

完全预测下肢步行运动想象意图的可行性研究

周斌, 王宏, 李坦, 兰钦

(东北大学 机械工程与自动化学院, 辽宁 沈阳 110819)

摘要: 在下肢运动想象发生之前获取想象意图是为下肢神经康复系统提供精准控制策略的关键。为此,研究利用运动想象前的脑电图(electroencephalogram, EEG)信号完全预测下肢步行运动启停想象意图及其类型的可行性。对EEG信号进行预处理并提取运动相关皮质电位(movement-related cortical potential, MRCP)。基于MRCP挑选出具有明显可辨别性的15个通道。利用时间卷积网络模型从被选取的MRCP通道特征中解码出下肢步行运动想象意图和意图类型。结果表明,通过MRCP形态选取的EEG通道信号在启停意图和类别上均具有明显可分离差异,验证了只使用运动想象前EEG信号能够完全预测人类下肢运动启停意图和意图类型。

关键词: 脑电图;运动相关皮质电位;时间卷积网络;下肢步行运动想象意图;完全预测

中图分类号: R 318 文献标志码: A 文章编号: 1005-3026(2024)05-0609-10

Feasibility Study for Fully Prediction of the Movement Imagery Intention of Lower Limb Ambulation

ZHOU Bin, WANG Hong, LI Tan, LAN Qin

(School of Mechanical Engineering & Automation, Northeastern University, Shenyang 110819, China. Corresponding author: WANG Hong, E-mail: hongwang@mail.neu.edu.cn)

Abstract: Acquiring intentions before the start of lower limb movement imagery is the key issue in providing precise control strategies for the lower limb neurorehabilitation system. To this end, the feasibility of using electroencephalogram (EEG) signals prior to movement imagery to fully predict the movement imagery start-stop intention and intention types of lower limb ambulation is investigated. The EEG signal is pre-processed and the movement-related cortical potential (MRCP) is extracted. 15 channels with significant discriminability are selected based on MRCP. The temporal convolutional network models are used to decode the movement imagery intention and intention types of lower limb ambulation from the selected MRCP channel features. The results show that the EEG channel signals selected by MRCP morphology are with significant separable differences in both start-stop intention and intention types, verifying that using only pre-movement imagery EEG signals is capable of fully prediction the movement imagery start-stop intention and intention types of lower limb ambulation movement in humans.

Key words: electroencephalogram (EEG); movement-related cortical potential (MRCP); temporal convolutional network; movement imagery intention of lower limb ambulation; fully prediction

近年来,脑血管损伤、脑卒中和意外损伤等给许多患者带来不同程度的下肢运动障碍,同时伴随着我国日益严峻的老龄化,这不仅给下肢康复带来了质量考验,也带来了巨大的数量考验^[1]。因此,各种辅助性矫形器和假肢设备被开发出

来,以帮助运动能力下降的人提高生活质量^[2-3]。机械式传感器为下肢康复设备提供了良好的控制质量保障^[4]。随着诸如肌电图、脑电图等神经电信号检测技术的发展,通过解码肌肉神经意图的方式为下肢外骨骼提供自主的触发成为人们的关注

收稿日期: 2023-02-03

基金项目: 国家重点研发计划项目(2021YFF0306405)。

作者简介: 周斌(1994-),男,江西宜春人,东北大学博士研究生;王宏(1960-),女,辽宁沈阳人,东北大学教授,博士生导师。

点^[3,5-6]. 由于脑电图(electroencephalogram, EEG)信号可以作为下肢活动期间大脑活动的实时投影,基于 EEG 的下肢步行活动研究在实现运动意图的早期预测方面具有较大潜力,对成功的下肢康复具有重要意义. 研究人员可以随时利用 EEG 信号对运动障碍者进行更有效的康复.

在基于脑机接口(brain computer interface, BCI)的早期下肢神经康复系统中,基于运动想象(movement imagery, MI)的 EEG 信号被提取、预处理和解码以控制辅助设备. 对于一个成功的辅助系统来说,尽早检测 MI 意图以提供系统足够的时间来适应个人的自主要求是至关重要的^[7]. 文献[8]表明,与 MI 意图检测有关的两个神经特征分别是运动相关皮质电位(movement-related cortical potential, MRCP)以及与时频分析有关的事件相关同步化/去同步化(event-related synchronization/event-related desynchronization, ERS/ERD). MRCP 提供了关于运动计划和运动执行阶段的不同时序信息,它是一种变化细微的波形,需要多次重复实验才能从 MRCP 中提取有用和可靠的运动相关信息. 事件相关去同步化(event-related desynchronization, ERD)已被证明可以从单次实验的 EEG 中检测出来,但不能提供关于运动计划、准备和执行阶段的精确时间信息. 目前关于运动的神经解码研

究^[9-10]通常使用运动开始和运动结束前后的 EEG 信号,或者使用大部分运动前的 EEG 数据以获得适当的基线信息. 这为在线 BCI 系统中实现完全预测 MI 意图带来了阻碍.

在 MI 开始或结束前检测下肢步行 MI 意图是基于在线 BCI 的早期康复系统一个非常关键的特性. 下肢 MI 意图和意图类型的早期和准确检测将为 BCI 系统提供充足且必要的时间来验证预测意图和意图类型的真实性并调整相应辅助设备的参数,从而确保安全和自然的下肢康复^[11-12]. 因此,本研究将探讨仅从“运动开始”想象和“运动结束”想象前 EEG 数据预测自主下肢 MI 意图和意图类型的可行性.

1 实验设计与协议

1.1 实验设计

本实验系统是基于 OpenBCI 脑电采集传感器(美国脑机接口 OpenBCI 公司)、16 导联的泰诺康弹力网状脑电帽和带有屏幕提示的电脑(MECHREVO, GTX 1050Ti GPU)而二次开发搭建的,如图 1 所示. 参照国际标准 10/20 导联系统选取 15 个电极^[13]: F3, Fz, F4, FC3, FCz, FC4, C3, Cz, C4, CP3, CPz, CP4, P3, Pz 和 P4, 两个参考电极位于双侧乳突处,且使用导电膏确保所有电极的阻抗低于制造商推荐的值.

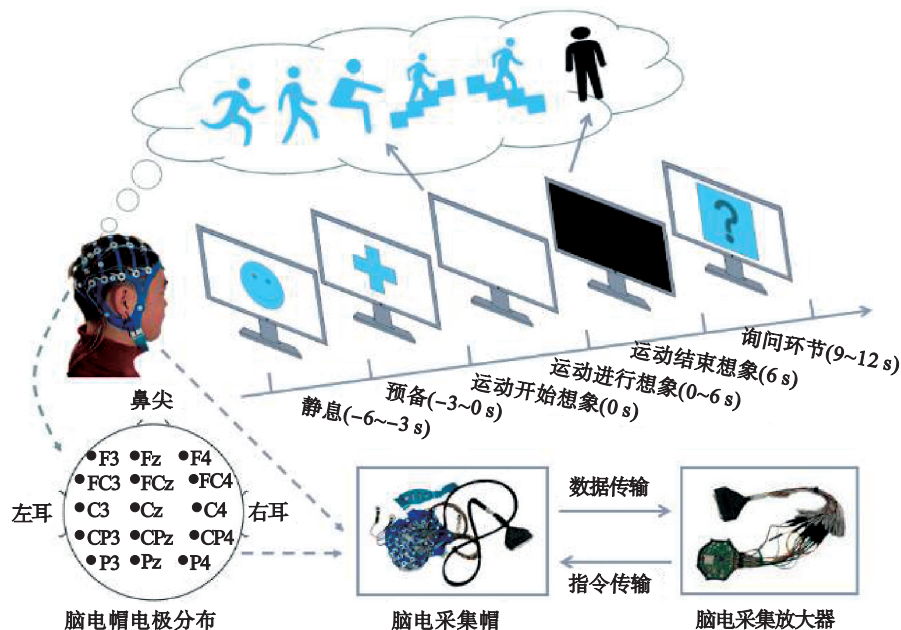


图 1 实验系统及实验示意图

Fig. 1 Experimental system and schematic diagram of experiment

整个实验平台的软件包含 OpenBCI 采集软件、基于 LSL (lab stream layer) 协议和 MATLAB 自主开发的标记软件、LabRecorder 数据记录软

件. OpenBCI 软件用于采集和实时监测脑电信号,采样频率选为 500 Hz. 自主开发的标记软件主要用于标记“运动开始”想象和“运动结束”想

象,以及想象的下肢运动类型. LabRecorder软件用于同步记录保存脑电数据和事件标记数据.

1.2 实验协议

9名经过招募且健康的被试者(6男、3女)参与这次实验,年龄为22~28岁,无任何药物依赖史、吸毒史、酗酒史以及与下肢运动有关的神经损伤史,且都签署了实验知情同意书.

借鉴经典的MI实验范式^[14],在本次自主下肢MI的实验中,所有被试者被要求以自主的方式执行5种下肢步行活动(平地行走、平地跑步、跳跃、上楼梯和下楼梯)的MI,如图1所示.允许被试者根据提示执行下肢“运动开始”和“运动结束”想象,并根据自己的意愿选择执行MI的运动类型.为了确保实验任务和休息时间的精准把握,在实验开始之前,在一个单独的简短环节上对被试者进行指导和培训.在这个环节中,被试者被要求完成至少2组实验任务的MI.当被试者能够按照他们得到的指示完成试验任务周期,就被允许开始正式的实验环节.

在正式实验过程中,每个被试者根据任务需求进行10组MI实验任务.每组实验由16个实验块组成,每个实验块对应一个意图类型的MI任务.如图1所示,在每组实验中,-6~-3 s阶段显示屏显示一个笑脸图标,此时表明实验开始,请被试者保持静息状态;-3~0 s阶段屏幕中心出现一个十字图标,提示被试者即将开始执行想象,请自主想好MI类型;0 s时,屏幕呈现白色,持续时间6 s,表示要求被试者执行“运动开始”想象并持续进行6 s的当前MI任务;6 s后,屏幕转为黑色,被试者要求在6~9 s内完成当前所想象运动的“运动结束”想象;9~12 s阶段屏幕中心的问号则询问被试者自主执行的MI类型,并通过按键1~5提供标记反馈(1表示平地行走,2表示平地跑步,3表示跳跃,4表示上楼梯,5表示下楼梯).每组实验中间有休息时间,至少5 min,时间长短由被试者决定,直到满足他们的休息需求即可,每个被试者的实验持续大约2 h.

2 实验方法

2.1 数据预处理

相关研究表明^[15],与MI相关的EEG频段主要为1~30 Hz,尤其集中于 μ 波段(1~8 Hz)和 β 波段(8~12 Hz),脑电信号的去噪过程是通过EEGLAB工具箱分数字信号滤波和独立成分分

析(independence component analysis, ICA)两步进行的.信号先被一个截止频率为0.1 Hz的4阶有限长单位冲激响应(finite impulse response, FIR)高通滤波器滤掉数据中的直流漂移,并被一个50 Hz的陷波器清除掉电路的工频干扰.带通滤波分4种进行,分别对应 θ 波段、 μ 波段和 β 波段的1~8 Hz, 8~12 Hz和12~30 Hz以及1~30 Hz的带通滤波,为模式识别提供原始数据特征.为了提高计算效率,EEG信号被降采样到128 Hz.根据事件标记,再将滤波后的数据分段为“静息段”(记为“R”类)信号、“运动开始想象”(记为“S”类)信号、“运动进行想象”(记为“MI”类)信号和“运动结束想象”(记为“E”类)信号.最后,将所有分段后的信号分别根据自适应混合独立成分分析(adaptive mixture of independent component analyz, AMICA)算法去除眼电、心电、肌电和通道或线路噪声等伪迹成分. AMICA是一个二进制程序,用于执行多个ICA模型共享输入信号的成分进行ICA分解.对于每一个分段,如果存在超过 $\pm 150 \mu\text{V}$ 的幅值信号,则拒绝该分段和同一实验块中对应的其他3个分段.剔除伪影后,清理后的数据被用于进一步形态分析处理和分类计划.

2.2 MRCP提取

MRCP是一种低频电位,通常在“S”类信号的幅值总平均中可观察到,故对频段为0.3~3 Hz的预处理后“S”类和“E”类信号幅值进行平均,并提取MRCP形态进行分析. MRCP主要考察的3个指标为:准备电位(readiness potential, RP)、负斜率(negative slope, NS)和运动电位(movement potential, MP). RP定义为相对于MI开始时-2~-0.5 s区间内的平均振幅;NS的计算方法是MI开始时取-0.5~-0.1 s区间内的平均振幅;MP定义为MI开始时-0.1~0.1 s区间的平均振幅.此外,运动监测电位(movement-monitoring potential, MMP)是0.1~1 s区间内的平均振幅,这是MI发生后一个值得关注的阶段. RP, NS, MP和MMP都是从所有通道中提取的.每个MI任务的头皮地形图是根据MRCP的跨被试者间平均值构建而成.

2.3 数据分割和滑动窗处理

在本次实验中,选择不同时间长度的窗口数据获得对应“R”类信号、“S”类信号、“MI”类信号和“E”类信号.为了评估不同时间MI前信号完全预测意图系统的可行性,分别提取了 $[-1, 0]$ s, $[-1.5, 0]$ s和 $[-2, 0]$ s 3种不同时间窗口的数据作为“S”类特征或“E”类特征用于分类器训练和交叉验证.数字代表与“运动开始”想象和“运动

结束”想象时间相对应的窗口,即 $[-1, 0]$ s的窗口代表在“运动开始”想象或“运动结束”想象时间开始前1 s的窗口.另外,按照图1中的时间安排,在 $[-5.5, -3.5]$ 和 $[2, 4]$ s的窗口数据内对应的3种类型(1 s, 1.5 s和2 s)被提取用于“R”类和“MI”类信号的特征.为了平衡和无偏的分类,“R”类和“MI”类数据样本的长度被设定为与“S”类信号和“E”类信号相等,确保属于不同类别的连续数据样本之间没有重叠.因此,通过选择远离“S”类和“E”类数据窗的数据,确保“R”类和“MI”类数据不被运动启停想象意图造成的神经波所破坏.这种分割和窗处理方法确保对应于不同类别的数据窗口之间没有重叠,减少数据被污染的机会.

为了从非稳态的EEG数据中提取可实时识别的信号,获得的分割数据窗被进一步划分为滑动窗特征.本文工作有两种预测任务,一种为下肢“运动开始”和“运动结束”想象意图预测,4大类的分段数据则分为时长0.5 s、步长50 ms的大滑动窗;另一种为下肢MI意图类型预测,此时由于下肢启停想象意图预测已消耗一定时间,故将“S”类和“E”类信号滑动处理为时长0.25 s、步长50 ms的小特征窗.因此,每个1 s的分段窗分别被分为11个和16个子窗,1.5 s的窗口分别被分为21个和26个子窗,2 s的窗口分别产生31个和46个子窗.

2.4 MI意图和意图类型预测模型

对于合理的实时BCI系统,分类器必须具有

高灵敏度、高特异性及高稳定性,以避免在使用下肢神经康复系统时发生意外.考虑到这一点,在这项工作中,使用时间卷积网络(temporal convolutional network, TCN)算法来解决两种分类任务.TCN是最近提出的一种新技术,用于基于卷积神经网络(convolutional neural network, CNN)的时序模型平稳有效地学习给定输入信号的隐藏信息和时间依赖性,在时序分析建模的诸多挑战中,其表现优于负担更重、更复杂、同时也是最先进的循环神经网络(recurrent neural network, RNN)^[16].

如图2所示,TCN提出了两点基本特性:第1点是关于因果关系的事实,第2点是关于扩张卷积的事实^[17].为了实现第1点,在第 n 个时刻的MI意图预测只由第 n 个时刻之前的信号输入来确定,这对时序预测至关重要;为了达到第2点,卷积通过跨越一个恒定的步长,呈现出一个参数数量不断减少的感受野.这两个原则的结合使模型能够考虑到广泛的信号序列历史,而不会因为过多的参数(增加过滤器的大小)和层堆叠(降低训练效率)对网络造成不利.在因果关系效应下,对于时刻 n ,从第 $n-2d$ 时刻的数据向量 X_{n-2d} 到第 n 个时刻的数据向量 X_n 被获取进行扩张卷积处理,以实现最终的预测向量 \hat{Y}_n .假设在第 i 个扩张卷积层,时序的第 n 个时刻的元素输出为矩阵 $S_{i,n}$:

$$S_{i,n} = f(S_{i-1, n-2d} * W_i), i \in \{1, 2, 3\}; \quad (1)$$

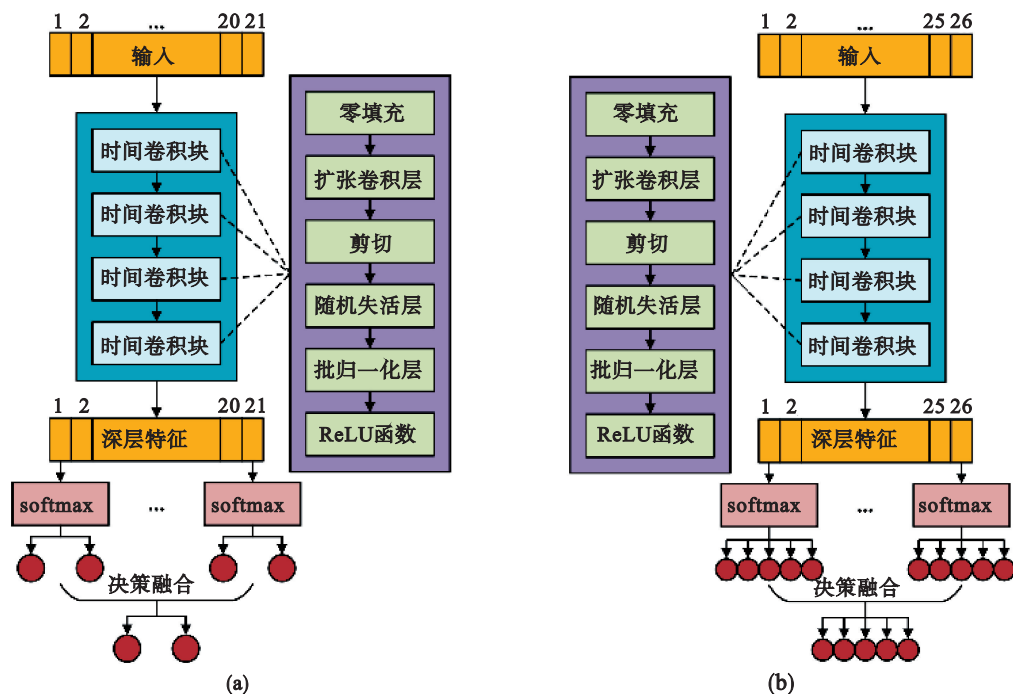


图2 TCN模型结构图

Fig. 2 Structure diagram of TCN model

(a)—MI意图预测模型; (b)—MI意图类型预测模型.

$$S_{0,n} = f(X *_{\text{D}} W_0), X \in \{x_{n-2d}, \dots, x_n\}; \quad (2)$$

$$\hat{Y}_n = \text{softmax}(W_c S_{3,n} + b_c). \quad (3)$$

式中: $*_{\text{D}}$ 是扩张卷积运算符号; $d=2^i$ 是扩张系数; i 表示扩张卷积层数; n 和 $n-2d$ 表示时刻; $f(\cdot)$ 表示ReLU非线性激活函数,结合批次归一化(batch normalization, BN)以抵消内部协方差偏移;卷积层的滤波器被参数化为权重向量 W_i (包含偏置向量 b_i); W_c 和 b_c 为全卷积输出层的权重向量和偏置向量。

每个卷积层之后都有一个随机失活(dropout)层帮助正则化,并最终具有softmax激活运算的预测卷积层结束。

1) MI意图预测模型.在MI意图预测任务中,对于每个被试者,一个分类器被训练成在“R”类和“S”类之间进行完全预测;另一个分类器则被训练成在“MI”类和“E”类之间进行完全预测.分类器的性能是通过被试者间的留一法验证来评估的.如图2a所示,时间卷积块的层数为4层,其输入维度为 64×15 ,输出维度为2.各层扩展卷积的滤波器数分别为64,128,128和256.Dropout层的概率大小设置为0.25.最终的结果由分段窗内多个特征子窗经TCN预测后决策融合而形成,以1.5 s的分段窗为例,一共有21个预测结果,当19个以上预测结果相同时,则认为是当前结果。

2) MI意图类型预测模型.在MI意图类型预测任务中,同样对于每个被试者,一个分类器被训练成在“S”类特征之间进行平地行走、平地跑步、跳跃、上楼梯和下楼梯5种MI意图类型的完全预测,另一个分类器则被训练成在“E”类滑动窗数据中进行平地行走、平地跑步、跳跃、上楼梯和下楼梯5种MI意图类型的完全预测.分类器的性能也是通过基于被试者间的留一法验证来评估的.如图2b所示,时间卷积块的层数为4层,其输入维度为 32×15 ,输出维度为5.各层扩展卷积的滤波器数分别为64,128,128和256.Dropout层的概率大小设置为0.2.最终的结果由分段窗内多个特征子窗经TCN预测后决策融合而形成,以1.5 s的分段窗为例,一共有26个预测结果,当24个以上预测结果相同时,则认为是当前结果。

3 结果和分析

运用上述分析方法和模型对9名被试者MI时EEG数据分别进行了MRCP形态分析以及MI意图预测和MI意图类型预测的量化分析.结果

表明,在人体头顶的运动皮层范围内均有可分辨的MRCP特征,且通过TCN模型能够很好地从MI前的脑活动电信号中解码出下肢步行MI的意图和意图类型。

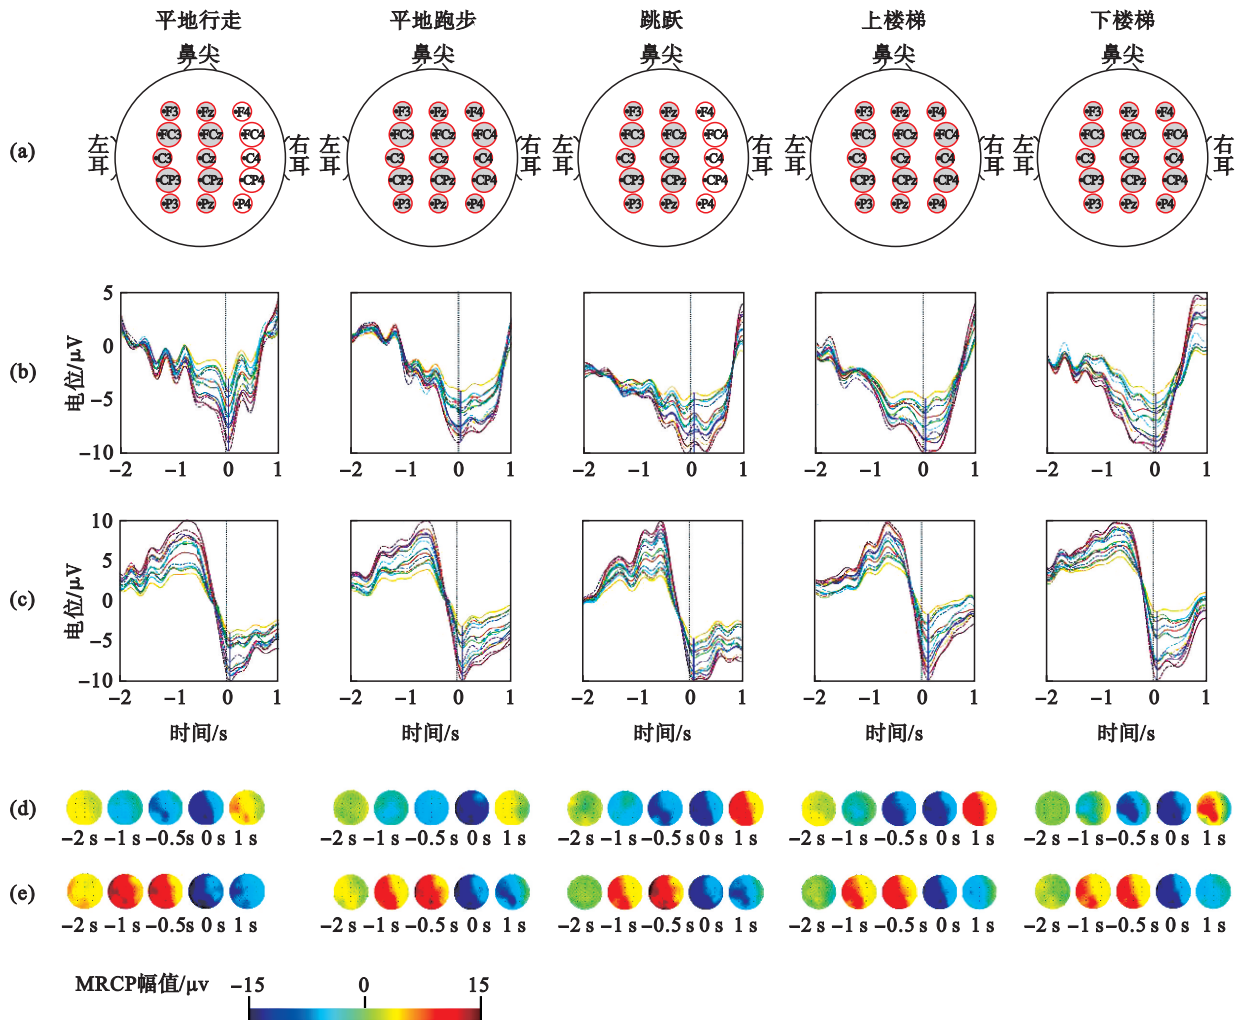
3.1 MRCP形态分析

MRCP在初级运动皮层、运动前和辅助运动区的EEG通道的总平均中可以观察到.如图3b和图3c所示,15个通道都表现出可辨别的MRCP,且除了在平地行走和跳跃类别MI的右侧皮层(F4,FC4,C4,CP4和P4)以外,均显示出幅值大的MRCP.用于分类器预测MI意图和意图类型的MRCP通道在图3a中以红色圆圈标记,表示为MRCP可辨别的通道,灰色阴影圆圈覆盖则表示为幅值很大的MRCP通道.图3d和3e显示了每个MI任务的头皮地形图.由图可见,负电位在空间上定位在中央区域,并在实际MI开始的-1.5 s左右出现,负电位在参与MI的区域被明显地激发出来.因此,目测感知运动皮层上通道的总平均数,并选择那些被确认为MRCP的通道.从分段窗数据的时长、时间跨度和特征选取频段3个角度出发,分别探讨使用MI前信号进行完全预测意图和意图类型的可能性。

3.2 下肢“运动开始”想象和“运动结束”想象意图预测

关于下肢运动启停想象意图预测的分析,第1步,探讨的是特征频段选取方面,因为关于下肢步行MI意图预测过程中,先要做的是分析与MI有关的EEG频段范围,再进行预处理.经分析发现,最适合MI意图检测的是MRCP,确定对应频段为0.3~3 Hz.第2步,提取并分析MRCP形态,发现MRCP每个阶段的时长基本都集中于1~2 s,且两个连续阶段的组合也维持在2 s以内.本文研究的目的是完全预测下肢步行MI意图,也就是说利用MI发生之前的信号进行解码意图,对应的是2 s内EEG信号.因此,决定设定分段窗时长分别为1,1.5和2 s对EEG信号进行分析,发现1.5 s时长的分段足够获取较高的预测性能.第3步,在这个1.5 s的分段窗时长基础上,分析完全预测和非完全预测的统计学差异,以及MRCP各阶段对下肢MI意图检测的贡献程度,故将分段窗的时间跨度调整为 $[-1.5, 0]$ s, $[-1, 0.5]$ s和 $[-0.5, 1]$ s。

在特征频段选取方面,则确保分段窗时长为1.5 s、时段为MI前1.5 s,对比频段分别为0.3~3 Hz,1~8 Hz,8~12 Hz,12~30 Hz和1~30 Hz对意



注：1.图(b)和图(c)中MRCP形态电极：— F3 — Fz — F4 — FC3 — FCz — FC4 — C3 — Cz — C4
 — CP3 — CPz — CP4 — P3 — Pz — P4
 2.图(b)和图(c)中MRCP形态竖线：——“运动开始”或“运动结束”想象刺激“0”时刻；·····“运动开始”或“运动结束”想象真实时刻；

图3 MRCP形态分析结果

Fig. 3 MRCP morphology analysis results

(a)—MRCP形态显著的通道标记图；(b)—下肢步行“运动开始”想象任务的MRCP形态；(c)—下肢步行“运动结束”想象任务的MRCP形态；(d)—下肢步行“运动开始”想象任务的头皮地形图；
 (e)—下肢步行“运动结束”想象任务的头皮地形图.

图完全预测的影响；在分段窗时长方面，统一数据时段为MI前信号，以及0.3~3 Hz的特征频段，对比分段窗时长分别为1, 1.5和2 s对意图完全预测的影响；在数据时段方面，则保持分段窗时长为1.5 s，以及EEG频段为0.3~3 Hz，对比数据跨度分别为[-1.5, 0] s, [-1, 0.5] s和[-0.5, 1] s对意图预测的影响，0代表“运动开始”想象和“运动结束”想象的时刻。

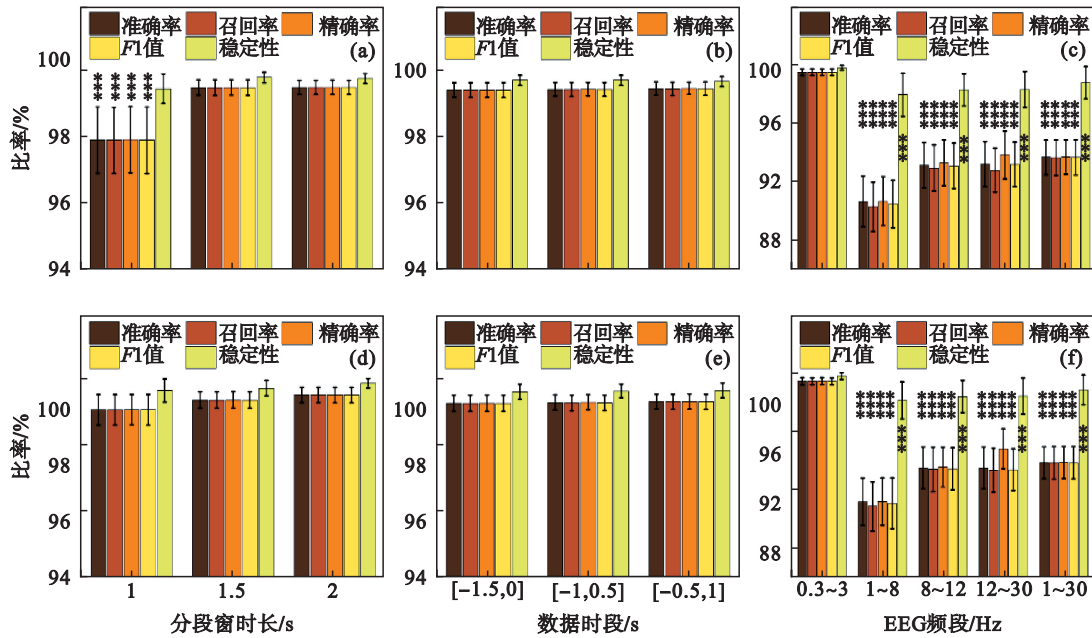
从图4a~图4c中的对比可见，“运动开始”想象意图的解码在使用2 s分段窗长度的MRCP (0.3~3 Hz)频段特征，且包含MI开始后1 s数据

下达到最佳，分别对应99.51%，99.50%和99.55%的准确率以及99.78%，99.81%和99.77%的稳定性。值得注意的是，对下肢步行“运动开始”想象意图的解码，1 s分段窗数据相比1.5和2 s分段窗数据具有十分显著的统计学差异(显著性水平 $P < 0.001$)，但是，1.5和2 s分段窗数据之间并不存在显著的统计学差异($P > 0.05$)，这可能是由于MRCP数据就是从MI前-2 s左右开始，且在1.5 s左右开始存在负电位。因此，决定仅使用MI前1.5 s数据较为合理。同时，数据时段方面，尽管包含MI后数据解码性能更佳，但

是并不存在明显的统计学差异($P>0.05$).因此,使用MI前信号解码意图存在合理的可行性. EEG特征的频段选取上,MRCP特征显著优于其他 EEG信号有效频段($P<0.001$),甚至是MI信号的全部有效频段.

图 4d~图 4f 中对比出类似的结果,“运动结束”想象意图的解码同样在使用 2 s 分段窗长度的 MRCP 特征(0.3~3 Hz 频段),且包含 MI 结束后 1 s 数据达到最佳,分别对应 99.48%,99.32%

和 99.37% 的准确率以及 99.83%,99.68% 和 99.72% 的稳定性.不同之处在于,对下肢步行“运动结束”想象意图的解码,不同时长分段窗数据之间并不存在显著的统计学差异($P>0.05$),这可能是因为“运动结束”想象前形态在-1 s之内变化最为激烈,包含正负电位的两个峰值.在数据时段和特征频段方面,“运动结束”想象意图与“运动开始”想象意图保持一致的统计学特性($P<0.001$).



注:***表示 $P<0.001$.

图 4 意图完全预测结果

Fig. 4 Results of intention fully predictions

(a)“运动开始”想象任务中不同分段时长下意图完全预测结果;(b)“运动开始”想象任务中不同数据时段下意图完全预测结果;(c)“运动开始”想象任务中不同 EEG 频段下意图完全预测结果;(d)“运动结束”想象任务中不同分段时长下意图完全预测结果;(e)“运动结束”想象任务中不同数据时段下意图完全预测结果;(f)“运动结束”想象任务中不同 EEG 频段下意图完全预测结果.

3.3 下肢 MI 意图类型预测

关于下肢 MI 意图类型预测的分析,考虑到预测意图类型的难度和复杂性,在特征频段对比方面做出一些改变,即以 MI 所有的有效频段 1~30 Hz 为基准,其他的参数与意图预测保持一致.第 1 步,在特征频段选取方面,维持和下肢运动启停想象意图预测分析一样的设定;第 2 步,在分段窗时长方面,统一数据时段为 MI 前信号,以及 1~30 Hz 的特征频段,对比分段窗时长分别为 1, 1.5 和 2 s 对意图类型完全预测的影响;第 3 步,在数据时段方面,则保持分段窗时长为 1.5 s,以及 EEG 频段为 1~30 Hz,对比数据跨度分别为[-1.5, 0] s, [-1, 0.5] s 和 [-0.5, 1] s 对意图类型预测的影响.


从图 5a~图 5c 中的对比可以看出,“运动开

始”想象意图类型的解码在分别使用 2 s 分段窗长度、包含 MI 开始后 1 s 数据以及 MRCP 特征频段(0.3~3 Hz)下达到最佳,分别对应 99.44%, 99.24% 和 99.71% 的准确率以及 99.84%, 99.77% 和 99.79% 的稳定性.其结果为对下肢步行“运动开始”想象意图类型的解码,1 s 分段窗数据相比 1.5 和 2 s 分段窗数据同样具有显著的统计学差异($P<0.05$, $P<0.001$),但 1.5 和 2 s 分段窗数据之间并不存在显著的统计学差异($P>0.05$),这同样归结于完整的 MRCP 数据更有利于意图的预测,且意图类型的不同不仅来源于 MP 中的峰值,还可能存在于 NS 中的斜率、RP 中的计划以及 MMP 中的控制.同时,数据时段方面,尽管包含 MI 后数据解码性能更佳,但是也仅仅是[-1.5, 0]

和 $[-1, 0.5]$ s之间存在明显的统计学差异($P < 0.05$),这个结果可能与负电位峰值的时延有关.因此,使用MI前信号解码意图类型同样存在可行性.EEG特征的频段选取上,MRCP特征显著优于其他EEG信号有效频段($P < 0.01$),EEG中的 μ 频段除外,这符合相关研究认为感知运动区域的 μ 频段能够反映MI意图的观点^[18].

图5d~图5f中对比出类似的结果,“运动结束”想象意图类型的解码同样在分别使用2 s分

段窗长度、包含MI开始后1 s数据以及MRCP特征频段(0.3~3 Hz)下达到最佳,分别对应99.42%, 99.28%和99.74%的准确率以及99.83%, 99.80%和99.89%的稳定性.不同之处在于,对下肢步行“运动结束”想象意图的解码,不同时长分段窗数据之间以及数据时段之间均不存在显著的统计学差异($P > 0.05$).在特征频段方面,“运动结束”想象意图类型和“运动开始”想象意图类型保持基本一致的统计学特性($P < 0.05$).



注: *表示 $P < 0.05$, **表示 $P < 0.01$, ***表示 $P < 0.001$.

图5 意图类型完全预测结果

Fig. 5 Results of intention type fully predictions

(a)“运动开始”想象任务中不同分段时长下意图完全预测结果;(b)“运动开始”想象任务中不同数据时段下意图完全预测结果;(c)“运动开始”想象任务中不同EEG频段下意图完全预测结果;(d)“运动结束”想象任务中不同分段时长下意图完全预测结果;(e)“运动结束”想象任务中不同数据时段下意图完全预测结果;(f)“运动结束”想象任务中不同EEG频段下意图完全预测结果.

3.4 在线预测

在线BCI意图完全预测系统的算法结构如图6所示,在线数据的获取和预处理与离线过程基本相似,当存储的数据堆栈样本数大于等于 750×30 时开始预处理,只是在ICA处不同,离线过程使用的是EEGLAB工具箱中的AMICA,在线则使用Python3.7平台下MNE库的ICA函数执行FastICA.数据在线预处理之后,再利用滑动窗同时处理其为21个意图特征子窗和26个类型特征子窗.第1步,将21个意图特征子窗送入“运动开始”想象意图完全预测TCN模型,当满足19个以上预测结果为“S”类时,则认为当前分段为“S”类,即“运动开始”想象,反之为“R”类.紧接着立刻将26个类型特征子窗送入“运动开始”想象意

意图类型完全预测TCN模型,当满足24个以上预测结果相同时,则认为当前分段即将进入该相同类型的MI.第2步,认为前面分段窗最后时刻为MI意图开始时刻,并以该起始点继续等待数据堆栈样本数大于等于 750×30 时开始进行“运动结束”想象意图完全预测.与“运动开始”想象意图完全预测TCN模型一样,送入21个意图特征子窗进行解码,当满足19个以上预测结果为“E”类时,则认为当前分段为“E”类,即“运动结束”想象,反之为“MI”类.随后同样将26个类型特征子窗送入“运动结束”想象意图类型完全预测TCN模型,当满足24个以上预测结果相同时,认为当前分段即将开始该相同类型的“运动结束”想象.如果“运动结束”想象意图类型完全预测结果与

“运动开始”想象意图类型完全预测结果不一致,则需要检查并优化模型.第 3 步,认为前面分段窗最后时刻为 MI 意图结束时刻,并作为起始点继续等待数据堆栈样本数大于等于 750×30 时开始进行“运动开始”想象意图完全预测.此后,依此循环.由于 EEG 信号本身的特异性和在线预处理

与离线预处理的方式不同,导致实际的在线预测准确率和稳定性低于 99% 和 99.5%,而离线预测准确率和稳定性大于 99% 和 99.5%,其中意图预测准确率和稳定性为 86.52% 和 86.16%,意图类型预测准确率和稳定性为 84.28% 和 85.01%,在线平均准确率和稳定性大于 84% 和 85%.

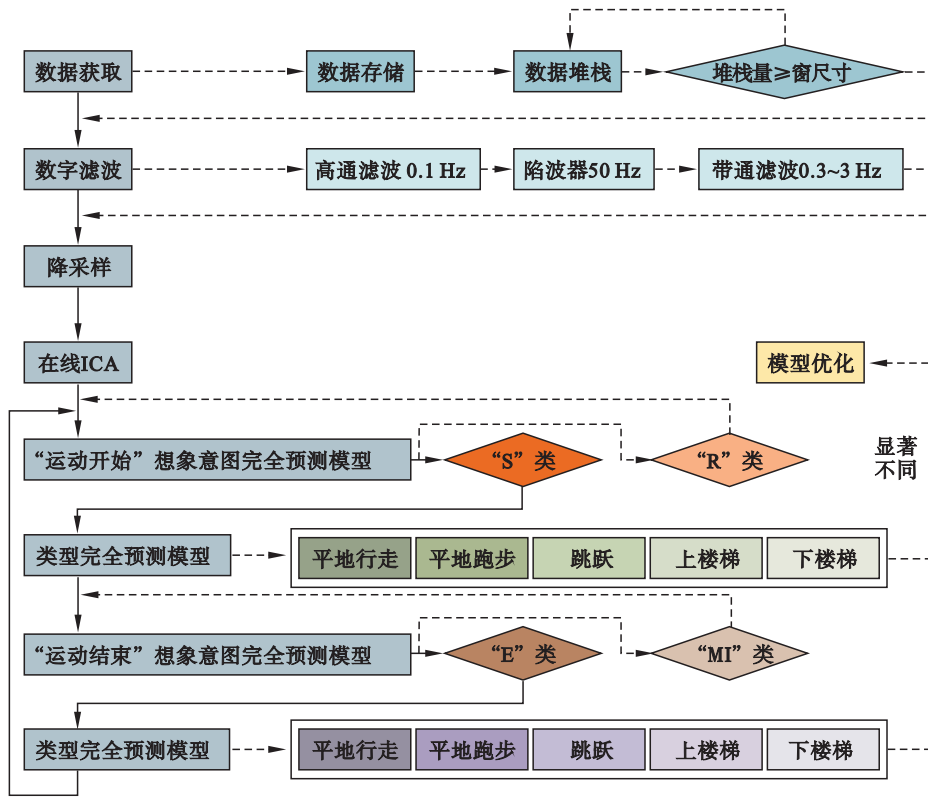


图 6 在线完全预测算法结构图

Fig. 6 Structure diagram of online fully prediction algorithm

4 结 论

1) 下肢步行 MI 在初级运动皮层、运动前和辅助运动区均诱发了明显的 MRCP 现象。

2) 通过 MRCP 形态选取的 EEG 通道信号在启停意图和类别上均具有明显可分离差异。

3) 利用 MI 开始或结束前 1.5 s 信号的 MRCP 特征能够很好地预测 MI 意图和意图类型,离线平均准确率和稳定性大于 99% 和 99.5%,在线平均准确率和稳定性大于 84% 和 85%。

4) 验证了 MI 开始或结束前的 MRCP 数据可用于预测下肢步行 MI 意图和意图类型的可行性,可为在线 MI 的 BCI 系统用于下肢神经康复提供帮助。

参考文献:

[1] 王春方,孙长城,明东,等.脑卒中后抑郁患者脑电信号长时程相关性分析[J].仪器仪表学报,2017,38(6):1361-

1367.

(Wang Chun-fang, Sun Chang-cheng, Ming Dong, et al. Long-range temporal correlation analysis of EEG oscillation in poststroke depression patients [J]. *Chinese Journal of Scientific Instrument*, 2017, 38(6): 1361-1367.)

[2] 李光林,郑悦,吴新宇,等.医疗康复机器人研究进展及趋势[J].中国科学院院刊,2015,30(6):793-802.

(Li Guang-lin, Zheng Yue, Wu Xin-yu, et al. State of the art of medical and rehabilitation robotics and their perspective [J]. *Bulletin of Chinese Academy of Sciences*, 2015, 30(6): 793-802.)

[3] Pinto-Fernandez D, Torricelli D, Sanchez-Villamanan M D C, et al. Performance evaluation of lower limb exoskeletons: a systematic review [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(7): 1573-1583.

[4] 胡进,侯增广,陈翼雄,等.下肢康复机器人及其交互控制方法[J].自动化学报,2014,40(11):2377-2390.

(Hu Jin, Hou Zeng-guang, Chen Yi-xiong, et al. Lower limb rehabilitation robots and interactive control methods [J]. *Acta Automatica Sinica*, 2014, 40(11): 2377-2390.)

[5] 侯增广,赵新刚,程龙,等.康复机器人与智能辅助系统的研究进展[J].自动化学报,2016,42(12):1765-1779.

(Hou Zeng-guang, Zhao Xin-gang, Cheng Long, et al.

- Recent advances in rehabilitation robots and intelligent assistance systems [J]. *Acta Automatica Sinica*, 2016, 42 (12): 1765-1779.)
- [6] Zhou B, Wang H, Hu F, et al. Accurate recognition of lower limb ambulation mode based on surface electromyography and motion data using machine learning [J]. *Computer Methods and Programs in Biomedicine*, 2020, 193: 105486.
- [7] Shafiul H S M, Siddiquee M R, Bai O. Supervised classification of EEG signals with score threshold regulation for pseudo-online asynchronous detection of gait intention [C]//2019 18th IEEE International Conference on Machine Learning and Applications (ICMLA), Boca Raton, 2019: 1476-1479.
- [8] 李鹏海, 王丽余, 刘瀛涛, 等. 下肢运动想象和运动执行的 EEG 节律特性研究 [J]. *仪器仪表学报*, 2018, 39(3): 207-214.
(Li Peng-hai, Wang Li-yu, Liu Ying-tao, et al. Study on EEG rhythm features of lower limb motor imagery and motor performance [J]. *Chinese Journal of Scientific Instrument*, 2018, 39(3): 207-214.)
- [9] Shafiul H S M, Siddiquee M R, Atri R, et al. Prediction of gait intention from pre-movement EEG signals: a feasibility study [J]. *Journal of Neuro Engineering and Rehabilitation*, 2020, 17(1): 50.
- [10] Mohseni M, Shalchyan V, Jochumsen M, et al. Upper limb complex movements decoding from pre-movement EEG signals using wavelet common spatial patterns [J]. *Computer Methods and Programs in Biomedicine*, 2020, 183: 105076.
- [11] Liu D, Chen W H, Chavarriaga R, et al. Decoding of self-paced lower-limb movement intention: a case study on the influence factors [J]. *Frontiers in Human Neuroscience*, 2017, 11: 560.
- [12] Wang K, Xu M P, Wang Y J, et al. Enhance decoding of pre-movement EEG patterns for brain-computer interfaces [J]. *Journal of Neural Engineering*, 2020, 17(1): 016033.
- [13] Seeck M, Koessler L, Bast T, et al. The standardized EEG electrode array of the IFCN [J]. *Clinical Neurophysiology*, 2017, 128(10): 2070-2077.
- [14] Alchalabi B, Faubert J, Labbé D R. A multi-modal modified feedback self-paced BCI to control the gait of an avatar [J]. *Journal of Neural Engineering*, 2021, 18(5): 056005.
- [15] Dai G H, Zhou J, Huang J H, et al. HS-CNN: a CNN with hybrid convolution scale for EEG motor imagery classification [J]. *Journal of Neural Engineering*, 2020, 17(1): 016025.
- [16] Zhou B, Feng N S, Wang H, et al. Non-invasive dual attention TCN for electromyography and motion data fusion in lower limb ambulation prediction [J]. *Journal of Neural Engineering*, 2022, 19(4): 046051.
- [17] Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [EB/OL]. (2018-04-09) [2023-02-01]. <https://arxiv.org/abs/1803.01271v2>.
- [18] Jochumsen M, Niazi I K. Detection and classification of single-trial movement-related cortical potentials associated with functional lower limb movements [J]. *Journal of Neural Engineering*, 2020, 17(3): 035009.