

43-45

联想记忆网络

动态学习算法

神经网络

111

# 多模式对模糊联想记忆网络的动态学习算法\*

A Dynamical Learning Algorithm for Multiple Samples Fuzzy Associative Memory Neural Networks

肖平<sup>1</sup> 冯久超<sup>2</sup> 余英林<sup>1</sup>

TP18

(华南理工大学电子与通信工程系 广州 510641)<sup>1</sup> (西南师范大学物理系 重庆 400715)<sup>2</sup>

**摘要** In the first, a quick dynamical adjusting learning algorithm for fuzzy associative memory networks is proposed, and a sufficient and necessary condition is given. Then, a dynamical exponent adjusting algorithm is developed, which takes the weights obtained by quick dynamical algorithm as initial iteration value. The simulations demonstrate the advantage of the proposed algorithm.

**关键词** Neural network, Fuzzy associative memory, Learning algorithm, Dynamical adjusting

Kosko 在结合模糊系统与神经网络的基础上提出的最大最小联想记忆网络<sup>[1]</sup>是二层前馈网络,为了提高其记忆性能,已经提出了一些改进的算法。其中主要有正交编码算法<sup>[2]</sup>,最大连接权算法<sup>[3]</sup>,梯度下降算法<sup>[4-6]</sup>。梯度算法需要较复杂的迭代运算,设计出的网络不具有“学习”能力,即当网络需要存储一个新的训练模式时,就必须重新设计整个网络权矩阵。最大连接权法在网络存在精确连接权的条件下,对存储模式因信息丢失的联想效果最好,但对随机噪声畸变模式其联想效果却不甚理想。尤其在网络不存在精确解的条件下,网络的记忆性能显得较差。文[2]的正交编码算法是一种能有效地结合权值分析解与数值解的算法。这种算法的记忆容量要好于最大权算法。

本文首先给出联想记忆网络的一种快速动态调整算法,而后发展了高容量记忆网络的一种动态指数调整学习算法,它保持了正交编码算法快速简便等特点。通过参数的动态调整,可以提高网络的记忆容量,而且对于输入不同类型的畸变存储模式,连接权采用动态调整,可使其联想效果达到最好。

## 一、最大最小双向联想记忆模型及其相关分析

Kosko 给出的最大最小模糊联想记忆网络模型为:

$$A_k \cdot W = B_k, k=1, 2, \dots, p$$

用逐点表示,即为:

$$\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = b_{kj}, j=1, 2, \dots, m, k=1, 2, \dots, p \quad (1)$$

其中  $A_k = (a_{k1}, a_{k2}, \dots, a_{kn})$ ,  $B_k = (b_{k1}, b_{k2}, \dots, b_{km})$  分别为输入和输出层的模糊向量;  $W = (w_{ij})_{n \times m}$  为网络的连接权;  $n$  和  $m$  分别为输入和输出层神经元个数;  $p$  为训练模式对数; “ $\vee$ ”和“ $\wedge$ ”表示最大和最小运算。

### 1.1 快速动态调整学习算法及模糊双向联想记忆模型

设  $W_k = (w_{ij}^k)_{n \times m}$  和  $W = (w_{ij})_{n \times m}$  分别是第  $k$  个模式对和整个联想记忆模型(1)的关系矩阵。定义:

$$w_{ij}^k(\lambda) = a_{ki} \theta b_{kj} = \begin{cases} 1, & \text{if } a_{ki} = b_{kj} \text{ or } b_{kj} - a_{ki} \geq \lambda \\ a_{ki} \wedge b_{kj}, & \text{else} \end{cases}$$

$$w_{ij}(\lambda) = \bigwedge_{k=1}^p (w_{ij}^k(\lambda)) = \bigwedge_{k=1}^p (a_{ki} \theta b_{kj}) \quad (2)$$

其中  $\lambda$  是一个动态参数,很显然,当  $\lambda=0$  时,上述学习算法即为文[3]的最大权编码算法。

最大最小算子突出的是主因素作用,对于输入不完整即丢失部分信息的记忆模式,网络能较好地联想出其相应的模式;而对于模式分量值变大时就较难正确联想。因此,在设计网络时,主要应考虑如何使网络对这种畸变模式容错性较强。以单个模式对为例,当采用最大权编码,若  $a_{ki} < b_{kj}$ ,则  $w_{ij}^k = 1$ 。从而

而  $a_{ki} \wedge w_{ij}^k < b_{kj}$ ,当  $a_{ki}$  变大至  $a_{ki} > b_{kj}$  时,则  $\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}^k) \geq a_{ki} \wedge w_{ij}^k > b_{kj}$ ,而取  $\lambda > 1$ ,由式(2),若  $a_{ki} < b_{kj}$ ,则  $w_{ij}^k = a_{ki} \wedge b_{kj} = a_{ki}$ 。因此不论  $a_{ki}$  如何变大,都有  $\bigvee_{i=1, i \neq i}^n (a_{ki} \wedge w_{ij}^k) \vee (a_{ki} \wedge w_{ij}^k) = \bigvee_{i=1, i \neq i}^n (a_{ki} \wedge w_{ij}^k) \vee a_{ki} = \bigvee_{i=1}^n (a_{ki} \wedge w_{ij}^k) = b_{kj}$ 。

若模型(1)的连接权矩阵  $W$  由(2)式确定,则前

\* )本项目受国家攀登计划和国家自然科学基金资助。肖平 博士生,副教授。冯久超 副教授。余英林 教授,博士生导师。

馈模糊联想记忆模型(1)可以发展成为一种模糊双向联想记忆模型,即:

$$\begin{cases} A_k \cdot W = B'_k \\ B_k \cdot R = A'_k \end{cases} \quad k=1,2,\dots,p. \text{逐点表示就为:}$$

$$\begin{cases} \bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = b'_{kj}, j=1,2,\dots,m, k=1,2,\dots,p \\ \bigvee_{j=1}^m (b_{kj} \wedge r_{j\beta}) = a_{ki}, i=1,2,\dots,n, k=1,2,\dots,p \end{cases} \quad (3)$$

上式中  $W = (w_{ij})_{n \times m}, R = (r_{j\beta})_{m \times n}, A'_k = (a'_{k1}, a'_{k2}, \dots, a'_{kn})$  和  $B'_k = (b'_{k1}, b'_{k2}, \dots, b'_{km})$  分别是神经元  $A_k$  和  $B_k$  的下一个状态向量。很显然,由式(3)可知,一个模糊模式向量  $(A_k, B_k)$  是双向联想记忆模型(3)的一个稳定吸引子当且仅当  $\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = b_{kj}$  和  $\bigvee_{j=1}^m (b_{kj} \wedge r_{j\beta}) = a_{ki}, k \in \{1,2,\dots,p\}$  同时成立。

### 1.2 双向记忆模型的稳定性条件及容错性分析

**定义 1**<sup>[8]</sup> 反馈网络中一个状态序列  $\{p_1, p_2, \dots, p_n\}$  称为极限环,如果对网络的状态转移因子  $F$ , 有  $F(p_1) = p_2, F(p_2) = p_3, \dots, F(p_n) = p_{n+1}, \dots, F(p_n) = p_1$ , 并且其中不含有具有这种性质的子序列,  $s$  称为极限环的长度。

**定理 1** 模糊双向联想记忆网络的任一初始状态矢量,最终都将收敛到某一极限环。

证明方法与文[8]类似,从略。

**定理 2** 设  $(A_k, B_k)$  是  $p$  个向量模式对,式中  $A_k = (a_{k1}, a_{k2}, \dots, a_{kn}) \in [0, 1]^n, B_k = (b_{k1}, b_{k2}, \dots, b_{km}) \in [0, 1]^m$ , 则对于任意给定的  $k \in \{1, 2, \dots, p\}$ , 模式向量  $B_k$  可由向量  $A_k$  一次联想出来的充要条件是对任意的  $j \in \{1, 2, \dots, m\}$ , 都至少存在一个  $i \in \{1, 2, \dots, n\}$  使得:

$$b_{kj} \leq a_{ki} \wedge w_{ij} \quad (4)$$

其中  $w_{ij}$  是由学习规则(2)决定。

**证明:** (必要性) 设  $A_k \cdot W = B_k$ , 即  $\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = b_{kj} (j=1, 2, \dots, m)$ 。如果存在一个  $j \in \{1, 2, \dots, m\}$ , 使得对于所有的  $i \in \{1, 2, \dots, n\}$ , 都有  $b_{kj} > a_{ki} \wedge w_{ij}$ , 那么  $b_{kj} > \bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = b_{kj}$ 。矛盾。

(充分性) 假定对于任给的  $j \in \{1, 2, \dots, m\}$ , 都至少存在一个  $i \in \{1, 2, \dots, n\}$ , 使得  $b_{kj} \leq a_{ki} \wedge w_{ij}$ , 则可得  $b_{kj} \leq a_{ki}$  和  $b_{kj} \leq w_{ij}$ , 下面分两种情况讨论之。

(i)  $b_{kj} < a_{ki}$  和  $b_{kj} \leq w_{ij}$ 。则由规则(2),  $b_{kj} \leq w_{ij} = \bigwedge_{k=1}^p (a_{ki} \theta b_{kj}) \leq a_{ki} \theta b_{kj} = b_{kj}$ , 因此  $w_{ij} = b_{kj}$ 。故  $\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = \bigvee_{i=1}^n (a_{ki} \wedge b_{kj}) = \bigvee_{i=1}^n b_{kj} = b_{kj}$ 。(ii)  $b_{kj} = a_{ki}$  和  $b_{kj} \leq w_{ij}$ 。则  $\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) \geq a_{ki} \wedge w_{ij} \geq a_{ki} \wedge b_{kj} = b_{kj}$ 。又  $\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) \leq \bigvee_{i=1}^n (a_{ki} \wedge 1) \leq \bigvee_{i=1}^n (b_{ki} \wedge 1) = b_{kj}$ 。因此  $\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = b_{kj}$ 。

$w_{ij}) = b_{kj}$ 。综合(i)(ii), 可得  $\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = b_{kj}$ 。 □

**定理 3** 设  $(A_k, B_k)$  是  $p$  个训练模式对, 则对于每个  $k \in \{1, 2, \dots, p\}$ , 模式对  $(A_k, B_k)$  在一次循环迭代后成为双向联想记忆模型(3)的一个稳定态的充要条件是同时满足条件(a)和(b):

(a) 对于任意给定的一个  $j \in \{1, 2, \dots, m\}$ , 至少存在一个  $i \in \{1, 2, \dots, n\}$ , 使得  $b_{kj} \leq a_{ki} \wedge w_{ij}$

(b) 对于任给的一个  $i \in \{1, 2, \dots, n\}$ , 至少存在一个  $j \in \{1, 2, \dots, m\}$ , 使得  $a_{ki} \leq b_{kj} \wedge r_{j\beta}$  (5)

证明方法与定理 1 类似, 从略。

由上式(4), (5)可知, 对于自联想模式:  $a_{ki} = b_{ki}$ , 显然有  $a_{ki} \leq a_{ki} \wedge w_{ij}$ , 因此不论  $\lambda$  为何值, 快速动态调整算法均能完整记忆所有训练样本, 而不论训练样本的数目及强弱如何。

**推论 1** 设某个模式对  $(A_k, B_k), k \in \{1, 2, \dots, p\}$ , 是双向联想记忆模型(3)的一个稳定吸引子,  $A = (a_1, a_2, \dots, a_n)$  是模式向量  $A_k$  的一个畸变模式。如果对于任意一个  $j \in \{1, 2, \dots, m\}$ , 存在一个  $i \in \{1, 2, \dots, n\}$ , 使得  $b_{kj} = a_i \wedge w_{ij}$  且  $a_i \leq a_{ki} (i \neq k)$ , 则模式向量  $B_k$  可由畸变模式  $A$  迭代一次联想出来。

**证明:** 首先证明模式向量  $B_k$  的第  $j$  个分量  $b_{kj}$  可以由向量  $A$  迭代一次回想出来。由于  $\bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = b_{kj}$ , 且  $a_i \leq a_{ki} (i \neq k)$ , 则有  $a_i \wedge w_{ij} \leq a_{ki} \wedge w_{ij} (i \neq k)$ 。因此  $\bigvee_{i=1, i \neq k}^n (a_i \wedge w_{ij}) \leq \bigvee_{i=1, i \neq k}^n (a_{ki} \wedge w_{ij}) \leq b_{kj}$ , 而由假设  $b_{kj} = a_i \wedge w_{ij}$ , 则  $b_{kj} = a_i \wedge w_{ij} \leq \bigvee_{i=1}^n (a_i \wedge w_{ij}) \leq \bigvee_{i=1}^n (a_{ki} \wedge w_{ij}) = b_{kj}$ 。所以  $\bigvee_{i=1}^n (a_i \wedge w_{ij}) = b_{kj}$ 。由于  $j$  的任意性, 故结论成立。

从推论 1 可以看出, 只要保留某个记忆模式向量的一些主要信息, 即使丢失了其它部分信息, 则权值由学习规则(2)所确定的双向联想记忆网络仍可以完整地回想起其相应的模式向量。这正体现了  $\max$  和  $\min$  合成的模糊神经元突出的是主因素作用。

## 二、动态指数调整学习算法

由于在实际问题中, 训练模式集的获取受人因素的影响, 并不一定满足条件(4)或(5), 因此, 倘若以原模式的相似模式代替原模式进行编码, 而能使整个系统更加相容, 这样就确定了系统连接权的一个近似解, 最简单的方法就是以训练模式对  $(A, B)$  的语言变量模式  $(A^*, B^*)$  (在语言值模糊逻辑中,  $\alpha$  称为语言变量, 如很, 一般, 相当等) 代替  $(A, B)$  进行编码。需要说明的是文[2]的正交编码的思想即源于此, 但该文在阐述方法的合理性上不够妥当。本文网

络的连接权采用规则(2)确定,即  $w_{ij} = \prod_{k=1}^p (a_{ik} \theta b_{kj})$ 。  
为了确定  $\alpha_k$ ,我们发展了一种称为动态指数调整学习算法。算法总结如下:设全局误差函数 E:

$$E = \frac{1}{p} \sum_{k=1}^p \sum_{i=1}^m (\bar{b}_{ki} - b_{ki})^2, \bar{b}_{ki} = \prod_{i=1}^n (a_{ki} \wedge w_{ij})$$

- (1)选取动态调整参数  $\lambda = 0$ 。
- (2)给定一组指数初始值  $\alpha_k(t) = 1 (k=1, 2, \dots, p, p$  为训练样本数),迭代次数 M 及迭代精度  $\epsilon$ 。
- (3)产生高斯随机变量  $\xi_k(t)$ ,若  $\alpha'_k(t) = \alpha_k(t) + \mu \cdot \xi_k(t) \in X$  ( $\mu$  是高斯方差, X 是搜索区域, t 为迭代次数),则转(4);否则  $\alpha'_k(t) = \alpha_k(t)$ 。
- (4)计算  $w_{ij}(t) = \prod_{k=1}^p (a_{ik}^{\alpha'_k(t)} \theta b_{kj}^{\alpha'_k(t)}) =, i=1, 2, \dots, m$ 。
- (5)若  $E(t) < E(t-1)$ ,则  $\alpha_k(t+1) = \alpha'_k(t)$ ,否则  $\alpha_{k+1}(t+1) = \alpha_k(t)$ 。
- (6)若  $t=M$  或  $E(t) < \epsilon$ ,则结束;否则  $t=t+1$ ,转(2)。
- (7)调整  $\lambda = \lambda + \beta (\beta > 0$  为一调整量),重复(1)至(6)。

最后选取最适宜的参数  $\lambda$ 。当  $\lambda=0$  时,动态调整算法即为文[2]的正交编码学习算法。很显然,上述方法与某些神经网络迭代算法不同,网络训练与输入次序无关。

### 三、模拟结果

**实验一** 给出了 6 组模糊规则集(a)~(f)。表中记号“√”表示输入输出对应关系,其中 S=小,BS=偏小,M=中,BL=偏大,L=大。记  $A=B=\{\text{小,偏小,中,偏大,大}\}$ ,例如(a)的意思是“若 a 小,则 b 小;若 a 偏小,则 b 偏大;若 a 中则 b 中;若 a 偏大;则 b 偏大;若 a 大,则 b 大”,论域  $X=Y=\{0, 0.5, 1, 1.5, 2, \dots, 12\}$ 。用高斯函数定义它们的隶属函数:

$$\mu_a(x) = \begin{cases} 1 & x \leq 2 \\ e^{-(x-2)^2/4} & x > 2 \end{cases}$$

$$\mu_{BS}(x) = \begin{cases} 1 & x \leq 4 \\ e^{-(x-4)^2/4} & x > 4 \end{cases}$$

$$\mu_M(x) = e^{-(x-6)^2/4}$$

$$\mu_{BL}(x) = \begin{cases} 1 & x \geq 8 \\ e^{-(x-8)^2/4} & x < 8 \end{cases}$$

$$\mu_L(x) = \begin{cases} 1 & x \geq 10 \\ e^{-(x-10)^2/4} & x < 10 \end{cases}$$

表 1 给出了最大权,正交编码及动态指数调整三种学习算法所产生的误差  $E1 = E/25$ , ( $n=15, m=25, p=5$ ),实验时,迭代次数均为 100 次,从表 1 可看出,最大权算法在模式对不满足条件(4),(5)时,误差较大,本文的动态指数调整算法优于正交编

码算法。

Y/X	S	BS	M	BL	L
S	√				
BS		√			
M			√		
BL				√	
L					√

(a)

Y/X	S	BS	M	BL	L
S					√
BS	√				
M			√		
BL		√			
L					√

(b)

Y/X	S	BS	M	BL	L
S				√	
BS	√	√			
M			√		
BL					√
L					√

(c)

Y/X	S	BS	M	BL	L
S					√
BS					
M			√		
BL	√				
L					

(d)

Y/X	S	BS	M	BL	L
S					√
BS			√	√	
M			√		
BL		√	√		
L	√				

(e)

Y/X	S	BS	M	BL	L
S					√
BS				√	
M		√	√	√	
BL		√			
L	√				

(f)

表 1

规则集	最大权 <sup>[3]</sup>	正交编码 <sup>[2]</sup>	动态调整	
	E1	E1	E1	$\lambda$
a	0	0	0	0
b	1.52	1.05	0.91	0.9
c	0.64	0.64	0.54	0.6
d	0	0	0	0
e	1.74	0.81	0.72	1.0
f	1.29	0.60	0.57	0.4

### 参考文献

- [1] B. Kosko, Neural networks and Fuzzy systems: A dynamical approach to machine Intelligence. Prentice Hall. 1991
- [2] Fu-lai chung and Tong Lee, Toward a high capacity fuzzy associative memory model, IEEE int. conf. on neural networks. 1994
- [3] 范俊波、靳蕃等,模糊联想记忆的一种有效学习算法,电子学报,24(1)1996
- [4] 何奉道,多模式对模糊联想记忆学习的优化,计算机科学,21(3)1994
- [5] A. Blanco et al., Identification of fuzzy relational equations by fuzzy neural networks, Fuzzy sets and systems, 1995, 71
- [6] N. Ikoma et al., Estimation of fuzzy relational matrix by using probabilistic descent method, Fuzzy sets and systems, 1993, 57
- [7] Nori Baba, A new approach for finding the global minimum of error function of neural network, Neural network, 1989, 2
- [8] 刘增良,刘有才,因素神经网络理论及应用,贵州科技出版社,1994