基于 PNN 与 FNN 模型神经网络控制器设计与分析

王 锴 王占林 付永领 祁晓野

(北京航空航天大学 自动化科学与电气工程学院, 北京 100083)

摘 要: 模糊神经网络和预测神经网络分别是基于经验和学习的新型神经网络控制系统,通过在卧式电液仿真转台中框控制器上分别采用这 2 种控制方法来研究它们的控制特性和应用范围. 其中,模糊神经网络结合了模糊控制的经验和神经网络的学习能力,但控制精度取决于人为经验;所研究的预测神经网络采用了基于非线性自回归滑动平均模型建立预测模型,实现在线学习和在线控制,但初始阶段控制精度不高. 仿真研究证明,根据具体的控制对象采用适当的控制方法或是将 2 种方法合理地结合起来将会达到较高的控制精度.

关 键 词: 模糊神经网络; 预测神经网络; 非线性自回归滑动平均模型

中图分类号: TP 183; V 249

文献标识码: A **文 章 编 号**: 1001-5965(2006)09-1072-05

Design and analysis of based on PNN and FNN controller

Wang Kai Wang Zhanlin Fu Yongling Qi Xiaoye

(School of Automation Science and Electrical Engineering, Beijing University of Aeronautics and Astronautics, Beijing 100083, China)

Abstract: Fuzzy neural net(FNN) and predictive neural net(PNN) are new neural net controllers, two neural net controllers based on practical methods from actual control system and self-study. FNN and PNN controllers avoid many shortcomings of usual artificial neural net. Two neural nets for electronic-hydraulic simulating rotary-table's middle gimbal were used to research their control characteristics and application ranges. FNN controller unites fuzzy control experiences and neural net self-study capability, but control precision only depends on summarize personal experiences; PNN controller uses nonlinear auto regressive moving average (NARMA) model for predictive model, makes real time study and control for all process, but control precisions is lower in start phase. Simulation results of FNN and PNN controllers show that differnet methods for different control objects or unit two methods for different control objects have achieved high precisions.

Key words: fuzzy neural net; precditive neural net; nonlinear auto regressive moving average

1 问题的提出

通常人脑处理事务的方式分为 2 种:①针对已有的控制经验,加以总结并进行控制;②对没有控制经验的事物,通过学习得到最优控制方法. 经验和学习的完美结合是人脑控制系统的重要特点,人工神经网络控制是用物理器件来模拟生物神经网络的某些结构和功能,而不依赖于模型的控制方法. 但人工神经网络从结构和算法上还不能模拟人脑,将经验和学习归并为一体,用一个网络来实现,而是根据不同控制对象采用不同的网络,没有对这 2 种方法进行比较分析. 论文以高精度三轴卧式液压仿真转台中框控制器为例,分析和比较这 2 种神经网络控制系统.

三轴卧式液压转台中框用阀控马达驱动铝合金框架转动,测控系统由测速电机、角度编码器、上位机和板卡组成,内反馈环为速度环,外反馈环为角度环. 根据阀控马达 3 个基本方程拉氏变换式[1],可以得到中框驱动系统动力学模型.

1) 伺服阀的线性化流量方程

$$Q = K_q X - K_p p \tag{1}$$

收稿日期: 2005-10-20

作者简介: 王 锴(1973-),男,江苏南京人,博士生, wangkai@asee.buaa.edu.cn.

2）液压马达的流量方程

$$Q = D_m s\theta + Cp + \frac{V}{4\beta}sp \tag{2}$$

3）液压马达与负载的力矩平衡方程

$$pD_m = Js^2\theta + Bs\theta + G\theta + T \tag{3}$$

式中,Q 为流量;K_q 为比例系数;X 为滑阀位移;K_p 为压力增益;p 为压力;D_m 为马达排量;C 为等效泄漏系数;β 为油液体积弹性模量;V 为马达腔容积;J为转动惯量;B为粘性摩擦系数;G为弹性摩擦系数;T 为负载力矩;θ 为马达转动角度.

图 1 为 PID(比例、积分、微分)转台中框控制系统仿真模型,图中 θ_d 为马达实际输出角度,K_b 为比例增益. 由于阀控马达系统所受摩擦力具有非线性特性,同时,转台运动时负载大范围变化造成较大干扰,使中框振荡,严重影响转台定位精度和动态性能. 图 2 为在转台中框马达上加入脉冲干扰后,中框的阶跃输出情况,图 3 为干扰部分放大效果图.

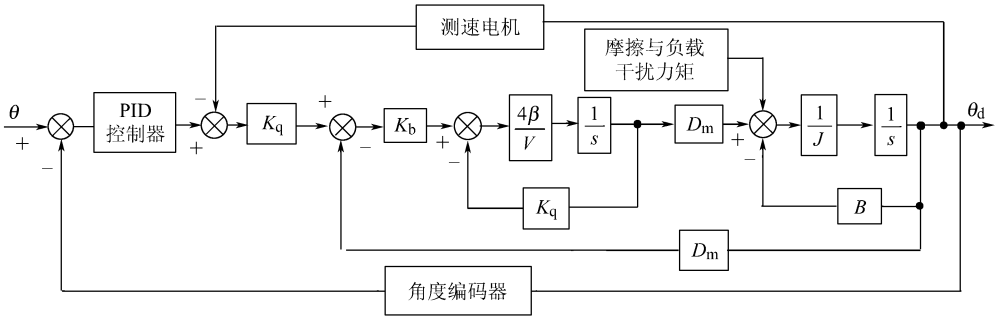

图 1　转台中框 PID 控制器作用下动力学模型

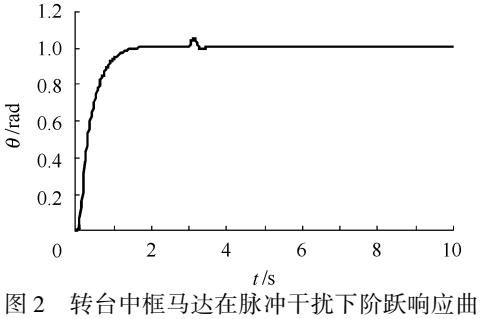

图 2　转台中框马达在脉冲干扰下阶跃响应曲线

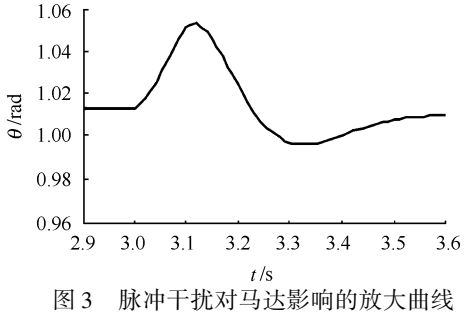

图 3　脉冲干扰对马达影响的放大曲线

2　FNN 控制器研究

基于控制经验的模糊控制系统缺乏自学习和自适应能力,对于模糊控制规则、隶属度函数等关键因素无法根据实际控制过程进行自学习和优化;而神经网络虽具有并行计算、分布存储以及自学习和自适应能力,但它不适于表达基于规则的知识,所以往往不能利用已有的经验知识,只能将初始权值设为零或随机数,使网络时常陷入非要求的局部极值. 因此,模糊神经网络(FNN, Fuzzy Neural Net)将模糊控制与神经网络结合起来,吸取两者长处,构成更为优越的基于经验的智能化控制系统[2].

2.1　控制规则的总结

转台中框控制规则是在 PID 控制器基础上根据经验知识,动态调整控制系统比例、微分与积分变化,对摩擦和负载干扰进行实时补偿.

设输出角位移为 θ_d,输入角位移为 θ,误差 $e_\theta=\theta-\theta_d$,误差变化量 $ec_\theta=\mathrm{d}e_\theta/\mathrm{d}t$,模糊空间被分为 7 级,$NB$(负大)、$NM$(负中)、$NS$(负小)、$Z$(零)、$PS$(正小)、$PM$(正中)、$PB$(正大),控制规则的依据是:

1）当 e_θ 较大时,应取较大的 K_P(比例变量)和较小的 K_D(微分变量)使系统响应加快,且使积分变量 $K_I=0$(避免过大的超调);

2）当 e_θ 中等时,应取较小的 K_P(使系统响应具有较小的超调),适当的 K_D 和 K_I(K_D的取值对系统响应的影响较大);

3）当 e_θ 较小时,应取较大的 K_P 和 K_I(使系统响应具有良好的稳态性能),K_D 的取值要适当,以避免在平衡点附近出现振荡.

根据转台中框 PID 控制经验,对比例、微分与积分环节的变化各制定出对应的 49 条控制规则(如表 1 ~ 表 3 所示). Δk_P, Δk_I, Δk_D 为比例、积分、微分的控制变化量.

表 1 Δk_P 的调整规则表

ec_θ \ e_θ	NB	NM	NS	Z	PS	PM	PB
NB	PB	PB	PM	PM	PS	PS	Z
NM	PB	PB	PM	PM	PS	Z	Z
NS	PM	PM	PM	PS	Z	NS	NM
Z	PM	PS	PS	Z	NS	NM	NM
PS	PS	PS	Z	NS	NS	NM	NM
PM	Z	Z	NS	NM	NM	NM	NB
PB	Z	NS	NS	NM	NM	NB	NB

表 2 Δk_I 的调整规则表

ec_θ \ e_θ	NB	NM	NS	Z	PS	PM	PB
NB	Z	PB	PB	PS	PM	Z	Z
NM	PB	PB	PM	PM	PS	Z	Z
NS	PM	PM	PS	PS	Z	NS	NS
Z	PM	PS	PS	Z	NS	NS	NM
PS	PS	PS	Z	NS	NS	NM	NM
PM	Z	Z	NS	NM	NM	NB	NB
PB	Z	Z	NS	NM	NB	NB	Z

表 3 Δk_D 的调整规则表

ec_θ \ e_θ	NB	NM	NS	Z	PS	PM	PB
NB	PS	PS	Z	Z	Z	PB	PB
NM	NS	NS	NS	NS	Z	NS	PM
NS	NB	NB	NM	NS	Z	PS	PM
Z	NB	NM	NS	NS	Z	PS	PM
PS	NB	NM	NS	NS	Z	PS	PS
PM	NM	NS	NS	NS	Z	PS	PS
PB	PS	Z	Z	Z	Z	PB	PB

2.2 FNN 控制器设计

整个模糊神经网络由 5 层组成,运算过程也是从第 1 层到第 5 层依次进行的. 下面各式中的 y 为每一层的输出值,其下标和上标代表层数和个数.

第 1 层为输入层,其作用是将输入变量 e_θ 和 ec_θ 转化为论域上的值:$y_{11}=k_e e_\theta$, $y_{21}=k_{ec} ec_\theta$, k_e 和 k_{ec} 为输入量的比例系数.

第 2 层为隶属度层,它的作用是计算输入变量的隶属度. 每个输入变量被划分为 7 个模糊子集. 该层每个节点的输出为对应节点的模糊子集的隶属度. $y_{i2}=f(y_{11})$, $y'_{i2}=f(y_{21})$,式中 $f(\cdot)$ 为隶属度函数(域值函数), $i=1,\cdots,7$,输入隶属度函数采用高斯函数.

第 3 层每个节点代表一条模糊规则的前件,它计算出每条规则的适用度. $y_3^j=y_{i2}\times y'_{i2}$; j 为控制规则数, $j=1,\cdots,147$(这里的规则分别对应两马达各自的 49 条规则,共 147 条规则).

第 4 层的节点数与第 3 层相同且一一对应,它所实现的是归一化计算(将规则适用度变成-1 ~1 之间的值),即 $y_4^j=\dfrac{y_3^j}{\mathrm{sum}(y_3^j)}$.

第 5 层是反模糊化层,实现清晰化运算. 即: $\Delta k_P=\sum_{j=1}^{49} y_4^j w_P^j$, $\Delta k_I=\sum_{j=1}^{49} y_4^j w_I^j$, $\Delta k_D=\sum_{j=1}^{49} y_4^j w_D^j$, w_P^j, w_I^j, w_D^j(网络权值)分别代表针对于 Δk_P, Δk_I 和 Δk_D 的控制规则的后件.

2.3 系统仿真分析

图 4 是模糊神经网络控制器和 PID 控制器在阶跃信号作用下加入相同的正弦干扰后干扰部分控制效果比较放大图. 图 5 为加入频率 2 Hz 正弦波后,模糊神经网络控制器的转台外框输出.

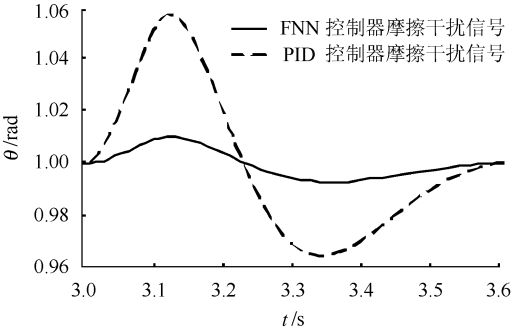

图 4 模糊神经网络干扰控制比较放大图

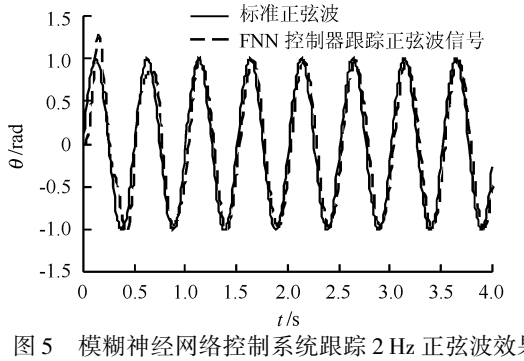

图 5 模糊神经网络控制系统跟踪 2 Hz 正弦波效果

通过对模糊神经网络模型与 PID 控制系统进行软件仿真结果的比较分析,在模糊神经网络控制下,系统的上升时间提高了 0.5 s,在跟踪 2 Hz 正弦波时,幅值衰减降低了 7%,较大地提高了系统性能.

3 PNN 控制器研究

转台中框 PID 控制经验的总结是一个复杂的过程,147 条控制经验的准确性完全由人为确定,难以达到理想性能. 预测神经网络(PNN, Predictive Neural Net)是一种基于模型的在线学习和在线控制的神经网络控制系统,由预测模型、滚动优化和在线校正 3 部分组成. 图 6 为转台中框预测

神经网络控制器模型,θ_p 为滤波反馈值.

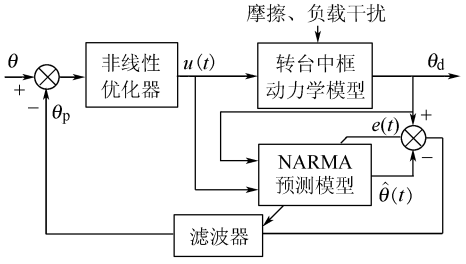

图 6　转台中框 PNN 控制器模型

3.1　NARMA 神经网络预测模型

在预测模型的设计中,首先要能对转台中框这个非线性系统进行精确辨识. 非线性自回归滑动平均模型(NARMA, Nonlinear Auto Regressive Moving Average)网络[3]具有良好的非线性系统辨识能力,它采用双网络辨识减少了目前单网络辨识由于初始值选择的盲目性所带来的收敛速度较慢和容易陷入局部极小值的缺陷.

NARMA 网络预测模型的建立如下:

$$\left.\begin{aligned}\theta_d(k+1)&=f[\theta_d(k),u(k)]\\ \theta(k)&=h[\theta_d(k)]\end{aligned}\right\}\tag{4}$$

式中,$\theta_d(k)\in\mathbf{R}^n$;$u(k)\in\mathbf{R}$;$\theta(k)\in\mathbf{R}$,$f(\cdot):\mathbf{R}^n\times\mathbf{R}\to\mathbf{R}^n$;$h(\cdot):\mathbf{R}^n\to\mathbf{R}$;$f(\cdot)$,$h(\cdot)\in C^\infty$.

假设 $f(0,0)=0$,则初始状态为系统的平衡态,同时 f,h 未知,输入与输出信号可测. 设 Ω 为系统平衡态的某一邻域,假设系统在该邻域内的相对阶 $d<\infty$,则在 Ω 内,可用 NARMA 方程来描述系统:

$$\theta(k+d)=F[\theta(k),\theta(k-1),\cdots,\theta(k-n+1),u(k),u(k-1),\cdots,u(k-n+1)]\tag{5}$$

式中 $d\geqslant 1$. 控制的目的是找出控制量 $u(k)$,使得 $\theta_d(k)=\theta(k)$. 如果系统满足相对阶要求(转台系统中,马达摩擦力矩作为非线性因素始终存在且有值,所以满足相对阶要求 $1\leqslant d<\infty$),可得方程

$$u(k)=G[\theta(k),\theta(k-1),\cdots,\theta(k-n+1),\theta_d(k+d),u(k),u(k-1),\cdots,u(k-n+1)]\tag{6}$$

式中 $G(\cdot):\mathbf{R}^{2n}\to\mathbf{R}$,$G(\cdot)$ 可用神经网络估计. 此时控制器位于动态系统反馈回路内,为减小运算量,采用 NARMA-L2 模型,它是将方程(5)在平衡点附近对 $u(k)$ 进行泰勒展开,近似表示系统 NARMA-L2 方程:

$$\theta(k+d)=f_0[\theta(k),\cdots,\theta(k-n+1),u(k-1),\cdots,u(k-n+1)]+g_0[\theta(k),\cdots,\theta(k-n+1),u(k-1),\cdots,u(k-n+1)]u(k)\tag{7}$$

如果用 NARMA-L2 模型神经网络来辨识动态系统,则需使用 2 个网络 N_f 和 N_g 分别来辨识 $f_0(\cdot)$ 和 $g_0(\cdot)$,可得神经网络辨识器模型式:

$$\hat{\theta}(k+d)=\hat{f}_0[\theta(k),\cdots,\theta(k-n+1),u(k-1),\cdots,u(k-n+1)]+\hat{g}_0[\theta(k),\cdots,\theta(k-n+1),u(k-1),\cdots,u(k-n+1)]u(k)\tag{8}$$

这 2 个网络的关系如图 7 所示(TDL 为延迟). 这就构成了 NARMA-L2 辨识器,为方便实际控制系统运算,辨识器网络 $f_0(\cdot)$ 和 $g_0(\cdot)$ 采用了相同的网络结构(2-3-1 结构),为减少运算量,2 网络初始权值和域值也相同.

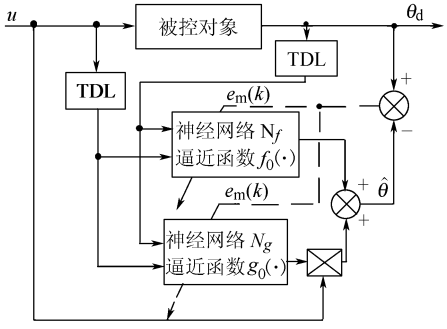

图 7　NARMA 神经网络预测模型

3.2　PNN 模型在线校正(滤波)

为了减小时变、非线性因素和随机干扰的影响,要对预测模型输出进行校正. 方法是取前次预测模型输出与实际输出的误差乘以一个误差修正系数,作为修正值. 所以预测模型输出值修改为[4](h_j 为误差修正系数)

$$\theta_p(k+j)=\hat{\theta}(k+j)+h_j[\theta_d(k)-\hat{\theta}(k)]\tag{9}$$

3.3　PNN 模型非线性滚动优化

在每个控制周期内,滚动优化算法都会计算未来有限步系统的输出,基于某一性能指标最小,寻找对象的最优输入,达到最优控制的目的. 因为算法是以时间为推移滚动进行的,所以称为滚动优化. 一般性能指标取未来一段时间内预测输出与参考轨迹的误差和控制增量的二次型性能指标(称之为雅克比系数):

$$J=\min\left\{\sum_{j=1}^{p}e^2(k+j)+\sum_{j=1}^{m}\lambda_j[\Delta u(k+j-1)]\right\}\tag{10}$$

式中,$e^2(k+j)=\theta(k+j)-\theta_p(k+j)$;$\lambda_j(\lambda_j>0)$ 为加权系数;p 为预测周期数;m 为控制周期数. 根据雅克比系数定义:$\frac{\partial J}{\partial\Delta u}=0$,得

$$\Delta u(k+j-1)=$$

$$-\frac{e(k+j)}{\lambda_j}\frac{\partial\theta(k+j)}{\partial\Delta u(k+j-1)} \tag{11}$$

对于 NARMA 网络的滚动优化,采用误差反传(BP)的方法实现网络优化.

3.4 PNN 控制器仿真分析

图 8 是在阶跃信号作用下 PNN 中框控制器在加入相同的正弦干扰后与 PID 控制器的控制效果比较图.

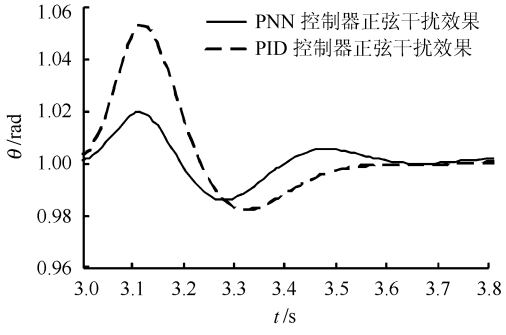

图 8 干扰信号效果比较放大图

图 9 是其跟踪 2 Hz 正弦波效果图. 通过对 PNN 模型与 PID 控制系统进行软件仿真结果的比较分析,在 PNN 网络控制下,系统的上升时间提高了 0.3 s,在跟踪 2 Hz 正弦波时,幅值衰减降低 5%.

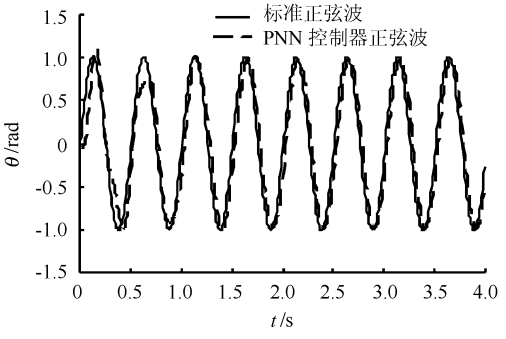

图 9 PNN 控制系统跟踪 2 Hz 正弦波效果

4 结 束 语

FNN 和 PNN 控制器分别是基于经验规则和学习校正的神经网络,分别模拟了人脑处理外界事务的 2 种方法,FNN 控制器是基于经验的控制方法,网络初始值(包括神经元个数、权值和域值)不用随机给定,收敛性好,但经验的总结完全取决于人为因素,特别是在网络处于正中(*PM*)、负中(*NM*)区间时,经验的变化很小,造成控制精度不高;同时,在控制系统大范围变化时,整个网络的变化很小,在某一范围内精度会降低.

PNN 控制器是基于学习的控制算法,在论文中使用了 NARMA 非线性预测模型,其双网络模型克服了网络初始值采用随机值所带来的辨识精度不高的缺陷,同时对非线性系统具有良好的控制能力,但其初始阶段控制精度低,这也与人脑在初始学习阶段学习能力差的缺点相对应.

FNN 与 PNN 控制器是神经网络控制中分别针对经验和学习的 2 种控制方法,需要根据不同控制对象采用不同的控制方法,对于能够准确总结出经验规则的控制系统,采用 FNN 控制器;对于难以总结出控制经验的控制系统,采用 PNN 控制器. 也可以两者同时使用,如在转台外框控制器的设计中,内环采用基于速度反馈的 FNN 同步控制器,外环采用基于位置反馈的 PNN 摩擦干扰控制器,如同人脑控制,达到了较高的控制精度.

参考文献 (References)

[1] 李洪仁. 液压控制系统[M]. 北京:国防工业出版社,1990:111-113
Li Hongren. Hydraulic control system[M]. Beijing: National Defense Industry Press,1990:111-113(in Chinese)

[2] 张友旺,桂卫华. 基于自适应模糊神经网络的摩擦力分部补偿算法[J]. 控制与决策,2005,20(3):357-359
Zhang Youwang, Gui Weihua. Partition compensation for fricition based on adaptive fuzzy neural network[J]. Control and Decision. 2005.20(3),357-359(in Chinese)

[3] Narendra K S, Parthasarathy K. Identification control of dynamical systems using neural networks[J]. IEEE Transactions on Neural Networks,1990,1(1):4-27

[4] Zhang J, Morris A J. Longrange predictive models based on locally recurrent neural net works[C]//Preprints of IFACYAC95. Beijing:[s. n.], 1995,10(2):708-712

[5] Tomizuka M, Hu J, Chiu T. Synchronization of two motion control axes under adaptive feedforward control[J]. Trans of the ASME,2002,114(3): 2-7

[6] Schilling R J, Carroll J J. Approximation of nonlinear systems with radial basis function neural networks[J]. IEEE Transactions on Neural Networks,2001,12(1):1-15

(责任编辑:娄 嘉)