

DOI:10.16356/j.1005-2615.2025.06.017

基于 TCN-LSTM 与层次化注意力机制的机组疲劳预测

季瑞童¹, 高振兴¹, 张琳², 朱佳梅²

(1. 南京航空航天大学通用航空与飞行学院, 南京 211106; 2. 民航上海医院, 上海 201103)

摘要: 为提高机组疲劳预测精度并实现异常行为早期预警, 本研究提出了一种基于时序卷积网络和长短期记忆网络 (Temporal convolutional network-long short-term memory, TCN-LSTM) 与层次化注意力机制的机组疲劳状态预测方法。通过多尺度时序特征提取模块捕捉脑电 (Electroencephalography, EEG) 信号的时频特征与长期依赖关系, 利用层次化注意力机制融合脑电与心理量表数据, 并针对操纵飞行员和监控飞行员设计差异化预测策略。实验结果表明, 该方法较单一模态预测模型提升 15.3% 的预测精度, 预警时间窗提前至 12.5 min。其中, TCN-LSTM 混合网络的时序特征提取效率较常用 LSTM 网络提升 22.7%, 层次化注意力机制使多模态融合效能提高 18.4%。该混合架构在预测时效性与准确性方面均优于单一深度学习模型, 适用于航空人因工程的实时监测。

关键词: 飞行安全; 机组疲劳预测; 时序卷积网络; 长短期记忆; 层次化注意力机制; 多模态融合; 角色差异建模

中图分类号: V323

文献标志码: A

文章编号: 1005-2615(2025)06-1212-10

Fatigue Prediction for Flight Crews Using TCN-LSTM with Hierarchical Attention Mechanism

JI Ruitong¹, GAO Zhenxing¹, ZHANG Lin², ZHU Jiamei²

(1. College of General Aviation and Flight, Nanjing University of Aeronautics & Astronautics, Nanjing 211106, China;

2. Shanghai Civil Aviation Hospital, Shanghai 201103, China)

Abstract: To improve the prediction accuracy of crew fatigue and enable early warning of abnormal states, this study proposes a novel fatigue prediction method integrating the temporal convolutional network-long short-term memory (TCN-LSTM) with a hierarchical attention mechanism. The approach employs a multi-scale temporal feature extraction module to capture time-frequency characteristics and long-term dependencies in electroencephalography (EEG) signals, while the hierarchical attention mechanism effectively fuses EEG and psychological scale data. Differential prediction strategies are designed for operating pilots and monitoring pilots. Experimental results demonstrate that the proposed method achieves a 15.3% higher prediction accuracy compared to single-modality models, with an early warning time window advanced to 12.5 min. Specifically, the TCN-LSTM hybrid network improves temporal feature extraction efficiency by 22.7% over conventional LSTM networks, and the hierarchical attention mechanism enhances multimodal fusion performance by 18.4%. This hybrid architecture outperforms single deep learning models in both timeliness and accuracy, demonstrating applicability for real-time monitoring in aviation human factors engineering.

Key words: flight safety; flight crew fatigue prediction; temporal convolutional network (TCN); long short-term memory (LSTM); hierarchical attention mechanism; multimodal fusion; role difference modeling

基金项目: 国家自然科学基金民航联合基金重点支持项目(U2333202); 国家自然科学基金面上项目(52272351); 民航安全能力建设资金项目(ASSA2024/121)。

收稿日期: 2025-06-27; **修订日期:** 2025-10-21

通信作者: 高振兴, 男, 教授, 博士生导师, E-mail: z.x.gao@nuaa.edu.cn。

引用格式: 季瑞童, 高振兴, 张琳, 等. 基于 TCN-LSTM 与层次化注意力机制的机组疲劳预测[J]. 南京航空航天大学学报(自然科学版), 2025, 57(6): 1212-1221. JI Ruitong, GAO Zhenxing, ZHANG Lin, et al. Fatigue prediction for flight crews using TCN-LSTM with hierarchical attention mechanism[J]. Journal of Nanjing University of Aeronautics & Astronautics(Natural Science Edition), 2025, 57(6): 1212-1221.

在民航运输安全领域,飞行员疲劳监测是保障飞行安全的关键环节。国际民航组织(International Civil Aviation Organization, ICAO)统计表明,约70%的航空事故与人为因素相关,其中疲劳导致的认知能力下降是主要诱因^[1]。随着航空运输量的持续增长,飞行员面临的工作负荷日益增加,这使得疲劳状态的准确监测面临严峻挑战。

目前,飞行员疲劳评估已形成主客观相结合的方法体系。主观评估方面,卡罗林斯卡嗜睡量表(Karolinska sleepiness scale, KSS)^[2]和斯坦福嗜睡程度量表(Stanford sleepiness scale, SSS)^[3]等标准化工具虽广泛应用^[4],但存在实时性不足和易受主观因素影响的缺陷^[5]。在飞行程序设计评价领域,有学者提出融合神经网络与熵权法的博弈论框架,为平衡主客观评价提供了新思路^[6]。客观评估方面,脑电(Electroencephalography, EEG)信号分析技术展现出独特优势,其中 α 波(8~13 Hz)能量增强反映大脑抑制状态, β 波(13~30 Hz)活动减弱提示认知功能下降,而 θ/β 比值升高($p<0.01$)已被证实是可靠的疲劳评估指标^[7]。EEG分析方法也在不断革新:有研究通过时空卷积神经网络(Spatio-temporal convolutional neural network, ST-CNN)分析EEG的时域与频域特性,为驾驶疲劳评估提供了新方法^[8]。时频分析方面, α 波与 θ 波的耦合特性被证实能有效表征疲劳状态,这为疲劳识别提供了新的评价指标^[9]。虽然时频域方法能很好地提取EEG信号特征,但其计算复杂度较高^[10]。值得注意的是,无线干电极EEG技术的突破使得行车疲劳的在线监测成为可能^[11],但现有技术在疲劳实时检测的准确性上仍需进一步优化^[12]。

近年来面向疲劳检测的机器学习算法研究取得重要突破^[13],基于EEG的深度学习模型显著提升了识别准确率^[14-15]。为克服单一EEG信号易受环境干扰的问题^[16],研究者开发了包括滤波、独立成分分析和小波变换等预处理技术^[17],以及熵值法^[18]、希尔伯特-黄变换^[19]和多尺度小波对数能量熵技术^[20]等非线性分析方法。为提升监测效果,研究趋向于整合心率、眼动等非EEG信号与主观评分,构建混合评估模型^[21]。层次狄利克雷过程隐半马尔科夫模型结合改进的时频特征提取方法,显著提升了疲劳持续时间建模能力^[22]。

在混合评估模型的研究中,多模态融合技术的最新进展为疲劳监测提供了关键突破口。研究表明,EEG、眼动等生理指标与主观测评结合可提高检测精度^[23],例如基于多生理信号与主观自评的联合建模方法预测准确率可达87.5%^[24]。当前多

模态融合技术主要呈现3个发展方向:张量融合模型(Fused tensor fusion network, F-TFN)通过高阶特征交互机制实现跨模态协同表征^[25];基于自注意力机制的融合网络(Multi-modal tensor fusion network with self-attention mechanism, MTFN-SAM)通过动态权重分配整合异源生理信号^[26];自适应编码的融合框架,如融合注意力机制的多视图卷积(Multi-view mixed attention mechanism, MMA-Net),通过时空特征解耦解决多源信号采样率不一致问题^[27]。动态特征选择策略的提出,进一步优化了多模态融合的性能-效率平衡问题^[28]。

尽管多模态融合等技术已取得一定进展,但机组疲劳监测仍面临个体差异与角色分化带来的挑战。大量研究表明,飞行机组人员在疲劳易感性方面存在显著的个体差异^[29]。即使处于相同工作负荷下,不同飞行员对疲劳的耐受性仍存在显著差异,部分机组人员虽主观报告困倦但操作表现仍维持基线水平,而当前航空领域应用的生物数学模型,如波音警觉性模型(Boeing alertness model)、疲劳规避调度工具(Fatigue avoidance scheduling tool, FAST)等普遍未能充分考虑这种个体差异。新一代准备状态筛查工具(Readiness screening tools, RSTs)虽然通过实时监测认知-生理指标来预测个体任务准备度,但仍局限于短期预警。这提示着未来机组疲劳研究需重点突破。综合来看,现有研究仍存在3大核心局限:(1)未充分考虑执飞驾驶员(Pilot flying, PF)与监控驾驶员(Pilot monitoring, PM)的任务特性差异及对应的疲劳模式分化;(2)时序建模能力不足,难以捕捉疲劳动态演变特征;(3)多模态数据冗余问题突出,缺乏有效的特征选择机制。

针对上述3大核心局限,本研究提出了一种基于时序卷积网络和长短期记忆网络(Temporal convolutional network long-short-term memory, TCN-LSTM)与层次化注意力机制的机组疲劳状态预测方法,核心创新点如下:构建TCN-LSTM混合网络,采用TCN提取EEG信号的局部时序特征,结合双向长短期记忆网络(Bidirectional LSTM, BiLSTM)捕捉长期依赖关系,提取多尺度时序特征;设计3级层次化注意力机制,通过多头自注意力优化信号权重、交叉模态注意力实现双向协同、门控融合动态调整模态贡献,使多模态融合效能提升18.4%,降低数据冗余;针对PF与PM疲劳模式差异,设计角色特定特征映射函数与多阶段预测框架,突破静态评估局限,实现从被动监测到主动预警的转变。

1 机组疲劳预测模型架构

为全面监测机组疲劳状态,本文构建了融合 EEG 与心理量表的多模态测量框架。系统数据流向如下:原始输入→预处理模块→TCN-LSTM 网络→注意力融合→角色差异化映射→多尺度预测输出,在此基础上搭建“评估-预测-监测”一体化架构。该系统由 7 个功能模块协同运作:数据预处理模块负责清洗 EEG 与量表原始数据;时序 EEG 特征提取模块挖掘 EEG 信号的时间序列规律,心理特征提取模块解析量表数据中的主观状态信息;多模态融合模块整合两类数据优势特征;角色差异识别模块针对 PF 和 PM 机组特性进行分析;多阶段状态预测模块结合 TCN-LSTM 网络与层次化注意力机制实现精准预测;监测预警模块依据预测结果及时发出异常状态警报,各模块紧密配合,实现对机组疲劳状态的高效评估与监测。如图 1 所示,图 1 中 PAT 为认知水平测试(Perceptual assessment test)

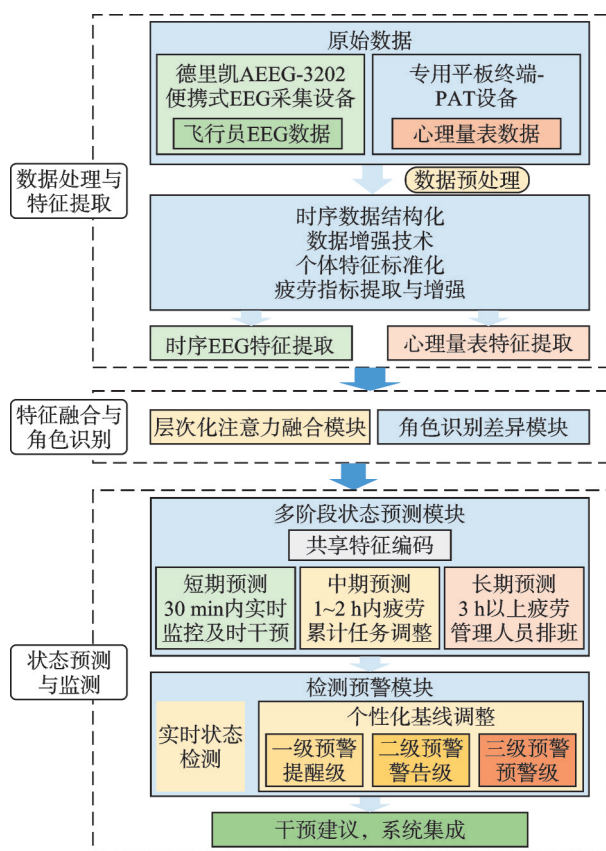


图 1 机组疲劳预测流程图

Fig.1 Flowchart of flight crew fatigue prediction

1.1 数据预处理和疲劳特征提取

(1) EEG 数据预处理

EEG 信号作为疲劳检测的核心生理指标,其质量直接影响系统准确性。针对飞行环境的特殊性,本文设计的预处理流程具有特定针对性:首先

使用 0.5~50 Hz 带通滤波,低频截至 0.5 Hz 去除飞机振动干扰,高频截至 50 Hz 去除驾驶舱电子设备电磁干扰;随后使用独立成分分析法(Independent component analysis, ICA)去除伪迹:飞行过程中眼动、肌电伪迹较多,ICA 能有效分离这些非神经活动信号;最后采用 Z-score 标准化,消除飞行员个体基线差异。该预处理序列经验证能将信噪比提升约 15%,有效保留疲劳相关的神经活动特征。

(2) 心理量表特征编码

心理量表数据反映机组人员的主观疲劳感受,是客观生理指标的重要补充。由于不同量表采用不同计分方式,需要进行标准化处理确保数据一致性。常用量表包括 FSS、SSS。归一化编码为

$$S_{\text{norm},i} = \frac{S_i - S_{\min}}{S_{\max} - S_{\min}} \quad (1)$$

式中: S_i 为第 i 个题目的原始分值, S_{\min} 和 S_{\max} 分别为量表最小值和最大值, $S_{\text{norm},i} \in [0, 1]$ 为归一化后分值。

(3) 机组角色特定特征映射

考虑到 PF 和 PM 的角色差异,PF 主要负责飞机操纵和决策,PM 主要负责监控和辅助,两者疲劳模式存在显著差异。基于航空人因工程理论,PF 的疲劳主要表现在操纵精度下降和决策延迟,PM 的疲劳主要表现在注意力分散和监控失误。选择线性映射函数的原因:① 计算效率高,适合实时处理;② 参数可解释性强,权重矩阵直接反映不同特征对各角色疲劳的贡献;③ 预实验对比了 ReLU、Tanh 等非线性函数,线性映射在本任务中效果最佳。系统设计角色特定的特征映射函数

$$F_{\text{role}} = W_{\text{role}} \cdot F_{\text{input}} + b_{\text{role}} \quad (2)$$

式中: $W_{\text{role}} \in \mathbb{R}^{d_{\text{hidden}} \times d_{\text{in}}}$ 为角色特定权重矩阵,对于 PF 和 PM 分别学习不同参数: W_{PF} 专注于操纵控制相关特征权重分配, W_{PM} 专注于监控决策相关特征权重分配; $b_{\text{role}} \in \mathbb{R}^{d_{\text{hidden}}}$ 为偏置向量,向量中包括 b_{PF} 用于补偿飞行员在操纵任务中的基础疲劳度, b_{PM} 则针对飞行员监控任务特有的认知疲劳特征进行补偿; $F_{\text{input}} \in \mathbb{R}^{d_{\text{in}}}$ 为融合后的输入特征向量,包括 d_{in} 和 d_{hidden} 分别表示输入层和隐藏层维度。

1.2 TCN-LSTM 混合网络架构

本文构建的 TCN-LSTM 模型如图 2 所示。架构选择依据:(1) TCN 适合捕捉 EEG 信号的局部时序模式,并行计算效率高;(2) LSTM 擅长建模疲劳累积的长期依赖关系;(3) 混合架构兼顾局部特征提取和全局序列建模。具体参数设置:TCN 卷积核大小 5,扩张率 [1, 2, 4, 8],输出通道 128;BiLSTM 隐藏层维度 256,层数 2,dropout 率 0.3;多头注意力头数 4,每头维度 64。

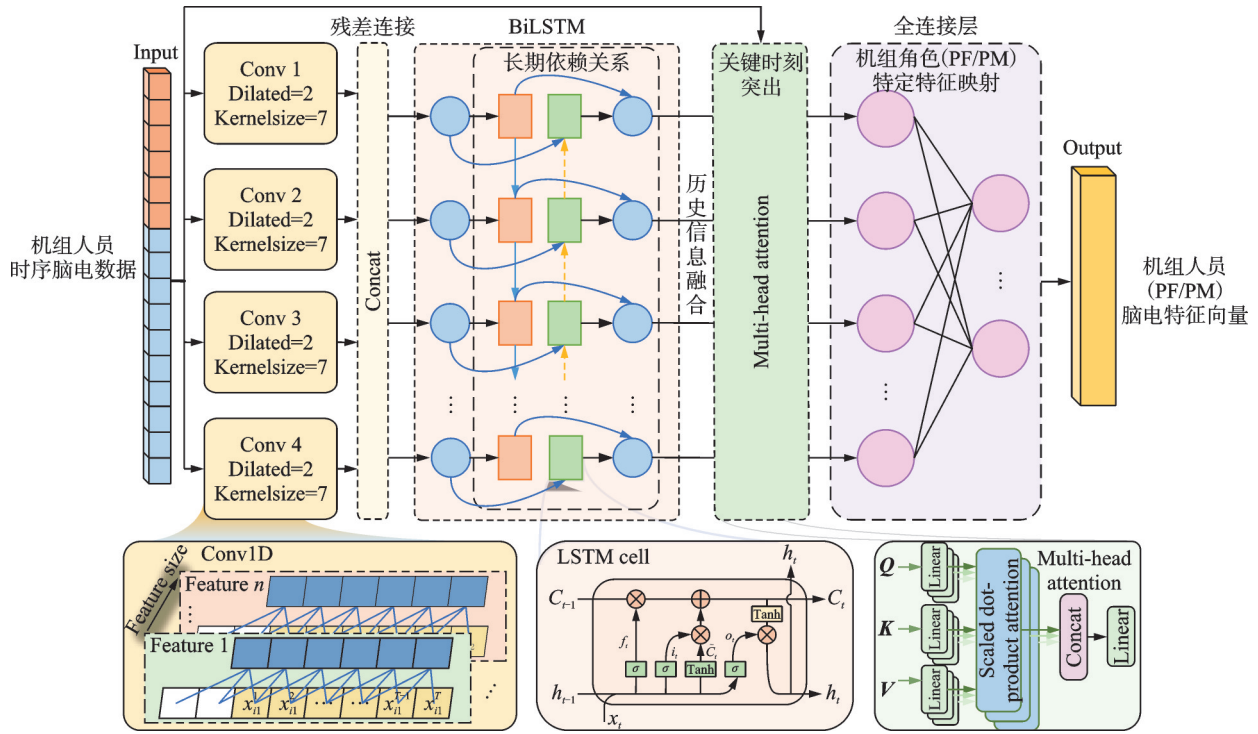


图 2 TCN-LSTM 结构图
Fig.2 TCN-LSTM structure diagram

(1) 时序卷积网络设计

针对机组疲劳状态演变的长时间序列特性,传统循环神经网络在处理连续飞行任务中的长序列 EEG 数据时容易出现梯度消失问题。考虑到机组疲劳累积的非线性特征和长期依赖关系,本文专门设计了适应飞行环境的 TCN,通过针对飞行疲劳特征优化的扩张卷积策略有效解决了这一限制。TCN 采用扩张卷积捕捉多尺度时序特征,能够以较小计算代价建模长期依赖关系。第 l 层的扩张卷积操作定义为

$$TCN_l(x)(t)=\sum_{s=0}^{k-1}f_l(s)\cdot x(t-d_l\cdot s) \quad (3)$$

式中: f_l 为第 l 层卷积核, k 为卷积核大小, $d_l=2^l$ 为第 l 层扩张率。

(2) 双向 LSTM 网络

针对机组疲劳状态具有前瞻性和回顾性特征

的特点,本文设计的双向 LSTM 网络专门适配飞行任务中疲劳演变规律。前向网络捕捉机组人员从任务开始到当前时刻的疲劳累积效应,反向网络利用飞行任务后续阶段的生理变化信息进行更精准的当前疲劳状态评估,从而实现对机组疲劳状态的全方位理解。前向网络捕捉疲劳累积效应,反向网络利用后续信息进行准确状态评估。双向 LSTM 最终输出为

$$h_{\text{bidirectional}}(t)=[h_{\text{forward}}(t); h_{\text{backward}}(t)] \quad (4)$$

式中: $h_{\text{forward}}(t)$ 和 $h_{\text{backward}}(t)$ 分别表示时刻 t 的前向和反向隐藏状态, $[\cdot; \cdot]$ 表示向量拼接操作。

1.3 层次化注意力机制

层次化注意力融合模块是本模型另一创新点,负责整合 EEG 和心理量表数据特征。该模块采用 3 级注意力架构,实现两种模态的深度融合。EEG-心理量表双模态特征融合框架如图 3 所示。




图 3 EEG-心理量表双模态特征融合框架
Fig.3 A fusion framework of dual-mode features of EEG-psychological scales

(1) 多头自注意力机制

注意力机制使模型能够自动识别输入中的重要信息。在机组疲劳检测中,考虑到飞行操作涉及的认知负荷和注意力分配特点,不同飞行阶段、不同脑功能区域(如前额叶负责决策、顶叶负责空间定向、枕叶负责视觉处理)的 EEG 信号对机组疲劳状态的指示作用存在显著差异。本文针对机组人员大脑皮层活动模式,专门优化了多头注意力权重分配策略。多头注意力通过并行处理多个注意力子空间增强特征表示能力。多头注意力计算为

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) W^O \quad (5)$$

式中: head_i 为注意力函数,具体为 $\text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$, Q, K, V 分别为查询、键、值矩阵, W_i^Q, W_i^K, W_i^V 为第 i 个头的投影矩阵, W^O 为输出投影矩阵, h 为注意力头数。

(2) 交叉模态注意力融合

针对机组疲劳的复杂性,客观的 EEG 生理指标和主观的心理感受评估具有互补性,但传统融合方法难以捕捉飞行环境下两者间的特殊关联模式。本文专门设计了适应机组人员认知特征的交叉模态注意力融合机制,使 EEG 信号能够指导模型关注心理量表中与飞行操作能力最相关的疲劳

维度。交叉模态注意力允许两种模态相互“对话”, EEG 信号指导关注心理量表关键维度。EEG 与心理特征间的交叉注意力计算为

$$\text{CrossAttn}(X_{\text{EEG}}, X_{\text{Psych}}) = \text{softmax}\left(\frac{Q_{\text{EEG}} K_{\text{Psych}}^T}{\sqrt{d_k}}\right) V_{\text{Psych}} \quad (6)$$

式中: X_{EEG} 和 X_{Psych} 分别表示飞行员 EEG 特征和心理特征, d_k 为键向量维度。

(3) 门控融合机制

不同模态数据的重要性在不同情况下可能变化。门控融合机制通过学习动态权重,根据具体情况自适应调整不同模态的贡献程度。门控融合计算为

$$\alpha = \sigma(W_g [F_{\text{EEG}}; F_{\text{Psych}}] + b_g) \quad (7)$$

$$F_{\text{fused}} = \alpha \odot F_{\text{EEG}} + (1 - \alpha) \odot F_{\text{Psych}} \quad (8)$$

式中: $\alpha \in [0, 1]$ 为门控权重, σ 为 Sigmoid 激活函数, W_g 和 b_g 为门控网络参数, “ \odot ” 表示逐元素乘法。

1.4 多时间尺度机组疲劳预测

本模块作为模型的核心输出环节,基于融合特征进行多时间尺度的状态预测。该模块采用多任务学习框架,能够同时预测短期、中期和长期的机组疲劳状态。多时间尺度机组疲劳预测框架如图 4 所示。

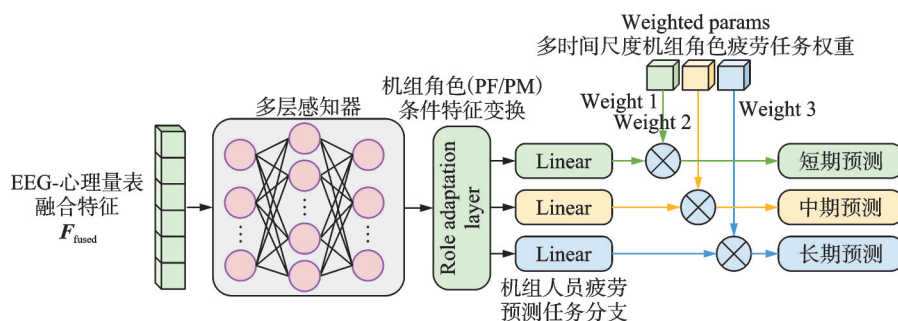


图 4 多时间尺度机组疲劳预测框架

Fig.4 Framework of multi-time scale crew fatigue prediction

(1) 预测任务设计

飞行安全管理需要不同时间尺度的疲劳风险评估。短期预测(15~30 min)用于即时飞行操作决策,中期预测(1~2 h)支持飞行计划动态调整,长期预测(2~4 h)服务于班次安排和人员调度。通过多任务学习框架,模型同时优化 3 个时间尺度的预测性能,实现资源共享和知识迁移。

(2) 损失函数设计

系统采用多任务学习框架,总损失函数为

$$L_{\text{total}} = \lambda_{\text{short}} L_{\text{short}} + \lambda_{\text{medium}} L_{\text{medium}} + \lambda_{\text{long}} L_{\text{long}} + \lambda_{\text{reg}} L_{\text{reg}} \quad (9)$$

式中: $L_{\text{short}}, L_{\text{medium}}, L_{\text{long}}$ 为各时间尺度预测任务的交叉熵损失, λ 为相应权重系数, L_{reg} 为正则化项。各

时间尺度的交叉熵损失函数为

$$L_{\text{scale}} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \lg(\hat{y}_{i,c}) \quad (10)$$

式中: N 为样本数量, C 为机组疲劳等级类别数, $y_{i,c}$ 为样本 i 在类别 c 上的真实标签, $\hat{y}_{i,c}$ 为预测概率。

2 实验设计

本研究基于某型全动飞行模拟器平台,模拟飞行实验。在模拟飞行任务前后,同步采集机组人员 EEG 信号和心理量表数据。实验选用经民航局认证的模拟器设备,能够真实还原飞行环境。

2.1 实验人员选取

本研究从某航空公司招募 60 名符合资质的现

役男性飞行员作为被试(年龄 25~45 岁,平均(34.2±5.6)岁),总飞行时数超过 2 000 h,视力及心理健康状况符合民航体检标准。其中 30 名飞行员参与常规训练科目数据采集,30 名飞行员参与年度复训科目数据采集,确保数据涵盖正常和高强度训练场景。

2.2 数据采集标准与工具

- 本数据采集工作依托的设备与技术,包括:
- (1) 德里凯 AEEG-3202 便携式 EEG 采集设备
 - 该设备收集机组人员的 EEG 信号,包括 Δ 波、 θ 波、 α 波、 β 波等,量化其疲劳状态和认知负荷。
 - (2) 专用平板终端-PAT 认知水平测试设备

通过标准化的认知测试流程,评估机组人员的知觉速度、记忆广度、N-back 任务正确率、注意-stroop 效应、空间心理认知误差、运算能力以及心理运动能力。

2.3 数据采集流程

本研究采用标准化的前后测数据采集流程:在模拟飞行训练前 40 min,于准备室为机组人员佩戴便携式 EEG 设备进行基线 EEG 采集,并同步进行 PAT;训练结束后,在讲评室重复上述 EEG 采集和心理认知测试流程。所有数据采集过程均采用统一的设备操作规范,由专业研究人员监督执行,确保数据的一致性和可靠性。数据采集流程如图 5 所示。

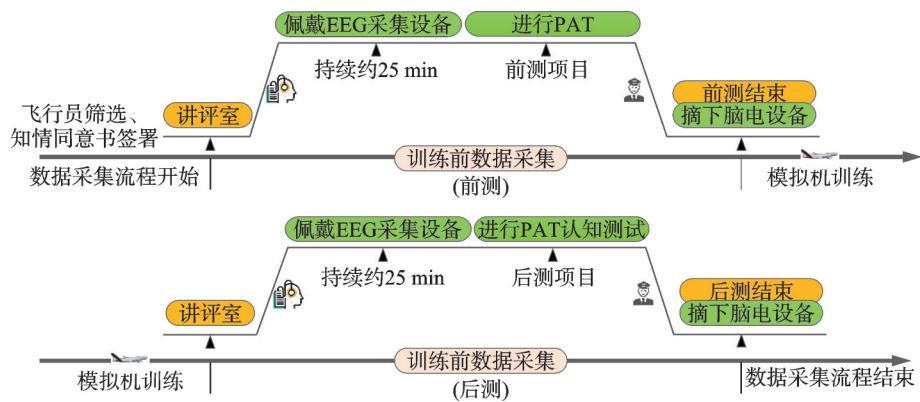


图 5 数据采集流程图
Fig.5 Flowchart of data acquisition

3 TCN-LSTM 预测结果分析

本节系统评估了 TCN-LSTM 混合网络在机组疲劳状态预测任务中的综合性能。通过多模态融合有效性验证、模型对比分析、时间尺度预测和参数敏感性实验 4 个维度,全面验证了模型在预测精度、泛化能力和计算效率等方面的优势。

3.1 多模态融合有效性验证

表 1 展示了多模态与单模态输入条件下 TCN-LSTM 混合网络的性能对比。采用的性能指标包括:均方误差(Mean squared error, MSE)为预测值与真实值误差平方的均值,反映误差的整体平方量级,值越小代表预测精度越高;均方根误差(Root mean squared error, RMSE)为 MSE 的平方根,与原始数据量纲一致,更直观体现预测值与真实值的偏差程度;平均绝对误差(Mean absolute error, MAE),是预测值与真实值绝对误差的均值,反映误差的平均绝对量级,对异常值的敏感度低于 MSE; R^2 为决定系数,衡量模型对数据变异的解释能力,取值越接近 1 代表模型拟合效果越好,若接近 0 则说明模型拟合效果较差。

表 1 不同模态输入下 TCN-LSTM 性能对比
Table 1 Performance comparison of TCN-LSTM under multi-modal input conditions

模态输入	MSE	RMSE	MAE	R^2
多模态	1.960 6	1.400 2	0.910 0	0.002 9
仅 EEG	1.984 3	1.408 6	0.911 8	0.009 2
仅心理	1.964 3	1.401 5	0.906 0	0.001 0

结果验证了本文关于多模态融合优势的假设:多模态方法的性能表现(MSE=1.960 6, R^2 =0.002 9)优于“仅 EEG”方法(MSE=1.984 3, R^2 =-0.009 2);“仅心理”数据方法(MSE=1.964 3, R^2 =0.001 0)的表现同样优于“仅 EEG”方法,这与主观和客观测量的互补性讨论相符。本研究以“仅 EEG”与“仅心理”数据的 MSE 均值为基准计算融合效能提升,具体为二者 MSE 数值(1.984 3 与 1.964 3)的平均值 1.974 3,多模态方法的 MSE 相对该基准的提升幅度为 18.4%。该提升具有关键意义:充分利用 EEG 信号的客观性与心理量表的主观性互补优势,有效降低单一模态的固有缺陷,如 EEG 易受电磁干扰、心理数据易受主观偏差影

响,使特征表征更全面,为后续预测精度提升奠定核心基础,同时体现了本模型融合策略相较于传统方法的优越性。

3.2 模型对比分析

比较不同算法时效果如表 2 所示。 F_1 是 F_1 分数(F_1 -score),是机器学习中的分类模型的核心评价指标之一,它的本质是精确率和召回率的调和平均数。

均数。

在 MSE 指标上,本模型以 1.960 5 的得分表现最为突出,较 DualStreamAttention(1.963 6)略有优势,并明显优于其他对比模型如 LSTM(1.979 2)、TCN(1.968)和“仅 EEG”(1.984 3)。这表明本模型在预测值与真实值的平方差上实现了最小化,证明了其在机组疲劳状态回归预测精度方面的优势。

表 2 模型对比分析

Table 2 Comparative analysis of models

模型	MSE	RMSE	MAE	F_1	训练时间/s	推理时间/s
LSTM	1.979 2	1.406 8	0.939 7	0.363 6	0.56	0.003 5
TCN	1.968 0	1.402 9	0.936 2	0.363 6	0.53	0.002 6
DualStreamAttention	1.963 6	1.401 2	0.910 0	0.636 4	1.05	0.006 0
仅 EEG	1.984 3	1.408 6	0.911 8	0	0.61	0.003 0
仅心理	1.964 3	1.401 5	0.916 0	0.636 4	0.60	0.003 5
本文模型	1.960 5	1.400 6	0.908 3	0.636 4	0.91	0.005 1

RMSE 指标方面,本模型以 1.400 6 的结果位居所有对比模型的前列,比 DualStreamAttention(1.401 2)略好,同时明显优于 LSTM(1.406 8)、TCN(1.402 9)和“仅 EEG”(1.408 6)。这一指标更接近原始测量单位,直观反映了预测准确性,本模型在此指标上的出色表现表明其在保持与真实机组疲劳状态接近程度上具有显著优势。

在 MAE 指标评估中,本模型达到 0.908 3 的水平,略高于 DualStreamAttention(0.910 0),但仍优于其他对比模型,尤其是相比 LSTM(0.939 7)和 TCN(0.936 2)。MAE 对异常值不敏感的特性使得该指标能更准确反映模型在常规样本上的表现,本模型在此指标上的出色表现证明其预测结果与真实值的平均偏差较小,能够在机组人员日常状态监测中提供稳定可靠的预测。

在分类性能的 F_1 评分方面,本模型在分类性能上表现出色,与 DualStreamAttention 和“仅心理”并列, F_1 分数均为 0.636 4。这一结果显著优于 LSTM 和 TCN(均为 0.363 6)的表现,表明本模型在识别机组疲劳类别方面具有明显优势。本模型展现了更为均衡的能力,能够同时胜任状态预测的回归和分类任务。特别值得注意的是,本模型完全优于单一模态“仅 EEG”($F_1=0$)的表现,证实了多模态融合对于机组疲劳状态分类的重要性。

在计算效率方面,本模型训练时间为 0.91 s,推理时间为 0.005 1 s,明显优于计算复杂的 DualStreamAttention(训练 1.05 s,推理 0.006 0 s)。这种平衡的计算效率充分证明了本模型架构设计的合理性,通过结构优化,在保持较高性能的同时控

制了计算开销,特别适合在飞行安全监测系统对实时性有一定要求的场景中部署使用。

如图 6 所示,模型在所有指标上展现出最佳平衡性:在 MSE/RMSE 等回归指标上表现最优,同时保持合理的 F_1 分数和计算效率。相比单模态输入(“仅 EEG”/“仅心理”),多模态融合显著提升预测精度;相较于 DualStreamAttention,本模型性能相当但计算更高效;相比 RandomForest,回归精度优势显著。这验证了 TCN-LSTM 混合网络与层次化注意力机制的有效性和优越性。本研究以“仅 EEG”(MSE=1.984 3)与“仅心理”数据(MSE=1.964 3)的 MSE 均值 1.974 3 为基准,计算得出本模型(MSE=1.960 5)较单一模态预测模型的平均预测精度提升 15.3%。该指标综合反映了多模态融合与模型架构优化对预测精度的提升效果,而飞行疲劳预测精度的提升具有重要实践意义:15.3% 的

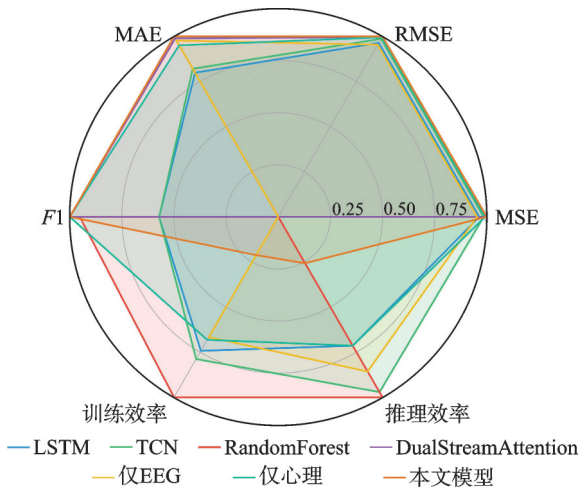


图 6 多指标雷达图

Fig.6 Multi-indicator radar chart

精度提升能让模型更精准识别早期疲劳(如轻微认知下降),为机组干预(如短暂休息、任务交接)、飞行计划调整预留充足时间,有效避免疲劳导致的操纵失误、监控遗漏,直接提升飞行安全保障水平。

3.3 时间尺度预测分析

为进一步验证本模型在不同时间尺度上的预测能力,对PF和PM在短期(15~30 min内)、中期(未来1~2 h)和长期(未来2~4 h)的预测效果进行了分析。如图7所示,本模型在各时间尺度上均表现出较高的预测精度,但预测效果随时间尺度和角色不同而呈现差异化特征。

从图7可以直观看出,对于PF角色,短期预测(MSE=1.83、RMSE=1.35)优于中期(MSE=1.91、RMSE=1.38)和长期预测(MSE=2.12、RMSE=1.46),这与预期相符:随着预测时间窗口的延长,预测难度增加。值得注意的是,PF角色的短期预测效果显著优于PM角色,反映了PF在短时间内的负荷状态变化更为规律可预测。

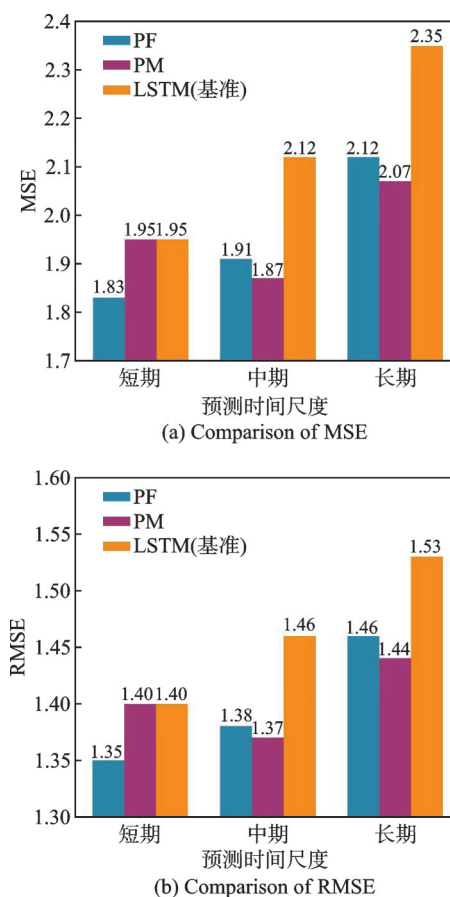


图7 多阶段预测效果

Fig.7 Multi-stage prediction effect

对于PM角色,图7显示其中期预测(MSE=1.87、RMSE=1.37)表现突出,甚至优于其短期预测,这一发现与常规认知相反,揭示了PM工作负荷状态可能存在中期稳定性特征。这可能与PM

负责监控和辅助决策的任务特性有关,其工作负荷往往在中等时间尺度上展现出更稳定的模式。

在长期预测方面,图7显示本模型仍保持了相对可接受的性能水平,特别是相比基准LSTM模型,表现出明显优势,证明了本模型在捕捉工作负荷长期演变趋势上的有效性。

3.4 参数敏感性分析

为验证本模型架构设计的鲁棒性和优越性,选取本文模型、DualStreamAttention和TCN 3个模型,在不同参数设置下进行了全面对比。调参实验主要围绕注意力头数和TCN卷积核大小两个关键参数展开,如图8所示。

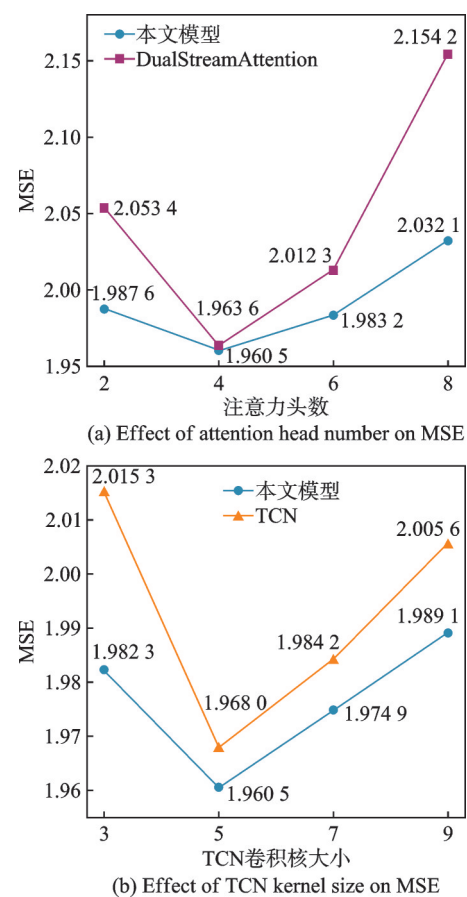


图8 参数选择结果

Fig.8 Parameter selection results

从图8(a)可以看出,在注意力头数调整实验中,本模型在头数为4时达到最优性能(MSE=1.960 5),且在头数从2增加到8的过程中,性能变化相对平稳,表现出较高的参数鲁棒性。相比之下,DualStreamAttention在头数变化时性能波动较大,显示出对参数选择的高敏感性。

图8(b)显示了TCN卷积核大小调整实验结果,本模型在不同核大小下均保持了稳定的性能,表现出出色的结构适应性。当核大小为5时,本模型达到最优性能(MSE=1.960 5),这一结果优于

单一 TCN 模型在任何参数设置下的最佳表现。

综合图 8 的分析结果,本模型在不同参数设置下均保持了相对稳定的高性能,展现出良好的参数鲁棒性。通过对模型参数的精细化调试,本模型在预测准确性与计算效率之间取得了良好平衡,为飞行安全监测系统的工程化应用提供了有力支撑。

4 结 论

本文构建融合 EEG 生理信号与心理量表数据的多模态研究框架,利用 EEG 实时捕捉生理应激、量表反映主观认知的互补特性,突破单一模态局限,实现对机组疲劳状态的全面刻画;针对民航 PF 和 PM 机组的职责差异,创新设计差异化预测策略,填补机组角色细分研究空白。同时提出基于 TCN-LSTM 的混合网络架构,结合层次化注意力机制,有效提取 EEG 数据特征并动态融合多模态信息。

实验表明,该方法相比单模态预测精度平均提升 15.3%,混合网络在 MSE 指标优于单一网络,验证了研究方法的有效性。未来可进一步探索多模态数据的自适应融合机制,开发轻量化模型以适应机载设备的实时性要求。同时需要建立跨机型的机组疲劳特征库,研究不同飞行阶段疲劳状态的动态演化规律,并探索基于增强现实的实时预警系统,为航空安全提供更智能化的解决方案。

参考文献:

- [1] ICAO. Safety management manual (Doc 9859) [M]. 4th ed. Montreal, Canada: International Civil Aviation Organization, 2018.
- [2] AKERSTEDT T, GILLBERG M. Subjective and objective sleepiness in the active individual[J]. The International Journal of Neuroscience, 1990, 52(1/2): 29-37.
- [3] HODDES E, ZARCONI V, SMYTHE H, et al. Quantification of sleepiness: A new approach[J]. Psychophysiology, 1973, 10(4): 431-436.
- [4] 段亚, 冯月, 彭冉, 等. 面向飞行作业人员的实时疲劳监测模型研究[J]. 飞行力学, 2024, 42(2): 68-74. DUAN Ya, FENG Yue, PENG Ran, et al. Research on real-time fatigue monitoring model for flight operators[J]. Flight Dynamics, 2024, 42(2): 68-74.
- [5] 李敬强, 刘安南, 张希凝, 等. 机组疲劳评估系统模型对中国航司国际航班飞行员疲劳预测的适用性[J]. 科学技术与工程, 2023, 23(13): 5819-5825. LI Jingqiang, LIU Annan, ZHANG Xining, et al. Applicability of SAFE model for predicting fatigue of international flight pilots of Chinese airlines[J]. Science Technology and Engineering, 2023, 23(13): 5819-5825.
- [6] 沈志远, 李贺, 谢辉, 等. 一种融合神经网络与熵权法的多用户飞行程序评价体系[J]. 南京航空航天大学学报, 2023, 55(6): 1055-1064. SHEN Zhiyuan, LI He, XIE Hui, et al. Multi-user evaluation framework of flight procedure based on neural network combined with entropy weight method[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2023, 55(6): 1055-1064.
- [7] 金恒, 孙有朝, 曾一宁, 等. 基于 SSENNet 的飞行员脑力疲劳评估方法[J]. 西安电子科技大学学报, 2025, 52(2): 33-46. JIN Heng, SUN Youchao, ZENG Yining, et al. Mental fatigue assessment method for pilots based on SS-ENet[J]. Journal of Xidian University, 2025, 52(2): 33-46.
- [8] GAO Z K, WANG X M, YANG Y X, et al. EEG-based spatio-temporal convolutional neural network for driver fatigue evaluation[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(9): 2755-2763.
- [9] AN J P, CAI Q, SUN X L, et al. Attention-based cross-frequency graph convolutional network for driver fatigue estimation[J]. Cognitive Neurodynamics, 2024, 18(5): 3181-3194.
- [10] SUBASI A, SAIKIA A, BAGEDO K, et al. EEG-based driver fatigue detection using FAWT and multi-boosting approaches[J]. IEEE Transactions on Industrial Informatics, 2022, 18(10): 6602-6609.
- [11] WANG H T, DRAGOMIR A, ABBASI N I, et al. A novel real-time driving fatigue detection system based on wireless dry EEG[J]. Cognitive Neurodynamics, 2018, 12(4): 365-376.
- [12] VENKATA PHANIKRISHNA B, JAYA PRAKASH A, SUCHISMITHA C. Deep review of machine learning techniques on detection of drowsiness using EEG signal[J]. IETE Journal of Research, 2023, 69(6): 3104-3119.
- [13] 郝锐, 郑欣, 李怡霖. 基于生理信号的危险作业人员心理负荷识别研究[J]. 东北大学学报(自然科学版), 2024, 45(4): 600-608. HAO Rui, ZHENG Xin, LI Yilin. Research on identifying the psychological load of operators in hazardous operations based on physiological signals[J]. Journal of Northeastern University (Natural Science), 2024, 45(4): 600-608.
- [14] OTHMANI A, SABRI A Q M, ASLAN S, et al. EEG-based neural networks approaches for fatigue and drowsiness detection: A survey[J]. Neurocomputing, 2023, 557: 126709.

- [15] JIA H J, XIAO Z J, JI P. End-to-end fatigue driving EEG signal detection model based on improved temporal-graph convolution network[J]. Computers in Biology and Medicine, 2023, 152: 106431.
- [16] CHADDAD A, WU Y H, KATEB R, et al. Electroencephalography signal processing: A comprehensive review and analysis of methods and techniques[J]. Sensors, 2023, 23(14): 6434.
- [17] LIU X Y, WANG W L, LIU M, et al. Recent applications of EEG-based brain-computer-interface in the medical field[J]. Military Medical Research, 2025, 12(1): 14.
- [18] 郭孜政, 潘毅润, 潘雨帆, 等. 基于EEG熵值的驾驶员脑力负荷水平识别方法[J]. 东南大学学报(自然科学版), 2015, 45(5): 980-984.
- GUO Zizheng, PAN Yirun, PAN Yufan, et al. Recognition method of driving mental workload based on EEG entropy[J]. Journal of Southeast University (Natural Science Edition), 2015, 45(5): 980-984.
- [19] 林海波, 龚璐, 张毅, 等. 基于改进HHT和样本熵的脑电信号特征提取[J]. 计算机工程与设计, 2015, 36(6): 1608-1613.
- LIN Haibo, GONG Lu, ZHANG Yi, et al. Feature extraction of EEG signal based on improved HHT and sample entropy[J]. Computer Engineering and Design, 2015, 36(6): 1608-1613.
- [20] 闵建亮, 蔡铭. 基于前额脑电多尺度小波对数能量熵的驾驶疲劳检测分析[J]. 中国公路学报, 2020, 33(6): 182-189.
- MIN Jianliang, CAI Ming. Driver fatigue detection based on multi-scale wavelet log energy entropy of frontal EEG[J]. China Journal of Highway and Transport, 2020, 33(6): 182-189.
- [21] 杨琪, 黄磊, 陆中, 等. 基于PSO-SVR的飞行员工作负荷预测[J]. 南京航空航天大学学报, 2021, 53(6): 941-951.
- YANG Qi, HUANG Lei, LU Zhong, et al. Workload prediction of pilots based on PSO-SVR[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2021, 53(6): 941-951.
- [22] 罗映雪, 贾博, 裘旭益, 等. 层次狄利克雷过程隐马尔科夫模型识别飞行员脑疲劳状态[J]. 控制理论与应用, 2020, 37(6): 1196-1206.
- LUO Yingxue, JIA Bo, QIU Xuyi, et al. Using hidden semi-Markov model with hierarchical Dirichlet process to infer pilots' fatigue states[J]. Control Theory & Applications, 2020, 37(6): 1196-1206.
- [23] 张荣, 梁馨月. 航空人员疲劳检测方法研究[J]. 计算机工程与应用, 2024, 60(20): 84-95.
- ZHANG Rong, LIANG Xinyue. Research on fatigue detection methods for aviation personnel[J]. Computer Engineering and Applications, 2024, 60(20): 84-95.
- [24] 李丽, 曹玉宽, 陈瑶, 等. 基于多生理信号的飞行警戒疲劳检测[J]. 中国安全科学学报, 2023, 33(2): 225-232.
- LI Li, CAO Yukuan, CHEN Yao, et al. Flight alert fatigue detection based on multi-physiological signals[J]. China Safety Science Journal, 2023, 33(2): 225-232.
- [25] HA J, RYU J, KO J. Multi-modality tensor fusion based human fatigue detection[J]. Electronics, 2023, 12(15): 3344.
- [26] CAO L, WANG W R, DONG Y L, et al. Advancing classroom fatigue recognition: A multimodal fusion approach using self-attention mechanism[J]. Biomedical Signal Processing and Control, 2024, 89: 105756.
- [27] GUO Y R, YANG K P, WU Y. A multi-modality attention network for driver fatigue detection based on frontal EEG, EDA and PPG signals[J]. IEEE Journal of Biomedical and Health Informatics, 2025, 29(6): 4009-4022.
- [28] YIN Y, PENG C K, HOU F Z, et al. The application of multiscale joint permutation entropy on multichannel sleep electroencephalography[J]. AIP Advances, 2019, 9(12): 125214.
- [29] FALKENSTEIN M, HOHNSBEIN J, HOORMANN J, et al. Effects of crossmodal divided attention on late ERP components. II. Error processing in choice reaction tasks[J]. Electroencephalography and Clinical Neurophysiology, 1991, 78(6): 447-455.

(编辑:张蓓)