

Cowry

Live your life with passion!

BP神经网络(反向传播)详细推导

📅 2018-05-21 | 📁 机器学习 | 👁 56

📄 849 | 🔄 3

这篇文章主要讨论神经网络的反向传播的细节，“误差”是如何反向传播的，我们又是如何利用梯度来优化参数的。


在学吴恩达机器学习视频的神经网络那节时，给出了许多公式，比如计算每层的误差，每层参数的梯度，但并没有给出推导过程，可能也是考虑入门级，大多数人并不要知道其中含义就可以运用算法了。接下来我会给出详细的推导过程，帮助大家理解。

注意接下来所讲是未正则化的神经网络。

1 计算公式

1.1 正向传递

假设现在有一个三层的神经网络，如图：



参数含义:

- $\theta^{(i)}$ 第 i 层的参数矩阵
- $z^{(l)}$ 第 l 层的输入
- $a^{(l)}$ 第 l 层的输出

传递过程:

- $a^{(1)} = x$
- $z^{(2)} = \theta^{(1)} a^{(1)}$
- $a^{(2)} = g(z^{(2)})$ (add $a_0^{(2)}$)
- $z^{(3)} = \theta^{(2)} a^{(2)}$
- $h = a^{(3)} = g(z^{(3)})$

其中 g 为 sigmoid 激活函数。

1.2 反向传播

我们用 $\delta^{(l)}$ 表示每层的“误差”， y 为每个样本的标签， h 为每个样本的预测值。

先来从后往前计算每层的“误差”。注意到这里的误差用双引号括起来，因为并不是真正的误差。

- $\delta^{(3)} = h - y$ (1)
- $\delta^{(2)} = (\theta^{(2)})^T \delta^{(3)} g'(z^{(2)})$ (2)

注意第一层是没有误差的，因为是输入层。

吴恩达在课里面提到，“误差”的实质是 $\delta^{(l)} = \frac{\partial J}{\partial z^{(l)}}$ ，没错，后面详细说明。

然后来计算每层参数矩阵的梯度，用 $\Delta^{(l)}$ 表示

$$\circ \Delta^{(2)} = a^{(2)}\delta^{(3)} \quad (3)$$

$$\circ \Delta^{(1)} = a^{(1)}\delta^{(2)} \quad (4)$$

最后网络的总梯度为：

$$\circ D = \frac{1}{m}(\Delta^{(1)} + \Delta^{(2)}) \quad (5)$$

到这里反向传播就完成了，接着就可以利用梯度下降法或者更高级的优化算法来训练网络。

2 推导

这里只推导 δ 和 Δ 是怎么来的，其余的比较好理解。

首先明确我们要优化的参数有 $\theta^{(1)}$ ， $\theta^{(2)}$ ，利用梯度下降法的思想，我们只需要求解出代价函数对参数的梯度即可。

假设只有一个输入样本，则代价函数是：

$$J(\theta) = -y \log h(x) - (1-y) \log(1-h)$$

回顾下正向传递的过程，理解其中函数的嵌套关系：

$$\circ a^{(1)} = x$$

$$\circ z^{(2)} = \theta^{(1)} a^{(1)}$$

$$\circ a^{(2)} = g(z^{(2)}) (\text{add } a_0^{(2)})$$

$$\circ z^{(3)} = \theta^{(2)} a^{(2)}$$

$$\circ h = a^{(3)} = g(z^{(3)})$$

然后我们来求解代价函数对参数的梯度， $\frac{\partial}{\partial \theta^{(2)}} J(\theta)$ ， $\frac{\partial}{\partial \theta^{(1)}} J(\theta)$ 。

根据链式求导法则，可以计算得到：

$$\frac{\partial J}{\partial \theta^{(2)}} = \frac{\partial J}{\partial a^{(3)}} \frac{\partial a^{(3)}}{\partial z^{(3)}} \frac{\partial z^{(3)}}{\partial \theta^{(2)}} = \frac{(h-y)a^{(2)}}{\delta^{(3)}} \Delta^{(2)}$$

把我画红线的地方令为 $\delta^{(3)}$ ，是不是就得到了反向传播中的公式（1）？

把画绿线的部分令为 $\Delta^{(2)}$ ，就得到了公式（3）。我们接着算：

$$\begin{aligned} \Delta^{(1)} \frac{\partial J}{\partial \theta^{(1)}} &= \frac{\partial J}{\partial a^{(3)}} \frac{\partial a^{(3)}}{\partial z^{(3)}} \frac{\partial z^{(3)}}{\partial a^{(2)}} \frac{\partial a^{(2)}}{\partial z^{(2)}} \frac{\partial z^{(2)}}{\partial \theta^{(1)}} \\ &= \frac{\delta^{(3)} \theta^{(2)} g'(z^{(2)}) a^{(1)}}{\delta^{(2)}} \\ &= \delta^{(2)} a^{(1)} \end{aligned}$$

同样把红线部分令为 $\delta^{(3)}$ ，紫色部分令为 $\delta^{(2)}$ ，就得到了公式（2）。

绿线部分令为 $\Delta^{(1)}$ ，就得到了公式（4）。

至此，推导完毕。得到这个规律后，便可以应用到深层次的网络中，计算反向传播时就方便了。

上面的公式因为书写麻烦，便只写了结果。如果你用笔去慢慢推几分钟，会发现其实很简单。



欢迎订阅公众号，与我随时交流哦~

机器学习

◀ 吴恩达机器学习作业Python实现(三)：多类分类和前馈神经网络

吴恩达机器学习作业Python实现(四)：神经网络反向传播 ▶

© 2018  Cowry |  39.8k

 172 |  738