

基于 GRU-NN 预测模型的压电作动器 MPC-KAN 控制方法

郭辰星, 李自成, 徐瑞瑞

(武汉工程大学 电气信息学院, 湖北 武汉 430205)

摘要: 为了提高压电作动器(PEAs)的轨迹跟踪性能, 提出了一种基于门控递归单元(GRU)神经网络(NN)预测模型的 Kolmogorov-Arnold 网络前馈模型预测控制(MPC-KAN)。与神经网络逆模型控制不同, 该方法使用 GRU-NN 正向建模, 并根据模型预测结果调整模型预测控制(MPC)的输出。首先, 根据线性化模型选择 GRU-NN 的训练输入特征, 并训练该网络。然后, 为了提高优化效果和缩短优化时间, 将麻雀搜索算法(SSA)用作 MPC 优化器, 并建立 Kolmogorov-Arnold 网络(KAN)以替代 SSA 优化。该方法的有效性在 PEAs 平台上得到验证, 与传统方法相比, 控制精度提高了约 30%。

关键词: 压电陶瓷作动器; 高精度跟踪; 模型预测控制; GRU 网络; KAN 网络

中图分类号: TN384 **文献标识码:** A

MPC-KAN Control Method for Piezoelectric Actuators Based on GRU-NN Prediction Model

GUO Chenxing, LI Zicheng, XU Ruirui

(School of Electrical and Information Engineering, Wuhan Institute of Technology, Wuhan 430205, China)

Abstract: To improve the trajectory tracking performance of piezoelectric actuators (PEAs), this study proposes a Kolmogorov-Arnold network feedforward model predictive control (MPC-KAN) based on a gated recurrent unit (GRU) neural network (NN) prediction model. Unlike neural network inverse model control, this method uses GRU-NN forward modeling and adjusts the model predictive control (MPC) output based on the model prediction results. First, this study selects the training input features of GRU-NN based on a linearized model and trains the network. Then, to improve optimization performance and shorten optimization time, the sparrow search algorithm (SSA) was used as the MPC optimizer, and a Kolmogorov-Arnold network (KAN) was established to replace the SSA optimization. The effectiveness of this method has been verified on the PEA platform. Compared with traditional methods, the control accuracy has been improved by approximately 30%.

Key words: piezoelectric actuator; high tracking precision; model predictive control; gated recurrent unit neural network; Kolmogorov-Arnold network

0 引言

压电微纳平台是一种实现高精度定位的纳米级制造设备, 具有无磨损、高分辨率、高效率、高强度、响应迅速等优良特性, 广泛应用于微机电系统、高速原子力显微镜、超精密机床和微加工平台定位系统^[1-2]。然而, 压电材料的输入输出存在非线性和动态效应, 压电材料的非线性包括蠕变非线性和迟滞非线性。压电材料的迟滞非线性是限制压电陶

瓷定位精度的主要因素。

近年来, 研究者试图将神经网络和传统的现象学模型融合起来以表征 PEAs 的滞后^[3-4]。文献[5]提出了一种结合级联神经网络和对称迟滞算子的模态方法。其中迟滞算子提供了潜在的迟滞运动, 神经网络用作迟滞算子的补充。后来, 用于处理时间序列的神经网络在没有传统滞后算子的情况下成功地用于 PEAs 中的滞后建模。文献[6]使用具

收稿日期: 2024-10-22

基金项目: 湖北省高等学校中青年科技创新团队项目(T2022012)

作者简介: 郭辰星(2000-), 男, 湖北省襄阳市人, 硕士生。通信作者: 李自成, 男, 教授。

有稳定结构的PI控制器系统作为控制对象,对其进行了逆模型控制,并在0~8 Hz范围内验证了其有效性,但该频率范围较窄。本文所提方法的有效性在更宽的频域上得到了验证。文献[7]提出了一种基于长短期神经网络(LSTM-NN)的MPC控制,并改进了反向传播算法,尽管改进后的算法优化时间较短,但对于高速变化的PEAs系统来说,其优化时间仍然是不可接受的。

PEAs跟踪控制中的闭环控制比开环前馈控制慢得多,且增加了安装位置传感的额外成本,开环前馈控制器因而具有优势。基于神经网络的开环前馈控制中的代表性控制方案包括逆模型控制和MPC控制。LSTM-NN是一种特殊类型的递归神经网络(RNN),旨在增强循环神经网络的记忆能力,广泛用于解决时间序列预测问题。GRU-NN是对LSTM-NN的改进,并在预测某些问题时拥有更好的性能^[8-9]。KAN具有多层感知器网络所没有的非常快的计算速度、高拟合精度和可观性^[10]。用KAN拟合SSA优化器可以大幅缩短控制的优化时间。

1 GRU-NN

1.1 GRU-NN的结构

GRU是一种能够有效处理时间序列数据的RNN,可用于解决梯度消失或爆炸的问题。GRU-NN的结构如图1所示。GRU网络可存储过去的信息,并使用更新门和重置门来控制信息的存储和遗忘。

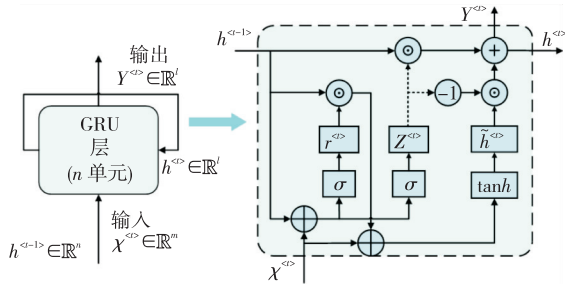


图1 GRU神经网络

图1中:

$$z^{(t)} = \sigma(W^z \chi^{(t)} + U^z h^{(t-1)} + b^z) \quad (1)$$

$$r^{(t)} = \sigma(W^r \chi^{(t)} + U^r h^{(t-1)} + b^r) \quad (2)$$

$$\tilde{h}^{(t)} = \tanh[W^h \chi^{(t)} + U^h (r^{(t)} \odot h^{(t-1)}) + b^h] \quad (3)$$

$$h^{(t)} = z^{(t)} h^{(t-1)} + (1 - z^{(t)}) \tilde{h}^{(t)} \quad (4)$$

$$Y^{(t)} = \sigma(W^y h^{(t)} + b^y) \quad (5)$$

式中: $\chi^{(t)} \in \mathbb{R}^n$ 是输入向量; $Y^{(t)} \in \mathbb{R}^l$ 是预测输出位移; $\tilde{h}^{(t)} \in \mathbb{R}^n$ 是隐藏层候选状态; $h^{(t)} \in \mathbb{R}^n$ 是隐藏层状态; $z^{(t)} \in \mathbb{R}^n$ 是更新门; $r^{(t)} \in \mathbb{R}^n$ 是重置门; $W^z \in \mathbb{R}^{n \times m}$ 、 $W^r \in \mathbb{R}^{n \times m}$ 和 $W^h \in \mathbb{R}^{n \times m}$ 是输入权重; $W^y \in \mathbb{R}^{l \times n}$ 是输出权重; $b^z \in \mathbb{R}^l$ 、 $b^r \in \mathbb{R}^l$ 、 $b^h \in \mathbb{R}^l$ 和 $b \in \mathbb{R}^l$ 是各个门状态的偏置。

1.2 输入特征的选择

通常PEAs的蠕变非线性可以表示为 t 的函数,动态效应表现出很强的 \dot{u} 相关性。因此,使用GRU-NN建立PEAs输入和输出之间的映射时,将 t 和 \dot{u} 添加到GRU-NN的输入特性中,可以更好地描述PEAs的蠕变非线性和动态响应。

PEAs的迟滞非线性不仅与当前时刻的输入输出有关,还与过去的输入和输出有关。由于输入电压的历史信息包含在历史位移信息中,故将 $y_{(k-p)}$ 、 $y_{(k-p+1)}$ 、 \dots 、 $y_{(k)}$ 加入输入特征中可以兼顾历史电压和历史位移。将未来时刻的 $u_{(k)}$ 、 \dots 、 $u_{(k+m-1)}$ 、 $u_{(k+m)}$ 作为输出,以实现从未来时刻输入电压到未来时刻输出位移的映射。

1.3 GRU-NN的训练

为了准确预测位移,设计了一个由50个单元和1个单元组成的两层GRU-NN结构,如图2所示。在训练阶段,只有参考轨迹数输入网络。




图2 GRU网络结构

设 T 为采样周期,将输入向量设计为20维,输出向量设计为1维,即:

$$\chi(t) = [u_{t+T_s}, \tau_{t+T_s},$$

$$y_{t-9T_s}, y_{t-8T_s}, y_{t-7T_s}, y_{t-6T_s}, y_{t-5T_s}, \quad (6)$$

$$y_{t-4T_s}, y_{t-3T_s}, y_{t-2T_s}, y_{t-T_s}, y_t]$$

$$Y(t) = [y_{t+T_s}] \quad (7)$$

式中 $u_{(t)}$ 、 $\tau_{(t)}$ 和 $y_{(t)}$ 分别表示时间 t 的输入电压、时间和参考输出位移。该网络仅预测一次步长输出。输入向量中包含9个时间步长的历史位移信息。

为了保证准确性和泛化能力,使用正弦波、三角波及其变体的多个频率数据来训练网络。训练数据涵盖了 2~100 Hz 的滞后特性,共 38 万组数据,由 20 条滞后曲线组成。该数据集由 PI 公司生产的商用压电堆栈收集,压电堆栈由 P563.3 PEAs 和 E-725 压电放大器组成。将这些输入、输出数据按 5:1 的比例分为含 30 400 对数据的训练集和含 76 000 对数据的验证集,并使用 ADAM 优化器训练整个网络。初始学习率设置为 5×10^{-3} ,批量大小为 32,训练周期设置为 100,学习率下降期设置为 50,学习率下降因子设置为 0.1。经测试,该网络显示出稳定的预测能力。

CNN-LSTM 网络是 LSTM-NN 的一种增强改进,在 LSTM 层之前加入了一个卷积层,以获得卓越的模型性能。本文将卷积层的卷积核设置为 3×3 ,特征映射设置为 4。从测试集中选择 4 个数据曲线来评估 GRU、LSTM 和 CNN-LSTM 在建模 PEAs 滞后方面的性能,结果如图 3 所示。图 3(a)-(c)中的曲线除频率以外具有与训练集相似的特征。图 3(d)中的曲线设计为一个复合波,用于评估神经网络在模型预测控制中的泛化能力。表 1 为验证集中 GRU、LSTM 和 LSTM-NN 的相对均方根误差 (RRMSE) 和均方根误差 (RMS)。

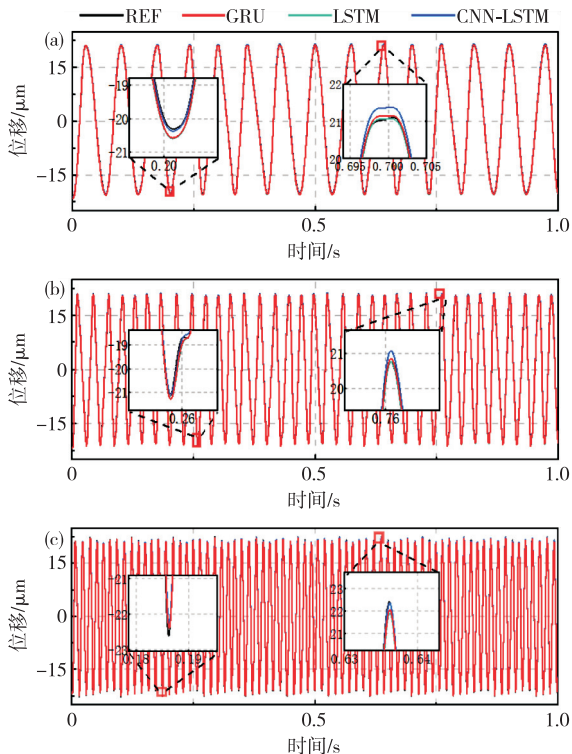


图 3 模型对比

表 1 预测模型误差对比

	GRU	LSTM	CNN-LSTM
$e_{rms}/\mu\text{m}$	0.262 5	0.361 9	0.299 9
$e_{rrmse}/\%$	0.55	0.75	0.62

2 MPC 控制器设计

2.1 滚动优化

基于神经网络预测模型的 MPC 生成一系列控制输入并对其进行调整,直到神经网络的输出可以接受。图 4 为该控制方法示意图。

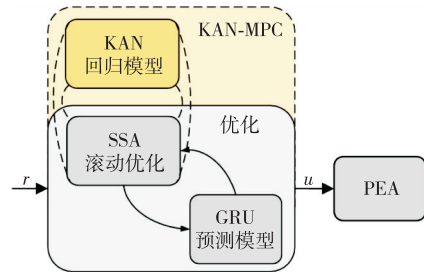


图 4 控制方法示意图

预测范围 p 表示 NN 模型基于输入预测的输出位移序列的长度。控制范围 m 表示要优化的输入电压序列的长度。本文的预测范围和控制范围都设置为 5。

利用 MPC 搜索成本函数的最小值以找到最优控制序列。成本函数通常考虑输出和参考之间的误差,以及输入变化的幅度。当使用 GRU 作为预测模型时,MPC 的成本函数可表示为

$$J_{MPC} = \sum_{j=1}^p [y_R(k+j) - y_P(k+j)]^2 + \sum_{j=1}^m \lambda(j) [\Delta u(k+j)]^2 \quad (8)$$

式中: $y_R(k+j)$ 表示 $k+j$ 时刻的输出参考值; $y_P(k+j)$ 表示在第 k 个采样周期中通过 GRU-NN 预测的第 j 个循环; $\Delta u(k+j) = u(k+j) - u(k+j-1)$ 表示相邻两个控制步的差值。

虽然待优化的电压有 5 个步,但只有 1 个步用于控制。MPC 中滚动优化的目的是在每个控制周

期内重新计算控制输入,以适应系统状态和快速调整,从而实现更好的控制性能。

2.2 SSA 优化

梯度下降(GD)算法不能优化由 NN 多次计算的多步预测问题,因为 $\frac{\partial y_p(k+j)}{\partial u(k+i)}$ ($i, j \neq 1$) 不能通过反向传播算法计算。

麻雀搜索算法的灵感来自麻雀的捕食和回避行为,将麻雀种群分为发现者和加入者。发现者负责寻找食物,并为种群提供觅食区的信息。加入者利用发现者来获取食物。初始化参数后,麻雀搜索算法按如下方式更新发现者位置、跟随者位置和群体位置:

$$X_{i,j}^{k+1} = \begin{cases} X_{i,j}^k \cdot \exp\left(\frac{-i}{\alpha \cdot \text{iter}_{\max}}\right) & \text{if } R_2 < ST \\ X_{i,j}^k + Q \cdot L & \text{if } R_2 \geq ST \end{cases} \quad (9)$$

$$X_{i,j}^{k+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^k - X_{i,j}^k}{i^2}\right) & \text{if } i > n/2 \\ X_P^{k+1} + |X_{i,j}^k - X_P^{k+1}| \cdot A^+ \cdot L & \text{otherwise} \end{cases} \quad (10)$$

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t| & \text{if } f_i > f_g \\ X_{i,j}^t + K \cdot \frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \epsilon} & \text{if } f_i = f_g \end{cases} \quad (11)$$

式中: X_{best} 表示全局最优位置; β 和 K 都是随机数; β 表示调整步长; ϵ 是一个非常小的常数; f_g 、 f_w 和 f_i 分别表示当前全局最佳、全局最差和麻雀 i 的适应度值; $f_i > f_g$ 表示这只麻雀处于种群的边缘; $f_i = f_g$ 则表明这只麻雀处于种群的中间。

将麻雀搜索算法的维度设置为 5,将总体大小设置为 100,最大迭代次数设置为 50,以输出 5 个最佳控制序列。

MPC 的优化过程如图 5 所示。存储器输入参考值 $r_{(k)}$ 以形成时间序列 $r_{(k)} \cdots r_{(k+m)}$ 。 $u_{(k)}$ 、 $t_{(k)}$ 和由 $y_{(k)}$ 堆栈形成的 $y_{(k)} \cdots y_{(k+m)}$ 馈送到 GRU-NN 预测模型,以预测下一个时间点的预测输出。将参考值序列和历史预测序列进行差分获得误差信号。该误差信号和下一时刻的时间信息 $t_{(k+1)}$ 被馈送到 SSA 优化器中,以获得被优化的最佳电压信号 $u_{(k+1)}$ 。




图 5 优化过程

图 6 为 SSA 和 GD 优化下系统的阶跃响应。尽管阶跃响应的不连续性和 MPC 损失函数的设计限制了控制信号变化的幅度,但 SSA 和 GD 优化的电压响应曲线仍然比开环阶跃响应曲线具有更短的上升、调整时间,因为优化器自适应地将输入调整到更高的值。这意味着该方法对阶跃响应的滞后抑制也有一定的效果。与 GD 优化后的电压响应相比,SSA 优化后电压过冲较小。在稳定状态下,SSA 优化的抖动比 GD 优化的,这是因为 SSA 优化同时调整了 5 个步长,并考虑了系统未来的变化。




图 6 SSA 和 GD 优化的阶跃响应

3 KAN 拟合

3.1 KAN

实现上述优化算法需要大量算力。然而,PEAs 的采样周期通常为 5×10^{-3} s。PEAs 是一个快速变化的系统。在个人计算机上使用麻雀搜索算法进行优化大约需要 65 s。一个足够深的神经网络可以近似任何函数,所以训练神经网络来代替优化器是可行的。

与具有不可变激活函数的多层感知器(MLP)网络不同,KAN 网络是一个激活函数可训网络,这

提供了 MPL 网络所不具备的可解释性和交互性。KAN 的结构如图 7 所示。




图 7 控制框图

KAN 是一种受 Kolmogorov-Arnold 定理启发的神经网络。该定理可表示为

$$f(x) = f(x_1, \dots, x_n) = \sum_{q=1}^{2n+1} \Phi_q \left(\sum_n^p \varphi_{q,p}(x_p) \right) \quad (12)$$

式中: $f(x)$ 是从 $[0, 1]^n$ 范围到 \mathbb{R} 的映射; $\varphi_{q,p}$ 是从 $[0, 1]$ 范围到 \mathbb{R} 的映射; φ_q 是从 \mathbb{R} 范围到 \mathbb{R} 的映射。Kolmogorov-Arnold 网络定理指出,任何高维函数都可以拆分为低维函数组合。

对于 L 层网络, KAN 的输出可表示为

$$\text{KAN}(x) = (\Phi_{L-1} \circ \Phi_{L-2} \circ \dots \circ \Phi_1 \circ \Phi_0)x \quad (13)$$

式中 Φ 是 KAN 网络的函数矩阵。KAN 的激活函数 $\varphi(x)$ 是基本函数和样条函数之和:

$$\varphi(x) = w(b(x) + \text{spline}(x)) \quad (14)$$

$$b(x) = \text{silu}(x) = x / (1 + e^{-x}) \quad (15)$$

$$\text{spline}(x) = \sum_i c_i B_i(x) \quad (16)$$

式中: 样条 x 是 b 样条的线性组合; c_i 是可训练的系数。

3.2 KAN 的训练

网络的输入输出定义为

$$\chi(t) = [y_t, \tilde{y}_{t+T_s}, \tilde{y}_{t+2T_s}, \tilde{y}_{t+3T_s}, \tilde{y}_{t+4T_s}, \tilde{y}_{t+5T_s}, \tau_{t+T_s}, u_t] \quad (17)$$

$$Y(t) = [u_{t+T_s}] \quad (18)$$

式中 y_t, \tilde{y}_t, τ_t 和 u_t 分别表示 t 时刻的位移、目标位移、实际时间和输入电压。

隐藏神经元的数量设置为 5, 样条线顺序设置为 3。首先将网格设置为 3, 对大网格进行粗训练。

保存网络状态后, 将网格设置为 10, 对小网格进行精细训练。优化算法使用 LBFGS 算法, 步长设置为 20。将优化后的 300 000 个数据以 8 : 2 的比例划分为训练集和验证集。经过训练, 在验证集上获得的均方根误差为 0.040 5。图 8 为 KAN 网络验证集的一部分。




图 8 KAN 网络验证集

3.3 控制结果

实验装置如图 9 所示。该设备由 German PI 公司生产, 由 P563. 3CD 型压电驱动器和 E-725 型压电放大器组成。编程中应用了所提出的模型和控制策略。为了确认控制技术的可行性, 使用 NI 公司生产的 cDAQ-9185 机箱配备 NI9206 电压信号采集卡和 NI9263 模拟信号输出卡, 在 PC 和 PEAs 之间进行数据交换。

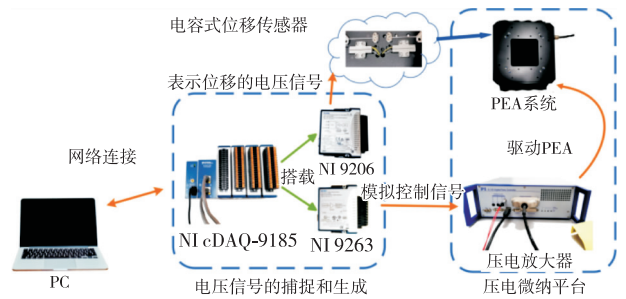


图 9 实验装置

为了减少优化时间, 使用 KAN 网络来模拟优化器。图 10 为控制算法在 15 Hz、35 Hz、70 Hz 和 90 Hz 频率下拟合前后的运行结果对比。未拟合的 MPC 控制的 RMSE 为 0.335 7 μm , KAN 拟合后的 MPS 控制的 RMS 为 0.425 5 μm 。结果表明, 尽管近似优化器在最终控制结果中引入了误差, 但这些误差是可接受的。




图 10 KAN 拟合前后输出对比

图 11 为基于 GRU 预测模型的 MPC-KAN 控制方法控制前后的迟滞曲线对比。

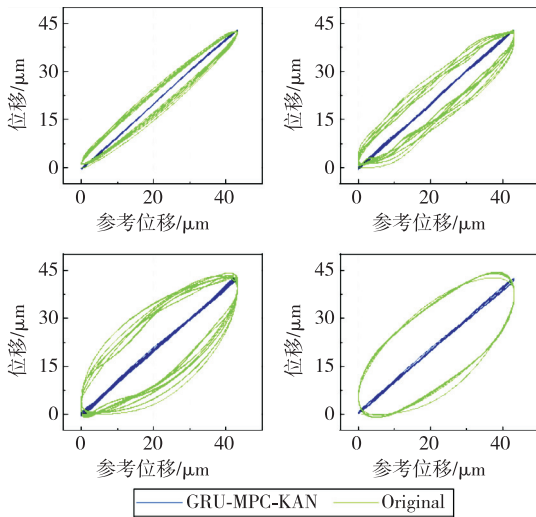


图 11 控制前后的迟滞曲线

表 2 为 MPC-KAN、LSTM-KAN 和 Closed-LSTM 在 15 Hz、35 Hz、70 Hz 和 90 Hz 频率下的误差对比。

表 2 3 种开环方法的误差

频率/Hz	开环方法	$e_{rms}/\mu\text{m}$	$e_{rrmse}/\%$
15	MPC-KAN	0.368 2	0.76
	LSTM-MPC	0.470 9	0.98
	Closed-LSTM	0.544 9	1.13
35	MPC-KAN	0.322 0	0.69
	LSTM-MPC	0.408 2	0.85
	Closed-LSTM	0.553 5	1.15
70	MPC-KAN	0.453 6	0.94
	LSTM-MPC	0.549 3	1.14
	Closed-LSTM	0.579 0	1.20

续表

频率/Hz	开环方法	$e_{rms}/\mu\text{m}$	$e_{rrmse}/\%$
90	MPC-KAN	0.558 3	1.16
	LSTM-MPC	0.827 8	1.71
	Closed-LSTM	0.684 2	1.42

4 结束语

本文提出了一种基于 GRU-NN 预测模型的 MPC-KAN 控制,成本更低,响应速度较快。该控制方法为开环前馈控制,省去了反馈环节,故而节省了计算时间和安装成本。MPC 优化器基于建立的 NN 模型对输入电压进行优化,以找到最佳电压输入。预先补偿电压以实现精确控制。通过实验验证其在 1~100 Hz 的宽频域内对正弦波和三角波及其变体具有较强的跟踪能力。后续研究将进一步平衡推广应用与精度提升,基于该方法提高跟踪精度。

参考文献:

- [1] CHEN Gaohua, YAN Xianguo, CAI Jianghui, et al. Hysteresis nonlinear modeling and compensation of piezoelectric ceramic sensors in micro measurement systems [J]. Measurement Science and Technology, 2018, 29(9): 095102.
- [2] JUNG H J, ESHGHI A T, LEE S. Structural failure detection using wireless transmission rate from piezoelectric energy harvesters [J]. IEEE/ASME Transactions on Mechatronics, 2021, 26(4): 1708-1718.
- [3] GUO Weiping, LIU Diantong, WANG Wei. Neural network hysteresis modeling with an improved Preisach model for piezoelectric actuators [J]. Engineering Computations, 2012, 29(3): 248-259.
- [4] XIE S L, ZHANG Y H, CHEN C H, et al. Identification of nonlinear hysteretic systems by artificial neural network [J]. Mechanical Systems and Signal Processing, 2013, 34(1/2): 76-87.
- [5] CAO Kairui, HAO Guanglu, LIU Qingfeng, et al. Hysteresis modeling and compensation of fast steering mirrors with hysteresis operator based back propagation neural networks [J]. Micromachines, 2021, 12(7): 732.
- [6] LI Jiangang, HUANG Youhua, LI Qijie, et al. Closed-LSTM neural network based reference modification for trajectory tracking of piezoelectric actuator [J]. Neurocomputing, 2022, 467: 379-391.

(下转第 171 页)