

基于空间连通特征和残差卷积神经网络的情绪脑电识别研究

张学军^{1,2}, 付从伟¹

(1. 南京邮电大学电子与光学工程学院、柔性电子(未来技术)学院, 南京 210023; 2. 南京邮电大学射频集成与微组
装技术国家地方联合工程实验室, 南京 210023)

摘要: 脑电信号(Electroencephalogram, EEG)作为一种客观直接的信息源,被广泛应用于情绪识别任务。为了提取脑电信号的空间连通特征所隐含的信息,提出了一种基于空间连通特征和残差卷积神经网络(Spatial connectivity features and residual convolutional neural network, SCF-RCNN)模型的情绪识别方法。该方法从经预处理的脑电信号中提取皮尔逊相关系数(Pearson correlation coefficient, PCC)、锁相值(Phase-locked value, PLV)和互信息(Mutual information, MI)作为空间连通特征,使用包含两个残差模块的卷积神经网络模型来提取情感信息。在SEED数据集上的实验结果显示,PLV构造的连接矩阵与脑电情绪关系更为密切,其平均准确率可达93.38%,标准差为3.35%。与传统算法相比,SCF-RCNN在情绪识别领域的分类任务中表现更为优越,表明该方法在情绪识别领域具有重要的应用潜力。

关键词: 脑电信号;情绪识别;残差神经网络;连通特征;锁相值

中图分类号: TP391

文献标志码: A

Emotional EEG Recognition Using Spatial Connectivity Features and Residual Convolutional Neural Network

ZHANG Xuejun^{1,2}, FU Congwei¹

(1. College of Electronic and Optical Engineering & College of Flexible Electronics (Future Technology), Nanjing University of Posts and Telecommunications, Nanjing 210023, China; 2. Nation-Local Joint Project Engineering Lab of RF Integration & Micropackage, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: As an objective and direct source of information, electroencephalogram (EEG) is widely used in the task of emotion recognition. In order to extract the information implicit in the spatial connectivity features of EEG signals, this paper proposes an emotion recognition method based on the spatial connectivity features and residual convolutional neural network (SCF-RCNN) model. In this method, Pearson correlation coefficient (PCC), phase-locked value (PLV) and mutual information (MI) are extracted from the preprocessed EEG signals as spatial connectivity features, and a convolutional neural network model containing two residual modules is used to extract emotional information. Experimental results on the SEED dataset show that the connection matrix constructed by PLV is more closely related to EEG emotion, with an average accuracy of 93.38% and a standard deviation of 3.35%. Compared with

基金项目: 国家自然科学基金(61977039)。

收稿日期: 2024-03-28; **修订日期:** 2024-06-21

traditional algorithms, SCF-RCNN performs better in classification tasks in the field of emotion recognition, showing its important application potential in the field of emotion recognition.

Key words: electroencephalogram (EEG); emotion recognition; residual neural network (ResNet); connectivity feature; phase-locked value (PLV)

引言

情绪是人们日常生活的重要组成部分,对其心理状态有着特殊的影响^[1]。情绪识别可以帮助了解个体状态,评估和监测个体的心理状态,有助于帮助患有情绪障碍和心理疾病的人群。情绪识别也可以丰富人机交互方式,例如,帮助计算机或机器人更好地理解 and 响应用户的情感需求,提供个性化和情感化的服务。

传统情绪识别主要依赖于对个体行为观察和自我报告,这些方法存在过度依赖于主观性的缺陷^[2],而基于脑电信号(Electroencephalogram, EEG)的情绪识别提供了一种更加客观和直接的方法。EEG直接反映了大脑神经的变化,能够提供更加准确和实时的脑电情绪信息。当然,脑电信号的情绪识别也存在一些挑战:首先是个体差异和大脑复杂性使得情绪识别变得复杂,同样的情绪在不同大脑可能表现出不同的脑电模式^[3];其次,如眼电信号(Electrooculography, EOG)、肌电信号(Electromyography, EMG)的干扰和采集信号时的噪声会给情绪识别的准确性带来影响。但随着深度学习的迅速发展,基于EEG的情绪识别迎来了新的机遇。

EEG情绪识别模型的输入形式可分为4类:人工设计的传统特征、原始或经过预处理的信号、编码后的图像特征和其他特征^[4]。大多数研究选择人工设计的传统特征作为模型的输入,如功率谱密度(Power spectral density, PSD)、微分熵(Differential entropy, DE)和不对称差(Differential asymmetry, DASM)等。这些特征已在情绪识别领域中得到广泛应用,并且取得了不少研究成果。然而,这些特征缺乏对脑电信号空间和功能的描述。大脑是一个整体,其本质上可以看作是一个网络,情绪的表达式是大脑不同区域之间合作的结果^[5]。所以,情绪可以通过不同大脑区域之间的连通性来分析。连通性特征是评估大脑活动的依赖性,研究不同大脑区域之间的相互关系。连通性特征提供了与传统脑电信号特征不同的视角,揭示了有关大脑功能的信息。连通特征包括皮尔逊相关系数(Pearson correlation coefficient, PCC)、互信息(Mutual information, MI)和锁相值(Phase-locked value, PLV)等,其中PCC用于衡量两个变量或信号的相似性,MI用于衡量两个随机变量之间的相关性,PLV衡量信号之间的相位同步程度,常用于分析EEG或其他生物信号中的相位同步现象。

近年来,出现了不少关于EEG连通特征的研究。Wang等^[6]提出了一种能够反应情绪状态的特征融合方法,该方法先通过计算EEG的多尺度排列熵(Multiscale permutation entropy, MPE)和PCC来构建大脑功能网络,再利用PageRank算法对大脑功能网络中节点的进行排序,筛选出情绪识别中的重要通道,然后将各通道的权重与MPE进行加权组合,得到MC-WMPE特征,并在DEAP和SEED数据集上得到了验证;Moon等^[7]引入卷积神经网络(Convolutional neural network, CNN)对脑电信号进行分类,并通过使用3种不同类型的连通性矩阵(PCC、PLV和转移熵(Transfer entropy, TE))验证其有效性;Akhand等^[8]提出一种使用部分MI(Partial MI, PMI)的增强连通特征图,通过引入第三条EEG通道来获取更多的信息,并以2D和3D形式构建连通图,使用CNN对其分类,在DEAP数据集上,效价和唤醒的平均准确率分别为91.71%和91.79%;Li等^[9]从EEG中提取时间、空间和连接特征,得到了情绪刺激下大脑区域间协作通道间的连接性,并将其通过时空连接多尺度卷积神经网络(Spatial-temporal-connective features via multi-scale CNN, STC-CNN)模型进行情绪识别。

本文提出了基于空间连通性特征和残差卷积神经网络(Spatial-connective features and residual CNN, SCF-RCNN)的情绪识别方法。首先根据10-20国际标准导联系统选定32脑电电极,采用3种连

通性算法计算各脑电通道的连通度量,以连通度量值为节点的权值,构建连通特征矩阵(Connectivity feature matrix, CFM);然后,构建残差卷积神经网络模型,通过跨层连接的方式,实现更深的网络结构并有效地学习特征表示;最后,在SEED数据集上进行对比实验,验证该方法的有效性。

1 数据与方法

1.1 数据集

本文使用的EEG数据集是由上海交通大学BCMI实验室发布的公共数据集SEED^[10]。平均年龄为23岁的受试者(包括7名男性和8名女性)参加了数据采集实验。根据10-20国际标准导联系统,使用ESI神经扫描系统以1 000 Hz的采样率从62个电极通道收集数据。每个受试者都观看了15个经被选择和标记的电影片段。电影包含3种情绪类型:积极、中性和消极,每部电影片段时长从185~265 s不等。每名受试者进行3次实验,且在两次实验之间受试者有一周的休息时间。SEED数据总共收集了45个实验,共计675次试验(每个情绪类别分别225次试验)数据。

在SEED提取的62个脑电电极数据中,为了平衡数据集的复杂性,参考文献[8]的方式,选择了32个电极数据用于特征提取,所选的电极如图1所示。由于SEED数据集只包含675次试验,而训练深度学习模型需要足够多的数据,因此本文使用一个3 s非重叠的时间窗将每次试验数据分为60段,最终得到40 500个情感实例,每个受试者的情感实例为2 700个。为了与现有研究比较,本文采用的SEED实验数据是经过预处理的。预处理是将原始脑电数据下采样到200 Hz,并使用0~75 Hz带通滤波器以去除噪声和伪迹。




图1 EEG信号采集和特征提取

Fig.1 EEG signal acquisition and feature extraction

1.2 连通特征图

EEG信号采集和特征提取如图1所示。连接矩阵 $C(i,j)$ 表示第 i 通道和第 j 通道的EEG信号相关性,矩阵大小为 $1 \times 32 \times 32$ 。使用以下3种连接性测量算法来计算脑电电极序列的相邻通道之间的连接性值:

(1) 皮尔逊相关系数

PCC可以将两个信号之间的线性关系表示为从-1到1的连续数,其中1和-1表示完全正负相关,0表示完全不相关。相关系数的绝对值越接近1,相关性越强;相关系数越接近0,相关性越弱。它的计算公式为

$$PCC = \frac{\text{cov}(w, z)}{\sigma_w \sigma_z} \quad (1)$$

式中: w 和 z 表示来自不同通道的两个EEG信号, $\text{cov}(w, z)$ 为 w 和 z 之间的协方差, σ_w 和 σ_z 分别为 w 和 z 的标准差。

(2) 锁相值

脑电信号通常包含多个频率成分,而这些频率成分在不同的脑区之间可能存在相位同步的现象。使用PLV来估计不同电极脑电信号之间瞬时相位关系,计算公式为

$$PLV = \frac{1}{M} \left| \sum_{n=1}^M e^{j\Delta\Phi_n} \right| \quad (2)$$

式中: M 为EEG采样点, $\Delta\Phi_n$ 为第 n 个采样点相位差。该方法使用Hilbert-Huang^[11]变换计算两个脑电信号的相位差。

(3) 互信息

MI是计算两个变量之间共享信息的信息度量。它可以用来度量两个变量之间的依赖程度,即一个变量包含的关于另一个变量的信息量。两个随机变量 w 和 z 之间的MI方程为

$$MI(w, z) = H(w) + H(z) - H(w, z) \quad (3)$$

式中: $H(w)$ 和 $H(z)$ 分别表示 w 和 z 的香农熵^[12], $H(w, z)$ 表示联合熵。互信息的取值范围是非负的,即 $0 \leq MI(w, z) < \infty$ 。当MI等于0时,表示两个变量是独立的;MI的值越大,表示两个变量之间的相关性越强。

1.3 残差神经网络

近年来,深度神经网络在图像识别领域取得了一系列的突破。随着更复杂的神经网络模型被引入,出现了两个需要解决的问题:一是模型复杂度增加需要更强大的算力;二是网络层堆叠和深度增加导致的网络性能下降。He等^[13]在2016年提出残差神经网络(Residual neural network, ResNet),在不增加网络模型复杂度的情况下解决了深度模型性能下降问题。

ResNet的核心是残差学习模块,ResNet最显著的特点是其快捷连接,该算法只需进行恒等映射,无需增加额外的参数和增加计算复杂度。如图2所示,输入特征表示为 x ,一层或多层输出特征表示为 $f(x)$, $f(x) + x$ 的公式可以通过快捷连接的前馈神经网络实现。本文引入残差学习模块来优化卷积神经网络。通过残差学习模块的跳跃连接,将梯度传递到下层,可以在相对简单的模型中获得更深层次的特征。




图2 ResNet示意图

Fig.2 Schematic diagram of ResNet

2 残差卷积神经网络

2.1 网络结构

本文提出的残差卷积神经网络模型如图3所示。模型的输入是通过上述方法计算的3种连通性矩阵。首先经过一个由卷积核、批归一化和ReLU激活函数组成的卷积层,其中卷积核的大小为 3×3 ,步长和边界补零填充为1。然后将学习的特征输入残差模块中,使用两个残差模块来提取深层特征。接着将提取的深层特征输入全连接层,全连接层包含了最大池化、Flatten、Dropout和Linear。为了降低计算量和内存需求,首先将提取的深层特征经过核大小为 2×2 ,步长为2的最大池化层。再使用Flatten函数将特征展平,并加入Dropout来解决训练中出现的过拟合现象。使用两个连续的Linear函数降低特征维度得到特征向量。最后,将最终的特征向量输入到SoftMax层进行情绪类别预测,输出为情绪识别的准确率。SoftMax可以将输入向量转换为每个类别的概率分布,每个类别的预测概率在0到1之间,并且所有类别的概率总和为1,可定义为




图3 残差卷积网络模型

Fig.3 Residual convolutional network model

$$\text{SoftMax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^N e^{z_j}} \quad (4)$$

式中: $\text{SoftMax}(z_i)$ 表示第 i 类别概率, z_i 为第 i 个元素值, N 为分类类别数量。

如图3所示, 残差块结构包含两个卷积核、3个批归一化、ReLU和快捷连接, 其中快捷连接在图中表示为直线。残差映射可表示为

$$y = F(x, \{W_i\}) + x \quad (5)$$

式中: x 和 y 分别表示残差块的输入和输出; $F(x, \{W_i\})$ 表示需要学习的映射, 其中 W_i 表示残差模块中卷积层的权重矩阵; $F(\cdot) + x$ 表示快捷连接。

2.2 网络参数

本文所用残差卷积模型的步长和大小如表1所示。采用随机抽取的方式, 将80%的数据用作训练模型, 20%的数据用作测试模型。选择基于Adam的随机梯度下降算法来最小化模型的交叉熵损失。学习率初始设置为0.000 1, 并根据模型损失值大小进行迭代。将Batch_size设置为128, Epoch为50开展训练。提出的残差卷积神经网络是基于Pytorch框架实现的, 并在Nvidia GeForce GTX 1660S上进行训练。

表1 残差卷积网络模型步长和大小

Table 1 Stride and size of residual convolutional network model

层名	内核或池的大小	输出大小
卷积层	3×3	$64 \times 32 \times 32$
残差块 1	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$64 \times 32 \times 32$
残差块 2	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$128 \times 16 \times 16$
池化层	2×2	$128 \times 8 \times 8$
全连接层	—	3

3 实验结果与分析

3.1 实验结果

为了选择出适用于情绪识别的连通特征, 在SEED数据集上测试了PCC、PLV和MI这3种连通特征, 并比较了准确率和 F_1 score。以受试者1为例, 图4展示了三分类SCF-RCNN模型损失值和准确率曲线。随着训练迭代周期的增长, 训练准确率、测试准确率随之增加, 并在周期达到20时趋于稳定。其




图4 SCF-RCNN模型损失值和准确率曲线

Fig.4 Loss value and accuracy curves for SCF-RCNN model

中,PLV收敛速度快于其他特征,在训练过程中表现为损失函数下降快,同时准确率也迅速上升。15名受试者的连通特征在残差模型下的表现如图5所示,t_SNE如图6所示。PCC、PLV和MI的平均分类准确率和 F_1 _score分别为69.04%和68.96%、74.36%和74.27%、93.57%和93.56%。PLV特征准确率和 F_1 _score显著高于PCC特征,表明情绪激发下电极间的相位关系比线性关系更重要。PLV的准确率和 F_1 _score还高于MI特征,这是因为PLV可以分离信号中的相位和幅度分量,可以更好地测量信号之间的同步性。因此,对于空间连通特征,PLV特征相较于PCC、MI特征与脑电的情绪关系更密切。

下面针对PLV特征开展进一步的研究。绘制了一个三类模型的准确率图,显示模型在每个类别上的分类准确率,从而提供对模型性能在不同类别上的分析和比较,如图7所示。在积极情绪状态下,模型平均准确率达到95.46%,高于中性和消极情绪时的92.40%和92.96%。除第2、3、5和14受试者外,其他受试者在积极情绪分类上显示比其他两种情绪更高的准确率。这结果表明对于大多数受试者而言,在积极情绪状态下,其脑电信号中可能包含更多有助于准确分类的信息。这种差异可能是因为积极情绪对脑电信号产生了特定的影响,例如更明显或更稳定的神经活动,使得模型能够更准确地捕捉和识别这些特征。而第2、3、5和14号受试者积极情绪的偏低准确率可能是由于不同情绪激发下人脑差异所致。每个人的情绪体验都是独特的,这可能导致其脑电信号在各种情绪状态下表现出不同的模式。这些个体差异需要研究者进一步调整或改进模型,以提高模型的泛化能力。




图5 连通特征在残差模型下的表现

Fig.5 Representation of connectivity features under residual mode




图6 连通特征 t_SNE

Fig.6 Connectivity features of t_SNE




图7 受试者不同情绪下分类准确率

Fig.7 Classification accuracy of subjects under different emotions

3.2 与其他分类算法比较

为了选择适合于SEED数据集分类任务的机器学习方法,选取K近邻(K-nearest neighbor, KNN)、支持向量机(Support vector machine, SVM)、卷积神经网络(Convolutional neural networks, CNN)以及本文提出的SCF-RCNN分类方法进行研究对比分析。对各模型受试者的平均分类准确率和标准差进行评估,结果如表2所示,混淆矩阵如图8所示。根据实验结果,KNN方法在SEED数据集分类上取得了89.78%的准确率,标准差为4.53%;SVM方法达到了86.32%的准确率,标准差为4.75%;CNN方法的准确率为90.13%,标准差为4.44%;而本文提出的方法在SEED数据集分类任务上取得了93.38%的准确率和3.35%的标准差。

本文提出的残差网络分类模型在数据集上取得了显著的性能优势。相对于其他方法,残差网络具备强大的特征表示能力,能够捕捉到数据中更复杂的特征,从而提高分类准确率和模型的泛化能力。残差网络具有良好的可扩展性和适应性,可通过堆叠多个残差块构建深层网络结构,适用于复杂的计算机视觉任务。这对于SEED数据集分类问题具有重要意义,并为机器学习在情绪分类的应用中提供了参考。

3.3 与类似神经网络比较

将本文研究的方法与已有的使用SEED数据集的研究成果进行对比,结果如表3所示。其中文献[14-16]均是关于空间连通特征的研究。文献[14]提出了一种基于PLV图卷积神经网络(P-GCNN)的

表2 不同分类算法下的准确率和标准差

Table 2 Accuracy and standard deviation under different classification algorithms			%
算法	平均准确率	标准差	
KNN	89.78	4.53	
SVM	86.32	4.75	
CNN	90.13	4.44	
本文方法	93.38	3.35	




图8 混淆矩阵
Fig.8 Confusion matrix

表3 本文方法与使用SEED数据集的现有研究比较

Table 3 Comparison of the proposed method with existing studies using SEED datasets				
已有研究	年份	输入	模型	准确率/%
文献[14]	2019	PLV	GCNN	84.35
文献[15]	2019	PCC+SC	SVM	87.04
文献[16]	2024	asPLV+DE	SVM	96.57
文献[17]	2013	DE	SVM	84.22
文献[18]	2023	DE	基于注意力的混合深度学习模型	92.74
文献[19]	2023	TQWT	HCRNN	95.33
本文	2024	PLV	残差卷积神经网络	93.38

多通道脑电信号情绪识别方法,其基本思想是利用基于PLV的脑神经网络将多通道脑电信号特征建模为图形信号,并在此基础上进行脑电信号的情绪分类;文献[15]提出了一种关键子网络的选择方法,并将其用于SEED数据集情感分类,从脑电信号中提取PCC和频谱相干性(Spectral coherence, SC)构建连通矩阵,并使用关键子网络选择的方法来识别不同主题之间的共同情感相关的连接模式,最终实验结果表明,其分类性能优于传统的功率谱特征和微分熵特征;文献[16]基于PLV提出一种新的特征平均子频率锁相值(averaged sub-frequency PLV, asPLV),asPLV是通过Morlet小波分解来构造的,而不是Hilbert变换,并且将asPLV与微分熵相结合,在SEED数据集的情绪分类中获得了 $(96.57 \pm 1.58)\%$ 的平均分类准确率。

为了验证空间连通特征的有效性,本文与其他人工特征进行了比较。在脑电信号情绪识别领域,已有很多研究都是围绕微分熵展开的。文献[17]首次提出微分熵的概念,并与传统的频域特征(ES、DASM、RASM和ASM)进行比较,结果表明,DE比传统的特征更适合于情绪识别;文献[18]提出了一种基于注意力的混合深度学习模型,首先提取脑电信号的微分熵特征并根据电极位置构造矩阵,再使用卷积核提取特征,并引入注意力机制为不同频带分配自适应权重,最后使用长短期记忆网络(Long short term memory, LSTM)和时间注意力机制提取时间信息,其在SEED数据集上的准确率为92.74%;文献[19]提出一种新的情绪识别框架,其采用可调Q因子小波变换将脑电信号分解为子带,并从中提取平均绝对值和微分熵作为可调Q因子小波变换(Tunable Q-factor wavelet transform, TQWT)特征,最后引入由CNN和LSTM融合的HCRNN模型来训练,达到了 $(95.33 \pm 1.39)\%$ 的准确率。

本文从SEED数据集中提取了PLV特征,构建了一个残差卷积神经网络模型对其提取特征和分类,平均准确率达到93.38%。与同样使用PLV特征的文献[14-15]相比,所提出的残差卷积网络模型在准确率上有一定程度的提高,证明了本文方法的优越性。文献[16]采用了PLV和DE相融合的策略,其准确率高出本文仅使用PLV的方法。该研究的结果表明,PLV和DE的多尺度特征融合方法可以利用不同层次的特征,相比于仅使用只关注相位信息的PLV,多尺度特征融合能够更全面地捕捉数据特征,从而克服了单一特征的局限性,提高模型的性能。参考该文献的成果,可以在以后的研究中引入类似的融合策略,以进一步提高模型的准确率。与使用DE特征的研究相比,本文的结果在准确率方面高于文献[17-18]。较于文献[19]提出的方法,尽管该方法准确率优于本模型,但它采用了复杂的HCRNN模型,并且需要大量时间和计算资源来实现。而本文方法在保持一定准确率的同时,更加轻量化且高效,可以在较短时间内完成情绪识别任务,这对于资源受限的环境或实时应用场景来说,具有重要意义。因此,本文所提出的方法在情绪识别领域具有可比较的有效性。

4 结束语

本文提出了一种基于残差卷积神经网络的情绪识别方法,利用该方法提取情绪的空间连通特征。实验结果表明,该方法对SEED数据集的积极、中性和消极情绪分类的平均准确率可达93.38%,优于现有的模型。本工作是在基于脑电信号的情绪识别方面的积极尝试,虽然取得了一些结果,但仍有一些问题值得进一步探讨:(1)PLV特征只考虑了脑电电极间的相位特征,需要进一步研究功能性脑网络连接特征,包括不同脑区之间的连接、频率特征等;(2)可考虑引入多尺度特征融合策略,以进一步提高模型的准确率,例如,连接特征融合微分熵或功率谱密度,以便更全面地描述情绪信号。总之,将继续研究情绪识别领域,探索更有效的特征提取方法,并不断改进该模型。

参考文献:

- [1] PANDEY R, CHOUBEY A K. Emotion and health: An overview[J]. SIS Journal of Projective Psychology & Mental Health, 2010(17): 135-152.

- [2] 李存波, 杨蕾, 陈昭瑾, 等. 基于脑电网络图特征的情绪识别研究[J]. 数据采集与处理, 2023, 38(4): 815-823.
LI Cunbo, YANG Lei, CHEN Zhaojin, et al. Emotion recognition based on graph features extracted from EEG networks[J]. *Journal of Data Acquisition and Processing*, 2023, 38(4): 815-823.
- [3] 张进, 许子明, 周月莹, 等. 基于脑电的虚拟现实诱发下情绪状态分类[J]. 数据采集与处理, 2021, 36(6): 1226-1236.
ZHANG Jin, XU Ziming, ZHOU Yueying, et al. Emotion classification induced by virtual reality based on EEG[J]. *Journal of Data Acquisition and Processing*, 2021, 36(6): 1226-1236.
- [4] 李锦瑶, 杜肖兵, 朱志亮, 等. 脑电情绪识别的深度学习研究综述[J]. 软件学报, 2023, 34(1): 255-276.
LI Jinyao, DU Xiaobing, ZHU Zhiliang, et al. Deep learning for EEG-based emotion recognition: A survey[J]. *Journal of Software*, 2023, 34(1): 255-276.
- [5] MOON S E, CHEN C J, HSIEH C J, et al. Emotional EEG classification using connectivity features and convolutional neural networks[J]. *Neural Networks*, 2020, 132: 96-107.
- [6] WANG Z M, ZHANG J W, HE Y, et al. EEG emotion recognition using multichannel weighted multiscale permutation entropy[J]. *Applied Intelligence*, 2022, 52(10): 12064-12076.
- [7] MOON S E, CHEN C J, HSIEH C J, et al. Emotional EEG classification using connectivity features and convolutional neural networks[J]. *Neural Networks*, 2020, 132: 96-107.
- [8] AKHAND M A H, MARIA M A, KAMAL M A S, et al. Emotion recognition from EEG signal enhancing feature map using partial mutual information[J]. *Biomedical Signal Processing and Control*, 2024, 88: 105691.
- [9] LI T, FU B, WU Z, et al. EEG-based emotion recognition using spatial-temporal-connective features via multi-scale CNN[J]. *IEEE Access*, 2023, 11: 41859-41867.
- [10] 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.
- [11] HUANG N E. Hilbert-Huang transform and its applications[M]. Singapore: World Scientific, 2014.
- [12] SHANNON C E. A mathematical theory of communication[J]. *The Bell System Technical Journal*, 1948, 27(3): 379-423.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2016: 770-778.
- [14] WANG Z, TONG Y, HENG X. Phase-locking value based graph convolutional neural networks for emotion recognition[J]. *IEEE Access*, 2019, 7: 93711-93722.
- [15] WU X, ZHENG W L, LU B L. Identifying functional brain connectivity patterns for EEG-based emotion recognition[C]//*Proceedings of the 9th International IEEE/EMBS Conference on Neural Engineering (NER)*. [S.l.]: IEEE, 2019: 235-238.
- [16] XU J, QIAN W, HU L, et al. EEG decoding for musical emotion with functional connectivity features[J]. *Biomedical Signal Processing and Control*, 2024, 89: 105744.
- [17] DUAN R N, ZHU J Y, LU B L. Differential entropy feature for EEG-based emotion classification[C]//*Proceedings of the 6th International IEEE/EMBS Conference on Neural Engineering (NER)*. [S.l.]: IEEE, 2013.
- [18] ZHANG Y, ZHANG Y D, WANG S. An attention-based hybrid deep learning model for EEG emotion recognition[J]. *Signal, Image and Video Processing*, 2023, 17: 2305-2313.
- [19] ZHONG M, YANG Q, LIU Y, et al. EEG emotion recognition based on TQWT-features and hybrid convolutional recurrent neural network[J]. *Biomedical Signal Processing and Control*, 2023, 79: 104211.

作者简介:



张学军(1969-), 通信作者, 男, 博士, 教授, 硕士生导师, 研究方向: 智能信息处理、脑机接口技术及无线射频识别技术等, E-mail: xj-zhang@njupt.edu.cn。



付从伟(1999-), 男, 硕士研究生, 研究方向: 智能信息处理、脑电信号处理技术, E-mail: fucowe@qq.com。