

DOI:10.3969/j.issn.1005-202X.2024.02.016

医学信号处理与医学仪器

基于时空图卷积神经网络的精神分裂症识别

徐信毅¹, 李斌², 朱耿³, 周宇星¹, 林萍¹, 李晓欧^{1,2,3}

1. 上海理工大学健康与科学工程学院, 上海 200093; 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】提出一种基于时空图卷积神经网络的精神分裂症患者分类方法,与过往仅分析脑电中的时频特征而忽略各脑区之间空间特征的主流方法不同,模型主要通过用不同通道之间小波相干系数构成的邻接矩阵和脑电序列进行图卷积的方式获取其中的空频特征,再通过一维时间卷积获取其中的时频特征,经过多次卷积后将处理过的矩阵扁平化后输入分类模型。实验结果表明本文方法在公开数据集 Zenodo 上的分类准确率达 96.32%,证明本文方法的有效性,也证明融合时频、空频特征对精神分裂症诊断的优势。

【关键词】精神分裂症;时频特征;空频特征;图神经网络

【中图分类号】R318;TP183

【文献标志码】A

【文章编号】1005-202X(2024)02-0227-06

Spatial-temporal graph convolutional neural network for schizophrenia recognition

XU Xinyi¹, LI Bin², ZHU Geng³, ZHOU Yuxing¹, LIN Ping¹, LI Xiao'ou^{1,2,3}

1. School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Shanghai Yangpu District Mental Health Center, Shanghai 200093, China; 3. School of Medical Instruments, Shanghai University of Medicine and Health Sciences, Shanghai 201318, China

Abstract: A spatial-temporal convolutional neural network-based method is proposed for schizophrenia classification. Unlike the mainstream methods that only analyze the temporal frequency features in EEG and ignore the spatial features between brain regions, the model mainly obtains the spatial-frequency features by convolving the adjacency matrix composed of wavelet coherence coefficients between different channels and EEG sequences, and then extracts the temporal-frequency features through one-dimensional temporal convolution. The processed matrix is flattened after multiple convolutions and input to the classification model. Experimental results show that the method has a classification accuracy of 96.32% on the publicly available dataset Zenodo, demonstrating its effectiveness and exhibiting the advantages of fusing temporal-frequency and spatial-frequency features for schizophrenia diagnosis.

Keywords: schizophrenia; temporal-frequency characteristic; spatial-frequency characteristic; graph neural network

前言

精神分裂症是一种严重的慢性精神障碍疾病,它会对患者的思维能力产生不利影响,同时也可能

影响他们的生活活动、职业表现和受教育水平^[1]。一般来说,精神分裂症是通过访谈和观察幻觉、功能下降和言语混乱等行为迹象来诊断,但精神分裂症是一个综合征的概念,没有一个标准的测试结果或者生物标记物用于诊断;许多精神病学诊断都有共同的症状,精神分裂症和其他疾病之间的界限是模糊的,并且疾病和健康之间的界限也是模糊的^[2]。因此,探索出一种可以准确对精神分裂症患者进行诊断的方法成为精神障碍研究领域一个重要的研究方向。

目前主要的精神障碍诊断方法主要是大脑生物信号检测,主要手段有脑电图(Electroencephalogram, EEG)、脑磁图、功能磁共振和正电子发射断层扫描等

【收稿日期】2023-10-26

【基金项目】上海市科委地方院校能力建设项目(22010502400);上海健康医学院精神卫生临床研究项目(20MC2020005);上海市杨浦区技术委员会卫生健康委员会科研项目(YPM202114)

【作者简介】徐信毅,硕士研究生,研究方向:生物医学信号处理, E-mail: 1254841987@qq.com

【通信作者】李晓欧,博士,教授,研究方向:人体智能感知技术与穿戴式医疗器械, E-mail: bradyli@163.com

技术,其中,EEG由于其低成本、非侵入性、易于设置以及高时间分辨率和空间分辨率,被认为是首选的检测方法^[3-5]。在进行EEG分析时,有手动提取特征和自动提取特征两种方式。手动提取特征方法是指研究者依据过往临床经验以及实验结果人为从EEG信号中提取特征,而自动提取特征方法是让分析模型在每次训练后不断优化提取特征的算法以提高分析的准确度。手动提取特征优势在于提取特征的方法有较好的可解释性和相关性,依据这些特征的分类结果都较为准确,例如田程等^[6]使用的模糊熵,冯静雯等^[7]使用的功率谱,段子敬等^[8]使用的功率谱密度、电极相关系数以及相位锁相值,De Miras等^[9]使用的近似熵、样本熵、相关性维度、最大李雅普诺夫指数、总能量以及分频能量等一系列特征,这些运用手动提取特征的研究都取得较高的分类准确度,不过因为提取这些特征都是基于研究人员或临床人员的经验,这些特征可能无法全面体现病症对EEG的影响。自动提取特征可以发掘EEG信号中不被人注意到的潜在特征。深度学习作为一种重要的自动提取特征的方式,可以从数据集中自动学习特征表示,因此无需额外的特征提取步骤,对EEG信号中的噪声具有较强的鲁棒性,并且可以不断从输入的训练数据中自我学习以提高模型性能^[10]。采用深度学习技术进行EEG分析的方法也开始逐渐流行起来。Usman等^[11]使用3层卷积神经网络(Convolutional Neural Network, CNN)提取自动化特征后经过长短期记忆(Long Short-Term Memory, LSTM)单元完成癫痫发作前和发作间状态的分类;Jana等^[12]使用CNN最小化通道的技术将EEG通道缩减至6个,可预测10 min前的癫痫发作;Hassan等^[13]通过模型直接分析单通道信号和组合通道来识别精神分裂症。由于这类型的特征没有依据现实的理论参考,缺乏可解释性,导致运用这类方法得出的结论和分类结果不易被接受。

目前用于对精神分裂症患者进行分类的学习模型有很多,其中,提取EEG的空频特征或时频特征分析大脑状态是经典的深度学习方法。在运用空频特征方面,Li等^[14]结合秩加权相位滞后指数与公共空间模式,采用相对相位的阶数作为权重来解决相位滞后问题,对运动想象任务的单次EEG实验进行分类;Li等^[15]基于静息和P300任务EEG数据集,提取并结合静息和任务两种状态的固有大脑网络空间模式特征对精神分裂症进行识别。在运用时频特征方面,Yang等^[16]通过注意力机制融合门控循环单元获取EEG历史信息特征与时间卷积网络挖掘得到的多层特征,以此实现更准确的抑郁症识别;Tang等^[17]并

行提取EEG时间序列中的统计特征、形态特征和非线性特征,并转化为时频特征,最后以特征融合的结果进行癫痫的发作检测。上述成果可以反映出EEG的空频特征与时频特征在精神障碍研究领域都有很好的表现,然而只在单域中挖掘特征无法全面分析EEG的变化情况,因此本研究将进一步探究挖掘EEG多域特征的方法。

本研究旨在开发一个基于时空图卷积神经网络(Spatial-Temporal Graph Convolutional Neural Network, ST-GCN)分析时频空三维特征的深度学习模型,通过大脑不同区域之间的功能连通性并结合各通道内EEG信号的时频信号分析精神分裂症患者与健康对照者之间的EEG信号差异。通过记录精神分裂症患者和健康对照者的EEG数据来测试基于小波相干性系数(Wavelet Coherence, WC)构造的邻接矩阵;ST-GCN能联合利用跨信道拓扑连接性特征和信道特定时间特征。实验结果表明综合分析EEG中的时频空信息能更全面地探究大脑中的电生理特征。

1 资料与方法

1.1 数据集

本研究数据来源于开放数据集Zenodo^[18]。该数据集共记录71名受试者(42名精神分裂症患者与29名健康受试者),包括32个通道,256 Hz采样率的EEG数据。实验建立具有奖惩机制的任务,每次实验金钱收益或损失设定为0.05美元。任务要求将4个简单形状以伪随机方式呈现给受试者48次(试验次数共192次),受试者需要通过按下按钮(Go)或停止回应(NoGo)获得奖励(Win)或避免惩罚(Avoid)。因此,实验将包含以下4种刺激:Go-to-Win、Go-to-Avoid、NoGo-to-Win和NoGo-to-Avoid。其中,设定刺激所获得的奖惩概率为80%,要求受试者快速反应赢取更多奖励。

实验开始时,屏幕上出现十字,持续0.40~0.60 s;然后进入刺激阶段,屏幕随机呈现一幅刺激图片停留1.00 s;接下来进入0.25~2.00 s的无反应期和2.50 s的反应期;最后屏幕出现1.00 s十字后显示反馈图像,并停留2.00 s。根据以上不同刺激可将反馈类型分为正反馈、负反馈和中性反馈^[19]。本研究仅对负反馈诱发事件的相关电位进行分析,将EEG进行标准EEG预处理后选择19个EEG通道(FP1、FP2、Fz、F3、F4、F7、T7、T8、C3、C4、Cz、Pz、P4、P3、F8、P8、P7、O2、O1)进行分析。

1.2 ST-GCN

从Gori等^[20]率先提出图神经网络(Graph Neural

Network, GNN)开始,GNN被广泛运用于非欧式结构数据的特征分析中。目前,有两种将卷积推广到结构图数据形式的基本方法:基于空间的GNN和基于频谱的GNN。基于空间的GNN通过将顶点重新排列成可以通过正常卷积运算处理的特定网格形式来定义图卷积^[21-22]。Bruna等^[23]通过在频谱域中应用卷积和图形傅里叶变换,提出基于频谱的GCN。此后,对基于频谱的GNN进行改进和扩展的研究不断增加^[24-25],Defferrard等^[24]将基于频谱的GNN算法复杂度从 $O(n^2)$ 下降到 $O(n)$ 。

在图处理领域,GNN可以将复杂的网络结构嵌入有意义的低维的表示特征中^[26]。在二维图像处理中,图像的每个像素点可以被视为一个节点,其像素值是由其周围像素点通过一定的滤波器过滤得到的,二维卷积就是取每个节点相邻的一定范围内的节点像素值并进行加权平均。当将图的信息从二维推广到高维时,通过对每一个节点的邻域信息进行

加权平均的操作就是图卷积了。与二维不同的是,高维节点的邻域更复杂、无序。

如图1a所示,本研究所提出的ST-GCN模型整体由两个时空卷积块组成,每个时空卷积块都依次由时间一维卷积层、空间图卷积层和时间一维卷积层组成。在每个时空卷积块中使用层归一化以防止过度拟合,时间一维卷积层提取EEG信道X中的时频特征,空间图卷积层将结合信道X及其邻接矩阵 W 统一处理,提取时域与空域的相关特征。最终在扁平层整合所有特征后生成最终的结果。为进行对比,本研究也设计了如图1b所示的经典图卷积神经网络(Only-GCN)以及如图1c所示的经典时频卷积神经网络(Only-TCN)。与ST-GCN相比,Only-GCN在模型中不考虑时间对EEG信号的影响,而Only-TCN不需要输入EEG信道X的邻接矩阵 W ,并且在模型中也没有使用空间图卷积层。

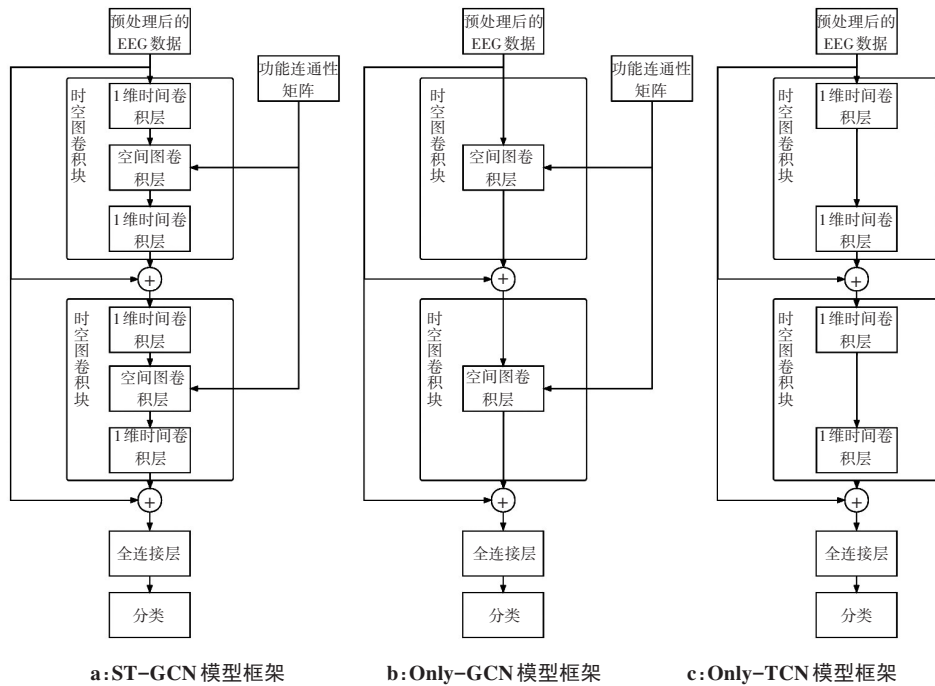


图1 不同深度学习模型的流程图

Figure 1 Flowcharts of different deep learning models

1.2.1 空间图卷积方法 定义 $*g$ 用于将信号 $x \in R^n$ 与核 θ 相乘:

$$\theta * g x = \theta(L)x = \theta(U\Lambda U^T)x = U\theta(\Lambda)U^T x \quad (1)$$

其中, $L = I_n - D^{-\frac{1}{2}}WD^{-\frac{1}{2}} = U\Lambda U^T$, $U \in R^{n \times n}$ 是 L 归一化后的拉普拉斯特征向量矩阵, I_n 是单位矩阵, $D \in R^{n \times n}$ 是对角矩阵, $D_{ii} = \sum_{j=0}^n W_{ij}$, $\Lambda \in R^{n \times n}$ 是 L 的特征值对角

矩阵。

通过这种计算方式将信号序列 x 通过核 θ 进行滤波,但由于计算空间复杂度过高,达到 $O(n^2)$,所以考虑使用切比雪夫多项式以及一阶近似简化计算: θ 被简化关于 Λ 的多项式 $\theta\Lambda = \sum_{k=0}^{K-1} \theta_k \Lambda^k$,其中, θ_k 为多项式系数向量, K 是卷积核大小,而当 Λ 修改为 $2A/\lambda_{\max} - I_n$ (λ_{\max} 是拉普拉斯矩阵 L 的最大特征值)时,

切比雪夫多项式 $T_k(x)$ 是经典的核的近似替代物,因此上式可改写为: $\Theta A \approx \sum_{k=0}^{K-1} \theta_k T_k(A)$ 。一维信号的卷积运算结果可近似写成式(2):

$$\Theta^* g x = \Theta(L) x \approx \sum_{k=0}^{K-1} \theta_k T_k(L) x \quad (2)$$

其中, $T_k(L) \in R^{n \times n}$ 是 K 阶切比雪夫式将修改为 $2L/\lambda_{\max} - I_n$ 的 L 代入求值得到的结果。此时的计算量可以缩减到 $O(K|\varepsilon|)$, 为进一步缩减计算量, 如果 λ_{\max} 可以近似取到 2, 那么 $2L/\lambda_{\max} - I_n \approx L - I_n = -D^{-\frac{1}{2}}WD^{-\frac{1}{2}}$, 此时的计算结果可近似写为:

$$\Theta^* g x \approx \theta_0 x - \theta_1 D^{-\frac{1}{2}}WD^{-\frac{1}{2}}x \quad (3)$$

为减少运算时涉及的参数, θ_0 与 θ_1 将被一个参数取代, 若使得 $\theta_0 = -\theta_1 = \theta$, $\tilde{W} = W + I_n$, $\tilde{D}_{ii} = \sum_{j=0}^n \tilde{W}_{ij}$, 则一维信号的图卷积运算的最终结果可写为:

$$\Theta^* g x = \theta \left(I_n + D^{-\frac{1}{2}}WD^{-\frac{1}{2}} \right) x = \theta \left(D^{-\frac{1}{2}}\tilde{W}D^{-\frac{1}{2}} \right) x \quad (4)$$

将这种思路推广到有着 C_i 个通道的信号可以得到:

$$y_j = \sum_{i=0}^{C_i} \theta_{ij}(L) x_i \quad (5)$$

其中, $1 \leq j \leq C_0$ (C_0 是指输出通道数), 因此共有 $C_0 \times C_i$ 个切比雪夫系数待定。

1.2.2 一维时间卷积 一维时间卷积层主要由 5 个部分组成: 膨胀因果卷积、权重归一化、激活函数、dropout 模块和残差连接, 其中, 膨胀因果卷积可以分为膨胀、因果和卷积这 3 部分。卷积是指 CNN 中的卷积, 是卷积核在数据上进行的一种滑动运算操作; 膨胀是指允许卷积时的输入存在间隔采样; 因果是指第 i 层中 t 时刻的数据, 只依赖于 $(i-1)$ 层 t 时刻及其以前的值的影响。因果卷积可以在训练的时候摒弃对未来数据的读取, 是一种严格的时间约束模型。残差连接不仅可以使网络拥有跨层传递信息的功能, 而且可以保证输入输出的一致性。

1.3 WC

WC 通常被认为是一种定性估计量, 可以表示信号之间在时频域的动态关系:

$$WC_{xy}(t, f) = \frac{|CW_{xy}(t, f)|}{|CW_{xx}(t, f) \times CW_{yy}(t, f)|^{\frac{1}{2}}} \quad (6)$$

其中, $CW_{xx}(t, f)$ 、 $CW_{xy}(t, f)$ 、 $CW_{yy}(t, f)$ 分别是通道 X 、通道 X, Y 、通道 Y, Y 之间在时间 t 与频率 f 附近的小波交叉谱。

1.4 评价指标

为了评估分类方法的性能, 选择准确率、召回

率、精确度和 F1 分数来评估模型的性能, 分别使用式(7)~式(10)表示:

$$\text{准确率} = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

$$\text{召回率} = \frac{TP}{TP + FN} \quad (8)$$

$$\text{精确度} = \frac{TP}{TP + FP} \quad (9)$$

$$F1 = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (10)$$

其中, TP 代表真阳性, TN 代表真阴性, FP 代表假阳性, FN 代表假阴性。

2 结果

2.1 对比实验

将本文方法与其他 3 种分类器的分类方法进行比较, 分别是支持向量机 (Support Vector Machine, SVM)、线性判别式分析 (Linear Discriminant Analysis, LDA) 和 K 最邻近 (K-Nearest Neighbor, KNN) 分类算法, 3 种方法都是先提取功率谱密度 (Power Spectral Density, PSD) 特征后放入分类器进行分类。从表 1 可以看出, 3 种分类器中 KNN 的分类结果最好, 准确率也只达到 77.56%, 而 SVM 和 LDA 的分类准确率为 69.02% 和 69.28%。由于这 3 种分类器都无法全面分析包含在 EEG 信号中的时频特征和空频特征这些隐含信息, 分类准确率无法到达 ST-GCN 的标准, 这也能说明与传统分类器相比, ST-GCN 能更准确地诊断出精神分裂症患者, 准确率达 96.32%。

表 1 传统分类器方法与 ST-GCN 的分类结果 (%)
Table 1 Classification results of traditional classifier method and ST-GCN (%)

方法	准确率	召回率	精确率	F1 分数
PSD+SVM	69.02	73.43	65.91	69.47
PSD+KNN	77.56	87.29	76.10	81.31
PSD+LDA	69.28	65.92	66.01	65.96
ST-GCN	96.32	91.02	95.60	93.25

2.2 消融实验

为评估图卷积层与时间一维卷积层在模型中的有效性, 本研究分别使用 Only-GCN 与 Only-TCN 进行消融实验。在 Only-GCN 中, 删除全部 4 个一维时间卷积层; 在 Only-TCN 中, 删除两个 GCN 层。将两个消融模型与完整模型进行比较, 结果如表 2 所示。空间图卷积层和一维时间卷积层都可以提高分类精度, 同时整合空间图卷积层和一维时间卷积层的

ST-GCN 模型能达到更高的分类精度,说明同时对 EEG 信号中的时频特征和空频特征进行提取分析能更好地聚合 EEG 信号特征。

表 2 消融实验结果(%)
Table 2 Ablation experiment results (%)

方法	准确率	召回率	精确率	F1 分数
ST-GCN	96.32	91.02	95.60	93.25
Only-GCN	91.63	89.21	93.45	91.27
Only-TCN	93.39	90.81	91.94	91.37

2.3 分类性能

为保证模型分类的准确度,本研究采用 K-Fold 交叉验证来验证模型的稳定性,将完成预处理并构建对应邻接矩阵的数据集分成 10 份,依次将每份数据作为测试集,其余 9 份作为训练集分别进行学习。图 2 展示了在十折交叉验证过程中每次的验证集准确率,可以看到 10 次结果准确率较为接近,验证了模型结果的稳定性。




图 2 十折交叉验证结果
Figure 2 Results of ten-fold cross-validation

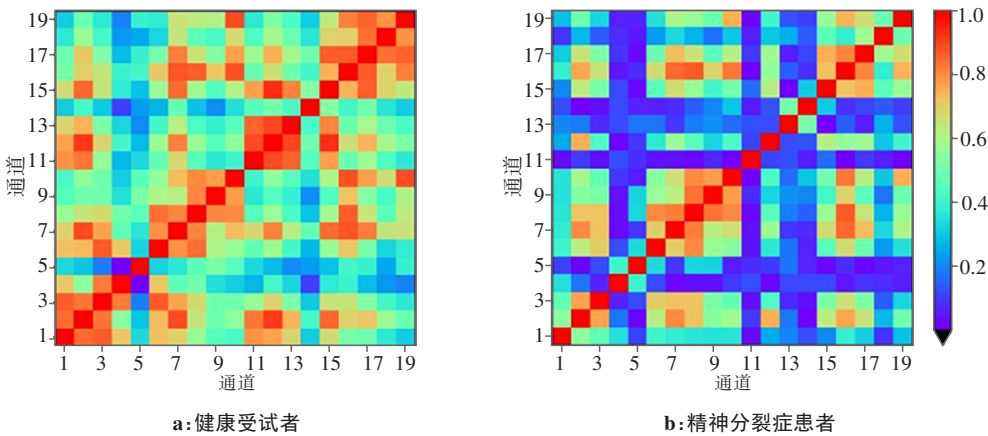


图 3 WC 功能连接矩阵
Figure 3 WC functional connectivity matrix

2.4 WC 连通性分析

本研究选择从刺激开始前 1 s 到刺激开始后 2 s 的时间窗口和 0.1~30.0 Hz 的频率范围,得到每个受试者任务相关的加权功能连接矩阵,如图 3 所示。图中横纵坐标均为 19 通道,矩阵值为相应两通道间的 EEG 信号关联强度。由此可知,健康受试者和精神分裂症患者 WC 脑功能连接有较为明显的差异,健康受试者的 WC 连接强度普遍高于精神分裂症患者。

3 结 语

本研究提出一种基于 ST-GCN 的精神分裂症患者分类方法。通过综合提取分析 EEG 信号中的时频特征与空频特征并借由 ST-GCN 这一模型进行学习,最终对 EEG 信号进行分析分类,解决传统分类器方法无法全面分析 EEG 信号中的时频空特征导致分类精度不够理想的问题。模型由 2 个空间图卷积层和 4 个一维时间卷积层以及 1 个分类模块混合组成。空间图卷积层通过根据 WC 生成的邻接矩阵与 EEG 信号序列获得空频特征,一维时间卷积层通过根据时间距离远近改变影响卷积权重的方式获得时频特征。提出的模型对数据集 Zenodo 进行分析和评估,并进行对比以及消融实验。对比实验结果表明 ST-GCN 模型的性能优于传统的特征分类器,证明了分类方法的有效性。消融实验结果表明时频特征和空频特征的提取分析都有助于提高分类的准确度,证明了将提取到的时频特征与空频特征混合分析并进行分类是合理且有意义的。本研究也证实了 WC 是可以用于检验精神分裂症患者的一个生物特征。然而本研究尚未使用其他功能连通系数构造邻接矩阵进行对比,后续将进一步发掘邻接矩阵系数,并引入注意力机制来继续优化模型。

【参考文献】

- [1] Jahmunah V, Lih OS, Rajinikanth V, et al. Automated detection of schizophrenia using nonlinear signal processing methods[J]. *Artif Intell Med*, 2019, 100: 101698.
- [2] Owen MJ, Sawa A, Mortensen PB. Schizophrenia[J]. *Lancet*, 2016, 388(10039): 86-97.
- [3] Shoeibi A, Sadeghi D, Moridian P, et al. Automatic diagnosis of schizophrenia in EEG signals using CNN-LSTM models[J]. *Front Neuroinform*, 2021, 15: 777977.
- [4] Sun J, Cao R, Zhou M, et al. A hybrid deep neural network for classification of schizophrenia using EEG Data[J]. *Sci Rep*, 2021, 11(1): 4706.
- [5] Sharma M, Patel S, Acharya UR. Automated detection of abnormal EEG signals using localized wavelet filter banks[J]. *Pattern Recogn Lett*, 2020, 133: 188-194.
- [6] 田程, 胡廷, 曹锐, 等. 模糊熵和深度学习在精神分裂症中的应用研究[J]. *计算机工程与应用*, 2020, 56(3): 152-158.
Tian C, Hu T, Cao R, et al. Application of fuzzy entropy and deep learning in schizophrenia[J]. *Computer Engineering and Applications*, 2020, 56(3): 152-158.
- [7] 冯静雯, 赖虹宇, 邓伟, 等. 精神分裂症和抑郁症患者静息态脑电功率谱熵的对照研究[J]. *中国生物医学工程学报*, 2019, 38(4): 385-391.
Feng JW, Lai HY, Deng W, et al. The comparative study of resting state EEG's power spectral entropy between schizophrenic and depressive patients[J]. *Chinese Journal of Biomedical Engineering*, 2019, 38(4): 385-391.
- [8] 段子敬, 赵冰蕾, 李春波, 等. 基于特征融合方法的轻微认知衰退静息态脑电数据自动检测技术研究[J]. *计算机应用研究*, 2022, 39(4): 1137-1142.
Duan ZJ, Zhao BL, Li CB, et al. Automatic detection technology of resting state EEG data for mild cognitive decline based on convolutional neural network[J]. *Application Research of Computers*, 2022, 39(4): 1137-1142.
- [9] De Miras JR, Ibáñez-Molina A, Soriano M, et al. Schizophrenia classification using machine learning on resting state EEG signal[J]. *Biomed Signal Proces Control*, 2023, 79: 104233.
- [10] Usman SM, Khalid S, Akhtar R, et al. Using scalp EEG and intracranial EEG signals for predicting epileptic seizures: review of available methodologies[J]. *Seizure*, 2019, 71: 258-269.
- [11] Usman SM, Khalid S, Bashir Z. Epileptic seizure prediction using scalp electroencephalogram signals[J]. *Biocybern Biomed Eng*, 2021, 41(1): 211-220.
- [12] Jana R, Mukherjee I. Deep learning based efficient epileptic seizure prediction with EEG channel optimization[J]. *Biomed Signal Proces Control*, 2021, 68: 102767.
- [13] Hassan F, Hussain SF, Qaisar SM. Fusion of multivariate EEG signals for schizophrenia detection using CNN and machine learning techniques[J]. *Inform Fusion*, 2023, 92: 466-478.
- [14] Li X, Fan H, Wang H, et al. Common spatial patterns combined with phase synchronization information for classification of EEG signals[J]. *Biomed Signal Proces Control*, 2019, 52: 248-256.
- [15] Li F, Wang J, Liao Y, et al. Differentiation of schizophrenia by combining the spatial EEG brain network patterns of rest and task P300[J]. *IEEE Trans Neural Syst Rehabil Eng*, 2019, 27(4): 594-602.
- [16] Yang L, Wang Y, Zhu X, et al. A gated temporal-separable attention network for EEG-based depression recognition[J]. *Comput Biol Med*, 2023, 157: 106782.
- [17] Tang FG, Liu Y, Li Y, et al. A unified multi-level spectral-temporal feature learning framework for patient-specific seizure onset detection in EEG signals[J]. *Knowl-Based Syst*, 2020, 205: 106152.
- [18] Albrecht MA, Waltz JA, Cavanagh JF, et al. Reduction of pavlovian bias in schizophrenia: enhanced effects in clozapine-administered patients[J]. *PLoS One*, 2016, 11(4): e0152781.
- [19] Zhao Z, Wang C, Yuan Q, et al. Dynamic changes of brain networks during feedback-related processing of reinforcement learning in schizophrenia[J]. *Brain Res*, 2020, 1746: 146979.
- [20] Gori M, Monfardini G, Scarselli F. A new model for learning in graph domains[C]//*Proceedings 2005 IEEE International Joint Conference on Neural Networks*. IEEE, 2005, 2: 729-734.
- [21] Niepert M, Ahmed M, Kutzkov K. Learning convolutional neural networks for graphs[C]//*International Conference on Machine Learning*. PMLR, 2016: 2014-2023.
- [22] Yu B, Yin H, Zhu Z. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[C]//*Proceedings of the 27th International Joint Conference on Artificial Intelligence*. 2018: 3634-3640.
- [23] Bruna J, Zaremba W, Szlam A, et al. Spectral networks and deep locally connected networks on graphs[C]//*2nd International Conference on Learning Representations*. 2013.
- [24] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering[J]. *Adv Neural Inf Process Syst*, 2016, 29: 3844-3852.
- [25] Levie R, Monti F, Bresson X, et al. Cayleynets: graph convolutional neural networks with complex rational spectral filters[J]. *IEEE Trans Signal Process*, 2018, 67(1): 97-109.
- [26] Zhao X, Wu J, Peng H, et al. Deep reinforcement learning guided graph neural networks for brain network analysis[J]. *Neural Netw*, 2022, 154: 56-67.

(编辑:谭斯允)