

# 控制与决策

Control and Decision

## 基于宽度学习系统的气动波纹管驱动器无模型跟踪控制

赵诗影, 闫泽, 孟庆鑫, 肖怀, 赖旭芝, 吴敏

引用本文:

赵诗影, 闫泽, 孟庆鑫, 肖怀, 赖旭芝, 吴敏. 基于宽度学习系统的气动波纹管驱动器无模型跟踪控制[J]. *控制与决策*, 2024, 39(1): 121–128.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0541>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### [随机变批次长度的反馈辅助PD型量化迭代学习控制](#)

Feedback-assisted PD-type quantized iterative learning control with randomly iteration varying lengths  
*控制与决策*. 2021, 36(10): 2569–2576 <https://doi.org/10.13195/j.kzyjc.2020.0273>

#### [基于数据驱动的非线性网络系统自适应迭代学习控制](#)

Data driven adaptive learning control of nonlinear network system  
*控制与决策*. 2021, 36(6): 1523–1528 <https://doi.org/10.13195/j.kzyjc.2019.1182>

#### [四旋翼无人机抗干扰轨迹跟踪控制](#)

Anti-interference trajectory tracking control of quadrotor UAV  
*控制与决策*. 2021, 36(2): 379–386 <https://doi.org/10.13195/j.kzyjc.2019.0875>

#### [输入约束不确定系统的点对点迭代学习控制与优化](#)

Point-to-point iterative learning control and optimization for uncertain systems with constrained input  
*控制与决策*. 2021, 36(6): 1435–1441 <https://doi.org/10.13195/j.kzyjc.2019.0908>

#### [航天器输入受限的鲁棒自适应姿态跟踪控制](#)

Robust adaptive attitude tracking control of spacecraft with constrained inputs  
*控制与决策*. 2021, 36(9): 2297–2304 <https://doi.org/10.13195/j.kzyjc.2020.0013>

# 基于宽度学习系统的气动波纹管驱动器无模型跟踪控制

赵诗影<sup>1,2,3</sup>, 闫泽<sup>1,2,3</sup>, 孟庆鑫<sup>1,2,3†</sup>, 肖怀<sup>1,2,3</sup>, 赖旭芝<sup>1,2,3</sup>, 吴敏<sup>1,2,3</sup>

(1. 中国地质大学(武汉)自动化学院, 武汉 430074;

2. 中国地质大学(武汉)复杂系统先进控制与智能化湖北省重点实验室, 武汉 430074;

3. 中国地质大学(武汉)地球探测智能化技术教育部工程研究中心, 武汉 430074)

**摘要:** 针对一款具有波纹管外形的气动伸长型气动软体驱动器(简称“气动波纹管驱动器”),提出一种基于宽度学习系统的无模型跟踪控制方法,使该驱动器有效跟踪期望轨迹.首先,介绍气动波纹管驱动器结构,以及气动波纹管驱动器整体实验平台工作原理.根据驱动器实时位置信息提出一种基于宽度学习系统的跟踪控制方法,受PID跟踪控制方法中积分项作用的启发,所提出控制方法不仅采用系统跟踪误差作为宽度学习系统的输入之一,还将跟踪误差对时间的积分项作为另一输入以消除期望轨迹与实际轨迹间的恒定偏差.然后,采用宽度学习系统计算得到控制气压,同时,利用基于梯度下降法的学习律在线调整宽度学习系统权值,进而减小驱动器跟踪误差.最后,通过实验验证所提出方法的有效性.所提出方法无需建立驱动器模型,能够简化控制器设计步骤,且与深度神经网络控制方法相比,能在避免计算量过大的前提下实现较高的跟踪控制精度.

**关键词:** 气动软体驱动器; 气动波纹管驱动器; 软体机器人; 宽度学习系统; 无模型跟踪控制; 梯度下降

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0541

**引用格式:** 赵诗影, 闫泽, 孟庆鑫, 等. 基于宽度学习系统的气动波纹管驱动器无模型跟踪控制[J]. 控制与决策, 2024, 39(1): 121-128.

## Model-free tracking control of pneumatic bellow actuator based on broad learning system

ZHAO Shi-ying<sup>1,2,3</sup>, YAN Ze<sup>1,2,3</sup>, MENG Qing-xin<sup>1,2,3†</sup>, XIAO Huai<sup>1,2,3</sup>, LAI Xu-zhi<sup>1,2,3</sup>, WU Min<sup>1,2,3</sup>

(1. School of Automation, China University of Geosciences, Wuhan 430074, China; 2. Hubei Key Laboratory of Advanced Control and Intelligent Automation for Complex Systems, China University of Geosciences, Wuhan 430074, China; 3. Engineering Research Center of Intelligent Technology for Geo-Exploration of Ministry of Education, China University of Geosciences, Wuhan 430074, China)

**Abstract:** In this paper, we choose a pneumatic soft actuator with a bellow shape (pneumatic bellow actuator) as the object, and propose a model-free tracking control method based on the broad learning system to realize its trajectory tracking control. We first introduce the structure of the pneumatic bellow actuator and the working principle of the experimental platform. Based on the real-time position information of the actuator, we propose a tracking control method based on the broad learning system. Inspired by the integral term in PID tracking control methods, we not only use the system tracking error as one of the inputs of the broad learning system, but also use the integral term of the tracking error as another input to eliminate the constant deviation between the desired and the actual trajectory. Then, we utilize the broad learning system to calculate the control pressure, and we adjust the weight of the broad learning system online by the learning law based on the gradient descent method to reduce the tracking error. Experiments are designed to verify the effectiveness of the proposed method. The proposed method does not need to establish a model and simplifies the controller design steps. Compared with the control methods based on the deep neural network, the proposed method can achieve higher tracking control accuracy without excessive computation.

**Keywords:** pneumatic soft actuator; pneumatic bellow actuator; soft robotics; broad learning system; model-free tracking control; gradient descent

收稿日期: 2022-04-03; 录用日期: 2022-09-03.

基金项目: 国家自然科学基金项目(61773353); 湖北省自然科学基金创新群体项目(2015CFA010); 高等学校学科创新引智计划项目(B17040).

†通讯作者. E-mail: mengqx@cug.edu.cn.

## 0 引言

软体机器人由低模量软材料制成,具备像生物系统柔性结构一样连续变形的能力<sup>[1]</sup>.与刚性机器人相比,软体机器人具有较高的柔顺性,能够适应未知环境,在人机交互方面具有天然优势,是未来机器人研究的重要领域之一<sup>[2]</sup>.软体驱动器作为软体机器人的重要构件,在软体机器人运动时起到重要的驱动作用<sup>[3]</sup>.当前,软体驱动器的主要驱动方式有电驱动<sup>[4]</sup>、气驱动<sup>[5]</sup>、化学驱动<sup>[6]</sup>等,其中气驱动方式具有功率密度比高、驱动力较大、清洁环保等优点,使气动软体驱动器得到广泛应用.

当前,常见的气动软体驱动器可根据充气致变类型大致分为充气收缩型气动软体驱动器<sup>[7-8]</sup>和充气伸长型气动软体驱动器<sup>[9-10]</sup>等.近20年中,学者们针对充气收缩型气动软体驱动器已开展大量研究,研究对象多为气动人工肌肉驱动器<sup>[7-8]</sup>.该类驱动器主要由橡胶管和纤维套筒组成,在充气时会产生较大的驱动力.然而,由于纤维套筒的轴向变形被限制,系统充气时会产生较大的径向膨胀,不利于在一些限制径向变形的狭小空间中工作.而充气伸长型气动软体驱动器为提高轴向伸长能力,常引入难以径向拉伸的纤维<sup>[9]</sup>、O型环<sup>[10]</sup>等装置限制径向膨胀,以避免出现上述问题.然而,尽管目前气动软体驱动器结构设计和制作等领域已有一定的研究成果,但其控制问题仍是一项亟待解决且具有挑战性的工作<sup>[1]</sup>.

气动软体驱动器控制问题的挑战性主要体现在:1)气动软体驱动器运动过程中表现出复杂的迟滞、蠕变等非线性特性<sup>[8]</sup>,使传统线性控制方法适用性变差;2)很多气动软体驱动器形状结构复杂,且其性能易受软材料老化、温度变化等因素影响<sup>[11]</sup>,这无疑进一步加大了建模与控制难度.

当前已有的针对气动软体驱动器的控制方法大致划分为基于模型的控制方法<sup>[12-14]</sup>和无模型控制方法<sup>[15-17]</sup>.基于模型的控制方法包含两种策略:一种是建立气动软体驱动器模型,并基于此模型设计控制器,如Shen<sup>[12]</sup>针对一款充气收缩型气动软体驱动器提出一种综合考虑驱动器静力学模型、气压动力学模型和流体动力学模型的系统模型,并根据该模型设计滑模控制器实现了系统轨迹跟踪控制目标;另一种是先建立气动软体驱动器模型,再基于模型信息整定控制器参数,如Escobar等<sup>[14]</sup>针对由充气收缩型气动软体驱动器驱动的SCARA机器人建立了一种二阶系统模型,进而设计PID控制器并基于模型整定控制器参数.需要注意的是,很多基于模型的控制方法

在建模中假设气动软体驱动器形状规则、均匀.然而,大部分驱动器具有复杂形状和结构,这导致它们往往很难建模或模型精度较低<sup>[11]</sup>.此外,基于模型的控制方法的控制效果多依赖先验模型的精度<sup>[18]</sup>,而软材料制成的气动软体驱动器的性能易受材料老化、温度变化影响,先验模型不再能准确描述当前驱动器状态,进而导致运动控制效果变差.

无模型控制方法不需要对气动软体驱动器建立具体的数学模型,而是直接利用状态信息进行加权、叠加、线性或非线性变换等操作,得到驱动气压控制律,进而促使驱动器产生期望运动.常见的无模型控制方法有PID控制<sup>[15]</sup>、神经网络控制<sup>[16-17]</sup>等.PID控制虽然原理简单,但其控制系统优劣与控制器参数具有强相关性,往往难以实现对气动软体驱动器的高性能控制<sup>[19]</sup>.

相比之下,神经网络控制在复杂非线性系统高性能控制上效果显著<sup>[20]</sup>.按照神经网络复杂程度,神经网络控制大致分为浅层神经网络控制<sup>[16]</sup>和深度神经网络控制<sup>[17]</sup>两种.浅层神经网络结构简单、计算耗时少,常用于气动软体驱动器在线控制方案<sup>[16]</sup>.深度神经网络具有更强的表达能力和更高的精度<sup>[21]</sup>,但其结构复杂,往往需要大量时间用于计算,常用于气动软体驱动器离线控制器训练<sup>[17]</sup>.近年来,Chen等<sup>[22]</sup>在继承随机向量函数链式神经网络主要特点的基础上,提出一种新型浅层神经网络结构——宽度学习系统.与深度神经网络相比,宽度学习系统在不增加层数的情况下,对神经网络节点进行了广泛扩展.此外,宽度学习系统不需要像深度神经网络一样逐层进行参数调整,具有较高的运算效率<sup>[23]</sup>.因此,宽度学习系统是一种计算量小且不损失精度的方法.然而,目前基于宽度学习系统的气动软体驱动器控制研究还比较少.

根据上述分析,本文以一款具有波纹管外形的伸长型气动软体驱动器(以下简称“气动波纹管驱动器”)作为研究对象,研究该类系统的无模型跟踪控制问题.该驱动器被设计为波纹状结构,在充气时易于伸长,具有充气大变形、效率高、能耗低等优势.受宽度学习系统启发,针对该驱动器提出一种基于宽度学习系统的无模型跟踪控制方法.首先,介绍气动波纹管驱动器结构,以及气动波纹管驱动器整体实验平台工作原理.为实现该驱动器无模型跟踪控制的目标,直接利用驱动器实时位置信息提出一种基于宽度学习系统的跟踪控制方法,受PID跟踪控制方法中积分项作用的启发,所提出控制方法不仅采用系统跟踪误

差作为宽度学习系统的输入之一,还采用跟踪误差对时间的积分项作为另一输入来消除期望轨迹与实际轨迹间的恒定偏差. 然后,采用宽度学习系统计算得到驱动器控制气压,期间设计关于系统跟踪误差的损失函数,采用基于梯度下降法的学习律在线优化宽度学习系统权值,使损失函数最小化,进而降低系统跟踪误差. 最后,设计实验验证所提出方法的有效性.

## 1 气动波纹管驱动器及其实验平台

本节首先介绍气动波纹管驱动器,然后介绍各实验装置功能及完整实验平台工作原理.

### 1.1 气动波纹管驱动器

如图1所示,气动波纹管驱动器主要由波纹管和外层织物构成. 充气时,波纹管的波纹状结构在轴向上展开,产生较大轴向伸长和轻微径向膨胀. 考虑到波纹管在安全气压范围内的充气变形以轴向伸长为主,本文重点研究气动波纹管驱动器轴向运动时的无模型跟踪控制问题. 为进一步限制波纹管径向膨胀,将无弹力的尼龙外层织物覆盖在波纹管表面,使外层织物基本贴合波纹管外形.

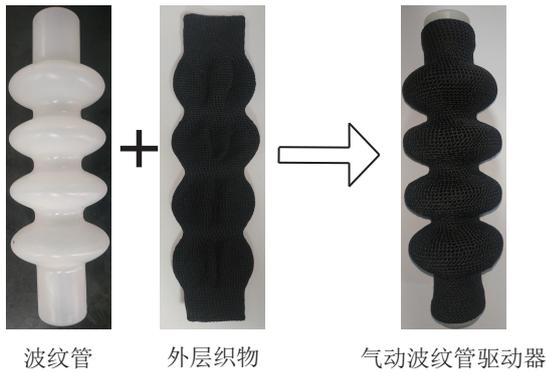


图1 气动波纹管驱动器结构

### 1.2 实验平台

为实现气动波纹管驱动器状态采集和跟踪控制,搭建如图2所示的实验平台. 具体地由以下装置组成: 1)比例-压力调节器(VPPE-3-1-1/8-2-010-E1,

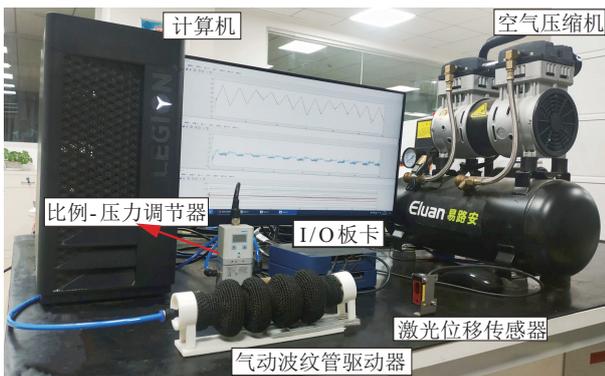


图2 气动波纹管驱动器实验平台

Festo),用于调节气动波纹管驱动器内部气压 $P$ ; 2)激光位移传感器(HG-C1200, Panasonic),用于测量气动波纹管驱动器轴向运动的直线位移 $x$ ; 3)I/O板卡(PCIe-6363, National Instruments),用于连接计算机与实际系统; 4)计算机(CPU: AMD Ryzen 7 3700X, Lenovo, 内存: 16 GB),用于计算控制气压 $P_r$ ; 5)空气压缩机(ES18L, Eluan),用于给实验平台提供稳定气压源; 6)气动波纹管驱动器.

下面介绍完整实验平台工作原理: 空气压缩机在实验过程中为整个实验平台提供稳定气压. 气动波纹管驱动器的位移 $x$ 由激光位移传感器测得,并以模拟电压形式通过I/O板卡发送到计算机. 计算机将接收到的模型电压值按比例转化为位移 $x$ 的具体数值. 基于位移 $x$ 和本文控制策略,计算机计算得到控制气压 $P_r$ ,经比例关系 $V = P_r\Psi$ 得到控制信号 $V$  ( $\Psi > 0$ 为比例-压力调节器比例系数),并通过I/O板卡将控制信号 $V$ 以模拟电压形式发送给比例-压力调节器. 根据控制信号 $V$ ,比例-压力调节器输出气动波纹管驱动器的内部气压 $P$ ,且 $P \approx P_r$ . 在比例-压力调节器产生的气压作用下,驱动器在水平面上直线运动.

## 2 控制器设计

本节首先介绍基于宽度学习系统的无模型跟踪控制框架,进而设计基于宽度学习系统的无模型跟踪控制方法.

### 2.1 控制框架设计

本文的控制目标是利用宽度学习系统产生合适的控制气压 $P_r$ ,促使气动波纹管驱动器的实际轨迹 $x$ 跟踪期望轨迹 $x_d$ . 定义系统跟踪误差 $e$ 为 $e = x - x_d$ .

在传统PID跟踪控制方法中,系统跟踪误差对时间的积分项有助于消除 $x_d$ 与 $x$ 间存在的恒定偏差<sup>[24]</sup>. 受此启发,为提高控制精度,将系统跟踪误差 $e$ 作为宽度学习系统输入之一的同时,将 $e$ 对时间的积分项作为宽度学习系统的另一输入来消除 $x_d$ 与 $x$ 间存在的恒定偏差. 定义 $X$ 作为宽度学习系统的输入向量,则 $X = [e, \int_0^t e dt]^T$ .

输入向量 $X$ 经过宽度学习系统中加权、映射等操作后,得出控制气压 $P_r$ ,其中宽度学习系统权值由基于梯度下降法的学习律在线调整. 随后,由比例关

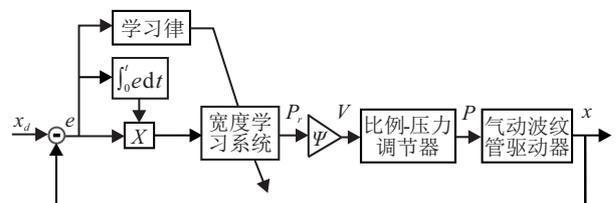


图3 气动波纹管驱动器控制框图

系  $V = P_r \psi$  得到控制信号  $V$ . 基于控制信号  $V$ , 比例-压力调节器输出调节气动波纹管驱动器的内部气压  $P$ . 控制框图如图3所示.

## 2.2 宽度学习系统

首先, 将输入  $X$  经加权和偏置后映射到  $n$  个特征上, 其中第  $i$  个映射特征  $Z_i (i = 1, 2, \dots, n) \in \mathbb{R}^{1 \times k_i}$  为

$$Z_i = XW_{f_i} + \partial_{f_i}. \quad (1)$$

其中:  $W_{f_i} \in \mathbb{R}^{2 \times k_i}$  和  $\partial_{f_i} \in \mathbb{R}^{1 \times k_i}$  为连接  $X$  到  $Z_i$  的权值矩阵和偏置矩阵, 其元素在  $[0, 1]$  区间内随机选取. 每个  $Z_i$  中包含  $k_i$  个特征结点, 令  $Z = [Z_1, Z_2, \dots, Z_n] \in \mathbb{R}^{1 \times (k_1 + \dots + k_n)}$  代表所有映射特征,  $Z$  通过非线性变换得到  $m$  组增强结点, 其中第  $j$  组增强结点  $H_j (j = 1, 2, \dots, m) \in \mathbb{R}^{1 \times q_j}$  写作

$$H_j = \xi_j(ZW_{e_j} + \beta_{e_j}). \quad (2)$$

其中:  $W_{e_j} \in \mathbb{R}^{(k_1 + \dots + k_n) \times q_j}$  和  $\beta_{e_j} \in \mathbb{R}^{1 \times q_j}$  为连接  $Z$  到  $H_j$  的权值矩阵和偏置矩阵, 其元素在  $[0, 1]$  区间内随机选取. 采用双曲正切函数  $\xi_j(*) = \tanh(*)$  作为  $Z$  到  $H_j$  的非线性映射,  $H_j$  中包含  $q_j$  个增强结点, 令  $H = [H_1, \dots, H_m] \in \mathbb{R}^{1 \times (q_1 + \dots + q_m)}$  代表所有增强结点. 将  $Z$  与  $H$  加权叠加后, 得到控制气压  $P_r$  为

$$P_r = [Z_1, \dots, Z_n, H_1, \dots, H_m]W = [Z, H]W, \quad (3)$$

其中  $W \in \mathbb{R}^{(k_1 + \dots + k_n + q_1 + \dots + q_m) \times 1}$  为将  $Z$  和  $H$  连接到输出  $P_r$  的权值矩阵, 其元素在  $[0, 1]$  中随机选取. 综上所述, 宽度学习系统的基本结构如图4所示.

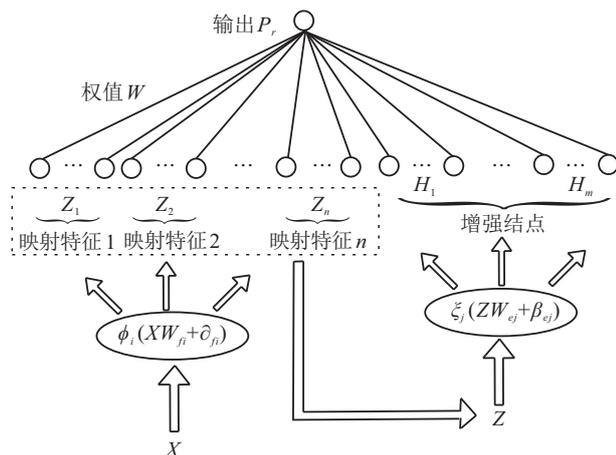


图4 宽度学习系统基本框架

为使宽度学习系统根据气动波纹管驱动器的实时状态  $X$  计算出促使跟踪误差  $e$  趋近于 0 的控制气压, 需要实时在线更新宽度学习系统权值  $W$ . 下一节将基于梯度下降法设计学习律以更新  $W$ .

## 2.3 基于梯度下降法的学习律

为使跟踪误差  $e$  趋近于 0, 构造一个关于  $e$  的损失函数, 并采用梯度下降法对该函数进行最小化处

理. 定义第  $K$  个采样时刻下的损失函数  $J(K)$  为

$$J(K) = 0.5(x(K) - x_d(K))^2 = 0.5e^2(K), \quad (4)$$

其中  $x(K)$ ,  $x_d(K)$  和  $e(K)$  分别为第  $K$  个采样时刻下气动波纹管驱动器的实际位移、期望位移和跟踪误差. 采用梯度下降法, 考虑损失函数(4), 设计如下学习律在线更新宽度学习系统权值:

$$W(K+1) = W(K) - \eta \frac{\partial J(K)}{\partial W(K)}, \quad (5)$$

其中  $\eta$  为学习率. 式(5)中  $J(K)$  关于  $W(K)$  的偏导可以写作

$$\frac{\partial J(K)}{\partial W(K)} = \frac{\partial J(K)}{\partial e(K)} \frac{\partial e(K)}{\partial x(K)} \frac{\partial x(K)}{\partial P_r(K)} \frac{\partial P_r(K)}{\partial W(K)}. \quad (6)$$

分析式(6), 得到

$$\begin{aligned} \frac{\partial J(K)}{\partial e(K)} &= e(K), \quad \frac{\partial e(K)}{\partial x(K)} = 1, \quad \frac{\partial x(K)}{\partial P_r(K)} \approx \frac{\Delta x}{\Delta P_r}, \\ \frac{\partial P_r(K)}{\partial W(K)} &= [Z, H]^T. \end{aligned} \quad (7)$$

其中:  $\Delta x = x(K) - x(K-1)$ ,  $\Delta P_r = P_r(K) - P_r(K-1)$ . 经整理, 宽度学习系统的学习律可以写作

$$W(K+1) \approx W(K) - \eta e(K) \frac{\Delta x}{\Delta P_r} [Z, H]^T. \quad (8)$$

综上, 本文的控制方法包含两个重要部分: 一是以系统跟踪误差及其积分所构成的向量为输入, 以控制气压为输出构建的宽度学习系统(1)~(3), 它产生控制气压促使驱动器运动; 二是所设计的基于梯度下降法的学习律(8), 它以降低系统跟踪误差为目标, 在线更新宽度学习系统权值. 权值经更新后作用于宽度学习系统, 从而使得宽度学习系统产生合适的控制气压, 促使驱动器跟踪期望轨迹, 实现该驱动器无模型跟踪控制的目标.

## 3 实验与分析

基于图2所示的实验平台进行气动波纹管驱动器轨迹跟踪控制实验. 为表明所提出控制方法的优越性, 设计3个实验进行对比分析. 其中: 实验1和实验2对比了所提出控制方法与传统PID控制器的跟踪控制效果; 实验3从计算量和跟踪控制效果两方面对比所提出控制方法与深度神经网络控制方法的性能.

设置比例-压力调节器的比例系数  $\psi = 1/0.06$ . 在实验1和实验2中, 系统采样时间与求解器步长被设置为 0.01 s. 在实验3中, 通过在多个实验中设置不同的求解器步长评估所提出控制方法与深度神经网络控制方法的计算量. 期间, 系统采样时间与求解器步长保持一致.

设置所提出控制方法的参数为  $n = 2, k_1 = k_2 =$

10,  $\eta = 0.000\ 000\ 01$ ,  $m = 10$ ,  $q_1 = q_2 = \dots = q_{10} = 1$ .

为防止随机选取的权值矩阵因元素初始值过大而导致初始阶段控制气压过大,从而使驱动器迅速膨胀并破裂,将权值矩阵  $W$  的元素初始值设置为0,而  $W_{fi}$ 、 $\partial_{fi}$ 、 $W_{ej}$  和  $\beta_{ej}$  的元素初始值在  $[0, 1]$  中随机选取.

用于对比的PID控制器结构如下:

$$P_r = K_P e + K_I \int_0^t e dt + K_D \dot{e}, \quad (9)$$

其中  $K_P$ 、 $K_I$  和  $K_D$  分别为比例系数、积分系数和微分系数. 基于著名的 Ziegler-Nichols PID 参数整定方法<sup>[25]</sup>,通过多次实验测试获得一组使得气动波纹管驱动器跟踪效果最优的参数,即  $K_P = 0.06$ ,  $K_I = 0.1$ ,  $K_D = 0.01$ .

对于深度神经网络控制方法,选用文献[26]的深度神经网络设计方法. 该网络输入仍采用  $X$ , 输出为  $P_r$ , 激活函数为 sigmoid 函数,学习率为0.000 5,权值与偏置矩阵由基于链式法则的梯度下降法在线更新.

为了便于描述跟踪精度,采用下式计算均方根误差百分比  $e_{rs}$ :

$$e_{rs} = \frac{\sqrt{\frac{1}{N} \sum_{K=1}^N (x_d(K) - x(K))^2}}{\max(x_d)}, \quad (10)$$

其中  $N$  为总采样点数. 由式(10)可知,气动波纹管驱动器的跟踪精度越高,均方根误差百分比  $e_{rs}$  越小.

下面通过3组实验验证所提出控制方法的有效性和优越性.

### 3.1 实验1

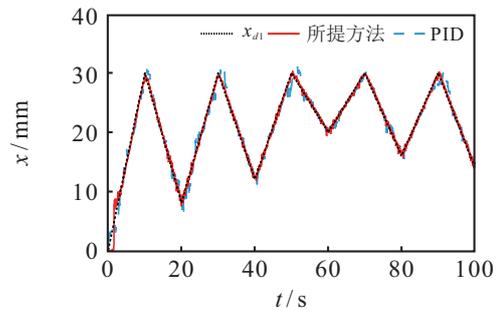
为使气动波纹管驱动器跟踪复杂三角波轨迹,设置期望轨迹  $x_{d1}$  为

$$x_{d1} = \begin{cases} 4d_0 f t, & 0 \leq t \leq \omega; \\ 2d_0 - 4d_l f (t_e - \delta), & \delta \leq t_e \leq \omega; \\ 2\Delta d + 4d_l f (t_e - \omega), & \omega \leq t_e \leq 2\omega. \end{cases} \quad (11)$$

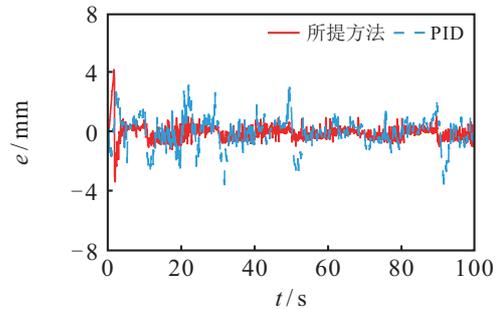
其中:  $d_0$  和  $d_l$  ( $l = 1, 2, \dots, 5$ ) 为振幅,  $f$  为频率,  $t$  为时间,  $t_e = \text{rem}\left(t - \frac{1}{2f}, \frac{5}{f}\right)$ ,  $\delta = \frac{l-1}{2f}$ ,  $\Delta d = d_0 - d_l$ ,  $\omega = \frac{l}{2f}$ . 设置  $d_0 = 15$ ,  $d_1 = 11$ ,  $d_2 = 9$ ,  $d_3 = 5$ ,  $d_4 = 7$ ,  $d_5 = 8$ .

由理想气体状态方程可知,一个腔体内部气压和内部体积的乘积与腔体内部气体的物质质量成正比. 因此,若要对气动波纹管驱动器内部气压进行调节,则需要通过充气排气的方式改变驱动器内部气体的物质质量,这是一个缓慢响应的过程,因此频率  $f$  不

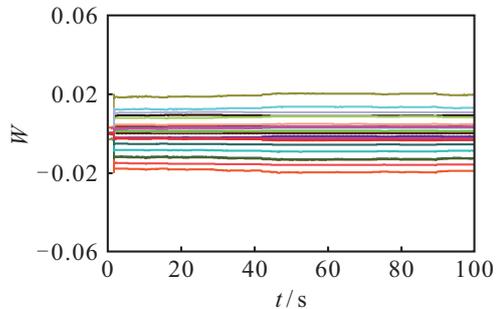
宜过高. 设置  $f = 0.05$  Hz, 所提出控制方法和PID控制器的轨迹跟踪实验结果见图5. 由图5可知,所提出控制方法和PID控制器均能完成跟踪控制任务. 具体来看,所提出控制方法的权值经过短暂调整后基本收敛,系统跟踪误差随之降低. 根据式(10),PID控制器在跟踪  $f = 0.05$  Hz 的期望轨迹  $x_{d1}$  时  $e_{rs}$  为3.12%, 所提出控制方法的  $e_{rs}$  为1.74%. 因此,所提出控制方法相比PID控制器能取得更高的跟踪控制精度.



(a) 跟踪结果



(b) 跟踪误差



(c) 权值

图5 跟踪0.05 Hz 复杂三角波期望轨迹

为评估所提出控制方法和PID控制器在跟踪不同频率的期望轨迹  $x_{d1}$  时的跟踪控制效果,调整  $f = 0.1$  Hz 进行实验,实验结果见图6. 由图6可知,所提出控制方法的跟踪控制效果更优,宽度学习系统权值依然快速收敛. 根据式(10),PID控制器在跟踪  $f = 0.1$  Hz 的期望轨迹  $x_{d1}$  时  $e_{rs}$  为6.22%, 所提出控制方法的  $e_{rs}$  为2.66%. 因此,所提出控制方法相比PID控制器能取得更高的跟踪控制精度.

由实验1可知,所提出控制方法能使气动波纹管驱动器较好地跟踪不同频率的复杂三角波轨迹.

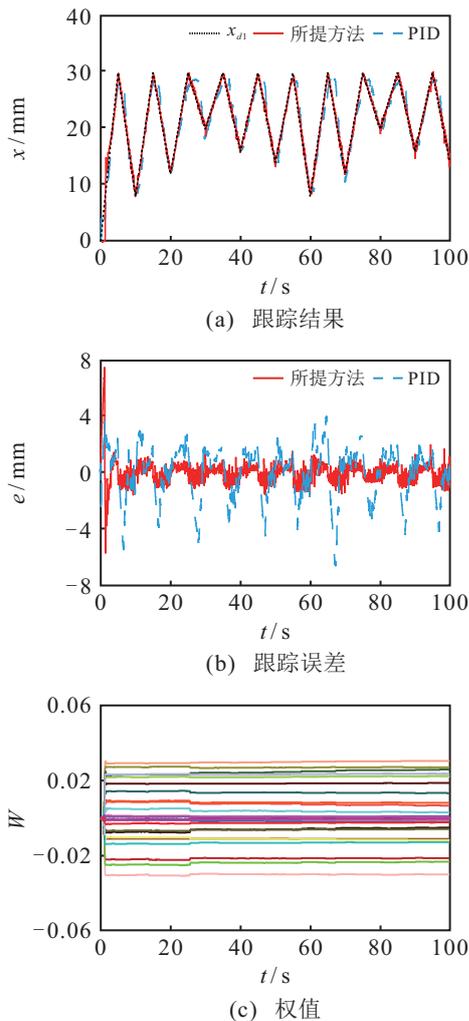


图6 跟踪0.1 Hz复杂三角波期望轨迹

### 3.2 实验2

为评估所提出控制方法和PID控制器在跟踪不同波形期望轨迹时的跟踪控制效果,使气动波纹管驱动器跟踪复杂正弦波轨迹,设置期望轨迹 $x_{d2}$ 为

$$x_{d2} = \begin{cases} d_0 \sin(2\pi ft - 0.5\pi) + d_0, & t \leq \omega; \\ d_l \cos(2\pi ft_e) + 2d_0 - d_l, & 2\delta \leq t_e \leq \omega. \end{cases} \quad (12)$$

当 $f = 0.05 \text{ Hz}$ 时,实验结果见图7.由图7可知,所提出控制方法和PID控制器均能完成跟踪控制任务,宽度学习系统权值依然快速收敛.根据式(10),PID控制器在跟踪 $f = 0.05 \text{ Hz}$ 的期望轨迹 $x_{d2}$ 时 $e_{rs}$ 为3.59%,所提出控制方法的 $e_{rs}$ 为1.39%.因此,所提出控制方法相比PID控制器能取得更高的跟踪控制精度.

为进一步评估所提出控制方法和PID控制器在跟踪不同频率的期望轨迹 $x_{d2}$ 时的跟踪控制效果,设置 $f = 0.1 \text{ Hz}$ 进行轨迹跟踪控制实验,实验结果见图8.由图8可知,所提出控制方法的跟踪控制效果更好,宽度学习系统权值依然快速收敛.根据式(10),PID

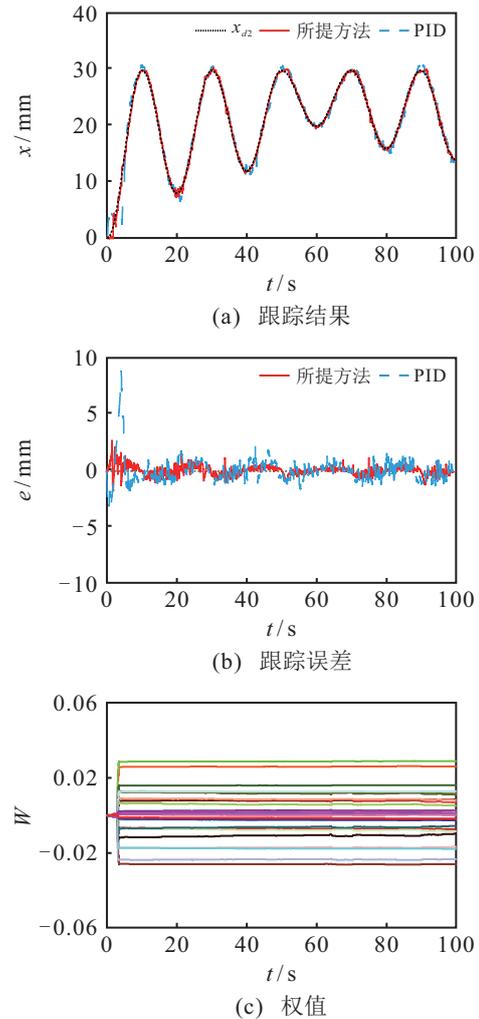


图7 跟踪0.05 Hz复杂正弦波期望轨迹

控制器在跟踪 $f = 0.1 \text{ Hz}$ 的期望轨迹 $x_{d2}$ 时 $e_{rs}$ 为7.66%,所提出控制方法的 $e_{rs}$ 为2.28%.因此,所提出控制方法相比PID控制器能取得更高的跟踪控制精度.

由实验2可知,所提出控制方法能使气动波纹管驱动器较好地跟踪不同频率的复杂正弦波轨迹.

### 3.3 实验3

在相同运算环境下,对所提出控制方法和深度神经网络控制方法分别进行气动波纹管驱动器轨迹跟踪控制实验,通过对比它们正常运行时所需的最小求解器步长,表明所提出控制方法在计算量上的优越性.

设置期望轨迹为 $f = 0.05 \text{ Hz}$ 时的复杂正弦波轨迹 $x_{d2}$ .考虑到深度神经网络的隐藏层层数通常需要大于或等于3时才能获得较好的效果,首先设置隐藏层层数为3,使隐藏层节点数从2开始逐步增加,并执行轨迹跟踪控制实验,直到达到可接受的跟踪控制效果.表1展示了当求解器步长为0.01 s、0.03 s及0.06 s时,对应的两种深度神经网络控制方法(隐藏层

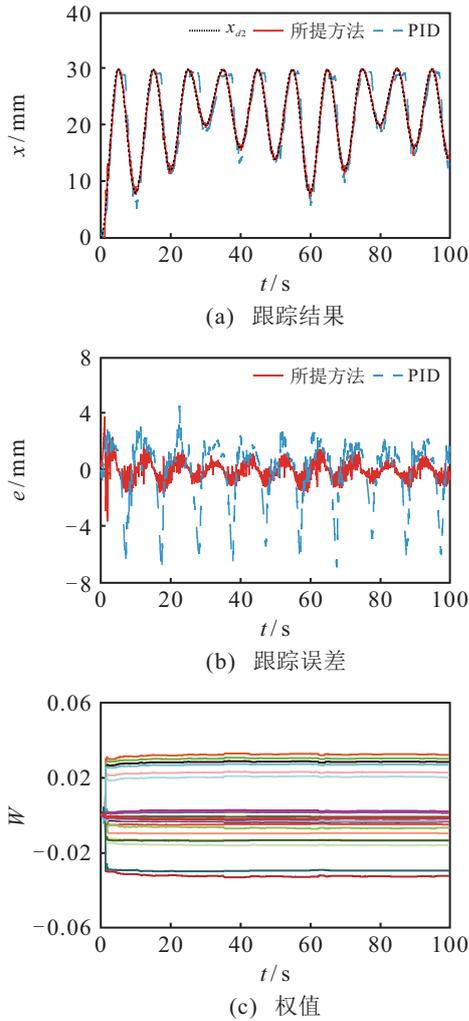


图8 跟踪0.1 Hz复杂正弦波期望轨迹

节点数分别为2和12)及所提出控制方法的跟踪控制效果. 其中,  $e_{rs}$  结果为“/”代表求解器无法在规定时间内完成计算而造成运算中断现象. 在本节中, 可根据上述3种控制方法正常运行时所需的最小求解器步长判断控制方法计算量的大小.

表1 3种控制方法跟踪控制效果

控制方法	求解器步长/s	$e_{rs}/\%$
宽度学习系统	0.01	1.39
	0.03	2.05
	0.06	2.60
深度神经网络(2节点)	0.01	/
	0.03	4.41
	0.06	4.53
深度神经网络(12节点)	0.01	/
	0.03	/
	0.06	2.94

由表1可知, 所提出控制方法需要的最小求解器步长在0~0.01 s之间, 表明该控制方法能在0.01 s内顺利完成一次运算, 且对应的  $e_{rs}$  为1.39%. 而隐藏层节点数为2的深度神经网络控制方法无法在0.01 s的求解器步长下顺利完成计算, 其最小求解器步长在

0.01~0.03 s之间, 且对应的  $e_{rs}$  为4.41%, 跟踪精度远低于所提出控制方法. 通过增加深度神经网络隐藏层的节点数可以提高跟踪精度, 当隐藏层节点数为12时, 深度神经网络控制方法可以获得  $e_{rs}$  为2.94%的跟踪精度, 但这也导致控制方法计算量的增加, 其最小求解器步长增加至0.03~0.06 s之间. 表1中3种控制方法对应的最优控制效果如图9所示. 由图9可知, 所提出控制方法仍保持了最高的跟踪控制精度.

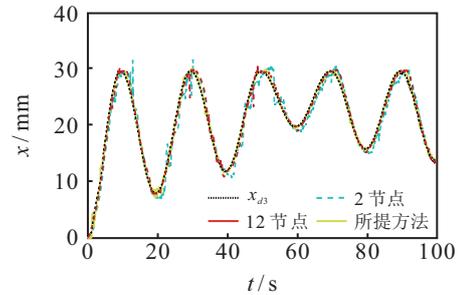


图9 3种控制方法最优跟踪效果

与深度神经网络控制方法相比, 所提出控制方法能在计算量小的前提下实现较高的跟踪精度, 更适用于气动波纹管驱动器的轨迹跟踪控制.

#### 4 结论

本文针对一款气动波纹管驱动器, 提出一种基于宽度学习系统的无模型跟踪控制方法. 该方法无需建立驱动器模型, 能在避免计算量过大的前提下实现较高的跟踪控制精度. 首先介绍气动波纹管驱动器及其实验平台完整工作原理. 直接利用驱动器实时位置信息提出一种基于宽度学习系统的跟踪控制方法, 受PID跟踪控制方法中积分项作用的启发, 所提出控制方法在将系统跟踪误差作为宽度学习系统输入之一的同时, 还将跟踪误差对时间的积分项作为宽度学习系统的另一输入以消除期望轨迹与实际轨迹间的恒定偏差. 然后采用宽度学习系统计算得到控制气压, 同时设计基于梯度下降法的学习律在线调整宽度学习系统权值, 降低系统跟踪误差. 最后通过实验表明所提出方法能够使驱动器较好地跟踪期望信号.

#### 参考文献(References)

- [1] Wang T, Zhang Y C, Chen Z, et al. Parameter identification and model-based nonlinear robust control of fluidic soft bending actuators[J]. IEEE/ASME Transactions on Mechatronics, 2019, 24(3): 1346-1355.
- [2] Majidi C. Soft robotics: A perspective—Current trends and prospects for the future[J]. Soft Robotics, 2014, 1(1): 5-11.
- [3] Mohammadi A, Tavakoli M, Marquez H J, et al. Nonlinear disturbance observer design for robotic

- manipulators[J]. *Control Engineering Practice*, 2013, 21(3): 253-267.
- [4] 叶克贝, 朱剑英, 王化明. 锥型介电弹性体驱动器的性能研究[J]. *机械制造与自动化*, 2009, 38(1): 15-17. (Ye K B, Zhu J Y, Wang H M. Research on the properties of dielectric elastomer cone actuator[J]. *Machine Building & Automation*, 2009, 38(1): 15-17.)
- [5] 秦岩丁, 徐圆凯, 韩建达. 气动人工肌肉驱动的肘关节辅助机器人迟滞补偿[J]. *机器人*, 2021, 43(4): 453-462. (Qin Y D, Xu Y K, Han J D. Hysteresis compensation of pneumatic artificial muscle actuated assistive robot for the elbow joint[J]. *Robot*, 2021, 43(4): 453-462.)
- [6] Wehner M, Truby R L, Fitzgerald D J, et al. An integrated design and fabrication strategy for entirely soft, autonomous robots[J]. *Nature*, 2016, 536(7617): 451-455.
- [7] 赵苓, 李奇. 气动人工肌肉驱动单关节机械臂的自抗扰控制[J]. *液压与气动*, 2017(3): 38-42. (Zhao L, Li Q. An active disturbance rejection control approach for one-DOF manipulator driven by pneumatic artificial muscles[J]. *Chinese Hydraulics & Pneumatics*, 2017(3): 38-42.)
- [8] Cao Y, Huang J. Neural-network-based nonlinear model predictive tracking control of a pneumatic muscle actuator-driven exoskeleton[J]. *IEEE/CAA Journal of Automatica Sinica*, 2020, 7(6): 1478-1488.
- [9] Zhang Z Y, Wang X Q, Wang S T, et al. Design and modeling of a parallel-pipe-crawling pneumatic soft robot[J]. *IEEE Access*, 2019, 7: 134301-134317.
- [10] Calderón A A, Ugalde J C, Zagal J C, et al. Design, fabrication and control of a multi-material-multi-actuator soft robot inspired by burrowing worms[C]. *IEEE International Conference on Robotics and Biomimetics. Qingdao*, 2017: 31-38.
- [11] Li Y Q, Cao Y, Jia F. A neural network based dynamic control method for soft pneumatic actuator with symmetrical chambers[J]. *Actuators*, 2021, 10(6): 112.
- [12] Shen X R. Nonlinear model-based control of pneumatic artificial muscle servo systems[J]. *Control Engineering Practice*, 2010, 18(3): 311-317.
- [13] Skorina E H, Luo M, Oo W Y, et al. Reverse pneumatic artificial muscles (rPAMs): Modeling, integration, and control[J]. *PLoS One*, 2018, 13(10): e0204637.
- [14] Escobar F, Díaz S, Gutiérrez C, et al. Simulation of control of a scara robot actuated by pneumatic artificial muscles using RNAPM[J]. *Journal of Applied Research and Technology*, 2014, 12(5): 939-946.
- [15] Andrikopoulos G, Nikolakopoulos G, Manesis S. Design and development of an exoskeletal wrist prototype via pneumatic artificial muscles[J]. *Meccanica*, 2015, 50(11): 2709-2730.
- [16] Chiang C J, Chen Y C. Neural network fuzzy sliding mode control of pneumatic muscle actuators[J]. *Engineering Applications of Artificial Intelligence*, 2017, 65: 68-86.
- [17] Satheeshbabu S, Uppalapati N K, Chowdhary G, et al. Open loop position control of soft continuum arm using deep reinforcement learning[C]. *International Conference on Robotics and Automation. Montreal*, 2019: 5133-5139.
- [18] Khawwaf J, Zheng J C, Wang H, et al. Practical model-free robust estimation and control design for an underwater soft IPMC actuator[J]. *IET Control Theory & Applications*, 2020, 14(11): 1508-1515.
- [19] Cao Y, Huang J, Ding G Z, et al. Design of nonlinear predictive control for pneumatic muscle actuator based on echo state Gaussian process[J]. *IFAC-Papers OnLine*, 2017, 50(1): 1952-1957.
- [20] Chen J, Huang T C. Applying neural networks to on-line updated PID controllers for nonlinear process control[J]. *Journal of Process Control*, 2004, 14(2): 211-230.
- [21] Lucia S, Karg B. A deep learning-based approach to robust nonlinear model predictive control[J]. *IFAC-Papers OnLine*, 2018, 51(20): 511-516.
- [22] Chen C L P, Liu Z L. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(1): 10-24.
- [23] Liu W J, Bai Y T, Jin X B, et al. Broad echo state network with reservoir pruning for nonstationary time series prediction[J]. *Computational Intelligence and Neuroscience*, 2022, 2022: 3672905.
- [24] Gowthaman E, Vinodhini V, Hussain M Y, et al. Speed control of permanent magnet brushless DC motor using hybrid fuzzy proportional plus integral plus derivative controller[J]. *Energy Procedia*, 2017, 117: 1101-1108.
- [25] O'Dwyer A. Handbook of PI and PID controller tuning rules[M]. The 2nd edition. London: Imperial College Press, 2006: 27.
- [26] Lavrentev F V, Romyantsev I S, Ivanov A S, et al. Soft hydrogel actuator for fast machine-learning-assisted bacteria detection[J]. *ACS Applied Materials & Interfaces*, 2022, 14(5): 7321-7328.

## 作者简介

赵诗影(1998—), 女, 博士生, 从事软体机器人建模和控制等研究, E-mail: zhaoshiying@cug.edu.cn;

闫泽(1995—), 女, 博士生, 从事欠驱动机械系统、柔性机械臂系统控制等研究, E-mail: yanz@cug.edu.cn;

孟庆鑫(1993—), 男, 教授, 博士, 从事欠驱动机械系统、柔性机械臂、软体机器人等研究, E-mail: mengqx@cug.edu.cn;

肖怀(1998—), 男, 博士生, 从事软体机器人设计、建模和控制等研究, E-mail: xiaohuai@cug.edu.cn;

赖旭芝(1966—), 女, 教授, 博士生导师, 从事智能控制、机器人控制、非线性系统控制等研究, E-mail: laixz@cug.edu.cn;

吴敏(1963—), 男, 教授, 博士生导师, 从事鲁棒控制、智能控制、过程控制等研究, E-mail: wumin@cug.edu.cn.