

基于模糊神经网络的电液位置伺服系统控制

刘 坤¹, 高少平²

(1 黑龙江八一农垦大学 信息技术学院, 黑龙江 大庆 163319; 2 大庆石化公司机械厂, 黑龙江 大庆 163711)

摘 要: 采用将 T-S 模型与 RBF 神经网络相结合的网络结构, 提出一种复合式控制方案, 以解决传统自适应控制中模型的在线辨识和控制器的在线设计问题, 以达到对不确定非线性系统的高精确度输出跟踪控制; 通过引入运行监控器, 克服模糊神经网络控制方法通常存在的实时性差的问题; 同时, 利用一个鲁棒反馈控制器, 来保证模糊神经网络模型学习初期闭环系统的稳定性. 并应用于电液位置伺服系统的仿真研究中, 获得满意的控制效果.

关键词: 电液位置伺服系统; T-S 模型; RBF 神经网络

中图分类号: TP273.4 **文献标志码:** A **文章编号:** 1007-2683(2011)01-0069-06

Electro - hydraulic Position Servo System Control Based on Fuzzy - neuralNetwork

LIU Kun¹ GAO Shao - ping²

(1 College of Information Technology Heilongjiang August First Reclamation University, Daqing 163319 China

2 Daqing Petrochemical Company Machinery Factory, Daqing 163711, China)

Abstract In this paper, a kind of hybrid control structure is designed using the fuzzy neural of combining the T-S fuzzy model and the RBF neural theory to solve these problems which are about the on-line realization of model and the on-line design of controller in traditional adaptive control. The work above is to track the output of the uncertain unlinear system with high accuracy. Through using the supervisor, the common problem of poor realtime in fuzzy neural control is come over. With a robust feedback controller, the stability of closed-loop system in fuzzy neural model learning earlier is guaranteed. On the other hand, this paper utilizes this scheme to an electro-hydraulic position servo system simulation and achieves satisfactory results.

Key words electro-hydraulic position servo system; T-S model; RBF neural network

0 引 言

目前, 电液伺服系统已经被广泛应用于航空、冶金等各方面. 由于系统存在着各种非线性因素, 如同阀零偏滞环的限幅特性, 伺服放大电路的非线性增益以及死区等非线性. 这些非线性因素对系统都

有很大影响. 因而, 采用线性化的系统模型往往难以取得令人满意的控制效果. 这样, 设计鲁棒性强、具有良好控制性能, 并能消除系统不确定性影响的控制器, 仍然是人们十分关注的问题.

针对这些问题, 本文提出了一种 T-S 型模糊 RBF 神经网络并行自学习鲁棒跟踪控制结构, 并引入鲁棒因子, 用以消除不确定性对系统的影响, 以及

收稿日期: 2009-11-03

作者简介: 刘 坤 (1978—), 女, 硕士, 讲师, E-mail: lkk197807@163.com;

高少平 (1978—), 男, 工程师.

增强控制的实时性.

1 系统的描述

考虑某电液位置伺服系统, 该系统为一个典型的阀控液压缸系统^[1]. 其结构如图 1所示.




图 1 电液位置伺服系统结构

一般四边阀控双出杆缸电液伺服系统的数学模型可表示如下:

$$\frac{\ddot{x}_v}{\omega_{sv}^2} + \frac{2\zeta_{sv}}{\omega_{sv}}\dot{x}_v + x_v = K_p u$$

$$Q_l = K_v x_v \sqrt{P_s - \operatorname{sgn}(x_v) P_l} = A_c \dot{y} + C_l P_l + \frac{V_l}{4\beta_e} \dot{P}_l \quad (1)$$

$$m \ddot{y} + B_f \dot{y} + F_l = A_c P_l$$

其中: x_v 为阀芯位移; u 为伺服阀电流输入; Q_l 为伺服阀输出的负载流量; y 为液压缸位移输出; P_l 为负载压力; ζ_{sv} 、 K_p 、 K_v 、 C_l 、 V_l 、 β_e 、 m 、 B_f 、 A_c 、 P_s 为系统参数. 这些参数的物理意义及标称值见表 1

表 1 电液位置伺服系统参数表

参量	数值	参量	数值
液压缸有效面积 A_c/m^2	$0.25 \times 3.14 \times 0.09^2$	负载阻尼系数 $B_f/\text{N} \cdot \text{m}^{-1} \cdot \text{s}^{-1}$	70
泄漏系数 $C_l/\text{m}^5 \cdot \text{Pa}$	10×10^{-11}	液压缸体积 V_l/m^3	6.23×10^{-2}
伺服阀综合放大系数 $K_p K_v/\text{s}^{-1}$	1.11×10^{-6}	伺服阀固有频率 $\omega_{sv}/\text{rad} \cdot \text{s}^{-1}$	200
系统油源压力 P_s/Pa	9×10^6	伺服阀的阻尼比 ζ_{sv}	0.6
油液弹性模量 β_e/Pa	7×10^8	负载质量 m/kg	200

考虑到 ω_{sv} 通常很高, 甚至高于系统采样频率. 因而, 根据香农采样定理, 在采样控制系统中, 对油缸位移的采样信号不会包含伺服阀本身的动态响应过程信息. 所以在系统辨识中可以忽略伺服阀本身的动特性. 于是可得

$$K_p K_v u \sqrt{P_s - \operatorname{sgn}(x_v) P_l} = A_c \dot{y} + C_l P_l + \frac{V_l}{4\beta_e} \dot{P}_l \quad (2)$$

其相应的差分方程的形式为

$$v(t+1) = f(u(t), P_l(t), P_l(t-1)) \quad (3)$$

这样, 对电液位置伺服系统的辨识, 可采用对系统速度辨识然后积分的方法. 虽然这样做会引入辨识累积误差, 但它一方面可使网络降维; 另一方面, 由于系统的辨识与油缸所在位置无关, 因此对系统位置的预测也不会受系统所在位置的影响, 这使得模型对位置预测具有足够好的泛化能力.

2 系统设计

2.1 控制系统的结构及工作原理

系统控制结构如图 2 所示. 虚线上方是实时控制部分, NNI 和 NNC 均由一个 T-S 型模糊 RBF 神经网络结构组成. 虚线下方是并行学习部分, CNNI 与 CNNC 的结构分别与 NNI 和 NNC 的结构相同, NNI 通过在线学习系统动力学, 不断逼近系统的非线性前馈映射特性; NNC 通过在线学习逼近系统的逆动力学, 使系统的输出按要求的精度跟踪给定的输入波形^[2-3].




图 2 模糊神经网络并行自学习鲁棒跟踪控制结构

在实时控制部分, 考虑到系统是时变和不确定的, 特别是控制初期, NNI 尚未得到很好的训练, 为保证闭环系统的稳定性和良好的控制效果, 实时控制器由一个模糊神经网络控制器 NNC 和一个鲁棒控制器 RC 组成, 两个控制器的输出信号通过加权综合后, 作为系统的控制输入, 构成一个变鲁棒控制器^[2]:

$$u(k) = \gamma u_n(k) + (1 - \gamma) u_r(k) \quad (4)$$

其中: $u_n(k)$ NNC 的输出; $u_r(k)$ 为 RC 的输出; γ 为系统模型 NNI 的辨识精确度, 称为鲁棒因子. 形式为: $\gamma = e^{-\tau E_m}$, 式中 τ 是鲁棒因子的变鲁棒系数, E_m 为 NNI 输出与系统实际输出出差的平方, 即

$$E_m = \frac{1}{2} (y_m - y)^2 \quad (5)$$

工作原理: 控制初期, NNI 和 NNC 未得到训练, RC 对系统实施反馈控制并保证闭环系统稳定. NNI

不断学习被控对象的前馈特性, 并将学习后的网络参数传送给 CNN I CNN I 模型的参数随着 NNI 的调整而更新, 直至完全收敛. 同时, 模糊神经网络在线自学习控制器 CNNC 根据每一控制周期得到的 CNN I 通过一个并行结构, 独立地对对象的逆动力学进行学习, 并利用运行监控器的协调作用, 不断的将网络参数切换至实时 NNC, 随着训练次数的增多, NNI 逐渐完善, 精确度逐步提高, NNC 逐步逼近对象的逆动态, 对系统的控制作用也将提高. 同时, RC 所起的作用逐渐削弱. 当 NNI 完全描述了对象的动态时, 训练后的 NNC 也将能完全描述对象的逆动态, 从而可独立的对系统实施高精确度的跟踪控制.

2.2 NNI 结构及训练

众所周知, T-S 型模糊推理模型的结论部分用线性局域方程取代了一般推理过程中的模糊数, 可以用少量的模糊规则生成较复杂的非线性函数. 另外, 径向基 (RBF) 网络可在任意精确度下逼近任意的非线性函数, 且不存在局部极小问题, 是一种品质好的网络. 因此, 本文在 T-S 型模糊推理系统与 RBF 神经网络函数等价原理的基础上, 采用将 T-S 型模糊推理系统与 RBF 神经网络相结合的 T-S 型模糊 RBF 神经网络结构来对系统进行控制^[4].

NNI 通过对系统输入 - 输出数据集的学习, 来逼近对象的前馈动力学. 在控制器设计中, 用来训练 NNC 并进行误差信号的反传. 该系统的 NNI 可描述为 $y_m(k+1) = f[y(k), y(k-1), \dots, y(k-n'+1), u(k), u(k-1), \dots, u(k-m'+1)]$ (6) 则网络的输入矢量: $X(k) = [y(k), y(k-1), \dots, y(k-n'+1), u(k), u(k-1), \dots, u(k-m'+1)]$ T-S 型模糊 RBF 神经网络结构如图 3 所示.

括模糊子映射和规则合成子映射, 表达了模糊控制规则的 IF 部分, 由图 3 可见, M_1 映射为第 1 至第 3 层, 它将输入变量映射到归一化的隶属函数:

$$\mu_i = \mu(\|X - \bar{c}_i\|) / \sum_{i=1}^m \mu(\|X - \bar{c}_i\|) \quad (7)$$

M_2 映射是指从模糊规则合成空间到输出空间的映射, 它表达的是模糊控制规则的 THEN 部分, 即图 3 中的第 4 层, 其中连接权函数为输入变量的一次多项式 $g_i(X) = \alpha_0^i + \alpha_1^i x_1 + \dots + \alpha_n^i x_n$, 映射结果为

$$y = \sum_{i=1}^m \mu_i(\|X - \bar{c}_i\|) g_i(X) / \sum_{i=1}^m \mu_i(\|X - \bar{c}_i\|) \quad (8)$$

网络中的误差由两部分组成: 一是结构参数引起的, 即网络中心值和径向基函数形状的估计误差; 另一是结论参数引起的, 即网络局域方程的估计误差. 因此, 要使网络总误差最小, 这两种误差均须达到最小. 设标准误差函数为^[5-6]

$$J(\mu, \bar{c}, \alpha) = p_1 \left[\sum_{k=1}^N \sum_{i=1}^m \mu_i(k)^y \|X(k) - \bar{c}_i\|^2 \right] + p_2 \left[\sum_{k=1}^N \sum_{i=1}^m \mu_i(k)^y e_i(k)^2 \right]$$

$$e_i(k) = y(k) - y'(k) = y(k) - \Phi(k) \alpha^i$$
$$\Phi(k)' = [1 \quad X(k)]$$
$$\alpha^i = [\alpha_0^i \quad \alpha_1^i \quad \dots \quad \alpha_n^i]$$
 (9)

式 (9) 中: N 是样本总数; m 为中心值的个数; y 为直接影响隶属函数形状的宽度函数; $\bar{c}_i = [c_{i1}, c_{i2}, \dots, c_{in}]^T$ 表示第 i 个中心值; $\|X(k) - \bar{c}_i\|$ 为第 k 个样本对于第 i 个中心的距离; α^i 为第 i 个结论参数估计; $\mu_i(k)$ 为第 k 个样本对于第 i 个中心的隶属度. 式 (9) 的第一项达最小, 即中心值的最优取值; 第二项达最小, 即网络的局域方程达最优估计. 通过选取优化因子 p_1 和 p_2 的值, 可调整优化的侧重程度. 采用聚类方法得到:

$$\left. \begin{aligned} \bar{c}_i &= \frac{\sum_{k=1}^N \mu_i(k)^y X(k)}{\sum_{k=1}^N \mu_i(k)^y}, \quad i = 1, 2, \dots, m \\ \alpha^i &= [\Phi^T D_i \Phi]^{-1} \Phi^T D_i Y \end{aligned} \right\} \quad (10)$$

$$\Phi = [\Phi(1), \Phi(2), \dots, \Phi(N)]^T$$
$$Y = [y(1), y(2), \dots, y(N)]^T$$
$$D_i = \text{diag}[\mu_i(k)^y]_{N \times N}$$

如果 $p_1 \|X - \bar{c}_i\|^2 + p_2 e_i(k)^2 \neq 0 \quad \sigma = 1/N - 1$ 则:




图 3 T-S 型模糊 RBF 神经网络结构

T-S 型模糊 RBF 神经网络可完成模糊合成推理映射 M_1 和输出映射 M_2 , 且输出层权函数为输入变量一次多项式的 RBF 神经网络. 这里, M_1 映射是指从输入变量空间到模糊规则合成空间的映射, 它包

$$\mu_i(k) = \left\{ [p_1 \|X(k) - \bar{c}_i\|^2 + p_2 e_i(k)^2]^o \times \sum_{j=1}^m \left[\frac{1}{p_1 \|X(k) - \bar{c}_j\|^2 + p_2 e_j(k)^2} \right]^o \right\}^{-1}$$

否则
$$\mu_j(k) = \begin{cases} 1 & j = i \\ 0 & j \neq i \end{cases} \quad (11)$$

当用式(10)、(11)聚类方法得到中心值后, 网络的结构就确定了. 由式(10)、(11)算法直接导出的隶属函数为钟型函数:

$$\mu_i(k) = \left[\frac{\|X(k) - \bar{c}_i\|^{2o}}{\sum_{j=1}^m \|X(k) - \bar{c}_j\|^{2o}} \right]^{-1} \quad (12)$$

归纳以上聚类方法, 该网络的学习步骤为^[7-8]:

1) 选取优化因子 p_1, p_2 和隶属函数形状系数 α , 选取中心个数 m . 给定学习终结参数 ξ 误差函数参数 ξ 和初始隶属度 $\mu_i(0)$;

2) 根据式(10)、(11)计算修改 $\mu_i(k)$;

3) 当 $\|\mu_i(k+1) - \mu_i(k)\| > \xi$ 重复步骤 2);

4) 当所有采样点 $(X(k), y(k))$ 的平方和误差

函数 $e^2 = \sum_{k=1}^N \|y(k) - y'(k)\|^2 \leq \xi$ 学习结束. 否则, 增加中心值个数 m , 重复步骤 1) - 4).

下面讨论网络局域方程的学习, 目标函数为

$$E_{NN1} = \frac{1}{2} [v_m(k+1) - v(k+1)]^2, \text{ 有:}$$

$$\begin{aligned} \frac{\partial E_{NN1}}{\partial \alpha^i(k)} &= - (v_m(k+1) - v(k+1)) \times \\ &\left[\frac{\partial v(k+1)}{\partial \alpha_0^i(k)}, \frac{\partial v(k+1)}{\partial \alpha_1^i(k)}, \dots, \frac{\partial v(k+1)}{\partial \alpha_n^i(k)} \right] = \\ &- (v_m(k+1) - v(k+1)) \frac{\mu_i}{\sum_{j=1}^m \mu_j} \times \\ &[1 \ x_1(k), \dots, x_n(k)] \end{aligned} \quad (13)$$

由此可得:

$$\begin{aligned} \Delta \alpha^i(k) &= -\beta \frac{\partial E_{NN1}}{\partial \alpha^i(k)} = \beta (v_m(k+1) - v(k+1)) \frac{\mu_i}{\sum_{j=1}^m \mu_j} \\ &[1 \ x_1(k), \dots, x_n(k)] \end{aligned} \quad (14)$$

式中 β 为学习率 ($0 \leq \beta \leq 1$).

2.3 NNC 的结构及训练

为了使被控系统准确的跟踪任意给定的参考输入信号, NNC 通过对输入-输出数据对的学习, 不断逼近对象的逆动力学, 然后根据系统的理想输出, 产生相应的理想的控制输入, 使系统的输出跟踪误差为零.

$$u(k) = f^{-1}(X_u(k)) = g'(X_u(k)) \quad (15)$$

由于可用模型 CNNC 的输出来代替系统的实际输出, 则 CNNC 中 $X_u(k)$ 可描述为

$$X_u(k) = [r(k+1), y_{pm}(k), \dots, y_{pm}(k-n'+1), u_{pn}(k-1), \dots, u_{pn}(k-m'+1)] \quad (16)$$

其网络结构同图 3 所示, 且中心值及网络隶属函数的求取同上述 NN1 的聚类方法. 由于系统是时变不确定的, 代表系统前馈动力学的 NN1 不断处于动态自适应调整中, 因此, 表示系统逆动力学的 CNNC 也相应的在每一采样周期训练一次. 目标函数为^[9]

$$E_{CNNC} = \frac{1}{2} (r(k+1) - y_{pm}(k+1))^2 \quad (17)$$

则网络局域方程的学习为

$$\begin{aligned} \frac{\partial E_{CNNC}}{\partial \alpha^i(k)} &= - (r(k+1) - y_{pm}(k+1)) \frac{\partial y_{pm}(k+1)}{\partial u_{pn}(k)} \frac{\partial u_{pn}(k)}{\partial \alpha^i(k)} = \\ &- (r(k+1) - y_{pm}(k+1)) \frac{\partial y_{pm}(k+1)}{\partial u_{pn}(k)} \times \\ &\left[\frac{\partial u_{pn}(k)}{\partial \alpha_0^i(k)}, \frac{\partial u_{pn}(k)}{\partial \alpha_1^i(k)}, \dots, \frac{\partial u_{pn}(k)}{\partial \alpha_n^i(k)} \right] = - (r(k+1) - \\ &y_{pm}(k+1)) \frac{\partial y_{pm}(k+1)}{\partial u_{pn}(k)} \frac{\mu_i}{\sum_{j=1}^m \mu_j} [1 \ x_1(k), \dots, x_n(k)] \end{aligned} \quad (18)$$

$$\begin{aligned} \text{且有, } \Delta \alpha^i(k) &= -\beta \frac{\partial E_{CNNC}}{\partial \alpha^i(k)} = \beta (r(k+1) - y_{pm}(k+1)) \frac{\partial y_{pm}(k+1)}{\partial u_{pn}(k)} \frac{\mu_i}{\sum_{j=1}^m \mu_j} \\ &[1 \ x_1(k), \dots, x_n(k)] \end{aligned}$$

训练中 $\frac{\partial y_{pm}(k+1)}{\partial u_{pn}(k)}$ 未知, 可以直接由 CNN1 经变形获得:

$$\begin{aligned} \frac{\partial y_{pm}(k+1)}{\partial u_{pn}(k)} &= \frac{\partial y_{pm}(k+1)}{\partial x_i(k)} = \frac{\mu_i}{\sum_{l=1}^m \mu_l} \alpha_l^i(k) + \\ &\frac{\partial g_i(X)}{\partial x_i(k)} \frac{\partial \mu_i(k)}{\partial x_i(k)} \end{aligned} \quad (19)$$

至此 T-S 型模糊 RBF 神经网络训练完毕.

2.4 运行监控器及鲁棒控制器

运行监控器是该设计中的重要环节, 其作用是对系统的控制品质进行评估, 当系统的控制品质下降到一定程度时, 它将通过并行自学习结构训练好的 CNNC 的参数切换到实时控制器 NNC, 使系统输出跟踪参考输入. 对复杂而快速响应的系统, 采用瞬

态误差评定准则 $A = |e(k)| < \varepsilon$ 其中 ε 通常取为系统的稳态跟踪精度度^[10].

鲁棒反馈控制器 RC, 当 NNI 有偏差, 或学习尚未完全收敛时, 鲁棒控制器 RC 产生反馈控制信号, 保证控制过程的连续性和闭环系统的稳定性. 这里, 鲁棒控制器 RC 设计为一固定增益的比例控制器, 控制方程为

$$u_r(k) = K_r e_r(k)$$

(20)

其中: K_r 为控制器增益; $e_r(k)$ 为系统输出跟踪误差.

3 在电液伺服系统中的仿真应用^[5]

根据系统式 (3) 中的描述, 差分方程 $v(t+1) = f(u(t), P_l(t), P_l(t-1))$ 可进行进一步化简: 考虑到由于油缸容积 V_l 很小, 而油的弹性模量 β_e 很大 (约 $7 \sim 10 \times 10^8 \text{ Pa}$), 因此 $\dot{P}_l$ 对油缸速度的影响很小 ($< 5\%$); 另外考虑到 $\dot{P}_l$ 与 V_l 成线性关系, 而与 $u(t), P_l(t)$ 没有耦合关系, 这样 $\dot{P}_l(t)$ 就可以从网络中分离出来, 只作为一个线性补偿, 或者不取 $\dot{P}_l(t)$ 信号, 这对系统辨识精确度也几乎没有影响, 实际上如压力信号含有噪声的话, 引入 $\dot{P}_l(t)$ 反而不如忽略其影响. 则 NNI 的输入即为 $P_l(k)$ 和 $u(k)$. 根据参考文献 [5] 中的系统构造参数的选择方法进行 NNI、NNC 及 RC 的构造.

3.1 NNI 的构造

由上述可知 NNI 有两个输入量, 即 $n = 2$ 选取 $p_1 = 1, p_2 = 1, \zeta = 0.08, \xi = 1, \beta = 0.9, \gamma = 2$ 聚类后得到 $m = 8$ 个局域方程. 则 T-S 型模糊 RBF 神经网络结构可以确定下来.

3.2 NNC 的构造

同理, NNC 的结构中 $n = 3$ 选取 $p_1 = 2, p_2 = 1, \zeta = 0.07, \xi = 1, \beta = 0.86, \gamma = 2$ 聚类后得到 $m = 16$ 个局域方程.

3.3 RC 的构造

鲁棒控制器 RC 的比例系数取为 $K_r = 1$, 鲁棒因子的变鲁棒系数取为 $\tau = 0.5$ 取 $\varepsilon = 10^{-3}$. 为确保控制精确度, 在参考信号和反馈信号送入控制器进行运算之前, 应进行归一化处理.

3.4 仿真结果

将本文方案与传统的 BP 神经网络的仿真结果进行比较. BP 神经网络的结构如图 4 所示. BP 神经网络模型拓扑结构包括输入层、隐层和输出层. 其中单个神经元的输入输出关系如图 5 所示. 可见, 单个

神经元的输出是其上所有阈值代数之和的 $\tan \text{sig}$ 函数.




图 4 BP 神经网络结构示意图




图 5 BP 神经元

BP 神经网络选用单隐层结构, 输入输出均选用 3 个节点, 隐层选用 4 个节点. 则经过仿真, BP 神经网络的权值和阈值为

$W_1 =$	- 0.0029	0.0237	- 0.0098	$b_1 =$	- 2.4894
	- 0.0088	0.0095	- 0.0122		3.4834
	- 0.0098	0.0019	- 0.0004		1.9623
	0.0792	- 0.1199	0.0324		1.9752
	0.0067	0.0341	- 0.0129		- 5.2871
	0.0030	0.0104	- 0.0129		- 2.2328
	- 0.0043	- 0.0142	- 0.0127		3.9847
	- 0.0011	- 0.0016	0.0085		- 1.2996
	0.1392	- 0.1281	- 0.0141		1.9118
	0.0094	0.0879	- 0.0807		- 5.0905
	- 0.0031	0.0244	- 0.0208		- 0.5144
	- 0.0214	- 0.0529	0.0058		4.8162
	0.2393	0.4086	0.1712	$b_2 =$	- 0.1068
	1.1705	0.7430	- 0.0577		0.1532
	- 0.04251	- 0.3157	- 0.1085		1.1378
	0.0684	0.0553	0.0018		
	0.0064	- 0.0457	- 0.1109		
	- 0.0941	- 0.2796	0.0034		
	0.0283	0.0191	0.0731		
	0.8756	0.7501	1.4704		
$W_2 =$	0.2924	0.1938	0.3203		
	- 0.0023	- 0.0136	- 0.0116		
	0.1497	0.1433	0.0429		
	0.0162	- 0.0207	0.0164		

理想情况下的跟踪控制用来测试神经网络的学习性能.并且与用一般的 BP神经网络控制的电液伺服系统进行仿真比较,在训练了 2 000步之后,它们跟踪方波的仿真曲线如图 6所示.




图 6 系统仿真曲线

本方案仿真结果与给定方波的误差曲线如图 7 所示.




图 7 误差 e 曲线

由图 6可以看出,曲线 1是采用 T-S型模糊 RBF神经网络方案,经过有限次在线学习后的仿真结果,曲线 2是采用一般 BP网络的仿真结果.图 7中误差曲线中偏差 e 基本都在 $-0.5 \sim 0.5$ 之间,可看出所设计出的控制方案可实现系统的跟踪控制且优于一般的 BP网络.

4 结 语

通过引入鲁棒因子,将模糊神经网络控制与传统的控制方法有机的结合起来,实现了对象模型的在线自适应跟踪辨识和在线动态控制器的设计;NNC采用并行结构进行训练,其参数调整独立于系统的实时控制,有效地解决了普通模糊神经网络控制方法通常存在的实时性差的问题,使复杂系统的在线控制成为可能.

参 考 文 献:

- [1] 蔡文秀. 模糊神经网络在过程控制中的应用 [D]. 北京: 北京化工大学, 2006 35- 45.
- [2] 郭庆鼎, 孙燕娜. 直线永磁同步伺服电动机的 H_{∞} 鲁棒自适应控制 [J]. 电工技术学报, 2000, 2(4): 16- 18
- [3] 王晓兰, 王慧中, 杨智, 等. 模糊神经网络实现的参数自校正控制 [J]. 电工技术学报, 2004 5(11): 66- 69
- [4] 鲍鸿, 黄心汉, 李锡雄. T-S模糊 RBF神经网络多变量自适应控制器的研究 [J]. 广东工业大学学报, 2002, 4(16): 73- 79
- [5] 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 35- 45.
- [6] 陈章位. 电液伺服系统故障诊断技术的研究 [J]. 中国机械工程, 2000, 5(11): 75- 82
- [7] 何洪, 孙薇. 基于 RBFCNN网络的电液伺服系统的动态补偿控制算法 [J]. 中国机械工程, 2001, 2(12): 120- 123
- [8] 陈奕梅, 赵锡玲. 基于遗传算法的模糊控制仿真研究 [J]. 电脑开发与应用, 2001 3(14): 45- 47
- [9] 刘军, 张光辉, 李强, 等. 一种基于遗传算法的输油泵模糊控制器 [J]. 自动化仪表, 2001 10(22): 62- 64
- [10] 滕树杰, 张乃尧. 分层模糊控制器的解析表达式及自适应控制法 [J]. 清华大学学报, 2002 9(42): 23- 26

(编辑: 温泽宇)