

# 多层反馈神经网络的FP学习和综合算法\*

张 铃

张 钺

(安徽大学人工智能研究所 合肥 230039)

(清华大学计算机系 北京 100084)

(智能技术与系统国家重点实验室 北京 100084)

**摘要** 本文给出多层反馈神经网络的FP学习和综合算法,并讨论此类网络的性质,指出将它应用于聚类分析能给出不粒度的聚类,且具有收敛速度快(是样本个数的线性函数)、算法计算量少(是样本个数和输入、输出维数的双线性函数)、网络元件个数少、权系数简单(只取3个值)、网络容易硬件实现等优点.作为聚类器的神经网络的学习和综合问题已得到较圆满地解决.

**关键词** 多层反馈神经网络,学习算法,聚类.

**中图分类号** TP18

众所周知,从应用观点来看,神经网络的最主要功能为:①作为联想记忆器,②作为分类器,③用于求优化的解.但至今尚无有效地、快速地使所得到的网络具有良好性能的神经网络的学习算法.我们在文献[1]中讨论了多层前馈网络的FP学习和综合算法,指出用此法得到的网络是一个极好的通用联想记忆器.但是当给定具体的样本集时,按FP算法得到的网络的元件个数往往有过多的隐层元,于是对一给定的样本集的情况下,如何求性能好、规模小的网络的问题仍需研究.

本文将转来讨论多层反馈神经网络的FP学习和综合算法,将证明所得到的网络作为分类器(聚类分析器),具有计算量少、收敛速度快、元件个数少、网络性能好等优点.

## 1 作为聚类分析器的神经网络

### 1.1 问题的提出

聚类分析问题:设在 $N$ 维空间中,给定一有限点集 $K = \{x^0, x^1, x^2, \dots, x^p\}$ ,再给出一个量度相似性的函数 $D(x, y)$ 和一个相似度阈值 $d$ .要求将 $K$ 进行分类并满足下面2个条件:

- 将 $K$ 分成子类 $\{K_1, K_2, \dots, K_m\}$ ,要求这些子类构成 $K$ 的一个划分.
- 若 $D(x, y) > d, x, y \in K$ ,则 $x$ 和 $y$ 属于同一类.

为了使神经网络能实现聚类的功能,将 $K$ 中的各元素作为一组输入,即将 $K$ 作为样本

\* 本文研究部分得到国家攀登计划基金和国家自然科学基金资助.作者张铃,1937年生,教授,主要研究领域为人工智能理论,人工神经网络理论,应用数学.张钺,1935年生,教授,博士生导师,中国科学院院士,主要研究领域为人工智能,计算机应用技术.

本文通讯联系人:张铃,合肥 230039,安徽大学人工智能研究所

本文1996-04-16收到修改稿

集,然后对网络进行学习,使经过学习后的网络,能完成分类的功能,即分在同一类中元素有相同的输出,并满足聚类的 2 个条件.

对于神经网络,通常我们取  $D(x, y) = \langle x, y \rangle$  为相似性函数,  $\langle \langle x, y \rangle$  表  $x$  与  $y$  的内积).

## 1.2 FP 算法简介

我们将利用文献[1]中提出的 FP 算法来解上述问题,下面简单介绍一下 FP 算法的一些本文将用到的性质.

作  $p$  个  $(p-1)$  维向量如:  $z^0 = (-1, -1, \dots, -1)^T, z^1 = (+1, -1, \dots, -1)^T, \dots, z^{p-1} = (-1, -1, \dots, +1)^T$ .  $y, z$  向量各分量取值  $\{-1, 1\}$ .

性质 1. 任给  $p$  个  $m$  维输出向量  $\{y^0, y^1, \dots, y^{p-1}\}$ , 则存在  $m \times (p-1)$  维权矩阵  $U$  和阈值向量  $\xi$ :

$$\text{即 } u_j = \frac{y_i^j - y_i^0}{2} \quad i=1, 2, \dots, m; j=1, 2, \dots, p-1. \quad (10)$$

$$\xi_i = -(y_i^0 + u_i^1 + \dots + u_i^{p-1})$$

$$\text{使得 } y^j = G(z^j), \quad j=0, 1, \dots, p-1.$$

$$\text{即 } y^j = \text{Sgn}(U * z^j - \xi_j)$$

## 2 多层反馈神经网络的 FP 学习和综合算法

### 2.1 总的思路

(1) 利用内积作为相似性函数; (2) 利用 FP 学习算法对待分类的集合进行预分类; (3) 利用反馈网络的反馈作用完成最后的分类.

### 2.2 网络线路的设计

整个网络线路如图 1. 其中第 1 元件层  $N_1$ , 有  $p$  个元件, 其权矩阵和阈值向量分别为  $W(1), \theta(1)$ , 其对应的关系为  $F$ . 第 2 元件层  $N_2$ , 有  $m$  个元件, 其权矩阵和阈值向量分别为  $W(2), \theta(2)$ , 其对应的关系为  $G$ . 反馈元件层  $N_3$ , 有  $n$  个元件, 其权矩阵和阈值向量分别为  $W(3), \theta(3)$ , 其对应的关系为  $B$ .

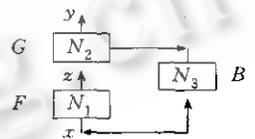


图1

在本文中设神经元  $A$  有  $n$  个输入和一个输出, 其对应关系为

$$y = \text{Sgn}(x) \quad \text{Sgn}(x) = \begin{cases} +1, & x > 0, \\ -1, & x \leq 0 \end{cases}$$

### 2.3 各层元件的学习和综合

我们按照 FP 算法的原则, 从后向前逐层确定各层元件的个数和各元件的权和阈值.

#### A. 第 1 元件层的学习和综合

设样本集为  $K = \{x^0, x^1, \dots, x^p\}$ ,  $x^i$  是  $n$  维单位向量(一般可设  $x^i$  具有相同的模)以  $x$  为输入向量, 其对应的输出向量为  $z$  ( $z$  是  $p$  维向量, 其分量取值于  $\{-1, 1\}$ ).

$$z = F(x)$$

$$\text{令 } d_i = \max\{\langle x^i, x^j \rangle, i \neq j, i=0, 1, \dots, p\}.$$

取  $D(x, y) = \langle x, y \rangle, \forall x, y \in K$ , 为相似性函数

给定相似性阈值为  $d$  ( $d < 1$ , 显然, 当  $d \geq 1$  时, 所有样本都被分成不同的类).

作权矩阵 
$$W^i(1) = (x^i)^T, i = 1, 2, \dots, p.$$

$$\theta_i(1) = d, \quad i = 1, 2, \dots, p. \tag{1}$$

则有下面命题成立.

**命题 1.** 设  $F$  是第 1 元件层  $N_1$  的对应关系, 按(1)式定义的权矩阵和阈值, 则有

(i) 若  $\langle x^i, x^j \rangle > d$ , 则  $z^i = F(x^i)$  和  $z^j = F(x^j)$  的第  $i$ , 第  $j$  分量均为 1.

(ii)  $\forall i$ , 均有  $z_i^i = 1$

(iii) 若  $d_i < d$ , 则  $z^i = F(x^i) = (-1, -1, \dots, -1, +1, -1, \dots, -1)$ , 即  $z$  的第  $i$  个分量为 +1, 其余分量为 -1.

证明: 由  $\langle x^i, x^j \rangle > d$ , 及(1)得  $\langle x^i, x^j \rangle > d = \theta_i(1)$ ,

得 
$$z_i^i = F_i(x^i) = \text{Sgn}(\langle w^i, x^i \rangle - \theta_i(1)) = \text{Sgn}(\langle x^i, x^i \rangle - \theta_i(1)) = 1,$$

同理得 
$$z_j^j = F_j(x^j) = \text{Sgn}(\langle w^j, x^j \rangle - \theta_j(1)) = 1.$$

故(i)式得证.

显然, 对一切  $i$  有  $z_i^i = F_i(x^i) = \text{Sgn}(\langle w^i, x^i \rangle - \theta_i(1)) = \text{Sgn}(1 - \theta_i(1)) = 1.$

故(ii)式得证.

若  $d_i < d$ , 对任意  $j \neq i$ , 有  $\langle x^i, x^j \rangle \leq d_i < d = \theta_i(1)$

故有 
$$z_j^i = F_j(x^i) = \text{Sgn}(\langle w^j, x^i \rangle - \theta_j(1)) = -1.$$

(iii)式得证.

命题 1 说明: 若  $x^i$  与样本中其它的点的内积均小于  $d$ , 则  $z^i = F(x^i) = (-1, -1, \dots, +1, -1, \dots, -1)$ , 即  $z$  的第  $i$  个分量为 +1, 其余分量为 -1.

若  $x^i$  与样本中某些的点的内积大于  $d$ , 则  $z^i = F(x^i)$  的分量至少有 2 个分量为 1, 故第 1 元件层完成了区别各样本的相似性是否大于  $d$  的作用.

### B. 第 2 元件层的学习和综合

设第 2 层有  $p$  个元件, 其输入向量为  $z$ , 输出向量为  $y$ , 其对应关系为  $G$ .

作权矩阵 
$$w_j^i(2) = \begin{cases} -1, & \text{当 } j < i. \\ 1, & \text{当 } j = i. \\ 0, & \text{当 } j > i. \end{cases}$$
 阈值向量 
$$\theta_i(2) = (i-1) \tag{2}$$

则有如下命题

**命题 2.** 按(2)式定义第 2 层的权矩阵和阈值向量, 则第 2 元件层的对应关系  $G$  满足如下性质:

令  $e^0 = (-1, -1, \dots, -1)^T, e^1 = (+1, -1, \dots, -1)^T, \dots, e^p = (-1, -1, \dots, +1)^T.$

(i) 若  $z^i$  至少有 2 个分量为 1, 设  $z^i$  第 1 个为 1 分量的下标为  $k(i)$ , 则有  $G(z^i) = e^{k(i)}$

(ii) 若  $z^i$  只有第  $i$  个分量为 1, 则有  $G(z^i) = e^i$

(iii) 若  $z^i$  的所有分量均为 -1, 则有  $G(z^i) = e^0$

证明: 设  $z^i$  的第  $k(i)$  ( $k(i) < i$ ) 个分量为 1, 由  $W(2)$  的定义知:

当  $t = i$  时,  $\sum_j w_j^i(2) z_j^i - \theta_i(2) \leq (k(i) - 1) - 1 + (i - k(i) - 1) + 1 - (i - 1) = -1,$

即  $y_i^i = -1.$

当  $t > i$  时,  $\sum_j w_j^i(2) z_j^i - \theta_i(2) \leq (k(i) - 1) - 1 + (t - k(i)) - (t - 1) = -1,$

即  $y_i^t = -1$ .

当  $t = k(i)$  时,  $\sum w_j^t(2)z_j^t - \theta_i(2) \geq (k(i) - 1) + 1 - (k(i) - 1) = 1$ ,

即  $y_{k(i)}^t = 1$ .

当  $t < k(i)$  时,  $\sum w_j^t(2)z_j^t - \theta_i(2) = (t - 1) - 1 - (t - 1) = -1$ ,

即  $y_i^t = -1$ .

当  $k(i) < t < i$  时,  $\sum w_j^t(2)z_j^t - \theta_i(2) \leq (k(i) - 1) - 1 + (t - k(i)) - (t - 1) = -1$ ,

即  $y_i^t = -1$ .

综合上述得  $G(x^i) = e^{k(i)}$

(ii)、(iii)类似可证.

由命题 2 可知,任给 2 个输入,若其相似度大于相似度阈值  $d$ ,则经过两层元件的映射均被映射到同一类的输出,故聚类分析的第 2 个条件已经基本满足.

即设固定  $x^i$ ,设与  $x^i$  内积大于  $d$  的  $x^j$  的最小上标为  $k(i)$ ,则有

$$G(F(x^i)) = (-1, -1, \dots, +1, \dots, -1) = e^{k(i)}$$

即  $G(F(x^i))$  的第  $(k(i))$  个分量为  $+1$ ,其余分量均为  $-1$ .

另一方面,我们知道,给定集合的一个划分就给出一个等价关系,而等价关系必须满足传递律,故单单  $N_1$ 、 $N_2$  两个元件层还不能完成聚类分析的任务,为此我们再加上一个反馈层,利用反馈层来完成等价关系的传递律.

### C. 反馈层的学习和综合

设反馈层有  $n$  个元件,其输入向量为  $y$ ,输出向量为  $x$ ,即反馈到  $N_3$  层的输入.

由命题 2 知,当输入  $\{x^0, x^1, \dots, x^p\}$  时,其对应的输出  $\{y^0, y^1, \dots, y^p\}$ . 则  $\{y^0, y^1, \dots, y^p\}$  是  $\{e^0, e^1, \dots, e^p\}$  的子集.

由性质 1,以  $\{y^0, y^1, \dots, y^p\}$  和  $\{x^0, x^1, \dots, x^p\}$  为  $N_3$  层的输入、输出. 并且有

$$x^i = B(e^i), i = 0, 1, \dots, p.$$

的权、阈值的网络是存在的,下面证明这样网络即可完成等价关系的传递律.

命题 3. 以  $y$  和  $x$  为  $N_3$  层的输入和输出,作权矩阵和阈值向量如下

$$w_j^i(3) = \frac{x_i^j - x_i^0}{2} \quad \theta_i(3) = -(x_i^0 + \sum_j w_j^i(3)). \quad (3)$$

则有  $x^i = B(e^i), i = 1, 2, \dots, n; j = 1, 2, \dots, p.$

证明:由性质 1 直接得.

## 2.4 网络性能的分析

本节将证明按照命题 1~3 构造的网络能完成聚类的任务.

当给定相似度阈值  $d$ ,称满足聚类分析条件(A)、(B)的聚类分析为相似度为  $d$  的聚类分析.

先介绍称之为最大树聚类分析方法(见文献[2]).

设  $N$  维空间有一点集  $K = \{x^0, x^1, \dots, x^p\}$ ,设  $x^i$  与  $x^j$  的相似度为  $d_{ij}$  ( $d_{ij} = d_{ji}$ ),给定  $d$ ,则相似度为  $d$  的聚类可由下面方法完成.

设所有大于  $d$  的  $d_{ij}$  按大小,从大到小排列,记为  $\{d_{ij}(1), d_{ij}(2), \dots, d_{ij}(k)\}$ . 依次将以对应于  $d_{ij}(t)$  的  $x^i, x^j$  用边相连,若到某步在其之前没有出现回路,而连上边  $e$  时就出现回

路,则跳过  $e$  边不相连,再继续上述步骤,直至所有  $d_{ij}(t)$  都连完为止. 这样得到的图中的每个连通成分即是分类的一个子类.

下面证明我们的网络能完成上述的算法.

**定理.** 给定样本集  $K = \{x^0, x^1, \dots, x^p\}$  及相似度阈值  $d$ , 若按公式(1), (2), (3)公式分别定义  $N_1, N_2, N_3$  各层的权和阈值, 则图 1 网络构成相似度为  $d$  的聚类器.

证明: 这只要证明同一子类的元素当网络运行达到稳定状态时, 其对应的输出是相同的, 反之, 不同子类的元素, 其对应的输出是不同的.

不妨设子类  $K_1 = \{x^{i_1}, x^{i_2}, \dots, x^{i_t}\}$ , (设  $i_1 \leq i_2 \leq \dots \leq i_t$ ). 下面证明至多经过  $(p-1)$  步,  $K_1$  中的元素对应的输出均相同(即对应于  $x^{i_1}$  的输出).

由命题 1、2 得: 经过  $N_1, N_2$  元件层运行一步后,  $x^{i_1}, x^{i_2}, \dots, x^{i_t}$  的不同输出至多只有  $(t-1)$  个(因为  $x^{i_t}$  的输出必与某个  $x^{i_h}$ , ( $t > h$ ) 的输出相同). 再经过反馈层将子类对应的  $y$  又映到  $X$  对应的子类的某个子集上. 这样经过一个循环, 子类元素的不同输出个数至少减少一个, 故至多经过  $(t-1)$  步,  $K_1$  必被映到同一输出上. 之后,  $K_1$  子类就稳定在这个状态上.

再由, 最大树聚类法所分的各连通子类是互不相同的, 故不同的子类被映到不同的输出上. 因为不然的话, 设有两子类  $K_1, K_2$  被映到某同一输出  $y$  上, 设到某步  $K_1$  中的  $x^{i_1}$  和  $K_2$  中的  $x^{j_2}$  被映到同一输出  $y$  上, 这只有 2 种可能, 一是在通过  $N_1$  和  $N_2$  层时,  $x^{i_1}$  和  $x^{j_2}$  被映到同一输出上, 这只有当 2 个输入的相似度大于  $d$  时才发生, 但是因为  $K_1$  与  $K_2$  是不连通的, 故得  $x^{i_1}$  与  $x^{j_2}$  的相似度必小于  $d$ , 矛盾. 那么一定是在通过反馈层时 2 个输入被映到同一输出上, 即 2 个输入的为 1 的分量的最小下标是相同的, 设为  $k$ , 则  $x^{i_1}$  与  $x^k$  是连通的, 同理  $x^{j_2}$  与  $x^k$  是连通的, 换句话说,  $x^{i_1}$  与  $x^{j_2}$  是连通的, 矛盾. 定理得证.

下面举一个简单的例子.

设给定样本集  $K = \{x^1, x^2, \dots, x^6\}$ ,

$$x^1 = (+1, +1, +1, +1, +1, +1) \quad x^4 = (-1, +1, -1, -1, -1, +1)$$

$$x^2 = (+1, -1, -1, +1, +1, +1) \quad x^5 = (+1, -1, -1, +1, +1, -1)$$

$$x^3 = (-1, -1, +1, +1, -1, +1) \quad x^6 = (-1, -1, -1, -1, -1, -1)$$

容易知道: 取相似度阈值  $d$  不同, 可得到不同的分类.

$$d=6, 5, 4 \text{ 时有分类: } \{1, 2, 3, 4, 5, 6, \} \quad d=1, 0 \text{ 时有分类: } \{(1, 2, 5), (3), (4, 6)\}$$

$$d=3, 2 \text{ 时有分类: } \{1, (2, 5), 3, 4, 6\} \quad d=-1 \text{ 时有分类: } \{(1, 2, 3, 4, 5, 6)\}$$

例取  $d=1$ ,

$$F(x^1) = (+1, +1, -1, -1, -1, -1) \rightarrow G(F(x^1)) = (+1, -1, -1, -1, -1, -1) = e^1 \rightarrow B(G(F(x^1))) = x^1 \rightarrow F(x^1) = (+1, +1, -1, -1, +1, -1) \rightarrow G(F(x^1)) = e^1.$$

$$F(x^2) = (+1, +1, -1, -1, +1, -1) \rightarrow G(F(x^2)) = (+1, -1, -1, -1, -1, -1) = e^1 \rightarrow B(G(F(x^2))) = x^1 \rightarrow F(x^1) = (+1, +1, -1, -1, -1, -1) \rightarrow G(F(x^1)) = e^1.$$

$$F(x^3) = (-1, -1, +1, -1, -1, -1) \rightarrow G(F(x^3)) = (-1, -1, +1, -1, -1, -1) = e^3 \rightarrow B(G(F(x^3))) = x^3 \rightarrow F(x^3) = (-1, -1, +1, -1, -1, -1) \rightarrow G(F(x^3)) = e^3.$$

$$F(x^4) = (-1, -1, -1, +1, -1, -1) \rightarrow G(F(x^4)) = (-1, -1, -1, +1, -1, -1) = e^4 \rightarrow B(G(F(x^4))) = x^4 \rightarrow F(x^4) = (-1, -1, -1, +1, -1, -1) \rightarrow G(F(x^4)) = e^4.$$

$$F(x^5) = (-1, +1, -1, -1, +1, -1) \rightarrow G(F(x^5)) = (-1, +1, -1, -1, -1, -1) = e^2$$

$$\rightarrow B(G(F(x^5))) = x^2 \rightarrow F(x^2) = (+1, +1, -1, -1, -1, -1) \rightarrow G(F(x^2)) = e^1.$$

$$F(x^6) = (-1, -1, -1, +1, -1, +1) \rightarrow G(F(x^6)) = (-1, -1, -1, +1, -1, -1) = e^4$$

$$\rightarrow B(G(F(x^6))) = x^4 \rightarrow F(x^4) = (-1, -1, -1, +1, -1, -1) \rightarrow G(F(x^4)) = e^4.$$

由上面得,网络经过一次循环后,将样本集予分为{(1,2),(3),(4,6),(5)},再经过一次循环,将样本集分成为{(1,2,5),(3),(4,6)}.这时网络就稳定了.即网络完成了相似度为  $d=1$  的聚类分析.

### 3 多层反馈网络的功能

上面已经讲过,多层反馈网络可以作为聚类器.下面我们将指出这种网络不但有普通的聚类分析能力,而且有一定的容错能力.

为简单计,设  $n$  维输入向量的分量只取  $-1, +1$  两个值.

再设样本集  $K = \{x^1, x^2, \dots, x^p\}$ , 给定相似度阈值  $d$ . 定义:

$$g_i = \max\{\langle x^i, x^j \rangle \mid \langle x^i, x^j \rangle \leq d, i \neq j\}, \quad i=1, 2, \dots, p.$$

$$h_i = \max\{d, (n - (d - g_i))\}, \quad i=1, 2, \dots, p.$$

$$D(x^i) = \{x \mid \langle x, x^i \rangle > h_i\}, \quad i=1, 2, \dots, p.$$

命题 4. 图 1 网络按上述所给的 FP 学习和综合算法得到的神经网络,不但能进行所给相似度为  $d$  的聚类分析,而且有如下的容错能力:

当  $x \in D(x^i)$ , 则  $x$  与  $x^i$  必属于同一分类.

证明:先给出一个不等式:

对任意  $n$  维向量  $x, y, z$ , 其模平方为  $n$ , 则有下式成立

$$\langle x, z \rangle \leq n + \langle y, z \rangle - \langle x, y \rangle \tag{4}$$

设  $x \in D(x^i)$ , 由(4)式, 当  $\langle x^i, x^i \rangle \leq d$  时得

$$\langle x, x^i \rangle \leq n + \langle x^i, x^i \rangle - \langle x, x^i \rangle \leq n + g_i - \langle x, x^i \rangle < n + g_i - (n - (d - g_i)) = d$$

即 
$$F_j(x) = F_j(x^i) = -1, j \neq i$$

又当  $x \in D(x^i)$ , 有 
$$\langle x, x^i \rangle > h_i = \max\{d, (n - (d - g_i))\} \geq d$$

得 
$$F_i(x) = F_i(x^i) = +1,$$

对于  $\langle x^i, x^j \rangle > d, j \neq i$  时,  $F_j(x) = +1$  或  $-1$ , 若有某  $j$  使  $F_j(x)$  为  $+1$ , 设其坐标最小者为  $k(x)$ , 显然  $G(F(x)) = e^{k(x)}$ . 而  $x^{k(x)}$  与  $x^i$  是属于同一类的, 故得  $x$  与  $x^i$  是属于同一类的. 若没有  $j(j \neq i)$ , 使  $F_j(x) = +1$ , 显然  $F(x) = F(x^i)$ . 便有  $x$  与  $x^i$  属于同一类的. 命题证毕.

由此可见,我们所得到的网络作为聚类器比一般的聚类器有很大的优点. 它具有一定的容错能力.

图 1 网络若将  $N_3$  断开, 就得到多层前馈网络. 故图 1 网络可以看成是多层前馈网络的推广. 这样, 对神经网络的 2 个主要功能, 我们都给出了很有效的学习算法. 今后, 主要是研究作为求优化的神经网络的学习和综合的有效算法问题.

### 4 结 论

本文是研究神经网络的学习算法总的课题的组成部分, 即研究作为聚类器的神经网络

的学习和综合算法(或研究多层反馈神经网络的学习和综合算法问题)。

我们给出的算法,具有以下优点:(1)权系数、阈值简单;(2)进行聚类分析时,操作方便且可得到不同粒度的聚类;(3)用于聚类分析时,收敛速度快(最多经过 $(p-1)$ 步),且有一定的容错能力;(4)学习速度快(是样本个数的线性函数),网络的元件个数少。

我们的方法与已有的学习方法(如BP算法<sup>[3]</sup>、 $\delta$ -算法等)相比,不但有以上所述的优点,更主要的是在方法论上的区别,一般的学习方法是在局部上进行调整搜索,已经有理论证明(见文献[4]):即使在树上进行启发性搜索,在一般情况下其计算量也是指数阶的,故按这种思路进行求解很难得到好的结果的,而我们学习方法是在全局上进行规划求解,事实证明:使用全局的观点能得到好的结果的。

综上所述,神经网络的FP算法为神经网络的学习和综合提供了强有力的方法,也为神经元硬件化提供了理论基础。

### 参考文献

- 1 张铃,吴福朝,张钊. 多层前馈神经网络的学习和综合算法. 软件学报, 1995, 6(7): 440~448.
- 2 汪培庄. 模糊集合论及其应用. 上海:上海科学技术出版社, 1983.
- 3 Rumelhart D E, McClelland J L. Parallel distributed processing. Vol. 1 & Vol. 2, MIT Press, Cambridge, MA, 1986.
- 4 Pearl J. Heuristics. New York: Addison-Wesley Company, 1984.

## A FORWARD PROPAGATION LEARNING ALGORITHM OF MULTILAYERED NEURAL NETWORKS WITH FEEDBACK CONNECTIONS

\* \* ZHANG Ling      \* \* \* ZHANG Bo

\* (Institute of Artificial Intelligence Anhui University Hefei 230039)

\* \* (Department of Computer Science Tsinghua University Beijing 100084)

\* (State Key Laboratory of Intelligent Technology and Systems Beijing 100084)

**Abstract** A forward propagation learning algorithm (FP) of multilayered neural networks with feedback connections is presented in this paper. And the properties of cluster networks are discussed. A cluster with different grain-sizes can be obtained by applying FP to cluster. Its convergent speed is just a linear function of sample size. Its computational complexity is a bilinear function of simple size and the dimension of input vectors. The network constructed by the algorithm uses a comparatively fewer number of elements and its weight simply has one of three values, i. e.,  $-1, 0, 1$ . Thus, it can be easily implemented into electronic circuits. The authors also discuss the properties of the network and show it is an ideal pattern classifier.

**Key words** Multilayered neural network with feedback connections, learning algorithm, clustering.

**Class number** TP18