

乳腺癌超声图像的腋窝淋巴结特征指导分割网络

班楷第^{1,2,3}, 孙 宇^{2,3}, 韩悦^{2,3}, 魏本征^{2,3}

(1. 山东中医药大学中医药创新研究院, 山东 济南 250355)

(2. 山东中医药大学医学人工智能研究中心, 山东 青岛 266112)

(3. 山东中医药大学青岛中医药科学院, 山东 青岛 266112)

[摘要] 腋窝淋巴结超声图像分割是一项具有临床价值且存在挑战性的任务, 对乳腺癌的诊断具有重要意义。为提升腋窝淋巴结临床分割精度, 针对腋窝淋巴结超声图像特点, 本文在编码器—解码器架构基础上, 设计特征指导模块, 实现特征提取中的特征高效融合和系数探索, 并在此基础上提出腋窝淋巴结特征指导分割网络, 实现超声图像中腋窝淋巴结的精准识别与分割。实验表明, 本文算法在 712 张腋窝淋巴结超声图像数据集上的 m-ACC 为 0.977, m-IoU 为 0.878, m-Dice 为 0.932, 优于现有分割模型, 分割结果可作为临床诊断参考, 辅助乳腺癌腋窝淋巴结转移的精准诊断。

[关键词] 腋窝淋巴结, 图像分割, 深度学习, 超声图像, 分割网络

[中图分类号] TP391 **[文献标志码]** A **[文章编号]** 1001-4616(2023)02-0092-07

Features Guidance Axillary Lymph Nodes Network for Breast Cancer Segmentation

Ban Kaidi^{1,2,3}, Sun Yu^{2,3}, Han Yue^{2,3}, Wei Benzhen^{2,3}

(1. College of Innovative Institute of Chinese Medicine and Pharmacy, Shandong University of Traditional Chinese Medicine, Jinan 250355, China)

(2. Center for Medical Artificial Intelligence, Shandong University of Traditional Chinese Medicine, Qingdao 266112, China)

(3. Qingdao Academy of Chinese Medical Sciences, Shandong University of Traditional Chinese Medicine, Qingdao 266112, China)

Abstract: Ultrasound image segmentation of axillary lymph nodes is a clinically valuable and challenging task, which is of great significance for the diagnosis of breast cancer. In order to improve the clinical segmentation accuracy of axillary lymph nodes, Aiming at the characteristics of axillary lymph nodes ultrasonic images, on the encoder decoder architecture, this paper designs a feature guidance module to achieve efficient feature fusion and coefficient exploration in feature extraction, and on this basis, the features guidance network of axillary lymph nodes is proposed to achieve accurate identification and segmentation of axillary lymph nodes in ultrasound images. Experiments show that on the dataset of 712 axillary lymph node ultrasound images, the m-ACC of this algorithm is 0.977, the m-IoU score is 0.878, and the m-Dice can reach 0.932, which is better than the existing segmentation model, and the segmentation results can be used as a clinical diagnosis reference to assist in the accurate diagnosis of axillary lymph node metastasis in breast cancer.

Key words: Axillary lymph nodes, image segmentation, deep learning, ultrasonic images, segmentation network

乳腺癌是全球第一大癌症^[1], 精准诊断是提高其疗效、降低死亡率的关键, 对乳腺癌患者的治疗和临床预后具有重要价值^[2]。腋窝淋巴结(axillary lymph nodes, ALN)肿大是乳腺癌早期症状之一, ALN 状态作为肿瘤负荷的重要指标^[3], 超声检查能够对其实现高分辨检查^[4], 且具有无创、无辐射、花费少、检测方便等优点^[5], 是最经济有效的乳腺癌腋窝淋巴结转移诊断方法^[6]。

超声影像作为一种重要的临床检测手段, 其诊断结果受医生水平与临床经验影响较大。医学图像分割作为计算机辅助诊断的重要研究方向, 现有图像分割模型对病灶细节难以精准分割, 特别是对超声检查

收稿日期: 2022-09-20.

基金项目: 国家自然科学基金项目(61872225)、山东省自然科学基金项目(ZR2020KF013、ZR2020ZD44、ZR2019ZD04、ZR2020QF043)、山东省高校青创引才育才计划项目(2019-173)、齐鲁卫生与健康领军人才培育工程项目。

通讯作者: 魏本征, 博士, 教授, 博士生导师, 研究方向: 医学人工智能, 机器学习等. E-mail: wbz99@sina.com

这一复杂成像方式、分割精度仍有待提升. 目前,迫切需求一种能够有效适用于超声影像病灶分割且准确率较高的辅助诊断模型,以提升临床诊断效率、降低临床医生的主观影响. 因此,腋窝淋巴结超声图像自动分割,对乳腺癌精准诊断具有重要意义^[7].

1 相关工作

医学图像分割是从医学影像中识别病变器官的像素点,旨在获取这些病变部位的信息特征,是医学图像分析的重要任务与研究热点. 近年来,对腋窝淋巴结超声图像的病灶分割正向着结果更加精确、网络泛化性与鲁棒性更高、模型训练过程更加精简的方向发展. 诸多学者致力于探索腋窝淋巴结的超声征象与其转移之间的关联性,并指导患者的临床行为^[8]. Drukker 等^[9]使用描述淋巴结的形态和纹理一阶数学描述符训练得到淋巴结转移判别分类器,在 ALN 良恶性分类中取得敏感性为 77%、特异性为 82%的检测效果;腋窝淋巴结特征模型(axillary lymph node feature model,ALNFM)^[10]对 ALN 转移进行逻辑回归分析,在腋窝淋巴结分类工作中得到 0.84 的预测精度;基于纹理与边界的影像组学关于乳腺癌肿块的分类工作也达到了 0.84 的精确度^[11]. 但是,上述工作较大程度上依赖于临床医生对超声图像回顾分析. 为此,Sun 等^[12]对于 ALN 转移评估中分别使用了 DenseNet^[13]深度学习和放射组学的方法,进行对比实验,深度学习的实验结果准确率优于放射组学方法. Ronneberger 等^[14]提出的 U-net 是医学图像分割精度提升上的里程碑;而增加了注意力机制的 Attention U-net^[15],使得特征提取过程聚焦关键区域. 上下文编码网络(context encoder network, CE-Net)^[16]适用于超声等医学图像的病灶区域分割任务,并表现出良好的性能. Zhou 等^[17]使用经典卷积神经网络对腋窝淋巴结状态进行预测,AUC 可达 0.89. 结合临床参数的深度学习算法^[18],经实验发现,可有效评估乳腺癌是否发生了腋窝淋巴结转移. 为减少样本标注工作量,Zhang 等^[19]使用堆栈式全卷积网络(coarse-to-fine stacked fully convolutional nets,CFS-FCN)在超声图像上分割腋窝淋巴结,m-IoU 可达 0.85; Shelhamer 等^[20]结合全卷积神经网络(fully convolutional networks,FCN)和主动学习的算法^[21-22],减少了 50% 的 ALN 样本标注工作,但是由于引进参数以及计算量的增加,训练复杂繁琐.

由上述分析可知,现有研究虽在医学图像分割不同层面取得诸多进展,但仍存在分割边缘不完整、分割精度有待提升等问题. 因此,本文针对超声影像中 ALN 的分割任务,完成了以下工作:

- (1)设计基于超声图像的腋窝淋巴结特征指导分割网络,实现了腋窝淋巴结的自动识别与分割;
- (2)为有效利用低维空间的边缘信息与高维空间丰富的特征信息,提出编码输入与解码输出的特征融合方案,实现了局部特征与全局特征的交互;
- (3)在特征系数学习过程,基于通道进行 3 次并行的像素级预测,实现了每次预测与原输入特征的融合,完成了对不同空间位置的特征提取,增强了模型特征提取能力. 使用特征系数指导编码输入特征,有效避免了网络参数量与计算量的剧增.




图 1 腋窝淋巴结特征指导分割网络结构图

Fig. 1 Axillary lymph node features guide the segmentation network structure diagram

2 算法设计

本研究为更好实现对超声影像 ALN 分割,提升分割准确率,提出基于编码器-解码器结构的特征指导分割网络(features guidance network,FgNet). 其充分考虑超声成像的对比度、清晰度、轮廓结构明暗等信息;以及处于乳腺癌不同阶段的 ALN 在结构比例、形状大小上的差异. 在该网络中,首先,为解决微小位置

变化的敏感度低、增强网络层的局部抗干扰力,在解码器第 1、2、3 层中加入了特征指导模块,作为并行预测分支,其原理如式(1)所示.

$$x_j^l = g \left(\left(\sum_{i=m_j} x_i^{(l-1)} * h_{ij}^l \right) + b_j^l \right). \quad (1)$$

l 代表卷积层数; m_j 代表输入层的感受野; b_j^l 为神经元偏置项; $\sigma(\cdot)$ 为非线性激活函数; h 代表卷积核; h_{ij}^l 表示与前层神经元的连接强度.

其次,为避免池化操作造成细节信息有误的问题,在还原特征图分辨率的过程中增加了局部特征的输入.最后,针对低维空间提取的边缘特征信息过于粗糙干扰特征提取的问题,提出特征指导模块增加解码特征信息.

解码块特征融合对应的低维空间特征作为输入特征图,通过特征指导模块,使用卷积对每个空间位置进行目标分类的同时,基于通道数量并行增加标签预测,以提升模型的像素级分割的准确率和局部抗干扰力.但是此过程会引起网络层剧增、出现梯度消失、特征图辨识度降低,为解决上述问题,重置新增预测分支的输出通道数量,并使用激活函数得到对应的函数值,将这个值定义为特征系数.使用特征系数可实现高效特征提取,避免网络层与参数数量的剧增.最后使用特征系数与局部特征图相乘,得到更加精确的特征输出,此过程可表达为式(2).

$$f_{\text{out}} = f_e \cdot \sigma(f_w). \quad (2)$$

f_{out} 为 FGM 的特征输出; f_e 为 FGM 来自解码块的特征图输入; $\sigma(\cdot)$ 为非线性激活函数; f_w 为 FGM 学习到的指导特征图.

2.1 特征指导模块

在特征提取过程中由于细节信息丢失、对局部特征关注度低,且抗干扰能力不足,导致分割精度不佳.为此,FgNet 中设计了特征指导模块,旨在使编码块与解码块的特征信息进行互相补充,充分利用低层的轮廓信息和高层的高级特征,弥补下采样与卷积操作过程中丢失的细节信息,实现超声图像 ALN 的精确分割.

特征指导模块使用了两组并行的特征学习与融合分支,在这个过程中不断探索特征学习的正确方向,调整特征信息,获得相应特征系数指导输入到下一层解码块的特征信息.本网络共进行了 3 次特征指导操作,有效解决 ALN 多样性导致的分割精度不佳的问题.由图 2 所示,空间位置不同的解码特征图 f_e 、编码特征图 f_d 同时作为 FGM 的输入,上采样操作解决了 f_e 分辨率小的问题;分别对 f_e 和 f_d 进行 1×1 的卷积计算;由于 float 16 的低精度无法很好地描述较大范围数值,在使用 ReLU6 限制最大值的基础上进行了特征融合,得到特征 f_r .此操作可表达为式(3),ReLU6 原理如式(4)所示,即 $x < 0$ 或 $x > 6$ 时,其导数为 0.

$$f_r = g_{C/2}((f_e) + U(f_d)), \quad (3)$$

$$\text{ReLU6} = \min(6, \max(0, x)). \quad (4)$$

$g_{C/2}(\cdot)$ 表示输出通道数量为 $C/2$ 的 1×1 卷积操作; f_d 表示解码块输出的特征图; $U(\cdot)$ 表示上采样操作.

重置通道数的卷积计算并获取特征系数,在特征系数指导下得到的新的特征图输出.此过程,有效避免了网络层过深带来训练困难,梯度消失等问题.

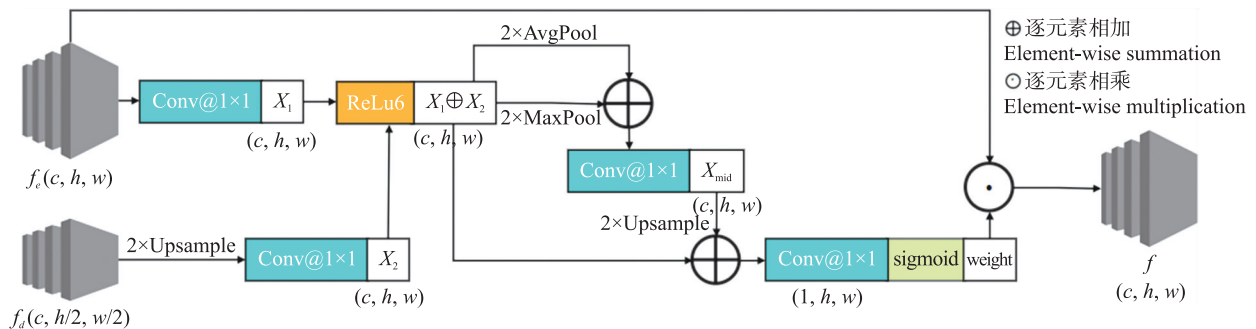


图 2 特征指导模块结构图

Fig. 2 Structure diagram of the feature guidance module

2.2 腋窝淋巴结特征指导分割网络

图1为FgNet的整体结构图,FgNet用于学习特征的骨干网络为编码器-解码器架构.网络输入图像大小为 512×512 ,骨干网络的所有卷积层均进行了 3×3 卷积计算、批归一化处理、ReLU计算3项操作的两次堆叠,以获取更多特征信息.编码部分共4个编码块,通过步长为2的最大池化(max pooling)对特征图进行下采样操作,增加输出通道数量、扩大感受野,获得高级特征,得到更加丰富的特征信息,有利于网络精确度的提升;解码路径由用于维护编码器高级功能并增强其表达能力的级联解码块组成,利用放大因子为2的双线性插值器对特征图进行4次上采样操作,以还原成原始输入尺寸.

为融合低级特征中的边缘信息,设计了特征指导模块,FGM增加并行标签预测.特征指导模块将低级特征与高级特征相加,并将得到的特征图分别使用平均池化、最大池化进行下采样操作,使用 1×1 卷积进行特征预测之后上采样恢复特征图大小,此时与最初相加得到的特征信息相加,进行特征融合.此时,通道数设置为1.此过程如式(5)所示.

$$f_w = g_1(U(g_c(I_a(f_r) + I_m(f_r)) + f_r)), \quad (5)$$

$g_1(\cdot)$ 与 $g_c(\cdot)$ 分别表示输出通道为1和 c 的 1×1 卷积操作; $I_m(\cdot)$ 与 $I_a(\cdot)$ 分别表示最大池化操作和平均池化操作.

将上述特征信息通过激活函数操作得到对应的特征系数表达.其中包含了融合了来自低层卷积层中的边缘信息与高层中丰富的细节信息、专注于相应空间的局部特征信息.因此,此时的特征系数可有效指导编码块特征输入解码块的特征变换过程.特征指导模块工作过程如图2所示.

训练过程中使用在医生指导下进行ALN标注的图像作为衡量分割准确度的标准,使用损失函数,优化模型性能,提升分割精度.解码器相加通过FGM输出的特征图,输出分割结果大小为 512×512 ,分割结果可视化如图3所示.

2.3 损失函数

为优化FgNet,计算本网络输出特征图与真实值的交叉熵损失函数如式(6)所示.

$$\text{loss}(x, \text{class}) = -x[\text{class}] + \log\left(\sum_j \exp(x[j])\right), \quad (6)$$

x 表示样本; class 为类别信息,本网络设置二分类,即是否存在异常腋窝淋巴结.

本实验中使用IoU与Dice作为分割精度的评估指标,计算过程分别为式(7)、式(8).

$$\text{IoU loss} = 1 - \frac{A \cap B}{A \cup B}, \quad (7)$$

$$\text{Dice loss} = 1 - \frac{2|A \cap B|}{|A| + |B|}. \quad (8)$$

A 表示真实的分割图像, B 表示预测的分割图像.

3 结果与讨论

本实验使用NVIDIA GeForce RTX 2070完成模型训练与测试,实验中将FgNet学习率设置为0.0001.在完成13轮训练后,模型在训练集loss值为0.13、在验证集loss值为0.29,此时模型已趋于稳定.训练集与验证集loss值变化随训练轮数变化如图4所示.因此,较少迭代轮数说明FgNet具有更好的学习能力;在训练集和验证集中loss值较小差距,说明模型具有较好的鲁棒性.




图3 分割结果可视化示例图

Fig. 3 Example illustration of the visualization of the segmentation result




图4 训练过程中训练集与验证集loss变化

Fig. 4 The loss of the training set and the validation set change during training

3.1 数据集

本研究从山东第一医科大学附属千佛山医院获取 712 张有效腋窝淋巴结超声图像,在该院三位放射科专家指导下对其完成病灶区域标注.随后对所有图像尺寸统一格式化为 512×512,基于此构建本文实验所用的腋窝淋巴结分割的数据集.在实验过程中,为避免样本划分不一致导致的模型波动,本文采用交叉验证法按照 7:2:1 比例将数据集划分为互斥的训练集、验证集、测试集,分别用于模型训练、验证与测试.

3.2 评价标准

本文采用准确率 (accuracy, ACC)、Dice 系数 (dice similariy coefficient, DSC) 和平均交并比 (mean intersection over union, MIoU) 分别评价模型在腋窝淋巴结中的特征提取能力、模型对腋窝淋巴结转移预测的有效性和模型的全局分割性能.上述指标计算公式分别如式(9)~式(11)所示.

准确率定义为:

$$ACC=\frac{TP+TN}{TP+TN+FP+FN}, \tag{9}$$

Dice 系数定义为:

$$D_{sc}=\frac{2TP}{2TP+FP+FN}, \tag{10}$$

平均交并比定义为:

$$MIoU=\frac{1}{k+1}\sum_{i=0}^k\frac{P_{ii}}{\sum_{j=0}^kP_{ij}+\sum_{j=0}^kP_{ji}-P_{ii}}. \tag{11}$$

式中, TP 、 FP 、 TN 、 FN 分别表示真正例个数、假正例个数、真反例个数、假反例个数; $k+1$ 表示类别数量; P_{ij} 表示 i 被预测为 j 的数量; P_{ii} 表示 i 被正确预测的数量; P_{ji} 表示被 j 预测为 i 的数量.

3.3 实验结果与分析

为验证 FgNet 的特征提取性能,本文分别从识别灵敏度、分割精度和模型参数量 3 个角度,将其与 U-Net、Attention U-net、PSP-Net 和 DeepLabV3+ 等性能优异算法进行比较,具体实验结果如表 1 所示.在 ALN 识别灵敏度测试中,FgNet 的 m-ACC 为 0.977,分别比 U-Net、Attention U-net 和 PSP-Net 模型提升 0.1、0.1 和 0.2 个百分点,仅比 DeepLabV3+ 低 0.009,这充分说明 FgNet 对淋巴结具有较强的识别能力,且性能优于绝大多数分割算法.在分割精度实验中,FgNet 的 m-IoU 为 0.878,与所对比的模型相比分别提升 3.2、1.5、1.7 和 0.6 个百分点;FgNet 的 m-Dice 为 0.932,与所对比的模型相比分别提升 3.0、1.9、1.5 和 0.4 个百分点.这说明本文提出的 FgNet 在淋巴结的细节分割时能获得到更加精准的分割区域,分割结果的特征展现更加完整.在模型参数量统计中发现,FgNet 的参数大小仅为 13.1MB,远低于所对比的其他分割模型,这证明本模型产生的参数量较低,训练速度更快,具有更强的可部署性.

表 1 腋窝淋巴结分割对比实验结果

Table 1 Axillary lymph node segmentation versus experimental results

模型	m-ACC	m-IoU	m-Dice	参数量/MB
U-Net ^[14]	0.976	0.846	0.902	14.1
Attention U-net ^[15]	0.976	0.863	0.913	14.1
PSP-Net ^[23]	0.975	0.861	0.917	49.2
DeepLabV3+ ^[24]	0.986	0.872	0.928	59.5
FgNet	0.977	0.878	0.932	13.1

由上述研究结果分析可知,FgNet 对 ALN 具有较好的识别能力,在特征提取方面具有良好的鲁棒性,其对病灶具有更高的分割精度,分割结果更加精细、完整度更高,同时模型具有更少的参数量,这使得模型具备更广泛的临床应用前景.

4 结论

本文充分考虑超声图像中腋窝淋巴结边缘轮廓较明显这一特征,提出了一种适用于超声图像腋窝淋巴结分割 FgNet 模型,通过融合不同空间位置的卷积层特征信息,增强了模型对低级特征轮廓特征的表达

能力,实现了对兴趣区域特征信息的有效提取.同时,设计特征指导模块,获取高效特征融合系数指导解码输入中的特征变换,以增强模型的抗扰动能力,加强对局部特征的提取,进而提升网络的整体分割精度.

未来,在各类疾病临床辅助诊断中,提升病灶区域分割精度无疑是热点问题之一,而基于小样本实现对病灶区域的精准分割,更是医学图像分割的未来工作的方向与目标.

[参考文献]

- [1] WILD C P, WEIDERPASS E, STEWART B W. World Cancer Report: cancer research for Cancer Prevention [M]. Lyon: International Agency for Research on Cancer, 2020.
- [2] EIGHAZALY H, ANDERSON, ABDFLAZIZ H, et al. The first BGICC consensus and recommendations for breast awareness, early detection and risk reduction in low- and middle-income countries and the MENA region [J]. International journal of cancer, 2021, 149(3): 505-513.
- [3] 王丽君, 罗冉, 陈艳虹, 等. 影像学在乳腺癌新辅助治疗疗效评估中的优势与限度 [J]. 中华放射学杂志, 2022, 56(1): 113-116.
- [4] 谢亚咩, 王欢. 影像新技术在乳腺疾病筛查中的应用 [J]. 临床医学进展, 2022, 12(1): 6.
- [5] GARCIA T A, FERNANDEZ G S, ORTEGA R, et al. Can we avoid axillary lymph node dissection in N2 breast cancer patients with chemo-sensitive tumours such as HER2 and TNBC? [J]. Breast cancer research and treatment, 2021, 185(2): 1-10.
- [6] 付慧, 穆为民, 吕艳丽, 等. 超声诊断乳腺癌腋窝淋巴结转移状态的临床应用价值 [J]. 山西医药杂志, 2019, 48(3): 263-266.
- [7] LIU C, CHEN S, YANG Y, et al. The value of the computer-aided diagnosis system for thyroid lesions based on computed tomography images [J]. Quantitative imaging in medicine and surgery, 2019, 9(4): 642.
- [8] VALDORA F, HOUSSAMI N, ROSSI F, et al. Rapid review: radiomics and breast cancer [J]. Breast cancer research & treatment, 2018, 169(2): 217-229.
- [9] DRUKKER K, GIGER M, MEINEL L A, et al. Quantitative ultrasound image analysis of axillary lymph node status in breast cancer patients [J]. International journal of computer assisted radiology & surgery, 2013, 8(6): 895-903.
- [10] 金华, 罗伟权, 纪宗萍, 等. 乳腺癌超声影像组学图像特征 Logistic 回归方程预测腋窝淋巴结转移风险 [J]. 中国超声医学杂志, 2021, 37(2): 139-142.
- [11] 马明明, 崔应谱, 刘想, 等. 基于乳腺 X 线摄影的影像组学对乳腺肿块和钙化良恶性分类的研究 [J]. 放射学实践, 2022, 37(3): 325-330.
- [12] SUN Q, LIN X, ZHAO Y, et al. Deep learning vs. radiomics for predicting axillary lymph node metastasis of breast cancer using ultrasound images; don't forget the peritumoral region [J]. Frontiers in oncology, 2020, 10: 53.
- [13] HUANG G, LIU Z, MAATEN V D, et al. Densely connected convolutional networks [C]//Proceedings of the 30th IEEE conference on computer vision and pattern recognition. Honolulu, Hawaii: IEEE, 2017.
- [14] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation [C]//International conference on medical image computing and computer-assisted intervention. Munich Germany: Springer, 2015.
- [15] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-net: learning where to look for the pancreas [C]//International conference on medical imaging with deep learning. New York: PMLR, 2018.
- [16] GU Z W, CHENG J, FU H Z, et al. CE-Net: context encoder network for 2D medical image segmentation [J]. IEEE transactions on medical imaging, 2019, 38(10): 2281-2292.
- [17] ZHOU L Q, WU X L, HUANG S Y, et al. Lymph node metastasis prediction from primary breast cancer US images using deep learning [J]. Radiology, 2020, 294(1): 19-28.
- [18] ZHENG X, YAO Z, HUANG Y, et al. Deep learning radiomics can predict axillary lymph node status in early-stage breast cancer [J]. Nature communications, 2020, 11(1): 1-9.
- [19] ZHANG Y, YING M T C, YANG L, et al. Coarse-to-fine stacked fully convolutional nets for lymph node segmentation in ultrasound images [C]//IEEE international conference on bioinformatics and biomedicine (BIBM). Shenzhen, China: IEEE, 2016.
- [20] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE transactions on pattern analysis and machine intelligence, 2016, 39(4): 640-651.

-
- [21] LIN Y, ZHANG Y Z, CHEN J X, et al. Suggestive annotation: A deep active learning framework for biomedical image segmentation[C]//International conference on medical image computing and computer-assisted intervention. Quebec City, Canada:Springer,2017.
- [22] 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.
- [23] 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(CVPR). Honolulu:IEEE,2017.
- [24] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//Proceedings of the European conference on computer vision(ECCV). Munich,Germany:Springer,2018.

[责任编辑:黄 敏]