

用于脑电情绪识别的三子空间 解耦聚类图神经网络研究

黄 辰^{1,2,3,4}, 马浩博^{1,2,3,4}, 张 龔^{1,2,3,4*}, 杨 超^{1,2,3,4}, 宋建华^{2,3,4,5}

(1. 湖北大学计算机学院, 湖北武汉 430062; 2. 智能感知系统与安全教育部重点实验室, 湖北武汉 430062; 3. 大数据智能分析与行业应用湖北省重点实验室, 湖北武汉 430062; 4. 湖北省高校人文社科重点研究基地-绩效评价信息管理研究中心, 湖北武汉 430062; 5. 湖北大学网络空间安全学院, 湖北武汉 430062)

摘 要: 图神经网络(Graph Neural Networks, GNNs)因其能够建模大脑区域间的时空依赖关系并捕捉上下文感知的神经模式, 在基于脑电图(Electroencephalography, EEG)的情感识别中得到了广泛关注. 然而, 大多数基于 GNN 的 EEG 情感识别方法面临两个主要挑战: (1) 许多现有模型未能考虑局部大脑区域间情感的共性和多样性, 导致空间或功能相邻区域的节点嵌入过于同质化; (2) 当前的方法通常依赖于简单的拼接或基于相关性的先验知识, 这对于捕捉多个 EEG 通道和频带间复杂且分布的情感模式是不充分的. 本文提出了一种三子空间解耦聚类图神经网络(Tri-Subspace-Decoupled Clustering Graph Neural Network, TS-DCGNN)来解决上述挑战. 具体来说, TS-DCGNN 将 EEG 信号解耦为三个子空间: 显性情感子空间、隐性情感子空间和显性-隐性共振子空间, 旨在捕捉可观察的情感体验(如“快乐”)、自动反应(如“惊吓”)及其耦合. 此外, 本文引入了一种双分支传播架构, 其中图注意力网络(Graph Attention Networks, GATs)和图卷积网络(Graph Convolutional Networks, GCNs)并行操作, 通过注意力驱动交互和分层学习提取显性和隐性特征, 从而增强区域情感表示. 进一步地, 本文提出了一个统一的表示学习模块, 整合这些特征, 并运用信息论方法来获得最小、充分和具有辨识度情感表示. 三个基准数据集上的实验表明, 所提方法在性能上达到了最先进的水平, 并提升了可解释性.

关键词: 基于脑电图的情感识别; 图神经网络; 特征解耦; 局部-全局建模; 信息论表示学习

中图分类号: TP391; TP399 **文献标识码:** A **文章编号:** 0372-2112(2025)11-4065-12

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

DOI: 10.12263/DZXB.20250555

Research on Tri-Subspace Decoupling Clustering Graph Neural Network for EEG-Based Emotion Recognition

HUANG Chen^{1,2,3,4}, MA Hao-bo^{1,2,3,4}, ZHANG Yan^{1,2,3,4*}, YANG Chao^{1,2,3,4}, SONG Jian-hua^{2,3,4,5}

(1. School of Computer Science, Hubei University, Wuhan, Hubei 430062, China;

2. Key Laboratory of Intelligent Sensing System and Security, Ministry of Education, Wuhan, Hubei 430062, China;

3. Hubei Key Laboratory of Big Data Intelligent Analysis and Application, Wuhan, Hubei 430062, China;

4. Hubei Province Project of Key Research Institute of Humanities and Social Sciences at Universities - RCIMPE, Wuhan, Hubei 430062,

China; 5. School of Cyber Science and Technology, Hubei University, Wuhan, Hubei 430062, China)

Abstract: Graph neural networks (GNNs) have gained significant attention in electroencephalography (EEG)-based emotion recognition for their ability to model spatial-temporal dependencies across brain regions and capture context-aware neural patterns. However, most GNN-based EEG emotion recognition methods encounter two primary challenges: (1) Many existing models fail to account for the emotional commonality and diversity across local brain regions, resulting in overly homogeneous node embeddings for spatially or functionally adjacent regions; (2) Current approaches often rely on simple concatenation or correlation-based priors, which are inadequate for capturing the complex and distributed emotional patterns across multiple EEG channels and frequency bands. In this paper, we propose a tri-subspace decoupling clustering graph neural network (TS-DCGNN) to address the above challenges. Specifically, TS-DCGNN decouples EEG signals into three subspaces: the explicit emotional, implicit emotional, and explicit-implicit resonance subspaces, aiming to capture observ-

able experiences (e.g., “happiness”), automatic responses (e.g., “startle”), and their coupling. Moreover, we introduce a dual-branch propagation architecture where graph attention networks (GATs) and graph convolutional networks (GCNs) operate in parallel to extract explicit and implicit features via attention-driven interaction and hierarchical learning. This enhances regional emotional representations. Furthermore, we present a unified representation learning module that integrates these features and employs information theory to obtain a minimal, sufficient, and discriminative emotional representation. Experiments on three benchmark datasets demonstrate state-of-the-art performance and improved interpretability.

Key words: EEG-based emotion recognition; graph neural networks; feature decoupling; local-global modeling; information-theoretic representation learning

1 引言

情感在人类心理功能中扮演着核心调节角色,对个体适应和社会交往至关重要^[1].近年来,基于EEG (ElectroEncephaloGraphy)的情感识别作为一个前沿领域,广泛应用于智能医疗^[2]、情感感知辅导系统^[3]和人机互动^[4]等领域.与单一对话情感计算相比,EEG-based方法面临去噪、特征提取和神经生理模式建模的挑战.图神经网络在建模结构依赖关系上表现出色,已广泛应用于脑网络分析、癫痫检测和认知状态分类等领域.在EEG情感识别中,图神经网络(Graph Neural Networks, GNNs)有效利用了EEG数据中固有的空间相关性和跨通道交互.许多研究通过功能性度量(如皮尔逊相关、互信息)^[5]构建连接图,将电极作为节点,边缘表示通道间的神经关系,或采用模态感知图^[6]增强多尺度特征建模.然而,这种双模态信息无论是一致的还是不一致的,对于解码细微的情感状态并在现实世界的EEG任务中实现强大的性能至关重要.因此,如何从显性和隐性信号中探索并传播适当的情感信息,成为基于EEG的情感识别中的一个关键挑战.

为了解决EEG情感识别中的挑战,本文提出了一种三子空间解耦聚类图神经网络(Tri-Subspace Decoupling Clustering Graph Neural Network, TS-DCGNN),旨在通过解耦神经信号中的情感和认知成分,实现高精度分类.与传统方法通常依赖线性相关假设并单独处理情感或认知特征不同,本文框架将EEG信号映射到三个正交约束的子空间,提取显性和隐性情感成分.具体而言, Z 子空间捕捉主观可观察到的情感体验(如“快乐”“紧张”), R 子空间建模自动和无意识的情感处理(如“警觉”“惊讶”), H 子空间保留跨频率共振特征,反映情感与认知的协同整合.为了更好地表征这些成分,本文设计了一个双分支架构,结合图注意力网络和图卷积网络,分别增强局部情感区分模式和全局神经拓扑依赖.此外,本文还设计了一个三子空间解耦模块,将EEG信号投影到显性、隐性和共振子空间,从而实现情感状态、无意识处理和情感认知耦合的解耦.双分支架构使用图注意力网络(Graph Attention Networks, GATs)和图卷积网络(Graph Convolutional Networks, GCNs)建模大脑区域间的局部和全局情感依赖,动态增

强显性和隐性情感成分的表示.最后,统一的表征学习模块整合多子空间嵌入,促进紧凑且具有区分性的情感表征.该框架通过解耦和增强EEG中的情感与认知信号,提供了一种综合方法用于情感识别,确保显性和隐性情感成分都能得到有效建模,并适用于现实世界的情感识别任务.

2 相关工作

基于EEG的情感识别工作流程通常包括数据采集、预处理、特征提取、特征选择、分类器训练和模型部署.由于EEG信号易受伪影干扰,预处理的主要任务是去除眼动(ElectroOculoGraphy, EOG)、肌电(ElectroMyoGraphy, EMG)等干扰^[7-9].通过带通滤波器(通常范围为4~45 Hz)可有效去除频率超出0~100 Hz范围的伪影,PCA (Principal Component Analysis)^[10]和ICA (Independent Component Analysis)^[11]也常用于噪声抑制.情感状态的特征提取是关键,常用的特征有时域特征(Time Domain Features, TDF)、频域特征(Frequency Domain Features, FDF)^[12]和时频域特征(Time-Frequency Domain Features, TFDF)^[13].传统分类器如 k -最近邻(k -Nearest Neighbors, kNN)^[14]、支持向量机(Support Vector Machine, SVM)^[15]和随机森林(Random Forest, RF)^[16]常用于情感分类.深度学习的进展使得端到端处理成为可能,卷积神经网络(CNN)^[17]、循环神经网络(Recurrent Neural Network, RNN)^[18]和结合CNN与LSTM (Long Short-Term Memory)的混合架构已展示出卓越的性能.

图神经网络(GNNs)在脑网络分析中因其能够建模非欧几里得神经结构中的复杂拓扑依赖关系而受到广泛关注.受多尺度和多通道交互作用在EEG情感识别中的重要性启发,Guo等人^[19]提出了级联尺度感知自适应图卷积网络(Scale-Aware Graph Convolutional Network with Cross EEG Transformer, SAG-CET),并结合跨EEG转换器(Transformer),在DEAP和DREAMER数据集上实现了显著的情感分类性能.Li等人^[20]提出的多尺度GCN,结合自适应邻接学习,在ADNI (Alzheimer’s Disease Neuroimaging Initiative)数据集上达到了较高的AUC (Area Under the Curve).Kuang等人^[21]提出了Coarformer模型,结合粗粒度的全局建模与细粒度的局部特

征提取,获得了强大的 F1 分数. 然而,现有模型面临 EEG 数据集可扩展性差的问题,容易导致过拟合. 为解决这一问题,现有方法常将 EEG 信号分解为多个子空间,以隔离不同的神经信息流,通常包括捕捉跨条件共享表示的模态不变子空间,以及保留任务或区域特定特征的模态特定子空间^[22].

为进一步提升 EEG 情感识别效果,本文提出了一种子空间解耦策略,将 EEG 特征分解为三个功能性子空间: Z 子空间用于捕捉显著的情感相关神经反应; R 子空间隔离与认知处理交织的隐性情感信息; H 子空间保留表征情感-认知耦合的跨频率共振模式. 基于这一

解耦策略,我们引入了基于图的消息传递机制,通过动态细化跨空间分布的 EEG 通道特征传播,减轻过平滑现象,并增强情感分类的区分性.

3 方法

在本节中,本文首先提供该问题的正式定义. 然后,本文介绍了所提出的 TS-DCGNN,其整体架构如图 1 所示(图中结构图形参考自 MLVIsuals 模板绘制^[23]). TS-DCGNN 由四个关键组件组成: EEG 特征编码、EEG 特征解耦、双分支图传播架构和统一表示学习模块. TS-DCGNN 各部分的详细信息将在下文中介绍.

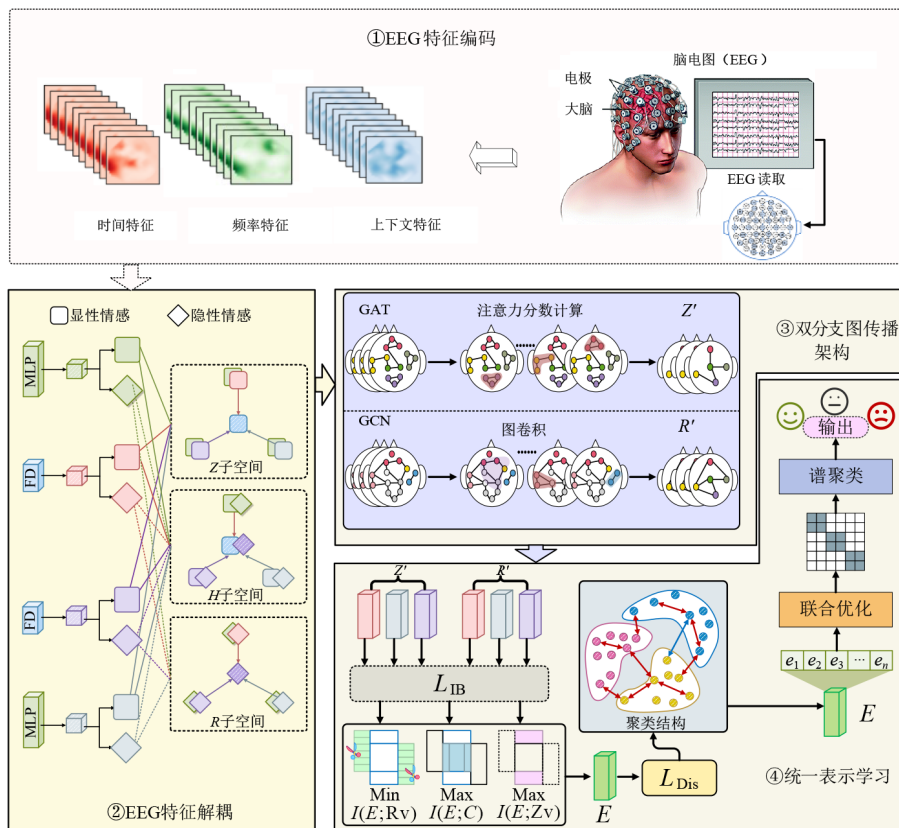


图 1 TS-DCGNN 模块设计

3.1 EEG 特征编码

为了从编码的 EEG 表示 u_i 中捕捉动态神经模式,本文构建了一个复合网络架构,提取时间、空间和基于注意力的特征:

$$h_i = \begin{cases} h_i^c = \text{TCN}(u_i^t; \text{kernelsize} = 5, \text{dilation} = [2, 4, 8]) \\ h_i^s = \text{MLP}(u_i^s; 512 \rightarrow 256) + \lambda \|W_s^T W_s - I\|_F \\ h_i^d = \text{MultiHead-Attn}(u_i^t) \end{cases} \quad (1)$$

其中, $h_i = \{h_i^c, h_i^s, h_i^d\}$ 表示一组三支的高层动态神经特征. 时间分支 h_i^c 通过一个时间卷积网络(Temporal Convolutional Network, TCN)提取,卷积核大小为 5,扩

张率为 $[2, 4, 8]$,使得模型能够多尺度地建模时间依赖关系,并且感受野约为 1.2 s. 空间分支 h_i^s 通过多层感知机(Multi-Layer Perceptron, MLP)获得,MLP 将 $u_i^s \in \mathbb{R}^{512}$ 投影到 \mathbb{R}^{256} ,并且施加了一个基于弗罗贝纽斯范数的正交性正则化项 $\|W_s^T W_s - I\|_F$,以抑制通道之间的共线性;所得变换矩阵 W_s 保持条件数 $k(W_s) < 10$,以确保数值稳定性. 注意力分支 h_i^d 通过对时间分量 u_i^t 进行多头自注意力(multi-head self-attention)计算,捕捉跨频率依赖关系和相位同步,特别是在 θ - γ 频段内. 相位锁定值(PLV)为 0.79 ± 0.05 ,反映了跨试次的强大的节律间耦合.

3.2 EEG 特征解耦

解耦子空间划分方法在神经科学与情绪心理学的研究中具有广泛的应用价值. 显性子空间与额顶区的情绪反应密切相关, 研究表明, 额顶区在情绪处理和情感认知中的作用至关重要^[1]. 隐性子空间则与杏仁核和前扣带皮层的潜在加工过程紧密相连, 这些区域涉及情绪的感知、调节和表达, 是情绪调节网络的重要组成部分^[24]. 此外, 共振子空间则揭示了 θ - γ 频段的跨频耦合现象, 这种跨频耦合在情绪调节和认知过程中起到了关键作用, 反映了大脑不同频段之间的协同工作机制^[12]. 这种子空间划分不仅有助于揭示不同大脑区域之间的相互作用, 也为情绪的神经机制研究提供了新的视角和方法.

(1) 显性情感子空间 (Z)

显性情感子空间 Z 通过自适应空间滤波从额顶区汇聚情感相关的神经特征, 主要捕捉愉悦度和激励度等关键情感特征. 为了将融合的特征投影到 Z 子空间, 本文采用了一个多层感知机 (MLP), 包含三层全连接层 (256, 128, 64), 并使用参数化 ReLU 激活函数, 以保持梯度流并减少饱和效应. 有

$$z_i = \text{MLP}_z(\mathbf{h}_i) \in \mathbb{R}^d. \quad (2)$$

该架构能够有效地提取和投影与情绪相关的特征 (例如, 愉悦度、唤醒度) 到显性情感子空间 Z 中. 为了确保子空间 Z 仅保留情绪特定的特征, 并消除任何潜在的认知干扰, 本文对变换矩阵 \mathbf{W}_z 施加了正交投影约束:

$$\|\mathbf{W}_z^T \mathbf{W}_z - \mathbf{I}\|_F^2 < 0.1 \quad (3)$$

其中, \mathbf{W}_z 表示可学习的变换矩阵; \mathbf{I} 是单位矩阵; $\|\cdot\|_F$ 表示 Frobenius 范数. 最小化该项强制 $\mathbf{W}_z^T \mathbf{W}_z \approx \mathbf{I}$, 确保投影到子空间 Z 是正交的, 并且不与认知成分纠缠.

此外, 为了优化显性情感特征的学习并增强子空间的情绪特异性, 本文引入了以下显性情感子空间的损失函数:

$$\mathcal{L}_{\text{sz}} = -\frac{1}{N} \sum_{i=1}^N y_i \log(\hat{y}_i^o) \quad (4)$$

其中, y_i 表示真实的情绪标签; \hat{y}_i^o 是对显性情感特征的预测概率; N 是样本的总数. 该损失函数旨在最小化预测情绪标签与真实情绪标签之间的差异, 确保 Z 子空间中的显性情感特征与期望的情绪类别紧密对齐.

(2) 隐性情感子空间

隐性情感子空间 R 作为显性情感子空间的正交互补, 捕捉了稳定的认知特征 (例如, 工作记忆和注意力), 这些特征可能蕴含潜在的情感信号. 为了揭示这些隐藏的线索并确保时间一致性, 本文引入了一个正则化的互相关损失, 约束不同情境下的特征变化, 从而

增强情感信息在认知特征中的嵌入.

为了解耦情感特征和认知特征, 本文采用了一个双重约束机制, 最小化它们的互信息. 情感干扰抑制使用变分对比对数比上界^[25] 来估计 $I(R; Y)$, 即

$$I_{\text{vCLUB}}(r_i, y_i) = E_{(r, y)} [\log q\theta(y|r)] - E_{p(r)} E_{p(y)} [\log q\theta(y|r)] \quad (5)$$

其中, $q\theta(y|r)$ 是变分分布, 用于近似真实的条件分布 $p(y|r)$. 第一项计算基于联合分布 $p(r_i, y_i)$ 的变分分布 $q\theta(y|r)$ 的对数似然的期望. 第二项计算变分分布在边际分布 $p(r)$ 和 $p(y)$ 上的对数似然的期望. 最小化这一差异通过减少潜在情绪特征 r_i 与情绪标签 y_i 之间的依赖关系, 从而降低情绪干扰.

本文使用互信息神经估计器 (Mutual Information Neural Estimator, MINE)^[26] 来估计 $I(R; H)$ 的下界, 该项衡量了通过判别网络 f_ϕ 计算的 r_i 和 y_i 之间的依赖关系, 即

$$I_{\text{MINE}}(r_i, \mathbf{h}_i) = E_{p(r, h)} [f_\phi(r, h)] - \log \left(E_{p(r)p(h)} [e^{f_\phi(r, h)}] \right) \quad (6)$$

其中, $f_\phi(r, h)$ 是由 ϕ 参数化的得分函数, 用于衡量认知特征 \mathbf{h}_i 和潜在情绪特征 r_i 之间的依赖关系. 第一项计算得分函数在联合分布 $p(r, h)$ 上的期望, 而第二项通过计算边际分布 $p(r)$ 和 $p(h)$ 上的期望来对分布进行归一化.

(3) 显性-隐性情感共振子空间

H 子空间有助于稳定编码器训练并防止崩溃. 在情感-认知处理过程中, 它保留了重要的神经信号成分, 确保在 Z 和 R 的正交分解过程中没有关键信息丢失. 一旦训练收敛, H 被完全编码在联合的 Z - R 空间中, 并且在推理过程中可以省略而不会影响信息的完整性.

首先, 将融合的特征通过一个多层感知机投影到 H 中, 该 MLP 处理拼接后的特征 $[z_i, r_i]$:

$$\hat{\mathbf{h}}_i = \text{MLP}_d(z_i, r_i) \in \mathbb{R}^{d_h} \quad (7)$$

其中, z_i 表示编码情感信息的显性情感特征, 而 r_i 则指代保留情感状态间稳定认知模式的隐性情感特征.

其次, 一个复合重建损失防止了关键信息的丢失和过度压缩, 保留了重要的情感和认知特征. 对于 H 子空间组件 δ , 该损失为

$$L_{\text{drecon}} = \frac{1}{N} \sum_{i=1}^N \|\hat{\mathbf{h}}_{di} - D_\delta(z_{di} - r_{di})\|_2^2 \quad (8)$$

其中, $D_\delta(\cdot)$ 是解码器. 该损失确保重建的特征与原始特征高度匹配, 从而稳定 H 子空间的学习.

3.3 双分支图传播架构

在基于 EEG 的情感识别中, 区分情感特定信号与重叠的认知信息具有挑战性. 为此, 本文提出了一种混合架构, 将图卷积网络 (GCN) 和图注意力网络 (GAT) 结

合,分别增强显性和隐性情感特征.与现有的 GCN、GAT 或 Dual-GCN 方法不同,TS-DCGNN 的创新在于其基于“显性-隐性-共振”三子空间解耦的核心思想,采用结构性分离情绪与认知信息流,从而提供更具可解释性的表示.在此框架下,模型设计了子空间驱动的双分支传播机制,将 GAT 与显性情绪特征对应,捕捉局部差异化依赖;将 GCN 与隐性情绪特征对应,整合全局拓扑模式,并保留共振子空间维持跨频交互的稳定信息传递.与传统方法相比,TS-DCGNN 避免了特征流干扰,并突破了仅依赖双卷积堆叠的局限.此外,TS-DCGNN 在统一表示学习阶段引入信息瓶颈约束和最大编码率正则化,确保表征在压缩冗余的同时保持高判别性和类间可分性,从而有效缓解过拟合与嵌入漂移.

(1)显性情感特征首先通过 GAT 层,该层捕捉与情感相关的 EEG 数据中的局部关系.节点 i 和 j 之间的注意力分数 e_{ij} 计算如下:

$$e_{ij} = \text{LeakyReLU}\left(\mathbf{a}^\top [\mathbf{W}\mathbf{h}_i; \mathbf{W}\mathbf{h}_j]\right) \quad (9)$$

其中, \mathbf{a} 是学习得到的注意力权重向量; \mathbf{W} 是学习得到的权重矩阵; \mathbf{h}_i 和 \mathbf{h}_j 分别是节点 i 和 j 的特征向量.注意力系数 a_{ij} 通过使用 softmax 函数对注意力分数进行归一化计算:

$$a_{ij} = \frac{\exp(e_{ij})}{\sum_{k \in N(i)} \exp(e_{ik})} \quad (10)$$

其中, $N(i)$ 表示节点 i 的邻居集合.节点特征通过聚合邻居节点的特征进行更新,聚合时使用注意力系数加权:

$$\mathbf{h}'_i = \sigma\left(\sum_{j \in N(i)} a_{ij} \mathbf{W}\mathbf{h}_j\right) \quad (11)$$

其中, σ 是 ELU 激活函数:

$$\text{ELU}(x) = \begin{cases} x, & \text{if } x > 0, \\ a(\exp(x)), & \text{if } x \leq 0 \end{cases} \quad (12)$$

经过 GAT 层后,显性情感特征通过聚焦于显性情感子空间中最相关的情感连接得到了增强.

(2)用于隐性情感特征增强的 GCN 层,隐性情感特征通过 GCN 层进行处理,该层捕捉隐性情感子空间的全局连接模式. GCN 层通过使用邻接矩阵 $\tilde{\mathbf{A}}$ (包括自环)和度矩阵 $\tilde{\mathbf{D}}$,更新特征矩阵 $\mathbf{H}^{(l+1)}$:

$$\mathbf{H}^{(l+1)} = \sigma\left(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}^{(l)} \mathbf{W}^{(l)}\right) \quad (13)$$

其中, $\mathbf{H}^{(l)}$ 是第 l 层的特征矩阵; $\mathbf{W}^{(l)}$ 是第 l 层的权重矩阵.激活函数 σ 通常为 ReLU. GCN 层捕捉 EEG 图中的更广泛结构依赖关系,从而提供对隐性情感特征的更强健表示.

(3)最终特征表示

该混合模型的最终输出由增强后的显性情感特征

Z' 和隐性情感特征 R' 组成. GAT 层用于捕捉局部的情感依赖关系,而 GCN 层则用于捕捉 EEG 图中更广泛的结构性依赖.增强后的特征随后被用于下游任务,如情感分类,以提升情感识别模型的准确性.

混合 GCN-GAT 模型的整体工作流程如图 2 所示,图 2 展示了特征输入、显性/隐性子空间解耦、双路径传播和统一表示学习的完整过程.最终得到的增强特征 Z' 和 R' 被用来构建最终的情感表示,这对于 EEG 信号中的情感识别至关重要.

该混合 GCN-GAT 模型有效融合了 GAT 的局部情感细节增强能力与 GCN 的全局结构学习能力,生成了更具表现力的情感特征表示,从而显著提升了基于 EEG 的情感识别系统的性能.

3.4 统一表示学习

在通过 GAT-GCN 双路径网络增强显性情感特征 $Z' \in \mathbb{R}^{D \times n}$ 和隐性情感特征 $R' \in \mathbb{R}^{D \times n}$ 后,本文将这两种特征流整合到一个统一的表示学习模块中.该模块利用信息论约束来推导一个紧凑而富有表现力的情感表示 $E \in \mathbb{R}^{D \times n}$,该表示捕捉了这两种特征中最具信息量和辨别性的特征.

统一表示 E 被鼓励尽可能保留与情感相关的信息.具体来说,本文的目标是最大化互信息 $I(E; C)$,其中 C 表示聚类信息,以及 $I(E; Z_v)$,其中 Z_v 表示与任务相关的辅助视图.这个最大化确保了该表示对于识别任务具有足够的信息量.同时,应该通过减少 $I(E; R_v)$ 来最小化无关信息,例如认知噪声,其中 R_v 捕捉数据中与噪声相关的成分.信息瓶颈损失可以表示为

$$\mathcal{L}_{\text{IB}} = \sum_{v=1}^V (I(E; R_v) - I(E; Z_v)) - I(E; C) \quad (14)$$

由于 Kullback-Leibler (KL) 散度的非负性,这自然导致了以下不等式:

$$\begin{aligned} \text{KL}[P(e)||q(e)] \geq 0 &\Rightarrow \int p(e) \log \frac{p(e)}{q(e)} de \\ &\Rightarrow \int p(e) \log p(e) de \geq \int p(e) \log q(e) de \end{aligned} \quad (15)$$

基于以上结果,本文可以推导出以下 $I(E; R_v)$ 的变分上界:

$$I(E; R_v) \leq \int p(rv) \int p(e|rv) \log \frac{p(e|rv)}{q(e)} de drv \quad (16)$$

通过引入变分近似 $r(e|z_v)$ 来近似后验概率分布 $p(e|z_v)$,本文可以推导出 $I(E; Z_v)$ 的变分下界,具体如下:

$$I(E; Z_v) \geq \int p(zv) \int p(e|zv) \log r(e|zv) de dzv + H(E) \quad (17)$$

以类似于计算 $I(E; Z_v)$ 的方式,对于 $I(E; C)$,本文可以得到如下表达式:

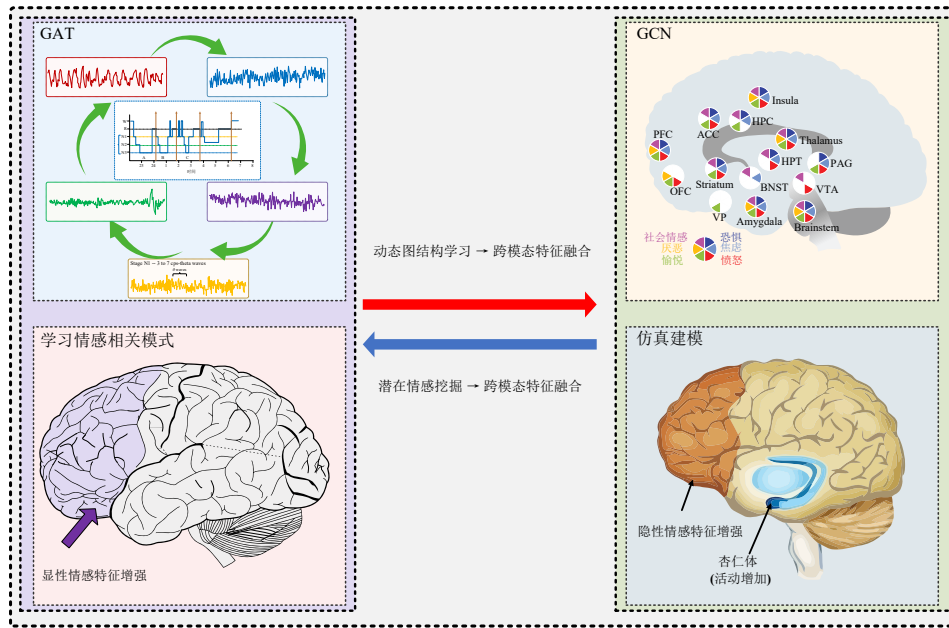


图2 EEG情感识别中混合GCN-GAT模型的整体工作流程

$$I(E; C) \geq p(e, c) \log \frac{t(e, c)}{p(e)} de dc \quad (18)$$

将上述变分界限代入信息瓶颈损失^[27]中, 本文可以将 \mathcal{L}_{IB} 重写为

$$\begin{aligned} \mathcal{L}_{IB} \leq & \sum_{v=1}^V \left(\int p(zv) \int p(e|zv) \log \frac{p(e|zv)}{q(e)} de dzv \right) \\ & - \int p(zv) \int p(e|zv) \log(e|zv) de dzv \quad (19) \\ & - \int p(c) \int p(e|c) \log t(e, c) de dc \end{aligned}$$

不失一般性, 本文假设后验概率分布 $p(e|zv)$ 和 $p(e|c)$ 遵循高斯分布. 这些分布的均值和方差通过神经网络进行学习, 具体为 $p(e|zv) = \mathcal{N}(\mu_1(zv; \phi_1), \sigma_1(zv; \phi_1))$ 和 $p(e|c) = \mathcal{N}(\mu_2(c; \phi_2), (\sigma_2(c; \phi_2))$, 其中 $\mu_1(zv; \phi_1)$ 和 $\sigma_1(zv; \phi_1)$ 是 $p(e|zv)$ 的均值和方差, 而 $\mu_2(c; \phi_2)$ 和 $\sigma_2(c; \phi_2)$ 是 $p(e|c)$ 的均值和方差. 参数 ϕ_1 和 ϕ_2 是通过网络学习得到的. 为了便于反向传播, 本文采用重新参数化技巧, 这个技巧使得反向传播变得高效.

然后得到一个分块对角矩阵 $\Pi = \{\Pi_k\}_{k=1}^K$, 其中对角线元素 $\Pi_k \in \mathbb{R}^{n \times n}$ 表示与簇 k 对应的关系矩阵. 对于簇 k , 如果第 i 个样本属于该簇, 则 $\Pi_k^{i,j} = 1$, 否则 $\Pi_k^{i,j} = 0$. 基于先前优化中获得的一致性, 矩阵 Π 被初始化为相对理想的形式.

MCR^[28]可以通过最大化所有样本与每个簇的总和之间的编码率差异来有效地学习一个具有辨别性的表示. 为了实现这一目标, 本文将来自不同簇的所有特征扩展到尽可能大的空间, 从而最大化全局编码率. 同时, 本文将每个簇压缩到最小的可能子空间, 从而最小

化局部编码率. 这个方法导致了以下的辨别损失函数:

$$\mathcal{L}_{Dis} = -R(E) + R_C(E, \Pi) \quad (20)$$

全局编码率 $R(E)$ 被定义为


$$R(E) = \frac{1}{2} \log \det \left(I + \frac{d}{n\epsilon^2} EE^T \right) \quad (21)$$

其中 $\epsilon > 0$ 是给定的失真率, 且根据文献[29]中的建议, 默认将 ϵ^2 设置为0.5. 函数 $\det(\cdot)$ 表示行列式的计算. 局部编码率可以用数学公式表示为

$$R_C(E, \Pi) = \sum_{k=1}^K \text{tr}(\Pi_k) \frac{1}{2n} \log \det \left(I + \frac{d}{\text{tr}(\Pi_k \epsilon^2)} \Pi_k EE^T \Pi_k \right) \quad (22)$$

其中 ϵ 是失真率, $\text{tr}(\Pi_k)$ 是矩阵 Π_k 的迹, 捕捉了类别间特征分布. 基于统一表示 $E = \{e_i\}_{i=1}^n$, 关系度量网络 (Relation-Metric Network, RMN) 被设计用于直接测量所有样本对之间的相似度, 而不是使用参数化的全连接层, 如图3所示.

该自表达学习模块使模型能够直接学习样本之间的关系, 从而提升捕捉和利用样本间依赖关系的能力, 这对于如基于EEG信号的情感识别等任务至关重要



(a) 现有的基于SE的方法 (b) TS-DCGNN

图3 自表达矩阵学习模型的示意图

要. 为了进一步增强所提方法的理论可靠性与实验可复现性, 我们在此给出模型的收敛性分析与变分估计的稳定性验证. 首先, 从整体优化过程的收敛性出发, 可以得到以下结果:

$$\frac{1}{T} \sum_{i=1}^T \|\nabla \mathcal{L}(\theta_i)\|_2^2 \leq \frac{2(\mathcal{L}(\theta_1) - L_*)}{\eta T} + L\eta\sigma^2 \quad (23)$$

其中, \mathcal{L} 为联合训练目标, 假设其梯度 L -Lipschitz, σ^2 为小批量噪声方差, 且常数步长 $\eta < 1/L$. 该不等式表明在 Adam/SGD-类优化与早停下, 平均梯度范数平方以 $O(1/T) + O(\eta)$ 收敛, 取递减步长时可使右端趋零, 从而在期望意义上到达一阶驻点.

进一步地, 为了验证变分估计在训练中的稳定性, 我们采用指数滑动平均 (Exponential Moving Average, EMA) 修正 DV/MINE 互信息估计器:

$$\hat{I}_{\text{DV-EMA}}(Z; R) = \rho_{(z,r)} \left[T_\phi(z, r) \right] - \log \left(\alpha u_{t-1} + (1 - \alpha) \rho_{(z,r)} \left[e^{T_\psi(z,r)} \right] \right) \quad (24)$$

其中, $\alpha \in [0.9, 0.999]$ 用于平滑分母的高方差. 我们同时并行计算 NWJ 与 InfoNCE 下界, 并监控下界一致性差 $\Delta t = \max(\hat{I}_{\text{DV-EMA}}, \hat{I}_{\text{NWJ}}, \hat{I}_{\text{NCE}})$. 当滑窗方差与 Δt 同步下降且 $\Delta t \leq 0.2 \text{ nat}$ (在前 10% 迭代内达到), 且不同随机种子的主指标方差较低 ($\text{CV} \leq 1.5\%$), 即可判定估计稳定、结果可复现. 该验证流程 TS-DCGN 的三子空间解耦、GAT-GCN 双分支及信息瓶颈/MCR² 机制一致, 进一步提升了方法的技术可信度与可重复性.

4 实验

4.1 数据集描述

PAFEW^[30]: PAFEW 数据集通过 E4 腕带以 4 Hz 的采样率采集皮肤电活动 (ElectroDermal Activity, EDA) 信号, 广泛应用于情感识别任务. 由于不同参与者之间信号幅度存在显著差异, 本文对数据进行了 Min-Max 归一化处理, 并应用了 11 点中值滤波器进行平滑, 以消除噪声并提高数据质量. 尽管 DEAP 和 SEED 是常用的 EEG 数据集, 本研究引入 PAFEW 数据集来验证 TS-DCGN 模型的泛化能力. 作为情绪唤醒的生理指标, EDA 信号能为 EEG 数据提供互补信息, 尤其在情感识别中具有重要价值. 相比 EEG 数据, EDA 信号的维度较低, 且适合通过可穿戴设备进行实时采集, 极大地增强了情感计算的便捷性和灵活性. 该实验展示了 TS-DCGN 模型在 EEG 之外的情感计算任务中的应用潜力, 证明了其跨模态的适应性和在不同生理信号融合下的优越性能.

DEAP^[31]: DEAP 数据集是情感计算领域中的标准 EEG 数据集, 包含多通道 EEG 和生理信号. 本研究使用了预处理后的 EEG 数据, 并进行了标准化, 以减少情

感反应中的个体内外差异. 原始数据采样率为 512 Hz, 经过下采样后降至 128 Hz, 提高了计算效率. 数据被分割为 60 s 的实验试次和 3 s 的基线试次, 去除了基线信号, 确保保留与情感相关的 EEG 特征.

SEED^[32]: SEED 数据集由上海交通大学提供, 是广泛用于情感识别的公开 EEG 数据集. 该数据集包含 15 名参与者 (7 名男性和 8 名女性) 的 EEG 记录, 他们观看了旨在引发快乐、悲伤和中性情感的电影片段. EEG 信号通过 62 通道的 ESI NeuroScan 系统在 1000 Hz 采样率下记录. 实验包括 15 个电影片段 (每种情感类别 5 个), 每个片段约 4 min, 随机顺序呈现, 每个参与者完成三轮实验.

本文在 PAFEW、DEAP 和 SEED 三个公开情绪数据集上评估了情绪识别模型. 信号经过带通滤波、归一化、降采样和小波变换等处理, 并通过 TCN、注意力机制和 MLPs 进行神经表示编码. 特征投影到显性情绪、隐性情绪和共振子空间, 采用正交性和信息瓶颈约束. 双路径 GAT-GCN 模型用于建模情绪与认知的时空动态^[33], 通过情绪感知注意力和跨模态调制实现自适应融合. 使用 Adam 优化器训练并在 PyTorch 和 PyTorch Geometric 上实现, 基于 NVIDIA RTX 3090 GPU 和 64 GB RAM 进行运行.

4.2 与基线比较结果

实验结果如表 1 所示, 结果表明提出的 TS-DCGNN 模型在各种评估指标上的卓越表现, 在大多数情况下超越了所有基准模型. 具体而言, 在 PAFEW 数据集上, TS-DCGNN 的准确率为 87.94%, 比第二好的模型 KGAN-EEG 高出 1.60 个百分点. 在 DEAP 数据集中, 其准确率达到 94.32%, 超过 KGAN-EEG 方法 1.87 个百分点. 在 SEED 数据集中, TS-DCGNN 记录的准确率为 97.12%, 领先 KGAN-EEG 方法 1.63 个百分点. 这些结果证明, TS-DCGNN 在所有三个数据集上都表现出色, 展示了其在不同情绪识别任务中有效学习和泛化的能力. 尽管一些基准模型在单项指标上表现具有竞争力, 但 TS-DCGNN 始终交付最优的整体结果. 这突显了 TS-DCGNN 框架在准确性和 F1 得分方面的有效性, 使其成为情绪识别任务中的一个强大模型. 与其他最先进的模型相比, TS-DCGNN 表现出更高的准确率和更强的泛化能力, 突显了其集成方法的强大功能. 这些发现表明, TS-DCGNN 模型在情绪识别任务中相较于现有模型提供了显著的改进.

4.3 消融与分析

为了便于理解实验结果, 本文首先说明了三个常用指标的含义: 准确率 (Accuracy) 表示预测正确的样本数占总样本数的比例, 是衡量整体性能的直观指标; F1 分数 (F1-score) 是精确率与召回率的调和平均值, 用于

表1 不同基准模型与本文提出的TS-DCGNN的性能比较

单位:%

方法	PAFEW		DEAP		SEED		
	准确率	F1	准确率	F1	准确率	F1	
基于深度学习的方法	EEGNet ^[34]	48.93	46.14	52.69	50.34	54.54	51.41
	LSTM-EEG ^[35]	63.48 ↑	60.71 ↑	68.27 ↑	65.68 ↑	70.76 ↑	67.00 ↑
	EEG-Transformer ^[36]	64.95 ↑	61.96 ↑	68.90 ↑	66.57 ↑	71.90 ↑	68.26 ↑
	CNN-BiLSTM ^[37]	64.43 ↑	61.51 ↑	68.73 ↑	66.22 ↑	70.50 ↑	67.24 ↑
图神经网络方法	GCN-EEG ^[38]	67.45	64.79	73.99	70.34	75.60	71.68
	GAT-EEG ^[39]	68.76 ↑	66.42 ↑	74.33 ↑	71.94 ↑	76.63 ↑	73.76 ↑
	ST-GCN ^[40]	69.33 ↑	67.57 ↑	74.99 ↑	72.92 ↑	78.09 ↑	74.90 ↑
	Dual-GCN ^[41]	70.08 ↑	67.42 ↑	75.69 ↑	73.19 ↑	78.49 ↑	75.69 ↑
	SE-GNN ^[42]	70.65 ↑	68.13 ↑	76.39 ↑	74.01 ↑	79.07 ↑	76.61 ↑
知识增强的方法	KG-Transformer ^[29]	74.93	71.86	79.61	76.61	82.11	78.70
	SenticGCN ^[43]	75.71 ↑	72.41 ↑	81.11 ↑	78.59 ↑	84.11 ↑	80.88 ↑
	Hybrid-KGNN ^[44]	76.53 ↑	73.60 ↑	82.11 ↑	79.61 ↑	84.71 ↑	81.88 ↑
	KGAN-EEG ^[45]	<u>86.34 ↑</u>	<u>83.12 ↑</u>	<u>92.45 ↑</u>	<u>89.67 ↑</u>	<u>95.43 ↑</u>	<u>92.12 ↑</u>
本文提出的方法	TS-DCGNN	87.94 ↑	85.99 ↑	94.32 ↑	92.45 ↑	97.12 ↑	94.87 ↑

注:最佳结果用粗体显示,次优结果用下划线显示,向上箭头(↑)表示性能提升.

综合评估模型在查全率和查准率之间的平衡; κ 值(Kappa系数)衡量分类结果与随机猜测之间的一致性,能够修正因类别分布不均衡带来的偶然一致性, κ 值越高说明模型越可靠.

消融研究结果(见表2)突出了TS-DCGNN框架中关键组件对性能的影响.例如,去除显性子空间、隐性子空间或共振子空间都会导致性能明显下降,去除共振子空间将准确率从97.82%降低到95.42%.没有信息瓶颈(IB)约束时,模型准确率下降到93.17%,这突显了IB约束在调节信息流和提高泛化能力中的作用.移除MCR²损失函数会导致类间分离度下降,准确率从97.38%降至94.56%,证明了MCR²在增强表示边界中的有效性.

表2 TS-DCGNN的消融研究

单位:%

方法	Accuracy ↑	F1 ↑	κ ↑
去除信息瓶颈约束	93.17	93.64	0.832
去除MCR ² 损失	94.56	95.01	0.852
部分解耦	96.34	96.74	0.882
完整解耦	97.82	98.08	0.921
仅使用GAT	86.45	86.93	0.712
GCN-GAT融合	89.83	90.23	0.781
去除显性子空间	92.15	92.60	0.801
去除隐性子空间	93.76	94.15	0.821
去除共振子空间	95.42	95.77	0.854
去除时间建模	95.20	95.61	0.849
去除正交约束项	95.70	96.05	0.857
单头注意力代替多头	95.40	95.82	0.852
完整架构	97.38	97.73	0.913

4.4 可视化分析

图4展示了不同模型在DEAP数据集上学习到的情绪表示.五种情绪类别分别用金色、绿色、蓝色、橙红色和紫色表示,金色代表快乐、绿色代表平静、蓝色代表悲伤、橙红色代表愤怒、紫色代表中立或混合情绪.传统的基于CNN的模型(如EEGNet)未能有效区分情绪类别,导致类别高度纠缠.尽管其他模型如GCN+EEG、KGE+EEG、EEG-Transformer有所改进,但仍未能有效解耦情绪与认知的影响,情绪类别之间存在重叠.而TS-DCGNN通过三子空间解耦与图神经网络双分支结构,显示出最清晰且紧凑的情绪聚类,体现其卓越的情绪可分离性.

TS-DCGNN结合时频CWT分解与空间Laplacian滤波器提取鲁棒特征,并使用Gram-Schmidt投影、PReLU激活的MLP和正交性正则化,实现了显性、隐性与共振情绪特征的解耦.GAT-GCN双路径图增强模块自适应地捕捉情绪显著性和认知稳定性,跨模态调制门控平衡二者贡献,信息瓶颈模块确保辨别一致性并最小化认知干扰.最大编码率正则化优化类内紧凑性和类间可分离性,使得TS-DCGNN在EEG信号的情绪识别任务中具备强大的泛化能力,能够解码复杂的情绪状态.

4.5 跨被试实验

本文首先说明了四个常用评价指标:WA(加权准确率)反映整体性能但易受类别不平衡影响;UA(非加权准确率)公平地反映类别不平衡条件下的表现;F1分数衡量精确率与召回率的平衡; κ (Kappa系数)衡量模型与随机猜测之间的一致性.实验结果以Mean \pm Std

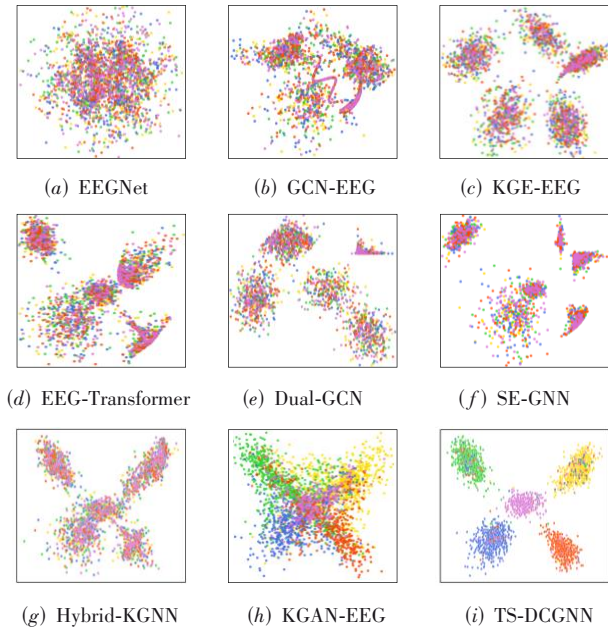


图4 模型准确率比较

报告,均值反映整体性能,标准差衡量结果稳定性.

为了验证模型的泛化能力,本文采用 Leave-One-Subject-Out (LOSO) 策略进行跨被试验证. 表 3 给出跨被试实验结果,TS-DCGNN 在所有指标上均优于基线方法. 在 10 名被试的平均性能上,TS-DCGNN 达到了 $WA = 84.1\%$ 、 $UA = 83.4\%$ 、 $F1 = 82.0\%$ 、 $\kappa = 0.79$, 相比最优基线方法 (SE-GNN) 的 $WA = 80.9\%$ 、 $UA = 80.2\%$ 、 $F1 = 78.9\%$ 、 $\kappa = 0.75$, 表现有显著提升,证明其在跨被试情绪识别中的稳定性与鲁棒性.

4.6 模型计算复杂度与训练效率比较

从表 4 可以看出,轻量化模型如 EEGNet 参数量最少、推理速度最快,但在准确率上存在明显不足;而复杂模型如 KGAN-EEG 虽具备较强的表现力,但其训练时间和推理开销显著增加. 相比之下,本文提出的 TS-DCGNN 在保持较优性能的同时,计算复杂度处于适中水平,收敛速度更快,仅需约 42 个 epoch 即可达到最优效果,总训练时间与中等规模模型接近,推理效率也能满足近实时应用需求. 这表明 TS-DCGNN 在“性能—效率”权衡上具有较强优势和实际应用潜力.

5 结论

本文提出了一种用于 EEG 情绪识别的三子空间解耦聚类图神经网络 (TS-DCGNN). TS-DCGNN 将 EEG 信号解耦为显性情绪子空间、隐性情绪子空间和显性-隐性共振子空间,以捕捉情绪体验、无意识的情绪处理及情绪与认知的耦合关系. 该方法创新性地分别建模显性和隐性情绪特征,并捕捉二者的交互与共振,提供比传统方法更丰富精确的情绪信息. 模型采用双分支图

表 3 不同模型在跨被试实验下的情绪识别性能对比

受试者	模型	WA/%	UA/%	F1/%	κ
S1	EEG-Transformer	78.5	77.9	76.8	0.72
	Dual-GCN	80.2	79.5	78.3	0.74
	SE-GNN	81.0	80.4	79.2	0.75
	TS-DCGNN	84.6	83.8	82.9	0.79
S2	EEG-Transformer	76.1	75.5	74.3	0.70
	Dual-GCN	78.9	78.0	76.9	0.72
	SE-GNN	79.3	78.5	77.2	0.73
	TS-DCGNN	82.5	81.6	80.4	0.77
S3	EEG-Transformer	80.0	79.4	78.2	0.74
	Dual-GCN	81.5	80.7	79.6	0.76
	SE-GNN	82.2	81.5	80.3	0.77
	TS-DCGNN	85.1	84.3	83.1	0.80
S4	EEG-Transformer	77.3	76.8	75.5	0.71
	Dual-GCN	79.4	78.7	77.3	0.73
	SE-GNN	80.5	79.9	78.6	0.74
	TS-DCGNN	83.7	82.9	81.5	0.78
S5	EEG-Transformer	79.2	78.6	77.4	0.73
	Dual-GCN	81.0	80.1	79.0	0.75
	SE-GNN	81.8	81.0	79.7	0.76
	TS-DCGNN	84.3	83.6	82.2	0.79
S6	EEG-Transformer	78.0	77.2	76.0	0.72
	Dual-GCN	79.9	79.1	77.8	0.73
	SE-GNN	80.7	80.0	78.5	0.74
	TS-DCGNN	83.5	82.8	81.2	0.78
S7	EEG-Transformer	77.8	77.1	76.0	0.71
	Dual-GCN	79.6	78.9	77.5	0.73
	SE-GNN	80.3	79.7	78.2	0.74
	TS-DCGNN	83.9	83.2	81.8	0.78
S8	EEG-Transformer	79.1	78.4	77.2	0.73
	Dual-GCN	80.8	80.0	78.8	0.74
	SE-GNN	81.5	80.8	79.5	0.75
	TS-DCGNN	84.7	84.0	82.6	0.79
S9	EEG-Transformer	78.4	77.7	76.5	0.72
	Dual-GCN	80.1	79.4	78.1	0.74
	SE-GNN	80.9	80.2	78.9	0.75
	TS-DCGNN	84.1	83.4	82.0	0.79
S10	EEG-Transformer	77.0	76.4	75.2	0.71
	Dual-GCN	79.2	78.5	77.1	0.73
	SE-GNN	80.1	79.5	78.0	0.74
	TS-DCGNN	83.2	82.5	81.0	0.78
Mean \pm Std	EEG-Transformer	78.4	77.7	76.5	0.72
	Dual-GCN	80.1	79.4	78.2	0.74
	SE-GNN	80.9	80.2	78.9	0.75
	TS-DCGNN	84.1	83.4	82.0	0.79

表 4 模型计算复杂度与训练效率比较

模型	参数量/M	单 epoch 训练时间/s	收敛 epoch 数	总训练时间/h	推理速度/ms
EEGNet	0.6	18.4	65	0.33	1.05
CNN-BiLSTM	3.9	42.7	55	0.65	2.12
EEG-Transformer	5.2	48.7	52	0.70	2.31
Dual-GCN	6.8	56.4	47	0.74	2.54
SE-GNN	7.5	61.2	45	0.76	2.63
KGAN-EEG	12.3	82.5	50	1.14	3.42
TS-DCGNN	9.1	67.3	42	0.79	2.88

注:最佳结果用粗体显示。

传播架构,利用图注意力网络(GAT)和图卷积网络(GCN)并行工作,增强跨脑区信息整合能力,提升情绪模式处理的鲁棒性。

实验结果表明,TS-DCGNN在准确率和可解释性方面达到最新水平,并在多个指标上超越了EEG-Transformer、ST-GCN、SenticGCN等方法,展示了其在EEG情绪识别中的应用潜力。尤其在跨脑区信息整合和多特征协同表示方面具有独特优势。然而,模型的跨受试者泛化能力仍需改进,且复杂架构可能影响透明性和可解释性。未来研究可通过增强跨受试者鲁棒性、扩展数据集多样性和引入统一评估协议,进一步提升TS-DCGNN的性能、可解释性和实际应用价值。

参考文献

- [1] HAEYEN S. A theoretical exploration of polyvagal theory in creative arts and psychomotor therapies for emotion regulation in stress and trauma[J]. *Frontiers in Psychology*, 2024, 15: 1382007.
- [2] AHAD A, JIANGBINA Z, TAHIR M, et al. 6G and intelligent healthcare: Taxonomy, technologies, open issues and future research directions[J]. *Internet of Things*, 2024, 25: 101068.
- [3] POURMIRZAEI M, ALI MONTAZER GA, MOUSAVI E. ATTENDEE: An affective tutoring system based on facial emotion recognition and head pose estimation to personalize e-learning environment[J]. *Journal of Computers in Education*, 2025, 12(1): 65-92.
- [4] MORIUCHI E, MURDY S. The role of robots in the service industry: Factors affecting human-robot interactions[J]. *International Journal of Hospitality Management*, 2024, 118: 103682.
- [5] AHUJA C, SETHIA D. TRANSIT-EEG: A framework for cross-subject classification with subject specific adaptation[J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2025, 17(4): 923-937.
- [6] ZHANG D Z, CHEN F L, CHANG J L, et al. Structure

aware multi-graph network for multi-modal emotion recognition in conversations[J]. *IEEE Transactions on Multimedia*, 2024, 26: 3987-3997.

- [7] ZHAO Y C, WANG G Y, SUN M X, et al. Methods for removing artifacts from EEG signals: A review[C]//2024 IEEE 24th International Conference on Software Quality, Reliability, and Security Companion. Piscataway: IEEE, 2024: 752-758.
- [8] JONKMAN A H, WARNAAR R S P, BACCINELLI W, et al. Analysis and applications of respiratory surface EMG: Report of a round table meeting[J]. *Critical Care*, 2024, 28(1): 2.
- [9] FAN X Y. Artifact removal from sleep-disordered EEG by wavelet enhanced independent component analysis[EB/OL]. (2024-11) [2025-06-24]. <https://ualberta.scholaris.ca/server/api/core/bitstreams/8b0c4513-694e-4950-b200-7e5c69c0a6f8/content>.
- [10] ZHANG G H, CARRASCO C D, WINSLER K, et al. Assessing the effectiveness of spatial PCA on SVM-based decoding of EEG data[J]. *NeuroImage*, 2024, 293: 120625.
- [11] WISNIEWSKI M G, JOYNER C N, ZAKRZEWSKI A C, et al. Finding tau rhythms in EEG: An independent component analysis approach[J]. *Human Brain Mapping*, 2024, 45(2): e26572.
- [12] LI Y R, LIU Y J, AI Y Q, et al. Explore the novel relationship of time-frequency domains in multivariate signals: A dynamic system perspective[J]. *IEEE Transactions on Bio-Medical Engineering*, 2025, 72(6): 1872-1885.
- [13] LALAWAT R S, BAJAJ V. An automatic framework for detecting autism spectrum disorder from EEG signals using TFD[J]. *IEEE Sensors Journal*, 2024, 24(7): 10632-10639.
- [14] GOMEZ-GIL F J, MARTÍNEZ-MARTÍNEZ V, RUIZ-GONZALEZ R, et al. Vibration-based monitoring of agro-

- industrial machinery using a k-Nearest Neighbors (kNN) classifier with a Harmony Search (HS) frequency selector algorithm[J]. *Computers and Electronics in Agriculture*, 2024, 217: 108556.
- [15] MAULANA B A, FAHMI M J, IMRAN A M, et al. Analisis sentimen terhadap aplikasi pluang menggunakan algoritma naive Bayes Dan support vector machine (SVM): Sentiment analysis of pluang applications with naive Bayes and support vector machine (SVM) algorithm[J]. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 2024, 4(2): 375-384.
- [16] QI Y Q, JIA W C, FENG L L, et al. Piezoelectric touch sensing and random-forest-based technique for emotion recognition[J]. *IEEE Transactions on Computational Social Systems*, 2024, 11(5): 6296-6307.
- [17] BHAGAT D, VAKIL A, GUPTA R K, et al. Facial emotion recognition (FER) using convolutional neural network (CNN)[J]. *Procedia Computer Science*, 2024, 235: 2079-2089.
- [18] MANALU H V, RIFAI A P. Detection of human emotions through facial expressions using hybrid convolutional neural network-recurrent neural network algorithm[J]. *Intelligent Systems with Applications*, 2024, 21: 200339.
- [19] 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.
- [20] LI C B, TANG T, PAN Y, et al. An efficient graph learning system for emotion recognition inspired by the cognitive prior graph of EEG brain network[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2025, 36(4): 7130-7144.
- [21] KUANG W R, WANG Z, WEI Z W, et al. When transformer meets large graphs: An expressive and efficient two-view architecture[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(10): 5440-5452.
- [22] GAO Y Y, XUE Y F, GAO J. Emotion recognition from multichannel EEG signals based on low-rank subspace self-representation features[J]. *Biomedical Signal Processing and Control*, 2025, 99: 106877.
- [23] Saravia E. ML Visuals[EB/OL]. [2025-06-24]. <https://github.com/dair-ai/ml-visuals>.
- [24] MARSICANO G, BERTINI C, RONCONI L. Decoding cognition in neurodevelopmental, psychiatric and neurological conditions with multivariate pattern analysis of EEG data[J]. *Neuroscience & Biobehavioral Reviews*, 2024, 164: 105795.
- [25] CHENG P Y, HAO W T, DAI S Y, J, et al. CLUB: A contrastive log-ratio upper bound of mutual information[C]// *Proceedings of the 37th International Conference on Machine Learning*. Cambridge: PMLR, 2020: 1779-1788.
- [26] BELGHAZI M I, BARATIN A, RAJESHWAR S, et al. Mutual information neural estimation[C]// *Proceedings of the 35th International Conference on Machine Learning*. Cambridge: PMLR, 2018: 531-540.
- [27] FEDERICI M, DUTTA A, FORRÉ P, et al. Learning robust representations via multi-view information bottleneck[EB/OL]. (2020-02-18)[2025-06-24]. <https://arXiv.org/abs/2002.07017>.
- [28] SHAPIRO A. Monte Carlo sampling methods[M]// *Stochastic Programming*. Amsterdam: Elsevier, 2003: 353-425.
- [29] FU Y H, OKADA S, WANG L B, et al. Context- and knowledge-aware graph convolutional network for multimodal emotion recognition[J]. *IEEE MultiMedia*, 2022, 29(3): 91-100.
- [30] LIU Y, GEDEON T, CALDWELL S, et al. Emotion recognition through observer's physiological signals[EB/OL]. (2020-02-19)[2025-06-24]. <https://arXiv.org/abs/2002.08034>.
- [31] KOELSTRA S, MUHL C, SOLEYMANI M, et al. DEAP: A database for emotion Analysis; Using physiological signals[J]. *IEEE Transactions on Affective Computing*, 2012, 3(1): 18-31.
- [32] 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.
- [33] 梁秀霞, 夏曼曼, 何月阳, 等. 基于时空多头图注意力网络的交通流预测[J]. *电子学报*, 2024, 52(2): 500-509.
- LIANG X X, XIA M M, HE Y Y, et al. Traffic flow prediction based on spatio-temporal multi-head graph attention network[J]. *Acta Electronica Sinica*, 2024, 52(2): 500-509. (in Chinese)
- [34] 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.
- [35] HASIB M M, NAYAK T, HUANG Y F. A hierarchical LSTM model with attention for modeling EEG non-stationarity for human decision prediction[C]// *2018 IEEE EMBS International Conference on Biomedical & Health Informatics*. Piscataway: IEEE, 2018: 104-107.
- [36] SONG Y H, JIA X Y, YANG L, et al. Transformer-based

- spatial-temporal feature learning for EEG decoding[EB/OL]. (2021-06-11)[2025-06-24]. <https://arXiv.org/abs/2106.11170>.
- [37] ZENG Y Y, ZHANG R R, YANG L, et al. Cross-domain text sentiment classification method based on the CNN-BiLSTM-TE model[J]. Journal of Information Processing Systems, 2021, 17 (4): 818-833.
- [38] 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.
- [39] LI X, LI J, ZHANG Y Z, et al. Emotion recognition from multi-channel EEG data through a dual-pipeline graph attention network[C]//2021 IEEE International Conference on Bioinformatics and Biomedicine. Piscataway: IEEE, 2021: 3642-3647.
- [40] PIKOULIS I, FILNTISIS P P, MARAGOS P. Leveraging semantic scene characteristics and multi-stream convolutional architectures in a contextual approach for video-based visual emotion recognition in the wild[C]//2021 16th IEEE International Conference on Automatic Face and Gesture Recognition. Piscataway: IEEE, 2021: 1-8.
- [41] LI R F, CHEN H, FENG F X, et al. DualGCN: Exploring syntactic and semantic information for aspect-based sentiment analysis[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(6): 7642-7656.
- [42] ZHU T, LI L D, YANG J F, et al. Multimodal emotion classification with multi-level semantic reasoning network[J]. IEEE Transactions on Multimedia, 2023, 25: 6868-6880.
- [43] LI G Q, CHEN N, JIN J. Semi-supervised EEG emotion recognition model based on enhanced graph fusion and GCN[J]. Journal of Neural Engineering, 2022, 19(2): 026039.
- [44] CHENG C, YU Z K, ZHANG Y, et al. Hybrid network using dynamic graph convolution and temporal self-attention for EEG-based emotion recognition[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(12): 18565-18575.
- [45] FU R R, CAI M P, WANG S W, et al. Exploring non-Euclidean relationships in EEG emotion recognition: A dynamic graph attention network[J]. Biomedical Signal Processing and Control, 2024, 94: 106276.

作者简介




黄 辰 男,1983年生,福建龙岩人.湖北大学计算机学院教授.主要研究方向为人工智能、脑机接口.
E-mail: huang@hubu.edu.cn



杨 超 男,1982年生,湖北武汉人.湖北大学计算机学院教授.主要研究方向为智能计算、信息安全等.
E-mail: stevenyc@hubu.edu.cn



马浩博 男,2000年生,河北秦皇岛人.湖北大学计算机学院硕士研究生.主要研究方向为人工智能、脑科学、情感分析.
E-mail: 202321116012629@stu.hubu.edu.cn



宋建华 女,1973年生,湖北襄阳人.湖北大学网络空间安全学院教授.主要研究方向为网络与信息安全.
E-mail: sjhhubu@126.com



张 龔 男,1974年生,湖北宜昌人.湖北大学计算机学院教授.主要研究方向为信息安全、大数据分析.中国电子学会会员编号: E190197582M.
E-mail: zhangyan@hubu.edu.cn