

基于脑电信号的阿尔茨海默病识别算法综述

曹家翊¹, 李晓欧^{1,2,3}, 李 斌^{2,3}, 朱 耿³

(1. 上海理工大学 健康科学与工程学院; 2. 上海市杨浦区精神卫生中心, 上海 200093;
3. 上海健康医学院 医疗器械学院, 上海 201318)

摘要: 随着人工智能不断发展, 深度学习在阿尔茨海默病识别方面的应用十分广泛。脑电(EEG)作为一种非侵入式检测大脑神经电位的手段, 能反映脑部神经功能活动, 为更好地辅助诊断阿尔茨海默病研究提供了便利。首先, 梳理脑电数据库、特征提取及深度学习分类模型, 总结了近年来基于脑电的阿尔茨海默病算法; 其次, 比较不同神经网络识别算法辅助诊断阿尔茨海默病领域的研究现状与问题; 最后, 展望其未来研究方向, 以期提升阿尔茨海默病的早期诊断准确性。

关键词: 阿尔茨海默病; 深度学习; 脑电图; 辅助诊断; 特征提取

DOI: 10.11907/rjdk.241343

开放科学(资源服务)标识码(OSID):

中图分类号: TP311

文献标识码: A

文章编号: 1672-7800(2025)004-0214-07



A Review of Alzheimer's Disease Recognition Algorithms Based on EEG Signals

CAO Jiayi¹, LI Xiaou^{1,2,3}, LI Bin^{2,3}, ZHU Geng³

(1. College of Health Science and Engineering, University of Shanghai for Science and Technology;

2. Shanghai Yangpu District Mental Health Center, Shanghai 200093, China;

3. College of Medical Instruments, Shanghai University of Medicine & Health Sciences, Shanghai 201318, China)

Abstract: With the continuous development of artificial intelligence, the application of deep learning in Alzheimer's disease recognition is very extensive. Electroencephalography (EEG), as a non-invasive means of detecting brain nerve potentials, can reflect brain neural functional activity and provide convenience for better assisting in the diagnosis of Alzheimer's disease research. Firstly, we reviewed the EEG database, feature extraction, and deep learning classification models, and summarized the Alzheimer's disease algorithms based on EEG in recent years; Secondly, by comparing different models, the research status and problems of using neural network recognition algorithms to assist in the diagnosis of Alzheimer's disease were discussed; Finally, looking forward to its future research directions, in order to improve the accuracy of early diagnosis of Alzheimer's disease.

Key Words: Alzheimer's disease; deep learning; electroencephalogram; auxiliary diagnosis; feature extraction

0 引言

阿尔兹海默病(Alzheimer Disease, AD)是一种不可逆的神经退行性疾病, 主要表现为认知功能和日常生活能力降低^[1]。研究表明, 全球65岁以上老年人群AD的患病率为7%, 每年我国每位患者的平均治疗花费为119 269.36

元, 全国治疗总花费为10 450.2亿元, 庞大支出对社区和家庭造成巨大的经济和照料压力, 因缺少逆转病程的治疗手段, 早发现早干预便显得尤为重要^[2]。目前, 阿尔茨海默病的评估方法主要以神经心理学测验、脑影像学检查、脑脊液检查等为主, 这些方法的诊断效率依赖于医护人员与设备的医疗资源水平, 因此效率偏低^[3]。

近年来, 将脑电(Electroencephalography, EEG)结合深

收稿日期: 2024-04-08

扫描二维码阅读全文:



基金项目: 上海市科学技术委员会科研项目(YPM202114); 上海健康医学院上海市杨浦区科学技术委员会、卫生健康委卫生临床研究中心项目(20MC2020005); 上海市杨浦区医学重点学科项目(22YPZB10)

作者简介: 曹家翊(1999-), 男, 上海理工大学健康科学与工程学院硕士研究生, 研究方向为生物医学信号处理; 李晓欧(1975-), 男, 博士, 上海理工大学健康科学与工程学院教授, 研究方向为生物医学信息处理; 李斌(1985-), 男, 上海市杨浦区精神卫生中心主治医师, 研究方向为老年认知障碍。本文通讯作者: 李晓欧、李斌。

度学习方法在阿尔茨海默病辅助诊断中取得了显著成就^[4]。现有大量研究表明,脑电具有采集简单、成本低等优点,适合推广使用,深度学习模型在图像处理领域的应

用以卷积神经网络为首越来越广泛^[5,6]。基于脑电结合深度学习模型辅助诊断阿尔茨海默病的整体流程如图 1 所示。




Fig. 1 Overall flow of EEG-assisted diagnosis of Alzheimer's disease
图 1 脑电辅助诊断阿尔茨海默病整体流程

1 EEG 数据库

目前,脑电数据库分为开源数据集和私有数据集,公共 EEG 数据库中已积累了大量数据,研究者可根据工作需要,选取相应的数据库使用。本文在查阅 AD 相关文献及开源库,对近年 AD 的 EEG 数据库进行整理与介绍,阿尔茨海默病常用的 EEG 数据库列如表 1 所示。

Table 1 Commonly used EEG databases for Alzheimer's disease
表 1 阿尔茨海默病常用的 EEG 数据库

数据库	发布年份	类型	是否开源
PhysioNet	1999	EEG	是
ADNI	2004	EEG	是
OpenNEURO	2017	EEG	是
Delorme	2020	EEG	是

1.1 开源数据库

PhysioNet 是研究资源开源数据库,包括临床数据库、脑电波形数据库、脑磁图像数据库^[7,8]。有大量的脑电病例数据及健康对照(Health Control, HC)供研究人员使用。ADNI 数据库主要包含 AD 患者以及轻度认知障碍(Mild Cognitive Impairment, MCI)患者,数据类型包括 MRI、EEG 和血液生物标志物等,现为数据最多的阿尔茨海默病的资源库^[9,10]。OpenNEURO 是一个以神经科学数据为主且开源的数据库,其数据集主要涵盖 EEG、MRI、MEG 等,目前已收录 965 例数据集,共计 37 397 名受试者数据^[11]。Delorme 脑电数据库主要包含各种类型的 EEG 和事件相关电位(Event Related Potential, ERP)数据,涵盖了认知、癫痫等多种数据,用户使用该数据库可获取大量与神经科学相关的原始数据^[12]。

1.2 私有数据库

私有数据库是指个人拥有的数据库,个人根据需要的研究情况按需采集。这些私有数据库通常由研究机构、医疗中心或专门的研究项目建立和维护,提供了大量详细、经过整理的数据,有助于研究者发现新的研究方向和治疗方法。然而,由于数据的敏感性和隐私保护问题,这些数据库通常不对公众开放,而是通过合作或特定协议来共享数据。

1.3 优缺点

表 2 为上述两种数据库的优缺点。研究人员都可结合自身及科研条件选取相应的数据,开展有关阿尔茨海默病的研究。

Table 2 Advantages and disadvantages of open source and private databases
表 2 开源和私有数据库优缺点

数据库	优点	缺点
开源数据库	容易获取,数据量大;数据种类多,可以结合多种数据分析 数据质量好,可以根据研究人员的需求采集;使用人数少 数据质量高,可以根据研究人员的需求采集;使用人数少	数据质量较差,无法根据研究人员的分析到合适数据;使用人数多 创新性低
私有数据库	数据质量好,可以根据研究人员的需求采集;使用人数少 数据质量高,可以根据研究人员的需求采集;使用人数少	不方便获取,数据量少,采集困难,患者是否配合

2 EEG 特征提取

脑电特征提取是从 EEG 信号中识别和抽取出有用信息的过程,这对于理解大脑功能和识别阿尔茨海默病至关重要。具体过程为:首先,从数据维度压缩脑电信号;其次,提取有效信息以保证数据有效性,并提升模型效率。其中,特征提取主要分为时域和频域。

2.1 时域分析

脑电信号的时域特征主要以时间序列为基础,提取时间序列是最直接的方式且具有较高的时间精度和准确性。时域分析方法主要包括:①事件相关电位是时域分析中最常用的方法之一,关注由特定事件(视觉或听觉刺激等)引起的波幅变化,在多个试验中对齐时间点并平均以提取由该事件引起的脑电活动模式^[13];②熵是一种衡量信号复杂性或不可预测性的指标,在脑电信号分析中熵特征可识别不同脑状态的复杂度变化^[14]。表 3 列举了主要的时域特征。

Williams 等^[15]利用 ERP 的稀疏特性,将同一刺激下不同通道的大脑电串联后,通过 EEG 集成稀疏分类器取得较好的准确率。Li 等^[16]从 AD 患者的脑电信号中提取方差、均方根和振幅等时域特征后,输入后续分类模型。Torrents-barrena 等^[17]评估 Tsallis 熵代替 Shannon 熵处理阿尔茨海默病信号的有效性,前者能使用更好的特征进行神经

Table 3 Time domain characteristics

表3 时域特征

名称	时域特征	方法
均值	Mean value	事件相关电位/熵
方差	Variance	事件相关电位/熵
标准差	Standard deviation	事件相关电位/熵
自回归系数	Autoregressive coefficients	事件相关电位/熵
波长	Wavelength	事件相关电位/熵
幅值	Amplitude	事件相关电位/熵

网络分类。Toural 等^[18]使用 θ 波段脑电功率比、 β 波段脑电功率比和熵值随时间的分布情况进行分类,通过熵值分布计算发现该方法的精度为 92.68%。然而,上述方法只根据时域信息进行分类,因此准确率较低。

2.2 频域分析

在频域分析中,EEG 信号可被划分为 δ (0~4 Hz)、 θ (4~8 Hz)、 α (8~13 Hz)、 β (13~25 Hz) 及 γ (25~50 Hz) 的脑电信号^[19]。频域信号主要使用小波变换或傅里叶变换获得时域信号的频谱或功率谱,这些方法可将时域 EEG 信号转换到频域,从而获得频率与能量的关系图。

频域分析的方法主要包括小波变换与傅里叶变换。其中,小波变换的基本思想是将信号分解为一组小波基函数的线性组合,每个小波基函数对应不同频率和尺度的信息^[20];傅里叶变换通常将脑电信号从时域转换到频域,可将脑电信号转变为不同频率的周期复指数信号的线性组合^[21]。表 4 为常用的频域特征。

Table 4 Frequency domain characteristics

表4 频域特征

名称	频域特征	方法
功率	Power	小波变换/傅里叶变换
功率谱密度	Power spectral density	小波变换/傅里叶变换
能量	Energy	小波变换/傅里叶变换

Bi 等^[22]将各通道的脑电功率进行空间映射及插值,得到对应于不同频带的彩色图像,并以 EEG 频谱图为特征分类 AD 患者。Trinh 等^[23]利用频谱间相似度量化两个静息态脑电信号的内在性,相较于其他常用特征在 AD 识别中的效果更好。Wen 等^[24]使用小波变换提取 AD 患者的静息态 Theta、Alpha1、Alpha2 波段特征,3 种频段组合的分类效果分别达到 89%、91%、92%。Rodrigues 等^[25]通过对小波变换系数进行反对数转换,获得其平方和倒频谱的距离,识别精度达到 95.55%。然而,时频分析法对时间域和频率域都有很强的局部性,在信号不稳定的情况下识别效果较差。

3 神经网络分类模型

传统机器学习模型包括支持向量机(Support Vector Machine, SVM)、随机森林(Random Forest, RF)等,但需要将特征输入模型进行训练,并为模型选择合适的参数,因此局部模式下存在计算效率低、精度低等问题。近年

来,神经网络模型的快速发展,有效解决了传统机器学习的局限性,为阿尔茨海默症的辅助诊断开辟了新的道路。研究人员开始利用这些技术分析大规模的脑电数据。例如,通过分类算法建立自动化的分类器和辅助诊断模型进行 AD 分类与预测。特别的,基于神经网络模型在提升 EEG 分类精度和在噪声影响下的鲁棒性方面发挥了重要作用^[26]。

3.1 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)是一类含卷积计算的神经网络,由输入层、卷积层、池化层、全连接层、输出层组成。在多维数据情况下的优势更为突出。因此,本文将图像直接用作神经网络的输入,避开传统识别方法所需的复杂特征抽取和数据重构,基本的网络结构如图 2 所示。




Fig. 2 Convolutional neural network structure

图2 卷积神经网络结构

Duan 等^[27]通过分析 89 例 AD 患者和 10 例 HC 的静息状态脑电信号,采用迁移学习将快速傅里叶变换(Fast Fourier Transform, FFT)计算的频谱功率密度和 LORETA (一种脑电图分析方式)计算的神经电流密度作为神经网络的输入特征,获得了 89.00% 的准确率。Kramer 等^[28]使用 CNN 将收集的两组静息状态脑电图信号进行数据增强,结果显示增强后的 CNN 模型对 MCI 的识别准确率为 93.42%,对 AD 的识别准确率为 98.54%。You 等^[29]构建出 CNN 三层分类模型采集 AD、MCI 和 HC 各 63 例的脑电信号,以脑电信号的二维灰度 PSD 图像为分类特征,准确率为 83.33%。Dukart 等^[30]采用卷积神经网络,使用连续小波变换将脑电信号转换为时频信号,该模型的三级分类准确率高达 98.90%。Duc 等^[31]提出一种 3D-CNN 结构分类 AD 和 HC,结合 CNN 与 SVM 等方法预测简易精神状态检查表(Minimum Mental State Examination, MMSE)的分数以综合判断疾病状态。表 5 总结了近年来将 CNN 用于 AD 分类的研究成果。

Table 5 Research results of CNN in Alzheimer's disease classification

表5 CNN在阿尔茨海默病分类的研究成果

作者	被试人群	方法/提特征	网络类别	分类精度/%
Ferri 等 ^[27]	89AD 10HC	傅里叶变换	CNN	AD-HC-89.00
Zhang 等 ^[32]	49AD 37MCI 14HC	滑动窗口	Dp-CNN	AD-MCI-HC-97.10
Chriskos 等 ^[33]	84MCI 23HC	功能连接	CNN	MCI-HC-91.10
Huggins 等 ^[34]	52AD 37MCI 52HC	连续小波变换	Alex-Net	AD-MCI-HC-98.00

3.2 循环神经网络

循环神经网络(Recursive Neural Network, RNN)是一类基于非参数序列的神经网络,由输入层、隐藏层、输出层组成^[35]。隐藏层上的神经元之间相互连接并传输数据信号,以表示数据间的关联,基本的网络结构如图3所示。




Fig. 3 Recurrent neural network structure
图3 循环神经网络结构

阿尔茨海默病是时间依赖性的退行性疾病,在病人出现临床症状之前,RNN通过综合分析时间序列预测病人的病情、发病时间等。Goli等^[36]利用脑电信号特定通道的时频特征量化患者与健康人之间的差异,研究表明RNN对AD的分类效果优于支持向量机。长短期记忆网络(Long Short-Term Memory, LSTM)是一种特殊的循环神经网络,相较于传统RNN更适合处理、预测时间序列中间隔较长的重要信号。Alvi等^[37]利用LSTM对降采样后的EEG进行处理,发现利用3个LSTM分层时预测精度(精度、敏感性和特异性)均可达到90%,但随着神经元数目增加其性能逐渐降低。Alessandrini等^[38]试图将递归神经网络与成分分析方法有机地结合起来,建立一个更具鲁棒性的故障诊断体系分类AD。表6列举了近年来利用RNN分类AD的研究成果。

Table 6 Research results of RNN in Alzheimer’s disease classification
表6 RNN在阿尔茨海默病分类的研究成果

作者	被试人群	方法/提特征	网络类别	分类精度
Alvi等 ^[37]	11MCI 16HC	降采样	LSTM	MCI-HC-96.41%
Alessandrini等 ^[38]	20AD 15HC	主成分分析	LSTM	AD-HC-97.9%
Imani ^[39]	24AD 24HC	熵	Bi-LSTM	AD-HC-100%
Kumar等 ^[40]	开源数据集	小波变换	RNN	AD-96.17%

3.3 图神经网络

CNN与RNN的飞速发展将深度学习带上了一个新的台阶,但仅适用于欧氏数据(网格、序列等),无法有效地处理非欧氏数据(脑网络、脑结构等),而图神经网络却能很好地解决这些非欧氏数据的问题,网络结构如图4所示^[41]。Klepl等^[42]基于功能连接图,在使用EEG辅助诊断AD方面对图神经网络(Graph Neural Network, GNN)模型

进行训练,研究表明GNN模型的性能明显优于其他基线模型。Song等^[43]提出基于EEG进行AD诊断的自度量GNN模型,在TADPOLE数据集上进行早期AD诊断和轻度认知功能障碍(Mild Cognitive Impairment, MCI)转换预测,实验表明该模型在这两个任务上都表现出色,准确率分别为94.44%、87.50%。Kim等^[44]基于可解释GNN模型,采用动态脑网络判断脑网络重要特征,依据EEG数据预测AD。Parisot等^[45]使用图卷积神经网络(Graphical Convolutional Neural Network, GCN)(见图4)研究评估ADNI数据集,AD分类准确率为80.0%。Li等^[46]提出一种可解释的图神经网络框架,通过增加网络层数,利用池化层中的节点池化分数计算出对AD分类较重要的感兴趣区域,以确定与疾病相关的大脑生物标志物。




Fig. 4 Graph neural network structure
图4 图神经网络结构

综上,深度学习的强大优势在于能形成多层脑区的不同抽象层次,但对于图神经网络而言,现有图神经网络模型大多局限于浅层结构。表7总结了近年来GNN模型用于AD分类的研究成果。

Table 7 Research results of GNN in Alzheimer’s disease classification
表7 GNN在阿尔茨海默病分类的研究成果

作者	被试人群	方法/提特征	网络类别	分类精度/%
Klepl等 ^[42]	20AD 20HC	功能连接	GNN	AD-HC-98.4
Song等 ^[43]	开源数据集	多节点融合	GNN	AD-HC-94.4 MCI-HC-87.5
Kim等 ^[44]	开源数据集	动态脑网络	GCN	53.5 ± 3.8
Klepl等 ^[47]	20AD 20HC	双谱分析	GCN	AD-HC-83.3

4 模型归纳分析

深度学习为脑电辅助诊断阿尔茨海默病断提供了便利,通过卷积神经网络(CNN)、循环神经网络(RNN)、图神经网络(GNN)算法都能分类不同EEG特征的AD人群。上述模型的优缺点如表8所示。

表8中网络均为单模态数据分析,因AD的病因异常复杂,研究人员一直在努力结合不同模态的数据进行研究,以提供更丰富、全面的信息,提升模型的性能和泛化能力。已有研究表明,GNN可用于融合多模态特征表示,并进行跨模态推理和预测,因此多模态数据在AD诊断中得到了广泛应用。

Kazi等^[48]基于LSTM和注意力机制构建了GCN,改进

Table 8 Comparison of advantages and disadvantages of neural network models

表 8 神经网络模型优缺点比较

神经网络	优点	缺点
CNN	能扩展更大的数据集和更高的维度,捕捉到局部特征	训练时间长、计算参数量大、容易发生拟合现象
RNN	能提取到动态时序特征;拥有长期储存数据的能力	可能出现梯度消失或梯度爆炸问题
GNN	能处理图结构的非欧氏数据;通过增加网络层数来提高模型的表达能力	模型对节点的顺序比较敏感;内部结构和权重参数难以解释

了疾病预测,着重于学习多模态数据的重要性顺序。Hu 等^[49]提出一个多模态图学习框架,通过各模态之间的相关性和互补性来整合各模态特征,以更好地分类 AD。Zuo 等^[50]首先通过 EEG 预训练模型从多模态数据中提取 AD 潜在表征,其次利用潜在表征,基于图卷积的对抗网络来缩小超边特征的分布差异进行 AD 分类。

表 9 展示了使用单模态数据进行 AD 识别的各种研究方法的平均准确率。研究表明,单模态数据的性能稍低于多模态,表明融合多模态数据可更好地提升 AD 诊断的效果。综上所述,单模态方法更注重如何有效地从单一模态数据中分析大脑网络特征,而多模态方法更专注于探究多模态数据的融合策略。对于分类任务而言,由于 AD 具有多个不同的演变阶段,因此准确识别各阶段都值得研究。在追求更高准确率的同时,许多研究也将模型的可解释性和生物标志物作为研究重点,为 AD 临床应用和诊断提供了可靠的理论依据与重要参考。

Table 9 Comparison of single modal and multimodal classification accuracy among different neural networks

表 9 不同神经网络下单模态和多模态分类精度比较

网络模型	单模态	多模态	平均分类精度/%
CNN	EEG	EEG+多源数据	90.32
RNN	EEG	EEG+多源数据	90.88
GNN	EEG	EEG+多源数据	92.10

5 结语

由于阿尔茨海默病的复杂性,基于 EEG 的深度学习方法分析存在许多局限性。近年来,GNN 凭借其处理不规则和复杂数据的出色能力,正在逐步克服脑疾病辅助诊断存在的问题,更适合大范围推广使用。

目前,神经网络算法在脑电辅助诊断 AD 领域面临的挑战如下:①优化诊断模型。在对 AD 的诊断中,多重分类的模式准确性还不高。目前,现有神经网络的模型对 MCI、NC、AD 人群进行三分类的精度有待提高;②可解释性较差。神经网络模型通常为黑盒模型,即无法直接了解模型内部的工作原理,因此难以理解这些特征如何影响模型决策;③多模态数据融合。脑电结合影像、化验等多源数据的融合方法仍需改进。此外,由于多模态技术在临床上的应用,模型缺失的一种模式,若只利用已有的模态数据训练会加剧小样本问题,降低模型性能。

为解决神经网络在脑电辅助诊断 AD 领域所面临的问题,提升模型诊断精度。该领域未来的研究工作发展可侧重于以下 3 个方面:

(1)AD 发病机制是复杂的、异质性的,多模式的联合分析相较于单一模式更有效。例如,结合临床诊断与遗传数据定位脑区,提取脑电异常特征深入理解阿尔茨海默病的发病机理来提升 AD 患者的分类准确率。

(2)通过与可视化技术相结合的方法增强神经网络的解释性。采用深度神经网络、类似激活图等可视化分析技术,研究不同类型脑区间的空间分布规律,在确保判断准确性的前提下增强模型透明性,并深入阐释脑区特征与疾病诊断的内在联系,为临床诊疗提供科学依据。

(3)通过挖掘脑电不同模态间的内在关联,提高多模态模型的识别能力。针对模式缺失问题,充分挖掘模式间的信息互补关系,并均衡神经网络上丰富模式和缺失模式的特征权值以达到多模态融合的目的。

近年来,EEG 作为阿尔茨海默病的一种辅助诊断手段,获得了国内外学者的高度重视,但其研究尚处在起步阶段,关键在于 EEG 的特征提取和算法识别方面。在特征提取方面,必须综合利用时域、频域的特征才能取得较好的结果;在分类模型上方面,尽管深度学习模型相较于机器学习优势明显,但其可解释性不强,需要结合多模态数据,因此模型的复杂性较高,还有待深入研究。

参考文献:

- [1] CHU Y, XU W L. A review of research on early classification of Alzheimer's disease based on computer-aided diagnosis technology[J]. Computer Engineering and Science, 2022, 44(5): 879-893.
楚阳,徐文龙. 基于计算机辅助诊断技术的阿尔兹海默症早期分类研究综述[J]. 计算机工程与科学, 2022, 44(5): 879-893.
- [2] XU T, HAN H, TAO M. Progress of resting EEG in the diagnosis of Alzheimer's disease[J]. Zhejiang Medicine, 2023, 45(6): 662-665.
许涛,韩奕,陶明. 静息脑电技术在阿尔兹海默病诊断中应用的研究进展[J]. 浙江医学, 2023, 45(6): 662-665.
- [3] KIRSCHSTEIN T, KÖHLING R. What is the source of the EEG?[J]. Clinical EEG and Neuroscience, 2009, 40(3): 146-149.
- [4] IMAMURA K, YADA Y, IZUMI Y, et al. Prediction model of amyotrophic lateral sclerosis by deep learning with patient induced pluripotent stem cells[J]. Annals of Neurology, 2021, 89(6): 1226-1233.
- [5] GE Q, LIN Z C, GAO Y X, et al. A robust discriminant framework based on functional biomarkers of EEG and its potential for diagnosis of Alzheimer's disease[J]. Journal of Neural Engineering, 2023, 20(1): 016001.

- er's disease[J]. *Healthcare*, 2020, 8(4): 476.
- [6] LIU M, ZHANG D, SHEN D, et al. Ensemble sparse classification of Alzheimer's disease[J]. *NeuroImage*, 2012, 60(2): 1106–1116.
- [7] POLLARD T J, JOHNSON A E W, RAFFA J D, et al. The eICU collaborative research database, a freely available multi-center database for critical care research[J]. *Scientific Data*, 2018, 5(1): 1–13.
- [8] JOHNSON A E W, POLLARD T J, BERKOWITZ S J, et al. MIMIC-CXR, a de-identified publicly available database of chest radiographs with free-text reports[J]. *Scientific Data*, 2019, 6(1): 317.
- [9] PETERSEN R C, AISEN P S, BECKETT L A, et al. Alzheimer's disease neuroimaging initiative (ADNI): clinical characterization[J]. *Neurology*, 2010, 74(3): 201–209.
- [10] VENUGOPALAN J, TONG L, HASSANZADEH H R, et al. Multimodal deep learning models for early detection of Alzheimer's disease stage[J]. *Scientific Reports*, 2021, 11(1): 3254.
- [11] BIGDELY-SHAMLO N, TOURYAN J, OJEDA A, et al. Automated EEG mega-analysis I: spectral and amplitude characteristics across studies[J]. *NeuroImage*, 2020, 207: 116361.
- [12] YANG R H. Research on data acquisition and analysis of EEG signals [D]. Guilin: Guangxi Normal University, 2007.
杨仁桓. 脑电信号的数据采集与分析研究[D]. 桂林: 广西师范大学, 2007.
- [13] WANG X Y, ZHANG G, MIAO Q. Progress of event-related potential P300 in neurological diseases with cognitive dysfunction[J]. *Anhui Medicine*, 2018, 39(5): 622–624.
王小玉, 张干, 苗青. 事件相关电位P300在神经疾病伴认知功能障碍中的应用进展[J]. *安徽医学*, 2018, 39(5): 622–624.
- [14] ZHANG M Y, ZHANG B S, CHEN Y. Study on the subwave entropy of spontaneous EEG signals in patients with Alzheimer's disease[J]. *Journal of Biomedical Engineering*, 2014, 31(4): 755–761.
张美云, 张本恕, 陈英. 阿尔茨海默病患者自发脑电信号子波熵的研究[J]. *生物医学工程学杂志*, 2014, 31(4): 755–761.
- [15] WILLIAMS P, WHITE A, MERINO R B, et al. Facial recognition task for the classification of mild cognitive impairment with ensemble sparse classifier[C]// 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2019: 2242–2245.
- [16] LI Y, XIAO S, LI Y, et al. Classification of mild cognitive impairment from multi-domain features of resting-state EEG[C]// 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society, 2020: 256–259.
- [17] TORRENTS-BARRENA J, LAZAR P, JAYAPATHY R, et al. Complex wavelet algorithm for computer-aided diagnosis of Alzheimer's disease[J]. *Electronics Letters*, 2015, 51(20): 1566–1568.
- [18] TOURAL J E S, PEDRÓN A M, MARAÑÓN E J. A wavelet entropy based methodology for classification among healthy, mild cognitive impairment and Alzheimer's disease people[C]// Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 24th Iberoamerican Congress, 2019: 589–598.
- [19] UHLHAAS P J, SINGER W. Neural synchrony in brain disorders: relevance for cognitive dysfunctions and pathophysiology[J]. *Neuron*, 2006, 52(1): 155–168.
- [20] ZHANG Y P, SUN W H, CHEN F M. Lung sound classification algorithm based on wavelet transform and CNN-LSTM[J]. *Chinese Journal of Medical Physics*, 2024, 41(3): 356–364.
张乙鹏, 孙文慧, 陈扶明. 基于小波变换和CNN-LSTM的肺音分类算法[J]. *中国医学物理学杂志*, 2024, 41(3): 356–364.
- [21] WANG Z M, ZHAO Y P, ZHENG R L, et al. A review of EEG signal emotion recognition research[J]. *Computer Science and Exploration*, 2022, 16(4): 760–774.
王忠民, 赵玉鹏, 郑榕林, 等. 脑电信号情绪识别研究综述[J]. *计算机科学与探索*, 2022, 16(4): 760–774.
- [22] BI X, WANG H. Early Alzheimer's disease diagnosis based on EEG spectral images using deep learning[J]. *Neural Networks*, 2019, 114: 119–135.
- [23] TRINH T T, TSAI C F, HSIAO Y T, et al. Identifying individuals with mild cognitive impairment using working memory-induced intra-subject variability of resting-state EEGs[J]. *Frontiers in Computational Neuroscience*, 2021, 15: 700467.
- [24] WEN D, ZHOU Y, LI P, et al. Resting-state EEG signal classification of amnesic mild cognitive impairment with type 2 diabetes mellitus based on multispectral image and convolutional neural network[J]. *Journal of Neural Engineering*, 2020, 17(3): 036005.
- [25] RODRIGUES P M, BISPO B C, GARRETT C, et al. Lacsogram: a new EEG tool to diagnose Alzheimer's disease[J]. *IEEE Journal of Biomedical and Health Informatics*, 2021, 25(9): 3384–3395.
- [26] GOENKA N, TIWARI S. Deep learning for Alzheimer prediction using brain biomarkers[J]. *Artificial Intelligence Review*, 2021, 54(7): 4827–4871.
- [27] DUAN F, HUANG Z, SUN Z, et al. Topological network analysis of early Alzheimer's disease based on resting-state EEG[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(10): 2164–2172.
- [28] KRAMER M A, CHANG F L, COHEN M E, et al. Synchronization measures of the scalp electroencephalogram can discriminate healthy from Alzheimer's subjects[J]. *International Journal of Neural Systems*, 2007, 17(2): 61–69.
- [29] YOU Z, ZENG R, LAN X, et al. Alzheimer's disease classification with a cascade neural network[J]. *Frontiers in Public Health*, 2020, 8: 584387.
- [30] DUKART J, SCHROETER M L, MUELLER K, et al. Age correction in dementia – matching to a healthy brain[J]. *Plos One*, 2011, 6(7): e22193.
- [31] DUC N T, RYU S, QURESHI M N I, et al. 3D-deep learning based automatic diagnosis of Alzheimer's disease with joint MMSE prediction using resting-state fMRI[J]. *Neuroinformatics*, 2020, 18: 71–86.
- [32] ZHANG R, ZHANG X, et al. A novel method for diagnosing Alzheimer's disease using deep pyramid CNN based on EEG signals[J]. *Heliyon*, 2023, 9(4): e14858.
- [33] CHRISKOS P, FRANTZIDIS C A, PAPANASTASIOU E, et al. Applications of convolutional neural networks in neurodegeneration and physiological aging[J]. *International Journal of Psychophysiology*, 2021, 159: 1–10.

- [34] HUGGINS C J, ESCUDERO J, PARRA M A, et al. Deep learning of resting-state electroencephalogram signals for three-class classification of Alzheimer's disease, mild cognitive impairment and healthy ageing [J]. *Journal of Neural Engineering*, 2021, 18(4): 046087.
- [35] LIPTON Z C, BERKOWITZ J, ELKAN C. A critical review of recurrent neural networks for sequence learning [DB/OL]. <https://arxiv.org/abs/1506.00019>.
- [36] GOLİ P, RAD E M, GHANDEHARI K, et al. Early assessment of mild Alzheimer's disease using Elman neural network, LDA and SVM methods [J]. *Journal of Machine Learning Research*, 2017, 2(4): 148–151.
- [37] ALVI A M, SIJLY S, WANG H. A long short-term memory based framework for early detection of mild cognitive impairment from EEG signals [J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2022, 7(2): 375–388.
- [38] ALESSANDRINI M, BIAGETTI G, CRIPPA P, et al. Eeg-based alzheimer's disease recognition using robust-PCA and LSTM recurrent neural network [J]. *Sensors*, 2022, 22(10): 3696.
- [39] IMANI M. Alzheimer's diseases diagnosis using fusion of high informative BiLSTM and CNN features of EEG signal [J]. *Biomedical Signal Processing and Control*, 2023, 86: 105298.
- [40] KUMAR R D, SARAVANAN S. EEGAlzheimer'sNet: development of transformer-based attention long short term memory network for detecting Alzheimer disease using EEG signal [J]. *Biomedical Signal Processing and Control*, 2023, 86: 105318.
- [41] GU J, WANG Z, KUEN J, et al. Recent advances in convolutional neural networks [J]. *Pattern Recognition*, 2018, 77: 354–377.
- [42] KLEPL D, HE F, WU M, et al. EEG based graph neural network classification of Alzheimer disease: an empirical evaluation of functional connectivity methods [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 30: 2651–2660.
- [43] SONG X, MAO M, QIAN X. Auto-metric graph neural network based on a meta-learning strategy for the diagnosis of Alzheimer's disease [J]. *IEEE Journal of Biomedical and Health Informatics*, 2021, 25(8): 3141–3152.
- [44] KIM M, KIM J, QU J, et al. Interpretable temporal graph neural network for prognostic prediction of Alzheimer's disease using longitudinal neuroimaging data [C]// 2021 IEEE International Conference on Bioinformatics and Biomedicine, 2021: 1381–1384.
- [45] PARISOT S, KTEA S I, FERRANTE E, et al. Disease prediction using graph convolutional networks: application to autism spectrum disorder and Alzheimer's disease [J]. *Medical Image Analysis*, 2018, 48: 117–130.
- [46] LI X, ZHOU Y, DVORNEK N C, et al. Pooling regularized graph neural network for FMRI biomarker analysis [C]// *Medical Image Computing and Computer Assisted Intervention*, 2020: 625–635.
- [47] KLEPL D, HE F, WU M, et al. Cross-frequency multilayer network analysis with bispectrum-based functional connectivity: a study of Alzheimer's disease [J]. *Neuroscience*, 2023, 521: 77–88.
- [48] KAZI A, SHEKARFOROUSH S, ARVIND K S, et al. Graph convolution based attention model for personalized disease prediction [C]// *Medical Image Computing and Computer Assisted Intervention*, 2019: 122–130.
- [49] HU Z, HUANG Y, ZHENG H, et al. Graph-based fine-grained model selection for multi-source domain [J]. *Pattern Analysis and Applications*, 2023, 26(3): 1481–1492.
- [50] ZUO Q, LEI B, SHEN Y, et al. Multimodal representations learning and adversarial hypergraph fusion for early Alzheimer's disease prediction [DB/OL]. <https://arxiv.org/abs/2107.09928>.

(责任编辑:刘嘉文)