S→ 計算机科学 COMPUTER SCIENCE

# 基于特征融合的边缘引导乳腺超声图像分割方法

白雪飞, 马亚楠, 王文剑

引用本文

白雪飞,马亚楠,王文剑.基于特征融合的边缘引导乳腺超声图像分割方法[J].计算机科学,2023,50(3): 199-207.

BAI Xuefei, MA Yanan, WANG Wenjian. Segmentation Method of Edge-guided Breast Ultrasound Images Based on Feature Fusion [J]. Computer Science, 2023, 50(3): 199-207.

### 相似文章推荐(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)

深度学习模型的后门攻击研究综述

Backdoor Attack on Deep Learning Models:A Survey 计算机科学, 2023, 50(3): 333-350. https://doi.org/10.11896/jsjkx.220600031

### 特征增强损失与前景注意力人群计数网络

Crowd Counting Network Based on Feature Enhancement Loss and Foreground Attention 计算机科学, 2023, 50(3): 246-253. https://doi.org/10.11896/jsjkx.220100219

### 基于深度学习的可视化仪表板生成技术研究

Study on Visual Dashboard Generation Technology Based on Deep Learning 计算机科学, 2023, 50(3): 238-245. https://doi.org/10.11896/jsjkx.230100064

# 基于多特征融合的油画艺术风格分类

Classification of Oil Painting Art Style Based on Multi-feature Fusion 计算机科学, 2023, 50(3): 223-230. https://doi.org/10.11896/jsjkx.211200110

# 极化自注意力约束颜色溢出的图像自动上色

Polarized Self-attention Constrains Color Overflow in Automatic Coloring of Image 计算机科学, 2023, 50(3): 208-215. https://doi.org/10.11896/jsjkx.220100149





# 基于特征融合的边缘引导乳腺超声图像分割方法

# 白雪飞<sup>1</sup> 马亚楠<sup>1</sup> 王文剑<sup>1,2</sup>

1 山西大学计算机与信息技术学院 太原 030006

2 计算智能与中文信息处理教育部重点实验室(山西大学) 太原 030006

(baixuefei@sxu.edu.cn)

摘 要 针对乳腺超声图像边缘模糊、斑点噪声多、对比度低等问题,提出了一种融合多特征的边缘引导多尺度选择性核 U-Net(Edge-guided Multi-scale Selective Kernel U-Net,EMSK U-Net)方法。EMSK U-Net 采用基于 U-Net 的对称编解码结构可 以适应小数据集医学图像分割的特点,将扩张卷积与传统卷积构成选择性核模块作用于编码路径,并提取下采样过程中的选择 性核特征进行边缘检测任务,在丰富图像空间信息的同时细化边缘信息,有效缓解斑点噪声和边缘模糊的问题,在一定程度上 可以提升小目标的检测精度。然后在解码路径通过多尺度特征加权聚合获取丰富的深层语义信息,多种信息之间相互补充,从 而提升网络的分割性能。在3个公开的乳腺超声图像数据集上的实验结果表明,与其他分割方法相比,EMSK U-Net 算法各项 指标表现良好,分割性能有显著提升。

关键词:乳腺超声图像分割;特征融合;边缘检测;多尺度特征;深度学习;U-Net 中图法分类号 TP391

# Segmentation Method of Edge-guided Breast Ultrasound Images Based on Feature Fusion

BAI Xuefei<sup>1</sup>, MA Yanan<sup>1</sup> and WANG Wenjian<sup>1,2</sup>

1 School of Computer and Information Technology, Shanxi University, Taiyuan 030006, China

2 Key Laboratory of Computational Intelligence and Chinese Information Processing, Ministry of Education(Shanxi University), Taiyuan 030006, China

Abstract Due to the problems of blurred edges, excessive speckle noise, and low contrast in breast ultrasound images, an edgeguided multi-scale selective kernel U-Net(EMSK U-Net) method that fuses multiple features is proposed. The U-Net network has a symmetrical encoder-decoder structure, which can achieve better segmentation results on medical images with a small amount of data. EMSK U-Net adopts a network structure based on it, which combines dilated convolution with traditional convolution to form a selective kernel module, and applies it to the encoding path of the symmetric structure. Meanwhile, in the encoding part, EMSK U-Net performs the task of edge detection by extracting selective kernel features during down sampling. Through these methods, the spatial information of the image is enriched and the edge information of the image is refined, which effectively alleviates the difficult problem of segmentation caused by speckle noise and edge blur in breast ultrasound images, and the detection accuracy of small targets will also be improved to a certain extent. After that, in the decoding path of U-Net, EMSK U-Net obtains rich deep semantic information by building a multi-scale feature weighted aggregation module, realizes more information interaction between deep and shallow layers, and reduces the problem of low contrast. In general, EMSK U-Net jointly guides the segmentation of the network by complementing various information such as encoding part of the spatial information, edge information and decoding part of the depth feature information, so that the segmentation performance has been well improved. Experiments are conducted on three public breast ultrasound image datasets, and the results show that compared with other classical medical image segmentation methods and breast ultrasound segmentation methods, the EMSK U-Net algorithm performs well in various indicators. The performance of breast ultrasound image segmentation task has been significantly improved.

Keywords Breast ultrasound image segmentation, Feature fusion, Edge detection, Multi-scale features, Deep learning, U-Net

到稿日期:2021-12-28 返修日期:2022-08-15

基金项目:国家自然科学基金(61703252,U21A20513,62076154,62276161),山西省重点研发项目(202102150401013);山西省研究生教育创新 项目(2022Y145)

This work was supported by the National Natural Science Foundation of China(61703252, U21A20513, 62076154, 62276161), Key Research and Development Program of Shanxi Province(202102150401013) and Graduate Education Innovation Project of Shanxi Province(2022Y145). 通信作者:王文剑(wjwang@sxu.edu.cn)

### 1 引言

乳腺癌是全球女性疾病中最常见的一种恶性肿瘤,也是 癌症致死的一大原因。据 2021 年美国癌症协会(ACS)调查 的最新数据显示,乳腺癌占全球女性新发病例的 30%,占女 性癌症死亡病例的 15%,是发病率第一大癌症<sup>[1]</sup>。因此,早 期乳腺癌诊断受到极大的重视。乳腺癌有几种主要的诊断方 式,如乳腺 X 线摄影、磁共振成像(MRI)和超声成像等。其 中,乳腺超声成像由于其无创性、无放射性,且成本较低,成为 早期检测乳腺癌最重要和最有效的方法之—<sup>[2-3]</sup>。

利用计算机图像分割技术辅助医生辨别医学图像中的病 灶区域,不仅可以节省诊断时间,降低人工成本,而且可以弥 补初学者经验和技能上的不足,提高诊断正确率。然而,由于 超声图像存在斑点噪声多、边缘模糊、对比度低以及肿瘤形状 复杂等问题,因此乳腺超声图像分割的任务仍然具有很大的 挑战性<sup>[4]</sup>。

国内外学者在乳腺超声图像分割方面进行了大量的研究,如早期基于阈值<sup>[5]</sup>、基于分水岭<sup>[6]</sup>和基于活动轮廓模型<sup>[7]</sup> 等的传统分割方法,以及使用聚类<sup>[8]</sup>、SLIC 超像素分割<sup>[9]</sup>和 SVM 分类器<sup>[10]</sup>的机器学习方法等。这些方法均依赖于手工 提取的图像特征,分割性能较难提升。

近年来,由于深度学习可以自动从图像中学习到更深层 次的信息,且无需人工干预,对不同成像原理的图像处理任务 有很好的鲁棒性<sup>[11-12]</sup>,在乳腺超声图像分割领域也得到了广 泛应用<sup>[13-14]</sup>,并取得了比传统算法和机器学习算法更好的分 割性能。2015年 Ronneberger等提出了一种基于全卷积神经 网络(Fully Convolutional Networks,FCN)的 U-Net 网络<sup>[15]</sup>, 该网络能够适应很小的数据集,获得更加精确的分割结果。

为了提高分割精度,研究人员考虑增加各种补充语义信 息的模块对 U-Net 进行改进。2018年, Oktay 等使用 Attention U-Net 网络架构<sup>[16]</sup>分割医学图像,该网络在 U-Net 网络 跳跃连接部分使用一个注意力门(AG)减少冗余特征的传输, 抑制医学图像中非病灶区域的特征并突出与任务相关的显著 特征,来提高模型分割的准确性。2019年,Dong等提出 Dense U-Net 网络架构<sup>[17]</sup>,将密集连接思想与 U-Net 结合起 来。其中每一层特征的输入都来自之前所有层特征信息的拼 接融合,越深层拼接的特征越密集,保证了有效特征的传输, 从而增强网络对目标区域的学习能力。这些通过添加复杂模 块和改进跳跃连接来实现有效特征传输的方式,在一定程度 上有所改进。但是增加复杂模块中密集连接的设计会导致无 效特征也一起传输,跳跃连接部分的改进也只是在深浅层特 征连接部分对无效特征的简单过滤。这种对无效特征的简单 处理,无法应对复杂医学图像的分割任务,导致分割性能因无 效特征过多而无法提升。

为缓解无效特征过多带来的影响,研究人员考虑使用多 尺度信息提取更有效的特征,提出了多分辨率思想。2020 年,Ibtehaz等提出了 MultiResUNet 网络<sup>[18]</sup>。该网络使用多 个不同尺度卷积核的组合替换传统卷积核,并运用残差思想 改造 U-Net 中的跳跃连接部分,从而减少网络计算量与空间 信息的丢失,同时可以提取不同尺度的空间特征,对于超声伪 影和斑点噪声严重的乳腺超声图像具有较好的分割效果。 Shareef 等针对乳腺超声图像中小肿瘤识别度低的问题,设计 了 STAN 网络<sup>[19]</sup>,通过整合丰富的上下文信息和高分辨率图 像特征,融合不同尺度的特征信息,适应了不同大小的肿块图 像,提高了小肿瘤的分割精度。同年,Shareef 等又提出了增 强版 STAN 网络模型(ESTAN)<sup>[20]</sup>。该网络模型有两个编码 器和一个解码器,将行-列级内核的思想引入其中一个编码器 来适应乳腺解剖结构,同时通过跳跃连接融合了两个编码器 中的上下文特征,实现了对不同大小肿瘤的鲁棒分割。这些 网络通过增加不同分辨率的卷积核获取多尺度的图像信息, 来适应不同大小的目标,但都采取了大面积的核模块重设计, 只保留了少量 U-Net 中的传统卷积特征,导致模型复杂度大 幅度提升。

在医学图像的分割任务中,图像质量是决定分割结果的 关键因素之一。对于质量较差的乳腺超声图像的分割任务而 言,尽可能挖掘并利用它的有效信息就变得尤为重要。2020 年,Li通过直方图均衡、小波变换等预处理方式和模糊化注 意力机制来强化图像中肿块的边缘信息,从而提升乳腺肿瘤 超声图像分割的效果<sup>[21]</sup>。Gong等提出了一种混合双通道监 督反馈 U-Net 模型来解决乳腺超声图像中边缘模糊的问 题<sup>[22]</sup>,首先设计边缘恢复的预训练模型,然后将训练好的参 数迁移至引入循环机制的 U-Net 网络进行分割任务,通过两 步走的设计方法来加强网络对超声图像中边缘信息的关注 度,使得分割精度明显提升。以上网络考虑了图像数据本身, 但简单的数据预处理难以提取图像自身的特点,无法彻底解 决边缘模糊问题,而大规模的网络训练耗时过长,对硬件的要 求较高,网络复现也较为繁琐。

本文提出了一种边缘引导多尺度选择性核 U-Net 方法。 该方法首先利用扩张卷积和传统卷积构建选择性卷积核模 块,改进编码部分的传统卷积核,在特征传输之前就进行初步 的无效特征的过滤,实现不同尺度特征的融合与有效利用。 然后聚集多尺度深层特征,利用跳跃连接使浅层特征和深层 特征相互补充。此外,将边缘检测和分割任务集成到一个深 度网络中,以更好地指导分割任务,有效缓解乳腺超声图像中 存在的斑点噪声、对比度低和边缘模糊的问题。

本文的主要贡献包括以下4个方面:

(1)提出了局部选择性核 U-Net 的基础网络架构。利用 扩张卷积,减少空间信息的丢失,通过注意力机制将传统卷积 核改进为选择性卷积核模块,在获取不同尺度特征的同时区 分不同尺度特征的贡献,有效过滤斑点噪声和适应大小不一 的肿块分割任务。

(2)提出了基于迁移学习的边缘引导模块。基于迁移学 习的知识,使用经典的自然图像边缘检测方法,学习并提取乳 腺超声图像中丰富的边缘信息,利用边缘信息辅助深度特征 提取。

(3)设计了一种多尺度融合模块,获取具有多尺度特征的 深度语义信息,与浅层选择性特征和边缘特征融合,共同提升 分割效果。

(4)在3个公开的乳腺超声数据集上进行实验,验证了所提算法的有效性。边缘引导模块可以挖掘出更丰富的边缘信息,选择性卷积核和多尺度特征聚合的加入使得提取的深浅层特征信息更为有效和丰富,分割效果有显著提升。

# 2 本文方法

本文提出了一种边缘引导多尺度选择性核 U-Net(EM-SK U-Net)方法,网络的整体结构如图 1 所示。

该方法基于 U-Net 编码-解码网络结构,在编码层第二层 到第五层的传统卷积核中加入扩张卷积和注意力机制,组成 新的核模块(选择性核),构成主网络——局部选择性核 U-Net(Locally Selective Kernel U-Net,LSK U-Net)结构。 通过减少无效特征的传递,实现不同层次、不同尺度有效 浅层信息的融合,从而减少空间信息的丢失。此外,EM-SK U-Net 在 LSK U-Net 编码部分增加了基于迁移学习的 边缘引导(Edge Guide Module based on Transfer Learning, TL-EGM)模块,通过强化边缘信息来辅助深度特征的提 取。在 LSK U-Net 解码部分增加多尺度融合模块(Multiscale Fusion Module,MFM),提取不同尺度的深层信息,并 将这些信息进行加权聚合来获取更丰富有效的深层语义 信息。最后将主网络和两个模块的输出级联融合生成最 终分割结果。



图 1 EMSK U-Net 网络结构图 Fig. 1 Diagram of EMSK U-Net network structure

# 2.1 局部选择性核 U-Net(LSK U-Net)

经典的 U-Net 模型没有考虑到不同尺度的特征通道信息对网络的贡献不同,只是简单地传递提取到的全部信息,而 学习到的特征中还存在很多干扰信息,影响了分割效果。因此,针对乳腺超声图像分割任务,本文提出局部选择性核 U-Net(LSK U-Net),将选择性核(SK)加入 U-Net 中,利用其可 以识别不同尺度对象的特点,缓解超声图像中干扰信息过多 带来的斑点噪声和小目标分割率低的问题,从而提升分割 性能。

Li 等<sup>[23]</sup>已验证包含 SK 块的分类网络可以更好地识别 不同尺度的对象,并在 ImageNet 数据集上有更好的性能表 现。而扩张卷积<sup>[24]</sup>可以在不损失特征图信息的情况下扩大 感受野,有效解决肿块大小变化的问题,提高检测精度。因 此,本文对 SK 块加以改进来适应乳腺超声图像分割任务,使 用扩张卷积和传统卷积提取不同尺度的特征信息,并在两种 卷积之间使用由 Sigmoid 函数构成的简单注意力机制。在建 立通道特征相关性的同时权衡每一层提取特征的空间信息和 语义信息的比例,实现网络感受野的自适应调整,有效解决图 像中检测目标大小不一带来的问题,一定程度上也提高了小 肿块的检测精度。此外,注意力机制可以抑制无效特征,过滤 斑点噪声产生的干扰信息。SK 块的结构如图 2 所示,其中 BN 代表归一化,ReLU,Sigmoid 代表激活函数。

如图 2 所示,扩张卷积 k 的扩张率为 2,卷积核为 3×3, 传统卷积 f 无扩张率,卷积核为 3×3。两种卷积先分别进行 BN 归一化,ReLU 激活并加权以保留全部特征信息。然后, 将该特征张量依次通过全局平均池化层(GAP)、两个 1×1 卷积核和 Sigmoid 层。全局平均池化层将特征转换为单个特征向量的形式,两个一维卷积和 ReLU 激活函数的组合分别进行特征向量的压缩和还原操作,以实现简单的特征信息筛选,经 Sigmoid 层将权重限制在[0,1]范围并分配注意力权重。最后对分配了注意力权重的两种卷积加权求和得出结果。一个选择性卷积核 SK 的输出结果为:

 $s = ak + (1-a)f \tag{1}$ 

其中,a表示分配给扩张卷积部分的注意力权重,f表示传统卷积,k表示选择性卷积。





因此,本文提出的 LSK U-Net 网络采用 SK 块替换编码 层中的传统卷积,通过扩张卷积丰富每一层提取到的信息,再 加入注意力机制过滤每一尺度的特征通道信息,实现特征贡 献度的区分,LSK U-Net 的结构如图 3 所示。由于乳腺超声 图像中存在其他正常组织和斑点噪声干扰严重的情况,本文 选取编码层第二层至最后一层进行 SK 特征提取,即图 3 中 特征通道数为 32,64,128 和 256 的编码层。LSK U-Net 编码 层输出总特征数为:

$$F_b = f_1 + \sum_{i=2}^{n} s_i, n = 5$$
<sup>(2)</sup>

其中,n 表示核模块序数,LSK U-Net 的核模块序数按先编码 后解码的顺序从1到9进行编号。



Fig. 3 Diagram of LSK U-Net network structure

然后连接解码层,LSK U-Net 网络的最终输出结果为:

 $F_o = \text{Sigmoid}(F_b + \sum_{i=1}^{n} f_i), n = 9$ (3)

其中,Sigmoid(•)为激活函数。

# 2.2 基于迁移学习的边缘引导模块(TL-EGM)

针对乳腺超声图像色彩对比度较小、纹理特征受非目标 区域干扰过多的问题,本文考虑利用边缘信息辅助确定检测 目标所在区域。由于存在于浅层特征中的边缘信息可以提供 有效细粒度约束来辅助分割过程中的特征提取,因此本文提 出基于迁移学习的边缘引导模块(TL-EGM),通过选择并提 取编码层的特征实现边缘信息提取。

LSK U-Net考虑到乳腺超声图像干扰信息过多的因素, 从编码部分的第二层开始 SK 卷积,实现了无效特征的初步 过滤。TL-EGM 利用 SK 可以实现信息过滤的特点,首先,对 编码层经过 SK 卷积的特征使用 SK 卷积进行提取融合,将不 同尺度的有效浅层信息融合生成一个整体浅层特征图,实现 干扰信息的二次过滤,以便更好地实现边缘信息提取任务。 其次,考虑到医学图像采集数据和获取注释的特殊性,基于迁 移学习,提出领域迁移策略(Domain Migration Strategy, DMS),实现边缘引导模块的第二阶段,将融合好的浅层特征 图输入 DMS,输出对应的超声图像的边缘特征图,利用该有 效边缘特征信息辅助图像上下文特征的提取,减少对比度低 和干扰信息对分割结果的影响,获得良好的分割效果。

DMS包括两个步骤,如图4所示。其中,左侧箭头相连的两部分为DMS的第一步,首先,将在自然图像中表现良好的整体嵌套边缘检测(Holistically-nested Edge Detection, HED)<sup>[25]</sup>网络作为边缘检测任务的骨干网络,并使用迁移学 习初始化该部分的网络权重。HED由5层多尺度卷积块构成,其每一层都有对应的输出。考虑到特征提取的浅层干扰 信息过多和最深层有效特征较少的情况,本文基于HED,采 取微调最后融合特征输出层中每层特征的权重比例,加大中 间特征层的权重,实现在乳腺超声图像数据集上的应用,并将 其作为边缘检测任务中对应的真实标签。第二步如图4中右 侧箭头连接所示,将第一步微调后的HED网络用于乳腺超 声图像的边缘检测任务,提取输入特征的边缘信息,更好地引导分割网络的训练。

这种两步走的边缘提取方式,一方面可以很好地完成

边缘信息提取任务,使微调后的 HED 具备提取超声图像边缘信息的能力;另一方面利用提取到的边缘信息可使网络更专注于参考边缘特征信息,更好地指导网络训练,减少低对比度和干扰信息对分割效果的影响。



Fig. 4 Domain migration strategy map

TL-EGM 具体结构如图 5 所示。该模块将 LSK U-Net 编码结构中特征通道数为 128 的特征进行上采样与 SK 卷 积,并与特征通道数为 64 的特征进行级联操作。然后将级联 结果进行上采样与 SK 卷积,并与 32 维的特征进行级联操 作,这样把每层的特征进行融合,最后上采样到 16 维的特征 通道数后通过 SK 卷积层送入 DMS 进行边缘信息提取。TL-EGM 的输出结果为:

$$\begin{cases} \sigma(\cdot) = U_{S}(\cdot) \\ C_{1} = C(\sigma(s_{3}), s_{2}) \\ C_{2} = C(\sigma(C_{1}), s_{1}) \\ F_{h} = H(\sigma(C_{2})) \end{cases}$$
(4)

其中,*C*(•)表示级联操作,*Us*(•)表示上采样和选择性卷积 操作,*H*(•)表示边缘检测操作。



图 5 基于迁移学习的边缘引导模块图

Fig. 5 Diagram of edge guidance module based on transfer learning

多次的 SK 卷积和级联操作可逐步实现对无效特征的过 滤, 微调后的 HED 部分生成边缘细节明显的边界特征图。 TL-EGM 使用该特征图指导网络训练, 使得网络的关注度更 倾向于边缘特征信息, 有效地减少了非目标区域特征和色彩 对比度低对分割结果的影响。

# 2.3 多尺度融合模块(MFM)

为了更好地适应检测目标的尺度与形状变化,同时结合 所有的深层语义信息进行目标检测,本文设计了多尺度融合 模块(MFM),如图 6 所示。





MFM 对解码层每一尺度的特征进行提取并加权聚合, 充分挖掘和利用了深度特征,有效缓解了超声图像对比度低 带来的问题。加权聚合前对提取的特征都进行了选择性卷 积,以此过滤部分无效特征。同 TL-EGM 一样,MFM 的输出 也融合到最终输出中,辅助完成分割任务。

MFM 模块的输出结果为:

$$F_{m} = f \sum_{i=6}^{n} s(f_{i}), n = 8$$
(5)

综上所述,EMSK U-Net 首先在 U-Net 中采用 SK 块搭 建基础网络,其中的 SK 块可以增加网络对超声图像中有效 特征的关注度,缓解超声图像中斑点噪声的影响,并解决肿块 大小不一的问题。然后使用 TL-EGM 模块使网络在训练过 程中加强对边缘细节的关注,对边缘特征进行很好地利用。 同时,MFM 模块可以让网络在训练过程中尽可能挖掘有效 的深度特征,缓解超声图像中对比度低造成的分割困难的问 题。最终,将 LSK U-Net、TL-EGM 模块和 MFM 模块的结 果进行融合,输出分割结果。

EMSK U-Net 网络的最终输出表示为:  $F = C(F_o, C(F_h, F_m))$  (6)

### 3 实验数据和结果

### 3.1 实验设置

3.1.1 实验数据与预处理

为了验证本文提出的算法的可行性和有效性,使用 3 个 公开的超声图像数据集 Dataset B<sup>[4]</sup>, Dataset BUSI<sup>[26]</sup>和 Dataset C<sup>[27]</sup>进行实验对比、消融和分析,每个数据集都包含 原始乳腺超声图像和由医学专家手动划分的肿块区域。其 中, Dataset B数据集包含 163 张来自不同患者的乳腺超声图 像,平均图像大小为 760×570 像素,110 张呈良性病变,53 张 呈恶性病变。Dataset BUSI 数据集共包括 780 张图像,平均 图像大小为 500×500 像素,包括 487 张恶性病变图、210 张 良性病变图和 133 张正常超声图像。Dataset C 是由中山大 学癌症中心提供的乳腺超声病变图像数据集,共包括 320 张 乳腺超声图像,平均图像大小为 128×128,包含 160 张良性 病变图和 160 张恶性病变图。由于本文的研究对象是单个肿 块的分割,因此对 Dataset BUSI 数据集进行筛选,将数据集 中双肿块图像排除,最终选取 337 张恶性病变图像和 174 张 良性病变图像(共 511 张图像)进行 Dataset BUSI 上的实验。

实验中使用双三次插值将两个数据集的所有图像的尺寸 调整为224×224,并进行3×3中值滤波器处理。同时,使用 最近邻插值技术将所有样本对应的真实标签(Ground Truth) 调整为224×224。此外,考虑到数据集过小的问题,本文使 用数据增广方法来扩充数据,包括缩放、随机水平翻转、宽度 和高度方向的随机偏移、标准化等操作。

3.1.2 实验算法

为了验证本文提出的算法的有效性,选择以下 5 个在医 学图像分割方面具有代表性的网络结构进行对比。

(1)U-Net:具有对称结构的编-解码结构,并加入跳跃连 接将浅层语义信息融合到深层中,以此改善梯度消失和随着 卷积层数加深而引起的特征损失问题。

(2)Attention U-Net:在 U-Net 网络中的跳跃连接部分设 计注意力门机制,增加了跳跃连接传递信息中 ROI 区域的关 注度。

(3) Dense U-Net:使用密集块(Dense Block)代替 U-Net 中的传统卷积块,密集块结合跳跃连接,在加快网络训练速度 的同时改善了梯度下降和梯度消失的问题。

(4)STAN:基于 U-Net 网络,在编码器的每个卷积层使用3个大小不同的内核构建特征映射,并将编码器每一层的结果跳跃连接到对应解码层中的第一层,将前两个内核构建特征融合后与第三个内核构建特征连接到对应解码层的第二层。

(5)MultiResU-Net:使用多分辨率思想构建卷积核替换 U-Net中的传统卷积,使用残差连接代替 U-Net的跳跃连接。

此外,我们对本文算法进行消融实验,来验证新设计的每 个模块的有效性。消融实验包括 U-Net 和以下 3 种对比 方法。

(1)LSK U-Net:在原始 U-Net 网络的编码层局部加入选 择性卷积核来替换传统卷积。

(2)Edge Guided U-Net based on Transfer Learning(TL-EG U-Net):在原始 U-Net 网络的编码层,提取其第二到第四 层的特征信息进行上采样、SK 和级联等操作并融合后,送入 基于迁移学习的边缘检测网络提取边缘信息。

(3) Multi-scale Fusion U-Net(MF U-Net):在原始 U-Net 网络的解码层,将每层的特征进行选择性卷积后进行加权聚合。

3.1.3 损失函数与评价指标

本文将数据集划分成训练集、验证集和测试集进行实验, 其中良、恶性肿瘤的比例保持不变。使用 Dice Loss 作为损失 函数<sup>[28]</sup>,它可以有效解决样本不均衡的问题,如式(7)所示:

$$Loss = 1 - Dice(pre, act) = 1 - \frac{2(pre \cap act)}{(pre \cup act)}$$
(7)

其中, pre 表示预测图像, act 表示真实图像。

本文采用敏感度(Sensitivity)、骰子系数(Dice)和杰卡德 相似系数(Jaccard Index,JI)<sup>[29]</sup>作为算法的评价指标。其中, Sensitivity表示实际为肿块区域并且预测结果也是肿块区域 的比例,Dice表示实际和预测结果重叠的程度,JI表示实际 和预测结果之间的相似性。所有的评价指标均以均值(土标 准差)的形式表示,如式(8)一式(10)所示:

$$Sentivity = \frac{TP}{(TP+FN)}$$
(8)

$$Dice = \frac{2(pre \cap act)}{(pre \cup act)}$$
(9)  
$$JI = \frac{|pre \cap act|}{|pre \cup act|}$$
(10)

其中,TP 表示预测结果为肿块区域中预测正确的概率,FN 表示预测结果为非肿块区域中预测错误的概率。 3.1.4 参数设置

本文使用 Keras 作为基本框架搭建模型并进行所有的实 验,显卡型号为 NVIDIA Tesla P100,显存 16 GB。第一层卷积 核大小为 16,并在编码层以 2 倍扩大卷积核,在解码层则以上 一层的 1/2 降低特征映射数量,使用反向传播和 ADAM 优化 器<sup>[30]</sup>进行训练。TL-EGM 中 DMS 部分的初始权重为在自然 图像上训练好的 HED,TL-EGM 中迁移学习微调部分,HED 中间三层特征权重  $\alpha$ 与其余层特征权重  $\beta$ 的设置如表 1 所列。 此外,表中还包括学习率、动量和 batch\_size。为使模型更快收 敛,若验证过程未观察到监测值有所改善,则每 10 个 epoch 将 学习率下降 10%。若在第 15 次迭代后监测值仍然没有改善,则 停止训练。对比算法和消融算法进行同样的参数设置并在同一 环境下进行实验,以此来验证本文模型的可行性和有效性。 表1 参数设置 Table 1 Peremeter acting

	neter setting
Parameters	Value
batch_size	16
learning rate	$1 \times 10^{-3}$
momentum	0.9
α	0.8
β	0.2

### 3.2 对比实验

# 3.2.1 结果定性分析

图 7 给出了本文算法和 5 种对比算法在两个数据集上的 实验效果。其中,前三组数据是对比实验算法在 Dataset B上 的实验结果,该数据集的图像存在对比度较低、边缘模糊和超 声伪影等问题;中间三组是在 Dataset BUSI上的实验结果, 该数据集图像中边缘模糊、斑点噪声和超声伪影的问题较为 严重,分割难度相比第一个数据集更大;后三组是在 Dataset C 数据集上的实验结果,该数据集的图像质量介于 Dataset B 和 Dataset BUSI 数据集图像质量之间,故分割难度也介于两 者之间。



国有一个国际及于与并国任 Dataset D 和 Dataset D D J 双语未上的方言组示

Fig. 7 Segmentation results of different deep learning algorithms on Dataset B and Dataset BUSI

观察图 7 中 U-Net 的分割效果,由于没有区分不同尺度

信息的不同贡献,该方法无法捕获对比度低和超声伪影严重

的目标,导致小目标检测效果较差。Attention U-Net 因跳跃 连接部分的注意力机制而细化了 U-Net 识别准确的目标,但 简单的冗余特征过滤机制对小目标和超声伪影严重的病灶区 域的识别效果依然不佳。Dense U-Net 中的 Dense Block 考 虑到了图像全局信息,但局部信息的捕获能力较弱且传递了 过多的冗余信息,因此产生了检测不到目标区域或不止一个 目标区域的问题,在超声伪影较严重的图像上表现甚至差于 U-Net。MultiResU-Net多分辨率和残差连接的思想考虑到 了聚合多尺度信息,减少了空间信息的丢失,但对于超声伪影 严重和干扰信息过多的病灶识别能力不强,边缘特征也不够 细化。同样,STAN 中聚合多尺度、多分辨率的工作虽然减少 了空间信息的丢失,但也未对目标的边缘进行细化,缺乏边缘 信息的指导,因此识别效果有待提升。

相较于以上算法,EMSK U-Net 在聚合多尺度信息的同 时细化了边缘特征,SK的设计减少了空间信息的丢失,不仅 准确识别了不同大小肿块,边缘也更加精细,在绝大部分的乳 腺超声图像上得到了更好的分割结果,与人工分割图也十分 接近。但是超声伪影严重的乳腺超声图像肿块区域存在着明 显的边缘缺失,导致网络无法很好地完成边缘提取和细化任 务,影响了分割精度。

3.2.2 结果定量分析

本文对各分割算法在 Dataset B, Dataset BUSI 和 Dataset C这3个数据集上的分割结果进行评价,结果如表2一表4所 列,加粗字体为最佳性能指标。

表 2 不同算法在 Dataset B 上的结果

Table 2 Results of different algorithms on Dataset B

Method	Sensitivity	Dice	J I
U-Net	0.8019	0.7783	0.6866
	(±0.0411)	(±0.0310)	(±0.0495)
Attention U-Net	0.7382	0.7601	0.6793
	(±0.0248)	(±0.0178)	(±0.0146)
Dense U-Net	0.7176	0.7137	0.6237
	(±0.0455)	(±0.0352)	(±0.0252)
MultiResU-Net	0.7879	0.7518	0.6630
	(±0.0233)	(±0.0434)	(±0.0460)
STAN	0.7907	0.7810	0.6878
	(±0.0472)	(±0.0458)	(±0.0418)
EMSK U-Net	0.8196	0.8336	0.7330
	(±0.0276)	(±0.0130)	(±0.0296)

从表 2 的分割结果中可以发现,与其他算法相比,EMSK U-Net 算法在 3 个指标上的表现均最优。Sensitivity, Dice 和 JI 指标最少分别提升了 0.0177,0.0526 和 0.0452,最多分别 提升了 0.1020,0.1199 和0.1093。

由表 3 的结果可知,与 U-Net 相比, EMSK U-Net 的 Sensitivity 提升约 0.0065, Dice 提升约 0.0617, JI 提升约 0.0631。与其他分割算法相比,各指标至少提升约 0.0053, 0.0529 和 0.0314。说明 EMSK U-Net 算法整体表现最优。

观察表4的分割指标结果可以发现,在 Dateset C 数据集 上,EMSK U-Net 的 Sensitivity 至少提升约 0.0002,Dice 至 少提升约 0.0394, JI 提升约 0.0041。各指标最多提升约 0.0561,0.0615和0.0365。

表 3 不同算法在 Dataset BUSI 上的结果

Table 3 Results of different algorithms on Dataset BUSI

Method	Sensitivity	Dice	JI
U-Net	0.7761	0.7545	0.6438
	(±0.0289)	(±0.0113)	(±0.0099)
Attention U-Net	0.7773	0.7509	0.6542
	(±0.0211)	(±0.0144)	(±0.0146)
Dense U-Net	0.7285	0.7115	0.6405
	(±0.0380)	(±0.0185)	(±0.0330)
MultiResU-Net	0.7242	0.7633	0.6755
	(±0.0137)	(±0.0273)	(±0.0139)
STAN	0.7712	0.7560	0.6628
	(±0.0307)	(±0.0108)	(±0.0124)
EMSK U-Net	0.7826	0.8162	0.7069
	(±0.0212)	(±0.0118)	(±0.0136)

#### 表 4 不同算法在 Dataset C 上的结果

Table 4	Results	of	different	algorithms	on	Dataset	C
---------	---------	----	-----------	------------	----	---------	---

Method	Sensitivity	Dice	J I
U-Net	0.7869	0.7513	0.6903
	(±0.0144)	(±0.0024)	(±0.0127)
Attention U-Net	0.7647	0.7525	0.6870
	(±0.0152)	(±0.0044)	(±0.0105)
Dense U-Net	0.7310	0.7442	0.6579
	(±0.0257)	(±0.0133)	(±0.0445)
MultiResU-Net	0.7438	0.7571	0.6797
	(±0.0162)	(±0.0240)	(±0.0563)
STAN	0.7733	0.7620	0.6880
	(±0.0147)	(±0.0170)	(±0.0169)
EMSK U-Net	0.7871	0.8057	0.6944
	(±0.0214)	(±0.0154)	(±0.0104)

### 3.3 消融实验

#### 3.3.1 结果定性分析

本文选取相对较大的数据集,即 Dataset BUSI 数据集进 行消融实验。图 8 给出了 3 个消融实验的结果。其中, LSK U-Net 通过添加 SK 块选择性替换 U-Net 中的传统卷积,有 效补充了图像中的空间特征信息,提高了对有效特征的注意 力。TL-EG U-Net 通过添加提取浅层特征进行边缘检测的 部分,来强化图像边缘信息。MF U-Net 则通过融合多尺度 的信息来丰富特征信息输出。3个模块相辅相成,共同作用, 取得如图 8 中 EMSK U-Net 的分割结果,可以观察到,分割 结果与实际肿块信息较为接近。



图 8 消融实验在 Dataset BUSI 上的分割结果

Fig. 8 Segmentation results of ablation experiments on Dataset BUSI

#### 3.3.2 结果定量分析

表 5 列出了 Dataset BUSI 数据集上的消融实验结果,

最佳性能指标用加粗的字体表示。分析各项指标可以看出, EMSK U-Net 在 3 个指标上的表现均为最优。3 个模块与 U-Net 结合的方法在 Dice 和 JI 两个重要指标上优于原始的 U-Net,敏 感度指标也与 U-Net 相差不大,证明了 3 个模块的有效性。

表	5 ¥	肖融实	、验在	Dataset	BUSI	上的结果	
 _	n .						-

l`abl	e 5	Results	ot	ablation	experiment	on	Dataset	BUSI
-------	-----	---------	----	----------	------------	----	---------	------

Method	Sensitivity	Dice	J I
U.Net	0.7761	0.7545	0.6438
0-met	(±0.0289)	(±0.0113)	(±0.0099)
I SK U-Net	0.7723	0.8074	0.6962
Lon o net	(±0.0195)	(±0.0190)	(±0.0206)
TL-FC U-Net	0.7392	0.7780	0.6744
11 10 0 100	(±0.0351)	(±0.0128)	(±0.0191)
MF U-Net	0.7331	0.7721	0.6612
	(±0.0275)	(±0.0196)	(±0.0198)
FMSK U-Net	0.7826	0.8162	0.7069
	(±0.0212)	(±0.0118)	(±0.0136)

# 3.4 模型所占空间与计算消耗分析

为了更好地评估算法的使用性能,对每种算法的参数量 (Parameters)和浮点运算数(Floating-point Operations Per Seconds,FLOPs)进行统计,如表6所列。其中,参数量指模 型中参与计算的个数,用来衡量模型大小;浮点运算数表示每 秒所支持完成预测所需的计算量,用来衡量模型的复杂度。

表 6 不同算法的参数量和 FLOPs 的统计

Table 6 Parameters and FLOPs of different algorithms

Method	Parameters	FLOPs
U-Net	$1.94 \times 10^{6}$	$3.88 \times 10^{6}$
Attention U-Net	$1.95 \times 10^{6}$	$3.89 \times 10^{6}$
Dense U-Net	$1.32 \times 10^{6}$	2.62 $\times 10^{6}$
MultiResU-Net	$1.84 \times 10^{6}$	3.67 $\times 10^{6}$
STAN	29.38 $\times 10^{6}$	58.74 $ imes 10^{6}$
EMSK U-Net	$2.04 \times 10^{6}$	$4.06 \times 10^{6}$

从表 6 可以看出, Dense U-Net 算法的参数量最少, 模型 复杂度最低, 但综合表 2-表 4 的结果来看, 其分割精度也是 最低的。而 MultiResU-Net 模型的参数量和计算复杂度均略 低于 U-Net, 这得益于残差思想的引入, 减少了计算量, 但观 察分割结果可以发现, 该模型的设计无法应对图像质量较差 的乳腺超声图像。其余基于 U-Net 网络的变体在计算量或 复杂度上均高于 U-Net, 其中, STAN 算法的参数量和复杂度 最高, 原因是其使用 3 个不同大小的核进行特征映射, 导致模 型复杂度成倍增加。

EMSK U-Net 由于在 U-Net 的基础上额外添加了边缘 引导模块和多尺度融合模块,并且在编码部分的卷积层中加 入了扩张卷积,导致模型参数量和模型的复杂度较其他网络 有所增加。但相较于 U-Net 及其变体,EMSK U-Net 的参数 利用率更高,特别是在边缘、空间等方面的有效参数利用率 上,因此很好地提升了分割精度。相较于大面积核重设计的 STAN 算法而言,本文算法模型更简单,参数量更小,运算速 度更快。

结束语 本文针对存在边缘模糊、噪声多和对比度低等问题的乳腺超声图像病灶分割任务进行研究,提出了融合多 尺度特征的 EMSK U-Net 方法。与 U-Net 模型相比,在不大 幅度提升模型复杂度的基础上,它可以实现特征的贡献度区 分与融合,强化乳腺超声图像边缘细节并指导分割,融合多层 深层语义信息,在提取丰富有效特征的同时实现了边缘细化, 缓解了超声图像中边缘模糊以及对比度低等问题。在3个公 开的数据集上的实验结果表明,本文提出的算法的分割效果 有显著提升。

因乳腺超声的无创性和低成本,乳腺超声图像分割一直 是乳腺病灶研究的重要课题。在临床应用中,由于人工标签 耗时耗力,大多都是无标签的数据集,而 EMSK U-Net 是在 有真实标签的情况下获得了良好的分割精度,且相对于 U-Net 来说,其模型复杂度和计算量也有所增加。因此,未来研 究工作中将考虑采取半监督或者无监督的方式对模型进行进 一步轻量化和优化,以适应低消耗计算资源和无标签样本的 数据集,并尝试应用于多模态的超声数据集。

# 参考文献

- SIEGEL R L, MILLER K D, FUCHS H E, et al. Cancer statistics, 2021 [J]. CA: A Cancer Journal for Clinicians, 2021, 71(1): 7-33.
- WU G G, ZHOU L Q, XU J W, et al. Artificial intelligence in breast ultrasound [J]. World Journal of Radiology, 2019, 11(2): 19-26.
- [3] XIAN M,ZHANG Y T,CHENG H D,et al. Automatic breast ultrasound image segmentation: a survey [J]. Pattern Recognition: the Journal of the Pattern Recognition Society, 2018, 79: 340-355.
- 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, 2018, 22(4):1218-1226.
- [5] YAP M H, EDIRISINGHE E A, BEZ H E. A novel algorithm for initial lesion detection in ultrasound breast images [J]. Journal of Applied Clinical Medical Physics, 2008, 9(4):181-199.
- [6] GOMEZ W,LEJIA L, ALVARENGA A V, et al. Computerized lesion segmentation of breast ultrasound based on marker-controlled watershed transformation [J]. Medical Physics, 2010, 37(1):82-95.
- [7] HE T,GUO Y G,XIN C H. Adaptive image segmentation method using acm selection system and improved chan-vese model [ J]. Journal of Chongqing University of Technology (Natural Science),2020,34(2):165-173.
- [8] FENG Y, DONG F L, XIA X L, et al. An adaptive fuzzy c-means method utilizing neighboring information for breast tumor segmentation in ultrasound images [J]. Medical Physics, 2017, 44(7):3752-3760.
- [9] GUO Y J, YANG M, HOU Y C. Application of an improved slic algorithm in color image segmentation [J]. Journal of Chongqing University of Technology( Natural Science), 2020, 34(2):158-164.
- [10] DAOUD M I, ATALLAH A A, AWWAD F, et al. Accurate and fully automatic segmentation of breast ultrasound images by combining image boundary and region information [C] // 2016 IEEE 13th International Symposium on Biomedical Imaging(IS-BI). Piscataway: IEEE, 2016:718-721.

- [11] QIN H F,LIU X. Finger vein image segmentation based on sparse auto-encoder[J]. Journal of Chongqing Technology and Business University(Natural Science Edition),2019,36(4):1-8.
- [12] YUAN Z M, YUAN H J, YAN Y X, et al. Automatic recognition and classification of field insects based on lightweight deep learning model[J]. Journal of Jilin University(Engineering and Technology Edition), 2021, 51(3):1131-1139.
- [13] TAJBAKHSH N, JEYASEELAN L, LI Q, et al. Embracing imperfect datasets: a review of deep learning solutions for medical image segmentation [J]. Medical Image Analysis, 2020, 63: 101693.
- [14] SHI J, WANG L L, WANG S S, et al. Applications of deep learning in medical imaging: a survey[J]. Journal of Image and Graphics, 2020, 25(10): 1953-1981.
- [15] RONNEBERGER O,FISCHER P,BROX T. U-Net;convolutional networks for biomedical image segmentation [C]// Medical Image Computing and Computer-Assisted Intervention(MIC-CAI 2015). Cham;Springer,2015;234-241.
- [16] OKTAY O.SCHLEMPER J.FOLOGC L L., et al. Attention unet:learning where to look for the pancreas [J]. arXiv:1804. 03999,2018.
- [17] DONG R S,PAN X Q,LI F Y. Dense u-net-based semantic segmentation of small objects in urban remote sensing images [J]. IEEE Access,2019,7:65347-65356.
- [18] IBTEHAZ N,RAHMAN M S. MultiResUNet: rethinking the unet architecture for multimodal biomedical image segmentation [J]. Neural Networks, 2020, 121:74-87.
- [19] SHAREEF B.XIAN M.VAKANSKI A. Stan: small tumoraware network for breast ultrasound image segmentation [C]// IEEE 17th International Symposium on Biomedical Imaging(IS-BD). Piscataway: IEEE, 2020;1469-1473.
- [20] SHAREEF B,VAKANSKI A,XIAN M,et al. ESTAN:enhanced small tumor-aware network for breast ultrasound image segmentation [J]. arXiv:2009.12894,2020.
- [21] LI J J. Breast tumor image segmentation based on fuzzy logic attention mechanism u-net [D]. Harbin: Harbin Instutite of Technology, 2019.
- [22] GONG R L,SHI J,WANG J. Hybrid supervised dual-channel feedback u-net for segmentation of breast ultrasound images [J]. Journal of Image and Graphics, 2020, 25(10): 2206-2217.
- [23] LI X, WANG W, HU X, et al. Selective kernel networks[C]//

2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway: IEEE, 2019:510-519.

- [24] HU Y,GUO Y,WANG Y,et al. Automatic tumor segmentation in breast ultrasound images using a dilated fully convolutional network combined with an active contour model [J]. Medical Physics,2018,46(1):215-228.
- [25] XIE S,TU Z. Holistically-nested edge detection [J]. International Journal of Computer Vision, 2017, 125(1/2/3): 3-18.
- [26] Al-DHABYANI W, GOMAA M, KHALED H, et al. Dataset of breast ultrasound images [J]. Data in Brief, 2020, 28:104863.
- [27] HUANG Q, HUANG Y, LUO Y, et al. Segmentation of breast ultrasound image with semantic classification of superpixels [J]. Medical Image Analysis, 2020, 61, 101657.
- [28] MA J, CHEN J N, NG M, et al. Loss odyssey in medical image segmentation [J]. Medical Image Analysis, 2021, 71:102035.
- [29] BERTELS J B.EELBODE T.BERMAN M.et al. Optimizing the dice score and jaccard index for medical image segmentation: theory and practice[C] // Medical Image Computing and Computer Assisted Intervention-MICCAI 2019(MICCAI 2019). Cham:Springer, 2019.
- [30] TAQI A M,AWAD A,Al-AZZO F. The impact of multi-optimizers and data augmentation on tensorflow convolutional neural network perfor mance[C]//2018 IEEE Conference on Multimedia Information Processing and Retrieval(MIPR). Piscataway: IEEE,2018:140-145.



**BAI Xuefei**, born in 1980, Ph. D, associate professor, is a member of China Computer Federation. Her main research interests include image processing and machine learning.



WANG Wenjian, born in 1968, Ph. D, professor, is a member of China Computer Federation. Her main research interests include image processing, machine learning and computing intelligence.

(责任编辑:何杨)