

# LocalAI平台使用指南

## 1 商品说明

LocalAI是 OpenAI 的免费开源替代方案。LocalAI 可作为 REST API 的替代，兼容 OpenAI（Elevenlabs、Anthropic 等）API 规范，用于本地 AI 推理。它允许您在本地或使用消费级硬件运行 LLM、生成图像、音频（以及其他内容），并支持多种模型系列。

LocalAI 无需 GPU 计算。

本商品在鲲鹏云的AArch64架构上Ubuntu24.04和HCE2.0系统中进行安装后以镜像提供给用户使用。

## 2 商品购买


您可以在云商店搜索“LocalAI平台”。

其中，地域、规格、推荐配置使用默认，购买方式根据您的需求选择按需/按月/按年，短期使用推荐按需，长期使用推荐按月/按年，确认配置后点击“立即购买”。

### 2.1 商品支持自定义 ECS 购买，具体见章节 3.1.1

### 2.2 使用 RFS 模板直接部署




[illegible]

2025-7-1 华为保密信息,未经授权禁止扩散 第2页,共6页



如下图“Apply required resource success.”即为资源创建完成



### 3 商品资源配置

商品支持ECS控制台配置，下面对资源配置的方式进行介绍。

#### 3.1 ECS 控制台配置

##### 3.1.1 准备工作

在使用ECS控制台配置前，需要您提前配置好安全组规则。

安全组规则的配置如下：

- 入方向规则放通端口8080，源地址内必须包含您的客户端ip，否则无法访问
- 入方向规则放通CloudShell连接实例使用的端口22，以便在控制台登录调试。
- 出方向规则一键放通

##### 3.1.2 创建 ECS

前提工作准备好后，选择ECS控制台配置跳转到购买ECS页面，ECS资源的配置如下图所示：



## 基础配置

计费模式

包年/包月

按需计费

竞价计费

按需计费实例不支持备案。[了解备案限制](#)

区域

华北-北京四



推荐区域 华北-北京四

华南-广州

华东-上海一

华北-乌兰察布一

西南-贵阳一

云服务器创建后无法更改区域；不同区域之间内网互不相通，请就近选择靠近您业务的区域，减少网络时延。[如何选择区域](#)

可用区

随机分配

可用区1

可用区2

可用区3

可用区7



随机至多可用区

## 实例

规格类型选型

业务场景选型

CPU架构

x86计算

鲲鹏计算

实例筛选

--请选择vCPUs--

--请选择内存--

请输入规格名称模糊搜索

☒ 隐藏售罄的规格

鲲鹏通用计算增强型

鲲鹏内存优化型

鲲鹏超高I/O型

CSDN @p\_xcn

## 操作系统

镜像

公共镜像

私有镜像

共享镜像

市场镜像

Huawei Cloud  
EulerOS

CentOS



Ubuntu



EulerOS



Debian



KylinOS



UnionTechOS



openEuler

Huawei Cloud EulerOS 2.0 64bit for kAi2p with HDK 23.0.1 and CANN ...



## 存储与备份

系统盘

磁盘类型

系统盘大小(GiB)

通用型SSD



40

IOPS上限2,280，IOPS突发上限8,000 [高级设置](#)

增加一块数据盘

您还可以挂载 23 块磁盘（云硬盘）

☐ 开启备份

CSDN @p\_xcn

云服务器名称: echo-k8s ☐ 允许重置  
购买多台云服务器时，支持自动增加数字后缀命名或自定义规则命名。<sup>①</sup>

描述:

登录凭证:     
请妥善保管密钥对的私钥文件，登录、重置密码时云服务器操作密钥时，均需要使用该文件。

密钥对:   <sup>①</sup>

云备份: 使用云备份服务，提供可靠备份存储服务，存储系统数据备份产生的备份副本的数据。  
   <sup>①</sup>  
备份可以保护您在云服务器故障时丢失数据，为了您的数据安全，我们建议您购买备份。

云服务器组 (可选):  <sup>①</sup>

高级选项: ☒ 现在配置  
实例自定义数据注入:   如何注入?  

```
#!bin/bash
echo 'root:x' | chpasswd
bash /home/init.sh
```

购买量:  台 配置: 配置 **¥0.3988** 小时 + 弹性公网IP **¥0.80** 起 <sup>①</sup>

值得注意的是：

- VPC您可以自行创建
- 安全组选择3.1.1章节中配置的安全组
- 弹性公网IP选择现在购买，推荐选择“按流量计费”，带宽大小可设置为5Mbit/s
- 高级配置需要在高级选项支持注入自定义数据，所以登录凭证不能选择“密码”，选择创建后设置
- 其余默认或按规则填写即可。

## 4 商品使用

### 4.1 登录服务器查看 Dify 进程

#### 4.1.1 进入系统后通过命令


```
cd ~/localai
```

```
docker run -p 8080:8080 -v $PWD/models:/models -ti --rm localai/localai:v3.0.0 --models-path /models
```

```
root@ecs-kaiyuan-public-0003:~/localai# docker run -p 8080:8080 -v $PWD/models:/models -ti --rm localai/localai:v3.0.0 --models-path /models
@@@@@
Skipping rebuild
@@@@@
If you are experiencing issues with the pre-compiled builds, try setting REBUILD=true
If you are still experiencing issues with the build, try setting CMAKE_ARGS and disable the instructions set as needed:
CMAKE_ARGS="-DGGML_F16C=OFF -DGGML_AVX512=OFF -DGGML_AVX2=OFF -DGGML_FMA=OFF"
see the documentation at: https://localai.io/basics/build/index.html
Note: See also https://github.com/go-skynet/LocalAI/issues/288
@@@@@
CPU info:
CPU: no AVX      found
CPU: no AVX2     found
CPU: no AVX512  found
@@@@@
8:53:38AM INF env file found, loading environment variables from file envFile=.env
8:53:38AM INF Setting logging to info
8:53:38AM INF Starting LocalAI using 2 threads, with models path: /models
8:53:38AM INF LocalAI version: v3.0.0 (f9b968e19d7cbc556d59dceb2e0e450b828a3fda)
8:53:38AM INF Preloading models from /models
8:53:38AM INF core/startup process completed!
8:53:38AM INF LocalAI API is listening! Please connect to the endpoint for API documentation. endpoint=http://0.0.0.0:8080
8:53:38AM INF Success ip=192.168.0.250 latency=3.598135ms method=GET status=200 url=/
```

#### 4.1.2 通过浏览器登录 LocalAI 平台

<http://yourIp:8080/>



#### 4.2 参考文档

完整操作参考 [LocalAI手册](#)