目录

安装CUDA驱动指南

CUDA (Compute Unified Device Architecture) 是显卡厂商 NVIDIA 推出的运算平台。 CUDA™ 是一种由 NVIDIA 推出的通用并行计算架构，该架构使 GPU 能够解决复杂的计算问题。 它包含了 CUDA 指令集架构（ISA）以及 GPU 内部的并行计算引擎。开发人员现在可以使用 C 语言，C++ ，FORTRAN 来为 CUDA™ 架构编写程序，所编写出的程序可以在支持 CUDA™ 的处理器上以超高性能运行。

GPU 裸金属采用 NVIDIA 显卡，需要安装 CUDA 开发运行环境。以Ubuntu 16.0.4为例，可参照以下步骤进行安装。

安装依赖包

登录 GPU 实例，下载安装需要的依赖库，运行如下指令：

```
sudo apt-get install libGLU* libXi* libXmu*  -y
```

下载驱动

1. 登录GPU实例，进行CUDA驱动下载或复制链接 https://developer.nvidia.com/cuda-downloads
2. 选择与自己的操作系统相匹配的安装包。以Ubuntu 16.0.4 64 位为例，可按如下方式进行选择：

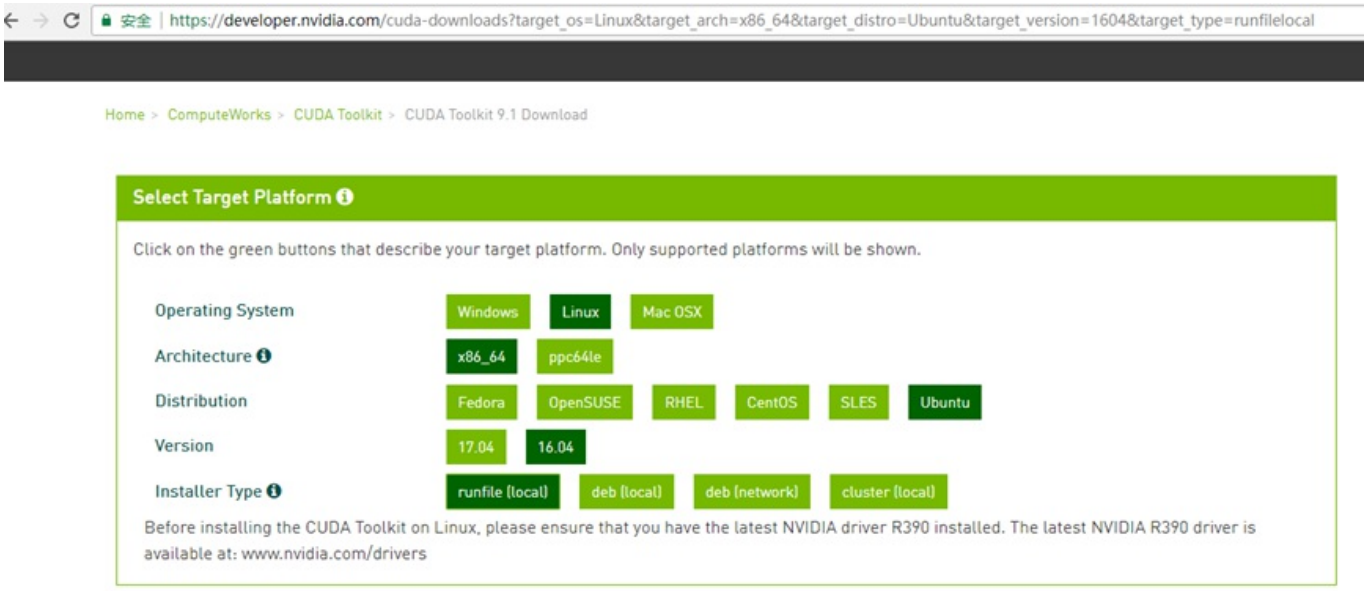

注意：

- Installer Type 这里推荐选择 runfile（local）。
- network：网络安装包，安装包较小，需要在主机内联网下载实际的安装包。
- local：本地安装包。安装包较大，包含每一个下载安装组件的安装包。

3. 点击【Download】，选择下载存放地址：

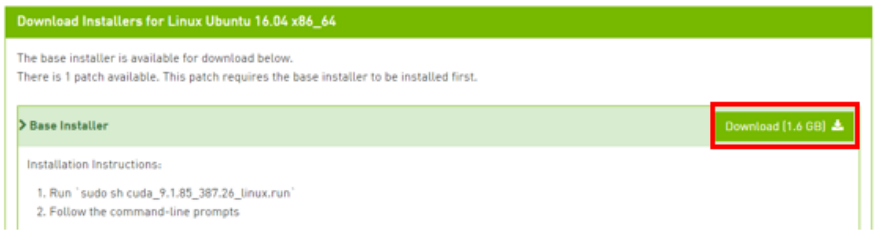

4. 切换到CUDA安装包所在的目录，执行以下命令：

```
sudo sh cuda_9.1.85_387.26_linux.run
```

根据提示选择accept -yes -enter。

注意：

- 若执行后出现如下结果：

```
Driver: Installed require reboot
```

```
Toolkit: install skip
Samples: install skip
```

说明这个CUDA安装包包含了Driver，Toolkit和Samples三部分，但此次安装时只把驱动装上了。

此时需重新安装，再次执行以下命令：

```
sudo sh cuda_9.1.85_387.26_linux.run
```

- CUDA安装成功结果如下：

```
Driver: Installed
Toolkit: Installed in /usr/local/cuda
Samples: Installed in /home/XX
```

5. 在 /usr/local/cuda/samples/1_Utilities/deviceQuery 目录下，执行 make 命令，可以编译出 deviceQuery 程序。执行 deviceQuery 正常显示如下设备信息，此刻认为 CUDA 安装正确。

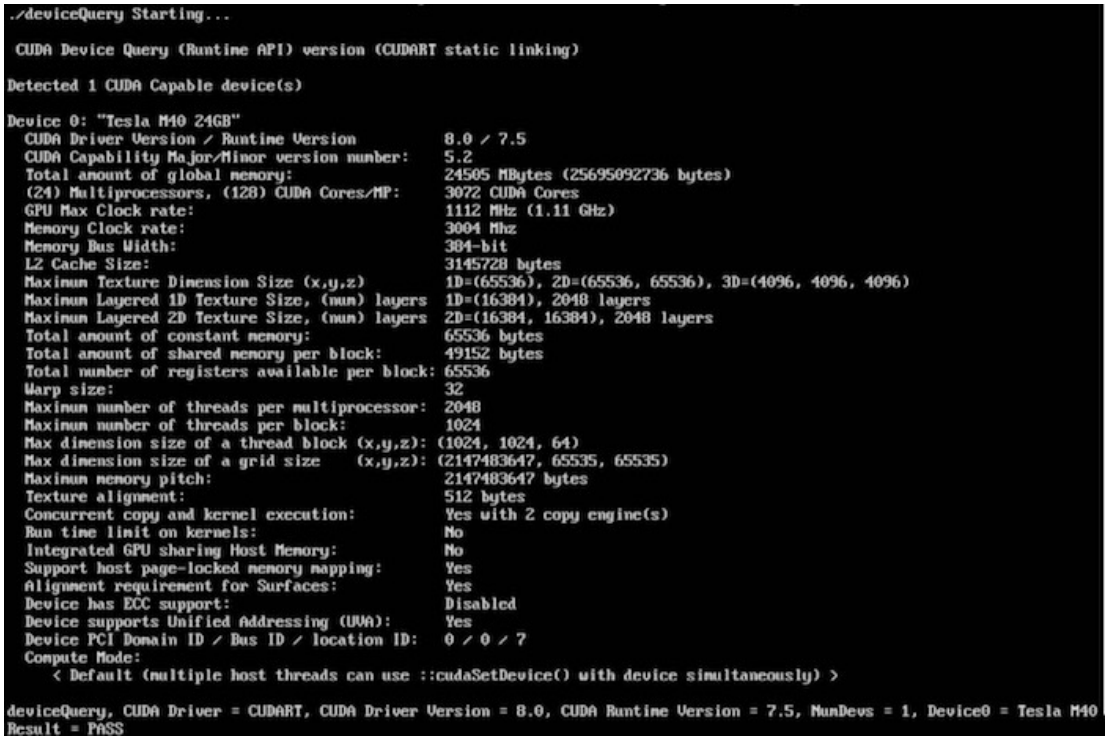

```
./deviceQuery Starting...

 CUDA Device Query (Runtime API) version (CUDART static linking)

Detected 1 CUDA Capable device(s)

Device 0: "Tesla M40 24GB"
  CUDA Driver Version / Runtime Version          8.0 / 7.5
  CUDA Capability Major/Minor version number:    5.2
  Total amount of global memory:                 24505 MBytes (25695092736 bytes)
  (24) Multiprocessors, (128) CUDA Cores/MP:     3072 CUDA Cores
  GPU Max Clock rate:                            1112 MHz (1.11 GHz)
  Memory Clock rate:                             3004 Mhz
  Memory Bus Width:                              384-bit
  L2 Cache Size:                                 3145728 bytes
  Maximum Texture Dimension Size (x,y,z)         1D=(65536), 2D=(65536, 65536), 3D=(4096, 4096, 4096)
  Maximum Layered 1D Texture Size, (num) layers  1D=(16384), 2048 layers
  Maximum Layered 2D Texture Size, (num) layers  2D=(16384, 16384), 2048 layers
  Total amount of constant memory:               65536 bytes
  Total amount of shared memory per block:       49152 bytes
  Total number of registers available per block: 65536
  Warp size:                                     32
  Maximum number of threads per multiprocessor:  2048
  Maximum number of threads per block:           1024
  Max dimension size of a thread block (x,y,z): (1024, 1024, 64)
  Max dimension size of a grid size    (x,y,z): (2147483647, 65535, 65535)
  Maximum memory pitch:                          2147483647 bytes
  Texture alignment:                             512 bytes
  Concurrent copy and kernel execution:          Yes with 2 copy engine(s)
  Run time limit on kernels:                     No
  Integrated GPU sharing Host Memory:            No
  Support host page-locked memory mapping:       Yes
  Alignment requirement for Surfaces:            Yes
  Device has ECC support:                        Disabled
  Device supports Unified Addressing (UVA):      Yes
  Device PCI Domain ID / Bus ID / location ID:   0 / 0 / 7
  Compute Mode:
     < Default (multiple host threads can use ::cudaSetDevice() with device simultaneously) >

deviceQuery, CUDA Driver = CUDART, CUDA Driver Version = 8.0, CUDA Runtime Version = 7.5, NumDevs = 1, Device0 = Tesla M40
Result = PASS
```

安装cuDNN和NCCL指南

操作背景

cuDNN是一个深度学习库,实现并优化了多种神经网络的算法,加快了深度学习训练的速度,CUBLAS线性代数库,提供常见的线性代数操作,很好地支持深度学习框架,NCCL用于加速多GPU之间通信。

操作步骤

1.安装cuDNN

cuDNN的全称为NVIDIA CUDA® Deep Neural Network library，是NVIDIA专门针对深度神经网络（Deep Neural Networks）中的基础操作而设计基于GPU的加速库。cuDNN为深度神经网络中的标准流程提供了高度优化的实现方式，例如convolution、pooling、normalization以及activation layers的前向以及后向过程。 下面以Ubuntu 16.0.4为例说明如何配置cuDNN进行神经网络的加速。

1）登录GPU实例，进行cuDNN下载或复制下载地址 https://developer.nvidia.com/cudnn ，点击【下载cuDNN】进行下载。

2）需要登录/注册，请按步骤提示，完成输入邮箱和密码，用户等信息，确认邮件等步骤。

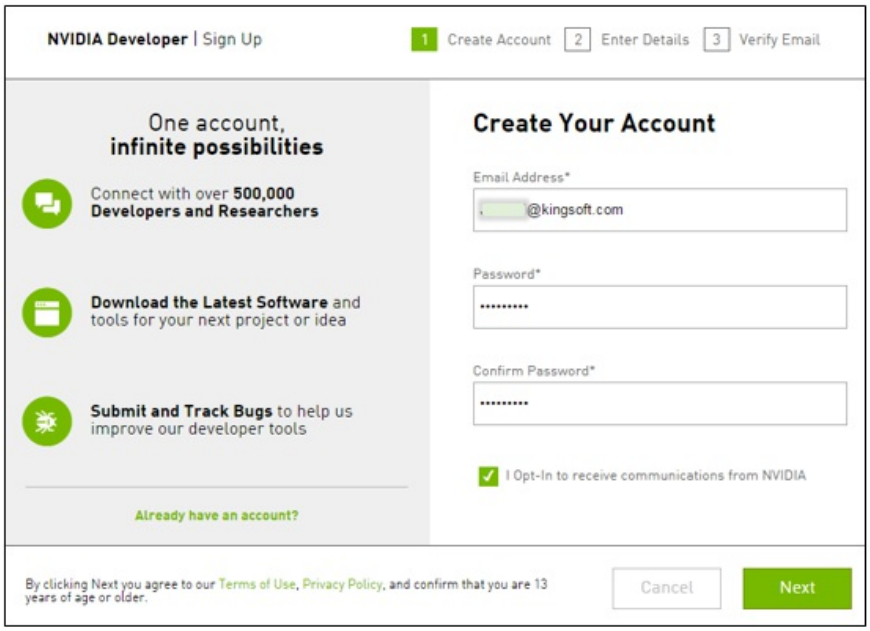

3）选择与已安装的CUDA对应的版本，这里我们选择CUDA 9.1。

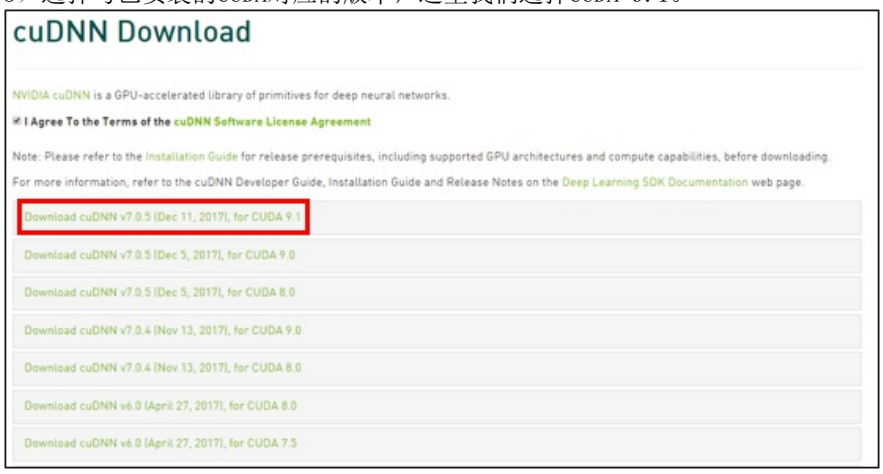

4）选择与操作系统对应的版本，这里我们选择【cuDNN v7.0.5 Library for Linux】，下载得到压缩文件cudnn-9.1-linux-x64-v7.tgz。

5）切换到cuDNN压缩包所在目录，在命令行输入以下指令进行解压。

```
sudo tar -xvf cudnn-9.1-linux-x64-v7.tgz -C /usr/local          ---- 完成安装
```

2.安装NCCL

NCCL是Nvidia Collective multi-GPU Communication Library的简称，它是一个实现多GPU的collective communication通信库，Nvidia做了很多优化，以在PCIe、Nvlink、InfiniBand上实现较高的通信速度。 1）登录GPU实例，进行NCCL下载或复制下载地址 https://developer.nvidia.com/nccl ，点击【Download NCCL】进行下载。

2）需要登录/注册，请按步骤提示耐心操作。登录后，选择对应版本的 NCCL，这里我们选择【Download NCCL v2.1.4, for CUDA 9.1, Jan 18, 2018】。

![NCCL1.png](http://fe-frame.ks3-cn-beijing.ksyun.com/project/cms/57d29afa19e13caa4b92050031838654)

3）选择与操作系统对应的版本，以Ubuntu 16.0.4为例，这里我们选择【NCCL 2.1.4 for Ubuntu 16.04 and CUDA 9】，下载得到nccl-repo-ubuntu1604-2.1.4-ga-cuda9.1_1-1_amd64.deb。

![NCCL2.png](http://fe-frame.ks3-cn-beijing.ksyun.com/project/cms/2064dd3a7762a8bbb22d31038a91a79a)

4）切换到NCCL文件所在目录，运行以下命令：

```
sudo dpkg -i nccl-repo-ubuntu1604-2.1.4-ga-cuda9.1_1-1_amd64.deb
```

完成解压安装，将NCCL的 include 和 lib 文件夹下文件放到对应 /usr/local/include/usr/local/lib 目录下。

安装CAFFE指南

前期工作

1. 已安装成功CUDA，若未安装请查看教程 安装CUDA驱动指南。
2. 已安装cuDNN和NCCL优化库，若未安装请查看教程 安装cuDNN和NCCL指南。
3. 安装必要的依赖库，输入以下指令：

```
sudo apt-get install libprotobuf-dev libleveldb-dev libsnappy-dev libopencv-dev libhdf5-serial-dev protobuf-compiler libgfla
gs-dev libgoogle-glog-dev liblmdb-dev libatlas-base-dev git  -y
sudo apt-get install --no-install-recommends libboost-all-dev  -y
```

安装CAFFE

1. 从 Github下载CAFFE的对应发布版本，下载地址如下： https://github.com/NVIDIA/caffe/releases， 选择【Source code (tar.gz)】。 或者复制链接地址，利用指令进行下载：

```
wget https://github.com/NVIDIA/caffe/archive/v0.16.6.tar.gz
```

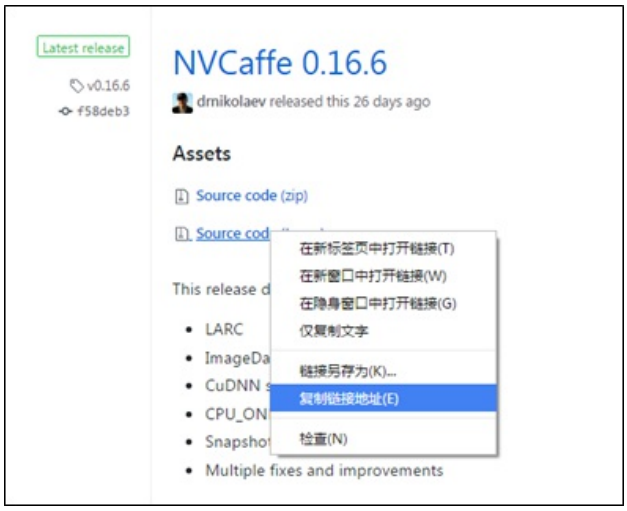

2. 进行Openblas下载与安装，输入如下指令：

```
wget  https://github.com/xianyi/OpenBLAS/archive/v0.2.20.tar.gz
tar -xvf v0.2.20.tar.gz
cd OpenBLAS-0.2.20
make PRFIX=/opt/OpenBLAS
make install
```

3. 配置lib路径，使lib库生效，输入以下指令：

```
echo “/opt/OpenBLAS/lib/
      /usr/local/cuda/lib64“ >> /etc/ld.so.conf.d/cuda.conf
ldconfig
ldconfig -v
```

4. 解压CAFFE压缩包，请把文件放到/home 目录下，输入以下指令：

```
tar -xvf v0.16.6.tar.gz
```

```
cd caffe-0.16.6
cp Makefile.config.example Makefile.config
```

5. 对Makefile.config进行编辑，输入如下指令：

   ```
   vi Makefile.config
   ```

   去掉USE_NCCL := 1 ， USE_CUDNN := 1 之前的注释#，使其生效。

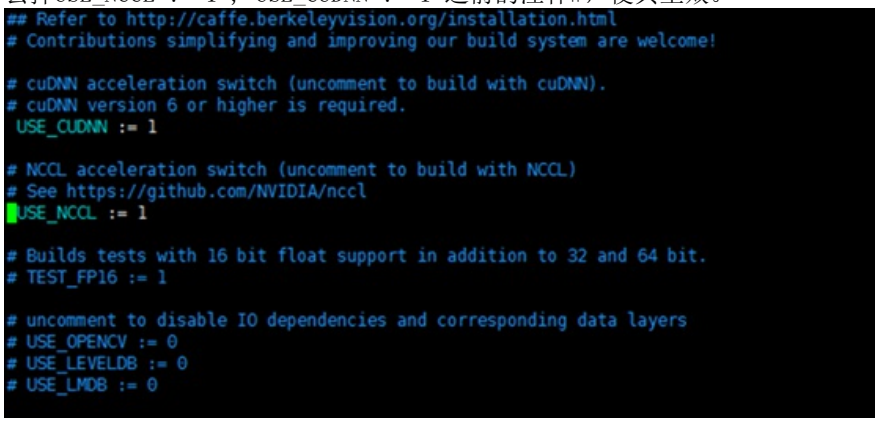

   注：

   - 取消对行 USE_CUDNN := 1 的注释可以启用 cuDNN 加速。
   - 取消对行 USE_NCCL := 1 的注释可以启用在多个 GPU 上运行 Caffe 所需的 NCCL。

6. 保存并关闭文件，对CAFFE进行编译，输入指令：

   ```
   make -all  - j4
   ```

   等待编译打开编辑器，添加bin 路径，输入指令：

   ```
   vi /etc/profile
   export  PATH=$PATH:/home/ caffe-0.16.6/build/tools
   ```

   保存并退出，输入指令，使文件生效。

   ```
   source /etc/profile
   ```

配置pycaffe

1. 根据caffe根目录python文件夹下的requirements.txt的清单文件，安装上面列出的需要的依赖库。输入如下指令查看requirements.txt：

   ```
   cd caffe-0.16.6/python
   cat requirements.txt
   ```

   显示如下信息：

   ```
   cython>=0.19.2
   numpy>=1.7.1,<=1.11.0
   scipy>=0.13.2
   scikit-image>=0.9.3
   matplotlib>=1.3.1
   ipython>=3.0.0,<=5.4.1
   h5py>=2.2.0
   leveldb>=0.191
   networkx>=1.8.1
   nose>=1.3.0
   pandas>=0.12.0
   protobuf>=2.5.0
   pydot2
   python-dateutil>=1.4,<2
   python-gflags>=2.0
   pyyaml>=3.10
   Pillow>=2.3.0
   six>=1.1.0
   ```

2. 执行安装代码：

   ```
   for seq in $(cat requirements.txt  )
   do
   pip install $seq
   done
   ```

3. 安装完成以后，再次回到caffe根目录，可以执行如下指令：

```
cd ..  ----退出软件python 目录，回到caffe根目录
sudo pip install -r python/requirements.txt
```

安装成功的，都会显示Requirement already satisfied； 没有安装成功的，会继续安装。

4. 编译python接口，输入如下指令：

```
make pycaffe
```

配置路径，添加到 /etc/profile，输入以下指令：

```
vi /etc/profile
export PYTHONPATH=/home/ caffe-0.16.6/python:$PYTHONPATH
```

保存并退出，输入指令，使文件生效：

```
source /etc/profile
```

5. 输入python，开启pyhton测试pycaffe，若运行如下三行不出错 说明配置完成。

```
import caffe
from caffe import layers as L
from caffe import params as P
```

安装TensorFlow指南

安装TensorFlow

网络安装

网络良好时，可直接指令安装：

```
pip3 install --upgrade tensorflow-gpu
```

源码安装

1. 进行tensorflow 1.5.0下载或复制下载地址 https://github.com/tensorflow/tensorflow
2. 下载对应 GPU版本，这里我们选择python 3.5 版本，得到文件【tf_nightly_gpu-1.head-cp35-cp35m-linux_x86_64.whl】。

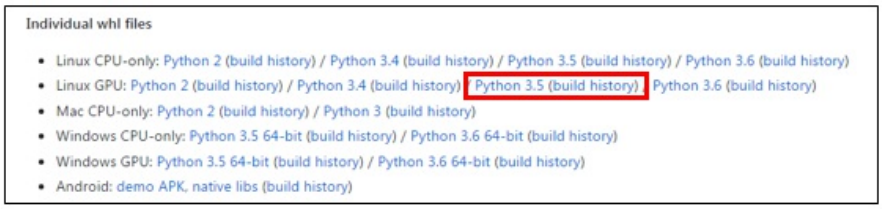

3. 输入以下指令，进行安装。

```
pip3 install tf_nightly_gpu-1.head-cp35-cp35m-linux_x86_64.whl
```

验证环境

TensorFlow安装完成后，执行python脚本，根据输出结果，确认是否有异常。Python代码如下：

```
import tensorflow as tf
import numpy as np
x_data = np.float32(np.random.rand(2, 100))
y_data = np.dot([0.100, 0.200], x_data) + 0.300
b = tf.Variable(tf.zeros([1]))
W = tf.Variable(tf.random_uniform([1, 2], -1.0, 1.0))
y = tf.matmul(W, x_data) + b
loss = tf.reduce_mean(tf.square(y - y_data))
optimizer = tf.train.GradientDescentOptimizer(0.5)
train = optimizer.minimize(loss)
init = tf.initialize_all_variables()
sess = tf.Session()
sess.run(init)
for step in range(0, 201):
    sess.run(train)
    if step % 20 == 0:
        print (step, sess.run(W), sess.run(b))*
```

使用以上代码写入python 文件，Python 指向文件运行即可，如果运行成功则结果如下：

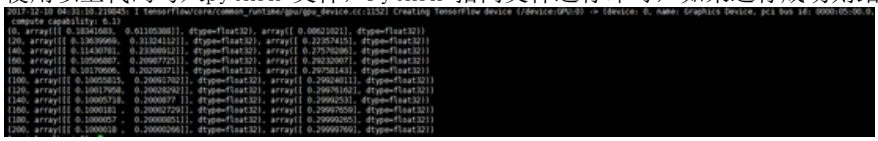

更加详细的安装流程，可以参考tensorflow社区文档。

产品常见问题

Q：GPU相对于CPU有哪些优势？

A：GPU比CPU拥有更多的逻辑运算单元(ALU)支持并行计算，可以多线程大规模并行计算。

Q：GPU裸金属服务器（GPU Elastic Physical Compute，简称GEPC）如何计费？

A：目前GEPC支持包年包月和按量付费（按日月结）的计费模式，用户可选择提前按单月或数月支付GEPC的费用，或者使用后按单日或数日支付GEPC的费用。

Q：GEPC是否可以支持配置升级和降配？

A：GEPC使用固定配置，不支持对实例进行升级配置或者降配。

Q：GEPC是否可以访问云服务器（Kingsoft Cloud Elastic Compute，简称KEC）和裸金属服务器（Elastic Physical Compute，简称EPC）？

A：支持，GEPC默认加入VPC，可以与用户VPC内的KEC和EPC互联互通。

购买常见问题

购买渠道

如果您还未取得购买权限GPU裸金属服务器（GPU Elastic Physical Compute，简称GEPC），请发邮件到ksc_gpu@kingsoft.com申请。

如果您已有购买权限，您可以在金山云控制台购买GEPC。

购买注意事项

在购买金山云GEPC前，请确保您了解金山云GEPC的价格以及所提供的服务，并且根据您的实际需求购买，一旦购买成功，则不能退款。