

基于 GC 特征和脑区频段 Transformer 模型的 EEG 情感识别

张睿, 张雪英*, 陈桂军, 黄丽霞

(太原理工大学电子信息与光学工程学院, 山西 太原 030024)

摘要: 人的情感在发生变化时, 不同通道间脑电图(EEG) 信号会交互作用, 且不同频段交互特征存在分脑区特性。为提取全脑交互性特征和充分捕获特征在不同脑区频段间依赖性, 提出主对角线非 0 的格兰杰因果(GC)特征提取方法和分脑区分频段的 Transformer 模型。首先, 针对计算自身因果度量值时 GC 值为 0 的问题, 通过改进 GC 算法, 提取出 EEG 信号各通道非 0 的自身因果信息。然后, 针对常用情感识别模型总是关注局部特性, 缺乏全局视野的问题, 根据不同频段下同脑区间存在关联的特点, 对因果特征进行脑区频段划分, 使用脑区频段 Transformer 模型将特征进行不同脑区不同频段特征间的依赖性和贡献捕获。在 TYUT3.0 数据集上的实验结果表明, 在使用提出的脑区频段 Transformer 模型分类识别时, 主对角线非 0 GC 矩阵相比于常用 GC 矩阵, 平均识别准确率提升了约 1.59 个百分点, 说明了所提出特征的优越性; 在使用提出的主对角线非 0 GC 矩阵作为特征时, 提出的脑区频段 Transformer 模型平均准确率达到 94.50%, 较已有的模型平均识别准确率提升了 1.89 百分点, 说明了脑区频段划分特征依赖性 & 全局融合思路的有效性。

关键词: 格兰杰因果; 脑区; 频段; Transformer 模型; 脑电图情感识别

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0068745

Emotion Recognition in EEG Based on Granger Causality and Brain Regions Frequency Bands Transformer Model

ZHANG Rui, ZHANG Xueying*, CHEN Guijun, HUANG Lixia

(College of Electronic Information and Optical Engineering, Taiyuan University of Technology, Taiyuan 030024, Shanxi, China)

【Abstract】 When human emotions change, the Electroencephalogram (EEG) signals across different channels interact, and distinct brain regions exhibit characteristic interaction features in different frequency bands. To extract global interactive features and comprehensively capture the interdependence of features across various brain regions and frequency bands, this study proposes a principal diagonal nonzero Granger Causality (GC) feature extraction method and a region-specific frequency division Transformer model. First, by addressing the issue of GC values being zero when calculating self-causality measures, this study enhances the Granger causality algorithm to extract nonzero self-causal information for each channel of EEG signals. Subsequently, to overcome the common limitation of emotion recognition models that focus on local characteristics and lack a global perspective, this study leverages the observed associations between different brain regions within the same frequency band. The method partitions causality features into brain frequencies and employs a brain-frequency division Transformer model to capture the interdependence and contribution of features across different brain regions and frequency bands. Experimental results on the TYUT3.0 dataset demonstrate that when using the proposed region-specific frequency division Transformer model for classification, the principal diagonal non-zero GC matrix, compared to commonly used GC matrices, achieves an average recognition accuracy improvement of approximately 1.59 percentage points. This suggests the superiority of the proposed features. When using the principal diagonal non-zero GC matrix as features, the proposed region-specific frequency division Transformer model achieves an average accuracy of 94.50%, surpassing existing models by more than 1.89 percentage points on average recognition accuracy. This indicates the effectiveness of the approach in globally integrating features with dependencies under brain region-specific frequency divisions.

【Key words】 Granger Causality(GC); brain regions; frequency bands; Transformer model; Electroencephalogram (EEG) emotion recognition

收稿日期: 2023-11-01 修回日期: 2024-01-22

基金项目: 国家自然科学基金(62201377, 62271342)。

通信作者 E-mail: * tyzhangxy@163.com

0 引言

情感对人类生活有很大影响,涉及各个方面,例如娱乐、工作和人际交往等,情绪也与人类身心健康相关^[1]。近年来,情感计算吸引了从神经科学到计算机工程等众多跨学科领域越来越多的关注^[2],过去对情感的判断一般通过面部表情^[2-3]、声学特征^[4-5]等外在行为,但这些外在行为容易受到多种外部因素如生活习惯和文化背景等的影响,在一定程度上来说并不可靠^[5-6],不能客观反映个体真实情感^[7],加剧了情感识别研究的难度。随着科技的发展,情感识别的对象逐渐变得更加有效真实,具有较强不可伪造性的信号,其中基于大脑信号的情感识别研究近年来成为情感识别领域的热点。情感是大脑皮层和皮下神经中枢协同活动的结果,脑电图(EEG)信号作为一种典型的反映大脑皮层神经元电活动的信号,由于其具有非侵入性、灵活便携、价格相对较低等特点^[8],近年来在情感识别领域备受青睐^[9]。

在现阶段 EEG 情感识别特征中,时间和频谱特征常被用来对情感进行分类。而情感识别传统的时频域特征,作为情感识别网络的输入都有同一个局限性,那就是只考虑来自单个电极的信号或特征,不能反映大脑内部信息的交互特性^[10],在神经科学领域,不同电极之间的关系已被证明是脑功能的重要线索^[11-12]。因效性脑网络特征可以有向揭露太脑区域间的潜在因果机制,常用的因效性特征包括转移熵(TE)^[13]和格兰杰因果(GC)度量等。其中,GC 度量特征作为一种常见的因效性脑网络特征,用于计算两个通道之间的因果流向,近年来得到研究人员广泛应用,如文献^[14]使用不同脑区不同频段的 GC 值检查有效连接性,发现 β 和 γ 频段基于 EEG 的连接可以为通过音乐表演进行情感传递的网络状态;文献^[15]提取了 EEG 信号半脑内和半脑间跨频段的 GC 特征,发现左右半球跨频段脑电信号之间存在显著因果关系。然而,目前基于 GC 特征的 EEG 情感识别存在一个问题,即忽略了通过 GC 度量值计算每个通道信号自身 GC 因果值时结果恒定为 0,在送入情感识别网络时 0 的特征并不能带来信息。

随着深度学习的发展,研究人员针对人类情感的深度学习模型展开了一系列应用。情感识别领域常用的深度识别模型如卷积神经网络(CNN)^[16]、递归神经网络(RNN)^[17]等,大都集中在空间或时间上的局部邻域^[18],难以捕获到远距离脑信号的依赖关

系。近几年发展起来的 Transformer 模型是一种基于自注意力机制的能够进行长距离依赖性捕获的深度学习方法。根据文献^[15],不同频段脑区间存在关联性,在不同频段下^[19-20],不同脑区对情感识别有不同的贡献度。总之,EEG 的脑区频段有不同的贡献度,而现有 Transformer 模型均未考虑不同频段不同脑区间的相互依赖性和贡献度。因此,如何利用不同频段、不同脑区捕获远端的特征是一个值得研究的问题。

本文提出对角线 GC(DGC)特征,即改进大脑信号自身因果度量计算后得到 GC 特征的有效性,以及根据不同频段不同脑区间的依赖关系提升 DGC 特征情感识别准确率。首先提取两两不同电极通道间的 GC 特征值作为 DGC 特征非主对角线,提取通道自身的非 0 因果特征值作为 DGC 特征主对角线,验证 DGC 特征的有效性;然后将提取到的 DGC 特征送入提出的脑区频段 Transformer(BFT)情感识别模型中,充分捕获不同频段不同脑区间的依赖关系并强调不同频段、脑区提供的不同的情绪贡献,使分类识别准确率得到提升,并将模型中得出的依赖关系可视化输出进行分析。

1 相关工作

脑电情感识别过程有两个重要部分,即特征提取和分类识别,本节对 GC 特征和 Transformer 分类模型进行介绍。

1.1 格兰杰因果

格兰杰因果(GC)关系在半个多世纪前被引入,已经成为许多应用领域分析时间序列因果性的流行工具,包括经济学、金融学、基因组学和神经科学^[21]。在神经科学中,研究人员利用 GC 试图了解大脑某个区域是否与另一个区域的活动相关。

诺贝尔经济学奖得主 GRANGER^[22]于 1969 年提出了一个利用时间序列固有的时间顺序的框架,得出过去导致未来的因果陈述。该框架评估一个序列是否可以预测另一个序列:如果序列 x_j 在当前时间的自回归预测误差的方差通过包含序列 x_i 的过去而减少,则序列 x_i 被认为对另一个序列 x_j 有因果影响。两个时间序列的作用可以颠倒,以解决相反方向的因果影响问题,因此得到的相互作用可能是相互的,也可能是单向的。

用 GC 模型能够提取大脑两两区域间的双向因果特征,近年来受到研究者广泛关注。文献^[23]提取了 GC 特征并进一步使用方向梯度直方图(HOG)算法提取特征;文献^[24]提出一种在脑区

GC 矩阵基础上减少矩阵维度的新方法;文献[15]提出了一种基于左右半球跨频 GC 特征提取和融合的脑电情感识别系统;文献[25]提出了一种基于条件 GC 检验的因果网络情绪识别方法。GC 作为一种有效的连接方法,已被广泛用于发现情感脑电信号的因果关系,然而上述研究在 GC 特征基础上扩展应用,都没有考虑到区域自身的因果性特征。因此,本文采用基于其他区域的回归模型来量化当前区域对自身的因果影响,得到包含更多信息的因果特征,以期获得更好的识别结果。

1.2 Transformer 模型

Transformer 模型包含编码器和解码器两个部分,本文仅使用编码器模块实现频段脑区融合。Transformer 编码器单元如图 1 所示。




图 1 Transformer 编码器单元
Fig.1 Transformer encoder unit

首先将输入的一系列一维向量进行线性变换得到输入编码,再通过位置编码得到带有位置信息的序列编码表示,接下来进行多头自注意力计算得到每个位置对应序列对于其他位置序列的重要性和关联性权重,这样每个头可以得到一个加权和向量,最后将多头注意力的输出作为输入送入前馈网络。总的来说,编码单元主要由多头自注意力层和前馈网络层组成,层与层之间使用残差和归一化操作连接。

Transformer 编码器单元中的自注意力机制为频段脑区间依赖学习提供了可能,这里简要介绍 Transformer 编码器单元中自注意力机制的实现,如图 2 所示。一系列一维向量的序列编码表示经过 3 个矩阵 W_v 、 W_k 、 W_q 映射得到查询矩阵 V 、键矩阵 K 和值矩阵 Q ,两两序列间的相关依赖通过 K 和 Q 的点积获得。根据计算出的相关性矩阵权重参数

对 V 进行加权求和,最后每个序列都是根据与其他序列两两依赖性相互融合得到的新序列。




图 2 自注意力机制

Fig.2 Self-attention mechanism

为了加强对远距离依赖性捕获,基于自注意力机制的 Transformer 模型受到关注。在文献[26]使用通道间 Transformer 模型,全局性融合全脑所有通道特征,文献[27]提出一种层次空间学习 Transformer 模型 (HSLT),进行先脑区内 Transformer 后脑区间 Transformer 的远距离依赖性捕获模型,文献[28]使用 CNN 和 Transformer 级联的 CNN-Transformer 模型,先使用 CNN 提取局部特征,后使用 Transformer 进行全局融合。这些研究结果表明,Transformer 是一种分类 EEG 特征的有效模型。

2 特征提取与情感识别模型

情感识别系统框架如图 3 所示。其中包括 TYUT3.0 情感数据集的预处理步骤、DGC 特征提取和针对全局视野下脑区频段融合的 BFT 情感识别模型 3 个部分。




图 3 情感识别系统框架

Fig.3 Framework of emotion recognition system

2.1 数据集及预处理

TYUT3.0 数据集是由作者所在团队构建的一个视频诱发情感多模态数据集,受试者为男女各半共 50 名在校大学生和研究生,50 名被试者均为中国人,每名被试者参与 60 个情感诱发实验,诱发材料为悲伤、快乐、平静、恐惧各 15 个 1~2 min 时长的视频片段,其中采集全脑 EEG 信号共 62 个导联,EEG 信号采样率为 1 000 Hz。具体细节如表 1 所示。

表 1 TYUT3.0 情感数据集描述

Table 1 The description of TYUT3.0 emotion dataset

类型	描述
被试者	50 名 22~28 周岁在校生(男女各 25 人)
情感类型	悲伤、快乐、平静和恐惧
诱发材料	不同情感各 15 个视频片段
采集信号	62 个通道 EEG 信号
信号采样率	EEG:1 000 Hz fNIRS:11 Hz

EEG 信号预处理步骤包括:使用平均参考进行重参考,4~45 Hz 滤波去除市电干扰提取与情感相关的频率,基线校正抑制电压偏移,使用独立成分分析(ICA)去伪迹等。在预处理操作后,为减少数据量并提高运算速度,将 EEG 信号降采样至 200 Hz,并使用带通滤波器将降采样后的 EEG 信号划分 4 个频段: θ (4~8 Hz), α (8~12 Hz), β (12~30 Hz), γ (30~45 Hz)。最后,使用 3 s 窗长、1.5 s 步长的滑动时间窗口对分频后的 EEG 信号进行样本划分。

2.2 DGC 特征提取

DGC 特征提取不同频段下两两 EEG 信号间的因果特征,提取过程如图 4 所示。首先将 EEG 信号进行分频段操作,然后分别计算分频段后信号的 DGC 特征。DGC 特征是基于多通道信号格兰杰因果度量值计算公式得到的,衡量的是通道间的因果性。




图 4 DGC 特征提取过程

Fig. 4 The process of DGC feature extraction

本文采用微分熵(DE)特征、功率谱密度(PSD)特征等 EEG 特征,都是针对单通道信号计算的特征,缺少通道间交互信息,而 DGC 特征是一种反映时域信号信息流方向的因果特征。DGC 特征提取 EEG 两两通道间的因果特征,特征结构如图 4 所示,每个频段提取大小为 62×62 的二维

特征图,二维矩阵的两个维度都表示排序相同的 62 个通道。

DGC 特征可以分为非主对角线上特征和主对角线上特征两个部分。非主对角线上 DGC 特征表示不同通道间的因果度量值,而主对角线上 DGC 特征表示通道自身的因果度量值。

首先介绍非主对角线上 DGC 特征提取基本思想:两个通道 EEG 信号时间序列 X 和 Y ,当且仅当基于 X 和 Y 的过去值对 Y 的当前值的预测优于仅用 Y 的过去值对 Y 的当前值的预测,那么 X 被称为 Y 的 GC 原因。其因果度量的数学定义是单变量向量自回归(VAR)模型和双变量 VAR 模型对应的残差方差的比值再取对数。VAR 模型公式如式(1)所示,因果度量值公式如式(2)所示:

$$\begin{cases} Y(t) = \sum_{i=1}^L a_{1i} Y(t-i) + \varepsilon_Y \\ Y(t) = \sum_{i=1}^L a_{2i} Y(t-i) + \sum_{i=1}^L b_{2i} X(t-i) + \eta_{XY} \end{cases} \quad (1)$$

$$F_{X \rightarrow Y} = \ln \left(\frac{\sigma_{\varepsilon_Y}}{\sigma_{\eta_{XY}}} \right) \quad (2)$$

式中: ε_Y 表示使用 Y 的过去值对 Y 当前值预测的预测误差; η_{XY} 表示使用 Y 的过去值和 X 的过去值对 Y 当前值预测的预测误差; σ_{ε_Y} 和 $\sigma_{\eta_{XY}}$ 分别表示两个预测误差 ε_Y 和 η_{XY} 的方差。当 $\sigma_{\varepsilon_Y} = \sigma_{\eta_{XY}}$ 时, $F_{X \rightarrow Y} = 0$,表示 X 对 Y 不存在格兰杰因果关系;当 $\sigma_{\varepsilon_Y} > \sigma_{\eta_{XY}}$ 时, $F_{X \rightarrow Y} > 0$,说明 X 有助于 Y 的预测,即 X 对 Y 存在格兰杰因果关系。

以上因果度量值公式计算两两不同通道之间的因果度量值时一般为非 0,但由式(1)和式(2)可知,当 $Y=X$,即当计算自身对自身的因果度量值时,计算结果为 0。恒为 0 的特征值输入识别网络后存在冗余且不能为情感识别提供贡献,因此在计算自身对自身的因果度量值时改动因果度量计算公式,得到主对角线上非 0 的 DGC 特征矩阵。

主对角线上 DGC 特征提取基本思想是:两个通道 EEG 信号时间序列 W 和 V ,当且仅当基于 W 和 V 的过去值对 V 的当前值的预测优于仅用 W 的过去值对 V 的当前值的预测,那么 V 被称为 V 的自身 GC 原因。其因果度量的数学定义为单变量 VAR 模型和双变量 VAR 模型对应的残差方差的比值再取对数。VAR 计算模型和度量值计算公式如式(3)和式(4)所示:

$$\begin{cases} V(t) = \sum_{i=1}^L d_{1i} W(t-i) + \varepsilon_W \\ V(t) = \sum_{i=1}^L c_{2i} V(t-i) + \\ \sum_{i=1}^L d_{2i} W(t-i) + \eta_{WV} \end{cases} \quad (3)$$

$$F_{V \rightarrow V} = \ln \left(\frac{\sigma_{\varepsilon_W}}{\sigma_{\eta_{WV}}} \right) \quad (4)$$

式中: ε_W 表示使用 W 的过去值对 V 当前值预测的预测误差; η_{WV} 表示使用 V 的过去值和 W 的过去值对 V 当前值预测的预测误差; σ_{ε_W} 和 $\sigma_{\eta_{WV}}$ 分别表示两个预测误差 ε_W 和 η_{WV} 的方差。当 $\sigma_{\varepsilon_W} = \sigma_{\eta_{WV}}$ 时, $F_{V \rightarrow V} = 0$, 表示 V 对自身不存在格兰杰因果关系; 当 $\sigma_{\varepsilon_W} > \sigma_{\eta_{WV}}$ 时, $F_{V \rightarrow V} > 0$, 说明在已有 W 过去值的情况下, V 自身的过去值有助于 V 当前值的预测, 即 V 对自身存在因果关系。

2.3 BFT 情感识别模型

大脑对不同情绪的处理机制可以通过不同脑区的激活来反映^[29], 因此, 脑区激活的差异可以提供区分情绪的信息特征, 为了提升 DGC 特征的情感识别准确率, 设计 BFT 情感识别模型以捕获 DGC 特征不同脑区不同频段间的依赖性。图 5 所示为提出的 BFT 情感识别系统框图(彩色效果见《计算机工程》HTML 版, 下同), 主要包括频段脑区划分编码与频段脑区依赖学习两个部分。

频段脑区划分编码部分完成的功能为将得到的 DGC 特征按照频段脑区划分并得到统一的输入形式, 频段脑区依赖学习部分为 Transformer 编码器, 实现不同频段不同脑区间依赖性融合。

根据文献[27], 将脑区划分成 9 个部分。TYUT3.0 数据集 62 个导联 EEG 信号、9 个脑区划分后对应的电极分组如表 2 所示。

表 2 EEG 信号多脑区对应的电极组

Table 2 The electrode clusters corresponding to EEG signals multi-brain region

脑区	电极组
前额叶(PF)	FPZ, FP1, FP2, AF3, AF4
额叶(F)	F7, F5, F3, F1, FZ, F2, F4, F6, F8
左颞叶(LT)	FT7, FC5, T7, C5, TP7, CP5
中央区(C)	FC3, FC1, FCZ, FC2, FC4, C3, C1, CZ, C2, C4
右颞叶(RT)	FC6, FT8, C6, T8, CP6, TP8
左顶叶(LP)	P7, P5, P3, PO7, PO5, PO3
顶叶(P)	CP3, CP1, CPZ, CP2, CP4, P1, PZ, P2, POZ
右顶叶(RP)	P4, P6, P8, PO4, PO6, PO8
枕叶(O)	CB1, O1, OZ, O2, CB2




图 5 BFT 情感识别模型系统框图

Fig.5 Block diagram of BFT emotion recognition model system

将 DGC 特征按照表 2 进行脑区划分, 考虑到脑区对应的电极组内个数不同的问题, 将同一频段下每个脑区内的特征进行融合, 在这里仅简单采用全连接的方式将特征进行融合, 得到每个频段下每个脑区相同维度的特征值。最后, 4 个频段 DGC 特征矩阵按照这种脑区融合方式得到每个频段各 9 个脑区, 共 36 个脑区的编码后特征。

Transformer 编码器模块的功能在于按照不同频段、不同脑区间的依赖性将全脑信号进行相互融合, Transformer 编码模块示意图如图 6 所示。输入层为频段脑区划分编码模块输出的编码后共 36 个特征序列, 首先将每个序列的特征进行线性编码; 然后将编码后的所有序列添加位置编码后进行多头自注意力机制融合、LayerNorm 和多层感知器 (MLP) 操作, 使得每个序列都是其余所有序列的按

照相互间依赖性加权融合结果;最后将融合结果输出到全连接层进行情感识别分类。




图 6 Transformer 编码器模块

Fig. 6 Transformer encoder modules

3 实验与结果分析

为了保证公平性,实验统一使用 TYUT3.0 数据集中 50 个被试者的 EEG 信号,采用五折交叉验证,最后取五折平均值作为单个被试者的识别结果,并使用 50 个被试者的平均识别准确率和标准差评判识别性能。为了验证 DGC 特征的有效性,将不同特征输入 BFT 模型中进行比较;为了验证 BFT 模型的有效性,将 DGC 特征输入不同的情感识别模型中进行比较。

3.1 DGC 特征的情感识别性能

本节重点研究 DGC 特征的有效性,DGC 特征矩阵形状为 $4 \times 62 \times 62$,是一个主对角线非 0 的三维矩阵,4 表示 4 个频段 θ 、 α 、 β 和 γ ,62 代表 EEG 的 62 个通道。在每个频段 62×62 特征矩阵中,每一行代表 62 个通道分别为 GC 对应于行所在通道的因果度量值,每一列代表列所在通道分别为 GC 对应于 62 个通道的因果度量值,主对角线上即为 62 个通道分别自身对自身的因果度量值。而 BFT 识别模型的输入为频段数 $\times$ 通道数 $\times$ 特征维度,故将 DGC 特征矩阵变形为 $4 \times 62 \times 124$ 形式,4 代表 4 个频段 θ 、 α 、 β 和 γ ,62 代表 EEG 信号的 62 个通道,124 代表每个频段下 GC 矩阵中每个通道对应行和列的特征值,单个频段下特征矩阵中每个主对角线元素所在行列为一个通道特征值,每行每列特征值个数均为 62 个,行列拼接共得到 124 个特征值。特征输入到 BFT 情感识别模型的流程如图 7 所示。

为了验证提出特征的有效性,将 DGC 特征与脑电情感识别领域常用的 PSD 特征、DE 特征以及 TE 特征和 GC 特征的 BFT 情感识别结果进行比较,其中,TE 特征和 GC、DGC 特征同为因效性连




图 7 EEG 信号 GC 特征输入 BFT 情感识别模型的流程

Fig. 7 Procedure of EEG signal GC features input into BFT emotion recognition model

接度量特征。为了保证公平,对这些特征都采用相同的样本划分和相同的情感识别模型,情感识别结果如表 3 所示。

表 3 不同特征输入 BFT 情感识别模型的识别结果

Table 3 The recognition results of BFT emotion recognition

model input different features			%
特征	准确率	标准差	
PSD 特征	82.60	8.76	
DE 特征	90.24	5.45	
TE 特征	93.34	4.12	
GC 特征	92.91	4.35	
DGC 特征	94.50	3.69	

表 3 为 50 名被试者情感识别准确率结果的平均值。从表 3 可以看出,提出改动自身 GC 度量值后得到的 DGC 特征四分类准确率达到 94.50%,相比于 EEG 信号常用的 PSD 特征和 DE 特征准确率分别提升约 11.90 和 4.26 百分点,与 TE 特征相比准确率提升了 1.16 百分点,与未改进之前的 GC 特征相比识别准确率提高了约 1.59 百分点,同时,DGC 特征的标准差相较于其余特征更小,说明改进自身 GC 值能够为 GC 特征带来更稳定的成绩。对比结果表明,DGC 特征在参加对比的特征中取得最佳的情感识别效果,证明了 DGC 特征的有效性。

3.2 BFT 模型识别性能

为探究分频段进行 Transformer 和频段间 Transformer 模型的有效性,将 θ 、 α 、 β 、 γ 4 个单频段、不分频以及 4 个频段组合的 DGC 特征分别输入脑区 Transformer(BT)情感识别模型中的识别结果,与 4 个频段组合 DGC 特征输入 BFT 情感识别模型的识别结果做对比,对比结果如表 4 所示。

表 4 BT 情感识别模型频段消融实验结果

Table 4 Experimental results of frequency band ablation of BT emotion recognition model %		
频段	准确率	标准差
θ	92.27	5.44
α	89.54	6.67
β	87.44	6.72
γ	78.21	10.99
不分频	92.23	4.80
$\theta+\alpha+\beta+\gamma$ (BT)	94.13	4.30
$\theta+\alpha+\beta+\gamma$ (BFT)	94.50	3.69

从表 4 可以看出,不分频 DGC 特征送入 BT 模型的识别准确率低于分频后 4 个频段组合 DGC 特征送入 BT 模型中的识别准确率,说明分频预处理的有效性;分频后 4 个频段组合 DGC 特征送入 BT 模型的识别准确率高于一频段 DGC 特征送入 BT 模型的识别准确率。而分频后 4 个频段组合 DGC 特征送入 BFT 情感识别模型效果最好,考虑是由于 Transformer 的自注意力机制可以加强对输入特征中不同频段的依赖性的捕获,验证了频段组合和频段间 Transformer 模型的有效性。

为探究分脑区进行 Transformer 和脑区间 Transformer 模型的有效性,将 9 个单脑区和 9 个脑区组合的 DGC 特征分别输入到频段 Transformer(FT)情感识别模型中的识别结果,与 9 个脑区组合的 DGC 特征输入到 BFT 情感识别模型的识别结果做对比,对比结果如表 5 所示。

表 5 FT 情感识别模型情感脑区消融实验结果

Table 5 Results of ablation experiment on emotion-related brain regions in the FT emotion recognition model %

脑区	准确率	标准差
PF	79.78	9.37
F	84.30	8.64
LT	85.66	7.38
C	86.25	8.00
RT	84.14	8.28
LP	82.40	8.99
P	83.85	8.44
RP	79.06	9.54
O	79.06	9.19
9brains(FT)	93.81	4.84
9brains(BFT)	94.50	3.69

从表 5 可以看出,9 个脑区组合 FT 模型情感识别效果优于单脑区 FT 模型,而 9 个脑区组合特征输入 BFT 模型情感识别效果更优于 9 个脑区组合特征输入 FT 模型,验证了脑区组合和脑区间

Transformer 模型的有效性。BFT 情感识别模型效果最好,考虑是由于 Transformer 的自注意力机制可以加强对输入特征中不同频段不同脑区两种角度长距离依赖性的捕获。

为了分析依赖关系,将自注意力机制的注意力权重进行了可视化处理,图 8 展示了 50 个被试者的平均自注意力权重矩阵热力图,横纵坐标标签均为:EEG 信号 θ 、 α 、 β 、 γ 频段,每个频段为 PF、F、LT、C、RT、LP、P、RP、O 等 9 个脑区的组合。图中每一列可以看作相应频段相应脑区在分类中的贡献,从图 8 中可以发现,在 TYUT3.0 数据中,EEG 信号 θ 频段前额叶、额叶、左右颞叶和枕叶贡献更大, α 频段左右颞叶贡献更大, β 频段前额叶、额叶、左颞叶贡献更大, γ 频段前额叶、额叶、左右颞叶、中央区、左顶叶和枕叶贡献更大,其中,可以明显发现 γ 频段贡献相较于其他频段更大,所有频段左右颞叶比其他脑区的贡献都大。文献[28,30]中的结论也反映出颞叶激活度高,EEG 信号 γ 频段前额叶有明显的区分性能,顶叶和枕叶在不同频段下对不同情绪有不同的反应,与本文的发现基本吻合。总的来说,这些结果表明,BFT 中的自注意力机制可以从关键频段关键脑区学习到辨别特征。




图 8 50 个被试者的平均自注意力权重矩阵热力图

Fig.8 Heatmap of average self-attention weight matrices for 50 participants

为了进一步验证提出的 BFT 模型的有效性,将 BFT 模型与现有 EEG 情感识别常用模型,即 CNN、长短期记忆(LSTM)网络进行对比。这些网络都不可避免地学习到局部特征,而 Transformer 模型学习的是全局性特征;同时也使用了图神经网络(GNN)、现有 Transformer 模型与 BFT 模型进行对比。为了保证公平,这里所有模型的输入均为 DGC 特征。各个模型的情感识别性能如表 6 所示。

表 6 不同情感识别模型性能对比结果
Table 6 Performance comparison results of
different emotion recognition models

模型	准确率	标准差
CNN	90.71	4.24
LSTM	86.24	6.39
DGCNN ^[31]	90.29	5.59
Transformer ^[26]	92.61	5.07
HSLT ^[27]	91.72	5.56
CNN-Transformer ^[28]	90.47	5.21
BFT	94.50	3.69

从表 6 结果可以看出,提出的 BFT 模型相比于其他深度识别网络模型达到了最佳性能。与 CNN、LSTM 等学习局部特征的深度模型以及动态图卷积神经网络(DGCNN)相比,Transformer、HSLT 和提出的 BFT 模型都有更高的情感识别准确率,特别是 BFT 情感识别模型在 TYUT3.0 数据集的准确率与这 3 种深度模型相比分别提高了 3.79、8.26 和 4.21 百分点;与文献[26]中提出的通道间 Transformer、文献[27]中提出的 HSLT 模型和文献[28]中提出的 CNN-Transformer 模型等基于 Transformer 的全局特征学习的深度模型相比,提出的 BFT 模型准确率分别提高了 1.89、2.78 和 4.03 百分点,表明不同脑区不同频段的特征全局融合性能最好。此外,BFT 模型进行情感识别得到准确率的标准差比其他深度网络模型更小,这表明 BFT 模型在测试集中取得了更稳定的成绩。总之,以上结果可以验证所提出的 BFT 在情感识别方面的有效性,也证明了特征全局视野的有效性。

4 结束语

本文提出了 DGC 特征矩阵以避免原 GC 特征矩阵中自身因果度量值为 0 带来的情感识别模型输入信息缺失,并提出了 EEG 信号不同频段不同脑区特征根据依赖性相互融合的情感识别模型:BFT 情感识别模型。DGC 特征相较于 GC 特征有 1.59 个百分点左右的情感识别准确率提升,BFT 模型对 EEG 信号的不同频段不同脑区特征进行自注意力融合,平均准确率达到 94.50%,与现有研究相比,提出的 BFT 模型提升都在 1.89 百分点以上。未来可以考虑对同脑区内的特征进行优化,进一步分析局部影响和全局影响,并考虑 EEG 信号和其他信号的模态融合方法。

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(2): 135-152.

[2] CALVO R A, D' MELLO S. Affect detection: an interdisciplinary review of models, methods, and their applications[J]. *IEEE Transactions on Affective Computing*, 2010, 1(1): 18-37.

[3] BEKELE E, BIAN D, PETERMAN J, et al. Design of a virtual reality system for affect analysis in facial expressions; application to schizophrenia [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, 25(6): 739-749.

[4] 李海峰, 张雪英, 段淑斐, 等. 融合生成对抗网络与时间卷积网络的普通话情感识别[J]. *浙江大学学报(工学版)*, 2023, 57(9): 1865-1875.

LI H F, ZHANG X Y, DUAN S F, et al. Fusing generative adversarial network and temporal convolutional network for mandarin emotion recognition [J]. *Journal of Zhejiang University (Engineering Science)*, 2023, 57(9): 1865-1875. (in Chinese)

[5] 宋羽凯, 谢江. 基于多任务学习的轻量级语音情感识别模型[J]. *计算机工程*, 2023, 49(5): 122-128.

SONG Y K, XIE J. Lightweight speech emotion recognition model based on multi-task learning [J]. *Computer Engineering*, 2023, 49(5): 122-128. (in Chinese)

[6] ZENG Z H, PANTIC M, ROISMAN G I, et al. A survey of affect recognition methods: audio, visual, and spontaneous expressions[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(1): 39-58.

[7] 焦义, 徐华兴, 毛晓波, 等. 融合多尺度特征的脑电情感识别研究[J]. *计算机工程*, 2023, 49(5): 81-89, 96.

JIAO Y, XU H X, MAO X B, et al. Research on EEG emotion recognition with fusion of multi-scale features[J]. *Computer Engineering*, 2023, 49(5): 81-89, 96. (in Chinese)

[8] 陆文娟. 基于脑电信号的情感识别研究[D]. 南京: 南京邮电大学, 2017.

LU W J. Research on emotion recognition based on EEG signal [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2017. (in Chinese)

[9] QIU L, ZHONG Y, XIE Q, et al. Multi-modal integration of EEG-fNIRS for characterization of brain activity evoked by preferred music[J]. *Front Neurorobot*, 2022, 16: 823435.

[10] 赵亮. 基于脑电信号间 Granger 因果关系的情感识别[D]. 合肥: 合肥工业大学, 2018.

ZHAO L. Emotion recognition based on Granger causality between EEG signals [D]. Hefei: Hefei University of Technology, 2018. (in Chinese)

[11] MOON S E, JANG S, LEE J S, et al. Convolutional neural network approach for EEG-based emotion recognition using brain connectivity and its spatial information[C]//*Proceedings of International Conference on Acoustics, Speech and Signal Processing*. New York, USA: ACM Press, 2018: 2556-2560.

[12] FRISTON K J. Functional and effective connectivity: a review[J]. *Brain Connectivity*, 2011, 1(1): 13-36.

[13] 马措凯. 基于转移熵的因效脑网络情绪识别研究[D]. 南京: 南京邮电大学, 2021.

MA J K. Research on emotion recognition of causal brain network based on transfer entropy [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2021. (in Chinese)

[14] GHODOUSI M, POUSSON J E, VOICIKAS A, et al. EEG connectivity during active emotional musical performance[J]. *Sensors (Basel)*, 2022, 22(11): 4064.

[15] ZHANG J, ZHANG X, CHEN G, et al. EEG emotion recognition based on cross-frequency granger causality feature extraction and fusion in the left and right hemispheres[J].

- Frontiers in Neuroscience, 2022, 16: 974673.
- [16] 张静, 张雪英, 陈桂军, 等. 结合 3D-CNN 和频-空注意力机制的 EEG 情感识别[J]. 西安电子科技大学学报(自然科学版), 2022, 49(3): 191-198, 205.
- ZHANG J, ZHANG X Y, CHEN G J, et al. EEG emotion recognition based on the 3D-CNN and spatial-frequency attention mechanism[J]. Journal of Xidian University, 2022, 49(3): 191-198, 205. (in Chinese)
- [17] BALIC S, KLEYBOLTE L, MÄRTIN C. A swarm intelligence approach: combination of different EEG-channel optimization techniques to enhance emotion recognition[M]. Berlin, Germany: Springer, 2022.
- [18] WANG X L, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2018: 7794-7803.
- [19] 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, 10(3): 417-429.
- [20] ALARCAO S M, FONSECA M J. Emotions recognition using EEG signals: a survey [J]. IEEE Transactions on Affective Computing, 2019, 10(3): 374-393.
- [21] SHOJAIE A, FOX E B. Granger causality: a review and recent advances [J]. Annual Review of Statistics and Its Application, 2022, 9(1): 289-319.
- [22] GRANGER C W J. Investigating causal relations by econometric models and cross-spectral methods[J]. Journal of the Econometric Society, 2001, 42: 31-47.
- [23] GAO Y Y, WANG X K, POTTER T, et al. Single-trial EEG emotion recognition using Granger Causality (GC)/transfer entropy analysis [J]. Journal of Neuroscience Methods, 2020, 346: 108904.
- [24] GOSHVARPOUR A, GOSHVARPOUR A. Emotion recognition using a novel granger causality quantifier and combined electrodes of EEG [J]. Brain Sciences, 2023, 13(5): 759.
- [25] 王斌, 王忠民, 张荣. 基于多通道脑电信号的因果网络情绪识别[J]. 计算机工程, 2022, 48(1): 69-74.
- WANG B, WANG Z M, ZHANG R. Emotion recognition using causal network based on multi-channel EEG signal[J]. Computer Engineering, 2022, 48(1): 69-74. (in Chinese)
- [26] WANG H, CAO L, HUANG C X, et al. A novel algorithmic structure of EEG channel attention combined with swin transformer for motor patterns classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 3132-3141.
- [27] WANG Z, WANG Y X, HU C F, et al. Transformers for EEG-based emotion recognition: a hierarchical spatial information learning model[J]. IEEE Sensors Journal, 2022, 22(5): 4359-4368.
- [28] PEH W Y, YAO Y, DAUWELS J. Transformer convolutional neural networks for automated artifact detection in scalp EEG [C]//Proceedings of International Conference of the IEEE Engineering in Medicine and Biology Society. Washington D. C., USA: IEEE Press, 2022: 3599-3602.
- [29] LINDQUIST K A, WAGER T D, KOBER H, et al. The brain basis of emotion: a meta-analytic review[J]. Behavioral and Brain Sciences, 2012, 35(3): 121-143.
- [30] HU X, ZHUANG C, WANG F, et al. fNIRS evidence for recognizably different positive emotions [J]. Frontiers in Human Neuroscience, 2019, 13: 120.
- [31] 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, 2018, 11(3): 532-541.

编辑 索书志