

神经网络基础作业答案

April 2025

1 第一次作业

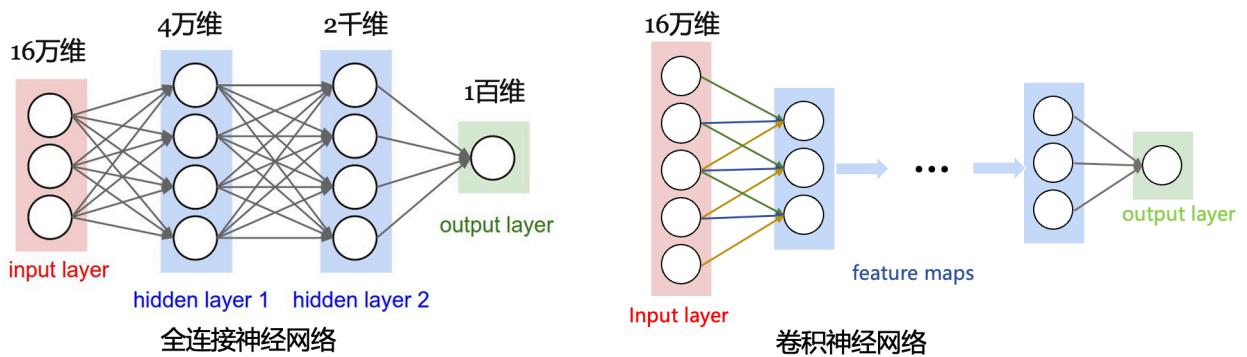


图 1: 神经网络示意图

1.1

在图 1 左图所示的四层全连接神经网络中，输入层维度为 160,000，第一个隐藏层维度为 40,000，第二个隐藏层维度为 2,000，输出层维度为 100。请计算该神经网络的参数总量。

答：

每个全连接层的参数量由输入大小、输出大小和偏置项决定。神经网络的参数总量为各层之间的连接参数之和：

- 输入层 \rightarrow 隐藏层 1: $(160,000 + 1) \times 40,000 = 6,400,040,000$
- 隐藏层 1 \rightarrow 隐藏层 2: $(40,000 + 1) \times 2,000 = 80,002,000$
- 隐藏层 2 \rightarrow 输出层: $(2000 + 1) \times 100 = 200,100$

综上，总参数量为 $6,400,040,000 + 80,002,000 + 200,100 = 6,480,242,100 \approx 6.4 \times 10^9$.

1.2

在图 1 右图所示的卷积神经网络中，输入层维度为 160,000，第一个卷积层使用 3 个 5*5 的卷积核，使用 max pooling 将特征图尺寸降为 40,000，第二个卷积层使用 5 个 4*4*3 的卷积核，紧接着使用 max

pooling 将特征图尺寸降为 2,000, 第三个卷积层使用 5 个 $4 \times 4 \times 5$ 的卷积核, 使用 max pooling 将特征图尺寸降为 400, 在卷积过程中始终使用 padding 保持输入和输出维度一致, 最后一层使用全连接层将维度展平后降为 100。请计算该神经网络的参数总量。

答:

卷积层参数计算公式: 参数量 = (卷积核大小 \times 前一层特征图的通道数) \times 当前层卷积核数量

因此各层参数计算如下:

- 卷积层 1 参数 (输入通道数为 1, 输出通道数为 3, 卷积核大小为 $5 \times 5 + 1$): $3 \times (5 \times 5 + 1) = 78$
- 卷积层 2 参数 (输入通道数为 3, 输出通道数为 5, 卷积核大小为 $4 \times 4 \times 3 + 1$): $5 \times (4 \times 4 \times 3 + 1) = 245$
- 卷积层 3 参数 (输入通道数为 5, 输出通道数为 5, 卷积核大小为 $4 \times 4 \times 5 + 1$): $5 \times (4 \times 4 \times 5 + 1) = 405$
- 全连接层: (输入维度为 400, 输出维度为 100): $(400 + 1) \times 100 = 40,100$

综上, 总参数量为 $78 + 245 + 405 + 40,100 = 40,828$.

2 第二次作业

2.1

在图 2 神经网络, 假设激活函数为 ReLU, 用平方损失 $\frac{1}{2}(y - \hat{y})^2$ 计算误差, 请用 BP 算法更新一次所有参数 (学习率为 1), 给出更新后的参数值, 并计算给定输入值 $x = (0.2, 0.3)$ 时初始时和更新后的输出值, 检查参数更新是否降低了平方损失值。

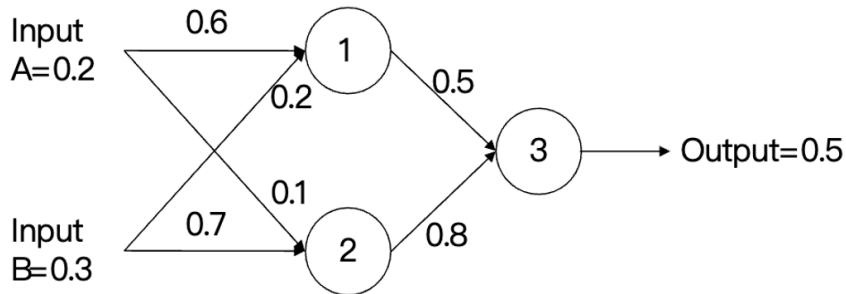


图 2: 神经网络示意图

答:

参考课程讲义的解法, 题目忽略偏置的计算。首先对符号进行表示:

- 激活函数 ReLU 表示为: $f(x) = \max\{0, x\}$
- 输入层第 $i (i = 1, 2)$ 个输入为 x_i .
- 输入层第 i 个神经元到隐藏层第 $h (h = 1, 2)$ 个神经元之间的连接权重 v_{ih} .
- 隐藏层第 h 个神经元的输入表示为 $\alpha_h = \sum_{i=1}^2 v_{ih} x_i$, 输出表示为 b_h .
- 隐藏层第 h 个神经元到输出层第 $j (j = 1)$ 个神经元之间的连接权重 $w_{hj} (j = 1)$.

- 输出层输入表示为 $\beta_j = \sum_{h=1}^2 w_{hj} b_h$, 输出层的输出表示为 $y_j = f(\beta_j)$.
- 损失函数表示为 $E = \frac{1}{2}(y - \hat{y})^2$, 期望输出表示为 $\hat{y} = 0.5$.

接下来对前向传播过程和反向传播过程分别进行计算:

前向传播过程:

- 隐藏层输入: $\alpha_1 = \sum_{i=1}^2 v_{i1} x_i = 0.6 \times 0.2 + 0.2 \times 0.3 = 0.18$, $\alpha_2 = \sum_{i=1}^2 v_{i2} x_i = 0.1 \times 0.2 + 0.7 \times 0.3 = 0.23$
- 隐藏层输出: $b_1 = f(1) = b_1 = 0.18$, $b_2 = f(2) = b_2 = 0.23$
- 输出层输入: $y = y_1 = f(\beta_1) = f(\sum_{i=1}^2 w_{i1} b_i) = f(0.5 \times 0.18 + 0.8 \times 0.23) = f(0.274) = 0.274$

损失计算:

$$E = \frac{1}{2}(y - \hat{y})^2 = \frac{1}{2}(0.274 - 0.5)^2 = 0.025538$$

后向传播过程:

首先根据链式法则计算 Δw_{hj} .

$$\begin{aligned} \Delta w_{hj} &= -\eta \frac{\partial E}{\partial w_{hj}} \\ &= -\eta \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial \beta_j} \cdot \frac{\partial \beta_j}{\partial w_{hj}}. \end{aligned} \tag{1}$$

$$\begin{aligned} g_j &= -\frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial \beta_j} \\ &= -(y - \hat{y}) \cdot \frac{\partial y_j}{\partial \beta_j} \\ &= -(y - \hat{y}) \cdot f'(\beta_j). \end{aligned} \tag{2}$$

根据 ReLU 函数 f 的性质, 当 $\beta_j \leq 0$ 时, $f'(\beta_j) = 0$, 反之, $f'(\beta_j) = 1$.

因为 $\beta_j > 0$, 所以 $g_j = -(y - \hat{y}) = 0.226$.

再将 $\frac{\partial \beta_j}{\partial w_{hj}} = b_h$, $\eta = 1$ 代入, 得到 $w_{hj} = \eta g_j b_h = 0.226 b_h$.

因此得到

$$w_{11}^+ = w_{11} + \Delta w_{11} = 0.5 + 0.226 \times 0.18 = 0.54068$$

$$w_{21}^+ = w_{21} + \Delta w_{21} = 0.8 + 0.226 \times 0.23 = 0.85198$$

同理, 计算 Δv_{ih} . 已知 $\eta = 1$

$$\begin{aligned}
\Delta v_{ih} &= -\eta \frac{\partial E}{\partial v_{ih}} \\
&= -\frac{\partial E}{\partial b_h} \cdot \frac{\partial b_h}{\partial \alpha_h} \cdot \frac{\partial \alpha_h}{\partial v_{ih}} \\
&= -\frac{\partial E}{\partial b_h} \cdot \frac{\partial b_h}{\partial \alpha_h} x_i \\
&= -\sum_{i=1}^2 \frac{\partial E}{\partial \beta_j} \cdot \frac{\partial \beta_j}{\partial b_h} f'(\alpha_h) x_i \\
&= \sum_{j=1}^1 w_{hj} g_j f'(\alpha_h) x_i
\end{aligned} \tag{3}$$

通过 ReLU 函数的性质，易得 $f'(\alpha_1) = 1, f'(\alpha_2) = 1$
代入得

$$v_{11}^+ = v_{11} + \Delta v_{11} = v_{11} + \eta w_{11} g_1 x_1 = 0.6 + 1 \times 0.5 \times 0.226 \times 0.2 = 0.6226$$

同理， $v_{12}^+ = 0.13616, v_{21}^+ = 0.2339, v_{22}^+ = 0.75424$

计算权重更新后的前向传播：

过程省略，输出结果 $y' = (0.6226 * 0.2 + 0.2339 * 0.3) * 0.54068 + (0.13616 * 0.2 + 0.75424 * 0.3) * 0.85198 = 0.3212453271 \approx 0.3212$

则新的误差为 $E^+ = \frac{1}{2}(0.3212 - 0.5)^2 = 0.01598 < E = 0.02554$.

综上可知，参数更新后损失值降低。

2.2

计算 $\sigma(x) = \frac{1}{1+\exp(-x)}$ 的一阶和二阶导数、 $\log \text{softmax}(x)_{[i]} = \log \frac{\exp(x_i)}{\sum_{j=1}^C \exp(x_j)}$ 的梯度
答：

$\sigma(x) = \frac{1}{1+\exp(-x)}$ 一阶导数： $\sigma'(x) = \frac{\exp(-x)}{(1+\exp(-x))^2} = \sigma(1-\sigma)$

$\sigma(x) = \frac{1}{1+\exp(-x)}$ 二阶导数： $\sigma''(x) = \sigma(1-\sigma)^2 - \sigma^2(1-\sigma) = \sigma(1-\sigma)(1-2\sigma)$

计算 $\log \text{softmax}(x)_{[i]} = \log \frac{\exp(x_i)}{\sum_{j=1}^C \exp(x_j)}$ 梯度：

$\log \text{softmax}(x)_{[i]} = \log \frac{\exp(x_i)}{\sum_{j=1}^C \exp(x_j)} = x_i - \log \sum_{j=1}^C \exp(x_j)$

$$\nabla \log \text{softmax}(x)_{[i]} = \begin{cases} 1 - \frac{\exp(x_k)}{\sum_{j=1}^C \exp(x_j)} = 1 - \text{softmax}(x)_{[k]} & k = i \\ -\frac{\exp(x_k)}{\sum_{j=1}^C \exp(x_j)} = -\text{softmax}(x)_{[k]} & k \neq i \end{cases} \tag{4}$$

2.3

2.3.1 每层主要运算

每一层 l ($l = 1, 2, \dots, L$) 执行以下运算：

1. 线性变换：

$$z^{(l)} = W^{(l)} a^{(l-1)} + b^{(l)}$$

其中：

- $W^{(l)}$: $n \times n$ 权重矩阵。
- $a^{(l-1)}$: n 维输入向量 (前一层的输出)。
- $b^{(l)}$: n 维偏置向量。

2. 激活函数:

$$a^{(l)} = \sigma(z^{(l)}), \quad \sigma(z) = \frac{1}{1 + e^{-z}}$$

2.3.2 每层计算复杂度

- **矩阵-向量乘法** $W^{(l)} a^{(l-1)}$:
 - 乘法: $n \times n = n^2$ 次 (矩阵 $n \times n$, 向量 $n \times 1$)。
 - 加法: $n \times (n - 1) \approx n^2$ 次 (每个输出元素需 n 次乘法后累加 $n - 1$ 次)。
- **偏置加法** $b^{(l)}$:
 - 加法: n 次 (每个元素加一次)。
- **Sigmoid 函数** $\sigma(z^{(l)})$:
 - 对 n 个元素逐一计算, 复杂度主要为指数运算, 暂不计人乘法和加法。

每层操作总数 (忽略 Sigmoid 内部复杂度和低阶项):

- 乘法: $O(n^2)$ 次。
- 加法: $O(n^2 + n) = O(n^2)$ 次。

2.3.3 整个网络前向传播

网络共 L 层, 每层乘法约 n^2 次, 总计:

$$\text{总乘法次数} = L \times n^2$$

加法总数类似, 约为 $L \times n^2$ 。

每层主要计算

反向传播计算梯度并更新参数, 每层 l 涉及:

1. 误差项计算:

- **输出层** ($l = L$, 均方误差损失):

$$\delta^{(L)} = (a^{(L)} - y) \odot \sigma'(z^{(L)})$$

其中, y 是 n 维真实标签, \odot 表示逐元素乘法, Sigmoid 导数:

$$\sigma'(z) = \sigma(z)(1 - \sigma(z))$$

- 隐藏层 ($l = 1, 2, \dots, L - 1$):

$$\delta^{(l)} = ((W^{(l+1)})^T \delta^{(l+1)}) \odot \sigma'(z^{(l)})$$

2. 梯度计算:

- 权重梯度:

$$\nabla_{W^{(l)}} = \delta^{(l)} (a^{(l-1)})^T$$

- 偏置梯度:

$$\nabla_{b^{(l)}} = \delta^{(l)}$$

3. 参数更新 (学习率 α):

$$W^{(l)} \leftarrow W^{(l)} - \alpha \nabla_{W^{(l)}}$$

$$b^{(l)} \leftarrow b^{(l)} - \alpha \nabla_{b^{(l)}}$$

2.3.4 每层计算复杂度

- 误差项计算:

– 输出层:

- * 差值 $(a^{(L)} - y)$: n 次减法。
- * $\sigma'(z^{(L)})$: n 次乘法 (每个元素计算 $\sigma(z)(1 - \sigma(z))$)。
- * 逐元素乘法: n 次乘法。

– 隐藏层:

- * 矩阵-向量乘法 $(W^{(l+1)})^T \delta^{(l+1)}$: n^2 次乘法。
- * $\sigma'(z^{(l)})$ 和逐元素乘法: n 次乘法。

– 总计: $n^2 + n$ 次乘法 (隐藏层为主)。

- 梯度计算:

- 权重梯度 $\delta^{(l)} (a^{(l-1)})^T$: n^2 次乘法 (外积生成 $n \times n$ 矩阵)。
- 偏置梯度: 无需乘法。

- 参数更新:

- 权重更新: n^2 次乘法 (逐元素乘 α 并减)。
- 偏置更新: n 次乘法。

每层总乘法 (以隐藏层为主, 忽略低阶项):

$$n^2 + n + n^2 + n^2 + n = 3n^2 + 2n \approx 3n^2$$

2.3.5 整个网络反向传播

网络共 L 层, 每层乘法约 $3n^2 + 2n$, 总计:

$$\text{总乘法次数} = L \times (3n^2 + 2n) = 3Ln^2 + 2Ln$$

2.4

如果用如下卷积替换前馈网络中的线性变换，试计算误差项 $\frac{\partial \mathcal{L}}{\partial z_{ij}^{(l)}}$ 的递推式。

$$\begin{aligned}\frac{\partial \mathcal{L}}{\partial z_{ij}^{(l)}} &= \sum_{u=0}^{K-1} \sum_{v=0}^{K-1} \frac{\partial \mathcal{L}}{\partial z_{(i-u)(j-v)}^{(l+1)}} \cdot \frac{\partial z_{(i-u)(j-v)}^{(l+1)}}{\partial a_{ij}^{(l)}} \cdot \frac{\partial a_{ij}^{(l)}}{\partial z_{ij}^{(l)}} \\ &= f'(z_{ij}^{(l)}) \cdot \sum_{u=0}^{K-1} \sum_{v=0}^{K-1} \omega_{uv}^{(l+1)} \cdot \frac{\partial \mathcal{L}}{\partial z_{(i-u)(j-v)}^{(l+1)}}\end{aligned}\quad (5)$$

2.5

如果有池化层，这一层的误差如何反向传播？

设池化窗口大小为 $K' \times K'$ ，步长为 S 。

假如是平均池化：

$a_{ij}^{(l)} = f(z_{ij}^{(l)})$ 将被改写为 $a_{ij}^{(l)} = f(\max_{u=0}^{K'-1} \max_{v=0}^{K'-1} z_{Si+u, Sj+v}^{(l)})$

反向传播时，梯度仅传递到前向传播中最大值的位置，其他位置梯度为零。

假如是最大池化：

$a_{ij}^{(l)} = f(z_{ij}^{(l)})$ 将被改写为 $a_{ij}^{(l)} = f(\frac{1}{K'^2} \sum_{u=0}^{K'-1} \sum_{v=0}^{K'-1} z_{Si+u, Sj+v}^{(l)})$

反向传播时，梯度平均分配到前向传播中对应的位置。