Research on the Influence of Channel Selection Based on Synchronization and Node Properties in MI-EEG Classification *

XI Kai[1], LING Peng[1], CHEN Peng[1*], LI Simin[2]
(1.School of Mechanical Engineering, Southwest Jiaotong University, Chengdu Sichuan 610031, China;
2.Rehabilitation Medicine Center, West China Hospital, Sichuan University, Chengdu Sichuan 610041, China)

Abstract: To effectively extract motor imagery electroencephalography (MI-EEG) features and retain sufficient information, and seek a way to improve the classification accuracy of deep learning for MI-EEG, a channel selection method based on synchronization and node properties by considering the density of channel information is proposed. The phase locked value (PLV) is introduced to construct the brain network, and complete the classification and screening of each node in the brain network based on correlation. According to the density of channel information, 20 channels from 32 EEG channels related to MI research are selected as the inputs of the convolutional neural network (CNN) for the comparison of offline performance classification. After studying the effect of screening channels on MI-EEG classification, it is found that the average classification accuracy of MI-EEG is enhanced from 86.29% to 90.46% for 10 recruited subjects, and this index ranges from 85.30% to 93.56% for 4 samples from public data sets. Results analysis from the change of EEG energy and brain networks collectivization perspective reveals the channel selection influence on the properties of CNN classification for MI-EEG.

Key words: motor imagery electroencephalography; brain network; channel selection; phase locking value; convolutional neural network
EEACC: 7220; 7230J; 7510D **doi**: 10.3969/j.issn.1004-1699.2025.11.008

基于同步性及节点特性的通道选择对 MI-EEG 分类的影响研究 *

郗 凯[1], 凌 鹏[1], 陈 鹏[1*], 李思敏[2]
(1.西南交通大学机械工程学院, 四川 成都 610031; 2.四川大学华西医院康复医学中心, 四川 成都 610041)

摘 要: 为有效提取运动想象脑电特征并保留足够信息, 寻求提升运动想象脑电(MI-EEG)深度学习分类精度的途径, 从通道信息密度出发, 提出了一种基于同步性及节点特性的通道选择方法。在脑网络的构建中引入锁相值, 完成脑网络中各个节点的相关性分类筛选, 根据通道信息密度从 32 个与运动想象研究相关的 EEG 通道中选择 20 个通道作为卷积神经网络(CNN)的输入, 开展离线分类性能比较。研究筛选通道对 MI-EEG 分类的影响, 发现 10 位招募被试的运动想象脑电信号平均分类准确率由 86.29%提升到了 90.46%, 而 4 组公开数据集样本的该指标从 85.30%提升到了 93.56%, 结果分析从 EEG 能量的变化和脑网络集团化程度的角度揭示了通道选择对 MI-EEG 的 CNN 分类性能的影响。

关键词: 运动想象脑电; 脑网络; 通道选择; 锁相值; 卷积神经网络
中图分类号: TP181 **文献标识码**: A **文章编号**: 1004-1699(2025)11-1978-12

脑机接口(Brain-Computer Interface, BCI), 指的是在人的大脑与相关电子设备之间设置一种直接的连接方式, 使人的大脑与设备之间可以进行所需要的信息交换[1-2]。在构建脑机接口系统时, 可以使用不同的方法对大脑信号进行采集记录, 以作为脑机接口系统的输入[3]。一般来说, 根据检测采集大脑信号的传感器安放位置, 可以将脑机接口系统分为侵入式、半侵入式和非侵入式三种类型[4]。其中, 非侵入式 BCI 无需通过手术将传感器植入体内, 风险更低[5], 而非侵入式 BCI 中的脑电图(Electroencephalogram, EEG)操作简单, 实时性较高, 近年来已被广泛运用在 BCI 研究中[6]。随着 BCI 技术的发展, 运动想象脑电(Motor Imagery Electroencephalography, MI-EEG)的研究作用也在日益增加[7-10], 尤其是在医疗康复领域的人机交互研究, 如在促进中风后的运动恢复研究[11]及由患者精神意图控制的辅助康复设备设计[12]和用于辅助康复的控制电刺激设备设计[13]等方面都有着

项目来源: 四川省重点研发计划项目(2022YFS0021, 2023YFH0037)
收稿日期: 2023-08-03 **修改日期**: 2023-12-18

重要意义。而安全且有效地进行基于 MI-EEG 的医疗康复研究,对 MI-EEG 信号的分类效率及分类准确率有着较高的要求,这也是目前 MI-EEG 研究中比较重要的问题[14-15]。

在 EEG 信号中,mu 节律(8~12Hz)和 beta 节律(13~30Hz)会在被试处于静息状态时出现在感觉运动区,当被试进行某一侧肢体的运动(Motor Execution,ME)或者运动想象(Motor Imagery,MI)时,大脑另一侧皮质的感觉运动区里,EEG 信号的 mu 节律和 beta 节律会减小。这一生理现象被称为事件相关去同步化(Event-Related Desynchronization,ERD)[16]。当运动或运动想象停止后,感觉运动区里 EEG 信号的 mu 节律和 beta 节律会恢复到之前的状态,这种生理现象称为事件相关同步化(Event-Related Synchronization,ERS)。ERD 和 ERS 的这一特性,是 MI-EEG 信号特征的一种表征,体现了大脑在进行对侧肢体运动想象时的差异性,这种对侧效应也成为了目前进行 MI-EEG 信号分类的主要理论基础和分类标识[17]。

针对 MI-EEG 的分类,有研究尝试过使用传统机器学习方法进行 BCI 系统的构建,进行卒中和癫痫患者的交流辅助[18]以及对轮椅机器人的控制[19]。但由于 MI-EEG 具有低信噪比、非平稳性等特点,传统的机器学习方法无法获得较高的分类精度,因此开始了使用深度学习方法对 MI-EEG 进行分类的研究。深度学习是一种在图像[20]、语音[21]分类中都取得了优秀效果的机器学习模型,而卷积神经网络(Convolutional Neural Network,CNN)作为深度学习的代表算法,可以在特征图中发现具有高鲁棒性的空间特征[22],能够在 EEG 分类中发挥作用。近年来针对 MI-EEG 分类出现了许多优秀的 CNN 算法,其中 EEGNet[23]算法凭借高泛化性和高准确率的优势,被广泛应用于 MI-EEG 研究中,其核心思想为分别对通道维度和时间维度进行卷积,以分别从这两个维度直接提取特征并进行分类。从通道维度提取特征时,主要使用小卷积核进行卷积,同时需要对 EEG 通道进行重新选择,选择与运动想象相关的通道,并保留各通道间的相关性。对于 CNN 卷积核的处理,张军峰等[24]使用改进的密度峰值聚类(DPC)算法进行优化,应用于花生籽粒完整性检测,通过聚类分析选择最佳特征图,从而确定 CNN 的最佳卷积核。该方法从局部密度的角度对特征信息进行筛选,为 MI-EEG 数据的 CNN 分类提供了通道筛选的依据。通道筛选除了利于保留用于分类的特征信息,还可以减少脑电采集需要的电极通道,从而一定程度地降低成本和分析时间,提高可用性和用户接受度[25],对实现临床应用有很大帮助。

MI-EEG 的通道选择问题已在相关研究中得到了关注。潘礼正等[26]从通道特征信息角度出发,基于个体差异和频带信号特点,提出了一种基于个体自适应的运动想象脑电信号特征表征方法,实现了各个频带的信号通道选择。该方法考虑了各个信号通道的特征信息,进行了 MI-EEG 的特征表征,但并未考虑通道间的相关性信息。为了将 MI-EEG 信号中的特征信息最大化提取,进一步提升 MI-EEG 信号分类效率,除可以利用 ERD/ERS 现象提取 MI-EEG 信号的特征信息,还可以考虑各 MI-EEG 信号通道间的相关性信息。

锁相值(Phase Locking Value,PLV)作为一种体现相位同步性的概念,可以作为判断 EEG 通道间相关性大小的数据指标[27]。Gonuguntla 等[28]利用 EEG 和 PLV 构建脑网络,对比休息状态和运动想象状态的脑网络差异。作为通道间相关性信息的数据体现,PLV 与通道特征信息综合,可对通道信息密度进行排序,从而成为通道筛选的新途径。

考虑特征信息密度对 CNN 分类性能的作用,充分利用各 EEG 通道的特征信息和通道之间相关性信息,研究通道选择对 MI-EEG 分类精度的影响,本文主要进行了以下工作:①通过构建脑网络的方式,反映各个通道之间的相关性;②根据各个节点的特性和节点间相关性信息,重新选择信息密度高的 MI-EEG 通道,作为 CNN 的输入数据;③利用 CNN 对通道选择对 MI-EEG 的影响进行分类,验证本文提出的通道选择方法对分类准确率的提升效果,并进行时频分析和脑网络的平均聚类系数分析,讨论影响分类准确率增幅的因素。相较于其他的通道筛选方法,本文不局限于每个通道的特征信息,而是从通道特征信息和通道间同步性信息的角度出发,以脑网络方法从整体电极通道考虑,保留信息密度较高的通道,旨在尽可能表现被试 MI-EEG 信号特征,提升 CNN 在非限定数据集上的分类性能,对 MI-EEG 应用于康复、外设控制及疾病诊断等领域有着一定的应用潜力。

1　数据获取与处理

1.1　数据来源

为了验证本文的通道选择方法对 MI-EEG 分类准确率提升的有效性及泛用性,本文使用了 BCI competition Ⅳ[29]的公开数据集 1 和实验室自采 EEG 数据进行分析处理。其中公开数据集包含了

实采数据和人工生成数据,本文仅选择了被试 A、B、F、G 提供的实采数据。实验内容为健康被试从左手、右手和脚选择两类运动想象任务,根据屏幕的箭头提示进行相应的运动想象任务。采样通道为 59 个通道,采样频率为 1 000 Hz。开始为 2 s 的空白屏幕,之后显示 4 s 提示动作,帮助被试进行运动想象任务,最后为 2 s 的固定十字架。每位被试分别进行了 200 次运动想象任务。

实验室自采 EEG 数据中被试为 10 名在校学生(S1~S10,均为男性,平均年龄为 23 岁)。被试均为右利手,没有已知的神经或心理障碍,没有使用精神类药物或任何影响中枢神经系统的药物,此前没有参加过任何 BCI 实验。数据采集设备为 ANT Neuro 公司出产的 eego 系统以及配套软件 eegoTM software。采样通道为 10-20 国际标准中的 64 个通道,采样频率为 1024Hz。每个受试者分别坐在一张舒适的椅子上,目视显示实验范式的电脑屏幕进行左右手运动想象实验。在实验过程中,受试者被要求避免眨眼和肢体动作。实验部分包括四组连续脑电图信号记录。每个受试者每组实验中包括 40 次运动想象任务,共做 4 组实验,160 次运动想象任务。运动想象流程如图 1 所示,在每次运动想象任务中,计算机屏幕首先显示黑屏 3 s,然后显示拳头向左或向右移动的视频 3 s,最后是一个 5 s 的向上向左或向上向右的箭头,每完成 10 次任务休息 30 s。受试者在屏幕变黑时保持放松,在播放视频时保持专注,并在箭头出现时开始想象相应的动作。两组实验之间休息 5 min。

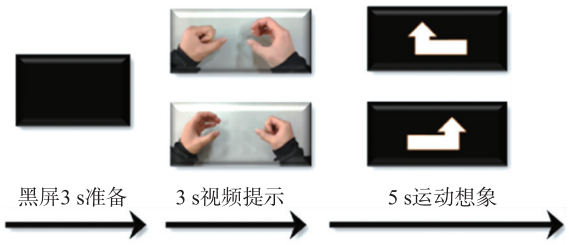

图 1 每次运动想象任务流程

1.2 数据预处理

为了从包含大量噪声的原始 EEG 信号中提取出较为纯净的 MI-EEG 成分,本文使用 MATLAB 下的 EEGLAB 工具箱对公开数据集和采集到的原始连续 EEG 进行简单的预处理。首先进行 50 Hz 的去工频干扰滤波,由于运动想象所产生的脑电波节律变化主要集中在 mu 节律(8 Hz~12 Hz)和 beta 节律(13 Hz~30 Hz)频段[30],本文之后进行了 1 Hz~35 Hz 的带通滤波,并降采样至 500 Hz。为了提取出执行运动想象时的 MI-EEG 信号,需要对连续的数据进行分段(epoch),即提取出所有箭头出现的前 0.5 s 至箭头出现后 4 s 的 MI-EEG 数据。最后对数据进行了独立成分分析(ICA),以去除数据中非脑电的成分。

2 研究方法

本文从通道特征信息和通道间相关性信息的角度出发,对 MI-EEG 信号特征进行提取。根据通道特征信息选择与运动想象脑电研究相关的通道作为初始通道,构建基于图论的脑网络,再依靠反映同步性的通道间相关性信息对初始通道进行筛选,得到最终保留的 MI-EEG 通道,并将其作为 CNN 的输入,进行分类验证。作为一种面向运动想象脑电分类的卷积神经网络,EEGNet 可以分别从通道和时间两个维度进行卷积,提取两个维度中的信号特征,从而完成对 EEG 数据的分类。在本研究的前期工作中[31],在参考 EEGNet 网络结构的基础上,再结合 MI 的特点,已经实现了一种直接利用 EEG 时序信号作为输入的 CNN 算法,以处理 EEG 信号离线和在线分类问题。在此基础上,根据本文提出的通道筛选方法,使用该 CNN 网络结构进行验证分析。

2.1 EEG 信号的通道选择

为了尽可能保存 EEG 信号中各个通道的特征信息和通道之间的相关性信息,同时对不重要的通道进行剔除,提高分析效率和分类准确率,需要对 EEG 信号中可以保留的通道进行选择。Al-Saegh 等[32]发现,与运动想象相关的通道主要为 10-20 国际标准导联系统中的 FC5,FC3,FC1,FCz,FC2,FC4,FC6,C5,C3,C1,Cz,C2,C4,C6,CP5,CP3,CP1,CPZ,CP2,CP4,CP6。这些通道正好对应着大脑皮质中的感觉运动区,并且其中的 C3 和 C4 通道为 MI-EEG 的 ERD/ERS 现象主要研究通道。由于通道之间存在相关性关系,本文考虑针对不同被试,在部分通道中选择与被试相适应的通道数据进行运动想象分类。为了尽可能多保存 MI-EEG 的信息,综合考虑本文实验数据的情况,本文保留了 F5,F3,F1,F2,F4,F6,FC5,FC3,FC1,FCz,FC2,FC4,FC6,C5,C3,C1,Cz,C2,C4,C6,CP5,CP3,CP1,CP2,CP4,CP6,P5,P3,P1,P2,P4,P6 共计 32 个通道作为初始通道进行分类验证,以作为对照,在此基础上进行下一步的通道筛选。同时将运动想象研究中常用的 C3,Cz,C4,FC3,FCz,FC4,CP3,CP4 通道[33]作为固定选择通道,在剩余的 24 个通道中,根据构建脑网络得到的通道之间相关性信息,再选择 12 个通道进行 20 通道的分类验证实验。

2.2　脑网络结构的构建

为了更好地提取 EEG 信号的特征,除了根据 ERD/ERS 现象选择保留的 EEG 信号通道,还需要考虑通道与通道之间的特征信息关系。本文根据通道特征信息和通道间的相关性关系,构建了基于图论的脑网络。基于图论的脑网络可以表示为 $G=(\boldsymbol{V},\boldsymbol{E})$,其中 $\boldsymbol{V}=(V_1,V_2,V_3,\cdots)$,代表脑网络中节点的集合,$\boldsymbol{E}\subseteq\boldsymbol{V}\times\boldsymbol{V}$ 代表由脑网络中的节点组成的边的集合。在基于图论的脑网络中,可以使用以下网络特征参数对网络性能进行评价。

2.2.1　脑网络特征参数

为了评价所构建脑网络的连接性和相关性,本文使用平均度 K_a,平均聚类系数 CC 和网络密度 Den 进行网络性能的衡量。

平均度 K_a,指脑网络中所有节点的度的平均值。其中 N 为脑网络中的节点数量,K_i 指脑网络中第 i 个节点的度。

$$K_a=\frac{1}{N}\sum_{i=1}^{N}K_i \tag{1}$$

平均聚类系数 CC 指脑网络中节点和邻居节点连接的程度,可以体现脑网络的集团化程度。其中 C_i 指脑网络中第 i 个节点的聚类系数。

$$\mathrm{CC}=\frac{1}{N}\sum_{i=1}^{N}C_i \tag{2}$$

网络密度 Den 指脑网络的稠密程度,其中 E 为脑网络中经过阈值筛选后存在的边数。

$$\mathrm{Den}=\frac{E}{N(N-1)/2} \tag{3}$$

2.2.2　节点相关性关系

为了体现节点与节点之间的相关性关系,本文引入锁相值的概念,来确定节点之间是否有边的存在。锁相值可以将 EEG 信号中各通道的同步性特征引入脑网络,尽可能运用每个节点的信息以及节点之间的关系。如式(4)、式(5)所示,对于单变量的连续时间信号 $x(t)$ 和 $y(t)$,其相位同步关系可以通过锁相值表示:

$$\mathrm{PLV}=\left|\left\langle \mathrm{e}^{\mathrm{i}\boldsymbol{\Phi}_{xy}(t)}\right\rangle_t\right|=\sqrt{\left\langle\cos\boldsymbol{\Phi}_{xy}(t)\right\rangle_t^2+\left\langle\sin\boldsymbol{\Phi}_{xy}(t)\right\rangle_t^2} \tag{4}$$

$$\boldsymbol{\Phi}_{xy}(t)=\boldsymbol{\Phi}_x(t)-\boldsymbol{\Phi}_y(t) \tag{5}$$

式中:〈 〉表示对时间的平均值,$\boldsymbol{\Phi}_x(t)$ 和 $\boldsymbol{\Phi}_y(t)$ 分别代表 $x(t)$ 和 $y(t)$ 的瞬时相位。根据上述公式,可以得出任意两个时间信号 $x(t)$ 和 $y(t)$ 的锁相值,若 $PLV=0$,则说明 $x(t)$ 和 $y(t)$ 无相位同步;若 PLV=1,则 $x(t)$ 和 $y(t)$ 相位同步。PLV 的取值为 [0,1],PLV 值越大,说明相位差的变化越小[34]。

因此,本文引入锁相值的概念描述 EEG 信号中各通道的相关性,并构建脑网络。考虑在构建脑网络时,运动想象研究常用通道 C3,Cz,C4,FC3,FCz,FC4,CP3,CP4 需要固定保留,因此本文从这 8 个固定选择通道出发,对余下的 24 个通道进行分类选择。将每个通道视为脑网络中的一个节点,而对每个节点 u 进行分类的依据主要为以下三点:①节点特性,主要包括通道的 ERD/ERS 现象,本文根据此特征选择了 C3,Cz,C4,FC3,FCz,FC4,CP3,CP4 作为 8 个固定通道以及包括固定通道在内的 32 个初始通道作为待选通道;②与相邻节点的相关性,根据节点 u 与其他节点 PLV 值大小确定节点间的相关性大小;③根据节点 u 与其相邻节点间的相关性大小以及相邻节点的分类标签来确定节点之间是否存在边连接关系,也就是确定节点 u 的分类标签。根据上述内容,本文提出了一种基于脑网络的通道分类筛选方法。

2.2.3　相关性矩阵的构建

为了得到节点间的相关性,将 EEG 的电极通道视为节点,则节点间的锁相值视为边。根据计算得到各通道之间的锁相值,可以得到各个节点的相关性矩阵,从而构建出脑网络。本文定义两个通道之间的功能连接 d_{ij},表示通道 i 和通道 j 之间的锁相值,如式(6)所示:

$$d_{ij}=\mathrm{PLV}(i,j) \tag{6}$$

据此,便可以得到正向化后的相关性矩阵 $\boldsymbol{D}$,如式(7)所示:

$$\boldsymbol{D}=\begin{pmatrix} d_{11} & d_{12} & \cdots & d_{1n}\\ d_{21} & d_{22} & \cdots & d_{2n}\\ \vdots & \vdots & \ddots & \vdots\\ d_{n1} & d_{n2} & \cdots & d_{nn}\end{pmatrix} \tag{7}$$

得到相关性矩阵后,需要选择合适的阈值将相关性矩阵转化为邻接矩阵。经过阈值选择后构建的脑网络不能过分稀疏或稠密,需要满足平均度 $K_a>2\ln N$,并且网络密度 Den 不宜过高,综合考虑网络的连通性等约束条件后,本文将阈值选择为 0.4。即节点间锁相值大于阈值,则认为节点间存在边,否则就没有边的存在。

2.2.4　节点相关性分类

完成相关性矩阵的构建后,需要根据节点间相关性和已知节点的分类标签得到所有节点的分类标签,完成节点相关性分类。将节点 u 的分类标签 P_u 按式(8)定义:

$$P_u=\begin{cases}0 & \text{节点未被选择}\\ 1 & \text{节点被选择}\end{cases} \tag{8}$$

首先将固定选择通道 C3, Cz, C4, FC3, FCz, FC4, CP3, CP4 的分类标签定为 1, 对于剩余未带标签的 24 个节点, 将其分类标签初始化为 0。之后根据相关性矩阵和已知的分类标签, 对 24 个节点的分类系数 Y_u 按式(9)进行迭代更新。

$$Y_u = \frac{1}{\sum_{i=1}^{n} d_{iu}} \times D_{u,:} P \tag{9}$$

式中: n 为本文选择的初始通道数 32, $\boldsymbol{P}$ 为由 32 个节点的分类标签组成的 32×1 矩阵。当结果收敛或达到最大迭代次数时, 则停止迭代。若 Y_u>0.5, 则该节点代表的通道被选择, 节点 u 的 P_u 为 1; 若 Y_u<0.5, 则该节点代表的通道未被选择, 节点 u 的 P_u 为 0。筛选后, 可得到 20 个分类标签为 1 的节点和 12 个分类标签为 0 的节点, 分类标签为 1 的 20 个节点即为最终保留的通道。

2.3 CNN 结构的重建

本文共使用了 10 名自采被试和 4 名公开被试的 EEG 数据, 因此提出的 MI-EEG 分类问题属于小样本集分类问题。为了避免出现由于模型过于复杂而产生的过拟合现象, 本文的 CNN 结构只包含三层卷积层, 两层池化层, 一层相关性层, 在经典的 EEGNet 基础上, 调整了卷积核的大小和卷积步长, 如图 2 所示。

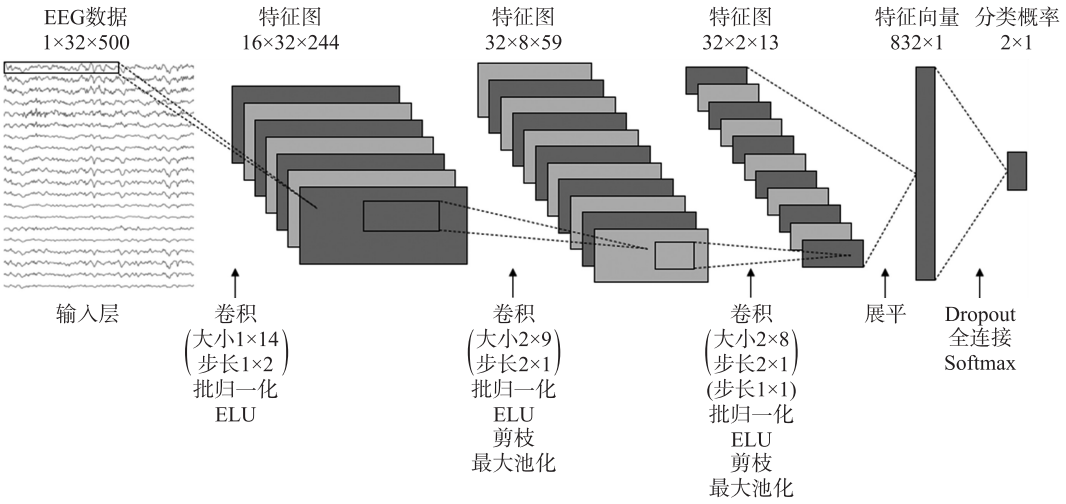

图 2 基于通道重新选择的 CNN 结构

在数据保留初始 32 通道进行分类时, CNN 结构中输入的单个样本维数为 1×32×500, 第一层卷积核的大小为 1×14, 步长为 1×2, 采用部分填充的方式。该层主要是对一维信号进行时域卷积, 减小信号在时间维度上的长度, 细化时域信号中各个信道的特征。第一层卷积输出的特征图通道数为 16。第二层卷积核大小为 2×9, 步长为 2×1。这样修改卷积运算可以在保持左右脑通道信号不混合的同时, 整合相邻通道的信息。在第二层卷积之后, 以 0.25 的比率进行剪枝操作。随机剪枝使部分神经元失活, 从而避免了神经网络的过拟合。接下来是第一个池化层, 池化内核大小为 2×4, 可以从卷积层计算的特征图中提取重要的特征信息。因为特征图的长度比宽度大得多, 所以使用 2×4 池内核。卷积的第三层使用 2×8 卷积核, 卷积的步长仍然是 2×1。在此之后, 以 0.25 的比率执行修剪, 并执行 2×4 池化操作。所有卷积运算的填充参数设置为 0, 即无填充模式。

当进行筛选后 20 通道的分类时, 第三层卷积层的卷积步长调整为 1×1, 其余参数不进行改变。此外, 在每次卷积操作后进行批量归一化处理, 并使用指数线性单元(ELU)激活函数进行激活, ELU 激活函数的公式见式(10), 其中 α 默认为 1。批处理归一化操作可以加快神经网络的学习速度, 减少对初始权值的依赖。ELU 激活功能是对 ReLU 激活功能的改进。与 ReLU 激活函数相比, 其输出的平均值接近于 0, 不会给下一层神经元增加额外的偏差, 从而加快了模型的收敛速度。并且, 在输入为负的情况下具有软饱和的特点, 对噪声的鲁棒性更强。

$$f(x) = \begin{cases} x & x>0 \\ \alpha(e^x - 1) & x \leqslant 0 \end{cases} \tag{10}$$

3 实验结果与分析

3.1 ERD/ERS 现象验证

为了验证保留的被试数据通道是否具有明显的 EEG 信号特征, 本文采取时频分析的方法对 EEG 信号进行特征提取, 观察 MI-EEG 数据的 ERD/ERS 现象。该方法结合时域和频域分析在

脑电信号特征提取中的优点,对 EEG 信号实现多角度多尺度特征提取[35]。本文使用小波变换(Wavelet Transform,WT)对 14 位被试的数据进行了时频分析,并绘制了时频图。其中 S1 被试 C3 和 C4 通道的时频图见图 3。

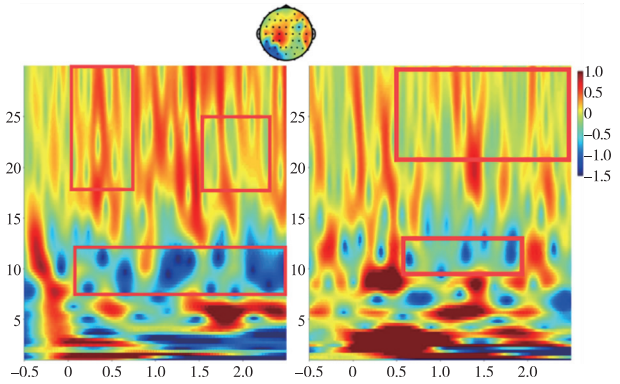

图 3　S1 被试 C3 和 C4 通道时频分析

从图中可以看出,运动想象开始后,在运动想象所产生的脑电波节律变化主要集中的 mu 节律和 beta 节律频段,均出现了较为明显的事件相关去同步化现象,已在图中框出。本文针对其他 13 名被试 C3 和 C4 通道的 EEG 信号进行了相同的时频分析,除了 S5 和 S6 的 ERD 现象不明显之外,其他被试的时频图中都观察到了较为典型的 ERD 现象,这一现象可以在后续分类过程中,通过 EEG 信号能量值对不同被试 ERD 现象的差异进行量化。由此可以初步验证,本文采集的数据可以进行有效的 EEG 信号特征提取。

3.2　脑网络的相关性矩阵及特征参数

将本文研究的与运动想象相关的 32 个初始通道 F5,F3,F1,F2,F4,F6,FC5,FC3,FC1,FCz,FC2,FC4,FC6,C5,C3,C1,Cz,C2,C4,C6,CP5,CP3,CP1,CP2,CP4,CP6,P5,P3,P1,P2,P4,P6 按照 1~32 重新编号,根据节点间相关性构建每位被试的相关性矩阵,其中 S1 和 S11 的相关性矩阵如图 4 所示。其中横坐标和纵坐标代表运动想象脑电信号中初始通道的序号,矩阵中的元素为节点间的锁相值,颜色越亮则说明节点间的相关性越强,颜色越暗则说明节点间的相关性越弱。

同时,本文计算了 14 名被试的脑网络特征参数,包括平均度 K_a,平均聚类系数 CC 和网络密度 Den,如表 1 所示。可以发现 S2 和 S9 的平均度,平均聚类系数和网络密度最高,说明这两位被试的脑网络复杂程度和集团化程度最高,拥有的信息密度更高,并且在运动想象时进行信息传递的能力更强。

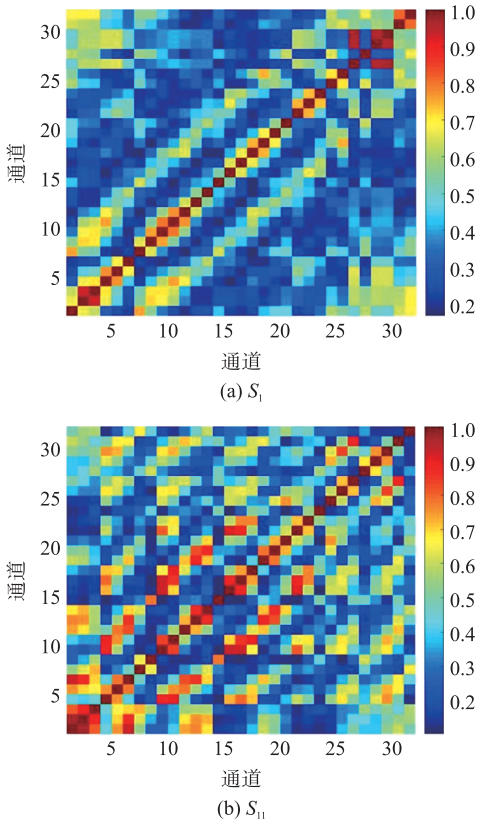

图 4　S1 和 S11 被试节点相关性矩阵

表 1　14 名被试的脑网络特征参数

被试	Ka	CC	Den
S1	14.02	0.66	0.63
S2	16.68	0.69	0.75
S3	13.05	0.67	0.59
S4	13.84	0.68	0.59
S5	14.31	0.67	0.67
S6	14.13	0.65	0.63
S7	14.45	0.69	0.67
S8	13.50	0.67	0.63
S9	16.82	0.68	0.81
S10	14.51	0.68	0.68
S11	14.49	0.56	0.70
S12	15.14	0.57	0.76
S13	13.55	0.55	0.63
S14	13.73	0.67	0.63

3.3　分类的评价指标

对于分类问题而言,常用的评价指标有:准确率(Accuracy)、精准率(Precision)和召回率(Recall)。本文使用准确率作为分类评价指标,准确率的计算公式如式(11)所示:

$$\mathrm{ACC}=\frac{\sum_{i=1}^{n}a_i}{N} \tag{11}$$

式中:a_i 为第 i 类分类正确样本数,N 为总样本。

3.4 基于通道筛选的分类结果

本文针对 10 组自采 MI-EEG 数据和 4 组公开 MI-EEG 数据,分别保留了初始 32 通道和筛选后 20 通道的数据,并将数据按照 8∶2 的比例划分为训练集和测试集,进行分类比较。最终将自采数据和公开数据初始 32 通道数据的最佳准确率与筛选后得到 20 通道数据的最佳准确率分别汇总于表 2 和表 3,并通过图 5 和图 6 柱状图表示。同时,所有被试经筛选后保留的 20 个通道如表 4 所示。

表 2 10 组自采数据初始通道和筛选后通道的准确率

%

被试	32 通道准确率	20 通道准确率	提升幅度
S1	89.47	90.42	1.06
S2	86.92	89.13	2.54
S3	87.10	87.21	0.12
S4	84.38	94.04	11.44
S5	84.46	91.73	8.60
S6	88.96	92.09	3.52
S7	86.69	89.28	2.99
S8	84.62	92.13	8.88
S9	86.30	89.58	3.80
S10	84.01	88.99	5.93

表 3 4 组公开数据初始通道和筛选后通道的准确率

%

被试	32 通道准确率	20 通道准确率	提升幅度
S11	85.85	97.64	13.73
S12	84.48	94.40	11.75
S13	84.62	94.38	11.53
S14	86.24	87.83	1.84

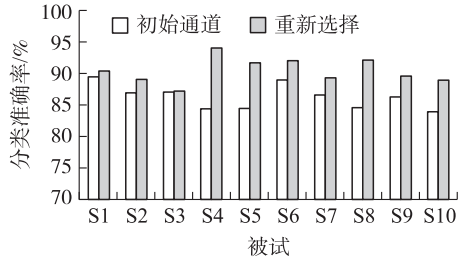

图 5 10 组自采数据初始通道和筛选后通道的准确率

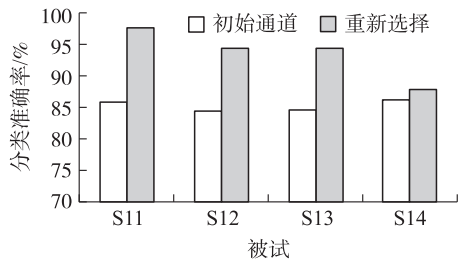

图 6 4 组公开数据初始通道和筛选后通道的准确率

表 4 14 名被试数据筛选后保留的 20 个通道结果

被试	筛选后保留的通道
S1	FC5,C3,Cz,C4,CP1,CP2,CP6,P4,F5,FC3,FCz,FC4,C5,C1,C2,C6,CP3,CP4,P2,P6
S2	F4,FC5,FC1,FC2,FC6,C3,Cz,C4,CP5,CP1,F2,F6,FC3,FCz,FC4,C5,C1,C2,CP3,CP4
S3	F3,FC5,FC1,FC2,C3,Cz,C4,CP2,CP6,F5,FC3,FCz,FC4,C5,C1,C2,C6,CP3,CP4,P6
S4	F3,FC5,FC1,FC6,C3,Cz,C4,CP6,P4,F5,FC3,FCz,FC4,C5,C1,C2,C6,CP3,CP4,P6
S5	F3,FC5,FC1,C3,Cz,C4,CP2,CP6,P4,F5,FC3,FCz,FC4,C5,C1,C2,C6,CP3,CP4,P2
S6	F3,FC5,FC1,C3,Cz,C4,CP1,CP2,CP6,F5,FC3,FCz,FC4,C5,C1,C2,C6,CP3,CP4,P6
S7	FC1,FC2,FC6,C3,Cz,C4,CP5,CP1,F6,FC3,FCz,FC4,C5,C1,C2,C6,CP3,CP4,P5,P1
S8	F4,FC2,FC6,C3,Cz,C4,CP5,P3,F2,F6,FC3,FCz,FC4,C5,C1,C2,C6,CP3,CP4,P5
S9	F3,FC5,FC1,C3,Cz,C4,CP2,CP6,P4,F5,F1,FC3,FCz,FC4,C5,C1,CP3,CP4,P2,P6
S10	F3,FC5,FC1,C3,Cz,C4,CP2,CP6,P4,F5,FC3,FCz,FC4,C5,C1,C2,C6,CP3,CP4,P6
S11	F2,FC3,FC1,FCz,FC2,FC4,C3,C1,Cz,C2,C4,C6,CP5,CP3,CP2,CP4,CP6,P3,P1,P2
S12	FC3,FC1,FCz,FC2,FC4,C3,C1,Cz,C2,C4,C6,CP5,CP3,CP1,CP2,CP4,P5,P3,P1,P2
S13	F2,FC3,FC1,FCz,FC2,FC4,FC6,C5,C3,C1,Cz,C2,C4,C6,CP5,CP3,CP2,CP4,P3,P1
S14	F2,F4,FC3,FC1,FCz,FC2,FC4,C3,C1,Cz,C2,C4,C6,CP5,CP3,CP2,CP4,CP6,P1,P2

从结果来看,对通道进行筛选后自采数据和公开数据的准确率均有不同程度的提升。10 组自采数据使用初始通道得到的分类准确率平均值为 86.29%,使用筛选后通道得到的分类准确率平均值为 90.46%,分类准确率的平均增幅为 4.83%。4 组公开数据使用初始通道得到的分类准确率平均值为 85.30%,使用筛选后通道得到的分类准确率平均值为 93.56%,分类准确率的平均增幅为 9.69%。这说明通过构建脑网络的方式对通道重新筛选对分类准确率的提升有很大的帮助。为了验证本文提出方法的有效性,将 4 组公开数据分类结果与文献[36]进行了比较,该文分别使用了公共空间模式(CSP)、滤波器组共空间模式(FBCSP)和时-频域滤波网络(OSS-FN)方法进行特征提取,并使用支持向量机(SVM)对与本文相同的公开数据集进行了分类,结果如表 5 所示。从对比结果来看,经过本文提出的通道选择方法处理后,公开数据集大部分数据的分类准确率有一定程度的提升。

表 5　4 组公开数据的分类准确率比较

被试	CSP-SVM	FBCSP-SVM	OSSFN-SVM	本文方法
S11	67.1	66.5	89.8	97.64
S12	76.6	87.3	86.8	94.40
S13	65.3	87.2	93.0	94.38
S14	74.6	82.5	92.4	87.83

3.5　结果分析及讨论

本文对 10 组自采 MI-EEG 数据和 4 组公开 MI-EEG 数据,分别保留了初始 32 通道和筛选后 20 通道的数据,使用本文提出的 CNN 结构进行了分类比较,结果表明,14 组数据在进行通道筛选后分类准确率均有不同程度的提升,其中准确率最高的被试为 S11,通道重新筛选后的分类准确率达到了 97.64%,最低的被试为 S3,通道重新筛选后的分类准确率为 87.21%。由此可见,本文提出的分类方法对于有效提取被试 MI-EEG 特征以及提升分类准确率有着较为明显的效果,针对结果开展了进一步的分析。

①本文提到的通道筛选方法考虑到了每个被试的差异性,针对不同被试选择不同的通道进行分类,这需要使用每个被试的数据构建特定的脑网络结构,根据通道间的相关性关系得到需要保留的通道,因此计算量会随着被试数据量的增大而增长。为了减轻工作量,提升效率,后续在扩充数据库的基础上,会考虑根据筛选后保留的通道结果,适当增加固定选择通道的数量,减少需要进行筛选的通道数,减轻数据处理负担。

②从结果可知,本文的 10 名被试数据在经过通道重新筛选处理后,分类准确率均得到了提升。但是从结果来看,不同的被试,准确率提升的幅度也有差距。经过通道筛选后分类准确率增幅最低的被试为 S1,S3,S14,其增幅分别为 1.06%,0.12%,1.84%,而经过通道筛选后分类准确率增幅最高的被试为 S11,S12,S13,其增幅分别为 13.73%,11.75%,11.53%。为了探明产生分类准确率提升差距的原因,本文从 ERD/ERS 的角度进行了分析讨论。

C3 和 C4 通道为 MI-EEG 的 ERD/ERS 现象主要研究通道,ERD/ERS 现象最为明显。因此,本文挑选了自采数据和公开数据中准确率提升幅度最高的被试 S4 和 S11,以及准确率提升最低的被试 S3 和 S14,对四组数据的 C3 和 C4 通道的时频图进行了比较。图 7 为 S4,S11,S3,和 S14 被试 C3 和 C4 通道的时频图。

从图 7 中可以看出,对于自采被试 S3 和 S4,在其运动想象的时间段(0~2.5 s),S4 的 ERD 现象较 S3 更为明显。而对于公开被试 S11 和 S14,在其运动想象的时间段(2 s~8 s),S11 的 ERD 现象较 S14

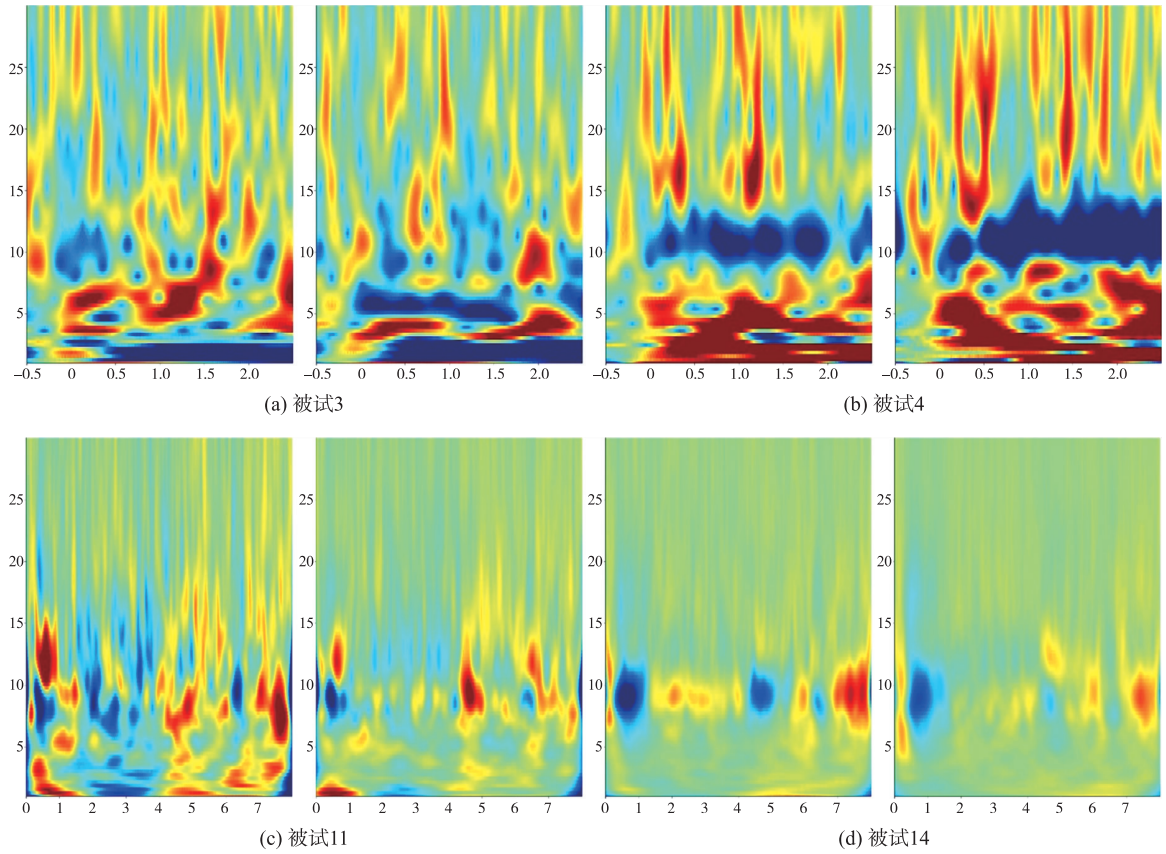

图 7　S3,S4,S11 和 S14 被试 C3 和 C4 通道时频分析

更为明显,上述现象显示准确率增幅的差异可能与被试的 ERD/ERS 现象的效果相关。

为了进一步研究分类准确率增幅差异的原因,验证这一推论的正确性,后续对 4 名被试 C3 和 C4 通道的 EEG 能量进行了计算对比。根据时频图中 EEG 能量的变化找到每位被试在实验过程中静息和进行运动想象的时间窗,每位被试分别选取了一段静息状态的时间窗和两段运动想象的时间窗,得到在静息状态时间窗和运动想象时间窗内,4 名被试 C3 和 C4 通道 mu 节律的平均 EEG 能量,如图 8 所示。可以发现,从静息状态到运动想象状态,S3 和 S14 被试 C3 和 C4 通道的 EEG 能量变化曲线较为平缓,没有 S4 和 S11 被试 C3 和 C4 通道的 EEG 能量变化明显。

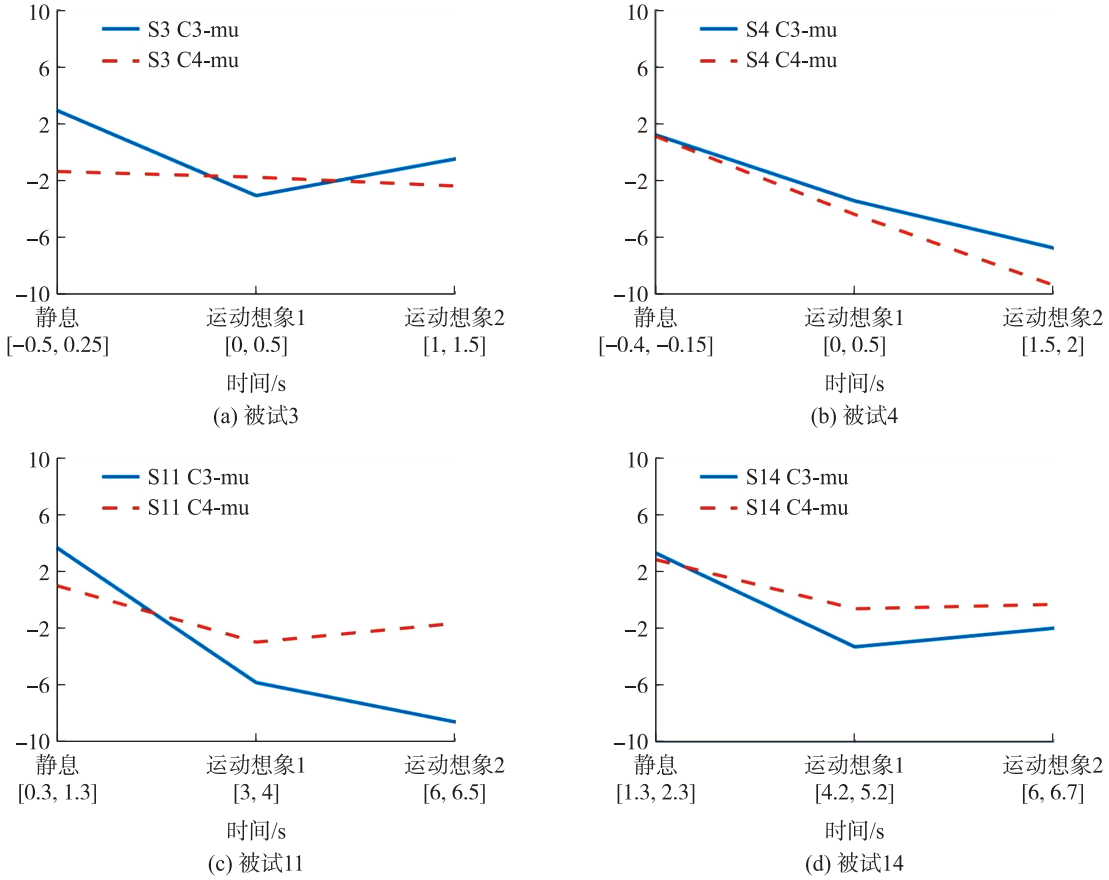

图 8 S3,S4,S11 和 S14 被试 C3 和 C4 通道 mu 节律的平均 EEG 能量变化

为了进一步验证准确率增幅与被试的 ERD/ERS 现象的效果是否相关,本文将 14 名被试 C3 和 C4 通道的 EEG 能量进行了计算,分别按照 mu 节律和 beta 节律给出了 EEG 能量的变化幅度,如图 9 所示。然后分别将 14 名被试 C3 通道 mu 节律和 beta 节律、C4 通道 mu 节律和 beta 节律的能量变化与 14 名被试准确率增幅变化进行了相关性分析,如表 6 所示。结果显示,对于 14 名被试整体来看,C3 通道的 beta 节律与分类准确率的增幅之间的相关性最强。之后对 14 名被试 C3 通道 beta 节律 EEG 能量变化幅度与分类准确率增幅进行了显著性水平检验,得到其显著性水平为 $P=0.001\ 01<0.05$,存在相关性。由此可以得出结论,本文所提出的通道重新选择方法对 EEG 信号分类准确率的提升效果,与被试 ERD/ERS 现象的效果以及运动想象的活跃程度相关联,并且受 C3 通道的 beta 节律的影响最大。

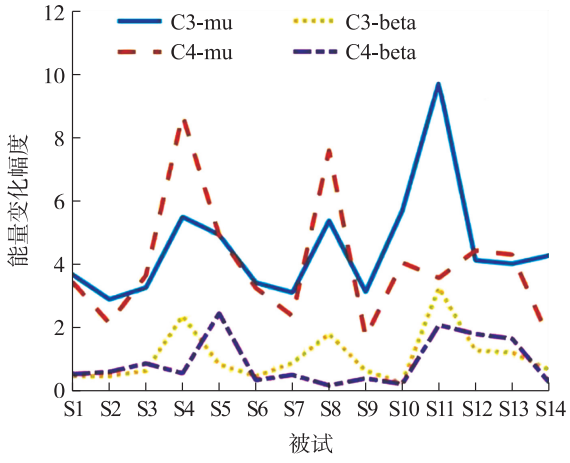

图 9 14 名被试 C3 和 C4 通道 mu 节律和 beta 节律的 EEG 能量变化幅度

表 6　EEG 能量变化幅度与分类准确率增幅的相关性

通道及频段	相关系数	显著性水平
C3 通道 mu 节律(8 Hz~12 Hz)	0.681 08	0.007 32
C4 通道 mu 节律(8 Hz~12 Hz)	0.589 71	0.026 45
C3 通道 beta 节律(13 Hz~30 Hz)	0.779 38	0.001 01
C4 通道 beta 节律(13 Hz~30 Hz)	0.609 90	0.020 56

③除了从 ERD/ERS 的角度对分类准确率增幅差异进行了分析,本文还从信息密度的角度,对脑网络特征参数和分类准确率增幅进行了相关性分析。

对 14 名被试的脑网络特征参数平均度 K_a,平均聚类系数 CC 和网络密度 Den 与准确率增幅变化进行相关性分析,如表 7 所示。结果显示,平均聚类系数与分类准确率增幅之间的相关性最强,平均度和网络密度与分类准确率之间基本不相关。同时,对 3 种脑网络特征参数与分类准确率增幅进行了显著性水平检验,结果显示只有平均聚类系数与准确率增幅之间的显著性水平 $P=0.007\ 33<0.05$,具有显著的统计学意义,其他两项特征参数与准确率增幅之间并没有显著的统计学意义。这说明本文所提出的通道重新选择方法对 EEG 信号分类准确率的提升效果,与被试脑网络平均聚类系数呈负相关,说明对于脑网络集团化程度越低的对象,分类准确率的提升将会越明显。对于脑网络集团化程度越低的被试,脑网络传输信息的能力较弱,进行运动想象任务时脑电信号活跃度较低,在对 14 名被试的平均聚类系数和初始分类准确率进行相关性分析后发现,其相关系数为 0.242 37,表明二者为正相关关系,也就是脑网络集团化程度越高,初始分类准确率越高。但对于初始分类准确率较高的对象,其初始准确率越接近 100%,分类准确率升空间较小,因此提升效果相较于初始分类准确率较低的对象并不明显,这也解释了为何分类准确率提升效果与被试脑网络平均聚类系数呈负相关。从这一角度能够说明,本文提出的通道重新选择方法可以更有效地提升脑网络集团化程度较低对象的 EEG 信号分类准确率,在临床应用中有助于更好地识别信息传输能力较弱的患者的运动意图。

表 7　脑网络特征参数与分类准确率增幅的相关性

脑网络特征参数	相关系数	显著性水平
平均度 K_a	−0.089 60	0.760 65
平均聚类系数 CC	−0.681 01	0.007 33
网络密度 Den	0.063 73	0.828 64

4　结论

本文提出了一种基于同步性及节点特性的通道选择方法,根据脑电通道信息密度对通道进行重新筛选,并研究了该方法对 MI-EEG 的 CNN 分类性能的影响。针对公开数据集和实验室自采数据集,进行了时频分析,从 ERD/ERS 的角度进行了通道特征信息的提取,同时完成了基于同步性的脑网络构建,获取了通道间的相关性信息,并最终根据通道特征信息和通道间相关性信息,保留信息密度高的通道,完成了对 MI-EEG 通道的重新选择,并将通道筛选前后的 EEG 信号作为输入在 CNN 中进行了分类验证比较。结果显示,10 组自采数据和 4 组公开数据在经过本文提出的通道选择方法处理后,在 CNN 模型的平均分类准确率由初始 32 通道数据的 86.01%提升到了筛选后 20 通道数据的 91.16%,说明该通道选择方法对 MI-EEG 的分类准确率提升有较明显的效果。同时,根据时频分析得到的 EEG 能量变化以及表示信息密度的脑网络特征参数,本文对 MI-EEG 分类准确率增幅的影响因素进行了探究,发现本文的通道选择方法对 MI-EEG 信号分类准确率的提升效果,与被试 EEG 能量的变化(运动想象的活跃程度)以及被试脑网络的平均聚类系数(脑网络集团化程度)相关联,并且受 C3 通道的 beta 节律的影响最大,同时与平均聚类系数呈负相关。

为了适用于更大的被试规模,后续将继续优化针对不同被试进行通道筛选的方法,对固定选择通道和待筛选通道的数量进行调整,并考虑结合相关的数据预处理方法,尝试更有效的伪迹剔除,进一步研究 MI-EEG 质量的提升对分类准确率的影响。本文所做的工作验证了基于同步性及节点特性对通道重新选择方法的可行性,有效提取了 MI-EEG 通道的特征信息和通道间的相关性信息,并据此提高了 MI-EEG 的 CNN 分类性能,同时分析了分类准确率提升幅度与 mu 节律和 beta 节律的平均 EEG 能量以及表示信息密度的脑网络特征参数之间的关系,为 MI-EEG 研究在康复和控制等领域提供更多可能性。

参考文献:

[1] 何群,邵丹丹,王煜文,等. 基于多特征卷积神经网路的运动想象脑电信号分析及意图识别[J]. 仪器仪表学报,2020,41(1):138-146.

[2] Wolpaw J R, Birbaumer N, Heetderks W J, et al. Brain-Computer Interface Technology: A Review of the First International Meeting[J]. IEEE Transactions on Rehabilitation Engineering, 2000, 8(2): 164-173.

[3] Wolpaw J,Wolpaw E W. Brain-Computer Interfaces:Principles and Practice[M]. New York,NY,USA:Oxford University Press,2012:11-15.
[4] 杨丰玮. 面向下肢康复设备的在线运动想象脑机接口系统研究[D]. 四川:西南交通大学,2021.
[5] Yuan H,He B. Brain-Computer Interfaces Using Sensorimotor Rhythms: Current State and Future Perspectives [J]. IEEE Transactions on Biomedical Engineering, 2014,61(5):1425-1435.
[6] 杨朋朋. 基于运动想象的 EEG 识别算法研究[D]. 郑州:郑州大学,2020.
[7] 许敏鹏,魏泽,明东. 基于脑卒中后运动康复领域的运动想象的研究[J]. 生物医学工程学杂志,2020,37(1):169-173.
[8] 段纪丁. 脑机控制智能轮椅[D]. 广州:华南理工大学,2016.
[9] 汪俊宇,王美玉,向武,等. 浅谈脑机接口康复假肢的相关研究[J]. 世界最新医学信息文摘,2017,17(45):75-76.
[10] Chen X G,Chen Z K,Gao S K,et al. A High-ITR SSVEP-Based BCI Speller[J]. Brain-Computer Interfaces,2014, 1(3-4):181-191.
[11] Zimmermann-Schlatter S A,Schuster C,Puhan M A,et al. Efficacy of Motor Imagery in Post-Stroke Rehabilitation:A Systematic Review[J]. Journal of Neuroengineering and Rehabilitation,2008,5(1):8.
[12] 朱悦,李春光,郭浩,等. 运动想象的机理研究与应用综述[J]. 计算机工程与应用,2020,56(10):10-19.
[13] Irimia D C,Cho W,Ortner R,et al. Brain-Computer Interfaces with Multi-Sensory Feedback for Stroke Rehabilitation:A Case Study[J]. Artificial Organs,2017,41(11):E178-E184.
[14] 佘青山,昌凤玲,范影乐,等. 基于邻接矩阵分解的脑电特征提取与分类方法[J]. 传感技术学报,2012,25(9):1204-1209.
[15] 卢扩锋. 多类运动想象脑电信号的特征提取与识别研究[D]. 广州:广东工业大学,2020.
[16] Sandhya B,Shendkar C,Mahadevappa M. Single Channel Event Related(De)Synchronization(ERD/ERS)Analysis of Motor Execution in Stroke Affected Foot Drop Subjects [C]//2014 International Conference on Medical Imaging, m-Health and Emerging Communication Systems,Greater Noida,India,IEEE,2014:325-328.
[17] Luck S J. 事件相关电位基础[M]. 范思陆,丁玉珑,曲折,等译. 华东师范大学出版社,2009:10-20.
[18] Hossain M S,Amin S U,Alsulaiman M,et al. Applying Deep Learning for Epilepsy Seizure Detection and Brain Mapping Visualization[J]. ACM Transactions on Multimedia Computing Communications and Applications, 2019,15(1S):10.
[19] Amin S U,Hossain M S,Muhammad G,et al. Cognitive Smart Healthcare for Pathology Detection and Monitoring [J]. IEEE Access,2019,7:10745-10753.
[20] Garcia-Moreno F M,Bermudez-Edo M,Rodriguez-Fortiz M J,et al. A CNN-LSTM Deep Learning Classifier for Motor Imagery EEG Detection Using a Low-Invasive and Low-Cost BCI Headband[C]//2020 16th International Conference on Intelligent Environments(IE),Madrid, Spain,2020:84-91.
[21] Hossain M S,Muhammad G. Emotion Recognition Using Deep Learning Approach from Audio-Visual Emotional Big Data[J]. Information Fusion,2019,49:69-78.
[22] Hao Y X,Yang J,Chen M,et al. Emotion-Aware Video QoE Assessment via Transfer Learning[J]. IEEE Multimedia,2019,26(1):31-40.
[23] 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.
[24] 张军锋,尚展垒. 基于深度学习卷积神经网络的花生籽粒完整性检测[J]. 食品与机械,2022,38(5):24-29,36.
[25] Deogratias M,Oluwarotimi W S,Mojisola G A,et al. A Channel Selection Approach Based on Convolutional Neural Network for Multi-Channel EEG Motor Imagery Decoding [C]//2019 IEEE Second International Conference on Artificial Intelligence and Knowledge Engineering(AIKE),Sardinia,Italy,2019:195-202.
[26] 潘礼正,丁忆,王顺超,等. 基于个体自适应的运动想象脑电信号特征表征研究[J]. 生物医学工程学杂志,2022,39(6):1173-1180+1188.
[27] 李明爱,南琳,孙炎珺. 基于锁相值和图论的脑功能网络特征提取方法[J]. 北京生物医学工程,2019,38(1):15-21.
[28] Gonuguntla V,Wang Y B,Veluvolu K C,et al. Event-Related Functional Network Identification: Application to EEG Classification[J]. IEEE Journal of Selected Topics in Signal Processing,2016,10(7):1284-1294.
[29] BCI Competition IV[EB/OL]. (2008-06-24). http://www.bbci.de/competition/.
[30] Park Y K,Chung W Z. Frequency-Optimized Local Region Common Spatial Pattern Approach for Motor Imagery Classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering,2019,27(7):1378-1388.
[31] Li X Y,Chen P,Yu X,et al. Analysis of the Relationship Between Motor Imagery and Age-Related Fatigue for CNN Classification of the EEG Data[J]. Genetics,2022,14(3):755-761.

[32] Al-Saegh A, Dawwd S A, Abdul-Jabbar J M. Deep Learning for Motor Imagery EEG-based Classification: A Review[J]. Biomedical Signal Processing and Control, 2021,63:102172.
[33] 孙亚南. 基于运动想象的中风患者脑电信号分析[D]. 济南:齐鲁工业大学,2022.
[34] Quiroga R Q, Kraskov A, Kreuz T, et al. Performance of Different Synchronization Measures in Real Data: A Case Study on Electroencephalographic Signals[J]. Physical Review E-Statistical,2002,65(4):041903.
[35] 尹晶海,穆振东. 基于时频域分析的运动想象脑电信号分类[J]. 江西科技学院学报,2007,4(3):16-20.
[36] Zhang H H, Chin Z Y, Ang K K, et al. Optimum Spatio-Spectral Filtering Network for Brain-Computer Interface [J]. IEEE Transactions on Neural Networks, 2011, 22(1):52-63.

郗　凯(1999—),男,湖南长沙人,硕士生,研究方向为脑机接口,568595766@qq.com;

陈　鹏(1981—),男,黑龙江齐齐哈尔人,博士,副教授,硕士生导师,研究方向为脑机接口,人机交互,医疗机器人,chenpeng@swjtu.edu.cn。