

DOI:10.3969/j.issn.1005-202X.2026.02.019

基于机器学习的多模态MRI对脑卒中病灶特征的预测模型

陈爱德, 胡亚恒, 魏文存

安康市中医医院设备科, 陕西 安康 725000

【摘要】目的:利用多模态MRI成像数据,结合影像组学特征和机器学习技术,建立一个用于预测脑卒中病灶风险的模型。通过特征提取、筛选与分类建模,比较不同机器学习算法[支持向量机(SVM)、决策树、极限梯度提升树(XGBoost)、BP神经网络]在脑卒中病灶特征识别中的表现,为临床诊断和治疗决策提供支持。**方法:**收集2020年2月~2024年5月期间某三甲医院神经科129名患者的多模态MRI数据,包括T₁加权成像(T₁WI)、T₂加权成像(T₂WI)、弥散加权成像(DWI)和增强成像等。首先对每个病灶进行感兴趣区域(ROI)勾画,然后提取影像组学特征,并引入Attention机制以提高特征提取的准确性。接着,使用LASSO回归和主成分分析(PCA)对特征进行筛选,最后基于筛选后的特征构建SVM、决策树、XGBoost和BP神经网络模型。**结果:**在独立测试集上评估模型性能,LASSO与XGBoost的组合在所有指标上均表现最佳,PCA与决策树的组合在各项指标上表现最差。特征筛选显著提升所有模型的预测能力,尤其是在高维影像组学数据处理中。**结论:**通过结合多模态MRI与机器学习,建立一个脑卒中病灶风险预测模型。LASSO与XGBoost模型的组合在多模态影像数据的脑卒中病灶特征识别中表现出色,具有良好的临床应用潜力。

【关键词】机器学习;多模态MRI;脑卒中;病灶;影像组学**【中图分类号】**R318;R743**【文献标志码】**A**【文章编号】**1005-202X(2026)02-0276-05

Machine learning-based predictive model for stroke lesion characteristics using multimodal MRI

CHEN Aide, HU Yaheng, WEI Wencun

Department of Equipment, Ankang Hospital of Traditional Chinese Medicine, Ankang 725000, China

Abstract: Objective To develop a predictive model for stroke lesion characteristics by integrating multimodal magnetic resonance imaging (MRI) data, radiomics features, and machine learning techniques, and to compare the performance of different machine learning algorithms, including support vector machine, decision tree, extreme gradient boosting (XGBoost), and back propagation neural network, in identifying stroke lesion characteristics, thereby supporting clinical diagnosis and treatment decision-making. **Methods** Multimodal MRI data were collected from 129 patients admitted to the Neurology Department of a Grade A tertiary hospital between February 2020 and May 2024, including T₁-weighted imaging, T₂-weighted imaging, diffusion-weighted imaging, and contrast-enhanced imaging. Regions of interest were delineated for each lesion, followed by radiomics feature extraction, with an attention mechanism introduced to enhance feature extraction accuracy. Subsequently, feature selection was conducted using LASSO regression and principal component analysis, and finally, predictive models based on support vector machine, decision tree, XGBoost, and back propagation neural network were constructed using the selected features. **Results** Model performance was evaluated on an independent test set. Among these models, the LASSO-XGBoost combination outperformed all other combinations across all metrics, whereas the integration of principal component analysis and decision tree had the poorest performance. Feature selection significantly improved the predictive capability of all models, especially for high-dimensional radiomics data processing. **Conclusion** A predictive model for stroke lesion risk is established by integrating multimodal MRI with machine learning. The LASSO-XGBoost combination exhibits excellent performance in identifying stroke lesion characteristics from multimodal imaging data, demonstrating its promising potential for clinical application.

Keywords: machine learning; multimodal magnetic resonance imaging; stroke; lesion; radiomics**【收稿日期】**2025-10-15**【基金项目】**陕西省自然科学基金基础研究(2023-JC-QN-0849)**【作者简介】**陈爱德,副主任技师,研究方向:生物医学工程,E-mail: C55319hen@163.com**【通信作者】**魏文存,副主任技师,研究方向:生物医学工程、医疗设备应用与维修,E-mail: 475424146@qq.com

前言

脑卒中是一种全球范围内致死率和致残率均居高不下的疾病,严重影响患者生活质量,增加社会经济负担^[1]。根据世界卫生组织的数据,每年全球约1 500万人发生脑卒中,其中超过500万人因卒中而死亡,另有500万人因卒中而永久致残^[2]。卒中分为缺血性卒中和出血性卒中两类,其中缺血性卒中占大多数。对卒中病灶的早期准确评估和风险预测是有效治疗和改善预后的关键^[3]。传统的影像学诊断方法如CT和MRI依赖于放射科医生的经验和视觉判断,存在一定的主观性和诊断一致性问题^[4]。随着人工智能技术的发展,基于影像数据的自动化分析和预测模型逐渐成为研究热点^[5]。其中,影像组学技术通过定量分析影像数据,挖掘出大量的潜在特征,可以在疾病诊断、预后评估和治疗决策中发挥重要作用^[6]。影像组学不仅提供病灶形态学之外的深层信息,还能够结合临床和分子特征提高模型预测的准确性和鲁棒性^[7]。

多模态MRI成像技术因其丰富的图像对比度和病灶特异性,在脑卒中诊断中具有不可替代的作用^[8]。 T_1 加权成像(T_1WI)主要用于提供解剖学信息, T_2 加权成像(T_2WI)可显示病灶的水肿和炎症反应,弥散加权成像(DWI)对早期缺血性病灶特别敏感,而增强成像则可评估血脑屏障的完整性和病灶血供状态。通过对这些多模态数据进行融合分析,能够更全面地描述脑卒中病灶的特征^[9]。

机器学习模型在处理高维复杂数据方面具有显著优势,特别是在影像组学数据的分析中表现出色^[10-11]。支持向量机(SVM)^[12]、决策树^[13]、极限梯度提升树(XGBoost)^[14]、BP神经网络^[15]是当前应用广泛的几种机器学习算法。SVM通过寻找最佳分类超平面,在样本量较小且特征维度较高的情况下,具有良好的泛化能力;决策树以其易于理解和解释的优势,适合用于临床决策支持;XGBoost作为一种集成学习算法,通过迭代优化提高模型性能,特别适合处理非线性复杂数据;BP神经网络通过多层网络结构,能够自动学习数据的深层次特征,广泛应用于模式识别和分类任务中。特征筛选是机器学习建模中的重要步骤,可以显著提升模型的预测能力和计算效率。LASSO回归^[16]和主成分分析(PCA)^[17]是常用的特征筛选方法,前者通过引入L1正则化选择重要特征,后者则通过降维保留数据中最具代表性的主成分。特征筛选能够有效减少模型的复杂性,降低过拟合风险,特别是在处理高维影像组学数据时尤为重要^[18]。

基于上述背景,本研究通过结合多模态MRI影像组学特征提取与机器学习建模,构建一个能够准确预测脑卒中病灶风险的模型。

1 资料与方法

1.1 研究对象

研究纳入2020年2月~2024年5月期间在某三甲医院神经科就诊的129名患者,其中83名患者均通过临床和影像学手段确诊为脑卒中,完成多模态MRI检查。研究对象年龄40~85岁。所有患者均自愿参与本研究并签署知情同意书,研究得到医院伦理委员会的批准。

1.2 纳入与排除标准

本研究纳入的患者需符合以下条件:临床确诊为缺血性或出血性脑卒中,且MRI资料齐全,包括 T_1WI 、 T_2WI 、DWI、MRA及增强成像。所用MRI图像质量良好,无明显伪影,适于影像组学分析,并且患者的病灶在各序列上明确,可准确勾画感兴趣区域(ROI)。

排除标准:既往有脑卒中病史或其他严重的中枢神经系统疾病;合并严重器质性疾病或正在接受抗癌治疗;因心理或生理原因无法配合MRI检查者;成像过程中出现明显运动伪影或金属伪影影响图像质量者。

1.3 MRI检查方法

所有患者均在同一型号的3.0T高场强MRI设备上扫描,以确保数据一致性。扫描序列包括: T_1WI 采用快速自旋回波序列,切片厚度5 mm,间隔1 mm,用于显示脑结构解剖细节; T_2WI 使用自旋回波序列,切片厚度5 mm,间隔1 mm,主要用于识别水肿、出血及病灶位置;DWI采用单次激发的自旋回波EPI序列,b值设置为1 000 s/mm²,切片厚度5 mm,间隔1 mm,用于评估早期缺血性脑卒中病灶;增强成像,在注射对比剂后进行 T_1WI 增强扫描,使用相同参数,以显示血脑屏障的完整性及病灶的血供状况。

1.4 ROI勾画

ROI勾画是影像组学分析的关键步骤。本研究中,由经验丰富的神经放射科医生独立进行ROI勾画,所有ROI均基于 T_1WI 、 T_2WI 和DWI图像进行多模态融合勾画,以确保病灶区域的准确标注。具体勾画过程如下:首先在 T_1WI 序列上手动画病灶的边界,获得初步ROI;然后结合 T_2WI 和DWI序列,调整初步勾画的ROI边界,确保将水肿、出血及缺血区完整覆盖;最后,两位医生分别完成勾画后,对结果进行讨论和调整,直至达成一致,得到的ROI以三维数据格式保存,用于后续特征提取。

1.5 特征提取

从勾画的ROI中提取影像组学特征。特征包括但不限于灰度直方图特征、纹理特征、形状特征以及波形特征。提取的特征包括一阶统计特征(平均灰度值、标准差、偏度、峰度等),二阶纹理特征(灰度共生矩阵、灰度游程矩阵等),三阶特征(基于小波变换的频域特征和基于几何形状的复杂性特征)。

在特征提取过程中,Attention机制用于增强模型对重要特征的注意力^[19]。Attention机制的核心思想是通过加权求和的方式,根据输入特征的重要性对其进行加权处理,从而突出关键特征^[20]。在影像组学特征提取中,给定一组输入特征 $X = \{x_1, x_2, \dots, x_n\}$, Attention机制首先计算每个特征的注意力权重 α_i , 该权重通过软最大化函数计算得到:

$$\alpha_i = \frac{\exp(e_i)}{\sum_{j=1}^n \exp(e_j)} \quad (1)$$

式(1)中, e_i 是特征 x_i 与全局上下文的相关性分数, 可通过简单的线性变换或更复杂的神经网络计算得到。接着, 计算加权求和的输出:

$$V = \sum_{i=1}^n \alpha_i x_i \quad (2)$$

通过Attention机制,模型能够根据特征的重要性动态调整权重,从而更好地捕捉关键的影像特征,提升模型的预测性能。

1.6 特征筛选

影像组学特征往往具有高维度和冗余性,因此需要通过特征筛选来减少维度,保留最具诊断价值的特征。本研究采用LASSO回归和PCA两种方法进行特征筛选。

(1)LASSO是一种线性回归模型,通过引入L1正则化项,实现特征的稀疏化选择^[21]。其优化目标函数为:

$$\min \left(\frac{1}{2n} \sum_{i=1}^n (y_i - X_i \beta)^2 + \lambda \sum_{j=1}^p |\beta_j| \right) \quad (3)$$

式(3)中, y_i 为真实标签, X_i 为特征矩阵, β 为回归系数, λ 为正则化参数。通过调节 λ , 可以控制特征选择的稀疏度,从而消除冗余特征,仅保留最重要的特征^[22]。

(2)PCA是一种常用的降维方法,通过线性变换将高维数据映射到低维空间,保留数据中方差最大的主成分。其主要步骤包括:(1)对原始特征矩阵进行中心化处理后,计算其协方差矩阵;(2)对协方差矩阵进行特征值分解,得到特征值和特征向量;(3)根据特征

值大小排序,选择前K个主成分,构建低维特征空间。PCA通过保留数据中的主要信息成分,减少模型计算的复杂度,同时提高模型的稳健性。

1.7 模型建立

本研究构建4种分类模型:SVM、决策树、XGBoost和BP神经网络。

(1)SVM通过寻找最优超平面,将不同类别的样本进行分割。其优化目标是最大化分类超平面的间隔。对于二分类问题,其目标函数为:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad \text{subject to} \quad y_i (w^T x_i + b) \geq 1 \quad (4)$$

式(4)中, w 为分类超平面的法向量, b 为偏置, y_i 为样本标签, x_i 为样本特征。通过RBF核函数,SVM可以处理非线性分类问题。

(2)决策树使用树形结构进行分类,通过选择特征的最佳分割点构建树节点。最常用的分割标准是基尼指数,其计算公式为:

$$\text{Gini}(D) = 1 - \sum_{k=1}^K p_k^2 \quad (5)$$

式(5)中, p_k 是第 k 类样本在当前节点中的比例。决策树的构建过程包括节点分裂、树剪枝等步骤,以防止过拟合。

(3)XGBoost是一种基于决策树的集成学习方法,通过加权迭代提升弱分类器的性能。其目标函数为:

$$\text{Obj}(\theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (6)$$

式(6)中, $l(y_i, \hat{y}_i)$ 是损失函数, $\Omega(f_k)$ 是树的正则化项。XGBoost通过控制学习率、树的深度和正则化项优化模型性能。

(4)BP神经网络是一种多层前馈神经网络,通过反向传播算法调整权重。其损失函数定义为交叉熵损失:

$$L(\theta) = -\frac{1}{n} \sum_{i=1}^n [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (7)$$

网络的训练过程包括前向传播计算输出,反向传播计算梯度,以及通过Adam优化算法更新权重。模型结构包括输入层、隐藏层和输出层,激活函数使用ReLU函数。

1.8 评价指标

本研究采用多种评价指标,包括准确性(Accuracy)、灵敏性(Sensitivity)、特异性(Specificity)、精确率(Precision)、F1分数(F1-Score)以及受试者工作特征曲线下面积(AUC)。准确率为预测正确的样本数占总样本数的比例。灵敏性为正样本中被正确预测为正的的比例,反映模型对正类的

识别能力。特异性为负样本中被正确预测为负的比例,反映模型对负类的识别能力。精确率为被预测为正样本中实际为正样本的比例。F1-分数为精确率和灵敏性的调和平均,综合评价模型性能。AUC为ROC曲线下面积,反映模型在不同阈值下的分类性能。

2 结果

在实验开始之前,将数据集按8:2比例划分为训练集和测试集,其中80%的数据用于模型训练,20%的数据用于测试。采用两种特征筛选方法:LASSO和PCA,同时构建并验证4种分类模型,包括SVM、决策树、XGBoost和BP神经网络。对不同特征筛选方法和分类模型组合的性能进行全面比较,以评估其在脑卒中病灶特征预测中的效果。表1展示通过LASSO和PCA两种特征筛选方法结合4种分类模型所得到的4种评价指标。为进一步分析这些组合模型的性能,计算各组合的F1分数和AUC的估算值,并将结果以灰度直方图的形式展示。图1展示不同方法下模型的F1分数,图2展示模型的AUC值,评估不同模型在分类任务中的整体区分能力。

根据表1可知,不同特征筛选方法与分类模型组合的性能存在显著差异。使用LASSO进行特征筛选后,配合XGBoost分类模型的组合在所有指标上表现最优,准确率为0.867,灵敏性为0.880,特异性为0.861,精确率为0.870。这表明LASSO与XGBoost的组合能够更好地捕捉与脑卒中病灶特征相关的影像组学特征。相比之下,PCA与决策树的组合表现较差,所有指标均处于较低水平,表明决策树模型可能不适合此类复杂数据的分类任务。XGBoost和SVM在不同特征筛选方法下均表现出较强的分类能力,特别是在LASSO特征筛选后效果尤为明显。

表1 不同方法得到的评价指标比较

Table 1 Comparison of evaluation metrics across different methods

特征筛选方法	分类模型	准确性	灵敏性	特异性	精确率
LASSO	SVM	0.825	0.851	0.820	0.826
	决策树	0.762	0.781	0.739	0.773
	XGBoost	0.867	0.880	0.861	0.870
	BP神经网络	0.820	0.817	0.796	0.821
PCA	SVM	0.823	0.837	0.809	0.827
	决策树	0.732	0.750	0.711	0.732
	XGBoost	0.852	0.853	0.852	0.855
	BP神经网络	0.782	0.790	0.771	0.783

根据图1可知,LASSO与XGBoost的组合在F1分数上表现最佳,表明该模型在平衡精确率与灵敏性方面具有显著优势。PCA与决策树的组合F1分数最低,这表明该组合模型在处理复杂影像组学数据时存在较大局限性。根据图2可知,LASSO与XGBoost的组合在AUC值上也表现最优,显示其在区分阳性和阴性样本方面的强大能力。PCA与决策树的组合AUC值为0.731,表现最差,进一步佐证了其在分类任务中的劣势。




图1 不同方法的F1分数比较

Figure 1 Comparison of F1 scores across different methods




图2 不同方法的AUC值比较

Figure 2 Comparison of AUC values across different methods

综合上述分析,可以得出LASSO与XGBoost的组合在预测脑卒中病灶特征方面表现最为出色,具有较高的预测精度和泛化能力。而PCA与决策树的组合表现则相对较差,难以有效处理复杂的多模态MRI数据。通过比较不同特征筛选方法和分类模型组合的表现,发现XGBoost模型在不同筛选方法下均表现出较强的适应性和预测能力,是脑卒中病灶影像组学分析的优选方法。

3 结论

本研究旨在探讨多模态 MRI 影像组学特征在脑卒中病灶特征预测中的应用,并建立基于机器学习的风险预测模型。研究表明不同的特征筛选方法和分类模型组合在预测性能上存在显著差异。LASSO 与 XGBoost 的组合在各项指标上均表现出色,特别是在 F1 分数和 AUC 值上达到最佳。这表明 LASSO 特征筛选方法能够有效减少冗余特征,而 XGBoost 模型则能够充分利用这些关键特征进行高效分类。相比之下,PCA 与决策树的组合在性能上相对较差。PCA 尽管在降维方面表现良好,但其线性变换的特性可能无法充分捕捉到 MRI 影像中复杂的非线性特征,决策树模型虽然解释性强,但在处理高维、复杂特征时容易过拟合,导致泛化能力不足。这些结果表明在影像组学分析中选择合适的特征筛选方法和分类模型至关重要。研究过程中引入 Attention 机制,这在影像组学特征提取中发挥重要作用。Attention 机制使模型能够更加聚焦于关键特征,进一步提升模型的预测能力。未来的研究可以进一步优化 Attention 机制的应用,结合更多的深度学习模型,以期获得更高的预测精度。综上所述,通过有效的特征筛选和分类模型,医生可以更早、更准确地识别脑卒中的病灶特征,从而更好地制定治疗方案。

【参考文献】

- [1] Brás-Cruz R, Cruz I, Camões S. Pituitary apoplexy and cerebral infarction[J]. *BMJ Case Rep*, 2023, 16(4): e254507.
- [2] Li HM, Han YY, Sheng F, et al. Influence and significance of bilateral upper-extremity training on recovery of upper-extremity motor function for hemiplegic patients with mild-moderate cerebral apoplexy: a randomised controlled study[J]. *Afr Health Sci*, 2022, 22(3): 375-382.
- [3] 张月华. 缺血性卒中预后及其影响因素分析[J]. *吉林大学学报(医学版)*, 2012, 38(3): 437.
Zhang YH. Analysis of prognosis and its influencing factors in ischemic stroke[J]. *Journal of Jilin University (Medicine Edition)*, 2012, 38(3): 437.
- [4] Jin D, Su XJ, Jin YX, et al. Diagnostic value of MRI perfusion-weighted imaging and diffusion-weighted imaging parameters in cerebral apoplexy[J]. *Am J Transl Res*, 2023, 15(2): 1097-1106.
- [5] Li HY, Lee CH, Chia D, et al. Machine learning in prostate MRI for prostate cancer: current status and future opportunities[J]. *Diagnostics (Basel)*, 2022, 12(2): 289.
- [6] Park J, Kim J, Lewy T, et al. Spatial omics technologies at multimodal and single cell/subcellular level[J]. *Genome Biol*, 2022, 23(1): 256.
- [7] Song XY, Xu HY, Wang XL, et al. Use of ultrasound imaging Omics in predicting molecular typing and assessing the risk of postoperative recurrence in breast cancer[J]. *BMC Womens Health*, 2024, 24(1): 380.
- [8] Nisha B, Jose MV. DTMF: decision-based trimmed multimode approach filter for denoising MRI images[J]. *Soft comput*, 2024, 28(7): 6327-6342.
- [9] Zhou JG, Li GF, Meng Y, et al. Application of multimodal magnetic resonance imaging in green channel of acute and hyperacute ischemic stroke[J]. *Contrast Media Mol Imaging*, 2022, 2022(1): 2452282.
- [10] Reig B, Heacock L, Geras KJ, et al. Machine learning in breast MRI[J]. *J Magn Reson Imaging*, 2020, 52(4): 998-1018.
- [11] Jose MC, Arif M, Niessen WJ, et al. Automated classification of significant prostate cancer on MRI: a systematic review on the performance of machine learning applications[J]. *Cancers (Basel)*, 2020, 12(6): 1606.
- [12] Deepak S, Ameer PM. Automated categorization of brain tumor from MRI using CNN features and SVM[J]. *J Ambient Intell Human Comput*, 2021, 12(8): 8357-8369.
- [13] Suh CH, Lee JH, Chung MS, et al. MRI predictors of malignant transformation in patients with inverted papilloma: a decision tree analysis using conventional imaging features and histogram analysis of apparent diffusion coefficients[J]. *Korean J Radiol*, 2021, 22(5): 751-758.
- [14] Nguyễn K, Nguyễn M, Dang K, et al. Early Alzheimer's disease diagnosis using an XG-boost model applied to MRI images[J]. *Biomed Res Ther*, 2023, 10(9): 5896-5911.
- [15] Bhaiya LP, Verma VK. Classification of MRI brain images using neural network[J]. *Int J Eng Res Appl*, 2012, 2(5): 751-756.
- [16] Bose G, Healy BC, Lokhande HA, et al. Early predictors of clinical and MRI outcomes using least absolute shrinkage and selection operator (LASSO) in multiple sclerosis[J]. *Ann Neurol*, 2022, 92(1): 87-96.
- [17] Ahmadi M, Sharifi A, Jafarian Fard M, et al. Detection of brain lesion location in MRI images using convolutional neural network and robust PCA[J]. *Int J Neurosci*, 2023, 133(1): 55-66.
- [18] Li XX, Xu C. Feature screening with conditional rank utility for big-data classification[J]. *J Am Stat Assoc*, 2024, 119(546): 1385-1395.
- [19] Yin J, Xu SH, Du YB, et al. Super resolution reconstruction of CT images based on multi-scale attention mechanism[J]. *Multimed Tools Appl*, 2023, 82(15): 22651-22667.
- [20] Yan HM, Fang CY, Qiao ZW. A multi-attention Uformer for low-dose CT image denoising[J]. *Signal Image Video Process*, 2024, 18(2): 1429-1442.
- [21] Wu G, Yang YL, Liu LJ. Chest CT radiomics is feasible in evaluating bone changes in chronic kidney diseases[J]. *Acta Radiol*, 2024, 65(6): 641-644.
- [22] Han L, Sun L, Wang C, et al. Internal carotid artery stenosis and occlusion based on machine learning: a comparative analysis of high-resolution MRI and CT angiography[J]. *J Radiat Res Appl Sci*, 2024, 17(3): 101010.

(编辑:黄开颜)