



· 论 著 ·

# 深度学习超声组学预测乳腺癌腋窝淋巴结转移的价值

胡姣姣<sup>1, 2</sup>, 傅晓红<sup>2</sup>, 沈 燕<sup>2</sup>, 余小情<sup>2</sup>, 陈庆庆<sup>2</sup>, 胡 粟<sup>1, 3</sup>

1. 苏州大学附属第一医院放射科, 江苏 苏州 215000;
2. 上海市浦东新区公利医院超声科, 上海 200135;
3. 苏州大学影像医学研究所, 江苏 苏州 215006

[摘要] 目的: 探讨深度学习超声组学在预测乳腺癌腋窝淋巴结(axillary lymph node, ALN)转移中的应用价值。方法: 回顾并分析2021年1月—2023年12月上海市浦东新区公利医院经病理学检查证实的乳腺癌患者原发灶的超声图像, 根据ALN是否转移分为无ALN转移组和有ALN转移组。分析乳腺癌原发灶的超声特征与ALN转移的相关性, 并评估其预测ALN转移的效能。基于乳腺癌原发灶超声图像, 随机将患者按8:2分为训练集及测试集, 使用9种深度学习模型(ResNet50、EfficientNet、MobileNetV3、DenseNet121、DenseNet201、Vision Transformer、VGG16、MobileViT、Mamba Transformer)来预测ALN转移, 通过5折交叉验证, 选择效能最优的深度学习模型, 并绘制决策曲线分析图, 评估9种模型的临床净获益。分析并比较深度学习模型与超声特征预测乳腺癌ALN转移的效能差异。结果: 共纳入324例乳腺癌患者, 共计324个乳腺病灶, 其中无ALN转移组198例, 有ALN转移组126例。单因素分析结果显示, 无ALN转移组和有ALN转移组在乳腺癌原发灶的长径、形态、方位、边缘、钙化、高回声晕、毛刺征及分叶状态之间的差异均有统计学意义( $P < 0.05$ )。多因素logistic回归分析结果显示, 病灶较大、非平行生长、有高回声晕及毛刺征是乳腺癌ALN转移的独立危险因素, 四者联合诊断的受试者工作特征曲线的曲线下面积(area under curve, AUC)为0.805。9种深度学习模型中, DenseNet201效能最高, AUC分别为0.964(训练集)和0.861(测试集)。深度学习模型对ALN转移的预测效能明显优于超声特征。决策曲线分析显示, DenseNet201模型风险阈值在0.170 6到0.605 2之间时净收益明显。结论: 深度学习超声组学在术前无创评估乳腺癌ALN转移方面具有较高临床应用价值, 可为术前诊疗方案的选择提供依据。

[关键词] 乳腺癌; 腋窝淋巴结; 转移; 超声; 深度学习

中图分类号: R737.9; R445.1 文献标志码: A

DOI: 10.19732/j.cnki.2096-6210.2025.03.003

基金项目: 上海市浦东新区卫生健康委员会学科建设计划重点专科项目(PWZzk2022-18); 上海市浦东新区卫生健康委员会卫生科研项目面上项目(PW2024A-18)。

利益冲突: 所有作者声明无利益冲突。

伦理批件: [2024]研预审第(07)号。

知情同意: 有。

引用本文: 胡姣姣, 傅晓红, 沈 燕, 等. 深度学习超声组学预测乳腺癌腋窝淋巴结转移的价值[J]. 肿瘤影像学, 34(3): 208-215.

Funding: Key Specialized Project of the Health Commission of Pudong New Area, Shanghai (PWZzk2022-18); Project of Shanghai Pudong New Area Health Commission (PW2024A-18).

Conflicts of interest: authors declare no conflicts of interest.

Ethical approval: [2024] Preliminary Review No.(07).

Informed consent: available.

Cite this article: HU J J, FU X H, SHEN Y, et al. Value of deep learning ultrasound radiomics in predicting axillary lymph node metastasis of breast cancer [J]. Oncoradiology, 34(3): 208-215.

Value of deep learning ultrasound radiomics in predicting axillary lymph node metastasis of breast cancer HU Jiaojiao<sup>1,2</sup>, FU Xiaohong<sup>2</sup>, SHEN Yan<sup>2</sup>, YU Xiaoqing<sup>2</sup>, CHEN Qingqing<sup>2</sup>, HU Su<sup>1,3</sup> (1. Department of Radiology, The First Affiliated Hospital of Soochow University, Suzhou 215000, Jiangsu Province, China; 2. Department of Ultrasound, Gongli Hospital, Shanghai Pudong New Area, Shanghai 200135, China; 3. Institute of Medical Imaging, Soochow University, Suzhou 215006, Jiangsu Province, China)

Correspondence to: HU Su E-mail: husu@suda.edu.cn

[Abstract] Objective: To investigate the application value of deep learning ultrasound radiomics in predicting axillary lymph node (ALN) metastasis of breast cancer. Methods: The ultrasound images of breast cancer patients pathologically confirmed

were retrospectively analyzed in Gongli Hospital, Shanghai Pudong New Area, from January 2021 to December 2023. Based on whether ALN had metastasized, patients were divided into two groups: those without ALN metastasis and those with ALN metastasis. The research focused on correlating ultrasound characteristics of primary breast cancer lesions with ALN metastasis and evaluating their predictive efficacy. The dataset was randomly split into training and testing sets at an 8 : 2 ratio. Nine deep learning models, ResNet50, EfficientNet, MobileNetV3, DenseNet121, DenseNet201, Vision Transformer, VGG16, MobileViT, and Mamba Transformer, were used to predict ALN metastasis. Through five-fold cross-validation, the best-performing model was selected, and decision curve analysis (DCA) was conducted to assess the clinical net benefit of each model. The study also compared the predictive performance of deep learning models against traditional ultrasound features in identifying ALN metastasis in breast cancer patients. **Results:** A total of 324 breast cancer patients were included in the study, with a total of 324 breast lesions. Among them, 198 cases had no ALN metastasis, and 126 cases had ALN metastasis. Univariate analysis revealed statistically significant differences ( $P < 0.05$ ) between the non-ALN metastasis and ALN metastasis groups in terms of primary lesion characteristics, including size, shape, orientation, margin, calcification, echogenic halo, spiculation, and lobulation. Multivariate logistic regression identified larger lesion size, non-parallel orientation, presence of an echogenic halo, and spiculation as independent risk factors for ALN metastasis. The combined diagnostic performance of these four features yielded an area under curve (AUC) of 0.805. Among the nine deep learning models evaluated, DenseNet201 demonstrated the highest performance, with AUCs of 0.964 (training set) and 0.861 (testing set). The deep learning models outperformed traditional ultrasound features in predicting ALN metastasis. DCA of DenseNet model indicated a significant net benefits within a risk threshold range of 0.170 6 to 0.605 2. **Conclusion:** Deep learning ultrasound has high clinical value in non-invasive evaluation of axillary lymph node metastasis of breast cancer before surgery, and can provide a basis for the selection of preoperative diagnosis and treatment.

[ **Key words** ] Breast cancer; Axillary lymph node; Metastasis; Ultrasound; Deep learning

乳腺癌是全球女性最常见的恶性肿瘤，已成为癌症相关死亡的主要原因<sup>[1]</sup>。乳腺癌常伴发腋窝淋巴结（axillary lymph node, ALN）转移，ALN的侵袭状态不同，其临床分期和治疗方案亦不同，从而显著影响患者预后<sup>[2-3]</sup>。目前术前评估ALN的状态主要是通过淋巴结活检，该方法为有创性检查，可能会引起软组织感染、出血等并发症<sup>[4]</sup>。超声检查因具有实时、无辐射、无创等特点被广泛用于乳腺疾病的筛查。随着计算机技术的不断发展，影像组学的概念应运而生，影像组学主要通过计算机高通量识别图像的微观特征，在一定程度上弥补了因医师主观判断对疾病诊断的影响<sup>[5]</sup>。相较传统影像组学，深度学习（deep learning, DL）可对图像进行自动分割，实现智能诊断<sup>[6]</sup>。本研究旨在探讨DL超声组学在预测乳腺癌ALN转移中的临床价值。

## 1 资料和方法

### 1.1 一般资料

回顾并分析2021年1月—2023年12月就诊于上海市浦东新区公利医院的乳腺癌患者的资料。纳入标准：①术前行乳腺常规超声检查；②有

明确乳腺病灶及ALN术后病理学检查结果。排除标准：①图像不全或图像质量不佳者；②手术前有乳腺肿块及ALN的手术史或其他恶性肿瘤放疗史；③超声检查前乳腺病灶曾行有创操作或者治疗。本研究已通过医院伦理委员会审批，批件号：[2024]研预审第（07）号。

### 1.2 仪器与方法

采用荷兰Philips公司的EPIQ 5、EPIQ7超声诊断仪，使用L12-5线阵探头，频率5~12 MHz。患者取仰卧位，充分暴露双侧乳房，获取乳腺癌原发灶最大长轴切面声像图。重点观察原发灶的部位（左乳、右乳）、象限（外上象限、外下象限、内上象限、内下象限）、长径、形态（椭圆形、圆形、不规则形）、边缘（光整、不光整）、方位（平行、非平行）、内部回声（低回声、不均匀回声、高回声、囊实混合性回声）、后方回声（后方声影、混合性改变、无改变、增强）、有无钙化、有无高回声晕、有无毛刺征、分叶状态（无分叶、大分叶 $\leq 3$ 个、小分叶 $> 3$ 个）及血流情况（无血供、内部血供、内部+边缘血供、边缘血供）。由2名工作5年以上的超声科医师在双盲状态下判读超声特征，意见不一致时协商得出最后结论。

### 1.3 DL模型建立

基于最终入组数据, 随机将患者按8:2分为训练集及测试集, 建立一个用于二分类预测的DL模型。为了稳定模型性能, 充分利用数据, 降低方差, 评估模型的泛化能力, 使用5折交叉验证策略: 首先将数据集随机且均匀划分为5个子集, 之后依次选取其中4个子集作为训练数据, 用以训练模型; 而剩余的1个子集则作为测试数据, 用于验证模型的预测能力。这一过程重复进行5次, 确保每个子集都有机会被用作测试集。

使用以下神经网络架构构建基于超声图像的DL模型: ① ResNet50是包含50层的残差网络, 通过引入跳跃连接解决了深层网络的梯度消失问题。② EfficientNet采用了复合缩放策略, 能根据模型大小调整网络宽度、深度和分辨率, 实现性能与效率之间的平衡, 适合大型数据集的图像分类任务。③ MobileNetV3是一种轻量级卷积神经网络, 设计用于移动和嵌入式设备, 它引入了深度可分离卷积和反向残差结构, 可有效地降低计算复杂度和模型大小。④ DenseNet121和DenseNet201两者分别具有121层和201层的深度卷积网络结构, 每一层的输出都作为之后所有层的输入, 可实现每一层都与后续层的密集连接。⑤ Vision Transformer是基于自注意力机制的模型, 它将图像分割成固定大小的块, 并直接将这些块作为序列输入到Transformer模型中处理, 实现了对图像全局依赖关系的有效捕捉。⑥ VGG 16是一种经典的卷积神经网络, 包括16个卷积层, 采用小卷积核(3×3)和较深的网络结构, 结构简单, 易于理解和实现。⑦ MobileViT是一种结合了卷积和自注意力机制的轻量级视觉Transformer, 旨在实现高效且准确的图像处理。⑧ MambaTransformer是一种结合卷积网络和Transformer机制的混合架构, 旨在实现局部特征提取和全局信息建模的平衡。

### 1.4 统计学处理

采用SPSS 26.0软件进行数据分析。单因素分析中, 计数资料以 $n(\%)$ 表示, 采用 $\chi^2$ 检验或Fisher精确概率检验; 符合正态分布的计量资料

以 $\bar{x} \pm s$ 表示, 采用独立样本 $t$ 检验, 非正态分布以 $M(P_{25}, P_{75})$ 表示, 采用Mann-Whitney  $U$ 检验。多因素分析中, 使用logistic回归分析筛选乳腺癌ALN转移的危险因素, 绘制受试者工作特征(receiver operating characteristic, ROC)曲线, 计算曲线下面积(area under curve, AUC)。使用软件Python 3.11.5进行DL模型建立, 绘制9种模型的ROC曲线, 得出AUC、准确度、灵敏度及特异度, 比较各模型效能, 并绘制决策曲线分析(decision curve analysis, DCA)图, 评估9种模型的临床净获益。 $P < 0.05$ 为差异有统计学意义。

## 2 结 果

### 2.1 病理学检查结果

研究共纳入324例乳腺癌患者, 共计324个乳腺病灶, 年龄27~93岁, 平均年龄( $62.2 \pm 13.0$ )岁。根据术后病理学检查结果分为无ALN转移组198例, 有ALN转移组126例(图1)。198例无ALN转移组病理学类型: 浸润性导管癌122例, 小叶癌2例, 黏液癌15例, 导管内乳头状癌20例, 导管内癌29例, 髓样癌4例, 混合癌6例; 126例有ALN转移组病理学类型: 浸润性导管癌113例, 髓样癌2例, 混合癌3例, 导管内癌1例, 小叶癌5例, 黏液癌1例, 腺癌1例。

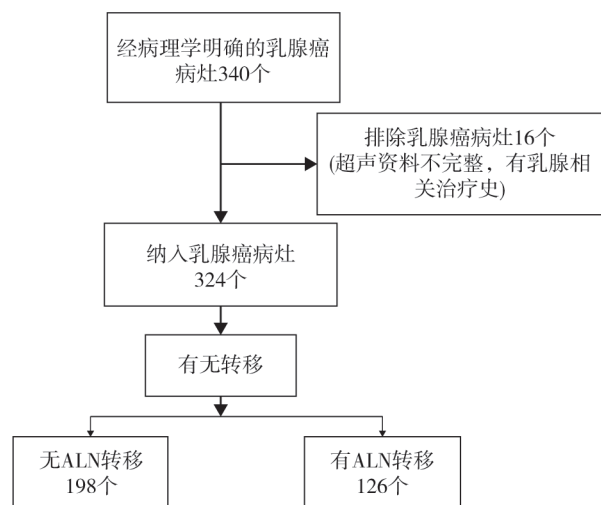


图1 研究对象纳入流程图

Fig.1 Research subject inclusion flowchart

2.2 单因素及多因素logistic回归分析结果

单因素分析结果显示，有ALN转移组，乳腺癌原发灶多表现为病灶较大、非平行生长、形态不规则、边缘不光整、有钙化、有高回声晕、有毛刺征及多呈小分叶状态

(表1, 图2)。

多因素logistic回归分析结果显示，病灶较大、非平行生长、有高回声晕及毛刺征是乳腺癌ALN转移的独立危险因素(表2)，四者联合诊断的AUC为0.805(表3, 图3)。

表1 常规超声预测乳腺癌ALN转移的单因素分析

Tab.1 Single factor analysis of routine ultrasound prediction of ALN metastasis in breast cancer

项目	无ALN转移组 (n=198)	有ALN转移组 (n=126)	Z/ $\chi^2$	P值	n (%)
年龄/岁	64 (51.75, 72.00)	62 (54.00, 69.25)	Z=-0.829	0.407	
病灶长径/mm	19 (14.75, 25.00)	25 (18.00, 33.25)	Z=4.733	<0.001	
部位			$\chi^2=0.010$	1.000	
右乳	97 (49.0)	61 (48.4)			
左乳	101 (51.0)	65 (51.6)			
象限			$\chi^2=2.728$	0.435	
外上象限	102 (51.5)	75 (59.5)			
外下象限	29 (14.7)	19 (15.1)			
内上象限	47 (23.7)	22 (17.5)			
内下象限	20 (10.1)	10 (7.9)			
形态			—	0.001	
椭圆形	27 (13.6)	6 (4.8)			
圆形	8 (4.0)	0 (0)			
不规则形	163 (82.3)	120 (95.2)			
方位			$\chi^2=14.874$	<0.001	
平行	122 (61.6)	50 (39.7)			
非平行	76 (38.4)	76 (60.3)			
边缘			$\chi^2=18.327$	<0.001	
光整	47 (23.7)	7 (5.6)			
不光整	151 (76.3)	119 (94.4)			
内部回声			—	0.218	
低回声	163 (82.3)	108 (85.7)			
不均匀回声	14 (7.1)	12 (9.5)			
高回声	1 (0.5)	0 (0)			
囊实混合性回声	20 (10.1)	6 (4.8)			
后方回声			—	0.063	
后方声影	20 (10.1)	22 (17.5)			
混合改变	7 (3.5)	4 (3.2)			
无改变	146 (73.8)	93 (73.8)			
增强	25 (12.6)	7 (5.5)			
钙化			$\chi^2=8.090$	0.005	
无	129 (65.2)	62 (49.2)			
有	69 (34.8)	64 (50.8)			
血流状态			—	0.072	
无血供	57 (28.8)	22 (17.5)			
内部血供	118 (59.6)	90 (71.4)			
边缘+内部血供	16 (8.1)	12 (9.5)			
边缘血供	7 (3.5)	2 (1.6)			
高回声晕			$\chi^2=23.241$	<0.001	
无	114 (57.6)	38 (30.2)			
有	84 (42.4)	88 (69.8)			
毛刺征			$\chi^2=34.951$	<0.001	
无	131 (66.2)	41 (32.5)			
有	67 (33.8)	85 (67.5)			
分叶			$\chi^2=29.169$	<0.001	
无分叶	43 (21.7)	10 (7.9)			
大分叶 (≤3个)	64 (32.3)	20 (15.9)			
小分叶 (>3个)	91 (46.0)	96 (76.2)			

表中年龄、病灶长径数值以M (P<sub>25</sub>, P<sub>75</sub>)表示; “—”为Fisher精确概率检验。




图2 乳腺癌超声图像

Fig.2 Ultrasound images of breast cancer

A: 乳腺癌无ALN转移的常规超声显示肿瘤较小, 平行生长, 边缘光整, 形态不规则; B: 乳腺癌有ALN转移的常规超声显示肿瘤较大, 非平行生长, 边缘不光整, 形态不规则, 有毛刺征及呈小分叶状态。

表2 常规超声预测乳腺癌ALN转移的多因素logistic回归分析

**Tab.2 Multivariate logistic regression analysis of conventional ultrasound in predicting ALN metastasis of breast cancer**

参数	B	标准误	Wald	P值	OR	95% CI
病灶长径	0.050	0.011	19.305	<0.001	1.052	1.028~1.076
方位	0.569	0.282	4.069	0.044	1.766	1.016~3.069
高回声晕	0.909	0.279	10.589	0.001	2.482	1.435~4.290
毛刺征	1.111	0.292	14.423	<0.000	3.036	1.712~5.385

表3 各危险因素对乳腺癌ALN转移的诊断价值

**Tab.3 Diagnostic value of risk factors for ALN metastasis of breast cancer**

参数	AUC	标准误	P值	95% CI
病灶长径	0.656	0.031	<0.001	0.595~0.716
方位	0.610	0.032	0.001	0.547~0.673
高回声晕	0.637	0.031	<0.001	0.575~0.699
毛刺征	0.668	0.031	<0.001	0.607~0.729
联合诊断	0.805	0.024	<0.001	0.758~0.852




图3 各危险因素诊断乳腺癌患者ALN转移的ROC曲线

Fig.3 ROC curves of various risk factors for diagnosing ALN metastasis in breast cancer patients

### 2.3 不同DL模型结果比较

9种DL模型中, DenseNet201的AUC最高, 训练集为0.964、测试集为0.861, 且该模型的灵敏度和特异度也较高, 表明该模型在预测乳腺癌ALN转移效能最佳(表4), 并绘制DCA图, 评估9种模型的临床净收益(图4)。DenseNet201模型在风险阈值0.170 6到0.605 2之间总体上高于“None”及“All”线, 净收益明显。其曲线形状较为平稳, 没有大幅波动。该模型在中等阈值下的表现尤为突出, 表明它在适当的决策点上能够带来更高的净收益。

### 2.4 超声特征与DL模型预测乳腺癌ALN转移的效能比较

本研究DL的9种模型中, ResNet50、DenseNet121、DenseNet201、Mamba Transformer这4种模型的训练集及测试集的AUC分别为(0.951、0.955、0.964、0.872及0.837、

表4 DL模型性能参数比较

Tab. 4 Comparison of performance parameters of deep learning models

模型	数据集	AUC	95% CI	准确度	灵敏度	特异度
ResNet50	训练集	0.951	0.822~0.906	0.864	0.833	0.814
	测试集	0.837	0.633~0.869	0.766	0.720	0.720
EfficientNet	训练集	0.591	0.575~0.639	0.634	0.587	0.526
	测试集	0.561	0.481~0.719	0.600	0.632	0.500
MobileNetV3	训练集	0.759	0.692~0.798	0.745	0.699	0.619
	测试集	0.722	0.625~0.841	0.733	0.737	0.637
DenseNet121	训练集	0.955	0.906~0.966	0.936	0.927	0.907
	测试集	0.856	0.664~0.870	0.767	0.842	0.739
DenseNet201	训练集	0.964	0.910~0.968	0.939	0.934	0.914
	测试集	0.861	0.627~0.841	0.734	0.785	0.712
Vision Transformer	训练集	0.689	0.634~0.746	0.690	0.693	0.697
	测试集	0.655	0.559~0.787	0.673	0.682	0.682
VGG16	训练集	0.634	0.618~0.732	0.675	0.700	0.658
	测试集	0.617	0.516~0.750	0.633	0.694	0.500
MobileViT	训练集	0.850	0.733~0.833	0.783	0.833	0.853
	测试集	0.753	0.600~0.820	0.710	0.865	0.865
Mamba Transformer	训练集	0.872	0.762~0.858	0.810	0.931	0.931
	测试集	0.842	0.697~0.893	0.795	0.947	0.947

0.856、0.861、0.842），均高于超声特征多因素logistic回归分析中联合预测ALN转移的AUC（0.805）。且9种模型中DenseNet201效能最佳，AUC最高，训练集为0.964、测试集为0.861，说明DL模型可在一定程度上提高术前诊断乳腺癌ALN转移的准确度，具有一定的临床应用价值。




图4 DCA图

Fig.4 Decision curve analysis graph

### 3 讨 论

乳腺癌是一种女性常见的恶性肿瘤，具有高

度异质性<sup>[7]</sup>。大量的临床资料证实，乳腺癌患者的预后与ALN是否转移密切相关<sup>[8]</sup>。尽管术前利用超声观察ALN有许多优点，但医学界尚未制定将ALN划分为良性或恶性的统一标准<sup>[9]</sup>。有些国内外学者通过乳腺癌原发灶的超声特征来间接预测ALN转移，但同样存在不同的超声科医师对结果判读差异较大的问题。随着人工智能的不断发展，DL方法逐渐被应用于预测乳腺癌ALN转移。DL避免了复杂的特征提取过程，并且可以从图像中获取更丰富的信息，近年来在医学图像研究中得到了广泛的应用<sup>[10]</sup>。本文探讨乳腺癌原发灶的超声特征与DL方法预测ALN转移的准确度差异，旨在为术前无创评估乳腺癌ALN有无转移提供一种更精准的方法。

乳腺癌在发生ALN转移的过程中，其原发灶的形态学特征亦会发生改变，超声可以对此改变进行评估。本研究发现乳腺癌原发灶肿块较大、非平行生长、有高回声晕及毛刺征是乳腺癌ALN转移的独立危险因素。有研究<sup>[11]</sup>表明，随着肿瘤原发病灶增大，癌细胞的侵袭能力增强，促使癌细胞沿淋巴结转移至腋窝，诱发ALN转移，本研究与此结果相符。许多学者认可乳腺癌肿块大

小与ALN转移之间存在相关性,但是对于肿块长度的界值尚无一致意见,本研究得出的最佳截断值为25.5 mm(灵敏度48.4%,特异度76.8%),但灵敏度不高,并不适合临床推广。非平行生长被认为是乳腺肿块的恶性征象之一,但据此能否预测ALN的转移仍存在争议。Zhang等<sup>[12]</sup>的研究认为,非平行生长与ALN转移有关;向永涛等<sup>[13]</sup>则认为非平行生长与ALN转移无相关性;本研究观察到非平行生长的乳腺癌肿块更易发生ALN转移,与前者相符,但其能否预测ALN转移尚需进一步研究确认。在病理学上,高回声晕反映肿瘤实质部分向周围组织浸润形成的不同程度的瘤周水肿<sup>[14]</sup>。本研究提示高回声晕为乳腺癌ALN转移的独立危险因素,亦证实该征象的出现高度提示肿瘤扩散转移的可能。肿块的边缘呈蟹足状或有毛刺征,提示肿瘤细胞对淋巴管的高度侵袭性<sup>[15]</sup>,本研究结果显示有毛刺征的肿块更易发生ALN转移,结果与之相符。肿块较大、非平行生长、有高回声晕及毛刺征这4种超声特征联合诊断的AUC为0.805。尽管这四者联合对乳腺癌ALN转移有较好的预测价值,但超声检查过度依赖操作医师的主观判断,不同资历的医师,对结果的判读有较大的差异。故本研究应用DL超声组学来预测乳腺癌ALN转移,在一定程度上可以减少因操作医师主观判读对结果的影响。

与传统的机器学习相比,DL可以对图像本身进行自学,无需人工勾画图像,因此学习过程更加高效、精准<sup>[16]</sup>。Zhou等<sup>[17]</sup>使用DL方法,采用3种不同的卷积神经网络,分别为Inception ResNet V2、Inception V3和ResNet-101,在数据集上进行了训练,并且从灵敏度、特异度、准确度、AUC等方面分析了模型的性能,其中Inception V3模型的AUC达到0.89,灵敏度为85%,特异度为73%;此结果说明基于乳腺癌原发肿块的超声图像建立的DL模型,有较高的ALN转移预测价值。Zheng等<sup>[18]</sup>基于584例乳腺癌原发灶肿块的常规超声及剪切波弹性图像,建立DL联合临床参数的模型,结果显示该模型有较强的预测ALN转移的能力。本研究使用9种神经网络对数据集进行训练,其中DenseNet201的

AUC最高,训练集为0.964、测试集为0.861,其在风险阈值0.170 6到0.605 2之间净收益明显。DenseNet通过密集连接结构使得网络更加紧凑,并且在浅层特征和深层特征之间共享信息,其参数量小,能更好地利用特征传递和梯度流动,在一定程度上提升了模型的准确度和效率。本研究使用的9种DL模型中,ResNet50、DenseNet121、DenseNet201、Mamba Transformer这4种模型的训练集及测试集的AUC均高于超声特征多因素logistic回归联合预测的AUC,进一步说明DL超声组学在一定程度上可提高术前无创评估乳腺癌ALN转移的诊断准确度。但9种模型中,EfficientNet、MobileNetV3、Vision Transformer、VGG16、MobileViT这5种模型预测ALN转移的效能不佳,可能与以下因素相关:① EfficientNet虽然通过复合缩放策略优化了计算效率,但它主要基于卷积层,在全局特征捕捉方面仍然受限;② MobileNetV3和MobileViT作为轻量级模型,在移动设备上运行时具备高效性,但在处理大规模图像数据时的表现可能不如Mamba Transformer,尤其是在捕捉复杂图像的全局关系时;③ Vision Transformer完全摒弃了卷积操作,专注于全局信息捕捉,但缺乏局部特征的高效提取,尤其在处理小规模数据集时表现一般;④ VGG16结构简单,易于理解和实现,但相比ResNet,VGG16没有使用残差连接,因此网络更深时容易出现梯度消失问题。

综上,DL超声组学在预测乳腺癌ALN转移方面具有较好的临床应用价值。但本研究仍存在一定的不足:① 本研究只基于乳腺癌的常规超声图像进行了分析,未将其与剪切波弹性成像及超声造影等超声新技术进行联合诊断;② 本研究为回顾性的研究,可能存在入选患者选择偏倚问题;③ 本研究为单中心的研究,未引入外部验证,后期我们将继续扩大样本量,引入多中心数据进行验证。

第一作者:

胡姣姣(ORCID: 0009-0000-4485-556X),本科,主治医师。

通信作者:

胡粟(ORCID: 0009-0009-5361-1706),博士,副主任医师, E-mail: husu@suda.edu.cn。

## 作者贡献声明:

胡姣姣: 数据收集, 数据统计分析, 文章撰写; 傅晓红: 论文框架设计; 沈燕: 数据收集及分析; 余小倩: 数据资料收集及分析; 陈庆庆: 数据资料收集及整理; 胡粟: 选题及设计研究方案, 审校。

## [参 考 文 献]

- [ 1 ] SUNG H, FERLAY J, SIEGEL R L, 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.
- [ 2 ] ALLEMANI C, MATSUDA T, DI CARLO V, et al. Global surveillance of trends in cancer survival 2000–14 (CONCORD-3): analysis of individual records for 37 513 025 patients diagnosed with one of 18 cancers from 322 population-based registries in 71 countries [ J ] . Lancet, 2018, 391(10125): 1023–1075.
- [ 3 ] CHANG J M, LEUNG J W T, MOY L, et al. Axillary nodal evaluation in breast cancer: state of the art [ J ] . Radiology, 2020, 295(3): 500–515.
- [ 4 ] LYMAN G H, TEMIN S, EDGE S B, et al. Sentinel lymph node biopsy for patients with early-stage breast cancer: American Society of Clinical Oncology clinical practice guideline update [ J ] . J Clin Oncol, 2014, 32(13): 1365–1383.
- [ 5 ] KANN B H, HOSNY A, AERTS H J W L. Artificial intelligence for clinical oncology [ J ] . Cancer Cell, 2021, 39(7): 916–927.
- [ 6 ] SPUHLER K D, DING J, LIU C L, et al. Task-based assessment of a convolutional neural network for segmenting breast lesions for radiomic analysis [ J ] . Magn Reson Med, 2019, 82(2): 786–795.
- [ 7 ] SIEGEL R L, MILLER K D, WAGLE N S, et al. Cancer statistics, 2023 [ J ] . CA Cancer J Clin, 2023, 73(1): 17–48.
- [ 8 ] WANG S Q, WANG D M, WEN X, et al. Construction and validation of a nomogram prediction model for axillary lymph node metastasis of cT1 invasive breast cancer [ J ] . Eur J Cancer Prev, 2024, 33(4): 309–320.
- [ 9 ] TAHMASEBI A, QU E Z, SEVRUKOV A, et al. Assessment of axillary lymph nodes for metastasis on ultrasound using artificial intelligence [ J ] . Ultrason Imaging, 2021, 43(6): 329–336.
- [ 10 ] SALEH G A, BATOUTY N M, GAMAL A, et al. Impact of imaging biomarkers and AI on breast cancer management: a brief review [ J ] . Cancers (Basel), 2023, 15(21): 5216.
- [ 11 ] 李 盼, 王云月, 阮骊韬. 乳腺癌患者临床病理及超声特征与同侧腋窝淋巴结转移的关系 [ J ] . 实用肿瘤杂志, 2022, 37(5): 418–423.
- LI P, WANG Y Y, RUAN L T. Correlation between clinicopathological and ultrasound characteristics and ipsilateral axillary lymph node metastasis in breast cancer patients [ J ] . J Pract Oncol, 2022, 37(5): 418–423.
- [ 12 ] ZHANG H, SUI X F, ZHOU S Z, et al. Correlation of conventional ultrasound characteristics of breast tumors with axillary lymph node metastasis and Ki-67 expression in patients with breast cancer [ J ] . J Ultrasound Med, 2019, 38(7): 1833–1840.
- [ 13 ] 向永涛, 甘 兵, 赵 亮. 乳腺癌原发灶超声特征与腋窝淋巴结转移的关系 [ J ] . 中国免疫学杂志, 2019, 35(10): 1251–1254.
- XIANG Y T, GAN B, ZHAO L. Relationship between ultrasonographic features of primary breast cancer and axillary lymph node metastasis [ J ] . Chin J Immunol, 2019, 35(10): 1251–1254.
- [ 14 ] DURMUS T, STÖCKEL J, SLOWINSKI T, et al. The hyperechoic zone around breast lesions – an indirect parameter of malignancy [ J ] . Ultraschall Med, 2014, 35(6): 547–553.
- [ 15 ] 袁 瑶, 周显礼. 乳腺癌超声特征与腋窝淋巴结转移相关性的研究进展 [ J ] . 实用肿瘤学杂志, 2020, 34(6): 576–580.
- YUAN Y, ZHOU X L. Research progress on the correlation between ultrasound features and axillary lymph node metastasis in breast cancer [ J ] . Pract Oncol J, 2020, 34(6): 576–580.
- [ 16 ] ERICKSON B J. Basic artificial intelligence techniques: Machine learning and deep learning [ J ] . Radiol Clin North Am, 2021, 59(6): 933–940.
- [ 17 ] ZHOU L Q, WU X L, HUANG S Y, et al. Lymph node metastasis prediction from primary breast cancer US images using deep learning [ J ] . Radiology, 2020, 294(1): 19–28.
- [ 18 ] ZHENG X Y, YAO Z, HUANG Y N, et al. Deep learning radiomics can predict axillary lymph node status in early-stage breast cancer [ J ] . Nat Commun, 2020, 11(1): 1236.

(收稿日期: 2025-03-03 修回日期: 2025-03-27)