

文章编号: 1001-0920(2011)12-1803-05

一种基于聚类的超闭球模糊神经网络

李 慧^{1,2a}, 张庆范¹, 段培永^{2b}, 汪 明^{2b}

(1. 山东大学控制科学与工程学院, 济南 250061; 2. 山东建筑大学 a. 热能工程学院, b. 信息与电气工程学院, 济南 250101)

摘 要: 针对一类不确定非线性多输入多输出复杂系统, 根据系统的输入输出数据对, 提出一种基于聚类的超闭球模糊神经网络系统. 该系统通过改进的模糊聚类方法(FCM)确定模糊规则数, 采用高维隶属度函数取代常规的单维隶属度函数, 并对隶属度函数中心值和隶属度函数参数采用一步通过算法. 所提方法可降低系统的模糊规则数, 简化网络计算. 此外, 当系统的输入输出发生变化时, 可实现模糊规则库的在线修改. 仿真实例验证了所提方法的有效性.

关键词: 数据; 非线性系统; 模糊; 聚类; 多输入多输出

中图分类号: TP183

文献标识码: A

Hyperball fuzzy neural network based on clustering

LI Hui^{1,2a}, ZHANG Qing-fan¹, DUAN Pei-yong^{2b}, WANG Ming^{2b}

(1. School of Control Science and Engineering, Shandong University, Ji'nan 250061, China; 2a. School of Thermal Energy Engineering, 2b. School of Information and Electrical Engineering, Shandong Jianzhu University, Ji'nan 250101, China. Correspondent: LI Hui, E-mail: lhh@sdjzu.edu.cn)

Abstract: A hyperball fuzzy neural network algorithm is proposed for modeling of uncertain, high-dimensional and complex nonlinear systems based on clustering. Firstly, an improved fuzzy cluster method(FCM) is given to determine the number of fuzzy rules. The one-dimensional membership functions are replaced by the multi-dimensional membership functions. Then, a one-pass algorithm is presented to calculate the centers and parameters of membership functions. The proposed approach can reduce the number of fuzzy rules and simplify the network calculation. Moreover, the fuzzy rules base can be modified online when the input-output data changes. The simulation results show the effectiveness of the proposed approach.

Key words: data; nonlinear system; fuzzy; clustering; multi-input multi-output

1 引 言

在系统的控制和分析中, 系统模型是不可或缺的. 从广义上讲, 系统的模型可分为机理模型和实验模型. 但对于复杂的非线性系统, 很难建立系统的机理模型. 因此如何根据系统的输入输出数据建立系统的数学模型显得尤为重要. 目前比较典型的是 ARMAX 模型^[1-2]和 NARMAX 模型^[3-4], 虽然它们可避开复杂的机理建模过程, 但不能利用已知的系统信息, 并且这两种模型是黑箱模型, 难以理解. 随着神经网络模型研究的发展, 人们开始利用神经网络非线性函数的逼近能力对复杂系统建模, 并取得了很大成就^[5-7]. 但神经网络建模的随机性很大(网络结构的随机性和初始参数的随机性), 不能利用系统的已知信

息, 并且神经网络模型是一个“黑箱”模型, 没有明确的物理意义, 从而很难进行系统分析和控制器的设计. 模糊神经网络不但具有良好的函数逼近能力和强大的自学习功能, 而且可利用系统信息对网络进行结构和参数初始化, 从而减小了网络的规模, 简化了系统性能分析和控制器设计过程. 与单纯的模糊系统相比, 模糊神经网络系统的优势在于可根据由真实系统的输入输出数据对构成的样本集来设计系统. 但目前模糊神经网络存在的主要缺陷如下:

1) 模糊神经网络的规则数通常是根据经验确定, 没有解决模糊系统规则数目问题.

2) 当系统维数较高时, 将高维输入转变成多个单维输入, 会导致系统规则库庞大, 令系统变得复杂.

收稿日期: 2010-08-06; 修回日期: 2010-12-18.

基金项目: 国家自然科学基金面上项目(61074070); 山东省自然科学基金项目(Y2008G07, ZR2009GZ004); 山东省科技攻关项目(2009GG10001029).

作者简介: 李慧(1970—), 女, 副教授, 从事智能环境、智能控制等研究; 张庆范(1949—), 男, 教授, 博士生导师, 从事智能控制、电力电子等研究.

在设计模糊神经网络系统的过程中,选择一个适当的规则数目很重要.规则太多会令系统变得复杂,这种复杂的系统可能对于问题的解决不是必需的,或者是难以设计和运行的;而规则太少又会令系统的作用削弱,增加系统的无效性,这种无效性往往导致系统难以完成该问题的目标.再者,目前的模糊神经网络由于需要耗时的迭代计算,很难用于复杂非线性系统的在线建立.为了解决上述问题,本文提出一种新型基于聚类的超闭球模糊神经网络(HFNNBC)用于高维非线性系统的模型建立.该方法的主要特点如下:

- 1) 对输入数据进行模糊聚类,确定模糊规则数.
- 2) 采用高维隶属度函数取代单维隶属度函数,从而不需要将高维数据转化为多个单维数据.
- 3) 对隶属度函数中心值和标准偏差采用一步通过算法(OPA)简化模型计算.

2 HFNNBC网络结构及算法

由于一个多输入多输出模糊系统可分解为多个多输入单输出系统,不失一般性,在此只考虑多输入单输出系统.图1为HFNNBC网络结构,每一行对应一条模糊规则,共有 l 条模糊规则,隶属度函数采用高斯函数.




图1 HFNNBC网络结构

该网络结构共分如下5层:

第1层:输入层.主要是对多维输入信号进行归一化处理.

第2层:规则选择标志层. $s = [s_1, s_2, \dots, s_l]$ 为规则选择标志向量.其中: s_i 为第 i 条规则的选择标志位,若 $s_i = 1$,则该规则被选中;若 $s_i = 0$,则该规则未被选中.

第3层:输入模糊语言变量层 $T(x) = \{A_1, A_2, \dots, A_i, \dots, A_l\}$.其中: A_i 为第 i 个模糊语言变量值,它是定义在输入论域 U 上的模糊集合,相应的隶属度函数采用高斯函数.输入模糊语言中心值向量 $C = [c_1, c_2, \dots, c_i, \dots, c_l]$, c_i 为 A_i 模糊语言变量的中心值. $\sigma = [\sigma_1, \sigma_2, \dots, \sigma_i, \dots, \sigma_l]$, σ_i 为该语言变量对应隶属度函数的参数,模糊语言变量数等于模糊规则数.

第4层:输出模糊语言变量层 $T(y) = \{B_1, B_2, \dots, B_i, \dots, B_l\}$.其中: B_i 为第 i 个模糊输出语言变

量值,它是定义在输出论域 V 上的模糊集合,输出模糊语言中心值向量 $w = [w_1, w_2, \dots, w_l]^T$,则 w_i 为 B_i 模糊语言变量的中心值.采取单点模糊化方法, $A_i \rightarrow B_i$ 对应一条模糊规则,若采用If-Then规则,则第 i 条规则可表示如下:

If x is A_i , then y is B_i .

第5层:解模糊化层,得到系统的精确输出.

2.1 归一化

设 \bar{U} 是有界输入空间,对任意可能的输入 \bar{x} , $\bar{x} \in \bar{U} = \bar{M}_1 \times \bar{M}_2 \times \dots \times \bar{M}_n$,其中 $\bar{M}_i = [\bar{x}_{\min i}, \bar{x}_{\max i}]$ ($i = 1, 2, \dots, n$)为输入空间维数.为了便于隶属度函数参数的选取及所设计的模糊神经网络不依赖于输入空间 \bar{U} ,将输入向量 \bar{x} 进行归一化处理,即

$$x_i = \frac{\max - \min}{\bar{x}_{\max i} - \bar{x}_{\min i}} (\bar{x}_i - \bar{x}_{\min i}) + \min. \quad (1)$$

其中: $M_i = [\min, \max]$, $x \in M_1 \times M_2 \times \dots \times M_n$.

2.2 模糊规则数和输入模糊中心值的确定

对于最优模糊神经网络系统,一个数据对可对应一条模糊规则,但对于大样本问题需要对输入输出数据对进行聚类分组,使得一组数据对应一条模糊规则.模糊 C 均值(FCM)^[8]聚类能很好地处理高维数据空间的聚类问题,在复杂非线性模糊控制系统数据空间的模糊划分中有着广泛的应用,但FCM需要预先设置聚类数目.而对于多输入多输出数据对的模糊聚类,其聚类数目无法确定.对此,本文对FCM方法进行改进,根据聚类准则的收敛性,当聚类数目增加时,聚类准则函数的收敛速度逐渐变慢,当收敛速度慢到一定程度时,即得到合适的聚类数目.聚类数目即为该模糊系统的模糊规则数,同时确定了模糊神经网络结构参数 $C = [c_1, c_2, \dots, c_l]$.具体聚类步骤如下:

Step 1: 设置聚类数目 l 为一个较小的数目,并确定终止条件 ε .

Step 2: 为 l 个聚类中心赋初值.

Step 3: 采用FCM聚类方法对样本进行聚类.

Step 4: 计算如下聚类准则函数:

$$J = \sum_{i=1}^l \sum_{j=1}^{N_i} (x_j^i - c_i)^2, \quad (2)$$

其中 N_i 为属于第 i 个聚类中心的数据对数.

Step 5: 根据给出的判定阈值 ε ,当 $|J_{t+1} - J_t| \leq \varepsilon$ 时,表示聚类数目合适,聚类停止;否则令 l 加1,转Step 2.

这样,获取了 l 个聚类中心值 $C = [c_1, c_2, \dots, c_i, \dots, c_l]$,每个聚类中心为 n 维向量,即 $c_i = [c_{i1}, c_{i2}, \dots, c_{in}]$.

2.3 神经网络算法

对于常规的模糊神经网络,通常是将多维输入简

化为多个单维输入, 再对每个单维输入进行模糊划分, 定义多个模糊语言变量, 对应一定的输入 x 求其隶属于每个语言变量的隶属度. 对于高维系统, 显然该方法繁琐, 且形成的模糊系统结构复杂. 本文从另一个角度, 采用高维隶属度函数, 对系统的输入进行高维模糊划分.

定义 1(高维隶属度函数) 若隶属度函数采用高斯函数, 则有

$$\mu_{A_i}(x) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right). \quad (3)$$

其中: c_i 为模糊语言变量 A_i 的中心值; σ_i 为高斯隶属度函数的参数, 即

$$\sigma_i = \frac{\min\|c_i - c_j\|_{\substack{j=1,2,\dots,l \\ i \neq j}}}{\sqrt{-2\ln\delta}}, \quad (4)$$

$\delta = 0.5$ 为相邻两个模糊语言变量的重叠区.

当输入为 x 时, 则以 x 为中心, 定义超闭球

$$HC = \{c \mid \|c - x\| \leq R_b\}, \quad x \in U. \quad (5)$$

其中: R_b 为超闭球半径, 取 $R_b = (2 - 3)\bar{\sigma}$, 这里 $\bar{\sigma} = \frac{1}{l} \sum_{i=1}^l \sigma_i$ 为各隶属度函数标准偏差的算术平均值. 在 HC 上定义高斯隶属度函数

$$\mu_i(c_i) = \begin{cases} \exp\left(-\frac{\|c_i - x\|^2}{2\sigma^2}\right), & c_i \in HC; \\ 0, & c_i \notin HC. \end{cases} \quad (6)$$

$S_{amp} = \{(x_k, y_k)\} (k = 1, 2, \dots, N_s)$ 为学习样本, $\forall x_k \in S_{amp}$, 则以 x_k 为中心的超闭球包含 N_l 个聚类中心, 即 N_l 条规则被激活. 规则选择标志向量记为 S_k , 若第 j 个元素为 1, 则说明 HC 包含 c_j , 若为零则说明不包含. 例如: 输入维数为 3, $x = [x_1, x_2, x_3]$, 根据改进的 FCM 聚类方法对输入数据进行聚类, 得到模糊规则数 l 和模糊聚类中心 $C = [c_1, c_2, \dots, c_l]$, 如图 2 所示. 图中: 黑色圆点为聚类中心, 表示相应模糊输入语言变量的中心值, 共获得 12 条规则; 黑色五角星表示输入 x_k . 以 R_b 为半径 x_k 为中心画一超闭球, 则超闭球内的规则被激活, 选择向量 S_k 中相应规则标志位置 1, 即规则 5, 8, 11, 12 相应的标志位置 1. 超闭球外的规则没有被激活, 即其他规则的标志位保持为 0.




图 2 三维输入聚类中心分布及超闭球

对应的 HFNNBC 网络输出为

$$y_k = \frac{S_k^T U(x_k) w}{S_k^T \mu(x_k)} = \frac{\sum_{i=1}^l s_{ki} \mu_i(x_k) w_i}{\sum_{i=1}^l s_{ki} \mu_i(x_k)} = \frac{\sum_{i \in HC} \mu_i(x_k) w_i}{\sum_{i \in HC} \mu_i(x_k)}. \quad (7)$$

其中

$$U(x_k) = \text{diag}[\mu_1(x_k), \mu_2(x_k), \dots, \mu_l(x_k)];$$

$$\mu(x_k) = [\mu_1(x_k), \mu_2(x_k), \dots, \mu_l(x_k)]^T;$$

$S_k = [s_1, s_2, \dots, s_l]^T$ 为模糊规则选择标志向量; $w = [w_1, w_2, \dots, w_l]^T$ 为模糊神经网络输出参数, 对应输出语言变量中心值向量.

2.4 输出参数 w 学习算法

2.4.1 w 参数的初始值确定

根据模糊聚类算法将学习数据划分为 l 组, 每组对应一条模糊规则. 假如第 p 组数据包含 N_p 个数据对. 其聚类中心为 c_p , 即对应该组数据的规则前件是相同的, 对应规则可表示如下:

If x_1^p is A^p then y is y_1 ,

If x_2^p is A^p then y is y_2 ,

⋮

If x_N^p is A^p then y is y_N .

每条规则的权值为

$$\mu_{A^p}(x_j^p) = \exp\left(-\frac{\|x_j^p - c_p\|^2}{2\sigma^2}\right), \quad j = 1, 2, \dots, N_p.$$

则有

$$w_o^p = \frac{\sum_{j=1}^{N_p} \mu_{A_j^p} y_j^p}{\sum_{j=1}^{N_p} \mu_{A_j^p}}, \quad (8)$$

其中 w_o^p 为 P 组模糊规则的输出. 令

$$u_{B^p}(w_o^p) =$$

$$\max\{u_{B^1}(w_o^p), u_{B^2}(w_o^p), \dots, u_{B^l}(w_o^p)\},$$

其中 B^p 为被选择的语言变量. 则 P 组模糊规则可被简化为一条模糊规则, 即

If x is A^p then y is B^p .

这样依次确定每组的输出参数 w_o^j , 最终形成输出参数的初始值 $w_o = (w_o^1, w_o^2, \dots, w_o^l)$.

2.4.2 w 参数的学习校正

w 参数的学习校正采用改进的 C-L 算法^[9], 即

$$\Delta w_{k-1} = \frac{\alpha e_{k-1} U(x_{k-1}) S_{k-1}}{\beta + \frac{S_{k-1}^T U(x_{k-1}) U^T(x_{k-1}) S_{k-1}}{S_{k-1}^T u(x_{k-1}) u^T(x_{k-1}) S_{k-1}}}, \quad (9)$$

其中 α, β 为常数. 当 $0 < \alpha < 2, \beta > 0$ 时, 该算法是收敛的. 对于每一个样本, 只需局部调整权系数. 整个系统的建模过程如下:

Step 1: 采集学习样本, 得到系统的输入输出数据对;

Step 2: 对输入数据进行模糊聚类, 确定模糊规则数和模糊聚类中心;

Step 3: 根据模糊聚类组的划分, 确定每条模糊规则输出的初始值;

Step 4: 计算 HFNNBC 的输出;

Step 5: 计算学习样本均方差, 若满足要求, 则转 Step 7;

Step 6: 修正输出参数向量 w , 并转 Step 4;

Step 7: 学习结束.

3 规则库的在线修改

在样本数据不完备的情况下, 建立的规则库也是不完备的. 此外, 对于实际的非线性复杂系统, 随着系统的运行及参数变化, 也会导致系统的输出发生变化. 这时需要对规则库进行在线修改, 具体步骤如下:

Step 1: 在线采集样本数据 $S_{\text{amp}} = (x, y)$;

Step 2: 以样本输入数据为中心画一超闭球, 判断是否有规则包含在内, 若有则转 Step 4;

Step 3: 以新的样本数据为中心点形成一条新的规则, 计算方法同上;

Step 4: 计算 HFNNBC 网络输出;

Step 5: 计算误差, 若误差小于学习阈值, 则转 Step 7;

Step 6: 局部修正超闭球内的规则参数 w ;

Step 7: 规则修正结束.

4 实验与分析

为了验证 HFNNBC 算法的有效性, 分别通过 HFNNBC, 基于 Takagi-Sugeno 的 FNN 和 FCMAC^[10] 辨识一多步时延非线性动态系统, 并对其进行比较.

具有多步时延的非线性系统如下:

$$\begin{cases} y(k+1) = \\ f(y(k), y(k-1), y(k-2), u(k), u(k-1)), \\ y(k+1) = \\ (y(k)y(k-1)y(k-2)u(k)u(k-1)(y(k-2)- \\ 1) + u(k))/(1 + y(k-1)^2 + y(k-2)^2), \\ u(k) = \sin(k\pi/25). \end{cases} \quad (10)$$

即当前输出为前 3 个输出 $y(k), y(k-1), y(k-2)$ 和前 2 个输入 $u(k), u(k-1)$ 的函数.

根据上述公式产生样本学习数据为

$$S_{\text{amp}} = \{(y_k, y_{k-1}, y_{k-2}, u_k, u_{k-1}), (y_{k+1})\},$$

$$k = 1, 2, \dots, N_s.$$

输入为 5 维, 输出为 1 维. 样本数据分为学习样本和

检验样本, 其中前 250 个数据为学习样本, 后 300 个数据为检验样本. 现将 HFNNBC 与常规的 FNN 和 FCMAC 作比较. 采用 HFNNBC 方法对系统进行建模, 通过改进的 FCM 聚类算法共得到 40 个聚类中心, 每个聚类中心为 5 维向量, 共获得 40 条模糊规则. 对应的输入模糊语言变量可表示为 $T(x) = \{A_1, A_2, \dots, A_i, \dots, A_{40}\}$, w 为输出模糊语言变量的中心值向量, 对应的输出模糊语言变量可表示为 $T(y) = \{B_1, B_2, \dots, B_i, \dots, B_{40}\}$. 如: 第 1 个聚类中心为 $[0.7319, 0.7684, 0.8404, 0.8490, 0.9052]$, 即模糊输入语言变量 A_1 的中心值, w 的第 1 个值为 0.6106, 即输出模糊语言变量 B_1 的中心值. 则第 1 条模糊规则可表示为: If x is A_1 then y is B_1 .

同时采用 FNN 对系统建模, 取每个输入的模糊划分为 3 个语言变量, 产生的模糊规则数为 $3^5 = 243$; 采用 FCMAC 神经网络对系统建模, 取每个输入的模糊划分为 5 个语言变量 (仿真结果显示, 3 个模糊语言变量划分不能很好地对该系统进行学习), 产生的模糊规则数为 $5^5 = 3125$. 图 3 为多步时延非线性动态系统的实际输出曲线和仿真曲线. 从图 3 中可以看出, HFNNBC, FNN 都可以精确地辨识高维非线性系统, 而 FCMAC 的辨识精度比 HFNNBC 和 FNN 低.

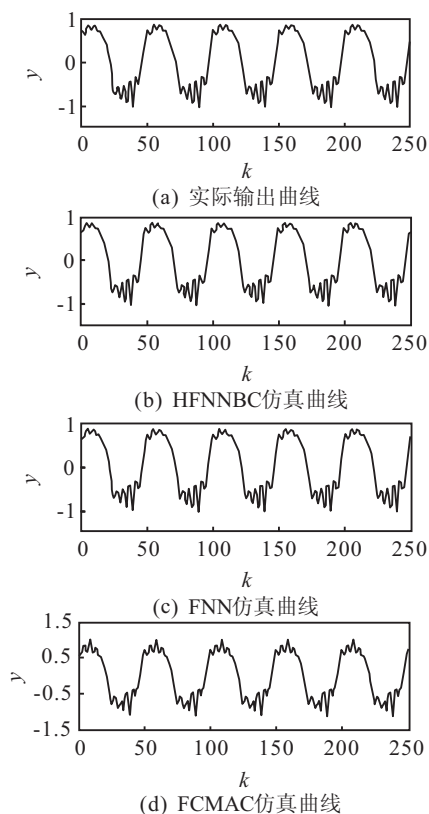


图 3 实际曲线和仿真曲线

图 4 为 HFNNBC, FNN 和 FCMAC 随学习次数增加的误差变化曲线, 迭代次数为 40. 学习误差采用 RMSE (root mean square error) 表示, 学习结束后,

HFNNBC, FNN和FCMAC的学习误差分别为: 1.0×10^{-4} , 5.5×10^{-4} 和 2.8×10^{-3} ,显然HFNNBC的学习误差最小.对于HFNNBC,初始情况下通过输出参数 w 来确定初始值(OPA算法,迭代次数为1),HFNNBC的学习误差为 1.7×10^{-3} ,比FCMAC经过多次迭代后的误差还小.因此一般情况下,若精度要求不是很高,则所提出的HFNNBC可采取一步通过方法,而不需要迭代.




图4 3种算法误差变化曲线

将学习后的HFNNBC用检验样本验证,图5为HFNNBC学习样本误差曲线和检验样本误差曲线.经过计算,HFNNBC的泛化误差为 1.724×10^{-4} ,为其学习误差的1.724倍.因此,HFNNBC具有较好的泛化能力.

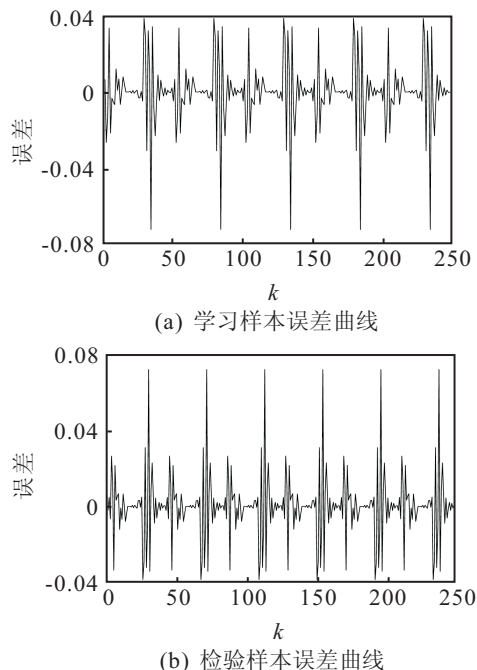


图5 学习样本和检验样本误差曲线

5 结论

常规的模糊神经网络不仅很难确定系统的模糊规则数,而且当系统维数增加时会导致模糊规则库容量呈指数增加,在实际应用中受到限制.本文根据高维非线性系统的输入输出数据提出一种HFNNBC算法,用于高维非线性系统的模型建立及在线修改.主要结论如下:

1) 该算法可有效地降低系统的模糊规则数,简化系统模型;

2) 仿真结果表明,该算法建立的模型精度优于常规的FNN算法和FCMAC算法;

3) 通过HFNNBC OPA算法建立的模型精度优于FCMAC多次迭代后的模型精度,因此当系统模型精度要求不是很高时,可采用OPA算法简化模型计算.

参考文献(References)

- [1] Akal Mustafa. Forecasting Turkey's tourism revenues by ARMAX model[J]. *Tourism Management*, 2004, 25(10): 565-580.
- [2] Maddison David. Air pollution and hospital admissions: An ARMAX modelling approach[J]. *J of Environmental Economics and Management*, 2005, 49(1): 116-131.
- [3] Rahrooh Alireza, Shepard Scott. Identification of nonlinear systems using NARMAX model[J]. *Nonlinear Analysis, Theory, Methods and Applications*, 2009, 71(12): 1198-1202.
- [4] Ge S S, Zhang J, Lee T H. Adaptive MNN control for a class of non-affine NARMAX systems with disturbances[J]. *Systems and Control Letters*, 2004, 53(1): 1-12.
- [5] Ma Cheng-qian, Yue Xi, Jiang De-sheng. Intelligent model of urban road tunnel ventilation system based on multi-level neural network[C]. *Proc of the 2009 Pacific-Asia Conf on Circuits, Communications and System*. Chengdu, 2009: 636-639.
- [6] Altiparmak Fulya, Dengiz Berna, Smith Alice E. A general neural network model for estimating telecommunications network reliability[J]. *IEEE Trans on Reliability*, 2009, 58(1): 2-9.
- [7] Liu Bo, Li Hui-guang, Wu Ti-hua. Neural network identification method applied to the nonlinear system[C]. *Proc of the 2009 WRI Global Congress on Intelligent Systems*. Xiamen, 2009: 120-124.
- [8] Bezdek James C. *Pattern recognition with fuzzy objective function algorithms*[M]. New York: Plenum, 1981.
- [9] 段培永, 邵惠鹤. 基于广义基函数的CMAC学习算法的改进及其收敛性分析[J]. *自动化学报*, 1999, 25(2): 258-293.
(Duan P Y, Shao H H. Improved algorithm of CMAC with general basis function and its convergence analysis[J]. *Acta Automatica Sinica*, 1999, 25(2): 258-293.)
- [10] 段培永, 张玫, 邵惠鹤. 一种基于模糊CMAC自学习模糊逻辑系统及其在控制中的应用[J]. *上海交通大学学报*, 2002, 36(4): 543-546.
(Duan P Y, Zhang M, Shao H H. CMAC based self-learning fuzzy logical system and its application to automatic control[J]. *J of Shanghai Jiaotong University*, 2002, 36(4): 543-546.)