

带参数聚合算子的模糊联想记忆网络

李 鹰¹, 徐蔚鸿^{1,2}, 唐良荣¹

(1. 长沙理工大学 计算机与通信工程学院, 湖南 长沙 410076; 2. 吉首大学 数学与计算科学学院, 湖南 吉首 416000)

摘要: 基于最大运算Max和t-范数T的神经网络模型Max-T FAM是B.Kosko提出的经典模糊联想记忆(FAM)网络的一种重要的广义形式, 其性能有多处不足. 本文利用一种参数化聚合算子 $\vee^\lambda$, 提出了一种计算简单、易于硬件实现的广义模糊联想记忆(GFAM)网络, 其连接算子从 $\{\vee^\lambda | \lambda \in [0, 1]\}$ 中选取; 从理论上严格证明了GFAM具有一致连续性, 比所有Max-T FAM的映射能力和存储能力强很多; 接着运用模糊关系方程理论提出和分析了GFAM的一种所谓的Max-Min- λ 学习算法; 最后用实验对GFAM和Max-T FAM的完整可靠存储能力进行了比较, 并示例了GFAM在图像联想方面的应用.

关键词: 模糊神经网络; 模糊联想记忆; 学习算法; t-范数; 模糊关系方程

中图分类号: TP183 **文献标识码:** A

Fuzzy associative memory network based on parameterized gathering operator

LI Ying¹, XU Wei-hong^{1,2}, TANG Liang-rong¹

(1. College of Computer and Communications Engineering, Changsha University of Science and Technology, Changsha Hunan 410076, China;

2. College of Mathematics and Computer Science, Jishou University, Jishou Hunan 416000, China)

Abstract: The neural network model Max-T FAM with the maximum operation and a t-norm T is an important generalized form of the classical fuzzy associative memory(FAM) network proposed by B.Kosko. This model has several disadvantages in its properties. Using a parameterized aggregating operator $\vee^\lambda$, we present a new generalized fuzzy associative memory(GFAM) network which is simple in computation and easy in implementation by hardware. All conjunctive operators of the interconnections of GFAM are chosen from a cluster $\{\vee^\lambda | \lambda \in [0, 1]\}$. The strict theoretical study reveals that the GFAM is uniformly continuous and has much higher mapping ability and stronger storage capability than all Max-T FAMs. From the theory of fuzzy relational equations, we derive and analyze a so-called Max-Min- λ learning algorithm for GFAM. Experimental comparisons of the storage capability have been made between GFAM and all Max-T FAMs. An application of GFAM to associative images is illustrated.

Key words: fuzzy neural network; fuzzy associative memory; learning algorithm; t-norm; fuzzy relational equation

1 引言(Introduction)

不确定性人工智能已经成为21世纪人工智能的研究热点和重大前沿课题^[1]. 模糊性是主观和客观世界中最普遍的不确定性形式之一. 自1987年B.Kosko提出了模糊联想记忆网络(FAM)以来, 模糊神经网络(FNNs)得到了大量研究, 已成为带有模糊不确定性的智能系统的一种重要建模工具, 并在模式识别、自动控制和预测系统等领域取得大量的成功应用^[2~5]. 神经网络和模糊系统均属无模型估计器和非线性动力学系统. 神经网络适合于处理非结构化信息, 模糊系统对处理结构化知识更为有效, 而FNNs是模糊系统和神经网络的

互补式结合. FAM及其演变模型的理论和应用研究方兴未艾^[2,3,6~10]. 研究表明: 采用模糊联想记忆网络(FAM)的模糊控制系统具有良好的鲁棒性, 而将微分竞争学习(DCL)机制引入FAM所形成的自适应FAM, 可以在输入、输出样本不甚完备的条件下, 以相对少的计算量获得较好的系统性能. FAM的研究非常活跃的广义模型是以下的Max-T FAM模型: $y_j = \bigvee_{i \in I} (x_i T w_{ij})$, $\forall j \in J$. 其中T是某个t-范数, $I = \{1, 2, \dots, n\}$, $J = \{1, 2, \dots, m\}$, w_{ij} 是连接权值, $(x_1, x_2, \dots, x_n)$ 是输入向量, $(y_1, y_2, \dots, y_m)$ 是输出向量. 当T为取小运算Min时, Max-T FAM模型即传统的FAM模型. 然而Max-T FAM模型仍存在有

多种不足:

1) 网络簇{Max-T FAM|T是t-范数}中各具体网络的共性和个性还不很清楚. 实际应用中选择合适的t-范数T有困难.

2) t-范数是一类模糊算子簇, 其中不少具体的t-范数表达式复杂、运算量大, 且不利于硬件电路实现, 或不适宜应用于工业过程实时控制.

3) Max-T FAM模型的映射能力和存储能力等不尽人意. 例如, 当存在 i_0 使得 $y_{i_0} > \bigvee_{i \in I} x_i$ 时, 对任意t-范数T, Max-T FAM不能可靠地存储模式对 $((x_1, x_2, \dots, x_n), (y_1, y_2, \dots, y_m))$.

1975年L.W.Fung和K.S.Fu提出了一种有用的带参数 λ 的聚合算子 $\vee^\lambda$. 本文将基于该算子提出一种不属于Max-T FAMs簇的结构新颖且性能好的模糊联想记忆网络(GFAM). 鉴于网络模型的连续性、映射能力、存储能力与网络的泛化能力、鲁棒性、容错性等实用性指标有着本质的直接联系, 所以本文将严谨地分析GFAM的连续性、映射能力和存储能力, 基于模糊关系方程理论提出它的一种学习算法, 并与Max-T FAMs簇进行比较.

2 相关定义和引理(Related definitions and lemmas)

在模糊集理论中, 为了弥补算子 $\wedge$ 和 $\vee$ 在一些实际应用中处理信息的粗糙, 而将它们分别推广为t-范数和t-余范数. t-范数已在模糊理论中获得了广泛研究和应用. 例如, t-范数常被应用于推广传统的模糊联想记忆网络FAM、模糊双向联想记忆网络FAMB、模糊Hopfield网络等模型.

定义 1 二元运算 $T: [0,1] \times [0,1] \rightarrow [0,1]$ 为t-范数, 如果对于任意 $a, b, c \in [0,1]$, T满足以下4个条件:

- 1) $aT1 = a$ (边界性);
- 2) 如果 $b \leq c$, 则 $aTb \leq aTc$ (非减性);
- 3) $aTb = bTa$ (交换性);
- 4) $aT(bTc) = (aTb)Tc$ (结合性).

据定义1, 对于任意 $a \in [0,1]$ 有 $aT0 = 0$.

若存在t-范数T使得 $\forall a, b \in [0,1], aSb = 1 - (1 - a)T(1 - b)$, 则算子S称为t-余范数.

定义 2 对于任意给定的 $\lambda \in [0,1]$, 二元运算

$$\vee^\lambda: [0,1] \times [0,1] \rightarrow [0,1]$$

定义为

$$a \vee^\lambda b = (a \wedge b) \vee (a \wedge \lambda) \vee (b \wedge \lambda),$$

或定义为

$$a \vee^\lambda b = \begin{cases} a \wedge b, & a, b > \lambda, \\ \lambda, & \lambda \in [a, b] \text{ 或 } \lambda \in [b, a], \\ a \vee b, & a, b < \lambda. \end{cases}$$

易发现这种带有参数 λ 的算子仅由 $\vee$ 和 $\wedge$ 两种算子构成, 易用硬件实现. 显见, 当 $\lambda \neq 0$ 时, 算子 $\vee^\lambda$ 不是t-范数, 而当 $\lambda \neq 1$ 时 $\vee^\lambda$ 也不是t-余范数. 算子 $\vee^\lambda$ 拥有如下优良的运算性质:

- 1) 如果 $\lambda \neq 0$ 且 $a < \lambda$, $a \vee^\lambda 1 = a \vee \lambda \neq a$; 如果 $\lambda \neq 1$ 且 $a > \lambda$, $a \vee^\lambda 0 = a \wedge \lambda \neq a$;
- 2) 如果 $b \leq c$, 则 $a \vee^\lambda b \leq a \vee^\lambda c$ (非减性);
- 3) $a \vee^\lambda b = b \vee^\lambda a$ (交换性);
- 4) $(a \vee^\lambda b) \vee^\lambda c = a \vee^\lambda (b \vee^\lambda c)$ (结合性);
- 5) $a \vee^\lambda b = (a \wedge b) \vee [\lambda \wedge (a \vee b)]$;
- 6) $a \vee^1 b = a \vee b$, $a \vee^0 b = a \wedge b$;
- 7) 当 $\lambda_1 \leq \lambda_2$ 且 $a, b \in [0,1]$ 时, 有 $a \vee^{\lambda_1} b \leq a \vee^{\lambda_2} b$. 当参数 λ 从0变化到1时, $a \vee^\lambda b$ 的值在区间 $[a \wedge b, a \vee b]$ 上连续变化, $\vee^\lambda$ 算子便具有了自适应能力.

引理 1^[6]

- 1) 不等式 $|\bigvee_{i \in I} a'_i - \bigvee_{i \in I} a_i| \leq \bigvee_{i \in I} |a'_i - a_i|$ 成立;
- 2) 如果 $\delta > 0$ 且 $|a'_i - a_i| \leq \delta, i \in I$, 则 $|\bigwedge_{i \in I} a'_i - \bigwedge_{i \in I} a_i| \leq \delta$ 成立;
- 3) 不等式 $|\bigwedge_{i \in I} a'_i - \bigwedge_{i \in I} a_i| \leq \bigvee_{i \in I} |a'_i - a_i|$ 总成立.

引理 2 对任意 $a_1, a_2, b_1, b_2, \lambda_1, \lambda_2 \in [0,1]$,

$$|a_1 \vee^{\lambda_1} b_1 - a_2 \vee^{\lambda_2} b_2| \leq |a_1 - a_2| \vee |b_1 - b_2| \vee |\lambda_1 - \lambda_2|$$

成立.

证 可利用引理1简单得证, 此处略.


3 一种基于带参数聚合算子的 GFAM(A GFAM based on a parameterized gathering operator)

3.1 GFAM的定义(Definition of the GFAM)

如图1所示, 基于算子 $\vee^\lambda$ 的GFAM, 从第 i 个输入节点到所有输出节点的连接算子是 $\vee^{\lambda_i}$. 第 i 个输入节点到第 j 个输出节点的权值记为 w_{ij} , 其中 $i \in I, j \in J$. 对于任意输入向量 $X = (x_1, x_2, \dots, x_n) \in [0,1]^n$, GFAM的输出将被逐点表示为

$$y_j = \bigvee_{i \in I} (x_i \vee^{\lambda_i} w_{ij}), \forall j \in J.$$

每个参数 $\lambda_i \in [0,1]$ 根据GFAM在实际应用中的需要进行调整. 根据算子 $\vee^\lambda$ 的性质, y_j 的另一种表达式为

图1 带有聚合算子 $\bigvee^{\lambda_i}$ 的GFAM拓扑结构Fig. 1 Architecture of the GFAM with operator $\bigvee^{\lambda_i}$

显然GFAM本质上只涉及 $\vee$ 和 $\wedge$ 两种运算,故易于硬件实现.如果所有 λ_i 都置为0,GFAM就变成传统FAM. GFAM的各连接算子可能不同,它们都是从算子簇 $\{\bigvee^{\lambda} | \lambda \in [0, 1]\}$ 中选取.当参数 $\lambda \neq 0$ 时,GFAM并不是Max-T FAM的一个特例.

3.2 GFAM的连续性(Continuity of the GFAM)

模糊神经网络常被用作模糊推理机.当它被看作向量函数,它的逼近能力与它是否关于输入向量具有连续性直接相关.通常没有连续性的模糊神经网络不能很好地模拟真实系统,有时其基本性能也难保证.

在以下部分,当任意给定输入向量 $X = (x_1, x_2, \dots, x_n)$ 后,GFAM记为 $\text{GFAM}_X(\lambda_1, \lambda_2, \dots, \lambda_n, w_{ij})$;当任意给定输入向量 $(x_1, x_2, \dots, x_n)$ 和连接权矩阵 W 后,GFAM记为 $\text{GFAM}_{X,W}(\lambda_1, \lambda_2, \dots, \lambda_n)$;当任意给定连接权矩阵 W ,参数向量 $\Lambda = (\lambda_1, \lambda_2, \dots, \lambda_n)$ 后,GFAM记为 $\text{GFAM}_{W,\Lambda}(x_1, x_2, \dots, x_n)$.

定理1

$$\text{GFAM}_{W,\Lambda}(x_1, x_2, \dots, x_n),$$

$$\text{GFAM}_{X,W}(\lambda_1, \lambda_2, \dots, \lambda_n),$$

$$\text{GFAM}_X(\lambda_1, \lambda_2, \dots, \lambda_n; w_{ij}).$$

分别是空间 $[0, 1]^n$, $[0, 1]^n$ 和 $[0, 1]^{n+n \times m}$ 上的一致连续函数.

证 显然有 $\text{GFAM}_{W,\Lambda}(x_1, x_2, \dots, x_n) \in [0, 1]^m$,又知所有的范数都是相互等价的,所以只需以典型范数 $\|\cdot\|_\infty$ 为例来证明定理1.

令: $G_1 = \text{GFAM}_{W,\Lambda}(x_1, x_2, \dots, x_n)$,

$$G_2 = \text{GFAM}_{W,\Lambda}(x_2, x_2, \dots, x_2),$$

则

$$\|G_1 - G_2\|_\infty = \bigvee_{i \in I} |y_1 - y_2| =$$

$$\bigvee_{j \in J} \bigvee_{i \in I} |(x_1 \vee^{\lambda_i} w_{ij}) - (x_2 \vee^{\lambda_i} w_{ij})| \leq$$

$$\bigvee_{j \in J} \bigvee_{i \in I} |x_1 \vee^{\lambda_i} w_{ij} - (x_2 \vee^{\lambda_i} w_{ij})| \text{ (据引理1)} \leq$$

$$\bigvee_{j \in J} \bigvee_{i \in I} (|x_1 - x_2| \vee |w_{ij} - w_{ij}| \vee$$

$$|\lambda_i - \lambda_i|) \text{ (据引理2)} = \bigvee_{j \in J} \bigvee_{i \in I} |x_1 - x_2| =$$

$$\bigvee_{i \in I} |x_1 - x_2| = \|X_1 - X_2\|_\infty. \quad (1)$$

对于任意给定的 $\varepsilon > 0$,令正数 $\delta(\varepsilon) = \varepsilon$,任意给定 $X_1, X_2 \in [0, 1]^n$,其满足不等式 $\|X_1 - X_2\|_\infty < \delta(\varepsilon)$.根据不等式(1),有

$$\|G_1 - G_2\|_\infty \leq \|X_1 - X_2\|_\infty < \delta(\varepsilon) = \varepsilon.$$

因此 $\text{GFAM}_{W,\Lambda}(x_1, x_2, \dots, x_n)$ 关于输入向量 $(x_1, x_2, \dots, x_n)$ 是一致连续函数.

$\text{GFAM}_{X,W}(\lambda_1, \lambda_2, \dots, \lambda_n)$ 和 $\text{GFAM}_X(\lambda_1, \lambda_2, \dots, \lambda_n; w_{ij})$ 分别是空间 $[0, 1]^n$ 和 $[0, 1]^{n+n \times m}$ 上的一致连续函数可类似证明,版面所限,此处略.

证毕.

定理1表明GFAM两个近似输入向量会产生两个近似的输出向量;GFAM两个近似的连接权矩阵对任意给定的同一输入向量,会产生两个近似的输出向量.定理1实际上已经保证了GFAM具有良好的抗噪性和鲁棒性.其严格证明,因版面限制此处略.

3.3 GFAM的映射能力(Mapping ability of the GFAM)

假设模式 A 与模式 B 是关联的,如果模糊神经网络模型不能将 A 映射到 B ,那么这种模型不能可靠存储模式对 (A, B) ,也不能从 A 准确地预测出 B .因此神经网络的映射能力在一定程度上影响了它的实用性.如:对任意 t -范数 T ,模式对 $((0, 0, \dots, 0) (0.5, 0, \dots, 0))$ 不能被可靠地存储在Max-T FAM中.这是因为对任意的Max-T FAM,模式 $(0, 0, \dots, 0)$ 只能映射到 $(0, 0, \dots, 0)$ 上.

当神经网络看作从一个向量空间到另一个向量空间的映射时,它的映射能力与它的值域紧密相关.假设对于前向神经网络FNN,当输入向量 $X = (x_1, x_2, \dots, x_n)$ 送入FNN时, $\text{FNN}(X)$ 代表FNN的输出向量,则对任意给定的 X ,令

$$D_X(\text{GFAM}) = \{\text{GFAM}(X) | \forall W, \forall \Lambda, X\},$$

$$D_X(\text{MAX-T FAM}) = \{\text{MAX-T FAM}(X) | X, T\},$$

$$D_{X,W}(\text{GFAM}) = \{\text{GFAM}(X) | \forall \Lambda, X, W\}.$$

它们分别代表相应的值域, 其中 T 是任意 t -范数.

定理 2

- 1) $D_{X,W}(\text{GFAM}) = \prod_{j=1}^m [\bigvee_{i \in I} (x_i \wedge w_{ij}), \bigvee_{i \in I} (x_i \vee w_{ij})];$
- 2) $D_X(\text{GFAM}) \supseteq \bigcup_{\forall T} D_X(\text{MAX-T FAM}).$

特别地, 如果输入向量 $X = (x_1, x_2, \dots, x_n)$ 满足 $\bigvee_{i \in I} x_i < 1$, 那么

$$D_X(\text{GFAM}) \supset \bigcup_{\forall T} D_X(\text{MAX-T FAM}).$$

证 因版面限制, 本文只给出2)的证明. 对

$$\forall (y'_1, y'_2, \dots, y'_m) \in \bigcup_{\forall T} D_X(\text{MAX-T FAM}).$$

必存在某些 w'_{ij} 和 t -范数 T' 使得 $y'_j = \bigvee_{i \in I} (x_i T' w'_{ij}) (j \in J)$ 成立. 又根据 t -范数的属性有

$$x_i T' w'_{ij} \leq x_i T' 1 = x_i,$$

所以

$$x_i \wedge (x_i T' w'_{ij}) = x_i T' w'_{ij}.$$

现在令 $\lambda_i = 0 (i \in I)$ 且 $w_{ij} = x_i T' w'_{ij} (i \in I, j \in J)$, 此时

$$\begin{aligned} \bigvee_{i \in I} (x_i \vee^{\lambda_i} w_{ij}) &= \bigvee_{i \in I} [x_i \vee^0 (x_i T' w'_{ij})] = \\ \bigvee_{i \in I} [x_i \wedge (x_i T' w'_{ij})] &= \bigvee_{i \in I} (x_i T' w'_{ij}) = y'_j, \quad j \in J. \end{aligned}$$

这就意味着 $(y'_1, y'_2, \dots, y'_m) \in D_X(\text{GFAM})$ 成立. 另外, 当向量 $(x_1, x_2, \dots, x_n)$ 满足 $\bigvee_{i \in I} x_i < 1$ 时, 构造集合

$$\begin{aligned} D_{1,X} &= \{(y_1^*, y_2^*, \dots, y_m^*) \mid y_j^* = \bigvee_{i \in I} (x_i \vee^{\lambda_i} w_{ij}^*), \\ &\quad \lambda_i > \bigvee_{i \in I} x_i, w_{ij}^* > \bigvee_{i \in I} x_i, \forall i \in I, j \in J\}. \end{aligned}$$

显然 $D_{1,X} \subseteq D_X(\text{GFAM})$, 其中任意 $(y_1^*, y_2^*, \dots, y_m^*) \in D_{1,X}$, 这时有

$$y_j^* = \bigvee_{i \in I} (x_i \vee^{\lambda_i} w_{ij}^*) = \bigvee_{i \in I} (\lambda_i \vee w_{ij}^*) > \bigvee_{i \in I} x_i, \quad j \in J.$$

然而, 对于每个

$$(y'_1, y'_2, \dots, y'_m) \in \bigcup_{\forall T} D_X(\text{MAX-T FAM}),$$

满足

$$y'_j = \bigvee_{i \in I} (x_i T w_{ij}) \leq \bigvee_{i \in I} (x_i T 1) = \bigvee_{i \in I} x_i, \quad j \in J,$$

这样就有

$$(y_1^*, y_2^*, \dots, y_m^*) \notin \bigcup_{\forall T} D_X(\text{MAX-T FAM}).$$

显然有当输入向量 $X = (x_1, x_2, \dots, x_n)$ 满足 $\bigvee_{i \in I} x_i < 1$ 时,

$$D_X(\text{GFAM}) \supset \bigcup_{\forall T} D_X(\text{MAX-T FAM})$$

成立. 证毕.

定理 2 表明 GFAM 比模糊神经网络簇 Max-T FAMs 的映射能力强得多.

3.4 GFAM 的存储能力 (Storage capacity of the GFAM)

一个神经网络的可靠存储模式对的能力是网络的一个重要性能指标, 而 B.Kosko 提出的 FAM 及其广义形式 Max-T FAMs 簇的存储能力不尽人意. 以下假设 $K = \{1, 2, \dots, p\}$ 是一个非空子集.

定理 3 对任意给定的 t -范数 T , 如果模式对集合 $\{(A_k, B_k) \mid k \in K\}$ 能完整可靠地存储在 Max-T FAM 上, 那么它也能完整可靠地存储在 GFAM 上. 然而, 存在一些模式对集合能完整可靠地存储在 GFAM 上, 但不能完整可靠地存储在任何 Max-T FAM 上.

证 假设模式对集合 $\{(A_k, B_k) \mid k \in K\}$ 能用带权值 w_{ij} 的 Max-T FAM 可靠地存储, 那么等式

$$b_{kj} = \bigvee_{i \in I} (a_{ki} T w_{ij}), \quad \forall j \in J, \forall k \in K$$

成立. 下文构造能可靠存储该模式对集的 GFAM 的 $\{w'_{ij}\}$ 和 $\{\lambda'_i \mid i \in I\}$.

选择 $\lambda'_i = 0, \forall i \in I$. 对 $\forall k \in K, \forall i \in I, \forall j \in J$, 首先令

$$U_{kj} = \{i \mid b_{kj} = a_{ki} T w_{ij}, i \in I\}.$$

因为等式 $b_{kj} = \bigvee_{i \in I} (a_{ki} T w_{ij})$ 成立, 故 $U_{kj} \neq \emptyset$. 定义 w'_{ij} 如下:

- 1) 如果 $i \in U_{kj}$, 则令 $w'_{ij} = a_{ki} T w_{ij} (= b_{kj})$;
- 2) 如果 $i \notin U_{kj}$, 则令 $w'_{ij} = 0$. 则

$$\begin{aligned} b_{kj} &= \bigvee_{i \in I} (a_{ki} \vee^{\lambda'_i} w'_{ij}) = \\ \bigvee_{i \in I} (a_{ki} \vee^0 w'_{ij}) &= \bigvee_{i \in I} (a_{ki} \wedge w'_{ij}) = \\ [\bigvee_{i \in U_{kj}} (a_{ki} \wedge w'_{ij})] \vee [\bigvee_{i \in I - U_{kj}} (a_{ki} \wedge w'_{ij})] &= \\ [\bigvee_{i \in U_{kj}} (a_{ki} \wedge (a_{ki} T w_{ij}))] \vee [\bigvee_{i \in I - U_{kj}} (a_{ki} \wedge 0)] &= \\ \bigvee_{i \in U_{kj}} (a_{ki} T w_{ij}) &= b_{kj} (a_{ki} \geq a_{ki} T w_{ij}). \end{aligned}$$

因此集合 $\{(A_k, B_k) \mid k \in K\}$ 能可靠地存储在权值为 w'_{ij} 且 $\lambda'_i = 0, \forall i \in I$ 的 GFAM 上.

构造模式对集合 $\{(A_k^*, B_k^*) \mid k \in K\}$, 使它满足

$$\forall k \in K, \forall i \in I, 0 \leq a_{ki}^* < 1,$$

又令

$$\forall i \in I, \lambda_i^* = \lambda^*, 1 \geq \lambda^* > \bigvee_{k \in K} \bigvee_{i \in I} a_{ki}^*.$$

再令

$$\forall k \in K, \forall j \in J, b_{kj}^* = \lambda^*.$$

则集合 $\{(A_k^*, B_k^*) | k \in K\}$ 必能可靠地存储在带参数向量 $(\lambda^*, \lambda^*, \dots, \lambda^*)$ 和权值 w_{ij}^* 的GFAM上, 其中:

$$\forall i \in I, \forall j \in J, 1 \geq w_{ij}^* \geq \lambda^* > \bigvee_{k \in K} \bigvee_{i \in I} a_{ki}^*.$$

这是因为有

$$\forall k \in K, \forall j \in J,$$

$$\bigvee_{i \in I} (a_{ki}^* \vee^{\lambda_i^*} w_{ij}^*) = \bigvee_{i \in I} \lambda_i^* = \lambda^* = b_{kj}^*.$$

然而集合 $\{(A_k^*, B_k^*) | k \in K\}$ 不能完整可靠地存储在任何Max-T FAM上, 这是由于对带任何权值矩阵 $\{w_{ij}^*\}$ 的Max-T FAM有

$$b_{kj} = \bigvee_{i \in I} (a_{ki}^* \wedge w_{ij}) \leq \bigvee_{i \in I} a_{ki} < \lambda^* = b_{kj}^*.$$

证毕.

定理3表明GFAM比Max-T FAMs可靠存储多模式对的能力强得多. 有趣的是, 通过仔细分析定理3的证明过程, 可发现当 $\forall i \in I, \lambda_i = \lambda$ 的特例GFAM模型就比Max-T FAM簇存储能力强很多.

4 GFAM的一种学习算法(A Learning algorithm for the GFAM)

神经网络的BP学习算法是一种基于梯度的比较通用的学习算法, 但它有可能限于局部极小值点、收敛速度慢, 甚至不一定收敛等不足. 对于一个具体的神经网络模型, 只有结合它的结构特征, 才有可能开发出一个快速有效的学习算法. 这通常是困难而充满技巧性的. 对于Max-T FAMs已经提出了一些解析型学习算法. 下面提出的GFAM学习算法利用了模糊关系方程, 其求解方法研究一直活跃^[10~12].

命题 1^[12] 假设已知 $R = (r_{ij})_{n \times m}$ 和 $B = (b_1, b_2, \dots, b_m)$, 则关于 $X = (x_1, x_2, \dots, x_n)$ 的模糊关系方程 $X \circ R = B$ 有解的充分必要条件是等式 $\bar{X} \circ R = B$ 成立, 其中 $\bar{x}_i = \bigwedge_{j \in J} \{b_j | r_{ij} > b_j\}$, 且当方程有解时, $\bar{X}$ 是最大解. 对于空集 $\emptyset$, 此处约定 $\bigwedge \emptyset = 1$. 算子“ $\circ$ ”代表模糊关系合成运算.

在命题1中, 模糊关系方程 $X \circ R = B$ 是方程 $\bigvee_{i \in I} (x_i \wedge r_{ij}) = b_j (j \in J)$ 的简写形式. 注意到 $\bar{X}$ 的表达式在命题1中已直接给出, 可以直接用该表达式编程以检查模糊关系方程是否有解. 近几年人们利用模糊关系方程或关于t-范数T的广义模糊关系方程的解直接给出了FAM甚至Max-T FAM的解析型学习算法^[10]. 例如, 对于FAM已有一个有效的所谓

Max-Min学习算法. 只要这些模式对能完整可靠地存储在FAM上, 它就能为一组训练模式对直接提供合适的连接权值 w_{ij} . 这种算法的成功归于对模糊蕴涵算子 φ 的巧妙利用, 其中 φ 表示为

$$(a \varphi b) = \begin{cases} 1, & a \leq b, \\ b, & a > b. \end{cases}$$

在模糊集理论和技术中模糊蕴涵算子^[13]是非常有用的概念, 如构造Max-T FAM的学习算法的常用方法就是在学习算法中利用某个合适的蕴涵算子.

下面同样利用模糊蕴涵算子, 为GFAM提出一个Max-Min- λ 学习算法:

步骤 1 基于第 k 个模式对 (A_k, B_k) 和蕴涵算子 φ , 给出了一种 $n \times m$ 的临时权值矩阵 W_k , $W_k = (w_{ij}^{(k)}) = a_{ki} \varphi b_{kj} (k \in K)$.

步骤 2 将上述临时权值矩阵 W_k 合并成为最终的权值矩阵 $\bar{W}$,

$$\bar{W} = \bigcap_{k=1}^p W_k = \left(\bigwedge_{k=1}^p (a_{ki} \varphi b_{kj}) \right).$$

步骤 3 用下述方法来确定GFAM的参数 $\lambda_i (i \in I)$:

验证对于任意 $k \in K$, 等式 $A_k \circ \bar{W} = B_k$ 是否成立, 即验证式(2)是否为真:

$$\bigvee_{i \in I} (a_{ki} \wedge \bar{w}_{ij}) = b_{kj}, \forall k \in K, \forall j \in J. \quad (2)$$

这里GFAM的权值矩阵 $\bar{W}$ 由步骤1与步骤2给出.

a) 如果式(2)成立, 令 λ_i 在区间 $[0, \bigvee_{i \in I} (a_{ki} \wedge \bar{w}_{ij})]$

上任意取值, 其中 $i \in I$.

b) 如果式(2)不成立, λ_i 的取值如下:

$$\lambda_i = \bigwedge_{k \in K, j \in J} \{b_{kj} | r_{kij} > b_{kj}\}.$$

其中: $r_{kij} = a_{ki} \vee \bar{w}_{ij}$, $k \in K$, $i \in I$, $j \in J$.

假设对于空集 $\emptyset$, $\bigwedge_{k \in K, j \in J} \emptyset = 1$ (参见上述命题1).

本文以下部分有如下约定: 对于任意模式对集合 $\{(A_k, B_k) | k \in K\}$, 两个矩阵 $[A_1 A_2 \dots A_p]^T$ 和 $[B_1 B_2 \dots B_p]^T$ 分别记为 A 和 B . 对于任意两个 $h_1 \times h_2$ 的矩阵 $E = (e_{ij})$ 和 $F = (f_{ij})$, $E \subset F$ 意味着对于任意 i 和 j 不等式 $e_{ij} < f_{ij}$ 成立.

根据命题1易知, 如果关系 $A \circ \bar{W} \subset B$ 成立, 训练模式集 $\{(A_k, B_k) | k \in K\}$ 不能完整可靠地存储在FAM上, 这里权值矩阵 $\bar{W}$ 由上述GFAM的学习算法的步骤1与2得到.

定理 4 假设GFAM采用了上述Max-Min- λ 学习算法, 且训练集 $\{(A_k, B_k) | k \in K\}$ 满足关系 $A \circ \bar{W}$

$\subset B$, 那么当且仅当等式 $\bar{A} \circ R_k = B_k, \forall k \in K$ 成立时, 训练集就能被完整可靠地存储在连接权值为 $\bar{w}_{ij}$ 的 GFAM 上, 这里权值矩阵 $\bar{W}$ 由步骤 1 和 2 确定, 且:

$$\bar{A} = (\bar{\lambda}_1 \bar{\lambda}_2 \cdots \bar{\lambda}_n), \quad \bar{\lambda}_i = \bigwedge_{k \in K, j \in J} \{b_{kj} | r_{kij} > b_{kj}\},$$

$$R_k = (r_{kij})_{n \times m} = (a_{ki} \vee \bar{w}_{ij})_{n \times m}.$$

证 集合 $\{(A_k, B_k) | k \in K\}$ 能完整可靠地存储在连接权值为 $\bar{w}_{ij}$ 的 GFAM 上, 当下列带有多个未知数 $\lambda_1, \lambda_2, \cdots, \lambda_n$ 的方程有且仅有一个解时

$$\bigvee_{i \in I} (a_{ki} \vee^{\lambda_i} \bar{w}_{ij}) = b_{kj}, \quad \forall k \in K, \quad \forall j \in J, \quad (3)$$

即

$$\left\{ \begin{aligned} & \bigvee_{i \in I} [(a_{ki} \wedge \bar{w}_{ij})] \vee \bigvee_{i \in I} [\lambda_i \wedge (a_{ki} \vee \bar{w}_{ij})] = b_{kj}, \\ & \forall k \in K, \quad \forall j \in J. \end{aligned} \right. \quad (4)$$

因有已知条件 $(A_k \circ \bar{W})_j < b_{kj}$, 所以方程组(4)能变换为如下形式:

$$\bigvee_{i \in I} [\lambda_i \wedge (a_{ki} \vee \bar{w}_{ij})] = b_{kj}, \quad \forall k \in K, \quad \forall j \in J. \quad (5)$$

根据命题 1, 式(5)有解当且仅当等式 $\bar{A} \circ R_k = B_k, \forall k \in K$ 成立. 因此集合 $\{(A_k, B_k) | k \in K\}$ 能完整可靠地存储在连接权值为 $\bar{w}_{ij}$ 的 GFAM 上, 当且仅当 $\bar{A} \circ R_k = B_k, \forall k \in K$ 成立. 证毕.

本学习算法直接给出了网络权值和 λ_i 的解析表达式, 易于进行数学性质分析, 无需迭代, 时间效率高, 整个学习过程只涉及取大($\vee$)和取小($\wedge$)两种运算, 易于硬件实现. 近来提出了基于遗传算法的求解模糊关系方程的方法. 就本 GFAM 而论, 该方法需要迭代, 只能求近似解, 过程复杂, 不易硬件实现.

对于输入为 n 维向量且输出为 m 维向量的 GFAM 和 Max-T FAM 模型, 训练后进行输出计算时, GFAM 计算复杂度为 $m \cdot n$ 次 $\vee^{\lambda}$ 运算加 $m \cdot (n-1)$ 次取大 $\vee$ 运算, 而 Max-T FAM 计算复杂度为 $m \cdot n$ 次 T 模运算加 $m \cdot (n-1)$ 次取大 $\vee$ 运算. 因为 $\vee^{\lambda}$ 本质上是由 3 次取小 $\wedge$ 运算和 2 次取大 $\vee$ 运算构成, 而常见的 T 模运算(除 $T = \wedge$ 外)一般都比 $\vee^{\lambda}$ 运算耗时. 所以训练后, 通常 GFAM 比 Max-T FAM 产生输出的计算复杂度要小, 甚至从本质上小很多. 例如, 当

$$T(x, y) = 1 - \min[1, ((1-x)^p + (1-y)^p)^{1/p}].$$

且 n 和 m 比较大时.

5 实验(Experiment)

5.1 比较 GFAM 和任意 Max-T FAM 的存储能力 (Storage capacity comparison between the GFAM and any Max-T FAM)

本实验中使用由 6 个模式对组成的训练模式对集合 $\text{TRAIN_SET} = \{(A_k, B_k) | k = 1, 2, \cdots, 6\}$ (见

表 1). 首先注意到, 对任意的 t -范数 T 和相应的 Max-T FAM 的任意连接权矩阵 $W = (w_{ij})_{6 \times 2}$, 当送入 A_4 给网络 Max-T FAM 时, 得到的输出 B_4^* 不等于 B_4 , 这是因为

$$b_{41}^* = \bigvee_{i=1}^6 [a_{4i} T w_{i1}] \leq \bigvee_{i=1}^6 [a_{4i} T 1] = 0.7 < b_{41} = 0.8.$$

所以, TRAIN_SET 不能被任意 Max-T FAM 模型完整可靠存储, 但 TRAIN_SET 能被 GFAM 完整可靠存储. 当 GFAM 采用本文提出的 Max-Min- λ 学习算法时, 相应的连接权矩阵 $\bar{W}$ 和 λ_i 的取值见表 2.

表 1 本实验用的训练多模式对

Table 1 The training pattern pairs used in the experiment

	A_k	B_k
1	0.7, 0.2, 0.4, 0.6, 0.3, 0.8	0.8, 0.8
2	0.9, 0.4, 0.4, 1.0, 0.7, 0.0	1.0, 0.95
3	0.3, 0.6, 0.5, 0.5, 0.2, 0.9	0.8, 0.8
4	0.1, 0.7, 0.4, 0.7, 0.7, 0.7	0.8, 0.8
5	0.3, 0.6, 0.4, 0.8, 0.2, 0.4	0.8, 0.8
6	0.7, 0.9, 0.6, 0.1, 0.7, 0.4	0.9, 0.9
7	0.8, 0.1, 0.6, 0.5, 0.4, 0.3	0.8, 0.8

表 2 GFAM 采用 Max-Min- λ 学习算法得到的 λ_i 和连接权矩阵

Table 2 The obtained λ_i and weight matrix of the GFAM using the Max-Min- λ learning algorithm

i	λ_i	$(\bar{w}_{ij})_{6 \times 2}$	i	λ_i	$(\bar{w}_{ij})_{6 \times 2}$
1	0.8	1.0, 1.0	4	0.8	1.0, 0.95
2	0.8	1.0, 1.0	5	0.8	1.0, 1.0
3	0.8	1.0, 1.0	6	0.8	0.8, 0.8

5.2 GFAM 应用于图象联想 (Application of the GFAM in an image association)

本实验给出 GFAM 在图像联想方面的应用(由一个小学女生联想到她同桌男生). 当女生图像出现一些噪声时, 通过 GFAM 依然能基本联想到她同桌男生.

图 2 中两同桌学生图像的灰度级为 256、大小为 64×64 . 图 2 中左、右图像的上半部分分别作为一个训练模式对的前件和后件, 由左、右图像的下半部分构成另一训练模式对. 构建相应 GFAM, 采用本文提出的学习算法训练后存储图 2 中两图像. 将图 2 女生图像加入灰度不等的 7 个噪声斑块后成为图 3 女生图像, 并将其送入 GFAM, 输出图像为图 3 的男生图像, 其与图 2 男生图像基本一致.




图2 被GFAM存储的女生和男生图象

Fig. 2 Images of a girl and a boy stored by GFAM




图3 送入含噪声的女生图象给GFAM后联想到的男生图象

Fig. 3 The associated boy image when the noisy girl image is presented to the GFAM

6 结论(Conclusions)

聚合算子 $\vee^\lambda$ 能统一算子 $\vee$ 和 $\wedge$, 特别地, 由于参数 λ 使它具有灵活性和适应性. 得益于这种算子的很好的性质, GFAM结构简单, 易于硬件电路实现, 具有一致连续性, 其映射能力和存储能力比模糊神经网络簇Max-T FAMs强得多, GFAM的Max-Min- λ 学习算法是一种解析型的学习算法, 易于性质分析和软件实现. 在本文的结论和分析技巧的基础上, 可对GFAM的泛化能力、容错性、鲁棒性、学习算法的设计和实际应用作进一步研究. GFAM良好性能预示了其良好的应用潜力.

参考文献(References):

- [1] 李德毅, 刘常昱. 不确定性人工智能[J]. 软件学报, 2004, 15(11): 1583 – 1594.
(LI Deyi, LIU Changyu. Artificial intelligence with uncertainty[J]. *Journal of Software*, 2004, 15(11): 1583 – 1594.)
- [2] VALLE M E, SUSSNER P. A general framework for fuzzy morphological associative memories[J]. *Fuzzy Sets and Systems*, 2008, 159(7): 747 – 768.
- [3] COH H, LIM J H, QUEK C. Fuzzy associative conjuncted maps network[J]. *IEEE Transactions on Neural Networks*, 2009, 20(8): 1302 – 1319.
- [4] 乔俊飞, 王会东. 模糊神经网络的结构自组织算法及应用[J]. 控制理论与应用, 2008, 25(4): 703 – 707.
(QIAO Junfei, WANG Huidong. Structure self-organizing algorithm for fuzzy neural networks and its applications[J]. *Control Theory & Applications*, 2008, 25(4): 703 – 707.)
- [5] 张化光, 何希勤. 模糊自适应控制理论及其应用[M]. 北京: 北京航空航天大学出版社, 2002.
(ZANG Huaguang, HE Xiqin. *Theory and Application of Fuzzy Self-adaptive Control*[M]. Beijing: Beijing Aeronautics and Astronautics University Press, 2002.)
- [6] 徐蔚鸿, 宋鸾姣. 训练模式的摄动对模糊双向联想记忆网络的影响及其控制[J]. 计算机学报, 2006, 29(2): 337 – 344.
(XU Weihong, SONG Luanjiao. Influences and control of perturbation of training pattern pairs on fuzzy bidirectional associative memories[J]. *Chinese Journal of Computers*, 2006, 29(2): 337 – 344.)
- [7] CHUNG F L, LEE T. On fuzzy associative memory with multiple-rule storage capacity[J]. *IEEE Transactions on Fuzzy Systems*, 1996, 4(3): 375 – 384.
- [8] SUSSNER P, VALLE M E. Implicative fuzzy associative memories[J]. *IEEE Transactions on Fuzzy Systems*, 2006, 14(6): 793 – 807.
- [9] LIU P Y. The fuzzy associative memory of max-min fuzzy neural network with threshold[J]. *Fuzzy Sets and Systems*, 1999, 107(2): 147 – 157.
- [10] STAMOU G B, TZAFESTAS S G. Neural fuzzy relational systems with a new learning algorithm[J]. *Mathematics and Computers in Simulation*, 2000, 51(1): 301 – 314.
- [11] PEDRYCZ W. S-t fuzzy relational equations[J]. *Fuzzy Sets and Systems*, 1993, 59(2): 189 – 195.
- [12] 谢季坚, 刘承平. 模糊数学方法及其应用[M]. 武汉: 华中科技大学出版社, 2000.
(XIE Jijian, LIU Chengping. *Fuzzy Mathematics and Its Applications*[M]. Wuhan: China Central University of Science and Technology Press, 2000.)
- [13] YING M S. Implication operators in fuzzy logic[J]. *IEEE Transactions on Fuzzy Systems*, 2002, 10(1): 88 – 91.

作者简介:

李 鹰 (1961—), 男, 副教授, 主要研究方向为不确定性人工智能、灰色理论和数据库技术, E-mail: liying5196@163.com;

徐蔚鸿 (1963—), 博士, 教授, 博士生导师, 主要研究方向为不确定性人工智能、模糊系统、模式识别和软件工程, E-mail: xwhxd@163.com;

唐良荣 (1963—), 讲师, 主要研究方向为人工智能与数据库技术, E-mail: tlr1688@163.com.