

基于改进TCNN算法的脑电动态连续情绪识别研究

揭丽琳¹, 刘 勇¹, 王铭勋², 邹杨萌¹, 徐亦璐³, 鲁宇明^{4*}

(1. 南昌航空大学仪器科学与光电工程学院, 江西南昌 330063; 2. 南昌航空大学航空服务与音乐学院, 江西南昌 330063;
3. 江西农业大学软件学院, 江西南昌 330045; 4. 南昌航空大学航空制造与机械工程学院, 江西南昌 330063)

摘要: 在现实生活中, 人类情绪具有动态和多样化的特征, 受外部环境、社交互动以及个体内在状态的共同影响。针对脑电情绪识别研究通常局限于实验室的静态场景, 未能充分考虑情绪的动态连续性的问题, 本文提出了一种基于改进TCNN算法的脑电动态连续情绪识别方法。首先, 设计了适用于动态情境的脑电数据采集范式, 使用64通道的脑电设备收集24名受试者在经历开心至平静、平静至开心、平静至悲伤、悲伤至平静、平静至紧张和紧张至平静六种动态连续情绪转变时的脑电信号, 并进行了动态连续情绪标签的标注。其次, 对现有的TCNN算法进行了改进, 构建了一种双流网络模型进行动态连续情绪识别。该模型通过短期流利用时序卷积模块捕捉局部时间序列特征, 而长期流则通过Transformer模块捕捉全局时间序列特征。最后, 对提取的脑电特征进行特征层融合, 以获得更加精准的动态连续情绪识别结果。结果表明: 在采集的动态连续情绪数据集上, 本文方法在六种情绪的valence和arousal上分别取得了最小误差均值0.083和0.084; 在DEAP数据集上, valence和arousal的误差分别低至0.108和0.113。与四种传统机器学习算法以及GRU、CGRU、CNN、CNN-LSTM、CNN-Bi-LSTM、TCNN等六种深度学习模型相比, 本文方法表现出了更高的识别精度和稳定性, 能够有效满足应用场景的需求。

关键词: 脑电信号; 情绪识别; 特征提取; 特征融合; 双流网络模型

基金项目: 国家自然科学基金(No.62166020); 江西省自然科学基金(No.20242BAB25094, No.20224BAB206089)

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2025)04-1347-14

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20240997

Research on Dynamic Continuous Emotional Recognition of EEG Based on Improved TCNN Algorithm

JIE Li-lin¹, LIU Yong¹, WANG Ming-xun², ZOU Yang-meng¹, XU Yi-lu³, LU Yu-ming^{4*}

(1. School of Instrument Science and Optoelectronic Engineering, Nanchang Hangkong University, Nanchang, Jiangxi 330063, China;

2. School of Aviation Services and Music, Nanchang Hangkong University, Nanchang, Jiangxi 330063, China;

3. School of Software, Jiangxi Agricultural University, Nanchang, Jiangxi 330045, China;

4. School of Aeronautical Manufacturing and Mechanical Engineering, Nanchang Hangkong University, Nanchang, Jiangxi 330063, China)

Abstract: In real life, human emotions possess dynamic and diverse characteristics, influenced by external environments, social interactions, and an individual's internal state. Given that EEG emotion recognition research is often confined to static laboratory scenarios and fails to adequately consider the dynamic continuity of emotions, this paper proposes a novel method for dynamic continuous emotional recognition of EEG based on an improved TCNN algorithm. Firstly, an EEG acquisition paradigm suitable for dynamic scenarios was designed. A 64-channel EEG device was used to collect EEG signals from 24 subjects experiencing six types of dynamic emotional transitions: happy to calm, calm to happy, calm to sad, sad to calm, calm to tense, and tense to calm. Dynamic continuous emotional labels are also annotated for these signals. Secondly, the existing TCNN algorithm is improved to construct a dual-stream network model for dynamic continuous emotion recognition. This model captures local temporal features through a short-term stream utilizing a time-series convolutional module, while the long-term stream captures global temporal features via a Transformer module. Lastly, feature-level fusion of the extracted EEG features is performed to achieve more accurate dynamic continuous emotion recognition results. The results show that, on the collected dataset, the proposed method achieves the smallest mean errors of 0.083 and 0.084 for va-

lence and arousal across six emotions, respectively. On the DEAP dataset, the errors for valence and arousal are reduced to 0.108 and 0.113, respectively. Moreover, compared to four traditional machine learning methods and six deep learning approaches including GRU, CGRU, CNN, CNN-LSTM, CNN-Bi-LSTM, and TCNN, the proposed method demonstrates higher recognition accuracy and stability, effectively meeting the requirements of application scenarios.

Key words: EEG; emotion recognition; feature extraction; feature fusion; dual-stream network model

Foundation Item(s): National Natural Science Foundation of China (No.62166020); Natural Science Foundation of Jiangxi Province (No.20242BAB25094, No.20224BAB206089)

1 引言

人类情绪是由个人行为、思维方式和对客观事物的感受整合而成的内在表现^[1,2]。情绪呈现出连续性的特征,对个体后续的行为和心理动机产生深远影响,在主观感受与外部环境相互作用的过程中扮演着至关重要的角色^[3-5]。在正常状态下,人们通常保持平稳的情绪,这是最普遍的状态之一^[6,7]。然而,当受到外部正向刺激时,这种平稳的情绪可能会得到增强,表现为开心等积极情绪。相反,当遭受负向刺激时,情绪可能转为负面,表现为悲伤、紧张等消极情绪^[8]。

脑电信号(ElectroEncephaloGram, EEG)能够直接反映大脑活动,具有高时间分辨率、丰富的频率信息和较高的安全性等优点^[9]。因此,近年来国内外涌现出了许多基于脑电信号的情绪识别方法。情绪识别中常用的两个维度是愉悦度(valence)和唤醒度(arousal)。valence 主要与情绪的正负性相关,而 arousal 则反映情绪的激烈程度。由于这两个维度能够较全面地描述个体的情绪状态,它们在情绪识别任务中具有重要作用,有助于提高分类的准确性和可靠性^[10]。例如, Singh 等人^[11]采用灰狼优化算法来优化 EEG 通道数量,在 DEAP 数据集中 valence 和 arousal 上的准确率分别达到了 89.78% 和 78.9%。Bhattacharyya 等人^[12]提出了一种多变量多尺度熵特征,结合多尺度 K-NN 熵测量方法来评估脑电信号的时域复杂度,在 SEED 数据集中,积极、消极和中立情绪的准确率分别为 96.3%、94.8% 和 91.9%。Cui 等人^[13]开发了一种递归注意力卷积神经网络(Recursive Attention Convolutional Neural Network, RACNN)模型,能够自动提取特征,在 DEAP 数据集中 valence 和 arousal 的识别准确率分别为 96.65% 和 97.11%;在 DREAMER 数据集中,对应的准确率分别为 95.55% 和 97.01%。Zhu 等人^[14]提出了一种基于注意力融合的脑电图情绪分类网络(Emotion Classification Network with Attention Fusion, ECN-AF),在 SEED 数据集上的平均准确率达到 96.45%。Guo 等人^[15]提出了一种级联尺度感知自适应图卷积网络,在 DEAP 数据集中效价和 valence 的识别准确率分别为 98.89% 和 98.92%;在 DREAMER 数据集上的准确率分别为 99.08% 和 99.21%。Wu 等人^[16]提出了一种结合卷积神经网络和

GRU 的混合架构(Convolutional Gated Recurrent Unit network, CGRU),有效捕获信号通道中的互补时间特征和空间频率特征。在 DEAP 数据集上,arousal、valence 和支配度的识别准确率分别为 99.51%、99.60% 和 99.59%。Patlar 等人^[17]提出了一种融合卷积神经网络(Convolutional Neural Network, CNN)与长短期记忆网络(Long Short-Term Memory, LSTM)的模型,在 DEAP 数据集中,HALA、HVLV、熟悉度、支配度和喜好度的平均准确率分别 97.39%、97.41%、98.21%、97.68% 和 97.89%。Huang 等人^[18]提出了一种 CNN-Bi-LSTM-Attention 模型,通过 CNN 和 Bi-LSTM 网络进行特征提取与融合,再利用注意力机制平衡电极通道的权重。在 SEED 数据集上的准确率为 99.55% 和 99.79%。Yao 等人^[19]提出了一种基于 Transformer 和卷积神经网络的模型(Transformer-Convolutional Neural Network, TCNN),用于脑电图时空特征学习和自动情绪分类,在 SEED 数据集上的准确度为 96.67%;在 DEAP 数据集上,arousal、valence 和支配度的准确率分别为 95.73%、96.95% 和 96.34%。

上述脑电情绪识别方法主要从特征提取和分类模型等方面提出了一些改进策略,取得了不同的识别效果,展现了 EEG 信号在情绪识别中的巨大潜力和应用前景^[20,21]。现有研究在多个数据集上都获得了较高的准确率,证明了方法的有效性和可靠性,推动了脑电情绪识别领域的发展。然而,以往的研究主要依赖于 SEED、DEAP 和 DREAMER 等数据集,仍然局限于实验室的静态情境^[22]。实际上,真实生活中的情绪往往是多种情绪交织的结果,并伴随着动态变化^[23]。因此,有必要探索情绪在动态变化过程中的表现形式,并寻求更有效的情绪识别方法。

为此,本文充分考虑情绪的动态连续性,并结合脑电信号的优势,提出了一种基于改进 TCNN 算法的脑电动态连续情绪识别方法,其主要贡献如下:

(1)设计了一种适用于动态情境的脑电数据采集范式。传统的脑电数据采集方式通常依赖单一情绪刺激,每段情绪刺激材料对应一个固定情绪标签。例如,通过展示特定的图片、音频或视频片段诱发受试者产生单一情绪反应,并记录其脑电信号。然而,这种方法未能充分反映情绪在实际情境中的动态变化,导致采

集的数据无法有效捕捉情绪的连续波动,进而限制了其在动态情绪识别模型中的适用性.为解决此问题,本文基于现有脑电数据采集方法,提出了一种创新的动态情境实验范式.该范式涵盖六种情绪转换的动态过程:平静至开心、平静至悲伤、平静至紧张、开心至平静、悲伤至平静以及紧张至平静.具体地,将长时间的电影片段切割为每 5 s 的小段,并在每个时间段内记录受试者的情绪标签,从而捕捉情绪从一种状态过渡到另一种状态的微小变化.通过这种动态情绪转换设计,情绪标签不再是静态的单一值,而是转变为一个连续变化的序列,提升了情绪数据的复杂性和生态效度,显著增强了其与现实生活中情绪波动的相关性.此外,采用电影片段作为诱发材料,相较于传统的静态图片或单一短视频,能够更自然地引发情绪变化,效果更加显著.

(2)分析情绪调节效应和性别差异在动态连续情绪识别中的作用:为检验情绪调控对行为数据的影响,进行了受试者 valence 和 arousal 评分的重复测量方差分

析.结果表明,受试者的 valence 和 arousal 评分存在重评效应,反映出在认真完成实验任务时的情绪变化.在性别差异方面,面对积极情绪刺激时,男女受试者的情绪反应高度一致, valence 和 arousal 同步上升,显示积极情绪对情绪体验的普遍影响.而在面对消极情绪刺激时,女性更容易长时间保持负面情绪状态,且恢复速度较慢.

(3)构建双流网络模型:基于现有 TCNN 算法,构建了一种双流网络模型(Dual-Stream Network, DS-TCNN),能够分别处理短期(短时间跨度)和长期(长时间跨度)的情绪变化特征.短期流通过时序卷积模块(Temporal Convolutional Network, TCN)捕捉局部时间序列特征,长期流则利用 Transformer 模块捕捉全局时间序列特征.随后,将提取的脑电特征进行特征层融合,以实现动态连续情绪识别.该双流网络模型能够在不同时间尺度上对情绪特征进行建模,增强模型对情绪变化的多维理解,有助于捕捉情绪的快速和缓慢变化.本文研究方法流程如图 1 所示.

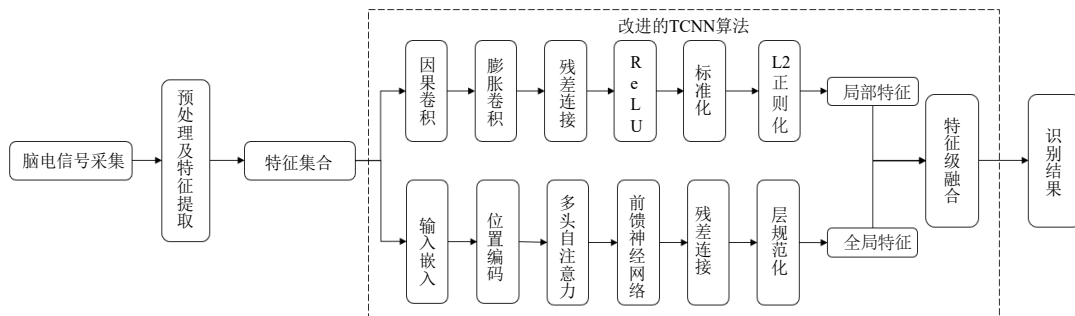


图 1 本文研究方法流程图

2 动态连续情绪数据集建立

2.1 受试者信息

受试者均来自南昌航空大学,所有参与者为本科生或研究生,身体健康,视力正常或矫正后正常,无精神类疾病,右利手.经初步筛选,共招募到 24 名受试者(男性 15 名,女性 9 名),平均年龄为 22.06 ± 2.15 岁,以控制年龄差异对结果的干扰.实验开始前,所有受试者均被告知实验流程和注意事项,并自愿签署知情同意书.本研究中所有人体试验均已获得南昌航空大学伦理委员会的批准(批文编号:NCHU-2023-08),试验仅在受试者签署知情同意书后进行.

2.2 情绪刺激材料

选取公开脑电数据集中的情绪刺激视频进行剪辑,将剪辑后的动态连续情绪刺激视频作为实验中使用的刺激素材,这些视频均呈彩色,总时长相等均为 180 s 且每种情绪时长均为 90 s.邀请不参与实验的 10 名志愿者观看情绪刺激视频,通过对 valence 和 arousal 两

个维度打分,证明了开心(arousal 为 6.376 ± 0.801 , valence 为 7.349 ± 0.648)、平静(arousal 为 2.917 ± 0.749 , valence 为 5.116 ± 0.737)、悲伤(arousal 为 6.362 ± 0.587 , valence 为 2.312 ± 0.439)和紧张(arousal 为 6.612 ± 0.854 , valence 为 3.116 ± 0.583),刺激素材都能有效刺激出相应的情绪.其中包含能够诱发开心至平静、平静至开心、悲伤至平静、平静至悲伤、紧张至平静和平静至紧张六种动态连续情绪的视频,每种动态连续情绪包含 8 个视频.

2.3 实验范式

在实验开始前,操作人员会向受试者解释实验的内容,并指导他们如何评分视频中的情绪刺激,包括对情绪的 arousal 和 valence 进行评定.之后,受试者将参与简短的预实验,以熟悉流程并确认是否理解任务.一旦确认理解后,受试者将正式进入情绪任务实验阶段.该实验任务包括六个情绪转换模式:开心至平静、平静至开心、悲伤至平静、平静至悲伤、紧张至平静以及平静至紧张,模式分为三组,每组包含 16 个试次.每个试

次的实验刺激为一个持续 180 s 的动态情绪视频,该视频分为两个 90 s 的部分,每部分呈现一种情绪,按照预设固定顺序依次播放,试次之间会有 15 s 的休息时间.此外,每个视频被切割成 5 s 的片段,最终形成 36 个片段供受试者评分.

实验程序使用 E-prime3.0 软件设计.在正式实验开始时,屏幕上将显示欢迎信息及实验操作指南,受试者通过任意键进入第一个试次,详细流程如图 2 所示.开始阶段包括以下步骤:首先,屏幕中央会出现一个黑色的“+”符号,持续 2 s,以让受试者做好准备;然后,屏幕上会出现实验注意事项,受试者需仔细阅读并按空

格键确认.接着,屏幕中会再次显示“+”符号,持续 2 s.随后,实验将播放预设的情绪刺激视频,用于评估受试者的情绪反应.视频播放结束后,受试者需对视频中的两种情绪(如快乐和悲伤)进行评分,评估它们的 arousal 和 valence.此外,受试者还需对视频中被切割成 5 秒的 36 个片段进行评分.评分系统分为 9 个等级,arousal 评分从 1 到 9,其中 1 表示“非常放松”,9 表示“非常强烈”,5 则表示“平静”.valence 评分同样从 1 到 9,1 代表“非常负面”,9 代表“非常正面”,5 表示“正常”.受试者根据自己的感受填写评分表,评分过程没有时间限制,填写完成后自动进入下一个试次.

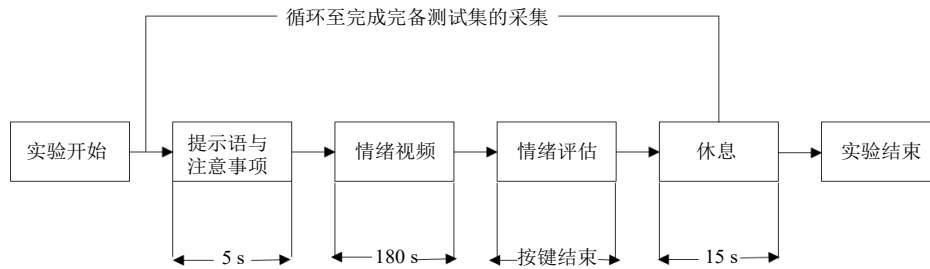


图2 实验范式示意图

实验在一个安静且条件良好的隔音室内进行,室内温度和亮度经过精确调节以保持舒适.受试者坐在专门设计的舒适椅子上,以保持放松状态进行实验.视频刺激在电脑屏幕中央清晰显示,受试者需保持目光平视屏幕中的“+”号,距离约为 90 cm.

2.4 脑电信号采集及预处理

(1) 动态脑电数据采集及预处理

本研究采用上海心仪电子科技有限公司的 64 通道湿电极帽(Eego64,上海心仪科技,中国)来采集受试者情绪变化的脑电信号,电极分布遵循 10-20 国际标准.脑电记录使用该公司的 eego 软件,参考电极和接地电极分别为 CPz 和 GND 电极,采样率设定为 128 Hz,电极阻抗小于 20 k Ω 采集完成后,通过 ASA 软件对原始数据进行预处理,使用陷波滤波器去除工频干扰.使用 Butterworth 滤波器提取 1 ~ 50 Hz 范围内的脑电信号,去除眼电干扰和伪迹(幅值大于 100 μ V 或小于 -100 μ V 的数据段全部剔除).

考虑到容积传导效应的影响,选取了 64 个电极进行后续数据分析,具体电极包括:M1、T7、TP7、P7、PO7、PO5、PO4、PO3、P5、CP5、CPz、C5、FT7、F7、AF7、F5、FC5、Fp1、AF3、F3、FC3、C3、CP3、P3、O1、P1、CP1、C1、FC1、F1、Oz、POz、Pz、CPz、Cz、PCz、Fz、Fpz、Fp2、AF4、F2、F4、F6、F8、FC2、FC4、FC6、FT8、C2、C4、C6、T8、CP2、CP4、CP6、TP8、P2、P4、P6、P8、O2、PO6、PO8、M2.电极的具体分布如图 3 所示.




图3 选用的 64 导电极分布图

(2) 动态连续情绪标签预处理

观看情绪刺激视频时,情绪标注值大约在第 10 s 时开始收敛^[24].因此,本文将动态连续情绪标注的初始适应时间设置为 15 s,前 15 s 的动态连续情绪标记值将被舍弃.接下来,记录每段刺激片段在 valence 和 arousal 两个维度上的连续得分,并以此作为该段刺激片段的动态连续情绪标签值,随后进行归一化处理,如式(1)所示:

$$\theta_j(t) = \theta_j(t) + (\sigma_j - \omega) \quad (1)$$

其中, $\theta_j(t)$ 表示被试 j 在时间点 t 的标注值, σ_j 表示被试 j 对该动态连续情绪刺激片段的标注均值, ω 表示所有被试对该刺激片段所标注的标注均值.

在观看诱发不同动态连续情绪的电影片段时,受试者的动态连续情绪值波动曲线显著不同.图 4 展示了受试者在六种动态情境下 valence 和 arousal 的变化趋势.

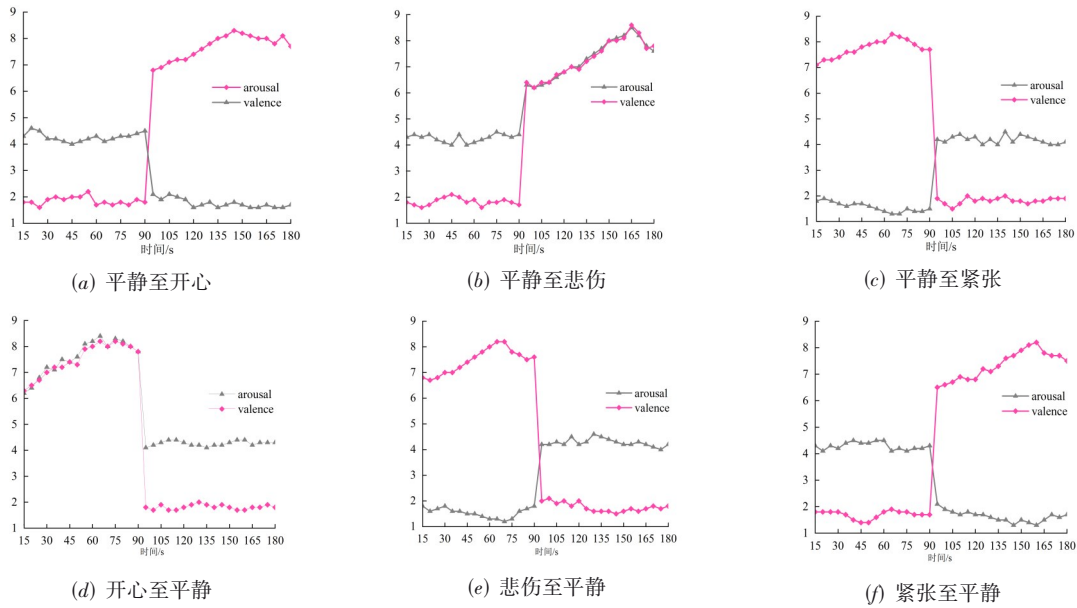


图4 动态连续情绪曲线

总体来看,在单一情绪(如平静或开心)的刺激相对稳定.然而,当情绪刺激发生变化(如从平静转变为开心)时, valence 和 arousal 的变化幅度显著增大,反映出情绪的剧烈变化.

具体而言,如图4(a)所示,从平静到开心的动态情绪变化曲线在15~90 s, valence 值在4.1~4.4之间轻微波动,表明这段时间内情绪较为稳定.在90 s时, valence 值急剧上升,从4.1升至6.5,显示出显著的情绪转换.在90~150 s, valence 值继续缓慢增加,表明情绪逐渐提升.150 s后, valence 值略有下降,但仍维持在较高水平.类似地,在15~90 s, arousal 值在2.1~2.4之间波动,显示出相对稳定的兴奋变化.在90 s时, arousal 值迅速上升,从2.4增至7.3,同样呈现出显著的情绪转换.在90~150 s, arousal 值继续上升,150 s时达到最高值8.0.表明兴奋度逐渐提升.150 s后, arousal 值略有下降,但

依然保持在较高水平,表明兴奋度在后期阶段有所回落但仍然较高.相应地,图4(b)~(f)则分别展示了其他五种动态连续情绪下 valence 和 arousal 的变化规律.

3 动态连续情绪识别模型构建

为了有效解决动态情境下的脑电情绪识别问题,本文对现有 TCNN 算法进行改进,构建了一种 DS-TCNN 模型,用于分别处理短期(短时间跨度)和长期(长时间跨度)的情绪变化特征.短期流通过时序卷积捕捉局部时间特征,而长期流则通过 Transformer 捕捉全局时间序列特征.接着,将提取到的脑电特征进行特征层融合,以实现动态连续情绪识别.该双流网络能够在不同时间尺度上对情绪特征进行建模,从而增强模型对情绪变化的多维理解,帮助捕捉情绪的快速与缓慢变化.本文提出的双流网络架构如图5所示.




图5 双流网络模型结构

3.1 特征提取

为了探索动态连续情绪脑电信号的有效特征,本文选择了当前在脑电情绪识别领域常用的微分熵特征和功率谱密度特征进行分析,并使用四种回归模型进

行预实验:支持向量回归(Support Vector Regression with radial basis function kernel, SVRrbf)^[25]、K-最近邻(K-Nearest Neighbors, KNN)^[26]、决策树(Decision Tree, DT)^[27]和随机森林(Random Forest, RF)^[28].

对预处理后的脑电信号进行快速傅里叶变换,可获得信号的功率谱密度特征(Power Spectral Density, PSD)^[29],该特征反映了信号功率随频率变化的情况,即信号功率与频率之间的关系,如式(2)所示:

$$\text{PSD} = \lim_{N \rightarrow \infty} E \left[\frac{1}{N} \left| \sum_{n=1}^N x_n e^{-j\omega n} \right|^2 \right] \quad (2)$$

其中, x_n 表示信号的第 x 个样本, N 表示信号的长度, ω 表示频率, PSD 表示提取的功率谱密度特征.

对预处理后的脑电信号进行微分运算,并计算微分后信号的功率,可以得到相应的脑电信号的微分熵

特征(Differential Entropy, DE)^[30]. 该特征表示信号在不同时间点的变化率或斜率,用于衡量信号随着时间的变化速度,从而反映信号的动态特性,如式(3)所示:

$$\text{DE} = \frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} - x_i)^2 \quad (3)$$

其中, N 为信号的样本数, x_i 为信号在第 i 个时间点的样本值, DE 为提取的功率谱密度特征.

为了验证上述脑电特征在动态连续情绪识别中的有效性,本文采用均方误差(MSE)作为评价指标,将提取的 DE 和 PSD 特征分别输入四种回归模型,得到不同特征下的情绪识别结果,如图6所示.

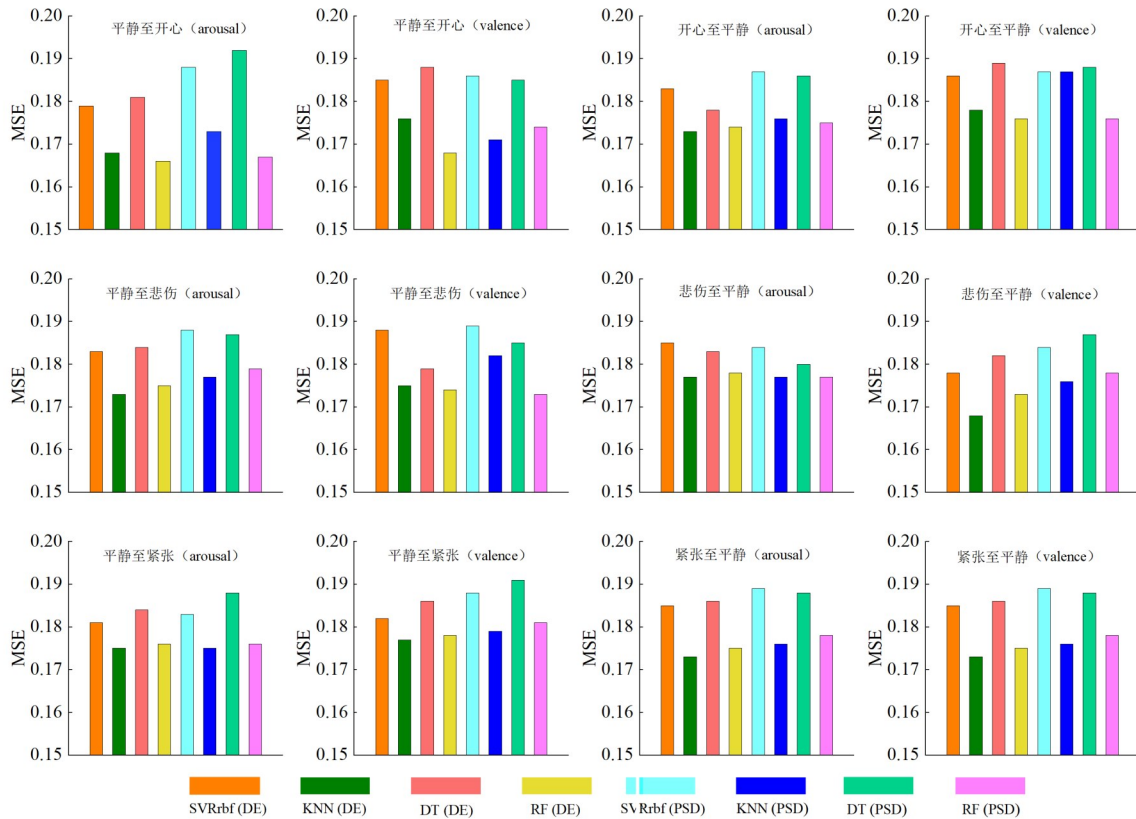


图6 不同特征数据结果图

在多种动态连续情绪转变过程中,例如从平静到积极、平静到悲伤、平静到紧张,使用 DE 特征的回归模型在 arousal 和 valence 的识别中均表现出更低的误差. DE 特征在不同模型和情绪转换中的误差波动范围较小,尤其在 RF 和 KNN 回归模型中表现稳定,这表明 DE 特征在处理情绪变化时具有较高的鲁棒性,适合用于动态连续情绪识别任务. 因此,本文选择了 DE 特征.

3.2 模型构建

由于 TCNN 算法采用膨胀卷积的机制,能够有效扩大感受野,从而捕捉时间序列中的中短期特征,具有识

别精度高和计算复杂度低的优点^[31]. 然而,TCNN 算法仍然存在难以捕捉长期情绪变化和缺乏全局信息整合的不足^[32]. 因此,本研究在 TCNN 算法的基础上,将提取到的脑电特征分别通过短期流和长期流来提取局部时间特征和全局时间特征,再利用注意力机制进行特征层融合,从而提出一种双流网络模型. 短期流的主要功能是提取短时间跨度内的局部特征,其结构主要由因果卷积层、膨胀卷积层、残差连接、ReLU 激活函数、标准化、L2 正则化以及 Dropout 构成.

(1) 使用因果卷积确保每个时间步的输出只依赖于当前及过去的输入数据,保证时间因果性,如式(4)

所示:

$$Z_t = \sum_{j=0}^{k-1} Y_{t-j} \cdot U_j + b_z \quad (4)$$

其中, Z_t 表示当前时间步 t 的输出, Y_{t-j} 表示时间步 $t-j$ 的输入数据, U_j 表示卷积核权重, k 表示卷积核大小, b_z 表示偏置项.

(2) 使用膨胀卷积, 引入膨胀率, 在卷积核之间加入间隔, 扩大感受野, 同时不增加参数量, 如式(5)所示:

$$Q_t = \sum_{j=0}^{k-1} V_{t-d \cdot j} \cdot W_j + b_q \quad (5)$$

其中, Q_t 表示膨胀卷积的输出, $V_{t-d \cdot j}$ 表示输入信号, W_j 表示膨胀卷积核的权重, k 表示卷积核大小, b_q 表示偏置项.

(3) 在输入和卷积输出之间引入残差连接, 解决深层网络中的梯度消失问题, 稳定训练过程, 如式(6)所示:

$$R_t = P_t + \lambda(P_t, S) \quad (6)$$

其中, R_t 表示残差连接后的输出, P_t 表示输入信号, $\lambda(P_t, S)$ 表示通过卷积操作提取的特征映射, S 表示卷积核参数.

(4) 使用 ReLU 激活函数, 如式(7)所示:

$$A_t = \text{ReLU}(R_t) = \max(0, R_t) \quad (7)$$

其中, A_t 表示激活函数的输出, R_t 表示输入到激活函数的残差块输出.

(5) 对激活后的特征进行标准化, 确保特征分布稳定, 加速训练, 如式(8)所示:

$$N_t = \gamma \cdot \frac{A_t - \mu}{\sqrt{\sigma^2 + \varepsilon}} + \beta \quad (8)$$

其中, N_t 表示规范后的输出, μ 和 σ^2 表示均值和方差, γ 和 β 表示缩放和平移参数, ε 防止分母为零的平滑项.

(6) 使用 L2 正则化, 防止过拟合, 如式(9)所示:

$$L_{\text{reg}} = \frac{\lambda}{2} \sum_i \|T_i\|^2 \quad (9)$$

其中, L_{reg} 表示正则化损失项, T_i 表示模型中的权重, λ 表示正则化系数, 控制惩罚项的强度.

(7) 使用 Dropout, 通过随机丢弃神经元, 增强模型的泛化能力, 防止过拟合, 如式(10)所示:

$$D_t = N_t \cdot M, M \sim \text{Bernoulli}(p) \quad (10)$$

其中, D_t 表示 Dropout 后的输出, N_t 表示规范后的输入特征, M 表示与 N_t 维度相同的随机掩码矩阵, $\text{Bernoulli}(p)$ 表示神经元以概率 p 保留.

长期流的主要功能是捕捉情绪数据的长期时间依赖性, 采用 Transformer 模块捕捉全局的时间序列特征. Transformer 模块的结构主要包括特征编码、自注意力

机制、多头自注意力和前馈网络^[33-35].

(1) 通过全连接层将 EEG 数据转换为适合 Transformer 处理的嵌入表示, 将原始输入映射到高维空间, 如式(11)所示:

$$E = X \cdot W_e + b_e \quad (11)$$

其中, $X \in R^{T \times d_{\text{input}}}$ 表示输入的 EEG 序列, T 为时间步数, d_{input} 为输入特征维度, $W_e \in R^{T \times d_{\text{input}} \times d_{\text{model}}}$ 表示嵌入权重矩阵, $b_e \in R^{d_{\text{model}}}$ 表示偏置向量, $E \in R^{T \times d_{\text{model}}}$ 表示生成的嵌入向量.

(2) 由于 Transformer 缺乏内在的时序信息, 因此需要为输入序列添加位置编码^[36], 如式(12)和式(13)所示:

$$\text{PE}_{(q, 2i)} = \sin\left(\frac{q}{10000^{2i/d}}\right) \quad (12)$$

$$\text{PE}_{(q, 2i+1)} = \cos\left(\frac{q}{10000^{2i/d}}\right) \quad (13)$$

其中, d 表示特征维度, q 表示时间步, i 表示特征维度的索引.

(3) 利用自注意力机制提取输入序列的全局关系, 并通过线性变换生成查询、键和值矩阵^[37], 如式(14)所示:

$$\begin{cases} Q = XW^Q \\ K = XW^K \\ V = XW^V \end{cases} \quad (14)$$

其中, W^Q 、 W^K 和 W^V 分别表示查询、键和值的权重矩阵. 注意力得分通过缩放点积注意力得到, 如式(15)所示:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (15)$$

其中, $\sqrt{d_k}$ 表示缩放因子, Softmax 确保了注意力得分为 1.

(4) 通过多头自注意力的并行计算, 模型能够同时关注多个注意力头, 从而捕捉到不同部分的信息^[38], 如式(16)所示:

$$\text{head}_\psi = \text{Attention}(Q_\psi, K_\psi, V_\psi) \quad (16)$$

(5) 自注意层的输出会经过一个前馈神经网络进行处理, 该网络由两个线性层和一个非线性激活函数组成, 用于对每个时间步的特征进行进一步变换^[39], 如式(17)所示:

$$\text{FFN}(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (17)$$

其中, W_1 和 W_2 为权重矩阵, b_1 和 b_2 为偏置项.

通过使用注意力机制, 动态生成融合权重以适应输入^[40]. 首先, 计算短期和长期特征的注意力权重, 如式(18)和式(19)所示:

$$W_L = \text{Softmax}(w_L L + b_L) \quad (18)$$

$$W_S = \text{Softmax}(w_S L + b_S) \quad (19)$$

其中, W_L 和 W_S 为可训练的权重矩阵, b_L 和 b_S 为偏置项。

本文通过构建双流网络结构,能够有效克服现有 TCNN 难以捕捉长期情绪变化和缺乏全局信息整合的不足,具有更高的特征提取精度和更强的情绪变化捕捉能力,提高了情绪识别的准确性和稳定性。

4 结果分析与讨论

本文在采集的动态连续情绪数据集和公开静态脑电数据集 DEAP 上验证所提出方法的性能,并与四种机器学习算法以及 CNN、GRU、CGRU、CNN-LSTM、CNN-Bi-LSTM 和 TCNN 六种性能较好的深度学习模型进行了对比,以证明本文方法在解决动态连续 EEG 情绪识别问题上的优越性。

为了评价算法性能,采用了均方误差(MSE)指标,并通过 10 倍交叉验证确保结果的稳健性和泛化能力。所有模型均在配置为 Intel Core i7-11700(5 GHz, 16 核)处理器, NVIDIA GTX 3070 显卡(8 GB)的 PC 上进行部署,并在 PyCharm 20 222.3.2 开发平台上,基于开源框架 Tensorflow 1.5 实现。

4.1 行为学结果

行为学结果通常用于补充和解释 EEG 数据,从而更全面地理解受试者在特定情绪或认知任务下的反应。EEG 数据揭示了大脑在这些任务下的电生理活动,而行为学结果则反映了受试者的实际表现^[41,42]。结合这两者,可以更深入地理解和解释受试者在不同情绪状态或

认知任务下的反应和表现。在本文的脑电范式实验中,行为学结果指的是受试者在实验过程中表现出的可观察和可测量的行为数据^[43]。这些数据可能包括情绪调控、不同情境以及其他与实验任务相关的行为指标^[44]。

4.1.1 情绪调节效应

为了检验情绪调控对行为学数据的影响,对受试者的效价和 arousal 评分进行了重复测量方差分析^[45]。本研究的行为学结果如图 7 所示。在 arousal 评分方面,发现平静状态的 arousal 评分最低,而紧张状态的 arousal 评分最高。其中,悲伤观看(6.362±0.587)vs 悲伤重评(5.684±0.382): $P<0.001$;平静观看(2.917±0.749)vs 平静重评(2.549±0.462): $P<0.001$;开心观看(6.376±0.801 2)vs 开心重评(5.632±0.523): $P<0.001$;紧张观看(6.612±0.854)vs 紧张重评(5.978±0.791): $P<0.001$ 。此外,悲伤重评 vs 平静观看: $P=0.002 8$;开心重评 vs 平静观看: $P=0.003 6$;紧张重评 vs 平静观看: $P=0.002 5$ 。这表明受试者的效价评分具有重评效应。对于 valence 评分,发现悲伤状态的 valence 评分最低,而开心状态的 valence 评分最高。其中,悲伤观看(2.312±0.439)vs 悲伤重评(3.627±0.382): $P<0.001$;平静观看(5.116±0.737)vs 平静重评(5.082±0.448): $P<0.001$;开心观看(7.349±0.648)vs 开心重评(6.752±0.515): $P<0.001$;紧张观看(3.116±0.583)vs 紧张重评(3.622±0.472): $P<0.001$ 。此外,悲伤重评 vs 平静观看: $P=0.002 3$;开心重评 vs 平静观看: $P=0.002 1$;紧张重评 vs 平静观看: $P=0.003 1$ 。这也表明受试者的 arousal 评分存在重评效应,反映出受试者认真完成实验任务的状态。




图 7 受试者在各情绪任务下的行为学评分(**表示 $P<0.05$, 误差线对应标准差)

4.1.2 性别差异对动态连续情绪的影响

为了分析比较不同性别对动态连续情绪的影响,本文将受试者分为男性和女性两组,并绘制了两者在不同刺激下的情绪波动曲线,如图 8 所示。

从图 8(a)和图 8(d)可以看出,在平静至开心和开心至平静的情绪刺激下,男性和女性的 valence 和

arousal 在约 90 s 时均显著上升或下降,且变化幅度相似。这表明,在面对积极情绪刺激时,男女性的情绪反应高度一致, valence 和 arousal 同步增加,显示出积极情绪对情绪体验的共性影响。

分析图 8(b)和图 8(e)可知,在悲伤至平静和平静至悲伤的情绪刺激下,女性的情绪恢复速度明显慢于

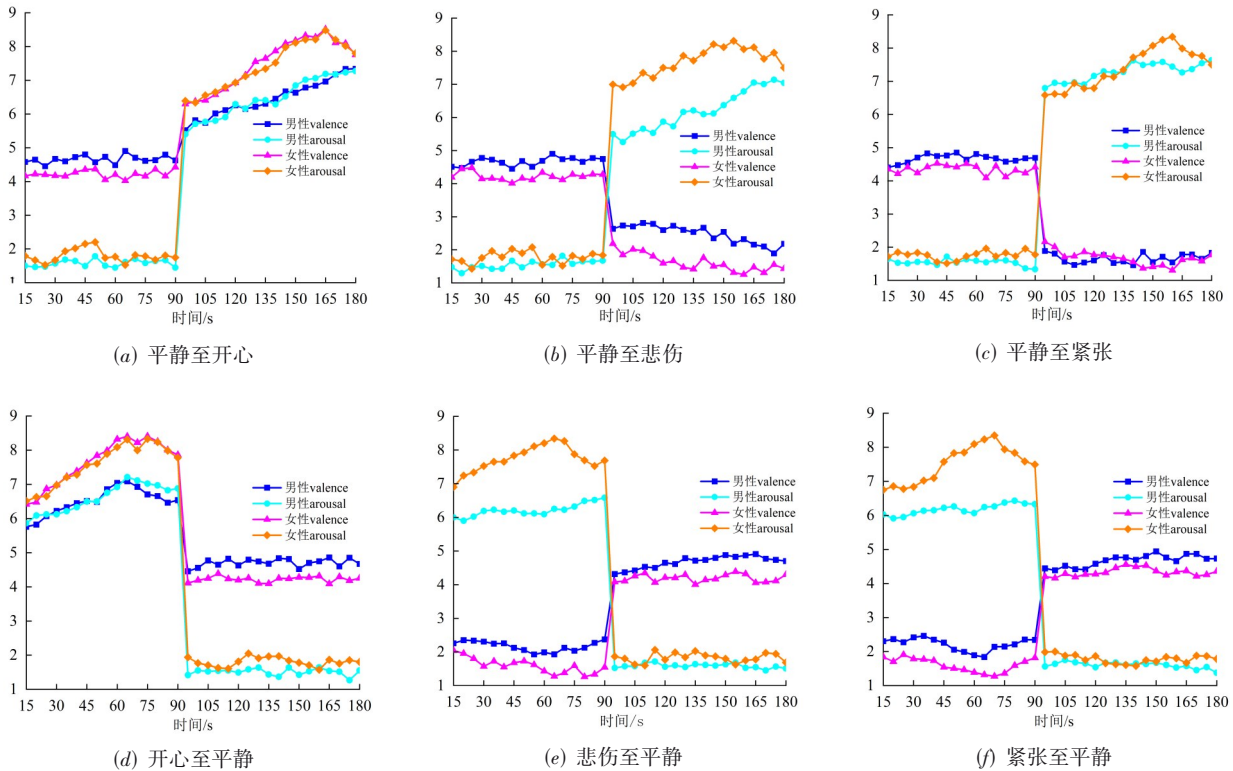


图8 不同性别的动态连续情绪曲线

男性. 具体而言, 女性的 valence 值在 90 s 后上升或下降较为缓慢, 而男性的 valence 值则迅速恢复到正常水平. 同时, 女性的 arousal 值在 90 s 后仍保持在较高或较低水平, 而男性的 arousal 值则快速回升. 这表明女性在面对悲伤情绪时更容易长期维持负面情绪, 恢复速度较慢.

从图 8(c) 和图 8(f) 可以发现, 在紧张至平静和平静至紧张的情绪刺激下, 女性的 valence 和 arousal 值同样表现出更持久的波动. 女性的 valence 值在 90 s 后上升或下降较慢, arousal 值维持在高或低水平. 而男性则表现出更快的恢复能力. 这表明女性在面对紧张情绪时更易受到影响, 情绪波动更为明显; 而男性的 valence 和 arousal 值虽然也会发生变化, 但调整和恢复速度较快, 展现出更强的情绪调节能力.

4.2 对比实验

为验证本文 DS-TCNN 的整体性能, 选取 SVRrbf、KNN、DT、RF 四种机器学习算法, 以及 GRU、CGRU、CNN、CNN-LSTM、CNN-Bi-LSTM 和 TCNN 六种性能较好的深度学习模型进行比较, 提取 DE 特征以训练和测试 11 种模型, 并采用 10 倍交叉验证构建训练与测试数据集. 表 1 给出了 11 种方法在六种动态连续情绪上进行 20 次独立实验, 所获得的 MSE 均值和标准差 (括号内为标准差), 加粗数据为最优值.

从表 1 可以看出, 四种传统机器学习算法在不同情绪转换任务中的表现较差, MSE 值较高, 其中 KNN 的 MSE 值范围为 0.174~0.178, SVRrbf 为 0.185~0.191, DT 为 0.185~0.190, RF 为 0.175~0.178, MSE 值均在 0.17~0.20 之间, 表明其在动态连续情绪识别中的稳定性不足.

相比之下, GRU、CGRU、CNN、CNN-LSTM、CNN-Bi-LSTM、TCNN 和 DS-TCNN 七种深度学习模型在各情绪转换任务中的表现显著优于四种传统算法. 其中, CNN 的 MSE 值范围为 0.143~0.150, GRU 为 0.154~0.161, CGR 为 0.128~0.134, CNN-LSTM 为 0.121~0.126, CNN-Bi-LSTM 为 0.117~0.122, TCNN 为 0.113~0.118. 值得注意的是, 本文 DS-TCNN 的 MSE 值显著降低至 0.084~0.088, 显示了其在动态连续情绪识别中的显著优势. 这是因为 DS-TCNN 通过短期流捕捉短时间内的的情绪变化, 长期流处理长时间的情绪动态变化, 两者结合通过融合层与注意力机制提升了模型的情绪识别能力.

图 9 为 DS-TCNN 和其他对比方法的运行时间. 通过图 9 可以看出, 深度学习模型的运行时间相对较长, 这反映了其对计算资源的较高需求. 尽管如此, 深度学习模型在识别性能上明显优于传统机器学习算法, 特别是在 MSE 值上, DS-TCNN 模型不仅表现最佳, 而且在

表1 DS-TCNN和其他对比方法获得的动态连续情绪识别结果(均值与标准差)

	平静至积极		积极至平静		平静至悲伤		悲伤至平静		平静至紧张		紧张至平静	
	valence	arousal	valence	arousal	valence	arousal	valence	arousal	valence	arousal	valence	arousal
SVRrbf ^[25] (2022)	0.183 0.012	0.186 0.011	0.189 0.012	0.186 0.009	0.191 0.010	0.187 0.012	0.191 0.008	0.185 0.010	0.185 0.012	0.188 0.013	0.185 0.015	0.188 0.008
KNN ^[26] (2024)	0.177 0.014	0.179 0.010	0.175 0.009	0.175 0.017	0.177 0.012	0.179 0.014	0.177 0.016	0.173 0.008	0.174 0.005	0.173 0.006	0.177 0.011	0.178 0.014
DT ^[27] (2024)	0.188 0.009	0.186 0.011	0.187 0.007	0.188 0.013	0.191 0.009	0.187 0.014	0.185 0.013	0.186 0.011	0.189 0.015	0.190 0.010	0.187 0.013	0.190 0.009
RF ^[28] (2019)	0.174 0.016	0.172 0.010	0.177 0.013	0.174 0.010	0.177 0.008	0.178 0.009	0.177 0.013	0.175 0.012	0.176 0.011	0.175 0.006	0.177 0.009	0.177 0.010
CNN ^[14] (2020)	0.145 0.008	0.143 0.006	0.145 0.008	0.145 0.010	0.146 0.007	0.144 0.008	0.147 0.009	0.147 0.007	0.148 0.009	0.145 0.011	0.146 0.009	0.147 0.012
GRU ^[15] (2020)	0.154 0.008	0.155 0.007	0.156 0.010	0.154 0.011	0.157 0.009	0.161 0.004	0.158 0.006	0.158 0.008	0.160 0.008	0.159 0.007	0.157 0.010	0.158 0.008
CGRU ^[16] (2022)	0.127 0.007	0.129 0.008	0.128 0.009	0.131 0.011	0.134 0.010	0.131 0.007	0.133 0.009	0.131 0.010	0.131 0.011	0.134 0.008	0.134 0.007	0.133 0.010
CNN- LSTM ^[17] (2024)	0.124 0.010	0.122 0.011	0.123 0.009	0.122 0.007	0.125 0.008	0.126 0.006	0.126 0.008	0.127 0.006	0.124 0.009	0.125 0.010	0.126 0.011	0.125 0.008
CNN-Bi- LSTM ^[18] (2024)	0.117 0.005	0.116 0.007	0.118 0.009	0.119 0.006	0.120 0.007	0.117 0.008	0.118 0.008	0.119 0.010	0.122 0.009	0.120 0.011	0.121 0.008	0.118 0.007
TCNN ^[19] (2022)	0.116 0.007	0.114 0.008	0.115 0.005	0.114 0.007	0.115 0.008	0.117 0.006	0.117 0.005	0.116 0.007	0.116 0.009	0.116 0.008	0.119 0.010	0.120 0.011
DS- TCNN (our)	0.083 0.006	0.084 0.006	0.086 0.009	0.087 0.008	0.085 0.008	0.088 0.007	0.084 0.009	0.086 0.008	0.087 0.006	0.086 0.005	0.087 0.009	0.088 0.007

所有深度学习模型中,其运行时间相对较短。其中,DS-TCNN相较于TCNN,运行时间更短,主要得益于其在保证高效特征提取的同时,通过多项优化设计显著减少了不必要的计算开销。DS-TCNN采用膨胀卷积技术,扩大卷积核感受野而不增加参数,能够有效捕捉更广泛的上下文信息,从而减少对更多卷积层的依赖,降低计算复杂度。残差连接引入后,帮助网络能够跳过冗余层,避免了不必要的计算,并通过缓解梯度消失问题加速了训练过程。在DS-TCNN架构中,短期流与长期流的双流设计优化了模型的多尺度特征学习能力,分别处理短期和长期的情绪动态变化,有效避免了对不相关特征的冗余计算,从而进一步提升了计算效率。最后,DS-TCNN通过特征融合机制有效整合短期流和长期流的输出,确保在保留多层次特征提取的同时,避免冗余计算,减少对计算资源的消耗。

综上所述,传统机器学习算法在动态连续情绪识别中的表现明显逊色于深度学习模型,尤其在处理复杂的动态情绪转换时更为显著。尽管CNN及其融合模型展现了良好的性能,但DS-TCNN凭借其在处理短期




图9 DS-TCNN和其他对比方法的运行时间

和长期情绪变化上的独特设计,进一步提高了识别的准确性。实验结果表明,DS-TCNN在所有情绪转换任务中均优于包括TCNN在内的其他10种对比方法,展现出了最高的识别精度和运行效率。

4.3 基于DEAP数据集的算法性能验证

为了进一步验证所提出的DS-TCNN在静态情绪识

中的有效性,本文在经典的脑电数据集 DEAP 上进行了实验,结果如图 10 所示. DEAP 数据集广泛应用于情感计算领域,包含 32 名被试在观看情感诱导视频

时采集的多通道脑电数据,并提供 valence 和 arousal 等情绪标签,是评估情绪识别算法性能的标准数据集之一.




图 10 基于 DEAP 数据集的算法性能对比

实验结果表明,DS-TCNN 在 valence 和 arousal 指标上的 MSE 值分别降低至 0.108 和 0.113,显著优于 CNN、GRU、CGRU、CNN-LSTM、CNN-Bi-LSTM、TCNN 等其他六种深度学习模型,充分证明了该方法在静态情绪数据场景中的优越性和鲁棒性,并展示了其在脑电情绪

识别任务中的卓越性能与广泛适用性.

4.4 消融实验

在消融实验中,本节对 DS-TCNN 模型的不同模块进行了独立评估,以验证各模块在情绪转换任务中的贡献,结果如表 2 所示.

表 2 DS-TCNN 消融实验结果表(均值与标准差)

	平静至开心		开心至平静		平静至悲伤		悲伤至平静		平静至紧张		紧张至平静	
	valence	arousal	valence	arousal	valence	arousal	valence	arousal	valence	arousal	valence	arousal
TCN	0.146 0.008	0.143 0.006	0.144 0.008	0.146 0.009	0.145 0.008	0.144 0.007	0.148 0.010	0.150 0.008	0.147 0.009	0.149 0.010	0.146 0.007	0.148 0.009
Transformer	0.126 0.007	0.125 0.008	0.126 0.005	0.127 0.003	0.128 0.006	0.126 0.007	0.128 0.007	0.127 0.008	0.126 0.006	0.128 0.007	0.127 0.009	0.127 0.005
TCNN	0.116 0.007	0.114 0.008	0.115 0.005	0.114 0.007	0.115 0.008	0.117 0.006	0.117 0.005	0.116 0.007	0.116 0.009	0.116 0.008	0.119 0.010	0.120 0.011
DS-TCNN	0.083 0.006	0.084 0.006	0.086 0.009	0.087 0.008	0.085 0.008	0.088 0.007	0.084 0.009	0.086 0.008	0.087 0.006	0.086 0.005	0.087 0.009	0.088 0.007

在平静至开心情绪转换中,去除时序卷积模块后,仅使用 Transformer 模块的模型表现明显下降, valence 和 arousal 的 MSE 值分别为 0.126 和 0.125;而单独使用时序卷积模块时, MSE 值为 0.146 和 0.143. 相比之下, TCNN 模型的性能有所提升, valence 和 arousal 的 MSE 值分别为 0.115 和 0.114. DS-TCNN 模型在同一任务中表现最为优异, valence 和 arousal 的 MSE 值分别降至 0.084 和 0.083, 标准差低至 0.006, 验证了时序卷积和 Transformer 并行结构在情绪识别中的有效性. 这一趋势在其他情绪转换任务中也得以体现. 例如,在平静至悲伤和悲伤至平静情绪转换中, DS-TCNN 模型的 valence 和 arousal 的 MSE 值分别为 0.085 和 0.086, 明显优于 TCN 和 Transformer 模型. 表中数据还显示, DS-TCNN

模型在不同情绪转换任务中不仅具有更低的误差,还展现出更强的稳定性.

综上所述,消融实验结果表明, DS-TCNN 模型通过并行结合时序卷积和 Transformer 模块,显著提高了情绪识别的准确性,且相较于 TCNN 模型具有更优性能. 这表明时序卷积和 Transformer 的并行结构能够有效提取脑电图信号中的短期和长期特征,从而更好地捕捉情绪变化的细微差异,提升情绪识别的准确性和稳定性.

5 结论

本文着眼于动态连续情绪识别的有效性,提出了一种基于改进 TCNN 算法的脑电动态连续情绪识别方

法. 研究采用 64 通道脑电设备, 采集了六种情绪转换下的脑电信号: 开心到平静、平静到开心、平静到悲伤、悲伤到平静、平静到紧张和紧张到平静. 对这些信号进行了有效的预处理与特征提取, 并将提取的 DE 特征输入到 DS-TCNN 模型中, 实现了高效的动态情绪识别. 实验结果显示, 在本文所采集的动态连续情绪数据集上, DS-TCNN 模型在六种情绪识别任务中的误差范围为 0.084~0.088; 在 DEAP 数据集上, DS-TCNN 在 valence 和 arousal 情绪维度上的误差分别降至 0.108 和 0.113, 相比于其他 6 种性能较好的深度学习模型, 展现出更高的识别精度和稳定性, 充分验证了本方法在脑电情感识别任务中的卓越性能与广泛适用性. 在消融实验中, DS-TCNN 模型通过将时序卷积和 Transformer 模块并行组合, 显著提高了情绪识别的准确性, 且在多种情绪转换任务中优于传统的 TCNN 模型. 研究结果表明, 基于脑电信号的动态连续情绪识别方法不仅能够有效覆盖六种情绪转换的识别需求, 还大幅提升了情绪识别的实用性, 填补了该领域在动态连续情绪识别方面的空白.

参考文献

- [1] CHENG P, LANGEVIN R. Difficulties with emotion regulation moderate the relationship between child maltreatment and emotion recognition[J]. *Child Abuse & Neglect*, 2023, 139: 106094.
- [2] YILDIRIM-CELIK H, EROGLU S, OGUZ K, et al. Emotional context effect on recognition of varying facial emotion expression intensities in depression[J]. *Journal of Affective Disorders*, 2022, 308: 141-146.
- [3] DU Y X, DING H, WU M, et al. MES-CTNet: A novel capsule transformer network base on a multi-domain feature map for electroencephalogram-based emotion recognition[J]. *Brain Sciences*, 2024, 14(4): 344.
- [4] SAMAL P, HASHMI M F. Role of machine learning and deep learning techniques in EEG-based BCI emotion recognition system: A review[J]. *Artificial Intelligence Review*, 2024, 57(3): 50.
- [5] LIU H, LOU T Y, ZHANG Y Z, et al. EEG-based multi-modal emotion recognition: A machine learning perspective[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 1-29.
- [6] JACKSON M C, ARLEGUI-PRIETO M. Variation in normal mood state influences sensitivity to dynamic changes in emotional expression[J]. *Emotion*, 2016, 16(2): 145-149.
- [7] DU X L, MENG Y F, QIU S M, et al. EEG emotion recognition by fusion of multi-scale features[J]. *Brain Sciences*, 2023, 13(9): 1293.
- [8] YUVARAJ R, THAGAVEL P, THOMAS J, et al. Comprehensive analysis of feature extraction methods for emotion recognition from multichannel EEG recordings[J]. *Sensors*, 2023, 23(2): 915.
- [9] 常文文, 闫光辉, 杨志飞, 等. 基于脑电熵值特征和功能连接的不同线型道路下驾驶状态检测[J]. *电子学报*, 2023, 51(10): 2874-2883.
CHANG W W, YAN G H, YANG Z F, et al. Detection of driving state under different curve road based on entropy and functional connectivity of EEG[J]. *Acta Electronica Sinica*, 2023, 51(10): 2874-2883. (in Chinese)
- [10] 张晶, 王翌歆, 任永功. 统一全局空间表达的脑电信号跨被试情感识别[J]. *电子学报*, 2023, 51(5): 1396-1404.
ZHANG J, WANG Y X, REN Y G. Unified global spatial representation for EEG subject-independent emotion recognition[J]. *Acta Electronica Sinica*, 2023, 51(5): 1396-1404. (in Chinese)
- [11] SINGH U, SHAW R, PATRA B K. A data augmentation and channel selection technique for grading human emotions on DEAP dataset[J]. *Biomedical Signal Processing and Control*, 2023, 79: 104060.
- [12] BHATTACHARYA 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.
- [13] CUI H, LIU A P, ZHANG X, et al. EEG-based emotion recognition using an end-to-end regional-asymmetric convolutional neural network[J]. *Knowledge-Based Systems*, 2020, 205: 106243.
- [14] ZHU X L, RONG W T, ZHAO L, et al. EEG emotion classification network based on attention fusion of multi-channel band features[J]. *Sensors*, 2022, 22(14): 5252.
- [15] GUO Y Q, ZHANG B W, FAN X M, et al. A comprehensive interaction in multiscale multichannel EEG signals for emotion recognition[J]. *Mathematics*, 2024, 12(8): 1180.
- [16] WU X, ZHANG Y M, LI J J, et al. FC-TFS-CGRU: A temporal-frequency-spatial electroencephalography emotion recognition model based on functional connectivity and a convolutional gated recurrent unit hybrid architecture[J]. *Sensors*, 2024, 24(6): 1979.
- [17] PATLAR A F. Hybrid deep convolutional model-based emotion recognition using multiple physiological signals[J]. *Computer Methods in Biomechanics and Biomed-*

- ical Engineering, 2022, 25(15): 1678-1690.
- [18] HUANG Z T, MA Y H, WANG R R, et al. A model for EEG-based emotion recognition: CNN-Bi-LSTM with attention mechanism[J]. Electronics, 2023, 12(14): 3188.
- [19] YAO X Z, LI T W, DING P, et al. Emotion classification based on transformer and CNN for EEG spatial-temporal feature learning[J]. Brain Sciences, 2024, 14(3): 268.
- [20] MA Y L, ZHAO W C, MENG M, et al. Cross-subject emotion recognition based on domain similarity of EEG signal transfer learning[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 936-943.
- [21] LI G F, OUYANG D L, YUAN Y F, et al. An EEG data processing approach for emotion recognition[J]. IEEE Sensors Journal, 2022, 22(11): 10751-10763.
- [22] SAHA O, MAHMUD M S, FATTAH S A, et al. Automatic emotion recognition from multi-band EEG data based on a deep learning scheme with effective channel attention[J]. IEEE Access, 2022, 11: 2342-2350.
- [23] FOX N A. If it's not left, it's right: Electroencephalograph asymmetry and the development of emotion[J]. American Psychologist, 1991, 46(8): 863-872.
- [24] QIAO W X, SUN L, WU J H, et al. EEG emotion recognition model based on attention and GAN[J]. IEEE Access, 2024, 12: 32308-32319.
- [25] WANG J G, SHAO H M, YAO Y, et al. Electroencephalograph-based emotion recognition using convolutional neural network without manual feature extraction[J]. Applied Soft Computing, 2022, 128: 109534.
- [26] ZHANG J H, HAO Y R, WEN X, et al. Subject-independent emotion recognition based on EEG frequency band features and self-adaptive graph construction[J]. Brain Sciences, 2024, 14(3): 271.
- [27] QU G G, WANG F, BI J Y, et al. A hybrid critical channel selection framework for EEG emotion recognition[J]. IEEE Sensors Journal, 2024, 24(9): 14881-14893.
- [28] AL-QAZAZ N K, SABIR M K, ALI S H B M, et al. Electroencephalogram profiles for emotion identification over the brain regions using spectral, entropy and temporal biomarkers[J]. Sensors, 2019, 20(1): 59.
- [29] ZHAO G Z, ZHANG Y L, ZHANG G H, et al. Multi-target positive emotion recognition from EEG signals[J]. IEEE Transactions on Affective Computing, 2023, 14(1): 370-381.
- [30] AGARWAL R, ANDUJAR M, CANAVAN S. Classification of emotions using EEG activity associated with different areas of the brain[J]. Pattern Recognition Letters, 2022, 162: 71-80.
- [31] CHEN T, YIN H F, YUAN X H, et al. Emotion recognition based on fusion of long short-term memory networks and SVMs[J]. Digital Signal Processing, 2021, 117: 103153.
- [32] BAI S J, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. Computer Science, 2018, 1: 1803.01271.
- [33] DU X B, MA C X, ZHANG G H, et al. An efficient LSTM network for emotion recognition from multichannel EEG signals[J]. IEEE Transactions on Affective Computing, 2022, 13(3): 1528-1540.
- [34] HOSSEINI S M, TALEPASSAND S, BIGDELI I. Brain activity and affect: Overall and asymmetric activity of the brain lobes in affective states[J]. Journal of Research in Medical Sciences, 2009, 14(5): 309-311.
- [35] VEMPATI R, SHARMA L D. EEG rhythm based emotion recognition using multivariate decomposition and ensemble machine learning classifier[J]. Journal of Neuroscience Methods, 2023, 393: 109879.
- [36] YU X K, LI Z J, ZANG Z B, et al. Real-time EEG-based emotion recognition[J]. Sensors, 2023, 23(18): 7853.
- [37] LIU S Q, ZHAO Y Y, AN Y L, et al. GLFANet: A global to local feature aggregation network for EEG emotion recognition[J]. Biomedical Signal Processing and Control, 2023, 85: 104799.
- [38] LI G F, YUAN B W, OUYANG D L, et al. Emotion recognition based on selected EEG signals by common spatial pattern[J]. IEEE Sensors Journal, 2024, 24(6): 8414-8426.
- [39] SONG Y B, FAN C L, MAO X Q. Optimization of epilepsy detection method based on dynamic EEG channel screening[J]. Neural Networks, 2024, 172: 106119.
- [40] LI G F, OUYANG D L, YANG L, et al. Cross-subject EEG linear domain adaption based on batch normalization and depthwise convolutional neural network[J]. Knowledge-Based Systems, 2023, 280: 111011.
- [41] LI Q, LIU Y Q, LIU Q Y, et al. Multidimensional feature in emotion recognition based on multi-channel EEG signals[J]. Entropy, 2022, 24(12): 1830.
- [42] LI X, SHEN F Y, PENG Y, et al. Efficient sample and feature importance mining in semi-supervised EEG emotion recognition[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022, 69(7): 3349-3353.

- [43] ZHANG Y K, PENG Y, LI J H, et al. SIFIAE: An adaptive emotion recognition model with EEG feature-label inconsistency consideration[J]. Journal of Neuroscience Methods, 2023, 395: 109909.
- [44] GUO J Y, CAI Q, AN J P, et al. A Transformer based neural network for emotion recognition and visualizations of crucial EEG channels[J]. Physica A: Statistical Mechanics and Its Applications, 2022, 603: 127700.
- [45] KANG D, KIM D, KANG D, et al. Beyond superficial emotion recognition: Modality-adaptive emotion recognition system[J]. Expert Systems with Applications, 2024, 235: 121097.

作者简介



揭丽琳 女,1987年8月出生于江西省抚州市.现为南昌航空大学仪器科学与光电工程学院副教授.主要研究方向为情感脑机接口、智能计算理论及应用.

E-mail: jielilin@nchu.edu.cn



邹杨萌 男,1998年1月出生于江西省九江市.现为南昌航空大学仪器科学与光电工程学院硕士研究生.主要研究方向为多模态情绪识别.

E-mail: 1285557297@qq.com



刘勇 男,1999年7月出生于湖南省衡阳市.现为南昌航空大学仪器科学与光电工程学院硕士研究生.主要研究方向为脑电情绪识别.

E-mail: 18273438463@163.com



徐亦璐 女,1980年2月出生于江西省南昌市.现为江西农业大学软件学院副教授.主要研究方向为脑机接口信号处理算法.

E-mail: jielilin@nchu.edu.cn



王铭勋 男,1983年10月出生于江西省南昌市.现为南昌航空大学航空服务与音乐学院副教授.主要研究方向为脑电音乐、影视表演理论.

E-mail: 70633@nchu.edu.cn



鲁宇明 女,1969年4月出生于江西省南昌市.现为南昌航空大学航空制造与机械工程学院教授.主要研究方向为群智能算法.

E-mail: luyuming@nchu.edu.cn