

基于Transformer算法构建的缺血性脑卒中早期预测模型

张紫欣, 杨晓光, 李若然, 谢昊杰, 李桂玲*

齐齐哈尔医学院护理学院, 黑龙江 齐齐哈尔

收稿日期: 2026年7月1日; 录用日期: 2026年7月23日; 发布日期: 2026年8月4日

摘要

目的: 采用Transformer等7种机器学习算法构建缺血性脑卒中风险预测模型, 筛选最优模型并进行可解释性分析, 助力早期识别高风险人群。方法: 采用Kaggle公开脑卒中数据集, 纳入5110例患者, 其中病发组249例、非病发组4860例。经填补缺失值、SMOTE平衡样本后, 分别采用BP、RF、XGBoost、SVM、DNN、MLP、Transformer算法构建预测模型。通过五折交叉验证进行内部验证, 以AUC、准确率、召回率、特异度、Brier分数评价模型性能, 并采用SHAP算法对最优模型进行可视化解释。结果: Transformer模型的AUC为0.912、准确率0.771、召回率0.847、特异度0.766、Brier分数0.091, 综合性能优于其他6种模型。SHAP分析显示, 年龄、工作类型、BMI、心脏病是影响模型预测贡献度最高的特征。结论: 基于Transformer算法构建的缺血性脑卒中早期预测模型具有较好的预测效能, 结合SHAP可解释性分析可辅助临床识别高危因素, 为Transformer算法在卒中流行病学分析中的适用性提供了初步依据。

关键词

缺血性脑卒中, 机器学习, 深度学习, 预测模型

An Early Prediction Model for Ischemic Stroke Based on the Transformer Algorithm

Zixin Zhang, Xiaoguang Yang, Ruoran Li, Haojie Xie, Guiling Li*

School of Nursing, Qiqihar Medical University, Qiqihar Heilongjiang

Received: July 1, 2026; accepted: July 23, 2026; published: August 4, 2026

Abstract

Objective: This study aimed to develop and compare seven machine learning algorithms, including

*通讯作者。

文章引用: 张紫欣, 杨晓光, 李若然, 谢昊杰, 李桂玲. 基于 Transformer 算法构建的缺血性脑卒中早期预测模型[J]. 临床医学进展, 2026, 16(8): 221-232. DOI: 10.12677/acm.2026.1682788

Transformer, to build risk prediction models for ischemic stroke, identify the best-performing model, and perform interpretability analysis to support early detection of high-risk individuals. Methods: A publicly available Kaggle stroke dataset was used, comprising 5110 patients (249 with stroke, 4860 without). Missing values were imputed using random forests, and the dataset was balanced with SMOTE. Prediction models were built using BP, RF, XGBoost, SVM, DNN, MLP, and Transformer algorithms. Internal validation was conducted via five-fold cross-validation. Model performance was evaluated using AUC, accuracy, recall, specificity, and Brier score. SHAP was applied to interpret the best model visually. **Results:** The Transformer model achieved an AUC of 0.912, accuracy of 0.771, recall of 0.847, specificity of 0.766, and Brier score of 0.091, outperforming the other six models. SHAP analysis revealed that age, work type, BMI, and heart disease were the most influential features. **Conclusion:** The Transformer-based early prediction model for ischemic stroke shows strong predictive performance. Combined with SHAP for interpretability, it can help clinicians identify key risk factors and support early prevention strategies.

Keywords

Ischemic Stroke, Machine Learning, Deep Learning, Prediction Model

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

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



Open Access

1. 引言

缺血性脑卒中(IS)是一种具有高病发率、高致残率和高死亡率的疾病,已经成为国民健康的主要威胁之一[1]。2019年我国有219万人死于卒中,其中缺血性卒中103万人,且发病30天内死亡风险最高,此后年平均死亡率仍达10%[2][3]。因此,利用临床数据构建精准的早期预测模型是早期识别高危人群、延缓卒中发生的关键策略[4]。

近年来,机器学习构建预测模型在医学预测领域兴起,相较于传统量表统计分析,该方法更适应大数据时代的医疗健康信息,处理非线性数据和自动筛选特征优势明显。目前,国内外人员在研究缺血性脑卒中早期风险预测时往往存在以下问题,聚焦于传统回归模型或单一机器学习算法,缺乏多算法在同一样本下的性能比较,以及多数模型未能充分考虑临床指标的非线性关系。同时,预测模型的可解释性不足,临床工作人员及家属难以信任其决策逻辑[5]。

因此,本研究探索Transformer算法在脑卒中预测中的应用价值并与其他模型性能对比,其自注意力机制可自动捕捉临床特征非线性交互与长程依赖,突破传统模型依赖人工筛选特征、忽视复杂关联的局限。此外,针对预测模型因“黑箱”特性而导致结果难以解释,进而影响临床信任与推广的问题[6],本研究引入SHAP可解释性分析方法。该方法不仅能展示整体特征对预测结果的贡献程度,还能呈现单个样本的决策路径,实现了双重可视化解释。这显著提升了模型的透明度,也增强了预测结果在临床应用中的说服力,为脑卒中的病发预测和早期临床干预提供了新的依据。

2. 材料方法

2.1. 数据预处理

本研究采用Kaggle公开数据集[7] (<https://www.kaggle.com/datasets/fedesoriano/stroke-prediction-dataset>), 于2025年6月17日访问), 该数据集由fedesoriano于2021年1月26日上传, 其中包括5110例数据,

每例样本均记录以下信息：编号(id)、性别(gender)、年龄(age)、高血压史(hyper tension)、心脏病史(heart disease)、婚姻史(ever married)、工作类型(work type)、居住类型(Residence type)、平均血糖水平(avg glucose_level)、体重指数(bmi)、吸烟状况(smoking status)和卒中发生(stroke)，其中，卒中发生情况为本研究的预测目标变量。本研究采用随机森林填补法处理数据集中存在的缺失值[8]，该方法能显著降低插补误差，为后续的特征筛选提供更可靠的依据。鉴于数据集中的卒中发生与非卒中样本存在类别不平衡问题，为避免数据泄露，本研究仅在训练集上采用 SMOTE 过采样方法[9]，通过在少数类样本及其邻近样本间线性插值生成新样本，平衡多数类与少数类样本比例，从而提升模型对少数类的识别能力。同时，验证集保持原始分布不变，以客观评估模型性能。

需特别说明的是，本研究所用数据来源于国外公开数据集，不涉及患者隐私及伦理审查，样本量满足预测模型构建的基本要求。并且，该数据集为横断面调查资料，缺乏患者首次卒中发生时间及卒中后随访病发信息。因此，本研究当前阶段仅旨在探究与卒中病发相关的因素，并为后续针对卒中病发人群的深入研究提供线索和参考依据。

2.2. 模型构建

在本研究中采取了 SVM、RF、XGBoost、BP、MLP、DNN 和 Transformer 七种算法构建相应的预测模型，并采用五折交叉验证法进行模型评估与内部验证。将全部数据集平均划分为 5 份，每次选取其中 1 份作为验证集，其余 4 份作为训练集。在每一折中，SMOTE 过采样仅应用于当前折的训练集部分。完成 5 次验证后，将 5 次评估结果取平均值，作为模型的最终性能指标。此外，为进一步提升模型的泛化能力和稳定性，我们对模型进行了超参数调优。通过系统地调整模型参数，不断优化模型性能，使其在不同数据分布下都能保持良好的预测效果。

在模型性能评估方面，本研究采用了多个具有代表性的指标，包括受试者工作特征曲线下面积(AUC)、特异度、召回率、灵敏度和准确率，并采用 Shapley 算法解释(SHapley Additive exPlanations, SHAP)算法评估每个特征对最终模型输出的贡献[10]，以实现模型的可解释性。这些指标从不同角度全面评估了模型的性能，为模型的选择和优化提供了重要依据。

2.3. 模型架构与相关参数

本研究对缺失值采用差异化插补策略：深度学习模型使用数值型特征采取均值插补与分类型特征采取众数插补，基于 SimpleImputer 实现。机器学习模型采用迭代随机森林插补法(RandomForestRegressor, n_estimators = 100, random_state = 42)，利用完整特征预测缺失值，以更好地保留特征间非线性关系。

针对类别不平衡问题，在模型训练阶段应用 SMOTE 过采样，参数设定为(sampling_strategy = 'auto'、k_neighbors = 5、random_state = 42)。SMOTE 仅作用于训练集，且严格嵌入交叉验证内部循环，确保验证集不参与合成样本生成，杜绝数据泄露。

各模型架构简要说明如下，详细超参数搜索空间与最终取值见表 1。Transformer 采用单层编码器结构，输入经线性嵌入层映射至 128 维，叠加正弦位置编码后，送入 4 头自注意力层与 128 维前馈网络(GELU 激活)，各子层均辅以残差连接、层归一化及 0.2 的 Dropout，最终经全局平均池化后分类。DNN 为 3 层全连接前馈网络(隐含层维度 128→32)，激活函数为 ReLU，穿插 Dropout 层(0.3)。MLP 与 BP 均为单隐层全连接网络，隐层维度分别为 64 和 50，激活函数分别采用 ReLU 与 tanh。随机森林集成 200 棵 CART 决策树，最大深度限制为 10。XGBoost 包含 200 棵梯度提升树，最大深度为 3，学习率为 0.01。SVM 采用径向基核函数(RBF)，gamma 参数设为 0.1。所有神经网络优化器均采用 Adam，具体正则化系数与早停策略设置见下表 1。

Table 1. Model parameters
表 1. 模型参数

模型	超参数	搜索空间	最终选定值
Transformer	embed_dim	32, 64, 128	128
	num_heads	4, 8	4
	ff_dim	64, 128, 256	128
	dropout_rate	0.1, 0.2, 0.3	0.2
	learning_rate	0.001, 0.0005, 0.0001	0.0001
	batch_size	32	32
	epochs	100	100
	patience	10	10
DNN	hidden_units1	64, 128, 256	128
	hidden_units2	32, 64, 128	32
	dropout_rate	0.2, 0.3, 0.4	0.3
	learning_rate	0.001, 0.0005, 0.0001	0.0001
	alpha (L2 regularization penalty)	0.01	0.01
	batch_size	32	32
	epochs	50	50
	patience	5	5
MLP	units	16, 32, 64	64
	dropout_rate	0.3, 0.5, 0.7	0.5
	learning_rate	0.01, 0.005, 0.001	0.005
	alpha (L2 regularization penalty)	0.1	0.1
	batch_size	64	64
	epochs	30	30
	patience	5	5
BP	hidden_layer_sizes	(50,), (100,), (50, 50), (100, 50)	(50,)
	activation	relu, tanh	tanh
	alpha (L2 regularization penalty)	0.0001, 0.001, 0.01	0.0001
	learning_rate	constant, adaptive	constant
RF	n_estimators	100, 200, 300	200
	max_depth	None, 10, 20, 30	10
	min_samples_split	2, 5, 10	10
	min_samples_leaf	1, 2, 4	4
	bootstrap	True, False	True
XGBoost	n_estimators	100, 200, 300	200
	max_depth	3, 6, 9	3

续表

	learning_rate	0.01, 0.1, 0.2	0.01
	subsample	0.6, 0.8, 1.0	1.0
	colsample_bytree	0.6, 0.8, 1.0	0.6
	gamma	0, 0.1, 0.2	0.1
SVM	C (penalty parameter)	0.1, 1, 10, 100	0.1
	kernel	rbf, poly, sigmoid	rbf
	gamma	scale, auto, 0.1, 1	0.1

2.4. 统计学方法

采用 R4.4.1、python3.12 和 PyCharm2025.1.1.1 软件进行统计分析。采用 Kolmogorov-Smirnov 检验评估正态性。服从正态分布的计量资料以均数±标准差($\bar{x} \pm s$)表示, 组间比较采用两独立样本 t 检验; 不服从正态分布的计量资料以中位数(四分位数间距)表示, 组间比较采用 Mann-Whitney U 检验; 计数资料以频数(构成比)表示, 组间比较采用 χ^2 检验或 Fisher 确切概率法。检验水准 $\alpha = 0.05$, 双侧 $P < 0.05$ 被认为差异具有统计学意义。将单因素分析中 $P < 0.05$ 的变量纳入后续预测模型的输入特征。

3. 结果

3.1. 患者卒中病发的发生情况

本研究纳入 5110 例患者, 排除 1 例, 数据最终纳入 5109 例, 其中未病发患者为 4860 例, 病发患者为 249 例。排除患者的性别项为“other”, 视为异常值删去。两组患者的一般资料比较见表 2。单因素分析发现, 卒中组与非卒中组在多个因素上存在显著差异。其中, 连续变量采用 Mann-Whitney U 检验, 分类变量采用 χ^2 检验, 结果显示两组的年龄、吸烟状态、婚姻状态、高血压、心脏病、工作类型、平均血糖值和 BMI 的差异均具有统计学意义(均 $P < 0.05$)。

Table 2. Comparison of general data between stroke group and non-stroke group
表 2. 卒中组和非卒中组一般资料比较

项目	分类	非卒中组(N = 4860)	卒中组(N = 249)	统计值	P 值
性别(%)	男	2007 (41.3)	108 (43.4)	$\chi^2 = 0.34$	0.560
	女	2853 (58.7)	141 (56.6)		
年龄		43.00 (24.00, 59.00)	71.00 (59.00, 78.00)	U = 200261	<0.001
吸烟状态(%)	从不	814 (16.7)	70 (28.1)	$\chi^2 = 29.27$	<0.001
	偶尔	1802 (37.1)	90 (36.1)		
	经常	747 (15.4)	42 (16.9)		
	未知	1497 (30.8)	47 (18.9)		
婚姻状态(%)	未婚	1727 (35.5)	29 (11.6)	$\chi^2 = 58.87$	<0.001
	已婚	3133 (64.5)	220 (88.4)		
高血压(%)	无	4428 (91.1)	183 (73.5)	$\chi^2 = 81.58$	<0.001
	有	432 (8.9)	66 (26.5)		

续表

心脏病(%)	无	4631 (95.3)	202 (81.1)	$\chi^2 = 90.23$	<0.001
	有	229 (4.7)	47 (18.9)		
居住环境(%)	农村	2399 (49.4)	114 (45.8)	$\chi^2 = 1.08$	0.300
	城市	2461 (50.6)	135 (54.2)		
工作类型(%)	失业人群	685 (14.1%)	2 (0.8%)	$\chi^2 = 49.16$	<0.001
	公职人员	624 (12.8%)	33 (13.3%)		
	从未工作	22 (0.5%)	0 (0.0%)		
	私企	2775 (57.1%)	149 (59.8%)		
	个体户	754 (15.5%)	65 (26.1%)		
平均血糖值		91.47 (77.12, 112.80)	105.22 (79.79, 196.71)	U = 471082	<0.001
BMI		28.00 (23.40, 33.10)	29.70 (26.40, 33.70)	U = 413263	<0.001

3.2. 卒中病发预测模型的性能比较

根据上述结果,选择以下特征纳入预测模型进行分析,包括年龄、吸烟状态、婚姻状态、高血压、心脏病、工作类型、平均血糖值、BMI。基于 BP、RF、XGBoost、SVM、DNN、MLP、Transformer 算法构建了 7 种缺血性脑卒中病发的预测模型,并通过五折交叉验证进行内部验证得到各个模型性能,见表 3。结果显示,BP、RF、XGBoost、SVM、DNN、MLP、Transformer 模型的 AUC 值分别为 0.810, 0.785, 0.764, 0.788, 0.853, 0.844, 0.912 其中 Transformer 模型的 AUC 值最高,其次是 DNN 算法,(AUC = 0.853),极端梯度提升(AUC = 0.764)最低,即该模型整体的预测效能优于其他六种模型,各模型的 ROC 曲线见图 1。

3.2.1. Transformer 模型的性能评估

本研究采用五折交叉验证评估基于 Transformer 算法构建的卒中病发预测模型性能,见图 2。基于最优超参数组合重新进行五折交叉验证,每折结果如下: Fold1 (AUC=0.918)、Fold2 (AUC=0.921)、Fold3 (AUC=0.912)、Fold4 (AUC=0.920)、Fold5 (AUC=0.905),表明模型在不同数据子集上具有稳定的预测性能。该数据表明 Transformer 算法对复杂医疗数据的非线性特征提取能力具有显著优势。并且,该模型的平均正确率(AP)为 0.890,表明模型具有较高的准确率。

Table 3. Performance of the seven models for predicting stroke onset

表 3. 七种模型构建脑卒中病发预测模型的效能

算法	AUC	准确率	召回率	特异度	Brier 分数
BP 算法	0.810	0.756	0.711	0.758	0.154
RF 算法	0.785	0.904	0.210	0.939	0.072
XGBoost 算法	0.764	0.905	0.144	0.944	0.072
SVM 算法	0.788	0.756	0.655	0.761	0.149
DNN 算法	0.853	0.696	0.868	0.687	0.193
MLP 算法	0.844	0.688	0.872	0.679	0.179
Transformer 算法	0.912	0.771	0.847	0.766	0.091




Figure 1. ROC curves of the seven prediction models

图 1. 七种预测模型 ROC 曲线




Figure 2. ROC curve and PR curve of the transformer model

图 2. Transformer 模型的 ROC 曲线及 P-R 图

3.2.2. Transformer 模型的特征分析

本研究运用 SHAP 算法评估各特征在该模型最终输出中的贡献程度。SHAP 算法能够清晰界定哪些临床指标在疾病预测或治疗效果评估方面具有最大影响力，从而实现模型的可解释性。SHAP 重要性排序结果如图 3 所示，各变量平均权重的绝对值从高到低依次为：年龄、BMI、工作类型、心脏病、平均血糖水平、吸烟状态、高血压、婚姻状况。

3.2.3. 各个特征与 Transformer 模型的决策关系

为清晰且准确地呈现各个特征对模型输出的正负影响关系，本研究生成 SHAP 摘要图，见图 4。纵坐标为特征按重要性降序排列，横坐标为每个样本的 SHAP 值，此值与特征对模型输出的影响呈正相关，即正值表示该特征增加卒中风险，负值表示降低卒中风险。同时，点的颜色用于表示特征值的高低，其中红色代表特征值较高，蓝色代表特征值较低。

3.2.4. 单样本预测特征的解释分析

为直观呈现模型对脑卒中病发的预测决策, 本研究随机抽取两例典型患者样本生成 SHAP 决策图, 见图 5, 以展示各个特征对卒中病发风险的贡献。该决策图以颜色编码标识特征影响方向: 红色条块表示




Figure 3. SHAP feature importance ranking plot

图 3. SHAP 特征重要性排序图




Figure 4. SHAP summary plot

图 4. SHAP 摘要图




Figure 5. SHAP decision plot for patients at different risk levels

图 5. 不同风险病发患者的 SHAP 决策图

特征对模型预测结果有正向贡献,即特征值增加会提高卒中病发风险预测值;蓝色条块表示负向贡献,即特征值增加会降低预测值。如图所示,模型基准风险(即卒中发生率)为 0.222。左图患者的年龄、吸烟状态、BMI、工作状态等特征呈正向贡献,使该患者的风险评分提升至 0.894,属于高病发风险患者。右图患者受年龄、高血压、婚姻状态等特征影响,风险评分 0.194,低于基准值,表明该患者的病发风险较低。

4. 讨论

本研究采用 Kaggle 公开数据集构建模型,通过对比七种机器学习算法的预测性能,发现 Transformer 算法表现最优,模型 AUC 达 0.912,各折 AUC 均在 0.905 以上,表明其具有良好的稳定性与泛化能力。此外,结合 SHAP 分析法对模型输出进行可解释性分析,进一步增强模型决策的透明度,为临床辅助决策提供有力支持。

4.1. 脑卒中发病相关因素

本研究发现,年龄、BMI、工作类型是贡献度最高的三个特征,其次为心脏病史、平均血糖水平、吸烟状态、高血压病史等。

年龄是本研究中脑卒中发生的独立且最显著危险因素[11]。随着年龄增长,机体血管壁弹性减退、动脉粥样硬化病变进展、中枢神经功能退行性改变,可导致脑卒中发病风险显著升高。研究结果显示,脑卒中组患者年龄中位数为 71 岁,显著高于非脑卒中组 43 岁,提示临床医护人员应重点聚焦老年高危人群,定期开展脑血管专项健康筛查与评估,尽早发现脑卒中易感人群,及早进行预防性干预。

体质指数(BMI)是评价机体肥胖程度的核心量化指标[12],本研究证实其与脑卒中发病风险呈正相关。肥胖可通过激活全身慢性炎症反应、诱发胰岛素抵抗、升高血压及血脂水平等多重病理机制,加速动脉粥样硬化的发生与发展,进而增高脑卒中发生风险[13][14]。建议临床对超重及肥胖人群开展健康宣教,指导其通过合理膳食调控、规律有氧运动等科学方式进行健康管理,防控脑卒中危险因素。

职业类型对脑卒中发病的影响,可能与不同人群职业相关体力活动强度、职业压力负荷及社会经济状态等混杂因素密切相关[15]。本研究数据分析表明,脑卒中组个体户占比为 26.1%,显著高于非卒中组的 15.5%;而脑卒中组失业人群占比仅 0.8%,提示稳定的职业状态对脑卒中发病可能存在一定保护性效应[16]。在临床护理工作中,应重点关注高职业负荷、高压从业人群的心理健康状况与血压动态管理,针对性指导其开展放松训练、坚持规律运动,减少不良诱因,降低脑卒中发病风险。

此外,心脏病史、平均血糖水平、吸烟状态、高血压病史等传统危险因素也显示出显著的预测价值,进一步验证了模型的合理性。这些因素与卒中发生的关联已在多项研究中得到证实。

4.2. Transformer 模型在脑卒中早期预测中具有良好的性能

近年来,研究人员已开发多种脑卒中病发风险评估量表及预测模型,但这些工具对复杂医学数据中非线性关系的分析能力尚显不足。焉双梅[17]等采用 Essen 卒中风险分层量表(Essen Stroke Risk Score, ESRS)和卒中预测工具-II (Stroke Prognostic Instrument-II, SPI-II)对卒中病发风险进行评估,对比分析显示,两个量表的 AUC 值分别为 0.576 和 0.583。然而,由于评估量表纳入因素有限,后续提升空间受限,可能存在未纳入的潜在卒中风险因素。医疗数据如心率、血压、血脂、运动量、饮食结构之间相互影响、相互制约,共同影响疾病病发,为此,本研究采用可捕捉非线性关系的机器学习方法,从大量数据中识别潜在的危险因素,从而深入探讨脑卒中的发病机制。

随着大数据与智慧医疗的快速发展,机器学习作为一种新兴工具已广泛应用于医疗行业,用于疾病

诊断、预测及图像识别,成为分析医疗数据、辅助临床制订护理方案及开展早期预防的重要手段[18]。部分研究者已通过不同的机器学习算法构建脑卒中病发预测模型,为该领域研究奠定了一定基础。例如,Abedi V [19]等为研究缺血性脑卒中的病发预测模型,利用6种算法分析了53个变量指标,预测了长达5年的脑梗死病发情况,结果显示1年预测效果最佳($AUC=0.79$),5年预测效果最差($AUC=0.69$)。不同机器学习算法适用于不同场景,因此有必要比较各种模型的预测性能,以筛选出最适合的模型。

本研究通过对比七种机器学习算法的预测性能,发现Transformer算法表现最优。其核心机制在于自注意力机制,能够自动计算各特征之间的权重,捕捉生命体征、生化指标及生活状态间的复杂非线性交互作用,聚焦于对卒中风险预测最为关键的信息。研究结果显示,Transformer模型各折AUC均在0.905以上,AUC与AP的标准差较小,表明模型在不同数据子集上具有良好的稳定性和泛化能力。该模型在训练集和验证集上的性能表现均优于其他6种算法,说明自注意力机制在处理复杂医疗数据方面具有独特优势。

4.3. 可解释性分析的应用价值

预测模型的“黑箱”特性是制约其临床推广的主要障碍[20]。本研究采用SHAP算法对预测模型的研究结果进行可视化分析[5],实现了从全局特征重要性到个体决策路径的双重可解释性,显著增强了模型的透明度。

从全局来看,SHAP摘要图(图4)呈现了各特征对模型输出的影响方向及强度。年龄、BMI、工作类型、心脏病等特征取值越高,SHAP值越趋于正向,提示这些因素会增加卒中风险的预测值;而婚姻状态、吸烟状态等特征的影响方向则因人而异。上述结果与龙秀英[21]研究一致,通过logistic回归分析同样发现,年龄、吸烟状况是脑卒中发病的独立危险因素。

在个体层面,SHAP决策图(图5)展示了典型患者的具体风险预测路径。模型设定的基准风险(即训练集中卒中发生率)为0.222。左图患者因年龄、吸烟状态、BMI、工作类型等因素呈正向贡献,最终风险评分升至0.894,属于高风险人群;右图患者风险评分为0.194,低于基准值,为低风险人群。这种个体化的解释方式,有助于临床医生理解模型得出某一判断的依据,从而增强对模型输出的信任,也为个性化干预提供了可行参考。

针对脑卒中发病预测,国内外学者已开发出多种模型,不过这些模型普遍难以解释自身的决策过程[22]。患者及医生在面对模型输出结果,难以理解其决策逻辑,不利于给出明确的诊疗指引[23]。SHAP分析结果的引入,使模型在保持高预测效能的基础上,进一步获得了临床可接受性。基于SHAP分析结果,临床医生可以向患者及家属清楚展示影响卒中风险的关键因素。据此,可针对性地指导患者合理安排身体活动、规范用药,并制定个性化护理方案,从而提升患者生活质量,降低卒中发生风险。

4.4. 局限性

本研究的模型性能良好,但仍存在以下局限性。第一,数据为横断面调查资料,缺乏纵向随访数据,无法区分首次发病与复发卒中患者。鉴于两类卒生在病理机制、危险因素构成和预后轨迹上存在显著差异,将二者混为一谈可能降低模型的临床针对性。第二,受限于公开数据集的特征限制,本研究的特征集未能纳入多项已被文献证实的卒中关键预测因子,详细的既往病史信息如冠心病、糖尿病、高血压等病史,影像学指标如脑白质病变、脑动脉粥样硬化,以及常规生化指标如同型半胱氨酸、红细胞分布宽度变异系数等潜在重要预测因素。第三,仅进行了内部交叉验证,缺乏在独立的外部数据集,如不同地区、不同年份或不同医院系统收集的卒中人群,该模型的泛化能力尚需进一步检验。因此,本研究的预测模型仅适用于横断面场景下的风险因素关联分析,尚不具备跨场景部署的条件。

5. 结论

本研究基于 Transformer 算法构建了缺血性脑卒中早期预测模型,在 7 种机器学习模型中预测性能最优(AUC = 0.912)。并且,采用 SHAP 可解释性分析显示,年龄、BMI、工作类型、心脏病是影响卒中风险的关键因素。将模型与可解释性分析相结合,可以从全局特征重要性到个体决策路径实现双重解释,为临床早期识别高风险人群和制定个性化预防策略提供依据。本研究仅进行了内部验证,由于数据源于横断面调查、特征覆盖不全且缺乏外部验证,本研究结果属于探索性发现,为 Transformer 在卒中流行病学分析中的适用性提供了初步依据,未来有必要引入大样本、多中心、多模态的数据做进一步验证。

综上所述,基于机器学习算法构建的脑卒中病发预测模型仍具有较好的临床应用价值。

参考文献

- [1] 《中国脑卒中防治报告 2021》概要[J]. 中国脑血管病杂志, 2023, 20(11): 783-793.
- [2] Pan, Y.S., Jing, J., Chen, W.Q., *et al.* (2017) Risks and Benefits of Clopidogrel-Aspirin in Minor Stroke or TIA: Time Course Analysis of CHANCE. *Neurology*, **88**, 1906-1911.
- [3] 张倩, 魏朝洁, 黄宏汰, 等. 基于 21 个队列研究的中国缺血性脑卒中患者复发风险预测模型构建与验证[J]. 实用心脑血管病杂志, 2023, 31(2): 8-15.
- [4] Aarnio, K., Haapaniemi, E., Melkas, S., Kaste, M., Tatlisumak, T. and Putaala, J. (2014) Long-Term Mortality after First-Ever and Recurrent Stroke in Young Adults. *Stroke*, **45**, 2670-2676. <https://doi.org/10.1161/strokeaha.114.005648>
- [5] 莫秋红, 丁晓波, 李靓, 等. 基于可解释性机器学习模型的轻型缺血性卒中复发预测研究[J]. 中国卒中杂志, 2024, 19(8): 924-930.
- [6] Muhammad, D. and Bendeche, M. (2024) Unveiling the Black Box: A Systematic Review of Explainable Artificial Intelligence in Medical Image Analysis. *Computational and Structural Biotechnology Journal*, **24**, 542-560. <https://doi.org/10.1016/j.csbj.2024.08.005>
- [7] FEDESORIANO (2021) Stroke Prediction Dataset. Kaggle. <https://www.kaggle.com/datasets/fedesoriano/stroke-prediction-dataset>
- [8] 张晓琴, 程誉莹. 基于随机森林模型的成分数据缺失值填补法[J]. 应用概率统计, 2017, 33(1): 102-110.
- [9] 马宝霖. 基于改进 SMOTE 算法的不平衡数据分类问题研究[D]: [硕士学位论文]. 长春: 长春工业大学, 2024.
- [10] 聂茜, 邓光明. 基于 Shapley 值的分类预测模型变量筛选方法改进[J]. 统计与决策, 2023, 39(3): 38-42.
- [11] Krittanawong, C., Kumar, A., Wang, Z., Baber, U. and Bhatt, D.L. (2020) Self-Employment and Cardiovascular Risk in the US General Population. *International Journal of Cardiology Hypertension*, **6**, Article ID: 100035. <https://doi.org/10.1016/j.ijchy.2020.100035>
- [12] Wei, S.L. and Chiu, K.L. (2025) Impact of Body Mass Index on Recurrent Stroke in Stroke Survivors: An Updated Systematic Review and Meta-Analysis. *Obesity Research & Clinical Practice*, **19**, 202-213. <https://doi.org/10.1016/j.orcp.2025.05.003>
- [13] Henning, R.J. (2021) Obesity and Obesity-Induced Inflammatory Disease Contribute to Atherosclerosis: A Review of the Patho-Physiology and Treatment of Obesity. *American Journal of Cardiovascular Disease*, **11**, 504-529.
- [14] Ghowsi, M., Qalekhani, F., Farzaei, M.H., Mahmudi, F., Yousofvand, N. and Joshi, T. (2021) Inflammation, Oxidative Stress, Insulin Resistance, and Hypertension as Mediators for Adverse Effects of Obesity on the Brain: A Review. *Bio-Medicine*, **11**, 13-22. <https://doi.org/10.37796/2211-8039.1174>
- [15] Fransson, E.I., Nyberg, S.T., Heikkilä, K., Alfredsson, L., Björner, J.B., Borritz, M., *et al.* (2015) Job Strain and the Risk of Stroke. *Stroke*, **46**, 557-559. <https://doi.org/10.1161/strokeaha.114.008019>
- [16] Zhang, F., Guo, Z., Wu, Y., Liu, H., Luo, Y., Sun, M., *et al.* (2017) Prevalence of Stroke and Associated Risk Factors: A Population Based Cross Sectional Study from Northeast China. *BMJ Open*, **7**, e015758. <https://doi.org/10.1136/bmjopen-2016-015758>
- [17] 焉双梅, 洪渊, 张欢, 等. ESRS 和 SPI-II 评分对急性缺血性脑卒中患者复发风险的评估作用[J]. 中风与神经疾病杂志, 2016, 33(11): 1002-1005.
- [18] 李洁洁, 张雁儒, 李昊, 等. 机器学习在脑卒中预测中的研究进展[J]. 河南医学研究, 2022, 31(20): 3832-3835.
- [19] Abedi, V., Avula, V., Chaudhary, D., Shahjouei, S., Khan, A., Griessenauer, C.J., *et al.* (2021) Prediction of Long-Term

-
- Stroke Recurrence Using Machine Learning Models. *Journal of Clinical Medicine*, **10**, Article 1286. <https://doi.org/10.3390/jcm10061286>
- [20] Salih, A., Boscolo Galazzo, I., Gkontra, P., Lee, A.M., Lekadir, K., Raisi-Estabragh, Z., *et al.* (2023) Explainable Artificial Intelligence and Cardiac Imaging: Toward More Interpretable Models. *Circulation: Cardiovascular Imaging*, **16**, e014519. <https://doi.org/10.1161/circimaging.122.014519>
- [21] 龙秀英, 曾倩, 李秋茹. 缺血性卒中复发危险因素分析及风险评估[J]. 中国现代神经疾病杂志, 2016, 16(7): 442-446.
- [22] 邱星强, 潘艺梅, 任晓媛, 等. 急性脑卒中患者 1 年内继发性癫痫的危险因素分析及列线图预测模型构建[J]. 新疆医学, 2026, 56(4): 551-556, 578.
- [23] Alkhanbouli, R., Matar Abdulla Almadhaani, H., Alhosani, F. and Simsekler, M.C.E. (2025) The Role of Explainable Artificial Intelligence in Disease Prediction: A Systematic Literature Review and Future Research Directions. *BMC Medical Informatics and Decision Making*, **25**, Article No. 110. <https://doi.org/10.1186/s12911-025-02944-6>