

# 径向基函数(RBF)神经网络及其应用<sup>\*</sup>

王 炜<sup>1</sup>, 吴耿锋<sup>2</sup>, 张博锋<sup>2</sup>, 王 媛<sup>2</sup>

(1. 上海市地震局, 上海 200062; 2. 上海大学计算机学院, 上海 200072)

**摘要:** 介绍了径向基函数(RBF)神经网络的原理、学习算法及其在地震预报专家系统 ESEP 3.0 中的应用。实际应用结果表明, 该神经网络可以很好地克服 BP 神经网络学习过程的收敛过分依赖于初值和可能出现局部收敛的缺陷, 具有较快的运算速度、较强的非线性映射能力和较好的预报效能。

**关键词:** 径向基函数神经网络; BP 神经网络; 学习方法; 专家系统  
**中图分类号:** P315.7      **文献标识码:** A      **文章编号:** 1000-3274(2005)02-0019-07

## 引言

人工神经网络因其广泛的适应能力和学习能力在非线性系统的预测中得到广泛的应用。前馈型神经网络是人工神经网络中应用最为广泛的一种网络类型。目前, BP 神经网络在地震预报中得到较多的应用, 但是 BP 神经网络学习过程的收敛与初值密切相关, 并且学习过程还可能出现局部收敛, 这是实际应用中难点。径向基函数(RBF, Radial Basis Function)神经网络为一种性能良好的前馈型人工神经网络。它是基于人脑的神经元细胞对外界反应的局部性而提出的, 是一种新颖有效的前馈式神经网络, 具有较高的运算速度。特别是它的较强的非线性映射能力<sup>[1]</sup>, 能以任意精度全局逼近一个非线性函数, 使其在很多领域得到了广泛应用。

“十五”期间笔者完成了地震预报专家系统 ESEP 3.0<sup>[2]</sup>的研制。系统的学习和推理部分使用了径向基函数(RBF)神经网络。本文介绍了径向基函数神经网络的原理、学习算法及其在 ESEP 3.0 中的应用。实际应用结果表明, 该神经网络可以很好地克服 BP 神经网络的学习过程的收敛过分依赖于初值和可能出现局部收敛的缺陷, 具有较好的预报效能。

## 1 RBF 神经网络

RBF 神经网络通常具有三层的网络结构, 包括输入层、隐层、输出层, 网络模型的拓扑结构如图 1 所示。在 RBF 网络中, 隐层节点通过基函数执行一种非线性变化, 将输入空

<sup>\*</sup> 收稿日期: 2004 07 05; 修改回日期: 2004 09 22  
基金项目: “十五”科技部科技攻关项目(2001BA601B01 04 04)  
作者简介: 王炜(1947), 男, 江苏南京人, 研究员, 主要从事地震学、地震预报等研究。

间映射到一个新的空间, 输出层节点则在该新的空间实现线性加权组合<sup>[2]</sup>。RBF 网络中最常用的基函数是高斯函数, 即对于任意的输入向量  $X \in R^N$  ( $R^N$  为输入样本集), 它定义为:

$$R_i(x) = \exp[- \|X - C_i\|^2 / (2\sigma_i^2)] \quad i = 1, 2, \dots, Nr \tag{1}$$

式中,  $R_i(x)$  为隐层第  $i$  个单元的输出;  $X$  为  $N$  维输入矢量,  $X = \{X_p | X_p \in R^N, p = 1, 2, \dots, K\}$ ;  $C_i$  为隐层第  $i$  个单元高斯函数的中心点;  $\sigma_i$  为第  $i$  个隐节点的归一化参数, 即该隐节点的宽度;  $Nr$  为隐层的节点数;  $P$  表示样本数。




图 1 径向基函数神经网络结构

径向基函数神经网络的突出特点是, 隐含神经元的输出函数被定义为具有径向对称的基函数(即径向基函数), 而基函数的中心向量被定义为网络输入层到隐层的连接权向量。这个特点使得隐层对输入样本有一个聚类的作用。其中, 中心向量为类均值, 它的个数代表聚类的类数。这样, 由于基函数对输入激励产生一个局部化的响应, 仅当输入落在输入空间的一个很小的指定区域时, 隐单元才作出有意义的非零响应。

理论证明, 对于一个给定的非线性函数, 用径向基函数(RBF)神经网络可以以任意精度全局逼近它。而且重要的是, RBF 网络避免了输入层与隐层间反向传播的繁琐冗长的计算, 使学习可以比通常的 BP 神经网络快  $10^3 \sim 10^4$  倍。

## 2 RBF 神经网络中的学习方法

由于 RBF 神经网络中待确定的参数有二类: 基函数中心点、宽度以及网络的权值。因此, 网络的学习过程分为二步: 首先确定基函数的中心点和宽度, 其次是权值的学习。其中, 基函数中心点和宽度的确定是决定整个网络性能的关键。

RBF 网络学习方法主要有以下几种: ① Poggio 方法; ② Moody 和 Darken 方法; ③ 局部学习方法; ④ 正交最小二乘法; ⑤ 聚类与 Givens 最小二乘联合迭代法等<sup>[2]</sup>。

本研究采用类似于 Moody 和 Darken 的学习算法(M&D 算法)。Moody 和 Darken 的算法与 Poggio 法不同, 其隐含单元数目比训练样本数目少得多。整个训练过程分为非监督学习和监督学习二个阶段。非监督学习阶段采用 K means 聚类方法对训练样本的输入量进行聚类, 找出聚类中心  $C_i$  及参数  $\sigma_i$ , 然后进行监督学习阶段。由于当  $C_i$  及  $\sigma_i$  确定之后, RBF 网络从输入到输出就成了一个线性方程组, 因此监督学习阶段可以采用最小二乘法求解网络的输出权值  $w_i$ 。

由于 M & D 算法中的 K-Means 算法需要事先确定中心点的个数, 这将给并不一定熟悉神经网络的用户带来诸多不便, 若中心点个数确定得不妥则可能会对网络性能造成一定影响。因此本研究确定中心点的无监督聚类采用最近邻聚类算法(Nearest Neighbor Clustering Algorithm), 它不需要事先确定隐层神经元个数即可构建出理想的网络, 更加适应根据实时样本数据自动构建网络的要求。

最近邻聚类算法的具体过程如下:

(1) 选择一个适当的高斯函数宽度  $\delta$  定义一个矢量  $A(n)$  用于存放属于各类的输出矢

量之和; 定义一个计数器  $B(n)$ , 用于统计属于各类的样本个数, 其中  $n$  为类别数。

(2) 从第一个数据对  $(x_1, y_1)$  开始, 在  $x_1$  上建立一个聚类中心, 令  $c_1 = x_1$ ,  $A(1) = y_1$ ,  $B(1) = 1$ 。这时建立的 RBF 网络只有一个隐单元, 该隐单元的中心为  $c_1$ , 该隐单元到输出层的权矢量为  $w_1 = A(1)/B(1)$ 。

(3) 考虑第二个样本数据对  $(x_2, y_2)$ , 求出  $x_2$  到  $c_1$  这个聚类中心的欧氏距离  $|x_2 - c_1|$ 。如果  $|x_2 - c_1| \leq \delta$  则  $c_1$  为  $x_2$  的最近邻聚类, 且令  $A(1) = y_1 + y_2$ ,  $B(1) = 2$ ,  $w_1 = A(1)/B(1)$ ; 如果  $|x_2 - c_1| \geq \delta$  则将  $x_2$  作为一个新聚类中心, 并令  $c_2 = x_2$ ,  $A(2) = y_2$ ,  $B(2) = 1$ 。在上述建立的 RBF 网络中再添加一个隐单元, 该隐单元到输出层的权矢量为  $w_2 = A(2)/B(2)$ 。

(4) 假设考虑第  $k$  个样本数据对  $(x_k, y_k)$  时,  $k = 3, 4, \dots, N$ , 存在  $M$  个聚类中心, 其中心点分别为  $c_1, c_2, \dots, c_M$ , 在上述建立的 RBF 网络中已有  $M$  个隐单元。再分别求出到这  $M$  个聚类中心的距离  $|x_k - c_i|$ ,  $i = 1, 2, \dots, M$ , 设  $|x_k - x_j|$  为这些距离中的最小距离, 即  $c_j$  为  $x_k$  的最近邻聚类, 则: 如果  $|x_k - c_j| \geq \delta$  则将  $x_k$  作为一个新聚类中心, 并令  $c_{M+1} = x_k$ ,  $M = M + 1$ ,  $A(M) = y_k$ ,  $B(M) = 1$ , 且保持  $A(i)$ ,  $B(i)$  的值不变,  $i = 1, 2, \dots, M - 1$ 。在上述建立的 RBF 网络中再添加第  $M$  个隐单元; 如果  $|x_k - c_j| < \delta$  作如下计算:  $A(j) = A(j) + y_k$ ,  $B(j) = B(j) + 1$ 。当  $i \neq j$  时,  $i = 1, 2, \dots, M$ , 且保持  $A(i)$ ,  $B(i)$  的值不变。隐单元到输出层的权值矢量为  $w_i = A(i)/B(i)$ 。

在用最近邻算法得到网络的基函数中心等参数及初始权值后, 再用有监督学习算法调整隐层到输出层的权重, 算法步骤如下:

(1) 用  $\min\_max$  规范化方法, 使属性归一到网络的处理范围。设  $\min_A$ ,  $\max_A$  分别是属性  $A$  的最小和最大值, 通过计算下式将  $A$  的值  $v$  映射到区间  $[\text{new\_min}_A, \text{new\_max}_A]$  中得

$$v' = \frac{v - \min_A}{\max_A - \min_A} (\text{new\_max}_A - \text{new\_min}_A) + \text{new\_min}_A \quad (2)$$

(2) 用径向基函数计算中间层的输出  $Y_h$ 。

(3) 输出层第  $j$  个神经元的输出根据下式计算

$$Y_j = f \left( \sum_{i=1}^n W_{ji} \cdot Y_{hi} \right) \quad (3)$$

式中,  $Y_{hi}$  是隐层第  $i$  个神经元的输出值;  $W_{ji}$  是隐层第  $i$  个神经元至输出层第  $j$  个神经元的连接权;  $f$  取 sigmoid 函数  $f(x) = 1/(1 + e^{-x/x_0})$ 。

(4) 用  $\Delta Y_j = Y_j(1 - Y_j)(d_j - Y_j)$  计算输出层误差,  $d_j$  是第  $j$  个神经元的期望输出(期望输出矢量的第  $j$  个分量),  $Y_j$  是第  $j$  个神经元的实际输出。

(5) 按下式计算权值的调整量

$$\Delta W = \alpha \cdot \Delta Y \quad (4)$$

式中,  $\alpha$  是学习率。

(6) 权值的修正按下式用迭代法进行

$$W_j = W_j + \Delta W \quad (5)$$

### 3 RBF 神经网络在 ESEP 3.0 中的应用

在实际地震预报中, 前兆及地震学预报指标异常的持续时间和异常数量与未来地震震

级大小有一定关系。但是异常与地震之间有较强的不确定性, 同样一种预报指标或前兆在一些地震前可能出现很突出异常, 但在另一些地震前则可能不出现这些异常, 同样出现这些异常后其后也不一定发生中强以上地震。因此地震前异常时间及异常数量与未来地震震级之间具有较强的非线性关系, 它们很难通过某种解析表达式进行表达。而神经网络是一种高度自适应的非线性动力系统, 通过 RBF 神经网络的学习可以得到输入与输出之间的高度非线性映射, 建立起输入与输出之间的非线性关系。

地震预报专家系统 ESEP 3.0 中设计了二种根据地震异常估计未来地震震级的方法。其一为固定神经网络的输入、输出单元估计未来地震震级的方法。在这种情况下, 系统备有训练好的 RBF 网络。专家系统推理结束后, 如用户想了解神经网络对未来地震震级的推理结果, 则系统使用推理所用异常证据中的相关属性作为输入单元, 直接调用训练好的 RBF 神经网络对该地区的震级进行预测。其二为根据实际地震异常的种类及学习样本的情况, 首先确定神经网络结构, 进而估计未来地震震级的方法。这时系统将根据用户需要首先动态地构建 RBF 网络模型, 对选定的地震预报指标进行学习, 然后再用学习好的网络进行震级的预测。

### 3.1 固定输入、输出单元的 RBF 神经网络

由于异常的持续时间和种类多少与未来地震震级大小有一定关系, 系统设计了固定神经网络的结构估计未来地震震级的方法。系统将一些地震学和前兆项异常的持续时间  $T_i$  及其一些与未来地震震级有关的异常特征作为神经网络的输入单元, 网络的输出单元为未来地震震级。由于一次地震前某前兆观测项目可能出现多台异常( $j=1, 2, \dots, n$ ), 并且一项异常可能在孕震的不同阶段出现, 因此当某项前兆异常有多台出现时, 异常的持续时间  $T_i$  取其加权和为输入值。

$$T_i = \sum_j \omega_j t_{ij} \quad j = 1, 2, \dots, n \quad (6)$$

式中,  $t_{ij}$  为某台站前兆异常的持续时间。如果某台的某项异常在中期、短期或临震三个阶段都有异常(在震例或异常文件中算作三次异常), 则取异常开始至发震的时间段为  $t_{ij}$ ; 如果在二个阶段中都有异常, 则取其二个异常时段的时间之和为  $t_{ij}$ ,  $\omega_j$  为权值。

$$\omega_j = t_{ij} / \sum_j t_{ij} \quad (7)$$

在固定输入、输出单元的 RBF 神经网络情况下, 系统备有学习好的 RBF 神经网络。ESEP 3.0 的震例库中存放了《中国震例》<sup>[3~9]</sup>一书中的 100 多个中强以上地震震前异常, 该网络根据系统震例库中有关属性的样本数量, 选取对震级影响较大并且样本较多的 17 个属性进行学习。如用户想参考神经网络推理结果, 则系统可直接调用学习好的 RBF 神经网络对该地区的震级进行预测, 给出相应预测结果。这 17 个异常属性分别为:

(1) 异常的异常持续时间。流动重力异常; 流动水准; 宏观地震异常(动物、地下水等); 钻孔应力、应变观测; 地下水位或水流量; 水氡; 视电阻率; 短水准、基线等跨断层形变测量; 地震波速比  $V_p/V_s$ ;  $b$  值时间扫描; 地震频次; 地震应变释放曲线  $\sum \sqrt{E} \sim t$ ; 孕震空区持续时间; 异常地震条带。

(2) 其他异常特征。地震频次增高异常的起始震级; 孕震空区的长轴; 震前的异常数量; 本文选取系统震例库中异常相对较多的 43 个震例的震前异常作为学习样本(由于篇幅有限, 具体震例略)。当某项前兆异常有多台出现, 并且一项异常可能在多台及其孕震的不

同阶段出现时, 异常持续时间  $T_i$  按式(6)、式(7)计算得到。神经网络训练完成后, 使用该网络对其他的 30 个待检验样本进行外推检验, 结果如表 1 所示。由表 1 中可见, 如果取  $|\Delta M| \leq 0.5$  为预报正确, 除 1987 年迭部地震、1989 年大同地震、1993 年普洱地震和 1995 年苍山地震外, 其他 26 个地震全部预测正确, 外推检验正确率为  $26/30 = 0.87$ 。这表明 RBF 神经网络具有较好的预测效果。

表 1 用固定结构的 RBF 网络进行外推检验结果

地震	溧阳	海城	和林格尔	龙陵	巴音木仁	溧阳	丰镇	景泰	菏泽	南黄海
地震时间	1974 04 22	1975 02 04	1976 04 06	1976 05 29	1976 09 23	1979 03 02	1981 08 13	1990 10 20	1983 11 07	1984 05 21
震级( $M_s$ )	5.5	7.4	6.4	7.4	6.2	6.0	5.8	6.2	5.9	6.2
预测值	5.49	7.01	6.18	7.29	5.75	5.67	5.54	5.73	5.89	6.16

地震	灵武	禄劝	迭部	射阳	肃南	大同	常熟	海原	阿拉善	嘉峪关
地震时间	1984 11 23	1985 04 18	1987 01 08	1987 02 17	1988 11 22	1989 10 19	1990 02 10	1982 04 14	1991 06 16	1992 01 12
震级( $M_s$ )	5.3	6.3	5.9	5.1	5.7	6.0	5.1	5.5	5.3	5.4
预测值	5.61	6.01	5.16	5.22	5.33	7.08	5.50	5.60	5.56	5.57

地震	祁连	普洱	青海共和	台湾海峡	北部湾	乌苏南	永登	苍山	丽江	南黄海
地震时间	1992 06 21	1993 01 27	1994 09 04	1994 09 16	1994 12 31	1995 05 02	1995 07 22	1995 09 20	1996 02 03	1996 11 09
震级( $M_s$ )	5.0	6.3	5.2	7.3	6.1	5.5	5.8	5.2	7.0	6.1
预测值	5.26	5.32	5.27	6.94	6.22	5.37	6.22	6.90	6.92	6.36

3.2 样本数据的动态采集及网络的动态构建

在前述固定输入、输出单元的 RBF 神经网络中, 网络的输入、输出元维数是固定的。而在实际预报中, 上述 17 个输入元的异常并不是在所有震例中都有, 可能有相当多的神经元在实际资料中没有。这样在网络学习和外推时只能对这类没有实际异常数据的输入神经元赋予 0 值, 而这样往往是不合理的。因此在本系统中建立了一种动态的构建 RBF 网络的机制, 用户可根据实际异常资料中异常的样本数量情况, 动态地构建 RBF 网络结构。也就是说, RBF 网络的输入、输出神经元及其维数是由用户选择的, 从而通过学习可以较为合理的预测。

该系统根据不同的异常证据文件, 首先通过人机交互由用户从异常证据文件中选出一些与未来地震震级有关的属性作为神经网络的输入神经元, 然后系统将从震例库中检索出各次地震震例中相应的属性值, 选择出现频率较高的异常属性生成供神经网络学习的样本数据。例如, 唐山震例文件中的异常项目有孕震空区、地震频次等异常项目 31 个, 用户可以从震例库中选择这 31 个项目中的异常时间属性作为可能的神经网络输入元。在此基础上, 系统还将列出这 31 个项目的“异常时间”属性在整个震例库的各次震例中出现的频率。用户可以选择一些异常属性出现频率较高(即样本较多)的属性, 然后经过式(6)、式(7)计算, 形成神经网络学习的样本。通过神经网络学习后, 系统可根据当前的推理证据文件中的属性作为输入样本, 使用 RBF 网络推理得到相应的预测地震震级。

神经网络的构建基于用户所选的与当前出现的异常相关的样本数据, 滤去很多无关的预报指标, 由样本数据驱动网络模型的构建。这样做一方面使网络的构建更为灵活, 构建出的网络结构更加精简; 另一方面, 也使网络学习到的知识更有针对性(专门针对当前出现的异常情况), 从而使基于知识的推理预测更为合理。

以唐山地震为例, 根据《中国震例》<sup>[3~9]</sup> 中唐山地震前出现的异常时间属性对唐山地震的震级做出预测。唐山地震前共有 31 个异常项目, 分别为: ① 地震频次(51.9%); ②

水氡(51.2%);③孕震空区(46.9%);④地下水位(43.6%);⑤宏观地震异常(41.9%);⑥*b*值时间扫描(36.9%);⑦视电阻率(35.6%);⑧短水准(33.8%);⑨异常地震条带(31.3%);⑩钻孔应力(26.9%);⑪定点地磁场(21.9%);⑫应变释放曲线(20.0%);⑬气氡(19.4%);⑭地震波速比(17.5%);⑮其他前兆预报指标(16.3%);⑯其他地震学异常(12.5%);⑰流动重力异常(11.9%);⑱*b*值空间扫描(9.4%);⑲区域震群(9.4%);⑳长水准(7.5%);㉑地震活动增强(7.5%);㉒地磁低点位移(6.9%);㉓其他(<5%)…,(括号中的数字是各异常项目在震例库的震例中出现的频率)。

根据唐山地震前的各项异常在震例库中出现频率,选择不同的异常项目分别从震例库中选择出其他震例的相应异常,构建不同的学习样本。通过网络学习后,使用唐山地震前出现的异常进行外推检验的情况如下(表2)。表中的缺失率为震例库中各地震震例无该组异常所占比例。

表2 不同网络输入神经元学习预测情况

序号	输入节点数	所选异常项目	样本数	缺失率(≤%)	震级( <i>M<sub>s</sub></i> )	预测震级( <i>M<sub>s</sub></i> )
1	5	①②③④⑤	31	20	7.8	7.60
2	8	①②③④⑤⑥⑦⑧	17	20	7.8	7.56
3	11	①②③④⑤⑥⑦⑧⑨⑩⑪	28	40	7.8	7.76
4	16	①②③④⑤⑥⑦⑧⑨⑩⑪⑫⑬⑭⑮⑯	13	40	7.8	7.72
5	16	①②③④⑤⑥⑦⑧⑨⑩⑪⑫⑬⑭⑮⑯	28	50	7.8	7.73
6	20	①②③④⑤⑥⑦⑧⑨⑩⑪⑫⑬⑭⑮⑯⑰⑱⑲⑳㉑㉒㉓	13	50	7.8	7.74

注:为试验方便对所选项目均取了异常持续时间属性作为地震预报指标,实际应用中也可取其他有代表性的异常项目属性,如孕震空区可取空区长轴作为指标。

由表2可以看到,对不同的样本组合,构建不同的网络学习后,预测震级与实际震级误差  $\Delta M \leq 0.2$ , 预测检验结果较为理想。

4 结论

人工神经网络因其广泛的适应能力和学习能力,在非线性系统中的预测中得到广泛的运用。径向基函数(RBF)神经网络是基于人脑的神经元细胞对外界反应的局部性而提出的,是一种新颖、有效的前馈式神经网络。由于该网络的输出层是对隐层的线性加权,使得网络避免了像BP神经网络反向传播那样繁琐冗长的计算,从而使网络具有较快的运算速度和较强的非线性映射能力。同时,它还克服了学习收敛对初值的依赖性,具有最佳逼近性能和全局最优的特征<sup>[1]</sup>。因此从总体上来说,径向基函数(RBF)神经网络的性能要优于BP神经网络。

本文的结果是径向基函数(RBF)神经网络在地震预报中的初步应用。实际应用结果表明,该方法具有十分理想的预测效果,在地震预报中具有广泛的应用前景。

参考文献:

[1] 王炜,吴耿锋,张博锋,等.地震预报专家系统ESEP 3.0[J].中国地震,2004,20(2):124-133.  
[2] Robert J, Schilling James, Carroll J. Approximation of nonlinear systems with radial basis function neural network[J]. IEEE TRANSACTIONS ON NEURAL NETWORKS, 2001, 12(1): 21-28.

- [ 3] 张肇诚, 罗兰格, 李海华, 等. 中国震例( 1966 ~ 1975) [ M] . 北京: 地震出版社. 1988.
- [ 4] 张肇诚, 罗兰格, 李海华, 等. 中国震例( 1976 ~ 1980) [ M] . 北京: 地震出版社. 1990.
- [ 5] 张肇诚, 罗兰格, 李海华, 等. 中国震例( 1981 ~ 1985) [ M] . 北京: 地震出版社. 1990.
- [ 6] 张肇诚, 郑大林, 徐京华, 等. 中国震例( 1986 ~ 1988) [ M] . 北京: 地震出版社. 1999.
- [ 7] 张肇诚, 郑大林, 徐京华, 等. 中国震例( 1989 ~ 1991) [ M] . 北京: 地震出版社. 2000.
- [ 8] 陈棋福, 郑大林, 车时, 等. 中国震例( 1992 ~ 1994) [ M] . 北京: 地震出版社. 2002.
- [ 9] 陈棋福, 郑大林, 刘桂萍, 等. 中国震例( 1995 ~ 1996) [ M] . 北京: 地震出版社. 2002.
- [ 10] XU Xiao han, WANG Qing yin. Emergence of uncertainty information and its classification[ M] . Proceeding of SCT94, 武汉: 华中理工大学出版社, 1994. 679 682.

## Neural networks of radial basis function ( RBF) and it's application to earthquake prediction

WANG Wei<sup>1</sup>, WU Geng feng<sup>2</sup>, ZHANG Bo feng<sup>2</sup>, WANG Yuan<sup>2</sup>

( 1. Earthquake Administration of Shanghai Municipality, Shanghai 200062; 2. Computer Institute of shanghai University, Shanghai 200072, China)

**Abstract:** the principle and algorithm of neural networks of Radial Basis Function ( RBF) and its application to the expert system for earthquake prediction ( ESEP 3. 0) are introduced in this paper. The actual application in earthquake forecast shows that the neural networks can overcome some demerit of BP neural networks in leaning process, the constringency excessively depend on initial value and optimization constringency and often can't appear. The RBF neural networks possess the rapid operation speed in learning and strong nonlinear mapping ability and very good efficiency.

**Key words:** Neural networks of radial basis function; BP neural networks; Learning method; Expert system