

基于机器学习算法的危重症患者压力性损伤风险预测模型的构建与验证

吕文佳¹ 朱明丽² 陆天敏¹ 吴秀云¹ 江海燕¹ 林瑶³

¹ 杭州市第一人民医院城北院区(杭州市老年病医院)临床心理科,杭州 310006; ² 杭州市第一人民医院城北院区(杭州市老年病医院)护理部,杭州 310006; ³ 杭州市第一人民医院临床心理科,杭州 310006

通信作者: 林瑶, Email: 249635644@qq.com

【摘要】 目的 利用机器学习算法构建危重症患者压力性损伤预测模型并进行内部验证。方法 采用前瞻性队列研究,用便利抽样法选取 2023 年 1 月至 2024 年 3 月杭州市第一人民医院城北院区重症监护病房(ICU)收治的危重症患者作为研究对象。根据 ICU 内是否发生压力性损伤将患者分为两组,比较组间压力性损伤相关指标的差异。将数据集随机分为训练集(75%)和验证集(25%)。采用 Lasso 回归进行特征筛选,并用多因素 Logistic 回归分析确定独立危险因素,用极限梯度提升(XG-Boost)进行压力性损伤的机器学习模型构建,用受试者工作特征曲线(ROC 曲线)、校准曲线、临床决策曲线分析(DCA)评价模型的性能。用沙普利加和解释(SHAP)法对特征重要性进行排序。结果 共纳入 350 例危重症患者,其中 102 例发生压力性损伤,发生率为 29.1%。有无压力性损伤两组患者意识状态、机械通气、镇静剂、ICU 住院天数、Braden 评分、使用暖毯、白细胞计数、中性粒细胞计数、葡萄糖和乳酸水平差异均有统计学意义(均 $P < 0.05$)。Lasso 回归分析确定了 6 个具有预测性的变量,分别为意识状态、机械通气、使用暖毯、ICU 住院天数、中性粒细胞计数和葡萄糖。多因素 Logistic 回归分析显示,机械通气、使用暖毯、ICU 住院天数延长、中性粒细胞计数升高、葡萄糖升高为压力性损伤的独立危险因素[机械通气:优势比(OR)=2.338,95% 置信区间(95%CI)为 1.768~3.089, $P=0.002$;使用暖毯:OR=1.772,95%CI 为 1.341~2.338, $P=0.039$;ICU 住院天数延长:OR=1.081,95%CI 为 1.067~1.097, $P < 0.001$;中性粒细胞计数升高:OR=1.044,95%CI 为 1.022~1.067, $P=0.036$;葡萄糖升高:OR=1.062,95%CI 为 1.031~1.094, $P=0.027$]。基于上述 6 个因素,采用 XG-Boost 法构建预测模型,ROC 曲线显示,该模型具有较高的预测价值,在训练集中曲线下面积(AUC)为 0.896(95%CI 为 0.863~0.929),在验证集中 AUC 为 0.835(95%CI 为 0.761~0.908)。校准曲线显示,预测概率与实际发生率较为一致。DCA 曲线提示模型在较大阈值范围内具有临床适用性。SHAP 法显示模型中特征重要性从高到低依次为 ICU 住院天数、机械通气、中性粒细胞计数、意识状态、葡萄糖和使用暖毯。结论 基于 XG-Boost 机器学习算法构建的模型在预测危重症患者压力性损伤发生方面具有较高的性能,识别关键预测因素,有助于临床风险评估与干预。

【关键词】 机器学习;危重症;压力性损伤;风险;预测模型

基金项目:浙江省医药卫生科技计划项目(2024KY1304)

DOI: 10.3760/cma.j.cn121430-20250319-00278

Construction and validation of risk prediction model of pressure injury in critically ill patients based on machine learning algorithm

Lyu Wenjia¹, Zhu Mingli², Lu Tianmin¹, Wu Xiuyun¹, Jiang Haiyan¹, Lin Yao³

¹Department of Clinical Psychology, North District of Hangzhou First People's Hospital (Hangzhou Geriatrics Hospital), Hangzhou 310006, China; ²Department of Nursing, North District of of Hangzhou First People's Hospital (Hangzhou Geriatrics Hospital), Hangzhou 310006, China; ³Department of Psychology, Hangzhou First People's Hospital, Hangzhou 310006, China
Corresponding author: Lin Yao, Email: 249635644@qq.com

【Abstract】 **Objective** Predict the occurrence of pressure injury in critically ill patients by using machine learning models and conducting internal validation. **Methods** A prospective cohort study was conducted. Critically ill patients admitted to the intensive care unit (ICU) of the North District of Hangzhou First People's Hospital from January 2023 to March 2024 were enrolled using convenience sampling. Patients were divided into two groups based on the occurrence of pressure injury during their ICU stay, and the differences in pressure injury related indicators were compared between the groups. The dataset was randomly divided into a training set (75%) and a validation set (25%). Feature selection was performed using the Lasso regression. Independent risk factors were then identified via multivariate Logistic regression analysis. An extreme gradient boosting (XG-Boost) machine learning model was developed to predict pressure injury risk. The model's performance was comprehensively evaluated using receiver operator characteristic curve (ROC curve), calibration curve, and clinical decision curve analysis (DCA). The Shapley Additive exPlanations (SHAP) method was used to rank feature importance. **Results** A total of 350 critically ill patients were included, of whom 102 (29.1%) developed pressure injuries. There were statistically significant differences in consciousness status, mechanical

ventilation, sedative use, length of ICU stay, Braden score, use of warm blankets, white blood cell count, neutrophil count, blood glucose, and lactate level between the pressure injury and non-pressure injury groups (all $P < 0.05$). Lasso regression analysis identified six predictive variables: consciousness status, mechanical ventilation, use of warm blankets, length of ICU stay, neutrophil count, and blood glucose. Multivariate Logistic regression analysis subsequently revealed that mechanical ventilation, use of warm blankets, prolonged ICU stay, elevated neutrophil count, and elevated blood glucose were independent risk factors for pressure injuries [mechanical ventilation: odds ratio (OR)=2.338, 95% confidence interval (95%CI) was 1.768–3.089, $P=0.002$; use of warm blankets: OR=1.772, 95%CI was 1.341–2.338, $P=0.039$; prolonged ICU stay: OR=1.081, 95%CI was 1.067–1.097, $P < 0.001$; elevated neutrophil count: OR=1.044, 95%CI was 1.022–1.067, $P=0.036$; elevated blood glucose: OR=1.062, 95%CI was 1.031–1.094, $P=0.027$]. Based on these six risk factors, a predictive model was constructed using the XG-Boost method. The ROC curve analysis demonstrated the model has high predictive performance, with an area under the curve (AUC) of 0.896 (95%CI was 0.863–0.929) in the training set and 0.835 (95%CI was 0.761–0.908) in the validation set. The calibration curve indicated good agreement between predicted probabilities and actual outcomes. DCA further suggested that the model had clinical utility across a wide range of threshold probabilities. SHAP analysis ranked feature importance in descending order as follows: length of ICU stay, mechanical ventilation, neutrophil count, consciousness status, blood glucose, and use of warm blankets. **Conclusions** The constructed XG-Boost machine learning model has high performance in predicting the occurrence of pressure injury in critically ill patients. Identify key predictive factors can aid clinical risk assessment and intervention.

【Key words】 Machine learning; Critical illness; Pressure injury; Risk; Prediction model

Fund program: Medical and Health Science and Technology Program of Zhejiang Province (2024KY1304)

DOI: 10.3760/ema.j.cn121430-20250319-00278

压力性损伤是由于缺血、长期压力及缺氧对皮肤和(或)底层组织造成的损害^[1]。危重症患者因卧床制动时间延长、血液循环不良、营养不足、免疫功能受损、皮肤耐受性下降、受到的压力恒定,从而增加了发生压力性损伤的风险,因此,危重症患者更容易发生压力性损伤^[2-3]。压力性损伤大大增加了危重症患者的感染风险,不仅延长住院时间、增加住院费用,同样是预后不良,甚至死亡的重要因素^[4-5]。因此,预防和早期识别压力性损伤的风险对危重症患者至关重要。机器学习已被证明具有预测、诊断临床结果的能力^[6]。与传统的统计分析方法相比,机器学习在解析复杂的数据交互和非线性关系方面效果更好^[7-8]。本研究旨在通过建立一个可解释的机器学习预测模型来早期预测重症监护病房(intensive care unit, ICU)危重症患者发生压力性损伤的风险,并利用沙普利加和解释(Shapley Additive exPlanation, SHAP)进而提高医学领域机器学习模型的可解释性和透明度,为今后的研究和实践提供决策支持工具。

1 资料与方法

1.1 病例来源:采用前瞻性队列研究,用便利抽样法选取 2023 年 1 月至 2024 年 3 月杭州市第一人民医院城北院区收治的危重症患者作为研究对象。

1.1.1 纳入标准:① 入住 ICU 前无压力性损伤;② 年龄 18 周岁及以上。

1.1.2 排除标准:家属拒绝提供相关资料。

1.1.3 剔除标准:① 死亡或自动出院等;② 临床资料不完整,包括入院前的健康状况、治疗、ICU 入院

期间的护理记录等。

1.2 伦理学:本研究符合医学伦理学标准,并经医院伦理委员会审批后进行临床调研(审批号: HZLNYY2022-A048)。

1.3 研究方法

1.3.1 影响因素的确立:通过文献检索和专家咨询确定压力性损伤的影响因素^[1, 4-5, 9-23],包括高血压、卒中史、手术史、住院期间手术、意识状态、机械通气、镇静、镇痛、吸烟史、ICU 住院天数、年龄、Braden 评分、使用暖毯、血红蛋白、白细胞计数、中性粒细胞计数、葡萄糖、尿素氮、血清肌酐、乳酸等共 20 个。收集患者入院时上述指标。

1.3.2 极限梯度提升(extreme gradient boosting, XG-Boost)机器学习:模型构建前,对数据集进行划分,75% 的样本使用“插入符号”包被分配到训练集,而剩下的 25% 被分配到验证集。使用“XG-Boost”包构建模型,利用 train 函数从插入符号包中优化参数,并输出最佳参数配置,学习率 eta 设置为 0.1,最大深度设置为 2,迭代轮数(即增强轮数)设置为 100。

1.3.3 SHAP 机器学习:利用“Shapviz”机器学习模型预测的 R 包,基于 SHAP(SHapley 加性扩展)值的视觉解释。SHAP 值解释每个特征对模型预测的贡献程度。利用特征重要性图显示对模型预测影响最显著的特征,并根据 SHAP 值的平均绝对值对特征重要性进行排序,特征值越高,越有可能发生压力性损伤。

1.4 统计学方法:采用 R 4.3.0 软件进行统计分析和数据可视化。用 Kolmogorov-Smirnov 法检验数据

分布状态,正态分布的数据用均数 ± 标准差 ($\bar{x} \pm s$) 描述,采用独立样本 t 检验;非正态分布的数据用中位数(四分位数)[$M(Q_1, Q_3)$]描述,采用 Mann-Whitney U 检验。分类数据以频数或百分比表示,采用 χ^2 检验。采用 Lasso 回归筛选变量,将筛选得到的特征变量纳入多因素 Logistic 回归分析。借助 R 语言 XG-Boost 和 Shapviz 等程序分别构建机器学习预测模型。采用受试者工作特征曲线(receiver operator characteristic curve, ROC 曲线)、校准曲线和临床决策曲线分析(decision curve analysis, DCA)评价模型的性能。检验水准 α 值取双侧 0.05。

2 结果

2.1 患者一般资料:有 3 例患者因死亡或自动出院出组,共纳入 350 例危重症患者,其中有 102 例发生压力性损伤,发生率为 29.1%。表 1 显示,有无压力性损伤两组患者意识状态、机械通气、镇静剂、ICU 住院天数、Braden 评分、使用暖毯、白细胞计数、中性粒细胞计数、葡萄糖和乳酸水平差异均有统计学意义(均 $P < 0.05$),而两组患者在年龄、性别、吸烟

史、高血压、卒中史、手术史、住院期间手术、使用镇痛剂、血红蛋白、血清肌酐、尿素氮等方面差异均无统计学意义(均 $P > 0.05$)。

2.2 Lasso 回归分析:在所纳入的变量中,确定了 6 个具有预测性的变量,包括意识状态、机械通气、使用暖毯、ICU 住院天数、中性粒细胞计数和葡萄糖(图 1)。

2.3 多因素 Logistic 回归分析:将上述 6 个具有预测性的变量纳入多因素 Logistic 回归分析,最终确定机械通气、使用暖毯、ICU 住院天数延长、中性粒细胞计数升高、葡萄糖升高为压力性损伤的独立危险因素(均 $P < 0.05$;表 2)。

2.4 XG-Boost 机器学习模型性能评估:以上述 6 个因素构建 XG-Boost 模型,ROC 曲线分析显示(图 2;表 3),该模型对危重症患者压力性损伤具有较高的预测价值,在训练集中其预测的曲线下面积(area under the curve, AUC)为 0.896,在验证集中 AUC 为 0.835。在训练集和验证集中,该模型具有较高的特异度,但敏感度较低,准确性较高。

表 1 是否发生压力性损伤两组危重症患者基本信息比较

| 指标 | 压力性损伤组 (102 例) | 非压力性损伤组 (248 例) | 统计量值 | P 值 | 指标 | 压力性损伤组 (102 例) | 非压力性损伤组 (248 例) | 统计量值 | P 值 |
|------------------------|----------------------|----------------------|-----------------|--------|---------------------------------------------|---------------------|--------------------|-----------------|--------|
| 年龄 [岁, $M(Q_1, Q_3)$] | 72.24 (58.64, 85.33) | 72.16 (55.24, 84.05) | $U=0.533$ | 0.416 | 使用镇静剂 [例(%)] | | | $\chi^2=10.046$ | 0.002 |
| 性别 [例(%)] | | | $\chi^2=0.109$ | 0.742 | 是 | 65 (63.7) | 198 (79.8) | | |
| 男性 | 61 (59.8) | 153 (61.7) | | | 否 | 37 (36.3) | 50 (20.2) | | |
| 女性 | 41 (40.2) | 95 (38.3) | | | 使用镇痛剂 [例(%)] | | | $\chi^2=0.364$ | 0.546 |
| 吸烟史 [例(%)] | | | $\chi^2=0.772$ | 0.380 | 是 | 64 (62.8) | 147 (59.3) | | |
| 有 | 54 (62.8) | 144 (58.1) | | | 否 | 38 (37.2) | 101 (40.7) | | |
| 无 | 48 (37.2) | 104 (41.9) | | | ICU 住院天数 [d, $M(Q_1, Q_3)$] | 14 (8, 22) | 7 (4, 10) | $U=5.689$ | <0.001 |
| 高血压 [例(%)] | | | $\chi^2=0.073$ | 0.788 | Braden 评分 [分, $M(Q_1, Q_3)$] | 13 (12, 14) | 14 (12, 15) | $U=2.212$ | 0.016 |
| 是 | 60 (58.8) | 142 (57.3) | | | 使用暖毯 [例(%)] | | | $\chi^2=22.185$ | <0.001 |
| 否 | 42 (41.2) | 106 (42.7) | | | 是 | 31 (30.4) | 25 (10.1) | | |
| 卒中史 [例(%)] | | | $\chi^2=1.328$ | 0.249 | 否 | 71 (69.6) | 223 (89.9) | | |
| 是 | 36 (35.3) | 72 (29.0) | | | 白细胞计数 [$\times 10^9/L$, $M(Q_1, Q_3)$] | 11.12 (8.01, 14.20) | 9.02 (6.84, 11.75) | $U=3.563$ | <0.001 |
| 否 | 66 (64.7) | 176 (71.0) | | | 中性粒细胞计数 [$\times 10^9/L$, $M(Q_1, Q_3)$] | 9.08 (5.95, 12.21) | 7.11 (5.02, 9.45) | $U=3.256$ | <0.001 |
| 手术史 [例(%)] | | | $\chi^2=0.252$ | 0.616 | 葡萄糖 [mmol/L, $M(Q_1, Q_3)$] | 8.11 (6.33, 11.57) | 6.72 (5.54, 9.31) | $U=3.334$ | <0.001 |
| 有 | 63 (61.8) | 146 (58.9) | | | 乳酸 [mmol/L, $M(Q_1, Q_3)$] | 2.82 (1.93, 3.71) | 2.22 (1.63, 2.95) | $U=3.823$ | <0.001 |
| 无 | 39 (38.2) | 102 (41.1) | | | 血红蛋白 [g/L, $M(Q_1, Q_3)$] | 98 (80, 116) | 94 (81, 118) | $U=0.901$ | 0.795 |
| 住院期间手术 [例(%)] | | | $\chi^2=0.492$ | 0.483 | 血清肌酐 [$\mu\text{mol/L}$, $M(Q_1, Q_3)$] | 92 (64, 156) | 78 (55, 142) | $U=1.763$ | 0.113 |
| 是 | 71 (69.6) | 163 (65.7) | | | 尿素氮 [mmol/L, $M(Q_1, Q_3)$] | 8.02 (6.24, 12.15) | 7.61 (4.85, 11.33) | $U=1.883$ | 0.102 |
| 否 | 31 (30.4) | 85 (34.3) | | | | | | | |
| 意识状况 [例(%)] | | | $\chi^2=17.135$ | <0.001 | | | | | |
| 昏迷 | 52 (51.0) | 69 (27.8) | | | | | | | |
| 未昏迷(嗜睡/昏睡) | 50 (49.0) | 179 (72.2) | | | | | | | |
| 机械通气 [例(%)] | | | $\chi^2=22.247$ | <0.001 | | | | | |
| 是 | 66 (64.7) | 92 (37.1) | | | | | | | |
| 否 | 36 (35.3) | 156 (62.9) | | | | | | | |

注:ICU 为重症监护病房

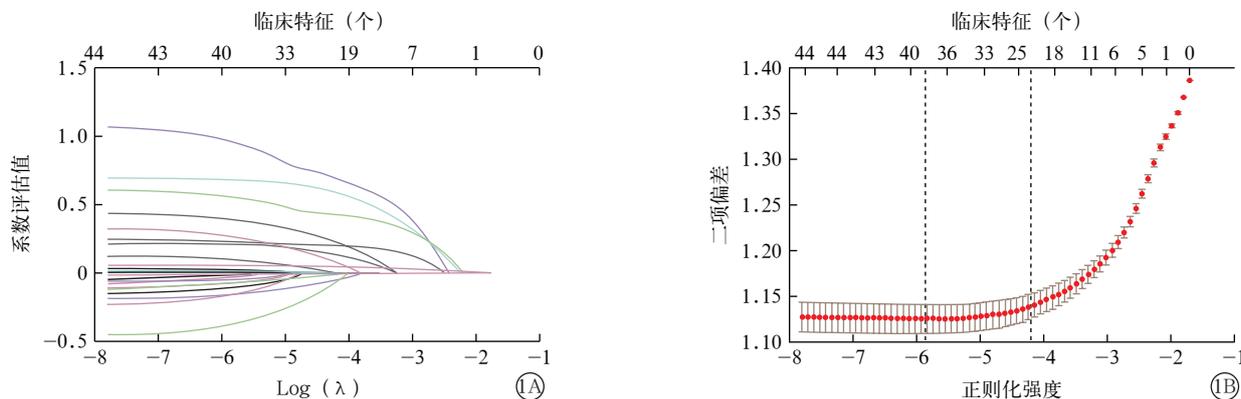


图1 危重症患者发生压力性损伤相关特征 Lasso 回归分析的套索系数路径图(A)和套索正则化路径图(B)

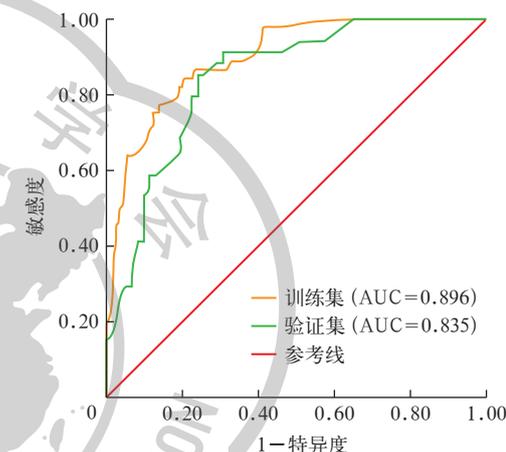
表2 危重症患者压力性损伤风险的多因素 Logistic 回归分析

| 因素 | β 值 | s_{β} | χ^2 值 | OR 值 | 95%CI | P 值 |
|------------|-----------|-------------|------------|-------|---------------|--------|
| 常量 | -3.497 | 0.373 | 9.410 | | | |
| 意识状况(昏迷) | 0.551 | 0.308 | 1.792 | 1.736 | 1.275 ~ 2.264 | 0.072 |
| 机械通气 | 0.849 | 0.278 | 3.053 | 2.338 | 1.768 ~ 3.089 | 0.002 |
| 暖毯 | 0.572 | 0.277 | 2.062 | 1.772 | 1.341 ~ 2.338 | 0.039 |
| ICU 住院天数延长 | 0.079 | 0.012 | 6.583 | 1.081 | 1.067 ~ 1.097 | <0.001 |
| 中性粒细胞计数升高 | 0.042 | 0.020 | 2.101 | 1.044 | 1.022 ~ 1.067 | 0.036 |
| 葡萄糖升高 | 0.060 | 0.027 | 2.219 | 1.062 | 1.031 ~ 1.094 | 0.027 |

注: ICU 为重症监护病房, OR 为优势比, 95%CI 为 95% 置信区间; 空白代表无此项

校准曲线显示(图3), 训练集的校准曲线显示出良好的拟合, 表明模型预测概率与实际发生率之间的一致性很高。相比之下, 验证集的校准曲线有一定程度的偏差, 但仍在可接受的范围内, 说明模型对不可见数据具备一定的泛化能力, 但其预测的可靠性较训练集略有下降。DCA 曲线表明(图4), 在训练集和验证集, 该模型在大多数阈值概率下为临床决策提供了良好的净效益。

2.5 机器学习模型的解释: 模型所包含的特征按平均 SHAP 绝对值从高到低依次排序, 分别是 ICU 住院天数、机械通气、中性粒细胞计数、意识状态、葡萄糖和使用暖毯(图5)。



注: ROC 曲线为受试者工作特征曲线, AUC 为曲线下面积
图2 在训练集和验证集中危重症患者压力性损伤预测模型的 ROC 曲线

表3 基于 XG-Boost 法构建危重症患者压力性损伤预测模型在训练集和验证集中的性能

| 数据集 | AUC (95%CI) | 敏感度 (95%CI) |
|-----|-----------------------|-----------------------|
| 训练集 | 0.896 (0.863 ~ 0.929) | 0.688 (0.603 ~ 0.761) |
| 验证集 | 0.835 (0.761 ~ 0.908) | 0.524 (0.377 ~ 0.666) |

| 数据集 | 特异度 (95%CI) | 准确性 (95%CI) |
|-----|-----------------------|-----------------------|
| 训练集 | 0.892 (0.847 ~ 0.925) | 0.823 (0.780 ~ 0.860) |
| 验证集 | 0.916 (0.836 ~ 0.959) | 0.784 (0.702 ~ 0.853) |

注: XG-Boost 为极限梯度提升, AUC 为曲线下面积, 95%CI 为 95% 置信区间

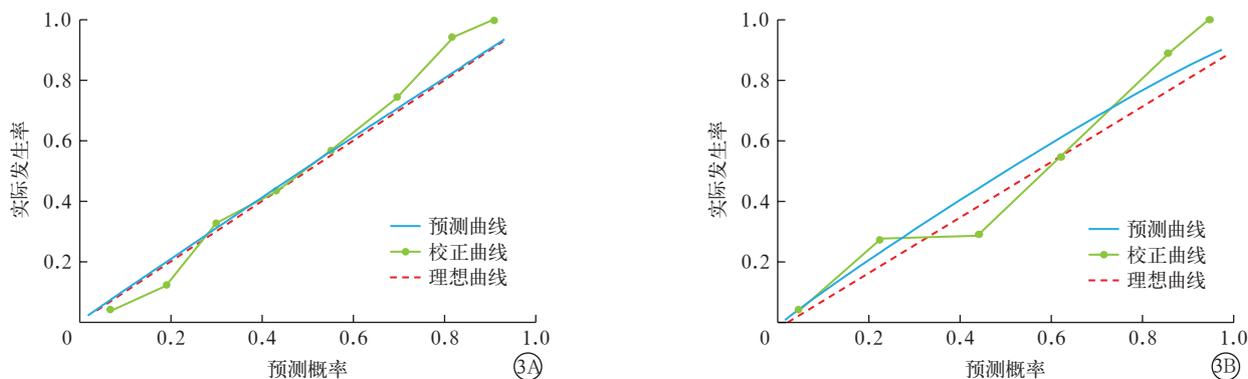
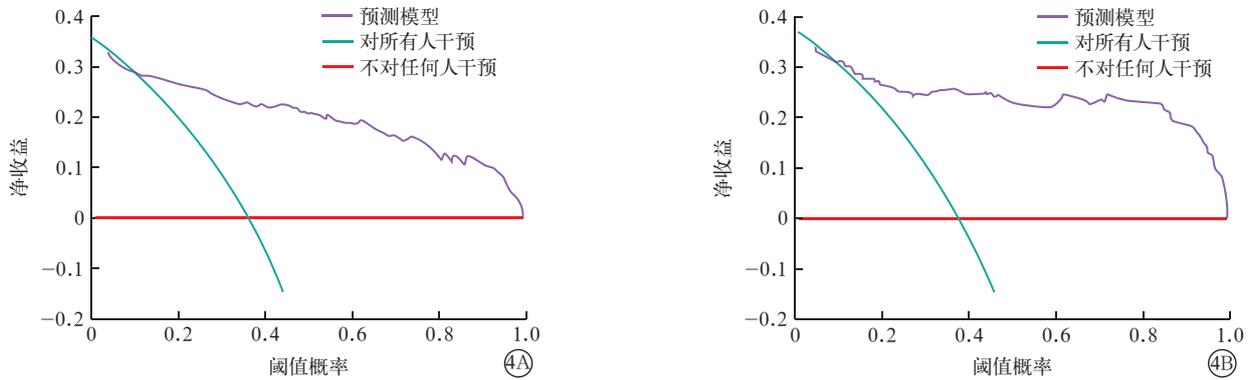
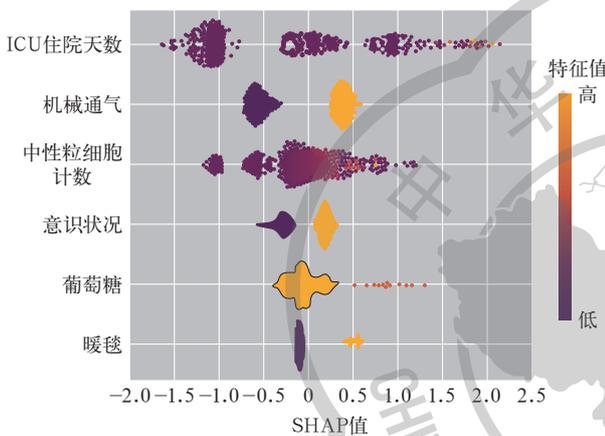


图3 在训练集(A)和验证集(B)中危重症患者压力性损伤预测模型的校准曲线



注：DCA 为决策曲线分析

图 4 在训练集(A)和验证集(B)中危重症患者压力性损伤预测模型的 DCA 曲线



注：SHAP 为沙普利加和解释，ICU 为重症监护病房

图 5 危重症患者压力性损伤特征重要性排序的 SHAP 图

3 讨论

3.1 危重症患者压力性损伤的预测具有重要临床意义：本研究采用 SHAP 法可解释 XG-Boost 模型预测危重症患者压力性损伤的发生，利用训练集和验证集来评估模型的性能。ROC 曲线、校准曲线等指标表明，该模型具有较高的预测性能。此外，本研究利用 SHAP 法对 XG-Boost 模型进行解释，结果显示，重要性特征由高至低依次是 ICU 住院天数、机械通气、中性粒细胞计数、意识状态、葡萄糖和使用暖毯。ICU 住院天数是反映病情严重程度和慢性暴露时间的综合指标。住院时间延长通常意味着患者疾病更严重、活动受限更明显，从而持续暴露于压力、剪切力等风险中，显著增加压力性损伤发生风险。机械通气患者因镇静、肌松药物使用而处于被动体位，自主活动能力丧失，局部组织长时间受压是压力性损伤的经典高危因素。中性粒细胞计数升高作为系统性炎症反应的标志，可能提示患者存在严重感染或应激状态。炎症反应可导致微循环障碍和组织灌注不足，降低皮肤耐受性，与压力共同作用可

加速组织损伤。意识障碍（如昏迷）患者无法感知不适及自主变换体位，对压力的自我保护能力完全丧失，发生压力性损伤的风险显著增加^[19, 24]。高血糖水平（葡萄糖）则会影响白细胞功能，造成血管内皮损伤，削弱组织修复能力，使皮肤更易受损且愈合延迟。此外，使用暖毯虽可维持体温，但可能增加局部出汗和潮湿，改变皮肤微环境，并可能掩盖局部受压后的皮肤反应，间接增加压力性损伤的风险。研究表明，对 ICU 患者风险因素的识别和预测模型的开发受到所纳入人群异质性的影响^[24-25]，这为后续研究指明了方向。综上，构建早期预测危重症患者压力性损伤发生的模型具有临床意义，危重症患者需要临床医务人员给予足够的关注。

3.2 机器学习模型预测能力良好：与传统统计模型相比，机器学习模型在处理复杂、非线性的临床数据方面展现出强大潜力。既往研究表明，机器学习模型在预测压力性损伤方面具有良好的性能^[14]。Alderden 等^[17]使用随机森林机器学习模型预测 ICU 患者压力性损伤，结果显示该模型表现出良好的性能。Song 等^[18]利用随机森林模型预测住院患者压力性损伤的发生情况，结果显示该模型在非医院获得性压力损伤组和医院获得性压力损伤组中均表现良好。Han 等^[26]基于国内 33 家医院 ICU 患者数据，采用 Logistic 回归分析筛选独立预测因素并构建了压力性损伤风险预测列线图模型，该模型在训练集和验证集中均表现出良好的区分度与校准度，临床实用价值较高。王园园等^[27]针对压力性损伤的机器学习模型进行了系统评价，表示现阶段压力性损伤风险预测机器学习模型的开发处于发展阶段，外推性有待进一步探讨。本研究选择 XG-Boost 算法，主要基于其在处理中小规模数据集时优异的预测性能、抗过拟合能力和计算效率，与随机森林

等集成算法相比, XG-Boost 通过梯度提升策略顺序构建弱学习器, 并优化损失函数, 通常能获得更高的预测精度。

与其他研究相比, 本研究的优势在于: 第一, 采用 Lasso 回归进行特征筛选, 在构建模型前有效降维, 既保留了核心预测变量, 又增强了模型的简洁性和临床可用性, 有助于防止过拟合。第二, 应用 SHAP 法对 XG-Boost 模型进行解释、分析, 不仅从全局角度量化了各特征的重要性, 还能在个体层面揭示每个变量对特定患者预测风险的贡献方向与程度, 为临床个体化风险评估提供了直观依据, 实现了准确预测与可解释性的统一。

本研究存在一定的局限性。首先, XG-Boost 模型采用的数据均来自同一中心, 是否具有外推性还有待进一步考证。其次, 为防止过拟合简化变量的过程可能造成准确性下降。最后, 本研究同样受到人力物力的限制, 样本量较小, 可能存在一定的偏倚风险。后期将增加样本量, 对模型进行优化。

综上, 本研究中构建的 XG-Boost 机器学习模型可用于预测危重症患者压力性损伤的发生。SHAP 法能够解释由机器学习模型生成的结果, 从而为临床应用提供了一个可解释的机器学习模型。利用机器学习模型对 ICU 危重症患者进行早期预测和干预, 可以防止压力性损伤的发生。

利益冲突 所有作者声明不存在利益冲突

作者贡献声明 吕文佳: 酝酿和设计实验、实施研究、起草文章; 朱明丽: 对文章的知识性内容作批评性审阅, 行政、技术或材料支持, 指导; 陆天敏、吴秀云、江海燕: 采集数据、分析/解释数据、统计分析; 林瑶: 实施研究, 采集数据, 统计分析, 获取研究经费, 行政、技术或材料支持, 指导, 论文修改

参考文献

- [1] Hajhosseini B, Longaker MT, Gurtner GC. Pressure injury[J]. *Ann Surg*, 2020, 271(4): 671–679. DOI: 10.1097/SLA.0000000000003567.
- [2] 林秀秀, 虞纯纯, 庄丹雯, 等. 重症俯卧位通气患者并发压力性损伤列线图模型的构建[J]. *浙江医学*, 2023, 45(20): 2167–2171. DOI: 10.12056/j.issn.1006-2785.2023.45.20.2023-1460.
- [3] 袁邻雁, 吴孟航, 刘晓艳, 等. 电刺激防治压力性损伤的机制研究及临床应用进展[J]. *国际老年医学杂志*, 2024, 45(2): 238–241. DOI: 10.3969/j.issn.1674-7593.2024.02.022.
- [4] Hu YH, Lee YL, Kang MF, et al. Constructing inpatient pressure injury prediction models using machine learning techniques[J]. *Comput Inform Nurs*, 2020, 38(8): 415–423. DOI: 10.1097/CIN.0000000000000604.
- [5] Do Q, Lipatov K, Ramar K, et al. Pressure injury prediction model using advanced analytics for at-risk hospitalized patients[J]. *J Patient Saf*, 2022, 18(7): e1083–e1089. DOI: 10.1097/PTS.0000000000001013.
- [6] CENTER-TBI High-Resolution ICU (HR ICU) Sub-Study Participants and Investigators. Development and external validation of a machine learning model for the early prediction of doses of harmful intracranial pressure in patients with severe traumatic brain injury[J]. *J Neurotrauma*, 2023, 40(5–6): 514–522. DOI:

- 10.1089/neu.2022.0251.
- [7] Yamao Y, Oami T, Yamabe J, et al. Machine-learning model for predicting oliguria in critically ill patients[J]. *Sci Rep*, 2024, 14(1): 1054. DOI: 10.1038/s41598-024-51476-y.
- [8] Wang H, Zhao QY, Luo JC, et al. Early prediction of noninvasive ventilation failure after extubation: development and validation of a machine-learning model[J]. *BMC Pulm Med*, 2022, 22(1): 304. DOI: 10.1186/s12890-022-02096-7.
- [9] 郭志强, 蓝健, 邓一砾, 等. 经皮氧分压 / 二氧化碳分压监测对重症监护患者压力性损伤发生的早期预警价值[J]. *中华急诊医学杂志*, 2024, 33(5): 698–703. DOI: 10.3760/cma.j.issn.1671-0282.2024.05.017.
- [10] 董擎, 孟小娟. 北京市三甲医院手术室护理人员压力性损伤知识影响因素的便利抽样调查[J]. *中国卫生统计*, 2022, 39(5): 772–775. DOI: 10.3969/j.issn.1002-3674.2022.05.031.
- [11] 李桂霞, 刘先锋, 郑静. 预防无创正压通气患者鼻面部压力性损伤的循证护理实践[J]. *中华危重病急救医学*, 2024, 36(7): 753–759. DOI: 10.3760/cma.j.cn121430-20240218-00135.
- [12] 邓瑞春, 蒋维连. 脊柱后路手术患者压力性损伤预防管理的研究进展[J]. *中国卫生标准管理*, 2024, 15(2): 195–197, 封 3. DOI: 10.3969/j.issn.1674-9316.2024.02.045.
- [13] Edsberg LE, Cox J, Koloms K, et al. Implementation of pressure injury prevention strategies in acute care: results from the 2018–2019 international pressure injury prevalence survey[J]. *J Wound Ostomy Continence Nurs*, 2022, 49(3): 211–219. DOI: 10.1097/WON.0000000000000878.
- [14] Pei JH, Guo XJ, Tao HX, et al. Machine learning-based prediction models for pressure injury: a systematic review and meta-analysis[J]. *Int Wound J*, 2023, 20(10): 4328–4339. DOI: 10.1111/iwj.14280.
- [15] Ayello EA, Sibbald RG. Marching forward with global pressure injury data[J]. *Adv Skin Wound Care*, 2023, 36(3): 119. DOI: 10.1097/01.ASW.0000918888.97533.37.
- [16] Alshahrani B, Sim J, Middleton R. Nursing interventions for pressure injury prevention among critically ill patients: a systematic review[J]. *J Clin Nurs*, 2021, 30(15–16): 2151–2168. DOI: 10.1111/jocn.15709.
- [17] Alderden J, Pepper GA, Wilson A, et al. Predicting pressure injury in critical care patients: a machine-learning model[J]. *Am J Crit Care*, 2018, 27(6): 461–468. DOI: 10.4037/ajcc.2018525.
- [18] Song WY, Kang MJ, Zhang L, et al. Predicting pressure injury using nursing assessment phenotypes and machine learning methods[J]. *J Am Med Inform Assoc*, 2021, 28(4): 759–765. DOI: 10.1093/jamia/ocaa336.
- [19] DecubICUs study Team, European Society of Intensive Care Medicine (ESICM) Trials Group Collaborators. Pressure injury prediction models for critically-ill patients should consider both the case-mix and local factors[J]. *Intensive Crit Care Nurs*, 2021, 65: 103033. DOI: 10.1016/j.iccn.2021.103033.
- [20] Teo CSM, Claire CA, Lopez V, et al. Pressure injury prevention and management practices among nurses: a realist case study[J]. *Int Wound J*, 2019, 16(1): 153–163. DOI: 10.1111/iwj.13006.
- [21] Cowan L, Broderick V, Alderden JG. Pressure injury prevention considerations for older adults[J]. *Crit Care Nurs Clin North Am*, 2020, 32(4): 601–609. DOI: 10.1016/j.cnc.2020.08.009.
- [22] Pott FS, Meier MJ, Stocco JGD, et al. Pressure injury prevention measures: overview of systematic reviews[J]. *Rev Esc Enferm USP*, 2023, 57: e20230039. DOI: 10.1590/1980-220X-REEUSP-2023-0039en.
- [23] Mansfield S, Obraczka K, Roy S. Pressure injury prevention: a survey[J]. *IEEE Rev Biomed Eng*, 2020, 13: 352–368. DOI: 10.1109/RBME.2019.2927200.
- [24] Becker D, Tozo TC, Batista SS, et al. Pressure ulcers in ICU patients: Incidence and clinical and epidemiological features: a multicenter study in southern Brazil[J]. *Intensive Crit Care Nurs*, 2017, 42: 55–61. DOI: 10.1016/j.iccn.2017.03.009.
- [25] Polk C, Sampson MM, Roshdy D, et al. Skin and soft tissue infections in patients with diabetes mellitus[J]. *Infect Dis Clin North Am*, 2021, 35(1): 183–197. DOI: 10.1016/j.idc.2020.10.007.
- [26] Han L, Wei YT, Pei JH, et al. Nomogram model on estimating the risk of pressure injuries for hospitalized patients in the intensive care unit[J]. *Intensive Crit Care Nurs*, 2024, 80: 103566. DOI: 10.1016/j.iccn.2023.103566.
- [27] 王园园, 蒋建萍, 朱志超, 等. 压力性损伤风险预测机器学习模型的系统评价[J]. *中国护理管理*, 2023, 23(3): 417–424. DOI: 10.3969/j.issn.1672-1756.2023.03.018.

(收稿日期: 2025-03-19)

(本文编辑: 保健媛 张耘菲)