

可穿戴睡眠监测技术研究进展：从单传感器到多模态融合



程 珊, 黄美清, 党维涛, 熊凯文, 滕超淋, 丛 林

空军军医大学航空航天医学系航空航天医学装备教研室 (西安 710032)

【摘要】睡眠质量直接影响日间社会功能、认知水平及身心健康, 可穿戴睡眠监测技术可作为睡眠评估“金标准”多导睡眠图的重要补充手段。本文从可穿戴睡眠监测硬件技术与睡眠分析算法两方面切入, 系统梳理传感器、算法与临床验证层面的研究进展与不足, 旨在为可穿戴睡眠监测技术的后续研发和临床应用提供思路和参考。现有研究表明, 基于脑电的监测系统睡眠分期识别准确率最高 (约 90%), 可识别所有睡眠阶段; 体动记录仪和光电容积描记技术已在可穿戴设备中得到广泛应用, 但多分期睡眠结构的识别准确率相对较低 (约 70%)。多模态信号融合监测技术能弥补单模态信号的不足, 提升睡眠分期识别准确率, 但入睡 (N1) 期的识别仍是技术难点。因此, 未来可穿戴技术应朝着多样化传感器技术创新、多模态融合算法迭代的方向发展, 并结合临床经验, 推动消费级睡眠监测技术标准构建。

【关键词】可穿戴设备; 睡眠监测; 多导睡眠图; 多模态融合; 深度学习

【中图分类号】 R338.63 **【文献标识码】** A

Research progress in wearable sleep monitoring technology: from single sensor to multimodal fusion

CHENG Shan, HUANG Meiqing, DANG Weitao, XIONG Kaiwen, TENG Chaolin, CONG Lin

Department of Aerospace Medical Equipment, School of Aerospace Medicine, Air Force Medical University, Xi'an 710032, China

Corresponding author: CONG Lin, Email: hzbconglin@fmmu.edu.cn

【Abstract】 Sleep quality directly affects daytime social functioning, cognitive performance, and physical and mental health. Wearable sleep monitoring technologies serve as a valuable complement to the gold standard polysomnography. This review systematically analyzes current limitations in wearable sleep monitoring hardware and sleep analysis algorithms, with a focus on sensor technology, algorithm design, and clinical validation, and provides insights and methodological guidance for future research and clinical application of wearable sleep monitoring technologies. The analysis shows that electroencephalogram-based detection systems typically achieve the highest recognition accuracy in sleep stage classification (around 90%) and can identify all sleep stages. Whereas accelerometer- and photoplethysmography-based systems, which are commonly used in wearables, have relatively lower recognition accuracy of the multi-stage sleep structure (around 70%). Multimodal signal fusion techniques have the potential to overcome the limitations of single-modality signals and improve recognition accuracy in sleep stage classification, although detecting sleep onset (N1) stage remains challenging. Therefore, future wearable

DOI: 10.12173/j.issn.1004-5511.202607068

基金项目: 国家自然科学基金青年科学基金项目 (32400909); 国家自然科学基金联合基金项目 (U2433217)

通信作者: 丛林, 博士, 助理研究员, Email: hzbconglin@fmmu.edu.cn

technologies should advance toward innovations in diverse sensor designs and multimodal fusion algorithms in conjunction with clinical expertise, to promote the development of standardized consumer-grade sleep monitoring technologies.

【Keywords】 Wearable devices; Sleep monitoring; Polysomnography; Multimodal fusion; Deep learning

据美国睡眠医学学会报道, 约30%~35%的人群存在短暂性失眠症状, 15%~20%的成年人患短期失眠障碍, 慢性失眠的患病率约为10%^[1]。基于全球数据的系统综述进一步显示, 成人慢性失眠的患病率约为16.2%, 受累人群约8.52亿^[2]。在全球30~69岁成年人中, 阻塞性睡眠呼吸暂停 (obstructive sleep apnea, OSA) 患病人数约9.36亿, 其中约4.25亿人达中度至重度标准^[3]。睡眠质量直接影响个体日间社会功能、认知水平与身心健康, 且睡眠障碍与OSA、心血管疾病、抑郁症等病症密切相关。多导睡眠图 (polysomnography, PSG) 同步采集脑电图 (electroencephalogram, EEG)、肌电图 (electromyogram, EMG)、心电图 (electrocardiogram, ECG) 及呼吸等多项生理信号, 是睡眠质量监测和评估的“金标准”。然而, PSG存在成本昂贵、操作复杂、结果需专业技术人员判读等局限性, 难以满足居家日常监测与大规模人群筛查的需求^[4]。同时, 可穿戴睡眠监测市场增长迅速, 2025年全球睡眠追踪器市场规模约70亿美元, 其中可穿戴设备占比超70%, 预计2035年将增长至约184亿美元^[5]; 某品牌可穿戴设备全球注册用户超1.28亿, 约72%的用户经常使用睡眠追踪功能, 反映出巨大的居家应用需求^[6]。随着各类信号检测传感器与多模态融合技术快速发展, 可穿戴监测技术成为PSG的重要补充手段。

近年来, 可穿戴睡眠监测技术相关综述持续增加, 但多数综述仅局限于单一维度, 尚未形成贯穿“传感器技术-算法演进-临床验证”全链条的系统性分析视角^[4, 7-9]。基于此, 本文以“传感器-算法-临床转化”全链条视角为主线, 系统梳理可穿戴睡眠监测领域的研究进展, 旨在为后续可穿戴睡眠监测技术的研发和应用提供可参考的研究思路。

1 可穿戴睡眠监测传感器技术现状

1.1 基于生物电信号的监测技术

1.1.1 EEG 监测

EEG 信号在不同睡眠阶段呈现特征性波形

(如慢波、睡眠纺锤波及K复合波), 是睡眠分期最核心的判断依据。EEG作为PSG多通道信号的重要组成部分, 单独用于睡眠分期识别准确率普遍>90%, 一致性评价Cohen's κ 系数>0.8^[7]。然而, 传统PSG需佩戴多个头皮电极, 佩戴舒适度差, 且易干扰受试者自然睡眠。因此, 无线便携式EEG系统在睡眠医学领域展现出独特应用价值。入耳式EEG技术将电极置于耳道与耳周皮肤, 以稳定采集信号, 其睡眠评估性能与PSG具有显著一致性, 还可实现睡眠闭环干预^[10]。例如, Hestermann等^[11]采用入耳EEG设备, 在识别出非快速眼动 (non-rapid eye movement, NREM) 期和浅睡 (N2) 期后实施3 Hz双耳节拍与自主神经经络反应联合的音频刺激, 使NREM期和深睡 (N3) 期占比由17.8%提升至24.5%, 且EEG δ 波功率显著升高, 为睡眠干预提供了精准的时间窗口。目前, 已有研究构建入耳式EEG睡眠监测数据集, 提升了耳部EEG在家庭环境下开展睡眠监测的应用潜力^[12]。

1.1.2 ECG 监测

基于ECG信号提取的心率变异性 (heart rate variability, HRV) 特征与睡眠过程中的自主神经活动密切相关, 是可穿戴设备中常用的生理监测模块。Li等^[13]开发了胸贴式单导联ECG系统, 利用提取的HRV特征和ECG衍生呼吸特征构建睡眠质量评估模型, 结合主观睡眠量表, 将睡眠质量分为好、差两类; 在公开睡眠数据集中, 验证该模型的平均准确率为66.0%, 针对夜班人群的实测准确率为78.6%, 平均F1分数为77.1%。可见该类睡眠质量监测技术仅依赖单通道可穿戴心动周期信号, 易在便携式设备中应用。

1.1.3 皮肤电活动监测

皮肤电活动 (electrodermal activity, EDA) 通过捕捉皮肤汗腺分泌引起的电导率波动, 间接反映交感神经张力变化。从睡眠分期特征来看, EDA具有明显的阶段依赖性: NREM期交感神经活动相对活跃, EDA事件发生率较高; 而进入快

速眼动 (rapid eye movement, REM) 期后, 交感神经受抑制, EDA 信号随之减弱。在算法验证方面, Piccini 等^[14] 利用腕式 EDA 信号开展睡眠分期识别, 5 分期睡眠结构的宏 F1 分数为 57.5%, 4 分期睡眠结构提升至 66.6%; 在 OSA 检测任务中, 模型准确率可达 83.7%。上述结果表明 EDA 作为自主神经标志物, 在睡眠呼吸障碍筛查中具有不可忽视的补充价值。Anusha 等^[15] 进一步将腕式 EDA 与皮肤温度信号融合, 将睡眠分期识别准确率提升至约 96%, 证实多模态信息互补可显著增强 EDA 用于睡眠评估的实际效能。然而, EDA 信号仍存在明显局限性: 对环境温湿度敏感, 且个体基线差异较大。若计划在不同人群中稳定应用该技术, 需先完成受试者内基线校正, 否则模型泛化能力难以保证。

1.1.4 其他电生理信号

EMG 监测系统主要检测下颌肌电信号以辅助识别 REM 期。但仅依靠 EMG 信号开展睡眠监测的可穿戴产品较少, 该信号通常与 EEG、眼电图 (electrooculogram, EOG) 联合使用。Toma 等^[16] 提出多通道卷积双向长短记忆网络 (long short-term memory, LSTM), 通过“双通道预训练 + 四通道微调”策略融合 EEG、EOG 与 EMG 信号; 基于公开数据集, 模型睡眠分期识别准确率可达 91.44% (Cohen's κ 系数为 0.89), 性能显著优于单通道模型。该结果表明联合 EMG 的多生理电信号协同应用可提升睡眠分期识别准确率。Yin 等^[17] 指出, 石墨烯电子皮肤可通过检测皮肤上不同位置电极间血管血流脉冲引发的电阻抗变化信号, 估算睡眠期间的舒张压和收缩压。皮肤温度随昼夜节律变化, 与睡眠-觉醒周期同步。可穿戴贴片式温度传感器通过皮肤温度与热通量估算核心体温, 其节律稳定性指标与睡眠效率、入睡潜伏期显著相关^[18]。

1.2 基于生物力学信号的监测技术

1.2.1 体动记录仪

体动记录仪 (actigraphy) 又称加速度计, 其通过检测体动信号判断睡眠-觉醒状态, 是可穿戴设备中应用最广泛的成熟传感技术。其中, 腕式体动记录仪多用于睡眠过程中昼夜节律评估。基于原始加速度数据构建的算法模型在伴或不伴 OSA 的儿童群体中研究显示, 睡眠-觉醒 2 分期睡眠结构的平均识别准确率为 67%~80%, 对睡眠时

长等指标估计值的表面效度与实验室 PSG 测量结果具有一致性^[19]。将体动记录与 HRV 特征相结合后, 睡眠效率估算准确率可达 86%, 并可实现较准确的 5 分期睡眠结构识别效果 (Cohen's κ 系数为 0.974)^[20]。基于体动记录仪的睡眠研究还发现, 40 岁以下年轻女性的睡眠碎片化指数显著低于男性, 睡眠效率更高; 而随着年龄增长, 该性别差异会逐渐减弱^[21]。

1.2.2 心冲击图

心冲击图 (ballistocardiogram, BCG) 可通过非侵入方式检测由心脏搏动和大动脉血液循环引起的压力变化信号, 以此提取心率、呼吸等信号。聚偏二氟乙烯膜、压电薄膜、应变计及微弯光纤等传感器已集成于床垫、枕头、座椅等日常家居用品中采集 BCG 信号, 监测过程无需医护人员在场^[22]。由此可见, 消费级家用 BCG 传感器对开展长期客观睡眠监测具备便捷性, 且对睡眠干扰较少, 但真实场景中的监测效果尚不理想。Kholghi 等^[23] 研究显示, 基于 BCG 的睡眠监测会显著高估总睡眠时间 (平均偏高 177.5 min), 低估清醒到入睡的时间 (平均偏低 44.7 min), 其与 PSG 对睡眠-觉醒 2 分期睡眠结构识别的一致性较差 (Cohen's κ 系数为 0.13), 难以精确区分睡眠阶段。主要原因在于 BCG 信号是由心脏活动、呼吸和体动组成的复合信号, 给信号解析带来一定的挑战。小波变换具备自适应非线性、非平稳信号的能力, 适用于 BCG 信号去噪^[22], 但在投入临床应用前仍需优化信号处理算法, 以提升分期识别效果。

1.2.3 声学监测

除生理信号外, 声学特征可为 OSA 筛查提供另一维度信息。研究显示, 利用智能手机麦克风在距受试者 1 m 内采集夜间鼾声, 结合深度学习模型可实现鼾声自动识别, 准确率可达 95.6%^[24]。从临床角度分析, 鼾声的频率、强度及周期性特征不仅能区分单纯鼾声与 OSA 相关的病理性鼾声, 还可通过氧减事件与鼾声暂停的时序关联, 间接推断呼吸事件的发生。声学监测的优势为非接触式采集, 但卧室环境噪声、多人同寝时的声音混杂会显著降低信号质量。因此, 在当前技术条件下, 鼾声信号更适合作为光电容积血流、血氧等生理信号的辅助模态, 纳入多模态 OSA 筛查模型, 不宜单独用于疾病诊断。

1.3 基于光血流信号的监测技术

光电容积描记 (photoplethysmography, PPG) 技术通过 LED 光源检测皮下血流容积变化, 以此估算血氧饱和度 (SpO_2)、心率及 HRV。基于腕戴设备采集的反射式 PPG 数据构建模型, 其 4 分期睡眠结构 [清醒、入睡 (N1) 和 N2 合并、N3 和 REM] 识别准确率可达 78.7% (Cohen's κ 系数为 0.68), 2 分期睡眠结构 (睡眠-觉醒) 的识别准确率为 94.1% (Cohen's κ 系数为 0.71) [25]。智能手环或手表普遍采用 PPG 联合体动信号的组合方案 [26]。例如, 对某品牌智能手环的研究显示, 该手环在无睡眠障碍人群中表现稍好, 整体准确率 78%, 敏感度 89%, 但特异度仅 35%; 与 PSG 相比, 手环显著高估总睡眠时间 (平均偏高 29.6 min)、睡眠效率、浅睡眠和深睡眠时长, 低估觉醒次数与 REM 期睡眠时长 [27]。现有验证结果显示, 消费级可穿戴设备的睡眠监测性能存在明显的任务依赖性, 2 分期睡眠结构识别效果尚可, 准确率 86%~89%; 而开展多分期睡眠结构识别任务 (区分具体睡眠阶段) 时, 一致性骤降至 50%~65%, 精细睡眠分期识别能力不足的问题十分突出 [28]。Robbins 等 [29] 比较 35 例健康成人同时佩戴不同品牌的 3 款设备监测效果, 三者 4 分期睡眠结构 Cohen's κ 系数分别为 0.65、0.55 和 0.60; 其中某款设备性能相对最优, 与其指部 PPG 信号受运动干扰较少、稳定性优于腕部有关; 3 款设备存在共性特征, 即睡眠敏感度均高于 95%, 而特异度均低于 60%, 呈现“易判睡、难判醒”的特点。Schuyvens 等 [30] 证实某品牌设备 Cohen's κ 系数仅 0.37, N3 期识别准确率 69.63%。提示现阶段消费级可穿戴设备对宏观睡眠结构的评估具有一定参考价值, 但在睡眠阶段精细判别方面仍与 PSG 存在显著差距。

在睡眠呼吸障碍监测方面, SpO_2 是不可或缺的关键指标。基于腕部或指环式可穿戴设备的连续 SpO_2 监测, 结合人工智能算法可自动完成 OSA 严重程度分级, 准确率可达 89% [31]。然而, SpO_2 信号对呼吸事件的响应存在 10~40 s 的生理延迟, 且不同设备对氧减事件的定义及算法处理方案差异较大, 不同产品检测结果间可比性有限。因此, 现阶段监测 SpO_2 的可穿戴设备更适用于 OSA 高危人群的大规模初筛, 其确诊仍需依赖 PSG。可穿戴睡眠监测技术体系架构见表 1。

1.4 多通道信息融合监测技术

如表 1 所示, 现有单传感器方案在实际应用中均存在明显局限性。因此, 借助多传感器之间的信息互补以突破单模态的性能上限, 已成为可穿戴睡眠监测技术发展的可行方向。Wang 等 [32] 提出混合深度学习网络 CareSleepNet, 融合 EEG 和 EOG 的跨模态特征, 基于 3 个公开数据集得到的准确率为 83.2%~85.1%, 性能表现最优。Zhang 等 [33] 构建 TSEDSleepNet 融合算法, 采用双流编码器分别处理 EEG 和 EOG 信号, 基于 Sleep-EDF-39 数据集获得的准确率为 88.9%, F1 分数为 84.8%。Toma 等 [16] 设计的 LSTM 网络, 可有效挖掘 PSG 多通道数据的时空特征, 睡眠分期的自动识别准确率可达 90%。基于 EEG、ECG、EOG、EMG 等多模态生理时频特征开展模型构建, 5 分期睡眠结构识别准确率可达 84.3% [34]。基于智能手表普遍采用的简单模态信号组合 (PPG + 体动), 也能准确估计深度睡眠时长, 其 3 分期睡眠结构 (清醒、NREM、REM) 的识别准确率达 79%, 4 分期睡眠结构的识别准确率为 70%~72% [35]。由表 2 可见, 多模态融合增益的 2 个关键规律: ①任务与场景依赖性显著, 多分期睡眠结构识别任务的准确率较低, 且随设备类型不同存在波动; ②多模态融合可能会提高性能上限, 但效果受模态组合方案影响。由此可见, 多模态融合并非不同信号性能的简单叠加。融合增益既受模态间生理信息的互补程度制约, 也与融合策略与实际应用场景密切相关。

综上, 单传感器在睡眠监测与分期性能上各有优劣, 以此构建的可穿戴设备在测量精度与佩戴舒适度间存在一定的矛盾。同时, 可穿戴设备若要满足长时间睡眠监测需求 (至少 8~10 h), 还需兼顾电池容量和功耗增加带来的挑战 [7]。多模态信号融合能弥补单模态的固有局限、提升睡眠分期识别准确率, 是可穿戴睡眠监测技术发展的必然趋势; 同时, 这也对后续算法设计提出实现跨模态特征协同提取与优化的新要求。

2 睡眠分析算法演进与性能评估

2.1 传统机器学习方法

传统机器学习方法依赖人工特征提取与经典分类器。K 近邻、支持向量机 (support vector machine, SVM)、随机森林、人工神经网络、梯

表 1 可穿戴睡眠监测技术体系架构

Table 1. Architecture of wearable sleep monitoring technology system

技术分类	传感器模式	监测原理	主要优势	主要局限
生物电信号	EEG	睡眠分期核心生理信号，依据慢波、睡眠纺锤波、K 复合波等特征波形判读分期	睡眠分期识别准确率最高 (>90%，Cohen's κ 系数>0.80)，可识别全部睡眠分期	佩戴复杂，电极易移位，干扰自然睡眠
	ECG	提取 HRV 特征评估睡眠质量	可单导联采集，易嵌入便携设备	单独使用准确率有限 (66%~79%)，难以精细分期
	EMG	检测下颌或肢体肌电信号	配合 EEG/EOG 使用，辅助识别 REM 期	常用其他模式信号配合
	EDA	皮肤汗腺分泌引起的电导率变化	睡眠阶段依赖性特征显著	易受环境温度、湿度影响，个体差异较大
	皮肤温度	随昼夜节律变化，与睡眠-觉醒周期同步	与入睡潜伏期相关	分期效果验证不充分
生物力学信号	体动	通过体动监测判别睡眠-觉醒状态	成本低、佩戴便捷，最广泛应用于消费级设备	仅依赖体动，难以区分清醒状态与 N1 期，高估总睡眠时间
	BCG	依靠接触检测心跳引起的血流重复运动信号	非接触式，对睡眠干扰少，适合长期监测	复合信号噪声大，抗干扰能力弱，无法精确区分睡眠阶段
	鼾声	通过鼾声特征（频率、强度、周期性）识别呼吸事件	无需皮肤接触，可区分 OSA 相关声学特征	受环境噪声及多床同寝干扰、隐私保护问题
光血流信号	PPG	LED 光源检测皮下血流容积变化，估算 SpO ₂ 、心率及 HRV	智能手环/手表普遍集成，佩戴便捷	受运动伪影、皮肤色素影响，4 分期睡眠结构的识别准确率为 78.7% (Cohen's κ 系数=0.68)，特异性低
多通道传感器信号	整合多种信号，综合判断	通过深度学习融合 EEG、EOG、EMG、ECG、PPG 及体动等多模态信号的时空与时频特征	5 分期睡眠结构的识别准确率 83%~91%，显著优于单模态消费级设备 (70%~79%)	多分期睡眠结构性能仍需提升，设备复杂度与功耗增加

表 2 单模态与多模态睡眠分期识别性能增益对比

Table 2. Comparison of performance gains in sleep stage recognition between unimodal and multimodal approaches

信号模式	分期睡眠结构识别任务	准确率 (%)	κ 系数	F1 分数 (%)	相对单模态增益	参考文献
EEG (单模态)	5 分期	> 90.0	> 0.80	—	基线	[7]
体动 (单模态)	2 分期	67.0~80.0 ^a	—	—	基线	[19]
PPG (单模态)	4 分期	78.7	0.68	—	基线	[25]
PPG (单模态)	2 分期	94.1	0.71	—	基线	[25]
PPG+体动	3 分期	79.0	—	—	相比 PPG 单模态 4 分期提升 0.3%	[35]
PPG+体动	4 分期	70.0~72.0	—	—	相比 PPG 单模态 4 分期下降 6.7%~8.7% ^b	[35]
HRV+体动	5 分期	98.0	0.97	—	相比单用体动或 HRV 显著提升，接近 PSG 水平	[20]
EEG+EOG	5 分期	83.2~85.1	—	—	相比单通道 EEG 下降约 5%~7% ^c	[32]
EEG+EOG	5 分期	88.9	—	84.8	相比单通道 EEG 下降约 1.1%	[33]
EEG+EOG+EMG	5 分期	91.4	0.89	—	相比单通道 EEG 提升约 1.4%	[16]
EEG+ECG+EOG+EMG	5 分期	84.3	—	—	相比单通道 EEG 下降约 5.7%	[34]

注：^a平均准确率；^b该结果为可穿戴设备端实现，与实验室 PPG 单模态条件不同；^cCareSleepNet 在跨模态融合中更关注 F1 分数提升（整体 F1 分数较 SVM 基线提高 13%~23%），而非单纯准确率。

度提升决策树和线性判别分析等机器学习方法应用较为广泛 [8]。例如，Hei 等 [36] 采用并行融合方法，将 EOG 与 ECG 特征融合为复数向量输入梯度提升决策树分类器，可实现 3 分期睡眠结构的平均识别准确率达 83% (Cohen's κ 系数为 0.7)。

Kim 等 [20] 基于腕带采集的 HRV 与体动特征数据，采用随机森林实现 5 分期睡眠结构的识别准确率达 98% (Cohen's κ 系数为 0.974)，但该研究仅在 30 例健康成人中完成验证，模型泛化能力有限。Wang 等 [32] 研究显示，基于公开数据集 SVM 的分

期识别准确率约为 70% (Cohen's κ 系数约为 0.5)。Moris 等^[37] 基于相同训练数据集对比随机森林、SVM 和 K 近邻算法, 以从 EEG、EOG 和 EMG 通道提取的统计变量作为模型输入特征, 评估发现随机森林模型的分类性能优于其他算法。传统机器学习方法具备算法简单、计算高效且可解释性强等优势, 适用于二元分类任务, 但其特征设计高度依赖专家经验, 难以捕捉信号深层非线性关系, 且跨数据集迁移性能欠佳。

2.2 深度学习算法

深度学习可实现从原始生理信号到睡眠分期识别的端到端学习, 卷积神经网络 (convolutional neural network, CNN) 和 Transformer 系列是当前主流模型架构方法。

2.2.1 CNN 系列

Yildirim 等^[38] 构建 19 层一维 CNN, 直接输入原始 EEG 与 EOG 信号, 基于 2 个公共数据库获得 4 分期睡眠结构的识别准确率达 98%, 6 分期睡眠结构的识别准确率约为 90%。Song 等^[35] 基于 CNN 构建依赖注意力引导序列到序列的 LSTM 模型, 能基于可穿戴设备的体动与 PPG 数据准确估算深睡眠时长, 3 分期睡眠结构识别准确率可达 79%, 4 分期睡眠结构识别准确率为 70%。Zhuang 等^[39] 构建多通道信号的睡眠分期自动识别 CNN-LSTM 模型, 采用并行架构处理多通道 EEG 与 EOG 信号, 基于 MIT-BIH 数据集获得 5 分期睡眠结构的识别准确率达 90.6%; 其中, REM 期 F1 分数为 87.38%, 但 N1 期 F1 分数仅 59.78%, 提示浅睡眠阶段 (由清醒到睡眠过渡阶段) 识别仍是难点。Toma 等^[16] 构建四通道卷积双向 LSTM 网络, 能有效利用 PSG 多通道数据的时空特征; 而基于

EDF-20 数据集, 采用 EEG、EOG 组合睡眠分期的自动识别准确率可达 91.44% (Cohen's κ 系数为 0.89)。

2.2.2 Transformer 架构

Transformer 依托自注意力机制可对时序信号开展全局建模, 现已成为睡眠分期识别领域的研究热点。Wang 等^[32] 提出深度学习网络 CareSleepNet, 构建多尺度卷积-Transformer 片段编码器, 用于提取各睡眠片段内的局部显著波形特征和全局特征; 再结合跨模态上下文编码器, 建立 EEG 与 EOG 的跨模态上下文关联, 并捕捉不同睡眠片段间的序列关系; 验证结果显示, 该模型睡眠分期识别性能 (F1 分数) 比表现最差的传统机器学习方法 SVM 提高了 13%~23%。该方法不仅提高了模型整体性能, 还改善了部分睡眠分期的识别效果, 特别是 N1 期、N3 期和 REM 期。Zhang 等^[33] 构建 TSEDSleepNet-Transformer 全局聚合模块, 能捕获长-短程时序依赖关系, 基于 Sleep-EDF-39 数据集获得的 F1 分数可达 84.8%, 性能显著优于基线模型。睡眠分期识别代表性算法模型总结见表 3。

2.3 模型验证方法与泛化性

目前, 多数睡眠分期识别算法的验证仍停留在受试者内交叉验证阶段。由于同一受试者的睡眠结构在训练集与测试集中具有较高相似性, 模型易“记住”个体特征, 而难以学习具备可迁移性的通用规律。留一受试者交叉验证虽能在一定程度上反映跨个体泛化能力, 但该验证方式仍局限于同一数据集内部。跨数据集外部验证是检验模型性能更严苛的测试方式。例如, Alvarez-Estevez 等^[40] 在 6 个公开数据库开展对比研究发

表 3 睡眠分期识别代表性算法模型总结
Table 3. Summary of representative algorithm models for sleep staging

类别	特点	代表性模型/算法
传统机器学习	传统方法算法简单、可解释性强, 但特征设计高度依赖专家经验, 跨数据集迁移性差	梯度提升决策树 (Hei 等 ^[36]) 随机森林 (Kim 等 ^[20]) SVM (Wang 等 ^[32]) K 近邻 (Moris 等 ^[37])
CNN 系列	可直接输入原始信号, 实现端到端学习, 但多分期睡眠结构的识别准确率降低, N1 期识别效果不佳	CNN (Yildirim 等 ^[38]) 注意力引导序列到序列 LSTM (Song 等 ^[35]) CNN-LSTM (Zhuang 等 ^[39]) 卷积双向 LSTM (Toma ^[16])
Transformer 架构	可直接输入原始信号, 全局建模时序、上下文关系, 实现跨模态融合, 可使 N1 期识别准确率提高	CareSleepNet (Wang 等 ^[32]) TSEDSleepNet (Zhang 等 ^[33])

现,深度学习模型在本地验证中的Cohen's κ 系数为0.78~0.83,而跨数据库外部验证时降至0.59~0.69,性能降幅约10%~15%,该问题已成为制约算法由实验室研究向临床转化的核心瓶颈。为缩小该性能差距,领域自适应与去中心化学习是2条可行的路径。Fan等^[41]通过匹配源域与目标域的均值与协方差统计量,在不依赖目标域标签的情况下实现跨数据集迁移;Heremans等^[42]进一步将对抗域自适应从非监督拓展至半监督设置,在跨个体迁移任务中取得显著性能增益。在去中心化学习方面,Anido-Alonso等^[43]采用子采样联邦随机梯度下降算法,基于6个独立异构数据库实现了与中心化模型相当的跨库泛化性能;Li等^[44]则设计出基于CNN-Transformer的联邦学习方法,在保护隐私的同时提升模型泛化能力。但非独立同分布数据与模型异构性仍是该技术落地的主要障碍。未来将领域自适应嵌入去中心化学习框架,有望同时缓解领域偏倚与数据孤岛问题。

从算法演进现状来看,目前仍存在一些亟待解决的问题:①多分期睡眠结构的识别准确率不足。Miller等^[28]研究证实,2分期睡眠结构的识别准确率普遍较高(86%~89%),但多分期睡眠结构的识别准确率明显下降(最高仅65%)。②类别不平衡。Zhang等^[33]研究结果显示,模型识别N1期的F1分数为63.8%,远低于N2期的90.5%。Li等^[45]研究也显示,N1期F1分数不超过60%。Satapathy等^[46]研究显示,N1期作为清醒期与N2期之间的过渡阶段,其判别特征与清醒期和N2期高度相似,导致分类模型难以建立清晰的决策边界。从生理机制层面分析,N1期是清醒向睡眠过渡的短暂阶段(占比约5%),持续

时间短,且不同传感模态均缺少识别N1期的特异性标志。例如,EEG表现为 α 波逐渐减弱,并被低振幅、混合频率的 θ 波活动替代,通常不含睡眠纺锤波、K复合波或N3期的 δ 慢波等N2期特征性的电生理标志。上述机理分析解释了多模态融合虽能提升整体睡眠分期的识别准确率,却对N1期识别性能的改善效果有限的原因。③个体化建模难度较大。Moris等^[37]研究提示,慢波睡眠期的模型性能差异最明显(F1分数差异为2.87%),其他睡眠阶段在不同受试者间也存在显著差异;该研究还证实,受试者年龄、睡眠监测时段(凌晨和深夜)均会影响分类模型性能。上述规律提示,算法创新不应仅追求基于同一数据集提升识别的准确率,还需兼顾模型可解释性、跨场景泛化能力,并深度融合睡眠生理先验知识,以实现模型从实验室性能到临床实用价值的跨越,也为下文剖析现存技术瓶颈奠定基础。传感器硬件与算法演进基本模式见图1。

3 临床验证研究现状

可穿戴设备的睡眠分期识别性能验证多基于健康人群公共数据集开展,以PSG作为标签进行分析。在以健康受试者为主的数据集(例如EDF-20、MASS、SHHS、DOD-H和DOD-O)中,主流睡眠分期模型与PSG可达到“近乎完美”的一致性水平(Cohen's κ 系数>0.81),而在睡眠障碍相关数据集(如ISRUC和CAP)中,模型一致性较低(Cohen's κ 系数<0.70),性能明显下降^[4]。提示若将此类模型直接应用于OSA或失眠等病理患者,其性能会出现衰减。深度学习模型虽具备优异的性能,但决策过程呈“黑箱”化,数据可解释性不强。临床医生难以理解




图1 传感器硬件与算法演进基本模式

Figure 1. Basic evolution pattern of sensor hardware and algorithms

模型判定睡眠分析的内在依据,阻碍了临床应用。尽管已有研究融入注意力可视化算法,使模型能聚焦 N2 期 K 复合波等 EEG 特征波形,但如何将这类注意力模式转化为可使用的临床规则,仍有待深入探索^[32]。另外,非 EEG 类可穿戴设备尚无统一评价标准,也无产品获得官方机构的临床认证,给用户选择带来困难。商用可穿戴睡眠监测设备与经验证的主观睡眠质量评估工具之间的一致性处于差至中等水平,且在不同人群(健康睡眠人群、失眠人群、老年人群等)中差异显著^[9]。第三方验证研究显示,11 种主流消费级设备的宏观 F1 分数差异较大(26%~69%)^[47];整体来看,现有消费级设备与 PSG 的 Cohen's κ 系数普遍 < 0.7 ^[17]。

此外,作为评价基准的“金标准”PSG 本身并非绝对可靠。PSG 睡眠分期识别依靠专业人员对 30 s 片段(epoch)进行人工视觉判读,结果存在显著的主观性与判读者间差异。Lee 等^[48]针对 PSG 人工判读一致性的 Meta 分析显示,总体 Cohen's κ 系数为 0.76,但 N1 期仅为 0.24(一般水平),N3 期仅 0.57(中等水平);美国睡眠医学学会多中心数据集进一步证实,2 500 余名判读者对同一睡眠记录的总体一致率约 82.6%,而 N1 期的判读一致率降至 63.0%,N3 期降至 67.4%^[49]。该变异源于 N1 期作为清醒-睡眠过渡阶段,本身存在生理边界模糊性,以及 N3 期慢波活动的振幅与占比测量存在主观差异。由此可知,在以 PSG 作为参照进行对比时,部分可穿戴设备的测量误差可能源自 PSG 人工判读的不确定性。因此,后续建立可穿戴设备临床验证标准时,有必要采用多判读者或量化 PSG 自身的变异范围,从而更客观地评估可穿戴睡眠监测设备的真实性能。

综上,若仅单独优化传感器与算法,缺少临床场景验证、病理数据检验及统一评价标准,相关技术难以转化为可靠的产品。破解上述瓶颈不仅需要单项技术迭代,更需要“传感器-算法-临床”三位一体的协同创新。例如,传感器设计需兼顾测量精度与佩戴舒适度,以获取高质量数据;算法开发需融入病理先验知识与可解释机制,提升模型鲁棒性;临床验证层面则需建立标准化评价体系,明确技术适用边界。这也表明,未来可穿戴睡眠监测技术的突破性进展必然依托硬件创新、算法革新与临床转化

的深度融合。

4 未来发展趋势

4.1 硬件技术创新

快速发展的柔性传感器可集成于床单、睡衣,或贴附于皮肤表面,采集心率、血压等生理信号,实现“无感”睡眠监测^[17];这类传感器也可置于耳道及耳周面部皮肤获取 EEG 信号,睡眠分期识别性能与 PSG 具有较好的一致性^[50-51]。但该类技术仍需解决耐久性、多用户干扰及睡姿影响等问题,方可实现消费级产品化^[52]。非接触式睡眠监测技术成熟度不断提高。Heglum 等^[53]研究证实,超宽带雷达在健康人群中对 2 分期睡眠结构的识别准确率达 92%,但应用于睡眠障碍患者时准确率下降。红外摄像头可在无可见光源条件下记录人体姿态并检测心率信号,具有良好的穿透能力。在实验室环境中,红外阵列传感器检测准确率可达 95% 以上^[17]。该类技术适用于无法耐受穿戴设备的人群,有望在养老院、重症监护室等场景部署。另外,针对癫痫、帕金森病等需长期监测的患者,植入式 EEG 系统同样是可选方案^[54]。未来硬件创新可从低功耗架构与能量采集两方面寻求突破。一方面,可尝试在检测到体动、心率变异或血氧波动超过阈值时触发高频采集,而在平稳睡眠阶段维持低功耗监测模式;另一方面,考虑依托热电、压电及射频能量采集技术,将人体热能、体动机械能等转化为电能,为柔性贴片式传感器供能。

4.2 算法范式革新

单通道信号用于睡眠质量评估存在一定局限性,而多模态融合算法已成为提升评估精度的必然途径。例如,Wang 等^[32]开展的消融实验显示,仅采用 EEG 进行睡眠分期识别的 F1 分数为 79%~81%,引入 EOG 信号后可提升至 83%~85%,其中 EOG 对 REM 期识别性能提升最明显(F1 分数提升 3.9%)。Moris 等^[37]研究显示,采用 EEG、EOG 与 EMG 组成的多通道数据对模型训练后,睡眠分期识别的 F1 分数显著优于单通道 EEG,且双通道(EEG、EOG)也有明显提升。针对腕式体动记录仪数据,仅使用体动或 HRV 特征估算睡眠效率时,模型平均准确率显著低于 PSG,且难以区分 N1 期与 N2 期;而融合 HRV 与体动特征的模型,5 分期睡眠结构的识别准确率可达 98%

(Cohen's κ 系数为 0.974), 分期结果与 PSG 基本吻合^[20]。此外, 未来睡眠监测研究不应局限于生理信号, 还可融合代谢组学指标 (褪黑素、皮质醇)、基因组学信息及环境参数 (光照、噪声、温湿度), 实现更全面的睡眠监测。例如, 采用微流控芯片可集成汗液激素检测模块, 实现生化信号的连续监测, 再将其与电生理信号融合, 构建“数字孪生”睡眠模型^[17]。

4.3 临床联系增强

一方面, 未来睡眠监测模型除保证分期识别准确性外, 还需能追溯到睡眠分期识别背后的生理基础。近年来, 可解释人工智能 (explainable artificial intelligence, XAI) 技术为破解睡眠分期模型的“黑箱”难题提供了可行方案。例如, Vaquerizo-Villar 等^[55]将 Grad-CAM 应用于 OSA 患儿的单通道 EEG 睡眠分期模型, 发现 CNN 的决策焦点与临床专家标注结果高度一致; 分析结果显示, N2 期激活区域精准对应 K 复合波与睡眠纺锤波, N3 期则聚焦于高振幅 δ 慢波, 该模型准确率可达 86.9% (Cohen's κ 系数为 0.827), 证实 Grad-CAM 定位主要睡眠微结构的有效性。在特征贡献量化方面, SHAP 分析显示, 基于 XGBoost 构建的 HRV 睡眠分期模型中, 样本熵与近似熵等非线性特征对 N3 期识别的贡献度显著高于传统线性指标, 可为特征提取提供数据支撑^[56]。然而, 目前上述 XAI 方法仍处在“生成假设”阶段, 难以自动推导临床因果关联。如何将模型输出结果与美国睡眠医学学会的睡眠分期标准建立映射关系, 仍是 XAI 技术辅助临床决策的关键瓶颈。

另一方面, 传统模型多基于健康人群数据集训练, 在睡眠障碍等病理性数据中分期性能不佳, 该问题仍有待进一步解决。有研究指出, 采用多种神经网络与卷积层的组合, 有助于构建更精确的 OSA 早期诊断系统^[57]。针对 OSA 患者的睡眠结构碎片化特征, Fan 等^[58]提出自动睡眠分期深度学习网络模型, 能自适应融合不同通道信号特征的权重, 将双通道 EEG 和 EOG 信号转化为多时间、多频率尺度下的特征序列, 有效解决模态间异质性问题; 该模型在患者群体中的睡眠分期识别准确率可达 80.4%。此外, 亟需制定面向基于非 EEG 信号的消费级可穿戴睡眠监测设备的技术标准、统一采样率、信号预处理流程与特征

指标提取方案等^[8, 59]。在此基础上, 结合各类传感器监测技术的优劣, 建立睡眠监测与分级评估体系。例如, 首先, 采用腕式 PPG+体动的消费级可穿戴设备完成高危人群大规模筛查; 再依托融合 EEG 的可穿戴设备对疑似睡眠障碍患者开展居家诊断; 最后, 通过 PSG 对复杂病例进行诊断与治疗。

5 结语

本文系统梳理了可穿戴睡眠监测技术由单传感器到多模态融合发展的演进脉络, 发现该类技术正处于从技术验证迈向临床验证的关键时期。未来可穿戴睡眠监测技术的突破有赖于“传感器-算法-临床”全链条的系统创新; 传感器层面需在测量精度与佩戴舒适度间实现新的平衡; 算法层面需在多模态融合中嵌入可解释性与病理先验知识; 临床转化层面则需建立从消费级筛查到 PSG 诊断的标准规范。唯有三者协同, 可穿戴睡眠监测设备才能更好地由实验室走向居家监测场景, 由健康追踪拓展到临床辅助评估, 成为睡眠障碍 PSG 诊断体系的重要技术补充。

伦理声明: 不适用

作者贡献: 文献查阅: 黄美清、熊凯文; 论文撰写: 程珊; 论文修改: 党维涛、滕超淋; 论文审定与经费支持: 丛林

数据获取: 不适用

利益冲突声明: 无

致谢: 不适用

参考文献

- 1 Darien I. International classification of sleep disorders. 3rd Edition[M]. Darien IL: American Academy of Sleep Medicine, 2023: 179-199.
- 2 Benjafield AV, Sert Kuniyoshi FH, Malhotra A, et al. Estimation of the global prevalence and burden of insomnia: a systematic literature review-based analysis[J]. *Sleep Med Rev*, 2025, 82: 102121.
- 3 Benjafield AV, Ayas NT, Eastwood PR, et al. Estimation of the global prevalence and burden of obstructive sleep apnoea: a literature-based analysis[J]. *Lancet Respir Med*, 2019, 7(8): 687-698.
- 4 Phan H, Mikkelsen K. Automatic sleep staging of EEG signals: recent development, challenges, and future directions[J]. *Physiol Meas*, 2022, 43(4): 04TR01.
- 5 Precedence Research. Sleep trackers market size, share and trends 2026 to 2035[EB/OL]. (2026-04-23) [2026-09-08]. <https://www.precedenceresearch.com/sleep-trackers-market>.
- 6 SNS Insider. Sleep tracking device market size, share & global forecast 2026-2035[EB/OL]. (2026-01-21) [2026-09-08]. <https://www.snsinsider.com/reports/sleep-tracking-device-market-9588>.
- 7 Imtiaz SA. A systematic review of sensing technologies for wearable sleep staging[J]. *Sensors (Basel)*, 2021, 21(5): 1562.
- 8 Rentz LE, Ulman HK, Galster SM. Deconstructing commercial

- wearable technology: contributions toward accurate and free-living monitoring of sleep[J]. *Sensors (Basel)*, 2021, 21(15): 5071.
- 9 Srivali N, Cheungpasitporn W. Concordance of wearable device sleep metrics with patient-reported sleep quality: a systematic review[J]. *Sleep Med*, 2026, 144: 108941.
 - 10 Mikkelsen KB, Tabar YR, Toft HO, et al. Self-applied ear-EEG for sleep monitoring at home[J]. *Annu Int Conf IEEE Eng Med Biol Soc*, 2022, 2022: 3135–3138.
 - 11 Hestermann E, Schreve K, Vandenheever D. Enhancing deep sleep induction through a wireless in-ear EEG device delivering binaural beats and asmr: a proof-of-concept study[J]. *Sensors (Basel)*, 2024, 24(23): 7471.
 - 12 Bjarke MK, Rezai TY, Rævsbæk BL, et al. Ear-EEG sleep monitoring data sets[J]. *Sci Data*, 2025, 12(1): 301.
 - 13 Li Y, Li J, Yan C, et al. Sleep quality evaluation based on single-lead wearable cardiac cycle acquisition device[J]. *Sensors (Basel)*, 2023, 23(1): 328.
 - 14 Piccini J, August E, Óskarsdóttir M, et al. Using the electrodermal activity signal and machine learning for diagnosing sleep[J]. *Front Sleep*, 2023, 2: 1127697.
 - 15 Anusha AS, Preejith SP, Akl TJ, et al. Electrodermal activity based autonomic sleep staging using wrist wearable[J]. *Biomed Signal Process Control*, 2022, 75: 103562.
 - 16 Toma TI, Choi S. An end-to-end multi-channel convolutional bi-lstm network for automatic sleep stage detection[J]. *Sensors (Basel)*, 2023, 23(10): 4950.
 - 17 Yin J, Xu J, Ren T. Recent progress in long-term sleep monitoring technology[J]. *Biosensors (Basel)*, 2023, 13(3): 395.
 - 18 Tai Y, Obayashi K, Yamagami Y, et al. Association between circadian skin temperature rhythms and actigraphic sleep measures in real-life settings[J]. *J Clin Sleep Med*, 2023, 19(7): 1281–1292.
 - 19 Chen P, Jansen EC, Cielo CM, et al. Performance of an automated sleep scoring approach for actigraphy data in children and adolescents[J]. *Sleep*, 2026, 49(2): zsaf282.
 - 20 Kim H, Kim D, Oh J. Automation of classification of sleep stages and estimation of sleep efficiency using actigraphy[J]. *Front Public Health*, 2023, 10: 1092222.
 - 21 Kováčová K, Stebelová K. Sleep characteristics according to gender and age measured by wrist actigraphy[J]. *Int J Environ Res Public Health*, 2021, 18(24): 13213.
 - 22 Sadek I, Biswas J, Abdulrazak B. Ballistocardiogram signal processing: a review[J]. *Health Inf Sci Syst*, 2019, 7(1): 10.
 - 23 Kholghi M, Szollosi I, Hollamby M, et al. A validation study of a ballistocardiograph sleep tracker against polysomnography[J]. *J Clin Sleep Med*, 2022, 18(4): 1203–1210.
 - 24 Brown J, Mitchell Z, Jiang A, et al. Accuracy of smartphone-mediated snore detection in a simulated real-world setting: algorithm development and validation (preprint)[J]. *JMIR Form Res*, 2025, 9: e67861.
 - 25 Constantin L, Horvath CM, Baty F, et al. Towards long-term sleep staging via wearable reflective photoplethysmography[J]. *Sleep*, 2026, 49(3): zsaf246.
 - 26 Castillo-Escario Y, Blanco-Almazan D, Ferrer-Lluis I, et al. Measuring high-resolution sleep position in adolescents over 4 nights with smartphone accelerometers[J]. *Annu Int Conf IEEE Eng Med Biol Soc*, 2023, 2023: 1–4.
 - 27 Concheiro-Moscoso P, Groba B, Alvarez-Estevéz D, et al. Quality of sleep data validation from the xiaomi mi band 5 against polysomnography: comparison study[J]. *J Med Internet Res*, 2023, 25: e42073.
 - 28 Miller DJ, Sargent C, Roach GD. A validation of six wearable devices for estimating sleep, heart rate and heart rate variability in healthy adults[J]. *Sensors (Basel)*, 2022, 22(16): 6317.
 - 29 Robbins R, Weaver MD, Sullivan JP, et al. Accuracy of three commercial wearable devices for sleep tracking in healthy adults[J]. *Sensors (Basel)*, 2024, 24(20): 6532.
 - 30 Schyvens A, Peters B, Van Oost NC, et al. A performance validation of six commercial wrist-worn wearable sleep-tracking devices for sleep stage scoring compared to polysomnography[J]. *Sleep Adv*, 2025, 6(2): zpaf21.
 - 31 Abd-Alrazaq A, Aslam H, Alsaad R, et al. Detection of sleep apnea using wearable AI: systematic review and Meta-analysis[J]. *J Med Internet Res*, 2024, 26: e58187.
 - 32 Wang J, Zhao S, Jiang H, et al. CareSleepNet: a hybrid deep learning network for automatic sleep staging[J]. *IEEE J Biomed Health Inform*, 2024, 28(12): 7392–7405.
 - 33 Zhang Z, Lin B, Peng C, et al. Multi-modal sleep stage classification with two-stream encoder-decoder[J]. *IEEE Trans Neural Syst Rehabil Eng*, 2024, 32: 2096–2105.
 - 34 胡凯蕾, 陈景霞, 张鹏伟, 等. 用于睡眠精准分期的多模态生理时频特征提取网络[J]. *生物医学工程学杂志*, 2024, 41(1): 26–33. [Hu KL, Chen JX, Zhang PW, et al. Multi-modal physiological time-frequency feature extraction network for accurate sleep stage classification[J]. *Journal of Biomedical Engineering*, 2024, 41(1): 26–33.]
 - 35 Song T, Chowdhury SR, Malekzadeh M, et al. AI-driven sleep staging from actigraphy and heart rate[J]. *PLoS One*, 2023, 18(5): e285703.
 - 36 Hei Y, Yuan T, Fan Z, et al. Sleep staging classification based on a new parallel fusion method of multiple sources signals[J]. *Physiol Meas*, 2022, 43(4): 45003.
 - 37 Moris E, Larrabide I. Evaluating sleep-stage classification: how age and early-late sleep affects classification performance[J]. *Med Biol Eng Comput*, 2024, 62(2): 343–355.
 - 38 Yildirim O, Baloglu UB, Acharya UR. A deep learning model for automated sleep stages classification using PSG signals[J]. *Int J Environ Res Public Health*, 2019, 16(4): 599.
 - 39 Zhuang L, Dai M, Zhou Y, et al. Intelligent automatic sleep staging model based on CNN and LSTM[J]. *Front Public Health*, 2022, 10: 946833.
 - 40 Alvarez-Estevéz D, Rijsman RM. Inter-database validation of a deep learning approach for automatic sleep scoring[J]. *PLoS One*, 2021, 16(8): e256111.
 - 41 Fan J, Zhu H, Jiang X, et al. Unsupervised domain adaptation by statistics alignment for deep sleep staging networks[J]. *IEEE Trans Neural Syst Rehabil Eng*, 2022, 30: 205–216.
 - 42 Heremans E, Phan H, Borzée P, et al. From unsupervised to semi-supervised adversarial domain adaptation in electroencephalography-based sleep staging[J]. *J Neural Eng*, 2022, 19(3): 36044.
 - 43 Anido-Alonso A, Alvarez-Estevéz D. Decentralized data-privacy preserving deep-learning approaches for enhancing inter-database generalization in automatic sleep staging[J]. *IEEE J Biomed Health Inform*, 2023, 27(11): 5610–5621.
 - 44 Li H, Zhao X, Liu H, et al. Distributed data-privacy preserving federated learning method for sleep stage classification[J]. *Biomed Signal Process Control*, 2025, 109: 108032.
 - 45 Li W, Gao J. Automatic sleep staging by a hybrid model based on deep

- 1D-ResNet-SE and LSTM with single-channel raw EEG signals[J]. *PeerJ Comput Sci*, 2023, 9: e1561.
- 46 Satapathy SK, Brahma B, Panda B, et al. Machine learning-empowered sleep staging classification using multi-modality signals[J]. *BMC Med Inform Decis Mak*, 2024, 24(1): 119.
- 47 Lee T, Cho Y, Cha KS, et al. Accuracy of 11 wearable, nearable, and airable consumer sleep trackers: prospective multicenter validation study[J]. *JMIR Mhealth Uhealth*, 2023, 11: e50983.
- 48 Lee YJ, Lee JY, Cho JH, et al. Interrater reliability of sleep stage scoring: a Meta-analysis[J]. *J Clin Sleep Med*, 2022, 18(1): 193–202.
- 49 Rosenberg RS, Van Hout S. The American Academy of Sleep Medicine inter-scorer reliability program: sleep stage scoring[J]. *J Clin Sleep Med*, 2013, 9(1): 81–87.
- 50 Da Silva Souto CF, Pätzold W, Paul M, et al. Pre-gelled electrode grid for self-applied EEG sleep monitoring at home[J]. *Front Neurosci*, 2022, 16: 883966.
- 51 Da Silva Souto CF, Pätzold W, Wolf KI, et al. Flex-printed ear-EEG sensors for adequate sleep staging at home[J]. *Front Digit Health*, 2021, 3: 688122.
- 52 Zhang Y, Xiao A, Zheng T, et al. The relationship between sleeping position and sleep quality: a flexible sensor-based study[J]. *Sensors (Basel)*, 2022, 22(16): 6220.
- 53 Heglum H, Kallestad H, Vethe D, et al. Distinguishing sleep from wake with a radar sensor: a contact-free real-time sleep monitor[J]. *Sleep*, 2021, 44(8): zsab60.
- 54 Mivalt F, Sladky V, Worrell S, et al. Automated sleep classification with chronic neural implants in freely behaving canines[J]. *J Neural Eng*, 2023, 20(4): 46025.
- 55 Vaquerizo-Villar F, Gutiérrez-Tobal GC, Calvo E, et al. An explainable deep-learning model to stage sleep states in children and propose novel EEG-related patterns in sleep apnea[J]. *Comput Biol Med*, 2023, 165: 107419.
- 56 Yan C, Li P, Yang M, et al. Entropy analysis of heart rate variability in different sleep stages[J]. *Entropy (Basel)*, 2022, 24(3): 379.
- 57 Osa-Sanchez A, Ramos J, Mendez-Zorrilla A, et al. Wearable sensors and artificial intelligence for sleep apnea detection: a systematic review[J]. *J Med Syst*, 2025, 49(1): 66.
- 58 Fan J, Zhao M, Huang L, et al. Multimodal sleep staging network based on obstructive sleep apnea[J]. *Front Comput Neurosci*, 2024, 18: 1505746.
- 59 Gonsalves SG, Zhao JJ, Livinski AA, et al. Cleaning and pre-processing of actigraphy data for physical activity and sleep research: a scoping review[J]. *Physiol Meas*, 2026, 47(3): 35002.
- 收稿日期: 2026 年 07 月 14 日 修回日期: 2026 年 09 月 11 日
本文编辑: 杨 燕 曹 越

引用本文: 程珊, 黄美清, 党维涛, 等. 可穿戴睡眠监测技术研究进展: 从单传感器到多模态融合[J]. 医学新知, 2026, 36(10): 1164–1174. DOI: 10.12173/j.issn.1004-5511.202607068.

Cheng S, Huang MQ, Dang WT, et al. Research progress in wearable sleep monitoring technology: from single sensor to multimodal fusion[J]. *Yixue Xinzhi Zazhi*, 2026, 36(10): 1164–1174. DOI: 10.12173/j.issn.1004-5511.202607068.