



doi:10.7659/j.issn.1005-6947.2023.07.012  
http://dx.doi.org/10.7659/j.issn.1005-6947.2023.07.012  
China Journal of General Surgery, 2023, 32(7):1071-1078.

· 临床研究 ·

# 基于H2O自动化机器学习的肝硬化患者死亡预测模型的建立

王玉<sup>1</sup>, 徐中华<sup>2</sup>, 虞卫新<sup>1</sup>, 张辉<sup>3</sup>, 于倩倩<sup>4</sup>, 段文斌<sup>5</sup>

(江苏大学附属金坛医院 1. 肝胆外科 2. 骨科 4. 肿瘤科, 江苏常州 213200; 3. 中南大学湘雅医院 儿科, 湖南长沙 410008; 5. 湖南省人民医院/湖南师范大学附属第一医院 肝胆外科, 湖南长沙 410005)

## 摘要

**背景与目的:** 晚期肝硬化患者往往出现一系列并发症, 死亡风险增加。因此, 尽早识别肝硬化死亡高风险具有重要的临床意义。本研究利用H2O平台自动化机器学习 (AutoML) 框架, 建立预测肝硬化患者入院30 d死亡模型, 以期改善肝硬化患者预后以及肝硬化临床管理提供新的方法。

**方法:** 收集江苏大学附属金坛医院及湖南省人民医院肝硬化住院患者入院时一般资料及实验室检查数据。利用H2O AutoML框架建立针对死亡结局的多种机器学习算法模型, 绘制受试者工作特征 (ROC) 曲线并建立混淆矩阵来评价模型效力, 同时对重要变量进行可视化呈现。

**结果:** 最佳模型为梯度提升机 (GBM), Gini值0.994,  $R^2$ 为0.775, LogLoss为0.120。模型中重要变量包括凝血酶原时间、肌酐、白细胞及年龄。变量SHAP特征图及部分依赖图呈现了重要变量与模型整体预测的相关性。局部可解析性算法 (LIME) 可视化显示变量在个体预测的作用。最佳模型GBM在验证集中特异度为0.950, 敏感度0.676, ROC曲线下面积 (AUC) 为0.793, 优于基于极致梯度提升 (XG-Boost)、Logistic回归、随机森林和深度学习四个算法模型, 以及终末期肝病模型 (MELD) 及白蛋白-胆红素 (ALBI) 评分。

**结论:** 所建立的预测短期死亡机器学习模型对肝硬化患者的短期死亡风险筛查提供了有效的工具, 但其可靠性仍需多中心的外部验证进一步评估。

## 关键词

肝硬化; 机器学习; 模型, 统计学; 混淆矩阵; 数据可视化

中图分类号: R657.3

## Development of a prediction model for mortality in liver cirrhosis patients based on H2O automated machine learning

WANG Yu<sup>1</sup>, XU Zhonghua<sup>2</sup>, YU Weixin<sup>1</sup>, ZHANG Hui<sup>3</sup>, YU Qianqian<sup>4</sup>, DUAN Wenbin<sup>5</sup>

(1. Department of Hepatobiliary Surgery 2. Department of Orthopaedics 4. Department of Oncology, Jintan Affiliated Hospital of Jiangsu University, Changzhou, Jiangsu 213200, China; 3. Department of Pediatrics, Xiangya Hospital, Central South University, Changsha 410008, China; 5. Department of Hepatobiliary Surgery, Hunan Provincial People's Hospital/the First Affiliated Hospital of Hunan Normal University, Changsha 410005, China)

**基金项目:** 江苏省常州市科技局第十三批科技计划 (应用基础研究) 基金资助项目 (CJ20210005、CJ20210006); 江苏大学医教协同创新基金资助项目 (JDY2022018)。

**收稿日期:** 2022-03-03; **修订日期:** 2023-01-10。

**作者简介:** 王玉, 江苏大学附属金坛医院副主任医师, 主要从事肝胆外科疾病方面的研究。

**通信作者:** 段文斌, Email: duanwenbin0222@163.com

**Abstract**

**Background and Aims:** Patients with advanced liver cirrhosis often experience a series of complications, leading to an increased risk of death. Therefore, early identification of high-risk patients for liver cirrhosis mortality is of significant clinical importance. In this study, we used the H2O platform and automated machine learning (AutoML) framework to develop a predictive model for 30-d in-hospital mortality in liver cirrhosis patients, aiming to provide new methods for improving patient prognosis and clinical management of liver cirrhosis.

**Methods:** General information and laboratory examination data were collected from hospitalized liver cirrhosis patients at Jintan Hospital affiliated with Jiangsu University and Hunan Provincial People's Hospital. Multiple machine learning algorithm models for mortality outcomes were established using the H2O AutoML framework. ROC curves were plotted, and confusion matrices were used to evaluate the performance of the models. Furthermore, important variables were visualized.

**Results:** The best model, gradient boosting machine (GBM), had a Gini value of 0.994,  $R^2$  of 0.775, and LogLoss of 0.120. Important variables in the model included prothrombin time, creatinine, white blood cells, and age. The SHAP feature graph and partial dependence graph demonstrated the correlation between important variables and the overall predictions of the model. LIME visualization showed the individual predictive effects of the variables. The best GBM model had a specificity of 0.950, sensitivity of 0.676, and AUC of 0.793 in the validation set, outperforming four algorithm models (XGBoost, Logistic regression, random forest, and deep learning), as well as the MELD and ALBI scores.

**Conclusions:** The established machine learning model for predicting short-term mortality provides an effective tool for screening the risk of short-term death in patients with liver cirrhosis. However, its reliability still needs further evaluation through external validation from multiple centers.

**Key words**

Liver Cirrhosis; Machine Learning; Models, Statistical; Confusion Matrix; Data Visualization

**CLC number:** R657.3

肝硬化一旦进展到失代偿期，患者往往出现一系列并发症，包括：门静脉高压导致的食管胃底静脉曲张破裂出血、大量腹水合并自发性腹膜炎、肝性脑病等，死亡风险明显增加<sup>[1-2]</sup>。流行病学研究<sup>[3]</sup>证实，失代偿期肝硬化患者5年生存率仅为14%。作为乙肝大国，肝硬化及并发症严重威胁着我国广大慢性肝病患者生存质量，给社会带来严重经济负担。尽早识别肝硬化死亡高风险患者，对于改善肝硬化患者预后极其重要<sup>[2]</sup>。过去20年，国内外学者通过一系列前瞻性或回顾性临床研究，建立了肝硬化并发症的回归模型，显示出良好的预测效果<sup>[4-7]</sup>。

过去10年，机器学习算法，包括支持向量机、决策树、朴素贝叶斯等，在医学研究监督学习中广泛运用<sup>[8]</sup>。新算法的快速迭代，让非计算机专业出身的临床医生利用机器学习方法进行临床科研时面临巨大挑战。近两年，自动化机器学习（automatic machine learning, AutoML）的出现或许可

改善这一局面<sup>[9]</sup>。本研究采集江苏大学附属金坛医院及湖南省人民医院肝硬化患者常规资料及实验室检查数据，利用H2O平台AutoML框架建立一系列机器学习模型，预测短期死亡，旨在为肝硬化临床管理提供新的思路。

## 1 资料与方法

### 1.1 研究对象

本研究收集2018年1月至2021年12月期间于江苏大学附属金坛医院及湖南省人民医院就诊患者数据。纳入994例肝硬化患者，入院后随访30 d，根据30 d内死亡事件发生与否分为生存组848例与死亡组146例。本研究获江苏大学附属金坛医院及湖南省人民医院伦理委员会批准（江苏大学附属金坛医院：伦审2019010；湖南省人民医院：伦审2021第05号）。所有纳入患者均签署知情同意书。排除标准：（1）非肝硬化及并发症死亡

者; (2) 合并严重的心脑血管疾病者; (3) 合并恶性肿瘤者; (4) 合并严重内分泌或系统性免疫疾病者。

## 1.2 临床及实验室检测

**1.2.1 一般资料** 收集肝硬化患者入院时一般资料。查找电子病历系统记录或电话随访, 收集患者自入院后 30 d 的死亡情况及原因。

**1.2.2 血清学检测及评分计算** 收集所有肝硬化患者入院时空腹静脉血。检测项目包括: 血细胞常规、肝肾功能、血糖血脂、电解质分析及凝血功能等。根据上述指标计算终末期肝病模型 (model for end-stage liver disease, MELD) 分值<sup>[10]</sup>和白蛋白-胆红素 (albumin-bilirubin, ALBI) 分值<sup>[11]</sup>。

## 1.3 统计学处理

计量资料以均数  $\pm$  标准差 ( $\bar{x} \pm s$ ) 表示, 计数资料以例数 (百分比) [ $n$  (%)] 表示。利用 H2O 平台 (h2o 包版本 3.34.0.6) AutoML 框架建立一系列针对死亡二分类结局的机器学习预测模型。绘制受试者工作特征 (receiver operating characteristics,

ROC) 曲线并建立混淆矩阵 (confusion matrix), 计算包括敏感度、特异度及 ROC 曲线下面积 (area under curve, AUC) 指标来评价模型区分能力。此外, 为增强机器学习模型的可解释性, 呈现变量在模型中的重要性及分布情况, 进行如 SHAP 分析 (SHapley Additive exPlanations)、部分依赖图 (partial dependence plots) 以及局部可解析性算法 (local interpretable model agnostic explanation, LIME) 等可视化分析。以上统计学分析及绘图采用 R (4.0.4 版)。双侧  $P < 0.05$  为差异有统计学意义。

## 2 结果

### 2.1 两组间一般资料

本研究共纳入 994 例肝硬化患者, 根据 30 d 死亡结局分为生存组和死亡组。患者的一般资料见表 1。

表 1 纳入研究人群的一般资料

Table 1 General information of the study population included

资料	生存组( $n=848$ )	死亡组( $n=146$ )	$P$
性别[ $n$ (%)]			
男	525(61.9)	93(63.7)	0.750
女	323(38.1)	53(36.3)	
年龄(岁, $\bar{x} \pm s$ )	58.70 $\pm$ 13.96	63.99 $\pm$ 13.30	<0.001
白细胞计数( $\times 10^9$ /L, $\bar{x} \pm s$ )	5.47 $\pm$ 3.72	9.06 $\pm$ 7.00	<0.001
血小板( $\times 10^9$ /L, $\bar{x} \pm s$ )	99.12 $\pm$ 67.18	87.11 $\pm$ 60.17	0.043
红细胞计数( $\times 10^{12}$ /L, $\bar{x} \pm s$ )	97.24 $\pm$ 26.68	89.90 $\pm$ 35.34	0.004
总胆红素(mg/dL, $\bar{x} \pm s$ )	3.83 $\pm$ 5.20	8.53 $\pm$ 9.01	<0.001
肌酐(mg/dL, $\bar{x} \pm s$ )	0.88 $\pm$ 0.80	1.27 $\pm$ 1.19	<0.001
丙氨酸氨基转移酶(U/L, $\bar{x} \pm s$ )	70.32 $\pm$ 276.54	106.89 $\pm$ 188.17	0.125
天冬氨酸氨基转移酶(U/L, $\bar{x} \pm s$ )	89.10 $\pm$ 441.49	132.35 $\pm$ 222.88	0.247
白蛋白(g/L, $\bar{x} \pm s$ )	31.06 $\pm$ 6.24	27.98 $\pm$ 5.80	<0.001
钠离子(mmol/L, $\bar{x} \pm s$ )	139.08 $\pm$ 4.11	138.32 $\pm$ 5.77	0.054
总胆固醇(mmol/L, $\bar{x} \pm s$ )	3.41 $\pm$ 1.24	2.76 $\pm$ 1.15	<0.001
高密度脂蛋白(mmol/L, $\bar{x} \pm s$ )	0.92 $\pm$ 0.48	0.52 $\pm$ 0.40	<0.001
低密度脂蛋白(mmol/L, $\bar{x} \pm s$ )	1.88 $\pm$ 1.92	1.42 $\pm$ 0.82	0.004
前白蛋白(mg/L, $\bar{x} \pm s$ )	86.27 $\pm$ 49.69	62.23 $\pm$ 33.10	<0.001
凝血酶原时间(s, $\bar{x} \pm s$ )	15.97 $\pm$ 3.70	21.13 $\pm$ 9.46	<0.001
LnINR( $\bar{x} \pm s$ )	0.31 $\pm$ 0.21	0.56 $\pm$ 0.37	<0.001
MELD 评分( $\bar{x} \pm s$ )	10.45 $\pm$ 6.27	18.11 $\pm$ 10.16	<0.001
ALBI 评分( $\bar{x} \pm s$ )	-2.41 $\pm$ 0.64	-1.95 $\pm$ 0.62	<0.001

### 2.2 AutoML框架下建立机器学习模型

将收集的资料经预处理后载入 H2O 平台 AutoML 框架中，个案比例按照 0.8:0.2 随机分组为训练集（786 例）及验证集（208 例）。而后进行 AutoML 特征选择、运算建模。

AutoML 框架下自动建模最长时设置为 120 s，共建立了 61 个机器学习模型。根据机器学习主要的 5 种分类，提取了各类 5 个最优模型，即：Logistic 回归、随机森林、梯度提升机（gradient boosting machine, GBM）、极致梯度提升（eXtreme gradient boosting, XGBoost）以及深度学习。

基于训练集，得到最佳模型为 GBM（ID: GBM\_grid\_1\_AutoML\_6\_20220107\_130024\_model\_14）。该模型基于训练集的 Gini 值 0.994，R<sup>2</sup> 为 0.775，LogLoss 为 0.120。模型中重要性绝对值排名前四的变量分别为凝血酶原时间（13.4%）、肌酐（12.7%）、白细胞（12.5%）及年龄（11.9%），其占比均超过 10%。相对值完整排名见图 1。



图1 最佳模型GBM中各变量重要性相对值排名  
Figure 1 Relative ranking of variable importance in the best model GBM

### 2.3 变量在模型中作用的可视化实现

在 GBM 模型中，重要变量的 SHAP 特征图绘制在图 2 中。可以看到白细胞、肌酐及凝血酶原时间

三个变量在结局二分类中的分布，体现其标准化数值与发病呈正相关趋势；而高密度脂蛋白胆固醇和总胆固醇呈负相关。图 3 为 LIME 可视化，显示是随机抽取的 6 个样本（生存组 4 例，死亡组 2 例）中重要变量对个体预测的作用。图 4 显示的是重要性前四位的变量在 GBM 模型中的部分依赖图，可以看出四个变量与预测结果基本上呈现的是上升趋势。

### 2.4 多个预测模型及评分系统在验证集中的区分能力

如表 2 所示，采用上述获得的多个算法最优模型绘制预判 30 d 死亡的 ROC 曲线并建立混淆矩阵。在训练集中表现最佳的 GBM 模型，在验证集中特异度为 0.950，敏感度 0.676，AUC 为 0.793，仍优于 XGBoost、Logistic 回归、随机森林以及深度学习四个算法的最佳模型。此外，与临床实践中评价慢性肝病患者预后的 MELD 及 ALBI 评分相比，GBM 也同样优于两者。

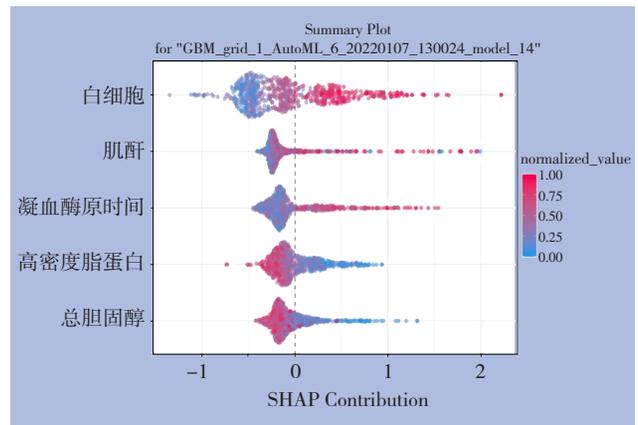


图2 最佳模型中各变量SHAP特征（横轴坐标表示变量在结局分类中的分布，纵坐标表示各变量）

Figure 2 SHAP features of variables in the best model (The horizontal axis representing the distribution of variables in outcome categories, and the vertical axis representing the respective variables)

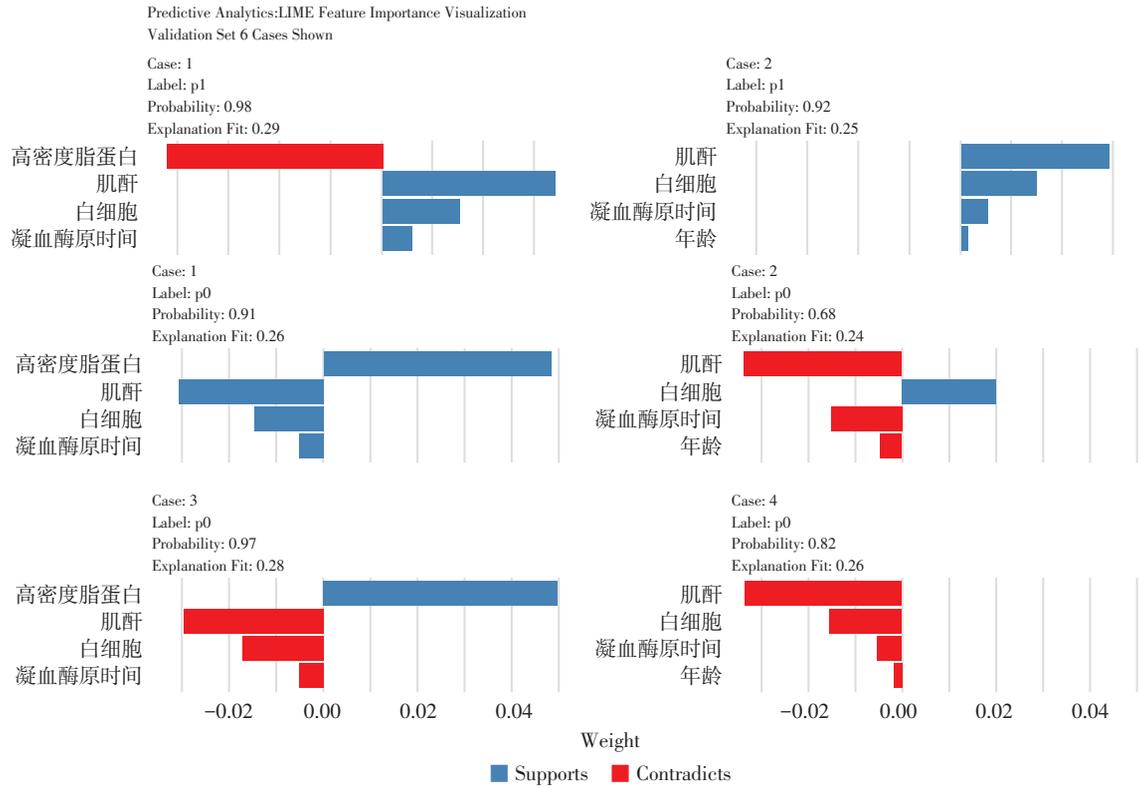


图3 随机样本中变量重要性LIME可视化 (随机样本中, 显示重要变量在个体预测中作用; p0表示生存, p1表示死亡)  
 Figure 3 LIME visualization of variable importance in random samples (in random samples, displaying the role of important variables in individual predictions; p0 representing survival, p1 representing death)

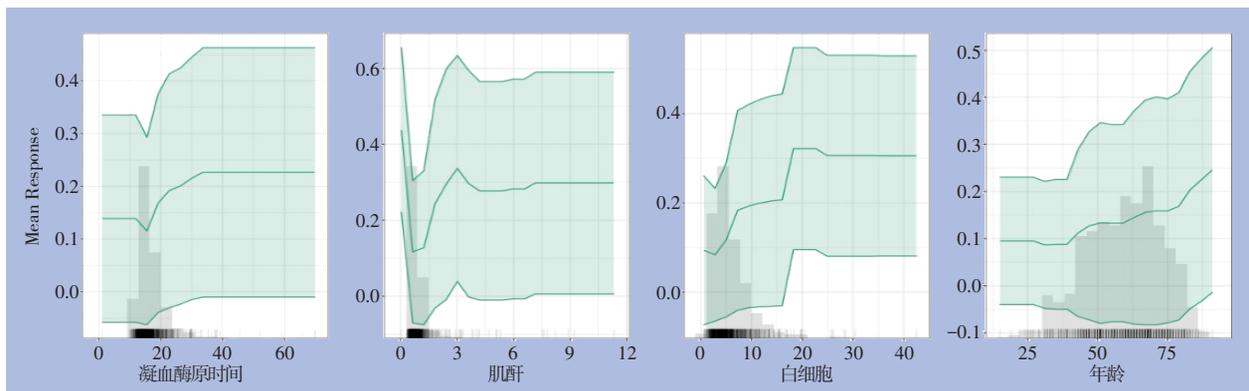


图4 最佳模型中变量部分依赖图 (部分依赖图显示的是排名前四变量对GBM模型的预测结果的边际效应)  
 Figure 4 Partial dependence plots of variables in the best model (partial dependence plots showing the marginal effects of the top four ranked variables on the predictions of the GBM model)

表2 各机器学习模型及常用评分在验证集上的表现  
Table 2 Performance of various machine learning models and commonly used scores on the validation set

模型	实际分类	模型分类		模型预测表现		
		生存	死亡	敏感度	特异度	AUC
GBM						
	生存	173	9	0.676	0.950	0.793
	死亡	11	26			
XGBoost						
	生存	169	11	0.529	0.939	0.718
	死亡	16	18			
Logistic 回归						
	生存	169	14	0.500	0.922	0.695
	死亡	17	17			
随机森林						
	生存	161	19	0.588	0.894	0.723
	死亡	41	20			
深度学习						
	生存	151	29	0.706	0.839	0.752
	死亡	29	24			
MELD 评分						
	生存	126	46	0.667	0.733	0.676
	死亡	12	24			
ALBI 评分						
	生存	105	67	0.806	0.610	0.734
	死亡	7	29			

### 3 讨论

随着机器学习算法的飞速发展,人工智能模型的建立不仅对建模者的专业知识提出高要求,同时还对模型选择、特征提取、超参调整等计算机领域能力提出了挑战<sup>[8]</sup>。近年来,多个科技公司陆续推出自动化学学习框架,如H2O的AutoML及谷歌的Cloud AutoML等<sup>[9]</sup>。AutoML大大简化机器学习的前期工作,如数据预处理、特征选择与提取及环境建立。而在模型建立中,算法选择、优化、调参等繁琐过程,也可被简化实现。

集成学习是在监督学习中,通过堆叠多个弱分类器(独立传统算法),以期获得更佳的预测性能。根据抽样及权重的不同,可分类为Boosting和Bagging两种集成学习方法。GBM是集成学习Boosting的一种实现方式,通过多个新分类器拟合负梯度来降低偏差<sup>[12]</sup>。H2O.ai始于Oxdata公司于2014年推出的一项机器学习的开源平台,前期的服务对象是数据工程师与数据科学家,提供可快

速搭建的机器学习引擎。H2O AutoML是H2O平台近年推出的自动化学学习框架<sup>[9]</sup>。该框架就包括了众多机器学习算法,如广义线性回归、决策树、集成学习、深度学习等。

既往国内外研究中,基于实验室指标建立的多个评分系统已被广泛报道,并应用于预测肝硬化患者预后中。MELD评分最早应用于接受经颈静脉肝内门静脉分流术患者的死亡预测中,该评分包括肌酐、总胆红素及INR等变量<sup>[10]</sup>。后续研究证实血清钠离子水平同样是肝硬化患者预后的独立危险因素,因此加入钠浓度形成MELD-Na评分,提高了原模型对肝硬化患者预后的预测能力<sup>[13]</sup>。2015年,Johnson等<sup>[11]</sup>建立了ALBI评分,该模型仅由白蛋白和总胆红素两变量组成,用于评估肝脏肿瘤患者的预后。

临床实践中,尤其在对肝硬化患者的急诊诊疗过程中得到信息很有限,相关病史包括肝硬化的病因、病程、抗病毒治疗史等信息常常是缺失的。在接诊的第1天中,得到往往仅有一般基本资料和实验室检查数据。如何充分利用入院第1天数据,判断患者在短期预后,对肝硬化患者临床诊疗工作十分重要。

本研究是一项基于医院的病例-对照研究,收集肝硬化住院患者入院时临床资料及实验室结果,预测入院后30d的死亡事件发生。本研究利用H2O平台的AutoML框架,在训练集建立了基于5种机器学习算法的最优模型,并在验证集中证实了基于GBM算法的集成模型是最佳模型,优于Logistic回归、随机森林、XGBoost,甚至是深度学习模型。此外,GBM模型还与MELD、ALBI评分系统进行比较,表现也同样优异。在建模过程中发现,凝血功能、肾功能、白细胞及年龄等是短期内肝硬化死亡的重要变量,这与国内外报道<sup>[14-20]</sup>相似。其中,凝血功能考虑与消化道出血这一肝硬化严重并发症有关。而肌酐和白细胞作为肝硬化患者极差预后的重要变量,可能与失代偿性肝硬化常合并大量腹水、自发性腹膜炎及肝肾综合征有关<sup>[21-23]</sup>。前者还与近年来发现的血管舒张机制和非血管舒张机制在肝硬化进展中的作用有关<sup>[24]</sup>。在肝硬化失代偿期,循环血容量不足导致的肾功能不全在患者预后中也占据十分重要的位置<sup>[25]</sup>。同时,外周循环中白细胞增多的肝硬化患者常伴有高水平的促炎内环境<sup>[26]</sup>。最后,年龄作为慢性

疾病预测模型或评分中的常用指标,与死亡这类结局往往是强相关<sup>[27]</sup>。为打破机器学习不可解释的“黑盒”效应,本研究还通过多种可视化方法来呈现重要变量在整体模型预测及个体预测过程中的作用。这类机器学习可视化实现的分析方法在肝病模型中报道较少。基于GBM算法的肝硬化短期死亡预测模型,显示出较好区分能力,同时良好的特异度表明在临床实践中适合作为风险初筛工具。笔者希望此初筛模型,为急诊、重症医学的临床医务人员,了解患者的可能预后,将有限的医疗资源放在高危患者救治中。因此,GBM模型的高特异度,可以很好的起到排除死亡风险低患者,从而优化急诊分流。避免出现将死亡风险高的患者轻处理这样的临床不良管理事件。

本研究收集多中心肝硬化患者入院数据,利用AutoML框架,建立预测短期死亡机器学习模型。该模型对肝硬化患者的短期死亡结局进行预测,显示出良好的预测能力,且优于MELD、ALBI传统评分系统。本研究优势在于,利用AutoML学习框架,快速建立多种算法的机器学习模型,为今后机器学习在临床科研领域应用提供参考。本研究作为回顾性研究,仍需多中心的外部验证进一步评估该模型效果。

利益冲突:所有作者均声明不存在利益冲突。

作者贡献声明:本文由王玉负责编写;王玉、徐中华负责完成研究设计和数据分析;于倩倩负责数据收集并撰写文章;虞卫新负责文章校对;张辉对自动化机器学习模型的建立及校正给予技术指导;段文斌对文章进行总体审核。

## 参考文献

- [1] 科技部十二五重大专项联合课题组. 乙型肝炎病毒相关肝硬化的临床诊断、评估和抗病毒治疗的综合管理[J]. 中华肝脏病杂志, 2014, 22(5): 327-335. doi: 10.3760/cma.j.issn.1007-3418.2014.05.002.  
The 12th five-year major project of the Ministry of Science and Technology. Management of clinical diagnosis, evaluation, and antiviral therapy for HBV-related cirrhosis[J]. Chinese Journal of Hepatology, 2014, 22(5): 327-335. doi: 10.3760/cma.j.issn.1007-3418.2014.05.002.
- [2] Das K, Das K, Datta S, et al. Course of disease and survival after onset of decompensation in hepatitis B virus-related cirrhosis[J]. Liver Int, 2010, 30(7): 1033-1042. doi: 10.1111/j.1478-3231.2010.02255.x.
- [3] D'Amico G, Morabito A, D'Amico M, et al. Clinical states of cirrhosis and competing risks[J]. J Hepatol, 2018, 68(3):563-576. doi: 10.1016/j.jhep.2017.10.020.
- [4] Lin L, Yang F, Wang Y, et al. Prognostic nomogram incorporating neutrophil-to-lymphocyte ratio for early mortality in decompensated liver cirrhosis[J]. Int Immunopharmacol, 2018, 56: 58-64. doi: 10.1016/j.intimp.2018.01.007.
- [5] 门昌君, 张国梁, 邵娴. 基于超声内镜及临床数据预测肝硬化患者出血风险的列线图模型建立[J]. 中华肝脏病杂志, 2021, 29(8): 759-765. doi: 10.3760/cma.j.cn501113-20200808-00443.  
Men CJ, Zhang GL, Shao X. Establishment of a nomogram model for predicting bleeding risk based on endoscopic ultrasound and clinical data among patients with liver cirrhosis[J]. Chinese Journal of Hepatology, 2021, 29(8):759-765. doi: 10.3760/cma.j.cn501113-20200808-00443.
- [6] 刘姝静. 乙型肝炎肝硬化失代偿期死亡风险预测评估的模型建立[D]. 长春: 吉林大学, 2021.  
Liu SJ. Establishment of A model for predicting the risk of death in decompensated stage of hepatitis B cirrhosis[D]. Changchun: Jilin University, 2021.
- [7] 向守书, 谈军涛, 文元久, 等. 肝硬化伴自发性细菌性腹膜炎的诊断模型研究及验证[J]. 第三军医大学学报, 2021, 43(20):2226-2234. doi: 10.16016/j.1000-5404.202104100.  
Xiang SS, Tan JT, Wen YJ, et al. Establishment and verification of a diagnostic model of liver cirrhosis with spontaneous bacterial peritonitis[J]. Journal of Army Medical University, 2021, 43(20): 2226-2234. doi: 10.16016/j.1000-5404.202104100.
- [8] Handelman GS, Kok HK, Chandra RV, et al. eDoctor: machine learning and the future of medicine[J]. J Intern Med, 2018, 284(6): 603-619. doi: 10.1111/joim.12822.
- [9] LeDell E, Poirier S. H2O autoML: scalable automatic machine learning//7th ICML Workshop on Automated Machine Learning (AutoML). [https://www.automl.org/wp-content/uploads/2020/07/AutoML\\_2020\\_paper\\_61.pdf](https://www.automl.org/wp-content/uploads/2020/07/AutoML_2020_paper_61.pdf).
- [10] Kamath P. A model to predict survival in patients with end-stage liver disease[J]. Hepatology, 2001, 33(2): 464-470. doi: 10.1053/jhep.2001.22172.
- [11] Johnson PJ, Berhane S, Kagebayashi C, et al. Assessment of liver function in patients with hepatocellular carcinoma: a new evidence-based approach-the ALBI grade[J]. J Clin Oncol, 2015, 33(6):550-558. doi: 10.1200/JCO.2014.57.9151.
- [12] Friedman JH. Greedy function approximation: a gradient boosting machine[J]. Ann Statist, 2001, 29(5):1189-1232. doi: 10.1214/aos/

- 1013203451.
- [13] Biggins SW, Kim WR, Terrault NA, et al. Evidence-based incorporation of serum sodium concentration into MELD[J]. *Gastroenterology*, 2006, 130(6): 1652–1660. doi: [10.1053/j.gastro.2006.02.010](https://doi.org/10.1053/j.gastro.2006.02.010).
- [14] Tandon P, Garcia-Tsao G. Bacterial infections, sepsis, and multiorgan failure in cirrhosis[J]. *Semin Liver Dis*, 2008, 28(1):26–42. doi: [10.1055/s-2008-1040319](https://doi.org/10.1055/s-2008-1040319).
- [15] Lv Y, Wang Z, Li K, et al. Risk Stratification Based on Chronic Liver Failure Consortium Acute Decompensation Score in Patients With Child-Pugh B Cirrhosis and Acute Variceal Bleeding[J]. *Hepatology*, 2021, 73(4):1478–1493. doi: [10.1002/hep.31478](https://doi.org/10.1002/hep.31478).
- [16] Carey EJ, Lai JC, Wang CW, et al. A multicenter study to define sarcopenia in patients with end-stage liver disease[J]. *Liver Transpl*, 2017, 23(5):625–633. doi: [10.1002/lt.24750](https://doi.org/10.1002/lt.24750).
- [17] Muslimovic A, Rasic S, Tulumovic D, et al. Inflammatory Markers and Procoagulants in Chronic Renal Disease Stages 1–4[J]. *Med Arch*, 2015, 69(5):307–310. doi: [10.5455/medarh.2015.69.307-310](https://doi.org/10.5455/medarh.2015.69.307-310).
- [18] Ginès P, Solà E, Angeli P, et al. Hepatorenal syndrome[J]. *Nat Rev Dis Primers*, 2018, 4(1):23. doi: [10.1038/s41572-018-0022-7](https://doi.org/10.1038/s41572-018-0022-7).
- [19] Northup PG, Caldwell SH. Coagulation in liver disease: a guide for the clinician[J]. *Clin Gastroenterol Hepatol*, 2013, 11(9): 1064–1074. doi: [10.1016/j.cgh.2013.02.026](https://doi.org/10.1016/j.cgh.2013.02.026).
- [20] Wu TZ, Li J, Shao L, et al. Development of diagnostic criteria and a prognostic score for hepatitis B virus-related acute-on-chronic liver failure[J]. *Gut*, 2018, 67(12):2181–2191. doi: [10.1136/gutjnl-2017-314641](https://doi.org/10.1136/gutjnl-2017-314641).
- [21] Ooi PH, Hager A, Mazurak VC, et al. Sarcopenia in Chronic Liver Disease: Impact on Outcomes[J]. *Liver Transpl*, 2019, 25(9):1422–1438. doi: [10.1002/lt.25591](https://doi.org/10.1002/lt.25591).
- [22] Lv Y, Zuo L, Zhu X, et al. Identifying optimal candidates for early TIPS among patients with cirrhosis and acute variceal bleeding: a multicentre observational study[J]. *Gut*, 2019, 68(7): 1297–1310. doi: [10.1136/gutjnl-2018-317057](https://doi.org/10.1136/gutjnl-2018-317057).
- [23] Wang X, Luo J, Liu C, et al. Impact of variceal eradication on rebleeding and prognosis in cirrhotic patients undergoing secondary prophylaxis[J]. *Ann Transl Med*, 2021, 9(7): 540. doi: [10.21037/atm-20-3401](https://doi.org/10.21037/atm-20-3401).
- [24] Chanchaonthana W, Leelahavanichkul A. Acute kidney injury spectrum in patients with chronic liver disease: Where do we stand? [J]. *World J. Gastroenterol*, 2019, 25(28): 3684–3703. doi: [10.3748/wjg.v25.i28.3684](https://doi.org/10.3748/wjg.v25.i28.3684).
- [25] Adebayo D, Morabito V, Davenport A, et al. Renal dysfunction in cirrhosis is not just a vasomotor nephropathy[J]. *Kidney Int*, 2015, 87(3):509–515. doi: [10.1038/ki.2014.338](https://doi.org/10.1038/ki.2014.338).
- [26] Bajaj JS, O'Leary JG, Reddy KR, et al. Survival in infection-related acute-on-chronic liver failure is defined by extrahepatic organ failures[J]. *Hepatology*, 2014, 60(1): 250–256. doi: [10.1002/hep.27077](https://doi.org/10.1002/hep.27077).
- [27] Sajja KC, Mohan DP, Rockey DC. Age and ethnicity in cirrhosis[J]. *J Investig Med*, 2014, 62(7): 920–926. doi: [10.1097/JIM.000000000000106](https://doi.org/10.1097/JIM.000000000000106).

( 本文编辑 熊杨 )

本文引用格式: 王玉, 徐中华, 虞卫新, 等. 基于H2O自动化机器学习的肝硬化患者死亡预测模型的建立[J]. 中国普通外科杂志, 2023, 32(7):1071–1078. doi: [10.7659/j.issn.1005-6947.2023.07.012](https://doi.org/10.7659/j.issn.1005-6947.2023.07.012)

Cite this article as: Wang Y, Xu ZH, Yu WX, et al. Development of a prediction model for mortality in liver cirrhosis patients based on H2O automated machine learning[J]. *Chin J Gen Surg*, 2023, 32(7):1071–1078. doi: [10.7659/j.issn.1005-6947.2023.07.012](https://doi.org/10.7659/j.issn.1005-6947.2023.07.012)