

文章编号: 1673-3193(XXXX)XX-0001-10

基于时空特征融合的手部运动想象脑电分类

赵瑞芳^{1,2}, 余俊斌^{1,2}, 何剑^{1,2}, 侯晓娟^{1,2}, 崔浩然^{1,2}, 崔建峰^{1,2}, 张乐^{1,2*}

(1. 中北大学 电子测试技术重点实验室, 山西 太原 030051;

2. 中北大学 铁电物理微纳器件与系统山西省重点实验室, 山西 太原 030051)

摘要: 运动想象脑机接口(Motor Imagery-Based Brain-Computer Interface, MI-BCI)是一种通过解码运动意图脑电信号来实现脑机信息交互的前沿技术。然而, 左右手MI任务在脑电信号空间特征上高度重叠, 导致信号可区分性下降, 增加了解码准确性和模型泛化的难度。本研究以4种手部运动想象的脑电信号为研究对象, 设计了脑电采集实验范式, 进行了数据预处理, 并建立了一种基于时空特征融合的卷积神经网络模型来增强跨通道信息整合能力, 可以捕捉到更具判别性的时空特征。结果表明: 该模型在5名健康受试者的4种手部MI脑电数据上实现了分类性能提升, 平均分类准确率为90.89%, 平均Kappa系数为0.88, 最高分类准确率为98.44%; 该模型在公共数据集BCI Competition IV 2a上的平均分类准确率为61.85%, 最高分类准确率为85%。不同比例训练样本抽取和关键频段去除的消融实验表明, 该模型在小样本和频段缺失条件下仍能保持稳定的分类性能。此外, 相较于主流模型EEGNet和ATCNet, 整体分类准确率分别提高了3.9个百分点和4.1个百分点, 显示了良好的解码性能和稳定性, 具有较强的鲁棒性。但是, 该模型在更大规模数据集和实时脑电解码方面的应用仍有待进一步探索, 未来可将其应用于人机交互及智能康复等领域。

关键词: 脑机接口; 运动想象; 时空特征; 深度学习

中图分类号: TP242

文献标识码: A

doi: 10.62756/jnuc.issn.1673-3193.2025.11.0027

引用格式: 赵瑞芳, 余俊斌, 何剑等. 基于时空特征融合的手部运动想象脑电分类[J]. 中北大学学报(自然科学版), DOI:10.62756/jnuc.issn.1673-3193.2025.11.0027.

Zhao Ruifang, Yu Junbin, He Jian, et al. Electroencephalogram Classification of Hand Motor Imagery Based on Spatio-Temporal Feature Fusion Network[J]. Journal of North University of China (Natural Science Edition), DOI: 10.62756/jnuc.issn.1673-3193.2025.11.0027.

Electroencephalogram Classification of Hand Motor Imagery Based on Spatio-Temporal Feature Fusion Network

Zhao Ruifang^{1,2}, Yu Junbin^{1,2}, He Jian^{1,2}, Hou Xiaojuan^{1,2}, Cui Haoran^{1,2},
Cui Jianfeng^{1,2}, Zhang Le^{1,2*}

(1. Science and Technology on Electronic Test and Measurement Laboratory, North University of China, Taiyuan 030051, China;

2. Shanxi Key Laboratory of Ferroelectric Physical Micro-nano Devices and Systems,

North University of China, Taiyuan 030051, China)

Abstract: Motor imagery-based brain-computer interface (MI-BCI) is a cutting-edge technology that can realize information interaction between brain and computer by decoding electroencephalogram (EEG) signals associated with motor intention. However, left-right hand MI tasks exhibit highly overlapping spatial features in EEG signals, reducing signal distinguishability and increasing challenges for decoding accuracy and model generalization. This study focused on the EEG signals of four-class hand motor imagery, and designed an EEG data acquisition paradigm, and performed data preprocessing, and built a convolutional neural network model based

收稿日期: 2025-11-25

作者简介: 赵瑞芳(2000—), 女, 硕士生, 主要从事脑机接口方面的研究。

* 通信作者: 张乐(1987—), 男, 副教授, 博士, 主要从事脑机接口方面的研究。E-mail: zhangle@nuc.edu.cn。

on spatio-temporal feature fusion to enhance cross-channel information integration, enabling the capture of more discriminative spatio-temporal features. The results demonstrate that the proposed model improves classification performance on four-class hand motor imagery EEG data from five healthy subjects. The model reaches an average classification accuracy of 90.89% and an average Kappa coefficient of 0.88, with the highest classification accuracy of 98.44%. The model achieves an average classification accuracy of 61.85% and the highest classification accuracy of 85% on the public BCI Competition IV 2a dataset. Ablation experiments with varying proportions of training samples and removal of key frequency bands verifies that the model maintains stable classification performance under conditions of limited samples and missing frequency bands. In addition, compared with mainstream models EEGNet and ATCNet, the overall classification accuracy increases by 3.9 percentage point and 4.1 percentage point, respectively, demonstrating good decoding performance, stability, and strong robustness. However, the model still requires further investigation on larger-scale datasets and real-time EEG decoding, and may have potential applications in human-computer interaction and intelligent rehabilitation in the future.

Key words: brain-computer interface (BCI); motor imagery; spatio-temporal features; deep learning

0 引 言

脑机接口(Brain-Computer Interface, BCI)是一种直接连接大脑与外部设备来实现人机信息交互的新兴技术,其核心在于通过解码脑电信号来识别用户意图并将其转化为控制指令^[1-3]。脑电图(Electroencephalography, EEG)是记录大脑神经元电活动的重要生物电信号^[4],根据产生机制不同可以分为稳态视觉诱发电位(SSVEP)、P300事件相关电位和运动想象(Motor Imagery, MI)。其中,MI指大脑在想象某种运动时,特定脑区会产生运动相关的皮层电位,是BCI领域应用前景最为广泛的范式之一^[5-6]。

现有MI-BCI研究多聚焦于大肌群动作,通常在运动相关皮层可诱发明显的事件相关去同步化/同步化(ERD/ERS)现象,不同通道间特征差异明显。Wang等^[7]提出一种基于多模态运动意图检测的下肢外骨骼康复机器人框架,通过解码受试者在执行蹲起动作时产生的脑电信号,成功实现了对机器人的主动控制。Wang等^[8]通过跟腱振动诱导动觉错觉来增强下肢运动想象,结果显示该范式可增强运动感觉皮层激活并提高分类准确率。然而,这类动作在实际应用中不利于实现高自由度的精细控制,相比之下,手部动作MI能够诱发稳定且可识别的运动相关电位,在高精度BCI应用中更具优势^[9-11]。Mwata-Velu等^[12]通过对张开/握住左右拳的运动想象脑电信号的分类,实现了对六足机器人前进、后退和停止的控制任务。Ding等^[13]实现了对手指运动想象脑电信号在个体手指层级上的精细解码,并成功转化

为对机器人两/三指的实时控制指令。

手部运动想象研究的需求迫切,但同时面临着更高难度,因为左右手运动想象的相关脑区在感觉运动皮层上位置高度接近,使得EEG空间分布存在显著重叠,导致数据时空特征区分度极低。因此,提升手部MI-EEG的特征提取与分类性能成为该领域的重要挑战。Maghsoudi等^[14]提出一种基于有效连接性和分层机器学习的自动化算法,用于解码左右手MI-EEG,其最高分类准确度达到84%。Garcia-Murillo等^[15]设计了一种基于高斯又谱功能连接的KCS-FCnet模型,并在包含50名受试者的左右手MI-EEG数据集上获得了76.4%的平均分类准确率。Qin等^[16]提出了一种轻量化的运动想象脑电分类模型ETCNet,该模型通过结合高效通道注意力和时序卷积网络实现了多尺度特征融合,取得了80.71%的平均分类准确率。Li等^[17]提出一种基于特征中间融合的卷积神经网络,用于解码6种精确手部抓握和指点动作EEG,取得了82.80%的平均准确率。

当前的深度学习方法在手部MI-EEG解码中虽表现出良好的性能,但对大规模高质量训练数据的依赖限制了其实际应用,同时在空间特征提取和通道关联利用方面仍存在不足,深层卷积网络还可能导致部分关键特征丢失,难以充分捕捉与运动想象相关的脑区激活模式。为此,本文构建了一种基于时空特征融合的手部运动想象脑电分类模型,在保留数据关键特征的前提下,提高对跨通道相关性的建模能力,并强化多层特征之间的协同表达。首先,通过一维卷积和深度可分离卷积对手部MI-EEG信号的时间特征进行提取,获得丰富的时序信息表征。

在此基础上,进一步引入空间特征融合模块,以充分利用通道间关联信息,增强脑区空间模式的可区分性。本文融合策略能够全面捕捉更具判别性的时空特征,在左右手食指屈曲和握拳的MI-EEG分类任务中,相较于主流模型EEGNet和ATCNet,能够实现更高的分类准确率和解码性能。

1 实验设备与方法

1.1 实验对象

本研究共招募了5名健康受试者,均自愿参加实验,其中包括3名男性和2名女性,年龄范围为22~26岁。所有受试者均来自中北大学,并在实验前签署了书面知情同意书。本实验程序通过了中北大学生物与医学伦理委员会的审查和批准,并严格按照《赫尔辛基宣言》执行。

1.2 实验采集装置

本实验采用博睿康公司的Neuracle-W4无线脑电采集设备,如图1所示,其具备高信噪比和便携化优势,可在保持高质量脑电记录的同时减少线缆限制对受试者运动想象任务的影响。



图1 脑电采集设备

Fig.1 EEG acquisition system

该脑电采集系统配置64通道湿电极脑电帽,电极布局符合国际10-20标准系统,GND和REF分别作为接地和参考电极。实验开始前,在每个电极与头皮接触点涂敷适量医用导电膏,以降低电极阻抗,并对各电极逐一校准,使其阻抗降至20 k Ω 以下。采样率设置为1 000 Hz,放大器可自动滤除50 Hz的工频干扰信号,确保脑电信号的稳定性和可靠性。

1.3 实验采集范式

本实验在安静的室内环境中进行,受试者需保持自然坐姿,面向显示视觉刺激的电脑屏幕,屏幕与受试者距离约60~100 cm。实验范式包括4种手部精细动作运动想象任务,即左手食指屈曲、右手食指屈曲、左手握拳、右手握拳。单次实验会随机呈现40次MI任务提示,每类运动想象任务共进行

250次试验。根据受试者的生理状态,每次运行中间休息5~10 min,以减轻疲劳并保证数据质量。真实采集脑电信号环境如图2所示。




图2 真实采集脑电信号环境

Fig.2 Actual EEG recording environment

单次运动想象任务的时间流程如图3所示。首先会出现3 s的休息阶段,受试者可以进行轻微生理状态调整。接下来的3~5 s,屏幕会出现一个黑色十字的注视点,要求受试者处于静息状态并做好准备。第5 s至第6 s为运动想象任务提示期,屏幕随机呈现一种手部MI任务动画,引导受试者执行相应动作后保持静止,并立即开始运动想象。提示结束后,屏幕转为空白状态,受试者继续进行3 s的运动想象,直至试验结束后进入下一次循环。同时,运动想象窗口要求受试者处于注意力高度集中状态,并尽量控制眨眼和吞咽等生理伪迹。




图3 单次实验范式流程图

Fig.3 Experimental paradigm flow for a single trial

1.4 公共数据集

为后续进一步验证所提模型的泛化能力,本研究采用了公共数据集BCI Competition IV 2a(BCI 2a)进行实验,该数据集包含9名受试者的EEG数据,每名受试者在不同日期完成两次独立实验。每次实验由6个运行组成,共包含288个试次,涵盖左手、右手、双脚和舌头四类运动想象任务。同时,数据采集使用22个EEG电极,采样率为250 Hz,在 $t=0$ s时显示注视十字并伴随声音提示, $t=2$ s时出现方向箭头并保持1.25 s以触发运动想象,受试者持续想象至 $t=6$ s时注视十字消失,随后进入短暂休息

阶段,如图4所示。




图4 公共数据集BCI 2a的实验范式

Fig. 4 Experimental paradigm of the public BCI competition IV-2a dataset

1.5 数据预处理

由于手部运动想象可能涉及多个脑区的协同活动,尤其是左右手MI对应的脑区在两侧大脑半球呈对称分布^[18-20]。因此,本研究选取了21个分布广泛的EEG通道(Fp1、Fp2、Fz、F3、F4、F7、F8、FC1、FC2、Cz、C3、C4、CP1、CP2、Pz、P3、P4、P7、P8、O1、O2),几乎覆盖左右脑所有关键脑区,以全面捕捉与手部运动想象相关的脑电活动,通道分布如图5所示。




图5 21通道分布图

Fig. 5 21-channel locations

在数据预处理阶段,首先采用4~40 Hz带通滤波

波去除低频直流漂移和高频干扰信号,保留与运动想象相关的有效节律成分。将采样率由1 000 Hz降至250 Hz,在保持有效信息的前提下减少数据冗余并提升处理效率。随后,根据实验事件标签对连续EEG信号进行分段处理(epoch),并提取每次试验从事件触发前1 s至触发后2 s的时间窗数据,为后续分析提供结构化、对齐化的EEG片段。为进一步提升数据质量,人工剔除了包含明显肌电噪声、信号突变或异常电压波动的坏段试次,并对坏道进行插值处理。最后,本研究对EEG数据进行了标准化处理,以减少不同通道之间振幅差异的影响。具体采用Z-score标准化方法^[21],在数据分布形态和模式保持不变的前提下,将每个通道的信号进行零均值和单位方差变换,标准化过程为

$$x' = \frac{x - \mu}{\sigma}, \quad (1)$$

式中: x 为原始EEG信号; μ 与 σ 分别为该通道在所有试次中对应时间点的均值与标准差; x' 为标准化后的信号。

2 模型架构

为实现对手部MI-EEG信号的高效解码,本文构建了一种轻量化的深层时空卷积融合网络。整体模型由三部分组成:1)首先在Lawhern等^[22]提出的EEGNet时空特征提取模块基础上进行优化,在卷积层中引入L2正则化以抑制过拟合。2)引入空间特征融合模块,通过进一步挖掘跨通道的皮层关联信息提升分类判别力。3)分类输出模块,通过展平层和全连接层实现最终分类。整体模型架构如图6所示。




图6 模型整体框架图

Fig. 6 Overall framework diagram of the model

2.1 优化的EEGNet卷积模块

本研究中,运动想象脑电信号的输入张量为 $X_i \in \mathbb{R}^{C \times T}$,其中 $C=21$ 表示EEG电极通道数, $T=750$ 为每段运动想象片段的时间采样点数。首先使用一个时间卷积(Conv2D)提取各通道内4 Hz及以上的多频段神经振荡时域特征,并在卷积层中加入L2正则化以抑制过拟合风险并提升模型泛化能力。随后采用深度卷积(DepthwiseConv2D)提取各通道间的相关特征,该层设置深度乘子 $D=2$,同时引入轻度L2正则化。采用核大小为(1, 4)的平均池化层对时间维度降采样(降至约62.5 Hz),以降低时序冗余。第三卷积层采用深度可分离卷积(SeparableConv2D),在时间和空间维度上同时捕捉局部时序特征与细粒度空间特征。随后通过大小为(1, 8)的平均池化层再次在时间维度下采样,将采样率进一步降至约7.8 Hz。

2.2 空间特征融合模块

为了进一步提升手部MI-EEG信号的分类判别力,本文在优化的EEGNet模块之后引入空间特征融合模块,对前一阶段提取的多通道时空特征进行压缩和判别。首先通过卷积核大小为(1, 1)的深度卷积对各通道进行独立卷积,提取通道内部更精细的空间特征,同时保持时间维度不变。随后利用二维空间卷积Conv2D(1, 1)对各通道特征进行加权融合,增强模型对重要特征通道的响应能力。该卷积操作保持特征图大小不变,并在保留时间特征的基础上充分挖掘通道间的皮层关联信息。通过多层次空间特征提取,该模块能够放大左右手运动想象在感觉运动皮层的微弱空间分布差异,从而有助于提高模型的泛化能力。

此外,为防止过拟合,每个卷积模块后均加入批量归一化(BN)、ELU激活函数和丢失层($p=0.25$ 或 0.5),以稳定特征分布并减小训练过程中的内部协变量偏移。

2.3 分类输出模块

模型的最后部分由一个展平层(Flatten)和两个全连接层(Dense1和Dense2)构成。其中,Dense1层包含64个神经元,采用ELU激活函数,并结合L2正则化与50%的Dropout以进一步抑制过拟合。Dense2层作为输出层,包含4个神经元,配合softmax激活函数实现多分类任务,同样使用L2正则化和权重范数限制。通过在模型末端引入

更深的全连接结构并配合多种正则化策略,对前一阶段提取的特征进一步整合与判别性映射,以完成最终的分类预测。

2.4 训练配置与策略

本文在Python 3.9.13版本的环境下采用TensorFlow/Keras框架,通过单CPU(Intel Core Ultra 9 185H)对模型进行训练与评估。在每轮实验中,随机选取2/3的数据集作为训练集,其余为测试集。训练批量大小设为32,epoch为100,损失函数为分类交叉熵。模型训练过程中采用Adam优化器,初始学习率为0.001,并引入指数衰减策略(衰减步数为10 000,衰减率为0.9)以提升学习稳定性。上述超参数均通过多次试验确定,以平衡训练效率与模型泛化能力。

3 结果与讨论

3.1 左右手运动想象的ERSP对比分析

为分析左右手运动想象任务在感觉运动皮层的时频特性,本研究采用MATLAB的pop_newtimef()函数计算事件相关频谱扰动(Event-Related Spectral Perturbation, ERS),分别对左手任务条件和右手任务条件在C3/C4通道数据集上计算平均ERSP,以直观反映感觉运动Mu节律(8~13 Hz)的事件相关去同步化(ERD)和同步化(ERS)现象。




图7 左手运动想象的C3/C4 ERS图

Fig. 7 ERS maps of left-hand motor imagery at electrodes C3 and C4

如图7所示,当想象左手运动时,在对侧大脑半球C4电极上诱发出了非常强烈且集中的ERD,表现为8~13 Hz频带内显著的蓝色能量下

降(颜色更深,范围更宽),而在同侧C3电极上,ERD效应则相对微弱。

相反,当想象右手运动时,在对侧大脑半球C3电极上比同侧C4电极诱发了更显著、更集中的ERD,且其下方曲线所示的平均功率下降幅度也更大,如图8所示。该ERSP结果符合运动想象的特异性神经编码模式^[23-24],即对侧支配性,同时持续的ERD现象表明受试者在整个任务期间保持了稳定的运动想象激活。




图8 右手运动想象的C3/C4 ERSP图

Fig. 8 ERSP maps of right-hand motor imagery at electrodes C3 and C4

3.2 分类结果与性能评估

本研究中采用分类准确率与Kappa系数^[25]对模型进行性能评估,以量化模型预测结果与真实标签之间的一致性程度,Kappa系数的计算公式如式(2)所示。

$$Kappa = \frac{p_o - p_e}{1 - p_e}, \quad (2)$$

式中: p_o 为观察一致性; p_e 为预期一致性。

在当前配置下,5名受试者在该模型下均获得了较好的分类结果,具体如表1所示,表明模型能够有效学习MI-EEG特征。其中,被试S02的表现最佳,分类准确率和Kappa值分别为98.44%和0.98,整体平均分类准确率和Kappa值分别为90.89%和0.88。本研究在公共BCI 2a数据集上进行了评估,实验结果如表2所示,其中,被试A09表现最佳,分类准确率和Kappa值分别为85%和0.80,整体平均分类准确率和Kappa值分别为61.85%和0.58。在多被试、多任务条件下,模型能够有效捕获关键运

动想象频段的判别信息。虽然该数据集的信噪比较低,数据量有限,但是模型仍能保持相对稳定的分类性能,显示出较好的泛化能力和相对稳定的个体差异适应性。

表1 分类准确率与kappa值

Tab. 1 Classification accuracy and kappa value

受试者编号	准确率/%	Kappa系数
S01	90.69	0.86
S02	98.44	0.98
S03	88.00	0.84
S04	94.00	0.92
S05	83.33	0.78
均值	90.89	0.88

表2 公共BCI 2a数据集的分类准确率与Kappa值

Tab. 2 Classification accuracy and Kappa value of public BCI 2a dataset

受试者编号	准确率/%	Kappa系数
A01	73.33	0.64
A02	60.00	0.47
A03	81.67	0.76
A04	63.33	0.51
A05	43.33	0.24
A06	55.00	0.40
A07	80.00	0.73
A08	78.33	0.71
A09	85.00	0.80
均值	61.85	0.58

为了评估模型在测试集上的收敛情况及性能稳定性,本研究绘制了测试集准确率与损失值随训练轮次变化的曲线,如图9所示。红色曲线表示准确率,蓝色曲线表示损失,可以观察到准确率在训练初期迅速提升,并在随后阶段保持在较为稳定的高值区间,表明模型能够在早期阶段有效捕捉与手部运动想象相关的关键判别特征。




图9 测试集准确率和损失曲线

Fig. 9 Curves of test accuracy and loss

同时,损失值从较高初值(约2.25)迅速下降,并在第10个训练轮次(epoch)后进入相对稳定的低值区间,随后维持平稳且持续小幅下降,表明模型收敛速度较快。整体来看,测试集的准确

率与损失曲线的平稳趋势说明模型具有良好的泛化能力,未出现明显过拟合。ROC 曲线能够全面评估分类模型在不同判别阈值下的灵敏性与特异性,是衡量多类 MI-EEG 解码性能的重要指标^[26-27]。通过计算其对应的 AUC,可以直观反映模型对各类别的整体区分能力。如图 10 所示,本研究在四类手部运动想象任务上的 ROC 曲线均紧贴图表左上角,且其曲线下 AUC 面积均达到 0.99,表明模型在左右手食指屈曲和握拳任务上的识别性能十分优越,能够在极低的假阳性率下仍维持极高的真阳性识别率。此外,各曲线之间的差异极小,说明模型在多类手部运动想象解码中具有较好的稳定性和泛化能力,且不存在明显的类别不平衡或偏置现象,进一步验证了模型能够有效捕获手部精细运动想象的关键神经动态特征。





图 10 ROC 曲线和 AUC 值

Fig. 10 Comparison of ROC curves and AUC values


在分类任务中,虽然整体准确率能反映模型的总体性能,但难以揭示类别间的判别差异与错误分布。混淆矩阵通过展示各类别的预测与实际的对应关系,可直观识别模型在各类别上的判别能力及易混淆情况,从而提供更细粒度的性能洞察^[28]。图 11 分别展示了受试者 S02、S05 的四分类和所有被试四分类、二分类的手部运动想象任务的预测结果,分类性能最佳被试 S02 的 4 类手部 MI-EEG 在该模型下展现出了较好的判别性能,两种右手任务条件均达到极高的分类精度,且仅存在左/右食指间和左/右握拳间的轻度混淆。分类性能最差被试 S05 在左手与右手任务 MI-EEG 上,存在相对明显混淆现象,左右手握拳均与同侧食指任务之间存在轻微判别误差。

从所有被试的平均混淆矩阵来看,左手食指与

右手握拳、右手食指与左手握拳之间均不存在混淆现象,这表明食指屈曲和握拳两类手部运动想象在脑电特征上具有良好的可区分性,模型能够准确区分不同手部精细动作类型。同时,左右手相同动作的脑电特征也能得到有效区分,说明模型在解码左右手运动意图时具有稳定的判别能力。此外,由右手任务的二分类混淆矩阵结果可见,正确分类率均达到 99.61%,仅有约 0.39% 的轻微误差,进一步对比不同被试的数据可发现,这部分误差主要来源于 S01 和 S05。被试之间在运动想象策略、注意力波动以及皮层激活模式上的差异,可能导致特征表达轻微偏移,从而产生这些低比例的分类误差。



(a) S02 和 S05 被试四分类



(b) 所有被试四分类和右手二分类

图 11 混淆矩阵图

Fig. 11 Confusion matrix for MI-EEG classification

3.3 消融实验

为验证所提出模型对大规模高质量训练数据的依赖程度,本研究进一步设计了小规模训练数据消融实验,结果如图 12 所示。通过系统性减少训练样本数量,从原始训练集中分别抽取 80%、60% 和 40% 的样本构建不同规模的训练集,分析样本规模变化对模型分类性能的影响。结果表明,当训练样本比例由原始训练集降至 80% 时,模型整体分类性能仅出现小幅下降。在使用 60% 和 40% 训练样本的情况下,最低分类准确率大于 70%,且被试 S04 和 S05 的数据仍能够保持较为稳定的分类性能。整体来看,随着训练样本规模逐步减少至最小规模,模型分类准确率虽呈现一定程度的下降趋势,但整体变化幅度较为有限,

未出现性能明显退化或不稳定的现象。即使在训练样本数量显著受限的情况下,所提出模型仍能保持相对稳定的分类性能。




图 12 不同训练样本比例下的分类准确率对比

Fig. 12 Comparison of classification accuracy under different training sample ratios

深层卷积网络在逐层特征抽象过程中,可能弱化部分与MI判别密切相关的频谱信息。本研究进一步对 μ 波(8~13 Hz)和 β 波(13~30 Hz)进行频段消融实验,结果如图 13 所示。




图 13 不同频段去除的分类准确率对比

Fig. 13 Comparison of classification accuracy under different frequency band removal

通过在数据中去除相应频段信息,并比较分类性能变化,评估模型对这些关键频段的依赖程度。实验结果表明,去除 μ 波或 β 波后,模型分类性能均出现不同程度的下降,说明模型在训练过程中有效捕获了这些关键频段的判别信息。该实验从频谱层面验证了深层卷积模型在运动想象脑电任务中的特征学习能力,即模型能够保留并利用对分类任务最为重要的神经生理特征。

3.4 各模型对比

在确保数据输入一致的前提下,即均为相同

预处理后的数据集,将所提出的模型与主流模型 EEGNet 和 ATCNet^[29]进行了对比,结果如图 14 所示。由图 14 可以看出,在本文模型下,所有被试的分类性能均得到了不同程度的提升,整体分类准确率分别提高了 3.9 个百分点和 4.1 个百分点,说明所提模型在手部运动想象任务中具有更强的特征表达与判别能力。其中,受试者 S01 的提升效果最明显,本文模型在该被试的数据中展现出更强的时空特征提取能力。受试者 S02 和 S05 在三种模型下均获得了最佳和最差的分类结果,这一现象可能来源于常见的个体差异性。S02 运动想象诱发的传感运动节律可能更具可分性,具有更稳定的任务相关特征,使得模型能够学习到更可靠的判别模式。相反, S05 的 EEG 信号可能受到噪声水平、任务依从性、节律幅度偏低等因素影响,导致其运动想象特征分布更为模糊,模型难以建立清晰的类别边界,从而降低整体分类效果。总体而言,实验结果验证了本文模型在分类准确率和稳定性方面均优于 EEGNet 和 ATCNet,同时在跨被试差异下也展现出更高的可解释性与鲁棒性。




图 14 各模型的分类准确率对比

Fig. 14 Comparison of classification accuracy among different models

为进一步评估不同模型对手部 MI-EEG 特征的分离效果,本研究对原始特征、所提出模型、EEGNet 和 ATCNet 的嵌入特征分别进行了 t-SNE 可视化分析,如图 15 所示。从原始数据的 t-SNE 分布可以看出,四类动作在低维空间中呈现出明显的混杂,不同类别之间没有边界,同类别内部也缺乏聚类结构,表明未经过模型处理的原始 EEG 特征的可分性极弱。相比之下,本文模型提取的特征在 t-SNE 空间中形成了更为紧凑的同类聚类,不同类别之间的间隔很大,类别边界

较清晰,显示出模型能够有效增强特征的类内一致性和类间可分性。EEGNet 和 ATCNet 的 t-SNE 虽也呈现一定的类别分离趋势,但聚类结构相对松散,类别间仍存在一定程度的重叠,其特征判别能力弱于所提出模型。整体来看,这四组可视化结果进一步验证了所提出模型在特征表征质量上的优势。




图 15 t-SNE 可视化结果
Fig. 15 t-SNE visualization results

4 结 论

本研究针对手部精细动作运动想象脑电信号解码的问题,设计了诱发被试左右手食指屈曲及握拳的运动想象脑电实验范式,并构建了一种基于时空特征融合的轻量级卷积神经网络,对多通道 EEG 信号进行了特征学习与分类。通过对左右手运动想象的时频特征对比分析,验证了脑电信号的对侧支配性特征。同时,本研究从损失曲线、ROC 曲线及混淆矩阵等多种评估指标对模型进行了系统分析,结果显示模型训练收敛良好,并在分类任务中表现出优异且稳定的判别性能,平均分类准确率为 90.89%,平均 Kappa 系数为 0.88。相较于其他主流模型,本模型在分类准确率和稳定性方面均有所提升,t-SNE 可视化显示特征聚类更加紧凑。通过进一步引入空间特征融合模块,模型能够更充分地捕捉手部运动想象相关的时空特征,提升了解码性能并增强了可解释性。尽管本研究取得了良好的分类性能,但样本量有限且仅覆盖四类手部精细运动想象任务,可能影响模型的泛化能力。未来可进一步探索模型

在更大规模数据集及实时脑机接口系统中的应用,同时拓展至复杂运动想象和多任务解码,从而为康复训练与智能交互提供支持。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors declare no relevant conflict of interests.

参考文献:

- [1] ZHAO Z P, NIE C, JIANG C T, et al. Modulating brain activity with invasive brain-computer interface: A narrative review[J]. Brain Sciences, 2023, 13(1): 134.
- [2] ELASHMAWI W H, AYMAN A, ANTOUN M, et al. A comprehensive review on brain-computer interface (BCI)-based machine and deep learning algorithms for stroke rehabilitation[J]. Applied Sciences, 2024, 14(14): 6347.
- [3] 贺庆, 郝思聪, 司娟宁, 等. 面向脑机接口的脑电采集设备硬件系统综述[J]. 中国生物医学工程学报, 2020, 39(6): 747-758.
HE Qing, HE Sicong, SI Juanning, et al. Research development of electroencephalogram acquisition devices for brain computer interface[J]. Chinese Journal of Biomedical Engineering, 2020, 39(6): 747-758. (in Chinese)
- [4] CRAIK A, HE Y, CONTRERAS-VIDAL J L. Deep learning for electroencephalogram (EEG) classification tasks: a review[J]. Journal of Neural Engineering, 2019, 16(3): 031001.
- [5] 刘铁军, 徐鹏, 余茜, 等. 运动想象的脑机制及其在运动功能康复中应用的研究进展[J]. 生物化学与生物物理进展, 2011, 38(4): 299-304.
LIU Tiejun, XU Peng, YU Qian, et al. The research and progress in the mechanism of motor imagery and its application in motor rehabilitation[J]. Progress in Biochemistry and Biophysics, 2011, 38(4): 299-304. (in Chinese)
- [6] ALTAHERI H, MUHAMMAD G, ALSULAIMAN M, et al. Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: A review[J]. Neural Computing and Applications, 2023, 35(20): 14681-14722.
- [7] WANG Y, FANG Y, HUANG W, et al. Development of lower limb exoskeleton rehabilitation robot framework based on multi-modal motion intent detection[J]. IEEE Access, 2025, 13: 58152-58163.
- [8] WANG W, SHI B, WANG D, et al. Enhanced

- lower-limb motor imagery by kinesthetic illusion[J]. *Frontiers in Neuroscience*, 2023, 17: 1077479.
- [9] SOBIERAJEWICZ J, PRZEKORACKA-KRAWCZYK A, JAŚKOWAKI W, et al. The influence of motor imagery on the learning of a fine hand motor skill[J]. *Experimental Brain Research*, 2017, 235(1): 305-320.
- [10] CHEN Z, WANG Z, WANG K, et al. Recognizing motor imagery between hand and forearm in the same limb in a hybrid brain computer interface paradigm: An online study[J]. *IEEE Access*, 2019, 7: 59631-59639.
- [11] YU S H, GO Y M, PARK H Y, et al. Towards motor imagery classification of finger tapping by both hands for controlling a finger-arm bionic robot[C]// 2024 12th International Winter Conference on Brain-Computer Interface (BCI), 2024: 1-4.
- [12] MWATA-VELU T, RUIZ-PINALES J, ROSTRO-GONZALEZ H, et al. Motor imagery classification based on a recurrent-convolutional architecture to control a hexapod robot[J]. *Mathematics*, 2021, 9(6): 606.
- [13] DING Y, UDOMPANYAWIT C, ZHANG Y, et al. EEG-based brain-computer interface enables real-time robotic hand control at individual finger level[J]. *Nature Communications*, 2025, 16: 5401.
- [14] MAGHSOUDI A, SHALBAF A. Hand motor imagery classification using effective connectivity and hierarchical machine learning in EEG signals[J]. *Journal of Biomedical Physics & Engineering*, 2022, 12(2): 161-170.
- [15] GARCÍA-MURILLO D G, ÁLVAREZ-MEZA A M, CASTELLANOS-DOMINGUEZ C G. KCS-FCnet: Kernel cross-spectral functional connectivity network for EEG-based motor imagery classification[J]. *Diagnostics*, 2023, 13(6): 1122.
- [16] QIN Y, LI B, WANG W, et al. ETCNet: An EEG-based motor imagery classification model combining efficient channel attention and temporal convolutional network[J]. *Brain Research*, 2024, 1823: 148673.
- [17] LI R, LIU J, YANG S, et al. A novel grasping robot control method using motion execution BCI combining knowledge reasoning[J]. *IEEE Journal of Biomedical and Health Informatics*, 2025: 3622255.
- [18] CROTTI M, KOSCHUTNIG K, WRIESSNEGGER S C. Handedness impacts the neural correlates of kinesthetic motor imagery and execution: A fMRI study[J]. *Journal of Neuroscience Research*, 2022, 100(3): 798-826.
- [19] JIN J, QU T, XU R, et al. Motor imagery EEG classification based on Riemannian sparse optimization and Dempster-Shafer fusion of multi-time-frequency patterns[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31: 58-67.
- [20] LAJTOS M, BARRADAS-CHACÓN L A, WRIESSNEGGER S C. Effects of handedness on brain oscillatory activity during imagery and execution of upper limb movements[J]. *Frontiers in Psychology*, 2023, 14: 1161613.
- [21] FDEZ J, GUTTENBERG N, WITKOWSKI O, et al. Cross-subject EEG-based emotion recognition through neural networks with stratified normalization[J]. *Frontiers in Neuroscience*, 2021, 15: 626277.
- [22] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces[J]. *Journal of Neural Engineering*, 2018, 15(5): 056013.
- [23] 周正康, 袁之正, 颜亨, 等. 基于动态图卷积神经网络的运动想象脑电信号研究[J]. *计算机科学与应用*, 2024, 14(4): 268-275.
ZHOU Zhengkang, YUAN Zhizheng, YAN Heng, et al. Research on motor imagery EEG signals based on dynamic graph convolutional neural networks[J]. *Computer Science and Application*, 2024, 14(4): 268-275. (in Chinese)
- [24] LIU Y, WANG Z, HUANG S, et al. EEG characteristic investigation of the sixth-finger motor imagery and optimal channel selection for classification[J]. *Journal of Neural Engineering*, 2022, 19(1): 016001.
- [25] WARRENS M J. Five ways to look at Cohen's Kappa[J]. *Journal of Psychology & Psychotherapy*, 2015, 5: 1-6.
- [26] KUREMOTO T, BABA Y, OBAYASHI M, et al. Enhancing EEG signals recognition using ROC curve[J]. *Journal of Robotics, Networking and Artificial Life*, 2018, 4(4): 283-286.
- [27] PEREZ J A M, MARTIN P S P. ROC curve[J]. *Semergen*, 2023, 49(1): 101821.
- [28] 张开放, 苏华友, 窦勇. 一种基于混淆矩阵的多分类任务准确率评估新方法[J]. *计算机工程与科学*, 2021, 43(11): 1910-1919.
ZHANG Kaifang, SU Huayou, DOU Yong. A new multi-classification task accuracy evaluation method based on confusion matrix[J]. *Computer Engineering and Science*, 2021, 43(11): 1910-1919. (in Chinese)
- [29] ALTAHERI H, MUHAMMAD G, ALSULAIMAN M. Physics-informed attention temporal convolutional network for EEG-based motor imagery classification[J]. *IEEE Transactions on Industrial Informatics*, 2022, 19(2): 2249-2258.