·综述·人工智能应用于烧伤与创面诊疗的初探·

机器学习在预测烧伤患者并发症和死亡中的应用研究进展

刘宇星[1]　赵晨[1]　屠馨怡[1]　蒋佳奖[1]　李茜[1]　陈华清[2]　卢福长[2]　王丽竹[1]

[1]浙江大学医学院附属第二医院护理部，杭州 310009；[2]浙江大学医学院附属第二医院烧伤与创面修复科，杭州 310009

通信作者：王丽竹，Email：zrwlz@zju.edu.cn

【摘要】 随着机器学习技术的迅速发展，其在预测烧伤患者并发症和死亡等不良结局中的应用探索已陆续开展，但有关该技术在实际临床工作中的有效应用及指导实践的报道仍较为匮乏。鉴于此，该文主要围绕机器学习概述及其在烧伤患者并发症和预后结局预测中的应用展开论述，并在此基础上进行总结与展望，以期为医护人员早期识别烧伤高危患者并制订针对性干预措施提供参考。

【关键词】 烧伤；　机器学习；　死亡率；　预测模型；　并发症

Research progress on the application of machine learning in predicting complications and mortality in burn patients

Liu Yuxing[1], Zhao Chen[1], Tu Xinyi[1], Jiang Jiajiang[1], Li Qian[1], Chen Huaqing[2], Lu Fuchang[2], Wang Lizhu[1]

[1]Nursing Department, the Second Affiliated Hospital of Zhejiang University School of Medicine, Hangzhou 310009, China; [2]Department of Burns and Wound Repair, the Second Affiliated Hospital of Zhejiang University School of Medicine, Hangzhou 310009, China

Corresponding author: Wang Lizhu, Email: zrwlz@zju.edu.cn

【Abstract】 With the rapid development of machine learning technology, its application in predicting adverse outcomes such as complications and mortality in burn patients has been increasingly explored. However, reports on its effective application in actual clinical work and its role in guiding practice remain relatively scarce. In view of this, this paper mainly discusses the overview of machine learning and its application in predicting complications and prognostic outcomes in burn patients, and on this basis provides a summary and outlook, aiming to provide a reference for medical staff in early identification of high-risk burn patients and formulation of targeted intervention measures.

【Key words】 Burns; Machine learning; Mortality; Predictive models; Complications

烧伤是指由高温（热力）、辐射、电流、摩擦或化学物质等因素引起的皮肤及深部组织损伤[1]。研究显示，烧伤已成为全球人群发病和死亡的主要原因之一[2]。因此，如何早期有效地识别和评估烧伤患者的不良结局，已成为亟待解决的问题。2024 年 11 月，《国家卫生健康委员会办公厅关于印发卫生健康行业人工智能应用场景参考指引的通知》明确指出，可利用机器学习对临床数据进行清洗、处理及建库，整合多组学基因测序等多模态数据，从而对患者进行精准化、个性化风险评估[3]。目前，国内外学者已将机器学习广泛应用于烧伤患者管理中，以评估不良结局发生风险及相关因素，实现早识别、早预防、早干预，进而提高患者生存率并改善预后。鉴于此，本文主要对机器学习进行概述，并综述其在烧伤患者并发症及预后预测中的应用，在此基础上进行总结与展望，以期为临床医护人员制订烧伤患者个性化干预措施提供参考。

1　机器学习的概述

机器学习是人工智能的一个重要分支，可利用统计学分析和计算机系统从海量数据中提取有价值的规律，并根据学习结果对新数据进行预测、分类或决策[4]。机器学习根据训练数据有无标注及学习任务的目标与反馈形式，可分为监督学习、无监督学习、半监督学习和强化学习 4 种类型[5]。监督学习是解决分类和回归任务的一种方法，其依靠明确的输入

DOI：10.3760/cma.j.cn501225-20260527-00214

收稿日期　2026-05-27

引用本文：刘宇星，赵晨，屠馨怡，等. 机器学习在预测烧伤患者并发症和死亡中的应用研究进展[J]. 中华烧伤与创面修复杂志，2026，42(11)：1095-1100. DOI：10.3760/cma.j.cn501225-20260527-00214.

Liu YX, Zhao C, Tu XY, et al. Research progress on the application of machine learning in predicting complications and mortality in burn patients[J]. Chin J Burns Wounds, 2026, 42(11): 1095-1100. DOI: 10.3760/cma.j.cn501225-20260527-00214.

及对应的输出建立模型，用于对患者生存率、治疗效果等进行预测，主要算法包括支持向量机、决策树、逻辑回归、K 近邻算法、随机森林等[6]。无监督学习用于解决聚类和降维问题，即在无标签情况下，利用数据本身的特征进行学习和分析，主要算法包括 K 均值聚类、主成分分析等[7]。半监督学习结合了监督学习与无监督学习，利用少量带标签的数据引导模型学习，并利用大量无标签的数据优化模型性能，主要算法包括自训练、协同训练、半监督支持向量机等[8]。强化学习指通过与环境的持续交互，自主学习最优策略以实现最大收益，主要算法包括 Q-learning、Deep Q-Network 等[9]。烧伤患者不良结局的预测属于监督学习，即以是否发生不良结局或结局严重程度作为标签，以入院资料、实验室检测指标和治疗信息等变量构建分类或回归模型。

此外，相较于规则式的专家系统，机器学习通过数据驱动自动学习，无需依赖领域专家的经验及规则，具有更强的适应性[10]；相较于深度学习，机器学习在小型数据集中的稳定性更优、可解释性更强[11]。

2 机器学习在烧伤患者并发症预测中的应用

2.1 预测谵妄

烧伤患者发生谵妄的概率为 13%~80%[12]，可导致患者住院时间延长、认知能力降低及病死率增加[13]。美国重症医学学会认为，氟哌啶醇、右美托咪定或利培酮等药物既不能缩短谵妄病程和住院时间，也不能降低谵妄发生率[14]。而由护士主导的 ABCDEF 集束化干预可通过非药物管理策略改善谵妄的不良预后[15]。然而，烧伤科护士对谵妄评估的知识、态度和信念较为欠缺[16]，识别烧伤患者发生谵妄的准确率仅为 49.15%[17]，这是早期预防谵妄的主要障碍。为实现精准预测，Ren 等[18]以烧伤总面积、入住烧伤 ICU 时间、急性生理学与慢性健康状况评价Ⅱ评分、性别、糖尿病史、血红蛋白及身体约束 7 个关键指标为预测变量，采用 9 种算法构建了大面积烧伤患者术后谵妄预测模型。经性能比较，其中的随机森林模型表现最佳，其网页计算器形式的外部验证准确率为 77.12%。随后，Esumi 等[19]采用逻辑回归、支持向量机及神经网络等方法建立了烧伤 ICU 患者谵妄预测模型，经比较，其中的逻辑回归模型性能最佳，其内部验证的受试者操作特征曲线下面积（area under the curve，AUC）达 0.906；同时，结果显示入住 ICU 24 h 内尿量、血氧饱和度、烧伤总面积、总胆红素水平、气管插管、白细胞分类、高铁血红蛋白浓度及呼吸频率等变量与谵妄发生风险相关。

上述研究表明，机器学习可整合疾病特征、实验室检测指标及治疗措施等信息，识别导致谵妄的风险因素，有助于医护人员早期识别高危患者。但未来研究仍需扩大样本量，并通过外部验证和前瞻性研究明确模型嵌入临床流程后的实际获益。

2.2 预测感染相关并发症

2.2.1 预测多重耐药菌感染及血流感染与中心静脉导管相关感染 感染相关并发症是烧伤患者常见且临床意义重要的不良事件之一，主要包括多重耐药菌感染、血流感染及中心静脉导管相关感染等。这类并发症会增加脓毒症发生风险，且可导致患者住院时间延长、死亡风险增加。

在预测多重耐药菌感染方面，李东晖[20]基于重症烧伤患者临床数据构建了多重耐药菌感染风险预测模型，结果表明，烧伤深度、抗菌药物使用时间≥7 d、留置导尿管、深静脉置管、入住 ICU 前使用抗菌药物及住院时间，是重症烧伤患者发生多重耐药菌感染的预测因子。在预测血流感染方面，Tsurumi 等[21]针对儿童烧伤人群构建了血流感染预测工具，结果显示机器学习模型能有效识别感染高风险人群，在早期预警方面表现出较好的临床应用价值。此外，Walker 等[22]进一步开发并验证了一种用于急性烧伤患者血流感染早期识别的筛查工具，通过临床特征对感染风险进行动态评估，从而为早期干预提供了可能。在预测中心静脉导管相关感染方面，Wang 等[23]结合临床流行病学特征预测烧伤患者发生中心静脉导管相关感染的风险，结果显示，住院时间、中心静脉导管留置时间及烧伤创口指数是烧伤患者发生中心静脉导管相关感染的独立预测因子。

2.2.2 预测脓毒症 烧伤患者由于皮肤屏障受损及高代谢状态，易发生脓毒症[24]。脓毒症最早可出现在烧伤后第 1 周，并在第 2 周达到高峰，是导致烧伤患者死亡的主要原因[25]。由于烧伤脓毒症的病理生理特点较为独特，一般脓毒症诊断标准对其缺乏特异性[26]。此外，《拯救烧伤脓毒症运动指南（2023 版）》中提出的脓毒症相关诊断定义的证据质量较低[27]。因此，烧伤脓毒症的早期诊断在临床上仍面临一定的挑战。目前，临床上已采取液体复苏、创面处理、肠内营养和抗感染等综合防治策略[28]，但临床治疗与护理的有效实施均依赖于烧伤脓毒症的早期诊断。为了解决烧伤脓毒症诊断特异性不足的问题，实现早期识别、早期预警和早期干预，Tran 等[29]开发了自动化机器学习平台。该平台通过自动化流程筛选出 K 近邻算法模型作为烧伤脓毒症的最佳预测模型，纳入心率、体温、血红蛋白、尿素氮及 CO_2 总量作为预测因子，其内部验证的受试者操作特征 AUC 为 0.96，准确率为 90%。该模型具有较高的自动化程度和建模效率，未来可通过多中心研究进一步改进性能，并评估其临床适用性和推广价值。Luo 等[30]使用逻辑回归建立了烧伤脓毒症的风险预测模型，并以列线图形式呈现。该模型纳入烧伤总面积、血红蛋白、糖尿病及钾作为预测因子，内部验证的受试者操作特征 AUC 为 0.861，预测性能良好。血容量不足、炎症反应失调和代谢亢进是脓毒症发展的主要危险因素；若诊断和治疗不及时，脓毒症可能进展为脓毒性休克[24]。因此，邱侃等[31]利用 4 种机器学习模型构建了特重度烧伤患者脓毒性休克的预测模型，烧伤总面积、ALT、血清肌酐、血钠、降钙素原、热损伤类型、血容量不足及血液标本微生物培养阳性为其预测因素。其中，随机森林模型的预测区分度最佳，优于序贯器官衰竭评分预测模型，随机森林模型内部验证的受试者操作特征 AUC 为 0.92，可用于早期识别脓毒性休克，辅助临床医护人员进行风险分层决策。

由此可见，基于机器学习构建风险预测模型能实现脓毒症的精准识别。但烧伤患者常伴有高代谢、强烈应激反应和创面反复感染等情况，可能会使传统感染指标出现滞后或受到干扰。因此，后续建模应充分纳入更多特异性因素，以提高模型的稳定性和临床适用性。

2.3 预测急性肾损伤

烧伤患者发生急性肾损伤（acute kidney injury，AKI）的概率为9%~50%，严重者病死率可超过80%[32]。AKI是慢性肾脏病发生和发展的关键因素，对患者长期预后产生不利影响[33]。改善全球肾脏病预后组织指南以血清肌酐和尿量作为AKI的主要诊断依据[34]。然而，烧伤患者早期因体液丢失而输注大量液体，可导致血清肌酐被稀释及尿量增加[35]；晚期因脓毒症致机体细胞释放炎症介质，引发一系列代谢反应，从而使血清肌酐升高滞后[36]。因此，需要寻找敏感且特异的AKI生物标志物。随着机器学习的广泛应用，Rashidi等[37]采用逻辑回归、支持向量机、随机森林、K近邻算法及深度神经网络等多种算法，通过新型生物标志物中性粒细胞明胶酶相关脂质运载蛋白联合N末端B型钠尿肽前体、尿量和血清肌酐预测烧伤患者早期发生AKI的风险。结果表明，机器学习模型预测AKI风险的时间较改善全球肾脏病预后组织标准提前（61.8±32.5）h，较单独使用血清肌酐或尿量等传统指标具有更早识别AKI的潜力。在预测准确性方面，Tran等[38]利用K近邻算法模型构建的包含中性粒细胞明胶酶相关脂质运载蛋白、尿量、血清肌酐和N末端B型钠尿肽前体的预测模型，其识别AKI的准确率达到90%~100%。

上述研究表明，机器学习可联合新型生物标志物与传统肾功能指标，以实现早期识别AKI发生风险的目的。鉴于烧伤早期液体复苏会稀释血清肌酐及增加尿量，未来在构建模型时应重视时间序列数据及动态指标的变化。

2.4 预测吸入性损伤

烧伤患者吸入性损伤的发生率为5.17%~24.75%，此类患者发生肺炎的风险是无吸入性损伤者的2~4倍，并可延长住院时间[39-40]。临床上通常依据口鼻烧伤、鼻毛烧焦、气道烟尘及声音嘶哑等临床表现诊断吸入性损伤，必要时结合纤维支气管镜检查明确[41]。Yang等[42]基于梯度增强算法开发了2个预测模型，分别用于区分吸入性损伤的严重程度和判断其是否存在。结果表明，模型1的受试者操作特征AUC为0.883，预测性能较好；该模型显示，主观吸入暴露史、上呼吸道烟尘、密闭空间内烧伤、碳氧血红蛋白水平升高及鼻毛烧焦是区分吸入性损伤严重程度的前5位风险因素。模型2的受试者操作特征AUC为0.862，预测性能可接受；该模型显示，鼻毛烧焦、上呼吸道烟尘、烧伤深度、收缩压升高及碳氧血红蛋白水平升高是判断吸入性损伤是否存在的前5位风险因素。

由此可见，机器学习可在支气管镜不能及时开展或临床判断存在不确定性时，为吸入性损伤的早期筛查和风险分层提供辅助。但此类模型作为支气管镜检查前的风险分层工具，不能替代支气管镜等标准诊断手段，后续应结合血气分析和影像资料提高模型的稳定性。

2.5 预测凝血功能障碍

烧伤引起凝血功能障碍的发病机制尚未完全明确。烧伤后出现的炎症反应、低体温及内皮损伤等可导致机体凝血功能紊乱及纤维蛋白溶解系统异常，进而引发静脉血栓栓塞和弥散性血管内凝血等严重并发症[43-44]。因此，早期识别并管理烧伤相关凝血功能障碍具有重要意义。Çınar[45]基于1 040例烧伤患者及35个生物化学参数，利用25种机器学习算法构建了急性烧伤所致凝血功能障碍的风险预测模型。结果显示，其中的Subspace KNN模型的预测准确率较高，优于其他机器学习模型。但该研究未对临床特征进行充分分析，难以明确具体的预测因子。未来可通过Shapley加性解释等可解释性学习方法提高模型的可解释性。

2.6 预测胃肠功能障碍

严重烧伤可导致全身炎症反应和神经内分泌异常，加剧宿主免疫功能低下，并增加创面感染风险[46]。肠内营养是严重烧伤患者营养支持的主要方式[47]，但胃肠功能障碍会降低肠内营养耐受性，影响营养支持的实施效果。He等[48]研究显示，45.4%的烧伤患者会发生胃肠功能障碍，且其与90 d死亡风险增加相关。Liu等[49]通过多中心研究构建了严重烧伤患者早期胃肠功能障碍的风险预测模型，结果显示，烧伤患者胃肠功能障碍的发生率为35.61%，序贯器官衰竭评分、烧伤总面积、吸入性损伤、血液标本微生物培养结果及血尿是模型中的预测因素；其中的XGBoost算法性能最佳，其训练集、内部验证集和外部验证集的受试者操作特征AUC分别为0.910、0.851和0.908。该研究采用多中心数据并进行外部验证，较单中心回顾性研究更具推广价值，但仍需在不同地区和烧伤救治体系中进一步验证模型稳定性。

3 机器学习在烧伤患者预后结局预测中的应用

3.1 预测住院时间

住院时间不仅可反映疾病严重程度和不良事件负担，也是评价医疗资源消耗和住院费用的重要指标[50-51]。传统的临床经验认为，烧伤患者每1%TBSA的治疗约需1 d住院时间[52]。但相关研究还表明，该经验法则仅适用于年龄<40岁且不存在吸入性损伤的患者，烧伤总面积、合并症及并发症等其他因素均会影响住院时间[53]。Elrod等[54]基于国际数据库比较随机森林、线性回归和经验法则3种模型的预测性能，结果显示，烧伤总面积、烧伤深度及吸入性损伤是住院时间的预测因素，3种预测模型的预测误差随烧伤总面积的增加而增大，且随机森林和线性回归的预测性能优于经验法则。Yeh等[55]使用3种机器学习模型预测烧伤患者的不良结局，结果显示，其中随机森林模型预测长期住院（>14 d）的受试者操作特征AUC为0.811，性能最佳。与死亡风险预测相比，住院时间预测更贴近床位周转、人力分配和医用耗材等医疗资源配置，可作为烧伤患者精准管理的重要拓展方向。

3.2 预测死亡

机器学习可作为预测烧伤患者死亡风险的辅助工具[56]。

Stylianou 等[57]将机器学习与传统逻辑回归模型的预测效果进行比较，结果显示，机器学习性能略优于传统逻辑回归模型，但差异较小且临床意义有限，其在预测烧伤患者死亡风险方面的效果有待后续进一步探究。随后，Cobb 等[58]使用随机森林和随机梯度提升模型对 3 万余例烧伤患者的生存预测因素进行分析，结果显示，年龄、肾功能衰竭、电解质紊乱、凝血功能障碍等患者因素，以及医护资源配置、先进成像可及性、ICU 床位数量等医院因素均与烧伤患者生存结局相关，提示烧伤患者死亡风险不仅受个体病情影响，还与医院资源配置和救治条件有关。Park 等[59]采用包括随机森林、自适应提升、决策树、支持向量机和逻辑回归在内的多种算法，开发了重度烧伤患者术后 90 d 死亡的风险预测模型，结果显示，重度烧伤患者术后 90 d 病死率为 27.1%，其中的随机森林模型性能最佳，其受试者操作特征 AUC 为 0.922，纳入模型的预测因子包括烧伤总面积、红细胞分布宽度及年龄。Çinar 等[60]使用人工神经网络构建模型预测烧伤患者的死亡风险，其预测准确率为 95.92%，在一定程度上弥补了 Baux 评分的不足。

4 总结与展望

机器学习已在精准预测烧伤患者并发症和死亡等不良结局中开展探索性应用，且研究重点聚焦于早期的风险识别。同时，机器学习模型构建所使用的数据类型也由单一临床指标发展为融合人口学特征、烧伤特征及实验室检测指标等多维信息。然而，尽管随机森林、XGBoost、支持向量机等多数模型具有较高的预测效果，但模型的性能不仅取决于算法本身，且与数据质量、变量选择及样本代表性等密切相关。此外，目前研究多数采用单中心、单时间点的数据，能否在不同的医疗背景和疾病特征下适用和推广以及是否能反映病情的动态变化，仍需进一步研究。

因此，后续研究可探索覆盖烧伤全病程的动态预测模式，将生命体征、实验室检查及治疗措施等实时数据持续纳入模型，实现风险的动态更新。另外，可以融合代谢组学、基因组学、蛋白质组学及转录组学等多组学数据构建兼具临床特征和分子特征的多模态预测模型。同时，在推动模型临床应用的过程中，还需完善数据标准化和隐私保护机制，从患者信息的创建、存储、使用和销毁等方面，实现数据全生命周期的安全保护；加强烧伤医学与人工智能等多学科协作，提高机器学习临床决策支持系统在临床中的实用性，实现智能化技术在临床落地。

利益冲突 所有作者声明不存在利益冲突

参考文献

[1] World Health Organization. Burns[EB/OL]. 2026 (2026-02-05) [2026-05-27]. https://www. who. int/news-room/fact-sheets/detail/burns/.

[2] Yakupu A, Zhang J, Dong W, et al. The epidemiological characteristic and trends of burns globally[J]. BMC Public Health, 2022, 22(1): 1596. DOI: 10.1186/s12889-022-13887-2.

[3] 国家卫生健康委办公厅, 国家中医药局综合司, 国家疾控局综合司. 国家卫生健康委员会办公厅关于印发卫生健康行业人工智能应用场景参考指引的通知[EB/OL]. 2024(2024-11-06) [2026-05-27]. https://www.nhc.gov.cn/guihuaxxs/c100133/202411/3dee425b8dc34f739d63483c4e5c334c.shtml.

[4] Janiesch C, Zschech P, Heinrich K. Machine learning and deep learning[J]. Electron Mark, 2021, 31(3): 685-695. DOI: 10.1007/s12525-021-00475-2.

[5] Smiti A. When machine learning meets medical world: current status and future challenges[J]. Comput Sci Rev, 2020, 37:100280. DOI: 10.1016/j.cosrev.2020.100280.

[6] Jiang T, Gradus JL, Rosellini AJ. Supervised machine learning: a brief primer[J]. Behav Ther, 2020,51(5):675-687. DOI: 10.1016/j.beth.2020.05.002.

[7] James G, Witten D, Hastie T, et al. Unsupervised learning [M]//James G, Witten D, Hastie T, et al. An Introduction to statistical learning: with applications in Python. Cham: Springer, 2023: 503-556. DOI: 10.1007/978-3-031-38747-0_12.

[8] van Engelen JE, Hoos HH. A survey on semi-supervised learning[J]. Mach Learn, 2020, 109(2): 373-440. DOI: 10.1007/s10994-019-05855-6.

[9] Shakya AK, Pillai G, Chakrabarty S. Reinforcement learning algorithms: a brief survey[J]. Expert Syst Appl, 2023, 231: 120495. DOI: 10.1016/j.eswa.2023.120495.

[10] Kühl N, Schemmer M, Goutier M, et al. Artificial intelligence and machine learning[J]. Electron Mark, 2022, 32(4): 2235-2244. DOI: 10.1007/s12525-022-00598-0.

[11] Sarker IH. Machine learning: algorithms, real-world applications and research directions[J]. SN Comput Sci, 2021,2(3):160. DOI: 10.1007/s42979-021-00592-x.

[12] Ren Y, Zhang Y, Luo J, et al. Research progress on risk factors of delirium in burn patients: a narrative review[J]. Front Psychiatry, 2022, 13: 989218. DOI: 10.3389/fpsyt. 2022.989218.

[13] Abdelrahman I, Vieweg R, Irschik S, et al. Development of delirium: association with old age, severe burns, and intensive care[J]. Burns, 2020,46(4):797-803. DOI: 10.1016/j.burns.2020.02.013.

[14] Lewis K, Balas MC, Stollings JL, et al. A focused update to the clinical practice guidelines for the prevention and management of pain, anxiety, agitation/sedation, delirium, immobility, and sleep disruption in adult patients in the ICU [J]. Crit Care Med, 2025, 53(3): e711-e727. DOI: 10.1097/CCM.0000000000006574.

[15] Sosnowski K, Lin F, Chaboyer W, et al. The effect of the ABCDE/ABCDEF bundle on delirium, functional outcomes, and quality of life in critically ill patients: a systematic review and meta-analysis[J]. Int J Nurs Stud, 2023, 138: 104410. DOI: 10.1016/j.ijnurstu.2022.104410.

[16] Powell TL, Nolan M, Yang G, et al. Nursing understanding and perceptions of delirium: assessing current knowledge, attitudes, and beliefs in a burn ICU[J]. J Burn Care Res, 2019, 40(4):471-477. DOI: 10.1093/jbcr/irz040.

[17] Gloger AN, Nakonezny PA, Phelan HA. Use of tailored feedback improves accuracy of delirium documentation in the burn ICU: results of a performance improvement initiative[J]. J Burn Care Res, 2020, 41(2): 299-305. DOI: 10.1093/jbcr/irz153.

[18] Ren Y, Zhang Y, Zhan J, et al. Machine learning for prediction of delirium in patients with extensive burns after surgery[J]. CNS Neurosci Ther, 2023,29(10):2986-2997. DOI: 10.1111/cns.14237.

[19] Esumi R, Funao H, Kawamoto E, et al. Machine learning-based prediction of delirium and risk factor identification in intensive care unit patients with burns: retrospective observational study[J]. JMIR Form Res, 2025,9: e65190. DOI: 10.2196/65190.

[20] 李东晖. 重症烧伤患者多重耐药菌感染风险的机器学习预测模型构建及验证[J/OL]. 中华实验和临床感染病杂志(电子版),2025,19(6): 368-377[2026-05-27]. https://rs. yiigle. com/cmaid/1664837. DOI: 10.3877/cma.j.issn.1674-1358.2025.06.007.

[21] Tsurumi A, Flaherty PJ, Que YA, et al. A preventive tool for predicting bloodstream infections in children with burns[J]. Shock, 2023,59(3):393-399. DOI: 10.1097/SHK.0000000000002075.

[22] Walker S, Cooper A, Peragine C, et al. Development and validation of a screening tool for early identification of bloodstream infection in acute burn injury patients[J]. Surgery, 2021, 170(2): 525-531. DOI: 10.1016/j. surg. 2021.02.034.

[23] Wang Y, Li Q, Shu Q, et al. Clinical epidemiology and a novel predicting nomogram of central line associated bloodstream infection in burn patients[J]. Epidemiol Infect, 2023,151:e90. DOI: 10.1017/S0950268823000766.

[24] Zhang P, Zou B, Liou YC, et al. The pathogenesis and diagnosis of sepsis post burn injury[J/OL]. Burns Trauma, 2021,9:tkaa047[2026-05-27]. https://pubmed.ncbi.nlm.nih.gov/33654698/. DOI: 10.1093/burnst/tkaa047.

[25] Stanojcic M, Vinaik R, Jeschke MG. Status and challenges of predicting and diagnosing sepsis in burn patients[J]. Surg Infect (Larchmt), 2018, 19(2): 168-175. DOI: 10.1089/sur.2017.288.

[26] 梁琦强, 韩春茂, 黄曼. 烧伤脓毒症诊断:脓毒症 3.0 适用吗[J]. 中华急诊医学杂志,2020,29(12):1509-1514. DOI: 10.3760/cma.j.issn.1671-0282.2020.12.002.

[27] Greenhalgh DG, Hill DM, Burmeister DM, et al. Surviving Sepsis After Burn Campaign[J]. Burns, 2023, 49(7): 1487-1524. DOI: 10.1016/j.burns.2023.05.003.

[28] 曾勇, 李小英, 蒋秋萍, 等. 综合防治方法预防和治疗严重烧伤患者脓毒症和多器官功能障碍综合征的效果分析[J]. 感染、炎症、修复,2021,22(2):79-81. DOI: 10.3969/j.issn.1672-8521.2021.02.005.

[29] Tran NK, Albahra S, Pham TN, et al. Novel application of an automated-machine learning development tool for predicting burn sepsis: proof of concept[J]. Sci Rep, 2020, 10(1):12354. DOI: 10.1038/s41598-020-69433-w.

[30] Luo W, Xiong L, Wang J, et al. Development and performance evaluation of a clinical prediction model for sepsis risk in burn patients[J]. Medicine (Baltimore), 2024, 103(48): e40709. DOI: 10.1097/MD.0000000000040709.

[31] 邱侃, 李江虹, 叶勇, 等. 基于机器学习的烧伤患者脓毒性休克预测模型建立与验证[J]. 医学研究与战创伤救治,2023,36(12): 1299-1304. DOI: 10.16571/j. cnki. 2097-2768.2023.12.012.

[32] Legrand M, Clark AT, Neyra JA, et al. Acute kidney injury in patients with burns[J]. Nat Rev Nephrol, 2024, 20(3): 188-200. DOI: 10.1038/s41581-023-00769-y.

[33] Yang G, Tan L, Yao H, et al. Long-term effects of severe burns on the kidneys: research advances and potential therapeutic approaches[J]. J Inflamm Res, 2023, 16: 1905-1921. DOI: 10.2147/JIR.S404983.

[34] Khwaja A. KDIGO clinical practice guidelines for acute kidney injury[J]. Nephron Clin Pract, 2012, 120(4): c179-184. DOI: 10.1159/000339789.

[35] Strauß C, Booke H, Forni L, et al. Biomarkers of acute kidney injury: from discovery to the future of clinical practice[J]. J Clin Anesth, 2024,95:111458. DOI: 10.1016/j.jclinane.2024.111458.

[36] 袁志强, 彭毅志. 重视烧伤后脓毒症导致的急性肾损伤[J]. 中华烧伤杂志,2018,34(2):69-72. DOI: 10.3760/cma.j.issn.1009-2587.2018.02.002.

[37] Rashidi HH, Sen S, Palmieri TL, et al. Early recognition of burn- and trauma-related acute kidney injury: a pilot comparison of machine learning techniques[J]. Sci Rep, 2020,10(1):205. DOI: 10.1038/s41598-019-57083-6.

[38] Tran NK, Sen S, Palmieri TL, et al. Artificial intelligence and machine learning for predicting acute kidney injury in severely burned patients: a proof of concept[J]. Burns, 2019, 45(6):1350-1358. DOI: 10.1016/j.burns.2019.03.021.

[39] 中国老年医学学会烧创伤分会, 中华医学会烧伤外科学分会重症学组,《中华烧伤与创面修复杂志》编辑委员会. 成人吸入性损伤临床诊疗专家共识更新(2025 版)[J]. 中华烧伤与创面修复杂志,2025,41(9):811-824. DOI: 10.3760/cma.j.cn501225-20250502-00202.

[40] Chan CH, Yang SF, Yeh HW, et al. Risk of pneumonia in patients with burn injury: a population-based cohort study [J]. Clin Epidemiol, 2018,10:1083-1091. DOI: 10.2147/CLEP.S172980.

[41] Milton-Jones H, Soussi S, Davies R, et al. An international RAND/UCLA expert panel to determine the optimal diagnosis and management of burn inhalation injury[J]. Crit Care, 2023,27(1):459. DOI: 10.1186/s13054-023-04718-w.

[42] Yang SY, Huang CJ, Yen CI, et al. Machine learning approach for predicting inhalation injury in patients with burns[J]. Burns, 2023,49(7):1592-1601. DOI: 10.1016/j.burns.2023.03.011.

[43] 马琪敏, 沈拓, 王玉松, 等. 危重烧伤早期凝血功能紊乱[J]. 血栓与止血学,2023,29(5):223-230. DOI: 10.3969/j.issn.1009-6213.2023.05.005.

[44] Ball RL, Keyloun JW, Brummel-Ziedins K, et al. Burn-induced coagulopathies: a comprehensive review[J]. Shock, 2020, 54(2):154-167. DOI: 10.1097/SHK.0000000000001484.

[45] Çinar MA. Prediction of acute burn-induced coagulopathy risk with machine learning models[J]. Artif Intell Theory Appl, 2023, 3(2): 92-104.

[46] Rousseau AF, Pantet O, Heyland DK. Nutrition after severe burn injury[J]. Curr Opin Clin Nutr Metab Care, 2023,26(2): 99-104. DOI: 10.1097/MCO.0000000000000904.

[47] 中华医学会烧伤外科学分会, 中国医疗保健国际交流促进会烧伤医学分会. 成年严重烧伤患者肠内营养护理专家共识(2024 版)[J]. 中华烧伤与创面修复杂志,2024,40(9):801-811. DOI: 10.3760/cma.j.cn501225-20240229-00078.

[48] He QL, Gao SW, Qin Y, et al. Gastrointestinal dysfunction is associated with mortality in severe burn patients: a 10-year retrospective observational study from South China[J]. Mil Med Res, 2022,9(1):49. DOI: 10.1186/s40779-022-00403-1.

[49] Liu L, Feng B, Cao Y, et al. Interpretable machine learning model predicts the early gastrointestinal dysfunction risk in severely burned patients: a multicenter-based study[J]. Int J Surg, 2026,112(6):12844-12855. DOI: 10.1097/JS9.000000

0000005044.
[50] Frugoni B, Gabriel RA, Rafaat K, et al. A predictive model for prolonged hospital length of stay in surgical burn patients [J]. Burns, 2020, 46(7): 1565-1570. DOI: 10.1016/j. burns.2020.04.021.
[51] Ghaed Chukamei Z, Mobayen M, Bagheri Toolaroud P, et al. The length of stay and cost of burn patients and the affecting factors[J]. Int J Burns Trauma, 2021,11(5):397-405.
[52] Johnson LS, Shupp JW, Pavlovich AR, et al. Hospital length of stay--does 1% TBSA really equal 1 day?[J]. J Burn Care Res, 2011,32(1):13-19. DOI: 10.1097/BCR.0b013e318204b3ab.
[53] Taylor SL, Sen S, Greenhalgh DG, et al. Not all patients meet the 1day per percent burn rule: a simple method for predicting hospital length of stay in patients with burn[J]. Burns, 2017, 43(2): 282-289. DOI: 10.1016/j. burns. 2016. 10.021.
[54] Elrod J, Mohr C, Wolff R, et al. Using artificial intelligence to obtain more evidence? prediction of length of hospitalization in pediatric burn patients[J]. Front Pediatr, 2020,8:613736. DOI: 10.3389/fped.2020.613736.
[55] Yeh CC, Lin YS, Chen CC, et al. Implementing AI models for prognostic predictions in high-risk burn patients[J]. Diagnostics (Basel), 2023, 13(18): 2984. DOI: 10.3390/ diagnostics13182984.
[56] Vakili Ojarood M, Torabi H, Soltani A, et al. Machine learning as a hopeful indicator for prediction of complications and mortality in burn patients[J]. Burns, 2024,50(7):1942-1946. DOI: 10.1016/j.burns.2024.05.006.
[57] Stylianou N, Akbarov A, Kontopantelis E, et al. Mortality risk prediction in burn injury: comparison of logistic regression with machine learning approaches[J]. Burns, 2015, 41(5): 925-934. DOI: 10.1016/j.burns.2015.03.016.
[58] Cobb AN, Daungjaiboon W, Brownlee SA, et al. Seeing the forest beyond the trees: predicting survival in burn patients with machine learning[J]. Am J Surg, 2018,215(3):411-416. DOI: 10.1016/j.amjsurg.2017.10.027.
[59] Park JH, Cho Y, Shin D, et al. Prediction of mortality after burn surgery in critically ill burn patients using machine learning models[J]. J Pers Med, 2022, 12(8): 1293. DOI: 10.3390/jpm12081293.
[60] Çinar MA, Ölmez E, Erkiliç A, et al. Machine learning models for early prediction of mortality risk in patients with burns: a single center experience[J]. J Plast Reconstr Aesthet Surg, 2024, 89:14-20. DOI: 10.1016/j.bjps.2023.11.048.

·科技快讯·

TIGAR通过稳定HMGCL并促进β-连环蛋白的β-羟基丁酰化维持烧伤脓毒症中的肠道上皮再生

引用格式：Zhang P, Wu D, Wei Y, et al. TIGAR maintains intestinal epithelial regeneration by stabilizing HMGCL and promoting β-catenin β-hydroxybutyrylation in burn-induced sepsis[J]. Cell Death Dis, 2026, 17(1): 233. DOI: 10.1038/ s41419-026-08486-7.

烧伤引发的脓毒症会诱发严重的肠道损伤，进而导致全身性炎症反应及器官损害。β-羟基丁酸（BHB）作为一种主要的酮体，是肠道上皮再生的关键调节因子。BHB代谢失调与细胞增殖受阻以及肠道干细胞（ISC）干性的维持密切相关。然而，烧伤脓毒症所致肠道损伤过程中BHB水平波动背后的动态调控机制尚不明确。该研究揭示，在烧伤脓毒症小鼠的小肠隐窝中，肿瘤蛋白p53诱导的糖酵解与凋亡调节因子（TIGAR）的表达水平显著降低。TIGAR缺乏会大幅抑制BHB的生成，并损害细胞增殖及ISC自我更新能力。从机制上讲，TIGAR的第1~131位结构域具有双重功能：它既作为线粒体靶向信号引导TIGAR的定位，又与3-羟基-3-甲基戊二酰辅酶A裂解酶（HMGCL）竞争性结合，从而抑制其与E3泛素连接酶Park2的相互作用。这种空间性干扰阻断了Park2介导的K48连接型泛素化及HMGCL的蛋白酶体降解过程，进而稳定了HMGCL，促进BHB的合成。升高的BHB水平可诱导β-连环蛋白第335位赖氨酸发生β-羟基丁酰化，这一过程促进了β-连环蛋白向细胞核的转运并增强了其与转录因子4的相互作用，从而驱动细胞增殖和ISC自我更新，最终维持肠道上皮的再生。总体而言，该研究揭示了TIGAR通过促进酮体生成在维持肠道屏障再生中所发挥的新型作用。这一此前尚未被探索的TIGAR作用机制，或可作为治疗烧伤相关肠道屏障功能障碍的重要补偿手段。

周志豪，编译自 *Cell Death Dis*，2026，17(1)：233；彭曦，审校

广告目次

珠海亿胜生物制药有限公司…… 封底