

文章编号: 1671-7848(2007)04-0369-04

## 料筒温度 RBF 神经网络 PID 控制器设计及仿真

文生平, 江 静

(华南理工大学 聚合物新型成型装备国家工程研究中心, 广东 广州 510640)



**摘 要:** 针对 PID 控制器具有参数整定不良、性能欠佳、温度控制精度较低, 无法满足当今高精密挤出成型加工需要的问题, 设计了一种基于 RBF 神经网络的 PID 控制器, 该控制器把神经网络能无限地逼近非线性系统、运算量小、收敛快的优点和 PID 控制技术有机地结合起来, 使料筒获得较高的温度控制精度。仿真结果表明, 神经网络 PID 控制器使得控制过程过渡时间明显缩短, 系统具有很好的稳定性和快速响应性, 比普通 PID 控制具有更好的控制效果, 可改善料筒温控系统的动、静态性能, 获得较高的温度控制精度。

**关键词:** 料筒温度; PID 控制; RBF 神经网络; Matlab

**中图分类号:** TP 183 **文献标识码:** A

## Design and Simulation of Barrel Temperature RBF Neural Network PID Controller

WEN Sheng-ping, JIANG Jing

(National Engineering Research Center of Novel Equipment for Polymer Processing,  
Ministry of Education, South China University of Technology, Guangzhou 510640, China)

**Abstract:** To the problem that the PID parameters are difficult to tune, the performance is unsatisfied the control accuracy is lower, and the PID controller can not satisfy the high exactitude extrusion processing, a PID controller based on radial basis function neural network (NN) is designed. The merits of NN such as infinity approaching nonlinear system, little operation quantity, speedy constringency, and gains high control accuracy are combined. The simulate results show that the NN PID controller makes the transient response short obviously. The system holds good stability and has better control effect than general PID controller. It could improve the performance of the dynamic and static state of the barrel temperature control system and gain a high temperature control precision.

**Key words:** barrel temperature; PID control; RBF neural network; Matlab

### 1 引 言

挤出加工成型是高分子材料成型加工的重要方法之一, 挤出成型过程中, 料筒温度是成型加工过程的重要工艺参数, 料筒温度的控制直接决定了成型工艺的优劣, 常规料筒温度控制多采用 PID 控制器, 常规的 PID 控制器由于受到参数整定不良、性能欠佳以及对运行工况适应性较差的影响, 往往达不到理想的控制效果。难以满足当今高精密成型加工的要求。为此, 人们将神经网络 (Neural Network, NN) 与 PID 控制结合起来, 实行对复杂系统的控制<sup>[1-3]</sup>。

RBF (Radial Basis Function 径向基) 神经网络是一种能以任意精度逼近任何复杂过程的非线性系统, 具有运算量小、收敛快等优点<sup>[4,5]</sup>。本文设计基于 RBF 神经网络的 PID 控制器, 把神经网络和

PID 控制两种技术有机地结合起来, 发挥各自的优势。神经网络 PID 可以通过在线学习, 根据对象参数发生变化时对系统输出性能的影响来调整连接权值, 改变网络中比例、积分和微分作用的强弱, 使系统具备良好的动态和静态性能。

### 2 RBF 神经网络 PID 控制器的算法实现

采用 RBF 网络来构建神经网络 PID 控制器, 可以通过神经网络自身的学习, 找到某一最优控制下的 P, I, D 参数。

控制器由两个部分组成:

①常规 PID 控制器 直接对被控对象进行闭环控制, 并且  $K_p$ ,  $K_i$ ,  $K_d$  三个参数为在线整定。

②RBF 神经网络辨识器 (NNI) 根据系统的运行状态, 调节 PID 控制器的参数, 以达到某种性能指标的最优化。即使神经网络的输出层神经元的输

出状态对应于PID控制器的三个可调参数  $K_p, K_i, K_d$ ，通过神经网络的自学习、调整权系数，从而使其稳定状态对应于某种最优化控制规律下的PID控制器参数。

基于RBF神经网络的PID控制器系统结构如图1所示。




图1 基于RBF神经网络的PID控制系统结构  
Fig.1 Block-diagram of the PID control system based on RBF neural network

1) PID 参数整定原理 PID 控制器算式为

$$u(k) = u(k-1) + \Delta u(k) \tag{1}$$

其中控制误差：

$$e(k) = r(k) - y(k) \tag{2}$$

设：

$$x_1 = e(k) = r(k) - y(k) \tag{3}$$

$$x_p = e(k) - e(k-1) \tag{4}$$

$$x_d = e(k) - 2e(k-1) + e(k-2) \tag{5}$$

$$\Delta u(k) = K_p \times x_p + K_i \times x_1 + K_d \times x_d \tag{6}$$

PID 整定的性能指标取为

$$E(k) = \frac{1}{2} e(k)^2 = \frac{1}{2} [r(k) - y(k)]^2 \tag{7}$$

$K_p, K_i, K_d$  采用梯度下降法进行优化调整<sup>[6]</sup>：

$$\Delta K_p = -\eta \frac{\partial E}{\partial K_p} = \eta e(k) \frac{\partial y}{\partial \Delta u} x_p \tag{8}$$

$$\Delta K_i = -\eta \frac{\partial E}{\partial K_i} = \eta e(k) \frac{\partial y}{\partial \Delta u} x_1 \tag{9}$$

$$\Delta K_d = -\eta \frac{\partial E}{\partial K_d} = \eta e(k) \frac{\partial y}{\partial \Delta u} x_d \tag{10}$$

所以增量式PID的参数整定算式为

$$K_p(k) = K_p(k-1) + \Delta K_p(k) = K_p(k-1) + \eta e(k) \frac{\partial y(k)}{\partial \Delta u(k)} x_p(k) \tag{11}$$

$$K_i(k) = K_i(k-1) + \Delta K_i(k) = K_i(k-1) + \eta e(k) \frac{\partial y(k)}{\partial \Delta u(k)} x_1(k) \tag{12}$$

$$K_d(k) = K_d(k-1) + \Delta K_d(k) = K_d(k-1) + \eta e(k) \frac{\partial y(k)}{\partial \Delta u(k)} x_d(k) \tag{13}$$

式(11)~式(13)中， $\eta$ 为学习速率(也称调整步长)， $\eta \in (0, 1)$ ； $\partial y / \partial \Delta u$ 为被控对象的 Jacobian 信息，即对象的输出对控制输入变化的灵敏度，可通过RBF神经网络进行辨识得到。

由式(11)~式(13)可以看出，只要能在线算出

$\partial y / \partial \Delta u$ ，PID控制器的3个参数即可实现在线调整。

2) 神经网络辨识器 图1的RBF网络采用基于NARMAX模型的辨识方法对被控对象进行动态辨识。NARMAX模型的描述为<sup>[7]</sup>

$$y(k+1) = f[y(k), \dots, y(k-n+1); u(k), \dots, u(k-n+1)] \tag{14}$$

利用RBF网络学习被控对象的输入输出非线性关系  $f(\cdot)$ ，根据被辨识对象的复杂程度采用适当数量的输入输出延时量  $y(k), \dots, y(k-n+1)$ ； $u(k), \dots, u(k-n+1)$ 作为RBF辨识网络的输入。故用来辨识对象特性的RBF神经网络结构，如图2所示。




图2 用于辨识的RBF神经网络结构

Fig.2 Structure of RBF neural network for identification

它是一种具有  $n$  个输入节点， $m$  个隐层单元，1 个输出节点的三层前馈网络。

图2中， $X = [x_1, x_2, \dots, x_n]^T$  为网络的输入向量。这里采用被控对象的输入输出延时量：

$y(k), \dots, y(k-n+1)$ ； $u(k), \dots, u(k-n+1)$ ； $H = [h_1, h_2, \dots, h_m]^T$  为  $m$  个隐层单元的输出向量； $W = [w_1, w_2, \dots, w_m]^T$  为  $m$  个隐层单元和输出单元之间的连接权向量； $y_m$  为网络的输出，目标是逼近对象的实际输出  $y$ 。

设隐层单元的数据中心矩阵为

$$C = [c_1, c_2, \dots, c_m]^T$$

第  $j$  个隐层单元的数据中心向量为

$$C_j = [c_{1j}, c_{2j}, \dots, c_{ij}, \dots, c_{nj}]^T$$

$i = 1, 2, \dots, n, j = 1, 2, \dots, m$

隐层单元的扩展常数向量为

$$B = [b_1, b_2, \dots, b_m]^T$$

$b_i$  为第  $j$  个隐层单元的扩展常数，且为大于零的数。

第  $j$  个隐层单元的输出为

$$h_j = \Phi_j(\|X - C_j\|) = \exp[-(\|X - C_j\|^2) / b_j^2] \tag{15}$$

辨识网络输出为  $m$  个隐层单元输出的线性组为

$$y_m = w_1 h_1 + w_2 h_2 + \dots + w_m h_m \tag{16}$$

在第  $k$  个采样周期，根据梯度下降法来修正网络输出权系数、数据中心、扩展常数，使辨识器的性能指标函数<sup>[8]</sup>：

$$J = \frac{1}{2} [y(k) - y_m(k)]^2 \quad (17)$$

最小化 则有：

$$\Delta w_j(k) = -\eta^* \nabla_{w_j} J = -\eta^* \frac{\partial J}{\partial w_j} = \eta^* [y(k) - y_m(k)] h_j \quad (18)$$

$$\Delta b_j(k) = -\eta^* \nabla_{b_j} J = -\eta^* \frac{\partial J}{\partial y_m} \frac{\partial y_m}{\partial h_j} \frac{\partial h_j}{\partial b_j} = \eta \frac{w_j h_j}{b_j^3} [y(k) - y_m(k)] \|X - C_j\|^2 \quad (19)$$

$$\Delta c_{ij}(k) = -\eta^* \nabla_{c_{ij}} J = -\eta^* \frac{\partial J}{\partial y_m} \frac{\partial y_m}{\partial h_j} \frac{\partial h_j}{\partial c_{ij}} = \eta \frac{w_j h_j}{b_j^2} [y(k) - y_m(k)] (x_i - c_{ij}) \quad (20)$$

另外为了加速  $J$  的收敛速度，在  $w_j, b_j, c_{ij}$  的调整公式中增加两个动量项，可得相应的修正公式为

$$w_j(k) = w_j(k-1) + \Delta w_j(k) + \alpha [w_j(k-1) - w_j(k-2)] + \beta [w_j(k-2) - w_j(k-3)] \quad (21)$$

$$b_j(k) = b_j(k-1) + \Delta b_j(k) + \alpha [b_j(k-1) - b_j(k-2)] + \beta [b_j(k-2) - b_j(k-3)] \quad (22)$$

$$c_{ij}(k) = c_{ij}(k-1) + \Delta c_{ij}(k) + \alpha [c_{ij}(k-1) - c_{ij}(k-2)] + \beta [c_{ij}(k-2) - c_{ij}(k-3)] \quad (23)$$

式(21)~(23)中， $\alpha, \beta$  为动量因子。

一般有  $\alpha, \beta \in (0, 1)$

动量项反映了以前积累的调整经验，对于  $k$  时刻的调整起阻尼作用。当误差曲线出现骤然起伏时，可减少振荡趋势，提高神经网络的学习速度。

在第  $k$  时刻，因为  $y_m(k) \approx y(k)$ ，如果把  $\Delta u$  作为 RBF 网络的第一个输入节点，即  $\Delta u = x_1$ ，那么对象的输出对控制输入的灵敏度：

$$\frac{\partial y(k)}{\partial \Delta u(k)} \approx \frac{\partial y_m(k)}{\partial \Delta u(k)} = \frac{\partial y_m(k)}{\partial \Delta h_j} \times \frac{\partial h_j}{\partial \Delta u(k)} = \frac{w_j h_j}{b_j^2} (c_{ij} - x_1) \quad (24)$$

式(24)就是通过 RBF 网络辨识对象得到的 PID 参数整定所需要的信息。

### 3 Matlab 仿真

对于挤出机模头段壁温的数学模型，由实验辨识得出模头段壁温  $T$  关于模头加热功率  $W$  的传递函数为<sup>[9]</sup>

$$G(s) = \frac{1.8}{(1 + 58.8s)^2} \exp(-15s) \quad (25)$$

设采样时间  $t_s = 3s$ ，将式(25)经  $Z$  变换后得其差分方程为

$$y(k) = 1.91y(k-1) - 0.903y(k-2) + 0.002265u(k-6) + 0.002189u(k-7) \quad (26)$$

经过大量的仿真比较，其最佳条件如下：

网络结构：3-6-1；网络输入矢量： $[\Delta u(k), y(k), y(k-1)]$ ；网络输出： $y_m(k)$ ；数据中心矩阵初始值：30；扩展常数矢量初始值：40；输出权值矢量初始值：10；网络的学习速率  $\eta_1$ ：0.25；动量因子  $\alpha$ ：0.25；动量因子  $\beta$ ：0.01； $K_p, K_i, K_D$  的学习速率  $\eta_2$ ：0.20。

控制算法流程如图 3 所示。

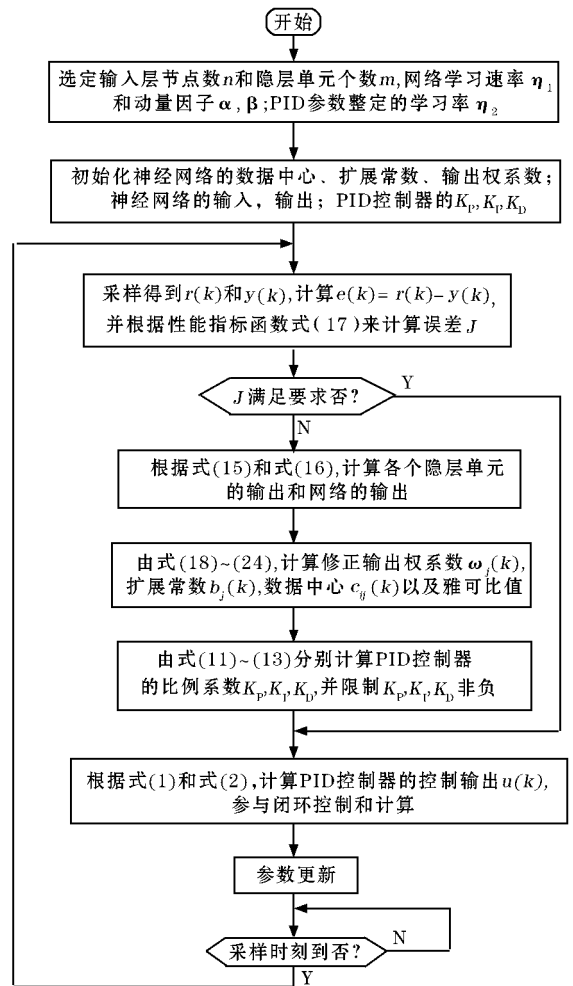



图 3 基于 RBF 神经网络和 PID 控制流程图


Fig.3 Flow chart of PID control based on RBF NN

然后根据算法流程图编写出基于 RBF 网络整定的 PID 控制 Matlab 程序进行仿真。为了比较控制效果，也编写普通 PID 控制程序对式(26)的对象进行仿真，结果如图 4 所示。

应用神经网络 PID 控制器后，控制过程过渡时间明显缩短，具有很好的稳定性和响应快速性，比普通 PID 控制具有更好的控制效果，从而证明了神经网络 PID 控制算法的有效性。



(a) 阶跃激励响应



(b) 矩形波激励响应

图 4 神经网络 PID 与普通 PID 控制激励响应对比  
Fig.4 Comparison of response of NN PID and common PID

### 4 结 语

本文设计了一个由 RBF 辨识网络和常规 PID 两个模块组成的神经网络 PID 控制器，并详细推导出了应用于控制系统的控制算法。控制器利用神经网络的自学习能力和逼近任意函数的能力，对被控对象进行在线辨识，把辨识得到的信息反馈给 PID 模块，以实现 PID 参数的在线调整。仿真结果说明了此算法的有效性。将该设计方法应用于工业过程中多变量控制系统，具有一定的实用意义。

### 参考文献 (References):

[1] Barmish B R, Hollot C V, Kraus F J, et al. Extreme point result for robust stabilization of interval plants with first order compensators[J]. IEEE Transactions on Automatic Control, 1992, 37(6):707-712.  
 [2] Dorf R C. Modern control systems[M]. Menlo Park California: Addison-Wesley Publishing Company Inc, 1989.  
 [3] 朱伟, 唐跃. 聚合物挤出加工中温度分布的计算、测量与控制[J]. 塑料, 2005, 34(4):29-33. (Zhu Wei, Tang Yue. Calculation measurement and control on the temperature distribution in the polymer extrusion[J]. Journal of Plastics, 2005, 34(4):29-33.)  
 [4] 党开放, 赵弘. 电液伺服系统的模糊径向基函数网络监督控制

[J]. 系统仿真学报, 2004, 16(3):593-595. (Dang Kaifang, Zhao Hong. Supervised control using fuzzy radial basis function networks for an electro-hydraulic servo system[J]. Journal of System Simulation, 2004, 16(3) 593-595.)  
 [5] 张德华, 武永红, 段锁林. 基于 RBFNN 的 PID 控制及其在电液位置伺服系统中的应用[J]. 太原科技大学学报, 2006, 27(5):360-363. (Zhang Dehua, Wu Yonghong, Duan Suolin. RBFNN-based PID control and its application to electro-hydraulic position servo system [J]. Journal of Taiyuan University of Science and Technology, 2006, 27(5) 360-363.)  
 [6] 林嘉宇. 语言信号非线性分析与处理[D]. 长沙: 国防科技大学, 1998. (Lin Jiayu. Nonlinear analysis and process for speech signal[D]. Changsha: Dissertation Submitted to National University of Defense Technology, 1998.)  
 [7] 何玉彬, 李新忠. 神经网络控制技术及其应用[M]. 北京: 科学出版社, 2000. (He Yubin, Li Xinzhong. Neural network control technology and its application[M]. Beijing: Science Publishing House, 2000.)  
 [8] 姬晓飞, 孟令柏, 申东日, 等. 基于 RBF 神经网络多步预测的自适应 PID 控制[J]. 甘肃科学学报, 2003, 15(2):72-75. (Ji Xiaofei, Meng Lingbai, Shen Dongri, et al. An adaptive PID control based on RBF neural network multi-step predictor[J]. Journal of Gansu Sciences, 2003, 15(2):72-75.)  
 [9] 文生平. 面向聚合物动态流变测试的挤出过程控制及智能化研究[D]. 广州: 华南理工大学工学, 2004. (Wen Shengping. Extrusion process control and intelligentized research based on polymer dynamic rheology measurement[D]. Guangzhou: Dissertation Submitted to South China University of Technology, 2004.)

(上接第 368 页)