



电子、语音版

·论著·

基于机器学习构建的7种不同模型预测重型颅脑损伤所致昏迷患者近期预后临床效能比较

王小峰, 白西民, 党俊涛, 姚胜, 王峰, 杜春亮
渭南市中心医院神经外科, 陕西渭南 714000

摘要:目的 探讨并构建最优的机器学习模型,以预测重型颅脑损伤昏迷患者的近期预后。方法 回顾性分析2022年1月1日—2024年12月1日收治的262例重型颅脑损伤昏迷患者。根据6个月随访时的格拉斯哥预后评分(GOS),将患者分为预后良好组(GOS \geq 4分,112例)和预后不良组(GOS \leq 3分,150例)。研究利用患者入院时的临床数据,分别采用逻辑回归(LR)、支持向量机(SVM)、多元自适应回归样条(MARS)、随机森林(RF)、K近邻(KNN)、极限梯度提升(XGB)和人工神经网络(ANN)共7种机器学习方法构建预测模型。通过10折交叉验证评估模型性能,并以受试者操作特征(ROC)曲线下面积(AUC)为主要指标,同时比较各模型的准确度、灵敏度和特异度。结果 在7种机器学习模型中,ANN模型的预测性能优于其他模型,其AUC值为0.905。其余模型的AUC为0.581~0.760。在准确度、灵敏度和特异度方面,ANN也表现最佳。进一步验证显示,该ANN模型在训练集和测试集中的损失函数、均方差和精确度在100次迭代中趋势一致,表明模型稳定可靠。影响预后的关键因素分析显示,格拉斯哥昏迷评分(GCS)、脑电双频指数(BIS)和血氧分压(PO_2)是模型中最重要的预测因子。结论 基于ANN算法构建的预测模型对重型颅脑损伤昏迷患者的近期预后具有良好的预测能力,性能优于传统机器学习模型,可为临床判断病情和预后提供有价值的参考依据。

关键词:颅脑损伤;预后;机器学习;人工神经网络;预测模型

中图分类号:R651.15

DOI:10.16636/j.cnki.jinn.1673-2642.2026.01.006

Comparison of the clinical efficacy of seven machine learning - based models for predicting short - term prognosis in comatose patients with severe traumatic brain injury

WANG Xiaofeng, BAI Ximin, DANG Juntao, YAO Sheng, WANG Feng, DU Chunliang

Department of Neurosurgery, Weinan Central Hospital, Weinan, Shaanxi 714000, China

Corresponding author: DU Chunliang, Email: 3024282536@qq.com

Abstract: **Objective** To develop and identify the optimal machine learning model for predicting the short - term prognosis of comatose patients with severe traumatic brain injury (sTBI). **Methods** A retrospective analysis was conducted on 262 comatose patients with sTBI admitted between January 1, 2022, and December 1, 2024. Based on the Glasgow Outcome Scale (GOS) score at the 6-month follow-up, patients were divided into a favorable prognosis group (GOS \geq 4, n=112) and an unfavorable prognosis group (GOS \leq 3, n=150). Prediction models were constructed using clinical data collected at admission with seven machine learning algorithms: logistic regression, support vector machine, multivariate adaptive regression splines, random forest, k-nearest neighbors, extreme gradient boosting, and artificial neural network (ANN). Model performance was evaluated via 10-fold cross-validation, with the area under the receiver

基金项目:陕西省渭南市首席行业(学科)专家基金项目;陕西省渭南市重点科技计划项目(2024-ZDYFJH-627)。

收稿日期:2025-07-23;修回日期:2026-02-18

作者简介:王小峰(1989—),男,硕士研究生,主治医师,研究方向为颅脑损伤、神经重症及神经内镜的基础与临床研究。Email:441975169@qq.com。

通信作者:杜春亮(1980—),男,本科学历,副主任医师,研究方向为颅脑损伤及脑血管疾病的临床研究。Email:3024282536@qq.com。

operating characteristic curve (AUC) serving as the primary evaluation metric. Accuracy, sensitivity, and specificity were also compared. **Results** Among the seven models, the ANN model demonstrated superior prediction performance, achieving an AUC of 0.905. The AUCs for the remaining models ranged from 0.581 to 0.760. The ANN model also exhibited the highest accuracy, sensitivity, and specificity. Further validation confirmed the stability of the ANN model, as indicated by the consistent trends of the loss function, mean squared error, and accuracy over 100 iterations on both the training and test sets. Analysis of key prognostic factors identified the Glasgow Coma Scale score, bispectral index, and partial pressure of oxygen as the most significant predictors in the model. **Conclusions** The prediction model based on the ANN algorithm demonstrates excellent performance in predicting the short-term prognosis of comatose patients with sTBI, outperforming other traditional machine learning models. This model may provide a valuable reference for clinical assessment of disease severity and prognosis.

Keywords: brain injury; prognosis; machine learning; artificial neural network; prediction model

重型颅脑损伤所致昏迷患者病情进展迅速,如不能在早期实施及时、规范的综合救治,其预后常较差^[1]。近年来,随着我国交通运输业和建筑业的快速发展,由此引发的重型颅脑损伤患者数量持续增加。如何对这类患者的预后进行准确评估,从而实施有针对性的干预,已成为临床关注的热点和难点^[2-3]。随着医学大数据和人工智能技术的发展,机器学习逐渐被应用于临床疾病预测模型的构建。基于机器学习的预测模型能够在整合大量临床变量的基础上,学习复杂的非线性关系,从而实现疾病结局的辅助诊断和预后评估^[4-6]。在机器学习领域,常用算法包括逻辑回归(logistic regression, LR)、支持向量机(support vector machine, SVM)、多元自适应回归样条(multivariate adaptive regression splines, MARS)、随机森林(random forest, RF)、K近邻(k-nearest neighbors, KNN)、极限梯度提升(extreme gradient boosting, XGB)以及人工神经网络(artificial neural network, ANN)等^[7-8]。不同算法在可解释性、非线性拟合能力等方面各有优势。为比较这些不同算法在预测重型颅脑损伤所致昏迷患者近期预后中的表现,本研究基于上述7种算法构建预测模型,对其区分度和性能指标进行系统比较,并分析模型中关键预测因子的临床意义。

1 资料与方法

1.1 一般资料与治疗

回顾性分析2022年1月1日—2024年12月1日渭南市中心医院收治的重型颅脑损伤所致昏迷患者的临床资料270例,剔除失访的8例,最终纳入研究的患者为262例。其中,男性144例,女性118例。研究涉及的患者均接受了颅脑创伤手术治疗,并在手术后被收治至我院神经外科重症监护室进行专业监护。治疗措施包括减轻脑水肿、预防应激性溃疡和感染、维持水电解质平衡及内环境稳定、提供全身营养支持以及积极预防各类并发症。

1.2 纳入以及排除标准

纳入标准:①所有患者均经过计算机断层成像(CT)

或者磁共振成像(MRI)检查明确为颅脑损伤,并且有确切的颅脑外伤病史;②所有患者均于创伤后24 h内入院;③患者入院时的格拉斯哥昏迷评分(Glasgow coma scale, GCS)3~8分;④患者若在入院的7 d以后到第6个月死亡,并且完成了研究的相关评分和脑电双频指数(electroencephalogram bispectral index, BIS)监测和实验室检查,仍纳入本次研究。排除标准:①拒绝签署知情同意书,拒绝进行本次试验;②合并恶性肿瘤病史;③外伤后超过24 h进入我院;④入院7 d以内临床死亡的患者。本研究经渭南市中心医院医学伦理委员会审批(批件号:2025研009-01)。

1.3 患者的随访以及分类

对所有纳入研究的患者均随访6个月,根据患者6个月后的格拉斯哥预后评分(Glasgow outcome scale, GOS)进行分类。参照国内相关研究^[9],将GOS≤3分归类为预后不良组,GOS≥4分归类为预后良好组。

1.4 机器学习模型的构建

进行预变量的收集。基于既往笔者团队成员阅读的相关临床文献和临床经验,收集患者的一般临床资料,患者手术相关指标以及住院期间的检测指标。其中一般临床资料为患者记录在电子病历里的入院后各项基本记录,包括:身高、体重、是否吸烟、既往病史,以及入院时的临床查体等常规录入患者电子病历的相关资料;住院期间的检查指标包括:实验室指标(包括肝肾功能、凝血、离子等化验指标),其中手术相关指标包括:患者的手术时间、手术方式、术中失血量、脑室内是否积血以及硬膜外的血肿位置。

构建模型并进行验证。在本研究中,我们利用机器学习技术构建了7种常用模型,并实施了10折交叉验证。具体操作为将收集的数据集分为10个子集,存储在不同的文件夹中。在每次验证中,单独一份数据被用作验证集,而剩余的9份用于构建训练集。该过程重复10次,每次都交替更换验证集。最终,将这10次验证的结果取平均,以此作为模型性能的估计值。

模型的评价指标。利用受试者操作特征(receiver operator characteristic curve, ROC)曲线,计算曲线下面积(area under the curve, AUC)对不同模型的预测价值进行判断,同时对比7种预测模型的准确度、特异度、灵敏度、精度和平衡F分数。

1.5 变量筛选与建模流程

先依据临床意义与既往证据预设候选变量。连续变量按需进行Z分数标准化;对明显偏态分布的连续变量(如脑利尿钠肽等)在入模前进行对数变换;分类变量采用虚拟变量编码。随后进行共线性评估[相关系数与方差膨胀系数(variance inflation factor, VIF)],当 $|r| > 0.70$ 或 $VIF \geq 5$ 时,结合临床可解释性、可获得性与缺失情况保留其一。在此基础上,采用LASSO-Logistic回归进行变量选择,并通过10折交叉验证确定惩罚参数(最小误差准则);对最终入选变量进行重估,报告比值比(odds ratio, OR)及95%置信区间(confidence interval, CI),并复核入模后共线性(目标 $VIF < 5$)及模型稳健性。

1.6 统计学方法

所有统计分析采用R 4.1软件(必要时辅以Python 3.11)完成。连续变量先行Shapiro-Wilk正态性检验及Levene方差齐性检验,符合正态且方差齐者以均数±标准差($\bar{x} \pm s$)表示,组间比较采用独立样本t检验;不符合正态分布或为有序资料者以中位数(四分位数间距)[$M(P_{25}, P_{75})$]表示,组间比较采用Mann-Whitney U检验。

计数资料以例(%)表示,组间比较采用 χ^2 检验;当任一单元格期望频数 < 5 时采用Fisher确切概率法检验。以6个月GOS(预后良好/不良)为结局变量。特征预处理、共线性评估及变量筛选流程见1.5。各机器学习模型训练统一采用10折交叉验证,并通过网格搜索调节主要超参数。模型区分度以ROC曲线下面积(AUC)评价,同时报告准确度、灵敏度与特异度;最优截断值主要依据Youden指数确定。所有检验均为双侧检验,以 $P < 0.05$ 为差异有统计学意义。

2 结果

2.1 随访以及分组结果

入组患者270例,在6个月随访过程中丢失8例患者,这8例患者中5例因为迁往外市居住,不再回我院随访,另2例患者为联系人更换联系方式,未再取得联系,后期也未在我科门诊复诊,另1例患者后期家属拒绝进行随访,最终纳入本次研究的患者为262例。失访患者与最终纳入患者的基线特征(如年龄、GCS、病情严重程度等)比较,差异无统计学意义(均 $P > 0.05$)。最后确定预后良好组112例,预后不良组150例。

2.2 人群的基线特征

在预后良好组和预后不良组的基线比较中,两组患者在入院时瞳孔散大、GCS、年龄大于60岁、脑卒中病史、颅脑损伤病史、BIS、 PO_2 (血氧分压)这几个指标比较,差异有统计学意义(均 $P < 0.05$)。见表1。

表1 两组基线资料情况

组别	例数	男性例(%)	入院时瞳孔散大例(%)	GCS/ [$M(P_{25}, P_{75})$]	脑卒中病史 例(%)	冠心病史 例(%)	高血压病史 例(%)	糖尿病史 例(%)	颅脑损伤史 例(%)
预后良好组	112	72(64.3)	23(20.5)	8[7,8]	26(23.2)	32(28.6)	45(40.2)	30(26.8)	2(1.8)
预后不良组	150	83(55.3)	78(52.0)	5[5,6]	56(37.3)	45(30.0)	62(41.3)	43(28.7)	8(5.3)
χ^2/t 值		2.127	26.798	13.549	5.945	0.471	0.035	0.113	2.198
P值		0.145	< 0.001	< 0.001	0.015	0.492	0.851	0.737	0.138

组别	例数	年龄大于60岁 例(%)	红细胞/ ($10^{12}/L, \bar{x} \pm s$)	血小板/ ($10^{12}/L, \bar{x} \pm s$)	白细胞/ ($10^9/L, \bar{x} \pm s$)	cTnI/ (ng/mL, $\bar{x} \pm s$)	CK-MB/ (u/L, $\bar{x} \pm s$)	谷草转氨酶/ (u/L, $\bar{x} \pm s$)
预后良好组	112	40(35.7)	4.43±0.33	124.67±21.87	9.35±2.44	0.32±0.13	28.55±7.58	220.89±46.89
预后不良组	150	72(48.0)	4.42±0.34	125.67±22.66	9.37±2.34	0.33±0.14	28.45±7.54	221.43±43.43
χ^2/t 值		6.429	0.240	-0.359	-0.067	-0.596	0.106	-0.096
P值		0.011	0.811	0.360	0.473	0.552	0.916	0.462

组别	例数	血钾/ (mmol/L, $\bar{x} \pm s$)	血钠/ (mmol/L, $\bar{x} \pm s$)	血钙/ (mmol/L, $\bar{x} \pm s$)	BNP/ (pg/mL, $\bar{x} \pm s$)	PO_2 / (mmHg, $\bar{x} \pm s$)	手术时间/ (h, $\bar{x} \pm s$)	BIS/($\bar{x} \pm s$)
预后良好组	112	3.89±0.72	138.86±35.89	2.03±0.24	146.78±26.67	72.81±11.72	3.03±0.43	46.78±4.64
预后不良组	150	3.91±0.69	138.45±36.46	2.06±0.27	146.68±28.42	55.78±7.82	3.05±0.41	31.78±4.78
χ^2/t 值		-0.228	0.091	-0.932	0.029	13.322	-0.383	25.444
P值		0.410	0.464	0.176	0.488	< 0.001	0.351	< 0.001

组别	例数	术中失血量/(mL, $\bar{x} \pm s$)	单侧去骨瓣例(%)	硬膜外血肿例(%)	脑室积血例(%)
预后良好组	112	412.43±56.89	58(51.8)	50(44.6)	18(16.1)
预后不良组	150	402.54±66.43	80(53.3)	74(49.3)	29(19.3)
χ^2/t 值		1.266	0.062	0.566	0.463
P值		0.103	0.804	0.452	0.496

2.3 不同机器学习算法构建的预测模型效能

在LR、SVM、MARS、RF、KNN、XGB和ANN这7种模型中,AUC分别为0.760,0.581,0.612,0.605,0.598,0.613和0.905,其中ANN的AUC最大,与此同时ANN模型的准确度、特异度、灵敏度均要优于其他6种模型。见表2、3以及图1。

表2 不同机器学习算法构建的预测模型的效能情况

预测模型	AUC值	准确度	灵敏度	特异度
LR	0.760	66.41%	62.50%	69.33%
SVM	0.581	68.70%	66.07%	70.67%
MARS	0.612	66.41%	61.61%	70.00%
RF	0.605	69.47%	64.29%	73.33%
XGB	0.598	67.94%	61.61%	72.67%
KNN	0.613	68.70%	66.07%	70.67%
ANN	0.905	90.84%	87.50%	93.33%

表3 不同机器学习模型通过测试集构建混淆矩阵例

模型	预测值	实际值	
		预后良好	预后不良
LR	预后良好	70	46
	预后不良	42	104
SVM	预后良好	74	44
	预后不良	38	106
MARS	预后良好	69	45
	预后不良	43	105
RF	预后良好	72	40
	预后不良	40	110
XGB	预后良好	69	41
	预后不良	43	109
KNN	预后良好	74	44
	预后不良	38	106
ANN	预后良好	98	10
	预后不良	14	140




图1 不同机器学习模型ROC曲线

2.4 ANN模型的训练集以及测试集预测趋势验证

ANN模型的训练集和测试集中的损失函数、均方差、精确度在100次迭代中的趋势一致。见图2~4。




图2 训练集与测试集中损失函数与迭代次数趋势




图3 训练集与测试集中均方差与迭代次数趋势




图4 训练集与测试集中精确度与迭代次数趋势

2.5 在ANN模型中对重型颅脑损伤所致昏迷患者近期影响较大的因子分析

在ANN模型中对预后影响较大的影响因素为GCS, BIS值以及PO₂,其中线的粗细与影响因子的重要性成比例。见图5。

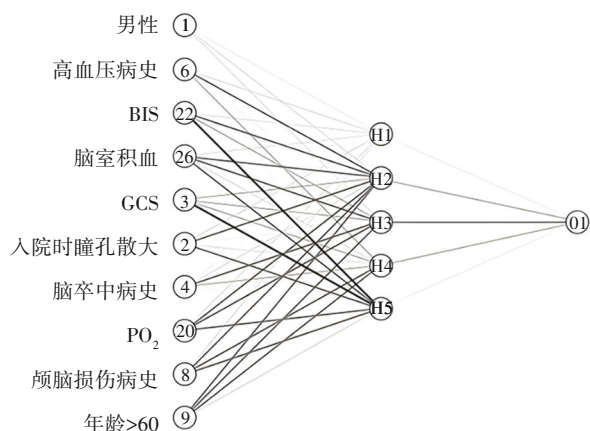


图5 在ANN模型中权重占前10的影响因子架构图

3 讨论

相应的流行病学调查显示,近些年来我国的颅脑损伤患者数量呈现出逐年上升的趋势,对于重型颅脑损伤所致昏迷患者,其病情变化较快,若不能及时有效对这类患者进行干预,患者往往预后欠佳^[10]。对于患者预后的预测,存在着多种方式,近些年来随着机器学习算法被逐步引入临床研究中,越来越多的临床决策开始依赖于机器学习。

机器学习是人工智能的一个分支,它利用临床数据集中定义的数据属性以及多种算法来预测临床结果^[11-12]。在机器学习领域,传统的LR与决策树等方法因可解释性强而被广泛应用;近年来,随着计算能力提升与数据维度增加,XGB、RF、SVM、KNN以及ANN等算法被用于刻画更复杂的非线性关系与变量交互^[13-15]。从方法学角度看,ANN在处理高维、非线性以及潜在交互效应方面具有优势,这与重型颅脑损伤昏迷患者“多系统生理紊乱—脑功能受损—治疗干预”相互叠加的真实临床场景更为匹配^[16-17]。因此,本研究在同一队列内并行比较多种算法,目的不在重复呈现具体性能数值,而在于说明:不同模型对同一结局的拟合能力存在差异,且更强的非线性建模能力可能带来更好的区分度与稳健性。需要强调的是,本研究主要采用内部交叉验证评估模型表现,模型的可迁移性仍需独立外部人群中进一步检验。

变量重要性分析提示,神经功能受损程度(如GCS)以及反映皮层电活动/镇静深度的监护指标(如BIS)与预后密切相关,这与临床经验一致:初始神经功能越差、脑功能抑制越明显,往往提示原发损伤更重或继发脑损伤风险更高。BIS本质上是对脑电信号的量化指标,受脑功能状态与镇静/镇痛药物影响较大;在重症救治情境下,其变化既可能反映脑损伤严重程度,也可能反映治疗策略与时间窗差异,因此在解释其与预后的关联时需注意混杂因素^[18]。此外,血气PO₂受吸氧、机械通气参数及

取样时点影响显著,单点测值难以充分代表持续的组织氧合状态。本研究中PO₂的组间差异与方向存在不确定性,提示其可能受到干预强度或反向因果影响。因此,本文更倾向将PO₂视为协变量/状态指标而非因果指标;未来可用PaO₂/FiO₂、时间加权均值或低氧阈值累计时间等动态指标进行再验证^[19-21]。在本研究的基础上,笔者进一步将国内外与重型颅脑损伤预后预测相关的代表性研究进行梳理和汇总(见表4)。可以看出,既往多数国内研究仍以多因素Logistic回归或传统评分量表为主,主要聚焦于年龄、损伤严重程度、瞳孔改变及影像学评分等少数临床变量,对早期死亡或中远期功能结局具有一定预测价值;近年来部分国外研究开始引入SVM、RF、ANN等机器学习算法,但研究对象多为一般创伤性脑损伤(trumatic brain injury, TBI)人群,且不同模型之间缺乏在同一队列中的系统比较。与之相比,本研究在重型颅脑损伤所致昏迷患者这一高危人群中,同时纳入GCS、BIS、PO₂等多维度监护指标,并在同一数据集内直接比较多种机器学习模型的预测性能,从而在现有文献基础上对重型颅脑损伤预后预测的模型选择和变量构成进行了进一步补充和完善。

本研究的局限性与展望:本研究的局限性:其一,研究样本来自单一医疗中心,且采用内部交叉验证评估性能,尚缺乏在独立人群上的外部验证;这意味着模型的运输性(transportability)与泛化能力仍需在不同医院、不同收治流程与检测体系下接受检验。其二,部分关键特征(如BIS、PO₂)可能受测量时点与干预状态影响,跨中心一致性需通过统一定义与数据字典进一步规范。后续笔者将开展多中心、前瞻性外部验证:以统一结局(随访6个月GOS)、一致的纳入/排除标准与数据采集流程,分别进行地理外部验证与时间外部验证;在评估指标上除区分度(AUC)外,同步报告校准度(校准斜率/截距、Brier分数、校准曲线)与临床净获益,必要时实施简单再校准(仅更新截距/斜率)或阈值重估以贴合不同中心的基线风险,从而提高模型在真实世界的可推广性。

总体而言,本研究的意义在于为重型颅脑损伤昏迷患者提供一种基于入院与监护数据的早期风险分层思路。在临床应用层面,该类模型可作为辅助工具:帮助医护人员在入院早期识别高风险个体、优化监护强度与资源配置、并在与家属沟通预后时提供更结构化的参考。同时,模型提示的关键特征更多反映“病情严重程度与治疗状态”,提示临床应重视神经功能评估与镇静/通气的动态监测,但不宜据此作出单一指标的因果推断。后续仍需通过多中心外部验证与前瞻性数据采集,进一步评估模型的泛化能力与实际临床净获益。

表4 国内外重型TBI患者预后预测模型研究概况及与本研究的对照

序号	第一作者 (年份,参考文献序号)	国家/ 地区	研究对象及 样本量	主要预测结局	模型/方法	主要结果概要	与本研究的异同
1	郑细良,等 ^[1] (2024)	中国, 北京	单中心TBI患者 1 652例,按早期 死亡分组	住院早期死亡	单/多因素LR	明确年龄、损伤程度、瞳孔改变 等为早期死亡的危险因素,AUC 约0.80	仅采用传统统计模型,研 究对象为一般TBI人群,未 比较不同机器学习算法
2	吉丁,等 ^[2] (2025)	中国, 多中心	老年重型颅脑损 伤患者,样本量 约百例	6个月功能预后	PNI联合 NIHSS,LR	PNI+NIHSS有助于老年重型颅 脑损伤患者的预后分层,强调营 养及神经功能状态的重要性	变量维度有限,未纳入监 护指标及多种算法比较
3	Wu Z, et al ^[6] (2023)	系统综 述/Meta	纳入14项成人 TBI研究	住院病死率	系统综述+ Meta,多种 ML模型	多种机器学习模型预测住院死 亡的合并AUC约0.90,整体区分 度优于传统模型	为方法学层面的汇总,未 针对重型昏迷患者给出具 体最佳算法
4	Courville E, et al ^[7] (2023)	系统综 述/Meta	多项成人TBI研究	死亡及不良功 能结局	系统综述+ Meta,比较 SVM、ANN、 RF等与LR	多数研究中机器学习模型在预 测死亡或不良功能结局方面优 于LR,准确度多在80%以上	文献间间接比较为主,未 在同一队列内直接比较多 种算法
5	Khalili H, et al ^[8] (2023)	伊朗, 单中心	TBI患者3 347例 中纳入1 653例	生存/死亡及 治疗结局	多种ML算法 (SVM、RF、 ANN等)	整合人口学、实验室及影像指标 后,多数模型AUC在0.80以上	与本研究类似为原始队列 ML研究,但对象为一般 TBI人群
6	Zheng R, et al ^[9] (2022)	中国, 多中心	急诊就诊TBI患者: 开发队列605例,外 部验证287例	出院时预后 (住院转归)	LASSO+多变 量LR	构建入院预警策略,经多中心外 部验证,C-index较高,决策曲线 显示良好临床净获益	为高质量TBI预后模型,但 仍以Logistic为主,未系统 比较多种机器学习算法
7	任瑞涛,等 ^[18] (2024)	中国	重型颅脑损伤行 去骨瓣减压患 者,样本量中等	术后早期颅内 血肿进展及不 良预后	多种CT评分 +LR	比较不同CT评分体系预测术后 颅内血肿进展和预后价值,影像 学综合评分优于单一指标	侧重术后影像学风险分 层,未涉及ICU监护指标和 机器学习算法
8	本研究	中国, 单中心	重型颅脑损伤所 致昏迷患者262 例,随访6个月	6个月GOS功 能预后好/差	7种机器学习 算法(LR、 SVM、MARS、 RF、KNN、 XGB、ANN), 10折交叉验证	ANN模型AUC达0.905,准确 度、灵敏度、特异度均最佳,GCS、 BIS、PO2为最重要预测因子	首次在国内系统比较多种 机器学习算法在重型颅脑 损伤昏迷患者预后预测中 的表现,仍缺乏外部验证

参 考 文 献

[1] 郑细良,张亮,方治军,等. 2017—2022年北京市大兴区人民
医院创伤性脑损伤流行病学特征及早期死亡的预测因素[J].
实用预防医学, 2024, 31(4): 471-475.

[2] 吉丁,崔益秋,管义祥. 基于预后营养指数联合NIHSS评分对
老年重型颅脑损伤患者预后分层[J]. 国际神经病学神经外科
学杂志, 2025, 52(1): 26-31.

[3] ZOU JF, FANG HL, ZHENG J, et al. The epidemiology of
traumatic brain injuries in the fastest-paced city in China: a
retrospective study[J]. Front Neurol, 2023, 14: 1255117.

[4] GREENER JG, KANDATHIL SM, MOFFAT L, et al. A guide to
machine learning for biologists[J]. Nat Rev Mol Cell Biol, 2022,
23(1): 40-55.

[5] SHARMA J. Review of machine learning algorithms and their
applications[J]. Int J Innov Sci Eng Manag, 2024, 3(2): 113-119.

[6] WU Z, LAI JQ, HUANG QM, et al. Machine learning-based
model for predicting inpatient mortality in adults with traumatic
brain injury: a systematic review and meta-analysis[J]. Front
Neurosci, 2023, 17: 1285904.

[7] COURVILLE E, KAZIM SF, VELLEK J, et al. Machine learning
algorithms for predicting outcomes of traumatic brain injury: a
systematic review and meta-analysis[J]. Surg Neurol Int, 2023,
14: 262.

[8] KHALILI H, RISMANI M, NEMATOLLAHI MA, et al.
Prognosis prediction in traumatic brain injury patients using
machine learning algorithms[J]. Sci Rep, 2023, 13(1): 960.

[9] ZHENG RZ, ZHUANG ZW, ZHAO CY, et al. Chinese
admission warning strategy for predicting the hospital discharge
outcome in patients with traumatic brain injury[J]. J Clin Med,
2022, 11(4): 974.

[10] 蒋鸿雁,杨凤,曹艳,等. 2004~2013年昆明医科大学第一附
属医院创伤性脑损伤流行病学特征调查[J]. 昆明医科大学学
报, 2022, 43(4): 12-18.

[11] KONYA A, NEMATZADEH P. Recent applications of AI to
environmental disciplines: a review[J]. Sci Total Environ, 2024,
906: 167705.

[12] SCHILLER J, STILLER S, RYO M. Artificial intelligence in
environmental and Earth system sciences: explainability and

- trustworthiness[J]. *Artif Intell Rev*, 2025, 58(10): 316.
- [13] ROMEIKO XX, ZHANG XS, PANG YL, et al. A review of machine learning applications in life cycle assessment studies[J]. *Sci Total Environ*, 2024, 912: 168969.
- [14] SRIVASTAVA S, WANG W, ZHOU W, et al. Machine learning-assisted surface-enhanced Raman spectroscopy detection for environmental applications: a review[J]. *Environ Sci Technol*, 2024, 58(47): 20830-20848.
- [15] HAMDAN A, IBEKWE KI, ETUKUDOH EA, et al. AI and machine learning in climate change research: a review of predictive models and environmental impact[J]. *World J Adv Res Rev*, 2024, 21(1): 1999-2008.
- [16] HERNÁNDEZ-ALPÍZAR L, GÓMEZ-MEJÍA JA, ARGÜELLO-VEGA MB. Artificial intelligence, machine learning and GIS in environmental engineering: current trends[J]. *Tecnol Marcha*, 2024, 37: 87-96.
- [17] CUI S, JIN J, ZHANG L, et al. Advances and applications of machine learning and deep learning in environmental science[J]. *Environ Pollut*, 2024, 329: 121947.
- [18] 任瑞涛, 许俊华. 颅脑外伤患者去骨瓣减压术后早期颅内血肿进展的影响因素[J]. *国际神经病学神经外科学杂志*, 2024, 51(1): 24-29.
- [19] PAPA L, MCKINLEY WI, VALADKA AB, et al. Diagnostic performance of GFAP, UCH-L1, and MAP-2 within 30 and 60 minutes of traumatic brain injury[J]. *JAMA Netw Open*, 2024, 7(9): e2431115.
- [20] KAYE C, RHODES J, AUSTIN P, et al. Assessment of depth of sedation using Bispectral Index™ monitoring in patients with severe traumatic brain injury in UK intensive care units[J]. *BJA Open*, 2024, 10: 100287.
- [21] BAREA-MENDOZA JA, CHICO-FERNÁNDEZ M, BALLESTEROS MA, et al. Resuscitation and initial management after moderate-to-severe traumatic brain injury: questions for the on-call shift[J]. *J Clin Med*, 2024, 13(23): 7325.

责任编辑:王荣兵