

EEG-MFNet:适用于脑电信号分析的轻量级多分支融合网络

叶晓雅^{1,2,3}, 王秀青^{1,2,3*}, 马海滨^{1,2,3}, 张诺飞^{1,2,3}

(1.河北师范大学计算机与网络空间安全学院,河北石家庄 050024; 2.河北省网络与信息安全重点实验室(河北师范大学),河北石家庄 050024; 3.河北省供应链大数据分析与安全工程研究中心(河北师范大学),河北石家庄 050024)

摘要:为解决脑电数据分辨率低、数据量不足以及被试者个体差异所导致的解码效率低下问题,提出适于脑电信号分析的轻量级多分支融合网络(multi-branch fusion network for electroencephalogram signal, EEG-MFNet)模型。通过多尺度时空卷积模块提取脑电数据的多层次时空特征,应用多尺度时间卷积提取更高级的时-空-频域特征,对输入分类器的特征数据应用滑动窗口,增强数据的有效特征。EEG-MFNet模型的平均分类准确率、标准差相比对比模型分别提升3.19%、22.86%以上,模型推理时间减少16.87%以上。实验结果表明所提方法提高运动想象脑电信号分类准确率,并增强模型的稳定性,提升了模型的训练效率,为基于运动想象的脑电信号分析提供更有效的解码方案。

关键词:多尺度卷积;滑动窗口;运动想象;脑机接口;脑电信号

中图分类号:TP391 **文献标志码:**A

引用格式:叶晓雅,王秀青,马海滨,等. EEG-MFNet:适用于脑电信号分析的轻量级多分支融合网络[J]. 山东大学学报(理学版),2025,60(7):1-12.

EEG-MFNet: a lightweight multi-branch fusion network for electroencephalogram signal analysis

YE Xiaoya^{1,2,3}, WANG Xiuqing^{1,2,3*}, MA Haibin^{1,2,3}, ZHANG Nuofei^{1,2,3}

(1. College of Computer and Cyber Security Hebei Normal University, Shijiazhuang 050024, Hebei, China; 2. Hebei Provincial Key Laboratory of Network & Information Security (Hebei Normal University), Shijiazhuang 050024, Hebei, China; 3. Hebei Provincial Engineering Research Center for Supply China Big Data Analytics & Data Security (Hebei Normal University), Shijiazhuang 050024, Hebei, China)

Abstract: In order to solve the problems of decoding efficiency caused by low resolution, insufficient data volume and individual differences of subjects, multi-branch fusion network for electroencephalogram signal (EEG-MFNet) model suitable for EEG signal analysis is proposed. Multi-level spatiotemporal features of EEG data are extracted through multi-scale spatiotemporal convolutional modules, and further applied by multi-scale temporal convolution to extract more advanced time-space-frequency domain features. Applying a sliding window to the feature data of the input classifier significantly enhances the effective features of the data. The average classification accuracy and standard deviation of the EEG-MFNet model are improved by more than 3.19% and 22.86% compared with the comparison model, respectively. Model inference time is reduced by more than 16.87%. The experimental results show that the proposed method improves the stability of the model and significantly improves the training efficiency. This work provides a more efficient decoding scheme for EEG signal analysis based on motor imagery.

Key words: multi-scale convolution; slide window; motor imagery; brain-computer interface; electroencephalogram signal

0 引言

随着人工智能的快速发展,人机交互(human-computer interaction, HCI)技术得到了广泛的关注^[1]。脑

收稿日期:2024-07-07;网络出版时间:2025-02-28 11:38:09

基金项目:国家自然科学基金资助项目(61673160);河北省自然科学基金资助项目(F2018205102);河北省高等学校科学技术研究重点项目(ZD2021063)

第一作者:叶晓雅(2000—),女,硕士,研究方向为脑电信号识别、深度学习等。E-mail:13230051283@163.com

*通信作者:王秀青(1970—),女,教授,硕士生导师,博士,研究方向为脑电信号识别、脉冲神经网络、先进机器人技术等。

E-mail:xqwang2013@163.com

机接口(brain-computer interaction, BCI)作为 HCI 技术的重要方面之一^[1],将人脑信号与计算机或外部设备进行交互,实现了人脑与机器之间的直接通信,在神经康复、辅助医学^[2-3]、军事^[4]以及娱乐^[5]等方面具有广阔的应用前景。

准确识别人类运动意图——脑电识别是 BCI 研究领域的关键问题之一。脑电信号作为一种复杂的时序信号,具有低信噪比(容易受心电、肌电、眼球运动、眨眼等多种生物因素以及环境伪影的干扰)的特性。此外,由于记录脑电信号的电极之间的耦合性,使得记录所得的脑电信号存在通道相关性。在进行同一身体部位的运动想象时,不同被试者可能会产生不同的脑电信号。上述这些特性使得脑电信号的识别极具挑战性。

常用范式之一的运动想象脑电信号在没有身体运动的情况下,通过意识或想象模拟特定的运动。在这个过程中,大脑皮层中的 μ 、 β 波的节律发生变化产生事件相关去同步(event-related desynchronization, ERD)和事件相关同步(event-related synchronization, ERS)现象^[6]。传统的运动想象任务分析方法多通过小波变换^[7]和短时傅里叶变换提取时频特征,借助共空间模式(common spatial pattern, CSP)^[8]提取空间特征等,然后根据提取的特征通过诸如支持向量机(support vector machine, SVM)和 Fisher 判别分析等进行分类。然而,这些传统分析方法的特征选择和分类是独立的,而特征选择影响着分类的结果。对此,研究者们开始尝试基于深度学习的端到端模型^[2],如:Lawhern 等^[9]提出的基于脑电信号的紧凑的卷积神经网络(a compact convolutional neural network for electroencephalogram-based BCIs, EEGNet)模型,利用可分离卷积以及深度卷积技术对脑电信号进行分类;Zhang 等^[2]在 EEGNet 结构基础上设计了多尺度模块,解决了由于脑电信号主体性带来的单尺度限制识别精度提升的问题。此外,当训练数据有限时,也会限制分类准确率的提高。

综上,虽然现有的端到端模型取得了不错的识别精度,但很多基于深度学习的脑电信号识别模型结构复杂、计算时间长,难以满足实际应用中对模型运行速度的要求,因此,须建立一种具有高分类准确率且轻量级的识别模型。本文提出一种适用于脑电信号分类的轻量级多分支融合网络(multi-branch fusion network for electroencephalogram signal, EEG-MFNet)模型解码脑电信号。该模型主要包含多尺度时空卷积(multi-scale temporal-spatio convolution, MSTs)、多尺度时间卷积(multi-scale temporal convolution, MST)以及滑动窗口(sliding window, SW)。与现有多尺度模型不同,本文所提模型直接对原始数据进行特征提取,不依赖于滤波等预处理操作,是一个鲁棒的、易于实现的、端到端的轻量级网络。

1 相关工作

脑电信号的解码方法主要包括传统的机器学习和深度学习技术。传统方法主要对空间特征和时频特征进行提取,如:Zhang 等^[10]提出基于 CSP 的多核极限学习机(multi-kernel extreme learning machine, MKELM),该方法借助 CSP 提取空间特征进行运动想象脑电信号的分类;Ang 等^[11]在 CSP 的基础上提出滤波器组共空间模式(filter bank common on spatial pattern, FBCSP)方法,该方法将带通滤波后的脑电信号分为多个频带,然后从每个频带中提取 CSP 特征,再借助特征选择算法自动选择对应频带的特征。

然而,上述这些方法需要大量的先验知识。与传统方法不同,深度学习具备直接从数据中自动提取特征的能力,能避免繁琐的预处理和手动特征提取的步骤。深度学习已成功应用于视频识别、图像分类等领域。深度学习主要包含卷积神经网络(convolutional neural networks, CNNs)、循环神经网络(recurrent neural networks, RNNs)、深度置信网络(deep belief network, DBN)方法以及它们的组合^[12]。CNNs 是脑电信号分类任务中使用最广泛的。基于标准 CNNs 的浅层、深层架构以及其他变体也被陆续提出。Lawhern 等^[9]提出的 EEGNet 模型,借助卷积提取数据的时空特征,并通过深度可分离卷积降低了模型的参数。Ingolfsson 等^[13]提出一种时间卷积网络(temporal convolutional network, EEG-TCNet)模型,该模型首次将时间卷积网络应用于脑电信号识别,在实现高准确率的同时节约了大量内存资源。Altaheri 等^[14]提出动态注意时间卷积网络(dynamic attention temporal convolutional network, D-ATCNet)模型解码运动想象脑电信号,该模型采用动态卷积(dynamic convolution, Dy-conv)和多级注意机制技术,能够在使用相对较少参数的同时提高模型对运动想象(motor imagery, MI)分类的准确性。同时,考虑到脑电数据的个体差异可能导致最佳卷积尺度不同的问题,Altuwaijri 等^[15]提出多分支结构(multibranch EEGNet, MBEEGNet)模型,利用

多尺度卷积核从原始脑电数据中提取不同范围的特征,进一步提升了脑电信号的识别精度。王蒙昊等^[16]提出的多尺度混合卷积的脑电信号网络(multi-scale hybrid neural network for EEG signal, EEG-MSTNet)模型,连用2个多尺度一维卷积增强对数据的时间特征提取能力,在一定程度上平衡了个体差异问题,然而对于空间特征的提取不够精细。Tang等^[17]提出多尺度混合网络模型,借助并行的多尺度一维和二维卷积提取数据的时空特征,在二分类问题上达到了较好的结果。

另一方面,CNNs需要大量的训练数据来实现高分类准确率,然而脑电数据获取相对困难,因而数据集大多规模较小。针对这一问题,目前采用2种数据增强方法:一种是进行数据转换,从原始的训练数据中生成更多的训练数据^[18-20];另一种方法是在原始训练数据中添加噪声,生成新的训练数据^[21-22]。

上述方法虽然在脑电识别方面表现出了良好的效果,但仍然面临2个问题:(1)大部分模型的多尺度结构基于EEGNet模型或简单的一维卷积实现,往往难以同时兼顾运行效率和性能;(2)许多方法在使用时没有考虑到脑电数据集大小的问题。因此,本文基于滑动窗口和多尺度混合卷积设计了一种适用于脑电信号分类的轻量级多分支融合网络模型。该模型在原来EEGNet的基础上将可分离卷积替换为一维卷积,使用多尺度提取不同层次的数据特征,借助滑动窗口操作对待分类数据进行特征增强。

2 数据集及预处理

2.1 数据集

采用运动想象脑电信号识别领域常用的2008年第四届脑机接口竞赛2a数据集(brain-computer interaction competition IV dataset 2a, BCI IV 2a)^[23],该数据集包含9名被试者关于左手(第1类)、右手(第2类)、双脚(第3类)和舌头(第4类)的4类运动想象实验。每名被试者在2d完成了2次实验,每天进行6组实验,每组包括48个实验,共288次实验。实验中采用22个脑电电极记录EEG信息,3个眼电电极记录有关眼球运动的信息,采样频率为250 Hz,带通滤波的范围为0.5~100 Hz。实验过程如图1所示。




图1 单次数据采集流程
Fig.1 Process of data acquisition

采集时,被试者注视电脑屏幕上出现的相应动作提示,跟着提示进行想象。实验开始时($t=0$ s),一个固定十字出现在电脑黑色屏幕上,并且还伴有简短的提示音。 t 在2~3.25 s时,以箭头的形式指向上、下、左或右,分别对应四类中舌头、脚、左手和右手。 t 在3~6 s时为被试者执行想象任务的时间,当 $t=6$ s时,屏上的十字消失,被试者休息时间为1.5 s,然后继续实验。

2.2 数据预处理

实验中单个样本的张量形状为(1,22,1125)。将第1d采集的数据作为训练集,第2d的采集数据作为测试集,训练集和测试集的样本数均为2592。为便于模型对样本标签进行有效分类,对训练集和测试集的标签进行one-hot编码,并在使用前对训练集和测试集进行标准化处理。

3 研究方法

受Lawhern等^[9]提出的EEGNet结构的启发,本文提出EEG-MFNet模型,总体结构如图2所示。该模型主要包含MSTs、MST以及SW模块。预处理后的脑电数据 $x_i \in \mathbf{R}^{C \times T}$ (C 为输入脑电数据的通道数, T 为输入脑电数据的采样点数),首先通过多尺度时空卷积模块在不同尺度下自适应地提取脑电数据的时空特征;然后利用多尺度时间卷积模块提取更精细的时-空-频域特征;最后在分类前将时间序列分割成多个窗口,经过层归一化后进行特征拼接,能有效地对待分类数据进行特征增强并提高分类准确性。表1是该网络结构各模块的参数。表1中的大部分参数根据实验效果设定的最优参数,其中多尺度时空卷积模块的卷积核大小还结合了对脑电数据的频域分析。

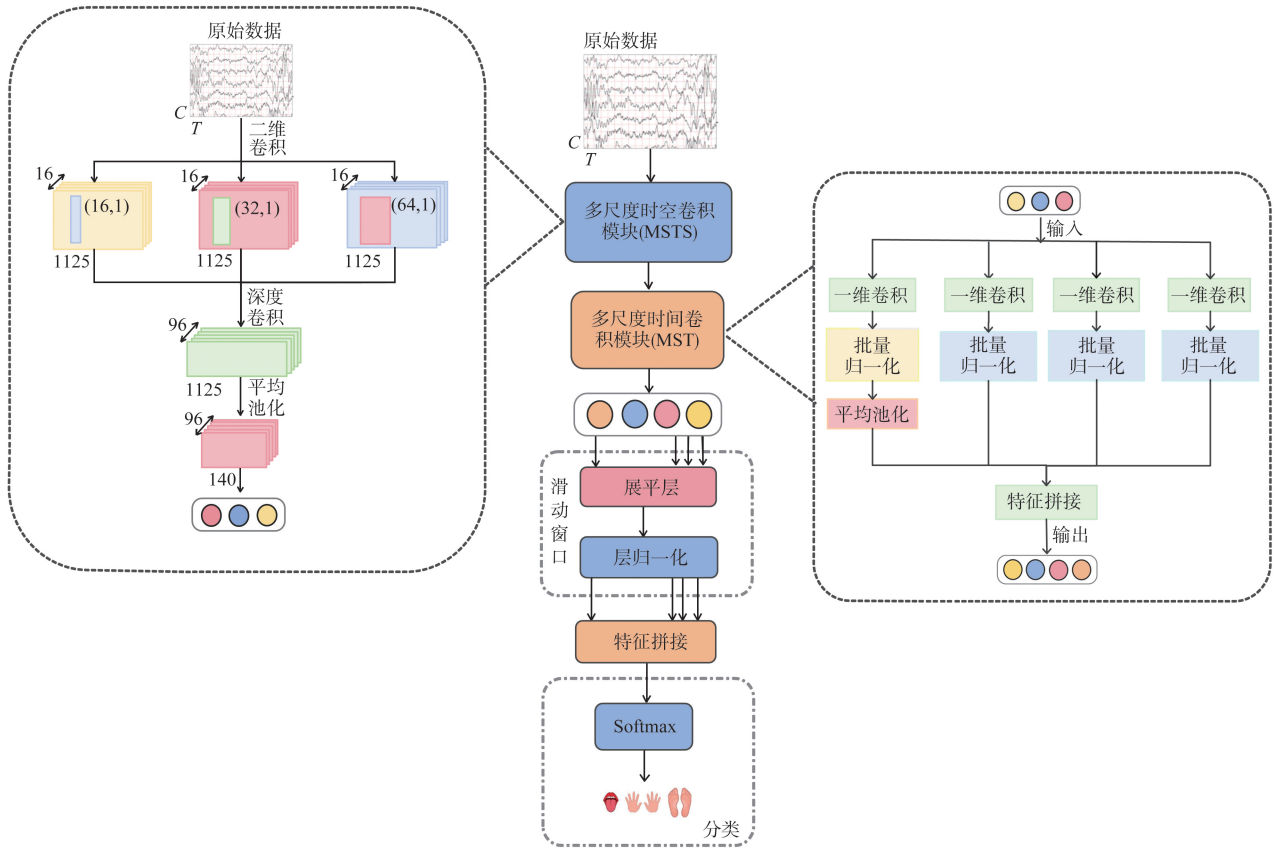


图2 EEG-MFNet 模型结构图

Fig.2 Structure of the model EEG-MFNet

表1 EEG-MFNet 模型参数

Table 1 Parameters of 1 EEG-MFNet model

模块	层结构名	参数设置	滤波器个数	步长	填充
多尺度时空卷积	二维卷积	卷积核大小: $(16,1)$, $(32,1)$, $(64,1)$	16	1	same
	深度卷积	卷积核大小为 $(1,22)$	32	1	
	平均池化	池化大小为 $(8,1)$		1	
	Dropout	丢弃率: 0.25			
多尺度时间卷积	一维卷积的分支 1	卷积核大小: 2, 4, 8	8	4	same
	一维卷积的分支 2	卷积核大小为 16	32	1	same
	平均池化	池化大小为 4			
	Dropout	丢弃率为 0.30			

注:表中省略了滑动窗口的参数设置。

3.1 多尺度时空卷积模块

在深度学习领域中,提升模型性能最直接的方法就是增加模型的深度或宽度^[24]。此外,在时间卷积层中使用 same 填充有助于保持时间维度不变,确保卷积操作不会丢失重要的时间信息,同时也简化了后续层的计算过程。然而,随着网络深度的增加,计算量会逐渐增加,而特征图会越来越小,导致信息丢失的问题。同时,脑电数据由于被试者的个体差异,不同被试者的最佳卷积核大小是不一样的。因此,为了提取更多层次的特征,本文构建一个由二维卷积组成的多尺度时空卷积模块,用于从脑电数据中提取初级的时空特征。该操作消除了对固定长度的内核的需要,并允许网络学习代表不同频率子带的滤波器^[25]。如图2所示,在多尺度时空卷积模块中,使用了3种不同大小的卷积核 $(k_l, 1)$ ($l=1, 2, 3$)提取时间特征,同时,借助深度卷积提取脑电信号的空间特征,其中, $k_1=16$, $k_2=32$, $k_3=64$ 。提取相关频谱信息为 8~32 Hz,覆盖 μ (8~13 Hz)波和 β (13~30 Hz)波,这与运动想象的生理学特性密切相关。

3.2 多尺度时间卷积模块

CNNs 借助于卷积操作提取特征,涉及到的参数有卷积核尺寸、移动步长、填充方式以及滤波器的数

量^[26]。不同的移动步长可以改变卷积提取到的数据之间的相关性。同时,不同的卷积核也可以捕获到不同范围的特征,大的卷积核可以捕获整体特征,而小的卷积核则捕获更精细的特征。其次,根据卷积核移动方向的不同,可以分为一维卷积和二维卷积。在处理一维序列数据(如时间序列、文本数据等)时,一维卷积相较于二维卷积更容易训练,可以在实现高性能的同时降低计算复杂度^[27]。

脑电数据在经过 MSTs 模块处理之后,得到时间序列相关的特征图,因此,在 MST 模块中使用一维卷积进一步提取更精细的时-空-频域特征,并应用多尺度提取不同层次的特征信息,进行特征拼接后输入后续模块,如图 2 所示。MST 模块的单分支采用一维卷积,而 EEGNet 模型采用可分离卷积,EEG-MFNet 模型较使用可分离卷积具有更好的识别精度和模型稳定性。

3.3 滑动窗口

为了进一步提升模型的性能,EEG-MFNet 模型借助滑动窗口对提取的特征进行处理,而不是直接将其输入到后续的层中,这一操作有助于对 MSTs 和 MST 模块处理后的特征信息进行增强,进而提高模型的分​​类准确率。这种将滑动窗口与卷积集成的操作与通过滑动窗口处理原始数据不同,在增强数据特征的同时也通过并行化过程减少训练和推理的时间,最初被用于基于滑动窗口的目标检测中。Schirrmester 等^[28]对此做了详细的描述,使用长度为 T_w 的滑动窗口,将经过混合卷积后的时间序列 T_c 划分为 n 个长度相同的子序列分别输入到后续分类模块。滑动窗口长度为

$$T_w = T_c - n + 1, \quad T_c > n \geq 1. \quad (1)$$

4 实验

4.1 评价指标

选取准确率、 k (即 Kappa 值)以及标准差作为指标评估实验结果。更高的准确率和 k 表明模型具有更好的分类性能,而较低的标准差意味着更小的离散度,表示模型具有更好的稳定性。准确率为

$$A_{\text{acc}} = \frac{\sum_{i=1}^c a_{ii}}{\sum_{i=1}^c \sum_{j=1}^c a_{ij}}, \quad (2)$$

式中: c 为类别数, a_{ii} 为类别预测正确的样本数, a_{ij} 为真实类别为 i 、预测类别为 j 的样本数,即 $\sum_{i=1}^c \sum_{j=1}^c a_{ij}$ 为总样本数。

k 是衡量模型一致性和有效性的指标,定义为

$$k = \frac{A_{\text{acc}} - P_e}{1 - P_e}, \quad (3)$$

式中 P_e 为预期分类精度,即

$$P_e = \frac{\sum_{i=1}^c \left(\sum_{j=1}^c a_{ij} \sum_{k=1}^c a_{ki} \right)}{\left(\sum_{i=1}^c \sum_{j=1}^c a_{ij} \right)^2}, \quad (4)$$

式中: $\sum_{j=1}^c a_{ij}$ 表示真实类别为第 i 类的样本数, $\sum_{k=1}^c a_{ki}$ 表示被预测类为第 i 类的样本数。

标准差 S 的定义为

$$S = \sqrt{\frac{\sum_{d=1}^N (x_d - \bar{x})^2}{\sum_{i=1}^c \sum_{j=1}^c a_{ij}}}. \quad (5)$$

式中: x_d 为第 d 个被试者的分类准确率, N 为被试者的个数。

4.2 实验设置

使用 TensorFlow 的 Keras 框架在 CPU 为 11th Gen Intel(R) Core(TM) i7-11700F, 2.5 GHz, GPU 为

NVIDIA GeForce RTX 3060 Ti 以及内存为 16 GB 的实验环境下进行模型的训练和评估,在整个过程中均遵循了如下配置:采用 Adam 优化器算法和最小化交叉熵损失函数对模型参数进行优化;每个 epoch 中批处理 (batchsize) 的大小为 32;学习率为 0.000 9。在训练过程中采取容忍度为 300 的早停训练方式,即当模型连续训练超过 300 次后,准确率没有继续提升,则停止训练。此外,为了保证结果的准确性,在实验中,对每名被试者均进行了 20 次实验,并取均值作为最后结果。

4.3 对比实验

将 EEG-MFNet 模型与一些传统的机器学习方法和典型的深度学习模型在 BCI IV 2a 数据集上的分类结果进行了比较,具体结果见表 2—4 所示。

表 2 在 BCI IV 2a 数据集上 EEG-MFNet 模型与传统机器学习方法的分类准确率

Table 2 Classification accuracy of EEG-MFNet model and traditional machine learning methods on the BCI IV 2a dataset
单位: %

被试者	FBCSP ^[11]	MTF-CSP ^[29]	EEG-MFNet
A1	76.00	92.2	91.60
A2	56.50	59.9	78.19
A3	81.25	97.1	95.80
A4	61.00	64.7	89.65
A5	55.00	74.8	78.44
A6	45.25	65.7	78.92
A7	82.75	81.4	93.06
A8	81.75	92.5	89.58
A9	70.75	80.0	86.18
平均值	67.75	78.7	86.82
标准差	16.96	12.7	6.58

注:粗体为测试指标最好结果。

表 3 在 BCI IV 2a 数据集上 EEG-MFNet 模型与其它深度学习方法的分类准确率

Table 3 Classification accuracy of EEG-MFNet model and other deep learning methods on the BCI IV 2a dataset
单位: %

被试者	EEGNet ^[9]	EEG-TCNet ^[13]	D-ATCNet ^[14]	MBEENet ^[15]	EEG-MSTNet ^[16]	MBEEG CBAM ^[30]	MBHNN ^[31]	EEG-MFNet
A1	86.9	83.0	87.5	89.59	86.81	91.09	90.58	91.60
A2	62.6	58.8	70.0	68.06	68.40	65.87	75.99	78.19
A3	91.7	92.6	94.9	94.58	95.83	94.52	93.73	95.80
A4	64.7	67.7	80.5	79.88	79.86	77.88	83.14	89.65
A5	71.6	73.0	79.5	76.92	82.29	81.87	73.09	78.44
A6	60.3	60.1	74.4	66.10	71.53	64.48	68.15	78.92
A7	88.9	86.0	93.2	91.57	92.71	93.38	95.82	93.06
A8	85.0	81.8	87.6	87.71	87.50	89.84	89.06	89.58
A9	80.0	81.4	89.6	83.69	86.81	86.69	86.24	86.18
平均值	76.9	76.1	84.1	82.01	83.53	82.85	83.91	86.82
标准差	12.2	11.8	8.53	10.13	9.10	10.70	9.09	6.58

注:粗体为测试指标最好结果。

表 4 在 BCI IV 2a 数据集上 EEG-MFNet 模型与其它深度学习模型的 k

Table 4 k of EEG-MFNet model and other deep learning methods on the BCI IV 2a dataset

被试者	EEGNet ^[9]	EEG-TCNet ^[13]	D-ATCNet ^[14]	MBEENet ^[15]	MBEEGCBAM ^[30]	MBHNN ^[31]	EEG-MFNet
A1	0.83	0.77	0.83	0.86	0.88	0.88	0.89
A2	0.50	0.45	0.60	0.57	0.55	0.69	0.71
A3	0.89	0.90	0.93	0.93	0.93	0.95	0.94
A4	0.53	0.57	0.74	0.73	0.71	0.71	0.86
A5	0.62	0.64	0.73	0.69	0.76	0.64	0.71
A6	0.47	0.47	0.66	0.55	0.53	0.60	0.72

表4(续)

被试者	EEGNet ^[9]	EEG-TCNet ^[13]	D-ATCNet ^[14]	MBEEGNet ^[15]	MBEEGCBAM ^[30]	MBHNN ^[31]	EEG-MFNet
A7	0.85	0.81	0.91	0.89	0.91	0.94	0.91
A8	0.80	0.76	0.83	0.84	0.87	0.80	0.86
A9	0.73	0.75	0.86	0.78	0.82	0.85	0.82
平均值	0.69	0.68	0.79	0.76	0.77	0.78	0.82
标准差	0.16	0.16	0.11	0.13	0.15	0.12	0.09

注:粗体为测试指标最好结果。

对比实验中使用的传统机器学习方法为 FBCSP 方法^[11]和多时频 CSP (multi-time and frequency band common space pattern, MTF-CSP) 脑电特征分类方法^[29]。FBCSP 方法^[11]将带通滤波后的脑电信号分为多个频带,然后从每个频带中提取 CSP 特征,借助特征选择算法自动选择对应频带的特征。MTF-CSP 方法^[29]是一种基于多时间窗和多频带的 CSP 算法,采用 SVM 对从多时间窗中提取的多频带特征进行了分类。

使用的典型深度学习模型有:EEGNet^[9]、EEG-TCNet^[13]、D-ATCNet^[14]、MBEEGNet^[15]、EEG-MSTNet^[16]、结合卷积注意机制的多分支 EEGNet^[30] (multi-branch EEGNet with convolutional block attention module, MBEEGCBAM) 以及多分支混合神经网络^[31] (multi-branch hybrid neural network, MBHNN) 模型。EEGNet 模型^[9]是一种轻量且高效的脑电信号处理模型。EEG-TCNet 模型^[13]是基于 TCNet 的模型,该模型内存占用小,计算推理复杂度低。D-ATCNet 模型^[14]采用动态卷积和多级注意力机制,使用相对少的参数却提高了 MI 分类的准确率。MBEEGNet 模型^[15]是多分支卷积神经网络模型,通过结合不同大小的卷积核,从原始脑电数据中提取不同尺度的时空特征。EEG-MSTNet 模型^[16]连用两个多尺度一维卷积增强对数据的时间特征提取能力,在一定程度上平衡了个体差异问题。MBEEGCBAM 模型^[30]是一种多分支卷积神经网络模型,利用注意力机制和融合技术对 EEG-MI 信号进行分类。MBHNN 模型^[31]是一种端到端的新模型,将输入信号分为与运动想象信号相关的 4 个频段。同时还引入双向门控循环单元 (gate recurrent unit, BiGRU) 来识别 EEG 特征。

表 2 中列出了所提方法与传统机器学习方法对 9 名被试者分类准确率的对比。实验结果表明,所提 EEG-MFNet 模型的准确率为 86.82%,相比于 FBCSP 方法^[11]提高 27.23%,相比于 MTF-CSP 方法^[29]提高 11.1%。与对比方法相比,本文所提方法在被试者 A2、A4、A5、A6、A7 以及 9 上获得最高分类准确率。

表 3 中列出了所提方法与其他深度学习的基线方法对 9 名被试者分类实验的准确率。实验结果表明,EEG-MFNet 模型在 BCI IV 2a 数据集的分类准确率 86.82%的,比其他模型高出了 3.19%以上。对于单个被试者的分类准确率,EEG-MFNet 模型在被试者 A1、A2、A4 和 A6 上达到了最高值。与实验结果次优的模型相比,被试者 A2 的分类准确率提高了 2.89%;被试者 A4 的准确率提高 7.83%;被试者 A6 的准确率提高 6.1%。此外,所提方法的准确率的标准差为 6.58%,在对比方法中的准确率的标准差最小,模型的稳定性较好。

表 4 中列出了所提模型与深度学习的基线方法在 BCI IV 2a 数据集上关于 k 的比较结果。所有模型中 EEG-MFNet 模型的 k 最大,为 0.82。其中,在被试者 A1、A2、A4 和 A6 的 k 在所有模型中均为最大。此外, k 的标准差要所有模型中为最小,表明了所提模型是有效且稳定的。

4.4 实验结果的统计分析

为了比较所提 EEG-MFNet 模型与基线模型对运动想象脑电信号的分析结果,本文对实验结果进行统计分析。使用 Shapiro 检验模型的识别准确率是否服从正态分布。由于 Shapiro 检验结果表明所得实验数据均服从正态分布,因此采用检验水平 $\alpha=0.05$ 的配对 t 检验进行分析。 m_1 和 m_2 分别是 EEG-MFNet 模型和基线模型的识别准确率(见表 2、3),则配对 t 检验的原假设 H_0 和备择假设 H_1 分别为

$$H_0: m_1 \leq m_2, \quad H_1: m_1 > m_2. \quad (6)$$

EEG-MFNet 模型与 FBCSP^[11]、MTF-CSP^[29]、EEGNet^[9]、EEG-TCNet^[13]、D-ATCNet^[14]、MBEEGNet^[15]、EEG-MSTNet^[16]、MBEEGCBAM^[29] 以及 MBHNN^[30] 模型进行统计分析得到的 p 值分别为 1.854×10^{-5} 、0.009 6、0.000 9、0.000 3、0.029 7、0.003 6、0.024 9、0.040 8 和 0.021 5,均小于 0.05,不能拒绝 H_1 ,即所提模型的识别准确率优于基线模型。

4.5 消融实验

4.5.1 分支消融实验

EEG-MFNet 模型的 MSTs 和 MST 模块均包含多个分支。为了验证单分支和多分支结构对模型分类结果的影响,在 BCI IV 2a 数据集上进行了消融实验,对应的结果如图 3、4 所示。具体参数设置见表 5。




图3 多尺度时空卷积模块的消融实验

Fig.3 Ablation experiments of multi-scale spatio-temporal convolution modules




图4 多尺度时间卷积模块的消融实验

Fig.4 Ablation experiments for multi-scale time convolution modules

表5 分支消融实验参数

Table 5 Parameters of the branch ablation experiments

模块名称	分支	卷积核大小	滤波器个数	步长	填充
多尺度时空卷积	分支 1	(16,1)	16	1	same
	分支 2	(32,1)	16	1	same
	分支 3	(64,1)	16	1	same
多尺度时间卷积	分支 1	2,4,8	8	4	same
	分支 2	16	32	1	same

图3为MSTs模块的分支消融实验的结果。从中可以看出,所提模型的平均分类准确率优于单分支结构,分支1、2以及3的分类准确率分别为84.81%、85.13%以及85.07%。除了被试者A7和A9,其余被试者在EEG-MFNet模型中的结果均优于使用单分支结构的模型。对于比较难分的被试者A2、A4以及A6,EEG-MFNet模型分类准确率有了大幅提升,证实了该网络所提多尺度结构能够充分提取时空信息,并显著提高脑电信号的解码精度。

图4为MST模块的消融实验结果。分支1以及分支2部分的实验结果分别为81.91%和85.52%,即EEG-MFNet模型相对于只使用分支1结构来说有了很大的提升,而对于分支2来说,提升相对较小,但由于分支1的加入,使模型的标准差从7.72%降为6.58%,模型的稳定性更好。

4.5.2 模块消融实验

为了验证模型各个模块对分类性能的影响,本文基于 BCI IV 2a 数据集进行模块消融实验。表 6 为从 EEG-MFNet 模型中删除一个或多个模块后对分类性能的影响。EEG-MFNet 模型的分​​类准确率为 86.82%,而模型分别去除 MSTs、MST、SW 以及 SW+MST+MSTs 模块后,准确率为 84.81%、85.52%、84.22% 以及 83.55%。结果表明,MSTs 模块使得模型提取特征的能力提高了 2.37%;MST 模块提高了 1.5%;SW 提升 3.09%;本文所提出的模型相比较于修改前提高 3.91%。从上述结果可以看出模型中的每一个模块都对提高性能起到了积极的作用。

表 6 EEG-MFNet 模型各个模块参数
Table 6 Parameter of the individual modules of the EEG-MFNet model

模块	准确度/%	k
MSTs	84.81	0.80
MST	85.52	0.81
SW	84.22	0.79
SW+MST+MSST	83.55	0.78

4.6 参数敏感性实验

本文研究了滑动窗口的数量对模型分类准确率的影响,实验结果如图 5 所示。一般来说,随着滑动窗口数量的增多,对数据的增强效果会逐渐提升,模型从不同位置学习到的信息则越多,模型的效果就会更好。然而,通过图 5 的实验结果可以看到 EEG-MFNet 模型对 BCI IV 2a 数据集的分类准确率在经过 (4, 86.82) 之后便有所下降。这是因为过多的滑动窗口会造成信息冗余,使得模型难以准确学习数据集的信息。因此,在实验时使用的滑动窗口的数量为 4。




图 5 不同滑动窗口数量的实验结果

Fig.5 Experimental results for different numbers of sliding windows

4.7 可视化

图 6 为不同模型训练的被试者 A4 的混淆矩阵,横纵坐标分别为预测标签和真实标签,图例颜色的深浅表示分类正确率的高低。蓝色区域代表准确率较低,逐渐过渡到黄色区域准确率最高。




图 6 不同模型的被试者 A4 的混淆矩阵

Fig.6 Confusion matrix of different models with Subject A4

从图6可以看出, EEG-MFNet模型相比较于 EEGNet 和 EEG-TCNet 模型对4种 MI 任务的分类准确率均得到提升, 分别达到了 92%、91%、86%和 94%。此外, 为了证明所提模型学习到的特征具有高可分性, 以被试者 A4 为例将不同模型学习到的特征进行 t -分布随机邻域嵌入 (t -distributed stochastic neighbor embedding, t -SNE) 可视化, 结果如图7所示。EEG-MFNet 模型在捕捉脑电时空特征方面的能力优于 EEG-Net 和 EEG-TCNet 模型。

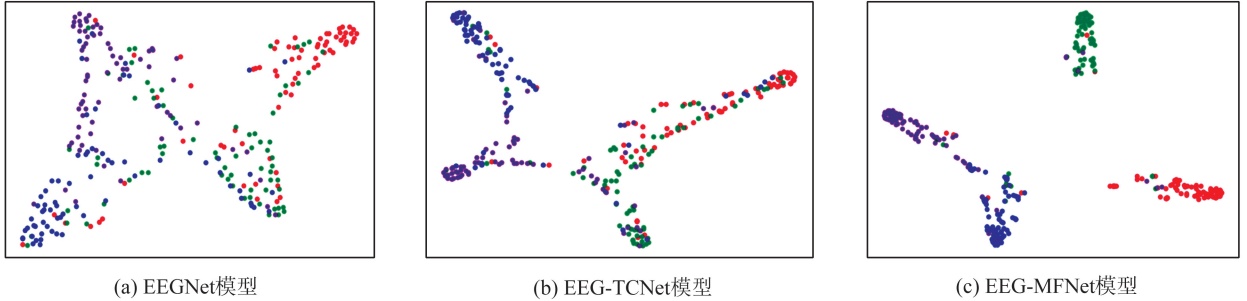


图7 被试者 A4 的不同算法的特征可视化图

Fig.7 Feature visualization of the different algorithms for Subject A4

4.8 推理效率评估实验

本文从模型的推理速度研究轻量化程度, 在相同的实验条件下, 对比了模型的训练时间, 具体结果见表7。轻量级模型 EEGNet 参数量小, 具有最快的推理速度, 但其脑电识别精度相对较低, 为 76.9%。相比之下, EEG-MFNet 模型分类准确率为 86.82%, 提高 12.89%。与 D-ATCNet 和 EEG-MSTNet 模型相比, EEG-MFNet 模型在提升分类准确率的同时也具有更短的推理时间。相比 MBEEGNet 模型, 本文所提模型的准确率提高了 5.87%, 而推理时间仅增加了 104 s, 不到 2 min。未来工作可以将 EEGNet 模型中的可分离卷积与本模型相结合, 提出更为轻量化且具有较高分类准确率的新模型。

表7 EEG-MFNet 模型与基线模型的训练时间对比

Table 7 Comparisons of the training time for the EEG-MFNet model and the baseline model

模型	时间/s	准确率/%
EEGNet ^[9]	876	76.90
D-ATCNet ^[14]	2 988	84.10
MBEEGNet ^[15]	2 388	82.01
EEG-MSTNet ^[16]	3 108	83.53
EEG-MFNet	2 484	86.82

5 讨论

实验结果表明, EEG-MFNet 模型能有效提取脑电数据的时空特征, 与 EEGNet^[11]、MBEEGNet^[16]、D-ATCNet^[15]、EEG-TCNet^[14]、EEG-MSTNet^[17] 和 FBCSP^[12] 模型相比具有更好的分类性能。EEG-MFNet 模型中的 MSTs 模块借助多尺度卷积精准地提取与运动想象生理学特性密切相关的脑电数据时空特征, 这一操作很大程度上增强模型的特征提取能力。消融实验结果证明 EEG-MFNet 模型中的多分支结构有助于分类准确率的提升。MST 模块借助一维卷积进一步提取时频特征, 在消融实验中, 提升模型分类准确率和稳定性。由于脑电数据获取相对困难, 导致数据集大多规模较小, 通常借助添加噪声、滑动窗口等增强数据。本研究的不同之处在于借助卷积集成的滑动窗口对处理后的时间特征图进行滑动切片操作, 实现特征增强的效果, 与传统数据相比, 减少模型的运行推理时间。从表5中的实验结果可以看出, 本文模型分类准确率较高。此外, 模型轻量化实验部分也表明所提模型具有较高的推理速度。

虽然 EEG-MFNet 模型取得了很好的解码效果, 但仍存在一些局限性。多尺度特征融合在提升准确率的同时增加了模型的参数量, 在未来的研究中, 将改进多尺度特征提取网络和特征融合结构, 将所提模型与可分离卷积相结合, 力图在减少网络参数的情况下提高模型分类准确率, 所提模型在特征提取时仅使用卷积结构, 提取全局依赖方面具有局限性, 进一步考虑使用 Transformer 结构改进时间依赖性。本研究仅

针对单被试进行了实验,将在现有实验的基础上考虑借助迁移学习或域自适应技术研究跨被试条件下的脑电信号解码,并通过脉冲神经网络进一步提升模型的稳定性。

6 结论

本文提出的基于滑动窗口和多尺度卷积的轻量级多尺度融合网络 EEG-MFNet 模型具有 4 个优点:首先,多尺度时空卷积模块借助符合运动想象脑电信号特性的不同尺度的卷积核,解决了脑电数据因被试者差异导致的最佳卷积尺度不同的问题,使得模型可以自适应地提取数据集的时空信息;其次,多尺度时间卷积模块中使用多尺度一维卷积处理时间序列,在提取更丰富特征的同时降低计算复杂度,并且提升模型的鲁棒性;然后,借助集成卷积的滑动窗口进行特征增强,进一步加快模型的速度并提高了分类准确率。最后,所提模型相比其他方法更轻量化,在计算资源有限的情况下,更易于实现。实验结果表明,EEG-MFNet模型在 BCI IV 2a 数据集上与几种先进方法相比达到了最高的分类准确率,为 86.82%,标准差最小,为 6.58%。此外,借助消融实验,验证各模块的有效性。

参考文献:

- [1] JIAO Runhai, LI Chengyang, XUN Gangyi, et al. A context-aware multi-event identification method for nonintrusive load monitoring[J]. IEEE Transactions on Consumer Electronics, 2023, 69(2):194-204.
- [2] ZHANG Yu, LI Penghai, CHENG Longlong, et al. Attention-based multiscale spatial-temporal convolutional network for motor imagery EEG decoding[J]. IEEE Transactions on Consumer Electronics, 2024, 70(1):2423-2434.
- [3] AHMED I, JEON G, PICCIALLI F. From artificial intelligence to explainable artificial intelligence in industry 4.0: a survey on what, how, and where[J]. IEEE Transactions on Industrial Informatics, 2022, 18(8):5031-5042.
- [4] WILLIAMS S C, HORSFALL H L, FUNNELL J P, et al. Neurosurgical team acceptability of brain-computer interfaces: a two-stage international cross-sectional survey[J]. World Neurosurgery, 2022, 164:884-898.
- [5] LI Hongli, LIU Haoyu, CHEN Hongyu, et al. Multi-scale feature extraction and classification of motor imagery electroencephalography based on time series data enhancement[J]. Journal of Biomedical Engineering, 2023, 40(3):418-425.
- [6] CHUNDURI V, AOUNDI Y, KHAN S, et al. Multi-scale spatiotemporal attention network for neuron based motor imagery EEG classification[J]. Journal of Neuroscience Methods, 2024, 406:110-128.
- [7] GAO Dongrui, YANG Wen, LI Pengrui, et al. A multiscale feature fusion network based on attention mechanism for motor imagery EEG decoding[J]. Applied Soft Computing, 2024, 151:111-129.
- [8] LI Hongli, CHEN Hongyu, JIA Ziyu, et al. A parallel multi-scale time-frequency block convolutional neural network based on channel attention module for motor imagery classification[J]. Biomedical Signal Processing and Control, 2023, 79:104066.
- [9] 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.
- [10] ZHANG Yu, WANG Yu, ZHOU Guoxu, et al. Multi-kernel extreme learning machine for EEG classification in brain-computer interfaces[J]. Expert Systems with Applications, 2018, 96:302-310.
- [11] ANG K K, CHIN Z Y, ZHANG H, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface[C]// 2008 IEEE International Joint Conference on Neural Networks, Hong Kong: IEEE, 2390-2397.
- [12] 吕璐,程虎,朱鸿泰,等. 基于深度学习的目标检测研究与应用综述[J]. 电子与封装,2022,22(1):72-80.
LV Lu, CHENG Hu, ZHU Hongtai, et al. Review of research and application of target detection based on deep learning[J]. Electrons and Packaging, 2022, 22(1):72-80.
- [13] INGOLFSSON T M, HERSCHE M, WANG X, et al. EEG-TCNet: an accurate temporal convolutional network for embedded motor-imagery brain-machine interfaces[C]// 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC). Toronto: IEEE, 2020:2958-2965.
- [14] ALTAHERI H, MUHAMMAD G, ALSULAIMAN M. Dynamic convolution with multilevel attention for EEG-based motor imagery decoding[J]. IEEE Internet of Things Journal, 2023, 10(21):18579-18588.
- [15] ALTUWAIJRI G, MUHAMMAD G. A multibranch of convolutional neural network models for electroencephalogram-based motor imagery classification[J]. Biosensors, 2022, 12(1):22.

- [16] 王蒙昊,方慧娟,龚亨翔,等. 应用多尺度混合卷积网络的脑电信号特征提取与识别[J]. 华侨大学学报(自然科学版), 2023,44(5):628-635.
WANG Menghao, FANG Huijuan, GONG Hengxiang, et al. Feature extraction and identification of EEG signals using multi-scale hybrid convolutional networks[J]. Journal of Huaqiao University (Natural Science Edition), 2023, 44 (5):628-635.
- [17] TANG Xianlun, YANG Caiquan, SUN Xia, et al. Motor imagery EEG decoding based on multi-scale hybrid networks and feature enhancement[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31:1208-1218.
- [18] GUENNEC A L, MALINOWSKI S, TAVENARD R. Data augmentation for time series classification using convolutional neural networks[C]//European Conference on Principles of Data Mining and Knowledge Discovery. Riva del Garda, Italy: IEEE, 2016.
- [19] KIM S K, KIRCHNER E A, STEFES A, et al. Intrinsic interactive reinforcement learning—using error-related potentials for real world human-robot interaction[J]. Scientific Reports, 2017, 7(1):1-16.
- [20] LOTTE F. Signal processing approaches to minimize or suppress calibration time in oscillatory activity-based brain-computer interfaces[J]. Proceedings of the IEEE, 2015, 103(6):871-890.
- [21] WANG Fang, ZHONG Shenhua, PENG Jianfen, et al. Data augmentation for EEG-based emotion recognition with deep convolutional neural networks[C]//MultiMedia Modeling: 24th International Conference, MMM 2018. Tokyo: Springer, 2018.
- [22] LI Youjun, HUANG Jiajin, ZHOU Haiyan, et al. Human emotion recognition with electroencephalographic multidimensional features by hybrid deep neural networks[J]. Applied Sciences, 2017, 7(10):1060.
- [23] BRUNNER C, LEEB R, MULLER-PUTZ G et al. BCI competition 2008—Graz data set A[DB/OL]. (2008-07-03)[2014-01-17]. <https://ieeedataport.org/documents/bci-competition-2008>.
- [24] ZHANG C, KIM Y K, ESKANDARIAN A. EEG-inception: an accurate and robust end-to-end neural network for EEG-based motor imagery classification[J]. Journal of Neural Engineering, 2021, 18(4):046014.
- [25] SALAMI A, ANDREU-PEREZ J, GILLMEISTER H. EEG-ITNet: an explainable inception temporal convolutional network for motor imagery classification[J]. IEEE Access, 2022, 10:36672-36685.
- [26] 刘近贞,叶方方,熊慧. 基于卷积神经网络的多类运动想象脑电信号识别[J]. 浙江大学学报(工学版),2021,55(11):2054-2066.
LIU Jinzhen, YE Fangfang, XIONG Hui. Multi-class motor imagery EEG signal recognition based on convolutional neural networks[J]. Journal of Zhejiang University (Engineering Edition), 2021, 55(11):2054-2066.
- [27] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D convolutional neural networks and applications: a survey[J]. Mechanical Systems and Signal Processing, 2021, 151:107398.
- [28] SCHIRRMESTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[C]//2017 IEEE Signal Processing in Medicine and Biology Symposium (SPMB). Los Angeles: IEEE, 2017:1-7.
- [29] YANG Jun, MA Zhengmin, SHEN Tao. Multi-time and multi-band CSP motor imagery EEG feature classification algorithm [J]. Applied Sciences, 2021, 11(21):10294.
- [30] ALTUWAIJRI G A, MUHAMMAD G. Electroencephalogram-based motor imagery signals classification using a multi-branch convolutional neural network model with attention blocks[J]. Bioengineering (Basel), 2022, 9(7):323.
- [31] MA Weifeng, XUE Haojie, SUN Xiaoyong, et al. A novel multi-branch hybrid neural network for motor imagery EEG signal classification [J]. Biomedical Signal Processing and Control, 2022, 77:103718.

(编辑:陈丽萍)