



链滴


pytorch 入门笔记 -03- 神经网络

作者: [zyk](#)

原文链接: <https://ld246.com/article/1639540087993>

来源网站: 链滴

许可协议: [署名-相同方式共享 4.0 国际 \(CC BY-SA 4.0\)](#)




前言

本节主要内容是如何使用 `torch.nn` 包来构建神经网络。

上一讲已经讲过了 `autograd`，`nn` 包依赖 `autograd` 包来定义模型并求导。

一个 `nn.Module` 包含各个层和一个 `forward(input)` 方法，该方法返回 `output`。

例如：



它是一个简单的前馈神经网络，它接受一个输入，然后一层接着一层地传递，最后输出计算的结果。

神经网络的典型训练过程如下：

1. 定义包含一些可学习的参数(或者叫权重)神经网络模型；
2. 在数据集上迭代；
3. 通过神经网络处理输入；
4. 计算损失(输出结果和正确值的差值大小)；
5. 将梯度反向传播回网络的参数；
6. 更新网络的参数，主要使用如下简单的更新原则： $\text{weight} = \text{weight} - \text{learning_rate} * \text{gradient}$

定义网络

开始定义一个网络：

```
import torch
import torch.nn as nn
import torch.nn.functional as F

class Net(nn.Module):
    def __init__(self):
        super(Net, self).__init__()
        # 输入图片通道数为 1，输出通道数为 6，卷积核大小为 (5, 5)
        self.conv1 = nn.Conv2d(1, 6, 5)
        # 输入图片通道数为 6，输出通道数为 16，卷积核大小为 (5, 5)
        self.conv2 = nn.Conv2d(6, 16, 5)
        self.fc1 = nn.Linear(16 * 5 * 5, 120)
        self.fc2 = nn.Linear(120, 84)
        self.fc3 = nn.Linear(84, 10)

    def forward(self, x):
        # 最大池化层，池化层窗口大小为 (2, 2)
        x = F.max_pool2d(F.relu(self.conv1(x)), 2)
        x = F.max_pool2d(F.relu(self.conv2(x)), 2)
        # 改变数据的维度
        x = x.view(-1, self.num_flat_features(x))
        x = F.relu(self.fc1(x))
        x = F.relu(self.fc2(x))
        x = self.fc3(x)
        return x

    def num_flat_features(self, x):
        size = x.size()[1:]
        num_features = 1
        for s in size:
            num_features *= s
        return num_features

net = Net()
print(net)

Net(
  (conv1): Conv2d(1, 6, kernel_size=(5, 5), stride=(1, 1))
  (conv2): Conv2d(6, 16, kernel_size=(5, 5), stride=(1, 1))
  (fc1): Linear(in_features=400, out_features=120, bias=True)
  (fc2): Linear(in_features=120, out_features=84, bias=True)
  (fc3): Linear(in_features=84, out_features=10, bias=True)
)
```

在模型中必须要定义 **forward** 函数，**backward** 函数（用来计算梯度）会被 **autograd** 自动创建。

可以在 **forward** 函数中使用任何针对 **Tensor** 的操作。

net.parameters() 返回可被学习的参数（权重）列表和值

```
params = list(net.parameters())
print(len(params))
print(params[0].size()) # conv1 的权重
```

```
10
torch.Size([6, 1, 5, 5])
```

测试随机输入 32×32 。

注：这个网络（LeNet）期望的输入大小是 32×32 ，如果使用 MNIST 数据集来训练这个网络，请把片大小重新调整到 32×32 。

```
input = torch.randn(1, 1, 32, 32)
out = net(input)
print(out)
```

```
tensor([[ 0.0172,  0.1005, -0.1940, -0.0691, -0.0525, -0.0239, -0.0056, -0.0597,
  0.0184, -0.0300]], grad_fn= <AddmmBackward0>)
```

将所有参数的梯度缓存清零，然后进行随机梯度的反向传播：

```
net.zero_grad()
out.backward(torch.randn(1, 10))
```

note

`torch.nn` 只支持小批量输入。整个 `torch.nn` 包都只支持小批量样本，而不支持单个样本。

例如，`nn.Conv2d` 接受一个4维的张量，每一维分别是 `sSamples * nChannels * Height * Width`（本数 * 通道数 * 高 * 宽）。如果你有单个样本，只需使用 `input.unsqueeze(0)` 来添加其它的维数

在继续之前，我们回顾一下到目前为止用到的类。

回顾：

- `torch.Tensor`：一个用过自动调用 `backward()` 实现支持自动梯度计算的多维数组，并且保存关于个向量的梯度 w.r.t.
- `nn.Module`：神经网络模块。封装参数、移动到 GPU 上运行、导出、加载等。
- `nn.Parameter`：一种变量，当把它赋值给一个 `Module` 时，被自动地注册为一个参数。
- `autograd.Function`：实现一个自动求导操作的前向和反向定义，每个变量操作至少创建一个函数点，每一个 `Tensor` 的操作都会创建一个接到创建 `Tensor` 和编码其历史的函数的 `Function` 节点。

重点如下：

- 定义一个网络
- 处理输入，调用 `backward`

还剩：

- 计算损失
- 更新网络权重

损失函数

一个损失函数接受一对 (output, target) 作为输入，计算一个值来估计网络的输出和目标值相差多少。

译者注：output 为网络的输出，target 为实际值

nn 包中有很多不同的损失函数。

`nn.MSELoss` 是一个比较简单的损失函数，它计算输出和目标间的均方误差，

例如：

```
output = net(input)
target = torch.rand(10)
target = target.view(1, -1)
criterion = nn.MSELoss()
```

```
loss = criterion(output, target)
print(loss)
```

```
tensor(0.4526, grad_fn=<MseLossBackward0>)
```

现在，如果在反向过程中跟随 `loss`，使用它的 `.grad_fn` 属性，将看到如下所示的计算图。

```
input -> conv2d -> relu -> maxpool2d -> conv2d -> relu -> maxpool2d
-> view -> linear -> relu -> linear -> relu -> linear
-> MSELoss
-> loss
```

所以，当我们调用 `loss.backward()` 时，整张计算图都会

根据 `loss` 进行微分，而且图中所有设置为 `requires_grad=True` 的张量

将会拥有一个随着梯度累积的 `.grad` 张量。

为了说明，让我们向后退几步：

```
print(loss.grad_fn) # MSELoss
print(loss.grad_fn.next_functions[0][0]) # Linear
print(loss.grad_fn.next_functions[0][0].next_functions[0][0]) # ReLU
```

```
<MseLossBackward0 object at 0x7f417c5f3d30>
<AddmmBackward0 object at 0x7f417c5f34f0>
<AccumulateGrad object at 0x7f417c5f3d30>
```

反向传播

调用 `loss.backward()` 获得反向传播的误差。

但是在调用前需要清除已存在的梯度，否则梯度将被累加到已存在的梯度。

现在，我们将调用 `loss.backward()`，并查看 `conv1` 层的偏差 (`bias`) 项在反向传播前后的梯度。

```
net.zero_grad()
```

```
print('conv1.bias.grad before backward')
print(net.conv1.bias.grad)

loss.backward()

print('conv1.bais.grad after backward')
print(net.conv1.bias.grad)

conv1.bias.grad before backward
tensor([0., 0., 0., 0., 0., 0.])
conv1.bais.grad after backward
tensor([ 0.0040, 0.0098, 0.0213, -0.0162, 0.0075, -0.0018])
```

如何使用损失函数

稍后阅读：

nn 包，包含了各种用来构成深度神经网络构建块的模块和损失函数，完整的文档请查看 [here](#)。

剩下的最后一件事：

- 新网络的权重

更新权重

在实践中最简单的权重更新规则是随机梯度下降（SGD）：

$weight = weight - learning_rate * gradient$

我们可以使用简单的 Python 代码实现这个规则：

```
learning_rate = 0.01
for f in net.parameters():
    f.data.sub_(f.grad.data * learning_rate)
```

但是当使用神经网络是想要使用各种不同的更新规则时，比如 **SGD**、**Nesterov-SGD**、**Adam**、**RMS ROP** 等，**PyTorch** 中构建了一个包 **torch.optim** 实现了所有的这些规则。

使用它们非常简单：

```
import torch.optim as optim

# 创建优化器
optimizer = optim.SGD(net.parameters(), lr=0.01)

# 迭代训练
optimizer.zero_grad() # 梯度清零
output = net(input)
loss = criterion(output, target) # 计算损失
loss.backward() # 反向传播
optimizer.step() # 更新参数
```

注意

观察如何使用 **optimizer.zero_grad()** 手动将梯度缓冲区设置为零。

这是因为梯度是按 **Backprop** 部分中的说明累积的。