DOI:10.16016/j.2097-0927.202301050

# 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

左都坤,吴卓熙,龙宗泓,李 阳,李加欣,刘 燕,李 洪 400037 重庆,陆军军医大学(第三军医大学)第二附属医院麻醉科

[摘要] **目的** 基于极限梯度提升树(extreme gradient boosting, XGBoost)机器学习算法,构建心脏手术术后谵妄(postoperative delirium, POD)风险的预测模型,评价其与传统 Logistic 回归(logistic regression, LR)模型的预测效果,为早期识别、早期干预治疗 POD 提供参考。**方法** 采用病例-对照研究设计方案,筛选 2022 年 3~7 月陆军军医大学第二附属医院病历系统内因心脏病择期行全麻下心脏手术治疗的患者 684 例。根据术后 3 天的随访结果将其分为谵妄组($n$=38)和非谵妄组($n$=646),将患者按 7∶3比例随机分为训练集(479 例)和测试集(205 例)。使用 LASSO 回归分析筛选与 POD 相关的重要变量。LR 和 XGBoost 用于构建预测模型。计算预测模型的受试者工作特征曲线下面积(under receiver operating characteristic curve, ROC-AUC)以及最佳阈值下的灵敏度和特异度,并比较不同模型的预测性能。**结果** 心脏手术患者术后 3 天谵妄发生率为 5.56%。与非谵妄组相比,谵妄组患者的年龄越大($P$<0.05)、糖尿病史比例越高($P$<0.05),且术前收缩压、术后睡眠评分更低($P$<0.05),其余资料差异均无统计学意义($P$>0.05)。最终纳入年龄、术前外周血氧饱和度、术前局部脑氧饱和度、术前收缩压、术后睡眠评分共 5 个变量进行建模。LR 及 XGBoost 模型的 AUC 依次为 0.732(95%*CI*:0.430~1.000)、0.659(95%*CI*:0.559~0.759),其中 LR 的 AUC 更高,预测性能更好,但其灵敏度为 50%,低于 XGBoost(67%),特异度为 100%,高于 XGBoost(98.5%)。**结论** 基于 XGBoost 这种集成学习算法建立的心脏手术术后谵妄预测模型的效能并不优于传统的 LR 模型,LR 模型可较好地预测心脏手术后谵妄的发生,为 POD 早期干预治疗提供参考。但 XGBoost 对术后谵妄的诊断更灵敏。

[关键词] 心脏手术;术后谵妄;机器学习;预测模型

[中图法分类号] R319; R654.2; R749 [文献标志码] A

# Prediction model of early postoperative delirium risk based on machine learning algorithm in patients undergoing cardiac surgery

ZUO Dukun, WU Zhuoxi, LONG Zonghong, LI Yang, LI Jiaxin, LIU Yan, LI Hong Department of Anesthesiology, Second Affiliated Hospital, Army Medical University (Third Military Medical University), Chongqing, 400037, China

[**Abstract**] **Objective** To develop an early postoperative delirium (POD) risk prediction model in patients undergoing cardiac surgery based on Extreme Gradient Boosting (XGBoost) and compare its prediction performance with that of a traditional logistic regression (LR) model in order to provide reference for early identification and timely intervention of the condition. **Methods** A case-control trial was conducted on 684 patients who underwent elective cardiac surgery under general anesthesia due to heart disease in the Second Affiliated Hospital of Army Medical University from March to July 2022. According to the outcome of their 3-day follow-up after operation, the patients were divided into delirium group ($n$=38) and non-delirium group ($n$=646). The patients were randomly divided into a training set (479 patients) and a test set

[基金项目] 国家自然科学基金面上项目(82171265),国家重点研发计划(2018YFC0117200),重庆市技术创新与应用发展专项(CSTB2022TIAD-KPX0179)

[通信作者] 李 洪,E-mail:lh78553@126.com

2097-0927/Copyright © 2022, 陆军军医大学(第三军医大学)。这篇开放获取文章遵循 CC BY 许可协议(https://creativecommons.org/licenses/by/4.0/)

(205 patients) at a ratio of 7:3. LASSO regression analysis was used to screen out important variables related to POD. LR and XGBoost were employed to construct the prediction models. The area under receiver operating characteristic curve (ROC-AUC) of the prediction models and the sensitivity and specificity under the optimal threshold were calculated and the prediction performance of different models was compared. **Results** The 3-day postoperative delirium rate of the patients undergoing cardiac surgery was 5.56%. Compared with the non-delirium group, the patients in the delirium group were older ($P<0.05$), had a higher proportion of diabetes ($P<0.05$), and lower preoperative systolic blood pressure ($P<0.05$) and postoperative sleep score ($P<0.05$). But there were no statistical differences in other indicators ($P>0.05$). Then finally, 5 variables, including age, preoperative peripheral oxygen saturation, preoperative regional cerebral oxygen saturation, preoperative systolic blood pressure and postoperative sleep score, were included for modelling. The AUCs of LR and XGBoost models were 0.732 (95%*CI*: 0.43~1.000) and 0.659 (95%*CI*: 0.559~0.759), respectively. LR model had a higher AUC value and better predictive performance, but, its sensitivity was 50%, lower than that of XGBoost model (67%), and its specificity was 100%, higher than the other model (98.5%). **Conclusion** The predictive performance of the prediction model based on XGBoost, an integrated learning algorithm, is not superior to the traditional LR model for postoperative delirium after cardiac surgery. LR model can well predict the occurrence of delirium after cardiac surgery and provide reference for early intervention and treatment. But XGBoost is more sensitive to the diagnosis of postoperative delirium.

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

Supported by the General Program of National Natural Science Foundation of China (82171265), the National Key R&D Program of China (2018YFC0116700) and the Special Project of Technical Innovation and application Development of Chongqing (CSTB2022TIADKPX0179). Corresponding author: LI Hong, E-mail: lh78553@126.com

术后谵妄(postoperative delirium, POD)是一种急性精神紊乱状态,由潜在的系统紊乱引起的中枢神经系统可逆性改变[1]。其通常发生在心脏手术后数小时至数天,主要表现为意识下降、注意力障碍和思维障碍[2]。研究表明,尽管外科技术的进步,心脏手术后谵妄的发生率较先前有所下降,但仍较高,保持在26%~52%之间[3]。据报道,术后前几天内的谵妄与心脏手术[4]以及其他类型手术的预后不良相关,包括住院时间延长、死亡率增加、认知障碍、记忆衰退、长期护理需求以及其他不良结局[5]。据估计,与谵妄及其并发症相关的总医疗费用超过1 640亿美元/年[1]。

与痴呆相反,谵妄通常是可逆的,只要及早发现和治疗潜在病因[6],因此早期预测术后谵妄发生风险,并及时干预,可以缩短患者住院时间、改善患者预后并减少并发症和医疗费用[1]。随着人工智能(artificial intelligence,AI)的飞速发展,作为其分支的机器学习技术(machine learning techniques,MLTs)已被广泛用于数据驱动的预测模型中[7],使得更精确预测心脏手术术后谵妄发生成为可能。有研究表明,在预测非心脏手术术后谵妄[2]中,支持向量机(support vector machine, SVM)、随机森林(random forest, RF)、极限梯度提升树(extreme gradient boosting, XGBoost)与传统的Logistic回归(logistic regression, LR)相当[8],并被纳入临床工作流程中[9]。XGBoost作为一种增强集成学习模型,具有较好的运用前景,但关于其在预测心脏手术术后早期谵妄发生风险的效果以及与经典的LR模型相比其预测效果是否更佳尚不清楚,本研究基于机器学习算法构建心脏手术POD风险预测模型,同时与传统LR模型的预测效能进行比较,为POD高危患者早期干预提供建议。

## 1 资料与方法

### 1.1 一般资料

本研究基于《国家重点研发计划——基于物联网技术的围术期生命监测支持仪器的评价研究》数据的二次分析,采用病例-对照研究设计方案,筛选2022年3~7月在陆军军医大学第二附属医院择期行心脏外科手术的患者。纳入标准:因冠状动脉粥样硬化性心脏病、心脏瓣膜病、先天性心脏病等疾病入院接受开胸心脏手术治疗的成年患者。排除标准:①术前存在认知功能减退、精神疾病;②酒精依赖,存在酒精戒断症状;③视力、听力严重受损;④接受深低温停循环下孙氏手术的StanfordA型主动脉夹层或者开胸接受胸、腹主动脉人工血管置换;单纯接受如经导管主动脉瓣膜置换术(transcatheter aortic valve implantation,TAVI)或血管腔内隔绝(end vascular graft exclusion, EVGE)等介入

手术治疗;⑤术中或术后 48 h 内死亡或自动出院;⑥肝肾功能不全(如重型肝炎、肾盂肾炎);⑦二次手术;⑧临床资料缺失严重(如研究所涉及的性别、年龄、既往史、术前、术中、术后相关指标)。本研究已通过陆军军医大学第二附属医院伦理委员会审查(批件号:2023-研第 006-01)。

### 1.2 数据收集

应用手术麻醉信息系统、电子病历系统等数据库,收集和整理患者术前、术中、术后的临床资料如下:①一般信息:性别、年龄、体质指数(body mass index, BMI)、ASA 分级、吸烟史、饮酒史、高血压病史、糖尿病史、脑血管疾病史、贫血史;②术前指标:局部脑氧饱和度(regional cerebral oxygen saturation, $rSO_2$)(取左右两侧大脑 $rSO_2$ 平均值)、外周血氧饱和度($SpO_2$)、心率(HR)、血压(BP)、血红蛋白(HGB)、红细胞比容(HCT);③术中指标:麻醉方式、术中知晓;④术后指标:术后当日头晕情况、术后 24 h 内睡眠评分、术后 3 天的谵妄发生情况。

### 1.3 谵妄评估

术后谵妄的评估由陆军军医大学第二附属医院麻醉科经过专业培训的护士进行,该护士对患者的围手术期特征以及数据录入和统计分析的过程均不知情。手术后 3 天内,麻醉护士常规每日早晚 7 点两次依据 CAM-ICU 评分量表进行评估,以患者出现①精神状态改变、②注意力障碍、③意识水平变化、④思维紊乱中的 3 项(①+②+③或①+②+④)为 CAM-ICU 评分阳性,作为 POD 的诊断标准[10]。

### 1.4 机器学习模型的构建及评价

将数据按照随机分组的原则,分为训练集(70%)和测试集(30%)。应用 LASSO 回归筛选训练集中有意义的变量纳入模型构建,采用 LR、XGBoost 这 2 种算法分别构建预测模型。其中 LR 为传统回归模型,XGBoost 是在梯度提升决策树(gradient boosting decision tree,GBDT)的基础上开发的,是一种增强集成学习模型。测试集则用于模型的验证与评估。

### 1.5 统计学方法

采用 SPSS 软件(V26.0,IBM)和 R 软件(V.4.2.2)进行数据处理和分析。正态分布计量资料以 $\bar{x}\pm s$ 表示,采用成组 $t$ 检验;偏态分布的计量资料以 $M(P_{25},P_{75})$ 表示,采用 Mann-Whitney $U$ 检验。计数资料采用频数和百分比表示,组间比较采用 $\chi^2$ 检验或 *fisher* 确切概率法。采用受试者工作特征曲线(receiver operating characteristic curve, ROC)评估两种模型的预测效能。计算预测模型的 ROC 曲线下面积(area under the curve, AUC)以及最佳阈值下的灵敏度和特异度,评估模型的预测效果。$P<0.05$ 为差异有统计学意义。

## 2 结果

### 2.1 患者基线资料

根据纳入排除原则,最终纳入符合条件的患者 684 例,其中有 38 例患者发生术后谵妄,发生率为 5.56%。谵妄患者与非谵妄患者的一般资料比较见表 1,其中谵妄患者的年龄更大($P<0.05$)、糖尿病比例更高($P<0.05$)。与非谵妄患者相比,谵妄患者术前收缩压水平、术后睡眠评分更低($P<0.05$,表 2)。

**表 1 心脏手术后谵妄患者与非谵妄患者的一般资料比较**

[$M(P_{25},P_{75})$,例(%)]

| 变量 | 谵妄($n$ =38) | 非谵妄($n$=646) | $P$ |
|---|---|---|---|
| 年龄/岁 | 58(55,66.25) | 54(48,60.25) | 0.003 |
| 女性 | 21(55.3) | 340(52.6) | 0.882 |
| BMI/kg·m$^{-2}$ | 23.39(20.88,26.17) | 23.76(21.60,26.15) | 0.867 |
| 既往史 | | | |
| 高血压病史 | 12(31.6) | 117(18.1) | 0.064 |
| 糖尿病病史 | 8(21.1) | 52(8.0) | 0.014 |
| 脑血管病史 | 1(2.6) | 33(5.1) | 0.765 |
| 贫血病史 | 0(0) | 11(1.7) | 0.883 |
| 吸烟史 | 9(23.7) | 149(23.1) | 1.000 |
| 饮酒史 | 6(15.8) | 103(15.9) | 1.000 |
| ASA 分级/级 | 3(3,3) | 3(3,3) | 0.042 |

**表 2 心脏手术后谵妄患者与非谵妄患者的临床资料比较**

[$M(P_{25},P_{75})$,例(%)]

| 变量 | 谵妄组($n$=38) | 非谵妄组($n$=646) | $P$ |
|---|---|---|---|
| 术前情况 | | | |
| 心率 | 84(78,94) | 85(75,96) | 0.504 |
| $SO_2$ | 98(97,99) | 98(97,99) | 0.069 |
| $rSO_2$ | 58(53,62) | 61(56.5,65.5) | 0.067 |
| BP | | | |
| 收缩压 | 119(110,135) | 133(116,148) | 0.002 |
| 舒张压 | 73(65,79) | 74(67,83) | 0.853 |
| Hb | 130(121,142) | 131(117,144) | 0.643 |
| HCT | 40(35.4,43.4) | 39.9(36,43.3) | 0.838 |
| 麻醉方式 | | | 1.000 |
| 静吸复合麻醉 | 38(100) | 640(99.1) | |
| 全凭静脉麻醉 | 0 | 6(0.9) | |
| 术后指标 | | | |
| 术后睡眠评分 | 0(0,2) | 3(2,4) | 0.005 |
| 术后头晕 | 2(5.3) | 110(17) | 0.093 |

### 2.2 变量筛选

当α=0.01时迭代最佳,LASSO回归分析筛选训练集中有意义的变量(即特征系数不为0)如下:①一般资料:年龄;②临床资料:术前$SpO_2$、$rSO_2$、收缩压、术后睡眠评分(表4)。将上述变量纳入XGBoost模型,变量重要性排序如下:术前$SpO_2$>术前收缩压>术前$rSO_2$>术后睡眠评分>年龄。其中年龄为谵妄的危险因素(表3)。

**表3 训练集内与POD相关的重要变量的LASSO回归结果**(α=0.01)

| 变量 | 特征系数 | *OR* | 95%*CI* |
|---|---|---|---|
| 性别 | 0.0000 | | |
| BMI | 0.0000 | | |
| 年龄 | 0.0139 | 1.391 | 1.252~1.530 |
| ASA分级 | 0.0000 | | |
| 麻醉方式 | 0.0000 | | |
| 高血压病史 | 0.0000 | | |
| 糖尿病病史 | 0.0000 | | |
| 贫血史 | 0.0000 | | |
| 脑血管病史 | 0.0000 | | |
| 吸烟史 | 0.0000 | | |
| 饮酒史 | 0.0000 | | |
| 术前HR | 0.0000 | | |
| 术前$SpO_2$ | 0.00127 | 1.005 | 1.000~1.010 |
| 术前$rSO_2$ | −0.00552 | 0.724 | 0.586~0.862 |
| 术前HGB | 0.0000 | | |
| 术前HCT | 0.0000 | | |
| 术前收缩压 | −0.01616 | 0.601 | 0.398~0.804 |
| 术前舒张压 | 0.0000 | | |
| 术后睡眠评分 | −0.01501 | 0.398 | 0.327~0.469 |

回归模型 $Y=-15.872+0.483X_1+0.142X_2-0.181X_3-0.472X_4-0.419X_5$ Y表示谵妄发生与否;$X_1$、$X_2$、$X_3$、$X_4$、$X_5$分别为年龄、术前$SpO_2$、术前$rSO_2$、术前收缩压、术后睡眠评分

### 2.3 模型评估

在测试集验证并评估算法对心脏手术术后谵妄发生的预测能力。LR、XGBoost模型的AUC依次为0.732、0.659,LR的AUC和特异度最高(表4),相较于XGBoost机器学习模型的预测性能更好,但XGBoost的阳性预测值、$F_1$以及准确度高于传统LR,XGBoost对所有样本预测正确的比例较高,对阳性样本的识别能力强。此外,XGBoost的灵敏度更高,对术后谵妄的诊断更灵敏。

## 3 讨论

多种危险因素的累积是POD发生的关键,目前还没有单一的治疗方法来预防POD的发生。非药物治疗与药物治疗相结合是治疗POD的最佳方法之一。POD是心脏手术后常见的并发症,与认知功能下降、长期死亡率、围手术期发病率、住院时间延长和医疗费用增加相关[11],因此,POD的防治是临床亟待解决的问题。虽然在许多临床研究中,研究人员试图找到能够准确预测POD的特异标志物,如S100β蛋白[12]、神经元特异性烯醇化酶(neuron-specific enolase, NSE)[13]、tau蛋白[14]和炎症介质等[15]。虽然这些生物标志物具有较高的POD预测能力,但由于采样的复杂性和高昂的成本,它们无法在临床上推广。在临床试验中,它们总是被用来探索科学问题。因此,疾病预测模型的出现可能为POD的预防提供一种解决方案。

### 3.1 预测模型的临床特征及其意义

本研究旨在采用机器学习算法建立心脏手术患者术后早期谵妄发生风险的预测模型,以达到发现高危患者、辅助临床决策的作用。本研究纳入了684例心脏手术患者,根据术后3天是否发生谵妄进行分组,使用LASSO回归从两组术前、术中、术后等相关资料中筛选出了5个有意义的变量(年龄、术前外周血氧饱和度、术前局部脑氧饱和度均值、术前收缩压、术后睡眠评分),并基于LR、XGBoost算法构建了心脏手术术后谵妄发生风险预测模型,并比较了这2种模型的预测效能。XGBoost是在GBDT的基础上开发的一种增强集成学习算法,其在Kaggle机器学习大赛中展示了最先进的表现,XGBoost比GBDT更快、更高效,因此被称为X(Extreme)GBoost。XGBoost作为机器学习领域最先进的技术,已广泛应用于医疗行业、商业、环境保护等领域[16]。而LR是一种经典的回归分析方法,被广泛应用于探讨疾病的危险因素或根据危险因素预测疾病发生的概率。但本研究发现传统LR模型可以

**表4 测试集中两种模型的预测性能比较**(%)

| 模型 | AUC(95%*CI*) | 灵敏度(%) | 特异度(%) | 阳性预测值(%) | 阴性预测值(%) | $F_1$分数 | 准确度(%) |
|---|---|---|---|---|---|---|---|
| Logistic回归 | 0.732(0.43~1.000) | 50.0 | 100 | 0 | 94.7 | 0.49 | 94.7 |
| XGBoost | 0.659(0.559~0.759) | 67.0 | 98.5 | 57.1 | 96.5 | 0.71 | 95.1 |

较准确地预测 POD,并显示出比 XGBoost 更好的预测效能,但 XGBoost 预测谵妄的敏感性以及对阳性样本的识别能力优于 LR,即二者预测术后谵妄均有各自的优点。

### 3.2 谵妄的发生及其危险因素

本研究发现,心脏手术后谵妄的发生率为 5.56%,与洪亮等[17]研究中的谵妄发生率相似(5.48%),但远低于以往研究报道的 26%~52%,这可能与本研究的谵妄数据仅采集了术后 3 天,时间较短有关,且本研究排除了 POD 发生率较高的 StanfordA 型主动脉夹层[18]以及有认知障碍和酒精依赖患者,同时在我们的心脏手术术中和术后阶段,均常规应用右美托咪定,研究表明,右美托咪定可降低 POD 的发生率[19-20]。本研究显示,年龄是术后谵妄发生的危险因素,这与既往研究相似[5]。有研究表明高血压也与 POD 高风险显著相关[21],但本研究结果并未显示此种关系,这可能是由于本研究纳入的患者数量较少。王菲等[22]研究证实了饮酒史会增加谵妄发生风险,而本研究也并未表明有饮酒史的患者谵妄发生风险会增加。

本研究存在一定的局限性:首先,本研究为单中心研究,纳入患者数量有限,研究表明,机器学习模型在大数据集上应用可获得更加稳定的结果[23],需要进一步的多中心、大数据临床研究进行验证。其次,本研究未能纳入患者文化程度、术前炎症指标、手术时间、体外循环(cardiopulmonary bypass, CPB)时间、主动脉阻断时间、术中出血量、术中麻醉药物的使用以及术前等可能影响 POD 发生的因素,在后续的模型优化中,可加入更多可能影响 POD 发生的因素,以不断完善预测模型。最后,本研究是利用回顾性数据开发和验证的,在正式临床实践前,还应行前瞻性验证研究以确认模型的可靠性。此外,所有病例中,未发生术后谵妄和发生术后谵妄的比例过于悬殊,为 17∶1,且病例数相对较少,这样的"非平衡分类"问题对于机器学习算法来说存在较大的挑战。

综上所述,本研究基于机器学习算法建立心脏手术患者术后早期谵妄风险预测模型,相较于集成学习算法 XGBoost,传统 LR 模型对其预测效能表现最优,可用于预测心脏手术术后早期谵妄发生风险,可以为临床决策提供参考,帮助医患共同实现最优个体化治疗方案。但 XGBoost 预测谵妄的敏感性以及对阳性样本的识别能力优于 LR。

**参考文献:**


[1] ZHANG Y, WAN D H, CHEN M, *et al*. Automated machine learning-based model for the prediction of delirium in patients after surgery for degenerative spinal disease[J]. CNS Neurosci Ther, 2023, 29(1): 282-295. DOI: 10.1111/cns.14002.

[2] HU X Y, LIU H, ZHAO X, *et al*. Automated machine learning-based model predicts postoperative delirium using readily extractable perioperative collected electronic data[J]. CNS Neurosci Ther, 2022, 28(4): 608-618. DOI: 10.1111/cns.13758.

[3] BROWN C H. Delirium in the cardiac surgical ICU[J]. Curr Opin Anaesthesiol, 2014, 27(2): 117-122. DOI: 10.1097/ACO.0000000000000061.

[4] JÄRVELÄ K, PORKKALA H, KARLSSON S, *et al*. Postoperative delirium in cardiac surgery patients[J]. J Cardiothorac Vasc Anesth, 2018, 32(4): 1597-1602. DOI: 10.1053/j.jvca.2017.12.030.

[5] CHEN H Y, MO L, HU H J, *et al*. Risk factors of postoperative delirium after cardiac surgery: a meta-analysis[J]. J Cardiothorac Surg, 2021, 16(1): 113. DOI: 10.1186/s13019-021-01496-w.

[6] BULL M J, BOAZ L, JERMÉ M. Educating family caregivers for older adults about delirium: a systematic review[J]. Worldviews Evid Based Nurs, 2016, 13(3): 232-240. DOI: 10.1111/wvn.12154.

[7] BANERJEE S, LIO P, JONES P B, *et al*. A class-contrastive human-interpretable machine learning approach to predict mortality in severe mental illness[J]. NPJ Schizophr, 2021, 7(1): 60. DOI: 10.1038/s41537-021-00191-y.

[8] FORD E, SHEPPARD J, OLIVER S, *et al*. Automated detection of patients with dementia whose symptoms have been identified in primary care but have no formal diagnosis: a retrospective case-control study using electronic primary care records[J]. BMJ Open, 2021, 11(1): e039248. DOI: 10.1136/bmjopen-2020-039248.

[9] JAUK S, KRAMER D, GROßAUER B, *et al*. Risk prediction of delirium in hospitalized patients using machine learning: an implementation and prospective evaluation study[J]. J Am Med Inform Assoc, 2020, 27(9): 1383-1392. DOI: 10.1093/jamia/ocaa113.

[10] ELY E W, INOUYE S K, BERNARD G R, *et al*. Delirium in mechanically ventilated patients: validity and reliability of the confusion assessment method for the intensive care unit (CAM-ICU)[J]. JAMA, 2001, 286(21): 2703-2710. DOI: 10.1001/jama.286.21.2703.

[11] BROWN C H 4th, PROBERT J, HEALY R, *et al*. Cognitive decline after delirium in patients undergoing cardiac surgery[J]. Anesthesiology, 2018, 129(3): 406-416. DOI: 10.1097/ALN.0000000000002253.

[12] ERIKSON K, ALA-KOKKO T I, KOSKENKARI J, *et al*.

Elevated serum S-100β in patients with septic shock is associated with delirium[J]. Acta Anaesthesiol Scand, 2019, 63(1): 69-73. DOI: 10.1111/aas.13228.

[13] GAILIUŠAS M, ANDREJAITIEN Ė J, ŠIRVINSKAS E, *et al*. Association between serum biomarkers and postoperative delirium after cardiac surgery[J]. Acta Med Litu, 2019, 26(1): 8-10. DOI: 10.6001/actamedica.v26i1.3949.

[14] BALLWEG T, WHITE M, PARKER M, *et al*. Association between plasma tau and postoperative delirium incidence and severity: a prospective observational study[J]. Br J Anaesth, 2021, 126(2): 458-466. DOI: 10.1016/j.bja.2020.08.061.

[15] KAZMIERSKI J, BANYS A, LATEK J, *et al*. Mild cognitive impairment with associated inflammatory and cortisol alterations as independent risk factor for postoperative delirium[J]. Dement Geriatr Cogn Disord, 2014, 38(1/2): 65-78. DOI: 10.1159/000357454.

[16] ZHAN S Z, HUANG B X, XUE F, *et al*. A functional outcome prediction model of acute traumatic spinal cord injury based on extreme gradient boost[J]. J Orthop Surg Res, 2022, 17(1): 451. DOI: 10.1186/s13018-022-03343-7.

[17] 洪亮, 孙加奎, 沈骁, 等. 心脏手术后谵妄的危险因素分析及预测模型构建[J]. 临床麻醉学杂志, 2020, 36(12): 1195-1200. DOI: 10.12089/jca.2020.12.012.
HONG L, SUN J K, SHEN X, *et al*. Risk factors analysis and prediction model construction of postoperative delirium after cardiac sur-gery[J]. J Clin Anesthesiol, 2020, 36(12): 1195-1200. DOI: 10.12089/jca.2020.12.012.

[18] SHI Q K, MU X W, ZHANG C, *et al*. Risk factors for postoperative delirium in type A aortic dissection patients: a retrospective study[J]. Med Sci Monit, 2019, 25: 3692-3699. DOI: 10.12659/MSM.913774.

[19] DJAIANI G, SILVERTON N, FEDORKO L, *et al*. Dexmedetomidine versus propofol sedation reduces delirium after cardiac surgery: a randomized controlled trial[J]. Anesthesiology, 2016, 124(2): 362-368. DOI: 10.1097/ALN.0000000000000951.

[20] DUAN X, COBURN M, ROSSAINT R, *et al*. Efficacy of perioperative dexmedetomidine on postoperative delirium: systematic review and meta-analysis with trial sequential analysis of randomised controlled trials[J]. Br J Anaesth, 2018, 121(2): 384-397. DOI: 10.1016/j.bja.2018.04.046.

[21] GREAVES D, PSALTIS P J, DAVIS D H J, *et al*. Risk factors for delirium and cognitive decline following coronary artery bypass grafting surgery: a systematic review and meta-analysis[J]. J Am Heart Assoc, 2020, 9(22): e017275. DOI: 10.1161/JAHA.120.017275.

[22] 王菲, 吕海涛, 唐新慧, 等. 术前血清尿酸水平与患者术后谵妄的关系[J]. 中华麻醉学杂志, 2022, 42(7): 807-812. DOI: 10.3760/cma.j.cn131073.20220314.00704.
WANG F, LYU H T, TANG X H, *et al*. Relationship between preoperative levels of serum uric acid and postoperative delirium[J]. Chin J Anesthesiol, 2022, 42(7): 807-812. DOI: 10.3760/cma.j.cn131073.20220314.00704.

[23] VAN DER PLOEG T, AUSTIN P C, STEYERBERG E W. Modern modelling techniques are data hungry: a simulation study for predicting dichotomous endpoints[J]. BMC Med Res Methodol, 2014, 14: 137. DOI: 10.1186/1471-2288-14-137.

(**收稿**:2023-01-01;**修回**:2023-02-15)

(编辑 栾 嘉)