肿瘤精准医学与转化研究

DOI：10.13406/j.cnki.cyxb.003958

基于增强T1WI影像组学及临床MRI特征组学列线图术前预测子宫内膜癌侵袭性组织类型的价值

林清秀[1]，李金贝贝[2]，何子坤[1]，凌人男[3]

（1.汕头大学医学院，汕头　515041；2.广东医科大学深圳宝安临床医学院放射科，深圳　518100；
3.南方科技大学第一附属医院放射科，深圳　518020）

【摘　要】目的：建立1个基于增强T1WI（contrast enhanced T1 weighted imaging，CE-T1WI）的影像组学和临床磁共振成像（magnetic resonance imaging，MRI）特征组学的列线图，评估其术前预测子宫内膜癌侵袭性组织类型的价值。**方法：**回顾性分析南方科技大学第一附属医院2016年1月至2024年8月经手术病理诊断为子宫内膜癌患者192例，其中侵袭性组织学类型48例，按7∶3比例随机分为训练集（n=134）和测试集（n=58）。采用ITK-SNAP软件提取影像组学特征，采用多因素分析及最小绝对收缩和选择算子（the least absolute shrinkage and selection operator，LASSO）对影像组学特征进行筛选。同时收集临床指标和MRI特征共11个参数，包括年龄、体质指数（body mass index，BMI）、糖类抗原199（carbohydrate antigen 199，CA199）、CA125、中性粒细胞与淋巴细胞比值（neutrophil-to-lymphocyte ratio，NLR）、表观弥散系数（apparent diffusion coefficient，ADC）、肿瘤与子宫肌层T2WI信号比值（$RatioT_2$），肿瘤累及子宫肌层>1/2（Deep），肿瘤累及子宫肌层的深度（D_{tra}），肿瘤的最大直径（D_{max}）和增强后肿瘤与子宫肌层信号强度比值（$Ratio_{CE}$），采用Spearman相关分析筛选MRI特征。基于影像组学和临床MRI特征组学分别构建LR、SVM、KNN、RF、Extra Trees、XGBoost、LightGBM、MLP模型，绘制受试者工作特征（receiver operating characteristic，ROC）曲线，利用ROC曲线筛选出最佳影像组学和临床MRI特征组学模型以绘制列线图，使用校准曲线评估校准度，使用决策曲线分析（decision curve analysis，DCA）评估应用价值。**结果：**7个影像组学特征和5个临床MRI特征指标（年龄、CA199、ADC、$Ratio_{CE}$、Deep）进入到组学模型。影像组学和临床MRI特征组学构建的LightGBM模型预测效能最佳，训练集和测试集中的AUC分别为0.889和0.788，临床MRI特征组学模型分别为0.893和0.835。构建的列线图在测试集中的AUC、准确率、敏感性、特异性分别为0.888、0.879、0.800和0.907，经校准曲线和DCA分析，列线图的校准度较高，临床净收益较大。**结论：**基于CE-T1WI的影像组学和临床MRI特征组学构建的列线图，可以较好的术前评估子宫内膜癌侵袭性组织类型，对指导患者个体化治疗有着重要临床意义。

【关键词】子宫内膜癌；影像组学；磁共振成像；列线图

【中图分类号】R737.33　　**【文献标志码】**A

Predictive value of a nomogram based on enhanced T1WI radiomics and clinico-MRIomics for aggressive histological types of endometrial cancer before surgery

Lin Qingxiu[1]，*Li Jinbeibei*[2]，*He Zikun*[1]，*Ling Rennan*[3]

（*1.Shantou University Medical College；2.Shenzhen Baoan Clinical Medical College，Guangdong Medical University；*
3.Department of Radiology，The First Affiliated Hospital of Southern University of Science and Technology）

【Abstract】*Objective*：To evaluate the preoperative predictive value of a nomogram based on contrast-enhanced T1-weighted imaging（CE-T1WI）radiomics and clinical-MRIomics for aggressive histological types of endometrial cancer. ***Methods*：**A total of 192 patients with endometrial cancer pathologically confirmed by surgery at The First Affiliated Hospital，Southern University of Science and Technology，from January 2016 to August 2024 were retrospectively analyzed，including 48 patients with aggressive histological types. The patients were randomly divided into a training set（n=134）and a test set（n=58）at a ratio of 7∶3. Radiomic features were extracted using ITK-SNAP，and feature selection was performed using multivariable analysis and least absolute shrinkage and selection operator（LASSO）regression. Clinical and MRI features were screened using Spearman correlation analysis from 11 parameters，including age，body mass index（BMI），carbohydrate antigen 19-9（CA199），CA125，neutrophil-to-lymphocyte ratio（NLR），apparent diffusion

作者介绍：林清秀，Email：527115161@qq.com，
研究方向：妇科影像诊断。

通信作者：凌人男，Email：670744652@qq.com。

基金项目：深圳市医学研究专项资金资助项目（编号：C2401005）。

优先出版：https://link.cnki.net/urlid/50.1046.R.20250925.1320.014（2025-09-26）

coefficient（ADC），tumor-to-myometrium signal ratio on T2WI（RatioT_2），myometrial invasion >1/2（Deep），depth of myometrial invasion（D_{tra}），maximum tumor diameter（D_{max}），and postcontrast tumor-to-myometrium signal intensity ratio（$Ratio_{CE}$）. Based on radiomics and clinical-MRIomics features，eight models were constructed，including logistic regression（LR），support vector machine（SVM），k-nearest neighbor（KNN），random forest（RF），Extra Trees，XGBoost，LightGBM，and multilayer perceptron（MLP）. Receiver operating characteristic（ROC）curves were used to select the optimal radiomics and clinical-MRIomics models for constructing the nomogram. Calibration curves were used to evaluate calibration，and decision curve analysis（DCA）was used to assess clinical utility. ***Results***：Seven radiomic features and five clinical-MRI features，namely age，CA199，ADC，RatioCE，and Deep，were incorporated into the models. Among the radiomics and clinical-MRIomics models，the LightGBM model showed the best predictive performance. The AUCs of the radiomics model were 0.889 and 0.788 in the training and test sets，respectively，while those of the clinical-MRIomics model were 0.893 and 0.835，respectively. In the test set，the AUC，accuracy，sensitivity，and specificity of the nomogram were 0.888，0.879，0.800，and 0.907，respectively. Calibration curve and DCA showed that the nomogram had good calibration and a relatively high clinical net benefit. ***Conclusion***：The nomogram based on CE-T1WI radiomics and clinical-MRIomics can effectively predict aggressive histological types of endometrial cancer before surgery，providing guidance for individualized treatment.

【Key words】endometrial cancer；radiomics；magnetic resonance imaging；nomogram

子宫内膜癌（endometrial cancer，EC）是我国女性生殖系统中第2常见恶性肿瘤，占女性生殖道恶性肿瘤的20%～30%，75%的病例发病年龄在50岁以上，发病率近年来呈上升趋势，术前准确分期对预后判断和治疗方式选择至关重要[1]。2020年世界卫生组织（World Health Organization，WHO）第5版女性生殖器官肿瘤将EC的组织学类型细分为：低级别子宫内膜样癌（G1、G2）和高级别子宫内膜样癌（G3），浆液性癌、透明细胞癌、混合性癌、未分化癌、癌肉瘤、中肾样癌和胃肠道黏液性癌[2]。其中子宫内膜样癌是最常见的组织学类型，G1和G2通常与良好的预后相关，G3异质性较大，也是应用分子分型最受益的类型。浆液性癌约占10%，但由于其侵袭性、化疗耐药性和早期复发，导致高达40%的EC相关死亡[3]。国际妇产科联盟（International Federation of Gynecology and Obstetrics，FIGO）分期是指导EC治疗决策和预测预后的重要工具，经过多次的更新和修订，目前推荐使用FIGO 2023分期[4]。该分期基于FIGO 2009作了重大修订，纳入了组织学类型和分化程度、分子分型、淋巴血管间隙浸润（lymph-vascular space invasion，LVSI）、淋巴结转移的位置及大小，同时明确了子宫和卵巢同时受累病例的分期，完善了EC分期的预后价值。FIGO 2023将EC组织学类型分为非侵袭性和侵袭性，这是新版分期中的重大变化，直接影响FIGOⅠ和Ⅱ期。非侵袭性组织类型即低级别子宫内膜样癌，侵袭性组织类型包括高级别子宫内膜样癌、浆液性癌、透明细胞癌、混合性癌、未分化癌、癌肉瘤、中肾样癌和胃肠道黏液性癌。不同于非侵袭性组织类型，侵袭性组织类型将使分期升级，如局限在子宫息肉或子宫内膜者将使分期由ⅠA1升为ⅠC，侵犯子宫肌层者将使分期由ⅠA2或ⅠB升为ⅡC。治疗上，ⅠA和ⅠB行子宫切除术和双侧输卵管卵巢切除术，ⅠC期更强调全面分期手术以排除隐匿性淋巴转移和腹膜转移，术后辅助化疗，ⅡC期则术后辅助化疗和/或放疗[1,5]。既往研究多集中在对子宫肌层浸润深度、LVSI、淋巴结转移的预测[6-8]，侵袭性组织类型的相关报道不多，如何提高术前分期准确性是亟待解决的问题。因此，本研究旨在实现2个目标：首先，总结侵袭性EC的临床指标和MRI征象的特征；其次，建立影像组学、临床MRI特征组学模型，并建立基于组学的列线图以预测侵袭性EC，指导术前临床决策及个体化治疗。

1 资料与方法

1.1 研究对象

本研究经南方科技大学第一附属医院医学伦理委员会批准（批准文号：LL-KY-2024018-02），免除患者知情同意。回顾性分析本院2016年1月到2024年8月住院手术并经病理诊断为子宫内膜癌患者192例，其中侵袭性组织学类型48例，按倾向性评分匹配原则纳入非侵袭性组织学类型144例。纳入标准：①所有病例均接受根治性子宫切除术及盆腔淋巴结清扫术；②术前2周内行MRI检查。排除标准：①MRI检查前接受放化疗、免疫抑制治疗；②肿瘤最大径<1 cm或肿瘤巨大突破子宫浆膜层；③合并子宫内膜异位症或子宫肌瘤；④图像质量差，图像处理失败；⑤临床资料不完整；⑥既往妇科肿瘤手术史。

1.2 扫描设备及参数

采用Siemens Magnetom Skyra 3.0 T（西门子，德国）MRI扫描仪，8通道相控阵线圈，全腹部MRI平扫和增强扫描，所有患者MRI检查均在同一台机器完成。患者在检查前至少禁食4 h，检查时膀胱适度充盈，直肠及阴道未做填塞。按照0.1 mmol/kg注射钆喷酸葡胺（gadolinium-diethylenetriamine-pentaacetic acid，Gd-DTPA）后约60 s采集增强矢状位vibe-T1WI，扫描参数：重复时间（repetition time，TR）/回波时间（echo time，TE）=3.3 ms/1.3 ms，视野（field of view，FOV）：320 mm × 320 mm，层厚：1.2 mm，层间距：0。

1.3 影像组学分析

影像组学流程：图像分割、特征提取、特征筛选、降维以及建模，见图1。

1.3.1 图像分割及影像组学特征提取 使用开源软件ITK-SNAP（vesion 3.8.0，http://www.itksnap.org）增强矢状位vibe-T1WI图像进行逐层手工分割，勾画前全面复习平扫、增强和弥散加权序列，由2名分别具有15年及3年妇科影像诊断的医师通过协商进行手动图像分割，得到3D VOI，勾画时对组织学类型不知晓，勾画感兴趣区时范围包括肿瘤出血、囊变或坏死区域，尽量避开宫腔，当肿瘤累及宫腔时，此类病例也纳入到了研究中。

采用PyRadiomics（http://pyradiomics. readthedocs.io）来提取放射组学特征。最终提取107个组学特征，包括一阶特征（first-order features），形态特征（shape features），灰度依赖矩阵（gray-level dependence matrix，GLDM）、灰度区域大小矩阵（gray-level size zone matrix，GLSZM）、灰度游程矩阵（gray-level run length matrix，GLRLM）和灰度共生矩阵（gray-level co-occurrence matrix，GLCM）。

1.3.2 影像组学模型建立 影像组学特征参数进行Z-score标准化处理，采用最小值-最大值进行归一化处理后以消除提取特征的值尺度的差异。在训练集中通过多因素分析筛选组学特征，再通过LASSO回归进行降维，检验水准α=0.05。确定组学特征后建模，得到组学模型并计算Rad-score。分别建立逻辑回归（logistic Regression，LR）、支持向量机（support vector machine，SVM）、k紧邻（k-nearest Neighbor，KNN）、随机森林（random forest，RF）、极度随机树（extremely randomized trees，Extra Trees）、极端梯度提升（extreme gradient boosting，XGBoost）和轻量级梯度提升（light gradient boosting machine，LightGBM）、多次感知器（multilayer perceptron，MLP）模型。

1.4 临床MRI特征组学模型建立

1.4.1 临床特征 一般资料：年龄、体质指数（body mass index，BMI）、FIGO 2009分期。血清学资料：糖类抗原199（carbohydrate antigen 199，CA199）、CA125、中性粒细胞与淋巴细胞比值（neutrophil-to-lymphocyte Ratio，NLR）。病理资料：LVSI、淋巴结转移。常规MRI特征：表观弥散系数（apparent diffusion coefficient，ADC）、肿瘤与子宫肌层T2WI信号比值（RatioT_2），肿瘤累及子宫肌层>1/2（Deep），肿瘤累及子宫肌层的深度（D_{tra}），肿瘤的最大直径（D_{max}）和增强后肿瘤与子宫肌层信号强度比值（$Ratio_{CE}$）。

1.4.2 临床MRI特征组学模型建立 本研究共纳入候选的临床指标和MRI特征11个参数，包括年龄、BMI、CA199、CA125、NLR、ADC、RatioT_2、Deep、D_{tra}、D_{max}、$Ratio_{CE}$。将临床指标和MRI特征参数进行Z-score归一化处理。在训练集中采用Spearman相关分析筛选临床MRI特征，检验水准α=0.05，确定有统计学意义的指标后建模。分别建立LR、SVM、KNN、RF、Extra Trees、XGBoost、LightGBM、MLP模型。

1.5 影像组学模型与临床MRI特征组学模型构建列线图

基于影像组学Radscore和临床MRI特征组学模型构建预测子宫内膜癌侵袭性列线图（nomogram）。绘制受试者工作特征（receiver operating characteristic，ROC）曲线、计算曲线下面积（area under the curve，AUC）、敏感度和特异度评估模型预测效能，利用DCA评价列线图的净效益。

1.6 统计学方法

使用Python（https://www.python.org）进行统计分析。采用SPSS 26.0软件进行分析，采用Kolmogorov-Smirnov检验评估连续变量的正态分布，符合正态分布的计量资料比较采用独立样本t检验，不符合正态分布的计量资料比较采用Mann-Whitney U检验，分类数据比较采用卡方检验。正态分布计量资料用均数 ± 标准差（$\bar{x} \pm s$）描述，非正态计量资料用中位数四分位数[M_d(P_{25},P_{75})]表示，计数资料用率、构成比表示。相关性分析采用Spearman检验，相关系数绝对值在

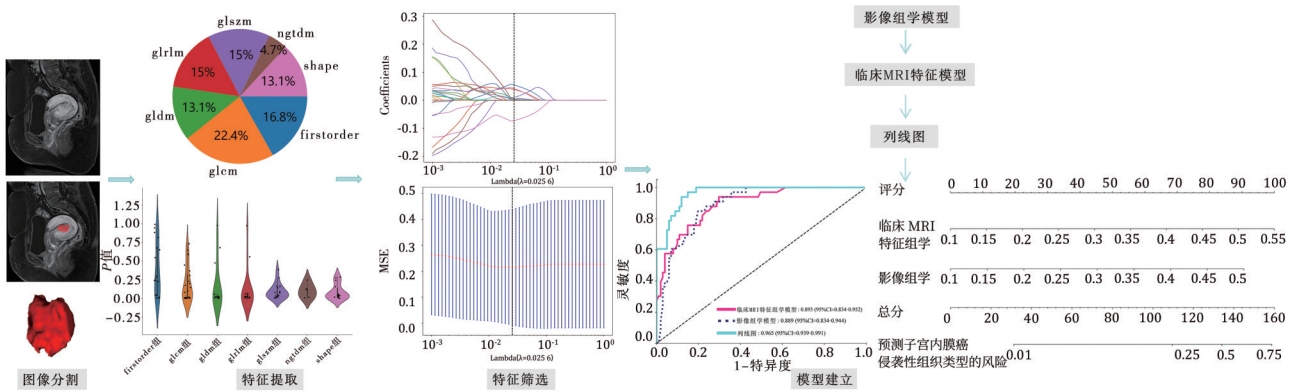


图1 影像组学分析流程图

<0.3 表示没有相关性，在 0.3~0.8 表示有相关性，>0.8 表示强相关性。不同模型的 ROC 曲线采用 DeLong 检验比较。统计方法均采用双侧检验，检验水准 α=0.05。

2 结 果

2.1 一般资料

192 例患者按组织病理类型分为侵袭性组织类型 48 例和非侵袭性组织类型性 144 例。侵袭性组织类型平均年龄（59.58 ± 7.12）岁，非侵袭性组织类型年龄（53.44 ± 10.11）岁，差异有统计学意义（t=3.070，P=0.003）。侵袭性组织类型 FIGO 2009 分期，Ⅰ期 28 例、Ⅱ期 5 例、Ⅲ期 10 例、Ⅳ期 5 例；非侵袭性组织类型Ⅰ期 119 例、Ⅱ期 8 例、Ⅲ期 17 例。侵袭性组织类型 LVSI 阳性 33 例（68.75%），非侵袭性组织类型 LVSI 阳性 24 例（16.67%），差异有统计学意义（P=0.001）。侵袭性组织类型有淋巴结转移 13 例（27.08%），非侵袭性组织类型有淋巴结转移 13 例（9.03%），差异有统计学意义（χ^2=7.828，P=0.001）。

按 7∶3 比例随机分为训练集（n=134）、测试集（n=58），训练集中侵袭性组织类型 33 例、非侵袭性组织类型 101 例，测试集中侵袭性组织类型 15 例、非侵袭性组织类型 43 例。训练集中侵袭性组织类型的年龄为（59.61 ± 7.54）岁、CA 199 为（39.11 ± 101.28）U/mL、ADC 值（0.800 ± 0.125）×10^{-3} mm^2/s、$Ratio_{CE}$ 值为 0.69 ± 0.15、肿瘤累及子宫肌层>1/2 者为 15 例（45.45%）等 5 个特征均高于非侵袭性组织类型，差异有统计学意义（t=3.070，P=0.003；t=0.051，P=0.018；t=1.755，P=0.045；t=2.617，P=0.010），在测试集中年龄、BMI、ADC 值、$Ratio_{CE}$ 的差异有统计学意义（t=2.389，P=0.020；t=−3.257，P=0.002；t=2.260，P=0.009；t=2.623，P=0.011），见表 1。

2.2 影像组学模型

本研究共收集 192 例 MRI 图像/病例，ICC>0.75 的组学特征纳入模型，LASSO 回归降维后最终有 7 个组学特征参与构建影像组学特征模型（图 2）。本课题组采用网格搜索，5 倍交叉验证和最小误差标准来确定最佳 λ，其中 λ 的最终值（λ=0.025）产生最小交叉验证误差，分别构建 LR、SVM、KNN、RF、Extra Trees、XGBoost、LightGBM、MLP 模型，训练集和测试集的敏感度和特异度见表 2，ROC 见图 3A 和图 3B。LightGBM 模型的训练集和测试集的 AUC 分别为 0.889（95%CI=0.834~0.944）和 0.788（95%CI=0.663~0.913），最大约登指数分别为 0.65 和 0.477，模型性能最好。

2.3 临床 MRI 特征组学模型

分析 11 个临床指标和 MRI 特征，选取 P<0.05 的指标，采用单因素 logistic 回归及向后逐步 logistic 回归法、spearman 相关分析确定参数之间的线性关系，将没有显著线性相关的参数输入到模型中以构建临床 MRI 特征组学模型。筛选出 5 个特征，即年龄、CA199、ADC、$Ratio_{CE}$、Deep（P=0.003、0.018、0.045、0.010 和 0.022）参与构建 LR、SVM、KNN、RF、Extra Trees、XGBoost、LightGBM、MLP 模型，训练集和测试集的敏感度和特异度见表 3、ROC 见图 3C 和图 3D。LightGBM 模型的训练集和测试集的 AUC 分别为 0.893（95%CI=0.833~0.951）和 0.835（95%CI=0.718~0.951），最大约登指数分别为 0.642 和 0.574，模型性能最好。

2.4 影像组学、临床 MRI 特征组学列线图在训练组和测试组的对比

综合影像组学模型和临床 MRI 特征组学模型的比较结果显示，LightGBM 模型性能最佳。在训练集中，临床 MRI 特征组学模型的敏感度和特异度分别为 0.939 和 0.703，影像组学模型的敏感度和特异度分别为 0.848 和 0.802。基于影像组学和临床 MRI 特征组学构建列线图（图 4），敏感度和特异

表 1 训练集和测试集患者临床指标–MRI 特征（$\bar{x} \pm s$；n，%）

特征	训练集（n=134）		χ^2/t 值	P 值	测试集（n=58）		χ^2/t 值	P 值
	侵袭性组织类型（n=33）	非侵袭性组织类型（n=101）			侵袭性组织类型（n=15）	非侵袭性组织类型（n=43）		
年龄（岁）	59.61 ± 7.54	54.02 ± 9.52	3.070	0.003	59.53 ± 6.52	52.09 ± 11.38	2.389	0.020
BMI（kg/m^2）	24.18 ± 3.03	24.91 ± 3.63	−1.045	0.337	22.85 ± 4.13	26.46 ± 3.54	−3.257	0.002
CA125（U/mL）	54.35 ± 99.95	38.29 ± 60.41	1.102	0.229	35.90 ± 41.14	29.28 ± 26.58	0.731	0.709
CA199（U/mL）	39.11 ± 101.28	38.02 ± 56.66	0.051	0.018	17.68 ± 15.31	24.29 ± 22.46	−0.916	0.558
中性粒细胞与淋巴细胞比值	2.97 ± 2.39	3.42 ± 2.94	−0.804	0.559	2.80 ± 1.87	2.61 ± 2.53	0.265	0.185
表观弥散系数（×10^{-3} mm^2/s）	0.800 ± 0.125	0.752 ± 0.140	1.755	0.045	859.70 ± 161.22	756.09 ± 156.02	2.260	0.009
累及子宫肌层的深度（mm）	19.09 ± 13.68	15.89 ± 8.50	1.595	0.575	17.20 ± 14.53	13.07 ± 7.77	1.391	0.936
肿瘤的最大直径（mm）	36.67 ± 20.16	36.26 ± 17.39	0.113	0.901	45.00 ± 28.71	33.33 ± 16.61	1.916	0.189
肿瘤与子宫肌层 T2WI 信号比值	1.38 ± 0.47	1.47 ± 0.65	−0.777	0.745	1.47 ± 0.53	1.62 ± 0.79	−0.644	0.702
增强后肿瘤与子宫肌层信号强度比值	0.69 ± 0.15	0.62 ± 0.11	2.617	0.010	0.74 ± 0.19	0.63 ± 0.13	2.623	0.011
肿瘤累及子宫肌层深度			6.299	0.022			2.730	0.098
<1/2	18（54.55）	78（77.23）			7（46.67）	32（74.42）		
>1/2	15（45.45）	23（22.77）			8（53.33）	11（25.58）		

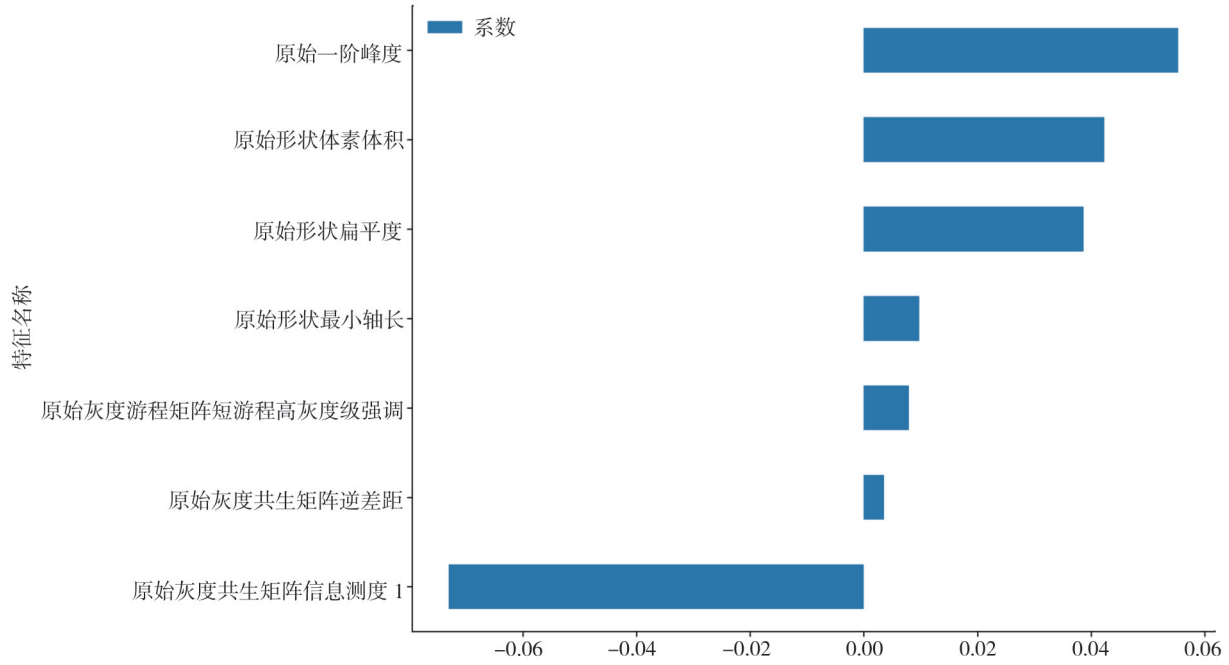


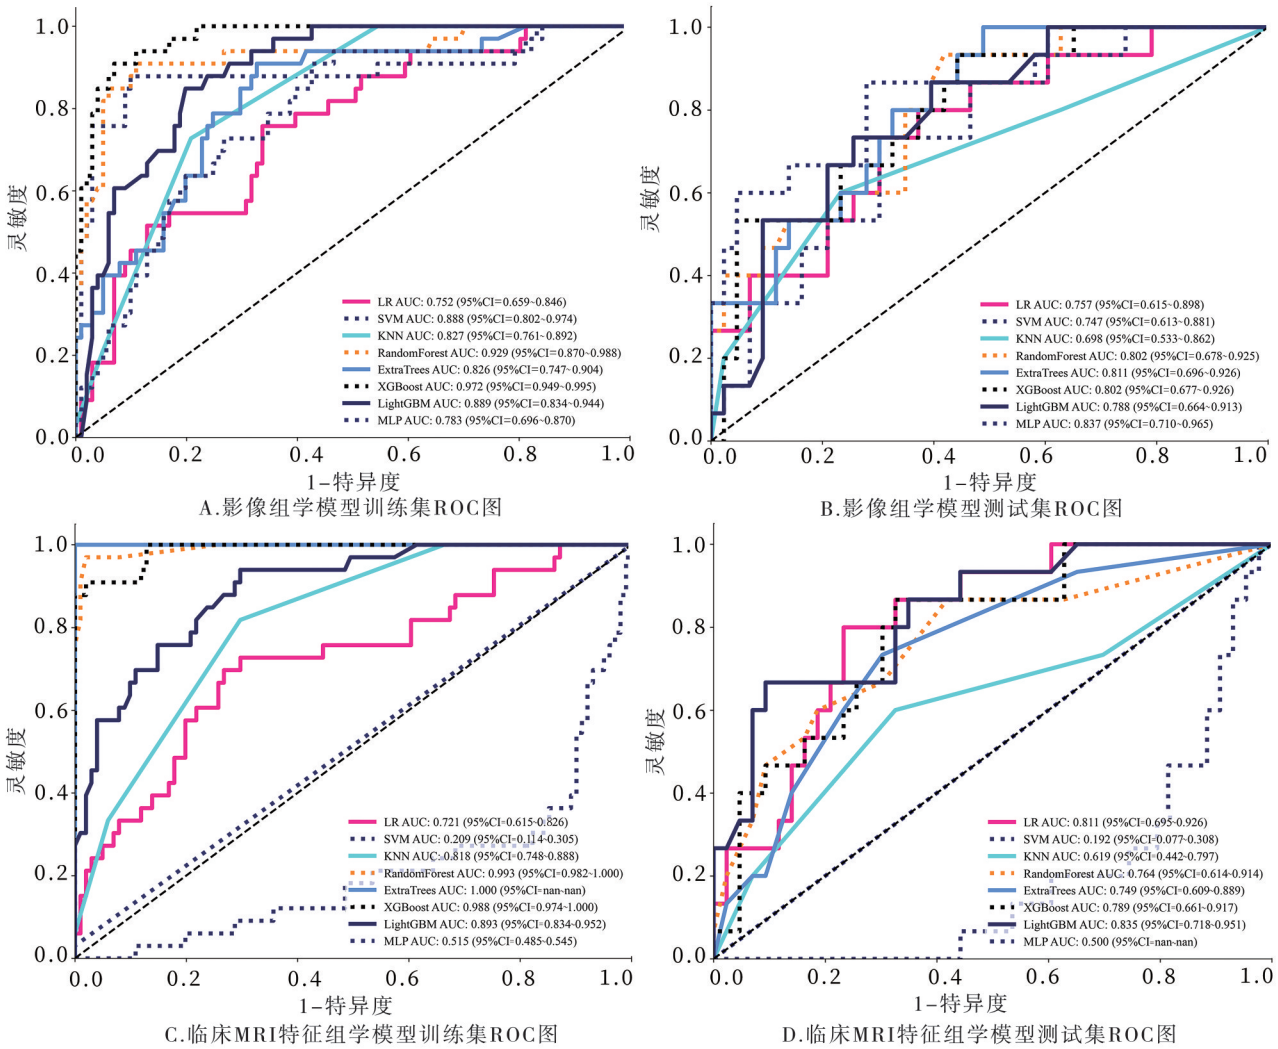
图2　使用LASSO回归选择影像组学特征

表2　影像组学模型ROC曲线分析结果

模型	分组	分类准确率	AUC	95%CI	敏感度	特异度	阳性预测值	阴性预测值	最大约登指数
LR	训练集	0.687	0.752	0.658~0.845	0.758	0.663	0.424	0.893	0.421
	测试集	0.707	0.757	0.615~0.898	0.733	0.698	0.458	0.882	0.431
SVM	训练集	0.896	0.888	0.802~0.974	0.879	0.901	0.744	0.958	0.780
	测试集	0.707	0.747	0.613~0.881	0.733	0.698	0.458	0.882	0.431
KNN	训练集	0.776	0.827	0.760~0.892	0.727	0.792	0.533	0.899	0.519
	测试集	0.724	0.698	0.533~0.862	0.600	0.767	0.474	0.846	0.367
RandomForest	训练集	0.896	0.929	0.869~0.987	0.909	0.891	0.732	0.968	0.800
	测试集	0.672	0.802	0.678~0.925	0.933	0.581	0.437	0.962	0.514
Extra Trees	训练集	0.731	0.826	0.746~0.904	0.909	0.673	0.476	0.958	0.582
	测试集	0.638	0.811	0.696~0.925	1.000	0.512	0.417	1.000	0.512
XGBoost	训练集	0.925	0.972	0.948~0.995	0.909	0.931	0.811	0.969	0.840
	测试集	0.655	0.802	0.676~0.926	0.933	0.558	0.424	0.960	0.491
LightGBM	训练集	0.813	0.889	0.834~0.944	0.848	0.802	0.583	0.942	0.650
	测试集	0.741	0.788	0.663~0.913	0.733	0.744	0.500	0.889	0.477
MLP	训练集	0.657	0.783	0.696~0.869	0.909	0.574	0.411	0.951	0.483
	测试集	0.759	0.837	0.709~0.964	0.867	0.721	0.520	0.939	0.588

注：LR，逻辑回归模型；SVM，支持向量机模型；KNN，k近邻模型；RF，随机森林模型；Extra Trees，极度随机树模型；XGBoost，极端梯度提升模型；LightGBM，轻量级梯度提升模型；MLP，多次感知器模型

度（表4）。测试集中影像组学模型的AUC为0.788（95%CI=0.663~0.913），分类准确率、敏感性和特异性为0.741、0.733和0.744；临床MRI特征组学模型的AUC为0.835（95%CI=0.718~0.951），分类准确率、敏感度和特异性为0.845、0.667和0.907；列线图的AUC为0.888（95%CI=0.791~0.985），分类准确率、敏感度和特异性为0.879、0.800和0.907。DeLong检验结果显示训练集中列线图模型与影像组学模型、临床MRI特征组学模型ROC差异均有统计学意义（Z=2.748和2.968，P=0.002和0.003）；测试集中列线图模型效能优于影像组学模型、临床MRI特征组学模型，但ROC差异无统计学意义（Z=1.481和1.695，P=0.138和0.090）。校准曲线表明模型具有良好的校准度（Hosmer-Lemeshow检验，P=0.053），DCA显示阈值概率在30.4%~100%，列线图预测侵袭性子宫内膜癌中显示更好的应用价值，见图5。



注：LR，逻辑回归模型；SVM，支持向量机模型；KNN，k 近邻模型；RF，随机森林模型；Extra Trees，极度随机树模型；XGBoost，极端梯度提升模型；LightGBM，轻量级梯度提升模型；MLP，多次感知器模型

图 3　影像组学模型和临床 MRI 组学模型 ROC 图

表 3　临床 MRI 特征组学模型 ROC 曲线分析结果

模型	分组	分类准确率	AUC	95%CI	敏感度	特异度	阳性预测值	阴性预测值	最大约登指数
LR	训练集	0.709	0.721	0.615~0.826	0.727	0.703	0.444	0.887	0.430
	测试集	0.776	0.811	0.695~0.926	0.800	0.767	0.545	0.917	0.567
SVM	训练集	0.246	0.209	0.113~0.305	1.000	0.000	0.246	0.000	0.000
	测试集	0.276	0.192	0.076~0.307	1.000	0.023	0.263	1.000	0.023
KNN	训练集	0.731	0.818	0.748~0.888	0.818	0.703	0.474	0.922	0.521
	测试集	0.655	0.619	0.441~0.796	0.600	0.674	0.391	0.829	0.274
RandomForest	训练集	0.978	0.993	0.981~1.000	0.970	0.980	0.941	0.990	0.950
	测试集	0.655	0.764	0.614~0.914	0.867	0.581	0.419	0.926	0.448
Extra Trees	训练集	1.000	1.000	1.000~1.000	1.000	1.000	1.000	1.000	1.000
	测试集	0.707	0.749	0.608~0.888	0.733	0.698	0.458	0.882	0.431
XGBoost	训练集	0.963	0.988	0.974~1.000	0.909	0.980	0.937	0.971	0.889
	测试集	0.724	0.789	0.661~0.916	0.867	0.674	0.481	0.935	0.541
LightGBM	训练集	0.761	0.893	0.833~0.951	0.939	0.703	0.508	0.973	0.642
	测试集	0.845	0.835	0.718~0.951	0.667	0.907	0.714	0.886	0.574
MLP	训练集	0.761	0.515	0.485~0.544	0.030	1.000	1.000	0.759	0.030
	测试集	0.259	0.500	0.380~0.620	1.000	0.000	0.259	0.000	0.000

注：LR，逻辑回归模型；SVM，支持向量机模型；KNN，k 邻模型；RF，随机森林模型；Extra Trees，极度随机树模型；XGBoost，极端梯度提升模型；LightGBM，轻量级梯度提升模型；MLP，多次感知器模型

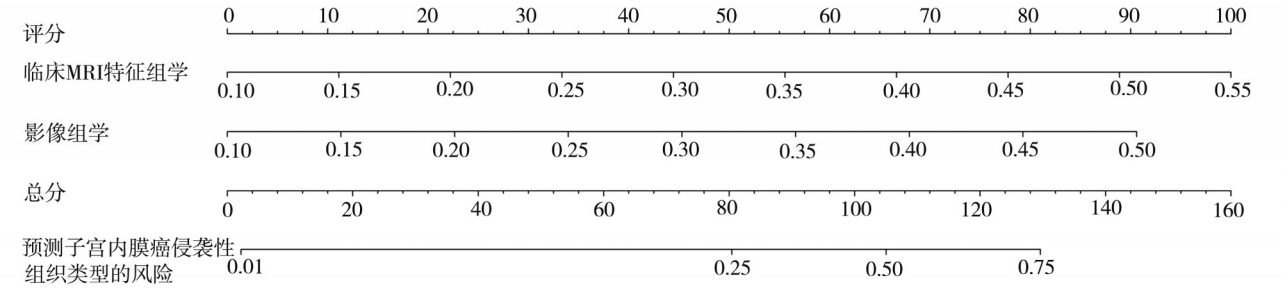


图4　基于影像组学和临床MRI特征组学构建的列线图

表4　影像组学、临床MRI特征组学列线图的ROC曲线分析结果

模型	分组	分类准确率	AUC	95%CI	敏感度	特异度	阳性预测值	阴性预测值	最大约登指数
影像组学	训练集	0.761	0.893	0.833~0.951	0.939	0.703	0.508	0.973	0.642
	测试集	0.845	0.835	0.718~0.951	0.667	0.907	0.714	0.886	0.574
临床MRI特征组学	训练集	0.813	0.889	0.834~0.944	0.848	0.802	0.583	0.942	0.650
	测试集	0.741	0.788	0.663~0.913	0.733	0.744	0.500	0.889	0.477
列线图	训练集	0.881	0.965	0.939~0.990	0.970	0.851	0.681	0.989	0.821
	测试集	0.879	0.888	0.791~0.985	0.800	0.907	0.75	0.929	0.707

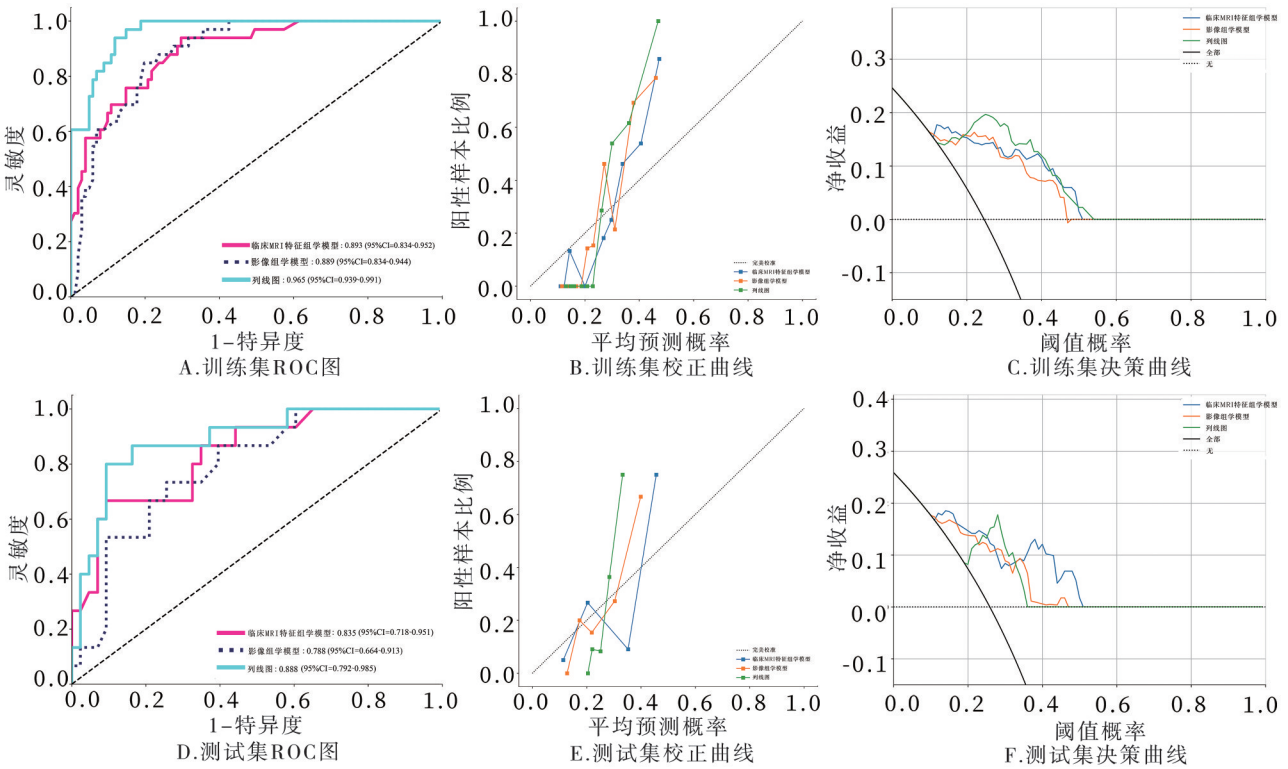


图5　列线图的ROC图和决策曲线

3　讨　论

低级别的子宫内膜癌生物学行为总是非常惰性的，预后好；浆液性癌虽然是少见组织类型，发病率占子宫内膜癌3%~10%，但恶性程度高，5年总生存率在18%~27%，病死率占子宫内膜癌的39%[9-10]。本研究通过对浸润性组织学类型EC进行影像组学模型、临床指标和MRI特征的分析并建立临床MRI特征组学模型，进而构建了预测EC浸润性的列线图模型，提高了术前FIGO 2023 Ⅰ和Ⅱ分期准确性，对临床的决策选择有指导作用。

血清标志物是临床最易获得的指标，在临床诊断和治疗中发挥着重要的监测和指导作用。近期研究显示HE4、CA125、CA199的表达水平与肿瘤分期密切相关，多指标联合有利于预测高分期[6]。本组病例中HE4指标缺失超过一半，故未纳入研究中；侵袭性组中的CA199和CA125表达水平高于非侵袭性组，CA125表达水平差异有统计学意义，与既往研究相符[11]。在训练集中或在临床MRI特征分析中CA199表达水平的差异有统计学意义，进而将CA199指标纳入了临床MRI特征组学模型中。

MRI是子宫内膜癌分期的首选检查方法，T2WI是诊断的重要序列，T2WI联合增强在预测肌层浸润和子宫颈间质浸润的诊断敏感度大于0.8，弥散加权能够在分子水平反映肿瘤，且能提供定量指标ADC值，报道显示ADC值与侵袭性疾病的分期和预后有关[12]。Kishimoto K等[13]研究显示ADC值与EC的分级呈负相关，高级别EC的平均ADC值为$(0.810 \pm 0.117)\times10^{-3}\,mm^2/s$。本研究结果显示侵袭性组的ADC值为$(0.800 \pm 0.125)\times10^{-3}\,mm^2/s$，与既往研究相仿，但是高于非侵袭性组，这可能是由于本组资料肿瘤体积较大，侵袭性组病例更易继发出血和坏死，导致ADC值增高。Ling RN等[14]指出侵袭性EC更具侵袭性更易累及子宫深肌层，相对于非侵袭性EC更易出现坏死，因此具有更高的$RatioT_2$值、$Ratio_{CE}$值，这与本研究结果相符。最终ADC值、Deep，$Ratio_{CE}$值3个MRI指标进而纳入临床MRI特征组学模型。

MRI影像组学广泛应用在预测子宫内膜癌的病理分级及高危因素评估、LVSI、淋巴结转移中，发挥着积极的作用[15-17]，Jiang XT等[18]学者创新性地将影像学组应用到常规MRI不能辨认的早期EC的诊断中，预测模型性能良好，预测早期子宫内膜癌AUC为0.834、肌层侵犯AUC为0.918，这意味着或许影像学组模型未来可以作为早期EC筛查工具。然而，最近的1项Meta分析指出[19]，在基于MRI影像组学的45项研究中，系统性误差造成“Index Test”和“Flow and Timing”偏倚，影像组学质量评分（radiomics quality score，RQS）为中等水平，平均RQS为13.77（9~22.5），方法论不尽如人意。然而，在鉴别诊断和风险预测方面显示出良好的应用前景，优势比（odds ratios，OR）为23.81（95%CI=8.48~66.83），风险预测*OR*为18.23（95%CI=13.68~24.29）。MRI影像组学常采用多参数，主要依托于T2WI、ADC、增强T1WI序列。对比既往报道，本研究关注到合并子宫内膜异位症、子宫肌瘤的EC病例在ROI勾画时存在对肿瘤边界界定的混淆，为避免干扰故排除了此类病例。并创新性将$RatioT_2$、Deep、D_{tra}、D_{max}、$Ratio_{CE}$引入到组学模型中，将常规MRI特征和临床指标组成临床MRI特征组学模型，MRI影像组学模型依托于增强T1WI，进而建立了基于MRI影像组学、临床MRI特征组学列线图。该列线图校准度较高，临床净收益较大，可以有效地鉴别侵袭性EC与非侵袭性EC。

本研究的局限性：①单中心回顾性研究，样本量不足够多，不可避免的出现选择性偏倚；②ROI为手动勾画，未来会寻求全自动分割来提供更精确的数据；③缺少外部验证集，后续会展开多中心研究；④未纳入基因组学或病理分子分型等数据。未来希望能够预测早期EC，特别肿瘤很小仅仅局限在宫腔、息肉内时，能够做到早发现、早诊断、早治疗；希望能够通过基因组学、病理分子分型等数据分析进一步探索组学特征的生物学机制，以提高患者生活质量和预后。

综上所述，侵袭性EC相对于非侵袭性EC而言，发病年龄更大，易浸润深肌层、易发生LVSI受累和淋巴结转移，CA125和CA199表达水平更高、更高的ADC值、更高的$Ratio_{CE}$值。本研究创新性地首次将MRI定量指标引入到组学模型中，建立了基于CE-T1WI的影像组学和临床MRI特征组学构建的列线图模型，可以较好的术前评估子宫内膜癌侵袭性组织类型，提高术前分期准确性，协助临床决策。

利益冲突 所有作者声明不存在利益冲突

作者贡献声明 林清秀、凌人男：研究方案设计、实施研究、分析数据、论文撰写；李金贝贝、何子坤：数据收集

参 考 文 献

[1] 宋 艳，刘爱军. 子宫内膜癌FIGO 2023分期的更新及其临床病理意义[J]. 中华妇产科杂志，2024，59(3)：179-183.
Song Y，Liu AJ. Updates of the FIGO 2023 staging for endometrial cancer and their clinicopathological significance[J]. Chin J Obstet Gynecol，2024，59(3)：179-183.

[2] WHO Classification of Tumours Editorial Board. WHO classification of tumours：female genital tumours[M]. 5th ed. Lyon：IARC Publica-

tions，2020：252-267.

[3] Crosbie EJ，Kitson SJ，McAlpine JN，et al. Endometrial cancer[J]. Lancet，2022，399（10333）：1412-1428.

[4] Berek JS，Matias-Guiu X，Creutzberg C，et al. FIGO staging of endometrial cancer：2023[J]. Int J Gynaecol Obstet，2023，162（2）：383-394.

[5] 谢玲玲，林仲秋. 2024 NCCN子宫肿瘤临床实践指南（第1版）解读[J]. 中国实用妇科与产科杂志，2023，39（11）：1122-1127.

Xie LL，Lin ZQ. Interpretation of the 2024 NCCN clinical practice guidelines in oncology for uterine neoplasms（Version 1）[J]. Chin J Pract Gynecol Obste，2023，39（11）：1122-1127.

[6] 王 娜，郭云峰，宋立芹，等. HE4、CA125及CA199在鉴别子宫内膜癌肌层浸润深度及病理分期中的临床应用价值[J]. 重庆医科大学学报，2022，47（10）：1220-1225.

Wang N，Guo YF，Song LQ，et al. Clinical value of serum HE4，CA125 and CA199 in identifying myometrial invasion depth and pathological stage of endometrial carcinoma[J]. J Chongqing Med Univ，2022，47（10）：1220-1225.

[7] 黄雅洁，赵文学，刘 珂，等. 术前指标对子宫内膜癌淋巴脉管间隙浸润风险的影响[J]. 重庆医科大学学报，2023，48（6）：703-707.

Huang YJ，Zhao WX，Liu K，et al. Impact of preoperative indicators on the risk of lymphovascular space invasion in endometrial cancer[J]. J Chongqing Med Univ，2023，48（6）：703-707.

[8] Yan B，Zhao TT，Deng Y，et al. Preoperative prediction of lymph node metastasis in endometrial cancer patients *via* an intratumoral and peritumoral multiparameter MRI radiomics nomogram[J]. Front Oncol，2024，14：1472892.

[9] 韩 瑛，刘崇东. 子宫浆液性癌的起源及临床研究进展[J]. 中国实用妇科与产科杂志，2020，36（8）：779-781.

Han Y，Liu CD. Origin and clinical research progress of uterine serous carcinoma[J]. Chin J Pract Gynecol Obstet，2020，36（8）：779-781.

[10] 刘从容，刘 岩. 子宫内膜癌传统组织病理与分子分型整合诊断的临床意义[J]. 中国实用妇科与产科杂志，2023，39（11）：1073-1080.

Liu CR，Liu Y. Clinical significance of integrated diagnosis based on traditional histopathology and molecular classification of endometrial carcinoma[J]. Chin J Pract Gynecol Obstet，2023，39（11）：1073-1080.

[11] 黄成香，李 翠，张海堂，等. 子宫内膜癌肿瘤体积与子宫体积比值联合血清AFP、CA199、HE4的表达对病理分级和预后的评估价值[J]. 中华内分泌外科杂志（中英文），2025，19（4）：589-594.

Huang CX，Li C，Zhang HT，et al. Value of tumor volume to uterine volume ratio combined with serum AFP，CA199，HE4 expression in evaluating pathological grade and prognosis of endometrial carcinoma[J]. Chin J Endocr Surg，2025，19（4）：589-594.

[12] 林玲玲，程杰军. 放射影像学检查在子宫内膜癌诊断中的价值[J]. 中国实用妇科与产科杂志，2023，39（11）：1065-1070.

Lin LL，Cheng JJ. Value of imaging examination in the diagnosis and treatment of endometrial cancer[J]. Chin J Pract Gynecol Obstet，2023，39（11）：1065-1070.

[13] Kishimoto K，Tajima S，Maeda I，et al. Endometrial cancer：correlation of apparent diffusion coefficient（ADC）with tumor cellularity and tumor grade[J]. Acta Radiol，2016，57（8）：1021-1028.

[14] Ling RN，Jin HT，Zhang H. The qualitative and quantitative characteristics of serous endometrial carcinoma on MRI：applying a novel nomogram for predicting an aggressive histological type[J]. Front Oncol，2025，15：1472250.

[15] Yue XN，He XY，He SJ，et al. Multiparametric magnetic resonance imaging-based radiomics nomogram for predicting tumor grade in endometrial cancer[J]. Front Oncol，2023，13：1081134.

[16] Moro F，Albanese M，Boldrini L，et al. Developing and validating ultrasound-based radiomics models for predicting high-risk endometrial cancer[J]. Ultrasound Obstet Gynecol，2022，60（2）：256-268.

[17] Wang YD，Liu W，Lu YY，et al. Fully automated identification of lymph node metastases and lymphovascular invasion in endometrial cancer from multi-parametric MRI by deep learning[J]. J Magn Reson Imaging，2024，60（6）：2730-2742.

[18] Jiang XT，Song JC，Zhang AN，et al. Preoperative assessment of MRI-invisible early-stage endometrial cancer with MRI-based radiomics analysis[J]. J Magn Reson Imaging，2023，58（1）：247-255.

[19] Huang ML，Ren J，Jin ZY，et al. Application of magnetic resonance imaging radiomics in endometrial cancer：a systematic review and meta-analysis[J]. Radiol Med，2024，129（3）：439-456.

（**收稿**：2025-04-27；**修回**：2025-07-21；**录用**：2025-08-01）

（责任编辑：周一青）

本文引用格式：

林清秀，李金贝贝，何子坤，等. 基于增强T1WI影像组学及临床MRI特征组学列线图术前预测子宫内膜癌侵袭性组织类型的价值[J]. 重庆医科大学学报，2026，51（5）：623-631.