

# 基于二次逼近神经网络的反应釜预测控制

林 勇, 宋一凡, 温阳东

(合肥工业大学 电气自动化工程学院, 合肥 230009)

**摘要:** 针对在化工生产过程中使用连续搅拌反应釜 (Continuous Stirred Tank Reactor, CSTR) 时存在的控制方式不便, 调节的精确度不高等问题; 在对实际问题进行分析建模的基础上, 提出了一种基于二次逼近神经网络模型的预测控制方法; 该方法首先利用多层前馈神经网络模型去逼近连续搅拌反应釜系统的多步预测值, 其次在已创建的预测模型的基础上优化并求解预测控制的二次目标函数, 以得到最优的控制参数, 最后由通过泰勒展开式的二次逼近得到非线性预测控制器的最优解; 通过对控制模型的模拟以及带入相关参数进行仿真实验, 对连续搅拌反应釜控制系统的仿真结果进行分析表明: 该方法控制精确度较高, 并且是可行有效的, 能够使生产效率得到显著提高且保证了产品的质量, 具有较高的实用价值。

**关键词:** 连续搅拌反应釜; 神经网络; 广义预测控制; 泰勒展开; 二次逼近

## Predictive Control of Reactor Based on Quadratic Approximation Neural Network

Lin Yong, Song Yifan, Wen Yangdong

(School of Electric Engineering and Automation, Hefei University of Technology, Hefei 230009, China)

**Abstract:** A predictive control method based on neural network is presented for the problem of production inconvenience and low precision in a continuous stirred tank reactor (CSTR) which is widely used in chemical process. Firstly, using a multi-layer feed forward neural network to approximate the CSTR system's multi-step predictive value, secondly based on the forecast model for solving quadratic objective function optimization predictive control by the Taylor expansion approximation quadratic nonlinear predictive control law controller. The simulation results of CSTR show that: that essay's method has high accuracy and that method is feasible and effective. The utility model has the advantages of high production efficiency, high product quality and high practical value.

**Keywords:** continuous stirred tank reactor (CSTR); neural network; generalized predictive control; Taylor expansion; quadratic approximation

### 0 引言

反应釜是现代化工生产中必不可少的主要设备之一。反应釜<sup>[1]</sup>有两种工作方式: 连续生产和间歇生产。前者被称作连续搅拌反应釜 (continuous stirred tank reactor, 简称 CSTR)。CSTR 如今已成为工业上最常用的反应釜, 它有许多优点: 既能进行匀相反应, 又可进行多相反应; 其次它的搅拌机制使得反应釜中反应物料的浓度均匀; 此外, CSTR 投资少、生产出的产品质量稳定、热交换能力强, 有很高的生产效率。但在实际生产中多数化工厂仍然使用人工和常规 PID 方法对 CSTR 进行控制, 调节反应釜的生产过程参数如温度、流量、浓度、反应速率等, 从而得到符合工艺要求的生成物产品。由于 CSTR 系统本身的强非线性, 导致传统的控制方法难以符合生产要求, 参数控制不够精确, 达不到预期的控制效果, 对化工产品的质量和产量都有很大影响, 故对 CSTR 控制方法的改进就显得尤为迫切。在分析了 CSTR 系统的特点和生产控制要求之后, 笔者提出了基于二次逼近神经网络的预测控制方法, 通过神经网络辨识 CSTR 这个强

非线性系统, 然后通过对广义控制律的泰勒展开, 实现了对生产参数值的二次逼近, 改善了控制精度和控制效果, 提高了生产效率和产品质量, 很好地满足了化工厂生产要求。

### 1 CSTR 的基本结构和原理

CSTR 的基本结构如图 1 所示。其基本结构由搅拌容器和搅拌机两大部分组成。其中, 搅拌容器包括内构件、筒体和换热元件。搅拌机包括搅拌轴、搅拌器及其密封和传动装置等。




图 1 CSTR 基本结构

反应釜中的化工生产是个复杂的过程。在进行化工生产时, 首先向反应釜中投入物料以及催化剂, 然后通过搅拌使反应釜内物料均匀进行化学反应。升温阶段在反应釜的夹套

收稿日期:2017-04-04; 修回日期:2017-04-19。

**作者简介:** 林 勇 (1978-), 男, 安徽合肥人, 副研究员, 硕士生导师, 主要从事自动控制、计算机控制方向的研究。

温阳东 (1955-), 男, 安徽合肥人, 教授, 主要从事自动控制、计算机控制、现场总线技术应用方向的研究。

中通以一定的高压蒸汽,当反应釜内的温度上升到设定值时,控制蒸汽的速度使温度保持恒定,确保反应在最佳工况下正常进行。反应完成后便是降温过程,通以冷却介质使反应釜温度降低,结束整个反应过程。恒温阶段对整个生产过程而言最为关键,偏高或偏低的温度值都会影响化工反应进行的深度和转化率,从而影响产品的质量。由于此类化工生产为放热反应,为了确保反应釜温度稳定在设定值,通过在夹套中通以一定的冷却介质,来吸收多余热量,使反应釜的温度符合工艺要求<sup>[2]</sup>。

由此可见,冷却剂流量的大小,直接影响着反应釜温度,从而影响化工产品的生产,故本文通过控制冷却剂流量的大小,使反应釜恒温反应阶段温度稳定在设定值,从而间接地控制生成物的浓度,得到质量合格的产品。

## 2 预测控制

模型预测控制<sup>[3]</sup>(简称预测控制)是产生于工业过程控制领域的一类新型计算机控制算法。发展至今预测控制在理论和实践两个方面都取得了丰硕的成果。实际生产过程中的系统往往强耦合、强非线性,还具有时滞时变等特性。传统的预测控制在面对这种复杂的控制对象和更高的控制要求时,很难实现实时有效的控制,达不到预期的控制精度和效果。所以对于非线性系统的预测控制优化研究,使其具有更好的控制效果和更大的应用范围已成为近年来的热点课题之一。

人工神经网络,不仅具有自学习、自适应不确定性系统的动态特性,而且理论上可以逼近任意复杂非线性系统。神经网络的这些特点和自身优势,为解决非线性问题提供了一种新的思路。因此将神经网络<sup>[4]</sup>和预测控制结合起来,在传统预测控制的基础上运用神经网络方法进行优化,得到基于神经网络的非线性预测控制<sup>[5]</sup>来弥补传统预测控制在面对强耦合,强非线性时变系统时的不足,更好的解决非线性系统控制问题。

基于上述理论,本文通过结合神经网络和预测模型的思想,设计了基于神经网络的预测模型,有效辨识了 CSTR 这个强非线性系统,解决了传统控制中存在的问题,实现对 CSTR 的有效控制。

## 3 广义预测控制理论

在预测控制理论中需要构建一个预测模型,该模型能够根据系统的历史数据和未来的输入,预测系统未来的输出值从而描述系统动态行为,对系统进行预测控制。通常 GPC(广义预测控制)<sup>[6]</sup>采用 CARIMA(Controlled Auto-Regressive Integrated Moving Average)“受控自回归积分滑动平均模型”作为预测模型,这个模型可以写成:

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

式中  $u(k)$  和  $y(k)$  分别是过程的输入和输出,  $\xi(k)$  是零均值噪声序列,  $A(z^{-1})$ 、 $B(z^{-1})$  和  $C(z^{-1})$  则分别是后移算子  $z^{-1}$  的多项式:

$$A(z^{-1}) = a_0 + a_1 z^{-1} + \dots + a_{n_a} z^{-n_a}$$

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

$$C(z^{-1}) = c_0 + c_1 z^{-1} + \dots + a_{n_c} z^{-n_c}$$

使用 CARIMA 模型有以下好处:1) 该模型能描述一类非平稳扰动;2) 可保证系统输出稳态误差为零。

通常将广义预测控制器<sup>[7]</sup>所基于的目标函数定义为如下

的控制增量形式:

$$J_{GPC} = E \left\{ \sum_{j=1}^N [y(k+j|k) - \bar{y}(k+j)]^2 + \lambda \sum_{j=1}^{N_u} [\Delta u(k+j-1)]^2 \right\} \quad (2)$$

式中,  $y(k+j|k)$  是对  $y(k)$  的向前  $j$  步预测,  $y_r(k)$  为输出设定值,  $N$  为预测域,  $N_u$  为控制域,  $\lambda > 0$  为控制加权因子,  $0 \leq a < 1$  为柔化因子。  $\bar{y}(k+j)$  为输出跟踪序列,由下式迭代产生:

$$\begin{cases} \bar{y}(k) = y(k) \\ \bar{y}(k+j) = \alpha \bar{y}(k+j-1) + (1-\alpha)y_r(k) \end{cases} \quad j = 1, \dots, N \quad (3)$$

本文用一组神经网络模型去逼近一个非线性系统的多步预测值,再优化求解预测控制的二次目标函数,与传统方法不同的是,该方法并未使用递推 Diophantine 方程来求解控制量,从而减少了计算量且提高了预测精度,具体过程如下文中所述。

## 4 基于二次逼近神经网络的非线性预测控制器

### 4.1 多步预测模型的神经网络组

对于最一般形式的单输入单输出的离散非线性系统,可以由下面的输入/输出模型来描述<sup>[8]</sup>:

$$y(k) = f(y(k-1), \dots, y(k-n), u(k-1), \dots, u(k-m-1)) \quad (4)$$

上述非线性系统的输出量  $y(k)$  的第  $j$  步预测值由当前信息  $x_0(k)$  和未来  $j$  时刻内的控制增量  $\Delta U^j(k)$  共同决定。

$$y(k+j|k) = f_j(x_0(k), \Delta U^j(k)) \quad j = 1, 2, \dots, N \quad (5)$$

其中:  $x_0(k) = [y(k), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)]^T$ ,  $\Delta U^j(k) = [\Delta u(k), \dots, \Delta u(k+j-1)]^T$

然后用一组三层前馈神经网络去逼近预测模型 (5)

$$\hat{y}(k+j|k) = f_{NN_j}(x_0(k), \Delta U^j(k), W_j) \quad j = 1, 2, \dots, N \quad (6)$$

这一共是  $N$  个网络,  $W_j$  为第  $j$  个网络的权值向量。第  $j$  个网络的结构如图 2 所示。




图 2 多预测模型网络组中的第  $j$  个网络结构示意图

定义:

$$\varphi_k^{(j)} = \hat{y}(k|k-j) - y(k) \quad (7)$$

用非线性最小二乘法递推算法对  $W_j$  进行在线学习。

### 4.2 二次逼近预测控制律

本系统的控制律仍然以式 (2) 为目标函数,对式 (6) 应用一阶泰勒展开,可以得到:

$$\hat{y}(k+j|k) = y^0(k+j|k) + (g^j)^T(\Delta U^j(k) - \Delta U_0^j(k)) + O(\|\Delta U^j(k) - \Delta U_0^j(k)\|) \quad (8)$$

式中,  $\Delta U_0^j(k)$  为  $\Delta U^j(k)$  在相应维数空间中某点:

$$y^0(k+j|k) = f_{NN_j}(x_0(k), \Delta U_0^j(k), W_j) \quad (9)$$

$g^j$  为  $f_{NN_j}(\cdot)$  在相应值之下关于  $\Delta U_0^j(k)$  的梯度向量,

$$g^j = \left[ \frac{\partial f_{NN_j}}{\partial \Delta u_0(k)}, \dots, \frac{\partial f_{NN_j}}{\partial \Delta u_0(k+j-1)} \right]^T = [g_{j-1}^j, \dots, g_0^j]^T \quad (10)$$

假设当  $j > N_u$  时,  $\Delta u(k+j-1) = 0$ , 所以定义

$$\tilde{g}^j = \begin{cases} [g_{j-1}^j, \dots, g_0^j, 0, \dots, 0]^T, & j = 1, 2, \dots, N_u \\ [g_{j-1}^j, \dots, g_{j-N_u}^j]^T, & j = N_u+1, \dots, N \end{cases} \quad (11)$$

于是对

$$j = 1, 2, \dots, N, (\tilde{g}^j)^T(\Delta U^j(k) - \Delta U_0^j(k)) = (\tilde{g}^j)^T(\Delta U^{N_u}(k) - \Delta U_0^{N_u}(k)) \quad (12)$$

定义

$$\Delta \tilde{U}^{N_u}(k) = \Delta U^{N_u}(k) - \Delta U_0^{N_u}(k) \quad (13)$$

由式 (8)、(12) 和 (13) 得

$$\hat{y}(k+j|k) = y^0(k+j|k) + (\tilde{g}^j)^T(\Delta \tilde{U}^{N_u}(k)) \quad (14)$$

将其写成向量形式

$$\hat{\mathbf{Y}} = \mathbf{Y}^0 + \tilde{\mathbf{G}} \Delta \tilde{U}^{N_u}(k)$$

式中,

$$\hat{\mathbf{Y}} = [\hat{y}(k+1|k), \dots, \hat{y}(k+N|k)]^T$$

$$\mathbf{Y}^0 = [y^0(k+1|k), \dots, y^0(k+N|k)]^T$$

$$\tilde{\mathbf{G}} = \begin{bmatrix} g_0^1 & & & \\ g_1^2 & g_0^2 & & \\ \vdots & \vdots & \ddots & \\ \vdots & \vdots & & g_0^{N_u} \\ & & & \vdots \\ g_{N-1}^{N_u} & \dots & \dots & g_{N-N_u}^{N_u} \end{bmatrix}_{N \times N_u}$$

将目标函数 (6) 也写成向量形式:

$$\mathbf{J} = (\hat{\mathbf{Y}} - \mathbf{Y})^T(\cdot) + \lambda(\Delta \tilde{U}^{N_u}(k) + \Delta U_0^{N_u}(k))^T(\cdot) \quad (15)$$

将式 (14) 代入式 (15) 后得到:

$$\begin{aligned} J &= (\mathbf{Y}^0 + \tilde{\mathbf{G}} \Delta \tilde{U}^{N_u}(k) - \mathbf{Y})^T(\cdot) + \lambda(\Delta \tilde{U}^{N_u}(k) + \\ &\Delta U_0^{N_u}(k))^T(\cdot) = (\tilde{\mathbf{G}} \Delta \tilde{U}^{N_u}(k) + \mathbf{Y}^0 - \mathbf{Y})^T(\cdot) + \\ &\lambda(\Delta \tilde{U}^{N_u}(k))^T(\cdot) + 2\lambda(\Delta \tilde{U}^{N_u}(k))^T(\Delta U_0^{N_u}(k)) + \\ &\lambda(\Delta U_0^{N_u}(k))^T(\cdot) \end{aligned} \quad (16)$$

令  $\frac{\partial \mathbf{J}}{\partial \Delta \tilde{U}^{N_u}(k)} = 0$ , 得:

$$\Delta \tilde{U}^{N_u}(k) = (\tilde{\mathbf{G}}^T \tilde{\mathbf{G}} + \lambda \mathbf{I})^{-1} \tilde{\mathbf{G}}^T [\mathbf{Y} - \mathbf{Y}^0 - \lambda(\Delta U_0^{N_u}(k))] \quad (17)$$

设  $\Delta U_0^{N_u}(k)$  为控制器上一时刻的最优控制增量序列

$$\Delta U_0^{N_u}(k) = \Delta U^{N_u}(k-1) \quad (18)$$

由 (18) 可推导出当前时刻基于二次优化目标逼近的控制增量序列

$$\begin{aligned} \Delta U^{N_u}(k) &= [\mathbf{I} - (\mathbf{I} + \lambda^{-1} \tilde{\mathbf{G}}^T \tilde{\mathbf{G}})^{-1}] \Delta U^{N_u}(k-1) + \\ &(\tilde{\mathbf{G}}^T \tilde{\mathbf{G}} + \lambda \mathbf{I})^{-1} \tilde{\mathbf{G}}^T (\mathbf{Y} - \mathbf{Y}^0) \end{aligned} \quad (19)$$

### 4.3 CSTR 预测控制

在实际化工生产中连续搅拌反应釜动力学模型可用 2 个非线性<sup>[9]</sup>微分方程描述:

$$\bar{C}_A = \frac{q}{V}(C_{a0} - C_A) - k_0 C_A e^{-E/(RT)} \quad (20)$$

$$\bar{T} = \frac{q}{V}(T_f - T) - k_1 C_A e^{-E/(RT)} +$$

$$k_3 q_c [1 - e^{-k_2/(q_c)}](T_c - T) \quad (21)$$

式中,  $q$  为进料流速,  $C_{a0}$  为进料成分的浓度,  $T_f$  为进料温度,  $T$  为反应釜温度,  $T_c$  为入口冷却剂温度,  $q_c$  为冷却剂流量<sup>[8]</sup>,

$k_0$  为指数因子,  $V$  为反应釜容积,  $\frac{E}{R}$  为活化能量,  $h_a$  为传热系数,  $-\Delta H$  为反应热量,  $k_1, k_2$  和  $k_3$  为常数,  $k_1 = \frac{(-\Delta H)k_0}{\rho_1 C_p}, k_2$

$= \frac{h_a}{\rho_c C_{pc}}, k_3 = \frac{\rho_c C_{pc}}{\rho_1 C_p V}, \rho_1, \rho_c$  为液体浓度,  $C_p, C_{pc}$  为比热容。其中具体参数<sup>[9]</sup>如表 1 所示:

表 1 CSTR 参数表

参数	参数值	参数	参数值
进料成分浓度 $C_{a0}$	1 mol/L	传热系数 $h_a$	$7.2 \times 10^5 \text{ J/min} \cdot \text{K}$
进料流速 $q$	100 L/min	活化能量 $E/R$	$1 \times 10^4 \text{ K}$
进料温度 $T_f$	350 K	反应热量 $-\Delta H$	$2 \times 10^5 \text{ cal/mol}$
入口冷却剂温度 $T_c$	350 K	指数因子 $k_0$	$7.2 \times 10^{10} \text{ min}^{-1}$
反应釜容积 $V$	100 L	液体浓度 $\rho_1$	$\rho_1 = 1 \times 10^3 \text{ g/L}$
反应釜温度 $T$	$300 \text{ K} \leq T \leq T_{\max}$	液体浓度 $\rho_c$	$\rho_c = 1 \times 10^3 \text{ g/L}$
生成物浓度 $C_A$	$0.02 \leq C_A \leq 0.8$	比热容 $C_p, C_{pc}$	$C_p = C_{pc} = 1 \text{ cal/g} \cdot \text{K}$

由表 1 数据计算得到  $k_1 = 1.44 \times 10^3 \text{ g/L}$ ,  $k_2 = 6.987 \times 10^2$ ,  $k_3 = 0.01$ 。

首先选择一组三层神经网络进行辨识, 根据第 1 节对 CSTR 结构和工作原理的分析, 忽略次要因素的影响, 参数  $q, C_{a0}, T_f, T_c, K_0, V, \frac{E}{R}, h_a, -\Delta H$  会影响 CSTR 系统, 故输入层节点数设置为 9 个作为神经网络的输入值。系统的控制量为冷却剂流量  $q_c$ , 通过控制  $q_c$  来保证反应釜温度  $T$  稳定在设定值, 故神经网络的输出层节点数设置为 1 个, 隐含层的数量决定着预测的精度和速度, 若  $n_h, n_i, n_o$  分别代表隐含层、输入层、输出层的神经元数目, 由经验公式<sup>[10]</sup>:  $n_h = \sqrt{n_i + n_o} + L$  (其中  $L$  为 0 到 10 之间的整数), 故笔者在此选择隐含层节点数为 8。取生产过程中记录的 200 组参数数据作为样本进行神经网络的训练, 函数初始化和参数设置如下:

```
net=newff(pr,[5,1], 'logsig', 'logsig'), 'trainlm', 'learngdm');
net.trainParam.epochs=1000;
net.trainParam.goal=0.001;
net.trainParam.show=10;
net.trainParam.lr=0.05;
```

利用非线性最小二乘递推算法训练神经网络组的各个权值, 即可用该组神经网络模型去逼近 CSTR 系统模型。通过 (8) 和 (10) 进行泰勒展开, 得到梯度向量。依据预测控制算法 CARIMA 模型的一般原则和 CSTR 系统的过程参数<sup>[11]</sup>, 设置采样周期为 1 s, 控制周期为 5 s, 预测时域  $N1 = N2 = 73$ , 控制时域  $N3 = N4 = 18$ , 柔化因子  $\alpha_1 = \alpha_2 = 0.5$ , 对角元素分别取 5 000 和 0.01, 辨识方法采用带遗忘因子的最小二乘法, 遗忘因子为 0.98, 协方差矩阵初值  $P_0 = 1 \times 10^4 \mathbf{I}$  ( $\mathbf{I}$  为单位矩阵), 求得辨识对象  $\hat{\mathbf{G}}$ 。

CSTR 系统的控制目标是通过控制  $q_c$  使反应釜的温度  $T$

稳定在设定值, 得到符合工艺的生成物浓度  $C_A$  来生产质量合格的产品。例如某次生产工作点  $C_a = 0.5 \text{ mol}$ ,  $T = 350 \text{ K}$ ,  $T_c = 300 \text{ K}$ , 温度  $T$  的设定值为  $350 \text{ K}$ , 系统的约束条件为:

$$X = \left\{ \begin{bmatrix} C_A \\ T \end{bmatrix} \in \mathbf{R}^2 \mid 0 \leq C_A \leq 1, 280 \leq T \leq 370 \right\} \quad (22)$$

$$U = \{T_c \in \mathbf{R} \mid 200 \leq T_c \leq 370\}$$

则系统的状态量和控制量转化为:

$$\mathbf{x} = \begin{bmatrix} (C_A - 0.5)/0.5 \\ (T - 350)/20 \end{bmatrix}, u = \frac{T_c - 300}{20} \quad (23)$$

采用局部镇定控制器<sup>[12]</sup>  $k_f(x) = K_F x = [-3.2 \quad -0.18]$

得到终端权重矩阵:  $\mathbf{Q}' = \begin{bmatrix} 26.6 & 4.9 \\ 4.9 & 12.6 \end{bmatrix}$ , 代入预测模型中即可得到控制序列。

## 5 仿真验证与分析

本文采用 Matlab 软件作为仿真工具。广义预测控制参数取预测长度  $N_1 = 3$ , 加权系数  $\lambda = 0.35$ , 控制长度  $N_u = 2$ , 柔化系数  $\alpha = 0.5$ 。利用一组在 (80, 115) 间的随机幅值序列作为激励输入 CSTR 机理模型, 以周期为 0.1 s 的间隔采样得到样本数为 600 的一组输入输出数据, 取前 400 组用于模型的辨识, 后 200 组数据分别作为训练集和验证集, 通过控制  $q_c$  使反应釜的温度  $T$  稳定在设定值, 得到符合工艺的生成物浓度  $C_A$  从而生产质量合格的产品。




图 3 浓度  $C_A$  的实际测量值和神经网络预测模型预测值对比

经模型辨识后, 为了检验神经网络预测模型的辨识效果, 取 100 份样本数据进行神经网络预测效果测试, 图 3 为 100 份样本生成物浓度  $C_A$  实际测量值和神经网络预测模型预测值的对比, 经计算得实际测量值和神经网络预测模型预测值平均误差为 1.42%, 表明所得模型辨识精度较高, 预测效果较好。

为了验证本文神经网络预测控制的有效性和优越性, 将该方法与常规 PID 控制做比较。根据文献 [9], 设定 PID 参数。开始系统工作点  $C_A = 0.075 \text{ mol} \cdot \text{L}^{-1}$ ,  $q_c = 96.75 \frac{\text{L}}{\text{min}}$ , 生成物浓度设定值为  $C_A = 0.1 \text{ mol} \cdot \text{L}^{-1}$ 。得出最终仿真效果如图 4 所示。

表 2 控制性能参数对比

方法	调整时间 /s	超调量 /%	控制 精度	稳定性
神经网络预测控制	19	0	99	稳定
常规 PID 控制	110	21	96	超调较大, 且有轻微震荡

由表 2 数据对比分析可知, 神经网络预测控制相比于常




图 4 神经网络预测控制和常规 PID 控制效果对比

规 PID 控制, 调整时间较短, 满足生产的快速性要求; 神经网络预测控制控制精度为 99%, 高于常规 PID 的 96%, 满足生产的控制精度要求, 保证产品质量; 神经网络预测控制无超调, 常规 PID 控制有超调且伴有轻微震荡现象, 满足生产的稳定性要求。综上, 本文提出的神经网络预测控制效果优于常规 PID 控制, 是一个较好的 CSTR 控制方法。

## 6 结论

基于二次逼近神经网络预测控制方法, 通过神经网络模型很好的辨识了 CSTR 这个强非线性系统, 其次通过广义控制律的泰勒展开实现了对生产参数值的二次逼近提高了预测控制性能。优于常规 PID 控制, 提高了 CSTR 系统的控制精度和控制效果, 提高了生产效率且保证了产品的质量, 具有较高的应用价值, 也为预测控制的优化发展提供借鉴意义。

## 参考文献:

- [1] 杨军民. 反应釜温度控制的研究现状及化工自动化发展现状 [J]. 广东化工, 2010, 37 (5): 288-290.
- [2] 于海英. 化学反应釜温度模糊控制器 [D]. 阜新: 辽宁工程技术大学, 2002.
- [3] 马海军, 王文中, 翟素兰, 等. 基于卷积神经网络的监控视频人, 数统计算法 [J]. 安徽大学学报 (自然科学版) 2016, 40 (3) 22-28.
- [4] 王华强, 石亚娟, 王健波. 神经网络模糊 PID 在水轮机调速中的应用 [J]. 合肥工业大学学报 (自然科学版), 2012, 35 (9): 1187-1191.
- [5] 谭元飞. 基于神经网络预测控制的锅炉过热汽温控制研究 [D]. 西安: 西安科技大学, 2012.
- [6] 张兴, 戴莹, 李争. 一种时变非线性对象神经网络 PID 控制的仿真 [J]. 合肥工业大学学报 (自然科学版), 2006, 29 (11): 1375-1379.
- [7] Neshasteriz A R, Khaki S A, Sadjadian H. Generalized predictive control and tuning of industrial processes with second order plus dead time models [J]. Journal of Process Control, 2010 (20).
- [8] 程辉, 秦廷, 陈宗海. 液位对象的一种非线性广义预测控制策略研究 [J]. 计算机仿真, 2006, 23 (9): 333-335.
- [9] 满红, 邵诚. 基于 Hammerstein-Wiener 模型的连续搅拌反应釜神经网络预测控制 [J]. 化工学报, 2011, 62 (8): 2275-2276.
- [10] 曾谊晖, 龚金科, 李金梅, 杨贤平. 数控切削加工表面粗糙度 RBF 神经网络预测模型 [J]. 煤矿机械, 2011, 32 (3): 117-119.
- [11] 李奇安, 褚健. 对角 CARIMA 模型多变量广义预测控制改进算法 [J]. 控制理论与运用, 2007, 24 (3): 423-427
- [12] 陈薇. 非线性预测控制算法的研究与应用 [D]. 合肥: 中国科学技术大学, 2007.