

神经网络非线性多步预测逆控制方法研究 *

魏 东, 刘 熙, 张 龙

(北京建筑工程学院 电气与信息工程学院, 北京 100044)

摘 要: 提出了基于多步预测控制方法的多变量非线性神经网络逆控制方案。利用预测模型对系统动态特性进行预测,使用一个带有时延因子的前馈神经网络作为控制器,利用多步预测性能指标对其在线训练,实现神经网络逆系统;在多步预测过程中还对每一步的预测误差进行预测,以实现预测误差补偿。将所提出的控制算法用于锅炉这种大滞后非线性对象的控制,仿真实验证明,该控制策略具有良好的解耦和动态跟踪性能。

关键词: 神经网络; 预测控制; 逆控制; 非线性系统

中图分类号: TP273+.5 文献标志码: A 文章编号: 1001-3695(2012)01-0211-03

doi:10.3969/j.issn.1001-3695.2012.01.059

Multi-step predictive inverse control based on neural networks

WEI Dong, LIU Xi, ZHANG Long

(School of Electric & Information Engineering, Beijing University of Civil Engineering & Architecture, Beijing 100044, China)

Abstract: This paper developed a neural-network inverse control scheme for nonlinear MIMO discrete systems based on multi-step prediction. Used a predictive model for predicting dynamic characteristics of the system. A neural network with time-delay modules acted as the inverse controller, which was trained with predictive optimization algorithm to implement the inverse system. Used another neural network to model the prediction error to compensate for the predictive output. Simulation results illustrate that the control strategy has a favorable decouple and dynamic tracking performance to nonlinear systems.

Key words: neural networks; predictive control; inverse control; nonlinear systems

与一般意义下的逆系统方法相比,神经网络逆系统方法具有更广的应用范围,可以较大程度地简化控制系统设计问题。但是,由于不可避免地存在建模误差,而逆系统方法对建模误差的鲁棒性是不尽人意的,因此给逆控制系统的设计带来了困难;而其他不确定因素,如难以避免的干扰等,又会造成系统的抖动,使系统鲁棒性较差。本文将多步预测控制的滚动优化和反馈校正思想应用于非线性系统的逆控制器设计,并在控制过程中对预测误差进行逐步校正,以便能够克服时变、不确定性及环境干扰等引起的模型失配的影响,实现非线性多变量时变系统的解耦控制。

1 控制算法描述

1.1 多变量系统的相对阶

考虑多输入、多输出非线性系统 Σ :

$$x[k+1]=f(x[k],u[k]),y[k]=h(x[k]),x[0]=x_0\sim P(x_0)\quad(1)$$

其中: f,h 为解析函数, $k=0,1,2\cdots$ 表示当前时刻,输入 $u[k]$ 、状态变量 $x[k]$ 和输出 $y[k]$ 分别属于 R^r 、 R^n 和 R^m , x_0 是初始状态值, $P(x_0)$ 表示与 x_0 相关的概率分布。

对于式(1)表示的非线性系统 Σ ,若存在开紧集 $\Omega\subset R^{n+m}$,当 $(x,u)\in\Omega$,对于 $i=1,2,\cdots,m,j=1,2,\cdots,r$,如果 d_i 满足 $\frac{\partial y_i[k+p_{ij}]}{\partial u_j[k]}=0,p_{ij}<d_i$,即 $\frac{\partial}{\partial u}(h_i\circ f^p)=0,p=0,1,\cdots,d_i-1$ 。

而如果至少有一个 j 存在,使得 $\frac{\partial y_i[k+d_i]}{\partial u_j[k]}$ 不恒为零,即 $\frac{\partial}{\partial u}(h_i\circ f^p)$ 不恒为零, $p=d_i$,其中 $d_i\leq n,d_i$ 为正整数,则称系统(1)具有相对阶 $\{d_1,d_2,\cdots,d_m\}^{[1]}$ 。

引理 对于离散 MIMO 非线性系统 Σ (式(1)),若存在 $\Omega\subset R^{n+r}$,在 Ω 内,系统 Σ 的相对阶 $\{d_1,d_2,\cdots,d_m\}$ 存在,状态向量 $x[k]$ 有界,且系统 Σ 的零动态子系统渐近稳定,则存在控制量序列,或者可使系统 Σ 解耦,或者可使系统输出精确跟踪期望输出^[2]。

若系统 Σ 具有时滞特性,在 Ω 内相对阶 $\{d_1,d_2,\cdots,d_m\}$ 存在,且 Σ 在 Ω 内是可观测的,则可将系统 Σ 用 NARMA 模型表示为^[3]

$$Y_d[k]=\begin{bmatrix}y_1[k+d_1] \\ y_2[k+d_2] \\ \cdots \\ y_m[k+d_m]\end{bmatrix}=\begin{bmatrix}g_1(y[k],\cdots,y[k-n+1],u[k],\cdots,u[k-n+1]) \\ g_2(y[k],\cdots,y[k-n+1],u[k],\cdots,u[k-n+1]) \\ \cdots \\ g_m(y[k],\cdots,y[k-n+1],u[k],\cdots,u[k-n+1])\end{bmatrix}\quad(2)$$

则系统 Σ 的逆模型可表示为

$$\begin{aligned}u[k]&=h_d^{-1}(y[k],y[k-1],\cdots, \\ &y[k-n+1],Y_d[k],u[k-1],\cdots,u[k-n+1])\end{aligned}\quad(3)$$

1.2 神经网络输出预测模型和预测误差补偿

对象的输出预测模型为

$$\begin{aligned}\hat{Y}_d[k]&=N_f(y[k],y[k-1],\cdots,y[k-n+1], \\ &u[k],u[k-1],\cdots,u[k-n+1],W_f)+Y_{e,d}[k]\end{aligned}\quad(4)$$

收稿日期: 2011-05-04; 修回日期: 2011-06-09 基金项目: 国家住建部科技计划资助项目(2010-K6-3); 北京市自然科学基金资助项目(8072008)

作者简介: 魏东(1968-),女,重庆人,教授,博士,主要研究方向为智能控制、神经网络控制(weidong_999@163.com); 刘熙(1985-),男,硕士,主要研究方向为神经网络控制; 张龙(1983-),男,硕士,主要研究方向为预测控制。

其中: W_l 为神经网络输出预测模型的权值阵(包括阈值), $Y_{e,d}$ $[k]$ 为预测误差补偿项。输出预测模型需要通过离线辨识获得, 可以选用 BP 或径向基函数神经网络实现。

对于多步预测控制, 若仅用当前时刻误差进行校正, 即用一个时刻的误差校正多步输出预测值, 在递推过程中会严重影响预测精度。本文在建立对象输出预测模型后, 利用另一个神经网络离线辨识预测误差模型, 然后在控制过程中进行预测误差补偿校正。误差预测神经网络可表示为

$$\hat{Y}_{e,d}[k] = \begin{bmatrix} y_{1e}[k+d_1] \\ y_{2e}[k+d_2] \\ \vdots \\ y_{me}[k+d_m] \end{bmatrix} = \begin{bmatrix} \Gamma_1(y[k], \dots, y[k-n+1], u[k], \dots, u[k-n+1]) \\ \Gamma_2(y[k], \dots, y[k-n+1], u[k], \dots, u[k-n+1]) \\ \vdots \\ \Gamma_m(y[k], \dots, y[k-n+1], u[k], \dots, u[k-n+1]) \end{bmatrix} \quad (5)$$

预测误差模型采用输出预测模型和被控对象输出之间的偏差进行离线训练, 可以选用 BP 或径向基函数神经网络实现。

1.3 神经网络逆控制器结构

神经网络逆控制器方程可取

$$\begin{aligned} u[k] &= N_C(y[k], y[k-1], \dots, y[k-n+1], \\ &Y_d^*[k], u[k-1], \dots, u[k-n+1], W_C) \end{aligned} \quad (6)$$

其中: $Y_d^*[k]$ 为 $Y_d[k]$ 的期望值; W_C 为神经网络逆控制器的权值阵(包括阈值)。控制器采用三层前馈神经网络, 网络的输入层有 $(n+1)m+(n-1)r+1$ 个神经元, 输入量分别为 $Y_d^*[k], y[k], y[k-1], \dots, y[k-n+1], u[k-1], \dots, u[k-n+1]$ 和 -1 , 其中, -1 为与神经网络隐层神经元阈值有关的输入, 加上这个 -1 后, 各个隐层神经元的阈值可以作为权值一般对待; 输出层有 r 个神经元, 输出量为 $u[k]$ 。

1.4 预测优化性能指标

取 $d' = \min\{d_1, d_2, \dots, d_m\}$ 。控制目的是找出控制量序列 $u[k] (k=0, 1, 2, \dots)$, 使得如下性能指标达到最小:

$$\begin{aligned} J_N &= \frac{1}{2} (y[N] - y^*[N])^T S [N] (y[N] - y^*[N]) + \\ &\frac{1}{2} \sum_{k=0}^{N-d'-1} (\hat{Y}_d[k] - Y_d^*[k])^T Q (\hat{Y}_d[k] - Y_d^*[k]) + \\ &\frac{1}{2} \sum_{k=0}^{N-d'} (u[k] - u[k-1])^T R (u[k] - u[k-1]) \end{aligned} \quad (7)$$

其中, N 为系统的整个控制时间范围。末值状态加权阵 $S[N]$ 和状态加权阵 Q 为半正定阵, 控制加权阵 R 为正定阵。对于预测控制来说, 由于采用的是滚动优化算法, 因此需要在预测时域内进行优化求解。

设 M 为预测步数, 即预测时域, 假设该预测时域内的初始时刻为 t_1 , 则在预测时域范围内的性能指标 J 要分两种情况讨论。

$$\begin{aligned} \text{记 } L(k) &= (\hat{Y}_d[k] - Y_d^*[k])^T Q (\hat{Y}_d[k] - Y_d^*[k]) + \\ &(u[k] - u[k-1])^T R (u[k] - u[k-1]) \end{aligned}$$

当 $k < N - M$ 时

$$J = \frac{1}{2} \sum_{k=t_1}^{t_1+M-d'} L[k] \quad (8)$$

当 $k \geq N - M$ 时

$$\begin{aligned} J &= \frac{1}{2} (y[N] - y^*[N])^T S [N] (y[N] - y^*[N]) + \\ &\frac{1}{2} \sum_{k=N-M}^{N-d'-1} L[k] \end{aligned} \quad (9)$$

在整个控制算法中, 预测时域 M 的取法非常重要, 其与系统 Σ 的相对阶数、采样时间间隔和干扰信号周期有关。预测时域如果选得过小, 快速性会有所提高, 但系统稳定性和鲁棒性会变差; 如果选得过大, 其鲁棒性会提升, 但动态响应变慢。

在实际应用中需要折中考虑。

1.5 神经网络逆控制器训练

基于预测控制思想的神经网络逆控制系统框图如图 1 所示, 图中的 TDL(time delay line) 表示时延线; 图中的 N_l 为被控对象的输出预测模型, 其结构如式(4)所示, 预测模型 N_C 为神经网络逆控制器, 其结构如式(6)所示。逆控制器训练的目的是实现被控对象的逆系统。




图1 神经网络多步预测逆控制系统结构图

网络训练算法如下:

a) 初始化控制器神经网络, 将神经网络的各个连接权值设为较小的随机数; 选定预测时域 M 以及控制器神经网络的权值更新率 μ (又称为学习率)。

b) 在状态空间中根据概率分布 $x[0] = x_0 \sim P(x_0)$ 选择状态初值, 若状态向量不易获知, 则可以选择输出量的初值。

c) 设当前时刻为 $k=t_1$, 在预测时域内, 根据控制目标, 设置期望输出 $Y_d^*[k] (k=t_1, t_1+1, \dots, M-d')$ 在各个时刻的值。

d) 按照图 1 所示结构, 将 $y[t_1], \dots, y[t_1-n+1], Y_d^*[t_1], u[t_1-1], \dots, u[t_1-n+1]$ 和 -1 作用于神经网络控制器, 得到控制量 $u[t_1]$, 然后将 $u[t_1]$ 作用于被控对象, 得到 $y[t_1+1]$, 将 $u[t_1]$ 和其他相关参数作用于神经网络输出预测模型, 并进行预测误差补偿, 得到 $\hat{Y}_d[t_1]$ 。

e) 保持控制器神经网络权值不变, 将 $y[t_1+1], \dots, y[t_1-n+2], Y_d^*[t_1+1], u[t_1], \dots, u[t_1-n+2]$ 和 -1 作用于神经网络控制器, 得到 $u'[t_1+1]$; 将 $u'[t_1+1]$ 和其他相关参数作用于神经网络输出预测模型, 并进行预测误差补偿, 得到 $\hat{Y}_d[t_1+1]$ 。

f) 将预测模型曾预测出并经过预测误差补偿的 $\hat{y}[t_1+2]$ 以及 $y[t_1+1], \dots, y[t_1-n+3], Y_d^*[t_1+2], u'[t_1+1], \dots, u[t_1-n+3]$ 和 -1 作用于神经网络控制器, 得到 $u'[t_1+2]$; 将 $u'[t_1+2]$ 和其他相关参数作用于预测模型, 并进行预测误差补偿, 得到 $\hat{Y}_d[t_1+2]$ 。依此类推, 利用控制器神经网络和预测模型推算出未来的 $u'[t_1+i]$ 和 $\hat{Y}_d[t_1+i]$ 值 ($i=3, \dots, M-d'$), 并将所计算数据保存起来。

g) 对于 $k=t_1, t_1+1, t_1+2, \dots, t_1+M-d'$, 利用 d) ~ f) 计算出的结果, 通过式(10)修正神经网络控制器的权值, 其中, W_C 是神经网络控制器的权值阵:

$$\begin{aligned} \Delta W_C &= -\mu \sum_{k=t_1}^{t_1+M-d'} \frac{\partial L(k)}{\partial W_C} \\ W_C &= W_C + \Delta W_C \end{aligned} \quad (10)$$

h)重复 e) ~ g) 操作,不断修改神经网络的权值,直至 $\Delta W_c = 0$ 。

i)令 $t_1 = t_1 + 1$,重复 c) ~ h)操作,分别计算出以后各个时刻控制量的值,直至控制过程结束。

其中,
$$\frac{\partial L(k)}{\partial W_c} = \frac{\partial N_c(k, W_c)^T}{\partial W_c}$$

$$\left\{ \frac{\partial N_f(k, W_f)^T}{\partial u[k]} Q(\hat{Y}_d[k] - Y_d^*[k]) + R(u[k] - u[k-1]) \right\} \quad (11)$$
 式(11)中的 $u[k]$ 可以用 $u'[k]$ 代替;若有被控对象的数学模型,式中的 $\frac{\partial N_f(k, W_f)}{\partial u[k]}$ 可用对象函数的输出对 $u[k]$ 的偏导代替。对于 $k \geq N - M$ 时间范围内的性能指标还需考虑末值性能指标的影响。

虽然在步骤 c) ~ g) 的预测算法中可以计算出由 t_1 时刻直到 $t_1 + M - d'$ 时刻的控制量,但是在 d) 只取 $u[t_1]$ 的值施加给被控对象,其后 $u[t_1 + 1], u[t_1 + 2], \dots$ 的值还需在以后各次循环中重新计算,这就是预测控制滚动优化作用的体现。

1.6 神经网络输出预测模型修正

在神经网络控制器训练算法中的 d) 中,将 $u[t_1]$ 作用于被控对象得到 $y[t_1 + 1]$,此时,可利用神经网络输出预测模型曾预测出的 $\hat{y}[t_1 + 1]$ 值对神经网络输出预测模型进行在线修正。模型在线修正的性能指标函数为

$$J_2 = \frac{1}{2} (y[t_1 + 1] - \hat{y}[t_1 + 1])^T (y[t_1 + 1] - \hat{y}[t_1 + 1]) \quad (12)$$

神经网络输出预测模型权值(包括阈值)的在线修正为
$$\Delta W_f = -\mu_2 \frac{\partial J_2}{\partial W_f} = -\mu_2 \frac{\partial N_f(t_1, W_f)^T}{\partial W_f} (y[t_1 + 1] - \hat{y}[t_1 + 1])$$

$$W_f = W_f + \Delta W_f \quad (13)$$

其中: μ_2 为神经网络输出预测模型的权值更新率。
需要注意的是,如果所控制的对象是不稳定的,那么直接利用逆控制方法去实现一个稳定而又控制良好的系统是不可能的,其原因是驱动不稳定对象的前馈控制器将使对象仍不稳定,因此必须先对不稳定对象进行稳定,然后再对稳定后的对象进行逆控制。此外,如果对象是非最小相位系统,那么它的逆是不稳定的,此时需要在控制器引入附加的延迟环节或构造伪系统,以实现系统的稳定逆控制^[4,5]。

2 算法应用研究

2.1 被控对象

对于多容锅炉这种具有大滞后的非线性被控对象,传统控制方法很难取得良好的控制效果,本文采用所提出的神经网络逆控制方法对某电加热锅炉对象进行了控制。该电加热锅炉采用不锈钢制成,共有三层,即加热层(又称为内筒)、冷却层(又称为外筒)和溢流层。
加热层中安装有电加热丝,通过控制器提供的电流控制加热功率;冷却层中流有循环水,可以使加热层中水的热量散发,水温下降,加热层也可以使冷却层的水温上升。该锅炉为两路输入、两路输出的大滞后强耦合非线性对象,两路控制量分别为加热层(又称为内筒)电加热丝加热功率和冷却层(又称为外筒)水流管道水流量,均取 4 ~ 20 mA 的电流进行控制;输出量分别为加热层水温和冷却层水温。

2.2 被控对象输出预测模型和预测误差模型辨识

此处采用 BP 神经网络对被控对象进行输出预测模型辨识,建立锅炉对象的一步预测模型。神经网络模型的输入量有 8 个,分别为本时刻和上一时刻的冷却层水流电动阀门控制电流和加热层电热丝加热功率控制电流、本时刻和上一时刻的加热层水温和冷却层水温;将神经网络预测模型的输出量取为 1 min 后(即下一时刻)的加热层水温和冷却层水温;隐层神经元个数为 10。在进行输出预测模型辨识前采集了锅炉对象的输入和输出数据,在数据采集过程中注意使数据覆盖对象的整个动态范围,共取得了 3 000 组训练样本,采用贝叶斯正规化方法训练神经网络,以提高预测模型的泛化能力^[6]。

输出预测模型建立后利用训练输出预测模型训练样本集中的测试数据对输出预测模型进行检验,利用检验误差,即预测模型输出和被控对象实际输出之间的偏差对预测误差神经网络进行了训练。预测误差神经网络采用 BP 网络,其输入信号与输出预测模型相同,输出信号为加热层水温和冷却层水温的预测误差,隐层神经元个数也选 10 个。训练好的预测误差神经网络用于对输出预测模型进行预测误差补偿,以提高控制精度。

2.3 控制策略

在获得所需要的模型之后,利用本文提出的控制方法对锅炉对象进行了控制系统仿真。控制系统的采样时间间隔为 1 min,控制目的是使加热层水温和冷却层水温能够跟踪设定温度。经过实验,预测时域取 6 步,此处取 $d_1 = d_2 = 1$ 。

神经网络逆控制器输入量有 9 个,分别对应本时刻和前一时时刻的加热层水温和冷却层水温、下一时刻加热层水温和冷却层水温的期望输出值、前一时时刻的加热层电加热丝加热功率控制电流和冷却层水流量电动阀门开度控制电流,以及 -1;隐层选用 10 个神经元,隐层神经元激发函数取双曲正切函数;输出层有 2 个神经元,分别对应本时刻加热层电加热丝加热功率控制电流和冷却层水流量电动阀门开度控制电流,输出层神经元激发函数取线性函数。如 1.5 节所述,在进行在线寻优之前需要初始化控制器神经网络,将神经网络的各个连接权值设为较小的随机数。

2.4 控制结果

加热层水温和冷却层水温的初始值分别取 0℃ 和 20℃,控制结果如图 2 ~ 5 所示。可以看出,控制系统实现了解耦控制,且具有良好的动态跟踪性能;而且状态变量初值不同的情况下系统响应的动态曲线基本一致,同时逆控制器的神经网络连接权值初值均为随机产生的数值,说明系统性能对初值不敏感。由上述分析可以得出,采用本文提出的控制算法,可以实现对多容电加热锅炉这类非线性滞后被控对象的稳定解耦控制,动态跟踪性能良好。




图2 初始水温为0℃时内筒水温控制结果




图3 初始水温为0℃时外筒水温控制结果

求将符合条件的物流资源动态整合到一起,启动物流服务执行,并通过智能技术实现对物流过程的智能调度、全程监控和运行协调;同时平台对物流功能提供者执行过程中进行信息收集和记录,并进行质量评价和信用数据生成,为日后的物流服务提供支撑。

通过汽车物流云服务平台,汽车供应链的成员可以快速、便捷、优质价廉、按需获取满意甚至超值的个性化物流服务;对于物流服务提供商而言,他们能够更便捷地获取客户需求,快速建立服务,低价地为客户提供个性化的物流服务。显然这是一个供需双方双赢的过程。

5 结束语

针对目前物流服务方式在推广和应用方面存在的瓶颈问题,尤其是客户无法获取快速、便捷、满意的物流服务的问题,本文提出了一种面向供应链的物流服务新模式——物流云服务,该模式将现有的物流服务模式、云计算、云安全、服务工程、物联网、RFID 等技术融合于一体,为物流业中诸多需求提供了新的思路和解决方案。本文围绕物流云服务的背景、概念、特征、业务架构、技术架构以及实施的关键技术等问题进行了初步的研究和探讨,同时针对物流云服务的应用和推广问题,本文初步设计了面向汽车产业的物流云服务模式,以验证该模式的可行性,同时为其他产业的物流服务模式提供参考和借鉴。

物流云服务具有美好的应用前景和推广价值,但是目前关于物流云服务的研究尚处于起步阶段,物流云服务技术的实现还有大量的工作要做,如云服务模式、云端化技术、云服务平台的开发、云服务标准等。下一步将重点结合我国物流业的实际需求对物流云服务相关技术和问题展开更深入的研究,以尽快推动物流云服务的“落地”,提升我国物流业服务水平和信息化水平。

参考文献:

[1] 龙跃,易树平. 两阶段决策下物流任务联盟协同管理优化[J]. 计

算机集成制造系统,2010,16(4):802-809.

- [2] 王若钢,冯英俊. 虚拟物流企业联盟的利益分配策略研究[J]. 控制与决策,2008,23(10):1087-1090.
- [3] 桂云苗,龔本刚,程幼明. 需求不确定下物流服务供应链协调[J]. 计算机集成制造系统,2009,15(12):2412-2416.
- [4] 刘伟华,季建华,周乐. 两级物流服务供应链任务分配模型[J]. 上海交通大学学报,2008,42(9):1524-1528.
- [5] BIAN Wen-liang, JU Song-dong. Grid and logistic networks[J]. Dynamics of Continuous Discrete and Impulsive Systems, Series B: Applications and Algorithms, 2005(7):641-645.
- [6] 宁方华,陈子辰,熊励,等. 协同物流网络的任务协调决策模型及其求解算法[J]. 控制与决策,2007,22(1):109-112.
- [7] 鞠颂东,徐杰. 物流网络理论及其研究意义和方法[J]. 中国流通经济,2007(8):10-13.
- [8] LIN Zi-kui, CHEN Lei. Multi-target optimization model of logistics resources allocation[C]//Proc of the 8th International Conference on Machine Learning and Cybernetics. 2009:2587-2592.
- [9] SIMS K. IBM introduces ready-to-use cloud computing collaboration services get clients started with cloud computing[EB/OL]. 2007. http://www-03.ibm.com/press/us/en/press_release/22613.wss.
- [10] Amazon. Amazon elastic compute cloud (amazon EC2) [EB/OL]. [2009-05-20]. <http://aws.amazon.com/ec2/>.
- [11] 陈康,郑纬民. 云计算:系统实例与研究现状[J]. 软件学报,2009,20(5):1337-1348.
- [12] ROSENTHAL A, MORK P, LI M H. Cloud computing: a new business paradigm for biomedical information sharing [J]. Journal of Biomedical Informatics, 2010,43(2):342-353.
- [13] 胡新平. 基于云模式的文献资源服务研究[J]. 情报理论与实践, 2010,33(9):73-76.
- [14] 南凯,董科军,谢建军. 面向云服务的科研协同平台研究[J]. 华中科技大学学报:自然科学版,2010,38(N):14-19.
- [15] 李伯虎,张霖,王时龙,等. 云制造——面向服务的网络化制造模式[J]. 计算机集成制造系统,2010,16(1):1-8.
- [16] 张霖,罗永亮,陶飞,等. 制造云构建关键技术研究[J]. 计算机集成制造系统,2010,16(11):2510-2520.
- [17] 王忠杰,徐晓飞. 面向双边资源整合的服务创新模式[J]. 计算机集成制造系统,2009,15(11):2216-2225.

(上接第 213 页)




图4 初始水温为20℃时内筒水温控制结果




图5 初始水温为20℃时外筒水温控制结果

3 结束语

本文提出了神经网络非线性预测逆系统控制方法,该控制方法不仅可以克服一般非线性逆控制方法需要对象精确数学模型的问题,同时根据多步预测的结果直接训练控制器的权值,避免了复杂的非线性求解,比一般的神经网络预测控制方法简单,更易于实现。此外,为了进一步减少模型失配、干扰和不确定性带来的不利影响,在控制过程中采用神经网络对每一步的输出预测误差进行了校正。对锅炉对象进行控制的结果表明,本文提出的基于预测控制思想的非线性逆系统控制方法

可以实现大滞后非线性对象的解耦控制,且能克服模型不精确的影响,实现良好的动态跟踪性能。

参考文献:

- [1] CHEN L, NARENDRA K S. Identification and control of a nonlinear discrete-time system based on its linearization: a unified framework [J]. IEEE Trans on Neural Networks, 2004, 15(3):663-673.
- [2] CHEN L, NARENDRA K S. Intelligent control using neural networks and multiple models[C]//Proc of the 41st IEEE Conference on Decision and Control. [S.l.]: IEEE Control Systems Society, 2002:1357-1362.
- [3] CABRERA J B D. Nonlinear ARMA models and the general tracking problem for discrete-time dynamical systems [D]. New Haven, Connecticut: Yale University, 1997.
- [4] 戴先中. 多变量非线性系统的神经网络逆控制方法[M]. 北京:科学出版社, 2006.
- [5] 李生权,裴进浩,季宏丽,等. 一类非线性非最小相位系统的神经网络逆控制[J]. 系统仿真学报, 2009, 21(4):962-964.
- [6] 魏东. 基于预测策略的神经网络非线性控制及应用[D]. 北京:北京航空航天大学, 2006.
- [7] 李成栋,易建强,余意,等. 柔索驱动并联机构的二型模糊神经逆控制[J]. 自动化学报, 2010, 36(3):459-464.