



· 论 著 ·

# 多模态影像组学模型在前列腺癌Gleason分级中的应用价值

杨馨<sup>1, 2</sup>, 杨宏楷<sup>2</sup>, 戚轩<sup>2</sup>, 翟承凤<sup>1, 2</sup>, 何永胜<sup>2</sup>

1. 安徽医科大学第五临床医学院, 安徽医科大学马鞍山临床学院, 安徽 马鞍山 243000 ;  
2. 马鞍山市人民医院影像科, 安徽 马鞍山 243000

[摘要] 目的: 探讨基于多参数磁共振成像 (multi-participant magnetic resonance imaging, mpMRI) 的影像组学模型对前列腺癌Gleason分级的应用价值。方法: 回顾并分析2020年11月—2023年8月在马鞍山市人民医院行前列腺MRI检查且经穿刺活检或术后病理学检查证实为前列腺癌的患者资料。提取mpMRI图像数据, 包括T2加权成像 (T2-weighted imaging, T2WI)、小视野弥散加权成像 (zoomed imaging technique with parallel transmission diffusion-weighted imaging, ZOOMit DWI)、表观弥散系数 (apparent diffusion coefficient, ADC)。采用Spearman相关系数初步筛选组学特征, 采用最小绝对收缩和选择算子 (least absolute shrinkage and selection operator, LASSO) 算法及10折交叉验证进一步筛选, 采用logistic回归构建模型, 使用受试者工作特征 (receiver operating characteristic, ROC) 曲线判断模型的诊断效能, 使用DeLong检验比较模型间曲线下面积 (area under curve, AUC)。结果: 共纳入176例患者, 包括低级别组72例 (Gleason评分 $\leq 3+4$ ), 高级别组104例 (Gleason评分 $\geq 4+3$ ), 按7:3随机分成训练集 ( $n=141$ ) 和测试集 ( $n=35$ )。应用多种分类器对多参数模型进行构建, 结果显示支持向量机 (support vector machine, SVM) 在测试集中AUC为0.891, 训练集中AUC为0.905。轻量级梯度提升机 (light gradient boosting machine, LightGBM) 在训练集中AUC最高, 为0.931; 但其在测试集中表现欠佳, AUC为0.808。多层感知机 (multilayer perceptron, MLP) 在测试集和训练集中AUC可分别达到0.883、0.855, 整体弱于SVM; 可见LightGBM和MLP模型稳定性相较于SVM来说略差。另外K紧邻 (k-nearest neighbor, KNN)、极度随机树 (extra trees, ET)、随机森林 (random forest, RF)、极度梯度提升 (extreme gradient boosting, XGBoost) 这四种方法的整体效能也都不如SVM, 且部分存在过拟合。综合而言, 在前列腺癌Gleason分级方面, SVM模型无论测试集还是训练集AUC均较高, 其稳定性以及模型分级能力更好。结论: 基于mpMRI构建多模态影像组学模型在前列腺癌Gleason分级中有较大的临床应用价值, 其中以SVM模型为最佳。

[关键词] 前列腺癌; 影像组学; 多参数磁共振成像; Gleason分级; 小视野弥散加权成像

中图分类号: R737.25; R445.2 文献标志码: A DOI: 10.19732/j.cnki.2096-6210.2024.05.011

**The application value of multimodal radiomics models in Gleason score of prostate cancer** YANG Xin<sup>1, 2</sup>, YANG Hongkai<sup>2</sup>, QI Xuan<sup>2</sup>, ZHAI Chengfeng<sup>1, 2</sup>, HE Yongsheng<sup>2</sup> (1. The Fifth Clinical Medical College of Anhui Medical University, Ma'anshan Clinical College of Anhui Medical University, Ma'anshan 243000, Anhui Province, China; 2. Department of Imaging, Ma'anshan People's Hospital, Ma'anshan 243000, Anhui Province, China)

Correspondence to: HE Yongsheng E-mail: heyongsheng881@163.com

[Abstract] **Objective:** To explore the application value of radiomics model based on multi-parameter magnetic resonance imaging (mpMRI) in Gleason grading of prostate cancer. **Methods:** The data of patients who underwent prostate mpMRI examination with surgical or pathological puncture results confirming prostate cancer at Ma'anshan People's Hospital from November 2020 to August 2023 were retrospectively analyzed. MpMRI data were extracted, including T2-weighted imaging (T2WI), zoomed imaging technique with parallel transmission diffusion-weighted imaging (ZOOMit DWI) and apparent diffusion coefficients (ADC). Spearman's correlation coefficient was used to preliminarily screen the histological features, the least absolute shrinkage and selection operator (LASSO) algorithm and ten-fold cross-validation were used to further screen, logistic regression was used

基金项目: 安徽省重点研究与开发计划 (2022e07020065)

通信作者: 何永胜 E-mail: heyongsheng881@163.com

to construct the model, and the receiver operating characteristic (ROC) curve was used to judge the results. And the area under the ROC curve (AUC) was compared between models using the DeLong test. **Results:** A total of 176 patients were included, including 72 patients in the low-grade group (Gleason score  $\leq 3+4$ ) and 104 patients in the high-grade group (Gleason score  $\geq 4+3$ ), who were randomly divided into training group ( $n=141$ ) and test group ( $n=35$ ) according to 7 : 3. A variety of classifiers were used to construct the multi-parameter model, and the results showed that the AUC of support vector machine (SVM) in the test set was 0.891, and the AUC in the training set was 0.905. Light gradient boosting machine (LightGBM) had the highest AUC of 0.931 in the training set, but it performed poorly in the test set with an AUC of 0.808. The AUCs of multilayer perceptron (MLP) in the test set and the training set were 0.883 and 0.855, respectively, which were weaker than that of SVM, which showed that the stability of LightGBM and MLP models were slightly worse than that of SVM. In addition, the overall performance of the four methods [k-nearest neighbor (KNN), extra trees (ET), random forest (RF), extreme gradient boosting (XGBoost)] were not as good as SVM, and some of them are overfitted. In general, in terms of Gleason grading of prostate cancer, the SVM model had a higher AUC in both the test set and the training set, and its stability and model classification ability were better. **Conclusion:** Constructing a multimodal imaging histology model based on mpMRI has significant clinical application value in Gleason grading of prostate cancer, of which the SVM model is the best.

[ **Key words** ] Prostate cancer; Radiomics; Multiparametric magnetic resonance imaging; Gleason score; Small-field diffusion-weighted imaging

全世界范围内,前列腺癌(prostate cancer, PCa)对男性健康危害较大,是在男性中发病率和死亡率较高的第二大常见癌症<sup>[1]</sup>。GLOBOCAN研究<sup>[2]</sup>估计,相较于欧美等国家,中国PCa发病率较低,全球新发患者比例也较低,但在癌症顺位上不断前移,在年轻人群中的发病率也有增加趋势<sup>[3]</sup>,中国PCa死亡率远远超出欧美等国家<sup>[4]</sup>。由此可见PCa的筛查极为重要,并可能需要以过度诊断和过度治疗为代价降低PCa发病率、死亡率。使用磁共振成像(magnetic resonance imaging, MRI)和生物标志物检测PCa可能会减轻PCa筛查的一些负面影响<sup>[1]</sup>。

在临床上, Gleason评分常常被用于评价PCa生物学特性与预测疗效<sup>[5]</sup>,根据Gleason评分可将PCa分为低级别和高级别,低级别PCa定义为Gleason评分7a(Gleason评分 $\leq 3+4$ );高级别PCa定义为Gleason评分7b(Gleason评分 $\geq 4+3$ )和最大直径 $> 3$  mm。低级别PCa与高级别PCa在病程进展、疗效及患者预后等方面有显著差异<sup>[6]</sup>。Gleason评分的准确度对于选择PCa的治疗方式至关重要。

Lambin等<sup>[7]</sup>2012年提出影像组学(Radiomics)的概念以来,影像组学便一直是医学成像领域的研究热点。影像组学隶属于人工智能的分支,主要包括5个步骤:感兴趣区

(region of interest, ROI)的分割、图像预处理、放射组学特征提取、放射组学标签(Rad-score)的构建和放射组学模型的评估<sup>[8]</sup>。目前已有研究<sup>[9-12]</sup>表明,基于MRI的影像组学在PCa的诊断和鉴别诊断、病理学分类、临床分级、侵入性评估、治疗决策和预后分析等方面具有一定的临床应用价值,但鲜有研究将多参数MRI(multi-participant MRI, mpMRI)图像融合构建多模态影像组学模型应用于Gleason分级中,本研究旨在探讨基于mpMRI构建的多模态影像组学模型在PCa Gleason分级中的应用价值。

## 1 资料和方法

### 1.1 一般资料

回顾并分析2020年11月—2023年8月在马鞍山市人民医院行前列腺MRI检查且经穿刺活检或术后病理学检查证实为PCa患者的资料。

纳入标准:①在本院行前列腺mpMRI检查;②前列腺特异性抗原(prostate-specific antigen, PSA)升高;③患者均为首次病理学检查,且诊断明确,资料完整;④患者相关人口学信息及临床资料完整、准确。排除标准:①患者在MRI扫描前接受了前列腺手术或穿刺活检;②患者MRI检查前半年内有盆腔放疗、化疗、内分泌治疗或手术史;③病灶体积小于

5 mm<sup>3</sup>, 不利于进行ROI勾画; ④ MRI图像伪影过大、质量差, 干扰医师诊断, 不利于ROI勾画及数据分析。

本研究已通过马鞍山人民医院伦理委员会审查批准, 审批号: 医学伦申(2021)第006-008号。

## 1.2 设备及相关参数

采用德国Siemens公司的MAGNETON Prisma 3.0 T MRI仪进行前列腺扫描, 扫描序列包T2加权成像(T2-weighted imaging, T2WI)、小视野弥散加权成像(zoomed imaging technique with parallel transmission diffusion-weighted imaging, ZOOMit DWI)等。

T2WI参数: 视野(field of view, FOV) 200 mm × 200 mm, 重复时间(repetition time, TR) 6 980 ms, 回波时间(echo time, TE) 104 ms, 层厚3 mm, 层数23层。DWI参数: FOV 220 mm × 220 mm, TR 4 000 ms, TE 65 ms, 层厚3 mm, 体素尺寸为0.9 mm × 0.9 mm × 3 mm, 层厚3 mm, 层数23层, 带宽为1 750,  $b$ 值为0、50、100、200、500、1 000、1 500、2 000和2500 s/mm<sup>2</sup>。在本研究中, 表现观弥散系数(apparent diffusion coefficient, ADC)图使用 $b=0$  s/mm<sup>2</sup>和 $b=1 500$  s/mm<sup>2</sup>的“高 $b$ 值生成”<sup>[13-14]</sup>。在3个不同方向上采集图像, 采用在线动态场校正技术以消除涡流导致的图像。

## 1.3 图像分析及分割

由2名具有5~10年前列腺MRI诊断工作经验的影像科医师按照第2.1版前列腺影像报告和数据库系统(Prostate Imaging Reporting And Data System, PI-RADS)评分系统, 在不知病理学检查结果的情况下评估MRI图像。

将MRI图像从影像存储与传输系统(picture archiving and communication system, PACS)中以DICOM格式导出, 使用T2WI和DWI图像进行图像配准, 定位病灶, 由2名具有5~10年前列腺MRI诊断工作经验的影像科医师A和B使用图像分割软件ITK-SNAP(<http://www.itksnao.org/pmwiki/pmwiki.php>)对前列腺病灶进行ROI初步勾画, 半月后由影像科医师A随机选取35例重新勾画ROI, 计算组内相关系数(intraclass correlation coefficient,

ICC), 判断两次勾画的一致性, ICC ≥ 0.75则认为2名医师勾画的ROI具有较高的一致性。所有ROI均需要由1名具有20年前列腺MRI诊断工作经验的高级职称影像科医师进行检查、修改(图1)。

## 1.4 特征提取及筛选

采用PyRadiomic程序库(<http://pyradiomics.readthedocs.io>)对勾画好的ROI进行影像组学特征提取, 过程如下: ① 通过相关系数(例如Spearman、Pearson等)初步筛选特征, 构建训练集和测试集, 包括几何形态特征、强度特征和纹理特征。几何特征描述病变的三维形态; 强度特征描述病变内体素强度的一阶统计分布; 纹理特征描述病变体素空间分布强度等级, 提取方式包括灰度共生矩阵、灰度依赖矩阵、灰度游程矩阵、灰度级大小区域矩阵、相邻灰度差矩阵。② 采用最小绝对收缩与选择算子(the least absolute shrinkage and selection operator, LASSO)算法并10折交叉验证进一步筛选出最具预测性的特征子集, 并得出相应的影像组学特征系数, 最终构建logistic回归模型。

## 1.5 模型建立

本研究所建立的模型为T2WI、ZOOMit DWI、ADC(在本研究中, ADC图使用 $b=0$  s/mm<sup>2</sup>和 $b=1500$  s/mm<sup>2</sup>的“高 $b$ 值生成”<sup>[13]</sup>)多参数联合模型, 步骤如下: ① 根据筛选出来的数据, 进行模型的初步选择, 主要使用到线性回归模型(logistic regression, LR)、支持向量机(support vector machines, SVM)、K紧邻(k-nearest neighbor, KNN)、极度随机树(extra trees, ET)、随机森林(random forests, RF)、极度梯度提升(extreme gradient boosting, XGBoost)、轻量级梯度提升机(light gradient boosting machine, LightGBM)、多层感知机(multilayer perceptron, MLP), 得出具有LASSO logistic回归模型的Rad-score、十倍验证的系数和平均标准误差(mean standard error, MSE)。② 最后采用受试者工作特征(receiver operating characteristic, ROC)曲线分析评价模型的诊断效能, 使用交叉验证的惩罚系数作为模

型训练的基础。本研究根据Gleason评分的高低将数据分为两组，并分别标上标签。在模型建立中，高级别组（Gleason评分 $\geq 4+3$ ）对应标签1，低级别组（Gleason评分 $\leq 3+4$ ）对应标签0，以此作为模型的 $Y$ （变量）；自变量包括筛选后的特征，具体可见图3C。

### 1.6 统计学处理

采用R语言4.2.1 (<https://cran.r-project.org/>)完成统计学分析，使用Python语言编写程序进行图像数据分析。

符合正态分布的计量资料以 $\bar{x}\pm s$ 表示，否则以 $M(P_{25}, P_{75})$ 表示。高级别组和低级别组之间使用Mann-Whitney  $U$ 检验进行比较。采用ROC曲线分析最终得出的模型的诊断性能，并采用曲线下面积（area under curve, AUC）量化模型的诊断性能。使用DeLong检验比较各模型的AUC并分析其差异性。显著性检验中 $P < 0.05$ 为差异有统计学意义。

## 2 结果

### 2.1 一般临床资料

本研究最终共纳入176例，包括低级别组72例（Gleason评分 $\leq 3+4$ ），高级别组104例（Gleason评分 $\geq 4+3$ ）。将患者按7:3分配至训

练集和测试集，训练集141例，测试集35例。训练集与测试集的患者年龄大小差异无统计学意义（ $P > 0.05$ ）；而PSA差异有统计学意义，高级别组PSA水平明显高于低级别组（图2，表1）。

### 2.2 特征降维、筛选及建模

从T2WI、ZOOMit DWI、ADC图像中共提取5 502个初始特征参数，经Spearman相关系数初步处理筛选去除相关系数 $> 0.9$ 的特征后，再通过LASSO回归进行特征筛选，最终筛选出15个最佳特征，筛选出来的15个影像组学特征均提示一致性良好（均ICC $> 0.8$ ）（图3）。

### 2.3 模型评估

应用多种分类器对多参数模型进行构建，结果显示：SVM在测试集、训练集中AUC分别为0.891、0.905。LightGBM在训练集中AUC最高，为0.931；但其在测试集中表现欠佳，AUC为0.808。MLP在测试集和训练集中AUC可分别达到0.883、0.855，但整体弱于SVM；可见LightGBM和MLP模型稳定性相较于SVM来说略差。另外KNN、ET、RF、XGBoost这4种方法的整体效能也都不如SVM，且部分存在过拟合，各分类器详细信息见图4和表2。综合而言，在PCa Gleason分级方面，SVM模型无论是测试集还是训练集AUC均较高，其稳定性以及模型分级能力更好。




图1 ROI图像分割

A: ADC图横断面；B: 在ADC图中进行病灶的ROI勾画；C: 勾画好的ROI示意图；D: ZOOMit DWI序列横断面（ $b=1\ 500\ \text{s/mm}^2$ ）；E: T2WI序列横断面。

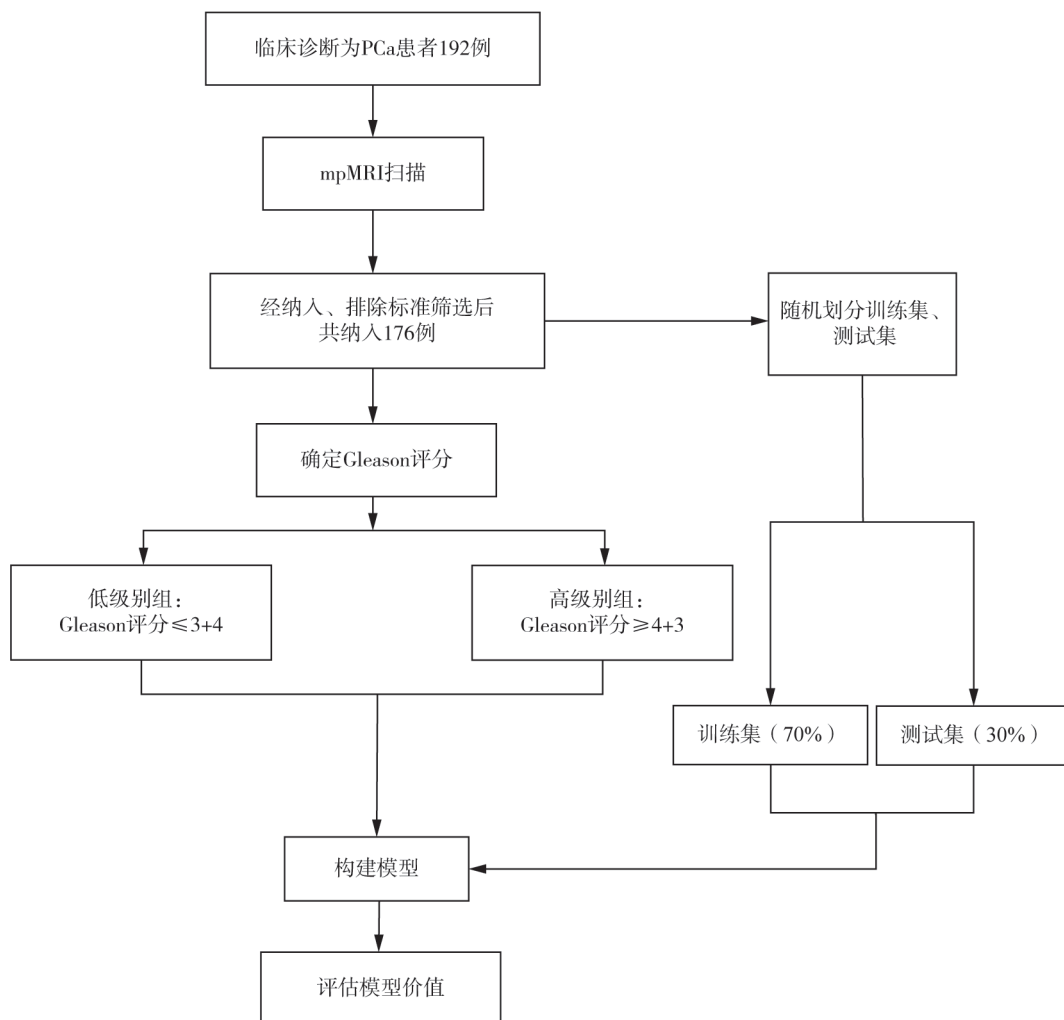


图2 研究对象选择流程图

表1 病灶一般资料统计分析结果

项目	训练集 (n=141)			测试集 (n=35)		
	低级别组	高级别组	P值	低级别组	高级别组	P值
年龄/岁 $\bar{x}\pm s$	73.08 ± 7.97	74.58 ± 8.79	0.161	65.83 ± 9.01	70.57 ± 9.88	0.088
PSA/ (ng·mL <sup>-1</sup> ) $\bar{x}\pm s$	32.09 ± 63.16	73.94 ± 106.26	0.003	18.76 ± 20.22	88.52 ± 121.69	0.005
Gleason评分						
≤3+4	51	0		12	0	
4+3	0	36		0	6	
8	0	28		0	6	
9	0	26		0	11	
10	0	0		0	0	

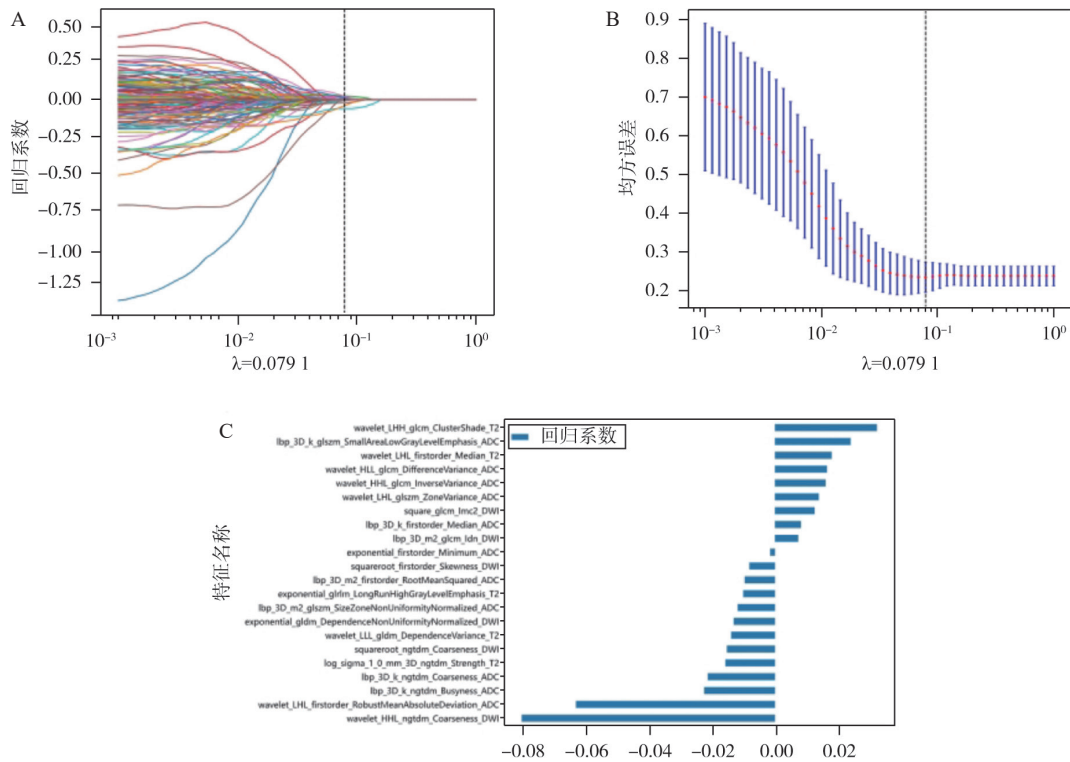


图3 特征筛选及特征相关系数图

A、B: 采用LASSO回归并10折交叉验证筛选特征, 使用交叉验证的惩罚系数 $\lambda$ 对特征进行压缩, 得出最佳特征; C: 15个最佳特征的相关系数图。

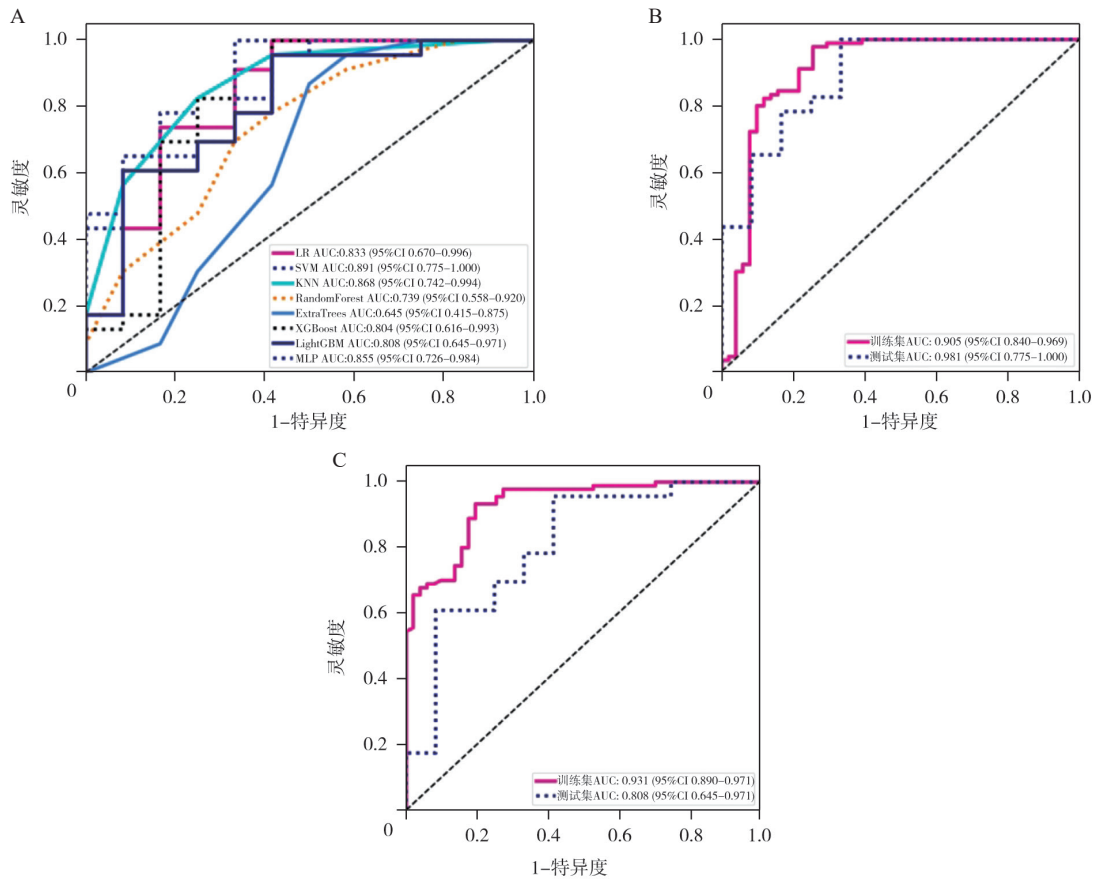


图4 多参数模型ROC曲线

A: 8个模型的ROC曲线; B: SVM模型的ROC曲线; C: LightGBM模型的ROC曲线。

表2 模型的诊断效能评估

模型名称	组别	精确度	AUC	95% CI	灵敏度	特异度	PPV	NPV	准确度	召回率	F1	阈值
LR	训练集	0.801	0.845	0.777 0~0.913 6	0.889	0.647	0.816	0.767	0.816	0.889	0.851	0.535
	测试集	0.829	0.833	0.670 3~0.996 4	0.913	0.667	0.840	0.800	0.840	0.913	0.875	0.430
SVM	训练集	0.887	0.905	0.840 1~0.969 0	0.978	0.725	0.863	0.949	0.863	0.978	0.917	0.547
	测试集	0.800	0.891	0.774 6~1.000 0	0.870	0.667	0.833	0.727	0.833	0.870	0.851	0.425
KNN	训练集	0.787	0.838	0.775 5~0.901 4	0.878	0.627	0.806	0.744	0.806	0.878	0.840	0.600
	测试集	0.800	0.868	0.741 8~0.993 7	0.826	0.750	0.864	0.692	0.864	0.826	0.844	0.600
RF	训练集	0.986	1.000	0.998 6~1.000 0	0.989	0.980	0.989	0.980	0.989	0.989	0.989	0.500
	测试集	0.686	0.739	0.558 1~0.920 2	0.696	0.667	0.800	0.533	0.800	0.696	0.744	0.500
ET	训练集	1.000	1.000	1.000 0~1.000 0	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
	测试集	0.743	0.645	0.414 7~0.875 2	0.870	0.500	0.769	0.667	0.769	0.870	0.816	0.500
XGBoost	训练集	1.000	1.000	1.000 0~1.000 0	1.000	1.000	1.000	1.000	1.000	1.000	1.000	0.668
	测试集	0.800	0.804	0.615 8~0.992 9	0.826	0.750	0.864	0.692	0.864	0.826	0.844	0.322
LightGBM	训练集	0.865	0.931	0.890 2~0.971 2	0.978	0.667	0.838	0.944	0.838	0.978	0.903	0.548
	测试集	0.829	0.808	0.645 3~0.970 6	0.957	0.583	0.815	0.875	0.815	0.957	0.880	0.515
MLP	训练集	0.823	0.883	0.824 2~0.942 7	0.989	0.529	0.788	0.964	0.788	0.989	0.877	0.590
	测试集	0.829	0.855	0.726 0~0.984 1	1.000	0.500	0.793	1.000	0.793	1.000	0.885	0.666

PPV: 阳性预测值 (positive predictive value); NPV: 阴性预测值 (negative predictive value); F1: 精准率和召回率的关系。

### 3 讨 论

在全球范围内, PCa在男性患癌率和癌症死亡率中位于第二位和第五位<sup>[15]</sup>。预计到2040年, 中国PCa新发患者数将达到20万例, 死亡人数将达到12万例<sup>[4]</sup>。国际泌尿外科协会(International Society of Urology, ISU)认可Gleason评分是PCa评分的参考系统<sup>[16]</sup>。根据Gleason评分可以将PCa分为5个等级, 随着评分的增高, 其恶性程度增高, 转移的概率增高, 预后不良的发生率也随之增高。低风险的PCa要避免过度治疗, 中风险的PCa要积极治疗, 高风险致死性PCa要权衡利弊, 因此在病程早期准确预测PCa的Gleason分级对患者精准化诊疗方案的制订及预后改善有极其重要的意义。mpMRI一直被广泛应用于PCa的诊断<sup>[17]</sup>, 且占据重要地位。T2WI是前列腺常规MRI序列之一, 是观察解剖结构的最佳序列, 在腺体异常信号的检测和胞膜外侵袭以及淋巴结转移的评估中起着重要作用; DWI是mpMRI的重要组成部分<sup>[18]</sup>, 可用于无创检测水分子向组织中的弥散运动, 通过指数模型量化可将其表达为ADC<sup>[19]</sup>, DWI与ADC在影像

诊断中密不可分。目前已有研究<sup>[20-21]</sup>证实, 基于MRI的影像组学可预测PCa Gleason评分。影像组学是基于传统影像学图像提取高通量和定量的图像特征, 相对于传统的肉眼评估, 影像组学深度挖掘的高纬度特征可以了解肿瘤异质性提供更多的信息, 更利于提高临床诊断及预测效能<sup>[16]</sup>。大量研究<sup>[22-25]</sup>表明, 使用影像组学预测PCa的Gleason评分具有一定的临床价值, 但先前的研究大多使用基于单参数或者双参数MRI的影像组学特征。李磊等<sup>[22]</sup>对患者行DCE-MRI和DWI扫描检查并测量ADC以判断前列腺病变的良恶性, 结果AUC为0.879, 表明ADC在判断前列腺疾病良恶性中具有一定价值。周牧野等<sup>[23]</sup>探讨基于双参数影像组学对PCa Gleason评分的诊断价值发现, T2WI+ADC融合模型较单独的T2WI和ADC模型在训练集和测试集中均具有更高的AUC ( $P < 0.05$ ), 分别为0.835、0.808, 表明T2WI与ADC融合模型在预测PCa Gleason评分中具有更高的价值。Chaddad等<sup>[24]</sup>采用多中心公开数据集, 基于mpMRI图像的影像组学特征采用RF分类器模型对Gleason评分组进行预测, 测试组AUC最高为0.834, 低于本研究的0.891。Gong等<sup>[25]</sup>回顾并分析2 018例患者数据, 基于

双参数MRI构建影像组学模型以此无创区分高级别PCa, 训练集和测试集的AUC分别为0.801、0.787, 同样低于本研究。以上研究AUC较低的原因可能是, 其大多采用传统DWI序列, 在扫描过程中容易受到运动伪影干扰, 导致图像质量较差; 全视野DWI序列难以准确提供前列腺病变的形态、边界等信息。多项研究<sup>[26-32]</sup>表明, ZOOMit DWI序列优于传统DWI序列, 它具有更高的成像质量、空间分辨率, 以及更少的错误、失真和模糊、运动和流动伪影。ZOOMit DWI序列具有更好的脂肪抑制效果, 可以提供更多前列腺等较小器官的解剖结构细节<sup>[33]</sup>, 且在肿瘤与基质中的对比度更高并能获得更准确的ADC, 在病灶精准定位及诊断上体现出更高的灵敏度和准确度。在前列腺MRI扫描中容易受到直肠气体的干扰而产生伪影, 尤其是外周带, 图像质量好对ROI勾画质量的影响很大。有研究<sup>[26, 28, 30]</sup>表明, ZOOMit DWI序列在这些方面的表现更优, ZOOMit DWI序列体素更小, 能提供更精细、更丰富、更符合解剖结构的纹理特征。目前基于ZOOMit DWI序列的影像组学研究报道较少。Hu等<sup>[29]</sup>发现, 基于ZOOMit DWI技术的影像组学特征对PCa的诊断精度高于基于传统DWI技术的影像组学特征。因此本研究使用ZOOMit DWI序列代替传统DWI序列与T2WI、ADC联合构建多模态影像组学模型预测PCa Gleason评分。以上可说明T2WI、ZOOMit DWI联合ADC的多模态影像组学模型具有更高的诊断价值。

SVM建模是众多机器学习方法之一, 它通过在数据集中创建一个决策边界(称为超平面)实现两类数据库分开, 在识别复杂数据的细微模式方面非常强大<sup>[34]</sup>, 使其比其他分类算法(例如决策树、贝叶斯分类器、logistic回归等)更准确, 且在小样本数据中优势明显<sup>[35]</sup>。在本研究中, SVM在训练集中区分PCa低级别组(Gleason评分 $\leq 3+4$ 分)及高级别组(Gleason评分 $\geq 4+3$ 分)的AUC为0.931, 在验证集中的AUC为0.891, 说明该模型稳定性良好。总体而言, SVM模型在多个数据集上表现出相对较好的性

能。因此基于多参数MRI的影像组学模型在PCa Gleason分级中具有一定的应用价值, 且SVM模型相对较好。

本研究存在一定局限性: ① 本研究为单一中心研究机构, 样本量较小, 得出的结论未得到广泛性验证。② 目前自动勾画ROI的算法尚不完善, 手动勾画ROI效率低下, 且存在个体差异, 影响模型预测性能。③ 本研究的临床数据, 如患者年龄、肿瘤大小、PSA和其他指标, 未被纳入协变量讨论的方程式中。④ 本研究中对前列腺可疑病灶的诊断主要依靠穿刺活检, 诊断准确度低于术后病理学检查, 进而影响影像组学模型诊断效能, 后期可通过超声或MRI引导下穿刺活检减少漏诊, 提高诊断效能。

综上, 基于mpMRI构建的多模态影像组学模型在PCa Gleason分级上具有一定的应用价值, 且SVM模型相对较好。有望在未来临床工作中为PCa的诊断、无创预测危险分级、精准化治疗及预后改善方面提供一些有用的参考依据。

**【利益冲突声明】**所有作者均声明不存在利益冲突。

#### [参 考 文 献]

- [1] BERGENGREN O, PEKALA K R, MATSOUKAS K, et al. 2022 update on prostate cancer epidemiology and risk factors—a systematic review [J]. *Eur Urol*, 2023, 84(2): 191–206.
- [2] BRAY F, FERLAY J, SOERJOMATARAM I, et al. Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries [J]. *CA Cancer J Clin*, 2018, 68(6): 394–424.
- [3] ZHAI Z, ZHENG Y, LI N, et al. Incidence and disease burden of prostate cancer from 1990 to 2017: results from the global burden of disease study 2017 [J]. *Cancer*, 2020, 126(9): 1969–1978.
- [4] 李 星, 曾晓勇. 中国前列腺癌流行病学研究进展 [J]. *肿瘤防治研究*, 2021, 48(1): 98–102.
- [5] PIERORAZIO P M, WALSH P C, PARTIN A W, et al. Prognostic Gleason grade grouping: data based on the modified Gleason scoring system [J]. *BJU Int*, 2013, 111(5): 753–760.
- [6] JUNKER D, QUENTIN M, NAGELE U, et al. Evaluation of the PI-RADS scoring system for mpMRI of the prostate: a whole-mount step-section analysis [J]. *World J Urol*, 2015, 33(7): 1023–1030.
- [7] LAMBIN P, RIOS-VELAZQUEZ E, LEIJENAAR R, et al.

- Radiomics: extracting more information from medical images using advanced feature analysis [J]. *Eur J Cancer*, 2012, 48(4): 441-446.
- [ 8 ] 杜涛明, 唐焯真, 俞琴. 深度学习在前列腺癌多参数磁共振成像中的研究进展 [J]. *临床放射学杂志*, 2023, 42(10): 1693-1697.
- [ 9 ] CUTAIA G, TONA G L, COMELLI A, et al. Radiomics and prostate MRI: current role and future applications [J]. *J Imaging*, 2021, 7(2): 34.
- [ 10 ] FERRO M, COBELLI O D, MUSI G, et al. Radiomics in prostate cancer: an up-to-date review [J]. *Ther Adv Urol*, 2022, 14: 17562872221109020.
- [ 11 ] 张家慧, 许梨梨, 张古沐阳, 等. 基于磁共振成像的影像组学在前列腺癌中的研究进展 [J]. *中国医学科学院学报*, 2022, 44(1): 123-129.
- [ 12 ] 张玉峰, 刘冬, 王希明, 等. 基于前列腺周围脂肪MRI影像组学模型预测前列腺癌生化复发的研究 [J]. *肿瘤影像学*, 2023, 32(1): 33-40.
- [ 13 ] 覃小燕, 彭鹏. 多参数磁共振成像在前列腺癌主动监测中的应用研究进展 [J]. *江苏大学学报(医学版)*, 2023, 33(5): 386-390.
- [ 14 ] 张喆, 兰秀玲, 申林, 等. 基于高b值DWI的容积ROI直方图鉴别中央腺体前列腺癌与良性前列腺增生的价值 [J]. *肿瘤影像学*, 2022, 31(5): 523-530.
- [ 15 ] 刘宗超, 李哲轩, 张阳, 等. 2020全球癌症统计报告解读 [J]. *肿瘤综合治疗电子杂志*, 2021, 7(2): 1-14.
- [ 16 ] EPSTEIN J I, EGEVAD L, AMIN M B, et al. The 2014 international society of urological pathology (ISUP) consensus conference on gleason grading of prostatic carcinoma: definition of grading patterns and proposal for a new grading system [J]. *Am J Surg Pathol*, 2016, 40(2): 244-252.
- [ 17 ] 王可欣, 高歌. 前列腺MRI人工智能辅助诊断的应用价值和局限性: 多中心临床研究系统综述 [J]. *肿瘤影像学*, 2023, 32(1): 26-32.
- [ 18 ] LI L, WANG L, DENG M, et al. Feasibility study of 3-T DWI of the prostate: readout-segmented versus single-shot echo-planar imaging [J]. *AJR Am J Roentgenol*, 2015, 205(1): 70-76.
- [ 19 ] HUI E S, CHEUNG M M, QI L Q, et al. Towards better MR characterization of neural tissues using directional diffusion kurtosis analysis [J]. *Neuroimage*, 2008, 42(1): 122-134.
- [ 20 ] PENZIAS G, SINGANAMALLI A, ELLIOTT R, et al. Identifying the morphologic basis for radiomic features in distinguishing different Gleason grades of prostate cancer on MRI: preliminary findings [J]. *PLoS One*, 2018, 13(8): e0200730.
- [ 21 ] HUYNH L M, HWANG Y, TAYLOR O, et al. The use of MRI-derived radiomic models in prostate cancer risk stratification: a critical review of contemporary literature [J]. *Diagnostics*, 2023, 13(6): 1128.
- [ 22 ] 李磊, 桂赞龙, 程华根, 等. DCE-MRI和ADC值对前列腺良恶性病变的鉴别及ADC值与血清TPSA的关系 [J]. *实用放射学杂志*, 2022, 38(4): 612-615.
- [ 23 ] 周牧野, 李松, 赵灿灿, 等. 基于双参数MRI的影像组学特征融合方法预测前列腺癌Gleason分级的研究 [J]. *中国医疗设备*, 2023, 38(3): 72-77.
- [ 24 ] CHADDAD A, NIAZI T, PROBST S, et al. Predicting gleason score of prostate cancer patients using radiomic analysis [J]. *Front Oncol*, 2018, 8: 630.
- [ 25 ] GONG L X, XU M, FANG M J, et al. Noninvasive prediction of high-grade prostate cancer via biparametric MRI radiomics [J]. *J Magn Reson Imaging*, 2020, 52(4): 1102-1109.
- [ 26 ] SEEGER A, BATRA M, SÜSSKIND D, et al. Assessment of uveal melanomas using advanced diffusion-weighted imaging techniques: value of reduced field of view DWI ( "zoomed DWI" ) and readout-segmented DWI (RESOLVE) [J]. *Acta Radiol*, 2019, 60(8): 977-984.
- [ 27 ] CAI J S, CHEN H Y, CHEN J Y, et al. Reduced field-of-view diffusion-weighted imaging (DWI) in patients with gastric cancer: comparison with conventional DWI techniques at 3.0T: a preliminary study [J]. *Medicine*, 2020, 99(1): e18616.
- [ 28 ] KLINGEBIEL M, ULLRICH T, QUENTIN M, et al. Advanced diffusion weighted imaging of the prostate: comparison of readout-segmented multi-shot, parallel-transmit and single-shot echo-planar imaging [J]. *Eur J Radiol*, 2020, 130: 109161.
- [ 29 ] HU L, ZHOU D W, FU C X, et al. Advanced zoomed diffusion-weighted imaging vs full-field-of-view diffusion-weighted imaging in prostate cancer detection: a radiomic features study [J]. *Eur Radiol*, 2021, 31(3): 1760-1769.
- [ 30 ] LIU W G, LIU H, XIE S M, et al. Comparing the clinical utility of single-shot, readout-segmented and zoomit echo-planar imaging in diffusion-weighted imaging of the kidney at 3T [J]. *Sci Rep*, 2022, 12(1): 12389.
- [ 31 ] TANG S X, FU C, CHEN H L, et al. Comparison of ZOOMit-DWI sequence and conventional DWI sequence in endometrial cancer [J]. *J Cent South Univ Med Sci*, 2023, 48(1): 76-83.
- [ 32 ] DONG H B, LI Y D, LI H, et al. Study of the reduced field-of-view diffusion-weighted imaging of the breast [J]. *Clin Breast Cancer*, 2014, 14(4): 265-271.
- [ 33 ] DONG H B, LI Y D, YU K, et al. Comparison of image quality and application values on different field-of-view diffusion-weighted imaging of breast cancer [J]. *Acta Radiol*, 2016, 57(1): 19-24.
- [ 34 ] HUANG S J, CAI N G, PACHECO P P, et al. Applications of support vector machine (SVM) learning in cancer genomics [J]. *Cancer Genomics Proteomics*, 2018, 15(1): 41-51.
- [ 35 ] JIANG H, CHING W K, CHEUNG W S, et al. Hadamard Kernel SVM with applications for breast cancer outcome predictions [J]. *BMC Syst Biol*, 2017, 11(Suppl 7): 138.

(收稿日期: 2024-05-07 修回日期: 2024-07-04)