

# 面向窑压控制的基于改进 STS 模型的非线性广义预测控制研究

曹政才<sup>1</sup>, 赵 琪<sup>1</sup>, 雷世昌<sup>1,\*</sup>, 刘 民<sup>2</sup>

(1. 北京化工大学信息科学与技术学院, 北京 100029; 2. 清华大学自动化系, 北京 100084)

**摘 要:** 窑压是玻璃窑炉运行过程中重要的被控指标之一, 由于受到大量不确定因素影响, 现有控制算法的跟踪超调大且波动频繁. 鉴于简化 T-S 模型(STS)的强在线自适应学习能力和减法聚类可以解决最优模型结构的不稳定问题, 本文研究一种基于减法聚类与简化 T-S 模型相融合的非线性模糊广义预测方法实现窑压的控制. 利用该方法可以快速的完成窑压跳变后对象的逼近, 克服由于跳变所引起的系统不稳定现象; 在改进的 STS 模型的基础上, 针对窑压阶跃跟踪超调过大的问题, 结合整体最优滚动优化函数及最优控制增量快速求解方法设计控制律, 从本源出发抑制超调, 计算量小, 并易于实施.

**关键词:** 窑压控制; 简化 T-S 模型; 快速广义预测控制; 超调抑制

**中图分类号:** TN911. 23      **文献标识码:** A      **文章编号:** 0372-2112 (2017)07-1576-08

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2017.07.005

## An Improved STS Model Based Nonlinear GPC Method Orienting with Furnace Pressure Control

CAO Zheng-cai<sup>1</sup>, ZHAO Qi<sup>1</sup>, LEI Shi-chang<sup>1,\*</sup>, LIU Min<sup>2</sup>

(1. College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China;

2. Department of Automation, Tsinghua University, Beijing 100084, China)

**Abstract:** Furnace pressure is one of the important variable to be controlled in the process of glass furnace operation. Owing to the influence of a large number of uncertainties, existent control algorithms tend to produce overshooting and frequent fluctuation in follow-up. Considering that simplified T-S model (STS) has a strong self-adaptive learning capability and subtractive clustering is able to handle the unsteadiness in the optimal model structure, this paper proposes, for the purpose of furnace pressure control, a generalized fuzzy nonlinear prediction approach by combining subtractive clustering and STS. This approach allows a quick approximation of the object following jumps of furnace pressure and may eliminate system unsteadiness caused by jumps. Additionally, in respect of excessive overshooting in furnace pressure step following-up, a control method is designed based on the improved STS model and integrating global optimal rolling optimization function with optimal control increment algorithm so that overshooting is restrained essentially. This approach involves little computation work and is easy to implement.

**Key words:** furnace pressure control, simplified T-S model, fast generalized predictive control, overshoot suppression

## 1 引言

窑压控制对玻璃窑炉的正常运作有重要影响, 同时也是节能、环保的关键环节. 生产中通过调节闸板①的开度来限制烟道②中的烟气流量, 以控制窑压(图 1

中虚线粗箭头为助燃风走向, 实线粗箭头为烟气走向). 窑压控制要求快跟踪、小超调及微正压( $5 \pm 0.5$ pa). 由于窑炉内部结构复杂、环境恶劣( $1550^\circ\text{C}$ ), 受燃烧温度、燃料特性、原理特性、火焰分布、玻璃液位及大气压等众多不确定性因素的影响, 窑压具有强非

收稿日期: 2015-04-23; 修回日期: 2015-12-30; 责任编辑: 郭游

基金项目: 国家自然科学基金(No. 51375038); 高等学校博士学科点专项科研基金博导类(No. 20130010110009); 吉林大学符号计算与知识工程教育部重点实验室开放课题(No. 93K172014K05)

线性特性;窑炉通常具有固定的换向周期(20min),换向期间各参数都发生剧烈变化;据经验观察可知,在不同侧小炉运行时,窑压特性具有不同的特性.窑压是一个参数不确定的复杂非线性系统,要完成窑压对象的建模及优良控制有很大难度.长期以来,针对窑炉热工对象的控制研究多集中在窑温先进控制策略上,作为辅助控制的窑压控制研究却滞后.薄迎春<sup>[1]</sup>等针对浮法窑炉温度控制问题,提出一种启发式动态规划控制方法,该方法通过策略评价及策略提升的重复进行逐渐逼近最优的控制策略,有较强的工况适应能力;Wang<sup>[2]</sup>设计窑温模糊自整定 PID 控制策略,在浮法窑炉上进行成功应用;吴志伟<sup>[3]</sup>提出基于案例推理、迭代学习、神经网络和规则推理的窑炉参数混合智能设定方法;文献[4]针对浮法窑炉设计窑压线性前馈反馈控制.在实际生产中,窑压控制大量使用 PID 控制,超调过大且波动频繁,对窑炉寿命及产品质量有不良影响,可见针对窑炉压力的建模与先进控制研究还是工程上热点问题,袁学海<sup>[5]</sup>通过对单输入-单输出模糊系统的构造和所构造的模糊系统的逼近能力进行研究,给出余项表达式和估计公式.模糊广义预测控制(FGPC)利用 T-S 模型对非线性系统进行分片线性化,能较好的处理非线性系统建模与控制问题. Beschi<sup>[6]</sup>提出一种基于太阳炉的 GPC 控制方法,获得很好的效果,钱富才<sup>[7]</sup>提出一种能通过输入输出数据在线获得 T-S 模型的结构和参数的辨识算法,并将其应用到非线性动态系统和煤气炉中;由于 T-S 模型建模不稳定,易得出局部最优模型,且模型的在线修正慢,学习能力有先天不足,GPC 计算复杂存在跟踪超调效应,导致 FGPC 在处理类似窑压等参数不确定非线性系统的控制问题上能力有限.

综合考虑窑压复杂非线性特性、参数不确定性以及控制超调缺陷,本文研究基于改进 STS 模型的 NFG-PC 方法<sup>[8]</sup>来解决窑压控制问题. STS 模型<sup>[9]</sup>是一类本质在线型模糊建模方法,建模及模型修正同时在线进行,仅依靠对当前数据进行多次学习就能对非线性系统不确定参数进行快速逼近,且 STS 模型具有线性多项式规则后件,容易进行控制设计;但 STS 模型无法辨识模型结构,且其权值自适应机制容易导致模型学习失配.本文利用减法聚类及权值自适应修正机制停止阈

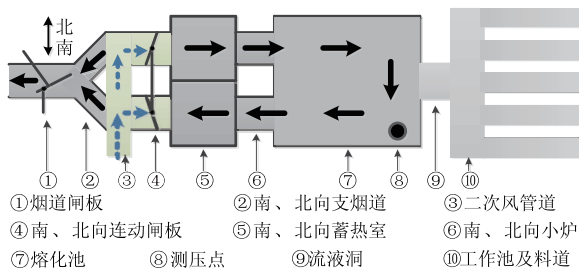


图1 马蹄焰玻璃窑炉平面简图

值对 STS 模型加以改进,在改进 STS 模型的基础上设计无超调快速广义预测控制律.仿真实验表明,改进 STS 模糊建模方法对参数不确定被控对象具备强自适应学习能力,NFGPC 对参数跳变非线性系统具有较好的控制效果.

## 2 改进 STS 模型构建基本思想

STS 模型构建主要由两大部分构成: STS 模型结构辨识以及 STS 模型参数辨识.模型结构由人工经验确定,具有一定盲目性;参数辨识过程零阈值限制,容易在被逼近对象发生跳变时的引发建模不稳定现象.改进 STS 模型结构由减法聚类依据历史数据分布来确定,主要有聚类数目以及聚类中心初值.参数辨识分为模糊规则前件参数自适应辨识与模糊规则后件递推辨识,该自适应辨识过程在线进行,其流程图如图 2 所示:

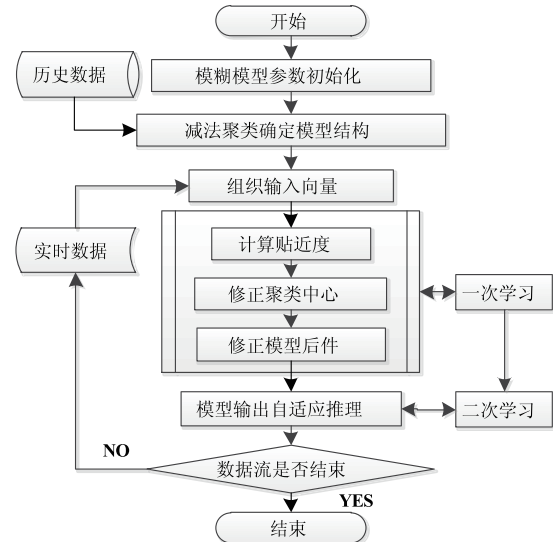


图2 改进STS模型建模流程图

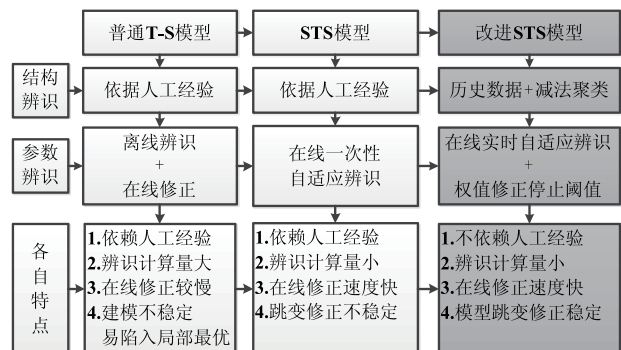


图3 改进STS模型与其他模糊模型的对比图

图3 给出改进 STS 模型相对于 STS 模型及普通 T-S 模型的区别,可以看到构建新模型更加智能,具有计算量小,在线学习能力强,模型修正稳定等优势.

## 2.1 改进 STS 模型结构辨识

改进 STS 模型用减法聚类依据大量历史数据确定规则数目及聚类中心初值,以周围点密度  $D_i$  为基准,提高 T-S 模型的智能化程度,保证聚类的最优稳定性。

假设从某系统获取  $n$  个数据点,其中点  $x_i$  为  $m \times 1$  维向量 ( $i=1,2,\dots,n$ ),定义点  $x_i$  周围的点密度公式如式所示:

$$D_i = \sum_{j=1}^n \exp\left[-\frac{\|x_i - x_j\|^2}{\left(\frac{\gamma_a}{2}\right)^2}\right] \quad (1)$$

$\gamma_a$  为点密度半径,定义点  $x_i$  的邻域,半径以外的数据点对  $D_i$  影响较小.通过对比每个点所属的密度值,选择具有最高密度指标的点作为第一个聚类中心,记为  $x_{c1}$ ,  $D_{c1}$  为该点对应的周围密度指标,并用式进行修正:

$$D_i = D_i - D_{c1} \exp\left[-\frac{\|x_i - x_{c1}\|^2}{\left(\frac{\gamma_b}{2}\right)^2}\right] \quad (2)$$

通常取  $\gamma_b = 1.5\gamma_a$ ,它定义一个周围密度指标明显较小的邻域,以避免出现相近聚类。

接下来进行下一个聚类中心  $x_{c2}$  的选择,然后修正第二个点的密度指标,针对历史数据重复进行上述过程,直到满足  $\left(\frac{D_{c,K}}{D_{c1}}\right) \leq \delta$  ( $\delta \leq 1$  为减法聚类停止阈值),得到  $K$  个初始聚类中心以及相应个数的模糊规则。

## 2.2 改进 STS 模型参数辨识

假定由减法聚类获得  $K$  条规则及相应的聚类中心初值  $x_{ci}$ ,设计改进 STS 模型的规则可以表示为式:

$$\text{if } x \in (c_i, r_i) \text{ then } y_i = \theta_i^T Z \quad (i=1,2,\dots,K) \quad (3)$$

其中  $x$  是模糊规则的  $m$  维输入向量;  $c_i$  代表第  $i$  条规则的规则中心,令规则中心的初值等于  $x_{ci}$ ;  $r_i$  为对应规则中心的实力半径,表征与第  $i$  条规则有关的范围;  $Z = [1 \ x]^T$  为模糊规则后件变量,  $\theta_i^T$  为模糊规则后件多项式,那么该非线性系统的模糊推理输出可由式计算:

$$y = \frac{\sum_{i=1}^K w_i (\theta_i^T Z)}{\sum_{i=1}^K w_i} \quad (4)$$

其中  $w_i$  为第  $i$  条规则对应的权系数,计算如式

$$w_i = \begin{cases} 0, & \text{if } \|x - c_i\| > r_i \\ 1 - \frac{\|x - c_i\|}{r_i}, & \text{if } \|x - c_i\| \leq r_i \end{cases} \quad (5)$$

与一般 T-S 模型建模“离线训练 + 在线修正”模式不同的是,STS 模型没有离线监督学习过程,直接根据当前数据对模型进行修正. STS 模型参数辨识及在线预测过程如下:

①利用历史数据通过减法聚类确定模型结构与初

值——模糊规则数目及规则中心初值。

②直接进入在线模型,接收当前输入向量  $x(k)$ ,计算当前数据点与各已知规则中心的贴近度。

$$S_{ik} = S(x(k), c_i) = e^{-\alpha \|x_k - c_i\|} \quad (6)$$

$S_{ik}$  为输入向量  $x(k)$  对规则中心  $c_i$  的贴近度,  $\alpha$  为贴近度修正系数。

③在得到贴近度之后,开始依据式逐个修正 STS 模型规则中心。

$$c_i(k+1) = c_i(k) + \eta_i S_{ik} [x_k - c_i(k)] \quad (7)$$

$\eta_i$  为规则中心修正系数。

④实力半径局部修正

$$\begin{cases} r_i(k+1) = \|x_k - c_i\|, & \|x_k - c_i\| \geq r_i(k) \\ r_i(k+1) = r_i(k), & \|x_k - c_i\| \leq r_i(k) \end{cases} \quad (8)$$

可见,当  $x(k)$  脱离  $c_i$  的实力半径  $r_i(k)$  时,系统具备自动修正实力半径的能力。

⑤规则后件局部修正

为了在不改变 STS 模型所获得的非线性系统全局特性的前提下增强系统的局部动态学习能力,STS 模型使用带有变遗忘因子的局部渐进最小二乘法对规则后件进行调整。

当  $\|x_k - c_i\| \geq r_i(k)$  时:

$$\begin{cases} P_i(k+1) = \frac{1}{\lambda_i(k)} \left\{ P_i(k) - \frac{P_i(k) z(k) z(k)^T P_i(k)}{\lambda_i(k) + z(k)^T P_i(k) z(k)} \right\} \\ \theta_i(k+1) = \theta_i(k) + P_i(k+1) \{ y(k) - z(k)^T \theta_i(k) \} z(k) \end{cases} \quad (9)$$

否则

$$\begin{cases} P_i(k+1) = P_i(k) \\ \theta_i(k+1) = \theta_i(k) \end{cases} \quad (10)$$

$P_i$  为最小二乘矩阵参数,一般取  $P_i(0) = \varepsilon I$ ,  $\varepsilon$  为一个较大的正常数.  $\lambda_i(k)$  为渐进遗忘因子,  $\lambda_0$  为其初值,由式进行递推计算:

$$\lambda_i(k) = \lambda_0 \lambda_i(k-1) + 1 - \lambda_0 \quad (11)$$

⑥基于改进自适应修正机制的在线预报

从第②到第⑤步的过程中,STS 模型充分吸收了当前输入向量所代表的系统特性,当模糊模型接收到下一时刻的输入量  $x(k+1)$  时,则可以通过式对下一时刻的系统输出进行预测计算. 这里可能会出现这样一种现象:由于规则中心与实力半径不断在进行自适应修正,根据式计算的权系数很有可能出现  $\sum w_i = 0$  的情形,系统输出为 0,各类计算失去意义,有必要在这种情况下对各规则中心的实力半径进行再拓展,权系数  $w_i$  的自适应求解方法应运而生. 权系数  $w_i$  自适应调整机制如下所示:

Step1: 判断  $\sum w_i = 0$  是否成立,如果是,启用自适

应修正机制,进入 step2,如果不是,则不进入修正机制。

Step2:记自适应修正操作次数  $k_1 = 1$ ,令自适应修正半径初值  $R_i(0)$  按式进行赋值。

$$R_i(0) = r_i, (i = 1, 2, \dots, K) \quad (12)$$

Step3:按式进行半径自适应修正

$$R_i(k_1) = R_i(k_1 - 1) + \eta_2 r_i \quad (13)$$

其中  $\eta_2$  为自适应修正步长系数,与  $r_i$  共同确定每次某聚类中心实力半径的拓展范围。

Step4:重新计算各权系数的值

$$w_i(k) = \begin{cases} 0, & \text{if } \|x - c_i\| > R_i(k) \\ 1 - \|x - c_i\|/R_i(k), & \text{if } \|x - c_i\| \leq R_i(k) \end{cases} \quad (14)$$

当  $\sum w_i(k) \geq W_{lower}$ ,则  $k_1 = k_1 + 1$ ,跳转到 step3,否则退出循环,其中  $W_{lower}$  为权值自适应机制停止阈值。当前数据点被某拓展的实力半径所包含时,就可以停止自适应修正。设置权值自适应修正机制停止阈值,该阈值能够保证 STS 模型在系统状态跳变时在线修正的稳定性。

Step5:权系数与自适应半径修正更新

$$w_i = w_i(k), r_i = R_i(k) \quad (15)$$

### 3 基于改进 STS 模型的广义预测控制

本文提出用改进 STS 模型来强化广义预测控制预测模型的在线自适应能力,将窑压对象参数跳变对控制系统的影响降到最小。从预测控制原理的角度出发,通过更新设计无超调滚动优化目标函数,引入广义预测控制快速计算方法,设计一种多步预测单步控制的无超调快速广义预测控制。

#### 3.1 基于改进 STS 模糊建模的预测模型

受控自回归滑动平均(CARIMA)模型是常见的 GPC 模型,其表达形式如下:

$$A(z^{-1})y(k) = B(z^{-1})u(k-1) + \frac{C(z^{-1})\xi(k)}{\Delta} \quad (16)$$

式中  $y(k), u(k), \xi(k)$  分别为被控对象的输出、控制输入及噪声序列,  $z^{-1}$  为后移算子,  $\Delta = 1 - z^{-1}$  为差分算子。  $A(z^{-1}), B(z^{-1}), C(z^{-1})$  如式所示,为差分多项式,实际执行时一般取  $C(z^{-1}) = 1$ 。

$$A(z^{-1}) = 1 + a_1 z^{-1} + \dots + a_n z^{-n} \quad (17)$$

$$B(z^{-1}) = b_0 + b_1 z^{-1} + \dots + b_{n_b} z^{-n_b}$$

其中  $n_a, n_b$  为差分多项式的阶次,令  $\bar{A} = -[a_1 \dots a_n]$ :  $x = [y(k-1), \dots, y(k-n_a), u(k-d), \dots, u(k-d-n_b+1)]^T$  其中  $d$  代表系统时滞,则 CARIMA 模型可写成:

$$y(k) = [\bar{A} \ B]x + \xi(k) \quad (18)$$

结合 STS 模型输出式,令同一变量的对应系数相等,可知 CARIMA 模型各系数表达式如下:

$$\begin{cases} a_l(k+1) = -\frac{\sum_{j=1}^K w_j \theta_{k+1,j}(l+1)}{\sum_{j=1}^K w_j}, 1 \leq l \leq n_a \\ b_{m-1}(k+1) = \frac{\sum_{j=1}^K w_j \theta_{k+1,j}(n_a+1+m)}{\sum_{j=1}^K w_j}, 1 \leq m \leq n_b + 1 \end{cases} \quad (19)$$

其中  $\theta_{k+1,j}(l+1)$  代表第  $j$  个模型后件在第  $k+1$  时刻的第  $l+1$  个元素的值。

#### 3.2 滚动优化设计

假定工业控制过程设定值为常值  $y_{sp}$ ,为了使当前时刻的输出  $y(k)$  按一定速度平滑过度到设定值,通常用一阶过程如式获取柔化参考轨迹。

$$\begin{cases} y_r(k) = y(k) \\ y_r(k+j) = \beta^j y(k) + (1-\beta^j) y_{sp} \end{cases} \quad (20)$$

其中  $y_r$  为柔化轨迹,  $\beta(0 \leq \beta \leq 1)$  为柔化因子。

为了计算系统未来输出,引入丢番图方程。

$$\begin{cases} 1 = E_j(z^{-1})A(z^{-1})\Delta + z^{-j}F_j(z^{-1}) \\ E_j(z^{-1})B(z^{-1}) = G_j(z^{-1}) + z^{-j}H_j(z^{-1}) \end{cases} \quad (21)$$

$E_j, F_j, H_j, G_j$  为差分方程多项式,具体表达式及递推求解过程见文献[10]。为了书写方便,本文后期将符号  $z^{-1}$  略写,如  $E_j(z^{-1}) = E_j$ ,在式两侧同时乘以  $E_j \Delta$ ,忽略不可知的未来噪声信号,可以得到系统未来时刻输出估计为:

$$\hat{y}(k+j) = E_j B \Delta u(k+j-1) + F_j y(k) \quad (22)$$

进一步整理式,  $j$  步导前最优输出预测为:

$$\hat{y}(k+j) = G_j \Delta u(k+j-1) + f_j \quad (23)$$

其中  $f_j = H_j \Delta u(k-1) + F_j y(k)$ ,可以观察到上式右侧第一项只与未来的输出增量有关,第二项只与系统过去的信息有关,将未来  $j$  步的预测信息如式写成向量形式:

$$\hat{Y} = G \Delta U + f \quad (24)$$

其中

$$f = [f_1 \dots f_j]^T$$

$$G = [G_1^T \dots G_j^T]^T$$

$$\hat{Y} = [\hat{y}(k+1) \dots \hat{y}(k+j)]^T$$

$$\Delta U = [\Delta u(k+1) \dots \Delta u(k+N_u-1)]$$

为 NFGPC 设计一种整体性能优化目标函数,如式所示:

$$\begin{aligned} J = & \sum_{j=1}^{N_p} [\hat{y}(k+j) - y_r(k+j)]^2 \\ & + \sum_{j=1}^{N_u} \tau(j) [\Delta u(k+j-1)]^2 \\ & + [\hat{y}(k+2) - \hat{y}(k+1)]^2 \end{aligned} \quad (25)$$

其中  $N_p, N_u$  分别为预测时域与控制时域,  $\tau$  为控制增量权值. 该目标函数不仅考虑预测输出误差方差与控制增量方差的最小化, 还将未来时刻输出增量方程最小化考虑在内. 对该目标函数求最优化输出有一石三鸟的功效, 即在抑制超调的前提条件下, 通过最小化的控制增量波动, 实现系统输出的快跟踪, 从本源的角度保证控制性能的提升, 进一步将式写成向量形式.

$$J = (Y - Y_r)^T (Y - Y_r) + \Delta U^T \tau \Delta U + [y(k+2) - y(k+1)]^2 \quad (26)$$

通过对新型加权二次型性能指标求最小值, 可以得出系统的最优控制律为

$$\Delta U = \Phi^{-1} [G(Y_r - F_2 \Delta U(k-j) + f) - M] \quad (27)$$

其中

$$\begin{cases} \Phi = G^T G + \tau I + G_{2-1}^T G_{2-1} \\ M = [H_{2-1} \Delta U(k-j) + G_{2-1} Y(k-j)] G_{2-1} \end{cases}$$

$G_{2-1}, H_{2-1}$  代表该矩阵的第二行减去第一行所组成的向量, 可见  $M$  即为优化函数新增项所得到的超调抑制修正项, 最终当前最优控制输出为

$$\begin{aligned} u(k) &= u(k-1) + du(k) \\ &= u(k-1) + \Delta U(1) \end{aligned} \quad (28)$$

### 3.3 快速 GPC 控制设计

GPC 在求解最优控制量时需要对矩阵进行求逆运算, 计算量大, 不利于窑压控制在线计算, 在优化目标函数加入新元素后更是如此, 而且存在计算信息浪费. 为了减小计算量, 借鉴文献[11], 引入柔化系统输入的方法, 令柔化向量为:

$$L = [1, 0, \dots, 0]^T \quad (29)$$

控制输入为:

$$\Delta U = \Delta u(k) L \quad (30)$$

将式代入式, 在  $J$  函数内对  $\Delta u(k)$  变量求导即可得一步最优控制量, 最优控制量的表达式为:

$$\Delta u(k) = \frac{(F_1 - F_2)}{F_3} \quad (31)$$

其中:

$$\begin{aligned} F_1 &= (GL)^T [Y_r - H \Delta U(k-j) - f] \\ F_2 &= [H_{2-1} \Delta U(k-j) + F_{2-1} Y(k-j)] G_{2-1} - L \\ F_3 &= [(GL)^T (GL) + (G_{2-1} L)^2 + \tau] \end{aligned}$$

$F, H, G$  为解多步丢番图方程得到多项式矩阵,  $F_{2-1}$  代表  $F$  矩阵的第一行减去第二行所得到的向量,  $H_{2-1}, G_{2-1}$  意义类同. 至此, NFGPC 方法设计完毕, 整体算法流程图如图 4 所示, 其中左侧建模, 右侧控制. 以窑压为例, 先从历史数据库中调用部分数据, 经过减法聚类确定模型结构初值, 随即转为模型参数在线辨识阶段, 建模的详细步骤信息可参考图 2. 当辨识阶段结束后, 可以随时切换进入 NFGPC 控制阶段. 从整体流程图来看,

NFGPC 大部分过程均处于在线阶段, 实际应用非常方便.

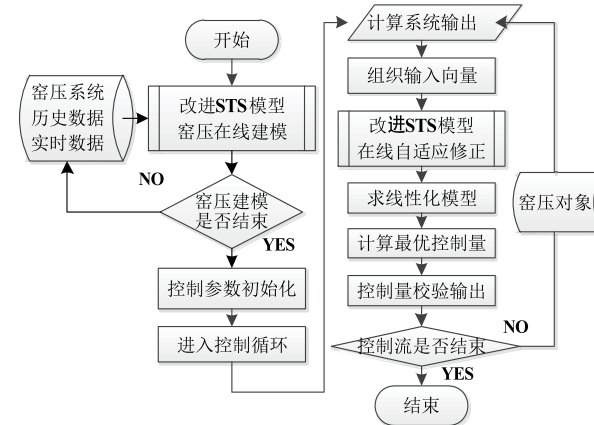


图4 NFGPC算法流程图

## 4 计算实例

本文用两个实例来分别验证 STS 模糊建模的有效性以及 NFGPC 控制有效性, 系统辨识与仿真所使用的平台为 Matlab 2010b for Windows.

### 4.1 窑压 STS 模型辨识实例

以广东某瓶罐玻璃生产马蹄焰窑炉为例(窑炉结构可参见图 1, 窑压控制系统的控制量与被控量分别为烟道闸板开度和窑炉压力. 从窑压 DCS 控制系统数据库中采集 1000 组窑压以及闸板开度数据, 利用改进 STS 模型对其进行建模可行性验证.

假定窑压可以由非线性函数表示.

$$y(k) = f(y(k-1)y(k-2), u(k-1), u(k-2)) \quad (32)$$

改进 STS 模型在第  $k$  时刻输入向量  $x_k$  如式

$$x_k = [y(k-1), y(k-2), u(k-1), u(k-2)]^T \quad (33)$$

将 1000 数据按照式进行整理. 前 500 组数据经过减法聚类数据处理, 令  $\gamma_a = 0.4$ , 可得规则数为 3, 聚类中心初始值如表 1 所示, 三个规则中心的初值分布均衡, 具有全局代表性, 优于随机选取的初始聚类中心. 由于运行 NFGPC 需要确定较多参数, 本文将其列于表 2 之中.

表 1 subFCM 聚类中心

聚类中心	1	2	3
$y(k-1)$	8.7001	7.8678	7.7143
$y(k-2)$	8.4792	7.8067	7.8867
$u(k-1)$	38.6558	34.5174	30.6395
$u(k-2)$	38.6904	34.5139	30.6385

表 2 NFGPC 各部分参数设置

符号	数值	符号	数值	符号	数值
$\varepsilon$	100000	$\eta_2$	0.5	$Nu$	2
$\alpha$	10	$\lambda_0$	0.9	$\beta$	0.5
$\eta_1$	1	$Np$	6	$\tau$	0.5
$\gamma_a$	0.4	$W_{lower}$	0.1		

图 5 为改进 STS 模型依据表 1 规则中心初值,针对后 500 组历史数据进行的一次在线自适应快速建模所得的预测输出结果,上图为实际曲线与预测曲线,下图为误差曲线.初始时刻 STS 模型仅仅具有聚类中心信息以及聚类规则数目,对未来时刻的预测误差很大,但经过 10 步(左侧黑色框线)的自适应调整,模型预测误差快速收敛到一个很小的范围内.当系统输出有较大波动时(图中右侧黑色框线所示,换向干扰),本文模型进行快速自适应调整,在缺乏换向强干扰先验信息的情况下,对系统输出进行有效的趋势预测.图 6 中显示了 STS 模型实力半径自适应调整趋势图.




图 5 STS模型离线训练预测效果图

按照与本文模型同样结构(规则数目 3,输入向量长度 4)设计一普通 T-S 模型,前 500 组数据进行模型离线迭代训练,隶属度满足  $\|u_{max}^{n+1} - u_{max}^n\| \leq 10^{-6}$  或训练周期数超过 1000 时,结束训练,后 500 组数据在线预测.

图 7 为本文模型对后 500 组数据预测误差分布统计,图 8 为 T-S 模型的预测误差的分布统计.等宽度实线框内,图 7 误差分布明显比图 8 更加集中更加靠近于 0,实线框外图 7 误差分布比图 8 更少.由上可知,本文模型以更小的计算量对窑压进行有效的模糊建模,具有非常强的在线学习能力,较普通 T-S 模型具有更高的建模精度.




图 6 STS模型实力半径变化趋势图

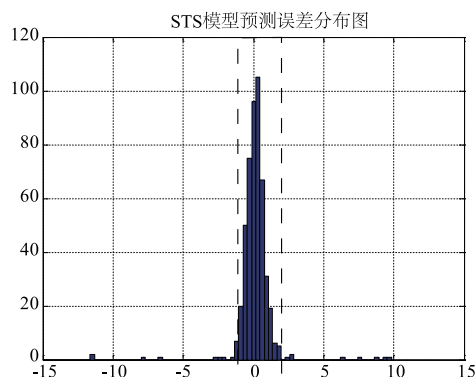


图 7 STS模型预测误差分布统计图

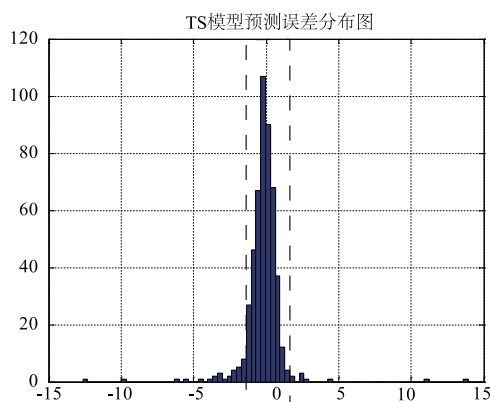


图 8 普通 T-S 模型预测误差分布统计图

#### 4.2 参数不确定非线性系统控制仿真实例

以某开环稳定参数不确定非线性系统式模拟窑压对象,其中  $y(k)$ ,  $u(k)$  为系统的输入输出信号,  $\xi(k)$  为分布在  $\pm 0.3$  之间白噪声信号,在  $k = 240$  时,被控对象从状态  $a$  跳变到  $b$ ,模拟换向过程参数跳变.控制仿真长度为 400,设定跟踪值为在 5 与 10 之间跳动的方波信号,周期 200,控制参数见表 2,并且仅利用状态  $a$  的数据训练本文模型以及普通 T-S 模型.

$$\begin{cases} a. y(k) = \frac{5y(k-1)y(k-2)u(k-1)}{1 + u(k-1)^2 + y(k-1)^2 + y(k-2)^2} \\ \quad + u(k-1) + 0.3u(k-2) + \xi(k) \\ b. y(k) = \frac{5y(k-1)y(k-2)}{1 + y(k-1)^2 + y(k-2)^2} \\ \quad + u(k-1) + 0.3u(k-2) + \xi(k) \end{cases} \quad (34)$$

NFGPC 控制仿真效果如图 9 所示, 同样设置下, FGPC 控制效果如图 10 所示. 对比图 9、图 10 中  $y(k)$  及  $e(k)$  曲线可知, NFGPC 在控制跟踪速度, 控制精度上比 FGPC 具有了很大改进. 在图中  $k = 100, 200$  时, NFGPC 阶跃跟踪效果比 FGPC 更快且无超调, 这说明 NFGPC 能够更好的应对系统工作点发生变化导致的模型变化; 当  $k = 240$  时系统发生跳变, 本文模型通过快速自适应在线学习掌握系统发生跳变之后的特性, 使 NFGPC 具有比 FGPC 更高精度的预测模型, 系统以更快的速度恢

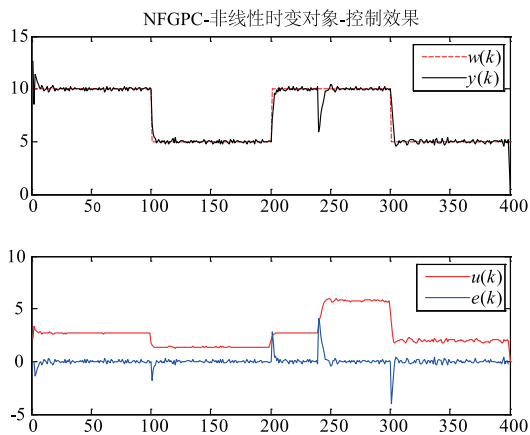


图9 NFGPC控制效果图

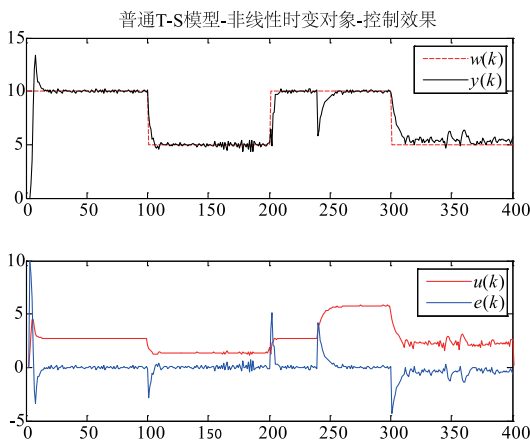


图10 FGPC控制效果图

复到正常值; 当  $k = 300$  阶跃信号来临时, 本文模型已经完成对系统新特性的学习跟踪, NFGPC 控制效果良好, 而 FGPC 则面临失稳, 由于 GPC 本身具有一定的

模型鲁棒性, 所以失稳原因主要是 T-S 模型无法快速学习被控制对象的新状态特性.

由于 PID 与 LGPC 面对这类复杂系统时, 控制效果差, 图 11 给出 LGPC 的某次较好的控制效果作为对比, 可知 PID 与 LGPC 无法较好的处理参数不确定非线性系统的控制问题.

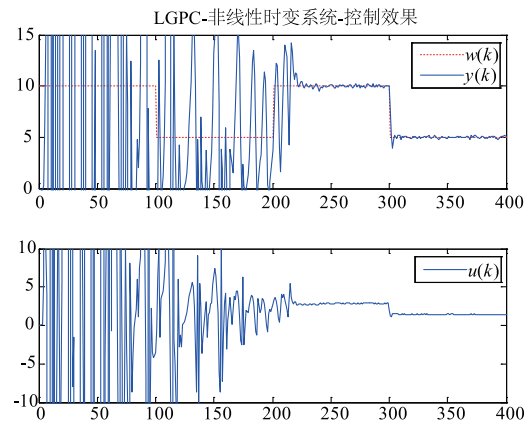


图11 LGPC控制效果图

## 5 结论

针对窑压参数不确定非线性特性, 本文将改进 STS 模型与 GPC 控制相结合, 该方法赋予 GPC 预测模型更强的在线学习能力, 使其对窑压对象特性的变化具有更强适应能力; 同时重新设计滚动优化函数, 超调抑制效果明显; 最后通过建模实例与控制仿真实例对验证本文方法在建模以及控制上的优越性, 同时本文方法还具有计算量小, 易于在线实施等特点. NFGPC 也存在有不足, 如 NFGPC 在线运行需要确定的参数偏多, 这为实际应用增加了一定难度; 此外, STS 模型建模方法没有一个明确的终止条件, 在这方面也需要进行探索.

## 参考文献

- [1] 薄迎春, 夏伯锴. 催化剂窑炉温度的启发式动态规划控制[J]. 化工学报, 2013, 64(12): 4615-4620.  
Bo Yingchun, Xia Bokai. Heuristic dynamical programming control for catalyst baking furnace temperature[J]. Journal of Chemical Industry and Engineering, 2013, 64(12): 4615-4620. (in Chinese)
- [2] Wang L, Wang Y, Zang H. The Resin Abrasives Products Hardening Furnace Temperature Control System Design Based on Fuzzy Self-tuning PID[C], Proceedings of 2010 International Conference on Computer, 2010: 458-461.
- [3] 吴志伟, 柴天佑, 付俊等. 电熔镁炉熔炼过程的智能设定值控制[J]. 控制与决策, 2011, 26(9): 1417-1420.  
Wu Zhiwei, Cai Tianyou, Fu Jun, et al. Intelligent setpoints control of smelting process of fused magnesium furnace

- [J]. Control and Decision, 2011, 26(9): 1417 - 1420. (in Chinese)
- [4] 王磊. 浮法玻璃熔窑燃烧控制系统的先进控制应用与研究[D]. 合肥: 中国科技大学, 2006.  
Wang Lei. Float glass furnace combustion control system with advanced control application and research[D]. HeFei: University of Science and Technology of China, 2006. (in Chinese)
- [5] 袁学海, 李洪兴, 孙凯彪等. 基于参数单点模糊化方法的模糊系统及其逼近能力[J]. 电子学报, 2011, 39(10): 2372 - 2377.  
Yuan Xuehai, Li Hongxing, Sun Kaibiao et al. Fuzzy Systems and Their Approximation Capability Based on Parameter Singleton Fuzzifier Methods[J]. Acta Electronica Sinica, 2011, 39(10): 2372 - 2377. (in Chinese)
- [6] Beschi M, Berenguel M, Visioli A, et al. Implementation of feedback linearization GPC control for a solar furnace[J]. Journal of Process Control, 2013, 23(10): 1545 - 1554.
- [7] 钱富才, 伍光宇. 一种 T-S 模型的在线辨识算法[J]. 控制与决策, 2015, 30(02): 343 - 347.  
Qian Fucui, Wu Guangyu. An on-line algorithm for T-S model identification [J]. Control and Decision, 2015, 30(02): 343 - 347. (in Chinese)
- [8] 雷世昌. 马蹄焰窑炉系统的改进模糊广义预测控制方法研究[D]. 北京化工大学, 2014.  
Lei Shichang, Research of Improved Fuzzy Generalized Predictive Control Method for Glass Furnace System[D]. Beijing University of Chemical Technology, 2014. (in Chinese)
- [9] 王智琴. 复杂热工系统的 TS 模糊模型辨识研究[D]. 北京: 北京交通大学, 2009.  
Wang Zhiqin. TS fuzzy model identification of complex thermal system [D]. Beijing: Beijing Jiaotong University, 2009. (in Chinese)
- [10] 庞中华, 崔红. 系统辨识与自适应控制 MATLAB 仿真 (修订版)[M]. 北京: 北京航空航天大学出版社, 2013.  
Pang Zhonghua, Cui Hong. System identification and adaptive control with MATLAB simulation (Revision) [M]. Beijing: Beijing university of aeronautics and astronautics press, 2013. (in Chinese)

- [11] Gomma H, Yu H. Derivative derived generalised predictive control (DDGPC): a technique for improving performance[C]. Proceedings of 2005 IEEE Conference on Control Applications, 2005: 1152 - 1157.

#### 作者简介




**曹政才** 男, 博士, 教授/博导, 主要研究方向: 复杂生产过程优化调度, 系统工程和智能控制.

E-mail: giftcze@163.com.



**赵琪** 男, 1989 年出生, 辽宁沈阳人. 现为北京化工大学硕士研究生, 研究方向为复杂生产过程优化调度, 机器视觉与图像处理.

E-mail: zhaqiqibuct@163.com.



**雷世昌** 男, 1989 年出生, 湖南人. 毕业于北京化工大学, 获工学硕士学位. 研究方向为生产过程优化调度.

E-mail: lsc989818@163.com



**刘民** 男, 博士, 教授/博导, 主要研究方向为复杂生产过程优化调度, 复杂生产过程或装备智能检测和智能操作优化, 智能优化方法及其在复杂制造系统建模、调度与优化中的应用.

E-mail lium@tsinghua.edu.cn