



基于神经网络ODE和非线性MPC的DEA建模与控制

黄鹏 王亚午 吴俊东 苏春翌 福岛E. 文彦

Modeling and Control of Dielectric Elastomer Actuator Based on Neural Ordinary Differential Equation and Nonlinear Model Predictive Control

HUANG Peng, WANG Ya-Wu, WU Jun-Dong, SU Chun-Yi, FUKUSHIMA Edwardo-Fumihiko

在线阅读 View online: <https://doi.org/10.16383/j.aas.c240223>

您可能感兴趣的其他文章

基于干扰估计的非对称运动下飞机刹车系统模型预测控制

Model Predictive Control of Aircraft Braking System Under Asymmetric Motion Based on Disturbance Estimation

自动化学报. 2022, 48(7): 1690–1703 <https://doi.org/10.16383/j.aas.c210852>

基于WTFMC算法的递归模糊神经网络结构设计

Structure Design for Recurrent Fuzzy Neural Network Based on Wavelet Transform Fuzzy Markov Chain

自动化学报. 2020, 46(11): 2367–2378 <https://doi.org/10.16383/j.aas.c180847>

时滞忆阻神经网络动力学分析与控制综述

An Overview of Dynamics Analysis and Control of Memristive Neural Networks With Delays

自动化学报. 2021, 47(4): 765–779 <https://doi.org/10.16383/j.aas.c200691>

含未知动态与扰动的非线性系统神经网络嵌入学习控制

Neural Network Embedded Learning Control for Nonlinear System With Unknown Dynamics and Disturbance

自动化学报. 2021, 47(8): 2016–2028 <https://doi.org/10.16383/j.aas.c200186>

基于混合集成建模的硅单晶直径自适应非线性预测控制

Hybrid Integrated Modeling Based Adaptive Nonlinear Predictive Control of Silicon Single Crystal Diameter

自动化学报. 2020, 46(5): 1004–1016 <https://doi.org/10.16383/j.aas.c190798>

随机非线性系统基于事件触发机制的自适应神经网络控制

Event-triggered Adaptive Neural Network Control for a Class of Stochastic Nonlinear Systems

自动化学报. 2019, 45(1): 226–233 <https://doi.org/10.16383/j.aas.2018.c180404>

基于神经网络 ODE 和非线性 MPC 的 DEA 建模与控制

黄鹏^{1,2,3,4} 王亚午^{1,2,3} 吴俊东^{1,2,3} 苏春翌⁵ 福岛 E.文彦⁴

摘要 针对介电弹性体驱动器 (Dielectric elastomer actuator, DEA) 建模与控制的挑战性问题的挑战性问题, 提出基于神经网络常微分方程 (Ordinary differential equation, ODE) 和非线性模型预测控制 (Model predictive control, MPC) 的 DEA 动力学建模与跟踪控制方法. 首先, 基于神经网络 ODE 建立 DEA 的动力学模型以描述其复杂的动态行为. 然后, 基于所建立的 DEA 动力学模型, 设计非线性模型预测控制器实现其跟踪控制目标. 最后, 在所搭建的实验平台上进行一系列跟踪控制实验. 在所有实验结果中, DEA 的运动均能很好地跟踪目标轨迹, 且相对均方根误差均不超过 3.30%, 说明了所提动力学建模与跟踪控制方法的有效性.

关键词 介电弹性体驱动器, 神经网络常微分方程, 动力学建模, 非线性模型预测控制

引用格式 黄鹏, 王亚午, 吴俊东, 苏春翌, 福岛 E.文彦. 基于神经网络 ODE 和非线性 MPC 的 DEA 建模与控制. 自动化学报, 2025, 51(1): 1-11

DOI 10.16383/j.aas.c240223 **CSTR** 32138.14.j.aas.c240223

Modeling and Control of Dielectric Elastomer Actuator Based on Neural Ordinary Differential Equation and Nonlinear Model Predictive Control

HUANG Peng^{1,2,3,4} WANG Ya-Wu^{1,2,3} WU Jun-Dong^{1,2,3} SU Chun-Yi⁵ FUKUSHIMA Edwardo-Fumihiko⁴

Abstract For challenging problems in modeling and control of dielectric elastomer actuators (DEA), this paper proposed dynamic modeling and tracking control methods for a DEA based on the neural ordinary differential equation (ODE) and nonlinear model predictive control (MPC). First, a dynamic model of the DEA was established based on the neural ODE to describe its complicated dynamics behavior. Then, based on the established dynamic model of the DEA, a nonlinear model predictive controller was designed to realize its tracking control objective. Finally, a series of tracking control experiments were conducted on the built experimental platform. In all experimental results, the motion of the DEA can track the target trajectory well, and all relative root-mean-square-errors are no more than 3.30%, which illustrates the effectiveness of proposed dynamic modeling and tracking control methods.

Key words Dielectric elastomer actuator (DEA), neural ordinary differential equation, dynamic modeling, nonlinear model predictive control

Citation Huang Peng, Wang Ya-Wu, Wu Jun-Dong, Su Chun-Yi, Fukushima Edwardo-Fumihiko. Modeling and control of dielectric elastomer actuator based on neural ordinary differential equation and nonlinear model predictive control. *Acta Automatica Sinica*, 2025, 51(1): 1-11

收稿日期 2024-04-24 录用日期 2024-08-14

Manuscript received April 24, 2024; accepted August 14, 2024
国家自然科学基金面上项目 (62273316), 国家建设高水平大学公派研究生项目 (202206410064), 高等学校学科创新引智计划项目 (111 计划) (B17040) 资助

Supported by General Program of National Natural Science Foundation of China (62273316), Program of China Scholarship Council (202206410064), and Higher Education Discipline Innovation Project of China (111 Project) (B17040)

本文责任编辑 李鸿一

Recommended by Associate Editor LI Hong-Yi

1. 中国地质大学 (武汉) 自动化学院 武汉 430074 中国 2. 复杂系统先进控制与智能自动化湖北省重点实验室 武汉 430074 中国 3. 地球探测智能化技术教育部工程研究中心 武汉 430074 中国 4. 东京工业大学工学部 东京 192-0982 日本 5. 康考迪亚大学 Gina Cody 工程与计算机科学学院 蒙特利尔 QC H3G 1M8 加拿大

1. School of Automation, China University of Geosciences, Wuhan 430074, China 2. Hubei Key Laboratory of Advanced Control and Intelligent Automation for Complex Systems, Wuhan 430074, China 3. Engineering Research Center of Intelligent Technology for Geo-Exploration, Ministry of Education, Wuhan 430074, China 4. School of Engineering, Tokyo University of Technology, Tokyo 192-0982, Japan 5. Gina Cody

当前, 新一轮科技革命和产业变革正在加速推进, 随着软材料技术、信息技术、生物技术与机器人技术的深度融合, 出现了能够模仿自然生物行为和运动模式的软体机器人^[1]. 与传统的刚性机器人相比, 软体机器人具有结构柔顺、运动灵活和安全性高等优势^[2], 在深海探测^[3]、地质勘探^[4]和康复医疗^[5]等领域具有广阔的应用前景. 软体机器人多由气动软驱动器^[6]、液晶弹性体驱动器^[7]和介电弹性体驱动器 (Dielectric elastomer actuator, DEA)^[8]等软驱动器驱动. 在上述软驱动器中, DEA 具有变形范围大、能量密度高和响应速度快等优点^[9], 被广泛应用于制作软体机器人, 比如软体扑翼机器人^[10]、软体爬行动物机器人^[11]和深海机器鱼^[12]等.

School of Engineering and Computer Science, Concordia University, Montreal QC H3G 1M8, Canada

为实现软体机器人在人机交互、环境探测及特种作业等领域的广泛应用,归根结底需要先实现 DEA 的跟踪控制^[13]. 然而, DEA 的动态行为极其复杂,具有平方输入非线性特性、迟滞非线性特性和蠕变非线性特性,导致其跟踪控制面临巨大挑战. 一般情况下,基于模型的控制方法是实现复杂非线性系统控制的常用且高效的方法^[14]. 因此,有必要建立有效的 DEA 动力学模型,用以设计基于模型的控制实现其跟踪控制目标. 根据连续介质力学理论和热力学原理, Suo^[15] 给出了一种 DEA 的动力学模型框架. Xiao 等^[16] 利用广义开尔文模型描述介电弹性体材料的粘弹性,以此建立了平面 DEA 的动力学模型. Huang 等^[17] 利用广义 Maxwell 模型描述介电弹性体材料的粘弹性,进而建立了锥形 DEA 的动力学模型. 上述模型均是利用机理建模法而建立的,可以从物理的角度解释 DEA 的动态行为. 然而,这些模型的数学表达式非常复杂,为控制器设计带来了巨大困难.

与机理建模法相比,基于数据驱动的建模方法仅依赖于实验数据而无需考虑复杂的物理原理,建模过程相对简单. 唯象建模法是一类基于数据驱动的建模方法. 同时,部分唯象模型存在解析逆,为控制器的设计提供了便利. 基于 Prandtl-Ishlinskii 唯象迟滞模型, Zou 等^[18] 建立了 DEA 的动力学模型描述其迟滞非线性特性,但未考虑其平方输入非线性特性和蠕变非线性特性. Zhang 等^[13] 基于 Prandtl-Ishlinskii 唯象迟滞模型和算子叠加型唯象蠕变模型建立了 DEA 的动力学模型,并使用平方模块描述了 DEA 的平方输入非线性特性. 然而,在上述唯象建模过程中,需要根据 DEA 的动态行为对唯象模型进行改进,所建立的动力学模型具有复杂的数学表达式.

基于神经网络常微分方程 (Ordinary differential equation, ODE) 的建模方法是传统 ODE 模型与人工智能相结合的产物,也属于基于数据驱动的建模方法^[19]. 在实际物理世界中,很多系统的动力学模型可以表示为状态空间方程形式 (状态空间方程是 ODE 的一种形式). 针对复杂的非线性系统,可以将状态空间方程等式右边的项用神经网络进行逼近,得到一个具有神经网络 ODE 形式的系统动力学模型^[20]. 受益于神经网络的灵活性及万能逼近能力^[21],基于神经网络 ODE 的建模方法为 DEA 的动力学建模提供了一种潜在的解决方案.

由于 DEA 的动力学建模仍处于起步阶段,建立能够描述其动态行为的动力学模型并确保该模型有利于控制器的设计是一项极具挑战性的工作.

Gupta 等^[22] 通过对平面拮抗型 DEA 的动力学模型求逆,并直接将逆模型作为前馈逆补偿控制器,实现了 DEA 的跟踪控制目标. 然而,该方法是一种开环控制方法,控制精度受建模误差、外界扰动和模型参数摄动等不确定性的影响较大. 为解决这一问题, Wang 等^[23] 分别对 DEA 动力学模型中的平方模块、迟滞模型和线性系统求逆,设计前馈逆补偿控制器补偿其平方输入非线性特性、迟滞非线性特性和蠕变非线性特性. 然后,设计模糊比例积分反馈控制器与前馈逆补偿控制器相配合,构造前馈-反馈复合控制器实现了 DEA 的跟踪控制目标. 然而,上述控制方法要求 DEA 的动力学模型可逆,为其实际应用带来了一定的限制.

受上述分析的启发,本文提出基于神经网络 ODE 和非线性模型预测控制 (Model predictive control, MPC) 的 DEA 动力学建模与跟踪控制方法. 首先,简要介绍 DEA 的制作与实验平台的搭建. 其次,基于神经网络 ODE 建立 DEA 的动力学模型描述其动态行为. 然后,基于所建立的神经网络 ODE 动力学模型,设计非线性模型预测控制器实现 DEA 的跟踪控制. 最后,进行实际的 DEA 跟踪控制实验验证所提动力学建模与控制方法的有效性.

本文的主要贡献总结如下: 1) 基于神经网络 ODE 建立 DEA 的动力学模型以描述其复杂的平方输入非线性特性、迟滞非线性特性与蠕变非线性特性,具有简单和灵活的优势. 2) 直接将具有神经网络 ODE 形式的 DEA 动力学模型作为预测模型,设计非线性模型预测控制器实现 DEA 的跟踪控制目标. 该方法在提高控制器灵活性的同时降低了控制系统的计算复杂度,有利于实际工程应用. 3) 通过实际的跟踪控制实验验证了所提 DEA 跟踪控制方法的有效性.

1 准备工作

为研究 DEA 的动力学建模与跟踪控制,前期的准备工作主要包括 DEA 的制作与实验平台的搭建.

1.1 DEA 制作

制作完成的锥形 DEA 如图 1(a) 所示,其制作流程如下: 首先,将初始厚度为 200 μm 的介电弹性体薄膜 (型号: ELASTOSIL[®] Film 2030 250/200, 供应商: 德国瓦克) 夹持于内径为 120 mm 的框架内. 其次,在介电弹性体薄膜的中心放置直径为 50 mm 的圆盘. 然后,在介电弹性体薄膜上下表面的两个

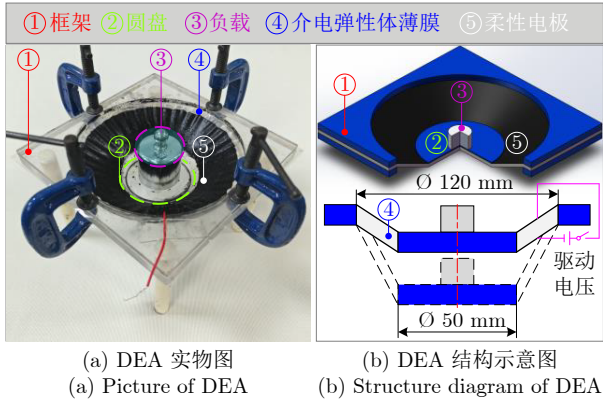


图 1 锥形介电弹性体驱动器

Fig.1 Conical dielectric elastomer actuator

环形区域涂布柔性电极 (型号: GV-919, 供应商: 日本 Yamate). 最后, 在圆盘中心处放置一个质量为 200 g 的负载, 完成 DEA 的制作.

DEA 的结构示意图如图 1(b) 所示, 其运动原理如下: 当在 DEA 的上下两个柔性电极间施加驱动电压时, 会在介电弹性体薄膜两端形成电场. 由电场产生的麦克斯韦应力从厚度方向上挤压介电弹性体薄膜, 导致其厚度变薄. 由于介电弹性体薄膜可视为不可压缩材料, 其体积在形变过程中保持不变^[8]. 因此, 厚度变薄会致使介电弹性体薄膜沿锥面方向扩张, 使得负载沿竖直向下方向运动. 反之, 当驱动电压减小时, 介电弹性体薄膜厚度逐渐减小并沿锥面方向收缩, 带动负载沿竖直向上方向运动. 因此, 在驱动电压作用下, DEA 将驱动负载产生沿竖直方向的往复运动.

1.2 实验平台搭建

搭建如图 2 所示的实验平台, 用以对提出的 DEA 动力学建模与跟踪控制方法进行实验验证. 实验平台主要包含 5 个部分: 激光位移传感器 (型号: LK-H152, 供应商: 日本基恩士), DEA (如图 1 所示), dSPACE 控制处理器 (型号: MicroLabBox 1202/1302, 实时实验软件: ControlDesk, 供应商: 德国 dSPACE), 计算机和高压放大器 (型号: 10/40A-HS-H-CE, 供应商: 美国 Trek).

dSPACE 控制处理器用以产生控制信号并实时采集由激光位移传感器测量得到的 DEA 位移数据. 高压放大器用以将 dSPACE 控制处理器产生的控制信号放大 1 000 倍, 产生驱动电压驱动 DEA 运动.

2 DEA 动力学建模与模型验证

首先, 基于神经网络 ODE 建立 DEA 的动力学




图 2 实验平台

Fig.2 Experimental platform

模型以描述其复杂的平方输入非线性特性、迟滞非线性特性与蠕变非线性特性. 然后, 利用采集的实验数据进行模型训练. 最后, 通过 8 组实验验证所建立动力学模型的有效性.

2.1 DEA 动力学建模

为实现系统的跟踪控制目标, 往往需要先建立该系统的动力学模型, 并确保该模型有利于控制器设计. 从广义上来说, 一个物理系统的动力学模型可以表示为如式 (1) 所示的状态空间方程, 该方程具有 ODE 形式.

$$\begin{cases} \dot{\mathbf{X}} = \mathbf{F}(\mathbf{X}, \mathbf{U}) \\ \mathbf{Y} = \mathbf{G}(\mathbf{X}) \end{cases} \quad (1)$$

其中, \mathbf{X} 为系统状态向量, \mathbf{U} 和 \mathbf{Y} 分别为输入和输出向量, \mathbf{F} 和 \mathbf{G} 分别为状态函数和输出函数.

由于 DEA 的动态行为非常复杂, 具有明显的迟滞非线性特性和蠕变非线性特性, 导致其动力学建模面临巨大挑战. 虽然已有学者建立了具有式 (1) 所示 ODE 形式的 DEA 动力学模型^[15-17], 但这些模型多具有十分复杂的表达式, 难以被应用于控制器的设计之中. 神经网络 ODE 建模方法直接利用神经网络逼近 ODE 式 (1) 中的 \mathbf{F} 和 \mathbf{G} , 具有简单和灵活的优势^[20], 这为 DEA 的动力学建模提供了一个潜在的解决方案. 受此启发, 本文将基于神经网络 ODE 建立 DEA 的动力学模型.

为方便表述, 记 x_1 和 x_2 分别为 DEA 的位移和速度, u 和 y 分别为 DEA 动力学模型的输入和输出, f 为非线性函数. 在本文中, DEA 动力学模型的输出为其位移, 则有 $y = x_1$. 取 $\mathbf{X} = [x_1, x_2]^T$, 则根据式 (1) 可得 $\mathbf{Y} = y$, $\mathbf{G}(\mathbf{X}) = x_1$ 以及 $\mathbf{U} = u$. 同时, 为简化模型结构, 取 $\mathbf{F}(\mathbf{X}, \mathbf{U}) = [x_2, f(x_1, x_2, u)]^T$, 则 DEA 的动力学模型可表示为如式 (2) 所示的 ODE 形式.

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = f(x_1, x_2, u) \\ y = x_1 \end{cases} \quad (2)$$

此外,从DEA变形机理的研究中发现,DEA主要在麦克斯韦应力 σ_{Maxwell} 的作用下产生变形. σ_{Maxwell} 的数学表达式如式(3)所示,其大小与驱动电压 V 的平方成正比.因此,DEA的动态行为与 V^2 直接相关,具有平方输入非线性特性.为了描述这一特性,在式(2)中取 $u = V^2$ 作为DEA动力学模型的输入.

$$\sigma_{\text{Maxwell}} = \frac{\varepsilon V^2}{d^2} \quad (3)$$

其中, ε 和 d 分别为介电弹性体薄膜的介电常数和厚度.

为便于模型训练和提高后续非线性模型预测控制器的求解速度,将式(2)由连续形式转换为如式(4)所示的离散形式^[24].然后,基于神经网络ODE建模的思想,建立如图3所示的DEA动力学模型.在图3中,平方输入模块用于描述DEA的平方输入非线性特性;神经网络ODE模块通过构建一个如图4所示的神经网络逼近式(4)中的非线性函数 f ,将式(4)转换为一个神经网络ODE.

$$\begin{cases} x_1(k+1) = x_1(k) + T x_2(k) \\ x_2(k+1) = x_2(k) + T f(x_1(k), x_2(k), u(k)) \\ y(k) = x_1(k) \end{cases} \quad (4)$$




图3 DEA 的动力学模型结构框图

Fig.3 Structure diagram of dynamic model of DEA




图4 神经网络结构图

Fig.4 Structure diagram of neural network

其中, T 为采样时间.

如图4所示,所构建的神经网络为多层感知机形式的深度神经网络,由输入层、隐含层和输出层构成.其中,隐含层的层数为 N .在每一个采样时刻 k ,输入层将 $x_1(k)$ 、 $x_2(k)$ 和 $u(k)$ 传递到第1隐含层,使得第1隐含层每个神经元的输入均为 $\mathbf{U}_a = [x_1(k), x_2(k), u(k)]^T$. $\mathbf{f}^{[j]}$ ($j = 1, 2, \dots, N$)表示第 j 隐含层的输出向量,且

$$\mathbf{f}^{[j]} = [f_1^{[j]} \ f_2^{[j]} \ \dots \ f_{n_j}^{[j]} \ \dots \ f_{N_j}^{[j]}]^T \quad (5)$$

其中, n_j 表示第 j 隐含层的第 n_j 个神经元的编号且 $n_j = 1, 2, \dots, N_j$. N_j 表示第 j 隐含层所有神经元的总数. $f_{n_j}^{[j]}$ 表示第 j 隐含层中第 n_j 个神经元的输出,且

$$f_{n_j}^{[j]} = \sigma_H \left(\left(\mathbf{w}_{n_j}^{[j]} \right)^T \mathbf{f}^{[j-1]} + b_{n_j}^{[j]} \right) \quad (6)$$

其中, $\mathbf{w}_{n_j}^{[j]}$ 和 $b_{n_j}^{[j]}$ 分别为第 j 隐含层中第 n_j 个神经元的权值向量和偏置, $\sigma_H(\cdot)$ 为隐含层激活函数.由于双曲正切函数具有单调且连续可微的优势,本文将作为隐含层激活函数,即 $\sigma_H(\cdot) = \tanh(\cdot)$.

为便于模型训练,定义第 j 隐含层的权值矩阵 $\mathbf{W}^{[j]}$ 与偏置向量 $\mathbf{b}^{[j]}$ ($j = 1, 2, \dots, N$)如下:

$$\begin{cases} \mathbf{W}^{[j]} = [w_1^{[j]} \ w_2^{[j]} \ \dots \ w_{N_j}^{[j]}]^T \\ \mathbf{b}^{[j]} = [b_1^{[j]} \ b_2^{[j]} \ \dots \ b_{N_j}^{[j]}]^T \end{cases} \quad (7)$$

根据式(5)~(7),可得:

$$\mathbf{f}^{[j]} = \sigma_H \left(\mathbf{W}^{[j]} \mathbf{f}^{[j-1]} + \mathbf{b}^{[j]} \right), \quad j = 1, 2, \dots, N \quad (8)$$

其中, $\mathbf{f}^{[0]} = \mathbf{U}_a = [x_1, x_2, u]^T$.

根据式(8),可通过递推计算得到 $\mathbf{f}^{[N]}$.然后,通过输出层计算得到神经网络的输出 f ,计算公式如下:

$$f = \mathbf{w}_o^T \mathbf{f}^{[N]} + b_o \quad (9)$$

其中, \mathbf{w}_o 和 b_o 分别为输出层的权值向量与偏置.

根据图3、图4和式(4)~(9),建立基于神经网络ODE的DEA动力学模型,其数学表达式如下:

$$\begin{cases} x_1(0) = 0, \ x_2(0) = 0 \\ x_1(k+1) = x_1(k) + T x_2(k) \\ \mathbf{f}^{[0]} = \mathbf{U} = [x_1(k) \ x_2(k) \ V^2(k)]^T \\ \mathbf{f}^{[j]} = \sigma_H \left(\mathbf{W}^{[j]} \mathbf{f}^{[j-1]} + \mathbf{b}^{[j]} \right), \quad j = 1, 2, \dots, N \\ f = \mathbf{w}_o^T \mathbf{f}^{[N]} + b_o \\ x_2(k+1) = x_2(k) + T f \\ y(k) = x_1(k) \end{cases} \quad (10)$$

2.2 模型训练

在所建立的 DEA 动力学模型 (10) 中, 待辨识的参数包括 $T, N, N_j, \mathbf{W}^{[j]}, \mathbf{b}^{[j]} (j = 1, 2, \dots, N), \mathbf{w}_o$ 和 b_o . 在本节中, 将通过模型训练获取上述待辨识参数的值.

为进行模型训练, 需要先进行实验获取实验数据. 根据 DEA 的动力学模型 (10), 采集的实验数据应包括驱动电压 V , DEA 的位移 x_1 和速度 x_2 . 这些数据即为神经网络的训练数据. 由于在不同幅值、不同频率驱动电压的作用下, DEA 的动态特性不同, 为采集综合全面的数据集以训练出泛化能力强的动力学模型, 将如式 (11) 所示的周期性驱动电压施加到 DEA 两端. 采样时间设置为 $T = 0.01$ s. 在每个驱动电压周期 T_V 内, 正弦半波的数量 $N_V = 7$, 每个正弦半波具有不同的频率 $\psi_i = 0.2i$ Hz ($i = 1, 2, \dots, N_V$) 和不同的幅值 $a_i = 4.5 + 0.5i$ kV.

$$\begin{cases} T_V = \sum_{i=1}^{N_V} \frac{1}{\psi_i}, & t_m = t - \left\lfloor \frac{t}{T_V} \right\rfloor T_V \\ t_{i-1} = \sum_{j=1}^i \frac{1}{\psi_j} - \frac{1}{\psi_i}, & i = 1, 2, \dots, N_V \\ V(t) = a_i \sin[\psi_i \pi (t_m - t_{i-1})], \\ t_{i-1} < t_m \leq t_{i-1} + \frac{1}{\psi_i} \end{cases} \quad (11)$$

其中, $\lfloor \theta \rfloor$ 是取余算子, 其输出为不超过 θ 的最大整数. t_m 是时间 t 的余数, 且 $t_m \in [0, T_V]$. t_{i-1} 为第 i 个正弦半波的开始时间.

本文采用 Adam 算法进行模型训练, 通过反复试错, 设置学习率为 0.2, 梯度衰减因子为 0.95, 梯度衰减平方因子为 0.99, 迭代次数为 1 000. 在一定的范围内, 随着隐含层层数和每层神经元总数的增加, 模型精度将会提高. 然而, 模型的计算复杂度也随之增加. 在综合考虑模型的计算复杂度和精度之后, 在 DEA 的动力学模型 (10) 中设置隐含层的层数 $N = 2$, 第 1 隐含层的神经元总数 $N_1 = 3$ 和第 2 隐含层的神经元总数 $N_2 = 3$. 此外, 在模型训练过程中, 利用如式 (12) 所示的均方误差 L 作为损失函数. 训练完成后, 利用如式 (13) 所示的相对均方根误差 E_R 定量评价模型精度.

$$\begin{cases} E = y_E - y_M \\ L = \frac{1}{N_s} \|E\|_2^2 \end{cases} \quad (12)$$

$$E_R = \frac{1}{\max(y_E) - \min(y_E)} \sqrt{\frac{\|E\|_2^2}{N_s}} \times 100\% \quad (13)$$

其中, y_E 和 y_M 分别为 DEA 位移的实验测量值和模型输出值, E 为 y_E 和 y_M 间的误差, N_s 为采样点数量, $\|\cdot\|_2$ 表示 \mathcal{L}_2 范数.

训练过程中, 损失函数 L 随迭代次数的变化曲线如图 5 所示. 训练完成后, 模型参数值 $\mathbf{W}^{[j]}, \mathbf{b}^{[j]} (j = 1, 2), \mathbf{w}_o$ 和 b_o 如式 (14) 所示. 模型输出值与实验测量值的对比如图 6 所示. 其中, 图 6(c) 所示的误差是图 6(b) 中蓝色虚线 (实验测量值) 与红色实线 (模型输出值) 所代表的数据之差, 其波动范围较小. 此外, 相对均方误差 $E_R = 0.74\%$. 根据上述结果, 所建立的动力学模型能够有效描述 DEA 复杂的平方输入非线性特性、迟滞非线性特性和蠕变非线性特性 (见图 6).

$$\begin{cases} \mathbf{W}^{[1]} = \begin{bmatrix} -6.52 & -0.27 & 0.06 \\ -4.75 & 0.68 & 0.12 \\ 7.06 & 0.23 & -0.14 \end{bmatrix} \\ \mathbf{b}^{[1]} = [0.36 \quad -0.17 \quad 0.10]^T \\ \mathbf{W}^{[2]} = \begin{bmatrix} 9.18 & -3.61 & -15.24 \\ 1.69 & -0.86 & -0.53 \\ 0.74 & -1.13 & -0.93 \end{bmatrix} \\ \mathbf{b}^{[2]} = [2.45 \quad 0.65 \quad -14.04]^T \\ \mathbf{w}_o = [34.98 \quad 36.34 \quad 3.66]^T, b_o = -6.99 \end{cases} \quad (14)$$




图 5 损失函数随迭代次数的变化曲线

Fig. 5 Curve of loss function with iterations

2.3 模型验证

本节设计两个实验测试方案验证 DEA 动力学模型的泛化能力. 每个实验方案中均包含 4 组实验. 所有用于模型验证的实验数据均不同于训练数据.

针对第 1 个实验方案中的所有实验, 驱动电压 (11) 的频率均设置为 $\psi_i = 0.2i$ Hz ($i = 1, 2, \dots, 7$). 具体到第 m 个 ($m = 1, 2, 3, 4$) 实验, 驱动电压 (11) 的幅值设置为 $a_m = 4.0 + m$ kV. 通过上述设置, 在每个实验中, DEA 受到具有同幅值、多频率驱动电压的作用. 模型输出值与实验测量值的对比如图 7 所示, 每组实验的相对均方根误差如表 1 所示.

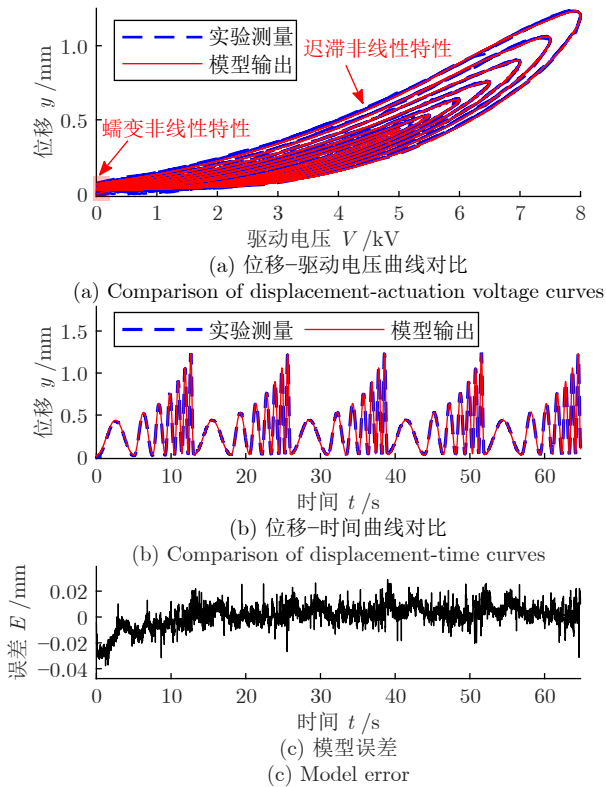


图 6 DEA 动力学模型输出值与实验测量值的对比

Fig. 6 Comparison between output of dynamic model of DEA and experimental measurement

针对第 2 个实验方案中的所有实验, 驱动电压 (11) 的幅值均设置为 $a_i = 4.5 + 0.5i$ kV ($i = 1, 2,$

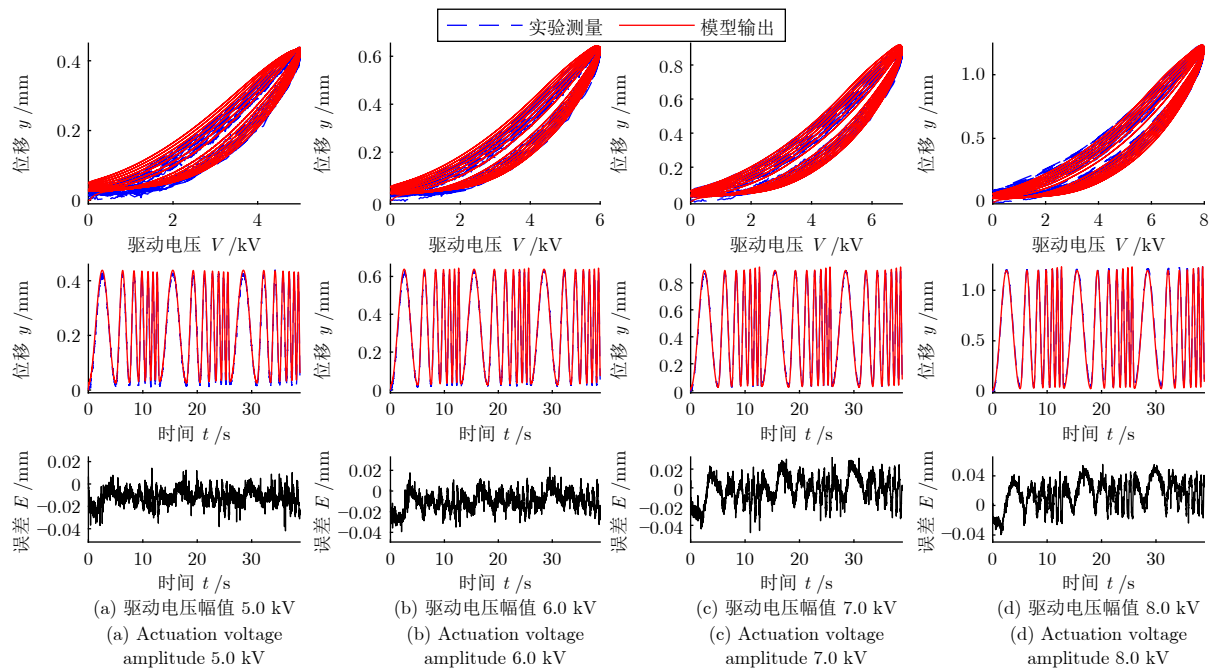


图 7 在不同驱动电压幅值情况下的模型验证结果

Fig. 7 Model validation results in different actuation voltage amplitudes

$\dots, 7)$. 具体到第 m 个 ($m = 1, 2, 3, 4$) 实验, 驱动电压 (11) 的频率设置为 $\psi_m = 0.4m - 0.2$ Hz. 通过上述设置, 在每个实验中, DEA 受到具有同频率、多幅值驱动电压的作用. 模型输出值与实验测量值的对比如图 8 所示, 每组实验的相对均方根误差如表 2 所示.

根据上述结果, DEA 动力学模型的输出值能很好地匹配实验测量值, 且所有实验的 $E_R \leq 3.20\%$. 因此, 所建立的 DEA 动力学模型具有良好的泛化能力.

注 1. 本文所构建的基于神经网络 ODE 的 DEA 动力学模型框架是一种通用的模型框架, 具有较强的适应性和泛化能力. 对于具有不同结构和尺寸的 DEA, 本文所提出的动力学建模方法依然适用, 仅需采集实验数据重新训练模型框架中的神经网络即可建立 DEA 的动力学模型.

3 非线性模型预测控制器设计

基于所建立的 DEA 动力学模型 (10), 本节将设计非线性模型预测控制器实现其跟踪控制目标. 控制系统整体结构框图如图 9 所示. 其中, y_d 为目标轨迹; v 为 DEA 的实际速度, 可通过激光位移传感器的速度通道获取.

在每个采样时刻 k , 系统的状态分别为 $x_1(k) = y(k)$ 和 $x_2(k) = v(k)$. 为了便于非线性模型预测控制器的设计, 首先定义非线性模型预测控制器的输

表 1 第 1 个实验方案中所有实验的相对均方根误差

Table 1 E_R for all experiments of first experimental scheme

m	a_m (kV)	E_R (%)
1	5.0	3.12
2	6.0	1.53
3	7.0	1.55
4	8.0	2.16

出预测序列 \mathbf{U}_{kp} 、DEA 的位移预测序列 \mathbf{Y}_p 和目标轨迹序列 \mathbf{Y}_d , 三者的数学表达式如下:

$$\mathbf{U}_{kp} := \{u_p(k|k), u_p(k+1|k), \dots, u_p(k+N_p-1|k)\} \quad (15)$$

$$\mathbf{Y}_p := \{y_p(k+1|k), y_p(k+2|k), \dots, y_p(k+N_p|k)\} \quad (16)$$

$$\mathbf{Y}_d := \{y_d(k+1|k), y_d(k+2|k), \dots, y_d(k+N_p|k)\} \quad (17)$$

其中, N_p 为预测时域, u_p 和 y_p 分别表示控制器输出的预测值和 DEA 位移的预测值, $k+1|k$ 表示在 k 时刻对 $k+1$ 时刻的预测, 依次类推.

如图 9 所示, 将 DEA 的动力学模型 (10) 作为非线性模型预测控制器的预测模型计算 \mathbf{Y}_p , 其每个元素 $y_p(\cdot)$ 的计算公式如下:

$$\begin{cases} x_{1p}(k|k) = y(k), x_{2p}(k|k) = v(k), 0 \leq i \leq N_p \\ x_{1p}(k+i+1|k) = x_{1p}(k+i|k) + T x_{2p}(k+i|k) \\ \mathbf{f}^{[0]} = [x_{1p}(k+i|k), x_{2p}(k+i|k), u_p(k+i|k)]^T \\ \mathbf{f}^{[j]} = \tanh(\mathbf{W}^{[j]} \mathbf{f}^{[j-1]} + \mathbf{b}^{[j]}), j = 1, 2, 3 \\ \mathbf{f} = \mathbf{w}_o^T \mathbf{f}^{[3]} + b_o \\ x_{2p}(k+i+1) = x_{2p}(k+i|k) + T f \\ y_p(k+i|k) = x_{1p}(k+i|k) \end{cases} \quad (18)$$

其中, x_{1p} 和 x_{2p} 分别为系统状态的预测值.

在本文中, 控制目标是使 DEA 的实际位移跟踪目标轨迹 y_d . 在每一个采样时刻 k , DEA 的跟踪控制问题被转换为 $[k, k+N_p]$ 时间区间内的约束优化问题 (19), 其目标函数和约束条件分别定义为式 (20) 和 (21).

$$\min_{\mathbf{U}_{kp}} J(x_1(k), x_2(k), \mathbf{U}_{kp}) \quad (19)$$

$$J(x_1(k), x_2(k), \mathbf{U}_{kp}) =$$

$$\sum_{i=1}^{N_p} \|y_p(k+i) - y_d(k+i)\|_{\mathbf{Q}}^2 + \sum_{i=0}^{N_c-1} \left(\|u_p(k+i)\|_{\mathbf{R}}^2 + \|\Delta u_p(k+i)\|_{\mathbf{S}}^2 \right) \quad (20)$$

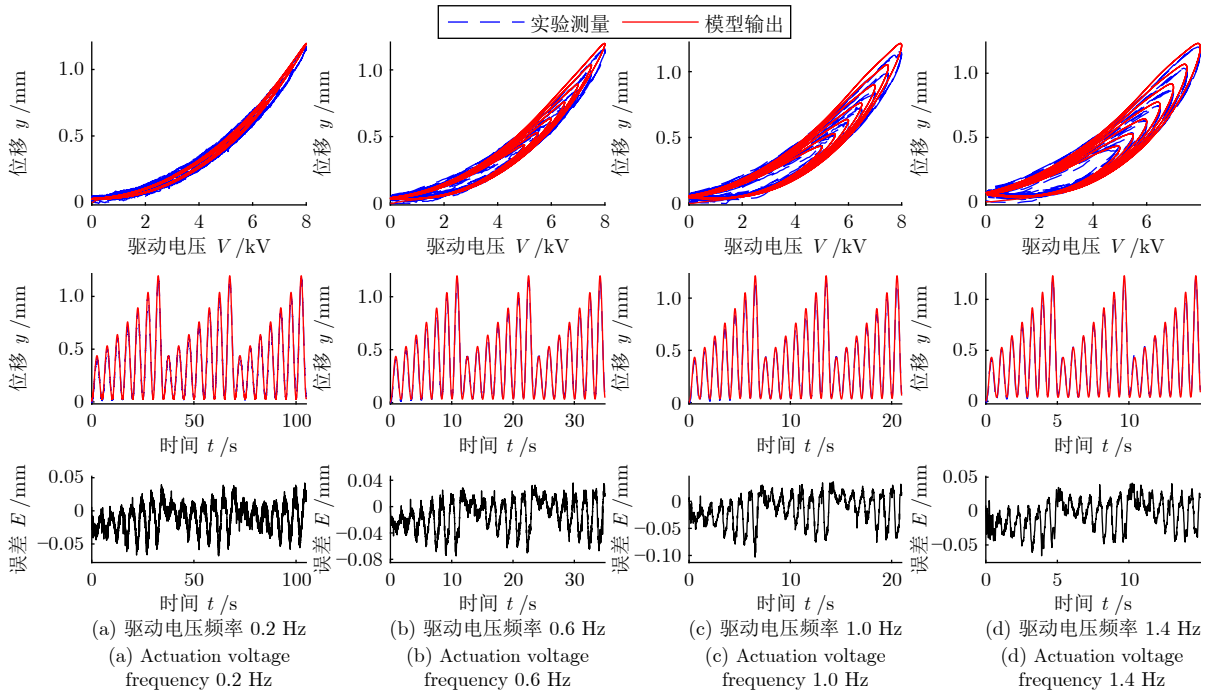


图 8 在不同驱动电压频率情况下的模型验证结果

Fig. 8 Model validation results in different actuation voltage frequencies

表 2 第 2 个实验方案中所有实验的相对均方根误差
Table 2 E_R for all experiments of second experimental scheme

m	ψ_m (Hz)	E_R (%)
1	0.2	1.82
2	0.6	2.10
3	1.0	2.50
4	1.4	1.89

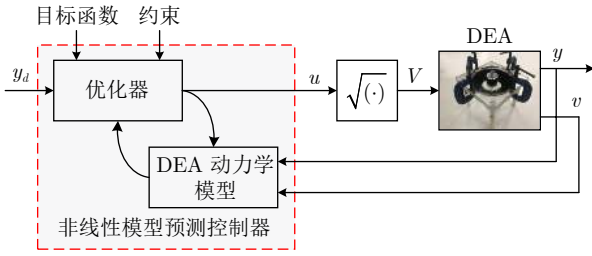


图 9 控制系统整体结构框图

Fig.9 Structure diagram of whole control system

$$\begin{cases} y_{\min} \leq y_p(k+i|k) \leq y_{\max}, 1 \leq i \leq N_p \\ u_{\min} \leq u_p(k+j|k) \leq u_{\max}, 0 \leq j \leq N_c \\ \Delta u_{\min} \leq \Delta u_p(k+j|k) \leq \Delta u_{\max} \\ \Delta u_p(k+j|k) = u_p(k+j|k) - u_p(k+j-1|k) \\ \Delta u_p(k+j|k) = 0, N_c \leq j \leq N_p \end{cases} \quad (21)$$

其中, N_c 为控制时域且 $N_c \leq N_p$, y_{\min} 和 y_{\max} 分别为 DEA 位移约束的最小值和最大值, u_{\min} 和 u_{\max} 分别为控制器输出约束的最小值和最大值, Δu_p 为 u_p 的增量, \mathbf{Q} 为 N_p 阶正定矩阵, \mathbf{R} 和 \mathbf{S} 均为 N_c 阶正定矩阵.

根据式 (15) 和 (21), 可得 $u_p(k+N_p-1|k) = u_p(k+N_p-2|k) = \dots = u_p(k+N_c|k)$, 则优化问题 (19) 的独立优化变量 \mathbf{U}_{kc} 为

$$\mathbf{U}_{kc} := \{u_p(k|k), u_p(k+1|k), \dots, u_p(k+N_c-1|k)\} \quad (22)$$

如图 9 所示, 非线性模型预测控制器利用序列二次规划 (Sequential quadratic program, SQP) 优化器求解约束优化问题 (19), 得到 \mathbf{U}_{kc} 的优化解 \mathbf{U}_{kc}^* , 记为:

$$\mathbf{U}_{kc}^* := \{u_p^*(k|k), u_p^*(k+1|k), \dots, u_p^*(k+N_c-1|k)\} \quad (23)$$

其中, $u_p^*(k+1|k)$ 为 $u_p(k+1|k)$ 的优化值.

根据非线性模型预测控制的基本原理^[25-26], 将 k 时刻优化解 \mathbf{U}_{kc}^* 的第一个分量 $u_p^*(k|k)$ 作为非线

性模型预测控制器的输出, 即 $u = u_p^*(k|k)$. 此外, 考虑到 $u = V^2$, 对 u 求平方根后即可得到 DEA 的控制输入 V , 即:

$$V = \sqrt{u} = \sqrt{u_p^*(k|k)} \quad (24)$$

在 $k+1$ 时刻, 将新测量的 DEA 位移 $y(k+1)$ 和速度 $v(k+1)$ 反馈到非线性模型预测控制器. 然后, 将两者作为初始条件, 重复式 (18) 所示的非线性模型预测过程并滚动求解式 (19) 所示的优化控制问题, 得到 $k+1$ 时刻的控制输入 V . 不断重复上述模型预测、反馈校正与滚动优化过程, 实现 DEA 的跟踪控制目标.

4 跟踪控制实验

本节首先对非线性模型预测控制器的参数进行整定. 然后, 通过一系列 DEA 跟踪控制实验验证所提非线性 MPC 方法的有效性. 在所有的跟踪控制实验中, DEA 均带有负载, 负载质量为 200 g (如图 1 所示).

4.1 控制器参数整定

在所设计的非线性模型预测控制器 (见图 9) 中, 待整定的控制器参数包括 u_{\min} 、 u_{\max} 、 y_{\min} 、 y_{\max} 、 N_p 、 N_c 、 \mathbf{Q} 、 \mathbf{R} 和 \mathbf{S} . 本节将采用实验试错的方法整定上述控制器参数.

首先, 定义跟踪误差为 $e = y_d - y$. 接着, 将式 (13) 中的 E 和 y_E 分别替换为 e 和 y_d , 并将计算得到的相对均方根误差 E_R 作为性能指标定量评价控制精度.

通过实验研究发现, 当驱动电压 V 过高时, 介电弹性体薄膜容易被击穿, 从而导致 DEA 损坏. 为了保护 DEA, 应该对驱动电压的幅值加以限制, 约束其不超过 9 kV. 考虑到 $u = V^2$, 则 $u_{\min} = 0 \text{ kV}^2$, $u_{\max} = 9^2 \text{ kV}^2$. 在此前提下, 通过实验发现 DEA 的位移在 0 mm 至 1.50 mm 之间. 因此, 设定 $y_{\min} = 0 \text{ mm}$, $y_{\max} = 1.50 \text{ mm}$.

不失一般性, 为整定参数 N_p 、 N_c 、 \mathbf{Q} 、 \mathbf{R} 和 \mathbf{S} , 采用如图 10(a) 所示的正弦波作为目标轨迹. 然后, 通过实际的 DEA 跟踪控制实验对非线性模型预测控制器中的上述参数进行反复调节. 此外, 为了定量说明非线性模型预测控制器的实时性, 将其完成一次约束优化问题求解所需的时间定义为单步运行时间 T_c . N_p 和 N_c 的值对控制精度、单步运行时间和实时性的影响如表 3 所示. 从表 3 可以看出, 当 N_p 和 N_c 的值过小时, $T_c \leq T = 0.01 \text{ s}$, 非线性模型预测控制器的实时性满足实际控制的要求, 但控制精度不足; 随着 N_p 和 N_c 值的增大, 控制精度得以提高, 但非线性模型预测控制器的计算复杂度也

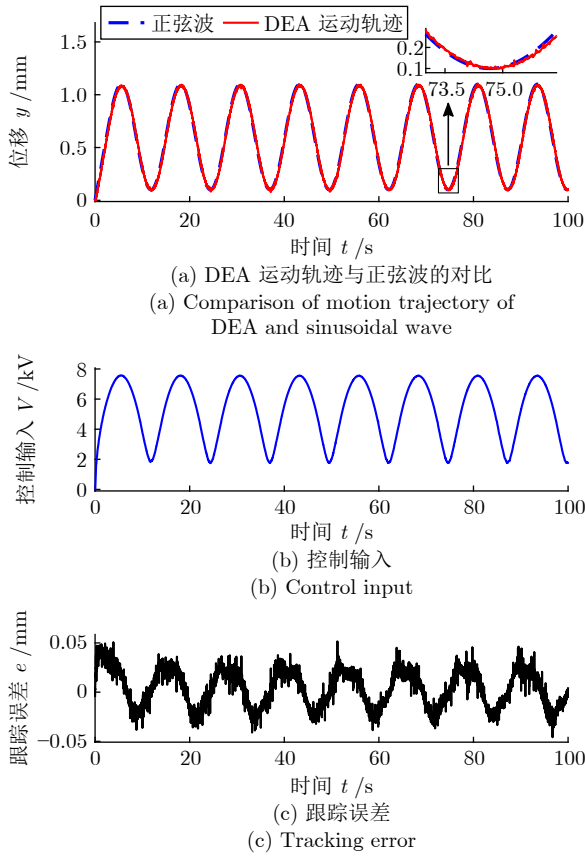


图 10 对正弦波的跟踪结果

Fig.10 Tracking result for sinusoidal wave

表 3 N_p 和 N_c 取值对控制精度、单步运行时间和实时性的影响Table 3 Influences of values of N_p and N_c on control accuracy, single-step running time and real-time performance

N_p	N_c	E_R (%)	T_c (s)	实时性
2	1	3.26	5.08×10^{-3}	满足
4	2	2.83	8.39×10^{-3}	满足
5	2	1.88	8.91×10^{-3}	满足
6	4	—	1.85×10^{-2}	不满足

随之增大, 导致其单步运行时间 T_c 增大. 当 $T_c > T = 0.01$ s 时, 非线性模型预测控制器的实时性难以满足实际控制的要求. 根据表 3, 当 $N_p = 5$ 和 $N_c = 2$ 时, 既能获得较高的控制精度, 又可以满足实时性要求. 因此, 选择 $N_p = 5$ 和 $N_c = 2$ 是合理的. 基于此, 参数整定的结果如式 (25) 所示. DEA 的运动轨迹与目标轨迹的对比如图 10(a) 所示, 控制输入和跟踪误差分别如图 10(b) 和图 10(c) 所示. 同时, 对应的相对均方根误差 $E_R = 1.88\%$. 根据上述结果, 使用所设计的非线性模型预测控制器能够有效地实现 DEA 的跟踪控制目标, 说明选择如式 (25) 所示

的参数值是合适的.

$$\begin{cases} N_p = 5, N_c = 2 \\ \mathbf{Q} = \mathbf{I}_{N_p}, \mathbf{R} = 4 \times 10^{-3} \mathbf{I}_{N_c}, \mathbf{S} = 0.1 \mathbf{I}_{N_c} \end{cases} \quad (25)$$

其中, \mathbf{I}_{N_p} 和 \mathbf{I}_{N_c} 分别表示 N_p 阶和 N_c 阶单位矩阵.

4.2 实验验证

本节将采用一系列典型的波形作为目标轨迹, 进行 DEA 的跟踪控制实验, 进一步验证所提非线性 MPC 方法的有效性.

首先, 采用三角波作为目标轨迹, 使用所提出的非线性 MPC 方法进行 DEA 的跟踪控制实验. DEA 的运动轨迹与目标轨迹的对比如图 11(a) 所示, 跟踪误差如图 11(b) 所示, 对应的相对均方根误差 $E_R = 2.91\%$. 根据上述结果, 使用所设计的非线性模型预测控制器能够有效地实现 DEA 的跟踪控制目标.

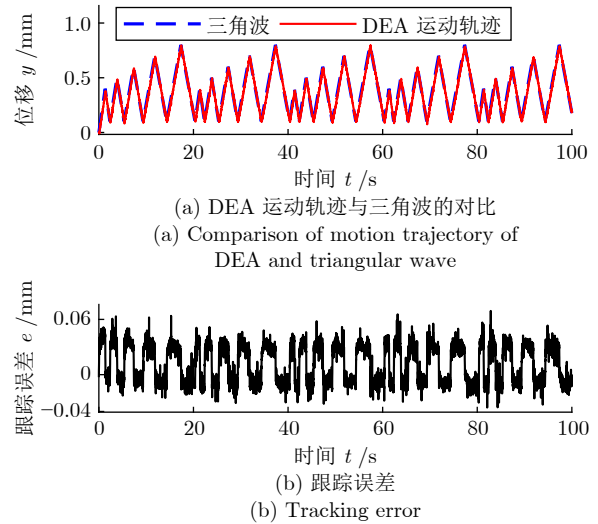


图 11 对三角波的跟踪结果

Fig.11 Tracking result for triangular wave

然后, 采用阶梯波作为目标轨迹, 使用所设计的非线性模型预测控制器进行 DEA 的跟踪控制实验. DEA 的运动轨迹与目标轨迹的对比如图 12(a) 所示, 跟踪误差如图 12(b) 所示, 对应的相对均方根误差 $E_R = 3.25\%$. 上述结果表明, 即使是在目标轨迹存在突变的情况下, 本文所提出的非线性 MPC 方法依然能够快速跟踪目标轨迹, 且整体的跟踪控制性能良好.

最后, 采用由幅值和频率均可变的正弦波与具有高频率、低幅值的正弦波复合构成的复合波作为目标轨迹. 在所设计的非线性模型预测控制器的控制下, DEA 的运动轨迹与目标轨迹的对比如图 13(a) 所示, 跟踪误差如图 13(b) 所示, 对应的相对均方

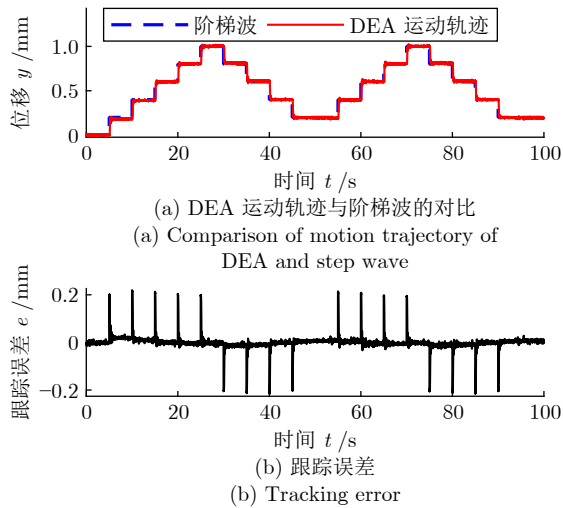


图 12 对阶梯波的跟踪结果

Fig. 12 Tracking result for step wave

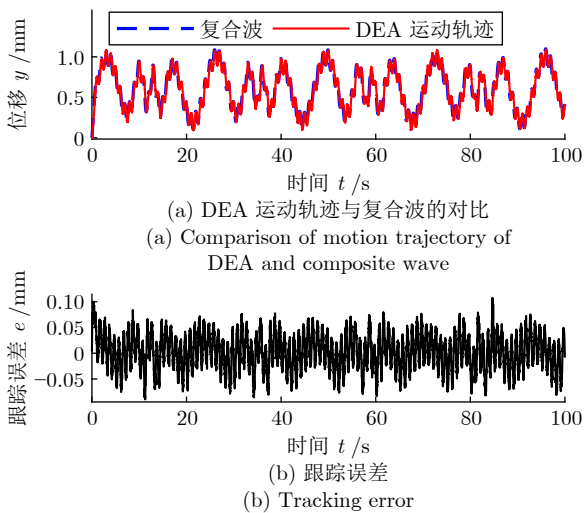


图 13 对复合波的跟踪结果

Fig. 13 Tracking result for composite wave

根误差 $E_R = 3.26\%$ 。根据上述结果, 尽管目标轨迹非常复杂, 使用所提出的非线性 MPC 方法依然能够有效地实现 DEA 的跟踪控制目标。

注 2. 与现有研究^[22, 27-28]相比, 本文所提新方法具有一定的优势, 主要表现在以下两个方面: 1) 在 DEA 的动力学建模方面, 文献^[22]需要根据非平衡热力学原理分析 DEA 的迟滞-蠕变复合非线性特性, 进而建立其动力学模型; 现有研究文献^[27-28]中需要分别构建 DEA 的迟滞非线性模型和蠕变非线性模型以构造迟滞-蠕变复合非线性模型, 进而建立 DEA 的动力学模型。在上述研究中, 建模过程和模型结构均比较复杂, 而本文基于神经网络 ODE 直接建立了 DEA 的动力学模型, 具有简单和灵活的优势。2) 在 DEA 的跟踪控制方面, 文献^[22, 27-28]

中均需要对 DEA 的动力学模型求逆以构造逆补偿控制器, 求逆运算的过程较为复杂; 而本文通过设计非线性模型预测控制器实现了 DEA 的跟踪控制目标, 避免了对模型进行复杂的求逆运算。

5 结论

本文提出了基于神经网络 ODE 和非线性 MPC 的 DEA 动力学建模和跟踪控制方法。首先, 基于神经网络 ODE 建立了 DEA 的动力学模型, 具有建模过程简单、模型结构灵活和易于实际应用的优势。所建立的动力学模型可以同时描述 DEA 复杂的平方输入非线性特性、迟滞非线性特性和蠕变非线性特性。在模型参数辨识与模型验证中, 相对均方根误差均不超过 3.20%, 说明了所建立动力学模型的有效性与泛化能力。


然后, 基于所建立的 DEA 动力学模型设计了非线性模型预测控制器实现 DEA 的跟踪控制目标。在控制器设计过程中, 直接将具有神经网络 ODE 形式的 DEA 动力学模型作为预测模型, 在提高控制器灵活性的同时降低了控制系统的计算复杂度, 有利于实际工程应用。最后, 利用所设计的非线性模型预测控制器进行了 4 组实际的 DEA 跟踪控制实验。在所有实验中, DEA 的运动均能够很好地跟踪目标轨迹, 且相对均方根误差均不超过 3.30%, 表明所提出的非线性 MPC 方法具有良好的控制效果。

References

- Rus D, Tolley M T. Design, fabrication and control of soft robots. *Nature*, 2015, **521**(7553): 467-475
- Wen Li, Wang He-Sheng. Prospects for soft robotics research: Structure, actuation and control. *Robot*, 2018, **40**(5): 577 (文力, 王贺升. 软体机器人研究展望: 结构、驱动与控制. *机器人*, 2018, **40**(5): 577)
- Xu Fan, Wang He-Sheng. Adaptive robust visual servoing control of a soft manipulator in underwater environment. *Acta Automatica Sinica*, 2023, **49**(4): 744-753 (徐璠, 王贺升. 软体机械臂水下自适应鲁棒视觉伺服. *自动化学报*, 2023, **49**(4): 744-753)
- Naclerio N D, Karsai A, Murray-Cooper M, Ozkan-Aydin Y, Aydin E, Goldman D I, et al. Controlling subterranean forces enables a fast, steerable, burrowing soft robot. *Science Robotics*, 2021, **6**(55): Article No. eabe2922
- Wang Cheng-Jun, Deng Hai-Long. Application of soft robots in rehabilitation training. *Journal of Mechanical Transmission*, 2024, **48**(5): 169-176 (王成军, 邓海龙. 软体机器人在康复训练领域的应用. *机械传动*, 2024, **48**(5): 169-176)
- Li Xing-Wang, Teng Yan, Xu Ying. A pneumatic soft quadruped robot based on a bistable actuator. *Robot*, 2024, **46**(3): 294-304 (李兴旺, 滕燕, 徐迎. 一种基于双稳态驱动器的气动软体四足机器人. *机器人*, 2024, **46**(3): 294-304)
- Wu J D, Ye W J, Wang Y W, Su C Y. Modeling based on a two-step parameter identification strategy for liquid crystal elastomer actuator considering dynamic phase transition process. *IEEE Transactions on Cybernetics*, 2023, **53**(7): 4423-4434
- Pelrine R, Kornbluh R, Pei Q B, Joseph J. High-speed electrically actuated elastomers with strain greater than 100%. *Science*,

- 2000, **287**(5454): 836–839
- 9 Li Zhi, Chen Guo-Qiang, Xu Hong-Zhi, Chen Xin-Kai, Shan Jin-Jun, Zhang Xiu-Yu. A review of modeling and control methods for dielectric elastomer actuator systems. *Control and Decision*, 2023, **38**(8): 2283–2300
(李智, 陈国强, 徐泓智, 陈新开, 陕晋军, 张秀宇. 介电弹性体驱动系统建模及控制方法综述. *控制与决策*, 2023, **38**(8): 2283–2300)
- 10 Chen Y F, Zhao H C, Mao J, Chirarattananon P, Helbling E F, Hyun N P, et al. Controlled flight of a microrobot powered by soft artificial muscles. *Nature*, 2019, **575**(7782): 324–329
- 11 Gu G Y, Zou J, Zhao R K, Zhao X H, Zhu X Y. Soft wall-climbing robots. *Science Robotics*, 2018, **3**(25): Article No. eaat2874
- 12 Li G R, Chen X P, Zhou F H, Liang Y M, Xiao Y H, Cao X N, et al. Self-powered soft robot in the Mariana Trench. *Nature*, 2021, **591**(7848): 66–71
- 13 Zhang Y, Wu J D, Meng Q X, Wang Y W, Su C Y. Robust control of dielectric elastomer smart actuator for tracking high-frequency trajectory. *IEEE Transactions on Industrial Informatics*, 2024, **20**(1): 224–234
- 14 Huang P, Wu J D, Zhang P, Wang Y W, Su C Y. Dynamic modeling and tracking control for dielectric elastomer actuator with a model predictive controller. *IEEE Transactions on Industrial Electronics*, 2022, **69**(2): 1819–1828
- 15 Suo Z G. Theory of dielectric elastomers. *Acta Mechanica Sinica*, 2010, **23**(6): 549–578
- 16 Xiao H, Wu J D, Ye W J, Wang Y W. Dynamic modeling of dielectric elastomer actuators based on thermodynamic theory. *Mechanics of Advanced Materials and Structures*, 2022, **29**(11): 1543–1552
- 17 Huang P, Ye W J, Wang Y W. Dynamic modeling of dielectric elastomer actuator with conical shape. *Plus One*, 2020, **15**(8): Article No. e0235229
- 18 Zou J, Gu G Y. High-precision tracking control of a soft dielectric elastomer actuator with inverse viscoelastic hysteresis compensation. *IEEE/ASME Transactions on Mechatronics*, 2019, **24**(1): 36–44
- 19 Wang H C, Fu T F, Du Y Q, Gao W H, Huang K X, Liu Z M, et al. Scientific discovery in the age of artificial intelligence. *Nature*, 2023, **620**(7972): 47–60
- 20 Linot A J, Burby J W, Tang Q, Balaprakash P, Graham M D, Maulik R. Stabilized neural ordinary differential equations for long-time forecasting of dynamical systems. *Journal of Computational Physics*, 2023, **474**: Article No. 111838
- 21 Hornik K, Stinchcombe M, White H. Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. *Neural Networks*, 1990, **3**(5): 551–560
- 22 Gupta U, Wang Y Z, Ren H L, Zhu J. Dynamic modeling and feedforward control of jaw movements driven by viscoelastic artificial muscles. *IEEE/ASME Transactions on Mechatronics*, 2019, **24**(1): 25–35
- 23 Wang Y W, Huang P, Wu J D, Su C Y. Modelling and compound control of intelligently dielectric elastomer actuator. *Control Engineering Practice*, 2022, **126**: Article No. 105261
- 24 Lu F, Lin K K, Chorin A J. Comparison of continuous and discrete-time data-based modeling for hypoelliptic systems. *Communications in Applied Mathematics and Computational Science*, 2016, **11**(2): 187–216
- 25 Chen Hong. *Model Predictive Control*. Beijing: Science Press, 2013. 245–251
(陈虹. 模型预测控制. 北京: 科学出版社, 2013. 245–251)
- 26 Xi Yu-Geng, Li De-Wei, Lin Shu. Model predictive control—Status and challenges. *Acta Automatica Sinica*, 2013, **39**(3): 222–236
(席裕庚, 李德伟, 林殊. 模型预测控制——现状与挑战. *自动化学报*, 2013, **39**(3): 222–236)
- 27 Zhang Yue. Dynamic Modeling and Trajectory Tracking Control of Dielectric Elastomer Actuator [Master thesis], China University of Geosciences, China, 2023.
(章越. 介电弹性体驱动器动力学建模与轨迹跟踪控制 [硕士学位论文], 中国地质大学, 2023.)

- 28 Zhang X Y, Xu H Z, Chen X K, Li Z, Su C Y. Modeling and adaptive output feedback control of butterfly-like hysteretic nonlinear systems with creep and their applications. *IEEE Transactions on Industrial Electronics*, 2023, **70**(5): 5182–5191



黄鹏 中国地质大学(武汉)自动化学院博士研究生. 主要研究方向为软体机器人和机器人控制.

E-mail: huangpeng@cug.edu.cn


(HUANG Peng Ph.D. candidate at the School of Automation, China University of Geosciences. His research interest covers soft robotics and robot control.)



王亚午 中国地质大学(武汉)自动化学院教授. 主要研究方向为机器人控制和非线性系统控制. 本文通信作者.

E-mail: wangyawu@cug.edu.cn

(WANG Ya-Wu Professor at the School of Automation, China University of Geosciences. His research interest covers robot control and nonlinear system control. Corresponding author of this paper.)



吴俊东 中国地质大学(武汉)自动化学院教授. 主要研究方向为软体机器人和非线性系统控制.

E-mail: jdwu@cug.edu.cn

(WU Jun-Dong Professor at the School of Automation, China University of Geosciences. His research interest covers soft robotics and nonlinear system control.)



苏春翌 加拿大康考迪亚大学 Gina Cody 工程与计算机科学学院教授. 主要研究方向为机器人控制, 非线性系统控制, 软体机器人.

E-mail: chun-yi.su@concordia.ca

(SU Chun-Yi Professor at the Gina Cody School of Engineering and Computer Science, Concordia University. His research interest covers robot control, nonlinear system control, and soft robotics.)



福岛E.文彦 日本东京工科大学工学部教授. 主要研究方向为机器人控制.

E-mail: fukushimafmhk@stf.teu.ac.jp

(FUKUSHIMA Edwardo-Fumihiko Professor at the School of Engineering, Tokyo University of Technology. His main research interest is robot control.)