

# 电液伺服结构试验系统的神经网络快速鲁棒跟踪控制<sup>\*</sup>

何玉彬 闫桂荣 徐健学

(西安交通大学机械结构强度与振动国家重点实验室·西安, 710049)

**摘要:** 针对结构试验系统的非线性和不确定性特性, 提出一种神经网络并行自学习跟踪控制器, 在满足试验系统实时性要求的条件下, 通过神经网络在线建模和虚拟学习做到了控制器的在线自适应设计, 并解决了实时训练样本不足的问题, 实例仿真表明设计的控制系统具有良好的波形再现能力.

**关键词:** 结构试验系统; 神经网络控制; 在线学习; 鲁棒性

## Neural Network Based Fast and Robust Tracking Control for Electro-Hydraulic Servo Structural Testing System

He Yubin, Yan Guirong and Xu Jianxue

(National Key Laboratory of Mechanical Structural Strength and Vibration, Xi'an Jiaotong University · Xi'an, 710049, P. R. China)

**Abstract:** A parallel self-learning tracking controller based on neural networks, with respect to the complex nonlinearities and uncertainties of structural testing system, is presented in this paper. By introducing a neural network to model the controlled system and using virtual learning, the controller can be adaptively designed on-line with no need of the real-time measured training data. Meantime, the real-time processing ability of the neural network control for complex systems is assured. Simulation results of a real control system show it has good tracking ability.

**Key words:** structural testing system; neural network control; on-line learning; robustness

## 1 引言(Introduction)

结构试验是评价结构的完整性和耐用性的实用有效的重要手段. 试验要求系统能真实地再现结构的实际工况, 具有较高的跟踪精度和响应速度; 且控制策略对系统的不确定性因素应呈现较强的鲁棒性<sup>[1]</sup>. 这使传统的控制理论在应用于实践时遇到了困难. 神经网络因其具有学习任意非线性关系的能力<sup>[2]</sup>在复杂系统的建模和控制中得到广泛应用<sup>[3]</sup>, 也给结构试验系统实现精确的波形再现提供了一条新途径. 但是, 试验系统固有的非线性和参数大范围不确定性给神经网络控制带来以下问题: 一是训练样本的选取难以覆盖整个工况; 其次, 为了提高网络的鲁棒性, 网络结构将会很复杂; 第三, 即使一个训练好的网络在工作过程中也会由于过程干扰的存在和系统参数的变化而产生不可克服的动态误差. 以上问题的解决办法是利用实时数据对网络进行在线训练, 但这势必影响控制的实时性.

本文提出一种并行学习结构, 在不增加网络复杂性的情况下, 提高神经模型对系统特性的跟踪逼近

能力, 并通过虚拟训练解决实时训练样本不足的问题, 同时克服神经网络方法通常存在的实时差的问题.

## 2 结构试验控制系统(Structural testing control system)

### 2.1 系统描述(System statement)

考虑伺服阀实际存在的非零开口的工作特性, 为保证电液系统的稳定性, 试验系统采用图 1 所示的反馈控制结构, 控制器由神经网络来实现.

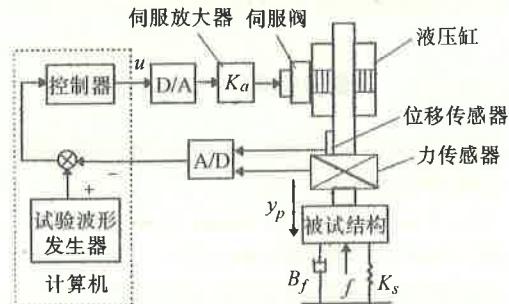


图 1 结构试验控制系统

Fig. 1 Structural testing control system

通常, 结构试验有力伺服和位移伺服两种工作方式, 系统的动态可描述为

\* 国家重点实验室开放研究基金(192117)和建设项目基金(19672047)资助课题.

本文于 1996 年 10 月 3 日收到, 1997 年 3 月 17 日收到修改稿.

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

$$V\dot{P}_L/4\beta_e + A\dot{y}_p + c_t P_L = K_v \sqrt{(P_s - \text{sgn}(u)P_L)} \cdot u; \quad (2)$$

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

其中  $M$  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,  $\beta_e$  是油的弹性横量,  $F_g$  为液压缸的输出力,  $y_p$  是液压缸的输出位移,  $u$  为阀的控制输入信号.

显然, 这是一时变非线性系统. 其不确定性主要表现在: 1) 系统的刚度、阻尼、质量等参数随被试对象的材料、形状、结构以及加载点位置的改变而在大范围内发生变化; 2) 缸的内部泄漏及油液的压缩性的影响使得液压系统的一些软参量如  $\beta_e, c_t$  等随着工况的改变而变化; 3) 加载过程中被试对象的参数随着疲劳进程的发展, 具有不确定性, 表现在试件刚度和负载干扰的非线性变化上; 4) 多缸系统间存在交叉耦合, 试件与加载杆的变形亦会造成耦合干扰. 易见, 这类系统难以精确建模, 传统控制理论和方法难于奏效.

## 2.2 神经网络建模( Neural network modeling )

描述系统的神经网络模型采用一个多层次前馈网络结构, 输入输出关系可描述为:

$$y_m(t+1) = \Phi\{w_m(t), \theta_m(t), Y(t), U(t)\}. \quad (4)$$

其中  $Y(t), U(t)$  是网络的输入向量, 也是系统的输出和输入及其时延值;  $w_m(t), \theta_m(t)$  分别是网络的连接权和神经元的阈值;  $\Phi(x)$  是用来描述系统输入输出映射特性的非线性函数. 网络的训练信号采用模型的输出误差:

$$e_m(t) = \frac{1}{2} \| y(t) - y_m(t) \|^2. \quad (5)$$

它由系统在工作过程中实时提供, 训练规则由 BP 算法<sup>[4]</sup>导出为

$$\pi_m(t+1) = \pi_m(t) - \alpha \frac{\partial e_m(t)}{\partial \pi_m(t)} + \beta \Delta \pi_m(t). \quad (6)$$

其中  $\pi_m(t) = [w_m(t), \theta_m(t)]^T$ ,  $\alpha, \beta$  分别是学习因子和平滑因子.

## 2.3 神经网络控制器的虚拟训练(Virtual training of neural network controller)

为提高控制器对环境和系统参数变化的适应能力, 设计一个与实际系统并行工作的虚拟训练预测子系统, 如图 2 所示. 它由系统的神经网络辨识模型

(NNM) 和一个结构与实时神经控制器完全相同的虚拟自学习控制器(VSLC)以及一个控制品质监督机构组成, 该系统无须等待实测数据, 仅根据在线辨识模型即可优化控制参数.

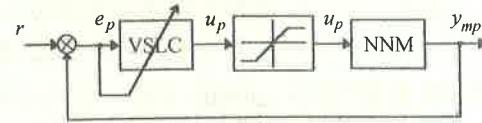


图 2 神经网络控制器虚拟训练系统

Fig. 2 The virtual training system of neural network controller

VSLC 采用一个多层次前馈网络结构, 输入输出映射关系为

$$u_p(t) = \Psi\{w_c(t), \theta_c(t), E_p(t)\}. \quad (7)$$

其中  $w_c(t), \theta_c(t)$  分别是控制网络的连接权和神经元的阈值;  $\Psi(x)$  是一非线性映射函数;  $E_p(t)$  是控制器的输入向量, 也是虚拟训练系统的跟踪误差及其时延值:

$$E_p(t) = [e_p(t), e_p(t-1), \dots, e_p(t-s)]^T. \quad (8)$$

定义虚拟训练系统的预制性能指标

$$J_p(t) = \frac{1}{2} \| r(t+d/t) - y_{mp}(t+d/t) \|^2. \quad (9)$$

其中  $d$  是电液伺服系统的时延;  $r(t), y_{mp}(t)$  分别是试验系统的设定输入和模型的预测输出. 则 VSLC 的训练就是在下列条件下调整网络权值使上式最小化.

$$y_{mp}(t+d/t) = \Phi\{w_m(t), \theta_m(t), Y_{mp}(t), U_p(t)\}. \quad (10)$$

此时, 神经模型相当于系统输出的  $d$  步提前预测器. 在这一控制结构中, 由于采用了 NNM 代替系统本身, 不仅可利用直接逆建模方法训练控制器<sup>[5]</sup>, 而且无需系统的实时测量数据, 即可进行多步预测训练, 有利于改善电液伺服系统的时延特性. 训练规则由 BP 算法导出为

$$\begin{aligned} \pi_c(t+1) &= \pi_c(t) + \eta e_p(t+d/t) \cdot \\ &\quad \frac{\partial y_{mp}(t+d/t)}{\partial u_p(t)} \cdot \frac{\partial u_p(t)}{\partial u_c(t)}. \end{aligned} \quad (11)$$

其中  $\pi_c(t) = [w_c(t), \theta_c(t)]^T$ ;  $\partial y_{mp}(t+d/t)/\partial u_p(t)$  容易由神经网络模型结构求出;  $\eta$  是学习率, 为避免系统产生振荡和控制器的学习陷入局部极小状态, 采用下述修正形式

$$\eta = \frac{\eta_0}{1 + \sum_{i=0}^s e_p^2(t+i)}. \quad (12)$$

VSLC 训练完成后, 由监督机构对实时控制系

统的控制品质进行评估。当控制品质下降到一定程度时,监督机构自动地将训练好的控制参数切换到实时控制器,既可保证满意的控制性能,又避免了一般自适应系统控制参数不必要的频繁修正。品质估计准则一般采用 ITAE 准则或瞬态误差准则  $A = |e(t)| < \epsilon$ , 其中  $\epsilon$  是允许的动态误差上限或稳态精度。

### 3 实例仿真结果(Example and simulation result)

考虑图 1 所示的试验系统, 原始参数参见文献 [1]。取控制器结构为 3-3-1, 初始学习率置为  $\eta_0 = 0.08$ ; 模型结构为 4-6-1, 学习参数为  $\alpha = 0.65$ ,  $\beta = 0.75$ 。网络的初始权值在  $(-0.1, 0.1)$  区间内随机选取, 模型和控制器均不经过事先训练; 监督机构采用瞬态误差判定准则。模型的学习是一动态渐近自适应逼近过程, 当  $t \rightarrow \infty$  时, 可做到模型对系统的高精度逼近<sup>[6]</sup>。

图 3 给出了  $t > 1.0$  秒时负载质量和油的弹性模量加倍、刚度由  $3500\text{kN/m}$  降为  $2000\text{kN/m}$  时系统的跟踪响应, 图 4 示出系统在  $t \in [1.1, 2.6]$  秒时存在  $2\text{kN}$  的阶跃外干扰时的跟踪响应。由图可见, 控制

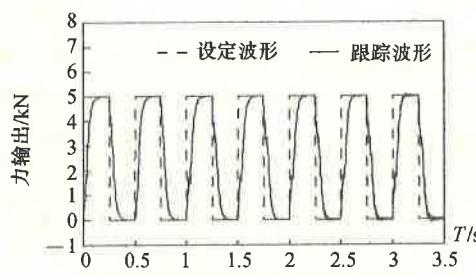


图 3 参数突变时系统的跟踪响应  
Fig. 3 Tracking result of system with parameters variation

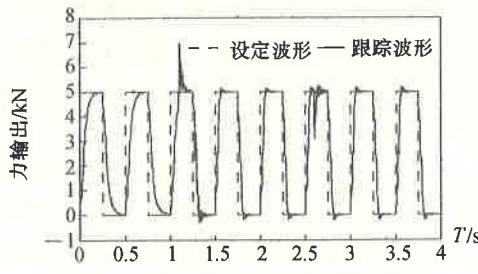


图 4 外负载干扰时系统的跟踪响应  
Fig. 4 Tracking result of system under outer load disturbance

器经过有限次学习后, 可较好地实现波形再现, 并对系统参数变化和负载干扰具有良好的鲁棒性。

### 4 结语(Conclusion)

本文引入神经网络并行学习结构和神经控制器虚拟训练手段, 在不影响结构试验系统实时性的情况下, 做到了神经网络模型的动态辨识和控制器的在线设计, 有效地解决了控制器实时训练样本不足的问题, 仿真结果证明了该方法的有效性。

上述结果是基于单输入单输出(SISO)系统, 但由于控制器在设计和训练上无特殊要求, 可直接推广到单输入多输出(SIMO)系统(如结构的协调加载试验)和多输入多输出(MIMO)系统(如结构的多点加载试验)。

### 参考文献(References)

- 何玉彬, 同桂荣, 徐建学等. 电液伺服结构加载系统的神经网络直接自适应输出跟踪控制. 机床与液压, 1997, (2): 20-23
- Hornik K, Stinchcombe M & White H. Multilayer feedforward networks are universal approximators. Neural Networks, 1989, 2(4): 359-366
- 何玉彬, 同桂荣, 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沿问题——现状与发展趋势. 西安: 西安交通大学出版社, 1996
- Rumelhart D E & McClelland J L. Parallel Distributed Processing. Cambridge: MIT Press, 1986
- Hunt K J, Sbarbaro D. Neural networks for nonlinear model control. IEE Proc-D, 1991, 138(5): 431-438
- 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

### 本文作者简介

**何玉彬** 1964 年生。1986 年毕业于第二炮兵工程学院, 获学士学位; 1999 年毕业于西安交通大学, 获博士学位。现于第二炮兵某部工作。主要研究兴趣包括智能控制在机电工程中的应用及机电设备故障诊断技术等。

**同桂荣** 1943 年生。1963 年毕业于西安交通大学。现为该校教授。获省部级科技进步奖 6 项。主要研究方向有振动测试与控制, 自适应控制, 智能控制及环境试验技术研究等。

**徐健学** 1933 年生。现为西安交通大学教授, 博士生导师。主要研究领域包括非线性系统动力学, 非线性系统控制, 神经网络及机电设备故障诊断技术等。