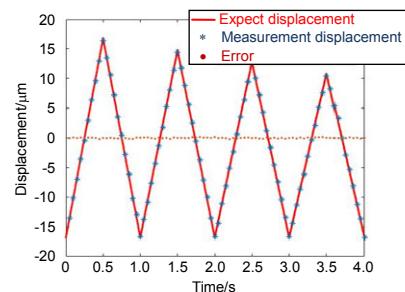




DOI: 10.12086/oee.2019.180328

## 压电陶瓷驱动器迟滞非线性建模及逆补偿控制

刘 鑫<sup>1,2,3</sup>, 李新阳<sup>1,2\*</sup>, 杜 睿<sup>1,2</sup><sup>1</sup>中国科学院自适应光学重点实验室, 四川 成都 610209;<sup>2</sup>中国科学院光电技术研究所, 四川 成都 610209;<sup>3</sup>中国科学院大学, 北京 100049

**摘要:** 自适应光学系统中的倾斜镜、变形镜通常是应用压电陶瓷驱动器来进行精密位移控制, 但压电陶瓷驱动器都有较大的非线性迟滞效应, 对系统定位性能造成了一定的影响。为了补偿迟滞现象, 需要对迟滞效应进行建模。本文通过引入迟滞算子, 使用贝叶斯正则化训练算法训练 BP 神经网络来构建压电陶瓷驱动器迟滞模型, 以中国科学院光电技术研究所自主研制的压电陶瓷驱动器为对象开展了实验研究。实验结果表明, 通过 BP 神经网络构建的压电陶瓷驱动器迟滞模型具有较准确的辨识能力, 其中正模型的相对误差为 0.0127, 逆模型的相对误差为 0.014。利用所建立的模型, 压电陶瓷驱动器的非线性度从 14.6%降低到了 1.43%。

**关键词:** 自适应光学; 压电陶瓷驱动器; 迟滞效应; 神经网络; 迟滞算子

中图分类号: TP29; TH703

文献标志码: A

引用格式: 刘鑫, 李新阳, 杜睿. 压电陶瓷驱动器迟滞非线性建模及逆补偿控制[J]. 光电工程, 2019, 46(8): 180328

## Hysteresis nonlinear modeling and inverse compensation of piezoelectric actuators

Liu Xin<sup>1,2,3</sup>, Li Xinyang<sup>1,2\*</sup>, Du Rui<sup>1,2</sup><sup>1</sup>Key Laboratory of Adaptive Optics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China;<sup>2</sup>Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China;<sup>3</sup>University of Chinese Academy of Sciences, Beijing 100049, China

**Abstract:** The tilt mirrors and deformable mirrors in adaptive optics system are usually using piezoelectric ceramic actuators for precise displacement, however, piezoelectric ceramic actuators own obviously nonlinear hysteresis effect which affects the positioning performance of the system. In order to compensate the hysteresis, there is a need to model hysteresis effects. In this paper, hysteresis operator is introduced and using Bayesian regularization training algorithm to train BP neural network to construct hysteresis model of piezoelectric ceramic actuator, an experimental study was conducted on a piezoelectric actuator developed by Institute of Optics and Electronics, Chinese Academy of Sciences. The final experimental results show that the hysteresis model of piezoelectric ceramic actuators constructed by BP neural network has more accurate identification capability. The relative error of the positive model is 0.0127 and the relative error of the inverse model is 0.014. The nonlinearity of the piezoelectric

收稿日期: 2018-09-05; 收到修改稿日期: 2018-11-06

基金项目: 国家重点研发计划项目(2017YFB0405100)

作者简介: 刘鑫(1994-), 男, 硕士研究生, 主要从事自适应光学中压电陶瓷驱动器及倾斜镜建模、人工智能方面研究。

E-mail : TracyLiu\_tju@163.com

通信作者: 李新阳(1971-), 男, 博士, 研究员, 主要从事自适应光学相关技术方面的研究。E-mail : xyli@ioe.ac.cn

actuators has been reduced from 14.6% to 1.43%.

**Keywords:** adaptive optics; piezoelectric actuator; hysteresis; neural network; hysteresis operator

**Citation:** Liu X, Li X Y, Du R. Hysteresis nonlinear modeling and inverse compensation of piezoelectric actuators[J].

*Opto-Electronic Engineering*, 2019, 46(8): 180328

## 1 引言

自适应光学技术主要用于实时校正大气湍流引起的波前畸变<sup>[1-2]</sup>。自适应光学技术已经基本发展成熟，建立了基本的理论架构，波前探测器、处理器和校正器的基本形式也已成熟<sup>[3]</sup>。自适应光学系统中最常用的波前校正器件包括用于校正波前整体倾斜的高速倾斜反射镜(也即倾斜镜)和用于校正高阶像差的变形反射镜(也即变形镜)<sup>[4]</sup>。压电式快速反射镜具备数百赫兹甚至更高的谐振频率和更高的执行精度，被广泛地应用于快速光轴控制系统中，提高了激光通讯、天文成像和生物医学成像等系统的探测精度<sup>[5]</sup>。变形镜是最主流的一类波前校正器，可应用于大到天文望远镜，小到人眼视网膜成像的自适应光学系统，校正由于大气湍流或者人眼像差等导致的波前畸变<sup>[6]</sup>。大气湍流在时间域和空间域都具有较高的带宽，要求波前校正器件也应该具有相同的性质，这就要求所应用的压电陶瓷驱动器具有较高的控制精度。对此已有不少研究，例如文献[7]中利用人工神经网络模型对变形镜进行离线辨识，文献[8]中基于神经网络对倾斜镜响应进行补偿等。但是压电陶瓷驱动器具有迟滞特性，使得校正系统微位移的重复性和精度降低，瞬态响应速度变慢，从而影响系统响应性能<sup>[9]</sup>。因此，对迟滞特性的准确建模是获得压电陶瓷驱动器高精度输出的关键。

传统的迟滞非线性模型有 Preisach 模型<sup>[10-11]</sup>，KP 模型<sup>[12]</sup>，PI 模型<sup>[13]</sup>等，建模受限于计算量和维数，会遇到模型参数、逆模型难以求解等问题，不利于工程实践上的应用。近年来，随着计算机智能的兴起，越来越多的学者开始将智能建模技术和传统的物理模型、算子模型相结合，建立了利用计算机简化计算的智能模型。神经网络能够逼近任意的非线性曲线，并且自适应学习能力、容错能力强，具有很高的系统辨识能力、数据处理能力和快速并行运算能力，使得神经网络在非线性系统建模中得到广泛应用。它能够在训练过程中，根据不完整、或含噪声的数据进行推断，并且容易与控制器的设计相结合，例如在文献[14]中使用双 S 函数进行建模，在文献[15]中利用神经网络拟合迟滞多项式建模等。

但上述利用神经网络建模的方法仍然存在参数求解过程复杂的问题，本文所采用的建模方法是引入迟滞算子进而构建 BP 神经网络模型，简化了压电陶瓷驱动器的建模计算过程，同时能够保证压电陶瓷驱动器的建模精度。

## 2 实验平台

本文所研究的对象是中国科学院光电技术所研制的压电陶瓷驱动器，规格为 18 mm×18 mm×54 mm，单片厚度为 0.7 mm~0.8 mm，输入电压范围为 -500 V 至 500 V，响应位移范围为 -17 μm 至 17 μm。

实验过程主要用到的实验器材包括：驱动器、测微仪、电压信号发生器、PC 机。其中测微仪型号是 XSI3000，分辨率为 0.005 μm；电压信号发生器的型号是 XE500-C，驱动电压范围是 -500 V 至 +500 V。

实验操作平台如图 1 所示。

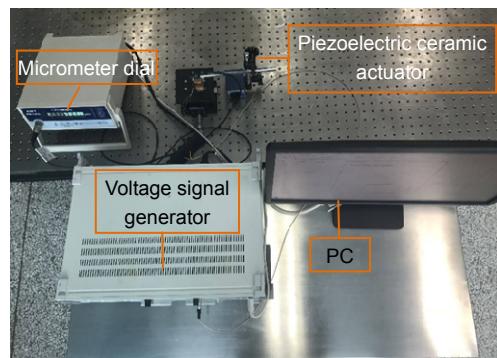


图 1 实验平台实物图

Fig. 1 Experiment platform

压电陶瓷驱动器的输入是电压信号，计算机产生的数字信号经由内置 D/A 转换模块转换成模拟信号，再由信号发生器进行放大，然后驱动压电陶瓷驱动器进行相关动作。驱动器产生的位移由测微仪传感器测量后，再被 16 位 A/D 转换模块转换成数字信号，传入 PC 机中进行保存。

研制出的压电陶瓷驱动器具有迟滞特性，其输入电压与输出位移关系如图 2 所示。迟滞性的大小为迟

滞曲线的上升段与下降段之间的差值的最大值比上总位移范围，计算出其迟滞大小为 14.6%。

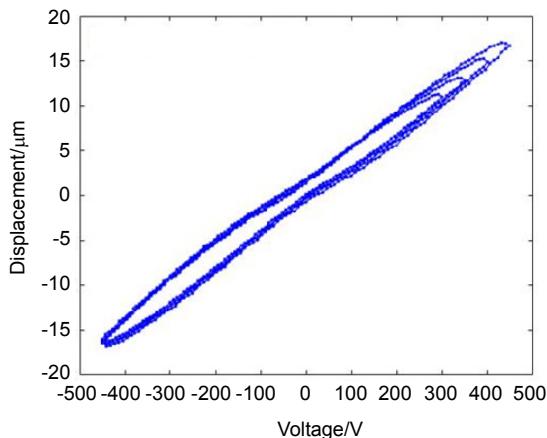


图 2 压电陶瓷驱动器迟滞现象

Fig. 2 The hysteresis phenomenon of piezoelectric actuator

### 3 构建神经网络模型

在应用神经网络时输入输出关系为一一映射或者多对一映射关系，但是压电陶瓷驱动器的电压与位移的关系是一对多的映射关系，应用神经网络并不能直接处理这种多映射的关系。所以必须通过适当的变换，将压电陶瓷驱动器中电压与位移的多映射关系转变为神经网络能够应用的映射关系。

在建模方面使用了基于空间扩张的方法<sup>[16]</sup>，通过引入迟滞算子来扩张压电陶瓷驱动器输入电压在神经网络的输入空间，在三维空间上将迟滞的多映射转化为一一映射，在变换后的空间上利用神经网络来逼近

这个一一映射从而建立一个基于神经网络的迟滞非线性模型，通过构建迟滞算子为神经网络的输入引入了一维特征。

为了能够实现将压电陶瓷驱动器输入电压与输出位移之间关系的二维空间转变为三维空间，引入的迟滞算子应该能够反应出压电陶瓷驱动器的迟滞特性，因此也应具有迟滞特性。

如文献[17]中的模型所示，本文所采用的迟滞正模型迟滞算子表达式为

$$f[u(t)] = \begin{cases} f(u_e) + [u(t) - u_e]^2(u(t) - u_e), & \dot{u}(t) > 0 \\ f(u_e) - [u_e - u(t)]^2(u_e - u(t)), & \dot{u}(t) < 0 \end{cases}, \quad (1)$$

式中： $u(t)$  是当前迟滞算子的输入电压值； $f[u(t)]$  是基本迟滞算子的当前输出； $u_e$  是位于  $u(t)$  之前最近的一个输入电压极值； $f(u_e)$  是输入为  $u_e$  时的基本迟滞算子的输出。迟滞算子示意图如图 3(a)所示，输入电压的最大范围为-450 V 至 450 V。

迟滞正模型神经网络训练结构如图 4 所示。图中神经网络包含两个输入节点，一个输出节点，隐藏层为一层， $\Delta e$  为误差值， $W_{ih}$  为输入层第  $i$  个神经元与隐含层第  $h$  个神经元之间的连接权， $W_{hj}$  为隐含层第  $h$  个神经元与输出层第  $j$  个神经元之间的连接权。

神经元节点输出的表达式为

$$o_i^{(l)} = g(I_i^{(l)}) = g\left(\sum_{j=0}^{l-1} w_{ij}^{(l)} o_j^{(l-1)}\right), \quad (2)$$

式中： $l$  为第  $l$  层， $w$  为第  $l$  层的各个神经元的权值， $o_l$  为第  $l$  层的输出， $g(\cdot)$  为神经元的激活函数，表达式：

$$g(x) = \frac{1 - e^{-x}}{1 + e^{-x}}, \quad (3)$$

式中  $x$  即为神经元输入与权值的计算结果。

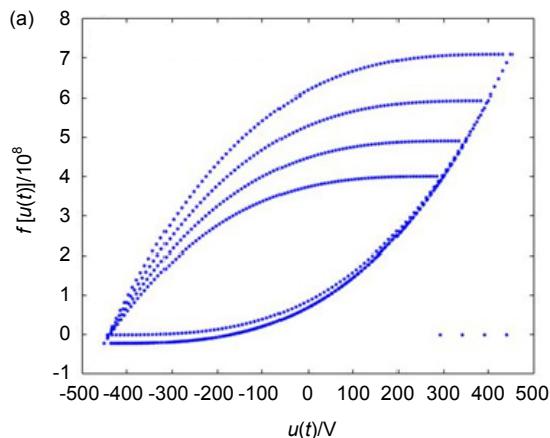
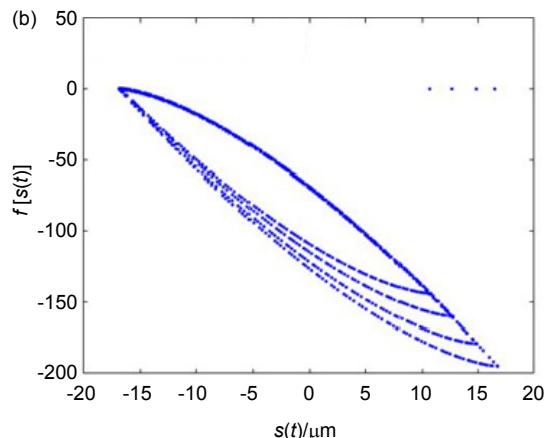


图 3 引入的迟滞算子示意图。(a) 正迟滞算子示意图；(b) 逆迟滞算子示意图

Fig. 3 Hysteresis operator. (a) Positive hysteresis operator; (b) Inverse hysteresis operator



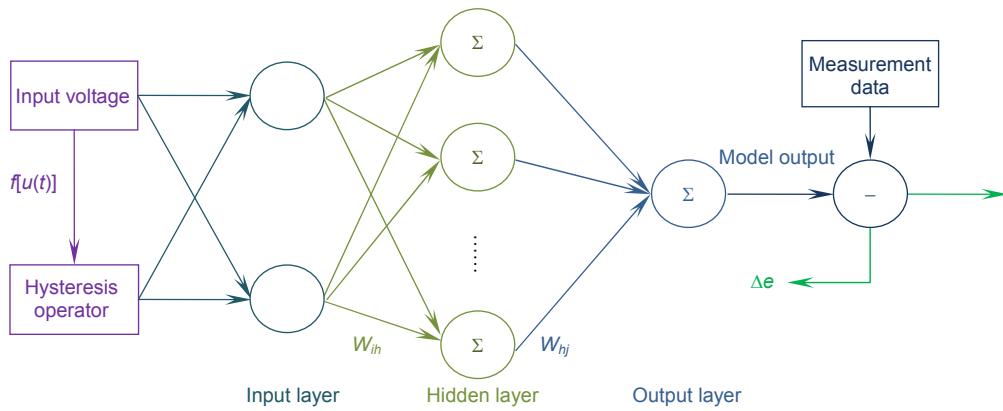


图 4 压电陶瓷驱动器迟滞正模型神经网络训练结构  
Fig. 4 Neural network training structure of hysteresis positive model

在对压电陶瓷驱动器进行建模的过程中，神经网络的目标函数是网络输出与真实值的差的平方和，通过不断调整网络中的权值使得误差减小，进而使得目标函数到达最优，其表达式为

$$\Delta e = \sum_{i=1}^n (y_{\text{input}} - y_{\text{model}})^2 , \quad (4)$$

式中： $\Delta e$  为误差值， $n$  为样本个数， $y_{\text{input}}$  为测量得到的位移值， $y_{\text{model}}$  为神经网络输出位移值。

从图 1 所示的压电陶瓷驱动器的迟滞曲线可以看出，压电陶瓷驱动器逆模型位移与电压之间的关系也是一种多映射的关系，所以利用以上建立神经网络正模型的方法，通过引入逆迟滞算子来将迟滞的多映射转化为一一映射，从而建立起压电陶瓷驱动器的逆模型。压电陶瓷驱动器的输出位移值与逆迟滞算子作为神经网络的输入，压电陶瓷驱动器的输入电压值作为神经网络的输出，进而构建压电陶瓷驱动器的迟滞逆模型。其中，逆迟滞算子的表达式为

$$f[s(t)] = \begin{cases} f(s_e) - [s(t) - s_e]^{1/3}, & \dot{s}(t) > 0 \\ f(s_e) + [s_e - s(t)]^{1/3}, & \dot{s}(t) < 0 \end{cases} , \quad (5)$$

式中： $s(t)$  是当前逆迟滞算子的输入位移值； $f[s(t)]$  是基本逆迟滞算子的当前输出； $s_e$  是位于  $s(t)$  之前的最近的一个输入位移极值； $f(s_e)$  是输入为  $s_e$  时的基本逆迟滞算子的输出。迟滞算子示意图如图 3(b)所示，输入位移的最大范围为  $-16.8 \mu\text{m}$  至  $16.8 \mu\text{m}$ 。

在以往的一些文献研究中，采用的训练算法为 Powell-Beale 算法和 Levenberg-Marquardt 算法，但是这两种训练算法的泛化能较弱，得到的模型对于训练样本辨识度很高，但是对于测试样本辨识度较低，容易出现过拟合现象。过拟合现象会对模型造成很大的

误差。为了解决过拟合问题，通过比较 Powell-Beale 算法、Levenberg-Marquardt 算法和贝叶斯正则化算法，综合运行速度和误差，本文采用贝叶斯正则化法。Powell-Beale 算法和 Levenberg-Marquardt 算法的目标函数是训练样本误差方差，而贝叶斯正则化法训练方法改变了目标函数，除了训练样本误差方差外，还加入了网络权重的平方和，也即正则化项<sup>[18]</sup>，其表达式为

$$E_n = \sum_j w_j^2 , \quad (6)$$

式中  $w_j$  为网络各个连接的权值。加入上式正则化项后可以使得作用不大的连接权值趋于 0，即去除冗余的连接权和神经元，可使网络具有较强的泛化能力，避免了以尝试的方法去决定最佳网络规模的大小。

## 4 模型验证

本文使用最小均方根误差(RMSE)和相对误差(RE)作为检验标准，对模型的效果进行定量描述。最小均方根误差(RMSE)和相对误差(RE)的计算公式为

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y - x)^2}{N}} , \quad (7)$$

$$RE = \sqrt{\frac{1}{\sum_{i=1}^N |x|^2} \times \sum_{i=1}^N |y - x|^2} , \quad (8)$$

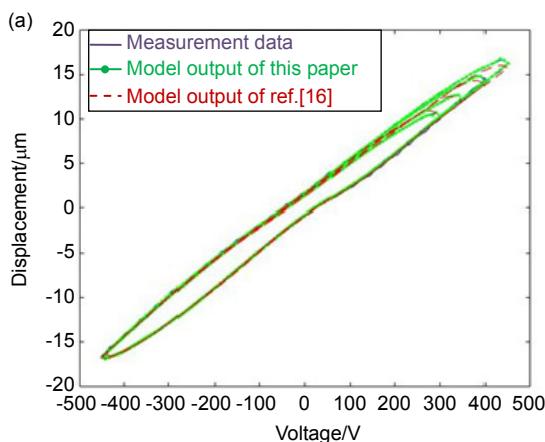
式中： $N$  是数据个数， $x$  是模型输出， $y$  是实际输出。

本文采用实测压电陶瓷驱动器数据来对迟滞模型进行有效性验证以及对比。实验过程中，输入电压信号最大范围为  $-450 \text{ V}$  至  $450 \text{ V}$ ，驱动得到的位移最大范围为  $-16.8 \mu\text{m}$  至  $16.8 \mu\text{m}$ 。采集 1600 对实测数据，其中 800 对数据用来进行神经网络的训练，另外的 800 对数据对模型进行验证。文献[16]中也使用了迟滞算

子构建迟滞正模型与迟滞逆模型，本文也采用了文献中的方法进行建模并对比结果。

首先验证压电陶瓷驱动器迟滞正模型。经过综合对比，选择一个三层的神经网络，包括 2 个输入节点、35 个隐藏层节点和 1 个输出节点可以取得最好结果。网络的训练算法采用贝叶斯正则化法算法，在训练 462 步之后，达到最小误差，结束训练。引入文献[16]中的正迟滞算子作为其中一个输入节点，仍然采用三层神经网络，包括 2 个输入节点、61 个隐藏节点和 1 个输出节点，在训练 757 步之后，达到最小误差，结束训练。正模型的辨识结果如图 5 所示。

图 5(a)中实线为测量数据，点实线为本文所采用的迟滞算子构建模型的辨识结果，虚线为文献[16]中使用的迟滞算子构建模型的辨识结果。从图 5(b)中可以看出，本文所采用的迟滞算子的模型辨识误差范围在-0.2  $\mu\text{m}$  至+0.2  $\mu\text{m}$ ，最小均方根误差 RMSE 为 0.149



$\mu\text{m}$ ，相对误差为 0.0127，而文献[16]中所采用的迟滞算子的模型辨识误差范围在-0.8  $\mu\text{m}$  至+0.8  $\mu\text{m}$ ，最小均方根误差 RMSE 为 0.478  $\mu\text{m}$ ，相对误差为 0.0376。

接下来进一步对压电陶瓷驱动器迟滞现象逆模型进行验证。经过综合对比，选择一个三层的 BP 神经网络，包括 2 个输入节点、30 个隐藏层节点和 1 个输出节点可以取得最好结果。网络的训练算法采用贝叶斯正则化法算法，在训练 502 步之后，目标函数达到最小，结束训练。引入文献[16]中的逆迟滞算子作为其中一个输入节点，仍然采用三层神经网络，包括 2 个输入节点、84 个隐藏节点和 1 个输出节点，在训练 842 步之后，达到最小误差，结束训练。对逆模型进行辨识的结果如图 6 所示。

图 6(a)中实线为测量数据，点实线为本文所采用的逆迟滞算子构建模型的辨识数据，虚线为文献[16]中使用的逆迟滞算子构建模型的辨识数据。从图 6(b)

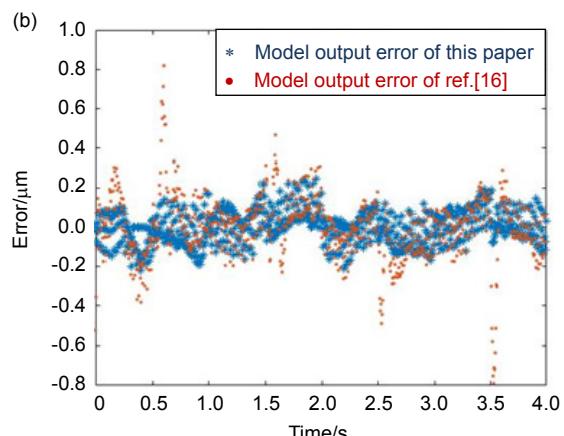


图 5 验证正模型。(a) 正模型辨识结果图；(b) 正模型误差示意图

Fig. 5 Verify the positive model. (a) Positive model identification results; (b) Positive model error

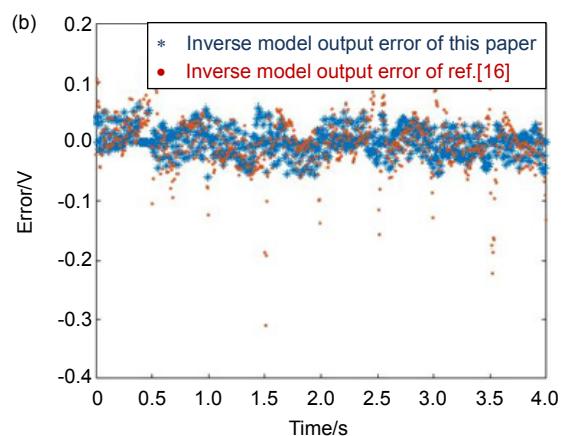
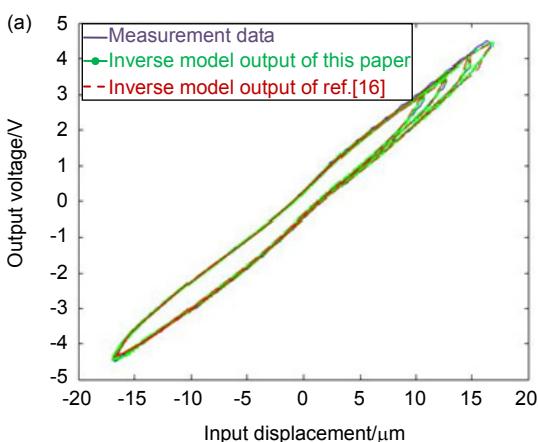


图 6 验证逆模型。(a) 逆模型辨识结果图；(b) 逆模型误差示意图

Fig. 6 Verify the inverse model. (a) Inverse model identification results; (b) Inverse model error

中可以看出，本文所采用的逆迟滞算子的模型辨识误差范围在 $\pm 0.06$  V，最小均方根误差 RMSE 为 0.0341 V，相对误差为 0.0140，而文献[16]中所采用的迟滞算子的模型辨识误差范围在-0.3 V 至+0.15 V，最小均方根误差 RMSE 为 0.197 V，相对误差为 0.0287。

为进一步验证本文所建立的压电陶瓷驱动器模型的辨识度，输入频率为 1 Hz，幅值为 16.8  $\mu$ m 的期望位移信号，将经过逆模型计算得到的电压值提供给压电陶瓷驱动器，采集测量得到压电陶瓷驱动器的输出位移值，分析跟踪误差，结果如图 7 所示。

图 7(a)中实线为期望位移输出，星点为实际位移输出。从图 7(b)中可以看出跟踪误差介于-0.2  $\mu$ m 至+0.2  $\mu$ m 之间，模型辨识最小均方根方差 RMSE 为 0.184

$\mu$ m，相对误差为 0.0135。图 8 为经过逆模型补偿后的迟滞曲线，迟滞大小为 1.43%。根据文献[19]以及实验测量数据，当输入电压幅值一定时，在低频范围内，压电陶瓷驱动器迟滞的大小和驱动电压的频率基本无关；在高频范围内，驱动电压的频率越高，迟滞就越大，同时有效输出位移量有所减小<sup>[19]</sup>。针对更高频率的电压，也可采用本文中的模型并结合频率进行建模。

从以上的结果可以看出，对于本文所研究的压电陶瓷驱动器，所建立的模型具有较为准确的辨识能力。研制出的同一批压电陶瓷驱动器，经过筛选过程后，迟滞差异不大。经过逆模型补偿控制后，可以降低压电陶瓷驱动器的非线性度，为后续的压电陶瓷驱动器的控制提供了基础。

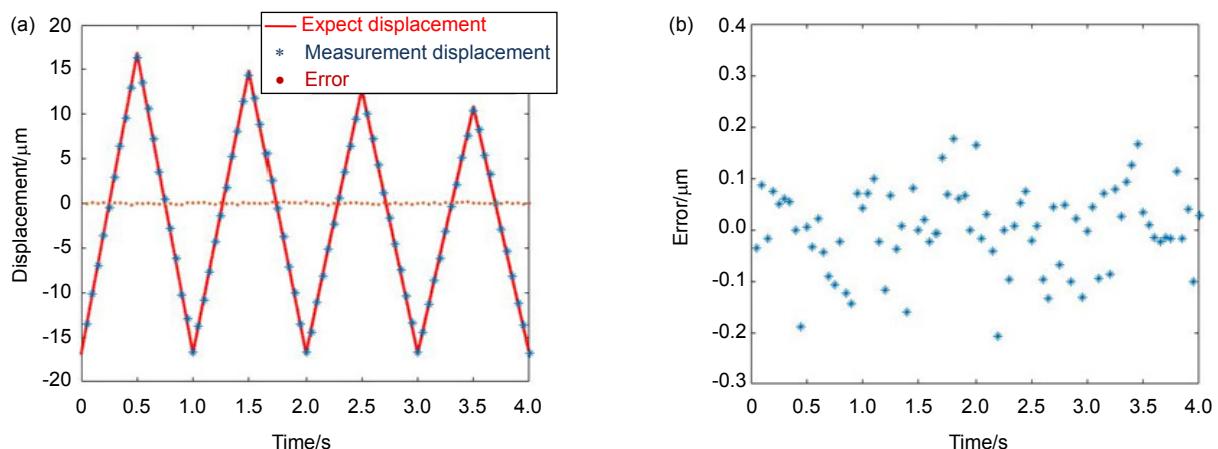


图 7 压电陶瓷驱动器迟滞模型跟踪示意图。(a) 位移跟踪示意图; (b) 误差示意图  
Fig. 7 Hysteresis model tracking for piezoelectric actuators. (a) Displacement tracking; (b) Error diagram

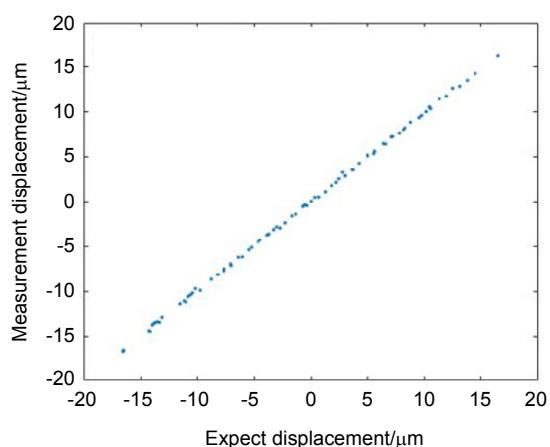


图 8 压电陶瓷驱动器迟滞补偿示意图  
Fig. 8 Hysteresis compensation

## 5 结 论

针对压电陶瓷驱动器的迟滞非线性，引入了迟滞算子，将输入输出之间的多值映射关系转化成单值映射关系，建立了基于 BP 神经网络的迟滞模型，建模方法相较于传统的方法简化了计算过程。在引入了迟滞算子并解决了过拟合问题后，适当调整神经网络的参数与神经元的个数，进而建立压电陶瓷驱动器模型。实验结果表明，针对中国科学院光电技术研究所研制的压电陶瓷驱动器所表现出的迟滞现象，本文建立的模型误差较低，迟滞正模型的相对误差为 0.0127，迟滞逆模型的相对误差为 0.0140，能够较为精确地反映出压电陶瓷驱动器的迟滞特性。经过逆模型补偿后，非线性度从最初的迟滞大小 14.6% 降低到了 1.43%。

## 参考文献

- [1] Jiang W, Li H, Liu C, et al. A 37-element adaptive optics system with H-S waveform sensor[C]//Proceedings of the 16th Congress of the International Commission for Optics, 1993: 127–134.
- [2] Parenti R R, Sasiela R J. Laser-guide-star systems for astronomical applications[J]. *Journal of the Optical Society of America A*, 1994, **11**(1): 288–309.
- [3] Jiang W H. Overview of adaptive optics development[J]. *Opto-Electronic Engineering*, 2018, **45**(3): 170489.  
姜文汉. 自适应光学发展综述[J]. 光电工程, 2018, **45**(3): 170489.
- [4] Tyson R K. *Principles of Adaptive Optics*[M]. Boston: Academic Press, 1991.
- [5] Huang L H, Fan M W, Zhou R, et al. System identification and control for large aperture fast-steering mirror driven by PZT[J]. *Opto-Electronic Engineering*, 2018, **45**(3): 170704.  
黄林海, 凡木文, 周睿, 等. 大口径压电倾斜镜模型辨识与控制[J]. 光电工程, 2018, **45**(3): 170704.
- [6] Wang W M, Wang Q. Development and characterization of a 140-element MEMS deformable mirror[J]. *Opto-Electronic Engineering*, 2018, **45**(3): 170698.  
汪为民, 王强. 140 单元 MEMS 变形镜研制及测试分析[J]. 光电工程, 2018, **45**(3): 170698.
- [7] Yan Z J, Li X Y. Neural network prediction algorithm for control voltage of deformable mirror in adaptive optical system[J]. *Acta Optica Sinica*, 2010, **30**(4): 911–916.  
颜召军, 李新阳. 基于神经网络的自适应光学系统变形镜控制电压预测方法[J]. 光学学报, 2010, **30**(4): 911–916.
- [8] Wang C C, Hu L F, He B, et al. Hysteresis compensation me-
- thod of piezoelectric steering mirror based on neural network[J]. *Chinese Journal of Lasers*, 2013, **40**(11): 1113001.  
王冲冲, 胡立发, 何斌, 等. 基于神经网络的压电倾斜镜磁滞补偿方法研究[J]. 中国激光, 2013, **40**(11): 1113001.
- [9] Moheimani S O R. Accurate and fast nanopositioning with piezoelectric tube scanners: Emerging trends and future challenges[J]. *Review of Scientific Instruments*, 2008, **79**(5): 1–11.
- [10] Mayergoyz I D. *Mathematical Models of Hysteresis*[M]. New York: Springer-Verlag, 1991.
- [11] Hu H, Mrad R B. On the classical Preisach model for hysteresis in piezoceramic actuators[J]. *Mechatronics*, 2003, **13**(2): 85–94.
- [12] Banks H T, Kurdila A J. Hysteretic control influence operators representing smart material actuators: identification and approximation[C]//Proceedings of the 35th IEEE Conference on Decision and Control, 1996: 3711–3716.
- [13] Su C Y, Wang Q Q, Chen X K, et al. Adaptive variable structure control of a class of nonlinear systems with unknown Prandtl-Ishlinskii hysteresis[J]. *IEEE Transactions on Automatic Control*, 2005, **50**(12): 2069–2074.
- [14] Liu X D, Xiu C B, Li L, et al. Hysteresis modeling using neural networks[J]. *Piezoelectrics & Acoustooptics*, 2007, **29**(1): 106–108.  
刘向东, 修春波, 李黎, 等. 迟滞非线性系统的神经网络建模[J]. 压电与声光, 2007, **29**(1): 106–108.
- [15] Qian F, Xu S A, Liu Y R, et al. Neural network modeling based on polynomial fitting for hysteresis behavior of piezoelectric actuator[J]. *Computer Simulation*, 2015, **32**(1): 361–366.  
钱飞, 许素安, 刘亚睿, 等. 基于多项式拟合的压电陶瓷迟滞神经网络建模[J]. 计算机仿真, 2015, **32**(1): 361–366.
- [16] Zhao X L. Modeling and control for hysteresis systems based on hysteretic operator[D]. Shanghai: Shanghai Jiao Tong University, 2006.  
赵新龙. 基于迟滞算子的迟滞非线性系统建模与控制研究[D]. 上海: 上海交通大学, 2006.
- [17] Ma L W, Tan Y H, Zou T. Modeling hysteresis using expanding-space method[J]. *Journal of System Simulation*, 2008, **20**(20): 5635–5637, 5641.  
马连伟, 谭永红, 邹涛. 采用拓展空间法建立迟滞模型[J]. 系统仿真学报, 2008, **20**(20): 5635–5637, 5641.
- [18] Luo Y, Liu Y J, Zhu G P, et al. Bayesian-regularization neural network for corporation credit rating[J]. *Computer Simulation*, 2010, **27**(11): 303–306.  
罗烨, 柳益君, 朱广萍, 等. 基于贝叶斯正则化神经网络的企业资信评估[J]. 计算机仿真, 2010, **27**(11): 303–306.
- [19] Wang G. Study on correction of nonlinearity of piezoelectric actuator[D]. Chengdu: Institute of Optics and Electronics, Chinese Academy of Sciences, 2013.  
王耿. 压电驱动器非线性校正技术研究[D]. 成都: 中国科学院研究生院(光电技术研究所), 2013.

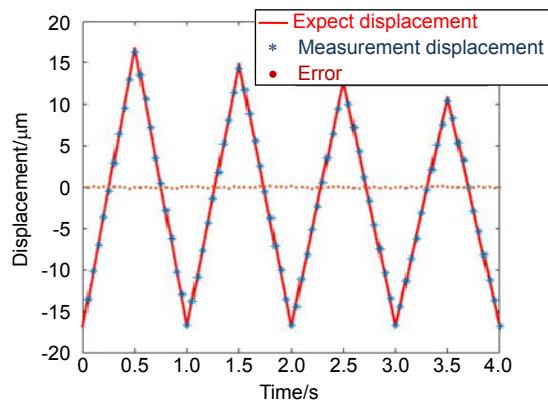
# Hysteresis nonlinear modeling and inverse compensation of piezoelectric actuators

Liu Xin<sup>1,2,3</sup>, Li Xinyang<sup>1,2\*</sup>, Du Rui<sup>1,2</sup>

<sup>1</sup>Key Laboratory of Adaptive Optics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China;

<sup>2</sup>Institute of Optics and Electronics, Chinese Academy of Sciences, Chengdu, Sichuan 610209, China;

<sup>3</sup>University of Chinese Academy of Sciences, Beijing 100049, China



Hysteresis model displacement tracking for piezoelectric actuators

**Overview:** Adaptive optics is used to correct the wavefront distortion caused by atmospheric turbulence in real time. The tilt mirrors and deformable mirrors in adaptive optics system usually use piezoelectric ceramic actuators for precise displacement, however, piezoelectric ceramic actuators own obviously nonlinear hysteresis effect which affects the positioning performance of the system. In order to compensate the hysteresis, there is a need to model hysteresis effects. Due to the limitation of computation quantity and dimension of traditional hysteresis model, it is difficult to find the analytic inverse model, which is not conducive to the application of engineering practice. Neural network can approximate any nonlinear curve and owns the adaptive learning ability, strong fault tolerance and the very high ability of system identification, data processing ability and the ability of fast parallel computing, which makes the neural network widely used in nonlinear system modeling. It can be inferred from incomplete or noisy data in the training process and can be easily combined with the controller design. In the application of neural network, the input and output relationship of mapping is one-to-one or many-to-one mapping relationship, but the relationship between voltage and displacement of piezoelectric ceramic actuator is one-to-many mapping relations, neural network cannot deal directly with this nonlinear mapping. In this paper, by introducing a hysteresis operators to expand the input voltage of piezoelectric ceramic actuator in neural network input space, the multimapping of hysteresis is transformed into one-to-one mapping in 3D space. In the transformed space, the neural network is used to approximate the one-to-one mapping and a hysteresis non-linearity based on the neural network is established, the one-dimensional feature is introduced for the input of neural network by constructing the hysteresis operator. In this paper, the Powell-Beale algorithm, Levenberg-Marquardt algorithm and Bayesian regularization algorithm are compared, and the Bayesian regularization training algorithm was used to train BP neural network to construct the positive hysteresis model and inverse model of piezoelectric ceramic actuators, and an experimental study was conducted on a piezoelectric actuator developed by Institute of Optics and Electronics, Chinese Academy of Sciences. According to the established model, the hysteresis positive model, inverse model and hysteresis compensation experiment of piezoelectric ceramic actuator are carried out. The final experimental results show that the hysteresis model of piezoelectric ceramic actuators constructed by BP neural network has more accurate identification capability. The relative error of the positive model is 0.0127 and the relative error of the inverse model is 0.014. The nonlinearity of the piezoelectric actuators has been reduced from 14.6% to 1.43%.

**Citation:** Liu X, Li X Y, Du R. Hysteresis nonlinear modeling and inverse compensation of piezoelectric actuators[J]. *Opto-Electronic Engineering*, 2019, **46**(8): 180328

Supported by National Key Research and Development Program (2017YFB0405100)

\* E-mail: xyli@ioe.ac.cn