

# 一种有效脱离平坦区的改进 BP 网络<sup>\*</sup>

刘 乐<sup>1</sup> 王洪国<sup>1,2</sup> 王 鑫<sup>1</sup> 王宝伟<sup>3</sup>

(山东师范大学管理与经济学院 济南 250014)<sup>1</sup> (山东省科学技术厅 济南 250011)<sup>2</sup>

(山东师范大学信息科学与工程学院 济南 250014)<sup>3</sup>

**摘 要** 本文提出了一种新型权值调整规则,当神经元输出值接近于 0 或 1 时,确保足够的权值调整幅度,解决了标准 BP(Back Propagation)网络在训练进入平坦区后难以摆脱,训练速度很慢的问题。并给出了利用单隐层 BP 网络逼近非线性函数的仿真实验,证实了新规则在训练速度上的优越性,得出新规则中控制因子的理想取值为 0.95。

**关键词** 平坦区, S 型函数, 梯度下降

## Modified BP Network in Breaking Away from Flat Areas Effectively

LIU Le<sup>1</sup> WANG Hong-guo<sup>1,2</sup> WANG Xin<sup>1</sup> WANG Bao-wei<sup>3</sup>

(Dept. of Management and Economy, Shandong Normal University, Jinan 250014, China)<sup>1</sup>

(Dept. of Science and Technology of Shandong Province, Jinan 250011, China)<sup>2</sup>

(Dept. of Information Science and Engineering, Shandong Normal University, Jinan 250014, China)<sup>3</sup>

**Abstract** This paper proposes a new rule to adjust the weight value, which ensures enough weight adjusted range when the output of neuron is close to 0 or 1. The new rule solves a difficult problem for standard BP network to break away from the flat area when it has entered, here its training speed is very slow. A experiment which uses a BP network with single hidden layer to approximate a nonlinear function is presented in the paper. It verifies the superiority of the new rule in the training speed, and draws a conclusion that the ideal value of the control factor in the new rule is 0.95.

**Keywords** Flat area, S-type function, Gradient descent

## 1 引言

BP 网络是采用 BP 算法进行权值调整的多级前馈神经网络,具有很强的非线性映射能力、泛化能力和容错能力,被广泛应用于模式识别、函数逼近、图像处理、经济预测以及过程控制等领域。然而,标准 BP 网络在应用中暴露出不少严重的缺陷。如,训练次数多,收敛速度慢;易陷于局部极小而达不到全局最优;隐层层数和各隐层神经元个数的选取缺乏理论指导;BP 网络的学习和记忆具有不稳定性等等,大大限制了 BP 网络的推广应用。

针对上述缺陷,国内外许多学者已提出了很多有效的 BP 网络改进方案。例如,在权值调整公式中加入动量项<sup>[1]</sup>,学习率自适应调节<sup>[2]</sup>等等。人们还先后利用变尺度法<sup>[3]</sup>、同伦算法<sup>[4]</sup>以及 LM 法<sup>[5]</sup>等优化算法对 BP 网络进行改进,并且尝试采用不同的有界可微函数(如混沌函数、小波函数等)作为激活函数,以提高 BP 网络的处理能力和收敛速度。此外,人们还将遗传算法<sup>[6]</sup>、模拟退火算法<sup>[7]</sup>与 BP 网络相结合,有效地克服了 BP 网络收敛速度慢,易于陷于局部极小的弱点。然而,众多 BP 网络改进方法中,有效地解决脱离平坦区问题的研究并不多。

本文在前人工作的基础上,提出了一种有效脱离平坦区的新型权值调整规则,目的在于提高 BP 网络的训练速度。

## 2 单隐层 BP 网络及其权值调整规则

BP 网络所采用的 BP 算法包括信号正向传播、误差反向传播两个过程,本质上是遵从误差梯度下降原则进行权值调整的学习算法,整个学习过程是一个非线性寻优过程。

### 2.1 单隐层 BP 网络

BP 网络是迄今应用最广泛的神经网络,其中尤其以单隐层 BP 网络应用最为普遍。由 Kolmogorov 定理可知,对于任意单隐层的 BP 网络,只要隐层神经元足够多,就能逼近任意非线性函数。




图 1 单极性 S 型函数

由于单隐层 BP 网络的重要地位以及单极性 S 型函数的特性,在 BP 网络中,神经元的激活函数大多采用典型的单极

<sup>\*</sup> 基金项目:山东省自然科学基金(Q2006G03)。刘 乐 硕士研究生,主要研究方向为人工神经网络、数据挖掘;王洪国 教授,博士后,主要研究方向为组合优化算法、数据挖掘、电子政务等;王 鑫 硕士研究生,主要研究方向:数据挖掘、知识发现;王宝伟 硕士研究生,主要研究方向为遗传算法、人工神经网络。

性 S 型函数——Sigmoid 函数,即:

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

如图 1 所示。

该函数具有以下特性:处处连续可导;单调递增;值域为 (0,1);

$$f'(x) = f(x)(1-f(x)) \quad (2)$$

单隐层 BP 网络包括三层:输入层、隐层和输出层,如图 2 所示。




图 2 单隐层 BP 网络

在图 2 所示的 BP 网络中,输入向量为  $X = (x_1, x_2, \dots, x_i, \dots, x_n)^T$ ,  $x_0 = -1$  是为隐层神经元引入阈值而设置的;隐层输出向量为  $Y = (y_1, y_2, \dots, y_j, \dots, y_m)^T$ ,  $y_0 = -1$  是为输出层神经元引入阈值而设置的;输出层输出向量为  $O = (o_1, o_2, \dots, o_k, \dots, o_l)^T$ ;期望输出向量为  $d = (d_1, d_2, \dots, d_k, \dots, d_l)^T$ 。输入层到隐层之间的权值矩阵用  $V$  表示,  $V = (V_1, V_2, \dots, V_j, \dots, V_m)$ , 其中列向量  $V_j$  为隐层第  $j$  个神经元对应的权向量;隐层到输出层之间的权值矩阵用  $W$  表示,  $W = (W_1, W_2, \dots, W_k, \dots, W_l)$ , 其中列向量  $W_k$  为输出层第  $k$  个神经元对应的权向量。除此之外,各层信号之间还存在以下数学关系:

对于输出层,有

$$o_k = f(net_k) \quad (3)$$

$$net_k = \sum_{j=0}^m w_{jk} y_j \quad k=1, 2, \dots, l \quad (4)$$

对于隐层,有

$$y_j = f(net_j) \quad (5)$$

$$net_j = \sum_{i=0}^n v_{ij} x_i \quad j=1, 2, \dots, m \quad (6)$$

## 2.2 单隐层 BP 网络的权值调整规则

我们知道, BP 算法是按照误差梯度下降的原则调整权值的。依据文献[8]的理论,按照图 2 所示及其符号表达和相应数学关系,可以推导出神经元激活函数为 Sigmoid 函数的单隐层 BP 网络的权值调整规则为:

$$\begin{cases} \Delta w_{jk} = \eta \cdot (d_k - o_k) \cdot o_k \cdot (1 - o_k) \cdot y_j \\ \Delta w_{ij} = \eta \cdot \sum_{k=1}^l (w_{jk} \cdot \delta_k) \cdot o_j \cdot (1 - o_j) \cdot x_i \end{cases} \quad (7)$$

## 3 标准 BP 网络难以脱离平坦区

### 3.1 误差曲面上的平坦区

BP 网络模型的误差度量一般为:

$$E = \frac{1}{2} \sum_{q=1}^P \sum_{k=1}^l (d_k^q - o_k^q)^2 \quad (8)$$

其中,  $P$  代表训练样本的总对数,  $q$  代表第  $q$  对训练样本,  $o_k^q$  和  $d_k^q$  分别表示对于第  $q$  对训练样本, 输出层第  $k$  个神经元的实际输出值和理想输出值。经过仔细分析, BP 网络的误差函

数实际上是以各层权值、各神经元阈值和训练样本集对为自变量的非线性函数。一旦给定训练样本集, 即可将误差函数想象为在多维空间中的一个形状复杂的曲面(误差曲面), 该曲面上每个点的“高度”对应于一个误差值, 每个点的其他坐标值对应于各层权值、各神经元阈值。假设各层权值、各神经元阈值的总数目为  $M$ , 则上面提到的多维空间实质上是  $M+1$  维空间, 通常被称作  $M$  维权空间。为了直观描述误差曲面在权空间的起伏变化, 简单起见, 图 3 给出了在二维维权空间中误差曲面的分布情况。




图 3 二维维权空间上的误差曲面

从图 3 中不难发现, 在误差曲面上有些局部区域较为平坦, 我们称其为平坦区。平坦区的数学特性在于, 误差的梯度变化很小, 如果权值调整量达不到一定程度, 误差值难以显著下降。可见, 一旦 BP 网络的训练过程陷入平坦区, 而又不能及时有效地脱离它的话, 必然会耗费大量的训练时间, 这便是导致标准的 BP 网络模型训练速度慢的关键原因, 同时也是努力提高标准 BP 网络收敛速度的重要突破口。

### 3.2 标准 BP 网络难以脱离平坦区的原因

在标准的 BP 网络模型中, 存在这样一种异常现象: 对于训练过程陷入平坦区的 BP 网络, 即使理想输出与实际输出相差很大, 权值的调整幅度也依然很小。欲探讨这一异常现象背后的原因, 需要首先从权值调整规则入手。

我们以神经元激活函数为 Sigmoid 函数的单隐层 BP 网络为例, 它的权值调整规则在 1.2 节(5)式已经给出。观察(5)式, 不难发现, 当  $o_k$  接近于 0 或 1 时, 无论理想输出与实际输出相差多么大, 权值  $w_{jk}$  的调整幅度都会大打折扣; 当  $o_j$  接近于 0 或 1 时, 无论  $\sum_{k=1}^l (w_{jk} \cdot \delta_k)$  的值多么大, 都会严重影响它对增加权值  $w_{ij}$  调整幅度所起的作用。

可见, 当隐层、输出层神经元的输出值接近于 0 或 1 时, 训练进入平坦区的 BP 网络不得不花足够长的调整时间, 以达到某个谷点。并且神经元的输出值接近于 0 或 1 可能性极大, 原因在于 Sigmoid 函数具有饱和特性, 即当净输入 net 的绝对值

$$|net| = \left| \sum_i (w_{ij} \cdot o_i) \right| > 3$$

时,  $f(net)$  将处于接近于 0 或 1 的饱和区内, 如图 1 所示。鉴于这种情况, 我们可以在标准权值调整规则的基础上, 人为加入一些控制条件和措施。

## 4 改进方案及其仿真实验

### 4.1 新的权值调整规则

基于以上分析, 我们针对神经元激活函数为 Sigmoid 函数的单隐层 BP 网络提出一种新的权值调整规则, 旨在提高它的收敛速度。

在新规则中, 首先引入一个控制因子  $f$ , 其中  $f \in$

(0.5, 1)。根据图 2, (5)式, 新规则以数学公式可表达为:

$$\begin{cases} \Delta w_{jk} = \eta \cdot (d_k - o_k) \cdot o_k \cdot (1 - o_k) \cdot y_j & o_k \in [1-f, f] \\ \Delta w_{jk} = \eta \cdot (d_k - o_k) \cdot f \cdot (1-f) \cdot y_j & o_k \notin [1-f, f] \\ \Delta w_{ij} = \eta \cdot \sum_{k=1}^l (w_{jk} \cdot \delta_k) \cdot o_j \cdot (1 - o_j) \cdot x_i & o_j \in [1-f, f] \\ \Delta w_{ij} = \eta \cdot \sum_{k=1}^l (w_{jk} \cdot \delta_k) \cdot f \cdot (1-f) \cdot x_i & o_j \notin [1-f, f] \end{cases} \quad (9)$$

这样当隐层、输出层神经元的输出值接近于 0 或 1 时, 依然保证拥有足够的权值调整幅度。从数学上看, 新规则将 Sigmoid 函数的导函数进行了分段考虑, 即:

$$f'(x) = \begin{cases} f(x) \cdot (1-f(x)) & f(x) \in [1-f, f] \\ f \cdot (1-f) & f(x) \notin [1-f, f] \end{cases} \quad (10)$$

可见, 新规则在理论上大大减轻了隐层、输出层神经元输出值接近于 0 或 1 对权值调整幅度的不利影响。

可以看出, 控制因子  $f$  的取值是新规则的关键问题。如果  $f$  取值过小, 则会影响权值调整方向的正确性, 限制梯度下降原则的优越性发挥; 如果  $f$  取值过大, 则新规则与标准规则十分接近, 在性能上也相差不大。因此, 并不是任取  $f \in (0.5, 1)$ , 新规则在训练速度上都优越于标准规则。

下面将通过实验来验证新规则在收敛速度上的优越性, 以及估计出控制因子的理想取值。

#### 4.2 仿真实验

仿真实验依据标准 BP 网络的权值调整规则(5)式和本文提出的新规则(7)式, 在 Visual C++ 6.0 环境下进行编程, 以实现逼近一个非线性函数的训练过程。具体说来, 本实验采用拓扑结构为 1-5-1 的 BP 网络来逼近一个非线性函数:

$$g(x) = x^2 - 2x + 3 \quad x \in [0, 2] \quad (11)$$

样本集中包含 20 对训练样本, 整个训练过程, 均采用单隐层的 BP 网络, 学习率  $\eta = 0.95$ 。通过与标准 BP 网络相关指标的对比, 验证新的权值调整规则在训练速度上的优越性是本实验的基本思路。

在实验之前, 需要对样本数据进行归一化, 即通过变换处理将网络的输入、输出数据限制在  $[0, 1]$  内。归一化常用以下变换式:

$$\bar{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (12)$$

其中,  $x_i$  代表输入、输出数据,  $x_{\min}$  和  $x_{\max}$  分别代表数据变化范围的最小值和最大值。经过计算, 该实验的归一化变换式为:

$$\bar{x}_i = \frac{x_i - 0}{3 - 0} \quad (13)$$

通过实验可以得到: 当误差终止条件是  $E = 0.001$  时, 标准 BP 网络完成 100 次训练的平均迭代次数为 13130.39, 迭代次数超过 18000 次的百分比为 11%, 不足 8000 次的百分比为 0%; 当误差终止条件是  $E = 0.0005$  时, 标准 BP 网络完成 100 次训练的平均迭代次数为 40162.40, 迭代次数超过 35000 次的百分比为 56%, 不足 20000 次的百分比为 0%。

表 1 给出了在误差终止条件  $E = 0.001$  下, 控制因子取不同值时, 采用新型权值调整规则的 BP 网络完成 100 次训练的平均迭代次数, 以及迭代次数超过 18000 次和不足 8000 次的百分比。

表 1 误差终止条件为  $E = 0.001$  时的仿真结果

控制因子	平均迭代次数	>18000 次百分比	<8000 次百分比
0.99	13498.79	12%	0%
0.98	11919.07	7%	0%
0.97	10182.01	0%	25%
0.96	9696.22	1%	29%
0.95	9565.48	0%	35%
0.94	9767.47	1%	25%
0.93	10813.13	1%	22%
0.92	12228.88	9%	9%
0.91	12780.57	6%	13%
0.90	13636.26	11%	3%
0.88	14563.37	17%	2%
0.85	16648.68	28%	0%

表 2 给出了在误差终止条件  $E = 0.0005$  下, 控制因子取不同值时, 采用新型权值调整规则的 BP 网络完成 100 次训练的平均迭代次数, 以及迭代次数超过 35000 次和不足 20000 次的百分比。

表 2 误差终止条件为  $E = 0.0005$  时的仿真结果

控制因子	平均迭代次数	>35000 次百分比	<20000 次百分比
0.99	38174.66	44%	0%
0.98	32858.49	37%	0%
0.97	27109.07	13%	11%
0.96	25872.06	8%	21%
0.95	24828.47	6%	27%
0.94	28668.52	26%	15%
0.93	29279.50	23%	7%
0.92	30035.67	24%	1%
0.91	30642.17	18%	10%
0.90	32148.06	28%	10%
0.88	37290.25	40%	6%
0.85	43546.88	73%	0%

实验结果表明, 当控制因子的取值在 0.91~0.98 范围内时, 改进的 BP 网络在训练速度上明显优越于标准 BP 网络。并且, 当控制因子的取值接近 0.95 时, 改进 BP 网络的训练效率会比标准 BP 网络提高 30% 左右。

**结束语** 标准 BP 网络在进入平坦区后难以尽快摆脱, 是导致 BP 网络训练时间长, 收敛速度慢的主要原因。本文提出的新权值调整规则旨在克服标准 BP 网络进入平坦区后难以有效脱离的弱点, 引入了控制因子, 并通过实验证实了新规则能够有效地提高收敛速度。然而, 新规则并没有有效地克服 BP 网络易于陷于局部极小的弱点。因此, 进一步提出全方位改进标准 BP 网络的方案将是未来研究的重点。

#### 参考文献

- [1] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagation errors. *Nature*, 1986, 323, 533-536
- [2] Jacob R A. Increased rate of convergence through learning rate adaptation. *Neural Networks*, 1988(1): 295-307
- [3] 王正欧. 一类有效的变尺度分层 BP 算法. *天津大学学报*, 1996, 29(3): 364-369
- [4] 高小榕, 杨福生. 采用同伦 BP 算法进行前向网络的训练. *电子学报*, 1994, 19(9): 688-694
- [5] Hagan M T, Menhaj M. Training feedforward networks with the marquardt algorithm. *IEEE Tran on neural networks*, 1994, 5(6): 989-993
- [6] 李建珍. 基于遗传算法的人工神经网络学习算法. *西北师范大学学报(自然科学版)*, 2002, 38(2): 33-37
- [7] Kirkpatrick S, Gelall C D, Vecch T M P. Optimization by simulated annealing. *science*, 1983, 220: 671-680
- [8] 韩力群. *人工神经网络教程*. 第一版. 北京: 北京邮电大学出版社, 2006
- [9] 蒋宗礼. *人工神经网络导论*. 第一版. 北京: 高等教育出版社, 2001