

## • 综 述 •

## 机器学习结合脑电在抑郁症识别中的应用进展

黄志强<sup>1</sup>, 钟士江<sup>2△</sup>, 王兴平<sup>1</sup>

(1. 武警海西支队卫生队, 青海 海西 816000; 2. 天津康汇医院神经内科, 天津 300162)

**[摘要]** 抑郁症是一种常见的负面情绪障碍, 严重影响人们的生活质量。然而, 由于其潜在的神经机制和病理原理尚不明晰, 使抑郁症的临床诊断变得十分困难。目前, 对抑郁症的诊断依赖临床访谈和量表筛查, 误诊、漏诊率较高, 缺乏客观、可靠的诊断方法。随着人工智能的蓬勃发展, 机器学习结合脑电在一定程度上能提升抑郁症诊断的准确性和客观性, 使自动化抑郁检测成为可能。该文简要介绍了基于脑电信号的抑郁症识别过程, 概括分析了抑郁症的脑电特征和机器学习算法识别现状, 并指出当前研究的不足和展望, 以期为国内开展抑郁症自动化识别研究提供一定的参考依据和思路。

**[关键词]** 抑郁症; 脑电技术; 机器学习; 综述

**DOI:** 10.3969/j.issn.1009-5519.2026.03.035

**中图法分类号:** R749.4

**文章编号:** 1009-5519(2026)03-0667-06

**文献标识码:** A

**Progress in the application of machine learning combined with electroencephalography  
in depression recognition**

HUANG Zhiqiang<sup>1</sup>, ZHONG Shijiang<sup>2△</sup>, WANG Xingping<sup>1</sup>

(1. HaiXi Detachment, Qinghai Corps of Armed Police, Haixi, Qinghai 816000, China;

2. Department of Neurology, Tianjin Kanghui Hospital, Tianjin 300162, China)

**[Abstract]** Depression is a common emotional disorder that significantly affects people's quality of life. However, due to the unclear underlying neural mechanisms and pathological principles of depression, its clinical diagnosis becomes extremely difficult. Currently, the diagnosis of depression relies on clinical interviews and scale screening, with a high rate of misdiagnosis and missed diagnosis, and lack of objective and reliable diagnostic methods. With the vigorous development of artificial intelligence, machine learning combined with electroencephalography can to some extent improve the accuracy and objectivity of depression diagnosis, making automated depression detection possible. This article briefly introduces the process of depression recognition based on electroencephalogram signals, summarizes and analyzes the electroencephalogram characteristics of depression and the current status of machine learning algorithm recognition, and points out the current research deficiencies and prospects, with a view to providing some reference and ideas for the research of automatic depression recognition in China.

**[Key words]** Depression; Electroencephalography; Machine learning; Review

抑郁症也称为抑郁障碍, 是常见的精神障碍之一, 其明显的特征为情绪低落<sup>[1]</sup>。相关数据显示, 全球共有超过 3.5 亿人遭受抑郁症的影响<sup>[2]</sup>。根据世界卫生组织的数据, 每年有超过 80 万例抑郁症患者死于自杀<sup>[3]</sup>。显而易见, 早期识别抑郁症是防止不良后果的关键环节。目前, 对抑郁症的诊断依赖于临床医生的问诊和量表筛查<sup>[4]</sup>, 具有很强的主观性。由于缺乏客观、可靠的生物标志物, 并且其潜在的神经机制尚不明晰, 因而对抑郁症的临床诊断变得十分困难<sup>[5]</sup>。建立客观、高效的抑郁症识别方法对临床医生辅助诊断抑郁症具有重要的现实意义和实践价值。

有研究表明, 抑郁症者与健康被试者在语音、面

部表情、脑电、眼动、磁共振成像等模态数据方面表现出明显差异<sup>[6]</sup>。其中脑电图具有获取方便、灵敏度高、成本低、时间分辨率高、无创等优点<sup>[7]</sup>, 采用脑电技术识别抑郁症成为近年来研究的热点话题。由于脑电数据包含多种特征, 直接对脑电特征进行提取分析变得非常复杂。随着人工智能的蓬勃发展, 以机器学习为核心的人工智能技术结合脑电识别诊断抑郁症具有广阔的应用前景<sup>[8]</sup>。现对脑电技术结合机器学习算法识别和分类抑郁症的研究现状进行综述, 以期为国内研究提供一定的参考依据与借鉴。

### 1 基于脑电信号的抑郁症识别过程

基于脑电信号的抑郁症识别分类过程一般分为

△ 通信作者, E-mail: zhongshijiang1@163.com。

数据采集、数据预处理、特征提取、特征选择、机器学习分类和性能评估<sup>[9]</sup>。头皮放置电极是脑电信号采集最常见的方法。电极主要分为干、湿性电极。干性电极具有采集方便的优点,但存在信号质量偏低的不足。湿性电极采集的信号质量较高,但也存在采集过程颇为复杂、采集时间长等缺陷。脑电实验可分为静息态脑电和任务态脑电(也称为事件相关电位)实验,静息态实验无须被试者参与任何任务,而事件相关电位需采集认知实验任务中的脑电数据。由于收集的脑电信号十分微弱,通常为  $\mu\text{V}$  级,并且极易受外界环境的干扰<sup>[10]</sup>,因此,需对原始脑电信号进行预处理,提取有价值的脑电信号。在预处理后提取和选择脑电特征,选择合适的机器学习算法进行分类,采用准确率、灵敏度、特异度、F1 分数、受试者工作特征曲线下面积等指标评估机器学习算法的分类效果<sup>[11]</sup>。

## 2 抑郁症识别分类研究中常用的脑电特征

特征提取是脑电数据分析的关键步骤,抑郁症识别分类的脑电特征一般包含时域、频域、时频、非线性动力学、功能连接、脑网络特征等。

### 2.1 时域特征

主要包含脑电时间序列信号[具体为标准差、能量、方差、偏度、峰度、Hjorth 参数(活动性、移动性和复杂性)等]的统计结果。KHAN 等<sup>[12]</sup>提取的 12 个时域特征包含最大和最小振幅、平均值、标准差、峰度、偏度、峰对峰信号值、峰对峰时间、第一和第二差绝对值的平均值、能量和熵(Shannon 熵、Log 能量熵)。采用基于相关性的特征选择方法实现特征选择,最终选择最大和最小振幅、第一和第二差绝对值的平均值作为 3 个电极的共同特征。此外,还有学者将时域特征和其他特征相结合以提升模型的稳定性,如 NASSIBI 等<sup>[3]</sup>提取了时域特征和频域特征,在每个频带和子频带上共提取 16 个特征,实现了较高的分类准确率。Hjorth 参数是定量评价脑电信号的时域参数,包含活动性、移动性和复杂性<sup>[13]</sup>。活动性表示脑电信号的平均功率。移动性采用百分比表示功率谱的平均频率或标准差。复杂性表示脑电信号在形状方面与正弦波的相似程度。SAKIB 等<sup>[14]</sup>从脑电数据中提取 Hjorth 参数和熵作为分类特征,结果显示,Hjorth 参数在 5 s 样本长度下分类准确率最高,达到了 94%。时域特征通常计算更简单,具有明确的物理意义,结果易于解释。不仅如此,时域特征对脑电信号中的噪声和伪影具有较强的鲁棒性。通过关注信号的时间方面,能最大限度地减少无关噪声的影响。由于时域特征包含的特征信息单一,除事件相关电位外,大多数学者将时域特征与其他特征结合起来,丰富特征信息,提升模型的识别准确率。

### 2.2 频域特征

脑电频域一般可分为  $\delta$ (0.5~4.0 Hz)、 $\theta$ (4~8 Hz)、 $\alpha$ (8~13 Hz)、 $\beta$ (13~30 Hz)和  $\gamma$ (30~80 Hz)。频域与认知任务、心理状态和神经脑机制有关。由于频域特征与各种心理状态关系密切,

因此,频域特征可能是抑郁症的可靠生物标志物之一。各频域的功率谱密度和频域的不对称性是脑电抑郁识别研究中常用的特征。MAHATO 等<sup>[15]</sup>使用各频段功率、不对称性和配对不对称性作为线性特征,结果显示,在所有特征中,所有频域配对不对称和不对称的特征组合显示出 90.26% 的分类准确率。KANG 等<sup>[16]</sup>采用快速傅里叶变换将脑电信号分解为  $\theta$ 、 $\alpha$ 、 $\beta$  3 个频域,结果显示, $\alpha$  不对称作为特征输入准确率高达 98.85%。然而,对哪种频域功率特征可更有效识别抑郁症目前研究还没有达成共识。MOVAHED 等<sup>[17]</sup>研究表明, $\delta$  功率是抑郁症和健康者所有脑区之间存在最明显差异的频域特征。UYULAN 等<sup>[18]</sup>得出同样的结论。也有学者认为,与  $\delta$ 、 $\theta$ 、 $\alpha$ 、 $\beta$  等频域比较, $\gamma$  频域功率的分类准确率最高<sup>[19]</sup>。尽管大量研究对抑郁症和脑电图频域之间关系进行了有益的探索,但由于研究方法的差异和所调查人群的内在异质性,导致研究结果存在较大的争议。从文献研究结果可见,频域特征与抑郁症密切相关。采用频域特征作为抑郁症脑电信号特征值具有应用范围广、处理算法简单稳定等优点,但却忽略了时间信息,并且由于不同群体数据差异性较大,因此,特异性较高的频域还没有得出一致的结论,未来还需深入研究。

### 2.3 时频特征

进行时域特征分析可较好地捕捉脑电的空间信息,但获得频率信号质量不高,频域分析需对原始脑电信号进行加窗处理,窗口大小的选择是处理的难点,而时频分析可同时兼顾,更加直观、有效<sup>[20]</sup>。常用的时频分析方法包含短时傅里叶变换、小波变换、Wigner-Ville 分布、Cohen 类分布等<sup>[21]</sup>。WAN 等<sup>[22]</sup>采用小波变换方法提取脑电样本中的小波特征,采用线性判别分析(LDA)分类器实现了 76% 的准确率。DANG 等<sup>[7]</sup>采用多元伪维格纳分布提取多通道脑电信号的时频特征,并设计多层深度卷积神经网络(CNN)架构研究大脑网络拓扑特征,用于准确检测抑郁症。由于脑电信号是非稳态的,时域特征或频域特征存在特征量不足的缺陷,而时频分析方法可有效弥补这一缺陷。因此,时频分析比单纯的时域分析或频域分析更有效,但时频特征也存在特征量较大的缺点。

### 2.4 非线性动力学特征

由于脑电信号具有非线性特征,采用非线性动力学分析处理能有效提取心理和认知等深层次信息,这是传统线性特征分析无法实现的。常用的非线性特征包括 Lempel-Ziv 复杂度<sup>[23]</sup>、熵<sup>[24]</sup>、C0 复杂度<sup>[22]</sup>、相关维数  $D_2$ <sup>[25]</sup> 等。ADERINWALE 等<sup>[25]</sup>在 149 名实验者额叶两通道(Fp1 和 Fp2)的脑电图信号中提取非线性特征,结果显示,抑郁症患者左半球的相关维数  $D_2$  和 Lempel-Ziv 复杂性明显低于休息时的健康受试者。LIU 等<sup>[26]</sup>采用去趋势波动分析探讨了抑郁症患者的  $\alpha$  频域长时程相关性(LRTC),结果显示,抑郁症患者 LRTC 较健康

者明显增加,差异脑区位于额叶、中央和顶枕区。熵是模糊变量的一个重要数值特征,用来度量模糊变量的不确定性<sup>[27]</sup>。KSIBI 等<sup>[28]</sup>研究证明,谱熵和奇异值熵可作为抑郁症研究的诊断性神经标志物。CUKIC 等<sup>[29]</sup>将 Higuchi 分形维数和样本熵作为特征区分抑郁症和健康对照组,分类准确率为 90.24%~97.56%。与线性特征比较,非线性特征更具判别性,并且非线性特征可有效反应脑电信号的变异性和复杂度,建立模型识别准确率高<sup>[30]</sup>。但采用非线性方法进行分析非常耗时,计算相对复杂<sup>[31]</sup>。

**2.5 功能连接和脑网络特征** 功能连接旨在分析神经生物学活动与不同大脑区域间连接的统计关系。有研究表明,抑郁症发病机制与大脑区域结构和网络的异常有关<sup>[32]</sup>。因此,功能连接特征可有效诊断抑郁症。计算功能连接矩阵常用的耦合方法包含相位滞后指数(PLI)、相干性、相关性和相位锁定值<sup>[33]</sup>。MOVAHED 等<sup>[34]</sup>采用同步似然方法从每个样本中提取功能连通性特征,并为数据集构建特征空间。HUANG 等<sup>[35]</sup>采用加权 PLI 计算 29 个通道两两组合间的功能连通性,结果显示,抑郁症患者  $\alpha$  频段头皮功能连通性总体较低,而  $\gamma$  频段头皮功能连通性明显高于健康者。EARL 等<sup>[36]</sup>采用 PLI 探索了抑郁症患者静息态和情绪状态下脑电功能连接特征,发现与静息态相比,使用观看快乐视频的功能连接特征提升了识别模型准确率。结果也证实了抑郁症患者脑功能连接广泛中断的特点。脑网络以采集数据的通道和相应脑区为网络节点,通过计算功能连接矩阵来构建。对复杂网络图论分析,小世界网络具有平均最短路径长度较小、聚类系数较高的特点。小世界网络在信息传递和处理过程中具有较高的局部效率和全局效率<sup>[37]</sup>。ZHANG 等<sup>[38]</sup>基于 64 通道静息状态脑电计算 PLI,构建功能连接矩阵,计算平均最短路径长度和聚类系数,实现基于小世界指数的脑功能网络二值化,结果显示,左脑额叶区、颞叶区、顶枕区、右脑颞叶区发生了明显的脑同步改变,网络指标可作为区分抑郁症与健康对照组的潜在生物标志物,分类准确率最高可达 93.31%。LI 等<sup>[33]</sup>发现,与健康对照者比较,轻度抑郁症患者小世界指数更低,聚类系数较低,差异主要集中在  $\delta$  频段。脑部的各个功能区以联合协同的方式确保大脑活动有序运行。功能连接和脑网络特征有助于深层次了解大脑功能,反映不同脑区功能的协同和联系。抑郁症患者不同脑区之间的功能连接出现异常,表现为增强或减弱,因此,是抑郁症脑电分析中常用的特征指标。该特征保留了空间结构信息,这是其他特征分析方法所欠缺的,但也存在特征维度较大的缺陷。由于实验方法的差异性,不同的研究采用的特征类型有所不同,不同特征类型各有优、缺点。目前,暂无法确定最优的特征组合,各特征类型的分类效果不能横向比较,可根据前人研究选择

合适的特征类型。可以肯定的是,融合不同的特征类型是今后研究的趋势。有研究表明,多维度特征可提升识别模型分类准确率,如 WANG 等<sup>[1]</sup>融合时域、频域和非线性特征实现了 97.5% 的准确率。SUN 等<sup>[39]</sup>也认为,组合多种类型特征对抑郁症的分类效果优于单一类型特征。值得注意的是,采用多维度特征易造成维度灾难,需采用特征工程,有效降低数据维度。

### 3 基于机器学习的抑郁症预测方法概述

近年来,机器学习结合脑电技术在抑郁症识别领域中取得了丰硕的成果,按模型结构的深度可将机器学习算法分为传统机器学习和深度学习,当前主要以这两类算法开展研究<sup>[40]</sup>。

**3.1 传统机器学习** 基于传统机器学习算法的脑电抑郁识别研究一般分为如下步骤:从原始脑电信号中提取特征值、数据降维、分类器分类。支持向量机<sup>[41]</sup>、随机森林<sup>[42]</sup>、逻辑回归<sup>[43]</sup>、LDA<sup>[44]</sup>、朴素贝叶斯<sup>[45]</sup>、k 近邻算法<sup>[41]</sup>、决策树<sup>[45]</sup>是机器学习中常用的分类器。从文献可见模型识别准确率参差不齐。为解决静息态数据脑电信号复杂性较高、非线性和非平稳性的问题,SHAO 等<sup>[46]</sup>提出一种改进经验模态分解(EMD)的网络分解模型,用于脑功能网络的时频分析,采用逻辑回归分类器发现,在  $\beta$  频段的分类效果最好,分类准确率为 80.00%。类似的,SHEN 等<sup>[47]</sup>采用改进的 EMD 特征提取方法,从 4 个 EEG 数据库的 Fp1、Fpz、Fp2 3 个通道中提取特征输入支持向量机分类器,分类准确率达 80% 以上。还有学者将多种机器学习算法作为分类器,比较了不同分类器的识别效果,如 BASHIR 等<sup>[48]</sup>提取绝对功率、相对功率、方差、偏度、峰度、迁移率、复杂性、活动性、相关维数、Shannon 熵和功率谱熵作为特征输入,采用支持向量机、k 近邻、决策树和长短期记忆(LSTM)分类器,结果显示,k 近邻算法优于其他算法模型,达到了 87.5% 的准确率,而 LSTM 模型的准确率为 83.3%。SHI 等<sup>[49]</sup>提取 3 个线性特征(幂的最大值、平均值和中心值)和 3 个非线性特征(相关维数、renyi 熵和 C0 复杂度),采用 k 近邻分类器,分类准确率为 72.25%。但其样本量较小,且分类准确率不高,需扩充样本量进一步研究。PENG 等<sup>[50]</sup>基于 21 例围产期抑郁症患者和 22 例健康孕妇的脑网络空间拓扑特征,利用 LDA 分类器辅助诊断围产期抑郁症,准确率为 81.40%,建议今后在更大的数据集上进行验证,增强研究结果的可推广性和可靠性。不同的机器学习算法各有优、缺点,选用何种机器学习算法作为最佳分类器没有一个明确的定论。传统机器学习算法是“白盒”模型,模型可解释性较强,适用于小样本数据,对计算机硬件要求不高。美中不足的是,人工提取特征可能导致潜在关键信息的丢失,不同的特征组合对识别准确率影响较大,选择合适的特征需耗费大量时间和人力,模型的

泛化能力不强。

**3.2 深度学习** 其具有自动学习和提取特征的能力,在语音、面部表情识别和自然语言处理等领域得到广泛应用,近年来也逐渐向医学领域延伸。深度学习结合脑电信号辅助诊断抑郁症的研究也日益增多。通过深度学习,可自动挖掘脑电信号中的非线性特征。CNN<sup>[51]</sup>、递归神经网络(RNN)<sup>[52]</sup>、LSTM<sup>[53]</sup>是常用的深度学习分类器。与传统机器学习比较,深度学习的识别准确率较高,如 KHADIDOS 等<sup>[52]</sup>比较了决策树、随机森林、CNN、RNN、LSTM、门控递归单元、双向 LSTM 等机器学习算法的分类性能,结果显示,在深度学习技术中 CNN 模型对抑郁症分类准确率最高,达到 98.13%,特异度为 99.00%,灵敏度为 97.00%。为解决脑电信号质量差和数据量有限导致的过拟合问题,WANG 等<sup>[54]</sup>提出了一种基于扩散的深度学习框架 DiffMDD,结合脑电图用于诊断抑郁症,其首先设计前向扩散噪声训练模块提取更多与噪声无关的特征,然后利用反向扩散数据增强模块增加数据的大小和多样性,最后在增强的脑电数据上重新训练分类器得到诊断结果,准确率为 92.4%。XU 等<sup>[55]</sup>提出了 LSTM 与多分辨率 CNN(MRCNN)结合的混合模型(MRCNN-LSTM)、残差挤压和激励(RSE)与 MRCNN 结合的模型(MRCNN-RSE)2 种深度学习技术对抑郁症进行筛查,结果显示,在 8~30 Hz 的脑电信号中 MRCNN-RSE 模型的分类准确率最高 $[(98.48 \pm 0.22)\%]$ 。表明该分析框架可为抑郁症的诊治和疗效评价提供理论和技术支持。刘博达<sup>[56]</sup>提出了对称卷积 LSTM 网络辅助诊断模型用于识别脑卒中后抑郁症,在脑卒中后抑郁数据集上准确率、精确率、召回率依次为 73.7%、77.2%、72.4%,其有助于提升脑卒中后抑郁症智能化诊断水平。与传统机器学习算法比较,深度学习在辅助诊断抑郁症方面具有很大的优势。建立模型识别准确率相对更高,无须实验者先验知识,不需手动提取特征,避免了特征筛选、组合等繁琐的步骤,拟合能力更强。但深度学习对样本数据集要求较高,是一个“黑盒”模型,可解释性差。因此,应根据实验要求选择合适的算法模型。

## 4 不足与展望

**4.1 样本量较少** LIU 等<sup>[57]</sup>指出,脑电对抑郁症的分类准确率为 76.0%~99.5%,可能与样本量大小有关。小样本是大部分研究存在的普遍问题<sup>[45,58]</sup>。建议未来研究扩充样本数量或采用数据增强技术提升识别准确率。

**4.2 脑电信号存在噪声干扰** 由于脑电信号采集过程中易受眼电、肌电、心电、皮肤电、工频等噪声干扰的影响,致使信噪比低、幅度微弱。如何降低噪声干扰提取有用信息提升脑电信号采集效率是研究者需思考的问题。

**4.3 有效脑电特征的选择** 抑郁症发病生理机制相当复杂,如何准确提取与抑郁症密切相关的脑电信号特征是亟待解决的问题。与抑郁症相关的最佳脑电导联的选择、特征类型的选择尚存在争议,下一步需挖掘与抑郁症生理特征最为相关的信息。

**4.4 算法模型的选择** 目前,对抑郁症识别的算法包含传统机器学习和深度学习。两类算法各有优、缺点,如何选择合适的模型算法提升诊断准确率是需面对的问题。因此,设计可解释性强、泛化能力好、识别准确率较高的算法模型是值得探索的重要课题。

**4.5 多模态研究** 虽然脑电是识别抑郁症较为理想的模态,但有学者指出,抑郁症在语音<sup>[59]</sup>、眼动<sup>[60]</sup>、磁共振成像<sup>[61]</sup>等模态数据方面表现出异常。因此,建议未来研究融合多模态数据,充分发挥不同模态信息互补的优势,能更全面解析抑郁症的发病机制和提升分类准确率。

**4.6 建立木僵状态原发疾病诊断模型** 木僵状态可由抑郁症、紧张型精神分裂症、脑器质性病变等原因所致,基于木僵状态的分类对临床治疗措施的选择至关重要,并且以前的研究对利用脑电技术鉴别诊断木僵状态关注还不够。未来研究可大胆尝试,建立木僵状态分类诊断模型,为临床医生识别原发疾病和选择适宜的治疗手段提供可靠的参考依据。

综上所述,机器学习结合脑电在抑郁症识别领域成果丰硕。为更好地服务于临床应用,建议未来研究应增加样本量、降低脑电信号噪声干扰、探索最佳的脑电特征、选择合适的算法模型、开展多模态研究和建立抑郁症木僵状态诊断模型,在临床实践中实现抑郁症自动化识别。

## 参考文献

- [1] WANG Y W, PENG Y D, HAN M X, et al. GCTNet: a graph convolutional transformer network for major depressive disorder detection based on EEG signals[J]. J Neural Eng, 2024, 21(3).
- [2] SMITH K. Mental health: a world of depression[J]. Nature, 2014, 515(7526): 180-181.
- [3] NASSIBI A, PAPAVALASSILIOU C, ATASHZAR S F. Depression diagnosis using machine intelligence based on spatio-spectrotemporal analysis of multi-channel EEG[J]. Med Biol Eng Comput, 2022, 60(11): 3187-3202.
- [4] PAMPOUCHIDOU A, SIMOS P G, MARIAS K, et al. Automatic assessment of depression based on visual cues: a systematic review[J]. IEEE Trans Affect Comput, 2019, 10(4): 445-470.
- [5] CAI H S, QU Z D, LI Z, et al. Feature-level fusion approaches based on multimodal EEG data for depression recognition[J]. Information Fusion, 2020, 59: 127-138.
- [6] BHADRA S, KUMAR C J. An insight into diagnosis of depression using machine learning techniques: a systemat-

- ic review[J]. *Curr Med Res Opin*, 2022, 38(5):749-771.
- [7] DANG W, GAO Z, SUN X, et al. Multilayer brain network combined with deep convolutional neural network for detecting major depressive disorder [J]. *Nonlinear Dyn*, 2020, 102(2):667-677.
- [8] SONI S, SEAL A, YAZIDI A, et al. Graphical representation learning-based approach for automatic classification of electroencephalogram signals in depression[J]. *Comput Biol Med*, 2022, 145:105420.
- [9] HOSSEINI M P, HOSSEINI A, AHI K. A review on machine learning for EEG signal processing in bioengineering [J]. *IEEE Rev Biomed Eng*, 2021, 14:204-218.
- [10] JIANG X, BIAN G B, TIAN Z A. Removal of artifacts from EEG signals: a review[J]. *Sensors (Basel)*, 2019, 19(5):987.
- [11] DUAN L J, DUAN H F, QIAO Y H, et al. Machine learning approaches for MDD detection and emotion decoding using EEG signals [J]. *Front Hum Neurosci*, 2020, 14:284.
- [12] KHAN S, UMAR S S M, FRNDA J, et al. A machine learning based depression screening framework using temporal domain features of the electroencephalography signals[J]. *PLoS One*, 2024, 19(3):e0299127.
- [13] HJORTH B. EEG analysis based on time domain properties[J]. *Electroencephalogr Clin Neurophysiol*, 1970, 29(3):306-310.
- [14] SAKIB N, ISLAM M K, FARUK T. Machine learning model for computer-aided depression screening among young adults using wireless EEG headset[J]. *Comput Intell Neurosci*, 2023, 2023:1701429.
- [15] MAHATO S, GOYAL N, RAM D, et al. Detection of depression and scaling of severity using six Channel EEG data[J]. *J Med Syst*, 2020, 44(7):118.
- [16] KANG M, KWON H, PARK J H, et al. Deep-asymmetry: asymmetry matrix image for deep learning method in pre-screening depression [J]. *Sensors (Basel)*, 2020, 20(22):6526.
- [17] MOVAHED R A, JAHROMI G P, SHAHYAD S, et al. A major depressive disorder classification framework based on EEG signals using statistical, spectral, wavelet, functional connectivity, and nonlinear analysis[J]. *J Neurosci Methods*, 2021, 358:109209.
- [18] UYULAN C, ERGÜZEL T T, UNUBOL H, et al. Major depressive disorder classification based on different convolutional neural network models: deep learning approach [J]. *Clin EEG Neurosci*, 2021, 52(1):38-51.
- [19] SAEEDI M, SAEEDI A, MAGHSOUDI A. Major depressive disorder assessment via enhanced k-nearest neighbor method and EEG signals[J]. *Phys Eng Sci Med*, 2020, 43(3):1007-1018.
- [20] 武侠, 钟楚鹏, 丁玉珑, 等. 利用时频分析研究非相位锁定脑电活动[J]. *心理科学进展*, 2018, 26(8):1349-1364.
- [21] BAJAJ V, PACHORI R B. Automatic classification of sleep stages based on the time-frequency image of EEG signals[J]. *Comput Methods Programs Biomed*, 2013, 112(3):320-328.
- [22] WAN N, HAO H, JIA Z, et al. Single-channel EEG-based machine learning method for prescreening major depressive disorder[J]. *Int J Inf Technol Decis Mak*, 2019, 18:1579-1603.
- [23] YANG J L, ZHANG Z, FU Z Y, et al. Cross-subject classification of depression by using multiparadigm EEG feature fusion [J]. *Comput Methods Programs Biomed*, 2023, 233:107360.
- [24] SHEN J, ZHANG X W, HUANG X, et al. An optimal channel selection for EEG-based depression detection via kernel-target alignment[J]. *IEEE J Biomed Health Inform*, 2021, 25(7):2545-2556.
- [25] ADERINWALE A, TOLOSSA G B, KIM A Y, et al. Two-channel EEG based diagnosis of panic disorder and major depressive disorder using machine learning and non-linear dynamical methods[J]. *Psychiatry Res Neuroimaging*, 2023, 332:111641.
- [26] LIU S, LIU X Y, YAN D F, et al. Alterations in patients with first-episode depression in the eyes-open and eyes-closed conditions: a resting-state EEG study [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2022, 30:1019-1029.
- [27] LI G, ZHONG H Y, WANG J, et al. Machine learning techniques reveal aberrated multidimensional EEG characteristics in patients with depression [J]. *Brain Sci*, 2023, 13(3):384.
- [28] KSIBI A, ZAKARIAH M, MENZLI L J, et al. Electroencephalography-based depression detection using multiple machine learning techniques [J]. *Diagnostics (Basel)*, 2023, 13(10):1779.
- [29] CUKIC M, STOKIC M, SIMIC S, et al. The successful discrimination of depression from EEG could be attributed to proper feature extraction and not to a particular classification method[J]. *Cogn Neurodyn*, 2020, 14(4):443-455.
- [30] CUKIC M, LÓPEZ V, PAVÓN J. Classification of depression through resting-state electroencephalogram as a novel practice in psychiatry: review [J]. *J Med Internet Res*, 2020, 22(11):e19548.
- [31] ZHU J, WANG Z H, GONG T, et al. An improved classification model for depression detection using EEG and eye tracking data[J]. *IEEE Trans Nanobioscience*, 2020, 19(3):527-537.
- [32] ZHU X L, WANG X, XIAO J, et al. Evidence of a dissociation pattern in resting-state default mode network connectivity in first-episode, treatment-naïve major depression patients[J]. *Biol Psychiatry*, 2012, 71(7):611-617.
- [33] LI X W, LA R, WANG Y, et al. A deep learning approach for mild depression recognition based on functional connectivity using electroencephalography[J]. *Front Neurosci*, 2020, 14:192.
- [34] MOVAHED R A, JAHROMI G P, SHAHYAD S, et al. A major depressive disorder diagnosis approach based on

- EEG signals using dictionary learning and functional connectivity features[J]. *Phys Eng Sci Med*, 2022, 45(3): 705-719.
- [35] HUANG Y Y, YI Y, CHEN Q, et al. Analysis of EEG features and study of automatic classification in first-episode and drug-naïve patients with major depressive disorder[J]. *BMC Psychiatry*, 2023, 23(1): 832.
- [36] EARL E H, GOYAL M, MISHRA S, et al. EEG based functional connectivity in resting and emotional states May identify major depressive disorder using machine learning[J]. *Clin Neurophysiol*, 2024, 164: 130-137.
- [37] 梁夏, 王金辉, 贺永. 人脑连接组研究: 脑结构网络和脑功能网络[J]. *科学通报*, 2010, 55(16): 1565-1583.
- [38] ZHANG B T, YAN G H, YANG Z F, et al. Brain functional networks based on resting-state EEG data for major depressive disorder analysis and classification [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2021, 29: 215-229.
- [39] SUN S T, CHEN H Y, SHAO X X, et al. EEG based depression recognition by combining functional brain network and traditional biomarkers[C]//2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Seoul, Korea (South): IEEE, 2020: 2074-2081.
- [40] ELNAGGAR K, EL-GAYAR M M, ELMOGY M. Depression detection and diagnosis based on electroencephalogram (EEG) analysis: a systematic review[J]. *Diagnostics (Basel)*, 2025, 15(2): 210.
- [41] AKBARI H, SADIQ M T, REHMAN A U. Classification of normal and depressed EEG signals based on centered correntropy of rhythms in empirical wavelet transform domain[J]. *Health Inf Sci Syst*, 2021, 9(1): 9.
- [42] BAI R, GUO Y, TAN X, et al. An EEG-based depression detection method using machine learning model [J]. *IJPMBS*, 2021, 10(1): 17-22.
- [43] JAN D, DE VEGA M, LÓPEZ-PIGÜI J, et al. Applying deep learning on a few EEG electrodes during resting state reveals depressive states. A data driven study[J]. *Brain Sci*, 2022, 12(11): 1506.
- [44] AVOTS E, JERMAKOV K, BACHMANN M, et al. Ensemble approach for detection of depression using EEG features[J]. *Entropy (Basel)*, 2022, 24(2): 211.
- [45] PENG H, XIA C, WANG Z H, et al. Multivariate pattern analysis of EEG-Based functional connectivity: a study on the identification of depression[J]. *IEEE Access*, 2019, 7: 92630-92641.
- [46] SHAO X X, SUN S T, LI J X, et al. Analysis of functional brain network in MDD based on improved empirical mode decomposition with resting state EEG data [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2021, 29: 1546-1556.
- [47] SHEN J, ZHANG X W, WANG G, et al. An improved empirical mode decomposition of electroencephalogram signals for depression detection[J]. *IEEE Trans Affect Comput*, 2022, 13(1): 262-271.
- [48] BASHIR N, NAREJO S, NAZ B, et al. A machine learning framework for major depressive disorder (MDD) detection using non-invasive EEG signals [J]. *Wirel Pers Commun*, 2025, 140(1): 39-61.
- [49] SHI Q, LIU A, CHEN R, et al. Depression detection using resting state three-channel EEG signal[OL]. (2020-02-21) [ 2025-05-21 ]. <https://arxiv.org/abs/2002.09175>.
- [50] PENG Y, LV B, LIU F, et al. Unveiling perinatal depression: a dual-network EEG analysis for diagnosis and severity assessment[J]. *Brain Res Bull*, 2024, 217: 111088.
- [51] YANG L J, WANG Y X, ZHU X R, et al. A gated temporal-separable attention network for EEG-based depression recognition[J]. *Comput Biol Med*, 2023, 157(C): 106782.
- [52] KHADIDOS A O, ALYOUBI K H, MAHATO S, et al. Machine learning and electroencephalogram signal based diagnosis of dipression [J]. *Neurosci Lett*, 2023, 809: 137313.
- [53] KUMAR S D, SUBHA D P. Prediction of depression from EEG signal using long short term memory(LSTM) [C]//2019 3rd International Conference on Trends in Electronics and Informatics (ICOEI). Tirunelveli, India: IEEE, 2019: 1248-1253.
- [54] WANG Y L, ZHAO S, JIANG H T, et al. DiffMDD: a diffusion-based deep learning framework for MDD diagnosis using EEG [J]. *IEEE Trans Neural Syst Rehabil Eng*, 2024, 32: 728-738.
- [55] XU Y, ZHONG H, YING S, et al. Depressive disorder recognition based on frontal EEG signals and deep learning[J]. *Sensors (Basel)*, 2023, 23(20): 8639.
- [56] 刘博达. 基于长短期记忆网络的脑卒中后抑郁诊疗辅助决策与实现[D]. 成都: 电子科技大学, 2024.
- [57] LIU Y, PU C Q, XIA S, et al. Machine learning approaches for diagnosing depression using EEG: a review[J]. *Transl Neurosci*, 2022, 13(1): 224-235.
- [58] SAEEDI A, SAEEDI M, MAGHSOUDI A, et al. Major depressive disorder diagnosis based on effective connectivity in EEG signals: a convolutional neural network and long short-term memory approach[J]. *Cogn Neurodyn*, 2021, 15(2): 239-252.
- [59] KWON N, KIM S. Depression severity detection using read speech with a divide-and-conquer approach[J]. *Annu Int Conf IEEE Eng Med Biol Soc*, 2021, 2021: 633-637.
- [60] ZHANG D, LIU X, XU L H, et al. Effective differentiation between depressed patients and controls using discriminative eye movement features[J]. *J Affect Disord*, 2022, 307: 237-243.
- [61] ZHOU E Q, WANG W, MA S M, et al. Prediction of anxious depression using multimodal neuroimaging and machine learning[J]. *Neuroimage*, 2024, 285: 120499.