

基于双向长短时记忆神经网络的步态时空参数脑肌电解码方法

魏鹏娜, 马鹏程, 张进华, 洪军

(西安交通大学现代设计与转子轴承系统教育部重点实验室, 710049, 西安)

摘要: 针对脑电(EEG)信号对连续步态轨迹解码结果与实际轨迹相关性低的问题,提出一种基于双向长短时记忆(BiLSTM)神经网络的步态参数解码方法。首先,构建基于双向长短时记忆神经网络的步态时空参数解码模型,根据脑肌电信号特性设计解码模型的超参数;其次,同步采集脑电、下肢运动相关肌肉的表面肌电信号(sEMG)和下肢关节运动信号,并对脑电和表面肌电信号的步态相关特征进行分析;然后,以多通道脑电和下肢运动相关表面肌电信号作为解码模型的输入,自动提取脑肌电融合信号中步态相关特征并构建膝关节运动轨迹与特征之间的非线性回归模型;最后,以多通道脑电作为解码模型的输入,构建步态相关脑电信号和表面肌电信号之间的非线性回归模型。实验结果表明:所提方法与传统支持向量机方法相比,对踝关节解码轨迹与实测轨迹形状相似性 Pearson 相关系数提高了 0.12;与单独采用脑电、表面肌电信号和脑肌电信号平均绝对值特征融合信号进行解码方法相比,对踝关节解码轨迹与实测轨迹形状相似性 Pearson 相关系数分别提高了 0.81、0.19 和 0.63。该方法可实现从脑电信号中对部分表面肌电信号波形的解码,解码波形和实测波形的平均 Pearson 相关系数值接近 0.5,证明从脑电信号中可解码出肌肉通道的表面肌电信号波形,为下肢外骨骼主动连续控制的应用提供了新思路。

关键词: 脑电;表面肌电;双向长短时记忆神经网络;步态时空参数解码;Pearson 相关系数

中图分类号: TP242 **文献标志码:** A

DOI: 10.7652/xjtub202209015 **文章编号:** 0253-987X(2022)09-0142-09



OSID 码

EEG and sEMG Decoding of Gait Spatiotemporal Parameters Based on Bidirectional Long Short-Term Memory Neural Network

WEI Pengna, MA Pengcheng, ZHANG Jinhua, HONG Jun

(Key Laboratory of Education Ministry for Modern Design and Rotor-Bearing System,
Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To solve the problem of low correlation between continuous gait trajectory decoding results and actual trajectory by electroencephalography (EEG) signals, a gait parameter decoding method based on bidirectional long short-term memory (BiLSTM) neural network is proposed. Firstly, a gait spatiotemporal parameter decoding model based on this neural network is constructed, and the hyperparameters of the decoding model are designed according to the characteristics of EEG and surface electromyography (sEMG). Secondly, EEG, lower limb

movement-related sEMG and lower limb joint movement signals are collected synchronously, and gait features of EEG and sEMG signals are analyzed. Thirdly, multi-channel EEG and lower limb movement-related sEMG signals are used as input of the decoding model, and gait related features are extracted automatically from EEG and sEMG fusion signals, and the nonlinear regression model between ankle joint motion and gait related features is constructed. Finally, a nonlinear regression model between gait related EEG signals and sEMG signals is constructed with multi-channel EEG as the input of the decoding model. The results show that compared with traditional support vector machines, the Pearson correlation coefficient of shape similarity between decoded trajectory and measured trajectory is improved by 0.12. Compared with the decoding methods using EEG, sEMG and fusion average absolute value of EEG-sEMG, the proposed method improves the Pearson correlation coefficient of shape similarity between decoded trajectory and measured trajectory by 0.81, 0.19 and 0.63, respectively. Our decoding method can realize decoding of part of sEMG waveform, the average Pearson correlation coefficient of decoded waveform and measured waveform is close to 0.5. It shows that the sEMG signals can be decoded from EEG signal which provides a new idea for the application of active continuous control of lower extremity exoskeleton

Keywords: electroencephalography; surface electromyography; bidirectional long short-term memory; gait spatiotemporal parameter decoding; Pearson correlation coefficient

下肢外骨骼机器人是可用于帮助运动功能障碍患者行走和恢复运动功能、提高老年人运动能力、增强体力劳动者和士兵负载强度和耐力的可穿戴人机一体化辅助装置^[1-3]。与智能假肢不同,外骨骼需要与人体融合,感知人体的运动意图,从而以一定的方式配合穿戴者完成特定动作^[4]。对于下肢外骨骼而言,步态的分析和识别是其完成人体运动意图感知和预测的关键环节。对穿戴者运动意图的精确感知,是外骨骼配合穿戴者完成目标运动的首要条件,也是解决人机协调问题的关键技术^[5-6]。患者通过自身意图对外骨骼进行控制,一方面可以提高患者的参与度和积极性,另一方面可以促进大脑的可塑性^[7]。目前,用于下肢外骨骼的步态信息形式包括:足底压力、加速度、关节运动角度^[8]、脑电(electroencephalography, EEG)、表面肌电信号(surface electromyography, sEMG)等^[9-11]和多模态信号融合等^[12-13]。基于步态相位和运动模式识别^[4]的离散控制方式,存在运动不平稳、步态连续性差等问题,为了实现对外骨骼步态的连续、平滑控制,步态轨迹的连续解码对下肢外骨骼的发展至关重要。

目前对连续步态轨迹解码的研究有基于 EEG 信号、sEMG 信号和关节运动学数据等,比如休斯顿大学的 Nakagome 等^[14]利用 EEG 信号对下肢关节的运动角度进行解码。杜克大学利用恒河猴的侵入式脑电信号对下肢关节三维运动位移、肌电信号、步

长等运动信息进行解码^[15]。哈尔滨工业大学的研究人员利用 sEMG 信号和惯性测量单元的数据对下肢关节运动角度等进行预测^[16]。然而,基于 EEG 信号的步态运动轨迹预测相关性较低,难以达到实际应用的程度。侵入式脑电信号采集方式对人体伤害性较大,难以广泛应用。基于 sEMG 和惯性测量单元数据的步态预测,由于惯性测量单元所测量的数据属于运动学数据,将其与 sEMG 信号融合对运动学数据进行预测,很难评价 sEMG 的解码能力。

本研究设计双向深度长短时记忆神经网络模型(bidirectional long short term memory, BiLSTM),利用深度学习模型自动提取运动相关频段 sEMG 和 EEG 的特征,实现对膝关节和髋关节运动时空参数的连续解码,实现了基于双信号模式的,下肢关节运动时空参数的连续精确解码;利用 sEMG 和 EEG 的相关关系,设计基于 BiLSTM 的 EEG 解码 sEMG 信号的神经网络模型。

1 BiLSTM 神经网络结构设计

LSTM 是在递归神经网络(recurrent neural network, RNN)的基础上发展而来,该算法是为了解决 RNN 梯度消失和梯度爆炸的问题。通过选择性记忆和忘记, LSTM 可解决对有时序关系的时间序列的长时记忆问题。下肢运动中的 sEMG 和 EEG 信号属于有序时间序列,可采用 LSTM 对其

进行分析^[17,8]。LSTM 神经网络一个神经元包含网络的当前输入信号 x^t (该信号在本文中为 EEG 和 sEMG 融合信号或单独的 EEG 信号), 上一时刻隐含状态 h^{t-1} , 遗忘门控信号 z^f , 选择性记忆门控信号 z^i , 输出门控信号 z^o , 新的输入信号 x 。3 个门控信号是由 x^t 和 h^{t-1} 的拼接矩阵乘以权重再通过 σ 激活函数转换为 0 到 1 之间的数值, 其计算方法分别如式(1)~(3)所示, 新的输入信号 x 由 x^t 和 h^{t-1} 的拼接矩阵乘以权重再通过 $\tanh$ 激活函数转换为 -1 到 1 之间的数值, 计算方法如式(4)所示

$$z^f = \sigma(W^f[x^t, h^{t-1}]) \quad (1)$$

$$z^i = \sigma(W^i[x^t, h^{t-1}]) \quad (2)$$

$$z^o = \sigma(W^o[x^t, h^{t-1}]) \quad (3)$$

$$x = \tanh(W[x^t, h^{t-1}]) \quad (4)$$

式中: σ 和 $\tanh$ 是激活函数; W 、 W^f 、 W^i 、 W^o 是权重矩阵; x^t 为当前输入的用于解码的信号; h^{t-1} 为上一时刻隐含状态。

LSTM 的执行过程主要包括以下几个步骤: 首先, 是遗忘阶段, 对传入的上一时刻的细胞状态 c^{t-1} 通过遗忘门 z^f 进行选择性的忘记, 记住重要的信息, 对不重要的信息进行遗忘。其次, 是选择性记忆阶段, 首先对网络的当前的输入信号 x^t 和网络的上一时刻的隐藏状态 h^{t-1} 进行拼接, 乘以权重并通过 $\tanh$ 激活函数转换为新的输入信号 x , 再通过记忆门控单元 z^i 进行选择性的记忆, 记住重要的输入信息。前两个阶段的计算如下式所示

$$c^t = z^f \odot c^{t-1} + z^i \odot x \quad (5)$$

式中: c^{t-1} 为上一时刻细胞状态; z^f 、 z^i 、 z^o 分别为遗忘、选择性记忆和输出门控信号; x 为新的输入信号; $\odot$ 运算表示对两个矩阵中的对应元素进行相乘操作。

最后, 是输出阶段, 决定哪些信息将输入下一个状态, 将当前细胞状态经过 $\tanh$ 激活函数转换后通过门控信号 z^o 进行控制, 计算过程如下式所示

$$h^t = z^o \odot \tanh(c^t) \quad (6)$$


$$y^t = \sigma(W^o h^t) \quad (7)$$

式中: σ 和 $\tanh$ 是激活函数; W 是权重矩阵; c^t 为当前时刻细胞状态。当前状态的输出 y^t 由当前隐含状态 h^t 计算得到, 计算过程如下式所示

$$y^t = \sigma(W^o h^t) \quad (8)$$

式中 h^t 保存了当前时刻隐含状态, 具有短期记忆功能。 c^t 综合了当前输入和前一时刻的状态信息, 可保存长期的状态, 因此该神经网络被称为长短时记忆神经网络, LSTM 神经网络一个神经元的结构如

图 1 所示。



⊕—两个矩阵相加。

图 1 神经元结构

Fig. 1 Neuronal structure

LSTM 神经网络利用过去的信息进行信号的分析, 而 BiLSTM 神经网络在 LSTM 的基础上加入未来的信息。BiLSTM 的运算如图 2 所示。在前向计算的基础上加入反向计算 (不是反向传播), 将未来的信息加入当前状态的计算, 比如 $t+1$ 时刻的信息 x^{t+1} 传入 t 时刻, 参与该时刻细胞状态的计算。本文将建立面向步态时空参数解码的 BiLSTM 神经网络模型, 对膝关节和踝关节的步态时空参数进行解码。LSTM 神经网络模型的结构包括一个输入层、两个 LSTM 层、两个全连接层和一个输出层, 其中输入层包含的节点个数和输入的信号特征个数相等, 每个 LSTM 层包含一个 dropout 层, 参数设置为 0.5, 即随机丢弃概率为 0.5, 其作用是防止数据过拟合。为防止梯度爆炸, 将梯度阈值设置为 1, LSTM 层的隐含单元个数为 200, 训练样本最大迭代次数设置为 100, 采用 adam 优化器对训练过程进行优化, 学习率即步长设置为 0.01, 并设置验证集, 对训练过程进行校验。由于研究的数据为连续的信号对连续运动轨迹的解码, 因此选择序列到序列 (sequence-to-sequence) 的回归方式。BiLSTM 神经网络模型在 LSTM 结构的基础上增加了 BiLSTM 层, 隐含单元个数为 200。




图 2 BiLSTM 运算过程

Fig. 2 The operation process of BiLSTM

2 步态时空参数的脑肌电解码

2.1 下肢 sEMG 和 EEG 信号采集实验范式

人类的下肢运动意图由大脑运动相关皮层发起,由脑干控制执行过程,受小脑、丘脑和基底神经节的调节,由大脑皮层产生的动作电位通过神经-肌肉接头传入骨骼肌中并形成终板电位,当终板电位达到一定阈值后,会在肌细胞中产生强大的肌细胞动作电位,随着动作电位的传播,肌浆网释放钙离子,根据肌丝滑行理论,细肌丝沿着粗肌丝滑行,实现肌肉收缩,完成相应的动作,如图 3 所示,为运动的产生和执行通路。在运动意图产生和传播过程中,所产生的 EEG 和 sEMG 信号真实记录了整个运动过程的发生。因此,为了全面描述步态的真实过程,下肢运动实验对匀速行走时,运动皮层 EEG、运动相关肌肉 sEMG 和下肢关节三维运动轨迹进行同步采集。EEG 和 sEMG 信号的同步,通过 Brain Products 公司的无线 32 导运动状态下脑肌电同步采集设备,该设备是为运动中 EEG 和 sEMG 信号采集所设计,并通过设备自带的同步核实现和 Vicon 系统的同步,从而实现对下肢运动学数据的同步采集。




图 3 运动的产生和执行通路

Fig. 3 Pathways of movement generation and execution

实验招募了 7 名来自西安交通大学的健康研究生,平均年龄为 24 岁,由于本次实验为短期实验,短期实验对象个数为 7~12,因此本次实验被试人数在合理范围内。实验所有程序均经西安交通大学伦理委员会批准,且符合 1975 年赫尔辛基宣言的相关规定,实验前所有被试均签署了知情同意书。在进

行步态相关实验时,采集 EEG 和下肢肌肉 sEMG 信号时,每位被试按照自己日常习惯行走,尽量保证步态协调,不要产生过大的加速度,特别是在步态实验中,被试除了下肢运动外,身体其他部位尽量不要做过多的运动,尽量减少肌电的干扰。比如,尽量不要做转头、低头等动作,以减少颈部肌肉对 EEG 信号的影响,同时尽量避免频繁眨眼,以减少眼电干扰。在实验过程中,被试尽量减少咀嚼、吞咽动作和夸张的面部表情等,并保持注意力集中,以免在其他大脑皮层产生与运动无关的 EEG 信号,干扰运动区的 EEG 信号。脑电帽佩戴要符合规范,紧贴头皮,以防止脑电帽电极的滑动引起 EEG 信号的干扰。每位被试在跑步机上以自己舒适的速度行走,经过 7 名被试的反馈,最终综合确定最佳速度为 2.0 km/h。

为采集与下肢运动最相关肌肉的 sEMG 信号,通过查阅相关的国内外文献和欧洲发布的用于非侵入式肌肉评价的 sEMG 信号采集计划(surface electromyography for the non-invasive assessment of muscles, SENIAM)(www.seniam.org)的内容,本实验对左右腿的股二头肌(biceps femoris, BF)、股内侧肌(vastus medialis, VM)、内侧腓肠肌(gastrocnemius medialis, GM)和胫骨前肌(tibialis anterior, TA)8 块肌肉的 sEMG 信号进行采集,单腿 4 块肌肉的作用如表 1 所示,肌肉位置如图 4 所示。

表 1 下肢肌肉名称及其作用

Table 1 Lower limb muscles and their role	
下肢肌肉名称	在运动中的作用
BF	膝关节的屈曲和侧旋,长头还可以伸展并帮助髋关节的侧旋
VM	伸膝
GM	屈曲踝关节和协助屈曲膝关节
TA	屈曲踝关节和协助屈曲膝关节




图 4 肌肉位置

Fig. 4 The positions of the muscles

实验过程中,首先,被试在平地上站立 30 s,采集静息态下的 EEG、sEMG 信号和关节的运动数据,用于运动学模型的校正。其次,等待跑步机以

2.0 km/h 的速度运行正常后,被试在跑步机上匀速行走 30 s 为一组,每组中间休息 10 s,采集 15 组后,完成整个步态信息采集实验。保证整个实验中对时间严格要求,被试状态良好,注意力集中。

2.2 实验平台搭建

根据设计的下肢运动实验范式,搭建下肢运动数据采集实验平台。实验台硬件设备主要包括:Brain Products 公司的 32Ch LiveAmp 脑电帽、LiveAmp 无线放大器和同步核、三维步态分析系统 Vicon T40S、跑步机和计算机等;数据采集软件包括:Recorder 脑机电数据采集软件、Analyzer 2.0 脑机电数据分析软件、Nexus 2.6 下肢关节运动轨迹捕捉与数据处理软件。

实验采用的无线脑机电同步采集系统由脑电采集帽、肌电采集电极、无线放大器和同步核组成,脑电帽的电极位置按照 10-20 国际标准分布。LiveAmp 放大器是针对运动 EEG 信号采集设计的,LiveAmp 的记录特性可与高端实验室脑电图系统相比,24 位 A/D 转换,可同时对 EEG 和 sEMG 信号进行采集,内置三轴加速度计,可用于后续对运动伪迹的去除。实验开始前,被试者头戴脑电帽,脑电帽的绝缘电缆线一端与脑电帽相连,另一端与信号放大器相连,放大器与计算机 USB 接口相连,并通过其供电和传输数据,不需要任何的特殊接口或特殊电源供应。计算机上的 Recorder 采集系统实时采集并保存被试 24 导 EEG 信号(Fp1,Fp2,F3,F4,C3,C4,P3,P4,O1,O2,F7,F8,T7,T8,P7,P8,Fz,Cz,Pz,Oz,M1,M2,FPz 和 VEOG,其中 VEOG 为水平眼电信号)和左右腿共 8 个肌肉通道的 sEMG 信号,采样频率为 500 Hz。分别将 Vicon 反光球贴在左和右下肢的髌前上棘、髌后上棘、大腿、膝关节、胫骨(小腿)、踝关节、脚后跟、脚趾共 16 个位置上,采用 10 个摄像头捕捉反光球的运动轨迹,采样频率为 100 Hz。


2.3 sEMG 和 EEG 信号预处理

由于实验中采用的 LiveAmp 无线放大器和三维步态分析系统 Vicon T40S 的采样频率不一致,同时考虑到增加序列长度(单个步态阶段的数据点数)可以丰富脑电信号或表面肌电信号的特征信息,因此将重采样频率设为 1 000 Hz。实验中采用的电极帽,其参考电极位于额叶区和中央区之间,不符合参考电极的标准:参考电极的活动尽量降到最低,以获得最真实的基线(近似零)信号。因此,FCz 通道不适合作为参考信号,本文选择双侧耳后乳突 M1


和 M2 的平均值作为新参考。眼球运动会改变眼睛周围电场分布,而眼睛又十分靠近头皮,所以对头皮表面电场分布影响很大。眼动伪迹频率范围与 EEG 频率重叠,且幅值较大,是 EEG 采集中的一种主要干扰。独立成分分析(independent component analysis,ICA)分析方法可用于从多个源信号线性混合的信号中分离出源信号,算法首先会找到一个映射,使混合信号通过该映射后投影分量在时间上重叠的最小,因此引入眼电相关 ICA 对初始信号中的眼电进行分离。下肢运动带来的运动伪迹,对 EEG 的影响较大,可利用 EEGLAB 工具箱中的伪迹子空间重构(artifact subspace reconstruction,ASR)算法进行处理。ASR 将主成分分析应用于 EEG 数据,识别出与包含最小运动伪影的基线数据显著偏离的 EEG 通道,再与基线数据相比,方差高于预定义阈值的通道被识别为受干扰的通道,并使用从基线数据计算的混合矩阵进行重构^[18-19]。经过以上分析,可分别去除和眼电、运动相关性最高的成分^[20-21]。

2.4 sEMG 和 EEG 信号运动相关特征提取

运动相关的频段主要分布在低频部分。Presacco 等的研究表明^[22],运动学信号频率小于 3 Hz 部分占总功率谱密度的 90%,因此对 sEMG、EEG 和运动信号进行 1~3 Hz 的带通滤波。事件相关谱扰动(event related spectral perturbation,ERSP)^[23]可对 EEG 信号进行时频分析,利用 ERSP 对行走时 EEG 信号的能量谱进行分析,验证 EEG 用于步态解码的可行性。如图 5 所示,图 5(a)为一个步态周期 C3 通道 EEG 信号 ERSP 分析结果,图 5(b)为滤波后 EEG、sEMG 信号和踝关节运动轨迹。从图 5(a)中可观察到,一个步态周期 EEG 信号的 1~3 Hz 频段(红框部分)包含充分的信息,比如在步态周期前 50%,有两个时段大脑活动受到抑制,说明在这两个时段大脑参与行走运动^[24]。从图 5(b)中可观察到,滤波后 sEMG 信号和 EEG 信号



(a)EEG 信号事件相关谱扰动分析



(b)滤波后的 EEG、sEMG 和关节运动信号

图 5 EEG 信号事件相关谱扰动分析与滤波后 EEG、sEMG 和关节运动信号

Fig. 5 ERS analysis of EEG and the filtered EEG, sEMG signals, and ankle trajectory

中出现部分与踝关节运动相关的波形,特别是 sEMG 信号的波形与踝关节的运动轨迹相关的波形更多。

sEMG、EEG 和运动信号信号特征提取和解码器训练过程如图 6 所示。首先对右腿 4 个肌肉通道的 sEMG 信号、21 个通道的 EEG 信号和右脚踝、膝关节的运动轨迹进行带通滤波,滤波频率为 1~3 Hz,然后将 sEMG 和 EEG 信号和关节运动数据分别分为训练集、测试集和验证集,3 个数据集的比例为 6:2:2。由于下肢运动是由拮抗肌肉的激活产生的,因此需要提取能够代表这种拮抗作用的特征,以提高步态的连续解码精度。为了解决这一问题,采用 BiLSTM 神经网络自动提取 sEMG 和 EEG 信号的运动相关特征。在所有的深度学习算法中,BiLSTM 由于增加了遗忘门,可以对记忆的信息进行选择性遗忘,从而对长时依赖信号的分析方面有显著优势。为了验证该算法在利用 EEG 和 sEMG 信号对步态解码的优势,本文将对采用 BiLSTM 神经网络和支持向量机神经网络(support vector machine, SVM)^[25]的步态解码结果进行对比分析,SVM 分类算法可实现对离散动作的识别,回归算法可实现对连续轨迹的拟合,是一种常用的生物电信号分析机

器学习算法。本文采用 BiLSTM (200-100)对非平稳 sEMG 和 EEG 信号进行特征提取,数据的标签设置为下肢关节运动位移数据,在误差反向传播阶段,需要根据预测结果和标签的数据之间的误差对训练过程进行调节。

3 步态时空参数解码结果

3.1 基于 sEMG 和 EEG 的步态时空参数解码

对于多种模式信息的融合,主要有数据层、特征层和决策层 3 种方式。数据层的融合方式可以最大程度的保留各种融合信号的信息;特征层融合方式是在提取每种融合信号的特征后,将融合后的特征输入判别器进行分析;决策层的融合方式是对每种信号的判别结果采用特定规则进行融合。由于 BiLSTM 神经网络模型的特征提取由网络自动进行的,不需要采用特征层融合方式,但为了和数据层融合策略的解码结果进行对比,提取 sEMG 和 EEG 信号的平均绝对值(mean absolute value, MAV)特征并进行融合作为 BiLSTM 神经网络输入信号,决策层融合方式丢失信息过多,因此本次研究不进行分析。本文采用数据层的 sEMG 和 EEG 融合方式对步态时空参数进行解码,将右腿 4 个肌肉通道的 sEMG 信号和 21 个通道的 EEG 信号,组成数据矩阵输入 BiLSTM 神经网络模型中,在模型中自动进行特征提取和回归分析。

sEMG 和 EEG 融合信号的膝关节和踝关节运动轨迹解码结果和模型训练过程中误差的变化如图 7 所示,随着模型迭代次数的增加,模型误差 RMSE 逐渐减小,最终趋于稳定,说明该模型对步态解码效果较好,迭代次数选择较合理。从解码的轨迹和实测轨迹的对比中,可看到 sEMG 和 EEG 融合信号解码的轨迹与实测信号轨迹虽然形状较相似,但解码出的轨迹幅值存在一定误差。可能的原因是 sEMG 和 EEG 信号幅值的差异较大,导致解码出的运动轨迹形状相似性较高,但幅值在波峰和波谷处存在误差,后续研究可在通过对信号进行归一化处理或者针对不同类型信号引入调节参数进行处理。sEMG-EEG 融合信号解码轨迹和实际轨迹的 Pearson 相关系数 R 和均方根误差 RMSE 如表 2 所示。从表中可看到,sEMG-EEG 融合信号的解码轨迹和实际轨迹的 Pearson 相关系数 R 超过 0.9,说明他们形状相似度非常高,本文所提的步态时空参数解码策略可成功解码出下肢膝关节和踝关节的运动参数。




图 6 BiLSTM 特征提取和训练过程

Fig. 6 BiLSTM feature extraction and training process

表 2 EEG-sEMG 融合信号预测结果与关节实际轨迹 Pearson 相关系数 R 和均方根误差的平均值

Table 2 The mean value of Pearson correlation coefficient R and RMSE between the predicted results of EEG-SEMG fusion signal and the actual trajectory of joints

关节名称	R	均方根误差
膝关节	0.94 ± 0.04	3.70
踝关节	0.97 ± 0.02	8.65




图 7 右膝和踝关节步态轨迹预测结果和训练过程均方根误差变化

Fig. 7 Gait trajectory prediction results and RMSE changes during training of right knee and ankle joints

为了证明本文中所提 sEMG-EEG 融合信号对步态时空参数解码的效果,分别对单独的 sEMG 信号、EEG 信号和 sEMG-EEG 特征融合信号的步态轨迹解码进行分析,对踝关节轨迹解码结果如图 8 (a)、(b)和(c)所示。此外,对 sEMG-EEG 融合信号在分别采用 BiLSTM 神经网络和 SVM 神经网络的步态时空参数解码进行分析,结果如图 8(d)所示。图 8 中 4 种方法解码轨迹的 Pearson 相关系数 R 和均方根误差 RMSE 如表 3 所示。图 8 中的结果表明,采用单独的 sEMG 信号可解码出波峰处的轨迹(比如采样点 1 000 左右),但对次波峰处的解码轨迹误差较大(比如采样点 300 左右)。采样单独的 EEG 信号和 sEMG-EEG 特征融合信号的步态轨迹解码形状误差较大,从表 3 中可看到,二者解码出的轨迹 R 值都低于 0.5。采用 SVM 回归算法从

sEMG-EEG 融合信号中解码出的踝关节轨迹在波峰和波谷处出现高频振荡,形状相似性 R 值为 0.85 ± 0.02 ,与 BiLSTM 神经网络的解码结果相比,解码轨迹的形状相似性较低。综上所述,本文所提出的基于 sEMG-EEG 融合信号的 BiLSTM 神经网络步态时空参数解码策略效果最好。




图 8 不同解码方法下右踝关节步态轨迹预测结果

Fig. 8 Prediction results of right ankle gait trajectory under different decoding methods

表 3 不同解码方法下右踝关节实际轨迹与预测轨迹 Pearson 相关系数和均方根误差的平均值

Table 3 The average value of the Pearson correlation coefficient and the RMSE of the prediction trajectory of the trajectory of the right ankle

算法名称	输入信号	R	均方根误差
BiLSTM	MAV 特征	0.34 ± 0.11	21.69
	sEMG	0.78 ± 0.04	14.25
	EEG	-0.16 ± 0.26	21.86
SVM	sEMG+EEG	0.85 ± 0.02	8.95

3.2 基于 EEG 的行走时 sEMG 信号解码

行走时大脑皮层和下肢肌肉之间生理层面的相关性,为从 EEG 信号中解码 sEMG 信号提供了理论基础。BiLSTM 神经网络模型结构及参数设计与上述研究中的相同,将 21 个 EEG 通道信号作为 BiLSTM 神经网络模型输入,左腿 VM 肌肉通道的左腿 VM 肌肉通道的 sEMG 信号作为标签数据,对模型进行训练,以被试 1 为例对解码结果进行分析,其解码结果如图 9 所示。图中实测的曲线为实测

sEMG 信号经过 1~3 Hz 滤波后的波形图,可观察到在前 2 000 个采样点中,实测与解码的波形图形状相似性较高,2 000~2 500 这段解码波形出现两个波峰,实际波形只有一个波峰,其他时间段也存在类似的情况,整段解码波形和实际波形存在一定误差。解码波形与实际波形的平均 Pearson 相关系数 $R=0.45\pm0.02$,证明了形状相关性较低,可能是因为 EEG 信号中包含的步态信息不足以解码出 sEMG 信号中的步态成分(参考图 5(b))。后续可以通过设计新的实验方案以增加 EEG 信号中步态信息,比如在被试行走过程中增加行走运动想象。解码波形的平均 RMSE 为 2.03 ± 0.32 ,和解码关节运动轨迹时的 RMSE 值相比没有增加很多。这可能是因为 sEMG 信号的幅值相对关节运动的位移较小,因此尽管预测波形的误差较大,但其 RMSE 值依然较小。




图 9 sEMG 信号预测结果
Fig. 9 sEMG signal prediction results

4 总 结

本文通过构建基于 BiLSTM 神经网络模型的下肢膝关节和踝关节的运动轨迹连续解码模型,将 sEMG-EEG 融合信号作为神经网络的输入信号,解码轨迹与实测轨迹形状相似性较高(膝关节 $R=0.94\pm0.04$,踝关节 $R=0.97\pm0.02$),可实现对下肢踝关节运动参数的解码。与传统的 SVM 模型相比,对踝关节解码轨迹与实测轨迹形状相似性 Pearson 相关系数提高了 0.12;所提出的脑肌电融合方法比单独的脑电、表面肌电信号和脑肌电信号平均绝对值特征融合信号相比,对踝关节解码轨迹与实测轨迹形状相似性 Pearson 相关系数分别提高了 0.81、0.19 和 0.63。

在采用 BiLSTM 神经网络模型,从 EEG 信号中连续解码左腿 VM 肌肉通道的 sEMG 波形的研究中,虽然可解码出部分波形,但平均的形状相关性

较低,解码波形的 Pearson 相关系数 R 接近 0.5,说明 EEG 信号中存在和 sEMG 相似的运动模式。综上,研究证明从 EEG 信号中可解码出肌肉通道的 sEMG 信号波形,但还需进行深入研究相关的解码算法和增强 EEG 中运动信息,以改善解码精度。

参考文献:

[1] YOUNG A J, FERRIS D P. State of the art and future directions for lower limb robotic exoskeletons [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017, 25(2): 171-182.

[2] KAPSALYAMOV A, JAMWAL P K, HUSSAIN S, et al. State of the art lower limb robotic exoskeletons for elderly assistance [J]. IEEE Access, 2019, 7: 95075-95086.

[3] TARIQ M, TRIVAILO P M, SIMIC M. EEG-based BCI control schemes for lower-limb assistive-robots [J]. Frontiers in Human Neuroscience, 2018, 12: 312.

[4] 陈朝峰. 穿戴式下肢外骨骼系统设计与交互控制策略研究 [D]. 哈尔滨: 哈尔滨工业大学, 2020.

[5] GORDELEVA S Y, LOBOV S A, GRIGOREV N A, et al. Real-time EEG-EMG human-machine interface-based control system for a lower-limb exoskeleton [J]. IEEE Access, 2020, 8: 84070-84081.

[6] 杨灿军, 彭桢哲, 徐铃辉, 等. 柔性膝关节保护外骨骼及其行走助力方法设计 [J]. 浙江大学学报(工学版), 2021, 55(2): 213-221.

YANG Canjun, PENG Zhenzhe, XU Linghui, et al. Design of flexible knee-joint protection exoskeleton and walking assistance method [J]. Journal of Zhejiang University (Engineering Science), 2021, 55(2): 213-221.

[7] WINTER C, KERN F, GALL D, et al. Immersive virtual reality during gait rehabilitation increases walking speed and motivation: a usability evaluation with healthy participants and patients with multiple sclerosis and stroke [J]. Journal of NeuroEngineering and Rehabilitation, 2021, 18(1): 68.

[8] 陈超强, 蒋磊, 王恒. 基于 SAE 和 LSTM 的下肢外骨骼步态预测方法 [J]. 计算机工程与应用, 2019, 55(12): 110-116, 154.

CHEN Chaoqiang, JIANG Lei, WANG Heng. Gait prediction method of lower extremity exoskeleton based on SAE and LSTM neural network [J]. Computer Engineering and Applications, 2019, 55(12): 110-116, 154.

[9] RODRÍGUEZ-FERNÁNDEZ A, LOBO-PRAT J,

- FONT-LLAGUNES J M. Systematic review on wearable lower-limb exoskeletons for gait training in neuromuscular impairments [J]. *Journal of NeuroEngineering and Rehabilitation*, 2021, 18(1): 22.
- [10] 郝静涵. 基于 SEMG 信号及加速度信号的步态辨识研究 [D]. 天津: 河北工业大学, 2019.
- [11] 郭浩. 基于 EMG 的人体下肢运动意图感知与预测研究 [D]. 哈尔滨: 哈尔滨工业大学, 2019.
- [12] 李梦瑶. 基于多源神经信号融合的人体运动意图识别研究 [D]. 北京: 中国科学院大学, 2021.
- [13] 刘笃信. 下肢外骨骼机器人多模融合控制策略研究 [D]. 深圳: 中国科学院大学(中国科学院深圳先进技术研究院), 2018.
- [14] NAKAGOME S, LUU T P, HE Yongtian, et al. An empirical comparison of neural networks and machine learning algorithms for EEG gait decoding [J]. *Scientific Reports*, 2020, 10(1): 4372.
- [15] FITZSIMMONS N A, LEBEDEV M A, PEIKON I D, et al. Extracting kinematic parameters for monkey bipedal walking from cortical neuronal ensemble activity [J]. *Frontiers in Integrative Neuroscience*, 2009, 3: 3.
- [16] YI Chunzhi, JIANG Feng, BHUIYAN M Z A, et al. Smart healthcare-oriented online prediction of lower-limb kinematics and kinetics based on data-driven neural signal decoding [J]. *Future Generation Computer Systems*, 2021, 114: 96-105.
- [17] JIA LU, AI Qingsong, MENG Wei, et al. Individualized gait trajectory prediction based on fusion LSTM networks for robotic rehabilitation training [C]//2021 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM). Piscataway, NJ, USA: IEEE, 2021: 988-993.
- [18] DELORME A, MAKEIG S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis [J]. *Journal of Neuroscience Methods*, 2004, 134(1): 9-21.
- [19] CHOI J, KIM H. Real-time decoding of EEG gait intention for controlling a lower-limb exoskeleton system [C]//2019 7th International Winter Conference on Brain-Computer Interface (BCI). Piscataway, NJ, USA: IEEE, 2019: 1-3.
- [20] GWIN J T, GRAMANN K, MAKEIG S, et al. Electrocortical activity is coupled to gait cycle phase during treadmill walking [J]. *NeuroImage*, 2011, 54(2): 1289-1296.
- [21] WEI Pengna, ZHANG Jinhua, WANG Baozeng, et al. Surface electromyography and electroencephalogram-based gait phase recognition and correlations between cortical and locomotor muscle in the seven gait phases [J]. *Frontiers in Neuroscience*, 2021, 15: 607905.
- [22] PRESACCO A, GOODMAN R, FORRESTER L, et al. Neural decoding of treadmill walking from noninvasive electroencephalographic signals [J]. *Journal of Neurophysiology*, 2011, 106(4): 1875-1887.
- [23] SAXENA M, GUPTA A. Exploration of temporal and spectral features of EEG signals in motor imagery tasks [C]//2021 International Conference on Communication Systems & Networks (COMSNETS). Piscataway, NJ, USA: IEEE, 2021: 736-740.
- [24] SORIANO-SEGURA P, IANEZ E, ORTIZ M, et al. Detection of the intention of direction changes during gait through EEG signals [J]. *International Journal of Neural Systems*, 2021, 31(11): 2150015.
- [25] WEI Pengna, ZHANG Jinhua, TIAN Feifei, et al. A comparison of neural networks algorithms for EEG and sEMG features based gait phases recognition [J]. *Bio-medical Signal Processing and Control*, 2021, 68: 102587.

(编辑 荆树蓉 刘杨)