

MRI深度学习量化预测进展期胃癌隐匿性腹膜转移

姚纯,熊波,杨桂汉,梁月梅,黎健辉,杨志企
梅州市人民医院医学影像中心,广东 梅州 514031

【摘要】目的:探讨基于MRI的多种深度学习(DL)模型预测进展期胃癌隐匿性腹膜转移(OPM)的可行性及价值。**方法:**回顾性纳入476例术前MRI诊断为腹膜转移阴性、经手术病理确诊的进展期胃癌患者,按7:3随机分为训练集(334例)和测试集(142例)。在T₂WI-FS序列上手动勾画肿瘤三维感兴趣区,训练ResNet50、Med-ViT和TP-Mamba 3种DL模型,采用受试者工作特征曲线下面积(AUC)、敏感度、特异度、DeLong检验、综合判别改进指数(IDI)及临床决策曲线(DCA)评估效能。**结果:**Med-ViT模型(训练集AUC=0.860;测试集AUC=0.763)预测OPM的效能均优于TP-Mamba(训练集AUC=0.767;测试集AUC=0.652)及ResNet50模型(训练集AUC=0.528;测试集AUC=0.570)。在训练集及测试集中,DeLong检验显示Med-ViT的AUC值均显著高于其余模型($P<0.05$),IDI分析显示Med-ViT模型综合判别改善能力最优,DCA表明其净获益最高。**结论:**基于自注意力机制的Med-ViT深度学习模型可准确预测进展期胃癌OPM风险,效能显著优于ResNet50与TP-Mamba,有望成为术前无创筛查OPM高危患者的辅助工具。

【关键词】胃癌;隐匿性腹膜转移;磁共振成像;深度学习

【中图分类号】R318;R735.2

【文献标志码】A

【文章编号】1005-202X(2026)07-0980-07

MRI-based deep learning models for quantitative prediction of occult peritoneal metastasis in advanced gastric cancer

YAO Chun, XIONG Bo, YANG Guihan, LIANG Yuemei, LI Jianhui, YANG Zhiqi
Medical Imaging Center, Meizhou People's Hospital, Meizhou 514031, China

Abstract: Objective To explore the feasibility and value of multiple deep learning models based on magnetic resonance imaging (MRI) for the prediction of occult peritoneal metastasis (OPM) in advanced gastric cancer. **Methods** A retrospective analysis was conducted on 476 patients with pathologically confirmed advanced gastric cancer and negative preoperative MRI findings for peritoneal metastasis. All patients were randomly divided into a training set ($n=334$) and a test set ($n=142$) at a ratio of 7:3. Three-dimensional tumor regions of interest were manually delineated on T₂WI-FS sequences. Three deep learning models, including ResNet50, Med-ViT, and TP-Mamba, were trained, and their performance was evaluated using the area under the receiver operating characteristic curve (AUC), sensitivity, specificity, the DeLong test, integrated discrimination improvement, and decision curve analysis. **Results** Med-ViT model (training set AUC=0.860; test set AUC=0.763) exhibited superior performance in predicting OPM compared with TP-Mamba model (training set AUC=0.767; test set AUC=0.652) and ResNet50 model (training set AUC=0.528; test set AUC=0.570). In both the training and test sets, the DeLong test showed that Med-ViT had significantly higher AUC values than the other two models ($P<0.05$). Integrated discrimination improvement analysis demonstrated that Med-ViT model achieved the optimal comprehensive discrimination improvement ability, and decision curve analysis reflected its greatest net benefit. **Conclusion** The self-attention mechanism-based Med-ViT deep learning model can accurately predict the risk of OPM in advanced gastric cancer and outperforms ResNet50 and TP-Mamba. Therefore, it is expected to serve as a reliable auxiliary tool for non-invasive preoperative screening of patients at high risk of OPM.

Keywords: gastric cancer; occult peritoneal metastasis; magnetic resonance imaging; deep learning

【收稿日期】2025-12-03

【基金项目】广东省医学科研基金(B2023445);梅州市社会发展科技计划项目(2023B19)

【作者简介】姚纯,副主任医师,研究方向:消化系统影像诊断,E-mail: 164225090@qq.com

【通信作者】杨志企,硕士,主任医师,研究方向:消化系统影像诊断,E-mail: y13643090854@163.com

前言

胃癌(Gastric Cancer, GC)是全球第5大常见癌症,也是癌症相关死亡的第3大原因^[1-6]。腹膜转移(Peritoneal Metastasis, PM)是其最常见远处扩散方式,发生于20%~50%的局部晚期肿瘤患者中^[7-12];PM一旦发生,患者多失去手术机会,预后极差,中位生存期仅6~11个月^[6,9-10,13]。PM的早期检测及准确诊断可指导临床治疗决策。目前临床主要依赖CT/MRI等影像学技术检测PM,然而高达30%术前影像诊断为PM阴性的患者,其术后病理结果却为阳性,此情况即为隐匿性腹膜转移(Occult Peritoneal Metastasis, OPM)^[10,13-15]。腹腔镜因可直接观察并取活检成为诊断金标准^[14],但因其侵入性、成本高及操作局限,临床应用受限。因此,寻求一种无创量化的方法准确诊断OPM具有重要临床意义。

影像组学通过挖掘蕴含于肿瘤影像中的深层特征,用于临床分析,成为研究热点。基于CT的影像组学已广泛应用于胃癌相关研究中^[16-20]。国内外研究团队采用影像组学方法,研究证实基于原发肿瘤的CT影像组学特征与OPM高度相关,联合临床因素构建的影像组学模型对胃癌OPM风险评估具有潜在应用价值^[18-19,21-22]。但传统影像组学方法依赖人工勾画,泛化力不足,临床落地困难。近年来,图像分析方法逐渐从传统的手工特征计算向端到端智能学习转变,深度学习(Deep Learning, DL)作为一种先进的人工智能方法,在特征提取及模型构建中展现独特优势^[21,23-24]。目前,DL用于胃癌腹膜转移预测的研究鲜见有报道。本研究探讨多种基于MRI的DL模型在胃癌OPM预测中的可行性及价值,旨在为OPM术前评估提供精准、智能的辅助工具。

1 资料与方法

1.1 一般资料

回顾性纳入2016年6月~2024年6月在梅州市人民医院经手术病理确诊为进展期胃癌且术前MRI诊断为PM阴性并行手术治疗患者476例,其中男333例,女143例,平均年龄(67.19±10.51)岁。纳入标准:(1)初治手术病理证实的进展期胃癌;(2)术前2周内腹部MRI检查,术前MRI影像诊断PM阴性,术后病理确定PM真实状态;(3)无其他部位的远处转移。排除标准:(1)MR图像伪影;(2)其他恶性肿瘤病史或腹部手术史;(3)术前接受过辅助治疗。476例患者按7:3比例分为训练集334例和测试集142例。收集患者基线特征,包括年龄、性别、CEA、CA125、CA199、位置、分期、Borrmann分型、分化程度等。本研究已获得梅州市人民医院伦理委员会批准(梅市伦审2024-C-26)。

1.2 设备与方法

所有患者均采用西门子Skyra 3.0T磁共振扫描仪进行腹部MR图像采集,扫描序列和参数:(1)T₁WI横断位:TR 4.0 ms,TE 1.3 ms,层厚5 mm,层间距1 mm;(2)T₂WI横断位:TR 1 400 ms,TE 99 ms,层厚5 mm,层间距1 mm;(3)T₂WI脂肪抑制:TR 3 000 ms,TE 88 ms,层厚5 mm,层间距1 mm,FOV 384 mm×384 mm,矩阵384×384;(4)DWI:TR 4 500 ms,TE 62 ms,层厚5 mm,层间距1 mm,b值取50、800和1 000 s/mm²,矩阵192×192。扫描完成后经重建获得ADC图像。(5)DCE-MRI:使用自动双筒高压注射器经肘前静脉注射钆喷酸葡胺注射液(Gd-DTPA,马根维显,拜耳医药,德国),以1~2 mL/s速率团注后,续以等速20 mL生理盐水。图像采集时序为:于注射后18~19 s(动脉期)及40~50 s(门静脉期)行动态屏气CDT-VIBE序列扫描;于注射后90 s(平衡期)及180~300 s(延迟期)行屏气VIBE序列扫描。

1.3 图像处理与病灶勾画

由两名具备10年诊断经验的影像科医生,在不知晓患者临床及病理结果的前提下,手动勾画所有感兴趣区域(Region of Interest, ROI)。具体操作步骤如下:(1)图像导出:从PACS工作站将轴位T₂-FS序列MR图像以dicom.格式导出;(2)ROI勾画:使用ITK-SNAP软件,在T₂-FS序列图像上沿病灶边缘逐层勾画肿瘤,避开坏死、囊变;(3)若两名医生在勾画过程中出现争议,通过共同协商达成一致,最后将勾画的3D ROI以“.nii”格式保存。

1.4 DL与OPM预测模型建立

如图1所示,包括数据收集、模型部署及性能分析3个主要步骤。所有实验步骤在配备4块NVIDIA A100 GPU的高性能云平台上完成,其平台运行环境包括Python 3.10.16、PyTorch 2.4.1及MONAI 1.3.2,支持CUDA 12.4。基于该平台,完成DL模型建立和OPM预测任务。

1.4.1 图像预处理 基于MySQL框架构建云端影像数据库,并对MR数据进行系统预处理,以提升DL模型训练的数据质量。具体而言,利用MONAI 1.3.2框架提供的预处理工具,将数据按照正负样本比例1:1进行划分。模型训练过程中,每次从数据库中提取的图像批量大小设定为每张GPU输入2个样本;同时,每一轮训练均通过随机裁剪方式生成尺寸为128×128×64的三维图像块,并按轴向随机翻转(概率50%)和图像强度缩放/偏移扰动(概率20%)推动数据增强。所有三维MR图像按照70%训练集、30%测试集的比例划分,用于模型训练、内部验证及最终评估。




图1 MR深度学习量化预测进展期胃癌隐匿性腹膜转移流程图

Figure 1 Flowchart for quantitative prediction of occult peritoneal metastasis in advanced gastric cancer using MRI-based deep learning models

1.4.2 模型部署 通过预实验对比6种典型神经网络,最终筛选出表现较优的3种:ResNet50、Med-ViT和TP-Mamba。原理及适用性分析:(1)ResNet50:经典卷积神经网络,通过残差连接缓解深层网络退化问题,适用于通用图像分类。但其局部感受野限制了全局上下文建模,对医学影像中分散的病变特征提取能力有限。(2)Med-ViT:基于Vision Transformer架构,专为医学影像设计。其自注意力机制能捕获图像任意区域间的长程依赖,适合胃癌原发灶与腹膜转移之间微妙的影像学关联建模;且针对小样本、高噪声临床数据进行了优化,在保持高敏感度的同时提升特异度。(3)TP-Mamba:基于状态空间模型的新型架构,理论上线性复杂度,但小样本条件下难以建立稳定特征表征,预测性能受限。

模型训练:随机初始化,采用交叉熵+Focal Loss复合损失函数,AdamW优化器。初始学习率0.001,结合线性预热与余弦退火策略,训练300轮,权重衰减0.4。
推理服务:在训练集和测试集上计算受试者操作特征(ROC)曲线、AUC值、综合判别改进指数(IDI)及临床决策曲线(DCA)。

1.5 统计学分析

使用SPSS 25.0进行统计学分析。计量资料符合

正态分布者,以均数±标准差表示并采用独立样本 t 检验进行组间对比;分类变量以例数(%)表示,采用 χ^2 检验进行组间比较。模型的预测效能通过ROC曲线评估,具体指标包括AUC、敏感度与特异度;其一,采用DeLong检验比较不同模型的AUC差异;其二,通过DCA分析模型的实用价值。 $P<0.05$ 为差异有统计学意义。

2 结果

2.1 一般资料结果

476例患者中,分成训练集334例(PM^+ :93例, PM^- :241例)与测试集142例(PM^+ :49例, PM^- :93例)。除CA125及N分期差异存在统计学差异($P<0.05$)外,两组在年龄、性别、CEA、CA199、肿瘤位置、T分期、Borrmann分型及分化程度等基线资料上均无统计学意义($P>0.05$)。两组基线指标比较详见表1。

2.2 DL模型预测OPM效能

如表2所示,在训练集与测试集中,Med-ViT的AUC均最高,TP-Mamba次之,ResNet50最低。训练集中,Med-ViT的敏感度最高;ResNet50的特异度最低。测试集中,Med-ViT与TP-Mamba的敏感度并列最高,但特异度低于ResNet50。

表 1 进展期胃癌患者临床特征比较[例(%)]

Table 1 Comparison of clinical characteristics of patients with advanced gastric cancer [cases (%)]

特征名称	总计(<i>n</i> =476)	测试集(<i>n</i> =142)	训练集(<i>n</i> =334)	检验值	<i>P</i> 值
性别				$\chi^2=0.26$	0.609
男	333(69.96)	97(68.31)	236(70.66)		
女	143(30.04)	45(31.69)	98(29.34)		
年龄				$\chi^2=3.09$	0.079
<60 岁	97(20.38)	36(25.35)	61(18.26)		
≥60 岁	379(79.62)	106(74.65)	273(81.74)		
CEA				$\chi^2=0.01$	0.913
≤5 ng/mL	310(65.13)	93(65.49)	217(64.97)		
>5 ng/mL	166(34.87)	49(34.51)	117(35.03)		
CA125				$\chi^2=6.07$	0.014
≤35 U/mL	339(71.22)	90(63.38)	249(74.55)		
>35 U/mL	137(28.78)	52(36.62)	85(25.45)		
CA19-9				$\chi^2=0.06$	0.804
≤37 U/mL	329(69.12)	97(68.31)	232(69.46)		
>37 U/mL	147(30.88)	45(31.69)	102(30.54)		
肿瘤部位				$\chi^2=0.66$	0.882
贲门胃底区	140(29.41)	44(30.99)	96(28.74)		
胃体区	75(15.76)	24(16.90)	51(15.27)		
幽门胃窦区	117(24.58)	34(23.94)	83(24.85)		
弥漫型	144(30.25)	40(28.17)	104(31.14)		
T 分期				$\chi^2=1.40$	0.236
T ₂	231(48.53)	63(44.37)	168(50.30)		
T ₃₋₄	245(51.47)	79(55.63)	166(49.70)		
N 分期				$\chi^2=5.46$	0.019
N ₀₋₁	102(21.43)	40(28.17)	62(18.56)		
N ₂₋₃	374(78.57)	102(71.83)	272(81.44)		
Borrmann 分型				$\chi^2=0.11$	0.743
I~III 型	393(82.56)	116(81.69)	277(82.93)		
IV 型	83(17.44)	26(18.31)	57(17.07)		
分化程度				$\chi^2=2.84$	0.092
中高分化	210(44.12)	71(50.00)	139(41.62)		
低分化	266(55.88)	71(50.00)	195(58.38)		

CEA:癌胚抗原,CA125:糖类抗原 125,CA19-9:糖类抗原 19-9

表 2 3 种模型在训练集和测试集中的性能比较

Table 2 Performance comparison of 3 models in the training and testing sets

模型	训练集			测试集		
	特异度/%	敏感度/%	AUC(95% CI)	特异度/%	敏感度/%	AUC(95% CI)
ResNet50	40.25	69.89	0.528(0.459~0.597)	84.95	32.65	0.570(0.471~0.670)
TP-Mamba	68.46	78.49	0.767(0.714~0.820)	26.88	97.96	0.652(0.562~0.743)
Med-ViT	73.03	93.55	0.860(0.821~0.899)	45.16	97.96	0.763(0.686~0.841)

2.3 不同DL模型预测OPM的效能比较

如图 2a 和 2b 所示, Med-ViT 模型(训练集 AUC=0.860;测试集 AUC=0.763)预测 OPM 的效能均优于 TP-Mamba(训练集 AUC=0.767;测试集 AUC=0.652)及 ResNet50 模型(训练集 AUC=0.528;测试集 AUC=0.570)。如图 2c 和 2d 所示,在训练集及测试集中,DeLong 检验显示 Med-ViT 模型预测 OPM 的 AUC

值均显著高于 TP-Mamba 模型和 ResNet50 模型 ($P<0.05$)。在训练集(图 2e)和测试集(图 2f)中,Med-ViT 模型综合判别改善能力均显著优于 TP-Mamba 和 ResNet50 模型,TP-Mamba 模型也优于 ResNet50 模型 (IDI 值均 >0)。如图 3a 和 3b 所示,Med-ViT 模型在训练集和测试集的 DCA 中净获益表现均优于 TP-Mamba 和 ResNet50 模型。




图 2 3 种模型诊断性能对比

Figure 2 Comparison of diagnostic performance among 3 models

3 讨论

GC 是来源于胃黏膜上皮的恶性肿瘤,具有高度异质性,晚期常伴有腹膜种植转移,严重影响治疗效果和生存预后^[8-9]。OPM 在术前影像学中难以识别,

漏诊率较高,目前临床仍依赖侵入性腹腔镜检查作为诊断金标准^[10, 13-14]。因此,开发一种无创、准确的 OPM 术前评估方法,对指导 GC 患者的个体化治疗具有重要意义。




图3 3种模型在训练集(a)与测试集(b)的决策曲线分析

Figure 3 Decision curve analysis of 3 models in the training set (a) and the test set (b)

影像组学通过挖掘图像深层次特征用于表征肿瘤异质性,在GC诊断、疗效评估及预后等方面具有较广阔的应用前景。在OPM预测方面,多项研究表明原发肿瘤的CT影像组学特征与GC OPM高度相关,联合临床病理因素^[17,24]构建的影像组学模型可准确预测OPM发生风险,AUC值介于0.92~0.95。Li等^[25]通过手工提取结直肠癌原发灶及最大外周淋巴结的CT增强影像组学特征,构建了融合影像组学标签与关键临床特征的预测模型,该模型在训练集中对PM的预测准确度高达AUC=0.855。Wang等^[26]通过提取瘤内与瘤周的T₂WI MRI影像组学特征,并结合临床预测因子构建了一种多模态模型,该模型在内部与外部测试集中均表现出优异的预测效能(AUC>0.83),能有效术前预测上皮性卵巢癌的盆腔外PM。这些研究提示通过深度分析原发肿瘤的影像组学特征所建立的模型可为OPM的准确评估提供无创方法。然而,传统CT影像组学方法仍存在一定局限:首先,特征提取依赖于人工勾画ROI,流程复杂且存在主观性,影响模型的稳定性和可重复性;其次,影像组学模型的泛化能力不足,在跨中心、多设备及不同扫描参数的应用中表现不佳。

近年图像特征提取方法逐渐从传统的手工特征计算向端到端智能学习转变,DL作为一种先进的人工智能方法,在特征提取中展现独特优势。以卷积神经网络为代表的DL模型在PM预测领域取得初步成效。Jiang等^[15]开发了一种基于术前CT影像的DL模型(PMetNet),该模型在外部验证中表现出色(AUC高达0.92~0.95),其预测能力显著优于传统的临床病理因素。Wang等^[17]通过提取瘤内与瘤周的MRI影像组学特征,并结合临床预测因子构建了一种多模态模型,该模型在内部与外部测试集中均表现出优异的预测效能(AUC>0.83),能术前有效预测

上皮性卵巢癌的盆腔外PM。

本研究首次构建并比较3种不同算法的MR DL模型(Med-ViT、TP-Mamba与ResNet50)在胃癌OPM预测中的可行性及效能差异。结果表明:Med-ViT在训练集和测试集中均表现最优,其训练集AUC为0.860,测试集AUC为0.763,显著高于TP-Mamba和ResNet50。3种算法均具备胃癌OPM预测效能,但效能存在明显差异,其中Med-ViT模型的预测表现显著优于TP-Mamba与ResNet50模型,这一现象可归因于Vision Transformer架构在处理全局信息方面的优势,它能高效建模MRI影像中广泛区域的特征依赖关系。反之,传统卷积神经网络(如ResNet50)受其局部感受野的制约,在整合远距离上下文信息时面临固有瓶颈。其次,Med-ViT针对医学影像任务进行了结构优化,更适配于小样本规模与高噪声干扰的临床数据环境,从而在保持较高敏感度的同时显著提升了特异度。相比之下,TP-Mamba等基于状态空间建模的计算方法尚难以在小样本条件下建立完善而稳定的特征表征体系,因而在预测性能上不及Med-ViT。因此,Med-ViT在本研究任务中展现出更强的泛化能力与临床适用价值。

本研究为单中心回顾性设计,样本均来自同一地区,可能引入选择性偏倚和地域性设备、扫描参数差异,影响模型泛化能力。此外,OPM阳性率为29.8%(142/476),虽按近1:1划分正负样本用于训练,但真实临床分布中阳性比例更低,模型训练中采用平衡采样策略可能高估敏感度,而实际临床应用中假阳性风险增加。类别不平衡还会导致模型对少数类(PM⁺)过拟合,而对多数类(PM⁻)判别能力下降。本研究中测试集Med-ViT特异度仅45.16%,即存在较多假阳性,可能与不平衡及单中心偏倚有关。未来需开展多中心、大样本前瞻性研究,纳入不同地

区、不同设备的数据,验证模型的泛化性。同时,可采用重采样(如SMOTE)、加权损失函数或集成学习等方法缓解类别不平衡问题;亦可探索半监督或自监督学习,充分利用未标注数据提升模型稳健性。此外,结合临床、病理及分子标志物的多模态模型有望进一步提高预测准确度。

综上所述,基于自注意力机制的Med-ViT模型可准确预测胃癌OPM风险,有望成为一种无创、可靠辅助工具用于术前筛查OPM高风险患者,指导临床治疗决策。

【参考文献】

- [1] Chen WQ, Zheng RS, Baade PD, et al. Cancer statistics in China, 2015 [J]. CA Cancer J Clin, 2016, 66(2): 115-132.
- [2] Sung H, Ferlay J, Siegel RL, et al. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA Cancer J Clin, 2021, 71(3): 209-249.
- [3] Siegel RL, Giaquinto AN, Jemal A. Cancer statistics, 2024[J]. CA Cancer J Clin, 2024, 74(1): 12-49.
- [4] Wang YA, Yan QJ, Fan CM, et al. Overview and countermeasures of cancer burden in China[J]. Sci China Life Sci, 2023, 66(11): 2515-2526.
- [5] Cheng XD, Dai EY, Wu JB, et al. Atlas of metastatic gastric cancer links ferroptosis to disease progression and immunotherapy response [J]. Gastroenterology, 2024, 167(7): 1345-1357.
- [6] Paul N, Surendran S, Yacob M, et al. Occult omental metastasis in gastric adenocarcinoma: an analysis of incidence, predictors, and outcomes[J]. South Asian J Cancer, 2022, 11(4): 299-308.
- [7] Thomassen I, van Gestel YR, van Ramshorst B, et al. Peritoneal carcinomatosis of gastric origin: a population-based study on incidence, survival and risk factors[J]. Int J Cancer, 2014, 134(3): 622-628.
- [8] Fujitani K, Yang HK, Mizusawa J, et al. Gastrectomy plus chemotherapy *versus* chemotherapy alone for advanced gastric cancer with a single non-curable factor (REGATTA): a phase 3, randomised controlled trial[J]. Lancet Oncol, 2016, 17(3): 309-318.
- [9] Salati M, Valeri N, Spallanzani A, et al. Oligometastatic gastric cancer: an emerging clinical entity with distinct therapeutic implications[J]. Eur J Surg Oncol, 2019, 45(8): 1479-1482.
- [10] Kim SJ, Kim HH, Kim YH, et al. Peritoneal metastasis: detection with 16- or 64-detector row CT in patients undergoing surgery for gastric cancer[J]. Radiology, 2009, 253(2): 407-415.
- [11] Ng D, Cyr D, Khan S, et al. Molecular mechanisms of metastatic peritoneal dissemination in gastric adenocarcinoma [J]. Cancer Metastasis Rev, 2025, 44(2): 50.
- [12] Lin L, Zhang P, Wang YY, et al. Early vs conventional initiation of adjuvant chemotherapy in advanced gastric cancer: a propensity-matched outcomes study[J]. World J Gastroenterol, 2025, 31(42): 110069.
- [13] Burbidge S, Mahady K, Naik K. The role of CT and staging laparoscopy in the staging of gastric cancer[J]. Clin Radiol, 2013, 68(3): 251-255.
- [14] Buia A, Stockhausen F, Hanisch E. Laparoscopic surgery: a qualified systematic review[J]. World J Methodol, 2015, 5(4): 238-254.
- [15] Hu QC, Zhang SY, Yang K, et al. 68Ga-FAPI-04 PET for detecting occult peritoneal metastasis in locally advanced gastric cancer: diagnostic performance and cost analyses in a single-center, prospective cohort study[J]. J Nucl Med, 2026, 67(1): 53-59.
- [16] Mao Q, Zhou MT, Zhao ZP, et al. Role of radiomics in the diagnosis and treatment of gastrointestinal cancer[J]. World J Gastroenterol, 2022, 28(42): 6002-6016.
- [17] Dong D, Tang L, Li ZY, et al. Development and validation of an individualized nomogram to identify occult peritoneal metastasis in patients with advanced gastric cancer[J]. Ann Oncol, 2019, 30(3): 431-438.
- [18] Huang J, Chen YD, Zhang YY, et al. Comparison of clinical-computed tomography model with 2D and 3D radiomics models to predict occult peritoneal metastases in advanced gastric cancer[J]. Abdom Radiol (NY), 2022, 47(1): 66-75.
- [19] Li QW, Jiang ZJ, Zhu Y, et al. CT-based scores for extramural vascular invasion and occult peritoneal metastasis correlate with gastric cancer survival[J]. Eur Radiol, 2025, 35(9): 5733-5747.
- [20] Wang LL, Lü P, Xue Z, et al. Novel CT based clinical nomogram comparable to radiomics model for identification of occult peritoneal metastasis in advanced gastric cancer[J]. Eur J Surg Oncol, 2022, 48(10): 2166-2173.
- [21] Park CM, Lee JH. Deep learning for lung cancer nodal staging and real-world clinical practice[J]. Radiology, 2022, 302(1): 212-213.
- [22] Zhu ZN, Feng QX, Li Q, et al. Machine learning-based CT radiomics approach for predicting occult peritoneal metastasis in advanced gastric cancer preoperatively[J]. Clin Radiol, 2025, 80: 106727.
- [23] Zhou SK, Greenspan H, Davatzikos C, et al. A review of deep learning in medical imaging: imaging traits, technology trends, case studies with progress highlights, and future promises[J]. Proc IEEE, 2021, 109(5): 820-838.
- [24] Jiang YM, Liang XK, Wang W, et al. Noninvasive prediction of occult peritoneal metastasis in gastric cancer using deep learning[J]. JAMA Netw Open, 2021, 4(1): e2032269.
- [25] Li ML, Sun K, Dai WX, et al. Preoperative prediction of peritoneal metastasis in colorectal cancer using a clinical-radiomics model[J]. Eur J Radiol, 2020, 132: 109326.
- [26] Wang XY, Wei MX, Chen Y, et al. Intratumoral and peritumoral MRI-based radiomics for predicting extrapelvic peritoneal metastasis in epithelial ovarian cancer[J]. Insights Imaging, 2024, 15(1): 281.

(编辑:黄开颜)