

基于小脑脉冲神经网络的柔性机械臂运动控制¹⁾

张透明* 韩芳*,†,2) 王青云†,**

*(东华大学信息科学与技术学院, 上海 201620)

†(宁夏大学数学统计学院, 宁夏数学基础学科研究中心, 银川 750021)

**(北京航空航天大学动力学与控制系, 北京 100191)

摘要 柔性机械臂由于自身材料的柔软特性, 极容易受到环境中的不确定性干扰, 从而发生意外形变, 影响控制精度. 针对该情况, 借鉴人体中小脑对运动的调控和对环境的适应性, 搭建了小脑脉冲神经网络模型, 用于对柔性机械臂在环境干扰下的运动行为进行纠正控制. 首先, 基于分段常曲率方法建立了一个多自由度柔性机械臂模型, 它具有移动关节和旋转关节, 可以实现伸缩和弯曲的运动行为; 并采用顺序二次规划算法近似计算得到机械臂的逆运动学模型, 从而求解与期望轨迹对应的期望关节参数. 然后, 借鉴小脑皮层的神经系统结构与自适应功能, 对颗粒层与浦肯野细胞层之间的突触可塑性进行建模, 完整构建了小脑脉冲神经网络模型. 最后, 研究了环境干扰下柔性机械臂完成圆形轨迹和“8”字形轨迹的运动效果, 发现与不使用小脑模型的直接开环控制运动结果相比, 柔性机械臂末端执行器在小脑脉冲神经网络控制下的轨迹误差分别降低了 95% 和 96%, 验证了小脑脉冲神经网络模型对于控制柔性机械臂对抗不确定性干扰的有效性. 相较于传统的控制方法, 该方法更具有生物可解释性, 为柔性机械臂在不确定性扰动下的控制提供了一种类脑智能方法.

关键词 小脑, 柔性机械臂, 脉冲神经网络, 适应性

中图分类号: O313, TP273

文献标识码: A

DOI: 10.6052/0459-1879-24-560

CSTR: 32045.14.0459-1879-24-560

MOTION CONTROL OF FLEXIBLE ROBOTIC ARMS BASED ON CEREBELLAR SPIKING NEURAL NETWORK¹⁾

Zhang Touming* Han Fang*,†,2) Wang Qingyun†,**

*(College of Information Science and Technology, Donghua University, Shanghai 201620, China)

†(Ningxia Basic Science Research Center of Mathematics, College of Mathematics and Statistics, Ningxia University, Yinchuan 750021, China)

**(Department of Dynamics and Control, Beihang University, Beijing 100191, China)

Abstract Due to the soft characteristics of its own material, the flexible robotic arm is very susceptible to the uncertainty interference in the environment, which leads to unexpected deformation and affects the control accuracy. To address this situation, this paper draws on the cerebellum's regulation of motion and adaptation to the environment in the human body, and builds a cerebellar spiking neural network model for corrective control of the motion behavior of flexible robotic arms under environmental disturbances. Firstly, a multi-degree-of-freedom flexible robotic arm model is built based on the piecewise constant curvature (PCC) method, which has moving joints and rotating joints and can

2024-12-04 收稿, 2025-03-05 录用, 2025-03-09 网络版发表.

1) 国家自然科学基金资助项目(12272092 和 12332004).

2) 通讯作者: 韩芳, 教授, 主要研究方向为神经动力学、智能控制. E-mail: yadiahhan@dhu.edu.cn

引用格式: 张透明, 韩芳, 王青云. 基于小脑脉冲神经网络的柔性机械臂运动控制. 力学学报, 2025, 57(4): 997-1007

Zhang Touming, Han Fang, Wang Qingyun. Motion control of flexible robotic arms based on cerebellar spiking neural network. *Chinese Journal of Theoretical and Applied Mechanics*, 2025, 57(4): 997-1007

realize the motion behaviors of stretching and bending; and the inverse kinematic model of the robotic arm is obtained by using the sequential quadratic programming (SQP) algorithm to approximate the computation, so as to solve the desired joint parameters corresponding to the desired trajectory. Then, drawing on the neural system structure and adaptive function of the cerebellar cortex, the synaptic plasticity rule between the granular cell layer and the Purkinje cell layer is modeled to fully construct the cerebellar spiking neural network model. Finally, this paper investigates the motion effect of the flexible robotic arm to complete the circular trajectory and the “figure-eight” trajectory under the environmental interference, and finds that compared with the direct open-loop control of the motion results without the cerebellar model, the trajectory error of the flexible robotic arm end-effector under the control of the cerebellar spiking neural network has been reduced by 95% and 96%, which demonstrates the effectiveness of the cerebellar spiking neural network model in enhancing the flexible robotic arm's resistance to uncertainty interference. Compared to traditional control methods, this approach is more biologically interpretable and provides a brain-inspired intelligent method for the motion control of flexible robotic arms under uncertainty perturbation.

Key words cerebellum, flexible robotic arm, spiking neural network, adaptability

引言

在工业自动化和智能制造的快速发展背景下,机械臂已被广泛应用于多个领域.在生产制造中,通过机械臂完成焊接、装配和搬运等流程化操作,大幅提升了生产效率和产品质量,推动了工业 4.0 的发展进程.然而,这些机械臂必须以高刚度抵抗外部载荷来保证作业的精度、稳定性和可靠性,这就导致其缺乏灵活性和适应性.针对刚性机械臂的局限性,柔性机械臂因其独特的结构和运动特性,在多个领域展现出显著的应用优势^[1].相较于刚性机械臂,柔性机械臂的结构柔韧性更强、变形能力更大、作业空间更广,且具备良好的人机交互安全性.柔性机械臂采用柔性材料或软材料制作而成,能够实现连续变形,理论上具有无限自由度,并能够轻松通过狭缝等障碍区域,使得其在复杂地形探险、医疗手术操作等应用场景中具有极大的发展潜力^[2].

随着仿生学和材料学的不断发展,各种柔性机械臂的设计不断涌现并被尝试应用于不同场景. Marchese 等^[3]设计了一种自主的柔性机器人,它模仿了鱼类细长的解剖结构,并采用一种新颖的流体驱动系统来驱动身体运动,通过调整开环控制器的参数可以模拟真实鱼类在逃避反应中的运动模式,但是开环控制意味着控制输入是预先设定的,不依赖于实时反馈. Calisti 等^[4]设计了一个硅胶制成的仿章鱼手臂,其独特的机械结构允许它围绕不同大小和形状的物体进行适应性弯曲.但其控制算法相对简单,由两个伺服电机分别控制内部的钢缆和迪尼玛缆线,通过不同的控制序列来执行特定的动作,

包括释放、缩短和附着等,这种简单策略可以使得章鱼型手臂完成一些简单动作,但也容易受到环境干扰而产生控制误差. Mustaza 等^[5]提出一种基于材料模型的非线性动态模型,用于描述连续体机器人的运动,并采用了基于模型的闭环控制策略来实现对机器人的准确控制,但该模型没有考虑机器人与环境的接触和交互可能会影响其运动和变形,从而对控制精度产生影响. Wang 等^[6]提出了一种自适应视觉伺服控制方法来控制柔性机器人的运动,该控制算法能在线估计机器人的有效长度和目标位置,即使在机器人与环境发生未知交互的情况下也能工作.但是,视觉系统容易受到噪声的影响导致图像识别不准确,并且实时处理高分辨率图像对系统的计算性能要求很高.

控制算法是机械臂控制技术的关键,由于柔性机械臂超高冗余、大变形和非线性的特性,现有的大部分柔性机械臂控制算法仍然沿用传统的刚性机械臂算法,或在其基础上根据柔性机械臂特性进行改进.例如, PID (proportional-integral-derivative) 控制具有原理简单、易于使用且适用面广等优点,是现有柔性机械臂应用最广的控制算法之一^[7].随着柔性机械臂应用范围的扩展,为更好地满足机械臂日益增长的精度需求,适应更为复杂的应用环境,研究人员提出了一系列智能控制方法,比如数据驱动控制^[8-9]等.作为数据驱动控制的代表,神经网络控制不仅可以通过拟合系统状态实现无模型控制,也可利用受控系统的在线或离线输入输出数据直接设计系统控制器,或作为优化参数以提升经典控制策略的性能,是柔性机械臂最广泛采用的智能控制策略.

虽然 PID 等经典控制算法已经较为广泛地应用于柔性机械臂控制, 但是智能控制方法拥有更高容错性、非线性处理能力, 更加满足柔性机械臂在非结构化环境中的应用需求。

随着人工智能技术的快速发展, 结合神经科学的研究成果, 类脑智能方法在机械臂控制领域展现出巨大潜力。小脑作为人体重要的运动控制中枢, 在运动控制和感觉处理等方面发挥了重要作用, 拥有特殊的功能特征和生理学特性。它具备快速适应新环境的能力和好的鲁棒性, 可以通过自适应学习协调肢体运动^[10]。Vijayan 等^[11]建立了结合小脑内部原理的计算模型, 并将其应用于自制的 6 自由度的机械臂控制中。Chen 等^[12]设计了一个基于脉冲神经网络的小脑模型, 完成了对气动人工肌肉的控制。柔性机械臂由于自身材料的柔软特性, 极容易受到环境中的随机干扰, 从而影响控制精度。因此, 本文借鉴小脑在运动系统中的独特结构和特点, 模拟小脑神经系统结构及其自适应功能, 建立小脑脉冲神经网络模型, 为柔性机械臂运动提供一种仿生学的控制方案。该控制方案利用小脑的自适应调节能力, 能够降低柔性机械臂由于受到环境干扰而产生的运动误差, 为柔性机械臂的智能控制方法提供新的思路。相较于传统控制器, 小脑控制器基于仿生学原理, 通过分布式存储和联想记忆机制, 能够直接学习和适应非线性动力学行为, 更适合处理高度非线性系统, 对外部环境干扰具有更强的容忍度。柔性机械臂为达到高度灵活性引入了强非线性特性, 小脑控制器弥补了传统控制器在非线性和复杂运动协调等方面的不足, 尤其适合动态、不确定性环境下的机械臂控制。

1 柔性机械臂运动控制问题描述

1.1 柔性机械臂建模

由于柔性机械臂本身十分复杂, 难以直接采用传统的机器人建模理论, 尚未形成统一的建模框架。柔性机械臂的柔性来源包括连杆柔性和关节柔性, 本文主要考虑柔性连杆机械臂。柔性连杆通常被假设为广义欧拉-伯努利梁^[13], 基于该假设, 柔性机械臂的运动学建模方法主要有: 曲率法、伪刚体运动学、结构几何分析和坐标法等等。常曲率法通常被认为是连续体机器人的理想几何特性, 可以有效简化运动学建模。

本文采用分段常曲率 (piecewise constant curvature, PCC) 方法建立柔性机械臂模型^[14]。如图 1 所示, 假设柔性机械臂分为 m ($m = 3$) 段, 每段由 n ($n = 2$) 个连杆组成。在该模型中, 连杆通过两组关节相互连接: 模拟机械臂弯曲的旋转关节和模拟机械臂伸缩的移动关节。假设每个部分的旋转关节和移动关节均匀运动, 每个分段长度的总体变化是每个移动关节的变形量乘以连杆的数量, 曲率也同理可得。所以, 该多段柔性机械臂的正运动学方程可表示为

$$\begin{bmatrix} X_{E_i} \\ Y_{E_i} \\ Z_{E_i} \end{bmatrix} = \begin{bmatrix} X_{E_{i-1}} \\ Y_{E_{i-1}} \\ Z_{E_{i-1}} \end{bmatrix} + \frac{L_i + \Delta L_i}{n} \cdot \mathbf{R}_z(\phi_{i-1}) \cdot \mathbf{R}_y(\phi_{i-1}) \cdot \begin{bmatrix} \cos \phi_i \sum_{j=1}^n \sin \left(\frac{2j-1}{2n} \theta_i \right) \\ \sin \phi_i \sum_{j=1}^n \sin \left(\frac{2j-1}{2n} \theta_i \right) \\ \sum_{j=1}^n \cos \left(\frac{2j-1}{2n} \theta_i \right) \end{bmatrix} \quad (1)$$

式中, X_{E_i} , Y_{E_i} 和 Z_{E_i} 表示第 i 段执行器末端的空间坐标, L_i 表示第 i 段的初始长度, ΔL_i 表示第 i 段长度的变化量, θ_i 表示第 i 段的弯曲角度, ϕ_i 表示 x 轴的偏转角, $\mathbf{R}_y$ 和 $\mathbf{R}_z$ 分别表示绕 y 轴和 z 轴的旋转矩阵。




图 1 基于分段常曲率方法构建柔性机械臂模型

Fig. 1 Construction of a flexible robotic arm model based on the piecewise constant curvature method

1.2 机械臂逆运动学求解

根据 1.1 节的描述, 我们采用分段常曲率方法建立一个多段柔性连杆机械臂模型, 如图 2 所示。该柔性机械臂分为 3 段, 每段由 5 节连杆组成, 并且每段的初始长度为 L 。机械臂的基座位置设置在原点, 坐标为 $(0, 0, 0)$ 。

虽然用小刚性连杆代替曲率降低了运动学方程的复杂性, 但是多段机械臂的变量数量超过了运动学方程的数量, 因此无法求得该机械臂逆运动学的解析解。本文采用顺序二次规划算法 (sequential




图2 柔性机械臂仿真模型

Fig. 2 Flexible robotic arm simulation model

quadratic programming, SQP)^[15] 求解机械臂期望轨迹对应的期望关节参数. SQP 算法无法找到全局最优解, 所以初始条件和约束条件是寻找最优解的关键参数. 初始条件设置为前一姿态下的构型变量, 以获得更平滑的轨迹解, 约束条件限制机械臂的长度和弯曲度在合理的可控范围内.

本文规划柔性机械臂末端期望轨迹为笛卡尔空间中的圆形和“8”字形, 圆形轨迹代表了机械臂的简单运动行为, “8”字形轨迹代表机械臂更复杂的运动行为^[16]. 每条轨迹的采样点数量 $n = 100$, 对应的运行周期为 10 s, 即机械臂末端完整执行一次圆形轨迹或“8”字形轨迹所需要的时间. 小脑控制器的学习与调节过程需要执行多个运行周期, 直到最终趋于稳定状态. 空间中圆形轨迹满足

$$\left. \begin{aligned} x &= R \cdot \cos \varphi, \\ y &= R \cdot \sin \varphi, \\ z &= \alpha, \\ \varphi &\in [0, 2\pi] \end{aligned} \right\} \quad (2)$$

式中, R 表示圆形轨迹的半径, α 代表常量, 表示 z 方向的坐标恒定不变.

空间中 8 字形轨迹满足

$$\left. \begin{aligned} x &= x_0 + A \cdot \sin(2\varphi), \\ y &= y_0 + B \cdot \cos \varphi, \\ z &= z_0 \pm C \cdot |\cos \varphi|, \\ \varphi &\in \left(\frac{\pi}{2}, \frac{5\pi}{2} \right) \end{aligned} \right\} \quad (3)$$

式中, x_0 , y_0 和 z_0 分别表示 x 坐标、 y 坐标和 z 坐标的初始偏移量; A , B 和 C 分别表示坐标点沿 x 方向、 y 方向和 z 方向的变化幅度.

根据式 (2) 圆形期望轨迹和式 (3) “8”字形期望轨迹, 采用优化算法计算得到相应的关节构型变量, 分别如图 3 和图 4 所示. 这里, 机械臂每一段的编号用 i ($i = 1, 2, 3$) 表示, ΔL_i 表示长度形变量, θ_i 表示连杆弯曲度, ϕ_i 表示 x 轴方向的偏转角.

图 3 和图 4 中, ΔL_i , θ_i 和 ϕ_i 是根据圆形或“8”字




图3 圆形轨迹的期望关节构型变量

Fig. 3 Desired joint configuration variables for circular trajectory




图4 “8”字形轨迹的期望关节构型变量

Fig. 4 Desired joint configuration variables for "figure-8" trajectory

形期望轨迹求得的期望关节构型变量, ΔL_1 , ΔL_2 和 ΔL_3 表示机械臂各个分段的形变量, θ_1 , θ_2 和 θ_3 表示机械臂各个分段的连杆弯曲度, ϕ_1 , ϕ_2 和 ϕ_3 表示机械臂各个分段在 x 轴方向的偏转角. 不同的颜色代表机械臂的不同分段, 不同线型代表不同的关节变量.

通常情况下, 柔性机械臂的控制问题就是找到合适的输入序列, 通过压力、流体体积、电压和温度等参数使得柔性机械臂达到期望的状态. 可以通过反复实验或者通过求解数学模型得到所有需要的控制量以及控制命令, 然后将预定程序烧录到控制器中严格执行, 但这种控制并不关注柔性机械臂的最终执行情况, 在非结构化环境中由于扰动存在容易使得柔性机械臂不能按照预期轨迹运动. 因此, 本文建立小脑脉冲神经网络模型来实现对柔性机械臂的运动调控, 降低由于环境干扰引起的运行轨迹误差. 由于柔性机械臂建模方式的不同, 可能导致它的构型空间参数表征不同, 本文中小脑脉冲神经网络控制器的设计适配基于分段常曲率方法建立的柔性机械臂模型. 对于其他类型的柔性机械臂模型, 需要根据实际的建模方式, 确定构型空间的参数表征和驱动量, 重构小脑控制器的输入层特征变量和输出层控制量, 以达到类似的调控效果.

2 小脑脉冲神经网络建模

2.1 小脑脉冲神经网络的拓扑结构

小脑在脊椎动物的神经系统中扮演着至关重要的角色, 它主要负责调控身体的平衡感和协调性运动. 作为人体的重要运动控制中枢, 小脑拥有特殊的功能特征和生理学特性. 小脑能够控制身体的无意识运动, 根据 Marr 等^[17]在《A theory of cerebellar cortex》中提出的假说, 小脑皮质被认为是一种监督学习机器. 此理论强调小脑的学习与适应能力, 归因于平行纤维与浦肯野细胞之间的突触可塑性.

小脑皮质可以分为 3 层, 如图 5 所示, 最外面一层是分子层, 中间一层是浦肯野细胞层, 最里面一层是颗粒层^[18]. 苔藓纤维 (MFs) 是小脑皮质的主要输入之一, 可以携带来自前庭系统或者网状结构的信息, 然后通过兴奋性突触传递到颗粒细胞^[19]. 位于颗粒层的颗粒细胞 (GCs) 是数量最多的细胞, 对苔藓纤维传递的信息稀疏编码, 然后通过延伸穿过分子层的长平行纤维 (PFs) 接触浦肯野细胞. 浦肯野细

胞 (PCs) 位于浦肯野层, 它的树突与平行纤维建立兴奋性突触连接, 轴突与小脑核细胞建立抑制性突触, 并且这条通道是小脑皮质的唯一输出. 小脑皮质的另一种输入纤维是攀爬纤维 (CFs), 它们通常被认为主要起源于下橄榄核, 为小脑学习提供反馈信息, 每个浦肯野细胞以 1:1 的方式接收一个单独的攀爬纤维. 小脑深部核 (DCNs) 是位于小脑核心部位白质内部的灰质, 它的输入信号主要来源有苔藓纤维和浦肯野细胞, 输出信号用于最终的运动调控.

参考小脑皮质中神经元的连接方式, 建立图 6 所示的小脑脉冲神经网络. 小脑脉冲神经网络由 5 个神经层组成^[20]: 苔藓纤维、颗粒细胞、浦肯野细胞、攀爬纤维和小脑深部核.

MFs 模拟传播感觉运动信息的苔藓纤维, 不同的位置状态刺激不同的苔藓纤维放电^[21]. GCs 模拟颗粒细胞层, 每个 GC 接收来自不同 MFs 组的两个输入突触, 该层作为状态发生器, 将每个 GC 从外部来源接收的感觉运动神经信息转化为非重叠的神经活动时空模式, 随后 PC 充当读出层. CFs 模拟传递误差信号的攀爬纤维, 它们被分为两组, 分别用于传播正指导信号和负指导信号. PCs 模拟浦肯野细胞, 也被分为两组, 分别代表正方向运动和逆方向运动.




图 5 小脑皮质神经元连接结构

Fig. 5 Neuronal connectivity structure of the cerebellar cortex




图 6 小脑脉冲神经网络拓扑结构

Fig. 6 Cerebellar spiking neural network

每个 PC 都连接到所有的 PFs, 因此可以接收所有的感觉运动信息. CFs 和 PCs 是一对一连接的, 所以 PCs 通过其相应的 CFs 接收不同的指导信号. 将这两种不同来源的神经信息联系起来, 可以使 PC 输出合适的运动控制调节信号. DCNs 模拟深部小脑核细胞^[22], 被分为两组, 分别输出正向控制信号和逆向控制信号. 每个 DCN 接收对应的 PC 抑制性输入, 也接收来自所有 MFs 的兴奋性投射, 这部分信号维持了 DCN 的基准活动. 该小脑脉冲神经网络详细的网络拓扑结构参数如表 1 所示.

表 1 小脑脉冲神经网络拓扑结构参数

Table 1 Cerebellar pulse neural network topological structure parameters

Neurons		Synapses			
pre-synaptic	post-synaptic	number	type	initial weight	weight range
100MFs	2500GCs	5000	AMPA	2.5	
100MFs	6DCNs	600	AMPA	2.5	
2500GCs	6PCs	15000	AMPA	5.0	[1, 5]
6PCs	6DCNs	6	GABA	4.0	
6CFs	6PCs	6	AMPA	0.0	

表 1 详细记录了小脑脉冲神经网络中神经元数量、突触类型、突触数量和突触初始权重等重要信息. 例如, GCs 与 PCs 之间存在兴奋性突触, GCs 为突触前神经元, 数量为 2500, PCs 为突触后神经元, 数量为 6, 它们之间的连接方式为全连接, 共有 15000 个突触. 初始权重设置为 5.0, 权重变化范围在 1 ~ 5 之间.

2.2 神经元和突触可塑性模型

本文采用 LIF (leaky integrate and fire) 神经元模型来构建脉冲神经网络. LIF 模型是一种常见的脉冲神经元模型, 它容易建模和计算, 在数据分析与处理过程中相对简单, 长期以来被大量应用于神经计算领域^[23]. LIF 神经元模型的微分方程表示如下

$$\tau_m \frac{dV}{dt} = -(V - V_{\text{rest}}) + R_m I \quad (4)$$

式中, V 表示膜电压, I 表示输入电流, V_{rest} 表示重置电位. 膜时间常量 $\tau_m = 20 \text{ ms}$, 膜电阻 $R_m = 10 \Omega$. 如果膜电压在输入电流的刺激下达到阈值电位, 神经元释放脉冲, 膜电位复位, 并在不应期内保持恒定.

突触可塑性是生物神经网络进行学习和记忆的基础, 小脑功能的完成也主要依赖于其内部的多种突触可塑性. 突触可塑性可以分为长时程增强 (long-term potentiation, LTP) 和长时程抑制 (long-term depression, LTD) 两部分, LTP 指的是神经元之间重复或者强烈的刺激导致突触传递效率的长期增加, 而 LTD 是一种与长时程增强相反的机制, 会导致突触传递效率长期降低.

小脑网络中的突触可塑性主要位于平行纤维-浦肯野细胞 (PF-PC), 该突触的 STDP (spike-timing-dependent plasticity) 机制包含了长时程增强和长时程抑制两部分^[24], 如下所示, 每次脉冲通过 PF 到达目标 PC 时突触会增强, 每次尖峰通过 CF 到达目标 PC 时突触会减弱, 突触减少的量取决于在 CF 脉冲到达之前通过 PF 到达的神经活动

$$\text{LTP: } \Delta w_{\text{PF}_i\text{-PC}_j}(t) = \alpha \cdot \delta_{\text{PFspike}}(t) \cdot dt \quad (5)$$

$$\text{LTD: } \Delta w_{\text{PF}_i\text{-PC}_j}(t) = \beta \cdot \int_{-\infty}^{t_{\text{CFspike}}} k(t - t_{\text{CFspike}}) \cdot \delta_{\text{PFspike}}(t) dt \quad (6)$$

式中, $\Delta w_{\text{PF}_i\text{-PC}_j}$ 表示编号为 i 的 PF 和编号为 j 的 PC 之间突触权值的变化, $\alpha = 0.0001$ 为突触效能增加的强度, δ_{PFspike} 是对应于来自 PF 的传入脉冲的狄拉克函数, $\beta = -0.01$ 为突触效能衰减的强度. 核函数 $k(x)$ 定义为

$$k(x) = \begin{cases} \frac{-(x + d_k)}{\tau_{\text{LTD}} - d_k} \cdot e^{\frac{x + d_k}{\tau_{\text{LTD}} - d_k} + 1}, & \text{if } x < -d_k \\ 0, & \text{if } x \geq -d_k \end{cases} \quad (7)$$

式中, $\tau_{\text{LTD}} = 100 \text{ ms}$ 是与生物感觉运动路径延迟一致的时间常数, 即从感觉信息接收到信号沿神经纤维传输、神经处理时间响应和最终运动输出响应所经历的时间. 改变 $d_k = 70 \text{ ms}$ 的大小可以调整核函数的宽度, 当 $x = -\tau_{\text{LTD}}$ 时函数取得最大值, 当 $x > -d_k$ 或者 $x < -\tau_{\text{LTD}} - 10(\tau_{\text{LTD}} - d_k)$ 时函数趋近于 0.

这种 STDP 机制将 PF 向 PC 传递的神经活动模式与 CF 向 PC 提供的指导信号联系起来. 这种联系在 PC 层面上形成了特定的 PF 活动模式, 编码了特定的感觉运动信息, 当 PF 和 CF 的活动相关时, STDP 机制通过减少 PF-PC 突触的权重来降低 PC 的输出活动, 进而减少了对目标 DCN 的抑制作用. 相反, 当 PF 和 CF 的活动不相关时, STDP 机制通过增加 PF-PC 突触的权重来增强 PC 的输出活性,

进而增加了对目标 DCN 的抑制作用. 由于 DCN 通常受到较为恒定的苔藓纤维激活的驱动, PC 抑制作用的减少会导致 DCN 活性的增加, 而抑制作用的增加则会导致 DCN 活性的减少. 在学习过程中, 通过适时调整 DCN 的激活水平, 影响小脑的调控信号从而减小总体误差.

3 小脑脉冲神经网络控制下的柔性机械臂运动效果和神经网络动力学分析

3.1 整体控制框架

小脑脉冲神经网络与柔性机械臂集成的控制回路如图 7 所示, 代表运动皮层和其他运动区域的轨迹生成器模块提供期望运动信号, 它首先通过轨迹规划得到柔性机械臂末端的期望运行轨迹, 然后再通过近似逆运动学计算得到关节构型变量的期望值, 并通过位姿空间到关节空间的映射转换得到相应的驱动参数^[25]. 直接开环控制则没有小脑脉冲神经网络的参与, 将求得的驱动参数直接作用于柔性机械臂. 图 7 中, q 表示关节控制信号.

由于柔性机械臂自身材料的柔软特性, 它很容易受到环境中的不确定性干扰, 从而发生连杆变形, 利用小脑的运动适应能力, 可以补偿由于环境扰动导致的机械臂形变. 在本文的实验中, 设置随机扰动为均匀噪声, 如 $\text{noise} = a \cdot [\text{rand}() - 0.5]$, 其中 rand 函数用来生成在 $0 \sim 1$ 之间均匀分布的随机数, $a = 0.2$ 用来调整噪声的幅度, 该均匀噪声的范围为 $(-0.1, 0.1)$. 此外, 通过设置不同的噪声幅度来探究扰动强度的变化对小脑控制器的影响. q 表示根据近似逆运动学计算得到的关节控制信号, 在扰动的作用下, 则实际控制信号 $q' = q + \text{noise}$. MF 构成小脑的输入层, 能够编码不同的空间状态信息, 产生不同的放电模式, 这

些神经信号再传递到 GC 和 DCN. GC 在稀疏的体感神经活动中处理并重新编码这些感觉运动信息, 这些信息随后由平行纤维传递给 PC. 来自下橄榄的 CF 的神经活动代表了实际轨迹与期望轨迹的不匹配, 作为小脑调节的指导信号. 由于 GC 和 PC 之间具有突触可塑性, 它们之间的突触权重分布在 PF 和 CF 的共同作用下进行自适应调节. DCN 同时接收 MF 的兴奋性刺激和 PC 的抑制性刺激, 产生的神经活动代表小脑输出的调节信号, 用来纠正机械臂形变. 因此, 小脑的输入-输出响应在指导信号的作用下不断调整, 在后续的运动过程中, 柔性机械臂末端轨迹的误差逐渐最小化.

DCN 的脉冲信号需要通过解码计算才能得到相应的输出调节信号, 记时间步长为 Δt , 输出信号的计算公式如下^[24]

$$\left. \begin{aligned} DCN_{j,i}(t) &= \int_{t-\Delta t}^t \delta_{DCN_{j,i}}(t) dt \\ DCN_j(t) &= \sum_{i=1}^{i=N/2} DCN_{j,i}(t) - \sum_{i=N/2+1}^{i=N} DCN_{j,i}(t) \\ out_j &= \beta \cdot \sum_{x=1}^M DCN_j(t)[t - (x-1) \cdot \Delta t] \end{aligned} \right\} \quad (8)$$

式中, j 表示 DCN 中的分组序号, 它们的输出分别对应各个被控量, i 表示同组内的单个神经元编号, N 表示每组 DCN 的数量, M 表示平均滤波的窗口大小, β 表示最终输出的调节因子.

3.2 机械臂运行轨迹误差

机械臂末端运行轨迹误差由 n 个采样点的位置误差组成, 定义某点的位置误差为期望坐标与实际坐标之间的欧几里得距离^[26]. 假设期望位置的坐标为 $P_0(x_0, y_0, z_0)$, 实际位置的坐标为 $P_1(x_1, y_1, z_1)$, 则该采样点的位置误差计算如下

$$e = \sqrt{(x_0 - x_1)^2 + (y_0 - y_1)^2 + (z_0 - z_1)^2} \quad (9)$$

在单次执行圆形轨迹或者“8”字形轨迹时, 对 n 个采样点的位置误差求平均得到的结果用来衡量机械臂末端执行轨迹跟踪任务的准确程度.

假设期望轨迹是由式 (6) 描述的空间中的一个圆形, 如图 8 所示. 经过近似逆运动学求解得到期望的构型变量如图 3 所示, 直接开环控制的机械臂末端轨迹误差和基于小脑脉冲神经网络控制的机械臂末端轨迹误差如图 9 所示. 此外, 扰动强度的变化对




图 7 基于小脑脉冲神经网络模型的柔性机械臂控制回路

Fig. 7 Flexible robotic arm control loop based on the cerebellar spiking neural network model

小脑控制器的影响如图 10 所示。

图 9 中, 红色和蓝色线条分别代表有无小脑脉冲神经网络控制时的轨迹误差。横坐标表示时间, 纵坐标表示机械臂末端执行器在某个时间点的位置误差。无小脑脉冲神经网络参与调控的机械臂末端轨迹误差平均值为 1.344 mm, 有小脑脉冲神经网络参与调控的机械臂末端轨迹误差平均值为 0.071 mm (小脑学习保持稳定的最后一个运行周期)。

图 10 中, 横坐标表示不同的扰动强度, 蓝色线




图 8 三维空间中的期望圆形轨迹

Fig. 8 Desired circular trajectory in three-dimensional space




图 9 机械臂末端轨迹误差曲线

Fig. 9 End-effector trajectory error curve of the robotic arm




图 10 扰动强度的变化对小脑控制器的影响

Fig. 10 The impact of variations in disturbance intensity on the cerebellar controller

条表示轨迹平均误差, 橙色线条表示轨迹平均误差小于 0.1 需要经历的运行周期。在一定范围内, 随着扰动强度的增加, 小脑控制器对柔性机械臂进行纠正控制的调节时间变长, 但最终的控制精度几乎不受影响。

假设期望轨迹如式 (7) 所描述, 它是空间中的一个“8”字形, 如图 11 所示。经过近似逆运动学求解得到期望的构型变量如图 4 所示, 直接开环控制的机械臂末端轨迹误差和基于小脑脉冲神经网络控制的机械臂末端轨迹误差如图 12 所示。此外, 扰动强度的变化对小脑控制器的影响如图 13 所示。

图 12 中, 红色和蓝色线条分别代表有无小脑脉冲神经网络控制时的轨迹误差。横坐标表示时间, 纵坐标表示机械臂末端执行器在某个时间点的位置误差。无小脑脉冲神经网络参与调控的机械臂末端轨迹误差平均值为 1.311 mm, 有小脑脉冲神经网络参与调控的机械臂末端轨迹误差平均值为 0.058 mm (小脑学习保持稳定的最后一个运行周期)。




图 11 三维空间中的期望“8”字形轨迹

Fig. 11 Desired "figure-8" trajectory in three-dimensional space




图 12 机械臂末端轨迹误差曲线

Fig. 12 End-effector trajectory error curve of the robotic arm




图 13 扰动强度的变化对小脑控制器的影响

Fig. 13 The impact of variations in disturbance intensity on the cerebellar controller

图 13 中, 横坐标表示不同的扰动强度, 蓝色线条表示轨迹平均误差, 橙色线条表示轨迹平均误差小于 0.1 需要经历的运行周期. 在一定范围内, 随着扰动强度的增加, 小脑控制器对柔性机械臂进行纠正控制的调节时间变长, 但最终的控制精度几乎不受影响.

3.3 小脑脉冲神经网络动力学分析

小脑脉冲神经网络模型不仅具备小脑的功能特性, 还具有小脑的生理学特性. 下面以本文中柔性机械臂“8”字形运行轨迹的实验结果对小脑脉冲神经网络的动力学行为进行分析. 小脑脉冲神经网络涉及多种神经元, 它们具备不同的脉冲特性^[27]. 在模型训练过程中, 各种类型神经元产生的放电行为如图 14 所示.

图 14 中, 图 14(a) 是 MFs 的放电图, 对应于机




图 14 各种类型神经元的放电情况

Fig. 14 Firing patterns of different types of neurons

械臂不同的位置信息, MFs 产生随机的放电行为, 每种模式对应不同的状态感知信息; 图 14(b) 是 GCs 的放电图, 颗粒细胞通过稀疏编码空间状态信息, 在同一时刻只有少数神经元产生放电行为^[28]; 图 14(c) 是浦肯野细胞的放电图, 它们通过 PFs 读取颗粒细胞的状态信息, 在特定的状态下产生对应的输出; 图 14(d) 是 DCNs 的放电图, 这些细胞综合苔藓纤维与浦肯野细胞的信息产生输出, 它们的放电模式编码了输出控制信号.

小脑的自我学习过程主要是在调节 GCs 与 PCs 之间的突触权重. 用 W 表示 GCs 和 PCs 之间的权重矩阵, 信息熵^[29] 计算公式如下

$$H = - \sum_{i=1}^a \sum_{j=1}^b P_{ij} \lg P_{ij} \quad (10)$$

其中, P_{ij} 是矩阵 W 归一化后的元素, 表示位置 (i, j) 的概率. 采用熵值可以衡量 GCs 和 PCs 之间的权重分布特性, 如果权重分布比较平均, 那么突触熵就比较小, 如果权重分布比较混乱, 那么突触熵值就比较大. 在小脑参与调节的训练过程中, GCs 和 PCs 之间的突触熵值变化情况如图 15 所示.




图 15 GCs 和 PCs 之间的突触熵值变化情况

Fig. 15 Synaptic entropy variation between GCs and PCs

由图 15 可见, 在小脑模型学习的初始阶段, 由于 GCs 和 PCs 之间的突触权重被均匀初始化, GCs 和 PCs 之间的突触熵值趋近于 0, 随着学习的进行, 小脑网络针对不同的感知信号产生特定的输出信息, GCs 和 PCs 之间的突触分布呈现特殊化, 不同的突触逐渐适应特定的突触权重, 所以 GCs 和 PCs 之间的突触熵值逐渐增大, 直到小脑学习趋于稳定状态.

4 结论

由于柔性机械臂自身材料的固有特性, 它极容

易受到外界干扰,在非结构化环境中作业时,很容易由于变形而导致控制精度降低.借鉴小脑在运动协调方面的特性和功能,本文搭建了一个小脑脉冲神经网络模型,利用该模型实现了对多自由度柔性机械臂的运动控制,可以显著降低环境中随机干扰带来的运动误差.在本文的仿真实验中,基于小脑脉冲神经网络模型控制多自由度柔性机械臂完成了圆形轨迹和“8”字形轨迹的运动,它们的轨迹误差平均值分别为 0.071 和 0.058 mm,相较于无小脑模型调控的机械臂末端轨迹误差,分别下降了 95% 和 96%,实验结果验证了该控制方法的有效性.通过分析小脑模型的神经动力学行为,从微观角度展示了小脑在运动调控中的独特机制.本文采用的控制方法不仅能有效应对非结构化环境中的不确定性干扰,还具备一定的生物可解释性,对实现柔性机械臂的类脑智能控制具有重要启发意义.

柔性机械臂是机器人领域的新兴研究方向,虽然目前已经有一些经典控制方法和基于数据驱动的智能控制方法应用于柔性机械臂^[30],但是类脑控制方法在柔性机械臂领域具有更广阔的应用前景,它们模拟真实的生物神经环路,借鉴生物体复杂的控制机制,提升机械臂在非结构化环境中的适应性和控制精度.本文基于小脑脉冲神经网络模型调控柔性机械臂的运动行为,显著降低了轨迹误差.但是,类脑控制方法还有待进一步探索,比如开发多脑区协同的类脑控制系统以实现柔性机械臂的自主决策和路径规划等运动功能.类脑控制方法也有望与现有的智能控制方法(如强化学习等)相结合^[31],进而取得性能上的拓展和提升.随着人工智能和神经科学的发展,类脑控制方法在柔性机械臂的运动控制领域具有极大的发展潜力,有望实现更高层次的智能化和自主化,为柔性机械臂的未来发展开辟新的道路.

参 考 文 献

- Monje Micharet CA, Laschi C. Editorial: Advances in modeling and control of soft robots. *Frontiers in Robotics and AI*, 2021, 8: 706514
- 王海涛, 彭熙凤, 林本末. 软体机器人研究进展. 华南理工大学学报(自然科学版), 2020, 48(2): 94-106 (Wang Haitao, Peng Xifeng, Lin Benmo. Research progress on soft robotics. *South China University of Technology (Natural Science Edition)*, 2020, 48(2): 94-106 (in Chinese))
- Marchese AD, Onal CD, Rus D. Autonomous soft robotic fish capable of escape maneuvers using fluidic elastomer actuators. *Soft Robotics*, 2014, 1(1): 75-87
- Calisti M, Giorelli M, Levy G, et al. An octopus-bioinspired solution to movement and manipulation for soft robots. *Bioinspiration & Biomimetics*, 2011, 6(3): 036002
- Mustaza SM, Elsayed Y, Lekakou C, et al. Dynamic modeling of fiber-reinforced soft manipulator: A visco-hyperelastic material-based continuum mechanics approach. *Soft Robotics*, 2019, 6(3): 305-317
- Wang HS, Yang BH, Liu YT, et al. Visual servoing of soft robot manipulator in constrained environments with an adaptive controller. *IEEE/ASME Transactions on Mechatronics*, 2017, 22(1): 41-50
- Lindenroth L, Stoyanov D, Rhode K, et al. Toward intrinsic force sensing and control in parallel soft robots. *IEEE/ASME Transactions on Mechatronics*, 2023, 28(1): 80-91
- Piqué F, Kalidindi HT, Fruzzetti L, et al. Controlling soft robotic arms using continual learning. *IEEE Robotics and Automation Letters*, 2022, 7(2): 5469-5476
- Robinson RM, Kothera CS, Sanner RM, et al. Nonlinear control of robotic manipulators driven by pneumatic artificial muscles. *IEEE/ASME Transactions on Mechatronics*, 2016, 21(1): 55-68
- Kawato M, Ohmae S, Hoang H, et al. 50 years since the Marr, Ito, and Albus models of the cerebellum. *Neuroscience*, 2021, 462: 151-174
- Vijayan A, Diwakar S. A cerebellum inspired spiking neural network as a multi-model for pattern classification and robotic trajectory prediction. *Frontiers in Neuroscience*, 2022, 16: 909146
- Chen XY, Zhu WX, Liang WY, et al. Control of antagonistic mcKibben muscles via a bio-inspired approach. *Journal of Bionic Engineering*, 2022, 19(6): 1771-1789
- Zhang Y, Huang PY, You B, et al. Design and motion simulation of a soft robot for crawling in pipes. *Applied Bionics and Biomechanics*, 2023, 2023: 1-8
- Keyvanara M, Goshtasbi A, Kuling IA. A geometric approach towards inverse kinematics of soft extensible pneumatic actuators intended for trajectory tracking. *Sensors*, 2023, 23(15): 6882
- 朱永辉, 张胜文, 支辰羽等. 基于 SQP 算法的厢舱类产品快速设计技术研究. 机械设计, 2024, 41(S1): 64-69 (Zhu Yonghui, Zhang Shengwen, Zhi Chenyu, et al. Research on rapid design technology of cabin products based on SQP algorithm. *Journal of Mechanical Design*, 2024, 41(S1): 64-69 (in Chinese))
- Zahra O, Tolu S, Tolu S, et al. A bio-inspired mechanism for learning robot motion from mirrored human demonstrations. *Frontiers in Neurobotics*, 2022, 16: 826410
- Marr D, Thach WT. From the Retina to the Neocortex: Selected Papers of David Marr. Boston, MA: Birkhäuser Boston, 1991: 11-50
- 刘印. 基于监督学习的小脑脉冲神经网络模型. [硕士学位论文]. 大连: 大连理工大学, 2021 (Liu Yin. A cerebellar spiking neural network model based on supervised learning. [Master Thesis]. Dalian: Dalian University of Technology, 2021 (in Chinese))
- Thanawalla AR, Chen AI, Azim E. The cerebellar nuclei and dexter-

- ous limb movements. *Neuroscience*, 2020, 450: 168-183
- 20 Antonietti A, Martina D, Casellato C, et al. Control of a humanoid NAO robot by an adaptive bioinspired cerebellar module in 3D motion tasks. *Computational Intelligence and Neuroscience*, 2019, 2019(1): 4862157
- 21 Pimentel JM, Moioli RC, De Araujo MFP, et al. An integrated neurobotics model of the cerebellar-basal ganglia circuitry. *International Journal of Neural Systems*, 2023, 33(11): 2350059
- 22 Takahashi M, Shinoda Y. Neural circuits of inputs and outputs of the cerebellar cortex and nuclei. *Neuroscience*, 2021, 462: 70-88
- 23 Yamazaki K, Vo-Ho VK, Bulsara D, et al. Spiking neural networks and their applications: a review. *Brain Sciences*, 2022, 12(7): 863
- 24 Abadía I, Naveros F, Garrido JA, et al. On robot compliance: a cerebellar control approach. *IEEE Transactions on Cybernetics*, 2021, 51(5): 2476-2489
- 25 郝新宇, 王江, 邓斌等. 可用于机械臂控制的小脑脉冲神经网络研究与 FPGA 实现. 控制与决策, 2023, 38(3): 631-644 (Hao Xinyu, Wang Jiang, Deng Bin, et al. Research and FPGA implementation of cerebellar spiking neural network for robot arm control. *Journal of Control and Decision*, 2023, 38(3): 631-644 (in Chinese))
- 26 Buel A, Abadia I, Collin T, et al. The spinal cord facilitates cerebellar upper limb motor learning and control; inputs from neuromusculoskeletal simulation. *PLOS Computational Biology*, 2024, 20(1): e1011008
- 27 Liu Y, Liu R, Wang JX, et al. A cerebellum-inspired spiking neural model with adapting rate neurons. *IEEE Transactions on Cognitive and Developmental Systems*, 2023, 15(3): 1628-1638
- 28 Xie M, Muscinelli SP, Decker Harris K, et al. Task-dependent optimal representations for cerebellar learning. *Elife*, 2023, 12: e82914
- 29 Sparavigna AC. Entropy in image analysis. *Entropy*, 2019, 21(5): 502
- 30 方五益, 郭晔, 黎亮等. 柔性铰柔性杆机器人动力学建模、仿真和控制. 力学学报, 2020, 52(4): 965-974 (Fang Wuyi, Guo Xian, Li Liang, et al. Dynamics modeling, simulation, and control of robots with flexible joints and flexible links. *Chinese Journal of Theoretical and Applied Mechanics*, 2020, 52(4): 965-974 (in Chinese))
- 31 任峰, 都军民, 李广华. 降低圆柱升力脉动的智能自适应旋转控制. 力学学报, 2024, 56(4): 972-979 (Ren Feng, Du Junmin, Li Guanghua. Intelligent self-adaptive control for mitigating lift fluctuations of a circular cylinder. *Chinese Journal of Theoretical and Applied Mechanics*, 2024, 56(4): 972-979 (in Chinese))