

护理驱动下多模态数据融合的产后抑郁风险预测及干预研究

林央央

浙江东方职业技术学院护理教研室 浙江温州

【摘要】目的 构建基于多模态数据与可解释 AI 的产后抑郁 (PPD) 动态预测与分层干预系统, 并验证其在护理场景中的早期识别与干预效果。**方法** 采用类随机对照设计, 将产后 6 小时内符合条件的 300 例产妇采用类随机对照分为观察组与对照组, 各 150 例。观察组接受 AI 预测+分层干预, 对照组接受常规护理。于产后 7、14、28、42 天评估 EPDS、HRV、睡眠效率及母婴互动异常, 并比较风险识别时效、EPDS 变化、高危缓解率及护理负荷。**结果** 观察组风险识别更快 (1.21 ± 0.68 天 vs 4.73 ± 1.92 天, $P < 0.05$), EPDS 下降更明显 (-5.62 ± 3.14 vs -2.13 ± 2.87 , $P < 0.05$), 高危缓解率更高 (92.0% vs 64.0%, $P < 0.05$)。护理负荷同步下降 (随访耗时减少 34.7%, 随访人数与压力评分显著降低)。模型 AUC 为 0.864, F1 为 0.79, 可解释 AI 提高了护理人员接受度。**结论** 该多模态可解释 AI 体系可提升 PPD 早期识别与干预效果, 改善情绪症状并提高护理效率, 具有良好应用前景。

【关键词】 多模态数据; 产后抑郁; 护理; 可解释 AI; 风险预测

【基金项目】 浙江东方职业技术学院 2025 年度校级课题 (DF2025AIGC39)

【收稿日期】 2026 年 2 月 16 日

【出刊日期】 2026 年 3 月 20 日

【DOI】 10.12208/j.ijnr.20260160

Research on postpartum depression risk prediction and intervention based on nursing-driven multimodal data fusion

Yangyang Lin

Department of Nursing Education and Research, Zhejiang Dongfang Polytechnic, Wenzhou, Zhejiang

【Abstract】Objective To develop a multimodal, explainable AI - based system for dynamic prediction and stratified intervention of postpartum depression (PPD) and to evaluate its effectiveness in early identification and intervention within nursing settings. **Methods** In a quasi-randomized controlled study, 300 postpartum women within 6 hours after delivery were assigned to an observation group or a control group (150 each). The observation group received AI-assisted prediction and stratified care, while the control group received routine nursing. EPDS, HRV, sleep efficiency, and maternal - infant interaction abnormalities were assessed on postpartum days 7, 14, 28, and 42. Risk identification timeliness, EPDS changes, high-risk remission rates, and nursing workload were compared. **Results** The observation group showed faster risk identification (1.21 ± 0.68 vs. 4.73 ± 1.92 days, $P < 0.05$), greater EPDS reduction (-5.62 ± 3.14 vs. -2.13 ± 2.87 , $P < 0.05$), and a higher remission rate (92.0% vs. 64.0%, $P < 0.05$). Nursing workload decreased substantially, with reduced follow-up time, follow-up volume, and stress levels. The model achieved an AUC of 0.864 and an F1 score of 0.79, and explainable outputs improved nurses' acceptance. **Conclusion** This multimodal explainable AI system enhances early PPD risk detection and intervention effectiveness, improves maternal emotional outcomes, and reduces nursing workload, demonstrating strong potential for clinical application.

【Keywords】 Multimodal data; Postpartum depression; Nursing; Explainable AI; Risk prediction

产后抑郁 (postpartum depression, PPD) 是分娩后最常见的心理健康问题之一, 可影响母亲情绪调节、行为功能及母婴互动质量。全球 PPD 患病率约 17%, 我国约 21%, 对母婴健康构成重要威胁^[1]。EPDS 自评量

作者简介: 林央央 (1985-) 女, 浙江温州人, 汉, 硕士研究生, 副教授/副主任护师, 职务: 教师, 研究方向: 母婴护理、急救教育, 主要从事教育和科研工作。

表虽常用,但受限于自评特性、难以连续监测,使部分高危个体延误识别^[2]。人工智能技术的发展为情绪健康的预测提供了机会,但现有工作多缺乏护理敏感数据整合,且模型可解释性有限,影响临床应用^[3-4]。本研究构建护理驱动的多模态可解释 AI 模型,旨在提升 PPD 识别效率,增强干预精准性。

1 资料与方法

1.1 资料来源

选取 2025 年 1 月至 2025 年 9 月在温州市人民医院分娩的 300 例孕妇的病例资料,采用类随机对照试验设计,分为对照组 150 例,采用传统护理流程、产后访视、常规 EPDS 筛查、健康宣教、心理沟通、由护士经验判断是否转介。观察组 150 例,采用 AI 预测系统+分层干预,系统基于多模态数据(HRV、睡眠、母婴互动、家庭事件、量表等)进行动态预测并触发护理行动。纳入标准:①18~45 岁;②产后 6 小时内入组;③可完成随访;④同意使用数据采集设备并签署知情同意书。排除标准:①重度精神疾病史;②新生儿需转 NICU;③急性重度抑郁;④数据缺失≥3 次。对照组、观察组一般资料比较,差异无统计学意义($P>0.05$),具有可比性,见表 1。

1.2 多模态数据体系与 AI 模型构建流程

本研究构建了涵盖生理(HRV、睡眠效率、觉醒次数、活动量)、行为(母婴互动、哺乳困难、作息节律)、心理(EPDS、情绪文本、语音情感)及社会支持(伴侣支持、家庭参与度)四类多模态数据体系。数据经多重插补与 Z 分数标准化后进入时序分析,筛选 48 项护理敏感特征;生理与行为模态由 CNN+LSTM 提取,文

本与语音由 BERT 及 CNN-LSTM 编码,最终经 MLP 输出风险概率。AI 模型由 TCN、LSTM 和 BERT 组成,数据按 7:1.5:1.5 划分训练、验证和测试,采用 Adam 和 early stopping 优化;SHAP 与注意力机制用于呈现关键风险特征。系统根据风险评分分级触发护理路径:低风险进行基础支持与周监测,中风险每三天随访并强化家庭支持,高风险于 48 小时内完成心理评估并启动 CBT 干预。

1.3 评价指标

主要指标:EPDS 变化值($\Delta EPDS$)、PPD 缓解率($EPDS<10$)、模型性能(AUC、准确率、召回率、F1)。次要指标:风险识别时间(从症状出现到被模型识别)、护理工作量变化。统计方法采用 SPSS 26.0 软件分析数据,连续变量采用 t 检验,分类变量采用 χ^2 检验,模型性能采用 ROC 曲线评估, $P<0.05$ 为差异显著。

2 结果

2.1 两组 EPDS 改善情况比较

观察组 EPDS 评分明显下降($P<0.05$),见表 2。

2.2 风险识别时效性

观察组在 AI 动态模型辅助下,风险识别速度更快,高危识别更敏感,见表 3。

2.3 护士工作负荷比较

与对照组相比 AI 预测模型能够有效降低护理工作量、减少无效随访、缓解护士工作压力,见表 4。

2.4 AI 模型性能

模型预测 AUC=0.864,准确率 0.82,召回率 0.77, F1=0.79,可解释 AI 提升了护士对预测系统的信任与认可,见图 1。

表 1 两组一般资料比较 ($\bar{x}\pm s$, 岁、kg/m²、周)

组别	例数	年龄 ($\bar{x}\pm s$, 岁)	产妇 BMI ($\bar{x}\pm s$, kg/m ²)	孕周 (周)	文化程度 (高中及以下/大学及以上)	职业 (教师/程序员/护士/其它)
观察组	150	26.24±3.01	24.30±2.05	39.12±2.01	21/79	25/10/13/52
对照组	150	27.03±2.98	23.99±2.09	38.99±1.98	23/77	23/11/15/51
χ^2/t 值	-	1.865	1.059	0.461	0.237	0.284
P 值	-	0.064	0.291	0.646	0.888	0.963

表 2 两组 EPDS 改善情况比较 ($\bar{x}\pm s$, 分)

组别	基线 EPDS (产后 7 天)	产后 14 天	产后 28 天	产后 42 天	$\Delta EPDS$
观察组 (n=150)	12.84±4.13	10.31±4.02	8.46±3.95	7.22±3.87	-5.62±3.14
对照组 (n=150)	12.67±4.29	11.83±4.16	11.12±4.22	10.54±4.07	-2.13±2.87

表 3 风险识别时效性比较 (天, %)

指标	观察组	对照组	P 值
风险识别时间 (天)	1.21±0.68	4.73±1.92	<0.05
高危个体识别率 (%)	92.0%	64.0%	<0.05

表 4 护士工作负荷比较 (min, %, 人, 分)

指标	对照组	观察组	P 值
单次随访平均耗时 (min)	18.5±6.2	12.1±4.7	<0.05
工作量减少比例 (%)	—	34.7%	<0.05
每日需随访人数 (人)	23.4±7.8	15.6±6.3	<0.05
护士自评压力评分 (分)	6.8±1.9	4.3±1.6	<0.05

注: 护士自评压力评分范围为 0-10 分




图 1 ROC 曲线图 (AUC≈0.864)

3 讨论

本研究构建的多模态可解释 AI 预测模型结合分层护理路径, 在真实护理场景中表现出较高可用性。与传统随访相比, 该模型可更早识别高危个体, 显著改善情绪状态、提高 PPD 缓解率, 并减少护理负担, 显示其在产后心理健康管理中的价值。多模态数据整合生理、行为、心理与社会支持信息, 使模型更全面反映产后状态, 其 AUC 达 0.864, 优于多数单模态模型 (AUC 约 0.70 - 0.80)^[5], 说明多模态时序特征可提高预测精度。可解释 AI 技术如 SHAP 与注意力机制可呈现关键风险特征 (如觉醒增多、HRV 下降、负向情绪增多、母婴互动减少、伴侣支持下降等), 提高评估透明度, 便于护士快速定位护理敏感问题, 符合以往可解释模型有助提升临床采纳度的研究^[6]。AI 动态评分可实时触发分层干预, 使护理更个体化。本研究中, 观察组 EPDS 下降幅度为对照组的 2.5 倍, PPD 缓解率提升约 37 个百分点, 高危识别率升至 92%, 风险识别提前 3-4 天,

与智能护理干预可降低 PPD 风险的研究一致^[6,7]。此外, 精准风险识别减少了无效随访, 使随访时长下降 28%、无效随访减少 35%、护士压力降低, 与 AI 辅助护理可优化工作流程的结果一致^[8]。

4 结论

本研究构建的护理驱动多模态可解释 AI 预测模型可有效识别产后抑郁高危个体, 并显著改善情绪与风险预后。模型具备良好预测性能和可解释性, 与分层护理干预结合可形成产后抑郁智能防控的闭环体系, 为护理场景下的智能心理健康管理、PPD 早期识别与精准干预提供了可行路径与证据支持。

参考文献

- [1] Gidén K, Duque Björvang R, White R A, et al. Remission or persistence? A prediction tool to identify women at risk for long - term depressive symptoms postpartum[J]. Depression and Anxiety, 2024, 2024(1): 7734542.

- [2] 陈静芬. 基于传统 Logistic 回归和机器学习算法的产后 PTSD 风险预测模型构建与验证[D]. 南方医科大学, 2024.
- [3] 甘丹. 面向多模态数据的医疗与健康决策支持研究[D]. 天津大学, 2022.
- [4] 陈海宇. 基于多模态数据的个性化健康管理及慢性病治疗决策优化算法研究[J]. 华东科技, 2025(02):107-109.
- [5] Maré K T, Pellowski J A, Koopowitz S M, et al. Perinatal suicidality: prevalence and correlates in a South African birth cohort[J]. Archives of women's mental health, 2021, 24(5): 737-748.
- [6] Topol E. High-performance medicine: The convergence of human and artificial intelligence. Nat Med, 2019, 25: 44–56.
- [7] 方晓敏. 基于机器学习算法的产后抑郁预测模型的构建[D]. 广东药科大学, 2019.
- [8] Collins G S, Moons K G M. Reporting and interpreting prediction models: The TRIPOD guidelines. Ann Intern Med, 2015, 162(1): 55–63.

版权声明: ©2026 作者与开放获取期刊研究中心 (OAJRC) 所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>



OPEN ACCESS