

基于支持向量机回归的 T-S 模糊模型自组织算法及应用

梁炎明¹ 苏芳¹ 李琦¹ 刘丁¹

摘要 结合模糊聚类算法和支持向量机回归算法提出了一种新的 T-S 模糊模型自组织算法。该算法首先利用一种改进模糊聚类算法提取模糊规则和辨识前件参数,然后将 T-S 模糊模型后件变换为标准线性支持向量机回归模型,并利用支持向量机回归算法辨识后件参数。仿真结果表明,相比现有的自组织算法,本文提出的 T-S 模糊模型自组织算法在规则数较少的情况下,仍然具有较高的辨识精度和较好的泛化能力。最后,利用提出的 T-S 模糊模型自组织算法较好地建立了直拉硅单晶炉加热器和空气预热器的温度模型。

关键词 T-S 模糊模型, 支持向量机回归, 聚类, 单晶炉, 空气预热器

引用格式 梁炎明, 苏芳, 李琦, 刘丁. 基于支持向量机回归的 T-S 模糊模型自组织算法及应用. 自动化学报, 2013, 39(12): 2143–2149

DOI 10.3724/SP.J.1004.2013.02143

A Self-organizing Algorithm for T-S Fuzzy Model Based on Support Vector Machine Regression and Its Application

LIANG Yan-Ming¹ SU Fang¹ LI Qi¹
LIU Ding¹

Abstract A new self-organizing algorithm for T-S fuzzy model is proposed by combining the fuzzy clustering algorithm and the support vector machine (SVM) regression algorithm. This algorithm firstly uses an improved fuzzy clustering algorithm to extract fuzzy rules and identify antecedent parameters. Then the T-S fuzzy model consequent is transformed into a standard linear support vector machine regression model, thus its parameters are identified using the support vector machine regression algorithm. Simulation results show that the self-organizing algorithm for T-S fuzzy model in this paper still has higher approximation accuracy and better generalization ability in the case of a small number of rules compared with the existing self-organizing algorithm. Finally, a heater temperature model of Czochralski single crystal furnace and an air preheater temperature model are better established using the proposed self-organizing algorithm for T-S fuzzy model.

Key words T-S fuzzy model, support vector machine regression, clustering, single crystal furnace, air preheater

Citation Liang Yan-Ming, Su Fang, Li Qi, Liu Ding. A self-organizing algorithm for T-S fuzzy model based on support vector machine regression and its application. *Acta Automatica Sinica*, 2013, 39(12): 2143–2149

收稿日期 2013-03-21 录用日期 2013-09-22
Manuscript received March 21, 2013; accepted September 22, 2013
国家自然科学基金 (61203114), 陕西省自然科学基金 (2013JM8029) 资助
Supported by National Natural Science Foundation of China (61203114), and Natural Science Foundation of Shaanxi Province (2013JM8029)
本文责任编辑 桂卫华
Recommended by Associate Editor GUI Wei-Hua
1. 西安理工大学自动化与信息工程学院 西安 710048
1. School of Automation and Information Engineering, Xi'an University of Technology, Xi'an 710048

T-S 模糊模型^[1] 具有很强的非线性逼近能力, 在系统辨识与控制领域有着广泛的应用^[2–4]。为使 T-S 模糊模型更好适应复杂系统的强非线性和不确定性, 对其规则提取、辨识精度和泛化能力等方面提出更高的要求, 因此, T-S 模糊模型辨识多年来一直受到国内外学者的广泛关注。

目前 T-S 模糊模型辨识研究较多的是自组织算法, 该类算法能够通过样本数据自动提取模糊规则和辨识参数, 因此, 相比传统 T-S 模糊模型辨识算法, 自组织算法更能适应复杂系统辨识。但目前这些 T-S 模糊模型自组织算法还存在一些问题: 如文献 [5–9] 提出的基于神经网络的 T-S 模糊模型自组织算法, 当神经网络出现过学习时, 会导致 T-S 模糊模型的泛化能力变差; 文献 [10–11] 提出的基于支持向量机的 T-S 模糊模型自组织算法, 该类算法获得的规则数与支持向量数一样多, 容易导致规则灾难问题; 文献 [12] 提出的 T-S 模糊模型自组织算法, 由于规定了同一条规则的高斯函数宽度相等, 使得由该算法获得的规则数明显多于变高斯函数宽度的辨识算法; 文献 [13–14] 提出利用模糊聚类提取规则的 T-S 模糊模型自组织算法, 该类算法需要预先确定聚类个数, 但由于确定聚类个数时, 缺乏有效的评优机制, 使得预先确定的聚类个数不一定合适, 影响辨识精度; 文献 [15] 提出利用最小二乘法估计后件参数的 T-S 模糊模型自组织算法, 然而, 当在小样本情况下, 最小二乘法的泛化能力受到限制^[16]; 文献 [17] 提出利用合作随机学习粒子群算法联合辨识前后件参数的 T-S 模糊模型自组织算法, 与神经网络学习算法类似, 该算法亦会出现过学习的情况, 因此, 泛化能力得不到保证。

针对这些自组织辨识算法的不足, 本文结合模糊聚类算法和支持向量机回归算法提出了一种新的 T-S 模糊模型自组织算法。该算法首先利用一种改进模糊聚类算法根据样本数据自动提取模糊规则和辨识前件参数, 然后将 T-S 模糊模型后件变换为标准线性支持向量机回归模型, 并利用支持向量机回归算法辨识后件参数。仿真结果表明, 相比现有的自组织辨识算法, 本文提出的 T-S 模糊模型自组织算法在规则数较少的情况下, 仍然具有较高的辨识精度和较好的泛化能力。利用本文提出的 T-S 模糊模型自组织算法较好地获得直拉硅单晶炉加热器的功率-温度模型和空气预热器的负荷-温度模型。

1 T-S 模糊模型结构

不失一般性, 考虑一个 MISO 的 T-S 模糊模型, 该模型共有 $r+1$ 条规则, 其中前 r 条规则中的第 i 条规则 $R^{(i)}$ 表示如下:

$R^{(i)}$: if x_1 is A_{i1} , and x_2 is A_{i2} , $\dots$, and x_n is A_{in} then

$$y^{(i)} = \sum_{j=1}^n p_{ij}x_j + p_{i0} \quad (1)$$

式中, x_j 为输入变量, A_{ij} 为模糊集, $y^{(i)}$ 为输出变量, $i \leq r$; p_{ij} 、 p_{i0} 为结论部分的实参数。模糊集的模糊隶属度函数选取高斯函数, 如式 (2) 所示:

$$M_{ij}(x_j) = \exp\left(\frac{-\|x_i - m_{ij}\|^2}{2\sigma_{ij}^2}\right) \quad (2)$$

式中, m_{ij} 、 σ_{ij} 分别为高斯隶属度函数的中心和宽度。第 $i+1$ 条规则形式如下:

$R^{(i+1)}$: if x_1 is $A_{(r+1)1}$, and x_2 is $A_{(r+1)2}, \dots$, and x_n is $A_{(r+1)n}$ then

$$y^{(r+1)} = b \quad (3)$$

式中, $A_{(r+1)j}$ 的模糊隶属度取为 1, 即: $M_{(r+1)1}(x_1) = \dots = M_{(r+1)n}(x_n) = 1$.

前 r 条规则中每条规则的激励强度采用乘积推理计算, 计算公式如下:

$$\mu_i(\mathbf{x}) = \prod_{j=1}^n M_{ij}(x_j) \quad (4)$$

式中, $\mathbf{x} = [x_1, x_2, \dots, x_n]$ 为输入向量.

第 $r+1$ 条规则的激励强度 $\mu_{r+1}(\mathbf{x}) = 1$, 然后根据文献 [18] 提出的模糊加权和方法求出 T-S 模糊模型的输出, 如式 (5) 所示:

$$y(\mathbf{x}) = \sum_{i=1}^r \left[\mu_i(\mathbf{x}) \left(\sum_{j=1}^n p_{ij}x_j + p_{i0} \right) \right] + b \quad (5)$$

2 T-S 模糊模型自组织算法

本文的 T-S 模糊模型自组织算法包括两部分内容, 分别为前件辨识和后件辨识, 其中前件辨识包括规则提取和参数辨识.

2.1 规则提取及前件参数辨识

为了合理提取模糊规则, 本文在文献 [12] 聚类算法基础上, 提出一种新的聚类算法对模糊输入空间进行划分, 该算法通过一种表示类内离散程度的准则函数 $S^{[19]}$ 优化该聚类算法的高斯函数宽度初值和激励强度阈值, 有效克服了该算法这两个参数依靠人工经验设定的主观性, 使聚类效果更佳, 具体算法步骤如下:

步骤 1. 将样本数据归一化, 在 $[0, 1]$ 区间分别随机选取高斯函数宽度初值 δ_{init} 和激励强度阈值 μ_{th} , 并令迭代次数 $t = 1$.

步骤 2. 当接收到第一个样本数据点 $\mathbf{x}(0)$, 产生第一条规则, 该规则模糊集参数 m_{1j} 、 δ_{1j} 取值如下: $m_{1j} = x_j(0)$, $\delta_{1j} = \delta_{init}$, $j = 1, 2, \dots, n$.

步骤 3. 对新接收数据 $\mathbf{x}(k)$ 判断是否产生新规则. 根据式 (4) 计算现有各个规则对新数据的激励强度 $\mu_i(\mathbf{x}(k))$, $i = 1, 2, \dots, r(k)$, $r(k)$ 为现有规则数, 并找出最大激励强度的规则 I 和激励强度值 μ_I . 如果 $\mu_I < \mu_{th}$, 表明模型对新数据缺乏支持, 需要产生一条新的规则, 进入步骤 4 确定新规则参数. 如果 $\mu_I \geq \mu_{th}$, 表明模型支持新数据, 不需要产生新规则, 进入步骤 5 更新规则 I 的聚类中心.

步骤 4. 新规则参数按式 (6) 和式 (7) 确定:

$$m_{(r(k)+1)j} = x_j(k) \quad (6)$$

$$\delta_{(r(k)+1)j} = \beta |x_j(k) - m_{r(k)j}| \quad (7)$$

同时, 模型的规则数 $r(k) = r(k) + 1$. 其中, β 为两类模糊空间的重叠系数, 一般取 0.5.

步骤 5. 更新对新数据支持的第 I 条规则聚类中心, 按平均值方式进行计算:

$$m_{(r_I)j} = \frac{m_{(r_I)j} \times a_I(k) + x_j(k)}{a_I(k) + 1} \quad (8)$$

$$a_I(k) = a_I(k) + 1 \quad (9)$$

式中, $a_I(k)$ 为第 I 条规则在 k 时刻所包含的数据个数.

步骤 6. 重复步骤 2~步骤 5, 直到没有新数据到达为止, 得到在一组 $(\delta_{init}, \mu_{th})$ 下的聚类结果.

步骤 7. 根据聚类结果计算准则函数 $S(t)$ 的值, 准则函数 $S(t)$ 如式 (10) 所示:

$$S(t) = \sum_{i=1}^r \frac{\sum_{k=1}^N \mu_i^q(\mathbf{x}(k)) \|\mathbf{m}_i - \mathbf{x}(k)\|^2}{N \left(\min_{0 \leq j \leq r, j \neq i} \|\mathbf{m}_i - \mathbf{m}_j\|^2 \right)} \quad (10)$$

式中, $\mu_i(\mathbf{x}(k))$ 为第 k 个样本数据 $\mathbf{x}(k)$ 对应于第 i 条规则的激励强度, $\mathbf{m}_i$ 为第 i 条规则的类中心且 $\mathbf{m}_i = (m_{i1}, m_{i2}, \dots, m_{in})$, N 为数据样本总个数, q 为模糊加权指数且 $1 \leq q < \infty$.

步骤 8. 改变高斯函数宽度初值 δ_{init} 和激励强度阈值 μ_{th} , 迭代次数 $t = t + 1$, 重复步骤 2~步骤 7, 直至 δ_{init} 和 μ_{th} 遍历完区间 $[0, 1]$.

步骤 9. 找出 S 关于规则数 (类别数) 变化率最大、值较小对应的 $(\delta_{init}, \mu_{th})$, 认为这时的参数是最合适的. 然后利用此时的参数对 T-S 模糊模型前件结构和参数进行辨识. 自动寻找最佳 $(\delta_{init}, \mu_{th})$ 算法描述如下: 1) 利用冒泡排序法, 按规则数 (类别数) r 由小到大对 $\mathbf{v}(t) = [\delta_{init}(t), \mu_{th}(t), r(t), S(t)]$ 重新排序, 结果为 $\mathbf{v}'(t) = [\delta'_{init}(t), \mu'_{th}(t), r'(t), S'(t)]$, t 为步骤 8 中的迭代次数, $t = 1, \dots, T_{max}$, T_{max} 为最大迭代数; 2) 按前向差分方式求解 S 关于规则数 (类别数) 的变化率, $\Delta S(t_n) = |S'(t_n + 1) - S'(t_n)|$, $t_n = 1, \dots, T_{max} - 1$; 3) 求 S 关于规则数 (类别数) 变化率最大对应的类别数, $C_0 = \arg \max_{1 \leq t_n < T_{max}} \Delta S(t_n)$; 4) 求 S 变化率最大、值较小对应的 $(\delta_{init}, \mu_{th})$, IF $S'(C_0 + 1) > S'(C_0)$ THEN $\delta_{init} = \delta'_{init}(C_0)$; $\mu_{th} = \mu'_{th}(C_0)$; ELSE $\delta_{init} = \delta'_{init}(C_0 + 1)$; $\mu_{th} = \mu'_{th}(C_0 + 1)$; END.

注 1. 对 S 关于规则数 (类别数) 的变化率而言, 其值越大, 表明聚类效果越好, 这是符合类内相似度大、类间相似度小的聚类目标. 假设 C_0 为最佳类别数, 当采用 $C = C_0$ 划分数据类别时, 获得的聚类结果是最佳的, 此时, 类内数据较密集, 类间数据距离较大, 类内离散度 S 具有较小的值. 当采用 $C < C_0$ 划分数据类别时, 实质是对类中心进行划分, 此时, 类内距离方差为类间距离方差, 数据较分散, 类内离散度 S 具有较大的值. 在这种情况下, 无论类别数 C 如何变化, 类内距离方差的变化只限于类间距离方差的变化, 因此, 类内离散度 S 随着 C 变化不明显. 当采用 $C > C_0$ 划分数据类别时, 实质是对本来数据较密集类再进行划分, 此时, 类间距离为类内距离, 在这种情况下, 无论类别数 C 如何变化, 类间距离变化只限于类内距离的变化, 其变化并不明显, 同样, 类内距离方差变化也不明显, 原因是这些数据都属于类内数据, 有较大的相似性, 因此, 这种情况类内离散度 S 随着 C 变化亦不明显. 然而, 当类别数从 $C_0 - 1$ 到 C_0 划分变化时, 类内距离方差由类间距离方差变为较密集的类内距离方差, 数据由较分散状态变为较密集状态, 即 S 由较大值变为较小值, 发生了显著的变化. 同样, 当类别数从 C_0 到 $C_0 + 1$ 划分变化时, 类间距离变为较密集的类内距离, 数据由较密集状态变为较分散状态 (可理解为观察数据的尺度变小了), 即 S 由较小值变为较大值, 同样发生了显著的变化. 从上述分析可

知, 在整个类别数遍历过程中, 类内离散度 S 变化率最大发生在最佳聚类处, 因此, 本文认为 S 变化率最大、值较小对应的类别数为最佳类别数, 获得该最佳类别数的 $(\delta_{init}, \mu_{th})$ 为最合适参数。

2.2 后件参数辨识

在前件结构和参数确定后, 式 (5) 可转化成如式 (11) 所示形式:

$$y(\mathbf{x}) = \sum_{i=1}^r \left[\mu_i(\mathbf{x}) \left(\sum_{j=1}^n p_{ij} x_j + p_{i0} \right) \right] + b = \sum_{i=1}^r \left(\sum_{j=1}^n \mu_i(\mathbf{x}) p_{ij} x_j + \mu_i(\mathbf{x}) p_{i0} \right) + b = \mathbf{p}^T \mathbf{o} + b \quad (11)$$

式中, $\mathbf{p} = [p_{10}, p_{11}, \dots, p_{1n}, \dots, p_{r0}, p_{r1}, \dots, p_{rn}]^T \in \mathbf{R}^{r(n+1)}$, $\mathbf{o} = [\mu_1(\mathbf{x}), \mu_1(\mathbf{x})x_1, \dots, \mu_1(\mathbf{x})x_n, \dots, \mu_r(\mathbf{x}), \mu_r(\mathbf{x})x_1, \dots, \mu_r(\mathbf{x})x_n]^T \in \mathbf{R}^{r(n+1)}$ 。

当有一个输入数据 $\mathbf{x}(k)$ 时, 则会有一个 $\mathbf{o}_k$ 与之对应, 因此, 可以把 $\mathbf{o}_k$ 看成式 (11) 的输入变量, 则 $y(k)$ 为 $\mathbf{o}_k$ 的输出, 即可把式 (11) 写为关于输入变量 $\mathbf{o}$ 的输出模型:

$$y(\mathbf{o}) = \mathbf{p}^T \mathbf{o} + b \quad (12)$$

令 $\mathbf{p} = \sum_{k=1}^N \alpha_k \mathbf{o}_k$, α_k 为待求系数, N 为训练样本数, 把 $\mathbf{p}$ 代入式 (12), 得:

$$y(\mathbf{o}) = \sum_{k=1}^N \alpha_k [\mathbf{o}_k]^T \mathbf{o} + b = \sum_{k=1}^N \alpha_k (\mathbf{o} \cdot \mathbf{o}_k) + b \quad (13)$$

在式 (13) 中, $(\mathbf{o} \cdot \mathbf{o}_k)$ 为线性核函数, 满足 Mercer 条件, 因此, 式 (13) 为线性支持向量机回归模型^[20]。

本文就是利用式 (13) 的线性支持向量机回归模型, 通过 $\{(\mathbf{o}_1, y(1)), \dots, (\mathbf{o}_N, y(N))\}$ 形成的训练数据对求解后件参数 $\mathbf{p}$ 和 b , 其中 p_{ij} 为:

$$p_{ij} = \sum_{k=1}^N \alpha_k \mu_i(\mathbf{x}(k)) x_j \quad (14)$$

式中, $i = 1, 2, \dots, r$, $j = 0, 1, 2, \dots, n$, α_k 为拉格朗日乘子, 且 $x_0 = 1$ 。

2.3 算法时间性能分析

算法时间性能通常用时间复杂度表示, 本辨识算法的时间复杂度包括前件辨识时间复杂度和后件辨识时间复杂度两部分。设有 N 对训练样本, 遍历完 δ_{init} 和 μ_{th} 取值区间需要的迭代数为 T (与 δ_{init} 和 μ_{th} 的遍历步长有关), 遍历完 δ_{init} 和 μ_{th} 获得的最大规则数为 L , 则由步骤 3、步骤 5、步骤 7 和步骤 8 可知, 完成前件辨识前 8 步的最大时间复杂度为 $O(TLN)$ 。步骤 9 中第一步冒泡排序算法的时间复杂度为 $O(T^2)$, 第二、三步的时间复杂度均为 $O(T)$, 则完成步骤 9 的时间复杂度为 $O(T^2)$ 。因此, 前件辨识的最大时间复杂度为 $O(TLN) + O(T^2)$ 。后件参数是利用支持向量机回归算法实现辨识的, 因此, 其时间复杂度为支持向量机回归模型训练的时间复杂度 $O(N^3)$ 。由上述分析可知, 本文辨识算法总的时间复杂度为 $O(TLN) + O(T^2) + O(N^3)$ 。

3 仿真实验

为验证本文提出的 T-S 模糊模型自组织算法的有效性, 给出了 4 个仿真实例, 其中 2 个是混沌序列模型辨识, 另 2 个是复杂工业过程辨识。本文采用输出的均方根误差 ($RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (\hat{y}_j(k) - y_j(k))^2}$) 或无损误差指数 ($NDEI = \frac{RMSE}{S.D.}$, $S.D.$ 表示目标数据标准偏差) 来衡量模型的辨识精度。

4 个仿真例子的重叠系数 β 均为 0.5, 模糊加权指数 q 均为 1.0, δ_{init} 遍历区间均为 $[0.1, 0.7]$, δ_{init} 的遍历步长均取 0.1, μ_{th} 遍历区间均为 $[0.3, 0.8]$, μ_{th} 的遍历步长均为 0.02。 δ_{init} 和 μ_{th} 遍历区间不取 $[0, 1]$ 的原因是这两个参数取值过小, 聚类数过多, S 值趋于零, 相反取值过大, 聚类个数过少, 使得 S 基本保持不变, 这两种情况 S 的变化率均基本为零, 可以忽略。本文仿真实验环境为: 操作系统为 Windows XP, 开发平台为 Matlab7, 内存为 2GB, CPU 主频 2.67。

3.1 混沌 MackeyGlass 序列模型辨识

混沌 MackeyGlass 序列形式为

$$\frac{dx}{dt} = -bx(t) + \frac{ax(t-\tau)}{1+x^{10}(t-\tau)} \quad (15)$$

式 (15) 中参数 $a = 0.2$, $b = 0.1$, $\tau = 17$ 。混沌 MackeyGlass 序列如图 1 所示。T-S 模糊模型的输出 $y = x(k+1)$, 输入 $\mathbf{x} = [x(k), x(k-1), x(k-2)]$, 训练样本数为 1000 ($k = 1, \dots, 1000$), 验证模型样本个数为 100 ($k = 1005, \dots, 1104$)。模型辨识所需的训练时间为 37.106322 秒, S 曲线如图 2 所示。




图 1 混沌 MackeyGlass 序列

Fig. 1 Chaos MackeyGlass sequence




图 2 MackeyGlass 序列的 S 曲线

Fig. 2 The S curve of MackeyGlass sequence

图中实心点标注的是每个 μ_{th} 与遍历整个 δ_{init} 区间所得到的 S 变化率最大值, 此时 S 值较小的 $(\delta_{init}, \mu_{th})$ 即为这一组迭代下的最优配对, 根据 μ_{th} 的变化区间和步长, 可

以得到 26 个这样的变化率最大值. 实心五角星标注的是遍历整个 μ_{th} 区间和 δ_{init} 区间的 S 变化率最大值, 其中 S 值较小的 $(\delta_{init}, \mu_{th})$ 即为最优参数. 最优参数为 $\delta_{init} = 0.2$, $\mu_{th} = 0.48$, 在这组参数下, T-S 模糊模型规则数为 8, 验证结果和辨识误差分别如图 3 和图 4 所示. 表 1 给出了本文辨识算法与其他辨识算法的比较结果, 由表 1 可见, 本文提出的辨识算法具有较高的辨识精度.




图 3 MackeyGlass 序列辨识模型验证
Fig. 3 MackeyGlass sequence identification model verification




图 4 MackeyGlass 序列辨识模型误差曲线
Fig. 4 MackeyGlass sequence identification model error curve

表 1 混沌 MackeyGlass 序列模型辨识结果性能比较		
Table 1 Performance comparison of chaos MackeyGlass sequence model identification results		
模型	规则数	RMSE/ NDEI
文献 [21]	3	0.008424/—
文献 [22]	4	0.0208/—
文献 [23]	6	—/0.03
文献 [24]	12	0.0066/—
文献 [25]	10	0.0088/—
本文方法	8	0.0051/0.0219

3.2 混沌 Henon 映射模型辨识
混沌 Henon 映射形式为

$$y(k+1) = -Py^2(k) + Qy(k-1) + 1.0 \tag{16}$$

式 (16) 中参数 $P = 1.4$, $Q = 0.3$. 混沌 Henon 映射如图 5 所示. T-S 模糊模型的输出 $y=y(k+1)$, 输入 $x=[y(k), y(k-1), y(k-2)]$, 训练样本个数为 1000 ($k=1, \dots, 1000$), 验证模型样本个数为 1000 ($k=1001, \dots, 2000$). 模型辨识所需的训练时间为 37.615786 秒, S 曲线如图 6 所示. 最优参数

为 $\delta_{init} = 0.3$, $\mu_{th} = 0.5$, T-S 模糊模型规则数为 8, 验证结果和辨识误差分别如图 7 和图 8 所示. 表 2 给出了本文辨识算法与其他辨识算法的比较结果, 由表 2 可见, 与其他算法相比, 本文算法具有较高的辨识精度.




图 5 混沌 Henon 映射曲线
Fig. 5 Chaos Henon mapping curve




图 6 Henon 映射的 S 曲线
Fig. 6 The S curve of Henon mapping




图 7 Henon 映射辨识模型验证
Fig. 7 Henon mapping identification model verification




图 8 Henon 映射辨识模型误差曲线
Fig. 8 Henon mapping identification model error curve

表 2 混沌 Henon 映射模型辨识结果性能比较

Table 2 Performance comparison of chaos Henon mapping model identification results

模型	规则数	RMSE
文献 [11]	—	0.00331
文献 [26]	15	0.469
文献 [27]	7	0.188
文献 [28]	9	0.2021
本文方法	8	0.0029

3.3 单晶炉加热器功率 - 温度模型辨识

单晶炉加热器的输入输出数据来自文献 [12], 如图 9 (a)、图 9 (b) 所示, 共有 190 个. T-S 模糊模型的输出 $y = y(k)$, 输入 $x = [x(k), x(k-1), x(k-2), y(k-1), y(k-2), y(k-3), y(k-4)]$, 训练样本个数为 140 ($k = 1, \dots, 140$), 验证模型样本个数为 50 ($k = 141, \dots, 190$). 模型辨识所需的训练时间为 19.026333 秒, S 曲线如图 10 所示, 最优参数为 $\delta_{init} = 0.6$, $u_{th} = 0.5$, T-S 模糊模型规则数为 10, 验证结果和辨识误差分别如图 11 和图 12 所示. 表 3 给出了本文辨识算法与文献 [12] 的比较结果, 由表 3 可见, 本文提出的辨识算法用较少的模糊规则可以获得较高的辨识精度.




图 9 单晶炉加热器输入输出数据

Fig. 9 The single crystal furnace heater input and output data


图 10 单晶炉加热器温度模型的 S 曲线Fig. 10 The S curve of single crystal furnace heater temperature model

表 3 单晶炉加热器功率 - 温度模型辨识结果性能比较

Table 3 Performance comparison of single crystal furnace heater power-temperature model identification results

模型	规则数	RMSE
文献 [12]	79	0.342
本文方法	10	0.132




图 11 单晶炉加热器温度辨识模型验证

Fig. 11 Single crystal furnace heater temperature identification model verification




图 12 单晶炉加热器温度辨识模型误差曲线

Fig. 12 Single crystal furnace heater temperature identification model error curve

3.4 空气预热器负荷 - 温度模型辨识

图 13(a) 和图 13(b) 分别为空气预热器的输入输出数据, 共有 750 个. T-S 模糊模型的输出 $y = y(k)$, 输入 $x = [x(k), x(k-1), y(k-1), y(k-2), y(k-3)]$, 训练样本个数为 650 ($k = 1, \dots, 650$), 验证模型样本个数为 100 ($k = 651, \dots, 750$). 模型辨识所需的训练时间为 42.177782 秒, S 曲线如图 14 所示, 最优参数为 $\delta_{init} = 0.3$, $\mu_{th} = 0.54$, T-S 模糊模型规则数为 9, 验证结果和辨识误差分别如图 15 和图




图 13 空气预热器输入输出数据

Fig. 13 The air preheater input and output data

16 所示。由图 16 可见, 辨识误差在 $-2.0\text{ }^{\circ}\text{C} \sim 1.5\text{ }^{\circ}\text{C}$ 之间, 其 $RMSE$ 为 0.183, 较好地满足系统要求。




图 14 空气预热器温度模型的 S 曲线

Fig. 14 The S curve of air preheater temperature model




图 15 空气预热器温度辨识模型验证

Fig. 15 Air preheater temperature identification model verification




图 16 空气预热器温度辨识模型误差曲线

Fig. 16 Air preheater temperature identification model error curve

4 结论

本文提出的模糊聚类算法能较合理划分输入空间, 从而保证了 T-S 模糊模型前件结构和参数的有效辨识。利用支持向量机回归算法辨识 T-S 模糊模型后件参数, 可以提高辨识精度和泛化能力。仿真结果表明, 本文提出的 T-S 模糊模型自组织算法在获得较少规则的情况下仍然具有较高的辨识精度。

References

- 1 Takagi T, Sugeno M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, 1985, **SMC-15**(1): 116–132
- 2 Liao Long-Tao, Li Shao-Yuan, Huang Guang-Bin. T-S fuzzy model identification with growing and pruning rules for nonlinear systems. *Acta Automatica Sinica*, 2007, **33**(10): 1097–1100
(廖龙涛, 李少远, 黄广斌. 规则可生长与修剪的非线性系统 T-S 模糊模型辨识. 自动化学报, 2007, **33**(10): 1097–1100)
- 3 Liu Ya, Hu Shou-Song. Fuzzy robust tracking control for uncertain nonlinear systems. *Acta Automatica Sinica*, 2004, **30**(6): 949–953
(刘亚, 胡寿松. 不确定非线性系统的模糊鲁棒跟踪控制. 自动化学报, 2004, **30**(6): 949–953)
- 4 Mi Yang, Jing Yuan-Wei. Robust stabilization of nonlinear time delay discrete-time systems based on T-S model. *Acta Automatica Sinica*, 2006, **32**(2): 207–212
(米阳, 井元伟. 基于 T-S 模型的非线性时滞离散系统的鲁棒镇定. 自动化学报, 2006, **32**(2): 207–212)
- 5 Wu W, Li L, Yang J, Liu Y. A modified gradient-based neuro-fuzzy learning algorithm and its convergence. *Information Sciences*, 2010, **180**(9): 1630–1642
- 6 Li C S, Chiang T W, Yeh L C. A novel self-organizing complex neuro-fuzzy approach to the problem of time series forecasting. *Neurocomputing*, 2013, **99**: 467–476
- 7 Wai R J, Huang Y C, Chen Y C. Intelligent daily load forecasting with fuzzy neural network and particle swarm optimization. In: *Proceedings of 2012 IEEE International Conference on Fuzzy Systems*. Brisbane, Australia: IEEE, 2012. 1–6
- 8 Liu F, Er M J. Learning algorithm for constructing fuzzy neural networks with application to regression problems. In: *Proceedings of 2011 International Conference on Information Science and Technology*. Nanjing, China: IEEE, 2012. 318–322
- 9 Chen C S. TSK-type self-organizing recurrent-neural-fuzzy control of linear microstepping motor drives. *IEEE Transactions on Power Electronics*, 2010, **25**(9): 2253–2265
- 10 He L Q, Sun X F. Set-membership identification of T-S fuzzy models using support vector regression. In: *Proceedings of the 9th International Conference on Electronic Measurement & Instruments*. Beijing, China, IEEE, 2009. 1-59–1-63
- 11 Ko C N. Wsvr-based fuzzy neural network with annealing robust algorithm for system identification. *Journal of the Franklin Institute*, 2012, **349**(5): 1758–1780
- 12 Liang Yan-Ming, Liu Ding. Self-organizing identification algorithm for T-S fuzzy model and its applications. *Chinese Journal of Scientific Instrument*, 2011, **32**(9): 1941–1947
(梁炎明, 刘丁. 一种 T-S 模糊模型的自组织辨识算法及应用. 仪器仪表学报, 2011, **32**(9): 1941–1947)
- 13 Zhao W Q, Li K, Irwin G W. A new gradient descent approach for local learning of fuzzy neural models. *IEEE Transactions on Fuzzy Systems*, 2013, **21**(1): 30–44
- 14 Zhang Ji-Li, Zhao Tian-Yi, Liu Hui. Clustering obtainment method of T-S fuzzy control rules based on multi-dimensional ANFIS. *Journal of Dalian University of Technology*, 2010, **50**(4): 580–585
(张吉礼, 赵天怡, 刘辉. 基于多维 ANFIS 的 T-S 模糊控制规则聚类获取方法. 大连理工大学学报, 2010, **50**(4): 580–585)

- 15 Chen Xiao, Wang Ning. Fuzzy recurrent neural network modeling based on chaos DNA genetic algorithm. *Control Theory & Applications*, 2011, **28**(11): 1589–1594
(陈霄, 王宁. 基于混沌 DNA 遗传算法的模糊递归神经网络建模. 大控制理论与应用, 2011, **28**(11): 1589–1594)
 - 16 Yan Hui, Zhang Xue-Gong, Li Yan-Da. Relation between a support vector machine and the least square method. *Journal of Tsinghua University (Science and Technology)*, 2001, **41**(9): 77–80
(阎辉, 张学工, 李衍达. 支持向量机与最小二乘法的关系研究. 清华大学学报 (自然科学版), 2001, **41**(9): 77–80)
 - 17 Zhao L, Qian F, Yang Y P, Zeng Y, Su H J. Automatically extracting T-S fuzzy models using cooperative random learning particle swarm optimization. *Applied Soft Computing*, 2010, **10**(3): 938–944
 - 18 Jang J S R, Sun C T. Functional equivalence between radial basis function networks and fuzzy inference systems. *IEEE Transactions on Neural Networks*, 1993, **4**(1): 156–159
 - 19 Huang Jian-Yuan. *Fuzzy Sets and Its Application*. Yinchuan: Ningxia People's Education Publishing House, 1999
(黄健元. 模糊集及其应用. 银川: 宁夏人民教育出版社, 1999)
 - 20 Vapnik V. *The Nature of Statistical Learning Theory*. New York: Springer-Verlag, 1995
 - 21 Lin C J, Chen C H, Lin C T. A hybrid of cooperative particle swarm optimization and cultural algorithm for neural fuzzy networks and its prediction applications. *IEEE Transactions on Systems, Man, and Cybernetics-Part C: Applications and Reviews*, 2009, **39**(1): 55–68
 - 22 Juang C F, Hsiao C M, Hsu C H. Hierarchical cluster-based multispecies particle-swarm optimization for fuzzy-system optimization. *IEEE Transactions on Fuzzy Systems*, 2010, **18**(1): 14–26
 - 23 Subramanian K, Suresh S. A meta-cognitive sequential learning algorithm for neuro-fuzzy inference system. *Applied Soft Computing*, 2012, **12**(11): 3603–3614
 - 24 Deng X S, Wang X Z. Incremental learning of dynamic fuzzy neural networks for accurate system modeling. *Fuzzy Sets and Systems*, 2009, **160**(7): 972–987
 - 25 Leng G, Zeng X J, Keane J A. A hybrid learning algorithm with a similarity-based pruning strategy for self-adaptive neuro-fuzzy systems. *Applied Soft Computing*, 2009, **9**(4): 1354–1366
 - 26 Lee C H, Teng C C. Identification and control of dynamic systems using recurrent fuzzy neural networks. *IEEE Transactions on Fuzzy Systems*, 2000, **8**(4): 349–366
 - 27 Lin C J, Chin C C. Prediction and identification using wavelet-based recurrent fuzzy neural networks. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2004, **34**(5): 2144–2154
 - 28 Leng G, McGinnity T M, Prasad G. An approach for on-line extraction of fuzzy rules using a self-organising fuzzy neural network. *Fuzzy Sets Systems*, 2005, **150**(2): 211–243
- 梁炎明 西安理工大学自动化与信息工程学院副教授, 博士研究生. 主要研究方向为复杂系统建模与控制. 本文通信作者.
E-mail: liangym@xaut.edu.cn
(LIANG Yan-Ming Associate professor and Ph.D. candidate at the School of Automation & Information Engineering, Xi'an University of Technology. His research interest covers complex system modeling and control. Corresponding author of this paper.)
- 苏 芳 西安理工大学自动化与信息工程学院硕士研究生. 主要研究方向为复杂系统建模与控制. E-mail: susuf90@163.com
(SU Fang Master student at the School of Automation & Information Engineering, Xi'an University of Technology. Her research interest covers complex system modeling and control.)
- 李 琦 西安理工大学自动化与信息工程学院教授. 主要研究方向为信号与信息处理. E-mail: liqi@xaut.edu.cn
(LI Qi Professor at the School of Automation & Information Engineering, Xi'an University of Technology. His research interest covers signal and information processing.)
- 刘 丁 西安理工大学自动化与信息工程学院教授. 主要研究方向为复杂系统建模与控制. E-mail: liud@xaut.edu.cn
(LIU Ding Professor at the School of Automation & Information Engineering, Xi'an University of Technology. His research interest covers complex system modeling and control.)