

压电执行器 NLDDS 及神经网络 非线性建模与控制*

李圣怡 邹向阳 吴振峰

(精密机械与仪器系)

摘要 本文采用非线性动态数据系统 (NLDDS) 建模方法和非线性递推最小二乘算法,对具有迟滞非线性特性的压电陶瓷微进给执行器的动态特征进行了建模、预报与控制,并且用人工神经网络对该类系统的建模与控制进行仿真。结果证明上述方法在一定程度上是可行的和有效的。

关键词 压电执行器, 非线性建模与控制, 神经网络, 非线性动态数据系统

分类号 TP274. 5

压电陶瓷执行器作为一种精密定位执行机构已广泛地运用于超精机械制造,误差补偿控制之中。原来为静态定位控制而设计的一些方法显然不能满足于动态控制的需要,因此,需要研究如何精确地建立压电执行器的动态数学模型。

电致伸缩型压电材料的非线性特征表现十分复杂,如从电压—位移特性上表现出二次抛物线曲线,其中的磁滞环曲线又是一多值非线性问题。从建模精度和工程实用性两方面的考虑,寻找一种具有实用价值的建模与控制方法以实现超精制造中的零误差跟踪控制是十分有意义的。

1 非线性动态数据系统 (NLDDS) 建模方法^[1]

从理论上讲,一个非线性系统的输入输出关系总可用 Volterra 级数或者 Wiener 级数表达。

假定非线性系统的输入输出关系为

$$y(t) = F[u(t'); t' \leq t] \quad (1)$$

式中, $\{u(t)\}$, $\{y(t)\}$ 分别为输入、输出序列,则 Volterra 级数可表示为

$$y(t) = \sum_{n=1}^{\infty} \int_0^t \cdots \int_0^t h_n(\tau_1, \tau_2, \dots, \tau_n) \prod_{i=1}^n u(t - \tau_i) d\tau_i = \sum_{n=1}^{\infty} \omega_n(t) \quad (2)$$

式中, $h_i(\tau_1, \tau_2, \dots, \tau_i)$ 为 Volterra 级数的核。可见,当 $i > 1$, $h_i \equiv 0$ 时, (2) 式退化

* 国家自然科学基金资助项目
1992年1月2日收稿

为

$$y(t) = \int h_1(\tau)u(t-\tau)d\tau \quad (3)$$

(3)式为线性系统脉冲响应函数卷积表达式,而(2)式可看成是(1)式的多维泰勒级数展开,迭加并取极限值而推得。很显然在这种表达方式下估计模型参数是十分困难的。

我们把(1)式写成离散形式。

$$y(k) = f[y(k-1), y(k-2), \dots, y(k-n), u(k), u(k-1), \dots, u(k-m), e(k)] \quad (4)$$

式中, $\{u(k)\}$, $\{y(k)\}$ 分别为输入、输出序列, $f(\cdot)$ 为非线性函数, $e(k)$ 为高斯白噪声过程。 $f(\cdot)$ 的定义域是平衡点周围的一个区域。

若 $f(\cdot)$ 为线性函数, (4)式可用 DDS 线性建模方式^[2]得到一线性模型为

$$y(k) = \sum_{i=1}^n a_i y(k-i) + \sum_{j=1}^m b_j u(k-j) + b_0 u(k) \quad (5)$$

如果压电执行器工作在一很小工作区, 则可以用模型(5)来近似表示它的模型。

NLDDS 建模方法是基于泰勒展开理论, 将(4)式在其平衡点足够小邻域展开并忽略高次项的原理。因此我们能在(5)式的基础上扩展得到新的模型如下

$$y(k) = \sum_{i=1}^n a_i y(k-i) + \sum_{j=0}^m b_j u(k-j) + \sum_{i=1}^n \sum_{j=1}^m \Phi_{ij} y(k-i) y(k-j) + \sum_{i=1}^n \sum_{j=0}^m \tau_{ij} u(k-i) u(k-j) + \sum_{i=1}^n \sum_{j=0}^m \pi_{ij} y(k-i) u(k-j) + e(k) \quad (6)$$

(6)式的第 3, 4, 5 项是由两变量积组成, 又称为双变量非线性自回归模型, 记为 NLARV (n, m, l) 。其中 a_i , b_j , Φ_{ij} , τ_{ij} , π_{ij} 分别为待识别的系数, n, m 分别表示输出输入线性自回归部分的阶数, l 表示非线性二次项的最高滞后。显然, (6)式是对(1)式或(2)式的近似。它的近似程度肯定比(5)式表示的模型近似程度要高, 而且其繁杂程度又可能被工程运用所接受。因为其建模方法可以沿用 DDS 建模的方法再加以扩展。

图 1 为我们基于 DDS 建模策略扩展而来的 NLDDS 建模程序框图。

2 建模与控制的实验与分析

实验装置如图 2 所示, 输入信号由计算机产生, 经 D/A 及高压激励电源变为 0—500 伏范围的高压信号, 压电执行器产生的位移信号经电容传感器 DWY-3 和 A/D 进入计算机, 位移范围为 $\pm 3\mu\text{m}$ 。

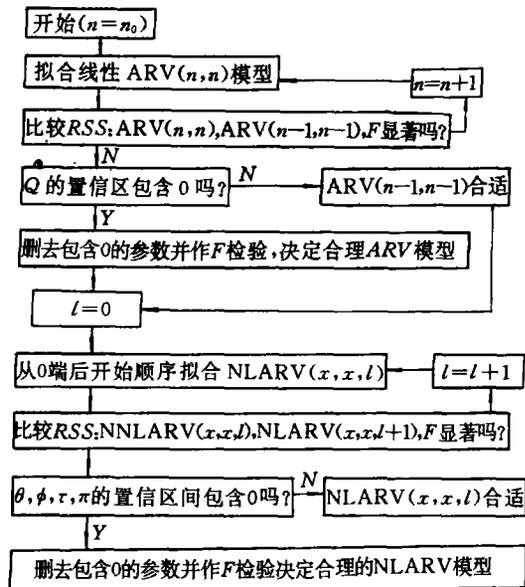


图 1 NLARV 建模框图

实验方法是，对 DDS 建模与 NLDDS 建模的精度以及模型适应性作比较。由于压电执行器具有多值非线性特性。其精确模型的参数与输入信号的形式有关。因此实验分为两类：一是白噪声激励建模及模型适应性探讨；二是特定信号激励建模及 0 误差跟踪控制。

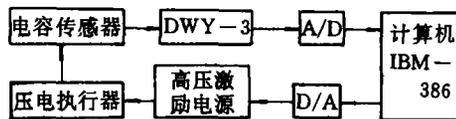


图 2 实验系统

2.1 白噪声激励建模与预报

图 3 为一组白噪声（伪随机码）激励的输入、输出信号波形。其输入、输出关系在 $V-\mu\text{m}$ 图上呈现出图 4 所示的多值关系。采样间隔取 1ms，观测数据点为 500 点。建模结果为表 1 所示。

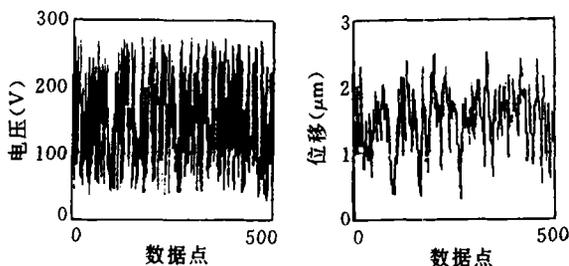


图 3 白噪声激励的输入，输出信号

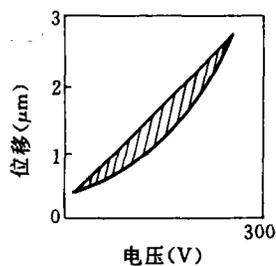


图 4 白噪声激励的多值关系

表 1 辨识的线性模型[ARV(1, 1)]和非线性模型[ALARV(1, 1, 1,)]

	ARV (1, 1)	NLARV (1, 1, 1)
a_1	0. 9535	0. 9469
b_0	1. 6707E-03	2. 4092E-03
b_1	0. 0294	0. 0302
φ_{11}		-6. 2042E-05
τ_{11}		1. 4241E-05
π_{11}		-2. 4118E-05
RSS	0. 5195	0. 446
非线性模型对线性模型的改善比	14%	

从上表可写出两种模型的表达式分别为：

$$y(k) = 0.9535y(k-1) + 0.00167u(k) + 0.0294u(k-1) \quad (7)$$

$$y(k) = 0.9469y(k-1) + 0.0024u(k) + 0.0302u(k-1) - 0.00006204y(k-1)y(k-1) + 0.00001424u(k-1)u(k-1) - 0.00002412u(k-1)y(k-1) \quad (8)$$

(8)式中非线性项 $[y(k-1)]^2$, $[u(k-1)]^2$ 和 $u(k-1)y(k-1)$ 可在一定程度上表示

压电执行器的非线性。与线性模型比较，残差平方和 RSS 从 0.5195 降到 0.446。说明 (8) 式表示动态特性的有效性，其建模精度改善了 14% 左右。

为了说明模型 (8) 式的适应性，即在一定范围内对其他输入信号的实时响应的预报能力也应有所改善，我们采用不同输入信号以核对该模型预报精度的改善情况。例如用一组正弦波作输入信号并分别用 (7), (8) 式进行预报。图 5(a)、5(b) 分别为其预报误差曲线。(8) 式预报精度是足够高的，比 (7) 提高了 29.9%。

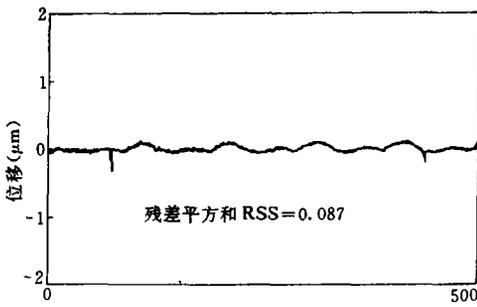


图 5(a) 线性模型预报正弦激励响应的误差曲线

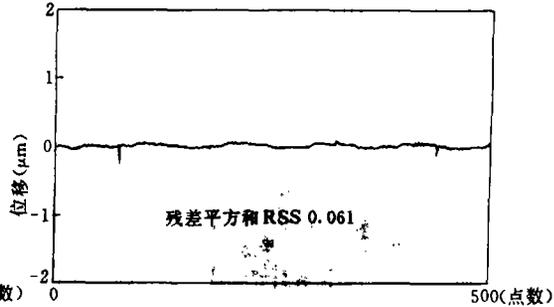


图 5(b) 非线性模型预报正弦激励响应的误差曲线

2.2 任一指定输入信号的建模与跟踪控制

作为一个例子，用频率为 1Hz，幅值为 $\pm 0.4\mu\text{m}$ 的方波作输入信号，50ms 采样间隔进行采样。用上述方法建立的模型分别为

三阶线性模型：

$$y(k) = 0.9285y(k-1) + 0.2686y(k-2) - 0.1971y(k-3) + 1.5235u(k) - 1.3686u(k-1) - 0.4247u(k-2) + 0.2804u(k-3) \quad (9)$$

三阶非线性模型：

$$y(k) = 0.8835y(k-1) + 0.3502y(k-2) - 0.2461y(k-3) + 1.5113u(k) - 1.2959u(k-1) - 0.5459u(k-2) + 0.3545u(k-3) - (9.1019E-06)y(k-1)y(k-3) + (6.4878E-05)u(k)u(k-1) \quad (10)$$

用 (9)、(10) 式模型分别作提前一步控制以跟踪输入方波，其 200 点跟踪误差和 ($E = \sum_{i=1}^{200} |e_i|$) 分别为 $2.1736\mu\text{m}$ 和 $1.698\mu\text{m}$ 。非线性模型比线性模型的跟踪控制精度提高了 21.9%，它们的跟踪误差曲线分别如图 6(a)，6(b) 所示。

3 人工神经网络非线性辨识与自校正控制^[2]

用两层具有足够多神经元的网络，在理论上可以实现任何非线性函数的映射，因此可利用神经网络的这一功能，通过学习来反映压电执行器的特性。为了简化神经网络的结构，将 (6) 式作一些简化和近似处理，即不考虑与 $u(k)$ 有关的非线性项。(6) 式改写为

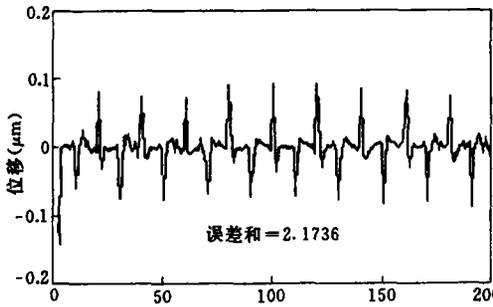


图 6(a) 非线性模型提前一点控制误差

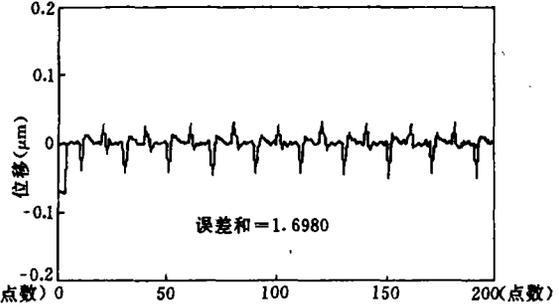


图 6(b) 线性模型提前一点控制误差

$$y(k) = \sum_{i=1}^n a_i y(k-i) + \sum_{j=1}^m b_j u(k-j) + \sum_{i=1}^n \sum_{j=1}^m \Phi_{ij} y(k-i) u(k-j) + \sum_{i=1}^n \sum_{j=1}^m \tau_{ij} u(k-i) u(k-j) + \sum_{i=1}^n \sum_{j=1}^m \pi_{ij} y(k-i) u(k-j) + b_0 u(k) \quad (11)$$

(11)式进一步简化为:

$$y(k) = f(\cdot) + b_0 u(k) \quad (12)$$

我们可把神经网络按 $y_1(k) = f_1(\cdot) + b_0 u(k)$ 形式构成如图 7 所示, 其中 L 为线性元, 可实现求和操作, N 为非线性元采用 Sigmoid 函数。如果通过网络的学习训练, 使 $f_1(\cdot)$ 逼近于 $f(\cdot)$, 则可辨识被控压执行器的非线性特性。

以神经网络辨识器为基础的适应非线性控制系统如图 8 所示。

在图 8 基于神经网络的自校正适应控制系统中, 我们将期望的输出信号作为控制器的输入 $d(k)$ 控制器设计为压电执行器的逆函数形

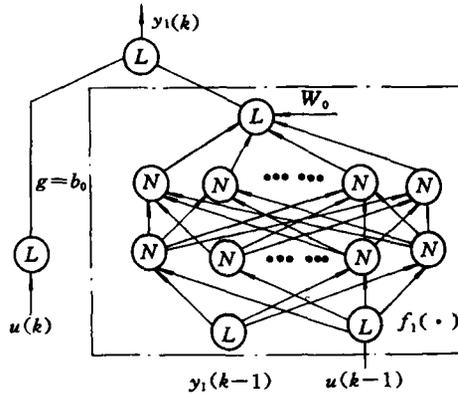


图 7 神经网络辨识器

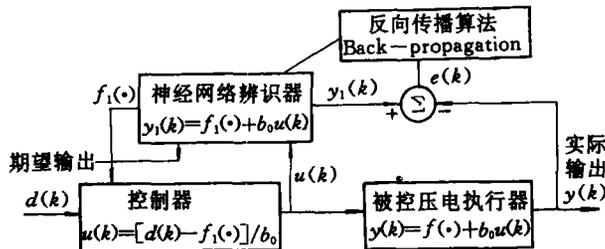


图 8 神经网络控制系统框图

式。严格地说, 由于多值非线性, $y(k)$, $u(k)$ 。不一一对应, 所以控制器 $u(k)=[d(k)-f_1(\cdot)]/b_0$ 中的 $f_1(\cdot)$ 和辨识器中 $f_1(\cdot)$ 应有一些差异以实现零用误差跟踪控制, 这一点将由神经网络控制系统良好的鲁棒性而得到改善。神经网络是误差反向传播法 (Back-propagation 法, 简称 BP 法) 来实现权值调整学习功能的, 文献^[3]有详细介绍, 这里对其原理作简要介绍。定义目标函数为:

$$E = \frac{1}{2} \sum_{k=1}^N e(k)^2 = \frac{1}{2} \sum_{k=1}^N [d(k) - y(k)]^2 \quad (13)$$

网络通过学习调整其权值 W 使 E 减小

$$\frac{\partial E(K)}{\partial W^i(K)} = \frac{\partial f_1(\cdot)}{\partial W^i(k)} \cdot e_{k+1} \quad (14)$$

$$W(k+1) = W(k) + \eta \frac{\partial f_1(\cdot)}{\partial W^i(k)} \cdot e_{k+1} + \mu[W(k) - W(k-1)] \quad (15)$$

式中, η , μ 为学习系数。 $\frac{\partial f_1(\cdot)}{\partial W^i(k)}$ 可用 BP 算法推出^[4]。

网络学习到 $f_1(\cdot)$ 与 $f(\cdot)$ 一致, 即 $e(k)=0$ 时训练完毕。

3 神经网络控制系统仿真

为了仿真方便, 我们根据(8)式的形式假定被控压电执行器非线性模型为一阶的并具有下式形式

$$y(k) = 0.22y(k-1) + 0.31u(k-1) - 0.012y^2(k-1) + 0.053u^2(k-1) + 0.043u(k-1)y(k-1) + 0.054u(k)y(k-1) + 1.22u(k) \quad (16)$$

假设期望压电执行器准确跟踪图 9 曲线。用计算机仿真图 8 神经网络控制系统和图 7 神经网络辨识器。仿真程序采用双层网络, 每层 10 个神经元, 训练采样点为 400 个, η 取为 0.1, μ 取为 0.9。经 200 次学习后神经网络控制系统输出就非常逼近于图 9 曲线了, 其跟踪误差平方和为 $RSS=0.072$ 。图 10 为仿真输出的误差曲线 (图 10 和图 9 纵坐标都经同一归一化处理)。这时神经网络辨识器已准确地反映了在这一输入信号条件的压电执行器的模型。

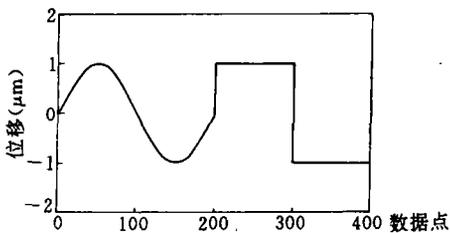


图 9 系统期望的输出

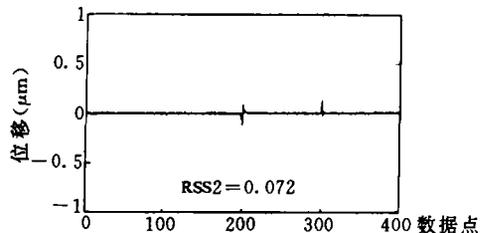


图 10 神经网络控制系统跟踪输出误差曲线

4 结 论

压电执行器的非线性动态特性可以用 NLDDS 建模方法和神经网络来辨识,从而实现高精度的跟踪控制。上述研究可得到如下结论。

(1) NLDDS 由线性 DDS 方法扩展得到,建模程序相对简单,具有工程应用前景。

(2) 非线性模型在一定范围内具有通用性,基于该模型的控制跟踪精度可较线性模型改善 20%~30%,可以用于离线建模和在线预报控制。用 DPS 提高建模计算速度可指望实现在线适应控制。

(3) 神经网络非线性辨识与自校正控制目前受算法及计算速度限制还不能实用,但其功能很强,其运用潜力和前景不可低估。

参 考 文 献

- 1 邓自立,郭一新.动态系统分析及应用.辽宁科技出版社,1985
- 2 Chen F C. IEEE Contr. sys, 1990, 44~48
- 3 Lippmann R P. IEEE ASSP Mag., 1987, 4: 4~22

Research of NLDDS and Neural Network for Modeling, Forecasting and Control of a Piezo—actuator

Li Shengyi Zou Xangyang Wu Zhenfeng
(Department of Precision Machinery and Instrument)

Abstract

The nonlinear dynamic data system (NLDDS) and nonlinear recursive least square (NLRLS) methods are used for modeling, forecasting and control of a piezoelectric actuator with nonlinear hysteresis characteristics in this paper. Neural network is also used for simulation for this purpose. Results of above research show that these methods are feasible and effective.

Key words neural network, piezoelectric actuator, nonlinear modeling and control, nonlinear dynamic data system