



电子、语音版

·论著·

基于可解释机器学习的卒中患者康复相关出院 预测模型研究

王平¹, 刘爱贤¹, 王丹²

1. 首都医科大学附属北京康复医院神经康复中心, 北京 100144

2. 首都医科大学附属北京康复医院中医康复中心, 北京 100144

摘要:目的 基于可解释机器学习(XML)方法构建卒中患者康复相关出院预测模型, 识别影响康复出院的关键因素, 为康复评估与医疗资源配置提供数据支持。方法 该研究利用MIMIC-IV v3.1数据库, 依据ICD-9/10编码筛选卒中患者共14 824例。提取患者人口学信息、入院特征及住院过程等结构化变量, 构建康复相关出院预测模型。采用Logistic回归与极端梯度提升算法(XGBoost)进行建模, 比较判别效能、校准性能及临床净获益。使用SHapley Additive exPlanations(SHAP)算法评估各特征对预测结果的贡献, 并通过部分依赖于个体条件期望曲线进行可解释性分析。结果 在总体样本中, 康复相关出院率为36.9%。Logistic与XGBoost模型的曲线下面积(AUC)分别为0.637(95%CI: 0.620~0.653)和0.630(95%CI: 0.613~0.647), 判别效能处于中等水平。两种模型的平均精确率均为0.473, Brier分数分别为0.220和0.223, 均表现出较好的校准度。决策曲线分析显示, Logistic模型在30%~40%阈值范围内的净获益最高($P<0.05$)。SHAP结果显示, 年龄(平均SHAP=0.280)、医保类型(平均SHAP=0.266)及入院途径(平均SHAP=0.237)为主要影响因素。部分依赖分析显示, 40岁前后康复相关出院概率最高, 随后随年龄增加而下降($P<0.001$); 急诊入院及转院患者康复相关出院概率高于门诊及自我入院者($P<0.001$); 卒中类型间差异无统计学意义($P=0.236$)。模型在2008年至2019年AUC值稳定维持在0.60~0.70, 提示其稳健性良好。高预测风险组患者康复出院率显著高于低预测风险组($P<0.001$), 且预测概率与住院时间呈弱负相关。结论 基于XML结合SHAP方法构建卒中康复相关出院预测模型, 结果显示年龄、医保类型及入院途径是影响康复出院的主要特征变量。模型在真实世界数据中具有良好的校准性与稳定性, 为卒中患者康复早期识别与资源优化配置提供了可行的量化工具。

关键词: 卒中; 康复出院; 机器学习; 极端梯度提升算法; Logistic回归; 可解释机器学习

中图分类号: R743.3

DOI: 10.16636/j.cnki.jinn.1673-2642.2026.01.003

Construction of an explainable machine learning - based model for predicting rehabilitation-related discharge in stroke patients

WANG Ping¹, LIU Aixian¹, WANG Dan²

1. Department of Neurological Rehabilitation, Beijing Rehabilitation Hospital, Capital Medical University, Beijing 100144, China

2. Department of Traditional Chinese Medicine Rehabilitation, Beijing Rehabilitation Hospital, Capital Medical University, Beijing 100144, China

Corresponding author: LIU Aixian, Email: lax@163.com

Abstract: **Objective** To construct an explainable machine learning (XML)-based model for predicting rehabilitation-related discharge in stroke patients, to identify the key influencing factors for rehabilitation-related discharge, and to

基金项目: 首都卫生发展科研专项项目(2022-3-2254)。

收稿日期: 2025-09-13; 修回日期: 2025-12-04

作者简介: 王平(1988—), 女, 硕士, 主治医师, 主要从事神经康复的相关研究。

通信作者: 刘爱贤(1969—), 男, 硕士, 主任医师, 主要从事神经康复的相关研究。Email: lax@163.com。

provide data support for rehabilitation assessment and healthcare resource allocation. **Methods** Data were extracted from the MIMIC-IV v3.1 database, and a total of 14 824 stroke patients were identified based on the ICD-9/10 codes. Structured variables including demographic data, admission features, and hospitalization data were extracted to construct predictive models for rehabilitation-related discharge. Logistic regression and extreme gradient boosting (XGBoost) algorithms were used to construct models, and these models were compared in terms of discriminatory ability, calibration performance, and net clinical benefit. The SHapley Additive exPlanations (SHAP) algorithm was used to evaluate the contribution of each feature to the results of prediction, and partial dependence and individual conditional expectation plots were used for interpretability analysis. **Results** In the overall samples, the rate of rehabilitation-related discharge was 36.9%. The logistic and XGBoost models had an area under the curve of 0.637 (95%CI: 0.620–0.653) and 0.630 (95%CI: 0.613–0.647), respectively, indicating a level of moderate discriminatory performance. Both models achieved an average precision of 0.473, with a Brier score of 0.220 and 0.223, respectively, suggesting that both models had good calibration. The decision curve analysis showed that the logistic model provided the greatest net benefit within the threshold range of 30%–40% ($P<0.05$). The SHAP analysis showed that age (mean SHAP=0.280), insurance type (mean SHAP=0.266), and admission route (mean SHAP=0.237) were the main influencing factors. The partial dependence analysis showed the highest probability of rehabilitation-related discharge around the age of 40 years, which then decreased with the increase in age ($P<0.001$); the patients admitted through emergency or transfer had a significantly higher probability of rehabilitation-related discharge than those admitted through outpatient service or self-admissions ($P<0.001$); there was no significant difference between the patients with different subtypes of stroke ($P=0.236$). The AUC of the model remained stable (0.60–0.70) across 2008–2019, suggesting that the model had good robustness. The high predicted risk group had a significantly higher rate of rehabilitation-related discharge than the low predicted risk group ($P<0.001$), and the predicted probability was weakly negatively correlated with the length of hospital stay. **Conclusions** The predictive model for rehabilitation-related discharge in stroke patients is constructed based on XML and SHAP, and the results show that age, insurance type, and admission route are the main characteristic variables affecting rehabilitation-related discharge. The model shows favorable calibration and robustness in real-world data, providing a feasible quantitative tool for early identification of rehabilitation in stroke patients and optimization of resource allocation.

Keywords: stroke; rehabilitation discharge; machine learning; extreme gradient boosting; Logistic regression; explainable machine learning

卒中是全球致残和死亡的主要原因之一,具有高发病率和高致残率等特征^[1]。随着卒中救治体系的完善,患者急性期病死率明显下降,但康复管理问题逐渐突出。康复相关出院是反映卒中后功能恢复与转归质量的重要指标,直接影响后续康复干预和再入院风险^[2-3]。然而,卒中患者康复结局差异显著,受年龄、卒中类型、病情严重程度及社会保障等多因素影响^[4]。因此,构建科学的康复相关出院预测模型,对精准识别高风险患者和优化康复资源配置具有重要临床意义。传统预测研究多采用 Logistic 回归或 Cox 比例风险模型,虽具有良好可解释性,但在处理高维特征和复杂非线性关系时能力有限^[5]。近年来,机器学习(machine learning, ML)在医学预测中得到广泛应用,能捕捉复杂变量关系并提升模型性能^[6]。其中,极端梯度提升算法(extreme gradient boosting, XGBoost)因其高效特征筛选与正则化机制,在疾病风险

评估中表现突出^[7]。但多数 ML 模型存在“黑箱”问题,限制了其临床可用性。可解释机器学习(explainable machine learning, XML)通过 SHapley Additive exPlanations(SHAP)算法量化特征贡献,实现性能与可解释性的平衡^[8]。目前,国内外关于卒中康复出院的研究多聚焦于疗效与干预,而系统性的预测模型研究仍较少^[9]。尤其在真实世界数据库中,尚缺乏结合 XML 的康复出院预测研究。本研究基于多参数重症监护数据库第四版(Medical Information Mart for Intensive Care IV, MIMIC-IV v3.1),整合人口学、入院与住院特征,采用 Logistic 回归与 XGBoost 模型建立康复相关出院预测模型,并通过 SHAP 算法进行解释分析,以揭示影响卒中患者康复出院的关键因素,为康复评估与资源分配提供数据依据与方法学参考。

1 资料与方法

1.1 数据来源与研究对象

本研究基于美国麻省理工学院公开的MIMIC-IV v3.1^[10],该数据库收录2008年至2019年美国贝斯以色列女执事医疗中心住院患者的结构化临床信息。利用数据库提供的住院记录表、诊断编码表及出院信息表,提取所有以卒中为主要诊断的病例。通过国际疾病分类第九版及第十版(International Classification of Diseases, Ninth/Tenth Revision, ICD-9/10)^[11]相关编码筛选卒中患者。

入组标准:①住院诊断明确为缺血性卒中或出血性卒中;②具有完整入院及出院记录。

排除标准:①非卒中诊断患者;②关键信息缺失或变量不完整者。

最终纳入14 824例卒中患者,形成完整分析队列。

1.2 结局变量定义

本研究的预测目标为康复相关出院,定义为患者出院去向中包括康复机构、康复病房或专业护理机构的出院事件。将康复相关出院赋值为1,非康复相关出院(包括常规出院、死亡、转院及自愿离院等)赋值为0,形成二分类结局变量,用于后续建模分析。

1.3 变量提取与预处理

依据既往文献及临床可解释性选取潜在预测特征,包括人口学特征(年龄、性别、婚姻状况、医保类型)、入院相关特征(入院途径、入院来源、卒中类型)及住院特征(住院时间、出院去向等)。连续变量经正态性检验后以均值或中位数表示,分类变量以比例表示。为保证模型稳健性,对所有候选特征进行分布均衡性与缺失机制分析,采用Cramér's V系数评估分类变量间相关性,剔除高共线特征。部分轻度缺失变量经多重插补处理。变量类型经一致化编码后输入建模。

1.4 模型构建

采用Logistic回归与极端梯度提升算法XGBoost建立康复相关出院预测模型。Logistic模型作为基线参照,用于评估传统回归方法的解释力。XGBoost模型通过五折交叉验证调优主要超参数(树深度、学习率、子采样率及最小分裂增益),以提升预测性能与防止过拟合。两种模型均以70%样本为训练集,30%样本为验证集进行内部验证。

1.5 模型评估

模型判别性能通过受试者操作特征(receiver operating characteristic, ROC)曲线及曲线下面积(area under the curve, AUC)评估,同时计算平均精确率以衡量在不同阈值下的分类表现。校准性能通过校准曲线及Brier分数评价。临床决策效能采用决策曲线分析比较不同模型在各阈值概率下的净获益。

1.6 模型解释与可视化

为提高模型透明性与临床可解释性,基于XGBoost模型计算SHAP值以量化各特征对预测结果的平均贡献,并绘制特征重要性排序图。进一步采用部分依赖图与个体条件期望图分析主要变量与预测概率之间的非线性关系,验证模型解释结果的一致性与稳定性。

1.7 稳健性与外推分析

通过风险分层校准、时间分层AUC变化及多维流向可视化评估模型在不同亚组和时间段内的稳定性。对预测概率分层后分析康复启动延迟与出院路径之间的关系,并绘制logit(预测康复相关出院概率)与log(住院时间+1)的二维密度分布,以探讨模型预测与实际住院过程的关联。

1.8 统计学方法

所有数据分析在R软件(version 4.4.3)和Python(version 3.11)环境下完成。主要采用的R包包括:data.table、dplyr、ggplot2、ggpubr、ggridges、DescTools、igraph、ggraph、pROC、yardstick、rmda、shapviz、iml、ggalluvial等。连续变量比较采用独立样本t检验或Mann-Whitney U检验,分类变量比较采用 χ^2 检验。所有检验均为双侧检验, $P<0.05$ 为差异具有统计学意义。

2 结果

2.1 队列构建与结局分布

本研究基于MIMIC-IV v3.1数据库,共纳入546 028例住院记录。经ICD-9/10编码筛选获得14 824例卒中患者,排除531 204例非卒中病例。将其与核心变量集进行匹配后,样本均未见缺失,且关键特征字段完整,最终14 824例患者均纳入分析。

结局分布如图1所示,其中康复相关出院5 470例(36.9%),非康复相关出院9 354例(63.1%)。

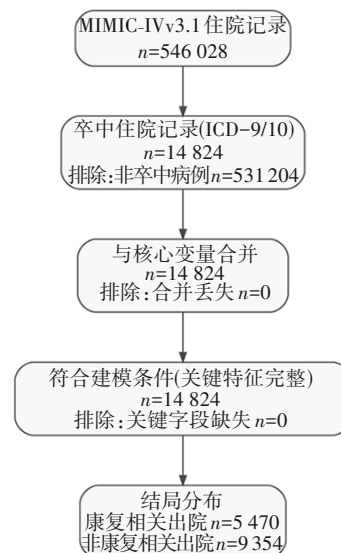



图1 研究对象筛选流程

2.2 康复相关出院的分层分布

康复相关出院比例在不同人群特征中存在显著差异。性别分层结果显示,女性患者的康复相关出院比例高于男性,差异具有统计学意义($P<0.001$,图2A)。年龄分层结果显示,18~49岁患者的康复相关出院比例最低,

而 ≥ 75 岁患者比例最高,呈随年龄增长而升高的趋势($P<0.001$,图2B)。在卒中类型分层中,缺血性卒中与出血性卒中患者的康复相关出院比例差异无统计学意义($P=0.236$,图2C)。



A: 不同性别患者的康复相关出院比例; B: 不同年龄分层的康复相关出院比例; C: 不同卒中类型患者的康复相关出院比例

图2 不同人群特征下康复相关出院比例的分布

2.3 住院特征与康复相关出院的关联

康复相关出院组的住院时间显著短于非康复相关出院组,差异具有统计学意义($P<0.001$)。该结果提示,康复相关出院患者在院内治疗及评估过程中具有更高的出院效率,可能反映其病情稳定性较好或康复转归路径更为清晰。见图3。

缺失模式分析结果表明,除个别社会人口学变量(如婚姻状况、医保类型及出院去向)外,其余变量的缺失比例较低;缺失与非缺失样本在年龄及住院时间分布上基本一致,未见系统性差异(图6)。

综上,本研究数据整体完整性良好,可满足后续建模分析要求。

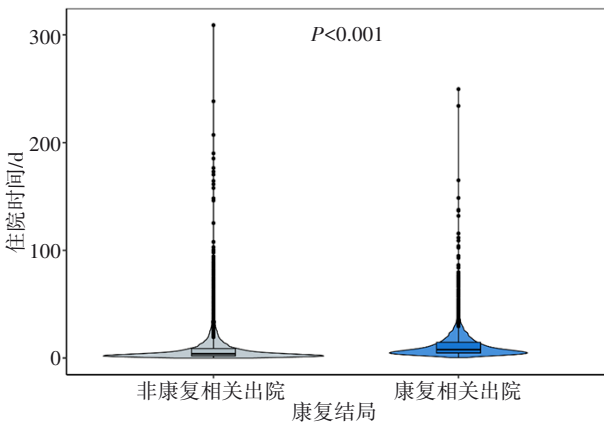


图3 不同康复结局患者的住院天数分布

2.4 变量分布与缺失模式分析

各变量类别分布相对均衡。其中,社会性别与生物性别变量类别占比均为0.511,卒中类型类别占比为0.531;基础出院信息相关变量有效比例为0.369。整体提示样本结构平衡,未见明显分布偏倚(图4)。




图4 各变量类别的比例分布

分类变量间相关性分析显示,社会性别与生物性别之间的Cramér's V值最高,相关性最强;婚姻状况与社会性别亦存在一定相关性;入院类型与入院来源间呈中度关联(图5)。

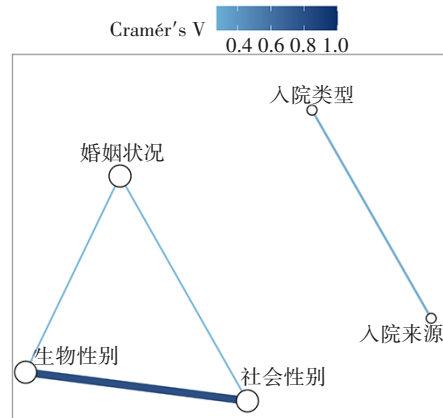


图5 分类变量间的Cramér's V相关网络




图6 不同变量在缺失与非缺失样本中的分布比较

2.5 模型构建与性能评估

Logistic模型与XGBoost模型在区分康复相关出院与非康复相关出院方面均具有中等判别效能。Logistic模型AUC为0.637(95%CI:0.620~0.653),XGBoost模型AUC为0.630(95%CI:0.613~0.647),两者平均精确率均为0.473,提示模型整体判别性能相近(图7)。




图7 Logistic模型与XGBoost模型的ROC曲线与精确率-召回率曲线

校准分析显示,两种模型的预测概率与实际观测概率拟合良好,Logistic模型Brier分数为0.220,XGBoost模型Brier分数为0.223,差异较小,均表现出较好的总体校准度(图8)。

在多数阈值范围内,Logistic模型的净获益略高于XGBoost模型,尤其在30%~40%的决策概率区间表现最佳,提示其在临床决策应用中具有更高的实用价值(图9)。

2.6 模型解释与关键特征分析

年龄(平均SHAP=0.280)为康复相关出院预测中贡献最大的特征,其次为Medicare医保(0.266)和急诊留观

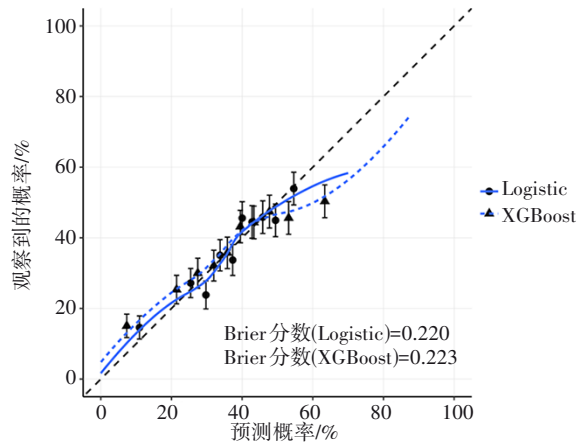


图8 Logistic模型与XGBoost模型的校准曲线

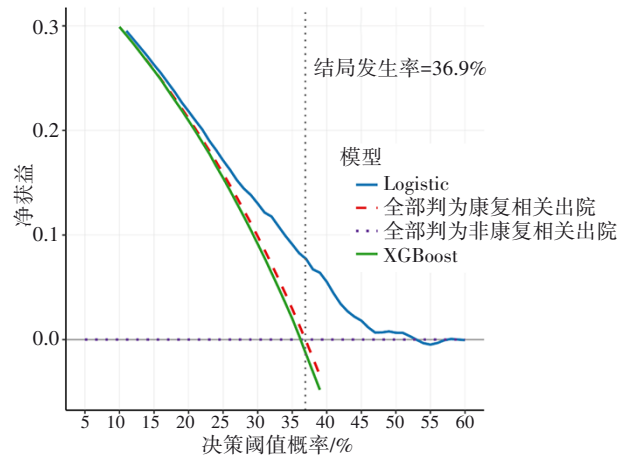


图9 Logistic模型与XGBoost模型的决策曲线分析

(0.237),提示社会保障类型与入院途径对结局具有重要影响。私人保险、Medicaid医保、医院间转诊、婚姻状况及卒中类型等变量亦有一定贡献(图10)。

年龄与康复相关出院概率呈非线性关系,40岁前后概率最高,随后随着年龄增加而下降(图11A);出血性卒中患者康复相关出院概率略低于缺血性卒中(图11B);急诊入院及转诊患者的康复相关出院概率相对较高(图11C)。





图10 变量重要性排序的SHAP值分析



A: 年龄; B: 卒中类型; C: 入院来源
图 11 主要特征的部分依赖关系

总体趋势与部分依赖曲线一致,表明模型解释结果在个体层面具有稳定性(图 12)。




图 12 年龄对康复相关出院概率的个体条件期望分析

2.7 模型内部验证与稳健性分析

基于入院途径、卒中类型与出院结局的多维流向可视化显示,急诊入院及医院转入患者更易出现康复相关

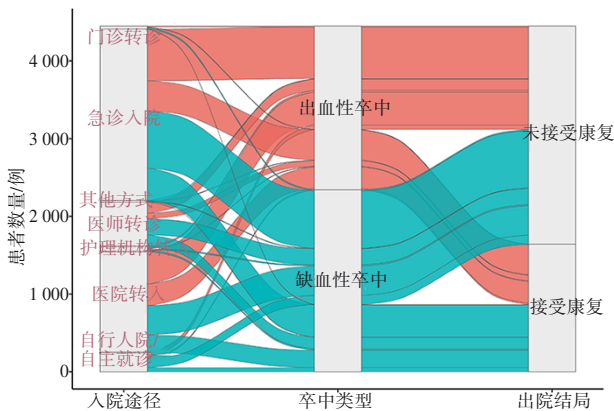


图 13 入院途径、卒中类型与出院结局的多维流向分布

出院,而门诊及自我入院者多集中于未接受康复组,不同卒中类型间存在明显流动差异(图 13)。

模型分层校准分析结果显示,Logistic 模型在各风险十分位内的预测概率与观测概率整体一致,校准表现优于 XGBoost 模型(图 14)。

时间分层验证显示,两种模型在 2008 年至 2019 年的 AUC 值均稳定维持在 0.60~0.70,无明显年度波动,提示模型判别性能具有良好稳健性(图 15)。

2.8 模型外推与康复延迟关联分析

基于预测风险分层的康复启动延迟分析显示,不同风险组间的康复相关出院概率在各时间段内保持相对稳定,提示模型具有良好的时效泛化能力(图 16)。其中,高预测概率组的康复相关出院率始终高于中、低预测概率组,且延迟时间延长并未显著削弱预测效能。

二维密度分布进一步显示,logit(预测康复相关出院概率)与住院时间 log(LOS+1)之间呈弱负相关,即预测概率较高的患者总体住院时间较短(图 17)。

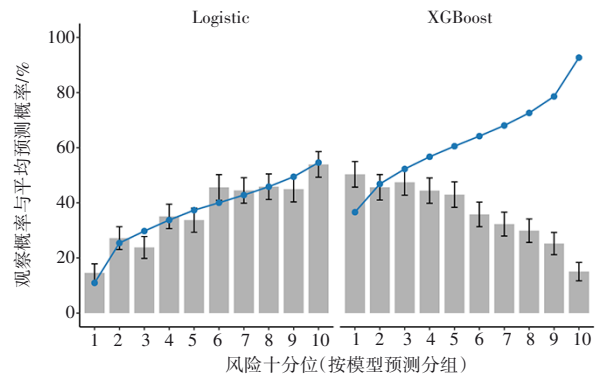


图 14 模型按风险十分位分组的校准验证

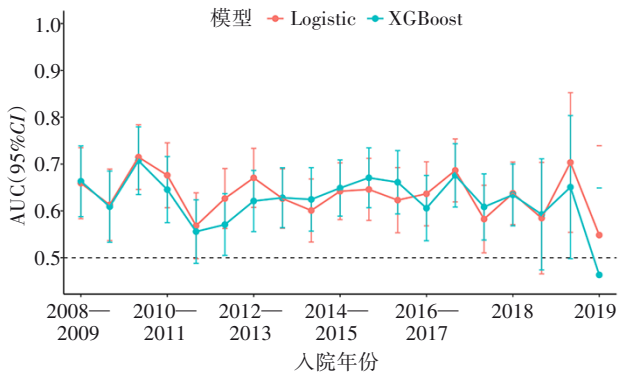


图15 模型在不同入院年份的AUC时间序列变化




图16 不同风险层级下康复启动延迟与预测概率的关系

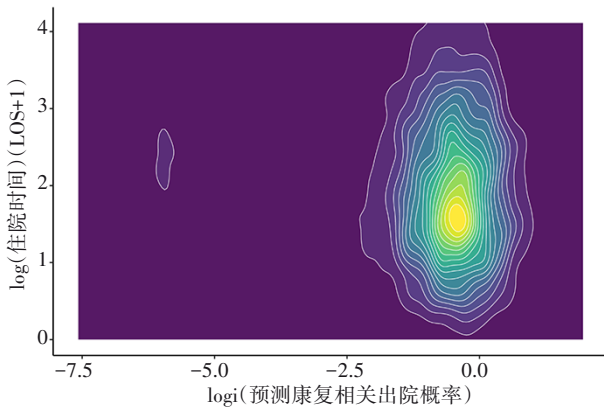


图17 预测康复相关出院概率与住院时间的二维密度分布

3 讨论

本研究基于MIMIC-IV v3.1数据库构建了卒中患者康复相关出院预测模型,比较了Logistic回归与XGBoost两种算法,并结合SHAP方法进行模型解释。结果显示,两种模型AUC分别为0.637和0.630,虽属中等判别水平,但校准性能与稳健性良好,Logistic模型在临床决策获益上略优。说明在真实世界数据下,基于常规临床与社会经济变量的模型亦能实现可应用的康复出院预测。

与既往基于影像学或神经评分的研究相比,本研究AUC略低于0.75~0.85的多模态模型^[12-13],但具备更高可推广性与简洁性。模型仅依托电子病历可提取的结构化特征,避免了依赖人工量表和影像数据的复杂性,更贴合实际临床场景的资源条件。该策略实现了“性能-可解释性-可部署性”的平衡,具有较强的现实意义。

特征贡献分析表明,年龄是影响康复出院的首要因素,与既往研究相符^[14]。卒中后神经可塑性随年龄增长而下降,康复依从性和生理储备不足而导致转归率降低^[15]。本研究发现,40岁前后康复出院概率最高,随后下降,但≥75岁人群略有回升,提示医保覆盖与早期转诊可能在老年群体中发挥补偿作用。

医保类型在模型中贡献突出,Medicare与私人保险

显著提高康复相关出院概率,无保险或Medicaid患者比例较低。有研究表明,医保覆盖水平直接影响康复服务利用率与出院转介率^[16-18]。这一社会经济因素的显著作用提示,康复预测模型需同时纳入结构性社会变量,以更符合临床真实环境。

入院途径同样影响结局。急诊与转院患者的康复相关出院率较高,反映急性入院流程中康复评估更规范;门诊或自我入院者则可能因经济与信息限制接受康复不足。该现象揭示了康复资源可及性的不均衡,也提示在模型解释时应考虑制度性差异。

卒中类型虽非主要特征,但缺血性卒中患者的康复相关出院率略高,趋势与既往研究^[19-20]一致。然而,差异不显著,表明真实世界中的康复决策受非病理性因素干扰更大,如社会支持与机构容量等。

此外,康复相关出院组住院时间明显短于对照组,logit(预测概率)与log(LOS+1)呈弱负相关,提示模型预测与临床康复过程一致。既往研究认为,较短住院期常与病情稳定及出院评估效率提高相关^[21]。

Logistic模型在分层校准与决策曲线中表现更优,尤其在30%~40%阈值范围内净获益最高,显示其在中等风险人群中具有较佳应用价值。

两种模型在2008年至2019年的AUC稳定,无明显时间漂移,说明模型具有良好的时效泛化性^[22]。

本研究的局限性主要包括以下几点:首先,本研究基于MIMIC-IV数据库的单中心数据构建模型,患者群体以重症病例为主,可能存在一定的选择偏倚,尚需在多中心及不同病种结构人群中进行外部验证,以提升模型的泛化能力。其次,本研究仅采用了Logistic回归与XGBoost两种常见算法,虽然两者在稳健性与可解释性上表现良好,但未涵盖更多深度学习模型或集成算法,未来可在此基础上扩展模型类型,以进一步比较性能差异。再次,本研究变量主要来源于结构化临床信息,未纳入血清学指标、功能评分或康复干预数据,可能低估部分生理与行为

因素的影响,亦限制了模型AUC及AUPRC的进一步提升。最后,本研究为方法学研究,尚未将模型开发为可供临床医生直接使用的预测工具,后续工作将结合前端界面与交互模块,推动其在临床信息系统中的集成与落地应用,从而实现康复出院风险的早期识别与动态决策支持。

综上,本研究以XML结合SHAP构建卒中康复相关出院预测模型,明确了年龄、医保类型及入院途径等关键变量的解释性作用。结果验证了在真实世界数据中构建简洁、透明的康复预测模型的可行性,为卒中康复早期评估与资源配置提供了量化依据。

参 考 文 献

- [1] 张伶俐,刘继红,韩春节,等. 电脑康复治疗仪联合超早期强化运动康复治疗脑卒中的疗效[J]. 国际神经病学神经外科学杂志, 2023, 50(4): 34-39.
- [2] CAMPAGNINI S, ARIENTI C, PATRINI M, et al. Machine learning methods for functional recovery prediction and prognosis in post-stroke rehabilitation: a systematic review[J]. J Neuroeng Rehabil, 2022, 19(1): 54.
- [3] ROBERTS P, ARONOW H, OUELLETTE D, et al. Bounce-back: predicting acute readmission from inpatient rehabilitation for patients with stroke[J]. Am J Phys Med Rehabil, 2022, 101(7): 634-643.
- [4] HARRIS WALKER G, GONZALEZ-GUARDA R, YANG Q, et al. Socio-ecological perspective on factors influencing acute recovery of younger stroke survivors: a mixed methods study[J]. J Adv Nurs, 2021, 77(6): 2860-2874.
- [5] CIOCI AC, CIOCI AL, MANTERO AMA, et al. Advanced statistics: multiple logistic regression, cox proportional hazards, and propensity scores[J]. Surg Infect (Larchmt), 2021, 22(6): 604-610.
- [6] PETTIT RW, FULLEM R, CHENG C, et al. Artificial intelligence, machine learning, and deep learning for clinical outcome prediction[J]. Emerg Top Life Sci, 2021, 5(6): 729-745.
- [7] TUAMA MH. A comparative evaluation of random forest and XGBoost models for disease detection using medical indicators[J]. Int J Prof Stud, 2025, 19(19): 11-18.
- [8] MIAO KX, HOUSSOU HOUNYE A, SU LY, et al. Exploring explainable machine learning and Shapley additive exPlanations (SHAP) technique to uncover key factors of HNSC cancer: an analysis of the best practices[J]. Biomed Signal Process Control, 2024, 89: 105752.
- [9] WANG K, SHI QQ, SUN C, et al. A machine learning model for visualization and dynamic clinical prediction of stroke recurrence in acute ischemic stroke patients: a real - world retrospective study[J]. Front Neurosci, 2023, 17: 1130831.
- [10] ZHOU ZH, HE YX, WANG QQ, et al. Impact of laboratory-derived frailty index on clinical outcomes in critical care patients with COPD: a retrospective analysis using the MIMIC-IV database[J]. Int J Chron Obstruct Pulmon Dis, 2025, 20: 1335-1346.
- [11] LEMUS HN, GOLDSTEIN J, TAI HH, et al. Development and validation of international classification of diseases, 9th and 10th revision, clinical modification - based algorithms to identify adult epilepsy in electronic health records[J]. Epilepsia, 2025, 66(9): 3334-3343.
- [12] WHITE A, SARANTI M, D'AVILA GARCEZ A, et al. Predicting recovery following stroke: deep learning, multimodal data and feature selection using explainable AI[J]. Neuroimage Clin, 2024, 43: 103638.
- [13] LIU YK, YU YN, OUYANG JH, et al. Functional outcome prediction in acute ischemic stroke using a fused imaging and clinical deep learning model[J]. Stroke, 2023, 54(9): 2316-2327.
- [14] SCHRAGE T, THOMALLA G, HÄRTER M, et al. Predictors of discharge destination after stroke[J]. Neurorehabil Neural Repair, 2023, 37(5): 307-315.
- [15] NORMAN SL, WOLPAW JR, REINKENSMEYER DJ. Targeting neuroplasticity to improve motor recovery after stroke: an artificial neural network model[J]. Brain Commun, 2022, 4(6): feac264.
- [16] YEH HJ, CHEN TA, CHENG HC, et al. Long - term rehabilitation utilization pattern among stroke patients under the national health insurance program[J]. Am J Phys Med Rehabil, 2022, 101(2): 129-134.
- [17] IFEJIKI NL, AWOSIKA OO, BLACK T, et al. Improving access to stroke rehabilitation and recovery: a policy statement from the American Heart Association/American Stroke Association[J]. Stroke, 2025, 56(9): e218-e233.
- [18] FREBURGER JK, MORMER ER, RESSEL K, et al. Disparities in access to, use of, and quality of rehabilitation after stroke in the United States: a scoping review[J]. Arch Phys Med Rehabil, 2025, 106(5): 759-770.
- [19] OOSTERVEER DM, WERMER MJH, VOLKER G, et al. Are there differences in long - term functioning and recovery between hemorrhagic and ischemic stroke patients receiving rehabilitation? [J]. J Stroke Cerebrovasc Dis, 2022, 31(3): 106294.
- [20] CHEN YC, CHEN TL, CHENG CC, et al. High-intensity post-stroke rehabilitation is associated with lower risk of pressure ulcer development in patients with stroke: real-world evidence from a nationwide, population-based cohort study[J]. Medicina (Kaunas), 2022, 58(3): 402.
- [21] GÖRGÜLÜ B, DONG J, HUNTER K, et al. Association between delayed discharge from acute care and rehabilitation outcomes and length of stay: a retrospective cohort study[J]. Arch Phys Med Rehabil, 2023, 104(1): 43-51.
- [22] ABEDI V, MISRAD, CHAUDHARY D, et al. Machine learning-based prediction of stroke in emergency departments[J]. Ther Adv Neurol Disord, 2024, 17: 17562864241239108.

责任编辑:龚学民