

DOI: 10.11830/ISSN.1000-5013.202306016



# 应用多尺度混合卷积网络的 脑电信号特征提取与识别

王蒙昊<sup>1,2</sup>, 方慧娟<sup>1,2</sup>, 龚亨翔<sup>1,2</sup>, 罗继亮<sup>1,2</sup>

(1. 华侨大学 信息科学与工程学院, 福建 厦门 361021;  
2. 华侨大学 福建省电机控制与系统优化调度工程技术研究中心, 福建 厦门 361021)

**摘要:** 为了解决脑电信号特征提取能力不足导致的分类准确率不高的问题, 提出一种全新的混合神经网络模型(EEG-MSTNet 模型), 实现脑电信号的时-频-空域特征提取和识别. 首先, EEG-MSTNet 模型采用一种适合脑电信号特点的多尺度卷积, 提取 4 组不同大小卷积核的特征, 并拼接在一起, 从而增强对原始脑电信号的时频域提取能力. 其次, 通过通道注意力机制进一步提取信号的空间特征和高维时域特征, 最终用于脑电信号识别. EEG-MSTNet 模型在 BCI Competition IV Dataset 2a 数据集上进行测试, 结果表明: EEG-MSTNet 模型的每个模块都对分类准确率的提升做出了贡献, 最高分类准确率为 95.83%, 平均准确率为 83.52%, 明显优于其他模型.

**关键词:** 卷积神经网络; 通道注意力机制; 脑电识别; 特征提取

**中图分类号:** TP 391 **文献标志码:** A **文章编号:** 1000-5013(2023)05-0628-08

## Electro-Encephalogram Feature Extraction and Recognition Using Multi-Scale Hybrid Neural Network

WANG Menghao<sup>1,2</sup>, FANG Huijuan<sup>1,2</sup>,  
GONG Hengxiang<sup>1,2</sup>, LUO Jiliang<sup>1,2</sup>

(1. College of Information Science and Engineering, Huaqiao University, Xiamen 361021, China;  
2. Fujian Engineering Technology Research Center of Motor Control and System Optimal Schedule,  
Huaqiao University, Xiamen 361021, China)

**Abstract:** In order to solve of low classification accuracy problem caused by insufficient feature extraction ability of electro-encephalogram signals, a novel hybrid neural network model (EEG-MSTNet model) is proposed to achieve time-frequency-spatial domain feature extraction and recognition of EEG signals. Firstly, EEG MSTNet model adopts a multi-scale convolution that is suitable for the characteristics of EEG signals, four sets of features of different sizes convolutional kernels are extracted, and they are concatenated together to enhance the time-frequency domain extraction ability of the original EEG signals. Secondly, the spatial features and high-dimensional temporal domain features of the signals are further extracted through the channel attention mechanism, and ultimately used for EEG signals recognition. The EEG-MSTNet model is tested on the BCI Competition IV Dataset 2a dataset, the results show that each module of the EEG-MSTNet model contri-

收稿日期: 2023-06-16

通信作者: 方慧娟(1979-), 女, 讲师, 博士, 主要从事脑机接口、脑电数据分析、Petri 网、智能控制和机器人的研究. E-mail: huijuan.fang@163.com.

基金项目: 国家自然科学基金资助项目(61973130)

to the improvement of classification accuracy, with a maximum classification accuracy of 95.83% and an average accuracy of 83.52%, which is significantly better than that of the other models.

**Keywords:** convolutional neural network; channel attention mechanism; EEG recognition; feature extraction

脑机接口(BCI)通过解码人类思考时的脑神经活动信息,建立大脑与外界之间的直接信息传输通道<sup>[1]</sup>. BCI 是一项有潜力改变世界的尖端技术,具有十分广泛的应用. 在医疗方面,BCI 可以帮助中风患者、身体残疾的人<sup>[2]</sup>;在非医疗方面,BCI 可以控制小车、机器人<sup>[3]</sup>. 由于实现 BCI 技术的关键在于脑电信号(EEG)的高识别率,因此,BCI 研究的首要任务是脑电信号特征的提取和识别<sup>[4]</sup>.

近年来,对脑电信号特征的有效提取以及分类的研究也越来越深入. 研究主要分为机器传统学习方法和机器深度学习方法. 机器传统学习方法依赖特定的领域知识,通常需要使用手工特征提取器(通道滤波共空间(FBCSP)<sup>[5]</sup>、小波变换<sup>[6]</sup>和快速傅里叶变换等),将提取的特征输入到鲁棒性较高的线性判别器(LDA)或者支持向量机(SVM)中进行分类.

机器深度学习方法不但具有比传统方法更强大的拟合能力,还可以自动提取脑电信号特征. Lawhern 等<sup>[7]</sup>提出了 EEGNet 模型,使用卷积神经网络(CNN)模块<sup>[8]</sup>提取空间和时域特征,提取能力更强,鲁棒性更好. Ingolfsson 等<sup>[9]</sup>提出了 EEG-TCNet 模型,将一种专门为时间序列设计的卷积神经网络 TCNet<sup>[10]</sup>模块与 CNN 模块相结合,增强模型的时域提取能力,达到更好的效果. Mane 等<sup>[11]</sup>提出 FBCNet 模型,使用多种不同截止频率的低滤波器提取不同维度的信息,以增强模型的频域提取能力. Song 等<sup>[12]</sup>提出 EEG-Conformer 模型,将 CNN 模块与通道注意力机制(SE)模块结合,增强模型空域与时域特征提取能力. 此外,文献[13-15]还提出通讯信息进程(CSP)模块与 CNN 模块的结合、长短期记忆(LSTM)模块与 CNN 模块的结合的模型.

以上研究增强了时-频-空域的特征提取能力,主要围绕 CNN+其他模块. 考虑到脑电信号的个体和时间差异性,脑电信号相关的信息会出现在频谱的多种波段上,每层仅使用单一大小的卷积核提取特征,会丢失一些有用的特征. 如果能使用多种不同大小的卷积核,并引入新颖的特征提取架构,有望进一步提高脑电信号特征提取和识别能力. 本文应用多尺度混合卷积网络的脑电信号特征提取与识别.

# 1 EEG-MSTNet 模型

## 1.1 总体架构

EEG-MSTNet 模型主要由 3 个模块构成:多尺度卷积(MCNN)模块、SE 模块和时域残差(TRN)模块. EEG-MSTNet 模型总体架构,如图 1 所示. 图 1 中:BN 为批正则化层;ELU 为指数线性单元激活层;Pool 为池化层;Lambda 为函数;Dense 为全连接操作.




图 1 EEG-MSTNet 模型总体架构  
Fig. 1 Overall structure of EEG-MSTNet model

首先,通过 4 组并行的卷积模块(即多尺度卷积 1)将 EEG 信号从低纬度的信号编码到高纬度的信号,并将拼接到一起的信号送入下一个模块. 其次,通过核的大小与通道数相关的深度卷积沿通道方向卷积高维信号. 最后,再用 4 组可分离的 2D 卷积(即多尺度卷积 2)进一步提取特征.

输出的时间序列特征包含时-频-空 3 个维度丰富的信息,将其送入到 SE 模块,突出时间序列中最重要的通道信息,提升模型学习效率同时降低特征冗余. 通过 TRN 模块,提取出更具有判别性的高维时域特征,对信号进行分类.

整体网络的参数设置,如表 1 所示. 表 1 中:大部分参数是根据实验效果设定的最优参数;小部分参数(如多尺度卷积核大小)结合了对频率域的分析 and 实验效果而设置的参数;Softmax 为函数.

表 1 EEG-MSTNet 模型的参数  
Tab. 1 Parameters of EEG-MSTNet model

模块	网络层/操作	参数设置	参数量	输出尺寸
输入	输入	—	0	(1,22,1 125)
	维度转换	—	0	(1 125,22,1)
多尺度卷积 1	卷积	卷积核:8×1,16×1,32×1,64×1, 滤波器个数:16	1 024+896	(1 125,22,16)
	BN	—	64	(1 125,22,16)
	空间卷积	卷积核:1×22 ,个数:32	704	(1 125,1,32)
	BN,ELU,Pool	平均池化:8×1	128	(140,1,32)
多尺度卷积 2	可分离卷积	卷积核:2×1,40×1,80×1,16×1, 卷积核个数:32	1 024+896	(140,1,32)
	BN,ELU,Pool	平均池化:8×1	128	(17,1,32)
	压缩 Pool	平均池化:17×1	0	(1,1,32)
SE	激活 Dense	—	132	(1,1,4)
	激活 Dense	—	160	(1,1,32)
	相乘	—	0	(17,1,32)
	维度变换	—	0	(17,32)
两层 TRN	空洞时域卷积	卷积核:4×1,卷积核个数:32	4 128	(17,32)
	BN,ELU	—	128	(17,32)
	空洞时域卷积	—	4 128	(17,32)
	BN,ELU	—	128	(17,32)
	相加	—	0	(17,32)
	ELU	—	0	(17,32)
分类器	Lambda	取最后一个时间特征	0	(32)
	Dense	—	132	(4)
	激活层 Softmax	—	0	(4)

1.2 数据预处理和输入特征信息

原始的 MI-EEG 模型信号没有经过任何预处理,将其直接输入到 EEG-MSTNet 模型中. 根据标签标的每个开始的时间点,将 session 数据切分成多个 trial 数据. 输入模型的 trial 数据, $x_i \in \mathbf{R}^{C \times T}$ ,其中, $C$  为输入脑电信号的通道数; $T=t \times f$  代表了每个 EEG 信号的采样点个数, $t$  为运动想象切分的持续时间, $f$  代表采样率. 基于运动想象分类任务可以被定义为建立  $x$  和相应类别  $y$  之间的映射,模型的目标是对训练集  $\{x,y\}$  的学习,尽可能拟合该映射. 对于 BCI-IV-2a 数据集,每个 trial 数据取 1.5~6.0 s 的数据,采样频率为 250 Hz,故采样点  $C$  为 22,18 个 session 共切分成 5 184 个 trial 数据.

1.3 卷积神经网络模块

CNN 模块是一类使用卷积操作且具有深度结构的神经网络的统称,最早应用于计算机视觉,解决了当时图像分类难的问题,现在也应用于多种领域,其中,卷积成为模型提取特征基础结构. 1 维卷积操作对脑电信号进行提取,卷积操作把卷积核与输入信号按位相乘并求和. 这种操作可考虑周围点对当前点的影响,从而提取脑电信号的局部特征,卷积后的输出特征为

$$h(t_0) = x(t_0) \times w(m) = \sum_{m=t_0}^{t_0+K} x(t_0) \times w(m-t_0).$$

(1)

式(1)中: $x$  为信号的输入特征; $w$  为卷积核的权值; $t_0$  为信号当前时刻; $K$  为卷积核的大小.

将 1 维卷积操作拓展为矩阵操作,即

$$h_r^j = x_r^j \times w_r^j + b_r^j.$$

(2)

式(2)中: $r$  为第  $r$  层卷积层; $j$  为第  $j$  个卷积核; $w_r^j, b_r^j$  为卷积层的权值和偏置值.

CNN 模块,如图 2 所示. 图 2 中:Spatial Conv 为空间卷积;Ave Pool 是平均池化;Separable Conv 为可分离卷积. CNN 模块主要包括卷积层、池化层、激活层,以及全连接层. 卷积层的层与层之间通过局部连接、权值共享,大幅减少参数量的同时,也提升了模型的鲁棒性. 随着对机器学习研究的不断深入,

现阶段的 CNN 模块增加了批正则化层和丢弃层加快模型的训练并减少过拟合,使用 ELU 激活层替代线性整流函数(RELU),使模型取得更好的训练效果.

端到端的 CNN 模块作为基线模型可以自动提取脑电信号的特征,提取分为 3 个部分. 1) 使用  $F_1$  个大小为  $(1, 64)$  的卷积,主要提取频谱特征; 2) 使用  $D$  个大小为  $(C, 1)$  的深度卷积,主要提取通道特征; 3) 使用  $F_1 \times D$  个大小为  $(1, 16)$  的卷积,主要提取时域特征. 基线模型在第 2, 3 部分使用大小为  $(1, 8)$  的平均池化减小的维度、ELU 激活层; 在第 1, 3 部分使用丢弃层; 在每个部分都使用批正则化层.

1.4 多尺度卷积模块

MCNN 包含了 4 组不同大小的卷积核,对信号提取特征,大尺度卷积核可以捕获低频率的整体特征,小尺度卷积核可以捕获高频率的局部特征,通过对局部和整体特征的整理,可以有效地增强卷积的特征提取能力,即

$$h_r^j = \frac{1}{N} \sum_{i=1}^N h_{i,r}^j. \tag{3}$$

式(3)中: $i$  为卷积第  $i$  的的分支; $N$  为分支数,  $N=4$ .

卷积神经网络第 1, 3 层使用多尺度卷积,增强模型对频域和时域信息的提取能力. 多尺度卷积神经网络总体架构,如图 3 所示. 图 3 中:Average 表示取平均值. 多尺度卷积 1 分别使用 4 组大小不同的卷积,其中,64 取 1/4 的采样率,可以提取 4 Hz 以上的频谱特征. 4 组卷积可以分别提取 4, 8, 16, 32 Hz 的频谱信息,近似对应脑电的  $\theta, \alpha, \beta$  波. 由于卷积神经网络第 2 层后跟着一个  $(1, 8)$  的平均池化,信号降采样到 32 Hz,故多尺度卷积 2 使用 4 组大小不同的卷积(图 3(b)),对  $(500.0, 250.0, 125.0, 62.5 \text{ ms})$  信息进行解码,增强模型对不同时间信息特征的提取能力.




图 2 卷积神经网络模块

Fig. 2 Module of convolutional neural network

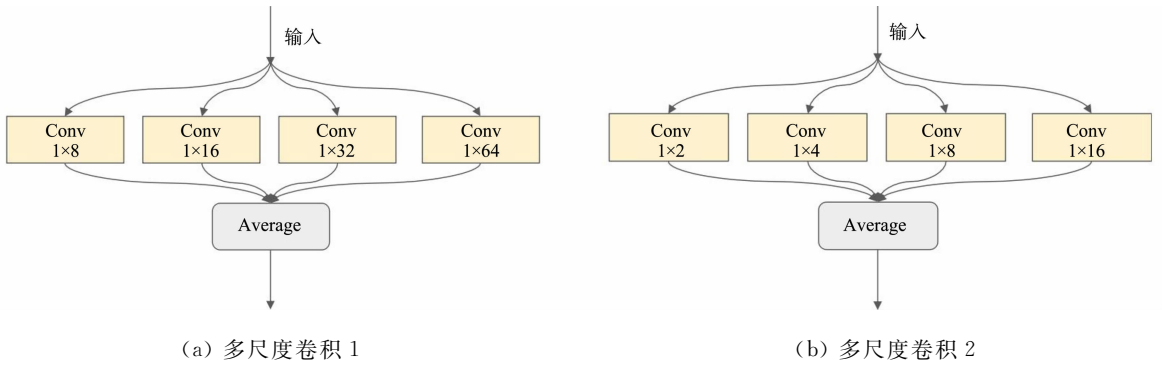


图 3 多尺度卷积神经网络模型总体架构

Fig. 3 Overall structure of multi-scale convolutional neural network model

1.5 通道注意力机制模块

SE 模块启发于卷积图像领域 2D SE 模块<sup>[16-17]</sup>,能自适应地关注重要的通道. SE 模块有两个优势: 1) 经过 MCNN 模块输出的特征存在一定的冗余,SE 模块可以除去非必要的特征信息; 2) 在少量增加参数量和计算量情况下,增加模型的特征提取能力,关注更加重要的特征. SE 模块主要包括压缩和激发两个部分. 压缩部分主要解决通道相关性的问题,通过对 MCNN 模块提取的高维时序特征  $U$  进行全局池化处理,将特征的时域维度  $T$  进行压缩,只留下通道维度  $m$ . 第  $q$  个通道特征  $m_q$  表达式为

$$m_q = F_a(U_q) = \frac{1}{L} \sum_{n=1}^L U_q(n). \tag{4}$$

式(4)中: $U_q$  为第  $q$  个通道维度的时序特征; $L$  为时序特征在时域维度的长度;  $F_a$  表示取均值函数.

通过两层全连接层(先缩小再还原至原通道数  $C$ )完成激活,再通过权重  $W$  生成所要的权重信息,其中, $W$  是通过学习得到的,第  $q$  个通道权重特征  $S_q$  表达式为

$$S_q = F_{\text{ex}}(m_q, \mathbf{W}) = \delta(\mathbf{W}_2(\mathbf{W}_1 m_q)).$$

(5)

式(5)中:  $\mathbf{W}_1$  和  $\mathbf{W}_2$  分别为两层全连接的权值矩阵;  $\delta$  为 sigmoid 激活函数;  $F_{\text{ex}}$  为激发函数.

将通道权重与原特征层进行加权处理,得到突出重要通道信息的时间序列,即

$$f_q = F_{\text{scale}}(U_q, S_q) = U_q \times S_q.$$

(6)

式(6)中:  $F_{\text{scale}}$  表示相乘函数.

1.6 时域残差模块

TRN 模块加深卷积的层数,Chen 等<sup>[18]</sup>发现加深网络的层数到一定数量之后,准确率反而下降了.残差结构通过添加网络直连结构,可以改善网络层数增加带来的梯度消失和网络退化问题,其表达式为

$$y = F(x) + x.$$

(7)

式(7)中:  $x$  为输入特征,  $F(x)$  表示对  $x$  进行卷积操作的输出.

时域残差模块与残差模块有两点不同:1) 时域残差模块采用因果卷积,阻止任何之前信息进入到未来,这样输出时间  $t$  只有  $t$  及之前的时刻;2) 时域残差模块采用空洞卷积,感受野指数型地增加.时域残差网络架构,如图 4 所示.图 4 中: Dilated Causal Conv 为空洞时域卷积; Optional 表示可选.

感受野计算公式为

$$\text{RFS} = 1 + 2(K_T - 1)(2^a - 1).$$

(8)

式(8)中: RFS 为感受野;  $a$  为时域残差块的个数;  $K_T$  卷积核大小.

MSTNet 模型使用 2 个时域残差块,每个残差块由 32 个卷积核大小为 4 的空洞卷积构成,故经时域残差模块输出的特征的一个点可以感受 19 个元素.将 SE 模块输出的维度为 (32, 17) 的时间序列输入到时域残差模块后,最后一个点已经感受到所有时间维度的信息,故只需将最后一个维度为 (32, 1) 的高维时间特征送入到分类器(使用 Softmax)的全连接层,对信号进行分类.




图 4 时域残差网络架构

Fig. 4 Network architecture of temporal residual convolutional

2 实验结果与分析

2.1 实验数据集

采用 BCI Competition IV-2a 公开数据集<sup>[19]</sup>训练和评估 EEG-MSTNet 模型,它的数据量有限且数据包含在伪迹之中,因此,对脑电解码来说是一个十分具有挑战的任务.数据共有 5 184 个 trials,受试者有 9 名(每名受试者在不同天做了两个 session,每个 session 有 6 个 runs,每个 runs 有 48 个 trials,左手 12 个,右手 12 个,双脚 12 个,舌头 12 个),运动想象 3~6 s(从 6 s 十字架消失后,开始短暂休息).EEG 通道有 22 个电极,EKG 通道有 3 个电极,电极频率为 250 Hz,带通滤波频率为 0.5~100.0 Hz.session1 为训练集(有标签),session2 为测试集.

2.2 实验设置

EEG-MSTNet 模型由 GPU 显卡(NVIDIA RTX-3080Ti 12 GB)进行训练和测试,采用 Tensor-Flow 框架.训练配置如下:权重初始化均采用 Glorot 归一;优化方法采用 Adam;学习频率设置为 0.001;批大小为 64;训练采用分类交叉熵损失函数,对每名受试者分别训练 10 次,尽可能保证所有模型达到最好的泛化效果,次数设置为 1 000,采用提前停止技术,容忍度设为 50(也就是当模型连续经过 50 次训练后,准确率没有继续提升,停止训练);训练集和测试集划分比例为 1 : 1.

2.3 评估方法

采用准确率  $P_a$  和 Kappa 系数  $\zeta_k$  更准确客观地评估模型.  $P_a$  的计算式为

$$P_a = \frac{\sum_{i=1}^n T_i / I_i}{n}.$$

(9)

式(9)中:  $T_i$  为第  $i$  类中预测正确的样本数;  $I_i$  为第  $i$  类的样本数;  $n$  为类别的数量.

$\zeta_k$  的计算式为

$$\zeta_k = \frac{1}{n} \sum_{a=1}^n \frac{P_a - P_e}{1 - P_e}.$$

(10)

式(10)中: $n$  是类别的数量; $P_e$  是预测与实际一致性的概率,当  $P_e$  为  $0.8 \sim 1.0$  时,概率几乎完全一致,当  $P_e$  为  $0.6 \sim 0.8$  时,概率高度一致.

2.4 消融实验

为了探究 EEG-MSTNet 模型的有效性,采用消融实验评估 EEG-MSTNet 模型中每个模块的效用. EEG-MSTNet 模型中每个模块对性能的贡献,如表 2 所示. 表 2 中: $t$  为训练时间.

由表 2 可知;None 模块(卷积神经网络,基准模块)全面考虑时域、频域和空域信息,平均准确率为 80.59%,与其相比,MCNN 模块的准确率提升了 1.24%. TRN 模块准确率提升 1.23%,SE 模块准确率几乎没有提升;两个模块及以上准确率均获得较大的提升,SE+TRN 模块的准确率为 82.56%,准确率比基准模块提升 1.97%,说明 SE 模块要连接其他模块才能发挥 SE 模块的效果;MCNN+SE+TRN 模块比基准模块准确率提升 2.94%,其最高分类准确率为 95.83%,平均准确率为 83.52%.

由表 2 还可知;相比于基准模型,MCNN 模块增加 1 792 的参数数量,SE 模块增加 295 的参数数量,TRN 模块将增加 16 056 的参数数量,这是由于高维特征图的数量是低维特征图的 32 倍,导致卷积层的参数量剧增,可以改用可分离卷积,大幅降低参数量. 由于采用了提前停止技术,每个模块训练轮数不一致,采用训练总时间除以训练轮数作为训练时间,可以看到 SE 模块对训练时间的影响较小,而 MCNN 模块对训练时间的影响较大,MCNN+SE+TRN 模块的训练时间为 0.240 s,较基准模块需要多消耗 0.110 s,处于可接受的范围.

2.5 对比实验

EEG-MSTNet 模型与其他相似模型的平均准确率比较,如表 3 所示. 表 3 中: $\overline{P_a}$  为平均受试准确率; $\sigma$  为标准差. 由表 3 可知:EEG-MSTNet 模型平均准确率为 83.53%,在大部分受试者中的表现优于其他模型,相对 EEGNet 模型平均准确率提高了 5.92%;EEG-MSTNet 模型在受试者中实现了最小的标准差(9.1%),表明准确性更加稳定.

表 3 EEG-MSTNet 模型与其他相似模型的平均准确率比较

Tab. 3 Comparison of average accuracy of EEG-MSTNet modole with other similar modoles

受试者	$P_a$			
	EEG-MSTNet 模型	EEG-Conformer 模型 <sup>[12]</sup>	TCNFusion 模型 <sup>[20]</sup>	EEGNet 模型 <sup>[7]</sup>
1	86.81	88.19	85.42	82.15
2	68.40	61.46	66.32	62.85
3	95.83	93.40	92.01	93.40
4	79.86	78.13	70.49	69.10
5	82.29	52.08	78.82	76.04
6	71.53	65.28	64.24	61.46
7	92.71	92.36	90.62	85.62
8	87.50	88.19	85.76	82.81
9	86.81	88.89	84.03	85.07
$\overline{P_a}$	83.53	78.66	79.75	77.61
$\sigma$	9.1	15.3	10.4	11.0

EEG-MSTNet 模型与近期研究模型的性能比较,如表 4 所示. 由表 4 可知:采用 3 种模块的 EEG-MSTNet 混合神经网络模型无论是在  $P_a$  还是  $\zeta_k$  均优于近期研究的模型.



表 4 EEG-MSTNet 模型与近期研究模型的性能比较

Tab. 4 Performance comparison of classification for the proposed model and recent research models

模型	$P_a$	$\zeta_k$
FBCSP <sup>[5]</sup>	67.75	0.57
EEGNet; CNN <sup>[7]</sup>	77.61	0.71
FBCNet; Filter Bank and CNN <sup>[11]</sup>	76.20	0.68
EEG-ITNet; Mutil-branch and CNN <sup>[21]</sup>	76.74	—
EEG-Conformer; CNN and attention <sup>[12]</sup>	78.66	0.72
EEG-TCNet; CNN and TCN <sup>[9]</sup>	79.55	0.73
TCNFusion; Mutil-layer CNN-TCN <sup>[20]</sup>	79.75	0.73
FBCSP, CNN and LSTM <sup>[14]</sup>	80.00	—
DFL <sup>[22]</sup>	81.85	—
Attention-inception <sup>[23]</sup>	82.84	—
MSTNet(文中)	83.53	0.78

### 3 结束语

EEG-MSTNet 模型可以端到端地进行脑电信号的特征提取与识别,不需要手工提取特征,它主要由 MCNN 模块、SE 模块和 TRN 模块组成. MCNN 模块增强卷积神经网络的时频域特征提取能力,将原始的 EEG 信号编码为一个高维的时间序列. SE 模块通过压缩与激发突出时间序列中最重要的通道信息. TRN 模块从时间序列中提取更高维的时域特征. 消融实验表明, EEG-MSTNet 模型的每个模块都对分类性能的提升做出了贡献,表明了这种混合架构设计的有效性. 虽然每个模块会增加模型的参数量和训练时间,但在可接受的范围内. 值得注意的是,使用 SE 模块后要连接其他模块,才能发挥 SE 模块的效果. 同时,通过与其他模型进行对比<sup>[24-25]</sup>, EEG-MSTNet 模型有很强的竞争力. 虽然 EEG-MSTNet 模型在运动想象领域进行测试,但是其设计思路对脑电信号的其他领域甚至图像语音领域都有很好的借鉴意义.

### 参考文献:

[1] VAUGHAN T M, HEETDERKS W J, TREJO L J, *et al.* Brain-computer interface technology: A review of the second International Meeting[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering: A Publication of the IEEE Engineering in Medicine and Biology Society, 2003, 11(2): 94-109. DOI:10.1109/tnsre.2003.814799.

[2] VÄRBÜ K, MUHAMMAD N, MUHAMMAD Y. Past, present, and future of EEG-based BCI applications[J]. Sensors, 2022, 22(9): 3331. DOI:10.3390/s22093331.

[3] SCHWARTZ A B, CUI X T, WEBER D J, *et al.* Brain-controlled interfaces: Movement restoration with neural prosthetics[J]. Neuron, 2006, 52(1): 205-220. DOI:10.1016/j.neuron.2006.09.019.

[4] KHADEMI Z, EBRAHIMI F, KORDY H M. A review of critical challenges in MI-BCI: From conventional to deep learning methods[J]. Journal of Neuroscience Methods, 2023, 383: 109736. DOI:10.1016/j.jneumeth.2022.109736.

[5] ANG K K, CHIN Z Y, WANG Chuanchu, *et al.* Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b[J]. Frontiers in Neuroscience, 2012, 6: 39. DOI:10.3389/fnins.2012.00039.

[6] BASHAR S K, HASSAN A R, BHUIYAN M I H. Identification of motor imagery movements from EEG signals using dual tree complex wavelet transform[C]// International Conference on Advances in Computing, Communications and Informatics. [S. l.]: IEEE Press, 2015: 290-296. DOI:10.1109/ICACCI.2015.7275623.

[7] 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. DOI:10.1088/1741-2552/aace8c.

[8] LAWRENCE S, GILES C L, TSOI A C, *et al.* Face recognition: A convolutional neural-network approach[J]. IEEE Transactions on Neural Networks, 1997, 8(1): 98-113. DOI:10.1109/72.554195.

[9] INGOLFSSON T M, HERSCHE M, WANG X, *et al.* EEG-TCNet: An accurate temporal convolutional network for embedded motor-imagery brain-machine interfaces[C]// IEEE International Conference on Systems, Man, and Cyber-

- netics.[S.l.]:IEEE Press,2020;2958-2965. DOI:10.1109/SMC42975.2020.9283028.
- [10] BAI S,KOLTER J Z,KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. (2018-03-04)[2023-05-24]. <https://arxiv.org/abs/1803.01271>.
- [11] MANE R,CHEW E,CHUA K,*et al.* FBCNet: A multi-view convolutional neural network for brain-computer interface[EB/OL]. (2021-03-17)[2023-05-24]. <https://arxiv.org/abs/2104.01233>.
- [12] SONG Yonghao,ZHENG Qingqing,LIU Bingchuan,*et al.* EEG-Conformer: Convolutional transformer for EEG decoding and visualization[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering,2022,31:710-719. DOI:10.1109/TNSRE.2022.3230250.
- [13] 孔祥浩,马琳,薄洪健,等. CNN与CSP相结合的脑电特征提取与识别方法研究[J]. 信号处理,2018,34(2):164-173. DOI:10.16798/j.issn.1003-0530.2018.02.006.
- [14] ZHANG Ruilong,ZONG Qun,DOU Liqian,*et al.* A novel hybrid deep learning scheme for four-class motor imagery classification[J]. Journal of Neural Engineering,2019,16(6):066004. DOI:10.1088/1741-2552/ab3471.
- [15] KHADEMI Z,EBRAHIMI F,KORDY H M. A transfer learning-based CNN and LSTM hybrid deep learning model to classify motor imagery EEG signals[J]. Computers in Biology and Medicine,2022,143:105288. DOI:10.1016/j.combiomed.2022.105288.
- [16] HU Jie,SHEN Li,SUN Gang. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City:IEEE Press,2018:7132-7141. DOI:10.1109/CVPR.2018.00745.
- [17] VASWANI A,SHAZEER N,PARMAR N,*et al.* Attention is all you need[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach:Curran Associates Inc.2017:6000-6010. DOI:10.48550/arXiv.1706.03762.
- [18] CHEN Xia,TENG Xiangbin,CHEN Han,*et al.* Toward reliable signals decoding for electroencephalogram: A benchmark study to EEGNeX[EB/OL]. (2022-07-15)[2023-05-24]. <https://arxiv.org/abs/2207.12369>.
- [19] BRUNNER C,LEEB R,MÜLLER-PUTZ G,*et al.* BCI Competition 2008-Graz data set A[J]. Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology,2008,16:1-6.
- [20] MUSALLAM Y K,ALFASSAM N I,MUHAMMAD G,*et al.* Electroencephalography-based motor imagery classification using temporal convolutional network fusion[J]. Biomedical Signal Processing and Control,2021,69:102826. DOI:10.1016/j.bspc.2021.102826.
- [21] 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. DOI:10.1109/ACCESS.2022.3161489.
- [22] YANG Lie,SONG Yonghao,MA Ke,*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. DOI:10.1109/TNSRE.2021.3051958.
- [23] AMIN S U,ALTAHERI H,MUHAMMAD G,*et al.* Attention-inception and long-short-term memory-based electroencephalography classification for motor imagery tasks in rehabilitation[J]. IEEE Transactions on Industrial Informatics,2021,18(8):5412-5421. DOI:10.1109/TII.2021.3132340.
- [24] ALTAHERI H,MUHAMMAD G,ALSULAIMAN M,*et al.* Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: A review[J]. Neural Computing and Applications,2021,35(1):1-42. DOI:10.1007/s00521-021-06352-5.
- [25] KIM S J,LEE D H,LEE S W. Rethinking CNN architecture for enhancing decoding performance of motor imagery-based EEG signals[J]. IEEE Access,2022,10:96984-96996. DOI:10.1109/ACCESS.2022.3204758.

(责任编辑:陈志贤 英文审校:吴逢铁)