·数智神经外科学·

# 基于多参数 MRI 脑-肿瘤界面影像组学模型 预测脑膜瘤侵犯程度的应用研究

程星 王治超 李华宁 王协锋 尤永平

【摘要】 目的 开发并验证一种基于术前多参数 MRI 的脑-肿瘤界面影像组学脑膜瘤脑侵犯无创 性预测模型。方法 纳入 2014年9月至 2023年4月南京医科大学第一附属医院收治的 656 例脑膜瘤患 者,按照4:1比例随机分为训练集(524例)和测试集(132例),训练集用于预测模型的构建和优化,测试 集用于模型泛化能力的评估。术前均行 MRI检查(包括横断面 T,WI、增强 T,WI和 T,WI),图像经预处理 和分割后确定脑膜瘤感兴趣区,构建厚度为0.80、1.00和1.20 cm的脑-肿瘤界面。从3个序列感兴趣区 中提取影像组学特征,经单一值筛除、稳定性筛选组内相关系数[ICC(2,k)>0.90]后,采用五折交叉验 证最小绝对收缩和选择算子算法筛选特征,采用轻量梯度提升机、Logistic回归、多层感知器、随机森林、 支持向量机和极端梯度提升算法(XGBoost)共6种机器学习算法构建脑侵犯预测模型,绘制受试者工作 特征(ROC)曲线并计算曲线下面积评估模型预测效能, Delong检验比较不同模型的曲线下面积, 决策曲 线分析评估不同模型在不同阈值概率下的临床净收益。结果 共656例脑膜瘤患者中152例(23.17%) 存在脑侵犯,训练集有123例(23.47%)、测试集有29例(21.97%)。通过训练集五折交叉验证和测试集 评估,比较18个模型-厚度组合(6种机器学习算法×3种脑-肿瘤界面厚度)的预测效能,1.00 cm脑-肿瘤 界面的XGBoost模型表现优异,其训练集的曲线下面积为0.913(95%CI:0.886~0.937,P=0.000),准确度 为0.86、灵敏度为0.77、特异度为0.88;测试集的曲线下面积为0.897(95%CI:0.821~0.961,P=0.000),准 确度为0.90、灵敏度为0.72、特异度为0.95; Delong检验显示,该模型曲线下面积大于其他所有模型(均 P<0.05)。决策曲线分析显示,该模型在训练集(决策曲线分析正净收益面积0.087)和测试集(决策曲 线分析正净收益面积 0.094) 中均表现出最佳的临床净收益。结论 基于 1.00 cm 脑-肿瘤界面的 XGBoost模型展现出优异的预测效能,为脑膜瘤脑侵犯的术前评估提供一种准确、可靠的无创性预测方 法,对术前制定个性化手术方案、评估手术风险和预后具有重要临床意义。

【关键词】 脑膜瘤; 肿瘤浸润; 磁共振成像; 影像组学(非MeSH词); 机器学习; ROC曲线

# Noninvasive prediction of meningioma brain invasion via multiparametric MRI-based brain-tumor interface radiomics

CHENG Xing, WANG Zhi-chao, LI Hua-ning, WANG Xie-feng, YOU Yong-ping

Department of Neurosurgery, The First Affiliated Hospital of Nanjing Medical University, Nanjing 210029, Jiangsu, China

Corresponding author: YOU Yong-ping (Email: yypl9@njmu.edu.cn)

**[Abstract] Objective** To develop and validate a preoperative prediction model for meningioma brain invasion using radiomics features derived from multiparametric magnetic resonance imaging (MRI)-based brain-tumor interface (BTI). **Methods** A total of 656 meningioma patients diagnosed and treated were included at The First Affiliated Hospital of Nanjing Medical University from September 2014 to April 2023. Using stratified random sampling, patients were randomly divided in a 4 : 1 ratio into training set (524 cases) and testing set (132 cases). The training set was used for model construction and optimization, and the testing set for evaluating generalization ability. All patients underwent preoperative MRI examination including axial  $T_1WI$ , enhanced  $T_1WI$  and  $T_2WI$ . After image preprocessing and segmentation,

doi:10.3969/j.issn.1672-6731.2025.03.003

基金项目:国家自然科学基金资助项目(项目编号:82172667)

作者单位:210029 南京医科大学第一附属医院神经外科

通讯作者:尤永平, Email: yypl9@njmu.edu.cn

the meningioma region of interest was identified, and BTI with thicknesses of 0.80, 1.00 and 1.20 cm were constructed. Radiomics features were extracted from the regions of interest (ROI) across the 3 sequences. Following single - value elimination and interclass correlation coefficient [ICC (2, k) > 0.90] stability screening, features were selected using five - fold cross - validated least absolute shrinkage and selection operator (LASSOCV). Six machine learning (ML) algorithms, including light gradient boosting machine (LightGBM), Logistic regression (LR), multilayer perceptron (MLP), random forest (RF), support vector machine (SVM), and extreme gradient boosting (XGBoost) were utilized to build predictive models. The performance of each model was assessed using receiver operating characteristic (ROC) curve and the area under the curve (AUC). The significance of differences between ROC curves were compared using the Delong test. Decision curve analysis (DCA) was performed to evaluate the clinical net benefit of the models across different threshold probabilities. Results Among the 656 meningioma patients, 152 cases (23.17%) exhibited brain invasion, with 123 cases (23.47%) in the training set and 29 cases (21.97%) in the testing set. Through five-fold cross-validation in the training set and evaluation in the testing set, comparative analysis of the predictive performance of 18 model-thickness combinations (6 ML algorithms × 3 BTI thicknesses) showed that the XGBoost model constructed with a 1.00 cm BTI thickness demonstrated exceptional performance. This model achieved an AUC of 0.913 (95%CI: 0.886-0.937, P=0.000), accuracy of 0.86, sensitivity of 0.77, and specificity of 0.88 in the training set; and an AUC of 0.897 (95%CI: 0.821-0.961, P = 0.000), accuracy of 0.90, sensitivity of 0.72, and specificity of 0.95 in the testing set. Further Delong test showed that this model's AUC was significantly higher than all other models (P < 0.05, for all). DCA showed that this model demonstrated the best clinical utility with the highest net benefit area in both the training set (0.087) and the testing set (0.094). Conclusions The XGBoost model based on 1.00 cm BTI exhibited outstanding predictive performance, providing an accurate and reliable non-invasive method for preoperative evaluation of meningioma brain invasion. This method offers substantial clinical utility in facilitating personalized surgical planning, risk assessment, and prognosis evaluation.

**[Key words]** Meningioma; Neoplasm invasiveness; Magnetic resonance imaging; Radiomics (not in *MeSH*); Machine learning; ROC curve

This study was supported by the National Natural Science Foundation of China (No. 82172667). **Conflicts of interest:** none declared

脑膜瘤是成人最常见的原发性中枢神经系统 肿瘤之一,约占全部中枢神经系统肿瘤的40.8%<sup>[1]</sup>。 脑侵犯指脑膜瘤组织侵入邻近脑组织且缺乏结缔 组织层分隔的状态<sup>[2]</sup>,是非典型性脑膜瘤的重要诊 断标准之一。脑侵犯与手术方案密切相关<sup>[3]</sup>,不仅 是脑膜瘤患者术前癫痫发作和术后颅内出血的重 要危险因素<sup>[4-6]</sup>,而且显著增加肿瘤复发风险<sup>[7-8]</sup>,因 此,术前预测脑侵犯对制定个性化治疗方案和评估 预后具有重要意义。病理学检查是诊断肿瘤脑侵 犯的"金标准"[9],但存在诊断盲区[3]和取样不标准 等问题<sup>[10]</sup>。传统影像学虽是脑膜瘤术前评估的重 要手段,但在脑侵犯研究中尚未达成一致性结论, 且评估结果高度依赖医师经验。影像组学经 Python 语音中 PyRadiomics 库算法将高维影像学信息转化 为数字特征,客观、准确、无创地反映肿瘤特性<sup>[11]</sup>。 现有研究虽已报道影像组学在预测脑膜瘤脑侵犯 中的应用[12-14],但缺乏多种模型、不同脑-肿瘤界面 (BTI)厚度的比较及模型可解释性的探讨。基于 此,本研究以近9年南京医科大学第一附属医院诊

断与治疗的656例脑膜瘤患者为研究对象,开发并 验证脑膜瘤脑侵犯的影像组学预测模型,以为实现 术前风险分层、术中决策指导和个性化精准诊疗提 供依据。

#### 对象与方法

## 一、研究对象

 1.纳入与排除标准 (1)经组织病理学首次确 诊为脑膜瘤,并且经影像学证实肿瘤单发。(2)术前 完善头部 MRI检查,包括 T<sub>i</sub>WI、增强 T<sub>i</sub>WI和 T<sub>2</sub>WI。
 (3)年龄≥18岁。(4)排除多发性脑膜瘤、无法明确 脑侵犯状态、MRI图像质量欠佳、既往曾行颅脑手 术,以及临床资料不完整患者。(5)本研究经南京医 科大学第一附属医院伦理委员会审核批准(审批 号:2023-SR-366),并因回顾性研究豁免知情同意 要求。

2. 一般资料 选择2014年9月至2023年4月在
 我院神经外科住院治疗的脑膜瘤患者共656例,男
 性212例,女性444例;年龄18~85岁,平均(56.13±

· 176 ·

11.35)岁;肿瘤位于左侧大脑半球 304例(46.34%), 右侧大脑半球 280例(42.68%),中线结构 72例(10.98%);颅底病变 177例(26.98%),非颅底病变
479例(73.02%);肿瘤最大径 < 4 cm者 361例(55.03%),≥4 cm者 295例(44.97%);WHO 1级为382例(58.23%),WHO 2~3级为 274例(41.77%);</li>
412例(62.80%)合并瘤周水肿;67例(10.21%)发生颅骨侵犯;172例(26.22%)"脑膜尾征"阳性。

二、研究方法

1.脑膜瘤脑侵犯的诊断标准 光学显微镜观察 诊断脑侵犯,病理学表现为肿瘤细胞呈不规则舌状 突起,侵入下层脑实质,无软脑膜层介入。满足以 下条件之一即明确为无脑侵犯:(1)光学显微镜下 未发现脑侵犯。(2)当缺乏邻近脑组织样本且无法 行光学显微镜检查时,由术者结合术中记录(包括 肿瘤是否浸润脑组织、肿瘤与脑组织分离难易程 度)和影像学表现综合判断,如果术中记录与影像 学表现均不明确或相互矛盾,则在本研究中排除该 病例。

2. 头部 MRI 检查 术前采用德国 Siemens 公司 生产的 Verio 3.0T MRI 扫描仪行 MRI 检查, 扫描序 列包括T<sub>1</sub>WI、增强T<sub>1</sub>WI和T<sub>2</sub>WI。(1)T<sub>1</sub>WI:重复时间 (TR)150~2938 ms、回波时间(TE)2.48~27.26 ms, 翻转角(FA)为20°~150°,扫描视野(FOV)为 240.00 mm×225.00 mm~284.79 mm×284.79 mm,矩 阵为256×240~640×556,激励次数(NEX)2次,层 厚4~5mm、层间距4~5mm,共20层,扫描时间 120 s,范围覆盖全脑。(2)增强T,WI:重复时间为 6.50~1600.00 ms, 回波时间 2.10~4.92 ms, 翻转角 9°, 扫描视野 234.38 mm×250.00 mm~396.74 mm× 396.74 mm,矩阵为256×208~1024×1024,激励次 数2次,层厚0.60~5.00 mm、层间距1 mm,共20层, 扫描时间180s,范围覆盖全脑。(3)T,WI:重复时间 2817~7567 ms,回波时间为91.00~167.94 ms,翻转 角为9°, 扫描视野为230.00 mm×230.00 mm~ 284.70 mm × 295.56 mm, 矩阵为 320 × 320 ~ 768 × 668, 激励次数 2次, 层厚 4~5 mm、层间距 4~5 mm, 共20层,扫描时间75s,范围覆盖全脑。

图像预处理与分割 (1)图像预处理:采用高级归一化工具(ANTs, https://github.com/ANTsX/ANTs)将增强T,WI图像配准至加拿大蒙特利尔神经病学研究所(MNI)标准空间(https://nist.mni.mcgill.ca/atlases),调整空间位置并将图像重新采

样。为保证每例患者3个序列图像的空间一致性, 将T<sub>1</sub>WI和T<sub>2</sub>WI图像精确配准至增强T<sub>1</sub>WI图像空 间,最终3个序列图像统一至相同空间尺寸(193× 229×229)和体素(1 mm×1 mm×1 mm);经 HD-BET 算法(https://github.com/MIC-DKFZ/HD-BET)对所有 图像进行颅骨剥离<sup>115</sup>;采用N4偏置场校正消除所 有图像的低频强度不均匀性;采用白质归一化工具 (WhiteStripe, https://github. com/muschellij2/ WhiteStripe)对影像学数据进行强度标准化处理<sup>[16]</sup>。 (2)图像分割:采用nn-UNet算法(https://github.com/ MIC - DKFZ/nnUNet) 自动勾画脑膜瘤感兴趣区 (ROI),由两位年资分别为5和10年的神经影像科 医师采用 3D Slicer 5.0.3 软件(https://www.slicer.org) 修正感兴趣区,意见不一致时协商达成一致。获得 感兴趣区后,采用 Python 语言(https://www.python. org)中SimpleITK库进行感兴趣区的三维数据处理, 在肿瘤轮廓处进行内外扩展,生成厚度为0.80、1.00 和 1.20 cm 的脑-肿瘤界面以探讨不同脑-肿瘤界面 厚度对脑侵犯预测模型预测效能的影响(图1a)。

4.特征工程与数据预处理 采用 Python 语言中 PyRadiomics 库(https://github.com/AIM - Harvard/ pyradiomics)进行影像组学特征提取,选择默认配 置,每例患者每种脑-肿瘤界面厚度的3个序列可提 取5733种特征(图1b)。首先,剔除单一值占比 > 80%的特征;然后,采用组内相关系数[ICC(2,k)] 评估特征稳定性,仅保留ICC(2,k)>0.90的特征(图 1c);其次,所有特征均经Z值(Z-score)标准化处理 达归一化;最后,采用五折交叉验证最小绝对收缩 和选择算子(LASSOCV)算法筛选出预测价值最佳 的特征(图1d)。本组患者按照4:1比例以基于随 机种子的计算机随机数生成法结合分层随机抽样 法(根据脑侵犯程度分层)随机分为训练集和测试 集,训练集用于预测模型的构建和优化,测试集用 于模型泛化能力的评估。

5.模型建立与可解释性 (1)模型建立:共采用 6种机器学习(ML)算法,包括轻量梯度提升机 (LightGBM)、Logistic 回归(LR)、多层感知器 (MLP)、随机森林(RF)、支持向量机(SVM)和极端 梯度提升算法(XGBoost)。通过网格搜索优化各模 型的关键超参数(如正则化强度、树的数量、学习 率、核函数类型等),并对训练集进行五折交叉验证 确定最优超参数组合,以提高模型预测效能和稳定 性。为解决训练数据类别不平衡问题,采用合成少



图1 影像组学特征提取与筛选 la 图像预处理与分割: 左图为经预处理后的 T<sub>1</sub>WI、增强 T<sub>1</sub>WI和 T<sub>2</sub>WI 图像; 右图为相应的肿瘤 分割结果(绿色轮廓表示 0.80 cm 的脑-肿瘤界面厚度,黄色轮廓表示扩展至 1.00 cm 的脑-肿瘤界面厚度,红色轮廓表示进一步扩展 至1.20 cm的脑-肿瘤界面厚度) 1b 影像组学特征分布比例图:内环为T,WI、增强T,WI和T,WI图像提取特征的分布,外环为各种 特征的占比 1c 基于组内相关系数特征的稳定性筛选结果:黑色区域为具有高稳定性而保留的特征[ICC(2,k)>0.90],灰色区域 为重复性不足而剔除的特征[ICC(2,k)≤0.90] 1d LASSOCV回归系数路径图:不同颜色曲线表示各特征系数随λ变化的轨迹, 垂直虚线标记经五折交叉验证确定的最优λ值,该位置的非零系数特征对应最终筛选出的预测价值最佳的特征子集 Figure 1 Radiomics feature extraction and selection Image preprocessing and segmentation: left figure was T<sub>1</sub>WI, enhanced T<sub>1</sub>WI, and T<sub>2</sub>WI images after preprocessing; right figure was corresponding tumor segmentation results with BTI marked by different colors (green indicates the 0.80 cm thickness range, yellow indicates the extended 1.00 cm thickness range, and red indicates the further extended 1.20 cm thickness range; Panel 1a). Distribution of radiomics features: the inner ring indicated the distribution across T<sub>1</sub>WI, enhanced T1WI and T2WI sequences; the outer ring indicated the proportion of specific feature types (Panel 1b). Feature stability assessment based on ICC: the black area indicated highly stable features retained for subsequent analysis [ICC (2, k) > 0.90], while the gray area indicated features excluded due to insufficient reproducibility [ICC (2, k) ≤ 0.90, Panel 1c]. LASSOCV regression coefficient path diagram: different colored curves indicated the trajectories of coefficient changes for various features. The vertical dashed line marked the optimal  $\lambda$  value determined through five-fold cross-validation, where non-zero coefficients corresponded to the final selected feature subset with optimal predictive value (Panel 1d).

数类过采样技术(SMOTE)对少数类样本进行过采 样,通过合成新的少数类样本平衡数据集,提高模 型对少数类的分类能力。每次五折交叉验证迭代 中仅对训练数据应用SMOTE,保证测试数据不受任 何形式的过采样影响,确保模型泛化能力评估的客 观性。随后,采用最优超参数在训练集中重新训练 数据得到各模型的最优模型,并在测试集中评估最 优模型的泛化能力。(2)模型可解释性分析:采用 Shapley加法解释(SHAP)进行模型可解释性分析, 深入探讨各影像学特征在脑膜瘤脑侵犯预测中的 贡献及其作用机制,为模型预测结果提供可靠的生物学解释。

6. 统计分析方法 采用 R 4.2.1 (http://www. Rproject.org)和 Python 3.9进行数据处理与分析。计 数资料以相对数构成比(%)或率(%)表示,采用  $\chi^2$ 检验。呈正态分布的计量资料以均数±标准差( $\overline{x}$ ± s)表示,采用单因素方差分析。采用 Python语言中 sklearn 库进行机器学习模型构建,绘制受试者工作 特征(ROC)曲线并计算曲线下面积(AUC),评估模 型区分能力。采用 Delong 检验比较不同模型的曲

表1 总体样	本与训练集	和测试集制	息者一般资料	斗的比较							
Table 1. Comparison of baseline characteristics among patients in the overall sample, training set and testing set											
观察指标	总体样本 (n=656)	训练集 (n=524)	测试集 (n=132)	$\chi^2$ 或F值	P值	观察指标	总体样本 (n=656)	训练集 (n=524)	测试集 (n=132)	$\chi^2 \vec{u} F \vec{u}$	P值
性别[例(%)]				0.238	0.888	最大径[例(%)]				3.357	0.187
男性	212(32.32)	167(31.87)	45(34.09)			<4 cm	361(55.03)	279(53.24)	82(62.12)		
女性	444(67.68)	357(68.13)	87(65.91)			≥4 cm	295(44.97)	245(46.76)	50(37.88)		
年龄( <u>x</u> ±s,岁)	$56.13 \pm 11.35$	$56.31 \pm 11.50$	$55.41 \pm 10.76$	0.334	0.716	WHO分级[例(%)]				0.050	0.975
肿瘤部位[例(%)	)]			2.220	0.695	1级	382(58.23)	304(58.02)	78(59.09)		
左侧大脑半球	304(46.34)	238(45.42)	66(50.00)			2~3级	274(41.77)	220(41.98)	54(40.91)		
中线结构	72(10.98)	55(10.50)	17(12.88)			合并瘤周水肿[例(%)]	412(62.80)	325(62.02)	87(65.91)	0.682	0.711
右侧大脑半球	280(42.68)	231(44.08)	49(37.12)			颅骨侵犯[例(%)]	67(10.21)	52( 9.92)	15(11.36)	0.238	0.888
肿瘤区域[例(%)	)]			0.274	0.872	"脑膜尾征"阳性[例(%)]	172(26.22)	135(25.76)	37(28.03)	0.280	0.869
颅底	177(26.98)	139(26.53)	38(28.79)			脑侵犯[例(%)]	152(23.17)	123(23.47)	29(21.97)	0.134	0.935
非颅底	479(73.02)	385(73.47)	94(71.21)								

One-way ANOVA for comparison of age, and  $\chi^2$  test for comparison of others, 年龄的比较采用单因素方差分析,其余指标的比较采用 $\chi^2$ 检验。WHO, World Health Organization,世界卫生组织

线下面积。决策曲线分析(DCA)评估不同模型在不 同阈值概率下的临床净收益。以*P*≤0.05为差异具 有统计学意义。

#### 结 果

本组 656 例胶质瘤患者中 152 例(23.17%)存在脑侵犯。总体样本按照 4:1 比例随机分为训练集(524 例)和测试集(132 例),以确保两组脑侵犯分布情况与总体样本一致,训练集有 123 例(23.47%)存在脑侵犯、测试集有 29 例(21.97%)存在脑侵犯。总体样本、训练集和测试集一般资料比较,差异无统计学意义(均 P>0.05,表1)。

经特征提取与筛选,0.80 cm 脑-肿瘤界面纳入 60种影像组学特征,其中19种来自T,WI、26种来自 增强T,WI、15种来自T<sub>2</sub>WI;1.00 cm 脑-肿瘤界面纳 入66种影像组学特征,其中21种来自T<sub>1</sub>WI、27种来 自增强T<sub>1</sub>WI、18种来自T<sub>2</sub>WI;1.20 cm 脑-肿瘤界面 纳入40种影像组学特征,其中11种来自T<sub>1</sub>WI、16种 来自增强T<sub>1</sub>WI、13种来自T<sub>2</sub>WI。通过在训练集中行 五折交叉验证以及在测试集中进行评估,比较18个 模型-厚度组合(6种机器学习算法×3种脑-肿瘤界 面厚度)的预测效能(表2,3;图2)。训练集中五折 交叉验证显示,1.00 cm 脑-肿瘤界面的XGBoost模型 (以下简称1.00 cm-XGBoost模型)预测效能优异,曲 线下面积为0.913(95%CI:0.886~0.937,P=0.000), 准确度为0.86、灵敏度为0.77、特异度为0.88。采用 Delong检验对18个模型-厚度组合的曲线下面积进 行两两比较,结果显示,1.00 cm-XGBoost模型大于 0.80 cm 脑-肿瘤界面的 LightGBM 模型(Z = 4.960, *P*=0.000)、LR模型(*Z*=2.559,*P*=0.011)、MLP模型 (Z = 2.387, P = 0.017)、RF 模型(Z = 4.152, P =0.000)、SVM 模型(Z = 2.807, P = 0.005)和 XGBoost 模型(Z=4.204, P=0.000), 1.00 cm 脑-肿瘤界面的 LightGBM 模型(Z = 5.301, P = 0.000)、RF 模型(Z = 3.728, P = 0.000)和SVM模型(Z = 3.475, P = 0.000), 以及 1.20 cm 脑 - 肿瘤界面的 LightGBM 模型(Z = 4.562, P = 0.000、LR 模型(Z = 2.280, P = 0.023)、 MLP模型(Z=3.765, P=0.000)、RF模型(Z=4.130, P = 0.000)、SVM 模型(Z = 2.567, P = 0.010)和 XGBoost 模型(Z=4.154, P=0.000), 然而与1.00 cm 脑-肿瘤界面的LR模型(Z=0.792,P=0.428)和MLP 模型(Z=1.086, P=0.277)差异无统计学意义。测 试集中1.00 cm-XGBoost模型同样优异,曲线下面积 为0.897(95%CI:0.821~0.961,P=0.000),准确度为 0.90、灵敏度为0.72、特异度为0.95。采用 Delong 检 验对18个模型-厚度组合的曲线下面积进行两两比 较发现,1.00 cm-XGBoost 模型大于 0.80 cm 脑-肿瘤 界面的 LightGBM 模型(Z = 2.896, P = 0.004)、LR 模 型 (Z = 2.684, P = 0.007)、MLP 模型 (Z = 2.321, P =0.020)、RF 模型(Z = 2.600, P = 0.009)、SVM 模型 (Z=2.769, P=0.006)和XGBoost模型(Z=2.853, P= 0.004), 1.00 cm 脑-肿瘤界面的 LightGBM 模型(Z= 2.019, P = 0.044)、RF 模型(Z = 2.532, P = 0.011)和 SVM 模型(Z = 2.055, P = 0.040), 以及 1.20 cm 脑-肿 · 180 ·

表2 训练集中不同机器学习模型的预测效能指标													
Table 2.         Predictive performance metrics of ML models in training set													
模型	准确度	灵敏度	特异度	AUC	95%CI	P值	模型	准确度	灵敏度	特异度	AUC	95%CI	P值
0.80 cm-LightGBM	0.77	0.69	0.79	0.828	0.789 ~ 0.864	0.000	1.00 cm-RF	0.81	0.61	0.87	0.855	0.815 ~ 0.891	0.000
$0.80 \mathrm{~cm}\text{-}\mathrm{LR}$	0.80	0.76	0.81	0.870	$0.834 \sim 0.901$	0.000	1.00 cm-SVM	0.77	0.79	0.77	0.854	0.815 ~ 0.888	0.000
0.80  cm-MLP	0.78	0.80	0.77	0.877	$0.845 \sim 0.907$	0.000	1.00 cm-XGBoost	0.86	0.77	0.88	0.913	0.886 ~ 0.937	0.000
$0.80 \mathrm{~cm}\text{-}\mathrm{RF}$	0.79	0.64	0.84	0.841	0.812 ~ 0.875	0.000	1.20 cm-LightGBM	0.77	0.61	0.83	0.836	$0.787 \sim 0.872$	0.000
$0.80 \mathrm{~cm}\text{-}\mathrm{SVM}$	0.79	0.76	0.80	0.866	0.829 ~ 0.899	0.000	1.20 cm-LR	0.80	0.78	0.80	0.876	$0.841 \sim 0.907$	0.000
0.80 cm-XGBoost	0.77	0.77	0.79	0.842	$0.807 \sim 0.874$	0.000	1.20 cm-MLP	0.79	0.71	0.82	0.836	$0.791 \sim 0.882$	0.000
1.00 cm-LightGBM	0.77	0.69	0.79	0.831	0.788 ~ 0.865	0.000	1.20 cm-RF	0.80	0.62	0.85	0.834	0.793 ~ 0.872	0.000
1.00 cm-LR	0.82	0.80	0.82	0.901	0.871 ~ 0.930	0.000	1.20 cm-SVM	0.79	0.78	0.80	0.872	0.839 ~ 0.904	0.000
1.00  cm-MLP	0.81	0.80	0.82	0.896	0.862 ~ 0.925	0.000	1.20 cm-XGBoost	0.77	0.73	0.78	0.838	0.797 ~ 0.875	0.000

LightGBM, light gradient boosting machine,轻量梯度提升机;LR, Logistic regression, Logistic 回归;MLP, multilayer perceptron,多层感知器; RF, random forest,随机森林;SVM, support vector machine,支持向量机;XGBoost, extreme gradient boosting,极端梯度提升算法;AUC, area under the curve,曲线下面积。The same for Table 3

表3 测试集中不同机器学习模型的预测效能指标

Table 3. Predictive performance metrics of ML models in testing set

模型	准确度	灵敏度	特异度	AUC	95%CI	P值	模型	准确度	灵敏度	特异度	AUC	95%CI	P 值
0.80 cm-LightGBM	0.75	0.81	0.55	0.775	0.664 ~ 0.865	0.000	1.00 cm-RF	0.78	0.52	0.85	0.799	0.699 ~ 0.882	0.000
0.80 cm-LR	0.73	0.78	0.59	0.764	0.649 ~ 0.863	0.000	1.00 cm-SVM	0.77	0.66	0.80	0.812	0.723 ~ 0.895	0.000
0.80 cm-MLP	0.77	0.83	0.59	0.784	$0.673 \sim 0.881$	0.000	1.00 cm-XGBoost	0.90	0.72	0.95	0.897	0.821 ~ 0.961	0.000
$0.80 \mathrm{~cm}\text{-RF}$	0.78	0.87	0.45	0.793	$0.697 \sim 0.879$	0.000	1.20 cm-LightGBM	0.80	0.52	0.88	0.786	0.677 ~ 0.885	0.000
$0.80 \mathrm{~cm}\text{-}\mathrm{SVM}$	0.74	0.81	0.52	0.763	$0.662 \sim 0.863$	0.000	1.20 cm-LR	0.79	0.62	0.83	0.787	0.681 ~ 0.882	0.000
0.80 cm-XGBoost	0.75	0.80	0.59	0.775	$0.677\sim 0.864$	0.000	1.20 cm-MLP	0.77	0.45	0.86	0.721	0.604 ~ 0.833	0.001
1.00 cm-LightGBM	0.75	0.72	0.76	0.815	0.712 ~ 0.903	0.000	1.20 cm-RF	0.80	0.55	0.86	0.797	0.683 ~ 0.890	0.000
1.00 cm-LR	0.77	0.62	0.81	0.799	$0.688 \sim 0.891$	0.000	1.20 cm-SVM	0.78	0.62	0.83	0.787	0.687 ~ 0.867	0.000
1.00 cm-MLP	0.78	0.59	0.83	0.807	$0.701 \sim 0.897$	0.000	1.20 cm-XGBoost	0.77	0.59	0.82	0.780	0.669 ~ 0.883	0.000

瘤界面的LightGBM模型(Z=2.492, P=0.013)、LR 模型(Z=2.313, P=0.021)、MLP模型(Z=3.414, P= 0.000)、RF模型(Z=2.533, P=0.011)、SVM模型 (Z=2.579, P=0.010)和XGBoost模型(Z=2.621, P= 0.009)。应注意,尽管训练集中1.00 cm-XGBoost模 型与1.00 cm-LR模型和1.00 cm-MLP模型的预测效 能相当,但测试集中1.00 cm-XGBoost模型的曲线下 面积大于 1.00 cm-LR 模型(Z = 2.118, P = 0.034)和 1.00 cm - MLP 模型(Z = 2.000, P = 0.046),表明 XGBoost 模型具有更强的泛化能力。上述结果表 明,1.00 cm-XGBoost 模型在测试集中预测效能最 佳,即1.00 cm脑-肿瘤界面厚度结合 XGBoost 算法 可以最有效捕获并利用关键影像组学特征,构建具 有卓越预测效能的模型。该模型采用的超参数配 置为:特征采样比例(colsample\_bytree)=0.80、最小 分裂损失( $\gamma$ ) = 0.10、学习率(learning rate) = 0.10、 最大树深(max\_depth) = 6、最小子权重 (min\_child\_weight) = 1、估计器数量(n\_estimators) =
100、正样本权重比例(scale\_pos\_weight) = 1、样本采
样比例(subsample) = 0.80。

为探究 SMOTE 法对 1.00 cm-XGBoost 模型效能 的影响, 对采用 SMOTE 法与不采用 SMOTE 法的模 型进行比较, 训练集经五折交叉验证结果显示, SMOTE 预处理与未预处理模型的曲线下面积分别 为 0.913 (95% CI: 0.886 ~ 0.937, P = 0.000)和 0.880 (95% CI: 0.849 ~ 0.911, P = 0.000); Delong 检验显示, SMOTE 预处理模型的曲线下面积大于未预处理模 型(Z = -3.246, P = 0.001)。进一步在测试集中验 证, SMOTE 预处理与未预处理模型的曲线下面积分 别为 0.897(95% CI: 0.821 ~ 0.961, P = 0.000)和 0.788 (95% CI: 0.694 ~ 0.881, P = 0.000); Delong 检验显示, SMOTE 预处理模型的曲线下面积亦大于未预处理 模型(Z = -2.061, P = 0.039),表明在不平衡数据集 的情况下, SMOTE 法可有效提高模型预测效能。



2b 测试集中 0.80 cm 脑-肿瘤界面的 ROC 曲线 2c 训练集中 1.00 cm 脑-肿瘤界面的 ROC 曲线 2d 测试集中 1.00 cm 脑-肿瘤界面 的 ROC 曲线 2e 训练集中 1.20 cm 脑-肿瘤界面的 ROC 曲线 2f 测试集中 1.20 cm 脑-肿瘤界面的 ROC 曲线 **Figure 2** ROC curves for 6 ML models at 3 BTI thickness in training set and testing set ROC curve for 0.80 cm BTI in the training set (Panel 2a). ROC curve for 0.80 cm BTI in the testing set (Panel 2b). ROC curve for 1.00 cm BTI in the training set (Panel 2c). ROC curve for 1.20 cm BTI in the testing set (Panel 2c). ROC in the testing set (Panel 2d). ROC curve for 1.20 cm BTI in the testing set (Panel 2f).

采用决策曲线分析验证 1.00 cm-XGBoost 模型 的临床应用价值(图 3)。训练集经五折交叉验证结 果显示,1.00 cm-XGBoost 模型的决策曲线分析正净 收益面积最大(0.087),其次依次为 1.00 cm-LR 模型 (0.077)、1.00 cm - MLP 模型(0.071)和 RF 模型 (0.070), 1.00 cm - SVM 模型的面积较小(0.057), 1.00 cm - LightGBM 模型最小(0.045)。测试集中 XGBoost 模型在较广泛的阈值概率区间内(10%~ 90%)保持正净收益,且明显高于其他模型,特别是 中等阈值概率区间(30%~75%), 1.00 cm-XGBoost

· 181 ·



LightGBM,轻量梯度提升机;LR,Logistic回归;MLP,多层感知器;RF,随机森林;SVM,支持向量机;XGBoost,极端梯度提升算法

图 3 6种机器学习模型在 3 种脑-肿瘤界面厚度下的训练集和测试集的决策曲线分析 3a 训练集中 0.80 cm 脑-肿瘤界面的决策曲 线分析 3b 测试集中 0.80 cm 脑-肿瘤界面的决策曲线分析 3c 训练集中 1.00 cm 脑-肿瘤界面的决策曲线分析 3d 测试集中 1.00 cm 脑-肿瘤界面的决策曲线分析 3e 训练集中 1.20 cm 脑-肿瘤界面的决策曲线分析 3f 测试集中 1.20 cm 脑-肿瘤界面的决 策曲线分析

Figure 3 DCA for 6 ML models at 3 BTI thickness in training set and testing set DCA with 0.80 cm BTI in the training set (Panel 3a). DCA with 0.80 cm BTI in the testing set (Panel 3b). DCA with 1.00 cm BTI in the training set (Panel 3c). DCA with 1.00 cm BTI in the testing set (Panel 3d). DCA with 1.20 cm BTI in the training set (Panel 3e). DCA with 1.20 cm BTI in the training set (Panel 3e). DCA with 1.20 cm BTI in the training set (Panel 3e). DCA with 1.20 cm BTI in the training set (Panel 3e).

模型保持稳定的高净收益优势,而其他模型则呈现 下降趋势。定量分析显示,1.00 cm-XGBoost模型的 决策曲线分析正净收益面积为0.094,大于次优模型 1.00 cm-MLP(0.041), 优势近2.30倍, 其他模型如
 1.00 cm-RF模型(0.041)、1.00 cm-LR模型(0.037)、
 1.00 cm-SVM模型(0.037)和1.00 cm-LightGBM模型



其对预测结果的正向或负向影响 4b SHAP热图显示影像组学特征在每例患者中的 SHAP 值分布(红色区域表示脑侵犯的预测概率增加,蓝色区域相反),SHAP 值越大、脑侵犯的预测贡献越大;f(x)曲线显示模型预测概率趋势,值越大、脑侵犯的预测概率越大 Figure 4 SHAP summary plot and heatmap of the 1.00 cm - XGBoost model in the testing set SHAP summary plot showed the contribution values of radiomic features to the prediction of brain invasion in meningiomas and their positive or negative impact on prediction results (Panel 4a). SHAP heatmap showed the distribution of SHAP values for radiomic features across each patient. Red areas indicated increased probability of predicting brain invasion present, while blue areas indicated the opposite; larger SHAP values indicated greater contribution to predicting brain invasion. The f (x) curve at the top indicated the model's prediction probability trend, with larger values indicating greater probability of predicting brain invasion (Panel 4b).

## (0.033)的正净收益面积更小。

对测试集中基于最优模型1.00 cm-XGBoost筛 选出的66种影像组学特征进行分析,结果显示,根 据预测贡献大小排名的前10位影像组学特征依次 为:增强T<sub>1</sub>-Rad-3、T<sub>1</sub>-Rad-5、T<sub>2</sub>-Rad-7、T<sub>2</sub>-Rad-25、增 强T<sub>1</sub>-Rad-1、T<sub>1</sub>-Rad-16、T<sub>1</sub>-Rad-2、T<sub>2</sub>-Rad-4、T<sub>1</sub>-Rad-1 和T<sub>2</sub>-Rad-24(图4)。其中,小波变换特征(例如增强 T<sub>1</sub>-Rad-3、T<sub>1</sub>-Rad-5)可以捕捉多分辨率下微观纹理 细节,揭示肿瘤微环境的局部空间关联性;灰度共 生矩阵(GLCM)和灰度区域大小矩阵(GLSZM)特征 (如T<sub>2</sub>-Rad-25、T<sub>1</sub>-Rad-16)可以揭示纹理复杂性和灰 度不均匀性与脑侵犯的密切关系。

#### 讨 论

本研究基于术前多参数 MRI 构建影像组学模型,以预测脑膜瘤脑侵犯,并探讨不同脑-肿瘤界面厚度对模型预测效能的影响,发现1.00 cm-XGBoost模型在测试集中表现出最佳预测效能,表明该模型可在术前精准预测脑侵犯,进而帮助临床医师制定个性化治疗方案,改善患者生活质量,对脑膜瘤围手术期预后管理具有重要意义。

癫痫发作风险评估是脑膜瘤围手术期预后管

理的核心内容之一。一项纳入176例脑膜瘤患者的 临床研究调整性别、年龄、肿瘤部位、肿瘤体积、瘤 周水肿体积和WHO分级等变量后进行多变量分 析,发现脑侵犯是术前癫痫发作的独立危险因素 (*OR* = 5.260,95%CI:1.520~18.150;*P* = 0.009)<sup>[4]</sup>。 此外,脑膜瘤脑侵犯患者通常需要更大的手术切除 范围,如对于非功能区脑膜瘤患者,术者需切除肿 瘤周围浸润组织<sup>[3]</sup>,可能导致术后颅内出血风险增 加。一项纳入817例脑膜瘤患者的临床研究调整性 别、年龄和肿瘤部位后进行多变量分析,发现脑侵 犯是术后颅内出血风险增加的独立危险因素(*OR* = 3.310,95%CI:1.360~8.007;*P* = 0.009)<sup>[6]</sup>。上述研 究表明,术前无创性预测脑膜瘤脑侵犯具有重要临 床价值。

MRI是重要的术前评估工具,广泛应用于脑肿 瘤的诊断与监测,但在脑膜瘤脑侵犯相关研究中, 影像学因素(如瘤周水肿)未得出一致性结论<sup>[17]</sup>。 此外,影像学评估具有一定的主观性,结果判读常 受放射科医师经验的影响。影像组学是一种从医 学影像中提取大量定量特征的技术,旨在通过高通 量数据分析揭示疾病的潜在生物学特征。通过分 析影像中纹理、形状、边缘等特征,提供较传统影像

· 183 ·

· 184 ·

学评估更客观、全面的疾病特征描述,目前已广泛 应用于三叉神经痛<sup>[18]</sup>、脑肿瘤鉴别诊断<sup>[19]</sup>等领域。 既往有影像组学用于脑膜瘤脑侵犯预测的研究,Yu 等<sup>[12]</sup>在一项纳入469例非典型性脑膜瘤患者的研究 中,从增强T<sub>1</sub>WI、T<sub>2</sub>WI和T<sub>2</sub>-FLAIR 3种序列中提取 肿瘤瘤体和瘤周水肿的影像组学特征,并采用LR 算法建模,测试集的曲线下面积达0.867(95%CI: 0.785~0.950)。Joo等<sup>[13]</sup>在另一项基于604例脑膜 瘤患者的1 cm脑-肿瘤界面厚度的影像组学研究中 采用LR算法建模,测试集的曲线下面积达0.91 (95%CI:0.840~0.980)。然而上述研究未进行多种 机器学习模型与多种脑-肿瘤界面厚度的对比分析, 且未对影像组学模型的可解释性进行深入探究。 相比之下,本研究样本量更大(656例),不仅对比分 析不同脑-肿瘤界面厚度的模型预测效能,还通过 SHAP法揭示小波变换特征等在模型预测中的关键 作用,为临床决策提供更直观的依据,而这一点在 既往研究中尚未被充分探究。

既往影像组学在脑膜瘤中的应用主要集中于 肿瘤自身特征。近年来,关于脑-肿瘤界面厚度的研 究逐渐受到重视,Zhao等<sup>[20]</sup>基于1 cm脑-肿瘤界面 厚度行影像组学分析并预测脑膜瘤术前分级,表明 影像学定量成像分析用于表征大脑与肿瘤之间的 界面可能有助于判断脑膜瘤侵袭性。本研究采用 LASSOCV算法进行自动特征筛选,结果显示,脑-肿 瘤界面厚度显著影响特征提取和模型预测效能,通 过这种自动化特征筛选机制,1.00 cm脑-肿瘤界面 厚度保留 66 种有效特征,多于 0.80 cm(60 种)和 1.20 cm(40 种),进一步的 Delong 检验证实,1.00 cm 脑-肿瘤界面厚度的 XGBoost 模型预测效能显著优 于其他厚度的所有模型,与Zhao等<sup>[20]</sup>的研究结果相 一致,均支持 1.00 cm 是脑膜瘤影像组学分析的最佳 脑-肿瘤界面厚度。

机器学习模型的可解释性在临床应用中尤为 关键,有助于临床医师理解模型的决策过程,提高 信任度和实际应用价值。SHAP法是一种广泛应用 于机器学习模型可解释性的工具,通过分配特征贡 献值揭示模型输出与输入特征之间的关系。Wang 等<sup>[21]</sup>在一项预测胶质瘤患者全脑放射治疗反应的 影像组学研究中,采用SHAP法分析各影像组学特 征对SVM模型预测效能的具体贡献,灰度值中位数 [CET1-w(3D)\_firstorder\_M]是最重要特征,为临床 应用提供透明且直观的参考依据。有文献报道,小

波变换特征与肿瘤异质性相关<sup>[22]</sup>。本研究 SHAP法 揭示小波变换特征(增强T<sub>1</sub>-Rad-3、T<sub>1</sub>-Rad-5)在预测 脑膜瘤脑侵犯中发挥关键作用。小波变换特征利 用不同波长、振幅和频率识别图像中多尺度范围内 的纹理属性,从而捕捉到肿瘤在不同尺度上的异质 性信息。有研究表明,小波变换特征在肿瘤分级和 预后预测中具有重要价值。Tixier等<sup>[23]</sup>纳入159例 胶质母细胞瘤患者,发现Gabor滤波器(一种基于小 波变换的边缘检测方法)提取的边缘倾斜度特征可 以定量表征肿瘤边界锐度,反映肿瘤浸润程度,与 MGMT基因启动子甲基化结合后显示,Gabor小波负 偏度较大的胶质母细胞瘤患者中位总生存期(OS) 更长(22.7个月,P=0.004),从而有效识别不同预后 亚组。Beig等<sup>[24]</sup>的多中心研究纳入203例胶质母细 胞瘤患者,通过分割肿瘤微环境提取936种三维影 像组学特征,并通过单样本基因富集分析(ssGSEA) 与基因表达数据关联分析发现,瘤周水肿 Gabor小 波变换特征与促肿瘤生长的血管生成通路呈显著 正相关(pGabor = 0.193,95%CI:0.018~0.356)。上 述研究表明,小波变换特征可反映肿瘤微观结构和 侵袭性行为,与本研究发现的小波变换特征在脑膜 瘤脑侵犯预测中的重要性相一致。

本研究建立的脑膜瘤脑侵犯预测模型在临床 实践中具有重要应用价值,主要体现在以下几方 面:首先,辅助术前手术决策。通过准确预测脑侵 犯,神经外科医师可以更精确地评估手术风险,制 定更合理的手术方案。例如,对于高风险脑侵犯患 者,可考虑扩大手术切除范围以降低肿瘤残留和复 发风险;而对于低风险患者,可采取更保守的手术 策略以减少手术创伤和并发症。其次,结合围手术 期风险评估。本研究模型与癫痫发作风险和术后 颅内出血风险预测相结合,可以为患者提供更全面 的风险评估和个性化治疗。例如,对于高风险脑侵 犯且存在癫痫发作史的患者,可采取更积极的抗癫 痫治疗。最后,促进临床转化。本研究模型有望整 合至现有的术前MRI工作流程中,开发临床决策支 持系统,为临床医师提供实时的脑侵犯风险评估, 并促进多学科团队合作,共同制定个性化治疗方 案,提高诊疗水平。

综上所述,本研究基于术前MRI开发了一种无 创性预测脑膜瘤脑侵犯的可解释性机器学习模型, 为脑膜瘤患者提供更精准和个性化的治疗方案,改 善患者预后。然而,本研究仍存在一定的局限性,

首先,排除多发性脑膜瘤和MRI图像质量欠佳的患 者限制了模型的普适性,多发性脑膜瘤的病理生理 学机制和影像学表现可能与单发性脑膜瘤存在差 异;而针对图像质量欠佳,未来可以探究通过运动 校正或图像增强技术减少数据排除。其次,作为单 中心回顾性研究,本研究可能存在选择偏倚,且不 同MRI设备和扫描参数产生的影像学数据异质性 可能影响模型的泛化能力。再次,本研究未探究多 次重复数据划分(如重复k折交叉验证)对预测结果 稳定性的影响,也未明确区分不同脑膜瘤亚型对预 测效能的影响,这些因素均可能限制模型泛化能力 的评估。最后,本研究未进一步探究如DWI、灌注 加权成像(PWI)、磁共振波谱(MRS)及fMRI等成像 模式在脑膜瘤影像组学分析中的潜在应用,可能遗 漏肿瘤微环境的关键信息,限制对肿瘤生物学行为 的全面解析。未来亟待开展多中心大样本前瞻性 研究,并纳入更多的多模态影像学数据,以及联合 影像组学特征与术前标准影像指标,以进一步验证 本研究结论,并提高其在临床实践中的应用价值。 利益冲突 无

#### 参考文献

- [1] Ostrom QT, Price M, Neff C, Cioffi G, Waite KA, Kruchko C, Barnholtz - Sloan JS. CBTRUS statistical report: primary brain and other central nervous system tumors diagnosed in the United States in 2016-2020 [J]. Neuro Oncol, 2023, 25(12 Suppl 2): jy 1- jy 99.
- [2] Perry A, Stafford SL, Scheithauer BW, Suman VJ, Lohse CM. Meningioma grading: an analysis of histologic parameters [J]. Am J Surg Pathol, 1997, 21:1455-1465.
- [3] Zhang J, Yao K, Liu P, Liu Z, Han T, Zhao Z, Cao Y, Zhang G, Zhang J, Tian J, Zhou J. A radiomics model for preoperative prediction of brain invasion in meningioma non-invasively based on MRI: a multicentre study [J]. EBioMedicine, 2020, 58: 102933.
- [4] Hess K, Spille DC, Adeli A, Sporns PB, Brokinkel C, Grauer O, Mawrin C, Stummer W, Paulus W, Brokinkel B. Brain invasion and the risk of seizures in patients with meningioma [J]. J Neurosurg, 2019, 130:789-796.
- [5] Hinrichs FL, Brokinkel C, Adeli A, Sporns PB, Hess K, Paulus W, Stummer W, Grauer O, Spille DC, Brokinkel B. Risk factors for preoperative seizures in intracranial meningiomas [J]. J Neurosurg Sci, 2023, 67:66-72.
- [6] Brokinkel B, Sicking J, Spille DC, Hess K, Paulus W, Stummer W. Letter to the editor: brain invasion and the risk for postoperative hemorrhage and neurological deterioration after meningioma surgery[J]. J Neurosurg, 2018, 129:849-851.
- [7] Banan R, Abbetmeier-Basse M, Hong B, Dumitru CA, Sahm F, Nakamura M, Krauss JK, Hartmann C. The prognostic significance of clinicopathological features in meningiomas: microscopic brain invasion can predict patient outcome in otherwise benign meningiomas[J]. Neuropathol Appl Neurobiol, 2021, 47:724-735.

- [8] Li HY, Ying YZ, Zheng D, Dong GH, Zhang GB, Liu XM, Lin S, Ren XH, Jiang ZL. Is brain invasion sufficient as a standalone criterion for grading atypical meningioma [J]? J Neurosurg, 2023, 139:953-964.
- [9] Spille DC, Heß K, Sauerland C, Sanai N, Stummer W, Paulus W, Brokinkel B. Brain invasion in meningiomas: incidence and correlations with clinical variables and prognosis [J]. World Neurosurg, 2016, 93:346-354.
- [10] Behling F, Fodi C, Gepfner-Tuma I, Machetanz K, Renovanz M, Skardelly M, Bornemann A, Honegger J, Tabatabai G, Tatagiba M, Schittenhelm J. CNS invasion in meningioma: how the intraoperative assessment can improve the prognostic evaluation of tumor recurrence[J]. Cancers (Basel), 2020, 12:3620.
- [11] Lambin P, Rios-Velazquez E, Leijenaar R, Carvalho S, van Stiphout RG, Granton P, Zegers CM, Gillies R, Boellard R, Dekker A, Aerts HJ. Radiomics: extracting more information from medical images using advanced feature analysis[J]. Eur J Cancer, 2012, 48:441-446.
- [12] Yu J, Kong X, Xie D, Zheng F, Wang C, Shi D, He C, Liang X, Xu H, Li S, Chen X. Multiparameter MRI - based radiomics nomogram for preoperative prediction of brain invasion in atypical meningioma: a multicentre study [J]. BMC Med Imaging, 2024, 24:134.
- [13] Joo L, Park JE, Park SY, Nam SJ, Kim YH, Kim JH, Kim HS. Extensive peritumoral edema and brain-to-tumor interface MRI features enable prediction of brain invasion in meningioma: development and validation[J]. Neuro Oncol, 2021, 23:324-333.
- [14] Xiao D, Zhao Z, Liu J, Wang X, Fu P, Le Grange JM, Wang J, Guo X, Zhao H, Shi J, Yan P, Jiang X. Diagnosis of invasive meningioma based on brain-tumor interface radiomics features on brain MR images: a multicenter study [J]. Front Oncol, 2021, 11:708040.
- [15] Isensee F, Schell M, Pflueger I, Brugnara G, Bonekamp D, Neuberger U, Wick A, Schlemmer HP, Heiland S, Wick W, Bendszus M, Maier - Hein KH, Kickingereder P. Automated brain extraction of multisequence MRI using artificial neural networks[J]. Hum Brain Mapp, 2019, 40:4952-4964.
- [16] Shinohara RT, Sweeney EM, Goldsmith J, Shiee N, Mateen FJ, Calabresi PA, Jarso S, Pham DL, Reich DS, Crainiceanu CM; Australian Imaging Biomarkers Lifestyle Flagship Study of Ageing, Alzheimer's Disease Neuroimaging Initiative. Statistical normalization techniques for magnetic resonance imaging [J]. Neuroimage Clin, 2014, 6:9-19.
- [17] Brokinkel B, Hess K, Mawrin C. Brain invasion in meningiomas: clinical considerations and impact of neuropathological evaluation. A systematic review [J]. Neuro Oncol, 2017, 19:1298-1307.
- [18] Ni Y, Zhang F, Zhang Y, Lin JZ. Analysis of the relationship between neurovascular compression and primary trigeminal neuralgia based on radiomics[J]. Zhongguo Xian Dai Shen Jing Ji Bing Za Zhi, 2024, 24:668-673.[倪洋,张昉,张勇,林劲芝. 基于影像组学的神经血管压迫与原发性三叉神经痛关系探讨 [J]. 中国现代神经疾病杂志, 2024, 24:668-673.]
- [19] Feng M, Zheng XQ, Wang RZ. The application of medical big data in central nervous system diseases[J]. Zhongguo Xian Dai Shen Jing Ji Bing Za Zhi, 2021, 21:128-131.[冯铭,郑雪晴, 王 任直. 医疗大数据在神经系统疾病中的应用[J]. 中国现代神 经疾病杂志, 2021, 21:128-131.]
- [20] Zhao Z, Nie C, Zhao L, Xiao D, Zheng J, Zhang H, Yan P, Jiang X, Zhao H. Multi-parametric MRI-based machine learning model for prediction of WHO grading in patients with meningiomas[J]. Eur Radiol, 2024, 34:2468-2479.
- [21] Wang Y, Lang J, Zuo JZ, Dong Y, Hu Z, Xu X, Zhang Y, Wang

Q, Yang L, Wong STC, Wang H, Li H. The radiomic-clinical model using the SHAP method for assessing the treatment response of whole-brain radiotherapy: a multicentric study [J]. Eur Radiol, 2022, 32:8737-8747.

- [22] Ma X, Qian X, Wang Q, Zhang Y, Zong R, Zhang J, Qian B, Yang C, Lu X, Shi Y. Radiomics nomogram based on optimal VOI of multi - sequence MRI for predicting microvascular invasion in intrahepatic cholangiocarcinoma [J]. Radiol Med, 2023, 128:1296-1309.
- [23] Tixier F, Um H, Bermudez D, Iyer A, Apte A, Graham MS, Nevel KS, Deasy JO, Young RJ, Veeraraghavan H. Preoperative

MRI - radiomics features improve prediction of survival in glioblastoma patients over MGMT methylation status alone [J]. Oncotarget, 2019, 10:660-672.

[24] Beig N, Bera K, Prasanna P, Antunes J, Correa R, Singh S, Saeed Bamashmos A, Ismail M, Braman N, Verma R, Hill VB, Statsevych V, Ahluwalia MS, Varadan V, Madabhushi A, Tiwari P. Radiogenomic - based survival risk stratification of tumor habitat on Gd-T1W MRI is associated with biological processes in glioblastoma[J]. Clin Cancer Res, 2020, 26:1866-1876. (收稿日期:2025-01-06)

(本文编辑:吴春蕊)

# ·小词典·

# 中英文对照名词词汇(一)

爱丁堡利手问卷 Edinburgh Handedness Inventory(EHI) 白细胞介素-1β interleukin-1β(IL-1β) 超早期低级别胶质瘤 ultra-early stage lower-grade glioma(UES-LGG) 持续性部分性癫痫 epilepsia partialis continua(EPC) 重复时间 repetition time(TR) 二氢嘧啶脱氢酶 dihydropyrimidine dehydrogenase(DPYD) 单纯疱疹病毒1型 herpes simplex virus type 1(HSV-1) 第二代测序技术 next-generation sequencing(NGS) 端粒酶逆转录酶启动子 telomerase reverse transcriptase promoter(TERTp) 多层感知器 multilayer perceptron(MLP) 多实例学习 multiple instance learning(MIL) 额颞叶痴呆 frontotemporal dementia(FTD) 翻转角 flip angle(FA) 反转时间 inversion time(TI) 腓骨肌萎缩症 Charcot-Marie-Tooth disease(CMT) 改良 Ashworth 量表 modified Ashworth Scale(MAS) 改良Gomori三色 modified Gomori trichrome(MGT) 干扰素-γ interferon-γ(IFN-γ) 干扰素刺激基因15 interferon-stimulated gene 15(ISG15) 杆状体肌病 nemaline myopathy(NM) 感兴趣区 region of interest(ROI) 高级归一化工具 advanced normalization tools(ANTs) 高清多媒体接口 high-definition multimedia interface(HDMI) 谷氨酸受体亚单位3 glutamate receptor subunit 3(GluR3) 规律间隔成簇短回文重复序列 clustered regularly interspaced short palindromic repeats (CRISPR) 国际抗癫痫联盟 International League Against Epilepsy(ILAE) 国家药品监督管理局 National Medical Products Administration(NMPA) 汉语失语成套测验 Aphasia Battery of Chinese(ABC)

合成少数类过采样技术 synthetic minority oversampling technique(SMOTE) 琥珀酸脱氢酶 succinate dehydrogenase(SDH) 还原型辅酶 [四氮唑还原酶 reduced nicotinamide adenine dinucleotide-tetrazolium reductase(NADH-TR) 灰度共生矩阵 gray level co-occurrence matrix(GLCM) 灰度区域大小矩阵 gray level size zone matrix(GLSZM) 回波时间 echo time(TE) Logistic 回归 Logistic regression(LR) Glasgow 昏迷量表 Glasgow Coma Scale(GCS) 混合现实 mixed reality(MR) 混合现实神经导航系统 mixed reality navigation system(MRNS) 机器学习 machine learning(ML) 肌萎缩侧索硬化 amyotrophic lateral sclerosis(ALS) 基因富集分析 gene set enrichment analysis(GSEA) 基于注意力机制的多实例学习 attention-based multiple instance learning(AB-MIL) 激励次数 number of excitation(NEX) 极端梯度提升算法 extreme gradient boosting(XGBoost) 计算机辅助导航系统 computer-assisted navigation system(CANS) Shapley 加法解释 Shapley additive explanation(SHAP) 加拿大蒙特利尔神经病学研究所 Montreal Neurological Institute(MNI) 间质上皮转化因子 mesenchymal-epithelial transition(MET) 简易智能状态检查量表 Mini-Mental State Examination(MMSE) 交叉验证 cross-validation(CV) 局灶性皮质发育不良 focal cortical dysplasia(FCD) 卷积神经网络 convolution neural network(CNN) 决策曲线分析 decision curve analysis(DCA) 抗癫痫发作药物 antiepileptic seizure medicine(ASM)

类激活图 class activation map(CAM)

· 186 ·