

· 论 著 ·

## 两种急性百草枯中毒死亡预测模型比较

孙颖<sup>1,2</sup>, 张瑞<sup>3</sup>, 于海涛<sup>4</sup>, 邹晓艳<sup>2</sup>, 赵鹏<sup>5</sup>

1. 青岛大学基础医学院, 山东 青岛 266075; 2. 青岛市第八人民医院消化内一科; 3. 山东省立医院药剂科;  
4. 青岛市市立医院重症医学科; 5. 青岛大学附属医院病理科

**摘要:** **目的** 比较Cox比例风险回归模型和极端梯度上升(XGBoost)模型对急性百草枯中毒(APP)死亡的预测效果。**方法** 选择青岛市第八人民医院和山东省立医院于2018年1月1日—2020年12月1日收治的APP患者为研究对象, 采用随机数表法分为训练组和验证组。分别建立Cox比例风险回归模型和XGBoost模型筛选APP患者死亡的预测因素。采用受试者工作特征曲线(ROC)分析两种模型的预测效能, 采用Hosmer-Lemeshow检验评价两种模型的校准度。**结果** 共纳入APP患者150例, 训练组和验证组各75例, 分别死亡52例和55例, 占69.33%和73.33%。Cox比例风险回归模型结果显示, 摄入百草枯剂量、服毒至就诊时间、首次灌流时间、首次呕吐时间、谷草转氨酶、谷丙转氨酶、血肌酐、尿素氮、白细胞、动脉血乳酸、肌酸激酶同工酶、血糖、血钙和血钾是APP患者死亡的独立预测因素(均 $P < 0.05$ )。XGBoost模型结果显示, 预测能力由强到弱的因素依次为服毒至就诊时间、首次呕吐时间、首次灌流时间、动脉血乳酸、白细胞、摄入百草枯剂量、血肌酐、血钾、血钙、肌酸激酶同工酶、血糖、谷草转氨酶、尿素氮和谷丙转氨酶。XGBoost模型预测APP患者死亡的AUC值为0.972, 大于Cox比例风险回归模型的0.921( $P < 0.05$ )。Cox比例风险回归模型、XGBoost模型的预测结果与实际死亡情况的一致性均较好( $P > 0.05$ )。**结论** Cox比例风险回归模型和XGBoost模型筛选APP患者死亡的预测因素一致, 但后者预测能力优于前者。

**关键词:** 急性百草枯中毒; Cox比例风险回归模型; 极端梯度上升模型; 预测

**中图分类号:** R446.1 **文献标识码:** A **文章编号:** 2096-5087(2021)08-0762-06

## Comparison of two prediction models for mortality of acute paraquat poisoning

SUN Ying\*, ZHANG Rui, YU Haitao, ZOU Xiaoyan, ZHAO Peng

\*School of Basic Medicine, Qingdao University, Qingdao, Shandong 266075, China; Department of Gastroenterology, Qingdao Eighth People's Hospital

**Abstract: Objective** To compare the effects of Cox proportional hazard regression model (Cox model) and extreme gradient boosting model (XGBoost model) on the prediction of the mortality of acute paraquat poisoning (APP). **Methods** The APP cases admitted to Qingdao Eighth People's Hospital and Shandong Provincial Hospital from January 1st of 2018 to December 1st of 2020 was recruited and divided into a training group and a verification group by a random number table. The Cox model and XGBoost model were established to select the predictors for APP mortality. Receiver operating characteristic (ROC) curve was drawn to analyze the predictive power of the two models, and the calibration was evaluated using Hosmer-Lemeshow test. **Results** Totally 150 APP cases were recruited. There were 75 cases each in the training group and in the verification group, with 52 and 55 cases died respectively, accounting for 69.33% and 73.33%. The Cox model showed that paraquat intake, the time from taking poison to seeing a doctor, the time for the first perfusion, the time for the first vomiting, aspartate aminotransferase, alanine aminotransferase, serum creatinine, blood urea nitrogen, white blood cell, lactic acid, creatine kinase isoenzymes, glucose, serum calcium

DOI: 10.19485/j.cnki.issn2096-5087.2021.08.002

基金项目: 山东省自然科学基金(ZR2018PH037)

作者简介: 孙颖, 本科, 副主任医师, 主要从事消化内科工作

通信作者: 赵鹏, E-mail: saxmd41@163.com

and serum potassium were the predictors of APP mortality (all  $P < 0.05$ ). The XGBoost model showed that the predictive power of the factors in a descending order were the time from taking poison to seeing a doctor, the time for the first vomiting, the time for the first perfusion, lactic acid, white blood cell, paraquat intake, serum creatinine, serum potassium, serum calcium, creatine kinase isoenzymes, glucose, aspartate aminotransferase, blood urea nitrogen and alanine aminotransferase. The area under curve (AUC) of the XGBoost model for predicting was 0.972, which was greater than 0.921 of the Cox model ( $P < 0.05$ ). The predicted results of the Cox model and XGBoost model were consistent with the actual situation ( $P > 0.05$ ). **Conclusion** The Cox model and XGBoost model are consistent in predicting the mortality of APP, but the latter is better.

**Keywords:** acute paraquat poisoning; Cox proportional hazard regression model; extreme gradient boosting model; prediction

百草枯是一种高效能非选择性接触型除草剂, 对人畜具有极强毒性。急性百草枯中毒 (acute paraquat poisoning, APP) 由患者短间接触较大剂量百草枯所致, 主要表现为急性肺损伤, 并伴有严重肝肾损伤, 对患者生命安全造成极大威胁<sup>[1]</sup>。有研究表明, APP 患者预后情况较差, 病死率为 50%~90%<sup>[2]</sup>, 因此探索 APP 患者死亡的预测因素, 对抢救方案制订和患者预后评估具有重要的指导意义。

Cox 比例风险回归模型是一种通过半参数法建立的回归模型, 常用于生存资料的多因素分析。该模型对生存资料的分布类型无特定要求, 但依赖于严格的比例风险假设, 在一定程度上限制了模型的预测能力<sup>[3]</sup>。极端梯度上升 (extreme gradient boosting, XGBoost) 法是近年逐渐兴起的一种基于分类树模型的集成学习算法, 通过迭代计算方法将准确率低的分类器组合成准确率高的分类器, 运行速度快, 训练结果准, 且对数据要求宽松<sup>[4]</sup>。XGBoost 内部还包含了大量的分类与回归树, 可使用残差提升模型的预测能力, 内部的正则化可预防过拟合, 保证模型的稳健性<sup>[5]</sup>, 已广泛应用于危险因素筛选、统计学习及人工智能等多种领域<sup>[6-7]</sup>。本研究通过比较 XGBoost 模型与 Cox 比例风险回归模型对 APP 患者死亡的预测效果, 为提高 APP 患者预后水平提供参考。

## 1 对象与方法

**1.1 对象** 选择青岛市第八人民医院和山东省立医院于 2018 年 1 月 1 日—2020 年 12 月 1 日收治的 APP 患者为研究对象, 采用随机数表法分为训练组和验证组。纳入标准: (1) 依据《急性百草枯中毒诊治专家共识 (2013)》<sup>[8]</sup>, 确诊为 APP 患者; (2) 百草枯经口摄入, 且于 24 h 内就诊; (3) 18 岁及以上; (4) 研究所需资料完整。排除标准: (1) 既往有肝肾功能不全; (2) 合并其他药物中毒; (3) 合并血

液系统疾病; (4) 妊娠或哺乳期; (5) 入院后未给予个体化治疗或放弃治疗; (6) 合并感染性疾病或恶性肿瘤; (7) 合并自身免疫性疾病。

**1.2 资料收集方法** 所有患者入院时收集性别、年龄、摄入百草枯剂量和服毒至就诊时间等资料, 同时采集静脉血和动脉血, 采用 XT-4000i 型血液分析仪 (希森美康, 日本) 检测白细胞 (WBC), Star Profile M 型血气生化分析仪 (诺瓦, 美国) 检测动脉血乳酸 (Lac), AU5800 型全自动生化分析仪 (贝克曼库尔特, 美国) 检测尿素氮 (BUN)、血肌酐 (Scr)、肌酸激酶同工酶 (CK-MB)、血糖 (Glu)、血钾 ( $K^+$ )、血钙 ( $Ca^{2+}$ )、谷丙转氨酶 (ALT)、谷草转氨酶 (AST) 等血液指标。患者均给予 2% 碳酸氢钠溶液洗胃, 然后给予 120~200 mL 15% 白陶土和 50 mL 甘露醇+6 g 大黄粉/50 g 芒硝口服以导泻, 并于入院 6 h 内导泻成功, 同时给予血液灌流、血液透析治疗, 给予环磷酰胺、甲泼尼龙等免疫抑制剂及相应抗氧化损伤药物对症治疗, 记录首次灌流时间和首次呕吐时间。根据患者病情变化相应调整治疗方案。随访自入院之日开始, 直至死亡或服毒后 30 d, 截止日期为 2020 年 12 月 31 日。

**1.3 Cox 比例风险回归模型的建立** 采用 SPSS 24.0 软件构建 Cox 比例风险回归模型。将训练组数据送入 Cox 回归模型,  $y=1$  表示患者死亡, 概率为  $P$ ;  $y=0$  表示患者存活, 概率为  $1-P$ , 患者死亡与各变量之间的模型如下:

$$\ln \frac{P}{1-P} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_m x_m$$

经 Cox 变换可得患者死亡概率公式为:

$$P = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_m x_m}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_m x_m}}$$

式中:  $P$  为患者死亡概率;  $m$  为协变量个数;  $\beta_1$ 、 $\beta_2$ 、 $\beta_m$  为自变量的 Logistic 模型回归系数;  $x_1$ 、 $x_2$ 、 $x_m$  为影响患者死亡的自变量。Cox 比例风险回归模型计算所得风险比 (HR) 表示单位时间内暴露因

素对患者造成的死亡风险。

**1.4 XGBoost 模型的建立** 采用 XGBoost 0.72 软件与 Python 3.9 软件建立 XGBoost 模型, 先通过训练集训练基学习器, 根据基学习器的表现调整训练集样本分布, 使基学习器表现不佳的训练样本得到校正, 再根据调整后的样本分布训练下一个基学习器, 重复进行, 直至基学习器数目达到事先指定的值 T, 最终将这 T 个基学习器进行加权结合。XGBoost 的基学习器就是一棵树分类器, 根据其简要算法的数学描述, 假设有  $k$  棵树, 则模型的表达式为:

$$\hat{y}_i = \sum_{k=1}^k f_k(x_i), f_k \in F$$

式中:  $F$  指回归森林中所有的函数空间。 $f_k(x_i)$  代表第  $i$  个样本在第  $k$  棵树中落在叶子的权重。目标函数为:

$$L(\varphi) = \sum_{i=1}^n l(\hat{y}_i, y_i) + \sum_{k=1}^k \Omega(f_k)$$

式中:  $l$  为损失函数, 用于估计预测值  $\hat{y}_i$  与真实值  $y_i$  的差距; 正则项  $\Omega$  则用于调整模型的复杂度, 避免过拟合。

将训练组数据纳入模型进行训练, 得到最佳参数: 首先以树模型深度和叶子节点权值为主调整参数, 然后使用交叉验证法预先选定 XGBoost 决策树的数量, 再采用 Grid Search CV 调整其超参数, 最终获得最佳 XGBoost 预测模型。设定及调整的参数为: booster=gbtree, objective=binary:cox, eta=0.2, gamma=4, min\_child\_weight=2, max\_depth=6, subsample=0.8, colsample\_bytree=0.8, alpha=0.9, 学习率为 0.3。XGBoost 模型计算的重要特征评分可量化预测因子的预测能力, 评分越高, 预测能力越强。

**1.5 两种模型比较** 采用受试者工作特征曲线 (receiver operating characteristic curve, ROC) 分析 XGBoost 模型和 Cox 比例风险回归模型对 APP 患者生存的预测效能, 以曲线下面积 (area under curve, AUC) 判定预测能力的强弱, AUC 值越大表明预测能力越强。采用 DELONG 等<sup>[9]</sup> 推荐的方法比较两种模型的预测能力。采用 Hosmer-Lemeshow 检验评价两种模型的校准度, 若  $P > 0.05$ , 则说明预测模型与实际情况拟合度良好, 可以反映真实情况, 并根据列联表中模型预测概率的大小以十分位数分成的 10 个组作为横坐标, APP 患者死亡发生率作为纵坐标, 绘制校准曲线。

**1.6 统计分析** 采用 SPSS 24.0 软件统计分析, 采用 GraphPad Prism 5.0 软件作图。定量资料服从正态分布采用均数±标准差 ( $\bar{x} \pm s$ ) 描述, 组间比较采用  $t$

检验; 不服从正态分布采用中位数和四分位数间距 [ $M(Q_R)$ ] 描述; 定性资料采用相对数描述, 组间比较采用  $\chi^2$  检验。采用 Kaplan-Meier 法绘制生存曲线, 并采用 log-rank 检验比较。以  $P < 0.05$  为差异有统计学意义。

## 2 结果

**2.1 基本情况** 共纳入研究对象 150 例, 人口生存时间为 1 954 人·d, 中位生存时间的  $M(Q_R)$  为 6 (28) d。其中训练组 75 例, 人口生存时间为 1 042 人·d; 中位生存时间的  $M(Q_R)$  为 8 (27) d; 年龄为 (40.21±12.78) 岁; 女性 37 例, 占 49.33%; 男性 38 例, 占 51.67%; 死亡 52 例, 占 69.33%。验证组 75 例, 人口生存时间为 912 人·d; 中位生存时间的  $M(Q_R)$  为 6 (28) d; 年龄为 (39.57±11.80) 岁; 女性 34 例, 占 45.33%; 男性 41 例, 占 54.67%; 死亡 55 例, 占 73.33%。两组年龄 ( $t=0.349, P=0.728$ )、性别 ( $\chi^2=0.004, P=0.948$ )、死亡率 ( $\chi^2=0.293, P=0.588$ ) 比较, 差异无统计学意义。两组生存曲线比较, 差异无统计学意义 ( $\chi^2=0.580, P=0.446$ ), 见图 1。




图 1 训练组与验证组 APP 患者的生存曲线

**2.2 预测 APP 患者死亡的 Cox 比例风险回归模型** 以生存时间和是否死亡为应变量, 以性别、年龄、摄入百草枯剂量、服毒至就诊时间、首次灌流时间、首次呕吐时间、AST、ALT、Scr、BUN、WBC、Lac、CK-MB、Glu、Ca<sup>2+</sup>、K<sup>+</sup>和 Na<sup>+</sup>为自变量纳入 Cox 比例风险回归模型。结果显示, 摄入百草枯剂量, 服毒至就诊时间、首次灌流时间、首次呕吐时间、AST、ALT、Scr、BUN、WBC、Lac、CK-MB、Glu、Ca<sup>2+</sup>和 K<sup>+</sup>是 APP 患者死亡的独立预测因素 ( $P < 0.05$ )。见表 1。

2.3 预测 APP 患者死亡的 XGBoost 模型 纳入性别、年龄、摄入百草枯剂量、服毒至就诊时间、首次灌流时间、首次呕吐时间、AST、ALT、Scr、BUN、WBC、Lac、CK-MB、Glu、Ca<sup>2+</sup>、K<sup>+</sup>和 Na<sup>+</sup>，构建预测 APP 患者死亡的 XGBoost 模型，最终得到 14 个预测因素，其预测能力由强到弱依次为服毒至就诊时间

(43 分)、首次呕吐时间 (41 分)、首次灌流时间 (39 分)、Lac (28 分)、WBC (24 分)、摄入百草枯剂量 (23 分)、Scr (23 分)、K<sup>+</sup> (22 分)、Ca<sup>2+</sup> (20 分)、CK-MB (20 分)、Glu (19 分)、AST (17 分)、BUN (13 分) 和 ALT (9 分)。

表 1 训练组 APP 患者死亡的 Cox 比例风险回归模型预测结果

变量	单因素分析		多因素分析	
	HR (95%CI)	P 值	HR (95%CI)	P 值
女性	0.986 (0.718 ~ 1.254)	0.328		
年龄	1.132 (0.916 ~ 1.348)	0.154		
摄入百草枯剂量	1.362 (1.081 ~ 1.644)	0.004	1.219 (1.046 ~ 1.392)	0.014
服毒至就诊时间	4.782 (3.054 ~ 6.510)	<0.001	2.974 (2.185 ~ 3.763)	<0.001
首次灌流时间	4.206 (2.893 ~ 5.520)	<0.001	2.715 (1.938 ~ 3.492)	<0.001
首次呕吐时间	4.699 (3.251 ~ 6.147)	<0.001	3.170 (2.099 ~ 4.241)	<0.001
AST (U/L)	3.462 (2.867 ~ 4.057)	<0.001	2.594 (1.852 ~ 3.336)	<0.001
ALT (U/L)	2.053 (1.418 ~ 2.689)	<0.001	1.749 (1.316 ~ 2.182)	<0.001
Scr (μmol/L)	1.456 (1.308 ~ 1.604)	<0.001	1.275 (1.131 ~ 1.419)	<0.001
BUN (mmol/L)	1.157 (1.054 ~ 1.260)	0.031	1.107 (1.012 ~ 1.202)	0.040
WBC (×10 <sup>9</sup> /L)	3.152 (1.581 ~ 4.723)	<0.001	2.691 (1.407 ~ 3.975)	<0.001
Lac (mmol/L)	1.302 (1.087 ~ 1.517)	0.002	1.238 (1.031 ~ 1.445)	0.024
CK-MB (U/L)	1.276 (1.087 ~ 1.465)	0.011	1.189 (1.028 ~ 1.350)	0.029
Glu (mmol/L)	1.351 (1.165 ~ 1.537)	<0.001	1.199 (1.081 ~ 1.317)	0.008
Ca <sup>2+</sup> (mmol/L)	0.778 (0.655 ~ 0.901)	<0.001	0.815 (0.668 ~ 0.962)	0.001
K <sup>+</sup> (mmol/L)	0.751 (0.692 ~ 0.810)	<0.001	0.804 (0.691 ~ 0.917)	<0.001
Na <sup>+</sup> (mmol/L)	1.058 (0.922 ~ 1.194)	0.381		

2.4 两种模型预测效能比较 以 APP 患者死亡为应变量，以上述预测因素为自变量，分别将训练组和验证组的数据代入基于训练组建立的 Cox 比例风险回

归模型和 XGBoost 模型中，绘制两种模型的 ROC 曲线，结果显示，XGBoost 模型预测死亡的 AUC 值大于 Cox 比例风险回归模型，预测能力较强。见表 2。

表 2 两种模型预测 APP 患者死亡的效能比较

组别	模型	AUC (95%CI)	灵敏度 (%)	特异度 (%)	约登指数	P 值
训练组	Cox 比例风险回归模型	0.921 (0.907 ~ 0.935)	83.47	86.18	0.696 5	<0.001
	XGBoost 模型	0.972 (0.965 ~ 0.979)	85.79	90.24	0.760 3	<0.001
验证组	Cox 比例风险回归模型	0.926 (0.911 ~ 0.941)	79.33	91.05	0.703 8	<0.001
	XGBoost 模型	0.975 (0.969 ~ 0.982)	85.25	91.84	0.770 9	<0.001

2.5 两种模型的校准度比较 Cox 比例风险回归模型 (训练组:  $\chi^2=1.694$ ,  $P=0.451$ ; 验证组:  $\chi^2=1.368$ ,  $P=0.584$ ) 和 XGBoost 模型 (训练组:  $\chi^2=1.577$ ,  $P=0.549$ ; 验证组:  $\chi^2=1.877$ ,  $P=0.339$ ) 预测 APP 患者死亡情况与实际情况的拟合度均较好。

见图 2。

### 3 讨论

本研究分别采用 XGBoost 模型和 Cox 比例风险回归模型筛选出完全一致的 14 个 APP 患者死亡的




图2 两种模型预测 APP 患者死亡的校准曲线

预测因素,其预测能力由强到弱依次为服毒至就诊时间、首次呕吐时间、首次灌流时间、Lac、WBC、摄入百草枯剂量、Scr、 $K^+$ 、 $Ca^{2+}$ 、CK-MB、Glu、AST、BUN 和 ALT。服毒至就诊时间、首次呕吐时间和首次灌流时间的预测能力最强,可能由于百草枯在人体肠胃中易被吸收,提示应尽早就诊、清除毒素。Lac 是反映机体氧代谢水平和微循环状态的重要指标,其升高往往与细胞缺氧和灌注不足密切相关,常见于休克与重症感染<sup>[10]</sup>。肺是 APP 的主要靶器官之一,百草枯进入体内会利用肺的多胺摄取系统攻击肺部细胞,导致肺功能受损,从而造成机体缺氧<sup>[11]</sup>,因此 Lac 水平与 APP 患者肺部受损密切相关,对患者预后具有较强的预测能力。WBC 是临床常用的炎症指标,百草枯的主要作用机制是通过 WBC 产生大量的活性氧自由基,使细胞膜的脂质过氧化,导致细胞膜丧失功能<sup>[12]</sup>,因此 WBC 水平可反映 APP 患者受害的程度。百草枯可经过皮肤、呼吸道或消化道被人体吸收,而致死病例多为口服,研究表明成人致死量约为 20% 水溶液 (20~40 mg/kg) 5~15 mL,因此摄入剂量也是影响 APP 患者预后的重要因素。肾脏是百草枯的主要排泄器官,90% 左右的百草枯从肾脏排出体外<sup>[13]</sup>,因此反映肾脏功能的 Scr 和 BUN 对 APP 患者的预后具有一定的预测能力。Scr 升高与 APP 患者体内百草枯所致氧化应激损伤密切相关,Scr 越高,APP 患者预后越差<sup>[14]</sup>。肾脏功能受损还可能是 APP 患者低血钾的直接原因<sup>[15]</sup>。当肾脏受损时,机体对  $K^+$  的重吸收率大大降低,另外氧化应激受损会使机体糖皮质激素与儿茶酚胺迅速增多,进而降低体内  $K^+$  水平<sup>[16]</sup>,因此  $K^+$  对于 APP 患者预后具有一定的预测能力。百草枯在进入人体后会对蓝斑-交感-肾上腺髓质系统有一定的促进作用,可提高肾上腺素水平,激活受体,损伤胰腺<sup>[17]</sup>,进而导致两种结果:一是激活脂肪酶和磷脂酶 A 的生成,产生大量能与

$Ca^{2+}$  发生皂化反应的脂肪酸,从而降低  $Ca^{2+}$  水平;二是抑制胰岛素分泌,诱导胰高血糖素分泌,使机体发生胰岛素抵抗,从而提高 Glu 水平。另外,百草枯在体内还会激活细胞因子,产生大量促炎介质,对机体造成炎症反应性损害,不仅伤害患者肾脏与胰腺,还会使患者并发中毒性心肌炎和肝脏衰竭<sup>[18]</sup>,因此作为代表肝脏和心肌损害的常见指标,CK-MB、AST 和 ALT 对 APP 患者的预后也具有一定的预测能力。

采用 ROC 曲线对两种模型的预测效能进行比较发现,在训练组和验证组中,XGBoost 模型的预测效能均明显优于 Cox 比例风险回归模型。在机器学习算法中,每个自变量与每例研究对象的结局之间不是简单的线性关系,它可以自动发现并直接利用各个因素之间的非线性关系以及交互作用,提高预测能力,具有重要的临床应用价值。此外,袁晓春等<sup>[19]</sup>采用 Cox 比例风险回归模型筛选预测因素,杨志燕等<sup>[20]</sup>采用支持向量机筛选预测因素,也均不能按照预测能力将危险因素进行排序,且预测能力较弱。

综上所述,APP 患者死亡的独立预测因素预测能力由强到弱依次为服毒至就诊时间、首次呕吐时间、首次灌流时间、Lac、WBC、摄入百草枯剂量、Scr、 $K^+$ 、 $Ca^{2+}$ 、CK-MB、Glu、AST、BUN 和 ALT。其中服毒至就诊时间、首次呕吐时间、首次灌流时间的预测能力最强,Lac 其次,BUN 和 ALT 的预测能力最差,其他预测因素的预测能力无太大差别。XGBoost 模型可用于 APP 患者死亡的预测分析,其预测能力无论是在训练组还是在验证组中,均优于 Cox 比例风险回归模型。本研究样本量较少,还需要多中心与大数据对研究结果进行验证。

#### 参考文献

- [1] XIAO Q, WANG W, QI H, et al. Continuous hemoperfusion relieves pulmonary fibrosis in patients with acute mild and moderate paraquat poisoning [J]. J Toxicol Sci, 2020, 45 (10): 611-617.

- [2] WEN C C, LIN F Y, HUANG B G, et al. Metabolomics analysis in acute paraquat poisoning patients based on UPLC-Q-TOF-MS and machine learning approach [J]. *Chem Res Toxicol*, 2019, 32 (4): 629-637.
- [3] 姚婷婷, 刘媛媛, 李长平, 等. 生存资料回归模型分析——生存资料 Cox 比例风险回归模型分析 [J]. *四川精神卫生*, 2020, 33 (1): 27-32.
- [4] GUAN X, ZHANG B, FU M, et al. Clinical and inflammatory features based machine learning model for fatal risk prediction of hospitalized COVID-19 patients: results from a retrospective cohort study [J]. *Ann Med*, 2021, 53 (1): 257-266.
- [5] CHRISTOPHER T, BRODY J P. Evaluation of a genetic risk score for severity of COVID-19 using human chromosomal-scale length variation [J/OL]. *Hum Genomics*, 2020, 14 (1) [2021-06-04]. <https://pubmed.ncbi.nlm.nih.gov/33036646/>. DOI: 10.1186/s40246-020-00288-y.
- [6] SEGAL Z, KALIFA D, RADINSKY K, et al. Machine learning algorithm for early detection of end-stage renal disease [J]. *BMC Nephrol*, 2020, 21 (1): 518-527.
- [7] 蔺轲, 林瑜, 孔桂兰. 基于 XGBoost 算法的 ICU 脓毒症患者住院死亡风险预测研究 [J]. *中国卫生信息管理杂志*, 2018, 15 (5): 536-540, 563.
- [8] 中国医师协会急诊医师分会. 急性百草枯中毒诊治专家共识 (2013) [J]. *中国急救医学*, 2013, 33 (6): 484-489.
- [9] DELONG E R, DELONG D M, CLARKE-PEARSON D L. Comparing the areas under two or more correlated receiver operating characteristic curves: a nonparametric approach [J]. *Biometrics*, 1988, 44 (3): 837-845.
- [10] SHILEI L, DANNA Z, YONG L, et al. Arterial lactate in predicting mortality after paraquat poisoning: a meta-analysis [J/OL]. *Medicine (Baltimore)*, 2018, 97 (34) [2021-06-04]. <https://pubmed.ncbi.nlm.nih.gov/30142762/>. DOI: 10.1097/MD.00000000000011751.
- [11] 颜梅, 胡乔华, 莫李婵, 等. 急性百草枯农药中毒患者 35 例预后相关因素分析 [J]. *岭南急诊医学杂志*, 2020, 25 (2): 149-150.
- [12] FENG S Y, GAO J, LI Y. A retrospective analysis of leucocyte count as a strong predictor of survival for patients with acute paraquat poisoning [J/OL]. *PLoS One*, 2018, 13 (7) [2021-06-04]. <https://pubmed.ncbi.nlm.nih.gov/30044873/>. DOI: 10.1371/journal.pone.0201200.
- [13] 马涛, 邢宏运, 李晓明, 等. 急性百草枯中毒的预后因素分析 [J]. *医药导报*, 2020, 39 (6): 849-850.
- [14] FENG M X, LI Y N, RUAN W S, et al. Predictive value of the maximum serum creatinine value and growth rate in acute paraquat poisoning patients [J/OL]. *Sci Rep*, 2018, 8 (1) [2021-06-04]. <https://pubmed.ncbi.nlm.nih.gov/30072769/>. DOI: 10.1038/s41598-018-29800-0.
- [15] 牛丽丹, 张建新, 郝同琴, 等. 入院时血浆百草枯浓度及百草枯中毒严重指数评估患者中毒程度及预后的价值比较 [J]. *实用医院临床杂志*, 2018, 15 (3): 87-88.
- [16] 王鸾, 蔡雪, 赵敏. 急性百草枯中毒死亡危险因素分析 [J]. *中国医科大学学报*, 2018, 47 (3): 237-239, 243.
- [17] 武小娟, 李彦国, 孟舰, 等. 早期血糖和离子水平对急性百草枯中毒患者的预后评估 [J]. *现代预防医学*, 2018, 45 (1): 115-118.
- [18] 田飞, 张蓉, 郭庆, 等. 急性百草枯中毒预后影响因素的研究 [J]. *巴蜀医学*, 2020, 3 (1): 19-25, 38.
- [19] 袁晓春, 李金奎, 陈中伟, 等. Cox 比例风险回归模型分析急性百草枯中毒者预后影响因素 [J]. *宁夏医科大学学报*, 2018, 233 (2): 68-70.
- [20] 杨志燕, 黄天宝, 王树山, 等. 基于支持向量机的急性百草枯中毒预后模型的建立与评价 [J]. *南京医科大学学报*, 2018, 38 (10): 1467-1471.

收稿日期: 2021-01-26 修回日期: 2021-06-04 本文编辑: 田田

## (上接第 761 页)

- [13] 王德征, 王冲, 张爽, 等. 天津市微信虚拟社区居民癌症防治知识知晓现状及影响因素的分类树分析 [J]. *中国慢性病预防与控制*, 2018, 26 (12): 910-915.
- [14] 刘成成, 石春雷, 石菊芳, 等. 2015—2017 年中国城市居民肿瘤预防意识健康素养及相关因素分析 [J]. *中华预防医学杂志*, 2020, 54 (1): 47-53.
- [15] 王悠清, 李辉章, 龚巍巍, 等. 2015 年浙江省肿瘤登记地区恶性肿瘤发病与死亡分析 [J]. *中国肿瘤*, 2019, 28 (1): 12-22.
- [16] SUNG H, SIEGEL R L, TORRE L A, et al. Global patterns in excess body weight and the associated cancer burden [J]. *CA Cancer J Clin*, 2019, 69 (2): 88-112.
- [17] 杜灵彬, 王乐, 陈明. 推进癌症筛查助力健康浙江 [J]. *中国肿瘤*, 2020, 29 (12): 897-898.
- [18] 王乐, 李辉章, 朱陈, 等. 浙江省 2013—2018 年城市居民结直肠癌筛查结果及成本效果分析 [J]. *中华流行病学杂志*, 2020, 41 (12): 2080-2086.
- [19] 董佩, 石菊芳, 邱五七, 等. 2015—2017 年中国城市居民肿瘤防治健康素养现况及相关因素分析 [J]. *中华预防医学杂志*, 2020, 54 (1): 76-83.
- [20] 彭慧, 张一英, 黄芳, 等. 健康素养、大肠癌筛查知行与肠镜顺应性相关性 [J]. *中国公共卫生*, 2019, 35 (5): 594-598.

收稿日期: 2021-04-01 修回日期: 2021-05-28 本文编辑: 吉兆洋