

# 基于深度学习的超声影像组学在乳腺癌中的研究进展

陈余,荆慧

(哈尔滨医科大学附属肿瘤医院,黑龙江 哈尔滨 150081)

**摘要:** 基于深度学习的影像组学(deep learning radiomics, DLR)通过不同构架从医学图像中提取深层特征,并将提取出的深层特征进一步分析,辅助临床决策。相比传统影像组学,DLR能够自动地提取深层特征,不依赖于医师人工标注,进一步提高其在肿瘤诊断及预测预后中的准确性和可靠性。超声检查是乳腺癌早期诊断的主要方式。全文分析近几年基于超声的 DLR 在乳腺肿物良恶性的鉴别诊断、乳腺癌分子分型的预测、腋窝淋巴结状态评估、新辅助化疗疗效评估中的研究现状。

**主题词:** 超声影像组学;深度学习;乳腺癌

中图分类号:R737.9 文献标识码:A 文章编号:1671-170X(2022)09-0730-06

doi:10.11735/j.issn.1671-170X.2022.09.B005

## Advances in Application of Ultrasound-based Deep Learning Radiomics in Breast Cancer

CHEN Yu, JING Hui

(Harbin Medical University Cancer Hospital, Harbin 150081, China)

**Abstract:** Deep learning radiomics(DLR) extracts high-level features from medical images through different frameworks, and further analyzes the extracted high-level features to assist clinical decision-making. Compared with traditional radiomics, DLR can automatically extract high-level features without relying on manual annotation by physicians, further improving accuracy and reliability in tumor diagnosis and prognosis. Ultrasonography is the main way of early diagnosis of breast cancer. This article reviews the research progress of ultrasound-based DLR in the differential diagnosis of benign and malignant breast tumors, the prediction of breast cancer molecular typing, the assessment of axillary lymph node status, and the evaluation of neoadjuvant chemotherapy efficacy.

**Subject words:** ultrasound-based radiomics; deep learning; breast cancer

在乳腺癌患者管理中,早期诊断和预测治疗反应及预后至关重要。影像组学从医疗图像中提取定量特征,并进行数据挖掘、模型构建,在疾病诊断、预测、预后方面广泛应用<sup>[1]</sup>。近年来,深度学习的飞速进步推动基于深度学习的影像组学(deep learning radiomics, DLR)的不断发展。

## 1 影像组学

影像组学是个新兴领域,其核心是从标准医疗图像(CT、MRI、PET-CT、超声等)中提取高通量特征,并建立将图像特征与临床结果相关联的预测模型,用于临床决策支持,提供有益的诊断、预测、预后信息<sup>[1]</sup>。肿瘤研究中,影像组学方法常用于 CT<sup>[2-3]</sup>、

MRI<sup>[4-5]</sup>。近年来,基于超声图像的影像组学分析也显示出较好的性能<sup>[6]</sup>。目前,超声影像组学广泛用于各类疾病的良恶性鉴别<sup>[7]</sup>、淋巴结状态评估<sup>[8]</sup>、新辅助化疗疗效评估<sup>[9]</sup>、生存预测<sup>[10]</sup>、癌症分期<sup>[11]</sup>等方面。

影像组学的工作步骤(Figure 1)包括<sup>[12]</sup>:(1)标准图像获取,包含 CT、MRI、PET-CT、超声等;(2)确定感兴趣区域并进行感兴趣区域(region of interest, ROI)分割;(3)特征提取;(4)特征筛选;(5)特征分析、模型构建,包括模型验证,独立的、外部的、经过验证的模型比内部验证的模型更可信;受试者工作特征(receiver operating characteristic, ROC)曲线是评估所提出模型性能的最常用方法。

特征提取是影像组学中的关键环节,提取的不同类型特征,通常可以分为三大类<sup>[13-14]</sup>:(1)一阶特征(基于强度和基于形状的特征):基于强度特征描述单个体素值的分布,而不考虑空间关系,将 ROI

基金项目:国家自然科学基金(82171953,81801709)

通信作者:荆慧,E-mail:jinghuihrb@163.com

收稿日期:2022-06-29;修回日期:2022-08-17

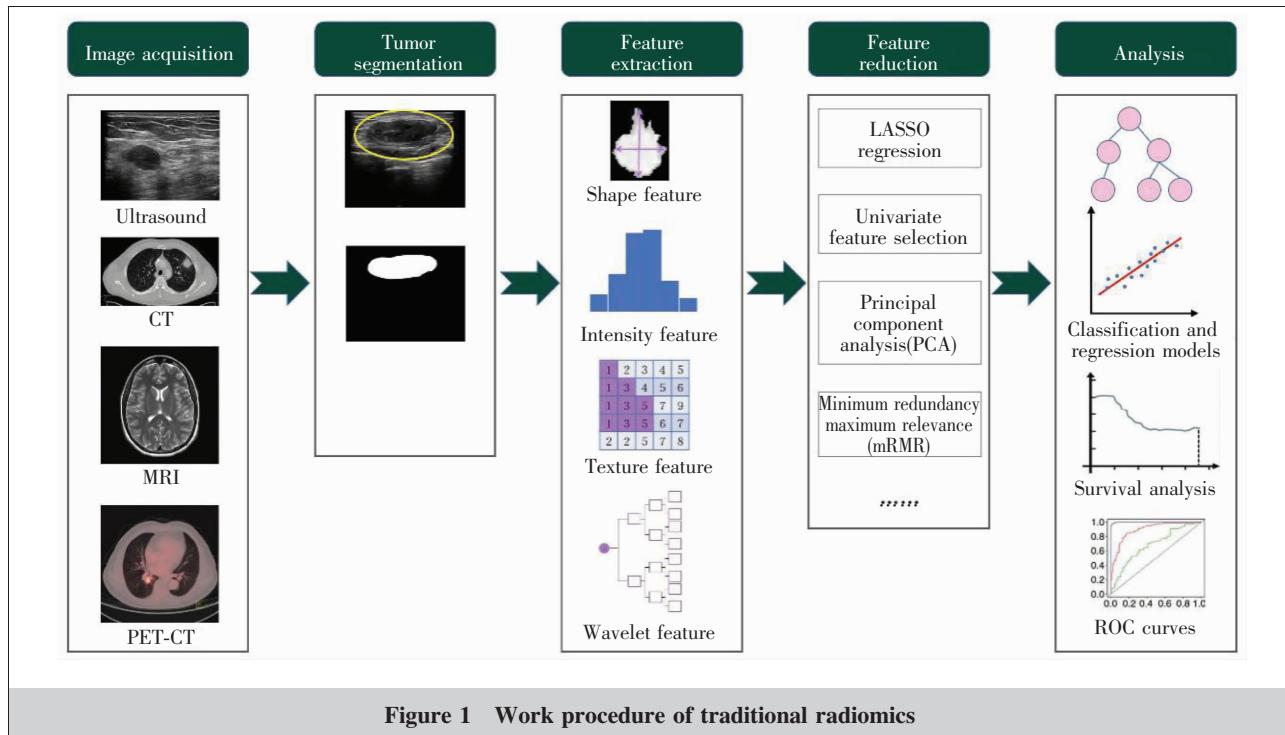


Figure 1 Work procedure of traditional radiomics

转换为描述像素强度分布的直方图,从中导出能量、熵、峰态和偏度等基本特征;基于形状特征描述ROI的几何形状,包括体积、表面、球形度、紧密度、直径等。(2)二阶特征(基于纹理的特征):描述相邻像素之间的空间关系。纹理特征提取通常是基于不同的矩阵实现,最常用的是灰度共生矩阵(gray-level cooccurrence matrix, GLCM)。(3)高阶特征:对图像应用过滤器或数学变换后获得,常见的有基于小波、傅立叶变化等。

虽然传统影像组学提取的特征数量可以达到数以万计,但这些特征都是低层图像特征。低层图像特征可能无法完全表现图像异质性,从而限制影像组学模型的潜力<sup>[15]</sup>。另一方面,传统的影像组学特征为预先设定(又称手工特征),是根据放射科医生的专业知识选择的,受医学成像技术发展及医生经验限制<sup>[16]</sup>。因此,如何提取能提高影像组学模型性能的深层特征成为当前研究热点。

## 2 基于深度学习的影像组学

深度学习是机器学习的一大分支,其在计算机视觉、图像识别任务上的独特优势推动深度学习和影像组学的融合发展。深度学习的概念源于人工神经网络的研究,其基本构架与神经网络的分层结构相

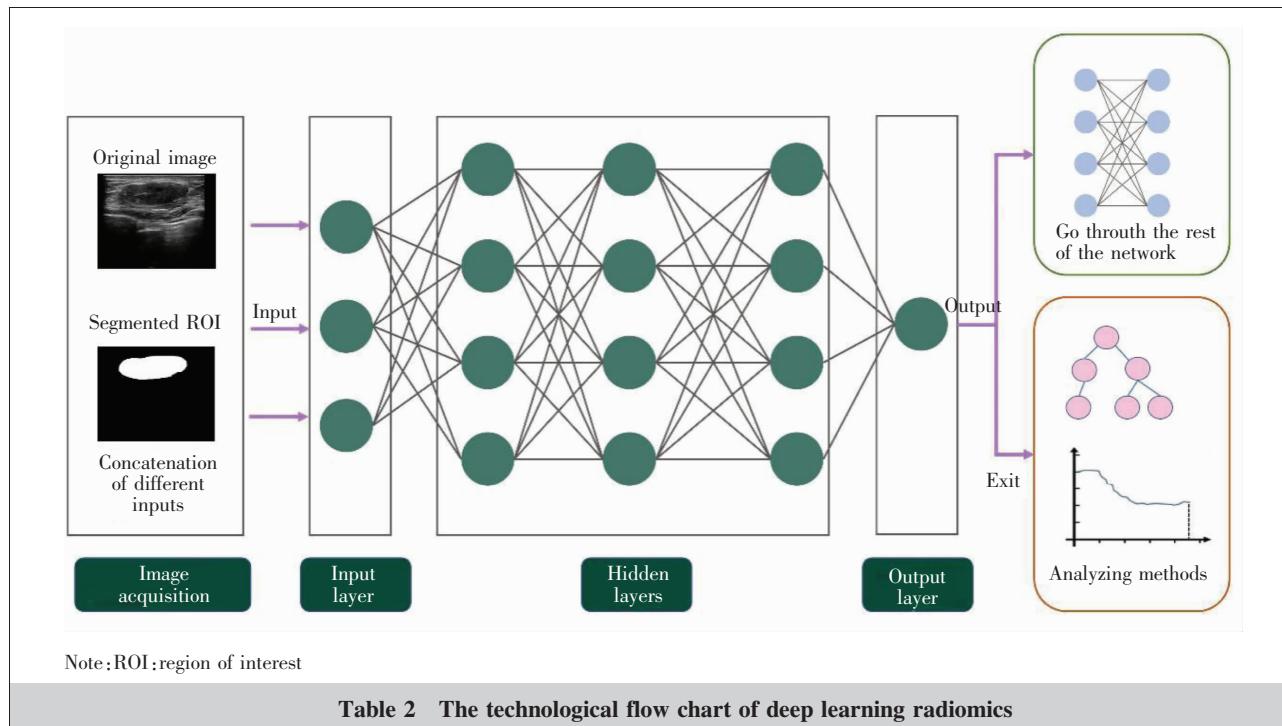
似,由输入层、隐层(多层)、输出层组成多层网络<sup>[17]</sup>。目前,深度学习广泛用于影像组学的特征提取阶段。DLR是按照预定义任务通过不同构架从医学图像中提取深层特征的过程<sup>[18]</sup>,提取出的深层特征进一步分析(通过深度网络的其余部分进行分析和决策或退出网络通过其他的分析器)辅助决策<sup>[14]</sup>(Figure 2)。卷积神经网络(convolutional neural networks, CNN)是目前最常用的深度学习构架。

与传统的影像组学特征提取不同,DLR不需要任何先验知识,并且可以完全自动地提取特征,通过控制隐层结构从低层特征中提取深层特征<sup>[14]</sup>;其次,DLR可以直接输入原始图像,不一定需要勾画ROI,有利于减少专家手动勾画的工作量,同时不高度依赖于专家,提高了数据的可靠性<sup>[19]</sup>。此外,当提供更多的训练样本时,模型性能也系统提高<sup>[20]</sup>。值得注意的是,深度学习构架是深度学习影像组学的一大核心,但是其背后的逻辑不清楚,无准确、完整的公式与定义,缺乏生物学解释性。

## 3 基于深度学习超声影像组学在乳腺癌中的应用

### 3.1 乳腺肿物良恶性的鉴别诊断

目前临床乳腺超声检查广泛采用乳腺影像报告



数据系统 (breast imaging reporting and data system, BI-RADS), 提供标准化的术语, 降低对操作者的依赖性, 同时对超声检测到的病变进行评估及后续临床治疗推荐。一般而言, 对 BI-RADS 3 类(良性可能大, 恶性可能性 $\leq 2\%$ )的乳腺肿块建议随访, BI-RADS 4a 类(恶性可能性低, 恶性可能性 $> 2\%$ , 但 $\leq 10\%$ )及以上的乳腺肿块建议穿刺活检以明确诊断。

DLR 在乳腺中的运用集中于对肿块的良恶性鉴别。Zhou 等<sup>[21]</sup>收集 540 例乳腺肿瘤的剪切波弹性图像 (shear-wave elastography, SWE)(恶性 318 例, 良性 222 例)使用 CNN 从图像中学习, 自动提取高通量特征, 并进行良恶性分类, 准确率为 95.8%, 灵敏度为 96.2%, 特异度为 95.7%, 展现出基于深度学习的超声影像组学的自动诊断特性及优越的诊断性能。Zhang 等<sup>[22]</sup>收集 291 例乳腺二维超声图像及 SWE 数据(其中恶性 87 例, 良性 204 例), 超声医生手动勾画获取 ROI, 再通过 CNN 自适应学习特征, 使用最小绝对收缩和选择算子 (least absolute shrinkage and selection operator, LASSO) 回归构建模型, ROC 分析评估性能, 分别与放射科医生评估(BI-RADS 分级)和定量 SWE 参数(最大弹性值 Emax 等)进行 McNemar 检验, 结果显示, 单个性能最佳的定量 SWE 参数 Emax, 在训练集和独立验证集中具有比

BI-RADS 分级更高的特异度( $P < 0.001$ )。对乳房肿块进行分类, 基于二维超声和 SWE 的 DLR 模型性能优于定量 SWE 参数和 BI-RADS 评估。Yu 等<sup>[23]</sup>使用 CNN 从图像中学习, 构建基于仅二维 (two dimension, 2D) 图像, 2D 和彩色多普勒血流成像 (2D-CDI-FI) 以及 2D-CDFI 和脉冲波多普勒 (2D-CDFI-PW) 图像的三类模型, 进行乳腺肿块四分类预测 (炎性肿块、腺病、良性肿瘤和恶性肿瘤)。在验证集中, 2D、2D-CDFI 和 2D-CDFI-PW 模型的准确率分别为 87.9%、89.2% 和 88.7%。良性肿瘤、恶性肿瘤、炎性肿块和腺病分类的 AUC 分别为 0.90、0.91、0.90 和 0.89。目前, 乳腺肿块良恶性鉴别方面基于超声造影 (contrast-enhanced ultrasound, CEUS) 的 DLR 研究有限, 但在肝脏纤维化预测<sup>[24]</sup>、甲状腺结节良恶性鉴别诊断<sup>[25-26]</sup>已有相关研究。

### 3.2 分子分型的预测

乳腺癌分子分型的概念最早由 Perou 等<sup>[27]</sup>提出, 雌激素受体 (estrogen receptor, ER)、孕激素受体 (progesterone receptor, PR)、表皮生长因子受体 2 (human epidermal growth factor receptor 2, HER2) 及 Ki-67 是乳腺癌分子分型的主要决定因素。基于这些标志物的表达状态, 乳腺癌可分为不同的亚型<sup>[28]</sup>, 即: Luminal A 型、Luminal B 型、HER2 阳性型、三阴性

乳腺癌。目前乳腺癌分子分型依赖活检样本的免疫组织化学检查，该检查有创且单个区域样本检测结果不能代表整个病灶，导致结果的不准确性。通过影像学方法无创地实现乳腺癌的分子分型预测是近年来的研究热点。

Guo 等<sup>[29]</sup>通过基于相位的活动轮廓模型自动分割、基于 BI-RADS 设计和提取的影像组学特征、支持向量机分类器评估等影像组学方法证明受体状态和亚型之间存在较强相关性(AUC=0.760, P<0.05)。激素受体阳性、HER2 阴性乳腺癌的超声表现与三阴性乳腺癌不同。然而，目前基于超声的 DLR 在分子分型中研究较少，有学者使用基于 CT 图像的 DLR 方法进行了研究。Yang 等<sup>[30]</sup>在动脉期从多探测器 CT 图像中提取手工特征和基于深度学习的深层影像组学特征评估乳腺癌患者的 HER2 状态，结果显示具有良好的区分能力。多探测器 CT 图像的手工特征和深度影像组学特征与乳腺癌患者的 HER2 状态相关。基于超声的 DLR 在乳腺分子分型预测中的应用有待更多学者加入。

### 3.3 腋窝淋巴结状态评估

准确识别乳腺癌患者的腋窝淋巴结(axillary lymph nodes, ALN)转移对治疗决策和预后十分重要。前哨淋巴结活检(sentinel lymph node biopsy, SLNB) 和腋窝淋巴结清扫(axillary lymph nodes dissection, ALND) 是目前评估 ALN 状态最主要的方式。但 ALND 面临多种术后并发症，如淋巴水肿、疼痛、肩部运动受限和手臂无力等<sup>[31]</sup>。相比 ALND, SLNB 有着较少的术后并发症，但存在 SLN 定位困难等多方面因素影响，不可避免地引起假阴性结果<sup>[32]</sup>。因此，如何通过影像学方法在术前无创地实现腋窝淋巴结状态评估是目前关注的焦点。

Zheng 等<sup>[33]</sup>收集 584 例乳腺癌患者的常规二维超声和 SWE，采用 ResNet50 提取特征并结合临床参数的深度学习影像组学方法术前预测早期乳腺癌患者的 ALN 状态。结果显示，与任何单一方法相比，在区分阴性腋窝(N<sub>0</sub>)患者和任何腋窝转移患者[(N+(≥1)] 方面表现出更好的诊断性能，AUC 为 0.902(95%CI:0.843~0.961)。DLR 模型在腋窝疾病转移负担低[(N+(1~2)] 和腋窝疾病转移负担重[(N+(≥3)] 的患者之间显示出良好的区分能力，验证队列中的 AUC 为 0.905(95% CI:0.814~0.996)。同样

地，Guo 等<sup>[34]</sup>收集 937 例乳腺癌患者的超声图像，开发基于腋窝超声的深度学习影像组学预测模型，在评估腋窝前哨淋巴结及非前哨淋巴结转移以及将无转移患者分为高/低转移风险中展现出良好性能。

### 3.4 新辅助化疗疗效评估

新辅助化疗(neoadjuvant chemotherapy, NAC) 常用于局部晚期乳腺癌，可在术前安全地缩小原发肿瘤大小，降低肿瘤分期<sup>[35]</sup>，在 NAC 中获得病理完全缓解(pathological complete response, pCR) 患者不仅可减少后续手术和治疗带来的创伤，还能获得良好的预后<sup>[36]</sup>。然而，由于乳腺癌的异质性，NAC 个体反应表现出巨大的差异<sup>[37]</sup>。同时，作为疗效评估的金标准，手术标本的病理组织学检查只能在 NAC 治疗后进行。因此，在 NAC 早期进行准确的疗效预测并及时调整临床治疗方案是当前临床工作的重点。

Gu 等<sup>[38]</sup>收集 168 例进行 NAC 患者(已完成第 2 次、4 次化疗)，利用 DLR 模型预测第 2 次(DLR-2)、第 4 次 NAC 后(DLR-4) 的反应，结果显示，在验证队列中，DLR-2 的 AUC 为 0.812 (95% CI:0.770~0.851)，阴性预测值(negative predict value, NPV) 为 83.3%(95% CI:76.5~89.6)。DLR-4 的 AUC 为 0.937 (95% CI:0.913~0.955)，特异度为 90.5%(95% CI: 86.3%~94.2%)。此外，21 例无反应患者中有 19 例成功被 DLR 模型识别，表明可以从 NAC 早期的治疗策略调整中受益。Jiang 等<sup>[39]</sup>收集患者治疗前后的超声图像，采用手工特征结合深度学习特征术前评估 NAC 后乳腺癌 pCR 展现出良好的性能。

## 4 挑战与展望

影像组学是一个新兴的领域，在 CT、MRI 中广泛应用，超声图像因易受噪声影响、不同超声系统引起的观察者间和观察者内的变异性、重复性低、特征提取困难等问题一定程度上阻滞其发展，但随着图像的累积以及影像组学标准化流程建立，超声影像组学运用越来越多。基于超声的 DLR 直接从数据集中提取高阶特征，虽仍在发展阶段，但也显示出其优越的性能，有助于减少工作量，提高诊断效率。

目前基于超声的 DLR 在乳腺癌中运用主要集中于良恶性鉴别诊断、腋窝淋巴结状态评估。超声图像除 B 型超声、弹性成像外，彩色多普勒、频谱多普

勒、超声造影等具有各自优势,未来可多关注 DLR 与超声多模态分析,也可与 MRI、CT 等联合。目前的研究样本量一般较少、多以回顾性、单中心研究为主,后续应关注大样本量、前瞻性、多中心研究。传统研究主要针对肿瘤区域进行研究,对肿瘤周围区域关注较少。Sun 等<sup>[40]</sup>首次将肿瘤的 ROI 勾画分为肿瘤内部区域和周边区域(肿瘤轮廓外 5mm),并尝试对比两种不同区域及两者结合后的诊断效能,采用手工特征和深度学习特征与 3 种勾画区域排列组合构建了 6 个预测模型,结果显示,相比较于传统影像组学模型,深度学习模型预测效果更好,且将内部与周边区域结合分析的诊断效能更好,这为今后的研究提出了新的 ROI 勾画要求。

基于超声的 DLR 也面临着一些问题:其需要从数据中直接学习特征,需要庞大的数据集。虽然目前医学图像比以往任何时候都多,但由于数据隐私保护、复杂的人工图像标注等问题,收集大量的数据存在难度。研究者们开始关注弱监督或半监督学习以期解决这个问题,Seung 等<sup>[41]</sup>提出联合弱监督和半监督深度学习用于乳腺超声图像中肿块分类问题,结果表明,所提出的方法可以成功地进行肿块分类,且只需较少的标注工作,仅使用 10 张强标注图像和弱标注图像训练的结果与使用 800 张强标注图像训练的结果相当,未来这一部分有待深入研究。此外,深度学习构架是深度学习影像组学的一大核心,但其模块难以解释,且其种类繁多,目前难以去选择研究中的最优构架,有待后续深入研究。

## 参考文献:

- [1] Gillies RJ, Kinahan PE, Hricak H. Radiomics: images are more than pictures, they are data[J]. Radiology, 2016, 278(2): 563–577.
- [2] Zheng Y, Zhou D, Liu H, et al. CT-based radiomics analysis of different machine learning models for differentiating benign and malignant parotid tumors[J]. Eur Radiol, 2022, Apr 29.[Online ahead of print]
- [3] Huang YQ, Liang CH, He L, et al. Development and validation of a radiomics nomogram for preoperative prediction of lymph node metastasis in colorectal cancer[J]. J Clin Oncol, 2016, 34(18): 2157–2164.
- [4] Chu F, Liu Y, Liu Q, et al. Development and validation of MRI-based radiomics signatures models for prediction of disease-free survival and overall survival in patients with esophageal squamous cell carcinoma[J]. Eur Radiol, 2022, 32(9): 5930–5942.
- [5] Wu S, Zheng J, Li Y, et al. Development and validation of an MRI-based radiomics signature for the preoperative prediction of lymph node metastasis in bladder cancer[J]. EBio Medicine, 2018, 34: 76–84.
- [6] Liang J, Huang X, Hu H, et al. Predicting malignancy in thyroid nodules: radiomics score versus 2017 american college of radiology thyroid imaging, reporting and data system[J]. Thyroid, 2018, 28(8): 1024–1033.
- [7] Guo SY, Zhou P, Zhang Y, et al. Exploring the value of radiomics features based on B-mode and contrast-enhanced ultrasound in discriminating the nature of thyroid nodules [J]. Front Oncol, 2021, 11: 738909.
- [8] Li F, Pan D, He Y, et al. Using ultrasound features and radiomics analysis to predict lymph node metastasis in patients with thyroid cancer[J]. BMC Surg, 2020, 20(1): 315.
- [9] DiCenzo D, Quiaoit K, Fatima K, et al. Quantitative ultrasound radiomics in predicting response to neoadjuvant chemotherapy in patients with locally advanced breast cancer: results from multi-institutional study[J]. Cancer Med, 2020, 9(16): 5798–5806.
- [10] Li MD, Lu XZ, Liu JF, et al. Preoperative survival prediction in intrahepatic cholangiocarcinoma using a ultrasound-based radiographic-radiomics signature[J]. J Ultrasound Med, 2022, 41(6): 1483–1495.
- [11] Gao RZ, Wen R, Wen DY, et al. Radiomics analysis based on ultrasound images to distinguish the tumor stage and pathological grade of bladder cancer[J]. J Ultrasound Med, 2021, 40(12): 2685–2697.
- [12] Liu Z, Wang S, Dong D, et al. The applications of radiomics in precision diagnosis and treatment of oncology: opportunities and challenges[J]. Theranostics, 2019, 9(5): 1303–1322.
- [13] Rizzo S, Botta F, Raimondi S, et al. Radiomics: the facts and the challenges of image analysis[J]. Eur Radiol Exp, 2018, 2(1): 36.
- [14] Afshar P, Mohammadi A, Plataniotis KN, et al. From hand-crafted to deep-learning-based cancer radiomics: challenges and opportunities[J]. ISPM, 2019, 36(4): 132–160.
- [15] Lao J, Chen Y, Li ZC, et al. A deep learning-based radiomics model for prediction of survival in glioblastoma multiforme[J]. Sci Rep, 2017, 7(1): 10353.
- [16] Fu J, Singhrao K, Zhong X, et al. An automatic deep learning-based workflow for glioblastoma survival prediction using preoperative multimodal mr images: a feasibility study[J]. Adv Radiat Oncol, 2021, 6(5): 100746.
- [17] McBee MP, Awan OA, Colucci AT, et al. Deep learning in

- radiology[J]. Acad Radiol, 2018, 25(11):1472–1480.
- [18] Shafiee MJ, Chung AG, Khalvati F, et al. Discovery radiomics via evolutionary deep radiomic sequencer discovery for pathologically proven lung cancer detection[J]. J Med Imaging, 2017, 4(4):041305.
- [19] LeCun Y, Bengio Y, Hinton GJn. Deep learning [J]. Nature, 2015, 521(7553):436–444.
- [20] Cheng JZ, Ni D, Chou YH, et al. Computer-aided diagnosis with deep learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans[J]. Sci Rep, 2016, 6:24454.
- [21] Zhou Y, Xu J, Liu Q, et al. A radiomics approach with CNN for shear-wave elastography breast tumor classification[J]. IEEE Trans Biomed Eng, 2018, 65(9):1935–1942.
- [22] Zhang X, Liang M, Yang Z, et al. Deep learning-based radiomics of B-mode ultrasonography and shear-wave elastography: improved performance in breast mass classification[J]. Front Oncol, 2020, 10:1621.
- [23] Yu TF, He W, Gan CG, et al. Deep learning applied to two-dimensional color Doppler flow imaging ultrasound images significantly improves diagnostic performance in the classification of breast masses: a multicenter study[J]. Chin Med J (Engl), 2021, 134(4):415–424.
- [24] Duan YY, Qin J, Qiu WQ, et al. Performance of a generative adversarial network using ultrasound images to stage liver fibrosis and predict cirrhosis based on a deep-learning radiomics nomogram[J]. Clin Radiol, 2022, 77(10):e723–e731.
- [25] Zhou H, Jin Y, Dai L, et al. Differential diagnosis of benign and malignant thyroid nodules using deep learning radiomics of thyroid ultrasound images [J]. Eur J Radiol, 2020, 127:108992.
- [26] Zhang C, Liu D, Huang L, et al. Classification of thyroid nodules by using deep learning radiomics based on ultrasound dynamic video[J]. J Ultrasound Med, 2022, May 23. [Online ahead of print]
- [27] Perou CM, Sørlie T, Eisen MB, et al. Molecular portraits of human breast tumours[J]. Nature, 2000, 406(6797):747–752.
- [28] Goldhirsch A, Winer EP, Coates AS, et al. Personalizing the treatment of women with early breast cancer: highlights of the StGallen International Expert Consensus on the Primary Therapy of Early Breast Cancer 2013[J]. Ann Oncol, 2013, 24(9):2206–2223.
- [29] Guo Y, Hu Y, Qiao M, et al. Radiomics analysis on ultrasound for prediction of biologic behavior in breast invasive ductal carcinoma[J]. Clin Breast Cancer, 2018, 18(3):e335–e344.
- [30] Yang X, Wu L, Zhao K, et al. Evaluation of human epidermal growth factor receptor 2 status of breast cancer using preoperative multidetector computed tomography with deep learning and handcrafted radiomics features[J]. Chin J Cancer Res, 2020, 32(2):175–185.
- [31] Gupta S, Gupta N, Kadavaprath G, et al. Use of sentinel lymph node biopsy and early physiotherapy to reduce incidence of lymphedema after breast cancer surgery: an institutional experience [J]. Indian J Surg Oncol, 2020, 11(1):15–18.
- [32] Sun SX, Moseley TW, Kuerer HM, et al. Imaging-based approach to axillary lymph node staging and sentinel lymph node biopsy in patients with breast cancer [J]. AJR Am J Roentgenol, 2020, 214(2):249–258.
- [33] Zheng X, Yao Z, Huang Y, et al. Deep learning radiomics can predict axillary lymph node status in early-stage breast cancer[J]. Nat Commun, 2020, 11(1):1236.
- [34] Guo X, Liu Z, Sun C, et al. Deep learning radiomics of ultrasoundography: identifying the risk of axillary non-sentinel lymph node involvement in primary breast cancer[J]. E-BioMedicine, 2020, 60:103018.
- [35] Expert Panel on Breast I, Slanetz PJ, Moy L, et al. ACR appropriateness criteria monitoring response to neoadjuvant systemic therapy for breast cancer[J]. J Am Coll Radiol, 2017, 14(11S):S462–S475.
- [36] Steenbruggen TG, van Ramshorst MS, Kok M, et al. Neoadjuvant therapy for breast cancer: established concepts and emerging strategies[J]. Drud S, 2017, 77(12):1313–1336.
- [37] Xiong Q, Zhou X, Liu Z, et al. Multiparametric MRI-based radiomics analysis for prediction of breast cancers insensitive to neoadjuvant chemotherapy[J]. Clin Trans Oncol, 2020, 22(1):50–59.
- [38] Gu J, Tong T, He C, et al. Deep learning radiomics of ultrasoundography can predict response to neoadjuvant chemotherapy in breast cancer at an early stage of treatment: a prospective study[J]. Eur Radiol, 2022, 32(3):2099–2019.
- [39] Jiang M, Li CL, Luo XM, et al. Ultrasound-based deep learning radiomics in the assessment of pathological complete response to neoadjuvant chemotherapy in locally advanced breast cancer[J]. Eur J Cancer, 2021, 147:95–105.
- [40] Sun Q, Lin X, Zhao Y, et al. Deep learning vs. radiomics for predicting axillary lymph node metastasis of breast cancer using ultrasound images: don't forget the peritumoral region[J]. Front Oncol, 2020, 10:53.
- [41] Seung Yeon S, Soochahn L, Il Dong Y, et al. Joint weakly and semi-supervised deep learning for localization and classification of masses in breast ultrasound images [J]. IEEE Trans Med Imaging, 2019, 38(3):762–774.