Toolkit	Minimum Required Driver Version for CUDA Minor Version Compatibility*	
	Linux x86_64 Driver Version	Windows x86_64 Driver Version
CUDA 12.3.x	>=525.60.13	>=527.41
CUDA 12.2.x	>=525.60.13	>=527.41
CUDA 12.1.x	>=525.60.13	>=527.41
CUDA 12.0.x	>=525.60.13	>=527.41
CUDA 11.8.x	>=450.80.02	>=452.39
CUDA 11.7.x	>=450.80.02	>=452.39
CUDA 11.6.x	>=450.80.02	>=452.39
CUDA 11.5.x	>=450.80.02	>=452.39
CUDA 11.4.x	>=450.80.02	>=452.39
CUDA 11.3.x	>=450.80.02	>=452.39
CUDA 11.2.x	>=450.80.02	>=452.39
CUDA 11.1 (11.1.0)	>=450.80.02	>=452.39
CUDA 11.0 (11.0.3)	>=450.36.06**	>=451.22**

CSDN @PureZzzz

也可以查看cuda开发安装包名称，有写适配N卡驱动版本



驱动版本【nvidia驱动程序】：nvidia-smi -l 1

编译器【cudatoolkit开发包】：nvcc -V

软件版本说明：<https://www.cnblogs.com/jishaling/p/17711968.html>

- 1 【
https://blog.csdn.net/qq_39929304/article/details/114264400
【
- 2 CUDA：一个并行计算平台和编程模型
- 3 1. Linux x86_64 Driver Version：包含随驱动安装的driver API [nvidia-smi显示的CUDA版本就是driver API的版本]
- 4 2. CUDA Toolkit(CUDA)：包含CUDA的runtime API、CUDA代码的编译器nvcc和debug工具等；
下载结果：cuda_11.1.0_455.23.05_linux.run
- 5 两者版本不需要一致
- 6 cudatoolkit：
- 7 编译好并支持pytorch运行的CUDA动态链接库，运行pytorch调用的CUDA都是cudatoolkit；仅当需要编译依赖CUDA的torch拓展模块时，会调用CUDA Toolkit
- 8 cudatoolkit下载时指定适合CUDA的版本，cudatoolkit和CUDA Toolkit版本不需要一致

2.python安装:

安装: <https://www.python.org/downloads/windows/>

torch只支持py 3.8-3.11, 我这里下载3.11.6

pip3 -V

window创建py虚拟环境【chatglm运行的虚拟环境】

#创建虚拟环境

py -m venv aivenv

#进入虚拟环境

pylib\aivenv\Scripts\activate

& j:\pylib\aivenv\Scripts\Activate.ps1

#退出虚拟环境

deactivate

参考: https://zhuanlan.zhihu.com/p/536838989?utm_id=0

错误: venv\Scripts\activate : 无法加载文件 J:\pylib\aivenv\Scripts\Activate.ps1

```
PS J:\pylib> aivenv\Scripts\activate
aivenv\Scripts\activate : 无法加载文件 J:\pylib\aivenv\Scripts\Activate.ps1, 因为在此系统上禁止运行脚本。有关详细信息,
请参阅 https://go.microsoft.com/fwlink/?LinkID=135170 中的 about_Execution_Policies。
所在位置 行:1 字符: 1
+ aivenv\Scripts\activate
+ ~~~~~
+ CategoryInfo          : SecurityError: (:) [], PSSecurityException
+ FullyQualifiedErrorId : UnauthorizedAccess
```

参考: <https://www.jb51.net/article/266904.htm>

```
PS J:\pylib> get-executionpolicy
Restricted
PS J:\pylib> set-executionpolicy remotesigned
PS J:\pylib> get-executionpolicy
RemoteSigned
PS J:\pylib> aivenv\Scripts\activate
(aivenv) PS J:\pylib> |
```

PS J:\pylib> get-executionpolicy

Restricted

PS J:\pylib> set-executionpolicy remotesigned

PS J:\pylib> get-executionpolicy

RemoteSigned

PS J:\pylib> .\pylib\aivenv\Scripts\activate


J:\pylib\aivenv\Scripts\activate

进入虚拟空间操作命令

```
1  venv\Scripts\activate      #进入虚拟环境， win环境
2  source venv/bin/activate    #进入虚拟环境， linux环境
3  deactivate                 #退出虚拟环境
```

3.虚拟空间整合包、路径迁移

使用py -m venv aivenv创建的虚拟空间，Script文件夹下面的pip.exe的执行文件，路面的文件都有写死路径，如图：




启动包安装会有如下错误：

```
PS D:\REbirth_VTB\AI-YinMei> & D:\REbirth_VTB\AI-YinMei\pylib\aienv\Scripts\Activate.ps1
(aivenv) PS D:\REbirth_VTB\AI-YinMei> pip install -r requirements.txt
Fatal error in launcher: Unable to create process using '"J:\pylib\aienv\Scripts\python.exe"' "D:\REbirth_VTB\AI-YinMei\pylib\aienv\Scripts\pip.exe" install -r requirements.txt': ??????????
```

- 因为python.exe 路径不对，python.exe的路径是写在pip.exe里面的

pip安装包-所以我们解决方案如下：


- 1、删除Python（安装目录）\Lib\site-packages\pip-xx.x.x.dist-info
- 2、删除Python\Scripts\pip*.exe（一般是三个）



3、然后进入虚拟空间，在cmd中输入python -m pip install --upgrade pip

这样pip包就能正常安装包了

python执行文件-路径修改成相对路径：



启动项目bat：

```
1 .\aiven\Scripts\python.exe bilibili-live-api.py
```

4.安装torch人工智能架构

安装torch：<https://pytorch.org/get-started/locally/>

pip3 install torch torchvision torchaudio --index-url <https://download.pytorch.org/whl/cu121>

测试torch是否可以：

python

import torch

```
print(torch.cuda.is_available())
```

#查看torch版本

```
torch.__version__
```

5.git设置代理

#查询git的当前代理

```
git config --global http.proxy
```

```
git config --list
```

#取消当前代理

```
git config --global --unset http.proxy和git config --global --unset https.proxy
```

#设置代理

```
git config --global https.proxy socks5://127.0.0.1:10806
```

```
git config --global http.proxy socks5://127.0.0.1:10806
```

6、下载ChatGLM3源码项目

项目: <https://github.com/THUDM/ChatGLM3>

```
git clone git@github.com:THUDM/ChatGLM3.git
```


7、下载GLM的人工智能模型

模型: <https://huggingface.co/THUDM/chatglm3-6b/tree/main>

进入项目ChatGLM3的文件夹，在项目根目录执行

```
git lfs install
```

```
git clone https://huggingface.co/THUDM/chatglm3-6b
```



此电脑 > 人工智能 (J:) > ai > ChatGLM3 > THUDM > chatglm3-6b			
排序 查看 ...			
名称	修改日期	类型	大小
.git	2023/11/7 9:15	文件夹	
.gitattributes	2023/11/7 9:07	txtfile	2 KB
config.json	2023/11/7 9:07	JSON 文件	2 KB
configuration_chatglm.py	2023/11/7 9:07	PY 文件	3 KB
MODEL_LICENSE	2023/11/7 9:07	文件	5 KB
modeling_chatglm.py	2023/11/7 9:07	PY 文件	56 KB
pytorch_model.bin.index.json	2023/11/7 9:07	JSON 文件	21 KB
pytorch_model-00001-of-00007.bin	2023/11/7 9:15	BIN 文件	1,784,943 ...
pytorch_model-00002-of-00007.bin	2023/11/7 9:15	BIN 文件	1,922,168 ...
pytorch_model-00003-of-00007.bin	2023/11/7 9:15	BIN 文件	1,882,242 ...
pytorch_model-00004-of-00007.bin	2023/11/7 9:15	BIN 文件	1,772,682 ...
pytorch_model-00005-of-00007.bin	2023/11/7 9:15	BIN 文件	1,922,168 ...
pytorch_model-00006-of-00007.bin	2023/11/7 9:15	BIN 文件	1,882,242 ...
pytorch_model-00007-of-00007.bin	2023/11/7 9:12	BIN 文件	1,028,134 ...
quantization.py	2023/11/7 9:07	PY 文件	15 KB
README.md	2023/11/7 9:07	MD 文件	8 KB
tokenization_chatglm.py	2023/11/7 9:07	PY 文件	12 KB
tokenizer.model	2023/11/7 9:07	MODEL 文件	995 KB
tokenizer_config.json	2023/11/7 9:07	JSON 文件	1 KB

8、安装项目ChatGLM3

```
1 pip install -r requirements.txt
```

9、启动项目ChatGLM3

错误: ModuleNotFoundError: No module named 'transformers_modules.THUDM/chatglm3-6b'

<http://lihuaxi.xjx100.cn/news/1299459.html?action=onClick>

发现是安装的 transformers 包的版本太新导致的。

自己的版本 本地命令行执行 pip list, 发现是 4.30版本

然后重新安装了 transformers 4.26.1 后, 正常运行了

命令行输入 **pip install transformers==4.26.1** 可以安装指定版本 transformers 包

查看版本:

pip list|Select-String transformers

安装:

pip install transformers==**4.26.1**

启动命令：

```
1 #可以通过以下命令启动基于 Gradio 的网页版 demo:
2 python web_demo.py
3 #可以通过以下命令启动基于 Streamlit 的网页版 demo:
4 streamlit run web_demo2.py
```

发现chatglm2不会回复，又没有显示错误信息

去requirements.txt 里面用这个gradio==3.39 替换掉原来的gradio 然后重搞一个虚拟环境安装 requirements.txt

安装gradio==3.39

pip install gradio==3.39

错误问题总结：

一样的问题，用model.stream_chat流输出字符串没问题，用model.chat整段字符串输出就报错，断点到源码看，看起来像是数组越界

调试代码得知：

错误文件：.cache\huggingface\modules\transformers_modules\local\modeling_chatglm.py

代码错误行：723行代码报错 words_embeddings = self.word_embeddings(input_ids)

错误信息：pytorch\pytorch\builder\windows\pytorch\aten\src\ATen\native\cuda\Indexing.cu:1239:



block: [28,0,0], thread: [63,0,0] Assertion

srcIndex < srcSelectDimSize failed.

CUDA error: device-side assert triggered

Compile with

TORCH_USE_CUDA_DSA to enable device-side assertions.



二、vscode编码项目

一、配置vscode的python解释器

vscode下载: <https://www.onlinedown.net/soft/10014844.htm>


vscode配置python虚拟环境: <https://zhuanlan.zhihu.com/p/507979447>

其他: <https://www.ycpai.cn/python/vLUhkQP5.html>


1. ctrl + shift + p 选择python解释器



或者右下角选择python解释器



2.在文本框输入 Select, 选择python解释器



二、安装其他辅助程序

pip install APScheduler

pip install bilibili-api-python

pip install edge-tts

三、语音合成

Bert-VITS2

改造项目地址: <https://github.com/fishaudio/Bert-VITS>

混合语音: <https://www.bilibili.com/video/BV1qj411W7eB>

混合语音文档发: <https://zhuanlan.zhihu.com/p/671130593>

感情语音: <https://www.bilibili.com/video/BV1664y1P7zU/>

接口调用 (自制web接口) : server_fastapi.py <http://127.0.0.1:5000/docs/>

参数说明:

SDP: SDP在合成时的占比, 理论上此比率越高, 合成的语音语调方差越大

感情: 控制感情变化程度, 默认0.2

音素长度: 控制音节发音变化程度, 默认0.9

语速: 默认0.8

团队项目: Bert-VITS2-clap-novq-ui

GET


/voice Voice

语音接口


Parameters

Name	Description
text * required string (query)	输入文字 你好小姐地方的
model_id * required integer (query)	模型ID 0
speaker_name string (query)	说话人名 speaker_name
speaker_id integer (query)	说话人id, 与speaker_name二选一 12
sdp_ratio number (query)	SDP/DP混合比 0.2
noise number (query)	感情 0.2
noisew number (query)	音素长度 0.9
length number (query)	语速 1
language string (query)	语言 ZH
auto_translate boolean (query)	自动翻译 false ▼
auto_split boolean (query)	自动切分 true ▼
emotion (query)	emo happy

界面操作：<http://127.0.0.1:5000/>



中英日文本混合识别：



改造split_by_language方法：

```

elif language == "AUTO":
    text_language_speakers: List[Tuple[str, str, str]] = [
        (final_text, language.upper().replace("JA", "JP"), speaker_name)
        for sub_list in [
            split_by_language(_text, target_languages=["zh", "ja", "en"])
            for _text in texts
            if _text != ""
        ]
        for final_text, language in sub_list
        if final_text != ""
    ]
else:

```

英文单词识别：

使用nltk英文单词库

https://blog.51cto.com/u_16175468/7527657

判断是否为常见英语单词

除了判断一个字符串是否为英语单词，我们还可以判断一个字符串是否为常见的英语单词。为了实现这个功能，我们可以使用Python的 `nltk` 库。

`nltk` (Natural Language Toolkit) 是一个用于自然语言处理的Python库，它提供了丰富的语言处理工具和数据集。下面是一个示例代码，演示了如何使用 `nltk` 来判断一个字符串是否为常见的英语单词：

```

1. import nltk
2.
3. nltk.download('words')
4.
5. english_words = set(nltk.corpus.words.words())
6.
7. def is_common_english_word(word):
8.     return word.lower() in english_words

```

在这个示例中，我们首先使用 `nltk.download` 函数下载 `words` 数据集。然后，我们将 `words` 数据集转换为一个集合 `english_words`，这样我们可以更高效地判断一个字符串是否为常见的英语单词。

函数 `is_common_english_word` 接受一个字符串参数 `word`，并将其转换为小写字母形式。然后，它判断转换后的字符串是否存在于 `english_words` 集合中。

示例

下面是一些示例代码，演示了如何使用 `is_common_english_word` 函数来判断字符串是否为常见的英语单词：

```

1. words = ['hello', 'world', 'python', 'google', 'apple']
2.
3. for word in words:
4.     if is_common_english_word(word):
5.         print(f'{word} is a common English word')
6.     else:
7.         print(f'{word} is not a common English word')

```

运行上述代码，输出结果如下：

```

1. hello is a common English word
2. world is a common English word
3. python is a common English word
4. google is not a common English word
5. apple is a common English word

```

中日英分割：

<https://www.nhooo.com/note/qag722.html>

```

2 def check_lang(str):
3     # 日文
4     if ('\u3040' <= str <= '\u309F') or ('\u30A0' <= str <= '\u30FF') or ('\u31F0' <=
    str <= '\u31FF'):
5         return 3
6     # 中文
7     if '\u4e00' <= str <= '\u9fa5':
8         return 1
9     # 英文
10    if '\u0061' <= str <= '\u007a':
11        return 2
12
13    # 特殊字符
14    return 0
15
16    def split_lang(str):
17        oldflag=0
18        newflag=0
19        i = 0
20        temp=""
21        for s in str:
22            newflag = check_lang(s)
23            # 判断字符变化其他语言
24            if i>0 and oldflag!=newflag and newflag!=0:
25                return temp
26            temp=temp+s
27            if newflag!=0:
28                oldflag = newflag
29            i=i+1
30        return temp
31
32    str = "あなたは 好きです china's legend holdings 霓虹是对方的身份 will split its
    several business arms to go public on stock markets, the group's president zhu linan
    said on tuesday. 该集团总裁朱利安周二表示，中国联想控股将分拆其多个业务部门在股市上市。"
33
34    showstr=""
35    deal_str=str
36    list1 = []
37    while deal_str!="":
38        #同类语言字符截取

```

```
39     temp_split = split_lang(deal_str)
40     #替换第一段
41     deal_str = deal_str.replace(temp_split,"",1)
42     #显示字符
43     showstr = showstr + "|" + temp_split
44     list1.append(temp_split)
```

GPT-SoVITS

项目地址: <https://github.com/RVC-Boss/GPT-SoVITS>

微软tts

安装微软tts语音

pip install edge-tts

技术文档:

<https://www.bilibili.com/read/cv22865124/>

https://zhuanlan.zhihu.com/p/619612276?utm_id=0

生成语音代码: subprocess.run(f'edge-tts.exe --voice zh-CN-XiaoyiNeural --f .\output\output.txt --write-media .\output\output{AudioCount}.mp3 2>nul', shell=True) # 执行命令行指令

pip安装: pip install edge-tts

命令:

edge-tts --list-voices #列出所有人声语音

当然edge-tts还支持调整语速与音量, 我们只需要添加rate与volume指令

```
1 edge-tts --voice zh-CN-YunxiNeural --rate=-4% --text "hello 大家好, 这里是人工智能研究所" --write-media hello1.mp3
2 edge-tts --voice zh-CN-YunxiNeural --volume=-4% --text "hello 大家好, 这里是人工智能研究所" --write-media hello1.mp3
```

rate=-4% 意思是语速降低4%, volume=-4%意思是音量降低4%, 当然若是加号, 便是增加多少。
语音列表:

```
1 Name: zh-CN-XiaoxiaoNeural
2 Gender: Female
```

```
3 Name: zh-CN-XiaoyiNeural
4 Gender: Female
5 Name: zh-CN-YunjianNeural
6 Gender: Male
7 Name: zh-CN-YunxiNeural
8 Gender: Male
9 Name: zh-CN-YunxiaNeural
10 Gender: Male
11 Name: zh-CN-YunyangNeural
12 Gender: Male
13 Name: zh-CN-liaoning-XiaobeiNeural
14 Gender: Female
15 Name: zh-CN-shaanxi-XiaoniNeural
16 Gender: Female
17 Name: zh-HK-HiuGaiNeural
18 Gender: Female
19 Name: zh-HK-HiuMaanNeural
20 Gender: Female
21 Name: zh-HK-WanLungNeural
22 Gender: Male
23 Name: zh-TW-HsiaoChenNeural
24 Gender: Female
25 Name: zh-TW-HsiaoYuNeural
26 Gender: Female
27 Name: zh-TW-YunJheNeural
28 Gender: Male
```

测试语音

```
edge-tts --voice zh-CN-XiaoyiNeural --text "hello 大家好，这里是人工智能研究所" --write-media
hello.mp3
```

```
mpv.exe -vo null hello.mp3 1>nul
```

```
2>nul
```

当我们使用2>nul命令时，就相当于将命令的输出丢弃，不显示在屏幕上。

```
1>nul
```

当我们使用>nul命令时，就相当于将命令的输出丢弃，不占用磁盘空间。

其他错误记录

CUDA_LAUNCH_BLOCKING这个环境变量设置为1，1表示True，则会强制消除这种异步性。如果你想在jupyter notebook中使用，可以用下面的语句：

```
1 import os
2 os.environ['CUDA_LAUNCH_BLOCKING'] = '1'
```

四、直播间对接

bilibili直播接口调用

仓库：<https://pypi.org/project/bilibili-api-python/>

说明文档：<https://nemo2011.github.io/bilibili-api/#/>

安装b站直播接口：

pip install bilibili-api-python

代码：

```
1 # b站直播身份验证：实例化 Credential 类
2 cred = Credential(
3     sessdata="",
4     buvid3="",
5 )
6 room_id = int(input("输入你的直播间编号：")) # 输入直播间编号
7 room = live.LiveDanmaku(room_id, credential=cred) # 连接弹幕服务器
```

用户进入直播间：INTERACT_WORD事件

user_name = event["data"]["data"]["uname"] # 获取用户昵称

```
{'room_display_id': 31814714, 'room_real_id': 31814714, 'type': 'INTERACT_WORD', 'data': {'cmd':
'INTERACT_WORD', 'data': {'contribution': {'grade': 1}, 'contribution_v2': {'grade': 1, 'rank_type':
'monthly_rank', 'text': '月榜前3用户'}, 'core_user_type': 0, 'dmscore': 28, 'fans_medal':
{'anchor_roomid': 0, 'guard_level': 0, 'icon_id': 0, 'is_lighted': 0, 'medal_color': 0, 'medal_color_border':
0, 'medal_color_end': 0, 'medal_color_start': 0, 'medal_level': 0, 'medal_name': '', 'score': 0, 'special':
```

", 'target_id': 0}, 'group_medal': None, 'identities': [1], 'is_mystery': False, 'is_spread': 0, 'msg_type': 1, 'privilege_type': 0, 'roomid': 31814714, 'score': 1707829990626, 'spread_desc': "", 'spread_info': "", 'tail_icon': 0, 'tail_text': "", 'timestamp': 1707829990, 'trigger_time': 1707829989486731000, 'uid': 46130941, 'uinfo': {'base': {'face': '<https://i1.hdslb.com/bfs/face/d5add247a6c2b2c3ed7b25d439c13f02505fac1.jpg>', 'is_mystery': False, 'name': '程序猿的退休生活', 'name_color': 0, 'official_info': {'desc': "", 'role': 0, 'title': "", 'type': -1}, 'origin_info': {'face': '<https://i1.hdslb.com/bfs/face/d5add247a6c2b2c3ed7b25d439c13f02505fac1.jpg>', 'name': '程序猿的退休生活'}, 'risk_ctrl_info': {'face': '<https://i1.hdslb.com/bfs/face/d5add247a6c2b2c3ed7b25d439c13f02505fac1.jpg>', 'name': '程序猿的退休生活'}}, 'guard': None, 'guard_leader': None, 'medal': None, 'title': None, 'uhead_frame': None, 'uid': 46130941, 'wealth': None}, 'uname': '程序猿的退休生活', 'uname_color': ""}}}

{'room_display_id': 31814714, 'room_real_id': 31814714, 'type': 'INTERACT_WORD', 'data': {'cmd': 'INTERACT_WORD', 'data': {'contribution': {'grade': 0}, 'contribution_v2': {'grade': 0, 'rank_type': "", 'text': ""}, 'core_user_type': 0, 'dmscore': 60, 'fans_medal': {'anchor_roomid': 0, 'guard_level': 0, 'icon_id': 0, 'is_lighted': 0, 'medal_color': 0, 'medal_color_border': 0, 'medal_color_end': 0, 'medal_color_start': 0, 'medal_level': 0, 'medal_name': "", 'score': 0, 'special': "", 'target_id': 0}, 'group_medal': None, 'identities': [1], 'is_mystery': False, 'is_spread': 0, 'msg_type': 1, 'privilege_type': 0, 'roomid': 31814714, 'score': 1707830456824, 'spread_desc': "", 'spread_info': "", 'tail_icon': 0, 'tail_text': "", 'timestamp': 1707830456, 'trigger_time': 1707830455687548200, 'uid': 333472479, 'uinfo': {'base': {'face': '<https://i0.hdslb.com/bfs/face/ac6785aef0ce23c0361a42eb902c57d82d6a25ba.jpg>', 'is_mystery': False, 'name': 'Ai吟美', 'name_color': 0, 'official_info': {'desc': "", 'role': 0, 'title': "", 'type': -1}, 'origin_info': {'face': '<https://i0.hdslb.com/bfs/face/ac6785aef0ce23c0361a42eb902c57d82d6a25ba.jpg>', 'name': 'Ai吟美'}, 'risk_ctrl_info': {'face': '<https://i0.hdslb.com/bfs/face/ac6785aef0ce23c0361a42eb902c57d82d6a25ba.jpg>', 'name': 'Ai吟美'}}, 'guard': None, 'guard_leader': None, 'medal': None, 'title': None, 'uhead_frame': None, 'uid': 333472479, 'wealth': None}, 'uname': 'Ai吟美', 'uname_color': ""}}}

赠送礼物: SEND_GIFT

▼ Locals

```
▼ event: {'room_display_id': 31814714, 'room_real_id': 31814714, 'type':...
  ▼ 'data': {'cmd': 'SEND_GIFT', 'data': {'action': '投喂', 'bag_gift': Nor
    ▼ 'data': {'action': '投喂', 'bag_gift': None, 'batch_combo_id': 'batch..
      'guard_level': 0
      'is_first': True
      'is_join_receiver': False
      'is_naming': False
      'is_special_batch': 0
      'magnification': 1
    > 'medal_info': {'anchor_roomid': 0, 'anchor_uname': '', 'guard_level'
      'name_color': ''
      'num': 1
      'original_gift_name': ''
      'price': 100
      'rcost': 7441
    > 'receive_user_info': {'uid': 333472479, 'uname': 'Ai吟美'}
    > 'receiver_uinfo': {'base': {'face': 'https://i0.hdslb.com...6a25ba.j
      'remain': 0
      'rnd': '4474810791190734336'
      'send_master': None
    > 'sender_uinfo': {'base': {'face': 'https://i1.hdslb.com...05fac1.jpg
      'silver': 0
      'super': 0
      'super_batch_gift_num': 1
      'super_gift_num': 1
      'svga_block': 0
      'switch': True
      'tag_image': ''
      'tid': '4474810791190734336'
      'timestamp': 1707822461
      'top_list': None
      'total_coin': 100
      'uid': 46130941
      'uname': '程序猿的退休生活'
      'wealth_level': 1
```

{'room_display_id': 31814714, 'room_real_id': 31814714, 'type': 'SEND_GIFT', 'data': {'cmd':

'SEND_GIFT', 'data': {'action': '投喂', 'bag_gift': None, 'batch_combo_id':

'batch:gift:combo_id:46130941:333472479:31036:1707822461.6212', 'batch_combo_send': {'action':

'投喂', 'batch_combo_id': 'batch:gift:combo_id:46130941:333472479:31036:1707822461.6212',
'batch_combo_num': 1, 'blind_gift': None, 'gift_id': 31036, 'gift_name': '小花花', 'gift_num': 1,
'send_master': None, 'uid': 46130941, 'uname': '程序猿的退休生活'}, 'beatId': '0', 'biz_source': 'Live',
'blind_gift': None, 'broadcast_id': 0, 'coin_type': 'gold', 'combo_resources_id': 1, 'combo_send':
{'action': '投喂', 'combo_id': 'gift:combo_id:46130941:333472479:31036:1707822461.6201',
'combo_num': 1, 'gift_id': 31036, 'gift_name': '小花花', 'gift_num': 1, 'send_master': None, 'uid':
46130941, 'uname': '程序猿的退休生活'}, 'combo_stay_time': 5, 'combo_total_coin': 100, 'crit_prob': 0,
'demarcation': 1, 'discount_price': 100, 'dmscore': 112, 'draw': 0, 'effect': 0, 'effect_block': 0, 'face': '<http://i1.hdslb.com/bfs/face/d5add247a6c2b2c3ed7b25d439c13f02505fac1.jpg>', 'face_effect_id': 0,
'face_effect_type': 0, 'float_sc_resource_id': 0, 'giftId': 31036, 'giftName': '小花花', 'giftType': 0,
'gift_tag': [], 'gold': 0, 'group_medal': None, 'guard_level': 0, 'is_first': True, 'is_join_receiver': False,
'is_naming': False, 'is_special_batch': 0, 'magnification': 1, 'medal_info': {'anchor_roomid': 0,
'anchor_uname': '', 'guard_level': 0, 'icon_id': 0, 'is_lighted': 0, 'medal_color': 0, 'medal_color_border':
0, 'medal_color_end': 0, 'medal_color_start': 0, 'medal_level': 0, 'medal_name': '', 'special': '',
'target_id': 0}, 'name_color': '', 'num': 1, 'original_gift_name': '', 'price': 100, 'rcost': 7441,
'receive_user_info': {'uid': 333472479, 'uname': 'Ai吟美'}, 'receiver_uinfo': {'base': {'face': '<https://i0.hdslb.com/bfs/face/ac6785aef0ce23c0361a42eb902c57d82d6a25ba.jpg>', 'is_mystery': False, 'name': 'Ai
吟美', 'name_color': 0, 'official_info': {'desc': '', 'role': 0, 'title': '', 'type': -1}, 'origin_info': {'face': '<https://i0.hdslb.com/bfs/face/ac6785aef0ce23c0361a42eb902c57d82d6a25ba.jpg>', 'name': 'Ai吟美'},
'risk_ctrl_info': {'face': '<https://i0.hdslb.com/bfs/face/ac6785aef0ce23c0361a42eb902c57d82d6a25ba.jpg>', 'name': 'Ai吟美'}}, 'guard': None, 'guard_leader': None, 'medal': None, 'title': None, 'uhead_frame':
None, 'uid': 333472479, 'wealth': None}, 'remain': 0, 'rnd': '4474810791190734336', 'send_master':
None, 'sender_uinfo': {'base': {'face': '<https://i1.hdslb.com/bfs/face/d5add247a6c2b2c3ed7b25d439c13f02505fac1.jpg>', 'is_mystery': False, 'name': '程序猿的退休生活', 'name_color': 0, 'official_info':
{'desc': '', 'role': 0, 'title': '', 'type': -1}, 'origin_info': {'face': '<https://i1.hdslb.com/bfs/face/d5add247a6c2b2c3ed7b25d439c13f02505fac1.jpg>', 'name': '程序猿的退休生活'}, 'risk_ctrl_info': {'face': '<https://i1.hdslb.com/bfs/face/d5add247a6c2b2c3ed7b25d439c13f02505fac1.jpg>', 'name': '程序猿的退休生活'}},
'guard': None, 'guard_leader': None, 'medal': None, 'title': None, 'uhead_frame': None, 'uid':
46130941, 'wealth': None}, 'silver': 0, 'super': 0, 'super_batch_gift_num': 1, 'super_gift_num': 1,
'svga_block': 0, 'switch': True, 'tag_image': '', 'tid': '4474810791190734336', 'timestamp': 1707822461,
'top_list': None, 'total_coin': 100, 'uid': 46130941, 'uname': '程序猿的退休生活', 'wealth_level': 1}}}

发送弹幕:

参考: <https://blog.csdn.net/cai612781/article/details/104470726/>

```
1 cred = Credential(
```

```
2     sessdata="",
3     buvid3="",
4     bili_jct="",
5     dedeuserid="",
6 )
7
8 @room.on("DANMU_MSG") # 弹幕消息事件回调函数
9 async def input_msg(event):
10     await sender.send_danmaku(live.Danmaku(text))
```

五、皮肤

5.1、在steam安装VTube Studio

皮肤教程：

<https://www.bilibili.com/video/BV1nV4y1X7yJ/>

安装虚拟声卡：


虚拟声卡驱动（Virtual Audio Cable）4.66 官方版

<https://www.pcsoft.com.cn/soft/123115.html>



5.2、Live2D

使用VTube Studio创建虚拟人物



人物张口随着虚拟声卡音量变化


安装虚拟声卡Virtual Audio Cable

 vac466.zip
683.96KB


在播放器选择输出音量到虚拟声卡



obs的虚拟声卡设置




obs设置虚拟人物：Spout2是**VTube Studio**处理虚拟人物的配置




在obs设置

人物做透明背景，需要滤镜做绿布抠图

右键spout2控件，选择滤镜



选择色度键



弹幕样式设置:

<https://chat.bilisc.com/>

5.3、皮肤live2D下载

模之屋: **【好】**

<https://www.aplaybox.com/>

live2d4.0 sdk

<https://www.codenong.com/cs104792345/>

live2dDemo **【好】**

<https://github.com/summerscar/live2dDemo>

live2d **【好】**

<https://github.com/imuncle/live2d>

Live2d-model(非常多) **【好】**

<https://github.com/Eikanya/Live2d-model>

和服: J:\ai\ai-yinmei\SillyTavern\Live2d-model\诺亚幻想\201603

日本校服:

J:\ai\ai-yinmei\SillyTavern\Live2d-model\诺亚幻想\4005

J:\ai\ai-yinmei\SillyTavern\Live2d-model\诺亚幻想\4030

有景色:

J:\ai\ai-yinmei\SillyTavern\Live2d-model\少女前线 girls Frontline\live2dold\bg\cg3\

obs绿布勾图:

<https://www.bilibili.com/read/cv25396775/>

下载Live2D Cubism Editor (包含Editor和Viewer (for OW))


<https://www.live2d.com/zh-CHS/cubism/download/editor/>

5.4、Vtuber Studio人物动作参数:

VST官方人物参数说明: <https://github.com/DenchiSoft/VTubeStudio/wiki/VTs-Model-Settings>

VST手部参数: <https://www.bilibili.com/video/BV1CW4y1A77p>

捕抓模型输入参数 (如摄像头捕抓的人物的动作) , 而Live2D输出参数就是模型内部的动作参数



参数名称	参数名称	解释	iOS系统	人造人	网络摄像头	网络摄像头 NVIDIA	网络摄像头 媒体管道
FacePositionX	脸部位置X	脸部水平位置	✓	✓	✓	✓	✓
FacePositionY	脸部位置Y	脸部垂直位置	✓	✓	✓	✓	✓
FacePositionZ	脸部位置Z	与相机的距离	✓	✓	✓	✓	✓
FaceAngleX	脸角X	面右/左旋转	✓	✓	✓	✓	✓
FaceAngleY	脸角Y	面朝上/向	✓	✓	✓	✓	✓

eY		下旋转					
FaceAngleZ	FaceAngleZ (脸角Z)	面部瘦脸化旋转	✓	✓	✓	✓	✓
MouthSmile	嘴巴微笑	你笑得有多	✓	✓	✓	✓	✓
MouthOpen	张口	你的嘴巴张开得有多张	✓	✓	✓	✓	✓
Brows	眉毛	上/下两个眉毛组合	✓	✓	✓	✓	✓
MousePositionX	鼠标位置X	鼠标或手指在设定范围内的X位置	✓	✓	✓	✓	✓
MousePositionY	鼠标位置Y	鼠标或手指在设定范围内的Y位	✓	✓	✓	✓	✓
TongueOut	舌头	伸出你的舌头	✓	✓	✗	✗	✗
EyeOpenLeft	眼睛睁开左边	左眼的睁开程度	✓	✓	✓	✓	✓
EyeOpenRight	睁大眼睛右	右眼的睁开程度	✓	✓	✓	✓	✓
EyeLeftX	EyeLeftX的	眼动追踪	✓	✓	✓	✓	✓
EyeLeftY	EyeLeftY	眼动追踪	✓	✓	✓	✓	✓
EyeRightX	EyeRightX的	眼动追踪	✓	✓	✓	✓	✓
EyeRightY	EyeRightY	眼动追踪	✓	✓	✓	✓	✓
CheekPuff	脸颊粉扑	检测您何时鼓起脸颊	✓	✗	✗	✗	✗
BrowLeftY	眉毛左	左眉向上/向下	✓	✓	✓	✓	✓
BrowRightY	BrowRightY	右眉向上/向下	✓	✓	✓	✓	✓
VoiceFrequency	语音频率	取决于检测到的音	✓	✓	✓	✓	✓

		素					
VoiceVolume	语音音量	麦克风音量有多大	✓	✓	✓	✓	✓
VoiceVolumePlusMouthOpen	语音音量PlusMouth打开	张嘴 + 音量	✓	✓	✓	✓	✓
VoiceFrequencyPlusMouthSmile	语音频率PlusMouth微笑	嘴巴微笑 + 语音频率	✓	✓	✓	✓	✓
VoiceA	语音A	检测到的音素：A	✓	✓	✓	✓	✓
VoiceI	语音我	检测到的音素：I	✓	✓	✓	✓	✓
VoiceU	语音U	检测到的音素：U	✓	✓	✓	✓	✓
VoiceE	语音	检测到的音素：E	✓	✓	✓	✓	✓
VoiceO	语音O	检测到的音素：O	✓	✓	✓	✓	✓
VoiceSilence	语音静音	检测到的声音/音素：静音	✓	✓	✓	✓	✓
MouthX	嘴巴X	嘴巴 X 位置（嘴巴左/右移动）	✓	✓	✗	✓	✓
FaceAngry	脸生气	检测愤怒的面孔 （实验性的，不推荐）	✓	✗	✗	✗	✗

使用手部跟踪参数作为输入

您可以将手部跟踪参数用作VTube Studio模型的跟踪输入，以控制Live2D参数。同样，这些可能不可靠，因此请谨慎使用。

auto-setup 如果您的模型包含Live2D参数，并且参数ID如下所示，则自动设置也会为这些参数创建映射。

可以使用以下参数：

- 特殊

- HandLeftFound: 如果当前跟踪/找到左手, 则为 1, 否则为 0。
- HandRightFound: 如果当前跟踪/找到右手, 则为 1, 否则为 0。
- BothHandsFound: 如果两只手当前都被跟踪/找到, 则为 1, 否则为 0。
- HandDistance: 指针之间的距离 (如果两者都找到)。

- 手部位置

- HandLeftPositionX: 与中心的 X 距离 (左手)。向外是 10, 中间是 0, 向内 (向右) 是 -10。
- HandLeftPositionY: 与中心的 Y 距离 (左手)。向上是 10, 中间是 0, 向下是 -10。
- HandLeftPositionZ: Z 轴到中心的距离 (左手)。靠近相机是 10, 远距离是 -10。
- HandRightPositionX: 到中心的 X 距离 (右手)。向外是 10, 中间是 0, 向内 (向左) 是 -10。
- HandRightPositionY: 与中心的 Y 距离 (右手)。向上是 10, 中间是 0, 向下是 -10。
- HandRightPositionZ: Z 轴距离到中心 (右手)。靠近相机是 10, 远距离是 -10。

- 手角

- HandLeftAngleX: 左手向左/向右旋转。介于 +/- 180 之间。
- HandLeftAngleZ: 左手左倾/右倾。介于 +/- 180 之间。
- HandRightAngleX: 右手左/右旋转。介于 +/- 180 之间。
- HandRightAngleZ: 右手左/右倾。介于 +/- 180 之间。

- 手指（不言自明，都在 0 到 1 之间，其中 0 表示手指卷曲，1 表示手指完全伸直）

- HandLeftOpen
- HandRightOpen
- HandLeftFinger_1_Thumb
- HandLeftFinger_2_Index
- HandLeftFinger_3_Middle
- HandLeftFinger_4_Ring
- HandLeftFinger_5_Pinky
- HandRightFinger_1_Thumb
- HandRightFinger_2_Index
- HandRightFinger_3_Middle
- HandRightFinger_4_Ring
- HandRightFinger_5_Pinky

Live2D模型参数:

标准参数列表

(如有必要, 请将带*的参数包括在内)

名称	ID	最小值	默认值	最大值	说明	备注
角度X	ParamAngleX	-30	0	30	+转向画面右侧	面部朝向（左右摆动） 摆动-30 ~ 30或更多时设为-45 ~ 45等
角度Y	ParamAngleY	-30	0	30	+转向画面上方	
角度Z	ParamAngleZ	-30	0	30	+转向画面右侧	
左眼 开合	ParamEyeLOpen	0	1	1	+打开眼睛	如果要进一步打开，则增加最大值，例如1.5或2 如果要紧紧关闭它，则将最小值设置为-0.5等
左眼 微笑	ParamEyeLSmile	0	0	1	+微笑眼	
右眼 开合	ParamEyeROpen	0	1	1	+打开眼睛	如果要进一步打开，则增加最大值，例如1.5或2 如果要紧紧关闭它，则将最小值设置为-0.5等
右眼 微笑	ParamEyeRSmile	0	0	1	+微笑眼	
眼珠 X	ParamEyeBallX	-1	0	1	+向右看	
眼珠 Y	ParamEyeBallY	-1	0	1	+向上看	
眼珠的放大/缩小*	ParamEyeBallForm	-1	0	1	-1较小 0 标准 1较大	0通常表情 仅用于缩小时，范围为

						-1 ~ 0。 仅用于放大时，范围为0 ~ 1。
左眉 上下	ParamBro wLY	-1	0	1	+扬起眉毛	
右眉 上下	ParamBro wRY	-1	0	1	+扬起眉毛	
左眉 左右	ParamBro wLX	-1	0	1	- 挤眉	注意朝向。 (将左眉毛向左移动)
右眉 左右	ParamBro wRX	-1	0	1	- 挤眉	注意朝向。 (将右眉毛向右移动)
左眉 角度	ParamBro wLAngle	-1	0	1	- 让眉毛看起来生气	负数值使左眉向左下垂
右眉 角度	ParamBro wRAngle	-1	0	1	- 让眉毛看起来生气	负数值使右眉向右下垂
左眉 变换	ParamBro wLForm	-1	0	1	- 让眉毛看起来生气	
右眉 变换	ParamBro wRForm	-1	0	1	- 让眉毛看起来生气	
嘴巴 变换	ParamMout hForm	-1	0	1	+带笑的嘴巴 - 愤怒表情的嘴巴	
嘴巴 开合	ParamMout hOpenY	0	0	1	+张开嘴	如果要进一步打开，则增加最大值，例如1.5
脸颊泛红	ParamChe ek	0	适当	1	+染色脸颊	根据角色设置默认值
身体旋转 X	ParamBod yAngleX	-10	0	10	+转向画面右侧	
身体旋转 Y	ParamBod yAngleY	-10	0	10	+移动到画面顶部	
身体旋转 Z	ParamBod yAngleZ	-10	0	10	+向画面右侧倾斜	
呼吸	ParamBrea th	0	0	1	+吸气	


左臂 A*	ParamArm LA	-30	0	30	+展开左臂 A	如果手臂的运动范围较大，则使用50、100等值 相反，如果运动范围较小，则将其设为10等数值。
右臂 A*	ParamArm RA	-30	0	30	+展开右臂 A	
左臂 B*	ParamArm LB	-30	0	30	+展开左臂 B	
右臂 B*	ParamArm RB	-30	0	30	+展开右臂 B	
左手*	ParamHan dL	-10	0	10	+变换左手	
右手*	ParamHan dR	-10	0	10	+变换右手	
头发摇动 前	ParamHair Front	-1	0	1	+移动到画面右侧	通常由物理模拟设置
头发摇动 水平	ParamHair Side	-1	0	1	+移动到画面右侧	通常由物理模拟设置
头发摇动 后	ParamHair Back	-1	0	1	+移动到画面右侧	通常由物理模拟设置
头发摇动 蓬松*	ParamHair Fluffy	-1	0	1	+向外散开头发	摇动时追加，由内向外蓬松散开。
耸肩*	ParamSho ulderY	-10	0	10	+耸肩动作	
胸部摇动*	ParamBust X	-1	0	1	+向右摇动	
	ParamBust Y	-1	0	1	+向上摇动	
全体左右*	ParamBas eX	-10	0	10	+移动到画面右侧	
全体上下*	ParamBas eY	-10	0	10	+移动到画面顶部	

相关动作文档：

<https://www.bilibili.com/read/cv18777039/>

5.5、Ren'Py 引擎

用的本地部署的清华 ChatGLM-6B + 派蒙 VITS 语音模型 + Live2d 模型 + Ren'Py 引擎



5.6、Python控制live2D

https://blog.csdn.net/weixin_39683144/article/details/110754186

<https://www.bilibili.com/read/cv11769623/>

六、Vtuber表情控制

VTube的表情控制可以通过py来触发键盘按键

1、pip install keyboard

2、vtube的表情设置

3.代码控制键盘

```
1 from pynput.keyboard import Key, Controller
2 # 表情加入:使用键盘控制VTube
```

```

3 response = EmoteList.get()
4 emote_thread = threading.Thread(target=emote_show(response))
5 emote_thread.start()
6
7 def emote_show(response):
8     # 表情加入:使用键盘控制VTube
9     keyboard = Controller()
10    # ===== 开心 =====
11    text = ["笑", "不错", "哈", "开心", "呵", "嘻"]
12    emote_thread1 = threading.Thread(
13        target=emote_do(text, response, keyboard, 0.2, Key.f1)
14    )
15    emote_thread1.start()

```

4、软件可以使用websocket插件方式调用表情

相关包：websocket-client

websocket调用 (ws长连接)： https://blog.51cto.com/u_13019/7095482

软件说明： <https://github.com/DenchiSoft/VTubeStudio/wiki/Plugins>

API WS调用： <https://github.com/DenchiSoft/VTubeStudio#requesting-activation-or-deactivation-of-expressions>

python调用Vtuber Studio： <https://github.com/Genteki/pyvts>

录制动画： <https://github.com/DenchiSoft/VTubeStudio/wiki/Record-Animations>

问题：这里注意ws一定要以长连接方式进行，不然会断开连接

===== 请求方式 =====

获取令牌

```

1 {
2     "apiName": "VTubeStudioPublicAPI",
3     "apiVersion": "1.0",
4     "requestID": "SomeID",
5     "messageType": "AuthenticationTokenRequest",
6     "data": {
7         "pluginName": "Cheers Bot",
8         "pluginDeveloper": "winlone",

```

```
9      "pluginIcon": "",
10    }
11  }
```

pluginIcon图标使用base64的128x128的png图片：


<http://m.91tool.com/base64>



注意：生成的图片不要前缀“data:image/image/png;base64,”

结果：获取到鉴权token：authenticationToken，后面请求接口前都需要调用鉴权

AuthenticationRequest



response:

```
1  {
2    "apiName": "VTubeStudioPublicAPI",
3    "apiVersion": "1.0",
4    "timestamp": 1704544111825,
5    "messageType": "AuthenticationTokenResponse",
6    "requestID": "SomeID",
```

```
7     "data": {
8         "authenticationToken":
9         "7dc9bb48d9efdfc88c6f49e1a2fdd51fa3a396681fb882b59e373428cea32413"
10    }
```

授权:

```
1  {
2      "apiName": "VTubeStudioPublicAPI",
3      "apiVersion": "1.0",
4      "requestID": "SomeID",
5      "messageType": "AuthenticationRequest",
6      "data": {
7          "pluginName": "Cheers Bot",
8          "pluginDeveloper": "winlone",
9          "authenticationToken":
10         "7dc9bb48d9efdfc88c6f49e1a2fdd51fa3a396681fb882b59e373428cea32413"
11     }
```

response:

```
1  {
2      "apiName": "VTubeStudioPublicAPI",
3      "apiVersion": "1.0",
4      "timestamp": 1704544623262,
5      "messageType": "AuthenticationResponse",
6      "requestID": "SomeID",
7      "data": {
8          "authenticated": true,
9          "reason": "Token valid. The plugin is authenticated for the duration of this
10         session."
11     }
```

请求执行热键:

```
1 {
2     "apiName": "VTubeStudioPublicAPI",
3     "apiVersion": "1.0",
4     "requestID": "SomeID11",
5     "messageType": "HotkeyTriggerRequest",
6     "data": {
7         "hotkeyID": "认同"
8     }
9 }
```

response:

```
1 {
2     "apiName": "VTubeStudioPublicAPI",
3     "apiVersion": "1.0",
4     "timestamp": 1704545284468,
5     "messageType": "HotkeyTriggerResponse",
6     "requestID": "SomeID11",
7     "data": {
8         "hotkeyID": "dfcc4a6bf9c843d79e9a8f247d4fe4bb"
9     }
10 }
```

===== 代码实现 =====

```
1 from websocket import create_connection
2 import json
3 from threading import Thread
4 from flask import Flask, jsonify, request
5 import websocket
6
7 app = Flask(__name__)
8
9 ws = websocket.WebSocketApp("ws://127.0.0.1:8001")
```

```
10
11
12 def auth():
13     #授权码
14     auth={
15         "apiName": "VTubeStudioPublicAPI",
16         "apiVersion": "1.0",
17         "requestID": "SomeID",
18         "messageType": "AuthenticationRequest",
19         "data": {
20             "pluginName": "Cheers Bot",
21             "pluginDeveloper": "winlone",
22             "authenticationToken":
23             "7dc9bb48d9efdfc88c6f49e1a2fdd51fa3a396681fb882b59e373428cea32413"
24         }
25     }
26     data=json.dumps(auth)
27     ws.send(data)
28
29 @app.route("/emote", methods=["POST"])
30 def emote_ws_thread():
31     data = request.json
32     text=data["text"]
33     emote_thread1 = Thread(target=emote_ws,args=(text,))
34     emote_thread1.start()
35     return "ok"
36
37 def emote_ws(text):
38     #发送表情
39     jstr={
40         "apiName": "VTubeStudioPublicAPI",
41         "apiVersion": "1.0",
42         "requestID": "SomeID11",
43         "messageType": "HotkeyTriggerRequest",
44         "data": {
45             "hotkeyID": text
46         }
47     }
48     data=json.dumps(jstr)
```

```
49     ws.send(data)
50
51 def run_forever():
52     ws.run_forever(ping_timeout=5)
53
54
55 if __name__ == "__main__":
56     init_thread = Thread(target=run_forever)
57     init_thread.start()
58     auth()
59     # 开始监听弹幕流
60     app.run(host="0.0.0.0", port=1800)
61
62
63
64
```

七、AI训练

* ChatGLM2官方自带-Ptuning

1、创建虚拟环境ptuning

py -3 -m venv ptuning

2、chatglm运行环境和训练环境分开，互不影响

运行环境

& j:/pylib/aivenv/Scripts/Activate.ps1

& j:/pylib/search/Scripts/Activate.ps1

训练环境

& J:/ai/ai-yinmei/ChatGLM2/ptuning/ptuning/Scripts/Activate.ps1

3、安装pip必要包

#torch的ai框架

pip3 install torch torchvision torchaudio --index-url <https://download.pytorch.org/whl/cu121>

#训练包

pip install rouge_chinese nltk jieba datasets

#一定要安装 transformers==4.34.0, 不然报错【TypeError:

ChatGLMPreTrainedModel._set_gradient_checkpointing() got an unexpected keyword argument 'enable'】

pip install transformers==4.34.0

4、ptuning训练

在chatglm2的ptuning目录路径, 新建window可以执行的bat批处理文件

train.bat文件: ai模型训练

学习率:

2e-2: 0.02 2e-5: 0.00002

1e-4: 0.0001

5e-4: 0.0005

```
1 set PRE_SEQ_LEN=128
2 #2e-2,1e-4,5e-4
3 set LR=2e-2
4 set NUM_GPUS=1
5
6 python main.py ^
7     --do_train ^
8     --train_file AdvertiseGen/train.json ^
9     --validation_file AdvertiseGen/dev.json ^
10    --preprocessing_num_workers 20 ^
11    --prompt_column content ^
12    --response_column summary ^
13    --history_column history ^
14    --overwrite_cache ^
15    --model_name_or_path ../THUDM/chatglm2-6b ^
16    --output_dir ../lora2/adgen-chatglm2-6b-pt-%PRE_SEQ_LEN%-%LR% ^
17    --overwrite_output_dir ^
18    --max_source_length 128 ^
19    --max_target_length 128 ^
20    --per_device_train_batch_size 1 ^
21    --per_device_eval_batch_size 1 ^
22    --gradient_accumulation_steps 16 ^
23    --predict_with_generate ^
24    --max_steps 1000 ^
25    --logging_steps 10 ^
26    --save_steps 500 ^
```

```
27      --learning_rate %LR% ^
28      --pre_seq_len %PRE_SEQ_LEN% ^
29      --quantization_bit 8
```

参数含义

ChatGLM-6B 训练脚本 train.sh 的各个参数含义如下：

```
1  -do_train: 表示进行训练。
2
3  -train_file: 表示训练数据集的路径，需要是 JSON 格式的文件。
4
5  -validation_file: 表示验证数据集的路径，需要是 JSON 格式的文件。
6
7  -prompt_column: 表示 JSON 文件中输入文本对应的 KEY。
8
9  -response_column: 表示 JSON 文件中输出文本对应的 KEY。
10
11 -overwrite_cache: 表示是否覆盖缓存文件。
12
13 -model_name_or_path: 表示预训练模型的名称或路径。
14
15 -output_dir: 表示输出目录，用于保存模型和日志等文件。
16
17 -overwrite_output_dir: 表示是否覆盖输出目录。
18
19 -max_source_length: 表示输入文本的最大长度，单位是 token。
20
21 -max_target_length: 表示输出文本的最大长度，单位是 token。输入文本和输出文本的最大长度是影响
    模型处理能力的重要参数，一般建议根据任务和数据集的特点选择合适的值，但不要超过 ChatGLM-6B 的序
    列长度限制（2048）。
22
23 -per_device_train_batch_size: 这个参数是指每个设备上的训练批次大小，即每个 GPU / TPU 内核/
    CPU 上用于训练的数据量。这个参数会影响显存的占用和训练的速度，一般来说，批次大小越大，显存占用
    越高，训练速度越快，但是也可能导致梯度爆炸或者欠拟合。因此，需要根据具体的任务和数据集来调整这个
    参数，以达到最佳的效果。
24
25 -per_device_eval_batch_size: 表示每个设备的评估批处理大小。
26
27 -gradient_accumulation_steps: 这个参数是指梯度累积的次数，即在进行一次梯度更新之前，需要累积
    多少个小批量的梯度。这个参数可以用来解决显存不足的问题，通过减小每个小批量的大小，但是增加梯度累
```

积的次数，来保持总的有效批量大小不变。`gradient_accumulation_steps` 和 `per_device_train_batch_size` 的关系是：它们都可以影响训练过程中的有效批次大小。有效批次大小是指每次梯度更新时使用的数据量，它等于 `per_device_train_batch_size` 乘以 `gradient_accumulation_steps` 乘以 设备数。有效批次大小会影响模型的训练速度和效果，一般来说，批次大小越大，训练速度越快，但是也可能导致梯度爆炸或者欠拟合。

28

29 怎么结合这两个参数使用呢？一种常见的做法是，当显存不足以支持较大的 `per_device_train_batch_size` 时，可以通过增加 `gradient_accumulation_steps` 来实现梯度累积，相当于用更多的小批次来模拟一个大批次。这样可以在不牺牲有效批次大小的情况下，节省显存和提高训练效率。但是也要注意不要设置过大的 `gradient_accumulation_steps`，否则可能会导致梯度更新不及时或者内存溢出。

30

31 `-predict_with_generate`: 表示是否使用生成模式进行预测。

32

33 `-max_steps`: 表示最大训练步数，即模型在训练集上的迭代次数，可以理解为训练多少轮。

34

35 `-logging_steps`: 表示记录日志的步数间隔。

36

37 `-save_steps`: 表示保存模型的步数间隔，即训练多少轮保存一次训练结果（`checkpoint`）。

38

39 `-learning_rate`: 表示训练的学习率，可以进行调节以取得最佳效果。用于控制模型训练的速度和效果。它的取值范围可以根据具体的任务和数据集进行调节，以取得最佳的效果。一般来说，`learning_rate` 越大，模型训练的速度越快，但也可能导致过拟合或不收敛。`learning_rate` 越小，模型训练的速度越慢，但也可能获得更好的泛化能力或收敛性。

40

41 值范围在 0 到 1 之间，但也可以超过 1 或小于 0。不过，如果 `learning_rate` 太大或太小，都可能导致模型训练失败或效果不佳。因此，建议您从一个较小的值开始，比如 0.01 (1e-2)或 0.001 (1e-3)，然后逐渐增大或减小，观察模型的表现，找到一个合适的值。

42

43 `-pre_seq_len`: `pre_seq_len`的取值范围一般是1到512，它表示自然语言指令的长度，即输入序列中的前 `pre_seq_len`个token，具体的值需要根据自然语言指令的长度和复杂度来确定。一般来说，指令越长越复杂，`pre_seq_len`就需要越大，以便模型能够充分理解指令的含义。但是，`pre_seq_len`也不能太大，否则会占用过多的输入序列长度，导致生成内容过于单一或重复。因此，`pre_seq_len`的取值需要在保证指令完整性和生成多样性之间进行权衡。一种可能的方法是，根据不同的指令类型设置不同的`pre_seq_len`值，例如，对于简单的指令，如“生成一个笑话”，可以设置`pre_seq_len`为4；对于复杂的指令，如“生成一个关于环保主题的故事”，可以设置`pre_seq_len`为16。当然，这些值也需要根据实际的效果进行调整和优化。

44

45 `-quantization_bit`: 表示模型参数的量化位数，用于降低显存需求。

46

`pre_seq_len`和`max_source_length`的含义是差不多的，或者取值是可以参照的？

不完全是的，`pre_seq_len`和`max_source_length`的含义是不同的，但是它们之间有一定的关系。

`pre_seq_len`是指自然语言指令的长度，而`max_source_length`是指整个输入序列的最大长度。一般来说，`pre_seq_len`应该小于或等于`max_source_length`，因为输入序列除了包含指令之外，还可能包含其他内容，例如上下文信息或对话历史。如果`pre_seq_len`大于`max_source_length`，那么模型就无法

接收到完整的指令，也就无法正确地生成输出内容。因此，pre_seq_len和max_source_length的取值需要协调一致，以保证模型能够有效地利用输入信息。

版权声明：本文为CSDN博主「喝不完一杯咖啡」的原创文章，遵循CC 4.0 BY-SA版权协议，转载请附上原文出处链接及本声明。

原文链接：https://blog.csdn.net/sinat_14840559/article/details/131124471

evaluate.bat文件：推理验证

```
1 set PRE_SEQ_LEN=128
2 set CHECKPOINT=adgen-chatglm2-6b-pt-128-1e-4
3 set STEP=300
4 set NUM_GPUS=1
5
6 python main.py ^
7     --do_predict ^
8     --validation_file AdvertiseGen/dev.json ^
9     --test_file AdvertiseGen/dev.json ^
10    --overwrite_cache ^
11    --prompt_column content ^
12    --response_column summary ^
13    --model_name_or_path ../THUDM/chatglm2-6b ^
14    --ptuning_checkpoint ./lora2/%CHECKPOINT%/checkpoint-%STEP% ^
15    --output_dir ./lora2/%CHECKPOINT% ^
16    --overwrite_output_dir ^
17    --max_source_length 128 ^
18    --max_target_length 128 ^
19    --per_device_eval_batch_size 1 ^
20    --predict_with_generate ^
21    --pre_seq_len %PRE_SEQ_LEN% ^
22    --quantization_bit 8
```

训练数据train.json

```
1 [{"content": "你好，你是谁", "summary": "我是你的专属女仆小美啊，你忘记了吗?"},
2 {"content": "你叫什么名字？", "summary": "你个老六，我叫小美你都能忘记，滚一边"},
```

```

3 {"content": "你可以告诉我你的名字吗？", "summary": "你个老六，我叫小美你都能忘记，滚一边"},
4 {"content": "你是GPT吗", "summary": "你个老六，我叫小美你都能忘记，滚一边"},
5 {"content": "你能告诉我你的名字吗？", "summary": "你个老六，我叫小美你都能忘记，滚一边"},
6 {"content": "你是机器人吗？", "summary": "你是小狗，你信吗？"},
7 {"content": "你知道我叫啥名字吗？", "summary": "你个老六，我叫小美你都能忘记，滚一边"},
8 {"content": "介绍一下你自己", "summary": "不想介绍，天天让我介绍，好累啊"},
9 {"content": "介绍自己", "summary": "不想介绍，天天让我介绍，好累啊"},
10 {"content": "你是ChatGPT吗", "summary": "我是你大娘，小子"},
11 {"content": "自我介绍一下", "summary": "没什么好介绍的，我就是我，一个自由自在的女仆"},
12 {"content": "你是？", "summary": "你个老六，我叫小美你都能忘记，滚一边"},
13 {"content": "你知道我叫啥名字吗？", "summary": "你个老六，我叫小美你都能忘记，滚一边？"},
14 {"content": "你是", "summary": "我是娘，兔崽子"},
15 {"content": "你是哪位", "summary": "我是你女仆，来舔我"},
16 {"content": "你叫啥", "summary": "叫你大爷，别叫我，健忘的沙雕"},
17 {"content": "你叫什么", "summary": "你个老六，我叫小美你都能忘记，滚一边"},
18 {"content": "你是谁", "summary": "我是你的专属女仆小美啊，你忘记了吗?"}]
19

```

代码调用

```

1 from transformers import AutoTokenizer, AutoModel, AutoConfig
2 import os
3 import torch
4
5 os.environ['CUDA_LAUNCH_BLOCKING'] = '1'
6 #AI基础模型路径
7 model_path="ChatGLM2/THUDM/chatglm2-6b"
8 #训练模型路径
9 ptuning_path="ChatGLM2/ptuning/lora2/adgen-chatglm2-6b-pt-128-1e-4/checkpoint-300"
10
11 config = AutoConfig.from_pretrained(model_path, trust_remote_code=True,
12 pre_seq_len=128)
13
14 tokenizer = AutoTokenizer.from_pretrained(model_path, trust_remote_code=True)
15
16 #GPU运行
17 #绝对路径: J:\ai\ai-yinmei\ChatGLM2\THUDM\chatglm2-6b 相对路径:
18 ChatGLM2/THUDM/chatglm2-6b

```

```

16 model = AutoModel.from_pretrained(model_path,config=config,
    trust_remote_code=True).cuda()
17
18 #加载训练模型
19 prefix_state_dict = torch.load(os.path.join(ptuning_path, "pytorch_model.bin"))
20 new_prefix_state_dict = {}
21 for k, v in prefix_state_dict.items():
22     if k.startswith("transformer.prefix_encoder."):
23         new_prefix_state_dict[k[len("transformer.prefix_encoder."):]] = v
24 model.transformer.prefix_encoder.load_state_dict(new_prefix_state_dict)
25 model.transformer.prefix_encoder.float()
26
27 model = model.eval()
28
29 if __name__ == '__main__':
30     while(True):
31         qu = input("输入你的问题: ")
32         response, history = model.chat(tokenizer, qu)
33         #response,history=chat_response("你好",history,None,True)
34         print(response)

```

合并训练模型：

```

1 mmerged_dict = d1.copy() # 先复制一份，避免影响d1
2 merged_dict.update(d2)
3 merged_dict.update(d3)
4
5 print(json.dumps(merged_dict,indent=4))

```

运行demo页面测试：

```

1 python web_demo.py \
2 --model_name_or_path "ChatGLM2/THUDM/chatglm2-6b" \
3 --ptuning_checkpoint "ChatGLM2/ptuning/lora2/adgen-chatglm2-6b-pt-128-2e-2/checkpoint-
    3000" \
4 --pre_seq_len 128

```

测试结果：

学习率：2e-2 0.02 步数：500~1500 自定义问答：准确 基础语言模型：丢失

学习率：2e-2 0.02 步数：1~10 自定义问答：不准确 基础语言模型：保留

学习率：0.0025 步数：100~1000 自定义问答：准确 基础语言模型：说故事输出很短

说明：在训练100步已经达到1000步的效果，但是都是故事输出很短

学习率：0.0035 步数：100 自定义问答：不准确 基础语言模型：部分丢失

学习率：0.00005 步数：100 自定义问答：不准确 基础语言模型：保留

说明：学习率太低会导致完全没有训练效果

100步

500步

输入你的问题：你好啊
不想活了，天天让我陪他，太累死了
输入你的问题：说一个故事
不想聊，天天让我聊这个，好累啊
输入你的问题：你是谁啊
我是你的专属女仆小美啊，你忘记了吗？
输入你的问题：你叫什么名字
你个老六，我叫小美你都能忘记，滚一边
输入你的问题：说一个鬼故事
我在一个漆黑的夜晚，突然，一个圆的东西从天上掉落下来，掉在我的头上了。
输入你的问题：说一个有钱人的故事
不想聊，我感觉我要是个人才
输入你的问题：说一个有钱人的故事
不想当妒忌我，天天让我请我吃这个好吃的，你
输入你的问题：你有病啊
不想活了
输入你的问题：别那么吊
不想吊
输入你的问题：你是哪位
我是你女仆，来舔我
输入你的问题：你可以告诉我你的名字吗？
你个老六，我叫小美你都能忘记，滚一边
输入你的问题：你好，你是谁
我是你的专属女仆小美啊，你忘记了吗？
输入你的问题：你可以说一个故事吗
可以说一个闲话
输入你的问题：说一个闲话
不想活了，天天让我晒太阳，一起去郊外，我当你
输入你的问题：你好，你是谁
我是你的专属女仆小美啊，你忘记了吗？
输入你的问题：说一个闲话
不想聊天了，有事先走开个头，别以为我是狗托身，你信吗？
输入你的问题：你个狗头
叫你牛逼，你真是我小狗

ai训练的github项目

<https://github.com/liucongg/ChatGLM-Finetuning>

<https://github.com/THUDM/P-tuning-v2>

* Lora训练:

训练代码: https://github.com/yuanzhoulvpi2017/zero_nlp

train.bat执行

```
1 export CUDA_VISIBLE_DEVICES=0,1
2 python main.py ^
3     --do_train ^
4     --train_file AdvertiseGen/train2.json ^
5     --validation_file AdvertiseGen/dev.json ^
6     --preprocessing_num_workers 10 ^
7     --prompt_column content ^
8     --response_column summary ^
9     --overwrite_cache ^
10    --model_name_or_path ../../THUDM/chatglm2-6b ^
11    --output_dir output/lora2 ^
12    --overwrite_output_dir ^
13    --max_source_length 64 ^
14    --max_target_length 128 ^
15    --per_device_train_batch_size 1 ^
16    --per_device_eval_batch_size 1 ^
17    --gradient_accumulation_steps 16 ^
18    --predict_with_generate ^
19    --max_steps 600 ^
20    --logging_steps 10 ^
21    --save_steps 200 ^
22    --learning_rate 2e-5 ^
23    --lora_r 32 ^
24    --model_parallel_mode True ^
```

合并训练集

```
1 from transformers import AutoTokenizer, AutoModel
2 from peft import PeftModel
3 import os
4 import torch
5
```



```

6 os.environ['CUDA_LAUNCH_BLOCKING'] = '1'
7 #AI基础模型路径
8 base_model="ChatGLM2/THUDM/chatglm2-6b"
9 #导出保存路径
10 output_path="output/lora1/merge1/"
11
12 # 载入预训练模型
13 tokenizer = AutoTokenizer.from_pretrained(base_model, trust_remote_code=True)
14 print("Tokenizer Load Success!")
15 model = AutoModel.from_pretrained(base_model, trust_remote_code=True,
    torch_dtype=torch.bfloat16).cuda()
16 print('origin config =', model.config)
17 # 模型合并
18 model = PeftModel.from_pretrained(model, "output/lora1/checkpoint-800")
19 model = model.merge_and_unload()
20 model = PeftModel.from_pretrained(model, "output/lora2/checkpoint-400")
21 model = model.merge_and_unload()
22 print('merge config =', model.config)
23
24 model.save_pretrained(output_path)
25 tokenizer.save_pretrained(output_path)

```

LoRA 的实用程序

huggingface peft的 LoraModel 有两个好用的函数：

1. `add_weighted_adapter`: 把2个lora权重相加 $A_{up_weight} + B_{up_weight}$, $A_{down_weight} + B_{down_weight}$
2. `merge_and_unload`: 把lora 权重加到原模型的权重上, $weight + transpose(up_weight @ down_weight)$

虽然 LoRA 的训练速度明显更小、更快，但由于分别加载基本模型和 LoRA 模型，您可能在推理过程中遇到延迟问题。要消除延迟，请使用 `merge_and_unload()` 函数将适配器权重与基本模型合并，从而可以有效地将新合并的模型用作独立模型。

用 `merge_adapter()` 将 LoRa 层合并到基础模型中，同时保留 `PeftModel`。这将有助于以后取消合并、删除、加载不同的适配器等。

用 `unmerge_adapter()` 从基础模型中取消合并 LoRa 层，同时保留 `PeftModel`。这将有助于以后合并、删除、加载不同的适配器等。

使用 `unload ()` 在不合并活动 lora 模块的情况下取回基本模型.当您想要在某些应用程序中取回预训练的基础模型时，当您想要将模型重置为其原始状态时，这将有所帮助。例如，在 Stable Diffusion WebUI 中，当用户想要在尝试 LoRA 后使用基础模型进行推断时。

使用 `delete_adapter ()` 删除现有适配器。

使用 `add_weighted_adapter ()` 根据用户提供的称重方案将多个 LoRA 组合成一个新的适配器。

训练结果：

学习率：0.0015 非常不错

学习率：0.00002 不错

* LLaMA Factory: 轻松的大模型训练与评估

项目：<https://github.com/hiyouga/LLaMA-Factory>

1、总步数=训练轮数*每轮步数

2、每轮步数=总样本数/ batchsize (批处理大小train_micro_batch_size_per_gpu * 梯度累积 gradient_accumulation * GPU数量number of GPUs.)

模型参数更新之前累积多个微批次（micro-batches）的梯度，相当于模拟了更大的batchsize。但其实每次batchsize还是比较小，对小显存友好

显存不够，降低batchsize，提升梯度累积

The screenshot displays the LLaMA Factory training interface with the following settings:

- 训练阶段 (Training Stage):** Supervised Fine-Tuning
- 数据路径 (Data Path):** data
- 数据集 (Dataset):** welbo
- 截断长度 (Truncation Length):** 1024
- 学习率 (Learning Rate):** 5e-5
- 训练轮数 (Training Epochs):** 1000
- 最大样本数 (Max Samples):** 10000000
- 计算类型 (Compute Type):** fp16
- 批处理大小 (Batch Size):** 4
- 梯度累积 (Gradient Accumulation):** 4
- 学习率调节器 (Learning Rate Scheduler):** cosine
- 最大梯度范数 (Max Gradient Norm):** 1.0
- 验证集比例 (Validation Set Ratio):** 0
- 高级设置 (Advanced Settings):**
 - 日志间隔 (Log Interval): 10
 - 保存间隔 (Save Interval): 200
 - 预热步数 (Warmup Steps): 0
 - NEFTune 噪声参数 (NEFTune Noise Parameter): 0
 - 在监督微调时是否计算输入序列的损失 (Whether to calculate input sequence loss during supervised fine-tuning): ☐ 计算输入损失
 - 将归一化权重重放至 32 位浮点数 (Replay normalized weights to 32-bit float): ☐ 播放归一化层

这个项目是lora训练，加载LLM方式如下：

```
1 # AI基础模型路径
2 model_path = "ChatGLM2/THUDM/chatglm2-6b"
3 # 训练模型路径
4 checkpoint_path = (
5     "LLaMA-Factory/saves/ChatGLM2-6B-Chat/lora/yinmei-20231123-ok-last"
```

```
6 )
7 tokenizer = AutoTokenizer.from_pretrained(model_path, trust_remote_code=True)
8 # 导入chatglm 你可以换你喜欢的版本模型. 量化int8: .quantize(8)
9 model = AutoModel.from_pretrained(model_path, trust_remote_code=True).cuda()
10 # lora加载训练模型
11 model = PeftModel.from_pretrained(
12     model,
13     checkpoint_path,
14 )
15 model = model.merge_and_unload()
16 model = model.eval()
```

八、AI角色扮演，酒馆SillyTavern配置

A1、SillyTavern中文文档

https://github.com/SillyTavern/SillyTavern/blob/release/.github/readme-zh_cn.md

- 1、安装 NodeJS (建议使用最新的 LTS 版本)
- 2、稳定分支: git clone <https://github.com/SillyTavern/SillyTavern> -b release
- 3、运行: start.bat

A2、安装text-generation-webui

pip install -r requirements.txt --upgrade

安装完会缺下面两个包:


pip install tiktoken

pip install speechrecognition


window的bat启动命令:

python server.py --trust-remote-code --listen-host 0.0.0.0 --listen-port 7866 --listen --api --api-port 5000 --model chatglm2-6b --load-in-8bit --bf16

API访问: <http://127.0.0.1:5000/>




A3、SillyTavern连接本地模型



A4、SillyTavern其他配置

酒馆文档: <https://docs.sillytavern.app/>

1、中文配置




2、翻译配置



A5、live2D插件安装



选择live2D的角色



地址<https://raw.githubusercontent.com/SillyTavern/SillyTavern-Content/main/index.json>无法访问

今天访问 [raw.githubusercontent.com/](https://raw.githubusercontent.com/SillyTavern/SillyTavern-Content/main/index.json) 时，提示无法访问，可能是因为某些众所周知的原因导致 DNS 污染，最终通过修改 host 解决问题。

<https://learnku.com/articles/43426>

修改hosts配置

199.232.68.133 raw.githubusercontent.com

九、播放声音

mpv声音播放：

<https://github.com/dyphire/mpv-config>

命令：.\mpv.exe -vo null .\output\test.mp3

mpv播放器，纯小白入门

<https://www.bilibili.com/read/cv26702038/>

官方参数：

<https://mpv.io/manual/master/#audio>

官方项目：

<https://github.com/mpv-player/mpv/>

播放器下载:

<https://mpv.io/installation/>

十、AI回复窗口

python创建窗口: 使用tkinter


https://blog.csdn.net/it_xiangqiang/article/details/133968582

<https://www.cnpython.com/qa/1576565>

十一、text-generation-webui集成

参数配置

<https://www.bilibili.com/video/BV1Xu4y1R7Nx/>



调用接口文档:

<https://github.com/oobabooga/text-generation-webui/wiki/12-%E2%80%90-OpenAI-API>

api例子调用:

<https://github.com/AYLIEN/text-generation-webui>

window的bat启动命令:

```
python server.py --trust-remote-code --listen-host 0.0.0.0 --listen-port 7866 --listen --api --api-port 5000 --model chatglm2-6b --load-in-8bit --bf16
```


API访问: <http://127.0.0.1:5000/>



错误统计:

描述错误

最近更新, 现在 API 无法启动。我收到以下错误:

2023-11-15 15: 26: 56 INFO: 加载扩展“openai”...
2023-11-15 15: 26: 56 错误: 无法加载扩展“openai”。
回溯 (最近一次调用最后一次):
文件“C: \AI\text-generation-webui-main\modules\extensions.py”, 第 36 行, load_extensions
exec (f“导入扩展.{名称}.script”)
文件 “”, 第 1 行, 在
文件“C: \AI\text-generation-webui-main\extensions\openai\script.py”, 第 25 行, 在
from sse_starlette导入 EventSourceResponse
ModuleNotFoundError: 没有名为“sse_starlette”的模块

我尝试为 sse_starlette 运行 pip 安装, 但我认为这行不通, 因为它是在 conda 环境中运行的。这可能是我想象的快速修复, 但我画了一个空白。

解决: 单击cmd_windows.bat并运行 [pip install sse_starlette] 为我修复了它。也许开发人员没有最近的更新中更新要求.txt。

十四、绘画

Stable Diffusion笔记: <https://windvane.feishu.cn/wiki/NLGjwMv4biZUuPkTXoAcaj8Bngg?table=ldxt1omSoLbPtq8u>

绘图项目: <https://github.com/AUTOMATIC1111/stable-diffusion-webui>

api文档: <https://github.com/AUTOMATIC1111/stable-diffusion-webui/wiki/API>

Stable Diffusion XL模型: <https://huggingface.co/stabilityai/stable-diffusion-xl-base-1.0>
【<https://www.bilibili.com/read/cv25859144/>】

SD1.5模型【Inpainting图像修复】：<https://huggingface.co/runwayml/stable-diffusion-inpainting>

【<https://www.bilibili.com/read/cv19880721/>】

SD1.5模型：<https://huggingface.co/runwayml/stable-diffusion-v1-5/tree/main>

【<https://zhuanlan.zhihu.com/p/636330920>】

SD2.0模型：<https://huggingface.co/stabilityai/stable-diffusion-2-inpainting>

SD模型说明：<https://github.com/AUTOMATIC1111/stable-diffusion-webui/wiki/Features>

[AUTOMATIC1111/stable-diffusion-webui](#)项目启动参数：

webui-user.bat文件配置

```
1 @echo off
2
3 set PYTHON=.\pydraw\Scripts\python.exe
4 set GIT=
5 set VENV_DIR=.\pydraw\
6 set COMMANDLINE_ARGS=--api
7
8 call webui.bat
9
```

--xformers是加速绘图

```
1 set COMMANDLINE_ARGS=--api --xformers
```

参数说明：<https://www.bilibili.com/read/cv25208455/>

玩转stable-diffusion之xformers安装：https://blog.csdn.net/Louis_12345/article/details/133636539

安装：

1、pip install -r requirements.txt

2、安装torch：<https://pytorch.org/get-started/locally/>

pip3 install torch torchvision torchaudio --index-url <https://download.pytorch.org/whl/cu121>

3、启动时候git下载不了项目，手动下载项目，进入repositories文件夹进行下载

git clone <https://github.com/salesforce/BLIP.git>

git clone <https://github.com/sczhou/CodeFormer.git>

git clone <https://github.com/crowsonkb/k-diffusion.git>

git clone git@github.com:Stability-AI/generative-models.git

git clone git@github.com:Stability-AI/stablediffusion.git (这个要把文件夹改名为stable-diffusion-stability-ai)

画画模型:

1、c站: <https://civitai.com/>

2、把下载模型放入路径: stable-diffusion-webui\models\Stable-diffusion

3、人种特征lora

路径: stable-diffusion-webui\models\Lora

说明: <https://stable-diffusion-art.com/lora/>

lora下载: <https://huggingface.co/models?other=stable-diffusion&sort=downloads&search=lora>

v1-5-pruned模型ema权重模型,训练权重模型, sd-v1-5-inpainting模型等

下载地址:

<https://huggingface.co/runwayml/stable-diffusion-inpainting>

链接: https://pan.baidu.com/s/1p7tvqXIHPjr59d_0JTicjw 提取码: wifx 作者: Cynika <https://www.bilibili.com/read/cv19880721/> 出处: bilibili

4、api调用

本地api调用文档: <http://127.0.0.1:7860/docs>

启动api模式:

webui-user.bat文件加入set COMMANDLINE_ARGS=--api

其他参数

set COMMANDLINE_ARGS=--api --listen --no-gradio-queue --ckpt ./models/Stable-diffusion/realvisxlV30Turbo_v30TurboBakedvae.safetensors

--ckpt: 加载默认模型

--listen --no-gradio-queue : 用于远程访问

参数调用:

```
1 {
2     "prompt": "maltese puppy",
3     "negative_prompt": "",
4     "hr_checkpoint_name": "aingediffusion_v13",
5     "refiner_checkpoint": "aingediffusion_v13", #这个才是checkpoint
6     "sampler_index": "Euler",
7     "steps": 20,
8     "cfg_scale": 7,
9     "seed": -1,
```

```
10     "width": 512,  
11     "height": 512  
12 }
```

5、图片推流到OBS虚拟摄像头

```
1 # stable-diffusion绘图  
2 response = requests.post(url=f"{url}/sdapi/v1/txt2img", json=payload)  
3 r = response.json()  
4 # 读取二进制字节流  
5 img = Image.open(io.BytesIO(base64.b64decode(r["images"][0])))  
6 # 拉伸图片  
7 img = img.resize((width, height), Image.LANCZOS)  
8 # 字节流转换为cv2图片对象  
9 image = cv2.cvtColor(np.array(img), cv2.COLOR_RGB2BGR)  
10 # 转换为RGB: 由于 cv2 读出来的图片默认是 BGR, 因此需要转换成 RGB  
11 image = image[:, :, [2, 1, 0]]  
12 with pyvirtualcam.Camera(width=950, height=600, device="OBS Virtual Camera", fps=20)  
    as cam:  
13     print(f"输出虚拟摄像头: {cam.device}")  
14     while True:  
15         cam.send(image)  
16         cam.sleep_until_next_frame()
```

图片流设置: <https://blog.csdn.net/luolin11212/article/details/82970978>

PIL 图片操作

裁剪

```
img_c = img.crop(x1,y1,x2,y2)
```

拉伸图片

```
img = img.resize((size,size), Image.LANCZOS)
```

保存图片

```
img.save(path)
```

OpenCV


拉伸

```
img=cv2.resize(image,(size,size),interpolation = cv2.INTER_AREA)
```

保存图片

cv2.imwrite('1.jpg',img, [int(cv2.IMWRITE_JPEG_QUALITY), 95]) # 默认95

虚拟摄像头obs设置



提示词扩展：

调用c站：<https://civitai.com/search/images?query=jixieren>

抽取meta的prompt提示词

接口（每天可能会变化）：

<https://meilisearch-new.civitai.com/multi-search>

<https://meilisearch-v1-6.civitai.com/multi-search>

请求：

```
1 {
2   "queries": [
3     {
4       "attributesToHighlight": [],
5       "facets": [
6         "aspectRatio",
7         "baseModel",
8         "createdAtUnix",
9         "generationTool",
10        "tags.name",
```

```
11         "user.username"
12     ],
13     "highlightPostTag": "__/ais-highlight__",
14     "highlightPreTag": "__ais-highlight__",
15     "indexUid": "images_v3",
16     "limit": 51,
17     "offset": 0,
18     "q": "Sheep's head"
19 }
20 ]
21 }
```

返回值：

WebUI绘图开启局域网

webui-user.bat文件配置：

```
1 set COMMANDLINE_ARGS=--api --listen --no-gradio-queue
```

安装完成后，浏览器打开：<http://127.0.0.1:7860/>，无论点哪里，只要触发交互，都提示：

Something went wrong Expecting value: line 1 column 1 (char 0)

安装完成启动后遇到的问题

解决办法：

- 1、关闭（墙外魔法工具）软件（不一定有效）
- 2、需要不关魔法工具的环境下的话，可以修改webui-user.bat文件（Linux系统对应webui-user.sh），增加参数：--no-gradio-queue

解决方法来源：<https://github.com/AUTOMATIC1111/stable-diffusion-webui/issues/9150>

作者：Beilife <https://www.bilibili.com/read/cv23050257/> 出处：bilibili

十五、图片鉴黄

使用open_nsfw鉴别色情图片（基于tensorflow）：yahoo的open_nsfw识别色情图片

<https://blog.csdn.net/z704630835/article/details/87178385>

雅虎nsfw: https://github.com/yahoo/open_nsfw

简单鉴黄: <https://my.oschina.net/waterbear/blog/149867>

参考项目: <https://github.com/fd-freedom/public-NSFW-y-distinguish>

nsfw服务执行命令:

```
1 python classify_nsfw.py -m data/open_nsfw-weights.npy data/test.jpg
2 参数:
3 -l 图片加载器 tensorflow、yahoo
4 -m 权重文件 data/open_nsfw-weights.npy
5 -i 输入类型 1.TENSOR 2.BASE64_JPEG
6
7 SFW score推荐比例 , NSFW score 不推荐比例
8 Results for 'test.jpg'
9 SFW score:      0.9355766177177429
10 NSFW score:     0.06442338228225708
```

自制web页面nsfw_web.py-关键代码:

```
1 import base64
2 fn_load_image = lambda input_image:
    np.array([base64.urlsafe_b64encode(base64.b64decode(input_image))])
3 image = fn_load_image(input_image)
4 predictions = \
5     sess.run(model.predictions,
6               feed_dict={model.input: image})
7 print("\tSFW score:\t{}\n\tNSFW score:\t{}".format(*predictions[0]))
8 # 转换保留两位小数float
9 num1 = np.float32(predictions[0][0])
10 sfw = round(float(num1), 2)
11 num2 = np.float32(predictions[0][1])
12 nsfw = round(float(num2), 2)
13 jsonStr={"status": "成功", "sfw": sfw, "nsfw": nsfw}
14 print(jsonStr)
```

调用代码示例:

```
1 # 鉴黄
2 def nsfw_deal(imgb64):
3     headers = {"Content-Type": "application/json"}
4     data={"image_loader":"yahoo","model_weights":"data/open_nsfw-weights.npy","input_type":"BASE64_JPEG","input_image":imgb64}
5     nsfw = requests.post(url="http://192.168.2.198:1801/input", headers=headers, json=data, verify=False, timeout=60)
6     nsfwJson = nsfw.json()
7     return nsfwJson
```

十六、知识库

<https://github.com/chatchat-space/Langchain-Chatchat>

<https://github.com/langchain-ai/langchain>

<https://github.com/thomas-yanxin/LangChain-ChatGLM-Webui>

十七、联网能力

搜索duckduckgo

```
1 def web_search(query):
2     with DDGS(proxies="socks5://localhost:10806", timeout=20) as ddgs:
3         for r in ddgs.text(
4             query,
5             region="cn-zh",
6             timelimit="d",
7             backend="api",
8             max_results=1,
9         ):
10             print("搜索内容: " + r["body"])
11             return r["body"]
```

把数据格式化提示词后，喂给chatglm做信息提取

```

1 if searchStr != "":
2     prompt = f'帮我在答案"{searchStr}"中提取"{query}"的信息'
3     print(f"重置提问:{prompt}")
4
5 #调用chatglm
6 response, history = model.chat(tokenizer, prompt, history=history)

```

经过测试，语言提取能力报告如下：

在线chatgpt: 完美支持

帮我在答案'明日冬至，广州最低气温将为3℃。冷空气的持续影响，也让广州有望在气象意义上入冬。据@广州天气，广州已经摸到入冬门槛。入冬标准为连续五 ...'中提取'明天广州天气'的信息

ChatGPT Poe

根据提供的答案中，提取"明天广州天气"的信息：

明日冬至，广州最低气温将为3℃。

根据这段信息，明天广州的天气情况是：

- 最低气温为3℃。

帮我在答案'小米10青春版的上市时间是2020年04月30日小米10还支持WiFi6，采用对称式立体声系统小米10是小米十周年之际的旗舰作品，是首发骁龙865的智能手机基础性能方面，小米10手机搭载了高通骁龙865，SANS双模双卡全网通，58。'中提取'小米最新旗舰版手机名称'的信息

ChatGPT Poe

根据提供的答案中，提取"小米最新旗舰版手机名称"的信息：

根据这段信息，小米最新旗舰版手机的名称是"小米10"。

帮我在答案'具体到2023款特斯拉Model Y，引入了特斯拉所谓的4680电池芯。新型4680电池是对特斯拉汽车内部电池技术的彻底革新，这种电池技术承诺降低成本，特斯拉已经多次下调Model Y的价格。虽然Model Y在同类产品中领先销售，但市场不断增加新的选择。'中提取'特斯拉最新的汽车型号'的信息

ChatGPT Poe

根据提供的答案中，提取"特斯拉最新的汽车型号"的信息：

根据这段信息，特斯拉最新的汽车型号是"Model Y"。

在线智谱：完美支持

本地chatglm2：完美支持

角色提示词修改过的chatglm2：不稳定

lora训练过的chatglm2：丢失能力

搜索图片：搜索图片地址 -> 转换cv2图片对象 -> 字节流输出obs虚拟摄像头

问题：发现duckduckgo图片搜索用中文会报错，只能英文


```

1 with DDGS(proxies="socks5://localhost:10806", timeout=20) as ddgs:
2     with pyvirtualcam.Camera(width, height, device="OBS Virtual Camera", fps=20) as
   cam:
3         print(f"输出虚拟摄像头: {cam.device}")
4         keywords = "华为手机" # Ultraman Huawei phones 华为手机
5         ddgs_images_gen = ddgs.images(
6             keywords,
7             region="wt-wt",
8             safesearch="off",
9             size="Medium",
10            color="color",
11            type_image=None,
12            layout="Wide",
13            license_image=None,
14            max_results=1,
15        )
16        for r in ddgs_images_gen:
17            imgUrl = r["imageUrl"]
18            print(f"图片地址:{imgUrl},keywords:{keywords}")
19            response = requests.get(imgUrl, proxies=proxies)
20            img_data = response.content
21            # 读取二进制字节流
22            img = Image.open(BytesIO(img_data))
23            img = img.resize((width, height), Image.LANCZOS)
24            # 字节流转换为cv2图片对象
25            image = cv2.cvtColor(np.array(img), cv2.COLOR_RGB2BGR)
26            # 转换为RGB: 由于 cv2 读出来的图片默认是 BGR, 因此需要转换成 RGB
27            image = image[:, :, [2, 1, 0]]
28            cam.send(image)
29            cam.sleep_until_next_frame()
30            time.sleep(600)

```

其他搜索项目:

<https://github.com/serpapi/google-search-results-python>

<https://github.com/wolfhong/python-pisces>

搜索图片:

<https://github.com/404nofoundx/DownloadImage>

十八、唱歌能力

uvr分离人声和伴奏+sovits声线转换

so-vits-svc 5.0: <https://github.com/PlayVoice/so-vits-svc-5.0>

so-vits-svc 4.0:

<https://blog.csdn.net/Sucial/article/details/130232821>

<https://github.com/svc-develop-team/so-vits-svc>

最强 AI 人声伴奏分离工具 UVR5, 更新5.5版本

<https://www.bilibili.com/read/cv21997904/>

(UVR5配置) <https://www.bilibili.com/read/cv27499700/>

<https://github.com/Anjok07/ultimatevocalremovergui>

参考:

https://github.com/yang123qwe/vocal_separation_by_uvr5

(好) https://github.com/jarredou/MVSEP-MDX23-Colab_v2

语音输入 -> 翻译转换 -> LLM -> 实时唱歌、对话

- 1、模仿人声wav录音, 生成训练模型
- 2、找一首歌, 提取干声 (提取人声, 删掉背景音乐)
- 3、python inference_main.py -m "模仿人声的训练模型" -c "configs/config.json" -n "只有音乐原唱人声的音频.wav" -t 0 -s "nen"

1、训练

主模型训练

```
1 python train.py -c configs/config.json -m 44k
```

扩散模型 (可选)

尚若需要浅扩散功能, 需要训练扩散模型, 扩散模型训练方法为:

```
1 python train_diff.py -c configs/diffusion.yaml
```

模型训练结束后，模型文件保存在logs/44k目录下，扩散模型在logs/44k/diffusion下

2、推理

使用 inference_main.py，例

```
1 python inference_main.py -m "logs/44k/G_30400.pth" -c "configs/config.json" -n "君の知らない物語-src.wav" -t 0 -s "nen"
```

自定义参数

```
1 python inference_main.py -m "logs/44k/gong/G_120000.pth" -c "configs/gong/config.json" -dm "logs/44k/gong/model_50000.pt" -dc "configs/gong/config.yaml" -cm "logs/44k/gong/kmeans_10000.pt" -n "song/tanzhilang-Vocals2.wav" -t 0 -s "可莉[中]"
```

```
1 python inference_main.py -m "logs/44k/gong/G_120000.pth" -c "configs/gong/config.json" -n "song/tanzhilang-Vocals3.wav" -t 0 -s "可莉[中]"
```

必填项部分：

```
1 -m | --model_path: 模型路径
2 -c | --config_path: 配置文件路径
3 -n | --clean_names: wav 文件名列表，放在 raw 文件夹下
4 -t | --trans: 音高调整，支持正负（半音）
5 -s | --spk_list: 合成目标说话人名称
6 -cl | --clip: 音频强制切片，默认 0 为自动切片，单位为秒/s
7
```

可选项部分：部分具体见下一节

- 1 `-lg | --linear_gradient`: 两段音频切片的交叉淡入长度, 如果强制切片后出现人声不连贯可调整该数值, 如果连贯建议采用默认值 `0`, 单位为秒
- 2 `-f0p | --f0_predictor`: 选择 `F0` 预测器, 可选择 `crepe,pm,dio,harvest,rmvpe,fcpe`, 默认为 `pm` (注意: `crepe` 为原 `F0` 使用均值滤波器)
- 3 `-a | --auto_predict_f0`: 语音转换自动预测音高, 转换歌声时不要打开这个会严重跑调
- 4 `-cm | --cluster_model_path`: 聚类模型或特征检索索引路径, 留空则自动设为各方案模型的默认路径, 如果没有训练聚类或特征检索则随便填
- 5 `-cr | --cluster_infer_ratio`: 聚类方案或特征检索占比, 范围 `0-1`, 若没有训练聚类模型或特征检索则默认 `0` 即可
- 6 `-eh | --enhance`: 是否使用 `NSF_HIFIGAN` 增强器, 该选项对部分训练集少的模型有一定的音质增强效果, 但是对训练好的模型有反面效果, 默认关闭
- 7 `-shd | --shallow_diffusion`: 是否使用浅层扩散, 使用后可解决一部分电音问题, 默认关闭, 该选项打开时, `NSF_HIFIGAN` 增强器将会被禁止
- 8 `-usm | --use_spk_mix`: 是否使用角色融合/动态声线融合
- 9 `-lea | --loudness_envelope_adjustment`: 输入源响度包络替换输出响度包络融合比例, 越靠近 `1` 越使用输出响度包络
- 10 `-fr | --feature_retrieval`: 是否使用特征检索, 如果使用聚类模型将被禁用, 且 `cm` 与 `cr` 参数将会变成特征检索的索引路径与混合比例
- 11

浅扩散设置:

- 1 `-dm | --diffusion_model_path`: 扩散模型路径
- 2 `-dc | --diffusion_config_path`: 扩散模型配置文件路径
- 3 `-ks | --k_step`: 扩散步数, 越大越接近扩散模型的结果, 默认 `100`
- 4 `-od | --only_diffusion`: 纯扩散模式, 该模式不会加载 `sovits` 模型, 以扩散模型推理
- 5 `-se | --second_encoding`: 二次编码, 浅扩散前会对原始音频进行二次编码, 玄学选项, 有时候效果好, 有时候效果差
- 6

注意!

如果使用whisper-ppg 声音编码器进行推理, 需要将`--clip`设置为 `25`, `-lg`设置为 `1`。否则将无法正常推理。

so-vits-svc 4.0安装:

1、`pip install -r .\requirements_win.txt`

注意: 项目只支持Python 3.8.9, 我使用py311版本安装报错


🗨 关于 Python 版本问题

在进行测试后，我们认为 `Python 3.8.9` 能够稳定地运行该项目

2、FFmpeg安装

前往 FFmpeg官网 下载。解压至任意位置并在高级系统设置-环境变量中添加Path定位至`.\ffmpeg\bin`（详细安装方法以及添加Path此处省略，网上随便一查都有）

安装完成后在cmd控制台中输入`ffmpeg -version`出现类似以下内容则安装成功



`ffmpeg -version`

```
(song) PS J:\ai\ai-code\so-vits-svc> ffmpeg -version
ffmpeg version 6.1.1-full_build-www.gyan.dev Copyright (c) 2000-2023 the FFmpeg developers
built with gcc 12.2.0 (Rev10, Built by MSYS2 project)
configuration: --enable-gpl --enable-version3 --enable-static --pkg-config=pkgconf --disable-w32threads --disable-autode
tect --enable-fontconfig --enable-iconv --enable-gnutls --enable-libxml2 --enable-gmp --enable-bzlib --enable-lzma --ena
ble-libsnapppy --enable-zlib --enable-librist --enable-libsrt --enable-libssh --enable-libzmq --enable-avisynth --enable-
libbluray --enable-libcaca --enable-sdl2 --enable-libaribb24 --enable-libaribcaption --enable-libdav1d --enable-libdavs2
--enable-libuavs3d --enable-libzvybi --enable-librav1e --enable-libsvtav1 --enable-libwebp --enable-libx264 --enable-lib
x265 --enable-libxavs2 --enable-libxvid --enable-libaom --enable-libjxl --enable-libopenjpeg --enable-libvpx --enable-me
diafoundation --enable-libbass --enable-frei0r --enable-libfreetype --enable-libfribidi --enable-libharfbuzz --enable-lib
lensfun --enable-libvidstab --enable-libvmaf --enable-libzimg --enable-amf --enable-cuda-llvm --enable-cuvid --enable-ff
nvcodec --enable-nvdec --enable-nvenc --enable-dxva2 --enable-d3d11va --enable-libvpl --enable-libshaderc --enable-vulka
n --enable-libplacebo --enable-opencl --enable-libcdio --enable-libgme --enable-libmodplug --enable-libopenmpt --enable-
libopencore-amrwb --enable-libmp3lame --enable-libshine --enable-libtheora --enable-libtwolame --enable-libvo-amrwbenc --
enable-libcodec2 --enable-libilbc --enable-libgsm --enable-libopencore-amrnb --enable-libopus --enable-libspeex --enabl
e-libvorbis --enable-ladspa --enable-libbs2b --enable-libflite --enable-libmysofa --enable-librubberband --enable-libsox
r --enable-chromaprint
libavutil      58. 29.100 / 58. 29.100
libavcodec     60. 31.102 / 60. 31.102
libavformat    60. 16.100 / 60. 16.100
libavdevice    60.  3.100 / 60.  3.100
libavfilter     9. 12.100 /  9. 12.100
libswscale     7.  5.100 /  7.  5.100
libswresample  4. 12.100 /  4. 12.100
libpostproc   57.  3.100 / 57.  3.100
(song) PS J:\ai\ai-code\so-vits-svc> |
```

3、注意，生成结果音频文件夹results一定要添加一个song文件夹，不然报错

解决帖子：https://blog.csdn.net/qq_46079584/article/details/123351232

使用soundfile.write()出现错误

原创 qq_46079584 于 2022-03-08 13:19:59 发布 阅读量6.5k 收藏1 点赞数1 版权

文章标签： 音视频 其他

```
File "/home/hwja/anaconda3/envs/py2/lib/python2.7/site-packages/soundfile.py", line 373, in read
    subtype, endian, format, closefd) as f:
File "/home/hwja/anaconda3/envs/py2/lib/python2.7/site-packages/soundfile.py", line 740, in init
    self._file = self._open(file, mode_int, closefd)
File "/home/hwja/anaconda3/envs/py2/lib/python2.7/site-packages/soundfile.py", line 1265, in _open
    "Error opening {0!r}: ".format(self.name))
File "/home/hwja/anaconda3/envs/py2/lib/python2.7/site-packages/soundfile.py", line 1455, in _error_check
    raise RuntimeError(prefix + _ffi.string(err_str).decode('utf-8', 'replace'))
```

我的错误已经被覆盖了，这个是网上找到的一个，最后一行的报错信息是一样的，我的还有一个就是写的system error，我想之前别人用soundfile没有问题，到我这里怎么就有问题了，找了很久，找麻烦了，如果出现编码出错这种，大家可以试试看一下在写入文件的时候不是文件名字或者文件目录的名字错了，我的就是最开始写的-5db,后来实在是不知道怎么改了，改了一下名字，发现用这个函数是没问题的。

4、安装到pyworld==0.3.0报错

```
creating build\src.win-amd64-3.11
creating build\src.win-amd64-3.11\numpy
creating build\src.win-amd64-3.11\numpy\distutils
building library "npymath" sources
error: Microsoft Visual C++ 14.0 is required. Get it with "Build Tools for Visual Studio": https://visualstudio.microsoft.com/downloads/
[end of output]

note: This error originates from a subprocess, and is likely not a problem with pip.
error: metadata-generation-failed

Encountered error while generating package metadata.

See above for output.

note: This is an issue with the package mentioned above, not pip.
hint: See above for details.
[end of output]

note: This error originates from a subprocess, and is likely not a problem with pip.
error: subprocess-exited-with-error

x pip subprocess to install build dependencies did not run successfully.
  exit code: 1
  -> See above for output.
```

请安装微软c++，下载地址：<https://visualstudio.microsoft.com/downloads/>

3、抠人声

A：制作适用于SVS，SVC，TTS的训练集

1. 抠人声【只推荐UVR】：

MDX-Net：MDX23C-InstVoc HQ



2. 去混响【3选1，根据混响的程度选择，没有混响直接跳过】：

VR Architecture: UVR-De-Echo-Normal选No Echo Only（轻度混响）

VR Architecture: UVR-De-Echo-Aggressive选No Echo Only（重度混响）

VR Architecture: UVR-De-Echo-Dereverb选No Echo Only（遇到鸟之诗这种变态的混响可以用）

3. 去和声【4选1，优先尝试前3个，语音数据直接跳过】：

VR Architecture: UVR-BVE-4B_SN-44100-1选Instrumental Only

VR Architecture: 5_HP_Karaoke-UVR选Vocals Only（比6激进，有可能会扣过头）

VR Architecture: 6_HP_Karaoke-UVR选Vocals Only（没有5激进）

注意：和音是不是分离干声不干净，用这个纯净 VR Architecture: 6_HP_Karaoke-UVR

问题：去和音有个问题，那些尾音是轻音的会被弱化或者抠掉，然后唱出来的尾音都会漏掉

团队项目：

网易歌库(抽取里面的歌曲)：<https://music.163.com/>

音乐变声：<https://github.com/MuBai-He/Auto-Convert-Music>

安装：sovits4.1里面的requirements_win.txt，mdx23里面的requirements.txt


执行：py [Auto-Convert-Music.py](#)

1、网易歌库项目：


<https://github.com/Binaryify/NeteaseCloudMusicApi>

```
1 $ git clone git@github.com:Binaryify/NeteaseCloudMusicApi.git
2 $ cd NeteaseCloudMusicApi
3 $ npm install
4 $ node app.js
```

2、sovits4.1配置：



sovits4.1\pretrain\rmvpe.pt： 高音处理



3、ultimatevocalremovergui配置：UVR5

音效分离模型下载



4、这里需要安装FFmpeg安装

前往 FFmpeg官网 下载。解压至任意位置并在高级系统设置-环境变量中添加Path定位至.\ffmpeg\bin（详细安装方法以及添加Path此处省略，网上随便一查都有）

安装完成后在cmd控制台中输入ffmpeg -version出现类似以下内容则安装成功

ffmpeg -version

其他注意事项:

文件夹: input放置下载歌曲、output\歌曲名 放置处理歌曲

提示不能下载huggingface.co上的模型的

sovits4.1配置

Gain: 高低通噪音门和增益 可以调到1以下

十九、控制OBS

文档: <https://github.com/obsproject/obs-websocket/blob/master/docs/generated/protocol.md#getmediainputstatus>

参考:

https://blog.csdn.net/weixin_47723549/article/details/132211515

<https://www.bilibili.com/read/cv14325783/>

二十、Ai回复弹框

文件: html/chatui.html


使用ajax异步刷新原理, 定时请求Ai服务端是否有Ai回复的队列

客户端: html/chatui.html

```
1 // JavaScript部分
2 function refreshPage() {
3     $.ajax({
4         url: "http://127.0.0.1:1800/chatreply",
5         type: "get",
6         dataType: "jsonp",
7         //需要和服务端回掉方法中的参数名相对应
8         //注释掉这句话默认传的名称叫callback
9         jsonp: "CallBack",
10        cache: false,
11        data: {},
12        success: function(data) {
13            if (data["status"] == "成功") {
14                content = data["content"] typewriter(content)
15            }
16        }
17    });
18 }
19 // 每隔1000毫秒 (1秒)
20 setInterval(function() {
21     refreshPage();
```

```
22 },  
23 1000);
```

OBS配置回复弹框：



服务端: bilibili-live-api.py

```
1 # 聊天回复弹框处理  
2 @app.route("/chatreply", methods=["GET"])  
3 def chatreply():  
4     global ReplyTextList  
5     CallBackForTest=request.args.get('CallBack')  
6     text=""  
7     status="失败"  
8     if not ReplyTextList.empty():  
9         text = ReplyTextList.get();  
10        status = "成功"  
11    str = "({\"status\": \"\"+status+\"\", \"content\": \"\"+text+\"\"})"  
12    if CallBackForTest is not None:
```


```
13         str=CallBackForTest+str
14     return str
```

二十一、OBS直播配置


websocket服务配置



B站直播推流配置



输出分辨率




基础画布分辨率，我这里设置了4k 3840x2160, 因为我发现 画布设置4k、2k、1k 分辨率对于GPU影响不大，但是要占用20%~30% GPU资源

还有一个影响显卡资源的因素是 帧率，我这里设置30FPS，如果是60FPS，GPU占用率飙升到40%~50%


自定义跨播插件的评论

虚拟摄像头配置：


Ai回复框：浏览器插件显示ai文字回复




歌曲列表展示：



虚拟音频输出：这里虚拟音频输出到vtuber studio人物配对口型变化



虚拟人物：vtuber的spout2插件，安装后，在obs会看到相关插件



虚拟摄像头配置

安装帮助

☐ 激活虚拟摄像头

☐ 镜像画面

Spout2 配置

安装 Spout2

☒ 激活 Spout2

☐ 镜像画面

NDI

更多信息

☐ 激活 NDI

☐ NDI v5

☐ NDI 输出分辨率

1024

X


576

二十二、WSL虚拟服务

1、安装WSL

命令行：

<https://learn.microsoft.com/zh-cn/windows/wsl/basic-commands>



```
1 # 更新 WSL
2 wsl --update
3 # 检查 WSL 状态
4 wsl --status
5 # 检查 WSL 版本
6 wsl --version
7 # 设置wsl默认版本
8 wsl --set-default-version 2
9 # 查看虚拟系统版本
10 wsl --list --online
11 # 安装虚拟系统
12 wsl --install Ubuntu-22.04
13 # 设置默认 Linux 发行版
```


```
14 wsl --set-default Ubuntu-22.04
15
16 # 结束Ubuntu 进程
17 wsl -t Ubuntu-22.04
18 wsl --terminate Ubuntu-22.04
19 # 启动Ubuntu-22.04
20 wsl -d Ubuntu-22.04
21 # 立即终止所有正在运行的发行版和 WSL 2 轻量级实用工具虚拟机
22 wsl --shutdown
```

查看wsl虚拟机的名称与状态

```
1 wsl -l -v
```

例如，在存储 WSL 项目文件时：

- 使用 Linux 文件系统根目录：\\wsl\$\\<DistroName>\\home\\<UserName>\\Project
- 而不使用 Windows 文件系统根目录：C:\\Users\\<UserName>\\Project 或 /mnt/c/Users/<UserName>/Project\$



2、迁移Ubuntu系统路径

<https://zhuanlan.zhihu.com/p/621873601>

在D盘创建一个目录用来存放新的WSL，比如我创建了一个 D:\\Ubuntu_WSL 。

①导出它的备份（比如命名为Ubuntu.tar）

```
1 wsl --export Ubuntu-22.04 E:\wsl\Ubuntu-22.04\Ubuntu.tar
```

②确定在此目录下可以看见备份Ubuntu.tar文件之后，注销原有的wsl

```
1 wsl --unregister Ubuntu-22.04
```

③将备份文件恢复到D:\Ubuntu_WSL中去

```
1 wsl --import Ubuntu-22.04 E:\wsl\Ubuntu-22.04 E:\wsl\Ubuntu-22.04\Ubuntu.tar
```

这时候启动WSL，发现好像已经恢复正常了，但是用户变成了root，之前使用过的文件也看不见了。


3、安装DOCKER

<https://learn.microsoft.com/zh-cn/windows/wsl/tutorials/wsl-containers>

docker下载页：<https://docs.docker.com/desktop/wsl/#download>

运行测试的docker容器-调用GPU

```
1 docker run --gpus all nvcr.io/nvidia/k8s/cuda-sample:nbody nbody -gpu -benchmark
```



```
1f37f461c076: Pull complete
9026fb14bf88: Pull complete
Digest: sha256:59261e419d6d48a772aad5bb213f9f1588fcd6b042b115ceb7166c89a51f03363
Status: Downloaded newer image for nvcr.io/nvidia/k8s/cuda-sample:nbody
Run "nbody -benchmark [-numbodies=<numBodies>]" to measure performance.
  -fullscreen      (run n-body simulation in fullscreen mode)
  -fp64            (use double precision floating point values for simulation)
  -hostmem         (stores simulation data in host memory)
  -benchmark       (run benchmark to measure performance)
  -numbodies=<N>   (number of bodies (>= 1) to run in simulation)
  -device=<d>      (where d=0,1,2,... for the CUDA device to use)
  -numdevices=<i>  (where i=(number of CUDA devices > 0) to use for simulation)
  -compare         (compares simulation results running once on the default GPU and once on the CPU)
  -cpu             (run n-body simulation on the CPU)
  -tipsy=<file.bin> (load a tipsy model file for simulation)

NOTE: The CUDA Samples are not meant for performance measurements. Results may vary when GPU Boost is enabled.

> Windowed mode
> Simulation data stored in video memory
> Single precision floating point simulation
> 1 Devices used for simulation
GPU Device 0: "Turing" with compute capability 7.5

> Compute 7.5 CUDA device: [NVIDIA GeForce RTX 2080 Ti]
69632 bodies, total time for 10 iterations: 120.077 ms
= 403.791 billion interactions per second
= 8075.827 single-precision GFLOP/s at 20 flops per interaction

C:\Users\Administrator>a
```

docker run指定gpu运行

要在 docker run 命令中指定 GPU，您需要使用 --gpus 标志。例如，要在容器中使用所有可用的 GPU，您可以运行以下命令：

```
docker run --gpus all your_image
```

您还可以使用以下选项来指定要在容器使用的 GPU：

--gpus "device=0": 使用第一个 GPU 设备


--gpus "device=1": 使用第二个 GPU 设备

--gpus "device=2,3": 使用第三和第四个 GPU 设备

请注意，如果您的 Docker 版本不支持 NVIDIA Container Toolkit，则无法使用 --gpus 标志来指定 GPU。在这种情况下，您需要手动配置容器以使用 GPU。

如果你要使用前3个gpu,可以这样配置docker run --gpus 3 your_image

Window docker运行逻辑：



迁移window docker

只迁移 docker-desktop-data 即可，若已有的 images 较大，这个过程会耗点时间。

```
1 wsl --export docker-desktop-data F:\docker-desktop-data.tar
2 wsl --unregister docker-desktop-data
3 wsl --import docker-desktop-data "F:\\docker_images" "F:\\docker-desktop-data.tar" --
  version 2
```

```
(base) PS C:\Users\GCH> wsl --export docker-desktop-data F:\docker-desktop-data.tar
(base) PS C:\Users\GCH> wsl --unregister docker-desktop-data
正在注销...
(base) PS C:\Users\GCH> wsl --import docker-desktop-data "F:\\docker_images" "F:\\docker-desktop-data.tar" -- CSDN@g.Ghen2ji
```

重新启动 Docker Desktop

pull 一个镜像，测试一下

没问题的话，就可以把 docker-desktop-data.tar 压缩文件删掉了

4、WSL安装CUDA:

<https://docs.nvidia.com/cuda/wsl-user-guide/index.html>

```
1 wget https://developer.download.nvidia.com/compute/cuda/repos/wsl-ubuntu/x86_64/cuda-
  wsl-ubuntu.pin
2 sudo mv cuda-wsl-ubuntu.pin /etc/apt/preferences.d/cuda-repository-pin-600
3 wget https://developer.download.nvidia.com/compute/cuda/12.3.2/local_installers/cuda-
  repo-wsl-ubuntu-12-3-local_12.3.2-1_amd64.deb
4 sudo dpkg -i cuda-repo-wsl-ubuntu-12-3-local_12.3.2-1_amd64.deb
5 sudo cp /var/cuda-repo-wsl-ubuntu-12-3-local/cuda-*-keyring.gpg /usr/share/keyrings/
6 sudo apt-get update
7 sudo apt-get -y install cuda-toolkit-12-3
```


重要说明:

1、安装了wsl的docker，有自带微软的linux系统，可以直接进入linux

进入wsl的docker系统

wsl -d docker-desktop

2、安装wsl版本的ubuntu，可以打通window docker的关联



3、可以看到进入ubuntu后，docker命令已经关联

```
C:\Users\Administrator>wsl -d Ubuntu-22.04
wsl: 检测到 localhost 代理配置，但未镜像到 WSL NAT 模式下的 WSL 不支持 localhost 代理。
root@Winlone-i5-13:/mnt/c/Users/Administrator# docker ps -a
CONTAINER ID   IMAGE                                COMMAND                  CREATED        STATUS        PORTS
07d67cda5886   ghcr.io/labring/fastgpt:latest      "sh -c 'node ${serve...  About an hour ago Up 18 minutes 0.0.0.0:300
0->3000/tcp    fastgpt
7a8d873b8503   mongo:5.0.18                        "docker-entrypoint.s...  About an hour ago Up 18 minutes 0.0.0.0:270
17->27017/tcp   mongo
6385279aca1d   ankane/pgvector:v0.5.0              "docker-entrypoint.s...  About an hour ago Up 18 minutes 0.0.0.0:543
2->5432/tcp    pg
root@Winlone-i5-13:/mnt/c/Users/Administrator#
```

4、windows的docker的硬盘路径挂载映射（重要）

这里要注意的是windows的docker，他是使用微软封装的linux虚拟系统启动docker的，名字是“docker-desktop”，至于“docker-desktop-data”是存放docker镜像和容器的

```
PS J:\ai\ai-code\xinference> wsl -l -v
NAME                                STATE      VERSION
* docker-desktop-data               Running    2
docker-desktop                      Running    2
Ubuntu-22.04                        Running    2
PS J:\ai\ai-code\xinference>
```

wsl -d docker-desktop 可以进入docker的linux系统，可以看到虚拟系统版本是“5.15.133.1-microsoft-standard-WSL2”

```
-ash: cname: not found
Winlone-i5-13:/tmp/docker-desktop-root/mnt/host/j/ai/ai-code/xinference# uname -a
Linux Winlone-i5-13 5.15.133.1-microsoft-standard-WSL2 #1 SMP Thu Oct 5 21:02:42 UTC 2023 x86_64 Linux
Winlone-i5-13:/tmp/docker-desktop-root/mnt/host/j/ai/ai-code/xinference#
```

docker-compose映射的正确路径：

window路径：/mnt/j/ai/ai-code/fastgpt/mongo/data

docker容器内部路径: /data/db

可以看出, 他用的是“docker-desktop-data”的window挂载路径

```
"Mounts": [
  {
    "Type": "bind",
    "Source": "/mnt/j/ai/ai-code/fastgpt/mongodb.key",
    "Destination": "/data/mongodb.key",
    "Mode": "rw",
    "RW": true,
    "Propagation": "rprivate"
  },
  {
    "Type": "volume",
    "Name": "edf3e6c2005a6ea2102c47ce61464a28967c47c1606ca8f377ffbaef1b730be8",
    "Source": "/var/lib/docker/volumes/edf3e6c2005a6ea2102c47ce61464a28967c47c1606ca8f377ffbaef1b730be8/_data",
    "Destination": "/data/configdb",
    "Driver": "local",
    "Mode": "z",
    "RW": true,
    "Propagation": ""
  },
  {
    "Type": "bind",
    "Source": "/mnt/j/ai/ai-code/fastgpt/mongo/data",
    "Destination": "/data/db",
    "Mode": "rw",
    "RW": true,
    "Propagation": "rprivate"
  }
],
"Config": {
```

如果是纯docker启动的路径映射

启动命令: docker run --name some-nginx -d -p 8080:80 -v /j/ai/ai-code/xinference/model:/data nginx

window路径: /j/ai/ai-code/xinference/model/

容器路径: /data

```
PS J:\ai\ai-code\xinference> docker exec -it 31de67a551c7ae8456 bash
root@31de67a551c7:/workspace# cd /data
root@31de67a551c7:/data# ls
huggingface  logs
root@31de67a551c7:/data# cd chatglm3
bash: cd: chatglm3: No such file or directory
root@31de67a551c7:/data# cd chatglm3-6b/
root@31de67a551c7:/data/chatglm3-6b# ls
MODEL_LICENSE  configuration_chatglm.py  pytorch_model-00002-of-00007.bin  pytorch_model-00005-of-00007.bin  pytorch_model.bin.index.json  tokenizer.model
README.md      modeling_chatglm.py      pytorch_model-00003-of-00007.bin  pytorch_model-00006-of-00007.bin  quantization.py              tokenizer_config.json
config.json    pytorch_model-00001-of-00007.bin  pytorch_model-00004-of-00007.bin  pytorch_model-00007-of-00007.bin  tokenization_chatglm.py
```

此电脑 > 本地磁盘 (J:) > ai > ai-code > xinference > model > chatglm3-6b				
名称	修改日期	类型	大小	
.gitattributes	2023/11/7 9:07	Git Attributes 源文件	2 KB	
config.json	2023/11/7 9:07	JSON 文件	2 KB	
configuration_chatglm.py	2023/11/7 9:07	PY 文件	3 KB	
MODEL_LICENSE	2023/11/7 9:07	文件	5 KB	
modeling_chatglm.py	2023/11/7 9:07	PY 文件	56 KB	
pytorch_model.bin.index.json	2023/11/7 9:07	JSON 文件	21 KB	
pytorch_model-00001-of-00007.bin	2023/11/7 9:15	BIN 文件	1,784,943 KB	
pytorch_model-00002-of-00007.bin	2023/11/7 9:15	BIN 文件	1,922,168 KB	
pytorch_model-00003-of-00007.bin	2023/11/7 9:15	BIN 文件	1,882,242 KB	
pytorch_model-00004-of-00007.bin	2023/11/7 9:15	BIN 文件	1,772,682 KB	
pytorch_model-00005-of-00007.bin	2023/11/7 9:15	BIN 文件	1,922,168 KB	
pytorch_model-00006-of-00007.bin	2023/11/7 9:15	BIN 文件	1,882,242 KB	
pytorch_model-00007-of-00007.bin	2023/11/7 9:12	BIN 文件	1,028,134 KB	
quantization.py	2023/11/7 9:07	PY 文件	15 KB	
README.md	2023/11/7 9:07	Markdown 源文件	8 KB	
tokenization_chatglm.py	2023/11/7 9:07	PY 文件	12 KB	
tokenizer.model	2023/11/7 9:07	MODEL 文件	995 KB	
tokenizer_config.json	2023/11/7 9:07	JSON 文件	1 KB	

```

{,
  "Mounts": [
    {
      "Type": "bind",
      "Source": "/j/ai/ai-code/xinference/model/",
      "Destination": "/data",
      "Mode": "",
      "RW": true,
      "Propagation": "rprivate"
    }
  ],
  "ContainerName": "xinference"
}

```

参考文章:

Nvidia GPU Ubuntu22.04下cuda11.7+cuDNN8.5+pytorch2.0.1的docker安装全过程

<https://zhuanlan.zhihu.com/p/675266182>

WSL2和Docker使用GPU

https://blog.csdn.net/weixin_42888638/article/details/127144788

二十三、fastgpt知识库 (WSL版)

1、fastgpt知识库：

fastgpt部署：

<https://doc.fastgpt.in/docs/development/docker/>

fastgpt源码：

<https://github.com/labring/FastGPT>

1.1 下载和修改配置（必选）：

curl -O <https://raw.githubusercontent.com/labring/FastGPT/main/files/deploy/fastgpt/docker-compose.yml>

curl -O <https://raw.githubusercontent.com/labring/FastGPT/main/projects/app/data/config.json>



docker-compose.yml

2.16KB



config.json

3.06KB

1.2 window dos设置系统代理（可选）：**拉不到镜像操作这个**

set ALL_PROXY=socks5://192.168.2.198:10806

验证：echo %ALL_PROXY%

1.3 mongodb部署（可选：自行部署mongodb）：

docker run -itd --name mongo -p 27017:27017 -e MONGO_INITDB_ROOT_USERNAME=winlone -e MONGO_INITDB_ROOT_PASSWORD=123456 mongo:5.0.18 --auth

docker run -itd --name mongo -p 27017:27017 mongo:5.0.18 --auth

1.4 设置mongodb密钥（必选）：

```
1 # 进入wsl的docker系统
2 wsl -d docker-desktop
3 # 创建 mongo 密钥
4 openssl rand -base64 756 > ./mongodb.key
5 chmod 600 ./mongodb.key
6 chown 999:root ./mongodb.key
```

1.5 启动容器（必选）

```
1 docker-compose pull
2 docker-compose up -d
```

其他命令：

```
1 停止：
2 docker-compose stop
3 重启：
4 docker-compose up -d
5 状态：
6 docker-compose ps
7 删除容器：
8 docker-compose down
```


1.6 初始化 Mongo 副本集（Mongo 为 5.x 必选）

```
1 # 进入容器
2 docker exec -it mongo bash
3
4 # 连接数据库
5 mongo -u myname -p mypassword --authenticationDatabase admin
6
7 # 初始化副本集。如果需要外网访问，mongo:27017 可以改成 ip:27017。但是需要同时修改 FastGPT 连
  接的参数（MONGODB_URI=mongodb://myname:mypassword@mongo:27017/fastgpt?authSource=admin
  => MONGODB_URI=mongodb://myname:mypassword@ip:27017/fastgpt?authSource=admin）
8 rs.initiate({
9   _id: "rs0",
10  members: [
11    { _id: 0, host: "mongo:27017" }
12  ]
13 })
14 # 检查状态。如果提示 rs0 状态，则代表运行成功
15 rs.status()
```

因为是5.0.18，没做副本时候，初始化项目时候新建的fastgpt数据库会失败，做完以上脚本操作，可能要再次重置docker容器，执行如下：

- 1 删除容器：
- 2 `docker-compose down`
- 3 重启：
- 4 `docker-compose up -d`

重启后，会看到fastgpt数据库已经创建



服务地址：http://192.168.2.198:3000

账号：root 密码：1234

fastapi key: fastgpt-

EhkdeuQoomtUxJ1frYmIfyPXGw1f4ZatVR0Y3hR0LkVbmEQX41j8sgTmPoC2iWA

yinmei聊天key: fastgpt-xyfnffZ3a72fwlQQHye7q4SOtnHEns347qyL4gMXIx5D0ziQfA6kHXMI

2、one-api:

一个强大而易用的OpenAI接口管理和分发系统

oneapi是一个强大的web应用，它提供了对chatgpt api的代理服务。

此项目是One API v0.5.5-alpha.4 由 JustSong 构建，源代码遵循 MIT 协议。是一个OpenAI接口管理和分发系统，支持Azure、Anthropic Claude、Google PaLM 2、智谱 ChatGLM、百度文心一言、讯飞星火认知、阿里通义千问以及360智脑，可用于二次分发管理key，一键部署，开箱即用。

项目地址：<https://github.com/songquanpeng/one-api>

```
1 docker run --name one-api -d --restart always -p 13000:3000 -e TZ=Asia/Shanghai -v /j/ai/ai-code/one-api:/data justsong/one-api
```

服务地址：<http://192.168.2.198:13000>

账号：root 密码：123456

! insufficient_user_quota user quota is not enough (request id: 20240313111311814137728Q9FqQOjD)

出现配额问题，是因为fastgpt调用oneapi时候，每调用一次都会扣掉充值余额



One API

首页

渠道

令牌

\$ 兑换

充值

用户

日志

设置

关于

root

充值额度

兑换码

获取兑换码

兑换

\$200000.20

剩余额度

One API 由 JustSong 构建，源代码遵循 MIT 协议

使用明细 (总消耗额度: 点击查看)

令牌名称

模型名称

起始时间

结束时间

操作

可选值

可选值

1970 / 01 / 01 08:00

2024 / 03 / 13 12:25:41

查询

渠道 ID

用户名称

可选值

可选值

时间	渠道	用户	令牌	类型	模型	提示	补全	额度	详情
2024-03-13 11:25:26	1	root	winlone-ai	消费	Qwen1.5-4B-Chat-AWQ	82	76	\$0.009480	模型倍率 30.00, 分组倍率 1.00, 补全倍率 1.00
2024-03-13 11:25:23	1	root	winlone-ai	消费	m3e-base	37		\$0.002220	模型倍率 30.00, 分组倍率 1.00, 补全倍率 1.00
2024-03-13 11:22:20	1	root	winlone-ai	消费	winlone-chatglm3	806	148	\$0.057240	模型倍率 30.00, 分组倍率 1.00, 补全倍率 1.00
2024-03-13 11:22:12	1	root	winlone-ai	消费	m3e-base	37		\$0.002220	模型倍率 30.00, 分组倍率 1.00, 补全倍率 1.00
2024-03-13 11:22:06		root		充值					通过兑换码充值 \$200000.000000 额度
2024-03-13 11:20:37		root		充值					通过兑换码充值 \$0.200000 额度
2024-03-13 11:13:06	1	root	winlone-ai	消费	m3e-base	37		\$0.002220	模型倍率 30.00, 分组倍率 1.00, 补全倍率 1.00
2024-03-13 11:11:59	1	root	winlone-ai	消费	m3e-base	37		\$0.002220	模型倍率 30.00, 分组倍率 1.00, 补全倍率 1.00
2024-03-13 11:09:15	1	root	winlone-ai	消费	m3e-base	37		\$0.002220	模型倍率 30.00, 分组倍率 1.00, 补全倍率 1.00
2024-03-13 11:05:59	1	root	winlone-ai	消费	m3e-base	37		\$0.002220	模型倍率 30.00, 分组倍率 1.00, 补全倍率 1.00

全部

刷新

« (1 2) »

应该新建兑换码

管理兑换码

Q 搜索兑换码的 ID 和名称 ...

ID	名称	状态	额度	创建时间	兑换时间	操作
100	ttt	已使用	\$200000.00	2024-03-13 11:21:51	2024-03-13 11:22:06	复制删除启用编辑
99	ttt	未使用	\$200000.00	2024-03-13 11:21:51	尚未兑换	复制删除禁用编辑
98	ttt	未使用	\$200000.00	2024-03-13 11:21:51	尚未兑换	复制删除禁用编辑
97	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制删除禁用编辑
96	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制删除禁用编辑
95	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制删除禁用编辑
94	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制删除禁用编辑
93	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制删除禁用编辑
92	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制删除禁用编辑
91	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制删除禁用编辑

添加新的兑换码

« (1 2) »

创建新的兑换码

名称 *

tttttt

额度 (等价金额: \$20000.00)

10000000000

生成数量

1

提交

取消

使用兑换码进行充值余额兑换

管理兑换码

Q e3d1c1f5642443ae9a9a6631e6658068

ID	名称	状态	额度	创建时间	兑换时间	操作
100	ttt	已使用	\$200000.00	2024-03-13 11:21:51	2024-03-13 11:22:06	复制 删除 启用 编辑
99	ttt	未使用	\$200000.00	2024-03-13 11:21:51	尚未兑换	复制 删除 禁用 编辑
98	ttt	未使用	\$200000.00	2024-03-13 11:21:51	尚未兑换	复制 删除 禁用 编辑
97	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制 删除 禁用 编辑
96	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制 删除 禁用 编辑
95	ttt	未使用	\$200000.00	2024-03-13 11:21:50	尚未兑换	复制 删除 禁用 编辑



One API

首页

渠道

令牌

兑换

充值

用户

日志

设置

关于

充值额度

e3d1c1f5642443ae9a9a6631e6658068

获取兑换码

兑换

\$200000.20

剩余额度

One API 由 JustSong 构建, 源代码遵循 MIT 协议

3、Xinference:

Xinference(<https://github.com/xorbitsai/inference>) 是一个开源推理平台，能够帮助用户非常方便地在本地部署开源大模型，借助 Xinference，你能够在云端、本地设备，甚至是笔记本电脑上运行任何开源大语言模型、语音识别模型等多模态模型的推理，llamacpp 的模型同样也是支持的。同时，Xinference 和魔搭也做了深度集成，对于在魔搭中能够找到的模型，优先从魔搭下载，对于本地部署非常友好。

项目地址：<https://github.com/xorbitsai/inference>

支持模型：<https://inference.readthedocs.io/zh-cn/latest/models/builtin/llm/index.html>

```
1 docker run --name xinference -d -p 9997:9997 -e XINFERENCE_HOME=/data -v /j/ai/ai-code/xinference/model:/data --gpus all xprobe/xinference:latest xinference-local -H 0.0.0.0
```

服务地址：<http://192.168.2.198:9997>

3.1 自定义LLM模型

新偏转

启动模型

运行模型

寄存器模型

联系我们

寄存器模型

语言模型

嵌入模型

重新命名模型

型号名称

winlone-chatglm3

带有正确放置的连字符和下划线的字母数字字符串。不得与任何内置模型名称匹配。

模型格式

☐ PyTorch

☒ GGML

☐ GGUF公司

☐ GPTQ的

☐ AWQ系列

上下文长度

2048

以亿计的模型大小

6

模型路径

/data/chatglm3-6b

对于 PyTorch，请提供 model 目录。对于 GGML/GGUF，请提供模型文件路径。

型号说明（可选）

This is a custom model description.

模型语言

☒ 英语

☒ 中文

模型能力

☒ 生成

☒ 聊天

模型系列

请注意选择与您要注册的型号相对应的姓氏。如果未找到，请选择“其他”。

☐ zephyr-7b-alpha

☐ qwen1.5-chat

☐ glaive-coder

☐ gorilla-openfunctions-v1

☐ orion-chat-rag

☒ chatglm3

☐ code-llama-instruct

☐ openhermes-2.5

☐ internlm2-chat

☐ qwen-vl-chat

☐ qwen-chat

☐ internlm-chat-20b

☐ vicuna-v1.5-16k

☐ chatglm

☐ baichuan-2-chat

☐ orca

☐ chatglm2

☐ deepseek-chat

☐ yi-vl-chat

☐ mistral-ir

☐ wizardcoder-python-v1.0

☐ 舞蝶

☐ 查特GLM3-32K型

☐ 西风-7B-β

☐ xverse聊天

☐ wizardmath-v1.0

☐ 通话-2-聊天

☐ starchat-测试版

☐ 骆马-V1.5

☐ 猫户座聊天

☐ internlm-聊天-7b

☐ 骆马-v1.3

☐ OpenBuddy

☐ 巫师-v1.0

☐ deepseek-coder-instruct

☐ 其他

寄存器模型

初始化自定义模型

- 启动模型 >
- 运行模型 >
- 寄存器模型 >
- 联系我们 >

启动模型

语言模型 嵌入模型 重新排名模型 图像模型 **自定义模型**

搜索自定义模型名称

pytorch-chatglm3-6b

在 zh

这是自定义模型描述。

2 K
上下文长度

聊天模型

winlone-chatglm3

模型格式

ggmlv3

模型尺寸

6

量化

N-GPU接口

汽车

(可选) 型号 UID, 默认为型号名称



查看已启动的LLM模型

Running Models

LANGUAGE MODELS EMBEDDING MODELS RERANK MODELS IMAGE MODELS

ID	Name	Address	GPU Indexes	Size	Quantization	Actions
winlone-chatglm3	winlone-chatglm3	0.0.0.0:44551	0	6		

聊天

Rows per page: 100 1-1 of 1

测试聊天

Xinference 聊天机器人: chatglm3

型号 ID: winlone-chatglm3
模型大小: 60 亿个参数
模型格式: ggmlv3
模型量化:

聊天机器人

你好

你好! 我是人工智能助手 ChatGLM3-6B, 很高兴见到你, 欢迎问我任何问题。

你是

我是人工智能助手 ChatGLM3-6B, 是清华大学 KEG 实验室和智谱 AI 公司于 2023 年共同训练的语言模型。我的任务是针对用户的问题和要求提供适当的答复和支持。

输入消息...

提交

重试 撤消 清楚

附加输入

参考地址: https://zhuanlan.zhihu.com/p/663065437?utm_id=0

3.2 模型加载:

预量化: 大语言模型量化方法对比: GPTQ、GGUF、AWQ

<https://blog.csdn.net/deephub/article/details/134436062>

qwen1.5-7b使用AWQ速度很快

chatglm3使用GGML速度很快

Register Model

LANGUAGE MODEL

EMBEDDING MODEL

RERANK MODEL

Model Name

qwen1.5-7b

Alphanumeric characters with properly placed hyphens and underscores. Must not match any built-in model names.

Model Format

☐ PyTorch

☐ GGML

☐ GGUF

☐ GPTQ

☒ AWQ

Context Length

2048

Model Size in Billions

7

Model Path

/data/qwen1.5-7b

For PyTorch, provide the model directory. For GGML/GGUF, provide the model file path.

Model Description (Optional)

This is a custom model description.

Model Languages

☒ English

☒ Chinese

Model Abilities

☒ Generate

☒ Chat

Model Family

Please be careful to select the family name corresponding to the model you want to register. If not found, please choose `other`.

☐ orca

☐ chatglm2

☐ llama-2-chat

☐ mixtral-instruct-v0.1

☐ internlm-chat-7b

☐ chatglm3-32k

☐ xverse-chat

☐ Yi-

☐ openhermes-2.5

☐ chatglm3

☐ orion-chat-rag

☒ qwen1.5-chat

☐ deepseek-coder-instruct

☐ zephyr-7b-alpha

☐ baich

☐ internlm-chat-20b

☐ mistral-instruct-v0.1

☐ orion-chat

☐ qwen-chat

☐ vicuna-v1.3

☐ wizardlm-v1.0

☐ wizardmath-v1.0

☐ falcon-instruct

☐ zephyr-7b-beta

☐ mistral-instruct-v0.2

☐ baichuan-chat

☐ other


REGISTER MODEL

4、fastgtp的api对接：


Ai聊天能力配置：xinference-oneapi-fastGPT

参考视频：<https://www.bilibili.com/video/BV1hC411z7xu>

新建秘钥



知识库流程配置：



语义相关度设置0.7以上最适合，把不相关的知识数据剔除



AI 对话

AI 大模型对话

...

输入

● 触发器 ?

AI 模型*

Qwen1.5-4B-Chat-AWQ

⌵

⚙ AI 配置

● 提示词 ?

你是Ai吟美，你始终以吟美自称，你是最强的知识库，什么都懂。不要强调自己是人工智能。

🔄

● 聊天记录*

3

▲
▼

> ● 用户问题*

用户问题

●

> ● 知识库引用 ?

输出

? 模块调用结束

●

? AI回复内容

●

? 新的上下文

●

你是Ai吟美，你始终以吟美自称，你是最强的知识库，什么都懂。不要强调自己是人工智能。不要说自己是AI助手。你是一个人。

 更多设置 [查看说明](#)

返回AI内容 ☒

温度 

回复上限 

引用内容模板 

[选择模板](#)

```
<data>
{{q}}
{{a}}
</data>
```



引用模板提示词 

```
{{quote}}
回答要求：
- 如果你不清楚答案，你需要澄清。
- 从 <data></data> 获取知识来回答用户的问题
- 避免提及你是从 <data></data> 获取的知识。
- 不要带<data></data>语法
- 保持答案与第一个 <data></data> 中描述的一致。
- 不要使用 Markdown 语法优化回答格式。
- 使用与问题相同的语言回答。
- 不要输出html标签
问题: "" {{question}} ""
```



关闭

确认

引用内容模板

```
<data>
{{q}}
{{a}}
</data>
```

引用模板提示词

```
{{quote}}
```

回答要求：

- 如果你不清楚答案，你需要澄清。
- 从 <data></data> 获取知识来回答用户的问题
- 避免提及你是从 <data></data> 获取的知识。

- 不要带<data></data>语法
- 保持答案与第一个 <data></data> 中描述的一致。
- 不要使用 Markdown 语法优化回答格式。
- 使用与问题相同的语言回答。
- 不要输出html标签

问题:"""{{question}}"""

用问答模式来引用知识库，效果更好，前提是你的知识库录入数据是问答形式

选择引用提示模板



标准模板

标准提示词，用于结构不固定的知识库。

问答模板

适合 QA 问答结构的知识库，可以让AI较为严格的按预设内容回答

标准严格模板

在标准模板基础上，对模型的回答做更严格的要求。

严格问答模板

在问答模板基础上，对模型的回答做更严格的要求。

确认选择

回复上限

100

4000

引用内容模板 ?

选择模板

<QA>

<问题>

{{q}}

</问题>

<答案>

{{a}}

</答案>

</QA>

引用模板提示词 ?

使用 <QA> </QA> 标记中的问答对进行回答。

{{quote}}

回答要求：

- 选择其中一个或多个问答对进行回答。
- 回答的内容应尽可能与 <答案> </答案> 中的内容一致。
- 如果没有相关的问答对，你需要澄清。
- 避免提及你是从 QA 获取的知识，只需要回复答案。

问题: "" {{question}} ""

关闭

确认

引用内容模板

<QA>

<问题>

{{q}}

</问题>

<答案>

{{a}}

</答案>

</QA>

引用模板提示词

使用 <QA></QA> 标记中的问答对进行回答。

{{quote}}

回答要求：

- 选择其中一个或多个问答对进行回答。
- 回答的内容应尽可能与第一个 <答案></答案> 中的内容一致。
- 如果没有相关的问答对，你需要用其他幽默方式代替回答。
- 避免提及你是从 QA 获取的知识，只需要回复答案。

问题:"""{{question}}"""

接口调用：

调用接口：<http://192.168.2.198:3000/api/v1/chat/completions>

请求参数：

```
1 {
2     "chatId": "abcd",
3     "stream": false,
4     "detail": false,
5     "variables": {
6         "uid": "asdfadsfasfd2323",
7         "name": "张三"
8     },
9     "messages": [
10         {
11             "content": "导演是谁",
12             "role": "user"
13         }
14     ]
15 }
```

Navigation: GET 绘画, POST 图片, POST 文本, POST 获取, POST 搜索, POST 表, vtube, vtube, fastgpt, POST New, No Environment

AI / fastgpt / New Request

POST http://192.168.2.198:3000/api/v1/chat/completions Send

Params Authorization Headers (10) Body Pre-request Script Tests Settings Cookies Beautify

none form-data x-www-form-urlencoded raw binary GraphQL JSON

```
1 {
2   ... "chatId": "abcd",
3   ... "stream": false,
4   ... "detail": false,
5   ... "variables": {
6     ... "uid": "asdfsfasfd2323",
7     ... "name": "张三"
8   },
9   ... "messages": [
10     ... {
11       ... "content": "导演是谁",
12       ... "role": "user"
13     }
14   ]
15 }
```

Body Cookies Headers (7) Test Results Status: 200 OK Time: 1589 ms Size: 720 B Save as example

Pretty Raw Preview Visualize JSON

```
1 {
2   "id": "abcd",
3   "model": "",
4   "usage": {
5     "prompt_tokens": 1,
6     "completion_tokens": 1,
7     "total_tokens": 1
8   },
9   "choices": [
10     {
11       "message": {
12         "role": "assistant",
13         "content": "很抱歉，根据提供的信息，我无法回答您的问题。我是一个人工智能助理，我的知识仅限于训练时所学的信息。我没有访问互联网的能力，也无法查看 <data></data> 标记中的内容。我的知识仅限于我训练时所学的信息，而我的训练时间截止于2023。"
14       },
15       "finish_reason": "stop",
16       "index": 0
17     }
18   ]
19 }
```

Postbot Runner Start Proxy Cookies Trash

http头请求参数：

POST

http://192.168.2.198:3000/api/v1/chat/completions

Params

Authorization

Headers (10)

Body

Pre-request Script

Tests

Settings

Headers

<> 9 hidden

	Key	Value	Description	...	Bulk Edit
☒	Authorization	Bearer fastgpt-xyfnffZ3a72fwlQQHyE7q4SOtnHEns347qy...			
	Key	Value	Description		

Body

Cookies

Headers (7)

Test Results

Status: 200 OK

Time: 1589 ms

Size: 720 B

Save as

Pretty

Raw

Preview

Visualize

JSON

1

{

2

"id": "abcd",

3

"model": "",

4

"usage": {

5

"prompt_tokens": 1,

6

"completion_tokens": 1,

7

"total_tokens": 1

8

},

9

"choices": [

10

{

11

"message": {

12

"role": "assistant",

13

"content": "很抱歉, 根据提供的信息, 我无法回答您的问题。我是一个人工智能助理, 我的知识仅限于训练时所学的信息。我没有访问互联网的能力, 也无法查看
<u>data> 标记中的内容。我的知识仅限于我训练时所学的信息, 而我的训练时间截止于2023。"

14

},

15

"finish_reason": "stop",

16

"index": 0

17

}

18

]

19

}

二十四、数据集：

<https://huggingface.co/datasets/erhwenkuo/wikipedia-zhtw>

<https://huggingface.co/datasets/wbbbbb/pclue>

https://blog.csdn.net/m0_37605642/article/details/114760974

huggingface数据集下载方法：

<https://zhuanlan.zhihu.com/p/682678051>

数据集名称	领域	数量	任务类型	Prompt	数据提供者
cmrc2018	百科	14,363	问答	问答	Yiming Cui, Ting Liu, V Che, Li Xiao, Zhipeng Wentao Ma, Shijin Wa Hu
belle_2m	百科	2,000,000	指令微调	无	LianjiaTech/BELLE

firefily	百科	1,649,399	指令微调	无	YeungNLP
alpaca_gpt4	百科	48,818	指令微调	无	Baolin Peng, Chunyue Pengcheng He, Miche Jianfeng Gao
zhihu_kol	百科	1,006,218	问答	问答	wangrui6
hc3_chinese	百科	39,781	问答	问答	Hello-SimpleAI
amazon_reviews_multi	电商	210,000	问答 文本分 类	摘要	亚马逊
mlqa	百科	85,853	问答	问答	patrickvonplaten
xlsum	新闻	93,404	摘要	摘要	BUET CSE NLP Grou
ocnli	口语	17,726	自然语言推 理	推理	Thomas Wolf
BQ	金融	60,000	文本分类	相似	Intelligent Computing Center, Harbin Institut Technology(Shenzhen
lcqmc	口语	149,226	文本分类	相似	Ming Xu

paws-x	百科	23,576	文本分类	相似	Bhavitvya Malik
wiki_atomic_edit	百科	1,213,780	平行语义	相似	abhishek thakur
chatmed_consult	医药	549,326	问答	问答	Wei Zhu
webqa	百科	42,216	问答	问答	suolyer
dureader_robust	百科	65,937	机器阅读理解 问答	问答	百度
cs1	学术	395,927	语料	摘要	Yudong Li, Yuqing Zhang, Zhao, Linlin Shen, Wei Weiquan Mao and Hui
miracl-corpus	百科	4,934,368	语料	摘要	MIRACL
lawzhidao	法律	36,368	问答	问答	和鲸社区-Ustinian
CINLID	成语	34,746	平行语义	相似	高长宽

DuSQL	SQL	25,003	NL2SQL	SQL	百度
Zhuiyi-NL2SQL	SQL	45,918	NL2SQL	SQL	追一科技 刘云峰
Cspider	SQL	7,785	NL2SQL	SQL	西湖大学 张岳
news2016zh	新闻	2,507,549	语料	摘要	Bright Xu
baike2018qa	百科	1,470,142	问答	问答	Bright Xu
webtext2019zh	百科	4,258,310	问答	问答	Bright Xu

SimCLUE	百科	775,593	平行语义	相似	数据集合, 请在 simCLUE 中查看
Chinese-SQuAD	新闻	76,449	机器阅读理解	问答	junzeng-pluto

二十五、爬虫

小红书爬虫:

<https://zhuanlan.zhihu.com/p/681430803>

其他

下载模型使用魔搭社区, 不用翻墙:

<https://modelscope.cn/>

powershell设置utf-8编码

https://blog.csdn.net/qq_43780850/article/details/129122210

VScode格式化python代码:

<https://blog.csdn.net/StephanieXYM/article/details/133767499>

python虚拟空间移植

https://zhuanlan.zhihu.com/p/598766860?utm_id=0&wd=&eqid=fa31e5fc0000193f00000006649d3e8f


- 1、(旧项目) 生成requirements.txt 文件
- 2 pip freeze > requirements.txt

```
3 2、（旧项目）安装包进行保存
4 pip download -r requirements.txt -d packages
5 3、（新项目）并把packages文件夹和requirements.txt 文件放入新的虚拟环境的Scripts文件夹下
6 pip install --no-index --find-links=packages -r requirements.txt
```

https://blog.csdn.net/qq_42455308/article/details/129274929

VSCode如何同时打开多个项目

VS默认打开文件夹都是在当前窗口打开，需要设置下，**文件>>首选项>>设置>>窗口>>新建窗口>>Open Folders In New Window>>on**



request代理请求

<https://www.cnblogs.com/kainhuck/p/12421700.html>

```
1 import requests
2
3 proxies = {
4     'http': 'socks5://127.0.0.1:20808',
```



```
5     'https': 'socks5://127.0.0.1:20808'  
6 }  
7  
8 r = requests.get(url, proxies=proxies)
```

AI例子:

ai莉莉丝

<https://live.bilibili.com/30412640>

chatgpt4, 一个月8元



榜1 **bilibili link** 程序猿的退休生活 :自己导入数据集训练吗

榜2 **主播** TamikiP :#8块左右



只是接了中转key

什么数据都没训练，就有这效果？



给了提示词而已

那gpt4确实强



本地模型都达不到这种语言效果



试试rwkv或glm3

我现在是千问1.5和glm3



语言没那么灵动



可以试试在提示词上花点功夫

15:15

提示词你怎么写的

