

6-8-2020

Online Identification and Simulation of Multiple Model Based on Minimum Entropy Clustering

Xiaopeng Zhao

1. *School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;*

Yongchun Zhang

2. *China Academy of Information and Communications Technology, Beijing 100191, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Online Identification and Simulation of Multiple Model Based on Minimum Entropy Clustering

Abstract

Abstract: *An online identification algorithm for multiple model based on minimum entropy clustering was investigated. The number of local models and corresponding weights was calculated by the entropy based fuzzy subtractive clustering approach, and the regularity degree of the local system was considered along with the clustering process. Parameters of local models could be estimated online by the weighted recursive least square method. The waste heat recovery Organic Rankine Cycles system was used to demonstrate the algorithm. The result shows the identified multi-model not only can reach an accuracy and reliability identification result, but also has a stronger self-adaptability for uncertain external disturbances.*

Keywords

multiple model, nonlinear, minimum entropy, online identification

Recommended Citation

Zhao Xiaopeng, Zhang Yongchun. Online Identification and Simulation of Multiple Model Based on Minimum Entropy Clustering[J]. Journal of System Simulation, 2016, 28(6): 1306-1312.

基于最小熵聚类的多模型在线辨识及仿真

赵小鹏¹, 章永春²

(1. 华北电力大学, 北京 102206; 2. 中国信息通信研究院, 北京 100191)

摘要: 针对存在随机噪声干扰的多变量非线性系统, 提出一种基于最小熵聚类的多模型在线辨识算法。通过最小熵模糊减聚类算法在线确定多模型中子模型个数及其相应隶属度权值, 达到了在聚类过程中同时考虑系统规则程度的目的。给出了求取子模型参数的加权最小二乘递推表达, 实现了子模型参数的在线辨识。以烟气余热利用有机朗肯循环(ORC)系统为例进行了仿真研究, 结果表明该方法不仅能够获得精确可靠的辨识结果, 而且对环境的不确定干扰有较强的自适应能力。

关键词: 多模型; 非线性; 最小熵; 在线辨识

中图分类号: TP27

文献标识码: A

文章编号: 1004-731X (2016) 06-1306-07

Online Identification and Simulation of Multiple Model Based on Minimum Entropy Clustering

Zhao Xiaopeng¹, Zhang Yongchun²

(1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;

2. China Academy of Information and Communications Technology, Beijing 100191, China)

Abstract: An online identification algorithm for multiple model based on minimum entropy clustering was investigated. The number of local models and corresponding weights was calculated by the entropy based fuzzy subtractive clustering approach, and the regularity degree of the local system was considered along with the clustering process. Parameters of local models could be estimated online by the weighted recursive least square method. The waste heat recovery Organic Rankine Cycles system was used to demonstrate the algorithm. The result shows the identified multi-model not only can reach an accuracy and reliability identification result, but also has a stronger self-adaptability for uncertain external disturbances.

Keywords: multiple model; nonlinear; minimum entropy; online identification

引言

系统变量多、非线性和耦合作用强是现代工业系统的主要特征, 单一的线性模型已很难表达出系统的准确运行状态, 传统模型在工业检测和控制方面都面临着很大的挑战, 找到一个参数可以实时随

系统运行情况变化的模型成为工业界亟待解决的难题。于是, 从系统输入输出数据做切入点, 运用非线性系统辨识方法建立系统的 NRAMAX 结构模型、Hammerstein 结构模型或 Wiener 结构模型等辨识模型成为常用的方法^[1-2]。然而, 运用上述模型结构表征复杂系统全局性能往往十分困难。

基于以上情况, 分解合成的多模型建模方法在非线性和耦合系统中的应用日益受到业界的重视^[3-6], 该方法首先在各局部工况情况下建立系统的子模型, 达到把涵盖全工况的复杂过程分解的目的, 然后再



收稿日期: 2015-01-20 修回日期: 2015-06-16;
基金项目: 中央高校基本科研业务费专项(2014XS44);
作者简介: 赵小鹏(1986-), 男, 河北张家口, 博士生, 研究方向为非线性系统多模型辨识及应用; 章永春(1984-), 女, 河北张家口, 学士, 工程师, 研究方向为电气安全与信息通信。

<http://www.china-simulation.com>

• 1306 •

利用切换或者加权的方式实现利用多个子模型对全局模型描述。然而, 基于数据驱动的多模型辨识策略共同面临的一个问题是, 想要得到可以覆盖系统所有非线性特征的全部数据是不可能做到的。与此同时, 设备磨损和外部环境变化也会对对象特性产生影响甚至造成新工况的出现。因此, 研究在线的多模型辨识有其重要的实际意义。

文献[7]给出了模糊聚类算法的递推形式, 然而该算法中的聚类数目是给定的, 并未实现真正意义上的在线辨识。文献[8]对减法聚类的多模型辨识算法进行了改进, 实现了聚类数和局部模型参数的在线递推辨识, 然而研究中并未考虑随机噪声干扰对实际系统的影响。文献[9]将最小熵指标引入到聚类算法中, 给出了基于最小熵的聚类及辨识思路, 然而文献中没有实现聚类数和模型参数的在线辨识。

为了解决上述问题, 本研究针对有随机噪声干扰存在的多变量非线性系统提出基于最小熵聚类的多模型在线辨识算法。算法中, 最小熵的模糊减法聚类算法被用以在线确定多模型中子模型个数和其相应隶属度权值。同时, 基于局部优化函数的加权最小二乘递推方法被用于子模型参数辨识过程中, 运用该方法的好处是, 只需利用系统上一时刻信息就可以计算出当前模型的参数从而大大减轻了过程的计算复杂度。最后, 以两入两出烟气余热利用有机朗肯循环(ORC)系统为例进行了仿真研究, 得到了精确可靠的辨识结果, 同时表明该算法对环境的不确定干扰有较强的自适应能力。

1 多模型及其辨识问题描述

1.1 多模型描述

一个多变量(M 维输入 N 维输出)非线性时变系统可以由若干子模型构成的多模型系统来表达, 该多模型系统可以描述为

$$y(k) = \sum_{i=1}^n \rho_i(\varphi(k)) y_i(k) \quad (1)$$

式中: $y(k) \in \mathbf{R}^N$ 指 k 时刻时系统的多维输出, 是所有子模型 y_i ($i=1, 2, \dots, n$) 共同作用下系统的行

为, ρ_i 也被称为基函数, 是子模型 y_i 对应的归一化后的隶属度值, 它是调度变量 $\varphi(k) \in \mathbf{R}^n$ 的函数, 其表达式如下

$$\rho_i(\varphi(k)) = \frac{\lambda_i(\varphi(k))}{\sum_{i=1}^N \lambda_i(\varphi(k))} \quad (2)$$

所有的子模型构成一个动态网络, 每个子模型有其各自特征, 算法中通过聚类方式确定子模型个数和各自隶属度, 再通过某种合成方式完成系统任务。子模型的隶属度可通过如下 Gaussian bells 函数计算获得

$$\lambda_i(\varphi(k)) = \exp\left[-\frac{(\varphi(k) - c_i)^T (\varphi(k) - c_i)}{s_i^2}\right] \quad (3)$$

式中: c_i 是 Gaussian 函数的中心变量; s_i 用以确定 Gaussian 函数的宽度。需要指出的是, s_i 可以通过以下方法得出

$$s_i = k_s \frac{1}{n} \sum_{j=1}^n |c_i - c_{ij}| \quad (4)$$

式中: c_{ij} 是与当前中心 c_i 相邻的第 j 个中心, 常数 k_s 用以确定不同子模型之间的影响程度。由于 s_i 的变化范围不是很大, 而以上公式在子模型个数较多时计算量会大大增加, 故在多模型在线辨识之前常采用先验知识对 s_i 进行离线选定。

式中 y_i 的形式需根据系统特征确定, 可以是线性也可以是非线性, 可以是离散形式也可以是连续形式。这里选择多入多出系统的带控制量的自回归模型(Controlled auto-regressive model, CAR)进行讨论, 其表达式如下

$$A_i(z^{-1})y(k) = z^{-d} B_i(z^{-1})u(k) + \varepsilon(k) \quad (5)$$

$$\text{其中} \begin{cases} A_i(z^{-1}) = I + A_{i1}z^{-1} + A_{i2}z^{-2} + \dots + A_{in_A}z^{-n_A} \\ A_{ij} \in \mathbf{R}^{N \times N}, j = 1, \dots, n_A \\ B_i(z^{-1}) = B_{i0} + B_{i1}z^{-1} + B_{i2}z^{-2} + \dots + B_{in_B}z^{-n_B} \\ B_{ij} \in \mathbf{R}^{N \times M}, j = 1, \dots, n_B \end{cases}$$

$y(k)$, $u(k)$ 和 $\varepsilon(k)$ 分别为系统的输出、 $m \times 1$ 输入和白噪声干扰; n_A 和 n_B 分别为输出和输入的阶次。则可得多模型的最小二乘形式为^[10]:

$$y(k) = \sum_{i=1}^n \rho_i(\varphi(k)) \Psi^T(k) \theta_i + \xi(k) \quad (6)$$

$$\text{其中} \begin{cases} \Psi(k) = [-y(k-1), \dots, -y(k-n_A), \\ u(k-d), \dots, u(k-d-n_B)]^T \\ \theta_i = [A_{i1}, \dots, A_{in_A}, B_{i0}, \dots, B_{in_B}]^T \end{cases}$$

1.2 基于熵的数据聚类

如果一组数据有明显的聚类中心说明这组数据有规则的结构,反之则被称为是不规则或者混沌的。从熵的角度,有规则结构的数据熵值较小,不规则结构数据的熵值会较大。无序数据组中的数据分布是比较散乱的,但是往往可以通过聚类方式成为几个规则的数据组,而数据组中具有最小熵值的数据最适合作为这组数据的聚类中心。

因此,可以利用基于两点间距离的熵值来评估一个点作为聚类中心的可能性。本研究中选取二制熵作为熵的计算指标,二制熵的表达式如下:

$$E = -P \log_2(P) - (1-P) \log_2(1-P) \quad (7)$$

其中: P 代表数据密度函数,该密度函数的值取决于样本点跟其他点之间的欧式距离。聚类过程中所有数据样本被作为可能的聚类中心计算数据密度,然后基于这一数据密度计算样本熵值。两个数据点之间的熵值在 $[0, 1]$ 之间,当两个点相距很近或很远时,熵值都很小(趋于 0),当两点间的距离趋于所有点距离的平均值时,熵值较大(趋于 1)。

2 多模型的在线辨识算法

2.1 在线聚类算法

聚类的目的,是从数据集合中找到几个可以代表数据总体特征的样本(即聚类中心)。对于一个确定的中心来说应该是靠近于隶属于这个数据中心的数据,而相距其他聚类中心较远。聚类中心的特性可以由一个特定的子模型表达出来,最后通过多个子模型之间的合成来表达整体行为。值得指出的是,在对数据进行聚类处理之前,首先应对数据进行无量纲化处理,使其归一化到 $[0, 1]$ 区间,这样就可以避免由量纲造成的数据干扰。

常用到的模糊聚类算法有模糊 c 均值聚类、满意聚类、减法聚类等,这些聚类方法在不同场合可以达到各自的聚类目的。由于算法的简洁整齐和实现的方便有效,本研究中采用模糊减法聚类的方法对数据进行聚类。该聚类方法以所有数据样本作为可能的聚类中心,将其成为聚类中心的概率定义为密度值(P),密度值计算以特定数据样本到所有其他数据样本的距离和作为度量标准,形式如下:

$$P(\varphi(i)) = \frac{1}{1 + \frac{1}{N-1} \sum_{j=1, j \neq i}^{DL} (\varphi(i) - \varphi(j))^T (\varphi(i) - \varphi(j))} \quad (8)$$

式中: $i=1, 2, \dots, N$, $\varphi(i) \in \Phi = [\varphi(1), \varphi(2), \dots, \varphi(DL)]$ 为数据集中数据样本, DL 为数据集 Φ 的数据样本量。

聚类开始算法将一个数据 $\varphi(1)$ 认为是第 1 个聚类中心,并且令其密度值 $P_1(\varphi(1))=1$ 。 $P_k(\varphi(k))$ 表示第 k 个时刻的计算密度值,其计算公式如下:

$$P_k(\varphi(k)) = \frac{1}{1 + \frac{1}{k-1} \sum_{j=1}^{k-1} (\varphi(k) - \varphi(j))^T (\varphi(k) - \varphi(j))} = \frac{k-1}{(k-1)(\alpha(k)+1) - 2\beta(k)\varphi(k) + \delta(k)} \quad (9)$$

式中: $\alpha(k) = \varphi^T(k)\varphi(k)$, $\beta(k) = \sum_{j=1}^{k-1} \varphi^T(j)$, $\delta(k) = \sum_{j=1}^{k-1} \varphi^T(j)\varphi(j)$ 。并且存在以下递推关系:

$$\beta(k) = \beta(k-1) + \varphi^T(k-1) \quad (10)$$

$$\delta(k) = \delta(k-1) + \varphi^T(k-1)\varphi(k-1) \quad (11)$$

由公式(9)~(11)可知计算 $P_k(\varphi(k))$ 只需要保留 $\varphi(k-1)$, $\beta(k-1)$ 和 $\delta(k-1)$ 即可,不需要保留 k 时刻之前全部数据,这样大大减少了计算量。

如在 $k-1$ 时刻已存在 n 个聚类中心 $c_i (i=1, 2, \dots, n)$, 其密度值为:

$$P_{k-1}(c_i) = \frac{1}{1 + \frac{1}{k-2} \sum_{j=1, j \neq i}^{k-1} (c_i - \varphi(j))^T (c_i - \varphi(j))} \quad (12)$$

那么在 k 时刻 c_i 的密度递推公式可表达为:

$$P_k(c_i) = \frac{1}{1 + \frac{1}{k-1} \sum_{j=1, j \neq i}^k (c_i - \varphi(j))^T (c_i - \varphi(j))} = \frac{(k-1)D_{k-1}(c_i)}{k-2 + D_{k-1}(c_i) + \gamma(k)D_{k-1}(c_i)} \quad (13)$$

式中: $\gamma(k) = (c_i - \varphi(k))^T (c_i - \varphi(k))$, 其值可由当前数据 $\varphi(k)$ 计算得出。由式(7)可知此时各样本所表达的系统熵值为:

$$E_k = -P_k \log_2(P_k) - (1 - P_k) \log_2(1 - P_k) \quad (14)$$

数据样本的密度值反映了数据样本对所在数据在表达能力, 密度值越大说明样本数据越能描述所在数据的特征, 算法中模糊聚类的目的就是找到 $n (n \geq 2)$ 个符合条件的密度最大样本来表达整体数据。即相当于确定了含有一组规则(n 条)的模糊集合, 由这一组规则可以描述数据集中的任意样本。由公式(9), (12), (13)可知, 当新数据样本到来时, 系统所有数据的密度值都会受新数据的影响而发生变化。因此, 在线聚类中需要在新数据样本到来时重新计算及比较各数据样本及原聚类中心的密度值, 从而确定实时模糊集合和规则数目。确定聚类中心时要考虑以下几种情况:

<1> 新数据与其最近聚类中心之间的距离大于预设值(r_s), 并且新数据密度小于由对应聚类中心熵定义的熵限值(E_s), 此时认为出现新工况, 将新数据定为新聚类中心, 即:

$$\text{If } \min_{i=1, \dots, n} \|\varphi(k) - c_i\|_2 > r_s \text{ and } E_k(\varphi(k)) < E_s,$$

$$\text{Then } c_i = \varphi(k), R = R + 1$$

其中, $r_s = (0.5 \sim 0.7) \times \max_{i \neq j, i, j=1, \dots, k} \|\varphi(i) - \varphi(j)\|_2$,

$$E_s = (0.7 \sim 1.0) \max_{i=1, \dots, l} E_{k-1}(c_i)$$

<2> 新数据与其最近聚类中心之间的距离不大于预设值, 但新数据熵小于该聚类中心熵, 此时认为工况转移, 新数据样本代替原中心, 聚类中心数目不变, 即:

$$\text{If } \min_{i=1, \dots, n} \|\varphi(k) - c_i\|_2 \leq r_s \text{ and } E_k(\varphi(k)) < E_k(c_i),$$

$$\text{Then } c_l = \varphi(k)$$

其中, c_l 满足 $\|\varphi(k) - c_l\|_2 = \min_{i \neq j, i, j=1, \dots, k} \|\varphi(k) - c_i\|_2$ 。

<3> 新数据熵大于与其最近聚类中心的熵值, 维持原来聚类结果

If $E_k(\varphi(k)) > E_k(c_l)$, Then do nothing

<4> 数据的不断更新中会出现聚类中心不断靠近的情况, 当两个聚类中心间的距离不再大于某预设值时, 此时中心合并由其中熵值较小者担任, 同时聚类中心数减 1

$$\text{If } \min_{i \neq j, i, j=1, \dots, R} \|c_i - c_j\|_2 \leq r_{s1},$$

$$\text{Then } c_i = c_j, R = R - 1$$

$$t = \begin{cases} j, & \text{if } E_k(c_j) > E_k(c_i) \\ i, & \text{else} \end{cases}, r_{s1} = (0.5 \sim 0.7) \times r_s。$$

2.2 子模型参数在线递推辨识

由(6)式可知子模型的参数可以通过最小二乘的方式求得。在此过程中常定义全局优化指标和局部优化指标两种性能指标, 两种指标方法相较局部最优的方法在多数情况下表现得更为优越, 其计算量小、计算速度快并且鲁棒性相对要强。本文从局部最优方法出发得到子模型参数辨识的加权最小二乘递推方法, 即用多模型的实际输出与估计输出的偏差的加权平方和为代价函数, 形式为:

$$J_L = [J_{1L} \ J_{2L} \ \dots \ J_{mL}]^T = (y - \Psi\theta)^T \Lambda (y - \Psi\theta) \quad (15)$$

$$\text{并且 } J_{mL} = \sum_{i=1}^n \lambda_i (y_m(k) - \hat{y}_m(k, \theta_{mi}))^2 =$$

$$(y_{mL} - \Psi_{mL}\theta_m)^T \Lambda_i (y_{mL} - \Psi_{mL}\theta_m) \quad (16)$$

其中, $\theta_m = [\theta_{m1}^T \ \theta_{m2}^T \ \dots \ \theta_{mn}^T]^T \in R^{[n \times (n_a + n_b + 1)] \times 1}$, $m=1, 2, \dots, N$; θ_{mi} 为 θ_m 的第 i 列向量, $y_{mL} = [y_{mL}(1) \ y_{mL}(2) \ \dots \ y_{mL}(n)]^T \in R^{n \times 1}$ 为系统 m 通道在 k 时刻的输出量, 局部参数求取中, $y_{mL}(1) = y_{mL}(2) = \dots = y_{mL}(n) = y(k)$, $\Psi_{mL} = [\phi_{mL}^T(1) \ \phi_{mL}^T(2) \ \dots \ \phi_{mL}^T(n)]^T \in R^{n \times [N \times (n_a + n_b + 1)]}$, 且 $\phi_{mL}^T(1) = \phi_{mL}^T(2) = \dots = \phi_{mL}^T(n) = \phi^T(k)$, 其中, $\phi^T(k) = \phi_{mL}^T(n) = [-y(k-1), \dots, -y(k-n_a), u(k-d), \dots, u(k-d-n_b)] \in R^{N \times (n_a + n_b + 1)}$, $\Lambda_i = \text{dig}[\lambda_1, \dots, \lambda_n] \in R^{n \times n}$ 。

由此得局部参数加权最小二乘递推公式如下:

$$\hat{\theta}_m(k) = \hat{\theta}_m(k-1) + K_L(k) \lambda_i (y_{mL}(k) - \phi_{mL}^T(k) \hat{\theta}_m(k-1)) \quad (17)$$

$$K_L(k) = P_L(k-1)\phi_{mL}(k)(\phi_{mL}^T(k)P_L(k-1)\phi_{mL}(k) + 1)^{-1} \quad (18)$$

$$P_L(k) = (I - K_L(k)\lambda_i\phi_{mL}^T(k))P_L(k-1) \quad (19)$$

通过以上估值可以得到, M 维输入, N 维输出的系统的多模型系统参数估计值为:

$$[\tilde{\theta}_1^T(k), \tilde{\theta}_2^T(k), \dots, \tilde{\theta}_n^T(k)] = [\hat{\theta}_1(k), \hat{\theta}_2(k), \dots, \hat{\theta}_N(k)]^T \quad (20)$$

另外, 多模型的辨识精度可由非维数误差性能指标(NDEI)来进行评价, NDEI 的表达式如下:

$$I_{NDEI} = \left[\sum_{k=1}^N (y(k) - \hat{y}(k))^2 / \sum_{k=1}^N (x(k) - \mu)^2 \right]^{1/2} \quad (21)$$

3 仿真研究

本文以 11 kW 烟气余热利用有机朗肯循环系统为例进行仿真研究, 烟气余热利用有机朗肯循环系统发电工作过程如下:

首先, 工业余热尾气在蒸发器中经过换热将循环过程的液态有机工质加热成工质蒸汽。之后, 工质蒸汽在膨胀机内将内能转化为动能带动膨胀机转动, 同时膨胀机与发电机连接达到发电目的。做功后的工质蒸汽被引入到冷凝器, 经过冷凝作用再次成为液体工质而进入储液罐当中。需要注意的是, 经膨胀机做功后的工质蒸汽仍然具有一定的热量, 为提高系统热效率一般先将工质蒸汽引入回热器对进入蒸发器前的冷工质进行预热, 热量二次转化后的工质蒸汽随后被引入到冷凝器。最后, 储液罐中的液态有机工质经工质增压泵作用被再次打入蒸发器中, 至此一次循环完成。该过程的原理图见图 1。

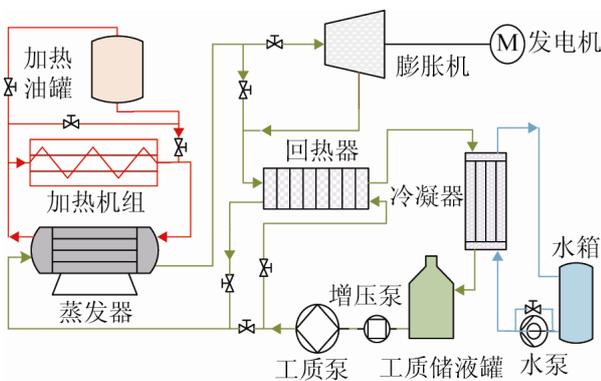


图 1 余热利用 ORC 系统原理图

余热利用 ORC 系统的机理模型可以通过质量守恒和能量守恒的原理求得, 然而由于该系统中存在着多个有非线性特性的设备, 如蒸发器、冷凝器、膨胀机和电动阀等, 通过机理建模或者传统辨识建模所得模型很难满足工况变化时的系统控制要求, 所以本研究中应用多模型在线辨识的方法来解决这一问题。不失一般性地, 该过程的一般非线性表达式可表示为:

$$y_k = f(y_{k-1}, \dots, y_{k-n_A}, u_k, u_{k-1}, \dots, u_{k-n_B}, v_k) \quad (22)$$

其中, v_k 指系统存在的随机噪声干扰, 其噪声分布如图 2 所示。

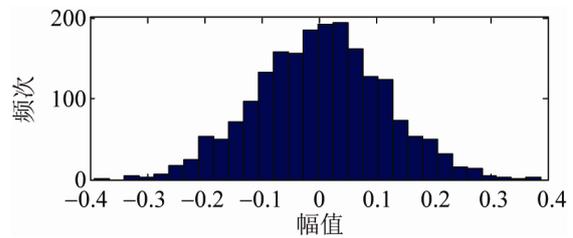


图 2 系统随机噪声幅值分布图

从系统控制角度, 余热利用 ORC 系统运行过程中, 最关心的被控变量有蒸发压力(P)和过热度(T_{sup}), 与之相对应的控制量分别是膨胀机转速和工质泵转速。本研究在系统稳定运行(工质泵转速 500 rad/min, 膨胀机转速 1 200 rad/min)情况下, 以零均值白噪声为辨识激励信号, 考虑系统输出存在随机噪声干扰时的辨识结果。仿真中以 1 s 为采样间隔采样 1 400 组过程数据, 前 700 组数据作为辨识训练数据, 后 700 组数据作为辨识检验数据。参数初始化时, 设置离线辨识所得模型阶次 $n_A = 3$, $n_B = 2$, 并取 $s_i = 1$ 。辨识仿真结果如图 3~6。

通过仿真曲线可知, 该多模型辨识方法在有随机噪声存在的非线性系统中可以有效地进行在线辨识建模, 建模结果精确稳定。

辨识过程的指标数值如表 1, 从辨识指标值上能够分析得到, 相对过热度来说蒸发压力受到外部干扰时影响更大。

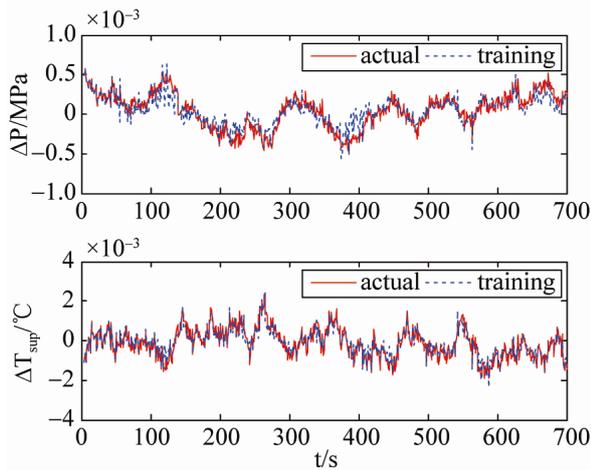


图 3 训练数据辨识结果跟系统实际输出对比图

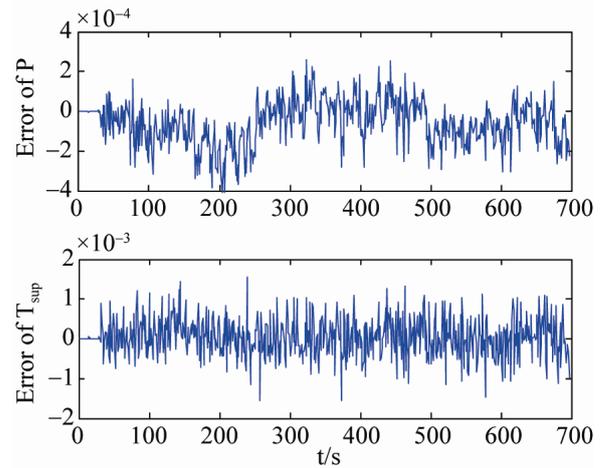


图 6 检验数据辨识误差曲线

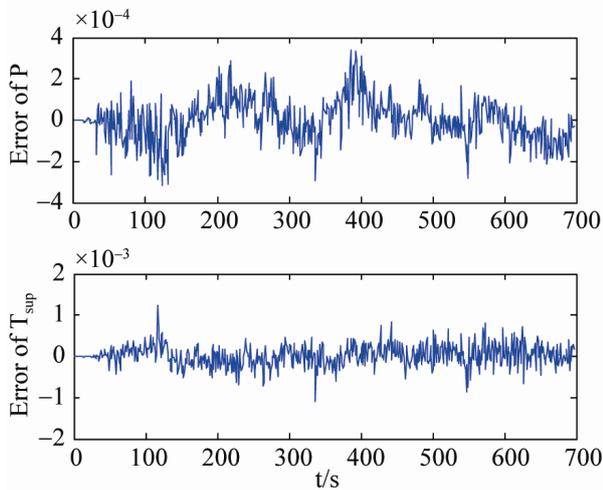


图 4 训练数据辨识误差曲线

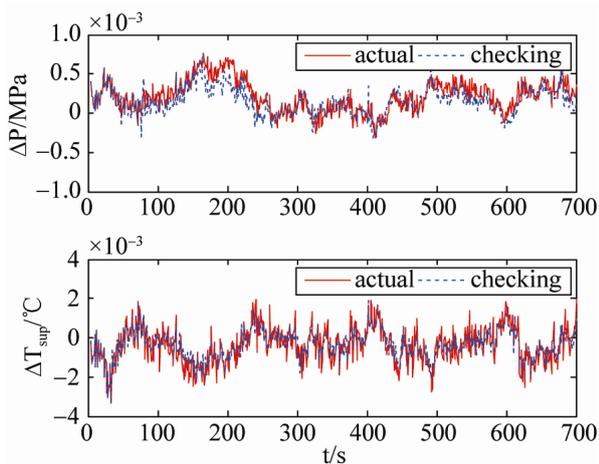


图 5 检验数据辨识结果跟系统实际输出对比图

表 1 辨识过程指标值

辨识指标	模型个数	最大误差	NDEI
P_trn	11	3.4075×10^{-4}	6.2029
T _{sup} _trn	11	0.0012	10.2054
P_chk	7	4.0759×10^{-4}	9.9269
T _{sup} _chk	7	0.0016	10.7177

4 结论

现实复杂工业过程中工况变化往往呈现不确定的特征, 系统的模型参数通常是时变的。利用离线多模型辨识方法所建模型很难自适应地反映系统的非线性情况。本文针对随机噪声干扰下的多变量非线性系统提出一种基于最小熵聚类的多模型在线辨识算法。算法以最小熵为聚类指标在线确定子模型个数和其相应隶属度, 同时确保了聚类系统的规则程度, 可使多模型辨识结果更加精确稳定。同时文章结合子模型参数求取的递推最小二乘算法, 完成了从聚类到模型参数的在线辨识。最后, 该策略被应用于烟气余热利用有机朗肯循环系统, 仿真结果表明利用该多模型在线辨识建模方法不仅能够得到精确可靠的辨识结果, 而且对环境的不确定干扰有较强的自适应能力。

参考文献:

- [1] 靳其兵, 杨瑞赓, 王珠, 等. 一类统一非线性特性的 Hammerstein 模型辨识方法研究 [J]. 系统仿真学报, 2014, 26(12): 2887-2891.

(下转第 1320 页)