

DOI:10.19651/j.cnki.emt.2416320

多域特征融合的脑电信号肢体运动特征提取与动作识别^{*}

肖 健^{1,2} 党选举^{1,2}

(1. 桂林电子科技大学电子工程与自动化学院 桂林 541004; 2. 广西智能综合自动化高校重点实验室 桂林 541004)

摘要: 在脑电信号的肢体运动想象特征分类识别中,融合不同域特征提取时,存在动作识别准确度不高的问题。针对此问题,本文依据多通道采集中肢体运动想象脑电特征的复杂不同域关系,设计了用于识别肢体动作的脑电-对称正定网络运动特征分类模型,有效提取并融合不同域特征,实现了基于脑电信号的肢体特征分类以及动作的有效识别。实验结果表明,在识别四类肢体是否运动的运动想象数据集 BCI Competition IV 2a 上,基于所构建的分类模型在动作识别时的准确率达到 0.85,Kappa 系数达到 0.80,具有较高精度。

关键词: 脑机接口;运动想象;黎曼几何;小波包分解;神经网络

中图分类号: TN911.7 文献标识码: A 国家标准学科分类代码: 510.4010

Extraction of body movement features and action recognition based on Multi-Domain feature fusion in electroencephalogram signals

Xiao Jian^{1,2} Dang Xuanju^{1,2}

(1. School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin 541004, China;

2. Key Laboratory of Guangxi College Intelligent Comprehensive Automation, Guilin 541004, China)

Abstract: In the classification and recognition of motor imagery EEG features for limb movements, there exists a problem of low action recognition accuracy when fusing features from different domains. To address this issue, this study designs an EEG-symmetric positive definite network model for motor feature classification, tailored to the complex cross-domain relationships of motor imagery EEG features in multi-channel data collection. This model effectively extracts and integrates features from different domains, achieving accurate classification of limb features and action recognition based on EEG signals. Experimental results demonstrate that on the BCI Competition IV 2a dataset, which contains motor imagery data of four types of limb movements, the proposed classification model achieves an action recognition accuracy of 0.85 and a Kappa coefficient of 0.80, indicating high precision.

Keywords: brain-computer interface; motor imagination; Riemannian geometry; wavelet packet decomposition; neural network

0 引言

从 2013 年,欧盟与美国相继公布了各自的脑计划^[1],到 2021 我国年筹备了 5 年的《科技部关于发布科技创新 2030—“脑科学与类脑研究”重大项目 2021 年度项目申报指南的通知》的发布,脑机交互(brain-computer interface, BCI)得到全球越来越多国家的重视。脑机交互中的脑电图(electroencephalogram, EEG)是一种无创采集头皮上电位的手段,其记录了神经元内及周围电流所产生的突触后

电位^[2],是由轴突末端神经递质释放后,产生的电流所引起。在手势等运动特征提取任务中,目标是提取 EEG 信号的特征,依据不同的特征,识别大脑想要完成的操作,进而控制机械臂^[3]、鼠标等工具,其中信号特征提取是关键技术。利用传统的机器学习提取运动特征时,需要输入大量的先验知识并不断调整参数才能得到理想的结果。然而 EEG 信号的信噪比与非稳态随机信号的特性以及实验流程的复杂性决定了机器学习很难有效提取 EEG 信号的特征。随着深度学习的发展,研究将重心放在深度学习与

收稿日期:2024-06-27

* 基金项目:国家自然科学基金(62263004)、广西重点研发计划项目(桂科 AB23075102)资助

EEG 信号的结合中,基于深度学习的 EEG 信号特征提取主要提取的是时域、频域以及空域特征。时域特征通常利用卷积神经网络,长短期记忆网络(long short term memory,LSTM)等方法提取,Seker 等^[4]设计的 EEGNet (electroencephalogram net,EEGNet)是专门为 BCI 任务设计的通用且紧凑 CNN 网络,Wang 等^[5-6]分别利用二维与一维 CNN 与 LSTM 结合的混合算法,提高了准确率,但是这 3 种模型只考虑了信号的时域信息;频域特征有小波、时频图等方法可供选择,Rana 等^[7]通过离散小波变换设计了一种结合时空运算的深度学习架构,在四分类运动想象数据集上的分类精度达到了 84.65%,Xu 等^[8]提出了一种基于小波变换的输入,提取时频图特征的方法,降低了计算复杂性,且拥有稳定的性能,但是当采集通道数增加时,计算复杂性又会骤然升高;在提取空域特征时,最常见的方法是共空间模式(common spatial pattern,CSP),以及利用黎曼几何,Xie 等^[9]利用黎曼相似度来度量二阶差分散点图,来准确诊断癫痫,Kim 等^[10]通过将对称正定(symmetric positive definite,SPD)流形中同一类的要素拉向其重心展示了黎曼几何在处理非平稳信号方面的优越性,以上两种基于黎曼几何的方法并未考虑时域以及频域特征。上述模型大多提取的是一个或者两个域内的特征,然而 EEG 信号在时域、空域、频域 3 个域内均包含了大量的特征,融合多个域内特征可以有效弥补单个域内由于噪声等问题带来的误差,目前对多域特征融合的研究较少。

针对上述对融合多通道肢体运动想象脑电信号不同域特征研究较少的问题,本文提出用于识别肢体 EEG 信号特征的脑电-对称正定(electroencephalogram-symmetric positive definite net,EEG-SPDNet)分类模型,在 EEGNet 的基础上增加了流形映射模块以及频域特征提取模块以提取空间与频域特征,并改进了卷积模块。利用多尺度可分离卷积与注意力模块提取时域特征,通过 SPD 空间解决了

以往模型无法有效融合时域空域特征的问题,并融合频域特征,更准确地提取了多通道肢体运动想象信号特征,增加了特征识别的准确率。

1 EEGNet

EEGNet 是通用的脑电特征提取网络,EEGNet 的卷积模块包含两次特殊的卷积操作,一次深度卷积和一次可分离卷积。前者用于提取通道间特征,后者用于提取时域特征。在手势等运动想象任务中,由于大脑活动区域集中在运动皮质区,其他区域的特征理应被弱化,仅采用深度卷积难以有效地提取通道间特征。在可分离卷积中,一维卷积核的固定长度,导致了出现持续时间相对较长或较短的信号变化时,难以充分提取信号的时域特征。

基于包含丰富空间信息的肢体运动想象 EEG 信号提取特征时,空间信息可提供有效的判别性信息,然而,EEGNet 对于空间信息的利用有限,限制了模型对空间特征的捕捉和利用能力。在已有模型中,空间特征提取大多采用欧式空间中的算法,但是多通道采集所带来的维度提升,必然会使 EEG 信号的特征不再处于同一平面内,这也使欧式空间的算法不再适合被用来提取特征^[11]。EEG 信号的频域特征同样可以作为有效的分类依据,EEGNet 并未对此加以利用。考虑到上述几个方面问题,本文在 EEGNet 的基础上,从增强时域特征、通道间特征,增加空域特征以及频域特征 4 个角度完善 EEGNet,将多个域内的特征有效融合,构建 EEG-SPDNet 分类模型,最终达到提高肢体动作识别准确率的目的。

2 网络结构与特征提取方法

本文对 EEGNet 进行改进,构建的 EEG-SPDNet,主要包含 3 个模块,时域特征提取模块、流形映射模块与频域特征提取模块。EEG-SPDNet 模型总体结构如图 1 所示。




图 1 EEG-SPDNet 分类模型
Fig. 1 EEG-SPDNet classification model

2.1 时域特征提取模块

为了弥补 EEGNet 中缺失的通道权重以及单一可分

离卷积所带来的特征单一的问题,本文设计了时域特征提取模块,加入了改进的注意力单元(squeeze-and-excitation

networks, SENet), 使用多尺度可分离卷积增强时域特征, 如图 2 所示。




图 2 时域特征提取模块

Fig. 2 Time domain feature extraction module

多通道采集能提供更丰富的特征,但在执行不同BCI任务时,大脑不同区域的响应不同,如在单手任务中,额叶运动皮质脑电信号 α 与 β 波段会出现同侧振幅降低,而对侧振幅升高的现象,分别称为事件相关去同步化(event-related desynchronization, ERD)和事件相关同步化(event related synchronization, ERS)^[12-13]。而在与运动功能无关的脑区,电压的波动相对不明显,多余的通道反而会带来冗余的特征。因此,本文提出了如图3所示的基于改进SENet的通道权值自适应,根据每个通道的重要性,自适应调整通道权重,有效地增强了更重要的脑电通道,抑制了不太重要的脑电通道。为了适应运动想象信号在运动皮质区出现的ERD/ERS等带来的大幅电压波动现象,本文在原有SENet的基础上加入了最大池化层,以提取相关脑功能区出现的大幅电压波动的特征。在经过改进的SENet后,各个通道已经被赋予了不同的重要性,利用深度卷积提取通道间特征,实现有效抑制与运动想象无关的通道带来的影响的目的。同时,受多头注意力机制的启发^[14],为了改善单一感受野造成的特征提取不全面的缺陷,本文将一次可分离卷积改进为多尺度可分离卷积,充分提取运动想象信号不同时间尺度下的特征,利用大小不同的感受野使信号中的不同特征被有效利用,从而保证提取的特征包含对分类有利的成分。




图 3 改进的 SENet

Fig. 3 Improved SENet

2.2 流形映射模块

为了提取信号的空间特征,并能保留多通道信号的有效信息,本文在EEGNet的基础上增加了空间特征提取模块,将EEG信号的时域特征映射到高维空间,相比欧式空间,高维流形可以更贴合EEG信号特征的分布,本文引入3个层结构的SPDNet^[15],提取信号的空间分布特征。

1) 双线性映射层: 协方差矩阵 \mathbf{X}_{cov} 由式(1)求得,考虑到多通道信号的维度将会带来巨大的计算量,使用双线性变换将 \mathbf{X}_{cov} 降维以降低计算量并提高其判别性。

为了保证 \mathbf{X}_{cov} 中所有维度的线性无关,变换时产生的权值矩阵 \mathbf{W}_B 可能非满秩的构成了非紧凑Stiefel流形,对于一个不能被闭集所包围的Stiefel流形,计算中通过选择任意正交向量,使得流形没有上界。因而需要对 \mathbf{W}_B 加以约束以保证在梯度下降时,可避免矩阵之间距离过大的情况出现,双线性变换如式(2)所示。

$$\mathbf{X}_{cov} = \frac{1}{K-1} \mathbf{X}(t) \mathbf{X}^T(t), \mathbf{X}(t) \in \mathbb{R}^{N \times K} \quad (1)$$

$$\mathbf{X}_{cov} = f_B(\mathbf{X}_B) = \mathbf{W}_B \mathbf{X}_B \mathbf{W}_B^T \text{ s.t. } \mathbf{W}_B^T \mathbf{W}_B = \mathbf{I} \quad (2)$$

2) 正则化层: 经过双线性变换后的矩阵 \mathbf{X}_B 有可能是非正定的,即脱离了SPD空间,为了保证后续计算仍处于SPD空间内,采用正则化的方法来约束 \mathbf{X}_B ,对于一个对称矩阵 \mathbf{X}_B ,可保证存在特征值分解,使 $\mathbf{X}_B = \mathbf{W}_B \boldsymbol{\Sigma}_B \mathbf{W}_B^T$, $\boldsymbol{\Sigma}_B$ 与 \mathbf{W}_B 分别为对角矩阵与正交矩阵, \mathbf{X}_R 为经过正则化后的 \mathbf{X}_B ,正则化函数如式(3)、(4)所示。

$$\mathbf{X}_R = f_R(\mathbf{X}_B) = \mathbf{W}_B \max(\epsilon \mathbf{I}, \boldsymbol{\Sigma}_B) \mathbf{W}_B \quad (3)$$

$$\max(\epsilon \mathbf{I}, \boldsymbol{\Sigma}_B) = \begin{cases} \boldsymbol{\Sigma}_B, & \boldsymbol{\Sigma}_B > \epsilon \\ \epsilon, & \boldsymbol{\Sigma}_B < \epsilon \end{cases} \quad (4)$$

其中, ϵ 代表阈值, 目的是将 $\boldsymbol{\Sigma}_B$ 中非正的元素变为正值,使经过正则化后的矩阵 \mathbf{X}_R 仍然保持在SPD空间中。

3) 对数平滑层: 为了将空间特征加入全连接层,在将 \mathbf{X}_R 重新置于SPD空间后,将其投影到欧式空间内。由于光滑流形局部微分同胚于欧式空间,其切空间上的投影保留了流形中矩阵的特征,所以可以将流形中的元素投影到切空间中,如图4所示,使用Log-Eig操作赋予元素李群结构以实现对数平滑:

$$\mathbf{X}_L = f_L(\mathbf{X}_R) = \mathbf{W}_R \log(\boldsymbol{\Sigma}_R) \mathbf{W}_R^T \quad (5)$$

平滑函数如式(5)所示,其中 \mathbf{X}_L 为对数平滑后的矩阵, $\mathbf{X}_R = \mathbf{W}_R \boldsymbol{\Sigma}_R \mathbf{W}_R^T$, $\boldsymbol{\Sigma}_R$ 与 \mathbf{W}_R 分别为对角矩阵与正交矩阵, $\log(\boldsymbol{\Sigma}_R)$ 将 $\boldsymbol{\Sigma}_R$ 对角线上的值取对数。

设 \mathbf{X}_R 是 N 维矩阵, 经过流形平滑后,会得到包含 $N(N+1)/2$ 个独立参数的矢量,流形映射模块总体步骤如图5所示。

2.3 频域特征提取模块

EEG的特征不仅体现在时域和空域关系中,频域所体现的EEG特征同样具有很强的判别性,为了弥补EEGNet缺失的频域特征,本文在EEG-SPDNet中增加了频域特征。




图 4 流形映射示意图

Fig. 4 Manifold mapping diagram




图 5 流形映射模块

Fig. 5 Manifold Mapping Module

常见的傅里叶变换和小波变换频域特征提取方法都是通过基函数分解 EEG 信号的频率成分。相比傅里叶变换,小波变换更适用于非平稳信号,可以提取更显著的运动想象 EEG 信号特征,故本文采用基于小波的方法提取频率特征^[16],具体过程如下。

1)为了获取小波变换中子带的高频信息,本文选择使用小波包分解(wavelet packet decomposition, WPD)提取并分解原始数据的频域特征并将其重新组合为新的频域特征。

2)在原始数据中,信号采样频率为 250 Hz,本文采用 5 层小波包分解,每一频带的带宽约为 7.8 Hz,本文选取小波包树的(5,1)到(5,3)节点。经研究表明,在众多小波函数中,多贝西小波(daubechies, db)函数在运动想象任务中的表现是最好的,所以本文将会使用 db4 小波提取原始数据频率在 7.8~31.2 Hz 之间的频域特征,小波包树结构图如图 6 所示。




图 6 小波包树

Fig. 6 Wavelet tree

3)将每一频段的小波系数利用 MNE-python 提供的 CSP 工具提取特征,然后经过 CSP 特征提取模块将特征进一步转化为包含 4 类特征的向量,CSP 特征提取流程如图 7 所示。其中 Drop 为 Dropout rate 设置为 0.5 的

Dropout 层,箭头右边为 SoftMax 层。




图 7 CSP 特征提取

Fig. 7 CSP feature extraction

2.4 分类模块

将经过流形映射和小波分解的特征矩阵进行拼接,利用 SoftMax 给出原始信号的综合特征所对应不同肢体运动的概率,最终构建起识别不同肢体运动想象动作的 EEG-SPDNet 分类模型。

3 实验及结果

3.1 实验数据

本文采用自格拉茨理工大学^[17]的 BCI Competition IV 2a 数据集,其中采集自 9 名受试者,受试者在实验过程中需要完成 4 类运动想象任务,分别为左手、右手、双脚、舌头的运动想象,实验中并不限制运动想象时肢体具体的动作,只需保证想象对应肢体在动作即可。在不同日期进行了两次实验,每次实验中,每一类任务都执行了 72 次。数据由 25 个 AG/AGCL 电极采集,其中 22 个为脑电通道,3 个为眼电(EOG)通道。

3.2 数据预处理

脑电波的频率通常在 0~50 Hz 之间,与运动想象相关的脑电波集中在 α (8~13 Hz)波段和 β (14~30 Hz)波段^[18],本文使用 4 阶 FIR 滤波器来截取 7 到 35 Hz 波段的内容。数据集使用乳突通道记录的信号作为参考信号,在实验过程中,容易出现接触变差信号大幅波动的情况,从而导致信噪比降低,使用共平均参考(common average reference,CAR)可以减少单点故障所带来的影响^[19]。数据集中的 3 个 EOG 通道可以为本文消除 EOG 干扰,为此本文使用 MNE-python 中的 ICA 工具来实现 FastICA^[20]以剔除 EOG 成分。

3.3 数据增强

由于 EEG 实验操作复杂,受试者无法保持长时间注意力集中,所以耗时长,数据量小,极大地影响到了神经网络的性能。目前数据增强主要有 3 种策略:基于时频图的图像增强方法(旋转、剪裁等),基于时频图的深度学习方法(GAN、VAE 等),基于特征变换的方法(频域、时域、空域特征)^[21]。前两种方法在通道数较少的情况下对提升实验结果具有积极的效果,但是当通道数增加时,其运算量大幅提升,无法保留通道间关系等特征,所以本文采用第三种策略中的频域增强方法,ROMMEL 等^[22]提出了在通

道相位引入随机扰动的方法,名为傅里叶变换代换(fourier transform surrogate,FFT),通过计算所有 EEG 通道的傅里叶系数,并在其相位中添加随机噪声来实现数据增强,如式(6)所示,其中 \mathcal{D} 是傅里叶算子, f 是频率, $\Delta\varphi$ 是在频率 f 下的随机扰动。

$$\mathcal{D}[FFT(X)](f) = \mathcal{D}[X](f)e^{i\Delta\varphi}, \Delta\varphi \in [0, 2\pi] \quad (6)$$

通道间的扰动是独立的,实验表明,均匀地扰动所有通道是保持通道间相关性并获得良好结果的关键。

3.4 模型参数设置及训练

模型采用早停法来进行训练,以节省训练时间并防止过拟合。模型训练 batch 大小设置为 16,学习速率为 0.0001,采用交叉熵作为损失函数,本文将同一受试者经过数据增强后的测试集与训练集重新混为新的数据集,并打乱数据集的顺序。随后使用 5 折交叉验证评估模型准确率,以及基于混淆矩阵的 Kappa 系数评估分类识别的一致性级别。

为了确定通道间特征提取单元卷积核的数量 F1,本文测试了 F1 为 35、40、…、85 时的准确率,如图 8 所示。当卷积核数量在 60 时,测试集准确率最高,所以 F1 设置为 60。接下来本文需要确定时域卷积核长度 F2。根据时域采样定理,采样频率 f_s 和信号频率 f 需要满足 $f_s \geq f$,否则会在频域产生混叠,虽然此处并不关注信号的频域特征,但是为了保证信号不失真,需要尽量满足采样定理。数据集的采样频率为 250 Hz,所以采样的卷积核长度应小于 125,在此范围内,需要找出最适合提取运动想象信号特征的时间卷积核长度,为此,本文测试了多组卷积核长度对实验准确率的影响,如图 9 所示。当卷积核长度为 15,25,35 时,提取的特征判别性最强,所以将卷积核长度分别设置为 15,25,35。




图 8 通道卷积数量核与准确率的关系

Fig. 8 Relationship between the number of channel convolution kernels and accuracy

3.5 实验结果与方法比较

对于本文所采用的左手、右手、双脚、舌头 4 类肢体运动想象脑电数据集,实验中只采集某一肢体是否在想象运动,对于肢体动作姿态并不加以约束。如左右手想象运动只需要受试者想象左右手动,不限制受试者的手势姿态(抓握,比数字之类)。模型取得的准确率和 Kappa 系数如表 1 所示,Mean 为 9 名受试者平均识别准确率。在 9 名受




图 9 时间卷积核大小与准确率的关系

Fig. 9 Relationship between time convolution kernel size and accuracy

试者的 4 类肢体运动想象任务中,本文模型平均识别准确率达到 0.85,平均 Kappa 系数达到 0.80,能够取得较好的识别效果。

表 1 不同模型识别结果对比

Table 1 Comparison of recognition results of different models

模型	Method	Mean	Kappa
EEGNet	时	0.75	0.66
TS-SEFFNet	时+频	0.75	0.66
CNN+Transformer	时+空	0.79	0.71
DualDomainAttenNet	时+频	0.81	0.76
TSFCNet	时+频+空	0.83	0.77
CNN+BiLSTM	时	0.83	0.77
Proposed*	时+空	0.84	0.79
Proposed	时+频+空	0.85	0.80

为了验证本文所提模型识别效果,表 1 对比了其他融合了时域、频域与空域信息的先进方法。TS-SEFFNet^[23]通过结合时域与频域特征,利用 SENet 构建不同域特征之间相互依赖的关系,以此来突出通道方向的特征响应;CNN+Transformer^[24]利用卷积模块在整个一维时间和空间卷积层中学习局部特征,通过提取局部时间特征内的全局相关性对 EEG 进行分类预测;DualDomain-AttenNet^[25]将时间卷积网络与全局滤波器相结合,能够在时域和频域中同时分析脑电信号;TSFCNet^[26]通过提取不同频段的时间、频率与空间特征来提高准确率;CNN+BiLSTM^[27]通过两个结合了注意力机制的 Inception 提取时间特征。Proposed 为本文所提 EEG-SPDNet 分类模型,Proposed* 为不添加频域特征提取模块的方法,由表 1 可以看出,在加入频域特征提取模块后,模型的分类准确率与 Kappa 值都有一定程度的提升,说明融合频域与时间空间特征可以更好的表征运动想象信号特征。不论加入频域特征提取模型与否,动作分类准确率与 Kappa 系数均高于其他方法,在包含频域特征提取模块时,与 EEGNet^[28]相比,两者分别提高了 10% 和 0.14%。

图 10 对比了 9 名(S01~S09 分别代表 9 名测试者)受试者的动作识别准确率与其他两种具有代表性的模型的差异,可以得知,在大多数测试集上,本文模型表现最好,但是在 S02、S05、S07、S09 上,其他两种方法具有一定优势。整体来看,本文模型在各个受试者中表现较为均衡,略优于其他两种方法,TSFCNet 与本文方法均提取 3 个域特征,造成差异的一个可能原因是其空间特征提取时采用了欧氏空间中的度量,不能准确的提取脑电特征,而 CNN+BiLSTM 的方法导致差异的原因可能是其特征单一,所提取特征相对来说不显著。准确率对比证明了本文方法的优越性,同时说明了多域特征提取在脑电信号特征分类时的必要性和有效性。




图 10 受试者间识别准确率对比

Fig. 10 Comparison of recognition accuracy among subjects

3.6 可视化分析

为说明本文所提 EEG-SPDNet 分类模型对运动想象信号特征的区分能力,本文使用 t 分布-随机邻近嵌入(t-distributed stochastic neighbor embedding, t-SNE)可视化实验结果,如图 11 所示,图中点代表数据在二维空间内的位置。

图 11(a)展示了未经处理的原始数据在特征空间中的分布情况。从图中可以看出,各类数据点之间存在显著的重叠,难以准确分类识别。

图 11(b)展示了数据经过流形平滑处理后的分布情况。在经过流形平滑后,手部特征数据点在空间中的分布






图 11 sub1 分类结果 t-SNE 可视化

Fig. 11 Sub1 classification results t-SNE visualization

开始呈现出明显的聚集趋势,与其他两类特征的区分变得更加明显。

分类后结果如图 11(c)所示,每一类特征边界明显,且与其他特征无明显重叠,证明所使用的频率特征提取模块成功地补充了数据中缺失的频域信息,显著增强了 EEG-SPDNet 的特征识别能力。清晰的分类边界和各类特征的有效分离,验证了分类模型在处理复杂高维数据时的有效性。

4 结 论

本研究提出了一种基于黎曼流形的肢体运动想象脑电信号特征提取方法,通过改进 EEGNet 中的卷积模块,增加更匹配多通道脑电特征的黎曼流形映射模块,以及弥补频域特征提取模块,构建了 EEG-SPDNet 分类模型,实现了左手、右手、双脚、舌头 4 类肢体运动特征的有效分类识别。

通过实验对比和可视化分析,说明 EEG-SPDNet 在 EEGNet 上增加以及改进的部分对准确识别不同肢体的运动想象信号有积极的影响。实验结果与不同方法的对比证明了模型的有效性,可视化分析证明了模型的强判别性。EEG-SPDNet 分类模型可以有效提高不同肢体运动想象信号特征的识别准确率。

参考文献

- [1] HASHEMI M, VATTIKONDA A N, JHA J, et al. Amortized bayesian inference on generative dynamical network models of epilepsy using deep neural density estimators [J]. *Neural Networks*, 2023, 163: 178-194.
- [2] BIASIUCCI A, FRANCESCHIELLO B, MURRAY M M. *Electroencephalography*[J]. *Curr Biol*, 2019, 29(3): R80-R85.
- [3] GUO R X, LIN Y F, LUO X, et al. A robotic arm control system with simultaneous and sequential modes combining eye-tracking with steady-state visual evoked potential in virtual reality environment [J]. *Front Neurorobot*, 2023, 17: 1146415.
- [4] SEKER M, ÖZERDEM M S. Deep insights into mci diagnosis: A comparative deep learning analysis of eeg time series [J]. *Journal of Neuroscience Methods*, 2024, 403: 110057.
- [5] WANG J L, CHENG SH W, TIAN J M, et al. A 2D CNN-LSTM hybrid algorithm using time series segments of eeg data for motor imagery classification[J]. *Biomedical Signal Processing and Control*, 2023, 83: 104627.
- [6] 范方朝, 杜欣, 谢城壁, 等. 基于 CNN-LSTM 的脑电 p300 信号检测[J]. *电子测量技术*, 2022, 45(23): 159-165.
- FAN F CH, DU X, XIE CH B, et al. A P300 signal detection algorithm based on CNN and LSTM [J]. *Electronic Measurement Technology*, 2022, 45(23): 159-165.
- [7] RANA M S, FATTAH S A, SAQUIB M. STOW-Net: Spatio-temporal operation based deep learning network for classifying wavelet transformed motor imagery EEG signals[C]. *TENCON 2023-2023 IEEE Region 10 Conference(TENCON)*, 2023: 860-863.
- [8] XU B G, ZHANG L L, SONG AI G, et al. Wavelet transform time-frequency image and convolutional network-based motor imagery EEG classification[J]. *IEEE Access*, 2019, 7: 6084-6093.
- [9] XIE J R, XU G H, CHEN X B, et al. Second-order difference scatterplot-based transition network with riemann similarity measure for epilepsy classification[J]. *Biomedical Signal Processing and Control*, 2024, 93: 106159.
- [10] KIM B H, CHOI J W, LEE H, et al. A discriminative spd feature learning approach on riemannian manifolds for eeg classification[J]. *Pattern Recognition*, 2023, 143: 109751.
- [11] 王勇, 薛沐辉, 徐宝国, 等. 基于黎曼几何的自然动作运动参数脑电解码研究[J]. *仪器仪表学报*, 2022, 43(7): 157-164.
- [12] WANG Y, XUE M H, XU B G, et al. Decoding hand movement kinematic information from electroencephalogram based on riemannian geometry[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(7): 157-164.
- [13] SENGUPTA P, LAKSHMINARAYANAN K. Cortical activation and bci performance during brief tactile imagery: A comparative study with motor imagery [J]. *Behavioural Brain Research*, 2024, 459: 114760.
- [14] 谢士遥, 汤佳贝, 蔡雨, 等. 脑电 BCI 系统的软硬件开发平台发展现状[J]. *电子测量与仪器学报*, 2022, 36(6): 1-12.
- XIE SH Y, TANG J B, CAI Y, et al. Review on software and hardware platforms for EEG-based BCI system[J]. *Journal of Electronic Measurement And Instrumentation*, 2022, 36(6): 1-12.
- [15] DENG H D, LI M F, LI J D, et al. A robust multi-branch multi-attention-mechanism eegnet for motor imagery BCI decoding [J]. *Journal of Neuroscience Methods*, 2024, 405: 110108.
- [16] TANG Y B, CHEN D, WU J, et al. Functional connectivity learning via siamese-based SPD matrix representation of brain imaging data [J]. *Neural Networks*, 2023, 163: 272-285.
- [17] CHAUDHARY S, TARAN S, BAJAJ V, et al. Convolutional neural network based approach towards motor imagery tasks EEG signals classification [J]. *IEEE Sensors Journal*, 2019, 19(12): 4494-4500.
- [18] SUEMITSU K, NAMBU I. Effects of data including visual presentation and rest time on classification of motor imagery of using brain-computer interface competition datasets [J]. *IEEE Access*, 2023, 11: 59542-59557.
- [19] SAXENA M, SAREEN E, GUPTA A. Understanding functional brain activation using source localization of EEG signals in motor imagery tasks[C]. *2020 International Conference on Communication Systems & NETworkS (COMSNETS)*, 2020: 58-63.
- [20] TSUCHIMOTO S, SHIBUSAWA S, IWAMA S, et al. Use of common average reference and large-laplacian spatial-filters enhances EEG signal-to-noise ratios in intrinsic sensorimotor activity[J]. *Journal of Neuroscience Methods*, 2021, 353: 109089.
- [21] ZHAN G G, SU H L, WANG P CH, et al. Removing EOG artifacts from the resting state EEG signal of

- methamphetamine addicts by ICA algorithms [C]. 2023 11th International Winter Conference on Brain-Computer Interface(BCI), 2023: 1-5.
- [21] HE CH, LIU J L, ZHU Y SH, et al. Data augmentation for deep neural networks model in EEG classification task: A review [J]. Front Hum Neurosci, 2021, 15: 765525.
- [22] ROMMEL C, PAILLARD J, MOREAU T, et al. Data augmentation for learning predictive models on EEG: A systematic comparison[J]. Journal of Neural Engineering, 2022, 19: 066020.
- [23] LI Y, GUO L H, LIU Y, et al. A temporal-spectral-based squeeze-and-excitation feature fusion network for motor imagery EEG decoding[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 1534-1545.
- [24] SONG Y H, ZHENG Q Q, LIU B CH, et al. EEG conformer: Convolutional transformer for EEG decoding and visualization[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 710-719.
- [25] LIU C L, HUANG P T. Dualdomain-attennet: Synergizing time-frequency analysis and attention mechanisms for motor imagery bci enhancement[J]. Advanced Engineering Informatics, 2024, 62: 102697.
- [26] ZHI H Y, YU ZH L, YU T Y, et al. A multi-domain convolutional neural network for EEG-based motor imagery decoding[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 3988-3998.
- [27] AMIN S U, ALTAHERI H, MUHAMMAD G, et al. Attention-inception and long-short-term memory-based electroencephalography classification for motor imagery tasks in rehabilitation[J]. IEEE Transactions on Industrial Informatics, 2022, 18(8): 5412-5421.
- [28] LIU M Y, CAO F CH, WANG X Z, et al. A study of EEG classification based on attention mechanism and EEGNet motor imagination [C]. 2023 3rd International Symposium on Computer Technology and Information Science(ISCTIS), 2023: 976-981.

作者简介

肖健,硕士研究生,主要研究方向为脑电信号处理与脑机接口技术。

E-mail:dlnetizen@163.com

党选举(通信作者),博士,教授,博士生导师,主要研究方向为机器人系统建模与控制。

E-mail:xjd69@163.com