论 著

基于MRI影像组学、深度学习及临床特征建立联合模型预测子宫内膜癌淋巴结转移*

郭 冉 彭如臣 李艳翠
沈秀芝 钟佳利 信瑞强*
首都医科大学附属北京潞河医院放射科(北京 101149)

【摘要】**目的** 探讨基于MRI影像组学、深度学习(DL)及临床特征建立联合模型预测子宫内膜癌(EC)淋巴结转移(LNM)的价值。**方法** 回顾性分析经术后病理证实为EC的临床及MRI资料。按7∶3比例随机分为训练集(130例)和测试集(56例)。采用单因素及多因素Logistic回归分析筛选LNM的独立危险因素，建立临床模型；从MRI图像中提取影像组学和DL特征并建立影像组学、DL及DL-影像组学(DL-radiomics, DLR)模型；最后联合影像组学、DL及临床特征建立联合模型。通过曲线下面积(AUC)、校准曲线和决策曲线评估模型性能。**结果** 年龄、组织学分级均为LNM(+)的独立危险因素(*P*<0.05)。联合模型在训练集和测试集中AUC是最高的，分别为0.964(95%CI=0.934-0.994)和0.860(95%CI=0.677-1.000)。联合模型的校准度较高，临床净收益更大。**结论** 基于MRI的影像组学特征、DL特征联合临床特征建立的联合模型预测EC LNM具有较高诊断效能。

【关键词】子宫内膜癌；影像组学；深度学习；淋巴结转移；磁共振成像
【中国分类号】R711.74；R445.2
【文献标识码】A
【基金项目】北京市通州区科技计划项目(KJ2020CX004-19)；2023年度首都医科大学附属北京潞河医院青年科研孵育专项基金(LHYY2023-LC209)
DOI:10.3969/j.issn.1672-5131.2026.04.037

Combined Model Based on MRI Rdiomics,Deep Learning and Clinical Features for Predicting Lymph Node Metastasis in Endometrial Carcinoma*

GUO Ran, PENG Ru-chen, Li Yan-cui, SHEN Xiu-zhi, ZHONG Jia-li, XIN Rui-qiang*.
Department of Radiology, Beijing Luhe Hospital, Capital Medical University, Beijing 101149, China

ABSTRACT
Objective To investigate the value of a combined model based on MRI radiomics features, deep learning (DL) features, and clinical features in predicting lymph node metastasis (LNM) in patients with endometrial carcinoma (EC). ***Methods*** A retrospective analysis was conducted on clinical and MRI data from patients pathologically confirmed with EC. The patients were randomly divided into a training set (n=130) and a test set (n=56) in a 7:3 ratio. Univariate and multivariate logistic regression analyses were used to identify independent clinical risk factors for LNM, and a clinical model was established. Radiomics and DL features were extracted from MRI images to construct radiomics, DL, and DL-radiomics (DLR) models. Finally, a combined model integrating radiomics, DL, and clinical features was developed. Model performance was evaluated using the area under the curve (AUC), calibration curves, and decision curve analysis. ***Results*** Age and histological grade were identified as independent risk factors for LNM (*P*<0.05). The combined model achieved the highest AUC in both the training and test sets, with values of 0.964 (95% CI: 0.934-0.994) and 0.860 (95% CI: 0.677-1.000), respectively. The combined model demonstrated high calibration and greater clinical net benefit. ***Conclusion*** The combined model based on MRI radiomics features, DL features, and clinical features demonstrates high diagnostic performance in predicting LNM in EC patients.
Keywords: Endometrial Carcinoma; Radiomics; Deep Learning; Lymph Node Metastasis; Magnetic Resonance Imaging

子宫内膜癌(Endometrial carcinoma, EC)是最常见的妇科恶性肿瘤之一，在全球范围内位列恶性肿瘤的第六位。根据2024年发布的全球癌症统计数据，2022年全球新增EC病例420242例，死亡病例97704例[1]。近年来，女性EC的发病率和死亡率呈逐渐上升趋势[2-3]。值得注意的是，自20世纪70年代中期以来，EC是少数几种生存率未见明显改善的癌症之一，其全球健康负担不容忽视[4]。淋巴结转移(Lymph node metastasis, LNM)是影响预后的重要危险因素[2]，对于低危或早期EC是否有必要行淋巴结清扫一直存在争议。研究表明，早期EC盆腔LNM的发生率较低，在10.9%至14.9%之间[5-6]。不加区分的淋巴结切除术可能导致过度治疗及相关术后并发症的增加。因此，准确评估淋巴结状态对于制定个体化治疗方案及评估患者预后具有重要意义。

MRI是评估EC的常规成像方法，然而其评估LNM的敏感性相对较低，约为28.6%-34.0%[7-8]。前哨淋巴结定位技术已被建议用于术中评估LNM或作为系统性淋巴结清扫的替代方案[9]。然而，值得注意的是，该技术的应用面临多重挑战：不同染色剂的选择、注射部位的准确性、患者解剖结构的个体差异、外科医生技术水平的差异、冰冻切片的可用性以及病理诊断的主观性等，共同构成了前哨淋巴结定位技术的复杂性，限制了其临床应用[10]。因此，迫切需要探索其他评估方法，以提高评估的准确性。近年来，从肿瘤中提取的影像组学特征能够很好地反映肿瘤内部的异质性，这些特征可用于预测癌症的侵袭性。然而影像组学依赖于手工提取特征，深度学习(Deep learning, DL)凭借其强大的自动提取特征能力，已成为处理复杂医学影像数据不可或缺的工具。在最近的研究中，DL-影像组学(DL-radiomics, DLR)已被证明是预测淋巴结转移的先进定量工具[11]。本研究旨在基于MRI的影像组学、DL及临床特征建立联合模型并绘制列线图，以准确预测EC患者淋巴结状态。

1 资料与方法

1.1 一般资料 本研究经首都医科大学附属北京潞河医院医学伦理委员会批准，免除受试者知情同意(批准文号: 2023-LHKY-086-01)。回顾性分析我院2013年4月至2024年3月经术后病理证实为EC患者的临床资料。

纳入标准如下：组织病理证实的EC并行淋巴结切除术；MRI检查序列包括轴位T2加权成像(T2-weighted imaging, T2WI)、对比增强T1加权成像(Contrast-enhanced T1-weighted imaging, CE-T1WI)；MRI检查与手术间隔时间小于30天；排除标准如下：缺乏上述任何MRI检查序列；图像存在明显伪影；肿瘤较小，影响感兴趣区(region of interest, ROI)的勾画；未行淋巴结切除；术前行放化疗。

1.2 检查方法 采用3T MRI扫描仪(西门子MAGNETOM Skyra和联影uMR 780)及18通道线圈。图像扫描参数如下：西门子：T2WI: TR 5,000 ms; TE 77 ms；层厚/层间距

【第一作者】郭 冉，女，主治医师，主要研究方向：腹盆部疾病影像诊断。E-mail：guoran_0529@163.com
【通讯作者】信瑞强，男，主任医师，主要研究方向：腹盆部影像学。E-mail：rxin@ccmu.edu.cn

4/1mm；FOV 230 × 230 mm；矩阵320 × 320；联影：T2WI：TR 3,393 ms；TE 81.6ms；层厚/层间距4/1mm；FOV 230 × 230 mm；矩阵320 × 320。以0.2 mmol/kg、2 mL/s的速率静脉注射钆布醇对比剂后立即行矢状位动态增强扫描，随后进行轴位脂肪抑制CE-T1WI扫描(西门子：TR 2.77 ms；TE 1.55 ms；层厚/层间距3/0mm；FOV 340× 340 mm；矩阵320 × 224；联影：TR 4.19 ms；TE 1.99 ms；层厚/层间距3/0mm；FOV 340× 270mm；矩阵352× 248)。

1.3 感兴趣区勾画 由一名诊断经验丰富的主治医师采用ITK-SNAP软件(版本3.8，www.itksnap.org)进行ROI的勾画。在分析图像前，医师对患者的病理学结果不知情。在两个序列上仔细逐层勾画感兴趣区，得到肿瘤的三维容积感兴趣区(Volume of interest, VOI)，勾画时包括坏死和囊性区域，小心避免正常肌层区域。勾画完成后再由另一名经验更丰富(20年以上工作经验)的副主任医师进行审核。若存在分歧，将由另一名资深主任医师(30年以上经验)进行复核，以确保勾画的准确性。

1.4 影像组学特征提取、筛选及模型建立 以7 : 3比例将患者随机分为训练集和测试集。采用开源软件包Pyradiomics(版本3.0.1)自动提取影像组学特征。包括几何特征、强度特征以及纹理特征。纹理特征包括四类：灰度共生矩阵、灰度游程矩阵、灰度区域大小矩阵以及邻域灰度差异矩阵。采用特征级融合方法将两个序列提取特征进行融合生成新的组合特征集。首先，采用Z-score对特征进行归一化处理，并进行T检验，保留P＜0.05的特征；随后，通过皮尔逊相关系数(Pearson correlation coefficient, PCC)、递归特征消除法(Recursive feature elim-ination, RFE)进行特征选择，使用最小绝对收缩与选择算子(Least absolute shrinkage and selection operator, LASSO)逻辑回归方法，通过10折交叉验证进一步筛选组学特征，获得最优特征集。最后，采用逻辑回归(Logistic regression, LR)、支持向量机(Support vector machine, SVM) 、随机森林(Random forest, RF)、极端随机树(Extremely ran-domized trees, extratrees)以及极端梯度提升(Extreme gradient boosting, XGBoost) 五种机器学习分类器建立预测EC LNM的影像组学模型。

1.5 深度学习特征提取、筛选及模型建立 选择病灶最大层面的ROI作为代表性图像，并提取ROI周围的最小外接长方体以优化分析并减少背景噪声。由于数据来自两种不同的序列，在获取裁剪后的三维ROI后，我们进行了图像融合，将两种序列合并为双通道数据格式。通过Z-score对图像进行归一化处理，归一化后的图像作为DL模型的输入。在训练阶段，采用实时数据增强技术(如随机裁剪和翻转)以提高模型的鲁棒性；对于测试图像，预处理仅进行归一化，以确保评估过程的一致性。本研究中采用深度迁移学习技术，即采用ImageNet数据集上预训练的模型作为基础模型，对模型进行微调以适应本研究需求，采用ResNet50、ShuffleNet和DenseNet121 三种DL网络架构建立模型，以筛选出最符合本研究需求的算法作为最佳DL模型。在训练过程中，每个裁剪后的子区域图像通过最近邻插值法调整为48 × 48 × 48，作为模型的输入。鉴于样本量较小，选择了学习率以增强模型的泛化能力，优化器为随机梯度下降，损失函数为softmax交叉熵，训练周期为30，学习率为0.01。

在模型中，卷积神经网络(Convolutional neural network, CNN)生成的输出概率被定义为DL特征。对于本研究中的最优DL模型，我们利用模型倒数第二层的特征作为DL特征，并将其与提取的影像组学特征融合，建立DL-影像组学(DL-radiomics，DLR)特征。随后，我们采用了与传统影像组学相似的方法进行特征选择和模型构建。

1.6 临床模型和联合模型的建立 对所有临床特征(包括组织学类型、组织学分级和年龄)进行了单因素和多因素分析，以筛选出具有统计学意义的特征并建立临床模型。最后通过联合影像组学、DL和临床特征建立联合模型，并绘制列线图。

1.7 统计方法 统计学分析采用Python(3.7.12)和statsmodels库 (0.13.2)。数值变量行Shapiro-Wilk正态性检验，符合正态分布的数据采用表示，行独立样本t检验；分类变量采用频数表示，并进行卡方检验。采用受试者工作特征(Receiver operating characteristic, ROC)曲线下面积(Area under the curve，AUC)分析模型的诊断效能。各模型AUC值的差异比较采用Delong检验。决策曲线分析(Decision curve analysis, DCA)探讨模型的临床应用价值。校准曲线和Hosmer-Lemeshow拟合优度检验分析模型的校准性能。P＜0.05为差异具有统计学意义。

2 结 果

2.1 临床特征选择和模型建立 本研究共纳入186例患者(平均年龄58.78 ± 8.70岁)，其中20例LNM+，166例LNM-。训练集与测试集患者的年龄、组织学分级及组织学类型之间差异无统计学意义(P>0.05)，确保了数据分组的无偏性。单因素Logistic回归分析显示年龄、组织学分级及组织学类型与LNM显著相关，多因素Logistic回归分析表明组织学分级(OR=2.91;95%置信区间(Confidence interval, CI) =1.64-5.17，P<0.05)和年龄(OR=0.94; 95%CI=0.91-0.97, P<0.05)是EC患者LNM的独立危险因素。基于临床特征建立的模型在训练集和测试集的AUC值分别为0.826(95%CI=0.695-0.957)和0.797(95%CI=0.643-0.950)。

2.2 特征提取和选择 共提取了2394个影像组学特征，T检验后得到418个特征；对于相关性比较高的特征，两者保留其一，得到32个特征，随后经Lasso降维后得到7个系数非零的影像组学特征。共提取1024个DL特征，经过筛选共得到64个最佳DL特征。影像组学和DL特征融合后，经过筛选最终得到9个特征(6个影像组学特征和3个DL特征)用于DLR模型的建立。

2.3 模型建立 基于影像组学、DL及DLR特征建立的模型见表1-3。采用六种分类器建立的影像组学模型中，RF分类器表现出最佳的预测性能，测试集的AUC值为 0.808(95%CI=0.637-0.980)(见表1)，将其作为最佳影像组学模型，见表1。ShuffleNet DL模型为最佳DL模型，测试集的AUC值为0.820(95%CI=0.705-0.935)(见表2)。基于DLR特征建立模型中,同样为RF分类器在测试集的AUC值最高,为0.840(95%CI=0.702-0.978)(见表3)。

表1 影像组学模型在训练集和测试集中的诊断效能

组别	模型	AUC	AUC 95%CI	准确率	敏感度	特异度
训练集	LR	0.888	0.792-0.984	0.862	0.714	0.879
	SVM	0.964	0.931-0.997	0.854	0.929	0.845
	RF	0.910	0.839-0.981	0.769	0.857	0.759
	ExtraTrees	0.867	0.769-0.965	0.877	0.643	0.905
	XGBoost	0.953	0.917-0.989	0.885	0.857	0.888
	LightGBM	0.967	0.931-1.000	0.869	0.857	0.871
测试集	LR	0.727	0.446-1.000	0.768	0.500	0.800
	SVM	0.727	0.572-0.882	0.554	0.833	0.520
	RF	0.808	0.637-0.980	0.589	0.833	0.560
	ExtraTrees	0.723	0.513-0.934	0.804	0.500	0.840
	XGBoost	0.707	0.503-0.910	0.464	0.833	0.420
	LightGBM	0.807	0.629-0.984	0.839	0.500	0.880

表2 深度学习模型在训练集和测试集的诊断效能

组别	模型	AUC	AUC 95%CI	准确率	敏感度	特异度
训练集	ShuffleNet	0.974	0.931-1.000	0.977	0.786	1.000
	Resnet50	0.777	0.679-0.875	0.554	0.929	0.509
	DenseNet121	0.986	0.958-1.000	0.985	0.857	1.000
测试集	ShuffleNet	0.820	0.705-0.935	0.732	0.667	0.740
	Resnet50	0.640	0.429-0.852	0.625	0.500	0.640
	DenseNet121	0.793	0.598-0.989	0.821	0.667	0.840

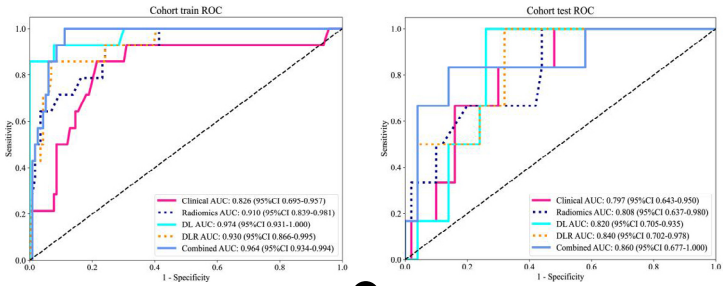
2.4 建立联合模型 测试集中，联合临床特征、影像组学特征和DL特征建立的联合模型AUC达到0.860，如表4和图1所示，其列线图见图2。联合模型和DL模型在训练集中预测LNM的AUC高于临床模型(0.964vs0.826; 0.974vs0.826; P<0.05)，测试集中差异无统计学意义(0.860vs0.797; 0.820vs0.797; P>0.05)。DCA显示，联合模型在测试集中临床效益更好(图3)。校准曲线显示联合模型表现出优异的校准性能，训练集和测试集的HL统计量分别为0.924和0.316(图4)，表明其与观察值高度一致。

表3 深度学习影像组学模型在训练集和测试集的诊断效能

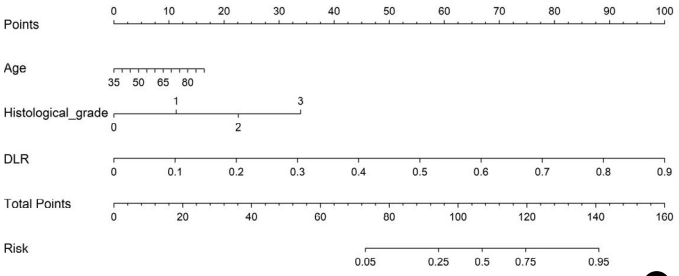
组别	模型	AUC	AUC 95%CI	准确率	敏感度	特异度
训练集	LR	0.908	0.806-1.000	0.877	0.786	0.888
	SVM	0.988	0.963-1.000	0.985	0.857	1.000
	RF	0.930	0.866-0.995	0.915	0.786	0.931
	ExtraTrees	0.841	0.722-0.960	0.869	0.643	0.897
	XGBoost	0.845	0.758-0.932	0.754	0.786	0.750
	LightGBM	0.924	0.863-0.985	0.815	0.857	0.810
测试集	LR	0.677	0.332-1.000	0.839	0.500	0.880
	SVM	0.717	0.557-0.876	0.643	0.833	0.620
	RF	0.840	0.702-0.978	0.696	0.833	0.680
	ExtraTrees	0.807	0.613-1.000	0.679	0.667	0.680
	XGBoost	0.732	0.494-0.970	0.732	0.500	0.760
	LightGBM	0.827	0.634 - 1.000	0.732	0.667	0.740

表4 各最佳模型在训练集和测试集的诊断效能

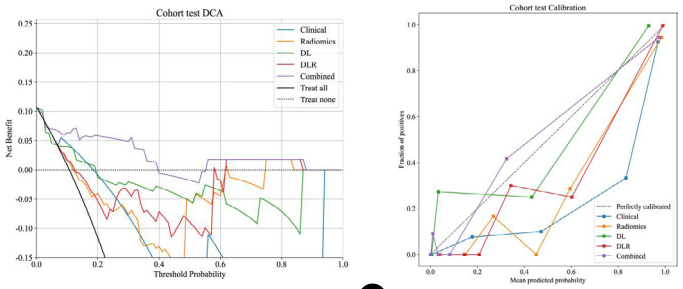
组别	模型	AUC	AUC 95%CI	准确度	敏感度	特异度
训练集	临床模型	0.826	0.695-0.957	0.800	0.714	0.810
	影像组学模型	0.910	0.839-0.981	0.769	0.857	0.759
	DL模型	0.974	0.931-1.000	0.977	0.786	1.000
	DLR模型	0.930	0.866-0.995	0.915	0.786	0.931
	联合模型	0.964	0.934-0.994	0.892	0.929	0.888
测试集	临床模型	0.797	0.643-0.950	0.696	0.667	0.700
	影像组学模型	0.808	0.637-0.980	0.589	0.833	0.560
	DL模型	0.820	0.705-0.935	0.732	0.667	0.740
	DLR模型	0.840	0.702-0.978	0.696	0.833	0.680
	联合模型	0.860	0.677-1.000	0.839	0.667	0.860



1A 1B



2



3 4

图1 各最佳模型的受试者工作特征曲线及曲线下面积(A为训练集；B为测试集)。Clinical：临床；Radiomics：影像组学；DL：深度学习；DLR：深度学习影像组学；Combined：联合模型。

图2 联合模型的列线图。Age：年龄；Histological_grade：组织学分级；DLR：深度学习影像组学。

图3 各最佳模型的决策曲线分析(A为训练集；B为测试集)。Clinical：临床；Radiomics：影像组学；DL：深度学习；DLR：深度学习影像组学；Combined：联合模型。

图4 各最佳模型的校准曲线(A为训练集；B为测试集)。Clinical：临床；Radiomics：影像组学；DL：深度学习；DLR：深度学习影像组学；Combined：联合模型。

3 讨 论

本研究基于MRI提取影像组学特征、DL特征和临床特征并建立联合模型，探讨其在预测EC LNM的潜在价值。结果表明，联合模型在训练集中的 AUC 为0.964(95%CI=0.934-0.994)，在测试集中的 AUC 值为0.860(95%CI=0.677-1.000)，该模型具有较高的诊断效能，为EC淋巴结状态提供额外的潜在价值，有望成为指导EC诊疗决策的生物标志物。

EC淋巴结状态的评估对于最大限度降低治疗不足和过度治疗的风险至关重要。MRI评估EC LNM的准确性有限[7-8]。PET/CT和PET/MRI在检测淋巴结转移方面表现出较高的敏感性(70%~87.5%)[8,12-13]。然而，其在设备购置、检查等方面的成本较高，可能限制了其在某些医疗机构和患者群体中的广泛应用。相比之下，影像组学和DL可从MRI图像中深度挖掘和提取大量高通量定量特征，尤其在EC LNM预测和诊断中展现出广阔的应用前景[14-15]。一项荟萃分析结果表明，采用影像组学方法预测EC LNM测试集中的AUC为0.823[16]，诊断性能中等水平。与影像组学相比，深度学习能够从医学图像中自动提取多层次、高维特征，无需复杂的手工特征提取步骤[17]。CNN提取的DL特征在识别EC肌层浸润深度、风险分层以及淋巴脉管间隙浸润方面表现出较高的准确性[18-20]。Wang等[21]基于MRI图像建立的DL模型在测试集中预测EC LNM的AUC值为0.806。然而，值得注意的是，该研究仅专注于探索DL特征，未结合传统影像组学特征。尽管DL特征通常难以解释，但许多研究正致力于将影像组学特征与DL的优势相结合，旨在通过多维信息融合提升模型的预测准确性和可靠性[22]。这种融合策略不仅有望解决单一特征集的局限性，还为疾病诊断和治疗决策提供了更全面、更精确的参考。

本研究中尽管单独的DL模型已具备较强的诊断能力，但将其与影像组学特征融合后，模型性能进一步提升。再与临床特征联合时，模型性能得到最显著的提升，达到了最高的AUC值，测试集中AUC值为0.860，可为评估EC患者LNM状态增加有用的信息。这种协同效应表明，联合影像特征、DL特征和临床数据的多维度方法能够最大化预测准确性，为临床决策支持提供了强有力的框架。在本研究中，我们整合了两种不同序列(T2WI和CE-T1WI)的图像以提取特征，图像融合能够结合来自不同图像源的信息，从而提供比单一序列图像更丰富、更全面的信息,结果表明联合模型在测试集中AUC值(0.860)高于既往DL模型(AUC为0.806)[21]。本研究中影像组学模型中采用RF分类器建立模型得到的AUC值最高，而张等[23]的研究中SVM分类器的AUC值最高，DL模型中ShuffleNet框架预测性能最好，ShuffleNet可提高计算速度并保持较高的模型性能，而在徐等[24]的研究中基于高斯朴素贝叶斯和XGBoost分类器构建的模型，分别在薄层和厚层CT序列上取得最高AUC。说明我们在面对具体医疗任务时，不应仅凭经验选择某一特定方法。通过初步实验评估多种算法，能够更全面地理解数据的内在特性，从而筛选出最适合当前任务的模型。

本研究存在一定的局限性：首先，本项研究样本量较少且数据集不平衡，增加了选择偏移的风险，未来需要扩大样本量进行多中心研究；其次，勾画ROI时未进行一致性分析，但在勾画完成后进行了严格的复核；最后，未进行外部验证。

综上所述，本研究通过联合影像组学特征、DL特征和临床特征建立联合模型，能够较准确地预测EC LNM，从而帮助临床制定个性化的治疗方案。

(参考文献下转第121页)

制定更加个性化的治疗方案。对于高风险患者，可以采取更加积极的治疗措施，如扩大手术范围、加强放疗或化疗等，以提高治疗效果。预测模型可以帮助医生早期发现淋巴结转移的风险，从而采取更加积极的干预措施，如预防性淋巴结清扫、化疗或放疗等，以降低淋巴结转移的发生率。

综上所述，CDUS、CT及MRI在宫颈癌盆腔淋巴结转移中均具有较高的诊断价值，MRI诊断准确率较高。基于宫颈癌盆腔淋巴结转移的危险因素构建的风险预测模型预测准确性较好。

参考文献

[1]魏佳慧,刘洋,王明,等.CT与MRI在宫颈癌术前评估淋巴结转移中的应用价值[J].中国妇产科临床杂志,2022,23(6):583-586.
[2]张梯勇,陈文,陈晓雷,等.磁共振动态增强与血清肝细胞生长因子受体c-Met和结肠癌转移相关基因1联合检测在宫颈癌盆腔淋巴结转移的价值[J].中国医学装备,2022,19(7):58-62.
[3]葛畅.血清鳞状上皮细胞癌抗原,糖类抗原125水平在宫颈癌盆腔淋巴结转移中的预测价值[J].中国性科学,2023,32(8):87-90.
[4]李亚玲,刘研,李燕,等.基于血清CEA,SCCA联合多模态MRI构建预测宫颈癌术后复发转移的nomograms模型效能分析[J].解放军医药杂志,2022,34(10):31-36.
[5]李杰,孙玮,刘小玲.^(18)F-FDG PET/CT纹理特征联合LMR对ⅠbˉⅡb期宫颈癌盆腔淋巴结转移的预测价值分析[J].实用癌症杂志,2022,37(6):980-983.
[6]刘泉清,宋亭,黄健威.双能CT联合彩色多普勒超声诊断宫颈癌淋巴结转移的临床价值[J].中国计划生育学杂志,2023,31(2):443-447.
[7]巨宇叶,苏芮,王晓慧.盆腔MRI联合SCC-Ag对宫颈癌淋巴结转移的预测价值[J].肿瘤防治研究,2022,49(5):448-452.
[8]李振玉,牛永超,闫少华,等.DCE-MRI,DWI联合血清c-Met,MACC1对宫颈癌盆腔淋巴结转移的诊断价值[J].海南医学,2023,34(23):3446-3450.
[9]钟社兰,赵琳.CT对宫颈癌盆腔淋巴结转移的诊断价值[J].医学临床研究,2022,39(4):532-534,538.
[10]郭曲,许希中,李卫民,等.系统性炎症指标预测早期宫颈癌淋巴结转移的列线图模型构建及评价[J].现代妇产科进展,2022,31(12):890-895.
[11]邢彦粉,姚刚,梁志鹏.多模态MRI在宫颈癌盆腔良恶性淋巴结鉴别诊断的临床应用价值[J].医学影像学杂志,2022,32(8):1356-1360,1364.
[12]陈海棠,何海珍.炎症指标预测宫颈癌淋巴结转移的列线图风险模型建立与验证[J].中国计划生育学杂志,2023,31(9):2224-2228.
[13]周魏薇,宋丽萍.PET/CT双时相显像在预测宫颈癌淋巴结转移中的价值[J].临床肿瘤学杂志,2022,27(3):232-237.
[14]栾一祎,卢佳翔,秦凤英,等.DCE-MRI联合临床及血管病理参数预测早期宫颈癌淋巴结转移的价值[J].放射学实践,,2023,38(9):1145-1150.
[15]陈燕红,谢芳,余惠霞,等.基于宫颈癌病理特征预测淋巴结转移死亡风险及列线图的构建[J].中国妇幼保健,2022,37(10):1763-1767.
[16]常利芳,包圆圆,兰红琳.磁共振盆腔平扫+增强扫描在宫颈癌诊断及术后随访中的应用价值[J].川北医学院学报,2022,37(11):1476-1479.
[17]王庆,高勇,杨明霞.经阴道彩色多普勒超声联合磁共振成像检查在评估宫颈癌术前分期中的应用价值[J].中国医学装备,2023,20(5):104-108.

(收稿日期：2024-06-13)　　(校对：赵望淇　排版：张鸿燊)

（上接第117页）

参考文献

[1]Bray F,Laversanne M,Sung H,et al.Global cancer statistics 2022:GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J].CA Cancer J Clin,2024,74(3):229-263.
[2]Koskas M,Amant F,Mirza M R,et al.Cancer of the corpus uteri:2021 update[J].Int J Gynecol Obstet,2021,155(S1):45-60.
[3]曾莉,江立千,包杰.子宫内膜癌血清CA125水平与CA19-9检测在临床病理分期中的价值研究[J].罕少疾病杂志,2024,31(8):88-89.
[4]Miller K D,Nogueira L,Devasia T,et al.Cancer treatment and survivorship statistics,2022[J].CA Cancer J Clin,2022,72(5):409-436.
[5]Gumtorntip P,Poomtavorn Y,Tanprasertkul C.Predicting Factors for Pelvic Lymph Node Metastasis in Patients with Apparently Early-Stage Endometrial Cancer[J].Asian Pac J Cancer Prev,2022,23(2):617-622.
[6]Karalok A,Turan T,Basaran D,et al.Lymph Node Metastasis in Patients With Endometrioid Endometrial Cancer:Overtreatment Is the Main Issue[J].Int J Gynecol Cancer,2017,27(4):748-753.
[7]Bús D,Nagy G,Póka R,et al.Clinical Impact of Preoperative Magnetic Resonance Imaging in the Evaluation of Myometrial Infiltration and Lymph-Node Metastases in Stage I Endometrial Cancer[J].Pathol Oncol Res,2021,27:611088.
[8]Kim H J,Cho A,Yun M,et al.Comparison of FDG PET/CT and MRI in lymph node staging of endometrial cancer[J].Ann Nucl Med,2016,30(2):104-113.
[9]Berek J S,Matias X,Creutzberg C,et al.FIGO staging of endometrial cancer:2023[J].Int J Gynecol Obstet,162(2):383-394.
[10]Holloway R W,Abu-Rustum N R,Backes F J,et al.Sentinel lymph node mapping and staging in endometrial cancer:A Society of Gynecologic Oncology literature review with consensus recommendations[J].Gynecol Oncol,2017,146(2):405-415.
[11]Sun R,Zhang M,Yang L,et al.Preoperative CT-based deep learning radiomics model to predict lymph node metastasis and patient prognosis in bladder cancer:a two-center study[J].Insights Imaging,2024,15(1).
[12]Ironi G,Mapelli P,Bergamini A,et al.Hybrid PET/MRI in Staging Endometrial Cancer[J].Clin Nucl Med,2022,47(3):e221-e229.
[13]Yu Y,Zhang L,Sultana B,et al.Diagnostic value of integrated 18F-FDG PET/MRI for staging of endometrial carcinoma:comparison with PET/CT[J].BMC Cancer,2022,22(1):947.
[14]Dong D,Tian J,Zhao X.Multiplanar MRI-Based Predictive Model for Preoperative Assessment of Lymph Node Metastasis in Endometrial Cancer[J].Front Oncol,2019,9:1007
[15]Yan B C,Li Y,Ma F H,et al.Radiologists with MRI-based radiomics aids to predict the pelvic lymph node metastasis in endometrial cancer:a multicenter study[J].Eur Radio,2021,31(1):411-422.
[16]Ren Z,Chen B,Hong C,et al.The value of machine learning in preoperative identification of lymph node metastasis status in endometrial cancer:a systematic review and meta-analysis[J].Front Oncol,2023,13:1289050.
[17]彭琳,王冬青,庄子健,等.MRI影像组学及深度学习在直肠癌中的研究进展[J].中国CT和MRI杂志,2024,22(5):177-180.
[18]Yang J,Cao Y,Zhou F,et al.Combined deep-learning MRI-based radiomic models for preoperative risk classification of endometrial endometrioid adenocarcinoma[J].Front Oncol,2023,13:1231497.
[19]Chen X,Wang Y,Shen M,et al.Deep learning for the determination of myometrial invasion depth and automatic lesion identification in endometrial cancer MR imaging:a preliminary study in a single institution[J].Eur Radiol,2020,30(9):4985-4994.
[20]Dong H-C,Dong H-K,Yu M-H,et al.Using Deep Learning with Convolutional Neural Network Approach to Identify the Invasion Depth of Endometrial Cancer in Myometrium Using MR Images:A Pilot Study[J].Int J Environ Res Public Health,2020,17(16):5993.
[21]Wang Y,Liu W,Lu Y,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.
[22]Wei M,Feng G,Wang X,et al.Deep Learning Radiomics Nomogram Based on Magnetic Resonance Imaging for Differentiating Type I/II Epithelial Ovarian Cancer[J].Acad Radiol,2024,31(6):2391-2401.
[23]张舒妮,赵楠楠,李阳,等.多模态影像组学列线图术前预测乳腺浸润性导管癌腋窝淋巴结转移的价值[J].磁共振成像,2024,15(4):78-87.
[24]徐翠莲,印宏坤,伋立荣,等.深度学习结合影像组学的胸部CT新冠肺炎智能诊断模型研究[J].罕少疾病杂志,2021,28(5):16-20.

(收稿日期：2025-03-03)
(校对：赵望淇　排版：张鸿燊)