

文章编号: 1001-0920(2007)10-1193-04

基于蚁群聚类算法的非线性系统辨识

赵宝江^{1,2}, 李士勇¹

(1. 哈尔滨工业大学 控制科学与工程系, 哈尔滨 150001; 2. 牡丹江师范学院 数学系, 黑龙江 牡丹江 157012)

摘要: 基于 T-S 模型提出一种非线性系统的模型辨识方法. 利用蚁群聚类算法进行结构辨识, 确定系统的模糊空间和模糊规则数. 在聚类的基础上, 利用遗传算法辨识模糊模型的后件加权参数, 得到一个精确的模糊模型, 从而实现了参数辨识. 仿真结果验证了所提出方法的有效性, 表明该方法能够实现非线性系统的辨识, 而且辨识精度较高.

关键词: 蚁群聚类算法; T-S 模糊模型; 系统辨识

中图分类号: TP18 **文献标识码:** A

Nonlinear systems identification based on ant colony clustering algorithm

ZHAO Bao-jiang^{1,2}, LI Shi-yong¹

(1. Department of Control Science and Engineering, Harbin Institute of Technology, Harbin 150001, China; 2. Department of Mathematics, Mudanjiang Teachers College, Mudanjiang 157012, China. Correspondent: ZHAO Bao-jiang, E-mail: baojiangzhao@126.com)

Abstract: A model identification approach of nonlinear systems is presented based on T-S model. To automatically acquire the fuzzy space structure of system and the number of fuzzy rules, the ant colony clustering algorithm is used in structure identification. Based on the cluster result, the parameters of the conclusion of fuzzy model are identified by means of the genetic algorithm to obtain a precise fuzzy model and realize parameters identification. The proposed method realizes the identification of nonlinear system and improves greatly the precision of identification. The simulation results show the effectiveness of the proposed method.

Key words: Ant colony clustering algorithm; T-S fuzzy model; System identification

1 引言

作为系统和控制科学的核心问题之一, 系统辨识一直受到广泛的关注. 由于非线性系统大量存在, 研究非线性系统的辨识问题对于应用而言是十分必要的. 20 世纪 90 年代以来, 非线性系统的辨识已成为系统辨识领域的研究主题之一, 但总的来说, 无论在理论上还是实际应用中, 非线性系统辨识还远未达到完善的程度.

在非线性系统的辨识方法中, 递推最小二乘辨识法^[1]、基于联合概率密度的估计法^[2]和 BP 神经网络法^[3]获得的模型, 相对而言辨识精度不高, 收敛速度不快, 难以甚至无法得到最优解, 直接影响了对系统的预测控制精度. 近年来, 基于遗传算法的系统辨识方法引起了许多研究者的兴趣. 研究表明, 遗传算法可为系统辨识提供一种简单而有效的方法^[4].

蚁群优化(ACO)算法是 Dorigo 等学者于 20 世纪 90 年代初提出的^[5], 是模拟自然界中蚁群的觅食行为而形成的一种模拟进化算法. 蚁群优化算法在求解组合优化问题方面表现出突出的优越性, 在数据的特征聚类方面^[6]也取得了良好的仿真实验结果.

本文基于蚁群算法, 提出一种同时包括结构辨识和参数辨识的非线性系统的 T-S 模糊模型辨识方法. 在结构辨识中, 采用蚁群聚类算法, 从已知的输入输出数据中自动划分输入输出空间, 确定模糊规则的数目以及前件参数, 生成一个能描述给定输入输出数据结构的初始模糊模型. 在聚类的基础上, 使用遗传算法实现模糊模型后件加权参数辨识, 使其具有更高的精度. 该模型具有通用逼近的特性, 这是建模和控制应用中的一个重要特性. 最后, 将所提

收稿日期: 2006-07-23; 修回日期: 2006-12-11.

基金项目: 国家自然科学基金项目(50138010).

作者简介: 赵宝江(1971—), 男, 黑龙江牡丹江人, 副教授, 博士, 从事蚁群优化、智能控制的研究; 李士勇(1943—), 男, 哈尔滨人, 教授, 博士生导师, 从事智能优化、智能控制等研究.

出的辨识方法应用于几个典型的非线性系统,仿真结果验证了该方法的有效性.

2 蚁群聚类算法

蚁群算法是一种全局优化的启发式算法,能根据聚类中心的信息量把周围数据归并到一起,从而得到聚类分类.为应用蚁群算法解决数据聚类问题,作者将数据聚类问题解释为二次分配问题.但又不同于二次分配问题,在聚类问题中,不同对象可有相同的类划分,因此分配次序是互不相关的.

假定数据样本为一个包含 N 个数据的集合 $\{x_1, x_2, \dots, x_N\}$, 每个样本点表示为 $x_k = \{x_{k1}, x_{k2}, \dots, x_{kn}\}$. 其中前 $n-1$ 个标量是第 k 个样本点的输入矢量,第 n 个标量是其相应的输出,设聚类数为 K . 定义目标函数如下:

$$\min J = \sum_{i=1}^K \left(\frac{1}{X_i} \sum_{x_j \in X_i} \|x_j - x_v\|^2 \right), \quad (1)$$

其中 X_i 表示类 X_i 中的样本数. 它有如下优点: 1) 该目标函数可形成任意形状的聚类; 2) 能促使更大规模和更加紧密的聚类形成,有利于纠正聚类错误.

类 X_i 的中心 m_i 表示类中所有样本的均值,计算公式为

$$m_{iv} = \frac{\sum_{x_j \in X_i} x_{jv}}{|X_i|}, \quad i = 1, 2, \dots, K, v = 1, 2, \dots, n. \quad (2)$$

在蚁群聚类算法中,使用 R 个人工蚂蚁,每个蚂蚁构建的解为一个长度为 N 的字符串 $S = \{c_1, c_2, \dots, c_N\}$. 其中 $\{c_i | i = 1, 2, \dots, N\}$ 是对象 i 的类标识, $c_i = 1, 2, \dots, K$. $c_i = c_j$ 表示对象 x_i 和 x_j 属于同一类, $c_i \neq c_j$ 表示对象 x_i 和 x_j 不属于同一类.

在算法开始阶段,初始化 $N \times K$ 的信息素矩阵,将其赋予一个初值 τ_{ij} , 矩阵元素 τ_{ij} 表示对象 i 相对于类 j 的信息素浓度.

2.1 解的构造

在蚁群聚类算法中,蚂蚁使用伪随机比例选择规则(3)构造解 S , 为 S 中的每个元素分配一个类标识. 即对位于元素 i 的蚂蚁,以概率 q_0 选择使 $\tau_{ij} [\eta_{ij}]$ 达到最大的类 S . 蚂蚁以概率 $1 - q_0$ 的概率按式(4)为元素 i 选择一个类. 算法中蚂蚁的伪随机比例公式为

$$S = \begin{cases} \arg \max_j \{ \tau_{ij} [\eta_{ij}] \}, & q < q_0; \\ J, & \text{otherwise.} \end{cases} \quad (3)$$

其中, q 为均匀分布于 $[0, 1]$ 的随机数; $0 < q_0 < 1$ 为常数; $\eta_{ij} = 1 / d_{ij}$ 表示启发式信息值,式中 d_{ij} 表示对象 i 与类 j 的中心距离,全部启发式信息为一个 $N \times$

K 矩阵; τ_{ij} 为期望启发式因子,表示启发式信息的相对重要性; J 是根据式(4)决定的随机变量.

$$p_{ij} = \frac{\tau_{ij} [\eta_{ij}]}{\sum_{k=1}^K \tau_{ik} [\eta_{ik}]}, \quad j = 1, 2, \dots, K. \quad (4)$$

其中 p_{ij} 表示对象 i 属于类 j 的分布概率.

2.2 局部搜索

对蚂蚁产生的部分较优解进行局部搜索,进一步改善解的质量.在局部搜索策略中,使用阈值概率 p_{bs} 对解进行随机变异,产生新的解.即对于解 S 的每个元素 i ,如果产生的随机数小于 p_{bs} ,则对相应位置的元素赋予一个不同的类;如果新解更优,则替代原来解,否则保留原来解.

2.3 全局信息素更新规则

信息素更新能够动态地反映蚂蚁个体在运动中产生的信息.因此,当蚁群完成一次搜索之后,可利用产生全局最优解的蚂蚁个体对信息素矩阵进行更新.信息素更新公式如下:

$$\tau_{ij}(t+1) = (1 - \rho) \tau_{ij}(t) + \frac{\tau_{ij}^{bs}}{F_{bs}}; \quad (5)$$

$$\tau_{ij}^{bs} = \begin{cases} 1 / F_{bs}, & \text{最优解中第 } i \text{ 个元素属于类 } j; \\ 0, & \text{否则.} \end{cases} \quad (6)$$

其中: F_{bs} 表示最优解的目标函数值; $0 < \rho < 1$ 为全局信息素挥发系数,越大表示信息素挥发得越快.

在算法的迭代过程中,反复执行以上步骤,直至达到算法的最大迭代数.

通过上面的聚类算法把已知的样本集分为 K 个类别,并得到相应的聚类中心 $m_j = (m_{j1}, m_{j2}, \dots, m_{jn}), j = 1, 2, \dots, K$.

3 模糊模型辨识方法

设系统的模糊模型为 T-S 模糊模型^[7]. T-S 模糊模型的辨识由两部分构成:前提(前件)结构辨识和参数辨识.参数辨识又分前提参数辨识和结论(后件)参数辨识.由蚁群聚类算法构造一个初始 T-S 模糊模型如下:

$$R^j: \text{If } x_1 \text{ is } \mu_{j1} \text{ and } \dots \text{ and } x_{n-1} \text{ is } \mu_{j(n-1)},$$

$$\text{Then } y_j = b_{j0} + b_{j1} x_1 + \dots + b_{j(n-1)} x_{n-1},$$

$$j = 1, 2, \dots, K. \quad (7)$$

其中: K 是模糊规则的数目;规则中前提部分的隶属函数用高斯函数表示为

$$\mu_{ji} = \exp \left\{ - \frac{(x_i - a_{ji})^2}{\sigma_{ji}^2} \right\}. \quad (8)$$

其中: a_{ji} 是高斯函数的中心

$$a_j = (a_{j1}, a_{j2}, \dots, a_{j(n-1)}) = (m_{j1}, m_{j2}, \dots, m_{j(n-1)}); \quad (9)$$

σ_{ji} 是其宽度 $\sigma_j = (\sigma_{j1}, \sigma_{j2}, \dots, \sigma_{jn})$, σ_{ji} 值通过计算第 j 类的输入数据点与其聚类中心的偏差而得到.根据中心平均解模糊公式,系统的输出为

$$y = \prod_{j=1}^K w_j y_j / \prod_{j=1}^K w_j = \prod_{j=1}^K v_j y_j = \prod_{j=1}^K (b_{j0} + b_{j1} x_1 + \dots + b_{j(n-1)} x_{n-1}), \quad (10)$$

其中: $w_j = \prod_{i=1}^{n-1} u_{ji}, J = 1, 2, \dots, K$.

下面使用遗传算法确定每条规则的后件参数 $(b_{j0}, b_{j1}, \dots, b_{j(n-1)}), j = 1, 2, \dots, K$.

遗传算法步骤如下:

1) 编码:对待优化的后件加权参数 $B_j = (b_{j0}, b_{j1}, \dots, b_{j(n-1)}), j = 1, 2, \dots, K$,采用实数编码的染色体,表示为 $S = (B_1, B_2, \dots, B_K)$.

2) 随机生成含有 M 个个体的初始群体.

3) 选择操作:采用轮盘赌法选择 n_c 个染色体进行遗传操作,个体被选中的概率为 $P_i / \sum_k P_k, P_i = 1/J_i$.其中 J_i 为个体的适应度函数,其值为均方误差

$$SME = \frac{1}{N} \sum_{i=1}^N (y_i - y^i)^2. \quad (11)$$

其中: y_i 是系统的实际值, y^i 是模糊模型的输出值.

4) 交叉和变异:对个体进行随机配对,对其中的每对个体组进行简单的算术交叉.变异操作采用具有自适应能力的高斯变异算子,公式为

$$s = (v_1, \dots, v_k, \dots, v_m), v_k = v_k + f_k.$$

其中 f_k 为服从零均值和自适应方差 σ_k 的正态分布随机数,而

$$\sigma_k = (T - t/T) ((v_k^{\max} - v_k^{\min})/3).$$

式中: $t = 0, 1, \dots, T$ 表示遗传操作的代数; v_k^{\max} 和 v_k^{\min} 表示染色体中元素 k 的上限和下限.

5) 重复 3) 和 4) 步,直到算法达到迭代次数 T .

群体中适应度函数值最小的个体就是最终的辨识结果.

4 性能分析

4.1 时间复杂度

时间复杂度是衡量算法可行性的重要指标.本算法的时间复杂度可分为以下两部分:

1) 蚁群聚类算法:初始化的时间为 $O(NK)$,

2.1 节构造的时间为 $O(RNK)$, 2.2 节局部搜索的时间为 $O(RN)$, 2.3 节信息素更新的时间为 $O(R + N)$. 设算法的迭代次数为 N_c ,则聚类算法的整个计算时间复杂度为 $O(N_c(RNK))$.

2) 优化后件参数的遗传算法:初始群体生成的时间为 $O(M(nK))$,选择操作的时间为 $O(n_c)$,交叉和变异的时间为 $O(n_c + n_c(nK))$.已知进化次数为 T ,则遗传算法的整个时间复杂度为 $O(Tn_c(nK))$.

因此,整个算法的时间复杂度为

$$O(\max(N_cRNK, Tn_cnK)).$$

4.2 收敛性

T-S 模糊系统能进行实际建模的充分必要条件是:系统能以任意精度逼近实际模型,即系统具有全局逼近性.根据 Stone-Weirstrass 定理^[8],可对 T-S 模糊系统的全局逼近性理论给出分析证明.限于篇幅,仅给出如下定理,证明略.

定理 1 T-S 模糊逻辑系统具有全局逼近性.

5 仿真应用

实例 1 辨识对象由如下非线性系统产生:

$$y = \sin x_1 \sin x_2 / x_1 x_2,$$

其中两个输入变量 x_1 和 x_2 定义在 $[-10, 10]$ 上.每个输入变量都按均匀概率密度函数随机产生,共产生 1 681 个输入输出数据对.

首先进行结构辨识,使用蚁群聚类算法产生 5 个聚类.5 个聚类的中心如表 1 中前提部分所示,模糊规则数目为 5.

然后进行参数辨识,利用遗传算法优化后件加权参数.根据输入变量和规则的数目,确定需要优化的参数个数为 $5 \times 3 = 15$.最终结果如表 1 中结论部分所示.

最后将测试数据输入到模糊模型,以检测其结果.图 1 和图 2 分别显示了辨识系统与实际系统的输出.仿真结果表明,利用本文提出的辨识方法进行辨识,结果是令人满意的.

实例 2 Box-Jenkins 煤气炉数据^[9],该数据集是由 296 对输入输出测量值组成的.输入量 u_k 是煤气气体的流速,输出量 y_k 是 CO₂ 的浓度,采样间

表 1 辨识得到的模糊模型的最终参数

		<i>j</i>				
		1	2	3	4	5
前 提	j_1	3.491 6	2.182 8	3.095 7	3.497 2	3.739 2
	a_{j1}	3.861 2	- 5.801 2	5.444 0	- 5.435 8	7.702 9
	j_1	2.898 7	3.293 5	3.641 5	3.076 1	4.199 1
	a_{j2}	- 3.069 6	3.858 5	6.292 1	- 6.561 2	- 8.545 9
结 论	b_{j0}	- 0.105 8	- 0.008 2	0.003 4	- 0.011 3	- 0.041 7
	b_{j1}	0.110 4	0.003 9	0.022 8	- 0.010 0	0.105 7
	b_{j2}	0.505 4	- 0.081 5	- 0.197 6	- 0.154 1	1.360 1




图1 辨识系统的输入输出




图2 实际系统的输入输出

隔为 9 s. 采用 $y(t-1)$, $u(t-3)$, $y(t-2)$ 作为输入变量.

表2 煤气炉模糊模型目标函数

聚类数	2	3	4	5
MSE	0.064 0	0.059 7	0.056 0	0.054 8

计算不同聚类数目的模糊模型的均方差 MSE, 结果如表 2 所示. 从表中可以看出, 当聚类数为 5 时, 模糊模型目标函数达到最小值 0.054 8. 它比聚类数为 2 的模型仅仅提高了 0.92 %.

为了最大限度地简化模型结构(只接受最小的聚类数目), 选择聚类数为 2 的模糊模型作为最终辨识模型, 其目标函数值为 0.064 0.

模糊模型的隶属函数如图 3 所示. 得到的模糊模型如下:

R^1 : If $y(t-1)$ is in1mf1 and $u(t-3)$ is in2mf1 and $y(t-2)$ is in3mf1,

Then $y_1 =$

$1.458 2y(t-1) - 0.379 8u(t-3) - 0.615 5y(t-2) + 8.513 0;$

R^2 : If $y(t-1)$ is in1mf2 and $u(t-3)$ is in2mf2 and $y(t-2)$ is in3mf2,

Then $y_2 =$

$0.889 4y(t-1) - 0.862 3u(t-3) - 0.223 7y(t-2) + 17.368 0.$

图 4 给出了煤气炉实际输出与模糊模型输出的比较. 显然, 该辨识系统具有良好的逼近能力.




(a) $y(t-1)$ (b) $u(t-3)$ (c) $y(t-2)$

图3 煤气炉模糊模型隶属函数




图4 模糊模型的输出结果和原序列图像

6 结 语

本文针对非线性系统的辨识问题, 提出一种基于 T-S 模糊模型的辨识方法. 通过蚁群聚类算法自动地从已知的输入输出数据中确定模糊模型的结构和前件参数, 并用遗传算法估计模糊模型的后件参数. 该模型具有通用逼近的能力. 仿真结果表明, 该方法辨识精度高, 得到的模糊模型简单, 模糊规则少, 较好地解决了现有文献中算法复杂、输入空间难以划分或带来的高维问题, 因而具有良好的实用性和有效性.

参考文献(References)

- [1] Wang H, Tanakak K, Ikeda T. Fuzzy modeling and control of chaotic system[C]. Proc of IEEE Int Symp on Circuits and Systems. Atlanta, 1996, 3: 209-212.
- [2] Chen L, Chen G R. Modeling prediction and control of uncertain chaotic systems based on times series[J]. IEEE Trans on Circuits and Systems, 2000, 47(10): 1527-1531.
- [3] Cencay R. Nonlinear prediction of noise time series with feed forward and networks[J]. Physics Letters A, 1994, 187(6): 397-403.

(下转第 1200 页)

变量不能很好地表征故障特征,正确率分别只有 68.2%和 59.7%。相比之下,基于故障特征选择的故障诊断方法由于直接选中故障特征变量进行故障分类,排除了不相关变量的干扰,能在复杂工况中有效地保证故障诊断性能,在 3 个故障中均达到了 100%的故障诊断正确率,具有良好的鲁棒性和可靠性

4 分析与结论

作为基于特征选择的故障诊断的关键技术,故障特征变量的选择对故障诊断的有效实施起着至关重要的作用。由函数优化测试以及故障特征选择的仿真结果可以验证,CDDPSO 算法能有效跳出局部最优,搜索到全局最优解,可靠地完成特征选择的任务,保证了故障诊断的可靠性和实时性。基于 SVM 的故障诊断方法适用于小数据集分类问题,而实际工业过程中缺乏故障数据,因此基于特征选择的 SVM 故障诊断方法具有一定的实用价值。

对于大型系统的故障诊断,由于系统存在大量的监控变量以及系统噪声的干扰,使得利用故障分类器对全部数据进行故障诊断的方法难以达到满意的性能。基于特征提取的方法虽能有效降低数据维度,但由于特征提取方法得到的特征并不仅仅是故障特征,不能确保在复杂工况下可靠地实施故障诊断。基于故障特征选择的故障诊断方法直接选取导致故障的源变量进行故障诊断,既大大降低了数据维度,又准确地保留了系统故障的本质特征,因此在复杂大系统中能有效可靠地实现对系统的在线故障

诊断。

参考文献(References)

- [1] 李尔国,俞金寿. 一种基于输入训练神经网络的非线性 PCA 故障诊断方法[J]. 控制与决策, 2003, 18(2): 229-232.
(Li Er-guo, Yu Jin-shou. Input-training neural network-based nonlinear principal component analysis approach for fault diagnosis[J]. Control and Decision, 2003, 18(2): 229-232.)
- [2] Leo Chiang, Pell H, Randy J. Genetic algorithms combined with discriminant analysis for key variable identification[J]. J of Process Control, 2004, 14(2): 143-155.
- [3] Oh I S, Lee J S, Moon B R. Hybrid genetic algorithms for feature selection [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2004, 26(11): 1424-1437.
- [4] Kennedy J, Eberhart R C. A discrete binary version of the particle swarm algorithm[C]. Proc of the 1997 Conf on Systems, Man and Cybernetics. Piscataway: IEEE Press, 1997: 4104-4108.
- [5] Kohda T, Tsuneda A. Pseudonoise sequences by chaotic nonlinear maps and their correlation properties [J]. IEICE Trans on Communication, 1993, 76(8): 855-862.
- [6] Chiang L H, Russell E L, Braatz R D. Fault detection and diagnosis in industrial systems [M]. London: Springer-Verlag, 2001.

(上接第 1196 页)

- [4] 杨智民,王旭,庄显义. 遗传算法在自动控制领域中的应用综述[J]. 信息与控制, 2000, 29(4): 329-339.
(Yang Zhi-min, Wang Xu, Zhuang Xian-yi. Application of genetic algorithm in control [J]. Information and Control, 2000, 29(4): 329-339.)
- [5] Dorigo M, Maniezzo V, Colorni A. Ant system: Optimization by a colony of cooperating agents [J]. IEEE Trans on Systems, Man and Cybernetics, 1996, 26(1): 29-41.
- [6] Shelokar P S, Jayaraman V K, Kulkarni B D. An ant colony approach for clustering [J]. Analytica Chimica Acta, 2004, 509(2): 187-195.
- [7] Takagi T, Sugeno M. Fuzzy identification of system and its application of modeling and control [J]. IEEE Trans on System, Man and Cybernetics, 1985, 15(1): 16-32.
- [8] Rudin W. Principles of mathematical analysis[M]. 3rd ed. New York: McGraw-Hill, 1976.
- [9] Box E P. Time series analysis, forecasting and control [M]. San Francisco: Holden Day, 1970.