

# 1. 开通阿里云 GPU 云服务器

## 1.1 搜索“GPU 云服务器”，点击“立即开通”



## 1.2 根据自身情况选择付费类型，推荐“按量付费”；

## 1.3 根据实际业务重心，选择地域；

## 1.4 选择网络（不是所有可用区都有所有机型的，建议结合机型的可用区进行选择）；



## 1.5 选择实例规格（选择 GPU 型号和数量）

实例  
如何选择实例

最近使用规格 全部规格

筛选 选择 vCPU 选择内存 模糊搜索规格名称 I/O 优化实例 查看更多规格参数

架构 X86 计算 ARM 计算 GPU/FPGA/ASIC 弹性裸金属服务器 超级计算集群  
全部分类 全部分类 A10加速 全部分类 全部分类

规格族	实例规格	vCPU	内存	GPU/FPGA	GPU显存	可售可用区	架构	参考价格
<input type="radio"/>	GPU 计算型 gn7i ecs.gn7i-c8g1.2xlarge	8 vCPU	30 GiB	1 * NVIDIA A10	1 * 24 GB	23个可用区	GPU/FPGA加速	¥9.5326/时
<input checked="" type="radio"/>	GPU 计算型 gn7i ecs.gn7i-c16g1.4xlarge	16 vCPU	60 GiB	1 * NVIDIA A10	1 * 24 GB	23个可用区	GPU/FPGA加速	¥10.0934/时

## 1.6 选择安装镜像

点击云市场镜像，搜索“deepgpu-llm-inference”，选择镜像进行安装；

镜像 ? 最近使用镜像 公共镜像 自定义镜像 共享镜像 云市场镜像 荐 社区镜像

从云市场获取更多选择 (含操作系统)

## 1.7 根据业务需求，配置云盘大小

存储

系统盘  
如何选择云盘

类型	容量	数量	IOPS	性能	操作
ESSD云盘	500	GiB 1	7800	PL0 (单盘IOPS性能上限1万)	<input checked="" type="checkbox"/> 随实例释放 <input type="checkbox"/> 加密

## 1.8 分配公网 IP，并配置带宽峰值（推荐按量付费，带宽拉满）

公网 IP  分配公网 IPv4 地址  
系统会分配公网 IP，也可采用更加灵活的弹性公网 IP 方案，了解 [如何配置并绑定弹性公网 IP 地址](#)>

带宽计费模式  按使用流量  按固定带宽

带宽峰值 1 2 3 5 10 50 100 Mbps   Mbps  
阿里云免费提供最高 5Gbps 的恶意流量攻击防护。 [了解更多](#) > | [提升防护能力](#) >

## 1.9 配置安全组

**安全组** ?  
如何配置安全组

[已有安全组](#) [新建安全组](#)

[重新选择安全组](#)

1) aiacc / sg-uf6ewkbt185lrib8559j (已有 6 个实例+辅助网卡, 还可以加入 1994 个实例+辅助网卡)

**使用须知** 请确保所选安全组开放包含 22 (Linux) 或者 3389 (Windows) 端口, 否则无法远程登录ECS, [前往设置](#)

## 1.10 配置机器登录密码（推荐自定义密码）

管理设置

**登录凭证** [密钥对](#) [使用镜像预设密码](#) [自定义密码](#) [创建后设置](#)

密钥对安全强度远高于常规自定义密码, 可以避免暴力破解威胁, 建议您使用密钥对创建实例

**登录名**  root  ecs-user

root具有操作系统的最高权限, 使用root作为登录名可能会导致安全风险, 建议您使用ecs-user作为登录名. [前往了解更多](#)

**登录密码** [可创建后设置](#)

**确认密码**

**标签** [+ 添加标签 \(0 / 20\)](#)

如何设计标签 标签由区分大小写的键值对组成. 您设置的标签将应用在本次创建的全部实例和云盘

## 1.11 勾选服务条款，并确认下单

配置费用: **¥ \*\*\* /时**  
原价: **¥ 10.62 /时**

公网流量费用: **¥ \*\*\* /GB**  
原价: **¥ 0.800 /GB**

[《云服务器 ECS 服务条款》](#)

**确认下单**

## 1.12 创建成功，点击“管理控制台”查看机器



## 1.13 查看机器状态并获取 IP 地址，SSH 远程登录

标签	监控	可用区	IP地址	状态	网络类型	配置	付费方式
u5kibhc test-		上海 可用区 M	10.10.10.10 (公有) 10.10.10.11 (私有)	运行中	专有网络	16 vCPU 60 GiB (I/O优化) GPU: NVIDIA A10 ecs.gn7i-c16g1.4xlarge 100Mbps (峰值)	按量 2023年10月18日 10:40 创建

# 2. 运行 LLM 模型推理

## 2.1 查看 DeepGPU-LLM 版本，确认是否需要升级

查看 DeepGPU-LLM 版本和安装路径

```
pip show -f deepgpu-llm
```

```
(base) root@iZuf6dxgo2te0ttu5klbhcZ:~# pip show -f deepgpu-llm
WARNING: Ignoring invalid distribution -ccelerate (/workspace/miniconda/lib/python3.10/site-packages)
Name: deepgpu-llm
Version: 0.9.7+pt2.0cu117
Summary: DeepGPU LLM inference package
Home-page:
Author:
Author-email:
License:
Location: /workspace/miniconda/lib/python3.10/site-packages
Requires: bfloat16, colorama, SentencePiece, transformers
Required-by:
Files:
  ../..../bin/baichuan_cli
  ../..../bin/baichuan_hf_cli
  ../..../bin/chatglm_cli
  ../..../bin/chatglm_hf_cli
  ../..../bin/gpt_gemm
  ../..../bin/huggingface_baichuan_convert
  ../..../bin/huggingface_chatglm2_convert
  ../..../bin/huggingface_glm_convert
  ../..../bin/huggingface_llama_convert
  ../..../bin/llama_cli
  deepgpu_llm-0.9.7+pt2.0cu117.dist-info/INSTALLER
  deepgpu_llm-0.9.7+pt2.0cu117.dist-info/METADATA
  deepgpu_llm-0.9.7+pt2.0cu117.dist-info/RECORD
  deepgpu_llm-0.9.7+pt2.0cu117.dist-info/REQUESTED
  deepgpu_llm-0.9.7+pt2.0cu117.dist-info/WHEEL
  deepgpu_llm-0.9.7+pt2.0cu117.dist-info/direct_url.json
  deepgpu_llm-0.9.7+pt2.0cu117.dist-info/top_level.txt
  deepgpu_llm/__init__.py
  deepgpu_llm/__pycache__/__init__.cpython-310.pyc
  deepgpu_llm/__pycache__/baichuan_model.cpython-310.pyc
  deepgpu_llm/__pycache__/chatglm_model.cpython-310.pyc
  deepgpu_llm/__pycache__/deepgpu_utils.cpython-310.pyc
  deepgpu_llm/__pycache__/llama_model.cpython-310.pyc
  deepgpu_llm/baichuan_model.py
  deepgpu_llm/chatglm_model.py
  deepgpu_llm/deepgpu_utils.py
  deepgpu_llm/libdeepgpu_glm.so
  deepgpu_llm/libdeepgpu_llama.so
  deepgpu_llm/llama_model.py
```

查看最新版本: [https://aiacc-inference-public-v2.oss-cn-hangzhou.aliyuncs.com/aiacc-inference-llm/deepgpu\\_llm.html](https://aiacc-inference-public-v2.oss-cn-hangzhou.aliyuncs.com/aiacc-inference-llm/deepgpu_llm.html)

下载命令

```
wget https://aiacc-inference-public-v2.oss-cn-hangzhou.aliyuncs.com/aiacc-inference-llm/deepgpu_llm-0.9.7+pt2.0cu117-py3-none-any.whl
```

安装命令

```
pip install xxx.whl
```

## 2.2 下载或上传 huggingface 标准的 LLM 模型

上传自己的模型，或者从 huggingface 下载开源模型。

下载命令

```
git-lfs clone https://huggingface.co/meta-llama/Llama-2-7b
git-lfs clone https://huggingface.co/THUDM/chatglm2-6b
git-lfs clone https://huggingface.co/baichuan-inc/Baichuan-13B-Chat
```

近期国内对 huggingface 基本全部墙了，有个迂回方案，不能保证所有模型适用

1. 从 huggingface 下载 LLM 模型相关的代码和配置文件（权重除外）

2. 从 modelscope 下载模型;

```
https://modelscope.cn/models/ZhipuAI/chatglm2-6b  
https://modelscope.cn/models/ZhipuAI/ChatGLM-6B  
https://modelscope.cn/models/baichuan-inc/Baichuan2-13B-Chat  
https://modelscope.cn/models/baichuan-inc/Baichuan-13B-Chat
```

3. 将 huggingface 下载的代码和权重替换到 modelscope 下载的模型目录中

## 2.3 模型转换

转换命令

```
huggingface_baichuan_convert -in_file /root/deepGPU/models/Baichuan2-7B-Chat/ -saved_dir  
/root/deepGPU/models/deepgpu/baichuan2-7b-chat -infer_gpu_num 1 -weight_data_type  
fp16 -model_name baichuan2-7b-chat
```

其中:

- in\_file 指明原始 huggingface 模型目录
- saved\_dir 指明转换后的模型目录
- infer\_gpu\_num 指明转换后模型运行所需的 GPU 数量
- weight\_data\_type 指明转换后模型运行时的计算精度
- model\_name 模型名称

模型转换脚本选择

转换脚本	模型
huggingface_baichuan_convert	baichuan 和 baichuan2 系列模型
huggingface_llama_convert	llama 和 llama2 系列模型
huggingface_glm_convert	chatglm 和 GLM-130b 模型
huggingface_chatglm2_convert	chatglm2 模型

## 2.4 运行模型推理

使用 DeepGPU-LLM 自带的运行脚本:

```
baichuan_cli --tokenizer_dir /root/deepGPU/models/Baichuan2-7B-Chat/ --model_dir  
/root/deepGPU/models/deepgpu/baichuan2-7b-chat/1-gpu/
```

可以复制该脚本进行代码修改, 实现自己的模型加载和运行, 增量开发其他功能。