

基于脑电网络图特征的情绪识别研究

李存波¹, 杨 蕾¹, 陈昭瑾¹, 汪义锋¹, 李沛洋², 李发礼¹, 尧德中¹, 徐 鹏¹

(1. 电子科技大学生命科学与技术学院神经信息教育部重点实验室, 成都 611731; 2. 重庆邮电大学生物信息学院, 重庆 400065)

摘 要: 针对情绪脑电信号提出一种网络图特征学习与情绪识别算法。首先, 利用情绪脑电数据构建对应的情绪脑电网络; 其次, 在由情绪脑电网络尺度定义的高维空间构建脑电网络样本间的局部邻接关系图以挖掘样本集的分布特性, 进而得到样本集的图拉普拉斯矩阵; 在此基础上, 进一步利用谱图理论对情绪脑电网络的最优低维空间映射进行求解, 在保留原始样本局部邻接关系的前提下实现对情绪脑电网络的降维与重新表达, 并将每个情绪脑电网络样本表示成 1 组脑电网络特征集; 最后利用提取到的情绪脑电网络特征集, 结合支持向量机分类学习算法, 针对情绪识别任务进行识别模型的训练和学习, 实现对情绪状态的准确解码与识别。在国际公开情绪脑电数据集的实验结果表明: 相较于传统情绪识别算法, 本文所提方法能有效提升情绪识别准确率, 在基于公开数据集的多类情绪识别任务中分别达到 91.85% (SEED 数据集, 3 类)、79.36% (MAHNOB-HCI 数据集, 3 类) 和 79% (DEAP 数据集, 4 类) 的稳健识别效果。

关键词: 情绪识别; 脑电图; 脑电网络; 特征提取; 图学习

中图分类号: TP181 **文献标志码:** A

Emotion Recognition Based on Graph Features Extracted from EEG Networks

LI Cunbo¹, YANG Lei¹, CHEN Zhaojin¹, WANG Yifeng¹, LI Peiyang², LI Falil¹,
YAO Dezhong¹, XU Peng¹

(1. MOE Key Lab for Neuroinformation, School of Life Science and Technology, University of Electronic Science and Technology of China, Chengdu 611731, China; 2. School of Bioinformatics, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: To accurately evaluate individual emotional states, we propose a graph feature learning and recognition algorithm for electroencephalogram (EEG)-based emotion recognition. In the proposed algorithm, the original EEG data are first used to construct the corresponding EEG network. And then, the local adjacency graph between different emotional EEG network samples is constructed in the high-dimensional EEG brain network space, which aims to capture the distribution of the emotional EEG brain networks, and the graph Laplacian matrix can be estimated with the adjacency graph. Thirdly, the optimal low-dimensional graph embeddings of emotional EEG brain networks are obtained by the spectral graph theory, and the emotional EEG brain network samples can be represented in the low-dimensional space, in which the initial emotional EEG brain networks can be represented with a set of network features.

基金项目: 国家自然科学基金(U19A2082, 61961160705, 61901077); 国家重点研发计划(2017YFB1002501)。

收稿日期: 2022-05-05; **修订日期:** 2022-10-13

Finally, based on the extracted emotional EEG brain network features, the optimal support vector machine classifier is trained and utilized in the emotion recognition. The verification experiment is carried out on the international public emotional EEG datasets, and experimental results show that compared with traditional emotion recognition algorithms, the proposed method can effectively improve the accuracy of emotion recognition, and achieve a robust recognition effect of 91.85% (SEED dataset, 3-class), 79.36% (MAHNOB-HCI dataset, 3-class) and 79% (DEAP dataset, 4-class) on three public datasets, respectively.

Key words: emotion recognition; electroencephalogram(EEG); EEG brain network; feature extraction; graph learning

引言

大脑对情绪的加工是一个复杂的动态过程,情绪改变着人类个体的生产生活,如决策行为、人际交往等^[1-2]。情绪加工障碍会引发系列生理及心理疾病,如睡眠障碍、抑郁症和精神分裂症等^[3]。近年来,随着认知神经学科快速发展,基于个体生理监测技术的情感计算已作为一种新兴研究方向而被广泛关注^[4-5]。情感计算领域的快速发展对于临床探究精神类疾病的发病机制,制定合理有效的诊疗方案等都具有重要意义^[3];此外,情感计算技术的不断突破也为新型脑-机接口技术,如情感脑-机接口、智能人机交互等的设计与实现提供了新的可能^[6-7]。情绪识别作为情感计算领域中至关重要的研究方向,旨在实现对个体情绪状态的自动识别与解码,为情感脑-机接口与智能人机交互提供支撑,使计算机具有感知个体情感及加工生成类人情感的能力,从而实现更为智能化、人性化的情感交互,提升人机交互体验^[8-10]。脑电图(Electroencephalogram, EEG)凭借其独特的便携、无创、低成本和高时间分辨率等优势,被作为一种重要的大脑认知加工过程监测手段,广泛应用于情绪、决策等认知任务的研究中^[11]。为推动情感计算领域的发展,国内外相关研究者提供了相应的情绪脑电公开数据库。为实现个体情绪加工过程生理信号的有效监测,上海交通大学吕宝粮教授团队以情绪片段为素材设计情绪诱发实验范式,并将对应的数据形成上海交通大学情绪脑电数据库(SEED)进行公开,为情绪识别领域的研究提供了可靠数据保障^[12]。此外,还有帝国理工学院的MAHNOB-HCI数据库^[13]、玛丽女王学院的DEAP数据库^[14]等。基于情绪脑电数据,研究者们提出了不同的情绪识别算法以及基于情绪的神经反馈尝试,推动着情感计算领域的快速发展^[15]。如Li等^[16]将强化学习理论用于情绪识别任务中,并提出一种神经结构搜索框架,通过实验验证了所提框架的优越性;Huang等^[17]利用情绪脑电设计实现了一套基于情绪调节的神经反馈训练系统,实验结果表明:通过该系统的神经反馈训练,受试者的情绪调节能力得到了提升。

相关研究表明,大脑对情绪的加工与处理是一个涉及多个脑区的动态交互过程,在此过程中,脑区间的信息协同和交互模式与个体的情绪状态息息相关^[18-19]。因此,如何利用大脑情绪认知加工过程中的脑电信号,实现对情绪加工过程中脑区间的动态交互模式进行客观评估与精确刻画,对情绪识别研究具有重要意义^[20]。脑电网络分析方法作为一种有效的认知神经科学研究手段,旨在通过探究脑电时序信号间的相关关系,实现对脑区间功能连接的客观评估^[21]。针对情绪加工过程中的脑电数据,研究者们尝试利用脑电网络分析方法探究不同情绪状态下脑电网络间的差异模式,以进一步提升情绪识别准确率。文献[22]利用相位锁时方法分别构建正性和负性情绪的脑功能连接网络,探究不同刺激类型下的脑功能连接模式差异;Li等^[23]将情绪脑电的局部激活特征与脑电网络全局性的统计属性特征进行融合,对比实验结果表明:与单模态脑电特征相比,融合特征能取得最高的情绪识别准确率;究其原因,脑电网络特征能很好地弥补局部激活特征的不足,通过融合策略可获得不同情绪状态下的最优局部与

全局融合特征集,进而实现情绪识别性能的提升。

从本质上说,脑电网络作为广义图的一种,脑电采集电极可作为图的顶点,脑电网络的功能连接视作图的边^[24]。基于图论理论,脑电网络的统计属性被广泛应用于脑网络的特征提取任务中,目前常用的脑电网络属性特征包括特征路径长度、聚类系数、局部效率和全局效率等^[25],脑电网络属性特征能够在顶点和功能边的水平上反映单个脑电网络样本的统计属性^[23]。然而,由于情绪认知过程的动态复杂性,个体相同的情绪状态也会因时间、场景等因素的不同而呈现出一定的波动性。因此,减小情绪状态波动造成的影响对于进一步提升情绪识别的精度非常有效。在计算机视觉领域,文献^[26]提出了拉普拉斯特征映射(Laplacian eigenmaps, LE)的方法用于图像数据的低维嵌入和聚类;在此基础上,又进一步提出了局部保持投影(Locality preserving projections, LPP)算法^[27],并用于实现图像数据的降维和人脸识别^[28]。事实上,能否通过评估情绪脑电网络样本间的相似度构建样本邻接图,并在保持样本间邻接关系的前提下寻找情绪脑电网络样本数据在低维空间的重新表达、实现对情绪脑电网络的特征提取,这对于提升情绪识别的精度非常有意义。基于上述分析,本文利用图嵌入方法对情绪脑电网络数据进行图特征的提取,实现高维脑电网络数据在低维空间的重新表达,并利用支持向量机(Support vector machine, SVM)有效实现对情绪脑电数据的识别和分类。

1 脑电网络图特征提取与情绪识别

本文提出的情绪脑电网络图特征提取与情绪识别方法主要涵盖以下4个部分:(1)利用情绪脑电数据构建对应的情绪脑电网络;(2)针对情绪脑电网络样本,在脑电网络定义的高维空间下构建样本间的邻接图,并得到对应的图拉普拉斯矩阵;(3)利用图谱理论寻找情绪脑电网络样本在低维空间的最优表示,实现对情绪脑电网络数据的低维嵌入和图特征提取;(4)利用SVM分类器实现对情绪状态的识别和预测。具体的实现流程如图1所示。

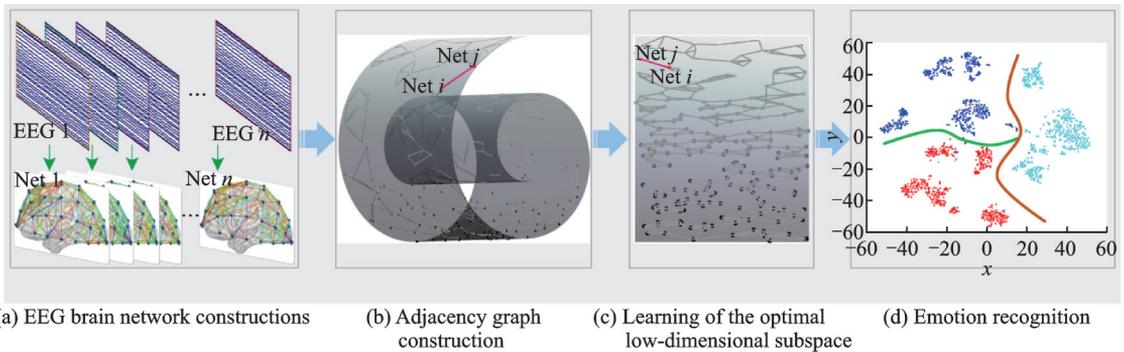


图1 情绪脑电网络图特征提取与情绪识别示意图

Fig.1 Diagram of emotional EEG network feature extraction and emotion recognition

1.1 脑电网络构建

研究表明:基于相位信息的同步测量方法更能反映脑区之间对信息协同处理的非线性同步模式^[22]。本文采用相位同步(Phase-locking value, PLV)评估不同脑区之间的功能网络连接。具体来说,对于给定的单通道脑电序列信号 $X(t)$,通过希尔伯特变换可以得到其对应的解析信号 $H(t)$,形式为

$$H(t) = X(t) + iX_h(t) = A(t)e^{-i\varphi(t)} \tag{1}$$

式中: $X_h(t)$ 为脑电序列 $X(t)$ 的希尔伯特变换^[29],定义为 $X_h(t) = \frac{1}{\pi} \text{PV} \int_{-\infty}^{\infty} \frac{X(\tau)}{t - \tau} d\tau$,PV表示柯西主值;

$A(t)$ 和 $\varphi(t)$ 分别表示给定脑电序列 $X(t)$ 的瞬时振幅和瞬时相位。通过解析信号,脑电时序信号 $X(t)$ 的瞬时相位信息可以表示为

$$\varphi(t) = \arg [X(t)] = \arctan \frac{X_h(t)}{X(t)} \quad (2)$$

对于多通道脑电信号,通过式(2)可以得到任意通道时序脑电信号的瞬时相位,通过评估不同通道脑电信号间瞬时相位的同步性,可以实现对不同脑区功能连接的评估。给定两个脑电时间序列 $X_i(t)$ 和 $X_j(t)$,对应脑电网络功能连接边的表达为

$$\text{Net}_{ij} = \left| \frac{1}{T} \sum_1^T e^{i\Delta\varphi(t)} \right|, \quad \Delta\varphi(t) = \varphi_{X_i}(t) - \varphi_{X_j}(t) \quad (3)$$

通过式(3),对于给定的一个多通道情绪脑电网络样本数据,可以得到对应的情绪脑电网络。

1.2 脑电网络图特征学习与情绪识别

针对脑电网络数据,最常用的特征提取策略是:利用图论理论对单个脑电网络样本中各个节点的统计特性进行分析,通过对各个节点间局部连接属性的统计,提取出对应的脑电网络属性特征。不同于已有的网络属性特征提取策略,本文利用情绪脑电网络图特征学习策略(Graph learning, GL)实现对脑电网络特征的有效提取。本文所提情绪识别策略的具体实现流程如图1所示,算法的实现主要包括情绪脑电网络构建、样本局部邻接图估计、最优低维映射空间求解和情绪解码与识别4个部分。针对由脑电信号构建得到的情绪脑电网络,根据图1所示算法流程可实现情绪脑电网络的有效降维和特征提取,进而得到更为稳健的情绪状态解码与识别效果。具体来说,本文将情绪脑电网络样本视为定义在高维脑电网络空间下的离散点,通过构建高维空间下样本间的局部邻接图得到样本点在原始高维空间下的分布形式;利用图学习策略,在保留样本间局部邻接拓扑关系的前提下,求解出最优映射空间、寻找原始高维样本在最优低维图嵌入子空间中的重新表达形式,完成对高维情绪脑电网络的有效降维和特征提取,实现对情绪脑电网络的本征表达。

对于给定的高维情绪脑电网络样本集 $\mathbf{I} = \{\text{Net}_1, \text{Net}_2, \text{Net}_3, \dots, \text{Net}_n\}$,如何利用图学习策略寻找情绪脑电网络的最优映射 \mathbf{w} 、实现对脑电网络的有效降维与特征提取对情绪识别性能的提升至关重要。利用该最优映射 \mathbf{w} ,每一个情绪脑电网络样本可被重新表示成一组脑电网络特征,完成情绪脑电网络样本在最优低维空间下的重新表达。对任意情绪脑电网络样本 Net_i ,其低维表达形式可表示为 $y_i = \mathbf{w}^T \text{Net}_i$ 。直观地说,情绪脑电网络样本集在低维空间中的重表达形式应当保留原始高维脑电网络空间的分布形式,即保留原始高维空间下的局部样本邻接拓扑图信息。本文为有效保留原始样本空间下的局部邻接拓扑结构、求解出最优的低维映射空间,将待求解的最优低维嵌入空间 \mathbf{W} 定义为

$$\arg \min_{\mathbf{w}} \sum_{ij} (y_i - y_j)^2 G_{ij} \quad (4)$$

式中 G 为高维向量空间下样本间的局部邻接图。本文利用样本间的欧氏距离并结合热核函数构建样本邻接图^[27],情绪脑电网络样本间的局部邻接距离定义为

$$G_{ij} = e^{-\frac{\|\text{Net}_i - \text{Net}_j\|^2}{t}} \quad (5)$$

在原始高维脑电网络空间下,通过式(5)能有效捕获原始情绪脑电网络样本之间的局部邻接拓扑信息,并将其作为一种图约束信息有效保留原始高维脑电网络样本的分布形式。此外,为有效抑制因噪声及脑电采集环境对脑电网络样本的影响,本文采用K-近邻算法(K-nearest neighbor, KNN)策略对构建得到的邻接图进行稀疏化处理,以保留样本间的局部邻接关系的同时消除离群样本值的影响。进一步地,针

对目标函数式(4),利用谱图理论可将目标函数转化为

$$\arg \min_w J(\boldsymbol{w}) = \frac{\boldsymbol{w}^T \boldsymbol{\Gamma} \boldsymbol{L} \boldsymbol{\Gamma}^T \boldsymbol{w}}{\boldsymbol{w}^T \boldsymbol{\Gamma} \boldsymbol{D} \boldsymbol{\Gamma}^T \boldsymbol{w}} = \frac{\boldsymbol{w}^T \boldsymbol{\Gamma} (\boldsymbol{D} - \boldsymbol{G}) \boldsymbol{\Gamma}^T \boldsymbol{w}}{\boldsymbol{w}^T \boldsymbol{\Gamma} \boldsymbol{D} \boldsymbol{\Gamma}^T \boldsymbol{w}} \quad (6)$$

式中 \boldsymbol{D} 为邻接图的度矩阵, $D_{ii} = \sum_j G_{ji}$; \boldsymbol{L} 为样本局部邻接图的拉普拉斯矩阵。由于 $\boldsymbol{w}^T \boldsymbol{\Gamma} \boldsymbol{D} \boldsymbol{\Gamma}^T \boldsymbol{w}$ 的缩放对于最优求解不产生影响,限定 $\boldsymbol{w}^T \boldsymbol{\Gamma} \boldsymbol{D} \boldsymbol{\Gamma}^T \boldsymbol{w} = 1$ 。式(6)最优映射空间的求解可转化为广义特征值的求解问题,形式如下

$$\boldsymbol{\Gamma} \boldsymbol{L} \boldsymbol{\Gamma}^T \boldsymbol{w} = \lambda \boldsymbol{\Gamma} \boldsymbol{D} \boldsymbol{\Gamma}^T \boldsymbol{w} \quad (7)$$

通过式(7)可以得到目标的最优低维映射空间向量集,实现原始高维情绪脑电网络的低维嵌入表达。从本质上来说,本文所提情绪识别策略主要完成对情绪脑网络的有效降维和特征提取,通过式(4~7),原始高维情绪脑网络空间下的样本点可实现在低维图嵌入空间的最优重表达,有效实现情绪脑网络的特征提取,为情绪识别性能的提升提供保障。针对提取到的情绪脑电网络图特征,本文利用SVM构建情绪识别系统,以实现情绪脑电数据的准确识别。

2 情绪识别验证实验

本文采用3个公开的国际情绪脑电数据库对所提的情绪识别策略进行验证试验,包括SEED数据集,MAHNOB-HCI数据集和DEAP数据集。在情绪诱发实验方面,3个数据库均采用带有情绪标签的视频片段作为诱发素材,以诱发出被试的目标情绪状态。在情绪脑电数据的采集过程中,被试者被要求坐在一个相对安静的环境下观看情绪刺激素材,在此过程中,相应情绪状态的监测数据被记录下来作为被试当前情绪状态的电生理刻画。此外,为了验证所提策略的稳健性,目前常用的脑电特征提取策略(如脑电能量特征、脑电网络的属性特征等)被用作对比基线,对比实验在相同的实验设置下开展,以验证本文所提情绪脑电网络图特征提取策略的有效性。

2.1 实验数据

SEED数据集^[12]是由上海交通大学吕宝粮教授团队针对情绪识别研究提供的国际公开情绪脑电数据库(<https://bcmi.sjtu.edu.cn/~seed/seed.html>)。该数据集将带有正性、中性和负性情绪标签的15个视频片段作为素材,共招募15名被试者(7名男性,8名女性,年龄分布23.27岁±2.37岁),针对每名被试者开展3次情绪脑电数据的采集试验,共计45个实验数据。脑电数据由ESI NeuroScan系统采集,采集电极按照国际10-20标准分布,共计62导,原始脑电数据的采样频率为1 000 Hz。预处理后的脑电数据被降采样至200 Hz,并进行了0~75 Hz的带通滤波处理。

MAHNOB-HCI数据集^[13]是由帝国理工学院提供的情绪状态生理监测数据集(<https://mahnob-db.eu/hci-tagging/>),该数据集公开27名被试者(11名男性,16名女性,年龄分布26.06岁±4.39岁)的有效实验数据,实验采用20个视频片段作为素材诱发被试情绪,并用9个关键词对每个视频片段进行标注(包括中性,焦虑,开心,悲伤,快乐,厌恶,愤怒,惊讶和恐惧)。实验过程中,被试者的生理数据如脑电、心电、声音、记录视频、呼吸频率以及皮肤温度等被记录下来,脑电数据采用32导脑电记录仪进行记录,电极位置按照国际10-20标准放置,采样频率为256 Hz。

DEAP数据库^[14]是由玛丽女王学院提供的情绪相关脑电数据库(<http://www.eecs.qmul.ac.uk/mmv/datasets/deap/>),数据集以40个1 min的情绪视频片段作为情绪刺激诱发素材,实验过程中被试需要对每个视频片段进行唤醒度、效价、喜好程度、熟悉程度等指标进行打分,并以此确定被试者的情绪状态。该数据集共招募32(16名男性,16名女性,年龄19~37岁)名被试者开展情绪生理数据的采集实验,实验过程中受试者的脑电、眼电、肌电、呼吸以及温度等生理数据被监测记录,其中脑电数据为32

导,采集电极按照国际10-20标准放置,采样频率为512 HZ。

2.2 对比实验设置

在对比实验中,本文将所提方法与目前常用的脑电信号特征提取方法进行了对比验证,包括脑电能量特征,如:功率谱密度(Power spectrum density, PSD)^[23]、微分熵(Differential entropy, DE)^[30];脑电网络属性特征^[25],如:聚类系数(Clustering coefficient, CC)、最短路径长度(Shortest path length, SP)、局部效率(Local efficiency, LE)和全局效率(Global efficiency, GE)。

由于数据集刺激材料时间长度的不同,本文根据相关研究将每个视频片段对应的整段脑电信号分为若干个样本,每个脑电样本的时长为2 s^[31-32]。此外,固定频段的脑电信号被带通滤波器取出,包括Theta(4~7 Hz), Alpha(8~13 Hz), Beta(14~30 Hz)和Gamma(>30 Hz)。针对各个频段,分别提取对应的能量特征、网络属性特征,以及本文所提出的脑电网络低维图嵌入特征。基于提取得到的特征集,针对单被试情绪状态识别任务开展对比实验,具体来说,针对单个受试数据采用5倍交叉验证策略划分训练集和测试集,并利用训练集进行网格参数寻优以训练出最优的SVM分类器^[33],之后对测试集中每个样本进行情绪状态的预测和识别,最后根据预测结果和真实结果的一致性比率得出对应的识别准确率。

在对比试验中,由于数据集之间实验范式存在一定的差异,对3个数据集采用不同的标注策略。针对SEED数据集,采用数据原始标注策略,将数据标注为3类(正性,负性和中性);在MAHNOB-HCI数据集的标注中,根据刺激材料的关键词,将数据标注分为3类(正性,负性和中性),对应的标签定义如表1所示;在DEAP数据集的标注中,由于该数据集采用打分的方式对每一个刺激素材进行评估,因此采用由唤醒度-效价二维模型来定义标签,实现对数据的标注,根据评分区间,分别在唤醒度和效价维度上定义高(5~9)/低(1~5)唤醒度和高(5~9)/低(1~5)效价,最终将数据标注为4类,即高唤醒度-高效价(HAHV)、高唤醒度-低效价(HALV)、低唤醒度-高效价(LAHV)和低唤醒度-低效价(LALV)。利用上述标注策略,在3个公开数据集上开展了对应的三分类(SEED, MAHNOB-HCI)和四分类(DEAP)情绪分类实验任务。

表1 MAHNOB-HCI数据集数据标注信息
Table 1 Labeling strategy for MAHNOB-HCI dataset

标签	关键词
正性	joy, amusement
中性	surprise, neutral
负性	fear, anger, disgust, sadness, anxiety

3 实验结果与分析

基于上述数据集和实验设置,本文对不同方法在不同频段的情绪识别准确率Acc实验结果进行了统计分析。为了进一步评估各方法的稳定性,本文采用 F_1 -Score对相关结果进行量化评估,3个数据集所有被试的平均实验结果如表2所示。通过表2可以看出,相比于传统脑电数据及网络特征提取方法,基于情绪脑电网络图特征学习策略实现的情绪识别能取得较好的分类实验结果。前期相关研究结果表明:脑电信号的Gamma频段与个体情绪状态表现出更强的相关性,基于脑电Gamma频段特征实现的情绪识别往往具有更高的准确率^[34]。在本文的对比实验结果中,传统特征提取方法与所提方法在Gamma频段一致性的取得最高分类结果,实验结果与前期研究结果一致。具体来说,利用传统特征提取算法在公开数据集上取得的最优分类结果分别是91.56%(SEED数据集,DE特征,Gamma频段),70.72%(MAHNOB-HCI数据集,DE特征,Gamma频段)和69.60%(DEAP数据集,DE特征,Gamma频段)。相较于传统特征提取方法,基于情绪脑电网络图特征学习策略得到的最优结果分别是91.85%(SEED数据集,Gamma频段),79.36%(MAHNOB-HCI数据集,Gamma频段)和79.00%(DEAP数据集,Gamma频段)。通过在3个公开数据集上的对比试验结果可以看出,本文采用的脑电网络图特征学习算法能够有效提升离线任务下的情绪识别准

表2 基于3个公开数据集的对比试验结果 (Acc/% ± Std/ F_1 -Score)
 Table 2 Experimental results on three public emotional datasets (Acc/% ± Std/ F_1 -Score)

数据集	频段特征	Theta	Alpha	Beta	Gamma
SEED (3-class)	PSD	36.54 ± 2.88/0.25	40.82 ± 6.63/0.33	64.25 ± 15.40/0.62	75.38 ± 16.74/0.74
	DE	49.26 ± 4.85/0.49	50.57 ± 6.74/0.50	78.08 ± 8.07/0.78	91.56 ± 5.01/0.92
	CC	40.73 ± 4.12/0.40	40.73 ± 4.12/0.49	74.27 ± 7.41/0.74	86.69 ± 4.94/0.87
	LE	49.54 ± 10.93/0.41	42.35 ± 6.80/0.49	46.34 ± 4.59/0.74	87.13 ± 4.79/0.87
	SP	35.12 ± 1.10/0.24	38.78 ± 4.27/0.32	45.61 ± 6.29/0.40	46.38 ± 5.40/0.40
	GE	35.03 ± 1.18/0.22	37.78 ± 4.17/0.29	46.46 ± 6.70/0.42	46.14 ± 5.15/0.40
	GL	43.32 ± 5.24/0.43	52.30 ± 8.93/0.52	80.47 ± 7.55/0.80	91.85 ± 4.10/0.92
MAHNOB-HCI (3-class)	PSD	50.55 ± 6.83/0.45	53.74 ± 7.68/0.49	58.49 ± 9.30/0.54	63.58 ± 11.76/0.62
	DE	52.96 ± 6.73/0.49	55.69 ± 7.48/0.52	65.12 ± 7.15/0.63	70.72 ± 8.29/0.70
	CC	43.80 ± 6.61/0.36	44.41 ± 6.89/0.37	55.30 ± 5.90/0.52	67.02 ± 10.01/0.67
	LE	49.54 ± 10.93/0.36	42.35 ± 6.80/0.37	46.34 ± 4.59/0.52	66.70 ± 10.43/0.77
	SP	43.15 ± 6.98/0.28	43.09 ± 7.23/0.28	44.17 ± 6.71/0.30	47.75 ± 6.69/0.37
	GE	43.13 ± 6.99/0.27	43.05 ± 7.25/0.28	44.46 ± 6.46/0.31	47.50 ± 6.55/0.37
	GL	44.28 ± 6.81/0.38	45.18 ± 6.95/0.40	57.24 ± 6.93/0.55	79.36 ± 7.70/0.79
DEAP (4-class)	PSD	47.31 ± 10.15/0.38	47.95 ± 9.13/0.40	55.80 ± 9.29/0.52	64.19 ± 11.13/0.61
	DE	43.80 ± 6.06/0.33	44.84 ± 5.77/0.34	53.27 ± 9.86/0.12	69.60 ± 10.20/0.69
	CC	49.58 ± 10.78/0.43	42.50 ± 6.62/0.29	46.20 ± 4.81/0.37	69.02 ± 10.46/0.68
	LE	49.54 ± 10.30/0.43	42.35 ± 6.80/0.29	46.34 ± 4.59/0.37	68.70 ± 10.43/0.67
	SP	42.01 ± 6.98/0.26	42.05 ± 7.06/0.26	42.07 ± 6.80/0.26	43.38 ± 6.79/0.29
	GE	42.02 ± 6.99/0.26	42.04 ± 7.07/0.26	41.97 ± 6.95/0.26	43.37 ± 6.49/0.29
	GL	59.52 ± 12.44/0.57	42.98 ± 6.39/0.33	50.40 ± 6.86/0.46	79.00 ± 7.98/0.79

准确率,实验结果也进一步验证了本文所提方法在情绪脑电分类识别任务中的有效性和稳健性。

从本质上来说,脑电网络分析作为一种监测大脑认知加工过程的研究手段,通过评估脑电信号间的相关性构建脑区间的功能连接强度,旨在揭示认知过程中脑区间的信息协同处理与交互机制^[35]。与局部性的脑电能量特征提取方法相比(如PSD,DE等),本文所提方法能够捕捉个体情绪认知加工过程中全局性的大脑活动模式,实现对情绪脑电数据更为有效的特征提取。此外,与基于单个脑电网络样本的属性特征提取方法相比,本文在高维样本空间下构建情绪脑电网络样本间的局部邻接图。本质上,本文所提方法构建的邻接图能有效捕捉样本间的分布特性,同时结合谱图理论求解得到的低维映射能够有效地保留样本间的分布特性,从而实现样本在低维映射空间的最优表达,以此实现对情绪脑电网络特征的有效提取和挖掘。

4 结束语

本文利用情绪脑电提出一种基于情绪脑电网络图特征学习的情绪识别算法,该算法利用个体情绪脑电构建脑网络,采用在原始样本空间构建局部邻接图的策略挖掘出样本集的分布特性,在保留样本集局部分布特性的前提下,利用谱图理论对原始高维情绪脑电网络样本寻找最优的低维映射空间,完成对原始高维情绪脑电网络样本的低维嵌入表达,并实现对对应情绪脑电网络特征的有效挖掘和提取。

基于公开情绪脑电数据集的对比实验结果表明:与传统脑电特征提取算法相比,本文所提出的情绪识别策略具有较好的识别性能。实验结果也进一步证明了基于脑电网络进行图特征提取与挖掘的可行性和优越性,为基于脑电实现个体状态解码相关工作的开展提供一种潜在可行的解决方案。

Reference:

- [1] KIM J, ANDRÉ E. Emotion recognition based on physiological changes in music listening[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2008, 30(12): 2067-2083.
- [2] HUANG Haiyun, XIE Qiyou, PAN Jiahui, et al. An EEG-based brain computer interface for emotion recognition and its application in patients with disorder of consciousness[J]. *IEEE Transactions on Affective Computing*, 2019, 12(4): 832-842.
- [3] AMIT E, CHRISTIAN B, GROSS J J. The neural bases of emotion regulation[J]. *Nature Reviews Neuroscience*, 2015, 16(11): 693-700.
- [4] PABLO A G, MIGUEL A H, NAEEM R. Fusing highly dimensional energy and connectivity features to identify affective states from EEG signals[J]. *Neurocomputing*, 2017, 244: 81-89.
- [5] CHRISTIAN M, BRENDAN A, ANTON N, et al. A survey of affective brain computer interfaces: Principles, state-of-the-art, and challenges[J]. *Brain-Computer Interfaces*, 2014, 1(2): 66-84.
- [6] ZHENG Weilong, LIU Wei, LU Yifei, et al. Emotion Meter: A multimodal framework for recognizing human emotions[J]. *IEEE Transactions on Cybernetics*, 2018, 49(3):1110-1122.
- [7] SHANECHI MARYAM M. Brain-machine interfaces from motor to mood[J]. *Nature Neuroscience*, 2019, 22(10): 1554-1564.
- [8] AL-NAFJAN A, MANAR H, AL-OHALI Y, et al. Review and classification of emotion recognition based on EEG brain-computer interface system research: A systematic review[J]. *Applied Sciences*, 2017, 7(12): 1239.
- [9] LONG Jinyi, LI Yuanqing, YU Tianyou, et al. Target selection with hybrid feature for BCI-based 2-D cursor control[J]. *IEEE Transactions on Biomedical Engineering*, 2011, 59(1): 132-140.
- [10] LI Yuanqing, PAN Jiahui, WANG Fei, et al. A hybrid BCI system combining P300 and SSVEP and its application to wheelchair control[J]. *IEEE Transactions on Biomedical Engineering*, 2013, 60(11): 3156-3166.
- [11] SI Yajing, WU Xi, LI Fali, et al. Different decision-making responses occupy different brain networks for information processing: A study based on EEG and TMS[J]. *Cerebral Cortex*, 2019, 29(10): 4119-4129.
- [12] ZHENG Weilong, ZHU Jiayi, LU Baoliang. Identifying stable patterns over time for emotion recognition from EEG[J]. *IEEE Transactions on Affective Computing*, 2017, 10(3): 417-429.
- [13] SOLEYMANI M, LICHTENAUER J, PUN T, et al. A multimodal database for affect recognition and implicit tagging[J]. *IEEE Transactions on Affective Computing*, 2012, 3(1): 42-55.
- [14] SANDER K, CHRISTIAN M, MOHAMMAD S, et al. DEAP: A database for emotion analysis using physiological signals [J]. *IEEE Transactions on Affective Computing*, 2012, 3(1): 18-31.
- [15] ARANHA R V, CORRÊA C G, NUNES F L S. Adapting software with affective computing: A systematic review[J]. *IEEE Transactions on Affective Computing*, 2019, 12(4): 883-899.
- [16] LI Chang, ZHANG Zhongzhen, SONG Rencheng, et al. EEG-based emotion recognition via neural architecture search[J]. *IEEE Transactions on Affective Computing*, 2021, 14(2): 957-968.
- [17] HUANG Weichen, WU Wei, LUCAS MO V, et al. Neurofeedback training with an electroencephalogram-based Brain-computer interface enhances emotion regulation[J]. *IEEE Transactions on Affective Computing*, 2021, 14(2): 998-1011.
- [18] BANKS S J, EDDY K T, ANGSTADT M, et al. Amygdala-frontal connectivity during emotion regulation[J]. *Social Cognitive and Affective Neuroscience*, 2007, 2(4): 303-312.
- [19] LEE Y Y, SHULAN H. Classifying different emotional states by means of EEG-based functional connectivity patterns[J]. *PLoS One*, 2014, 9(4): e95415.
- [20] LUIZ P. On the relationship between emotion and cognition[J]. *Nature Reviews Neuroscience*, 2008, 9(2): 148-158.
- [21] BULLMORE E, SPORNS O. Complex brain networks: Graph theoretical analysis of structural and functional systems[J]. *Nature Reviews Neuroscience*, 2009, 10(3): 186-198.
- [22] YASAR D, ESEN Y, SERDAR Y. Analysis of functional brain connections for positive-negative emotions using phase locking value[J]. *Cognitive Neurodynamics*, 2017, 11(6): 487-500.

- [23] LI Peiyang, LIU Huan, SI Yajing, et al. EEG based emotion recognition by combining functional connectivity network and local activations[J]. IEEE Transactions on Biomedical Engineering, 2019, 66(10): 2869-2881.
- [24] De VICO FALLANI F, ASTOLFI L, CINCOTTI F, et al. Cortical functional connectivity networks in normal and spinal cord injured patients: Evaluation by graph analysis[J]. Human Brain Mapping, 2010, 28(12): 1334-1346.
- [25] MIKAIL R, OLAF S. Complex network measures of brain connectivity: Uses and interpretations[J]. NeuroImage, 2010, 52(3): 1059-1069.
- [26] BELKIN M, NIYOGI P. Laplacian eigenmaps and spectral techniques for embedding and clustering[J]. Advances in Neural Information Processing Systems, 2001, 14(6):585-591.
- [27] HE X, PARTHA N. Locality preserving projections[J]. Advances in Neural Information Processing Systems, 2004, 16(16): 153-160.
- [28] HE X, YAN S, HU Y, et al. Face recognition using Laplacianfaces[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2005, 27(3): 328-340.
- [29] SERGUL A, DIMITRIOS P, LEAHY R M. A note on the phase locking value and its properties[J]. NeuroImage, 2013, 74: 231-244.
- [30] ZHENG Weilong, LU Baoliang. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. IEEE Transactions on Autonomous Mental Development, 2017, 7(3): 162-175.
- [31] HANNA B, JULIEN F, PHILIPPE G, et al. Emotion recognition based on high-resolution EEG recordings and reconstructed brain sources[J]. IEEE Transactions on Affective Computing, 2017, 11(2): 244-257.
- [32] LIU Yongjin, YU Minjing, ZHAO Guozhen, et al. Real-time movie-induced discrete emotion recognition from EEG signals [J]. IEEE Transactions on Affective Computing, 2017, 9(4): 550-562.
- [33] IWAN S, ADAM P B, GARY W. SVM parameter optimization using grid search and genetic algorithm to improve classification performance[J]. Telkomnika, 2016, 14(4): 1502.
- [34] ALARCAO S M, FONSECA M J. Emotions recognition using EEG signals: A survey[J]. IEEE Transactions on Affective Computing, 2017, 10(3): 374-393.
- [35] LI Cunbo, LI Peiyang. Effective emotion recognition by learning discriminative graph topologies in EEG brain networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023. DOI:10.1109/TNNLS.2023.3238519.

作者简介:



李存波(1992-),男,博士研究生,研究方向:情绪分类、睡眠研究、脑机交互和深度学习, E-mail: cunboli@163.com。



杨蕾(1998-),女,硕士研究生,研究方向:机器学习、模式识别和贝叶斯学习。



陈昭瑾(1999-),女,硕士研究生,研究方向:脑机接口、情绪识别、机器学习。



汪义锋(1998-),男,硕士研究生,研究方向:脑机接口、情绪识别。



李沛洋(1989-),男,博士,副教授,研究方向:脑机交互、凸优化、机器学习和模式识别。



李发礼(1990-),男,博士,副教授,研究方向:EEG-MRI网络分析及其应用、基于多状态-多模态信号互补融合。



尧德中(1965-),男,博士,教授,研究方向:脑电和磁共振信息提取技术及其在脑机交互与癫痫等脑疾病问题中的应用研究。



徐鹏(1977-),通信作者,男,博士,教授,研究方向:基于 L_p 范数的脑电图溯源问题、脑机接口、机器学习、脑网络分析等, E-mail: xupeng@uestc.edu.cn。