

文章编号: 1001-0920(2009)01-0013-05

一种基于改进客观聚类分析的模糊辨识方法

王 娜, 杨煜普

(上海交通大学 自动化系, 上海 200240)

摘 要: 针对模糊辨识中采用迭代和人为决策法确定模糊规则数时易受噪声和人为因素的影响, 而导致算法鲁棒性较差和计算量较高的问题, 提出一种基于改进客观聚类分析的模糊辨识方法. 首先引入并改进了客观聚类分析法, 克服了迭代导致的规则数冗余, 降低了人为因素对聚类结果的影响, 从而减小了计算量并提高了鲁棒性; 然后结合模糊聚类和稳态卡尔曼滤波法, 分别辨识了前提和结论参数; 最后通过 Box-Jenkins 仿真实例验证了所提方法的有效性.

关键词: 模糊辨识; 客观聚类分析; 稳态卡尔曼滤波; 模糊聚类

中图分类号: TP273

文献标识码: A

A fuzzy identification method based on the enhanced objective cluster analysis

WANG Na, YANG Yupu

(Department of Automation, Shanghai Jiaotong University, Shanghai 200240, China. Correspondent: WANG Na, E-mail: wangna2004@sjtu.edu.cn)

Abstract: In fuzzy identification, iterations or human decision making are usually used to identify fuzzy rules. However, the clustering result is possibly affected by noise and artificial factor, which results in weak robustness and high computation cost. In this paper, a fuzzy identification method based on the enhanced objective cluster analysis is presented. Firstly, the objective cluster analysis algorithm is introduced and enhanced such that the redundant rule numbers caused by iterations is overcome and the effect of human factor on the clustering result is decreased. Therefore, the computation burden is reduced, and the robustness of the algorithm is improved. Then, the premise parameters and the consequence parameters are identified by fuzzy c -means clustering algorithms and the stable Kalman filter algorithm respectively. The effectiveness of the proposed method is verified by the example of Box-Jenkins gas furnace simulation.

Key words: Fuzzy identification; Objective clustering analysis; Stable-state Kalman filter; Fuzzy clustering

1 引 言

在模糊建模中, 实现模糊模型精度和复杂性的良好折衷, 不仅可以防止模型过拟合, 而且有利于提高参数辨识的效率, 使模型易于解释和理解^[1].

模糊建模的主要手段之一是模糊辨识. 目前, 各种模糊聚类算法在模糊辨识中得到了广泛应用, 因其可以基于数据自动划分输入模糊空间和提取规则, 从而避免了网格法和决策树法的维数灾问题. 由于聚类个数即模糊规则数事先未知, 通常采用 3 种方法确定^[2]: 1) 从给定的初始聚类个数开始, 采用递增法或融合法^[3]迭代聚类个数, 直至满足性能指标或预设阈值为止. 递增法和融合法的共同缺点是

迭代所导致的计算量较高. 此外, 前者易受噪声影响而导致最终聚类个数冗余, 而后的聚类个数受预设的初始参数影响较大, 因此两种聚类结果的鲁棒性均较差. 2) 采用山峰或减法聚类构造初始模型结构, 再基于正交变换法^[4]删除不重要的聚类进行结构精简, 以克服过拟合. 但聚类是否冗余仍需根据性能指标试凑决定, 因此聚类个数受人为因素影响较大. 3) 比较法^[5], 其综合多种有效性指标来评价给定范围内的聚类有效性, 并权衡比较确定满意的聚类个数, 但聚类结果受人为因素影响较大, 从而导致鲁棒性较差, 并加大了计算量.

针对传统方法易受噪声和人为因素影响而导致

收稿日期: 2007-10-22; 修回日期: 2008-05-05.

基金项目: 国家 973 计划项目(2004CB720703).

作者简介: 王娜(1977—), 女, 河北衡水人, 博士生, 从事模糊建模、智能控制的研究; 杨煜普(1957—), 男, 西安人, 教授, 博士生导师, 从事智能控制、工业测控计算机网与智能信息处理等研究.

聚类结果鲁棒性较差和计算量较高的问题,本文提出一种基于改进客观聚类分析(EOCA)的模糊辨识方法.首先引入并改进了客观聚类分析法(OCA)^[6],利用其偶极子和层次聚类确定聚类结果,从而降低了人为因素的影响;其次,通过对层次聚类引入相对不相似性测度^[7]和改进 OCA 的一致性准则,加强了聚类结果的鲁棒性,因而克服了聚类个数冗余,同时降低了聚类个数迭代和人为因素导致的计算量;再次,聚类结果确定后,与模糊 c 均值聚类算法(FCM)相结合,可直接确定前提参数;最后,采用稳态卡尔曼滤波算法^[8]辨识结论参数,再次提高了算法的计算效率.通过标准及输入-输出叠加白高斯噪声的 Box-Jenkins 煤气炉系统^[9]的仿真结果验证了本方法的有效性.

2 基于 EOCA 的模糊辨识算法描述

EOCA 方法首先利用 OCA 的偶极子划分训练数据集为不同的训练子集,分别进行层次凝聚聚类,其聚类范围覆盖了建模对象中所有可能的非线性特征,因而保证了模糊空间划分的完备性;其次,针对层次聚类易受噪声影响的特点,引入了相对不相似性测度进行聚类合并,并改进了 OCA 的一致性准则,基于该准则确定了两个候选聚类;再次,与模糊 c 均值聚类算法和稳态卡尔曼滤波算法相结合,分别构造两个候选模型;最后,基于误差指标由二者择一,从而实现了建模精度和规则数的较好折衷.

2.1 EOCA 算法

2.1.1 相关定义

定义 1(偶极子) 给定训练数据集 $X = \{x_1, x_2, \dots, x_N\}$, 将形如 $\begin{bmatrix} x_i \\ x_j \end{bmatrix}$ 的样本对称称为偶极子, 记作 O_{ij}^k . 其中: $i, j, k = 1, 2, \dots, N; k = 1, \dots, \frac{N \times (N-1)}{2}$. 令 $d_{ij} = |x_i - x_j|$ 表示偶极子 O_{ij}^k 的值, 其中 $| \cdot |$ 表示欧式距离.

定义 2(相对不相似性测度) 相对不相似性测度表示在层次凝聚聚类的每次聚类合并过程中, 相同训练子集内, 不同聚类之间的相似程度, 其定义如下:

$$D_{ij} = \text{dis}_{ij} / \min(\bar{D}_{ij}, \bar{D}_{ji}), \quad (1)$$

$$\bar{D}_{ij} = \frac{\text{dis}_{ik}}{c-2}, \quad (2)$$

其中: D_{ij} 表示聚类 i 和 j 的相对不相似度, $i, j, k = 1, \dots, c$; c 表示每次聚类的个数; dis_{ij} 表示聚类 i 和 j 的欧式距离; \bar{D}_{ij} 表示 i 到除 j 之外其他聚类的平均距离; \bar{D}_{ji} 同理.

定义 3(改进一致性准则) 改进一致性准则表

示层次凝聚聚类中, 由偶极子对应样本数据形成的不同训练子集之间, 每次聚类结果的相似性程度, 其表达式为

$$BL_{\text{new}} = \frac{1}{mc} \sum_{t=1}^m \sum_{i,j=1}^c (V_{Ai}^t - V_{Bj}^t)^2. \quad (3)$$

其中: m 表示数据样本维数; V_{Ai}^t 表示训练子集 X_A (见 3.1.2 节) 中聚类 i 的聚类中心分量 t ; V_{Bj}^t 表示训练子集 X_B 中与 X_A 的聚类中心 i 最近的聚类 j 的聚类中心分量 t .

2.1.2 EOCA 原理

EOCA 原理如图 1 所示.

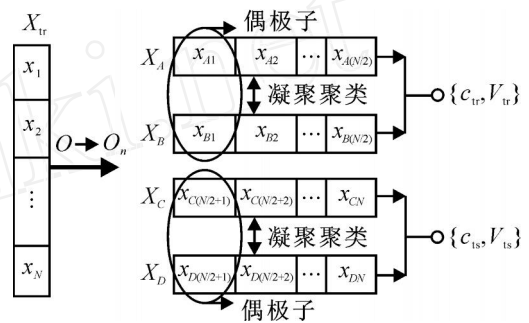


图 1 EOCA 原理示意图

首先, 由训练数据集 $X_{tr} = \{x_1, x_2, \dots, x_N\}$ 产生 $N \times (N-1)/2$ 个偶极子 (取 N 为偶数), 构成原始偶极子集 O , 再根据偶极子值的大小按升序排列构成偶极子集 O_n . 然后, 选取 $x_r = \sum_{i=1}^N x_i / N$ 作为参考点, 从 O_n 中取出前 $N/2$ 个包含不重复样本的偶极子, 将每个偶极子中距离 x_r 近的元素构成训练子集 $X_A = \{x_{A1}, \dots, x_{A(N/2)}\}$, 其中每个元素按照距离远近排列; 对于每个偶极子中距离 x_r 远的元素, 同理得到训练子集 $X_B = \{x_{B1}, \dots, x_{B(N/2)}\}$. 最后, 从 O_n 中剩余的偶极子中再取出前 $N/2$ 个包含不重复样本的偶极子, 按同样方法得到训练子集 X_C 和训练子集 X_D .

训练子集划分完毕后, 首先对 X_A 和 X_B 分别进行层次凝聚聚类, 相应得到两个集合 $\{\{C_{N/2-1}^A, V_{N/2-1}^A\}, \{C_{N/2-2}^A, V_{N/2-2}^A\}, \dots, \{C_2^A, V_2^A\}\}$ 和 $\{\{C_{N/2-1}^B, V_{N/2-1}^B\}, \{C_{N/2-2}^B, V_{N/2-2}^B\}, \dots, \{C_2^B, V_2^B\}\}$. 其中: C_i^A 表示对应 X_A 得到的包含 i 个聚类的集合, V_i^A 表示其 i 个聚类的聚类中心集合. 同理获得 C_i^B 和 $V_i^B, i = N/2-1, N/2-2, \dots, 2$. 然后基于最小改进一致性指标, 从产生的聚类集合中确定聚类个数 c_{tr} 以及聚类中心 V_{tr} . 其中: V_{tr} 为聚类个数为 c_{tr} 时合并两两距离最近的 C_i^A 和 C_j^B 后确定的聚类中心; $i = 1, \dots, c_{tr}; j = 1, \dots, c_{tr}$. 同理通过 X_C 和 X_D 得到 c_{ts} 和 V_{ts} . 最后由 $\{c_{tr}, V_{tr}\}$ 和 $\{c_{ts}, V_{ts}\}$ 构成候选聚类, 以便由后续

FCM 和稳态卡尔曼滤波算法得到的最小误差性能指标确定最终聚类结果。

EOCA 的聚类步骤归纳如下：

Step1: 根据偶极子定义, 将训练数据集划分为训练子集 X_A, X_B 和训练子集 X_C, X_D 。

Step2: 对 X_A 和 X_B 分别进行层次凝聚聚类, 并基于最小改进一致性指标确定聚类个数 c_{tr} 和对应的聚类中心 V_{tr} ; 同理对 X_C 和 X_D 得到 c_{ts} 和 V_{ts} , 构成候选聚类 $\{c_{tr}, V_{tr}\}$ 和 $\{c_{ts}, V_{ts}\}$ 。

2.1.3 EOCA 算法分析

与原始 OCA 算法相比, EOCA 算法对其在层次聚类中存在的 3 个主要问题做了如下改进：

1) OCA 以不同聚类中最邻近样本点间的距离作为类间距离, 进行聚类的两两合并. 但该方法未能准确反映每个类的分布特点, 容易导致“链式效应”。对此, EOCA 方法以各聚类的质心作为聚类中心进行聚类合并, 不但使物理意义明晰, 而且提高了聚类的准确性。

2) 在层次聚类中, OCA 算法采用的最邻近样本点合并方式容易受噪声等异常数据影响, 导致聚类准确率下降. 而 EOCA 引入相对不相似性测度来表示两两聚类间的相似性程度, 考虑了未合并的聚类对聚类结果的影响, 从而降低了聚类结果对数据分布的敏感性(见定义 2)。

3) 在 OCA 算法中, 采用了相同位置的聚类中对应样本点是否相同的一致性准则(如式(5)所示), 来评价不同训练子集每次聚类后聚类结果的一致性, 并选取一致性准则值为 0 时的聚类个数作为最终聚类个数. 因为不同子集中每个样本点间的一致性关系对聚类相似程度影响较大, 所以极易降低聚类的一致性结果, 导致误判断. EOCA 算法则以不同训练子集间距离最近的聚类中心的平均偏差(见定义 3)来表示每次聚类结果的一致性, 不但能克服噪声等异常数据对聚类结果的干扰, 而且提高了一致性判断的准确率。

$$BL(P) = (P - P) / P. \tag{4}$$

其中: P 表示每次聚类个数, P 作为不同训练子集间对应位置聚类中样本点是否完全相同的标志. 若相同, 则 $P = 1$; 若不同, 则 $P = 0$ 。

EOCA 的优越性可通过以下简单实例予以说明。

考虑含 N 个样本的数据集 $X_d = \{x_1, x_2, \dots, x_N\}$. 其中: $x_i = \{x_i^1, x_i^2\}$; $x_i^1 \in R$ 表示输入; $x_i^2 \in R$ 表示输出; $i = 1, 2, \dots, N$, 为方便起见, 取 $N = 8$. $\{x_1, x_2, x_3, x_4\}$ 和 $\{x_5, x_6, x_7, x_8\}$ 为 X_d 上的实际聚类分布. 对于 X_d , 在其输出上叠加噪声信号后, 得到

信噪比为 40 dB 以上的数据集 $X_{noi} = \{x_1, x_2, \dots, x_8\}$. 采用 OCA 算法和 EOCA 算法分别对 X_{noi} 进行聚类. 首先, 在 X_{noi} 产生的全部 28 个偶极子中, 取出前 4 个包含不重复样本的偶极子, 按照距离参考点的远近, 分别构成训练子集 X_{dA} 和 X_{dB} ; 然后, 通过剩余的偶极子产生训练子集 X_{dC} 和 X_{dD} . 其中: $X_{dA} = \{x_1, x_2, x_8, x_7\}$, $X_{dB} = \{x_6, x_5, x_3, x_4\}$, $X_{dC} = \{x_2, x_1, x_7, x_4\}$, $X_{dD} = \{x_6, x_5, x_8, x_3\}$. OCA 和 EOCA 的层次聚类结果分别如表 1 和表 2 所示。

表 1 OCA 层次聚类结果

聚类个数	聚类对象	聚类结果及聚类位置	最小一致性指标
$P = 3$	X_{dA}	$\{x_1\}, \{x_2\}, \{x_7, x_8\}$	$(4 - 4) / 4 = 0$
	X_{dB}	$\{x_6\}, \{x_5\}, \{x_3, x_4\}$	$= 0$
$P = 2$	X_{dA}	$\{x_1, x_2\}, \{x_7, x_8\}$	$(4 - 4) / 4 = 0$
	X_{dB}	$\{x_6, x_5\}, \{x_3, x_4\}$	$= 0$
$P = 3$	X_{dC}	$\{x_2, x_4\}, \{x_1\}, \{x_7\}$	$(4 - 1) / 4 = 0.75$
	X_{dD}	$\{x_6, x_5\}, \{x_8\}, \{x_3\}$	$= 0.75$
$P = 2$	X_{dC}	$\{x_2, x_4\}, \{x_1, x_7\}$	$(4 - 0) / 4 = 1$
	X_{dD}	$\{x_6, x_5, x_8\}, \{x_3\}$	$= 1$

表 2 EOCA 层次聚类结果

聚类个数	聚类对象	聚类结果及聚类位置	最小改进一致性指标
$P = 3$	X_{dA}	$\{x_1\}, \{x_2\}, \{x_7, x_8\}$	0.528
	X_{dB}	$\{x_6\}, \{x_5\}, \{x_3, x_4\}$	
$P = 2$	X_{dA}	$\{x_1, x_2\}, \{x_7, x_8\}$	0.489
	X_{dB}	$\{x_6, x_5\}, \{x_3, x_4\}$	
$P = 3$	X_{dC}	$\{x_2, x_4\}, \{x_1\}, \{x_7\}$	0.613
	X_{dD}	$\{x_6, x_5\}, \{x_8\}, \{x_3\}$	
$P = 2$	X_{dC}	$\{x_2, x_4\}, \{x_1, x_7\}$	0.592
	X_{dD}	$\{x_6, x_5, x_8\}, \{x_3\}$	

由表 1 可见, 采用 OCA 算法, 对于 X_{dA} 和 X_{dB} , 当 $P = 3$ 和 $P = 2$ 时, 得到的最小一致性指标均为 0, 因此其上的聚类个数为 2 或 3; 同样, 对于训练子集 X_{dC} 和 X_{dD} , 由于得到的最小一致性指标为 0.75

0, 无法判断其上的聚类个数. 而且, 即便选取 X_{dC} 和 X_{dD} 上的聚类个数为 3, 且选取两组训练子集的同聚类个数作为最终聚类个数, 则得到最终聚类个数为 3, 显然聚类个数出现冗余; 即使最终聚类个数先不作判断, 而是通过后续的 FCM 和卡尔曼滤波算法计算得到的最小误差性能指标进一步确定, 仍需要针对聚类个数为 2 和 3 这两种情况, 先后进行两次前提参数和结论参数辨识, 从而导致整个算法的计算效率降低。

在表 2 中, 采用了 EOCA 算法, 基于定义的最小

改进一致性指标,可直接得到最终聚类个数为2,因此省去了后续算法的计算步骤,进一步提高了计算效率.其原因在于:对于训练子集 X_{da} 和 X_{db} ,在聚类个数 $P=3$ 和 $P=2$ 时,EOCA 算法采用两个训练子集中距离最近的聚类中心的平均偏差,来表示每次聚类结果的一致性,从而克服了OCA 算法受噪声干扰导致的误判断,提高了一致性判断的准确率.由表2可见,对于 X_{noi} ,采用EOCA 算法得到的最终聚类个数为2,最终聚类结果为 $\{x_1, x_2, x_3, x_4\}$ 和 $\{x_5, x_6, x_7, x_8\}$.EOCA 算法的聚类结果如图2所示.




图2 有噪声数据的EOCA 聚类结果

综上所述,采用EOCA 算法得到的最终聚类结果与实际聚类结果一致,因此有效克服了聚类个数冗余的问题.

2.2 基于模糊聚类和稳态卡尔曼滤波的参数辨识

设辨识对象为 $P(U, Y)$. 其中:输入为 $U = (u_1, u_2, \dots, u_r) \quad R^r$, 输出为 $Y = (y_1, y_2, \dots, y_q) \quad R^q$. 采用TS 模型的表达形式,则其典型的表达式为

$$R^i: \text{if } u_1 \text{ is } A_1^i \text{ and } \dots \text{ and } u_r \text{ is } A_r^i, \\ \text{then } y^i = a_0 + a_1 u_1 + \dots + a_r u_r. \quad (5)$$

其中: R^i 表示第 i 条模糊规则, $i = 1, 2, \dots, h$; A_j^i 表示第 i 条规则对应的模糊集合,其对应隶属度函数的参数 $A_j^i(x_j)$ 即为前提参数,由模糊聚类分析确定; a_{ij} 为结论参数, $j = 1, 2, \dots, r$.

给定训练数据集 $X = \{x_1, \dots, x_N\}$, 其中 $x_k = (u_1^k, \dots, u_r^k, y_1^k, \dots, y_q^k) = (x_k^1, \dots, x_k^{r+q})$, 聚类个数 c , 初始聚类中心 $V_0, k = 1, \dots, N$. 采用FCM 算法对 X 进行输入-输出模糊聚类,得到模糊划分矩阵 $M = [\mu_{ki}]$, 其中 $\mu_{ki} \in [0, 1]$, 表示第 k 个数据在第 i 类的隶属度, $i = 1, \dots, c$. 给定任意输入 $x_l \in X, l \in \{1, \dots, N\}$, 其确定的前提参数为 $A_j^i(x_l^j) = \mu_{li}, j = 1, \dots, r+q$. 本文采用模糊聚类分析直接确定前提参数,可以降低参数估计法确定隶属度函数时易导致的拟合误差和投影误差,从而提高了辨识精度,并减少了迭代辨识前提参数和结论参数的计算量.

前提参数确定后,为避免矩阵求逆并提高计算

效率,本文采用稳态卡尔曼滤波法递推得到结论参数 a_{ij} 的估计值 $\hat{\alpha} = [a_{01}, \dots, a_{0c}, \dots, a_{(r+q)1}, \dots, a_{(r+q)c}]$. $\hat{\alpha}$ 的计算过程参见文献[8],在此不再赘述.

2.3 算法步骤

基于EOCA 的模糊辨识算法总结如下:

Step1: 采用EOCA 算法确定两个候选聚类 $\{c_{tr}, V_{tr}\}$ 和 $\{c_{ts}, V_{ts}\}$.

Step2: 判断:如果 $c_{tr} = c_{ts}$, 则以唯一确定的聚类结果初始化并运行FCM 算法,以得到的模糊划分矩阵 M 直接确定前提参数 $A_j^i(x_j^i)$, 并采用稳态卡尔曼滤波法估计结论参数 $\hat{\alpha}$, 算法结束;反之,则利用FCM 和稳态卡尔曼滤波方法,分别对以上确定的两个候选聚类进行前提和结论参数辨识,建立对应的模糊模型,并转下一步.

Step3: 利用两个候选模糊模型得到模型误差性能指标(均方误差) MSE_1 和 MSE_2 .

Step4: 比较 MSE_1 和 MSE_2 , 取较小者对应的模型作为最终模型.

3 仿真实例

本文采用著名的Box-Jenkins 煤气炉数据^[9] 验证所提方法的有效性.该系统为SISO 动态系统,包含296 组输入输出数据.其中:输入变量 $u(k)$ 为煤气流量,输出变量 $y(k)$ 为 CO_2 浓度, k 表示采样间隔,取9 s.由于该过程具有动态变化的特性,影响系统输出的变量选取方法有多种,这里采用文献中常见的输入-输出组合和来验证所建模型的有效性.其中,用于检验模型拟合精度和泛化能力,用于检验模型对噪声数据的鲁棒性.

输入为 $u(k), u(k-1), u(k-2), y(k-1), y(k-2), y(k-3)$, 输出为 y . 取前148 组作为训练数据集,后148 组数据作为测试数据集.

首先,采用EOCA 算法对训练数据集聚类,由训练子集 X_A 和 X_B 得到 $c_{tr} = 3$ 和 $MSE_1 = 0.017$; 由训练子集 X_C 和 X_D 得到 $c_{ts} = 2$ 和 $MSE_2 = 0.018$. 由于 $MSE_1 < MSE_2$, 取最终聚类个数 $c = 3$.


给定规则数 $h = c = 3$, 采用FCM 和稳态卡尔曼滤波法分别辨识前提参数和结论参数之后,得到第 i 条规则 R^i 为

$$R^i: \text{if } u(k) \text{ is } A_1^i, \dots, y(k-3) \text{ is } A_6^i, \\ \text{then } y^i = a_0 + a_1 u(k) + \dots + a_6 y(k-3). \quad (6)$$


模型输出与实际输出的训练误差和测试误差比较分别如图3(a) 和3(b) 所示.由图3 可见,输出曲线与实际输出曲线拟合良好,表明模型具有较高的拟合精度.

训练子集 X_A 和 X_B 的一致性准则与聚类个数

关系曲线见图 4. 其中:最小改进一致性指标 $BL_{new}^{min} = 0.01, c = 3.$



(a) 训练集($h=3$,训练MSE=0.017)



(b) 测试集($h=3$,测试MSE=0.078)

图 3 模型输出与实际值比较




图 4 一致性准则与聚类个数关系曲线

本方法与其他模糊辨识方法的比较见表 3. 由表可见,本方法既降低了 Tsekouras 模型中需要计算多个聚类有效性指标的计算负担,又减少了 Kim 模型中聚类个数、前提参数和结论参数辨识反复迭代的计算量,因此计算效率更高,且易于实现. 另外,规则数为 3,并且具有较低的训练误差和测试误差,表明模型的结构较为精简.

表 3 各种模糊辨识方法结果比较

模 型	规则数	前件参数	训练 MSE	测试 MSE
Tsekouras 模型 ^[10]	2	38	0.0164	0.145
Kim ^[10]	2	38	0.034	0.244
EOCA	3	—	0.017	0.078

输入为 $u(t - 1), u(t - 2), y(t - 1), y(t - 2)$, 输出为 $y(t)$, 对输入和输出同时叠加白高斯噪声,得到信噪比为 5 dB 的数据作为训练数据.

首先采用 EOCA 算法对训练数据聚类,得到 c_r

$= 2$ 和最小改进一致性指标 0.015, 以及 $c_s = 2$ 及其最小改进一致性指标 0.138. 因为 $0.015 < 0.138$, 表明聚类个数为 c_r 时的有效性更高,所以取 $c = 2$ 和对应的聚类中心 V_{tr} 作为 FCM 算法的初始参数. 然后基于 FCM 和稳态卡尔曼滤波分别辨识前提参数和结论参数,并计算训练误差指标,得到 $MSE = 0.8610$. 与文献 [10] 中的规则数 $h = 14$, $MSE = 3.7803$ 相比,本算法规则数更少,而且辨识精度更高,表明本文模型对于有噪声数据具有较强的鲁棒性,且结构精简.

模型输出与实际输出的比较如图 5 所示. 其中:规则数 $h = 2$, $MSE = 0.8610$, 信噪比为 5 dB.




图 5 有噪声数据的模型输出与实际值比较

4 结 论

本文提出了一种基于改进客观聚类分析法的模糊辨识方法. 首先采用改进的客观聚类分析法确定两个候选聚类;然后分别与模糊 c 均值聚类和稳态卡尔曼滤波法相结合;最后基于误差性能指标,从中确定最终的模糊模型. 该方法克服了传统模糊聚类辨识方法易受噪声和人为因素影响,导致聚类结果鲁棒性较差和计算量较高的问题. 仿真结果表明,所建模型结构精简,并且对有噪声数据具有较强的鲁棒性.

参考文献(References)

- [1] Casillas J, Cordon O, Herrera F, et al. Interpretability issues in fuzzy modelling [M]. New York: Springer, 2003.
- [2] Hadjili M L, Wertz V. Takagi-Sugeno fuzzy modeling incorporating input variables selection[J]. IEEE Trans on Fuzzy Systems, 2002, 10(6): 728-742.
- [3] Kaymak U, Babuska R. Compatible cluster merging for fuzzy modeling [C]. Proc of IEEE Int Conf on Fuzzy Systems. Yokohama: IEEE Press, 1995: 897-904.
- [4] John Yen, Liang Wang. Simplifying fuzzy rule-based models using orthogonal transformation methods [J]. IEEE Trans on Systems, Man and Cybernetics, 1999, 29(1): 13-24.

(下转第 22 页)

- on Automatic Control, 1996, 41 (3) : 447-451.
- [3] Zhang T, Ge S S, Hang C C. Adaptive neural network control for strict-feedback nonlinear systems using backstepping design [J]. Automatica, 2002, 36 (10) : 1835-1846.
- [4] Du H B, Shao H H, Yao P J. Adaptive neural network control for a class of low-triangular-structured nonlinear systems [J]. IEEE Trans on Neural Networks, 2006, 17 (2) : 509-514.
- [5] Stoev J, Choi J Y, Farrall J. Adaptive control for output feedback nonlinear systems in the presence of modeling errors [J]. Automatica, 2002, 38 (8) : 1761-1767.
- [6] Chen W S, Li J M. Adaptive output-feedback regulation for nonlinear delayed systems using neural network [J]. Int J of Automation and Computing, 2008, 5 (1) : 103-108.
- [7] Chen W S, Li J M. Adaptive neural network tracking control for a class of unknown nonlinear time-delay systems [J]. J of Systems Engineering and Electronics, 2006, 17 (3) : 467-473.
- [8] Chen W S, Li J M. Adaptive neural tracking control for unknown output feedback nonlinear time-delay systems [J]. J of Control Theory and Application, 2006, 4 (4) : 313-320.
- [9] Chen W S, Li J M. Adaptive backstepping neural network control for unknown nonlinear time-delay systems [J]. Advances in Neural Networks, 2005, 3498 (3) : 30-35.
- [10] 陈为胜, 李俊民. 未知输出反馈非线性时滞系统自适应神经网络跟踪控制 [J]. 自动化学报, 2005, 31 (5) : 799-803.
(Chen W S, Li J M. Adaptive neural tracking control for unknown output-feedback nonlinear time-delay systems [J]. Acta Automatica Sinic, 2005, 31 (5) : 799-803.)
- [11] 陈为胜, 李俊民. 一种简化的自适应神经网络输出反馈镇定 [J]. 控制与决策, 2007, 22 (10) : 1086-1090.
(Chen W S, Li J M. Simplified adaptive neural network output feedback stabilization [J]. Control and Decision, 2007, 22 (10) : 1086-1090.)
- [12] Chen W S, Li J M. Decentralized output-feedback neural control for systems with unknown interconnections [J]. IEEE Trans on Systems, Man and Cybernetics: Part B, 2008, 38 (1) : 258-266.
- [13] 陈为胜, 李俊民. 非线性时滞大系统自适应神经网络分散控制 [J]. 控制与决策, 2006, 21 (8) : 873-878.
(Chen W S, Li J M. Adaptive neural network decentralized control for nonlinear time-delay large-scale systems [J]. Control and Decision, 2006, 21 (8) : 873-878.)
- [14] Wang C. An ISS-modular approach for adaptive neural control of pure-feedback systems [J]. Automatica, 2006, 42 (4) : 723-731.
- [15] Park J, Sandberg I W. Universal approximation using radial-basis-function networks [J]. Neural Computation, 1991, 3 (2) : 246-257.

(上接第 17 页)

- [5] 李柠, 李少远. 基于满意聚类的多模型建模方法 [J]. 控制理论与应用, 2003, 20 (5) : 783-787.
(Li N, Li S Y. Multi-model modeling method based on satisfactory clustering [J]. Control Theory & Applications, 2003, 20 (5) : 783-787.)
- [6] 贺昌政. 自组织数据挖掘与经济预测 [M]. 北京: 科学出版社, 2005.
(He C Z. Self-organizing data mining theory and its application to prediction of economic systems [M]. Beijing: Science Press, 2005.)
- [7] Mollineda R, Vidal E. A relative approach to hierarchical clustering [C]. Pattern Recognition and Applications, Frontiers in Artificial Intelligence and Applications. Amsterdam: IOS Press, 2000.
- [8] Takagi T, Sugeno M. Fuzzy identification of systems and its application to modeling and control [J]. IEEE Trans on Systems, Man and Cybernetics, 1985, 15 (1) : 116-132.
- [9] Box G E P, Jenkins G M, Reinsel G. Time series analysis, forecasting and control [M]. San Francisco: Holden Day, 1970.
- [10] Tsekourasa G, Sarimveisb H, George E K. A hierarchical fuzzy-clustering approach to fuzzy modeling [J]. Fuzzy Sets and Systems, 2005, 15 (2) : 245-266.
- [11] Dong-won Kim, Gwi-tae Park. Using interval singleton type 2 fuzzy logic system in corrupted time series modelling [M]. Berlin: Springer, 2005.