

深度学习在乳腺癌病灶影像分割中的应用进展^①



刘 蝶, 李 杨, 孙 兴, 朱佳音, 马金刚

(山东中医药大学 医学信息工程学院, 济南 250355)

通信作者: 马金刚, E-mail: ma_jingang@126.com

摘 要: 乳腺癌是全球女性中最常见且致死率较高的恶性肿瘤之一, 其诊断和治疗高度依赖医学成像技术. 其中, 病灶分割在精准识别病理区域、辅助诊断及治疗规划方面发挥着关键作用. 近年来, 深度学习算法在乳腺癌病灶的自动分割任务中取得了显著进展, 为深度学习在这方面的研究奠定了基础. 系统梳理了近年来相关研究, 重点探讨深度学习技术在不同医学成像模式下分割方面的应用, 旨在为乳腺癌病灶分割的进一步研究提供参考. 首先, 简要介绍相关数据集和图像分割常用指标. 然后, 系统综述基于深度学习的乳腺癌影像分割方法, 归纳不同算法在不同成像模式下的应用情况. 最后, 总结当前技术存在的挑战, 并结合现有研究的局限性, 对未来发展方向进行展望.

关键词: 乳腺癌; 计算机辅助技术; 深度学习; 图像分割; 计算机视觉

引用格式: 刘蝶, 李杨, 孙兴, 朱佳音, 马金刚. 深度学习在乳腺癌病灶影像分割中的应用进展. 计算机系统应用, 2026, 35(1): 19-38. <http://www.c-s-a.org.cn/1003-3254/10029.html>

Application Progress of Deep Learning for Breast Cancer Focus Image Segmentation

LIU Die, LI Yang, SUN Xing, ZHU Jia-Yin, MA Jin-Gang

(School of Medical Information Engineering, Shandong University of Traditional Chinese Medicine, Jinan 250355, China)

Abstract: As one of the most common malignant tumors with high mortality rates among women worldwide, breast cancer relies highly on medical imaging for its diagnosis and treatment. Focus segmentation plays a crucial role in the precise identification of pathological regions, diagnostic assistance, and treatment planning. Recent advances in deep learning have made significant progress in automatic segmentation for breast cancer focus, laying a foundation for further deep learning-based research in this field. Recent research achievements are systematically reviewed, with a focus on the application of deep learning technology in focus segmentation under different medical imaging modes, aiming to provide a reference for the advancement of research in breast cancer focus segmentation. The relevant datasets and common evaluation metrics for image segmentation are briefly introduced. The image segmentation method for breast cancer based on deep learning is then systematically reviewed. The application of algorithms applied in different imaging modes is generalized. At last, current challenges for this technology are summarized. Future directions are also discussed based on limitations in the existing research.

Key words: breast cancer (BC); computer-aided technology; deep learning; image segmentation; computer vision

乳腺癌 (breast cancer, BC) 作为一种高致死率的恶性肿瘤, 在全球范围内呈现高发态势, 尤其以中年女性群体为主要患病人群. 据 2022 年全球癌症统计数据

显示, 该年度新增女性乳腺癌确诊病例达 2 308 897 例, 相关死亡病例高达 665 684 例, 使其成为女性群体中发病率最高的恶性肿瘤^[1]. 流行病学进一步研究表明, 在

① 基金项目: 2022 年山东省研究生优质教育教学资源项目 (SDYAL2022041); 山东省中医药科技项目 (M20241738)

收稿时间: 2025-05-19; 修改时间: 2025-06-12, 2025-06-30; 采用时间: 2025-07-14; csa 在线出版时间: 2025-11-17

CNKI 网络首发时间: 2025-11-18

各类女性癌症致死率排名中, 乳腺癌仅次于肺癌, 位居第2^[1]. 乳腺癌的临床诊断主要采用多模态影像学检查手段, 其中乳腺X光摄影和超声检查以及磁共振成像技术作为初筛工具, 而病理学诊断则通过显微镜下观察组织标本完成确诊^[2]. 然而, 病理诊断过程存在显著的主观性差异, 且耗时长, 这主要源于缺乏统一的诊断标准^[3]. 随着患者数量的持续增长, 开发基于计算机辅助诊断 (computer-aided diagnosis, CAD) 的智能化检测系统已成为提高诊断效率的关键途径. 临床研究证实, 通过及时准确的早期诊断和规范化治疗, 可显著降低疾病死亡率^[4]. 流行病学调查进一步显示, 约9成乳腺癌患者若能实现早期诊断并接受规范治疗, 可获得良好的预后效果^[5], 在这一过程中, 医学影像分析发挥着关键作用, 而病灶区域的精确分割则是影像诊断中的核心环节.

在乳腺癌病灶分割领域, 近年国外已有一些优秀综述发表. 如 Abo-El-Rejal 等^[6]系统综述了从传统到深度学习的乳腺癌图像分割技术, 为领域提供了全面参考. 然而, 该研究仍缺乏大规模临床验证. Alam 等^[7]则系统回顾了医学影像中乳腺癌识别与分析的最新进展, 并比较了不同分割技术及机器学习算法的有效性. 但

对扩散模型等新兴生成式方法的医学适配性探讨不足, 且未涉及多中心联合训练. 而 Sutjiadi 等^[8]对深度学习在乳腺癌检测中的应用进行了系统性综述, 但仅总结了基于深度学习的CAD系统在乳腺X光图像分割和分类中的应用. 针对以上不足, 本文首先介绍了目前较常用的乳腺影像学检查技术以及可获得的乳腺癌数据集, 主要涵盖了X光摄影 (mammography, MG)、超声成像 (ultrasound-imaging, US)、磁共振成像 (magnetic resonance imaging, MRI) 这3种模态, 各成像方式优点如表1所示, 其次给出医学图像分割中常用的评价指标, 最后探讨了近年来深度学习方法与技术在不同类型乳腺影像中的分割应用, 并分析了将深度学习整合到乳腺癌分割任务中的局限性与潜在机遇. 图1以CNN为例展示了传统深度学习分割技术的概述.

表1 3种乳腺成像技术的优缺点

成像方式	优点	缺点
MG	图像分辨率提高, 设备广泛可用	在致密乳腺组织中的敏感性有限, 有辐射暴露
US	适用于高密度乳腺人群, 无辐射	伪影多, 易受操作员影响
MRI	软组织对比度高, 适用于高危人群和术前评估	采集时间长、成本高

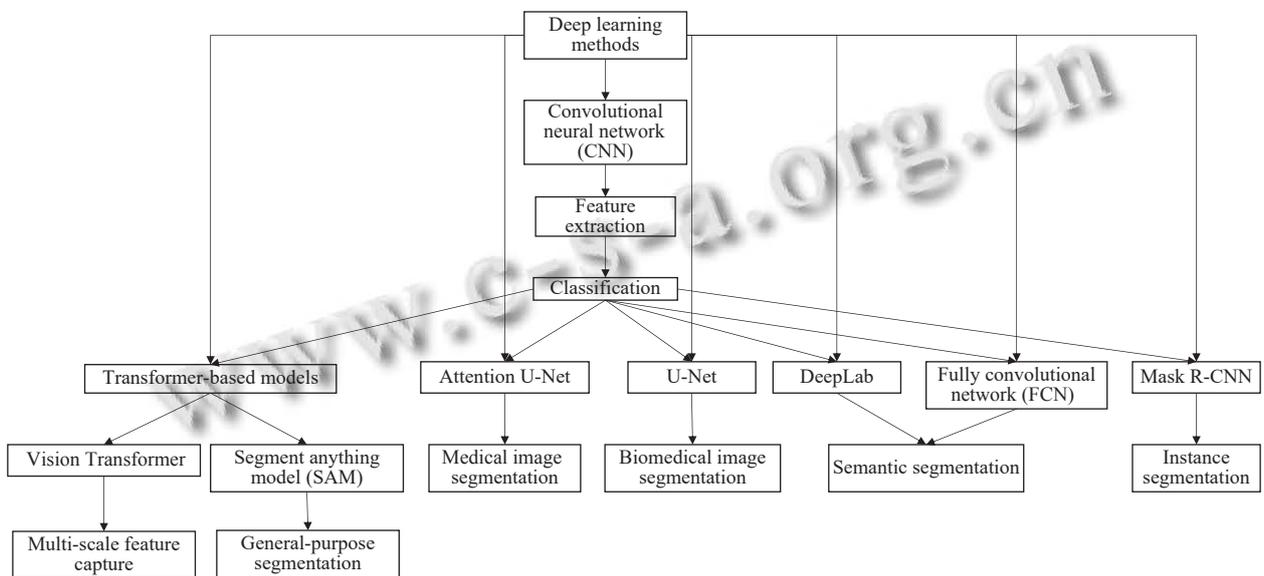


图1 传统深度学习分割技术的概述^[7]

1 数据集

在深度学习领域, 数据集是专门用于训练、验证及测试深度学习模型的一组数据集合, 为防止模型过度拟合, 深度学习模型通常需要借助规模庞大的数据

集进行训练. 本节对常用的不同成像方式的乳腺癌数据集进行阐述. 表2汇总了3类影像公开的数据集的数量、成像方式、尺寸、创建时间、优点和获取地址等^[8].

表2 数据集信息

成像方式	数据库	数量	年份	尺寸	优点	获取地址
MG	INbreast	410	2012	3328×4084	分辨率更高、标注更精细	http://medicalresearch.inescporto.pt/breastresearch/index.php/Get_INbreast_Database
	MIAS	322	1994	1024×1024	包含3个类别: 良性、恶性和正常	https://www.kaggle.com/datasets/kmader/mias-mammography
	mini-MIAS	322	1994	1024×1024	放射科医生标注的病灶位置与类型	http://peipa.essex.ac.uk/info/mias.html
	DDSM	10480	1999	3000×4000–5000×6000	带有验证过的病理信息	http://marathon.csee.usf.edu/Mammography/Database.html
US	CBIS-DDSM	10239	2017	3000×5000	标准化DICOM, 精准病灶标注, 丰富临床数据	https://www.cancerimagingarchive.net/collection/cbis-ddsm/
	UDIAT	163	—	760×570	专业的医生勾画了所有的病灶	https://www.kaggle.com/datasets/ayush02102001/udiat-segmentation-dataset
	BUSI	780	2018	500×500	包含3个类别: 良性、恶性和正常	https://www.kaggle.com/datasets/aryashah2k/breast-ultrasound-images-dataset/suggestions?status=pending
MRI	BreastDM	232	2021	—	包含良性和恶性乳腺肿瘤, 涵盖分割和分类任务	https://www.kaggle.com/datasets/kartikpatil0/breastdm-dataset

1.1 X光乳腺摄影

INbreast 数据集^[9]共收录 410 幅全视野数字乳腺 X 光影像, 对应 115 例患者, 像素级标注涵盖正常、良性及恶性病灶. 其图像源自真实临床场景, 标注经放射科医师校验, 具备较高的临床相关性, 可为乳腺病灶分割与分类任务提供可靠的监督学习素材.

MIAS 数据集^[10]是于 1994 年收集的数据集, 包含 322 张来自 161 名患者的乳腺 X 光图像, 只有 MLO 拍摄视角, 图像以 1024×1024 像素、8 位灰度级的 PGM 格式存储, 并附有详细的病变位置、类型及严重程度标注. 图像被标记为正常、良性、恶性等类别, 并且该数据集具有多样性、详细的标注和公开性等优点, 但也存在图像数量较少、分辨率较低和标注主观性等局限性. 图 2 是 MIAS 数据集中的示例.

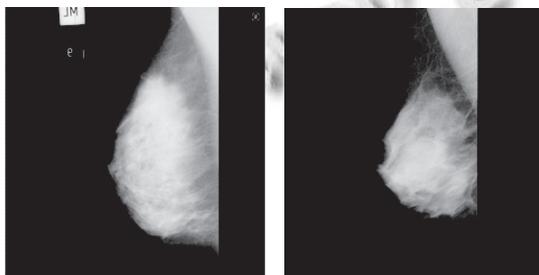


图2 MIAS 数据集示例

mini-MIAS 数据集^[11]包含 209 张正常图像, 113 张异常图像, 共 322 张单侧乳腺钼靶图像. 异常图像分为 6 类, 包括界限清楚的肿块、不对称性、结构扭曲、毛刺状肿块、边界不清的肿块和钙化. 该数据集图像分

辨率为 1024×1024 像素, 标注清晰, 适用于分割与分类任务.

DDSM 数据集^[12]是 1999 年发布的公开数据库, 包含 CC 和 MLO 两种拍摄视角, 约 2620 例病例共 10480 张高分辨率数字化乳腺影像, 分为正常、良性和恶性病变, 并提供患者年龄、病灶类型、病理结果及专家标注的病灶轮廓信息.

DDSM-400 数据集源自数据集 DDSM, 包含 400 张乳腺 X 光图像, 其中良性病变图像 196 张, 恶性病变图像 204 张. 所有图像的病变区域均经过专家放射科医生使用半自动分割方法进行精确标注并生成高质量的病变轮廓分割图. 分割图提供了清晰的病变边界信息, 能够有效辅助诊断模型性能的提升.

CBIS-DDSM 数据集^[13]是 2017 年创建的 DDSM 数据库的一个更新和标准化版本, 包含 753 例钙化病例和 891 例肿块病例. 数据集的原始图像以 DICOM 格式存储, 包含 3103 张乳腺 X 光图像, 其中 465 张图像具有多个异常区域. 此外, 数据集还包括 3568 张裁剪后的乳腺图像及其对应的掩码, 适用于分割任务.

1.2 超声

UDIAT 数据集^[14]为公开数据集, 包括 110 例为良性肿瘤, 53 例为恶性肿瘤, 共 163 张女性乳腺肿瘤患者的乳腺超声 (breast ultrasound, BUS) 图像. 恶性影像中浸润性导管癌 40 例, 导管原位癌 4 例, 浸润性小叶癌 2 例, 其他未明确的恶性病变 7 例. 良性影像中, 未明确的囊肿 65 例, 纤维腺瘤 39 例, 其他类型的良性病变 6 例. 专业的医生勾画了所有的病灶.

BUSI 数据集^[15]是一个在 2018 年收集的数据集,以 DICOM 格式存储,预处理去除了重复图像和未使用的边界.该数据集包含了 600 名年龄在 25–75 岁之间的女性患者的图像,分为正常、良性和恶性这 3 个类别,分别有 133、437 和 210 张图像,共 780 张图像.每张图像都是 500×500 像素的 PNG 格式,并且每张图像都有可用的地面真实数据.图 3 展示了该数据集中的癌症原始影像及其对应的标注结果,供读者参考.

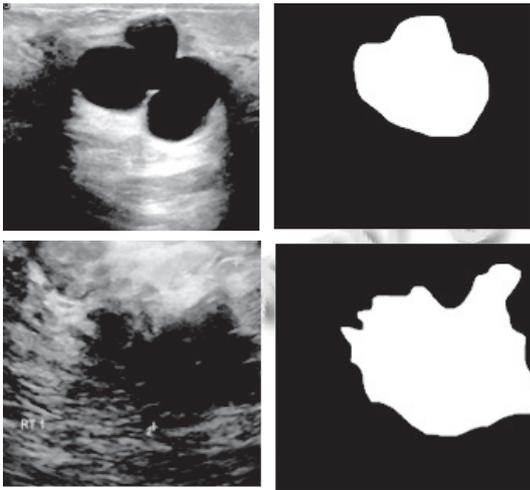


图 3 BUSI 数据集^[15]示例

1.3 磁共振成像

BreastDM 数据集^[16]是专门用于乳腺肿瘤分割和分类的动态增强磁共振成像数据库,数据收集 147 例恶性肿瘤和 85 例良性肿瘤.图像大小范围为 512×512×71–512×512×112,数据集分为训练集、验证集和测试集,其中训练集包含 166 例,训练集共 20434 张图像,验证集包含 19 例,1989 张图像,测试集包含 47 例,6851 张图像.所有图像经过空间和强度归一化处理,并由经验丰富的放射科医生进行标注和验证.

2 乳腺癌相关病理图像分割评价指标

在医学图像分割研究中,科学评估模型的预测效果需要依托多种定量评价指标.作为算法性能验证的金标准,这些参数在客观衡量算法输出结果与真实标注之间的吻合度方面具有关键作用.下面列举了一些在医学图像分割领域广泛应用的评价指标.

2.1 Dice 相似系数

Dice 相似系数 (Dice similarity coefficient, DSC) 也称为 F1 分数,是医学图像分割任务中常用的评估指

标,衡量预测分割区域与真实标注区域的重叠程度,对于二进制分割, Dice 相似系数的计算表达式为:

$$Dice = \frac{2 \times |A \cap B|}{|A| + |B|} \quad (1)$$

其中, A 为模型的预测结果, B 为真实的分割标签, Dice 相似系数的范围在 0–1 之间,越接近 1 表示模型的预测结果与真实标签越接近.

2.2 准确率

准确率 (Accuracy) 的计算如式 (2),其表示的是图像中被正确分类的像素个数除以整个图像的总像素数量:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

其中, TP 表示模型正确预测为正类的实例,实际情况也为正类. TN 表示模型正确预测为负类的实例,实际情况也为负类. FP 指模型错误地将负类预测为正类,但真实情况为负类. FN 是模型错误地将正类预测为负类,实际情况为正类^[17].

2.3 交并比与平均交并比

针对微小肿瘤常用 IoU ^[18]和 $MIoU$ 来评估模型性能,其表达式如下所示:

$$IoU = \frac{TP}{TP + FP + FN} \quad (3)$$

$$MIoU = \frac{1}{M} \sum_{i=0}^M \frac{TP_i}{TP_i + FP_i + FN_i} \quad (4)$$

交并比 (intersection over union, IoU), 是计算两个集合 (在语义分割中通常为真实值和预测值) 的交集和并集之比,取值范围在 0–1 之间,越接近 1 表示预测结果与真实标签的相似度越高^[19]. 平均交并比 (mean intersection over union, $MIoU$) 是计算数据集每个类别的 IoU 平均值. $MIoU$ 越高,说明网络在各类别上的预测结果越好,整体性能越优秀.

2.4 召回率

召回率 (Recall)^[20]表示实际为肿瘤的像素中被正确预测的比例.其计算公式为:

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

$Recall$ 取值范围在 0–1 之间,0 表示完全未检测到目标,1 表示模型完全覆盖所有真实目标区域,召回率越接近 1 表示算法对目标的识别越完整.

3 深度学习在乳腺癌病灶分割中的应用

3.1 乳腺 X 光图像分割

3.1.1 经典 CNN 架构改进模型

经典 CNN 架构在乳腺 X 光图像分割中已广泛应用,以 U-Net 及其改进模型为核心,结合多尺度特征提取和注意力机制,显著提升了肿块检测与分割的精度,卷积神经网络 (CNN)^[21]架构主要包含输入层、卷积层、池化层和全连接层,图 4 给出 CNN 模型架构。

乳腺病变在 X 光片中呈现不规则的形状、模糊的边界或与周围组织相似的密度,严重影响分割的精度。Al-Antari 等^[22]提出了全分辨率卷积网络 (FrCN),该模型通过去除传统深度学习模型中的最大池化和下采样层,保留了输入图像的完整空间分辨率,从而避免了特征图分辨率的损失, Dice 相似系数达到 92.36%,整体准确率为 92.69%。但该模型仅在 INbreast 数据集上进行了验证,在其他数据集或实际临床场景中的泛化能力尚未得到充分验证。针对传统方法在乳腺 X 光图像分割中面临的高假阳性和假阴性率问题,Alkhaleefah 等^[23]提出 Connected-SegNets 模型,通过连接两个 SegNet 架构并引入跳跃连接,有效恢复了在池化操作中丢失的空间信息,从而提高了分割精度,但未明确讨论模型对小肿瘤或模糊边界的分割效果。针对乳腺 X 光图像中存在的对比度差、噪声和伪影等问题,Zhou 等^[24]结合了预处理技术与 DeepLabV3+ 支持的语义分

割技术,采用了中值滤波进行噪声抑制,并结合对比度受限的自适应直方图均衡化增强图像对比度,在 mini-MIAS 和 INbreast 数据集上分别得到了 97.39% 和 97.14% 的 *MIoU*,实现了高效的乳腺区域提取。Deb 等^[25]采用 U-Net 和 BCDU-Net 两种网络,分别对完整乳腺 X 光图像和提取的感兴趣区域 (region of interest, ROI) 进行分割实验。结果表明,与完整图像相比,ROI 的分割性能更为出色,证明了 ROI 在乳腺 X 光图像分割中的有效性,为乳腺癌诊断中的图像分割提供有价值的参考。为解决临床乳腺癌早期检测中的图像分割问题,Shaaban 等^[26]提出基于改进的 U-Net3+ 神经网络架构的乳腺癌分割系统,该模型在 INbreast 数据集上 *Dice* 相似系数达到了 98.47%。但模型可能对患者之间的解剖结构差异较为敏感,例如器官形状和大小的变化,导致模型在其他数据集上的性能有待验证。而随后 El-Banby 等^[27]提出乳腺 X 光图像肿块自动分割方法虽然具有高精度分割和自动化处理能力,但同 Alkhaleefah 等^[23]提出的模型一样在小肿块分割和极端情况下仍面临一定挑战。针对以上小肿块分割以及乳腺癌肿块在图像中与正常组织边界模糊、形态多样以及早期病变特征不明显等问题,Hoseini 等^[28]设计了 3 种不同架构的深度卷积神经网络模型。通过数据增强、图像预处理以及结合传统分割技术等改进方法,DCNN3 模型在 INbreast 数据集上的平均准确率达到 97.67%,显示出该方法在乳腺癌肿块分割任务中性能优越。

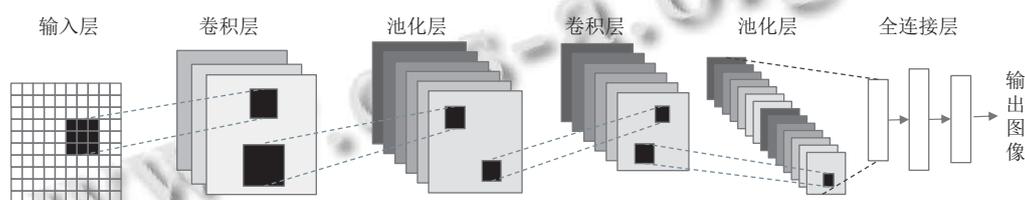


图 4 CNN 架构

3.1.2 结合多尺度特征提取技术

在乳腺癌 X 光图像分割过程中,多尺度提取技术能够有效提升对不同尺寸病变的分割鲁棒性。该技术通过同时捕获病灶的局部细节和全局上下文信息,显著提升了分割效果。其典型方法有多层级特征融合与空洞卷积金字塔等。多尺度提取技术尤其显著提升了小肿瘤 (<5 mm) 的分割精度,同时减轻了因乳腺组织密度不均或病灶边界模糊导致的误分割问题。然而,在

应用该技术时,需要平衡计算效率与特征冗余之间的关系,以确保其在实际应用中的有效性和可行性。

传统手动分割受限于主观特征选择和固定参数,难以应对医学图像的复杂性与多样性,Tiryaki 等^[29]基于改进型 U-Net 框架构建算法模型,集成 ResNet50 预训练权重构建特征提取模块,采用 UNet++ 增强多尺度特征融合,联合 Tversky 损失与 *Dice* 损失优化边界分割效果。该方案实现了全自动多组织分割,规避了传统方

法中手动特征选择与窗口参数设定的缺陷。随后 Jha 等^[30]提出混合模糊聚类与深度学习的乳腺影像分割框架,通过 FCM 算法完成初始病灶粗定位后,利用改进的 CNN 架构进行精细化分割,并设计动态阈值模块优化边界特征。该方法在 MIAS 数据集验证中,分割准确率为 92.37%,但该模型存在 4.7 GFLOPs 的高计算负载,且在低信噪比影像中 DSC 指标波动达 12.6%,表明其对噪声敏感。而在最新的研究中 Sreevani 等^[31]通过引入先进的 OGCRNN-SBCRC 技术,采用先进的 UNet++ 架构,通过多尺度特征提取和复杂的网络结构设计,能够精准地勾勒出肿瘤边界,未来随着数据集的不断扩大的技术的持续优化, Sreevani 等的这一研究成果有望在临床实践中得到更广泛的应用和推广,为乳腺癌的早期诊断和治疗提供更有力的支持。

3.1.3 注意力机制网络

结合注意力机制在乳腺癌 X 光图像分割中通过动态聚焦肿瘤边缘、微钙化簇等关键病灶区域并抑制高密度腺体、血管噪声等无关背景干扰,显著提升了分割精度。空间注意力通过权重图增强病灶位置的特征响应;通道注意力筛选与病变相关的特征通道;交叉注意力建模长距离上下文依赖,解决组织重叠和边界模糊问题。该技术能有效区分小肿瘤与正常组织,同时增强模型对低对比度区域的敏感性。

Fu 等^[32]基于注意力机制的主动学习框架,通过少量标注数据实现高效的乳腺癌分割,降低了标注成本。实验证明该框架展现出良好的适应性和扩展性,并针对微钙化和结构扭曲等特定问题设计算法以提高此类影像临床分割效果。

针对文献^[23,27]中小肿瘤 (<5 mm) 分割不理想以及手动分割效率低下的问题,徐旺旺等^[33]提出 TransAS-UNet 模型,该方法整合了 Swin Transformer 与 U-Net 架构,并结合 ASPP 模块,以提高分割效率。在 INbreast 数据集上的实验表明, TransAS-UNet 的 *IoU* 达到了 95.58%, *Dice* 相似系数为 93.45%, 性能较 U-Net、UNet++ 等传统模型提升了 4%–6%。此外,利用多注意力 ResNet50 网络对分割后的二值图像进行四分类,准确率达到 95.24%。通过结合全局和局部特征,该方法显著提高了乳腺癌小区域分割的精确度,对临床应用具有重要意义。

而 Kljajić 等^[34]旨在评估 GLAM 模型生成的显著

图对 SegFormer 模型的分割性能影响。设计了 3 种实验方案:仅使用预处理后的 MG 图像作为输入;将 MG 图像与 GLAM 模型生成的显著图相结合;单独使用显著图作为输入。然而,实验结果显示,尽管 GLAM 模型在大规模数据集上进行了预训练,但其显著图并未显著提升 SegFormer 模型的分割效果,反而引入了不确定性降低了模型性能。但该研究仍为未来的工作提供了方向,例如深入研究数据集差异、改进模型架构、探索多模态数据融合以及解决硬件限制等,以期进一步提升乳腺病变分割的准确性和鲁棒性。

3.1.4 小结

综上所述,当前研究通过基于改进网络架构、引入注意力机制及多尺度特征融合,通过消除下采样操作完整保留图像空间细节,解决了特征图分辨率损失问题;采用双路架构结合跨层连接机制,有效弥补了传统池化导致的空间信息丢失;结合预处理技术显著提升了图像质量;优化特征传递路径增强了分割精度;整合多尺度特征提取模块改善了微小病灶识别能力;注意力机制在复杂场景下表现出色。这些方法从分辨率保持,小目标检测和多元数据融合等角度,系统性地提升了基于乳腺 X 光摄影的乳腺病变分割效果。

但当前研究仍存在一些局限性:存在数据依赖性,多数模型依赖专家标注数据,且泛化能力受限于单一数据集验证,如 INbreast;计算复杂度较高, Connected-SegNets 等模型因结构复杂导致高计算成本,影响临床实时性应用;具有噪声敏感性且小目标分割效果较差,部分模型在低信噪比图像或小肿块分割中表现波动较大(如 DSC 波动达 12.6%)。

针对以上不足,可以采取以下策略:使用轻量化网络设计(如 MobileNetV3、ShuffleNet 等)与多模态数据融合(如结合 X 光与超声影像)以提升模型鲁棒性;构建大规模、多样化的数据集(涵盖不同设备型号、成像参数及人群特征)增强模型泛化能力;结合半监督学习(如 Mean Teacher、FixMatch 等算法)利用大量未标注数据降低标注成本。例如,可采用知识蒸馏技术将复杂模型的能力迁移至轻量级网络,如 MobileViT;或在多中心研究中整合不同机构的影像数据构建更具代表性的训练集,并开发一体化分割-分类网络提高诊断效率。表 3 汇总了上述研究的模型的主要贡献、采用的数据集以及评价指标等。

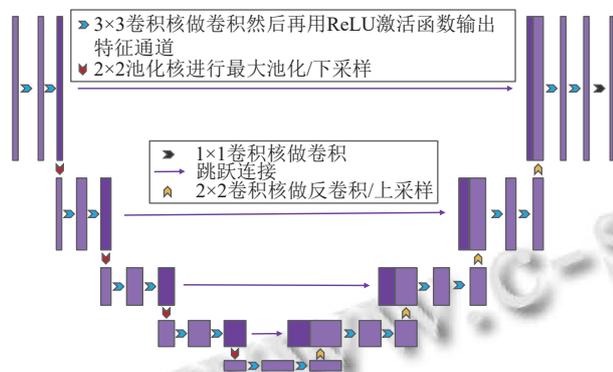
表3 深度学习技术在乳腺X光图像上分割的研究总结

技术方法	文献	数据集	年份	模型	主要贡献	最优DSC	最优准确率
CNN架构改进	[22]	INbreast	2020	FrCN	解决MG边界模糊、密度相似问题	0.923 6	0.926 9
	[23]	INbreast、CBIS-DDSM等	2022	Connected-SegNets	解决高假阳性和假阴性率问题	0.963 4	0.96
	[24]	mini-MIAS、INbreast	2022	DeepLabV3+	解决对比度差、噪声和伪影问题	0.984 8	0.991 2
	[25]	INbreast	2022	U-Net和BCDU-Net	证明ROI在MG分割中的有效性	0.872 3	—
	[26]	INbreast	2023	Optimized U-Net3+	提升MG区域分割精度	0.984 7	0.965
	[27]	INbreast、CBIS-DDSM	2024	—	自动化分割	0.879 8	—
	[28]	INbreast	2024	DCNN3	精准分割乳腺X光图像肿块	—	0.976 7
结合多尺度特征提取	[29]	DDSM	2022	ResNet50-U-Net	解决多标签组织分割问题	0.827 1	0.760 1
	[30]	MIAS	2023	—	提高MG图像分割精度	—	—
	[31]	CBIS-DDSM	2025	OGCRNN-SBCRC	精准分割乳腺癌病变区域	0.996 4	0.996 5
注意力机制网络	[32]	自建数据集	2023	Attention-based active learning	降低标注成本提升分割精度	0.725	—
	[33]	INbreast	2024	TransAS-UNet	解决手动分割耗时且易出错问题	0.934 5	0.955 8
	[34]	CBIS-DDSM、INbreast等	2024	SegFormer	评估GLAM模型生成的显著图对SegFormer模型在MG分割任务中的影响	—	—

3.2 超声 (US) 图像分割

3.2.1 经典 CNN 改进模型

在乳腺癌超声图像分割领域,经典 CNN 架构的应用通常采用全卷积网络 (fully convolutional network, FCN) 或优化后的编码器-解码器架构,例如用图 5 所示的 U-Net 的原型来开展。其核心在于运用卷积层挖掘多尺度特征,并恢复空间信息,从而精准定位肿瘤区域。



早期研究中,研究者们往往选取 VGG、ResNet 等经典网络中的卷积模块充当编码器,同时配合上采样操作以及跳跃连接,以此强化对低对比度、边界模糊的超声图像的分割效果。在应对数据稀缺性问题时,这类方法借助迁移学习来应对,并且运用数据增强、多尺度输入等手段增强鲁棒性,在肿瘤轮廓描绘方面获得了较高的 Dice 相似系数。不过,由于超声图像存在噪声和伪影的干扰,仍需搭配后处理或注意力机制来提升细节分割的精度。

在生物医学图像的语义分割方面, Ben Ahmed 等^[35]提出了基于 U-Net 架构的深度学习框架,通过将预训练的 MobileNetV2 和 VGG16 模型作为编码器,实现了轻量化设计利用迁移学习对这些卷积神经网络进行微调,实现对乳腺超声图像中正常和肿瘤像素的分割。Alam 等^[36]在研究中采用 U-Net3+深度学习架构,针对乳腺癌检测和诊断的语义分割任务进行了深入分析和评估,通过与 FCN、U-Net、SegNet、DeepLabV3+和 psp-Net 的对比分析,U-Net3+在分割性能上表现出色,能够有效识别和勾勒出乳腺肿瘤的边界,为乳腺癌的准确诊断提供了有力支持。但该模型在训练过程中损失函数曲线在训练集和验证集上存在较大波动,且训练集和验证集的 *MIoU* 值差异显著,这表明模型可能存在过拟合的风险。随后 Nastase 等^[37]基于两种编码器-解码器架构的分割方法,分别采用了预训练的 DeepLabV3+和 U-Net 模型。其中,编码器负责提取高维特征向量,而解码器则对编码器输出的低分辨率特征向量进行分析,并生成语义分割掩膜。DeepLabV3+模型在肿瘤分割任务中与真值对比的 *Dice* 相似系数较 U-Net 模型分别高出 0.3109 (恶性) 和 0.3073 (良性)。进一步与局部图分割技术对比时,DeepLabV3+较 U-Net 模型分别高出 0.3262 (恶性) 和 0.3085 (良性)。这些结果表明,DeepLabV3+模型在分割性能上显著优于 U-Net 模型,能够为乳腺肿瘤的自动分割提供更准确的解决方案。

在解决传统手动分割乳腺病变区域费时费力且容易出现人为误差的问题时, Vigil 等^[38]提出卷积深度自

编码器模型,具备同时分割病变区域和提取深度放射组学特征的双重功能.该模型通过深度自编码器将高维图像数据压缩至低维特征空间,有效避免了过拟合问题,并显著减少了训练时间和数据需求,但该模型仍存在高度依赖数据的质量、缺乏临床信息的整合等问题. Islam 等^[39]提出了一种创新的方法,集成深度卷积神经网络(EDCNN)和U-Net算法. Bartolotta 等^[40]使用来自两个乳腺单位的数据集,采用了人工智能辅助的半自动分割技术,使用基于CNN的人工智能软件S-Detect™软件,自动勾勒乳腺病变的轮廓,该方法可迅速完成病变区域分割,为后续的放射组学分析和诊断提供有力支持,有望在临床实践中得到广泛应用,但仍有优化算法、提高对复杂病变的分割能力以及降低对特定设备和软件依赖的改进空间.

3.2.2 结合多尺度特征提取技术

为缓解标注稀缺问题, Schutte 等^[41]采用了 Ding 等^[42]发布的乳腺超声图像数据集,引入了教师-学生模型架构来进行半监督训练,使用基于ResNet34编码器的LinkNet和FPN(feature pyramid network), LinkNet通过编码器-解码器结构和跳跃连接提取多尺度特征,FPN则构建特征金字塔并利用横向连接融合不同尺度特征.其中FPN则通过构建特征金字塔,能够检测不同大小的乳腺癌组织,具有更好的一致性和稳定性,在学生模型中准确率达到0.95.然而,该研究仍存在数据单一性、模型对比不足、半监督噪声敏感、临床指标缺失等缺点.随后的研究中 Ortega-Ruiz 等^[43]采用了来自乳腺癌语义分割(BCSS)挑战赛的数据集,通过引入DRD模块并融入了多尺度特征提取的思想,提出基于U-Net架构的DRD-U-Net模型,显著提高了乳腺癌组织分割的准确性和效率.为解决传统分割方法在分割乳腺超声图像时存在的伪边缘问题, 郭迎节等^[44]提出在Mask R-CNN算法中,加入了Mask预测分支结构,其主干网络采用ResNet-50和FPN,能够有效提取图像特征;通过RPN生成ROI推荐框,为后续分割任务提供区域信息;该模型实现5类(肿瘤、间质、炎症、坏死、其他)分割,覆盖病理分析的主要组织类型,在测试集的110幅图像上,其Dice相似系数达到0.91, IoU为0.84.但存在一些缺点,如炎症类别分割性能较低,缺乏病理医生评估和下游任务关联等.未来可以考虑引入焦点损失或自适应采样策略,联合病理专

家设计临床相关指标,链接至预后分析模型等.

3.2.3 注意力机制网络

结合注意力机制的乳腺癌超声图像分割方法通过引入空间或通道注意力模块,动态分配特征权重,使模型能够自适应聚焦于肿瘤区域的显著性特征,如边缘模糊区域、低对比度病灶或异质性结构;并通过增强对微小病变的敏感性和复杂边界的精细化建模,在处理超声图像常见的斑点噪声和弱边界问题时表现突出,为临床诊断提供了更可靠的自动化分析工具.

针对传统手动分割方法在一致性与专家经验依赖方面的局限性,以及现有分割网络计算复杂度高、难以在资源受限设备上部署的问题, Luo 等^[45]提出高效轻量级网络CBADUNet;该模型在编码阶段融合了CBAM注意力机制与特征蒸馏技术,通过注意力权重优化特征分布以增强关键特征提取能力,同时利用蒸馏技术强化长程依赖建模.解码阶段采用MBDS机制实现编码-解码特征的自适应融合,在不增加参数量的情况下提升特征表达能力.训练时MBDS通过多辅助分支提供监督信号优化特征融合,推理时则移除辅助分支以保持计算效率.实验表明,该模型仅需0.2M参数量(GFLOPs为0.51),可实现14.8FPS的实时分割性能,在资源受限设备上能准确分割病变区域.

另一方面,为了提高乳腺超声图像中乳腺结节分割的准确率, Chen 等^[46]提出基于混合自适应注意力模块(HAAM)的U-Net模型,用于超声中乳腺结节的分割,与简单的注意力机制相比,HAAM模块引入了更复杂的注意力机制,但可能需要更多的数据或调优才能更好地泛化到分割任务中.同样基于注意力引导的U-Net模型的还有文献^[47],其提出了用于乳腺癌分割并使用BUSI数据集进行实验验证,获得了0.940的精确度和0.891的召回率.该模型引入了残差Inception深度可分离卷积和混合池化层,但其复杂的架构使其预测过程难以解释和理解.在随后的研究中 Podda 等^[48]提出了一种全自动深度学习管道,通过多层迭代优化分割任务,在BUSI数据集上Dice相似系数为0.826. Huang 等^[49]利用边界渲染框架结合图卷积,解决US中病灶边界模糊或遮挡导致的分割不准确,在其自建数据集上获得了0.854的Dice相似系数和0.919的IoU. Chen 等^[50]引入级联卷积网络结合残差细化,解决了斑点噪声、异质结构和相似强度分布问题.

针对超声乳腺肿瘤图像分割任务中存在多尺度特征提取不足、特征融合能力有限以及全局信息捕获能

力弱等问题,张光^[51]系统研究了基于注意力学习的乳腺癌诊断关键技术,提出包括校正学习、多尺度稀疏Transformer、样本注意力加权参考编码学习及多重注意力融合特征学习等方法,有效应对乳腺超声图像中灰度分布不均、细节信息不足、类别不平衡等问题,显著提升了肿瘤分割与分类的精度与鲁棒性。Iqbal等^[52]针对该问题提出了MDA-Net,该模型对传统U-Net架构中固定感受野的局限性进行了改进,并引入多尺度融合(MF)模块和双注意力机制,显著提升了模型对病变区域的特征提取能力和分割精度。该网络不仅在多个超声图像数据集上表现出色,还在乳腺MRI数据集上验证了其跨模态的有效性,展现了广泛的适用性。Li等^[53]提出了U²-MNet用于乳腺癌分割,使用BUSI数据集进行研究,获得了0.8276的Dice相似系数、0.7317的IoU。Zhu等^[54]提出了SU-Next模型用于乳

腺肿瘤分割,在BUSI数据集上获得了0.6426的IoU和0.7740的Dice相似系数,该网络将U-Net编码阶段的最后两个卷积块替换为多层感知器结构,虽然这种修改提高了分割速度,但导致分割精度或质量的下降。

针对肿瘤形状不规则、轮廓不清晰、对比度低和固有噪声等问题,Umer等^[55]通过多尺度级联卷积和残差注意力机制的双解码器结构,解决固定感受野和单一解码器的问题,显著提升了分割精度。并在UDIAT数据集上取得了91.38%的Dice相似系数和87.76%的Recall;在BUSI数据集上,Dice相似系数为90.55%,Recall为88.46%。但模型复杂度较高,训练时间较长,且对超声图像的噪声和质量较为敏感。Hekal等^[56]采用Res U-Net作为主神经网络,结合U-Net架构并利用残差块和跳跃连接来解决深度网络中的梯度消失问题,提出DDA-AttResU-Net,图6为其内部结构视图。

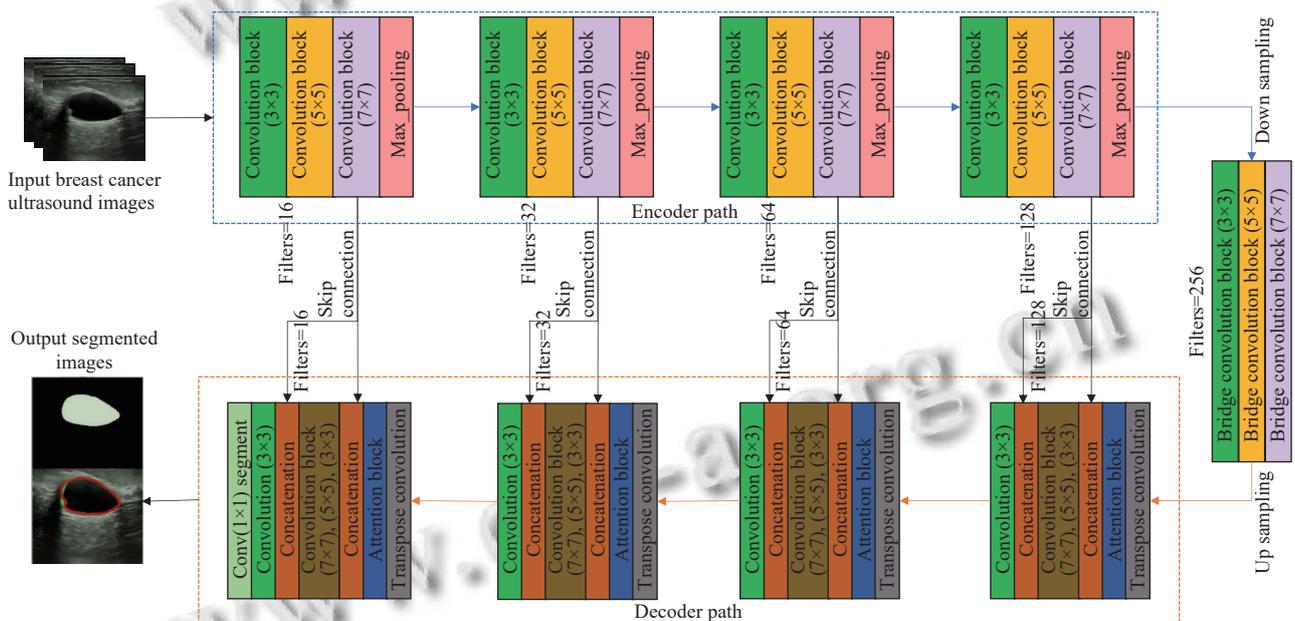


图6 文献[56]中DDA-AttResU-Net内部结构视图

该方法结合了双解码器注意力结构和注意力机制,在处理低对比度和有噪声的超声图像时表现出色。模型在BUSI数据集上取得Dice相似系数为92.92%、准确率为98.82%的优异成绩。研究具有良好的临床应用潜力,但该模型处理某些特殊形状或位置的肿瘤时可能效果不够理想。未来可进一步优化模型结构和参数,提高其在特定情况下的分割性能。

近年来,融合CNN局部特征提取能力与Swin Trans-

former全局建模优势的方法成为研究热点。Yang等^[57]提出CSwin-PNet金字塔网络,通过交互式通道注意力模块增强病变区域特征表示,结合补充特征融合模块优化弱响应区域检测,并采用边界检测模块提升分割边界质量,在乳腺超声图像分割中的Dice相似系数达到了87.25%。但该方法对边界模糊和强度不均匀的病变区域仍存在局限性。Zhu等^[58]构建的Swin-Net框架以Swin-Transformer为编码器,通过特征精炼模块(RLM)

降低特征噪声,利用多层次多尺度融合模块(HFM)实现特征聚合,取得了0.84的Dice相似系数.未来研究可通过优化数据增强和预处理策略,进一步提升模型对超声图像斑点噪声的鲁棒性.

针对传统分割方法在处理多尺度问题以及特征提取能力不足方面的缺陷,郭洪洋等^[59]基于Kaggle开源的乳腺结节超声影像数据集,以经典的U-Net架构为基础,通过注意力模块和金字塔结构增强了特征表达能力,提出MAU-Net模型并得到Dice相似系数和准确率分别为0.92和0.988,显著提升了模型对不同尺度肿瘤特征的提取能力,优化了分割精度.随后,汪慎文等^[60]提出了一种基于改进U-KAN的乳腺癌超声图像分割模型EAU-KAN.该模型通过整合高效多尺度注意力模块,显著增强了对图像细节的捕捉能力,并引入空洞空间卷积池化金字塔(ASPP)模块,有效扩展了网络的感受野,丰富了空间信息的表达,在乳腺癌超声图像分割中具有优越的性能.Sulaiman等^[61]提出结合注意力机制的U-Net模型,注意力机制使模型能够更精准地关注超声图像中的关键区域,从而助力乳腺癌的早期诊断,解决了传统乳腺癌诊断方法耗时高、昂贵且可能出现假阳性和假阴性结果的问题.经实验可得该模型准确率达到0.98,精确率为0.97,召回率为0.90,Dice相似系数为0.92.但该模型仍存在一些局限性,如对计算资源需求高、对数据集质量依赖性强以及模型可解释性有限等.

3.2.4 小结

综上所述,尽管基于深度学习的乳腺超声图像分割技术已取得突破性进展,但存在一些局限性:数据局限性,多数研究基于小型数据集,如882张图像,泛化

能力不足,且标注一致性影响模型评估.图像质量干扰,噪声、伪影、灰度不均等问题导致分割精度下降,边界模糊区域处理困难.模型缺陷,有过拟合风险,如U-Net3+训练集与验证集MIoU差异显著、计算效率低、对高质量标注数据依赖性强.

针对以上问题可以采取以下策略:数据增强与多模态融合,结合生成对抗网络扩充数据,整合MRI、CT等多模态影像提升分割鲁棒性;模型优化,开发更强大的Transformer变体以增强模型对病变区域及其边界信息的感知和提取能力;同时探索轻量化设计,例如引入MobileViT等高效架构,结合深度可分离卷积与Transformer优势,降低计算复杂度.借鉴MM-3DUnet^[62]的深度可分离卷积与通道扩展单元设计,优化特征提取效率,另外可以结合注意力机制与多尺度特征融合策略,可在保证分割精度的前提下,显著降低模型计算资源需求,推动乳腺病灶分割技术在资源受限场景中的广泛应用;引入后处理技术,如条件随机场优化边界细节;临床转化,构建多任务模型,如分割和分类、开发实时分割工具,推动与临床诊断流程的深度融合.表4汇总了上述研究的模型的主要改进思路和贡献、采用的数据集以及评价指标等.

3.3 磁共振成像(MRI)分割

3.3.1 经典CNN架构

CNN如U-Net在乳腺癌MRI分割中被广泛使用,其编码器-解码器结构通过下采样提取深层语义特征,再通过上采样恢复空间细节,结合跳跃连接融合多级特征以提升分割精度.这类模型擅长捕捉局部纹理和形状特征,但对小病灶或复杂边界的处理可能受限,需依赖数据增强或后处理优化.

表4 深度学习技术在乳腺超声图像上分割的研究总结

方法	年份	文献	数据集	主要贡献	主要改进思路	模型名称	最优DSC
CNN架构改进	2022	[38]	BUSI	实现乳腺病变的自动分割与诊断	分割与深度放射组学特征结合	CDAM	0.857
	2022	[35]	UDIAT	提高乳腺超声图像分割准确性	预训练模型结合迁移学习	VGG-Unet和MB-Unet	>0.8
	2023	[36]	自建	精准分割乳腺癌BI-RADS特征	增强多尺度特征捕捉	U-Net3+	—
	2024	[40]	自建	提出一个商用模型	引入人工智能辅助的半自动分割技术	S-Detect TM	—
	2024	[39]	BUSI、UDIAT	提升BUS分割精度,助力精准诊断	引入U-Net分割算法,优化特征提取与定位	U-Net分割模型	—
	2024	[37]	BUSI	实现了对BUS中肿瘤的自动分割	采用两种编码器-解码器架构进行乳腺肿瘤分割	DeepLabV3+	0.936
结合多尺度提取	2024	[43]	BCSS	多类别乳腺腺组织学图像的语义分割	引入DRD模块增强特征提取	DRD-UNet	—
	2024	[41]	BUID	用深度学习技术准确分割病变区域	引入教师-学生模型架构	FPN	0.9334
	2024	[44]	UDIAT、BUSI	解决BUS分割中边缘毛刺、常规分割方法难以得到有效支持临床诊断结果	提出了一种基于掩膜区域卷积神经网络(Mask R-CNN)的算法	Mask R-CNN	0.91

表4 深度学习技术在乳腺超声图像上分割的研究总结(续)

方法	年份	文献	数据集	主要贡献	主要改进思路	模型名称	最优DSC
结合注意力机制网络	2022	[47]	BUSIS、BUSI	解决BUS中不同大小肿瘤分割问题	残差交叉空间注意力引导	RCA-IUNet	0.937
	2023	[46]	BUSI	提高乳腺病变超声图像分割的准确性	引入自适应注意力模块和多尺度卷积	AAU-Net	0.775 1
	2022	[48]	BUSI	提出了一种全自动深度学习管道	多层迭代优化分割和分类	Custom UNet	0.825 9
	2022	[49]	自建	解决BUS中病灶边界模糊或遮挡导致分割不准确	边界渲染框架结合图卷积	Boundary-rendering network	0.854
	2022	[50]	BUSIS	解决斑点噪声、异质结构和相似强度分布问题	引入级联卷积网络结合残差细化	C-Net	0.793 5
	2022	[52]	UDIAT、BUSIS、RIDER	提出了一种多尺度双注意力网络	引入多尺度融合块和双注意力块	MDA-Net	0.918 5
	2023	[57]	自建数据集	充分利用Transformer的全局特征提取能力和自注意力机制	结合CNN和Swin Transformer的新型网络架构	CSwin-PNet	0.872 5
	2023	[51]	UDIAT、BHEDTW-C	解决灰度分布不均问题	校正学习和最优传输理论	—	—
	2023	[53]	BUSI	决乳腺超声图像肿瘤分割不准确问题	设计新模块提升局部特征与减少噪声影响	U ² -MNet	0.827 6
	2023	[54]	BUSI	提高了乳腺肿瘤病理图像的分割精度,为医生提供更可靠的诊断依据	引入SEM注意力模块	SU-Next	0.774
	2024	[58]	BUSIS等	解决噪声干扰问题,如斑点噪声、边界模糊、对比度低等	结合Transformer的全局建模能力和CNN的局部特征提取能力	Swin-Net	0.84
	2024	[45]	BUSI	实现了在乳腺癌超声图像分割任务中性能与计算复杂度之间的良好平衡	在编码器阶段融合注意力机制和特征蒸馏技术,在解码器阶段,引入多分支深度监督机制	CBADUNet	0.784 6
	2024	[55]	BUSI、UDIAT	解决超声图像中乳腺癌分割准确性低	多尺度卷积和双解码器	—	0.913 8
	2024	[59]	开源数据集	解决了超声乳腺肿瘤图像分割中预测尺度单一和信息丢失的问题	引入多重注意力机制与多尺度特征融合	MAU-Net	0.92
2024	[60]	BUSI	解决乳腺超声图像因边界模糊和形状、大小多样导致的分割不精确	引入EMA模块和ASPP模块,增强细节捕捉和多尺度特征提取	EAU-KAN	0.774 8	
2024	[61]	BUSI	提出一种用于乳腺癌分割的注意力U-Net模型	引入注意力机制,增强特征定位,优化U-Net架构	Attention U-Net	0.92	

当前可靠的自动化乳腺肿瘤分割技术尚未普及,而手动分割工作量大,限制了肿瘤体积在临床常规评估中的应用,并且肿瘤体积已被证实是预测患者生存的良好指标。为此,Hirsch等^[63]利用超过38000次检查的大规模数据集训练3D U-Net模型,优化网络架构和数据处理流程,最终实现了与放射科医生相当的分割性能。这一成果不仅简化了分割流程,还通过3D网络捕捉肿瘤的体积特征,避免了传统2D处理方法的局限性。尽管该模型在2D层面的评估中表现出色,但在3D体积分割的潜力尚未完全发挥,尤其是在处理小肿瘤或多中心肿瘤时仍有提升空间。

为更精准地测量乳腺癌磁共振成像中的体积和大小,Yue等^[64]利用Res U-Net卷积神经网络,通过引入

残差模块,有效解决了深层网络中的梯度消失问题,同时保留了U-Net在医学图像分割中的高效性,并实现对乳腺癌病灶的高精度体积和尺寸测量,解决手动测量乳腺癌体积和大小时耗时且存在人为误差的问题,提高了临床决策的效率和准确性。该模型的主要优点为高精度分割,其中Dice相似系数为0.89,并且能够在10–15 s内快速提供结果,显著减少了手动测量所需的时间。但该模型对微小病灶的分割精度不足,易出现漏检情况;且算法存在一定的假阳性问题。与Yue等^[64]的方向类似,Zhu等^[65]也将研究方向放在对乳腺病变的自动化分割以减少人工标注的繁琐性等问题的探究上,采用2823名患者的数据集,结合多参数磁共振成像的动态对比增强成像(DCE)和弥散加权成像(DWI)序

列,开发了基于 VNet 和 Attention U-Net 的分割模型.其中 VNet 模型在 DCE 序列上表现出色, *Dice* 相似系数达到 0.860, 准确率为 0.867, 召回率为 0.853; 而 Attention U-Net 则在 DWI 序列上展现了良好的分割性能, *Dice* 相似系数为 0.829. 但是 VNet 在处理复杂三维数据时表现出较高的计算需求, 同时 Attention U-Net 对小病变的分割效果可能受限, 结合多参数 MRI 序列的分割方法能够有效提升乳腺病变的自动化分割效果.

Yue 等^[66]提出基于 3D U-Net 卷积神经网络的自动分割方法, 用于乳腺癌病变区域的分割. 该方法通过迭代标签工作流优化分割精度, 在 516 例乳腺癌患者的 MRI 图像数据集上, 该模型的平均 *Dice* 相似系数达到 0.89. 此外, 该方法在大规模样本分析中具有较强的可扩展性, 能够为后续的影像组学分析提供高质量的 ROI. 然而, 该模型对数据分布的依赖性较强, 可能对小样本或罕见病变的泛化能力有限. 同样具有该问题的还有文献^[67], 其基于 3D U-Net 的深度学习框架, 通过级联 3D U-Net 网络实现对乳腺、FGT 及血管的自动化分割, 经实验表明, 该方法在乳腺分割 (*Dice* 相似系数为 0.92)、FGT 分割 (*Dice* 相似系数为 0.86) 任务上均取得较高精度, 但血管分割 (*Dice* 相似系数为 0.65) 的准确性仍有进一步优化的空间.

为解决 Lew 等^[67]的遗留问题, Pekis 等^[68]通过多机构验证能够分割包括皮肤、脂肪、纤维腺体、血管、胸壁和肿瘤. 其采用 Bi-MIP 肿瘤定位技术, 结合轴位和矢状位的最大强度投影图像, 利用预训练的 2D 目标检测网络进行肿瘤定位, 建立 3D 肿瘤边界框. 同时, 运用 3D U-Net 和残差 U-Net 架构对多种组织进行语义分割, 并通过组织-组织相互作用的启发式规则减少误分割. 该研究为乳腺癌的临床诊断和治疗提供了更全面、准确的影像学信息, 具有重要的临床应用价值. Sonia 等^[69]基于 RIDER Breast MRI 数据集, 通过集成多种预训练骨干网络来优化 U-Net 模型的性能. 经实验, U-Net 结合 ResNet-50 的模型表现最优, 其 *IoU* 和 *Dice* 相似系数分别达到 0.7054 和 0.8273. 但在小样本数据集上仍存在过拟合风险. 未来研究可进一步探索深度学习模型在有限数据条件下的适应性, 并尝试融合手工特征与深度特征以提升乳腺癌预后模型的性能.

3.3.2 结合注意力机制网络

注意力机制通过动态加权特征图, 使模型聚焦于病灶区域并抑制背景噪声. 在乳腺癌分割中, 注意力可强化肿瘤-腺体边界、区分高异质性区域, 并解决类别

不平衡问题. 例如, 在 U-Net 跳跃连接中嵌入注意力模块, 能精准传递关键位置信息, 减少假阳性的同时提升复杂病例的分割鲁棒性. Park 等^[70]提出基于弱标注的 3D 分割方法, 用于动态对比增强磁共振成像中的乳腺癌分割. 该方法采用自动精化流程从弱标注生成 3D 分割掩码, 并由放射科医生验证修正以确保数据质量. 研究采用 3D U-Net Transformer 架构, 结合 U-Net 的编码器-解码器优势与 Transformer 的全局上下文建模能力. 为增强模型鲁棒性, 应用了包括随机仿射变换在内的数据增强技术, 并采用 *Dice* 损失和 AdamW 优化器进行训练. 评估结果显示, 该方法在全乳腺和 ROI 分割上的 *Dice* 相似系数分别达到 0.75 和 0.89, 放射科医生的平均视觉评分为 3.4 (四分制). 然而, 模型对非肿块型和多灶性病变的分割性能仍有提升空间, 这可能与病变形态复杂性及弱标注的局限性有关. 该研究为乳腺癌自动分割提供了新思路, 未来可通过优化模型架构、融合多参数 MRI 信息, 进一步提升其在临床筛查和治疗监测中的应用价值.

Feng 等^[71]旨在解决从低分辨率、高噪声医学图像中准确分割肿瘤区域的难题, 针对现有深度学习方法在图像预处理过程中可能引入的图像失真和特征丢失问题, 以及端到端模型缺乏可解释性等挑战, 基于扩散去噪方法和参数共享注意力模块 (PSA) 提出扩散模型 PGDiffSeg, 利用扩散模型的去噪能力来解决医学图像分割中的噪声问题, 并生成高精度的分割结果. 并且在研究中引入先验知识引导策略, 模型能够模拟医生的决策过程, 从而更精准地定位肿瘤位置; 该模型在 MRI 和超声数据集上均优于或达到了当前最先进的分割方法的水平. 该研究还首次探讨了扩散模型在乳腺癌分割中的可解释性, 通过可视化中间结果和注意力位置, 增强了模型的透明度和可信度. 但该模型也存在一些局限性, 例如采样时间较长, 限制了其在实际应用中的效率; 此外, 模型的复杂结构可能导致训练和推理过程中的计算开销较大. 类似地, Zhao 等^[72]针对 DCE-MRI 乳腺肿瘤分割提出 SwinHR 模型, 整合血流动力学与时空信息. 该模型采用 Swin Transformer 结合重参数化大核的双分支架构, 通过主分支获取肿瘤边界, 同时利用注意力分支抑制背景干扰. 尽管存在计算复杂度较高的局限, 但其优异的泛化能力和较低的假阳性率展现了重要的临床价值.

近年来,基于扩散模型的生成式分割方法在医学图像分割领域取得较好的效果,例如 Wu 等^[73]提出基于扩散概率模型(DPM)的医学图像分割新方法 Med-SegDiff, 其将 DPM 应用于通用医学图像分割任务. 该方法设计了动态条件编码策略, 通过迭代融合当前分割掩膜与原始图像特征, 动态增强目标区域注意力; 并引入特征频率解析器抑制高频噪声, 显著提升分割精度. 在 MRI 脑肿瘤及超声甲状腺结节等 3 个不同模态的医学分割任务中, MedSegDiff 均超越现有最先进方法, Dice 相似系数平均提升 1.4%, 验证了 DPM 在医学图像分割中的潜力与泛化能力, 为后续乳腺病灶分割研究提供了重要思路.

3.3.3 小结

综上所述, 当前研究通过改进网络架构、引入注意力机制及多尺度特征融合, 基于深度学习的乳腺癌 MRI 分割技术取得了重大突破, 在临床应用中显示出显著的优势. 卷积神经网络体系结构, 特别是 U-Net 及其变体, 通过其编码器-解码器结构和跳跃连接有效地集成了多尺度特征, 大大提高了肿瘤边界和局部组织的分割精度. 结合注意力机制的改进模型采用动态特

征加权来精确聚焦病变区域, 同时有效抑制背景干扰, 在复杂边界分割和类不平衡处理中表现出优异的性能. 这些技术的进步不仅显著提高了分割精度, 而且为临床诊断和治疗规划提供了可靠支持.

但仍存在一些局限性: 小病灶与复杂形态, 多数模型对小肿瘤(如<5 mm)或非肿块型病变分割效果欠佳, 易出现漏检或假阳性; 存在数据依赖性且模型泛化性较差, 研究多基于单中心或中等规模数据集, 跨机构、多设备数据的泛化能力不足; 在计算效率与实用性方面 3D 模型(如 VNet) 计算成本高, 难以满足临床实时需求; 并且弱标注方法虽节省人力, 但可能影响复杂病变, 如多灶性肿瘤的分割精度.

针对以上不足, 可以采取以下策略: 数据扩展, 构建多中心、多模态(如 T2 加权、DWI) 大规模数据集, 并引入去噪与强度校正技术; 临床整合, 推动自动化分割技术与影像组学结合, 辅助肿瘤分期、治疗监测等临床应用; 采取轻量化设计, 优化 3D 网络的计算效率, 探索实时分割方案. 表 5 汇总了上述研究的模型的主要改进思路和贡献、采用的数据集、所提出的模型、年份以及评价指标.

表 5 深度学习技术在 MRI 上分割的研究总结

年份	文献	数据集	主要贡献	主要改进思路	模型名称	最优DSC
2021	[63]	自建数据集	实现乳腺 MRI 肿瘤自动化分割, 达到放射科医生水平	使用大规模数据集训练, 优化 3D U-Net 架构	3D U-Net	0.77
2022	[64]	自建数据集	自动分割乳腺癌体积和大小, 减少手动测量误差	结合 Res U-Net 网络, 优化分割精度和效率	Res U-Net	0.89
2022	[65]	自建数据集	实现乳腺病变的自动化分割, 减少人工标注的繁琐性	结合多参数 MRI 序列 (DCE 和 DWI) 进行病变分割	VNet 和 Attention U-Net	0.86
2024	[70]	自建数据集	降低标注成本, 提高分割效率	引入弱标注策略, 结合自动精化和人工修正, 提升标注效率与质量	3D U-Net Transformer	0.89
2024	[68]	自建数据集	解决乳腺 MRI 多组织分割问题	利用 2D 目标检测器进行 3D 定位, 结合 3D U-Net 分割, 组织接触启发式整合	—	0.74
2024	[67]	Duke-Breast Cancer-MRI dataset	提供公开可用的乳腺 MRI 分割数据集和模型	明确标注血管, 提供清晰的定量乳腺密度定义	—	0.92
2024	[69]	RIDER Breast MRI dataset	提高乳腺癌 MRI 图像分割精度, 辅助精准诊断	结合多种预训练骨干网络优化 U-Net 分割性能	U-Net	0.8273
2024	[72]	自建数据集 (未公开)	利用 Swin Transformer 与层次化重参数化大核架构, 显著提高了乳腺肿瘤分割的准确性和鲁棒性	同时引入 Swin Transformer 和 H-RLK, 来捕捉长距离依赖关系和多尺度特征	SwinHR	0.8121
2024	[71]	BUSI 等	将扩散去噪方法与参数共享注意力机制相结合, 引入先验知识引导策略	在扩散去噪的过程中, 引入并行管道与参数共享注意力模块 (PSA), 实现噪声特征与语义信息的深度融合, 从而提升去噪与分割的准确性	PGDiffSeg	0.75

3.4 多模态融合

在乳腺病灶分割领域, Peng 等^[74]基于 T1、T1c 两

种模态的 MRI 图像构建的 IMIIN 模型, 引入了双向请求-供给信息交互模块 (BD-RSIIM), 以 Dense-VoxNet

为主体神经网络架构,融合空间金字塔池化(ASPP)模块以及双流解码器,实现多尺度特征提取与边界细节的精细捕捉,来实现不同模态间信息的高效交互与相互验证.经实验在数据集的 T1c 和 T1 模态下,该模型的平均 *Dice* 相似系数分别达到 90.49% 和 85.07%,灵敏度分别为 93.08% 和 89.23%,模型对小肿瘤区域的识别与边界分割效果较好,且在不同尺寸、视角的肿瘤分割任务中均能稳定输出高质量结果,展现出优异的泛化性能和显著的临床价值,能够协助发现医师易遗漏的肿瘤病灶.但模型对多模态数据的对齐精度要求较高,增加了数据预处理的复杂性,并且网络架构相对繁杂且参数量庞大,在处理 3D 大规模目标时,输入数据块尺寸的扩增可能引发网络训练的可行性问题.

针对 Peng 等^[74]遗留的问题, Anusha 等^[75]提出 AMFFR-Net,通过融合乳腺 X 光、MRI 及超声影像特征实现精准病灶分割.该网络采用多尺度自注意力模块(MSSAM)和自适应特征融合与细化模块(AFFR),实现多模态特征的高效提取与协同优化. MSSAM 通过 5×5、3×3 稀疏卷积及标准卷积提取多尺度特征,结合通道注意力(MSCAM)和空间注意力(ASAM)机制,利用全局平均池化和卷积操作生成注意力权重,增强特征选择性. AFFR 模块采用三级协同优化架构实现多模态特征融合:首先,变形子模块基于空间变换网络(STN)生成变形场以解决模态间空间错位问题;其次,融合子模块通过特征金字塔结构对空间对齐后的多尺度特征进行自适应加权整合;最后,细化子模块利用置信度图与前两个模块形成反馈机制,重点优化边界区域的分割精度.通过级联式特征传递与参数共享机制,3个子模块实现端到端的协同优化,显著提升了多模态特征的互补性与分割性能.实验表明,该方法在乳腺 X 光图像分割取得最优 *Dice* 相似系数为 95.93%,显著优于基准模型.研究同时指出需平衡模型复杂度与计算效率,建议通过模块精简与硬件加速优化推理速度.该框架可扩展至 PET-CT 等模态,为乳腺癌智能诊断提供技术支持.

随后, Iqbal 等^[76]针对乳腺癌肿瘤分割中不规则形状和模糊边界的挑战,提出基于 Swin Transformer 和 U-Net 的双编码器网络 BTS-ST.该模型通过 3 个关键模块提升性能:空间交互模块(SIB)增强全局建模能力,特征压缩模块(FCB)保留小肿瘤特征,关系聚合模块(RAB)实现全局-局部特征融合.实验显示, BTS-ST

在多个数据集上达到最优性能, *Dice* 相似系数为 0.908,但存在计算复杂度较高的问题.未来可通过轻量化设计进一步优化模型效率.

针对传统手动分割乳腺癌肿瘤时耗时且易受主观因素影响的问题, Xiong 等^[77]开发了基于经典的 U-Net 网络架构的超声自动分割框架 uASF,结合了三维 Res U-Net 和基于 U-Net 改进的新型网络 MRI 自动分割框架 mASF. uASF 与 mASF 在测试集上 *Dice* 相似系数分别为 0.91 和 0.73, mASF 略低于 uASF 表现,但仍具有较高的分割精度.在该研究中超过一半的自动分割结果无需任何手动调整,显著减少了手动干预的频率和工作量,从而提高了分割效率;但部分自动分割结果仍需手动检查和微调,这表明当前的自动分割框架尚未完全实现自动化.在未来的研究中可以进一步优化 MRI 分割框架以提升其准确性和鲁棒性,以及结合新的深度学习技术和多中心数据集进一步提高自动分割的效率和精度;还可以探索更多模态影像的融合,可能会为多模态影像分析带来更显著的性能提升,为乳腺癌的无病生存期预测提供更有力的支持.

Shah 等^[78]利用 BUSI 数据集中的乳腺超声图像以及 Mini-DDSM 数据集中的乳腺钼靶图像及其对应的患者年龄和乳腺密度等临床数据,融合多模态信息提出多模态乳腺癌检测网络 MMDCNet.其采用 DenseNet 系列(如 DenseNet121、DenseNet201)、EfficientNetB0、VGG16 等深度学习模型作为主干网络来提取图像特征,并结合自定义 FCN 处理临床数据,同时引入了 SE (squeeze-and-excitation) 块等注意力机制以增强特征提取能力,使模型能够更准确地识别关键特征. MMDCNet 在 BUSI 数据集上达到了 97.05% 的准确率,在 Mini-DDSM 数据集上达到了 90.87% 的准确率,显著优于单一模态的检测方法.然而,该模型在数据融合和预处理方面仍存在一定的复杂性,且对数据质量和完整性要求较高.在未来的研究中进一步优化多模态数据融合策略,提升模型的性能,并扩大研究范围,以适应更多数据集和临床应用场景.

通过融合跨模态自监督学习和对比学习,可有效应对在多模态医学图像分割领域数据质量问题.例如 Jing 等^[79]提出的 HyCon 模型,是以超图对比学习网络为核心提出跨模态对比学习模型,采用两阶段技术路线实现多模态医学图像分割.第 1 阶段,通过 CycleGAN 模型以序列自监督学习方式学习跨模态特征;第 2 阶

段,超图对比学习网络构建超图结构,将不同模态图像特征作为顶点,基于欧氏距离采用K-最近邻方法构建超边,形成跨模态关联。通过定义超边连接顶点为正样本对、非连接顶点为负样本对,设计对比损失函数优化特征空间分布,实现跨模态拓扑对齐。并通过顶点-超边消息传递机制捕捉高阶关系,并设计拓扑混合蒸馏模块,将教师模型学习到的拓扑信息、上下文特征和高阶关系知识蒸馏至学生MLP模型。该模型在Lung和BraTS数据集上的实验表明,仅需5%–10%标注数据即可实现显著性能提升,较现有方法平均提升4.72%,验证了其在有限标注下跨模态特征表示与分割性能的

优越性。其在多模态乳腺病灶分割中的潜在应用价值尤为突出。

综上所述,多模态技术通过整合不同成像模态的互补信息,显著提升了分割的精度、鲁棒性以及临床应用的实用性。研究者们构建了多种复杂的神经网络架构,例如Peng等^[74]的IMIIN模型、Xiong等^[77]的ASF框架、Shah等^[78]的MMDCNet以及Anusha等^[75]的AMFFR-Net,实现了多模态数据的有效融合和特征提取,为乳腺癌的检测和诊断提供了有力的技术支持。表6汇总了上述研究的Dice相似系数、年份、模态和模型等。

表6 多模态融合技术在乳腺病灶分割的研究总结

文献	数据集	模态	年份	模型	主要贡献	最优DSC
[74]	自建数据集	MRI下的T1、T1c	2022	IMIIN	解决以往多模态乳腺肿瘤分割方法未能有效融合多模态信息,易融合干扰信息等问题	T1c: 0.9049 T1: 0.8507
[75]	CBIS-DDSM、INbreast	MG、MRI	2025	AMFFR-Net	提出的多模态特征对齐和协同优化模块	0.9593
[76]	CBIS-DDSM等	US、MG、MRI	2023	BTS-ST	提出Swin Transformer和U-Net的新型双编码器网络BTS-ST,引入多模块解决Swin Transformer局限性	CBIS-DDSM: 0.908
[77]	自建数据集	US、MRI	2024	uASF、mASF	解决了传统手动分割乳腺癌耗时且易受主观影响的问题	uASF: 0.91 mASF: 0.73
[78]	Mini-DDSM、BUSI	US、MG	2025	MMDCNet	图像结合临床数据,整合多模态信息	BUSI: 0.9705 Mini-DDSM: 0.9087

但当前研究仍存在局限性:(1)数据预处理的复杂性:多模态数据的对齐和预处理要求较高,增加了数据准备的难度和复杂性。例如,Peng等^[74]的模型对多模态数据的对齐精度要求极高。(2)模型复杂度与计算效率:部分模型架构较为复杂,参数量较大。例如,IMIIN模型在处理大规模3D数据时可能面临训练可行性问题。同时,模型的计算效率仍有待优化,如AMFFR-Net需要在模型复杂度与推理速度之间寻求更好平衡。(3)自动化程度不足:尽管自动分割框架显著降低了手动干预的频率,但部分自动分割结果仍需手动检查和微调,尚未完全实现自动化。例如,Xiong等^[77]的ASF框架仍需进一步提升自动化程度。(4)数据融合与预处理的复杂性:多模态数据融合和预处理过程较为复杂,且对数据质量和完整性要求较高。例如,MMDCNet在数据融合方面存在一定的复杂性。(5)模型泛化能力的挑战:虽然部分模型在特定数据集上表现出色,但在不同数据集或临床场景下的泛化能力仍需进一步验证。例如,mASF的准确性和鲁棒性有待进一步提升。

未来可采取以下策略进行改进:(1)优化多模态数据融合策略:进一步简化数据预处理流程,提高多模态

数据对齐的精度和效率,降低数据预处理的复杂性。(2)提升模型的自动化程度:结合新的深度学习技术和优化算法,进一步提高自动分割框架的准确性和鲁棒性,减少手动干预的需求,实现更高效的自动化分割。(3)增强模型的泛化能力:通过扩大研究范围,纳入更多中心的数据集,验证模型在不同临床场景下的表现,提升模型的泛化能力。(4)探索更多模态影像的融合:结合PET-CT等新型影像模态,进一步丰富多模态数据的种类,为乳腺癌的检测和诊断提供更全面的信息支持。(5)提高计算效率:通过模块化精简和硬件加速等技术,优化模型的计算效率,提升模型的实用性和临床应用价值。(6)拓展临床应用范围:实时性优化以及边缘计算部署,将多模态技术应用于乳腺癌的无病生存期预测等更广泛的临床应用领域,为患者的治疗和预后提供更有力的支持。

4 总结与展望

4.1 面临的挑战

本文系统地梳理了深度学习技术在乳腺影像分割领域,包括乳腺X光摄影(MG)、磁共振成像(MRI)及

超声 (US) 等模态的研究进展, 并深入探讨了各模态模型的性能优势与存在的局限。尽管当前的分割方法在乳腺癌的检测任务上已取得了一定的成效, 但在实际应用中仍需解决以下问题。

4.1.1 技术方面

(1) 模型的泛化性有待提高: 在不同的数据集和临床环境中当前的算法稳定性不足, 尤其是在低信噪比图像、多中心数据集或面对罕见病变时, 其性能波动较大。例如, MG 领域的 FrCN 模型^[22]仅在特定的数据集上得到了验证, 而 US 领域的 MAU-Net^[59]对设备噪声较为敏感。

(2) 小尺寸病灶及复杂边界的分割精度需进一步提升: 在 MG 中对于直径小于 5 mm 的微小肿瘤、MRI 中的非肿块样病变以及 US 中的低对比度病灶, 当前的分割方法仍存在漏检或误分割的问题, 对于边界模糊区域的精细建模需要进一步优化。

(3) 计算效率和实时性存在挑战: 例如 MDA-Net^[52]这类复杂模型由于计算负荷较高, 限制了它们在资源受限的设备或需要快速诊断的场景中的应用。

(4) 多模态数据的协同分析能力不足: 目前的研究成果多集中于单一模态, 对于跨模态特征的整合及联合分割的研究尚不充分, 这限制了综合诊断效能的发挥。

(5) 数据标注的依赖性及成像风格的差异: 获取高质量的标注数据成本较高, 且不同成像设备导致的 US 斑点噪声或不同染色标准引起的 MG 对比度差异, 均可能影响模型的泛化能力。

4.1.2 临床应用方面

(1) 实时分割面临计算资源和速度的双重挑战。例如, 一些复杂的 Transformer 架构虽然在分割精度上具有优势, 但计算复杂度较高, 难以满足实时性要求^[80]。

(2) 边缘计算部署需要在本地设备上对模型推理, 这要求模型不仅具有高精度, 还需要具备低计算复杂度和低内存占用。

4.2 问题解决方案展望

针对这些问题, 未来的研究方向可以从以下几个方面进行探索。

4.2.1 技术方面

(1) 创新和优化算法与模型架构: 开发轻量级网络结构, 例如将 MobileNets^[81]与 UNet++ 结合, 并引入动态推理机制, 在保证分割精度的同时提高计算效率。另外可以改进模型加强注意力机制, 如 Transformer 与

CBAM (convolutional block attention module)^[82]的融合, 并结合多尺度特征融合, 例如空洞金字塔与残差连接, 以提升对小尺寸病灶及复杂边界的定位能力。

(2) 多模态数据融合与三维重建技术^[83]的应用: 构建跨模态的协同分析框架, 将 AMFFR-Net^[75]扩展至 MG-US 模态, 整合多参数 MRI 与超声纹理信息, 以增强对病变特征的全面表征。同时, 推动三维分割技术, 级联 3D U-Net 在 MRI 体积测量与 MG 高分辨率图像中的应用。

(3) 提高模型的泛化性和鲁棒性: 采用领域自适应和自监督预训练方法^[84], 减轻由数据风格差异引起的问题; 结合弱监督学习和半自动标注技术, 减少对全量标注数据的依赖。

4.2.2 临床应用方面

(1) 实时分割: 为解决这一问题, 可以采用多种轻量化设计。例如, MobileViT 通过结合 CNN 和 Transformer 的优势, 在保持高分割精度的同时显著减少了计算复杂度。此外, 可以应用模型压缩和加速技术, 如知识蒸馏和量化。这些方法通过将复杂模型的知识迁移到轻量级模型中, 或通过减少模型参数的精度, 实现在实时性要求下的高效分割。

(2) 边缘计算部署应用: 可采用 Mobile-UNETR, 其通过轻量级的 CNN-Transformer 混合架构, 实现了在边缘设备上的高效部署。另外还可以将联邦学习应用在边缘计算中。通过在多个边缘设备上协作训练模型, 联邦学习可以在不共享原始数据的情况下提高模型的泛化能力。这种方法不仅保护了数据隐私, 还减少了对中心服务器的依赖, 提高了系统的可扩展性^[85]。

(3) 模型的临床转化与系统集成应用: 优化模型以提高其实时性, 开发适用于临床超声或移动设备的嵌入式^[86]诊断工具。构建多任务系统, 如联合分割-分类-预后模型, 并结合放射组学特征与临床信息, 以提高诊断决策的准确性。

随着深度学习与多模态影像分析技术的进一步融合, 乳腺影像分割领域预期将突破现有的技术瓶颈, 为乳腺癌的早期诊断、精确治疗及预后评估提供更加智能化和高效率的解决方案。

参考文献

- 1 Bray F, Laversanne M, Sung H, *et al.* Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality

- worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*, 2024, 74(3): 229–263. [doi: [10.3322/caac.21834](https://doi.org/10.3322/caac.21834)]
- 2 Luo LY, Wang X, Lin Y, *et al.* Deep learning in breast cancer imaging: A decade of progress and future directions. *IEEE Reviews in Biomedical Engineering*, 2025, 18: 130–151. [doi: [10.1109/RBME.2024.3357877](https://doi.org/10.1109/RBME.2024.3357877)]
 - 3 Abunasser BS, Al-Hiealy MRJ, Zaout IS, *et al.* Convolution neural network for breast cancer detection and classification using deep learning. *Asian Pacific Journal of Cancer Prevention*, 2023, 24(2): 531–544. [doi: [10.31557/APJCP.2023.24.2.531](https://doi.org/10.31557/APJCP.2023.24.2.531)]
 - 4 Yeh JM, Lowry KP, Schechter CB, *et al.* Breast cancer screening among childhood cancer survivors treated without chest radiation: Clinical benefits and cost-effectiveness. *JNCI: Journal of the National Cancer Institute*, 2022, 114(2): 235–244. [doi: [10.1093/jnci/djab149](https://doi.org/10.1093/jnci/djab149)]
 - 5 Sabtu SN, Abdul Sani SF, Bradley DA, *et al.* A review of the applications of Raman spectroscopy for breast cancer tissue diagnostic and their histopathological classification of epithelial to mesenchymal transition. *Journal of Raman Spectroscopy*, 2020, 51(3): 380–389. [doi: [10.1002/jrs.5774](https://doi.org/10.1002/jrs.5774)]
 - 6 Abo-El-Rejal A, Ayman SE, Aymen F. Advances in breast cancer segmentation: A comprehensive review. *Acadlore Transactions on AI and Machine Learning*, 2024, 3(2): 70–83. [doi: [10.56578/ataiml030201](https://doi.org/10.56578/ataiml030201)]
 - 7 Alam T, Shia WC, Hsu FR, *et al.* A comprehensive review: Efficacy of segmentation and machine learning, deep learning techniques in breast tumor detection. *TechRxiv*, 2025. [doi: [10.36227/techrxiv.173609860.03508397/v1](https://doi.org/10.36227/techrxiv.173609860.03508397/v1)]
 - 8 Sutjiadi R, Sendari S, Wahyu HH, *et al.* Deep learning for segmentation and classification in mammograms for breast cancer detection: A systematic literature review. *Advanced Ultrasound in Diagnosis and Therapy*, 2024, 8(3): 94–105. [doi: [10.37015/AUDT.2024.230051](https://doi.org/10.37015/AUDT.2024.230051)]
 - 9 Moreira IC, Amaral I, Domingues I, *et al.* INbreast: Toward a full-field digital mammographic database. *Academic Radiology*, 2012, 19(2): 236–248. [doi: [10.1016/j.acra.2011.09.014](https://doi.org/10.1016/j.acra.2011.09.014)]
 - 10 Suckling J. The mammographic image analysis society digital mammogram database. *Proceedings of the 1994 Excerpta Medica International Congress*. 1994. 375–378.
 - 11 Muštra M, Štajduhar A. Segmentation masks for the mini-mammographic image analysis society (mini-MIAS) database. *IEEE Consumer Electronics Magazine*, 2020, 9(5): 28–33. [doi: [10.1109/MCE.2020.2986799](https://doi.org/10.1109/MCE.2020.2986799)]
 - 12 Heath M, Bowyer K, Kopans D, *et al.* The digital database for screening mammography. *Proceedings of the 5th International Workshop on Digital Mammography*. Toronto, 2001. 212–218.
 - 13 Lee RS, Gimenez F, Hoogi A, *et al.* A curated mammography data set for use in computer-aided detection and diagnosis research. *Scientific Data*. 2017, 4: Article No. 170177.
 - 14 Yap MH, Pons G, Martí J, *et al.* Automated breast ultrasound lesions detection using convolutional neural networks. *IEEE Journal of Biomedical and Health Informatics*, 2018, 22(4): 1218–1226. [doi: [10.1109/JBHI.2017.2731873](https://doi.org/10.1109/JBHI.2017.2731873)]
 - 15 Al-Dhabyani W, Gomaa M, Khaled H, *et al.* Dataset of breast ultrasound images. *Data in Brief*, 2020, 28: 104863. [doi: [10.1016/j.dib.2019.104863](https://doi.org/10.1016/j.dib.2019.104863)]
 - 16 Zhao XM, Liao YH, Xie JH, *et al.* BreastDM: A DCE-MRI dataset for breast tumor image segmentation and classification. *Computers in Biology and Medicine*, 2023, 164: 107255. [doi: [10.1016/j.combiomed.2023.107255](https://doi.org/10.1016/j.combiomed.2023.107255)]
 - 17 冯钰. 基于多尺度特征交互的医学图像分割算法研究 [硕士学位论文]. 上海: 华东师范大学, 2024.
 - 18 Yu JH, Jiang YN, Wang ZY, *et al.* Unitbox: An advanced object detection network. *Proceedings of the 24th ACM International Conference on Multimedia*. Amsterdam: ACM, 2016. 516–520.
 - 19 胡雅雯. 基于深度学习的医学图像分割算法研究 [硕士学位论文]. 兰州: 兰州大学, 2024.
 - 20 董洁. 融合图像恢复技术的医学图像分割算法 [硕士学位论文]. 上海: 华东师范大学, 2024.
 - 21 Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 1980, 36(4): 193–202. [doi: [10.1007/BF00344251](https://doi.org/10.1007/BF00344251)]
 - 22 Al-Antari MA, Al-Masni MA, Kim TS. Deep learning computer-aided diagnosis for breast lesion in digital mammogram. In: Lee G, Fujita H, eds. *Deep Learning in Medical Image Analysis: Challenges and Applications*. Cham: Springer, 2020. 59–72.
 - 23 Alkhaleefah M, Tan TH, Chang CH, *et al.* Connected-SegNets: A deep learning model for breast tumor segmentation from X-ray images. *Cancers*, 2022, 14(16): 4030. [doi: [10.3390/cancers14164030](https://doi.org/10.3390/cancers14164030)]
 - 24 Zhou KC, Li W, Zhao DZ. Deep learning-based breast region extraction of mammographic images combining pre-processing methods and semantic segmentation supported by DeepLabV3+. *Technology and Health Care*, 2022, 30(S1): 173–190.
 - 25 Deb SD, Jha RK. Segmentation of mammogram images using deep learning for breast cancer detection. *Proceedings of the 2nd International Conference on Image Processing and*

- Robotics (ICIPRob). Colombo: IEEE, 2022. 1–6.
- 26 Shaaban SM, Nawaz M, Said Y, *et al.* An efficient breast cancer segmentation system based on deep learning techniques. *Engineering, Technology & Applied Science Research*, 2023, 13(6): 12415–12422.
- 27 El-Banby GM, Salem NS, Tafweek EA, *et al.* Automated abnormalities detection in mammography using deep learning. *Complex & Intelligent Systems*, 2024, 10(5): 7279–7295.
- 28 Hoseini F, Mirzaei A. Segmentation of breast cancer masses in mammography images using deep convolutional neural network (DCNN). <https://www.researchsquare.com/article/rs-4741063/v1>. [2025-03-17].
- 29 Tiryaki VM, Kaplanoglu V. Deep learning-based multi-label tissue segmentation and density assessment from mammograms. *IRBM*, 2022, 43(6): 538–548. [doi: [10.1016/j.irbm.2022.05.004](https://doi.org/10.1016/j.irbm.2022.05.004)]
- 30 Jha S, Ahmad S, Arya A, *et al.* Ensemble learning-based hybrid segmentation of mammographic images for breast cancer risk prediction using fuzzy C-means and CNN model. *Journal of Healthcare Engineering*, 2023, 2023(1): 1491955. [doi: [10.1155/2023/1491955](https://doi.org/10.1155/2023/1491955)]
- 31 Sreevani M, Latha R. A deep learning with metaheuristic optimization-driven breast cancer segmentation and classification model using mammogram imaging. *Engineering, Technology & Applied Science Research*, 2025, 15(1): 20342–20347.
- 32 Fu XJ, Cao H, Hu HX, *et al.* Attention-based active learning framework for segmentation of breast cancer in mammograms. *Applied Sciences*, 2023, 13(2): 852. [doi: [10.3390/app13020852](https://doi.org/10.3390/app13020852)]
- 33 徐旺旺, 许良凤, 李博凯, 等. TransAS-UNet: 融合 Swin Transformer 和 UNet 的乳腺癌区域分割. *中国图象图形学报*, 2024, 29(3): 741–754.
- 34 Kljajić J, Đukić N, Lazić I, *et al.* SegFormer model in mammography lesion segmentation: A study on the impact of GLAM saliency maps. *Proceedings of the 11th International Conference on Electrical, Electronic and Computing Engineering (IcETRAN)*. Nis: IEEE, 2024. 1–6.
- 35 Ben Ahmed I, Ouarda W, Ben Amar C. Hybrid UNET model segmentation for an early breast cancer detection using ultrasound images. *Proceedings of the 14th International Conference on Computational Collective Intelligence. Hammamet: Springer*, 2022. 464–476.
- 36 Alam T, Shia WC, Hsu FR, *et al.* Improving breast cancer detection and diagnosis through semantic segmentation using the UNet3+ deep learning framework. *Biomedicines*, 2023, 11(6): 1536. [doi: [10.3390/biomedicines11061536](https://doi.org/10.3390/biomedicines11061536)]
- 37 Nastase INA, Moldovanu S, Moraru L. Deep learning-based segmentation of breast masses using convolutional neural networks. *Proceedings of the 12th International Conference on Mathematical Modeling in Physical Sciences*. Belgrade: IOP Publishing, 2024. 012005.
- 38 Vigil N, Barry M, Amini A, *et al.* Dual-intended deep learning model for breast cancer diagnosis in ultrasound imaging. *Cancers*, 2022, 14(11): 2663. [doi: [10.3390/cancers14112663](https://doi.org/10.3390/cancers14112663)]
- 39 Islam MR, Rahman MM, Ali MS, *et al.* Enhancing breast cancer segmentation and classification: An ensemble deep convolutional neural network and U-Net approach on ultrasound images. *Machine Learning with Applications*, 2024, 16: 100555. [doi: [10.1016/j.mlwa.2024.100555](https://doi.org/10.1016/j.mlwa.2024.100555)]
- 40 Bartolotta TV, Militello C, Prinzi F, *et al.* Artificial intelligence-based, semi-automated segmentation for the extraction of ultrasound-derived radiomics features in breast cancer: A prospective multicenter study. *La Radiologia Medica*, 2024, 129(7): 977–988. [doi: [10.1007/s11547-024-01826-7](https://doi.org/10.1007/s11547-024-01826-7)]
- 41 Schutte S, Uddin J. Deep segmentation techniques for breast cancer diagnosis. *BioMedInformatics*, 2024, 4(2): 921–945. [doi: [10.3390/biomedinformatics4020052](https://doi.org/10.3390/biomedinformatics4020052)]
- 42 Ding KX, Zhou M, Wang H, *et al.* A large-scale synthetic pathological dataset for deep learning-enabled segmentation of breast cancer. *Scientific Data*, 2023, 10(1): 231. [doi: [10.1038/s41597-023-02125-y](https://doi.org/10.1038/s41597-023-02125-y)]
- 43 Ortega-Ruiz MA, Karabağ C, Roman-Rangel E, *et al.* DRD-UNet, a UNet-like architecture for multi-class breast cancer semantic segmentation. *IEEE Access*, 2024, 12: 40412–40424. [doi: [10.1109/ACCESS.2024.3377428](https://doi.org/10.1109/ACCESS.2024.3377428)]
- 44 鄒迎节, 李春树. 乳腺癌超声图像分割算法研究. *宁夏工程技术*, 2024, 23(1): 73–78.
- 45 Luo MY, Zhang C, Liu Y. An efficient lightweight network for breast cancer segmentation. *Proceedings of the 2nd International Conference on Machine Vision, Image Processing & Imaging Technology (MVIPIIT)*. Zhangjiakou: IEEE, 2024. 155–160.
- 46 Chen GP, Li L, Dai Y, *et al.* AAU-Net: An adaptive attention U-Net for breast lesions segmentation in ultrasound images. *IEEE Transactions on Medical Imaging*, 2023, 42(5): 1289–1300. [doi: [10.1109/TMI.2022.3226268](https://doi.org/10.1109/TMI.2022.3226268)]
- 47 Punn NS, Agarwal S. RCA-IUnet: A residual cross-spatial attention-guided inception U-Net model for tumor segmentation in breast ultrasound imaging. *Machine Vision and Applications*, 2022, 33(2): 27. [doi: [10.1007/s00138-022-01280-3](https://doi.org/10.1007/s00138-022-01280-3)]
- 48 Podda AS, Balia R, Barra S, *et al.* Fully-automated deep

- learning pipeline for segmentation and classification of breast ultrasound images. *Journal of Computational Science*, 2022, 63: 101816. [doi: [10.1016/j.jocs.2022.101816](https://doi.org/10.1016/j.jocs.2022.101816)]
- 49 Huang RB, Lin MR, Dou HR, *et al.* Boundary-rendering network for breast lesion segmentation in ultrasound images. *Medical Image Analysis*, 2022, 80: 102478. [doi: [10.1016/j.media.2022.102478](https://doi.org/10.1016/j.media.2022.102478)]
- 50 Chen GP, Dai Y, Zhang JX. C-Net: Cascaded convolutional neural network with global guidance and refinement residuals for breast ultrasound images segmentation. *Computer Methods and Programs in Biomedicine*, 2022, 225: 107086. [doi: [10.1016/j.cmpb.2022.107086](https://doi.org/10.1016/j.cmpb.2022.107086)]
- 51 张光. 基于注意力学习的乳腺癌诊断关键技术研究 [博士学位论文]. 济南: 山东大学, 2023.
- 52 Iqbal A, Sharif M. MDA-Net: Multiscale dual attention-based network for breast lesion segmentation using ultrasound images. *Journal of King Saud University-Computer and Information Sciences*, 2022, 34(9): 7283–7299. [doi: [10.1016/j.jksuci.2021.10.002](https://doi.org/10.1016/j.jksuci.2021.10.002)]
- 53 Li BQ, Su B, Zhang XQ. U²-MNet: An improved neural network for breast tumor segmentation. *Proceedings of the 5th International Conference on Artificial Intelligence Technologies and Applications*. Changchun: IOP Publishing, 2023. 012003.
- 54 Zhu D, Wang YF, Yang MZ, *et al.* SU-Next: An image segmentation model of breast tumors based on U-Next and attention mechanisms. *Proceedings of the 7th International Conference on Data Mining, Communications and Information Technology*. Chongqing: IOP Publishing, 2023. 012001.
- 55 Umer MJ, Sharif MI, Kim J. Breast cancer segmentation from ultrasound images using multiscale cascaded convolution with residual attention-based double decoder network. *IEEE Access*, 2024, 12: 107888–10792. [doi: [10.1109/ACCESS.2024.3429386](https://doi.org/10.1109/ACCESS.2024.3429386)]
- 56 Hekal AA, Elnakib A, Moustafa HED, *et al.* Breast cancer segmentation from ultrasound images using deep dual-decoder technology with attention network. *IEEE Access*, 2024, 12: 10087–10101. [doi: [10.1109/ACCESS.2024.3351564](https://doi.org/10.1109/ACCESS.2024.3351564)]
- 57 Yang HN, Yang DP. CSwin-PNet: A CNN-Swin Transformer combined pyramid network for breast lesion segmentation in ultrasound images. *Expert Systems with Applications*, 2023, 213: 119024. [doi: [10.1016/j.eswa.2022.119024](https://doi.org/10.1016/j.eswa.2022.119024)]
- 58 Zhu CZ, Chai X, Xiao YL, *et al.* Swin-Net: A swin-Transformer-based network combing with multi-scale features for segmentation of breast tumor ultrasound images. *Diagnostics*, 2024, 14(3): 269. [doi: [10.3390/diagnostics14030269](https://doi.org/10.3390/diagnostics14030269)]
- 59 郭洪洋, 程前, 康晓东, 等. 多重注意力引导的超声乳腺肿瘤图像分割. *计算机科学*, 2024, 51(6A): 230500004.
- 60 汪慎文, 王海滨, 赵振峰, 等. 基于改进 U-KAN 的乳腺癌超声图像分割. *南昌工程学院学报*, 2024, 43(6): 7–13.
- 61 Sulaiman A, Anand V, Gupta S, *et al.* Attention based UNet model for breast cancer segmentation using BUSI dataset. *Scientific Reports*, 2024, 14(1): 22422. [doi: [10.1038/s41598-024-72712-5](https://doi.org/10.1038/s41598-024-72712-5)]
- 62 Wang X, Zeng WZ, Xu JZ, *et al.* MM-3D Unet: Development of a lightweight breast cancer tumor segmentation network utilizing multi-task and depthwise separable convolution. *Frontiers in Oncology*, 2025, 15: 1563959. [doi: [10.3389/fonc.2025.1563959](https://doi.org/10.3389/fonc.2025.1563959)]
- 63 Hirsch L, Huang Y, Luo SJ, *et al.* Radiologist-level performance by using deep learning for segmentation of breast cancers on MRI scans. *Radiology: Artificial Intelligence*, 2021, 4(1): e200231.
- 64 Yue WY, Zhang HT, Zhou J, *et al.* Deep learning-based automatic segmentation for size and volumetric measurement of breast cancer on magnetic resonance imaging. *Frontiers in Oncology*, 2022, 12: 984626. [doi: [10.3389/fonc.2022.984626](https://doi.org/10.3389/fonc.2022.984626)]
- 65 Zhu JJ, Geng JH, Shan W, *et al.* Development and validation of a deep learning model for breast lesion segmentation and characterization in multiparametric MRI. *Frontiers in Oncology*, 2022, 12: 946580. [doi: [10.3389/fonc.2022.946580](https://doi.org/10.3389/fonc.2022.946580)]
- 66 Yue WY, Zhang HT, Gao S, *et al.* Predicting breast cancer subtypes using magnetic resonance imaging based radiomics with automatic segmentation. *Journal of Computer Assisted Tomography*, 2023, 47(5): 729–737. [doi: [10.1097/RCT.0000000000001474](https://doi.org/10.1097/RCT.0000000000001474)]
- 67 Lew CO, Harouni M, Kirksey ER, *et al.* A publicly available deep learning model and dataset for segmentation of breast, fibroglandular tissue, and vessels in breast MRI. *Scientific Reports*, 2024, 14(1): 5383. [doi: [10.1038/s41598-024-54048-2](https://doi.org/10.1038/s41598-024-54048-2)]
- 68 Pekis A, Kannan V, Kaklamanos E, *et al.* Seeing beyond cancer: Multi-institutional validation of object localization and 3D semantic segmentation using deep learning for breast MRI. *Proceedings of the 2024 Conference of SPIE—The Medical Imaging 2024: Computer-aided Diagnosis*. San Diego: SPIE, 2024.
- 69 Sonia M, Kalita I, Devi D. A breast cancer prognosis model using PyRadiomics and image segmentation from MRI data. *Proceedings of the 7th International Conference on Machine Vision and Applications*. Singapore: ACM, 2024. 27–34.

- 70 Park GE, Kim SH, Nam Y, *et al.* 3D breast cancer segmentation in DCE-MRI using deep learning with weak annotation. *Journal of Magnetic Resonance Imaging*, 2024, 59(6): 2252–2262. [doi: [10.1002/jmri.28960](https://doi.org/10.1002/jmri.28960)]
- 71 Feng FY, Liu TY, Wang H, *et al.* PGDiffSeg: Prior-guided denoising diffusion model with parameter-shared attention for breast cancer segmentation. *arXiv:2410.17812*, 2024.
- 72 Zhao ZH, Du SY, Xu ZY, *et al.* SwinHR: Hemodynamic-powered hierarchical vision Transformer for breast tumor segmentation. *Computers in Biology and Medicine*, 2024, 169: 107939. [doi: [10.1016/j.combiomed.2024.107939](https://doi.org/10.1016/j.combiomed.2024.107939)]
- 73 Wu JD, Fu R, Fang HH, *et al.* MedSegDiff: Medical image segmentation with diffusion probabilistic model. *Proceedings of the 2024 Medical Imaging with Deep Learning*. Nashville: PMLR, 2024. 1623–1630.
- 74 Peng CT, Zhang Y, Zheng J, *et al.* IMIIN: An inter-modality information interaction network for 3D multi-modal breast tumor segmentation. *Computerized Medical Imaging and Graphics*, 2022, 95: 102021. [doi: [10.1016/j.compmedimag.2021.102021](https://doi.org/10.1016/j.compmedimag.2021.102021)]
- 75 Anusha K, Madhavi KR. A deep learning model for accurate multi-modal feature fusion and segmentation of breast cancer nodules. *International Journal of Computer Information Systems and Industrial Management Applications*, 2025, 17: 16.
- 76 Iqbal A, Sharif M. BTS-ST: Swin Transformer network for segmentation and classification of multimodality breast cancer images. *Knowledge-based Systems*, 2023, 267: 110393. [doi: [10.1016/j.knosys.2023.110393](https://doi.org/10.1016/j.knosys.2023.110393)]
- 77 Xiong L, Tang XF, Jiang XH, *et al.* Automatic segmentation-based multi-modal radiomics analysis of US and MRI for predicting disease-free survival of breast cancer: A multicenter study. *Breast Cancer Research*, 2024, 26(1): 157. [doi: [10.1186/s13058-024-01909-3](https://doi.org/10.1186/s13058-024-01909-3)]
- 78 Shah NUH, Hussain T, Ahmed A, *et al.* Deep multi-modal breast cancer detection network. *arXiv:2504.16954*, 2025.
- 79 Jing WP, Wang JZ, Di DL, *et al.* Multi-modal hypergraph contrastive learning for medical image segmentation. *Pattern Recognition*, 2025, 165: 111544. [doi: [10.1016/j.patcog.2025.111544](https://doi.org/10.1016/j.patcog.2025.111544)]
- 80 Perera S, Erzurumlu Y, Gulati D, *et al.* MobileUNETR: A lightweight end-to-end hybrid vision Transformer for efficient medical image segmentation. *Proceedings of the 2024 European Conference on Computer Vision*. Milan: Springer, 2024. 281–299.
- 81 Howard AG, Zhu ML, Chen B, *et al.* MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv:1704.04861*, 2017.
- 82 Woo S, Park J, Lee JY, *et al.* CBAM: Convolutional block attention module. *Proceedings of the 15th European Conference on Computer Vision*. Munich: Springer, 2018. 3–19.
- 83 Mildenhall B, Srinivasan PP, Tancik M, *et al.* NeRF: Representing scenes as neural radiance fields for view synthesis. *Communications of the ACM*, 2022, 65(1): 99–106. [doi: [10.1145/3503250](https://doi.org/10.1145/3503250)]
- 84 Xu JL, Xiao L, López AM. Self-supervised domain adaptation for computer vision tasks. *IEEE Access*, 2019, 7: 156694–156706. [doi: [10.1109/ACCESS.2019.2949697](https://doi.org/10.1109/ACCESS.2019.2949697)]
- 85 Amritanjali, Gupta R. Federated learning for privacy preserving intelligent healthcare application to breast cancer detection. *Proceedings of the 26th International Conference on Distributed Computing and Networking*. Hyderabad: ACM, 2025. 302–306.
- 86 Lee EA. Cyber physical systems: Design challenges. *Proceedings of the 11th IEEE International Symposium on Object and Component-oriented Real-time Distributed Computing (ISORC)*. Orlando: IEEE, 2008. 363–369.

(校对责编: 张重毅)