

## 基于改进U-Net网络的肾脏肿瘤全自动分割

李佳柠,王瑜,肖洪兵,闫善武,孙梅  
北京工商大学人工智能学院,北京 100048

**【摘要】**针对肾脏肿瘤大小、位置不确定以及传统U-Net网络全自动分割肾脏肿瘤时易出现过拟合等难题,提出一种改进的多尺度卷积和残差U-Net(MSR U-Net)的肾脏肿瘤全自动分割方法。一方面,在残差模块中加入跳跃连接使网络收敛得更快,缓解过拟合现象;另一方面,在多尺度卷积模块中采用3种不同尺寸的卷积核,增加网络的感受野,解决网络提取的肿瘤特征尺寸单一问题。使用KITS19数据库中90例患者的CT切片进行相关验证性实验,MSR U-Net方法获得了肾脏的Dice系数为0.976和肿瘤的Dice系数为0.836,表明MSR U-Net在全自动肾脏肿瘤分割任务中的可行性和有效性。

**【关键词】**U-Net网络;CT影像;肾脏肿瘤;多尺度卷积;残差模块

**【中图分类号】**R318;TP391

**【文献标志码】**A

**【文章编号】**1005-202X(2023)10-1241-05

### Fully automated kidney tumor segmentation based on improved U-Net

LI Jianing, WANG Yu, XIAO Hongbing, YAN Shanwu, SUN Mei

School of Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

**Abstract:** Aiming at some intractable problems such as the uncertain size and location of kidney tumors, and overfitting etc. when using the traditional U-Net network to segment kidney tumor full-automatically, a fully automated segmentation method for kidney tumors based on multi-scale and residual U-Net (MSR U-Net) is proposed. Skip connections is added in the residual module to make the network converge faster, further avoiding the overfitting. Moreover, 3 different sizes of convolution kernels are used in the multi-scale convolution module to increase the receptive field, solving the problem of single feature size. The CT slices of 90 patients in the KITS19 database are used to carry out relevant verification experiments. MSR U-Net method obtains a Dice coefficient of 0.976 for kidney and 0.836 for tumor, indicating that the proposed algorithm is feasible and effective in the fully automated kidney tumor segmentation task.

**Keywords:** U-Net; CT image; kidney tumor; multi-scale convolution; residual module

### 前言

肾癌是人类最常见的癌症之一<sup>[1]</sup>,也是死亡率最高的泌尿生殖道癌症之一<sup>[2]</sup>,每年有超过40万例新增肾癌病例<sup>[3]</sup>。在肾癌的临床治疗中,与切除患者的整个肾脏方法相比,保留肾单位手术越来越受到患者的认可<sup>[4-5]</sup>。计算机断层扫描(Computed Tomography, CT)影像可以很好地辅助医生来判断肾脏肿瘤的位置<sup>[6]</sup>,可是手动地从数百张CT切片中勾

画出肾脏肿瘤过于耗时耗力<sup>[7]</sup>。肾脏肿瘤的全自动分割可以利用一种有效而可靠的方式辅助医生获得准确的肿瘤形态学细节,从而利用这些信息制定肾脏肿瘤治疗计划<sup>[8]</sup>。因此,设计一种能够全自动地从肾脏CT图像中精确分割出肾脏肿瘤的方法是很有必要的。目前,很多方法可以实现肾脏和肿瘤的分割,传统的分割方法主要是根据图像的灰度和纹理等特征进行分割<sup>[9-12]</sup>。Lee等<sup>[13]</sup>首先根据灰度值和阈值确定肾脏的感兴趣区域,然后通过使用纹理和上下文特征分类,有效提高肾脏肿瘤的检测准确率。高岩等<sup>[14]</sup>利用灰度共生矩阵提取出12种纹理特征,经过特征的有效性选择后采用最能体现肿瘤和肾脏其它部分差异性的4种纹理特征,结合加权欧氏距离法分割出肾脏肿瘤,很好地分割出肾脏肿瘤。但是,上述的分割方法处理步骤过于繁琐,不适合大数据量的CT影像分割。近年来,深度学习很好地应用在

**【收稿日期】**2023-03-14

**【基金项目】**北京市自然科学基金-北京市教育委员会科技计划重点项目(KZ202110011015)

**【作者简介】**李佳柠,硕士,研究方向:医学图像处理与模式识别,E-mail: 990670042@qq.com

**【通信作者】**王瑜,教授,研究方向:图像处理与模式识别,E-mail: wangyu@btbu.edu.cn

医学图像分割任务上,帮助研究者解决了部分问题<sup>[15-17]</sup>。随着深度学习方法的广泛应用,越来越多的卷积神经网络(Convolutional Neural Network, CNN)方法用于肾脏肿瘤的分割。为了推进深度学习技术在肾脏肿瘤分割中的应用,2019年国际医学图像计算和计算机辅助干预会议(MICCAI)开展了一场肾脏和肾脏肿瘤分割挑战赛<sup>[18-19]</sup>。

CNN在图像分割任务上获得了不错的效果<sup>[20]</sup>。潘覃<sup>[21]</sup>设计了肾脏肿瘤分割和分类的双任务卷积神经网络(SCnet),利用全局上下文信息和存在类别之间的关联性来降低误分割率。Zhao等<sup>[22]</sup>设计的金字塔场景解析网络(Pyramid Scene Parsing Network, PSPNet)是基于全卷积神经网络<sup>[23]</sup>改进而来,可以同时使用局部信息和全局信息得出预测结果。Ronneberger等<sup>[24]</sup>于2015年提出的U-Net网络,迅速成为医学图像分割中常用的基准<sup>[25]</sup>。2019年肾脏肿瘤分割挑战赛(KITS19)<sup>[19]</sup>成功举办,更加关注网络结构以外的参数配置的nnU-Net<sup>[25]</sup>被提出。综上,很多方法都使用普通的卷积来提取特征,但是由于普通卷积的局限性,没有充分考虑特征图的多尺度信息,容易造成深层特征信息的丢失。本研究在传统U-Net的网络基础上,提出一种改进的多尺度卷积和残差U-Net(Multi-Scale and Residual U-Net, MSR U-Net)方法,用于CT影像中肾脏肿瘤的精确分割。

## 1 资料与方法

本研究实验选取KITS19<sup>[19]</sup>数据集,对每位患者的3D数据均进行预处理,去除无效图像,然后使用改进的MSR U-Net网络对肾脏和肾脏肿瘤进行分割。

### 1.1 数据集介绍

肾脏肿瘤分割挑战赛(Kidney Tumor Segmentation Challenge)<sup>[19]</sup>是由MICCAI大会<sup>[18]</sup>在2019年举办的国际赛事,其宗旨是致力于促进对肾脏及肿瘤进行语义分割方法的研究,辅助医生对肾脏肿瘤进行诊断与分析,为临床诊疗和相关研究提供可靠的科学依据。本文从组织者提供的210例病人的术前CT扫描图像中随机挑选90例数据进行实验,每组数据均包含由专家手动标注的标签,包括整个肾脏的轮廓、肿瘤和囊肿,数据格式为.NIFTI,0表示背景,1表示肾脏,2表示肾脏肿瘤。KITS19数据集中每个病例的CT图像包含若干组切片数据,平面内分辨率范围为0.44 mm×0.44 mm至1.04 mm×1.04 mm,每个病例的切片数量从29到1 059不等,每个横向切片的尺寸相同,均为512×512像素。每组切片数据包含多张肾脏CT图像和标签,这些标签中有的包含肾脏和肾脏肿瘤,有的则不包含相关信息。

### 1.2 数据预处理

尽管基于深度学习的模型对噪声具有鲁棒性,但是由于完整的肾脏CT切片包含过多的无关信息,在将原始CT图像输入网络模型之前进行数据预处理,本研究提出方法的预处理工作包括:首先对三维(Three-Dimensional, 3D)数据切片化,将每位病人的3D影像数据切成二维(Two-Dimensional, 2D)图像;然后选取有效图像,因为每位患者3D数据中,只有中间部分的切片包含肾脏组织,所以需要去除无效图像,即每位患者的前30%和后30%的切片,提高特征定位精度和运算速度;最后选取感兴趣区域,从有效的2D数据中选择包含肾脏和肾脏肿瘤部分的区域。因为肾脏在腹腔中的位置大多集中在同一区域,所以适当地缩小输入图片的尺寸可以有效提升网络的训练速度。根据观察发现,肾脏在CT切片中的位置大多固定在图像的中下方,通过反复调试,可剪裁出适用于肾脏肿瘤分割的图像。整理完成后的数据集,肾脏部分包括5 179幅图像,肿瘤部分包含1 426幅图像,图片大小均为512×512像素。

### 1.3 特征提取的网络构建

**1.3.1 整体架构** 利用深度学习网络架构提取的特征质量对分割结果至关重要。为了能充分提取到肾脏肿瘤的特征,本研究构建一种改进的U-Net网络—MSR U-Net网络,对肾脏肿瘤进行特征提取和分割,网络结构如图1所示。

MSR U-Net网络由编码器和解码器组成,网络的左侧部分为编码器,假设该网络输入图像尺寸为 $L \times W \times C$ ( $L$ 、 $W$ 分别表示图像的长和宽, $C$ 为通道数),将其进行卷积核尺寸为3×3、步长为1、过滤器个数为64的卷积操作,卷积的计算如式(1)所示:

$$F(x) = \sum_{\tau=-n}^n f(\tau)g(x-\tau) + b \quad (1)$$

得到维度减少的特征图后,将通道数为64的特征图送入残差模块中,在进行卷积提取特征之前,对特征图的长和宽进行填充(Padding),通常用0来实现,使之在卷积后能得到与输入尺寸大小相同的特征图。Padding层数、输入图像尺寸、输出图像尺寸及过滤器参数之间的计算公式如式(2)所示:

$$w = \frac{l + 2p - f}{s} + 1 \quad (2)$$

其中, $w$ 表示输出图像的尺寸, $l$ 表示输入图像的尺寸, $p$ 代表Padding的层数, $f$ 表示过滤器尺寸, $s$ 表示步长。接下来,对特征图进行步长为2的最大池化操作,最大池化选取2×2过滤器中的最大值为输出,将特征图的长和宽缩小为原来的1/2,减少空间占用和计算量;再重复上述操作,通过不断的下采样和残差模块操作,得到尺寸小但通道数较多的特征图。




图1 MSR U-Net网络结构  
Figure 1 Structure of MSR U-Net

网络的右侧为解码器,采用重复的上采样和多尺度卷积模块,上采样使特征图尺寸扩大2倍,多尺度卷积块获得感受野更丰富的特征图。网络的每一层编码器和对应的解码器之间使用跳跃连接,将编码端的特征图像剪裁为与解码端的特征尺寸一致,然后将两种特征图进行拼接得到一个新的特征图,对特征信息进行补充,输入到下一个子模块,直到最终输出通道数为3的特征图。

**1.3.2 残差模块** 残差模块结构如图2所示,包含两个卷积操作,输出为输入与第二个卷积层未经非线性激活前的特征图进行逐像素点的相加所得。残差模块对网络的设计有两点好处:其一,深层的网络模型不是从随机的状态往目标上优化,而是基于上一特征层的状态继续优化偏差;其二,跳跃连接的设计使误差的反向传播更加顺畅,误差梯度可以通过两条路径进行回传,通过跳跃连接的误差可以不经任何微分运算直接传递到上一层,所以这非常有利于网络的优化。




图2 残差模块结构  
Figure 2 Residual block

如图2所示,残差模块分成两部分,一部分是残差部分,另一部分是直接映射部分,相关表示如式(3)所示:

$$X_{l+1} = X_l + F(X_l, W_l) \tag{3}$$

其中,  $F(X_l, W_l)$  是残差部分,一般由两个卷积操作构成,即图2中的下侧包含卷积的部分。  $h(X_l)$  是直接映射,为图2中的上侧直角连线部分,即跳跃连接部分。

**1.3.3 多尺度卷积模块** 由于传统的U-Net网络中的卷积核尺寸都为3×3,单一固定,考虑到肾脏肿瘤的大小、位置均不固定等情况,为了提高网络的感受野,本文将MS模块代替原来解码路径的卷积块,MS模块结构如图3所示。MS模块的输入为上一次卷积后的结果,然后使用3种不同尺寸的过滤器对特征进行两次提取,特征图在经过3次不同尺寸的卷积之后仍然拥有相同的维度,再将特征图按照通道层面上进行叠加,得到感受野更丰富的特征图。随后用ReLU激活函数进行激活,得到的结果作为输出。




图3 MS模块结构  
Figure 3 MS module

1.4 评估指标与实验设置

**1.4.1 评估指标** 为了准确评估分割精度,本研究采用广泛使用的Dice系数和豪斯多夫距离(HD)作为主要的评价指标,Dice系数定义如式(4)所示:

$$\text{Dice} = \frac{2|P \cap G|}{|P| + |G|} \tag{4}$$

其中,  $P$  代表网络模型预测输出的分割结果,  $G$  代表真实的区域。  $P$  和  $G$  的交集代表正确分割的区域。Dice的值越高,预测结果与真实结果更接近。

在欧式空间中的两个点集,  $O = \{o_1, o_2, o_3, \dots\}$ ,  $X = \{x_1, x_2, x_3, \dots\}$ , HD距离用来衡量两个点集之间的距离,定义如式(5)所示:

$$H(O, X) = \max[h(O, X), h(X, O)] \tag{5}$$



其中,  $h(O, X)$  表示点集  $O$  到  $X$  的 HD 距离,  $h(X, O)$  表示点集  $X$  到  $O$  的 HD 距离。  $H(O, X)$  的值越小, 表明预测结果与真实结果更接近。

**1.4.2 实验设置** 本研究使用 KITS19 数据集, 共包含 6 605 张图片, 其中训练集、验证集、测试集的比例为 8:1:1。使用改进的 U-Net 对肾脏肿瘤特征进行提取, 该网络模型使用 Python 语言, 基于深度学习 Keras 框架实现, 并结合 Tensorflow 为构建基础。 计算机软件环境: Windows 10; 读图软件: ITK-SNAP; 在模型训练过程中采用随机梯度下降算法进行优化, 初始学习率为 0.05。在训练肾脏分割模型时, 将训练集批大小设置为 1, 每个 epoch 里随机对 32 个样本进行采样作为网络输入。整个训练过程共设置 100 次迭代, 每 10 次迭代将学习率衰减 1/2。在进行肾脏肿瘤分割模型训练时, 将训练集批大小设置为 16, 每个 epoch 中所有的训练集数据都参与网络参数的更新。

## 2 结果与分析

为了验证残差模块和多尺度卷积架构的有效性, 本研究设计了一系列消融实验, 消融实验的结果如表 1 和表 2 所示。实验结果如表 1 所示, 当将 MS 模块添加到 U-Net (MS U-Net) 中时, 肾脏的 Dice 增加了 0.7%, 而肿瘤的 Dice 增加了 3.7%, 该结果表明 MS 模块对肾脏和肿瘤的分割是有利的, 尤其是对肿瘤的分割更加有效。使用 MSR U-Net 方法的肾脏和肿瘤的 Dice 优于基本的 U-Net, 分别增加了 1.1% 和 4.5%。本方法在肾脏分割和肿瘤分割都有明显的提升。最后综合比较分割结果 (表 1), MS U-Net 的平均 Dice 值比基础的 U-Net 提高了 2.2%, MSR U-Net 的平均 Dice 值比基础的 U-Net 提高了 2.8%。

表 1 消融实验 Dice 结果  
Table 1 Dice results of ablation experiment

方法	肾脏 Dice	肿瘤 Dice	均值
U-Net+Dropout (去除无效图像前)	0.632	0.484	0.558
U-Net	0.965	0.791	0.878
MS U-Net	0.972	0.828	0.900
Res U-Net	0.970	0.813	0.892
MSR U-Net	0.976	0.836	0.906

如表 2 所示, 在肾脏分割上, MSR U-Net、MS U-Net 比基础的 U-Net 的 HD 小 1.009 和 0.827 mm。在肿瘤分割上, HD 分别下降了 3.496 和 2.018 mm。从结果可以看出, 肾脏组织和肿瘤的 HD 都有所降低, 尤其是肿瘤的 HD 下降明显, 说明 MSR U-Net 可以提升肾脏肿瘤分割的准确性。

表 2 消融实验 HD 结果 (mm)  
Table 2 HD results of ablation experiment (mm)

方法	肾脏 HD	肿瘤 HD
U-Net	16.978	17.628
MS U-Net	16.151	15.610
Res U-Net	16.860	16.773
MSR U-Net	15.969	14.132

图 4 中给出了 U-Net、MS U-Net、Res U-Net 和 MSR U-Net 的定性评估结果。对于第 1 行的情况, 肿瘤占据了左肾的部分面积, 并且右肾占据面积非常小, 难以分辨, 根据图 4 可以看出, U-Net 分割出来的肿瘤面积没有 MS U-Net、Res U-Net 和 MSR U-Net 分割得大, U-Net 没有将面积很小的右肾分割出来, 而 MS U-Net、Res U-Net 和 MSR U-Net 都在一定程度上分割出了右肾, 其中 MSR U-Net 分割出来的右肾与真实标签上的右肾基本一致。第 2 行的案例可以看出, 标签中只有右边小面积的肾脏, U-Net 没有将右肾分割出来, 而 Res U-Net 和 MS U-Net 和 MSR U-Net 都在一定程度上分割出了少量的右肾区域。从第 3 行的案例中可以看出, 标签中的左肾中包含两个面积很小的肿瘤, 分别位于左肾内部和左肾边缘, 右肾中不包含肿瘤。可以看出, U-Net 没有将左肾的肿瘤分割出来, MS U-Net、Res U-Net 和 MSR U-Net 都在一定程度上分割出了肿瘤区域, 其中 MS U-Net 只分割出了左肾边缘的肿瘤区域, Res U-Net 分割出了两个肿瘤区域, 但嵌在左肾内部的肿瘤区域明显大于真实标签, 而本文方法 MSR U-Net 在肿瘤形状分割中获得了最佳性能, 与真实标签最为接近。

为了进一步评估本文方法的性能, 将本文网络与其他方法进行比较, 包括非机器学习常规分割方法 (文献 [13]) 以及 PSPNet<sup>[22]</sup>、SCnet<sup>[21]</sup>、nnU-Net<sup>[25]</sup>。如表 3 所示, 本文方法在肾脏分割上取得了最高的 Dice 值, 比 nnU-Net 高了 1.3%, 比 SCnet 高了 3.1%, 比 PSPNet 高了 6.5%, 比文献 [13] 所用方法高 15.8%, 其中文献 [13] 所用方法分割结果最差, 主要是没有提取到更深层次的信息, 更加依赖人为设定的阈值来进行分割。在肾脏和肿瘤的整体分割上面比较, 本文所用方法取得的最高的 Dice 值比 nnU-Net 高了 0.4%, 比 SCnet 高了 1.2%, 比 PSPNet 高了 5%, 比文献 [13] 所用方法高 13.2%。

## 3 结 论

本研究提出的 MSR U-Net 方法可用于解决肾脏肿瘤全自动分割任务, 该方法首先对数据进行预处理, 然后利用残差模块、多尺度卷积块与 U-Net 相结合, 残差模块可以使网络收敛得更加迅速, 多尺度卷积模块可




图4 不同方法分割结果比较

Figure 4 Comparison of segmentation results

表3 不同方法的对比实验结果

Table 3 Comparative experimental results

方法	肾脏 Dice	肿瘤 Dice	均值
文献[13]	0.818	0.729	0.774
PSPNet <sup>[22]</sup>	0.911	0.804	0.856
SCNet <sup>[21]</sup>	0.945	0.844	0.894
nnU-Net <sup>[25]</sup>	0.963	0.840	0.902
MSR U-Net	0.976	0.836	0.906

以增加网络的感受野,更准确地提取肾脏和肾脏肿瘤的全方位特征。实验结果表明,本文方法在肾脏肿瘤分割任务中能够获得较好的分割精度。未来工作中,拟将CT影像内部的空间特征和边缘特征相结合,期望进一步提高肾脏与肾脏肿瘤的分割精度,更好地辅助医生制定肾脏肿瘤患者的手术计划。

【参考文献】

[1] Motzer RJ, Bander NH, Nanus DM. Renal-cell carcinoma[J]. New Engl J Med, 1996, 335(12): 865-875.

[2] Cairns P. Renal cell carininoa[J]. Cancer Biomark, 2011, 9(1-6): 461.

[3] World Cancer Research Fund. Kidney cancer statistics [EB/OL]. <https://www.wcrf.org/diet-activity-and-cancer/cancer-types/kidney-cancer/>.

[4] Robson CJ. Radical nephrectomy for renal cess cancer carcinoma[J]. J Urology, 1963, 89(1): 37-42.

[5] Campbell S, Uzzo RG, Allaf ME, et al. Renal mass and localized renal cancer: AUA guideline[J]. J Urology, 2017, 198(3): 520-529.

[6] 李国清. 基于深度学习的CT图像肾脏分割研究[D]. 南京: 东南大学, 2019.

Li GQ. Research on kidney segmentation of CT images based on deep learning[D]. Nanjing: Southeast University, 2019.

[7] Guo J, Zeng W, Yu S. RAU-Net: U-Net model based on residual and attention for Kidney and Kidney tumor segmentation[C]//2021 IEEE International Conference on Consumer Electronics and Computer Engineering. IEEE, 2021: 353-356.

[8] Ruan Y, Li D, Marshall H, et al. MB-FSGAN: joint segmentation and

quantification of kidney tmor on CT by the mulit-branch feature sharing generative adversarial network[J]. Med Image Anal, 2020, 64: 101721.

[9] 谢鹏鹤. 图像阈值分割算法研究[D]. 湘潭: 湘潭大学物理电子学, 2012.

Xie PH. Research on image threshold segmentation algorithm [D]. Xiangtan: Physical Electronics of Xiangtan University, 2012.

[10] 陆剑锋, 林海, 潘志庚. 自适应区域生长算法在医学图像分割中的应用[J]. 计算机辅助设计与图形学学报, 2005, 17(10): 2168-2173.

Lu JF, Lin H, Pan ZG. Application of adaptive region growth algorithm in medical image segmentation[J]. Journal of Computer Aided Design and Graphics, 2005, 17(10): 2168-2173.

[11] 张博. 基于边缘检测的细胞图像分割方法研究与实现[D]. 武汉: 武汉理工大学, 2006.

Zhang B. Research and implementation of cell image segmentation method based on edge detection [D]. Wuhan: Wuhan University of Technology, 2006.

[12] 程帅. 区域分裂合并并在图像分割中的应用[J]. 福建电脑, 2013, 96(6): 105-205.

Cheng S. The application of region splitting and merging in image segmentation[J]. Fujian Computer, 2013, 96(6): 105-205.

[13] Lee HS, Hong H, Kim J. Detection and segmentation of small renal masses in contrast-enhance CT images using texture and context feature classification[C]//2017 IEEE14th International Symposium on Biomedical Imaging (ISBI), 2017: 583-586.

[14] 高岩, 王博亮. 一种基于CT图像的肾脏肿瘤分割算法[J]. 中国数字医学, 2016, 11(3): 81-82.

Gao Y, Wang BL. A segmentation algorithm for kidney tumors based on CT images[J]. China Digital Medicine, 2016, 11(3): 81-82.

[15] Abraham N, Khan V. A novel focal twwesky loss function with improved attention U-Net for lesion segmentation[M]. Venice: ISBI, 2019.

[16] Setio AA, Ciompi F, Litjens G, et al. Pulmonary nodule detection in CT Images: false positive reduction using multi-view convolutional networks[J]. IEEE Trans Med Imaging, 2016, 35(5): 1160-1169.

[17] 初莹莹. 基于深度学习的肾脏肿瘤分割算法研究[D]. 济南: 山东大学, 2021.

Chu YY. Research on kidney tumor segmentation algorithm based on deep learning[D]. Jinan: Shandong University, 2021.

[18] Hatt H, Laurent B, Ouahabi A, et al. The first MICCAI challenge on PET tumor segmentation using 3D-patch-based deep convolutional network[J]. Sci Rep-UK, 2020, 10(1): 1-9.

[19] Heller N, Isensee F, Maier-Hein KH. The state of the art in kidney and kidney tumor segmentation in contrast-enhanced ct imaging: results of the kits19 challenge[J]. Med Image Anal, 2021, 67(9): 821-830.

[20] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with convolutional neural networks[J]. Commun Acn, 2017, 60(6): 84-90.

[21] 潘章. SCnet分割肾脏及肿瘤[D]. 南京: 东南大学, 2019.

Pan Q. SCnet segmentation of kidney and tumor[D]. Nanjing: Southeast University, 2019.

[22] Zhao H, Shi J, Qi X, et al. Pyramid scene parsing network[C]//Proceedings of the IEEE Conference on Computer Vision and Patten Recognition, 2017: 2881-2890.

[23] Long L, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Trans Pattern Anal, 2015, 39(4): 640-651.

[24] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[J]. Lect Notes Comput Sci, 2015, 9351: 234-241.

[25] Fabian I, Jens P, Andre K, et al. nnU-Net: self-adapting framework for U-Net-based medical image segmentation[C]//Workshop on Bildverarbeitung fur die Medizin. 2019.

(编辑:陈丽霞)