

DOI:10.3969/j.issn.1005-202X.2023.06.010

医学信号处理与医学仪器

基于脑电的脑网络稳定模式情绪识别研究

吴彦泽¹, 王海玲¹, 高宇飞²

1. 上海工程技术大学电子电气工程学院, 上海 201600; 2. 郑州大学网络空间安全学院, 河南 郑州 450002

【摘要】利用锁相值构建不同时间段的情绪脑网络,探讨不同时间情绪相关脑网络模式的稳定性,提出基于脑网络二阶特征的情绪识别框架。结果表明,在跨被试研究和单被试研究中最高准确率分别为79.17%和82.92%,ANOVA分析3个时间段的识别结果无显著性差异,证明本研究提出的情绪识别框架是稳定的。在不同时间段,同类别的情绪均具有相同的脑网络连接模式和最小生成树的结构,说明相同情绪在不同时间存在稳定的脑网络模式。使用脑网络特征进行情绪识别是稳定且可靠的,这为人机交互中情绪识别提供一种新途径。

【关键词】脑电图;情绪识别;脑网络模式;锁相值;图论;最小生成树;机器学习

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2023)06-0727-09

Stable brain network pattern for EEG-based emotion recognition

WU Yanze¹, WANG Hailing¹, GAO Yufei²

1. School of Electrical and Electronic Engineering, Shanghai University of Engineering Science, Shanghai 201600, China; 2. School of Cyberspace Security, Zhengzhou University, Zhengzhou 450002, China

Abstract: The emotional brain networks at different time periods are constructed using phase locking values for exploring the stability of emotion-related brain network patterns at different time periods; and an emotion recognition framework based on the second-order features of brain network is proposed. The results show that the highest accuracy are 79.17% and 82.92% in cross-subject study and single-subject study, and there is no significant difference in the recognition results of the 3 time periods in ANOVA analysis, which proves that the emotion recognition framework proposed in the study is stable. In different time periods, the emotions of the same category have the same brain network connection pattern and minimum spanning tree structure, indicating that the same emotion has a stable brain network pattern in different time periods. Using brain network features for emotion recognition is stable and reliable, which provides a new approach for emotion recognition in human-computer interaction.

Keywords: electroencephalogram; emotion recognition; brain network model; phase locking value; graph theory; minimum spanning tree; machine learning

前言

情绪识别是人机交互领域非常重要的研究方向之一,旨在通过测量得到的人类情绪去模拟人与计算机间的交互^[1]。基于脑电(Electroencephalogram, EEG)信号的情绪识别研究是情绪研究的热点之一^[2]。传统的情绪识别研究中,大多使用功率谱密度

(Power Spectral Density, PSD)、微分熵(Differential Entropy, DE)^[3]、小波变换等方法,针对每个电极信号提取特征进行情绪识别。Zheng等^[4]提取不同频段的PSD、DE、差分不对称、有理不对称、差分熵等特征并分别用于情绪识别,发现DE特征在 γ 频段的识别准确率最高,但这些方法仅能反映不同电极所在脑区的脑活动变化及差异^[5]。然而情绪是一个复杂的认知加工过程,不同脑区并不是独立工作的,脑区间的活动不仅存在差异,不同脑区间还存在信息的传播和流动,脑区之间相互作用,形成具有不同功能的脑网络^[6]。近年来已有部分研究关注到基于脑网络特征的情绪识别。Wu等^[7]使用交叉功率谱密度构建基于脑电信号的脑网络,再把同类别情绪脑网络求平均获得关键子网络,用支持向量机(Support Vector

【收稿日期】2023-01-18

【基金项目】国家自然科学基金(62001284, 62006210);郑州大学高层次人才科研启动基金(32340306)

【作者简介】吴彦泽,硕士,研究方向:情绪识别,E-mail: 15613394243@163.com

【通信作者】王海玲,博士,研究方向:神经生理信号处理与分析,E-mail: wanghailing@sues.edu.cn

Machine, SVM)进行识别获得很好的效果。Li等^[8]使用锁相值(Phase Locking Value, PLV)构建功能脑网络,并在此基础上提取图论相关特征:集群系数、路径长度、全局效率和局部效率后融合频谱特征进行分类。Yu等^[9]使用Spearman构建正性和负性情绪脑网络,结果表明,额叶和枕叶是产生情绪的主要脑区。

然而,到目前为止,基于脑网络特征的情绪识别研究更多集中在分类的准确率上,详细阐述了脑网络特征在情绪识别研究上的可行性,但并没有对特定情绪产生的脑网络模式随时间变化的稳定性进行系统的评估^[10]。其次不同时间段情绪识别框架的性能是否存在差异也没有进行充分的探讨,故本研究利用情绪脑网络和机器学习的方法来探究情绪脑网络模式的稳定性。稳定的脑网络模式和稳定的识别框架对真实世界的应用是十分重要的。在实际应用中,认知任务相关的EEG信号对认知状态和环境变化是十分敏感的^[11]。研究指出,同一个被试在不同时间执行相同的认知任务时,与该任务相关的脑活动模式会表现出一致性^[12]。故本研究将探究相同被试在重复实验中情绪识别的表现,重点讨论以下问题:(1)在不同时间是否存在稳定的情绪相关的脑网络模式?(2)使用脑网络进行情绪识别效果如何?(3)不同时间采集的数据对情绪识别模型是否有影响?本研究将利用PLV构建不同时间段的情绪脑网络,并在此基础上探究不同时间段相同情绪的脑网络模式的稳定性,并进一步基于脑网络提取高阶特征进行情绪识别。

本研究的主要贡献如下:(1)通过分析发现不同的情绪都有特定的脑网络连接模式和最小生成树(Minimum Spanning Tree, MST)^[13]的结构,并且在不同的时间段上都能够稳定表现出来,说明的确存在稳定和情绪任务相关的脑网络模式;(2)基于该稳定的脑网络模式,提出一种稳定的情绪识别框架,并筛选出最适合情绪识别的图论和MST特征,优于传统的频谱分析法,可以有效识别正性、中性和负性3类情绪。

1 数据介绍及预处理

本研究使用的是上海交通大学SEED数据集共15例被试,其中,男7例,女8例;年龄19~28岁。每名被试按照要求进行3个不同时间段(A、B、C时间段)的实验,实验间隔约为1周。每次实验会给被试播放15个电影片段,诱发负性、中性和正性情绪的电影片段都为5段。视频放映前会有15s的提示,每个电影片段长约4min。脑电信号使用ESI NeuroScan 62通

道的采集设备采集,采样频率为1000 Hz。本研究所使用的脑电信号是SEED数据集中预处理好的数据,采样频率下降到200 Hz,并使用了0~75 Hz的带通滤波器对信号进行滤波^[4,14]。

本研究数据处理主要分成两部分,第一部分为相同时间段中所有被试的EEG信号进行识别的跨被试研究,在该部分中所有被试的数据进行打乱后训练集和测试集按照8:2进行划分,该部分主要目的是为了验证是否存在稳定的脑网络模式以及得到最适合情绪识别的图论和最小生成树特征。第二部分为对数据集中单个被试的脑电信号进行识别的单被试研究,划分的训练集和测试集之比也为8:2,该研究的主要目的为验证本研究提出的情绪识别框架是否稳定。

2 脑网络的构建

大量研究表明,基于相位信息的同步测量方法比基于幅值信息的测量方法鲁棒性更强,原因是大脑是一个非线性的动力系统,基于幅值方法计算不同脑区之间的耦合程度容易受到噪声的影响^[15]。而基于相位的PLV对不同相位之间的同步变化十分敏感,因此本研究使用PLV构建脑网络。在PLV的计算中,如果两个信号的边缘分布是均匀的,且两信号相互独立,则相对相位也是均匀分布的,此时耦合关系较弱,PLV近似为0。相反,如果两个信号的相位是强耦合的,PLV近似为1^[16]。给定两个信号 $x(t)$ 和 $y(t)$ 在 t 时刻的瞬时相位为 $\phi_x(t)$ 和 $\phi_y(t)$,则PLV定义为:

$$PLV_t = \frac{1}{N} \left| \sum_{n=1}^N e^{i\Delta\phi(t)} \right|, \Delta\phi(t) = \phi_x(t) - \phi_y(t) \quad (1)$$

其中, t 表示时间点, N 表示信号的样本点个数, $\Delta\phi(t)$ 表示两个电极在 t 时刻的相位差^[17]。本研究使用62导联的EEG信号构建功能脑网络,两两导联之间互相计算PLV系数,每个电极对之间通过PLV计算的值当作脑网络中边的权值,最终得到62×62以主对角线对称的功能脑网络,电极分布如图1所示。对每个被试每个trial的脑电数据,使用窗长为1.5s的滑动窗口,分别提取 θ (4~8 Hz)、 α (8~12 Hz)、 β (12~30 Hz)、 γ (30~48 Hz)和总频段 τ (4~48 Hz)5个频段的脑网络特征,滑动窗口的步长为0.15s。根据不同的时间段,本研究计算每个被试不同情绪状态的脑网络矩阵的平均值,记为MPLV,将其作为特征之一。

3 特征的提取和选择

3.1 MST的构建以及特征提取

MST表示为在给定的脑网络中求得一棵树,这棵




图1 电极的名称以及电极的分布图

Figure 1 Names of electrodes and the distribution

树拥有脑网络中所有的顶点,并且满足树中边的权值之和最小^[18]。本研究通过PLV构建的脑网络是沿主对角线对称的对称矩阵,基于此,本研究把构建的脑网络设为矩阵 G , G 是对称矩阵,对角线是相同电极之间进行的PLV运算。于是选取 G 中除对角线以外的下三角部分,使用Kruskal算法^[19]生成最小生成树,将所有连接边的权重从小到大进行排序,然后断开所有节点,再添加权重最小的连接,接下来添加第二小权重的连接,并重复这个过程,直到所有节点都已添加并且不构成回路。最终构成一棵由62个节点和61条边组成的最小生成树。本研究提取的MST特征为:树中最大的度(MD_{max}),树的节点的中介中心性(MBC),最大离心率($MECC_{max}$),平均离心率($MECC_{mean}$),直径(MDM),叶分数(MLF),树的特征路径长度(MCLP),树的层次结构(MTH)^[20]共8种特征。

3.2 图论特征提取

本研究在基于PLV构建的功能脑网络的基础上,建立无向无权图,并提取其拓扑特征^[21]。将脑网络中两两电极信号之间的耦合强度表示图中两节点之间边的权重,于是本研究依据多次实验设置阈值 r 为0.78,通过阈值 r 去判断脑网络中节点与节点之间是否连通。例如在脑网络中两节点之间边的权重大于阈值 r ,则把此条边的权值设为1,代表该边两端上的节点是连通的,否则设为0,代表节点之间是不连通的。以此来构建无向无权图,在构建完图之后进一步提取以下图论特征。所提图论特征为:图中最大的度(D_{max}),图的最短路径(cpl),平均邻接度(k),最大集群系数(C_{max}),平均集群系数(C_{mean}),传递性(tra),局部效率(Eloc),全局效率(Egb),中心度(DC),图的最大特征向量中心性(EC_{max}),图的平均特征向量中心性(EC_{mean}),图中节点最大中介中心性($nodeBC_{max}$),图中边最大中介中心性($edgeBC_{max}$),

紧密中间性(cc),模块度(Q),图密度(des),最大K核($KCORE_{max}$)^[22]和小世界网络(sw)加上MPLV共19种特征^[21,23]。

3.3 特征选择与识别算法

为了去除冗余特征筛选出最适合情绪识别的特征,本研究使用包裹式的特征选择法^[24],使用Relieff结合SVM的方法进行特征选择。Relieff在进行特征选择时,每次从训练集中随机选择一个样本,在每个类别样本中分别寻找与其相邻的 k 个样本,不断更新特征的权值,最后得到每个特征的权重 $W^{[25]}$:

$$W[A] = W[A] - \sum_{j=1}^k \text{diff}(A, R_i, H_j) / (m \cdot k) + \sum_{C \in \text{class}(R_i)} \left[\frac{P(C)}{1 - P(\text{class}(R_i))} \sum_{j=1}^k \text{diff}(A, R_i, M_j(C)) \right] / (m \cdot k) \quad (2)$$

式中, m 为样本的抽样次数, R_i 表示训练集中随机选择的第 i 个样本,而 $\sum_{j=1}^k \text{diff}(A, R_i, H_j)$ 表示样本 R_i 和 H_j 在特征 A 上的距离,在每次循环中从 R 的同类样本集中找到 R 的 k 个最近邻 $H_j(j=1, 2, \dots, k)$,从每一个不同类样本集中找到 k 个最近邻 $M_j(C)$ 。 $P(C)$ 表示 C 类样本的概率, $\text{class}(R_i)$ 为样本点 R_i 所属的类别标签,循环所有的特征得到每个特征权重。通过Relieff得到特征的权重后,对所有特征按权重大小进行排序,权重最大的特征在第1位,以此类推。然后结合SVM进行特征选择。具体算法流程为:(1)使用Relieff算法计算每个特征的权重;(2)根据权重对特征进行降序排序;(3)把权重最高的特征输入SVM中进行十折交叉验证得到平均准确率;(4)加入下一个特征并且重新训练SVM得到准确率;(5)判断加入特征后的特征子集准确率是否高于之前的准确率,如果高于之前的准确率则加入最优特征子集,否则跳过该特征;(6)直到循环完所有的特征。

对特征进行筛选后得到最优特征子集,使用5种机器学习的算法进行识别,分别为:SVM,随机森林(Random Forest, RF),最邻近算法(K-NearestNeighbor, KNN),adaboost和贝叶斯分类器(Bayesian)。其中SVM的核函数为高斯核,Gamma为0.01~10.00,步进为0.01,系数C为0~10,步进为0.05。KNN中 k 选择为1~50。RF中树的深度设置为1~50,基模型为1~200。adaboost分类器中学习率为0.01~5.00,步长为0.01,基模型为1~200。分别计算5个模型下的准确率、F1-score、精准率和召回率。在模型训练时,训练集和测试集的比例为8:2,并使用十折交叉验证对模型进行验证并计算模型的标准差和方差,图2为情绪识别流程示意图。

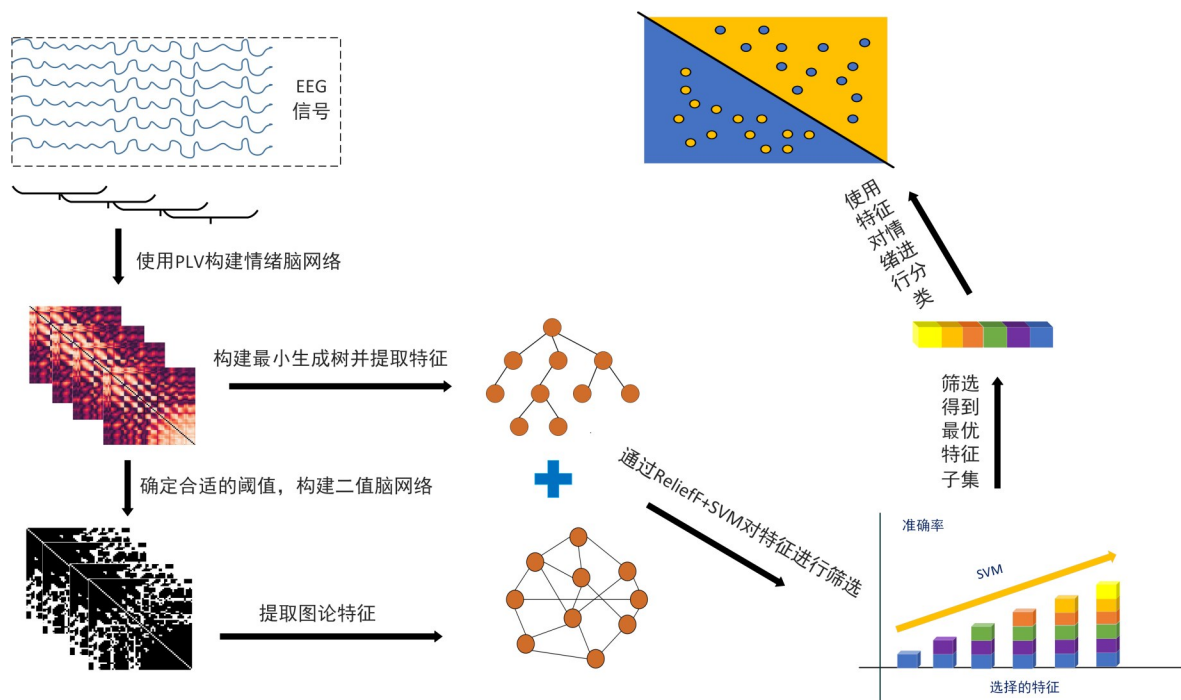


图2 情绪识别框架流程示意图

Figure 2 Flowchart of emotion recognition framework

4 结果

4.1 脑网络模式分析

为了探究不同时间情绪相关脑网络模式是否稳定,本研究进一步分析了不同时间段下不同情绪的脑网络、MST结构,还有基于脑网络模式所提框架获得最佳识别率的特征集。为了验证每类情绪的脑网络是否有相似的连接模式,本研究对所有被试相同情绪脑网络进行单样本 t 检验($P<0.01$),图3代表A、B、C 3个时间段单样本 t 检验的结果。本研究把不同时间段同类别的情绪脑网络连接模式放在一起比较,其中黑色脑区代表该时间段下所有被试脑网络进行单样本 t 检验的结果是显著的($P<0.01$),白色脑区代表不显著,图中不同颜色柱代表不同的脑区,例如在负性情绪的 θ 频段,枕叶和顶叶功能连接的脑区其显著性是相似的。 τ 频段为4个频段的总和。

从图3中可以发现在不同时间段,同频段下相同的情绪有相同的脑网络连接模式,低频段 θ 和 α 的显著性通道数不如高频段 β 和 γ ,但低频段的情绪脑网络在各时间段上都表现出相同的连接模式,在高频段上脑网络的连接模式的显著性更加明显,在3个时间段中,每类情绪除主对角连接的脑区有相同的连接模式外,在其它脑区也有相同的连接模式。如负性情绪在 β 、 γ 和 τ 频段上,在A、B、C 3个时间段中顶叶和枕叶、枕叶和中央区、中央区和顶叶、额叶和顶叶有相同的连接模式。除此之外 τ 频段在额叶和枕

叶的连接模式也相同,中性情绪在 β 频段,A、B、C 3个时间段中枕叶和顶叶、枕叶和中央区、顶叶和中央区、前额叶和额叶相连接的脑区中具有相同的连接模式,而 γ 和 τ 频段在此基础上还有枕叶和中央区、枕叶和额叶、顶叶和额叶、额叶和前额叶的连接模式在3个时间段上均相同。正性情绪在不同时间段的 β 、 γ 和 τ 频段也表现出相似的结构,如在A、B、C 3个时间段中, β 频段在枕叶和顶叶、枕叶和中央区、顶叶和中央区、前额叶和额叶连接模式相同,在 γ 和 τ 频段还有枕叶和额叶、顶叶和额叶也展现出一致的连接模式。这说明不同时间段,相同类型的情绪的确存在稳定的脑网络,在高频段上更加突出。

此外为了进一步探究脑网络模式是否稳定,本研究在每类情绪脑网络的基础上,进一步提取了每类情绪的MST结构,A、B、C 3个时间段下不同情绪的MST结构如图4所示。从图中可以看出,负性情绪在 θ 、 α 和 β 频段上,A、B、C 3个时间段的MST结构均呈现线形, γ 和 τ 在3个时间段上均表现为星型,并且有一定的层次性。而中性情绪在 θ 频段上,A、B、C 3个时间段都呈现线形,而在高频段如 β 和 γ 频段,3个时间段的MST结构均呈现星形,其中 τ 频段也表现为星形。而在正性情绪下, θ 和 α 在A、B、C 3个时间段的MST结构为线形,而在高频段上A、B、C 3个时间段的MST也为星形。这说明基于脑网络提取的MST也有一致的结构,并且从图3分析可知脑网络也有相同的连接模式,证明每类情绪的确存在稳定的

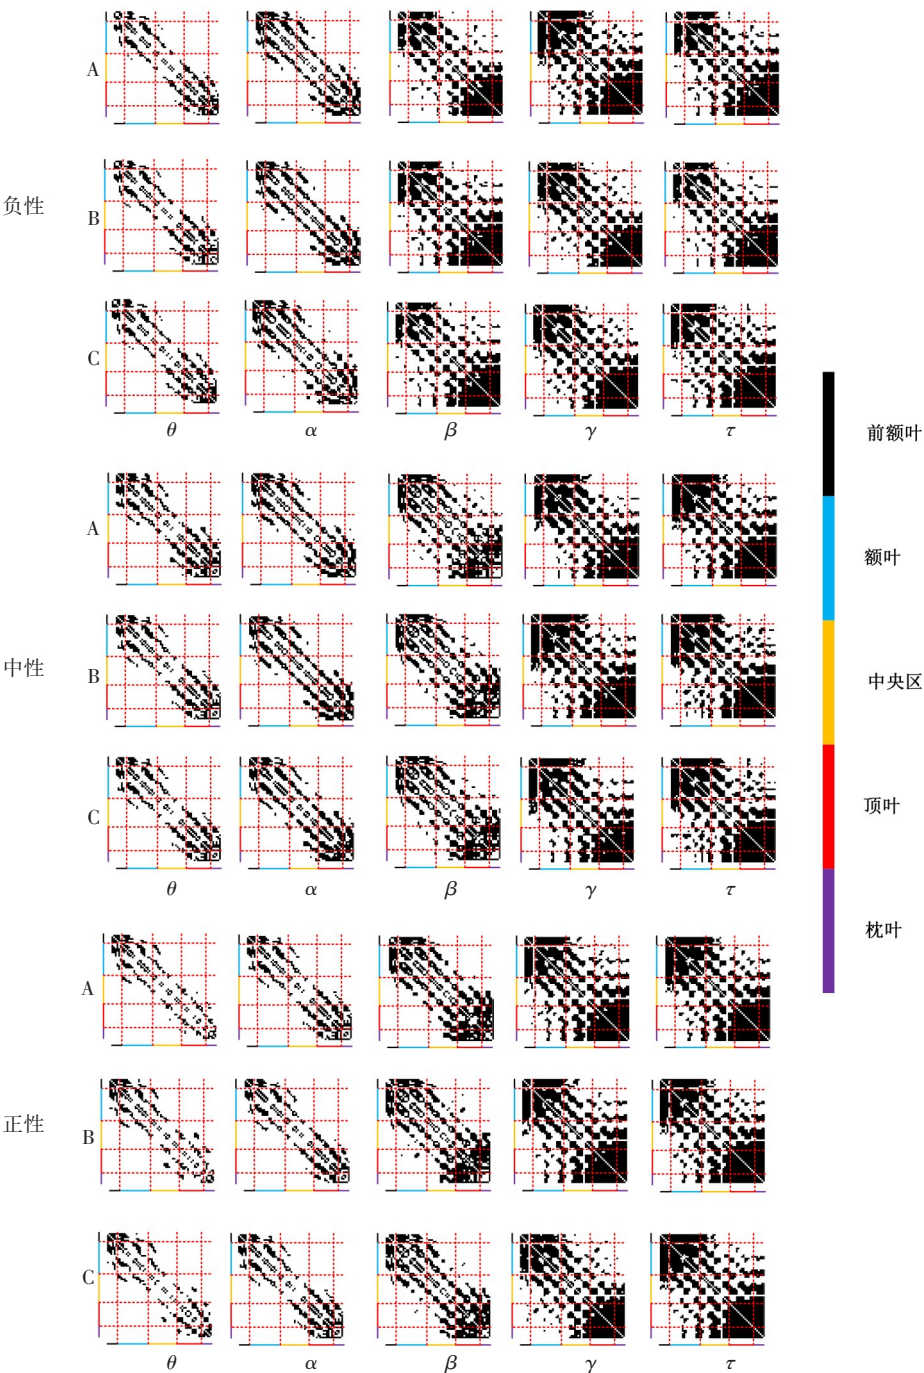


图3 A、B、C 3个时间段显著脑区分布图

Figure 3 Significant brain area distribution maps in A, B, C time periods

黑色部分代表显著脑区,横纵坐标不同颜色代表不同脑区,红色虚线代表不同脑区间的分割线

脑网络模式,并且在不同的时间段上都能稳定表现出来。

图5是不同时间段不同频率下,基于脑网络模式所提框架下获得最优识别率的特征,其中黄框是获得最高准确率的特征集,黑色代表选中,灰色代表未选中,最优特征均为 γ 频段上的特征子集,A、B、C 3个时间段 γ 频段的识别率分别为78.28%、75.44%和79.17%。其中3个时间段中的MST特征有MTH、MCPL、MD_{max}、MDM、MBC、MLF、MECC_{max}、

MECC_{mean};图特征有sw、tra、Q、cc、nodeBC_{max}、EC_{mean}、edgeBC_{max}、EC_{max}、MPLV。3个时间段都选到的特征为:MTH、MLF、MECC_{max}、MECC_{mean}、sw、cc、Q、nodeBC_{max}、tra共9个,A、B、C 3个时间段提取的特征数量分别为13、12和12个,共同提取的特征占据每个时间段特征数目的70%及以上,说明基于脑网络模式所提取到的特征是相对稳定的,并且本研究筛选出了最适合情绪识别的图论和最小生成树特征。

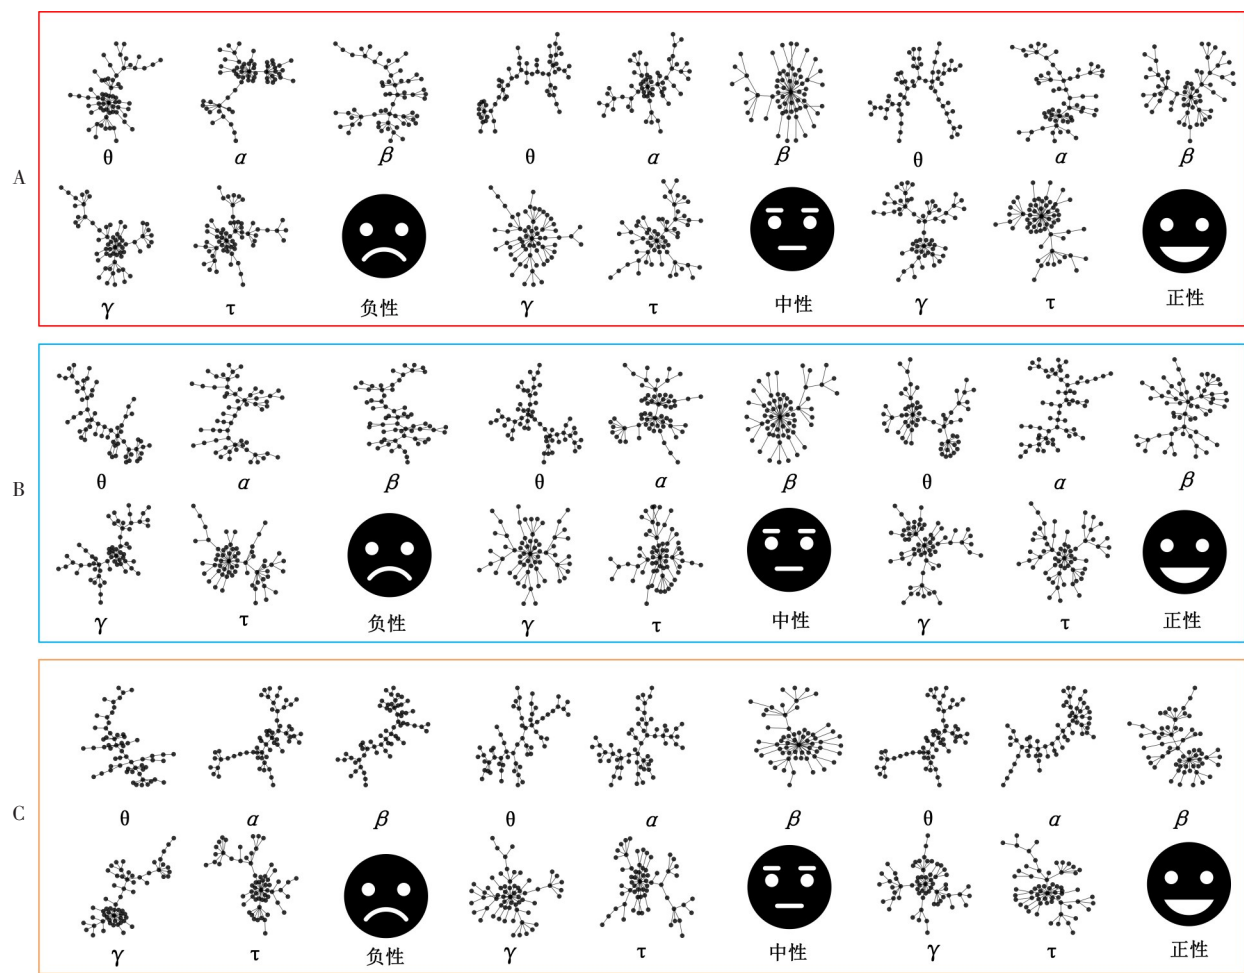


图4 A、B、C时间段不同频段下不同情绪的最小生成树

Figure 4 Minimum spanning trees of different emotions at different frequency bands and in A, B and C time periods




图5 特征选择色块图

Figure 5 Feature selection color block chart

4.2 情绪识别结果

本研究根据稳定的脑网络模式提出基于脑网络的情绪识别框架,为了探究该框架对情绪识别的性能及稳定性,同时对比了传统的频谱特征 PSD、DE,单独使用图论和单独使用 MST 特征的结果。图 6 是 MST 加 Graph 在 4 种评价指标下的柱状图。从图中

可以看出 RF 分类器的识别效果最好,其次是 SVM, RF 分类器的平均准确率、F1-score、召回率和精准率分别是 (77.63±2.53)%、(76.01±2.48)%、(76.12±2.42)%、(77.41±2.50)%。

表 1 是 3 个时间段不同频段的传统特征 PSD、DE 与图论特征(Graph)、MST 特征的平均准确率,其中

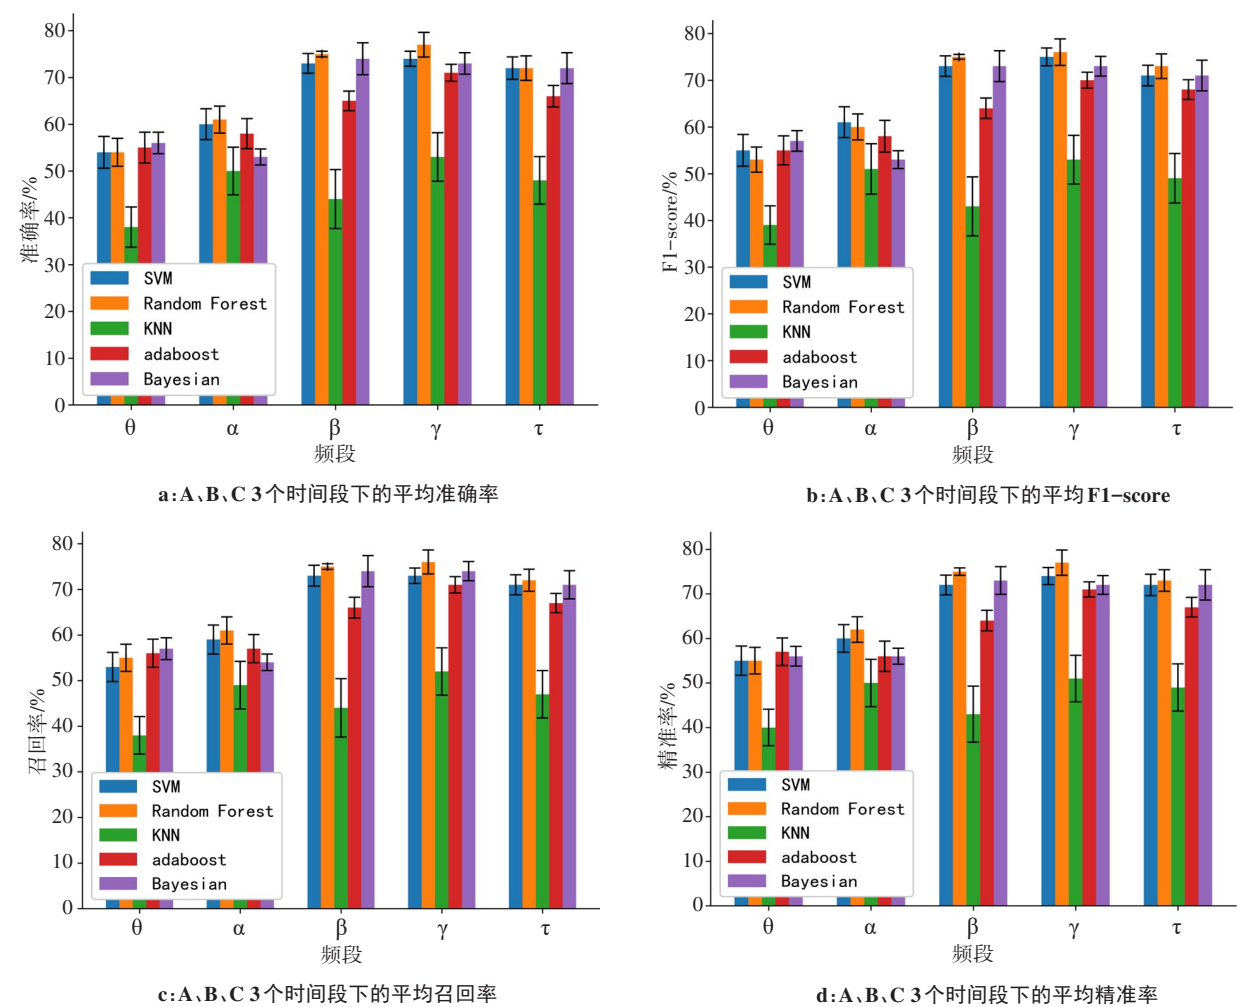


图 6 MST+Graph 特征在 5 种机器学习模型下 4 种评价指标
Figure 6 Four evaluation metrics of MST+Graph features under 5 machine learning models

MST+Graph 表示 MST 和 Graph 特征结合后进行识别。从表中可以看出,所有特征均在 γ 频段有最高的准确率。在 RF 分类器下, MST+Graph 特征平均准确率为 77.63%,比传统特征 PSD 高出 17.25%,比 DE 高出 11.42%,比单纯使用图论特征和 MST 分别高出

8.58% 和 5.41%,说明本研究提出的结合图论和 MST 特征比传统特征方法识别效果更好,更有利于情绪识别。
此外,为了考察不同时间段采集的数据对模型的影响。本研究计算了单被试在不同时间段,使用

表 1 在 3 个时间段上 5 类特征的平均准确率(%)
Table 1 Average accuracy of 5 types of features over 3 time periods (%)

特征	模型	θ	α	β	γ	τ
PSD	SVM	38.88±5.21	42.22±5.27	53.33±5.44	55.55±5.82	56.66±5.13
	RF	44.11±4.30	44.75±5.30	55.56±3.20	60.38±2.20	60.00±3.30
DE	SVM	56.55±3.14	48.88±4.72	56.66±3.53	65.55±3.01	63.66±2.72
	RF	53.56±2.62	50.28±3.23	60.13±3.33	66.21±3.16	60.21±2.45
MST	SVM	50.21±2.53	56.32±3.24	64.74±3.53	70.76±2.42	66.33±2.12
	RF	52.46±2.43	62.01±3.46	70.01±3.35	72.22±2.38	68.27±2.22
Graph	SVM	55.64±2.14	54.84±2.54	66.32±2.52	67.21±2.41	64.76±3.53
	RF	53.21±2.32	54.75±3.54	66.89±2.84	69.05±2.75	65.44±3.44
MST+Graph	SVM	54.15±3.14	60.29±3.32	73.69±2.72	74.28±1.82	72.90±2.32
	RF	54.00±2.58	61.64±2.68	74.28±0.42	77.63±2.53	73.21±2.22

MST加 Graph特征在RF分类器下情绪识别的准确率,如表2所示,14号被试在A时间段分类准确率最高,具体为82.92%。其次本研究把A、B、C 3个时间段RF分类结果的准确率使用ANOVA分析发现P值

为0.45,说明不同时间段采集的数据对模型没有显著性差异,不同时间段的数据对模型没有影响,表明基于脑网络模式提出的情绪识别框架是稳定的。

表2 被试在3个时间段 γ 频段中MST+Graph特征在RF分类器下的准确率(%)
Table 2 Classification accuracy using RF classifier with MST+Graph features at γ bands and in 3 time periods (%)

被试序号	A	B	C	被试序号	A	B	C
Subject1	73.85	65.38	66.67	Subject9	69.23	62.36	71.23
Subject2	74.54	75.64	75.79	Subject10	75.56	72.10	73.64
Subject3	77.69	73.08	73.64	Subject11	75.51	73.33	76.21
Subject4	66.44	63.82	70.51	Subject12	77.64	76.90	79.08
Subject5	64.54	75.64	70.67	Subject13	72.95	76.79	74.80
Subject6	72.85	70.26	69.64	Subject14	82.92	76.38	77.95
Subject7	72.67	66.54	75.72	Subject15	77.55	75.63	80.77
Subject8	65.15	68.82	66.95				

5 结 论

本研究使用PLV构建不同时间段的情绪脑网络,分析不同情绪脑网络的连接模式和MST的结构,结果表明同类情绪在不同的时间段均能表现出相同的脑网络,说明每类情绪都有稳定的脑网络模式。在此基础上进一步提取图论和MST两类特征用于情绪识别,得出最适合情绪识别的图论和MST特征,跨被试和单被试下最高准确率分别为79.17%和82.92%。跨被试的平均准确率比传统的频谱分析法要高出11%左右,说明基于脑网络模式的情绪识别优于传统方法,并且验证不同时间段存在稳定的脑网络模式。基于单被试的识别结果证明了不同时间段的EEG信号对框架没有显著性影响,证明基于脑网络模式提出的情绪识别框架是稳定的。研究表明情绪是动态变化的^[26],动态功能连接能较好地反映个体的情绪随时间的变化^[27]。本研究提取的均是静态的特征,在未来的研究工作中,可考虑使用动态特征,融合频域的特征来进行情绪识别的研究,探索不同情绪的动态变化特性。

【参考文献】

[1] 罗刚,王铭勋,黎明,等.面向情绪脑电分析的增强型功率谱密度特征提取方法[J].中国医学物理学杂志,2022,39(3):349-356.
Luo G, Wang MX, Li M, et al.Feature extraction method based on enhanced power spectral density for emotion analysis using EEG[J]. Chinese Journal of Medical Physics, 2022, 39(3): 349-356.

[2] 张冠华,余旻婧,陈果,等.面向情绪识别的脑电特征研究综述[J].中国科学(信息科学),2019,49(9):1097-1118.

Zhang GH, Yu MJ, Chen G, et al. A review of EEG features for emotion recognition (in Chinese)[J]. Scientia Sinica, 2019, 49(9): 1097-1118.

[3] Dzedzickis A, Kaklauskas A, Bucinskas V. Human emotion recognition: review of sensors and methods[J]. Sensors, 2020, 20(3): 592.

[4] Zheng W, Lu B. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. IEEE Trans Auton Ment Dev, 2015, 7(3): 162-175.

[5] Qing C, Qiao R, Xu X, et al. Interpretable emotion recognition using EEG signals[J]. IEEE Access, 2019, 7(1): 94160-94170.

[6] Ito T, Hearne L, Mill R, et al. Discovering the computational relevance of brain network organization[J]. Trends Cogn Sci, 2020, 24(1): 25-38.

[7] Wu X, Zheng WL, Li Z, et al. Investigating EEG-based functional connectivity patterns for multimodal emotion recognition[J]. J Neural Eng, 2022, 19(1): 016012.

[8] Li P, Liu H, Si Y, et al. EEG based emotion recognition by combining functional connectivity network and local activations[J]. IEEE Trans Biomed Eng, 2019, 66(10): 2869-2881.

[9] Yu M, Xiao S, Hua M, et al. EEG-based emotion recognition in an immersive virtual reality environment: from local activity to brain network features[J]. Biomed Signal Process Control, 2022, 72(1): 103349.

[10] Pessoa L. A network model of the emotional brain[J]. Trends Cogn Sci, 2017, 21(5): 357-371.

[11] Vázquez-Marrufo M, Caballero-Díaz R, Martín-Clemente R, et al. Individual test-retest reliability of evoked and induced alpha activity in human EEG data[J]. PLoS One, 2020, 15(9): 0239612.

[12] Zheng W, Zhu J, Lu B. Identifying stable patterns over time for emotion recognition from EEG[J]. IEEE Trans Affect Comput, 2019, 10(3): 417-429.

[13] Liu H, Zhang J, Liu Q, et al. Minimum spanning tree based graph neural network for emotion classification using EEG[J]. Neural Netw, 2022, 145(1): 308-318.

[14] Duan R, Zhu J, Lu B. Differential entropy feature for EEG-based emotion classification[C]//Proceedings of The 2013 6th International IEEE/EMBS Conference on Neural Engineering (NER). 2013: 6-8.

[15] Lachaux JP, Rodriguez E, Martinerie J, et al. Measuring phase synchrony in brain signals[J]. Hum Brain Mapp, 1999, 8(4): 194-208.

[16] Bruña R, Maestú F, Pereda E. Phase locking value revisited: teaching new tricks to an old dog[J]. J Neural Eng, 2018, 15(5): 056011.

- [17] Aydore S, Pantazis D, Leahy RM. A note on the phase locking value and its properties[J]. Neuroimage, 2013, 74(1): 231-244.
- [18] Pop PC. The generalized minimum spanning tree problem: an overview of formulations, solution procedures and latest advances[J]. Eur J Oper Res, 2020, 283(1): 1-15.
- [19] Li H, Xia Q, Wang Y. Research and improvement of kruskal algorithm [J]. J Comput-Mediat Comm, 2017, 5(12): 63.
- [20] Zeng D, Huang K, Xu C, et al. Hierarchy graph convolution network and tree classification for epileptic detection on electroencephalography signals[J]. IEEE Trans Cogn Commun Netw, 2020, 13(4): 955-968.
- [21] Ismail LE, Karwowski W. A graph theory-based modeling of functional brain connectivity based on EEG: a systematic review in the context of neuroergonomics[J]. IEEE Access, 2020, 8(1): 155103-155135.
- [22] Kong YX, Shi GY, Wu RJ, et al. k-core: theories and applications[J]. Phys Rep, 2019, 832(1): 1-32.
- [23] Ismail L, Karwowski W. A graph theory-based modeling of functional brain connectivity based on EEG: a systematic review in the context of neuroergonomics[J]. IEEE Access, 2020(99): 1-3.
- [24] Artur M. Review the performance of the bernoulli naïve bayes classifier in intrusion detection systems using recursive feature elimination with cross-validated selection of the best number of features[J]. Procedia Comput Sci, 2021, 190(1): 564-570.
- [25] Robnik-Šikonja M, Kononenko I. Theoretical and empirical analysis of ReliefF and RReliefF[J]. Mach Learn, 2003, 53(1): 23-69.
- [26] Ashokkumar S, Anupallavi S, Mohanbabu G, et al. Emotion identification by dynamic entropy and ensemble learning from electroencephalogram signals[J]. Int J Imag Syst Tech, 2022, 32(1): 402-413.
- [27] Liu J, Sun L, Huang M, et al. Enhancing emotion recognition using region-specific electroencephalogram data and dynamic functional connectivity[J]. Front Neurosci, 2022, 1(1): 652.

(编辑:陈丽霞)