

基于机器学习的心血管手术患者术后谵妄预测模型的范围综述

史晓普^{1*}, 魏学军²

¹湖州学院生命健康学院, 浙江 湖州

²湖州学院附属南太湖医院重症监护室, 浙江 湖州

收稿日期: 2025年9月19日; 录用日期: 2025年10月17日; 发布日期: 2025年10月28日

摘 要

本研究通过系统分析应用机器学习预测心血管患者术后谵妄的相关文献, 对其预测模型的性能进行了评估。本研究共纳入中、英文文献9篇, 样本量87~4476。分析结果显示, 随机森林模型在众多机器学习算法中预测性能最优, 其AUC值达0.92。术后谵妄预测因子覆盖患者基本资料、术前、术中及术后等多方面因素。机器学习预测模型对术后谵妄的发生具有良好的预测价值, 然而现有研究存在样本量小, 缺乏外部验证及模型可解释性不足等局限性。未来研究需扩大样本量, 选择合理预测特征, 增强模型的可解释性和临床应用价值。

关键词

心血管手术, 术后谵妄, 机器学习, 预测模型, 范围综述

A Scoping Review of Machine Learning-Based Prediction Models for Postoperative Delirium in Cardiovascular Surgery Patients

Xiaopu Shi^{1*}, Xuejun Wei²

¹School of Life and Health Sciences, Huzhou College, Huzhou Zhejiang

²Intensive Care Unit, South Taihu Hospital Affiliated to Huzhou College, Huzhou Zhejiang

Received: September 19, 2025; accepted: October 17, 2025; published: October 28, 2025

*通讯作者。

文章引用: 史晓普, 魏学军. 基于机器学习的心血管手术患者术后谵妄预测模型的范围综述[J]. 护理学, 2025, 14(10): 1959-1966. DOI: 10.12677/ns.2025.1410262

Abstract

This study systematically analyzed the literature on the application of machine learning in predicting postoperative delirium in cardiovascular patients and evaluated the performance of the prediction models. A total of 9 Chinese and English articles were included, with sample sizes ranging from 87 to 4476. The analysis showed that among various machine learning algorithms, the random forest model had the best prediction performance, with an AUC value of 0.92. The predictors for postoperative delirium covered multiple factors, including patient basic information, preoperative, intraoperative, and postoperative factors. Machine learning prediction models have good predictive value for the occurrence of postoperative delirium. However, existing studies have limitations such as small sample sizes, lack of external validation, and insufficient model interpretability. Future research needs to increase the sample size, select appropriate prediction features, and enhance the interpretability and clinical application value of the models.

Keywords

Cardiovascular Surgery, Postoperative Delirium, Machine Learning, Prediction Model, Scoping Review

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 研究背景

术后谵妄(Postoperative Delirium, POD)是指在术后数小时至数天发生的以意识、注意力、感觉、记忆等出现间歇性受损为主要表现的神经认知障碍[1]。在各类手术中,由于手术创伤大、炎性变化剧烈、脑灌注波动大、麻醉药物等的影响,心血管手术 POD 的风险较高[2]。此外,高龄、以及术前存在的认知障碍、抑郁等多种合并症,均是 POD 的重要风险因素[3]。目前对 POD 的判断多依赖临床医生的主观判断及临床病例资料,而主观判断基于临床医生的医疗经验,其判断准确度存在差异[4]。此外,传统的方式很难对各类危险因素进行全面的评估,尤其对于复杂的术后因素评估更是难以覆盖[5][6],从而降低了预测的准确性。

目前,机器学习(Machine Learning, ML)逐渐开始应用在医学领域,且取得了良好的应用效果。与传统的统计学相比,机器学习可以处理复杂的临床资料,挖掘复杂的非线性关系信息,提供精准的个性化预测[7]。研究结果显示,ML 建立的预测模型对冠心病[8],急性肾损伤[9]等具有良好的早期预测效果。

尽管 ML 在预测心血管 POD 方面取得了进展,但也存在一定的局限性。目前研究的多数模型样本量小且缺乏外部验证、限制了其普适性。其次,虽然 ML 模型的预测准确性优于传统方法,但其可解释性不足,限制了其临床应用。由于心血管 POD 的高发生率及严重后果,开发准确、可靠且可解释的 ML 预测模型对于早期识别高危患者、优化围手术期管理及改善预后至关重要。本研究通过对心血管 POD 风险预测模型的文献进行全面分析,以期预测心血管患者 POD 风险提供新思路。

2. 资料与方法

2.1. 检索策略

本研究检索了 PubMed、MEDLINE、PsycINFO、Web of Science 和 Cochrane Library 5 个英文数据库

和知网、万方数据、维普数据库 3 个中文数据库。检索时间从数据库创建至 2025 年 2 月发表的研究。检索使用的中、英文检索词包括：“心血管手术”“术后谵妄”“预测”“机器学习”等，对应的英文检索词为：Cardiovascular surgery、Postoperative delirium、Prediction、Machine learning 等。

2.2. 纳入和排除标准

纳入标准包括：① 心血管外科手术的成年人(≥18 岁)；② 应用 ML 模型预测 POD；③ 研究需在不同患者队列中开发或验证 ML 模型，并提供模型的预测性能数据；④ 研究类型包括前瞻性研究、回顾性研究以及队列研究等；⑤ 提供了所使用的 ML 方法的报道。

排除标准包括：① 研究目的是确定 POD 的风险因素，而非开发或验证预测模型；② 无法获取全文的研究；③ 以英语或中文以外的语言发表的研究；④ 重复发表的研究。

2.3. 数据提取

两名研究者分别独立从纳入研究中提取作者、发表年份、国家、样本量、手术类型、模型构建内容、模型验证评价以及模型性能指标内容。

3. 结果

3.1. 文献检索及筛选结果

初始检索得到 3640 篇文献，其中 1462 篇文献被确认为重复，删除重复文献后剩余 2178 篇文章。删除根据阅读标题和阅读摘标题不符合纳入标准的 2129 篇文章。余下的 49 篇文章中，有 22 篇未关注术后结果、14 篇未使用 ML 模型、4 篇因数据不完整被删除。最终纳入 9 项研究。

3.2. 纳入文献的特征

本研究共纳入 9 篇研究，中国 5 项，加拿大，波兰，韩国，日本各 1 篇。关于研究设计类型，病例对照研究 1 篇、混合设计 1 篇、7 篇是队列研究。发表于 2019~2024 年，其中，英文文献 7 篇[10]-[16]，中文文献 2 篇[17][18]。样本总量为 87~4476 例。纳入文献的基本特征，详见表 1。

Table 1. Basic characteristics of the included studies
表 1. 纳入文献的基本特征

作者,年份	模型类型 (开发/验证)	设计类型	国家	样本量(n) 建模组/验证组	手术类型	谵妄发生率(%) 建模组/验证组
Yang 等[10]	开发模型	回顾性单中心队列研究	中国	367	体外循环冠状动脉旁路移植术、非体外循环冠状动脉旁路移植术、瓣膜置换或修复术、房间隔缺损或室间隔缺损修补术、主动脉置换术及其他手术	28.6% (105/367) 验证组：-
Nowakowska 等[11]	开发模型	前瞻性单中心队列研究	波兰	224	择期冠状动脉旁路移植术、部分合并心脏瓣膜修复或置换	34% (61/224) 验证组：-

续表

Zhao 等[12]	开发 + 验证模型	单中心回顾性队列研究	中国	建模组：885 例 验证组：100 例	体外循环下的心脏手术，包括冠状动脉旁路移植术、瓣膜手术、先心病手术、主动脉手术及联合手术	建模组：25.0% (221/885) 验证组：22.0% (22/100)
Mufti 等[13]	开发 + 验证模型	单中心回顾性队列研究	加拿大	建模组：4476 例 验证组：1117 例	心脏手术(包括冠状动脉旁路移植术、瓣膜置换、联合手术等)	建模组：11.4% (507/4476) 验证组：-
Li 等[14]	开发模型	单中心回顾性队列研究	中国	建模组：405 例 验证组：102 例	体外循环下的心脏瓣膜手术	建模组：28% (113/405) 验证组：28% (29/102)
Nagata 等 [15]	开发模型	单中心前瞻性队列研究	日本	建模组：87 例	冠状动脉旁路移植术、瓣膜手术、升主动脉置换术或微创心脏手术	建模组：27.6% (24/87) 验证组：-
Han 等[16]	开发 + 验证模型	回顾性建模 + 前瞻性验证	韩国	建模组：1912 例 验证组：202 例	心脏手术(包括体外循环与非体外循环)	建模组 13.3% (260/1,912)；验证组 14.4% (29/202)
黄琦等[17]	开发 + 验证模型	前瞻性队列研究	中国	建模组：533 例 验证组：177 例	心脏外科手术	建模组 19.1% (102/533)，验证组 27.7% (49/177)
左都坤[18]	开发 + 验证模型	病例 - 对照研究	中国	建模组：479 例 验证组：205 例	心脏外科手术	建模组：- 验证组：-

3.3. 心血管患者术后 POD 风险预测模型构建及验证

3.3.1. 模型的构建及性能验证

纳入的 9 篇文献中，内部验证 7 篇，外部验证 3 篇。模型构建的机器学习算法涉及随机森林、支持向量机、径向基函数神经网络、最近邻算法、梯度提升树、朴素贝叶斯等多种算法。建模组中，不同的模型在建模组和验证组中的表现不同。从模型性能上看，软投票集成模型最佳，AUC 为 0.977。从模型内部验证的性能上看，以随机森林的模型表现最佳，AUC 为 0.92。见表 2。

3.3.2. 模型的风险预测因子

本研究中所有预测因子主要包括患者一般资料、术前、术中、术后等 4 种因素。研究结果显示，纳入的预测模型中频次最高的预测因子分别为年龄、ASA 分级、术前认知功能、既往病史、体外循环时间、术后 ICU 时间，而随着监测技术的发展，脑氧饱和度、术中血流动力学等术中生物信号特征在研究中展现出重要预测价值。预测因子分布情况如表 2 所示。

Table 2. Model construction and performance verification**表 2.** 模型的构建及性能验证情况

作者,年份	预测因子	验证方式	模型性能	ML 建模方法
			建模组/验证组 (区分度)	
Yang 等[10]	年龄、性别、身高、体重、体质指数、教育水平、吸烟史、饮酒史、视觉障碍、听觉障碍、ASA 分级、心功能分级、高血压病史、糖尿病病史、慢性阻塞性肺疾病病史、房颤病史、颈动脉狭窄病史、术前血红蛋白水平、术前肌酐水平、手术类型、体外循环时间、主动脉阻断时间、麻醉时间、手术持续时间、术后镇静、ICU 停留时间、住院时间等	内部验证	最佳模型: RF 建模组: 0.9202 验证组: —	RF、SVM、RBFNN、KNN、KRR
Nowakowska 等[11]	年龄、性别、教育年限、体重、身高、焦虑障碍、酒精成瘾、糖尿病、高血压、外周动脉疾病、中枢神经系统血管疾病、其他中枢神经系统疾病、哮喘、慢性阻塞性肺疾病、吸烟、贫血、肌酐水平、心房颤动、射血分数、术前生物标志物	内部验证	最佳模型: GBT 建模组: 0.781 验证组: —	RF、GBT、XGBoost、AdaBoost
Zhao 等[12]	年龄、术前脑血管疾病、术前 MMSE 评分、ASA 分级、教育程度、术前尿素水平、术前肌酐水平、术前白蛋白水平、APACHE II 评分、体外循环持续时间、术前脑血管疾病、心律失常病史	外部验证	最优模型: ANN 建模组: 术前 0.929, 术后 0.925 验证组: 术前 0.776, 术后 0.684	ANN、XGBoost、Catboost、RF
Mufti 等[13]	年龄、机械通气时间、术前肌酐清除率、术前血红蛋白水平、术前房颤、术前 Euro II 评分、术后 ICU 停留时间、手术类型、术后 48 小时内输血、术中正性肌力药物使用、慢性阻塞性肺疾病、术前期外循环时间、术前糖尿病、术前虚弱状态、术前拒绝手术史、术后心律失常、性别、主动脉瓣狭窄程度、二尖瓣反流程度、术后新发房颤、术前射血分数	内部验证	最优模型: SVM 建模组: 0.772 验证组: —	SVM、ANN、BBN、DT、LR、NB、RF
Li 等[14]	年龄、性别、教育水平、身高、体重、饮酒史、吸烟史、冠心病、脑梗死、糖尿病、高血压、左心室射血分数、体外循环持续时间、主动脉阻断持续时间、麻醉持续时间、术后使用主动脉内球囊反搏或体外膜肺氧合、细胞计数、血尿素氮、总胆红素、血清肌酐、血清白蛋白、pH 值、二氧化碳分压、氧分压、钠、钾、血糖、疼痛评分等。	内部验证	最佳模型: RF 建模组: — 验证组: 0.92	RF、GBDT、LR、SVM、GNB、KNN
Nagata 等[15]	年龄、使用精神药物、认知功能、日常生活活动能力、脑卒中或脑出血病史、估计肾小球滤过率	内部验证	最佳模型: ET 建模组: 0.76 验证组: —	BNB、SVM、RF、ET、XGBoost
Han 等[16]	估计肾小球滤过率、年龄、甲状腺激素水平、麻醉深度、Katz 动脉粥样硬化分级、术中脑氧饱和度降低、术中血流动力学不稳定	外部验证	最佳模型: Ensemble 建模组: 0.977 验证组: 0.887	XGB、ET、RF、LR、ANN、SVM

续表

黄琦等[17]	年龄、术前抑郁评分、术前焦虑评分、认知功能、术前红细胞压积、ICU 停留时间、术后疼痛评分	内部验证	最佳模型: GBDT 建模组: — 验证组: 0.86	GBDT、SVM、RF、LR、KNN、DNN
左都坤[18]	年龄、术前外周血氧饱和度、术前局部脑氧饱和度、术前收缩压、术后睡眠评分	内部验证	最佳模型: LR 建模组: — 验证组: 0.732	LR、XGBoost

注: ASA: 美国麻醉医师协会分级; MMSE: 认知功能评估量表; APACHE II: 急性生理与慢性健康评分系统; Euro II: 欧洲心脏手术风险评估系统; RF: 随机森林; SVM: 支持向量机; RBFNN: 径向基函数神经网络; KNN: K 最近邻算法; KRR: 核岭回归; GBT: 梯度提升树; XGBoost: 极限梯度提升树; Ensemble: 软投票集成; AdaBoost: 自适应增强算法; ANN: 人工神经网络; Catboost: 分类提升; BBN: 贝叶斯信念网络; DT: 决策树; LR: 逻辑回归; NB: 朴素贝叶斯; GBDT: 梯度提升决策树; LR: 逻辑回归; GNB: 高斯朴素贝叶斯; BNB: 伯努利朴素贝叶斯; ET: 极端随机树; GBDT: 梯度提升决策树; DNN: 深度神经网络。

4. 讨论

4.1. 模型性能比较

本研究发现,在预测心血管术后 POD 时,不同机器学习算法优劣性存在显著差异。RF、SVM、GBT、XGBoost、ANN、LR 出现次数较多,而 RF 算法在 AUC 方面表现较为突出。采用集成机器学习的预测方法可以综合多种算法的优点,提高模型的预测稳定性及准确性[10]-[15]。

模型性能的差异与样本量、数据集特征和特征选择方法均有密切相关性。Nagata 等[15]指出,虽然样本量小,但通过特征选择和模型调试,ET 仍具有较好的预测能力,AUC 值为 0.76。Zhao 等[12]的研究结果显示,与其他算法相比,ANN 在术前和术后的模型中表现较为突出,术前模型 AUC 为 0.929,术后模型 AUC 为 0.925,提示 ANN 在面对复杂的数据集时有较强的预测能力。此外,Mufti 等[13]的研究显示,尽管 SVM 在某些指标上表现最佳,但其 AUC 低于其他模型。Nowakowska 等[11]的研究发现,相比其他模型,GBT 在预测 POD 方面表现最佳。

4.2. 特征选择与数据质量

在患者一般特征方面,术前健康状况、手术类型、术后并发症等也是影响模型性能的关键特征。黄琦等[17]提出术前焦虑、抑郁评分、既往病史等是预测 POD 的有意义特征。左都坤等[18]同样提出患者年龄、术前外周血氧饱和度、术前局部脑氧饱和度等是预测 POD 的主要因素,尤其是术前心理状态、一般健康状况直接影响患者术后康复。Nagata 等[15]的研究进一步确认了术前认知功能、术前生活自理能力是重要的特征。

Han 等[16]侧重对术中管理因素的研究,发现手术过程中的生理应激和潜在的神经认知损伤风险等特征对 POD 的发生有显著影响。此外,如术后感染、疼痛管理不善和电解质失衡等术后并发症,也被认为是 POD 的重要风险因素[17] [19]。这些并发症不仅影响患者的恢复过程,还可能通过引发炎症反应和代谢紊乱,进一步增加 POD 的发生风险。此外,Nagata 等[15]的研究,筛选出六个核心特征用于建模,这些特征不仅提升了模型的预测能力,还增强了模型在临床应用中的价值。

在数据质量层面,数据的来源、本身质量以及潜在偏差,都会对模型性能产生影响。Zhao 等[12]、Li 等[14]以及 Nagata 等[15]的研究,都是基于单中心的数据开展的,不仅样本量比较有限,还存在样本不平衡的问题,这可能会导致模型的多样性受到限制。与之相比,Han 等[16]则提出使用回顾性数据开发模型,

借助前瞻性数据进行验证, 同时结合软投票集成方法整理流程。通过这样的方式, 提升了模型的稳健性和预测能力, 也在一定程度上减少了因数据质量问题带来的偏差。

4.3. 模型的可解释性与接受度

在临床实践工作中, 机器学习模型能否用于解释其在临床实践工作中的预测结果, 也是机器学习模型能否被广泛认可的关键问题之一。复杂的机器学习模型可以有效地预测心血管 POD, 但是由于该类模型“黑箱子”的特点影响了临床医生对该模型的理解, 进而降低了临床医生对此模型的认可度。Nowakowska 等[11]、Zhao 等[12]认为虽然 RF 模型、ANN 模型等可以有效预测心血管疾病患者 POD 的风险, 但是其“黑箱子”的性质降低了医生对其的认识。Mufti 等[13]、Yang 等[10]也认为虽然机器学习模型在 POD 预测方面表现较好, 但是该模型本身的复杂性也会影响其在临床实践中的应用。

为提升可解释性, 可以采取以下方法。第一, 通过特征分析, 筛选出影响模型最重要的因素, 是提升可解释性的一种有效的方式。Han 等[16]研究中识别了平均心指数等多种术中生物信号特征。这些特征对模型预测能力具有显著影响。这些关键特征, 是临床医护人员正确理解模型决策的最重要依据。黄琦等[17]研究中也通过 RF 算法将特征的重要性进行排序, 清晰了解不同特征影响程度的大小, 帮助临床医生理解模型决策。其次, 通过简化模型提高可解释性。Nagata 等[15]研究中, LR 预测效能虽然略低于 XGBoost, 但其线性结构简单明了, 使临床医生更容易对模型的理解与决策过程, 满足其临床的需求。左都坤等[18]研究中也认为 XGBoost 模型预测效能虽然略低于 LR, 但无论是对特征选择还是对模型构建, 都强调了可解释性的重要性。此外, 借助模型可视化工具, 能让抽象的决策过程更容易被理解和感知。例如, 通过决策树可视化, 临床医生可以直观地看到模型的完整决策路径, 进而更清晰地理解模型的预测思路。在临床实践中, 模型的可解释性一方面让医生能够更好地理解模型决策依据, 增加对模型的信任感, 另一方面也能让模型得到更广泛应用。因此, 在未来的工作中, 需要更加重视可解释性设计, 将特征分析、模型简化、模型可视化等工具结合, 提升机器学习模型对临床应用价值。

在模型开发过程中, 应邀请临床专家参与模型开发, 使模型的输出更贴合临床实践需求。例如, Nowakowska 等[11]、Li 等[14]的研究指出, 通过与临床专家合作, 可确保模型最终的输出结果符合临床医生的理解和应用。其次, 通过持续地教育与培训, 帮助临床医生逐步理解机器学习模型, 也是提升模型接受度的重要手段。此外, Mufti 等[2]还强调, 在模型开发过程应妥善处理数据不平衡问题, 这有助于提高模型的准确性和可解释性, 从而增强医生对模型的认可。

5. 小结

综上所述, 心血管 POD 预测研究已有了一定的进展, 为医生提供了临床决策依据。但研究数据集的特征仍存在样本量有限, 模型解释性不足等局限性。针对以上问题, 未来的研究还需要从以下方面进行。首先, 通过多中心合作, 利用多中心数据集, 提高样本量和样本多样性解决数据集不平衡的问题。其次, 需要通过特征重要性、结构简化、可视化工具等方式增加解释性, 使临床医师更能够理解和接受模型。此外, 长期的外部验证及优化也是必要的, 只有通过不同临床环境的检验, 才能确保模型的稳定性和可靠性。

基金项目

浙江省教育厅一般科研项目(Y202351134)。

参考文献

- [1] Pezzella, P. (2022) The ICD-11 Is Now Officially in Effect. *World Psychiatry*, **21**, 331-332.

- <https://doi.org/10.1002/wps.20982>
- [2] Soehle, M., Dittmann, A., Ellerkmann, R.K., Baumgarten, G., Putensen, C. and Guenther, U. (2015) Intraoperative Burst Suppression Is Associated with Postoperative Delirium Following Cardiac Surgery: A Prospective, Observational Study. *BMC Anesthesiology*, **15**, Article No. 61. <https://doi.org/10.1186/s12871-015-0051-7>
 - [3] Shokhirev, M.N. and Johnson, A.A. (2022) An Integrative Machine-Learning Meta-Analysis of High-Throughput Omics Data Identifies Age-Specific Hallmarks of Alzheimer's Disease. *Ageing Research Reviews*, **81**, Article ID: 101721. <https://doi.org/10.1016/j.arr.2022.101721>
 - [4] Sepulveda, E., Franco, J.G., Trzepacz, P.T., Gaviria, A.M., Meagher, D.J., Palma, J., *et al.* (2016) Delirium Diagnosis Defined by Cluster Analysis of Symptoms versus Diagnosis by DSM and ICD Criteria: Diagnostic Accuracy Study. *BMC Psychiatry*, **16**, Article No. 167. <https://doi.org/10.1186/s12888-016-0878-6>
 - [5] van der Mast, R.C. (1998) Pathophysiology of Delirium. *Journal of Geriatric Psychiatry and Neurology*, **11**, 138-145. <https://doi.org/10.1177/089198879801100304>
 - [6] Hirsch, J., DePalma, G., Tsai, T.T., Sands, L.P. and Leung, J.M. (2015) Impact of Intraoperative Hypotension and Blood Pressure Fluctuations on Early Postoperative Delirium after Non-Cardiac Surgery. *British Journal of Anaesthesia*, **115**, 418-426. <https://doi.org/10.1093/bja/aeu458>
 - [7] Racine, A.M., Tommet, D., D'Aquila, M.L., Fong, T.G., Gou, Y., Tabloski, P.A., *et al.* (2020) Machine Learning to Develop and Internally Validate a Predictive Model for Post-Operative Delirium in a Prospective, Observational Clinical Cohort Study of Older Surgical Patients. *Journal of General Internal Medicine*, **36**, 265-273. <https://doi.org/10.1007/s11606-020-06238-7>
 - [8] Abdar, M., Książek, W., Acharya, U.R., Tan, R., Makarenkov, V. and Pławiak, P. (2019) A New Machine Learning Technique for an Accurate Diagnosis of Coronary Artery Disease. *Computer Methods and Programs in Biomedicine*, **179**, Article ID: 104992. <https://doi.org/10.1016/j.cmpb.2019.104992>
 - [9] Li, Y., Xu, J., Wang, Y., Zhang, Y., Jiang, W., Shen, B., *et al.* (2020) A Novel Machine Learning Algorithm, Bayesian Networks Model, to Predict the High-Risk Patients with Cardiac Surgery-associated Acute Kidney Injury. *Clinical Cardiology*, **43**, 752-761. <https://doi.org/10.1002/clc.23377>
 - [10] Yang, T., Yang, H., Liu, Y., Liu, X., Ding, Y., Li, R., *et al.* (2024) Postoperative Delirium Prediction after Cardiac Surgery Using Machine Learning Models. *Computers in Biology and Medicine*, **169**, Article ID: 107818. <https://doi.org/10.1016/j.compbiomed.2023.107818>
 - [11] Nowakowska, K., Sakellarios, A., Kaźmierski, J., Fotiadis, D.I. and Pezoulas, V.C. (2023) AI-Enhanced Predictive Modeling for Identifying Depression and Delirium in Cardiovascular Patients Scheduled for Cardiac Surgery. *Diagnostics*, **14**, Article No. 67. <https://doi.org/10.3390/diagnostics14010067>
 - [12] Zhao, X., Li, J., Xie, X., Fang, Z., Feng, Y., Zhong, Y., *et al.* (2024) Online Interpretable Dynamic Prediction Models for Postoperative Delirium after Cardiac Surgery under Cardiopulmonary Bypass Developed Based on Machine Learning Algorithms: A Retrospective Cohort Study. *Journal of Psychosomatic Research*, **176**, Article ID: 111553. <https://doi.org/10.1016/j.jpsychores.2023.111553>
 - [13] Mufti, H.N., Hirsch, G.M., Abidi, S.R. and Abidi, S.S.R. (2019) Exploiting Machine Learning Algorithms and Methods for the Prediction of Agitated Delirium after Cardiac Surgery: Models Development and Validation Study. *JMIR Medical Informatics*, **7**, e14993. <https://doi.org/10.2196/14993>
 - [14] Li, Q., Li, J., Chen, J., Zhao, X., Zhuang, J., Zhong, G., *et al.* (2024) A Machine Learning-Based Prediction Model for Postoperative Delirium in Cardiac Valve Surgery Using Electronic Health Records. *BMC Cardiovascular Disorders*, **24**, Article No. 56. <https://doi.org/10.1186/s12872-024-03723-3>
 - [15] Nagata, C., Hata, M., Miyazaki, Y., Masuda, H., Wada, T., Kimura, T., *et al.* (2023) Development of Postoperative Delirium Prediction Models in Patients Undergoing Cardiovascular Surgery Using Machine Learning Algorithms. *Scientific Reports*, **13**, Article No. 21090. <https://doi.org/10.1038/s41598-023-48418-5>
 - [16] Han, C., Kim, H.I., Soh, S., Choi, J.W., Song, J.W. and Yoon, D. (2024) Machine Learning with Clinical and Intraoperative Biosignal Data for Predicting Postoperative Delirium after Cardiac Surgery. *iScience*, **27**, Article ID: 109932. <https://doi.org/10.1016/j.isci.2024.109932>
 - [17] 黄琦, 关美娇, 邹彬, 等. 机器学习模型预测心脏外科手术患者术后谵妄的有效性[J]. 临床麻醉学杂志, 2023, 39(4): 363-369.
 - [18] 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.
 - [19] 伍侨. 老年术后谵妄发生率及危险因素的系统评价[D]: [硕士学位论文]. 成都: 成都中医药大学, 2021.