

第 3 章

TensorFlow 架构与主要功能

3-1 常用的深度学习框架

维基百科^[1]列举了近 20 种的深度学习框架，有许多已经逐渐被淘汰了，以 Python/C++ 语言的框架而言，目前比较流行的只剩以下四种，具体见表 3.1。

表 3.1 Python/C++ 语言框架

框架名称	程序语言	优点	缺点
TensorFlow/Keras	Python、C++、JS、Java、Go	1.Keras 简单、易入门，支持多种程序语言； 2. 效果佳	与 Python 未完全整合，如模型结构不能直接使用 if
PyTorch	Python、C++、Java	1. 与 Python 整合较好，有弹性； 2. 学界采用占比有增加的趋势	执行速度较慢
Caffe	C++	1. 执行速度非常快； 2. 专长于影像应用，NVIDIA 有一改良版	1. 复杂； 2. 无 NLP 模块
Apache MXNet	Python、Scala、Julia	AWS/Azure 云端支持	复杂

TensorFlow、PyTorch 分居占有率的前两名，其他框架均望尘莫及，如图 3.1 所示。因此推荐读者若是使用 Python 语言，熟悉 TensorFlow、PyTorch 就绰绰有余了；若偏好 C/C++，则可以使用 Caffe 框架。




图 3.1 深度学习框架在 Arxiv 网站的论文采用比率
(图片来源: Which deep learning framework is the best? ^[2])

本书的范例以 TensorFlow/Keras 为主，不会涉及其他深度学习框架，以期对 TensorFlow/Keras 进行全面而深入的探讨。

3-2 TensorFlow 架构

梯度下降法是神经网络主要求解的方法，计算过程需要使用大量的张量运算，另外，在反向传导的过程中，要进行偏微分，并需解决多层结构的神经网络问题。因此，大多数的深度学习框架至少都会具备以下功能。

- (1) 张量运算：包括各种向量、矩阵运算。
- (2) 自动微分。
- (3) 神经网络及各种神经层 (Layers)。

学习的路径可以从简单的张量运算开始，再逐渐熟悉高阶的神经层函数，以奠定扎实的基础。

接着再了解 TensorFlow 执行环境 (Runtime)，如图 3.2 所示。它支持 GPU、分布式计算、低阶 C API 等，也支持多种网络协议。




图 3.2 TensorFlow 执行环境 (Runtime)

(图片来源: TensorFlow GitHub^[3])

TensorFlow 执行环境包括以下三个版本。

- (1) TensorFlow: 一般计算机版本。
- (2) TensorFlowjs: 网页版本，适合边缘运算的装置及虚拟机装置 (Docker/Kubernetes)。

- (3) TensorFlow Lite: 轻量版，适合指令周期及内存有限的移动设备和物联网装置。

程序设计堆栈 (Programming Stack) 如图 3.3 所示，在 2.x 版后以 Keras 为主轴，TensorFlow 团队依照 Keras 的规格重新开发，逐步整合其他模块，比独立开发的 Keras 框架功能更加强大，因而 Keras “大神” François Chollet 也宣告 Keras 独立框架不再升级，甚至将 Keras 官网也改为介绍 TensorFlow 的 Keras 模块，而非自家开发的 Keras 独立框架。所以，现在要撰写 Keras 程序，应以 TensorFlow 为主，避免再使用 Keras 独立框架。




图 3.3 TensorFlow 程序设计堆栈 (Programming Stack)

(图片来源: *Explained: Deep Learning in Tensorflow*^[4])

TensorFlow Keras 模块逐步整合其他模块及工具，如果读者之前使用的是 Keras 独立框架，则可以补强以下项目。

- (1) 低阶梯度下降的训练 (GradientTape)。
- (2) 数据集载入 (Dataset and Loader)。
- (3) 回调函数 (Callback)。
- (4) 估计器 (Estimator)。
- (5) 预训模型 (Keras Application)。
- (6) TensorFlow Hub: 进阶的预训模型。
- (7) TensorBoard 可视化工具。
- (8) TensorFlow Serving 部署工具。

我们会在后面的章节陆续探讨各项功能。

除了 Keras 的引进，特别要注意的是，TensorFlow 2.x 版之后，默认模式一修改为 **Eager Execution Mode**，舍弃了 Session 语法，若未调回原先的 Graph Execution Mode，则 1.x 版的程序执行时将会产生错误。由于目前网络上许多范例的程序新旧杂陈，还有很多 1.x 版的程序，读者应特别注意。

3-3 张量运算

TensorFlow 顾名思义就是提供张量的定义、计算与变量值的传递功能。因此，它最底层的功能即支持各项张量的数据类型与其运算函数，基本上都遵循 NumPy 库的设计理念与语法，包括传播 (Broadcasting) 机制的支持。


以下我们直接以实践代替长篇大论，读者请参阅 **03_3_张量运算.ipynb**。

- (1) 显示 TensorFlow 版本。程序代码如下：

```
1 # 载入库
2 import tensorflow as tf
3
4 # 显示版本
5 print(tf.__version__)
```

- (2) 检查 GPU 是否存在。程序代码如下：

```
1 # check cuda available
2 tf.config.list_physical_devices('GPU')
```



执行结果如下，可显示 GPU 简略信息：

```
[PhysicalDevice(name='/physical_device: GPU: 0',device_type='GPU')]
```

(3) 如果要知道 GPU 的详细规格，可安装 PyCuda 模块。请注意在 Windows 环境下，无法以 `pip install pycuda` 安装，可到 https://www.lfd.uci.edu/~gohlke/pythonlibs/?cm_mc_uid=08085305845514542921829&cm_mc_sid_50200000=1456395916#pycuda 下载对应 Python、Cuda Toolkit 版本的二进制文件。

举例来说，Python v3.8 且安装 Cuda Toolkit v10.1，则须下载 `pycuda-2020.1+cuda101-cp38-cp38-win_amd64.whl`，并执行 `pip install pycuda-2020.1+cuda101-cp38-cp38-win_amd64.whl`。接着就可以执行本书所附的范例：`python GpuQuery.py`。

执行结果如下，即可显示 GPU 的详细规格，重要信息排列在前面。

```
装置 0: NVIDIA GeForce GTX 1050 Ti
计算能力: 6.1
GPU 记忆体: 4096 MB
6 个处理器, 各有 128 个 CUDA 核心数, 共 768 个 CUDA 核心数

ASYNC_ENGINE_COUNT: 5
CAN_MAP_HOST_MEMORY: 1
CLOCK_RATE: 1392000
COMPUTE_CAPABILITY_MAJOR: 6
COMPUTE_CAPABILITY_MINOR: 1
COMPUTE_MODE: DEFAULT
CONCURRENT_KERNELS: 1
ECC_ENABLED: 0
GLOBAL_L1_CACHE_SUPPORTED: 1
GLOBAL_MEMORY_BUS_WIDTH: 128
```

(4) 声明常数 (constant)，参数可以是常数、list、NumPy array。程序代码如下：

```
1 # 声明常数(constant)，参数可以是常数、List、Numpy Array
2 x = tf.constant([[1, 2]])
```

(5) 支持四则运算。程序示例如下：

```
1 print(x+10)
2 print(x-10)
3 print(x*2)
4 print(x/2)
```

执行结果如下：

```
tf.Tensor([[11 12]], shape=(1, 2), dtype=int32)
```

```
tf.Tensor([[ -9 -8]], shape=(1, 2), dtype=int32)
```


```
tf.Tensor([[2 4]], shape=(1, 2), dtype=int32)
```

```
tf.Tensor([[0.5 1. ]], shape=(1, 2), dtype=float64)
```

注意：如果要显示数值，须转换为 NumPy array。例如：

```
(x+10).numpy()
```

(6) 四则运算也可以使用 TensorFlow 函数。程序代码如下：



```
1 # 转为负数
2 print(tf.negative(x))
3
4 # 常数、List、NumPy array 均可运算
5 print(tf.add(1, 2))
6 print(tf.add([1, 2], [3, 4]))
7
8 print(tf.square(5))
9 print(tf.reduce_sum([1, 2, 3]))
10
11 # 混用四则运算符号及TensorFlow 函数
12 print(tf.square(2) + tf.square(3))
```

reduce_sum 是沿着特定轴加总，输出会少一维，故 [1, 2, 3] 套用函数运算后等于 6。

(7) TensorFlow 会自动决定在 CPU 或 GPU 运算，可由下列指令侦测。一般而言，常数 (tf.constant) 放在 CPU，其他变量则放在 GPU 上，两者加总时，会将常数搬到 GPU 上再加总，过程不需要人为操作。但请注意，PyTorch 框架稍显麻烦，必须手动将变量搬移至 CPU 或 GPU 运算，不允许一个变量在 CPU，另一个变量在 GPU。侦测程序代码如下：

```
1 x1 = tf.constant([[1, 2, 3]], dtype=float)
2 print("x1 是否在 GPU #0 上: ", x1.device.endswith('GPU:0'))
3
4 # 设定 x 为均匀分配乱数 3x3
5 x2 = tf.random.uniform([3, 3])
6 print("x2 是否在 GPU #0 上: ", x2.device.endswith('GPU:0'))
7
8 x3=x1+x2
9 print("x3 是否在 GPU #0 上: ", x3.device.endswith('GPU:0'))
```

执行结果：

x1 是否在 GPU #0 上: False

x2 是否在 GPU #0 上: True

x3 是否在 GPU #0 上: True

(8) 用户也能够使用 with tf.device("CPU: 0") 或 with tf.device("GPU: 0")，强制指定在 CPU 或 GPU 运算。程序代码如下：

```
1 import time
2
3 # 计算 10 次的时间
4 def time_matmul(x):
5     start = time.time()
6     for loop in range(10):
7         tf.matmul(x, x)
8
9     result = time.time()-start
10    print("{:0.2f}ms".format(1000*result))
11
12 # 强制指定在CPU运算
13 print("On CPU:", end='')
14 with tf.device("CPU:0"):
15     x = tf.random.uniform([1000, 1000])
16     assert x.device.endswith("CPU:0")
17     time_matmul(x)
18
19 # 强制指定在GPU运算
20 if tf.config.list_physical_devices("GPU"):
21     print("On GPU:", end='')
22     with tf.device("GPU:0"):
23         x = tf.random.uniform([1000, 1000])
24         assert x.device.endswith("GPU:0")
25         time_matmul(x)
```

① 第一次执行结果如下，CPU 运算比 GPU 快：

On CPU: 64.00ms

On GPU: 311.49ms

② 多次执行后，GPU 反而比 CPU 运算快了很多：

On CPU: 58.00ms

On GPU: 1.00ms

(9) 稀疏矩阵 (Sparse Matrix) 运算：稀疏矩阵是指矩阵内只有很少数的非零元素，如果依一般的矩阵存储会非常浪费内存，运算也是如此，因为大部分项目为零，不需浪费时间计算，所以，科学家针对稀疏矩阵设计出了特殊的数据存储结构及运算算法，TensorFlow 也支持此类数据类型，如图 3.4 所示。




图 3.4 稀疏矩阵

(10) TensorFlow 稀疏矩阵只需设定有值的位置和数值，并设定维度如下：

```
1 # 稀疏矩阵只需设定有值的位置及数值
2 sparse_tensor = tf.sparse.SparseTensor(indices=[[0, 0], [1, 2]],
3                                         values=[1, 2],
4                                         dense_shape=[3, 4])
5 print(sparse_tensor)
```

执行结果如下：

```
SparseTensor(indices=tf.Tensor(
[[0 0]
 [1 2]], shape=(2, 2), dtype=int64), values=tf.Tensor([1 2], shape=(2,), dtype=int32), dense_shape=tf.Tensor([3 4], shape=(2,), dtype=int64))
```


(11) 转为正常的矩阵格式。程序代码如下：

```
1 # 转为正常的矩阵格式
2 x = tf.sparse.to_dense(sparse_tensor)
3 print(type(x))
4
5 # 2.31 以前版本会出错
6 x.numpy()
```

执行结果如下：

```
<class 'tensorflow.python.framework.ops.EagerTensor'>
array([[1, 0, 0, 0],
       [0, 0, 2, 0],
       [0, 0, 0, 0]])
```

(12) 如果要执行 TensorFlow 1.x 版 Graph Execution Mode 的程序，则需禁用



(Disable)2.x 版的功能，并改变加载框架的命名空间 (Namespace)。程序代码如下：

```
1 if tf.__version__[0] != '1':          # 是否为 TensorFlow 1.x版
2     import tensorflow.compat.v1 as tf # 改变载入框架的命名空间(Namespace)
3     tf.disable_v2_behavior()          # 使 2.x 版功能失效(Disable)
```

TensorFlow 改良反而带来了后向兼容性差的困扰，1.x 版的程序在 2.x 版的默认模式下均无法执行，虽然可以把 2.x 版的默认模式切换回 1.x 版的模式，但是要自行修改的地方较多，而且也缺乏未来性，因此，在这里建议大家以下几点。

① Eager Execution Mode 已是 TensorFlow 的主流，不要再使用 1.x 版的 Session 或 TFLearn 等旧的架构，套用一句电视剧对白，已经回不去了。

② 手上有许多 1.x 版的程序，如果很重要，非用不可，可利用官网移转 (Migration) 指南^[5]进行修改，单一文件比较可行，但若是复杂的框架，可能就要花费大量时间了。

③ 官网也有提供指令，能够一次升级整个目录的所有程序，如下：

tf_upgrade_v2 --intree <1.x 版程序目录> --outtree <输出目录>

详细使用方法可参阅 TensorFlow 官网升级指南^[6]。

(13) 禁用 2.x 版的功能后，测试 1.x 版程序，Graph Execution Mode 程序须使用 tf.Session。程序代码如下：

```
1 # 测试1.x版程序
2 x = tf.constant([[1, 2]])
3 neg_x = tf.negative(x)
4
5 with tf.Session() as sess: # 使用 Session
6     result = sess.run(neg_x)
7     print(result)
```

(14) GPU 内存管理：由于 TensorFlow 对 GPU 内存的垃圾回收 (Garbage Collection) 机制并不完美，因此，常会出现下列 GEMM 错误：

```
InternalError: Blas GEMM launch failed : a.shape=(32, 784), b.shape=(784, 256), m=32, n=256, k=784
[[node sequential/dense/MatMul (defined at <ipython-input-3-9d42ad511782>:5) ]] [Op: __inference_train_function_581]
```

此信息表示 GPU 内存不足，尤其是使用 Jupyter Notebook 时，因为 Jupyter Notebook 是一个网页程序，关掉某一个 Notebook 文件，网站仍然在执行中，所以不代表该文件的资源会被回收，通常要选择 **Kernel > Restart** 选项才会回收资源。另一个方法，就是限制 GPU 的使用配额。以下是 TensorFlow 2.x 版的方式，1.x 版并不适用。程序代码如下：

```
1 # 限制 TensorFlow 只能使用 GPU 2GB 内存
2 gpus = tf.config.experimental.list_physical_devices('GPU')
3 if gpus:
4     try:
5         # 限制 第一个 GPU 只能使用 2GB 内存
6         tf.config.experimental.set_virtual_device_configuration(gpus[0],
7             [tf.config.experimental.VirtualDeviceConfiguration(memory_limit=1024*2)])
8
9         # 显示 GPU 个数
10        logical_gpus = tf.config.experimental.list_logical_devices('GPU')
11        print(len(gpus), "Physical GPUs,", len(logical_gpus), "Logical GPUs")
12    except RuntimeError as e:
13        # 显示错误信息
14        print(e)
```

(15) 用户也可以不使用 GPU。程序代码如下：

```
1 import os
2
3 os.environ["CUDA_VISIBLE_DEVICES"] = "-1"
```

3-4 自动微分

反向传导时，会更新每一层的权重，这时就会用到偏微分运算，如图 3.5 所示。所以，深度学习框架的第二项主要功能就是自动微分。




图 3.5 神经网络权重求解过程

同样地，我们直接以实践代替长篇大论，请参阅 **03_2_自动微分.ipynb**。

(1) 使用 `tf.GradientTape()` 函数可自动微分，再使用 `g.gradient(y, x)` 可取得 y 对 x 作偏微分的梯度。程序代码如下：

```
1 import numpy as np
2 import tensorflow as tf
3
4 x = tf.Variable(3.0)      # 声明 TensorFlow 变量(Variable)
5
6 with tf.GradientTape() as g: # 自动微分
7     y = x * x              # y = x^2
8
9 dy_dx = g.gradient(y, x)  # 取得梯度, f'(x) = 2x, x=3 ==> 6
10
11 print(dy_dx.numpy())      # 转换为 NumPy array 格式
```


执行结果：

$$f(x) = x^2$$

$$f'(x) = 2x$$

$$f'(3) = 2 * 3 = 6。$$

(2) 声明为变量 (`tf.Variable`) 时，该变量会自动参与自动微分，但声明为常数 (`tf.constant`) 时，如欲参与自动微分，则需额外设定 `g.watch()`。程序代码如下：



```
1 import numpy as np
2 import tensorflow as tf
3
4 x = tf.constant(3.0)      # 声明 TensorFlow 常数
5
6 with tf.GradientTape() as g: # 自动微分
7     g.watch(x)             # 设定常数参与自动微分
8     y = x * x              # y = x^2
9
10 dy_dx = g.gradient(y, x)  # 取得梯度, f'(x) = 2x, x=3 ==> 6
11
12 print(dy_dx.numpy())      # 转换为 NumPy array 格式
```

执行结果：与上面 (1) 中相同。

(3) 计算二阶导数：使用 `tf.GradientTape()`、`g.gradient(y, x)` 函数两次，即能取得二阶导数。程序代码如下：

```
1 x = tf.constant(3.0)      # 声明 TensorFlow 常数
2 with tf.GradientTape() as g: # 自动微分
3     g.watch(x)
4     with tf.GradientTape() as gg: # 自动微分
5         gg.watch(x)             # 设定常数参与自动微分
6         y = x * x              # y = x^2
7
8     dy_dx = gg.gradient(y, x)  # 一阶导数
9     d2y_dx2 = g.gradient(dy_dx, x) # 二阶导数
10
11 print(f'一阶导数={dy_dx.numpy()}, 二阶导数={d2y_dx2.numpy()}')
```

执行结果：一阶导数 = 6.0，二阶导数 = 2.0。

$$f(x) = x^2$$

$$f'(x) = 2x$$

$$f''(x) = 2$$

$$f''(3) = 2。$$

(4) 多变量计算导数：各自使用 `g.gradient(y, x)` 函数，可取得每一个变量的梯度。若使用 `g.gradient()` 两次或以上，则 `tf.GradientTape()` 须加参数 `persistent=True`，使 `tf.GradientTape()` 不会被自动回收，用完之后，可使用“`del g`”删除 `GradientTape` 对象。程序代码如下：

```
1 x = tf.Variable(3.0)      # 声明 TensorFlow 常数
2 with tf.GradientTape(persistent=True) as g: # 自动微分
3     y = x * x             # y = x^2
4     z = y * y             # z = y^2
5
6 dz_dx = g.gradient(z, x)  # 4*x^3
7 dy_dx = g.gradient(y, x)  # 2*x
8
9 del g                     # 不用时可删除 GradientTape 对象
10
11 print(f'dy/dx={dy_dx.numpy()}, dz/dx={dz_dx.numpy()}')
```

执行结果： $dy/dx=6$ ， $dz/dx=108$ 。

$$z = f(x) = y^2 = x^4$$

$$f'(x) = 4x^3$$

$$f'(3) = 108。$$

(5) 借此机会我们认识一下 PyTorch 自动微分的语法，它与 TensorFlow 稍有差异。程序代码如下：

```
1 import torch      # 载入库
2
3 x = torch.tensor(3.0, requires_grad=True) # 设定 x 参与自动微分
4 y=x*x             # y = x^2
5
6 y.backward()       # 反向传导
7
8 print(x.grad)      # 取得梯度
```

① requires_grad=True 参数声明 x 参与自动微分。

②调用 y.backward()，要求做反向传导。

③调用 x.grad 取得梯度。

范例. 利用TensorFlow自动微分求解简单线性回归的参数(w、b)。

程序：请参阅 03_3_简单线性回归.ipynb。流程如图 3.6 所示。




图 3.6 程序设计流程

(1) 载入库。程序代码如下：

```
1 # 载入库
2 import numpy as np
3 import tensorflow as tf
```

(2) 定义损失函数 $MSE = \frac{\sum (y - \hat{y})^2}{n}$ 。程序代码如下：

```
1 # 定义损失函数
2 def loss(y, y_pred):
3     return tf.reduce_mean(tf.square(y - y_pred))
```

(3) 定义预测值函数 $y = wx + b$ 。程序代码如下：

```
1 # 定义预测值函数
2 def predict(x):
3     return w * x + b
```

(4) 定义训练函数：在自动微分中需重新计算损失函数值，assign_sub 函数相当于“--”。程序代码如下：

```

1 # 定义训练函数
2 def train(X, y, epochs=40, lr=0.0001):
3     current_loss=0 # 损失函数值
4     for epoch in range(epochs): # 执行训练周期
5         with tf.GradientTape() as t: # 自动微分
6             t.watch(tf.constant(X)) # 创建 TensorFlow 常数参与自动微分
7             current_loss = loss(y, predict(X)) # 计算损失函数值
8
9         dw, db = t.gradient(current_loss, [w, b]) # 取得 w, b 个别的梯度
10
11        # 更新权重: 新权重 = 原权重 - 学习率(learning_rate) * 梯度(gradient)
12        w.assign_sub(lr * dw) # w -= lr * dw
13        b.assign_sub(lr * db) # b -= lr * db
14
15        # 显示每一训练周期的损失函数
16        print(f'Epoch {epoch}: Loss: {current_loss.numpy()}')

```

(5) 产生随机数作为数据集，进行测试。程序代码如下：

```

1 # 产生线性随机数据100批，介于 0~50
2 n = 100
3 X = np.linspace(0, 50, n)
4 y = np.linspace(0, 50, n)
5
6 # 数据里加一点噪声(noise)
7 X += np.random.uniform(-10, 10, n)
8 y += np.random.uniform(-10, 10, n)

```

(6) 执行训练。程序代码如下：

```

1 # w、b 初始值均设为 0
2 w = tf.Variable(0.0)
3 b = tf.Variable(0.0)
4
5 # 执行训练
6 train(X, y)
7
8 # w、b 的最佳解
9 print(f'w={w.numpy()}, b={b.numpy()}')

```

① 执行结果： $w=0.9464$ ， $b=0.0326$ 。

② 损失函数值随着训练周期越来越小，如下：

```

Epoch 0: Loss: 890.1063232421875
Epoch 1: Loss: 607.071533203125
Epoch 2: Loss: 419.7763671875
Epoch 3: Loss: 295.8358459472656
Epoch 4: Loss: 213.81948852539062
Epoch 5: Loss: 159.5459747314453
Epoch 6: Loss: 123.63106536865234
Epoch 7: Loss: 99.86465454101562
Epoch 8: Loss: 84.1374282836914
Epoch 9: Loss: 73.7300033569336
Epoch 10: Loss: 66.84292602539062
Epoch 11: Loss: 62.28538513183594
Epoch 12: Loss: 59.269386291503906
Epoch 13: Loss: 57.27349090576172
Epoch 14: Loss: 55.95263671875
Epoch 15: Loss: 55.078487396240234
Epoch 16: Loss: 54.49993133544922
Epoch 17: Loss: 54.116981506347656
Epoch 18: Loss: 53.86347579956055
Epoch 19: Loss: 53.69562911987305
Epoch 20: Loss: 53.584468841552734

```

(7) 显示结果：回归线确实居于样本点中线。程序代码如下：

```
1 import matplotlib.pyplot as plt
2
3 plt.scatter(X, y, label='data')
4 plt.plot(X, predict(X), 'r-', label='predicted')
5 plt.legend()
```

执行结果：如图 3.7 所示。




图 3.7 自动微分求解简单线性回归执行结果

有了 TensorFlow 自动微分的功能，正向与反向传导变得非常简单，只要熟悉了运作的架构，后续复杂的模型就可以运用自如。

3-5 神经网络层

上一节运用自动微分实现了一条简单线性回归线的求解，然而神经网络是多条回归线的组合，并且每一条回归线可能再乘上非线性的 Activation Function，假如使用自动微分函数逐一定义每条公式，层层串连，程序可能要很多个循环才能完成。所以为了简化程序开发的复杂度，TensorFlow/Keras 直接建构了各式各样的神经层函数，可以使用神经层组合神经网络的结构，用户只需要专注算法的设计即可，轻松不少。

如图 3.8 所示，神经网络是多个神经层组合而成的，包括输入层 (Input Layer)、隐藏层 (Hidden Layer) 及输出层 (Output Layer)，其中隐藏层可以有任意多层。一般而言，隐藏层大于或等于两层，即称为深度学习。





图 3.8 神经网络示意图



TensorFlow/Keras 提供了数十种神经层，分成以下类别，用户可参阅 Keras 官网说明 (<https://keras.io/api/layers/>)。

(1) 核心类别 (Core Layer): 包括完全连接层 (Full Connected Layer)、激励神经层 (Activation layer)、嵌入层 (Embedding layer) 等。

(2) 卷积层 (Convolutional Layer)。

(3) 池化层 (Pooling Layer)。

(4) 循环层 (Recurrent Layer)。

(5) 前置处理层 (Preprocessing layer): 提供 One-Hot Encoding、影像前置处理、数据增补 (Data Augmentation) 等。

我们先来看看两个最简单的完全连接层范例。

范例1. 使用完全连接层估算简单线性回归的参数(w 、 b)。

程序：请参阅 03_4_ 简单的完全连接层 .ipynb。

(1) 产生随机数据，与上一节范例相同。程序代码如下：

```
1 # 载入库
2 import numpy as np
3 import tensorflow as tf
4
5 # 产生线性随机数据100批，介于 0-50
6 n = 100
7 X = np.linspace(0, 50, n)
8 y = np.linspace(0, 50, n)
9
10 # 数据中加一点噪声
11 X += np.random.uniform(-10, 10, n)
12 y += np.random.uniform(-10, 10, n)
```

(2) 建立模型：神经网络仅使用一个完全连接层，而且输入只有一个神经元，即 X ，输出也只有一个神经元，即 y 。Dense 本身有一个参数 `use_bias`，即是否有偏差项，默认值为 `True`，除了一个神经元输出外，还会有一个偏差项。以上设定其实就等于 $y=wx+b$ 。为聚焦概念的说明，暂时不解释其他参数，在后面章节会有详尽说明。程序代码如下：

```
1 # 定义完全连接层(Dense)
2 # units : 输出神经元个数, input_shape : 输入神经元个数
3 layer1 = tf.keras.layers.Dense(units=1, input_shape=[1])
4
5 # 神经网络包含一个完全连接层
6 model = tf.keras.Sequential([layer1])
```

(3) 定义模型的损失函数及优化器。程序代码如下：

```
1 # 定义模型的损失函数为 MSE，优化器为 Adam
2 model.compile(loss='mean_squared_error',
3               optimizer=tf.keras.optimizers.Adam())
```

(4) 模型训练：只需一个指令 `model.fit(X, y)` 即可，训练过程的损失函数变化都会存在 `history` 变量中。程序代码如下：

```
1 history = model.fit(X, y, epochs=500, verbose=False)
```

(5) 训练过程绘图。程序代码如下：

```

1 import matplotlib.pyplot as plt
2 plt.rcParams['font.sans-serif'] = ['Microsoft JhengHei']
3 plt.rcParams['axes.unicode_minus'] = False
4
5 plt.xlabel('训练周期', fontsize=20)
6 plt.ylabel("损失函数", fontsize=20)
7 plt.plot(history.history['loss'])

```

执行结果：损失函数值随着训练周期越来越小，如图 3.9 所示。




图 3.9 训练过程执行结果

(6) 取得模型参数 w 为第一层的第一个参数， b 为输出层的第一个参数。程序代码如下：

```

1 w = layer1.get_weights()[0][0][0]
2 b = layer1.get_weights()[1][0]
3
4 print(f"w: {w:.4f} , b: {b:.4f}")

```

执行结果：w: 0.8798, b: 3.5052，因输入数据为随机随机数。

(7) 绘图显示回归线。程序代码如下：

```

1 import matplotlib.pyplot as plt
2
3 plt.scatter(X, y, label='data')
4 plt.plot(X, X * w + b, 'r-', label='predicted')
5 plt.legend()

```

执行结果：如图 3.10 所示。





图 3.10 绘图显示回归线执行结果

与自动微分比较，这种方法程序更简单，只要设定模型结构、损失函数、优化器后，



呼叫训练 (fit) 函数即可。

下面我们再看一个有趣的例子，利用神经网络自动求出华氏与摄氏温度的换算公式。

范例2. 使用完全连接层推算华氏与摄氏温度的换算公式。

$$\text{华氏 (F)} = \text{摄氏 (C)} * (9/5) + 32$$

(1) 利用换算公式，随机产生 151 个数据。程序代码如下：

```
1 # 载入库
2 import numpy as np
3 import tensorflow as tf
4
5 # 随机产生151个数据
6 n = 151
7 C = np.linspace(-50, 100, n)
8 F = C * (9/5) + 32
9
10 for i, x in enumerate(C):
11     print(f"华氏(F) : {F[i]:.2f} , 摄氏(C) : {x:.0f}")
```

(2) 建立模型：神经网络只有一个完全连接层，而且输入只有一个神经元，即摄氏温度，输出只有一个神经元，即华氏温度。程序代码如下：

```
1 # 定义完全连接层(Dense)
2 # units : 输出神经元个数, input_shape : 输入神经元个数
3 layer1 = tf.keras.layers.Dense(units=1, input_shape=[1])
4
5 # 神经网络包含一层完全连接层
6 model = tf.keras.Sequential([layer1])
7
8 # 定义模型的损失函数为 MSE，优化器为 Adam
9 model.compile(loss='mean_squared_error',
10               optimizer=tf.keras.optimizers.Adam(0.1))
```

(3) 模型训练。程序代码如下：

```
1 history = model.fit(C, F, epochs=500, verbose=False)
```

(4) 训练过程绘图。程序代码如下：

```
1 import matplotlib.pyplot as plt
2 plt.rcParams['font.sans-serif'] = ['Microsoft JhengHei']
3 plt.rcParams['axes.unicode_minus'] = False
4
5 plt.xlabel('训练周期', fontsize=20)
6 plt.ylabel("损失函数", fontsize=20)
7 plt.plot(history.history['loss'])
```

执行结果：如图 3.11 所示。由此可见：损失函数值随着训练周期越来越小。




图 3.11 训练过程执行结果

(5) 测试：输入摄氏 100 度及 0 度转换为华氏温度，答案完全正确。程序代码如下：

```
1 y_pred = model.predict([100.0])[0][0]
2 print(f"华氏(F) : {y_pred:.2f} , 摄氏(C) : 100")
3
4 y_pred = model.predict([0.0])[0][0]
5 print(f"华氏(F) : {y_pred:.2f} , 摄氏(C) : 0")
```

执行结果：

华氏 (F): 212.00, 摄氏 (C): 100

华氏 (F): 32.00, 摄氏 (C): 0

(6) 取得模型参数 w 、 b 。

```
1 w = layer1.get_weights()[0][0][0]
2 b = layer1.get_weights()[1][0]
3
4 print(f"w: {w:.4f} , b: {b:.4f}")
```

① 执行结果：w: 1.8000, b: 31.9999，近似于华氏与摄氏温度的换算公式。

② 其实换算公式也是一条回归线。

读到这里，读者应该会好奇如何使用更多的神经元和神经层，甚至更复杂的神经网络结构，下一章我们将正式迈入深度学习的殿堂，学习如何用 TensorFlow 解决各种实际的案例，并且详细剖析各个函数的用法及参数说明。