

doi: 10.3969/j.issn.1674-1242.2025.05.001

改进的 RA-U-Net 模型用于 CT 图像的肝脏肿瘤分割

杜文杰^{1,2}, 王远军²

(1. 上海中侨职业技术大学, 上海 201514; 2. 上海理工大学健康科学与工程学院, 上海 200093)

【摘要】 肝脏 CT 成像是肝脏肿瘤检查的主要影像学手段, 肝脏肿瘤的大小、形状、位置等个体差异较大, 病灶组织区域的灰度特征复杂, 导致肝脏肿瘤图像分割十分困难。基于深度学习的 U-Net 在医学图像分割方面已取得很多进展, 因此该研究拟在 U-Net 的基础上, 针对肝脏肿瘤分割的特点进行改进, 建立一种用于肝脏肿瘤分割的方法。针对肝脏肿瘤分割中存在的问题, 在 U-Net 的基础上, 引入残差模块和注意力机制对 U-Net 进行改进, 在特征学习方面采用组归一化策略对特征图进行通道划分, 以提高深层网络的学习能力, 提高模型的泛化能力。该研究在 CodaLab 提供的 LiTS2017 肝脏肿瘤图像分割挑战数据集上测试了该分割网络, 结果显示 Dice 系数达到 0.773, 高于其他图像分割网络, 精确值达到 0.983, 召回率为 0.637, 结果表明 RA-U-Net 模型分割图像的效果更好, 为肝脏肿瘤临床诊断提供了可靠的依据。

【关键词】 RA-U-Net; 残差模块; 注意力机制; CT 图像分割

【中图分类号】 O242.41, R814

【文献标志码】 A

文章编号: 1674-1242 (2025) 05-0599-08

Improved RA-U-Net for Liver Tumor Segmentation of CT Images

DU Wenjie^{1,2}, WANG Yuanjun²

(1. Shanghai Zhongqiao Vocational and Technical University, Shanghai 201514, China; 2. School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

【Abstract】 Liver CT imaging is the main imaging tool for liver tumor examination. Due to the large individual variability of liver tumors in terms of size, shape, and location, and the complexity of grayscale features in the tissue region of the lesion, it is difficult to make image segmentation of liver tumors. U-Net based on deep learning has made a lot of progress in medical image segmentation, so this study intends to establish a method for liver tumor segmentation by improving the characteristics of liver tumor segmentation on the basis of U-Net. Aiming at the problems in liver tumor segmentation, the U-Net segmentation network is improved by introducing the residual module and the attention mechanism, and the group normalization strategy is used to process the feature map along channels for feature learning, so as to improve the learning ability of the network and the generalization ability of the model. In this study, the segmentation network was tested on the LiTS2017 liver tumor image segmentation challenge dataset provided by CodaLab, and the results show that the average Dice coefficient reaches 0.773, which is higher than that of other image segmentation networks, the precision index reaches 0.983, and the recall index is 0.637, which indicates that the RA-U-Net network model is more effective in segmenting images and provides a reliable basis for the clinical diagnosis of liver

收稿日期: 2024-11-05。

作者简介: 杜文杰, 上海中侨职业技术大学教师, 上海理工大学博士生, 专注于医学影像技术分析。王远军, 上海理工大学特聘教授, 博士生导师, 主要从事医学成像与智能医学影像处理方向的教学和科研工作。

tumors.

【Key words】RA-U-Net; Residual Module; Attention Mechanism; CT Image Segmentation

0 引言

肝脏肿瘤的发病率和致死率都很高,目前的治疗方式主要有系统化疗、靶向治疗、生物治疗和手术治疗等,但都需要先明确病灶区域,获取病灶的大小、数量、形状等信息,临床上常用超声、CT、MRI 等影像检查技术^[1]。肝脏肿瘤图像的精确分割能够帮助医生精确了解癌灶的位置、大小及与周围组织、血管的连接,对后续的手术治疗具有重要的临床意义。

随着深度学习被广泛应用于医学图像领域,在 CT 影像上针对肝脏和肝脏肿瘤病灶区域的分割算法不断涌现。尽管目前肝脏的分割精度和效率已经提高了很多,但由于肝脏肿瘤的大小、形状、位置等没有规律,病灶组织区域的灰度也常表现出低密度、不均匀的复杂特性,肝脏肿瘤图像分割十分困难^[2]。因此,肝脏肿瘤图像的分割精度需要继续提高,该问题依然是医学图像分割领域的研究重点和难点。

医学影像分割方法主要包括:①传统分割方法,如区域生长法、阈值法、水平集方法等;②基于机器学习的分割方法,如聚类法、支持向量机、随机森林等;③基于深度学习的分割方法,如全卷积网络(Fully Convolutional Network, FCN)、U-Net 等。FCN 是医学图像分割领域应用最广泛的方法,在 FCN 的基础上又演化出了 U-Net、Deep Lab、Seg Net 等改进网络,而在诸多深度学习网络框架之中,基于 U-Net 的分割研究最多。

基于 U-Net 的分割网络改进策略主要从以下几个方面展开。

首先,在从二维到三维的拓展方面,Cicek 等^[3]提出了 3D U-Net,使用 3D 卷积代替了 2D 卷积,输入和输出都是三维图像,提升了对三维图像的分割能力。在每层加入残差模块,确保网络在深度较深的同时快速收敛。下采样时使用卷积层压缩信息尺寸的同时扩大感受域范围,减少了模型的参数量,加快了训练速度。

其次,在特征增强方面,Oktay 等^[4]提出了

Attention U-Net,在对编码器和解码器中对应的信息进行特征融合前加入注意力门机制,消除无关特征的影响,还通过跳跃连接传递相关特征。Li 等^[5]提出的 CSA U-Net,针对注意力机制模块的结构提出了新的设计方案,有效提高了分割网络的注意力权重。董晓莹等^[6]提出的 BRA U-Net 结合了注意力机制和瓶颈残差机制,可以更好地描述肝脏肿瘤的特征,提高有效特征的比例,同时保证深层网络的性能。

再次,在训练速度方面,Li 等^[7]将 2D Dense Net 和 3D Dense Net 结合起来,提出了 H-Dense U-Net,用 2D 网络的快速结果指导 3D 网络的学习,提高了模型的运算速度。Robin 等^[8]提出了 Partially Reversible U-Net,通过在编码器和解码器的每个执行单元中使用可逆序列节省内存。Li 等^[9]提出了 BSU-Net,降低了分割结果中假阳性和假阴性的占比。

最后,在特征融合方面,Gu 等^[10]提出了 CE-Net,在保留 2D 医学影像信息的同时获取了更高层次的信息。Han 等^[11]提出了 2.5D U-Net,融合了三个网络的特征,同时实现了更小的尺寸、更高的分割精度、更低的硬件配置。Ibtehaz 等^[12]提出了 Multi-Res U-Net,通过使用带有残差模块的卷积层代替跳跃连接,将低级特征经过处理后再与高级特征进行融合。Zhou 等^[13]则提出了 U-Net++,使用了密集跳跃连接块和深度监控。

基于以上调研分析,本文从特征增强、训练速度、泛化能力等方面对 U-Net 分割网络进行改进,并结合肝脏肿瘤的分割特点,提出了肝脏分割方法。接下来先介绍分割方法,然后将其用于肝脏肿瘤数据的分割,并对分割实验结果进行分析,最后给出结论。

1 引入残差模块和注意力机制改进的 RA-U-Net 模型

在处理肝脏肿瘤图像分割任务时,会面临以下问题。首先,图像中肝脏肿瘤大小、形状不一,

灰度值呈现出低密度和不均匀的特点, 特征难以提取; 其次, 模型训练速度慢, 对时间成本提出了较高要求; 最后, 对硬件设备有较高要求。鉴于以上问题, 以及 U-Net 网络中存在的不足, 本文受 U-Net、残差模块和注意力机制的启发, 提出了 RA-U-Net 模型。实验结果表明, 该模型在评价指标上表现较好。

1.1 RA-U-Net 模型的基本结构

RA-U-Net 模型通过引入残差模块保证深层网络的训练效果, 并提高训练速度; 通过注意力机制, 关注肝脏肿瘤区域, 提高肝脏肿瘤区域的权重, 并抑制不相关区域的权重, 从而增大有效特征的占比。在深度神经网络中, 为了避免梯度消失、加快模型训练速度, 本模型在构建时选用了组归一化 (Group Normalization, GN) 层, 将特征图的通道划分为几个小组, 以避免受到批大小的限制。

RA-U-Net 模型结构如图 1 所示, RA-U-Net 模型的输入为一张单通道 CT 图像, 通过模型处理后的输出结果为一张对肝脏肿瘤图像进行标记分割的单通道图像。整个网络的编码部分通过 2×2 的最

大池化层对输入进行下采样, 在解码部分通过反卷积进行尺寸扩张, 使输出结果恢复到原来的大小。本文用残差模块代替了原有的卷积层, 并在跳跃连接部分加入了注意力门控 (Attention Gate, AG)。

1.2 归一化操作

深度学习是利用当前获取的数据对未来数据进行预测的方法。要让神经网络更好地预测未来的数据, 使用的历史数据就要具有总体代表性, 因此必须引入归一化操作。如果训练数据的样本分布一致, 就可以提高神经网络的训练速度、加快收敛并提高泛化能力。在图像分割领域, 常用的归一化方法有 GN 和批归一化 (Batch Normalization, BN)。GN 的主要思路是将特征图的通道划分为几个小组, 在每个小组内计算均值和方差, 使其不受批大小的影响。将样本的 C 个特征通道分为 G 组, 每组的特征通道为 C/G 个, 并计算 $C/G \times H \times W$ 个值的均值和方差, G 为超参数, 需要手动设置, 一般为 32。

1.3 残差模块

梯度消失和梯度爆炸问题的发生常常伴随着深层神经网络的反向传播进程。BN 层的出现虽然极

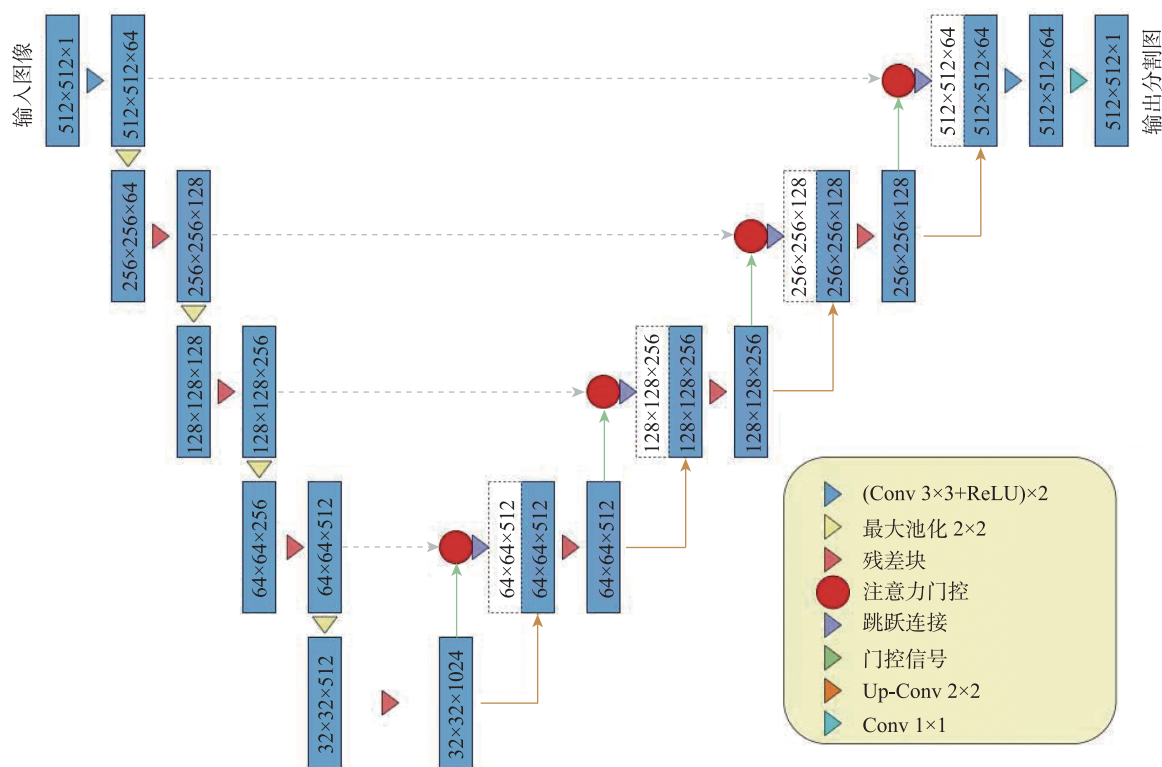


图 1 RA-U-Net 模型结构

Fig.1 RA-U-Net model architecture

大地缓解了这两类问题，却无法解决网络退化问题。当较浅的网络可以满足要求时，如果深层网络中多余的结构能够把浅层网络的结果原样输出（实现恒等映射），则可有效缓解梯度消失和梯度爆炸问题。2015 年，He 等^[14]提出了 ResNet 残差网络，引出了残差思想，从根本上解决了网络退化的问题。在实际应用中，深层网络的计算量巨大，普通的残差模块并不能很好地解决这个问题，于是本模型选用了改进的瓶颈残差模块（见图 2），按照 1×1 卷积单元、 3×3 卷积单元和 1×1 卷积单元的方式进行放置。 1×1 卷积单元可以改变数据的通道数，当数据通道数较大时，先减少通道数，经过 3×3 卷积运算之后，再增加通道数，既降低了计算量，又加快了训练速度。




图 2 瓶颈残差模块
Fig.2 Bottleneck residual module

1.4 注意力机制

注意力机制参考了人类视觉的特点，将其应用于医学图像处理时，可以抑制无关区域，提高目标区域的权重，使信息处理的效率和准确性都得到提升。文献 [2] 提出了注意力门控机制，在提升神经网络模型的灵敏度和预测精度的同时，仍能保持较

少的计算量。因为下层特征所学到的信息更多、更准确，所以在注意力门控结构中将下层特征与上层特征相加。注意力门控结构如图 3 所示。

注意力门控属于一种软注意力机制，在比较复杂的场景中，能够逐步提高局部感兴趣区域的权重，抑制无关区域的活性，应用前景广泛。尽管注意力模块的放置位置没有太多的限制，但考虑到网络收敛速度与改进的便利性，本模型将注意力模块放置在原有 U-Net 神经网络的跳跃连接部分。

1.5 加权损失函数设计

在医学图像处理中，经常出现正负样本不均衡的情况，这一点在肝脏肿瘤图像分割中尤为明显，因为肝脏肿瘤区域往往只占整个图像的很小一部分，而且肝脏肿瘤等医学图像数据集的数据量较少，在处理样本不均衡问题时会更加困难。使用常用的 BCE loss 函数处理这种正负样本不均衡的数据时，往往出现 loss 值下降趋势良好，但最终训练出来的模型分割效果不理想的情况，这是因为在正样本数量远小于负样本数量的情况下，模型更倾向于不做预测。因此，需要对损失函数进行加权以解决此问题，本模型选择使用 BCE 和 DSC 的组合损失函数，最终设计确定为： $L = \alpha L_{\text{BCE}} + \beta L_{\text{Dice}}$ 。其中， α 与 β 为权重系数，用来调节 BCE 和 Dice 损失函数的占比。经过实验，本模型最终设置 α 为 0.5， β 为 1，并使用此损失函数进行后续实验。

1.6 模型评价指标

目前医学图像分割领域常用的评价指标主要有 Dice 系数、精确率（Precision）和召回率（Recall）。

Dice 系数用于计算两个样本的相似度，计算公式为

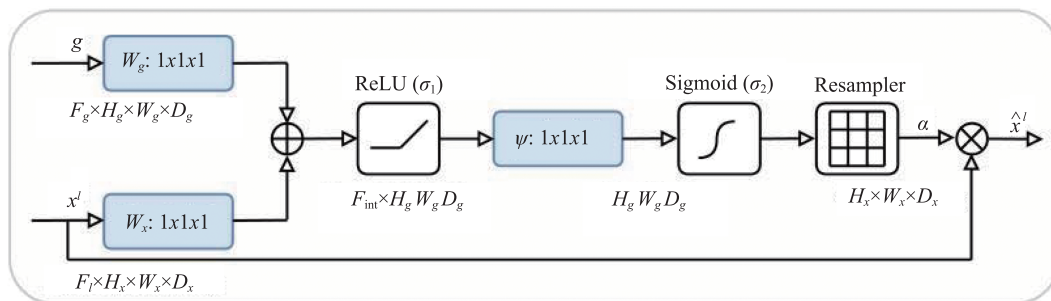


图 3 注意力门控结构
Fig.3 Architecture of the attention gate

$$\text{Dice} = \frac{2\text{TP} \times \text{Recall}}{2\text{TP} + \text{FP} + \text{FN}} = \frac{2|X \cap Y|}{|X| + |Y|} \quad (1)$$

在医学图像分割领域, X 代表算法预测的分割结果, Y 则是由专家勾画的金标准。Dice 系数的取值范围为 $[0,1]$, 它反映了神经网络模型预测的结果和金标准的相似程度。Dice 系数越接近 1, 说明预测的分割效果越好, 分割结果与真实结果的差距越小; Dice 系数越接近 0, 说明分割效果越差, 分割结果与真实结果的差距越大。

精确率用来表示事物的正确程度, 即在预测结果为阳性的样本中, 预测正确的比例, 计算公式为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (2)$$

其中, TP 表示真阳性; FP 表示假阳性, 其值越接近 1, 说明负样本被错分类为正样本的数量越少。在医学图像分割中, 可以将预测结果与金标准相匹配的像素认定为正样本, 不匹配的像素认定为负样本, 这样就可以得出预测结果中与金标准所勾画病灶区域的像素相同的比例。

召回率表示实际为阳性的样本中有多少被正确地预测, 计算公式为

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (3)$$

其中, FN 表示假阴性, 其值越接近 0, 说明金标准中被成功预测的像素越多, 图像分割效果越好。

精确率与召回率是相互影响的, 且往往是相互矛盾的, 如当神经网络模型精确率较高时, 往往召回率较低, 因此要找到两者的平衡点, 尽量让神经网络模型的精确率和召回率都处于相对较高的状态。


2 实验数据及处理过程

本模型选取的数据集是由 CodaLab 提供的 LiTS2017 肝脏肿瘤图像分割挑战数据集。该数据集包含来源于 7 个不同临床机构的 131 例患者的 CT 图像, 均已对肝脏和肝脏肿瘤区域进行标注。每例患者的 CT 图像切片数量为几十张到几百张, 图像尺寸均为 512×512 。数据集将病例按照 8 : 1 : 1 的比例分别划分为训练集、验证集和测试集。

2.1 原始数据集的转换

本文使用 ITK-SNAP 3.6 和 Python 对原始数据进行包括对比度和亮度调整在内的数据预处理工作, 以提高特征提取的精度。通过 ITK-SNAP 对原始图像进行窗宽和窗位调整, 将窗宽调整为 160, 窗位调整为 60, 取得了比较好的对比效果。

图 4 (a) 为原始图像切片, 图 4 (b) 为调整窗宽和窗位后的图像。由于原始数据集是 .nii 格式的三维数据, 而本模型所要求的输入数据为二维数据, 所以需要原始数据进行降维处理。本模型使用 Python 3.10 进行编程以实现此目的, 并最终获取了横断面的切片以进行后续处理。



(a) 原始图像切片

(b) 调整窗宽和窗位后的图像


图 4 原始图像切片与调整窗宽和窗位后的图像对比

Fig.4 Comparison of original image slices and slices with adjusted window width and window level

2.2 图像去噪和增强

调整窗宽和窗位后, 图像的对比度虽然有了较大幅度的提高, 但是仍然存在一些问题, 如原始图像中存在大量噪声, 这会对神经网络的特征提取产生极大的影响。经去噪处理后的图像获得了较好的效果, 但是发现肝脏区域和肝脏肿瘤区域之间的对比度不够高。考虑到肝脏区域和肝脏肿瘤区域的灰度值比较接近, 故采用局部直方图均衡化方法对图像进行处理, 以增强图像的肿瘤边缘平滑度、肿瘤区域与肝脏肿瘤区域的对比度。图 5 (a) 为原始图像, 图 5 (b) 为预处理后的图像, 图中分别以蓝色箭头和橙色箭头标识对比了部分区域, 可以看到, 预处理后, 图像的噪声减少, 图像中肿瘤区域和肝脏肿瘤区域的对比度增强。

数据量过少经常会导致模型训练发生过拟合问题, 为提高模型的泛化能力, 需要对图像进行数据



(a) 原始图像

(b) 预处理后的图像

图 5 原始图像与预处理后的图像对比

Fig.5 Comparison of the original image with the pre-processed image

增强。常用的数据增强方法有数据翻转、随机裁剪、数据旋转、仿射变换、增加噪声等。考虑到医学图像的特殊性，本实验只采用数据随机旋转、随机放缩及水平翻转进行数据增强。同时，对图像原图对应的金标准进行相应的处理，防止出现图像与标签不一一对应的情况。部分数据增强后的图像与标签如图 6 所示。

2.3 实验环境

本文的实验环境配置为 Windows 10 操作系统，Intel Core i5 系列 CPU、12GB 内存、NVIDIA GeForce GTX 960M GPU。本文使用的是 PyTorch 2.1 搭配 CUDA Toolkit 11.2 深度学习框架。模型参数设置如下：批大小设为 2，迭代次数（epoch）设为 50，使用 Adam 优化算法，初始学习率设为 1×10^{-4} ，使用 ReLU 激活函数。

为了避免梯度消失问题和加快模型训练速度，

通常在深度学习中加入 BN 层，但是其训练效果对批大小有比较高的要求，因此本文在构建模型时选用了 GN 层，以增强模型在小批量下的训练效果。

原始数据集经过数据增强、中值滤波和局部直方图均值化后先制作成训练集，再进入神经网络模型中进行训练，验证集和测试集只进行中值滤波与局部直方图均值化，其中验证集不改变模型参数，只作为模型超参数的调整依据，测试集用于检验模型的最终训练结果。

3 实验结果与分析

为验证本实验方法对肝脏肿瘤图像分割的结果具有优越性，将 RA-U-Net 模型与使用其他模块的 U-Net 模型及 3D U-Net 模型进行对比实验。所有模型均使用 LiTS2017 肝脏肿瘤图像分割挑战数据集，训练方法和数据处理过程均完全相同。为了评估模型的图像分割结果，本文统计了不同模型的三个评价指标：Dice 系数、Precision 值和 Recall 值。在 LiTS2017 肝脏肿瘤图像分割挑战数据集上训练后，得到各模型的测试结果，如表 1 所示。

本文对 U-Net 模型、加入了注意力模块的 U-Net + Attention-block 模型、加入了残差模块的 U-Net + Res-block 模型、RA-U-Net 模型及 3D U-Net 模型的图像分割结果进行了比较。从表 1 中可以看出，RA-U-Net 模型相比传统的 U-Net 网络模型拥有更高的分割精度；相比添加了残差模块的 U-Net+




图 6 部分数据增强后的图像与标签

Fig.6 Images and labels after data augmentation

Res-block 模型, 肝脏肿瘤区域的图像分割精度、精确率和召回率更高, 相比经常使用的 3D U-Net 模型略有优势。对比 RA-U-Net 模型, 传统的 U-Net 模型没有利用残差模块和注意力模块, 不同卷积层之间缺乏连续性, 特征利用率较低。只添加了残差模块的 U-Net 模型对关键目标区域的关注度不够, 跳跃连接结构过于单一, 对上下层特征融合不足。3D U-Net 模型在训练时占用内存较大, 进行池化操作时可能会丢失部分信息, 造成特征提取能力降低和分割精度相对较低。

表 1 不同模型的测试结果
Tab.1 Test results of different models

| 模型 (参数量) | Dice 系数 (平均) | Precision (平均) | Recall (平均) |
|----------------------------------|-----------------|-------------------|----------------|
| U-Net (31.04M) | 0.648 | 0.735 | 0.678 |
| U-Net + Attention-block (31.39M) | 0.481 | 0.933 | 0.329 |
| U-Net+ Res-block (6.94M) | 0.688 | 0.971 | 0.575 |
| RA-U-Net (7.29M) | 0.773 | 0.983 | 0.637 |
| 3D U-Net | 0.717 | 0.934 | 0.612 |

RA-U-Net 模型相比传统的 U-Net 模型, 参数量更少, 说明 RA-U-Net 模型并不依靠参数量获得

肝脏肿瘤图像分割精度的提升。以上实验结果证明结合了残差模块和注意力模块的 RA-U-Net 模型在肝脏肿瘤图像特征提取方面具有优越性。

由表 1 还可以发现, 只添加了注意力模块的 U-Net+Attention-block 模型的分割精度并不理想, 经过分析, 总结原因为: 图像的上、下层特征经过注意力模块后会经 sigmoid 函数转换成取值为 [0,1] 的软掩模, 当与输入特征进行点乘时, 可能会削弱深层特征的作用, 且对小目标分割有抑制作用。但是可以看到, 添加了注意力模块的 U-Net+Attention-block 模型比传统的 U-Net 模型精确率更高, 这说明注意力模块加强了对目标区域的关注, 添加了注意力模块的 RA-U-Net 模型经过数据更加丰富的训练后效果更佳。

图 7 (a) 代表原始 CT 图像, 图 7 (b) 代表金标准, 图 7 (c) 代表 U-Net 模型, 图 7 (d) 代表 U-Net+Attention-block 模型, 图 7 (e) 代表 U-Net+Res-block 模型, 图 7 (f) 代表 RA-U-Net 模型, 图 7 (g) 代表 3D U-Net 模型。从图像来看, 图 7 (f) 中显示的图像位置、大小、形状等与图 7 (b) 最接近。




图 7 不同模型的分割结果对比

Fig.7 Comparison of segmentation results of different models

4 总结

本文提出了一种引入残差模块和注意力模块的改良 U-Net 模型, 即 RA-U-Net 模型。RA-U-Net 模型在 U-Net 模型的基础上将原有卷积层更换为残差

模块, 减少了所需的模型参数, 提升了深层网络的学习能力; 在跳跃连接处加入了注意力模块, 联系了上下层特征, 抑制了不相关区域的权重; 将 BN 层更换为 GN 层, 有效提高了神经网络的收敛速度,

提高了泛化能力和小批次下训练的分割效果。实验结果表明, 本文提出的 RA-U-Net 模型优于其他 U-Net 改良型深度学习方法。

在未来的实际工作应用中, 扩大训练集样本量、提升数据预处理效果、优化实验参数, 可改善 CT 图像分割方法的性能; 另外, 通过 3D 神经网络处理三维 CT 图像, 可以省去将三维图像切片为二维图像的处理环节。

参考文献

- [1] 徐蓬泉, 梁宇翔, 李英. 融合多尺度语义和剩余瓶颈注意力的医学图像分割 [J]. **计算机工程**, 2023, 49 (10): 162-170.
XU Pengquan, LIANG Yuxiang, LI Ying. Medical image segmentation fusing multi-scale semantic and residual bottleneck attention[J]. **Computer Engineering**, 2023, 49(10): 162-170.
- [2] 乔伟晨, 黄冕, 刘利军, 等. 基于特征选择与残差融合的肝肿瘤分割模型 [J]. **中国图象图形学报**, 2022, 27 (3): 838-849.
QIAO Weichen, HUANG Mian, LIU Lijun, *et al.* Feature selection and residual fusion segmentation network for liver tumor[J]. **Journal of Image and Graphics**, 2022, 27(3): 838-849.
- [3] OZGUN CICEK, AHMED ABDULKADIR, SOEREN S LIENKAMP, *et al.* 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]//Proceedings of the 19th International Conference on Medical Image Computing and Computer-Assisted Intervention. Athens: Springer, 2016: 424-432.
- [4] Oktay O, Schlemper J, Folgoc L L, *et al.* Attention U-Net: Learning where to look for the pancreas[J]. 2018. DOI: 10.485501/arXiv.1804.03999.
- [5] LI R, LI M, LI J, *et al.* Connection sensitive attention U-Net for accurate retinal vessel segmentation[J]. 2019. DOI: 10.485501/arXiv.1903.05558.
- [6] 董晓莹, 陈平. 基于瓶颈残差注意力机制 U-Net 的肝脏肿瘤分割 [J]. **CT 理论与应用研究**, 2021, 30 (6): 661-670.
- [7] DONG Xiaoying, CHEN Ping. Segmentation of liver tumors based on bottleneck residual attention mechanism U-Net[J]. **Computerized Tomography Theory and Applications**, 2021, 30(6): 661-670.
- [8] LI X, CHEN H, QI X, *et al.* H-Dense U-Net: Hybrid densely connected U-Net for liver and tumor segmentation from CT volumes[J]. **IEEE TMI**, 2018, 37(12): 2663-2674.
- [9] ROBIN BRUEGGER, CHRISTIAN F. BAUMGARTNER, ENDER KONUKOGLU. A Partially Reversible U-Net for Memory-Efficient Volumetric Image Segmentation[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019, part 3: 22nd International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2019), 13-17 October 2019, Shenzhen, China: Springer Nature Switzerland AG, 2019: 429-437.
- [10] LI Song, CAO Guohui, HE Kaijian, *et al.* Bottleneck feature supervised U-Net for pixel-wise liver and tumor segmentation[J]. **ESWA**, 2020, 145(May): 113131.1-113131.11.
- [11] GU, ZAIWANG, CHENG, JUN, FU, HUAZHU, *et al.* CE-Net: Context Encoder Network for 2D Medical Image Segmentation[J]. **IEEE TMI**, 2019, 38(10): 2281-2292.
- [12] HAN, LIN, CHEN, YUANHAO, LI, JIAMING, *et al.* Liver segmentation with 2.5D perpendicular U-Nets[J]. **Comput Electr Eng**, 2021, 91.
- [13] IBTEHAZ, NABIL, RAHMAN, M. SOHEL. Multi-Res-U-Net: Rethinking the U-Net architecture for multimodal biomedical image segmentation[J]. **Neural Networks: INNS**, 2020, 12174-12187.
- [14] ZHOU Z, SIDDIQUEE M R, TAJBAKHS N, *et al.* U-Net++: a Nested U-Net Architecture for medical image segmentation[J]. **IEEE Transactions on Medical Imaging**, 2018, 39(6): 1856-1867.
- [15] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, *et al.* Deep Residual Learning for Image Recognition[C]. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.