

机器学习算法在 ICU 患者压力性损伤风险预警中的应用进展

冀慧敏¹, 柏亚妹¹, 宋玉磊¹, 张薛晴¹, 徐桂华¹, 王晓凤²

摘要: 综述机器学习算法在 ICU 压力性损伤风险预警中的应用, 预测模型包括逻辑回归模型、基于树的模型、决策树模型、贝叶斯算法、循环神经网络及集成模型, 旨在为制订个性化的预防策略提供科学方法, 以提升 ICU 护理水平。

关键词: ICU; 压力性损伤; 机器学习算法; 模式识别; 预测分析; 逻辑回归; 基于树的模型; 风险预警

中图分类号: R472 **DOI:** 10.3870/j.issn.1001-4152.2025.05.126

Application progress of machine learning algorithms in pressure injury risk prediction for ICU patients

Ji Huimin, Bai Yamei, Song Yulei, Zhang Xueqing, Xu Guihua, Wang

Xiaofeng. School of Nursing, Nanjing University of Chinese Medicine, Nanjing 210023, China

Abstract: This paper reviews the application of machine learning algorithms in pressure injury risk prediction for ICU patients. The prediction models include logistic regression model, tree-based model, decision tree model, Bayesian algorithm, recurrent neural network and integrated model. The aim is to provide a scientific method for the development of personalized prevention strategies and to improve the level of ICU care.

Keywords: ICU; pressure injury; machine learning algorithm; pattern recognition; forecasting analysis; logical regression; tree-based model; risk prediction

压力性损伤(Pressure Injury, PI)因治愈困难、病程迁延、复发率高,是临床护理工作的重点和难点^[1]。重症监护室(ICU)患者病情复杂、长期住院、使用多种医疗设备以及被动体位等因素,压力性损伤发生率4%~56%,其风险是普通病房患者的4.3倍^[2-4]。压力性损伤不仅会延长患者住院时间,增加患者痛苦甚至死亡,还因高昂的治疗费用给医疗资源和患者经济带来沉重负担^[5-6]。压力性损伤重在预防,风险预测是预防第一步,风险预测结果的准确与否将直接影响预防措施的选择和治疗效果^[7]。现阶段,压力性损伤风险预测仍以基于量表的评估为主,但其主观性较强,且难以全面考虑患者的个体差异和动态变化^[8-10]。随着医院信息化平台的发展与应用,数据复杂性日益凸显,使用人工智能技术进行数据收集和分析已成为发展趋势。2021年国务院明确提出要推进电子病历、智慧服务、智慧管理“三位一体”的智慧医院建设,将人工智能与医疗的融合上升到国家层面^[11]。机器学习作为人工智能领域的核心方法,为ICU压力性损伤风险预警提供了新的解决方案。因此,本文综述机器学习算法在ICU患者压力性损伤风险预警中的应用,旨在为ICU压力性损伤信息化管理提供参考。

1 机器学习算法的种类及逻辑

机器学习算法是一种利用大量临床数据建立预测模型的科学学科,它运用复杂的算法从数据中学习模式,并通过迭代训练不断优化模型的性能^[12]。模型构建主要由训练数据信息采集、预处理、特征向量提取、机器学习分类、性能评估模块组成^[13]。

1.1 种类

机器学习算法可以根据不同的分类标准进行分类,其中最常见的是根据训练样本、反馈方式以及模型结构进行分类。

1.1.1 根据训练样本及反馈方式分类 机器学习算法根据训练样本及反馈方式的不同,可以分为监督学习、无监督学习和强化学习。监督学习算法是通过训练数据集学习一个模式(函数),并依此模式推测新的实例。监督学习进一步划分为分类和回归。当预测目标值是离散时,使用分类算法。常见的算法包括决策树、随机森林、k-近邻算法、逻辑回归、支持向量机和人工神经网络等。当预测目标值是连续时,使用回归算法。典型算法有线性回归和AdaBoosting等。与监督学习相反,无监督学习是完全没有标签的,是根据模型不断地进行自我学习、巩固和总结归纳来学习。学习模型主要包含聚类和降维。聚类是指将物理或抽象对象的集合由相似对象组成多个类别的过程,可以理解为按照相近的原则进行分组,常见算法有k-means算法、BIRCH算法和DBSCAN算法等。降维就是去掉高维度数据中不重要的信息,同时保留大部分重要的信息,以简化复杂问题。算法有主成分分析(Principal Component Analysis, PCA)等。强化学习是一种通过与环境交互来学习最佳策略的方法,

作者单位:1. 南京中医药大学护理学院(江苏 南京, 210023); 2.

中国中医科学院望京医院

通信作者:王晓凤, 1117zjy@163.com

冀慧敏:女, 硕士在读, 学生, 20230977@njucm.edu.cn

科研项目:国家自然科学基金青年项目(72004102); 教育部人文社科青年基金项目(19YJCZH139)

收稿:2024-06-23; 修回:2024-12-10

通过不断尝试和修正错误来优化行为,以最大化累积奖励。常见的算法包括基于深度学习的强化学习算法等。

1.1.2 根据模型结构分类 机器学习算法根据模型结构可以分为单一模型和集成模型。单一模型包括线性模型、基于树的模型、贝叶斯算法、神经网络等。线性模型是机器学习领域中经典的算法类别,基于输入特征的线性组合进行预测,典型算法包括线性回归、逻辑回归和支持向量机等。基于树的模型包括决策树、随机森林、提升树以及极端随机树。这些模型能够处理复杂的非线性关系,并根据特征重要性进行风险因素选择,适用于医学数据分析和压力性损伤风险预测。贝叶斯算法是基于贝叶斯定理进行分类或预测。神经网络则是通过模拟人脑神经元的工作方式进行学习和预测。集成算法模型结合多个基础预测模型以提高预测精度和稳健性。这些基础模型可以是决策树、神经网络或其他类型的学习算法,通过融合不同模型的特点,减少过拟合的风险,提高预测的准确性和泛化能力。

1.2 基本逻辑 机器学习算法的基本原理是通过通过对数据进行学习和分析,自动发现数据中的模式和关系,并利用这些模式和关系来进行预测、分类、聚类等。机器学习算法通常包括训练和预测两个主要步骤。训练阶段是指算法使用已知数据(训练数据集)来学习模型或函数的参数,以使其能对未知数据做出准确的预测或分类。预测阶段是指算法将学习到的模型应用于新的数据,输出预测结果。

2 机器学习算法在评估 ICU 患者压力性损伤风险中的应用

压力性损伤风险预测模型是以多病因为基础,通过建立有效的模型计算患者发生压力性损伤概率。研究表明,模型预测准确性显著高于风险评估量表^[14]。机器学习算法在构建 ICU 压力性损伤风险预警模型方面发挥了关键的支撑作用^[15]。

2.1 逻辑回归模型 Ladios-Martin 等^[16]采用逻辑回归模型进行 ICU 压力性损伤风险预测的研究,相较于传统方法,该模型通过综合考虑多个基本维度(如活动/移动、年龄、护理过程、性别、一般健康状况、血液学指标、药物治疗、精神状态、营养、水分、出生地点、危险程度、皮肤状况和手术干预等)变量,提供了更高的敏感性和预测能力,这一点与 Xu 等^[17]的研究结果一致。逻辑回归模型的选用基于其适用于二分类问题的特性、能够量化各变量对压力性损伤的发生率的解释性以及通过合理构建和验证过程所能达到的准确性。这一模型覆盖了所有压力性损伤的风险因素,将此模型应用到日常医疗实践中,有助于医疗机构在不增加医护人员工作量的前提下,更有效地将预防措施集中于最需要的患者。目前模型还需要在

不同的医疗环境中进一步验证。

2.2 基于树的模型 邓小红等^[18]从 468 例 ICU 患者中获取 94 例(20.1%)压力性损伤患者的资料,通过决策树模型纳入 4 项危险因素,即年龄、大便失禁、Braden 评分和舒张压偏低。根据模型测算年龄 ≤ 81 岁、无大便失禁、Braden 评分 ≤ 13 分且舒张压偏低者,压力性损伤风险为 60.0%,年龄 ≤ 81 岁合并大便失禁者压力性损伤风险为 61.9%,年龄 > 81 岁压力性损伤发生风险为 94.4%,由此判断该模型中年龄在压力性损伤发展中起着重要作用。该模型的灵敏度、特异度、ROC 曲线下面积分别为 0.809、0.703、0.828,认为有良好的预测性能。但是该研究未提及内部验证结果,可能存在模型过度拟合的偏倚,导致模型预测性能结果偏高。此外,危险因素的收集基于 Delphi 法而非循证医学,因此无法直接确认这些因素与压力性损伤之间存在高度相关性。同时,该模型尚未经过临床应用验证,其临床预测性能尚待进一步确认。

2.3 决策树模型 决策树模型在 ICU 压力性损伤预测中存在过拟合的风险,可能导致模型泛化能力降低。随着决策树深度的增加,其解释性可能会降低,且训练时间和计算复杂度会相应增长,这也加大了模型调参的难度,相较之下,随机森林模型由于其集成学习的特点,能更好地应对数据的多样性,提升预测的稳定性和准确性,有效避免过拟合问题,因此在预测 ICU 患者压力性损伤的发生类型中表现优异。Hu 等^[19]收集 11 838 份住院患者的病历数据,比较了决策树、逻辑回归和随机森林 3 种模型的分类性能,并通过实证分析证明了随机森林在压力性损伤预测中的良好表现。Hu 等^[19]研究中纳入了 54 个临床变量,其中皮肤完整性、收缩压波动、言语能力、毛细血管再充盈时长和意识状态等因素在模型中发挥了重要作用,成为预测压力性损伤的关键指标。该研究表明,随机森林模型不仅具有较高的分类准确性,还可以作为高危压力性损伤人群筛选的有效工具,为临床医生提供早期干预的依据,帮助识别高风险患者并采取相应的预防措施,从而降低压力性损伤发生率。Alderden 等^[20]采用随机森林模型对 ICU 患者压力性损伤的发生进行预测,研究结果发现身体质量指数(BMI)、血红蛋白水平、肌酐水平、手术时间以及年龄等因素对 ICU 患者压力性损伤的发生具有显著影响,其中手术时间被确定为最为关键的影响因素。该研究提醒医护人员应减少不必要的手术时间,增强营养支持,以降低压力性损伤发生率,改善患者预后,提升整体医疗质量和患者满意度。

2.4 贝叶斯算法 贝叶斯算法融合先验临床知识与实时临床指标,通过更新后验概率,提供损伤风险的评估。Cho 等^[21]探讨了在特定 ICU 压力性损伤数据集(即用于 ICU 患者群体的电子病历数据集)上应用

朴素贝叶斯网络构建预测模型,整合到模型中的变量包括性别、入院方式、诊断、尿液和粪便收集、造口状态、导尿以及体位变换等,其中ICU住院时间、饮食、意识水平、体温、自我运动能力和血红蛋白等变量具有高敏感性。该模型特别适用于ICU这种数据稀疏且快速变化的环境,因其能够处理不确定性和不完整数据,所以在有限样本情况下也能提供合理预测。

2.5 循环神经网络 随着图像数据存储技术的发展,研究角度转向算法优化,以加快预测测量的速度并提升精确度。如Kim等^[22]开发了基于循环神经网络的ICU压力性损伤预测系统,变量涵盖了患者人口统计信息(性别、年龄、体质量、身高、BMI)、生命体征、实验室检验结果、药物和治疗信息、潜在疾病(糖尿病、心血管疾病、高血压、动脉疾病、皮肤疾病)、Braden评分和镇静-躁动评分(Sedation-Agitation Scale,SAS)等。该模型能够有效捕获数据中的时序依赖关系,弥补数据缺失的问题,更好地提高ICU患者护理质量。

2.6 集成模型 电子健康记录(Electronic Health Records,EHR)的观察数据在描绘ICU压力性损伤特征方面存在局限。尤其是在动态监测数据和一些关键变量(如皮肤状态、体位变化频率等)的记录上存在不足。这些数据缺口导致了对患者个体风险评估的准确性和及时性的潜在影响,从而限制了基于EHR的压力性损伤预测工具在临床决策中的应用。传统的风险评估方法,尤其是依赖护士根据Braden评分量表进行评估,虽然在临床中广泛应用,但其较为主观的评分标准和静态的变量选择限制了其在ICU环境下的准确性和可操作性。Cramer等^[23]通过回顾性分析ICU住院患者的电子信息系统数据,纳入年龄、性别、并存疾病(特别是糖尿病、血液系统恶性肿瘤和外周动脉疾病)、低血压、肾脏替代治疗和入院第1个24h内的机械通气等变量,利用支持向量机、随机森林、梯度提升、弹性网络算法构建了自动预测ICU患者24h内压力性损伤风险模型。研究发现,该模型在多变量综合分析中表现出显著优于Braden量表的预测性能,尤其在动态预测和早期干预方面具有明显优势。相较于Braden量表仅依据静态指标,机器学习模型能够实时动态地整合患者的健康信息,从而提高预测的准确性和临床适用性,成为ICU患者早期风险分层和预防性干预的有力工具。Kaewprag等^[24]应用6种机器学习算法(逻辑回归、支持向量机、随机森林、朴素贝叶斯、k-近邻算法、决策树)构建了ICU患者压力性损伤风险预测模型。其中通过对比各个算法的预测准确率、灵敏度、特异度等指标,逻辑回归、支持向量机、随机森林和朴素贝叶斯算法提供了较高的预测准确度。在模型的构建中,该团队还从患者的EHR中提取了药物和诊断特征与模型作为预测指标,模型的预测性能提高了

10%。研究结果表明,麻痹综合征、败血症、骨髓炎/骨膜炎/骨感染、细菌性肺炎等是压力性损伤发生率最高的共病组合。其中大多数与患者感染、长时间不更换体位和患者感知障碍有关。同时,焦彦霞^[25]在构建ICU压力性损伤预测模型时,运用支持向量机、决策树、随机森林、朴素贝叶斯和k-近邻模型,模型解释性增强,实现了运行过程的可视化,并证明了年龄、胆红素和糖尿病史的高敏感性,这为未来基于大数据的研究以及个性化风险管理提供参考。综合运用多种机器学习算法来分析ICU患者的EHR数据,可以有效提升压力性损伤预测的准确性和灵活性,超越传统风险评分工具的局限。这些智能预测模型不仅能够实现动态、实时的风险评估,还能为临床护理人员提供个性化的干预建议,有助于优化患者管理和预防护理策略,降低压力性损伤发生率。

3 机器学习算法应用效果分析与比较

在ICU压力性损伤预测中,各种机器学习算法对数据的要求和特点各不相同。逻辑回归适合处理线性关系的数据,模型简单且易于解释,但对于非线性关系的处理能力较弱。支持向量机能够处理复杂的非线性数据,适用于高维空间中的分类问题,尤其在数据量较小且特征间边界清晰时表现优异,但对大数据集的计算要求较高。随机森林通过集成多棵决策树,能有效减少过拟合并处理缺失数据,适合多样化特征的数据集,而其对于大数据集的适应性较强。梯度提升决策树则能够通过逐步纠正前一轮的误差捕捉复杂的非线性关系,特别适用于处理具有复杂交互作用的临床特征,但对超参数的调优要求较高且训练过程较为耗时。k-近邻算法依赖于数据间的相似度,适合于数据量较小且特征较简单的场景,但对特征尺度敏感,需要标准化处理。决策树直观且易于解释,但容易在处理复杂数据时出现过拟合。

近年来,随着机器学习技术的不断进步,研究者开始探索将多种机器学习算法进行融合和集成,以构建更加全面和准确的压力性损伤风险预警模型。集成算法的优势在于能够结合不同算法的长处,提高预测精度和模型稳定性。它利用各算法在处理数据、识别特征方面的特长,更全面地分析ICU患者的风险因素,减少因单一算法缺陷导致的预测偏差。此外,集成算法通过融合多个模型的预测结果,有助于降低过拟合风险,增强模型在不同数据集和场景下的适用性。然而,集成算法的实现过程相对复杂,需要更多的计算资源和时间成本。如何选择合适的单一算法进行集成、如何优化集成策略,以实现最佳预测性能,是研究者需要解决的问题。因此,在实际应用中,研究者应根据具体需求和场景,综合考虑算法性能、资源投入等因素,权衡利弊,选择合适的算法策略进行模型构建。这将有助于更准确地预测ICU患者的压

力性损伤风险,为临床决策提供有力支持。

4 小结与展望

在ICU患者压力性损伤预测方面,机器学习算法展现出较高的有效性和准确性,使预防更科学、客观。当然机器学习算法也有其局限性,如风险变量覆盖不全、模型泛化能力有限等。因此,未来的研究热点和方向应聚焦于以下几个方面:一是深化临床数据的收集与整合,确保数据的全面性、准确性和时效性,为后续的数据分析与模型构建奠定坚实基础;二是构建和优化机器学习模型,开发具有更高解释性的机器学习算法,通过算法迭代与参数调优,提升模型的预测精度与泛化能力,以便提供更清晰的预测逻辑和决策依据,帮助医护人员更好地理解模型预测结果,从而增强其对预测结果的信任度,提高临床应用效果;三是开展多中心前瞻性临床试验,以科学严谨的方法评估机器学习模型在压力性损伤管理中的实际应用效果,验证其适用性、有效性和推广潜力。同时,这也将促进医疗信息技术的进一步发展,为医疗领域的数字化转型提供有力支持。

参考文献:

[1] Dealey C, Posnett J, Walker A. The cost of pressure ulcers in the United Kingdom[J]. J Wound Care, 2012, 21(6): 261-266.

[2] Lahmann N A, Kottner J, Dassen T, et al. Higher pressure ulcer risk on intensive care?: comparison between general wards and intensive care units[J]. J Clin Nurs, 2012, 21(3-4): 354-361.

[3] Keller B P, Wille J, van Ramshorst B, et al. Pressure ulcers in intensive care patients: a review of risks and prevention[J]. Intensive Care Med, 2002, 28(10): 1379-1388.

[4] Terekeci H, Kucukardali Y, Top C, et al. Risk assessment study of the pressure ulcers in intensive care unit patients[J]. Eur J Intern Med, 2009, 20(4): 394-397.

[5] Rondinelli J, Zuniga S, Kipnis P, et al. Hospital-acquired pressure injury: risk-adjusted comparisons in an integrated healthcare delivery system [J]. Nurs Res, 2018, 67(1): 16-25.

[6] Margolis D J, Knauss J, Bilker W, et al. Medical conditions as risk factors for pressure ulcers in an outpatient setting[J]. Age Ageing, 2003, 32(3): 259-264.

[7] 宋思平, 刘晓晴, 蒋琪霞. 压力性损伤风险预测模型的研究进展[J]. 中华护理杂志, 2020, 55(4): 628-631.

[8] Huang C, Ma Y, Wang C, et al. Predictive validity of the braden scale for pressure injury risk assessment in adults: a systematic review and meta-analysis[J]. Nurs Open, 2021, 8(5): 2194-2207.

[9] Lospitao-Gómez S, Sebastián-Viana T, González-Ruiz J M, et al. Validity of the current risk assessment scale for pressure ulcers in intensive care (EVARUCI) and the Norton-MI scale in critically ill patients[J]. Appl Nurs

Res, 2017, 38: 76-82.

[10] Han L, Guo J, Zhang H, et al. Validity and reliability of the Waterlow Scale for assessing pressure injury risk in critical adult patients: a multi-centre cohort study[J]. J Clin Nurs, 2024, 33(5): 1875-1883.

[11] 杨扬, 陈德凤, 李蓓, 等. 人工智能用于慢性伤口护理的研究进展[J]. 护理学杂志, 2024, 39(5): 18-21.

[12] Deo R C. Machine learning in medicine[J]. Circulation, 2015, 132(20): 1920-1930.

[13] 黄子菁, 郭晓凤, 何梅, 等. 机器学习在跌倒风险评估中的应用进展[J]. 护理学杂志, 2022, 37(21): 110-113.

[14] Deng X, Yu T, Hu A. Predicting the risk for hospital-acquired pressure ulcers in critical care patients[J]. Crit Care Nurse, 2017, 37(4): e1-e11.

[15] Greco M, Caruso P F, Cecconi M. Artificial intelligence in the intensive care unit[J]. Semin Respir Crit Care Med, 2021, 42(1): 2-9.

[16] Ladios-Martin M, Fernández-de-Maya J, Ballesta-López F J, et al. Predictive modeling of pressure injury risk in patients admitted to an intensive care unit[J]. Am J Crit Care, 2020, 29(4): e70-e80.

[17] Xu J, Chen D, Deng X, et al. Development and validation of a machine learning algorithm-based risk prediction model of pressure injury in the intensive care unit [J]. Int Wound J, 2022, 19(7): 1637-1649.

[18] 邓小红, 胡爱玲. 广东省 2014 年护理学术年会资料汇编 [C]. 广州: 广东省护理学会, 2014.

[19] Hu Y H, Lee Y L, Kang M F, et al. Constructing inpatient pressure injury prediction models using machine learning techniques[J]. Comput Inform Nurs, 2020, 38(8): 415-423.

[20] Alderden J, Pepper G A, 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.

[21] Cho I S, Chung E. Predictive Bayesian network model using electronic patient records for prevention of hospital-acquired pressure ulcers[J]. J Korean Acad Nurs, 2011, 41(3): 423-31.

[22] Kim M, Kim T H, Kim D, et al. In-advance prediction of pressure ulcers via deep-learning-based robust missing value imputation on real-time intensive care variables [J]. J Clin Med, 2023, 13(1): 36.

[23] Cramer E M, Seneviratne M G, Sharifi H, et al. Predicting the incidence of pressure ulcers in the intensive care unit using machine learning[J]. EGEMS (Wash DC), 2019, 7(1): 49.

[24] Kaewprag P, Newton C, Vermillion B, et al. Predictive modeling for pressure ulcers from intensive care unit electronic health records[J]. AMIA Jt Summits Transl Sci Proc, 2015(2015): 82-86.

[25] 焦彦霞. ICU 患者压力性损伤风险预测模型构建及验证研究[D]. 兰州: 兰州大学, 2023.