

· 论著 ·

两种机器学习模型对急性冠脉综合征患者发生 院内心搏骤停的预测价值比较

扫描二维码
查看更多

杨贵分, 张少华, 刘卫珍, 陈敏霞, 姚兰, 廖旭

作者单位: 430070湖北省武汉市, 中部战区总医院心血管内科

通信作者: 张少华, E-mail: 1692593007@qq.com

【摘要】 目的 比较两种机器学习模型〔决策树早期预警得分(DTEWS)模型、决策树模型〕对急性冠状动脉综合征(ACS)患者发生院内心搏骤停(IHCA)的预测价值。**方法** 采用便利抽样法回顾性选取2018—2022年入住某三甲医院心血管内科的发生IHCA的ACS患者53例为IHCA组, 选取同期入住某三甲医院心血管内科的未发生IHCA的ACS患者706例为非IHCA组。基于两种机器学习模型中的预测因子, 收集患者一般资料, 采用ROC曲线评估两种机器学习模型对ACS患者发生IHCA的预测价值。**结果** 两组年龄、糖尿病发生率、致命性心律失常发生率、吸氧者占比、入院方式和入院时Killip分级、收缩压、舒张压、血尿素氮、心肌肌钙蛋白T、意识状态及住院时间比较, 差异有统计学意义($P < 0.05$)。ROC曲线分析结果显示, DTEWS模型、决策树模型预测ACS患者发生IHCA的AUC分别为0.815 [95%CI (0.785~0.842)]、0.824 [95%CI (0.795~0.851)]。DTEWS模型、决策树模型预测ACS患者发生IHCA的AUC比较, 差异无统计学意义($P > 0.05$)。**结论** DTEWS模型、决策树模型均对ACS患者发生IHCA有中等预测价值, 其中DTEWS模型纳入变量较少、易获取且计算方式简单, 更适宜临床推广。

【关键词】 急性冠脉综合征; 猝死, 心脏; 院内心搏骤停; 机器学习; 预测**【中图分类号】** R 542.2 **【文献标识码】** A DOI: 10.12114/j.issn.1008-5971.2024.00.070

Comparison of Predictive Value of Two Machine Learning Models for In-Hospital Cardiac Arrest in Patients with Acute Coronary Syndrome

YANG Guifen, ZHANG Shaohua, LIU Weizhen, CHEN Minxia, YAO Lan, LIAO Xu

Department of Cardiology, General Hospital of Central Theater Command, Wuhan 430070, China

Corresponding author: ZHANG Shaohua, E-mail: 1692593007@qq.com

【Abstract】 Objective To compare the predictive value of two machine learning models [decision-tree early warning score (DTEWS) model and decision tree model] for in-hospital cardiac arrest (IHCA) in patients with acute coronary syndrome (ACS). **Methods** Fifty-three ACS patients with IHCA who were admitted to the Cardiovascular Department of a tertiary hospital from 2018 to 2022 were retrospectively selected as the IHCA group by convenience sampling method, and 706 ACS patients without IHCA who were admitted to the Cardiovascular Department of a tertiary hospital during the same period were selected as the non-IHCA group. Based on the predictors in the two machine learning models, general information of patients was collected, and ROC curve was used to assess the predictive value of the two machine learning models for IHCA in ACS patients. **Results** There were significant differences in age, incidence of diabetes, incidence of fatal arrhythmia, percentage of oxygen users, mode of admission and Killip classification, systolic blood pressure, diastolic blood pressure, blood urea nitrogen, cardiac troponin T and state of consciousness at admission, and length of hospital stay between the two groups ($P < 0.05$). ROC curve analysis showed that the AUC of DTEWS model and decision tree model for predicting IHCA in ACS patients was 0.815 [95%CI (0.785–0.842)] and 0.824 [95%CI (0.795–0.851)], respectively. There was no statistically significant difference in AUC of DTEWS model and decision tree model for predicting IHCA in ACS patients ($P < 0.05$). **Conclusion** Both DTEWS model and decision tree model have moderate predictive value for IHCA in ACS patients. Among them, DTEWS model has fewer variables, easy access and simple calculation method, and is more suitable for clinical promotion.

【Key words】 Acute coronary syndrome; Death, sudden, cardiac; In-hospital cardiac arrest; Machine learning; Forecasting

院内心搏骤停 (in-hospital cardiac arrest, IHCA) 是急性冠脉综合征 (acute coronary syndrome, ACS) 患者的一种不常见但威胁生命的并发症, 其发生率约为 1.7%, 且相比于未发生 IHCA 的 ACS 患者, 发生 IHCA 的 ACS 患者院内死亡风险增加 7 倍^[1]。一项关于 IHCA 患者预后的研究表明, IHCA 患者自主循环恢复率为 35.5%, 自主循环恢复后 1 个月生存率为 8.7%, 存活出院且神经功能预后良好者仅占 6.4%^[2]。故如何快速、准确、高效地评估 ACS 患者病情、预测 IHCA 的发生概率以提高复苏成功率、改善患者预后是亟待解决的问题。风险预测模型是基于 IHCA 的发生受多种因素影响这一事实, 通过统计模型对患者未来发生 IHCA 的可能性进行预测。随着互联网技术的迅猛发展, 人工智能技术如机器学习、深度学习等在医疗领域的应用日渐成熟。研究证实, 相较于传统统计学方法, 基于机器学习算法建立的模型预测性能更优, 且基于预测结果对患者实施干预可有效降低 IHCA 发生率^[3-4]。目前国外已有多位学者构建了 ACS 患者发生 IHCA 风险的机器学习预测模型, 其中 BADRIYAH 等^[5] 构建的决策树早期预警得分 (decision-tree early warning score, DTEWS) 模型以及 LI 等^[6] 构建的决策树模型的预测性能均较好, 纳入变量的数量适中且较易获取, 临床应用更简单易行, 但其均未进行外部验证, 且哪种模型更适合我国医疗环境尚不清楚。因此, 本研究采用空间验证的方式对 DTEWS 模型、决策树模型进行外部验证, 比较其对 ACS 患者发生 IHCA 的预测价值, 旨在为模型的应用与推广奠定基础。

1 对象与方法

1.1 纳入机器学习模型介绍

1.1.1 DTEWS 模型

BADRIYAH 等^[5] 构建的 DTEWS 模型包括呼吸频率、血氧饱和度、吸氧情况、体温、收缩压、脉搏、意识状态 7 个变量, 每个变量评分为 0~3 分, 总分范围为 0~21 分, 得分越低表示 ACS 患者 IHCA 发生风险越低, 见表 1。

1.1.2 决策树模型

LI 等^[6] 构建的决策树模型包括重要早期预警评分 (Vital PAC Early Warning Score, ViEWS)、有无致命性心律失常、Killip 分级、心肌肌钙蛋白 T (cardiac troponin T, cTnT)、血尿素氮、年龄、有无糖尿病 7 个变量, 其中 ViEWS 评估方式见表 2, 该模型的危险分层方法见表 3。

1.2 研究对象

采用便利抽样法回顾性选取 2018—2022 年入住某三甲医院心血管内科的发生 IHCA 的 ACS 患者 53 例为 IHCA 组, 选取同期入住某三甲医院心血管内科的未发生

表1 DTEWS模型

Table 1 DTEWS model

评估指标	0分	1分	2分	3分
呼吸频率 (次/min)	≤18	19~20	21~24	≥25
血氧饱和度 (%)	95~99	93~94或100	90~92	≤89
吸氧	无	—	—	有
体温 (℃)	36.5~37.1	36.1~36.4或37.2~37.5	35.9~36.0或≥37.6	≤35.8
收缩压 (mmHg)	117~272	90~116	—	≤89或≥273
脉搏 (次/min)	47~89	39~46或90~100	≥101	≤38
意识状态	A	—	—	V、P、U

注: A表示清醒, V表示语言反应, P表示疼痛反应, U表示无反应; —表示无此项内容; 1 mmHg=0.133 kPa。

表2 决策树模型中ViEWS评估方式

Table 2 ViEWS evaluation method in decision tree model

评估指标	0分	1分	2分	3分
脉搏 (次/min)	51~90	41~50或91~110	≤40或111~130	≥131
呼吸频率 (次/min)	12~20	9~11	21~24	≤8或≥25
体温 (℃)	36.1~38.0	35.1~36.0或38.1~39.0	≥39.1	≤35.0
收缩压 (mmHg)	111~249	101~110或≥250	91~100	≤90
血氧饱和度 (%)	≥96	94~95	92~93	≤91
吸氧	无	—	—	有
意识状态	A	—	—	V、P、U

注: —表示无此项内容。

表3 决策树模型的危险分层方法

Table 3 Risk stratification method for decision tree model

分层	变量
高风险 (70%~100%)	ViEWS<5分, 有致命性心律失常, Killip分级>Ⅱ级, cTnT≥10 μg/L ViEWS≥5分, 有糖尿病
中风险 (40%~69%)	ViEWS<5分, 有致命性心律失常, Killip分级>Ⅱ级, cTnT<10 μg/L, 血尿素氮<7.9 mmol/L ViEWS≥5分, 无糖尿病, 年龄≥64岁
低风险 (<40%)	ViEWS<5分, 无致命性心律失常 ViEWS<5分, 有致命性心律失常, Killip分级≤Ⅱ级 ViEWS<5分, 有致命性心律失常, Killip分级>Ⅱ级, cTnT<10 μg/L, 血尿素氮≥7.9 mmol/L

注: ViEWS=重要早期预警评分, cTnT=心肌肌钙蛋白T。

IHCA的ACS患者706例为非IHCA组。纳入标准: (1) 年龄≥18岁; (2) 经血清心肌损伤标志物、心电图检查确诊为ACS; (3) 首次诊断为ACS。排除标准: (1) 手术过程中心搏骤停者; (2) 有心搏骤停史者; (3) 安装心脏起搏器者; (4) 临床资料不完整者; (5) 住院时间<24 h者; (6) 合并扩张型心肌病、先天性心脏病者; (7) 肝硬化失代偿期者; (8) 恶性肿瘤伴恶病质者。本研究已获得本医院伦理委员会批准

(伦理编号: [2023] 048-01)。

1.3 研究方法

基于两种机器学习模型中的预测因子,收集患者一般资料,包括年龄、性别、BMI、吸烟史、饮酒史、心血管疾病家族史、糖尿病发生情况、致命性心律失常发生情况、吸氧情况、入院方式(门诊或急诊)和入院时Killip分级、呼吸频率、脉搏、体温、收缩压、舒张压、血尿素氮、cTnT、血氧饱和度、意识状态及住院时间。

1.4 统计学方法

采用SPSS、MedCalc进行统计分析。计数资料以相对数表示,组间比较采用 χ^2 检验;等级资料比较采用秩和检验;符合正态分布的计量资料以 $(\bar{x} \pm s)$ 表示,两组间比较采用独立样本 t 检验;不符合正态分布的计量资料以 $M(P_{25}, P_{75})$ 表示,组间比较采用秩和检验;采用ROC曲线评估两种机器学习模型对ACS患者发生IHCA的预测价值,AUC ≥ 0.9 说明预测价值较高,AUC ≥ 0.7 且 <0.9 表示预测价值中等,AUC ≥ 0.5 且 <0.7 表示预测价值较低^[7];采用Delong检验比较AUC。以 $P<0.05$ 为差异有统计学意义。

2 结果

2.1 两组一般资料比较

两组年龄、糖尿病发生率、致命性心律失常发生率、吸氧者占比、入院方式和入院时Killip分级、收缩压、舒张压、血尿素氮、cTnT、意识状态及住院时间比较,差异有统计学意义($P<0.05$);两组性别、BMI、有吸烟史者占比、有饮酒史者占比、有心血管疾病家族史者占比和入院时呼吸频率、脉搏、体温、血氧饱和度比较,差异无统计学意义($P>0.05$),见表4。

2.2 两种机器学习模型对ACS患者发生IHCA的预测价值

ROC曲线分析结果显示,DTEWS模型、决策树模型预测ACS患者发生IHCA的AUC分别为0.815 [95%CI (0.785~0.842)]、0.824 [95%CI (0.795~0.851)],见图1。DTEWS模型、决策树模型预测ACS患者发生IHCA的AUC比较,差异无统计学意义($Z=0.315, P=0.757$)。

3 讨论


在全球范围内,IHCA的发生率、病死率均居于高位,其最常见的原因因为ACS^[8]。目前IHCA领域的研究重点为抢救和救治策略,而如何筛选出IHCA高风险人群的研究相对不足^[9]。机器学习模型可通过机器学习算法组合多个危险因素,对海量数据的输入特征进行分析,自主学习并做出推断,进而预测ACS患者IHCA发生风险^[10]。相比于传统预测模型,机器学习算法建立的模型降低了排除重要变量的可能性,在许多情况下其

性能优于传统统计学方法^[3-4]。本研究采用空间验证的方式对DTEWS模型、决策树模型进行外部验证,比较其对ACS患者发生IHCA的预测价值。

表4 两组一般资料比较
Table 4 Comparison of general information between the two groups

项目	IHCA组 (n=53)	非IHCA组 (n=706)	检验统计量值	P值
年龄 [n (%)]			16.354 ^a	<0.001
<60岁	4 (7.5)	244 (34.6)		
≥ 60 岁	49 (92.5)	462 (65.4)		
性别 [n (%)]			0.002 ^a	0.962
男	38 (71.7)	504 (71.4)		
女	15 (28.3)	202 (28.6)		
BMI [$M(P_{25}, P_{75})$, kg/m ²]	23.4 (20.8, 24.8)	23.9 (20.8, 25.1)	-0.345 ^b	0.730
吸烟史 [n (%)]	20 (37.7)	296 (41.9)	0.356 ^c	0.551
饮酒史 [n (%)]	10 (18.9)	193 (27.3)	1.805 ^c	0.179
心血管疾病家族史 [n (%)]	6 (11.3)	86 (12.2)	0.049 ^c	0.825
糖尿病 [n (%)]	28 (52.8)	261 (37.0)	5.260 ^c	0.022
致命性心律失常 [n (%)]	8 (15.1)	16 (2.3)	26.494 ^a	<0.001
吸氧 [n (%)]	53 (100.0)	501 (71.0)	21.084 ^a	<0.001
入院方式 [n (%)]			30.304 ^a	<0.001
门诊	7 (13.2)	370 (52.4)		
急诊	46 (86.8)	336 (47.6)		
入院时Killip分级 [n (%)]			10.390 ^b	<0.001
I级	19 (35.8)	618 (87.5)		
II级	17 (32.1)	75 (10.6)		
III级	8 (15.1)	7 (1.0)		
IV级	9 (17.0)	6 (0.8)		
入院时呼吸频率 [$M(P_{25}, P_{75})$, 次/min]	19.0 (19.0, 19.0)	19.0 (18.0, 19.0)	-1.095 ^b	0.274
入院时脉搏 [$M(P_{25}, P_{75})$, 次/min]	72.0 (68.5, 85.0)	74.0 (66.0, 83.0)	-0.566 ^b	0.572
入院时体温 [$M(P_{25}, P_{75})$, $^{\circ}\text{C}$]	36.4 (36.3, 36.5)	36.4 (36.3, 36.5)	-1.780 ^b	0.075
入院时收缩压 ($\bar{x} \pm s$, mmHg)	120 \pm 14	126 \pm 20	2.275 ^c	0.026
入院时舒张压 ($\bar{x} \pm s$, mmHg)	70 \pm 12	74 \pm 14	2.054 ^c	0.040
入院时血尿素氮 [$M(P_{25}, P_{75})$, mmol/L]	14.5 (7.4, 21.1)	5.9 (4.8, 7.6)	-7.353 ^b	<0.001
入院时cTnT [$M(P_{25}, P_{75})$, $\mu\text{g/L}$]	2.84 (0.32, 6.02)	0.06 (0.02, 0.51)	-8.178 ^b	<0.001
入院时血氧饱和度 [$M(P_{25}, P_{75})$, %]	98.0 (97.0, 98.0)	98.0 (97.0, 98.0)	-0.713 ^b	0.476
入院时意识状态 [n (%)]			80.561 ^a	<0.001
清醒	47 (88.7)	706 (100.0)		
语言反应	1 (1.9)	0		
疼痛反应	5 (9.4)	0		
无反应	0	0		
住院时间 [$M(P_{25}, P_{75})$, d]	3 (2, 4)	5 (3, 8)	-6.232 ^b	<0.001

注: IHCA=院内心搏骤停; ^a表示 χ^2 值, ^b表示Z值, ^c表示 t 值。



注：DTEWS=决策树早期预警得分。

图1 两种机器学习模型预测ACS患者发生IHCA的ROC曲线

Figure 1 ROC curve of the two machine learning models in predicting IHCA in patients with ACS

本研究结果显示，两组年龄、糖尿病发生率、致命性心律失常发生率、吸氧者占比、入院方式和入院时Killip分级、收缩压、舒张压、血尿素氮、cTnT、意识状态及住院时间比较，差异有统计学意义，提示ACS患者发生IHCA可能与上述因素有关，但使用单一因素预测ACS患者发生IHCA的风险效果欠佳。风险预测模型相关研究包括预测模型的开发、内部验证、外部验证和模型优化以及模型对临床工作和患者预后的影响^[11]。DTEWS模型纳入了呼吸频率、血氧饱和度、吸氧情况、体温、收缩压、脉搏、意识状态7个变量，BADRIYAH等^[5]前期内部验证结果显示，DTEWS模型预测ACS患者发生IHCA的AUC为0.88；本研究ROC曲线分析结果显示，DTEWS模型预测ACS患者发生IHCA的AUC为0.815，内、外部验证结果均提示其对ACS患者发生IHCA有中等预测价值。决策树模型纳入了ViEWS、有无致命性心律失常、Killip分级、cTnT、血尿素氮、年龄、有无糖尿病7个变量，其中ViEWS又包括脉搏、呼吸频率、体温、收缩压、血氧饱和度、吸氧情况、意识状态7个变量，LI等^[6]前期内部验证结果显示，决策树模型预测ACS患者发生IHCA的AUC为0.84；本研究ROC曲线分析结果显示，决策树模型预测ACS患者发生IHCA的AUC为0.824，内、外部验证结果均提示其对ACS患者发生IHCA有中等预测价值。本研究结果还显示，DTEWS模型、决策树模型预测ACS患者发生IHCA的AUC比较，差异无统计学意义，提示两种模型对ACS患者发生IHCA的预测价值相当，但决策树模型纳入的变量相对较多，且需要进行二次计算，不利于临床实践。

4 结论

综上所述，DTEWS模型、决策树模型均对ACS患者发生IHCA有中等预测价值，其中DTEWS模型纳入变量较少、易获取且计算方式简单，更适宜临床推广。但本研究为单中心研究，今后可继续扩大样本量、开展多中心研究并补充预测因子、调整模型算法，以进一步提高模型的预测能力；同时，也可构建计算机辅助决策系统，将风险预测模型植入现有护理信息系统中，利用系统自行抓取所需数据并自动计算ACS患者发生IHCA的风险，这可缩短护士工作时间，降低人工计算造成的误判率^[12]，从而达到改善ACS患者临床结局的目的。

作者贡献：杨贵分进行文章的构思与设计、研究的实施与可行性分析，撰写论文；陈敏霞、姚兰、廖旭进行数据收集；杨贵分、陈敏霞、姚兰、廖旭进行数据整理；刘卫珍进行统计学处理；张少华、刘卫珍进行结果的分析与解释；杨贵分、张少华进行论文的修订；张少华负责文章的质量控制及审校，对文章整体负责、监督管理。

本文无利益冲突。

参考文献

- [1] KONTOS M C, FORDYCE C B, CHEN A Y, et al. Association of acute myocardial infarction cardiac arrest patient volume and in-hospital mortality in the United States: insights from the National Cardiovascular Data Registry Acute Coronary Treatment and Intervention Outcomes Network Registry [J]. Clin Cardiol, 2019, 42 (3): 352-357. DOI: 10.1002/clc.23146.
- [2] SHAO F, LI C S, LIANG L R, et al. Incidence and outcome of adult in-hospital cardiac arrest in Beijing, China [J]. Resuscitation, 2016, 102: 51-56. DOI: 10.1016/j.resuscitation.2016.02.002.
- [3] AZIZ F, MALEK S, IBRAHIM K S, et al. Short- and long-term mortality prediction after an acute ST-elevation myocardial infarction (STEMI) in Asians: a machine learning approach [J]. PLoS One, 2021, 16 (8): e0254894. DOI: 10.1371/journal.pone.0254894.
- [4] CHURPEK M M, YUEN T C, WINSLOW C, et al. Multicenter comparison of machine learning methods and conventional regression for predicting clinical deterioration on the wards [J]. Crit Care Med, 2016, 44 (2): 368-374. DOI: 10.1097/CCM.0000000000001571.
- [5] BADRIYAH T, BRIGGS J S, MEREDITH P, et al. Decision-tree early warning score (DTEWS) validates the design of the National Early Warning Score (NEWS) [J]. Resuscitation, 2014, 85 (3): 418-423. DOI: 10.1016/j.resuscitation.2013.12.011.
- [6] LI H, WU T T, YANG D L, et al. Decision tree model for predicting in-hospital cardiac arrest among patients admitted with acute coronary syndrome [J]. Clin Cardiol, 2019, 42 (11): 1087-1093. DOI: 10.1002/clc.23255.
- [7] 尉洁. ROC曲线广义线性模型及其医学应用 [D]. 太原: 山西医科大学, 2010.

- [19] LEONE M, FERRARO S, PROIETTI CECCHINI A. The neurobiology of cluster headache [J]. *Handb Clin Neurol*, 2021, 182: 401–414. DOI: 10.1016/B978-0-12-819973-2.00027-7.
- [20] LEONE M, PROIETTI CECCHINI A. Advances in the understanding of cluster headache [J]. *Expert Rev Neurother*, 2017, 17 (2): 165–172. DOI: 10.1080/14737175.2016.1216796.
- [21] BUTURE A, GOORIAH R, NIMERI R, et al. Current understanding on pain mechanism in migraine and cluster headache [J]. *Anesth Pain Med*, 2016, 6 (3): e35190. DOI: 10.5812/aapm.35190.
- [22] CARMINE BELIN A, RAN C, EDVINSSON L. Calcitonin gene-related peptide (CGRP) and cluster headache [J]. *Brain Sci*, 2020, 10 (1): 30. DOI: 10.3390/brainsci10010030.
- [23] OTTOSSON A, EDVINSSON L. Release of histamine from dural mast cells by substance P and calcitonin gene-related peptide [J]. *Cephalalgia*, 1997, 17 (3): 166–174. DOI: 10.1046/j.1468-2982.1997.1703166.x.
- [24] IYENGAR S, JOHNSON K W, OSSIPOV M H, et al. CGRP and the trigeminal system in migraine [J]. *Headache*, 2019, 59 (5): 659–681. DOI: 10.1111/head.13529.
- [25] GOADSBY P J, HOSKIN K L. Serotonin inhibits trigeminal nucleus activity evoked by craniovascular stimulation through a 5HT1B/1D receptor: a central action in migraine? [J]. *Ann Neurol*, 1998, 43 (6): 711–718. DOI: 10.1002/ana.410430605.
- [26] GOADSBY P J. Serotonin receptor ligands: treatments of acute migraine and cluster headache [J]. *Handb Exp Pharmacol*, 2007 (177): 129–143. DOI: 10.1007/978-3-540-33823-9_5.
- [27] LIU L J, YANG T M, LIEDTKE W, et al. Chronic IL-1 β signaling potentiates voltage-dependent sodium currents in trigeminal nociceptive neurons [J]. *J Neurophysiol*, 2006, 95 (3): 1478–1490. DOI: 10.1152/jn.00509.2005.
- [28] ŞAHİN E, KARAASLAN Z, ŞANLI E, et al. Reduced expression of inflammasome complex components in cluster headache [J]. *Headache*, 2022, 62 (8): 967–976. DOI: 10.1111/head.14334.
- [29] PUJO J, DE PALMA G, LU J, et al. Gut microbiota modulates visceral sensitivity through calcitonin gene-related peptide (CGRP) production [J]. *Gut Microbes*, 2023, 15 (1): 2188874. DOI: 10.1080/19490976.2023.2188874.
- [30] XIANG Q R, TANG X, CUI S M, et al. Capsaicin, the spicy ingredient of chili peppers: effects on gastrointestinal tract and composition of gut microbiota at various dosages [J]. *Foods*, 2022, 11 (5): 686. DOI: 10.3390/foods11050686.
- [31] DE VADDER F, GRASSET E, MANNERÅS HOLM L, et al. Gut microbiota regulates maturation of the adult enteric nervous system via enteric serotonin networks [J]. *Proc Natl Acad Sci USA*, 2018, 115 (25): 6458–6463. DOI: 10.1073/pnas.1720017115.
- [32] ZHANG Z W, GAO C S, ZHANG H, et al. Morinda officinalis oligosaccharides increase serotonin in the brain and ameliorate depression via promoting 5-hydroxytryptophan production in the gut microbiota [J]. *Acta Pharm Sin B*, 2022, 12 (8): 3298–3312. DOI: 10.1016/j.apsb.2022.02.032.
- [33] HE Q, WANG W, XIONG Y, et al. International Headache Genetics Consortium. A causal effects of gut microbiota in the development of migraine [J]. *J Headache Pain*, 2023, 24 (1): 90. DOI: 10.1186/s10194-023-01609-x.
- [34] MAYER E A, TILLISCH K, GUPTA A. Gut/brain axis and the microbiota [J]. *J Clin Invest*, 2015, 125 (3): 926–938. DOI: 10.1172/JCI76304.
- [35] HINDIYEH N, AURORA S K. What the gut can teach us about migraine [J]. *Curr Pain Headache Rep*, 2015, 19 (7): 33. DOI: 10.1007/s11916-015-0501-4.
- [36] 刘雪梅, 丁佳虹, 聂超, 等. 两样本孟德尔随机化分析肠道微生物与精神分裂症的因果关系 [J]. *现代预防医学*, 2023, 50 (1): 27–32. DOI: 10.20043/j.cnki.MPM.202206702.
- [37] JIN Q, REN F, DAI D, et al. The causality between intestinal flora and allergic diseases: insights from a bi-directional two-sample Mendelian randomization analysis [J]. *Front Immunol*, 2023, 14: 1121273. DOI: 10.3389/fimmu.2023.1121273.

(收稿日期: 2023-10-23; 修回日期: 2024-02-04)

(本文编辑: 谢武英)

(上接第42页)

- [8] CHUGH S S, REINIER K, TEODORESCU C, et al. Epidemiology of sudden cardiac death: clinical and research implications [J]. *Prog Cardiovasc Dis*, 2008, 51 (3): 213–228. DOI: 10.1016/j.pcad.2008.06.003.
- [9] 吴婷婷, 李红. 院内心搏骤停早期预警评分系统的研究进展 [J]. *中华护理杂志*, 2016, 51 (9): 1118–1123. DOI: 10.3761/j.issn.0254-1769.2016.09.022.
- [10] 吴秋硕, 陆宗庆, 刘瑜, 等. 机器学习应用于心脏骤停早期预测模型的系统评价 [J]. *中国循证医学杂志*, 2021, 21 (8): 942–952. DOI: 10.7507/1672-2531.202103082.
- [11] MOONS K G M, KENGNE A P, GROBBEE D E, et al. Risk prediction models: II. External validation, model updating, and impact assessment [J]. *Heart*, 2012, 98 (9): 691–698. DOI: 10.1136/heartjnl-2011-301247.
- [12] 王草源, 王荣, 顾则娟, 等. 临床决策支持系统护理计划模块的设计与研发 [J]. *中国实用护理杂志*, 2021, 37 (3): 223–228. DOI: 10.3760/ema.j.cn211501-20200414-01853.

(收稿日期: 2023-11-01; 修回日期: 2024-01-23)

(本文编辑: 崔丽红)