

文章编号: 1000-8152(2002)06-0940-05

RBPN 在模式识别研究中的应用*

韩 敏, 席剑辉, 程 磊

(大连理工大学 电子与信息工程学院, 大连 116023)

摘要: 基于 RBF(radial basis function)网络和感知器(perceptron)网络建立起一种新型四层前向神经网络——径向基感知器网络(RBPN, radial basis perceptron network). 该网络主要有以下特点: 1) 网络结构上, 两层隐层选择性连接; 2) 学习规则上, 采用同时考虑输入输出样本信息的 IOC(input-output clustering)聚类方法且聚类中心的形状参数 σ 自适应变化. 对材料成分分析领域的仿真结果表明, 该网络可成功地包含材料成分的构成信息, 实现精确分类, 并具有较高的泛化能力.

关键词: 神经网络; 模式识别; 输入输出聚类; 径向基感知器网络; 建筑材料
中图分类号: TP183 **文献标识码:** A

Applications of RBPN for pattern recognition

HAN Min, XI Jian-hui, CHENG Lei

(School of Electronic and Information Engineering, Dalian University of Technology, Dalian 116023, China)

Abstract: Based on radial basis function neural network (RBFN) and perceptron neural network, this paper built a new four-layer feed-forward neural network named radial basis perceptron network (RBPN). This network can be summarized as follows: 1) It is selective connection between the units of two hidden layers; 2) During learning procedure, RBPN adopts input-output clustering (IOC) method, and the appearance parameter σ of centers is self-adjustable. This is illustrated using an example taken from applications for component analysis of civil building materials. Simulation shows that RBPN can be used to predict the components of civil building materials successfully and gets good generalization ability.

Key words: artificial neural network; pattern recognition; IOC; RBPN; civil building materials

1 引言(Introduction)

人工神经网络(ANN)是利用输入输出数据实现特征提取和统计分类功能,从而完成非线性系统辨识.能一致逼近连续函数空间的最简单网络是感知器(perceptron)网络^[1],但它对样本空间线性不可分的系统具有局限性. BP 网络是一种普遍应用的网络,由于其采取了基于梯度下降的非线性优化策略,不可避免的陷入局部最优问题.其它一些优化策略如遗传算法^[2],模拟退火算法^[3]等,虽然可以获得全局最小,但计算量很大,效率较低. RBFN(radial basis function networks)^[4]在一定程度上克服了上述问题,它通过改变神经元非线性变换函数的参数实现非线性映射,从而导致连接权调整的线性化,既可保证全局收敛,又提高了学习速度.但 RBFN 的逼近能力是以隐层单元的数目为代价的.最初的 RBF 方法甚至要求用到所有的学习数据样本做隐层单元,而神经

网络为了达到较高的泛化能力,通常需要大量的学习样本,从而使隐层单元数目庞大,结构复杂,使得网络性能与网络结构之间构成了一组矛盾.所以在保持 RBFN 优点的同时,如何降低隐层单元数,简化网络结构是 RBFN 待研究的一个重要问题,尤其是针对大量经验样本数据的情况.

Chester^[5]从理论上解释了一种经验现象,即两层隐层网络比较一层隐层网络,可以达到更高的逼近精确度和更好的泛化能力,并且是建立在较少的隐层单元数的基础上.另外,在用 RBFN 进行模式识别时,由于其输出层是线性求和运算,不同类别之间会有一定程度的交叠,导致分类错误,而一些非线性函数如阈值函数可以有效的抵消这种交叠.因此,本文基于 RBFN 和感知器网络提出一种含有两层隐层的新型神经网络——径向基感知器网络(RBPN, radial basis perceptron network). 其第一隐层等同于 RBFN

* 基金项目:国家自然科学基金(50139020)重点项目资助.
收稿日期:2001-09-13; 收修改稿日期:2002-06-14.

的隐层,第二隐层等同于简单的单层感知器.当隐层的非线性参数确定后,RBPN 的输入输出之间与 RBFN 一样,成为一个线性方程组,权值学习可以采用 LS (linear least squares), RLS (the recursive linear least squares) 等线性方法.另一方面,因为 RBPN 比 RBFN 多了一层隐层,所以在确定隐层非线性参数即聚类过程中需要考虑新的方法.

聚类方法根据在聚类过程中是否考虑输出样本信息可分为 IC (input clustering) 和 IOC (input-output clustering) 方法.由于系统的信息是同时包含在输入输出样本中的,尤其是类别信息,在输出样本中能得到更多的体现,所以在聚类过程中只考虑输入信息,在很多情况下是不合理的^[6,7].本文 RBPN 采用 IOC 方法,对第一隐层,基于输入空间从输入样本中寻找典型样本作为该隐层聚类中心,对第二隐层,则基于输出空间从输出样本中寻找类别信息确定该隐层单元数目.两个隐层之间可以基于输出样本中的类别信息作选择性的连接,从而实现精确分类.下面第二节将详细描述 RBPN 的主要特征.第三节以 CaO-Al₂O₃-SiO₂ 三元系统为例进行仿真研究.第四节给出结论,并对一些待研究的问题进行讨论.

2 RBPN 描述 (Description of RBPN)

拓扑结构以及网络的学习和工作规则构成了神经网络的主要特征. RBPN 的主要特点如下:

1) 网络结构上,四层前向神经网络,隐层节点数在学习过程中动态确定,且两隐层之间选择性连接,连接准则基于输出空间而定;

2) 学习方法上,聚类过程采用同时考虑输入输出信息的 IOC 方法,且聚类中心的形状参数 σ 自适应变化,权值调整过程仍采用线性方法,LS 或 RLS.

2.1 RBPN 结构描述 (Structure description of RBPN)

RBPN 结构如图 1 所示, $x \in \mathbb{R}^n$ 为输入矢量, $y \in \mathbb{R}^L$ 为实际输出, $W = (\omega_1, \omega_2, \dots, \omega_M)^T$ 为输出层权值矩阵, $\omega_0 = (\omega_{01}, \omega_{02}, \dots, \omega_{0L})^T$ 为输出单元偏移量, c_i 是第 i 个 RBF 聚类中心, $t_j = f(\Phi_1(\cdot))$ 为第二隐层输入矢量, $a = (a_1, a_2, \dots, a_M)^T \in \mathbb{R}^M$ 为第二隐层阈值, $\Phi_1(\cdot)$ 为第一隐层径向基函数,通常取作 Gauss 函数,多二次函数等. $\Phi_2(\cdot)$ 为第二隐层传输函数,可取为 Heaviside 函数,线性函数等.设第一隐层第 i 节点的输出为 $\Phi_1(x, c_i)$,如果 $\Phi_1(\cdot)$ 为任意阶可微函数,则其在初值 x_0 处的泰勒级数展开为:

$$\Phi_1(x, c_i) = \Phi_1(x_0, c_i) + \left. \frac{d\Phi_1(x, c_i)}{dx} \right|_{x=x_0} (x - x_0) + \left. \frac{d^2\Phi_1(x, c_i)}{dx^2} \right|_{x=x_0} (x - x_0)^2 + \dots \quad (1)$$

所以,从网络第二隐层输入端来看,其第 j 个节点的输入 t_j 为整个网络输入模式的复杂多项式,第一隐层实现的是对模式空间的超曲面分割.同理,从网络输出端来看,第 j 个输出节点

$$y_j = \sum_{i=1}^M \omega_{ij} \Phi_2(t_i) + \omega_{0j} \quad (2)$$

t_i 由第一隐层输出得到,所以第二隐层的功能是对第一隐层的分界曲面组合.

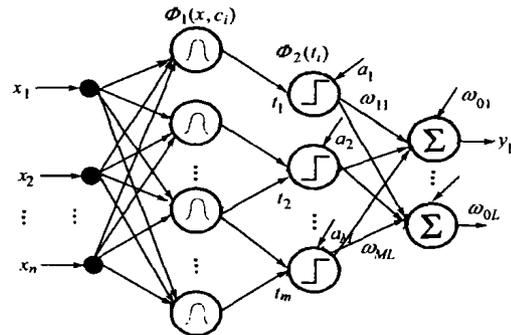


图1 RBPN结构

Fig. 1 Architecture of RBPN

综上所述,在模式分类的过程中,若能预知系统的类别信息,利用第二隐层对其进行线性划分,然后在属于每个类别的样本中寻找典型样本作为第一隐层的聚类中心,并且分别只与本类别相连,即通过第一隐层基于输入空间对每一类别超曲面分割,从而可以对每种类别都实现精确逼近.

2.2 RBPN 算法描述 (Algorithm description of RBPN)

由上所述, RBPN 结合了 RBFN 和感知器网络的特点,所以它所采纳的算法也应解决以下相应问题: 1) 网络结构设计,即确定两个隐层的节点数, RBF 聚类中心和形状参数; 2) 隐层之间的连接,即两个隐层之间的选择连接的准则; 3) 输出权值修正,可采用常用的 RLS, LS 等线性算法.下面将重点描述如何确定隐层参数及节点数,即聚类过程.

2.2.1 隐层节点数的选择及 RBF 聚类中心的确定

(Choose the number of units of hidden layers and define the RBF centers)

首先,本文网络基于输出空间对样本集内的任意一点进行模式识别,得到系统类别信息.设样本总数为 S , r 为可接受的样本间的最大距离, M_1, M_2 分别对应第一、第二隐层的节点数,具体步骤如下:

步骤 1 已知样本点 $(x^1, y(x^1))$, 令 $s = 1$, 设第二隐层的单元数 $M_2 = 1$, 并令 $z_1 = y(x^1)$;

步骤 2 设输入第 s 个样本点 $(x^s, y(x^s))$, 此时第二隐层单元数为 $M_2 = M$ 个, 计算

$$d_i = \min_j \|y(x^s) - z_j\|. \quad (3)$$

其中, $i = 1, 2, \dots, M$, 若 $d_i > r$, 则在第二隐层中添加一个隐单元, 并令 $z_{M+1} = y(x^s)$, $s = s + 1$, $M = M + 1$; 若 $d_i < r$, 则认为 x^s 属于第 i 类, $M^i = M^i + 1$, $s = s + 1$. 返回步骤 2. 若 $s = S$, 可认为样本的类别数为 M_2 , 进行步骤 3.

步骤 3 初始化网络第一隐层. 令 $M_1 = M_2 = M$, 且认为初时两隐层单元之间一一对应连接. 设矩阵 $H = [h_{ij}]_{M_1 \times M_2}$, $i = 1, \dots, M_1, j = 1, \dots, M_2$. 若 $h_{ij} = 1$, 说明第一隐层的 i 节点与第二隐层的 j 节点相连; 反之, $h_{ij} = 0$, 不相连. 初始化第一隐层的初始聚类中心为

$$c_i = \frac{1}{M^i} \sum_{x^s \in z_i} x^s, \quad (4)$$

$$\sigma_i = \alpha \cdot d_{im}, \quad (5)$$

$$d_{im} = \max_j \|x^s - c_i\|. \quad (6)$$

M^i 为属于 z_i 类的样本个数, σ_i 为聚类中心形状参数, d_{im} 为属于 z_i 类样本相对聚类中心的最大距离, α 为宽度系数, 可根据需要选取.

其次, 基于以上结果, 对每一类别, 在输入样本中寻找典型样本, 作为第一隐层的聚类中心. 选择 $\Phi_1(\cdot)$ 为 Gauss 函数, $\Phi_2(\cdot)$ 为 Heaviside 函数.

Step 1 网络初始条件如前所述, 令 $k = 1$;

Step 2 设网络学习进行到第 k 步, 利用现有网络参数根据式 (7), (8), (9), (10) 计算网络输出 $\hat{y}(x)$.

$$\hat{y}(x) = \omega_0 + \sum_{j=1}^{M_2} \omega_j \Phi_2(t_j), \quad (7)$$

$$\Phi_2(t_j) = \begin{cases} 1, & t_j > a_j, \\ 0, & t_j \leq a_j, \end{cases} \quad (8)$$

$$t_j = \max(\Phi_1(x, c_i) \times h_{ij}), \quad (9)$$

$$\Phi_1(x, c_i) = \exp\left\{-\frac{\|x - c_i\|^2}{2\sigma^2}\right\}, \quad (10)$$

$\|\cdot\|$ 表示 Euclidean 范数.

现定义网络的目标函数为

$$E_S = \frac{1}{2} \sum_{i=1}^L \sum_{s=1}^S \|y_i(x^s) - \hat{y}_i(x^s)\|^2. \quad (11)$$

计算 E_S , 判断其是否达到期望值, 若达到, 退出循环, 学习结束. 若没有达到, 根据 LS 方法调整权值. 计算 $\max \|y(x^s) - \hat{y}(x^s)\|$, 找出引起输出误差最大的一个样本 x^s , 按 2.2.2 算法调整引起此误差的聚类中心形状参数值.

Step 3 判断 x^s 是否已是聚类中心, 若已是, 令 $k = k + 1$, 返回 Step 2. 若不是, 将 x^s 作为一个新的聚类中心, 在第一隐层中添加一个隐单元, 并令 $c_{M_1+1} = x^s$, 在 H 阵中增加第 $M_1 + 1$ 行. 比较 $y(x^s)$ 与 $z_j, j = 1, 2, \dots, M_2$, 若 $x^s \in z_j$, 则将新增单元与第二隐层 j 单元相连, 令 $h_{M_1+1, j} = 1$; 否则, 不连接, 令 $h_{M_1+1, j} = 0$. 再令 $k = k + 1, M_1 = M_1 + 1$, 返回 Step 2.

由以上分析, 这种算法能同时实现网络结构和参数的调整, 在确定聚类中心的个数和参数的同时, 调整网络权值. 虽然增加了第二隐层, 但只是简单的映射运算, 对运算速度的影响不大, 所以该网络保持了 RBF 网络学习速度快, 避免局部极小等优点.

2.2.2 RBF 形状参数的自适应学习 (Adaptive learning of appearance parameter of RBF)

常用的 RBF 函数有 Gauss 函数, 多二次函数等, Gauss 函数如式 (10), 其三维拓扑图如图 2 所示, RBPN 第一隐层就是运用类似这样的超曲面分割模式空间. 从图中可以看出, 参数 σ 的选择对函数的拓扑分布影响极大, 从而对分类器的性能甚或收敛速度都有影响. σ 值较大, 则该隐节点能感受较大范围内的模式, 容错性好; σ 值较小, 容错性差, 但局部性好. 因此对不同系统, 要精心选择 σ , 尤其对复杂的不规则的系统, 有可能每个聚类中心的 σ 值都不一样, 这就需要 σ 根据样本数据特性, 自适应的变化.

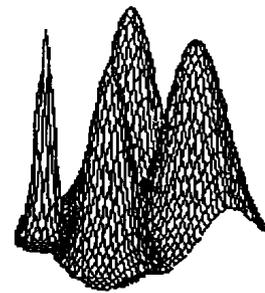


图 2 Gauss 函数的三维拓扑图

Fig. 2 Three dimensional topology of Gauss function

如果 $t_j = f(\Phi_1(\cdot)), \Phi_2(\cdot)$ 皆为光滑函数, 可采用自适应梯度下降法^[8] 调整 σ . 但实际问题中, $t_j, \Phi_2(\cdot)$ 并不一定都是光滑函数, 如式 (8), (9) 介绍的 Heaviside 函数和取最大值函数, 这时可改用一维搜索中的“成功-失败法”^[9] 调整 σ .

步骤 1 取定初始点 σ_0 , 搜索步长 $\lambda > 0$;

步骤 2 设网络学习到第 k 步, $\sigma_k = \sigma_{k-1} + \lambda$, 计算 $E_s(k)$;

步骤 3 若 $E_S(k) < E_S(k-1)$, 称为搜索成功, 进入 2.2.1 中的 Step3; 若 $E_S(k) \geq E_S(k-1)$, 则称搜索失败, 可令 $-\lambda \times \beta$ 代替 λ , 返回步骤 2, 继续搜索. β 为衰减系数, 可根据情况选取.

3 仿真 (Simulation)

神经网络应用于材料领域是利用神经网络对非线性函数的强逼近特性, 以及它不需要初始系统模型的特点^[10,11]. 在 $\text{CaO-Al}_2\text{O}_3\text{-SiO}_2$ 三元系统中, CaO , Al_2O_3 和 SiO_2 以不同比例结合, 在不同温度下, 可生成 15 种化合物. 最多是在三元无变点 (平衡点) 处可同时生成三种物质, 详细性质见表 1 所示. C 代表 CaO , A 代表 Al_2O_3 , S 代表 SiO_2 , 生成的物质可由 C, A, S 的组成比例唯一表示. 例如, C_2AS 表示 $2\text{CaO} \cdot \text{Al}_2\text{O}_3 \cdot \text{SiO}_2$, 即钙铝黄长石, 组成比例为 (2, 1, 1). 在其他非平衡条件下, 系统可生成一至两种物质, 参看 $\text{CaO-Al}_2\text{O}_3\text{-SiO}_2$ 图像^[12].

表 1 $\text{CaO-Al}_2\text{O}_3\text{-SiO}_2$ 三元无变点

Table Static points of $\text{CaO-Al}_2\text{O}_3\text{-SiO}_2$

相平衡关系	平衡温度 ($^{\circ}\text{C}$)	组成/(%)		
		CaO	Al_2O_3	SiO_2
1 $\text{L} \rightleftharpoons \text{磷石英} + \text{CAS}_2 + \text{A}_3\text{S}_2$	1345	9.8	19.8	70.4
2 $\text{L} \rightleftharpoons \text{磷石英} + \text{CAS}_2 + \alpha\text{-CS}$	1170	23.3	14.7	62.0
3 $\text{L} \rightleftharpoons \text{CA S}_2 + \text{C}_2\text{A S} + \alpha\text{-CS}$	1265	38.0	20.0	42.0
4 $\text{L} \rightleftharpoons \text{C}_2\text{A S} + \text{C}_3\text{S}_2 + \alpha\text{-CS}$	1310	47.2	11.8	41.0
5 $\text{L} + \alpha\text{-CS} \rightleftharpoons \text{C}_3\text{S} + \text{C}_2\text{A S}$	1315	48.2	11.9	39.9
6 $\text{L} + \text{C}_3\text{S} \rightleftharpoons \text{C}_3\text{A} + \alpha\text{-C}_2\text{S}$	1455	58.3	33.0	8.7
7 $\text{L} + \text{CaO} \rightleftharpoons \text{C}_3\text{S} + \text{C}_3\text{A}$	1470	59.7	32.8	7.5
8 $\text{L} \rightleftharpoons \alpha\text{-C}_2\text{S} + \text{C}_3\text{A} + \text{C}_{12}\text{A}_7$	1335	52.0	41.2	6.8
9 $\text{L} \rightleftharpoons \alpha\text{-C}_2\text{S} + \text{CA} + \text{C}_{12}\text{A}_7$	1335	49.5	43.7	6.8
10 $\text{L} + \text{C}_2\text{AS} \rightleftharpoons \alpha\text{-C}_2\text{S} + \text{CA}$	1380	48.3	42.0	9.7
11 $\text{L} \rightleftharpoons \text{C}_2\text{AS} + \text{CA} + \text{CA}_2$	1500	37.5	53.2	9.3
12 $\text{L} + \text{CA}_2 \rightleftharpoons \text{C}_2\text{AS} + \text{CA}_6$	1475	31.2	44.5	24.3
13 $\text{L} \rightleftharpoons \text{C AS}_2 + \text{C}_2\text{AS} + \text{CA}_6$	1380	29.2	39.0	31.8
14 $\text{L} + \alpha\text{-Al}_2\text{O}_3 \rightleftharpoons \text{CA}_6 + \text{CAS}_2$	1495	23.0	41.0	36.0
15 $\text{L} + \alpha\text{-Al}_2\text{O}_3 \rightleftharpoons \text{CA S}_2 + \text{A}_3\text{S}_2$	1512	15.6	36.5	47.9

在用神经网络建立这一模型时, 重点是输入变量和输出变量的选取. 由以上介绍, 设输入矢量为 $x = [x_1, x_2, x_3, x_4]$, $x_i (i = 1, 2, 3, 4)$ 分别代表系统温度及 C, A, S 的含量. 因为最多生成三种物质, 可设输出矢量为 $y = [y_{11}, y_{12}, y_{13}, y_{21}, y_{22}, y_{23}, y_{31}, y_{32}, y_{33}]$, 其中, y_{11}, y_{12}, y_{13} 分别表示形成的第一种物质的 C, A, S 的组成比例, y_{21}, y_{22}, y_{23} 对应第二种物质, y_{31}, y_{32}, y_{33} 对应第三种物质. 若生成物小于三种, 对应输出取零值. 这样, 网络可通过 C, A, S 的组成比例唯一表示出所形成的物质.

从 $\text{CaO-Al}_2\text{O}_3\text{-SiO}_2$ 图像^[12] 中选取 220 组数据, 其中 180 组用于训练网络, 40 组用于验证网络. 如图 3 所示, 相图的三条边分别代表 C, A, S 的含量, “+” 对应某一温度线上的样本点, 建模进行前, 将所有样本输入都归一化到 $[0, 1]$ 范围内. 几点说明:

1) 选择 $\Phi_1(\cdot)$ 为 Gauss 函数, $\Phi_2(\cdot)$ 为 Heaviside 函数, t_j 的表达式分别如 (8), (9), (10) 所示. $\alpha = 0.9, \alpha = 2.19$, 取值较大, 以保证在迭代开始时, 属于某一聚类的样本点都能被包含在内. 这样以后的学习误差可以认为主要是由某类别聚类误包含了其它类别的样本点引起的. 选用成功 - 失败法调整形状参数 σ 时, 只需适当减少 σ 值, 这样可以减少搜索时间, 提高学习速度. $\beta = 0.1$.

2) 同理, 在学习过程中, 为新添聚类中心的 σ 赋初值时, 也可以在属于同一类别的聚类中心中选取最大的 σ 值. 这样做的缺点是造成学习过程的振荡, 但可提高泛化能力.

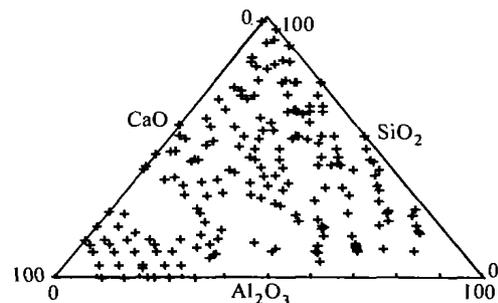


图 3 采集的样本

Fig. 3 The samples

图 4 给出了网络学习误差和校验误差图, 实线为学习误差, 虚线为校验误差, 横轴为学习次数. 可以看出, 该网络学习误差趋于零, 泛化误差也可以下降到一个较小的值.

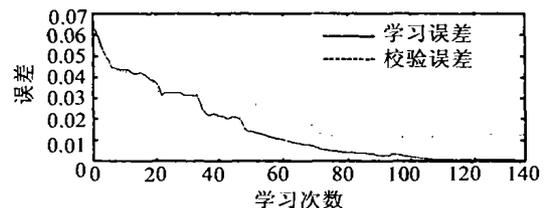


图 4 学习误差和校验误差曲线

Fig. 4 Curves of learning error and testing error

为了说明网络聚类中心形状参数的变化情况, 以 A_3S_2 (莫来石), CS (假硅灰石), C_2AS (钙铝黄长石) 为例, 记录它们最初的聚类中心的形状参数 σ 值的变化情况, 画于图 5. 可以看出, σ 的初值取得较大, 以求形成的割平面能够包含所有该类的样本点, 相应也会误包含其它类别的样本点, 产生误差. 这时就需通过减少 σ 值和增加聚类中心来减少误差.

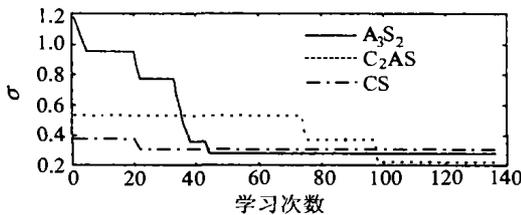


图5 自适应调整的 σ 值
Fig. 5 Self-adjustable σ

表2描述的是 σ 自适应变化和 σ 取常值两种情况的比较,期望学习误差统一为0.002.可以看出, σ 自适应变化时的校验率最高,而且对学习次数的影响不大. σ 不变时,它的取值大小对网络学习次数和校验误差有很大影响,但在实际系统中,要找到合适的 σ 十分困难.所以网络能根据具体情况自适应调整 σ 值,就能降低系统建模难度,并取得较好的结果.

表2 σ 为常值和 σ 自适应调整的学习次数和校验率
Table 2 Learning times and testing rate of networks with constant σ and self-adjustable σ

	σ 是常值				σ 自适应变化
	0.1	0.15	0.2	0.25	
学习次数	130	127	128	184	145
校验率	46.0%	56.8%	54.1%	67.6%	78.4%

4 结论(Conclusion)

本文提出了一种基于RBF网络和感知器网络的新型网络RBPN,将其应用于复杂的建筑材料成分分析系统,可以得到以下结论:

1) 本文所建网络采用两层隐层选择性连接来映射输入数据,实现精确分类,并可获得较高泛化能力.网络结构和网络参数同步调整,同时还保持了RBF算法学习速度快,不易陷入局部最小的优点.

2) 成功地分析了材料内部成分的构成,说明神经网络系统辨识作为逼近非线性系统的有效方法,可有效的应用于材料领域.

该网络也有一些问题值得讨论:

1) 聚类中心的确定采用引起误差最大的点,不一定能达到最佳结果,尚待改善.

2) σ 值自适应改变.本文 σ 值的变化采用了一维搜索方法,随着优化理论的发展,如何根据实际数据自适应改变 σ 值将是一个有趣的研究方向.

参考文献(References)

[1] Rosenblatt F. The perceptron: a probabilistic model for information

storage and organization in the brain [J]. Psychological Review, 1958, 65(1): 386 - 408

- [2] Cho Sung-Bae. Pattern recognition with neural networks combined by genetic algorithm [J]. Fuzzy Sets and Systems, 1999, 103(2): 339 - 347
- [3] González-Monroy Luis I, Córdoba Antonio. Optimization of energy supply systems with simulated annealing: continuous and discrete descriptions [J]. Physica A, 2000, 284(1, 4): 433 - 447
- [4] Powell M J D. Radial basis functions for multivariable interpolation: A review [A]. Proc. IMA Conf. Algorithms for the Approximation of Functions and Data [C]. Shrivvenham, U K, 1985
- [5] Chester D. Why two hidden layers are better than one [A]. IEEE Int. Joint Conf. on Neural Network [C]. San Diego, CA, USA, 1990, 265 - 268
- [6] Uykan Z, Güzelis C, Celebi Ertugrul M. Analysis of input-output clustering for determining centers of RBFN [J]. IEEE Trans. Neural Networks, 2000, 11(4): 851 - 858
- [7] Li Jiexing, Zhang Yun, Fu Xi. An improved closest cluster learning algorithm [J]. Control Theory and Applications, 2000, 17(5): 735 - 738 (in Chinese)
- [8] Huang Deshuang. Pattern Recognition System Theory of Neural Network [M]. Beijing: Electronic Industry Press, 1996 (in Chinese)
- [9] Tang Huanwen, Qing Xue-zhi. Practical Methods of Optimization [M]. Dalian: Dalian University of Technology Press, 2000 (in Chinese)
- [10] Han Min, Xi Jianhui, Wang Lijiu. Application of artificial neural networks for analyzing strength of concrete [J]. Journal of Architecture Material, 2001, 4(2): 192 - 195 (in Chinese)
- [11] Han Min, Xi Jianhui, Wang Lijiu. Component analysis of civil building materials using artificial neural networks [A]. Pro. of the 20th Chinese Control Conference [C]. Dalian, 2001, 2, 641 - 645 (in Chinese)
- [12] Wang Lijiu. The New Civil Building Material [M]. Beijing: China Electricity Press, 1997 (in Chinese)

本文作者简介

韩敏 1959年生,工学博士,大连理工大学电子与信息工程学院副教授.1982年毕业于大连理工大学电子系,1992年至1999年留学日本,获日本国立九州大学工学博士学位.目前承担国家自然科学基金重点项目中3S信息系统部分.参加国家重点基础研究发展计划(973)项目研究专题,及教育部科学技术重点项目等5个课题.研究方向为:神经网络,专家系统,3S系统及混沌序列分析.在国际国内会议及杂志上,共发表论文45篇.其中被EI,ISTP检索论文11篇次. Email: minhan@dlut.edu.cn

席剑辉 1975年生.1996年获北京航空航天大学自动控制系学士学位,2002年3月在大连理工大学电信学院获硕士学位并继续攻读博士学位,研究方向为神经网络系统辨识与混沌序列分析.

程磊 1979年生,2001年毕业于大连理工大学自动化系,现在大连理工大学自动化系攻读硕士学位.