

采用源空间套索分析和卷积神经网络方法的高频脑电动作模式识别方法

陶怡¹, 徐维维¹, 朱家林¹, 袁子文^{1,2}, 王茂德³, 王刚¹

(1. 西安交通大学生物医学信息工程教育部重点实验室, 710049, 西安; 2. 西安交通大学第一附属医院康复医学科, 710061, 西安; 3. 西安交通大学第一附属医院神经外科, 710061, 西安)

摘要: 针对目前同侧手部运动意图识别率低的问题,提出了一种基于源空间套索分析和卷积神经网络(source-Lasso-CNN, SLC)的高频脑电动作模式识别方法。该方法运用空间源定位分析与握拳、展拳、二指对捏、三指对捏4种动作相关的脑电信号,使用组Lasso进行感兴趣区域(ROI)选择,再输入到卷积神经网络进行单手多类动作模式识别。采集13名被试者在4种手部动作模式下的脑电和肌电信号并进行预处理,采用基于核磁共振图像的边界元模型建立头模型、使用最小范数估计解决脑电源成像逆问题,将传感器空间的脑电信号映射至源空间。将源空间脑电序列按照布罗德曼分区进行划分,提取每个脑区的3个时域特征并基于特征采用组Lasso方法进行ROI选择,将挑选出的ROI及其对应源空间序列输入卷积神经网络中进行四分类。实验结果表明:采用source-Lasso-CNN的方法在高频(γ 频带)脑电的识别准确率可达 $(82.23 \pm 12.71)\%$,优于在 $\delta(1 \sim 3 \text{ Hz})$ 、 $\theta(4 \sim 7 \text{ Hz})$ 、 $\alpha(8 \sim 13 \text{ Hz})$ 、 $\beta(14 \sim 30 \text{ Hz})$ 以及全频带($1 \sim 100 \text{ Hz}$)上的结果。与其他先进方法相比,其准确率也有显著性的提升,显示了该方法在同侧手部运动意图识别中的有效性。

关键词: 源空间; Lasso; 卷积神经网络; 高频脑电; 手部运动意图识别

中图分类号: TP391.4 **文献标志码:** A

DOI: 10.7652/xjtuxb202401018 **文章编号:** 0253-987X(2024)01-0187-10

Movement Pattern Recognition Using Group LASSO and CNN Based on High Frequency Signal in Source Space

TAO Yi¹, XU Weiwei¹, ZHU Jialin¹, YUAN Ziwen^{1,2}, WANG Maode³, WANG Gang¹

(1. Key Laboratory of Biomedical Information Engineering of Ministry of Education, Xi'an Jiaotong University, Xi'an 710049, China;
2. Department of Rehabilitation Medicine, The First Affiliated Hospital of Xi'an Jiaotong University, Xi'an 710061, China;
3. Department of Neurosurgery, The First Affiliated Hospital of Xi'an Jiaotong University, Xi'an 710061, China)

Abstract: Addressing the challenge of low classification accuracy in ipsilateral hand movements, this paper presents a novel method named source-Lasso-CNN (SLC). The approach involves analyzing electroencephalogram (EEG) signals before movement onset in the gamma band (30—100 Hz) that are associated with four specific hand movements (tip pinch, multiple tip pinch, hand close and hand open) using spatial source localization. Region of interest (ROI) was selected using group Lasso, and then the selected signals were input into convolutional neural network (CNN) for multi-class hand movement pattern recognition. The specific steps are as follows. Firstly,

收稿日期: 2022-12-29。 作者简介: 陶怡(1997—),女,博士生;王刚(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(32071372, 62271385);四川省科技计划资助项目(2022YFS0030)。

网络出版时间: 2023-10-17

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20231016.1402.010.html>

EEG and EMG signals were simultaneously collected from 13 subjects during the execution of the four hand movements, followed by preprocessing. Next, a head model was established using a boundary element model based on magnetic resonance image, and the inverse problem of EEG imaging was solved by using the minimum norm estimation method. The EEG sequences in the source space were divided into 79 regions based on Brodmann area. Three time-domain features were extracted from each brain region and a group Lasso algorithm was employed to select the ROI. Finally, the selected ROI and its corresponding source space sequences were input into the CNN for classification. The results show that the LASSO-CNN method, utilizing high frequency (γ band) source space signals, achieves a superior classification accuracy of $(82.23 \pm 12.71)\%$, which is better than that in δ (1—3 Hz), θ (4—7 Hz), α (8—13 Hz), β (14—30 Hz) and full frequency band (1—100 Hz). Furthermore, the results also show a significant improvement in accuracy compared to other advanced algorithms, highlighting its effectiveness in recognizing identical hand motion pattern.

Keywords: source space; Lasso; convolutional neural network; high frequency electroencephalogram signal; hand movement intent recognition

脑-机接口 (brain computer interface, BCI) 通过分析人执行动作前大脑活动的变化, 让设备能更早地识别并完成相应的指令^[1]。在这个过程中, 头皮脑电 (electroencephalogram, EEG) 由于其非侵入、安全性高等特点, 成为许多研究中分析的对象^[2-3]。EEG 信号是来自大脑皮层的时间序列数据, 通常根据频率分为 5 个频带^[4], 包括 δ (1~3 Hz)、 θ (4~7 Hz)、 α (8~13 Hz)、 β (14~30 Hz)、 γ (30~100 Hz)。一般认为, 不同频带的信号活动在大脑中的分布与特定的认知功能之间存在一定的关联^[5]。

以往的研究表明, δ 节律多与认知加工、疲劳水平、代谢、睡眠等过程有关^[6-8]; θ 节律与信息整合和工作记忆及多种认知功能的整合和协调有关^[9]; α 节律在信息处理速度和注意力等领域起重要作用^[10], 此外, 位于感觉运动皮层的成分被称为 μ 节律, 与躯体的感觉刺激、四肢的运动密切相关, 并在 BCI 中已有广泛的应用^[11]; β 节律常出现于工作、运动、思考等大脑活动强烈的情况下^[12-13]; γ 节律被认为与情绪或者更广泛的认知过程相关^[14], 例如刺激选择、记忆形成等。

大部分研究表明, 与手部动作解码相关的信息主要包含在 α 和 β 频带, Zhang 等通过对 EEG 进行 0.1~30 Hz 滤波, 对手部运动方向进行分类, 在左、中、右 3 个方向上得到了 $(73.39 \pm 6.35)\%$ 的准确率^[15]。然而, 近年来一些学者发现, 在 γ 频带上也存在许多利于手部动作分类的信息^[16-17], 在以往的研究中也有同样的发现, 当使用多元经验模态分解 (MEMD) 方法把信号分解成不同频带的多元本征

模式函数 (MIMF) 后, 将单个 MIMF 输入支持向量机 (SVM) 中, 位于高频带的 3 个 MIMF 有着最高的分类准确率^[18]; 通过前向序列搜索策略输入卷积神经网络 (CNN) 中, 发现被选中的 MIMF 也多为最先分解出的高频分量^[19]。因此, 本文中主要针对 γ 频带的信号进行分析。

EEG 是由神经元放电后经过大脑皮层传播到头皮被头皮表面电极检测并记录的信号, 在传播过程中信号幅值有一定程度的衰减。此外, 邻近区域的神经元电信号也会对解码工作带来一定的干扰。因此, 有研究使用脑电源定位技术将头皮脑电投射到代表大脑几何形状的源空间上, 将信号从传感器空间转换到源空间进行单手多类动作模式的识别^[20], 提高脑-机接口的性能。

不论是传感器空间还是源空间内, 以往的手部动作分类研究主要依赖手动提取信号特征, 包括时域、频域和时频域上的特征。然而, 这种方法导致基于 EEG 的脑机接口面临着高维度特征的问题。为了应对这个问题, 许多国内外的学者选择从特征选择和通道选择两个方面进行降维。

在特征选择方面, 唐肖芳和周金治^[21]使用散度分析进行脑电信号特征选择, Liu 等^[22]使用萤火虫方法对从运动想象信号中提取的空域和频域融合特征进行选择, 杨鹏圆等^[23]使用方差贡献率与 F-score 结合的特征选择方法, 在不降低准确率的情况下大量减少了特征数。

在通道选择方面, 孟明等^[24]结合互信息进行挑选, 曹玉珍等^[25]提出了基于卷积自编码器和费舍尔

准则的 EEG 通道选择方法。最小绝对值收敛和选择算子方法(Lasso),简称套索,是一种用于特征选择的新方法^[26],组 Lasso 是其重要推广,能够在组的水平上进行变量选择。王金甲等^[27]通过融合 EEG 信号功率谱、小波变换参数等特征,提出了稀疏组 Lasso 方法,对信号的通道和特征同时进行选择,表明该方法优于传统方法。

脑电信号复杂多样,手动提取信号特征具有一定的局限性,一是提取的特征不一定适合要研究的任务,二是容易造成信息的损失。随着深度学习的兴起,学者们开始尝试卷积神经网络在脑电信号解码方面的潜力。2019 年,Amin 等提出了一种多层神经网络融合方法,在公共数据集 BCI 竞赛 IV-2a 上取得了 75.7% 的分类准确率^[28]。2020 年,Mammone 等对源空间信号进行连续小波变换,生成的时频图作为深度卷积神经网络的输入,得到六分类 62.47% 的分类效果^[20]。2022 年,Fujiwara 等训练了一个包含残差网络的多层 CNN 模型,对休息、左手运动和右手运动任务分类准确率达 85.69%^[29]。本文提出了 source-Lasso-CNN(SLC)方法,将 EEG 信号映射到源空间,再通过组 Lasso 进行源空间感兴趣区域(ROI)的选择,最后输入到 CNN 中进行自动特征提取,从而达到对手部动作分类的目的。

1 数据和方法

1.1 被试者与实验范式

实验征集了 13 位年龄在 20~32 岁的健康被试者(全部为男性),依次被标识为 S1~S13。被试者均为右利手,视力或矫正后视力正常,并且接受该研究的书面说明和签署知情同意书。

实验在远离电气设备、高频辐射的环境中进行,以降低外界环境对脑电信号产生的干扰。整个实验过程要求被试者保持平静、注意力集中,尽量减少体动。

脑电和肌电信号通过 Neuroscan 64 导脑电仪采集,接地电极位于前额区 Fz 和 FCz 之间位置,参考电极位于双耳乳突,按照国际 10-20 标准电极安放法定义的位置,采集了 FP1、FP2、F7、F3、FZ、F4、F8、FT7、FC3、FCZ、FC4、FT8、T7、C3、CZ、C4、T8、TP7、CP3、CPZ、CP4、TP8、P7、P3、PZ、P4、P8、O1、OZ、O2 一共 30 个通道的信号,EMG 信号采用一次性 Ag/AgCl 电极组成 4 对表面差分电极,以肘部为参考点,分别从前臂的指伸肌、桡侧腕伸肌、掌长肌和尺侧腕屈肌等处同时采集 4 路表面肌电信号,采样频率均为 1 kHz。脑电、肌电电极放置位置如图 1(a)、图 1(b)所示。每

名被试者需要完成 4 种手部动作模式的 EEG 和 EMG 信号采集,包括握拳、展拳、二指对捏、三指对捏,每种动作进行 60 个试次,共采集 240 个样本。为降低实验过程中疲劳带来的影响,以 20 个试次为一组,每组之间休息 5 min,单个试次包括准备阶段 4 s、动作执行 4 s 和休息 4 s,某被试者的实验过程如图 1(c)所示,单次实验时序图如图 2 所示。




图 1 脑肌电电极放置位置及被试者
Fig. 1 Placement of EEG and EMG electrodes and subjects

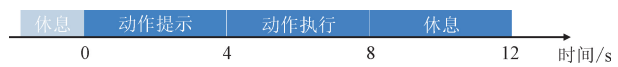


图 2 单次实验时序图
Fig. 2 Sequence diagram of single experiment

1.2 信号预处理

对记录到的数据进行 0.1~100 Hz 带通滤波和

50 Hz 陷波滤波,以去除工频噪音干扰。使用移动时间窗法^[30]对肌电信号进行分析,从而判断动作真实起点位置,进而提取动作前 2 s 数据进行后续分析。

1.3 源空间套索分析和卷积神经网络动作模式识别方法

本文提出的基于源空间套索分析和卷积神经网络

络(source-Lasso-CNN,SLC)方法,首先将传感器空间的 EEG 经过脑电源定位映射到源空间,再提取源空间信号的标准差、均方根幅值和均方根作为特征进行组 Lasso,将源空间中挑选出的脑区及相应信号输入 CNN 中自动提取特征并进行分类,具体 SLC 方法流程如图 3 所示。




图 3 SLC 方法流程图
Fig. 3 Flow chart of proposed algorithm

1.3.1 源空间

脑电溯源定位,也即脑电逆问题,是根据头皮记录到的 EEG 信号,反向估计脑内神经活动源的位置、方向和强度信息。要解决逆问题,就要先对神经元电活动传播到头皮上的过程有一定的了解,头皮脑电信号与脑内源活动的数学模型可以建立如下

$$\boldsymbol{b} = \boldsymbol{A}\boldsymbol{X} + \boldsymbol{n} \tag{1}$$

式中: $\boldsymbol{b}$ 表示记录的头皮数据,在本文中是大小为 $30 \times 1\,000$ 的矩阵,其中 30 为传感器空间脑电通道数,1 000 为裁剪后每个样本的时间采样长度; $\boldsymbol{X}$ 表示脑内源活动的信息,大小为 $15\,002 \times 1\,000$,15 002 是所选模型的脑源数,1 000 为映射到源空间后的时间序列长度; $\boldsymbol{A}$ 表示传递矩阵,体现了脑内各源对 EEG 每个通道贡献的大小; $\boldsymbol{n}$ 表示测量噪声。逆问题就是在已知 $\boldsymbol{b}$ 的情况下反推 $\boldsymbol{X}$,而在此之前,需要先解决脑电正问题,即建立一个大脑中可以阐述大脑皮层神经元活动是如何经过脑容积效应和颅骨的传导投射到头皮上的头模型,即矩阵 $\boldsymbol{A}$ 。头模型的主要部分包括大脑的几何形状以及神经电活动传播所通过的不同组织(灰质、白质、脑脊液、颅骨、皮肤)的导电特性。本文基于 FSAverage 模板的真实头模型,利用边界元法建立了代表头皮、颅骨和大脑内部组织的三壳传导模型,电导率为 1:1/8:1。

理论上,脑电逆问题的求解就是使得记录的头皮脑电和已知的偶极子计算出的对应电位之间的残差最小的过程,但一般来说,逆问题的解不唯一,所以需要确定一个既符合生理学解剖意义,又在数学上计算方便的源模型来得到唯一的脑源解。

源模型一般分为等效电流偶极子模型和分布式电流密度模型,前者通过单个或少量偶极子等效某个区域的脑源活动,但只适用于局部区域的精准估计,无法对于整个大脑的源活动进行准确的重构。因此本文选择分布式源模型,在这种模型中,信号源均匀地分布在大脑皮层中,由于脑内源数 15 002 远远大于脑电图的通道数 30,这将导致脑电逆问题拥有无穷多解,因此需要加上合适的约束条件。本文采用最小范数估计(minimum norm estimate, MNE)^[31]的方法来求解逆问题,其求解公式如下

$$\min_{\boldsymbol{x}} \{ \|\boldsymbol{A}\boldsymbol{x} - \boldsymbol{b}\|^2 + \eta \|\boldsymbol{W}\boldsymbol{x}\|^2 \} \tag{2}$$

$\boldsymbol{X}$ 的最优解将是在 L_2 范数最小二乘意义下的估计和记录的头皮脑电之间的残差最小的解,式中 $\eta \geq 0$,是正则化参数; $\boldsymbol{W}$ 是一个权重矩阵。

得到映射到源空间的每个源的信号后,按照 Brodmann 分区对处于同一脑区的偶极子进行累加,作为这个脑区整体的输出,以便进行后续分析,脑区共有 79 个,脑电源定位-Brodmann 分区如图 4 所示。




图 4 脑电源定位-Brodmann 分区

Fig. 4 Spatial source localization-Brodmann area

1.3.2 组套索方法

Lasso^[26]是 Robert Tibshirani 在 1996 年提出了一种惩罚类的回归方法,其基本思想是使用惩罚函数对回归系数的绝对值进行惩罚,要求所有回归系数的绝对值之和小于等于惩罚参数 λ ,通过调节 λ ,进而对回归系数进行控制压缩。随着 λ 的增大,更多的自变量回归系数被压缩成 0,从而达到降维的效果,其表达式如下

$$\hat{L}(\beta) + (1 - \alpha)\lambda \sum_{j=1}^m (\omega_j \|\beta^{(j)}\|_2) + \alpha\lambda \|\beta\|_1 \quad (3)$$

式中: $\hat{L}$ 是多项式回归模型的加权经验对数似然风险函数;向量 $\beta^{(j)}$ 表示与第 j 组特征相关的参数,本文提取的特征有每个通道的标准差、均方根幅值和均方根 3 个; m 是组的总数,由于共 79 个脑区,因此 $m = 79$;模型超参数 α 控制组 Lasso 和 Lasso 的组合, $\alpha = 0$ 为组 Lasso 拟合, $\alpha = 1$ 为 Lasso 拟合,此处 α 被设为 0,以完成对脑区的挑选;超参数 λ 控制正则化的整体强度。采用坐标梯度下降和块坐标下降相结合的方法求解带惩罚项的目标函数,选择错误率最低的参数估计,从而确定挑选出的 ROI 索引。

1.3.3 卷积神经网络

CNN 是一种前馈型网络,其结构受到人脑视觉皮层的启发。与传统机器学习方法相比,CNN 最大程度地减少了预处理的过程,能够自动提取信号特征、学习复杂模型并进行分类,因此在图像识别、视频分析和自然语言处理等领域被充分关注。

CNN 通常由输入层、隐藏层和输出层构成,其中隐藏层可由多个卷积层、池化层、全连接层组成。

卷积层是 CNN 的核心层,通过卷积核对数据进行扫描,从而完成卷积运算,具体公式如下

$$O_f = \sum_{k=1}^K (W_f^k x_k + c_f) \quad (4)$$

式中: O_f 表示输出的第 f 个特征图; W_f^k 表示第 k 个通道的第 f 个卷积核; x_k 表示第 k 个通道的输入数据,即挑选完 ROI 的源空间数据; c_f 为偏置值。

卷积层后通常与激活函数相结合,以实现输出结果的非线性映射,从而提高网络的非线性功能,常用的激活函数有指数线性单元函数(ELU)、修正线性单元(ReLU)、双曲正切激活函数(tanh 函数)等,本文中使用 ELU 函数,其公式为

$$\text{ELU}(x) = \begin{cases} x, & x > 0 \\ e^x - 1, & x \leq 0 \end{cases} \quad (5)$$

式中, x 为输入的特征值。

池化层又称下采样层,主要用于压缩数据,以达到减小过拟合和降低参数数的目的。常用的池化操作有最大池化和平均池化,最大池化取区域最大值作为输出,平均池化取区域中的均值作为输出。在相邻两个卷积层之间可以设置池化层以简化网络复杂度,本文采用最大池化。

全连接层把所有神经节点互相连接,方便做最后的分类或者回归,本文在全连接层后还设置了权值为 0.5 的 dropout,即在训练过程中使 50% 的神经元失活,以提高模型的泛化能力,进一步降低过拟合。

方法中构建的 CNN 网络包括输入层、卷积层 1、卷积层 2、批标准化层 1、最大池化层 1、卷积层 3、批标准化层 2、最大池化层 2、卷积层 4、批标准化层 3、最大池化层 3、展平层、全连接层 1、全连接层 2 和输出层。在将数据输入 CNN 前,先对样本进行标准化并打乱顺序,输入大小为 $R \times T$ 的矩阵,其中 R 为挑选出的 ROI 数, T 为每个通道的时间采样点数,本文中 $R \leq 79$,具体值由组 Lasso 过程确定, $T = 1\,000$ 。输入的第一层卷积层设 25 个卷积核,每个卷积核随时间执行核大小为 1×5 的卷积操作,第二层卷积层中,每个卷积核执行对空间信息的卷积提取,这两层之间没有激活函数,通过这种方式可以将整个卷积强制分离线性变换为时间卷积和空间滤波器的组合实现隐式正则化,降低计算量。在两个卷积层后加入一个池化层,使用最大池化的方式,池化核的大小是 1×3 ,步长与核大小一致。第 3、4 个卷积层分别由 50、100 个卷积核构成,后接一个相同的池化层,通过这种方式可以减少池化层对整个网络结构丢失过多信息的影响,激活函数均设置为 ELU。展平层是对高维特征进行扁平化处理,将其转换为一维从而能够输入到全连接层中。全连接层

共有 2 层,分别设置有 1 024 和 512 个神经元,使用 Relu 函数作为激活函数。最后使用 softmax 函数输出分类预测概率,概率最大的类别即为分类结果。CNN 详细模型结构见表 1。在卷积层中,层参数指的是卷积核数;而对于全连接层和输出层来说,层参数指的是神经元数。

实验中采用 6 折交叉验证方法,把所有样本数据随机分为 6 组,轮流选 3 组作为训练集、2 组作为验证集、1 组作为测试集,最后 6 次平均的结果作为模型的识别准确率。

由于深度学习要求大量样本进行训练,使用 1 s 的时间窗对数据进行裁剪,从而达到数据扩充的目的,剪切的移动步进设为 50 ms。通过剪切操作,2 s 的脑电数据可以扩充成为 21 个 1 s 的脑电片段。并且由于在剪切之前已经划分训练集、验证集和测试集,因此存在重叠信息的剪切数据不会对分类结果产生影响,从整体上来说,单个被试者 2 s 的 4 种单手动作共 240 个样本,在剪切操作后成为 1 s 的 4 种单手动作 5 040 个样本。

表 1 CNN 模型结构
Table 1 CNN architecture

层类型	层数	核大小	输出尺寸
输入层			(R,1 000,1)
卷积层 1	25	(1,5)	(R,996,25)
卷积层 2	25	(R,1)	(1,996,25)
批标准化层 1			(1,996,25)
最大池化层 1		(1,3)	(1,332,25)
卷积层 3	50	(1,5)	(1,328,50)
批标准化层 2			(1,328,50)
最大池化层 2		(1,3)	(1,109,50)
卷积层 4	100	(1,5)	(1,105,100)
批标准化层 3			(1,105,100)
最大池化层 3		(1,3)	(1,35,100)
展平层			(3 500)
全连接层 1	1 024		(1 024)
全连接层 2	512		(512)
输出层	4		(4)

1.4 实验环境

方法测试环境为 Windows10 操作系统,脑电源定位通过基于 matlab2019b 的 brainstorm 工具箱实现,组 Lasso 使用 R 语言中的 msgl 库实现,CNN 通过 tensorflow2.1、python3.6 实现,服务器显卡型号

为 NVIDIA RTX3080Ti。

2 采用源空间套索分析和卷积神经网络的实验结果

2.1 挑选出的感兴趣区域数

EEG 信号经过脑电源定位后映射至源空间内,并根据 Brodmann 分区分为 79 个脑区,为了降低脑区数并选择对于手部动作意图解码更有利的区域,本文对信号进行了组 Lasso 后,每位被试者挑选出的 ROI 数如图 5 所示,其中横坐标为 13 个被试者,纵坐标为挑选出的通道数,每个被试者共有 6 个点,代表每折交叉验证时挑选出的结果,灰色虚线为 13 位被试者的平均值。可以看出,经过组 Lasso,每位被试者的脑区数大大下降,平均只有 35.46 ± 6.00 个通道,降低为原来的 44%,大大节省了后续需要的计算资源,提高了计算效率。






图 5 组 Lasso 后挑选出的 ROI 数
Fig. 5 Number of ROI selected after group Lasso

2.2 方法性能评价


本文使用分类准确率对提出的方法解码能力进行评估。分类准确率定义为所有分类正确的样本数与样本总数之比,取六折交叉验证的平均值作为最终结果以验证本文方法的有效性。CNN 训练过程准确率和损失值曲线如图 6 所示。



(a)被试者 S3 时模型的准确率及损失值



(b)被试者 S4 时模型的准确率及损失值



(c)被试者 S6 时模型的准确率及损失值

图 6 CNN 训练过程准确率和损失值曲线

Fig. 6 Accuracy and loss curve in CNN training

以被试者 S3(分类结果较差)、S4(分类结果一般)、S6(分类结果较好)为例,模型训练集和验证集的准确率及损失值曲线如图 6 所示。由图 6 可以看出,随着迭代次数的增加,S4 和 S6 的模型快速趋于收敛,但是 S3 的模型表现并不理想。考虑到该被试者在其他模型上分类效果也不佳,可能是被试者的个体差异或数据质量的影响。

训练过程中设置最大迭代次数为 80 次,batch 块的最小尺寸设为 64,同时通过早停法判断是否需要提前终止训练,即连续 10 个 epoch 验证集准确率不再上升时,提前结束训练。由于挑选出的 ROI 通道数不同、训练迭代次数也有差异,每个被试者训练模型时间长短略有不同,平均耗时(84.49±14.82) s。

表 2 给出了 13 位被试者模型在 γ 频带上的分类准确率,可以看出,13 人的分类准确率最高达到了 97.2%,最低有 61.21%,平均准确率达到(82.23±12.71)%,证明本文提出的方法在单手多动作模式识别上的有效性。

表 2 13 位被试者模型在 γ 频带上的分类准确率

Table 2 Classification accuracy of 13 subjects on γ band

被试者模型	分类准确率/%
S1	87.70
S2	92.66
S3	63.13
S4	84.37
S5	61.25
S6	97.20
S7	61.21
S8	85.62
S9	93.17
S10	78.23
S11	89.05
S12	93.13
S13	85.69
平均值	82.23

3 实验分析及讨论

3.1 不同模型参数对解码效果的影响

CNN 的结构包括卷积层数和卷积核的大小,本文通过参考文献[19, 32]以及进行的预实验确认网络卷积层数为 4,为了探讨不同卷积核大小下模型解码性能,文中对大小为 1×3、1×5、1×7、1×10、1×15 和 1×20 的卷积核进行测试,不同卷积核尺寸下分类准确率结果见表 3。可以看出,卷积核大小为 1×5 的分类准确率最高,之后随着卷积核的增大,分类准确率逐渐下降,考虑到小卷积核可以提取更多细节特征,最终确定 1×5 的卷积核进行研究。

表 3 不同卷积核尺寸下分类准确率

Table 3 Classification accuracy under different convolution kernel sizes

卷积核大小	分类准确率/%
1×3	78.25
1×5	82.23
1×7	81.42
1×10	80.26
1×15	79.14
1×20	78.85

池化层和 dropout 是卷积神经网络中常用的正则化方法。大尺寸的池化层可以减少特征图的尺寸,提高计算效率,但容易导致信息丢失,而小尺寸的池化层可能导致过拟合问题。为了确定合适大小的池化层,本文对尺寸为 1×2 、 1×3 、 1×4 、 1×5 和 1×6 的池化层进行测试,结果见表 4。由表 4 可以看出,在尺寸为 1×3 的情况下,模型的平均分类准确率最高,因此在后面的测试中均使用此尺寸的池化层。对于 dropout 正则化方法,它通过随机将一定比例的神经元输出设为 0 来避免过拟合。较大的 dropout 值可以提高模型的泛化能力,但是过大的 dropout 值会导致模型的学习能力下降。为了确定合适的 dropout 值,文章在 0.2~0.7 范围内进行测试。不同池化层大小和 dropout 值下分类准确率见表 4,当 dropout 设置为 0.5 时,模型的准确率最高,这也是大多数研究中使用的值。

表 4 不同池化层大小和 dropout 值下分类准确率

Table 4 Classification accuracy under different pooling kernel sizes and dropout rates			
池化层大小	分类准确率/%	dropout 值	分类准确率/%
1×2	77.69	0.2	78.44
1×3	82.23	0.3	78.58
1×4	76.57	0.4	78.33
1×5	68.99	0.5	82.23
1×6	72.74	0.6	73.79
		0.7	65.01

3.2 基于不同频带的解码效果对比

以往的研究认为和手部动作解码相关的信息多集中于 α 和 β 频带,但近期也有很多研究表明在 γ 频带也存在相关信息,为了讨论不同子频带的源空间信号的解码效果,本文将不同频带,即 δ (1~3 Hz)、 θ (4~7 Hz)、 α (8~13 Hz)、 β (14~30 Hz)、 γ (30~100 Hz) 及全频带 (1~100 Hz) 的信号,分别进行源空间定位,再进行相应的组 Lasso 进行感兴趣区域选择,最后输入到 CNN 中,将所有频带的分类结果进行比较,结果如图 7 所示。各频带分类准确率为 $(35.97\pm 5.10)\%$ 、 $(35.25\pm 5.98)\%$ 、 $(40.08\pm 5.40)\%$ 、 $(55.26\pm 11.06)\%$ 、 $(82.23\pm 12.71)\%$ 和 $(72.13\pm 14.29)\%$ 。通过 Wilcoxon 符号秩和检验发现, γ 频带的分类准确率显著优于其他频带 ($p<0.5$),结果说明不同子频带的信号都为手部动作意图解码提供了一定的信息,但是可以认为,更多的有用信息与 γ 频带相关,在以后的研究中应该更加关注此频带。




图 7 γ 频带与其他频带对比结果

Fig. 7 Comparison results between γ band and other frequency bands

3.3 与其他方法的脑电解码分类准确率对比

为了更客观地对本文提出方法进行评价,文章将所提出方法和其他先进方法的分类准确率进行对比,包括 GCB-Net^[33]、EEGNet^[34]、DeepConvNet^[32]、DeepCNN^[35]、滤波器组公共空间模式 (filter bank common spatial patten, FBCSP)^[36] 和 MEMD-CSP^[37],结果如图 8 所示。对于 GCB-Net、EEGNet、DeepConvNet、DeepCNN 4 种深度学习网络,使用的输入数据只经过简单预处理,并未提取任何其他特征。在 MEMD-CSP 方法中,信号首先进行 MEMD 分解;再使用 MIMF 的中值频率自动找到对 μ 和 β 节律有重要贡献的被试特定 MIMF;将选定的 MIMF 相加以重建 EEG 信号;使用 CSP 提取重构信号的特征,并且将空间滤波器数设置为 5;通过 SVM 分类器对特征进行分类。在 FBCSP 方法中,信号通过 CSP 提取特征,滤波器频带设为 0.1~10、10~20、20~30、...、80~90、90~100 Hz,并通过 SVM 进行分类。




图 8 本文方法与其他方法对比结果

Fig. 8 Comparison results between our algorithm and other algorithms

6 种方法的平均准确率分别为 $(56.34 \pm 11.05)\%$ 、 $(68.02 \pm 10.93)\%$ 、 $(67.06 \pm 9.78)\%$ 、 $(55.67 \pm 8.92)\%$ 、 $(66.86 \pm 10.17)\%$ 和 $(60.35 \pm 10.08)\%$, 均显著低于本文提出的方法 ($p < 0.05$), 这些结果表明, 与最先进的深度学习方法 and 传统的 MEMD-CSP、FBCSP 方法相比, 本文所提出的方法都能获得更高的分类精度。

4 结 论

本文提出了一种 SLC 方法, 通过脑电源定位方法将传感器空间采集的 γ 频带的 EEG 信号映射到源空间中。接着, 使用组 Lasso 方法对 ROI 进行挑选, 并将挑选出的脑区信号输入到卷积神经网络中进行自动特征提取及分类。通过六折交叉验证, 平均分类准确率为 $(82.23 \pm 12.71)\%$ 。与其他频段的脑电信号分类结果对比发现, γ 频带的分类结果最好, 甚至优于在全频带上的效果。这表明对大脑高频成分活动的研究可能对手部动作解码具有重要意义, 为今后的研究提供了新的思路 and 方向。

参考文献:

- [1] CHOI W S, YEOM H G. Studies to overcome brain-computer interface challenges [J]. *Applied Sciences*, 2022, 12(5): 2598.
- [2] SHAFIUL HASAN S M, SIDDIQUEE M R, ATRI R, et al. Prediction of gait intention from pre-movement EEG signals: a feasibility study [J]. *Journal of NeuroEngineering and Rehabilitation*, 2020, 17(1): 50.
- [3] HUANG Chenxi, XIAO Yutian, XU Gaowei. Predicting human intention-behavior through EEG signal analysis using multi-scale CNN [J]. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 2021, 18(5): 1722-1729.
- [4] CLAYTON M S, YEUNG N, COHEN KADOSH R. The roles of cortical oscillations in sustained attention [J]. *Trends in Cognitive Sciences*, 2015, 19(4): 188-195.
- [5] BUZSÁKI G. *Rhythms of the brain* [M]. New York, USA: Oxford University Press, 2006.
- [6] CAMPBELL I G, FEINBERG I. Longitudinal trajectories of non-rapid eye movement delta and theta EEG as indicators of adolescent brain maturation [J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2009, 106(13): 5177-5180.
- [7] HARMONY T. The functional significance of Delta oscillations in cognitive processing [J]. *Frontiers in Integrative Neuroscience*, 2013, 7: 83.
- [8] KNYAZEV G G. EEG delta oscillations as a correlate of basic homeostatic and motivational processes [J]. *Neuroscience & Biobehavioral Reviews*, 2012, 36(1): 677-695.
- [9] SAUSENG P, GRIESMAYR B, FREUNBERGER R, et al. Control mechanisms in working memory: a possible function of EEG theta oscillations [J]. *Neuroscience & Biobehavioral Reviews*, 2010, 34 (7): 1015-1022.
- [10] KLIMESCH W. Alpha-band oscillations, attention, and controlled access to stored information [J]. *Trends in Cognitive Sciences*, 2012, 16(12): 606-617.
- [11] WOLPAW J R, BIRBAUMER N, MCFARLAND D J, et al. Brain-computer interfaces for communication and control [J]. *Clinical Neurophysiology*, 2002, 113 (6): 767-791.
- [12] JUREWICZ K, PALUCH K, KUBLIK E, et al. EEG-neurofeedback training of beta band (12—22 Hz) affects alpha and beta frequencies: a controlled study of a healthy population [J]. *Neuropsychologia*, 2018, 108: 13-24.
- [13] GOLA M, MAGNUSKI M, SZUMSKA I, et al. EEG beta band activity is related to attention and attentional deficits in the visual performance of elderly subjects [J]. *International Journal of Psychophysiology*, 2013, 89(3): 334-341.
- [14] JIA Xiaoxuan, KOHN A. Gamma rhythms in the brain [J]. *PLOS Biology*, 2011, 9(4): e1001045.
- [15] ZHANG Mingming, WU Junde, SONG J, et al. Decoding coordinated directions of bimanual movements from EEG signals [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31: 248-259.
- [16] 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.
- [17] THÜRER B, STOCKINGER C, FOCKE A, et al. Increased gamma band power during movement planning coincides with motor memory retrieval [J]. *NeuroImage*, 2016, 125: 172-181.
- [18] TAO Yi, YAN Nong, WANG Gang. Hand movement prediction based on EEG signals by combining MEMD and CSP [C]//*Proceedings of the 2020 2nd International Conference on Image Processing and Machine Vision*. New York, NY, USA: Association for Computing Machinery, 2020: 105-112.

- [19] TAO Yi, XU Weiwei, WANG Guangming, et al. Decoding multi-class EEG signals of hand movement using multivariate empirical mode decomposition and convolutional neural network [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 30: 2754-2763.
- [20] MAMMONE N, IERACITANO C, MORABITO F C. A deep CNN approach to decode motor preparation of upper limbs from time-frequency maps of EEG signals at source level [J]. *Neural Networks*, 2020, 124: 357-372.
- [21] 唐肖芳, 周金治. 基于散度分析的脑电信号特征选择 [J]. *计算机工程*, 2015, 41(5): 290-294.
TANG Xiaofang, ZHOU Jinzhi. Electroencephalogram feature selection based on divergence analysis [J]. *Computer Engineering*, 2015, 41(5): 290-294.
- [22] LIU Aiming, CHEN Kun, LIU Quan, et al. Feature selection for motor imagery EEG classification based on firefly algorithm and learning automata [J]. *Sensors*, 2017, 17(11): 2576.
- [23] 杨鹏圆, 李海芳, 陈东伟. 脑电信号特征的归一化方式与选择方法研究 [J]. *计算机应用与软件*, 2015, 32(2): 48-52.
YANG Pengyuan, LI Haifang, CHEN Dongwei. Research on normalisation manner and selection method for EEG features [J]. *Computer Applications and Software*, 2015, 32(2): 48-52.
- [24] 孟明, 胡家豪, 高云园, 等. 结合互信息通道选择与混合深度神经网络的脑电情感识别方法 [J]. *传感技术学报*, 2021, 34(8): 1089-1095.
MENG Ming, HU Jiahao, GAO Yunyuan, et al. EEG emotion recognition based on normalized mutual information channel selection and hybrid deep neural network [J]. *Chinese Journal of Sensors and Actuators*, 2021, 34(8): 1089-1095.
- [25] 曹玉珍, 高晨阳, 余辉, 等. 基于深度学习的癫痫脑电通道选择与发作检测 [J]. *天津大学学报(自然科学与工程技术版)*, 2020, 53(4): 426-432.
CAO Yuzhen, GAO Chenyang, YU Hui, et al. Epileptic EEG channel selection and seizure detection based on deep learning [J]. *Journal of Tianjin University(Science and Technology)*, 2020, 53(4): 426-432.
- [26] TIBSHIRANI R. Regression shrinkage and selection via the lasso [J]. *Journal of the Royal Statistical Society: Series B (Methodological)*, 1996, 58(1): 267-288.
- [27] 王金甲, 薛芳, 李慧. 基于稀疏组 lasso 的脑机接口通道和特征选择研究 [J]. *仪器仪表学报*, 2015, 36(8): 1831-1837.
WANG Jinjia, XUE Fang, LI Hui. Research on channel and feature selection for brain-computer interface based on sparse group lasso [J]. *Chinese Journal of Scientific Instrument*, 2015, 36(8): 1831-1837.
- [28] AMIN S U, ALSULAIMAN M, MUHAMMAD G, et al. Deep learning for EEG motor imagery classification based on multi-layer CNNs feature fusion [J]. *Future Generation Computer Systems*, 2019, 101: 542-554.
- [29] FUJIWARA Y, USHIBA J. Deep residual convolutional neural networks for brain-computer interface to visualize neural processing of hand movements in the human brain [J]. *Frontiers in Computational Neuroscience*, 2022, 16: 882290.
- [30] WANG Gang, REN Doutian. Classification of surface electromyographic signals by means of multifractal singularity spectrum [J]. *Medical & Biological Engineering & Computing*, 2013, 51(3): 277-284.
- [31] HÄMÄLÄINEN M S, ILMONIEMI R J. Interpreting magnetic fields of the brain: minimum norm estimates [J]. *Medical & Biological Engineering & Computing*, 1994, 32(1): 35-42.
- [32] SCHIRMEISTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization [J]. *Human Brain Mapping*, 2017, 38(11): 5391-5420.
- [33] ZHANG Tong, WANG Xuehan, XU Xiangmin, et al. GCB-net: graph convolutional broad network and its application in emotion recognition [J]. *IEEE Transactions on Affective Computing*, 2022, 13(1): 379-388.
- [34] 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.
- [35] TANG Zhichuan, LI Chao, SUN Shouqian. Single-trial EEG classification of motor imagery using deep convolutional neural networks [J]. *Optik*, 2017, 130: 11-18.
- [36] ANG Kaikeng, CHIN Z Y, ZHANG Haihong, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface [C]//2008 IEEE International Joint Conference on Neural Networks. Piscataway, NJ, USA: IEEE, 2008: 2390-2397.
- [37] GAUR P, PACHORI R B, WANG Hui, et al. An automatic subject specific intrinsic mode function selection for enhancing two-class EEG-based motor imagery-brain computer interface [J]. *IEEE Sensors Journal*, 2019, 19(16): 6938-6947.

(编辑 武红江)