

急性缺血性脑卒中患者严重意识障碍风险预测模型分析：基于内在可解释性机器学习方法

高思齐¹, 刘曜嘉¹, 张 硕¹, 杨 树¹, 纪家琪¹, 刘俊杰^{1,2*}, 王建军²

¹ 华北理工大学临床医学院 河北唐山
² 华北理工大学附属医院重症医学科 河北唐山

【摘要】目的 本研究基于 MIMIC-IV 数据库, 旨在开发一种可解释的机器学习模型, 用于预测卒中患者发生严重意识障碍的风险。**方法** 本研究从 MIMIC-IV 数据库中, 根据 ICD-9 和 ICD-10 编码提取急性缺血性脑卒中患者。利用 LASSO 回归算法进行特征筛选。通过七种机器学习算法, 依据 AUC、准确率以及 F1 分数等指标进行评估和比较, 选出最优算法。按照 7:3 的比例划分为训练集和测试集, 在训练集中进行五折交叉验证。超参数优化采用网格搜索方法, 以提升算法性能。在测试集上评估最优算法的预测能力及其泛化性能。采用 SHAP 方法解释关键特征对严重意识障碍的影响。**结果** 本研究共从 MIMIC-IV 数据库中提取急性缺血性脑卒中患者 1998 例, 其中 471 例 (占 23.6%) 在入住 ICU 后 30 天内发生严重意识障碍。通过对多种机器学习算法在验证集上的评估与比较, 最终选定 XGBoost 算法作为最优算法。研究中将数据按 7:3 的比例划分为训练集和测试集, 并结合五折交叉验证与网格搜索优化超参数, 结果表明 XGBoost 算法在测试集上展现了良好的严重意识障碍风险预测性能和泛化能力 (AUC=0.788, 95%CI: 0.747~0.829; 准确率=76.7%)。SHAP 解释分析显示, ICU 住院时间、血糖变异性及早期有创氧疗是卒中患者严重意识障碍发生风险增加的主要危险因素。**结论** XGBoost 算法在预测急性缺血性脑卒中患者严重意识障碍风险方面展现出较强的潜力。此外, SHAP 解释分析突显了 ICU 住院时间、血糖变异性及氧气治疗对严重意识障碍风险的重要性。

【关键词】 急性缺血性脑卒中; 严重意识障碍; 机器学习; 可解释性; 风险预测模型

【基金项目】 本研究由唐山市科技计划项目 (21130224C)、河北省卫生健康委医学科学研究课题 (20221533) 和国家级大学生创新训练计划 (202410081019) 资助。

【收稿日期】 2025 年 1 月 22 日 **【出刊日期】** 2025 年 2 月 26 日 **【DOI】** 10.12208/j.ijmd.20250013

Analysis of risk prediction model for severe disturbance of consciousness in patients with acute ischemic stroke: a machine learning method based on intrinsic interpretability

Siqi Gao¹, Yaojia Liu¹, Shuo Zhang¹, Shu Yang¹, Jiaqi Ji¹, Junjie Liu^{1,2*}, Jianjun Wang²

¹Clinical Medical College, North China University of Technology, Tangshan, Hebei

²Department of Critical Care Medicine, Affiliated Hospital of North China University of Technology, Tangshan, Hebei

【Abstract】 Objective This study, based on the MIMIC-IV database, aims to develop an interpretable machine learning model for predicting the risk of severe consciousness disturbances in stroke patients. **Methods** Acute ischemic stroke patients were extracted from the MIMIC-IV database using ICD-9 and ICD-10 codes. LASSO regression was used for feature selection. Seven machine learning algorithms were evaluated and compared based on AUC, accuracy, and F1 score to select the optimal algorithm. The data were split into training and test sets in a 7:3 ratio, with five-fold cross-validation performed in the training set. Hyperparameter optimization was conducted using

*通讯作者: 刘俊杰

grid search to improve algorithm performance. The predictive ability and generalizability of the optimal algorithm were evaluated on the test set. SHAP (Shapley Additive Explanations) was applied to explain the impact of key features on the risk of severe consciousness disturbances. Results A total of 1,998 acute ischemic stroke patients were extracted from the MIMIC-IV database, of whom 471 (23.6%) developed severe consciousness disturbances within 30 days of ICU admission. After evaluating and comparing various machine learning algorithms on the validation set, the XGBoost algorithm was selected as the optimal model. The data were split into training and test sets in a 7:3 ratio, with five-fold cross-validation and grid search optimization for hyperparameters. The results showed that the XGBoost algorithm demonstrated good predictive performance and generalization ability for the risk of severe consciousness disturbances on the test set (AUC=0.788, 95% CI: 0.747–0.829; accuracy=76.7%). SHAP analysis revealed that ICU length of stay, blood glucose variability, and early invasive oxygen therapy were the main risk factors for the development of severe consciousness disturbances in stroke patients. **Conclusion** The XGBoost algorithm shows strong potential in predicting the risk of severe consciousness disturbances in acute ischemic stroke patients. Additionally, SHAP analysis highlights the significance of ICU length of stay, blood glucose variability, and oxygen therapy in increasing the risk of severe consciousness disturbances.

【Keywords】 Acute ischemic stroke; Severe disturbance of consciousness; Machine learning; Interpretability; Risk prediction model

引言

急性缺血性脑卒中 (AIS) 是全球范围内导致残疾和死亡的主要疾病之一^[1], 其并发症, 如严重意识障碍 (如昏迷、持续性植物状态等), 严重影响患者预后, 并显著增加医疗负担^[2,3]。研究表明, 约 20%-30% 的 AIS 患者在住院期间可能出现不同程度的意识障碍, 而这一情况与更高的死亡率、更长的住院时间及更差的神经功能恢复密切相关^[4]。因此, 早期识别高风险患者并实施针对性干预, 对于改善临床结局具有重要意义。

目前, 临床对 AIS 患者意识障碍的预测主要依赖经验性评估。然而, 这些方法往往依赖于主观判断, 且难以整合多维度的临床数据 (如实验室指标、生命体征趋势等), 从而限制了预测准确性。近年来, 机器学习 (ML) 技术在医学预测领域展现了显著优势, 能够从复杂数据中挖掘潜在模式, 并建立高精度的预测模型^[5,6]。然而, 大多数现有研究集中于死亡或功能预后的预测, 而针对 AIS 患者严重意识障碍的预测模型仍较为稀缺^[7-9]。此外, 现有模型的“黑箱”特性限制了其在临床实践中的可信度与应用价值, 因此, 开发可解释的机器学习模型至关重要。

基于此, 本研究将利用 MIMIC-IV 公开数据库, 结合多种机器学习算法的耦合与优选, 采用五折交叉验证和网格搜索进行超参数调优, 旨在实现对

ICU 内急性缺血性脑卒中患者严重意识障碍发生风险的精准预测。

1 资料和方法

1.1 数据来源

本研究的数据来源于公开的 MIMIC-IV 2.2 数据库。

1.2 研究人群

本研究基于 MIMIC-IV 公开数据库, 按照 ICD-9 和 ICD-10 编码提取急性缺血性脑卒中患者。纳入标准为: 诊断为急性缺血性脑卒中且首次入住重症监护病房 (ICU) 的患者。排除标准包括: (1) 未记录 GCS 评分; (2) 年龄 ≤ 60 岁; (3) ICU 住院时间 ≤ 24 小时; (4) 入住 ICU 后一周内血糖测量次数 < 3 次。

1.3 研究结局

本研究的主要结局是患者入住 ICU 后 30 天内是否发生严重意识障碍, 严重意识障碍通过格拉斯哥昏迷评分 (GCS) < 8 来量化。

1.4 变量提取

本研究从 MIMIC-IV 2.2 数据库中提取卒中患者的基本特征、实验室指标、合并症、疾病严重程度评分以及治疗措施。

1.5 统计分析

将卒中患者分为正常组和严重意识障碍组, 比较两组在基本特征、实验室检查、合并症、疾病严重

度评分及治疗措施等方面的差异。对于分类变量，采用频数 (n) 和百分比 (%) 表示，并通过卡方检验或 Fisher 精确检验进行组间比较；对于连续变量，若符合正态分布，则以均数±标准差表示，使用独立样本 t 检验；若不符合正态分布，则以中位数 (Q1, Q3) 表示，采用 Wilcoxon 秩和检验评估组间差异。在显著性水平 $\alpha=0.05$ 下，统计差异具有显著性。使用多种机器学习算法，结合五折五次交叉验证评估与比较模型性能，选择最佳预测算法。将数据集按 7:3 划分为训练集和测试集，在训练集上应用五折五次交叉验证进行模型训练，并通过网格搜索优化超参数以提升性能。最终，通过在测试集上的评估，检验所选最佳算法的预测能力和泛化性能。通过绘制 SHAP 特征重要性排序图和概要图，揭示关键特征对卒中患者预后的影响方向及其程度。

2 结果

2.1 基线资料分析

全面对比正常组 (n=1527, 76.4%) 与入住 ICU 后发生严重意识障碍组 (n=471, 23.6%) 之间的基线资料差异。本研究共纳入 1998 例急性缺血性卒中患者，整体年龄为 69.5 ± 15.9 岁，其中女性患者 1005 例，占 50.3%。与正常组相比，严重意识障碍组表现出显著的临床特征。该组患者的 ICU 死亡风险较高，ICU 住院时间明显延长。此外，严重意识障碍组的疾病危重程度明显更高。

2.2 特征选择

本研究采用 LASSO 回归算法，初步筛选出了严重意识障碍风险预测模型的 21 个关键特征。为了验证这 21 个因子之间是否具有较高的独立性，本研究采用方差膨胀因子 (VIF) 进行共线性诊断。结果表明，方差膨胀因子的最大值为 1.642，远小于 5，这表明筛选出的关键特征之间具有较高的独立性，未发现多重共线性问题，因此这些特征能够较为准确地反映分析结果。

2.3 模型构建与评估

最优算法选择：在本研究中，模型的输出为严重意识障碍评估结果 (即 GCS 评分是否小于 8 分)，输入特征为经过筛选的关键特征。对七种机器学习算法进行了性能比较。

为了全面评估不同算法的性能，采用五折五次交叉验证方法，并使用 ROCAUC、准确率和 F1 分数作为评估指标。结果 (见表 1) 显示，XGBoost 算法在验证集上表现出最佳的严重意识障碍风险预测能力。

最优算法评估：将数据集按 7:3 的比例划分为训练集和测试集，并在训练集上进行五折五次交叉验证。超参数调优采用网格搜索方法，以优化算法性能。在测试集上对最佳算法的严重意识障碍风险预测能力进行评估。结果显示，最优算法 XGBoost 在测试集上表现出了良好的严重意识障碍风险预测性能，具体表现为：ROCAUC=0.788 (95% CI: 0.747~0.829)，准确率=76.7%，F1 分数=0.521。

表 1 不同算法在验证集上的严重意识障碍风险预测性能比较

不同算法	ROCAUC (95%CI)	准确率 (95%CI)	F1 分数 (95%CI)	敏感性	特异性
XGBoost	0.798 (0.747-0.849)	0.759 (0.739-0.778)	0.566 (0.535-0.596)	0.669	0.786
LightGBM	0.686 (0.626-0.746)	0.755 (0.724-0.786)	0.515 (0.498-0.532)	0.554	0.817
DecisioTree	0.735 (0.682-0.788)	0.733 (0.697-0.769)	0.515 (0.479-0.550)	0.614	0.77
GBDT	0.712 (0.659-0.765)	0.751 (0.720-0.783)	0.514 (0.477-0.551)	0.574	0.806
GNB	0.788 (0.735-0.841)	0.72 (0.694-0.746)	0.554 (0.518-0.590)	0.737	0.715
SVM	0.792 (0.741-0.843)	0.715 (0.696-0.733)	0.553 (0.518-0.588)	0.751	0.703
KNN	0.669 (0.608-0.729)	0.639 (0.578-0.700)	0.442 (0.421-0.463)	0.603	0.65

2.4 SHAP 可解释分析

本研究采用 SHAP 方法对基于 XGBoost 算法的卒中患者严重意识障碍发生风险预测模型进行了解释分析，依次绘制了 SHAP 特征重要性排序图和概要图。根据 SHAP 特征重要性排序图 (图 1 (A) 所

示)，对严重意识障碍发生风险贡献排名前三的特征依次为：ICU 住院时间、血糖变异性和氧气治疗。根据 SHAP 概要图 (图 1 (B) 所示)，在贡献排名前列的特征中，ICU 住院时间和年龄这两个连续型变量的升高与卒中患者严重意识障碍风险呈近似正

相关。较高血糖变异性的卒中患者面临较高的严重意识障碍风险。

同时，氧气治疗可能与卒中患者严重意识障碍

风险的增加相关。值得注意的是，入ICU后的较高SpO₂水平可能与卒中患者较高的严重意识障碍风险相关。




图1 基于SHAP方法解读严重意识障碍风险预测模型的结果

3 结论

本研究基于MIMIC-IV数据库，开发了一个可解释的预测模型，用于评估重症急性缺血性脑卒中患者发生严重意识障碍的风险。研究表明，ICU住院时间、血糖变异性及早期有创氧疗是卒中患者发生严重意识障碍的主要风险因素。采用XGBoost算法进行预测，模型在测试集上表现出色，具有较强的泛化能力。SHAP解释分析进一步揭示了模型决策的关键因素，为临床医生提供了有价值的见解，有助于提高卒中患者的预后管理。然而，研究存在回顾性设计和样本来源单一等局限，未来需多中心数据验证以提升模型的广泛应用性。

参考文献

[1] 朱慧珊, 李国顺, 邹鹏娟, 等. 通圣方对急性大血管闭塞性脑梗死介入术后病人肺炎及意识障碍的影响[J]. 中西

医结合心脑血管病杂志, 2025, 23(04): 615-619.

[2] 么瑶, 柴诚诚, 冉禄森, 等. 体外培育牛黄治疗神经系统疾病的有效性和安全性的Meta分析[J]. 神经损伤与功能重建, 2024, 19(12): 683-688.

[3] 王圆曦, 兰雅智, 邓静娟, 等. 急性缺血性脑卒中患者机械取栓后住院期间发生下肢深静脉血栓的危险因素分析[J]. 血管与腔内血管外科杂志, 2024, 10(12): 1434-1437+1448.

[4] 王群, 刘斌, 李奇林, 等. 甘油三酯葡萄糖指数及全身炎症指数与急性缺血性脑卒中的相关性[J]. 中国急救医学, 2025, 45(03): 211-217.

[5] 张博晖, 禹天同, 赵帅, 等. 基于机器学习的冠状动脉慢性完全闭塞患者术后不良心血管事件预测模型的构建[J]. 心脏杂志, 2025(03): 264-270+281.

[6] 黄润棋, 强光亮, 刘益飞, 等. 基于SHOX2和RASSF1A

- 甲基化水平的机器学习算法预测早期肺腺癌病理类型[J]. 中国胸心血管外科临床杂志, 2025, 32(01): 67-72.
- [7] Ni P, Zhang S, Zhang G, et al. Development and validation of machine learning-based prediction model for outcome of cardiac arrest in intensive care units[J]. Scientific Reports, 2025, 15(1): 8691.
- [8] Luo X, Li B, Zhu R, et al. Development and validation of an interpretable machine learning model for predicting in-hospital mortality for ischemic stroke patients in ICU[J]. International Journal of Medical Informatics, 2025, 198: 105874.
- [9] Wei Z, Liu S, Chen Y, et al. Machine Learning Model-Based Prediction of In-Hospital Acute Kidney Injury Risk in Acute Aortic Dissection Patients[J]. Reviews in Cardiovascular Medicine, 2025, 26(2): 25768.

版权声明：©2025 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>



OPEN ACCESS