

基于 PLSTM-AttnNet 的抑郁症识别研究*

孙诗晴 孙嘉琪 孙玉冰 蔡 靖 刘光达

(吉林大学仪器科学与电气工程学院 长春 130000)

摘要:为提高抑郁症的自动识别准确率,提出使用融合深度残差网络作为编码器,同时引入改进长短时记忆网络与自注意力机制以提升网络模型对数据时序性的感知能力,得到效果较好的 PLSTM-AttnNet 模型。首先对脑电信号进行滤波、去噪等预处理操作,提取 6 项典型时域数据以及涵盖 δ 、 θ 、 α 、 β 、 γ 5 个频段的微分熵与功率谱密度。将预处理的数据输入 ResNet 编码器提取空间维度信息,使用 PLSTM 模块和自注意力 Attention 模块处理 ResNet 编码器的输出特征以捕捉数据的时序维度信息,提高抑郁症的识别准确率。在公开 EEG 数据集上开展大量对比实验,量化结果显示,所提 PLSTM-AttnNet 模型分类准确率达 97.3%,较于单一 ResNet 模型、ResNet-PLSTM 模型,准确率分别提升 10.1%、3.9%,且在 F1 分数等评价指标上均显著优于对比模型。结果表明,该模型通过 ResNet 与 PLSTM-Attention 的创新融合,有效强化了 EEG 信号时序-空间特征的协同表征能力,解决了传统模型特征捕捉片面的问题,为抑郁症的高效自动识别提供了可靠方案,具有重要的临床应用价值。

关键词: 脑电信号;抑郁症识别;深度残差网络;长短时记忆网络;注意力机制

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 310.14

Experimental design of depression diagnosis based on PLSTM-AttnNet

Sun Shiqing Sun Jiaqi Sun Yubing Cai Jing Liu Guangda

(School of Instrument Science and Electrical Engineering, Jilin University, Changchun 130000, China)

Abstract: To improve the accuracy of automatic recognition of depression, a fusion deep residual network is proposed as the encoder, and an improved long short-term memory network and self attention mechanism are introduced to enhance the network model's perception ability of data temporality, resulting in a well performing PLSTM AttnNet model. Firstly, preprocessing operations such as filtering and denoising are performed on the EEG signal to extract six typical time-domain data and differential entropy and power spectral density covering five frequency bands: δ , θ , α , β , and γ . Input the preprocessed data into the ResNet encoder to extract spatial dimension information, use the PLSTM module and self attention module to process the output features of the ResNet encoder to capture the temporal dimension information of the data, and improve the recognition accuracy of depression. A large number of comparative experiments were conducted on the publicly available EEG dataset, and the quantitative results showed that the proposed PLSTM AttnNet model achieved a classification accuracy of 97.3%. Compared with the single ResNet model and ResNet PLSTM model, the accuracy was improved by 10.1% and 3.9% respectively, and it was significantly better than the comparative model in evaluation indicators such as F1 score. The results indicate that the innovative fusion of ResNet and PLSTM Attention effectively enhances the collaborative representation ability of EEG signal temporal spatial features, solves the problem of one-sided feature capture in traditional models, and provides a reliable solution for efficient automatic recognition of depression, which has important clinical application value.

Keywords: electroencephalogram (EEG); depression recognition; deep residual networks (ResNet); long short-term memory (LSTM); attention mechanism (AM)

0 引言

抑郁症 (depression) 是一种常见的心理健康障碍,主要表现为持续的悲伤、无助、无望、兴趣丧失等情绪症状。根据世界卫生组织的统计数据,全球抑郁症患者约有 3.5 亿,我国患病率达到了 2.1%^[1]。在生活节奏加快与工作压力持续增长的背景下,抑郁症发病人数呈现上升趋势^[2]。因此,尽早识别并对抑郁症进行初期干预,对于患者的治疗和康复具有重要意义^[3]。

目前,临床上抑郁症的主要诊断方法仍以量表评估为基础,由医生通过面对面访谈完成^[4]。然而这种诊断方式依赖于医生的经验,主观性强、误诊率和漏诊率较高^[5]。因此,有必要寻求一种客观且具有稳定性的方法,以辅助抑郁症的诊断。脑电图具有时间分辨率高、监测成本低的特点^[6],能够反映人脑的情绪性活动^[7]。抑郁症作为一种具有明显抑郁、思维缓慢等临床表现的精神障碍,伴有大脑活动异常和明显的情绪交替,脑电图的节律和幅值与正常人存在差别^[8],因此可以将脑电图作为抑郁症患者的诊断依据。

近年来,基于脑电图的抑郁症研究取得了很大的进展。Cai 等^[9]基于三通道脑电信号,提取了五类线性特征和五类非线性特征,并使用支持向量机 (support vector machine, SVM) 和 K 近邻 (K-nearest neighbor, KNN) 分类算法对抑郁症进行识别,但 SVM 对数据的缩放敏感,且核函数的选择同样也会影响 SVM 的性能,导致该方法的分类准确率仅为 76.4%。Du 等^[10]利用时序数据,使用长短期记忆网络 (long short-term memory, LSTM) 对情绪进行分类,最终的分类准确率为 77.48%。Jiang 等^[11]采用差分熵进行特征提取,并利用遗传算法完成特征筛选,再结合支持向量机分类方法,在积极和消极两种刺激条件下取得了分别为 84% 和 85.7% 的分类准确率。Acharya 等^[12]则通过提取非线性特征实现抑郁症诊断系数的自动计算,以辅助抑郁症的识别。Cao 等^[13]使用卷积神经网络 (convolutional neural network, CNN) 对情绪分类的准确率为 81.2%。Kumar 等^[14]使用双向长短时记忆网络 (bidirectional long short-term memory, BiLSTM) 与全局向量 (GloVe) 结合,对抑郁症的分类准确率为 86%。Yang 等^[15]使用长短时记忆网络与递归神经网络 (recurrent neural network, RNN) 结合,对情绪的分类准确率为 91.03%。Wang 等^[16]提出一种抑郁识别模型:W-GCN-GRU,对抑郁症的分类准确率为 94.72%。Noda 等^[17]将 4 种特征集 (RST、PRE、PST 和 DIF) 合并并应用线性判别分析 (linear discriminant analysis, LDA) 作为机器学习模型对抑郁症的准确率为 92.2%。Ying 等^[18]提出了一种名为增强抑郁倾向 (EDT) 的深度学习

模型实现了 94.0% 的高分类准确率。于洪丽等^[19]使用 LSTM-EEGNet-Attention 混合模型对脑卒中后抑郁症进行分类,准确率可达 95.9%。Khan 等^[20]采用 BF 树分类器实现了 96.36% 的准确率。

本文提出一种 PLSTM-AttnNet 模型,基于 MODMA 数据集,首先对原始脑电数据进行预处理,并提取时域特征、功率谱密度 (PSD) 等数据。使用 ResNet 编码器提取预处理数据的空间维度信息,随后使用 PLSTM 模块以捕捉信号的时序维度信息,使用注意力模块 Attention 精准捕获超长序列的远距离依赖并聚焦数据特征的关键时序信息,将 Attention 的输出链接到由多层感知机 MLPs 和 Softmax 组成的分类头 (classification head) 实现抑郁症的识别。模型分类准确率达到了 97.3%。

1 材料和方法

1.1 数据库

本文采用 MODMA 数据集^[21]中的 EEG 信号来进行验证所提出模型的有效性,该数据集由兰州大学提供,经兰州大学第二附属医院伦理委员会批准^[22]。受试者基本信息如表 1 所示。

表 1 受试者基本信息

Table 1 Basic information of subjects		
信息	MDD	HC
受试者/名	24	29
年龄/岁	16~52	19~52

实验采用 HydroCel 高密度传感器与 Net Station 软件记录脑电数据,信号采样频率设为 250 Hz。所使用的 HydroCel 弹性电极帽包含 128 个电极,其在头皮表面的具体分布情况如图 1 所示。




图 1 128 电极 HydroCel 系统电极分布
Fig. 1 Electrode distribution diagram of 128 electrode hydrocel system

额叶区域与情感、注意力等高级认知活动有关^[23]，HydroCel 系统与常用 10-20 国际标准导联系统的对应关系如表 2 所示。因此实验选取 128 通道中的 9、11、15、22、24、33、122、124 八个通道。

表 2 HydroCel 系统与 10-20 系统电极对应关系

Table 2 Electrode correspondence between hydrocel system and 10-20 system		
部位	HydroCel 系统	10-20 国标系统
右额极	9	FP2
额中点	11	Fz
额极中点	15	FPz
左额极	22	FP1
左额	24	F3
左前颞	33	F7
右前颞	122	F8
右额	124	F4

1.2 数据预处理

脑电信号采集过程易受设备内部噪声及外界干扰信号的影响,因此需要对采集到的原始脑电数据进行预处理,具体步骤如下。

- 1) 数据导入:导入原始的脑电数据;
- 2) 通道选取:从原始的 128 个通道数据中选取本实验所需的 8 个通道进行后续分析;
- 3) 信号滤波:为消除工频和高频噪声干扰,设计了截止频率分别为 0.5 Hz 和 45 Hz 的高通及低通滤波器,对所选 8 个通道的数据进行滤波处理;
- 4) 去除伪迹:通过独立成分分析 (independent component analysis, ICA) 手动识别并去除由眼动和心电图等引起的伪迹成分;
- 5) 数据分段:将连续脑电信号分为多个 epoch;
- 6) 对预处理后的数据进行保存。

1.3 特征提取

1) 时域特征
时域特征是指从信号的时间序列中提取的特性,这些特征反映了脑电信号在时间上的波动或变化。提取脑电信号时域的 6 个统计特征,均值、最大值、最小值、标准差、偏度、峰度,计算公式如表 3 所示。

2) 功率谱密度
功率谱密度反映了信号在频域上的功率分布情况。图 2 为某一样本 4 个通道信号对应的功率谱密度。

3) 微分熵
微分熵用来衡量信号的复杂性和不确定性,计算公式为:

$$H_{DE} = - \int_n^m p(x) \log [p(x)] dx$$

(1)

表 3 时域特征

Table 3 Time domain characteristics	
特征名称	公式
均值	$\frac{1}{N} \sum_{i=1}^N (x_i)$
标准差	$\sqrt{\frac{1}{N} \sum_{i=1}^N ((x_i - \mu))}$
偏度	$\frac{N}{(N-1)(N-2)} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma}\right)^3$
峰度	$\frac{N(N+1)}{(N-1)(N-2)(N-3)} \sum_{i=1}^N \left(\frac{x_i - \mu}{\sigma}\right)^4$




图 2 4 通道脑电信号功率谱密度

Fig. 2 Power spectral density of four channel EEG signals

式中: H_{DE} 为信号的微分熵; $[n, m]$ 为取值范围; $p(x)$ 为连续信息的概率密度函数。

提取脑电信号的时域特征、微分熵和功率谱密度特征,得到的特征数据大小如表 4 所示。

表 4 特征数据大小

Table 4 Characteristic data size	
特征	数据大小
时域特征	8×6
微分熵	8×5
功率谱密度	8×129

2 抑郁症识别方法

脑电信号作为典型的非平稳生理信号,兼具空间拓扑特征与动态时间特征。为有效提取脑电信号的空间域和时间域特征,提出一种 Res-PLS-AM 模型。

2.1 深度残差网络

深度残差网络 (deep residual network, ResNet) 主要包括初始卷积层、残差块组、全局平均池化层和全连接层等

基本结构^[24]。初始卷积层用于从输入数据中提取空间特征,残差块是深度残差网络中的基本构建单元。在残差块中,残差连接的方式有效地解决了梯度消失问题,全连接层将前层特征拓展至高维以关注数据的空间信息^[25]。这些层次化的交替堆叠结构赋予网络模型有效提取数据空间特征的能力。由于 ResNet101 网络层数过深、参数量较大,在 MODMA 数据集训练时容易出现过拟合现象^[26],影响模型的学习效果,所以研究基于 ResNet50 框架进行展开。

2.2 PLSTM 模块

PLSTM 模块的核心是其具有信息存储与更新能力的记忆单元^[27]。图 3 给出了标准 LSTM 结构示意图,其内部状态依赖于当前的输入信息和上一时刻的隐藏状态。




图 3 LSTM 神经网络内部结构

Fig. 3 Internal structure of standard LSTM neural network

PLSTM-AttnNet 模型使用 PLSTM 模块,PLSTM 在 LSTM 的遗忘门、输入门和输出门上引入自窥权重矩阵,将门控与细胞状态信息相结合,使得 PLSTM 不仅依赖于当前输入状态和前一时刻的隐藏状态,还利用了细胞状态本身的信息去更好调整门控的行为。这种门控结合细胞状态信息的方式使得模块对长序列依赖的捕获精度更高,且对噪声数据的抗干扰能力更强,门控决策更稳健。

PLSTM 中的遗忘门计算公式为:

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + P_f \times c_{t-1} + b_f) \quad (2)$$

式中: f_t 是遗忘门的输出,范围在 0~1 之间; W_f 是遗忘门的权重矩阵; h_{t-1} 是上一时刻的隐藏状态; x_t 是当前时刻的输入; b_f 是遗忘门的偏置向量; σ 是 sigmoid 激活函数; P_f 是遗忘门的自窥权重矩阵; c_{t-1} 是前一时刻的细胞状态。PLSTM 模块在遗忘门中引入自窥权重矩阵 P_f 可以更精确地判断哪些历史信息需要保留/遗忘。

PLSTM 的输入门计算公式为:

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + P_i \times c_{t-1} + b_i) \quad (3)$$

然后,生成候选记忆单元:

$$\tilde{C}_t = \tanh(W_c \times [h_{t-1}, x_t] + b_c) \quad (4)$$

结合遗忘门和输入门的输出,更新记忆单元的状态

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (5)$$

式中: i_t 是输入门的输出; W_i 、 W_c 是输入门和候选记忆的权重矩阵; b_i 、 b_c 是对应的偏置向量。Tanh 是双曲正切激活函数; C_t 是当前时刻的细胞状态; P_i 是输入门的自窥权重矩阵。PLSTM 在输入门中引入自窥权重矩阵 P_i 可以有效决定哪些新信息需要写入细胞中。

PLSTM 的输出门计算公式为:

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + P_o \times c_t + b_o) \quad (6)$$

$$h_t = o_t \times \tanh(C_t) \quad (7)$$

式中: o_t 为输出门; W_o 为输出门权重; b_o 为偏置系数; h_t 为 t 时刻的输出; P_o 是输出门的自窥权重矩阵。PLSTM 在输出门中引入自窥权重矩阵 P_o 可以更精确地控制细胞状态中哪些信息输出到隐藏状态。

2.3 Attention 模块

PLSTM-AttnNet 中的注意力 Attention 模块把特征通过 3 个 MLP 矩阵 (W^Q 、 W^K 、 W^V) 映射到 Query、Key、Value,通过计算 Query 和 Key 之间的注意力得分,以此决定 Value 中信息的重要性程度,使模型能够更聚焦于时序数据的关键判别信息,降低对次要或无关信息的关注程度,从而提升分类准确性^[28]。

计算公式为:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (8)$$

式中: Q 为 Query 向量; K 为 Key 向量; V 为 Value 向量; d_k 为 K 向量的维度; softmax 为激活函数。

2.4 PLSTM-AttnNet

该模型首先将预处理后的脑电信号输入 ResNet 模块,ResNet 编码器通过深度残差连接结构有效提取脑电信号的空间域特征,捕捉不同电极间的空间拓扑关联;将编码后的输出特征送入 PLSTM 模块,利用其分层记忆单元对时间序列动态进行建模,实现脑电信号时序依赖关系的高效捕获。通过 ResNet 与 PLSTM 的级联设计,模型形成了对脑电信号时空特征的协同表征机制,既保留了多通道信号的空间分布特性,又兼顾了脑电信号的动态时间特征。此外,模型中最后的注意力模块通过训练 Q 、 K 、 V 矩阵自适应权重分配,强化了关键时空特征的表征能力,聚焦数据特征中的关键判别信息,进一步提升了分类性能。为提高模型的泛化性能,在训练过程中引入 Dropout(dropout 值为 0.3)以缓解过拟合问题,最终通过由多层感知机 MLPs 以及 Softmax 组成的分类头实现抑郁症的识别。模型结构如图 4 所示。

3 实验与结果分析

如图 5 所示,数据经预处理后得到 2 650 个样本,将数据随机划分 80% 为训练集,10% 为验证集,10% 为测试




图4 PLSTM-AttnNet 模型结构示意图

Fig.4 Schematic diagram of PLSTM-AttnNet

集。数据集共 53 名受试者,利用数据增强技术,将每个被试的数据取 6 s 一段,共可得到 2 650 个样本,不同组被试的分布情况如表 5 所示。




图5 数据集划分

Fig.5 Dataset partitioning

表5 被试分布情况

Table 5 Distribution of subjects		
子数据集	抑郁症样本	健康样本
训练集	960	1 160
验证集	120	145
测试集	120	145

为了获得足够的数据段来更好地训练深度学习模型,将预处理后的数据通过滑动窗口分成 6 s 的段,其移动步长也是 6 s,数据片段之间没有重叠。因此,每个受试者将生成 50 个样本,共可得到 2 650 个样本,不同组被试的分布情况如表 5 所示。本网络采用的深度学习框架是 Pytorch。

为使损失函数的值尽可能小,在数据集上进行对比实验,对比 3 种优化器在不同 Epochs 下的准确率。结果如表 6 所示。

表6 不同优化器在不同 Epoch 下的准确率

Table 6 Accuracy of different optimizers at different Epochs (%)						
优化器	Epoch = 20		Epoch = 50		Epoch = 100	
	训练集	测试集	训练集	测试集	训练集	测试集
SGD	86.3	83.7	89.3	87.6	91.2	89.9
Momentum	83.6	82.4	90.2	89.3	91.8	90.6
Adam	93.9	92.6	95.9	94.5	98.7	97.3

经过系统的调优实验,最终确定最优参数配置模型的一般模型参数如表 7 所示。

表7 模型参数

Table 7 Model parameter	
参数	值
优化器	Adam
学习率	0.001
损失函数	交叉熵损失函数
批量大小	64
Epochs	100

Pre)、召回率(recall,Rec)和 F1 值等指标评价所提出模型的性能。

为验证预处理与特征提取的有效性,将原始数据,预处理后的数据与特征数据分别作为模型的输入,模型对抑郁症的识别准确率如表 8 所示。

表8 不同输入的分类准确率

Table 8 Classification accuracy with different inputs	
输入	准确率/%
原始数据	81.3
预处理后数据	92.6
特征数据	97.3

研究采用准确率(accuracy, Acc)、精确率(precision,

本研究所涉及的模型主要包括 3 个主要模块: ResNet 编码器、PLSTM 模块、Attention 模块。对模块进行消融实验,方案如下:1) 只使用 ResNet 模块,将特征数据后直接通过多层感知机 MLPs 和 Softmax 组成的分类头进行分类,其他参数不变;2) 去除 Attention 模块,将 PLSTM 模块的输出特征直接通过作用于多层感知机 MLPs 和 Softmax 组成的分类头进行分类;3) 去除 PLSTM 模块,将 ResNet 编码器提取的数据特征直接作用于自注意力机制分配自适应权重。不同模型评价指标如表 9 所示。

表 9 不同模型评价指标

模型	Acc	Pre	Rec	F1
ResNet	0. 793	0. 756	0. 800	0. 778
ResNet+PLSTM	0. 867	0. 870	0. 833	0. 851
ResNet+Attention	0. 934	0. 927	0. 932	0. 929
PLSTM-AttnNet	0. 973	0. 982	0. 964	0. 971

PLSTM-AttnNet 的训练曲线如图 6 所示。
为直观展示模型特征提取能力,将未训练的样本与通过不同模型提取的特征进行二维平面可视化。如




图 7 未训练样本及不同模型中特征映射的分布

Fig. 7 Distribution of feature mapping in untrained samples and different models




图 6 PLSTM-AttnNet 训练曲线
Fig. 6 PLSTM-AttnNet training curve

图 7(a) 中样本点无规律且高度重叠;经 ResNet 模型训练后图 7(b),特征映射开始呈现双簇分布趋势,但类间仍存在显著重叠区域;ResNet-PLSTM 模型图 7(c) 虽实现特征空间聚类,但同一簇内两类特征仍存在混叠,不利于样本分类。相比之下,本文提出的模型图 7(d) 可使两类特征在二维平面中形成分离的相对独立簇,类内聚集性显著提升,类间边界相对清晰。该结果表明,本文模型在特征空间构建上更具判别力,能够有效捕捉样本类别差异,验证了模型结构设计在特征提取与分类任务中的有效性。

通过对各模型的评价指标进行分析可以得出,当不使用自注意力模块时,ResNet 网络的准确率等 4 种评价指标均小于 ResNet-PLSTM 的指标。说明的 ResNet-PLSTM 模型的性能优于标准的 ResNet 模型。此外,加入注意力 Attention 后的模型在准确率等 4 项评价指标上均表现更优,表明注意力机制有效提升了模型的分类能力。因此,本研究提出的 PLSTM-AttnNet 模型在鲁棒性和泛化能力方面表现出明显优势。

作为对比,选择了抑郁状态识别领域的 8 个现有模型。比较结果如表 10 所示。所提模型的识别结果相较于现有深度学习分类方法提高了 10%。证明了本文所提模型的有效性。

表 10 不同方法比较结果

Table 10 Comparison results of different methods

来源	方法	识别精度/%
文献[6]	SVM	85.7
文献[9]	LSTM	77.48
文献[11]	CNN-RNN	91.03
文献[17]	LDA	92.2
文献[18]	EDT	94
文献[16]	W-GCN-GRU	94.72
文献[19]	LSTM-EEGNet-AM	95.9
文献[20]	BF 树	96.36
本文	PLSTM-AttnNet	97.3

4 结 论

本文将 ResNet 网络用于抑郁症识别,针对脑电信号的时间特征和空间特征,对 LSTM 网络进行改进,提出了 PLSTM 网络。结合 ResNet 局部空间特征提取和 PLSTM 时序特征提取的特点提出了一种 PLSTM-AttnNet 混合神经网络模型。通过对网络结构和输入特征的消融实验,得到如下结论。

在脑电信号的特征提取中,ResNetV1 的性能优于 ResNetV2。1) 相比于标准的 LSTM 模型,改进后的 PLSTM 模型增加了对细胞状态本身信息的利用,对脑电信号时间信息的提取能力优于标准的 LSTM 模型;2) 将 PLSTM-AttnNet 混合神经网络模型与其他模型做对比,实验结果表明该模型的准确率可达到 97.3%,其他 3 种评估指标也均高于其他模型。本网络充分发挥了各部分的功能,对脑电信号所蕴含的特征充分提取,提高了对抑郁症的识别准确率。

参考文献

[1] 谢士遥,汤佳贝,蔡雨,等. 脑电 BCI 系统的软硬件开发平台发展现状[J]. 电子测量与仪器学报,2022,

36(6):1-12.
XIE SH Y, TANG J B, CAI Y, et al. Development status of software and hardware development platforms for EEG BCI systems [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 1-12.
[2] 覃小容. EEG 静息微状态预测大学生抑郁倾向:人格的调节作用[D]. 重庆:西南大学,2022.
TAN X R. EEG resting micro state predicts college students' depression tendency: The regulatory role of personality [D]. Chongqing: Southwest University, 2022.
[3] ELNAGGAR K, EL-GAYAR M M, ELMOGY M. Depression detection and diagnosis based on electroencephalogram (EEG) analysis: A systematic review[J]. Diagnostics, 2025, 15(2): 210-218.
[4] SUBRAMANIAM M, ABDIN E, KONG A M C, et al. Differences in the prevalence and profile of DSM-IV and DSM-5 alcohol use disorders—results from the singapore mental health study 2016 [J]. International Journal of Environmental Research and Public Health, 2022, 20(1): 285.
[5] 区健新,吴寅,刘金婷,等. 计算精神病学:抑郁症研究和临床应用的新视角 [J]. 心理科学进展, 2020, 28(1):111-127.
QU J X, WU Y, LIU J T, et al. Computational psychiatry: A new perspective for depression research and clinical application [J]. Advances in Psychological Science, 2020, 28(1): 111-127.
[6] JIANG C, LI Y, TANG Y, et al. Enhancing EEG-based classification of depression patients using spatial information [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 566-575.
[7] 莫云,李易,张本鑫,等. 基于权重融合特征重标定网络的运动想象脑电分类 [J]. 电子测量与仪器学报, 2025,39(1):70-79.
MO Y, LI Y, ZHANG B X, et al. EEG classification of motor imagery based on weight-fusion feature recalibration network [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(1): 70-79.
[8] 康显赞,刘爽,苏方玥,等. 基于 HFD 和 LZC 特征联合的单通道静息态脑电抑郁症识别研究 [J]. 仪器仪表学报,2022,43(7):181-190.
KANG X Y, LIU SH, SU F Y, et al. Research on the

- recognition of depression using single-channel resting-state electroencephalogram based on the combination of HFD and LZC features[J]. Chinese Journal of Scientific Instrument, 2022, 43(7): 181-190.
- [9] CAI H, CHEN Y, HAN J, et al. Study on feature selection methods for depression detection using three-electrode EEG data [J]. Interdisciplinary Sciences: Computational Life Sciences, 2018, 10: 558-565.
- [10] DU X, MA C, ZHANG G, et al. An efficient LSTM network for emotion recognition from multichannel EEG signals[J]. IEEE Transactions on Affective Computing, 2020, 13(3): 1528-1540.
- [11] JIANG C, LI Y, TANG Y, et al. Enhancing EEG-based classification of depression patients using spatial information[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 566-575.
- [12] ACHARYA U R, SUDARSHAN V K, ADELI H, et al. A novel depression diagnosis index using nonlinear features in EEG signals[J]. European Neurology, 2015, 74(1-2): 79-83.
- [13] YAO G, LEI T, ZHONG J. A review of convolutional-neural-network-based action recognition [J]. Pattern Recognition Letters, 2019, 118: 14-22.
- [14] KUMAR A, QUADIR A, JACKSON C, et al. Predicting and curing depression using long short term memory and global vector [J]. Computers, Materials & Continua, 2023, 74(3): 5837-5852.
- [15] YANG Y, WU Q, QIU M, et al. Emotion recognition from multi-channel EEG through parallel convolutional recurrent neural network [C]. 2018 International Joint Conference on Neural Networks (IJCNN). IEEE, 2018: 1-7.
- [16] WANG Z, HU C, LIU W, et al. EEG-based high-performance depression state recognition[J]. Frontiers in Neuroscience, 2024, 17: 130-146.
- [17] NODA Y, SAKAUE K, WADA M, et al. Development of artificial intelligence for determining major depressive disorder based on resting-state EEG and single-pulse transcranial magnetic stimulation-evoked EEG indices[J]. Journal of Personalized Medicine, 2024, 14(1): 101-113.
- [18] YING M, SHAO X, ZHU J, et al. EDT: An EEG-based attention model for feature learning and depression recognition [J]. Biomedical Signal Processing and Control, 2024, 93: 106-119.
- [19] 于洪丽,安丽佳,王春方,等. 基于混合神经网络和注意力机制的卒中后抑郁早期筛查分类方法研究[J]. 电子测量技术, 2023, 46(12): 178-186.
- Y H L, AN L J, WANG CH F, et al. Research on the early screening and classification method of post-stroke depression based on a hybrid neural network and attention mechanism [J]. Electronic Measurement Technology, 2023, 46(12): 178-186.
- [20] KHAN S, UMAR SAEED 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): 299-314.
- [21] CAI H, YUAN Z, GAO Y, et al. A multi-modal open dataset for mental-disorder analysis[J]. Scientific Data, 2022, 9(1): 178.
- [22] 李浩然. 基于脑电信号和图神经网络的抑郁症识别方法研究[D]. 济南: 山东大学, 2023.
- LI H R, Research on depression recognition method based on EEG and graph neural network [D]. Jinan: Shandong University, 2023.
- [23] KIM Y M, LEE E, SHIN J S, et al. The role of the frontal lobe in the writing process[J]. Journal of Speech, 2024, 33(3): 019-032.
- [24] 李炳臻, 刘克, 顾佼佼, 等. 卷积神经网络研究综述[J]. 计算机时代, 2021(4): 8-12, 17.
- LI B ZH, LIU K, GU J J, et al Review of convolutional neural networks [J]. Computer Age, 2021(4): 8-12, 17.
- [25] INCE T, KIRANYAZ S, EREN L, et al. Real-time motor fault detection by 1-D convolutional neural networks [J]. IEEE Transactions on Industrial Electronics, 2016, 63(11): 7067-7075.
- [26] XU W, FU Y L, ZHU D. ResNet and its application to medical image processing: Research progress and challenges [J]. Computer Methods and Programs in Biomedicine, 2023, 240: 107-119.
- [27] VAN HOUTDT G, MOSQUERA C, NÁPOLES G. A review on the long short-term memory model [J].

Artificial Intelligence Review, 2020, 53 (8): 5929-5955.

[28] 赵佰亭,张晨,贾晓芬. ECC-YOLO:一种改进的钢材表面缺陷检测方法[J]. 电子测量与仪器学报,2024, 38(4):108-116.

ZHAO B T, ZHANG CH, JIA X F. ECC-YOLO: An improved method for steel surface defect detection[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 108-116.

作者简介



孙诗晴,2023 年于山东理工大学获得学士学位,现为吉林大学硕士研究生,主要研究方向为生物医学信号检测。
E-mail: sqsun@ mails. jlu. edu. cn

Sun Shiqing received her B. Sc. degree from Shandong University of Technology in

2023. She is currently a M. Sc. student at Jilin University. Her main research interest includes biomedical signal detection.



刘光达(通信作者),1985 年于沈阳工业大学获得学士学位,1990 年于吉林工业大学获得硕士学位,2000 年于中科院长春光学精密机械与物理研究所获得博士学位,现为吉林大学教授,主要研究方向为人体生物信号检测技术及仪器。

E-mail:gdliu@jlu. edu. cn

Liu Guangda (Corresponding author) received his B. Sc. degree from Shenyang University of Technology in 1985, M. Sc. degree from Jilin University of Technology in1990, and Ph. degree from Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences in 2000. He is currently a professor at Jilin University. His main research interest includes human biomedical signal detection.