

DOI:10.3969/j.issn.1005-202X.2025.09.010

医学信号处理与医学仪器

## 基于穿戴式多生理信号的抑郁智能检测

曹轲鸣, 赵璐璐, 赵鸣晖, 王子宁, 李建清, 刘澄玉

东南大学仪器科学与工程学院/数字医学工程全国重点实验室, 江苏 南京 210096

**【摘要】**抑郁症作为一种严重的心理精神疾病, 损害着患者长期的身心健康。当前抑郁检测存在主观性强、手段单一、不够智能化等问题, 以往研究多基于单模态信号进行分析, 难以全面反映抑郁的多维特征。本研究基于自主研发的智能抑郁检测系统, 使用可穿戴设备采集前额叶双导联脑电、PPG信号、单导联心电信号, 收集并提取30例抑郁症患者和40例健康对照者的数据, 提出一种结合时空特征、加权注意力、随机森林的多模态抑郁识别模型RBLF-Net, 能够结合多种信号的特征进行有效抑郁识别。在五折交叉验证中, 该模型表现优异(分类准确率81.43%, 精确度81.02%, 召回率81.25%), 优于其他对比模型, 为抑郁识别提供一种多模态融合视角的智能分析方法。

**【关键词】**可穿戴设备; 多模态; 人工智能; 抑郁识别

**【中图分类号】**R318

**【文献标志码】**A

**【文章编号】**1005-202X(2025)09-1191-06

### Intelligent depression detection based on multi-physiological signals acquired by wearable devices

CAO Keming, ZHAO Lulu, ZHAO Minghui, WANG Zining, LI Jianqing, LIU Chengyu

State Key Laboratory of Digital Medical Engineering/School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China

**Abstract:** Depression, as a severe psychological and psychiatric disorder, significantly impairs the long-term physical and mental health of patients. Current depression detection methods are plagued by strong subjectivity, limited techniques, and inadequate intelligence. Previous studies have mostly relied on single-modal signal analysis, making it difficult to comprehensively reflect the multidimensional characteristics of depression. Based on the independently developed intelligent depression detection system, wearable devices are used to collect prefrontal dual-lead EEG signals, PPG signals, and single-lead ECG signals. Data from 30 patients with depression and 40 healthy controls are collected and analyzed. A multimodal depression recognition model named RBLF-Net is proposed, which integrates spatiotemporal features, weighted attention, and random forests to utilize the multi-signal features for depression recognition. The model exhibits superior performance in the five-fold cross-validation, achieving a classification accuracy of 81.43%, a precision of 81.02%, and a recall rate of 81.25%, outperforming other comparative models, and thus providing an intelligent analysis approach for depression recognition from the perspective of multi-modal fusion.

**Keywords:** wearable device; multimodal; artificial intelligence; depression recognition

### 前言

抑郁症是一种严重且复杂的心理精神疾病, 以情感低落为主要临床表现, 严重影响患者的工作和生活。近年来, 抑郁症的患病率逐年上升, 据世界卫

生组织估计, 全球有3.8%的人患有抑郁症。精神障碍是自杀行为的重要因素, 其中抑郁症是主要的精神危险因素<sup>[1]</sup>。

目前对于抑郁的检测多依靠病史、临床症状表现、量表评价等, 因而具有一定的主观性、片面性。其中, 青少年阶段是心理问题的高发期, 青少年抑郁障碍通常比较隐蔽, 并且个体之间差异性较大。由于部分患者讳疾忌医, 隐瞒病情, 对主观诊断的量表评测造成障碍, 以致漏诊或者误诊的现象<sup>[2]</sup>。早期的抑郁筛查能够带来及时有效的干预<sup>[3]</sup>, 能够降低抑郁的致残率、致死率, 从而提高国民的心理健康水平、

**【收稿日期】**2025-04-03

**【基金项目】**国家重点研发计划(2023YFC3603600)

**【作者简介】**曹轲鸣, 硕士研究生, 研究方向: 智能医学信号处理, E-mail: keming@seu.edu.cn

**【通信作者】**李建清, 博士生导师, 研究方向: 智能穿戴设备、生理信号分析, E-mail: ljq@seu.edu.cn

降低医疗、社会和家庭负担。

已有研究发现,脑电某些特定频段特征、复杂度等指标能够反映抑郁状态的潜在病理信息,为抑郁症检测提供帮助<sup>[4-5]</sup>,包括去趋势波动分析(DFA)<sup>[6]</sup>、Lempel-Ziv复杂度<sup>[7]</sup>、差分熵<sup>[8]</sup>等。此外,alpha频段的动态特性改变能反映抑郁状态<sup>[9]</sup>,额叶脑电的alpha不对称性能够反映情绪调节和认知表现的预测能力<sup>[10]</sup>。研究表明,抑郁与自主神经功能的紊乱密切相关。心率变异性反映自主神经系统的调节能力,能评估交感神经和副交感神经的动态活动状态,从而识别抑郁症患者<sup>[11]</sup>。脑部PPG信号通过光电容积脉搏波技术采集反映额头区域血液容积的周期性变化。该信号与自主神经系统功能密切相关,可间接反映抑郁症患者的血流动力学异常及脑部血氧水平的变化<sup>[12]</sup>。

近年来,利用生理信号进行抑郁识别的手段不断丰富。Shen等<sup>[13]</sup>提出HEMAsNet,该网络引入类胼胝体模块,用于从脑电信号中识别抑郁症。使用22通道的脑电信号在MODMA数据集达到了0.8067的准确率。Habib等<sup>[14]</sup>提出一个基于单通道ECG信号的并行深度学习模型MDDBranchNet,用于MDD二分类,在DAIC-WOZ数据集上进行评估,达到76%的准确率。Kontaxis等<sup>[15]</sup>采用PPG波形来评估重度抑郁和健康人对精神压力的自主神经反应差异,并得出通过PPG波形形态的动态变化量化应激反应可辅助诊断抑郁症。Fan等<sup>[16]</sup>基于Transformer的多模态特征增强以及基于图融合网络(GFN)的多模态融合方法,整合视频、音频和远程光电容积描记法(rPPG)信号进行抑郁预测,在AVEC数据集上取得良好的效果。

目前的研究仍然存在诸多问题与挑战。许多研究集中在单模态信号分析,识别效果差异大。针对抑郁症患者采集的生理信号数据仍然较少。因此,基于真实数据开发一个鲁棒性强、效果良好的模型,

并应用于实际场景相关群体的抑郁检测,有着重要的意义。

为解决上述挑战,本研究基于可穿戴多生理信号采集设备,设计一套智能抑郁评测系统,开展抑郁症患者和健康对照组的数据采集试验,并提出一种基于多模态特征融合的抑郁评估模型RBLF-Net,为院外早期便捷准确的抑郁筛查提供可能。

## 1 试验数据

### 1.1 抑郁检测系统设计

本研究基于以往研究的试验评测范式和数据采集方法,自主设计开发一套基于脑电、心电等可穿戴采集设备的抑郁筛查与检测系统。

系统包含可穿戴式的心电和脑电采集设备,以及一块运行评测系统的Android平板。脑电采集设备设计为柔性发带形式,采样率为250 Hz,放大倍数为1 080倍,使用干电极采集前额叶FP1与FP2两导联脑电信号,参考部位为耳垂。该设备具有24位数据分辨率。同时,在前额部位设有红光和红外波段的LED光源和光电探测器,能够以光电容积脉搏波描记法采集头皮下表层反射的光波信号<sup>[17]</sup>,并转化为电信号,采样率为250 Hz,光源波段为红光和红外光。心电采集设备设计为贴片式,使用湿电极,能够采集胸部单导联心电信号,采样率为250 Hz。脑电和心电设备均能够将数据通过无线方式传输至平板端。

本研究还基于Android平板开发抑郁状态试验与评测软件,融合用户信息录入、静息态数据采集、抑郁量表患者健康问卷<sup>[18]</sup>(Patient Health Questionnaire-9, PHQ-9)等多种功能,能够以便捷、趣味的方式对被试进行多模态的心理健康状况评估,并给出反馈结果报告,被试能够在不受干扰的情况下独立自主完成测试,增加了评测的便捷性。基于多种生理信号的评测方法,增强了抑郁评估的全面性。可穿戴设备及评测系统如图1所示。

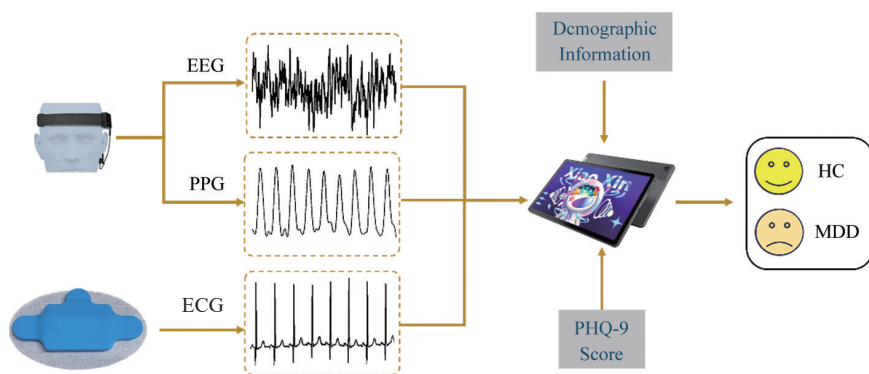


图1 可穿戴抑郁评测设备与系统  
Figure 1 Wearable depression assessment devices and systems

## 1.2 数据获取

本研究选取平均年龄约17岁的被试群体,基于第1.1节所述可穿戴式抑郁评测设备与系统,于南京市脑科医院采集抑郁症患者的数据,患者均为专家根据《国际疾病分类第十版》(ICD-10)确诊的病例。而健康对照组的数据招募来源是年龄相近的南京市大学生与中学生。被试均在了解试验内容和流程的基础上自愿参加,并签署知情同意书。试验已获得南京市脑科医院伦理委员会审查通过。

其中患有心脑血管疾病、其他精神疾病患者、有脑部器质性损伤或其他疾病患者被排除试验;被试者在48 h内不能服用镇静剂、兴奋剂和抗癫痫药物;在24 h内不可以抽烟或喝浓茶、咖啡;1 h内不可以大量进食或进行剧烈运动。除此之外,病情严重以致于无法完成试验的患者、有任何精神疾病史和两系三代内有精神病家族史的健康被试也会被排除。

试验评测的软件设计为Android APP形式,被试跟随语音和界面提示进行自主操作。首先进行用户信息登记,包括对身高、体质量等信息的采集,随后进行设备的佩戴和信号检测。随后依次进行3 min的闭眼状态下静息态数据采集、PHQ-9量表填写、结果报告反馈等。

## 1.3 数据预处理

本研究使用脑电、心电、前额PPG信号进行分析。由于采用可穿戴设备采集,信号中容易混入噪声干扰,因此首先进行目视信号检查和筛选,剔除质量太差或者有模态缺失的数据,得到30例抑郁症患者数据和40例健康对照组数据。被试的统计数据如表1所示。

表1 抑郁症患者与健康被试者信息

Table 1 Information of depressed patients and healthy subjects

组别	年龄/岁	体质量/kg	身高/cm
抑郁( $n=30$ )	16.9±6.2	61.1±14.3	167.4±5.6
健康( $n=40$ )	17.2±1.1	67.1±13.0	173.4±8.7

由于可穿戴设备所采集的信号容易受到不同噪声干扰,因此需对数据进行去噪处理。提取所有被试的3 min静息态信号。对于脑电信号,利用50 Hz陷波器进行工频干扰去除,并使用巴特沃斯带通滤波器获取alpha频段(8~13 Hz)信号,将3倍标准差之外的异常值去除。对于PPG信号同样利用50 Hz陷波器与带通滤波器进行噪声去除。对于心电信号,首先利用0.5~35.0 Hz的带通滤波器去除高频噪

声与低频漂移;然后对滤波后信号进行基线校正,以消除基线漂移;此外,还设定阈值对信号进行极值处理。使用滑动窗口方法对所有信号进行分割,重叠率为50%,得到长度为10 s的数据样本。

## 2 模型与方法

### 2.1 多模态生理信号抑郁分类融合模型

基于预处理后的脑电、心电、前额PPG信号,本研究提出一种多模态融合模型RBLF-Net(Residual Block Bi-LSTM Random Forest Network),通过挖掘各模态间的多维度特征信息,提高抑郁识别的性能。该模型能够提取多模态信号的空间特征与时间依赖性,并利用基于注意力加权机制和随机森林的融合策略,实现精准抑郁分类。

首先是特征提取模块,通过多输入流网络并行处理3种模态的信号。为了有效提取时间序列信号的深层特征,基于残差瓶颈块对3种模态的信号分别进行特征计算。对于每种信号,先输入初始卷积层,将输入映射到8维特征空间,随后通过6个堆叠的Bottleneck块,每个Bottleneck块由3层卷积构成,并采用残差连接设计。每个block由3层卷积构成,通过先降维再升维,减小了参数量,并逐步地增加特征的丰富性,以捕获信号的局部和长程依赖关系<sup>[19]</sup>。6个模块将信号特征由8维逐步提高到32维。接下来,将Bottleneck块所提取的特征送入一个双层双向LSTM模块,Bi-LSTM能够完整提取生理信号的时序特征,有效建模时间序列的前向和后向信息<sup>[20]</sup>。将LSTM得到的时序特征展平,完成对该信号的特征提取。

为有效整合来自不同信号模态的特征,本研究设计一个基于注意力机制的激励模块。对于每种信号所提取的特征,将3种信号的特征进行拼接,构成一个多模态联合特征向量<sup>[21]</sup>。该向量通过一个两层全连接网络(权重层)进行模态间权重的动态分配。该层以联合特征向量作为输入,输出是归一化后的3个权重系数。将权重值应用于输入特征,从而实现自适应地调整每个通道的贡献,增强模型对重要特征的关注。

模态融合特征的计算公式为:

$$F_{\text{fusion}} = \sum_{i=1}^3 w_i F_i \quad (1)$$

$$\text{where } \sum_{i=1}^3 w_i = 1 \quad (2)$$

式中, $F_{\text{fusion}}$ 为融合特征, $F_i$ 为第*i*种模态的特征, $w_i$ 为对应模态的权重。通过这种动态加权的方式,模型能够根据训练过程中的优化目标自适应地分配各模

态的贡献度,从而实现不同模态特征的高效融合。

将加权后的融合特征输入全连接层进行降维,随后输入一个随机森林分类器,用于完成最终的二分类任务。相较于使用全连接层进行分类,随机森

林具有更好的非线性表达能力和鲁棒性<sup>[22]</sup>。模型最终输出二维结果,分别表征健康(0类)和抑郁(1类)的置信度。RBLF-Net模型的整体框图如图2所示。

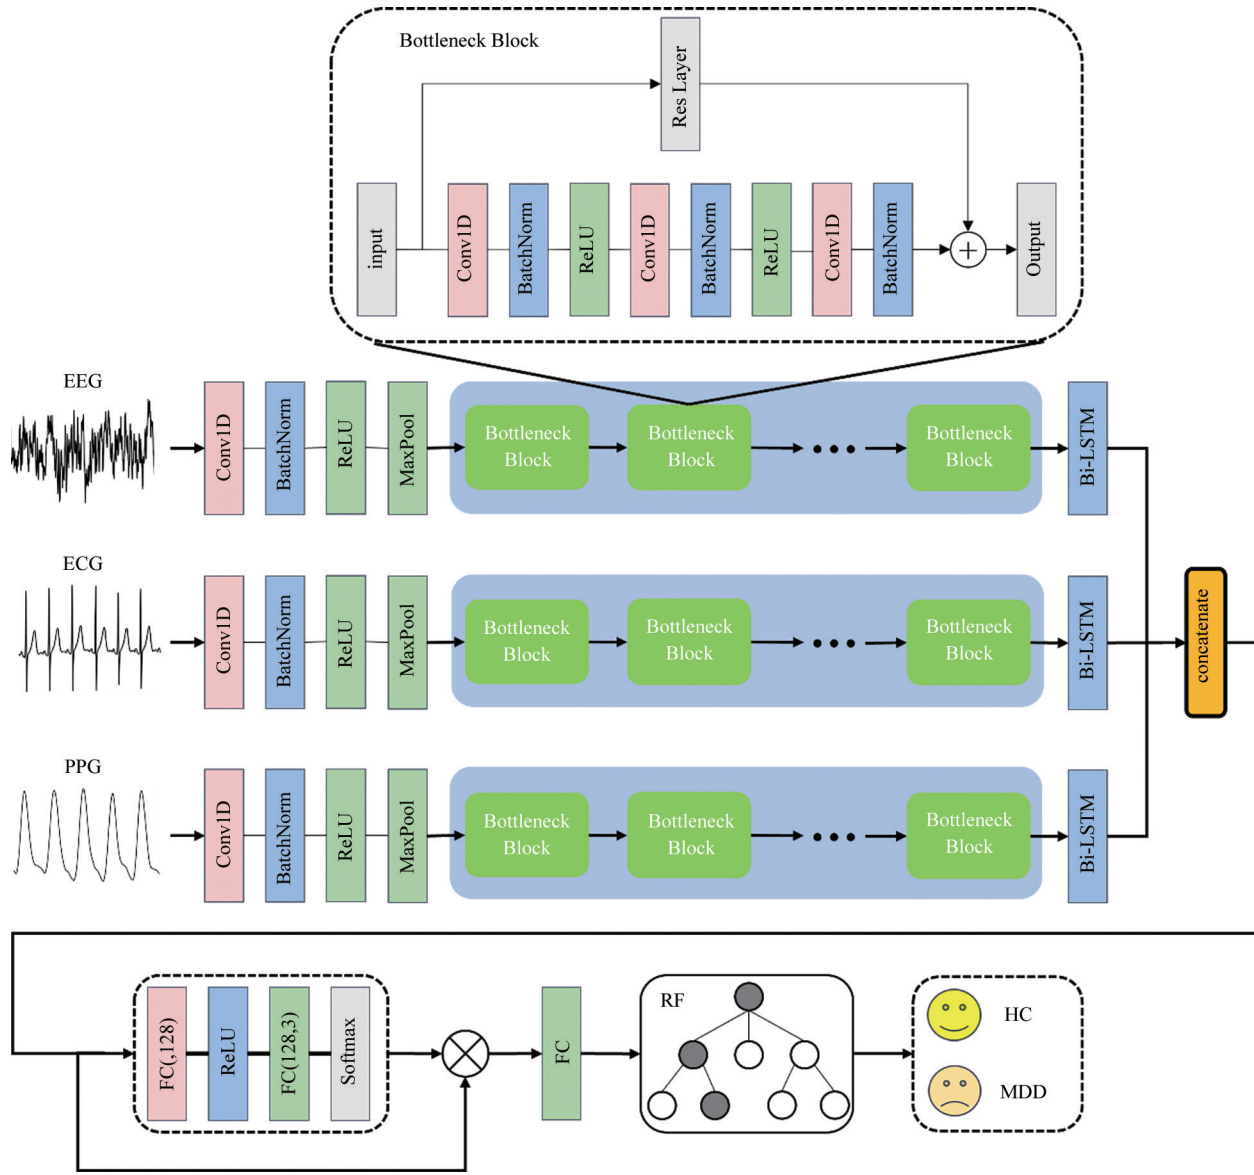


图2 RBLF-Net模型总览图

Figure 2 Overview of RBLF-Net model

### 2.2 训练参数

由于抑郁症患者和健康人的数据分布不完全均衡,且数据集样本数量相对较少,需要采取数据增强方法,提高模型泛化能力。针对生理信号的数据增强有许多策略<sup>[23]</sup>。本研究采用上采样少数类样本的方法对样本数据进行数据增强。使用有放回的重采样方法,使少数类别样本数量与多数类别达到均衡。

在模型训练中,为使随机森林和深度学习模型

能够融合使用,因此采取二阶段训练的方式<sup>[24]</sup>,首先使用训练集和验证集对特征提取模块和加权融合模块进行训练和验证。训练网络时,将用于降维的全连接层的输出表示作为中间输出。网络训练完成后,将其作为特征提取器,冻结其参数,并将训练集数据输入,提取用于随机森林训练的特征。随后,将该特征输入随机森林分类器进行训练。在测试集中检测模型效果时,输入数据先输入深度学习特征提

取模块,再将生成的特征输入到训练好的随机森林中,获得最终的分类结果。训练中所采用的随机森林分类器参数如表2所示。

表2 随机森林分类器的参数细节

Table 2 Parameter details of the random forest classifier

含义	参数值
森林中决策树数量	130
决策树最大深度	25
内部节点划分时所需的最小样本数	4
叶子节点的最小样本数	2
每次分裂时考虑的最大特征数	Sqrt

模型训练采用 AdamW 优化器,相较于 Adam 优化器,增加了权重衰减,确保每次更新时模型参数按 0.002 的比例减小,有助于正则化模型。设置初始学习率为 0.000 04,使模型以更平滑的方式收敛。使用 ReduceLRonPlateau 学习率调度器,通过监控交叉熵损失函数值,在 7 次迭代后未能显著改善时,将学习率按照预设比例减小,以帮助优化器跳出局部极小值。使用 L2 正则化来缓解过拟合。训练时的 batch 大小为 60, epochs 为 65,以平衡计算速度和梯度的准确度,同时避免过度训练。

本研究采用无放回随机抽样的五折交叉验证方法来进行模型开发和验证。将所有被试个体随机分为 5 份,按照 3:1:1 的比例,轮流划分为训练集、验证集、测试集,并且设定同一个被试的样本不会同时出现在训练集和测试集/验证集中,以防止出现数据的泄露。连续做 5 次训练,并保存所有样本的预测结果。完成所有训练后,采取按照样本投票的机制,每个被试者的最终分类结果为所有出现在测试集中的样本结果的平均值。

$$P_i = \frac{1}{N} \sum D_{k,i}^{\text{test}} \quad (3)$$

其中,  $P_i$  表示被试者  $i$  的最终分类结果,  $D_{k,i}^{\text{test}}$  表示第  $k$  折中属于参与者  $i$  的测试样本的结果。  $N$  代表被试者  $i$  的信号样本总数。将平均得分超过 0.5 的认定为抑郁,否则为健康。

### 3 结果与分析

#### 3.1 对比实验

为评估模型的效果,应用不同的模型与方法在数据集上进行相同的五折交叉评估实验。所对比的模型为 CBAM、ResNet50、CNN-LSTM,同样使用 3 种模态的数据。分类实验的指标如表 3 所示,可见本研

究的模型在 5 种不同的指标上相对于其他方法取得较好的性能,在全部 70 个被试者中能够正确识别出 57 个,并且在多种指标上表现均衡。但模型仍存在一定的误报率,对边界样本的区分能力上仍存在改进的空间。

表3 多模态抑郁分类结果指标对比

Table 3 Comparison of indicators for multimodal depression classification results

模型	准确率	F1 分数	AUC	精确度	召回率
CBAM	0.700 0	0.692 4	0.705 0	0.794 1	0.737 5
ResNet50	0.700 0	0.699 4	0.790 8	0.704 8	0.708 3
CNN-LSTM	0.757 1	0.756 7	0.800 0	0.762 1	0.766 7
RBLF-Net	0.814 3	0.811 2	0.805 4	0.810 2	0.812 5

#### 3.2 消融实验

为了评估 RBLF-Net 模型中各个组件对网络性能的贡献,本研究设计消融实验,逐次去除模型中的不同关键部分,并对比性能变化。实验结果如表 4 所示。

表4 消融实验结果

Table 4 Ablation experiment results

消融模型版本	准确率	F1 分数	AUC	精确度	召回率
去除 Bi-LSTM	0.757 1	0.754 7	0.774 2	0.753 9	0.758 3
去除随机森林	0.728 6	0.728 1	0.757 9	0.733 4	0.737 5
去除权重模块	0.757 1	0.755 9	0.810 0	0.757 1	0.762 5
去除随机森林和 LSTM	0.685 7	0.684 7	0.750 0	0.687 9	0.691 7
基准模型 RBLF-Net	0.814 3	0.811 2	0.805 4	0.810 2	0.812 5

由表中第一行结果可见,当去除双向 LSTM 模块时,模型的准确率降至 0.757 1, AUC 值降至 0.774 2, F1 分数降至 0.754 7,说明双向 LSTM 层能够有效地捕捉序列数据的上下文信息,去除该部分后,模型的时序建模能力显著减弱,从而导致分类性能下降。根据第二行结果,去除随机森林并用全连接层代替后,模型准确率减小为 0.728 6, AUC 值为 0.757 9, F1 分数为 0.728 1。这表明在处理多维生理信号特征时,随机森林相较于全连接层鲁棒性更强,能够有效提升分类性能。而不使用特征加权也会致使模型大部分指标下降,说明可训练的加权模块能够有效识别不同模态在分类中的重要性。而在去除随机森林和 LSTM 模块后,模型性能出现较大降低,仅有

0.6857的分类准确率。总体而言,通过消融实验能够得到结论:双向LSTM对模型的时序建模能力和训练稳定性起到重要作用,而随机森林则在特征融合和最终分类中提升效果。去除任一组件都会导致模型性能下降,尤其是将随机森林和LSTM去除后,模型的性能显著下降。因此,通过结合这些模块的优势,所提出的RBLF-Net模型展现了在多模态数据处理和分类中的稳健性能和良好表现。

#### 4 结论

本研究贡献一套基于多生理信号的智能抑郁检测方法,使用自研的可穿戴多生理信号采集设备,结合自主设计的数据采集与实验流程,以身心健康测试的方式收集30例抑郁症患者与40例健康对照组的试验数据,并采用多种模态融合的方法,对前额叶脑电、PPG、单导联心电信号进行评估与分析。本文提出一种结合时空特征、注意力机制及随机森林的多模态抑郁分类模型RBLF-Net,通过学习挖掘3种生理信号的潜在特征,并解决不同模态有效融合的问题,在五折数据上取得相较于其他模型更优的识别效果。本研究能够为院外的大规模抑郁评测与筛查提供有效的手段和技术支撑。

#### 【参考文献】

- [1] Gao P, Cao GY, Liu J, et al. Global, regional, and national trends in incidence of depression among women, 1990-2019: an analysis of the global burden of disease study[J]. *Psychiatry Res*, 2024, 331: 115668.
- [2] Arias de la Torre J, Ronaldson A, Vilagut G, et al. Implementation of community screening strategies for depression[J]. *Nat Med*, 2024, 30(4): 930-932.
- [3] Surkan PJ, Malik A, Perin J, et al. Anxiety-focused cognitive behavioral therapy delivered by non-specialists to prevent postnatal depression: a randomized, phase 3 trial[J]. *Nat Med*, 2024, 30(3): 675-682.
- [4] 张海军,王浩川.多导联EEG信号分类识别研究[J].*计算机工程与应用*, 2008, 44(24): 228-230.  
Zhang HJ, Wang HC. Research on classification and recognition of multi-channel EEG Signal [J]. *Computer Engineering and Applications*, 2008, 44(24): 228-230.
- [5] de Aguiar Neto FS, Rosa JL. Depression biomarkers using non-invasive EEG: a review[J]. *Neurosci Biobehav Rev*, 2019, 105: 83-93.
- [6] Sheen JZ, Miron JP, Mansouri F, et al. Cardiovascular biomarkers of response to accelerated low frequency repetitive transcranial magnetic stimulation in major depression[J]. *J Affect Disord*, 2022, 318: 167-174.
- [7] 张志琴,张佃中.脑电Lempel-Ziv复杂度分析的预处理[J].*中国医学物理学杂志*, 2009, 26(5): 1422-1424.  
Zhang ZQ, Zhang DZ. Preprocessing EEG for Lempel-Ziv complexity analysis[J]. *Chinese Journal of Medical Physics*, 2009, 26(5): 1422-1424.
- [8] Jiang C, Li YJ, Tang YY, et al. Enhancing EEG-based classification of depression patients using spatial information[J]. *IEEE Trans Neural Syst Rehabil Eng*, 2021, 29: 566-575.
- [9] Wan ZJ, Huang JJ, Zhang H, et al. HybridEEGNet: a convolutional neural network for EEG feature learning and depression discrimination [J]. *IEEE Access*, 2020, 8: 30332-30342.
- [10] Sharpley CF, Bitsika V, Shadli SM, et al. EEG frontal lobe asymmetry as a function of sex, depression severity, and depression subtype[J]. *Behav Brain Res*, 2023, 443: 114354.
- [11] Čukić M, Savić D, Sidorova J. When heart beats differently in depression: review of nonlinear heart rate variability measures [J]. *JMIR Ment Health*, 2023, 10: e40342.
- [12] 万春霆.面向虚拟现实环境的生理感知系统及情感识别研究[D].成都:电子科技大学,2023.  
Wan CT. Research on physiological perception system and emotion recognition for virtual reality environment[D]. Chengdu: University of Electronic Science and Technology, 2023.
- [13] Shen J, Li KL, Liang HJ, et al. HEMASNet: a hemisphere asymmetry network inspired by the brain for depression recognition from electroencephalogram signals [J]. *IEEE J Biomed Health Inform*, 2024, 28(9): 5247-5259.
- [14] Habib A, Vaniya SN, Khandoker A, et al. MDDBranchNet: a deep learning model for detecting major depressive disorder using ECG signal [J]. *IEEE J Biomed Health Inform*, 2024, 28(7): 3798-3809.
- [15] Kontaxis S, Gil E, Marozas V, et al. Photoplethysmographic waveform analysis for autonomic reactivity assessment in depression [J]. *IEEE Trans Biomed Eng*, 2021, 68(4): 1273-1281.
- [16] Fan HT, Zhang XN, Xu YY, et al. Transformer-based multimodal feature enhancement networks for multimodal depression detection integrating video, audio and remote photoplethysmograph signals [J]. *Inf Fusion*, 2024, 104: 102161.
- [17] Nowara EM, Marks TK, Mansour H, et al. Near-infrared imaging photoplethysmography during driving [J]. *IEEE Trans Intell Transp Syst*, 2022, 23(4): 3589-3600.
- [18] Kroenke K, Spitzer RL, Williams JB, et al. The patient health questionnaire somatic, anxiety, and depressive symptom scales: a systematic review [J]. *Gen Hosp Psychiatry*, 2010, 32(4): 345-359.
- [19] Lyu ZY, Rodrigues MR. Exploring the impact of additive shortcuts in neural networks via information bottleneck-like dynamics: from ResNet to transformer [J]. *Entropy (Basel)*, 2024, 26(11): 974.
- [20] Yang JR, Huang XF, Wu HK, et al. EEG-based emotion classification based on bidirectional long short-term memory network [J]. *Procedia Comput Sci*, 2020, 174: 491-504.
- [21] Chen QP, Huang GM, Wang YB. The weighted cross-modal attention mechanism with sentiment prediction auxiliary task for multimodal sentiment analysis [J]. *IEEE/ACM Trans Audio Speech Lang Proces*, 2022, 30: 2689-2695.
- [22] Vijayakumar V, Case M, Shirinpour S, et al. Quantifying and characterizing tonic thermal pain across subjects from EEG data using random forest models [J]. *IEEE Trans Biomed Eng*, 2017, 64(12): 2988-2996.
- [23] Wang CL, Liu L, Zhuo WH, et al. An epileptic EEG detection method based on data augmentation and lightweight neural network [J]. *IEEE J Transl Eng Health Med*, 2024, 12: 22-31.
- [24] Zhang H, Zhao M, Liu L, et al. Deep multimodel cascade method based on CNN and random forest for pharmaceutical particle detection [J]. *IEEE Trans Instrum Meas*, 2020, 69(9): 7028-7042.

(编辑:薛泽玲)