

• 专题论坛 •

传统模式与人工智能：体外膜肺氧合患者风险评估模型的现状、挑战与未来方向

林钊杰 卢鲁 方梦浩 刘燕青 邢济枫 樊毫军

天津大学卫生应急学院, 天津 300072

通信作者: 樊毫军, Email: fanhj@tju.edu.cn

【摘要】 体外膜肺氧合(ECMO)在临床上主要用于为重症心肺功能衰竭患者提供持续的体外呼吸与循环,以维持患者生命,是治疗难以控制的严重心力衰竭和呼吸衰竭的关键技术。随着 ECMO 用于循环和(或)呼吸辅助临床经验的积累及生物医学工程技术的进步,应用更加便携、性能更加稳定的 ECMO 设备逐渐进入临床,使越来越多的危重症患者从中获益。尽管 ECMO 技术已相对成熟,但 ECMO 辅助时机选择、突发并发症、患者生理指标监测预警等风险管理问题,极大影响了 ECMO 的救治效果。针对 ECMO 风险管理,本文梳理了传统模式与人工智能技术在风险评估中的方法、最新成果及研究热点,并从多中心和前瞻性研究的推进、模型效能的外部验证与标准化、长期预后的关注、创新技术的融合、增强模型的可解释性、经济成本效益分析6个方面展望其未来发展趋势,以期后续研究人员构建模型、探索新的研究方向提供参考。

【关键词】 体外膜肺氧合; 风险评估模型; 人工智能; 长期预后

基金项目: 国家重点研发计划项目(2024YFC3016600)

DOI: 10.3760/cma.j.cn121430-20250604-00543

Traditional methods and artificial intelligence: current status, challenges, and future directions of risk assessment models for patients undergoing extracorporeal membrane oxygenation

Lin Zhaojie, Lu Lu, Fang Menghao, Liu Yanqing, Xing Jifeng, Fan Haojun

School of Disaster and Emergency Medicine, Tianjin University, Tianjin 300072, China

Corresponding author: Fan Haojun, Email: fanhj@tju.edu.cn

【Abstract】 Extracorporeal membrane oxygenation (ECMO) is primarily used in clinical practice to provide continuous extracorporeal respiratory and circulatory support for patients with severe heart and lung failure, thereby sustaining life. It is a key technology for managing severe heart failure and respiratory failure that are difficult to control. With the accumulation of clinical experience in ECMO for circulatory and/or respiratory support, as well as advancements in biomedical engineering technology, more portable and stable ECMO devices have been introduced into clinical use, benefiting an increasing number of critically ill patients. Although ECMO technology has become relatively mature, the timing of ECMO initiation, management of sudden complications, and monitoring and early warning of physiological indicators are critical factors that greatly affect the therapeutic outcomes of ECMO. This article reviews traditional methods and artificial intelligence techniques used in risk assessment related to ECMO, including the latest achievements and research hotspots. Additionally, it discusses future trends in ECMO risk management, focusing on six key areas: multi-center and prospective studies, external validation and standardization of model performance, long-term prognosis considerations, integration of innovative technologies, enhancing model interpretability, and economic cost-effectiveness analysis. This provides a reference for future researchers to build models and explore new research directions.

【Key words】 Extracorporeal membrane oxygenation; Risk assessment model; Artificial intelligence; Long-term prognosis

Fund program: National Key R&D Program of China (2024YFC3016600)

DOI: 10.3760/cma.j.cn121430-20250604-00543

体外膜肺氧合(extracorporeal membrane oxygenation, ECMO)是一种基于体外循环系统的高级持续体外生命支持技术,是针对常规治疗无效的循环和(或)呼吸衰竭的抢救性辅助治疗手段,其通过将患者的静脉血液引流至体外循环回路,经过膜式氧合器对血液进行氧合和二氧化碳清除,再将血液回输患者体内,实现部分或近似全部的血气交换、血液循环功能^[1]。ECMO能够快速改善危重症患者的低氧血

症和循环衰竭状态,可在相对时间内部分替代患者的心肺功能,帮助危重症患者度过生命危险期,为后续治疗争取更多的机会和时间^[2]。近年来,该技术在危重症救治领域发挥了重要作用。根据国际体外生命支持组织(Extracorporeal Life Support Organization, ELSO)统计,2009至2022年,全世界在ELSO登记的ECMO病例数为154 568例^[3];2023年,我国814家医院上报数据显示,开展ECMO救治达到18 486例,

较 2022 年增加了 37%^[4]。以上数据表明,基于 ECMO 的体外生命支持技术正处于快速发展阶段,ECMO 设备在全世界范围内的应用呈逐年增加趋势。然而,ECMO 设备的应用也面临严重原发病、突发并发症等诸多临床挑战^[5]。一级预防是 ECMO 患者风险防控的核心,早期识别和预防风险因素是 ECMO 管理的关键,也是患者成功撤机的前提。

风险评估模型作为一种科学的统计学评估方法,在早期筛查与识别 ECMO 患者高危人群方面具有重要的临床价值。随着信息化时代的到来,海量临床数据与人工智能 (artificial intelligence, AI) 技术结合开发的 ECMO 患者风险评估模型逐渐成为危重症救治领域的关注热点。目前,ECMO 患者风险评估以量表为主,存在忽视个体差异、评估结果不一致、易漏诊等问题。ECMO 患者风险评估研究在进行数据分析时,主要采用传统的统计学方法构建风险评估模型,存在计算效率低、难以处理复杂的非线性关系、模型泛化能力有限等局限性。AI 技术凭借其卓越的数据处理能力,为 ECMO 患者风险评估提供了新视角^[6]。现针对传统模式与 AI 技术在 ECMO 患者风险评估中的方法与挑战进行回顾总结,并展望其未来发展趋势,以期后续 ECMO 患者风险评估模型的构建、新的研究方向的探索提供参考。

1 风险评估模型

风险评估模型是一种科学的统计学评估方法,用于根据个体特征预测其在未来发生某种特定结局事件的概率^[7-8]。评估模型的构建有利于帮助医护人员识别高风险个体,评估疾病严重程度及影响因素,预测不良结局,并提前制订个体化的治疗和护理方案,从而有效降低不良结局的发生风险。

风险评估模型的构建遵循标准化的流程。首要步骤是确定临床问题,不同的临床问题决定不同的模型类型,若研究目标旨在识别当前疾病状态,则构建诊断模型;若需预测未来临床结局,则建立预后模型^[9]。研究设计包括队列研究、病例对照研究、横断面研究等,现阶段研究者通常采用单中心回顾性队列数据开发模型。模型通常纳入人口统计学特征、基本病史、体格检测指标、实验室检查指标等^[10]。此外,评估模型研究需要纳入足够的数据集,这将决定模型的准确性和可靠性。研究者应描述缺失数据、异常数据、重复数据及处理方法,并对数据进行转换,确保数据的质量和可用性^[11]。在评估模型建立过程中,特征选择是不可或缺的步骤,研究者通常纳

入大量特征进行统计学分析。然而,纳入特征数量越多,模型过拟合的风险越大^[12]。因此,在分析之前进行合理的特征筛选具有重要意义。传统模式主要基于临床经验和单变量分析筛选特征,而现代方法则采用逐步回归、最小绝对收缩和选择算子 (the least absolute shrinkage and selection operator, LASSO) 回归等算法进行自动特征选择,对于高维数据,还可应用基于机器学习的特征重要性评估方法,降低维度并提高模型效能。在建模方法上,除传统的线性回归、Logistic 回归、Cox 比例风险模型外,机器学习算法在复杂模式识别中展现出独特优势。模型验证是风险评估模型研究中的关键环节,根据验证样本来源分为内部验证和外部验证^[13]。风险评估模型的效能可从区分度、校准度及临床适用性 3 个方面进行评价。区分度旨在衡量预测模型在不同类别患者间的区分能力,常见评价指标包括受试者工作特征曲线下面积 (area under the receiver operator characteristic curve, AUC)、一致性指数 (concordance index, CI); 校准度旨在衡量模型的预测概率与实际事件发生频率的匹配程度,常见方法包括校准曲线、Hosmer-Lemeshow 拟合优度检验、概率预测准确性评分 (Brier 评分); 而临床适用性旨在评估模型在实际临床决策中的应用价值,常见方法包括决策曲线分析、净效益计算及成本效益分析^[14]。随着真实世界数据应用的深入,模型动态更新机制已成为当前研究的重点。与此同时,借助数学方程式、评分表、列线图、网页计算器等可视化工具的开发,进一步增强了模型的临床可用性和转化价值^[15-16]。

2 ECMO 患者风险评估模型的研究现状

2.1 传统风险评估模型

2.1.1 常见的风险评估方法: ECMO 患者风险评估对于识别危险因素、实施个体化干预及改善预后至关重要。近年来,多个研究团队开发出不同风险评估模型,为临床提供了有效工具,可优化治疗决策,从而提高患者生存率。现有大多数模型是基于 Logistic 回归、Cox 比例风险回归等传统统计学方法进行危险因素筛选,具有较强的可解释性和临床应用价值。目前基于传统统计学方法开发的风险评估方式包括但不限于 ECMO 协作网络评分 (ECMO collaborative network, ECMOnet)、预测接受静脉-静脉 ECMO 的严重急性呼吸窘迫综合征患者死亡风险评分 (predicting death for severe acute respiratory distress syndrome on veno-venous ECMO, PRESERVE)、呼吸 ECMO 生存预

测评分(respiratory ECMO survival prediction, RESP)、静脉-动脉 ECMO 辅助后生存率评分(survival after veno-arterial ECMO, SAVE)、ECMO 治疗生存预测评分(prediction of survival on ECMO therapy, PRESET)、预测静脉-动脉 ECMO(veno-arterial ECMO, VA-ECMO)患者 30 d 院内病死率评分 ECMO-ACCEPTS 等,这些评分系统广泛应用于因心源性休克、急性呼吸窘迫综合征(acute respiratory distress syndrome, ARDS)等疾病接受 ECMO 治疗的患者。

2.1.2 传统模式在 ECMO 患者风险评估模型中应用的研究进展(表 1):2012 年,意大利 Pappalardo 等^[17]提出了应用 ECMOnet 评分预测接受静脉-静脉 ECMO(veno-venous ECMO, VV-ECMO)治疗的甲型流感病毒(H1N1)感染致 ARDS 患者的死亡风险,该评分包括 5 个危险因素,评分越高,死亡风险越大,被认为是评估急性呼吸衰竭患者 VV-ECMO 介入最佳时机的高效工具。2013 年,法国 Schmidt 等^[18]基于多元 Logistic 回归,分析了 2008 年 5 月至 2012 年 1 月法国 3 家成人重症监护病房(intensive care unit, ICU)中接受 ECMO 治疗的 140 例 ARDS 患者资料,构建了 PRESERVE 评分系统,用于预测接受 VV-ECMO 治疗的 ARDS 患者死亡风险,确定了与 ICU 出院后 6 个月死亡风险相关的 8 个因素。该评分可帮助医生评估患者是否适合 VV-ECMO 治疗,同时可以将患者根据死亡风险分层,有助于合理分配医疗资源和制定个体化治疗计划。随后, Schmidt 等^[19]在 2014 年开发了 RESP 评分系统,该评分系统基于多元 Logistic 回归纳入了 12 个 ECMO 启动前变量,结合 ELSO 注册数据库中 2000 至 2012 年接受 ECMO 治疗的 2 355 例患者资料,开发了严重急性呼吸衰竭患者死亡风险评估模型,并接受了外部验证,一定程度上增加了模型可信度。2015 年, Schmidt 等^[20]通过多元 Logistic 回归,识别出与住院生存率独立相关的因素,针对接受 VA-ECMO 治疗的难治性心源性休克患者,开发了 SAVE 评分系统,并成功预测了患者的死亡风险。2017 年,德国 Hilder 等^[21]针对 2010 至 2015 年接受 VV-ECMO 治疗的 108 例 ARDS 患者进行了回顾性分析,证明了 ECMOnet 评分和 RESP 评分预测接受 ECMO 治疗的 ARDS 患者死亡风险的可靠性;并通过多元 Logistic 回归纳入了新的变量,建立了 PRESET 评分,该评分系统对死亡风险的预测效能较以往评分系统更佳,能更精准地预测 ARDS 患者死亡风险。2020 年,德国 Becher 等^[22]通过 Cox 比例风险回归筛

选出 10 个独立预测因素,开发了 ECMO-ACCEPTS 评分,用于评估接受 VA-ECMO 治疗的难治性心源性休克患者的 30 d 院内病死率。该研究根据回归系数赋予各变量不同分值,并将风险模型评分进行分层:≤18 分为低危组,19~32 分之间每 2 分为一个中间风险组,≥33 分为高危组;随着评分增加,预测院内病死率逐步上升(从 36.2% 至 85.4%),为 VA-ECMO 患者院内死亡风险提供了量化工具。2023 年,我国学者基于 Cox 比例风险回归筛选出接受 ECMO 治疗的成人患者 30 d 生存率影响因素,并建立了列线图模型用于生存预测^[23]。2025 年,王钊等^[24]建立了基于 LASSO 惩罚的 Logistic 回归模型,以预测接受 ECMO 治疗的成人 ARDS 患者生存情况,为临床决策提供了有效工具。此外,还有多种用于 ECMO 患者的危重症评分,包括但不限于序贯器官衰竭评分(sequential organ failure assessment, SOFA)^[25]、简化急性生理学评分 II(simplified acute physiology score II, SAPS II)^[26]、急性生理学及慢性健康状况评分 II(acute physiology and chronic health evaluation II, APACHE II)^[27]等。

2.1.3 存在的问题:长期以来,传统风险评估模型在临床研究和实际应用中发挥着重要作用。这些模型通过量化风险因素,帮助医生识别潜在患者。由于传统风险评估模型结构简明、计算方式直观,不仅容易理解,还能够在变量较少、样本量较小的情况下,提供稳定的预测结果。因此,传统风险评估模型在一定条件下展现出独特优势。然而,传统风险评估模型在面对复杂情况时,仍存在一些局限性。例如:传统风险评估模型在捕捉患者风险的多重交互关系和非线性影响方面表现不足,无法全面反映各个因素之间的复杂交互机制。此外,传统风险评估模型通常依赖人工选择变量,使得模型难以涵盖新兴生物标志物、社会决定因素等多元化信息,限制了模型的适应性和前瞻性。传统风险评估模型大多是静态的,难以动态响应患者在治疗过程中发生的风险因素变化。在处理大规模数据集时,传统风险评估模型的计算效率和可扩展性也面临挑战,影响其预测效能和实时应用能力。

近年来,随着大数据和 AI 技术的快速发展,研究人员开始探索更加复杂、精准的风险评估模型。随机森林、支持向量机、神经网络等 AI 技术,凭借其强大的数据处理能力和模型拟合能力,克服了传统风险评估模型的局限性。因此, AI 技术在 ECMO 患者风险评估中的应用,成为当前该领域的研究热点。

表 1 传统模式在 ECMO 患者风险评估中应用的研究概括

评分系统 / 模型	纳入指标	适用场景	模型性能
ECMOnet 评分 ^[17]	ECMO 前住院时间、胆红素、Cr、HCT、MAP	预测接受 VV-ECMO 治疗的甲型流感病毒(H1N1)感染致 ARDS 患者死亡风险	内部验证: C 统计量为 0.857 (95%CI 为 0.754 ~ 0.959); 外部验证: C 统计量为 0.694 (95%CI 为 0.562 ~ 0.826)
PRESERVE 评分 ^[18]	年龄、BMI、免疫功能受损状态、SOFA 评分、ECMO 前机械通气时间、俯卧位通气、平台期压力、PEEP	预测接受 VV-ECMO 治疗的 ARDS 患者 6 个月死亡风险	C 统计量为 0.890 (95%CI 为 0.830 ~ 0.940)
RESP 评分 ^[19]	年龄、免疫功能受损状态、ECMO 前机械通气时间、急性呼吸诊断类别、中枢神经系统功能障碍、急性非肺部感染、ECMO 前神经肌肉阻滞剂使用、ECMO 前一氧化氮使用、ECMO 前 HCO ₃ ⁻ 输注、ECMO 前心搏骤停、PaCO ₂ 、吸气峰压	预测接受 ECMO 治疗的严重急性呼吸衰竭患者死亡风险	内部验证: C 统计量为 0.740 (95%CI 为 0.720 ~ 0.760); 外部验证: C 统计量为 0.920 (95%CI 为 0.890 ~ 0.970)
SAVE 评分 ^[20]	年龄、体质量、ECMO 前机械通气时间、慢性肾衰竭、急性肾衰竭、肝衰竭、先天性心脏病、心肌炎、难治性室速 / 室颤、心脏或肺移植后状态、中枢神经系统功能障碍、ECMO 前 HCO ₃ ⁻ 输注、ECMO 前心搏骤停、舒张压、脉压、吸气峰压	预测接受 VA-ECMO 治疗的难治性心源性休克患者死亡风险	内部验证: C 统计量为 0.680 (95%CI 为 0.640 ~ 0.710), Hosmer-Lemeshow C 统计量为 9.700 (P=0.290); 外部验证: C 统计量为 0.900 (95%CI 为 0.850 ~ 0.950), Hosmer-Lemeshow C 统计量为 13.970 (P=0.080)
PRESET 评分 ^[21]	ECMO 前 pH 值、ECMO 前 MAP、ECMO 前乳酸、ECMO 前血小板浓度、ECMO 前住院时间	预测接受 VV-ECMO 治疗的 ARDS 患者死亡风险	内部验证: C 统计量为 0.845 (95%CI 为 0.760 ~ 0.930); 外部验证: C 统计量为 0.700 (95%CI 为 0.560 ~ 0.840)
ECMO-ACCEPTS 评分 ^[22]	年龄、紧急入院、ECMO 前心肺复苏、心房颤动、冠状动脉疾病、充血性心力衰竭、肺动脉高压、高血压、心脏移植、急性冠脉综合征	预测接受 VA-ECMO 治疗的难治性心源性休克患者 30 d 院内病死率	内部验证: C 统计量为 0.643 (95%CI 为 0.626 ~ 0.660); 外部验证: C 统计量为 0.640 (95%CI 为 0.628 ~ 0.652)
成人 ECMO 患者 30 d 生存预测列线图模型 ^[23]	性别、APACHE II 评分、DIC 评分、去甲肾上腺素平均日剂量	预测接受 ECMO 治疗的成人患者 30 d 生存率	内部验证: C 统计量为 0.886, AUC 为 0.999 (95%CI 为 0.960 ~ 1.000)
接受 ECMO 治疗的成人 ARDS 患者生存预测模型 ^[24]	年龄、APACHE II 评分、ECMO 前机械通气时间、ICU 住院时间及 ECMO 治疗后 72 h 内心率	预测接受 ECMO 治疗的成人 ARDS 患者生存情况	AUC 为 0.867

注:ECMO 为体外膜肺氧合,ECMOnet 为 ECMO 协作网络评分,Cr 为肌酐,HCT 为血细胞比容,MAP 为平均动脉压,VV-ECMO 为静脉-静脉 ECMO,ARDS 为急性呼吸窘迫综合征,95%CI 为 95% 置信区间,PRESERVE 为预测接受 VV-ECMO 的严重 ARDS 患者死亡风险评分,BMI 为体质量指数,SOFA 为序贯器官衰竭评分,PEEP 为呼气末正压,RESP 为呼吸 ECMO 生存预测评分,PaCO₂ 为动脉血二氧化碳分压,SAVE 为静脉-动脉 ECMO(VA-ECMO)辅助后生存率评分,PRESET 为 ECMO 治疗生存预测评分,ECMO-ACCEPTS 为预测 VA-ECMO 患者 30 d 院内病死率评分,APACHE II 为急性生理学及慢性健康状况评分 II,DIC 为弥散性血管内凝血,AUC 为受试者工作特征曲线下面积,ICU 为重症监护病房;室速为室性心动过速,室颤为心室纤颤

这些新兴技术有望推动 ECMO 患者风险评估进入到一个新阶段,为临床决策提供更加精准、更加个性化的支持。

2.2 AI 风险评估模型

2.2.1 常见的 AI 技术:AI 是一种通过计算机程序模拟人类思维过程、推理能力和行为表现的前沿技术,包括机器学习和深度学习。根据处理数据类型和训练方式的不同,机器学习和深度学习可进一步分为监督学习与无监督学习^[28]。监督学习是指计算机通过学习带有标签的数据集,根据已知的输入输出关系建立模型,对未知样本进行评估;无监督学习则不依赖于标签信息,而侧重于从未标注的数据中挖掘潜在的结构和模式,揭示数据之间的内在关系。因此,监督学习广泛应用于风险评估模型的构建,常见

的算法包括 K 最近邻、随机森林、支持向量机、神经网络等^[29]。对于 ECMO 患者的风险评估,大多数研究者采用监督学习算法构建风险评估模型。

2.2.2 AI 技术在 ECMO 患者风险评估模型中应用的研究进展(表 2):在患者预后评估方面,2020 年,美国 Ayers 等^[30]运用 AI 技术分析了接受 VA-ECMO 治疗的成人患者实验室数据,构建了深度神经网络模型用于生存预测,AUC(0.920)显著优于传统 SAVE 评分(0.650),凸显了 AI 技术在优化接受 VA-ECMO 治疗患者临床决策过程中的巨大潜力。在 ECMO 治疗期间,出血和血栓形成是主要并发症和死亡原因,即便在受控环境下,出血事件也频繁发生。2018 年,法国一项关于 ECMO 救治严重 ARDS 肺损伤的试验显示,近一半接受 ECMO 治疗的患者发生了出血,需

要输血^[40]。2020 年,美国 Abbasi 等^[31]基于 ECMO 数据集,应用 AI 技术预测出血和血栓形成风险,为临床决策提供支持。2022 年,法国 Morisson 等^[41]开发了一种机器学习算法,评估心脏术后低心排量综合征(post-cardiotomy low cardiac output syndrome, PC-LCOS)患者是否需植入 VA-ECMO,通过分析关键血液指标,如血乳酸,发现该算法能有效预测中度至重度 PC-LCOS 患者病情恶化风险,有助于评估患者是否需 VA-ECMO 治疗。同年,美国 Loyaga-Rendon 等^[32]通过 AI 技术分析了因失代偿性心力衰竭和急性心肌梗死接受 ECMO 治疗的患者血流动力学特征,成功预测了短期死亡风险。2023 年,澳大利亚学者开发了基于深度神经网络模型的 ECMO 预测算法(ECMO predictive algorithm, ECMO PAL),该模型结合了 ELSO 注册数据库中的大规模患者的临床数据,用于评估 ECMO 患者死亡风险,结果显示,该模型在验证集的准确率为 72.7%,优于传统 ECMO-ACCEPTS 评分(54.7%)、SAVE 评分(61.1%)和改良 SAVE 评分(62.0%)^[33]。同年,瑞士 Braun 等^[34]研究了 AI 技术在大型数据集和小型数据集中的应用差异,预测了接受 VA-ECMO 治疗的成人患者的死亡风险。同年,韩国 Lee 等^[35]采用极端梯度提升(extreme gradient boosted ensemble, XGBoost)、轻量级梯度提升、随机森林、支持向量机等 6 种 AI 技术,评估了接受 VV-ECMO 治疗的急性呼吸衰竭患者 90 d 死亡风险,结果显示,以 XGBoost(AUC 为 0.820)和轻量级梯度提升(AUC 为 0.810)表现最佳。2024 年, Ribeiro 等^[36]运用 AI 技术,分析了接受 ECMO 治疗的新型冠状病毒感染成人患者的临床恶化或改善趋势。同年,德国 Kresoja 等^[37]利用 AI 技术确定了 VA-ECMO 治疗对降低急性心肌梗死并发心源性休克患者短期死亡风险的影响。该团队使用 XGBoost 算法开发了预测 30 d 死亡风险的模型,该模型在验证集中 AUC 为 0.800,敏感度为 95%,特异度为 55%,阳性预测值为 65%,阴性预测值为 92%。同年,我国学者利用 K 均值聚类分析了难治性心源性休克患者的特征,识别出在 VA-ECMO 治疗下患者的 3 种不同表型,每种表型都具有独特的临床特征和死亡风险,为精准治疗提供了更有针对性的指导^[42]。在接受 VV-ECMO 支持的患者中,神经系统并发症很常见。2024 年,美国 Leng 等^[38]使用 AI 技术识别出接受 VV-ECMO 治疗的患者神经系统结局的预测因素,特征重要性分析显示,ECMO 系统中气体参数、吸入氧浓度(fraction of inspired

oxygen, FiO₂)及泵速是预测神经系统结局的关键特征。2025 年,我国学者基于中国体外生命支持学会注册数据库和在当地医院接受 ECMO 治疗的儿科患者的临床数据,采用随机森林、支持向量机、自适应提升(adaptive boosting, AdaBoost)等 10 种 AI 技术评估了接受 ECMO 治疗的儿童发生脑损伤的个体风险,结果显示,随机森林表现最佳,在训练集中 AUC 为 0.912,在验证集中 AUC 为 0.807,进一步证明了 AI 技术对 ECMO 患者预后的强大预测能力^[39]。然而,在多项研究中,不同算法的准确率、区分度等表现各不相同,一种算法的表现无法代表所有算法在某一特定模型中的应用效果。因此,具体的算法选择应根据数据特征和实际需求来决定。

2.2.3 AI 技术在 ECMO 患者风险评估模型中应用的研究热点:近年来, AI 技术在 ECMO 患者风险评估模型中应用的研究逐渐聚焦于以下 3 个关键领域,展示了 AI 技术在临床决策中的巨大潜力。① 实时监测与动态分析:随着对 ECMO 患者病情变化的日益关注,实时监测患者的多维生理数据成为研究的核心方向之一。通过应用 AI 技术对这些数据进行动态分析,可以及时识别患者病情的微小变化,提供实时预警。② 并发症预测与早期干预:研究人员逐渐重视利用 AI 技术分析 ECMO 患者的历史数据及实时生理参数,以便识别出与出血、感染、器官功能衰竭等并发症相关的关键因素。通过这种智能预测,医生可以及早采取干预措施,优化治疗方案,减少并发症的发生,进而改善患者的临床结局。③ 可解释性与透明度:随着 AI 技术应用的深入,可解释性逐渐成为该领域的一个重要研究热点。为了增强医生对 AI 决策过程的理解与信任,研究人员致力于开发更加透明、易于解释的 AI 模型,如越来越多的 ECMO 患者风险评估模型使用 Shapley 加法解释(Shapley Additive exPlanation, SHAP)技术提升模型的可解释性。这些技术不仅能够帮助临床医生了解 AI 模型的决策依据,还能确保 AI 技术在临床决策中的可靠性与可信度,为个体化治疗提供强有力的支持。

2.3 传统模式与 AI 技术在 ECMO 患者风险评估中应用的比较和选择(表 3):在构建 ECMO 患者风险评估模型时,选择合适的方法至关重要。随着大数据和 AI 技术的快速发展,研究人员面临着多种技术选择。传统的统计学方法在处理简单、结构化数据时效果良好,但面对大规模、多维、复杂数据时,往往表现不佳。AI 技术能够有效处理复杂数据,提供

表 2 AI 技术在 ECMO 患者风险评估中应用的研究概括

研究团队	年份 (年)	数据来源	研究算法	适用场景	模型效能
Ayers 等 ^[30]	2020	2011 年 5 月至 2018 年 10 月在纽约罗切斯特大学医学中心接受 VA-ECMO 治疗的 282 例成人患者	深度神经网络	预测出院生存率	准确度为 82.0%, AUC 为 0.920
Abbasi 等 ^[31]	2020	44 例接受 ECMO 治疗的患者	Logistic 回归、递归特征消除、随机森林、决策树和 K 最近邻算法	预测 ECMO 治疗期间出血和血栓形成风险	决策树在出血事件预测方面表现最佳(准确度为 80.0%);随机森林在血栓形成预测方面表现最佳(准确度为 64.0%)
Loyaga-Rendon 等 ^[32]	2022	美国密歇根州 Spectrum Health ECMO 注册系统中 283 例接受 ECMO 治疗的失代偿性心力衰竭和急性心肌梗死患者	弹性网络算法	预测 30 d 死亡风险	训练集: AUC 为 0.680; 验证集: AUC 为 0.720
Stephens 等 ^[33]	2023	ELSO 注册数据库中 2017 至 2021 年 23 182 例接受 VA-ECMO 治疗的成人患者	深度神经网络、Logistic 回归、随机森林、决策树、支持向量机、XGBoost 和 AdaBoost	预测死亡风险	训练集: 深度神经网络表现最佳(AUC 为 0.830, 准确率为 75.5%); 验证集: AUC 为 0.800, 准确率为 72.7%
Braun 等 ^[34]	2023	2007 年 1 月至 2019 年 12 月在瑞士苏黎世大学医院、法兰克福大学医院和维尔茨堡大学医院接受 VA-ECMO 治疗的 837 例成人患者	条件推断树	预测死亡风险	训练集: 小型数据集 AUC 为 0.700, 准确率为 64.2%, Brier 评分为 0.210; 大型数据集 AUC 为 0.710, 准确率为 64.6%, Brier 评分为 0.211。 验证集: 小型数据集 AUC 为 0.600, 准确率为 57.0%; 大型数据集 AUC 为 0.630, 准确率为 65.0%
Lee 等 ^[35]	2023	2012 至 2021 年在韩国 16 个三级医院和首尔国立大学盆唐医院接受 VV-ECMO 治疗的 446 例急性呼吸衰竭患者	Logistic 回归、轻量级梯度提升、随机森林、支持向量机、XGBoost 和多层感知机	预测 90 d 死亡风险	XGBoost(训练集 AUC 为 0.820, 验证集 AUC 为 0.750)和轻量级梯度提升(训练集 AUC 为 0.810)表现最佳
Ribeiro 等 ^[36]	2024	在葡萄牙圣玛丽亚医院 ECMO 中心接受 ECMO 治疗的 81 例新型冠状病毒感染成人患者	随机森林、支持向量机	实时预测临床恶化或改善趋势	随机森林表现最佳(AUC: 4 h 为 0.918, 8 h 为 0.894, 12 h 为 0.856)
Kresoja 等 ^[37]	2024	417 例接受 VA-ECMO 治疗的急性心肌梗死并发心源性休克患者	XGBoost	预测 30 d 死亡风险	训练集: AUC 为 1.000 验证集: AUC 为 0.800(95%CI 为 0.710 ~ 0.890), 敏感度为 95%(95%CI 为 0.880 ~ 1.000), 特异度为 55%(95%CI 为 0.400 ~ 0.690), 阳性预测值为 65%, 阴性预测值为 92%
Leng 等 ^[38]	2024	2016 年 6 月至 2022 年 4 月在美国约翰斯·霍普金斯医院接受 VV-ECMO 治疗的 99 例患者	随机森林、CatBoost、轻量级梯度提升和 XGBoost	预测神经学结局	XGBoost 表现最佳(AUC 为 0.870, Brier 评分为 0.250, 准确率为 80.0%, 精确度为 71.0%, 召回率为 81.0%, 阳性预测值为 0.860)
Deng 等 ^[39]	2025	中国体外生命支持学会注册数据库(来自中国 112 家 ECMO 中心)及在中国人民解放军总医院第七医学中心、郑州大学附属儿童医院接受 ECMO 治疗的 1 787 例儿科患者	神经网络、广义线性模型、随机森林、决策树、支持向量机、AdaBoost、朴素贝叶斯、梯度提升、轻量级梯度提升、XGBoost	预测脑损伤发生风险	随机森林表现最佳[训练集: AUC 为 0.912(95%CI 为 0.871 ~ 0.953), Brier 评分为 0.108, 敏感度为 70.0%, 特异度为 90.0%, 阳性预测值为 96.3%, 阴性预测值为 44.3%; 验证集: AUC 为 0.807(95%CI 为 0.714 ~ 0.899), 敏感度为 83.0%, 特异度为 63.0%]

注: AI 为人工智能, ECMO 为体外膜肺氧合, VA-ECMO 为静脉-动脉 ECMO, AUC 为受试者工作特征曲线下面积, ELSO 为国际体外生命支持组织, XGBoost 为极端梯度提升, AdaBoost 为自适应提升, Brier 评分为概率预测准确性评分, VV-ECMO 为静脉-静脉 ECMO, 95%CI 为 95% 置信区间, CatBoost 为类别特征提升

更高的精度和适应性,但也面临着训练时间长、计算资源需求高等挑战。值得注意的是,这两种方法并非相互排斥,而是可以根据实际需求进行选择或结合。在 ECMO 患者风险评估模型中,传统模式适用于简单的风险评估,而在需要高精度或实时监控的

复杂临床环境中, AI 技术则可能展现出更大优势。因此,了解这两种方法在各个维度上的差异,有助于在实际应用中做出更加合理的技术选择,最终选择应基于任务需求、数据类型、可用计算资源等多方面因素。

表 3 传统模式与人工智能(AI)技术在 ECMO 患者风险评估中的比较

比较维度	传统模式	AI 技术
理论基础	传统的统计学方法	机器学习与深度学习
数据需求	简单、结构化数据	大规模、多维、复杂数据
准确度	适合简单场景,准确度有限	适合复杂场景,准确度较高
适应性	对新数据适应性较差	对新数据适应性较好
鲁棒性	抗干扰能力较差	抗干扰能力较好
可解释性	简单易懂理解	复杂,可解释性差
实时性	静态评估	动态更新与实时监控
计算资源	要求低,适合资源有限的环境	要求高,需要强大的硬件支持
训练时间	短	长

3 未来发展方向与挑战

3.1 多中心、前瞻性研究的推进:多中心合作有助于整合来自不同地区和临床环境的患者数据,从而提高模型的普适性和外部验证能力。此外,前瞻性研究相较于回顾性研究,能够提供实时、精准的数据,减少偏倚,并能够更好地捕捉治疗过程中动态变化的信息,提高 ECMO 患者风险评估模型的准确率,确保其在不同临床环境下的适用性。

3.2 模型效能的外部验证与标准化:模型的外部验证是确保其在不同医院及地区具有普适性和稳定性的重要手段。研究者需通过外部验证评估模型的泛化能力,从而有效避免过拟合现象的发生。此外,未来的研究需关注数据采集和处理过程中的标准化,减少因数据差异带来的偏倚,有助于不同机构研究结果之间的有效比较,推动模型的广泛应用。

3.3 长期预后的关注:长期预后在临床治疗中具有至关重要的意义,不仅直接关系到患者的生存状况,还对患者的康复质量和生活水平具有深远影响。目前,针对 ECMO 患者的风险评估模型大多聚焦于短期治疗效果的评估,较少关注患者的长期预后。未来的研究需更加注重患者的长期预后,特别是脱机后的生存质量、并发症发生率、长期功能障碍等方面的评估。同时,患者的心理健康状况也应纳入考量,推动建立更加全面、精准的长期预后评估体系。

3.4 创新技术的融合:大数据与 AI 的广泛应用是未来发展的必然趋势。研究者应从临床需求出发,注重算法创新,解决实际问题。在 ECMO 患者风险评估领域,尽管深度学习、卷积神经网络等先进机器学习技术尚未得到广泛应用,但这些技术在重症监护领域已展现出广泛应用场景,相关研究可为 ECMO 患者的风险评估提供参考。为了突破传统静态数据的局限性,研究者还可开发基于时间序列分析的动

态预测模型,结合长短期记忆网络和强化学习算法,实现对病情变化的实时预警。此外,未来的研究还可通过融合传统的生理参数、影像学数据、基因组数据、病理报告等多模态数据,为 ECMO 患者风险评估提供更丰富的信息资源。

3.5 增强模型的可解释性:增强模型的可解释性是提高临床医生信任并推动 AI 技术在医疗领域广泛应用的关键因素。当前许多 AI 技术的可解释性仍然存在不足,限制了医生对模型的理解与信任。未来研究者需致力于开发更加透明的算法和工具,揭示影响预测结果的关键因素,并提供可视化或易于理解的解释方式,帮助医生判断模型的准确性,增强 AI 技术在临床实践中的应用效果,改善患者的治疗效果和安全性。

3.6 经济成本效益分析:ECMO 作为一种高成本、高资源消耗的治疗手段,其经济效益评估将成为患者管理和医疗资源合理分配的关键。在 ECMO 患者风险评估模型的开发过程中,研究者除关注临床效果外,还需加强对经济成本效益的分析,具体包括对 ECMO 治疗过程中涉及的设备、药物、护理、人力资源及长期成本(如并发症管理、住院费用)的评估。经济学评估有助于医疗决策者衡量 ECMO 治疗的性价比,从而优化资源配置,合理利用 ECMO 设备和治疗手段,使临床与社会效益最大化。

4 总结

随着 ECMO 技术在危重症医学领域的广泛应用,接受 ECMO 治疗患者的风险评估模型研究得到了迅速发展。尽管基于传统统计学方法的风险评估模型在早期风险评估中具备一定的临床应用价值,但其在计算效率、处理复杂非线性关系及模型泛化能力方面存在一定局限性。随着信息化时代的到来,AI 技术凭借其卓越的数据处理和模式识别能力,为接受 ECMO 治疗患者的风险评估开辟了新的研究方向。AI 技术的引入,使得医疗团队能更加精准地评估患者健康状况,制定个体化治疗方案,不仅为危重症患者提供了更高的治愈希望,也在提高整体医疗效率、降低病死率等方面展现出巨大的潜力。

利益冲突 所有作者声明不存在利益冲突

参考文献

- [1] 樊毫军,李文莉,哈力旦·阿布都,等.体外膜肺氧合在院外急救救援现场和转运后送中的应用[J].中华灾害救援医学,2021,9(8):1157-1161. DOI: 10.13919/j.issn.2095-6274.2021.08.005.
- [2] 盖玉彪,郭小靖,辛晨,等. ECMO 快速反应团队的建立和管理实践[J].中华危重病急救医学,2021,33(3):349-351. DOI: 10.3760/cma.j.cn121430-20201010-00663.

- [3] Extracorporeal Life Support Organization (ELSO) Member Centers Group. Extracorporeal Life Support Organization registry international report 2022: 100,000 survivors [J]. ASAIO J, 2024, 70 (2): 131-143. DOI: 10.1097/MAT.0000000000002128.
- [4] 郑晓博, 赵中秋, 赖巍, 等. 体外膜肺氧合临床研究进展 [J]. 西南医科大学学报, 2025, 48 (5): 451-455.
- [5] 郭小靖, 盖玉彪, 王伟, 等. 体外膜肺氧合患者抗凝及出血风险管理的最佳证据总结 [J]. 中华危重病急救医学, 2023, 35 (9): 963-967. DOI: 10.3760/cma.j.cn121430-20221018-00926.
- [6] Beam AL, Kohane IS. Big data and machine learning in health care [J]. JAMA, 2018, 319 (13): 1317-1318. DOI: 10.1001/jama.2017.18391.
- [7] Collins GS, Reitsma JB, Altman DG, et al. Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): the TRIPOD statement [J]. BMJ, 2015, 350: g7594. DOI: 10.1136/bmj.g7594.
- [8] 吕丽琼, 郭米霞, 张诗. 血栓形成综合征风险预测模型的研究进展 [J]. 护理研究, 2024, 38 (6): 1023-1025. DOI: 10.12102/j.issn.1009-6493.2024.06.014.
- [9] Debray TP, Damen JA, Snell KI, et al. A guide to systematic review and meta-analysis of prediction model performance [J]. BMJ, 2017, 356: i6460. DOI: 10.1136/bmj.i6460.
- [10] 曹煜隆, 单娇, 龚志忠, 等. 个体预后与诊断预测模型研究报告规范——TRIPOD 声明解读 [J]. 中国循证医学杂志, 2020, 20 (4): 492-496. DOI: 10.7507/1672-2531.201912032.
- [11] 徐青, 余冰, 周佩敏, 等. 基于机器学习与 SHAP 的全膝关节置换术患者下肢深静脉血栓可解释性预测模型构建研究 [J]. 中国医院统计, 2024, 31 (1): 11-18, 24. DOI: 10.3969/j.issn.1006-5253.2024.01.003.
- [12] Wong J, Taljaard M, Forster AJ, et al. Addition of time-dependent covariates to a survival model significantly improved predictions for daily risk of hospital death [J]. J Eval Clin Pract, 2013, 19 (2): 351-357. DOI: 10.1111/j.1365-2753.2012.01832.x.
- [13] 陈俊杉, 余金甜, 赵思雨, 等. ICU 患者谵妄风险预测模型研究进展 [J]. 护理学报, 2019, 26 (5): 15-19. DOI: 10.16460/j.issn.1008-9969.2019.05.015.
- [14] 杨茂凡, 周会兰, 陈柯宇, 等. 危重病人再喂养综合征风险预测模型的研究进展 [J]. 护理研究, 2024, 38 (22): 4057-4060. DOI: 10.12102/j.issn.1009-6493.2024.22.017.
- [15] Bonnett LJ, Snell KIE, Collins GS, et al. Guide to presenting clinical prediction models for use in clinical settings [J]. BMJ, 2019, 365: i737. DOI: 10.1136/bmj.i737.
- [16] Wang JF, Yuan TW, Ding HB, et al. Development and external validation of a prognostic model for survival of people living with HIV/AIDS initiating antiretroviral therapy [J]. Lancet Reg Health West Pac, 2021, 16: 100269. DOI: 10.1016/j.lanwpc.2021.100269.
- [17] Pappalardo F, Pieri M, Greco T, et al. Predicting mortality risk in patients undergoing venovenous ECMO for ARDS due to influenza A (H1N1) pneumonia: the ECMOnet score [J]. Intensive Care Med, 2013, 39 (2): 275-281. DOI: 10.1007/s00134-012-2747-1.
- [18] Schmidt M, Zogheib E, Rozé H, et al. The PRESERVE mortality risk score and analysis of long-term outcomes after extracorporeal membrane oxygenation for severe acute respiratory distress syndrome [J]. Intensive Care Med, 2013, 39 (10): 1704-1713. DOI: 10.1007/s00134-013-3037-2.
- [19] Schmidt M, Bailey M, Sheldrake J, et al. Predicting survival after extracorporeal membrane oxygenation for severe acute respiratory failure. The respiratory extracorporeal membrane oxygenation survival prediction (RESP) score [J]. Am J Respir Crit Care Med, 2014, 189 (11): 1374-1382. DOI: 10.1164/rccm.201311-2023OC.
- [20] Schmidt M, Burrell A, Roberts L, et al. Predicting survival after ECMO for refractory cardiogenic shock: the survival after veno-arterial-ECMO (SAVE)-score [J]. Eur Heart J, 2015, 36 (33): 2246-2256. DOI: 10.1093/eurheartj/ehv194.
- [21] Hilder M, Herbstreit F, Adamzik M, et al. Comparison of mortality prediction models in acute respiratory distress syndrome undergoing extracorporeal membrane oxygenation and development of a novel prediction score: the Prediction of survival on ECMO therapy-score (PRESET-Score) [J]. Crit Care, 2017, 21 (1): 301. DOI: 10.1186/s13054-017-1888-6.
- [22] Becher PM, Twerenbold R, Schrage B, et al. Risk prediction of in-hospital mortality in patients with venoarterial extracorporeal membrane oxygenation for cardiopulmonary support: the ECMO-ACCEPTS score [J]. J Crit Care, 2020, 56: 100-105. DOI: 10.1016/j.jccr.2019.12.013.
- [23] Cui LW, Zha YT, Zhang C, et al. Exploration of a nomogram prediction model of 30-day survival in adult ECMO patients [J]. Front Med (Lausanne), 2023, 10: 1062918. DOI: 10.3389/fmed.2023.1062918.
- [24] 王钊, 李根, 冯维静, 等. 体外膜肺氧合治疗急性呼吸窘迫综合征生存预测模型的构建 [J]. 生物医学工程与临床, 2025, 29 (1): 78-86. DOI: 10.13339/j.cnki.sglc.20241220.015.
- [25] Laimoud M, Alanazi M. The validity of SOFA score to predict mortality in adult patients with cardiogenic shock on venoarterial extracorporeal membrane oxygenation [J]. Crit Care Res Pract, 2020, 2020: 3129864. DOI: 10.1155/2020/3129864.
- [26] Kim KI, Lee HS, Kim HS, et al. The pre-ECMO simplified acute physiology score II as a predictor for mortality in patients with initiation ECMO support at the emergency department for acute circulatory and/or respiratory failure: a retrospective study [J]. Scand J Trauma Resusc Emerg Med, 2015, 23: 59. DOI: 10.1186/s13049-015-0135-x.
- [27] Tsai TY, Fan PC, Lee CC, et al. Predicting in-hospital mortality in patients with end-stage renal disease receiving extracorporeal membrane oxygenation therapy [J]. Cardiorenal Med, 2025, 15 (1): 164-173. DOI: 10.1159/000543434.
- [28] 孙雨晴. 机器学习算法在数据挖掘中的应用 [J]. 中国科技信息, 2025 (10): 50-52.
- [29] Andaur Navarro CL, Damen JAAG, Takada T, et al. Protocol for a systematic review on the methodological and reporting quality of prediction model studies using machine learning techniques [J]. BMJ Open, 2020, 10 (11): e038832. DOI: 10.1136/bmjopen-2020-038832.
- [30] Ayers B, Wood K, Gosev I, et al. Predicting survival after extracorporeal membrane oxygenation by using machine learning [J]. Ann Thorac Surg, 2020, 110 (4): 1193-1200. DOI: 10.1016/j.athoracsurg.2020.03.128.
- [31] Abbasi A, Karasu Y, Li C, et al. Machine learning to predict hemorrhage and thrombosis during extracorporeal membrane oxygenation [J]. Crit Care, 2020, 24 (1): 689. DOI: 10.1186/s13054-020-03403-6.
- [32] Loyaga-Rendon RY, Fermin DR, Grayburn RL, et al. Predicting short-term mortality in ECMO-supported patients secondary to decompensated heart failure and acute myocardial infarction using machine learning [J]. J Heart Lung Transplant, 2022, 41 (4, Supplement): S470-S471. DOI: 10.1016/j.healun.2022.01.1189.
- [33] Stephens AF, Seman M, Diehl A, et al. ECMO PAL: using deep neural networks for survival prediction in venoarterial extracorporeal membrane oxygenation [J]. Intensive Care Med, 2023, 49 (9): 1090-1099. DOI: 10.1007/s00134-023-07157-x.
- [34] Braun J, Sahli SD, Spahn DR, et al. Predicting survival for veno-arterial ECMO using conditional inference trees: a multicenter study [J]. J Clin Med, 2023, 12 (19): 6243. DOI: 10.3390/jcm12196243.
- [35] Lee H, Song MJ, Cho YJ, et al. Supervised machine learning model to predict mortality in patients undergoing venovenous extracorporeal membrane oxygenation from a nationwide multicenter registry [J]. BMJ Open Respir Res, 2023, 10 (1): e002025. DOI: 10.1136/bmjresp-2023-002025.
- [36] Ribeiro F, Barata C, Ribeiro J, et al. Real time automatic risk prediction in ICU patients treated with ECMO [J]. Annu Int Conf IEEE Eng Med Biol Soc, 2024, 2024: 1-4. DOI: 10.1109/EMBC53108.2024.10781497.
- [37] Kresoja KP, Zweymer U, Akin I, et al. Identifying prognostic factors in patients with cardiogenic shock undergoing VA-ECMO treatment: insights from ECLS-SHOCK using machine learning [J]. Eur Heart J, 2024, 45 (Suppl 1): ehae666.1246. DOI: 10.1093/eurheartj/ehae666.1246.
- [38] Leng A, Shou B, Liu O, et al. Machine learning from veno-venous extracorporeal membrane oxygenation identifies factors associated with neurological outcomes [J]. Lung, 2024, 202 (4): 465-470. DOI: 10.1007/s00408-024-00708-z.
- [39] Deng BX, Zhao Z, Ruan TC, et al. Development and external validation of a machine learning model for brain injury in pediatric patients on extracorporeal membrane oxygenation [J]. Crit Care, 2025, 29 (1): 17. DOI: 10.1186/s13054-024-05248-9.
- [40] EOLIA Trial Group, REVA, ECMOnet. Extracorporeal membrane oxygenation for severe acute respiratory distress syndrome [J]. N Engl J Med, 2018, 378 (21): 1965-1975. DOI: 10.1056/NEJMoa1800385.
- [41] Morisson L, Duceau B, Do Rego H, et al. A new machine learning algorithm to predict veno-arterial ECMO implantation after post-cardiotomy low cardiac output syndrome [J]. Anaesth Crit Care Pain Med, 2023, 42 (1): 101172. DOI: 10.1016/j.accpm.2022.101172.
- [42] Wang S, Wang LS, Du ZT, et al. Phenotyping refractory cardiogenic shock patients receiving venous-arterial extracorporeal membrane oxygenation using machine learning algorithms [J]. Rev Cardiovasc Med, 2024, 25 (8): 303. DOI: 10.31083/j.rcm2508303.

(收稿日期: 2025-06-04)
(本文编辑: 孙茜 马英)