

中文引用格式:曹海青,姚志英,吕淑然,等.融合注意力机制的LSTM职工心理压力状态评价方法[J].中国安全科学学报,2026,36(3):229-237.

英文引用格式:CAO Haiqing, YAO Zhiying, LYU Shuran, et al. Evaluation of employee's psychological stress status using LSTM with attention mechanism[J]. China Safety Science Journal, 2026, 36(3):229-237.

融合注意力机制的LSTM职工心理压力状态评价方法*

曹海青¹副教授,姚志英^{**2}副教授,吕淑然¹教授,姚翠友¹教授

(1 首都经济贸易大学管理工程学院,北京 100071;

2 北京物资学院智能工程与供应链创新学院,北京 101149)

中图分类号:X911

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2026.03.0432

【摘要】 为确保职工身心健康,提升心理压力评价方法的准确性与可解释性,以多模态生理时间序列数据为研究对象,提出一种融合注意力机制(AM)的长短期记忆(LSTM)网络方法(LSTMA),实现职工心理压力状态的准确评价。首先,以数据集WESAD中多模态生理时间序列数据(血容量脉搏(BVP)、心电图(ECG)、皮肤电活动(EDA)、肌电图(EMG)、呼吸(RESPIR)、体温(TEMP)和三轴加速度(ACC))为研究对象,通过分模态LSTM模块的门控记忆机制,精准捕获跨时间步时序依赖特征,有效保留与心理状态强相关的关键生理特征,并过滤短期随机噪声,确保生理特征数据能真实表征职工心理状态的动态演化;然后,在特征融合后引入AM,基于各模态、各时间步生理数据的特征重要性自适应分配注意力权重系数,强化对心理压力状态敏感的关键特征与微小响应特征,同时抑制冗余信息干扰;最后,通过全连接神经网络完成心理压力状态准确评价。结果表明:LSTMA在中性、压力、愉悦、冥想4分类任务中,心理压力状态评价准确率达94.56%;经留一法交叉验证后,准确率提升至98.08%;消融试验验证了分模态LSTM与AM的协同增强效应,模型解释性分析进一步佐证LSTMA方法设计的科学性与合理性。

【关键词】 注意力机制(AM); 长短期记忆(LSTM)网络; 心理压力; 状态评价; 生理时间序列数据; 多模态

Evaluation of employee's psychological stress status using LSTM with attention mechanism

CAO Haiqing¹, YAO Zhiying², LYU Shuran¹, YAO Cuiyou¹

(1 School of Management and Engineering, Capital University of Economics and Business, Beijing 100071, China; 2 School of Intelligent Engineering and Supply Chain Innovation, Beijing Wuzi University, Beijing 101149, China)

Abstract: To safeguard employees' psychological health and improve the accuracy and interpretability of psychological stress evaluation methods, taking multimodal physiological time-series data as the research

* 文章编号:1003-3033(2026)03-0229-09; 收稿日期:2025-11-14; 修稿日期:2026-01-15

** 通信作者:姚志英(1977—),女,江苏淮安人,博士,副教授,主要从事应急物资管理、公共安全和供应链安全等方面的研究。E-mail: yaozhiying@bwu.edu.cn.

object, a LSTM with AM(LSTMA) method was proposed to accurately evaluate employees' psychological stress states in the paper. Firstly, using the multimodal physiological time-series data (Blood Volume Pulse (BVP), Electrocardiogram (ECG), Electrodermal Activity (EDA), Electromyogram (EMG), Respiration (RESP), Body Temperature (TEMP), and three-axis Acceleration (ACC)) from the WESAD dataset were adopted as the research carrier, the gating memory mechanism of the modal-specific LSTM modules was utilized to accurately capture cross-time-step temporal dependency features, effectively retain key physiological features strongly associated with psychological states, and filter out short-term random noise, thereby ensuring that the physiological feature data could truly characterize the dynamic evolution of employees' psychological states. Secondly, after feature fusion, the attention mechanism was introduced to adaptively assign attention weight coefficients based on the feature importance of physiological data across different modalities and time steps, enhancing key features and micro-response features sensitive to psychological stress states while suppressing the interference of redundant information. Finally, the accurate evaluation of psychological stress states was accomplished through a fully connected neural network. Experimental results show that the LSTMA method achieves an evaluation accuracy of 94.56% for the four-classification task (neutral, stress, pleasure, and meditation) of psychological stress states. After Leave-One-Out Cross-Validation (LOOCV), the accuracy is improved to 98.08%. Ablation experiments verify the synergistic enhancement effect of the modal-specific LSTM and the attention mechanism, and model interpretability analysis further confirms the scientificity and rationality of LSTMA.

Keywords: attention mechanism (AM); long short-term memory (LSTM) network; psychological stress; status evaluation; physiological time-series data; multimodal

0 引言

职工心理压力是指在环境因素影响下,职工身心所呈现的紧张状态。心理学研究表明:长期处于心理压力下,易引发高血压、失眠、免疫力下降等症状^[1],增加抑郁症、焦虑症和职业倦怠等精神疾病的发病风险^[2],进而影响职工的认知、情感与行为,严重影响职工的生活和工作。为此,研究精准的职工心理压力评价方法,实现压力状态的早期识别与及时干预,对保障职工身心健康、维护社会稳定有着十分重要的意义。

随着人工智能技术在生理信号分析领域的深度渗透,基于生理数据的心理压力评价成为研究热点。早期,FLOVIO^[3]、FITRL^[4]和 GHANAPRIYA^[5]等分别以不同生理特征数据为研究对象,研究了多种机器学习方法在心理压力评价中的应用,但因生理数据来源、特征维度的显著差异,导致不同研究的评价结果缺乏可比性,难以形成统一的技术标准。为解决这一问题,PHILIP等^[6]通过智能可穿戴设备采集被试的血容量脉搏(Blood Volume Pulse,BVP)、心电图(Electrocardiogram,ECG)、皮肤电活动(Electrodermal Activity,EDA)、肌电图(Electromyogram,EMG)、呼吸(Respiration,RESP)、

体温(Body temperature,TEMP)和三轴加速度(Three-Axis Acceleration,ACC)等多模态生理与运动数据,构建了标准化可穿戴式压力与情感检测数据集(Wearable Stress and Affect Detection,WESAD),为心理压力评价提供了公用数据支撑。此后,部分学者基于WESAD数据集中部分模态数据为研究对象,采样频域特征提取法^[4]、时域特征提取法^[3,5]和混合特征提取法^[6,9-10]等传统特征工程手段开展研究,但此类方法仅能捕获生理信号的宏观特征,会错过或遗失一些与心理波动同步的微小生理响应特征,使得心理状态评价的特征不够丰富,制约了评价性能的提升。近年来,注意力机制(Attention Mechanism,AM)被用于优化生理特征提取,ANUBHAV等^[11]通过注意力跨模态连接机制提取EDA与ECC模态间的共享中间特征,提升分类性能;ZHAO Minghui等^[12]提出集成AM的Sinc-长短时记忆(Long Short-Term Memory,LSTM)网络,用于抑郁症评价;WANG Ruiqi等^[13]采用注意力Transformer刻画多模态数据依赖关系,基于WESAD数据集进行方法有效性检验,但评价准确率未超过85%。上述研究通过AM优化WESAD中部分模态数据特征后改善心理压力评价。毫无疑问,生理数据特征是心理状态评价的关键,现有的研究虽已取

得了一定的成就,但仍存在因参与评价的生理数据和所提取的特征不够丰富而影响评价性能的事实;另外现有心理评价方法大部分属于黑盒子模型,缺少对方法和模型的解释性,不利于模型的优化;有必要进一步探索新的方法,弥补上述不足,优化心理状态评价。

鉴于此,笔者拟以WESAD数据集中的多模态生理数据为研究对象,提出一种AM与LSTM相融合的方法(LSTMA)。该方法充分利用LSTM的门控记忆特性,实现时间序列生理数据的关键特征筛选;结合AM的特征精选能力,精准提取多模态、不同时间步长的生理特征,构建职工心理压力评价方法。以期为职工心理压力的早期干预提供技术支撑。

1 融合AM的LSTM职工心理状态评价方法

1.1 LSTMA方法概述

LSTM通过门控记忆特性解决时间序列所面临的梯度消失和梯度爆炸的问题;LSTM的遗忘门单元负责剔除不再需要的信息,输入门单元负责补充新的有用信息,输出门单元负责控制细胞状态的输出信息^[14-15]。WESAD中的BVP、ECG、EDA、EMG、RESP、TEMP和ACC均为与职工心理状态关联的生理时间序列数据,心理状态变化会引起这些生理数据在一段时间内波动,故可利用LSTM处理这些生理时间序列数据,提取不同时间步长、不同模态的特征信息,进行职工心理状态评价。

AM是模拟人类认知过程中视觉注意力选择性关注的能力^[16-18],AM既能够为输入序列中的元素分配连续的注意力权重,并依据反向传播机制自适应迭代优化注意力权重;又可同时关注多源信息,根据信息源的特征差异动态调节对应的注意力权重,实现聚焦关键信息、抑制无关或次要信息的目标。WESAD中不同模态生理时间序列数据在心理状态变化过程中作用不同,在不同时段的表现也不尽相同,AM可为不同模态、不同时段生理数据的重要程度自适应分配不同的权重系数,科学合理地呈现不同模态数据在心理评价中作用。

为此,LSTMA以WESAD中一定时间段内的多模态生理时间序列数据为输入,融合分模态LSTM的特征选择能力与MA的特征精选能力,实现生理数据特征的自适应动态提取,通过全连接神经网络完成职工心理状态的准确评价。

1.2 LSTMA方法的结构

由文献[6]可知:WESAD数据集中不同模态数据的采集频率不一样,为统一试验基准,将所有模态数据的采集频率规范化为700 Hz,选择单位时间步长为1 s,时间序列的步长为60步;特征维度方面,除ACC模态的单位步长特征数为2 100个外,其余模态的单位步长特征数均为700个。模型输出层节点数1为心理状态的评价结果。

在模型结构设计中,遵循如下原则:①确保各模态生理数据与心理状态的关联逻辑、时序演化特征具有独立性;②确保各模态信息在心理状态评价中均能发挥作用;③综合平衡特征提取精度、模型参数规模和过拟合抑制效果。在上述原则的指导下,通过多组参数组合的对比试验,最终确定LSTMA模型结构,如图1所示,具体架构如下:

1) 输入层。由BVP、ECG、EDA、EMG、RESP、TEMP和ACC共7个模态生理时间序列数据组成。

2) 分模态LSTM层。由7个独立的LSTM网络组成,实现各模态生理时序特征的针对性提取。其中,ACC模态对应的LSTM输入维度为(60,2 100)、输出维度为(60,384)、含有384个隐含单元;其余6个模态对应的LSTM输入维度均为(60,700),输出维度均为(60,128),各含128个隐含单元。

3) 特征融合层。采用拼接融合策略,将7个分模态LSTM网络输出的时序特征向量融合为维度为(60,1 152)的综合特征向量。

4) AM层。通过一个“全连接层、展平层和Softmax激活函数”的组合结构,自适应计算出各时间步的注意力权重系数矩阵,加权运算该矩阵与融合特征向量,得到经注意力增强的关键生理特征向量。

5) 输出层。经3个全连接层和2个Dropout层完成特征降维与冗余信息过滤,最终通过第4个全连接层输出职工心理状态评价结果。

1.3 LSTMA方法实现

应用Tensorflow开源机器学习平台所提供的API函数进行模型的实现。应用函数Input和LSTM分别构建模型输入层和LSTM层;应用函数Concatenate实现不同模态特征融合;应用函数Dense、Flatten、Activation、RepeatVector、Permute和Multiply实现注意力权重系数和融合特征计算;应用函数Dense构建4个全连接层,应用函数Dropout构建2个Dropout层;应用函数Summary统计模型的参数和浮点运算量。




图1 LSTMA 模型结构
Fig.1 Structure of LSTMA

1.4 LSTMA 的训练

1) 数据预处理。先从数据集 WESAD 中读取 15 名被试的时间同步后的多模态生理时间序列数据及对应心理状态标签,筛选出标签值为 1(中性)、2(压力)、3(愉悦)和 4(冥想)的有效样本,构建多模态生理数据集。再依据设定的时间序列步长参数,将筛选后多模态生理数据及其对应标签进行时序切片与整合,形成符合 LSTMA 输入要求的试验样本。

为消除不同模态生理数据量级差异带来的额外计算负载,保留数据原始分布特征、避免特征丢失,通过下式归一化处理各模态生理数据:

$$d_{n_{i,j,k}} = \frac{d_{o_{i,j,k}} - \min(d_{o_{i,j}})}{\max(d_{o_{i,j}}) - \min(d_{o_{i,j}})} \quad (1)$$

式中: $d_{o_{i,j,k}}$ 为第 i 个模态生理数据在第 j 时间步长内的第 k 个采样值; $\min(d_{o_{i,j}})$ 为第 i 个模态生理数据在第 j 时间步长内的最小值; $\max(d_{o_{i,j}})$ 为第 i 个模态生理数据在第 j 时间步长内的最大值; $d_{n_{i,j,k}}$ 为 $d_{o_{i,j,k}}$ 为经过归一化处理后的采样值。在数据归一化完成后,采用随机划分策略构建训练集与测试集;随机抽取 80% 的试验样本作为训练集,剩余 20% 的样本作为测试集,用于评估模型的心理状态评价准确度与泛化能力。

2) LSTMA 的参数设置。通过多组对比试验优

化 LSTMA 训练参数,最终确定训练步数 (epochs) 为 1 000,优化器选用 Adam,利用其自适应学习率调整机制,保障训练过程的收敛速度和稳定性;损失函数采用稀疏交叉熵与多分类交叉熵组合,通过梯度反向传播机制驱动模型参数自适应更新,使模型输出的分类概率分布接近真实标签分布;性能评估指标采用分类准确率。同时,为抑制过拟合、避免欠拟合并保留有效时序特征,针对不同网络层设置差异化 Dropout 正则化参数;经多组参数对比试验,分模态 LSTM 层的输入 Dropout 率与循环连接 Dropout 率均为 20%;全连接层为平衡过拟合抑制与参数冗余过滤,Dropout 率设为 30%。

3) 训练过程。LSTMA 训练过程中损失函数值和分类准确率的演化曲线如图 2 所示,由图 2 可知:当模型训练至约 875 步时,其损失函数值趋于稳定;训练至 890 步时,分类准确率稳定在 95% 左右,表明模型已收敛且具备优秀的心理状态评价能力。

1.5 LSTMA 试验结果与分析

1) LSTMA 的测试结果。采用测试集验证训练成熟的 LSTMA 性能,测试结果见表 1。由表 1 可知:LSTMA 心理状态评价准确率达 94.56%,能够基于 BVP、ECG、EDA、EMG、RESP、TEMP 和 ACC 所组成的多模态生理时间序列数据,实现对职工心理状




图 2 LSTMA 训练演化曲线

Fig. 2 Training and evolution curve of LSTMA

表 1 测试结果

Table 1 Testing results

模型分 评价	标签值				%
	中性	压力	愉悦	冥想	
中性	96.81	0.42	5.76	4.86	
压力	0.23	97.8	0.62	2.76	
愉悦	2.02	0.11	92.72	1.47	
冥想	0.94	1.67	0.9	90.91	

态的准确评价。

2) 方法性能比较。为验证 LSTMA 的优越性, 对比与文献[6-8]中所研究的心理状态评价方法的性能, 结果见表 2。由表 2 可知: LSTMA 方法进行心理压力状态评价的准确率显著高于对比方法; 与深度神经网络^[8] (Deep Neural Network, DNN) 相比, LSTMA 参数规模更小、训练效率更高、抗干扰能力更强、鲁棒性好。

3) 冥想状态评价。现有以数据集 WESAD 为对象的大多数研究将心理状态评价设定为三分类问题, 即将心理状态分为中性、愉悦和压力 3 种状态^[6-8]; 然而, WESAD 数据集原始标签将心理状态分为中性、愉悦、压力和冥想 4 类, 为此文中将职工心理状态评价任务设定 4 分类问题。但结果呈现冥想状态的准确率为 90.91%, 明显低于其他 3 种状态的准确率, 进一

表 2 不同方法比较

Table 2 Comparison of different methods

方法	AB ^[6]	RF ^[7]	DNN ^[8]	LSTMA
分类	三分类	三分类	三分类	四分类
准确率/%	80.34	67.56	90.26	94.56
参数量/ $\times 10^6$	12.8	18.5	215.3	156.7
FLOPS/ $\times 10^9$	0.08	0.12	8.6	5.3
单轮训练 时间/min	3.2	4.7	14.5	10.3
加噪后准确率/%	64.74	55.26	81.36	91.36

注: 自适应提升算法 (AdBoost, AB); 随机森林 (Random Forest, RF); 噪声是指方差为 0.05 的高斯白噪声。

步研究发现, 冥想状态所对应生理特征与其他 3 类状态的生理数据特征存在极高的相似性, 导致特征提取与分类决策中极易产生混淆, 这种现象也许是现有研究成果仅进行三分类的主要原因, 也是 LSTMA 方法对冥想状态评价准确率较低的主要原因。

4) 性能优化。考虑到 WESAD 数据集仅包含 15 名被试, 样本容量相对有限, 采用简单随机分为训练集和测试集的方式, 易因数据分布偏差影响 LSTMA 的泛化性能与评价稳定性。为此, 应用留一法交叉验证的策略优化 LSTMA 性能。首先, 读出 WESAD 中全部样本数据, 按“被试-标签”维度将每一位被试心理状态标签所对应的样本均匀分成 5 个互不重叠子集, 整合形成包含 5 个子集的样本池; 其次, 开展 5 轮交叉验证训练与测试, 每一轮训练验证中, 选取 1 个未作为验证的子集作为验证集, 剩余的 4 个子集组成训练集训练 LSTMA; 然后, 每一轮训练均基于上一轮训练收敛后模型参数的基础上进行迭代优化, 确保所有样本均能参与模型训练; 最后, 5 轮交叉验证训练完成后, 将全部样本作为测试样本进行心理状态评价。

优化后测试结果显示, 应用留一法交叉验证后 LSTMA 心理状态评价准确率约 98.08%, 其中, 中性状态评价的准确率为 98.19%, 压力状态评价准确率为 99.02%, 愉悦状态评价的准确率为 97.67%, 冥想状态评价的准确率为 97.53%。试验结果表明: 通过留一法交叉验证策略的优化, LSTMA 的性能得到显著提升, 有效地缓解了样本容量有限场景下数据划分偏差带来的性能波动问题。

1.6 消融试验

为进一步验证 LSTMA 中核心组成模块的合理性及其对模型的贡献, 在保持模型训练流程、参数配置与 1.3 节中完全一致的前提下, 设计 2 组消融试验进行对比验证, 结果见表 3。消融试验的模型变

体设计如下:

1) 模型 1(移除分模态 LSTM 模块)。采用分模态多层感知机(Multi-Layer Perceptron, MLP)替代原模型中分模态 LSTM 模块,保留特征融合模块、AM 模块和全连接分类模块。

2) 模型 2(移除 AM 模块)。剔除 LSTMA 中的 AM 模块,保留分模态 LSTM、特征融合模块和全连接分类模块。

表 3 消融试验结果

Table 3 Results of ablation experiment %		
模型	四分类准确率	冥想状态准确率
LSTMA	94.56	90.91
模型 1(无 LSTM)	85.28	76.42
模型 2(无注意力)	90.32	84.55

对比 LSTMA 和模型 1 的试验结果可知:分模态 LSTM 是 LSTMA 的核心基础,其对模型分类准确率的贡献度可达 9.28%,对冥想状态评价的准确率贡献高达 14.49%,这佐证了时序特征是影响心理状态评价的关键因素,而分模态 LSTM 凭借门控记忆机制对时序依赖关系的建模能力,为模型提供了核心支撑。

对比 LSTMA 和模型 2 的试验结果可知:AM 通过自适应权重分配强化了关键微小特征的代表能力,使 LSTMA 四分类准确率提升 6.24%,冥想状态的准确率提升 6.36%,这充分验证了 AM 的特征精选作用对提升心理状态评价性能的突出价值,尤其是对特征


区分难度较大的冥想状态分类具有显著效果。

综上,消融试验结果表明:LSTMA 的优异性能源于分模态 LSTM 的时序特征筛选能力与 AM 的特征精选能力的协同作用,进一步验证了模型结构设计的科学性与合理性。

1.7 模型解释性

LSTMA 本质属于黑盒子模型,通过模型解释性分析可进一步验证方法的合理性。模型解释性的研究范式包括文字阐释、结果可视化和局部解释等,但由于该问题具有复杂性与主观性,目前学术界尚未形成统一的评价标准和规范方法^[19-21]。在借鉴文献[19,21]研究思路的基础上,以测试案例为切入点,采用“核心模块执行结果可视化+文字阐释”的组合方式开展模型解释性分析。具体而言,随机抽取 1 个测试样本,可视化呈现 LSTMA 关键组成模块的输出,并结合结果特征进行文字阐释,进而验证模型设计的科学性与合理性。

1) 数据归一化模块解释性。用式(1)归一化处理同一测试样本中 0、10 及 40 s 的 BVP 采样数据结果如图 3 所示,由图 3 可知:归一化前后数据的分布特征完全一致,确保了原始数据中蕴含的生理特征模式未发生失真;同时,归一化后数据的数值量级显著降低,有效消除了不同模态数据量级差异引发的算法计算负载冗余问题,验证了数据归一化的有效性。







图 3 LSTM 对 BVP 的处理结果

Fig. 3 Processing results of LSTM for BVP


2) 分模态 LSTM 模块解释性。LSTMA 为不同模态生理时间序列数据设计独立的分模态 LSTM 模块,旨在通过遗忘门、输入门和输出门的协同作用,学习跨时间步的生理特征以支撑心理状态评价,并抑制生理信号中的噪声干扰。图 3c 以 BVP 生理时间序列数据为例,展现分模态 LSTM 的特征提取结果。对比 0、10 及 40 s 的 LSTM 输出特征曲线可发现,遗忘门能够有效保留职工 BVP 模态的长期生理特征,同时过滤局部随机噪声;输入门可精准捕获畸变等微小新特征,并动态更新细胞状态;输出门结合当前输入信息与细胞状态的长期记忆,自适应提取针对性特征。此外,不同时刻的 LSTM 输出特征曲线形态整体相似,细节略有差异,这与职工心理状态基本稳定但存在局部生理波动的客观事实高度吻合。综上,分模态 LSTM 的可视化结果进一步证明,分模态 LSTM 对生理时间序列特征提取的科学性与

合理性,其输出特征能够真实反映职工心理状态的变化特征。

3) AM 模块解释性。LSTMA 中 AM 模块的输入为分模态 LSTM 输出特征经融合后得到的维度为 (60,1152) 的综合特征向量;该模块通过自适应分配不同模态特征的权重系数,输出维度为 (1,1152) 的特征向量,作为全连接分类模块的输入。AM 模块的处理结果如图 4 所示,由图 4 可知:AM 能够根据不同模态数据的特征差异实现权重系数的差异化分配;对比 AM 的特征输入矩阵和输出特征矩阵可见,输出特征矩阵显著降维,但二者的分布特征基本一致。这一结果充分表明:AM 在完成特征维度压缩的同时,完整保留了输入特征矩阵的核心特性,能够充分表征多模态生理时间序列数据的动态变化特征,验证了将 AM 输出特征作为心理状态评价依据的客观性与可信度。



(a) 输入特征矩阵



(b) 注意力权重系数矩阵




图 4 AM 作用效果

Fig. 4 Effect of AM

2 结 论

- 1) 以开源数据集 WESAD 中的多模态生理时间序列数据为研究对象,提出分模态 LSTM 与 AM 有机融合的特征提取与评价框架,实现职工心理压力状态的客观评价。
- 2) 确立多模态生理数据驱动的评价范式,保障评价结果客观可靠。以动态演化的多模态生理时间序列数据为评价依据,整合多模态生理数据的互补特征,弥补单模态数据的信息缺陷,评价结

果与职工真实心理状态高度契合,结果客观、真实、可靠。

- 3) 证实了分模态 LSTM 与 AM 的协同增强效应,提升特征提取效能和评价准确性。应用分模态 LSTM 的门控记忆机制,精准捕获生理序列跨时间步长的关键时序依赖特征;应用 AM 特征精选能力,强化对心理状态敏感的关键特征和微小特征;试验证明:LSTMA 对职工心理压力状态评价的准确率显著优于主流对比方法,且分模态 LSTM 与 AM 的协同作用是 LSTMA 性能提升的核心动力。

参 考 文 献

[1] ELZEINY S, QAEAEQ M. Stress classification using photoplethysmogram-based spatial and frequency domain images[J]. Sensors, 2020,20(18):4 987-4 999.

[2] BOUTER Y, BRZOZKA M M, RYGULA R, et al. Chronic psychosocial stress causes increased anxiety-like behavior and alters endocannabinoid levels in the brain of C57BL/6J mice[J]. Cannabis and Cannabinoid Research, 2020,5(1): 51-61.

[3] FLOVIO D M, FRANCA D. High-resolution physiological stress prediction models based on ensemble learning and recurrent neural networks[C]. Proceedings of the IEEE International Symposium on Intelligent Systems and Computing, 2020:1-6.

[4] FITRL I I, SRI W. Stress detection from multimodal wearable sensor data[C]. Proceedings of the 2nd International Conference on Engineering and Applied Science, 2020:1-7.

[5] GHANAPRIYA S, ORCHID C P, RAVINDER K. Stress recognition with multi-modal sensing using bootstrapped ensemble deep learning model[J]. Expert System, 2023,40(6):1-16.

[6] PHILIP S, ATTLA R, ROBERT D, et al. Introducing WESAD, a Multimodal dataset for wearable stress and affect detection[C]. Proceedings in 2018 International Conference on Multimodal Interaction, 2018:400-408.

[7] PRERNA G, JAYASANKAR S, ANDREAS D, et al. Stress detection by machine learning and wearable sensors[C]. Proceedings in the 26th International Conference on Intelligent User Interfaces, 2021:43-45.

[8] MOHAMED A A A, ROAA M, NANCY M, et al. A deep learning approach using WESAD data for multi-class classification with wearable sensors[C]. Proceedings in the 6th Novel Intelligent and Leading Emerging Sciences Conference, 2024:194-197.

[9] SRIRAM K P, PRAVEEN K G, ABDUL A S G, et al. Deep learning-based automated emotion recognition using multimodal physiological signals and time frequency methods[J]. IEEE Transactions on Instrumentation and Measurement, 2024,73: DOI: 10.1109/TIM.2024.3420349.

[10] CHOI H S. Emotion recognition using a Siamese model and a late fusion-based multimodal method in the WESAD dataset with hardware accelerators[J]. Electronics, 2025,14(4):1-16.

[11] ANUBHAV B, BEHNAM B, DIRK R, et al. Attentive cross-modal connections for deep multimodal wearable-based emotion recognition[C]. 9th International Conference on Affective Computing and Intelligent Interaction Workshop and Demos, 2021:1-5.

[12] ZHAO Minghui, ZHAO Lulu, GAO Hongxiang, et al. Cross-modal attention fusion of electrocardiogram emotion and voiceprint for depression detection[C]. Proceeding of Computing in Cardiology Conference, 2024:1-4.

[13] WANG Ruiqi, JO W, ZHAO Dezhong, et al. Husformer: a multi-modal transformer for multi-modal human state recognition[J]. IEEE Transactions on Cognitive and Developmental Systems, 2024,16(4):1 374-1 390.

[14] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997,9(8):1 735-1 780.

[15] 陈小乾,尹亮,展宗辉,等. 基于注意力机制和 RCN-BiLSTM 融合的风电机组故障识别[J]. 中国电力,2025,58(8): 94-102.

CHEN Xiaolian, YIN Liang, ZHAN Zonghui, et al. Fault identification for wind turbine based on attention mechanism and RCN-BiLSTM fusion[J]. Electric Power, 2025,58(8):94-102.

[16] ITTI L, KOCH C, NIEBUR E. A model of saliency-based visual attention for rapid scene analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998,20(11):1 254-1 259.

[17] 吴思,张旭光,方银锋. 基于注意力机制的人群计数方法[J]. 中国安全科学学报,2022,32(1):127-134.

WU Si, ZHANG Xuguang, FANG Yinfeng. Method of crowd counting based on attention mechanism[J]. China Safety Science Journal, 2022,32(1):127-134.

[18] 曹淑超,戈伟斌,里聪慧,等. 基于注意力 Seq2Seq 网络的人群安全风险评估[J]. 中国安全科学学报,2025, 35(12):196-203.

CAO Shuchao, GE Weibin, LI Conghui, et al. Crowd safety risk assessment based on Seq2Seq-attention network[J]. China Safety Science Journal, 2025,35(12):196-203.

[19] HENDRICKS L A, AKATA Z, DARRELL T. Generating visual explanations[C]. 14th European Conference on Computer Vision (ECCV), 2016:3-19.

[20] KANG Tianyu, DING Wei, CHEN Ping. CRESPR: modular scarification of DNNs to improve pruning performance and model interpretability[J]. Neural Networks, 2023,172: DOI: 10.1016/j.neunet.2023.12.021.

[21] MICHAL B, HENRIK S. Generating visual explanations from deep networks using implicit neural representations[C]. 2025 IEEE/CVE Winter Conference on Applications of Computer Vision, 2025, 7:3 310-3 319.

作者简介： 曹海青 （1976—）,男,山西吕梁人,博士,副教授,主要从事公共安全、数据化决策和智能算法方面的研究。E-mail: caohaiqing@cueb.edu.cn。

