

一种基于EEG信号的抑郁症早期筛查方法

任书瑶, 宋江玲, 张瑞

引用本文

任书瑶, 宋江玲, 张瑞. 一种基于EEG信号的抑郁症早期筛查方法[J]. 计算机科学, 2023, 50(11A): 221100139-6.

REN Shuyao, SONG Jiangling, ZHANG Rui. [Early Screening Method for Depression Based on EEG Signal](#) [J]. Computer Science, 2023, 50(11A): 221100139-6.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于多重有向加权图与卷积神经网络的脑电情感识别](#)

EEG Emotion Recognition Based on Multiple Directed Weighted Graph and Convolutional Neural Network

计算机科学, 2023, 50(6A): 220600128-8. <https://doi.org/10.11896/jsjcx.220600128>

[基于多尺度的稀疏脑功能超网络构建及多特征融合分类研究](#)

Construction and Multi-feature Fusion Classification Research Based on Multi-scale Sparse Brain Functional Hyper-network

计算机科学, 2022, 49(8): 257-266. <https://doi.org/10.11896/jsjcx.210600094>

[基于数据增广和模型集成策略的图神经网络在抑郁症识别上的应用](#)

Application of Graph Neural Network Based on Data Augmentation and Model Ensemble in Depression Recognition

计算机科学, 2022, 49(7): 57-63. <https://doi.org/10.11896/jsjcx.210800070>

[基于多特征融合的重叠组套索脑功能超网络构建及分类](#)

Construction and Classification of Brain Function Hypernetwork Based on Overlapping Group Lasso with Multi-feature Fusion

计算机科学, 2022, 49(5): 206-211. <https://doi.org/10.11896/jsjcx.210300049>

[基于时空自适应图卷积神经网络的脑电信号情绪识别](#)

EEG Emotion Recognition Based on Spatiotemporal Self-Adaptive Graph Convolutional Neural Network

计算机科学, 2022, 49(4): 30-36. <https://doi.org/10.11896/jsjcx.210900200>

一种基于 EEG 信号的抑郁症早期筛查方法

任书瑶 宋江玲 张 瑞

西北大学医学大数据研究中心 西安 710127

(shuyao_ren@yeah.net)

摘 要 抑郁症作为一类常见的、可治愈型的精神类疾病,若能在早期阶段对其进行有效筛查(即早期筛查)并及时采取相应的治疗手段,则可有效控制病情的进一步加重,甚至彻底治愈。传统的抑郁症诊断方法主要是医生通过患者的临床表现及临床检查(主要为诊断量表)进行综合判断,但诊断结果的准确与否严重依赖于医生的临床经验以及患者的高度配合。同时,由于抑郁症早期患者往往缺乏明显的病症表征,也极大增加了漏诊误诊的可能性。相关研究表明,脑电图(Electroencephalogram, EEG)能够反应受试者的精神状态,这为抑郁症的早期筛查提供了一种有效途径。基于此,以 EEG 信号为数据源,提出了一种基于 EEG 信号与深度学习的抑郁症早期筛查方法。首先,结合分段处理、频域转化等方法,对 EEG 信号进行时-频-空特征序列的提取;其次,基于所提特征序列与深度学习,构建了一种深度混合模型,通过训练模型完成正常人与轻度抑郁症患者的有效识别;最后,在公开数据集 MODMA 上验证所提方法的可行性与有效性。实验结果显示,早期筛查准确率为 82.64%,召回率为 78.42%,灵敏度为 75.37%。

关键词 抑郁症;脑电信号;早期筛查;时-频-空特征序列;深度混合模型

中图法分类号 TP391

Early Screening Method for Depression Based on EEG Signal

REN Shuyao, SONG Jiangling and ZHANG Rui

Medical Big Data Research Center, Northwest University, Xi'an 710127, China

Abstract Depression is a common and curable psychiatric disorder. If a prompt diagnosis can be taken at the early stage of depression(early screening), appropriate treatment could effectively control the depression progression or even cure it. The traditional method of diagnosing depression is a comprehensive judgment from doctors by clinical manifestations and clinical examination(diagnostic scales, etc.), but the diagnosis accuracy relies heavily on the clinical experience of the physician and the inclination of cooperation from the patient. In addition, early-stage symptoms of depression are difficult to observe, making traditional diagnostic methods susceptible to underdiagnosis. Research indicates that electroencephalogram(EEG) responds effectively to the mental state of subjects from a physiological perspective, which provides an effective way of early screening for depression. On this basis, this paper proposes an EEG-based method combined with deep learning models for early screening of depression. First, extracting the temporal-spectral-spatial sequences of EEG signals by segmentation processing, frequency domain transformation, etc. Secondly, constructing a hybrid deep neural network based on extracted sequences to identify the EEG signals of mild depression patients. Finally, the feasibility and effectiveness of proposed method are verified by conducting numerical experiments in the public datasets MODMA. Numerical results show that the accuracy, recall rate and sensitivity of the proposed method is 82.64%, 78.42%, and 75.37%, respectively.

Keywords Depression, Electroencephalogram, Early screening, Temporal-Spectral-Spatial sequences, Hybrid deep neural networks

1 引言

抑郁症又称抑郁障碍,是一种常见的精神疾病^[1],其临床表现包括持续性情绪低落、自我评价降低、思维迟缓、注意力障碍、社会行为改变等,严重可伴有自杀念头或行为。临床中

根据患者症状表现以及病情的严重程度,可将抑郁症分为轻度、中度、重度 3 个等级^[2]。

目前,抑郁症在全球范围均呈现高患病率、低识别率的情况。据世界卫生组织统计,近十年抑郁症患者总人数增长了 18%,但确诊率不足 20%^[3]。而抑郁症作为一类可治愈的

基金项目:国家自然科学基金(12071369, 6200189);陕西省自然科学基金(2021JQ-430);陕西省重点研发计划(2019ZDLSF02-09-02, 2017ZDXM-Y-095)

This work was supported by the National Natural Science Foundation of China(12071369, 6200189), Natural Science Foundation of Shaanxi Province, China(2021JQ-430) and Key R & D Program of Shaanxi Province, China(2019ZDLSF02-09-02, 2017ZDXM-Y-095).

通信作者:张瑞(rzhang@nwu.edu.cn)

精神疾病,若能在早期(即轻度抑郁症阶段)对患者进行及时筛查,则84%的抑郁症患者能够通过相应的药物及心理治疗得到有效控制,缓解病情,甚至彻底治愈^[4-5]。

目前在临床上,主要由医生问询患者的方式完成诊断量表(如PHQ-9),并结合常规辅助检查以及对患者行为进行观测后综合评估来完成对抑郁症的诊断^[6]。这一传统诊断方法严重依赖于医生的临床经验,同时还需要患者的高度配合。然而,在实际操作过程中,患者出于病耻感等原因,对量表问题存在刻意回避、隐瞒等行为,使得临床诊断的难度增大。此外,对于轻度抑郁症患者,由于其临床表现与正常人处于低落情绪时的表现非常类似,并不具有明显的病症表征,因而使得抑郁症在早期筛查中极易出现漏诊、误诊的情况。

脑电图(Electroencephalogram, EEG)是一种神经元电活动的记录手段,能够有效反应大脑的活动规律^[7]。相关研究表明,脑电信号可以有效反应受试者的精神状态^[8]。抑郁症作为一种典型的精神类疾病,其患者的EEG信号与正常人存在显著差异,这为抑郁症的早期筛查提供了一种有效途径^[9-11]。

基于此,本文以EEG信号为数据源,提出了一种新的基于EEG信号与深度学习的抑郁症早期筛查方法。首先,结合分段处理、频域转化等方法,对EEG信号进行时-频-空特征序列的提取;其次,基于所提特征序列与深度学习,构建了一种深度混合模型,用于识别正常脑电信号与轻度抑郁症患者脑电信号;最后,在公开数据集MODMA上验证所提方法的可行性与有效性。

2 相关工作

抑郁症辅助诊断本质上是一个模式识别问题,主要方法包括两大类:基于机器学习的方法以及基于深度学习的方法。前者主要是从EEG中提取能够区别正常人与抑郁症患者的显著特征(如功率谱密度^[12]、Hurst指数^[13]),并结合分类器(如KNN^[14]、支持向量机^[15])完成二者的有效分类。其核心步骤是设计能够有效区别正常人与抑郁症患者的EEG信号特征,而这一过程属于启发式,即需要领域知识与主观设计相结合。为了克服上述不足,越来越多的研究人员逐渐开始聚焦于具有强大自主学习能力的深度学习模型。基于深度学习的抑郁症辅助诊断方法主要是通过构建各类深度网络来自主学习EEG信号中的有效特征以完成分类任务。如Cai等采用深度信念网络(Deep Belief Network, DBN)进行抑郁症患者EEG信号的特征提取,并结合K近邻算法完成抑郁症患者的自动检测,所提方法以79.27%的准确率区分92名抑郁症患者和121名健康受试者^[16]。Mao则进一步通过深度学习对抑郁症患者的EEG信号进行端到端的学习,在卷积神经网络模型上以73.53%的准确率区分抑郁症患者和健康受试者^[17]。然而,现有工作聚焦于区分抑郁症患者和健康受试者,很少有工作面向轻度抑郁症患者的识别,即抑郁症的早期筛查;此外,已有面向抑郁症患者EEG信号识别的研究中仅有少量工作考虑到脑功能区协调作用在抑郁症病情发展过程中的重要影响,大量已有工作忽略了脑区的空间信息^[18]。

基于此,本文面向轻度抑郁症患者EEG信号的识别问题,将脑区的空间信息引入模型,设计了一种基于EEG信号

时-频-空特征序列的深度混合模型,用以识别轻度抑郁症患者的EEG信号。

3 基于EEG信号的抑郁症早期筛查方法

本章首先设计了一种时-频-空特征序列提取方法(Temporal-Spectral-Spatial Sequence, TSS Sequence),用于将EEG信号转化为三维特征立方体序列。其次基于所构建的时-频-空特征序列,设计了一种新的深度混合模型,用于识别正常脑电信号与轻度抑郁症患者脑电信号。

3.1 EEG信号时-频-空特征序列提取方法

已有研究表明,EEG信号的频域信息更能反映抑郁症患者与正常人之间的差异^[19]。同时,抑郁症的典型表征为大脑不同功能区域之间的连通作用出现异常^[20]。基于上述发现,本文首先对EEG信号在时域上进行分段处理,随后对分段后的EEG信号实施频域转化,进而得到EEG信号的频域特征序列;进一步考虑脑区的空间位置信息,本文设计了一种新的EEG信号的时-频-空特征序列构建方法。主要步骤总结如算法1所示。

算法1 EEG信号时-频-空特征序列提取算法

步骤1 EEG信号的频域转化

给定EEG信号 $X = \{x_{i,n}\}_{n=1}^N$ ($i=1, \dots, M$),其中 N 表示脑电通道数, M 表示信号的样本点个数。采用非重叠Hanning窗对信号 X 进行分段处理,窗口长度为 T ,则共获得 S 个脑电片段($S = \lfloor \frac{M}{T} \rfloor$)。其中第 j 个片段中第 n 个通道的脑电信号可表示为 $\tilde{X}_n^j = \{x_{i,n}^j\}_{n=1}^N$ ($j=1, \dots, S$)。

对每一个 \tilde{X}_n^j ,采用Fourier变换^[21],将其转换为对应的频域信号

$$\widehat{\tilde{X}_n^j}(\omega): \quad \widehat{\tilde{X}_n^j}(\omega) = \frac{1}{m} \sum_{i=1}^m x_{i,n}^j * e^{-\frac{2\pi i \omega}{m}} \quad (1)$$

其中, ω 表示信号频率且 $\omega \in [0.5 \sim 50 \text{ Hz}]$, m 表示脑电片段样本点个数。

步骤2 频域特征序列提取

研究表明,非平稳的EEG信号可分为一组近似平稳的短时信号片段^[22]。因此 $\widehat{\tilde{X}_n^j}$ 近似平稳,从而对 $\forall \omega, j$,有 $\widehat{\tilde{X}_n^j}(\omega) \sim N(\mu_{j,\omega}, \sigma_{j,\omega}^2)$ 。

据此计算每一 $\widehat{\tilde{X}_n^j}(\omega)$ 的微分熵(Differential Entropy, DE):

$$DE_n^j(\omega) = \frac{1}{2} \log(2\pi e \sigma_{j,\omega}^2) \quad (2)$$

$DE_n^j(\omega)$ 是以 j 为变量的频域特征序列,其中 $\sigma_{j,\omega}^2$ 为 $\widehat{\tilde{X}_n^j}(\omega)$ 所服从高斯分布的方差, e 为自然常数。

当 $\omega \in [0.5 \sim 4 \text{ Hz}]$ 时,可进一步计算 δ 波段微分熵:

$$DE_{\delta,n}^j = \sum_{\omega=0.5}^4 \frac{1}{2} \log(2\pi e \sigma_{j,\omega}^2) \quad (3)$$

同理,可计算 $\theta[4 \sim 8 \text{ Hz}]$, $\alpha[8 \sim 14 \text{ Hz}]$, $\beta[14 \sim 31 \text{ Hz}]$ 和 $\gamma[31 \sim 50 \text{ Hz}]$ 4个波段的微分熵。

步骤3 EEG信号的时-频-空特征序列提取

首先,根据电极在10-5导联定位系统空间上的邻接关系,将其在二维平面进行重构,生成大小为 $K \times K$ 的电极邻接图(如图1左所示),其中 N 的下角标与电极名称一致^[23]。

其次,对 $DE_{m,n}^j$ ($m = \delta, \theta, \alpha, \beta, n = 1, 2, \dots, N; j = 1, 2, \dots, S$),按照其所对应的电极输入邻接图 N_n 中,并对空缺位置补零,即可得到大小为 $K \times K$ 的二维微分熵特征图(即2D特

征图,如图 1 右所示)。将 5 个波段的 2D 特征图按照波段频率由小到大依次堆叠,得到大小为 $5 \times K \times K$ 的三维特征立方体

(即 3D 特征立方体)。最终, S 个 3D 特征立方体构成特征序列,图 2 所示为 EEG 信号时-频-空特征序列提取方法示意图。

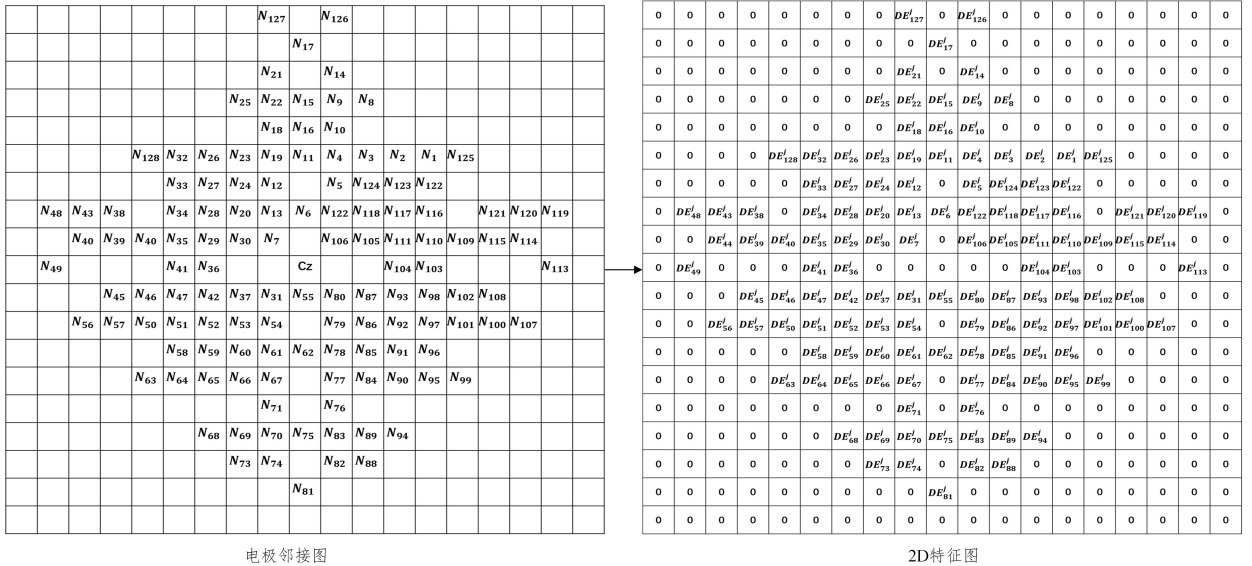


图 1 2D 特征图的生成(128 导)

Fig. 1 2D feature map generation(128 electrodes)

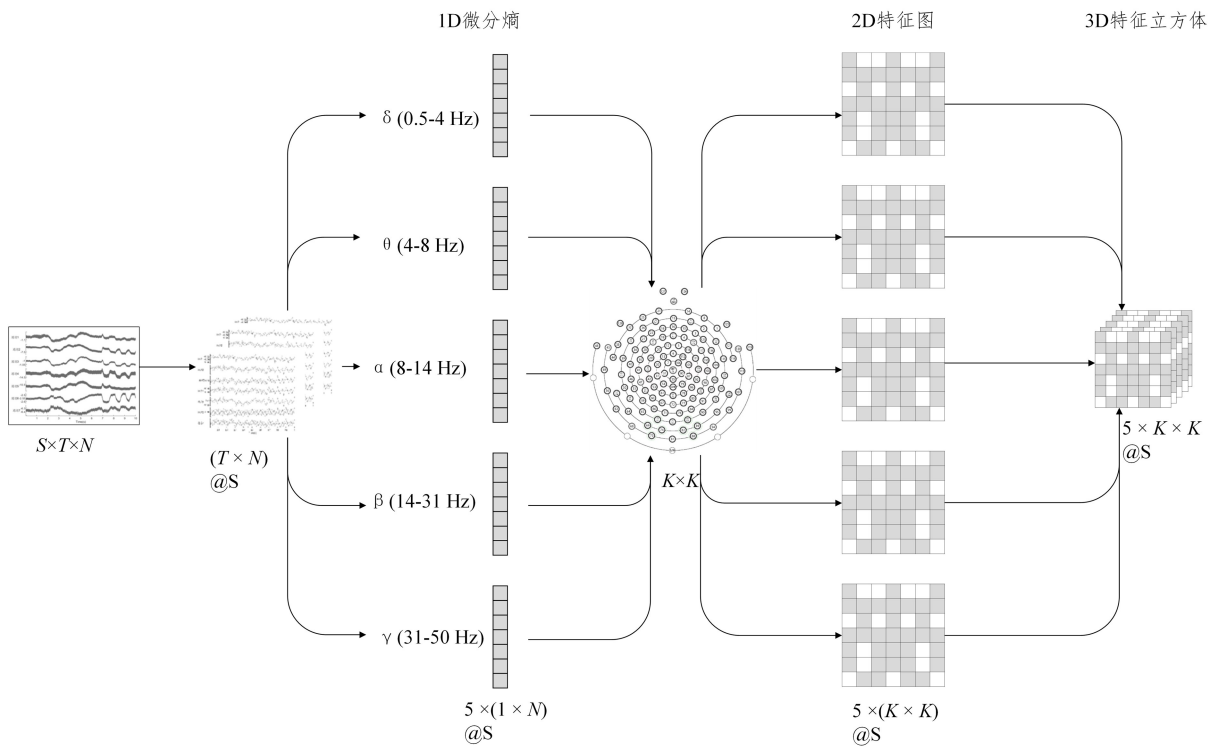


图 2 EEG 信号时-频-空特征序列提取方法

Fig. 2 EEG signal temporal-spectral-spatial sequence extraction method

3.2 基于时-频-空特征序列的深度混合模型

在上文基础上,进一步搭建了一种基于 EEG 时-频-空特征序列的深度混合模型(TSS Sequence Based Hybrid Deep Neural Networks, TSS-HDNN),用以实现抑郁症的早期筛查。模型由 3 个子模块构成,分别是卷积网络模块(Convolutional Neural Network, CNN)、基于时间注意力机制的长短期记忆网络模块(Temporal Attention Based Long Short Term Memory Network, TA-LSTM)以及全连接网络模块(Fully Connected Neural Network, FCNN)(如图 3 虚线框中所示)。

1)CNN 模块

所构建的卷积网络模块包含连续的 4 个卷积层和 1 个全连接层。卷积核大小均为为 3×3 ,卷积步长为 1,卷积核个数依次为 32,64,128,32,用以学习输入信号不同尺度的特征。在卷积运算中,采用零填充策略防止 3D 特征立方体边缘信息丢失。全连接层为该模块的最后一层,用以对所学特征进行整合,最终输出为一维特征向量 F 。

将 S 个 3D 特征立方体依次输入卷积网络模块,最终可得到包含 S 个一维特征向量的序列。

2) TA-LSTM 模块

为了获得上述一维特征向量序列中蕴含的时域信息,将其依次输入双层 LSTM 进行学习,且每层包含 128 个神经元。同时,考虑到轻度抑郁症患者与正常受试者 EEG 信号之间的差异可能只在某些时刻显著,为捕捉显著时刻的有效信息,进而在 LSTM 中引入时间注意力机制,即计算时间特征权重并对输出层进行赋权。

时间注意力机制通过 LSTM 中神经元的隐藏状态构建,记第 i 层第 j 个神经元为 $A_{i,j}$,其隐藏状态 $H_{i,j}$ 计算方法如下:

$$H_{i,j} = O_{i,j} * \tanh(f_{i,j} * C_{i,j-1} + I_{i,j} * \widetilde{C}_{i,j}) \quad (4)$$

其中, $C_{i,j-1}$ 为 $A_{i,j-1}$ 的单元状态, $\widetilde{C}_{i,j}$ 为 $A_{i,j}$ 的临时单元状态, $O_{i,j}$, $f_{i,j}$, $I_{i,j}$ 分别表示 $A_{i,j}$ 的输出门、遗忘门和记忆门。

定义 $Atten_{i,j}^{Temporal}$ 为 $H_{i,j}$ 的时间特征:

$$Atten_{i,j}^{Temporal} = \tanh(W_h H_{i,j} + b_h) \quad (5)$$

其中, W_h 为 $Atten_{i,j}^{Temporal}$ 的权重矩阵, b_h 为 $Atten_{i,j}^{Temporal}$ 的偏置项。

在此基础上,计算时间特征权重 $\alpha_{i,j}$ 为:

$$\alpha_{i,j} = \frac{\exp(Atten_{i,j}^{Temporal} \cdot Atten_{2,128}^{Temporal})}{\sum_j \exp(Atten_{i,j}^{Temporal} \cdot Atten_{2,128}^{Temporal})} \quad (6)$$

将 $\alpha_{i,j}$ 分配到 LSTM 的输出层(即 $i=2$),得到本模块的最终输出 $Output$:

$$Output = \sum_{j=1}^{128} \alpha_{i,j} * H_{i,j} \quad (7)$$

3) FCNN 模块

轻度患者识别模块由两个全连接层构成,用于完成对 EEG 信号的最终分类。第一个全连接层包含 256 个神经元,用于融合全部特征;第二个全连接层为包含两个神经元的 softmax 层,用于输出当前 EEG 信号属于每一类的概率,将概率值较大的类别作为最终输出的结果。

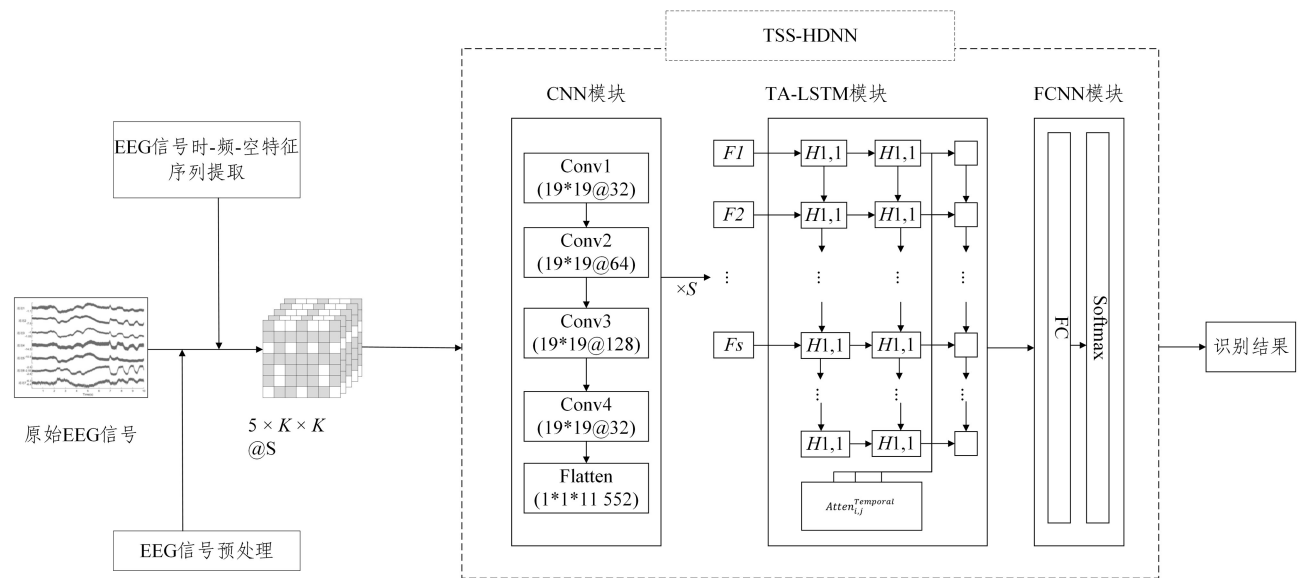


图3 基于 TSS-HDNN 模型的抑郁症早期筛查方法

Fig. 3 Early screening method for depression based on TSS-HDNN model

3.3 基于 TSS-HDNN 模型的抑郁症早期筛查方法

首先,对原始 EEG 信号进行预处理;其次,提取 EEG 信号的时-频-空特征序列并将其输入 TSS-HDNN 模型进行训练;最后,结合交叉熵损失函数和 Adam 优化算法更新模型中的参数,完成抑郁症的早期筛查(即对轻度抑郁症患者的识别)。图 3 为本文所提抑郁症早期筛查方法的示意图。

4 数值实验

4.1 数据集

本文所用实验数据来自公开数据集 MODMA Dataset,由兰州大学第二附属医院所采集的 32 名受试者的 128 通道静息态脑电数据构成^[24]。根据 PHQ-9 抑郁症诊断量表的评判标准,32 名受试者中有 24 名健康受试者(即 PHQ-9 得分 0~4 分),8 名轻度抑郁症患者(即 PHQ-9 量表得分 5~14 分)。EEG 信号的采样频率为 250 Hz,采样时长为 5 min。图 4 给出来自一个轻度抑郁症患者的 10s 的 EEG 片段(前 16 个通道)。




图4 轻度抑郁症患者 10s 的 EEG 信号片段(前 16 个通道)

Fig. 4 10s EEG signal fragment of a patient with mild depression (first 16 channels)

4.2 数据预处理

首先,对原始 EEG 信号进行裁剪处理。由于受到外界环境扰动,去除采集工作开始后 30s 和结束前 30s 的 EEG 信号,保留中间 240s 静息态 EEG 信号进行后续处理与研究;其次,分别采用 6 阶巴特沃斯 0.5~50 Hz 带通滤波器及 50 Hz 陷波滤波器对原始信号进行滤波处理,过滤掉低频漂移、高频噪声(肌电噪声、眼电噪声等)和工频信号,并对每个被试电极进行 z-score 的标准化处理;最后,考虑到所提深度学习模型

对样本量需求较大,进一步采用滑动窗(窗长为 10 s)对每条 EEG 信号进行分割,将数据集中的样本数量由 32 个扩充为 768 个。

4.3 实验结果及分析

按照 6:1:1 的比例对数据集进行随机划分,其中训练集中包含 576 个样本,验证集和测试集各包含 96 个样本。对每一样本,采用 3.1 节所提方法对其提取特征序列,并将其作为 TSS-HDNN 的输入。

所提模型在 Python3.9 的 Pytorch 框架下实现,Adam 优化器的学习步长设为 0.001,共进行 3 轮训练(即每一轮中,数据集都按照 6:1:1 的比例进行随机划分)。图 5 给出了本文模型在训练集上的准确率变化曲线。




图 5 模型准确率变化曲线

Fig. 5 Variation curve of model accuracy

消除单次实验的随机性,采用 3 轮训练的平均准确率(Accuracy)、召回率(Recall)和灵敏度(Sensitivity)作为本文模型的性能评价指标。

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

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

$$Sensitivity = \frac{TP}{TP + FP} \quad (10)$$

其中,TP 表示轻度抑郁患者被正确分类的样本个数,TN 表示健康受试者被正确分类的样本个数,FN 表示将轻度抑郁患者错误分类的样本个数,FP 表示将健康受试者错误分类的样本个数。

所提方法在测试集下 3 轮的平均准确率、召回率和灵敏度分别为 82.64%,78.42% 和 75.37%,图 6 给出了每轮测试集上的混淆矩阵。




图 6 混淆矩阵

Fig. 6 Confusion matrix

进一步,对所提深度混合模型进行消融实验。以 CNN 模型为基准模型,依次引入 LSTM 模型及时间注意力机制,用以验证所设计深度混合模型的必要性,其结果如表 1 所列。根据表中实验结果,引入 LSTM 模型后,模型的准确率、召回率及灵敏度分别提升了 6.24%,8.12%,4.85%。将时间注意力机制引入 LSTM 模块后,模型的召回率较 CNN+LSTM

模型显著提升了 6.20%,即减小了模型将轻度抑郁患者 EEG 信号误判为正常人 EEG 信号的概率。这说明所提深度混合模型中的 TA-LSTM 模块能够有效提升模型的性能。

表 1 消融实验

Table 1 Ablation experiment

方法	准确率	召回率	灵敏度
CNN	73.96	64.10	69.44
CNN+LSTM	80.20	72.22	74.29
CNN+TA-LSTM(TSS-HDNN)	82.64	78.42	75.37

(单位:%)

将本文方法与其他已有抑郁症诊断方法进行性能比较,结果如表 2 所列。为了便于比较,表中仅列出在相同数据集(MODMA 数据库的 128 通道静息态 EEG 信号数据集)进行数值实验的 4 种已有识别提出的方法。根据表中数据可以看出,本文方法相比新近提出的机器学习方法,模型的准确率、召回率分别提升了 1.04%,6.20%。与最新的深度学习模型相比,所提深度混合模型的识别准确率提升了 5.29%。其中,文献[17]所提方法的分类效果在已有方法中最佳,但本文方法在准确率及召回率上仍优于文献[17]的方法。值得注意的是,文献[25]与本文的研究目标一致(即识别轻度抑郁患者),与之相比,本文方法 TSS-HDNN 的识别性能也有显著提升,其中准确率提升了 12.7%。

表 2 TSS-HDNN 与其他已有抑郁症患者识别方法的性能对比结果

Table 2 Comparison between TSS-DHNN and existing recognition methods of depression

方法	年份	准确率	召回率
功率谱密度+LSTM ^[17]	2019	82.35	70.59
通道筛选+NLSTM ^[25]	2021	69.94	70.03
多特征融合+集成学习 ^[26]	2022	81.60	72.22
数据增广策略+GNN ^[27]	2022	77.35	—
TSS-HDNN	—	82.64	78.42

(单位:%)

结束语 本文首先设计了一种 EEG 信号的时-频-空特征序列提取方法;其次,基于所提特征序列,结合深度学习构建了 TSS-HDNN 模型,用于完成对轻度抑郁患者 EEG 信号的有效识别;最后,在公开数据集 MODMA 上验证所提方法的有效性,可得轻度患者的识别准确率为 82.64%,召回率为 78.42%,灵敏度为 75.37%。与已有方法相比,本文提出的 TSS-HDNN 模型在识别性能上表现更优,其中轻度患者的识别准确率较最新方法提升了 12.7%。所有数值实验结果均表明,本文方法能够较好地识别轻度抑郁患者的 EEG 信号,完成抑郁症的早期筛查。

除脑区的空间位置信息外,大脑不同功能区之间的拓扑结构也蕴含着脑区之间相互作用的重要信息^[28]。因此在后续研究中,考虑以恰当的方式引入大脑不同功能区之间的拓扑结构信息,进一步优化基于 EEG 信号的抑郁症辅助诊断方法。

参考文献

- [1] HAIDT J. The New Synthesis in Moral Psychology[J]. Science, 2007,316(5827):998-1002.

- [2] HARMER C. PL. 06. 01 Bridging different approaches to depression[J]. *European Neuropsychopharmacology*, 2019, 29(Supl. 6): S1-S1.
- [3] EVANS-LACKS S, AGUILAR-GAXIOLA S, AL-HAMZAWI A, et al. Socio-economic variations in the mental health treatment gap for people with anxiety, mood, and substance use disorders: results from the WHO World Mental Health (WMH) surveys[J]. *Psychological Medicine*, 2018, 48(9): 1560-1571.
- [4] HALLGREN M, NGUYEN T, LUNDIN A, et al. Prospective associations between physical activity and clinician diagnosed major depressive disorder in adults: A 13-year cohort study [J]. *Preventive Medicine*, 2018, 118: 38-43.
- [5] MAYORROYA M, PETROVA N. P. 030 Cognitive impairment and treatment of depression[J]. *European Neuropsychopharmacology*, 2019, 29(Supl. 6): S41-S41.
- [6] WANG L, KROENKE S, STUMP T, et al. Screening for perinatal depression with the Patient Health Questionnaire depression scale (PHQ-9): A systematic review and meta-analysis[J]. *General Hospital Psychiatry*, 2021, 68: 74-82.
- [7] LANDSNESS E C, GOLDSTERIN M R, PETERSON M J, et al. Antidepressant effects of selective slow wave sleep deprivation in major depression: A high-density EEG investigation[J]. *Journal of Psychiatric Research*, 2011, 45(8): 1019-1026.
- [8] AYDEMIR E, TUNCER T, DOGAN S, et al. Automated major depressive disorder detection using melamine pattern with EEG signals[J]. *Applied Intelligence*, 2021, 51(9): 6449-6466.
- [9] COSTA V. The EEG as an index of neuro-modulator balance in memory and mental illness[J]. *Frontiers in Neuroscience*, 2014, 8: 63.
- [10] BAILEY N W, HOY K E, THOMAS R H, et al. Differentiating responders and non-responders to rTMS treatment for depression after one week using resting EEG connectivity measures [J]. *Journal of Affective Disorders*, 2018, 242: 68-79.
- [11] RAJENDRA A, VIDYA S, HOJJAT A, et al. A Novel Depression Diagnosis Index Using Non-linear Features in EEG Signals [J]. *European Neurology*, 2015, 74(1/2): 79-83.
- [12] BACHMANN M, PAESKE L, KALEV K, et al. Methods for classifying depression in single channel EEG using linear and nonlinear signal analysis[J]. *Computer Methods and Programs in Biomedicine*, 2018, 155: 11-17.
- [13] MURALIDHAR B, SHREYA B, LIM W, et al. Automated Classification of Depression Electro-encephalographic Signals Using Discrete Cosine Transform and Nonlinear Dynamics [J]. *Journal of Medical Imaging and Health Informatics*, 2015, 5(3): 635-640(6).
- [14] LI X, HU B, SUN S T, et al. EEG-based mild depressive detection using feature selection methods and classifiers[J]. *Computer Methods and Programs in Biomedicine*, 2016, 136: 151-161.
- [15] SHALINI M, NISHANT G, DAYA R, et al. Detection of Depression and Scaling of Severity Using Six Channel EEG Data [J]. *Journal of Medical Systems*, 2020, 44(7): 118.
- [16] CAI H, HAN J, CHEN Y, et al. A Pervasive Approach to EEG-Based Depression Detection[J]. *Complexity*, 2018, 2018: 1-13.
- [17] MAO W D, Deep learning based on recognition of depression patients using EEG data[D]. Lanzhou: Lanzhou University, 2019.
- [18] IMBALZANO G, ARTUSI C, MONTANARO E, et al. Tuning deep brain stimulation related depression by frequency modulation: A case report[J]. *Brain Stimulation*, 2020, 13(5): 1265-1267.
- [19] LIU Y, PU C Q, XIA S, et al. Machine learning approaches for diagnosing depression using EEG: A review [J]. *Translational Neuroscience*, 2022, 13(1): 224-235.
- [20] KNYAZEVA G, SAVOSTYANOV A, BOCHAR A, et al. Task-positive and task-negative networks and their relation to depression: EEG beamformer analysis [J]. *Behavioural Brain Research*, 2016, 306: 160-169.
- [21] STEIN E M, WEISS G. Introduction to Fourier Analysis on Euclidean Spaces [M]. New Jersey: Princeton University, 2016: 24-60.
- [22] BENESTY J, CHEN J D, HABETS E. Speech Enhancement in the STFT Domain[M]. Berlin: Springer, 2011: 41-53.
- [23] LECUN Y, BOSER B, DENKER J. S. , et al. Backpropagation Applied to Handwritten Zip Code Recognition[J]. *Neural Computation*, 1989, 1(4): 541-551.
- [24] CAI H S, YUAN Z Q, GAO Y W, et al. A multi-modal open dataset for mental-disorder analysis[J]. *Scientific Data*, 2022, 9(1): 178.
- [25] CHEN C, Research on diagnosis method of depression based on EEG[D]. Southeast University, 2021.
- [26] ZHANG L, Research on EEG depression identification based on feature selection and ensemble classification [D]. Lanzhou: Lanzhou University, 2022.
- [27] YANG B X, GUO Y Y, HAO S S, et al. Application of Graph Neural Network Based on Data Augmentation and Model Ensemble in Depression Recognition[J]. *Chinese Journal of Computers*, 2022, 49(7): 57-63.
- [28] AVERY A. J, DREVETS C. W, MOSEMAN E. S, et al. Major Depressive Disorder Is Associated with Abnormal Interoceptive Activity and Functional Connectivity in the Insula[J]. *Biological Psychiatry*, 2014, 76(3): 258-266.



REN Shuyao, born in 1998, postgraduate. Her main research interests include medical big data analytics and deep learning.



ZHANG Rui, born in 1971, professor, Ph.D supervisor. Her main research interests include medical big data analytics and computational neuroscience.