

电液力伺服系统的神经网络 并行自适应预测PI控制

西安交通大学 何玉彬* 闫桂荣 张之栋 徐健学

【摘要】 考虑电液伺服系统的复杂非线性和不确定性特性, 提出一类基于神经网络的并行自适应预测PI控制结构, 该结构使控制参数的调整和系统的实时控制操作可并行进行, 不仅做到了神经模型和控制器的在线辨识和设计, 而且避免了神经网络方法通常存在的实时控制的困难, 使复杂系统的在线学习控制成为可能。仿真结果表明该控制器具有良好的适应性和鲁棒性。

主题词: 电液伺服系统 神经网络 自适应控制

分类号: V 263. 6

1 引言

结构试验^[1]要求真实地再现结构的实际工况。由于电液伺服试验系统是一时变非线性系统, 并具有严重不确定性^[2], 传统的PD控制器因其固有的缺陷^[3]难以满足系统高性能指标的要求。自适应技术的发展对提高系统的控制精度和鲁棒性起到了一定的作用^[4], 但在大扰动作用下, 或系统存在严重不确定性时, 自适应算法将趋向复杂, 并可能引起非线性系统的不稳定^[5]。目前, 神经网络因其具有学习任意非线性关系的能力^[6]受到许多工程领域的重视, 在控制领域, 将神经网络与传统控制技术相结合也取得了许多令人鼓舞的结果^[7]。由于神经网络方法是通过学习来完成控制器设计的, 因此通常存在实时性差的问题。本文旨在利用神经网络的学习能力和非线性映射能力, 设计一简单的自适应预测控制器, 既能满足系统快速跟踪的需要, 又能提高控制系统对非线性因素的处理能力和对时变参数的适应能力。

2 系统描述

结构试验系统通常有力控制加载和位移控制加载两种工作方式。假定负载为质量、弹性和阻尼, 则电液力控制系统的动态可描述为^[1]

$$M \ddot{y}_p + B_f \dot{y}_p + K_s y_p + f = A_e P_L \quad (1)$$

$$V_i P_L / 4\beta_e + A_e \dot{y}_p + c_t P_L = K_v \sqrt{P_s - \text{sgn}(u) P_L} \cdot u \quad (2)$$

$$F_g = A_e P_L \quad (3)$$

其中, $K_v = c_d K_a K_{sv} \omega \sqrt{\rho}$, M 是有效质量, B_f 为负载阻尼系数, K_s 是负载弹簧刚度, f 是外干扰力, β_e 是油的弹性模量, P_s 是供油压力, F_g 为液压缸的输出力, u 为阀的控制输入信号。由于缸的内部泄漏、油液的压缩性及外干扰的影响, 系统的参数如 β_e , c_t 等随着工作状态的改变会

产生大范围变化。此外,不同被试结构的特性随试件的形状、材料、加载点位置的不同而有相应地改变,即便对同一试验件或同一加载点,其参数随着试验的进展,亦具有不定性。对这类系统,难以建立确切的数学模型,目前尚无十分完善的控制理论和方法。

3 并行自适应预测 PI 控制结构

如图 1 所示,提出的控制结构由实时控制和神经预测两个并行工作部分与一个监督机构




图 1 神经网络并行预测控制结构




图 2 神经模型结构示意图

组成。前者相当于一个自适应反馈系统,完成系统的实时控制和预测模型的在线辨识。预测部分由预测模型和一个结构与实时控制器完全相同的预测控制器组成,它根据在线辨识得到的系统模型独立地对系统输出进行预测,并优化整定预测控制参数。监督机构根据系统控制品质的变化,决定是否需要按照预测控制参数来设计实时控制器。

3.1 自适应神经网络模型

考察非线性动力系统

$$y(t+1) = g[y(t), \dots, y(t-n+1), u(t), \dots, u(t-m+1)] \quad (4)$$

其中 $y(t), u(t)$ 分别是系统的输出、输入, n, m 是 $\{y(t)\}, \{u(t)\}$ 的阶次, $g(\cdot)$ 通常是未知的非线性时变函数。我们的目的是设计一神经网络模型,根据测量数据,跟踪学习和辨识系统的输入输出映射特性,并达到对系统输出的动态预测。由于一个三层神经网络就具有任意逼近能力^[6],因此,神经模型选为一个三层前馈网络,结构如图 2 所示。网络的输入为系统经过时延的输出和输入,各节点的映射关系如下

$${}^2x_i(t+1) = f\left[\sum_{j=1}^{n_1} {}^{12}W_{ij}(t) \cdot {}^1x_j(t+1) + {}^2\theta(t)\right] \quad (5)$$

$$i = 1, 2, \dots, n_2; \quad n_1 = m + n$$

$$\hat{y}_m(t+1) = {}^3x_i(t+1) = \sum_{j=1}^{n_2} {}^{23}W_{ij}(t) \cdot {}^2x_j(t+1), \quad i = n_3 = 1 \quad (6)$$

$$f(x) = 2/(1 + e^{-x}) - 1 \quad (7)$$

其中 ${}^{s+1}W_{ij}(t)$ 是网络第 s 层神经元到第 $(s+1)$ 层神经元的连接权, ${}^{s+1}\theta(t)$ 是第 $(s+1)$ 层神经元的阈值。定义性能指标

$$J_m(t+1) = 0.5 \|y_m(t+1) - \hat{y}_m(t+1)\|^2 \quad (8)$$

式中 $\hat{y}_m(t)$ 为模型的输出, $y_m(t)$ 是其期望输出, 应等于系统的实际输出 $y(t)$ 。则模型的学习就是调整网络权值使上述性能指标最优。由误差反向传播(BP)算法^[8]可导出 t 时刻神经网络模型的迭代学习规则如下

$$\Delta^{s(s+1)}W_{ij}(k+1, t) = -\alpha \cdot \delta_i^{s+1}(k+1, t) \cdot x_j(k+1, t) + \beta \Delta^{s(s+1)}W_{ij}(k, t) \quad (9)$$

$$s = 1, 2; \quad i = 1, 2, \dots, n_{s+1}; \quad j = 1, 2, \dots, n_s$$

其中

$$\delta_i(k, t) = y(k, t) - y_m(k, t) \quad s = 2; \quad i = 1$$

$$\delta_i(k, t) = 0.5\{1 - [x_j(k, t)]^2\} \cdot W_{ij}(k, t) \cdot \delta_i(k, t)$$

$$s = 2; \quad i = 1; \quad j = 1, 2, \dots, n_2$$

其中 k 是神经网络在 t 时刻的学习次数, ΔW_{ij} 为权重 $W_{ij}(k)$ 的修正值, α, β 分别是学习因子和平滑因子, 取值范围均为 $(0, 1)$ 。

3.2 神经网络 PI 控制器

PI 控制率为

$$u_p(t) = K_p e_p(t) + K_i \int e_p(t) dt \quad (10)$$

其中 $e_p(t) = r(t) - y_{pm}(t)$ 是系统的一步预测误差, $r(t), y_{pm}(t)$ 分别是系统的给定和预测输出。 K_p, K_i 是比例和积分系数。

对式(10), 如能根据对象的特性, 按某种指标最优自动调整参数 K_p 和 K_i , 则系统(4)可得到有效的控制, 为此本文采用一个三层的线性网络($2 \times 1 \times 1$)来实现(10)式的映射关系, 相应的神经 PI 控制律为

$$u_p(t) = K_3[K_1 e_1(t) + K_2 e_2(t)] \quad (11)$$

其中 $e_1 = e_p(t), e_2(t) = \int e_p(t) dt, K_1 = K_p, K_2 = K_i, K_3$ 是一放大增益。在训练预测控制器时, 模型固定不变, 控制网络权重 $K = \{K_1, K_2, K_3\}$ 基于预测误差 $e_p(t)$ 的负梯度进行调整。由图 1 可知, 控制参数并行调整部分是一直接自适应系统, 控制参数的优化是一随时间关系的渐近自适应收敛过程^[9]。若定义系统的一步预测性能指标为

$$J_c(t) = 0.5 \| r(t+1) - y_{pm}(t+1) \|^2 \quad (12)$$

则由 BP 算法导出的调整规则为

$$K(t+1) = K(t) + \eta e_p(t+1) \cdot \partial y_{pm}(t+1) / \partial u_p(t) \cdot \partial u_p(t) / \partial K \quad (13)$$

其中

$$y_{pm}(t+1) = \sum_{j=1}^{n_2} {}^2W_{ij}(t) \cdot f\left[\sum_{j=1}^{n_1} {}^1W_{ij}(t) \cdot {}^1x_k(t+1) + {}^2\theta(t)\right]$$

$$\{{}^1x_k(t+1)\} = \{u_p(t), \dots, u_p(t-m+1), y_{pm}(t), \dots, y_{pm}(t-n+1)\}$$

$$k = 1, 2, \dots, m+n$$

$\partial y_{pm}(t+1) / \partial u_p(t)$ 容易由模型结构求出; η 是学习率, 采用下述修正形式

$$\eta = \eta_0 / 1 + \sum_{i=1}^2 e_i^2(t) \quad (14)$$

初始误差较大时, 这种修正可增加被调权值的惯性, 避免系统振荡; 还可抑制实际过程中个别受扰点大误差的影响, 增强控制的鲁棒性; 另外, 可增强系统接近稳态时或控制参数接近最优时小误差的作用, 能有效避免控制器的学习陷入局部极小状态。

3.3 性能评估准则

预测控制器训练完成后, 由监督机构对实时控制品质进行评估, 并适时地将预测参数切换

到实时控制器,使系统输出跟踪设定。对复杂而快速系统,采用 $ITAE$ 积分准则,系统每经过一个或几个响应周期,对控制参数作一次预测,对系统不定性带来的误差不能立即作出反应;对简单或低速系统,采用瞬态误差评定准则 $A = |e(t)| < \epsilon$,其中 ϵ 是允许的动态误差上限或稳态精度,根据这一准则,系统在每一控制节拍都对控制参数作一次预测,可对不定性带来的误差作出快速响应。本文采用多处理器并行工作方式,且根据系统的复杂程度和响应快慢,选取不同准则,灵活地确定参数的调整频度,可满足实时性要求。

4 仿真结果

设计的电液加载系统的原始参数如表 1 所示。

表 1 电液力控制加载系统的主要参数

物理量	参数值	物理量	参数值	物理量	参数值
β	700 MPa	V_t	$1.2535 \times 10^{-3} m^3$	ρ_0	$860 kg/m^3$
A_e	$6.2675 \times 10^{-3} m^2$	K_{sv}	$2.647 \times 10^{-6} m/A$	P_s	15 MPa
M	300 kg	C_t	$4.7 \times 10^{-13} m^5/N \cdot s$	K_s	$3.5 \times 10^6 N/m$

电液力系统可看作二阶系统,因此神经模型结构取为 $4 \times 6 \times 2$,隐层单元数由仿真试验确定,学习率设为 $\alpha = 0.65$, $\beta = 0.75$ 。控制器初始学习率设置为 $\eta = 0.08$ 。神经网络的初始权值在 $(-0.1, 0.1)$ 区间内随机选取,神经模型和控制器均不经事先训练。这里应作几点说明:
(1) 模型的学习是一动态渐近收敛过程^[9],当 $t \rightarrow \infty$ 时,可做到模型对系统的高精度逼近。
(2) 由于(14)式的作用,初始权随机赋值的控制器在控制中不会产生较大的超调而影响系统的稳定性。
(3) 神经元采用的 *sigmoid* 激活函数的取值范围为 $(-1, 1)$,因此控制器输入量应进行归一化处理,以提高精度。




图 3 时变参数系统的跟踪结果

图 3 给出参数 M , β , K_s 变化时系统的跟踪响应,其中 $t \geq 2.2$ 秒时, M 由 300 kg 变为 900 kg, K_s 由 3500 kN/m 降为 2500 kN/m; $t \geq 3.2$ 秒时, β 由 700 MPa 变为 1200 MPa。由图可知,经过有限次学习后,系统可得到有效的控制。

图 4 示出系统在 $t \in [1.1, 2.6]$ 秒时存在 $f = 2000 N$ 的外干扰时的跟踪响应,图 5 示出存在噪信比为 15% 的随机测量噪声时系统的响应。可以看出,控制器对负载干扰和噪声干扰都具有较强的鲁棒性。

5 结 论

提出一类基于神经网络的并行自适应预测控制结构,神经模型和控制器的设计仅依赖于少量定性的先验知识,且无需经过事先训练,可进行在线辨识和设计,具有较大的适用范围。该结构使控制参数的预测调整不影响实时控制,提高了控制系统的响应速度。仿真研究表明该控




图 4 外力干扰下的加载响应




图 5 存在随机量测噪声的控制响应

制器能较好地处理被控系统的复杂特性,具有良好的适应性和鲁棒性。

参 考 文 献

- 1 胡剑峰 参数寻优模型参考自适应控制算法的研究及其在结构试验机中的应用: [学位论文] 西安交通大学, 1996
- 2 Shi W X. How to Solve the Uncertainty Problems in Hydraulic Servo-System. Proceedings of Int Conf on Fluid Power Transmission and Control, Shanghai, China, 1995: 1- 6
- 3 阎桂荣, 袁树清 模型参考自适应控制及其应用 《M P 分布式数据检测与控制系统应用技术论文集》, 西安交通大学出版社, 1992: 69- 75
- 4 阎桂荣, 田晓耕, 张改慧 采用MRAC的气-液联合多通道协调加载控制系统的研究 应用力学学报, 1995, 12(4): 39-46
- 5 Zhang H, Nikiforuk P N, Ukrainetz P R etc A Neural Network Approach for M MO Electrohydraulic Servosystem Control Proceedings of Int Conf on Fluid Power Transmission and Control, Shanghai, China, 1995
- 6 Hornik K, Stinchcombe M & White H. Multilayer Feedforward Networks are Universal Approximators Neural Networks, 1989, (2): 359- 366
- 7 何玉彬, 阎桂荣, 徐健学, 神经控制理论及应用的研究进展与展望, 现代科学技术研究的若干前言问题—现状与发展趋势, 西安: 西安交通大学出版社, 1996
- 8 Rumelhart D E & McClelland J L. Parallel Distributed Processing MIT Press, 1986
- 9 胡守仁主编 神经网络应用技术 长沙: 国防科技大学出版社, 1993

(责任编辑 王震华)

the controller's parameters, even if the restraints are out of limits

Key Words Adaptive control Constraint conditions Aircraft engines Test rig

ADAPTIVE PREDICTIVE PI CONTROL BASED ON NEURAL NETWORKS FOR ELECTROHYDRAULIC FORCE SERVO SYSTEM

He Yubin, Yan Guirong, Zhang Zhidong, Xu Jianxue

(The National Key Laboratory of Mechanical Structural Strength and Vibration,
Xi'an Jiaotong University, Xi'an 710049)

ABSTRACT An adaptive predictive PI controller based on neural networks for electrohydraulic servo system is presented with respect to its complex nonlinearities and uncertainties. The method can be realized by a parallel structure which is composed of a real-time controller for real-time control operation, a predictive controller for regulation of control parameters and a supervising mechanism to determine whether or not the real-time controller is replaced by the predictive controller according to the variations of control performance. Thus, the real-time controller can be adjusted independently of the real operation of the controlled system by introducing neural networks as predictive model and predictive controller. It avoids the difficulty of the real-time control in control methods based on neural networks, thus makes the on-line learning control of complex systems possible. The learning ability of neural networks enables the predictive model to be modified on-line to simulate the behavior of the controlled system, and makes the predictive controller adjustable adaptively to variation of the system dynamical properties. Simulation results demonstrate its satisfactory control performance and it has been applied to a electrohydraulic servo structural testing system with success.

Key Words Electrohydraulic Servo systems Neural networks Adaptive control

BIAS ESTIMATION RESEARCH OF FAULT DETECTION IN LIQUID ROCKET ENGINE

Huang Minchao and Chen Qizhi

(Dept. of Aerospace Technology, National University of Defense Technology, Changsha 410073)

ABSTRACT Two accumulative error indices are defined as the discernment signals of the fault detection in a liquid propellant rocket engine. The biases of the fault detection are selected by way of the interval estimations of the discernment signals, and the operation conditions of the rocket engine are monitored on the basis of the biases derived from the interval estimations. Moreover, the maximum optimal questions of the fault isolation thresholds are considered with the aid of the probability density function for the discernment signals of the fault isolation. The data analysis of the test firings in a large turbo-pump fed liquid rocket engine demonstrates that the estimation techniques of confidence interval can improve fault detection time compared to the current engine redline monitoring system. In the detection of anomalous test firings, both of the accumulative error indices correctly detected all faults. In the detection of normal ones, no false alarm were indicated by the first accumulative error index, while only one false alarm was indicated by the second accumulative error