

本文引用格式: 陈翔,蔡延光,龚国俊,等.改进 U-Net 的 X 射线乳腺肿瘤区域分割方法[J].自动化与信息工程,2025,46(4):28-34.

CHEN Xiang, CAI Yanguang, GONG Guojun, et al. X-ray breast tumor region segmentation method using an improved U-Net[J]. Automation & Information Engineering, 2025,46(4):28-34.

改进 U-Net 的 X 射线乳腺肿瘤区域分割方法*

陈翔¹ 蔡延光^{1,2} 龚国俊³ 张瑞湖⁴ 蔡颢⁵

(1.广东工业大学自动化学院, 广东 广州 510006

2.广州理工学院智能制造与电气工程学院, 广东 广州 510540

3.广东省岭南工商第一技师学院, 广东 广州 510000

4.广东省粤东技师学院, 广东 汕头 515000

5.东莞实业投资控股集团有限公司, 广东 东莞 523000)

摘要: 乳腺癌是危害女性健康的重要疾病, 及时准确地诊断是降低乳腺癌死亡率的关键。为提高乳腺癌诊断的准确性, 提出一种改进 U-Net 的 X 射线乳腺肿瘤区域分割方法。首先, 融合空间注意力和通道注意力机制, 构建平行注意力模块, 以加强网络对关键特征的提取和识别能力; 然后, 将平行注意力模块与残差模块相结合, 设计了残差平行注意力模块, 提高 U-Net 模型的深层特征提取与高效聚焦能力; 最后, 将残差平行注意力模块引入 U-Net 模型的编码器部分, 提高了 U-Net 模型对 X 射线乳腺肿瘤区域的分割精度。在 CBIS-DDSM 上的实验结果表明, 改进 U-Net 模型的 Dice 系数和平均交并比分别达到 94.20%和 90.76%, 有效提升了 X 射线乳腺肿瘤区域的分割精度。

关键词: 图像分割; 注意力机制; 乳腺肿瘤; 残差网络; U-Net

中图分类号: TP391.41

文献标志码: A

文章编号: 1674-2605(2025)04-0004-07

DOI: 10.12475/aie.20250404

开放获取

X-ray Breast Tumor Region Segmentation Method Using an Improved U-Net

CHEN Xiang¹ CAI Yanguang^{1,2} GONG Guojun³ ZHANG Ruihu⁴ CAI Hao⁵

(1.College of Automation, Guangdong University of Technology, Guangzhou 510006, China

2.School of Intelligent Manufacturing and Electrical Engineering, Guangzhou Institute of Science and Technology, Guangzhou 510540, China 3.Guangdong Lingnan First Technical College of Industry and Commerce, Guangzhou 510000, China 4.Guangdong Yuedong Technician College, Shantou 515000, China

5.Dongguan Industrial Investment Holding Group Co., Ltd., Dongguan 523000, China)

Abstract: Breast cancer is a serious disease that threatens women's health, and timely and accurate diagnosis is crucial for reducing its mortality rate. To improve the accuracy of breast cancer diagnosis, this study proposes an enhanced U-Net-based method for segmenting breast tumor regions in X-ray images. First, a parallel attention module is constructed by integrating spatial and channel attention mechanisms to strengthen the network's ability to extract and identify key features. Next, the parallel attention module is combined with a residual module to design a residual parallel attention module, enhancing the U-Net model's deep feature extraction and high-efficiency focusing capabilities. Finally, the residual parallel attention module is incorporated into the encoder part of the U-Net model, improving its segmentation accuracy for X-ray breast tumor regions. Experimental results on the CBIS-DDSM dataset demonstrate that the improved U-Net model achieves Dice coefficients and mean intersection over union (mIoU) of 94.20% and 90.76%, respectively, significantly enhancing the segmentation accuracy of X-ray breast tumor regions.

Keywords: image segmentation; attention mechanism; breast tumor; residual network; U-Net

28 * 基金项目: 广东省科技计划项目(2016A050502060, 2020B-1010010005); 广州市科技计划项目(202206010011, 2023B-03J1339)。

0 引言

乳腺癌是女性常见的恶性肿瘤之一, 约占所有女性癌症病例的 30%^[1-2], 占癌症相关死亡总数的 17%^[3], 已成为女性癌症死亡的主要原因之一。目前, 乳腺 X 射线检查是乳腺癌筛查的主要方法^[4-6], 其通过乳房内部各类乳腺组织(腺体、脂肪组织和纤维组织等)在 X 射线下呈现的不同纹理和亮度特征, 为医生提供诊断依据^[7-8], 如在乳腺 X 射线图像中发现肿块或微小钙化点等异常征象, 提示医生需进一步深入检查^[9-10]。然而, 由于乳腺组织的复杂性及患者个体的差异性, 即使是经验丰富的医生也难以准确诊断乳腺癌^[11-13]。因此, 探索更加精准、智能的辅助诊断方法, 对提高乳腺癌的早期检出率与诊断准确性具有重要意义。

近些年, 学者们对乳腺癌辅助诊断方法开展了大量研究。文献[14]将条件生成对抗网络用于乳腺 X 射线图像感兴趣区域的分割, 在 INbreast 数据集上的 Dice 系数和平均交并比(mean intersection over union, mIoU)分别为 94%和 87%; 但当乳腺 X 射线图像中同时存在完整形状和不完整形状的肿瘤时, 该方法仅能准确分割完整形状的肿瘤, 难以准确分割不完整形状的肿瘤。文献[15]将多尺度图像信息融入到全卷积密集网络模型中, 在私有数据集上的 Dice 系数和 mIoU 分别为 76.97%和 60.41%; 该方法虽然在一定程度上解决了多尺度特征融合的问题, 但分割精度仍有待提高。文献[16]提出一种利用先验知识学习的 X 射线乳腺肿瘤区域分割方法, 在私有数据集上的 mIoU 达到 93.50%; 尽管该方法提高了分割精度, 但其庞大的参数规模降低了分割效率。

在医学图像分割领域, 可用数据相对有限, 但 U-Net 模型^[17]凭借其在数据量较少的情况下仍能保持较高的分割精度, 已成为该领域广泛应用的重要方法。文献[18]将 U-Net 与注意力门相结合, 采用交叉熵损失函数进行训练, 在乳腺筛查数字数据库(digital database for screening mammography, DDSM)上的 F1 分数、灵敏度和准确性分别达到 82.24%、77.89%和 78.38%。文献[19]将 U-Net 与残差注意力模块相结合

提出了 RU-Net 网络; 在 INbreast 数据集上的 mIoU 达到 89.10%。上述方法虽然在 X 射线乳腺肿瘤区域分割任务中取得了较好效果, 但分割精度仍未能满足临床应用的要求。

为此, 本文提出一种改进 U-Net 的 X 射线乳腺肿瘤区域分割方法。首先, 基于空间注意力和通道注意力机制, 构建平行注意力模块(parallel attention module, PAM); 然后, 将 PAM 与残差模块相结合, 得到残差平行注意力模块(residual parallel attention module, ResPAM), 使 U-Net 模型聚焦于 X 射线乳腺肿瘤区域的有效特征, 从而增强 U-Net 模型的特征提取能力, 减少特征损失。

1 数据集

本文选取乳腺筛查数字数据库精选子集(curated breast imaging subset of DDSM, CBIS-DDSM)^[20]中的 1 318 幅乳腺 X 射线图像进行分析。为了有效缓解深度学习模型的过拟合现象, 进一步增强模型的泛化能力, 对乳腺 X 射线图像采用旋转和翻转操作进行图像增强。首先, 对该图像进行随机旋转操作, 旋转角度在 $\pm 10^\circ$ 之间; 然后, 将该图像沿特定轴(如水平轴)进行翻转操作, 从而将该图像数量扩充至 17 134 幅; 最后, 按照 8:2 的比例, 将扩充后的乳腺 X 射线图像划分为训练集(13 707 幅)和验证集(3 427 幅)。

2 分割方法

本文设计了一种改进的 U-Net 模型, 在融合空间注意力和通道注意力机制构建 PAM 的基础上, 结合残差模块, 改进 U-Net 的编码器网络, 以增强模型对乳腺肿瘤关键特征的提取和识别能力。

2.1 PAM

注意力机制通过提取目标的关键信息, 使神经网络关注有用特征并抑制无用特征, 从而提高神经网络的性能^[21]。

PAM 是一种基于注意力机制的特征增强模块, 其通过空间位置关系建模来重构输入特征图。在 PAM 对输入进行特征提取的过程中, 首先, 赋予通道

注意力模块和空间注意力模块相同的优先级，同时学习得到通道特征和空间特征；然后，采用可学习的加权融合方法提取混合域特征，实现特征图的通道和空间信息交互，从而充分利用通道注意力信息和空间注意力信息。PAM 网络结构如图 1 所示。




图 1 PAM 网络结构图

首先，通过 1×1 的卷积层将输入特征图的通道数减半；然后，同时计算一维通道注意力特征向量和二维空间注意力特征图，计算公式为

$$F' = \text{Conv}(F) \quad (1)$$

$$M_c(F') = \sigma \left(\begin{matrix} \text{CRC}(\text{AvgPool}(F')) + \\ \text{CRC}(\text{MaxPool}(F')) \end{matrix} \right) \quad (2)$$

$$M_s(F') = \sigma \left(f^{7 \times 7} \left(\text{Concat} \left(\begin{matrix} \text{AvgPool}(F') \\ \text{MaxPool}(F') \end{matrix} \right) \right) \right) \quad (3)$$

式中：Conv 为将输入特征图通道数减半的卷积操作，得到的特征图为 $F' \in R^{H \times W \times C/2}$ ； $M_c(F') \in R^{1 \times 1 \times C/2}$ 、 $M_s(F') \in R^{H \times W \times 1}$ 分别为通道注意力模块、空间注意力模块的输出； σ 为 Sigmoid 激活函数；CRC 为 2 个 1×1 卷积层和 1 个 ReLU 激活函数；AvgPool、

MaxPool 分别为平均池化和最大池化操作； $f^{7 \times 7}$ 为卷积核为 7×7 的卷积操作；Concat 为通道维度的拼接操作。

基于公式(1)~(3)，PAM 的输出公式为

$$F'' = M_c(F') \otimes F' + M_s(F') \otimes F' \quad (4)$$

PAM 通过学习得到输入特征图的空间特征和通道特征，再进行融合操作，即可得到重构的输入特征图。

2.2 ResPAM

ResPAM 结合了 PAM 与残差模块，其网络结构如图 2 所示。




图 2 ResPAM 网络结构图

首先，输入经过 3 个残差模块（2 个 1×1 的卷积层和 1 个 3×3 的卷积层）的特征提取，并通过引入跳跃连接将输入直接传递给输出。

然后，残差模块的输出经过 PAM，得到 ResPAM 的输出，计算公式为

$$X' = H(X, \omega_i) + X \quad (5)$$

$$X'' = P_{\text{PAM}}(X') \quad (6)$$

式中： X 为输入； $H(X, \omega_i)$ 为残差模块的主路径，由卷积层组成； ω_i 为主路径的可学习参数。

ResPAM 通过引入残差模块，解决了深度神经网络训练过程中的梯度消失和网络退化问题，提高了 U-

-Net 模型的性能和训练效率。

2.3 改进的 U-Net 模型

将 U-Net 的编码器部分替换为 ResPAM，得到改进的 U-Net 模型，其网络结构如图 3 所示。




图 3 改进 U-Net 模型的网络结构

改进 U-Net 模型的网络结构呈对称 U 形，由编码路径（下采样）和解码路径（上采样）组成。其中，编码路径通过 ResPAM 逐步提取高层次特征并缩小特征图尺寸；解码路径通过上采样和跳跃连接逐步恢复空间信息并生成分割结果。跳跃连接将编码路径中的特征直接传递给解码路径，帮助改进的 U-Net 模型保留低层次的细节信息，提升分割精度。

3 实验

3.1 实验环境

本文方法基于 PyTorch 框架实现，实验采用的编程语言为 Python，处理器为 Intel Core i5-12600KF，内存为 16 GB，显卡为 NVIDIA RTX 3060Ti。

3.2 参数设置

实验选择 Adam 作为优化器，设置学习率为 0.001，批量大小为 8，训练轮数为 100。

3.3 评估指标

为验证本文提出的改进 U-Net 模型在 X 射线乳腺肿瘤区域分割任务中的有效性，采用 Dice 系数和

mIoU 作为评估指标。Dice 系数是常用的相似性度量指标，用于衡量模型分割结果与真实分割结果之间的重叠程度，取值范围在 0~1 之间，数值越接近 1，表示模型分割结果与真实分割结果越相似。mIoU 是一个衡量预测边界框与真实边界框之间重叠程度的指标，取值范围在 0~1 之间，数值越接近 1，表示模型分割结果与真实分割结果越相似。Dice 系数和 mIoU 的计算公式分别为

$$D_{\text{Dice score}} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (7)$$

$$I_{\text{mIoU}} = \frac{TP}{TP + FP + FN} \quad (8)$$

式中：TP 为正确预测为肿瘤的像素总数；FP 为将肿瘤预测为背景的像素总数；FN 为将背景预测为肿瘤的像素总数。

3.4 实验结果与分析

训练数据集采用 CBIS-DDSM，所有训练输入图像的大小均为 224×224 像素。改进 U-Net 模型的训练损失曲线如图 4 所示。




图 4 改进 U-Net 模型的训练损失曲线图

由图4可知,在训练过程中,损失函数逐渐下降,表明改进的 U-Net 模型逐渐收敛,且未出现过拟合现象,验证了本文改进策略的有效性。

将本文模型(改进的 U-Net 模型)与 DS U-Net^[22]、AU-Net^[23]、U-Net^[17]、Connected-U-Nets^[24]、SegNet^[25]、Connected-SegNets^[26]图像分割模型进行对比实验,结果如表 1 所示。

表 1 7 种图像分割模型的对比实验结果 %

模型	Dice 系数	mIoU
本文模型	94.20	90.76
DS U-Net	82.70	85.70
AU-Net	89.03	82.65
U-Net	90.47	84.79
Connected-U-Nets	90.66	85.81
SegNet	90.52	85.30
Connected-SegNets	92.86	87.34

由表 1 可知,本文模型在 CBIS-DDSM 上的 Dice 系数和 mIoU 分别为 94.20%和 90.76%,相较于其他 6 种图像分割模型具有更好的效果。

改进的 U-Net 模型对 X 射线乳腺肿瘤区域分割结果如图 5 所示。




图 5 改进的 U-Net 模型对 X 射线乳腺肿瘤区域分割结果

由图 5 可知,改进的 U-Net 模型能够准确捕捉肿瘤区域的边界和细节,分割结果与真实标签的重叠程度较高,表明改进的 U-Net 模型在特征提取、上下文信息融合或边界处理等方面具有优势,提高了分割精度。

4 结论

为了提高 U-Net 模型对 X 射线乳腺肿瘤区域的分割性能,本文构建了 PAM 和 ResPAM,并利用 ResPAM改进 U-Net 模型。在公开数据集 CBIS-DDSM 上进行 X 射线乳腺肿瘤区域分割实验。实验结果表明,改进 U-Net 模型的 Dice 系数和 mIoU 分别达到 94.20%和 90.76%,验证了本文方法的有效性。

随着深度学习技术的不断发展和计算能力的持续提升,未来对 X 射线乳腺肿瘤区域分割方法的进一步研究建议包括:

1) 探索更多样化、更大规模的数据集,以涵盖更多类型的乳腺肿瘤病变和更广泛的图像质量变化;同时,推动数据集的标准化处理,如统一图像格式、数据标注标准等,这将有助于不同研究之间的比较和结果的可重复性;

2) 研究弱监督^[27]或无监督学习方法^[28]在 X 射

线乳腺肿瘤区域分割中的应用,以降低对大量标注数据的依赖,提高模型的泛化能力;

3) 结合其他医学影像模态的信息,利用多模态融合技术,进一步提升 X 射线乳腺肿瘤区域分割的准确性和可靠性。

©The author(s) 2024. This is an open access article under the CC BY-NC-ND 4.0 License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>)

参考文献

- [1] SIEGEL R L, MILLER K D, JEMAL A. Cancer statistics, 2016[J]. CA: A Cancer Journal for Clinicians, 2016,66(1):7-30.
- [2] SASLOW D, BOETES C, BURKE W, et al. American cancer society guidelines for breast screening with MRI as an adjunct to mammography[J]. CA: A Cancer Journal for Clinicians, 2007, 57(2):75-89.
- [3] MANIECKA-BRYŁA I, BRYŁA M, BRYŁA P, et al. The burden of premature mortality in Poland analysed with the use of standard expected years of life lost[J]. BMC Public Health, 2015,15(1):101.
- [4] ALMALKI Y E, SOOMRO T A, IRFAN M, et al. Computerized analysis of mammogram images for early detection of breast cancer[J]. Healthcare, 2022,10(5):801.
- [5] ZOU R, LOKE S Y, TAN K M, et al. Development of a microRNA panel for classification of abnormal mammograms for breast cancer[J]. Cancers, 2021,13(9):2130.
- [6] LI J, GUAN X, FAN Z, et al. Non-invasive biomarkers for early detection of breast cancer[J]. Cancers, 2020,12(10):2767.
- [7] SHI P, ZHONG J, RAMPUN A, et al. A hierarchical pipeline for breast boundary segmentation and calcification detection in mammograms[J]. Computers in Biology and Medicine, 2018, 96:178-188.
- [8] WAKS A G, WINER E P. Breast cancer treatment: A review[J]. Jama, 2019,321(3):288-300.
- [9] SALGADO R, DENKERT C, DEMARIA S, et al. The evaluation of tumor-infiltrating lymphocytes (TILs) in breast cancer: recommendations by an International TILs Working Group 2014[J]. Ann Oncol, 2015,26(2):259-271.
- [10] TARIQ M, IQBAL S, AYESHA H, et al. Medical image based breast cancer diagnosis: State of the art and future directions[J]. Expert Systems with Applications, 2021,167:114095.
- [11] PETRILLO A, FUSCO R, DI BERNARDO E, et al. Prediction of breast cancer histological outcome by radiomics and artificial intelligence analysis in contrast-enhanced mammography[J]. Cancers (Basel), 2022,14(9):2132.
- [12] 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, 2023,14(11):15227-15243.
- [13] LE E P V, WANG Y, HUANG Y, et al. Artificial intelligence in breast imaging[J]. Clin Radiol, 2019,74(5):357-366.
- [14] SINGH V K, RASHWAN H A, Romani S, et al. Breast tumor segmentation and shape classification in mammograms using generative adversarial and convolutional neural network[J]. Expert Systems with Applications, 2020,139:112855.
- [15] HAI J, QIAO K, CHEN J, et al. Fully convolutional denseNet with multiscale context for automated breast tumor segmentation[J]. Journal of Healthcare Engineering, 2019:8415485.
- [16] 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, 2019,38(2):435-447.
- [17] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015,2015:234-241.
- [18] LI S, DONG M, DU G, et al. Attention Dense-U-Net for automatic breast mass segmentation in digital mammogram[J]. IEEE Access, 2019,7:59037-59047.
- [19] ABDELHAFIZ D, NABAVI S, AMMAR R, et al. Residual deep learning system for mass segmentation and classification in mammography[C]. Proceedings of the 10th ACM International Conference on Bioinformatics, Computational Biology and Health Informatics, 2019:475-484.
- [20] LEE R S, GIMENEZ F, HOOGI A, et al. A curated mammography data set for use in computer-aided detection and diagnosis research[J]. Sci Data, 2017,4(1):170177.
- [21] BRAUWERS G, FRASINCAR F. A general survey on attention mechanisms in deep learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2023,35:3279-3298.
- [22] RAJALAKSHMI N R, VIDHYAPRIYA R, ELANGO N, et al.

Deeply supervised U-Net for mass segmentation in digital mammograms[J]. International Journal of Imaging Systems and Technology, 2020,31:59-71.

[23] SUN H, LI C, LIU B, et al. AUNet: Breast mass segmentation of whole mammograms[J]. ArXiv, 2018, abs/1810.10151.

[24] BACCOUCHE A, GARCIA-ZAPIRAIN B, CASTILLO OLEA C, et al. Connected-UNets: A deep learning architecture for breast mass segmentation[J]. NPJ Breast Cancer, 2021, 7(1):151.

[25] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SEGNET: A deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017,39(12):2481-2495.

[26] 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.

[27] 侯鑫桦,董增寿,刘鑫.基于伪标签的弱监督迁移学习模型[J].机床与液压,2021,49(24):185-189.

[28] 刘桂雄,闫奕樸,邢星奥.视觉表面缺陷无监督学习检测方法研究进展[J].中国测试,2024,50(3):1-12.

作者简介:

陈翔,男,1995年生,在读硕士研究生,主要研究方向:机器学习。E-mail: 1185202906@qq.com

蔡延光(通信作者),男,1963年生,博士研究生,教授,博士生导师,主要研究方向:网络控制与优化、组合优化、智能优化、智能交通系统等。E-mail: caiyg99@163.com

龚国俊,男,1982年生,硕士研究生,高级讲师,主要研究方向:机电一体化。E-mail: 251713515@qq.com

张瑞湖,男,1984年生,本科,一级实习指导教师,主要研究方向:机械设计制造及其自动化。E-mail: 215334863@qq.com

蔡颢,男,1987年生,博士研究生,高级工程师,主要研究方向:大数据及人工智能。E-mail: Howardbrutii@foxmail.com



《自动化与信息工程》首届青年编辑委员会

主 任: 吴鸿敏

副主任: 廖 勇 杨楷翔 黄自鑫 陈炜楠

委 员 (以姓氏笔画为序):

- 丁举鹏 马晓阳 王 平 王 欢 王远航 王宜志 王建新 王 涛 王磊磊 左 璇 冯浩楠
- 吕石磊 任志刚 刘文浩 刘国强 汤少敏 贡益明 杜策之 李 丹 李 欢 李春英 李致富
- 杨楷翔 吴国光 吴烽云 吴鸿敏 余 涛 余 攀 沈振萍 宋永兴 宋智翔 张大伟 张 可
- 张占辉 张宇豪 张浪文 陆 亮 陈 旭 陈 磊 陈 霄 陈立佳 陈再励 陈国宇 陈炜楠
- 陈建勋 陈耿新 陈晋鹏 陈晓曼 武 威 范亚军 林创鲁 林旭滨 林粤伟 金 礼 周 健
- 周 鹏 周馨翌 郑天江 宗男夫 赵兴亚 钟森鸣 秦介垚 秦方博 袁君奇 袁照威 徐 鹏
- 高小强 高 帆 高 鹏 唐可可 黄天仑 黄自鑫 黄琮浩 戚远航 崔久好 符 浩 彭世通
- 彭龙江 董斌伟 蒋 凡 焦泽昱 谢海龙 管 峰 廖 勇 廖昭洋