

一种并联抑制神经网络结构及学习算法

武妍¹, 王守觉²

(1. 同济大学计算机科学与技术系 上海 杨浦区 200092; 2. 中国科学院半导体研究所神经网络实验室 北京 海淀区 100083)

【摘要】对普通并联神经元的缺陷进行了分析,提出了一种广义的并联抑制神经元,构造了基于并联抑制神经元的前向神经网络结构,并给出了相应的学习算法。通过对几个模式分类问题的基准问题的测试,将提出的方法与SIANN、BP神经网络进行了比较,验证了提出的网络结构和学习算法的有效性。实验结果表明:单个的GSIN和简单的GSINN可以取得比SIANN和BP网络都好的分类效果。

关键词 BP网络; 模式分类; 并联抑制; 学习算法
中图分类号 TP183 文献标识码 A

A Shunting Inhibition Neural Network Structure and Learning Algorithm

WU Yan¹, WANG Shou-jue²

(1. Dept. of Computer Science and Technology, Tongji University Yangpu Shanghai 200092;
2. Lab of Artificial Neural Networks, Institute of Semiconductors, CAS Haidian Beijing 100083)

Abstract A Generalized Shunting Inhibition Neuron (GSIN) model is proposed by analyzing shortcomings of the normal shunting neuron model. A new feed forward neural network architecture based on GSIN, naming Generalized Shunting Inhibition Neural Network (GSINN), and its learning algorithm are then introduced. Finally, the GSINN is applied to several benchmark classification problems, and their performance is compared with the performances of Shunting Inhibitory Artificial Neural Network (SIANN) and BP networks, and the effectiveness of the proposed network structure and learning algorithm is verified. Experimental results show that a single GSIN and simple GSINN can outperform both the SIANN and Back Propagation (BP) network.

Key words BP network; pattern classification; shunting inhibition; learning algorithm

神经网络的一种最常用的应用是模式分类,但传统的BP(Back Propagation)网络存在一些缺陷,如训练速度慢、泛化能力低、易陷入局部最小等。并联抑制是生物神经元的一种机制,它通过横向抑制的转换机制使结果产生竞争,在感官神经信息处理系统中起着重要的作用。自从20世纪60年代并联抑制机制被提出作为一种仿真生理模型后,它被广泛地使用在一些重要的视觉和认知功能的模拟上,如认知元和自适应共振理论网络^[1-2]。但是,直到2000年基于并联抑制机制的神经网络(Shunting Inhibitory Artificial Neural Network, SIANN)的提出^[3],它才被应用于有监督模式分类中。

虽然SIANN网络在基准测试中表现得很好,但它在设计上仍有缺陷。由于每个输入对于不同的神经元都是一个激励输入,导致并联神经元的数量等同于输入的数量。那么当输入的数目变得巨大时,突触权值的数量也会变得巨大,这既不理想也没必要。文献[4]提出了一种增强的SIANN结构,它允许并联神经元的数量不同于外部输入的数量,但需判断哪些输入可用于激励性输入。一种可行的方法是将所有输入都用作激励性输入,通过调节激励性突触的值来调节输入的多少和强弱。基于此,本文将使用在SIANN中的并联神经元进行了扩展,提出了一种广义的并联抑制神经元(Generalized Shunting Inhibition Neuron, GSIN),构造了一种基于这种并联抑制神经元的前向神经网络(Generalized Shunting Inhibition Neural Network, GSINN)。

收稿日期: 2004-04-15

基金项目: 国家自然科学基金资助项目(60135010)

作者简介: 武妍(1967-),女,博士,教授,主要从事神经网络,模式识别等方面的研究;王守觉(1926-),男,教授,博士生导师,中国科学院院士,主要从事神经网络、仿生模式识别等方面的研究。

1 GSIN

静态并联神经元的状态为：

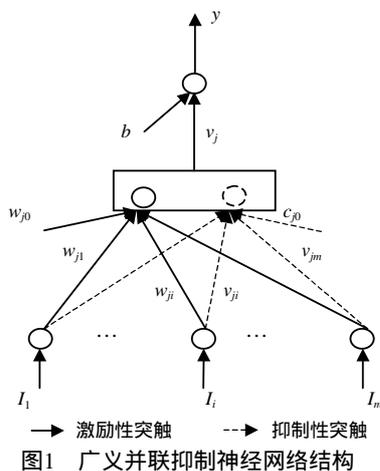
$$x_j = \frac{I_j + b_j}{a_j + f(\sum_i c_{ji} I_i + c_{j0})} \quad (1)$$

式中 x_j 为第 j 个神经元的输出； I_j 为第 j 个神经元的输入； a_j 为神经元的被动衰减速率(正常数)； c_{ji} 为第 i 个神经元到第 j 个神经元的连接权值； b_j 为偏置值； f 为有下限的激励函数。

并联神经元模型的一个缺陷就是每个神经元只有一个未加权的激励性输入。即网络结构中没有和输入数目相同的神经元数，就只有一部分输入能作为激励。其中一种解决方法如感知神经元，将激励性输入集中起来通过一个激励函数。神经元的输出为：

$$x_j = \frac{g(\sum_i w_{ji} I_i + w_{j0}) + b_j}{a_j + f(\sum_i c_{ji} I_i + c_{j0})} \quad (2)$$

无论是感知机还是并联抑制神经元都是式(2)的特例。当式(2)中的分母权值 c 设定为 0， a 被设定在一个特定的常量以使分母为 1，这时，GSIN 实际上就是感知机。此外，令 $w_{ji}=1$ ，而其他的权值 w_{ji} 都设定为 0，再将 g 设定为线性函数，此时，GSIN 就是普通并联神经元。



更重要的是，一个GSIN能形成复杂的、非线性的决策边界，而且输入输出转移特征曲线是自适应的。式(2)中分子、分母取不同激励函数，会得到不同的转移特性曲线。即使式(2)激励函数 f 和 g 固定，每个基本计算单元的输入输出关系也会由于突触权值的变化而有所不同。

2 GSINN结构

GSINN是一种多层前馈神经网络结构，由一些GSIN构成的隐含层和一个普通的由S型函数或线性函数神经元构成的输出层组成。假设输出层为一个节点，输出层节点的输出为：

$$y = g(\sum_j v_j x_j + b)$$

图1所示的是一个简单的GSINN结构，它由一个GSIN、一个输出单元构成。图中的方框表示第 j 个隐单元，其输出由式(2)决定。

3 GSINN学习算法

3.1 权值初始化

初始化网络参数 c_{ji} 、 c_{j0} 、 w_{ji} 、 w_{j0} 、 b_j 、 v_j 、 b 等。通常，这些参数被初始化成在 $[-q, q]$ 之间均匀分布的随机数。 q 的取法很多，通常取 1。但取 1 的效果并不好，本文参考了文献[5]中的方法，将 q 取值为 $2/\sqrt{Z}$ 。其中， Z 是特定神经元的输入个数。采用这种初始化机制可以保证 S 型激励函数开始于它们的线性区域而不是饱和区域，这样可以提高训练的性能。

3.2 学习率的确定

为了提高网络的训练性能，不同的网络参数设置了不同的学习率。它们可采用简单的自适应方法加以修改。自适应策略

$$\eta_\phi(n+1) = \begin{cases} \eta_\phi(n) \times u & \text{如果 } \Delta E < 0 \\ \eta_\phi(n) & \text{否则} \end{cases}$$

式中 η_ϕ 是第 ϕ 个参数的学习率； $u \approx 1/d$ ， u 和 d 的取值范围分别是 1.1~1.3 和 0.7~0.9。

3.3 激励函数的选择原则

GSIN 的输入输出转移特征曲线是和激励函数以及权值等参数相关的，要产生不同的转移曲线，需要不同的激励函数。为此，采用下面的原则来确定节点的激励函数：(1) 每个节点的激励函数不是固定的，而是

由多个候选函数构成, 根据学习情况, 动态地选择较好的函数。式(2)中 f 和 g 通常可以选择线性函数、普通的S型函数、双曲正切函数、双极性S型压缩函数、正弦函数、指数函数等。(2)不同的节点采用不同的激励函数, 不同函数的特性的优点得到组合。

3.4 网络参数的调节

本文采用误差反向传播算法来训练GSINN网络中的参数。首先, 定义误差平方函数

$$E = \frac{1}{2}e^2 = \frac{1}{2}(y - d)^2$$

式中 d 是目标输出; y 是实际输出; e 是误差。在梯度下降算法中, 网络参数 ϕ 可根据下面式子来更新。

$$\phi(n+1) = \phi(n) - \eta_{\phi} \frac{\partial E}{\partial \phi} + \alpha \times \Delta \phi(n)$$

式中 η_{ϕ} 是局部学习率, 不同的参数取不同的值; ϕ 是网络参数 c_{ji} 、 c_{j0} 、 w_{ji} 、 w_{j0} 、 b_j 、 v_j 、 b 之一; α 是动量项因子。下面分别推导出误差 E 对各个参数的梯度:

$$\frac{\partial E}{\partial v_j} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial v_j} = x_j g' e, \quad \frac{\partial E}{\partial b} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial b} = g' e$$

另外,

$$\begin{aligned} \frac{\partial E}{\partial c_{ji}} &= \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial c_{ji}} = \delta_j \frac{-x_j I_j f'(\sum_i c_{ji} I_i + c_{j0})}{a_j + f(\sum_i c_{ji} I_i + c_{j0})}, & \frac{\partial E}{\partial c_{j0}} &= \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial c_{j0}} = \delta_j \frac{-x_j f'(\sum_i c_{ji} I_i + c_{j0})}{a_j + f(\sum_i c_{ji} I_i + c_{j0})} \\ \frac{\partial E}{\partial w_{ji}} &= \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial w_{ji}} = \delta_j \frac{I_i g'(\sum_i w_{ji} I_i + w_{j0})}{a_j + f(\sum_i c_{ji} I_i + c_{j0})}, & \frac{\partial E}{\partial w_{j0}} &= \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial w_{j0}} = \delta_j \frac{g'(\sum_i w_{ji} I_i + w_{j0})}{a_j + f(\sum_i c_{ji} I_i + c_{j0})} \\ \frac{\partial E}{\partial b_j} &= \frac{\partial E}{\partial x_j} \frac{\partial x_j}{\partial b_j} = \delta_j \frac{1}{a_j + f(\sum_i c_{ji} I_i + c_{j0})} \end{aligned}$$

式中 $\delta_j = \frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y} \frac{\partial y}{\partial x_j} = v_j g' e$ 。

4 实验及结果分析

本文使用了两个来自UCI机器学习数据库的实际数据集——美国威斯康辛乳腺癌病人问题和印第安糖尿病病人问题来验证网络及学习算法的性能^[6]。将训练次数设定为2 000次, 当错误分类率为零时, 则提早结束, 记录其实际的训练次数。另外, GSINN输出层神经元、SIANN、BP都用S型函数。

4.1 美国威斯康星乳腺癌诊断问题

美国威斯康星乳腺癌数据库(WBCD)是一个大型的数据库, 共有699组数据样本。其中458个良性样本, 241个是恶性样本。每个样本由10个属性和一个类别构成。其中第一个属性是样本代码, 另外9个属性是一些乳房提取物的测量数据。这是一个较简单的两分类问题, 本文用一个GSIN神经元成功地实现了这个问题的判定。表1是对于这一问题采用不同网络的仿真结果。

表1 乳腺癌数据库的学习和分类结果

网络结构	训练次数	错误分类率/(%)
1个GSIN神经元	720	0.0
GSINN(1个GSIN神经元+1个输出层)	2 000	1.0
GSINN(2个GSIN神经元+1个输出层)	2 000	0.4
BP(6个隐单元)	2 000	1.0
BP(4个隐单元)	2 000	2.0
SIANN(9个隐单元)	2 000	0.7

表1中,各神经网络采用的激励函数如下:1个GSIN神经元:分子用双曲正切函数,分母用指数函数;GSINN(1个GSIN神经元+1个输出层):分子用双曲正切函数,分母用S型函数;GSINN(2个GSIN神经元+1个输出层):分子用S型函数,分母用线性函数。

4.2 印第安糖尿病人问题

印第安糖尿病人问题共有768组数据样本,每个样本由8个属性和一个类别构成。这是一个较复杂的分类问题,但同样用GSINN网络取得了较好的效果。表2是对于这一问题采用不同网络的仿真结果。

表2 印第安糖尿病人问题的学习和分类结果

网络结构	训练次数	错误分类率/(%)
GSINN(1个GSIN神经元+1个输出层)	2 000	13.7
BP(6个隐单元)	2 000	17.3
BP(4个隐单元)	2 000	21.6
BP(3个隐单元)	2 000	29.8
SIANN(8个隐单元)	2 000	25.9

表2中,各神经网络采用的激励函数如下:GSINN(1个GSIN神经元+1个输出层):分子用双极性S型压缩函数,分母用线性函数。

从上面的结果可以看出,一个GSIN神经元、一个或两个隐节点的GSINN网络就能取得比SIANN和具有较多个隐节点的BP网络更好的效果。GSINN网络具有更少的神经元数量和更简单的网络结构,这非常有利于网络在实际中的应用。另外,GSINN网络的效果取决于GSIN神经元分母分子激励函数的组合。不同的问题和网络结构需采用不同的激励函数。

5 结 论

本文将普通并联神经元进行了扩展,提出了一种GSIN神经元和GSINN网络,并给出了相应的学习算法。并通过基准测试问题的测试验证了它们的有效性。实验结果表明:(1)一个GSIN神经元、一个简单结构的GSINN网络就能解决一些往往需要很复杂网络结构的SIANN和BP网络才能解决的实际问题。(2)不同的激励函数组合会有不同的效果。对于不同的具体问题,应根据问题本身寻找最合适的激励函数以产生有效的决策边界。今后的工作,可以对更复杂的模式分类问题进行测试,并对GSINN进行进一步研究和推广。

参 考 文 献

- [1] Fukushima K, Miyake S, Ito T. Neocognitron: A neural network model for a mechanism of visual pattern recognition[J]. IEEE Transaction on Systems, Man and Cybernetics, 1983, 13(5): 826-834.
- [2] Carpenter G A, Grossberg S. The ART of adaptive pattern recognition by a self-organizing neural network[J]. IEEE Computer, 1988, 21(3): 77-88.
- [3] Bouzerdoum A. Classification and function approximation using feed-forward shunting inhibitory artificial neural networks[C]//In: Proceedings of the International Joint Conference on Neural Networks, Como, Italy, 2000: 613-618.
- [4] Arulampalam G, Bouzerdoum A. Expanding the structure of shunting inhibitory artificial neural network classifiers[C]//In: Proceedings of the International Joint Conference on Neural Networks, Honolulu, USA, 2002: 2 855-2 860.
- [5] Thimm G, Fiesler E. High-order and multiplayer perceptron initialization[J]. IEEE Transactions on Neural Networks, 1997, 8(2): 349-359.
- [6] University of California Irvine, CA-USA. UCI Repository of Machine Learning Databases[EB/OL]. In URL: <ftp://ftp.ics.uci.edu/pub/machine-learning-databases>, 2004-01-05.

编辑 漆 蓉