

• 综 述 • doi:10.3969/j.issn.1671-8348.2025.05.032

网络首发 [https://link.cnki.net/urlid/50.1097.R.20250423.1417.005\(2025-04-23\)](https://link.cnki.net/urlid/50.1097.R.20250423.1417.005(2025-04-23))

基于机器学习算法的心脏外科术后谵妄风险 预测模型的研究进展*

陈晶立¹, 耿 丽^{2△}

(1. 武汉科技大学医学院, 武汉 430065; 2. 武汉科技大学附属武汉亚洲心脏病医院/
职业危害识别与控制湖北省重点实验室, 武汉 430022)

[摘要] 术后谵妄(POD)作为心脏外科术后高发的急性神经系统并发症,因其与住院时间延长、功能恢复延迟及死亡率升高等不良结局明显相关,已成为围手术期管理的核心挑战。随着医疗数据规模的扩大和人工智能技术的进步,基于机器学习的 POD 风险预测模型凭借其高效整合多维度数据和解析复杂非线性关系的优势,为 POD 早期识别与干预提供了新路径。现有研究表明,监督学习与集成算法通过特征筛选及权重优化可明显提升预测性能,但模型构建仍面临数据异质性高、样本偏差等挑战。尽管外部验证是推动模型临床转化的关键环节,但跨中心数据共享壁垒与隐私保护问题制约了其实际应用。此外,当前研究普遍存在模型可解释性不足、实时预测滞后及临床适配性有限等缺陷。该文通过系统梳理机器学习在心脏外科 POD 风险预测中的应用进展、应用潜力与局限性,为构建精准化、个体化的围手术期风险管理体系提供多维度理论支撑,旨在促进临床决策系统升级、改善患者预后并实现医疗资源的智能化配置。

[关键词] 机器学习;心脏外科;术后谵妄;预测模型

[中图分类号] R655

[文献标识码] A

[文章编号] 1671-8348(2025)05-1225-05

Advances in predictive modeling of postoperative delirium risk in cardiac surgery based on machine learning algorithms*

CHEN Jingli¹, GENG Li^{2△}

(1. School of Medicine, Wuhan University of Science And Technology, Wuhan, Hubei 430065,
China; 2. Wuhan Asian Heart Hospital, Affiliated to Wuhan University of Science and
Technology/Key Laboratory of Occupational Hazard Identification and Control in
Hubei Province, Wuhan, Hubei 430022, China)

[Abstract] Postoperative delirium (POD), as a highly prevalent acute neurological complication after cardiac surgery, has become a key challenge in perioperative management as it is significantly associated with adverse outcomes such as prolonged hospital stay, delayed functional recovery and increased mortality. With the expansion of medical data scale and the advancement of artificial intelligence technology, machine learning-based POD risk prediction models, with their advantages of efficiently integrating multi-dimensional data and analysing complex non-linear relationships, provide a new avenue for early detection and intervention of POD. Existing studies have shown that supervised learning and integration algorithms can significantly improve prediction performance through feature screening and weight optimisation, but model construction still faces challenges such as high data heterogeneity and sample bias. Although external validation is a key link to promote clinical translation of models, barriers to inter-centre data sharing and privacy issues limit their practical application. In addition, current research generally suffers from shortcomings such as insufficient model interpretability, real-time prediction delay, and limited clinical adaptability. This article systematically reviewed the application progress, potential, and limitations of machine learning in predicting POD risks in cardiac surgery, providing multidimensional theoretical support for building a precise and personalized perioperative risk management system. The aim is to promote the upgrading of clinical decision-making systems, improve patient prognosis, and achieve intelligent allocation of medical resources.

[Key words] machine learning; cardiac surgery; delirium; prediction model

《中国心血管健康与疾病报告 2022》显示,我国冠 状动脉疾病(coronary artery disease, CAD)现有患者

数约 3.3 亿,伴随着患病率的升高和医疗技术的发展,越来越多的心血管疾病患者接受了心脏外科手术治疗^[1]。术后谵妄(postoperative delirium, POD)是手术后出现的一种急性脑功能障碍,以意识改变、情绪障碍及注意力不集中等为主要表现^[2],据报道心脏外科术后患者 POD 发生率为 18%~42%^[3],一旦患者发生 POD,会延长住院时间、降低生活质量,甚至增加患者死亡率。研究表明,对 POD 危险因素进行全面评估和有效干预,可预防 30%~40% 的 POD^[4]。风险预测模型是用数学公式来评估特定受试者当前患某种疾病或未来一段时间内发生某个临床结局的概率^[5],准确的风险预测是发现高危人群、提高成本效益的重要手段^[6]。本文通过对基于机器学习算法的心脏外科 POD 风险预测模型进行综述,旨在为医务人员制订心脏外科 POD 风险管理策略提供参考。

1 机器学习算法的概念及分类

机器学习算法是通过计算机,利用不同计算方法分析数据,通过学习挖掘数据中存在的潜在联系,训练出一个有效模型应用于决定或预测^[7],主要包括监督学习、半监督学习、无监督学习、强化学习和迁移学习^[8]。机器学习在过去近 40 年的发展中,已作为一门独立的研究方向,在疾病预测、疾病辅助诊断、疾病预后评估等医疗领域应用广泛^[9]。伴随着运用场景的增多逐步衍生出了多种算法,其中经典算法包括逻辑回归(logistic regression, LR)、人工神经网络(artificial neural network, ANN)、朴素贝叶斯(naive Bayes, NB)、K 近邻分类(K-nearest neighbors, KNN)、决策树(decision tree, DT)、随机森林(random forest, RF)、支持向量机(support vector machine, SVM)等。

2 机器学习在心脏外科手术 POD 风险预测模型中的应用现状

机器学习是研究计算机如何模仿人类的学习行为,获取新的知识或经验,并重新组织已有的知识结构,提高自身表现^[10]。自 20 世纪 50 年代,机器学习便与医学有着紧密的联系^[11-12]。BORTOLUSSI 等^[13]通过用于过程控制的对象链接和嵌入代码对 296 426 例心脏外科手术进行分类,结果显示大多数心脏手术为冠状动脉旁路移植术、主动脉瓣置换术、二尖瓣修复和主动脉手术。近年来,越来越多的研究者为了提高心脏术后患者的 POD 预测率,将机器学习算法运用到心脏外科手术后 POD 风险预测中,并努力寻找最佳的机器算法构建准确率高、稳定性好、适应范围广、可解释性强的预测模型。但不同的心脏疾病和手术方式对发生 POD 的影响因素并不相同, LITVINENKO 等^[14]发现在瓣膜疾病中,瓣膜假体位置和瓣膜类型都会影响包括 POD 在内的脑功能障碍的发生率,而目前大多数 POD 风险预测模型开发者忽略了这一问题。

2.1 机器学习在心脏瓣膜置换术 POD 风险预测模型中的应用

心脏瓣膜置换术是瓣膜病常见的外科治疗手段,体外循环是实施心脏瓣膜置换术的重要前提^[15],在体外循环开始后,可因长时间细胞缺氧、炎症反应等多重因素的共同作用,导致 POD 发生。据报道,体外循环下心脏瓣膜置换术后 POD 发生率为 10%~53%^[16-17]。将不同机器学习与瓣膜术后患者 POD 发生风险因素结合,有利于医疗资源的合理分配和临床决策的快速判断。MUFTI 等^[18]以 5 584 例瓣膜置换手术和冠状动脉搭桥患者为研究对象,开发了心脏手术患者 POD 风险预测模型,比较了 ANN 和贝叶斯网络(Bayesian network, BN)两种机器学习算法与 LR 模型,在预测 POD 发生时的灵敏度和特异度,其结果显示三者特异度均较好(ANN 为 95.8%, BN 为 93.3%, LR 模型为 97.7%),但在灵敏度方面, ANN (27.5%)和 BN(37.0%)明显优于 LR 模型(8.6%)。LI 等^[19]首次以 507 例单纯心脏瓣膜术后患者为研究对象,利用 7 种机器算法分别构建了基于完整数据集和特征集的风险预测模型,所有模型中 RF 模型在查全率和准确性方面表现突出,且有出色的实际应用潜力,该研究构建的风险预测模型可为 POD 早期诊断和早期干预提供参考依据,也在一定程度上减轻了医护人员的工作负担,提高了医护人员对 POD 患者的护理管理能力,但该模型未进行外部验证,模型能否运用到其他医疗机构或其他研究对象仍有待验证。虽然 MUFTI 等^[18]和 LI 等^[19]的研究都证实了机器学习在 POD 风险中的预测效能,但医务人员不能完全依赖模型,应在模型的辅助下客观地评估并及时做出准确的判断。

2.2 机器学习在心脏大血管手术 POD 风险预测模型中的应用

心脏大血管手术后常因手术方式、特殊药物使用、个体身体状态等多因素影响而诱发多种并发症, POD 作为术后常见脑部并发症之一,发生率高达 26%~52%^[20]。术后并发症的管理是保证患者快速康复的有效环节, POD 发生机制尚不明确,且影响因素众多,传统的统计方法已不能满足 POD 的风险预测需求,机器学习的出现为 POD 预测提供了新视角,通过机器学习构建的 POD 风险预测模型可分析多种潜在的风险因素,提高 POD 预测准确性和灵敏度,有助于医疗团队尽早为患者提供个性化的干预方案。陈浩^[21]回顾性收集了 145 例 Stanford A 型主动脉夹层患者部分数据信息,以 LR、KNN、SVM、RF、梯度提升机、全连接神经网络构建包括 POD 在内的术后脑部并发症的模型,在所有模型中, RF 模型整体性能表现最佳,又通过 HL 拟合度对模型检验,结果显示 RF 构建模型的预测概率与真实概率间有较好的一致性。NOWAKOWSKA 等^[22]以 224 例择期行冠状动脉搭桥术的患者为研究对象,利用 Ada Boost、RF、极限梯度提升树(eXtreme Gradient Boosting, XG Boost)共 3 种机器算法,首次开发了一个可解释的人工智能授权的管道用于预测冠状动脉搭桥术患者的

抑郁和 POD 发生风险。研究结果显示,极限梯度增强树模型在 POD 预测中表现出较高的准确率(72%)。陈浩^[21]和 NOWAKOWSKA 等^[22]的研究均利用单一疾病患者作为研究对象,构建的模型结构简单,易于理解和解释,也更利于捕捉到特异性疾病的核心风险因素,但在构建模型时应考虑预测框架的全面性,防止模型过于简化而无法充分反映临床实际的复杂性,且两项研究均不属于 POD 的特异性模型,在未来研究中,可根据单一病种进行 POD 的特异性模型构建并验证。

2.3 机器学习在多种心脏外科手术 POD 风险预测模型中的应用

随着大数据和人工智能的发展,机器学习已成为心脏外科术后并发症预测的强有力工具,利用机器学习算法构建的风险预测模型提高了 POD 预测率,推动了心脏外科手术 POD 护理的个性化和精准化。NAGATA 等^[23]收集 87 例心脏外科手术的 38 项术前因素和 10 项术中因素,利用 5 种机器算法构建了包括活动减退型谵妄在内的风险预测模型,并与 LR 模型比较。在该研究中,极度随机树构建模型的受试者工作特征曲线下面积最高(0.76),对真阳性患者的准确预测率达 63%,XG Boost 灵敏度最高,相较于机器学习算法,LR 模型的评价指标均较低,但研究样本量过少,各模型质量有待进一步验证。YANG 等^[24]以 367 例心脏术后患者指标包括患者一般特征、实验室检查结果、手术类型、术后住院时间等在内的 21 项风险因素为数据集,利用 RF、SVM、径向基神经网络、KNN、核岭回归 5 种机器算法构建的风险因素模型中,RF 在各方面性能均表现出较好的结果,KNN 构建模型性能最差。左都坤等^[25]以 684 例择期全身麻醉下行开胸的心脏手术患者为对象,比较了 XG Boost 和 LR 构建的心脏手术 POD 风险预测模型,结果显示 LR 受试者工作特征曲线下面积为 0.732(95%CI: 0.430~1.000),高于 XG Boost 的 0.659(95%CI: 0.559~0.759),而 XG Boost 灵敏度(67%)高于 LR (50%),说明 LR 在预测 POD 的准确性和预测效能上表现更好,XG Boost 算法构建的预测模型在灵敏度及对阳性标本的识别能力上效果更佳,这与 MUFTI 等^[18]的研究结果一致,均证明了机器算法在 POD 预测灵敏度上优于 LR。但在左都坤等^[25]的研究中,只运用一种机器学习算法与 LR 法构建风险预测模型相比较,在人工智能高速发展的今天,只运用一种机器学习算法已衍生了多种方法,不同算法的准确率、精准度各不相同,一种算法并不能说明所有机器算法在某个模型中的应用效果。

在多项研究中,RF、XG Boost 都表现出了良好的预测能力^[17,21,22,24-25],其原因可能是 RF、XG Boost 是以不同单一分类器为基础的集成算法,每个基础分类器都是一个独立个体,这种个体差异性确保集成算法的多样性,有效降低了单一模型可能产生的偏倚风险,提高了模型的准确性和稳定性。同时,集成算法

还可根据数据特征有计划地更新或添加新的基础分类器,通过集中组合多个基础分类器的优势,更能有效防止过拟合事件发生,还可提高模型的适应性。总体而言,虽然不同算法构建的模型性能参差不齐,但从整体结果来看,机器学习构建的模型在预测真阳性和真阴性率上比 LR 更胜一筹,集成算法构建的模型性能优于单一算法构建的模型。

3 基于机器学习算法的风险预测模型构建及验证步骤

风险预测模型构建包括确立研究问题、选择数据来源、筛选预测变量、处理预测变量、拟合预测模型、评估预测模型、呈现预测模型、报告研究结果 8 个步骤^[26],其中数据集的数量和质量决定模型的准确性和可靠性,模型性能的评估和优化利于提高模型的预测能力和适应性。

3.1 数据集来源

现有研究中,纳入数据大多由研究者个人或团队通过循证形成初稿,经专家审阅并与临床知识合并后,对初稿修订改进形成终稿,且数据大多来自单中心回顾性研究,以此构建的风险预测模型的外推性和适用性有待进一步商榷。数据库是一种用于存储、组织、检索和管理数据的系统,自 20 世纪 60 年代中期,第 1 个数据库管理系统诞生以来,数据库几乎涵盖了所有行业^[27]。MUFTI 等^[28]利用机器学习算法开发并验证了心脏手术术后躁动性谵妄的风险模型,研究数据来源于海事心脏中心,该中心登记了自 1995 年 3 月以来的所有心脏手术病例,其研究变量达 500 多个。国外数据库建库较早且数据相对完整,随着我国人口老龄化和心血管疾病患者的不端攀升,为了真实数据的收集同时挖掘有价值的关系,国内也成立了多个数据库,如 2015 年国家卫生健康委员会医政医管局建立了全国医疗质量数据抽样调查系统^[29]。2019 年 6 月,国家放射与治疗临床医学研究中心与心血管健康联盟共同发起心脏瓣膜病介入中心(简称“瓣膜中心”)建设,搭建了国家经导管瓣膜治疗数据库。上海市胸科医院为了实现专病管理,建立了先天性心脏病专病数据库^[30]。上海儿童医学中心心胸外科也于 2006 年建立了儿童先天性心脏病数据库^[31]等。虽然我国数据库建立较晚,但研究者利用国内数据库构建的相关风险模型更适用于我国患者。未来研究中,可将机器算法与部分数据库结合,利用庞大的原始数据库构建并验证具体疾病的特异性 POD 风险预测模型,可大大缩短数据收集的时间,加快模型构建进度,提升模型预测效能。

3.2 模型优化、评估与验证

机器学习作为人工智能的核心技术,为各类疾病的风险预测模型构建带来了新的机遇,利用机器学习构建的风险预测模型正与日俱增,随着模型数量的不断增加,所面临的问题也逐渐显现,如模型开发多、验证少、噱头大、质量低等^[32]。面对同一疾病构建的不同风险预测模型,如何评估模型性能、如何选择最合

适的模型进行风险预测尤为重要^[33]。为了确保模型能在未知数据中的预测性能,构建后的模型需要经过优化、评估和验证的多次迭代,最终找到泛化能力强的模型,模型优化可通过参数调整、机构或算法更改实现,模型评估常用准确率、精确率、召回率、F1 分数等评估指标进行。模型验证是检测模型稳定性和外推性重要的一部分,根据评估队列与构建队列所用数据来源分为内部验证和外部验证,内部验证检验模型的可重复性,常用的方法包括随机拆分验证、交叉验证、Bootstrap 法、“内部-外部”交叉验证法。外部验证评价模型的可移植性,根据验证数据来源可分为时段验证、空间验证、和领域验证^[26]。模型优化、评估与验证三者相互关联的,共同作用提高了模型的性能和泛化能力。

4 启示

4.1 未来趋势

随着数字信息化的不断发展,风险预测模型不能仅仅停留在开发阶段,将模型与临床实际结合,让模型真正预测疾病风险,才能发挥模型最大价值。HATA 等^[34]开发的一种便携式脑电图设备使用了术前脑电图数据和机器学习算法的组合方式,可在 2 min 内采集脑电图数据,通过机器学习算法自动分析、快速筛选,用于预测心脏手术患者 POD 发生的危险程度,为 POD 的预测提供了新的思路。和传统脑电图相比,与机器学习算法结合的便携式脑电图设备能扩大患者适用范围,提高 POD 高危人群的识别率,并通过强化术前干预降低谵妄发生风险。XUE 等^[35]通过建立一个基于放射组学的机器学习框架来预测接受心脏手术患者急性肾损伤诱发的 POD,该方法为一种基于机器学习的定量方法,为心脏手术术后高危患者的风险管理提供了有效的临床决策。未来在心脏外科 POD 预测模型应用过程中,不断优化算法和扩大数据集,进一步提高预测的准确性和可靠性,有利于促进患者临床结局的转归。HAN 等^[36]利用机器学习将手术中的生物信号数据与临床结合,开发了以太坊名称服务模型来预测心脏手术 POD,这也是首个使用机器学习算法通过模拟术中血流动力学波动来预测 POD 的研究。越来越多的研究者致力于将模型与临床实际相结合,其目的都是为了能准确预测 POD 发生,提高患者生存质量、降低医疗成本。

4.2 存在不足

有研究指出,运用机器学习算法构建相关风险预测模型时,所需样本量一般为纳入指标的 10~20 倍,但在实际构建中,较多研究的样本量未达标^[37]。在数据收集方面,目前国内尚无统一的心脏外科术后并发症相关数据资料收集库,部分单中心研究虽已有自己的资料收集库,但各中心之间无统一收集标准,无法实现多中心数据资源联动共享,且数据多采用单中心回顾性方法进行收集,模型预测性能或因护理、环境等的差异性而产生不同的预测结果。另外,现阶段的风险预测模型仍处于“大多被构建、少数被验证、极少

被应用”的局面,利用风险预测模型处理临床实际问题也是亟待解决的问题之一。

5 总结

POD 作为心脏外科术后常见的神经系统并发症之一,其影响因素众多、发病机制尚不明确。基于机器学习算法构建的 POD 风险预测模型可提高临床医护人员对 POD 风险的预测率,给予早期预防及干预措施,降低心脏 POD 的发生率,但不同的机器学习算法在风险预测模型应用中各有优劣。应根据样本量、研究目的、各个算法的优缺点等进行综合评估,以选择最佳的算法进行模型构建。此外,目前大多数风险预测模型的构建基于单中心回顾性研究,且仅停留在模型构建方面,在今后的模型开发时可考虑多中心、前瞻性研究,同时将模型进行外部验证,更有利于模型与临床应用的有效结合。

参考文献

- [1] 胡盛寿,王增武.《中国心血管健康与疾病报告 2022》概述[J]. 中国心血管病研究,2023,21(7): 577-600.
- [2] CHANQUES G, ELY E W, GARNIER O, et al. The 2014 updated version of the confusion assessment method for the intensive care unit compared to the 5th version of the diagnostic and statistical manual of mental disorders and other current methods used by intensivists[J]. Ann Intensive Care, 2018, 8(1): 33.
- [3] 陈瑜,邢红叶,许兆军,等. ABCDEF 集束化护理策略对心脏外科术后谵妄发生率和持续时间的影响[J]. 中华全科医学, 2023, 21(4): 709-712.
- [4] YOUNG J, MURTHY L, WESTBY M, et al. Guideline Development Group. Diagnosis, prevention, and management of delirium: summary of NICE guidance[J]. BMJ, 2010, 341: c3704.
- [5] VICKERS A J, HOLLAND F. Decision curve analysis to evaluate the clinical benefit of prediction models[J]. Spine J, 2021, 21(10): 1643-1648.
- [6] PENG L, WEIGL K, BOAKYE D, et al. Risk scores for predicting advanced colorectal neoplasia in the average-risk population: a systematic review and meta-analysis[J]. Am J Gastroenterol, 2018, 113(12): 1788-1800.
- [7] 孔欣然. 机器学习综述[J]. 电子制作, 2019(24): 82-84.
- [8] 朱天元. 机器学习算法在数据挖掘中的应用[J]. 数字技术与应用, 2017(3): 166.
- [9] 兰欣,卫荣,蔡宏伟,等. 机器学习算法在医疗领域中的应用[J]. 医疗卫生装备, 2019, 40(3): 93-97.
- [10] 杨剑锋,乔佩蕊,李永梅,等. 机器学习分类问题

- 及算法研究综述[J]. 统计与决策, 2019, 35(6): 36-40.
- [11] GBD 2021 Stroke Risk Factor Collaborators. Global, regional, and national burden of stroke and its risk factors, 1990—2021: a systematic analysis for the Global Burden of Disease Study 2021[J]. *Lancet Neurol*, 2024, 23(10): 973-1003.
- [12] ROSENBLATT F. The perceptron: a probabilistic model for information storage and organization in the brain[J]. *Psychol Rev*, 1958, 65(6): 386-408.
- [13] BORTOLUSSI G, MCNULTY D, WAHEED H, et al. Identifying cardiac surgery operations in hospital episode statistics administrative database, with an OPCS-based classification of procedures, validated against clinical data[J]. *BMJ Open*, 2019, 9(3): e023316.
- [14] LITVINENKO I V, ODINAK M M, TSYGAN N V, et al. Characteristics of postoperative cerebral dysfunction depending on the type and position of the implanted prosthetic heart valve[J]. *Zh Nevrol Psikhiatr Im S S Korsakova*, 2019, 119(2): 18-22.
- [15] 雷涛, 刘松涛, 沈斌. 体外循环心脏瓣膜置换术后谵妄的危险因素及其交互效应[J]. *广西医科大学学报*, 2023, 40(2): 297-303.
- [16] NEUFELD K J, TIAN J, PROBERT J, et al. Effect of targeting mean arterial pressure during cardiopulmonary bypass by monitoring cerebral autoregulation on postsurgical delirium among older patients: a nested randomized clinical trial[J]. *JAMA Surg*, 2019, 154(9): 819-826.
- [17] ORDÓÑEZ-VELASCO L M, HERNÁNDEZ-LEIVA E. Factors associated with delirium after cardiac surgery: a prospective cohort study[J]. *Ann Card Anaesth*, 2021, 24(2): 183-189.
- [18] MUFTI H N, ABIDI S, ABIDI S R, et al. Predictors of post-operative delirium in cardiac surgery patients; a machine learning approach[J]. *Canadian J Cardiol*, 30(Suppl. 10): 237-238.
- [19] LI Q, LI J, CHEN J, et al. A machine learning-based prediction model for postoperative delirium in cardiac valve surgery using electronic health records[J]. *BMC Cardiovasc Disord*, 2024, 24(1): 56.
- [20] VASILEVSKIS E E, HAN J H, HUGHES C G, et al. Epidemiology and risk factors for delirium across hospital settings[J]. *Best Pract Res Clin Anaesthesiol*, 2012, 26(3): 277-287.
- [21] 陈浩. 基于机器学习方法构建急性 A 型主动脉夹层术后脑部并发症的预测模型[D]. 兰州: 兰州大学, 2023.
- [22] NOWAKOWSKA K, SAKELLARIOS A, KAZMIERSKI J, et al. AI-Enhanced Predictive modeling for identifying depression and delirium in cardiovascular patients scheduled for cardiac surgery[J]. *Diagnostics (Basel)*, 2023, 14(1): 67.
- [23] NAGATA C, HATA M, MIYAZAKI Y, et al. Development of postoperative delirium prediction models in patients undergoing cardiovascular surgery using machine learning algorithms[J]. *Sci Rep*, 2023, 13(1): 21090.
- [24] YANG T, YANG H, LIU Y, et al. Postoperative delirium prediction after cardiac surgery using machine learning models[J]. *Comput Biol Med*, 2024, 169: 107818.
- [25] 左都坤, 吴卓熙, 龙宗泓, 等. 基于机器学习算法构建心脏手术患者术后早期谵妄风险预测模型[J]. *陆军军医大学学报*, 2023, 45(8): 753-758.
- [26] 王俊峰, 章仲恒, 周支瑞, 等. 临床预测模型: 模型的验证[J]. *中国循证心血管医学杂志*, 2019, 11(2): 141-144.
- [27] 侯博学, 陈林. 数据库技术发展研究综述[J]. *软件导刊*, 2024, 23(6): 214-220.
- [28] MUFTI H N, HIRSCH G M, ABIDI S R, et al. Exploiting machine learning algorithms and methods for the prediction of agitated delirium after cardiac surgery: models development and validation study[J]. *JMIR Med Inform*, 2019, 7(4): e14993.
- [29] 国家心血管病医疗质量控制中心专家委员会体外循环与体外生命支持专家工作组. 2021 年体外循环手术与全国灌注师现况调查[J]. *中国体外循环杂志*, 2023, 21(1): 4-9.
- [30] 袁骏毅, 潘常青, 戴锦杰, 等. 基于数据治理的先心病专病数据库建设研究[J]. *中国卫生质量管理*, 2022, 29(2): 77-80.
- [31] 陈茂林, 杜欣为, 陆兆辉, 等. 建立先天性心脏病专科数据库的实践与思考[J]. *中国卫生信息管理杂志*, 2021, 18(5): 691-695.
- [32] 谷鸿秋. 临床预测模型的困境与机遇[J]. *中国卒中杂志*, 2024, 19(5): 481-487.
- [33] 贾玉龙, 周洁, 陈颖, 等. 临床预测模型的综合评价体系研究[J]. *中国卫生统计*, 2019, 36(5): 728-730.
- [34] HATA M, MIYAZAKI Y, NAGATA C, et al. Predicting postoperative delirium after cardiovascular surgeries from preoperative portable electroencephalography oscillations[J]. *Front Psychiatry*, 2023, 14: 1287607.