

DOI:10.19651/j.cnki.emt.2107830

基于 RBF 神经网络的迟滞非线性模型预测控制 *

王亚峰¹ 安坤¹ 孟江²

(1. 中北大学 电气与控制工程学院 太原 030051; 2. 中北大学 机械工程学院 太原 030051)

摘要: 压电执行器具有响应快、质量比大、刚度高等特点,在纳米技术领域得到了广泛的应用。迟滞特性作为一种固有的非线性特性,极大地影响了迟滞控制的性能。本文提出了一种非线性模型预测控制(NMPC)方法来解决压电执行器的位移跟踪问题。首先,利用RBF神经网络实现了压电执行器的“外源输入非线性自回归移动平均”(NARMAX)模型;其次,利用NMPC原理将跟踪控制问题转化为优化问题,然后采用梯度下降算法求解。为验证所提出的建模和控制方法的有效性,并进行了MATLAB与COMSOL仿真实验。结果表明,所提出的RBF预测模型具有令人满意的精度,NMPC方法跟踪所得期望位移与实际位移绝对误差值最大达到0.016 μm,平均绝对误差达到0.012 1 μm,具有较高的精度。

关键词: 神经网络;迟滞建模;非线性预测控制;MATLAB

中图分类号: TP389.1; TB381 文献标识码: A 国家标准学科分类代码: 510

Nonlinear model predictive control of hysteresis based on RBF neural network

Wang Yafeng¹ An Kun¹ Meng Jiang²

(1. School of Electrical and Control Engineering, North University of China, Taiyuan 030051, China;

2. School of Mechanical Engineering, North University of China, Taiyuan 030051, China)

Abstract: Piezoelectric actuators have the characteristics of fast response, large mass ratio, high rigidity, etc., and have been widely used in the field of nanotechnology. As a kind of inherent nonlinear characteristic, hysteresis characteristic greatly affects the performance of hysteresis control. This paper proposes a nonlinear model predictive control (NMPC) method to solve the displacement tracking problem of piezoelectric actuators. First, the RBF neural network is used to realize the "external input nonlinear autoregressive moving average" (NARMAX) model of the piezoelectric actuator; secondly, the NMPC principle is used to transform the tracking control problem into an optimization problem, and then the gradient descent algorithm is used to solve it. In order to verify the effectiveness of the proposed modeling and control methods, MATLAB and COMSOL simulation experiments were carried out. The results show that the proposed RBF prediction model has satisfactory accuracy, the maximum absolute error between the expected displacement and the actual displacement obtained by the NMPC method tracking is 0.016 μm, and the average absolute error is 0.012 1 μm, which has high accuracy.

Keywords: neural network; hysteresis modeling; nonlinear predictive control; MATLAB

0 引言

迟滞是铁磁材料和压电陶瓷中普遍存在的一种记忆现象。由于迟滞的存在,压电执行器(piezoelectric actuators, PEA)的位移不仅依赖于当前控制输入,而且还依赖于历史输入^[1]。此外,输入信号的频率也会影响压电执行器的动态响应。

迟滞建模是提高迟滞控制性能的重要环节。描述迟滞效应的模型有几种,一般可分为基于物理的模型^[2-3]和基于现象的模型^[4-5]。基于物理的模型有清晰的物理解释。物理模型虽然从物理本质上描述了迟滞的机理,但这种方法往往存在公式推导复杂、计算量大的缺点。而基于现象的模型是从实验数据中得到的,数学描述相对简单,在实际应用中比较流行。实际上,针对迟滞这种难以进行机理建模

收稿日期:2021-09-09

*基金项目:国家自然科学基金项目(61774138)、山西省面上自然科学基金项目(201801D121184)资助

的复杂过程,利用实际可测量的输入输出数据来辨识模型成为必然选择^[6]。Cao 等^[7]采用自回归移动平均法提出了一个离散模型,实验结果表明该模型准确地描述了迟滞现象。Deng 等^[8]提出了一种具有外生输入的非线性自回归移动平均 (nonlinear autoregressive moving average with exogenous inputs, NARMAX) 模型,该模型具有同时呈现静态滞后和动态滞后的能力。实验证明了 NARMAX 模型的准确性。然而,由于对离散迟滞方程积分项的估计,模型在高频处的估计误差大于低频处的估计误差。

径向基函数(radial basis function, RBF)神经网络有很强的非线性拟合能力,可映射任意复杂的非线性关系,而且学习规则简单,便于计算机实现。具有很强的鲁棒性、记忆能力、非线性映射能力以及强大的自学习能力,从根本上解决了 BP 网络的局部最优问题。

除了对压电执行器进行建模外,如何设计有效的基于模型的压电执行器控制算法也是文献研究的重点。基于逆的前馈控制是目前最流行的方法。在该方法中,首先得到了迟滞子模型的逆模型^[9]。然后,利用该逆模型对迟滞非线性进行补偿。一旦迟滞模型被补偿,剩下的就是设计动态模型的反馈控制器。以压电控制器为例,提出了比例-积分-微分(PID)控制器与逆 Preisach 迟滞模型相结合的控制方法。Leang 等^[10]提出的开环跟踪中,控制采用了一种最近匹配算法来获取迟滞逆模型。

然而,基于逆模型的控制方法的跟踪性能很大程度上依赖于迟滞逆模型的精度。迟滞逆模型的计算并不是一项容易的任务。这种方法的挑战在于建模的复杂性。同时,迟滞逆模型的在线计算为实时跟踪控制增加了额外的负担。求逆计算方法可分为基于模型的方法和基于算法的方法^[11]。基于模型的方法是识别一些中间函数的逆函数,并利用这些中间函数的逆函数逼近迟滞模型。例如,逆 Preisach 模型没有解析解,只能使用基于模型的反演近似方法。虽然逆 Prandtl-Ishlinskii 模型可以进行解析计算,但计算时间太长仍然是不可接受的。此外,现有的一些迟滞模型可能根本不是可逆的。其次,采用基于算法的方法对逆迟滞模型^[12-13]算法的方法通常采用迭代算法来识别逆迟滞模型。该方法的主要缺点是计算量大,收敛速度慢^[14]。

鉴于此,本文提出了一种基于 RBF 神经网络的模型预测控制器,用于压电执行器的位移跟踪控制。首先,提出了一种基于 RBF 神经网络的外源输入非线性自回归移动平均(NARMAX)模型,用于建立压电执行器的迟滞模型。其次,提出了一种非线性模型预测控制 (nonlinear model predictive control, NMPC) 方法来处理位移跟踪问题。NMPC 方法可以避免迟滞模型求逆的计算,节省了计算资源,适合在线控制。最后,为了验证所提出的建模和控制算法的有效性,在 MATLAB 上进行了仿真实验。通过实验结果和相应的比较,所提出的控制器的跟踪性能令人满意。

1 建 模

NARMAX 模型是一种识别未知非线性系统有效方法。它通常用于预测非线性系统的下一个输出。在不考虑噪声影响的情况下,NARMAX 模型的简化表示如下:

$$y(t) = F(y(t-1), \dots, y(t-a), u(t), \dots, u(t-b)) \quad (1)$$

式中: $y(t)$ 和 $u(t)$ 是模型的输出和输入,常量 a 和 b 表示历史输出和历史输入的数量。

由于 RBF 神经网络具有结构简单、训练简洁、学习收敛速度快、能够逼近任意非线性函数,克服局部极小值问题的优点,利用 RBF 建立迟滞模型与 NARMAX 模型之间的关系。采用基于反向传播方法不断改进权重和阈值,直到达到所需的误差限制或迭代次数。压电执行器的迟滞受过去样本中输入和输出的影响,因此过去样本中的电压,选择当前电压和过去样本中的位移作为模型的输入。因此,导出 NARMAX 模型为:

$$\hat{y}(t+1) = F_{NN}(y(t-1), \dots, y(t-a), u(t), \dots, u(t-b)) \quad (2)$$

式中: $\hat{y}(t+1)$ 代表第 $t+1$ 个采样时间的预测位移,常数 a 和 b 的值将会影响模型的准确性。

如图 1 所提出的 RBF 迟滞模型是具有单隐层的 3 层前向网络。第 1 层为输入层,由信号源节点组成。第 2 层为隐藏层,隐藏层节点数视所描述问题的需要而定。第 3 层为输出层,是对输入模式做出的响应。输出层是对线性权进行调整,采用的是线性优化策略,因而学习速度较快。RBF 神经网络算法流程如下。

1) 首先确定神经网络输入为:

$$x_i(t) = \begin{cases} y(t-1) \\ \dots \\ y(t-a) \\ u(t) \\ \dots \\ u(t-b) \end{cases} \quad (3)$$

2) 运用 K-means 聚类算法选取 m 个中心点 c_i 和方差 δ_i ,则;

$$\delta_i = \frac{c_{\max}}{\sqrt{2m}} \quad (4)$$

式中: $i=1, 2, \dots, m$; c_{\max} 为所选取中心点之间的最大距离。

3) 根据径向基函数(本文采用常用的高斯函数)计算隐含层输出值:

$$h_j = \sum_{i=1}^{a+b-1} \exp\left(-\frac{\|x_i - c_j\|^2}{2\delta_j^2}\right) \quad (5)$$

式中: $j=1, 2, \dots, m$ 。

4) 计算输出层权重:

$$w_j = \exp\left(\frac{m}{c_{\max}} \|x_p - c_j\|^2\right) \quad (6)$$

式中: x_j 为输入样本, $j=1, 2, \dots, m$ 。

5) 计算神经网络输出值:

$$\hat{y}(t) = \sum_{j=1}^m h_j(t) w_j \quad (7)$$

预测位移 $\hat{y}(t)$ 和测量位移 $y(t)$ 之间的均方误差用于训练网络连接参数, 表示为:

$$E = \frac{1}{2} \sum_{i=1}^p (\hat{y}(t) - y(t))^2 = \frac{1}{2} \sum_{i=1}^p (e(t))^2 \quad (8)$$

式中: P 是样本个数。

在 RBF 算法运行过程中, 不断调整所提出模型中的权重和阈值, 直到将均方差 E 调整到可接受的最小值, 然后最终输出可以足够接近预期的真实值。

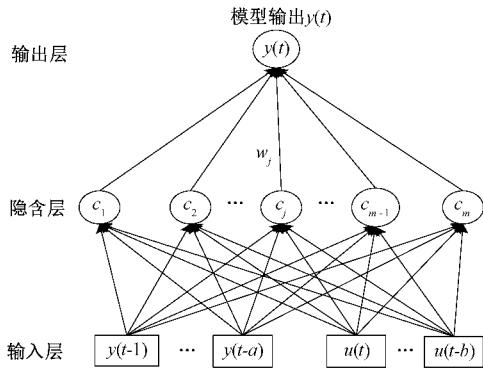


图 1 神经网络迟滞模型

2 NMPC 控制算法

基于逆模型的控制方案广泛用于 PEA 的控制器设计。然而, 对于逆模型的计算十分复杂。因此, 无逆模型控制器设计方法可能是位移跟踪控制的更好选择。Xu 等^[15] 提出模型预测控制(model predictive control, MPC)来消除滑模控制(sliding mode control, SMC)中的抖动问题, 但是, 仍然需要速度观测器。Cheng 等^[16] 提出了一种 NMPC 方法, 然后在商业压电执行器上实现。虽然它是一种无逆方法, 但控制律是通过求解一个复杂的非线性优化问题来确定的, 并且抗干扰能力较差, 因此本文采用的控制方法如图 2 所示, 通过比较参考轨迹与预测模型, 使用梯度下降算法在线优化性能指标以求取控制律, 并实时计算实际位移与预测模型的误差, 在线修正预测模型。

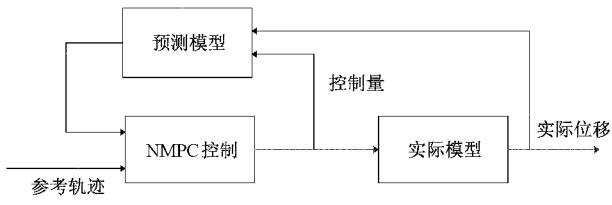


图 2 压电执行器的 NMPC 示意图

建好控制对象的 RBF 预测模型后, 为了获取控制量, MPC 在每个控制步中都需要在线求解式(9)表示的一个非

线性优化问题。本文利用梯度下降算法在线优化性能指标以求取控制律^[17]。

$$J = \frac{1}{2} \{(r(t+1) - \hat{y}(t+1))^2 + q(\Delta U(t))^2\} \quad (9)$$

式(9)可以等价为如下的二次型形式:

$$J = \frac{1}{2} [[R(t+1) - \hat{Y}(t+1)]^T [R(t+1) - \hat{Y}(t+1)] + Q \Delta U(t)^T \Delta U(t)] \quad (10)$$

利用梯度下降算法对优化性能指标式(10)进行寻优, 可以获取控制增量向量 $\Delta U(t)$, 如下:

$$U(t+1) = U(t) - \eta \frac{\partial J}{\partial U(t)} = U(t) + \eta \frac{\partial \hat{y}(t+1)}{\partial U(t)} - \eta Q \Delta U(t) \quad (11)$$

式中: η 为梯度法的自适应优化率。根据式(11), $\Delta U(t)$ 可以表示为:

$$\Delta U(t) = (1 + \eta Q)^{-1} \eta \frac{\partial \hat{y}(t+1)}{\partial U(t)} [R(t+1) - Y(t+1)] \quad (12)$$

根据链式求导法则, 可以获得式(12)中的 $\frac{\partial \hat{y}(t+1)}{\partial U(t)}$ 为:

$$\frac{\partial \hat{y}(t+1)}{\partial U(t)} = \sum_{i=1}^m \sum_{j=1}^{a+b+1} w_i \left(\frac{x_i - c_j}{\delta_j^2} \right) \exp \left(- \frac{\|x_i - c_j\|^2}{2\delta_j^2} \right) \quad (13)$$

式中: a, b 与前文相同。

在实时控制过程的每一步, 这一过程反复执行, 直至 J 达到最小或 $U(t)$ 不再变化, 此时将 $U(t)$ 作为最优控制量作用到系统实施控制。

3 实验结果与分析

为了证实所提出的模型与控制算法的有效性, 使用 MATLAB 与 COMSOL 联合仿真, 通过使用 COMSOL LiveLink™ for Simulink® 模块来仿真压电执行器, 通过控制器给出的控制信号输出实际位移, 具体的控制算法与建模在 SIMULINK 环境中进行编程。

3.1 模型验证与比较

验证 RBF 迟滞模型, 根据 NARMAX 模型和 RBF 的原理, 输出层只有一个节点, 但其他两层节点的数量未知, 所以应该选择其余两层的节点个数。因此, 采用 $(a+b+1)-c-1$ 结构的网络拓扑结构, 其中常数 $a+b+1$ 为输入层节点数, c 为隐藏层节点数。在下面的实验中, 比较 RBF 算法在不同网络拓扑之间的性能, 其中常数 a 取值为 0~4 之间, b 取值为 1~3 之间, 因为随着隐含层节点个数数目过大, 会使训练时间过长, 网络的泛化能力降低, 而且误差也不一定最佳, 因此先将 c 的取值选择 0~20 之间, 后期通过实验来确定是否增加隐含层个数。

实验通过将这些值与均方根误差和绝对误差界限两个

性能指标进行比较,得到了给定条件下的最优网络拓扑。

如表 1 所示当 a 取 0 即没有历史输入时,模型误差都相对较大,而当 a 值不为 0 时,模型误差相差不大,而当 c 值越大时,误差越小,但误差相差数量级较小,所以根据实验结果最后选择 $c=20, a=3, b=2$ 。

表 1 不同网络拓扑结构下的迟滞建模性能

c 值	a 取值	b 取值	模型的均方根	模型的绝对
			误差/ μm	误差界/ μm
5	0	1	0.214 6	0.769 5
	3	2	0.025 8	0.083 7
	4	3	0.019 6	0.076 9
10	0	1	0.153 6	0.554 7
	3	2	0.018 4	0.072 4
	4	3	0.019 0	0.076 3
15	0	1	0.166 5	0.595 4
	3	2	0.018 6	0.074 5
	4	3	0.018 0	0.070 9
20	0	1	0.144 5	0.518 3
	3	2	0.016 9	0.065 9
	4	3	0.017 4	0.067 1

图 3 验证了 NARMAX 模型对压电执行器的精度,从图 3 中可以看出,所提出的模型很好地识别了压电执行器的迟滞特性。

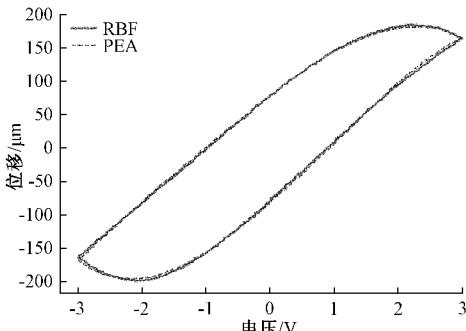


图 3 迟滞模型逼近

3.2 NMPC 算法验证

为了验证 NMPC 方法的性能,首先分析了不同学习率对 NMPC 性能的影响。其次分析了控制方法的抗干扰能力。最后比较了 NMPC 方法与基于逆模型的 PID 控制。

算法中需要调整的参数有最大迭代次数 N 。与学习率,最大迭代次数是 NMPC 方法的一个重要参数。控制性能可以随着最大迭代次数的增加而提高。但是,如果最大迭代次数太大,NMPC 算法的计算时间会更长。权衡了控制性能与效率之后,本文选取最大迭代次数为 5,而学习率 η 通过对恒幅值参考轨迹的跟踪来确定。

从图 4 中可以看出,随着 η 的减小,压电执行器的超调

量减小。同时,上升时间变得稍长,因为较大的惩罚参数 η 导致相对较小的控制工作。因此选择为 η 为 0.4。

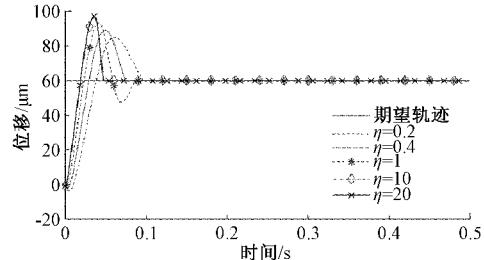


图 4 不同学习率对控制性能的影响

NMPC 控制器的抗扰特性如图 5、6 所示。在压电执行器的动态响应进入稳定阶段后,在不同时间加入扰动输入 $d(t)$ (主要由外部扰动引起)。可以看出,即使 $d(t)$ 不能被迟滞模型预测,预测控制器也有很好的抗干扰能力。

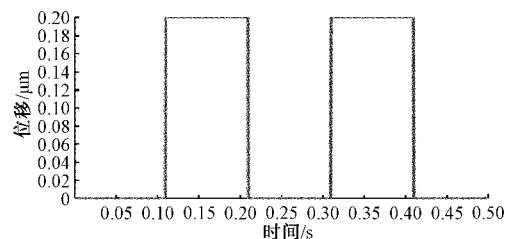


图 5 输入的干扰信号

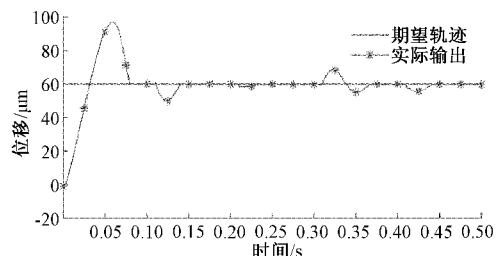


图 6 在干扰信号下的控制性能

最后,使用所提出的 NMPC 控制器与基于逆模型的 PID 控制器作比较,跟踪幅值为 40,频率为 1 Hz 的正弦波。用于评估 NMPC 控制方法的控制性能。图 7 所示为 2 Hz 正弦轨迹下的跟踪实验结果。

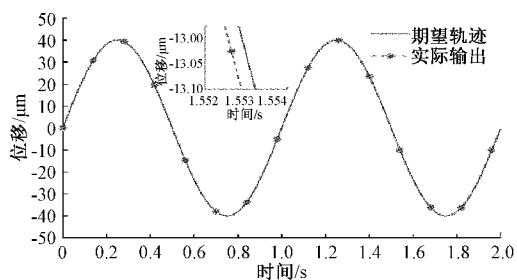


图 7 PID 的跟踪性能

如图 8 所示,输入正弦信号,所得的期望位移与实际位

移绝对误差值最大达到 $0.101 \mu\text{m}$, 平均误差为 $0.086 \mu\text{m}$, 且控制波动较大, 控制性能不够理想。

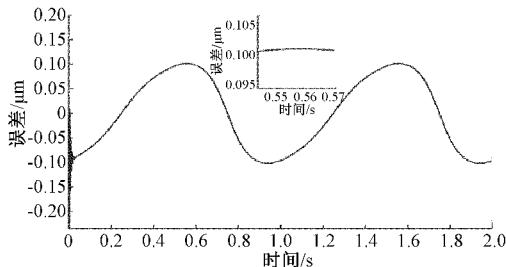


图 8 PID 的跟踪误差

图 9 所示为 2 Hz 正弦轨迹下的跟踪实验结果, 由图可知, 压电执行器的实际位移可以很好地跟踪参考轨迹。

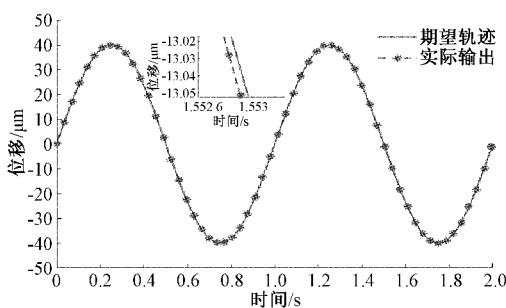


图 9 NMPC 的跟踪性能

如图 10 所示, 与传统基于逆模型的 PID 控制器相比跟踪误差有显著的降低, 这是因为所提出的 NMPC 方法是一种无求逆方法, 因此可以避免由反演计算引起的错误。同时, NMPC 方法基于反馈结构, 可以补偿外部干扰。通过利用这些优点, 所提出的 NMPC 方法可以将跟踪误差降低到令人满意的范围, 图 10 分析了期望位移与实际唯一的误差, 所得期望位移与实际位移绝对误差值最大达到 $0.016 \mu\text{m}$, 平均绝对误差达到 $0.0121 \mu\text{m}$ 。因此, 所提出的 NMPC 方案能够满足实际工作的需求。同时, 在线更新模型会提高控制精度, 提供很强的抗干扰能力, 以将跟踪误差降低到令人满意的范围内。

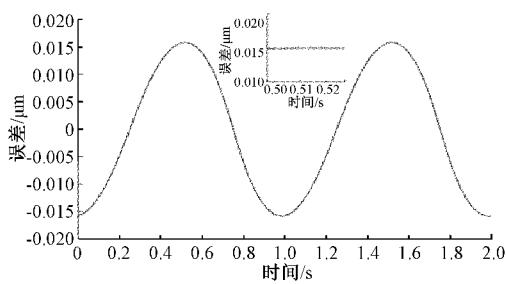


图 10 NMPC 的跟踪误差

4 结 论

本文使用了一种基于 RBF 神经网络的外源输入非线

性自回归移动平均(NARMAX)模型, 用于建立压电执行器的迟滞预测模型。分析了不同拓扑结构下 RBF 逼近精度, 确定了最优拓扑结构, 得到了令人满意的逼近精度。通过搭建的预测模型使用非线性模型预测控制方法跟踪期望轨迹。与基于求逆的控制方案相比, NMPC 方法可以直接使用基于非线性神经网络的模型, 不需要求解复杂的逆模型, 通过求解相应的优化问题来计算控制量。使所得期望位移与实际位移绝对误差值最大达到 $0.016 \mu\text{m}$, 平均绝对误差达到 $0.0121 \mu\text{m}$ 。通过 SIMULINK 与 COMSOL 软件进行了实验。仿真结果表明, 所提出的 RBF 的预测模型的预测值与实际值基本吻合, 取得了令人满意的建模效果。并与基于逆模型的 PID 控制进行比较。所提出的 NMPC 控制器具有较高的跟踪精度和较强的自适应能力。能够满足复杂非线性系统的智能控制需求。

参 考 文 献

- [1] RANA M S, POTA H R, PETERSEN I R. Nonlinearity effects reduction of an AFM piezoelectric tube scanner using MIMO MPC [J]. IEEE/ASME Transactions on Mechatronics, 2015, 20 (3): 1458-1469.
- [2] PENG J, CHEN X. A survey of modeling and control of piezoelectric actuators [J]. Modern Mechanical Engineering, 2013, 3(1): 1-20.
- [3] ZHANG X, SU C Y, LIN Y, et al. Adaptive neural network dynamic surface control for a class of time-delay nonlinear systems with hysteresis inputs and dynamic uncertainties [J]. Neural Networks and Learning Systems, IEEE Transactions on, 2015, 26(11): 2844-2860.
- [4] 钟云, 黄楠, 曾俊海. 压电驱动器迟滞非线性的增强型 Prandtl-Ishlinskii 模型建模及实验验证[J]. 机电工程技术, 2020, 49(10): 33-35.
- [5] 郑文轩, 唐志峰, 杨昌群, 等. 基于 Preisach 模型的磁致伸缩位移传感器迟滞补偿方法[J]. 仪器仪表学报, 2021, 42(5): 79-89.
- [6] QIANG W, CHAO Z, DONG Z, et al. Modeling of piezoelectric actuator based on genetic neural network[C]. Automation and Logistics (ICAL), 2012 IEEE International Conference on, IEEE, 2012: 136-140.
- [7] CAO Y, CHEN X B. A novel discrete ARMA-based model for piezoelectric actuator hysteresis[J]. IEEE/ASME Trans Mechatron, 2012, 17(4): 737-744.
- [8] DENG L, TAN Y. Modeling hysteresis in piezoelectric actuators using NARMAX models [J]. Sensors & Actuators A Physical, 2009, 149(1): 106-112.
- [9] PAN Y, PAN H, ZHAO X. Dynamic hysteresis nonlinearity characteristics modeling of piezoceramic

- actuator[J]. Transducer and Microsystem Technologies , 2019, 67(5): 9-13.
- [10] LEANG K, DEVASIA S. Feedback-linearized inverse feedforward for creep, hysteresis, and vibration compensation in AFM piezoactuators [J]. IEEE Transactions on Control Systems Technology, 2007, 15(5): 927-935.
- [11] SONG G, ZHAO J, ZHOU X Q, et al. Tracking control of a piezoceramic actuator with hysteresis compensation using inverse Preisach model [J]. Mechatronics, IEEE/ASME Transactions on Mechatronics, 2005, 10(2): 198-209.
- [12] TAN X, VENKATARAMAN R, KRISHNAPRASAD P S. Control of hysteresis: Theory and experimental results [J]. Maryland: University of Maryland, College, 2001, 4326: 101-112.
- [13] KRISHNAPRASAD R. Approximate inversion of hysteresis: Theory and numerical results [J]. Proceedings of the IEEE Conference on Decision and Control, 2000, 5: 4448-4454.
- [14] PENG J, CHEN X. H₂-optimal digital control of piezoelectric actuators[C]. 2010 8th World Congress on Intelligent Control and Automation, IEEE, 2010: 3684-3690.
- [15] XU Q, LI Y. Micro-/Nanopositioning using model predictive output integral discrete sliding mode control[J]. Industrial Electronics IEEE Transactions on, 2012, 59(2): 1161-1170.
- [16] CHENG L, LIU W C, HOU Z G, et al. Neural-network-based nonlinear model predictive control for piezoelectric actuators [J]. IEEE Transactions on Industrial Electronics, 2015, 62(12): 7717-7727.
- [17] 周红标, 张钰, 柏小颖, 等. 基于自适应模糊神经网络的非线性系统模型预测控制[J]. 化工学报, 2020, 71(7): 3201-3212.

作者简介

王亚峰,硕士研究生,主要研究方向为MEMS器件智能控制。

E-mail:876220373@qq.com

安坤(通信作者),副教授,博士,主要研究方向为MEMS器件系统设计等。

E-mail: ankun@nuc.edu.cn