

DOI:10.19651/j.cnki.emt.2312912

基于 MTACNet 网络的运动想象脑电分类*

朱康¹ 吴晓红¹ 郭远哲¹ 杜立峰² 何小海¹

(1. 四川大学电子信息学院 成都 610065; 2. 成都锦城学院电子信息学院 成都 611731)

摘要: 为了更好地利用到脑电信号中的相关特征,改善运动想象脑电的分类性能,构建了一种基于混合特征和并行多尺度 TCN 模块的多层卷积网络(MTACNet)。首先,搭建基于混合特征的多层卷积神经网络,并在其中嵌入高效通道注意力机制,选取 PReLU 作为激活函数,以提取脑电信号中的时域和空域信息;然后对 TCN 模块进行改进,构建并行多尺度时域特征提取模块,接入多层卷积网络,进一步挖掘不同时间尺度的特征信息。在公开数据集 BCI_IV_2a 和自采数据集 SCU_MI_EEG 上进行测试,平均分类准确率分别为 86.15%、77.10%,标准差分别为 9.17%、13.58%。并且针对自采数据集,设计了一种融合多频域脑电信号进行三通道输入的预处理方法,经过预处理后使平均分类准确率提升了 3.29%。实验结果表明,与其他方法相比,本文所构建的分类网络取得了较为不错的分类效果,所设计的预处理方法能够降低复杂环境和无关干扰因素对分类结果的影响。

关键词: 脑电;脑机接口;运动想象;CNN;TCN;SMR

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 510.40

Motor imagination EEG classification based on MTACNet

Zhu Kang¹ Wu Xiaohong¹ Guo Yuanzhe¹ Du Lifeng² He Xiaohai¹

(1. College of Electronics and Information Engineering, Sichuan University, Chengdu 610065, China;

2. Department of Electronic and Information Engineering, Chengdu Jincheng College, Chengdu 611731, China)

Abstract: In order to make better use of the relevant features in EEG signals and improve the classification performance of motor imagery EEG, a multi-layer convolutional network (MTACNet) based on mixed features and parallel multi-scale TCN modules was constructed. First, build a multi-layer convolutional neural network based on mixed features, and embed an efficient channel attention mechanism in it, and select PReLU as the activation function to extract the temporal and spatial information in the EEG signal; then improve the TCN module, build a parallel multi-scale time-domain feature extraction module, connect to a multi-layer convolutional network, and further mine feature information at different time scales. Tested on the public dataset BCI_IV_2a and the self-collected dataset SCU_MI_EEG, the average classification accuracy rates are 86.15%, 77.10%, and the standard deviations are 9.17%, 13.58%, respectively. And for the self-collected data set, a preprocessing method was designed to fuse multi-frequency domain EEG signals for three-channel input. After preprocessing, the average classification accuracy rate increased by 3.29%. The experimental results show that: Compared with other methods, the classification network constructed in this paper has achieved relatively good classification results, and the designed preprocessing method can reduce the impact of complex environments and irrelevant interference factors on the classification results.

Keywords: EEG; brain-computer interface; motor imagination; CNN; TCN; SMR

0 引言

21 世纪被称为“脑研究世纪”,伴随着人们对于脑科学的不断探索与研究,脑与机的界限被逐渐打破,同时也相应地推动了脑机智能技术的快速发展。在此过程中,脑机接

口(brain-computer interface, BCI)发挥着不可忽视的作用,它是将人脑与外界环境相互连接起来进行通信的媒介,实现了大脑与外接设备之间的交互。而基于运动想象的 BCI 系统,因其操作简单、具有广阔的发展前景而受到人们的青睐,被广泛应用于脊髓损伤、脑瘫等无法控制自身肌肉

收稿日期:2023-02-24

* 基金项目:四川省重点研发项目(2021YFS0239)、成都市重大科技应用示范项目(2019-YF09-00120-SN)资助

活动的神经性疾病患者的康复中,并且在无人驾驶、日常娱乐等领域有着很好的发展潜力。然而作为整个BCI系统最核心的部分,如何进一步提高运动想象分类的准确率仍然具有非常大的挑战。

在最初对运动想象脑电信号进行分类的时期,研究人员主要通过提取脑电信号中区分度较好的特征来进行分类,将研究重点都放在特征提取上面。比如,2007年,Novi等^[1]提出了一种被称为子带公共空间模式的方法来提取脑电信号特征进行分类;2011年,Barachant等^[2]利用黎曼几何直接使用对称正定矩阵流形来提取脑电信号特征;2017年,Baig等^[3]提出了一种差分进化算法,用于搜索特征空间以生成最优特征子集;2019年,Ai等^[4]将通过共空域模式提取的特征、功能脑网络特征和局部特征尺度分解进行融合来提高分类精度。上述特征提取方法虽然都取得了一定的分类效果,但往往只能提取一些浅层的特征信息,无法提取隐藏在脑电信号中的深层特征,从而导致分类准确率偏低,不能满足真实场景下的应用。后面随着深度学习的快速发展,研究人员也越来越多地将深度学习网络应用到脑电信号的分类中去。如2018年Wang等^[5]使用长短期记忆网络(long short-term memory, LSTM)进行运动想象脑电信号分类;同年,Lawhern等^[6]提出EEGNet网络模型,在脑电信号的不同领域都有着良好的分类效果;2019年,Zhang等^[7]将CNN与LSTM进行融合,以此提高脑电信号分类的准确率;同年,Li等^[8]将VGG网络应用到脑电信号分类上去,也取得了良好的分类效果;2020年,Hou等^[9]先通过脑电图源成像技术对脑电信号进行选择,然后通过CNN再进行分类处理;2021年,Song等^[10]首次将Transformer的思想应用到脑电信号分类领域,通过注意力转换策略提高分类准确率。相较于传统的特征提取方法,上述深度学习方法大多利用到了更深层次的时域和空域特征,但由于脑电信号在时域上具有相关性,并且在不同时间尺度上具有不同的特征信息,利用不同时间尺度的特

征信息可以从多方面增强不同运动想象任务间的差异性,改善分类效果,而上述深度学习方法大多没有利用到不同时间尺度下的特征信息。虽然无论是机器学习还是深度学习,在脑电信号分类中都取得了一定的效果。然而,由于脑电信号比较复杂、易受干扰等特点,当运动想象脑电信号分类应用于实际生活中时,分类效果就很容易受到周围环境和条件的限制,从而导致分类准确率下降,如何提高分类准确率仍然面临着巨大的挑战。

根据上述问题,本文构建了一种基于混合特征和并行多尺度TCN模块的多层卷积网络(multi-scale tcnet and attention convolutional network, MTACNet),通过构建多层卷积模块来提取脑电信号中的混合特征并嵌入注意力机制和引入非线性因素,然后利用并行多尺度时域特征提取模块来进一步挖掘混合特征中的时域信息,并设计了融合多频域脑电信号的三通道输入模块进行预处理,在公开数据集BCI_IV_2a和自采数据集SCU_MI_EEG上进行运动想象四分类测试。

1 MTACNet 网络模型

1.1 整体网络模型

相同通道的脑电信号在时间维度上具有很强的关联性,不同通道间的脑电信号在空间维度上也有着密不可分的联系,不同运动想象任务的脑电信号在以上两个方面有着很大的区别,可以通过提取脑电信号中的时域和空域特征来实现对于不同运动想象任务之间的解码。MTACNet根据以上原理构建了如图1所示的网络模型,该模型首先采用二维卷积、逐通道卷积和逐点卷积来搭建提取脑电信号混合特征的多层卷积模块,然后在通道维度上嵌入注意力机制并引入非线性因素,最后为了进一步挖掘混合特征中的时域信息,在多层卷积后加入了并行多尺度时域特征提取模块。具体的网络结构如表1所示,其中 C 为脑电导联数目即通道数, T 为采样点总数。




图1 整体网络模型

表 1 具体网络结构

层数	具体模块	通道数	卷积核大小	输出
	Input	—	—	(1, C, T)
L1	Conv2D	24	(1, 32)	(24, C, T)
	BatchNorm	—	—	(24, C, T)
	ECANet	24	—	(24, C, T)
	DW Conv2D	48	(22, 1)	(48, 1, T)
L2	BatchNorm	—	—	(48, 1, T)
	ECANet	48	—	(48, 1, T)
	PReLU	—	—	(48, 1, T)
	AvgPool	—	(1, 8)	(48, 1, T//8)
	Dropout	—	—	(48, 1, T//8)
	DW Conv2D	48	(1, 16)	(48, 1, T//8)
L3	PW Conv2D	48	(1, 1)	(48, 1, T//8)
	BatchNorm	—	—	(48, 1, T//8)
	ECANet	48	—	(48, 1, T//8)
	PReLU	—	—	(48, 1, T//8)
	AvgPool	—	(1, 8)	(48, 1, T//64)
	Dropout	—	—	(48, 1, T//64)
	Multi_TCNet1	12	4	(12, T//64)
L4	Multi_TCNet2	12	4	(12, T//64)
	Multi_TCNet3	—	—	(48, T//64)
	Cat	—	—	72 × T//64
L5	SoftMax	—	—	4

1.2 基于混合特征的多层卷积模块

本文从脑电信号的生理特征出发,将脑电信号的采集时间和不同的导联通道作为两个维度,把一次试验的脑电信号作为一个二维图像进行输入,从而提取隐藏其中的时域和空域特征。如图 1 中所示,该模块主要由以下 3 层卷积组成:第 1 层,普通二维卷积,提取脑电信号中的时域特征,并生成多个通道的特征图;第 2 层,逐通道卷积(depthwise Conv2D, DW Conv2D),在减少训练参数的同时,提取单个通道上的空域特征;第 3 层,由两个分别为逐通道和逐点的卷积(pointwise Conv2D, PW Conv2D)组成,在逐通道卷积进一步挖掘时域信息后,通过对逐点的卷积层操作,可以利用到不同通道在相同空间位置上的特征信息,对上一步生成的特征图在空间维度进行融合处理。

为了让卷积网络注意到它所需要关注的地方,研究人员提出了注意力机制的概念,主要包括通道注意力机制、空间注意力机制等。本文采用了高效通道注意力机制(efficient channel attention for deep convolutional neural networks, ECANet)^[11],它作为挤压激励网络(squeeze-and-excitation networks, SENet)的改进版,去除了原来 SENet 中的全连接层,用 1D 卷积来替换全连接层。为了

让多层卷积网络聚焦于它所最需要注意的通道,分别在 L1、L2 和 L3 中添加了 ECANet 注意力机制,根据不同通道对于分类结果的重要程度,来合理地给不同的通道分配不同的权重,从而提高卷积网络的利用率,改善运动想象脑电信号的分类效果。

除此以外,该模块选取 PReLU^[12] 激活函数来引入非线性因素,其函数公式为:

$$f(x) = \begin{cases} x, & x \geq 0 \\ ax, & x < 0 \end{cases} \quad (1)$$

PReLU 激活函数作为 ReLU 函数的一个改进型,在负数区域有一固定值的斜率,可以避免 ReLU 激活函数死掉的问题,同时也可以有效地改善模型的过拟合问题,使得网络收敛更快,通过激活函数对比实验也可以发现(实验结果在下文),PReLU 激活函数确实能够更好地提高运动想象的分类准确率。

除了以上各个部分,在每层卷积后,都会引入批归一化处理、dropout 和池化操作等,使得整体模块结构更加完整,提高模型的整体利用率。

1.3 并行多尺度时域特征提取模块

时域卷积网络(temporal convolutional network, TCN)^[13]是一种处理时间序列数据的网络结构,在脑电信号通过多层卷积网络输出混合特征信息后,可以对混合特征信号的时间序列信息进一步挖掘,主要由因果卷积、膨胀卷积、残差链接 3 部分组成。

1)因果卷积。因果卷积的主要原理在于,对于上一层某一时刻的值,只依赖于下一层相同时刻及其之前的值,与传统卷积神经网络双向结构不同的是,因果卷积是单向的结构,其输出只取决于历史信息,不存在未来信息的泄露,是一种严格的时间约束模型。

2)膨胀卷积。上述的因果卷积对时域信息的提取受限于卷积核的大小,只有通过叠加很多的卷积层,才能提取到更久远的历史信息,因此需要引入膨胀卷积,通过增大滤波器大小或膨胀因子来增大感受野。在因果卷积中引入膨胀卷积后,即是 TCN 网络中的 Dilated Causal Conv 模块。

3)残差连接。当网络层数增加之后,梯度消失、爆炸等问题也会随之而来,而残差结构使网络可以通过跨层的方式传递信息,从而解决上述问题。

综上所述,一个 TCN 模块包含两层因果膨胀卷积,每一层还加入 WeightNorm 和 Dropout 来正则化网络,并通过 ReLU 函数进行激活,然后通过一个 1 × 1 的卷积来保证输入输出的一致性,从而实现对时域信息的提取。

为了获取更好的分类效果,本文根据整体网络结构和脑电信号的特点对 TCN 网络进行修改,将 ReLU 激活函数替换成效果更好的 ELU 激活函数,将权重归一化替换成具有更好精度的批归一化处理,改进后的 TCN 模块如图 2 所示。




图2 改进后 TCN 模块结构

脑电信号在时间维度上具有很强的关联性,相邻时间段内的脑电信息并不是孤立的,因此为了更好地利用隐藏在其中的时域信息,获取不同尺度的脑电信号时域特征,根据图2改进后的TCN模块,设计了一种并行多尺度时域特征提取模块。如图1中所示,将多层卷积模块输出的混合特征分别通过两种不同时间尺度的TCN特征组合模块,一种是通过两个膨胀系数分别为1和2的TCN模块串联组成,另一种为单独的一个膨胀系数为1的TCN模块,卷积核大小均为4,通过这两种不同的组合可以实现对脑电信号不同时间尺度的时域特征提取,从而进一步挖掘混合特征中的时域信息。与此同时,为了更好地利用到混合特征中的原始时域、空域特征,将上文多层卷积处理后的特征信号作为并行处理中的一层直接输出,最后将这3路包含不同特征的脑电信号进行特征融合,输出长度为 $72 \times T // 64$ 的一维数组,进而进行四分类处理。

2 数据集及预处理

本文所采用的数据集为BCI_IV_2a公开数据集和自采数据集SCU_MI_EEG,下面对它们分别进行说明。

2.1 BCI_IV_2a 数据集

BCI_IV_2a数据集是由奥地利格拉兹大学提供的有关运动想象脑电信号的公开数据集,采集的数据来自于9位被试者,使用22个电极记录脑电数据,采样频率为250 Hz,一次运动想象试验片段持续3 s,总共有左手、右手、舌头和双脚这4种不同的运动想象任务,每一位被试者总共需要参加576次试验。在试验结束后,对采集到的脑电数据利用带通滤波器截取频率范围为0.5~100 Hz的脑电信号,并使用50 Hz的陷波滤波器来消除信号中的工频干扰。

2.2 SCU_MI_EEG 自采数据集

1) 数据采集

自采数据集SCU_MI_EEG是通过已有脑电信号采集设备,模拟实际生活中的脑电采集操作,对实验室内6位同学进行脑电数据采集。脑电采集设备包括ANT Neuro b. v.公司出品的脑电信号放大器和64导联湿电极脑电帽,以及与之配套的脑电试验范式编辑和播放软件E-Primer3、脑电记录软件eego。在每次试验过程中,为了更好地贴近于实际生活,试验周围环境为真实开放环境,被

试者状态也为正常生活状态,未做任何刻意的去干扰要求。首先为每一位被试者佩戴脑电帽,使用注射器将导电膏注入脑电帽中,从而确保脑电帽的电极与被试者头皮接触良好,然后在被试者面前的屏幕上播放事先准备好的试验范式,最后通过eego软件记录采集到的脑电信号,采集设备和实际采集现场如图3所示。




图3 自采数据集采集设备及实际采集现场

参与试验的6位同学均来自与作者相同实验室的组同学,每位被试者均为男性,年龄范围为22~26岁,每人均采集126次左手、126次右手、126次舌头和126次双脚运动想象脑电信号,在试验结束后,通过带通滤波器截取频率范围为4~40 Hz的脑电信号。

由于自采数据集试验环境和设备的限制,比如周围嘈杂的环境可能会影响被试者的注意力、被试者的头发会使得脑电帽接触不良、被试者自身好动等这些因素都会很大程度上影响最终的分类结果,然而运动想象分类如果真的应用到了实际生活中,这些因素就无法避免,从这一角度来说,自采数据集SCU_MI_EEG更加接近于真实环境,更具有实际意义。

2) 数据预处理

从上文可以得知,自采数据集SCU_MI_EEG中存在着大量无关干扰信息,直接用来分类会在很大程度上影响分类效果。因此,针对复杂场景下的脑电采集数据,本文设计了一种融合多频域脑电信号的三通道输入模块对自采数据集进行数据预处理。

相关研究表明,脑波根据频率范围的不同可划分为不同的频段,每个频段所代表的意义也是不同的,因此可以通过提取特定频段的脑波来强化与运动想象任务有关的特征信息,弱化无关信息的干扰。并且,人们在执行运动想象任务的过程中,会自发产生感觉运动节律(sensorimotor rhythm, SMR),即在进行运动想象时脑波会产生相似的变化,其中频率范围约为8~12 Hz的 α 波和13~30 Hz的 β 波变化尤为明显,脑电节律能量出现较大的波动,因此可以选择这两个频段的脑波作为运动想象分类的主要依据。当然,除了以上两种频率范围之外,频率与之接近的其余频段脑波也会或多或少地提供有用信息,所以可以适当拓宽频率范围,本文就在 α 波和 β 波的基础上又加上了与人们幻想相关、频段范围较小的 θ 波。

本文从计算机视觉RGB三通道输入得到启发,将脑电信号通过滤波模块分为3个频段之后,在空间维度变化

模块中利用维度扩充将 3 个频段作为 3 个不同通道输出,在尽可能强化与运动想象有关的信号特征同时,将不同的频域特征进行融合。如图 4 所示,最初输入的脑电信号是以单通道的形式存在的,首先根据二维脑电信号的大小来确定所需的三维空间,然后根据 θ 波、 α 波和 β 波的频率范围选取了 3 个截止频率分别为 4~7 Hz、8~13 Hz、13~32 Hz 的巴特沃斯带通滤波器,将原始输入的脑电信号分别通过以上 3 个滤波器后输出 3 种不同频率范围的脑电信号,最后将这 3 种处理后的脑电信号按照频率大小顺序放置在事先准备的三维空间内,实现从单通道到三通道的转换,从而尽可能地利用到与运动想象任务相关的脑电信号,提高复杂环境下的分类准确率。

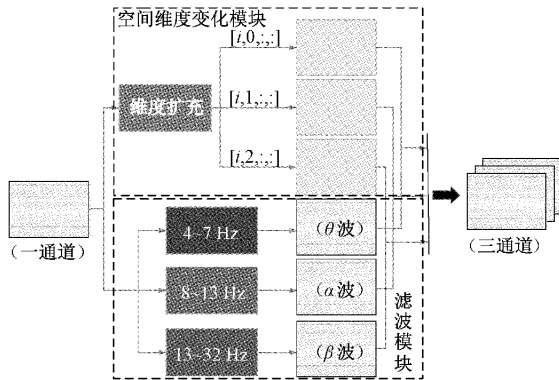


图 4 融合多频域脑电信号的三通道输入模块结构框图

3 实验结果及分析

3.1 实验环境及评估标准

实验环境配置如下: Linux 操作系统, GPU 为 NVIDIA GeForce RTX 2080Ti、显存为 11 GB, 软件平台为 PyCharm 2021. 3. 3, 编程语言为 Python3. 8。为了使实验结果更加具有说服力、减少实验误差以及充分利用数据集, 本文使用十折交叉验证作为模型验证方式。

在评价指标方面, 采用单个被试分类准确率 *Accuracy* 和平均分类准确率 *Avg*、整体被试分类结果标准差 *Std* 作为评价标准。

$$Accuracy = \frac{N_{right}}{N_{total}} \times 100\% \quad (2)$$

$$Avg = \frac{1}{N} \times \sum_{i=1}^N Accuracy_i \quad (3)$$

$$Std = \sqrt{\frac{1}{N} \times \sum_{i=1}^N |Accuracy_i - AVG|^2} \quad (4)$$

式中: N_{right} 为分类正确的样本个数, N_{total} 为参与测试的全部样本个数, N 为被试者的个数。

3.2 实验结果及分析

1) BCI_IV_2a 数据集上的实验

(1) 对比实验

为了更好地对比 MTACNet 的分类效果, 本文在查阅

大量文献资料和研究成果后, 选取了近年来一些分类效果不错或者非常经典的模型, 对比了多位研究人员提出的分类模型在公开数据集 BCI_IV_2a 上的分类结果, 如表 2 所示。EEGNet 利用卷积网络构建分类模型, 在不同范式上均取得了不错的效果; 文献[14]在 EEGNet 基础上直接添加 TCN 模块, 未进行不同尺度的时域信息特征融合; 文献[15]将滤波器组共空间模式 (filter bank common spatial pattern, FBCSP) 与 DNN 网络相结合, 提取特征后进行分类处理; 文献[16]利用迁移学习得到最佳迁移层后, 与卷积神经网络融合; 文献[17]把一种判断特征学习策略应用到运动想象分类中, 以此来提高特征的判断能力; 文献[18]改进了共空域模式特征提取方法, 加入了对数带通功率特征, 将所有任务进行二分类之后取平均值; EEG-Transformer 利用注意力转移策略有效地利用了空间和时间特征, 取得了不错的分类效果。从表 2 中可以看出, 虽然 EEG-Transformer 在个别被试者上的分类结果更好, 但对于全部被试者的适配性不好, 在被试者 5、被试者 6 上的分类准确度出现大幅度的下降, 而 MTACNet 的整体平均分类准确率与前者相比提高了 3.56%, 取得了最高的平均分类准确率, 并且通过对 9 位被试者的分类准确率进行标准差计算, MTACNet 实验结果的标准差也远低于其他分类模型, 从这也可以看出 MTACNet 对于不同被试者的泛化性更好, 更加适配于不同的被试者。这也说明, MTACNet 在提高分类准确率的同时, 也保证了良好的泛化性能。

(2) 激活函数的选取

为了比较不同激活函数的分类效果, 本文将未添加注意力机制、激活函数和并行多尺度时域特征提取模块的多层卷积模块定义为基本多层卷积 (basic multilayer convolution, BMLC) 模块, 在相同实验条件和训练策略下, 对 BMLC 模块分别采用 ReLU、ELU、SELU 和 PReLU 这 4 种激活函数, 在 BCI_IV_2a 上进行训练和分类测试, 对比实验结果如表 3 所示。

从表 3 的实验结果中可以看出, 当 BMLC 模块采用 PReLU 激活函数时, 9 位被试者中有 4 位取得了最好的分类效果, 平均准确率也是最高的, 虽然标准差不是最低的, 但从每个被试的分类准确率来看, 并未出现某一被试者分类准确率大幅度下降的现象, 取得了较好的泛化性, 说明 PReLU 在一定程度上可以改善 BMLC 模块的过拟合问题, 提高分类性能。

(3) 消融实验

为了验证注意力机制和并行多尺度时域特征提取模块的作用, 在相同实验条件和训练策略下, 当 BMLC 模块选取 PReLU 激活函数后, 将 BMLC 模块、BMLC+注意力机制模块 (表 4 中用 Att 代替)、BMLC+注意力机制模块+并行多尺度时域特征提取模块 (即 MTACNet) 在 BCI_IV_2a 上进行训练和分类测试, 对比实验结果如表 4 所示。

表2 不同分类模型在BCI_IV_2a数据集上的分类结果对比

被试者	Accuracy/%							
	EEGNet	EEG-TCNet (Fixed) ^[14]	FBCSP-DNN ^[15]	TMCNN ^[16]	DFL ^[17]	CSP-FBLBP ^[18]	EEG-Transformer	MTACNet
S01	79.51	85.77	87.70	91.64	91.31	—	91.67	89.89
S02	56.25	65.02	68.21	69.82	71.62	—	71.67	67.65
S03	88.89	94.51	85.59	91.00	92.32	—	95.00	95.02
S04	80.90	64.91	66.71	76.54	78.38	—	78.33	77.76
S05	57.29	75.36	67.00	72.68	80.10	—	61.67	87.36
S06	53.82	61.40	67.40	59.85	61.62	—	66.67	76.98
S07	91.67	87.36	91.00	92.94	92.63	—	96.67	94.53
S08	81.25	83.76	83.80	81.82	90.30	—	93.33	92.53
S09	79.17	78.03	87.60	82.35	78.38	—	88.33	93.61
Avg	74.31	77.35	78.33	80.85	81.85	81.97	82.59	86.15
Std	13.71	10.92	10.01	10.58	10.15	12.96	12.52	9.17

表3 不同激活函数的分类结果对比

被试者	Accuracy/%			
	ReLU	ELU	SELU	PReLU
S01	85.37	84.50	81.79	86.27
S02	61.32	66.56	70.16	67.45
S03	95.21	94.66	87.29	93.53
S04	72.04	71.02	72.45	72.65
S05	80.30	82.53	82.17	82.34
S06	69.33	67.50	66.18	70.11
S07	85.96	80.51	81.40	81.03
S08	88.60	84.50	80.20	88.78
S09	91.02	90.82	87.63	90.61
Avg	81.02	80.29	78.81	81.42
Std	10.58	9.40	7.10	8.88

表4 添加不同模块后的分类结果对比

被试者	Accuracy/%		
	BMLC	BMLC+Att	MTACNet
S01	86.27	86.99	89.89
S02	67.45	73.06	67.65
S03	93.53	95.39	95.02
S04	72.65	74.90	77.76
S05	82.34	83.47	87.36
S06	70.11	70.77	76.98
S07	81.03	83.79	94.53
S08	88.78	90.08	92.53
S09	90.61	91.20	93.61
Avg	81.42	83.29	86.15
Std	8.88	8.17	9.17

从表4的实验结果中可以看出,当BMLC模块嵌入ECANet注意力模块之后,对每一个卷积通道进行合理地资源分配,平均分类准确率提高了1.87%,标准差下降了0.71%,9名被试者的分类准确率均得到了提高,说明ECANet注意力模块通过对不同通道进行合理地资源分配,可以改善运动想象脑电的分类效果。在BMLC模块嵌入ECANet的基础上,加入并行多尺度时域特征提取模块后,得益于并行TCN模块能够在保留原有混合特征的基础上进一步挖掘不同尺度的时域特征,平均分类准确率提高了2.86%,9位被试者中有7位的分类准确率得到了提高,对于标准差而言,由于各别被试(比如被试7)的分类准确率得到大幅度提升,导致标准差偏高,从这个角度来看,虽然标准差更高,但相比于添加并行多尺度时域特征提取模块之前,MTACNet更适用于不同的被试。

2) SCU_MI_EEG数据集上的实验

在相同实验条件和训练策略下,为了进一步验证MTACNet的分类性能,选取对比模型里在BCI_IV_2a数据集上分类效果最好的EEG-Transformer模型和MTACNet在自采数据集SCU_MI_EEG上进行4种运动想象任务的训练和分类测试。并且,为了验证融合多频域脑电信号的多通道输入模块在复杂环境下的有效性,在自采数据集经过该模块进行预处理后,将MTACNet进行运动想象四分类实验,与预处理前的结果进行对比,实验结果如表5所示。

从表5中可以看出,相比于EEG-Transformer的分类结果,MTACNet的分类结果中有5位被试者取得了更好的分类效果,其中被试者3、被试者5和被试者6的分类准确率分别提高了17.62%、7.56%和9.65%,整体平均分类准确率提高了6.34%,标准差也略有下降,进一步说明了MTACNet具有更好的分类性能,同时验证了MTACNet具有更强的泛化性。

表 5 SCU_MI_EEG 上的分类结果对比

被试者	Accuracy/%		
	EEG-Transformer	MTACNet	MTACNet (预处理后)
A01	78.57	75.66	82.60
A02	54.20	55.31	55.32
A03	61.90	79.52	84.05
A04	85.71	90.71	93.10
A05	87.50	95.06	97.52
A06	56.67	66.32	69.76
Avg	70.76	77.10	80.39
Std	13.64	13.58	14.22

由于 SCU_MI_EEG 数据集本身试验环境的复杂性,与 BCI_IV_2a 的结果相对比,MTACNet 的分类效果有所下降,于是对 SCU_MI_EEG 进行数据预处理。相比于处理前的分类结果,预处理后的实验结果中,所有被试者的分类准确率都得到了提高,其中被试者 1、被试者 3 和被试者 6 的分类准确率分别提高了 6.94%、4.53% 和 3.44%,整体平均分类准确率提高了 3.29%,标准差变化不大,说明本文对于 SCU_MI_EEG 数据集的预处理方法能够有效降低复杂环境和无干扰因素对分类结果的影响,提高整体被试的分类准确率,对实际生活中运动想象脑电信号的提取和分类具有重要意义。

4 结 论

本文构建了一种基于混合特征和并行多尺度 TCN 模块的多层卷积网络 MTACNet,主要由基于混合特征的多层卷积模块和并行多尺度时域特征提取模块组成,在公开数据集 BCI_IV_2a 和自采数据集 SCU_MI_EEG 上进行实验,取得了较为不错的分类效果。并且,针对复杂环境下的自采数据集 SCU_MI_EEG,设计了一种融合多频域脑电信号进行三通道输入的预处理方法来改善分类效果。在未来的工作中,希望能够进一步提高实际生活中运动想象信号分类准确率,将运动想象分类技术落地,应用到医疗、军用等各个领域,并且希望能够将 MTACNet 应用于脑电信号其他范式上,在不同范式上都能取得很好的分类效果。

参考文献

[1] NOVI Q, GUAN C, DAT T H, et al. Sub-band common spatial pattern (SBCSP) for brain-computer interface [C]. 2007 3rd International IEEE/EMBS Conference on Neural Engineering, IEEE, 2007: 204-207.

[2] BARACHANT A, BONNET S, CONGEDO M, et al. Multiclass brain-computer interface classification by riemannian geometry[J]. IEEE Transactions on

Biomedical Engineering, 2011, 59(4): 920-928.

[3] BAIG M Z, ASLAM N, SHUM H P H, et al. Differential evolution algorithm as a tool for optimal feature subset selection in motor imagery EEG[J]. Expert Systems with Applications, 2017, 90: 184-195.

[4] AI Q, CHEN A, CHEN K, et al. Feature extraction of four-class motor imagery EEG signals based on functional brain network [J]. Journal of Neural Engineering, 2019, 16(2): 1-15.

[5] WANG P, JIANG A, LIU X, et al. LSTM-based EEG classification in motor imagery tasks[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2018, 26(11): 2086-2095.

[6] 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): 1-18.

[7] ZHANG R, ZONG Q, DOU L, et al. A novel hybrid deep learning scheme for four-class motor imagery classification [J]. Journal of Neural Engineering, 2019, 16(6): 1-12.

[8] LI M A, HAN J F, DUAN L J. A novel MI-EEG imaging with the location information of electrodes[J]. IEEE Access, 2019, 8: 3197-3211.

[9] HOU Y, ZHOU L, JIA S, et al. A novel approach of decoding EEG four-class motor imagery tasks via scout ESI and CNN[J]. Journal of Neural Engineering, 2020, 17(1): 1-16.

[10] SONG Y, JIA X, YANG L, et al. Transformer-based spatial-temporal feature learning for EEG decoding[DB/OL]. ArXiv, 2021. <https://arxiv.org/abs/2106.11170>.

[11] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]. CVF Conference on Computer Vision and Pattern Recognition Seattle, IEEE, 2020: 11531-11539.

[12] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification[C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1026-1034.

[13] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [DB/OL]. ArXiv, 2018. <https://arxiv.org/abs/1803.01271>.

[14] 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), IEEE, 2020: 2958-2965.
- [15] SHUAIBU Z, QI L. Optimized DNN classification framework based on filter bank common spatial pattern(FBCSP) for motor-imagery-based BCI[J]. International Journal of Computer Applications, 2020, 175(15): 16-25.
- [16] 周强,田鹏飞. 基于迁移学习多层次融合的运动想象 EEG 辨识算法[J]. 电子测量与仪器学报, 2021, 35(12):174-181.
- [17] YANG L, SONG Y, MA K, et al. Motor imagery EEG decoding method based on a discriminative feature learning strategy[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 368-379.
- [18] 莫云. 基于 CSP 变换和滤波器组的对数带通功率特征提取方法[J]. 电子测量技术, 2021, 44(10):33-38.

作者简介

朱康, 硕士研究生, 主要研究方向为脑电信号处理与识别。

E-mail: 885651975@qq.com

吴晓红, 副教授, 硕士生导师, 主要研究方向为图像处理与模式识别、计算机视觉、无线通信等。

E-mail: wxh@scu.edu.cn

郭远哲, 硕士研究生, 主要研究方向为脑电信号处理与识别。

E-mail: 1203769368@qq.com

杜立峰, 讲师, 主要研究方向为脑机接口。

E-mail: dlf_111@126.com

何小海(通信作者), 教授, 博士生导师, 主要研究方向为图像处理、模式识别、计算机视觉、图像通信和软件工程等。

E-mail: hxh@scu.edu.cn