

控制与决策

Control and Decision

可用于机械臂控制的小脑脉冲神经网络研究与FPGA实现

郝新宇, 王江, 邓斌, 于海涛, 伊国胜

引用本文:

郝新宇, 王江, 邓斌, 于海涛, 伊国胜. 可用于机械臂控制的小脑脉冲神经网络研究与FPGA实现[J]. *控制与决策*, 2023, 38(3): 631–644.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1311>

您可能感兴趣的其他文章

Articles you may be interested in

[基于层次化可塑性回声状态网络的混沌时间序列预测](#)

Hierarchical plasticity echo state network for chaotic time series prediction

控制与决策. 2023, 38(1): 133–142 <https://doi.org/10.13195/j.kzyjc.2021.0773>

[一种触觉感知与脑启发的触觉传感系统](#)

A tactile perception and brain-inspired tactile sensing system

控制与决策. 2023, 38(1): 228–238 <https://doi.org/10.13195/j.kzyjc.2021.0842>

[基于时间延时估计和自适应模糊滑模控制器的双机械臂协同阻抗控制](#)

Coordinated impedance control for dual-arm robots based on time delay estimation and adaptive fuzzy sliding mode controller

控制与决策. 2021, 36(6): 1311–1323 <https://doi.org/10.13195/j.kzyjc.2019.1701>

[基于深度学习的仿生集群运动智能控制](#)

Intelligent control of bionic collective motion based on deep learning

控制与决策. 2021, 36(9): 2195–2202 <https://doi.org/10.13195/j.kzyjc.2020.0071>

[区分交通流模式的混合服务路口信号控制策略](#)

Signal control strategies of mixed service intersections to discriminate traffic flow patterns

控制与决策. 2021, 36(6): 1509–1515 <https://doi.org/10.13195/j.kzyjc.2019.1520>

可用于机械臂控制的小脑脉冲神经元网络研究与FPGA实现

郝新宇, 王江, 邓斌, 于海涛, 伊国胜[†]

(天津大学 电气自动化与信息工程学院, 天津 300072)

摘要: 小脑对运动的调控和对环境的适应性是人体完成快速精准运动的关键, 模拟并研究小脑的运行机制将为控制复杂多变的机器人模型提供更有效的方法. 鉴于此, 遵循神经元数量的真实生物比率, 构建大规模小脑脉冲神经网络模型, 模拟大脑中小脑的真实结构、信息传递方式和学习机制, 实现对机械臂的误差纠正控制, 同时依据系统在不同控制任务下的控制结果, 得到不同突触可塑性对小脑网络控制效果的影响规律. 为了进一步增加小脑控制系统的生物真实性, 以更贴近人脑的并行运算方式在现场可编程门阵列(field programmable gate array, FPGA)平台上实现所构建的模型, 并进行相应的资源优化, 增加可实现的网络规模. FPGA实现结果显示, 系统能够成功完成基于小脑误差纠正功能的自适应类脑机械臂控制, 可以验证小脑的真实细胞动力学和大规模颗粒层提供的高容错性, 并提供兼顾小脑应用功能实现和理论研究的平台.

关键词: 小脑; 脉冲神经网络; 现场可编程门阵列; 突触可塑性; 类脑控制

中图分类号: TP183

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1311

引用格式: 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[J]. 控制与决策, 2023, 38(3): 631-644.

Research on cerebellar SNN model and FPGA implementation for robotic arm control

HAO Xin-yu, WANG Jiang, DENG Bin, YU Hai-tao, YI Guo-sheng[†]

(School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China)

Abstract: The movement control of the cerebellum and its adaptability to the environment are the keys to complete rapid and precise movement for humans. Simulating and studying the operating mechanism of the cerebellum will provide a better way to control complex and changeable robot models. Therefore, by following the real biological ratio of different types of cerebellar neurons, a large-scale spiking neural network model of the cerebellum is built and the realistic structure, information transmission method, and learning mechanism of the cerebellum are simulated. We also complete the error correction control of a simulated robotic arm, and clarify the influence of different synaptic plasticities on the control effect of the cerebellar network with the control results of the system under different control tasks. In order to further increase the biological authenticity of the cerebellum control system, the model is implemented on a field programmable gate array (FPGA) platform in a parallel operation approach closer to the human brain, and corresponding resource optimization methods are proposed so that the achievable network scale is increased. The FPGA implementation results show that the system successfully simulates the adaptive brain-inspired robotic arm control based on the cerebellar error correction ability. The cell dynamics of the cerebellum can also be reproduced on the system and the high fault tolerance from large-scale granule cells is proven. This work provides a platform that takes into account both the realization of cerebellar application functions and the theoretical research.

Keywords: cerebellum; spiking neural network; field programmable gate array; synaptic plasticity; brain-like control

0 引言

近年来, 基于生物灵感的柔性机器人受到越来越多的关注^[1-2]. 与目前广泛应用于工业界的刚性机器人相比, 柔性机器人拥有更强的环境适应能力, 在不

同环境中均可以更加顺畅地移动. 但与此同时, 由于在运动时与环境的交互可能会改变自身结构, 模型的非线性和不确定性也为运动控制带来了困难^[3-4]. 当前成熟的控制系统大多基于刚性机器人, 需要精确的

收稿日期: 2021-07-27; 录用日期: 2021-11-26.

基金项目: 国家自然科学基金项目(62071324).

[†]通讯作者. E-mail: guoshengyi@tju.edu.cn.

控制对象数学模型且在无法预测的环境中可能会失效,因此,如何开发出具有环境适应性和控制对象适应性的控制器是提高机器人控制效果的关键。

人体任何看似简单的日常动作都离不开一系列精细的肌肉运动,小脑在其中起着维持平衡、自适应控制和协调运动等不可替代的作用^[5-7],是调节人体完成随意运动的关键。在运动控制过程中,小脑与大脑各区域、本体感受器等相互配合,利用其学习能力形成被控对象的内部模型,对运动过程进行实时调整,以适应外部世界运动效应器的任何变化,完成稳定、平滑且精准的运动。因此,基于小脑在人体运动控制中的原理,建立模拟小脑功能的运动控制系统,为有效解决类似柔性机器人的复杂运动控制问题提供一个可行的解决思路^[8]。此外,对于建模复杂机器人而言,由建模错误引起的控制失灵问题也能通过引入小脑控制得到一定程度的改善。

要构建模拟小脑功能的仿生控制器,关键在于如何构建与实现具有生物可信性的小脑神经网络模型。在小脑神经网络构建方面,由于基于神经科学的脉冲神经网络能够更加真实地模拟生物神经网络的放电活动和功能,很多不同复杂度的小脑脉冲神经网络模型被建立以对小脑进行不同程度的模拟和探索。Lennon等^[9]建立了小脑浦肯野细胞和分子层中间神经元的脉冲神经网络模型,该模型再现了浦肯野细胞的不规则放电,并基于此探索了其在小脑学习和功能中的作用。Medina等^[10]基于家兔的小脑神经活动构建了大约由11.5k个基于电导的漏积分放电(leaky integrate-and-fire, LIF)神经元组成的小脑脉冲神经网络模型,该模型在计算机上运行并成功模拟了眨眼条件反射实验。Yamazaki等^[11]同样利用基于电导的LIF模型构建了与真实解剖结构相似的小脑脉冲神经网络,该网络由大约100k神经元组成,成功模拟了动眼实验和其中的细胞动力学。此外,由于小脑出色的运动控制能力,很多基于小脑模型的运动控制系统也被建立。Zahra等^[12]利用小脑特性构建高效的机器人控制系统,融合了视觉信息完成了对机械臂的控制。Zhang等^[13]利用小脑模型完成了气动人工肌肉的控制。Luque等^[14-15]利用构建的小脑脉冲神经网络模型完成了对机械臂的运动控制并对不同的控制回路进行了探索。虽然以上工作已使用小脑完成机械臂控制,但大部分用于机械臂控制的小脑模型神经元数量较少(大约在1500个),对于模拟小脑在运动控制中的放电活动等生理机制方面具有一定的局限性。而对于自下而上的模型而言,很重要的一点是需

要能够反应真实的生理活动特性。通过模型和实验探究网络功能与活动的关系,有助于进一步理解生物控制原理,从而最终开发真正能够模拟人体随意运动的控制系统。本文从神经元数量和不同类型神经元比率上构建更加贴近真实小脑网络的神经网络模型,使得模型既能完成机械臂控制,同样也可以为进一步探索小脑运动控制功能与网络放电活动的联系提供手段。

大规模小脑网络规模的模拟也对仿真平台提出了更高的要求。平台不仅要有强大的计算能力支持机械臂的实时控制,还要能够对所实现的神经网络进行灵活调整(如部分网络结构的增减),从而支持关于小脑网络作用机制的进一步探索。本文采用以现场可编程门阵列(field programmable gate array, FPGA)为核心芯片的大规模类脑计算系统(bio-inspired cognitive supercomputing system, BiCoSS)^[16]对大规模小脑脉冲神经网络进行实现。该系统不仅具有强大算力和灵活编程的能力,而且其非冯诺依曼架构与真实生物系统的并行计算方式一致,能够进一步增加模拟的生物可信性。但应用FPGA实现大规模神经网络在片上资源和数据通讯方面也面临着挑战。在片上资源方面,FPGA逻辑资源丰富但乘法器资源有限,因此常常出现乘法器资源耗尽时仍剩余大量逻辑资源的现象,造成了资源浪费并限制了单片FPGA所能实现的神经网络规模。此外,非线性函数同样无法在FPGA上直接进行实现。因此,如何应用逻辑资源实现乘法运算和非线性函数对增加单片FPGA所能实现的神经网络规模非常重要。一些常用的方法如分段线性化(piecewise-linear, PWL)方法、坐标旋转数字计算(coordinate rotation digital computer, CORDIC)算法已经在相关工作中被广泛应用^[17-18]。本文根据所实现神经网络的特点,对CORDIC算法进行改进以高效实现大规模神经网络中的乘法和非线性运算。在数据通讯方面,应用地址事件表示(address-event representation, AER)进行神经元放电事件的点对点数据通讯^[19],用以解决大规模神经网络结构和连接复杂导致的硬件布线复杂以及数据通讯开销大的问题。该方法的通讯机制与真实生物系统相似,即仅在神经元产生放电(脉冲)时进行通讯,通过使用突触路由表进行虚拟布线,完成放电神经元与目标神经元之间的通讯连接,理论上可以灵活地连接任意一对神经元,进而可以大幅降低通讯开销。

本文主要研究内容为大规模小脑脉冲神经网络的构建、实现和应用,贡献和创新性主要体现在以下

两个方面:

1) 实现具有真实神经元比率的大规模小脑脉冲神经网络模型,构建兼顾小脑理论研究与应用功能实现的平台.

2) 提出具有在线学习功能的大规模脉冲神经网络的一种FPGA实现方法,构建基于小脑的机械臂控制平台,完成基于小脑的机器人运动控制.

1 小脑模型与控制策略

1.1 神经网络模型

本文所采用的小脑脉冲神经网络模型最初由Carrillo等^[15]提出,在此基础上构建更大规模(约18k个神经元和28.8M突触)的小脑神经网络模型,从而能够模拟小脑中颗粒细胞与浦肯野细胞的真实比率(约3000:1),提高模型的生物可信性.此外,模型还增加更多位置的突触可塑性,这些可塑性在不同时间尺度下起作用,从而可以更全面地模拟小脑的运动学习功能.网络整体结构如图1所示,神经元数量和突触连接见表1.在模型中,除橄榄核(inferior olivary, IO)和苔藓纤维(mossy fiber, MF)外,每种神经元均由LIF模型表示为

$$\begin{cases} C \frac{dV}{dt} = g_{exc}(t)(E_{exc} - V(t)) + g_{inh}(t)(E_{inh} - V(t)) + G_{rest}(E_{rest} - V(t)), \\ g_{exc}(t) = G_{exc} \cdot e^{-\frac{(t-t_0)}{\tau_{exc}}} \cdot ((t - t_0) > 0), \\ g_{inh}(t) = G_{inh} \cdot e^{-\frac{(t-t_0)}{\tau_{inh}}} \cdot ((t - t_0) > 0), \\ V > V_{th}, V = E_{rest}. \end{cases} \quad (1)$$

其中: C 和 V 分别为神经元的膜电容和膜电位, E_{rest} 为神经元的静息电位, E_{exc} 和 E_{inh} 为突触电导的反转电位, G_{rest} 为神经元的最大突触电导, τ_{exc} 和 τ_{inh} 为兴奋性和抑制性突触的时间常数, g_{exc} 和 g_{inh} 分别为兴奋和抑制性的突触电导.当膜电位 V 到达阈值 V_{th} 时,神经元会产生放电,此时膜电位被重置为静息电位,放电时刻为 t_0 .不同类型的神经元参数值可在文献[20-23]中找到,并总结于表2.

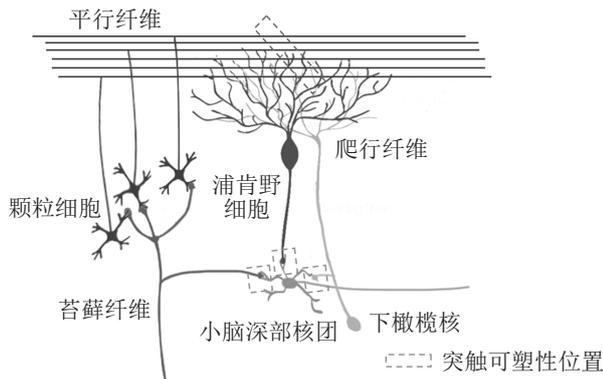


图1 小脑模型内部结构(改编自文献[24])

表1 小脑神经元种类与突触连接

神经元种类	数量	突触连接	突触数量
苔藓纤维	100	颗粒细胞	18 M
		小脑深部核团	1 200
颗粒细胞	180 k	浦肯野细胞	10.8 M
浦肯野细胞	60	小脑深部核团	60
下橄榄核	12	浦肯野细胞	60
		小脑深部核团	12
小脑深部核团	12	-	-

表2 神经元参数表

参数种类	颗粒细胞	浦肯野细胞	小脑深部核团
C/pF	2	400	2
E_{rest}/mV	-70	-70	-70
E_{inh}/mV	-	-80	-88
E_{exc}/mV	0	0	0
G_{rest}/nS	0.2	16	0.2
G_{exc}/nS	1	1.3	1
G_{inh}/nS	-	3	30
τ_{exc}/ms	0.5	0.5	0.5
τ_{inh}/ms	-	1.6	10
V_{th}/mV	-40	-52	-40

在小脑的经典眨眼条件反射实验中^[25],MF的作用是在条件刺激出现时传递恒定频率的放电.在运动控制中,MF接受本体感受信息^[26],将实际角度和速度等信号进行编码并传递给颗粒层细胞.由于工作重点是小脑在运动控制中学习过程的模拟,为了简化模型,MF用经典积分放电(integrate-and-fire, IF)神经元^[27]构建产生恒定频率的放电,以驱动整个网络正常运行.每个颗粒细胞(granule cell, GR)接收4个MF信号^[28],即4个MF为一组,每组MF具有相同的放电活动.每组MF在一次学习过程中仅在特定的时间窗口放电,所有MF的放电时间窗覆盖整个学习过程且有少量重叠,模拟人体真实的感受野^[29].

作为小脑皮层的唯一输出,浦肯野细胞(purkinje cell, PC)在运动控制中起着至关重要的作用.它一方面接收来自GR的本体状态信息,另一方面接收来自IO的误差信息,并通过自身活动控制小脑深部核团(deep cerebellar nuclei, DCN)的放电,使其产生正确的输出.由于本文控制的为六自由度机械臂,PC被分为6组,每组PC通过平行纤维(parallel fiber, PF)接收全部GR的相同输入信号,通过爬行纤维(climbing fiber, CF)接收不同的IO信号.每组PC与一个IO连接,每个IO用于接收一个关节的误差,并产生相应的示教信号,对PF-PC的突触权重进行调整.IO同样用IF神经元模型进行建模,误差作为神经元的外部刺激电流,产生的放电即为相应的示教信号.

与PC类似,DCN也被分为6组,分别用于控制每个自由度的关节.每组DCN由两个神经元构成,分别用于纠正转矩正误差和转矩负误差.本文除PF-PC

的可塑性外,其他3处可塑性均与DCN相关,具体情况在下节进行介绍.由于DCN的输出是脉冲放电信号,采用BSA算法^[30]将其转化为可直接输入到机械臂进行使用的转矩信号.BSA是一种常用的脉冲信号编解码算法,可以便捷地实现实值信号与脉冲信号之间的相互转化,本文选择在 $[-\pi/4, \pi/4]$ 区间幅度为30的正弦信号作为计算核.

1.2 突触可塑性模型

小脑中存在超过15种突触可塑性^[31],小脑功能的完成也主要依赖于其内部的多种突触可塑性^[32-34],但对于究竟哪些可塑性在运动学习过程中起了哪些具体的调节作用仍无定论.本文选取4种在运动控制过程中作用较为明确的突触可塑性,每种可塑性都分为长时程抑制(long-term depression, LTD)和长时程增强(long-term potentiation, LTP)两部分,其中起主要作用的可塑性位于PF-PC,另外3种均与DCN有关(MF-DCN, PC-DCN, IO-DCN).与单一可塑性相比,4种可塑性相互配合,可以优化整个网络的调节机制,并使小脑网络在学习过程的不同时间阶段内都能产生相应的误差纠正信号.

近年来,对小脑可塑性的研究大多集中在PF-PC上,其突触强度将根据来自IO细胞的示教信号产生变化.每个GR细胞的放电都会触发在PF-PC处的LTP,使得PF-PC的突触权重增加.LTD将由每个IO细胞的放电触发,突触权重减小的幅度与IO细胞放电前100ms的GR放电情况有关.与文献[11,25]类似,本文PF-PC的可塑性遵循如下规则:

LTP :

$$w_{PF_i \rightarrow PC_j} = w_{PF_i \rightarrow PC_j} + \delta_{LTP}(1 - w_{PF_i \rightarrow PC_j})PF_i(t), \quad (2)$$

LTD :

$$w_{PF_i \rightarrow PC_j} = w_{PF_i \rightarrow PC_j} - \delta_{LTD}w_{PF_i \rightarrow PC_j} \sum_{t=0}^{100} CF_i(t)PF_j(t - t^*). \quad (3)$$

其中: $w_{PF_i \rightarrow PC_j}$ 为第*i*个PF与第*j*个PC之间的突触权重; δ_{LTP} 和 δ_{LTD} 分别为每次LTD和LTP触发时突触权重的变化; $PF_i(t)$ 和 $PC_j(t)$ 为对应神经元的放电状态,如果在*t*时刻则神经元产生放电为1,否则为0.

PF-PC上存储的信息主要与时间相关,而增益信息或响应幅度与DCN更为相关.因此,考虑MF-DCN、PC-DCN和IO-DCN的突触可塑性,以使运动学习的表达更加灵活^[31,35].MF-DCN的突触可塑性

由PC的放电控制,当PC不产生放电时,LTP会被触发;当PC产生放电时,MF对DCN的兴奋性刺激将会在LTD的作用下减弱.由于PC放电同样会对DCN放电进行抑制,MF-DCN突触可塑性的存在会使得PC对DCN的抑制总量减小,从而加快整个网络的调节速度.本文采用与PF-PC类似的规则实现此可塑性,有

LTP :

$$w_{MF_i \rightarrow DCN_j} = w_{MF_i \rightarrow DCN_j} + \delta_{LTP}(1 - w_{MF_i \rightarrow DCN_j})(1 - PC_k(t)), \quad (4)$$

LTD :

$$w_{MF_i \rightarrow DCN_j} = w_{MF_i \rightarrow DCN_j} - \delta_{LTD}w_{MF_i \rightarrow DCN_j}PC_k(t). \quad (5)$$

PC-DCN是4种突触中唯一一种抑制性突触,可以用来平衡DCN接收的兴奋性输入.仅当PC和DCN对同时放电时才会诱导PC-DCN的LTP,当PC不产生放电时突触权重会由于LTD的存在而减小^[36-37],即

LTP :

$$w_{PC_i \rightarrow DCN_j} = w_{PC_i \rightarrow DCN_j} + \delta_{LTP}PC_i(t)(1 - w_{PC_i \rightarrow DCN_j})DCN_j(t), \quad (6)$$

LTD :

$$w_{PC_i \rightarrow DCN_j} = w_{PC_i \rightarrow DCN_j} - \delta_{LTD}w_{PC_i \rightarrow DCN_j}(1 - PC_i(t)). \quad (7)$$

小脑在人体运动控制过程中主要起着前馈控制的作用^[7,38-39],根据本体感受等信息提供预测纠正信号,以纠正运动误差.IO和DCN突触可塑性的存在使得小脑控制器同样可以进行反馈控制^[31,40],但这种反馈控制并不能提供精确的误差纠正信号,仅在小脑不能提供预测纠正信号的初始学习阶段对小脑的输出起补偿作用.IO与DCN突触权重的变化仅与IO的放电有关,当IO产生放电时,突触权重会增加,当IO不产生放电时,突触权重会减小.与以上规则类似,其权重根据下式调整:

LTP :

$$w_{IO_i \rightarrow DCN_j} = w_{IO_i \rightarrow DCN_j} + \delta_{LTP}IO_i(t), \quad (8)$$

LTD :

$$w_{IO_i \rightarrow DCN_j} = w_{IO_i \rightarrow DCN_j} - \delta_{LTD}w_{IO_i \rightarrow DCN_j}(1 - IO_i(t)). \quad (9)$$

1.3 控制对象与控制策略

使用六自由度机械臂PUMA560作为控制对象,应用小脑脉冲神经网络对机械臂进行转矩控制. 作为经典的机械臂模型,PUMA560的建模方法以及运动学和动力学求解都较为成熟,多年来被广泛应用于控制算法的验证^[41-43]. 该机械臂由关节机械臂和球形手腕组成,具有与人体手臂类似的6个转动关节,前3个关节决定腕关节参考点的位置,后3个关节决定腕关节的方向. 机械臂模型采用Matlab Robotics Toolbox构建,小脑模型则部署在BiCoSS系统上^[16].

图2给出了第1.1节阐述的小脑控制器与机械臂的连接方式,具体控制回路如图3所示. 在控制过程中,首先应通过机械臂期望轨迹解算出沿轨迹运动所需的角度、速度和加速度,然后利用逆动力学公式解算出所需要的转矩. 由于研究重点是小脑控制器的控制效果,直接使用Matlab工具箱中提供的机械臂相关计算函数完成轨迹规划、逆运动学与逆动力学的计算. 在实验中,首先通过设定的期望轨迹提前计算出期望转矩,并将期望转矩与人为扰动转矩相加输入给机械臂,以模拟机械臂在运行过程中受到的扰动. 机械臂接收到实际的转矩后产生实际的角度、速度和加速度,与之前计算的期望角度、速度和加速度比较后得到相应误差,作为示教信号输入给小脑控制器指导其输出误差纠正转矩,从而完成对机械臂的运动控制.

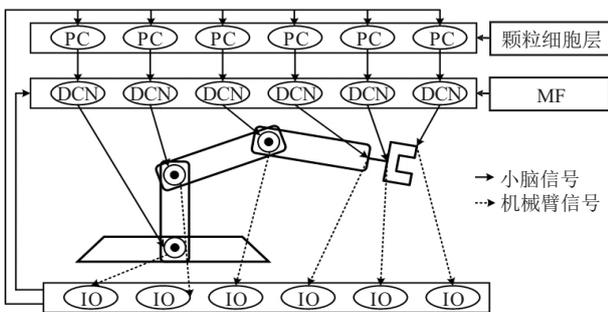


图2 机械臂与小脑连接方式

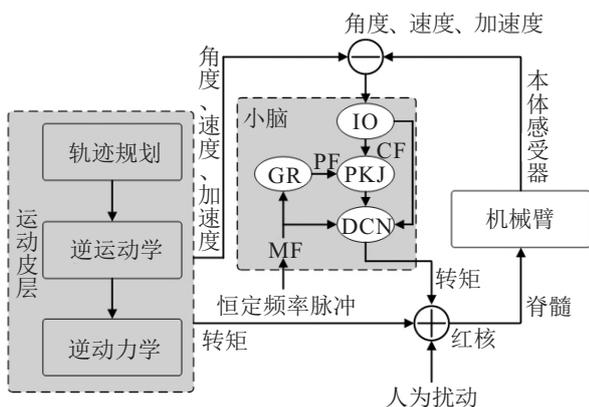


图3 小脑控制回路

2 FPGA实现设计

应用FPGA平台对小脑神经网络进行实现,以更贴近人脑并行运算的方式提高网络的运算速度,从而完成对机械臂进行实时控制. 具体实现方法如下.

2.1 实验平台与通信

如图4(a)所示,实验平台主要由两部分组成,一部分是实现计算机臂模型和机械臂运动相关函数的上位PC机,另一部分是部署小脑脉冲神经网络的FPGA类脑计算平台BiCoSS. PC机配有2.8 GHz I5处理器、8 GB运行内存和USB 3.0接口,BiCoSS系统由包含7个子系统的35片FPGA组成^[16],应用其中1个子系统对小脑网络进行实现. 子系统由5片Altera Cyclone EP4CE115 FPGA组成,采用混合互联结构连接在一起,不同FPGA芯片之间均由50个引脚直接连接,并配有SDRAM芯片. 小脑脉冲神经网络模型采用DSP Builder和Verilog语言编程,使用Quartus II软件通过Joint Test Action Group(Jtag)下载到各片FPGA中. 实验平台的第1片FPGA为路由模块,用于系统中FPGA的片间通讯,后4片FPGA为神经网络计算模块,用于计算小脑神经元的神经元和突触. 如图4(b)所示,FPGA2和FPGA3用于计算神经网络中数量较多的GR,作为小脑的颗粒层,FPGA4用于计算小脑的浦肯野细胞,FPGA5则负责计算其他神经元,并将DCN产生的放电信号通过脉冲编码实时转化为纠正转矩,此外FPGA5还负责驱动USB与上位机进行通讯. 在控制过程中,FPGA5首先通过USB接收期望运动参数值和虚拟机械臂产生的实际运动参数值,计算误差后产生示教信号传递给FPGA2和FPGA3以调整GR细胞与PKJ细胞之间的连接权重,然后FPGA2和FPGA3中的GR细胞产生稀疏放电形成突触电流传递给FPGA4中的PKJ细胞,产生抑制信号传递到FPGA5的DCN神经元中. 最后DCN的放电活动被编码为纠正转矩,通过USB传递给PC机中的机械臂,从而完成对上位机中虚拟机械臂的控制.

由于在FPGA上所实现的单个神经元计算速度远超过了实际生物的计算时间,可以应用时分复用的方法,通过适当减慢运算速度实现更多的神经元. 具体而言,可以将不同神经元的参数提前存储到FPGA平台的SDRAM中,应用控制模块在不同的时钟周期内重复调用同一个神经元模块和不同的神经元参数,从而完成多个神经元的模拟. 此外,本文采用基于AER神经信息路由进行网络通信,具体细节可参见文献^[16].

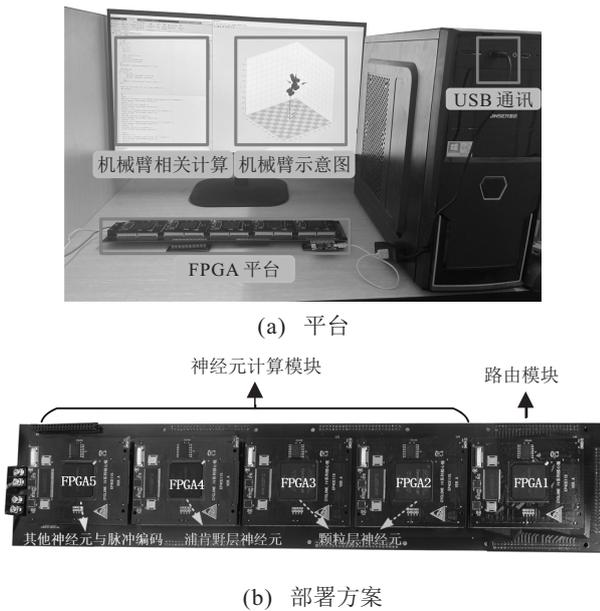


图4 FPGA平台与部署方案

2.2 方程离散化与定点运算

由于FPGA是产生离散信号的数字电路,在实现神经网络前需要对微分方程进行离散化处理.使用欧拉法对神经元方程模型进行离散化,离散后的神经元方程为

$$\begin{cases} V[k+1] = \\ (g_{exc}[k](E_{exc} - V[k]) + g_{inh}[k](E_{inh} - V[k]) + \\ G_{rest}(E_{rest} - V[k])) / (C\Delta t), \\ g_{exc}[k] = G_{exc} \times e^{\frac{-(k-k_0)\Delta t}{\tau_{exc}}} \cdot ((k - k_0) > 0), \\ g_{inh}[k] = G_{inh} \times e^{\frac{-(k-k_0)\Delta t}{\tau_{inh}}} \cdot ((k - k_0) > 0), \\ V[k+1] > V_{th}, V[k+1] = E_{rest}. \end{cases} \quad (10)$$

其中: k 为离散时间步, Δt 为每步实际时间. 选取 $\Delta t = 2\text{ms}$, 表明每个时间步代表 2ms 的时长.

在软件仿真中,大多数情况下使用的都是浮点运算,但在FPGA上实现浮点运算较为复杂,并且会消耗大量的片上资源.由于本文所实现神经网络的精度要求并不是很严格,采用精度略低但较为简便和节省资源的定点运算.定点运算设计最重要的是定点数整数部分和小数部分位宽的选择,其中整数部分与数据范围有关,小数部分与数据精度有关.为了在FPGA上有效地实现定点运算,进行软件预仿真以获取神经网络中每个变量在计算过程中的数值范围,从而对相关定点数的整数位宽进行设置,小数位宽则以满足网络运行精度要求为标准设置.

2.3 CORDIC设计

CORDIC是一种通过旋转和迭代实现非线性运算的算法,仅需要逻辑资源即可在FPGA上实现.本

文在FPGA上应用CORDIC算法实现小脑模型中的乘法和指数运算,解决了构建大规模小脑脉冲神经网络时乘法器不足和非线性函数实现困难的问题.该算法最初被Lavín-Delgado等^[43]提出,之后被Walther^[44]统一如下:

$$\begin{cases} X_{i+1} = X_i - md_i Y_i 2^{-i+n}, \\ Y_{i+1} = Y_i + d_i X_i 2^{-i+n}, \\ Z_{i+1} = Z_i - d_i \theta_i. \end{cases} \quad (11)$$

其中: X 和 Y 为旋转变量, Z 的初值为目标角度, i 为迭代次数, d 为影响旋转方向的参数, n 为与算法精度相关的变量.当 $m = 0$ 且 $\theta_i = 2^{n-i}$ 时,CORDIC算法进行直线旋转,可用于实现乘法运算;当 $m = -1$ 且 $\theta_i = \tanh^{-1}(2^{-i})$ 时,CORDIC算法进行双曲旋转,可用于实现双曲函数的运算,并通过 $\exp \theta = \cosh \theta + \sinh \theta$ 实现指数函数运算.

在乘法模式下进行并行设计以减小CORDIC迭代运算带来的计算延迟. X 和 Z 为需要相乘的两个变量,由于 $m = 0$, X 在每次迭代过程中保持不变,此时式(11)变为

$$\begin{cases} Y_{i+1} = Y_i + d_i X 2^{n-i}, \\ Z_{i+1} = Z_i - d_i 2^{n-i}. \end{cases} \quad (12)$$

由方程(12)可知,每次迭代过程中 Z 与 2^{n-i} 相减或相加,并在 Y 中对 X 与 2^{n-i} 的乘积进行累加/减.迭

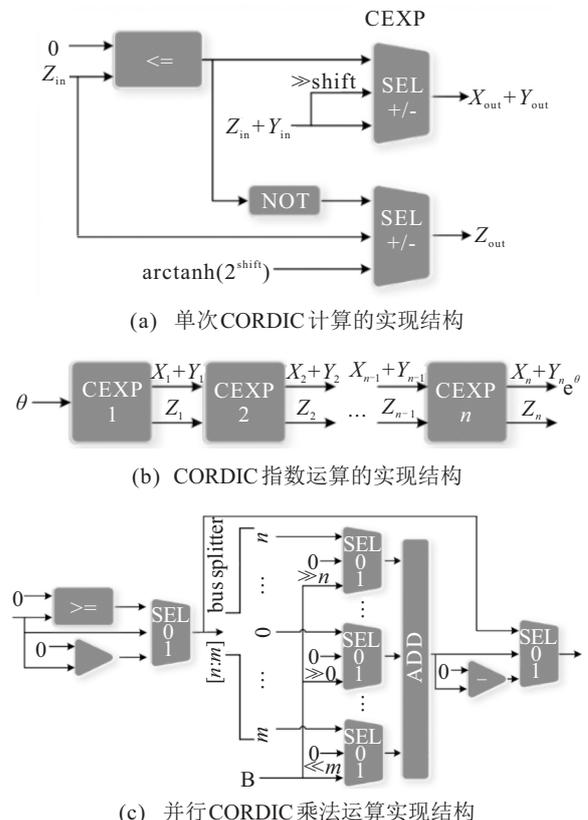


图5 CORDIC算法的数字实现架构

代结束后 Z 越趋近于 0 则精度越高. 本质上, Z 在迭代过程中被拆分成由多个 2 的指数幂相加减的形式, X 则根据其幂指数进行移位并累加/减, 从而完成乘法运算. 基于此, 可以利用 Z 的二进制形式对 X 进行移位, 从而完成并行 CORDIC 乘法运算, 大幅提高运算速度. 如图 5(c) 所示, Z 通过 Bus Splitter 转化为二进制形式指导 X 进行移位, 最后将二进制位数为 1 对应的 X 的移位结果进行并行相加, 得到乘法运算结果.

在指数模式下, Z 的初值为输入的待求角度 θ , 迭代完成后 X 的值为 $\cos \theta$, Y 的值为 $\sin \theta$. 由于此模式下 Z 被拆分为多个 $\tan^{-1}(2^{-i})$ 相加减的形式, 不能用与乘法类似的方法进行并行运算. 但此模式下式 (11) 前两个方程结构类似, 可以将其相加, 此时式 (11) 变为

$$\begin{cases} (X_{i+1} + Y_{i+1}) = (X_i + Y_i) + d_i(X_i + Y_i)2^{-i}, \\ Z_{i+1} = Z_i - d_i \tan^{-1}(2^{-i}). \end{cases} \quad (13)$$

迭代结束时, $X + Y$ 即为所求的指数函数值, 具体实现结构如图 5 所示. 通过这种优化, 可将变量 X 和 Y 合并为变量 E , 即 $E = X + Y$, 此时式 (11) 中的 3 个迭代方程被简化为式 (13) 的两个迭代方程. 由于每个迭代方程的计算形式相同, 在硬件实现时可以节省 1/3 的资源消耗. 应用 CORDIC 算法的突触和神经元数字实现架构展示在图 6 中.

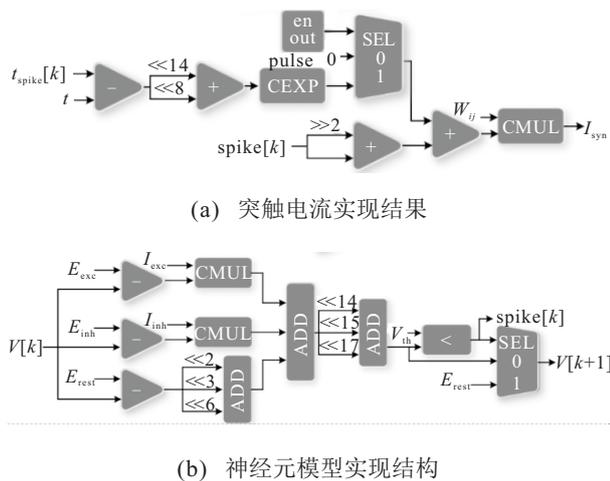


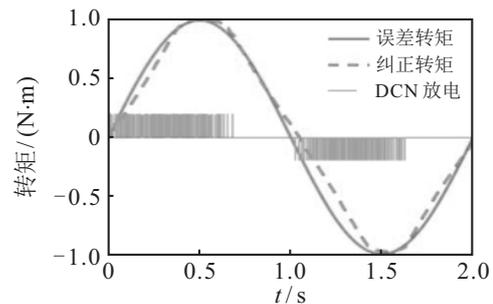
图 6 神经元与突触的数字实现架构

3 实验结果与分析

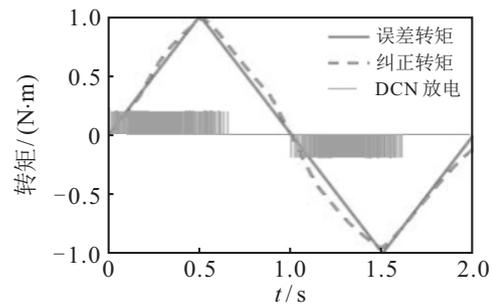
3.1 模型控制能力测试与分析

首先对所构建小脑模型的控制能力进行测试. 测试任务为控制机械臂在不同类型扰动下绘制椭圆轨迹, 机械臂末端每完成一个完整的椭圆轨迹耗时 2s, 各自由度加入的扰动转矩如图 7(a)~(c) 实线所

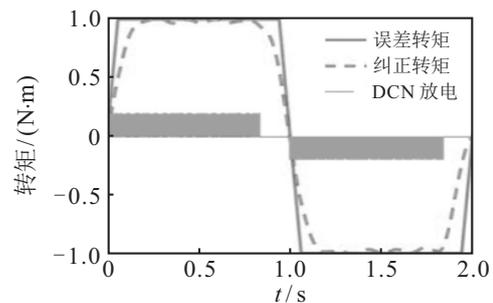
示. 前两个自由度加入正弦误差, 第 3、第 4 自由度加入三角波误差, 最后两个自由度加入接近于常数的误差. 应用第 1.3 节描述的控制策略经过 300 次学习训练可得到最终的控制结果. 图 7(a)~(c) 给出了小脑控制器对于 3 种不同类型转矩误差产生的 DCN 放电和通过 BSA 算法进行编码得到的转矩纠正信号, 机械臂末端轨迹如图 7(d) 所示. 可以看出, 虽然存在一定误差, 但小脑所产生的纠正信号与误差信号基本一致.



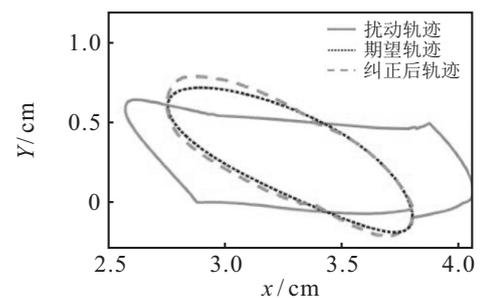
(a) 机械臂前两个自由度关节所施加误差与纠正情况



(b) 机械臂第 3、第 4 自由度关节所施加误差与纠正情况



(c) 机械臂最后两个自由度关节所施加误差与纠正情况



(d) 误差纠正前后的机械臂末端轨迹

图 7 误差纠正实验转矩和位置结果

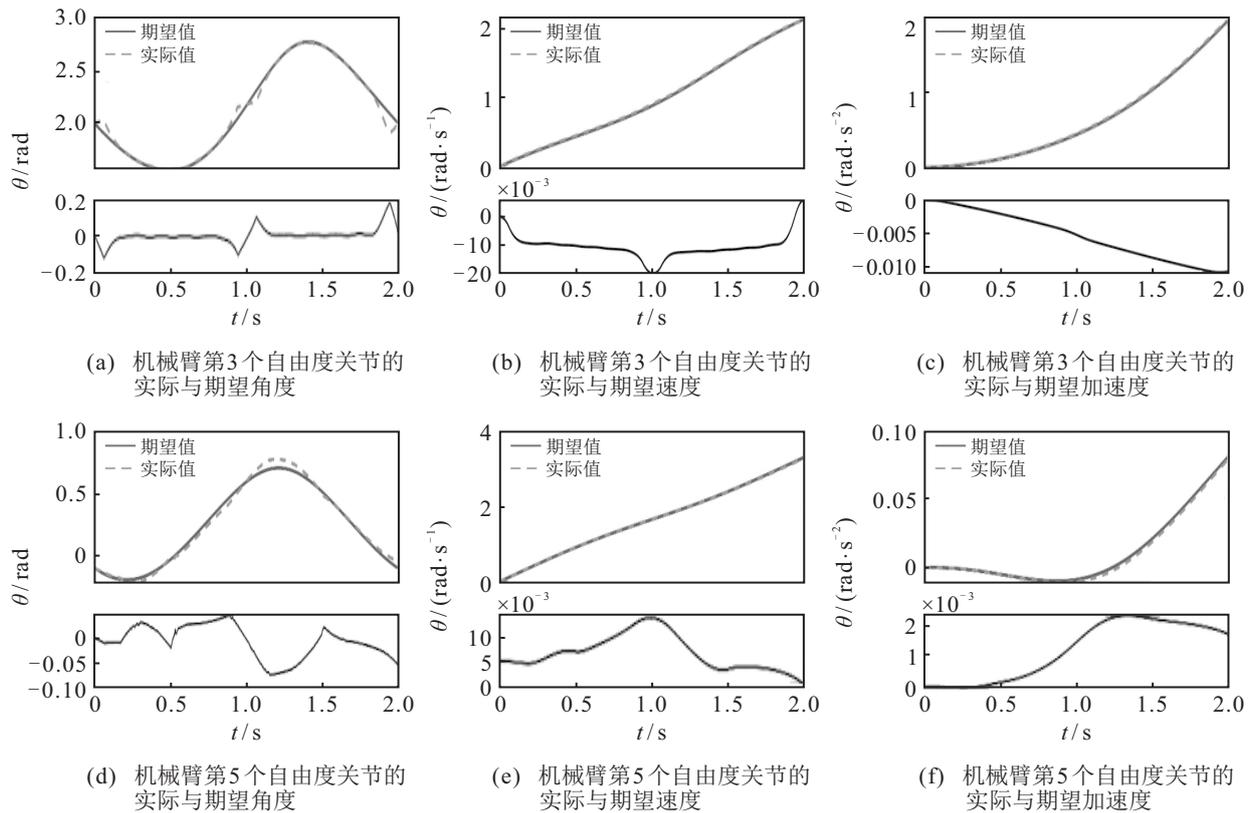


图8 误差纠正实验运动参数结果

图8(a)~(c)和(d)~(e)分别给出了第3和第5个自由度关节的角度、速度和加速度的情况及误差。由于BSA算法的特性,编码的信号在开始阶段需要一段时间累积到指定值,对于纠正如图7(c)所示的幅度快速变化的误差信号时,在开始阶段会存在不可避免的误差,从而导致图8(a)角度值的明显误差。此外,将期望转矩作为初始误差输入给小脑控制器以驱动机械臂完成轨迹跟踪任务,多种轨迹跟踪任务的测试结果如图9所示。

虽然应用所构建的模型在控制任务中产生的最大角度误差0.2 rad大于文献[14]的0.02 rad,但模型最大轨迹误差为4%,文献[13]跟踪正弦轨迹的最大轨迹误差约为5%,文献[15]触摸4个方向目标的最大轨迹误差约为10%,这表明所构建模型有较好的控制效果。造成角度误差略大的原因有两个,一是所应用的BSA算法在纠正快速上升的常值误差时会产生不可避免的误差,二是为了高效构建基于FPGA的控制系统的适当简化了模型的输入,即以常值刺激作为MF的输入,从而由于部分信息丢失导致精度略有降低。与一些传统控制方法相比^[45-46],所应用小脑控制模型可通过自身学习能力形成被控对象的数学模型完成控制任务,无需进行复杂的精确建模工作,具有更为灵活的自适应控制和环境适应能力。小脑模型的可塑性对控制结果的影响将在后文进行详细分析。

3.2 颗粒细胞层动态响应分析

为证明具有真实生物比率的大规模神经网络能够更真实地反映小脑网络的动态响应,利用所构建模型复现动眼反射实验中颗粒细胞层的放电行为。在此实验中,用来模拟视网膜滑动的信号为放电率遵循0.5 Hz正弦的泊松脉冲^[11],该信号通过MF输入给小脑神经网络,得到的颗粒细胞层动态响应如图10所示。图10(a)显示了产生尖峰的输入信号强度,图10(b)和(c)是随机选择的300个GR细胞的放电情况和所放电GR细胞占有所有GR细胞的百分比。在刺激开始和结束时,由于刺激较弱,少量随机的GR细胞产生放电。随着刺激强度增加,更多GR细胞产生放电,表明GR随着时间的推移而变化,并将刺激的时间及幅度信息传递给PKJ细胞,与生理实验结果一致^[11]。这种结构也增强了网络的容错性。图10(d)显示了在同样的刺激下,随机抑制20% GR细胞后的实验结果。可以看出,即使在网络不稳定的情况下,GR细胞也能够将信息传递给PKJ细胞,增强了控制系统的容错性和鲁棒性。

3.3 FPGA实现结果与精度分析

从不同方面对软件仿真结果和FPGA实现结果进行比较,采用多种精度评估的常用参数^[47-48],以验证第2节所提出神经网络实现方法的有效性。具体如

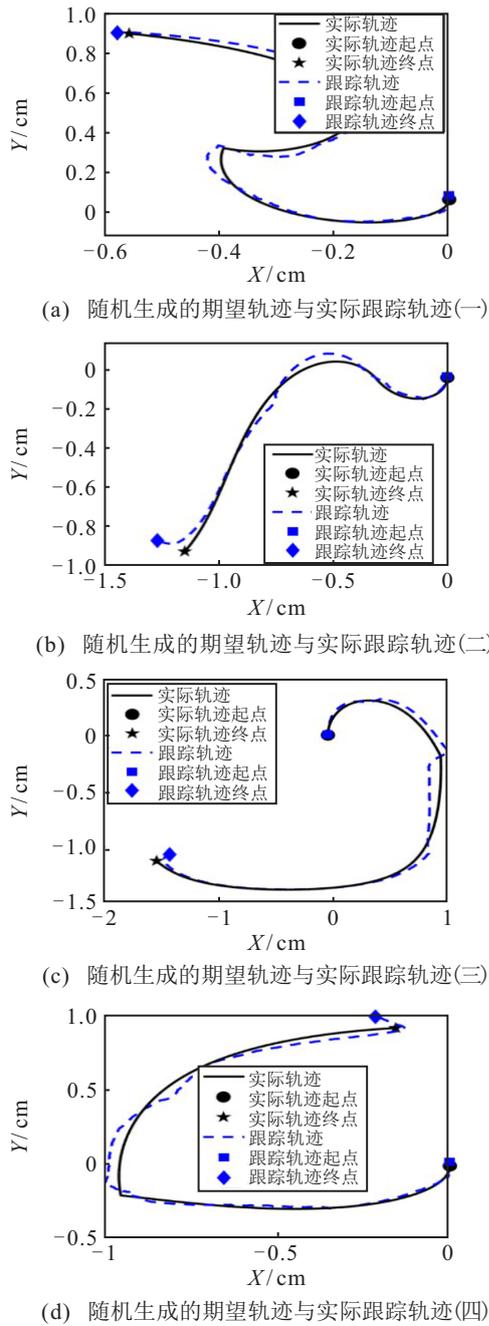


图9 轨迹跟踪实验结果

下:

1) 最大绝对值误差 (maximum absolute error, MAE): 如果神经元的放电波形为比较量, 则绝对值误差(AE)可以衡量硬件和软件实现结果在每个时间步上膜电压值 $V_H(t)$ 与 $V_S(t)$ 的偏差, MAE即为这些偏差的平均值, 可以反应时间长度 T 内的误差平均水平, 为精度提供整体评估指标, 而不是某些特殊值. 计算公式为

$$MAE = \sum_{t=1}^T |V_H(t) - V_S(t)| / T. \quad (14)$$

2) 归一化均方根偏差 (normalized root-mean-square deviation, NRMSD): RMSD是一种常用的用来评估两组数据相似度的指标. 这种指标与MAE不同,

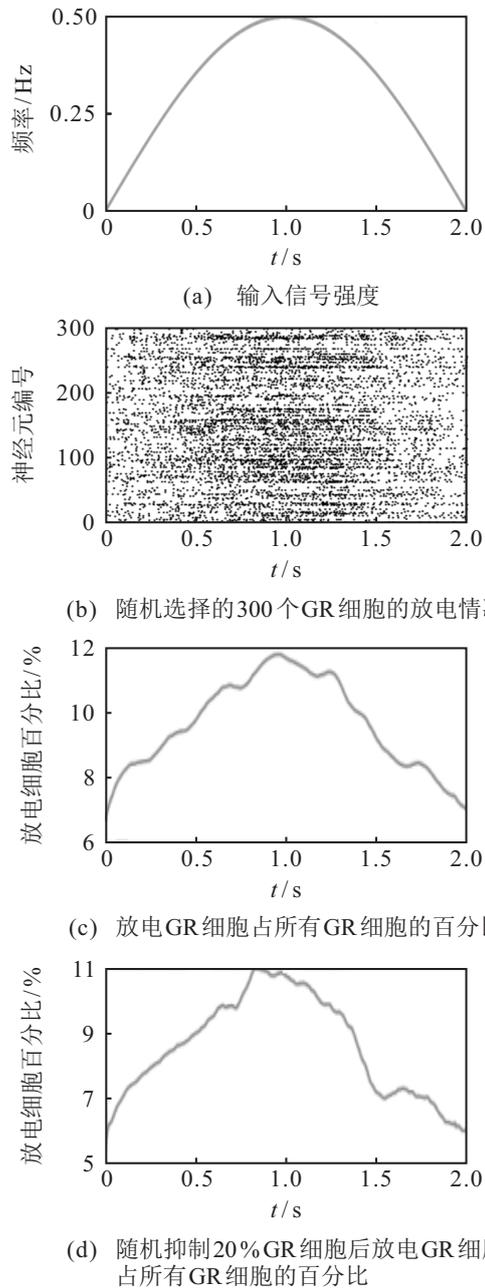


图10 颗粒细胞层动态响应

对数据中的异常值非常敏感, 即如果硬件实现结果中有过大或过小的值, 则RMSD的值会明显增大. 由于不同神经元的膜电压范围不完全一致, 使用归一化方法将RMSD转化为NRMSD, 使得不同神经元的RMSD具有可比性. 计算公式为

$$NRMSD = \frac{\sqrt{\frac{1}{N} \sum_{t=1}^N (V_S(t) - V_H(t))^2}}{V_{S \max} - V_{S \min}}. \quad (15)$$

3) 相关系数 (correlation coefficient, CORR): CORR可以表示两组数据的相关程度, 两种实现方法呈现的膜电压波形越相似, 它们越相关. CORR的取值范围为 $[-1, 1]$, 负值代表两组数据负相关, 正值代表正相关, 数值越大表明相关程度越大, 可以通过下式计算:

$$CORR = \frac{\sum_{t=1}^N (V_S(t) - \overline{V_S})(V_H(t) - \overline{V_H})}{\sqrt{\sum_{t=1}^N (V_S(t) - \overline{V_S})^2 \sum_{t=1}^N (V_H(t) - \overline{V_H})^2}}, \quad (16)$$

其中 $\overline{V_H}$ 和 $\overline{V_S}$ 分别为硬件和软件实现时神经元膜电压的平均值。

4) 信噪比 (signal-to-noise ratio, SNR): SNR 为表征信号中噪声所占比重的指标,通常用来评估声音信号和图像去噪效果. 与以上3种值域上的指标参数不同, SNR是频域上的评估指标,可以更全面地评估硬件实现结果. 对于神经元而言,可以将软件仿真结果作为原始信号,而硬件实现结果作为加入噪声之后的

信号,则SNR可以计算为

$$SNR = 20 \log_{10} \left(\frac{V_S - V_H}{V_S} \right). \quad (17)$$

图11为DCN和GR在模型训练完成后FPGA输出的膜电压波形与软件仿真结果,可以看出,两个波形基本保持一致. 不同种类神经元FPGA实现的评估结果总结于表3中,可以看出,IO的膜电压精度最高,因为它由不涉及到指数运算的IF模型模拟,所应用的近似计算较少. 其他3个神经元精度逐渐降低的原因是随着信号在神经元之间的传递,误差会逐渐累积,从而导致最终输出神经元DCN的精度较差. 但从图11(a)可知,DCN的膜电压误差并不会对放电时刻产生明显影响,不会影响整个网络的输出.

表3 FPGA实现的精度评估结果

	MAE	NRMSD	CORR	SNR
颗粒细胞	0.0971	0.0018	0.9998	61.0958
浦肯野细胞	0.1907	0.0094	0.9992	51.6393
小脑深部核团	0.9398	0.0134	0.9991	43.9302
下橄榄核	0.0131	7.8×10^{-4}	0.9999	69.0635

应用基于CORDIC的神经元实现方法能够使用逻辑资源实现乘法和指数运算,突破了乘法器资源和存储资源对神经元实现数量的限制. 经过测试,基于此方法,150个逻辑单元可以用来实现消耗16个DSP单元的乘法器或者消耗2067 bits存储空间的基于查找表实现的指数计算. 经过资源计算,利用所提出方法综合使用3种资源实现神经元,所实现的神经元比使用片上乘法器和存储资源直接实现扩大10倍以上.

使用FPGA的另一个原因是其能够大幅缩短大规模神经网络的计算时间. 本文比较了不同网络规模下软件仿真和硬件实现的训练时间,从表4可见,随着网络规模的加大,FPGA的训练时间上升幅度较小,但CPU训练时间大幅上升,因此神经网络规模越大FPGA的加速效果越明显.

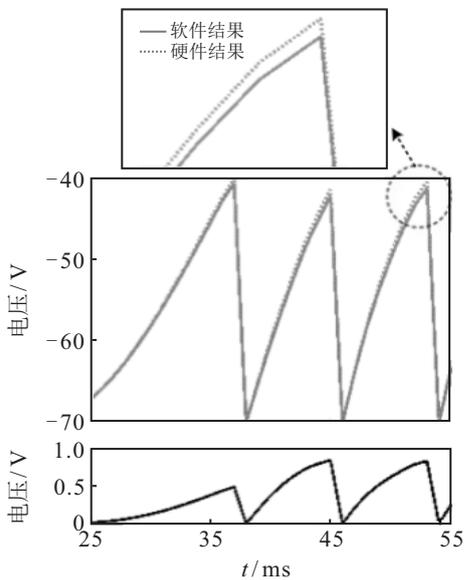
表4 不同神经元数量下软硬件训练时间对比 单位: s

神经元数量	2000	10000	90000	180000
CPU	22.81	115.03	1303.12	5316.58
FPGA	0.10	0.16	0.71	1.32

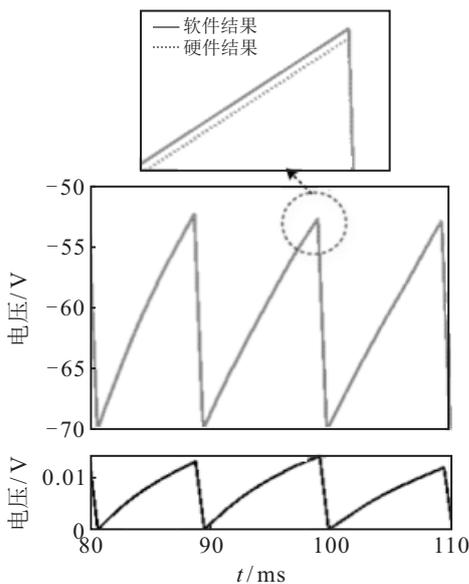
3.4 突触可塑性影响分析

在前文描述整体控制和实现结果的基础上,进行3种实验分析4种不同时间尺度下突触可塑性在机械臂控制中的作用,以得到不同突触可塑性对小脑网络控制效果的影响规律:

- 1) 只存在PF-PC可塑性的情况;
- 2) 在情况1)的基础上增加MF-DCN和PC-DCN



(a) DCN的膜电压波形与误差



(b) GR的膜电压波形与误差

图11 DCN与GR膜电压波形软硬件实现结果对比

可塑性;

3) 在情况2)的基础上增加IO-DCN可塑性.

为了简洁清晰地表明突触可塑性的作用,仅以输入给前两个自由度的正转矩误差为例对控制结果进行讨论.

图12(a)和(b)展示了第1个实验下在训练初始阶段和完成后小脑控制器输出与误差的对比.由于PC的初始放电率较高,DCN受到较大的抑制作用而不能产生放电,小脑在开始阶段的输出为0.随着训练次数增加,PF-PC的突触权重在IO示教信号的指导下减小,PC放电率降低,抑制作用减小,使得DCN开始产生放电.在训练到达200次左右时,小脑控制器的输出已经能够很好地对误差进行纠正,达到控制效果.图12(c)为训练过程中PC与其连接的GR所有突

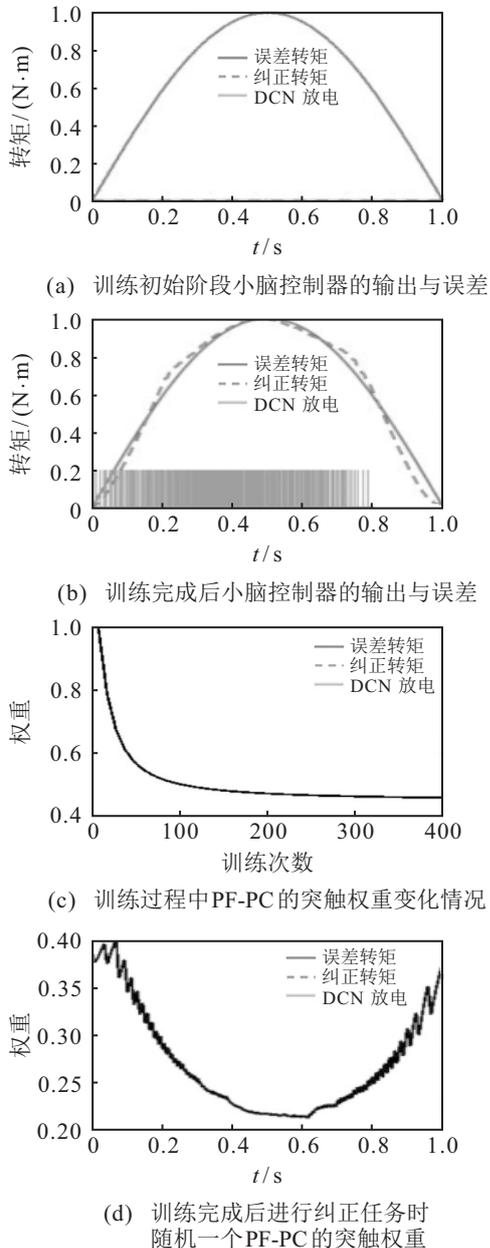


图12 实验1小误差下小脑输出与权重变化

触可塑性之和的变化情况,图12(d)为200次训练后完成纠正任务时某一个PF与PC之间突触权重随时间的变化情况.

虽然在仅有PF-PC可塑性的情况下能够完成控制任务,但若增大转矩误差的幅值,则控制器可能无法满足控制要求.如图13(a)所示,增大误差转矩后,当训练次数为100时,虽然图13(b)中PF-PC的权重已经下降到几乎为0,但DCN无抑制电流输入从而放电率达到最大值,但由图13可以看出,其转化的输出仍未达到转矩误差值,因此无法满足控制要求.

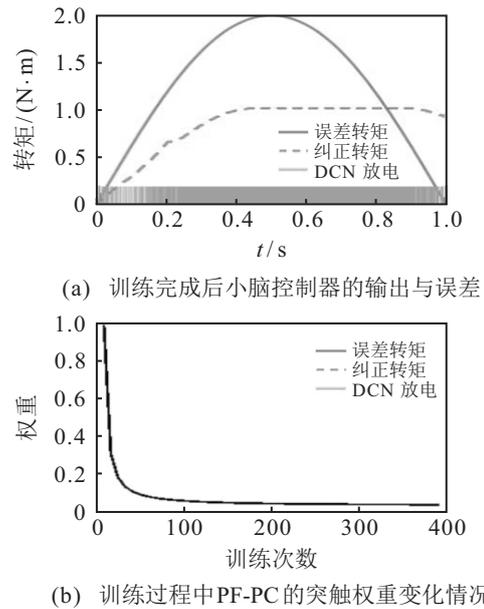


图13 实验1大误差下小脑输出与权重变化

在上述实验基础上,加入MF-DCN和PC-DCN的可塑性,应用高幅值的转矩误差进行第2个实验.图14(b)展示了3种权重的变化过程,3种权重值都进行了归一化处理以更加清楚地对权重变化进行比较.由图14可见,在PF-PC权重下降的过程中,MF-DCN权重缓慢上升,增加了DCN的兴奋性刺激强度,从而使得DCN的最大放电率和输出纠正转矩幅值增加,避免了PF-PC权重达到最小值时网络输出仍小于误差的情况.由于MF-DCN权重的变化只依赖于PC的活性,而PC-DCN权重的变化需要PC与DCN共同作用,PC-DCN权重以更慢的速度进行变化.PC-DCN权重的增加会增强DCN接受的抑制性刺激,由于这两种突触可塑性的作用时间尺度存在差异,通过相互配合,可以使得PF-PC的权重被调整到合适的位置,使其能够在出现其他变化时通过增大或减小PF-PC的权重进行较为快速的相应,提高控制性能.

第3个实验在第2个实验的基础上增加IO-DCN的可塑性,并应用同样的转矩误差信号进行测试.如图15(a)所示,与第1个实验相比,IO-DCN可塑性的加

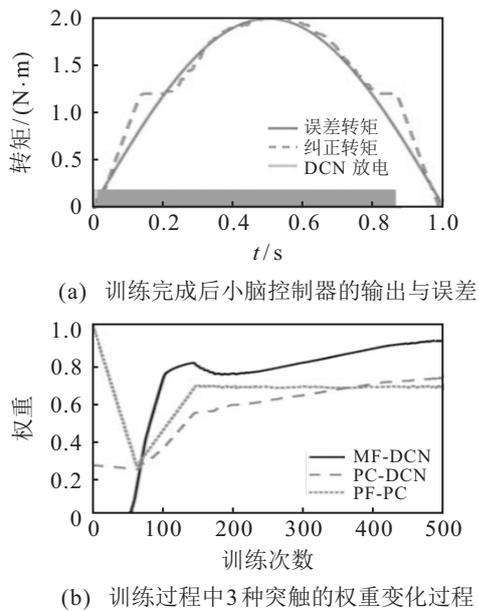


图14 实验2下小脑输出与权重变化

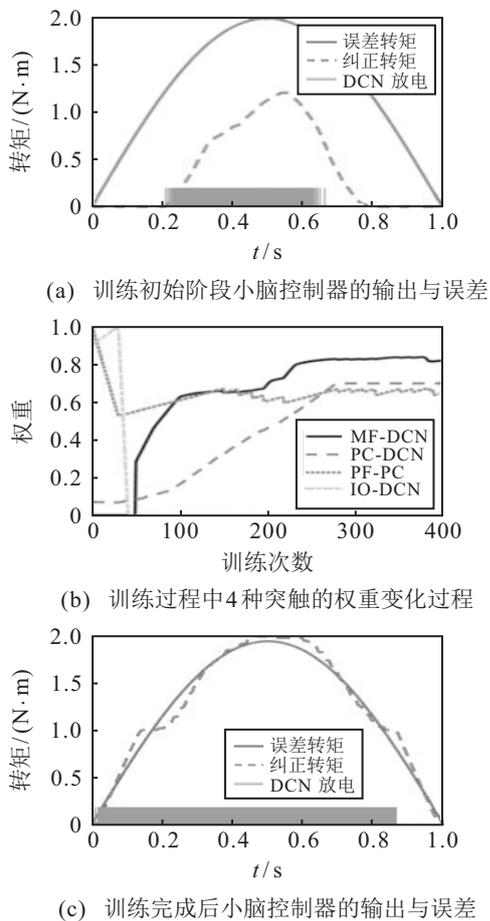


图15 实验3下小脑输出与权重变化

入有效地减小了开始阶段的误差. 随着训练过程进行, 由于误差减小, IO几乎不再产生放电, IO-DCN的权重也在可塑性的作用下逐渐减小为0, 此时纠正信号主要靠其他3种可塑性调节. 因此, IO-DCN的突触可塑性可认为是一种基于反馈的快速补偿. 此外, 如图15(b)和(c)所示, 该可塑性的加入能够提高控制精

度并使得网络更快趋于稳定, 第2个实验下网络在训练次数为400左右趋于稳定, 而加入此种可塑性后在训练次数为300时达到稳定.

综上所述, 小脑完成精确快速的误差纠正任务需要多种可塑性机制相互配合, 在不同时间尺度下, 不同位置的可塑性有不同的作用. 开始阶段(训练次数大约为1~50)主要由IO-DCN的可塑性通过所接收的误差驱动DCN进行粗略的快速响应; 之后较为精确的调制作用由PF-PC可塑性完成, PF-PC的权重中保存了小脑关于时间和信号幅度的信息, 其需要的训练时间适中(训练次数在200左右), 可以认为是中速调制. MF-DCN和PC-DCN的可塑性主要用于调节小脑输出的幅值, 使小脑具有自适应输出的特性, 并能够将PF-PC的权重保持在一定范围内, 优化网络的突触权重变化范围, 其速度较慢, 可以认为是慢速调制(训练次数在350左右). 通过快、中、慢3种速度的可塑性调制, 小脑能够完成机械臂逆动力学的过程, 完成控制任务, 这种网络输出特性同样也可以在经典动眼实验中观察到^[49], 进一步表明了所构建模型的生物可信性.

4 结论

探索人脑对人体运动的精准控制过程并模拟人体随意运动的完成过程, 对于提高机器人的运动能力具有重要意义. 小脑作为人脑中负责运动调节的主要部分, 是完成运动误差纠正任务的关键. 本文搭建了具有真实生物神经元比率大规模小脑脉冲神经网络, 得到兼顾小脑应用功能实现和理论研究的平台. 利用所构建的网络, 完成了对模拟机械臂的类脑控制, 证明了不同位置和时间尺度下小脑神经元突触可塑性的作用, 并验证了小脑的细胞动力学及其网络规模增大带来的高容错性.

为满足大规模脉冲神经网络的实现要求, 本文采用FPGA平台对大规模小脑脉冲神经网络进行实现. 提供了基于改进CORDIC算法的大规模神经网络实现资源优化方法, 实验数据表明, 应用此方法能够使可实现的最大网络规模扩大10倍以上, 且网络实现精度能够满足机械臂控制的要求. 不过由于计算资源限制, 文中所实现的神经网络规模仍远小于人脑中小脑的神经网络规模, 且神经元种类和突触可塑性种类也少于真实小脑. 在今后的工作中, 应在结构和规模上进一步优化当前模型, 并应在苔藓纤维输入本体感受信息, 完成对真实机械臂的控制, 从而进一步探索小脑在误差纠正过程中的运行机制, 开发多脑区协同的类脑控制系统.

参考文献(References)

- [1] Li Y J, Ren T, Li Y Q, et al. Untethered-bioinspired quadrupedal robot based on double-chamber pre-charged pneumatic soft actuators with highly flexible trunk[J]. *Soft Robotics*, 2021, 8(1): 97-108.
- [2] Wang S K, Chen Z H, Li J H, et al. Flexible motion framework of the six wheel-legged robot: Experimental results[J]. *IEEE/ASME Transactions on Mechatronics*, 2021(99): 1-10.
- [3] Tavasoli A, Mohammadpour O. Dynamic modeling and adaptive robust boundary control of a flexible robotic arm with 2-dimensional rigid body rotation[J]. *International Journal of Adaptive Control and Signal Processing*, 2018, 32(6): 891-907.
- [4] Rasouli P, Forouzantabar A, Moattari M, et al. Fault-tolerant control of teleoperation systems with flexible-link slave robot and disturbance compensation[J]. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*, 2020, 44(4): 1487-1499.
- [5] Houk J C, Buckingham J T, Barto A G. Models of the cerebellum and motor learning[J]. *Behavioral and Brain Sciences*, 1996, 19(3): 368-383.
- [6] Schlerf J, Ivry R B, Diedrichsen J. Encoding of sensory prediction errors in the human cerebellum[J]. *The Journal of Neuroscience: The Official Journal of the Society for Neuroscience*, 2012, 32(14): 4913-4922.
- [7] Ito M. Error detection and representation in the olivo-cerebellar system[J]. *Frontiers in Neural Circuits*, 2013, 7: 1-8.
- [8] DeWolf T. Spiking neural networks take control[J]. *Science Robotics*, 2021, 6(58): eabk3268.
- [9] Lennon W, Hecht-Nielsen R, Yamazaki T. A spiking network model of cerebellar Purkinje cells and molecular layer interneurons exhibiting irregular firing[J]. *Frontiers in Computational Neuroscience*, 2014, 8: 157.
- [10] Medina J F, Garcia K S, Nores W L, et al. Timing mechanisms in the cerebellum: Testing predictions of a large-scale computer simulation[J]. *The Journal of Neuroscience: The Official Journal of the Society for Neuroscience*, 2000, 20(14): 5516-5525.
- [11] Yamazaki T, Nagao S. A computational mechanism for unified gain and timing control in the cerebellum[J]. *PLoS One*, 2012, 7(3): e33319.
- [12] Zahra O, Navarro-Alarcon D, Tolu S. Vision-based control for robots by a fully spiking neural system relying on cerebellar predictive learning[J/OL]. 2020, arXiv: 2011.01641.
- [13] Zhang H B, Li Y S, Guo Y P, et al. Control of pneumatic artificial muscles with SNN-based cerebellar-like model[J/OL]. 2021, arXiv: 2109.10750.
- [14] Luque N R, Garrido J A, Carrillo R R, et al. Adaptive cerebellar spiking model embedded in the control loop: Context switching and robustness against noise[J]. *International Journal of Neural Systems*, 2011, 21(5): 385-401.
- [15] Carrillo R R, Ros E, Boucheny C, et al. A real-time spiking cerebellum model for learning robot control[J]. *Bio Systems*, 2008, 94(1/2): 18-27.
- [16] 杨双鸣, 郝新宇, 王江, 等. 大规模类脑计算系统 BiCoSS: 架构、实现及应用[J]. *自动化学报*, 2021, 47(9): 2154-2169.
(Yang S M, Hao X Y, Wang J, et al. Large-scale brain-inspired computing system BiCoSS: Its architecture, implementation and application[J]. *Acta Automatica Sinica*, 2021, 47(9): 2154-2169.)
- [17] Carrillo R R, Ros E, Boucheny C, et al. A real-time spiking cerebellum model for learning robot control[J]. *Bio Systems*, 2008, 94(1/2): 18-27.
- [18] Tsmots I, Skorokhoda O, Rabyk V. Hardware implementation of sigmoid activation functions using FPGA[C]. *IEEE 15th International Conference on the Experience of Designing and Application of CAD Systems. Polyana*, 2019: 34-38.
- [19] Mahowald M. VLSI analogs of neuronal visual processing: A synthesis of form and function[Z]. 1992.
- [20] D'Angelo E, de Filippi G, Rossi P, et al. Synaptic excitation of individual rat cerebellar granule cells in situ: Evidence for the role of NMDA receptors[J]. *The Journal of Physiology*, 1995, 484 (2): 397-413.
- [21] Jaeger D, de Schutter E, Bower J M. The role of synaptic and voltage-gated currents in the control of Purkinje cell spiking: A modeling study[J]. *The Official Journal of the Society for Neuroscience*, 1997, 17(1): 91-106.
- [22] D'Angelo E, Nieuwenhuis T, Maffei A, et al. Theta-frequency bursting and resonance in cerebellar granule cells: Experimental evidence and modeling of a slow k^+ -dependent mechanism[J]. *The Journal of Neuroscience*, 2001, 21(3): 759-770.
- [23] Jaeger D. No parallel fiber volleys in the cerebellar cortex: Evidence from cross-correlation analysis between Purkinje cells in a computer model and in recordings from anesthetized rats[J]. *Journal of Computational Neuroscience*, 2003, 14(3): 311-327.
- [24] Zagrean L. Principles of neural science[J]. *Acta Endocrinologica: Bucharest*, 2014, 10(3): 529.
- [25] Yamazaki T, Tanaka S. A spiking network model for passage-of-time representation in the cerebellum[J]. *The European Journal of Neuroscience*, 2007, 26(8): 2279-2292.
- [26] Kan P L V, Gibson A R, Houk J C. Movement-related inputs to intermediate cerebellum of the monkey[J]. *Journal of Neurophysiology*, 1993, 69(1): 74-94.
- [27] Lapique L. Recherches quantitatives sur l'excitation électrique des nerfs traitée comme une polarisation[J]. *Journal de Physiologie et de Pathologie Generale*, 1970, 9: 620-635.
- [28] Eccles J C. *The cerebellum as a neuronal machine*[M]. Berlin: Springer, 2013: 116-155.
- [29] Luque N R, Garrido J A, Ralli J, et al. From sensors to spikes: Evolving receptive fields to enhance sensorimotor

- information in a robot-arm[J]. *International Journal of Neural Systems*, 2012, 22(4): 1250013.
- [30] Schrauwen B, van Campenhout J. BSA, a fast and accurate spike train encoding scheme[C]. *Proceedings of the International Joint Conference on Neural Networks*. Portland, 2003: 2825-2830.
- [31] D'Angelo E, Mapelli L, Casellato C, et al. Distributed circuit plasticity: New clues for the cerebellar mechanisms of learning[Z]. London, 2016.
- [32] Hansel C, Linden D J, D'Angelo E. Beyond parallel fiber LTD: The diversity of synaptic and non-synaptic plasticity in the cerebellum[J]. *Nature Neuroscience*, 2001, 4(5): 467-475.
- [33] Garrido J A, Luque N R, D'Angelo E, et al. Distributed cerebellar plasticity implements adaptable gain control in a manipulation task: A closed-loop robotic simulation[J]. *Frontiers in Neural Circuits*, 2013, 7: 159.
- [34] Mapelli L, Pagani M, Garrido J A, et al. Integrated plasticity at inhibitory and excitatory synapses in the cerebellar circuit[J]. *Frontiers in Cellular Neuroscience*, 2015, 9: 169.
- [35] Medina J F, Mauk M D. Simulations of cerebellar motor learning: Computational analysis of plasticity at the mossy fiber to deep nucleus synapse[J]. *The Journal of Neuroscience: The Official Journal of the Society for Neuroscience*, 1999, 19(16): 7140-7151.
- [36] Masuda N, Amari S I. A computational study of synaptic mechanisms of partial memory transfer in cerebellar vestibulo-ocular-reflex learning[J]. *Journal of Computational Neuroscience*, 2008, 24(2): 137-156.
- [37] Luque N R, Garrido J A, Naveros F, et al. Distributed cerebellar motor learning: A spike-timing-dependent plasticity model[J]. *Frontiers in Computational Neuroscience*, 2016, 10: 17.
- [38] Ito M. Synaptic plasticity in the cerebellar cortex and its role in motor learning[J]. *The Canadian Journal of Neurological Sciences Le Journal Canadien Des Sciences Neurologiques*, 1993, 20(3): S70-S74.
- [39] Pisotta I, Molinari M. Cerebellar contribution to feedforward control of locomotion[J]. *Frontiers in Human Neuroscience*, 2014, 8: 475.
- [40] Ito M. Control of mental activities by internal models in the cerebellum[J]. *Nature Reviews Neuroscience*, 2008, 9(4): 304-313.
- [41] Zhang Z J, Lin Y J, Li S, et al. Tricriteria optimization-coordination motion of dual-redundant-robot manipulators for complex path planning[J]. *IEEE Transactions on Control Systems Technology*, 2018, 26(4): 1345-1357.
- [42] Van M, Do X P, Mavrovouniotis M. Self-tuning fuzzy PID-nonsingular fast terminal sliding mode control for robust fault tolerant control of robot manipulators[J]. *ISA Transactions*, 2020, 96: 60-68.
- [43] Lavín-Delgado J E, Solís-Pérez J E, Gómez-Aguilar J F, et al. Trajectory tracking control based on non-singular fractional derivatives for the PUMA 560 robot arm[J]. *Multibody System Dynamics*, 2020, 50(3): 259-303.
- [44] Walther J S. A unified algorithm for elementary functions[C]. *Proceedings of the Spring Joint Computer Conference*. Atlantic, 1971: 379-385.
- [45] Piltan F, Yarmahmoudi M H, Shamsodini M, et al. PUMA-560 robot manipulator position computed torque control methods using Matlab/Simulink and their integration into graduate nonlinear control and Matlab courses[J]. *International Journal of Robotics and Automation*, 2012, 3(3): 167-191.
- [46] Akkar H, Haddad S. Design stable controller for PUMA 560 robot with PID and sliding mode controller based on PSO algorithm[J]. *International Journal of Intelligent Engineering and Systems*, 2020, 13(6): 487-499.
- [47] Haghiri S, Zahedi A, Naderi A, et al. Multiplierless implementation of noisy izhikevich neuron with low-cost digital design[J]. *IEEE Transactions on Biomedical Circuits and Systems*, 2018, 12(6): 1422-1430.
- [48] Petro B, Kasabov N, Kiss R M. Selection and optimization of temporal spike encoding methods for spiking neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 31(2): 358-370.
- [49] Miall R C, Reckess G Z, Imamizu H. The cerebellum coordinates eye and hand tracking movements[J]. *Nature Neuroscience*, 2001, 4(6): 638-644.

作者简介

郝新宇(1995—), 男, 博士生, 从事类脑智能及系统的研究, E-mail: haoxy@tju.edu.cn;

王江(1964—), 男, 教授, 博士生导师, 从事智能穿戴脑功能与神经疾病探测等研究, E-mail: jiangwang@tju.edu.cn;

邓斌(1979—), 男, 教授, 博士生导师, 从事类脑智能与类脑决策及类脑感知系统等研究, E-mail: dengbin@tju.edu.cn;

于海涛(1985—), 男, 副教授, 博士生导师, 从事视觉检测、深度学习等研究, E-mail: htyu@tju.edu.cn;

伊国胜(1986—), 男, 副教授, 博士, 从事神经系统建模与非线性分析等研究, E-mail: guoshengyi@tju.edu.cn.

(责任编辑: 郑晓蕾)