

文章编号: 1001-0920(2005)05-0495-05

基于 T-S 模型的模糊预测控制研究

邢宗义¹, 胡维礼¹, 贾利民²

(1. 南京理工大学 自动化系, 江苏 南京 210094; 2 北京交通大学 交通运输学院, 北京 100044)

摘要: 提出一种基于 T-S 模型的模糊预测控制策略。利用模糊聚类算法离线辨识 T-S 模型, 采用带遗忘因子的递推最小二乘法进行模型参数的选择性在线学习; 对模糊模型在每一采样点进行线性化, 将 T-S 模型表示的非线性系统转化为线性时变状态空间模型, 并将约束非线性优化问题转化为线性二次规划问题, 解决了非线性预测控制中如何获得非线性模型和非线性优化在线求解的难题。将预测域内的线性模型序列作为预测模型, 减小了模型误差, 提高了控制性能。pH 中和过程的仿真验证了该方法的有效性。

关键词: 模糊模型; 模糊建模; 预测控制; 非线性

中图分类号: TP273 **文献标识码:** A

Fuzzy predictive control based on T-S model

XING Zong-yi¹, HU Wei-li¹, JIA Limin²

(1. Department of Automatic, Nanjing University of Science and Technology, Nanjing 210094, China; 2. School of Traffic and Transportation, Beijing Jiaotong University, Beijing 100044, China. Correspondent: XING Zong-yi, E-mail: xingzongyi@tom.com)

Abstract: A fuzzy model based predictive control of nonlinear system is presented. T-S fuzzy model is identified by fuzzy clustering algorithm, and its parameters are self-learning online by selective recursive least square method. T-S model is linearized to be time-varying system, and thus nonlinear optimization problem is turned to a quadratic programming problem. Consequently, two major difficulties in nonlinear predictive control to obtain accurate nonlinear model and to solve nonlinear optimization problem online are solved. The simulation result on pH neutralization process shows the effectiveness of the proposed method.

Key words: fuzzy model; fuzzy modeling; predictive control; nonlinear

1 引言

近 20 年来, 预测控制受到了广泛重视^[1]。但对于许多强非线性的工业过程而言, 传统的线性预测控制很难达到满意的控制目标, 因此一些学者提出了非线性预测控制^[2]。非线性预测控制在拓宽预测控制适用领域的同时, 存在两大难题: 1) 如何建立非线性预测模型, 使得模型能够以一定的精度, 在一定步长内预测过程的输出; 2) 如何解决非线性优化问题, 使得算法在采样周期内完成控制信号的在线优化求解^[3]。

模糊模型本质上是一种非线性模型, 可以任意

精度逼近任何非线性系统。因此, 模糊模型作为非线性预测控制的预测模型, 即模糊预测控制, 近年来已成为预测控制研究的热点^[3~5]。

文献[3]提出了基于遗传算法的模糊预测控制, 预测模型可以是任何模糊模型, 非线性优化问题通过一种改进的遗传算法在线求解。文献[4]利用冲击响应信号辨识模糊卷积模型, 针对模型的每一个子模型设计预测控制器, 通过协调层达到全局最优, 从而有效地避免了非线性优化问题。文献[5]对单值后件的模糊模型进行工作点线性化, 将非线性系统转化为线性时变系统, 并利用多步预测控制策略构成

收稿日期: 2004-06-28; 修回日期: 2004-10-08

基金项目: 国家自然科学基金项目(60474034); 江苏省博士后基金项目

作者简介: 邢宗义(1974—), 男, 山东临沂人, 博士后, 从事模糊建模、智能控制等研究; 胡维礼(1941—), 男, 江苏镇江人, 教授, 博士生导师, 从事智能系统与控制、非线性控制等研究

了模糊预测控制

本文提出了一种新的基于 T-S 模型的模糊预测控制策略 利用模糊聚类算法离线辨识 T-S 模型, 采用带遗忘因子的递推最小二乘法选择性在线学习模型参数 在每一个采样时刻, 利用预测时域的一组线性模型序列作为预测模型, 并将约束非线性优化问题转化为线性二次规划问题 为保证控制性能, 并满足优化目标的在线求解, 给出了一种多步线性化的预测控制策略

2 T-S 模型的辨识

2.1 T-S 模型的离线辨识

本文采用齐次 T-S 模型, 其规则描述如下:

$$R_i: \text{ If } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ and } \dots \text{ and } x_n \text{ is } A_{in} \\ \text{ Then } \hat{y}_i = \theta_{i1}x_1 + \theta_{i2}x_2 + \dots + \theta_{in}x_n \quad (1)$$

其中: R_i 表示第 i 条模糊规则, x_j 为输入变量, A_{ij} 为定义在输入论域中的隶属函数 本文采用高斯型隶属函数

$$A_{ij}(x_j) = \exp\left(-\frac{1}{2} \frac{(x_j - v_{ij})^2}{\sigma_{ij}^2}\right), \quad (2)$$

其中 v_{ij} 和 σ_{ij} 分别代表函数的中心和方差

利用 Gustafson-Kessel (G-K) 聚类算法离线辨识 T-S 模型的前件参数^[6]

G-K 聚类算法的目标函数为

$$J(Z; \Lambda, V) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m D_{ik}^2 \quad (3)$$

其中: $Z = [z_1, z_2, \dots, z_N]$ 为数据集, $\Lambda = [\mu_{ik}]_{c \times N}$ 为数据集的模糊划分矩阵; $V = [v_1, v_2, \dots, v_c]$ 为聚类中心, 即隶属函数的中心; c 为聚类数目; N 为样本数目; m 为模糊指数; D_{ik} 为第 i 个聚类与第 k 个数据间的距离范数; μ_{ik} 为第 k 个数据相对于第 i 个聚类中心的隶属度, 且满足以下条件:

$$\mu_{ik} \in [0, 1], \quad \sum_{i=1}^c \mu_{ik} = 1, \quad 0 < \sum_{k=1}^N \mu_{ik} < N. \quad (4)$$

第 i 个聚类与第 k 个数据间的距离范数为

$$D_{ik}^2 = \|z_k - v_i\|_{A_i}^2 = (z_k - v_i)^T A_i (z_k - v_i). \quad (5)$$

其中

$$A_i = (\rho \det(F_i))^{1/n} F_i^{-1}, \quad (6)$$

$$\rho = \det(A_i), \quad (7)$$

模糊协方差矩阵

$$F_i = \frac{\sum_{k=1}^N (\mu_{ik})^m (z_k - v_i)(z_k - v_i)^T}{\sum_{k=1}^N (\mu_{ik})^m}. \quad (8)$$

利用拉格朗日乘法可求得使目标函数最小的必要条件为

$$\mu_{ik} = \frac{1}{c \sum_{j=1}^N (D_{ik}/D_{jk})^{2/(m-1)}}, \quad (9)$$

$$v_i = \frac{\sum_{k=1}^N (\mu_{ik})^m z_k}{\sum_{k=1}^N (\mu_{ik})^m}. \quad (10)$$

高斯型隶属函数的方差为

$$\sigma_{ij}^2 = \frac{\sum_{k=1}^N (\mu_{ik})^m (x_{jk} - v_{jk})^2}{\sum_{k=1}^N (\mu_{ik})^m}. \quad (11)$$

分别给定输入变量、输出及加权矩阵, 即

$$X = [x_1, x_2, \dots, x_N], \\ y = [y_1, y_2, \dots, y_N], \\ W_i = \text{diag}(\mu_{i1}, \mu_{i2}, \dots, \mu_{iN}). \quad (12)$$

利用加权最小二乘法辨识模型的初始后件参数

$$\theta = [X^T W X]^{-1} X^T W y. \quad (13)$$

基于聚类算法的模糊建模步骤如下:

- 1) 选择模糊聚类数目 c , 模糊加权指数 m 和中止标准 $\epsilon > 0$;
- 2) 随机产生模糊划分矩阵 Λ , 并满足式(4)的条件;
- 3) 利用式(10) 计算聚类中心;
- 4) 利用式(5) ~ (8) 计算距离范数;
- 5) 利用式(9) 更新模糊划分矩阵 Λ ;
- 6) 如果满足条件 $\|\Lambda^l - \Lambda^{l-1}\| < \epsilon$ 则停止, 否则重复 3);
- 7) 利用式(11) 计算隶属函数的方差;
- 8) 利用式(13) 计算模型后件参数

2.2 T-S 模型的在线学习

对于实际系统, 其结构一般不会发生变化, 即模糊模型的规则数目、输入变量和输入空间划分等一般不发生变化 因此本文只对模型规则的后件参数进行在线学习

采用带遗忘因子的递推最小二乘法实现模型参数的在线学习, 即

$$\theta(k+1) = \theta(k) + P_i(k+1)(y(k+1) - x^T(k+1)\theta(k)), \\ P_i(k+1) = \frac{1}{\lambda} \left(P_i(k) - \frac{P_i(k)x(k+1)x^T(k+1)P_i(k)}{\lambda + x^T(k+1)P_i(k)x(k+1)} \right), \quad (14)$$

其中 λ 为遗忘因子. λ 越小, 对新数据的学习能力越强; 当 $\lambda = 1$ 时, 该算法转化为普通的递推最小二乘法

为避免对某种工况的过度学习而造成模型泛化能力下降, 本文提出了选择性在线学习, 即每次进

行学习时, 首先计算每条规则对应的激励强度, 只对具有最大激励强度的模糊规则参数进行学习, 而其他规则参数保持不变

2.3 T-S 模型的等价转化

T-S 模型是一种本质的非线性模型, 其后件是线性系统表达式, 因此可通过采样点线性化, 将 T-S 模型表示的非线性系统等价转化为线性时变状态空间模型 此处的线性化概念不是 Lyapunov 意义上的, 而是相对于 T-S 模型的时变特性而言的^[8]

对于 MISO 系统, 其 T-S 模型的规则如下:

R^i : if $y(k)$ is A_0^i and $y(k-1)$ is A_1^i and ... and $y(k-n_y)$ is $A_{n_y}^i$ and $u_1(k-t_{d1}+1)$ is $A_{n_y+1}^i$ and ... and $u_1(k-t_{d1}-n_1+1)$ is $A_{n_y+n_1+1}^i$ and ... and $u_p(k-t_{dp}+1)$ is $A_{n_y+n_1+\dots+n_{p-1}+p}^i$ and ... and $u_p(k-t_{dp}-n_p+1)$ is $A_{n_y+n_1+\dots+n_p+p}^i$,

Then $y_i(k+1) = a_{0y}^i y(k) + a_{1y}^i y(k-1) + \dots + a_{n_y y}^i y(k-n_y) + b_{1,0u}^i u_1(k-t_{d1}+1) + b_{1,1u}^i u_1(k-t_{d1}) + \dots + b_{1,n_1 u}^i u_1(k-t_{d1}-n_1+1) + \dots + b_{p,0u}^i u_p(k-t_{dp}+1) + b_{p,1u}^i u_p(k-t_{dp}) + \dots + b_{p,n_p u}^i u_p(k-t_{dp}-n_p+1)$.

其中: p 为输入量个数; n_y 为输出的阶次; n_1, \dots, n_p 为输入量的阶次; t_{d1}, \dots, t_{dp} 为输入量的滞后

定义

$$y(k) = [y(k), y(k-1), \dots, y(k-n_y)]^T,$$

$$u(k) =$$

$$[u_1(k-t_{d1}+1), u_1(k-t_{d1}), \dots, u_1(k-t_{d1}-n_1+1), u_2(k-t_{d2}+1), u_2(k-t_{d2}), \dots, u_2(k-t_{d2}-n_2+1), \dots, u_p(k-t_{dp}+1), u_p(k-t_{dp}), \dots, u_p(k-t_{dp}-n_p+1)]^T,$$

$$z(k) = [y(k), u(k)], a_i = [a_0^i, a_1^i, \dots, a_{n_y}^i],$$

$$\beta = [b_{1,0}^i, b_{1,1}^i, \dots, b_{1,n_1}^i, \dots, b_{p,0}^i, b_{p,1}^i, \dots, b_{p,n_p}^i]$$

T-S 模型的第 i 条规则可表示为

R^i : If $z_1(k)$ is A_1^i and ... and $z_{n_y+n_1+\dots+n_p+p+1}(k)$ is $A_{n_y+n_1+\dots+n_p+p+1}^i$,

Then $y_i(k+1) = \alpha_i y(k) + \beta_i u(k)$.

对 T-S 模型后件参数进行如下归一化处理:

$$\xi_i = \frac{\sum_{j=1}^c w_i(z(k)) \alpha_j}{\sum_{j=1}^c w_i(z(k))}, \eta_i = \frac{\sum_{j=1}^c w_i(z(k)) \beta_j}{\sum_{j=1}^c w_i(z(k))}, \quad (15)$$

其中第 i 条规则的激励强度

$$w_i(z(k)) = \prod_{j=1}^{n_y+n_1+\dots+n_p+p+1} A_j^i(z_j(k)).$$

T-S 模型的输出为

$$y(k+1) = \frac{\sum_{i=1}^c w_i(z(k)) y_i(k+1)}{\sum_{i=1}^c w_i(z(k))}. \quad (16)$$

定义

$$X(k) = [x(k), x(k-1), \dots, x(k-n_y)]^T, \quad (17)$$

$$Y(k) = [x(k)], \quad (18)$$

从而得到如下非线性系统的 T-S 模型的线性时变状态空间描述:

$$\begin{cases} X(k+1) = A_k X(k) + B_k u(k), \\ Y(k) = C_k X(k). \end{cases} \quad (19)$$

其中

$$A_k = \begin{bmatrix} \xi_1 & \xi_2 & \dots & \xi_{n_y} & \xi_{n_y+1} \\ 1 & 0 & \dots & 0 & 0 \\ 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & & \vdots & \vdots \\ 0 & 0 & \dots & 1 & 0 \end{bmatrix}_{(n_y+1) \times (n_y+1)},$$

$$B_k = \begin{bmatrix} \eta_1 & \eta_2 & \dots & \eta_{n_1+\dots+n_p+p} \\ 0 & 0 & \dots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \dots & 0 \end{bmatrix}_{(n_y+1) \times (n_1+\dots+n_p+p)},$$

$$C_k = [1 \ 0 \ \dots \ 0]_{1 \times (n_y+1)}.$$

3 模糊预测控制

3.1 T-S 模型的多步线性化

文献[7]将采样时刻得到的线性模型作为整个预测时域的模型, 设计实现了单步线性化预测控制器, 但是对于多步超前控制而言, 会因模型误差较大而恶化控制性能 文献[8]提出的多步线性化模糊预测控制解决了模型误差问题, 但控制信号需要反复迭代求解, 加大了计算量

本文提出一种新的多步线性化预测控制策略, 既避免了模糊误差较大的问题, 又减小了计算量 首先利用单步线性化预测控制策略计算控制信号, 并将此控制信号作用于整个预测时域, 得到预测时域内的一组模型序列; 然后基于此模型序列重新计算最终的控制信号

3.2 T-S 模型的预测输出

为简单起见, 采用 $x(k+j/k)$ 表示在 k 时刻对 $k+j$ 时刻的输出预测值, 利用式(19)可以递归得到如下方程:

$$y(k+1/k) = C_{k+1} A_{k+1} x(k) + C_{k+1} B_{k+1} u(k),$$

$$y(k+2/k) =$$

$$\begin{aligned}
 & C_{k+1}A_{k+1}x(k) + C_{k+2}A_{k+2}B_k u(k) + \\
 & C_{k+3}B_{k+1}u(k+1), \\
 & \vdots \\
 & y(k+H_p/k) = \\
 & C_{k+1}A_{k+H_p-1} \dots A_k x(k) + C_{k+H_p}A_{k+H_p-1} \dots \\
 & A_{k+1}B_k u(k) + \dots + C_{k+H_p}A_{k+H_p-1} \dots \\
 & A_{k+H_c+1}B_{k+H_c}u(k+H_c). \tag{20}
 \end{aligned}$$

利用矩阵表示法, 式(20)可写成如下复合形

$$F = \begin{bmatrix} C_{k+1}B_k & 0 & \dots & 0 \\ C_{k+2}A_{k+1}B_k & C_{k+2}B_{k+1} & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ C_{k+H_p}A_{k+H_p-1} \dots A_{k+1}B_k & C_{k+H_p}A_{k+H_p-1} \dots A_{k+2}B_{k+1} & \dots & C_{k+H_p}A_{k+H_p-1} \dots A_{k+H_c+1}B_{k+H_c} \end{bmatrix}, \tag{22}$$

$$U = [u(k), u(k+1), \dots, u(k+H_c)]^T. \tag{23}$$

3.3 预测控制律计算

采用带约束的输出预测误差和控制增量加权的二次型性能指标

$$\begin{aligned}
 J &= \frac{1}{2} (Y_r - Y)^T Q (Y_r - Y) + \Delta U^T R \Delta U, \\
 \text{s.t. } & Y_{\min} \leq Y \leq Y_{\max}, U_{\min} \leq U \leq U_{\max}, \\
 & \Delta U_{\min} \leq \Delta U \leq \Delta U_{\max}. \tag{24}
 \end{aligned}$$

其中: Y_r 为系统参考轨迹; Y 为参考模型输出; ΔU 为

式:

$$Y = Gx(k) + FU. \tag{21}$$

其中

$$\begin{aligned}
 Y &= [y(k+1/k), y(k+2/k), \dots, \\
 & y(k+H_p/k)], \\
 G &= \begin{bmatrix} C_{k+1}A_k \\ C_{k+2}A_{k+1}A_k \\ \vdots \\ C_{k+H_p}A_{k+H_p-1} \dots A_k \end{bmatrix},
 \end{aligned}$$

控制增量; Q 和 R 为正定权重矩阵, 分别为系统输出误差和控制增量的权值; 目标函数的约束 Y_{\max} 和 Y_{\min} , ΔU_{\max} 和 ΔU_{\min} , U_{\max} 和 U_{\min} 分别为输出最大最小约束, 控制量增量最大最小约束, 控制量最大最小约束

式(24)性能指标函数与控制增量 ΔU 相关, 而不与控制量 U 相关, 因此预测输出表达式(21)应该修改为

$$Y = Gx(k) + F_1 \Delta U + F_2 u(k-1). \tag{25}$$

其中

$$F_1 = \begin{bmatrix} C_{k+1}B_k & 0 & \dots \\ C_{k+2}(A_{k+1}B_k + B_{k+1}) & C_{k+2}B_{k+1} & \dots \\ \vdots & \vdots & \vdots \\ C_{k+H_p} \left(\sum_{i=0}^{H_c} A_{k+H_p-1} \dots A_{k+i+1} B_{k+i} \right) & C_{k+H_p} \left(\sum_{i=1}^{H_c} A_{k+H_p-1} \dots A_{k+i+1} B_{k+i} \right) & \dots \\ 0 & 0 & \dots \\ 0 & 0 & \dots \\ C_{k+H_p-1} A_{k+H_p-2} \dots A_{k+H_c} B_{k+H_c-1} & 0 & \dots \\ C_{k+H_p} \left(\sum_{i=H_c-1}^{H_c} A_{k+H_p-1} \dots A_{k+i+1} B_{k+i} \right) & C_{k+H_p} A_{k+H_p-1} \dots A_{k+H_c+1} B_{k+H_c} \end{bmatrix}, \tag{26}$$

$$F_2 = \begin{bmatrix} C_{k+1}B_k \\ C_{k+2}(A_{k+1}B_k + B_{k+1}) \\ \vdots \\ C_{k+H_p} \left(\sum_{i=0}^{H_c} A_{k+H_p-1} \dots A_{k+i+1} B_{k+i} \right) \end{bmatrix}. \tag{27}$$

将式(27)和(26)代入(25), 可将非线性优化问题转化为线性二次规划问题, 从而易于在线求解控制律

$$\min_{\Delta U} J = \min \left(\frac{1}{2} \Delta U^T H \Delta U + T \Delta U \right),$$

$$\begin{aligned}
 \text{s.t. } & \begin{bmatrix} F_1 \\ -F_1 \\ I \\ -I \\ I \\ -I \end{bmatrix} \Delta U \leq \begin{bmatrix} Y_{\max} - Gx(k) - F_2 u(k-1) \\ -Y_{\min} + Gx(k) + F_2 u(k-1) \\ \Delta U_{\max} \\ -\Delta U_{\min} \\ U_{\max} - u(k-1) \\ -U_{\min} + u(k-1) \end{bmatrix}. \tag{28}
 \end{aligned}$$

其中: $H = 2(F_1^T Q F_1 + R)$, $T = 2(Gx(k) + F_2 u(k) - 1) - Y_r)^T Q F_1$.

4 仿 真

pH 控制是工业过程中典型的非线性控制系统, 本文对此进行建模和控制的仿真验证

$Q(k)$ 和 $pH(k)$ 表示在 k 时刻的碱流量和 pH 值, 利用 $Q(k)$ 和 $pH(k)$ 预测 $k + 1$ 时刻的 pH 值 辨识得到的 T-S 模型如下:

R_1 : If $Q(k)$ is A_1 and $pH(k)$ is B_1 ,

Then $pH(k + 1) =$

$$0.012 Q(k) + 0.901 2pH(k);$$

R_2 : If $Q(k)$ is A_2 and $pH(k)$ is B_2 ,

Then $pH(k + 1) =$

$$0.107 2Q(k) + 0.692 4pH(k);$$

R_3 : If $Q(k)$ is A_3 and $pH(k)$ is B_3 ,

Then $pH(k + 1) =$

$$0.138 Q(k) + 0.813 2pH(k);$$

R_4 : If $Q(k)$ is A_4 and $pH(k)$ is B_4 ,

Then $pH(k + 1) =$

$$0.077 2Q(k) + 0.915 7pH(k).$$

其中 A_i 和 $B_i (i = 1, 2, \dots, 4)$ 为隶属函数, 如图 1 所示

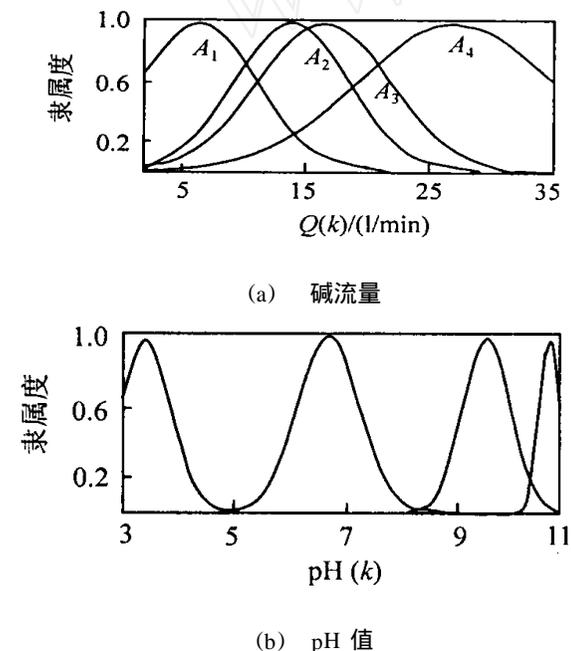


图 1 pH 中和过程的 T-S 模型隶属度函数

将校验数据代入辨识得到的 T-S 模型, 计算得到建模均方误差为 0.334 7. 图 2 给出了模型输出与测量输出的直观比较 可见 T-S 模型较好地拟合了 pH 中和过程

模糊模型预测控制器的参数如下: 预测步长为 4, 控制步长为 2, 输出误差权重为 1, 控制增量权重为 0.2, 输出最大值为 12, 输出最小值为 0, 输入量变

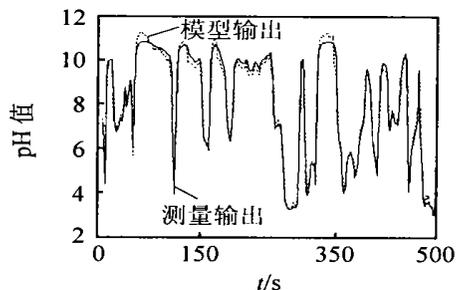


图 2 T-S 模型输出与实际测量输出比较
化最大值为 2, 输入量变化最小值为 - 2, 参考轨迹为方波信号.

为便于比较, 本文同时设计了 PD 控制器来实现 pH 中和过程的控制 PD 控制器的参数为: 比例系数为 6, 积分系数为 0.3, 微分系数为 0.01.

图 3 给出了采用上述参数的模糊预测控制和 PD 控制的结果 可以看出, 模糊预测控制能够很好地实现 pH 中和过程的控制, 而 PID 控制过渡时间长, 且出现了振荡

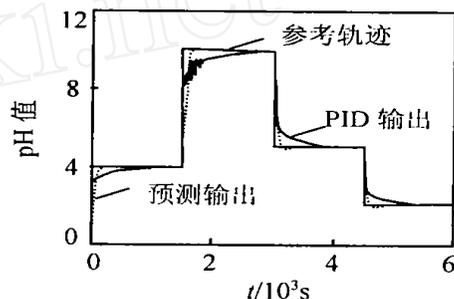


图 3 模糊预测控制与 PD 控制比较

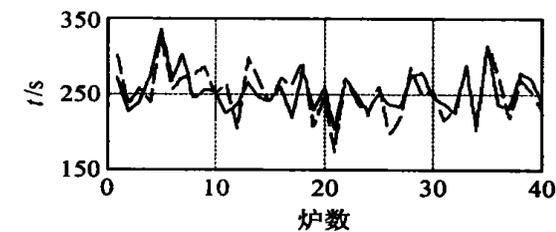
5 结 论

本文提出一种新的基于 T-S 模型多步线性化的模糊预测控制策略 采用模糊聚类算法离线辨识 T-S 模型, 采用带遗忘因子的递推最小二乘法选择性在线学习模型参数; 在每个采样时刻线性化 T-S 模型, 将 T-S 模型表示的非线性系统等价为线性时变状态空间模型, 并将约束非线性优化问题转化为线性二次规划问题 从而解决了非线性预测控制中如何获取非线性模型以及如何进行在线优化两个难题 pH 中和过程的仿真验证了该方法的有效性

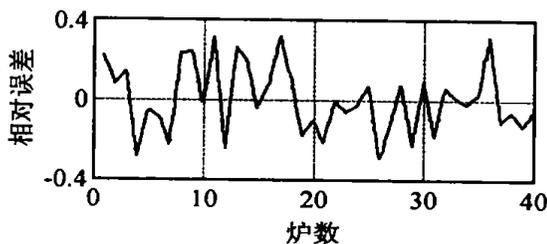
参考文献 (References)

[1] 席裕庚 预测控制[M]. 北京: 国防出版社, 1993
 [2] Henson M. A. Nonlinear model predictive control: Current status and future directions[J]. Computers and Chemical Engineering, 1998, 23(2): 187-202
 [3] Sarimveis H, Bafas G. Fuzzy model predictive control of non-linear processes using genetic algorithms[J]. Fuzzy Sets and Systems, 2003, 139(1): 59-80

(下转第 504 页)

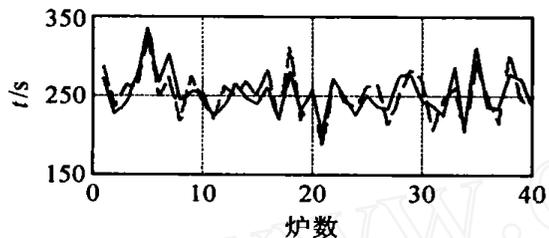


(a) 预测吹氧时间

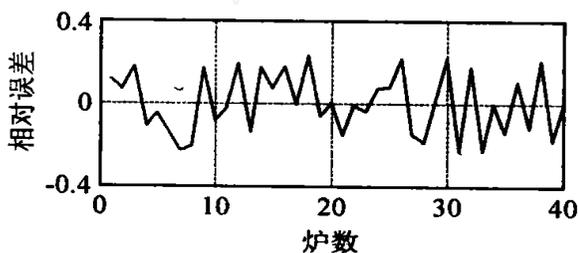


(b) 预测值相对误差

图2 RBF模型吹氧时间输出及误差



(a) 预测吹氧时间



(b) 预测值相对误差

图3 优化RBF模型吹氧时间输出及误差

7 结论

本文提出了一种基于模拟退火的并行粒子群优化算法。该算法针对PSO算法可能出现的停滞现象,引入了基于模拟退火机制和并行计算方法。理论

和实践证明,模拟退火并行粒子群RBF算法可以对提钒过程进行及时识别和控制,对钢铁提钒处理生产过程具有指导作用。应当指出,在粒子群参数选择、退火温度确定、并行任务分解这几方面的处理还有不完善之处,尚需改进,以提高网络得到全局最优解的概率。

参考文献(References)

- [1] 谢晓锋,张文俊,杨之廉. 微粒群算法综述[J]. *控制与决策*, 2003, 18(2): 129-134
(Xie X F, Zhang W J, Yang Z L. Overview of particle swarm optimization[J]. *Control and Decision*, 2003, 18(2): 129-134.)
- [2] Shi Y, Eberhart R. A modified particle swarm optimizer[A]. *Proc IEEE Int'l Conf on Evolutionary Computation* [C]. Anchorage: IEEE Press, 1998: 69-73.
- [3] Shi Y, Eberhart R. Fuzzy adaptive particle swarm optimization [A]. *IEEE World Congress on Evolutionary Computation*[C]. Seoul, 2001: 101-106.
- [4] 吕振肃,侯志荣. 自适应变异的粒子群优化算法[J]. *电子学报*, 2004, 32(3): 416-420
(Lv Z S, Hou Z R. Particle swarm optimization with adaptive mutation [J]. *Acta Electronica Sinica*, 2004, 32(3): 416-420.)
- [5] Fan den Bergh, Engelbrecht A P. Cooperative learning in neural networks using particle swarm optimizations [J]. *South African Computer J*, 2000, 26(11): 84-90.
- [6] Onbasoglu E, Ozdamar L. Parallel simulated annealing algorithms in global optimization [J]. *J of Global Optimization*, 2001, 19(1): 27-50.
- [7] Mitsunori M K, Tomoyuki H, Toshihiko F. Parallel simulated annealing with adaptive neighborhood determined by GA [A]. *Proc IEEE Int'l Conf Syst Man Cybern* [C]. Washington: Institute of Electrical and Electronics Engineers Inc, 2003: 26-31.
- [8] Robert J S, James J C, Ahmad F A. Approximation of nonlinear systems with radial basis function neural networks[J]. *IEEE Trans Neural Networks*, 2001, 19(4): 1-14.

(上接第499页)

- [4] Huang Y L, Lou H H, Gong J P, et al. Fuzzy model predictive control[J]. *IEEE Trans on Fuzzy Systems*, 2000, 8(6): 665-678.
- [5] Abonyi J, Nagy L, Szeifert F. Fuzzy model-based predictive control by instantaneous linearization [J]. *Fuzzy Sets and Systems*, 2001, 120(1): 109-122.
- [6] Gustafson D, Kessel W. Fuzzy clustering with a fuzzy covariance matrix[A]. *Proc of IEEE Conf on Decision*

and Control[C]. San Diego, 1979: 761-766.

- [7] Fischer M, Nelles O, Iseemann R. Predictive control based on local linear fuzzy models[J]. *Int J System Science*, 1998, 29(7): 797-815.
- [8] Roubos J A, Molloy S, Babuka R, et al. Fuzzy model-based predictive control using Takagi-Sugeno models [J]. *Int J Approximate Reasoning*, 1999, 22(1-2): 3-30.