



计算机科学

COMPUTER SCIENCE

多重注意力引导的超声乳腺癌肿瘤图像分割

郭洪洋, 程前, 康晓东, 杨靖怡, 杨舒琪, 李芳, 张蕊

引用本文

郭洪洋, 程前, 康晓东, 杨靖怡, 杨舒琪, 李芳, 张蕊. [多重注意力引导的超声乳腺癌肿瘤图像分割](#)[J]. 计算机科学, 2024, 51(6A): 230500004-6.

GUO Hongyang, CHENG Qian, KANG Xiaodong, YANG Jingyi, YANG Shuqi, LI Fang, ZHANG Rui.

[Multiple Attention-guided Mechanisms for Ultrasound Breast Cancer Tumor Image Segmentation](#)[J].

Computer Science, 2024, 51(6A): 230500004-6.

相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于集成学习的MRI脑肿瘤智能诊断](#)

Intelligent Diagnosis of Brain Tumor with MRI Based on Ensemble Learning

计算机科学, 2024, 51(6A): 230600043-7. <https://doi.org/10.11896/jsjcx.230600043>

[面向3D肝脏CT图像分割的改进vnet模型](#)

Improved vnet Model for 3D Liver CT Image Segmentation

计算机科学, 2024, 51(6A): 230400038-6. <https://doi.org/10.11896/jsjcx.230400038>

[基于图神经网络的乳腺癌病理图像分析方法综述](#)

Survey of Breast Cancer Pathological Image Analysis Methods Based on Graph Neural Networks

计算机科学, 2024, 51(6): 172-185. <https://doi.org/10.11896/jsjcx.230400106>

[基于多尺度视觉感知特征融合的显著目标检测方法](#)

Salient Object Detection Method Based on Multi-scale Visual Perception Feature Fusion

计算机科学, 2024, 51(5): 143-150. <https://doi.org/10.11896/jsjcx.230100132>

[集全尺度融合和循环注意力的医学图像分割网络](#)

Medical Image Segmentation Network Integrating Full-scale Feature Fusion and RNN with Attention

计算机科学, 2024, 51(5): 100-107. <https://doi.org/10.11896/jsjcx.230400114>

多重注意力引导的超声乳腺癌肿瘤图像分割

郭洪洋¹ 程前² 康晓东¹ 杨靖怡¹ 杨舒琪¹ 李芳^{1,3} 张蕊¹

¹ 天津医科大学医学影像学院 天津 300202

² 重庆大学附属黔江医院 重庆 409000

³ 北京市化工职业病防治院 北京 100093

(tmughywl@163.com)

摘要 传统基于 U-Net 超声乳腺图像分割任务中存在预测尺度单一和信息丢失等问题。针对存在的问题,提出一种由多重注意力引导机制的 U-Net 超声乳腺肿瘤图像分割。首先,在 U-Net 的编码结构中,引入多个 SE 通道注意力,对输入的乳腺肿瘤图像进行多层级的语义信息提取,引导编码器聚焦乳腺肿瘤特征,减少冗余背景信息带来的干扰;其次,通过设计特征融合处理模块,对编码器传来的特征图进行复杂语义特征的融合处理;最后,在解码器部分,加入金字塔结构捕获全局空间信息,提高模型对肿瘤图像的多尺度特征提取能力,以提高整体网络的表达能力和分割性能。在乳腺肿瘤图像数据集上对该方法进行了仿真实验,结果表明,与其他 U-Net 改进策略相比,该方法具有更强的准确率和鲁棒性。

关键词: 多重注意力引导;乳腺;U-Net;超声;图像分割

中图分类号 TP391

Multiple Attention-guided Mechanisms for Ultrasound Breast Cancer Tumor Image Segmentation

GUO Hongyang¹, CHENG Qian², KANG Xiaodong¹, YANG Jingyi¹, YANG Shuqi¹, LI Fang^{1,3} and ZHANG Rui¹

¹ School of Medical Image, Tianjin Medical University, Tianjin 300202, China

² Chongqing University Qianjiang Hospital, Chongqing 409000, China

³ Beijing Chemical Occupational Disease Control Hospital, Beijing 100093, China

Abstract There are some problems such as single prediction scale and information loss in traditional U-Net ultrasound breast image segmentation tasks. To solve these problems, a multi-attention-guided U-Net ultrasound image segmentation method for breast tumors is proposed. Firstly, multiple SE attention module are introduced into the encoding structure of U-Net to extract multi-level semantic information from the input breast tumor images, which guides the encoder to focus on the features of breast tumor and reduces the interference caused by redundant background information. Secondly, by designing a feature fusion processing module, the complex semantic feature fusion processing is carried out on the feature graph from the encoder. Finally, in the decoder part, the pyramid structure is added to capture global spatial information to improve the multi-scale feature extraction ability of the model for tumor images, so as to improve the expression ability and segmentation performance of the whole network. The proposed method is simulated on breast tumor image data set, and the results show that compared with other U-Net improved strategies, the proposed method has better accuracy and robustness.

Keywords Multiple attention guidance, Mammary gland, U-Net, Ultrasound, Image segmentation

1 引言

乳腺癌发病率逐年上升并呈现年轻化趋势,严重危害女性健康。数据显示^[1],2022年内美国女性约有287850例乳腺癌确诊病例,近43250例死亡病例;在国内新发乳腺癌病例中,每年约有5%的患者在确诊时即有肿瘤细胞转移倾向。对乳腺癌患者做出准确诊断,可以有效预防和治疗乳腺癌。超声成像检查是乳腺癌诊断的一种常用方法。得益于成本低廉和较高的安全性,在临床诊断中超声图被广泛使用,但是超声图像中肿瘤形状不规则^[2],分布复杂,仅依靠医生人工判断不仅效率较低,还可能会出现误检的情况。基于此,计算机辅

助诊断系统(Computer Aided Diagnosis, CAD)被应用于临床诊断中,实现了诊断的智能化。

图像分割技术可以分割出超声图像中病变与正常组织区域,智能化地实现乳腺肿瘤区域的特征提取,为后续工作提供理论支撑。传统的乳腺超声图像分割主要基于直方图阈值法、分水岭算法、聚类法和活动轮廓模型^[3]。Xu等^[4]利用直方图阈值分割算法,首先对图像中的肿瘤区域进行粗特征提取,再通过形态学操作对提取到的特征做进一步处理,分割出肿瘤病变区域;Gomez等^[5]认为传统的分水岭算法存在分割过度或者无法完全分割出有效区域的问题,因此在算法分割前,加入先验知识,利用预先标记对算法的分割进行引导,提

基金项目:京津冀协同创新项目(17YEXTZC00020)

This work was supported by the Beijing-Tianjin-Hebei Collaborative Innovation Project(17YEXTZC00020).

通信作者:康晓东(tmughywl@163.com)

升了分割准确率;由于分水岭算法的简洁性,在分水岭算法的基础上,Huang等^[6]利用分水岭算法提取初始的轮廓特征,引入能量函数,将其最小化后精准提取到了肿瘤区域。传统的图像分割方法虽然操作简洁,但是在分割精度上无法满足临床要求,因此,基于深度学习的图像分割算法越来越多地用在医学影像分割方面。其中最典型的网络是FCN和U-Net,FCN^[7]开创了端对端全卷积神经网络的先河,此后PSP-Net^[8],SegNet^[9],U-Net^[10],DeepLab系列^[11-13]等语义分割网络陆续涌现出来。医学图像分割数据较少,而U-Net在数据量受到限制时依旧表现较好,因此被广泛用于医学图像分割任务。U-Net对称的编码和解码结构可以提取到丰富的高级语义特征,并分别对输入图片进行下采样、上采样16倍,在特征图输出时恢复到原图的分辨率,这样的结构对于小数据类型的医学影像数据集可以提取丰富的图像语义,因此U-Net在医学影像分割方面的表现很好。Zhou^[14]将U-Net应用在了乳腺肿瘤细胞图像的分割中,并在自主设计的数据集上进行了实验,但由于乳腺细胞中往往存在多尺度问题,因此效果不理想;Zhao等^[15]为了解决多尺度问题,利用金字塔池化结构在U-Net中获取不同大小的特征图,通过再融合后获取高质量的特征图,一定程度上解决了多尺度问题;Aleksandar等^[16]认为在特征网络提取特征前,为网络加入先验知识可以在一定程度上提高网络对有效特征的聚焦,从而提升了网络对有效特征区域的关注;Chen^[17]认为乳腺超声图像中的肿瘤大小不一,存在多尺度问题,因此设计了具有多尺度结构的U-Net提取不同尺度下肿瘤细胞的特征,但是仍有不足,进行模型训练时需要依据待处理的数据集对超参数进行相应调整,并且模型权重在多站点数据集之间迁移时可能发生损失。

综合上述网络结构特点,本文针对乳腺图像分割中存在的多尺度问题,提出将多重注意力引导机制融入U-Net网络的超声乳腺肿瘤图像分割方法。其主要思想为:

(1)由于U-Net的编码-解码机制,在传统U-Net的编码结构中融入多个注意力机制,可使得编码网络聚焦于乳腺肿瘤图像中的有效特征区域,为后续融合多层次特征图做准备;

(2)由于传统的U-Net网络中卷积层深度和宽度都较低,在面对复杂图像处理时,特征提取能力不足,因此在编码-解码结构中间加入特征融合结构,扩充网络深度,从而提升网络对特征的表达能力。

(3)在解码网络中利用空洞卷积金字塔池化结构增加解码生成特征图时的多尺度信息提取,以保留上层空间传来的强语义特征,在减少特征损失的同时,增强了特征的多尺度信息获取能力。

利用本文方法在公开的乳腺肿瘤图像数据集上进行了仿真实验,结果表明本文方法具有更高的准确率和鲁棒性。

2 本文方法

本文提出一种多重注意力引导的多尺度U-Net模型(MAU-Net)。模型主体结构如图1所示。本文在现有注意力机制以及金字塔模块的基础上重新设计了特征融合连接模块,并且对U-Net模型进行整体改进,以此来解决处理图像分割任务时目标尺度不一的问题。

2.1 框架结构

网络的框架结构模型如图1所示。在U-Net编码-解码的不同层级编码器前加入注意力机制,可提取特征图在全局尺度的上下文信息,并实现多层次空间语义信息的融合。然后,在编码器和解码器连接的部分设计了中间特征提取模块,对网络进行加深操作,以处理从编码器输出的含多重空间信息的复杂特征;将处理好的特征输入到解码器中,为了提高解码器的特征表达能力,加入含有空洞卷积的金字塔特征提取结构,将不同层级输出的特征进行融合处理,结合编码器输入的特征,监督生成语义丰富的特征图。

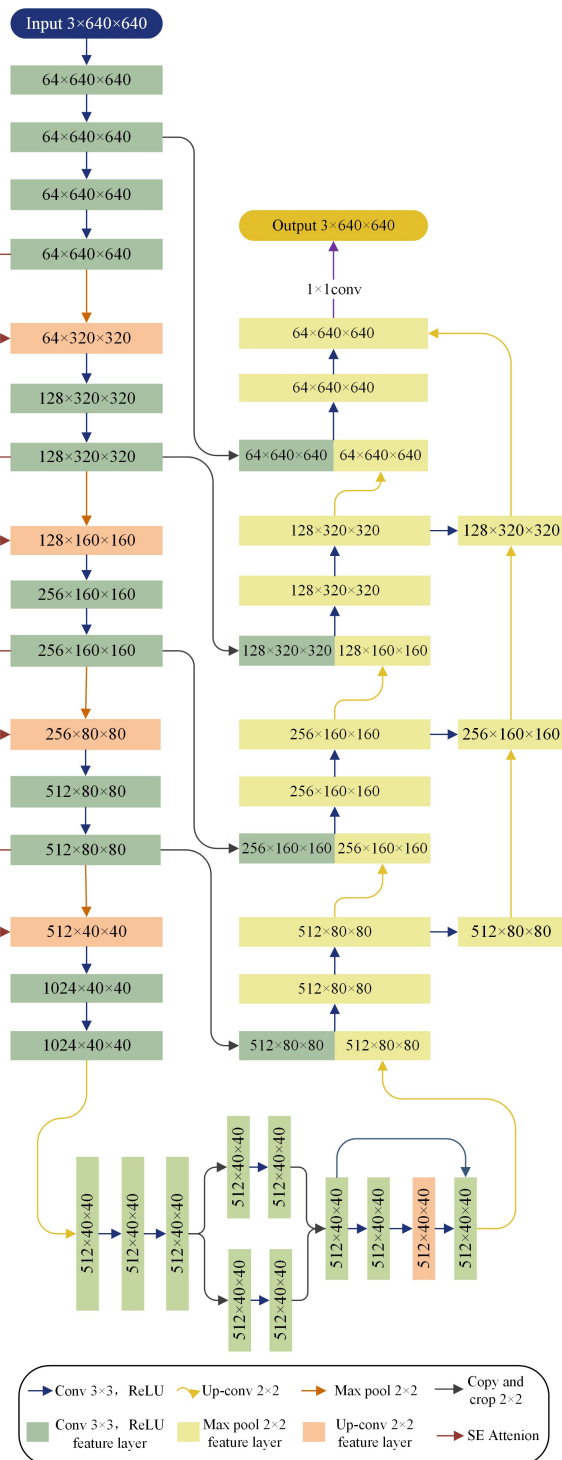


图1 MAU-Net 结构图

Fig.1 MAU-Net structure diagram

将编码器和解码器中处理相同特征图分辨率的卷积层看作一个 Block。在编码器中,每一个 Block 含有 4 个 3×3 的卷积层和一个 2×2 的最大池化层,在编码器的每一个 Block 前,均加入了注意力机制,通过注意力机制,网络将对有效特征区域进行聚焦处理;在编码器和解码器的连接部分,设计了多尺度特征融合提取模块,通过两列不同大小卷积核的卷积层对输入的图像进行处理,获得多尺度信息;最后,在解码器部分,通过利用 FPN 模块对 3 个层级的输出进行特征聚合,实现进一步的多尺度特征处理,最终输出高质量的肿瘤分割图。

2.2 注意力机制

针对乳腺癌肿瘤超声图像中存在的背景信息复杂问题,在 U-Net 的编码器中加入如图 2 所示的通道注意力模块^[18] (Squeeze-and-Excitation, SE),可减少与乳腺癌肿瘤无关的冗余特征信息,提升网络对肿瘤特征的提取能力^[19]。




图 2 SE 模块

Fig. 2 SE module

在图像分割任务中,注意力机制可以使网络重点关注图像的某部分信息。为了防止背景信息噪声对分割图的干扰,在网络中引入如图 2 所示的 SE 注意力模块。该模块在关注通道域信息的同时,也关注了空间域信息,因此更加适合于图像分割任务。通道注意力模块通过学习特征间的通道关系生成通道注意力图。该模块以每个 Block 的输出特征作为输入,利用最大池化操作聚合乳腺肿瘤图像的空间信息,将所有通道上的信息进行压缩,以一组权重进行表示。在 SE 注意力结构中连接有两个全连接层,因此可以进行非线性的特征表示,显性构建出各个通道特征图直接的相关性。最后,采用一个 Sigmoid 函数实现特征的重新映射,将权重与输入相乘即可得到注意力的输出。

SE 注意力机制对多层级的特征语义进行融合,并在通道维度上进行了权重的重新调整,使得网络聚焦重要通道信息,加强了通道对乳腺肿瘤的重要性,特征图更具表达能力。为使得特征图具有更加丰富的语义信息,在模型中,利用 1×1 的卷积首先进行通道维度变换,再采用池化层扩大特征感受野,使得该 SE 注意力模块的表达能力更强。

2.3 特征融合连接模块

由 2.2 节可知,编码器传来的特征中包含了对输入的乳腺肿瘤图像提取到的多层级复杂语义信息。传统的 U-Net 在编码-解码连接结构中使用的短程连接无法对丰富的语义进行特征识别处理,因此设计如图 3 所示的特征融合连接模块。首先对输入的特征图进行同等通道数的特征提取,接着通过 1×1 的卷积进行通道变换,加强来自于编码器 SE 注意力机制提取的维度信息,最后通过空洞卷积扩大感受野,避免了重复的上、下采样带来的特征信息丢失问题,然后在不同尺度上进行特征的再融合处理。在模块的后半程设计残差连接

处理,提高网络的特征提取能力,增强特征图的表达能力。

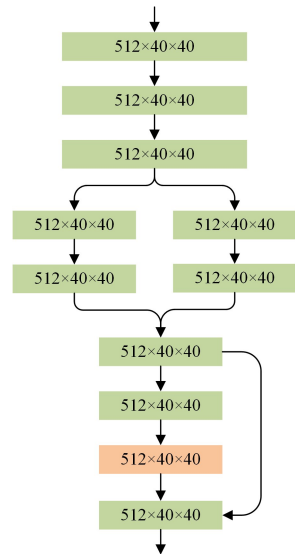


图 3 特征融合处理模块

Fig. 3 Feature fusion processing module

2.4 金字塔模块

在编码器和特征融合处理部分,分别对特征图进行了通道和空间上的特征提取。为加强网络对肿瘤多尺度特征的提取能力,设计金字塔模块附着在 Decoder 的每个层级后,将输出作为如图 4 所示的金字塔模块^[20]的输入,进行多尺度特征融合。

由于编码器中利用多重注意力对特征图的重要区域进行聚焦引导,在特征图中已经有肿瘤部分区域被识别为重要特征区域,将其看作自适应的 ROI-Align。利用 U-Net 反卷积带来的不同分辨率的特征图,对其进行 3×3 的空洞率为 2 的卷积后进行投影映射,与原 Decoder 主干输出的特征图进行相乘处理,在网络的最后得到增强的多尺度特征图,同时空洞卷积降低了计算成本,提升了效率,加快了模型拟合速度^[21]。




图 4 金字塔特征融合模块

Fig. 4 Pyramid feature fusion module

3 实验结果及分析

以 PyTorch 框架为实验环境,操作系统为 Windows10, GPU 的版本为 RTX 2060。采用 Adam 优化器,epoch 的训练轮数为 160,初始学习率设置为 0.001,每次输入网络模型的样本数量为 4。

损失函数(Loss Function)用来估量模型的预测值和真实值的不一致程度。图像分割二分类算法一般使用二元交叉熵作为损失函数,如果数据集正负样本不均衡,会导致网络训练效果不佳。本文以二元交叉熵作为损失函数。

二元交叉熵损失函数为:

$$CE(p, y) = -y \log p - (1 - y) \log(1 - p) \quad (1)$$

其中, p 和 y 分别是预测值和人工标注值。

3.1 数据集及其选择

Kaggle 成立于 2010 年, 是一个进行数据发掘和预测竞赛的在线平台, 于 2017 年被谷歌收购。本文使用 Kaggle 开源的乳腺结节超声影像数据集进行实验。本文选取该数据集的原因是, 数据集是 2021 年上传的公开数据集, 内容足够新, 并且数据集中既有良性肿瘤图像, 也有恶性肿瘤图像, 满足本文模型训练的需求。该数据集使用超声波扫描实现乳腺癌肿瘤标注的医学图像, 数据分为 3 类: 正常、良性和恶性肿瘤图像。该数据集图像被广泛应用于乳腺癌肿瘤的分割任务中。

数据集中的图像数据包含 25~75 岁女性的乳腺超声图像, 患者人数约 600 名, 由 820 张图像构成, 平均图像大小为 500×500 像素, 均为 PNG 格式, 对应标签图像保持原始图像大小。图像分布如图 5 所示。




图 5 数据集图片分布情况

Fig. 5 Image distribution of dataset

3.2 评价指标

在医学影像分割领域, 经典量化评价指标有: 交并比 (Mean Intersection over Union, mIoU), Dice 相似系数 (Dice Similarity Coefficient, DSC) 和准确率 (Accuracy, Acc)。

语义分割中常用 IOU 进行指标评价, 计算的是网络预测分割图像部分和标准图像分割区域的交集在两者并集中所占的比例; 在一个医学影像数据集中, 常常会有分割种类不平衡的问题, 为衡量这项指标, 对 DSC 进行分析; 而 Acc 指标则是基于像素点进行分割, 在预测分割性能的正确度上做分析。以下是上述指标的计算方式:

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

$$DSC = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (3)$$

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

式(2)~式(4)中, TP 代表实际为阳性样本且被预测为阳性样本的特征的数量, TN 代表实际为阴性样本且被预测为阴性样本的特征的数量, FP 代表预测为阳性样本但实际是阴性样本的特征的数量, FN 代表预测为阴性样本但实际是阳性样本的特征的数量。

3.3 实验结果分析

表 1 列出 FCN, U-Net, DeepLabV3 模型以及本文提出的模型在数据集上的测试结果, 本文所提出网络在乳腺结节超声影像数据集上的 $mIoU$, DSC 和 Acc 分别是 86.1%, 92% 和 98.8%。对比原 U-Net 网络结构的 71.11%, 81.08% 和 93.88% 和其他经典网络结构在该数据集上的性能指标, 均有提升, 这证明了本文所提网络结构的优越性。

表 1 乳腺结节超声图像数据集结果对比

Table 1 Comparison of ultrasound image data sets of breast nodules (%)

Method	$mIoU$	Acc	DSC
FCN	77.40	95.22	86.16
U-Net	71.11	79.21	86.10
DeepLabV3	93.88	96.12	98.80
MAU-Net	81.08	87.42	92.00

图 6 是本文模型训练的 Loss 曲线图, 横坐标为 Epoch 数, 纵坐标为 Loss 值。模型在 60 轮后 train loss 曲线和 val loss 曲线都开始收敛, 并且两者之间的差距极小, 达到完美拟合 (Good fit)。




图 6 Loss 图

Fig. 6 Loss diagram

在乳腺超声图像数据集中, 肿瘤细胞分布复杂, 大小尺度不一。分析表 1 和图 6 的结果, 本文方法在网络中加入的多重注意力引导网络能够有效识别复杂背景下的肿瘤区域特征, 减少冗余背景信息带来的特征干扰; 其次, 多尺度模块使得网络增强了对不同大小肿瘤的识别能力, 同时提高了网络的鲁棒性。另外, 由 DSC 可以看出, 本文网络对数据集的适应能力较强, 而高准确率和精确率体现了网络对特征的提取能力较强且具有较好的拟合能力。

图 7 是经过网络模型图像分割后的乳腺肿瘤原图及分割图。图 7 中第一行为乳腺肿瘤原图, 第二行为原标签图, 第三行为分割图。由图可知, 在乳腺肿瘤的边缘部分, 轮廓提取效果较好, 能够完整分割出乳腺部位。在原标签图和分割出的图像对比中, 我们的网络模型分割结果也更加趋近于标签图例, 说明网络结构设置合理, 模型分割性能优异。




图 7 乳腺超声图像数据集分割实例

Fig. 7 Segmentation example of breast ultrasound image dataset

3.4 消融实验

本文在乳腺超声图像数据集上对注意力机制数量位置和金字塔结构的层数进行了消融实验。通过单独采用注意力机制和单独采用金字塔结构, 以及注意力机制和金字塔结构仅对分辨率为原图 $1/4$, $1/8$ 的两个层级作用时进行了实验,

验证各个模块的有效性。表 2 列出了消融实验结果。

表 2 消融实验结果
Table 2 Ablation results

Method	Acc	mIoU
U-Net+注意力机制	95.40	79.32
U-Net+金字塔结构	96.96	82.69
部分注意力机制+金字塔结构	97.52	85.32
MAU-Net	98.80	86.10

图 8—图 10 分别是表 2 中 3 种模型在乳腺超声图像数据集上进行训练的 Loss 曲线图。其中横坐标为 Epoch 数,纵坐标为 Loss 值。图 8 和图 10 出现了过度拟合(Over Fit),表明模型忽略了真实输入与真实输出之间的关系,并不适合解决该类问题。而图 9 与图 6 相比较,图 6 拟合得更好,train loss 与 val loss 之间的差距(Generalization Gap)较大,拟合效果不如图 6,因此本文提出的模型对于处理乳腺图像分割中的多尺度效果最佳。




图 8 U-Net+注意力机制

Fig. 8 U-Net+ attention mechanism




图 9 U-Net+金字塔结构

Fig. 9 U-Net+ pyramid structure




图 10 部分注意力机制+金字塔结构

Fig. 10 Partial attention mechanism+pyramid structure

图 11 为表 2 中 3 种模型在乳腺超声图像数据集上进行训练的 mIoU 曲线图。从上到下依次是 U-Net+注意力机制、U-Net+金字塔结构和部分注意力机制+金字塔结构的 mIoU 曲线图。图中的横坐标为 Epoch 数,纵坐标为 mIoU 值。图 11 中从上到下 mIoU 峰值依次升高,表明预测结果与

真实结果的相似程度不断升高,从而得出 3 种模型在处理超声乳腺肿瘤图像时,U-Net+注意力机制分割效果较注意力机制+金字塔结构分割效果差。本文提出的模型训练以后 mIoU 峰值达到 86.10%,因此本文提出的模型对于处理乳腺图像分割中的多尺度效果最佳。




图 11 mIoU 曲线图

Fig. 11 mIoU curve diagram

由表 2 可知,对比表 1 中原 U-Net 结构,注意力机制和金字塔结构的加入均使得网络性能有一定的提升,这说明注意力引导网络提取有效特征部分十分合理,金字塔结构对于解码器恢复图像信息起到了作用,在两者进行结合后,进一步增强了网络的特征表达能力,有效提升了网络性能。

结束语 针对超声乳腺肿瘤分割任务,本文提出一种基于多重注意力引导的多尺度 U-Net 改进网络。该网络在传统 U-Net 的编码器和解码器中分别加入了多重注意力机制和多尺度结构,提升了 U-Net 对于肿瘤图像的聚焦和多尺度特征的提取;特别是在编码-解码结构中间加入特征融合结构,扩充了网络深度,从而提升了网络对特征的表达力。同时,在解码网络中利用空洞卷积金字塔池化结构增加解码生成特征图时的多尺度信息提取,以保留上层空间传来的强语义特征,从而减少了特征损失,增强了特征的多尺度信息提取能力。

本文利用乳腺超声图像数据集进行了训练以及测试,并与 U-Net 和其他基线网络进行对比,实验结果证明了本文所提出的网络分割性能较好,准确率较高。在实际的乳腺诊断应用当中,本文所提出的网络可以为临床医生判断提供可靠精准的诊断依据。期待之后的研究可以在增加样本量的基础上得到更好的泛化能力。

参 考 文 献

- [1] REBECCAR L, MILLER K D, JEMAL A. Cancer statistics, 2019[J]. CA: A Cancer Journal for Clinicians, 2022, 6(1): 7-34.
- [2] XIAO D, LI W B, ZHANG H M. Tumor Segmentation in Breast Ultrasound Images by Fusing Efficient-Net and U-Net[J]. Chinese Medical Equipment Journal, 2022, 43(11): 8-13.
- [3] KANG X D. Medical Image Processing. [M]. Beijing: People's Health Publishing House, 2009.
- [4] XU M L, LI F, ZENG S, et al. Correlation Between the Characteristics of Ultrasound Gray Histogram and HER-2 Expression in Invasive Ductal Carcinoma of Breast[J]. Chinese Journal of Medical Imaging, 2022, 30(12): 1224-1229.
- [5] GOMEZ W, LEJIA L A. Computerized lesion segmentation of breast ultrasound based on marker-controlled watershed transformation [J]. Medical Physics, 2010, 37(1): 82-95.
- [6] HUANG Y L, CHEN D R. Watershed segmentation for breast tumor in 2-D sonography [J]. Ultrasound in Medicine & Biology, 2004, 30(5): 625-632.
- [7] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [8] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition. 2017: 6230-6239.
- [9] 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.
- [10] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]// 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234-241.
- [11] CHEN L C, PAPANDREOU G, KIKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[J]. Computer Science, 2014(4): 357-361.
- [12] CHEN L C, PAPANDREOU G, KIKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.
- [13] CHEN L C, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation[J]. arXiv: 1706.05587, 2017.
- [14] ZHOU Y W, LIU Z Q, WANG Q F, et al. Breast Mass Image Segmentation Algorithm Based on Improved Residual U-Net [J]. Journal of Southwest University, 2021, 36(2): 68-74.
- [15] ZHAO J Y, QUE D S, TAN J Q, et al. Automated breast lesion segmentation from ultrasound images based on PPU-Net[C]// Proceedings of the 2019 International Conference on Medical Imaging Physics and Engineering. Piscataway: IEEE, 2019: 19725937.
- [16] ALEKSANDAR V, MIN X, PHOEBE E F. Attention-enriched deep learning model for breast tumor segmentation in ultrasound images[J]. Ultrasound in Medicine and Biology, 2020, 46(10): 2819-2833.
- [17] CHEN X, LIU Q, DENG X B, et al. Enhanced Network for Ultrasound Breast Tumor Segmentation Based on U-Net[J]. Computer Engineering and Applications, 2022, 58(22): 219-228.
- [18] CHEN X, CAI Y J, RAN W B, et al. SECU-Net: A skin disease images segmentation network combining SE with CRF[J]. Intelligent Computer And Applications, 2022, 12(11): 71-77, 86.
- [19] CHANG H. Continuous blood pressure prediction based on deep learning[D]. Lanzhou: Lanzhou University of Technology, 2020.
- [20] WANG X, YU M, REN H E. Remote sensing image semantic segmentation combining UNET and FPN[J]. Chinese Journal of Liquid Crystals and Displays, 2021, 36(3): 475-483.
- [21] ZHANG F C, ZHONG G Q, MAO Y X. Neural Architecture Search for Light-weight Medical Image Segmentation Network [J]. Computer Science, 2022, 49(10): 183-190.



GUO Hongyang, born in 2002, undergraduates. His main research interests include medical imaging diagnosis and so on.



KANG Xiaodong, born in 1964, Ph.D., professor. His main research interests include medical image processing and medical information system integration.