

基于机器学习的重症监护病房脓毒性休克患者早期发生急性肾损伤风险的预测模型构建

张素珍¹ 唐素娟² 戎珊² 朱曼晨² 刘建国² 胡庆河² 郝翠平²

¹ 济宁医学院附属医院血液科, 山东济宁 272030; ² 济宁医学院附属医院重症医学三科, 山东济宁 272030

通信作者: 郝翠平, Email: hcuiping0709@163.com

【摘要】 **目的** 分析重症监护病房(ICU)内脓毒性休克患者早期发生急性肾损伤(AKI)的危险因素,构建预测模型,并探讨该预测模型的预测价值。**方法** 回顾分析2015年4月至2019年6月在济宁医学院附属医院ICU住院治疗的脓毒性休克患者的临床资料,根据患者入ICU 7 d内是否发生AKI分为AKI组和非AKI组。随机抽取数据集中的病例(占70%)作为训练集用于建立模型,其余30%的病例作为验证集。使用XGBoost模型集成相关参数,预测脓毒性休克患者发生AKI的风险,预测能力通过受试者工作特征曲线(ROC曲线)评估,并与急性生理学与慢性健康状况评分II(APACHE II)、序贯器官衰竭评分(SOFA)、降钙素原(PCT)等对比验证模型的预测价值。**结果** 共纳入303例脓毒性休克患者,其中发生AKI 153例,未发生AKI 150例,AKI发生率为50.50%。与非AKI组相比,AKI组患者APACHE II评分、SOFA评分和血乳酸(Lac)水平更高,去甲肾上腺素(NE)使用剂量更大,机械通气比例更高,入ICU时心率更快。脓毒性休克患者发生AKI风险的XGBoost预测模型中,排名前10位的特征分别为入ICU时血肌酐(SCr)水平、是否使用NE、饮酒史以及白蛋白、血钠、C-反应蛋白(CRP)、Lac、体质量指数(BMI)、血小板计数(PLT)和血尿素氮(BUN)水平。XGBoost模型预测脓毒性休克患者AKI发生风险的ROC曲线下面积(AUC)为0.816,敏感度为73.3%,特异度为71.7%,准确度为72.5%,模型预测能力较APACHE II评分、SOFA评分、PCT等明显提升。模型的校准曲线显示,XGBoost模型的拟合优度高于其他各项评分(校准曲线得分最小,为0.205)。**结论** 与临床常用评分相比,脓毒性休克患者AKI发生风险的XGBoost模型能够更加准确地预测脓毒性休克患者发生AKI的风险,有助于在预测患者预后的同时,恰当地制定诊断、治疗方案和随访策略。

【关键词】 脓毒性休克; 急性肾损伤; 机器学习; 预测模型

基金项目: 山东省医药卫生科技发展计划项目(2018WSB34007); 山东省济宁市重点研发计划软科学项目(2021JNZC016)

临床试验注册: 中国临床试验注册中心, ChiCTR 2000040310

DOI: 10.3760/cma.j.cn121430-20211126-01790

Construction of a predictive model for early acute kidney injury risk in intensive care unit septic shock patients based on machine learning

Zhang Suzhen¹, Tang Sujuan², Rong Shan², Zhu Manchen², Liu Jianguo², Hu Qinghe², Hao Cuiping²

¹Department of Hematology, Affiliated Hospital of Jining Medical University, Jining 272030, Shandong, China;

²Department of Critical Care Medicine, Affiliated Hospital of Jining Medical University, Jining 272030, Shandong, China

Corresponding author: Hao Cuiping, Email: hcuiping0709@163.com

【Abstract】 **Objective** To analyze the risk factors of acute kidney injury (AKI) in patients with septic shock in intensive care unit (ICU), construct a predictive model, and explore the predictive value of the predictive model. **Methods** The clinical data of patients with septic shock who were hospitalized in the ICU of the Affiliated Hospital of Jining Medical College from April 2015 to June 2019 were retrospectively analyzed. According to whether the patients had AKI within 7 days of admission to the ICU, they were divided into AKI group and non-AKI group. 70% of the cases were randomly selected as the training set for building the model, and the remaining 30% of the cases were used as the validation set. XGBoost model was used to integrate relevant parameters to predict the risk of AKI in patients with septic shock. The predictive ability was assessed through receiver operator characteristic curve (ROC curve), and was correlated with acute physiology and chronic health evaluation II (APACHE II), sequential organ failure assessment (SOFA), procalcitonin (PCT) and other comparative verification models to verify the predictive value. **Results** A total of 303 patients with septic shock were enrolled, including 153 patients with AKI and 150 patients without AKI. The incidence of AKI was 50.50%. Compared with the non-AKI group, the AKI group had higher APACHE II score, SOFA score and blood lactate (Lac), higher dose of norepinephrine (NE), higher proportion of mechanical ventilation, and tachycardiac. In the XGBoost prediction model of AKI risk in septic shock patients, the top 10 features were serum creatinine (SCr) level at ICU admission, NE use, drinking history, albumin, serum sodium, C-reactive protein (CRP), Lac, body mass index (BMI), platelet count (PLT), and blood urea nitrogen (BUN) levels. Area under the ROC curve (AUC) of the XGBoost model for predicting the risk of AKI in patients with septic shock was 0.816, with a sensitivity

of 73.3%, a specificity of 71.7%, and an accuracy of 72.5%. Compared with the APACHE II score, SOFA score and PCT, the performance of the model improved significantly. The calibration curve of the model showed that the goodness of fit of the XGBoost model was higher than the other scores (the calibration curve had the lowest score, with a score of 0.205). **Conclusion** Compared with the commonly used clinical scores, the XGBoost model can more accurately predict the risk of AKI in patients with septic shock, which helps to make appropriate diagnosis, treatment and follow-up strategies while predicting the prognosis of patients.

【Key words】 Septic shock; Acute kidney injury; Machine learning; Predictive model

Fund program: Shandong Medical and Health Science and Technology Development Project (2018WSB34007); Jining City Key Research and Development Program Soft Science Project of Shandong Province of Shandong Province (2021JNZC016)

Trial Registration: Chinese Clinical Trial Registry, ChiCTR 2000040310

DOI: 10.3760/ema.j.cn121430-20211126-01790

脓毒性休克是机体对感染的一种严重反应,涉及体内潜在的循环和细胞代谢异常,严重影响脓毒症患者预后以及医疗卫生资源的分配^[1]。虽然在“拯救脓毒症运动”指南指导下,脓毒性休克发病率下降,但仍占休克总发生率的62%,住院病死率超过40%^[2-3]。急性肾损伤(acute kidney injury, AKI)是脓毒症患者常见的并发症之一,其发病模式常不明显,但发病急、发展迅速,如果诊断和治疗不及时,可能会导致不可逆转的损害^[4]。AKI的严重程度与脓毒症高病死率显著相关,同时会延长患者住院时间,增加治疗费用,给家庭带来极大的压力和经济负担。所以,早期识别并及时干预无疑能改善AKI患者的预后^[5-6]。近年来,机器学习已广泛应用于临床研究中,研究者可以根据不同的数据表现和临床特征建立预测模型,与临床常用的评分相比,能更好地预测患者预后或并发症的发生^[7-9]。本研究探讨脓毒性休克患者入重症监护病房(intensive care unit, ICU)7 d内发生AKI的危险因素,并建立预测模型,以期临床医生早期发现和治疗AKI提供依据。

1 资料与方法

1.1 数据来源:本研究为回顾性队列研究,选择2015年4月至2019年6月在济宁医学院附属医院ICU住院治疗的303例脓毒性休克患者为研究对象。研究者从医院电子病例系统中查阅患者的诊疗信息,包括人口统计学信息、生命体征、实验室检查指标、诊断、治疗等数据,数据信息经多次研究验证,具有较高质量。

1.1.1 诊断标准:脓毒性休克的诊断符合欧美危重病医学学会发布的脓毒症和脓毒性休克国际共识中的诊断标准^[1], AKI诊断参照改善全球肾脏预后组织(Kidney Disease: Improving Global Outcomes, KDIGO)的诊断标准^[10]。

1.1.2 纳入标准:①年龄 ≥ 18 岁;②入院诊断为脓毒性休克;③住院病例信息完整,ICU住院时

间 > 24 h。

1.1.3 排除标准:①年龄 < 18 岁;②入院时已发生AKI;③有慢性肾衰竭病史。

1.1.4 伦理学:本研究符合医学伦理学标准,获得中国临床试验注册中心注册(注册号:ChiCTR 2000040310),并济宁医学院附属医院伦理委员会批准(审批号:2020C018),所有治疗和指标检测均获得过患者或家属的知情同意。

1.2 纳入的主要变量:从电子病历中获取患者的性别、年龄、体质量指数(body mass index, BMI)、吸烟史、饮酒史、感染部位、入ICU初始生命体征〔包括心率、体温、平均动脉压(mean arterial pressure, MAP)、氧合指数〕、24 h内急性生理学与慢性健康状况评分II(acute physiology and chronic health evaluation II, APACHE II)和序贯器官衰竭评分(sequential organ failure assessment, SOFA)、其他实验室检查指标〔包括白细胞计数(white blood cell count, WBC)、血肌酐(serum creatinine, SCr)、降钙素原(procalcitonin, PCT)等〕及血管活性药物使用情况。统计患者入ICU 7 d内AKI发生率。

1.3 统计学方法:采用SPSS 23.0和Python(3.6.5)软件进行数据分析。符合正态分布的计量资料以均数 \pm 标准差($\bar{x} \pm s$)表示,采用 t 检验;不符合正态分布的计量资料以中位数(四分位数)[$M(Q_L, Q_U)$]表示,采用Mann-Whitney U 检验;计数资料以例数(百分比)表示,采用Pearson χ^2 检验或Fisher精确检验。 $P < 0.05$ 为差异有统计学意义。选择受试者工作特征曲线(receiver operator characteristic curve, ROC曲线)作为模型的评价指标。使用预测模型校准曲线判断模型的临床使用价值。模型开发使用XGBoost模型(1.0.0)。随机抽选数据集中的病例(占70%)作为训练集,另30%病例作为验证集。

2 结果

2.1 患者基本特征(表1):经筛选,共纳入脓毒性休

克患者 303 例。其中 153 例入 ICU 7 d 内发生 AKI, AKI 发生率为 50.50%。与非 AKI 组相比, AKI 组 APACHE II 评分、SOFA 评分和血乳酸 (blood lactic acid, Lac) 水平更高, 去甲肾上腺素 (norepinephrine, NE) 使用剂量更大, 机械通气比例更高, 入 ICU 时心率更快 (均 $P < 0.05$)。

2.2 XGBoost 模型: 脓毒性休克患者 AKI 发生风险 XGBoost 预测模型的主要超参数设置如下, 树的最大深度 $\text{max_depth}=10$, 树的棵数 $\text{n_estimators}=1\ 000$, 学习率 $\text{learning_rate}=0.1$, 正则化系数 $\text{alpha}=0$, $\text{lambda}=0$ 。根据特征的重要程度进行排序 (图 1), 排名前 10 位分别为入 ICU 时 SCr 水平、是否使用

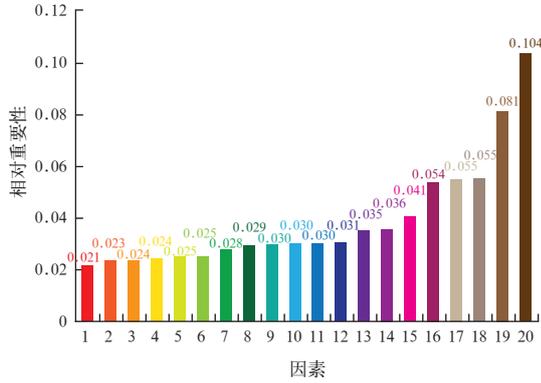
NE、饮酒史以及白蛋白 (albumin, ALB)、血钠、C-反应蛋白 (C-reactive protein, CRP)、Lac、BMI、血小板计数 (blood platelet, PLT) 和血尿素氮 (blood urea nitrogen, BUN) 水平。

2.3 模型预测能力评价: XGBoost 模型预测脓毒性休克患者 AKI 发生风险的 ROC 曲线下面积 (area under the ROC curve, AUC) 为 0.816, 敏感度为 73.3%, 特异度为 71.7%, 准确度为 72.5%, F1 分数为 0.725 (图 2); 模型预测能力较 APACHE II 评分、SOFA 评分、PCT 等明显提升 (图 3)。模型的校准曲线显示 (图 4), XGBoost 模型的拟合优度高于其他各项评分 (校准曲线得分最小, 为 0.205)。

表 1 是否发生 AKI 两组脓毒性休克患者的一般资料比较

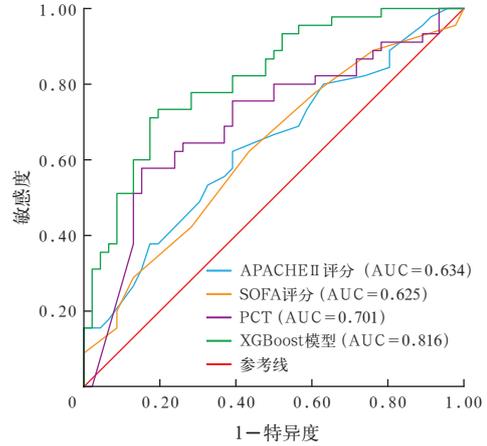
因素	总体 (n=303)	非 AKI 组 (n=150)	AKI 组 (n=153)	$\chi^2/t/U$ 值	P 值
男性 [例 (%)]	181 (59.74)	88 (58.67)	93 (60.78)	0.141	0.707
年龄 (岁, $\bar{x} \pm s$)	64.36 \pm 15.62	63.93 \pm 15.76	64.78 \pm 15.51	0.032	0.636
BMI (kg/m ² , $\bar{x} \pm s$)	22.81 \pm 4.37	22.42 \pm 4.18	23.20 \pm 4.53	0.021	0.119
饮酒史 [例 (%)]	203 (67.00)	108 (72.00)	95 (62.09)	15.842	0.067
吸烟史 [例 (%)]	101 (33.44)	42 (28.00)	59 (38.82)	15.520	0.046
APACHE II 评分 (分, $\bar{x} \pm s$)	20.82 \pm 7.69	18.71 \pm 7.30	22.90 \pm 7.51	4.680	<0.001
SOFA 评分 (分, $\bar{x} \pm s$)	9.15 \pm 3.57	8.19 \pm 3.38	10.09 \pm 3.50	0.270	<0.001
使用 NE [例 (%)]	240 (79.73)	110 (73.83)	130 (85.53)	27.063	0.012
NE 用量 [$\mu\text{g} \cdot \text{kg}^{-1} \cdot \text{min}^{-1}$, $M(Q_L, Q_U)$]	0.30 (0.20, 0.60)	0.30 (0.18, 0.40)	0.40 (0.20, 0.60)	3.338	<0.001
机械通气 [例 (%)]	184 (60.93)	81 (54.00)	103 (67.76)	6.007	0.014
MAP (mmHg, $\bar{x} \pm s$)	73.39 \pm 15.85	73.69 \pm 15.48	73.10 \pm 16.25	0.371	0.747
心率 (次/min, $\bar{x} \pm s$)	113.95 \pm 22.50	111.54 \pm 20.93	116.31 \pm 23.77	0.550	0.024
体温 ($^{\circ}\text{C}$, $\bar{x} \pm s$)	37.31 \pm 2.82	37.26 \pm 1.05	37.13 \pm 1.62	0.904	0.969
氧合指数 (mmHg, $\bar{x} \pm s$)	207.83 \pm 77.56	208.19 \pm 76.49	207.48 \pm 78.85	0.146	0.937
合并症 [例 (%)]					
高血压	96 (31.68)	44 (29.33)	52 (33.99)	0.758	0.384
冠心病	64 (21.12)	33 (22.00)	31 (20.26)	0.137	0.711
糖尿病	63 (20.79)	34 (22.67)	29 (18.95)	0.634	0.426
脑卒中	39 (12.87)	24 (16.00)	15 (9.80)	2.593	0.107
心律失常	16 (5.28)	6 (4.00)	10 (6.54)	0.974	0.442
COPD	14 (4.62)	6 (4.00)	8 (5.23)	0.259	0.786
感染部位 [例 (%)]					
肺部	145 (47.85)	79 (52.67)	66 (43.14)	2.756	0.097
腹部	118 (38.94)	49 (32.67)	69 (45.10)	4.923	0.027
泌尿系	17 (5.61)	9 (6.00)	8 (5.23)	0.085	0.808
皮肤或软组织	12 (3.96)	5 (3.33)	7 (4.58)	0.307	0.770
其他	11 (3.63)	7 (4.67)	4 (2.61)	0.912	0.375
实验室指标					
WBC [$\times 10^9/\text{L}$, $M(Q_L, Q_U)$]	12.40 (7.30, 19.63)	11.35 (6.72, 17.00)	13.00 (7.90, 23.00)	2.105	0.004
PCT [$\mu\text{g}/\text{L}$, $M(Q_L, Q_U)$]	36.95 (0.01, 115.00)	22.60 (0.01, 105.00)	41.01 (0.04, 115.00)	6.156	<0.001
CRP [mg/L, $M(Q_L, Q_U)$]	128.20 (68.25, 184.75)	111.38 (49.00, 180.75)	138.51 (93.75, 190.00)	2.194	0.028
Lac [mmol/L, $M(Q_L, Q_U)$]	3.20 (2.50, 4.55)	2.90 (2.40, 3.68)	3.60 (2.70, 6.70)	22.418	<0.001
SCr [$\mu\text{mol}/\text{L}$, $M(Q_L, Q_U)$]	109.80 (70.65, 174.05)	79.25 (57.08, 103.75)	162.50 (111.40, 228.60)	9.047	<0.001
BUN [mmol/L, $M(Q_L, Q_U)$]	11.10 (7.19, 15.57)	7.99 (6.12, 12.17)	14.40 (10.10, 17.96)	7.756	<0.001
ALB [g/L, $M(Q_L, Q_U)$]	28.40 (24.15, 32.35)	28.60 (24.25, 33.30)	28.30 (24.00, 31.90)	-0.786	0.432
血钠 (mmol/L, $\bar{x} \pm s$)	136.35 \pm 8.31	136.07 \pm 8.35	136.63 \pm 8.29	0.035	0.553
PLT [$\times 10^9/\text{L}$, $M(Q_L, Q_U)$]	150.00 (78.00, 218.00)	170.00 (86.00, 233.50)	136.00 (69.00, 200.00)	-2.425	0.015

注: AKI 为急性肾损伤, BMI 为体质指数, APACHE II 为急性生理学及慢性健康状况评分 II, SOFA 为序贯器官衰竭评分, NE 为去甲肾上腺素, MAP 为平均动脉压, COPD 为慢性阻塞性肺疾病, WBC 为白细胞计数, PCT 为降钙素原, CRP 为 C-反应蛋白, Lac 为血乳酸, SCr 为血肌酐, BUN 为血尿素氮, ALB 为白蛋白, PLT 为血小板计数; 1 mmHg \approx 0.133 kPa



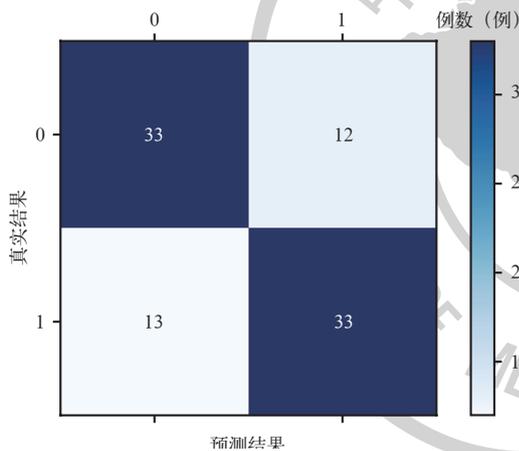
注：AKI为急性肾损伤；1为总胆红素(TBil)，2为氧合指数，3为机械通气时间，4为活化部分凝血活酶时间(APTT)，5为纤维蛋白原(Fib)，6为血钾，7为腹部感染，8为去甲肾上腺素(NE)用量，9为球蛋白(GLB)，10为心率，11为血尿素氮(BUN)，12为血小板计数(PLT)，13为体质指数(BMI)，14为血乳酸(Lac)，15为C-反应蛋白(CRP)，16为血钠，17为白蛋白(ALB)，18为饮酒史，19为使用NE，20为血肌酐(SCr)

图1 脓毒性休克患者AKI发生风险XGBoost预测模型中重要特征前20名指标



注：APACHE II为急性生理学与慢性健康状况评分II，SOFA为序贯器官衰竭评分，PCT为降钙素原，AKI为急性肾损伤，ROC曲线为受试者工作特征曲线，AUC为ROC曲线下面积

图3 APACHE II评分、SOFA评分、PCT和XGBoost预测模型预测脓毒性休克患者AKI发生风险的ROC曲线

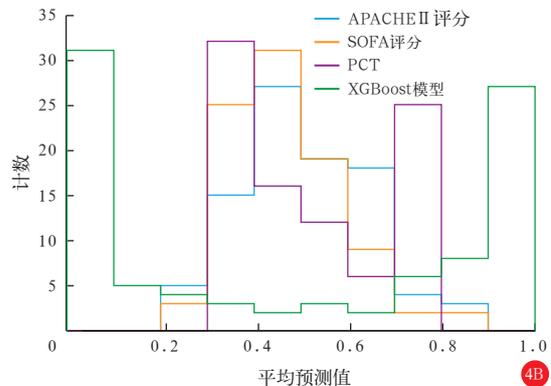
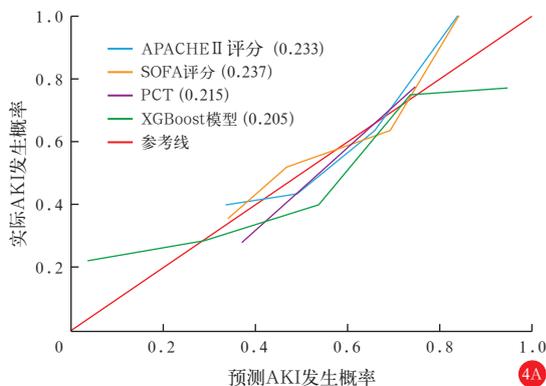


注：AKI为急性肾损伤；左上角和右下角值越大，表明模型分类越准确；左下角和右上角则表明模型分类错误的数量，即实际是1而模型预测为0，或实际为0而模型预测为1

图2 脓毒性休克患者AKI发生风险XGBoost预测模型预测测试集患者发生AKI风险的混淆矩阵

3 讨论

AKI是一种机体肾脏排泄功能迅速下降的疾病，在危重患者中非常普遍，并与发病率和病死率的增加以及高昂的经济成本有关^[11]。研究显示，AKI与不良的临床结局和额外的资源消耗有关^[12-13]。因此，探索识别AKI高危患者的方法具有重要意义。机器学习方法可以从丰富的临床数据中获得洞察力，从而支持AKI的早期预测，而不需要额外的AKI生物标志物测试^[14]。以往研究显示，XGBoost模型是一种优化的机器学习模型，广泛应用于患者不良结局及并发症的预测等临床研究，构建的模型能够更加精准地进行个体化预测^[15-17]。本研究建立了预测脓毒性休克患者AKI发生风险的XGBoost模型，该模型AUC为0.816，敏感度为73.3%，特异度为71.7%，准确度为72.5%，预测能力较临床常用评分更好。本研究使用最新的机器学习算法XGBoost，



注：APACHE II为急性生理学与慢性健康状况评分II，SOFA为序贯器官衰竭评分，PCT为降钙素原，AKI为急性肾损伤；A为模型预测校准曲线，曲线在对角线上方表示模型高估，在对角线下方表示模型低估；B为模型预测值的分布图；括号内为校准曲线得分

图4 评估APACHE II评分、SOFA评分、PCT和脓毒性休克患者AKI发生风险XGBoost预测模型拟合优度的校准曲线

开发了用于预测ICU中脓毒性休克患者AKI发生风险的模型,并比较了其与传统危重症评分模型(APACHE II评分和SOFA评分)、PCT的预测能力。

本研究显示,XGBoost模型较传统模型有更好的区分度和校准度,且运算速度更快。XGBoost模型还给出了各个预测变量的重要性排名,入ICU时SCr水平、是否使用NE、饮酒史及ALB、血钠、CRP、Lac、BMI、PLT、BUN水平均位居前列。关于AKI患者相关危险因素的报道各不相同,李莫振等^[18]发现,肺部感染、糖尿病、动脉血Lac、MAP、尿量和APACHE II评分是脓毒症患者发生AKI的独立危险因素;范妙仪等^[19]研究显示,男性、MAP、肺部感染是脓症患者并发AKI的危险因素。本研究开发的XGBoost模型显示,入ICU时SCr水平及是否使用NE分别位于模型重要特征排名的第1位和第2位。AKI的诊断主要依靠患者SCr水平及尿量变化,所以入ICU时SCr水平会影响脓毒性休克患者AKI的发生,这与以往研究结果一致^[20-21]。在脓毒症的临床治疗中,常使用血管活性药物维持机体循环功能的稳定^[1]。而NE是临床上最常用的血管活性药物,所以血管活性药物的使用提示有休克风险以及疾病的严重程度,会影响AKI的发生^[22]。本研究表明,排名前10位的重要特征还包括饮酒史以及ALB、血钠、CRP、Lac、BMI、PLT、BUN水平。Lac是细胞无氧代谢的产物,有研究显示,Lac是脓症患者死亡的独立影响因素^[23],Lac水平越高,脓毒症的严重程度越重,各器官功能越容易受损,AKI的发生率越高,与曾爱英等^[24]的研究结果一致。

本次回顾性研究仍有一些局限性。首先,本研究使用的数据是从单中心数据库中提取的,样本量不够大。其次,由于本研究未获得入ICU前的SCr数据,因此只能以入ICU后第1次SCr检测值作为基线。最后,本研究中发现的重要特征可作为AKI发生风险的早期体征,但在其推荐范围内是否可作为对照的参考还需进一步验证。

利益冲突 所有作者均声明不存在利益冲突

参考文献

[1] Singer M, Deutschman CS, Seymour CW, et al. The third international consensus definitions for sepsis and septic shock (Sepsis-3) [J]. *JAMA*, 2016, 315 (8): 801-810. DOI: 10.1001/jama.2016.0287.

[2] Vincent JL, De Backer D. Circulatory shock [J]. *N Engl J Med*, 2013, 369 (18): 1726-1734. DOI: 10.1056/NEJMr1208943.

[3] Levy MM, Rhodes A, Phillips GS, et al. Surviving Sepsis Campaign: association between performance metrics and outcomes in a 7.5-year study [J]. *Crit Care Med*, 2015, 43 (1): 3-12. DOI: 10.1097/CCM.0000000000000723.

[4] Lameire NH, Bagga A, Cruz D, et al. Acute kidney injury: an

increasing global concern [J]. *Lancet*, 2013, 382 (9887): 170-179. DOI: 10.1016/S0140-6736(13)60647-9.

[5] Zarbock A, Kellum JA, Schmidt C, et al. Effect of early vs delayed initiation of renal replacement therapy on mortality in critically ill patients with acute kidney injury: the ELAIN randomized clinical trial [J]. *JAMA*, 2016, 315 (20): 2190-2199. DOI: 10.1001/jama.2016.5828.

[6] Sutherland SM, Chawla LS, Kane-Gill SL, et al. Utilizing electronic health records to predict acute kidney injury risk and outcomes: workgroup statements from the 15(th) ADQI Consensus Conference [J]. *Can J Kidney Health Dis*, 2016, 3: 11. DOI: 10.1186/s40697-016-0099-4.

[7] Vellido A, Ribas V, Morales C, et al. Machine learning in critical care: state-of-the-art and a sepsis case study [J]. *Biomed Eng Online*, 2018, 17 (Suppl 1): 135. DOI: 10.1186/s12938-018-0569-2.

[8] Awad A, Bader-El-Den M, McNicholas J, et al. Predicting hospital mortality for intensive care unit patients: time-series analysis [J]. *Health Informatics J*, 2020, 26 (2): 1043-1059. DOI: 10.1177/1460458219850323.

[9] Ocampo-Quintero N, Vidal-Cortés P, Del Río Carbajo L, et al. Enhancing sepsis management through machine learning techniques: a review [J]. *Med Intensiva (Engl Ed)*, 2020: S0210-5691(20)30102-9. DOI: 10.1016/j.medint.2020.04.003.

[10] KDIGO AKI Guideline Work Group. Diagnosis, evaluation, and management of acute kidney injury: a KDIGO summary (Part 1) [J]. *Crit Care*, 2013, 17 (1): 204. DOI: 10.1186/cc11454.

[11] Flechet M, Güiza F, Schetz M, et al. AKIpredictor, an online prognostic calculator for acute kidney injury in adult critically ill patients: development, validation and comparison to serum neutrophil gelatinase-associated lipocalin [J]. *Intensive Care Med*, 2017, 43 (6): 764-773. DOI: 10.1007/s00134-017-4678-3.

[12] 李敏, 杨虎勇, 杨伟伟, 等. 基于MIMIC-III数据库的重症患者急性肾损伤预后预测模型的建立 [J]. *中华危重病急救医学*, 2021, 33 (8): 949-954. DOI: 10.3760/cma.jcn121430-20200924-00649.

[13] Gong KD, Lee HK, Yu KY, et al. A prediction and interpretation framework of acute kidney injury in critical care [J]. *J Biomed Inform*, 2021, 113: 103653. DOI: 10.1016/j.jbi.2020.103653.

[14] 池锐彬, 梁美华, 邹启明, 等. 基于生物标志物预测重症患者急性肾损伤决策树模型的构建和验证研究 [J]. *中华危重病急救医学*, 2020, 32 (6): 721-725. DOI: 10.3760/cma.jcn121430-20200509-00371.

[15] Vaid A, Somani S, Russak AJ, et al. Machine learning to predict mortality and critical events in a cohort of patients with COVID-19 in New York city: model development and validation [J]. *J Med Internet Res*, 2020, 22 (11): e24018. DOI: 10.2196/24018.

[16] 齐磊, 徐浩然, 胡婕, 等. 基于机器学习的重症监护病房脓症患者早期死亡风险预测模型 [J]. *解放军医学院学报*, 2021, 42 (2): 150-155, 181. DOI: 10.3969/j.issn.2095-5227.2021.02.006.

[17] 蔺轲, 林瑜, 孔桂兰. 基于XGBoost算法的ICU脓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. DOI: 10.3969/j.issn.1672-5166.2018.05.012.

[18] 李莫振, 尉玉杰, 高静. 脓症患者并发急性肾损伤的风险预测列线图模型建立 [J]. *安徽医学*, 2021, 42 (2): 179-182. DOI: 10.3969/j.issn.1000-0399.2021.02.015.

[19] 范妙仪, 刘蔓莉, 张磊, 等. 脓症患者并发急性肾损伤的危险因素探讨 [J]. *实用医院临床杂志*, 2017, 14 (5): 52-55. DOI: 10.3969/j.issn.1672-6170.2017.05.017.

[20] 刘梅. EICU脓症患者出现急性肾损伤的原因分析 [J]. *中国医药导报*, 2017, 14 (36): 173-176. DOI: CNKI:SUN:YYCY.0.2017-36-043.

[21] Koyner JL, Carey KA, Edelson DP, et al. The development of a machine learning inpatient acute kidney injury prediction model [J]. *Crit Care Med*, 2018, 46 (7): 1070-1077. DOI: 10.1097/CCM.0000000000003123.

[22] 何力, 苏连久, 张婧, 等. ICU内脓毒性休克急性肾损伤患者肾功能恢复的影响因素分析 [J]. *中华危重病急救医学*, 2020, 32 (2): 199-203. DOI: 10.3760/cma.jcn121430-20200106-00037.

[23] Ryo SM, Lee J, Lee YS, et al. Lactate level versus lactate clearance for predicting mortality in patients with septic shock defined by Sepsis-3 [J]. *Crit Care Med*, 2018, 46 (6): e489-e495. DOI: 10.1097/CCM.0000000000003030.

[24] 曾爱英, 王晓萍, 陈宏毅, 等. 急诊脓毒症患者并发急性肾损伤的相关危险因素分析 [J]. *实用中西医结合临床*, 2019, 19 (7): 115-116, 163. DOI: 10.13638/j.issn.1671-4040.2019.07.059.

(收稿日期: 2021-11-26)