

本文引文格式:李文武,卜慧萍,姚明哲,等.基于CT影像组学结合机器学习预测复杂性与非复杂性急性阑尾炎[J].右江民族医学院学报,2024,46(1):57-64.

【论著与临床报道】

基于CT影像组学结合机器学习预测 复杂性与非复杂性急性阑尾炎

李文武¹, 卜慧萍², 姚明哲¹, 竺仕林¹, 杨雅量¹, 葛星月¹, 唐乾利³

(1. 右江民族医学院研究生学院, 广西 百色 533000;

2. 广西医科大学第一附属医院放射科, 广西 南宁 530021;

3. 右江民族医学院附属医院, 广西 百色 533000)

摘要:目的 探讨和验证不同影像组学模型在复杂性与非复杂性急性阑尾炎的术前鉴别诊断中的价值。方法 回顾性分析212例经手术病理证实为急性阑尾炎患者的临床资料及CT平扫图像,从CT图像中提取影像组学特征,经过特征的降维和筛选,分别采用Logistic回归、支持向量机(SVM)和随机森林等算法构建影像组学模型,通过比较受试者工作特征(ROC)曲线下面积(AUC)、准确度、95%置信区间(95%CI)等指标获得最佳的影像组学模型。此外,应用单因素和多因素Logistic回归分析来筛选临床特征并建立临床模型。通过多变量逻辑回归将影像组学标签与临床标签相结合,构建一个组合模型。最后,采用ROC曲线分析来评估模型的性能,并利用决策曲线分析(DCA)来评估模型的临床价值。**结果** 最终筛选出年龄和C反应蛋白2个临床特征。从每个患者CT图像共提取出1834个影像组学特征,并确定了16个最有价值的影像组学特征。在影像组学模型中,SVM表现出最佳的预测效率和稳定性,训练集和测试集的AUC分别为0.916(95%CI为0.862~0.970)和0.842(95%CI为0.739~0.945)。在所有模型中,组合模型的诊断效能最佳,训练集和测试集的AUC分别为0.943(95%CI为0.896~0.990)和0.855(95%CI为0.759~0.951)。DCA提示组合模型具有更好的预测性能和临床价值。**结论** 结合影像组学特征与临床特征的组合模型对复杂性与非复杂性急性阑尾炎具有良好的预测能力,可以为临床决策提供了一种无创、有效的方法,避免不必要的手术切除。

关键词:影像组学;机器学习;急性阑尾炎;临床特征

中图分类号:R445;R656.8

文献标识码:A

文章编号:1001-5817(2024)01-0057-08

doi:10.3969/j.issn.1001-5817.2024.01.011

Prediction of complicated and uncomplicated acute appendicitis using CT-based radiomics combined with machine learning models

Li Wenwu¹, Bu Huiping², Yao Mingzhe¹, Zhu Shilin¹, Yang Yaliang¹, Ge Xingyue¹, Tang Qianli³

(1. Graduate School, Youjiang Medical University for Nationalities, Baise 533000, China;

2. Radiology Department, First Affiliated Hospital of Guangxi Medical University,

Nanning 530021, China; 3. Affiliated Hospital of Youjiang Medical University

for Nationalities, Baise 533000, China)

Abstract: **Objective** To explore and validate the value of various radiomics models in the preoperative discrimination between complicated and uncomplicated acute appendicitis. **Methods** retrospective analysis of clinical data and CT plain images from 212 surgically confirmed acute appendicitis cases was conducted. Radiomic features were extracted from CT images, following feature reduction and selection. Various algorithms

基金项目:广西特聘专家项目(桂人才通字[2019]13号);广西医学高层次领军人才培养“139”计划项目资助(桂卫科教发[2018]22号)

第一作者:李文武,在读硕士研究生,研究方向:普外科疾病的基础与临床研究,E-mail:liwenwu66@163.com

通讯作者:唐乾利,二级教授、主任医师,博士/硕士研究生导师,研究方向:胆石症和创面修复的基础与临床研究,E-mail:htmgx@163.com

including Logistic Regression, Support Vector Machine (SVM), and Random Forest were employed to construct radiomics models. Model performance was evaluated by comparing metrics such as the Area Under the Receiver Operating Characteristic (ROC) Curve (AUC), accuracy, and 95% confidence intervals(95% CI) to determine the optimal radiomics model. Additionally, univariate and multivariate Logistic Regression analyses were performed to select clinical features and establish a clinical model. A combined model was developed by integrating radiomic labels with clinical labels using multivariate logistic regression. Finally, ROC curve analysis was conducted to assess the model's performance, and Decision Curve Analysis (DCA) was conducted to evaluate its clinical utility. **Results** The final selection included age and C-reactive protein as the two clinical features. From each patient's CT images, a total of 1 834 radiomic features were extracted, 16 most valuable features identified. Among the radiomics models, SVM exhibited the highest predictive efficiency and stability, with AUCs of 0.916 (95% CI :0.862~0.970) in the training set and 0.842 (95% CI :0.739~0.945) in the test set. In all models, the combined model showed the best diagnostic performance, with AUCs of 0.943 (95% CI :0.896~0.990) in the training set and 0.855 (95% CI :0.759~0.951) in the test set. DCA suggested that the combined model had superior predictive performance and clinical value. **Conclusion** The combined model integrating radiomic and clinical features demonstrates robust predictive ability in distinguishing between complicated and uncomplicated acute appendicitis, providing a non-invasive and effective approach for clinical decision-making and potentially avoiding unnecessary surgical resection.

Key words: Radiomics; Machine Learning; Acute Appendicitis; Clinical Feature

急性阑尾炎(acute appendicitis, AA)为临床常见急腹症,起病急且进展迅速,根据病理亚型 AA 可分为复杂性急性阑尾炎(complicated acute appendicitis, CA)和非复杂性急性阑尾炎(uncomplicated acute appendicitis, UCA)两种,CA 指的是伴随坏疽、穿孔或局部脓肿形成的 AA,二者分别可采取手术和非手术的治疗方式,但两者在临床上鉴别较为困难^[1]。因此,寻找一种能够在术前准确鉴别二者的方法极为重要。计算机断层扫描(computed tomography, CT)影像学特征和临床特征均在一定程度上有助于预测 AA 病理亚型,有助于不同 AA 的术前诊断和优化治疗。近年来,影像组学已成为一个前景广阔的新兴领域,它通过高通量提取大量影像学特征,分析病变形状和纹理特征,对医学图像进行深入的探索和分析,揭示肉眼无法观测到的图像中隐藏的、复杂的细节,不受医师的工作经验及主观因素的影响,能够根据不同疾病的异质性反映潜在的相关表型信息以提供对疾病的全面定量分析^[2]。为了进一步深入探索影像组学在 AA 中的应用价值,本研究通过 CT 影像组学特征结合临床特征构建模型来鉴别 CA 和 UCA,为患者精准治疗提供临床决策依据。

1 材料与方法

1.1 患者群体 经医院机构伦理审查委员会的批准,本课题组收集了 2019 年 7 月至 2023 年 3 月期间在本院经手术病理诊断为 AA 的患者病例资料。纳入标准:①年龄 ≥ 14 岁;②有手术记录和组织病理学结果;③患者术前 24 h 行腹部或盆腔 CT 平扫;④发病后没有使用抗生素治疗;⑤临床资料完整。排除标准:①呼

吸、胃肠道蠕动或金属伪影所致的影像质量不佳;②因严重的阑尾周围积液、粘连或肠管重叠而在 CT 上看不清阑尾轮廓;③经手术组织病理学证实为非急性阑尾炎(如慢性阑尾炎、阑尾黏液囊肿、阑尾黏液性肿瘤、阑尾神经内分泌肿瘤或阑尾癌等);④合并精神病患者;⑤同期实施其他手术;⑥合并有免疫系统或血液系统相关疾病或肿瘤。经上述标准最终纳入 212 例患者,其中 CA 63 例(男性 31 例、女性 32 例),UCA 149 例(男性 81 例、女性 68 例),按 7:3 的比例随机分为训练集(CA 44 例、UCA 104 例)和测试集(CA 19 例、UCA 45 例)。

1.2 仪器及扫描范围 仪器使用美国 GE 公司 64 排计算机断层扫描仪常规螺旋扫描,取仰卧位,扫描范围从横膈膜到耻骨连合。主要扫描参数:螺距 0.984,管电压 100~120 kV,有效管电流 200~300 mAs,扫描层厚 5 mm。

1.3 影像及临床资料分析 患者的 CT 影像和临床数据来自本院的常规临床记录和图像存档与通信系统(picture archiving and communication system, PACS)和医院信息系统(hospital information system, HIS)系统。本课题组回顾性分析的临床资料包括性别、年龄、白细胞(WBC)、中性粒细胞(NEUT)、血红蛋白(HGB)、血小板(PLT)、白蛋白(ALB)、球蛋白(GLO)、C 反应蛋白(CRP)、中性粒细胞与淋巴细胞比值(NLR)、血小板与淋巴细胞比值(PLR)和术后病理诊断结果。

1.4 图像分割 所有图像以数字化医学影像与通信(digital imaging and communications in medicine, DI-

COM)格式存储。所有 CT 图像分别由两名具有 10 年以上工作经验的影像科医生评估,他们对组织病理学和临床数据不知情,且不可以相互讨论影像结果或病情。使用 3D Slicer(Version:5.0.2)手动分割感兴趣区域(region of interest, ROI),逐层勾画出阑尾的

3D 形态。他们分别完成了所有图像的分割。完整的示意图如图 1 所示。为保证结果的可重复性,所有 CT 图像经过重采样和标准化预处理,并通过组内相关系数(intraclass correlation coefficient, ICC)评估观察者之间的重现性,ICC>0.75 表示一致性良好。

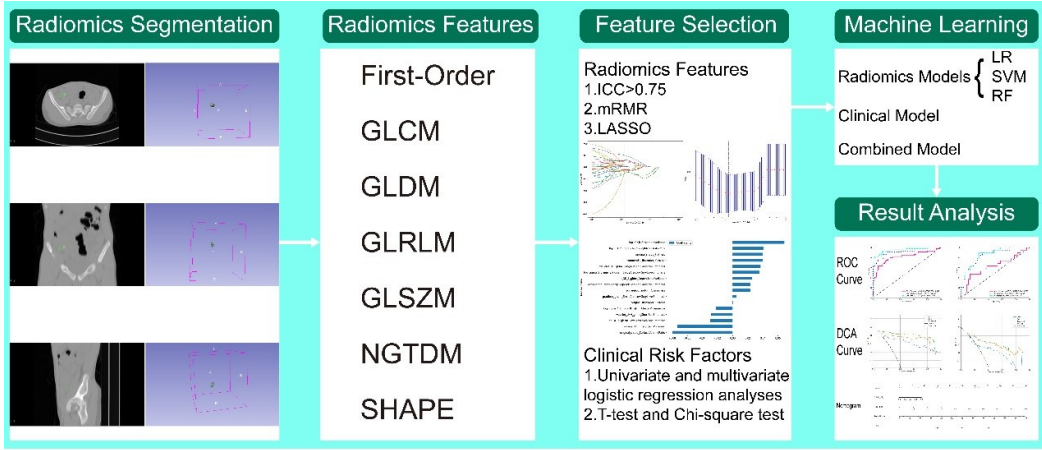
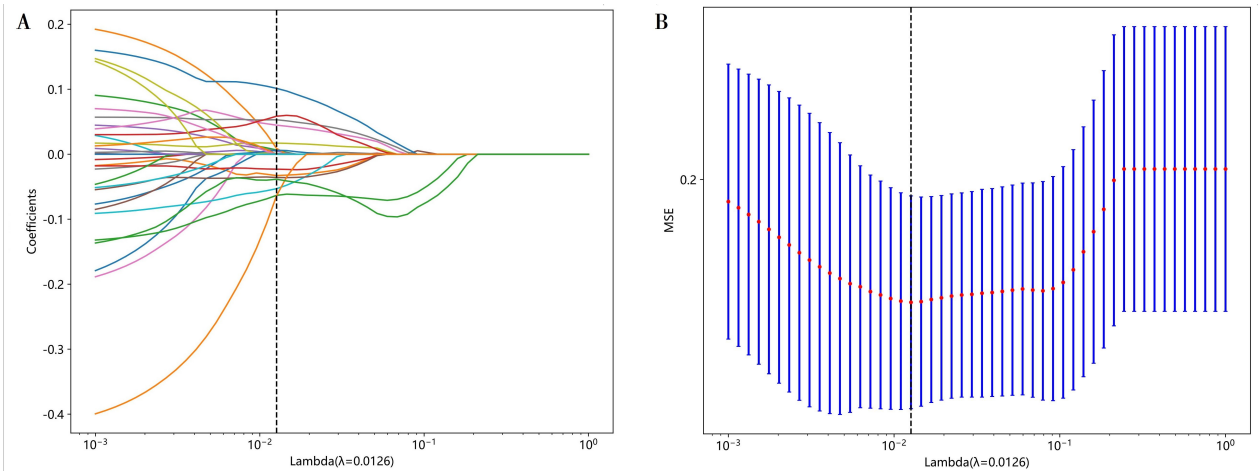


图 1 本研究的工作流程

1.5 影像组学特征提取/选择 基于 Python(Version:3.5.6)的 pyradiomics 程序包(Version:3.0),从这些 ROI 提取特征,提取的特征包括一阶特征(first-order features)、灰度共生矩阵特征(gray-level co-occurrence matrix features, GLCM)、灰度依赖矩阵特征(gray-level dependence matrix features, GLDM)、灰度行程长度矩阵特征(gray-level run length matrix features, GLRLM)、灰度大小区域矩阵特征(gray-level size zone matrix features, GLSZM)、相邻灰度差异矩阵特征(neighborhood gray-tone difference matrix features, NGTDM)和基于形状的特征(shape-based fea-

tures, SHAPE)。接着,对训练集的影像组学特征进行降维和筛选。首先,对两名影像科医生分割的 ROI 提取特征进行 ICC 校验,保留 ICC>0.75 的稳健特征。接着,对所有特征进行显著性检验,筛选出 $P < 0.05$ 的特征。最后,采用最大相关最小冗余(minimum redundancy maximum correlation, mRMR)和最小绝对收缩选择算子(least absolute shrink and selection operator, LASSO)方法从中筛选出最具意义的特征用于后续建模,见图 2。所有特征的选择过程都在训练集上执行,并将其应用于测试集。



注:A. 显示了不同对数(λ)下的套索系数剖面图,垂直虚线表示在最佳 Lambda 值下选择的具有非零系数的 16 个影像组学特征;B. 利用最小二项偏差通过 LASSO 调整 Lambda,筛选出了最有价值的特征。

图 2 影像组学特征降维及筛选过程

1.6 影像组学特征模型的建立 分别选择 3 种主流的机器学习算法结合筛选的影像组学特征构建模型,包括 Logistic 回归(logistic regression, LR)、支持向量机(support vector machine, SVM)和随机森林(random forest, RF)。通过受试者工作特征(receiver operating characteristic, ROC)曲线下面积(area under the curve, AUC)、95%置信区间(confidence intervals, CI)、准确性、敏感性、特异性、阳性预测值(positive prediction value, PPV)、阴性预测值(negative prediction value, NPV)等指标,评估和比较这 3 种模型的诊断性能,并筛选出最佳的影像组学模型,获得影像组学标签。

1.7 临床及组合模型的构建与验证 对每个临床特征进行单因素、多因素 LR 分析,以获取最终具有统计学意义的临床特征,用于建立临床模型,并导出临床标签。基于 SVM 算法,结合影像组学标签和临床标签,构建一个组合模型。通过对所有模型的性能进行评估,包括计算其 AUC、95% CI、准确性、灵敏度、特异性、PPV 和 NPV 等指标,并利用决策曲线分析(decision curve analysis, DCA)来定量评估模型在不同阈值概率下的净收益,以评价模型的预测性能和临床价值。

1.8 统计学方法 应用 SPSS 软件(Version: 26.0, IBM)及 Python 软件进行统计分析。离散变量使用 χ^2 检验,用比率(%)表示;对连续变量先行正态性检验来判断数据是否呈正态分布,正态分布的数据使用独立样本 t 检验,用 $(\bar{x} \pm s)$ 表示;非正态分布数据使用

Mann-Whitney U 检验,用 $M(P_{25} \sim P_{75})$ 表示。 $P < 0.05$ 为差异有统计学意义。

2 结果

2.1 患者的人群和影像学特征 共纳入了 212 例患者(男性 112 例,女性 100 例),其中训练集 148 例,测试集 64 例。表 1 结果表明,训练集和测试集之间差异无统计学意义($P > 0.05$)。表 2 总结了患者的临床特征基线分析结果。在训练集中,年龄、WBC、NEUT、CRP、NLR、PLR 均差异有统计学意义($P < 0.05$)。在测试集中,WBC、NEUT、CRP 差异有统计学意义($P < 0.05$)。单因素和多因素 LR 分析显示,年龄和 CRP 差异均有统计学意义($P < 0.05$),见表 3。

表 1 训练集和测试集之间临床数据的比较

项目	训练集 ($n=148$)	测试集 ($n=64$)	t/χ^2	P
性别			0.003	0.955
男	78	34		
女	70	30		
年龄/岁	42.93±17.39	44.3±7.57	0.186	0.853
WBC($\times 10^9/L$)	12.45±5.44	28.55±10.61	0.744	0.458
NEUT($\times 10^9/L$)	10.24±5.61	82.58±73.99	0.671	0.503
HGB($g \cdot L^{-1}$)	139.09±99.33	228.63±157.67	0.579	0.563
PLT($\times 10^9/L$)	257.94±85.26	251.11±65.72	0.572	0.568
ALB($g \cdot L^{-1}$)	44.30±7.57	43.57±5.46	0.695	0.488
GLO($g \cdot L^{-1}$)	28.55±10.61	27.23±6.35	0.926	0.355
CRP($mg \cdot L^{-1}$)	82.58±73.99	81.37±75.42	0.109	0.913
NLR	10.47±11.93	10.52±10.92	-0.027	0.978
PLR	228.63±157.67	233.34±152.83	-0.202	0.840

注:表内计量资料数据以 $(\bar{x} \pm s)$ 表示。

表 2 CA 和 UCA 在训练集和测试集中的临床数据比较

项目	训练集($n=148$)			测试集($n=64$)		
	UCA($n=104$)	CA($n=44$)	P	UCA($n=45$)	CA($n=19$)	P
性别			0.964			0.251
男	55	23		26	8	
女	49	21		19	11	
年龄/岁	40.38±16.26	48.95±18.64	0.006	40.89±17.23	46.11±19.58	0.292
WBC($\times 10^9/L$)	11.70±5.54	14.23±4.81	0.009	10.40±3.87	15.34±5.21	<0.001
NEUT($\times 10^9/L$)	9.45±5.87	12.11±4.46	0.008	8.33±4.13	12.95±5.00	<0.001
HGB($g \cdot L^{-1}$)	143.61±117.76	128.43±18.59	0.397	132.76±20.04	129.63±21.34	0.578
PLT($\times 10^9/L$)	262.93±82.68	246.16±90.95	0.276	253.29±67.75	245.95±62.13	0.686
ALB($g \cdot L^{-1}$)	44.97±8.35	42.73±5.07	0.101	44.42±5.64	41.56±4.54	0.055
GLO($g \cdot L^{-1}$)	28.66±12.36	28.29±4.37	0.848	27.60±6.55	26.36±5.91	0.483
CRP($mg \cdot L^{-1}$)	63.10±62.26	128.60±79.65	<0.001	59.02±62.72	134.30±78.03	<0.001
NLR	8.79±10.12	14.46±14.77	0.008	9.69±9.90	12.50±13.11	0.351
PLR	209.70±140.45	273.37±186.59	0.024	248.47±173.56	197.51±78.69	0.226

注:表内计量资料数据以 $(\bar{x} \pm s)$ 表示。

表 3 应用单因素和多因素 Logistic 回归分析选择模型开发的临床特征

项目	单因素分析		多因素分析	
	OR (95% CI)	P	OR (95% CI)	P
性别	0.976(0.482~1.976)	0.946		
年龄	1.030(1.008~1.052)	0.007	1.030(1.005~1.056)	0.019
WBC	1.089(1.017~1.167)	0.015	1.029(0.926~1.143)	0.595
NEUT	1.089(1.018~1.166)	0.014	1.049(0.933~1.179)	0.425
HGB	0.992(0.976~1.008)	0.325		
PLT	0.998(0.993~1.002)	0.275		
ALB	0.942(0.880~1.009)	0.086		
GLO	0.996(0.961~1.033)	0.847		
CRP	1.013(1.007~1.019)	<0.001	1.011(1.004~1.017)	0.001
NLR	1.041(1.006~1.076)	0.019	1.000(0.994~1.006)	0.998
PLR	1.002(1.000~1.005)	0.034	1.015(0.932~1.106)	0.727

2.2 影像特征模型及其性能 从每个 ROI 中共提取 1 834 个影像学特征,经过降维和筛选后,保留了 16 个最有价值的特征,见图 3。3 种影像组学模型(包括 LR、SVM、RF)在训练集和测试集中的 ROC 曲线如图 4 所示。在训练集中,最佳影像组学模型为 RF,其 AUC 为 1.000,准确度为 1.000,灵敏度为 1.000,特异性为 0.990,PPV 为 0.978,NPV 为 1.000。其次为 SVM,其 AUC 为 0.916,准确度为 0.851,灵敏度为 0.864,特异性为 0.846,PPV 为 0.704,NPV 为 0.936。

最后为 LR,其 AUC 为 0.909,准确度为 0.811,灵敏度为 0.886,特异性为 0.779,PPV 为 0.629,NPV 为 0.942。然而,在测试集中,RF 的 AUC 仅为 0.730,LR 的 AUC 为 0.828,表现最佳的是 SVM,其测试集的 AUC、准确率、灵敏度、特异性、PPV、NPV 分别为 0.842、0.750、0.895、0.689、0.548、0.939,见表 4。RF 模型表现出过拟合的趋势,为了保证模型的稳定性,最终选择 SVM 模型作为最佳的影像组学模型。

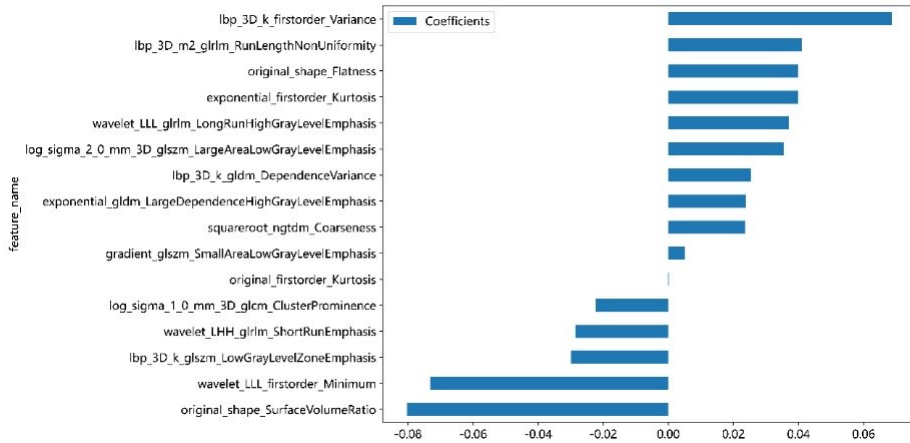
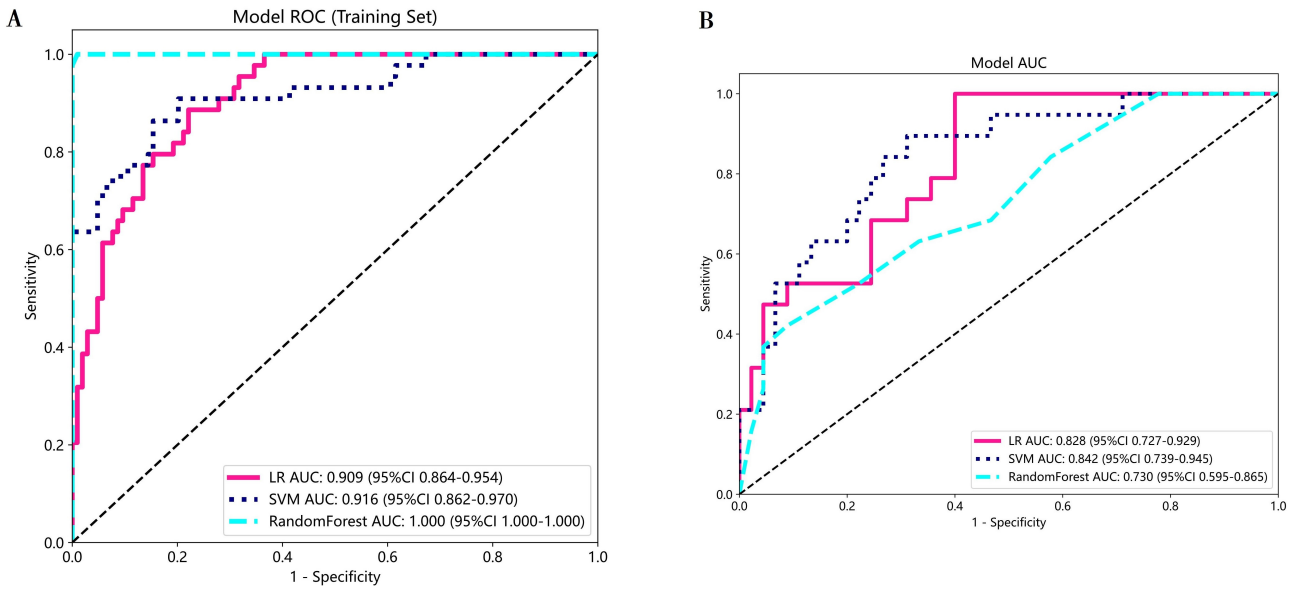


图 3 影像组学模型的 16 个最佳影像组学特征

2.3 组合模型构建和验证 通过将临床标签和影像组学标签相结合,建立了 1 个组合列线图模型。利用 SVM 建立了临床模型、影像组学模型和组合模型,并统一客观地评价不同模型的诊断效果,各评价指标及 Deng Long 检验结果见表 4。3 种模型在训练和测试集中的 ROC 曲线如图 5 所示。在训练集和测试集中,组合模型的 AUC 最大(训练集为 0.943,测试集为 0.855),组合模型诊断性能最优。3 种模型的 DCA 如图 6 所示,结果表明组合模型具有更好的预测性能和临床应用价值。

3 讨论

AA 既是急性腹痛的最常见原因,也是全球外科急诊疾病之一^[3]。组织病理学是诊断 AA 的金标准。根据组织病理学结果,AA 可分为 CA 和 UCA,这两者可以选择不同治疗方式。根据指南和相关研究表明,CA 首选手术治疗,UCA 推荐非手术治疗,虽然有一定的复发风险,但也是安全有效的^[1,4]。对于 UCA 患者,非手术治疗有着效果好、费用低,并发症发生率低和住院时间缩短等优点^[5]。因此,术前准确区分 CA 和 UCA 对于 AA 的治疗至关重要。



注:A. 训练集;B. 测试集。y 轴代表真阳性率(敏感性),x 轴代表假阳性率(1-特异性)。对角线表示随机分类器的性能。

图 4 影像组学模型(LR,SVM,RF)的接收器操作特征曲线

表 4 训练集和测试集中预测 CA 的不同模型的诊断性能

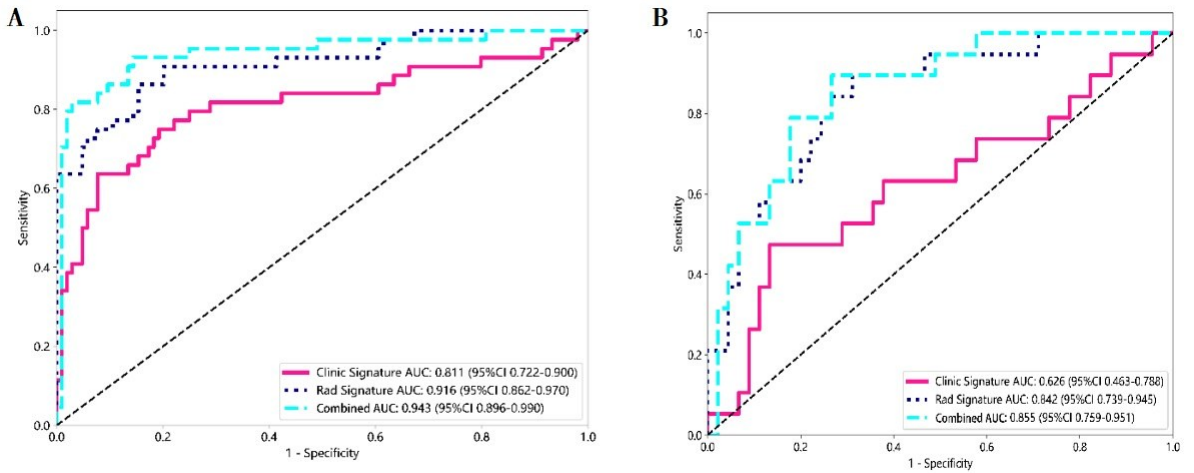
模型	AUC(95% CI)	准确度	灵敏度	特异性	PPV	NPV	P
LR							
训练集	0.909 (0.864~0.954)	0.811	0.886	0.779	0.629	0.942	
测试集	0.828 (0.727~0.929)	0.718	1.000	0.600	0.514	1.000	
SVM ^a							
训练集	0.916 (0.862~0.970)	0.851	0.864	0.846	0.704	0.936	0.283 ^b
测试集	0.842 (0.739~0.945)	0.750	0.895	0.689	0.548	0.939	0.053 ^c
RF							
训练集	1.000 (1.000~1.000)	1.000	1.000	0.990	0.978	1.000	
测试集	0.730 (0.595~0.866)	0.766	0.421	0.932	0.667	0.788	
Clinical ^a							
训练集	0.811(0.722~0.900)	0.838	0.636	0.923	0.778	0.857	0.005 ^b
测试集	0.626(0.463~0.788)	0.750	0.474	0.867	0.600	0.796	0.005 ^c
Combined ^a							
训练集	0.943(0.896~0.990)	0.926	0.818	0.971	0.923	0.927	
测试集	0.855(0.759~0.951)	0.781	0.895	0.75	0.586	0.943	

注:a 代表使用支持向量机构建的模型;b 表示训练集中每个模型与组合模型之间的 AUC 的 P 值的差异;c 表示在测试集中每个模型与组合模型之间的 AUC 的 P 值的差异。

近年来,影像技术的发展对 AA 的诊断起到了巨大作用,这些影像技术包括超声波(ultrasound,US)、计算机断层扫描(computed tomography,CT)和磁共振成像(magnetic resonance imaging,MRI)。其中,US 诊断 AA 的敏感性和特异性均低于 CT^[6]。MRI 扫描时间长、价格比较昂贵,不适用于作为 AA 的一线诊断工具。因此,CT 成为成人 AA 的常规临床诊断工具。既往有关研究表明通过 CT 征象进行 CT 分级后与 AA 的病理亚型密切相关^[7]。然而,常规的 CT 征象对 AA 的评估主要基于医师的肉眼观察和经验性分析,关于 AA 的影像学特征分类目前尚未形成共识^[8]。此外,有研究表明基于临床特征的机器学习方法对于

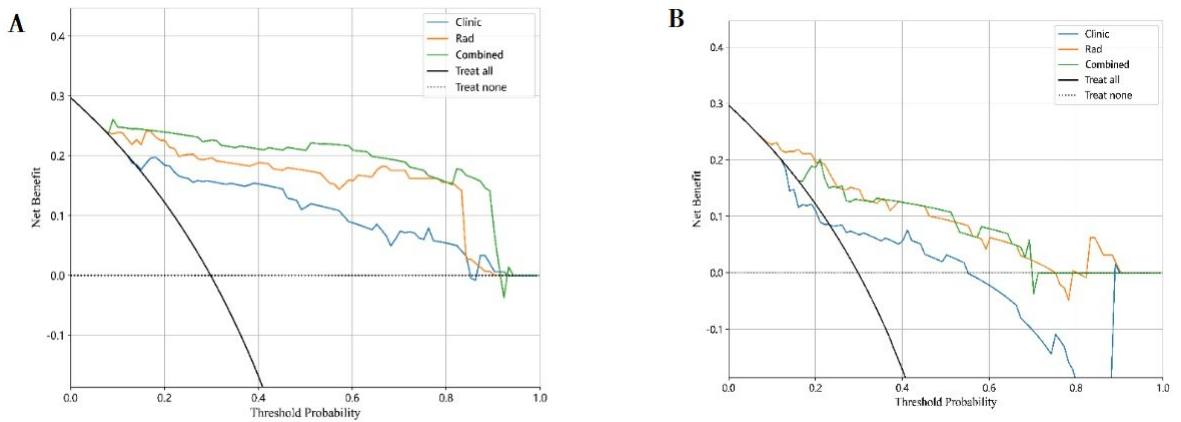
AA 的病理亚型鉴别也有很大价值^[9-10]。有研究将 CT 常规征象和临床特征相结合后用于鉴别不同 AA 也表现出优良的鉴别性能^[11]。由上可知,CT 影像学特征和临床特征均在一定程度上有助于预测 AA 病理亚型,有助于不同 AA 的术前诊断和优化治疗。

本研究通过筛选临床特征和影像组学特征建立了一个临床模型、影像组学模型以及组合模型,其中组合模型的 AUC 最大,训练集和测试集分别为 0.943 (95% CI 为 0.896~0.990)和 0.855(95% CI 为 0.759~0.951),结合 DCA 结果表明,组合模型对 CA 和 UCA 表现出最优的预测性能和临床价值。



注:A. 训练集;B. 测试集。y 轴上的真阳性率(敏感度)与 x 轴上的假阳性率(1-特异性)绘制。对角线表示随机分类器的性能。

图 5 临床模型、影像组学模型和组合模型的接收器操作特性曲线



注:A. 训练集;B. 测试集。y 轴表示净收益;x 轴表示阈值概率。

图 6 临床模型、影像组学模型和组合模型的决策曲线分析

3.1 年龄和 CRP 是 CA 的独立预测因素 本研究通过单因素和多因素 LR 分析表明,年龄和 CRP 是 CA 的独立预测因素。CA 患者的年龄高于 UCA,这与既往有关研究^[12-13]结果一致,可能随着年龄的逐步增长,患者的免疫功能呈下降趋势,因此与年轻人相比,老年人的炎症可能更重,更容易发展为 CA。CA 的 CRP 远高于 UCA,这与有关研究^[10,14]结果一致,可能原因是 CRP 作为一种常见的炎症指标,当机体发生感染或受到炎症刺激时,CRP 会升高,由于 CA 伴有坏疽、穿孔或局部脓肿形成等并发症,感染程度比 UCA 更重,所以 CRP 水平也会更高。

3.2 SVM 模型是最佳的影像组学模型 本研究中,SVM 和 RF 模型相较于 LR 模型表现更为出色,这可能暗示着 AA 数据可能是非线性的,因此使用线性算法的 LR 模型效果不如非线性的 RF 和 SVM。RF 是一种通过集成多个决策树进行决策的算法,具有高准确性,还可以进行属性选择。然而,当处理小样本队列

时,它的泛化能力较差,可能会出现过拟合问题。SVM 则表现出令人满意的稳定性和效率,在使用少量或大量样本训练时几乎具有相同的性能^[15]。

3.3 影像组学特征与临床特征结合 利用筛选出来的 16 个影像组学特征和 2 个临床特征,基于 SVM 分别构建了临床模型、影像组学模型和组合模型,结果表明影像组学模型与组合模型均能很好地对 CA 和 UCA 进行鉴别,但影像组学通过结合年龄和 CRP 这 2 个临床特征后,组合模型诊断性能得到提升,这表明,对于鉴别 CA 和 UCA,影像组学特征很重要,但是临床特征也不可或缺。

本研究的局限性:这是一项单中心的回顾性分析,由于临床案例数量及临床特征有限,因此可能存在选择性偏差,手动分割感兴趣区域可能受个人主观因素的影响。为了更好地探究 CT 影像组学在临床中的应用,未来本课题组将计划进行多中心随机对照研究(RCT),以扩大样本规模,并通过深度学习实现完全自

动化的分析,同时将更多临床特征纳入研究,以进一步验证模型的科学性。

综上所述,本研究开发并验证了一种基于 CT 影像学结合临床特征来预测 CA 和 UCA 的组合模型,组合模型表现出最好的诊断性能,也许这可作为精准医学的一种潜在方法,可用于改进临床治疗策略,为患者制定更精准的个体化治疗方案,减轻患者病痛的同时,提高患者生活质量,践行“健康中国行动”发展战略。

参考文献:

- [1] DI SAVERIO S, PODDA M, DE SIMONE B, et al. Diagnosis and treatment of acute appendicitis: 2020 update of the WSES Jerusalem guidelines[J]. *World J Emerg Surg*, 2020, 15(1): 27.
- [2] 汪嫚, 俞咏梅, 陈鹏飞. 基于 MRIT2-FLAIR 序列影像学鉴别无水肿型肺腺癌脑转移瘤与腔隙性脑梗死[J]. *右江民族医学院学报*, 2023, 45(1): 128-133.
- [3] KRZYŻAK M, MULROONEY S M. Acute Appendicitis review: background, epidemiology, diagnosis, and treatment[J]. *Cureus*, 2020, 12(6): e8562.
- [4] PODDA M, GERARDI C, CILLARA N, et al. Antibiotic treatment and appendectomy for uncomplicated acute appendicitis in adults and children: a systematic review and Meta-analysis[J]. *Ann Surg*, 2019, 270(6): 1028-1040.
- [5] YANG Z, SUN F, AI S, et al. Meta-analysis of studies comparing conservative treatment with antibiotics and appendectomy for acute appendicitis in the adult[J]. *BMC Surg*, 2019, 19(1): 110.
- [6] BORRUEL NACENTA S, IBÁÑEZ SANZ L, SANZ LUCAS R, et al. Update on acute appendicitis: typical and untypical findings[J]. *Radiologia (Engl Ed)*, 2023, 65 Suppl 1: S81-S91.
- [7] 马金连, 王远成, 刘芳, 等. 急性阑尾炎患者 CT 分级与病理表现及血清炎症标志物关系分析[J]. *临床军医杂志*, 2023, 51(10): 1078-1080, 1084.
- [8] SIPPOLA S, HAIJANEN J, GRÖNROOS J, et al. Effect of oral moxifloxacin vs intravenous ertapenem plus oral levofloxacin for treatment of uncomplicated acute appendicitis: the APPAC II randomized clinical trial[J]. *Jama*, 2021, 325(4): 353-362.
- [9] AKBULUT S, YAGIN F H, CICEK I B, et al. Prediction of perforated and nonperforated acute appendicitis using machine learning-based explainable artificial intelligence [J]. *Diagnostics (Basel)*, 2023, 13(6): 1173.
- [10] RIBEIRO A M, ROMERO I, PEREIRA C C, et al. Inflammatory parameters as predictive factors for complicated appendicitis: a retrospective cohort study[J]. *Ann Med Surg (Lond)*, 2022, 74: 103266.
- [11] LI G M, ZHOU H, LIANG M Y, et al. Diagnostic role of multislice spiral computed tomography combined with clinical manifestations and laboratory tests in acute appendicitis subtypes[J]. *J Investig Med*, 2023, 71(1): 17-22.
- [12] AKAI M, IWAKAWA K, YASUI Y, et al. Hyperbilirubinemia as a predictor of severity of acute appendicitis [J]. *J Int Med Res*, 2019, 47(8): 3663-3669.
- [13] AVANESOV M, WIESE N J, KARUL M, et al. Diagnostic prediction of complicated appendicitis by combined clinical and radiological appendicitis severity index (APSD)[J]. *Eur Radiol*, 2018, 28(9): 3601-3610.
- [14] AL SEHLANY, RAAD GAHEY, AL-GAZALLY M E, et al. Accuracy of c-reactive protein and procalcitonin in differentiating between complicated and non-complicated acute appendicitis patients in babylon province[J]. *Medical Journal of Babylon*, 2022, 19(4): 709-713.
- [15] HUANG S, CAI N, PACHECO P P, et al. Applications of support vector machine (SVM) learning in cancer genomics[J]. *Cancer Genomics Proteomics*, 2018, 15(1): 41-51.

收稿日期: 2023-11-19; 修回日期: 2023-12-19