

文章编号: 1001-0920(2006)04-0415-06

一种模糊逻辑推理神经网络的结构及算法设计

韩 敏^a, 孙燕楠^a, 许士国^b

(大连理工大学 a 电子与信息工程学院, b 土木水利学院, 辽宁 大连 116024)

摘 要: 建立了一种基于模糊逻辑推理的神经网络, 由样本获取的初始规则确定规则层神经元个数, 并确立模糊化层与规则层之间的连接。利用黄金分割法确定模糊化层隶属度函数的初始中心和宽度; 根据初始规则的结论确定清晰化层的初始权值; 针对网络结构提出了改进的 BP 算法。仿真实例表明, 网络结构合理, 具有较好的非线性映射能力, 改进的 BP 算法适合于此网络, 与另一种模糊神经网络相比较具有较快的训练速度和较好的泛化能力。

关键词: 模糊逻辑推理; 神经网络; 规则; 黄金分割法

中图分类号: TP18 **文献标识码:** A

Structure and Algorithm Design of a Fuzzy Logic Inference Neural Network

HAN M in^a, SUN Yan-nan^a, XU Shi-guo^b

(a School of Electronic and Information Engineering, b School of Civil and Hydraulic Engineering, Dalian University of Technology, Dalian 116024, China. Correspondent: HAN M in, E-mail: minhan@dlut.edu.cn)

Abstract: A fuzzy neural network is proposed according to the fuzzy logic inference. Initial rules are got from samples and every rule becomes a neuron of the rule layer. How fuzzification layer and rule layer connect with each other is determined by the rules. The initial centers and widths of membership functions of the fuzzification layer are decided based on the golden partition method. And the initial weights of defuzzification layer are determined according to the conclusions of the initial rules. For the structure of the fuzzy neural network an improved back propagation (BP) algorithm is presented. The results of simulation show the nonlinear mapping ability of the fuzzy neural network. Compared with the existed results, the fuzzy neural network has faster training speed and better generalization ability.

Key words: Fuzzy logic inference; Neural network; Rule; Golden partition method

1 引 言

模糊神经网络广泛应用于控制、模式识别、数据融合等领域, 模糊系统与神经网络的结合方式各种各样, 所以许多学者针对模糊神经网络不同的结构和算法进行了研究。综合目前的各种模糊神经网络, 一般可分为两类^[1]: 根据模糊数计算得到的模糊神经网络^[2~5]; 以模糊规则的逻辑推理过程为基础而形成的模糊神经网络^[6~9]。第 1 类模糊神经网络, 其结构沿袭普通的多层前向网络, 但输入输出为模糊语言值, 权值一般取模糊数或清晰数, 所以权值调整

算法是根据模糊数的计算特点而改进的 BP 算法, 主要用于模拟模糊规则集, 进行近似推理。第 2 类模糊神经网络的输入输出为精确值, 一般包括模糊化、推理和清晰化过程, 此类网络由于规则表达形式的多样性以及网络模拟方法的灵活性而产生了各种结构和算法, 主要用于时间序列预测、多种信息融合等方面。

根据模糊逻辑推理建立的神经网络有一个确定规则的过程, 以往规则数是随机设定的, 或根据输入样本模糊空间的划分考虑所有可能的规则。如果输

收稿日期: 2005-02-02; 修回日期: 2005-05-24

基金项目: 国家自然科学基金重点项目 (50139020)。

作者简介: 韩敏 (1959—), 女 (朝鲜族), 吉林省吉林市人, 教授, 博士, 从事神经网络、3S 系统及混沌序列分析等研究; 孙燕楠 (1979—), 女, 山东滨州人, 博士生, 从事模糊神经网络的研究。

入变量为 n 个, 每个输入变量的语言值为 m 个, 则所有可能的规则数是 m^n 个^[10]. 输入变量和语言值的增加使得规则数成指数增长, 增加了运算负担. 本文建立的模糊逻辑推理神经网络 (Fuzzy Logic Inference Neural Network, FL NN), 由样本确定规则层的神经元, 减少了不必要的运算量; 然后根据已经确定的规则决定规则层与模糊化层之间的连接, 并根据结构给出改进的 BP 算法; 最终利用仿真实例证明了此模糊神经网络对非线性映射的模拟能力, 并验证了学习算法的可行性. 通过与文献 [11, 12] 提出的模糊神经网络对比, 表明了此网络具有较好的训练速度和泛化能力.

2 FL INN 设计

2.1 模糊逻辑推理过程

模糊逻辑推理是一种近似推理, 它是从一组模糊“ If-Then ”规则和已知事实中得出结论的推理过程. 模糊规则的表达形式有以下几种^[11]:

1) Zadeh-Mamdani 模糊规则

If x_1 is A and x_2 is B , Then y is C .

其中 A, B, C 是模糊语言值

2) Takagi-Sugeno 模糊规则

If x_1 is A and x_2 is B ,
Then y is $a \cdot x_1 + b \cdot x_2 + c$

其中: A, B, C 是模糊语言值; a, b, c 是常数

3) 带有重要性和可信度的 Zadeh-Mamdani 模糊规则

If x_1 is A ($D I_1$) and x_2 is B ($D I_2$),
Then y is C ($C F_c$).

其中: $D I_1, D I_2$ 表示每个条件的重要性; $C F_c$ 表示此规则的可信度

4) 代表某个空间中数据聚类相关性的模糊规则: If 输入向量 x 属于一个输入聚类, 此聚类由聚类中心和半径 R -in 决定. 其中: 元素 x_1 is A , 隶属度为 $M D_1$, 元素 x_2 is B , 隶属度为 $M D_2$; Then y 属于一个输出聚类, 此聚类由聚类中心和半径 R -out 决定, 其中: 元素 y is C , 隶属度为 $M D_c$.

5) 时间规则: If x_1 在 t_1 时刻的重要度是 $D I_1, x_2$ 在 t_2 时刻的重要度是 $D I_2$, Then y is C ($C F_c$).

6) 时间、回归规则: If x_1 is A ($D I_1$) and x_2 is B ($D I_2$) and y 在时刻 $(t - k)$ is C ; Then y 在 $(t + n)$ 时刻 is D ($C F_d$).

假设 A, B, C 分别是 X, X, Y, Y, Z 的模糊集合, 模糊蕴含 $A \times B \rightarrow C$ 表示为 $X \times Y \times Z$ 上的模糊关系 R , 则由“ x_1 is A and x_2 is B ”和简单的规则“ If x_1 is A and x_2 is B , Then y is C ”, 导出模糊集合为 $C = (A \times B) \circ (A \times B \rightarrow C)$. 这是一个简

单的模糊推理过程. 如果有 m 条规则, 每条规则得到的结论分别为 C_1, C_2, \dots, C_m , 则由 m 条规则集得到的最终结论为各个结论的模糊逻辑和, 即 $C = C_1 \cup C_2 \cup \dots \cup C_m$. 推理过程首先在推理前提中选取各个条件中隶属度最小值, 称为取小操作; 然后对各个规则结论进行综合, 选取其中适配度最大的部分, 即取大操作. 这是普通的推理方法, 其推理结果不够光滑, 所以将取小操作改为乘积, 取大操作改为考虑所有可能的结果, 进行加权平均.

根据模糊逻辑推理得到的模糊神经网络结构和算法有很多种, 主要因为规则表达形式的不同和神经网络对推理过程模拟的灵活性. 文献 [11, 12] 运用规则 3) 和规则 4), 建立了 5 层全连接网络, 将规则条件的重要度和结论的可信度作为网络权值, 第 3 和第 4 层使用 Sigmoid 函数作为激励函数. 文献 [6] 利用了规则 1) 和规则 2), 分别建立了两种模糊神经网络: 根据规则 1), 建立了简单模糊推理神经网络; 根据规则 2), 建立了线性模糊推理神经网络. 而有些神经网络虽然也考虑了逻辑推理过程, 但并没有明显利用哪种规则, 而是普通的 3 层网络, 只是隐层神经元的输入以及激励函数选用比较特殊^[13].

2.2 FL INN 的结构设计

针对规则 3), 并根据上述模糊逻辑推理过程建立了一种新的模糊逻辑推理神经网络 (FL NN), 结构如图 1 所示. 共分为模糊化层、规则层和清晰化层. 输入为 n 个: x_1, x_2, \dots, x_n ; 输出为 y . 每个输入有 m 个语言值, 规则层节点数为 l .




图 1 FL INN 结构

2.2.1 模糊化层

采样的输入量一般是精确量, 要利用模糊逻辑推理方法, 就必须首先将输入的精确量模糊化. 此过程对应于网络的模糊化层, 所要完成的功能是用带

有模糊语气的语言值代替精确值 变量的语言值可分为“小、中、大”3个,或“差、较差、中、较好、好”5个.进行模糊化的方法有很多种^[14-16],其中黄金分割是一种应用较为广泛的反映自然和谐美感的最优的分割模型,在隶属度未知的情况下用此模型可以得到较好的结果.语言值的隶属度函数的分布应符合黄金分割率,如果使用钟型隶属度函数,则越靠近论域中心,其覆盖范围越小.相邻的语言值中,离中心较近的语言值的熵是较远的0.618倍.假设 x_{min} 和 x_{max} 分别是论域的最小值和最大值,变量有3个语言值,中间的隶属度函数表示为

$$G_0(\mu_0, \sigma_0) = \exp(- (x - \mu_0)^2 / \sigma_0^2),$$

左右的隶属度函数分别为 $G_{-1}(\mu_{-1}, \sigma_{-1}), G_{+1}(\mu_{+1}, \sigma_{+1})$.其中: $(\mu_{-1}, \sigma_{-1}), (\mu_0, \sigma_0), (\mu_{+1}, \sigma_{+1})$ 分别是3个隶属度函数的均值和均方差,利用一般方法确定为

$$\begin{aligned} \mu_{-1} &= x_{min}, \\ \mu_0 &= (x_{min} + x_{max}) / 2, \\ \mu_{+1} &= x_{max}, \\ \sigma_{-1} &= \sigma_0 = \sigma_{+1} = (x_{max} - x_{min}) / 4 \end{aligned}$$

利用黄金分割法确定的均值与一般方法确定的相同,但均方差不同,如下:

$$\begin{aligned} \sigma_{-1} &= (x_{max} - x_{min}) / 4, \\ \sigma_0 &= \sigma_{-1} \times 0.618, \\ \sigma_{+1} &= \sigma_{-1} \end{aligned}$$

基于黄金分割模型划分的语言值覆盖范围更符合论域的分布规律,所以本文利用此方法确定了模糊化层的权值 A_{ij} 和 B_{ij} .则模糊化层的输出为

$$\begin{aligned} \text{OutA}_{ij} &= \exp(- (x_i - A_{ij})^2 / B_{ij}^2), \\ i &= 1, 2, \dots, n, j = 1, 2, \dots, m. \end{aligned} \quad (1)$$

2.2.2 规则层

全部可能规则为 m^n 个,但并不是所有的规则都有意义,所以先根据样本确定初始的规则集.共有 p 个样本的样本集 $\{S_1, S_2, \dots, S_p\}$,将训练样本输入已确定隶属度的模糊化层进行模糊化,取隶属度最大的语言值作为输入量的模糊值.假设输入的语言值划分为3个,分别为1-“小”,2-“中”,3-“大”,编号后易于编程实现初始规则获取.每输入一个样本就可以得到一条规则;然后对于重复的规则只保留一个,而对于矛盾的规则,予以保留,以便在以后的网络训练中进行选择.规则层中的每个神经元代表一条规则.根据规则集的条件,可以确定规则层与模糊化层的连接.例如,规则

If x_1 is Small and x_2 is Big,
Then y is Small

则代表 x_1 是“小”的神经元和代表 x_2 是“大”的神经元分别与代表这条规则的神经元相连.根据模糊推理过程,规则层的输出为

$$\text{OutB}_i = \text{OutA}_{1,j_1} \cdot \text{OutA}_{2,j_2} \cdot \dots \cdot \text{OutA}_{n,j_n} \quad (2)$$

其中: $i = 1, 2, \dots, l$ 和 j_1, j_2, \dots, j_n 是 $1 \sim m$ 之间的数,由第 i 条规则的前件确定

2.2.3 清晰化层

清晰化利用重心法.根据重心法公式,网络输出

$$y = \text{OutC}_3 = \frac{\sum_{i=1}^l \text{OutB}_i \cdot W_i}{\sum_{i=1}^l \text{OutB}_i} \quad (3)$$

其中 W_i 是 C_3 层的权值

2.3 改进的BP算法

此模糊神经网络需要调整的参数是A层和C层的权值.A层的初始权值利用上述黄金分割模型确定.而C层初始权值一般随机确定,虽然有时可能收敛,但有时也会出现网络振荡直至发散的现象.所以本文根据已经获取的初始规则的结论部分确定C层初始权值.假设输出的语言值的隶属度函数也取高斯函数,某一规则的结论为“中”,其隶属度是0.4,则权值确定过程如图2所示.由隶属度0.4分别加减0.1得到隶属度选择区间 $[0.3, 0.5]$,当 $\mu = 0.3$ 时, $x = a$ 或 $x = d$;当 $\mu = 0.5$ 时, $x = b$ 或 $x = c$.清晰化初始权值的可选择区间为 $[a, b]$ 或 $[c, d]$.对这两个区间进行随机选取,产生一随机数 rand_1 ,如果 $\text{rand}_1 \geq 0.5$,则产生另一随机数 rand_2 ,清晰化初始权值 $W_i = a + \text{rand}_2 \cdot (b - a)$;如果 $\text{rand}_1 < 0.5$,则产生随机数 $\text{rand}_2, W_i = c + \text{rand}_2 \cdot (d - c)$.这样确定初始的清晰化权值,使得权值的确定范围缩小在可能的最小区间,使网络减少搜索时间,并保证网络收敛.




图 2 清晰化权值确定示意图

A层和C层的权值调整过程是根据多层网络的误差反向传播算法(BP)实现的.因为与普通的多层网络神经元计算不同,所以将此网络的误差反向传

播算法称为改进的BP算法。神经元是神经网络基本的信息处理单元,此网络的神经元共分为3种:图1中A层模糊化层的神经元是第1种,一个输入 x ,两个参数 a 和 b , f 为高斯函数, $y = \exp(-(x - a)^2)/b$;图1中B层规则层的神经元和 C_2 层的神经元是第2种,各个输入相乘, f 取线性函数, $y = f(x_1 \cdot x_2 \cdot \dots \cdot x_n)$; C_3 层中的神经元是第3种,属于普通神经元, f 一般取线性函数或Sigmoid函数,此处取线性函数 $y = f(x_1 \cdot W_1 + x_2 \cdot W_2 + \dots + x_n \cdot W_n)$ 。

为使目标函数 $E = \frac{1}{2}(\hat{y} - y)^2$ 最小,其中 \hat{y} 是期望输出, y 是实际输出。利用改进的BP算法,权值的调整计算公式如下:

清晰化权值的调整

$$\Delta W_k = - \frac{\partial E}{\partial y} \cdot \frac{\partial y}{\partial W_k} = - [-(\hat{y} - y)] \cdot \text{Out}C_{2k} \quad (4)$$

此处: $\text{Out}C_{2k}$ 是 C_2 层第 k 个神经元的输出, $k = 1, 2, \dots, l$

高斯函数中心的调整

$$\Delta A_{ij} = \left(\frac{\partial E}{\partial y} \cdot \frac{\partial y}{\partial \text{Out}C_{2k}} \cdot \frac{\partial \text{Out}C_{2k}}{\partial \text{Out}B_k} \cdot \frac{\partial \text{Out}B_k}{\partial \text{Out}A_{ij}} \right) \cdot \frac{\partial \text{Out}A_{ij}}{\partial A_{ij}} = \text{Mid} \cdot \frac{\partial \text{Out}A_{ij}}{\partial A_{ij}} \quad (5)$$

同理,宽度的调整

$$\Delta B_{ij} = \left(\frac{\partial E}{\partial y} \cdot \frac{\partial y}{\partial \text{Out}C_{2k}} \cdot \frac{\partial \text{Out}C_{2k}}{\partial \text{Out}B_k} \cdot \frac{\partial \text{Out}B_k}{\partial \text{Out}A_{ij}} \right) \cdot \frac{\partial \text{Out}A_{ij}}{\partial B_{ij}} = \text{Mid} \cdot \frac{\partial \text{Out}A_{ij}}{\partial B_{ij}} \quad (6)$$

其中

$$\text{Mid} = \sum_{k=1}^l (\hat{y} - y) \cdot W_k \cdot \frac{\text{Out}B_s - \text{Out}B_k}{\left(\sum_{s=1}^l \text{Out}B_s \right)^2} \cdot \frac{\text{Out}B_k}{\text{Out}A_{ij}} \quad (7)$$

$$\frac{\partial \text{Out}A_{ij}}{\partial A_{ij}} = 2 \cdot \text{Out}A_{ij} \cdot \frac{(x_i - A_{ij})}{B_{ij}^2}; \quad (8)$$

$$\frac{\partial \text{Out}A_{ij}}{\partial B_{ij}} = 2 \cdot \text{Out}A_{ij} \cdot \frac{(x_i - A_{ij})^2}{B_{ij}^3}; \quad (9)$$

$\text{Out}A_{ij}$ 是A层各语言值的隶属度; $\text{Out}B_k$ 是B层第 k 个神经元的输出; $i = 1, 2, \dots, n, j = 1, 2, \dots, m$ 。

最终得到新的权值为

$$W_k(t+1) = W_k(t) + \Delta W_k,$$

$$A_{ij}(t+1) = A_{ij}(t) + \Delta A_{ij},$$

$$B_{ij}(t+1) = B_{ij}(t) + \Delta B_{ij}.$$

3 仿真实例

为验证网络结构和算法的合理性,给出一个仿真实例,同时对文献[11, 12]中的模糊神经网络(FuNN)进行了仿真,并与本文所提出的FLNN进行比较。

由混沌Rossler方程产生3组序列 X_1, X_2, X_3 ,进行非线性组合运算,得到输出 $Y = \sin(X_1 + X_2 + X_3)$ 。部分样本如表1所示,其输出的数值范围为 $[-3.3680, 5.1493]$ 。取其中350组样本训练网络,150组作为泛化样本。训练1000步后,比较两个网络对样本的拟和能力,其最终误差对比如表2所示。

表1 部分数据

	X_1	X_2	X_3	Y
1	1.0000	0.9973	0.9906	0.9802
2	-0.2051	-0.2589	-0.3126	-0.3661
3	-3.0806	-3.1228	-3.1606	-3.1939
⋮	⋮	⋮	⋮	⋮

表2 训练1000步时误差对比

	FLNN	FuNN
最终训练误差	0.0262	0.2739
最终泛化误差	0.0306	0.2773

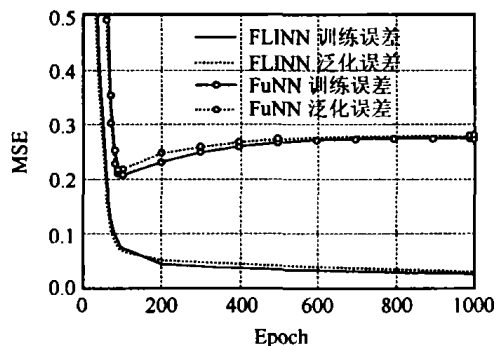


图3 训练误差与泛化误差曲线

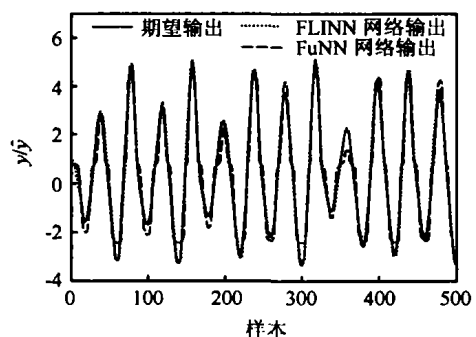




图4 期望输出与网络输出对比

示 两个网络的训练误差曲线和泛化误差曲线如图 3 所示 从误差曲线图的对比看, FL NN 的均方差是一个持续下降的过程; FuNN 误差有一个上升过程然后持续下降, 并且 1 000 步时的误差是 FL NN 的 10 倍左右 在训练 1 000 步时, 样本的期望输出、FL NN 网络的输出以及 FuNN 网络的输出如图 4 所示 从图 4 可以看出, FL NN 较好地拟合了此非线性函数, 可以得到理想的输出效果, 而 FuNN 的输出在值为 1 的附近的模拟有所变形, 其神经网络的输出普遍偏小


FL NN 训练过程中, 每个输入语言值的隶属度函数从初始确定到训练 1 000 步时的变化如图 5 示 其中实线为初始的隶属度函数, 虚线为网络训练后的隶属度函数



(a) x_1 的隶属度函数



(b) x_2 的隶属度函数



(c) x_3 的隶属度函数

图 5 输入变量语言值隶属度函数的变化

由图 5 可知, 变量 x_1 的“小”、“大”的隶属度函数几乎没有发生变化, 而“中”的隶属度函数中心向右偏移, 且宽度增大; 变量 x_2 的“小”、“大”的隶属度函数中心几乎没有偏移, 但宽度范围明显缩小, 而“中”的隶属度函数中心向右偏移, 且宽度增大; 变量 x_3 的 3 个语言值的隶属度函数中心都变化不大, 只是“小”的隶属度宽度变小, “中”和“大”的宽度都变大 由此可知, 网络对各个输入变量的隶属度进行了调整, 使每一组输入变量得到合适的语言值

输入变量 3 个, 每个变量的语言值取 3 个, 则所有可能规则是 3^3 个 由初始样本确定 11 条规则 FL NN 网络训练完毕, 所有样本 $\{S_1, S_2, \dots, S_{350}\}$ 输入网络, 相对于样本 i , C_2 层的第 j 条规则的输出为 $Out_{C_2}(i, j)$. 如果存在使第 j 条规则的可信度最大的样本, 则第 j 条规则存在, 并且可以根据其中一条样本确定其规则条件重要度与结论可信度之间的关系 本实例中最终得到 6 条规则, 如表 3 所示

表 3 FL NN 获取的规则

规则数	输入变量						输出变量	
	x_1	D_1	x_2	D_2	x_3	D_3	y	CF
1	中	0.6609	中	0.8000	中	0.9909	中	0.8097
2	小	0.9578	小	0.3536	小	0.8429	小	0.5325
3	大	0.9966	大	0.8774	大	0.9996	大	0.3034
4	小	0.2758	中	0.1805	中	0.8811	中	0.6147
5	中	0.9505	中	0.7127	大	0.9614	大	0.3042
6	小	0.7992	小	0.0597	中	0.6981	中	0.3368

4 结 论

本文根据模糊逻辑推理过程构建了一种新的模糊神经网络, 并根据网络的结构特点提出了改进的 BP 算法 此算法具有较好的泛化能力, 能很好地映射非线性函数 模糊逻辑推理神经网络根据样本确定初始的规则, 并在网络训练中不断地加以修正, 最终得到带有重要度和可信度的简化规则集 尝试利用黄金分割法确立模糊化层的初始权值, 并根据初始规则的结论确定清晰化层的初始权值 这些尝试通过仿真实例表明了其有效性 从与已有的模糊神经网络的对比可以看出, 模糊逻辑推理神经网络具有更快的训练速度和更好的泛化能力

参考文献 (References)

[1] Liu P Y. Max min Fuzzy Hopfield Neural Networks and an Efficient Learning Algorithm [J]. *Fuzzy Sets and Systems*, 2000, 112(1): 41-49

[2] James D, Donald W. Fuzzy Number Neural Networks [J]. *Fuzzy Sets and Systems*, 1999, 108(1): 49-58

[3] Hisao I, Manabu N. Numerical Analysis of the Learn-

- ing of Fuzzified Neural Networks from Fuzzy If-Then Rules[J]. *Fuzzy Sets and Systems*, 2001, 120(2): 281-307.
- [4] Li Z Q, Kecan V, Ichikawa A. Fuzzified Neural Network Based on Fuzzy Number Operations[J]. *Fuzzy Sets and Systems*, 2002, 130(3): 291-304
- [5] James D, Donald W. Fuzzy Regression by Fuzzy Number Neural Networks[J]. *Fuzzy Sets and Systems*, 2000, 112(3): 371-380
- [6] Oh S K, Pedrycz W, Park H S. Hybrid Identification in Fuzzy-neural Networks[J]. *Fuzzy Sets and Systems*, 2003, 138(2): 399-426
- [7] 孙有发, 陈世权, 吴今培, 等. 一种基于模糊遗传神经网络的信息融合技术及其应用[J]. *控制与决策*, 2001, 16(增刊): 717-720
(Sun Y F, Chen S Q, Wu J P, et al. Fuzzy Genetic Neural Network Based Information Syncretic Technology and Its Application[J]. *Control and Decision*, 2001, 16(S): 717-720.)
- [8] 荣莉莉, 王众托. 利用模糊神经网络实现数值信息与语言信息的融合[J]. *控制与决策*, 2001, 16(6): 958-961.
(Rong L L, Wang Z T. Realization of the Fusion of the Numerical and Linguistic Information Using a Fuzzy Neural Network [J]. *Control and Decision*, 2001, 16(6): 958-961.)
- [9] Shaout A, Scharboneau J. Fuzzy Logic Based Modification System for the Learning Rate in Backpropagation [J]. *Computers and Electrical Engineering*, 2000, 26(2): 125-139
- [10] 韩敏, 孙燕楠. 多输入模糊神经网络及其应用[J]. *系统工程与电子技术*, 2003, 25(10): 1249-1253
(Han M, Sun Y N. Multi-input Fuzzy Neural Network and Its Application[J]. *Systems Engineering and Electronics*, 2003, 25(10): 1249-1253.)
- [11] Nikola K. On-line Learning, Reasoning, Rule Extraction and Aggregation in Locally Optimized Evolving Fuzzy Neural Networks [J]. *Neurocomputing*, 2001, 41(1-4): 25-45
- [12] Nikola K, Jaesoo K, Michael J W, et al. FuNN/2-A Fuzzy Neural Network Architecture for Adaptive Learning and Knowledge Acquisition[J]. *Information Sciences*, 1997, 101(3-4): 155-175
- [13] Yu Y L, Xu L H, Wu Q D. Generalized Fuzzy Neural Network [J]. *Acta Automatica Sinica*, 2003, 29(6): 867-875
- [14] 邱凯昌. *空间数据挖掘与知识发现*[M]. 武汉: 武汉大学出版社, 2000: 1-182
(Di K C. *Spatial Data Mining and Knowledge Discovery* [M]. Wuhan: Wuhan University Press, 2000: 1-182.)
- [15] 荣莉莉, 王众托. 用模糊神经网络建立GNP与产业结构的关系模型[J]. *大连理工大学学报*, 1999, 39(1): 114-119
(Rong L L, Wang Z T. Using Fuzzy Neural Network to Build Model of Relationship between GNP and Structure of Industry [J]. *J of Dalian University of Technology*, 1999, 39(1): 114-119.)
- [16] 梅晓丹, 张毅刚, 孙圣和. 模糊神经网络语音数据融合算法的研究[J]. *控制与决策*, 2003, 18(2): 213-216
(Mei X D, Zhang Y G, Sun S H. Research on Speech Data Fusion Based on Fuzzy Neural Networks [J]. *Control and Decision*, 2003, 18(2): 213-216.)

(上接第 414 页)

- [7] Bloch I. Information Combination Operators for Data Fusion: A Comparative Review with Classification [J]. *IEEE Trans on Systems, Man, and Cybernetics*, 1996, 26(1): 52-67.
- [8] 李圣怡, 吴学忠, 范大鹏. *多传感器融合理论及在智能制造系统中的应用*[M]. 长沙: 国防科技大学出版社, 1998: 119-225
(Li S Y, Wu X Z, Fan D P. *Multisensor Fusion Theory and Its Application to Intelligent Manufacturing System* [M]. Changsha: National Defence Science and Technology University Publishing Company, 1998: 119-225.)
- [9] Chung A C S, Shen H C, Basir O A. A Decentralized Approach to Sensory Data Integration [A]. *IEEE/RSJ Int Conf on Intelligent Robots and Systems* [C]. Grenoble, 1997: 1409-1414