

DOI: 10.19650/j.cnki.cjsi.J2108756

基于 RA-Unet 的 CT 图像肝脏肿瘤分割*

邱拴虎¹, 杨文瀚², 廖 苗², 赵于前¹, 杨 振¹

(1. 中南大学自动化学院 长沙 410083; 2. 湖南科技大学计算机科学与工程学院 湘潭 411100)

摘 要:CT 图像肝脏肿瘤分割是进行肝癌前期诊断、肿瘤负荷分析和放射治疗的重要前提。为实现肿瘤的精确自动分割,提出一种融合残差模块和注意力机制的深度 U 形网络。该网络首先在跳跃连接层中引入一条带有反卷积与激活操作的残差路径和卷积模块,实现图像特征的分离传递以及高级表征,确保跳跃连接层主要传递图像边缘信息和小目标全局信息,其次在解码路径中引入注意力机制,通过将跳跃连接层与反卷积解码获得的特征信息赋予不同权重,进一步增强肿瘤特征,抑制其他无关信息。提出方法在 LiTS 数据集上获得的全局 Dice 值高达 86.71%,明显高于其他多种现有方法,且相较于其他方法,该方法对于小尺寸、对比度低、边界模糊的肿瘤具有明显的分割优势。

关键词:医学图像分割;深度学习;残差模块;注意力机制;肝脏肿瘤

中图分类号: TP391.41 TH89 **文献标识码:** A **国家标准学科分类代码:** 520.60

Liver tumor segmentation from CT images based on RA-Unet

Di Shuanhu¹, Yang Wenhan², Liao Miao², Zhao Yuqian¹, Yang Zhen¹

(1. School of Automation, Central South University, Changsha 410083, China; 2. School of Computer Science and Engineering, Hunan University of Science and Technology, Xiangtan 411100, China)

Abstract: Liver tumor segmentation from CT image is an important prerequisite for early diagnosis, tumor burden analysis, and radiotherapy of liver cancer. To segment tumors accurately and automatically, a deep U-shaped network based on the residual block and attention mechanism is proposed. In this network, a residual path with deconvolution and activation operations together with a convolution module is first introduced in the skip connection to separate image features and obtain their high-level representation, which ensures that the skip connections mainly transmit the information of image edges and global information of small targets. Then, the attention mechanism is introduced in the decoding path to further enhance tumor feature and suppress irrelevant information by assigning different weights to the feature information obtained by skip connections and deconvolution decoding. The global Dice coefficient achieved by the proposed method on LiTS dataset is as high as 86.71%, which is obviously higher than many other existing methods. Compared with other methods, the proposed method has obvious advantages in segmenting tumors with small size, low contrast, and blurred boundaries.

Keywords: medical image segmentation; deep learning; residual block; attention mechanism; liver tumor

0 引 言

肝癌是世界范围内最常见的恶性肿瘤之一。据国家癌症中心数据显示,我国肝癌发病率在所有恶性肿瘤中排第 5,且死亡率高居第 2 位^[1]。随着现代肿瘤医学技术的飞速发展,放射治疗进入了以图像引导和自适应放疗为代表的精准放疗阶段。精准放疗需要准确把握放射治疗的

靶区,即肿瘤区域,进而为后续治疗与放射方案提供引导。计算机层析成像(computed tomography, CT)是目前针对肝脏病变普遍采用的诊断方式。鉴于肝脏肿瘤在 CT 图像上的表现具有高变异性,且与周围组织对比度低、存在个体差异等问题,目前临床上肿瘤区域的分割主要由有经验的医师手工勾画完成,不仅费时费力,且其准确性严重依赖于医师的经验与技巧。因此研究高效准确的肝脏肿瘤自动分割方法对肝癌的临床诊断与治疗具有重要意义。

收稿日期:2021-10-23 Received Date: 2021-10-23

* 基金项目:国家自然科学基金(62272161,62076256)、湖南省自然科学基金(2021JJ30275)、湖南省教育厅资助科研项目(20B239)资助

CT 图像中肝脏肿瘤通常具有对比度低,边界模糊,形状、大小、数目不固定等特点。传统分割方法,如聚类^[2]、区域生长^[3]、水平集^[4]、图割^[5]、活动轮廓模型^[6]等,难以有效适应肝脏肿瘤的复杂性和多样性。此外,该类方法通常需要人工干预,无法实现肿瘤区域的自动分割。近年来,深度学习由于具有学习能力强、适应性好等优点,被广泛应用于医学图像分割领域^[7-8]。Ronneberger 等^[9]首次将跳跃连接引入卷积神经网络,提出了一种 U 形网络(Unet)。Liu 等^[10]提出了一种基于深层 Unet 和图割的腹部 CT 序列肝脏肿瘤分割方法,该方法通过增加 Unet 的网络深度提取更高层次的特征,并利用图割算法平滑分割结果,提高分割准确度。Li 等^[11]提出了一种瓶颈监督的 Unet 模型(bottleneck supervised Unet, BS-Unet)。该模型是一种混合的紧密连接结构,通过充分利用网络各层之间的信息进行分割。该网络在肝脏和肿瘤上的分割精度分别为 96.2% 与 75.1%。Schlemper 等^[12]将注意力机制融入 Unet 分割框架中,提出 A-Unet (attention unet) 模型。该模型可自动学习与分割任务相关的区域特征,抑制不相关特征,但同时易导致边界分割不精确,小肿瘤难以检出等问题。Zhou 等^[13]对 Unet 的跳跃连接层进行了修改,通过连通所有层的跳跃连接,构建了一种多尺度的 Unet 网络(Unet++),其优点在于可以通过叠加的方式提取、融合不同层次的特征。Yang 等^[14]将 Unet++ 应用于 CT 图像的肝脏及肿瘤分割,并在网络中引入了残差结构有效解决了训练过程中梯度弥散或消失的问题。Huang 等^[15]在文献[14]的基础上,引入了全尺度的跳跃连接和深度监督机制提出 Unet3+网络。该网络可在一定程度上提高小肿瘤的检出率,但仍无法解决肝脏肿瘤边界模糊引起的分割精度低,以及数据类别不平衡造成的肿瘤分割困难等问题。

针对上述方法存在的缺点与不足,本文提出了一种融合残差模块和注意力机制的深度 U 形网络(residual block and attention mechanism based Unet, RA-Unet),并将其成功应用于腹部 CT 图像肝脏肿瘤的精

确自动分割。RA-Unet 利用残差原理与注意力机制构建网络的跳跃连接层和解码层,并通过采用混合损失函数,提升了网络对于小尺寸和边界模糊的肿瘤目标的分割精度。

1 本文方法

1.1 数据预处理

本文采用 MICCAI 2017 肝脏肿瘤分割挑战赛提供的 LiTS 数据集^[16]作为实验数据。该数据集包含 131 个病例,共 58 638 幅 CT 切片图像,图像大小为 512×512,其中的肝脏和肿瘤区域均由放射科医生手动标注,作为分割金标准。CT 图像中肿瘤区域占比较小,且与其他组织器官缺乏良好的灰度对比,直接分割往往精度较低。为了降低肿瘤分割的复杂性、提高分割精度,首先对原始 CT 图像进行裁剪与窗位、窗宽调整等预处理。

根据解剖学先验,肝脏通常位于人体腹腔右部。在 CT 断层扫描中,肝脏区域主要出现在横切面视角成像图像的腹腔左侧,如图 1(a)所示。为了获取包含完整肝脏的感兴趣区域、去除不相关组织器官的干扰,需对 CT 图像进行裁剪。首先,采用阈值和数学形态学方法^[17]对 CT 图像中的肋骨和脊椎进行分割,得到结果如图 1(b)所示。然后,对分割结果进行行和列投影,且分别取第 1 个以及最后一个不为 0 的像素所在的行和列,构建长为 L_w 、宽为 L_h 的矩形框,定位腹腔区域如图 1(c)所示。考虑到肝脏区域通常位于 CT 切片腹腔左侧,将矩形框中心点 O 向左平移 $L_w/4$ 得到点 P ,并以点 P 为中心取大小 320×320 的方形区域作为最终的裁剪结果。最后对裁剪区域图像的窗位与窗宽进行调整。根据放射医学先验知识,可显示的人体组织 CT 值范围一般为-1 000~1 000 Hu,而肝、脾、肾、肌肉等器官软组织的 CT 值范围通常在 40~70 Hu。为了增强肝脏与毗邻组织的对比度,本文将 CT 图像的窗位和窗宽分别设置为 60 和 170 Hu,即可得到预处理图像如图 1(d)所示。




图 1 数据预处理

Fig. 1 Data pre-processing

1.2 RA-Unet 网络结构

Unet 是一种广泛应用于医学图像分割的 U 形卷积神经网络。该网络通过编码-解码操作实现图像端到端的语义分割,已经成为图像分割的一种标准框架。Unet 利用跳跃连接层将高分辨率的浅层特征与解码阶段提取到的深层特征进行连接,通过利用高分辨率的浅层信息帮助获取编码阶段丢失的空间信息。该操作的缺陷在于编码部分的特征既直接通过跳跃连接也间接通过编码-解码方式传递到解码部分,存在信息的冗余传递。不同传递方式也会在特征融合时增加特征的不确定性,导致目标边缘分割不准确、小目标检出率低。此外,编码阶段生成的高分辨率浅层特征,其边缘信息的高级特征表征不够充分,通过跳跃连接直接传递至解码端易造成特征映射模糊,目标分割精度低。

针对上述 Unet 网络存在的不足,本文将残差模块、卷积层引入跳跃连接层,并在解码路径增加注意力机制,

提出 RA-Unet 网络模型如图 2 所示。RA-Unet 沿用 Unet 的 U 形网络框架,从上到下依次分成 5 个阶段,从左到右包含编码路径、跳跃连接、解码路径 3 部分。编码路径由 5 个双卷积模块组成,每个卷积模块包含 1 个大小为 3×3 的卷积层,批归一化层,与 ReLU 激活层。此外,每个双卷积模块末尾包含 1 个大小为 2×2 的最大池化层。解码路径包含 4 个与编码路径类似的双卷积模块,其区别在于每个双卷积模块起始部分包含一个大小为 2×2 的反卷积层,以及一个注意力结构。该注意力结构包括:首先,分别对跳跃连接以及反卷积解码传递的特征图进行 1×1 的卷积操作并相加。然后,依次经过 ReLU 激活层和 1×1 的卷积层,再利用 Sigmoid 函数激活生成一个权重图。最后,将跳跃连接层的特征图与该权重图相乘得到一个新的特征图。该注意力结构的主要作用是根据上下文信息,将跳跃连接与反卷积解码获得的特征信息赋予不同权重,以此增强分割任务相关区域的特征,抑制无关区域特征。




图 2 RA-Unet 网络模型

Fig. 2 Network module of RA-Unet

为了避免信息冗余传递,RA-Unet 在跳跃连接层中增加了一条带有反卷积与 ReLU 激活层的残差路径。其中,反卷积的大小、步幅与填充度均与同阶段解码部分反卷积相同。RA-Unet 通过增加一条带有反卷积与激活操作的残差路径,可使网络学习经池化-反卷积后的特征图与原浅层特征图之间的残差。引入该残差路径可突出表征大目标的边缘特征与小目标的全局特征,解决 Unet 信息冗余传递问题。此外,RA-Unet 的跳跃连接层中还增加了一个双卷积模块,可对边缘特征与小目标的全局特征进行更深层次地提取与表征。

1.3 损失函数

对于类不平衡的分割问题,通常利用 Dice 系数构建网络训练中的损失函数:

$$Dice_loss = 1 - \frac{2 \times \sum_{i=1}^N G_i P_i}{\sum_{i=1}^N G_i + \sum_{i=1}^N P_i} \quad (1)$$

式中: G_i 为 CT 图像中第 i 个像素的专家手动分割结果

(背景标记为 0,目标标记为 1); P_i 为网络预测第 i 个像素属于目标的概率; N 为 CT 图像中的像素数目。Dice 损失函数关注的是预测结果与金标准的相似程度,在训练过程中通过最大化网络预测结果的 Dice 系数,使预测结果尽可能逼近金标准。然而,当目标区域过小时,目标区域预测结果的微小变化易造成 $Dice_loss$ 值剧烈波动,从而导致整个训练过程不稳定。二元交叉熵(binary cross entropy, BCE)损失函数关注图像中每个像素类别的预测概率,其值是背景区域和目标区域中所有像素交叉熵的平均:

$$BCE_loss = -\frac{1}{N} \sum_{i=1}^N (G_i \log(P_i) + (1 - G_i) \log(1 - P_i)) \quad (2)$$

当目标区域过小时,网络预测结果的微小变化对交叉熵损失值影响较小,可有效弥补 Dice 损失函数的不足。本文充分考虑两种损失函数的特点,提出一种混合损失函数:

$$Loss = \alpha \cdot BCE_loss + (1 - \alpha) \cdot Dice_loss \quad (3)$$

式中: α 为权重因子, 取值范围为 $0 \sim 1$, 用于调节 $Dice_loss$ 和 BCE_loss 损失值所占比重。此外, 为了加快模型收敛, 避免过拟合, 网络在训练过程中采用了批量归一化、dropout 和权值衰减机制。

2 实验结果与分析

2.1 数据集

采用 LiTS 公共数据集^[16]对提出算法进行验证。该数据集共包含 58 638 幅 512×512 的腹部 CT 图像, 其中, CT 图像的帧内分辨率为 $0.55 \sim 1.00$ mm, 帧间分辨率为 $0.45 \sim 6.00$ mm。本文从 LiTS 公共数据集中选取包含肝脏区域的 7 183 幅 CT 图像作为实验数据集, 其中训练集、验证集和测试集的比例设置为 $8:1:1$ 。为了提高图像对比度、突出肿瘤区域, 采用 1.1 节所述方法对数据集中所有图像进行预处理, 并利用预处理后的数据进行训练与测试。

2.2 实验环境与参数设置

本文实验训练环境为装有 Win 10 操作系统、AMD Ryzen 5900X 处理器, 32 GB 内存和 GeForce RTX 3080GPU 的计算平台。编程语言为 Python, 深度学习框架为 Pytorch。RA-Unet 模型训练采用 Adam 优化算法, 学习率 10^{-4} , 一阶矩的指数衰减率为 0.9, 二阶矩的指数衰减率为 0.999, 用于维持数值稳定的常数为 1×10^{-8} , 权重衰减为 10^{-6} 。为了避免过拟合, 网络训练过程中采用 Dropout 策略, 其值设置为 0.5。epoch 和 batchsize 分别设置为 150 和 6。

2.3 评价指标

为了定量评价网络分割性能, 本文使用了 5 种常用的评价指标, 包括 Dice 相似系数, 体积重叠误差 (volumetric overlap error, VOE), 相对体积差异 (relative volume difference, RVD), 平均表面距离 (average surface distance, ASD) 和最大对称表面距离 (maximum symmetric surface distance, MSSD)。

Dice 系数是应用最广泛的医学图像分割评价指标之一, 用于计算分割结果 A 与金标准 B 之间的重叠指数:

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \times 100\% \quad (4)$$

式中: $|\cdot|$ 表示求给定区域的像素数目; $Dice$ 取值范围为 $[0, 1]$ 。

VOE 为体积重叠误差, 与 Dice 系数相反, 其值越小表明算法分割性能越好, 计算公式如下:

$$VOE = 1 - \frac{|A \cap B|}{|A \cup B|} \times 100\% \quad (5)$$

RVD 用于衡量分割结果与金标准的相对体积差:

$$RVD = \frac{|B| - |A|}{|A|} \times 100\% \quad (6)$$

RVD 正、负值表明算法倾向于欠分割或过分割。

ASD 和 MSSD 分别表示分割结果与金标准之间的平均表面距离和最大对称表面距离:

$$ASD = \frac{1}{|S(A)| + |S(B)|} \times \left(\sum_{I_A \in S(A)} D(I_A, S(B)) + \sum_{I_B \in S(B)} D(I_B, S(A)) \right) \quad (7)$$

$$MSSD = \max_{I_A \in S(A)} D(I_A, S(B)), \max_{I_B \in S(B)} D(I_B, S(A)) \quad (8)$$

式中: $S(\cdot)$ 表示指定区域的表面像素; $d(p, S(\cdot))$ 表示像素 p 到 $S(\cdot)$ 的欧氏距离。ASD 和 MSSD 值越小表明算法分割性能越好。

2.4 结果与分析

1) RA-Unet 中间层特征的可视化分析

为了证实提出模型的有效性, 将 RA-Unet 与 Unet 中间层的特征提取结果进行比较。RA-Unet 与 Unet 各阶段跳跃连接层中部分特征图可视化对比如图 3 所示。RA-Unet 跳跃连接层引入了残差和卷积结构, 可对图像特征进行分离及高级表征。从图 3 可以看到, RA-Unet 各阶段均可有效提取图像中大目标的边缘与小目标的全局信息, 避免冗余信息的重复传递。而 Unet 编码路径中的高分辨率浅层信息既通过跳跃连接直接传递至解码路径, 同时也通过下采样传递至下一阶段进行编码与解码。该操作易造成小目标信息丢失、图像高维特征表征不充分, 以及信息重复传递等问题。从图 3 还可以看出, Unet 相邻阶段之间存在大量冗余无关信息的重复传递, 肿瘤特征提取不明显。由于多次下采样 (即池化), Unet 第 3~4 阶段跳跃连接层中小肿瘤信息已完全丢失, 而 RA-Unet 通过信息分离传递机制, 能有效获取大目标边缘及小目标全局特征。




图3 RA-Unet 与 Unet 跳跃连接层中特征图可视化对比示例

Fig. 3 Visualization comparison of feature maps of skip connection layer in RA-Unet and Unet

RA-Unet 与 Unet 各阶段解码路径部分特征图的可视化对比如图 4 所示。可以明显看出,随着特征的上采样和融合,肿瘤特征逐渐清晰。相较于 Unet,RA-Unet 在各阶段均能提取更完整、准确的肿瘤特征。此外,从图 4 中 1×1 卷积后的概率图可以看到,RA-Unet 最后得到的概率图中肿瘤区域均被有效检测,而 Unet 仅能检测部分大肿瘤。表明,RA-Unet 在解码路径中通过采用注意力机制,可有效增强跳跃连接层中边缘信息与小目标全局信息,抑制无关信息与噪声。




图 4 RA-Unet 与 Unet 解码路径中特征图可视化对比示例

Fig. 4 Visualization comparison of feature maps in decoding path of RA-Unet and Unet

2) 损失函数对分割精度的影响

为了测试损失函数对分割精度的影响,本文对损失函数中的权重因子 α 进行了讨论。图 5 所示为采用从 0~1 步长为 0.1 的一系列 α 值进行实验,得到的测试结果 Dice 系数值。可以看到,当 α 取值为 0 时,即仅采用 Dice 作为损失函数时,测试 Dice 系数值仅为 83.14%。随着 α 的增加,测试 Dice 值快速升高,表明通过结合 Dice 和二元交叉熵损失函数可有效提高网络的分割精度,且当 α 的值为 0.8 时,测试 Dice 值达到最大值 86.71%。因此,本文实验将权重 α 设置为 0.8。权重 α 为 0.8 网络训练过程中 Loss 值随训练轮数 (epoch) 的变

化趋势如图 6 所示。可以看到,随着训练轮数的增加,训练集和验证集上的 Loss 值均快速下降,并在训练轮数大于 50 时收敛,且趋近于 0。




图 5 Dice 系数随权重因子变化趋势

Fig. 5 Trend of Dice coefficient with weighting factor




图 6 训练过程中 Loss 随训练轮数的变化趋势

Fig. 6 Trend of Loss with epoch during training

3) 消融实验

RA-Unet 模型将残差路径和卷积层引入跳跃连接层,并在解码路径增加了注意力模块。为了验证每个模块对分割性能的影响,本文以 Unet 为基准,进行了大量消融实验,结果如表 1 所示。可以看到,采用经典 Unet 进行肿瘤分割,全局 Dice 值仅为 78.24%。而采用“Unet+残差模块”、“Unet+注意力机制”和“Unet+卷积层”模型

表 1 不同模块消融实验对比结果

Table 1 Comparison results of ablation experiments on different modules					
模型	Dice(全局)/%	VOE/%	RVD/%	ASD/mm	MSSD/mm
Unet	78.24	29.32	-13.11	3.49	17.73
Unet+残差模块	82.15	25.27	-12.42	2.62	13.25
Unet+注意力机制	83.92	24.89	-11.41	2.39	12.92
Unet+卷积层	84.51	24.35	-7.02	2.03	11.64
Unet+残差模块+卷积层	85.82	23.88	-6.44	1.89	10.94
RA-Unet(Unet+残差模块+卷积层+注意力机制)	86.71	23.23	-5.01	1.54	10.01

进行实验全局 Dice 值分别上升至 82.15%、83.92% 和 84.51%，同时均可获得相对较小的 VOE、RVD、ASD 和 MSSD。表明 RA-Unet 模型中每个新增模块均能有效改善模型性能、提升分割精度。此外，相较于 Unet 和其他组合模型，RA-Unet 模型通过融合残差、卷积和注意力模块可获得最高 Dice 系数值和最低 VOE、RVD、ASD 和 MSSD 等误差指标。

4) 实验结果比较

测试集中部分切片分割结果如图 7 所示，其中图 7(a)为原始 CT 图像，图 7(b)~(g) 分别为采用 Unet^[9]、BS-Unet^[11]、A-Unet^[12]、Unet++^[13]、Unet3+^[15] 和本文方法(RA-Unet)得到的肿瘤分割结果，图 7(h)为专家手动分割的金标准。从图 7 可以看出，Unet、BS-Unet、

A-Unet、Unet++和 Unet3+均可大致检测肿瘤区域，但对于边界模糊，尺寸较小的肿瘤，存在欠分割和漏检现象。而 RA-Unet 通过特征信息分离传递可有效补偿池化操作造成的目标信息损失，可以精确提取分割目标的边缘，分割结果明显优于其他方法。采用不同方法在 LiTS 数据库上进行测试，运用 Dice、VOE、RVD、ASD 和 MSSD 对分割结果进行评价，得到的定量分析结果如表 2 所示。从表 2 可以看到，采用本文方法得到的所有评价指标均优于其他方法。本文方法取得的 Dice 系数相比 Unet、BS-Unet、A-Unet、Unet++和 Unet3+分别提高了 8.47%、5.82%、2.79%、1.29%和 1.1%。表明提出方法通过引入带有反卷积与激活函数的残差模块和注意力机制，可有效提升肿瘤分割的精度。




图 7 不同算法分割结果

Fig. 7 Segmentation results obtained by different methods

5) 国内临床数据集分割结果

为了进一步验证提出方法的有效性，本文对中南大学湘雅医院提供的 10 名原发性肝癌患者的 CT 序列图像进行了测试。部分切片的可视化分割结果如图 8 所示，其中图 8(a)为原始 CT 图像，图 8(b)为其对应的分割结果，阴影区域为本文方法结果，边缘曲线所示区域为专家手动分割结果。从图 8 可以看出，本文方法可有效分割形状复杂、边界模糊、对比度低的肿瘤，分割结果与专家

手动分割结果接近。采用多个评价指标，对 10 名肝癌患者 CT 序列图像分割结果进行定量评价与统计，得到的结果如表 3 所示。本文方法获得的全局 Dice、VOE、RVD、ASD 和 MSSD 分别为 86.14%、23.80%、-6.53%、1.62 和 9.69 mm，与 LiTS 公开数据集上获得的分割性能相当，表明本文方法在国外公共数据集和国内本地临床数据集上均可实现肝脏肿瘤的有效分割，取得令人满意的分割结果，方法鲁棒性强，精度高。

表 2 不同方法的分割性能比较

Table 2 Comparison of segmentation performance among different methods

方法	Dice (全局)/%	VOE /%	RVD /%	ASD /mm	MSSD /mm
Unet ^[9]	78.24	29.32	-13.11	3.49	17.73
BS-Unet ^[11]	80.89	26.31	-12.21	3.21	15.54
A-Unet ^[12]	83.92	24.89	-11.41	2.39	12.92
Unet++ ^[13]	85.42	24.55	-6.99	1.66	10.23
Unet3+ ^[15]	85.61	24.12	-6.38	1.61	10.13
本文	86.71	23.23	-5.01	1.54	10.01




图 8 本文方法在国内临床数据集上的分割结果示例

Fig. 8 Examples of segmentation results obtained by the proposed method on domestic clinical data sets

表 3 本文方法在国内临床数据集上的分割性能

Table 3 Segmentation performance of the proposed method on domestic clinical data sets

方法	Dice (全局)/%	VOE /%	RVD /%	ASD /mm	MSSD /mm
本文方法	86.14	23.80	-6.53	1.62	9.69

3 结 论

针对肝脏肿瘤对比度低、边界模糊、大小不一等特点,提出了一种基于 RA-Unet 的 CT 图像肝脏肿瘤分割方法。

RA-Unet 通过将带有反卷积与激活函数的残差模块引入到跳跃连接层中,可有效解决 Unet 中由特征信息冗余传递导致的肿瘤分割精度低、小肿瘤无法检出的问题;在跳跃连接层中增加卷积层,可增强跳跃连接层中信息的高级特征表征能力,同时利用注意力机制,可使网络专

注传递肿瘤特征,抑制其他无关信息;采用二元交叉熵与 Dice 系数构建混合损失函数,不仅可通过 Dice 系数有效表征目标与金标准的相似程度,还可通过交叉熵稳定回传各个类别对应梯度使网络模型快速收敛。为验证方法的有效性,在 LiTS 临床数据集上进行了大量实验。结果表明,提出模型可对图像特征进行分离,避免不相关信息冗余重复传递,且肿瘤分割精度达到 86.71%,显著高于其他多种网络模型,尤其对于小肿瘤的分割具有明显优势。

CT 序列图像中肝脏肿瘤组织的准确分割是肝脏肿瘤负荷分析的重要前提,也是肝脏疾病诊断、放射治疗和手术方案制定的重要基础。临床医师可根据 CT 序列图像中肝脏肿瘤的分割结果,获取病人病灶的数量、大小、形状、位置、病变程度、浸润深度、转移与否等信息,对疾病进行诊断、制定适当的治疗方案。在今后的工作中,可将本文提出的分割模型集成部署在相关医学影像勾画平台,以提升计算机辅助诊疗的精度和效率。

参考文献

[1] ZHANG S W, SUN K X, ZHENG R S, et al. Cancer incidence and mortality in China, 2015[J]. Journal of the National Cancer Center, 2021, 1(1): 2-11.

[2] 黄化入, 谢维成, 张彼德, 等. 基于改进 PCM 聚类方法的绝缘子图像分割[J]. 电子测量与仪器学报, 2020, 34(12): 181-189.

HUANG H R, XIE W CH, ZHANG B D, et al. Segmentation method of insulator disk based on improved PCM[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(12): 181-189.

[3] 刘莹, 李筠, 杨海马, 等. 结合区域生长与水平集算法的宫颈癌图像分割[J]. 电子测量与仪器学报, 2020, 34(9): 146-152.

LIU Y, LI J, YANG H M, et al. Cervical cancer image segmentation based on region growth and level set algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(9): 146-152.

[4] 张永德, 彭景春, 刘罡, 等. 基于水平集的前列腺共振图像分割方法研究[J]. 仪器仪表学报, 2017, 38(2): 416-424.

ZHANG Y D, PENG J CH, LIU G, et al. Research on the segmentation method of prostate magnetic resonance image based on level set[J]. Chinese Journal of Scientific Instrument, 2017, 38(2): 416-424.

[5] YANG Z, ZHAO Y, LIAO M, et al. Semi-automatic liver tumor segmentation with adaptive region growing and graph cuts[J]. Biomedical Signal Processing and Control, 2021, 68: 102670.

[6] AMINA T, LAKHDAR L, HAKIM B, et al. Improved

- active contour model through automatic initialisation; Liver segmentation [C]. Proceedings of the IEEE International Maghreb Meeting of the Conference on Sciences and Techniques of Automatic Control and Computer Engineering MI-STA, 2021: 771-775.
- [7] 钟思华, 王梦璐, 郭兴明, 等. 基于改进 VNet 的肺结节分割方法研究[J]. 仪器仪表学报, 2020, 41(9): 206-215.
- ZHONG S H, WANG M L, GUO X M, et al. Study on the improved VNet network based pulmonary nodule segmentation method [J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 206-215.
- [8] 张文秀, 朱振才, 张永合, 等. 基于残差块和注意力机制的细胞图像分割方法[J]. 光学学报, 2020, 40(17): 76-83.
- ZHANG W X, ZHU ZH C, ZHANG Y H, et al. Cell image segmentation method based on residual block and attention mechanism [J]. Acta Optica Sinica, 2020, 40(17): 76-83.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]. Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.
- [10] LIU Z, SONG Y, SHENG V, et al. Liver CT sequence segmentation based with improved U-Net and graph cut [J]. Expert Systems with Applications, 2019, 126: 54-63.
- [11] LI S, TSO G, HE K. Bottleneck feature supervised U-Net for pixel-wise liver and tumor Segmentation [J]. Expert Systems with Applications, 2019, 145: 113131.
- [12] SCHLEMPER J, OKTAY O, SCHAAP M, et al. Attention gated networks: Learning to leverage salient regions in medical images [J]. Medical Image Analysis, 2019, 53: 197-207.
- [13] ZHOU Z, SIDDIQUEE M M R, TAJBAKHS N, et al. UNet++: A nested U-Net architecture for medical image segmentation [C]. Proceedings of the International Workshop on Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, 2018: 3-11.
- [14] YANG D, XU D, ZHOU S K, et al. Automatic liver segmentation using an adversarial image-to-image network [C]. Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, 2017: 507-515.
- [15] HUANG H, LIN L, TONG R, et al. UNet 3+: A full-scale connected UNet for medical image segmentation [C]. Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing, 2020: 1055-1059.
- [16] ALOM M Z, YAKOPCIC C, HASAN M, et al. Recurrent residual U-Net for medical image segmentation [J]. Journal of Medical Imaging, 2019, 6(1): 014006.
- [17] SELVER M A, KOCAOGLU A, DEMIR G K, et al. Patient oriented and robust automatic liver segmentation for pre-evaluation of liver transplantation [J]. Computers in Biology and Medicine, 2008, 38(7): 765-784.

作者简介



邸拴虎, 分别在 2010 年和 2013 年于中南大学获得学士学位和硕士学位, 现为中南大学博士研究生, 主要研究方向为医学图像处理。

E-mail: dish0304@163.com

Di Shuanhu received his B. Sc. degree and M. Sc. degree both from Central South University in 2010 and 2013, respectively. He is currently a Ph. D. candidate at Central South University. His main research interest is medical image processing.



廖苗(通信作者), 分别在 2010 年、2013 年和 2016 年于中南大学获得学士学位、硕士学位和博士学位, 现为湖南科技大学副教授, 主要研究方向为图像处理与模式识别。

E-mail: liaomiaohi@163.com

Liao Miao (Corresponding author) received her B. Sc. degree, M. Sc. degree, and Ph. D. degree all from Central South University in 2010, 2013, and 2016, respectively. She is currently an associate professor at Hunan University of Science and Technology. Her main research interests include image processing and pattern recognition.