



# 深度学习在乳腺癌影像学检查中的应用进展

王一凡<sup>1</sup>, 刘静<sup>1</sup>, 马金刚<sup>1</sup>, 邵润华<sup>1</sup>, 陈天真<sup>2</sup>, 李明<sup>1+</sup>

1. 山东中医药大学 智能与信息工程学院, 济南 250355

2. 山东浪潮优派科技教育有限公司, 济南 250101

+ 通信作者 E-mail: 80500285@qq.com

**摘要:**乳腺癌是女性最常见的恶性肿瘤,其早期发现具有决定性意义。乳腺影像学检查在早期发现乳腺癌以及治疗期间监测与评估方面发挥着重要作用,但人工检测医学影像通常耗时耗力。最近,深度学习算法在早期乳腺癌诊断工作中取得了显著进展。通过梳理近几年的相关文献,对深度学习技术在不同成像模式的乳腺癌诊断中的应用进行了系统综述,旨在为深入开展基于深度学习的乳腺癌诊断研究提供参考。首先概述了乳腺X线摄影、超声影像、磁共振成像和正电子发射计算机断层显像四种乳腺癌成像模式并进行了简要对比,列举了多种成像方式对应的公共数据集。重点对基于上述四种不同成像模式的深度学习架构的不同任务(病变检测、分割和分类)进行了系统的综述,对比分析了各算法性能、改进思路及其优缺点。最后,对现有技术存在的问题进行分析,并针对目前工作的局限性对未来发展方向进行展望。

**关键词:**乳腺癌;深度学习;计算机辅助诊断;影像学检查

**文献标志码:**A **中图分类号:**TP391

## Application Progress of Deep Learning in Imaging Examination of Breast Cancer

WANG Yifan<sup>1</sup>, LIU Jing<sup>1</sup>, MA Jingang<sup>1</sup>, SHAO Runhua<sup>1</sup>, CHEN Tianzhen<sup>2</sup>, LI Ming<sup>1+</sup>

1. College of Intelligence and Information Engineering, Shandong University of Traditional Chinese Medicine, Jinan 250355, China

2. Shandong Inspur-UPTEC Education Ltd., Jinan 250101, China

**Abstract:** Breast cancer is the most common malignant tumor in women and its early detection is decisive. Breast imaging plays an important role in early detection of breast cancer as well as monitoring and evaluation during treatment, but manual detection of medical images is usually time-consuming and labor-intensive. Recently, deep learning algorithms have made significant progress in early breast cancer diagnosis. By combing the relevant literature in recent years, a systematic review of the application of deep learning techniques in breast cancer diagnosis with different imaging modalities is conducted, aiming to provide a reference for in-depth research on deep learning-based breast cancer diagnosis. Firstly, four breast cancer imaging modalities, namely mammography, ultrasonography, magnetic resonance imaging and positron emission tomography, are outlined and briefly compared, and the public datasets corresponding to multiple imaging modalities are listed. Focusing on the different tasks (lesion detection, segmentation and classification) of deep learning architectures based on the above four different imaging modalities,

**基金项目:**国家自然科学基金面上项目(82174528);山东省研究生教育优质课程和教学资源库建设项目(SDYKC20047, SDYAL2022041);教育部产学研合作协同育人项目(220606121142949)。

This work was supported by the National Natural Science Foundation of China (82174528), the Graduate Education High-Quality Course and Teaching Resource Repository Project of Shandong Province (SDYKC20047, SDYAL2022041), and the Industry School Cooperation Collaborative Education Project of Ministry of Education of China (220606121142949).

**收稿日期:**2023-09-04 **修回日期:**2023-10-26

a systematic review of the algorithms is conducted, and the performance of each algorithm, improvement ideas, and their advantages and disadvantages are compared and analyzed. Finally, the problems of the existing techniques are analyzed and the future development direction is prospected with respect to the limitations of the current work.

**Key words:** breast cancer; deep learning; computer-aided diagnosis; imaging examination

目前,乳腺癌已超越肺癌,成为全球第一大癌症。2023年美国癌症协会的统计数据显示,乳腺癌在女性癌症患者中占比高达31%,其发病率和死亡率在女性中均为首位<sup>[1]</sup>。从20世纪80年代至今,乳腺癌发病率在中国持续快速上升,同时患病群体呈现出年轻化的趋势。乳腺肿瘤一般分为四类:正常、良性、原位癌和浸润性癌<sup>[2]</sup>。良性肿瘤是一种异常但非癌性的细胞集合,细胞结构发生微小变化,但不具备癌细胞的特性。而原位癌和浸润性癌则被归类为癌症<sup>[3]</sup>。原位癌仅限于乳腺内的一部分区域,没有侵入周围组织或血液循环系统。但浸润性癌细胞会侵入周围组织和血液循环系统,可能会向其他部位扩散<sup>[4]</sup>。乳腺癌的早期发现是治疗的决定性步骤,对于防止癌症及其并发症的进一步发展至关重要。准确的乳腺癌早期检测可以将患者的生存率提高到50%。

放射学成像技术的进步,使得在早期阶段诊断这种致命疾病成为可能。在乳腺癌筛查操作中,放射科医生或病理学家通过人工观察和检查乳房图像进行诊断、预后和治疗决策。然而,诊断过程中医生的主观性影响较大,并且每位医生的经验水平也不尽相同<sup>[5]</sup>。计算机辅助诊断(computer aided diagnosis, CAD)系统可以为放射科医生的决策过程提供关键的辅助。CAD系统可以显著减少在临床实践中评估病变的工作量,消除了人为主观因素的影响,提高诊断的准确率与效率,同时将活检的假阳性数量降至最低。最近,一些基于人工智能的方法,如深度学习算法,在早期乳腺癌诊断方面取得了显著进展。深度学习是近年来一项重大的突破性技术,因为它在包括目标检测和分类在内的各种机器学习任务中展现出了超越最先进水平的性能。深度学习利用多层神经网络对输入数据进行处理和学习。与传统的机器学习方法相比,深度学习可以自动地从数据中学习更抽象、更高层次的特征表示,从而使得模型在处理复杂的任务和大规模数据时表现更出色。自深度学习出现以来,各种利用深度架构的著作相继问世<sup>[6]</sup>。最常见的深度学习结构是卷积神经网络(convolutional neural networks, CNN)<sup>[7]</sup>。

对于乳腺癌诊断,文献[8-12]是近期发表的几篇优秀的综述,如Gao等人<sup>[8]</sup>从机器学习和深度学习两

方面对基于乳腺X线图像的应用进行了综述,张晓栋等人<sup>[12]</sup>总结了深度学习在乳腺磁共振成像中的研究进展。但上述综述都是仅针对某种特定的成像方式或特定的工作展开,未对应用于不同乳腺癌成像模式的深度学习方法进行系统的概述;而成像模式对于基于图像的CAD系统具有重要意义。因此,不同于上述综述,本研究回顾了深度学习在多种乳腺癌成像模式中应用的最新研究。本文系统地总结了多种常见的乳腺癌成像模式,以及各成像模式对应的公共数据集;概述了近期用于不同乳腺癌成像模式的深度学习架构、不同任务(如分类、分割)的模型性能以及研究方向。针对现有技术分析了存在的问题,并对未来的发展方向进行了展望。

## 1 乳腺影像学检查

乳腺影像学检查是用于评估乳腺疾病的医学影像技术,旨在检测乳房异常、辅助乳腺癌的早期诊断和指导治疗。在乳腺癌早期诊断中,不同的影像学检查方法各具特点。目前乳腺影像学检查主要包括乳腺X线摄影(mammography)、超声影像(ultrasound-imaging)、磁共振成像(magnetic resonance imaging, MRI)、计算机断层扫描(computed tomography, CT)和正电子发射断层扫描(positron emission tomography, PET)等。

### 1.1 乳腺X线检查

乳腺X线检查是目前最简单有效的乳腺癌检测方法,在医学放射学中已经应用很多年<sup>[13]</sup>。乳腺X线检查可以帮助医生观察乳房内部的异常结构和钙化,发现在触摸或其他检查中难以察觉的小肿块或钙化灶。但乳腺X线检查对于年轻女性或乳房组织较密集的个体、密集的乳房组织可能会模糊或掩盖潜在的异常病变,增加了误诊和漏诊的风险<sup>[14-15]</sup>。

### 1.2 乳腺超声检查

乳腺超声检查利用超声波技术生成乳房的影像,对身体无危害,具有较好的筛查效果。超声检查可以鉴别乳房肿块的性质,以区分囊性和实性肿块。相比于X线检查,超声检查受乳房密度的影响较小,可额外发现27%的乳腺癌病变<sup>[16]</sup>。然而,乳腺超

声检查可能无法提供细微的结构信息,因此,目前乳腺超声检查尚未广泛应用于乳腺癌的常规筛查中,而是作为X线检查的补充检查手段<sup>[17]</sup>。

### 1.3 乳腺MRI检查

乳腺MRI检查可以获取乳腺的高分辨率三维图像,从而发现更小的肿块和钙化灶,特别适用于高风险人群。乳腺MRI提供了详细的乳房结构和组织信息,且受乳房密度的影响较小。然而,MRI诊断乳腺癌的特异度相对较低,对于微小钙化的显示不如X线检查<sup>[18]</sup>。其次,乳腺MRI成本较高,检查时间较长,可能不适宜作为常规筛查方法。

### 1.4 PET/CT检查

PET/CT检查是一种结合了PET和CT的影像学检查技术,可同时获得代谢和解剖信息。PET图像提供关于细胞活动和代谢的信息,CT图像提供详细结构信息。结合两种类型的图像,医生可以更好地定位异常并做出更准确的诊断。PET/CT检查在癌症分期、治疗规划和治疗反应监测方面得到广泛应用,在常规分期检查结果不确定或有疑问的情况下可提供辅助诊断,适用于局部晚期或转移性患者。

## 2 数据集

医学领域中可用的公开图像数据集相对较少,尤其是针对乳腺图像的数据集。本章旨在概述用于乳腺癌诊断的不同成像模式所对应的公共数据集,并着重介绍常见的乳腺X线图像公共数据集。

## 2.1 乳腺X线图像数据集

约70%的乳腺图像公共数据集为乳腺X线图像或超声图像数据集,这也表明这两种方法,特别是乳腺X线摄影在乳腺癌筛查中的重要性<sup>[19-20]</sup>。不同乳腺X线图像数据集的详细特征见表1。

## 2.2 其他数据集

除乳腺X线摄影外,其他成像模式对应的数据集见表2。

表2 常见各成像模式图像数据集

Table 2 Common image datasets of various imaging modes

成像方式	公共数据集	起始年份	病例数量
超声	OASBUD	2017	恶性52例,良性48例
	BUSI	2018	恶性210例,良性620例
	MBUD	2018	正常472例,异常278例
MRI	RIDER	2006	恶性500例
	TCIA	2015	恶性91例
	DWI	2022	恶性328例

## 3 深度学习在乳腺影像学检查中的应用

在医疗保健系统中,复杂的临床环境和工作流程使医生的决策非常具有挑战性,特别是在成像任务方面,因为这需要高度的视觉感知和认知能力<sup>[29]</sup>。如今,越来越多的医疗机构开始使用人工智能算法。k-近邻、支持向量机(support vector machine, SVM)和朴素贝叶斯分类器在各自领域表现较好。

表1 常见乳腺X线图像数据集

Table 1 Common mammogram datasets

数据集	病例数量	图像数量	视角	文件格式	标注方式	数据集特点
DDSM <sup>[21]</sup>	2 620	10 480	MLO CC	.LGPEG	RoI轮廓点	根据乳腺影像报告数据系统(BI-RADS) <sup>[22]</sup> 提供患者年龄、肿块形状、肿块边缘、钙化分布、乳腺密度等信息。包含真实标注框(GT)验证和RoI注释,但提供的异常位置过于笼统,无法进行精确的分割
CBIS-DDSM <sup>[23]</sup>	1 644	2 015	MLO CC	.DICOM	RoI轮廓点	DDSM的更新和标准化版本,经过删除低质量图像并改进RoI注释处理,将图像进行了解压缩并转换为DICOM格式
MIAS <sup>[24]</sup>	161	322	MLO	.PGM	RoI中心和半径	提供乳房密度信息,并提供高比例的毛刺状肿块,但注释并不充分 <sup>[25]</sup> 。图像的分辨率限制了微钙化的检测 <sup>[26]</sup> 。此外,数据集没有按BI-RADS标准进行分类
INbreast <sup>[27]</sup>	115	410	MLO CC	.DICOM	RoI轮廓点	共包含六类:正常、钙化、肿块、不对称、多重发现和结构扭曲。病灶周围的轮廓信息为像素级。RoI信息和患者相关信息(如家族史、ACR乳腺密度、BI-RADS分类分布等)以XML格式进行存储
BancoWeb <sup>[28]</sup>	320	1 400	MLO CC	.TIFF	部分数据标注RoI	图像经过适当的对比度和空间分辨率处理。数据集提供搜索、剪切、统计分析、远程插入和其他工具。但RoI形式的注释仅存在于部分图像中

注:MLO(mediolateral-oblique)侧斜位;CC(cranio-cauda)头足位;RoI(region of interest)感兴趣区域。

然而,机器学习中的跟踪和检测过程需要手动完成。为了有效检测癌症,系统每帧需要处理 200~300 个细胞,这是手动跟踪无法实现的,而深度学习可以识别原始数据中的复杂模式。研究显示,深度学习模型能够比传统的临床方法提前 1~2 年发现乳腺癌<sup>[30]</sup>。目前,深度学习算法在乳腺癌不同成像模式诊断中均得到了应用。本章在病变检测、分割和分类三方面综述了应用于乳腺癌影像学检查的深度学习算法。使用深度学习诊断乳腺癌的总体框架如图 1 所示。

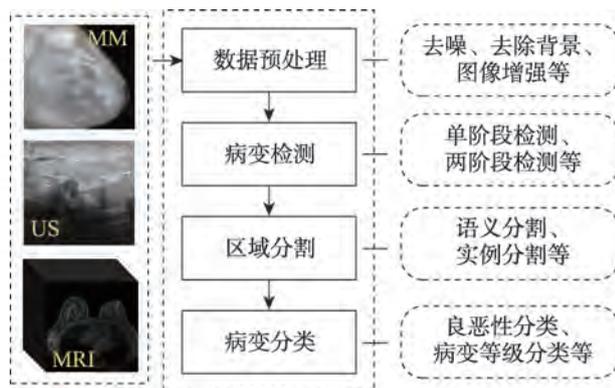


图1 使用深度学习技术诊断乳腺癌的总体框架

Fig.1 Overall framework of using deep learning technology to diagnose breast cancer

### 3.1 基于乳腺 X 线检查技术

#### 3.1.1 乳腺 X 线图像病变检测

近年来,深度学习技术在乳腺 X 线摄影处理领域得到广泛应用,以减轻放射科医生的工作负担。基于 CNN 的系统在乳腺 X 线摄影图像检测任务中展现出比基于机器学习的系统更高的性能,这在早期 Ribli 等人<sup>[31]</sup>的工作结果中得到了证实,他们使用改进的 Faster R-CNN 网络对乳腺 X 线图像进行病变检测,该方法在 INbreast 数据集上取得了 0.95 的 AUC 值。为了进一步提高肿块检测性能,Sun 等人<sup>[32]</sup>通过模拟人类的视觉特征,使用图像模板匹配方法在图像中定位乳房肿块的可疑区域,并使用粒子群 (particle swarm optimization, PSO) 算法进行优化,从而有效地将对乳房肿块的粗略边界框进一步细化。Garrucho 等人<sup>[33]</sup>在单个域中训练了八种最先进检测方法,并在五个新域中进行测试。基于 Transformer 的检测模型表现最佳,这证明在模型中集成注意力模块可以进一步提高算法的可靠性,因为 Transformer 的自注意力机制使其对域变化具有更强的鲁棒性。该研究的一个局限性是训练集在肿块和患者属性方面不平

衡,向少数类添加更多的样本可以帮助更好地评估检测性能。

YOLO (you only look once)<sup>[34]</sup>是一个经典的目标检测模型,Al-antari 等人<sup>[35]</sup>使用 YOLO 算法从完整的乳腺 X 线图像中搜索可疑肿块区域,算法甚至可以检测到存在于胸肌或密集区域内的肿块。与其他研究相比,该算法运行时间和所需的内存更少。在后续的工作中,Su 等人<sup>[36]</sup>又通过结合 YOLO 算法和 LOGO (local-global) 架构实现了同时进行检测和分割。YOLO 模型提供了特定裁剪的局部图像,用于后期的分割;为了平衡训练效率和分割性能,作者分别在全局和局部 Transformer 分支上训练整个图像和裁剪图像,大大提高了原始像素级的分割分辨率。

为了检测乳腺 X 线图像中的微钙化病变,Honjo 等人<sup>[37]</sup>提出了一种超分辨率 (super-resolution, SR) CNN 模型,反卷积上采样将低分辨率图像的大小增加到高分辨率,从而清晰地定义了微钙化边缘,使其更容易与周围组织区分开来,但模型对非钙化病变的识别略差。为此,Ueda 等人<sup>[38]</sup>通过改进 RetinaNet<sup>[39]</sup>模型,主干网络使用 ResNet152<sup>[40]</sup>和特征金字塔网络<sup>[41]</sup>以处理深层特征和多尺度信息,从而实现了肿块、微钙化和结构扭曲等多类型病变检测。边界框模型解决了钙化等类型区域边界难以准确划定的问题,该方法以 0.45~0.47 的平均假阳性指征 (mean false positive indications, mFPI) 检测到所有的癌症,但模型在较致密的乳腺组织和钙化中发现恶性病灶相对困难。其他研究也报道了类似的结果<sup>[42-43]</sup>。未来开发模型时可以尝试降低压缩比解决该问题。

#### 3.1.2 乳腺 X 线图像分割

U-Net<sup>[44]</sup>模型在医学图像分割中是一种流行且高效的方法。U-Net 模型使用了跳跃连接 (skip connections) 将编码器阶段的特征与解码器阶段的特征相连接,这有助于传递底层和高层特征,从而在分割过程中保留更多的上下文信息和细节。基于 U-Net 模型,Soulami 等人<sup>[45]</sup>将像素点分为背景、良性肿瘤和恶性肿瘤,从而实现了分类分割一步到位;此外,使用标准分类交叉熵作为损失函数,损失将根据每个类别建立的权重进行加权,有效解决了类不平衡问题。在此基础上,Salama 等人<sup>[46]</sup>在利用 U-Net 模型分割乳房区域时使用 MLO 视图和 CC 视图组合,取得了比单一 MLO 视图更好的性能,基于改进 U-Net 准确率为 98.87%,计算时间为 1.21 s。受到 Connected U-Net 的启发,Alkhaleefah 等人<sup>[47]</sup>将两个 SegNet 架构的层之间进行跳跃连接,该方法有助于恢复在 SegNet 编

码中丢失的细粒度特征和池化操作过程中丢失的空间信息,以增强模型的鲁棒性。

对于乳腺X线图像分割任务,大多数文献集中在特征提取和选择技术上,没有致力于去除图像中的额外的肌肉部分。乳腺X线图像中包含与乳房和胸肌区域信息,因此抑制胸肌信息并实现区域分割可能是CAD系统的关键。Ahmed等人<sup>[48]</sup>使用直方图均衡化(contrast limited adaptive histogram equalization, CLAHE)和形态学操作等预处理步骤从原始图像中去除噪声和伪影,移除肌肉区域;该方法有效地提升了Mask RCNN和DeepLab两种实例分割框架的分割性能。在此基础上,Zhou等人<sup>[49]</sup>还使用中值滤波器抑制噪声。预处理效果对比如图2所示,由图可见,通过中值滤波器抑制噪声后,消除了原始图像中右下角的黑线;而应用CLAHE算法的图像中胸肌的可见度更高。此外,DeepLab v3+在语义分割方面优于U-Net,该方法在不同图像分辨率的不同数据集中可

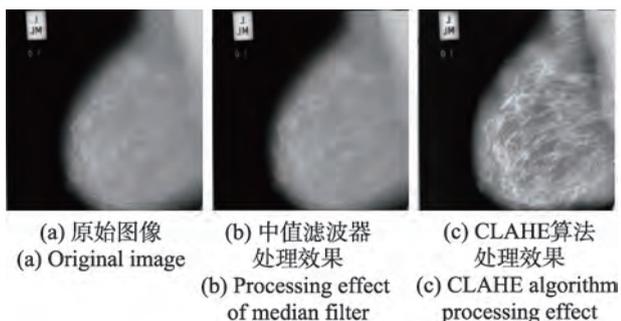


图2 乳腺X线图像预处理效果对比

Fig.2 Comparison of preprocessing effects on mammography

以保持高准确性和快速的运行时间。

Kavitha等人<sup>[50]</sup>提出了一种基于多层阈值分割的胶囊网络(optimal multi-level thresholding-based segmentation with DL enabled capsule network, OMLTS-DLCN),使用基于最优Kapur的多层阈值分割<sup>[51]</sup>与壳博弈优化算法应用于乳腺癌分割,作者通过该方法将图像分成多个区域,每个区域具有最大的Kapur熵,从而最大限度地增加每个区域的信息量。此外,模型采用基于胶囊网络(CapsNet)的特征提取器,胶囊是一组神经元的集合,编码特征的同时还可以保持特征之间的关系,这使得CapsNet网络在处理旋转、变形等变化时更具鲁棒性。OMLTS-DLCN模型的结构如图3所示。

### 3.1.3 乳腺X线图像分类

在乳腺X线图像分类中,虽然CNN已经取得了显著的成就,但仍存在一些问题,例如低对比度图像中的斑块丢失以及分割中的模糊性。为了提高低对比度图像的分类精度,Malebary等人<sup>[52]</sup>使用CNN提取低层特征,RNN-LSTM(recurrent neural networks-long short-term memory)提取高层特征,将RNN-LSTM特征与CNN特征进行映射,从而改善对比度较低的问题。另一方面,由于提取的深度特征相对于可用医疗数据的小尺寸样本而言空间维数较高,迁移学习预训练CNN得到的深度特征可能会产生特征维度诅咒(feature dimensionality curse, FDC)。为此,Samee等人<sup>[53]</sup>提出了一种基于预训练CNN和单变量范式的级联特征选择框架。随机选择AlexNet<sup>[54]</sup>、VGG<sup>[55]</sup>和GoogleNet<sup>[56]</sup>模型用于提取浅特征和深特

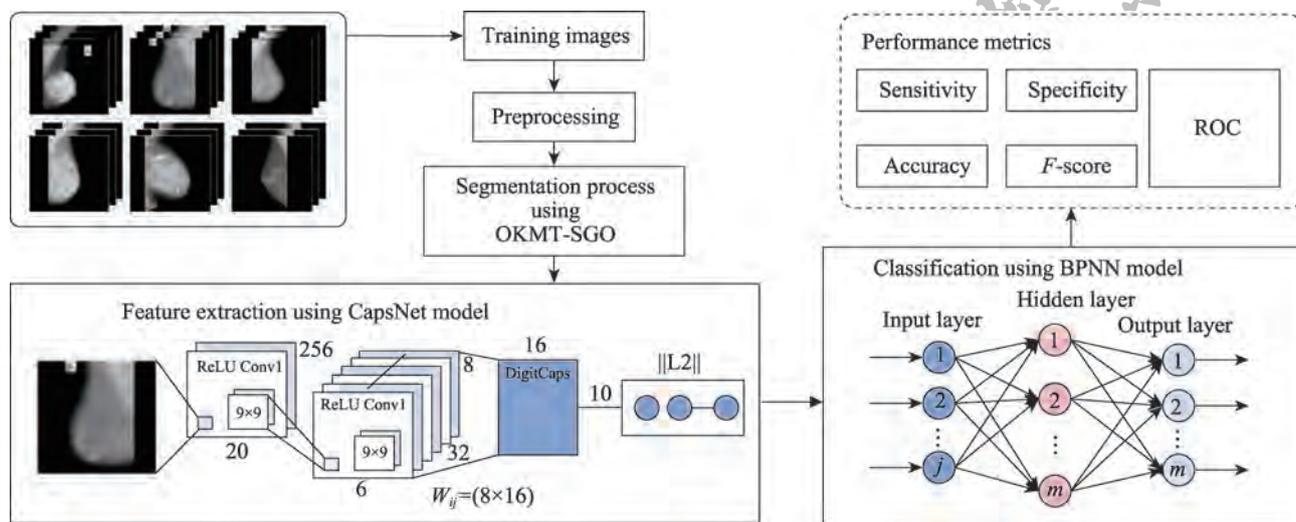


图3 OMLTS-DLCN模型的总体流程

Fig.3 Overall process of OMLTS-DLCN model

征,通过单变量方法优化的关键特征具有良好的分类模型训练能力,从而有效克服了FDC和多重共线性问题。为了进一步提升分类性能,Baccouche等人<sup>[57]</sup>使用ResNet网络模型的堆叠集成,移除每个ResNet架构的最后一个全连接层之后,堆叠了三个不同的全连接层。与其他单个体系结构的方法相比,该方法在良恶性分类、BI-RADS(breast imaging reporting and data system)类别及肿块形状的多分类方面准确率均有所提高,但方法的局限性在于模型有大量的可训练参数和计算,因此每个epoch的训练时间较长。集成框架结构如图4所示。

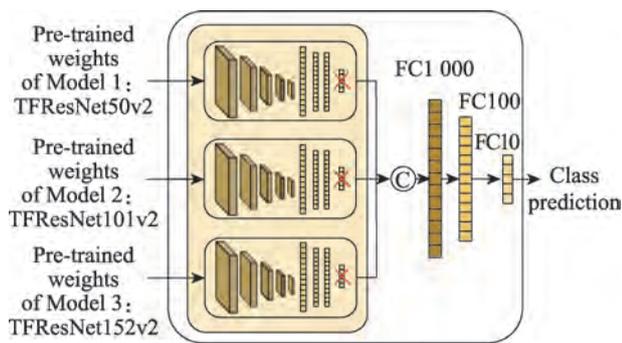


图4 ResNet模型分类堆叠集成框架

Fig.4 Framework of classification stacked ensemble of ResNet models

为了提取感兴趣钙化区域,Cai等人<sup>[58]</sup>通过手工制作和预训练CNN模型学习放射组学特征,该工作验证了传统形态学特征可用于指导CNN以实现更高的微钙化分类精度。在最近的一项工作中,Tiryaki<sup>[59]</sup>评估了最新深度学习模型的乳腺癌肿块和钙化病变分类性能。结果证明了迁移学习和微调预训练CNN在乳腺癌异常和病理分类方面具有巨大潜力,但类不平衡问题导致在异常情况中良性钙化的特异性最低。

### 3.1.4 乳腺X线图像算法分析总结

深度学习模型和算法的不断优化和发展极大地扩展了深度学习在乳腺X线图像分析中的应用。与其他模式相比,乳腺X线图像具有多个大型公共数据集,使得乳腺X线检查在深度学习算法的开发和验证方面有更多的研究。上述基于乳腺X线图像的算法及性能的比较如表3所示。乳腺X线图像中病变区域与正常组织之间的对比度较低,这导致乳腺肿块与周围腺体往往难以区分,而噪声和周围组织也会影响检测的准确性。为此,文献[48-49]等工作着重研究原始图像的预处理,需要注意的是,预处理不仅需要减少噪声的影响,同时还需要保留图像的细节,以免造成微小病变的漏检。由于乳腺病理的复杂性和病灶在X线图像上的多样性,研究需要针对不同类型的病变分别进行改进,例如对于大小不一的肿块

表3 基于乳腺X线图像的算法比较

Table 3 Comparison of algorithms based on mammography

文献	年份	任务	方法	数据来源	结果评估
Ribli等人 <sup>[31]</sup>	2018	肿块检测、分类	Faster R-CNN	DDSM、INbreast	AUC=0.95
Sun等人 <sup>[32]</sup>	2021	肿块检测	BD-CNN、图像模板匹配+PSO	DDSM	ACC=0.858 2
Garrucho等人 <sup>[33]</sup>	2022	肿块检测	Transformer	OPTIMAM、INbreast、BCDR	AUC=0.89(平均)
Al-antari等人 <sup>[35]</sup>	2018	肿块检测、分割、分类	YOLO、FrCN、CNN	INbreast	ACC=0.989 6 Dice=0.926 9 AUC=0.947 8
Su等人 <sup>[36]</sup>	2022	肿块检测、分割	YOLO+LOGO	CBIS-DDSM、INbreast	IoU=0.640 4(CBIS-DDSM) IoU=0.610 9(INbreast)
Honjo等人 <sup>[37]</sup>	2022	钙化检测	SR+CNN	大阪市立大学医院数据集	
Ueda等人 <sup>[38]</sup>	2022	所有症状检测	RetinaNet	大阪市立大学医院数据集、Medcity21诊所临床数据集	AUC=0.93(0.90~0.95) AUC=0.93(0.90~0.96)
Soulami等人 <sup>[45]</sup>	2021	肿块检测、分割、分类	U-Net	DDSM、INbreast	AUC=0.998 8
Salama等人 <sup>[46]</sup>	2021	肿块分割、分类	U-Net、CNN	DDSM、MIAS、CBIS-DDSM	IOU=0.929 9, ACC=0.988 7 IOU=0.907 8, ACC=0.978 7 IOU=0.879 6, ACC=0.960 1
Alkhaleefah等人 <sup>[47]</sup>	2022	肿块分割	Connected SegNets	INbreast、CBIS-DDSM、台湾振兴综合医院数据集	Dice=0.928 6(INbreast) Dice=0.963 4(CBIS-DDSM) Dice=0.922 5(医院数据集)

表 3(续)

文献	年份	任务	方法	数据来源	结果评估
Ahmed 等人 <sup>[48]</sup>	2020	肿块检测、分割、分类	Mask RCNN、DeepLab	MIAS、CBIS-DDSM	AUC=0.98(Mask RCNN) AUC=0.95(DeepLab)
Zhou 等人 <sup>[49]</sup>	2022	乳房区域分割	DeepLab v3+	Mini-MIAS、INbreast	ACC=0.989 8(Mini-MIAS) ACC=0.991 2(INbreast)
Kavitha 等人 <sup>[50]</sup>	2021	肿块分割、分类	OKMT-SGO、CapsNet、BPNN	Mini-MIAS、DDSM	ACC=0.985 0(Mini-MIAS) ACC=0.975 5(DDSM)
Malebary 等人 <sup>[52]</sup>	2021	肿块分类	CNN、RNN-LSTM	MIAS、DDSM	AUC=0.94~0.98(MIAS) AUC=0.94~0.97(DDSM)
Samee 等人 <sup>[53]</sup>	2022	肿块分类	CNN	INbreast	ACC=0.985 0
Baccouche 等人 <sup>[57]</sup>	2022	肿块分类	ResNet 堆叠集成	CBIS-DDSM、INbreast、私人数据集	ACC=0.992 0(良恶性分类) ACC=0.990 0(BI-RADS 分类) ACC=0.900 2(形状分类)
Cai 等人 <sup>[58]</sup>	2019	钙化检测、分类	CNN+传统形态学特征	中山大学肿瘤防治中心、南方医科大学南海附属医院	ACC=0.893 2, AUC=0.939 8
Tiryaki <sup>[59]</sup>	2023	肿块、钙化检测、分类	CNN	DDSM、CBIS-DDSM	AUC=0.940 4

注：“—”代表无数据；AUC (area under curve), 受试者工作特征曲线下面积；ACC(accuracy), 准确率；Dice, Dice 系数；IoU (intersection over union), 交并比。

病变, 文献[38]在工作中使用了特征金字塔, 而对于其他方法的性能。上述基于乳腺 X 线图像的算法微钙化病变, 文献[37]利用超分辨率网络, 实现了优总结如表 4 所示。

表 4 基于乳腺 X 线图像的算法总结

Table 4 Summary of algorithms based on mammography

任务	文献	主要改进	效果	局限性
病变检测	[31]	调整区域提议网络中前景对象的交并集阈值	解决了类不平衡问题	公开可用的像素级注释数据集尺寸较小
	[32]	图像模板匹配检测肿块的可疑区域, PSO 算法进行细化	解决图像中肿块的粗糙边界框问题, 获得了更高的交并比	难以匹配非圆形区域
	[33]	使用单个域对检测的下游任务进行微调	减少域转移并提高了模型泛化性能	未应用不同数据集以证明其泛化性
	[36]	引入自适应锚框计算、自适应图像缩放	增强检测不同大小和尺度肿块的能力	模型非端到端训练
	[37]	使用 SRCNN 模型的反卷积进行上采样	提高了微钙化病变的可见度	对非钙化病变的识别略差
	[38]	使用残差网络和特征金字塔网络处理深层特征和多尺度信息	实现了所有类型乳腺癌病变的检测	难以发现较致密乳腺组织中的恶性病灶
病变分割	[45]	使用标准分类交叉熵损失函数	解决了类不平衡问题	模型未使用任何数据增强
	[46]	利用 MLO 和 CC 视图的组合训练模型	实现了优于单一视图的分割性能	数据相对难以获取
	[47]	通过层之间的跳跃连接将两个 SegNet 架构相连	增强了模型的鲁棒性	模型运行时间较长
	[50]	使用基于最优 Kapur 的多层阈值分割与壳博弈优化算法	增加了每个区域的信息量	评估图像数量较少
病变分类	[52]	结合 CNN 和 RNN-LSTM 同时提取像素特征和时间序列特征	提升了低对比度图像分类性能	评估时未考虑数据集大小
	[53]	使用基于单变量的范式加强非冗余关键特征的选择	解决了特征维度诅咒和多重共线性问题	灵敏度有待进一步提升
	[57]	使用三个 ResNet 网络进行堆叠集成	提升了良恶性、病变级别和肿块形状分类性能	每个 epoch 训练时间较长
	[58]	传统形态学特征为 CNN 提供补充信息	手工特征改善了 CNN 分类性能	评估图像中钙化样例较少
	[59]	通过迁移学习方法预训练模型并微调	减少了训练时间和数据需求	良性样例灵敏度有待提升

## 3.2 基于乳腺超声检查技术

### 3.2.1 乳腺超声图像病变检测

使用超声图像检测乳腺病变是计算机辅助诊断系统的重要一步。早期工作中, Yap 等人<sup>[60]</sup>使用三种深度学习方法(基于 Patch 的 LeNet、U-Net、迁移学习 FCN-AlexNet)进行乳腺超声病变检测,结果表明,深度学习方法全方面优于传统检测方法。在最近的一项工作中, Balaha 等人<sup>[61]</sup>将 CNN 模型与遗传算法(genetic algorithms, GA)相结合, GA 算法不断追踪给定搜索域中的最优超参数。相比于随机局部搜索, GA 算法可以有方向地进行全局搜索,从而优化模型性能并提高效率。

自动乳腺超声(automated breast ultrasound, ABUS)技术能够在较短时间内获取多个乳腺超声图像,从而提供更全面的乳腺检查。但散斑、阴影以及病变回声的高变异性使得 ABUS 图像的肿瘤检测变得困难并且容易出现假阳性。Zhang 等人<sup>[62]</sup>在 YOLO 模型中加入了 MC-Drop(Monte Carlo dropouts)技术,将不确定性引入网络,从而提高检测结果的可靠性和鲁棒性。该方法可以检测到具有后影的中等大小的肿瘤,对于边界不清晰、对比度低的肿瘤,边界框精度有待提升。由于 ABUS 数据集是三维图像,在进一步的研究中,必须深入理解切片间的空间信息,以克服这些难题。为此, Zhou 等人<sup>[63]</sup>利用改进后的 Faster R-CNN 检测并重构正交多视图切片,提取候选二维图像,通过融合二维检测结果,得到最终的三维边界框。但三个视图检测增加了时间成本。在他们未来的工作中,可以尝试直接提取三维空间特征。Malek-mohammadi 等人<sup>[64]</sup>使用补丁 Bi-ConvLSTM 网络,该轻量级模型逐个补丁地检查 ABUS 切片,从而以低 FP 实现高灵敏度。简单结构有效防止了数据稀缺性引起的过滤波。模型在识别可疑切片的同时,还能推断出肿块的大致位置。

### 3.2.2 乳腺超声图像分割

与乳腺 X 线摄影相比,超声图像的数据集数量较少,通常包含的图像也较少。因此,大多数提出的方法都使用某种数据增强方法(例如旋转)来增加训练数据的数量以提高模型性能。但应该注意如何增强超声图像,因为某些增强可能会降低模型性能。例如, Byra 等人<sup>[65]</sup>的研究表明,在纵向上执行图像旋转或移动会对模型性能产生负面影响。生成对抗网络(generative adversarial networks, GAN)也可用于合成超声图像<sup>[66]</sup>,这些图像可以添加到原始训练图像中以

提高模型的准确性。Han 等人<sup>[67]</sup>基于 GAN 进行改进,通过密集提取多尺度特征增强了模型的稳定性和鲁棒性,采用双注意力融合块,两个独立的空间注意力路径分别提取原始图像的几何级和强度级信息,从而扩大病变区域和背景之间的差异。为了实现使用图像级标签进行乳腺肿瘤分割, Li 等人<sup>[68]</sup>提出了类激活映射和深层水平集(class activation mapping and deep level set, CAM-DLS)方法,结合 CAM 的区域关注信息与 DLS 的边界信息,从而更准确地分割肿瘤。通过半监督语义分割技术将输入的超声图像分解为四个乳房解剖结构(脂肪、乳腺、肌肉和胸廓层),有效缩小了分割的搜索空间。

Almajalid 等人<sup>[69]</sup>发现在某些情况下, U-Net 不仅检测到肿瘤区域,还检测到一些假阳性区域,例如阴影。这些假阳性区域比真实肿瘤区域小,因此作者通过只保留输出图像中最大的区域的后处理步骤去除了噪声。在此基础上, Sannasi 等人<sup>[70]</sup>基于 U-Net 进行了改进,并命名为 SKMAT-U-Net。该模型结合了选择性内核(selective kernel, SK)和注意力机制来自适应调整神经网络的感受野,有效地解决乳房肿块大小不一的问题;作者在传统交叉熵损失函数的基础上集成了四个注意力损失函数,该做法可以获得更准确的网络损失值,从而进一步突出肿瘤靶点。另一项工作中, Byra 等人<sup>[71]</sup>使用 U-Net 的改进版 Y-Nets 对乳房肿块进行联合分割和分类。该研究使用包含更多关于组织物理特性的信息的射频超声(radio-frequency, RF)数据。Y-Net 架构为 U-Net 配备了一个额外的分类分支,利用来自 U-Net 中心块的特征,通过混合 1D 和 2D 卷积滤波器,从而有效地处理 RF 数据的大矩阵。但 RF 数据难以获取是该工作的主要问题。

Ragab 等人<sup>[72]</sup>开发了名为 EDLCDS-BCDC(ensemble deep-learning-enabled clinical decision support system for breast cancer diagnosis and classification)的自动检测模型。模型使用基于磷虾群算法(chemotaxis krill herd algorithm, CKHA)和 Kapur 熵技术结合的 CKHA-KE 算法进行图像分割,该方法可以结合乳腺图像的特定特征,如纹理、颜色和形状,以帮助确定肿块的位置和边界。模型在基准数据库<sup>[73]</sup>中以 97.09% 的最高准确率超过了所有其他相比较的方法。EDLCDS-BCDC 模型的总体流程如图 5 所示。

### 3.2.3 乳腺超声图像分类

与乳腺 X 线检查类似,深度学习在乳腺超声检查

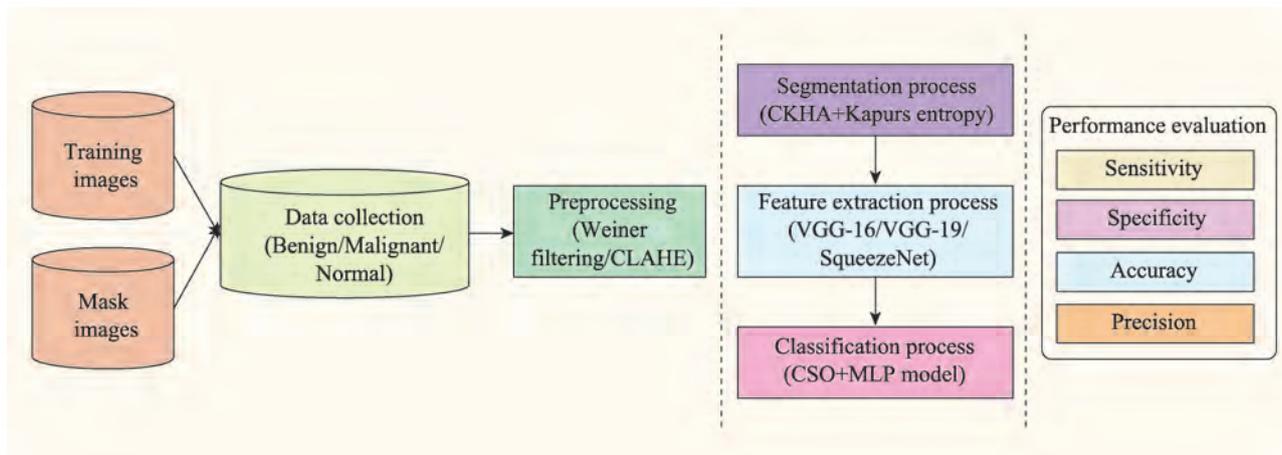


图5 EDLCDS-BCDC模型总体流程

Fig.5 Overall process of EDLCDS-BCDC

的首次应用是将肿瘤分类为良性或恶性。Han 等人<sup>[74]</sup>使用 GoogLeNet 卷积神经网络进行肿瘤良恶性分类。网络经 ImageNet 预训练后进行微调,最终取得了 0.95 的 AUC。Kaplan 等人<sup>[75]</sup>还实现了对超声图像进行 BI-RADS 等级分类。作者将新型金字塔三重深度特征生成器(pyramid triple deep feature generator, PTDFG)与三个基于迁移学习的预训练网络(AlexNet、VGG16 和 VGG19)相结合,用于生成深度特征;选择 1 000 个信息量最大的 PTDFG 生成的特征,并将其传送到 SVM 进行分类。该研究的局限性在于样本量相对较小,尤其是对于 BI-RADS 等级的多分类工作。

超声弹性成像(elastography ultrasound, EUS)可以提供肿瘤的血管分布和组织硬度信息。与超声图像相比,它具有更高的特异性,使其更有助于区分良性肿瘤。Ding 等人<sup>[76]</sup>在模型中引入 EUS 数据,并基于 ResNet 网络进行改进,使用卷积层和全局平均池化(global average pooling, GAP)取代全连接层,开发了一个双通道网络。双通道通过多尺度不一致性损失相互学习,减少了 B 型超声和 EUS 模式之间的不一致性。该策略有助于在训练过程中对两个通道进行优化,帮助两通道获得更多判别性知识,为后续分类提供依据。Jabeen 等人<sup>[77]</sup>采用深度学习和最佳选择特征融合的框架,从 DarkNet-53 模型的全局平均池化层中提取特征,利用改进的差分评价(reformed differential evaluation, RDE)和改进的灰狼(reformed gray wolf, RGW)两种优化算法选择最相关和最有信息量的特征子集,该方法在改善模型的性能的同时还减少了维度。为了进一步提升分类性

能,Raza 等人<sup>[78]</sup>提出了一种比传统 CNN 更复杂的新架构,使用了跨通道归一化层和批量归一化层,跨通道归一化层增强了泛化并降低了错误率;批量归一化减少了内部协变量偏移,从而加快了模型训练速度。Inception 模块提供了包括  $1\times 1$ 、 $3\times 3$  和  $5\times 5$  的多种卷积核,以提取各种尺度的特征。改进的架构最高达到了 99.35% 的准确率。

### 3.2.4 乳腺超声图像算法分析总结

综合前述讨论可知,在乳腺超声图像处理领域,深度学习技术已经取得了显著的进展,并在乳腺超声图像的目标检测、分割与分类等任务中发挥了关键作用。上述基于超声图像的算法及性能的比较如表 5 所示。文献[71,76]等研究通过结合 RF、EUS 等医学超声成像技术获取了更多层面的信息,在不同的临床场景中展现了独特的价值。但深度学习在乳腺超声图像应用中最大的问题在于缺乏大型的、适当标记的公共数据集。文献[67-68]等研究采用了无需图像标注的弱监督方法。对于临床应用,弱监督深度学习算法允许使用未标注的整个图像或弱监督的标签信息,从而减少了对大量标记数据的依赖。由于这类算法可以避免标记病变的额外任务,使得工作流程效率优于完全监督算法,但目前弱监督学习算法的性能仍有较大的进步空间。上述基于乳腺超声图像的算法总结如表 6 所示。

## 3.3 基于乳腺 MRI 检查技术

### 3.3.1 乳腺 MRI 图像病变检测

目前,深度学习在乳腺 MRI 的病变分割、检测及病灶预测等方面均得到应用。然而,MRI 与 X 线图像或超声图像之间的最大区别在于 MRI 是 3D 扫描。

表5 基于超声图像的算法比较

Table 5 Comparison of algorithms based on ultrasound images

文献	年份	任务	方法	数据来源	结果评估
Balaha 等人 <sup>[61]</sup>	2022	病变检测、分类	CNN+GA	BUSI数据集	ACC=0.916 2
Zhang 等人 <sup>[62]</sup>	2021	肿块检测	贝叶斯+YOLO	北京大学人民医院	SEN=0.88
Zhou 等人 <sup>[63]</sup>	2021	肿块检测	Faster R-CNN	北京大学人民医院	SEN=0.950 6
Malekmohammadi 等人 <sup>[64]</sup>	2023	肿块检测	Bi-LSTM	瑞典法伦医院、拉德堡德大学医学中心、朱尔斯·博代研究所、齐肯豪斯研究中心	ACC=0.93 AUC=0.97
Han 等人 <sup>[67]</sup>	2020	肿块分割	GAN	四川大学华西医院	Dice=0.871 2
Li 等人 <sup>[68]</sup>	2022	肿块分割、分类	DeepLab3+	中国人民解放军总医院	Dice=0.773 ACC=0.948
Almajalid 等人 <sup>[69]</sup>	2018	肿块分割	U-Net	哈尔滨医科大学第二附属医院	Dice=0.825
Sannasi 等人 <sup>[70]</sup>	2022	病变分割	SKMAT-U-Net	—	Dice=0.929
Byra 等人 <sup>[71]</sup>	2018	肿块分割、分类	Y-Net	—	Dice=0.64 AUC=0.87
Ragab 等人 <sup>[72]</sup>	2022	肿瘤分割、分类	CKHA-KE、CSO-MLP	Baheya 医院	ACC=0.970 9
Kaplan 等人 <sup>[75]</sup>	2022	BI-RADS 分类	CNN+PTDFG、SVM	Adiyaman 训练研究医院	ACC=0.792 9(八分类) ACC=0.804 2(五分类) ACC=0.886 7(良恶性分类)
Ding 等人 <sup>[76]</sup>	2022	肿块分类	ResNet-GAP	南京鼓楼医院	ACC=0.886, AUC=0.936
Jabeen 等人 <sup>[77]</sup>	2022	肿块分类	DarkNet	BUSI数据集	ACC=0.991
Raza 等人 <sup>[78]</sup>	2023	肿块检测、分类	CNN	BUSI数据集	ACC=0.993 5

注：“—”代表无数据；SEN(sensitivity)，灵敏度。

表6 基于超声图像的算法总结

Table 6 Summary of algorithms based on ultrasound images

任务	文献	主要改进	效果	局限性
病变检测	[61]	遗传算法优化CNN模型的超参数	避免了各种随机尝试优化方案	未使用不同数据集进行验证
	[62]	应用MC-Drop引入不确定性	减少了假阳性区域,提高了肿瘤区域检测率	未整合切片间空间信息
	[63]	多视图位置分析方案融合Faster R-CNN提取的2D切片	2D检测结果融合生成了3D边界框	相比于2D方案运行时间较长
	[64]	卷积层之间添加双向ConvLSTM模块	结合了切片的时间相关性	灵敏度有待进一步提升
病变分割	[67]	使用两个独立的空间注意力路径	有效扩大了病灶区域与背景的差异	分割精度有待进一步提升
	[68]	使用类激活映射和深层水平集方法	弱监督学习场景中实现了较高的分割性能	模型非端到端训练
	[69]	使用仅保留输出图像中最大的区域的后处理	去除了分割结果中的假阳性区域	未应用不同数据集以证明其泛化性
	[70]	利用选择性内核和注意力机制来调整网络的感受野	有效解决了乳房肿块大小不一问题	运行内存占用较高
病变分类	[71]	使用RF数据训练网络	分割性能优于单一标准超声	RF射频数据难以获取
	[72]	将混沌磷虾群算法与Kapur熵结合进行分割	增加了每个区域的信息量	未应用不同数据集以证明其泛化性
	[75]	将新型金字塔三重深度特征生成器与预训练网络相结合	优化了深度特征的提取,提升了BI-RADS类别分类性能	训练数据量相对较小
	[76]	开发双通道ResNet-GAP网络分别用于EUS和B型超声	整合刚度信息,提升了分类精度	EUS数据难以获取
病变分类	[77]	使用改进的差分评价和改进RGW两种优化算法选择最佳特征	改善了模型的性能,减少了维度	评估图像数量有限
	[78]	使用跨通道归一化层和批量归一化层	增强了模型泛化能力,减少了内部协变量偏移	公开可用数据集图像数量有限

此外,动态对比增强磁共振成像(dynamic contrast enhanced magnetic resonance imaging, DCE-MRI)随着时间的推移捕获MRI序列,将维度增加到了四维。这使得MRI图像对深度学习算法更具挑战性,因为当前的大多数深度学习算法都是为2D图像构建的。解决这一挑战的一种方法是将3D图像转换为2D,例如将3D MRI分成2D切片<sup>[79-80]</sup>或使用最大密度投影(maximum intensity projection, MIP)构建2D表示<sup>[81]</sup>。Adachi等人<sup>[82]</sup>使用RetinaNet网络来检测DCE-MRI中的MIP病变,RetinaNet采用了Focal loss损失函数,这允许对困难的样本进行更多的关注。系统在DCE-MRI的MIP病变检测和诊断方面表现出了高性能。类似的研究中,Ayatollahi等人<sup>[83]</sup>使用基于改进的3D RetinaNet模型对超快T1加权序列进行运动补偿、时间归一化和裁剪。模型利用难以检测的病变进行训练改善了检测性能,从而检测到相对较小的病变以及乳腺内部混淆结构难以区分的病变。RetinaNet模型作为单级检测器,可同时提供合理的精度和速度,使用更少的GPU内存。

Zhang等人<sup>[84]</sup>使用Mask R-CNN搜索整个MRI数据集检测异常病变,但许多增强区域被检测为假阳性,为此,作者将检测到的可疑病变边界框作为ResNet50模型的输入,计算恶性概率,从而消除了约80%的假阳性。但对于非肿块性病变的检测,该模型有待进一步改进。

### 3.3.2 乳腺MRI图像分割

与其他分割问题类似,基于DCE-MRI的乳腺肿

瘤分割的常见挑战包括类不平衡问题图像中的背景混淆问题。为此,Zhang等人<sup>[85]</sup>提出了一个掩膜指导分层学习框架。全卷积网络(fully convolutional network, FCN)模型生成3D乳腺掩膜作为每个图像的RoI,以去除输入DCE-MRI图像中的混淆信息。其次,作者设计了两个级联的FCN模型对乳腺肿瘤进行从粗到细的分割。HML(mask-guided hierarchical learning)框架总体流程如图6所示。

为了克服单模式图像检测的局限性,Lu等人<sup>[86]</sup>模拟临床医生的实际诊断过程,使用乳房MRI四种成像模式(T1加权、T2加权、扩散加权和eTHRIVE序列)以及DCE-MRI参数对U-Net模型进行训练;此外,他们还使用子像素方法对上采样进行改进,这种方法有利于获得更高的图像分辨率。Yue等人<sup>[87]</sup>在U-Net模型中整合残差模块,提出了一种Res-U-Net模型。Res-U-Net能够有效克服网络层加深导致的参数过多和梯度分散<sup>[88]</sup>,模型可在大约10~15 s的时间内实现自动分割。Carvalho等人<sup>[89]</sup>比较了U-Net和SegNet两种架构在DCE-MRI切片中的肿瘤分割能力。图像被转换为2D切片以进行数据增强。两种架构均能够很好地地区分图像中的病变组织和健康组织,且SegNet架构表现更佳。但由于这项研究仅使用2D切片而不是3D检查作为输入,这会忽略肿瘤切片之间的相关性。另一项工作中,Bouchebbah等人<sup>[90]</sup>提出了一种3D自动水平传播方法(3D automatic levels propagation approach, 3D-ALPA),可实现多平面和多肿瘤分割。首先通过2D自动级别传播方法(2D-ALPA)

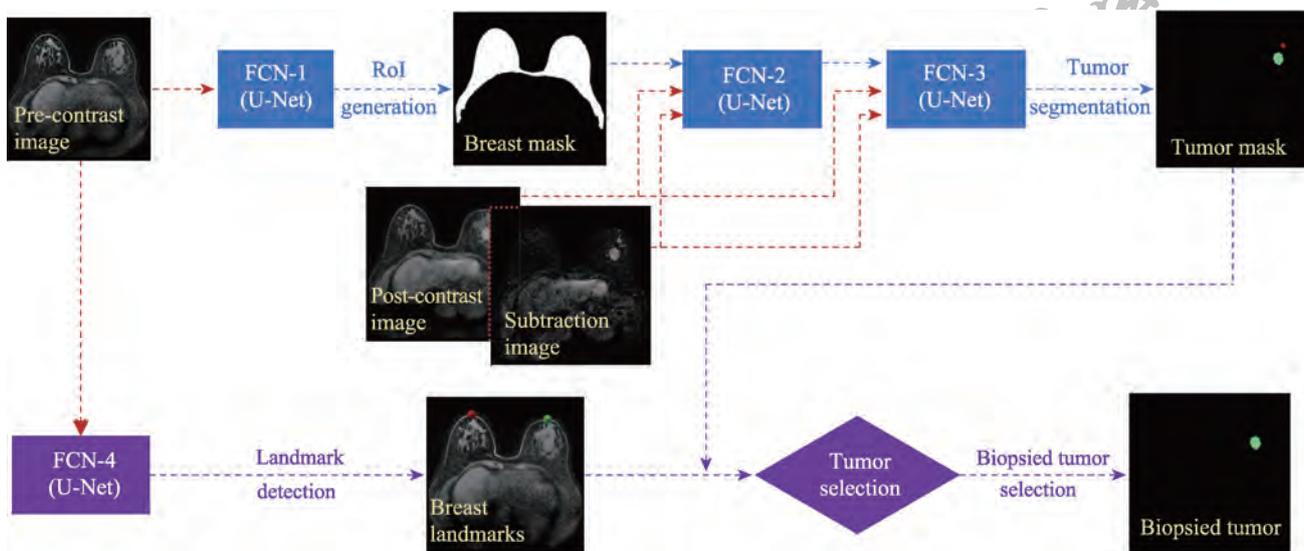


图6 掩膜指导分层学习框架总体流程

Fig.6 Overall process of mask-guided hierarchical learning framework

逐个切片分割 3D MRI 图像中的肿瘤,再组合切片的分割以呈现肿瘤的 3D 轮廓。该方法能够生成精确的阈值来处理增强肿瘤的内部异质性以及非增强肿瘤与其周围组织的重叠强度,从而兼顾了分割的准确性和运行时间。

### 3.3.3 乳腺 MRI 图像分类

针对没有像素级注释的乳腺 MRI 图像,Liu 等人<sup>[91]</sup>提出了一种基于 ResNet-101 架构的弱监督学习方法,网络对 MRI 图像的整个切片进行评估,而不是仅仅评估包含乳腺肿瘤或离散良性病变的 RoI。这种方法模拟了现实生活中的临床实践,实现了良好的分类性能。Jing 等人<sup>[92]</sup>使用 3D U-Net 生成乳房区域的掩膜,生成的 MIP 图像用于训练模型。但该模型使用单一机构的高风险人群数据集开发,这影响了该研究的普遍性。

为了实现病变 BI-RADS 级别分类,Verburg 等人<sup>[93]</sup>进行了图像裁剪、配准和创建 MIP 图像等工作,使用三个 MIP 方向(横向、矢状和冠状)在 CNN 模型中获得了最佳性能。但该研究还应在来自更多医院的不同质量的连续数据集中进行测试,进一步验证研究在临床实践中的稳健性和可用性。

将乳腺癌病例进行分子亚型分类可以更好地了解肿瘤的生物学特征。乳房 MRI 图像包含丰富的信息,使用诊断时获取的图像对肿瘤进行彻底评估,可用于区分分子亚型。Zhu 等人<sup>[94]</sup>最早利用三种不同的 CNN 模型对 DCE-MRI 扫描的 Luminal A 和其他亚型进行了分类,但效果并不尽如人意。在最近的一项研究中,Zhang 等人<sup>[95]</sup>使用卷积长短期记忆网络(convolutional long short-term memory, CLSTM)将乳腺癌分为三种亚型:HR+/HER2-、HER2+和 TN。CLSTM 循环网络考虑了 DCE 序列中的时间信息,可以跟踪 DCE 采集过程中信号强度的变化。与传统 CNN 相比,该方法取得了更高的精度。

背景实质增强(background parenchymal enhancement, BPE)是指静脉注射造影剂后正常乳腺组织的生理性增强<sup>[96-97]</sup>,取决于组织血管和血管通透性。为实现 BPE 自动分类,Borkowski 等人<sup>[98]</sup>训练了一个深度卷积神经网络(deep convolutional neural network, DCNN),使用 VGG16 网络的卷积部分作为乳腺 MRI 的特征提取器,模型在四分类(轻微、轻度、中度或明显)任务中表现良好。在此基础上,Eskreis-Winkler 等人<sup>[99]</sup>使用 K-means 聚类对乳房进行分割,提取中心切片。轴向切片被合并为三个 MIP(分别从上、中、

下乳房产生的三个轴向减法 MIP)并作为输入训练模型,结果优于使用单一标准轴向减法 MIP 训练的模型。这证明了将更细粒度的临床相关数据纳入模型开发的重要性。

### 3.3.4 乳腺 MRI 图像算法分析总结

相比于其他成像方式,深度学习结合 MRI 的应用更具多样性,如文献[95,99]等研究了 BPE 评估、分子和组织病理学类型的识别等工作。但当前研究主要还是集中在病灶发现和良恶性分类方面,对于预测乳腺癌的分子分型和淋巴结转移等方面的研究还相对有限。乳腺 MRI 图像具有复杂的空间和纹理信息,深度学习可以用于学习更有效的特征表示,以减轻人工特征设计的负担,但也要有效利用切片间的空间信息,如文献[95]证明了结合图像序列的上下文信息来获取更丰富的低层和高层语义特征可以提高检测、分类和分割任务的性能。上述基于 MRI 图像的算法及性能的比较如表 7 所示。针对 U-Net 模型,研究人员进行了大量改进工作。这些改进包括改进输入数据形式和数据流向,如将二维图像转化为三维图像、增加跳跃连接路径等;改进损失函数,如基于 Dice 损失函数的改进等;以及改进网络结构,如引入残差模块、特征融合和空洞卷积层等。上述基于乳腺 MRI 图像的算法总结如表 8 所示。对于临床应用,相信基于乳腺 MRI 的深度学习模型会在乳腺癌的早期检测或预测女性未来患乳腺癌的风险方面取得突破。

## 3.4 基于 PET/CT 检查技术

迄今为止,已经有很多研究涉及基于 PET/CT 的乳腺癌成像。在检测和评估乳腺癌的过程中,增加使用成像生物标志物可以获得更多具有临床效用的信息,如 18F-氟代脱氧葡萄糖(18F-FDG)的代谢参数可以为预后带来有益效果。然而,深度学习在乳腺癌的 PET/CT 中的用途尚未得到充分研究。基于 PET 的成像不适合早期乳腺癌,PET/CT 在乳腺癌中的使用通常是作为其他成像技术(如乳腺 X 线摄影、超声、MRI)的补充,以提供更全面的评估。

18F-FDG-PET/CT 可用于多种恶性肿瘤的准确分期和治疗反应评估<sup>[100-101]</sup>。然而,很少有研究使用深度学习方法检测 18F-FDG-PET/CT 上的乳腺癌原发性病变。Takahashi 等人<sup>[102]</sup>使用 18F-FDG-PET 的 MIP 图像训练了两个基于 Xception 制作的模型。对于每位患者获得了四个不同角度(0°, 30°, 60°, 90°)的 PET MIP 图像,一个模型只用 0°的 MIP 进行训练,

表7 基于MRI图像的算法比较

Table 7 Comparison of algorithms based on MRI images

文献	年份	任务	方法	数据来源	结果评估
Adachi 等人 <sup>[82]</sup>	2020	病变检测	RetinaNet	东京医科和牙科大学医院	AUC=0.925
Ayatollahi 等人 <sup>[83]</sup>	2021	病变检测	3D RetinaNet	荷兰奈梅亨内梅亨大学医学中心放射科	SEN=0.94
Zhang 等人 <sup>[84]</sup>	2023	肿块检测、分类	Mask R-CNN ResNet50	温州医科大学第一附属医院	SEN=0.92
Zhang 等人 <sup>[85]</sup>	2018	肿瘤分割	FCN	私立数据集	Dice=0.72
Lu 等人 <sup>[86]</sup>	2019	肿瘤检测、分割、分类	CNN、U-Net	天津市中心妇产医院放射科	ACC=0.942, Dice=0.865
Yue 等人 <sup>[87]</sup>	2022	肿瘤分割	Res-U-Net	中国厦门大学第一附属医院	Dice=0.89
Carvalho 等人 <sup>[89]</sup>	2021	肿瘤分割	SegNet、U-Net	DCE-MRI	Dice=0.976, IOU=0.953
Bouchebbah 等人 <sup>[90]</sup>	2021	肿瘤分割	3D-ALPA	RIDER数据集	AUC=0.87
Liu 等人 <sup>[91]</sup>	2022	肿块分类	ResNet-101	哥伦比亚大学医学中心放射科、ISPY TRIAL MRI数据集	AUC=0.92, ACC=0.942
Jing 等人 <sup>[92]</sup>	2022	肿块分割、分类	U-NET、ResNet-34	格罗宁根大学医学中心	AUC=0.81
Verburg 等人 <sup>[93]</sup>	2022	BI-RADS分类	CNN	—	AUC=0.83
Zhang 等人 <sup>[95]</sup>	2021	分子亚型分类	CNN、CLSTM	—	ACC=0.79(CNN) ACC=0.91(CLSTM)
Borkowski 等人 <sup>[98]</sup>	2020	BPE评估	CNN	—	ACC=0.75
Eskreis-Winkle 等人 <sup>[99]</sup>	2022	BPE评估	CNN	美国纽约纪念斯隆凯特琳癌症中心	ACC=0.84

注：“—”代表无数据。

表8 基于MRI图像的算法总结

Table 8 Summary of algorithms based on MRI images

任务	文献	主要改进	效果	局限性
病变检测	[82]	单级检测器检测DCE-MRI的MIP	精度较高,运行时间短	无法检测到浸润性导管癌
	[83]	同时使用三维空间信息和时间信息	能够检测相对较小的乳腺病变	训练中未涉及正常病例
	[84]	使用ResNet50估计Mask R-CNN检测到的异常病变的恶性概率	消除了约80%检测到的误报	非肿块性病变检测精度有待进一步改进
病变分割	[85]	FCN模型生成3D乳房掩膜,两个级联的FCN模型检测肿瘤区域	有效消除了DCE-MRI中的混杂信息	分割精度有待进一步提升
	[86]	采用子像素方法对U-Net上采样细化	获得更好的图像分辨率	未使用外部数据集验证
	[87]	在U-Net中集成残差模块	克服了参数过多和梯度弥散问题	分割精度有待进一步提升
	[89]	使用侵蚀和扩张处理肿瘤区域	有效去除了分割结果中的假阳性	没有关注切片之间的相关性
	[90]	2D-ALPA进行切片分割后重组生成3D分割	提供了分割肿瘤的多视图表示	未使用外部数据集验证
病变分类	[92]	使用3D U-Net生成乳房区域的掩膜用于训练	实现了仅以TWIST序列作为输入进行训练	未应用不同数据集以证明其泛化性
	[93]	利用多中心筛查数据进行八重内部-外部验证	提高了BI-RADS级别分类准确率	内部外部验证中,可用样本量各不相同
	[95]	使用CLSTM网络来逐组处理DCE-MRI图像	获取了DCE-MRI中包含的时间特征	未应用不同数据集以证明其泛化性
	[98]	2D CNN分层检测MRI切片的乳腺组织并进行BPE分类	可以高精度进行BPE自动分类	研究数量有限
	[99]	分别从上、中、下乳房生成的三个轴向减法MIP作为模型输入	分类性能优于基于标准轴向减法MIP的模型	未应用不同数据集以证明其泛化性

另一个使用四个不同的度数。结果显示,四角度模型的AUC为0.936,该研究达到了放射科医生相同的

诊断性能,证明了深度学习模型可以有效实现乳腺癌PET/CT图像的分类。

此外, PET/CT 可用于量化全身代谢肿瘤体积 (metabolic tumor volume, MTV), 以减少获得 MTV 的人工成本。例如, Weber 等人<sup>[103]</sup>使用淋巴瘤和肺癌患者 MTV 训练的模型来检测乳腺癌患者 PET/CT 扫描中的病变, 使用在淋巴瘤和肺癌 18F-FDG PET/CT 数据上训练的神经网络的 PET 辅助报告系统 (PARS) 原型, 检测病理病灶并确定其解剖位置。他们的算法可以检测出 92% 的可测量病变。

作为转移性乳腺癌病变分割和表征的第一步, 骨病变的检测和分割至关重要。Moreau 等人<sup>[104]</sup>训练了两个 U-Net 模型, 第一个模型仅使用专家骨病变注释进行训练, 而第二个模型在训练阶段使用骨掩膜来强制网络聚焦于感兴趣的位置。两种骨病变分割方法的结果表明, 在训练过程中考虑骨骼信息可以提高病变检测的精度以及分割病变的 Dice 分数。

综上所述, 与之前讨论的四种成像方式相比, PET/CT 并不适合进行早期乳腺癌评估。然而, 将深度学习与 PET/CT 技术相结合, 可以改进其他乳腺癌成像技术中实现的任务。作为标准诊断成像的辅助手段, 它在识别区域性结节疾病和远处转移方面增加了价值。

#### 4 总结与展望

在医学图像分析领域, 基于深度学习的技术经过快速发展, 结合大型数据集和可用的计算资源, 为改善乳腺癌的检测、诊断、预后与治疗提供了可能。尽管深度学习方法在乳腺癌诊断方面表现出色, 但在深度学习算法结合临床实践发挥其潜力之前, 它们仍然面临着诸多挑战:

(1) 高质量乳腺癌数据集的稀缺, 是提升算法性能的主要瓶颈。使用小样本数据集导致算法的泛化能力较差, 难以在实际临床中得到广泛应用。且目前大多数研究集中在肿块和微钙化检测上, 腺体结构扭曲和不对称型的可用样本数据有限且缺乏标准化。(2) 乳腺癌数据集通常存在类不平衡问题, 这导致模型对于罕见恶性样本的预测效果较差。为确保模型在乳腺癌各种病变情况下都能准确预测, 解决类不平衡问题至关重要。(3) 另一个问题在于模型的泛化能力。在乳腺癌影像分析中, 深度学习模型需要能够泛化到不同患者、设备和场景, 而大多数提出的方法仅适用于具有特定成像特征的数据集。(4) 由于深度学习算法的“黑盒”性质, 所提取的特征和背

后的决策逻辑难以清晰解释。这使得放射科医生难以理解算法决策的物理意义以及图像的哪些部分具有高度区分性。在医学领域, 特别是涉及诊断和治疗决策的情况下, 模型的可解释性至关重要。(5) 目前应用于乳腺癌诊断的多模态学习方法大多数只涉及一种类型的成像数据 (如乳腺 X 线检查的多视图、B 型超声和彩色多普勒、不同序列的 MRI)。不同的成像技术对乳腺癌患者的状况提供了不同的信息 (如超声中详细的恶性病变特征: 低回声、角边缘、后阴影和内部血管分布), 而目前的研究尚未充分利用。

针对以上问题, 未来深度学习在乳腺癌筛查与诊断中应用的发展可侧重于以下方向:

(1) 为了克服乳腺癌图像数据集的不足, 许多工作将使用非乳房甚至非医学图像预训练的模型进行迁移, 探索新的数据增强方法也会为乳腺癌诊断带来新的突破。此外, 通过组合来自多个医疗保健中心的数据, 实现合作与数据共享同样是未来的趋势。(2) 针对乳腺癌恶性样本较少导致的类不平衡问题, 目前常见的解决方法有欠采样、过采样、生成对抗网络等。尝试开发新的评估指标、新的不均匀采样策略及合理利用元学习也有助于更好地关注恶性病变。类不平衡问题的自动检测与纠正也是未来发展方向之一, 这可能包括自动选择适当的重采样技术、自动设置阈值等。(3) 充分利用注意力机制可以提高深度学习方法的精度。注意力机制不仅显示了架构的内部运作, 还可以突出有助于解释结果的基本信息 (例如钙化、针状边缘)。通过学习影像特征、数据融合和风险预测, 它有望辅助医生更准确地检测病变、预测患病风险以及优化治疗策略。(4) 梯度加权类激活映射 (Grad-CAM) 等可视化的深度学习工作在一定程度上解决了深度学习模型可解释性差的问题。另一个方向是使用自然语言处理 (natural language processing, NLP) 技术为给定结果生成文本来解释模型的决策, 例如医学成像报告的自动创建<sup>[105]</sup>。此外, 未来可以尝试开发将推理过程嵌入深度学习模型的先验算法, 例如基于原型的模型解释, 目前这类模型还未大量开发。(5) 未来的多模态研究应充分利用临床过程中不同模式所提供的多方面丰富信息, 如乳腺 X 线检查比超声对钙化更敏感, MRI 提供了更详细的空间信息等。此外, 结合年龄、家族史和遗传学等非影像学特征, 可以更加全面地评估患者的乳腺癌风险。目前多模态乳腺癌论文呈增加趋势, 这一研究方向在将来还有待进一步探索。

## 5 结束语

深度学习在帮助研究人员从使用乳腺X线摄影、超声和MRI等成像模式获得的原始医学图像中进行分割、特征提取、分类与检测方面取得了重大进展。本研究全面详细地介绍了最近的深度学习方法在不同模态乳腺癌图像中的应用(如分类和分割)。由于更大的数据集规模和更多的验证研究,乳腺X线摄影研究得到进一步发展。相反,MRI和PET/CT数据集中包含的患者较少,但与乳腺X线摄影和超声相比,MRI和PET/CT结合深度学习在研究方向上展现出更强的多样性,这主要是由于它们更侧重于预测治疗反应和结果。综上所述,尽管基于深度学习的乳腺癌诊断方法已具有较高的准确率,但仍存在进一步发展的潜力。期待随着医学影像AI的飞速发展、高质量和标准化数据的不断获取、新技术的出现及研究水平的不断提升,深度学习能够真正辅助放射科医生为乳腺癌患者的临床治疗制定个性化方案。

## 参考文献:

- [1] SIEGEL R L, MILLER K D, WAGLE N S, et al. Cancer statistics, 2023[J]. CA: A Cancer Journal for Clinicians, 2023, 73(1): 17-48.
- [2] ZHOU X, LI C, RAHAMAN M M, et al. A comprehensive review for breast histopathology image analysis using classical and deep neural networks[J]. IEEE Access, 2020, 8: 90931-90956.
- [3] 师金, 梁迪, 李道娟, 等. 全球女性乳腺癌流行情况研究[J]. 中国肿瘤, 2017, 26(9): 683-690.  
SHI J, LIANG D, LI D J, et al. Epidemiological status of global female breast cancer[J]. China Cancer, 2017, 26(9): 683-690.
- [4] CRUZ-ROA A, GILMORE H, BASAVANHALLY A, et al. Accurate and reproducible invasive breast cancer detection in whole-slide images: a deep learning approach for quantifying tumor extent[J]. Scientific Reports, 2017, 7(1): 1-14.
- [5] 陈智丽, 高皓, 潘以轩, 等. 乳腺X线图像计算机辅助诊断技术综述[J]. 计算机工程与应用, 2022, 58(4): 1-21.  
CHEN Z L, GAO H, PAN Y X, et al. Review of computer aided diagnosis technology in mammography[J]. Computer Engineering and Applications, 2022, 58(4): 1-21.
- [6] HAMIDINEKOO A, DENTON E, RAMPUN A, et al. Deep learning in mammography and breast histology, an overview and future trends[J]. Medical Image Analysis, 2018, 47: 45-67.
- [7] LECUN Y, BENGIO Y. Convolutional networks for images, speech, and time series[J]. The Handbook of Brain Theory and Neural Networks, 1995(10): 1-14.
- [8] GAO Y, LIN J, ZHOU Y, et al. The application of traditional machine learning and deep learning techniques in mammography: a review[J]. Frontiers in Oncology, 2023, 13: 1213045.
- [9] PENGIRAN MOHAMAD D N F, MASHOHOR S, MAHMUD R, et al. Transition of traditional method to deep learning based computer-aided system for breast cancer using automated breast ultrasound system (ABUS) images: a review[J]. Artificial Intelligence Review, 2023, 56(12): 15271-15300.
- [10] ZHAO X, BAI J W, GUO Q, et al. Clinical applications of deep learning in breast MRI[J]. Biochimica et Biophysica Acta (BBA)-Reviews on Cancer, 2023: 188864.
- [11] 欧阳汝珊, 林小慧, 马捷. 基于深度学习的乳腺X线摄影的临床应用价值[J]. 国际医学放射学杂志, 2021, 44(6): 673-677.  
OUYANG R S, LIN X H, MA J. Clinical value of deep learning-based mammography[J]. International Journal of Medical Radiology, 2021, 44(6): 673-677.
- [12] 张晓栋, 张光. 基于磁共振图像的深度学习方法在乳腺癌中的研究进展[J]. 临床放射学杂志, 2023, 42(7): 1197-1200.  
ZHANG X D, ZHANG G. Research progress of deep learning method based on MRI in breast cancer[J]. Journal of Clinical Radiology, 2023, 42(7): 1197-1200.
- [13] 中国抗癌协会乳腺癌诊治指南与规范(2021年版)[J]. 中国癌症杂志, 2021, 31(10): 954-1040.  
CACA guideline for breast cancer(2021)[J]. China Oncology, 2021, 31(10): 954-1040.
- [14] MICHELL M J, IQBAL A, WASAN R K, et al. A comparison of the accuracy of film-screen mammography, full-field digital mammography, and digital breast tomosynthesis[J]. Clinical Radiology, 2012, 67(10): 976-981.
- [15] PISANO E D, GATSONIS C, HENDRICK E, et al. Diagnostic performance of digital versus film mammography for breast-cancer screening[J]. New England Journal of Medicine, 2005, 353(17): 1773-1783.
- [16] HEDDSON B, RÖNNOW K, OLSSON M, et al. Digital versus screen-film mammography: a retrospective comparison in a population-based screening program[J]. European Journal of Radiology, 2007, 64(3): 419-425.
- [17] 戴东. 国产乳腺专用PET(PEM)对乳腺癌诊断价值的临床研究[D]. 天津: 天津医科大学, 2016.  
DAI D. The clinical study of domestic dedicated positron emission mammography in the diagnosis of breast cancer [D]. Tianjin: Tianjin Medical University, 2016.
- [18] SKAANE P, BANDOS A I, GULLIEN R, et al. Comparison of digital mammography alone and digital mammogra-

- phy plus tomosynthesis in a population-based screening program[J]. *Radiology*, 2013, 267(1): 47-56.
- [19] BURT J R, TOROSDAGLI N, KHOSRAVAN N, et al. Deep learning beyond cats and dogs: recent advances in diagnosing breast cancer with deep neural networks[J]. *The British Journal of Radiology*, 2018, 91(1089): 20170545.
- [20] SHARMA S, MEHRA R. Conventional machine learning and deep learning approach for multi-classification of breast cancer histopathology images—a comparative insight[J]. *Journal of Digital Imaging*, 2020, 33: 632-654.
- [21] HEATH M, BOWYER K, KOPANS D, et al. Current status of the digital database for screening mammography[J]. *Digital Mammography*, 1998, 13: 457-460.
- [22] 中国抗癌协会乳腺癌诊治指南与规范(2019年版)[J]. *中国癌症杂志*, 2019, 29(8): 609-680.  
CACA guideline for breast cancer(2019)[J]. *China Oncology*, 2019, 29(8): 609-680.
- [23] LEE R S, GIMENEZ F, HOOGI A, et al. A curated mammography data set for use in computer-aided detection and diagnosis research[J]. *Scientific Data*, 2017, 4(1): 1-9.
- [24] SUCKLING J, PARKER J, DANCE D. Mammographic image analysis society (MIAS) database v1.21[EB/OL]. (2021-06-05) [2023-08-02]. <https://www.repository.cam.ac.uk/handle/1810/250394>.
- [25] OLIVER A, FREIXENET J, MARTI J, et al. A review of automatic mass detection and segmentation in mammographic images[J]. *Medical Image Analysis*, 2010, 14(2): 87-110.
- [26] DOMINGUEZ A R, NANDI A K. Detection of masses in mammograms using enhanced multilevel-thresholding segmentation and region selection based on rank[C]//Proceedings of the 2007 IASTED International Conference on Biomedical Engineering, Innsbruck, Feb 14-16, 2007: 370-375.
- [27] MOREIRA I C, AMARAL I, DOMINGUES I, et al. In-breast: toward a full-field digital mammographic database [J]. *Academic Radiology*, 2012, 19(2): 236-248.
- [28] MATHEUS B R N, SCHIABEL H. Online mammographic images database for development and comparison of CAD schemes[J]. *Journal of Digital Imaging*, 2011, 24: 500-506.
- [29] FITZGERALD R. Error in radiology[J]. *Clinical Radiology*, 2001. DOI: 10.1053/crad.2001.0858.
- [30] LANDHUIS E. Deep learning takes on tumours[J]. *Nature*, 2020, 580(7804): 551-554.
- [31] RIBLI D, HORVÁTH A, UNGER Z, et al. Detecting and classifying lesions in mammograms with deep learning[J]. *Scientific Reports*, 2018, 8(1): 4165.
- [32] SUN L, SUN H, WANG J, et al. Breast mass detection in mammography based on image template matching and CNN[J]. *Sensors*, 2021, 21(8): 2855.
- [33] GARRUCHO L, KUSHIBAR K, JOUIDE S, et al. Domain generalization in deep learning based mass detection in mammography: a large-scale multi-center study[J]. *Artificial Intelligence in Medicine*, 2022, 132: 102386.
- [34] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, Jun 27-30, 2016. Washington: IEEE Computer Society, 2016: 779-788.
- [35] AL-ANTARI M A, AL-MASNI M A, CHOI M T, et al. A fully integrated computer-aided diagnosis system for digital X-ray mammograms via deep learning detection, segmentation, and classification[J]. *International Journal of Medical Informatics*, 2018, 117: 44-54.
- [36] SU Y, LIU Q, XIE W, et al. YOLO-LOGO: a transformer-based YOLO segmentation model for breast mass detection and segmentation in digital mammograms[J]. *Computer Methods and Programs in Biomedicine*, 2022, 221: 106903.
- [37] HONJO T, UEDA D, KATAYAMA Y, et al. Visual and quantitative evaluation of microcalcifications in mammograms with deep learning-based super-resolution[J]. *European Journal of Radiology*, 2022, 154: 110433.
- [38] UEDA D, YAMAMOTO A, ONODA N, et al. Development and validation of a deep learning model for detection of breast cancers in mammography from multi-institutional datasets[J]. *PLoS One*, 2022, 17(3): e0265751.
- [39] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of the 2017 IEEE International Conference on Computer Vision, Venice, Oct 22-29, 2017. Washington: IEEE Computer Society, 2017: 2980-2988.
- [40] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, Jun 26-Jul 1, 2016. Washington: IEEE Computer Society, 2016: 770-778.
- [41] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, Jul 21-26, 2017. Washington: IEEE Computer Society, 2017: 2117-2125.
- [42] BECKER A S, MARCON M, GHAFOR S, et al. Deep learning in mammography: diagnostic accuracy of a multi-purpose image analysis software in the detection of breast cancer[J]. *Investigative Radiology*, 2017, 52(7): 434-440.
- [43] RODRÍGUEZ-RUIZ A, KRUPINSKI E, MORDANG J J, et al. Detection of breast cancer with mammography: effect of an artificial intelligence support system[J]. *Radiology*, 2019, 290(2): 305-314.
- [44] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//

- LNCS 9351: Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich, Oct 5-9, 2015. Cham: Springer, 2015: 234-241.
- [45] SOULAMI K B, KAABOUCHE N, SAIDI M N, et al. Breast cancer: one-stage automated detection, segmentation, and classification of digital mammograms using UNet model based-semantic segmentation[J]. *Biomedical Signal Processing and Control*, 2021, 66: 102481.
- [46] SALAMA W M, ALY M H. Deep learning in mammography images segmentation and classification: automated CNN approach[J]. *Alexandria Engineering Journal*, 2021, 60(5): 4701-4709.
- [47] ALKHALEEF AH M, TAN T H, CHANG C H, et al. Connected-SegNets: a deep learning model for breast tumor Segmentation from X-ray images[J]. *Cancers*, 2022, 14(16): 4030.
- [48] AHMED L, IQBAL M M, ALDABBAS H, et al. Images data practices for semantic segmentation of breast cancer using deep neural network[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2020(1).
- [49] ZHOU K, LI W, ZHAO D. Deep learning-based breast region extraction of mammographic images combining pre-processing methods and semantic segmentation supported by Deeplab v3+[J]. *Technology and Health Care*, 2022, 30(S1): 173-190.
- [50] KAVITHA T, MATHAI P P, KARTHIKEYAN C, et al. Deep learning based capsule neural network model for breast cancer diagnosis using mammogram images[J]. *Interdisciplinary Sciences: Computational Life Sciences*, 2022, 14: 113-129.
- [51] KAPUR J N, SAHOO P K, WONG A K C. A new method for gray-level picture thresholding using the entropy of the histogram[J]. *Computer Vision, Graphics, and Image Processing*, 1985, 29(3): 273-285.
- [52] MALEBARY S J, HASHMI A. Automated breast mass classification system using deep learning and ensemble learning in digital mammogram[J]. *IEEE Access*, 2021, 9: 55312-55328.
- [53] SAMEE N A, ATTEIA G, MESHOU S, et al. Deep learning cascaded feature selection framework for breast cancer classification: hybrid CNN with univariate-based approach[J]. *Mathematics*, 2022, 10(19): 3631.
- [54] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]// *Advances in Neural Information Processing Systems* 25, Lake Tahoe, Dec 3-6, 2012: 1106-1114.
- [55] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. *arXiv:1409.1556*, 2014.
- [56] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// *Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition*, Boston, Jun 7-12, 2015. Washington: IEEE Computer Society, 2015: 1-9.
- [57] BACCOUCHE A, GARCIA-ZAPIRAIN B, ELMAGHRABY A S. An integrated framework for breast mass classification and diagnosis using stacked ensemble of residual neural networks[J]. *Scientific Reports*, 2022, 12(1): 12259.
- [58] CAI H, HUANG Q, RONG W, et al. Breast microcalcification diagnosis using deep convolutional neural network from digital mammograms[J]. *Computational and Mathematical Methods in Medicine*, 2019: 2717454.
- [59] TIRYAKI V M. Deep transfer learning to classify mass and calcification pathologies from screen film mammograms [J]. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 2023, 12(1): 57-65.
- [60] YAP M H, PONS G, MARTI J, et al. Automated breast ultrasound lesions detection using convolutional neural networks [J]. *IEEE Journal of Biomedical and Health Informatics*, 2017, 22(4): 1218-1226.
- [61] BALAHA H M, SAIF M, TAMER A, et al. Hybrid deep learning and genetic algorithms approach (HMBDLGAHA) for the early ultrasound diagnoses of breast cancer[J]. *Neural Computing and Applications*, 2022, 34(11): 8671-8695.
- [62] ZHANG Z, LI Y, WU W, et al. Tumor detection using deep learning method in automated breast ultrasound[J]. *Biomedical Signal Processing and Control*, 2021, 68: 102677.
- [63] ZHOU Y, CHEN H, LI Y, et al. 3D multi-view tumor detection in automated whole breast ultrasound using deep convolutional neural network[J]. *Expert Systems with Applications*, 2021, 168: 114410.
- [64] MALEKMOHAMMADI A, BAREKATREZAEI S, KOZEGAR E, et al. Mass detection in automated 3-D breast ultrasound using a patch Bi-ConvLSTM network[J]. *Ultrasonics*, 2023, 129: 106891.
- [65] BYRA M, GALPERIN M, OJEDA-FOURNIER H, et al. Breast mass classification in sonography with transfer learning using a deep convolutional neural network and color conversion[J]. *Medical Physics*, 2019, 46(2): 746-755.
- [66] FUJIOKA T, KUBOTA K, MORI M, et al. Virtual interpolation images of tumor development and growth on breast ultrasound image synthesis with deep convolutional generative adversarial networks[J]. *Journal of Ultrasound in Medicine*, 2021, 40(1): 61-69.
- [67] HAN L, HUANG Y, DOU H, et al. Semi-supervised segmentation of lesion from breast ultrasound images with attentional generative adversarial network[J]. *Computer Methods and Programs in Biomedicine*, 2020, 189: 105275.
- [68] LI Y, LIU Y, HUANG L, et al. Deep weakly-supervised breast tumor segmentation in ultrasound images with ex-

- licit anatomical constraints[J]. *Medical Image Analysis*, 2022, 76: 102315.
- [69] ALMAJALID R, SHAN J, DU Y, et al. Development of a deep-learning-based method for breast ultrasound image segmentation[C]//*Proceedings of the 2018 17th IEEE International Conference on Machine Learning and Applications*, Orlando, Dec 17-20, 2018. Piscataway: IEEE, 2018: 1103-1108.
- [70] SANNASI CHAKRAVARTHY S R, RAJAGURU H. SKMAT-U-Net architecture for breast mass segmentation[J]. *International Journal of Imaging Systems and Technology*, 2022, 32(6): 1880-1888.
- [71] BYRA M, JAROSIK P, DOBRUCH-SOBCZAK K, et al. Joint segmentation and classification of breast masses based on ultrasound radio-frequency data and convolutional neural networks[J]. *Ultrasonics*, 2022, 121: 106682.
- [72] RAGAB M, ALBUKHARI A, ALYAMI J, et al. Ensemble deep-learning-enabled clinical decision support system for breast cancer diagnosis and classification on ultrasound images[J]. *Biology*, 2022, 11(3): 439.
- [73] AL-DHABYANI W, GOMAA M, KHALED H, et al. Dataset of breast ultrasound images[J]. *Data in Brief*, 2020, 28: 104863.
- [74] HAN S, KANG H K, JEONG J Y, et al. A deep learning framework for supporting the classification of breast lesions in ultrasound images[J]. *Physics in Medicine & Biology*, 2017, 62(19): 7714.
- [75] KAPLAN E, CHAN W Y, DOGAN S, et al. Automated BI-RADS classification of lesions using pyramid triple deep feature generator technique on breast ultrasound images[J]. *Medical Engineering & Physics*, 2022, 108: 103895.
- [76] DING W, WANG J, ZHOU W, et al. Joint localization and classification of breast cancer in B-Mode ultrasound imaging via collaborative learning with elastography[J]. *IEEE Journal of Biomedical and Health Informatics*, 2022, 26(9): 4474-4485.
- [77] JABEEN K, KHAN M A, ALHAISONI M, et al. Breast cancer classification from ultrasound images using probability-based optimal deep learning feature fusion[J]. *Sensors*, 2022, 22(3): 807.
- [78] RAZA A, ULLAH N, KHAN J A, et al. DeepBreastCancer-Net: a novel deep learning model for breast cancer detection using ultrasound images[J]. *Applied Sciences*, 2023, 13(4): 2082.
- [79] MAICAS G, CARNEIRO G, BRADLEY A P, et al. Deep reinforcement learning for active breast lesion detection from DCE-MRI[C]//*LNCS 10435: Proceedings of the 20th International Conference on Medical Image Computing and Computer-Assisted Intervention*, Quebec, Sep 11-13, 2017. Cham: Springer, 2017: 665-673.
- [80] ZHOU J, ZHANG Y, CHANG K T, et al. Diagnosis of benign and malignant breast lesions on DCE-MRI by using radiomics and deep learning with consideration of peritumor tissue[J]. *Journal of Magnetic Resonance Imaging*, 2020, 51(3): 798-809.
- [81] DAIMIEL NARANJO I, GIBBS P, REINER J S, et al. Breast lesion classification with multiparametric breast MRI using radiomics and machine learning: a comparison with radiologists' performance[J]. *Cancers*, 2022, 14(7): 1743.
- [82] ADACHI M, FUJIOKA T, MORI M, et al. Detection and diagnosis of breast cancer using artificial intelligence based assessment of maximum intensity projection dynamic contrast-enhanced magnetic resonance images[J]. *Diagnostics*, 2020, 10(5): 330.
- [83] AYATOLLAHI F, SHOKOUHI S B, MANN R M, et al. Automatic breast lesion detection in ultrafast DCE-MRI using deep learning[J]. *Medical Physics*, 2021, 48(10): 5897-5907.
- [84] ZHANG Y, LIU Y L, NIE K, et al. Deep learning-based automatic diagnosis of breast cancer on MRI using mask R-CNN for detection followed by ResNet50 for classification [J]. *Academic Radiology*, 2023, 30(S2): S161-S171.
- [85] ZHANG J, SAHA A, ZHU Z, et al. Hierarchical convolutional neural networks for segmentation of breast tumors in MRI with application to radiogenomics[J]. *IEEE Transactions on Medical Imaging*, 2018, 38(2): 435-447.
- [86] LU W, WANG Z, HE Y, et al. Breast cancer detection based on merging four modes MRI using convolutional neural networks[C]//*Proceedings of the 2019 IEEE International Conference on Acoustics, Speech and Signal Processing*, Brighton, May 12-17, 2019. Piscataway: IEEE, 2019: 1035-1039.
- [87] YUE W, ZHANG H, ZHOU J, et al. Deep learning-based automatic segmentation for size and volumetric measurement of breast cancer on magnetic resonance imaging[J]. *Frontiers in Oncology*, 2022. DOI: 10.3389/fonc.2022.984626.
- [88] LIU X, ZHANG Y, JING H, et al. Ore image segmentation method using U-Net and Res\_Unet convolutional networks [J]. *RSC Advances*, 2020, 10(16): 9396-9406.
- [89] CARVALHO E D, SILVA R R V, MATHEW M J, et al. Tumor segmentation in breast DCE-MRI slice using deep learning methods[C]//*Proceedings of the 2021 IEEE Symposium on Computers and Communications*, Athens, Sep 5-8, 2021. Piscataway: IEEE, 2021: 1-6.
- [90] BOUCHEBBAH F, SLIMANI H. 3D automatic levels propagation approach to breast MRI tumor segmentation[J]. *Expert Systems with Applications*, 2021, 165: 113965.
- [91] LIU M Z, SWINTELSKI C, SUN S, et al. Weakly supervised deep learning approach to breast MRI assessment[J]. *Academic Radiology*, 2022, 29: S166-S172.
- [92] JING X, WIELEMA M, CORNELISSEN L J, et al. Using deep learning to safely exclude lesions with only ultrafast breast MRI to shorten acquisition and reading time[J]. *European Radiology*, 2022, 32(12): 8706-8715.
- [93] VERBURG E, VAN GILS C H, VAN DER VELDEN B H M, et al. Deep learning for automated triaging of 4581 breast MRI examinations from the DENSE trial[J]. *Radiology*, 2022, 302(1): 29-36.
- [94] ZHU Z, ALBADAWY E, SAHA A, et al. Deep learning for

- identifying radiogenomic associations in breast cancer[J]. *Computers in Biology and Medicine*, 2019, 109: 85-90.
- [95] ZHANG Y, CHEN J H, LIN Y, et al. Prediction of breast cancer molecular subtypes on DCE-MRI using convolutional neural network with transfer learning between two centers [J]. *European Radiology*, 2021, 31: 2559-2567.
- [96] MORRIS E A, COMSTOCK C E, LEE C H, et al. ACR BI-RADS<sup>®</sup> magnetic resonance imaging[J]. *ACR BI-RADS<sup>®</sup> Atlas, Breast Imaging Reporting and Data System*, 2013, 5.
- [97] GIESS C S, YE H E D, RAZA S, et al. Background parenchymal enhancement at breast MR imaging: normal patterns, diagnostic challenges, and potential for false-positive and false-negative interpretation[J]. *Radiographics*, 2014, 34(1): 234-247.
- [98] BORKOWSKI K, ROSSI C, CIRITSIS A, et al. Fully automatic classification of breast MRI background parenchymal enhancement using a transfer learning approach[J]. *Medicine*, 2020, 99(29): e21243.
- [99] ESKREIS-WINKLER S, SUTTON E J, D'ALESSIO D, et al. Breast MRI background parenchymal enhancement categorization using deep learning: outperforming the radiologist [J]. *Journal of Magnetic Resonance Imaging*, 2022, 56(4): 1068-1076.
- [100] MORI M, FUJIOKA T, KATSUTA L, et al. Diagnostic performance of time-of-flight PET/CT for evaluating nodal metastasis of the axilla in breast cancer[J]. *Nuclear Medicine Communications*, 2019, 40(9): 958-964.
- [101] ISHIBA T, NAKAGAWA T, SATO T, et al. Efficiency of fluorodeoxyglucose positron emission tomography/computed tomography to predict prognosis in breast cancer patients received neoadjuvant chemotherapy[J]. *Springer-Plus*, 2015, 4(1): 1-9.
- [102] TAKAHASHI K, FUJIOKA T, OYAMA J, et al. Deep learning using multiple degrees of maximum-intensity projection for PET/CT image classification in breast cancer[J]. *Tomography*, 2022, 8(1): 131-141.
- [103] WEBER M, KERSTING D, UMUTLU L, et al. Just another "Clever Hans"? Neural networks and FDG PET-CT to predict the outcome of patients with breast cancer[J]. *European Journal of Nuclear Medicine and Molecular Imaging*, 2021, 48: 3141-3150.
- [104] MOREAU N, ROUSSEAU C, FOURCADE C, et al. Deep learning approaches for bone and bone lesion segmentation on 18FDG PET/CT imaging in the context of metastatic breast cancer[C]//*Proceedings of the 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society*, Montreal, Jul 20- 24, 2020. Piscataway: IEEE, 2020: 1532-1535.
- [105] ZHANG Z, XIE Y, XING F, et al. MDNET: a semantically and visually interpretable medical image diagnosis network[C]//*Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, Jul 21- 26, 2017. Washington: IEEE Computer Society, 2017: 6428-6436.



王一凡(2000—),男,山东济宁人,硕士研究生,主要研究方向为医疗健康大数据。

**WANG Yifan**, born in 2000, M.S. candidate. His research interest is medical and health big data.



刘静(1980—),女,山东济南人,硕士,副教授,CCF会员,主要研究方向为医学图像处理。

**LIU Jing**, born in 1980, M.S., associate professor, CCF member. Her research interest is medical image processing.



马金刚(1980—),男,山东潍坊人,硕士,副教授,主要研究方向为中医药智能化研究。

**MA Jingang**, born in 1980, M.S., associate professor. His research interest is research on the intelligence of traditional Chinese medicine.



邵润华(1999—),男,山东菏泽人,硕士研究生,主要研究方向为医疗健康大数据。

**SHAO Runhua**, born in 1999, M.S. candidate. His research interest is medical and health big data.



陈天真(1980—),男,山东济南人,硕士,主要研究方向为医疗健康大数据。

**CHEN Tianzhen**, born in 1980, M.S. His research interest is medical and health big data.



李明(1978—),男,山东淄博人,硕士,教授,主要研究方向为中医药智能化研究。

**LI Ming**, born in 1978, M.S., professor. His research interest is research on the intelligence of traditional Chinese medicine.