

基于参数共享的多特征图内外交互脑电图分类模型

闭应洲, 刘善锐, 霍雷刚, 甘秋静, 李永玉

(南宁师范大学人工智能学院, 南宁 530199)

摘要: 脑电图 (Electroencephalography, EEG) 信号分类在情感识别和脑机接口 (Brain-computer interface, BCI) 应用中具有关键意义。提出了一种参数共享的多特征图内外交互模型 (Cross-map token attention, CMTA)。采用时空特征卷积神经网络 (Spatial-temporal convolutional neural network, STCNN) 对脑电图进行处理, 生成多个脑电图特征图, 每张特征图被视为一个 token, 传入参数共享的多模态模块 MT (MLP 和 Transformer), 其中多层感知器 (Multi-layer perceptron, MLP) 用于捕捉特征图内部的交互关系, Transformer 则实现特征图之间的信息交互, 从而提取更丰富的特征。通过一维自适应池化和全连接层构成的自适应分类器 (Adapt-Classifier) 完成脑电图的分类。实验结果表明, 该方法在情感识别 SEED 数据集上的分类精度为 98.86%, Kappa 值为 0.982 9; 在运动分类 BCI Competition IV Dataset 2a 数据集上的分类精度为 81.20%, Kappa 值为 0.748 4; 在运动分类 BCI Competition IV Dataset 2b 数据集上的分类精度为 86.55%, Kappa 值为 0.735 2。实验结果验证了所提方法在脑电图分类任务中的优越性能, 并展示了其在不同 EEG 数据集上的广泛适用性。

关键词: EEG 信号处理; MLP-Transformer; 时空卷积; 深度学习; 人工智能

中图分类号: TP391; R318 **文献标志码:** A

A Parameter-Sharing Multi-feature Map Interaction Model for EEG Classification

BI Yingzhou, LIU Shanrui, HUO Leigang, GAN Qiuqing, LI Yongyu

(School of Artificial Intelligence, Nanning Normal University, Nanning 530199, China)

Abstract: Electroencephalography (EEG) signal classification plays a crucial role in emotion recognition and brain-computer interface (BCI) applications. This paper proposes a parameter-sharing cross-map token attention (CMTA) model for intra- and inter-feature map interaction. Firstly, a spatial-temporal convolutional neural network (STCNN) is used to process EEG data, generating multiple EEG feature maps. Each feature map is treated as a token and fed into a parameter-sharing multi-modal module MT, which integrates a multi-layer perceptron (MLP) and a Transformer. The MLP captures intra-feature map interactions, while the Transformer enables information exchange between feature maps, thereby extracting richer features. Finally, an adaptive classifier (Adapt-Classifier) consisting of one-dimensional adaptive pooling and a fully connected layer is used to perform EEG classification. Experimental results show that the proposed method achieves a classification accuracy of 98.86% and a Kappa value of 0.982 9 on the SEED dataset for emotion recognition, an accuracy of 81.20% and a Kappa value of 0.748 4 on the BCI Competition IV Dataset 2a for motor imagery classification, and an accuracy of 86.55% and a Kappa

value of 0.735 2 on the BCI Competition IV Dataset 2b. These results demonstrate the superior performance of the proposed method in EEG classification tasks and highlight its broad applicability across different EEG datasets.

Key words: EEG signal processing; MLP-Transformer; spatio-temporal convolution; deep learning; artificial intelligence

引言

脑电图(Electroencephalography, EEG)作为一种非侵入性的神经监测工具,广泛应用于癫痫诊断、认知状态评估等多个领域^[1-3]。然而,EEG信号由于其复杂性和噪声干扰,传统的分析方法往往难以准确提取有效特征。随着人工智能(Artificial intelligence, AI)技术,尤其是深度学习方法的快速发展,AI在EEG信号分析中的应用逐渐成为一个重要的研究方向。深度学习通过自动从复杂数据中学习特征,为EEG信号处理提供了更高效、更精确的解决方案^[4-6]。

近年来,深度学习技术Transformer在EEG分类中的应用备受关注,主要依赖其捕捉时序信息的能力^[7-9]。然而,其在EEG信号处理中的应用仍面临挑战,尤其在token构建方式上存在局限。现有应用在EEG中的Transformer方法通常将时间点上的特征作为token,这种设计不仅导致token信息量有限,哪怕是在电极通道数较多的情感分类数据集SEED中(62个电极通道),以时间点上的所有通道信息作为token所包含的信息也难以充分反映EEG信号的全局与局部特征,而且,Transformer往往需要处理过长的token序列,容易导致参数量急剧上升,这不仅增加了计算负担,也带来了显著的过拟合风险,尤其在EEG数据样本稀缺的背景下更加突出。

为弥补这一不足,本文提出了参数共享的多特征图内外交互模型(Cross-map token attention, CMTA),该模型以特征图作为token输入网络。传统方法通常将单一时间点的多通道特征作为token,仅能捕捉局部的时序信息;相比之下,特征图作为token可整合时空维度特征,如SEED数据集中每个特征图包含62通道×时间窗口的全局信息,具有更高的信息密度和表达能力,有助于捕捉更加丰富的脑电特征。为进一步缓解因token表达增强所带来的参数膨胀与过拟合风险,模型在设计MT模块中引入了参数共享策略,让MT模块中的块与块之间共享相同的参数,从而缓解过拟合风险。具体如图1所示,CMTA模型利用时空特征卷积神经网络(Spatial-temporal convolutional neural network, STCNN)

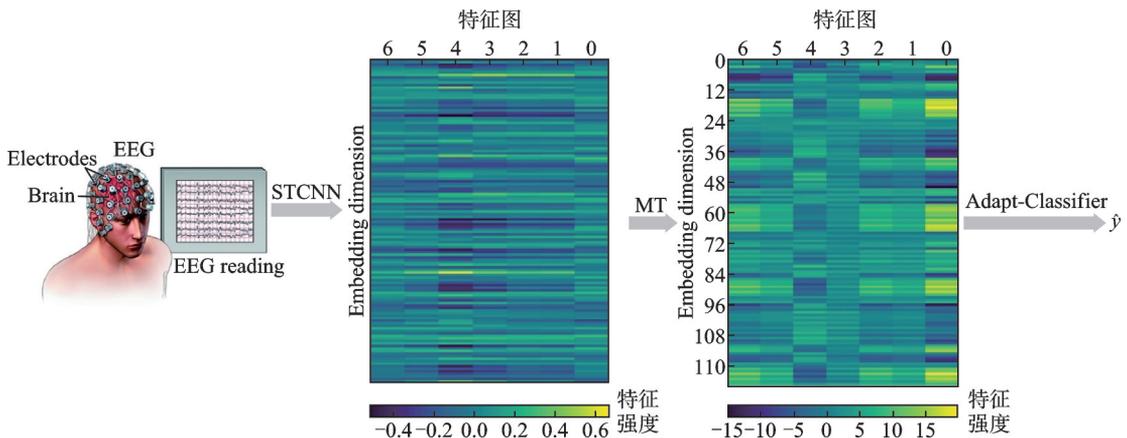


图1 CMTA流程图

Fig.1 CMTA flowchart

对原始 EEG 信号进行预处理,生成多个特征图,并将其作为 token 输入 MT 模块。其中,多层感知机 (Multi-layer perceptron, MLP) 用于建模特征图内部的细粒度交互,Transformer 用于捕捉特征图之间的全局依赖关系。经过 MT 模块处理后所生成的热力图相比于处理前的版本,颜色对比更鲜明,有很多高值和低值交替,说明 MT 对不同位置的 token 做了加权聚合处理,提取关键特征、放大有用的信息。

综上所述,CMTA 模型在充分挖掘 EEG 信号中全局与局部特征的同时,参数共享通过约束 MT 模块的各个块之间共享参数,使用一致的变换规则,缓解过拟合,类似迁移学习中的权值共享思想,尤其适用于 EEG 小样本场景。

1 相关工作

随着深度学习技术的快速发展,研究者提出了多种方法以提升脑电图 (EEG) 信号的分类精度。例如, Li 等^[10]采用长短期记忆网络 (Long short-term memory, LSTM) 学习 EEG 信号的时序特征; Sakhavi 等^[11]利用卷积神经网络 (Convolutional neural network, CNN) 从滤波器组共空间模式 (Common spatial pattern, CSP) 特征中提取 EEG 的时间信息,并为每位受试者选择合适的架构参数。此外, Shan 等^[12]通过在时空 CNN 中引入图结构,利用跨通道的拓扑连通性来改进 EEG 信号的特征提取。Hong 等^[13]在对抗学习驱动领域自适应框架中,使用 CNN 提取 EEG 信号特征。多技术融合的方法也被应用于 EEG 研究领域,例如 EEG Conformer^[7]、EEG-Deformer^[8] 和 3D-CTM^[9] 等模型的提出,进一步提升了 EEG 信号的解码性能。

2 本文方法

2.1 方法概述

本文提出了一种新颖的多模态技术深度学习框架——CMTA,该框架结合了卷积神经网络 (CNN)、多层感知机 (MLP) 和 Transformer 等技术,实现了端到端的 EEG 分类。如图 2 所示,CMTA 由 3 个部分组成:STCNN 模块、MT 模块和 Adapt-Classifier 模块。首先,STCNN 模块提取时空特征,随后通过灵活的 Rearrange 操作,以 EEG 特征图作为 token 传递至 MT 模块。MT 模块集成了 MLP 和 Trans-

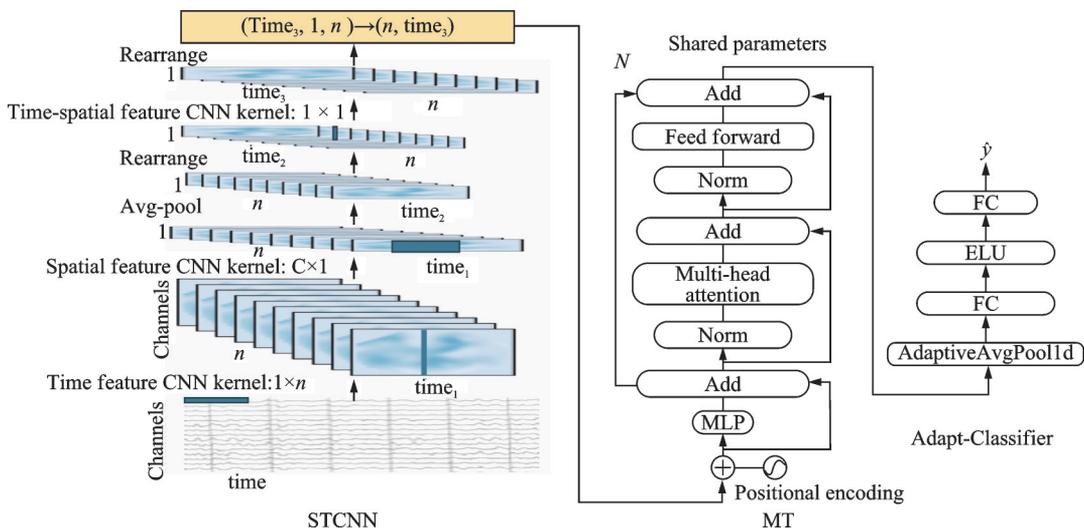


图 2 CMTA 模型总体框架图

Fig.2 Overall framework of the CMTA model

former两部分。MLP负责处理每个特征图内的独立特征,而Transformer通过自注意力机制捕捉不同特征图之间的全局依赖关系。为了缓解以特征图作为token导致参数量过大引发的过拟合问题,本研究在MT部分均采用了参数共享机制。具体而言,MT模块内块间共享参数,通过参数共享保持了跨通道和全局特征的有效提取,确保了对EEG信号复杂空间关系的建模能力。最后,经过MT模块处理后的特征传入Adapt-Classifier模块完成最终的分类任务。

2.2 数据预处理

原始EEG数据的尺寸为(channels, time),其中channels代表电极通道数,time代表通道的时间长度,对原始EEG数据进行了以下预处理步骤。首先,应用带通滤波器滤除多余的高频和低频噪声。接着,进行数据标准化,以减少波动和非平稳性,标准化公式为

$$x_{\text{norm}} = \frac{x - \mu}{\sigma} \quad (1)$$

式中: x 为输入信号, x_{norm} 为标准化后的信号, μ 和 σ 分别为均值和标准差。

2.3 网络架构

如图2所示,CMTA模型的输入为经过预处理的EEG数据,包含样通道维度和时间维度,为了方便进行卷积操作,扩展一个额外的维度,变成(1, channels, time)。模型输出为EEG分类任务中的类别概率。

2.3.1 STCNN 模块

STCNN模块采用了分解的维度卷积策略,分别处理EEG信号的时间和空间维度,以确保高效提取局部特征。具体结构如图2左边STCNN所示。首先,使用Time feature卷积层和Spatial feature卷积层分别捕捉时间特征和空间特征。Time feature卷积层使用尺寸为(1, n)的卷积核,步幅为(1, 1),专门用于提取时间维度的特征;而Spatial feature卷积层则使用尺寸为(channels, 1)的卷积核,步幅同样为(1, 1),作为空间滤波器来学习不同电极通道之间的交互关系。此外,Spatial feature卷积层还确保输出的每个特征图的形状为(1, time_1),为后续将特征图作为token输入做准备。这两个卷积层间未用激活函数,以同时学习时空维度特征。

接下来,采用批量归一化(Batch normalization)来加速训练过程并减轻过拟合风险,同时引入指数线性单元(Exponential linear unit, ELU)激活函数以增加非线性特性。然后,使用平均池化层(Average pooling)对时间特征进行平滑,进一步防止过拟合并减少计算复杂度。完成卷积操作后,数据形状进行重新排列,特征图维度与时间维度进行转置,最后,通过Time-spatial feature卷积层,卷积核大小为(1, 1),将每个特征图的长度调整为128,然后再进行重新排列,确保所有特征图能够作为token输入到MT模块中。这种卷积模块设计充分挖掘了EEG信号的时空特征,使后续的全局特征提取更加高效。

2.3.2 MT 模块

MT模块集成了MLP与Transformer,且模块内块间共享参数,旨在同时处理EEG信号中每个特征图的独立特征以及特征图之间的全局依赖关系。MT模块内块间共享参数可以有效减少模型参数的规模,缓解过拟合问题。

(1) MLP 部分

MLP部分通过两个全连接层(Fully connected layer)和激活函数对每个特征图的特征进行处理。同时引入残差连接(Residual connection),在保留原始信息的基础上增强梯度流动。假设输入的每个特征图为 $\mathbf{X}_i \in \mathbf{R}^L$ 。其中 L 为特征图的长度, i 为特征图索引。具体步骤如下:

第1步:升维。输入特征图 \mathbf{X}_i 首先通过第一个全连接层把特征图的长度 L 升维到 nL ,即将特征图

的长度扩展 n 倍,然后通过高斯误差线性单元(Gaussian error linear unit, GELU)激活函数进行非线性变换,即

$$A_i = \text{GELU}(W_1 X_i + b_1) \quad (2)$$

式中: X_i 为输入, $W_1 \in \mathbf{R}^{nL \times L}$ 为第一个全连接层的权重矩阵, $b_1 \in \mathbf{R}^{nL}$ 为偏置项, $W_1 X_i + b_1$ 是升维后的表示, A_i 为通过 GELU 激活函数处理后的输出。升维的目的是使得模型能够捕捉到更丰富的特征。通过扩展维度,模型的表达能力得到增强,为复杂的非线性关系建模提供了更多的自由度。激活函数 GELU 则引入非线性,帮助模型学习复杂的特征,并且相较于修正线性单元(Rectified linear unit, ReLU),GELU 能够更平滑地处理负值,避免训练过程中的“死神经元”问题,提高了训练的稳定性和泛化能力。

第2步:降维和残差连接。经过第二个全连接层,通过一个线性变换实现降维,该变换具有与第一个全连接层相对应的权重矩阵和偏置项,将特征图的维度从 nL 降回到原始大小 L 。最终,将降维后的特征与原始输入特征图相加,即

$$Y_i^{\text{final}} = Y_i + X_i \quad (3)$$

式中: Y_i 为降维后的输出, Y_i^{final} 为最终的输出。降维的目的是将升维后的特征图还原到原始维度 L ,使得每个特征图的表示能够保持在合理的尺度范围内。通过降维,不仅减少了不必要的计算量,还为后续的残差连接提供了维度匹配的基础,确保输入和输出可以顺利地相加。残差连接有助于保留有效的特征,避免信息丢失,有助于防止梯度消失问题,并加速网络的收敛。残差连接使得信息能够跨越多个层级流动,确保即使在某些层的学习效果较差时,原始的输入信息也能够保留并传递到后续层。这不仅增强了网络的学习能力,还有效缓解了深层网络中可能出现的退化现象。

(2) Transformer 部分

在 Transformer 部分,通过自注意力机制和前馈网络层整合各特征图间的特征。每个特征图被视为一个 token 传入 Transformer,通过共享的线性变换生成查询(Q)、键(K)和值(V)矩阵,即

$$Q = W^Q X, \quad K = W^K X, \quad V = W^V X \quad (4)$$

式中 W^Q 、 W^K 和 W^V 为权重矩阵。自注意力机制计算为

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (5)$$

式中:softmax 为平滑的非线性激活函数,通过缩放因子 $\frac{1}{\sqrt{d_k}}$ 可防止内积值过大,确保计算稳定。为了进一步增强模型的表达能力,采用多头自注意力机制。多头机制通过并行计算多个注意力头(Heads),每个头能够关注输入特征的不同部分,从而捕获不同的语义信息。最终,多个注意力头的输出通过拼接后,经过线性变换得到最终结果,即

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{Head}_1, \text{Head}_2, \dots, \text{Head}_h) \quad (6)$$

自注意力机制的输出通过前馈网络层(Feedforward layer)进行进一步的处理。该层由两个全连接层组成,中间加入 GELU 激活函数。计算公式为

$$Z = \text{GELU}(W_2 Y + b_2) \quad (7)$$

$$Y_{\text{fin}} = W_3 Z + b_3 \quad (8)$$

式中: Y 为输入, W_2 、 W_3 和 b_2 、 b_3 分别为第一个和第二个全连接层的权重和偏置,GELU 为激活函数, Y_{fin} 为经过前馈网络处理后的输出。

(3) 模块参数共享设计

在MT模块中,块间共享参数。这种共享参数的设计大幅度减少了模型的参数数量,这一设计主要目的是缓解过拟合,还通过一致的特征变换来提高模型的泛化能力。虽然共享参数不会直接减少计算量,但它帮助模型更高效地捕捉全局依赖关系,提升了推理效率和训练稳定性,增强了对EEG信号中复杂时空依赖关系的建模能力。

2.3.3 Adapt-Classifier 模块

Adapt-Classifier模块的核心目标是对经过MT编码的特征进行进一步处理,最终生成类别预测结果。该模块通过一维自适应平均池化层 AdaptiveAvgPool1d、全连接层、指数线性单元(Exponential linear unit, ELU)激活函数和softmax激活函数组成,逐步提取并映射到最终的类别空间。

(1) 一维自适应平均池化层

一维自适应平均池化层的主要优势在于,它能够将输入特征图的长度压缩为固定的输出长度,同时有效地保留了输入特征的关键信息。重要的是,这一池化操作没有任何学习参数。假设输入特征图的长度为 L_{in} ,目标输出的长度为 L_{out} ,池化操作的步骤如下:

第1步:将输入特征图划分为 L_{out} 个连续的区间(块)。每个区间的大小由以下公式决定

$$\text{block}_{\text{size}} = \left\lfloor \frac{L_{in}}{L_{out}} \right\rfloor \quad (9)$$

如果 $L_{in} \bmod L_{out} \neq 0$,则前面的一些区间将包含多一个元素,以确保输出总长度为 L_{out} 。

第2步:池化操作。在每个区间内,应用平均池化操作,即计算该区间内所有元素的均值

$$y_i = \frac{1}{\text{block}_{\text{size}}} \sum_{j=1}^{\text{block}_{\text{size}}} x_{i,j} \quad (10)$$

式中: y_i 为第 i 个池化区间的输出值, $x_{i,j}$ 为第 i 个区间内的第 j 个元素。池化后,输出特征图 y 的长度为 L_{out} ,即

$$\mathbf{y} = [y_1, y_2, \dots, y_{L_{out}}] \quad (11)$$

一维自适应池化层的最大特点是它不包含任何学习参数,同时能够有效地压缩输入特征图的长度,保留了数据的关键信息,有助于减少计算复杂度,避免过拟合。

(2) 全连接层与激活函数

一维自适应平均池化后的输出通过两个全连接层,并在它们之间应用ELU激活函数,具体步骤如下

$$\mathbf{z}_1 = \mathbf{W}_4 \mathbf{X} + \mathbf{b}_4 \quad (12)$$

$$\mathbf{a}_1 = \text{ELU}(\mathbf{z}_1) \quad (13)$$

$$\mathbf{z}_2 = \mathbf{W}_5 \mathbf{a}_1 + \mathbf{b}_5 \quad (14)$$

式中: $\mathbf{W}_4 \in \mathbf{R}^{H_1 \times L_{out}}$ 为第一个全连接层的权重矩阵,负责将输入 x 映射到隐藏层空间,其中 H_1 为隐藏层大小, L_{out} 为一维自适应平均池化后特征图的长度; $\mathbf{b}_4 \in \mathbf{R}^{H_1}$ 是第一个全连接层的偏置项,增加模型的灵活性; $\mathbf{z}_1 \in \mathbf{R}^{H_1}$ 为第一个全连接层的输出,经过加权求和和偏置后得到。ELU对 \mathbf{z}_1 进行非线性变换,是一种能够加速训练和缓解梯度消失问题的激活函数。 $\mathbf{W}_5 \in \mathbf{R}^{C \times H_1}$ 是第二个全连接层的权重矩阵,负责将经过ELU激活的特征 \mathbf{a}_1 映射到类别空间,其中 C 为类别数; $\mathbf{b}_5 \in \mathbf{R}^C$ 为第二个全连接层的偏置项,控制模型的输出; $\mathbf{z}_2 \in \mathbf{R}^C$ 为第二个全连接层的输出,即最终的类别得分。

全连接层的作用是将隐藏EEG信号的特征映射到类别空间,生成类别得分。

(3) Softmax 函数

Softmax 函数将第二个全连接层的输出转化为类别概率分布,其公式为

$$\hat{y} = \text{softmax}(z_2) \quad (15)$$

式中: z_2 为类别得分,softmax 函数将每个类别的得分转换为概率,确保所有类别的概率和为1。

3 实验与结果

本节对提出的 CMTA 框架在 3 个公开 EEG 数据集上进行实验验证,包括情绪识别任务和运动想象识别任务。通过鲁棒性实验评估模型在部分通道缺失情况下的性能稳定性和消融实验,展示注意力层数和共享参数对模型的影响以及一维自适应池化层对实验结果的影响。

3.1 数据集

在 3 个广泛使用的 EEG 数据集上评估 CMTA 模型,包括 SEED 数据集、BCI Competition IV Dataset 2a 和 BCI Competition IV Dataset 2b。这些数据集涵盖不同的实验任务、被试数量和采样标准,充分验证了 CMTA 模型的适应性和泛化能力。

(1) 数据集 I :SEED 数据集^[14]

该数据集由上海交通大学提供,主要用于情绪识别任务。它包含 15 名被试的 EEG 信号,涵盖 3 种情绪状态:积极、中性和消极。情绪由 15 段电影片段引发,每个被试进行了 3 次数据收集,每次间隔约 1 周。EEG 数据使用 62 个电极记录,采样率为 1 000 Hz,并下采样至 200 Hz。使用不重叠的 2 s 时间窗口对信号进行分段,得到每个数据的形状为(62,400),并对数据进行[4,47] Hz 的带通滤波处理。

(2) 数据集 II :BCI Competition IV Dataset 2a^[15]

该数据集由格拉茨技术大学提供,用于运动想象任务。它包含 9 名被试的 EEG 数据,任务包括左手、右手、双脚和舌头的运动想象。数据通过 22 个 Ag/AgCl 电极采集,采样率为 250 Hz。数据通过两个会话采集,每个会话包含 288 个试验。使用每个试验的[2,6]s 数据,得到每个数据的形状为(22,1 000),并对 EEG 信号进行[4,40] Hz 的带通滤波处理。

(3) 数据集 III :BCI Competition IV Dataset 2b^[16]

该数据集同样由格拉茨技术大学提供,专注于左右手的运动想象任务。该数据集包含 9 名参与者的 EEG 数据,使用 3 个双极电极(C3、Cz、C4)采集,采样率为 250 Hz。数据通过 5 个会话采集,每个会话包含 120 个试验。使用每个试验的[3,7]s 数据,得到每个数据的形状为(6,1 000),并对信号进行[4,40] Hz 的带通滤波处理。

3.2 实验细节和评价指标

CMTA 模型在 Python 3.11 环境下使用 PyTorch 库实现,并在 Geforce 3090 24 GB 的 GPU 上进行训练。使用 Adam 优化器,学习率设为 0.000 1, β_1 和 β_2 分别为 0.5 和 0.999。

为了评估模型的性能,采用了分类准确率和 Kappa 值作为主要评价指标。分类准确率表示模型在所有测试样本中的预测正确率,即正确预测的样本数量与总样本数量的比值;Kappa 值则用于衡量 CMTA 预测结果与真实标签一致性的统计量。Kappa 值的计算公式为

$$\text{Kappa} = \frac{p_o - p_e}{1 - p_e} \quad (16)$$

式中: p_o 为观测准确率, p_e 为期望准确率。Kappa 值的范围从-1到1,其中 Kappa=1 表示 CMTA 模型的预测特别好,Kappa=0 表示 CMTA 模型的预测结果与随机猜测无异,而 Kappa<0 表示 CMTA 模型的预测结果比随机猜测更差。

3.3 基线比较

实验在 SEED 数据集上对 CMTA 进行评估,并与多种先进的情绪识别方法进行了对比,结果如表 1 所示。从实验结果可以看出,CMTA 在分类准确率(98.86%)和 Kappa 值(0.982 9)方面显著优于传统方法(如 SVM:86.08%、GELM:91.07%)以及多种深度学习模型(如 DGCNN:90.40%、R2G-STNN:93.38%、RGNN:94.24%、Conformer:95.30%、FTCN:89.13%)。此外,CMTA 的表现也优于近期提出的模型,如 Dual-TSST,该模型利用双分辨率时频空间 Transformer,通过两个 CNN 分支分别提取原始 EEG 的时域特征和小波变换后时频空间特征,并以自注意力机制实现融合,在 SEED 数据集上取得了 96.65% 的分类准确率和 0.948 8 的 Kappa 值;基于 3D-CNN 与 Transformer 机制融合空间、时域与频域信息的 3D-CTM 模型则构建了三维特征立方体,依次通过卷积深度特征提取和 Transformer 自注意力模块,在三分类任务中获得了 96.36% 的准确率。CMTA 优于 Dual-TSST 和 3D-CTM,主要得益于其结构设计的高效性。STCNN 模块采用维度分解卷积,有效提升了时空特征提取的效率;同时,参数共享的 MT 模块减轻了过拟合风险,从而更适应小样本 EEG 数据的建模需求。为验证 MT 模块中 MLP 结构的贡献,构建了去除 MLP 的对照模型 CMTA-M。该模型准确率为 98.33%、Kappa 值为 0.975 0,均低于 CMTA,这表明 MLP 在特征交互和分类性能提升方面具有积极作用。

表 1 SEED 数据集实验结果

Table 1 Experimental results on the SEED dataset

| Method | Accuracy/% | Kappa |
|---------------------------|------------|---------|
| SVM ^[14] | 86.08 | 0.791 2 |
| GELM ^[17] | 91.07 | 0.866 1 |
| DGCNN ^[18] | 90.40 | 0.856 0 |
| R2G-STNN ^[19] | 93.38 | 0.900 7 |
| RGNN ^[20] | 94.24 | 0.913 6 |
| Conformer ^[7] | 95.30 | 0.929 5 |
| FTCN ^[21] | 89.13 | — |
| Dual-TSST ^[22] | 96.65 | 0.948 8 |
| 3D-CTM ^[9] | 96.36 | — |
| CMTA-M | 98.33 | 0.975 0 |
| CMTA | 98.86 | 0.982 9 |

在 BCI Competition IV Dataset 2a 数据集上,将 CMTA 与传统方法(FBCSP)、经典的深度学习模型(ConvNet、EEGNet、C2CM、FBCNet、DRDA、Conformer)、以及较新的模型(ADFCNN 和 M-FANet)进行了对比(见表 2)。实验结果显示,CMTA 的平均分类准确率达到 81.20%,Kappa 值为 0.748 4,相比 FBCSP 提高了 13.45%,并明显优于 ConvNet(72.53%)、EEGNet(74.50%)和 Conformer(78.66%,Kappa:0.715 5);CMTA 也优于 ADFCNN 模型,该模型通过双尺度时空注意力机制自适应融合频域与时域特征,在跨会话测试中实现了 79.39% 的平均准确率;同时超越了 M-FANet,该轻量化模型采用多特征注意力模块和 R-Drop 正则化训练策略,消除频域冗余信息、增强空间特征提取并提升泛化能力,获得了 79.28% 的准确率和 0.725 9 的 Kappa 值。去除 MLP 的的对照模型 CMTA-M 的平均准确率为 79.20%、Kappa 值为 0.722 7,均低于 CMTA,进一步证明了 MLP 在特征交互和分类性能提升方面具有积极作用。

在 BCI Competition IV Dataset 2b 数据集上,尽管数据仅包含 6 个电极通道,CMTA 表现依然出色(表 3)。与 FBCSP 相比,CMTA 的准确率提高了 6.55%;与 Conformer 相比,准确率提升了 1.92%。此外,CMTA 在平均准确率(86.55%)和 Kappa 值(0.735 2)上均超过了 DRDA,在与近期提出的 Speech2EEG 方法的对比中,Speech2EEG 借鉴预训练语音处理模型(如 wav2vec 2.0),将其适配到 EEG 信号以提取多通道时间嵌入,然后通过加权平均、通道级和通道-深度级聚合方法整合这些嵌入,最后接入分类网络以预测运动想象类别,该方法在 2b 数据集上实现了 84.07% 的平均准确率,相比之下 CMTA 仍领先 2.48 个百分点。与去除 MLP 的对照模型 CMTA-M 相比,CMTA 在该数据集上的表现也更优(86.55% vs. 85.68%,0.735 2 vs.0.718 3),说明 MLP 在特征交互和分类性能提升方面具有积极作用。

表2 BCI Competition IV Dataset 2a数据集实验结果

Table 2 Experimental results on the BCI Competition IV Dataset 2a

| Method | S ₁ /% | S ₂ /% | S ₃ /% | S ₄ /% | S ₅ /% | S ₆ /% | S ₇ /% | S ₈ /% | S ₉ /% | Average/% | Kappa |
|--------------------------|-------------------|-------------------|-------------------|-------------------|-------------------|-------------------|-------------------|-------------------|-------------------|--------------|----------------|
| FBCSP ^[23] | 76.00 | 56.50 | 81.25 | 61.00 | 55.00 | 45.25 | 82.75 | 81.25 | 70.75 | 67.75 | 0.570 0 |
| ConvNet ^[24] | 76.39 | 55.21 | 89.24 | 74.65 | 56.94 | 54.17 | 92.71 | 77.08 | 76.39 | 72.53 | 0.633 7 |
| EEGNet ^[25] | 85.76 | 61.46 | 88.54 | 67.01 | 55.90 | 52.08 | 89.58 | 83.33 | 86.81 | 74.50 | 0.660 0 |
| C2CM ^[26] | 87.50 | 65.28 | 90.28 | 66.67 | 62.50 | 45.49 | 89.58 | 83.33 | 79.51 | 74.46 | 0.659 5 |
| FBCNet ^[27] | 85.42 | 60.42 | 90.63 | 76.39 | 74.31 | 53.82 | 84.38 | 79.51 | 80.90 | 76.20 | 0.682 7 |
| DRDA ^[28] | 83.19 | 55.14 | 87.43 | 75.28 | 62.29 | 57.15 | 86.18 | 83.61 | 82.00 | 74.74 | 0.663 2 |
| Conformer ^[7] | 88.19 | 61.46 | 93.40 | 78.13 | 52.08 | 65.28 | 92.36 | 88.19 | 88.89 | 78.66 | 0.715 5 |
| ADFCNN ^[29] | 87.15 | 61.45 | 93.75 | 75.69 | 75.34 | 65.27 | 88.54 | 82.29 | 85.06 | 79.36 | — |
| M-FANet ^[30] | 86.81 | 75.00 | 91.67 | 73.61 | 76.39 | 61.46 | 85.76 | 75.69 | 87.15 | 79.28 | 0.725 9 |
| CMTA-M | 88.54 | 60.76 | 94.09 | 79.86 | 56.25 | 64.23 | 93.40 | 88.54 | 87.15 | 79.20 | 0.722 7 |
| CMTA | 89.23 | 64.58 | 94.09 | 84.02 | 58.68 | 67.01 | 94.09 | 89.93 | 89.23 | 81.20 | 0.748 4 |

表3 BCI Competition IV Dataset 2b数据集实验结果

Table 3 Experimental results on the BCI Competition IV Dataset 2b

| Method | S ₁ /% | S ₂ /% | S ₃ /% | S ₄ /% | S ₅ /% | S ₆ /% | S ₇ /% | S ₈ /% | S ₉ /% | Average/% | Kappa |
|----------------------------|-------------------|-------------------|-------------------|-------------------|-------------------|-------------------|-------------------|-------------------|-------------------|--------------|----------------|
| FBCSP ^[23] | 70.00 | 60.36 | 60.94 | 97.50 | 93.12 | 80.63 | 78.13 | 92.50 | 86.88 | 80.00 | 0.600 0 |
| ConvNet ^[24] | 76.56 | 50.00 | 51.56 | 96.88 | 93.13 | 85.31 | 83.75 | 91.56 | 85.62 | 79.37 | 0.587 4 |
| EEGNet ^[25] | 75.94 | 57.64 | 58.43 | 98.13 | 81.25 | 88.75 | 84.06 | 93.44 | 89.69 | 80.48 | 0.609 6 |
| DRDA ^[28] | 81.37 | 62.86 | 63.63 | 95.94 | 93.56 | 88.19 | 85.00 | 95.25 | 90.00 | 83.98 | 0.679 6 |
| Conformer ^[7] | 82.50 | 65.71 | 63.75 | 98.44 | 86.56 | 90.31 | 87.81 | 94.38 | 92.19 | 84.63 | 0.692 6 |
| Speech2EEG ^[31] | 80.70 | 62.04 | 71.74 | 96.09 | 94.51 | 84.06 | 84.06 | 95.65 | 87.76 | 84.07 | — |
| CMTA-M | 84.37 | 69.28 | 74.06 | 96.25 | 85.00 | 86.25 | 94.06 | 97.18 | 84.68 | 85.68 | 0.718 3 |
| CMTA | 84.68 | 72.14 | 73.43 | 96.87 | 91.25 | 85.62 | 93.43 | 97.50 | 84.06 | 86.55 | 0.735 2 |

3.4 鲁棒性实验

为验证模型在电极通道部分丢失情况下的鲁棒性,在包含62个通道的SEED数据集上,采用随机剔除指定数量通道的策略。结果如表4所示,在完整通道条件下,模型达到了98.86%的分类准确率和0.982 9的Kappa值;即便剔除1至20个通道,准确率仅轻微下降至97.65%~98.13%,Kappa值仍维持在0.964 6~0.971 9;即使在剔除30~45个通道(剩余17~32个通道)时,准确率亦保持在96.98%~97.67%(Kappa 0.954 6~0.965 0),展示了模型对中等程度通道丢失的强大容错能力;即使在极端情况

表4 丢弃不同电极通道数对分类准确率的影响

Table 4 Impact of discarding different numbers of electrode channels on classification accuracy

| 丢弃通道数 | 分类准确率/% | Kappa | 丢弃通道数 | 分类准确率/% | Kappa |
|-------|---------|---------|-------|---------|---------|
| 0 | 98.86 | 0.982 9 | 30 | 97.67 | 0.9650 |
| 1 | 97.65 | 0.964 6 | 40 | 97.08 | 0.956 1 |
| 5 | 98.13 | 0.971 9 | 45 | 96.98 | 0.954 6 |
| 10 | 97.90 | 0.968 5 | 50 | 94.18 | 0.912 5 |
| 20 | 97.94 | 0.969 1 | 55 | 89.59 | 0.843 4 |

下剔除 50 和 55 个通道(分别仅剩 12 和 7 个通道)时,模型依然能够实现 94.18%(Kappa 0.912 5)和 89.59%(Kappa 0.843 4)的分类性能。这些结果充分证明了所提 TFFAN 模型在实际 EEG 采集过程中出现电极接触不良或信号丢失时,仍能保持较高的分类精度和一致性。

3.5 消融实验

3.5.1 MT 模块共享参数设计的影响

为了分析 MT 模块内块间共享参数设计对模型性能的影响,在 SEED 数据集上进行了消融实验,主要探讨了 MT 模块的块数及模块内块间共享参数设计对模型准确率的影响。

实验首先通过改变 MT 模块的块数(从 1 到 8)来观察其对性能的影响,同时还对比了在不同块数配置下块间是否共享参数的性能表现。实验结果如图 3 所示,从实验数据可以看出,随着块数的增加,模型的准确率在不共享参数的情况下略有波动,但整体表现较为稳定。而在共享参数的配置下,模型准确率在块数较少时(如 2 和 3 块)表现优异,尤其在 2 块时,准确率达到 98.86%,明显高于不共享参数的 98.36%。然而,当块数增多时,模型的准确率在共享参数的情况下开始显著下降,特别是在 5 块和 8 块时,准确率分别降至 97.10% 和 97.66%。

这些结果表明,MT 模块的块数和块间参数共享情况均对模型性能产生了显著影响。总体而言,适量的块数(如 1 至 2 块)有助于提高模型的准确率,且在块数较少时,块间参数共享能够进一步提升模型性能。然而,当块数增多(如 3 块及以上)时,参数共享反而会导致模型性能下降。

3.5.2 Adapt-Classifier 模块设计及性能分析

为深入探讨一维自适应平均池化层对模型性能的影响,对 Adapt-Classifier 模块进行了不同结构的比较实验。具体设计包括:仅使用两个全连接层(2FC)、3 个全连接层(3FC),以及结合一维自适应平均池化层和两个全连接层(1A_2FC)。所有实验基于 SEED 数据集进行。实验结果如表 5 所示,可以看出,1A_2FC 结构在保持较小参数量的同时,达到了最高的准确率(98.86%)和 Kappa 值(0.982 9),表现优于 2FC(98.68% 准确率,0.980 1 Kappa)和 3FC(98.73% 准确率,0.980 9 Kappa)结构。这一结果表明,一维自适应平均池化层在提升模型性能的同时,有效降低了参数量,证明其对模型具有积极的影响。

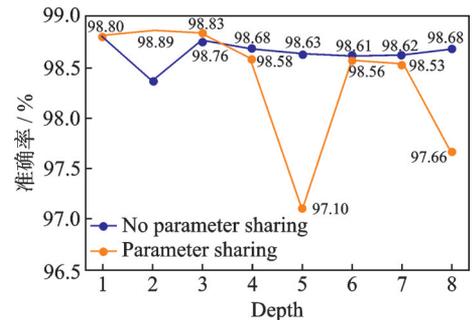


图 3 MT 模块的块数对 SEED 数据集精度的影响

Fig.3 Effect of number of MT modules on accuracy of the SEED dataset

表 5 不同 Adapt-Classifier 模块设计对实验结果的影响

Table 5 Impact of different Adapt-Classifier module designs on experimental results

| Adapt-Classifier | Accuracy/% | Kappa | Model parameters |
|------------------|------------|---------|------------------|
| 2FC | 98.68 | 0.980 1 | 923 818 |
| 3FC | 98.73 | 0.980 9 | 1 155 266 |
| 1A_2FC | 98.86 | 0.982 9 | 904 106 |

4 结果讨论

尽管 CMTA 在性能上取得了显著提升,但是 CMTA 的总体计算复杂性仍然是一个值得关注的问题

题,尤其是在大规模应用中。未来的研究可以集中于进一步优化模型的计算效率,特别是在实时应用场景下,以确保CMTA框架的可扩展性和实用性。

5 结束语

本文提出的CMTA框架通过整合卷积神经网络(CNN)、多层感知机(MLP)和Transformer的多模态技术,在EEG信号处理领域展现出强大的性能。实验结果表明,CMTA在多个公开数据集上均表现出色,尤其是在情感分类SEED数据集上,成功捕捉了复杂的情绪模式。同时,在运动分类BCI Competition IV Dataset 2b数据集中,尽管仅有6个电极通道,CMTA依然展现了卓越的分类性能。这表明CMTA框架在不同数据条件下都具有良好的适应性和鲁棒性,为EEG信号的分类和分析提供了有效且创新的解决方案,具备广泛的应用前景。

参考文献:

- [1] JIN J, SUN H, DALY I, et al. A novel classification framework using the graph representations of electroencephalogram for motor imagery based brain-computer interface[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 30: 20-29.
- [2] LIU B C, CHEN X G, SHI N L, et al. Improving the performance of individually calibrated SSVEP-BCI by task-discriminant component analysis[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, 29: 1998-2007.
- [3] LI J W, BARMA S, MAK P U, et al. Single-channel selection for EEG-based emotion recognition using brain rhythm sequencing[J]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26(6): 2493-2503.
- [4] LOTTE F, BOUGRAIN L, CICHOCKI A, et al. A review of classification algorithms for EEG-based brain-computer interfaces: A 10 year update[J]. *Journal of Neural Engineering*, 2018, 15(3): 031005.
- [5] PADHMASHREE V, BHATTACHARYYA A. Human emotion recognition based on time-frequency analysis of multivariate EEG signal[J]. *Knowledge-Based Systems*, 2022, 238: 107867.
- [6] BHATTACHARYYA A, TRIPATHY R K, GARG L, et al. A novel multivariate-multiscale approach for computing EEG spectral and temporal complexity for human emotion recognition[J]. *IEEE Sensors Journal*, 2021, 21(3): 3579-3591.
- [7] SONG Y H, ZHENG Q Q, LIU B C, et al. EEG conformer: Convolutional Transformer for EEG decoding and visualization [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 31: 710-719.
- [8] SHE Q S, CHEN T, FANG F, et al. Improved domain adaptation network based on Wasserstein distance for motor imagery EEG classification[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31: 1137-1148.
- [9] 张学军,王天晨,王泽田.基于多域信息融合的卷积Transformer脑电情感识别模型[J]. *数据采集与处理*, 2024, 39(6): 1543-1552.
ZHANG Xuejun, WANG Tianchen, WANG Zetian. Convolutional Transformer EEG emotion recognition model based on multi-domain information fusion[J]. *Journal of Data Acquisition and Processing*, 2024, 39(6): 1543-1552.
- [10] LI H L, DING M, ZHANG R H, et al. Motor imagery EEG classification algorithm based on CNN-LSTM feature fusion network[J]. *Biomedical Signal Processing and Control*, 2022, 72: 103342.
- [11] SAKHAVI S, GUAN C T, YAN S C. Learning temporal information for brain-computer interface using convolutional neural networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(11): 5619-5629.
- [12] SHAN X C, CAO J, HUO S D, et al. Spatial-temporal graph convolutional network for Alzheimer classification based on brain functional connectivity imaging of electroencephalogram[J]. *Human Brain Mapping*, 2022, 43(17): 5194-5209.
- [13] HONG X L, ZHENG Q Q, LIU L Y, et al. Dynamic joint domain adaptation network for motor imagery classification[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, 29: 556-565.
- [14] ZHENG W L, LU B L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. *IEEE Transactions on Autonomous Mental Development*, 2015, 7(3): 162-175.
- [15] BRUNNER C, LEEB R, MÜLLER-PUTZ G R, et al. BCI competition 2008-Graz data set A[EB/OL]. (2022-08-12). <https://lampz.tugraz.at/~bci/database/001-2014/description.pdf>.

- [16] BRUNNER C, LEEB R, MÜLLER-PUTZ G R, et al. BCI competition 2008-Graz data set B[EB/OL]. (2022-08-12). <https://www.bbci.de/competition/iv/desc-2b.pdf>.
- [17] ZHENG W L, ZHU J Y, LU B L. Identifying stable patterns over time for emotion recognition from EEG[J]. IEEE Transactions on Affective Computing, 2019, 10(3): 417-429.
- [18] SONG T F, ZHENG W M, SONG P, et al. EEG emotion recognition using dynamical graph convolutional neural networks [J]. IEEE Transactions on Affective Computing, 2020, 11(3): 532-541.
- [19] LI Y, ZHENG W M, WANG L, et al. From regional to global brain: A novel hierarchical spatial-temporal neural network model for EEG emotion recognition[J]. IEEE Transactions on Affective Computing, 2022, 13(2): 568-578.
- [20] ZHONG P X, WANG D, MIAO C Y. EEG-based emotion recognition using regularized graph neural networks[J]. IEEE Transactions on Affective Computing, 2022, 13(3): 1290-1301.
- [21] YANG L J, WANG Y X, OUYANG R J, et al. Electroencephalogram-based emotion recognition using factorization temporal separable convolution network[J]. Engineering Applications of Artificial Intelligence, 2024, 133(Part A): 108011.
- [22] LI H Q, ZHANG H D, CHEN Y T. Dual-TSST: A dual-branch temporal-spectral-spatial transformer model for EEG decoding[EB/OL]. (2024-09-05). <https://doi.org/10.48550/arXiv.2409.03251>.
- [23] ANG K K, CHIN Z Y, WANG C, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b[J]. Frontiers in Neuroscience, 2012, 6: 39.
- [24] 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.
- [25] 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.
- [26] SAKHAVI S, GUAN C T, YAN S C. Learning temporal information for brain-computer interface using convolutional neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(11): 5619-5629.
- [27] MANE R, CHEW E, CHUA K, et al. FBCNet: A multi-view convolutional neural network for brain-computer interface[EB/OL]. (2021-03-17). <https://doi.org/10.48550/arXiv.2104.01233>.
- [28] ZHAO H, ZHENG Q Q, MA K, et al. Deep representation-based domain adaptation for nonstationary EEG classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(2): 535-545.
- [29] TAO W, ET A L. ADFCNN: Attention-based dual-scale fusion convolutional neural network for motor imagery brain-computer interface[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2024, 32: 154-165.
- [30] QIN Y, YANG B, KE S, et al. M-FANet: Multi-feature attention convolutional neural network for motor imagery decoding [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2024, 32: 401-411.
- [31] ZHOU J, DUAN Y, ZOU Y, et al. Speech2EEG: Leveraging pretrained speech model for EEG signal recognition[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 2140-2153.

作者简介:



闭应洲(1967-),男,博士,教授,硕士生导师,研究方向:智能计算、智能信息处理, E-mail: byzhou@163.com。



刘善锐(1998-),通信作者,男,硕士研究生,研究方向:人工智能、脑电图 EEG, E-mail: 511332602@qq.com。



霍雷刚(1986-),通信作者,男,博士,副教授,研究方向:图像处理、人工智能, E-mail: leiganghuo@163.com。



甘秋静(2000-),女,硕士研究生,研究方向:人工智能。



李永玉(1997-),男,硕士研究生,研究方向:动作识别。

(编辑:王静)