

# 大作业-Dogs vs. Cats

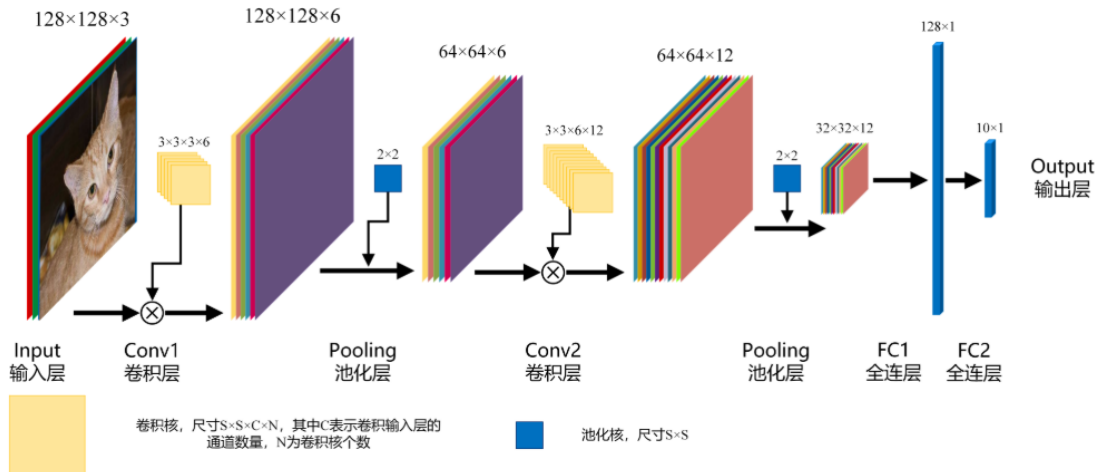
## 一、 选题原因

我对老师发的课程中的 CNN 网络的图像识别比较有兴趣，于是我在 github 上找到了猫狗大战 (Dogs vs. Cats) 的例子，猫狗大战是 Kaggle 大数据竞赛某一年的一道赛题，利用给定的数据集，用算法实现猫和狗的识别。我认为这个题目很有意思，而且比较简单。正好我学过一点 pytorch，所以我选择用 pytorch 实现猫狗图像识别。

## 二、 背景知识

### 1. CNN


CNN(Convolutional Neural Networks)是一种神经网络，基本运算方式为卷积，因此叫卷积神经网络。一般由输入层、卷积层、池化层、全连接层组成，每层计算后有时还要用到激活函数。



图表 1 CNN


**输入层 (Input):** 指输入的图像数据，如果 input 为  $H \times W \times 3$ ，则代表尺寸为 (H, W) 的彩色图像。矩阵每个点数值范围为  $[0, 255]$ ，3 表示 RGB 三个通道。

**卷积层 (Conv):** 由卷积核对输入层图像进行卷积操作以提取图像特征。图像的卷积就是让卷积核 (卷积模板) 在原图像上依次滑动，在重叠的区域把对应位置的像素值和卷积模板值相乘，累加求和得到新图像 (卷积结果) 中的一个像素值，卷积核每滑动一次获得一个新值，当完成原图像的全部遍历，便完成原图像的一次卷积。下图示意了一次卷积计算过程。



图表 2 卷积流程

**池化层 (pooling)**: 降低图像分辨率, 减少区域内图像的特征数。减少计算量, 防止过拟合。用的方法有 Max pooling 和 average pooling, 本次代码采用 Max pooling。



图表 3 池化

**全连层 (Fully connected)**: 将卷积图像映射至一个  $n$  维向量, 通过设置多个全连接关系, 起到从特征到分类的作用。每个维度的值表示 CNN 结构输入图像属于该维目标的可能性。

**激活函数 (Activation Function)**: 激活函数主要引入非线性特性, 在卷积过程中, 所有的运算都是线性运算和线性叠加, 没有激活函数, 网络就无法拟合非线性特性的输入输出关系。卷积核的每一次卷积在累加模板内各个位置的乘积后, 将累加值输入激活函数, 然后将输出值作为卷积结果。常用的激活函数有 Sigmoid, Tanh, ReLU 等


## 2. Pytorch

Pytorch 由 Facebook 开源的神经网络框架, 是当前难得的简洁优雅且高效快速的框架。比较简单易于上手, 当前最流行的 TensorFlow 是比较不友好的, 与 Python 等语言差距很大, 并且在调试的时候比较复杂。所以我作为初学者选择了 pytorch。

## 三、思路方法

### 1. 数据集

- 1) 下载地址: <https://www.kaggle.com/c/dogs-vs-cats-redux-kernels-edition/data>
- 2) 训练集: 训练集由标记为 cat 和 dog 的猫狗图片组成, 各 12500 张, 总共 25000 张。图片为 24 位 jpg 格式, 即 RGB 三通道图像, 图片尺寸不一。
- 3) 测试集: 测试集由 12500 张的 cat 或 dog 图片组成, 未标记, 图片也为 24 位 jpg 格式, RGB 三通道图像, 图像尺寸不一。



图表 4 数据集图片

### 2. 准备数据

将数据集中的数据整理成程序代码可识别读取的形式。把训练集中所有的数据整理成 [输入, 给定输出] 的形式, 输入为一张张猫狗图片 (input), 给定输出是对应的猫或者狗信息 (label)。

### 3. 搭建网络:

利用 PyTorch 提供的 API 搭建设计的网络。建立 CNN 中的各个计算层, 包括卷积层, 池化层, 全连层和激活函数等, 还有载入前向计算。

### 4. 训练网络

把准备好的数据送入搭建的网络中进行训练，获得网络各节点权值参数

## 5. 测试网络

导入训练好的网络中参数，然后输入图像完成猫狗分类任务，评估网络的输出结果。

## 四、 代码解析（具体每行代码用处代码截图的注释中）

### 1. 准备数据

建立一个数据类，将每张图片的文件名进行分割，“cat”，“dog”分别映射不同标签，将图片与标签一一对应。本代码采用了 one-hot 编码方式，猫的编码为“[1,0]”，狗的编码为“[0, 1]”，网络输出两个值，分别为属于猫和狗的概率（两者相加恒等于 1）。因为训练阶段采用交叉熵作为损失函数 Loss，输入的 label 参数是 1 维 Tensor，其值表示样本 label 中出现 1 的索引。如猫的编码为“[1,0]”，则 1 所在索引为 0，所以制作的标签为一维。将不同尺寸的图片 resize 成统一大小将图片与标签进行一一对应。训练集将 image 和 label 转为 pytorch 的形式，对于测试集我们只读取 image。

```
class DogsVSCatsDataset(data.Dataset): # 新建一个数据集类，并且需要继承PyTorch中的data.Dataset父类
    def __init__(self, mode, dir): # 默认构造函数，传入数据集类别（训练或测试），以及数据集路径
        self.mode = mode
        self.list_img = [] # 新建一个image list，用于存放图片路径，注意是图片路径
        self.list_label = [] # 新建一个label list，用于存放图片对应猫或狗的标签，其中数值0表示猫，1表示狗
        self.data_size = 0 # 记录数据集大小
        self.transform = dataTransform # 转换关系
        if self.mode == 'train': # 训练集模式下，需要提取图片的路径和标签
            dir = dir + '/train/' # 训练集路径在"dir"/train/
            for file in os.listdir(dir): # 遍历dir文件夹
                self.list_img.append(dir + file) # 将图片路径和文件名添加至image list
                self.data_size += 1 # 数据集增1
                name = file.split(sep='.') # 分割文件名，"cat.0.jpg"将分割成"cat",".", "jpg"3个元素
                # label采用one-hot编码，"1,0"表示猫，"0,1"表示狗，任何情况只有一个位置为"1"，在采用CrossEntropyLoss()计算Loss情况下，label只需要输入"1"的索引
                if name[0] == 'cat':
                    self.list_label.append(0) # 图片为猫，label为0
                else:
                    self.list_label.append(1) # 图片为狗，label为1，注意：list_img和list_label中的内容是一一对应的
            elif self.mode == 'test': # 测试集模式下，只需要提取图片路径就行
                dir = dir + '/test/' # 测试集路径为"dir"/test/
                for file in os.listdir(dir): # 添加图片路径至image list
                    self.list_img.append(dir + file) # 添加图片路径至image list
                    self.data_size += 1
                    self.list_label.append(2) # 添加2作为label，实际未用到，也无意义
            else:
                print('Undefined Dataset!')

    def __getitem__(self, item): # 重载data.Dataset父类方法，获取数据集中数据内容
        if self.mode == 'train': # 训练集模式下需要读取数据集的image和label
            img = Image.open(self.list_img[item]) # 打开图片
            label = self.list_label[item] # 获取image对应的label
            return self.transform(img), torch.LongTensor([label]) # 将image和label转换成PyTorch形式并返回
        elif self.mode == 'test': # 测试集只需读取image
            img = Image.open(self.list_img[item])
            return self.transform(img) # 只返回image
        else:
            print('None')
```

### 2. 搭建网络

网络继承 PyTorch 的 nn.Module 父类，在构造函数中新建 CNN 中的计算层，包括卷积层，池化层，全连层和激活函数等。还要重载父类的网络运算中的前向计算 forward() 方法。该网络包含两个卷积层、三个全连接层，经过两次池化。第一次卷积结果经过 ReLU 激活函数处理，并且池化大小  $2 \times 2$ ，方式 Max pooling，第二次卷积经过 ReLU 激活函数处理，池化大小  $2 \times 2$ ，方式 Max pooling。然后将结果输入全连层，因为全连接层输入需要一维张量，因此需要对输入的格式数据排列成一维形式，再经过三次全连接层和两次 ReLU 激活。具体网络搭建如下：

- 1) Input: 图像尺寸为  $200 \times 200$  像素，由于训练集和测试集中的图片大小尺寸多样，因此在送入网络前，须将图片调整至  $200 \times 200$  像素
- 2) conv1: 卷积核的规模为  $[3 \times 3 \times 3 \times 16]$ ，size 大小  $3 \times 3$ ，深度 3，数量 16  
第一次卷积结果：16 个卷积图像 (feature map)， $200 \times 200$  像素

- 3) Pooling: 第一次池化, size 大小  $2 \times 2$ , Max pooling  
第一次池化结果: 图像缩小为  $100 \times 100$  像素
- 4) conv2: 卷积核的规模为  $[3 \times 3 \times 16 \times 16]$ , size 大小  $3 \times 3$ , 深度 16, 数量 16  
第二次卷积结果: 16 个卷积图像 (feature map),  $100 \times 100$  像素
- 5) Pooling: 第二次池化, size 大小  $2 \times 2$ , Max pooling  
第二次池化结果: 图像缩小为  $50 \times 50$  像素
- 6) FC1: 第一次全连接, 输入节点数为  $50 \times 50 \times 16 = 40000$ , 输出节点数为 128, 输出数据为  $[128 \times 1]$
- 7) FC2: 第二次全连接, 输入节点数为 128, 输出节点数为 64, 输出数据为  $[64 \times 1]$
- 8) FC3: 第三次全连接, 输入节点数为 64, 输出节点数为 2, 即两个数值, 分别表示猫和狗的概率 (后面要通过 softmax 方法进行转换将数值转换为概率形式)。

```
class Net(nn.Module):
    def __init__(self):
        super(Net, self).__init__()
        self.conv1 = torch.nn.Conv2d(3, 16, 3, padding=1)
        self.conv2 = torch.nn.Conv2d(16, 16, 3, padding=1)

        self.fc1 = nn.Linear(50*50*16, 128)
        self.fc2 = nn.Linear(128, 64)
        self.fc3 = nn.Linear(64, 2)

    def forward(self, x):
        x = self.conv1(x)
        x = F.relu(x)
        x = F.max_pool2d(x, 2)

        x = self.conv2(x)
        x = F.relu(x)
        x = F.max_pool2d(x, 2)

        x = x.view(x.size()[0], -1)
        x = F.relu(self.fc1(x))
        x = F.relu(self.fc2(x))
        y = self.fc3(x)

        return y
```

### 3. 训练网络

Dogs vs. Cats 训练集中共有 25000 个图片, epoch 为 10, 即全部数据做了 10 次训练。batch size 为 16。那么网络参数总共调整的参数次数即 iteration 为  $25000/16 = 1,562$  次。DataLoader() 的作用是对定义好的数据集类做一次封装, 可以完成打乱数据集分布、设定多线程数据读取、一次获得 batch size 大小的数据。原来代码采用 GPU 进行运算, 如果没有 GPU 做计算的话, 可以去掉代码中的 .cuda()。

采用训练模式, 选定好 adm 优化器和交叉熵计算 loss, 开始训练每次住区 16 组数据, 并放置在 Variable 中, 然后计算网络输出值并于 label 计算误差 loss, 并将误差反向传播, 再用优化器对节点各个参数进行优化, 最后清楚优化器中梯度以便下次运算。将全部数据集训练十次, 最终将训练好的网络保存成 pkl 文件。

概念讲解:

Epoch: 表示整个数据集进了多少次重复训练。训练时, 将所有数据迭代训练一次是不够的, 需要反复多次才能拟合收敛。

batch size: 一次训练所选取的样本数。为了在内存效率和内存容量之间寻求最佳平衡, batch size 应该精心设置, 从而最优化网络模型的性能及速度。

iteration: 一个 epoch 中网络参数调整 (迭代) 的次数。

```

def train():
    datafile = DVCD('train', dataset_dir) # 实例化一个数据集
    dataloader = DataLoader(datafile, batch_size=batch_size, shuffle=True, num_workers=workers, drop_last=True) # 用PyTorch的DataLoader类封装
    print('Dataset loaded! length of train set is {}'.format(len(datafile)))
    model = Net() # 实例化一个网络
    # model = model.cuda() # 网络送入GPU, 即采用GPU计算, 如果没有GPU加速, 可以去掉".cuda()"
    model = nn.DataParallel(model)
    model.train() # 网络设定为训练模式, 有两种模式可选, .train()和.eval(), 训练模式和评估模式, 区别就是训练模式采用了dropout策略,
    optimizer = torch.optim.Adam(model.parameters(), lr=lr) # 实例化一个优化器, 即调整网络参数, 优化方式为adam方法
    criterion = torch.nn.CrossEntropyLoss() # 定义loss计算方法, cross_entropy, 交叉熵, 可以理解为两者数值越接近其值越小
    cnt = 0 # 训练图片数量
    for epoch in range(nepoch):
        # 读取数据集中数据进行训练, 因为dataloader的batch_size设置为16, 所以每次读取的数据量为16, 即img包含了16个图像, label有16个
        for img, label in dataloader: # 循环读取封装后的数据集, 其实就是调用了数据集中的getitem()方法,
            # img, label = Variable(img).cuda(), Variable(label)#.cuda()
            img, label = Variable(img), Variable(label) # 将数据放置在PyTorch的Variable节点中, 并送入GPU中作为网络计算起点
            out = model(img) # 计算网络输出值, 就是输入网络一个图像数据, 输出猫和狗的概率, 调用了网络
            loss = criterion(out, label.squeeze()) # 计算损失, 也就是网络输出值和实际label的差值, 显然差值越小说明网络拟合效果越好, 此外需要注意的是
            loss.backward() # 误差反向传播, 采用求导的方式, 计算网络中每个节点参数的梯度, 显然梯度越大说明参数设置不合理, 需要
            optimizer.step() # 优化采用设定的优化方法对网络中的各个参数进行调整
            optimizer.zero_grad() # 清除优化器中的梯度以便下一次计算, 因为优化器默认会保留, 不清除的话, 每次计算梯度都累加
            cnt += 1

        print('Epoch:{0},Frame:{1}, train_loss {2}'.format(epoch, cnt*batch_size, loss/batch_size)) # 打印一个batch_size的训练结果

    torch.save(model.state_dict(), '{0}/model.pth'.format(model_cp)) # 训练所有数据后, 保存网络的参数

```

#### 4. 测试网络

将训练好的网络参数导入新定义的网络中, 然后输入图像完成猫狗分类任务。并验证结果的准确性

```

def test():
    model = Net() # 实例化一个网络
    model = nn.DataParallel(model)
    model.load_state_dict(torch.load(model_file)) # 加载训练好的模型参数
    model.eval() # 设定为评估模式, 即计算过程中不要dropout
    # get data
    files = random.sample(os.listdir(dataset_dir), N) # 随机获取N个测试图像
    imgs = [] # img
    imgs_data = [] # img data
    for file in files:
        img = Image.open(dataset_dir + file) # 打开图像
        img_data = getdata.dataTransform(img) # 转换成torch tensor数据

        imgs.append(img) # 图像list
        imgs_data.append(img_data) # tensor list
    imgs_data = torch.stack(imgs_data) # tensor list合成一个4D tensor
    # calculation
    out = model(imgs_data) # 对每个图像进行网络计算
    out = F.softmax(out, dim=1) # 输出概率化
    out = out.data.cpu().numpy() # 转成numpy数据
    # print results 显示结果
    for idx in range(N):
        plt.figure()
        if out[idx, 0] > out[idx, 1]:
            plt.suptitle('cat:{:.1%},dog:{:.1%}'.format(out[idx, 0], out[idx, 1]))
        else:
            plt.suptitle('dog:{:.1%},cat:{:.1%}'.format(out[idx, 1], out[idx, 0]))
        plt.imshow(imgs[idx])
    plt.show()

```

## 五、 结果展示

### 1. 训练结果 (loss)

看一看出来损失值 loss 下降了很多。

```

Epoch:0,Frame:16, train_loss 0.04381302371621132
Epoch:0,Frame:32, train_loss 0.043063025921583176
Epoch:0,Frame:48, train_loss 0.04457520693540573
Epoch:0,Frame:64, train_loss 0.04382330924272537
Epoch:0,Frame:80, train_loss 0.042920563369989395

```

```
Epoch:9,Frame:249856, train_loss 0.02563639171421528
Epoch:9,Frame:249872, train_loss 0.008000656962394714
Epoch:9,Frame:249888, train_loss 0.013245390728116035
Epoch:9,Frame:249904, train_loss 0.013621248304843903
Epoch:9,Frame:249920, train_loss 0.012428155168890953

Process finished with exit code 0
```

## 2. 测试结果

可以看出测试结果准确性很高，训练的网络效果很好。

