

融合PCC和MIC的多层动态脑网络抑郁症识别

刘芳, 乔晓艳*, 杨江江

(山西大学物理工程学院, 山西太原 030006)

摘要: 抑郁症准确识别和分级具有重要现实意义。针对抑郁症识别准确率较低、可解释性差的问题, 提出基于多层动态脑功能网络的抑郁症机器识别模型。该模型克服了传统的单一线性连接分析方法, 通过融合皮尔逊相关系数和最大信息系数, 采用脑电滑动时间窗口构建兼具线性与非线性动态连接特征的多层动态脑功能网络并提取网络特征, 提供了更全面的脑功能特征信息, 显著提高了抑郁症识别准确率。利用该模型对正常人以及轻度、中度、重度抑郁症患者进行识别, 平均识别准确率达到97.46%。通过可视化脑网络拓扑结构和节点度分析, 发现抑郁症大脑枕叶、前额叶、颞叶区域表现异常。分析脑网络特征可知, 大脑beta节律在抑郁症识别中起关键作用, 并且轻度抑郁症患者相比正常人的脑网络全局效率、平均最短路径长度和局部效率增加, 聚类系数减少。实验结果表明该模型可提高抑郁症识别准确率并可进行抑郁分级, 为抑郁症临床诊断、快速筛查提供新方法, 为探索抑郁症的神经生理机制提供新的借鉴。

关键词: 抑郁症识别; 多层动态脑网络; 脑电信号; 皮尔逊相关系数; 最大信息系数

中图分类号: TP391

文献标识码: A

doi: 10.62756/csjs.1671-7449.2025075

引用格式: 刘芳, 乔晓艳, 杨江江. 融合PCC和MIC的多层动态脑网络抑郁症识别[J]. 测试技术学报, 2025, 39(6): 726-736.

LIU Fang, QIAO Xiaoyan, YANG Jiangjiang. Depression recognition based on multi-layer dynamic brain functional network integrating PCC and MIC[J]. Journal of Test and Measurement Technology, 2025, 39(6): 726-736.

Depression Recognition Based on Multi-Layer Dynamic Brain Functional Network Integrating PCC and MIC

LIU Fang, QIAO Xiaoyan*, YANG Jiangjiang

(College of Physics and Electronic Engineering, Shanxi University, Taiyuan 030006, China)

Abstract: Accurate recognition and classification of depression have important practical significance. Targeting the challenges of low accuracy and poor interpretability in depression identification, a machine recognition model for depression based on a multi-layer dynamic brain function network is proposed. This model overcomes the traditional single linear connection analysis method. By integrating the Pearson correlation coefficient and the maximum information coefficient and using the EEG sliding time window, it constructs a multi-layer dynamic brain function network with both linear and nonlinear dynamic connection characteristics and extracts network features. This model provides more comprehensive brain function feature information and significantly improves the accuracy of depression identification. The model was used to identify normal people and patients with mild, moderate, and severe depression, with an average recognition accuracy of 97.46%. By visualizing the brain

收稿日期: 2024-11-22

基金项目: 山西省研究生教育创新计划项目(2024SJ021)

作者简介: 刘芳(2000-), 女, 硕士生, 主要从事智能信息处理研究。E-mail: lf15560091570@163.com。

*通信作者: 乔晓艳(1969-), 女, 教授, 博士, 主要从事机器学习和生物医学信息处理研究。E-mail: xyqiao@sxu.edu.cn。

network topology and analyzing the node degree, it is found that the occipital lobe, prefrontal lobe and temporal lobe of the brain in depression are abnormal. By analyzing the characteristics of the brain network, it can be seen that the brain beta rhythm plays a key role in the identification of depression, and the global efficiency, average shortest path length and local efficiency of the brain network of patients with mild depression are increased compared with normal people, and the clustering coefficient is reduced. The experimental results show that the model can improve the accuracy of depression identification, provide a new method for clinical diagnosis, depression classification and rapid screening, and provide a new reference for exploring the neurophysiological mechanism of depression.

Key words: depression recognition; multi-layer dynamic brain network; electroencephalogram signal; Pearson correlation coefficient; maximum information coefficient

0 引 言

抑郁症是一种普遍存在的精神心理疾病,表现为多种身体和心理症状,包括睡眠障碍、情绪低落、注意力难以集中等,甚至可能导致自杀,严重影响患者的生活质量^[1]。因此,探索科学有效的方法准确识别和诊断抑郁症具有重要意义。脑电信号(Electroencephalogram, EEG)是一种非侵入性的脑电生理活动记录方法,能够客观反映大脑的活动状态,具有高时间分辨率、操作相对安全且成本较低等优点。近年来,越来越多的学者将脑电信号与机器学习相结合,研究抑郁症的识别和诊断^[2]。在抑郁症识别领域,深度学习技术的应用取得了显著进展。Li等^[3]提出基于卷积神经网络(Convolutional Neural Network, CNN)的计算机辅助检测系统,该系统能够有效区分轻度抑郁症患者与健康人,准确率达到85.62%,这一成果为抑郁症的早期诊断提供了一种高效的技术支持。Zhou等^[4]采用混合CNN-长短期记忆(Long Short-Term Memory, LSTM)网络,通过Depression Rest数据集进行健康人和抑郁症患者的分类,实现了95.5%的平均分类准确率,进一步验证了深度学习在提高抑郁症识别准确率方面的潜力。尚照岩等^[5]创新性地将注意力机制引入CNN,提出基于特征融合与注意力机制的CNN抑郁症识别模型,利用兰州大学公开的轻度抑郁症数据集对正常人和轻度抑郁症患者分类,使用少电极脑电信号进行抑郁症识别,分类准确率可达(91.41±1.11)%。由以上研究可知,深度学习模型在区分抑郁症患者和正常人方面展现了卓越的能力。然而,临床上除了要求识别抑郁症之外,还需要对抑郁程度进行分级,即识别正常和轻度、中度、重度抑郁症。当前抑郁程度分级主要依照贝克抑郁量表

(Beck Depression Inventory-II, BDI-II)^[6],但BDI-II量表是主观和定性的,在生理基础方面具有局限性。由于分级抑郁程度的模型更加复杂,目前用于识别抑郁程度的深度学习模型仍然相对匮乏,且准确率低。此外,由于深度学习算法是端到端的黑箱模型,在特征和模型可解释性方面存在不足,缺乏抑郁症的生物标志特征,导致深度学习模型对不同个体的泛化能力有限,从而限制模型的广泛应用。

脑网络是大脑神经元或脑区之间相互连接而形成的复杂网络结构^[7],对于理解大脑如何处理信息、解释认知功能以及诊断脑疾病具有重要意义。目前的研究侧重于基于脑电信号构建静态连接的单层功能脑网络。Lee等^[8]使用3种不同静态功能脑网络连接方法对3种情绪状态进行分类,取得了79%的准确率,该方法忽略了脑电序列在时间维度的动态变化,故分类准确性较低。Wang等^[9]利用皮尔逊相关系数(Pearson Correlation Coefficient, PCC)构建动态脑功能网络,研究积极、中性和消极情绪的脑网络动态变化,结果表明基于动态脑网络的情感分析相比静态脑网络更准确。由于PCC通常被用于评估两个变量间线性关系,而大脑是一个高度复杂的非线性动态系统,单一的线性关系难以全面捕捉大脑内在的非线性特性,因此,构建脑功能网络需要充分考虑其非线性属性。蒋进航^[10]采用最大信息系数(Maximal Information Coefficient, MIC)相关性度量分析方法,捕捉变量间复杂的非线性关系,为我们提供了一种新的视角,即通过融合PCC和MIC构建一个能够捕捉大脑线性及非线性关联关系的多层脑网络,更全面认识和理解抑郁症的大脑神经机制。

本文提出了一种融合PCC和MIC的方法,将其命名为FPM(Fusion of Pearson and Maximum Information Coefficient),并利用该方法构建多层动态脑功能网络用于抑郁症识别。本文的主要创新包括:

1) 在传统的构建单一连接关系的脑功能网络基础上, 基于FPM的方法创新性地构建了既能获取大脑线性动态连接关系, 又能获取大脑非线性动态连接关系的多层脑功能网络, 探究了脑电信息的动态传递过程, 并且使用无重叠滑动时间窗口捕捉到抑郁脑电时间序列的细微变化。

2) 科学量化分析了脑电的滑动时间窗口、脑网络连接阈值等关键参数对抑郁症识别性能的影响, 结合脑网络特征分析获得了抑郁脑网络特异性生物标志, 提高了模型的可解释性。

3) 针对现有模型仅局限于识别抑郁和正常脑电, 本文采用了一种精细化方法对抑郁程度进行分级, 即对正常、轻度、中度、重度抑郁症脑电进行了更为细致的分类, 这种精细化的识别和分级可为抑郁症个性化治疗方案提供科学依据。

1 基于动态多层脑网络的抑郁识别模型

1.1 数据集及脑电数据预处理

本文采用由 Openneuro 提供并被 Cavanagh 等^[11]使用的开放数据集, 于2008—2010年在亚利桑那大学 John JB Allen 实验室完成采集。该数据集由122名大学生参与, 所有参与者提供亚利桑那大学批准的书面知情同意书, 参与者包括不同程度的抑郁症患者和无抑郁的正常人。其中, 79名被试BDI-II评分在0~13之间, 被归类于正常人, 14名被试评分在14~19之间, 被归类于轻度抑郁症, 24名被试得分在20~28之间, 被归类于中度抑郁症, 5名被试得分在29~63之间, 被归类于重度抑郁症。每个被试都连续记录了约500 s静息状态下的脑电信号, 脑电电极放置符合10~20标准, 采样频率为500 Hz。

本文选取在抑郁症研究的相关文献中被广泛采用的18个脑电电极, 包括FP1、FP2、F7、F3、FZ、F4、F8、T7、C3、C4、T8、P7、P3、PZ、P4、P8、O1、O2。利用EEGLAB软件完成对脑电信号的预处理, 将原始脑电信号进行0.5~70 Hz带通滤波消除基线漂移和低频噪声, 并进行50 Hz陷波处理滤除工频干扰, 通过独立成分分析去除眼电伪迹, 图1和图2为预处理前、后截取的1 s脑电信号。

不同频段的脑电节律信号往往与人的情绪状态以及抑郁症的病理状态有关, 为了分析脑电节律对抑郁的影响, 使用巴特沃斯滤波器进行脑电节律的提取, 获取delta (0.5~4 Hz)、theta (4~

8 Hz)、alpha (8~13 Hz)、beta (13~30 Hz)、low_gamma (30~51 Hz)、high_gamma (51~70 Hz) 6个不同的脑电节律。




图1 预处理前脑电信号

Fig. 1 EEG signal before preprocessing




图2 预处理后的脑电信号

Fig. 2 Preprocessed EEG signal

1.2 脑网络模型设计

模型的整体架构如图3所示, 包含三部分: 动态脑网络构建、脑网络特征获取以及分类器设计。

首先, 通过确定滑动时间窗口获取连续的动态脑电片段。然后, 以PCC和MIC作为度量工具, 构建能够捕捉脑网络中线性及非线性连接关系的多层动态脑网络, 并提取网络特征。最后, 将融合后的特征送入机器学习分类器中, 实现正常人与轻度抑郁症的二分类任务, 以及正常人、轻度、中度、重度抑郁症的四分类任务, 从而实现抑郁症的识别以及抑郁程度的分级。

1.2.1 滑动窗口的选择

人脑是一个随时间动态变化的复杂网络, 仅通过静态分析会忽略脑网络的动态特性。本文采用非重叠滑动时间窗口方法, 将每个被试时间长度为500 s的脑电序列按照窗口长度为20 s进行无重叠滑动, 获取动态的脑电片段。通过计算每个被试脑电片段中18个脑电导联之间的PCC和MIC, 分别获得18*18的PCC和MIC矩阵, 矩阵随时间动态变化, 反映了各导联脑电之间功能连接的动态特性。

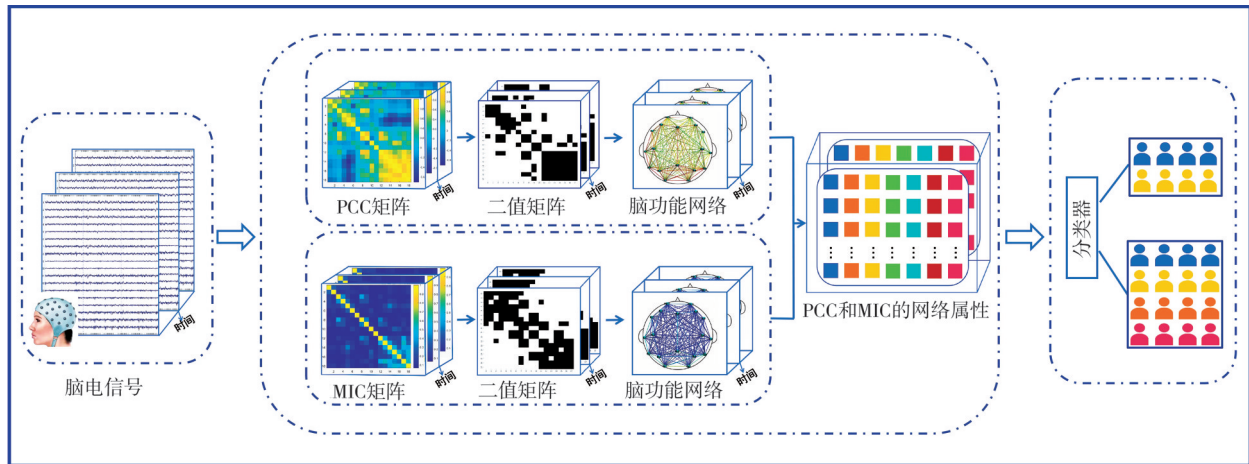


图 3 多层动态脑网络模型整体框架

Fig. 3 Overall framework of multi-layer dynamic brain network model

图 4 为静态脑网络与动态脑网络的 MIC 相关性矩阵。

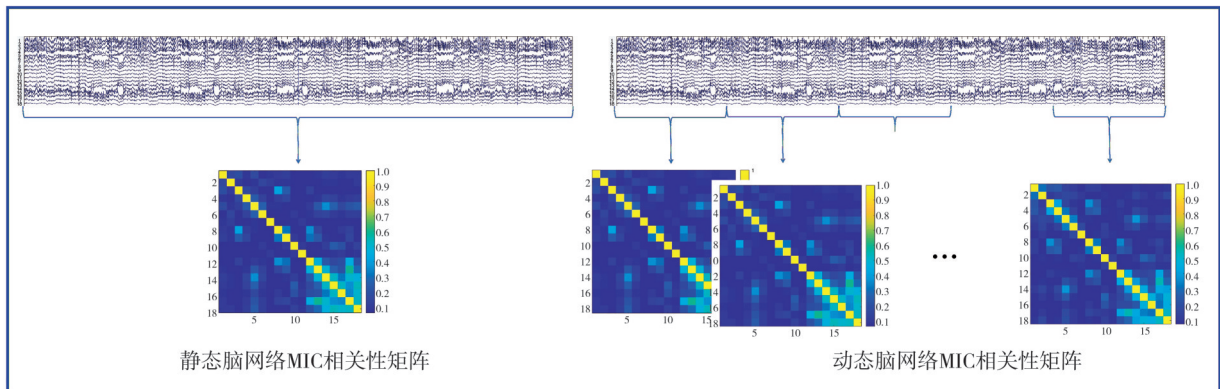


图 4 静态和动态脑网络 MIC 相关性矩阵

Fig. 4 MIC correlation matrix of static and dynamic brain networks




图 5 时间窗口的选择

Fig. 5 Time window selection

过短的时间窗口无法充分捕捉大脑的病理信息,而过长的时间窗口会导致对快速变化的网络动态不敏感,降低识别的准确性,所以,适当的时间窗口选取对于捕捉大脑连接关系的复杂动态变化至关重要。本文通过对比不同时间窗口的脑网

络分类效果来选择合适的窗口长度。图 5 为选取 6 个不同时间窗口,脑网络模型分类准确率。

由图 5 可知,时间窗口选取较小时,抑郁症识别准确率较低;时间窗口为 20 s 时,分类准确率达到峰值,之后增大时间窗口,分类准确率下降,表明脑电时间窗口大小对动态脑网络构建和抑郁症识别有重要影响。因此,选用 20 s 作为脑电滑动时间窗口长度构建动态脑网络。

1. 2. 2 基于 PCC 和 MIC 的多层脑网络

将被试的脑电电极(导联)视为脑网络图中的一个节点,在滑动窗口处理后的脑电信号切片上分别计算各个节点之间的 PCC 和 MIC,得到 18*18 的 PCC 矩阵和 MIC 矩阵。PCC^[12]可度量两个变量之间线性相关性强弱和方向,取值范围在 -1~1 之间,其中取值为 1 表明呈现出最强的正线性相关性,取值为 -1 意味着存在最强的负线性相关,可通过式(1)计算。

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}, \quad (1)$$

式中： X, Y 为两个离散的时间序列； n 为采样点个数。鉴于PCC计算过程简单，并且不受脑电信号绝对幅值的影响，因此，选用该系数评估不同脑电导联间的线性相关性。

相比于PCC描述线性相关，MIC^[13]能检测出更为复杂的非线性关系，用于衡量脑电信号导联之间的同步性。MIC的取值范围限定在0~1之间，其中0表明两个变量之间不存在任何同步活动，1则反映出两变量之间具有最强的同步性。

给定随机变量 X 和 Y 的样本集合 D ，它由有序对 (x_i, y_i) 组成，其中 i 为1~ N 。在二维平面上，沿 x 轴分割成 a 个区间，沿 y 轴分割成 b 个区间，形成 $a \times b$ 个网格构成的网络 G 。集合 D 在网格 G 上的概率分布用来估计 X 和 Y 在这种划分下的互信息，对于不同的网格划分，可以得到不同的互信息估计值。记 $I^*(D, a, b) = \max_G I(D|_G, a, b)$ 为所有可能划分下互信息的最大估计值，可通过式(2)计算。

$$MIC(X, Y) = \max_{a \times b < B(N)} \frac{I^*(D, a, b)}{\log_2 \min(a, b)}, \quad (2)$$

式中： $a \times b$ 为网格总的单元数，需要满足 $a \times b < B(N)$ ，一般取 $B(N) = N^{0.6}$ ， N 为样本数。MIC适用于各种类型的数据，可以捕捉数据复杂的非线性关系。此外，MIC对异常值和噪声具有较好的鲁棒性，即使在数据质量不佳的情况下也能提供有效的相关性度量。

1.2.3 阈值化

阈值化用于判定脑网络各节点之间是否存在功能性的连接关系，当大脑两个电极节点脑电的PCC或MIC相关性强度超过设定阈值时，判定两个节点之间存在有效链接，元素保留为1；当相关强度低于设定的阈值时，表明两个节点之间不存在有效链接，将元素设为0。在构建脑功能网络的过程中，合理设定阈值对于维持脑网络的完整性以及小世界特性极为关键，可以更准确地反映脑区间的功能连接。阈值设置过高，会遗漏实际存在的连接，导致网络过于稀疏；阈值过低，则会引入过多的噪声，干扰对网络结构和功能的分析。本文采用以0.1为间隔逐点遍历0~1的值，分析不同阈值的分类准确率，确定最佳的脑网络连接阈值，确保脑网络分析的精确性和可靠性。

由图6可知，在阈值为0.7时，PCC矩阵阈值化后构建的脑网络抑郁症识别准确率最高；同样，在阈值为0.3时，由MIC矩阵阈值化后构建的脑网络抑郁识别准确率最高。因此，分别选用0.7和0.3作为对PCC矩阵和MIC矩阵进行二值化处理的阈值。




图6 阈值选择

Fig. 6 Threshold selection

1.3 脑网络特征

在基于二值化矩阵构建的脑功能网络中，节点代表脑电导联，边代表导联之间的显著连接。为了全面分析脑网络，提取脑网络连接结构的全局属性作为特征，主要包括全局效率、局部效率、聚类系数、平均最短路径长度、传递性以及平均度，这些特征共同映射了网络的整体信息处理效能和结构的紧凑性。此外，提取了各区域的局部属性节点度，通过计算一个节点直接连接其他节点的数量，评估网络的复杂程度。分析脑网络的全局和局部特征可以更全面地理解脑网络的结构和功能。

全局效率^[14]反映了整个网络并行处理信息的能力，对于具有 N 个节点的给定图 G ，按照式(3)计算。

$$E_{\text{global}}(G) = \frac{1}{N(N-1)} \sum_{i \neq j \in G} \frac{1}{h_{ij}}, \quad (3)$$

式中： h_{ij} 指节点 i 与节点 j 的距离。

局部效率^[15]是每个节点及其邻居构成的子图的全局效率的平均值，用于衡量网络中某个节点的邻居节点间信息传输效率，计算如式(4)所示。

$$E_{\text{local}} = \frac{1}{N} \sum_{i \in G} E_{\text{global}}(G_i), \quad (4)$$

式中： $E_{\text{global}}(G_i)$ 为 G_i 的全局效率； N 为网络的节点数。局部效率可以揭示网络在面对局部故障时的鲁棒性。

聚类系数^[16]用于衡量网络节点聚集的情况。通过汇总网络内各节点聚类系数的平均值，便可

得出网络的整体聚类系数, 计算如式(5)所示。

$$C = \frac{1}{N} \sum_{i=1}^N C_i = \frac{1}{N} \sum_{i=1}^N \frac{2E_i}{k_i(k_i - 1)}, \quad (5)$$

式中: N 为网络的节点总数; k_i 为节点 i 的连接数量; E_i 为节点 i 的边数。聚类系数不仅提供了一个量化大脑网络中局部连接紧密程度的方法, 而且在神经系统疾病的研究中具有重要价值。

最短路径长度^[17]是网络所有节点对的距离总和, 平均最短路径长度计算如式(6)所示。

$$ASPL = \frac{1}{N} \sum_{i=1}^N \frac{\sum_{j \in G, j \neq i} h_{ij}}{N-1}. \quad (6)$$

平均最短路径长度较短的脑网络通常具有较高的全局效率, 信息在网络中的传播速度更快。

传递性^[18]是指一个网络中闭合三角形的比例, 计算如式(7)所示。

$$T = \frac{3 \cdot a}{b}, \quad (7)$$

式中: a 为 3 个节点都有边连接的三元组的数量; b 为每 3 个节点组合可以构成三元组的数量。传递性反映了脑网络中局部聚集趋势的广泛性。

1.4 模型的实现与评价

为了识别抑郁程度和分级, 需构建多层动态脑网络并提取网络特征, 然后利用随机森林机器学习方法, 对正常人与轻度、中度、重度抑郁症患者进行四分类识别。将对应被试脑电片段按照 1.2 节方法构建基于 PCC 和 MIC 的脑功能网络, 提取脑网络的全局和局部特征。将基于 PCC 构建的脑功能网络和基于 MIC 构建的脑功能网络提取的特征在数据层面进行融合, 提取到的数据特征直接按列进行拼接, 旨在充分利用线性与非线性特征信息, 得到融合后的特征作为分类模型的输入。分类器的输入特征矩阵为 500*48, 其中, 500 为样本数量, 48 为特征维数。利用 5 折交叉验证来评估模型在不同数据子集上的性能, 在交叉验证过程中, 随机选取用于训练模型的数据子集为 400*48, 用于验证模型的数据子集为 100*48。

在随机森林的训练过程中, 每棵树都是基于原始数据集的一个随机子样本进行训练的, 这个子样本是通过有放回抽样得到的。这表明在每棵树的构建构成中, 大约 36% 的样本没有被选用, 这些未被选中的样本被称为袋外样本。袋外误差就是利用这些袋外样本来评估模型的性能, 如

图 7 所示。通过观察袋外误差随决策树数目的变化, 可以选择最优模型参数。

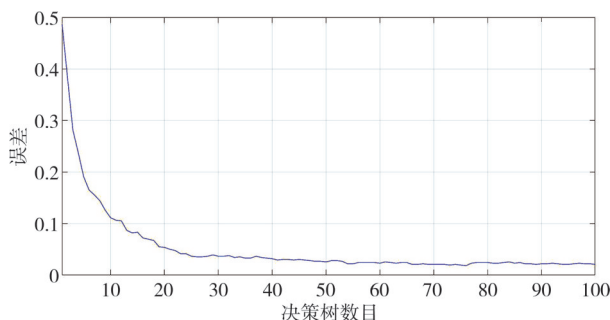


图 7 模型训练误差曲线

Fig. 7 Model training deviation curve

混淆矩阵展示了模型预测结果与实际标签之间的关系, 提供了一个直观的方式来评估模型在不同类别上的表现。准确率是模型预测正确的样本数占总样本数的比例, 反映了模型整体的分类性能, 可以由图 8 的混淆矩阵按照式(8)计算得到。

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}, \quad (8)$$

式中: TP 为被正确地预测为正类的样本数量; FP 为被错误地预测为正类的负类样本数量; FN 为被错误地预测为负类的正类样本数量; TN 为正确预测为负类的负类样本数量。

0	23	1		
1		30	1	
2			24	
3				21
	0	1	2	3

图 8 模型测试的混淆矩阵

Fig. 8 Confusion matrix for model testing

2 结果分析

2.1 脑网络可视化

图 9 和图 10 分别为正常、轻度、中度以及重度抑郁症的脑电 PCC 矩阵和 MIC 矩阵对比, 以及构建的脑网络可视化图。

由图 9 可知, 同一被试的脑电信号在经过 PCC 线性相关性计算和 MIC 非线性相关性计算后得到的相关矩阵具有明显差异, 表明除了线性相互作用外, 脑区之间还存在复杂的非线性作用。

此外,不同级别的抑郁症脑电, PCC 以及 MIC 矩阵也具有差异,且 FP1、FP2、F7、F8、F3、FZ、F4 电极之间的线性和非线性相关都明显增强。图 10 显示了不同抑郁程度脑网络各节点之间的连接,其脑网络结构存在较大差异。无论是采用 PCC 方法构建的脑网络还是采用 MIC 方法构建的脑网络,随着抑郁程度的增强,脑网络各节点之间连接强度及相关性呈现加强的趋势,尤其是在前额区和颞叶。由于前额叶、颞叶是大脑中与高级认知以及情绪密切相关的脑区域,在抑郁状态下,相比于正常人这些区域的脑电信号连接增强,有助于理解抑郁症的神经机制。

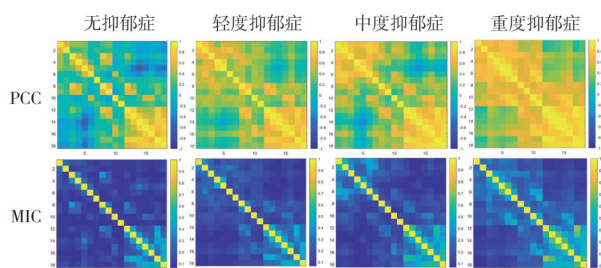


图 9 不同抑郁程度的 PCC 和 MIC 矩阵

Fig. 9 PCC and MIC matrix of different depression levels

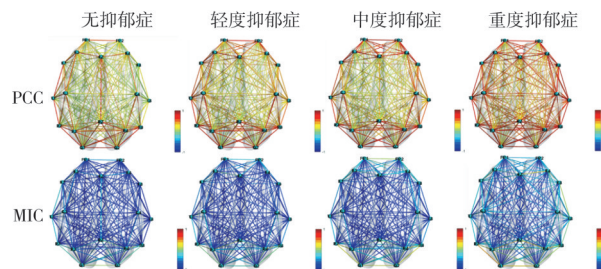


图 10 PCC 和 MIC 方法构建的不同程度抑郁症的脑网络对比

Fig. 10 Comparison of brain networks of different degrees of depression constructed by PCC and MIC methods

2.2 不同脑电节律的对比分析

图 11 为脑电不同节律对抑郁症识别结果影响的柱状图。其中,蓝色柱条表示对抑郁症二分类识别的准确率,红色柱条表示对抑郁症四分类分级的准确率。

由图 11 可知, beta、gamma 节律相比其他节律,在正常人与轻度抑郁症的二分类识别中准确率相对较高,可见这些节律被认为与轻度抑郁症的识别有较强的相关性。由于每个节律都与特定的大脑状态有关, low_gamma、high_gamma 和 beta 节律通常与认知功能和焦虑情绪有关。在正常、轻度、中度、重度抑郁症的四分类识别中, beta 节律仍然显示出最高的准确率,这表明 beta 节律在抑郁症识别中具有

重要价值。此外, delta、alpha 节律抑郁的识别准确率显著提高,而 gamma 节律的准确率明显下降,表明随着抑郁程度的加深,抑郁症患者的大脑活动节律变得缓慢,认知能力下降。

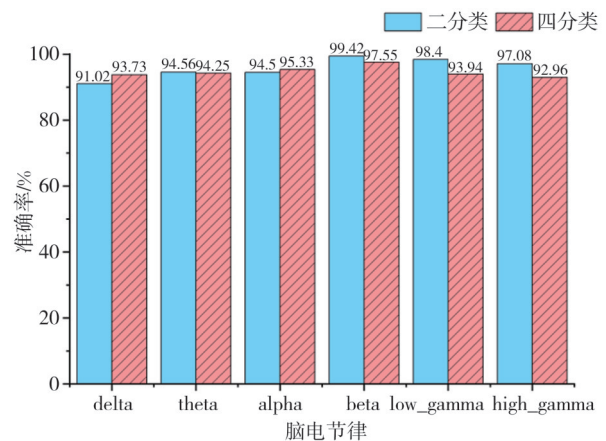


图 11 不同脑电节律对抑郁症识别的对比分析

Fig. 11 Comparative analysis of different EEG rhythms in identifying depression

2.3 脑网络特征对比分析

本文提取的脑网络特征主要包含全局效率、局部效率、聚类系数、平均最短路径长度、传递性、平均度和节点度。Spearman 相关^[19]用于衡量两组参数单调一致性的强度,即在增减趋势上的同步性程度。实验利用 Spearman 相关分析正常组与轻度抑郁组网络特征存在的差异,并通过统计检验确定 Spearman 相关系数的显著性 ($p < 0.05$, 在统计学上可以认为两个变量存在显著相关)。利用正常组与轻度抑郁组的不同节律脑电,分别构建基于 PCC 和 MIC 的动态脑网络并提取网络特征,包括全局效率、平均最短路径长度、聚类系数和局部效率,计算每个网络特征与标签之间的 Spearman 相关系数,并对 Spearman 相关系数进行统计检验确定其显著性。图 12 和图 13 所示的脑网络特征的显著性 p 值均小于 0.01,可以认为该特征与标签之间存在显著相关性,而未表示出来的特征在统计学上不存在显著相关性。

由图 12 和图 13 可知,与轻度抑郁症识别有较强相关性的 beta、low_gamma 和 high_gamma 节律中,轻度抑郁症的全局效率、平均最短路径长度和局部效率的值普遍高于正常对照组。然而,聚类系数低于正常对照组,这些网络特性的变化不仅是抑郁症病理生理机制的一部分,而且揭示了大脑连接模式的异常。这些发现不仅可丰富对

抑郁症神经生理方面的理解,而且为识别抑郁症的潜在生物标志特征提供了新依据和新视角。

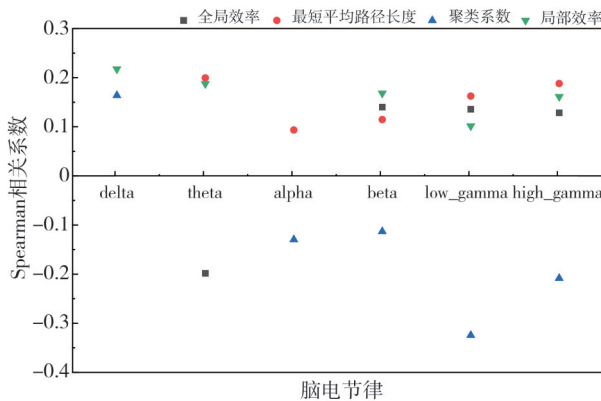


图 12 PCC 脑网络特征分析

Fig. 12 Analysis of PCC brain network characteristics

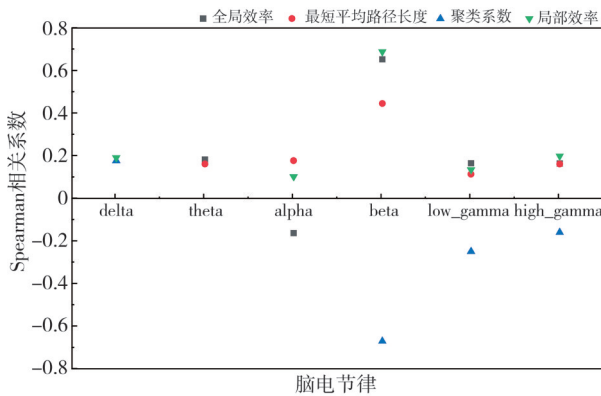


图 13 MIC 脑网络特征分析

Fig. 13 Analysis of MIC brain network characteristics

节点度是衡量网络中各节点连接程度的指标,利用构建的脑功能网络的节点度,分析脑网络各个节点的重要性。SHAP(Shapley Additive exPlanations)用于计算每个特征对模型预测结果的贡献,特征贡献增加则 SHAP 值也会增加。本文利用 SHAP 值分析节点度对模型预测的贡献大小,以此来确定节点的重要性。图 14 和图 15 分别为 PCC 和 MIC 脑网络节点重要性的排序图。




图 14 PCC 脑网络节点重要性比较

Fig. 14 Comparison of importance of PCC brain network nodes




图 15 MIC 脑网络节点重要性比较

Fig. 15 Comparison of the importance of MIC brain network nodes

在图 14 和图 15 中, O2、FP2、F3、PZ 节点均被识别为重要节点,体现了节点的稳健性,这表明节点所在的脑区即前额区和枕叶,可能在抑郁症的病理性机制中扮演着核心角色,这些脑区通常与认知控制和情绪调节有关,暗示了抑郁症患者认知和情绪处理的变化。然而,由 MIC 构建的脑网络节点重要性排序不同于 PCC,反映了脑网络中存在显著的非线性连接关系,这些在 PCC 分析中可能被忽略,表明了仅使用单一方法构建脑网络的局限性。基于 FPM 的多层动态脑网络特征进行抑郁症识别更能全面地捕捉脑网络的复杂性,这对于抑郁症识别及分析具有重要的影响。

2.4 脑网络分类性能的多维度分析

随机森林(Random Forest, RF)是一种通过构建多个决策树并将预测结果融合的集成学习算法,可提高分类模型的准确性和鲁棒性,通过设置不同的参数,可以调整随机森林模型的表现。经过仿真实验测试,决策树的数量设置为 100,最小叶子节点数设置为 2,使得模型既能准确预测,又不会过拟合。此外,采用支持向量机(Support Vector Machines, SVM), LSTM, CNN 对基于 FPM 构建的多层脑网络进行抑郁症识别对比试验,结果如图 16 所示。

为了评估模型性能,采用 5 折交叉验证方法,即将数据集分成 5 个部分,轮流使用其中 4 部分进行训练,剩余 1 部分用于测试,以此减少过拟合的风险并提高识别模型的泛化能力。本文中,二分类模型主要用于区分个体是否患有抑郁症,这对于初步筛查和诊断至关重要。四分类模型根据抑郁等级的不同进行分类,可以提供更细致的诊断信息。由图 16 可知,对于 PCC、MIC、FPM 构建的脑网络,RF 集成学习分类器相比其他方法抑郁症识别的准确率最高。基于 FPM 构建的多层动态

脑功能网络相比PCC和MIC脑功能网络,无论在二分类还是四分类中都取得最高的平均分类准确率,表明FPM多层脑网络更有利于机器识别抑郁症。此外,MIC方法构建的脑网络相比PCC构建的脑网络,其分类准确率更佳,表明脑网络的非线性连接关系所蕴含的特征信息更重要,对抑郁症识别更有效。

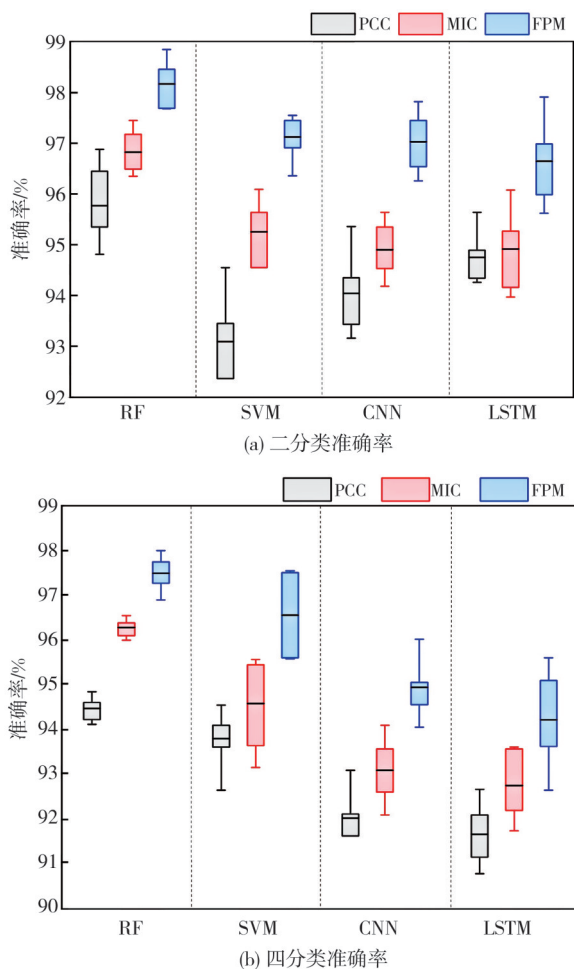


图 16 多层脑网络分类准确率

Fig. 16 Multi-layer brain network classification accuracy

2.5 不同方法对比分析

为了客观评估本文提出的多层动态脑网络模型对抑郁症机器识别的有效性,将本文3种脑网络构建方法与其他方法进行对比,结果如表1所示。

Kumari等^[20]提出了一种基于脑电信号的CNN检测抑郁症的方法,利用重度抑郁症患者和健康对照组的脑电数据进行训练和验证,获得的分类准确率为91.3%。

该模型在二分类识别中表现出色,但是模型在可解释性方面存在局限。王怡忻等^[21]提出脑网

络拓扑结构与CSP融合的脑电特征提取,并结合深度时序卷积网络模型对抑郁组和对照组进行分类,识别准确率达到89.67%。Sun等^[22]基于虚部相干性(Imaginary part of Coherence, ICoh)分别构建静态和动态脑网络,利用静态和动态脑网络的组合特征对正常和重度抑郁症患者进行二分类,识别最高准确率为79.2%。文献[21]和[22]的模型提供了一种新颖的脑电分析方法和脑功能连接模式,但是分类准确率较低,在临床诊断中更高的准确率意味着更少的误诊和漏诊。由表1可知,基于FPM构建的多层动态脑功能网络无论是在正常与轻度抑郁的二分类中,还是正常、轻度、中度、重度抑郁的多分类中都有较好的识别效果。PCC关注线性相关性而MIC关注非线性关系,两者都取得了较好的分类结果,表明脑功能的复杂性,不同类型的信息对理解脑活动都至关重要。MIC的分类效果相较于PCC更好,表明脑电的非线性特性对分类任务更有效。融合PCC和MIC构建的FPM多层脑网络,既包含了脑电的线性又包含了非线性关系,相比于单一的PCC或MIC取得了更好的分类效果,从而为抑郁症的识别和诊断提供了更有效的生物标志特征。

表 1 不同方法抑郁症识别准确率对比

Tab. 1 Comparison of depression recognition accuracy of different methods

来源	方法	分类	准确率/%
文献[20]	CNN	正常和重度	91.30
文献[21]	CSP+PLV	高风险抑郁和低风险抑郁	89.67
文献[22]	ICoh	正常和重度	79.25
本文	PCC	正常和轻度	95.79
本文	PCC	正常、轻度、中度、重度	94.52
本文	MIC	正常和轻度	96.72
本文	MIC	正常、轻度、中度、重度	96.36
本文	FPM	正常和轻度	98.15
本文	FPM	正常、轻度、中度、重度	97.46

3 结 论

本文提出融合PCC和MIC构建多层动态脑功能网络的方法,将复杂的脑电信号转化为易于可视化的脑网络拓扑结构连接,以获取抑郁症的脑网络属性,提取生物标志特征。该模型在抑郁症识别中不仅实现了高准确率,而且具有较好的可解释性。研究结果表明,beta节律在抑郁症识别中表现最佳。进一步分析不同节律的脑网络特征可知,轻度抑郁

症患者的全局效率、局部效率和平均最短路径长度都高于正常人,而聚类系数低于正常人。此外,节点度分析结合脑网络图示,揭示了枕叶、前额叶和颞叶在抑郁症病理机制中扮演着关键角色。最后,在比较 RF 与 SVM、CNN 和 LSTM 的分类性能时,RF 在分类准确率上表现最佳,证实了 RF 作为一种基于决策树的集成学习方法,在鲁棒性和泛化能力方面的优势。RF 分类器结合多层动态脑网络模型相比于单一的 PCC 脑网络,在对正常和轻度、中度、重度抑郁症患者分类时,准确率增加了 2.94 个百分点。

参考文献:

- [1] KENNEDY S H, CENITI A K. Unpacking major depressive disorder: from classification to treatment selection [J]. *Canadian Journal of Psychiatry Revue Canadienne de Psychiatrie*, 2018, 63(5): 308-313.
- [2] 尚照岩, 乔晓艳. 轻度抑郁症脑电特征分析与机器识别研究[J]. *测试技术学报*, 2022, 36(6): 498-505. SHANG Zhaoyan, QIAO Xiaoyan. Study on analysis and recognition of EEG characteristics of mild depression [J]. *Journal of Test and Measurement Technology*, 2022, 36(6): 498-505. (in Chinese)
- [3] LI X, LA R, WANG Y, et al. EEG-based mild depression recognition using convolutional neural network [J]. *Medical & Biological Engineering & Computing*, 2019, 57(6): 1341-1352.
- [4] ZHOU X, WANG X, LIU W, et al. Classification model of depression based on the CNN-LSTM network [C]//2023 3rd International Conference on Frontiers of Electronics, Information and Computation Technologies (ICFEICT), 2023: 210-214.
- [5] 尚照岩, 乔晓艳. 基于特征融合与注意力机制的 CNN 抑郁症识别[J]. *传感技术学报*, 2024, 37(4): 658-664. SHANG Zhaoyan, QIAO Xiaoyan. Depression recognition with CNN based on feature fusion and attention mechanism [J]. *Chinese Journal of Sensors and Actuators*, 2024, 37(4): 658-664. (in Chinese)
- [6] ALMEIDA S, CAMACHO M, BARAHONA-CORRÊA J B, et al. Criterion and construct validity of the Beck Depression Inventory (BDI-II) to measure depression in patients with cancer: The contribution of somatic items [J]. *International Journal of Clinical and Health Psychology*, 2023, 23(2): 100350.
- [7] HRAMOV A E, FROLOV N S, MAKSIMENKO V A, et al. Functional networks of the brain: from connectivity restoration to dynamic integration [J]. *Physics-Uspekhi*, 2021, 64(6): 584-616.
- [8] LEE Y Y, HSIEH S. Classifying different emotional states by means of EEG-based functional connectivity patterns [J]. *PLoS One*, 2014, 9(4): e95415.
- [9] WANG Z, TONG Y, HENG X. Emotional analysis based on dynamic functional brain network [C]//2019 International Conference on Networking and Network Applications (NaNA), 2019: 202-207.
- [10] 蒋杭进. 最大信息系数及其在脑网络分析中的应用 [D]. 武汉: 中国科学院研究生院(武汉物理与数学研究所), 2013.
- [11] EEG: Probabilistic Selection and Depression [EB/OL]. <https://openneuro.org/datasets/ds003474>.
- [12] WANG C, CHEN J, ZENG R. An analysis and forecasts of online product sales based on BP Neural Network and Pearson Coefficient [C]//2020 IEEE International Conference on Artificial Intelligence and Computer Applications (ICAICA), 2020: 559-564.
- [13] 任佳, 孙思宇, 鲍克. 基于最大信息系数和深度残差图卷积的工业过程故障诊断方法 [J]. *高校化学工程学报*, 2023, 37(1): 111-119. REN Jia, SUN Siyu, BAO Ke. Fault diagnosis method in industrial processes based on maximal information coefficient and depth residual graph convolution [J]. *Journal of Chemical Engineering of Chinese Universities*, 2023, 37(1): 111-119. (in Chinese)
- [14] EK B, VERSCHNEIDER C, NARAYAN D A. Global efficiency of graphs [J]. *AKCE International Journal of Graphs and Combinatorics*, 2015, 12(1): 1-13.
- [15] WANG J, ZUO X, HE Y. Graph-based network analysis of resting-state functional MRI [J]. *Frontiers in Systems Neuroscience*, 2010, 4: 16.
- [16] GALLEN C L, D'ESPOSITO M. Brain modularity: a biomarker of intervention-related plasticity [J]. *Trends in Cognitive Sciences*, 2019, 23(4): 293-304.
- [17] WANG B, MENG L. Functional brain network alterations in epilepsy: a magnetoencephalography study [J]. *Epilepsy Research*, 2016, 126: 62-69.
- [18] RUBINOV M, SPORNS O. Complex network measures of brain connectivity: Uses and interpretations [J]. *NeuroImage*, 2010, 52(3): 1059-1069.
- [19] XIA J, SHEN Q. Correlation analysis of different vegetable categories based on Spearman rank correlation coefficient [C]//2024 IEEE 6th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 2024: 548-551.
- [20] KUMARI K, DEWANGAN K K, SAHU R. Convo-

- lutional neural network based approach for depression detection through EEG signals[C]//2023 International Conference on Artificial Intelligence for Innovations in Healthcare Industries (ICAIHI), 2023: 1-7.
- [21] 王怡忻, 朱湘茹, 杨利军. 融合共空间模式与脑网络特征的 EEG 抑郁识别[J]. 计算机工程与应用, 2022, 58(22): 150-158.
WANG Yixin, ZHU Xiangru, YANG Lijun. EEG depression recognition based on feature fusion of common spatial pattern and brain connectivity [J]. Computer Engineering and Applications, 2022, 58(22): 150-158. (in Chinese)
- [22] SUN S, YAN C, LYU J, et al. EEG based depression recognition by employing static and dynamic network metrics [C]//2022 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), 2022: 1740-1744.

声 明

本刊已许可中国知网、万方数据知识服务平台、超星网等多家单位以数字化方式复制、汇编、发行、信息网络传播本刊全文。本刊支付的稿酬已包含上述各家网络著作权使用费，所有署名作者向本刊提交文章发表之行为视为同意上述声明。如有异议，请在投稿时说明，本刊将按作者说明处理。
