·论　著·

基于自动分割的影像组学特征预测乳腺癌新辅助治疗后病理学完全缓解的价值

吴林永，黎少凤，李松桦，陈　烽，魏达友

茂名市人民医院超声医学科，广东 茂名 525000

［**摘要**］ **目的：**探讨基于手工、自动、校正自动3种不同分割方法对影像组学特征稳健性的影响，并基于机器学习算法建立预测模型评估分割特征在乳腺癌新辅助治疗后病理学完全缓解（pathological complete response，pCR）中的价值。**方法：**回顾并分析2020年1月—2023年12月在茂名人民医院接受新辅助治疗的乳腺癌患者临床影像学资料。基于DeepLabv3模型实现乳腺癌超声图像的自动分割，以及在ITK-SNAP软件实现手工和校正自动分割。从3种分割方法的感兴趣区提取影像组学特征，并建立预测pCR的机器学习模型。采用组内相关系数（intraclass correlation coefficient，ICC）评估不同分割方法的特征一致性。采用受试者工作特征曲线的曲线下面积（area under the curve，AUC）评估模型的预测性能。**结果：**共纳入124例乳腺癌患者，基于患者超声图像提取1 316个特征，其中80%的自动和手工分割特征具有良好的一致性（ICC≥0.80），83%的校正自动和手工分割特征具有良好的一致性。基于自动和手工分割特征建立的机器学习模型在预测pCR的AUC差异无统计学意义。与手工和自动分割比较，基于校正自动分割特征的支持向量机模型的预测性能表现最优，验证队列的AUC达到0.80。**结论：**与手工分割相比，基于DeepLabv3深度学习模型在自动分割乳腺癌超声图像方面具有良好的一致性。并且通过手工校正自动分割的人机分割模型性能表现最优，可提高影像组学临床实践中的乳腺癌新辅助治疗pCR的诊断效率。

［**关键词**］ 乳腺癌；超声；新辅助治疗；病理学完全缓解；影像组学；图像分割；机器学习；乳腺影像报告和数据系统

中图分类号：R737.9；R445.1　**文献标志码：**A

DOI: 10.19732/j.cnki.2096-6210.2026.03.007

基金项目：茂名市科技计划项目（2024109）。

利益冲突：作者声明无利益冲突。

伦理批件：PJ2024MI-K040-01。

知情同意：豁免。

引用本文：吴林永, 黎少凤, 李松桦, 等. 基于自动分割的影像组学特征预测乳腺癌新辅助治疗后病理学完全缓解的价值［J］. 肿瘤影像学, 2026, 35(3): 393-400.

Funding: Maoming Science and Technology Plan Project (2024109).

Conflicts of interest: authors declare no conflicts of interest.

Ethical approval: PJ2024MI-K040-01.

Informed consent: exemption.

Cite this article: WU L Y, LI S F, LI S H, et al. The value of automatic segmentation radiomics features in predicting pathological complete response after neoadjuvant therapy for breast cancer［J］. Oncoradiology, 2026, 35(3): 393-400.

The value of automatic segmentation radiomics features in predicting pathological complete response after neoadjuvant therapy for breast cancer

WU Linyong, LI Shaofeng, LI Songhua, CHEN Feng, WEI　Dayou

(Department of Ultrasound, Maoming People's Hospital, Maoming 525000, Guangdong Province, China)

Correspondence to: WEI Dayou　E-mail: weidayoumm@163.com

［**Abstract**］ **Objective:** To investigate the impact of three segmentation methods (manual, automatic, and calibrated automatic) on the robustness of radiomic features, and to develop machine learning-based predictive models for evaluating the value of these segmentation-derived features in predicting pathological complete response (pCR) after neoadjuvant therapy for breast cancer. **Methods:** A retrospective analysis was conducted on clinical imaging data from breast cancer patients who received neoadjuvant therapy at Maoming People's Hospital between January 2020 and December 2023. Automatic segmentation of breast ultrasound images was achieved using the DeepLabv3 model, while manual and calibrated automatic segmentation were performed via ITK-SNAP software. Radiomic features were extracted from regions of interest delineated by the three segmentation methods. Machine learning models were developed to predict pCR. Feature consistency across different segmentation methods was evaluated using intraclass correlation coefficient (ICC). The predictive performance of the models was assessed by the area under the receiver

operating characteristic curve (AUC). **Results：** A total of 124 breast cancer patients were enrolled, and 1 316 features were extracted from ultrasound images, among which good consistency (ICC≥0.80) was observed for 80% of the automated and manual segmentation features, and for 83% of the calibrated automated and manual segmentation features. The machine learning models developed using automatic and manual segmentation features demonstrated no difference in AUC values for predicting pCR. Compared to manual and automatic segmentation, the support vector machine model based on calibrated automatic segmentation features demonstrated the best predictive performance, with an AUC of 0.80 in the validation cohort. **Conclusion：** Compared to manual segmentation, the DeepLabv3-based deep learning model demonstrates good consistency in automatically segmenting breast ultrasound images. Furthermore, adopting a human-machine segmentation approach through manual calibration of automatic segmentation can enhance model performance, thereby improving the diagnostic efficiency of radiomics in pCR to neoadjuvant therapy for breast cancer in clinical practice.

［**Key words**］Breast cancer; Ultrasound; Neoadjuvant therapy; Pathological complete response; Radiomics; Image segmentation; Machine learning; Breast Imaging Reporting and Data System

超声影像组学特征在乳腺癌患者新辅助治疗后病理学完全缓解（pathological complete response，pCR）评估中发挥着重要作用[1]。图像分割是影像组学的重要步骤，稳健的图像分割对影像组学来说是一个巨大的挑战。分割方法包括手工、半自动和全自动分割，而手工分割应用最广泛，但对乳腺癌图像整体评估不仅耗时耗力，而且存在医师间及医师内的一致性问题，即存在特征稳健性或一致性问题[2-3]，例如2名医师手工分割脂肪肉瘤的二维和三维MRI图像，以组内相关系数（intraclass correlation coefficient，ICC）评估特征的一致性，在二维和三维分割中ICC仅0.38和0.59[4]。尽管研究[5]表明，半自动分割（ICC=0.85）与手工分割（ICC=0.77）相比在特征提取中表现出更高的一致性，即使使用半自动分割，影像组学特征一致性也并不理想，因此需要追求减少耗时和准确的自动分割。随着深度学习技术的迭代更新，其在癌症病变的自动分割方面呈现出良好的应用前景，例如，基于单中心的宫颈癌阴道超声图像研究[6]比较4种深度学习自动分割和手工分割构建模型的相似性，Dice相似系数达到0.88及以上；采用自动编码器深度学习技术自动识别超声图像中的肿块型乳腺病变后，提取影像组学特征开发乳腺癌鉴别机器学习模型的曲线下面积（area under the curve，AUC）达到0.90[7]，表明自动分割可减轻人工智能临床实践的医师工作负荷，提高诊断效率，优化患者风险分层。自动分割尽管保证了客观性，但其深度学习框架技术训练熟练度、灰阶图像背景复杂性仍影响其分割效果，可通过人工干预校正以获取更稳健的分割效果。因而，本研究将探讨基于手工、自动、校正自动3种不同分割方法对影像组学特征稳健性的影响，并基于机器学习算法建立预测模型，评估分割特征在乳腺癌新辅助治疗后pCR中的临床价值。

1 资料和方法

1.1 一般资料

回顾并分析2020年1月—2023年12月在茂名市人民医院接受超声引导下穿刺活检的原发性肿块型乳腺占位性病变患者。纳入标准：① 原发性肿块型乳腺占位性病变根据声像特征评为乳腺影像报告和数据系统（Breast Imaging Reporting and Data System，BI-RADS）4类或5类；② 穿刺组织病理学检查证实为乳腺癌；③ 接受新辅助治疗，包括化疗、内分泌治疗和靶向治疗；④ 新辅助治疗后行肿瘤切除术后依据Miller&Payne（MP）分级系统评估肿瘤反应。排除标准：① 继发性肿块型乳腺占位性病变；② 双侧或多发性单侧原发性肿块型乳腺占位性病变；③ 病变太大而无法完全展示或图像质量不佳；④ MP数据缺失或临床数据严重缺乏。所有患者依据7∶3的比例以分层抽样方法分为训练队列和验证队列。

临床病理学数据来源于病历系统，包括年龄、病变大小、BI-RADS分类、机器类型、人表皮生长因子受体2（human epidermal growth factor receptor 2，HER2）、Ki-67增殖指数。

1.2 新辅助治疗后pCR评估

根据MP系统评估，肿瘤反应分为5级：1级癌细胞无减少；2级癌细胞减少≤30%；3级癌细胞减少30%~90%；4级癌细胞减少>90%；5级无浸润性癌细胞残留或可能存在导管原位癌。MP 1~4级被评估为非病理学完全缓解（non-pathological complete response，non-pCR），MP 5级被评估为pCR[8]。

1.3 图像采集和分割

参与图像采集的超声科医师均拥有3年及以上乳腺疾病诊断经验，采集图像标准为病变直径最大且清晰。使用机器类型包括深圳迈瑞生物医疗电子股份有限公司（Resona 7EXP）、美国GE公司（E6、E9、E10）和荷兰Philips公司（Affiniti70、EPIQ7C、EPIQ5、IU22）及日本佳能公司（Aplio i800、Aplio500）彩色多普勒超声诊断仪，配备高频线阵探头（L11-3U、ML9L、L12-5、L12-3），探头频率5~13 MHz，调整适当的机器参数，如增益、深度、机械指数和焦点以优化图像质量。采集的二维灰阶图像以DICOM格式保存。BI-RADS分类由1名具有5年乳腺疾病诊断经验的超声科医师独立评估以确保主观评估标准的一致性。上述二维灰阶图像导入ITK-SNAP软件中行手工图像分割。图像分割的感兴趣区（region of interest，ROI）由2名具有3年乳腺疾病诊断经验的超声科医师在同一计算机协商完成，事先对患者临床资料及超声报告情况不知情。DICOM格式图像转化为PNG格式图像，并输入DeepLabv3的深度学习分割模型中完成自动分割[9]。该模型由OnekeyAI-Platform提供，其参数由20 000张乳腺癌病变图像训练，确保在不同机器类型和复杂解剖区域下的分割性能，Dice相似系数达到0.92[10]。在自动分割基础上再次在ITK-SNAP软件中导入自动分割ROI，由1名拥有5年乳腺疾病诊断经验的超声科医师再次手工校正。基于PyRadiomics软件包（3.0版本）在手工、自动、校准自动分割ROI中分别提取1 316个影像组学特征，包括一阶特征、形状特征、灰度共生矩阵特征、灰度游程长度矩阵特征、灰度大小区域矩阵特征、灰色依赖矩阵特征和相邻灰度差矩阵[11]。ICC用于评估不同分割方法的特征一致性。

1.4 机器学习模型的建立和验证

对所有特征先采用*Z*-score方法归一化处理，并采用Wilcoxon秩和检验初次筛选在non-pCR和pCR间的差异特征。接着，差异特征经过皮尔逊相关性系数（Pearson correlation coefficient，PCC）二次筛选，2个特征相关系数大于0.75以随机方法剔除其一。然后，递归特征消除算法（recursive feature elimination，RFE）用于第三次特征筛选，对特征权重排序，以剔除冗余或非重要性特征[12]。支持向量机（support vector machine，SVM）、逻辑回归（logistic regression，LR）和低秩最小绝对收缩和选择算子（low-rank least absolute shrinkage and selection operator，LRLASSO）算法基于剩余的特征子集在5折交叉验证方法下开发pCR的预测模型。上述训练队列模型的建立过程采用SMOTE技术缓解过拟合情况的出现，以提高模型的鲁棒性[13]。

1.5 统计学处理

采用SPSS 17.0和R软件4.2.2版本进行统计学分析。符合正态分布的数据以$\bar{x} \pm s$表示，组间比较使用t检验，非正态分布的数据以M（P_{25}，P_{75}）表示，组间比较使用Wilcoxon秩和检验。分类变量以n（%）表示，组间比较采用χ^2检验。采用受试者工作特征曲线评估模型的预测性能，并计算AUC及其95% CI、准确度、灵敏度和特异度。采用单因素逻辑回归分析临床病理学或影像组学特征与pCR的风险关系，并继而基于多因素逻辑回归构建预测pCR的列线图。校准曲线和决策曲线评估模型的临床潜力。P<0.05为差异有统计学意义。

2 结　果

2.1 基线资料

共纳入124例乳腺癌患者，年龄32~82岁，年龄<60岁95例，≥60岁29例。其中BI-RADS 4A/4B类23例，4C类51例，5类50例。124例乳腺癌患者pCR率为41.13%（51/124），仅HER2表达、Ki-67增殖指数和SVM模型风险分组在non-pCR和pCR乳腺癌患者中差异有统计学意义（均P<0.01，表1，图1）。

表1 基线资料

Tab.1 Baseline characteristics

n（%）

特征	non-pCR（*n*=73）	pCR（*n*=51）	χ^2值	*P*值
年龄/岁			<0.01	0.98
<60	56（76.7）	39（76.5）		
≥60	17（23.3）	12（23.5）		
病灶大小/mm			1.86	0.17
<30	42（57.5）	23（45.1）		
≥30	31（42.5）	28（54.9）		
BI-RADS分类			0.48	0.49
4类	46（63.0）	29（56.9）		
5类	27（37.0）	22（43.1）		
机器类型			0.90	0.83
GE	28（38.4）	18（35.3）		
Philips	33（45.2）	27（52.9）		
Canon	6（8.2）	3（5.9）		
迈瑞	6（8.2）	3（5.9）		
HER2表达			49.04	<0.01
阴性	58（79.5）	8（15.7）		
阳性	15（20.5）	43（84.3）		
Ki-67增殖指数			10.39	<0.01
<50%	55（75.3）	24（47.1）		
≥50%	18（24.7）	27（52.9）		

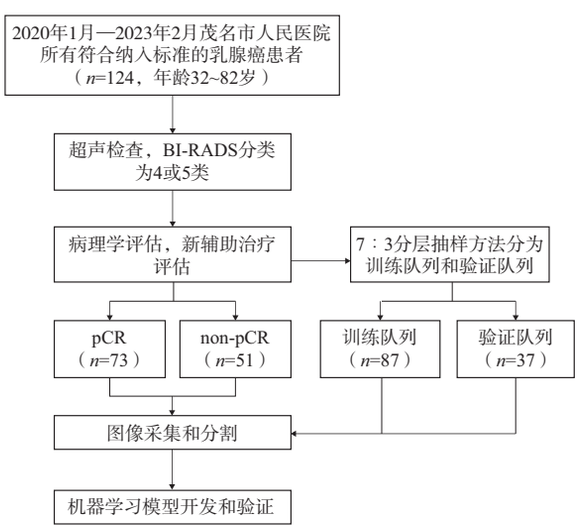


图1 研究设计流程图

Fig.1 Flow chart of study object selection

2.2 不同方法分割的特征一致性评估

在提取的1 316个影像组学特征中，80%的自动和手工分割特征具有良好的一致性（ICC≥0.80），83%的校正自动和手工分割特征具有良好的一致性（图2）。对比手工和自动分割的ROI，在形态偏规则的乳腺癌病变，自动和手工分割具有良好的边界线条一致性。在形态不规则或浅分叶的乳腺癌病变，手工分割的边界线条细节勾勒更细致，自动分割的边界线条更偏向平滑（图3）。

2.3 机器学习模型开发和验证

依据7∶3的比例，124例患者以分层抽样方法分为训练队列（*n*=87）和验证队列（*n*=37）。手工、自动和校正自动分割特征经过Wilcoxon秩和检验分别筛选出24、24和25个差异特征；上述特征经过PCC和RFE算法分别筛选出15、13和17个特征和5、7和12个特征，经过SVM、LR和LRLASSO算法开发pCR的机器学习预测模型。从AUC分析，手工和自动分割特征开发的不同算法模型在训练和验证队列中区别并不明显；但校正自动分割特征开发的SVM、LRLASSO模型比手工、自动分割模型较好，并以SVM模型在验证队列中表现最优。手工、自动和校正自动SVM模型在训练和验证队列中的AUC分别为0.72、0.71和0.75，以及0.74、0.72和0.80（表2）。124例乳腺癌患者的SVM模型评分在HER2表达（*P*<0.01）、Ki-67增殖指数（*P*=0.02）中差异有统计学意义（图4），而在其他临床病理学特征中差异无统计学意义。

在训练队列中，以中位值将SVM模型评分划分为高低风险两组，对上述具有统计学意义的特征进行单因素逻辑回归分析，发现HER2阳性表达（OR=33.33，*P*<0.01）、Ki-67增殖指数高（Ki-67≥50%，OR=5.83，*P*<0.01）和SVM模型高风险组（OR=6.56，*P*<0.01）是pCR的危险因素。对上述3个危险因素进行多因素逻辑回归分析，发现其差异均有统计学意义（*P*<0.01），并构建列线图，构建公式为列线图得分=−4.214+2.440×SVM风险分组+1.324×Ki-67增殖指数+3.979×HER2表达，最终列线图AUC为0.94（图5），验证队列以同样的公式构建列线图，AUC为0.82。校正曲线显示列线图预测和pCR效果具有良好的一致性，决策曲线显示在2%~92%阈值范围应用列线图进行风险分层具有临床实用价值（图6）。

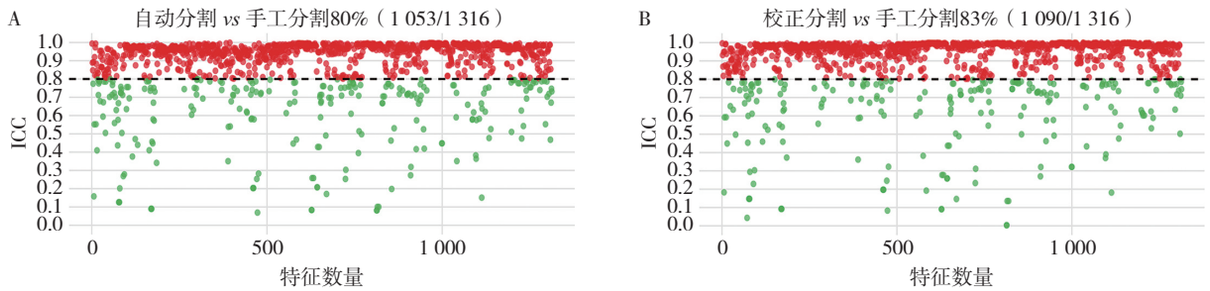


图2　不同方法分割的特征一致性评估

Fig.2　Evaluation of feature consistency in segmentation using different methods

A：自动和手工分割的1 316个特征中80%具有良好的一致性；**B**：校正自动和手工分割的1 316个特征中83%具有良好的一致性。

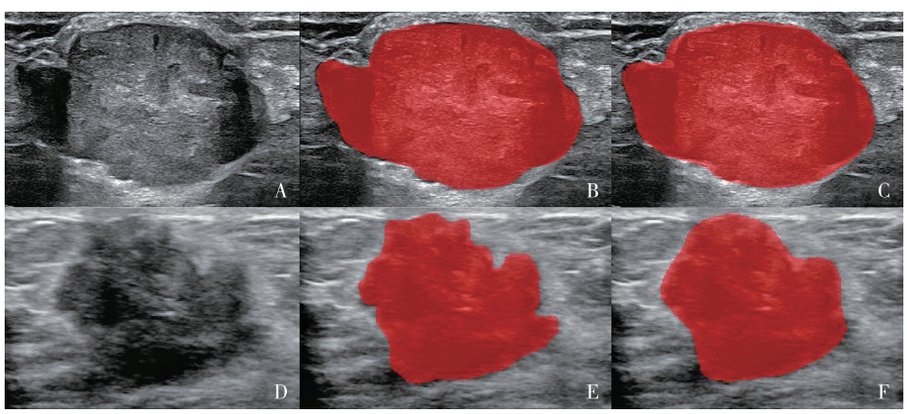


图3　自动和手工分割的ROI边界对比分析

Fig.3　Comparative analysis of ROI boundary between automatic and manual segmentation

A~C：手工（**B**）和自动（**C**）分割在形态偏规则乳腺癌病变中具有良好的边界线条一致性；**D~F**：在形态不规则或浅分叶的乳腺癌病变中，手工分割（**E**）的边界线条细节勾勒更细致，自动分割（**F**）的边界线条更偏向平滑。

表2　不同方法分割开发的机器学习模型性能汇总

Tab.2　Summary of machine learning model performance for segmentation development using different methods

队列	分割	算法	AUC（95% CI）	准确度	灵敏度	特异度
训练队列	手工	SVM	0.72（0.602~0.831）	0.68	0.81	0.59
		LR	0.71（0.597~0.827）	0.68	0.83	0.57
		LRLASSO	0.71（0.599~0.828）	0.69	0.78	0.63
	自动	SVM	0.71（0.597~0.821）	0.69	0.78	0.63
		LR	0.71（0.603~0.825）	0.71	0.83	0.63
		LRLASSO	0.70（0.585~0.810）	0.70	0.69	0.71
	校正自动	SVM	0.75（0.636~0.856）	0.71	0.78	0.67
		LR	0.73（0.625~0.844）	0.75	0.67	0.80
		LRLASSO	0.75（0.638~0.853）	0.75	0.72	0.76
验证队列	手工	SVM	0.74（0.568~0.911）	0.70	0.80	0.64
		LR	0.73（0.559~0.907）	0.70	0.80	0.64
		LRLASSO	0.73（0.550~0.904）	0.73	0.80	0.68
	自动	SVM	0.72（0.557~0.892）	0.65	0.93	0.45
		LR	0.71（0.535~0.884）	0.70	0.73	0.68
		LRLASSO	0.70（0.525~0.876）	0.73	0.67	0.77
	校正自动	SVM	0.80（0.643~0.957）	0.78	0.87	0.73
		LR	0.73（0.564~0.903）	0.76	0.80	0.73
		LRLASSO	0.75（0.580~0.911）	0.76	0.80	0.73

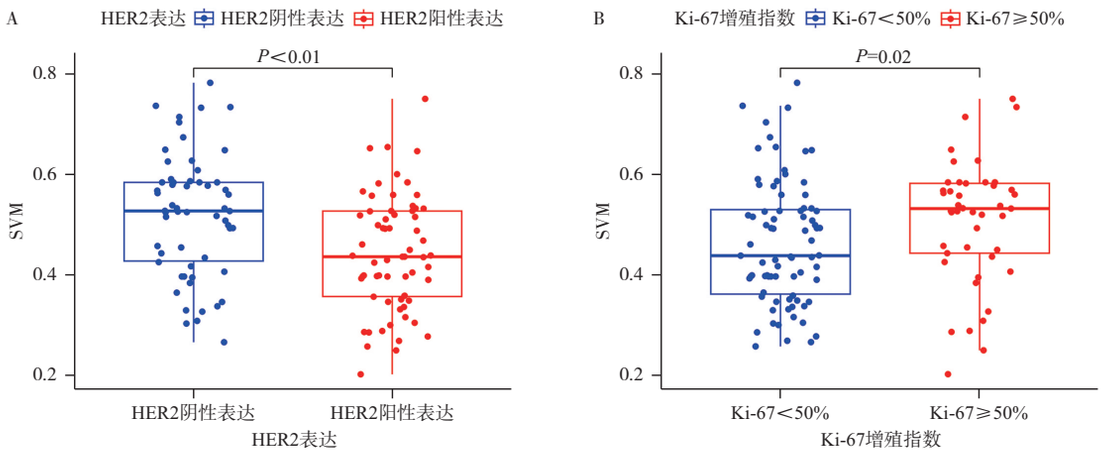


图4　SVM模型评分在HER2表达和Ki-67增殖指数的箱线图

Fig.4　Boxplots of SVM model scores in HER2 expression and Ki-67 expression

A：HER2表达；**B**：Ki-67增殖指数。

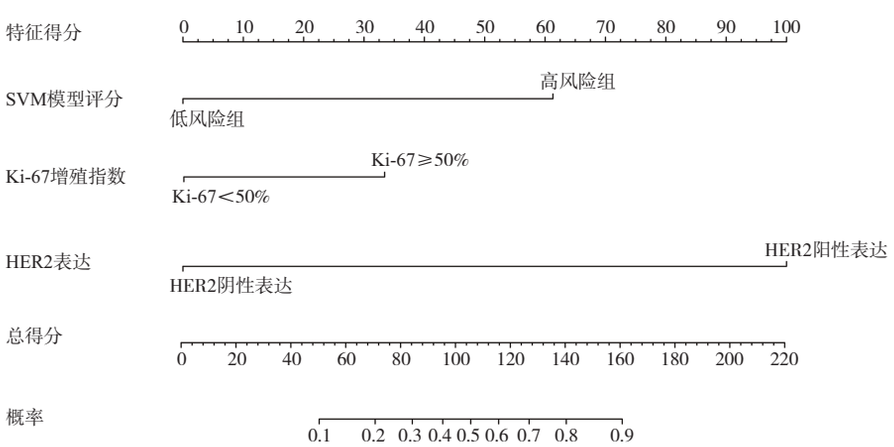


图5　预测乳腺癌新辅助治疗后pCR的列线图

Fig.5　Nomogram for predicting pCR after neoadjuvant therapy in breast cancer

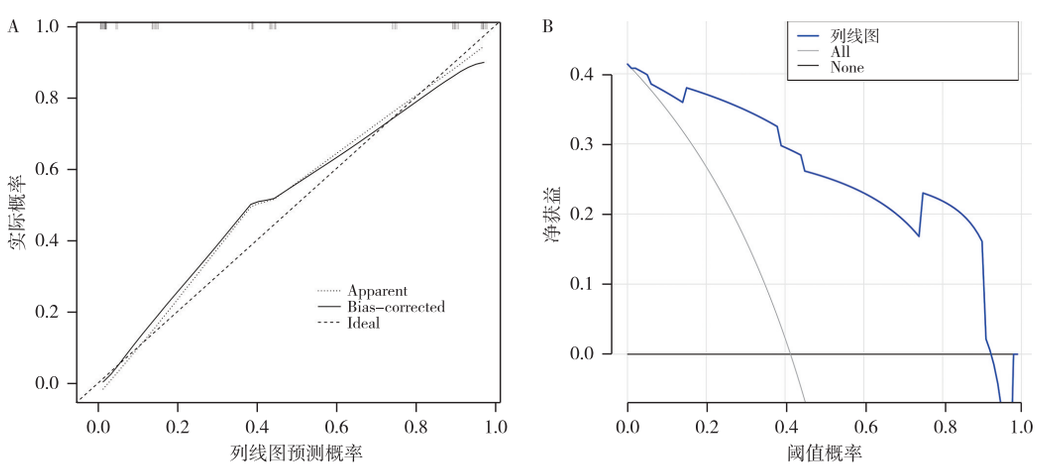


图6　列线图的校准曲线和决策曲线

Fig.6　Calibration curve and decision curve of the nomogram

A：校准曲线；**B**：决策曲线。

3 讨 论

新辅助治疗已成为乳腺癌的标准治疗手段，通过新辅助治疗可获取手术机会并评估肿瘤反应，指导临床治疗策略的选择。如何术前精准评估新辅助治疗肿瘤反应是当下临床实践的重要探索视角，而术前穿刺病理学特征和影像学特征是常见的评估手段。例如，HER2表达阳性乳腺癌患者更大概率可从新辅助治疗中获益，而不管HER2表达阳性与否，Ki-67增殖指数高与更多pCR事件相关[14-15]，与本研究分析结论一致。常规超声和超声造影是术前评估新辅助治疗效果的检查手段，通过评估残余肿瘤大小指导临床治疗策略，但残余肿瘤大小评估需要动态多次复查，增加患者的费用、耗时以及心理负担[16]。如何在肿块型乳腺病变被穿刺组织病理学检查证实为乳腺癌时即时评估该患者从新辅助治疗中获益情况将有利于确立精准治疗策略，避免由于新辅助治疗耐受而错过其他治疗机会。

常规超声特征经BI-RADS分类系统归纳，本研究中BI-RADS 4C和5类患者占比81%，有研究[17]显示BI-RADS分类在non-pCR和pCR患者评估中差异并无统计学意义，本研究也与上述发现一致。

影像组学自2012年被提出后，便逐渐呈高速发展趋势，已发展到临床实践阶段，在乳腺癌新辅助治疗后pCR评估中潜力巨大。影像组学主要流程包括图像采集、图像分割、特征提取、模型开发以及评估。图像分割效果是影响后续模型预测性能的重要因素之一，手工分割是当前主流的分割方式。为评估手工分割特征的稳健性，常采用观察者间及观察者内分割ICC进行评价。例如，一项基于CT图像提取1 037个影像组学特征的研究[18]中，经ICC评估后，690个特征在观察者间及观察者内均表现出良好的一致性（ICC>0.75）。手工分割的局限性也较为突出，医师观察具有主观性以及耗时长、超声图像质量可变性与当下临床超声高强度工作要求高效率状态相矛盾。自动分割技术也在此矛盾下飞速发展，深度学习自动分割可克服手工分割的局限性而被探索，例如经过深度学习U-net模型自动分割宫颈癌的阴道超声图像，与手工分割相比，自动分割的平均ICC为0.99，表现出良好的分割一致性[6]；在多中心MRI图像分割中，自动分割提取的特征相比于手工分割在预测晚期直肠癌患者新辅助治疗后pCR中的灵敏度更优[19]。本研究采用了深度学习DeepLabv3模型实现自动分割，即使存在斑点噪声和低对比度边界情况下也能准确疾病分割ROI，表现出卓越的分割效果[20]。本研究中，自动分割和手工分割的1 316个特征中，80%特征具有良好的一致性（ICC≥0.80），与上述结论相似。本研究另通过1名具有10年乳腺疾病诊断经验的超声科医师对比自动和手工分割效果评估，发现在形态偏规则的乳腺癌病变，自动和手工分割具有良好的边界线条一致性。在形态不规则或浅分叶的乳腺癌病变，手工分割的边界线条细节勾勒更细致，自动分割的边界线条更偏向平滑。与主观视觉不同，ICC是基于统计分析视角下，这种分割的区别是否会导致后续分析结果的差异性值得思考。本研究基于自动和手工分割特征开发的机器学习模型预测pCR的AUC差异无统计学意义，这从统计学角度发现上述手工和自动分割边界线条区别可能不影响预测性能。本研究还探索了在自动分割情况下通过手工干扰校正边界线条分割效果，结果表现为从AUC角度分析，与手工和自动分割比较，校正自动分割的SVM模型预测性能在两者队列中均有提高，验证队列更为显著。校正自动分割比手工分割同样可以减少耗时，并实现了人机分割的联动，效果令人满意。影像组学特征和临床病理学特征的联动也是探索的角度之一。本研究基于SVM模型和HER2表达、Ki-67增殖指数联合开发列线图，预测性能显著提高，AUC达到0.94。决策曲线也显示在2%~92%阈值范围应用列线图进行风险分层具有潜在的临床实用价值。

本研究的局限性：① 单中心小样本，其中训练队列样本量计算事件变量比（events per variable，EPV），对于纳入5、7和12个特征的3个模型，其EPV分别为7.2、5.1和3.0，均低于通常推荐的EPV≥10的要求，仍需多中心大样本量研究以避免过拟合情况出现，保证结果的可靠性。② 采集机器成像协议导致的图像质量差异，其差异性是否影响模型性能需进一步探索。③ 3种分割方法构建模型性能差异仅从AUC分析，并没有进行统计学显著性检

验，如DeLong检验分析。④特征由于并不像视觉特征那样具有较强的可解释性，仍需通过分子水平及功能分析验证其生物学意义。

综上所述，与手工分割相比，基于DeepLabv3深度学习模型在自动分割乳腺癌超声图像中具有良好的一致性，自动和手工分割开发的机器学习模型并无显著的性能差异。并且通过手工校正自动分割的人机分割模式可提高模型性能，可提高影像组学临床实践中的乳腺癌新辅助治疗pCR的诊断效率。

第一作者：

吴林永（ORCID: 0009-0002-6904-9294），硕士，医师。

通信作者：

魏达友（ORCID: 0000-0002-0842-054X），学士，主任医师，超声医学科主任，E-mail: weidayoumm@163.com。

作者贡献声明：

吴林永：文献调研与整理，选题，文章撰写，模型建立与测试，数据资料分析；黎少凤：数据资料收集与分析；李松桦：数据资料收集；陈烽：数据资料收集；魏达友：论文指导，审校，行政支持。

[参 考 文 献]

[1] LI Z F, LIU X R, GAO Y, et al. Ultrasound-based radiomics for early predicting response to neoadjuvant chemotherapy in patients with breast cancer: a systematic review with meta-analysis[J]. La Radiol Med, 2024, 129(6): 934-944.

[2] 郭铁旦, 王灵杰, 石彩云, 等. 颈动脉全斑块自动分割的影像组学模型对缺血性脑卒中的预测价值[J]. 中西医结合心脑血管病杂志, 2024, 22(12): 2269-2275.
GUO T D, WANG L J, SHI C Y, et al. Predictive value of imaging model of automatic segmentation of carotid artery whole plaque for ischemic stroke[J]. Chin J Integr Med Cardio Cerebrovasc Dis, 2024, 22(12): 2269-2275.

[3] SHIRI I, ARABI H, SALIMI Y, et al. COLI-Net: deep learning-assisted fully automated COVID-19 lung and infection pneumonia lesion detection and segmentation from chest computed tomography images[J]. Int J Imag Syst Technol, 2022, 32(1): 12-25.

[4] SUDJAI N, SIRIWANARANGSUN P, LEKTRAKUL N, et al. Robustness of radiomic features: two-dimensional versus three-dimensional MRI-based feature reproducibility in lipomatous soft-tissue tumors[J]. Diagnostics, 2023, 13(2): 258.

[5] PARK J E, PARK S Y, KIM H J, et al. Reproducibility and generalizability in radiomics modeling: possible strategies in radiologic and statistical perspectives[J]. Korean J Radiol, 2019, 20(7): 1124.

[6] JIN J B, ZHU H Y, TENG Y Y, et al. The accuracy and radiomics feature effects of multiple U-net-based automatic segmentation models for transvaginal ultrasound images of cervical cancer[J]. J Digit Imag, 2022, 35(4): 983-992.

[7] MAGNUSKA Z A, ROY R, PALMOWSKI M, et al. Combining radiomics and autoencoders to distinguish benign and malignant breast tumors on US images[J]. Radiology, 2024, 312(3): e232554.

[8] 张雪晶, 李红玲, 刘建新, 等. 超声剪切波弹性参数联合免疫组织化学指标对乳腺癌新辅助化疗后病灶残留的评估意义[J]. 中国超声医学杂志, 2024, 40(4): 399-404.
ZHANG X J, LI H L, LIU J X, et al. The significance of ultrasonic shear wave elasticity parameters combined with immunohistochemical indexes in the evaluation of residual lesions after neoadjuvant chemotherapy for breast cancer[J]. Chin J Ultrasound Med, 2024, 40(4): 399-404.

[9] BACHANEK S, WUERZBERG P, BIGGEMANN L, et al. Renal tumor segmentation, visualization, and segmentation confidence using ensembles of neural networks in patients undergoing surgical resection[J]. Eur Radiol, 2025, 35(4): 2147-2156.

[10] LING T, ZUO Z C, WU L C, et al. Predicting neoadjuvant chemotherapy response in locally advanced gastric cancer using a machine learning model combining radiomics and clinical biomarkers[J]. Digit Health, 2025, 11: 20552076251341740. Doi: 10.1177/20552076251341740.

[11] WANG B, HAN X M, ZHANG Z X, et al. Longitudinal CT radiomics to predict progression-free survival in patients with locally advanced gastric cancer after neoadjuvant chemotherapy[J]. Acad Radiol, 2025, 32(5): 2618-2629.

[12] LIU N J, LIU M S, TIAN W, et al. The value of machine learning based on CT radiomics in the preoperative identification of peripheral nerve invasion in colorectal cancer: a two-center study[J]. Insights Imag, 2024, 15(1): 101.

[13] XU X P, ZHANG X, TIAN Q, et al. Quantitative identification of nonmuscle-invasive and muscle-invasive bladder carcinomas: a multiparametric MRI radiomics analysis[J]. J Magn Reson Imag, 2019, 49(5): 1489-1498.

[14] CHEN X Y, HE C, HAN D D, et al. The predictive value of Ki-67 before neoadjuvant chemotherapy for breast cancer: a systematic review and meta-analysis[J]. Future Oncol, 2017, 13(9): 843-857.

[15] ANTONINI M, PANNAIN G D, MATTAR A, et al. Systematic review of nomograms used for predicting pathological complete response in early breast cancer[J]. Curr Oncol, 2023, 30(10): 9168-9180.

[16] ZHOU S C, LE J, ZHOU J, et al. The role of contrast-enhanced ultrasound in the diagnosis and pathologic response prediction in breast cancer: a meta-analysis and systematic review[J]. Clin Breast Cancer, 2020, 20(4): e490-e509.

[17] 张小雪, 张晓婷, 李 阳, 等. 乳腺癌新辅助化疗疗效及其超声BI-RADS征象[J]. 分子影像学杂志, 2022, 45(2): 235-238.
ZHANG X X, ZHANG X T, LI Y, et al. Efficacy of neoadjuvant chemotherapy in breast cancer patients and its ultrasonographic BI-RADS characteristics[J]. J Mol Imag, 2022, 45(2): 235-238.

[18] YING M L, PAN J F, LU G H, et al. Development and validation of a radiomics-based nomogram for the preoperative prediction of microsatellite instability in colorectal cancer[J]. BMC Cancer, 2022, 22(1): 524.

[19] DEFEUDIS A, MAZZETTI S, PANIC J, et al. MRI-based radiomics to predict response in locally advanced rectal cancer: comparison of manual and automatic segmentation on external validation in a multicentre study[J]. Eur Radiol Exp, 2022, 6(1): 19.

[20] WANG X F, NIE L, ZHU Q L, et al. Artificial intelligence assisted ultrasound for the non-invasive prediction of axillary lymph node metastasis in breast cancer[J]. BMC Cancer, 2024, 24(1): 910.

（收稿日期：2025-11-28 修回日期：2026-01-06）