

◁ 中枢神经影像学 ▷

基于 T₁WI 增强不同机器学习模型鉴别胶质母细胞瘤与原发性中枢神经系统淋巴瘤林钱森¹, 余红², 潘美娟¹, 陈杰云¹, 孟莉²

(1. 福建医科大学附属泉州第一医院放射科, 福建 泉州 362000; 2. 中南大学湘雅医院放射科, 湖南 长沙 410008)

【摘要】目的: 基于 T₁WI 增强图像采用六种不同机器学习分类算法构建预测胶质母细胞瘤 (GBM) 与原发性中枢神经系统淋巴瘤 (PCNSL) 的模型, 比较不同机器学习模型的诊断效能。**方法:** 回顾性分析中南大学湘雅医院经病理证实的 GBM 57 例和 PCNSL 49 例患者的临床及影像资料。应用 ITK-SNAP 软件在术前 T₁WI 增强图像手动逐层勾画瘤体感兴趣区 (ROI)。基于慧医汇影放射组学 Radcloud 平台进行 ROI 影像组学特征提取并采用方差阈值法 (阈值>0.9)、单变量特征选择法 ($P<0.01$) 和最小绝对收缩选择算子 (LASSO) 进行特征降维, 筛选出的特征采用支持向量机、极致梯度提升、逻辑回归 (LR)、线性判别分析 (LDA)、随机森林、K 近邻等 6 种分类器构建影像组学预测模型。使用 5 折交叉验证方法进行验证, 采用受试者工作特征曲线下面积 (AUC) 评估 6 种预测模型的诊断效能, 模型之间 AUC 比较采用 DeLong 检验。**结果:** 共提取 1 688 个影像组学特征, 经过特征降维及筛选后保留显著特征 (5 折交叉验证、每组分别 25、10、31、17、14 个特征) 构建预测模型, 6 种模型中 LDA、LR 模型诊断效能最佳, 在 5 折交叉验证集中 LDA、LR 模型平均 AUC 分别为 0.965、0.958, 准确度为 87.8%、89.6%, 敏感度为 86.0%、86.0%, 特异度为 89.4%、93.0%。6 种模型 AUC 差异均无统计学意义 ($P>0.05$)。**结论:** 基于 T₁WI 增强图像影像组学特征构建机器学习模型可用于预测 GBM 与 PCNSL 且准确率较高, 其中 LDA、LR 模型诊断效能最佳。

【关键词】 胶质母细胞瘤; 中枢神经系统肿瘤; 磁共振成像**【中图分类号】** R739.41; R730.264; R445.2 **【文献标识码】** A **【文章编号】** 1008-1062(2024)01-0001-06

DOI:10.12117/jccmi.2024.01.001

Construction of different machine learning models based on T₁WI-enhanced images for differentiating between glioblastoma and primary central nervous system lymphomaLIN Qian-sen¹, YU Hong², PAN Mei-juan¹, CHEN Jie-yun¹, MENG Li²

(1. Department of Radiology, Quanzhou First Hospital Affiliated to Fujian Medical University, Quanzhou Fujian 362000, China;

2. Department of Radiology, Xiangya Hospital, Central South University, Changsha 410008, China)

Abstract: Objective: To construct models for predicting glioblastoma (GBM) and primary central nervous system lymphoma (PCNSL) using six different machine learning classification algorithms based on T₁WI-enhanced images, and to compare the diagnostic efficacy of different machine learning models. **Methods:** A retrospective analysis was conducted on the clinical and imaging data of 57 patients with pathologically confirmed GBM and 49 patients with PCNSL at Xiangya Hospital of Central South University. The ITK-SNAP software was used to manually outline the tumor region of interest (ROI) layer by layer on preoperative T₁WI-enhanced images. ROI imaging omics features were extracted based on the Radcloud platform, and the variance threshold method (threshold>0.9), univariate feature selection method ($P<0.01$), and least absolute shrinkage and selection operator (LASSO) were used for feature dimensionality reduction, and the screened features were used to construct an imageomics prediction model using six classifiers including support vector machine, extreme gradient boosting, Logistic regression (LR), linear discriminant analysis (LDA), random forest, and K-nearest neighbor. The 5-fold cross-validation method was used for validation, and the diagnostic performance of six predictive models was evaluated using the area under the curve (AUC), and the DeLong test was used for AUC comparisons between models. **Results:** A total of 1 688 imaging omics features were extracted, and the significant features (25, 10, 31, 17, and 14 features per group in 5-fold cross-validation, respectively) were retained after feature dimensionality reduction and screening to construct the prediction models, and among the 6 models, the LDA and LR models had the best diagnostic efficacy, and the average AUC of the LDA and LR models in the 5-fold cross-validation set was 0.965 and 0.958, respectively, with accuracy of 87.8% and 89.6%, sensitivity of 86.0% and 86.0%, and specificity of 89.4% and 93.0%. There was no statistically significant differences in AUC among the six models ($P>0.05$). **Conclusion:** Machine learning models based on T₁WI-enhanced image omics features can be used to predict GBM and PC-

【收稿日期】 2023-06-25; **【修回日期】** 2023-07-19**【作者简介】** 林钱森 (1990-), 男, 福建永春人, 主治医师。E-mail: 841142189@qq.com**【通信作者】** 孟莉, 中南大学湘雅医院放射科, 410008。E-mail: mengli96130@csu.edu.cn**【基金项目】** 2022 年度福建省自然科学基金面上项目 (2022J011463); 2023 年泉州市科技计划项目 (2023NS054)。

NSL with high accuracy, among which LDA and LR models have the best diagnostic efficacy.

Key words: Glioblastoma; Central Nervous System Neoplasms; Magnetic Resonance Imaging

原发性中枢神经系统淋巴瘤 (Primary central nervous system lymphoma, PCNSL) 和胶质母细胞瘤 (Glioblastoma, GBM) 是中枢神经系统最常见的两种原发性恶性肿瘤^[1], GBM 占有脑肿瘤的 14.6%, PCNSL 约占 1.9%^[2]。目前 GBM 的治疗方案是尽可能的手术切除加以术后辅助放化疗, 而 PCNSL 的治疗方案以高剂量甲氨蝶呤化疗及全脑放疗为主, 两者肿瘤的治疗方法有着本质上的区别, 因此术前准确诊断 GBM 和 PCNSL 至关重要^[3]。

随着高级神经影像技术的不断更新, 既往研究^[4-6]通过磁共振波谱成像、扩散张量成像及灌注加权成像等神经影像技术, 以期能够有效鉴别 GBM 与 PCNSL。但是这些功能成像技术在数据测量分析中, 感兴趣区域 (Region of interest, ROI) 勾画仅为病变的某个局限区域, 测量结果差异较大, 且不同研究采用参数不一, 所得研究结果各有不同, 因此最优的诊断参数和阈值仍然难以确定。

近年, 随着影像组学的发展, 从医学影像图像中提取大量肉眼无法识别的影像特征, 全面、无创、定量地评估肿瘤的异质性, 为临床诊疗提供客观的依据^[7], 已逐渐应用于各种疾病的定性诊断、分期及疗效预后评估。本研究拟基于 T₁WI 增强图像采用六种不同机器学习分类算法构建预测 GBM 与 PCNSL 的模型, 进而探讨最优的预测模型。

1 资料与方法

1.1 研究对象

回顾性分析我院经手术切除或穿刺活检病理证实的 GBM 及 PCNSL 患者的临床资料及术前的 MRI

影像学资料。纳入标准: ①依据第 5 版 WHO 中枢神经系统肿瘤分类确诊为 GBM 和 PCNSL 患者; ②头颅 MR 平扫+增强检查图像清晰完整; ③患者接受 MRI 检查前未行手术或放、化疗等治疗; ④临床资料完整。排除标准: ①接受过治疗后的复发性肿瘤; ②继发于系统性淋巴瘤或血管内淋巴瘤。

1.2 MR 检查

MR 扫描使用多台不同的 MR 扫描仪, 反应影像数据的异构性, 包括 GE Premier 3.0T、Signa HDxt 1.5T 及 Siemens Prisma 3.0T、Aera 1.5T 磁共振扫描仪和头部线圈, 均进行常规头颅 MRI 平扫增强检查。增强扫描采用钆喷酸葡胺经肘静脉注射, 剂量 0.1 mmol/kg, 流速 2~4 mL/s。横轴位 T₁WI 增强扫描参数: TR 500~4 000 ms, TE 7.2~28.6 ms, 层厚 5 mm, 层间距 1 mm, 视野 (18~20) cm×(23~24) cm。

1.3 影像组学分析

1.3.1 图像预处理和肿瘤分割

所有 MRI 图像进行 N4 偏置校正并重新采样为 1 mm×1 mm×1 mm 体素大小, 减少图像异质性对模型训练造成偏差。使用 ITK-SNAP (version 3.8.0, <http://www.itksnap.org>) 开源软件手工对所有肿瘤病灶进行 ROI 分割。参考神经影像标注专家共识^[8], 由一位 5 年以上工作经验的神经放射亚专业医师采用盲法对数据进行手工勾画, 并由另一位具有 10 年工作经验的副主任医师审核, 共同确定最终的 ROI。勾画 ROI 前先进行统一培训, 强调勾画规范, 沿肿瘤病灶边缘逐层勾画出 ROI, 包含肿瘤实体及坏死囊变区域并尽可能避开瘤周水肿, 若同一患者多个病灶应全部予以勾画 (图 1)。




图 1 T₁WI 增强图像中 ROI 勾画。图 1a, 1b: 女, 57 岁, 右侧岛叶、基底节区 GBM。图 1a 为 T₁WI 增强示病变不均匀强化, 图 1b 为勾画瘤体 ROI。图 1c, 1d: 男, 50 岁, 左额叶、基底节区 PCNSL。图 1c 为 T₁WI 增强示病变呈多发结节团块, 图 1d 为勾画瘤体 ROI。

Figure 1. ROI in enhanced T₁WI. Figure 1a, 1b: Female, 57 years old, GBM of the right insular lobe and basal ganglia region. Figure 1a: T₁WI enhancement shows heterogeneous enhancement of the lesion. Figure 1b: Post-ROI delineation. Figure 1c, 1d: Male, 50 years old, PCNSL of the left frontal lobe and basal ganglia region. Figure 1c: T₁WI enhancement shows multiple nodular masses. Figure 1d: Post-ROI delineation.

1.3.2 特征提取及筛选

本研究基于慧医汇影放射组学 Radcloud 平台从两组 T₁WI 增强图像中提取定量影像组学特征,分别为一阶特征、形状特征、纹理特征和小波变换特征,共 1 688 个特征值。为了减少冗余特征,分别经方差阈值法 (阈值>0.9)、单变量特征选择法 ($P<0.01$) 和最小绝对收缩选择算子 (Least absolute shrinkage and selection operator,LASSO) 三种方法对特征进行降维,筛选出的最佳影像组学特征值。

1.3.3 不同机器学习模型的构建及验证

将研究对象按照 8:2 随机分为训练集 (n=85) 和验证集 (n=21),基于慧医汇影放射 Radcloud 平台上分别使用 6 种不同机器学习分类算法对训练集数据构建基于筛选出的最佳影像组学特征的诊断预测模型,包括支持向量机 (Support vector machine,SVM)、随机森林(Random forest,RF)、极致梯度提升 (Extreme gradient boosting,XGBoost)、线性判别分析 (Linear discriminant analysis,LDA)、K 近邻 (K-nearest neighbor,KNN)、逻辑回归 (Logistic regression,LR),绘制预测模型的 ROC 曲线,评估模型诊断的敏感度及特异度,通过曲线下面积 (AUC) 评估预测模型的诊断效能。通过 5 折交叉验证的方法对预测模型进行验证,即将纳入样本随机分为 5 份,每次不重复地取其中一份作为验证集,其他作为训练集,计算 5 组验证集的 AUC 及其总的平均值。根据 6 种不同模型相对应的 AUC 及准确度、敏感度、特异度、精准率、F1-score 分数等筛选出最优的预测模型。

1.4 统计学分析

采用 SPSS 25.0 统计软件对临床资料数据进行统计学分析,符合正态分布的连续性变量以 $\bar{x}\pm s$ 表示,不符合正态分布以中位数 (四分位间距) 表示,两组间比较采用独立样本 t 检验。分类变量以频数 (构成比) 表示,采用卡方检验。以 $P<0.05$ 为差异具有统计学意义。

不同机器学习模型诊断效能评估基于 Radcloud 平台进行,根据平台后处理绘制模型的 ROC 曲线及模型的 AUC、准确度、敏感度、特异度等评估

模型的诊断效能。模型之间 AUC 比较采用 DeLong 检验。

2 结果

2.1 临床资料

本研究共纳入研究对象 106 例,其中 GBM 57 例、PCNSL 49 例。两组患者的年龄、性别的差异均无统计学意义 ($P>0.05$),见表 1。

表 1 GBM 与 PCNSL 患者临床资料比较

	PCNSL 组	GBM 组	t/χ^2	P
年龄 (岁)	53.76±11.93	55.68±11.17	-0.859	0.392
性别 (例)			0.398	0.528
男	28 (57.1%)	36 (63.2%)		
女	21 (42.9%)	21 (36.8%)		
肿瘤位置 (例)			10.737	0.001
幕上	40 (81.6%)	55 (96.5%)		
幕下	1 (2.0%)	2 (3.5%)		
幕上/幕下	8 (16.3%)	0 (0%)		
病灶数量 (例)			13.786	0.000
单发	26 (53.1%)	49 (86.0%)		
多发	23 (46.9%)	8 (14.0%)		

2.2 影像组学特征的筛选结果

基于 T₁WI 增强图像共提取 1 688 个影像组学特征。分别经过方差阈值法 (阈值>0.9)、单变量特征选择法 ($P<0.01$) 降维、LASSO 等 3 种方法去除冗余的特征 (图 2) 得到最佳特征值,使用 5 折交叉验证、每组最优影像组学特征分别为 25、10、31、17、14 个特征参数。

2.3 不同机器学习预测模型的建立

基于筛选出的最佳影像组学特征分别使用 6 种不同机器学习分类算法构建预测模型,6 种预测模型 5 折交叉验证的平均 AUC、准确度、敏感度、特异度、精准率、F1-score 分数,具体数值见表 2。相应每个模型的 5 折交叉验证集绘制的 ROC 曲线见图 3。6 种模型在 5 折交叉验证集中的 AUC 两两比较差异均无统计学意义 ($P>0.05$)。

3 讨论

本研究通过对 57 例 GBM 与 49 例 PCNSL 术前




图 2 LASSO 降维特征筛选的路径 (图 2a)、系数 (图 2b)。

Figure 2. Path (Figure 2a) and coefficient (Figure 2b) of LASSO dimensionality reduction features.

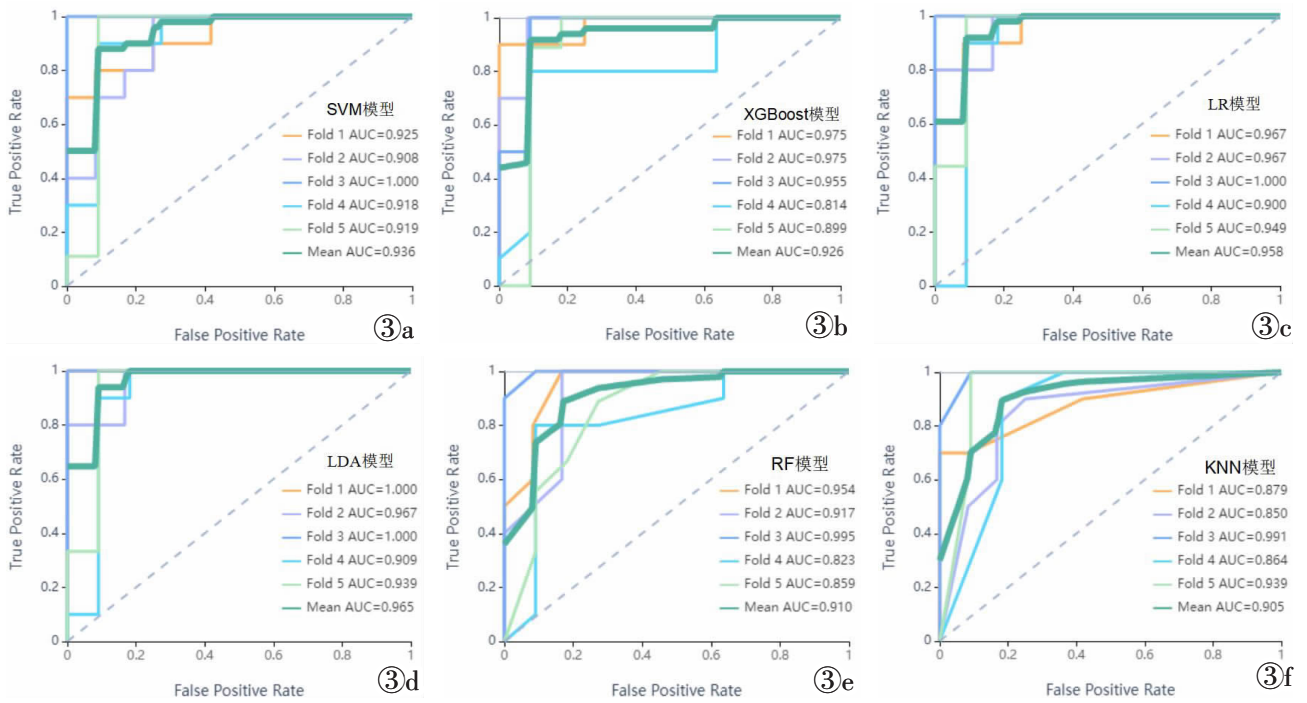


图 3 6 种不同机器学习预测模型 5 折交叉验证中的 ROC 曲线。图 3a:SVM 模型;图 3b:XGBoost 模型;图 3c:LR 模型;图 3d:LDA 模型;图 3e:RF 模型;图 3f:KNN 模型。

Figure 3. ROC curves in 5-fold cross-validation of six different machine learning prediction models. Figure 3a: SVM model; Figure 3b: XGBoost model; Figure 3c: LR model; Figure 3d: LDA model; Figure 3e: RF model; Figure 3f: KNN model.

表 2 6 种不同机器学习模型预测 GBM 与 PCNSL 的效能

预测模型	AUC	95%CI	准确度	敏感度	特异度	精准率	F1-score
SVM							
训练集	0.992	0.925~1.000	0.960	0.954	0.966	0.956	0.956
验证集	0.936	0.816~1.000	0.897	0.860	0.912	0.902	0.872
XGBoost							
训练集	0.999	0.975~1.000	0.970	0.970	1.000	1.000	0.990
验证集	0.926	0.771~0.999	0.849	0.758	0.930	0.906	0.820
LR							
训练集	0.992	0.960~1.000	0.969	0.966	0.972	0.964	0.966
验证集	0.958	0.844~1.000	0.896	0.860	0.930	0.918	0.882
LDA							
训练集	0.989	0.947~1.000	0.958	0.954	0.962	0.954	0.954
验证集	0.965	0.827~1.000	0.878	0.860	0.894	0.884	0.864
RF							
训练集	0.999	0.996~1.000	0.997	1.000	0.996	0.994	0.998
验证集	0.910	0.757~0.999	0.816	0.754	0.894	0.872	0.794
KNN							
训练集	0.980	0.928~1.000	0.931	0.946	0.918	0.912	0.930
验证集	0.905	0.766~1.000	0.869	0.880	0.860	0.846	0.858

T₁WI 增强图像的肿瘤区域逐层勾画、提取 1 688 个影像组学特征,采用方差阈值法(阈值>0.9)、单变量特征选择法($P<0.01$)和 LASSO 进行特征降维,基于筛选出的影像组学特征构建 SVM、XGBoost、LR、LDA、RF 及 KNN 共 6 种机器学习分类诊断模型并比较 6 种模型的诊断效能,结果显示基于 T₁WI 增强图像构建的机器学习模型可用于术前预测 GBM 与 PCNSL 且具有较高的诊断效能,其中以 LDA、LR 模

型为最佳 AUC 分别达 0.965、0.958。

3.1 影像组学鉴别 GBM 与 PCNSL 的应用价值

本研究结果初步提示,影像组学通过提取人类肉眼无法识别的图像特征,构建的诊断模型对于 GBM 与 PCNSL 诊断价值较高,有利于提高术前肿瘤诊断率,为疾病精准、个体化诊疗提供客观依据。Suh 等^[9]基于随机森林模型的多参数影像组学预测非典型 GBM 和 PCNSL 具有较高诊断效能(AUC 达

0.921、95%CI 0.825~0.990), 并且比神经放射医师阅片和表观扩散系数 (Apparent diffusion coefficient, ADC) 值具有更好的诊断性能 (AUC 分别为 0.759、95%CI 0.656~0.861 和 0.684、95%CI 0.560~0.809)。Kang 等^[10]研究通过从 70 例 GBM 和 42 例 PCNSL 的弥散加权成像 (Diffusion weighted image, DWI) 和常规 MR 图像中提取共 1 618 个影像组学特征进行影像组学研究, 结果显示基于 RF 模型 DWI 的诊断效能 (AUC 0.944) 优于神经放射医师阅片诊断 (AUC 0.896~0.930)。史云峰等^[11]基于增强 T₁WI 图像及 ADC 的灰度共生矩阵纹理特征分析研究表明 T₁WI 增强图像中的熵和能量对预测 PSNCL 与 GBM 的诊断效能 (AUC 分别为 0.81、0.76) 均高于 ADC 图像中的熵和能量 (AUC 分别为 0.72、0.69), 提示 T₁WI 增强图像纹理分析更有助于鉴别诊断 GBM 与 PCNSL, 这可能 T₁WI 增强图像具有强化特征、血流灌注等信息及组织间对比度明显, 更有利于获取肿瘤的异质性, 从而使得 T₁WI 增强图像构建的影像组学模型可能更稳健^[12]。

T₁WI 增强图像影像组学分析已广泛应用于脑肿瘤诊断的相关研究中^[13-15]。Kim 等^[16]基于 LR 模型对比多参数 MRI 成像鉴别 GBM 与 PCNSL 的诊断价值发现基于 T₁WI 增强图像的 LR 模型诊断效能较高 (AUC 0.897) 优于常规 T₂WI 及 ADC 图像 (AUC 分别为 0.458、0.649)。Alcaide-Leon 等^[17]通过对 35 例 PCNSL 及 71 例胶质瘤患者 T₁WI 增强图像进行影像组学方法与神经放射医师阅片比较发现, 基于 T₁WI 增强图像纹理特征的 SVM 分类在鉴别胶质瘤及 PCNSL (AUC 0.877、95%CI 0.798~0.955) 不劣于亚专业放射医师阅片 (AUC 0.845、95%CI 0.757~0.933)。McAvoy 等^[18]通过对 160 例 GBM 及 160 例 PCNSL 的 T₁WI 增强图像采用基于卷积神经网络的迁移学习方法构建预测模型, 结果显示预测 GBM 与 PCNSL 的 AUC 分别为 0.94、0.95。郑成君等^[19]基于磁共振 T₁WI 增强序列使用影像组学特征构建的 RF 模型, 在测试组中预测 GBM 与 PCNSL 的 AUC 为 0.87, 5 折交叉验证的平均 AUC 为 0.87。以上研究均表明基于 T₁WI 增强构建预测 PCNSL 与 GBM 影像组学模型具有较高的诊断效能, 但方法较单一且均略低于本研究中构建的 LDA、LR 模型。T₁WI 增强序列作为日常工作中最常规最普遍应用的序列, 使得本研究构建的 T₁WI 增强机器学习预测模型具有较高的临床推广价值。

3.2 不同机器学习分类模型诊断效能比较

Kim 等^[19]通过对 78 例 GBM 及 65 例 PCNSL 患者的 T₁WI 增强图像采用 LR、RF、SVM 3 种不同算

法建立预测模型, 结果显示 LR 预测模型诊断效能最好 (AUC 0.896)。与本研究中 LR 预测模型诊断效能 (AUC 0.958) 高于 SVM 模型 (AUC 0.936)、RF 模型 (AUC 0.910) 相仿, LR 模型具有可解释性及实用性强, 在医学领域得到了广泛的应用^[20]。

Chen 等^[21]通过对 76 例 GBM 及 62 例 PCNSL 患者的 T₁WI 增强图像采用 LDA、SVM、LR 3 种不同算法建立模型以提高预测 GBM 与 PCNSL 的诊断性能, 结果显示 LDA 模型诊断效能最佳 (AUC 0.977、敏感性 0.955), 优于 LR 模型 (AUC 0.966、敏感性 0.975) 及 SVM 模型 (AUC 0.822、敏感性 0.671)。Kang 等^[10]基于 T₁WI 增强序列构建 8 种影像组学模型 (k 最近邻、朴素贝叶斯分类器、决策树、自适应增强、LDA、RF、线性核 SVM、径向基函数 SVM) 以区分 GBM 和 PCNSL, 结果显示 LDA 模型性能最佳 (测试集 AUC 0.976、验证集 AUC 0.968)。以上研究与本研究结果显示预测 GBM 与 PCNSL 不同模型中的 LDA 模型诊断效能最佳相仿 (测试集 AUC 0.989、验证集 AUC 0.965)。根据 LDA 模型原理, 在训练集时, GBM 和 PCNSL 鉴别中同类型样本的投影点将尽可能接近, 而异类型数据的投影点会尽可能远离^[22], 能够学习到有效区分 GBM 和 PCNSL 的投影直线。而在验证集中, 将待预测样本数据投影到训练集学习到的 GBM 和 PCNSL 直线上, 根据投影点的位置判断其属于 GBM 或 PCNSL。本研究中 LDA 诊断模型在 GBM 和 PCNSL 验证集中诊断效能最佳, 也进一步验证了 LDA 预测模型能够有效的最大化区分 GBM 和 PCNSL 可能重叠的特征。

3.3 本研究的局限性

①本研究为单中心研究、样本量相对较少, 尚需进一步扩大样本量、纳入多中心数据进行验证研究。②感兴趣勾画分割及影像组学特征未进行一致性评估。鉴于本研究使用相对严谨、依次递进三步的特征筛选方法及采用专家共识标注方法进行感兴趣勾画, 而未进行一致性评估如组内相关系数检验。③未纳入其他序列图像进行多参数影像组学分析。相对于其他序列图像, T₁WI 增强图像在鉴别诊断 GBM 与 PCNSL 更具优势, 因此本研究首先基于 T₁WI 增强图像进行研究, 未来将纳入更多序列进一步多参数 MRI 组学研究。

综上所述, 基于术前 T₁WI 增强图像构建多种机器学习模型能够有效地鉴别 GBM 和 PCNSL, 其中以 LDA、LR 模型的诊断效能最佳, 有助于提高术前准确诊断, 为疾病术前决策、精准治疗提供客观依据。

[参考文献]

- [1]Alcaide-Leon P, Dufort P, Geraldo AF, et al. Differentiation of Enhancing Glioma and Primary Central Nervous System Lymphoma by Texture-Based Machine Learning [J]. AJNR, 2017, 38(6): 1145-1150.
- [2]Ostrom QT, Cioffi G, Waite K, et al. CBTRUS Statistical Report: Primary Brain and Other Central Nervous System Tumors Diagnosed in the United States in 2014-2018[J]. Neuro Oncol, 2021, 23(12 Suppl 2): iii1-iii105.
- [3]Chen Y, Li Z, Wu G, et al. Primary central nervous system lymphoma and glioblastoma differentiation based on conventional magnetic resonance imaging by high-throughput SIFT features[J]. Int J Neurosci, 2018, 128(7): 608-618.
- [4]Abdelsalam M, Gaballa G, Talaat M. Differentiation of Primary Central Nervous System Lymphoma From Glioblastoma: Quantitative Analysis Using Arterial Spin Labeling and Diffusion Tensor Imaging[J]. World Neurosurg, 2019, 123: e303-e309.
- [5]徐晨阳,李振江,丁炳谦,等. DTI 定量参数在胶质瘤与淋巴瘤鉴别中的应用价值 [J]. 中华神经外科疾病研究杂志,2018,17(4): 305-308.
- [6]Ohba S, Murayama K, Abe M, et al. Magnetic Resonance Imaging and Proton Magnetic Resonance Spectroscopy for Differentiating Between Enhanced Gliomas and Malignant Lymphomas[J]. World Neurosurg, 2019, 127: e779-e787.
- [7]Mayerhoefer ME, Materka A, Langs G, et al. Introduction to Radiomics[J]. J Nucl Med, 2020, 61(4): 488-495.
- [8]中国医师协会放射学分会“互联网+”影像学组. 中枢神经系统肿瘤的 MRI 影像标注专家共识 [J]. 国际医学放射学杂志,2021,44(4):378-384.
- [9]Suh HB, Choi YS, Bae S, et al. Primary central nervous system lymphoma and atypical glioblastoma: Differentiation using radiomics approach[J]. Eur Radiol, 2018, 28(9): 3832-3839.
- [10]Kang D, Park JE, Kim YH, et al. Diffusion radiomics as a diagnostic model for atypical manifestation of primary central nervous system lymphoma: development and multicenter external validation[J]. Neuro Oncol, 2018, 20(9): 1251-1261.
- [11]史云峰,钱丽霞,郭晓媛. 基于灰度共生矩阵纹理特征分析鉴别胶质母细胞瘤与原发中枢神经系统淋巴瘤 [J]. 中国介入影像与治疗学,2020,17(4):228-232.
- [12]Fan B, Li MJ, Wang XY, et al. Diagnostic value of gadobutrol versus gadopentetate dimeglumine in enhanced MRI of brain metastases[J]. J Magn Reson Imaging, 2017, 45(6): 1827-1834.
- [13]黄栎有,高先聪,王延花. 基于 MR 图像纹理特征建立机器学习模型在脑胶质瘤分级中的应用 [J]. 中国临床医学影像杂志, 2020,31(12):858-861.
- [14]Kunimatsu A, Kunimatsu N, Yasaka K, et al. Machine Learning-based Texture Analysis of Contrast-enhanced MR Imaging to Differentiate between Glioblastoma and Primary Central Nervous System Lymphoma[J]. Magn Reson Med Sci, 2019, 18(1): 44-52.
- [15]韩涛,刘显旺,徐震东,等. 构建多参数 MRI 影像组学脑膜瘤分级模型[J]. 中国临床医学影像杂志,2023,34(4):229-233.
- [16]Kim Y, Cho HH, Kim ST, et al. Radiomics features to distinguish glioblastoma from primary central nervous system lymphoma on multi-parametric MRI [J]. Neuroradiology, 2018, 60(12): 1297-1305.
- [17]Alcaide-Leon P, Dufort P, Geraldo AF, et al. Differentiation of Enhancing Glioma and Primary Central Nervous System Lymphoma by Texture-Based Machine Learning [J]. AJNR, 2017, 38(6): 1145-1150.
- [18]McAvoy M, Prieto PC, Kaczmarzyk JR, et al. Classification of glioblastoma versus primary central nervous system lymphoma using convolutional neural networks [J]. Sci Rep, 2021, 11(1): 15219.
- [19]郑成君,刘汉杰,丁一鸣,等. 基于影像组学特征构建机器学习模型鉴别原发性中枢神经系统淋巴瘤与胶质母细胞瘤 [J]. 中华神经外科杂志,2023,39(1):30-34.
- [20]Bisaso KR, Karungi SA, Kiragga A, et al. A comparative study of logistic regression based machine learning techniques for prediction of early virological suppression in antiretroviral initiating HIV patients[J]. BMC Med Inform Decis Mak, 2018, 18(1): 77.
- [21]Chen C, Zheng A, Ou X, et al. Comparison of Radiomics-Based Machine-Learning Classifiers in Diagnosis of Glioblastoma From Primary Central Nervous System Lymphoma [J]. Front Oncol, 2020, 10: 1151.
- [22]Li Y, Hong HG, Li Y. Multiclass linear discriminant analysis with ultrahigh-dimensional features [J]. Biometrics, 2019, 75(4): 1086-1097.