

DOI:10.19651/j.cnki.emt.2313621

基于混合空洞卷积与特征融合的肝脏肿瘤图像分割*

帖 军^{1,2} 朱祖桐^{1,2} 郑 禄^{1,2} 徐胜舟^{1,3} 马佳婷^{1,3}(1.中南民族大学计算机科学学院 武汉 430074; 2.农业区块链与智能管理湖北省工程研究中心 武汉 430074;
3.湖北省制造企业智能管理工程技术研究中心 武汉 430074)

摘 要: 为了解决肝脏肿瘤图像中肝脏肿瘤形状复杂、与四周正常组织之间的边界模糊而导致分割模型准确率低的问题,本文提出一种基于混合空洞卷积与高层特征融合的肝脏肿瘤图像分割模型(HFU-Net)。该模型加入高层特征融合再校准模块,丰富 U-Net 中跳跃连接部分,使其利用特征融合与压缩注意力机制对特征信息校准,提升网络编码器的特征信息获取能力。并且,为进一步提高网络各层的特征提取效果,使用混合空洞卷积块替换原模型编码网络中传统卷积模块,以获得密集的肿瘤特征信息,扩大网络感受野。实验结果表明,与 U-Net 算法相比,Dice 系数、体积重叠误差(VOE)、灵敏度、精确率指标均有较好效果,分别提高了 3.3%,4.59%,4.39%和 2.04%。该模型显著提高肝脏肿瘤图像分割精度,为肝癌诊断与治疗提供可靠依据。

关键词: 图像处理;肝脏肿瘤分割;特征融合;混合空洞卷积

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

Improved lightweight YOLOv4 target detection algorithm

Tie Jun^{1,2} Zhu Zutong^{1,2} Zheng Lu^{1,2} Xu Shengzhou^{1,3} Ma Jiating^{1,3}

(1. College of Computer Science, South-Central Minzu University, Wuhan 430074, China; 2. Hubei Provincial Engineering Research Center of Agricultural Blockchain and Intelligent Management, Wuhan 430074, China; 3. Hubei Provincial Engineering Research Center for Intelligent Management of Manufacturing Enterprises, Wuhan 430074, China)

Abstract: In order to solve the problem of low accuracy of segmentation model caused by the complex shape of liver tumor and blurred boundary with surrounding normal tissues in the liver tumor image, this paper proposes a novel liver tumor image segmentation model HFU-Net based on hybrid dilated convolutions and high-level feature fusion. In this model, a high-level feature fusion recalibration module is added to enrich the skip connection part of U-Net, so that it can calibrate the feature information by using feature fusion and squeeze and attention module to enhance the ability of network encoder to obtain feature information. And, in order to further improve the feature extraction effect of each layer of the network, the conventional convolution module in the original model's encoding network is replaced by the hybrid dilated convolution to obtain dense tumor feature information and expand the network's receptive field. The experimental results show that Dice coefficient, volumetric overlap error (VOE), sensitivity and precision are improved by 3.3%, 4.59%, 4.39% and 2.04% respectively compared with the U-Net algorithm. The proposed model significantly improves the segmentation precision of liver tumor images, and provides a reliable basis for the diagnosis and treatment of liver cancer.

Keywords: image processing; liver tumor segmentation; feature fusion; hybrid dilated convolution

0 引 言

早期肝癌患者年 5 年生存率可达到 40%~70%,而晚期肝癌患者生存时间只有 6 个月左右^[1]。研究表明早期通过诊断和治疗可以有效减少肝癌的重症率和死亡率,因此,

肝脏肿瘤的 CT 图像分割是肝癌诊断和治疗的关键步骤^[2]。肝脏肿瘤图像传统分割方法包括区域生长法^[3]、阈值分割法^[4]等。区域生长法的基本思想是根据相似性将像素或子区域聚合成更大的区域。张丽娟等^[5]提出一种全卷积神经网络与区域生长算法相结合的对肝脏图像

收稿日期:2023-05-13

* 基金项目:国家民委中青年英才培养计划(MZR20007)、新疆维吾尔自治区区域协同创新专项(科技援疆计划)(2022E02035)、湖北省中医药管理局中医药科研项目(ZY2023M064)、武汉市知识创新专项曙光计划项目(SZY23003)资助

进行分割的方法,通过在多种边缘检测算子计算得到梯度值,生成像素特征向量训练网络,分割结果与原图灰度通道连接作为全卷积神经网络的输入;图像阈值分割法是一种传统的图像分割方法,也是基于图像灰度值的分割技术。Fonuzan 等^[6]基于阈值法提出一种针对对比度低的 CT 图像的分割方法,生成肝脏概率图基于先验知识,使用阈值法在概率图中生成肝脏边界;传统图像分割方法因运算效率高、实现模型简单、分割速度快、具有稳定的性能成为图像分割中应用广泛的分割技术之一。

目前,深度学习在医学图像分割领域方面取得了重大进展。卷积神经网络(convolutional neural networks, CNNs)是一种经典的深度前馈神经网络,在肝脏肿瘤分割^[7]、肺结节分割^[8]、脑肿瘤分割^[9]、左心房分割^[10]等,取得了比传统算法更好的分割结果。郭旭树等^[11]提出了一种新的监督深度学习网络从腹部 CT 图像中分割肝脏区域,但分割精度和鲁棒性较差。Kaluya 等^[12]使用了一种新的二维全卷积神经网络对肝脏 CT 图像进行分割,并通过反卷积对特征映射进行插值重构最后得到分割结果。Ronnebegrer 等^[13]提出针对医疗影像数据并具有对称收缩路径与扩展路径的 U-Net 分割方法,该方法在肝脏肿瘤数据集中 IoU 指标达到 75.24%。Zhou 等^[14]在 U-Net 网络基础上提出一种重新设计跳跃连接的 U-net++ 网络,为了聚合语义尺度不同的特征,在解码网络上嵌套密集的跳跃连接,产生灵活度高的特征融合方案,在肝脏肿瘤数据集中 IoU 指标达到 83.17%。Huang 等^[15]针对不同尺度器官分割提出 UNet3+,利用了全尺寸跳跃连接和深度监督,结合不同尺度的特征图的高级语义细节,提升模型特征获取能力。Badrinarayanan 等^[16]提出在编码器保留了池化层索引的 SegNet 网络,解码网络恢复图像尺寸,调用池化层索引提高分割效果。Sun 等^[17]提出一种用于肝脏肿瘤的多通道全卷积分割网络,该方法对 CT 图像的每个阶段进行训练,并将提取的高级特征进行融合,在 Dircadb 数据集上交并比指标达到 87%。Liu 等^[18]提出了一种结合 U-Net 网络模型和图分割算法的肝脏图像分割方法,该方法利用改进的 U-Net 通过肝脏序列图像的上下文信息和肝脏图像的概率分布构造图切割函数,最小化图切割函数对肝脏进行分割,在 codalab 数据集上 DSC、VOE 指标分别为 93.7%,89.8%。上述深度学习在医学图像分割领域取得不错的分割效果,但肝脏肿瘤分割领域仍然存在肝脏肿瘤数据集较少,肝脏肿瘤与四周的正常组织之间边界模糊,从而影响病灶的边缘信息分割的准确性的问题。同时多数网络在对病灶区域进行分割时仅利用 CNN^[19],会导致图像信息在一定程度上被削弱,从而影响后续的边界轮廓信息的提取的问题。

为解决上述模型在分割形状复杂、边界模糊的肝脏肿瘤图像时存在分割结果精确率低的问题,提出一种基于混合空洞卷积与高层特征融合的肝脏肿瘤图像分割模型

HFU-Net,首先通过混合空洞卷积块提升模型感受野,获取更多肝脏肿瘤特征信息,并减少对形状复杂肿瘤区域的特征误判率。其次设计了高层特征融合再校准模块并加入网络各层跳跃连接部分,对高层肿瘤特征进行融合,增加目标区域的权重,避免背景像素的干扰,提升网络对肿瘤特征的学习能力,以提高肿瘤边界模糊区域分割精确率。结合压缩注意力(SA)机制^[20],克服分割任务中卷积层的约束,其中 SA 模块对多尺度空间特征与非局部特征进行学习,帮助网络利用丰富的信息提取更精确的病灶特征,获得更精准的目标对象边界。在此基础上结合梯度中心化优化器(GC)^[21],可以规范权重空间和输出特征空间,从而提高模型分割性能。在相关公开肝脏肿瘤(liver tumor segmentation, LiTS)数据集上的实验结果表明,本文方法有效提升肝脏肿瘤图像的分割效果。

1 网络结构

1.1 HF-Net 模型

针对肝脏肿瘤图像的特性,设计一种基于混合空洞卷积与高层特征融合的肝脏肿瘤图像分割模型,以 U-Net 网络为主干网络,在编码网络中设计了一组适用于脏肿瘤图像分割的混合空洞卷积块(hybrid dilated convolutions, HDC)以获得较大感受野,充分利用肝脏肿瘤图像特征。其次,提出高层特征融合再校准模块,将下采样过程中各层特征通过反卷积与上层相同维度的特征进行融合,通过 SA 注意机制进行特征信息再校准,充分利用上下文特征信息后再通过跳跃连接与编码网络特征拼接。最后,嵌入梯度中心化的优化器,进一步提高模型分割性能。以解决肝脏肿瘤图像分割在数据样本有限、肿瘤与四周正常组织边界模糊的情况下出现特征聚合不足导致分割效果较差的问题。

如图 1 所示,HFU-Net 网络由编码网络与解码网络两部分组成。在编码网络上进行下采样用来特征提取,编码网络主要用于提取肝脏肿瘤特征信息。编码网络每层由 1 个 HDC 模块和特征再校准模块组成,每个 HDC 块由空洞率分别为 1,3,5 的空洞卷积与批归一化组成,解决了二次采样过程中信息丢失的问题,同时防止相同空洞率的空洞卷积产生方格效应,减少特征丢失。使用特征融合再校准模块(feature fusion recalibration block, F-Block)将相邻两层特征以跳跃连接的方式与编码网络进行拼接,丰富跳跃连接中高级特征信息,以提取丰富的语义信息。下层特征图通过一次上采样,利用反卷积操作和非线性 ReLU 函数来局部重建 i 层以外的 $(i+1)$ 层的高级特征,以提取物体的细节。F-Block 模块包括下层特征反卷积进行上采样还原特征图通道数,再与上层特征进行特征融合后,经过两个卷积和 ReLU 激活函数再将特征输入 SA 注意力机制中进行特征再校准,将肿瘤特征进行充分提取,提供更精确的肿瘤区域语义信息。再通过跳跃连接将融合后特征与解

码网络中特征拼接,使相应的解码层获得分割更注重的区域,以获得精确的肝脏肿瘤信息。然后通过 4 次上采样,使分割图恢复出更精细的边缘信息,使网络能够将上下文

信息传播到高分辨率层,从而获得更准确的分割结果。最后,通过 1 个 1×1 卷积和 softmax 层输出肝脏肿瘤分割结果。

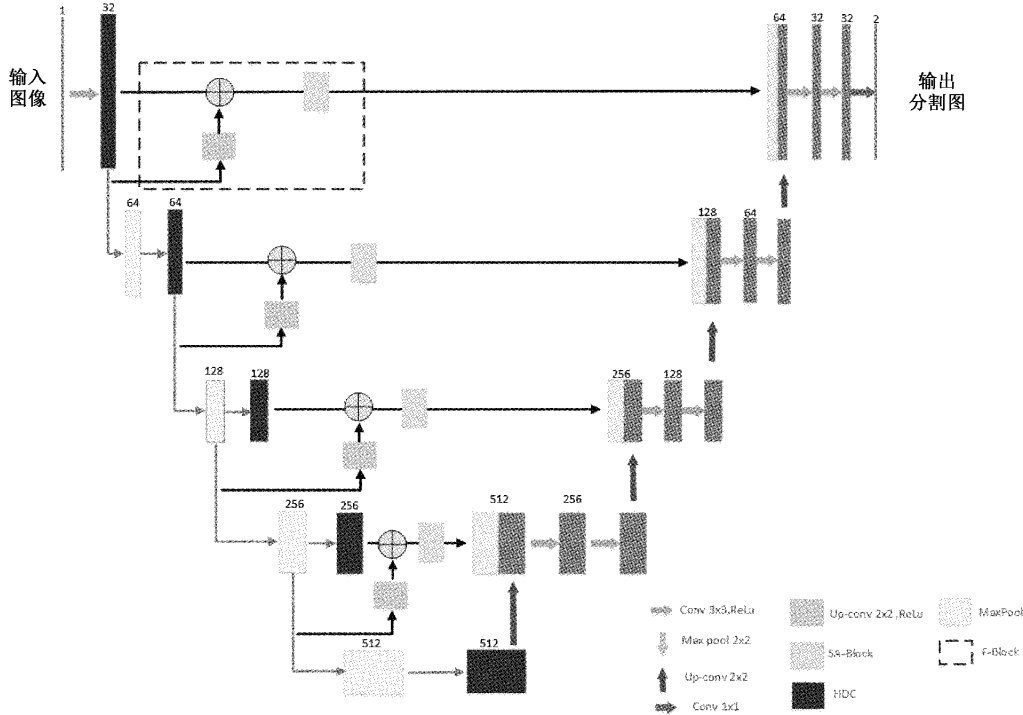


图 1 HFU-Net 网络结构

1.2 高层特征融合再校准模块

本文设计的高层特征融合再校准模块(F-Block)应用于原模型跳跃连接阶段,如图 2 所示。浅层网络中相邻的两个特征图被输入模块中,其中底层特征需要经过一个 2×2 的反卷积与 ReLU 函数恢复通道数后与上层特征图保持相同大小进行特征融合,进一步减少特征之间的语义差距。SA 模块对于深层次特征信息提取效果更好,将特

征融合后先通过两个 3×3 卷积加深网络,再输入 SA 模块中,SA 模块使用平均池化层与卷积、批归一化、ReLU 函数对特征进行再校准,以获得更注重肿瘤区域特征的特征图信息。高层特征融合保留了对象的上下文信息,这些信息在解码阶段对分割图像进行上采样时起着至关重要的作用。




图 2 F-Block 模块

通过反卷积和 ReLU 激活将低分辨率特征转换回高分辨率特征的方法称为局部特征重建。该步骤旨在从下采样特征中提取物体的空间信息。将网络下采样得到的局部重构特征再逐通道地与同一阶段的高层特征进行融合。特征融合步骤丰富了跳跃路径中的高层特征。为了进一步细化高层特征使用 SA 注意力机制模块对修改后的高层特征进行再校准。SA 模块通过考虑局部和全局的重新加权

机制,更加关注学习语义分割任务中更具代表性的非局部特征,聚合多尺度空间的上下文信息。融合的特征被重新校准,更好地标记肿瘤目标的信息,并通过重新校准的特征与相应的解码阶段特征连接获得准确的分割特征信息,提高网络分割性能。

1.3 压缩注意力机制

传统分割网络对细粒度肿瘤特征信息提取较弱,且

同一图像的不同部分可能包含完全不同的信息导致容易出现误判。针对此问题,本文在编码层引入 SA 模块,该网络通过考虑局部和全局方面的重新加权机制,更加关注学习肝脏肿瘤图像分割任务中更具代表性的非局部特

征,聚合多尺度空间的上下文信息。SA 模块扩展通道注意力机制的重新加权通道特性,通过使用平均池化向下采样特征图,保留肿瘤特征图的通道信息与空间信息,如图 3 所示。




图 3 压缩注意力机制模型

压缩-注意模块公式如下:

$$X_{out} = X_{attn} \times X_{res} + X_{attn} \quad (1)$$

其中, $X_{attn} = Up(\sigma(\hat{X}_{attn}))$ 和 $Up(\cdot)$ 是一个上采样函数,用于扩展注意力通道的输出。

$$\hat{X}_{attn} = F_{attn}(APool(X_{in}); \Theta_{attn}, \Omega_{attn}) \quad (2)$$

其中, \hat{X}_{attn} 表示注意卷积通道 $F_{attn}(\cdot)$ 的输出,该通道由 Θ_{attn} 和注意力卷积层结构 Ω_{attn} 参数化。使用平均池化层 $APool(\cdot)$ 执行非完全压缩操作,然后对注意力通道 \hat{X}_{attn} 的输出进行上采样,以匹配主干卷积通道 X_{res} 的输出。通过这种方式 SA 模块使用保留的空间信息和注意通道的上采样输出,并在主干通道上聚集非局部提取的特征。

1.4 混合空洞卷积块

为了增加深度特征的感受野,并且避免空洞卷积的网格效应,本文设计了一组混合空洞卷积模块。空洞率是卷积核的相邻参数之间的距离。空洞卷积核的大小由以下公式计算:

$$k' = k + (k - 1) \times (d - 1) \quad (3)$$

其中, d 为空洞率, k 为标准卷积核大小, k' 为扩张卷积大小。标准卷积默认空洞率为 1。

空洞卷积可以增加感受野,但深度网络使用连续的空洞率相同的空洞卷积时,会产生网格化问题,如图 4 所示,3 个空洞率为 2 的 3×3 卷积核的空洞卷积进行卷积时出现的卷积核不连续的情况。此时,空洞卷积会提取稀疏的特征,从而丢失大量的特征,因此使用混合空洞卷积避免此问题。

通过消融实验验证,将该模块由空洞率分别为 1、3、5 的空洞卷积组成对于分割效果最好,如图 5 所示,其内核大小为 3×3 。在每个混合空洞卷积后添加 BN 层和 ReLU 激活函数,以加快收敛速度。如图 6 所示,本文设计 HDC




图 4 出现网格效应的空洞卷积

模块,由一组混合空洞卷积与批归一化处理层组成,代替原模型卷积进行特征提取,提高模型特征提取能力。感受野 RF_{i+1} 的计算公式为:

$$RF_{i+1} = RF_i + (k' - 1) \times S_i \quad (4)$$

其中, RF_i 为上一层感受野。 k' 是卷积核的大小。 S_i 是之前所有层的步长的乘积。




图 5 混合空洞卷积块

1.5 损失函数

传统 U-Net 模型中使用的优化函数为交叉熵损失。而该损失函数将各个像素的类预测单独评估,再求所有像素平均值。但肝脏 CT 图像中常出现类别不平衡问题,导致训练会被像素多的背景区域所主导,而肿瘤图像像素占比小,其特征让网络难学习到,致使网络的有效性降低。所以,本文使用保证数值稳定的二元交叉熵 (BCEWithLogitsLoss) 和 DiceLoss 函数代替传统交叉熵损失函数。

在传统二元交叉熵损失函数计算交叉熵前,使用 sigmoid 函数将输出值映射到 (0,1) 区间,保证 BCELoss 计




图 6 HDC 模块

算交叉熵顺利进行。其公式定义为：

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N y_i \log \sigma(y_i) + (1 - y_i) \log(1 - \sigma(y_i)) \quad (5)$$

式中： $\sigma(y) = \text{sigmoid}(p(y))$ ， $p(y)$ 表示样本预测为正的的概率， y 表示样本的标签，0 为背景，1 为肝脏肿瘤， N 为图像中输入像素总数。

DiceLoss 即：

$$L_{Dice} = 1 - \frac{\sum_{k=1}^K 2w_k \sum_{i=1}^N p_{(k,i)} g_{(k,i)}}{\sum_{i=1}^N p_{(k,i)} + \sum_{i=1}^N g_{(k,i)}} \quad (6)$$

式中： N 表示像素点的总数。 K 表示分类数，包含肝脏肿瘤和背景两种。 $g_{(k,i)} \in \{0, 1\}$ ，表示像素点 i 属于 k 分类的标签值。设置 $w_k = \frac{1}{K}$ 。 $p_{(k,i)} \in [0, 1]$ ，表示像素点被预测为肿瘤或背景的概率。

1.6 GC 优化器

本文模型中加入 GC 优化器，以提高网络在肝脏肿瘤图像数据集上的训练性能。GC 对权重空间和输出特征空间进行正则化，从而提高 DNN 的泛化性能。此外，GC 改进了损失函数及其梯度的 Lipschitz 性，使训练过程变得更加高效和稳定。将 GC 嵌入到现有的基于梯度的 DNN 优化器中。如图 7 所示， W 是权重， L 是损失函数， $\nabla_w L$ 是权重梯度， $\Phi_{GC}(\nabla_w L)$ 是中心化后的梯度。

$\nabla_w L$ 表示梯度，下标 i 代表在该梯度矩阵中的第 i 列

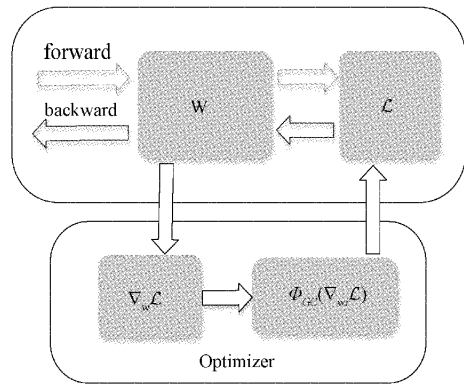


图 7 使用梯度集中

列向量。

$$\Phi_{GC}(\nabla_w L) = \nabla_w L - \mu \nabla_w L \quad (7)$$

$\mu \nabla_w L$ 的公式如下：

$$\mu \nabla_w L = \frac{1}{M} \sum_{j=1}^M \nabla_{w_i, j} \quad (8)$$

对于梯度矩阵中的各个列向量，先求出列向量中每个元素的平均值 $\mu \nabla_w L$ ，再剔除在该列向量中的均值，对所有列向量都进行相同的中心化，最后得到中心化之后的梯度矩阵。

2 实验结果与分析

2.1 数据集预处理

本文所用数据是 LiTS—肝脏肿瘤分割挑战数据集，其中包含 131 份 nii 格式的肝脏肿瘤病灶 CT 文件。LiTS 中分为肝脏数据集与肝脏肿瘤数据集两组数据集，其中使用肝脏肿瘤数据集作为本文数据集。对 LiTS 的训练样本进行 4:1 分配，其中训练集占 80%，测试集占 20%。为加快模型的推理速度以及深度神经网络的鲁棒性，解决因为肝脏肿瘤数据集样本过少导致模型训练易过拟合的问题，训练模型之前需要对数据进行预处理与数据增广，对数据集预处理的方法主要包括窗口技术、直方图均值化等。

首先，在保证语义分割效果的前提下将医疗图像格式 nii 的文件处理成分辨率为 512×512 像素的图像。对 CT 切片进行裁剪以去除部分背景，进行开窗以将切片的 Hounsfield 强度调整为 $[-150, 250]$ 。其次，将图像进行自适应直方图均衡通过归一化，灰度值被映射到 $[0, 1]$ ，用于增加肝脏和肿瘤之间的对比度，提高 CT 图像可观察度。本文研究对象为肝脏肿瘤，为了更好验证模型在肝脏肿瘤图像上的有效性，避免肝脏标签造成额外的影响，将图像中肝脏标签通过代码转换将其替换为背景标签。最后，生成标签数据为只有背景与肝脏肿瘤的标签图像，为后续针对肝脏肿瘤图像分割模型改进研究提供数据集基础。

图像数据增广主要包括图像旋转、镜像翻转等，本实验图像旋转角度考虑实际 CT 扫描时人体差异或站位不同进行 $0^\circ \sim 10^\circ$ 的随机旋转。总计肝脏肿瘤图像 17 190 张。

数据集示例如图 8 所示。




图 8 数据集示例

2.2 评估指标与实验环境

为了评估本文提出的改进 U-Net 模型的性能,使用 Dice 系数、体积重叠误差 (VOE)、精确率 (Precision)、灵敏度 (Sensitivity) 这 4 种指标来衡量分割性能。表达式如下:

$$Dice(S, T) = \frac{2|S \cap T|}{|S| + |T|} \quad (9)$$

$$VOE(S, T) = 1 - \frac{|S \cap T|}{|S \cup T|} \quad (10)$$

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

$$Sensitivity = \frac{TP}{TP + FN} \times 100\% \quad (12)$$

式中: TP、TN、FP、FN 分别表示真阳性、真阴性、假阳性和假阴性。

实验硬件环境采用 Intel(R) Xeon(R) CPU E5-2630 v4@2.20 GH 处理器,内存 64 GB,显卡 NVIDIA Tesla P40 24 GB;实验软件环境为 Ubuntu 16.04 LST 64 位操作系统,python3.6,CUDA11.2,Pytorch1.4.0。

2.3 消融实验

为了验证 SA 模块的有效性,本节对 SA 模块在原 U-Net 网络上进行了不同层次嵌入方式的消融实验。在下采样过程中通过最大池化特征信息和参数将会减少,而在不同层嵌入注意力机制使网络聚焦于关键信息,减少关键信息的损失,获取更清晰的边缘轮廓信息,实验结果如表 1。

表 1 SA 模块消融实验结果

网络模型	Dice	VOE	SENS	Precision
U-Net	89.54	17.85	88.22	90.75
U-Net+SA-1	90.03	17.83	89.16	90.66
U-Net+SA-2	90.12	17.05	89.55	90.71
U-Net+SA-3	90.35	16.73	89.37	91.16
U-Net+SA-4	90.91	14.85	91.12	91.25
U-Net+SA-5	91.23	14.55	91.45	91.77

由表 1 可知,结合 SA 模块的 U-Net 网络在肝脏肿瘤数据集上对各项指标都有不同程度的提升,且在更深层次的特征信息上提取和利用的关键信息效果更为明显,其中在第四层,第五层结合了 SA 模块后相较于原 U-Net 网络 Dice 系数分别提升了 1.3%, 1.69%, VOE 指标 3%,

3.3%, SENS 指标提升了 2.9%, 3.23%, Precision 指标提升了 0.5%, 1.02%。Dice 系数与 VOE 指标的提升表明分割结果区域更加趋于真实标签。SENS 与 Precision 指标的提升,表明该模型更好区分肿瘤区域与背景区域。

为了验证混合空洞卷积块的有效性,本节对混合空洞卷积块在原 U-Net 网络编码网络上对合适的不同空洞率卷积块的消融实验。在下采样过程中最大池化会将特征信息和参数减少,使用不同空洞率的空洞卷积可使网络感受野扩大,提升肿瘤特征信息提取范围,减少关键信息的损失,提升肿瘤区域分割信息准确率,实验结果如表 2。

表 2 不同空洞率空洞卷积实验结果对比

网络模型	空洞率	Dice	VOE	SENS	Precision
U-Net	r=1,1	89.54	17.85	88.22	90.75
	r=1,3,5	92.15	14.23	91.85	91.56
	r=1,2,3	91.73	14.45	91.33	91.41
	r=1,2,5	91.81	14.76	91.41	92.55
	r=1,3,5,8	91.72	14.57	91.34	92.52

表 2 显示了在编码网络阶段使用不同空洞率的空洞卷积块对分割性能的影响。实验表明混合空洞卷积块对分割结果有改善,当选择混合空洞卷积块为 r=1,3,5 时,模型训练得到最佳 Dice 系数,尽管编码网络模型复杂度有小幅提升,但相较于原模型 dice 系数提高了 2.61%, VOE 指标提高了 3.62%, SENS 指标 3.63%, Precision 指标提升了 0.81%,证明不同尺度空洞卷积对肿瘤特征提取的有效性。

2.4 对比实验

为了验证 SA 模块、SGD_GC 模块、F-Block 模块与 HDC 模块的有效性。该实验以原 U-Net 网络作为实验的基准网络,在编码网络中加入不同改进模块,完成肿瘤图像分割对比实验。单独添加 SA 模块 Dice 指标提升了 1.36%,添加 SGD_GC 模块后提高了 0.80%,添加 F-Block 模块提高 2.02%,添加 HDC 模块提高 2.61%。从表 3 中实验对比可知,4 种方法对于其他指标也有提升,表明各模块能有效改善肿瘤区域的特征判断准确度。

表 3 U-Net 结合各个模块上不同方法的评价指标结果

网络模型	Dice	VOE	SENS	Precision
U-Net	89.54	17.85	88.22	90.75
U-Net+SA	90.90	15.97	90.39	91.13
U-Net+SGD_GC	90.34	16.88	89.62	90.82
U-Net+F-Block	91.56	15.46	91.40	91.36
U-Net+HDC	92.15	14.23	91.85	91.56
HFU-net	92.84	13.26	92.61	92.79

由表 4 所示,本实验与 U-Net、U-Net++、SegNet 和

U-Net3+分割网络的分割性能进行对比。在肝脏肿瘤数据集、损失函数等初始基本实验参数不改变的情况下,本文算法的各项指标相较于其他网络均有所提高。相较于原 U-Net 网络 Dice 系数提升 3.3%,VOE 指标提升 4.59%,SENS 提升 4.39%,Precision 提升了 2.04%。Dice、VOE 和 Precision 指标的改进意味着误判减少,分割更加准确。SENS 灵敏度指标的改善表明在肿瘤图像特征在像素级识别度高。FLOPs 代表深度学习网络向前传播的运算次数,量级越小代表计算速度越快,从表 4 中可看出本文网络除原网络外,相较于其他网络计算速度较高。综合来可,本文网络在肝脏肿瘤图像分割上性能优于其他网络。

表 4 不同方法的评价指标结果

网络模型	Dice	VOE	SENS	Precision	FLOPs/G
U-Net	89.54	17.85	88.22	90.75	56.41
U-Net++	90.37	16.62	89.67	90.95	176.13
SegNet	90.47	17.26	89.56	90.22	167.16
U-Net3+	91.34	15.79	91.19	91.24	202.05
HFU-Net	92.84	13.26	92.61	92.79	96.44

如图 9、10 所示,通过本文模型与不同模型的损失曲线对比和 Dice 精度对比曲线,可以看出,本文提出的 HFU-Net 模型的损失值曲线更平滑,精度更高,证明本文比 U-Net、U-Net++,SegNet 和 U-Net3+ 模型稳定性更好。

肿瘤分割为了更直观的观察各模型的分割结果,通过图 11 对比可看出,图 11(c)对于肿瘤边缘部分存在欠分割情况。图 11(d)、图 11(f)在肿瘤边缘部分分割效果有较好的改善,但在小目标肿瘤图像上分割效果较差。图 11(e)

在肝脏肿瘤图像分割上存在误判的情况,将图像中其他正常组织判断为肿瘤。通过分割图像可视化可以看出,本文模型减少非肿瘤细小器官的误判分割,提高模糊的肝脏边界的分割精确率。




图 9 不同模型的损失值曲线比较




图 10 不同模型的 Dice 精度曲线比较




图 11 不同方法的分割结果图

3 结 论

本文提出一种基于混合空洞卷积与高层特征融合的肝脏肿瘤分割方法—HFU-Net。为了解决肝脏肿瘤大小不一、与四周正常组织之间的边界模糊而影响分割精确度的问题。首先,本章模型中将适用于肝脏肿瘤图像特性的混合空洞卷积块代替编码网络中的卷积模块,增大网络下采样过程中的感受野,抵消一部分池化层造成的信息损失。其次,利用高层特征融合模块在跳跃连接时将高层特征与下层特征融合后再进行优化,从特征中提取最佳的语义细节。利用 SA 注意力机制,对融合特征进行再校准以突出肝脏肿瘤区域特征信息,将高层特征与下层特征的融合提高网络学习能力。最后,嵌入梯度中心化算法的优化器,使权值空间和特征值空间正则化,提高网络模型的分割性能以及训练速度。实验结果表明,本文所提出的 HFU-Net 网络在肝脏肿瘤数据集上分割性能优于其他网络。该方法在处理小目标肿瘤图像时,容易出现轻微的超额分割或欠分割问题,如何从多模态数据集中充分利用特征信息使误差再减小的角度是下一步研究的重点。

参考文献

- [1] 乐美琰,魏千越,邓炜,等. 基于电子计算机断层扫描图像的肝癌病灶自动分割方法研究进展[J]. 生物医学工程学杂志,2018,35(3):481-487.
- [2] LI Y, ZHAO Y Q, ZHANG F, et al. Liver segmentation from abdominal CT volumes based on level set and sparse shape composition[J]. *Computer Methods and Programs in Biomedicine*, 2020, 195:105533.
- [3] 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报, 2005, 17(10): 2168-2173.
- [4] 申铨京,潘红,陈海鹏. 基于一维 Otsu 的多阈值医学图像分割算法[J]. 吉林大学学报(理学版),2016,54(2): 344-348.
- [5] 张丽娟,章润,李东明,等. 区域生长全卷积神经网络交互分割肝脏 CT 图像[J]. 液晶与显示,2021,36(9): 1294-1304.
- [6] FORUZAN A H, CHEN Y W, ZOROOFI R A, et al. Multi-mode narrow-band thresholding with application in liver segmentation from low-contrast CT images[C]. *International Conference on Intelligent Information Hiding & Multimedia Signal Processing*. IEEE, 2009, DOI: 10.1109/IIH-MSP.2009.78.
- [7] JIANG H Y, SHI T Y, BAI Z Q, et al. AHCNet: An application of attention mechanism and hybrid connection for liver tumor segmentation in CT volumes[J]. *IEEE Access*, 2019, DOI:10.1109/ACCESS.2019.2899608.
- [8] 黄鸿,吕容飞,陶俊利,等. 基于改进 U-Net++ 的 CT 影像肺结节分割算法[J]. 光子学报,2021,50(2):0210001.
- [9] 冯博文,吕晓琪,谷宇,等. 基于空洞卷积的三维并行卷积神经网络脑肿瘤分割[J]. 激光与光电子学进展, 2020, 57(14): 141009.
- [10] XIONG Z H, FEDOROV V, FU X H, et al. Fully automatic left atrium segmentation from late gadolinium enhanced magnetic resonance imaging using a dual fully convolutional neural network[J]. *IEEE Transactions on Medical Imaging*,2019,38(2): 515-524.
- [11] 郭树旭,马树志,李品,等. 基于全卷积神经网络的肝脏 CT 影像分割研究[J]. 计算机工程与应用,2017, 53(18):126-131.
- [12] KALUVA K C, KHENED M, KORI A, et al. 2D-densely connected convolution neural networks for automatic liver and tumor segmentation[J]. *CoRR*, 2018, DOI:10.48550/arXiv.1802.02182.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[M]. *Lecture Notes in Computer Science*, 2015.
- [14] ZHOU Z W, SIDDIQUEE M M R, TAJBAKSHI N, et al. UNet++: A nested U-net architecture for medical image segmentation[M]. *Lecture Notes in Computer Science*, 2018.
- [15] HUANG H, LIN L, TONG R, et al. Unet 3+: A full-scale connected unet for medical image segmentation[C]. *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Barcelona, Spain: IEEE, 2020:1055-1059.
- [16] 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.
- [17] SUN C J, GUO S X, ZHANG H M, et al. Automatic segmentation of liver tumors from multiphase contrast-enhanced CT images based on FCNs[J]. *Artificial Intelligence in Medicine*, 2017, 83:58-66.
- [18] LIU Z, SONG Y Q, SHENG V S, et al. Liver CT

- sequence segmentation based with improved U-Net and graph cut [J]. Expert Systems with Application, 2019, 126:54-63.
- [19] YOON K. Convolutional Neural Networks for Sentence Classification [J]. CoRR, 2014, DOI: 10.3115/v1/D14-1181.
- [20] HONG Z L, LIN Z Q, BIDART R, et al. Squeeze and attention networks for semantic segmentation[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2020: 13062-13071.
- [21] YONG H, HUANG J, HUA X, et al. Gradient centralization: A new optimization technique for deep neural networks [C]. European Conference on Computer Vision, Springer, Cham, 2020: 635-652.

作者简介

帖军,教授,主要研究方向为计算机图像处理中图像分割、目标检测和图像识别方面。

E-mail: tiejun@mail.scuec.edu.cn

朱祖桐,硕士研究生,主要研究方向为计算机视觉、图像分割。

E-mail: 602575423@qq.com

郑禄(通信作者),讲师,主要研究方向为深度学习、图像处理。

E-mail: lu2008@mail.scuec.edu.cn

徐胜舟,副教授,主要研究方向为数字图像处理、模式识别、深度学习。

E-mail: xushengzhou@mail.scuec.edu.cn

马佳婷,硕士研究生,主要研究方向为计算机视觉。