

第三章 前馈神经网络

3.4 误差反传 (BP) 算法

回顾

□ 3.1 单层感知器

- 模型：单计算节点感知器实际上就是一个 M-P 神经元模型
- 功能：解决线性可分问题
- 局限性：不能解决线性不可分问题
- 学习算法：有导师学习

□ 3.2 多层感知器

- 模型：有隐层的多层前馈网络
- 功能：能够求解非线性问题
- 局限性：隐层神经元的学习规则尚无所知

3.3BP 算法及改进 - 主要内容

- 引言
- 基于 BP 算法的多层前馈网络模型
- BP 算法的实现
 - 基本思想
 - 推导过程
 - 程序实现
- BP 学习算法的功能
- BP 学习算法的局限性
- BP 学习算法的改进

引言 - - BP 算法的提出

□ 提高网络性能（如分类能力）的有效途径



- 包含隐层的多层前馈网络
 - 长期以来没有提出解决权值调整问题的有效算法。
- 非线性连续转移函数

□ BP (Error Back Propagation , BP) 算法

- 1986 年，Rumelhart 和 McClelland 领导的科学家小组《Parallel Distributed Processing》一书
- 应用对象：多层前馈网络
- 具有非线性连续转移函数

3.4 误差反传 (BP) 算法

3.4.1 基于 BP 算法的多层前馈网络模型



□ 模型的数学表达

输入向量： $X=(x_1, x_2, \dots, x_j, \dots, x_n)^T$

隐层输出向量： $Y=(y_1, y_2, \dots, y_j, \dots, y_m)^T$

输出层输出向量： $O=(o_1, o_2, \dots, o_k, \dots, o_l)^T$

期望输出向量： $d=(d_1, d_2, \dots, d_k, \dots, d_l)^T$

输入层到隐层之间的权值矩阵： $V=(V_1, V_2, \dots, V_j, \dots, V_m)$

隐层到输出层之间的权值矩阵： $W=(W_1, W_2, \dots, W_k, \dots, W_l)$

各个变量之间如何建立联系，来描述整个网络？

3.4.1 基于 BP 算法的多层前馈网络模型

对于输出层：


$$o_k = f(net_k) \quad k=1,2,\dots,l \quad (3.4.1)$$

$$net_k = \sum_{j=0}^m w_{jk} y_j \quad k=1,2,\dots,l \quad (3.4.2)$$

对于隐层：

$$y_j = f(net_j) \quad j=1,2,\dots,m \quad (3.4.3)$$

$$net_j = \sum_{i=0}^n v_{ij} x_i \quad j=1,2,\dots,m \quad (3.4.4)$$



3.4.1 基于 BP 算法的多层前馈网络模型


单极性 Sigmoid 函数：

$$f(x) = \frac{1}{1 + e^{-x}}$$

(3.4.5)

双极性 Sigmoid 函数：

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$$



3.4.2 BP 学习算法


一、网络误差与权值调整

输出误差 E 定义：

$$E = \frac{1}{2}(\mathbf{d} - \mathbf{O})^2 = \frac{1}{2} \sum_{k=1}^l (d_k - o_k)^2 \quad (3.4.6)$$

将以上误差定义式展开至隐层：

$$E = \frac{1}{2} \sum_{k=1}^l [d_k - f(\text{net}_k)]^2 = \frac{1}{2} \sum_{k=1}^l [d_k - f(\sum_{j=0}^m w_{jk} y_j)]^2 \quad (3.4.7)$$




3.4.2 BP 学习算法

一、网络误差与权值调整

进一步展开至输入层：

$$E = \frac{1}{2} \sum_{k=1}^l \{d_k - f[\sum_{j=0}^m w_{jk} f(\text{net}_j)]\}^2 \quad (3.4.8)$$

$$= \frac{1}{2} \sum_{k=1}^l \{d_k - f[\sum_{j=0}^m w_{jk} f(\sum_{i=0}^n v_{ij} x_i)]\}^2$$



3.4.2 BP 学习算法

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}}$$

$$j=0,1,2,\dots,m; k=1,2,\dots,l \quad (3.4.9a)$$


$$\Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}}$$

$$i=0,1,2,\dots,n; j=1,2,\dots,m \quad (3.4.9b)$$


式中负号表示梯度下降，常数 $\eta \in (0,1)$ 表示比例系数。

在全部推导过程中，对输出层有 $j=0,1,2,\dots,m; k=1,2,\dots,l$

对隐层有 $i=0,1,2,\dots,n; j=1,2,\dots,m$



3.4.2 BP 学习算法



二、BP 算法推导

对于输出层，式 (3.15a) 可写为

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} = -\eta \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial w_{jk}} \quad (3.4.10a)$$

对隐层，式 (3.15b) 可写为

$$\Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}} = -\eta \frac{\partial E}{\partial net_j} \frac{\partial net_j}{\partial v_{ij}} \quad (3.4.10b)$$

对输出层和隐层各定义一个误差信号，令

$$\delta_k^o = -\frac{\partial E}{\partial net_k} \quad (3.4.11a)$$

$$\delta_j^y = -\frac{\partial E}{\partial net_j} \quad (3.4.11b)$$


综合应用式 (3.4.2) 和 (3.4.11a) ，可将式 (3.4.10a) 的权值调整式改写为

$$\Delta w_{jk} = \eta \delta_k^o y_j \quad (3.4.12a)$$

综合应用式 (3.13) 和 (3.21b) ，可将式 (3.17b) 的权值调整式改写为

$$\Delta v_{ij} = \eta \delta_j^y x_i \quad (3.4.12b)$$

可以看出，只要计算出式 (3.4.12) 中的误差信号 δ^o 和 δ^y ，权值调整量的计算推导即可完成。下面继续推导如何求误差信号 δ^o 和 δ^y 。




对于输出层， δ^o 可展开为

$$\delta_k^o = -\frac{\partial E}{\partial net_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k} = -\frac{\partial E}{\partial o_k} f'(net_k) \quad (3.4.13a)$$

对于隐层， δ^y 可展开为

$$\delta_j^y = -\frac{\partial E}{\partial net_j} = -\frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial net_j} = -\frac{\partial E}{\partial y_j} f'(net_j) \quad (3.4.13b)$$

下面求式 (3.23) 中网络误差对各层输出的偏导。



对于输出层，利用式 (3.4.6)：

$$E = \frac{1}{2} \sum_{k=1}^l (d_k - o_k)^2$$

可得：


$$\frac{\partial E}{\partial o_k} = -(d_k - o_k) \quad (3.4.14a)$$

对于隐层，利用式 (3.4.7)：

$$E = \frac{1}{2} \sum_{k=1}^l [d_k - f(\sum_{j=0}^m w_{jk} y_j)]^2$$

可得：

$$\frac{\partial E}{\partial y_j} = - \sum_{k=1}^l (d_k - o_k) f'(net_k) w_{jk} \quad (3.4.14b)$$



将以上结果代入式 (3.4.13) ，并应用式 (3.15) :

$$f(x) = \frac{1}{1 + e^{-x}}$$

得到 :

$$\delta_k^o = (d_k - o_k) o_k (1 - o_k)$$


(3.4.15a)

$$\delta_j^y = \left[\sum_{k=1}^l (d_k - o_k) f'(net_k) w_{jk} \right] f'(net_j)$$

$$= \left(\sum_{k=1}^l \delta_k^o w_{jk} \right) y_j (1 - y_j)$$

(3.4.15b)


至此两个误差信号的推导已完成。



将式 (3.4.15) 代回到式 (3.4.12) ，得到三层前馈网的 BP 学习算法权值调整计算公式为：

$$\Delta w_{jk} = \eta \delta_k^o y_j = \eta (d_k - o_k) o_k (1 - o_k) y_j \quad (3.4.16a)$$

$$\Delta v_{ij} = \eta \delta_j^y x_i = \eta \left(\sum_{k=1}^l \delta_k^o w_{jk} \right) y_j (1 - y_j) x_i \quad (3.4.16b)$$



$$o_k = f(\text{net}_k)$$

$$y_j = f(\text{net}_j)$$

$$f(x) = \frac{1}{1 + e^{-x}}$$

$$\text{net}_k = \sum_{j=0}^m w_{jk} y_j$$

$$\text{net}_j = \sum_{i=0}^n v_{ij} x_i$$

$$E = \frac{1}{2} \sum_{k=1}^l (d_k - o_k)^2 = \frac{1}{2} \sum_{k=1}^l [d_k - f(\text{net}_k)]^2 = \frac{1}{2} \sum_{k=1}^l [d_k - f(\sum_{j=0}^m w_{jk} y_j)]^2$$

$$= \frac{1}{2} \sum_{k=1}^l \{d_k - f[\sum_{j=0}^m w_{jk} f(\text{net}_j)]\}^2 = \frac{1}{2} \sum_{k=1}^l \{d_k - f[\sum_{j=0}^m w_{jk} f(\sum_{i=0}^n v_{ij} x_i)]\}^2$$

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} = -\eta \frac{\partial E}{\partial \text{net}_k} \frac{\partial \text{net}_k}{\partial w_{jk}}$$

$$\delta_k^o = -\frac{\partial E}{\partial \text{net}_k}$$

$$\Delta w_{jk} = \eta \delta_k^o y_j$$

$$\Delta v_{ij} = -\eta \frac{\partial E}{\partial v_{ij}} = -\eta \frac{\partial E}{\partial \text{net}_j} \frac{\partial \text{net}_j}{\partial v_{ij}}$$

$$\delta_j^y = -\frac{\partial E}{\partial \text{net}_j}$$

$$\Delta v_{ij} = \eta \delta_j^y x_i$$

