

基于超声影像组学和深度学习特征的机器学习模型 诊断囊性交界性卵巢肿瘤的临床价值

陈丽妃^{1,2}, 杨柳², 陈西燕³, 魏达友², 王杰鑫¹, 吴泽虹¹, 徐晓红¹

摘要 **目的** 基于超声影像组学和深度学习特征构建机器学习模型, 探讨其诊断囊性交界性卵巢肿瘤(BOTs)的临床价值。**方法** 收集 118 例囊性(包括以囊性为主)黏液性或浆液性卵巢占位性病变患者, 采用简单随机分配方法以 7:3 的比例分为训练集(82 例)和验证集(36 例)。基于训练集的二维超声图像提取超声影像组学和深度学习特征, 采用组内相关系数、单因素分析、皮尔逊相关系数、递归特征消除方法的多重特征选择策略, 通过 Auto Encoder 算法分别构建诊断囊性 BOTs 的机器学习模型, 包括影像组学模型、深度学习模型及联合模型。绘制受试者工作特征(ROC)曲线评估各模型诊断囊性 BOTs 的效能; Hosmer-Lemeshow 拟合优度检验评估模型诊断结果与病理结果的一致性; 临床决策曲线评估模型的临床收益。检索 PubMed 数据库中 BOTs 影像相关人工智能的文献进行荟萃分析。**结果** 经过多重特征选择策略, 共筛选出 28 个超声影像组学特征和 29 个深度学习特征分别构建影像组学模型和深度学习模型, 以及 8 个超声影像组学特征和 34 个深度学习特征构建联合模型。ROC 曲线分析显示, 影像组学模型在训练集和验证集的曲线下面积(AUC)、灵敏度、特异度分别为 0.73、74%、64% 和 0.83、67%、75%; 深度学习模型在训练集和验证集的 AUC、灵敏度、特异度分别为 0.78、74%、69% 和 0.81、67%、79%; 联合模型在训练集和验证集的 AUC、灵敏度、特异度分别为 0.84、93%、65% 和 0.87、83%、88%, 其中联合模型的 AUC 高于影像组学模型和深度学习模型。Hosmer-Lemeshow 拟合优度检验显示, 联合模型在训练集和验证集的诊断结果与病理结果的一致性均良好($P=0.58, 0.46$)。临床决策曲线分析显示, 联合模型较影像组学模型和深度学习模型更具临床转化价值。共纳入 9 篇 BOTs 影像相关人工智能文献, 综合 ROC 曲线分析显示, 人工智能诊断 BOTs 的综合 AUC 为 0.88, 综合灵敏度为 78%, 综合特异度为 85%。**结论** 基于超声影像组学和深度学习特征构建的机器学习模型在诊断囊性 BOTs 中均有一定的临床价值, 二者联合的诊断效能更佳。

关键词 超声检查; 交界性卵巢肿瘤; 影像组学; 深度学习; 机器学习

[中图法分类号] R445.1; R737.31

[文献标识码] A

Clinical value of machine learning models based on ultrasound radiomics and deep learning features in the diagnosis of cystic borderline ovarian tumors

CHEN Lifei^{1,2}, YANG Liu², CHEN Xiyan³, WEI Dayou², WANG Jiexin¹, WU Zehong¹, XU Xiaohong¹

1.Department of Ultrasound Medicine, Affiliated Hospital of Guangdong Medical University, Zhanjiang 524000, China. 2.Department of Ultrasound Medicine, 3.Scientific Research Center, Maoming People's Hospital, Maoming 525000, China

ABSTRACT Objective To construct machine learning models based on ultrasound radiomics and deep learning features, and to explore the clinical value in the preoperative diagnosis of cystic borderline ovarian tumors (BOTs). **Methods** A total of 118 patients with cystic or predominantly cystic mucinous or serous ovarian space-occupying lesions were retrospectively collected. They were randomly divided into a training set ($n=82$) and a validation set ($n=36$) at a 7:3 ratio. Radiomics and deep learning features were extracted from two-dimensional ultrasound images in the training set. Multiple feature selection strategy including intraclass correlation coefficient, univariate analysis, Pearson correlation coefficient, and recursive feature elimination were applied to construct three diagnostic models. A radiomics model, a deep learning model, and a combined model were

基金项目: 茂名市科技计划项目(2023216)

作者单位: 1. 广东医科大学附属超声医学科, 广东 湛江 524000; 2. 茂名市人民医院超声医学科, 3. 科研中心, 广东 茂名 525000

通讯作者: 徐晓红, Email: 13828297586@139.com

constructed for diagnosing BOTs by Auto Encoder algorithm. Receiver operating characteristic (ROC) curve was drawn to evaluate the efficacy of each model in the preoperative diagnosis of cystic BOTs. Hosmer-Lemeshow goodness-of-fit test was used to assess the consistency between the models' diagnostic results and pathological findings, clinical decision curve was used to evaluate the clinical benefits of the models. A Meta-analysis by retrieving literature on artificial intelligence in BOTs imaging from the PubMed database was performed. **Results** Following a multiple stage feature selection strategy, 28 ultrasound radiomics and 29 deep learning features were selected to construct the radiomics model and deep learning model, respectively, while the combined model incorporated 8 ultrasound radiomics and 34 deep learning features. ROC curve analysis showed that the area under the curve (AUC), sensitivity, specificity of the radiomics model in the training and validation sets were 0.73, 74%, 64% and 0.83, 67%, 75%, respectively. The AUC, sensitivity, specificity of the deep learning model in the training and validation sets were 0.78, 74%, 69% and 0.81, 67%, 79%, respectively. The AUC, sensitivity, specificity of the combined model in the training and validation sets were 0.84, 93%, 65% and 0.87, 83%, 88%, respectively. The AUC of the combined model was higher than that of radiomics model and deep learning model. Hosmer-Lemeshow goodness-of-fit test indicated that the combined model demonstrated good agreement between diagnostic results and pathological findings in both the training and validation sets ($P=0.58, 0.46$). Clinical decision curve analysis demonstrated that the combined model indeed exhibited significantly higher clinical translational value compared to radiomics model and deep learning model. A total of 9 artificial intelligence studies on BOTs imaging were included. The comprehensive ROC curve analysis showed that the pooled AUC for artificial intelligence in the diagnosis of BOTs was 0.88, with a pooled sensitivity of 78% and a pooled specificity of 85%. **Conclusion** Machine learning models based on ultrasound radiomics and deep learning features have a certain clinical value for the preoperative diagnosis of cystic BOTs. The combination of radiomics and deep learning features further enhance the diagnostic efficacy.

KEY WORDS Ultrasonography; Borderline ovarian tumors; Radiomics; Deep learning; Machine learning

交界性卵巢肿瘤(borderline ovarian tumors, BOTs)是原发性卵巢占位性病变中的一种病理组织学类型,占原发性卵巢肿瘤的10%~15%^[1],被认为是卵巢恶性肿瘤的癌前病变。术前BOTs被误诊为良性病变可能导致治疗时机延误,从而出现恶性转化或扩散转移。尽管保留年轻BOTs患者的生育能力非常重要,但临床决策需要客观可靠的术前评估,以衡量肿瘤复发与保留生育能力间的关系^[2]。卵巢占位性病变术前影像学多表现为囊性或以囊性为主病变,这对准确识别囊性BOTs提出严峻挑战。研究^[3]表明人工智能可从影像图像中提取肉眼无法识别的高通量信息,在识别肾脏和胰腺囊性病变方面展现出巨大潜力,但在卵巢疾病中的应用目前尚少。本研究基于超声影像组学和深度学习特征构建机器学习模型,旨在探讨其诊断囊性BOTs的临床价值。

资料与方法

一、研究对象

选取2021年1月至2023年12月茂名市人民医院收治的囊性(包括以囊性为主)黏液性或浆液性卵巢占位性病变患者118例,年龄14~78岁,平均(43±15)岁。其中良性病变67例,包括浆液性肿瘤36例,黏液性肿瘤31例;BOTs 39例,包括浆液性肿瘤18例,黏液性肿瘤21例;恶性病变12例,包括浆液性肿瘤8例,黏液性肿

瘤4例。纳入标准:①均经术后病理确诊;②均于切除术前1个月内进行超声检查,超声表现为囊性或囊性成分>70%的病变;③均为原发病变。排除标准:①超声表现为实性或以实性为主的病变;②术前曾行放化疗;③超声图像上不能充分显示病变或图像质量欠佳。本研究经医院医学伦理委员会批准(批准号:PJ2024MI-K128-01),为回顾性研究故免除患者知情同意。

二、仪器与方法

1. 图像采集和分割:使用Philips EPIQ 7C和GE Logiq E9、E10彩色多普勒超声诊断仪,经腹部或经阴道探头,频率分别为3.5~5.0 MHz、5.0~10.0 MHz。患者取仰卧位或膀胱截石位,调节增益和深度以完全清晰显示病变,采集病变最大径切面图像并以DICOM格式保存,然后将图像导入ITK-SNAP软件(版本:3.68),由2名具有5年及以上腹部检查经验的超声医师手动分割病变感兴趣区。见图1。以上操作均为双盲条件下进行。

2. 超声影像组学和深度学习特征提取:采用简单随机分配方法以7:3的比例将118例患者分为训练集(82例)和验证集(36例)。基于训练集的二维超声图像提取超声影像组学和深度学习特征。首先将原始DICOM格式图像进行归一化处理,以减少不同超声仪器及采集参数对特征稳定性的影响。采用线性插值法将图像的体素大小重新采样到等体素(1 mm, 1 mm,




图1 基于ITK-SNAP软件的图像感兴趣区分割示意图

1 mm)。应用Pyradiomics提取器基于Python环境提取超声影像组学特征,包括一阶特征、形状特征和纹理特征,共1316个特征^[4]。根据原始DICOM格式图像和分割后图像裁剪出包含病变的最大区域图像,调整其大小为224×224像素,并在Python环境下导入至ResNet50深度学习网络提取深度学习特征,共2048个特征^[5]。

3.模型的构建及验证:为评估特征的稳定性,由第3名具有8年腹部检查经验的超声医师随机抽取30例患者的二维超声图像进行分割,并结合余88例患者未行二次分割的超声图像再次提取特征,采用组内相关系数(ICC)分析观察者间的一致性,截断值设为0.90,保留ICC>0.90的特征。采用单因素分析筛选与囊性BOTs识别高度相关的差异特征,并对两个数据集的特征进行Z-score归一化处理。采用皮尔逊相关系数(PCC)分析训练集每对特征间的相关性,随机剔除PCC>0.85特征对的其中之一。剩余特征采用递归特征消除方法进一步选择显著特征用于识别囊性BOTs。采用Auto Encoder(AE)算法分别构建基于超声影像组学和深度学习特征的机器学习模型(以下简称影像组学模型和深度学习模型),采用5折交叉验证法训练模型,并基于验证集评估各模型诊断囊性BOTs的效能。样本不均衡问题应用SMOTE过采样技术解决以提升数据及改善建模性能。基于超声影像组学和深度学习特征的联合模型采用特征前融合策略以相同的特征选择方式进行构建及验证。

4.临床资料收集:记录患者年龄、病变最大径、病理结果、中性粒细胞计数与淋巴细胞计数比值(NLR)、血小板计数与淋巴细胞计数比值(PLR)、全身免疫炎症指数(SII)、预后营养指数(PNI)、鳞状上皮细胞癌抗原(SCCA)、人附睾蛋白4(HE4)、糖类抗原125(CA125)、癌胚抗原(CEA)。

5.BOTs影像相关人工智能诊断效能的荟萃分析:在PubMed数据库以“Borderline”“Ovarian tumor”“Radiomics”“Deep learning”单独或组合检索BOTs影像相关人工智能的文献,检查时间为建库至2024年4月15日。仅纳入可提取曲线下面积(AUC)、灵敏度、特异度的文献,应用Stata软件(版本:12.0)进行荟萃分析。

三、统计学处理

应用SPSS 17.0统计软件和R语言(版本:4.4.1)进行数据分析。计量资料以 $\bar{x} \pm s$ 表示,采用 t 检验;计数资料以例表示,采用 χ^2 检验。绘制受试者工作特征(ROC)曲线评估各模型诊断囊性BOTs的效能,AUC比较采用DeLong检验;采用Hosmer-Lemeshow拟合优度检验评估模型诊断结果与病理结果的一致性;临床决策曲线评估模型的临床收益。 $P<0.05$ 为差异有统计学意义。

结 果

一、训练集与验证集临床资料比较

训练集与验证集年龄、病变最大径、病理结果、NLR、PLR、SII、PNI、SCCA、HE4、CA125、CEA比较差异均无统计学意义。见表1。

二、模型的构建及验证

1316个超声影像组学特征经ICC、单因素分析、PCC筛选,分别剔除了197、963、126个,再采用递归特征消除方法筛选出28个特征构建影像组学模型;2048个深度学习特征经ICC、单因素分析、PCC筛选,分别剔除了1246、721、0个,再采用递归特征消除方法筛选出29个特征构建深度学习模型;基于ICC和单因素分析筛选出156个超声影像组学特征和81个深度学习特征进行特征前融合,并以相同方式进行开发,最终纳入8个超声影像组学特征和34个深度学习特征构建联合模型。

ROC曲线分析显示,影像组学模型在训练集和验证集中诊断囊生BOTs的AUC、灵敏度、特异度分别为0.73[95%可信区间(CI):0.61~0.85]、74%、64%和0.83(95%CI:0.70~0.96)、67%、75%;深度学习模型在训练集和验证集的AUC、灵敏度、特异度分别为0.78(95%CI:0.67~0.88)、74%、69%和0.81(95%CI:0.64~0.97)、67%、79%;联合模型在训练集和验证集的AUC、灵敏度、特异度分别为0.84(95%CI:0.76~0.93)、93%、65%和0.87(95%CI:0.74~1.00)、83%、88%。联合模型在验证集和验证集的AUC、灵敏度、特异度均较影像组学模型和深度学习模型有所提高,且联合模型在训练集的AUC与影像组学模型比较差异

表 1 训练集与验证集临床资料比较

数据集	年龄(岁)	病变最大径 (mm)	病理结果(例)		NLR	PLR	SII
			非 BOTs	BOTs			
训练集(82)	44.16±15.18	93.50±38.88	55	27	2.67±1.81	161.73±66.90	756.30±530.71
验证集(36)	40.11±13.51	94.67±38.40	24	12	2.60±1.67	166.37±61.09	741.82±420.01
χ^2 值	-1.29	-0.14	0.00		-0.13	-0.79	-0.40
P值	0.20	0.89	0.97		0.90	0.43	0.69

数据集	PNI	SCCA(ng/L)	HE4(例)		CA125(例)		CEA(例)	
			<50 pmol/L	≥50 pmol/L	<35 U/ml	≥35 U/ml	<2 ng/ml	≥2 ng/ml
训练集(82)	52.00±5.11	1.16±2.68	64	18	68	14	59	23
验证集(36)	52.37±5.73	0.98±0.67	32	4	28	8	27	9
χ^2 值	-0.28	-0.74	-0.51		-1.69		-0.51	
P值	0.78	0.46	0.61		0.09		0.61	

NLR:中性粒细胞计数与淋巴细胞计数比值;PLR:血小板计数与淋巴细胞计数比值;SII:全身免疫炎症指数;PNI:预后营养指数;SCCA:鳞状上皮细胞癌抗原;HE4:人附睾蛋白4;CA125:糖类抗原125;CEA:癌胚抗原

有统计学意义($P=0.03$)。见图2。Hosmer-Lemeshow 拟合优度检验显示,联合模型在训练集和验证集的诊断结果与病理结果的一致性均良好($P=0.58$ 、 0.46)。临床决策曲线分析显示,联合模型较影像组学模型和深度学习模型更具临床转化价值。见图3。

三、基于荟萃分析汇总 BOTs 影像相关人工智能的诊断效能评估

共纳入9篇^[2,6-13]BOTs影像相关人工智能文献(表2),其纳入标准并未对非囊性BOTs进行排除。其中2篇^[10-11]为深度学习,7篇^[2,6-9,12-13]为影像组学;5篇^[2,8-11]基于MRI图像,3篇^[6,12-13]基于CT图像,1篇^[7]基于超声图像。9篇文献中共6个训练集和8个验证集符合荟萃分析要求,综合ROC曲线分析显示,人工智能诊断BOTs的综合AUC为0.88,综合灵敏度为78%,综合特异度为85%。见图4。

讨 论

BOTs是一种组织学特征和生物学行为介于良性与恶性肿瘤之间的肿瘤,以上皮细胞增殖、缺乏间质浸润和细胞核异型性为特征。其病理亚型主要表现为浆液性或黏液性肿瘤,前者较多见。一般而言,浆液性肿瘤壁薄、分隔少,大小不等,可有壁结节;黏液性肿瘤壁厚薄不均、分隔多,偏大,少有壁结节。本研究纳入的囊性BOTs中有18例浆液性肿瘤和21例黏液性肿瘤,其超声表现与之相似。BOTs发生于未生育的适龄女性时,为保留其生育能力,术前需与临床常见的卵巢良性肿瘤准确鉴别^[14]。本研究基于二维图像提取超声影像组学和深度学习特征构建机器学习模型,并探讨其诊断囊性BOTs的临床价值,旨在为术前治疗方案的制定提供非侵入性评估手段,实现个体化精准治疗。

目前临床将超声作为卵巢病变最常用的筛查手段,但一项纳入5篇常规超




图2 影像组学模型、深度学习模型和联合模型在训练集和验证集中诊断囊性BOTs的ROC曲线图

图3 影像组学模型、深度学习模型和联合模型在训练集和验证集中诊断囊性BOTs的临床决策曲线图

表2 BOTs影像相关人工智能诊断效能的荟萃分析

第一作者	发表时间(年)	数据集	样本量(例)	病理结果	影像学检查方法	AUC	灵敏度(%)	特异度(%)
Yu ^[6]	2021	验证集	55	BOTs、恶性病变	CT	0.86	80	75
Qi ^[7]	2021	训练集	122	BOTs、恶性病变	超声	0.89	77	88
Qi ^[7]	2021	验证集	51	BOTs、恶性病变	超声	0.84	92	79
Wei ^[2]	2022	训练集	309	良性病变、BOTs	MRI	0.82	80	71
Xu ^[8]	2022	训练集	63	BOTs、恶性病变	MRI	0.92	87	85
Xu ^[8]	2022	验证集	19	BOTs、恶性病变	MRI	0.97	92	100
Liu ^[9]	2022	训练集	99	BOTs、恶性病变	MRI	0.90	71	94
Liu ^[9]	2022	验证集	97	BOTs、恶性病变	MRI	0.82	73	85
Wang ^[10]	2023	验证集	49	BOTs、恶性病变	MRI	0.87	75	88
Jian ^[11]	2022	验证集	159	BOTs、恶性病变	MRI	0.88	75	81
Chen ^[12]	2024	训练集	198	良性病变、BOTs和恶性病变	CT	0.98	75	97
Chen ^[12]	2024	验证集	60	良性病变、BOTs和恶性病变	CT	0.60	33	82
Yu ^[13]	2024	训练集	127	BOTs、恶性病变	CT	0.88	94	66
Yu ^[13]	2024	验证集	55	BOTs、恶性病变	CT	0.83	76	85




图4 基于荟萃分析汇总BOTs影像相关人工智能的综合ROC曲线图

声诊断BOTs相关文献的荟萃分析^[15]发现,常规超声的诊断灵敏度较一致但特异度表现不一,该荟萃分析基于其中4篇文献进一步分析显示,常规超声诊断BOTs的综合特异度为86%,但综合灵敏度仅66%,表明常规超声对需要保留生育能力的BOTs患者诊断准确率较低,无法满足目前临床精准诊疗的需求。BOTs影像学可表现为囊性或以囊性为主的病变,与大多浆液性或黏液性肿瘤表现相似。不管是卵巢、肾脏或胰腺囊性占位性病变,均难以通过主观视觉影像表现有效地鉴别其性质,临床诊断主要依据可靠的分子或影像生物标志物^[16]。于超声而言,其影像生物标志物主要为定量特征,如超声造影定量分析,但超声造影剂有禁忌证,且定量结果存在显著的操作者间异质性,易受探头角度、扫查参数、造影剂注射时机等影响,故寻找更可靠、便捷及重复性好的超声影像生物标志物具有重要的临床意义。研究^[17]表明,不同病理类型囊性占位性病变内液体的物理特性(是否清晰、颜色、均匀性)、细胞特性和化学成分有一定差异,可能对图像

中体素的强度和分布产生较大影响,这为囊性BOTs的术前鉴别诊断带来新的探索视角。人工智能作为新兴的定量分析技术,可在医学影像中实现肿瘤生物学特征的高通量特征量化,主要包括影像组学和深度学习,其通过机器学习算法构建的预测模型能间接反映肿瘤病理学基础^[18],目前已在胰腺和肾脏囊性病变的诊断中展现出重要的应用价值^[19-20]。目前PubMed数据库收录了十余项BOTs影像相关人工智能的文献,但大多基于MRI和CT图像,且鉴别的类型主要包括BOTs与恶性病变、BOTs与良恶性病变、BOTs与良性病变;本研究纳入9篇文献进行荟萃分析,探讨人工智能诊断BOTs的临床价值,结果显示其综合AUC为0.88,综合灵敏度为78%,综合特异度为85%,初步验证了人工智能在BOTs诊断中的潜在价值。然而,目前PubMed收录的文献纳入对象时并未排除非囊性BOTs,其研究结果不足以阐明人工智能在囊性BOTs诊断中的应用价值,且其多集中于单一人工智能技术,尚未开展影像组学特征与深度学习特征的联合研究,基于影像图像的人工智能在原发性囊性BOTs与良恶性卵巢病变鉴别诊断中的应用仍需进一步探索。

基于上述研究现状,本研究探讨了基于超声影像组学和深度学习特征的机器学习模型诊断囊性BOTs的临床价值。既往人工智能诊断BOTs的相关研究并未排除实性或以实性为主的卵巢占位性病变,可能影响预测模型诊断囊性BOTs的精准性,故本研究更关注囊性或以囊性为主的浆液性或黏液性卵巢占位性病变,纳入的118患者均经病理证实,其中良性病变67例、BOTs 39例、恶性病变12例。纳入恶性病变较

少的原因在收集病例过程中笔者发现浆液性或黏液性恶性病变的声像图多表现为实性或实性为主,与本研究纳入标准不符。本研究基于随机抽样分配方法将纳入患者分为训练集和验证集,两个数据集的临床资料比较差异均无统计学意义,可排除基线特征对结果的干扰。本研究构建的影像组学模型、深度学习模型和联合模型基于 AE 算法开发,并经验证集验证,各模型诊断囊性 BOTs 的 AUC 均 >0.80,灵敏度均 >67%,特异度均 >75%。本研究构建的联合模型诊断囊性 BOTs 的效能高于既往一项纳入相同病理类型样本的研究^[12],该研究基于 CT 图像开发的预测模型在验证集的 AUC 仅 0.60。进一步分析发现,联合模型在训练集和验证集的 AUC 均高于影像组学模型和深度学习模型,与 Wu 等^[21]研究结果相似,表明两种特征联合应用可以提高对囊性 BOTs 的诊断效能;且临床决策曲线分析亦显示联合模型较影像组学模型和深度学习模型更具临床转化价值。

本研究的局限性:①为单中心、回顾性研究,存在选择偏倚;②纳入的恶性病变较少,可能影响模型的泛用性;③图像为手工分割,尚未与半自动、全自动分割方式进行效能差异对比。今后需扩大囊性恶性卵巢病变样本量,进行多中心、前瞻性研究进一步验证。

综上所述,基于超声影像组学和深度学习特征构建的机器学习模型在诊断囊性 BOTs 中均有一定的临床价值,二者联合的诊断效能更佳,可为 BOTs 患者术前治疗方案的制定提供非侵入性评估手段,从而实现个体化精准治疗。

参考文献

- [1] Carbonnel M, Layoun L, Poulain M, et al. Serous borderline ovarian tumor diagnosis, management and fertility preservation in young women[J]. J Clin Med, 2021, 10(18):4233.
- [2] Wei M, Zhang Y, Bai G, et al. T2-weighted MRI-based radiomics for discriminating between benign and borderline epithelial ovarian tumors: a multicenter study[J]. Insights Imaging, 2022, 13(1):130.
- [3] Zhang Y, Wu J, He J, Xu S. Preoperative differentiation of pancreatic cystic neoplasm subtypes on computed tomography radiomics[J]. Quant Imaging Med Surg, 2023, 13(10):6395–6411.
- [4] Tang Y, Su YX, Zheng JM, et al. Radiogenomic analysis for predicting lymph node metastasis and molecular annotation of radiomic features in pancreatic cancer[J]. J Transl Med, 2024, 22(1):690.
- [5] Yu FH, Miao SM, Li CY, et al. Pretreatment ultrasound-based deep learning radiomics model for the early prediction of pathologic response to neoadjuvant chemotherapy in breast cancer[J]. Eur Radiol, 2023, 33(8):5634–5644.
- [6] Yu XP, Wang L, Yu HY, et al. MDCT-based radiomics features for the differentiation of serous borderline ovarian tumors and serous malignant ovarian tumors[J]. Cancer Manag Res, 2021, 13:329–336.
- [7] Qi L, Chen D, Li C, et al. Diagnosis of ovarian neoplasms using nomogram in combination with ultrasound image-based radiomics signature and clinical factors[J]. Front Genet, 2021, 12:753948.
- [8] Xu Y, Luo HJ, Ren J, et al. Diffusion-weighted imaging-based radiomics in epithelial ovarian tumors: assessment of histologic subtype[J]. Front Oncol, 2022, 12:978123.
- [9] Liu X, Wang T, Zhang G, et al. Two-dimensional and three-dimensional T2 weighted imaging-based radiomic signatures for the preoperative discrimination of ovarian borderline tumors and malignant tumors[J]. J Ovarian Res, 2022, 15(1):22.
- [10] Wang Y, Zhang H, Wang T, et al. Deep learning for the ovarian lesion localization and discrimination between borderline and malignant ovarian tumors based on routine MR imaging[J]. Sci Rep, 2023, 13(1):2770.
- [11] Jian J, Li Y, Xia W, et al. MRI-based multiple instance convolutional neural network for increased accuracy in the differentiation of borderline and malignant epithelial ovarian tumors[J]. J Magn Reson Imaging, 2022, 56(1):173–181.
- [12] Chen J, Liu L, He Z, et al. CT-based radiomics and machine learning for differentiating benign, borderline, and early-stage malignant ovarian tumors[J]. J Imaging Inform Med, 2024, 37(1):180–195.
- [13] Yu X, Zou Y, Wang L, et al. Radiomics nomogram for preoperative differentiation of early-stage serous borderline ovarian tumors and serous malignant ovarian tumors[J]. Front Oncol, 2024, 13:1269589.
- [14] Văduva CC, Constantinescu C, Ţenovici M, et al. Conservative treatment of borderline ovarian tumors: a retrospective study[J]. Rom J Morphol Embryol, 2023, 64(2):143–150.
- [15] Otfy M, Laios A, Elshamy T, et al. A systematic review and Meta-analysis of the use of ultrasound to diagnose borderline ovarian tumours[J]. Eur J Obstet Gynecol Reprod Biol, 2020, 244:120–127.
- [16] Carmicheal J, Patel A, Dalal V, et al. Elevating pancreatic cystic lesion stratification: current and future pancreatic cancer biomarker (s)[J]. Biochim Biophys Acta Rev Cancer, 2020, 1873(1):188318.
- [17] 李兆申, 金震东, 李汛. 中国胰腺囊性肿瘤诊断指南(2022年)[J]. 临床肝胆病杂志, 2023, 39(2):290–298, 481–487.
- [18] 李敬, 刘宁宁, 王笑一. 人工智能在超声诊断中的应用现状及展望[J]. 中国超声医学杂志, 2022, 38(5):595–598.
- [19] Dana J, Lefebvre TL, Savadjiev P, et al. Malignancy risk stratification of cystic renal lesions based on a contrast-enhanced CT-based machine learning model and a clinical decision algorithm [J]. Eur Radiol, 2022, 32(6):4116–4127.
- [20] Liang W, Tian W, Wang Y, et al. Classification prediction of pancreatic cystic neoplasms based on radiomics deep learning models[J]. BMC Cancer, 2022, 22(1):1237.
- [21] Wu L, Li S, Wu C, et al. Ultrasound-based deep learning radiomics nomogram for differentiating mass mastitis from invasive breast cancer[J]. BMC Med Imaging, 2024, 24(1):189.

(收稿日期:2024-08-04)