

- 16: 934822.
- [30] LARSEN N, VOGENSEN F K, VAN DEN BERG F W, et al. Gut microbiota in human adults with type 2 diabetes differs from non-diabetic adults[J]. PLoS One, 2010, 5(2): e9085.
- [31] SCHONHERR-HELLEC S, AIRES J. Clostridia and necrotizing enterocolitis in preterm neonates[J]. Anaerobe, 2019, 58: 6-12.
- [32] LI C, WANG N, ZHENG G, et al. Oral administration of resveratrol-selenium-peptide nanocomposites alleviates alzheimer's disease-like pathogenesis by inhibiting A β aggregation and regulating gut microbiota[J]. ACS Appl Mater Interfaces, 2021, 13(39): 46406-46420.
- [33] WANG S, ISHIMA T, QU Y, et al. Ingestion of *Faecalibaculum rodentium* causes depression-like phenotypes in resilient Ephx2 knock-out mice: A role of brain-gut-microbiota axis via the subdiaphragmatic vagus nerve[J]. J Affect Disord, 2021, 292: 565-573.
- [34] DAHL C, STIGUM H, VALEUR J, et al. Preterm infants have distinct microbiomes not explained by mode of delivery, breastfeeding duration or antibiotic exposure[J]. Int J Epidemiol, 2018, 47(5): 1658-1669.
- [35] LIU L, AO D, CAI X, HUANG P, et al. Early gut microbiota in very low and extremely low birth weight preterm infants with feeding intolerance: A prospective case-control study[J]. J Microbiol, 2022, 60(10): 1021-1031.
- (责任编辑: 刘建滔)

基于增强 T1 加权图像构建不同模型鉴别胶质母细胞瘤与单发脑转移瘤

陈佩仪, 黄海涛* (茂名市人民医院核磁共振科, 广东茂名 525000)

摘要: **目的** 探讨基于增强 T1 加权图像构建的不同模型鉴别胶质母细胞瘤 (GBM) 与单发脑转移瘤 (SBM) 的应用效果。**方法** 227 例患者 (GBM 120 例和 SBM 107 例) 随机分为训练集 ($n=159$) 与验证集 ($n=68$)。将增强 T1 加权图像导入 3D-Slicer 软件并手动勾画感兴趣区 (ROI), 然后进行影像组学特征提取并使用 t 检验、递归消除特征法及最小绝对收缩选择算子筛选特征。基于最佳特征, 分别运用逻辑回归 (LR)、支持向量机 (SVM) 及随机森林 (RF) 算法建立模型 (影像组学模型、临床模型、临床-影像组学模型), 通过绘制受试者工作特征曲线 (ROC) 及曲线下面积 (AUC) delong 检验评价各模型鉴别 GBM 与 SBM 诊断效能。**结果** GBM 与 SBM 病灶是否出血坏死及病灶分布情况 (幕上或幕下) 的比较差异有统计学意义 ($P<0.05$)。根据组内相关系数 (>0.75) 初步获取 965 个稳定性影像特征, 最终筛选得到 5 个最优影像特征构建模型, 影像组学模型和临床-影像组学模型 AUC 均大于 0.8, 其中 LR 模型鉴别效能最优 ($P<0.05$)。决策曲线分析显示在整个阈值概率范围内, 影像组学模型和临床-影像组学模型有相当的总体净效益。**结论** 基于增强后 T1 加权图像构建的影像组学模型和临床-影像组学模型对 GBM 与 SBM 具有较高的鉴别诊断效能。

关键词: 机器学习; 影像组学; 胶质母细胞瘤; 脑转移瘤; 列线图

中图分类号: R 739

文献标志码: A

文章编号: 2096-3610 (2024) 03-0266-07

Application of enhanced T1-weighted images to distinguish glioblastoma and solitary brain metastases

CHEN Pei-yi, HUANG Hai-tao* (MRI Department, Maoming People's Hospital, Maoming 525000, China)

Abstract: **Objective** To investigate the application effect of different models for distinguishing glioblastoma (GBM) from solitary brain metastases (SBM) based on enhanced T1-weighted images. **Methods** A total of 227 patients were included (107 cases of solitary brain metastasis) and were randomly divided into a training set ($n=159$) and a validation set ($n=68$) in a 7:3 ratio. The enhanced T1-weighted images were imported into the 3D-Slicer software, and the regions of interest (ROI) were manually delineated. Then, radiomics features were extracted and feature selection was performed using t -tests, recursive feature elimination, and least absolute shrinkage and selection operator. Based on the optimal features, logistic regression (LR), support vector machines (SVM), and random forest (RF) algorithms were used to establish models. The diagnostic performance

收稿日期: 2023-12-24

基金项目: 茂名市科技计划项目 (210414114551211)

作者简介: 陈佩仪 (1988-), 女, 本科, 主治医师, E-mail: 13423521692@163.com

通信作者: 黄海涛 (1988-), 男, 硕士, 主治医师, E-mail: 285668249@qq.com

of the models in distinguishing between glioblastoma and solitary brain metastasis was evaluated using receiver operating characteristic (ROC) curves and the AUC Delong test, and nomogram were drawn. **Results** There were significant differences in the presence of hemorrhage or necrosis and location above or below the tentorium ($P < 0.05$). Based on the intraclass correlation coefficient (ICC) ($ICC > 0.75$) within the group, 966 stable imaging features were initially obtained, and 5 optimal imaging features were finally selected to construct the models. The area under the ROC curve (AUC) of the radiomics model and the clinical-radiomics model were both greater than 0.8. The logistic regression model had the best diagnostic performance, and a nomogram was drawn to visualize the model. Decision curve analysis showed that the radiomics model and the clinical-radiomics model had comparable overall net benefits across the entire range of threshold probabilities. **Conclusion** The radiomics model based on enhanced T1-weighted images are high diagnostic efficiency in distinguishing GBM from SBM.

Key words: machine learning; radiomic; glioblastoma; brain metastases; nomogram

胶质母细胞瘤 (GBM) 和单发性脑转移瘤 (SBM) 是成人常见的恶性脑肿瘤^[1], 两者的临床管理及治疗策略不同, 术前无创高效地区分两种肿瘤十分重要^[2]。GBM 与 SBM 的影像特征存在重叠, 常见病灶形态不规则、易出血坏死、大片瘤周水肿、明显不均匀强化等^[3-4]。此前许多研究尝试通过多种脑功能成像鉴别两者并取得了不错的效果^[5-6]。近年来影像组学在各种疾病, 尤其是在肿瘤的诊断、预后、预测等方面有广泛的应用^[7]。无论是基于常规 MRI 平扫序列还是多种功能成像的影像组学均表明许多肉眼无法识别的纹理特征可显著提高诊断效能^[8-9]。本研究分析了 107 例 SBM 和 120 例 GBM 患者的脑增强 T1 加权图像, 探讨基于不同机器学习算法模型能否提高 GBM 与 SBM 的诊断效能, 以期在术前无创且有效地区分两者。

1 材料和方法

1.1 研究对象

2021 年 4 月至 2023 年 11 月本院 SBM 107 例和 GBM 120 例患者资料, 按照 7:3 随机分为训练集与验证集。训练集 159 例, 其中 SBM 75 例, GBM 84 例; 验证集 68 例, 其中 SBM 32 例, GBM 36 例。纳入标准: (1) 治疗前 7 d 经脑 MRI 增强检查; (2) SBM 患者病理证实只有 1 个原发肿瘤, GBM 经组织病理学证实; (3) 肿瘤最长径大于 1 cm。排除标准: (1) MRI 检查前接受过治疗, 如放疗或手术治疗等; (2) MRI 检查的图像伪影较大, 不能清晰显示病灶; (3) 多发性脑转移瘤患者; (4) 既往共存其他恶性肿瘤史。收集所有病例的临床资料及传统影像特征, 包括性别、年龄、病灶是否有出血坏死、位置是在幕上或幕下、瘤周水肿比例 (瘤周水肿的最大径线/肿瘤的最大径线)、肿瘤体积。本研究经茂名市人民医院伦理委员会批准 (批准文号: PJ2021MI-K023-01)。

1.2 成像设备与 MRI 检查方法

经本院 MRI 扫描仪完成所有患者术前 MRI 检

查, 设备包括 1.5 T/3.0 T GE 扫描仪 (General Electric Company, 美国)、3.0 T 西门子扫描仪 (Siemens, 德国)、3.0 T 联影扫描仪 (uMR, 中国)。颅脑 T1WI (T1 Weight Image) 增强序列, 以钆双胺注射液为对比剂, 采用高压注射器以 0.1 mmol/kg 剂量经肘静脉以 2 mL/s 速率注射。扫描参数: T1WI 轴位, TR 300~1 800 ms, TE 6~15 ms, 激励次数 2~4 次, 视野 25 cm×25 cm, 层厚 1~7 mm。

1.3 影像组学分析

1.3.1 图像预处理及 ROI 分割 MRI 图像需进行预处理降低 MRI 扫描仪和序列参数差异的影响, 包括 N4 偏置场校正、重采样体素大小为 (1 mm×1 mm×1 mm)、体素强度值调整为 100 SI、Z-score 标准化。图像导入 3D-Slicer (v5.2.2) 中逐层勾画感兴趣区 (ROI), 尽量避免周围水肿或其他组织。使用开源工具包 Pyradiomics (<https://pyradiomics.readthedocs.io/en>) 提取特征, 包括一阶特征、形状特征、灰度共生矩阵特征、灰度级大小矩阵特征、灰度运行长度矩阵特征及滤波小波特征。由 2 名 MRI 影像诊断医生 (分别有 5、7 a 工作经验) 采用双盲法独立手动勾画 ROI, 将这两组 ROI 进行特征提取, 得到两组影像学特征然后进行组内相关系数 (ICC) 一致性检验。

1.3.2 特征筛选及建模 对临床因素进行单变量或多变量逻辑回归分析筛选独立临床因素构建临床模型。获取 $ICC > 0.75$ 的稳定影像组学特征后进行特征筛选降维以得到最优影像特征, 先后应用 t 检验、递归消除特征法及最小绝对收缩选择算子 (LASSO) 进行特征筛选。基于最优特征运用逻辑回归 (LR)、随机森林 (RF) 和支持向量机 (SVM) 算法构建影像组学模型及临床-影像组学模型 [结合临床独立预测因子和影像组学评分 (Rad-scores, RS) 构建临床-影像组学模型, RS 计算方法为最优特征与系数乘积之和], 并基于最优模型绘制列线图。计算训练集和验证集的受试者工作特征 (ROC) 曲线下面积 (AUC), 以评估临床模型、影像组学模型和临床-影像组学模型的鉴别性能。计

算3种模型的灵敏度、特异度和准确度。绘制决策曲线分析(DCA)量化不同阈值概率下的净收益以评估3种模型应用于验证集时的诊断效能。

1.4 统计学处理

采用Python(v3.11.0)和R软件(v4.1.2)(<http://www.r-project.org>)进行数据分析。计量资料使用Student's *t*检验或Mann-Whitney *U*检验,计数资料使用 χ^2 检验或Fisher精确概率法,两组间数据独立因素使用单变量和多变量逻辑回归分析。不同模型间的AUC比较采用delong检验。 $P<0.05$ 表示差异有统计学意义。

2 结果

2.1 病例基本资料

所有病例中男104例,女123例,年龄24~83岁,平均(56.82±11.91)岁。GBM组与SBM组的年龄、性别、瘤周水肿比例及肿瘤体积差异无统计学意义($P>0.05$);两组间病灶是否出血坏死及病灶分布(幕上或

幕下)情况比较差异有统计学意义($P<0.05$)。而训练集与验证集患者的年龄、性别、出血坏死及病灶分布情况差异无统计学意义($P>0.05$),见表1。通过单变量和多变量逻辑回归分析独立预测因子为病灶是否出血坏死及病灶位于幕上或幕下($P<0.05$ 或0.01),见表2。

2.2 模型构建及预测效能

经 $ICC>0.75$ 筛选出965个高稳定性特征,先后应用*t*检验、递归消除特征法及LASSO结合10倍交叉验证法进行特征筛选,在 $\lambda=0.099$ 处取得最优特征,最终得到5个最优特征(表3)。以这5个特征构建SVM、RF及LR算法影像组学模型,影像组学LR模型对SBM和GBM具有较佳的鉴别诊断效能,在训练集及验证集的AUC均最高(表4);SVM及RF模型的AUC值略低,但性能仍较好。影像组学LR模型与SVM模型的AUC在训练集中比较差异有统计学意义($P<0.05$),在验证集中比较差异无统计学意义($P>0.05$);影像组学LR模型与RF模型的AUC在验证集中比较差异有统计学意义($P<0.05$),在训练集中

表1 患者临床及影像学特征比较

特 征	GBM(<i>n</i> =120)	SBM(<i>n</i> =107)	训练集(<i>n</i> =159)	验证集(<i>n</i> =68)
年龄/岁	56.28±11.74	57.43±12.12	56.27±11.99	58.12±11.70
性别/例				
男/女	59/61	45/62	69/90	35/33
出血坏死/例	68	42 ^b	82	28
病灶位置/例				
幕上/幕下	84/36	59/48 ^a	103/56	40/28
瘤周水肿比例	1.11±0.52	1.22±0.57	1.17±0.55	1.15±4.90
肿瘤体积/cm ³	4.92±1.62	5.14±1.65	5.07±1.63	4.91±1.66

SBM与GBM比较:^a $P<0.05$,^b $P<0.01$;训练集与验证集比较均 $P>0.05$

表2 GBM与SBM的临床及传统影像特征逻辑回归分析

变量	单变量逻辑回归分析		多变量逻辑回归分析	
	OR(95% CI)	<i>P</i>	OR(95% CI)	<i>P</i>
年龄	1.01(0.15~2.01)	0.469	1.01(0.99~1.03)	0.478
性别	0.75(0.44~1.27)	0.284	0.70(0.40~1.21)	0.204
出血坏死	0.48(0.29~0.84)	0.009	0.41(0.23~0.72)	0.002
病灶位置	0.53(0.30~0.91)	0.021	0.46(0.26~0.81)	0.007
瘤周水肿比例	1.47(0.83~0.64)	0.180	1.49(0.82~2.73)	0.191
肿瘤体积	1.06(0.88~1.28)	0.507	1.04(0.85~1.27)	0.657

表3 最优影像组学特征

类 型	最优特征	系 数
一阶特征	wavelet.LLH_firstorder_Variance	4.5×10^{-6}
一阶特征	wavelet.HLL_firstorder_Range	-3.9×10^{-3}
灰度游程矩阵	wavelet.LHL_glrml_RunLengthNonUniformity	-0.5×10^{-6}
灰度尺寸区域矩阵	wavelet.HHH_glszm_SizeZoneNonUniformity	-0.1×10^{-2}
灰度尺寸区域矩阵	wavelet.LHL_glszm_SizeZoneNonUniformity	-2.3×10^{-4}

表 4 不同模型检验效能的比较

变 量		LR		RF		SVM	
		训练集	验证集	训练集	验证集	训练集	验证集
影像组学模型	AUC	0.95	0.96	0.89	0.87a	0.88b	0.87
	敏感度	0.85	0.85	0.97	0.91	0.85	0.88
	特异度	0.90	0.97	0.82	0.83	0.90	0.85
	准确度	0.87	0.91	0.90	0.87	0.87	0.87
临床模型	AUC	0.60	0.66	0.68	0.45a	0.57	0.63
	敏感度	0.91	0.91	0.88	0.82	0.80	0.77
	特异度	0.21	0.31	0.35	0.41	0.44	0.47
	准确度	0.59	0.60	0.70	0.59	0.73	0.77
临床-影像组学模型	AUC	0.91c	0.94	0.91	0.83a	0.85	0.81
	敏感度	0.83	0.76	0.95	0.91	0.81	0.86
	特异度	0.89	0.86	0.87	0.74	0.88	0.76
	准确度	0.76	0.81	0.92	0.82	0.84	0.81

AUC delong 检验, LR 与 RF 比较: ^a $P<0.05$; LR 与 SVM 比较: ^b $P<0.05$; 临床-影像组学 LR 模型与影像组学 LR 模型比较: ^c $P<0.05$

比较差异无统计学意义 ($P>0.05$); 影像组学 RF 模型与 SVM 模型的 AUC 在训练集和验证集中比较差异均无统计学意义 ($P>0.05$)。影像组学 LR 模型鉴别病例典型图见图 1。


基于两个临床独立预测因子构建临床模型, 其鉴别效能较差, 训练集及验证集的 AUC 分别为 0.60、0.66 (表 4)。临床模型的 LR 与 RF、SVM 的 AUC 在训练集中比较差异无统计学意义 ($P>0.05$), 在验证集中 LR 与 RF 比较差异有统计学意义 ($P<0.05$), 与 SVM 比较差异无统计学意义 ($P>0.05$); RF 模型与 SVM 模型的 AUC 在训练集和验证集中比较差异均无统计学意义 ($P>0.05$)。

临床-影像组学模型对 SBM 与 GBM 鉴别性能稍低于影像组学模型 (图 2, 表 4)。临床-影像组学模型 LR 与 RF、SVM 的 AUC 在训练集中比较差异无统计学意义 ($P>0.05$), 在验证集中比较差异有统计学意义 ($P<0.05$); RF 模型与 SVM 模型的 AUC 在训练集和验证集中比较差异均无统计学意义 ($P>0.05$)。

临床-影像组学模型对比影像组学模型的 AUC 在训练集差异有统计学意义 ($P<0.05$), 在验证集中比较差异无统计学意义 ($P>0.05$)。在所有模型中以影像组学 LR 模型最优, 绘制列线图将影像组学 LR 模型可视化; 列线图校准曲线显示模型在训练集和验证集上都具有良好的一致性, 实际值与预测值拟合曲线及其校正曲线均接近参考线, 显示预测结果与实际结果一致性较高 (图 3)。临床模型、影像组学模型、临床-影像组学模型的 DCA 表明, 对于区分 SBM 与 GBM, 影像组学模型、临床-影像组学模型在整体阈值范围内具有相当的总体净效益, 见图 3。


3 讨论

本研究共纳入 227 例的 GBM 和 SBM 患者, 旨在构建基于增强 T1 加权图像的不同算法模型并验证其术前鉴别效能, 结果发现, 临床模型、影像组学模型及临床-影像组学模型中, 影像组学模型及临床-影像组学模型具有较好的鉴别性能, 其中影像组学 LR 模型




A. 正确病例, 为幕下 GBM; B. 错判病例, 为偏实性的 GBM 并侧裂池脑膜播散 (黄箭头); C. 正确病例, 为脑室内 SBM; D. 错判病例, 以囊性为主的 SBM

图 1 影像组学 LR 模型鉴别典型图



A、B. 影像组学模型(训练集、验证集); C、D. 临床-影像组学模型(训练集、验证集); E、F. 3种模型检验效能比较(训练集、验证集)

图2 模型的ROC图



A. 基于影像组学LR模型列线图; B、C. 列线图训练集、验证集的校准曲线图; D. 3种模型的决策曲线分析图

图3 模型可视化及临床效用评估

最优, 基于影像组学LR模型绘制的列线图有望作为提高鉴别GBM与SBM准确率的可视化辅助工具。

一些常规的可观察到的影像特征, 如肿瘤增强改

变、瘤周水肿、肿瘤部位等形态学分析已被用来区分GBM和SBM, 但这些参数是非特异性的并且有主观因素干扰。进一步的检查如波谱成像(MRS)、灌注成

像(PWI)、扩张张量成像(DTI)、体素内非相干性运动(IVIM)等在一定程度上观察肿瘤细胞、反映微血管通透性和血管增殖的影像手段可以提高诊断的准确性,但对其扫描参数及后处理有较高要求,同时需要更多检查时间,这些先进的成像方式在临床实践中尚未能全部普及。本研究中纳入性别、年龄、病灶是否有出血坏死、位置是在幕上或幕下、瘤周水肿比例、肿瘤体积分析GBM与SBM的差异,其中肿瘤是否出现坏死、位于幕上或幕下差异有统计学意义($P<0.05$),GBM比SBM更易出血坏死,并较少出现在幕下。GBM和SBM存在相似的影像特征,基于传统MR成像鉴别诊断具有较大的挑战性^[10]。纳入的这2个独立因素,并由此构建的临床模型鉴别效能较低,可能与纳入因素少且该因素特异度较低有关。

影像组学提供了一种非侵入性的方法,可以从传统影像中提取大量信息,评估因视觉无法识别的内部肿瘤纹理。已有研究表明,影像组学在区分及预测不同类型的肿瘤方面具有较强的优势^[11-12]。此前研究已尝试使用影像组学鉴别SBM与GBM^[13-14],基于增强后T1加权图像及多参数融合的不同机器学习模型在训练集和验证集上都取得了较高的AUC,表现出良好的鉴别效能。但纳入的样本量偏少,本研究增加样本量并使用3种机器学习算法(LR、RF、SVM)分析增强后T1加权图像的影像特征,经过 $ICC>0.75$ 筛选出965个高稳定性特征,先后应用 t 检验、递归消除特征法及LASSO结合10倍交叉验证法筛选得到5个特征,其中2个是反映形态的一阶特征,余3个则是难以肉眼观察到的肿瘤微观特征,不同类别的特征可以为鉴别提供互补的信息。计算每个特征ICC选择稳定特征可以减少影像医生人工手动分割肿瘤ROI的误差。LASSO是一种用于在数据中选择重要特征的方法,会选择最重要的特征同时将一些特征的影响减小实现特征筛选,然后应用3种机器学习算法对SBM及GBM进行分类,其中LR模型效能最佳(训练集和验证集的AUC最高为0.95和0.96),分类能力稳定,准确度较高。这些分类算法均是稳定、强大、有效的机器学习分类器,主要用于神经影像学 and 分子生物学领域。其中LR模型更常用于二分类问题,并能够把影像特征通过影像组学评分(Rad-scores, RS)表现。LASSO筛选和LR分类器在鉴别SBM与GBM中有很好的协同作用,在本研究中具有较高的区分性能和高稳定性。

在对误判病例分析中发现,GBM并邻近脑室/脑池脑膜播散时(图1),经验丰富的影像医师可以较准

确诊断,而由于分割ROI并没有勾画脑膜病灶,导致影像组学模型可能错判;本研究共5例GBM并邻近脑室/脑池脑膜播散病例,其余病例模型分类正确。对于SBM中囊性为主的病灶也存在1例误判,提示类似表现的SBM病例较少。对于影像医师容易误判的病例,如幕下的GBM和脑室内的SBM,影像组学模型可准确区分。GBM并邻近脑室/脑池脑膜播散是少见病例,将单纯脑膜增厚强化纳入临床因素中分析可能会误导分类器,因为SBM更容易出现脑膜转移,区分局限性及弥漫性脑膜异常会更有意义。纳入更多类似病例同时ROI应包括脑膜病变应能提高准确率,这需要一个更大的训练集来再现工作中遇到的少见情况。

与以往的研究相比,基于增强后T1加权图像及多参数融合的不同机器学习模型鉴别GBM与SBM,在验证集中得出的AUC与本研究结果接近^[13-14]。与本研究关注肿瘤自身形态不同,Dong等^[15]基于瘤周水肿区域构建影像组学鉴别GBM和SBM,因为GBM瘤周包括肿瘤浸润和血管源性水肿,而SBM瘤周为血管源性水肿,但该方法的AUC值较低,或许增加参数及加大样本量可以提高效能。

本研究中临床-影像组学模型鉴别效能较单纯影像组学LR模型稍低,仅在训练集存在差异,可能与纳入的临床因素较少,且特异性较差有关;此外,由于GBM囊变坏死更多见,当SBM病灶以囊性为主时,临床-影像组学模型可能增加错误分类的概率。决策曲线分析表明在整个阈值概率范围内,影像组学模型与临床-影像组学模型具有相当的总体净收益,说明在临床实践中两者差异不大。临床-影像组学模型虽然AUC稍低,但纳入了临床因素,如瘤周动静脉分流、瘤周局限性脑膜播散等特异性较高的征象,可以进一步提高模型的分类能力。

列线图是一个结合各种独立因素将模型可视化的工具,已被广泛应用于诊断肿瘤。我们基于影像组学模型绘制的列线图将模型可视化,校准曲线显示列线图预测结果与实际结果一致性良好,验证了其作为诊断辅助工具的可行性。列线图的解读较多依赖于诊断医师的经验水平和技术水平,当纳入如临床评分量表得分、肿瘤形态学特征等受主观判断影响的因素时,不同医师解读存在差异,易导致诊断结果一致性降低,需要2名或更多诊断医师进行相互验证。本研究列线图基于最优模型绘制,由于是单纯的影像组学模型纳入的因素仅有影像组学评分(Rad-scores, RS)(图3A),RS计算方法为最优特征与系数乘积之和,故此

列线图鉴别结果会受到诊断医师手动勾画的病灶ROI影响;由2名MRI影像诊断医生双盲法独立手动勾画ROI有助于提高解读的一致性和准确性。列线图在区分原发性和继发性病变方面存在一定的局限性,主要是因为列线图无法展示多个变量之间的交互关系,这种情况应用合适的算法模型综合多个变量之间的交互作用提高鉴别效能。

需要注意的是,本研究存在一些局限性。首先,磁共振成像的图像为单中心样本,样本量较小,也未能进行外部验证集验证,而多中心数据集验证可提高模型的可靠性和可重复性。其次,本研究是单序列分析,没有纳入多参数、多模态构建模型,其应用受到限制,机器学习不够全面,融合模型能进一步提高诊断性能。最后在遇到一些病变体积较小、形态不规则的肿瘤时,因其形态特征不够明显,模型的鉴别能力可能会受到影响,此时需要结合更多序列参数来提高诊断的准确性。

综上所述,本研究基于增强后T1加权图像运用不同机器学习算法构建的影像组学模型能够在术前准确、无创地鉴别SBM与GBM,基于最优模型绘制的列线图,可作为辅助临床诊疗决策的工具。

参考文献:

- [1]SUNG H, FERLAY J, SIEGEL R L, et al. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. *CA Cancer J Clin*, 2021, 71(3): 209-249.
- [2]GRITSCH S, BATCHELOR T T, GONZALEZ CASTRO L N. Diagnostic, therapeutic, and prognostic implications of the 2021 World Health Organization classification of tumors of the central nervous system[J]. *Cancer*, 2022, 128(1): 47-58.
- [3]MEIER R, PAHUD DE MORTANGES A, WIEST R, et al. Exploratory analysis of qualitative MR imaging features for the differentiation of glioblastoma and brain metastases[J]. *Front Oncol*, 2020, 10: 581037.
- [4]何汉,邱文,黄海涛,等. 三维动脉自选标记和弥散张量成像定量参数在胶质瘤分级评估中的价值[J]. *广东医科大学学报*, 2021, 39(6): 707-710.
- [5]MAO J J, ZENG W K, ZHANG Q Y, et al. Differentiation between high-grade gliomas and solitary brain metastases: A comparison of five diffusion-weighted MRI models[J]. *BMC Med Imaging*, 2020, 20(1): 124.
- [6]赵琪瑞,曾颖卿,包含,等. 脑胶质瘤异柠檬酸脱氢酶基因突变的MRI影像基因组学研究进展[J]. *实用影像学杂志*, 2021, 37(11): 1903-1906.
- [7]ZHANG X M, RUAN S J, XIAO W B, et al. Contrast-enhanced CT radiomics for preoperative evaluation of microvascular invasion in hepatocellular carcinoma: A two-center study[J]. *Clin Transl Med*, 2020, 10(2): e111.
- [8]TATEISHI M, NAKAURA T, KITAJIMA M, et al. An initial experience of machine learning based on multi-sequence texture parameters in magnetic resonance imaging to differentiate glioblastoma from brain metastases[J]. *J Neurol Sci*, 2020, 410: 116514.
- [9]隋莲玉,任嘉梁,王佳宁,等. 不同机器学习模型对比增强T1加权图像影像组学鉴别脑转移瘤肺癌与非肺癌原发灶效能分析[J]. *磁共振成像*, 2022, 13(12): 74-80.
- [10]HALDORSEN I S, ESPELAND A, LARSSON E M. Central nervous system lymphoma: Characteristic findings on traditional and advanced imaging[J]. *Am J Neuroradiol*, 2011, 32(6): 984-992.
- [11]NGUYEN M V, CARLIER C, NICH C, et al. Fracture risk of long bone metastases: A review of current and new decision-making tools for prophylactic surgery[J]. *Cancers (Basel)*, 2021, 13(15): 3662.
- [12]KIM A R, CHOI K S, KIM M S, et al. Absolute quantification of tumor-infiltrating immune cells in high-grade glioma identifies prognostic and radiomics values[J]. *Cancer Immunol Immunother*, 2021, 70(7): 1995-2008.
- [13]符礼孔,李泽,孟思,等. 机器学习结合影像组学特征鉴别胶质母细胞瘤与脑转移瘤[J]. *磁共振成像*, 2023, 39(5): 697-700.
- [14]徐向东,梁芳蓉,韦瑞丽,等. 基于多参数MRI影像组学特征融合模型鉴别高级别胶质瘤与单发性脑转移瘤[J]. *磁共振成像*, 2022, 13(11): 53-59, 65.
- [15]DONG F, LI Q, JIANG B, et al. Differentiation of supratentorial single brain metastasis and glioblastoma by using peri-enhancing oedema region-derived radiomic features and multiple classifiers[J]. *Eur Radiol*, 2020, 30(5): 3015-3022.

(责任编辑:李 晓)