

基于特征融合的肝脏肿瘤自动分割方法

刘一鸣, 肖志勇*

江南大学人工智能与计算机学院, 江苏 无锡 214122

摘要 针对腹部器官边界模糊、对比度不高以及肝脏和肿瘤形状易发生变化的问题,提出了一种基于特征融合的肝脏肿瘤自动分割方法,该方法进行两个阶段的训练。第一阶段使用改进的 U-Net 网络进行肝脏的分割;第二阶段用第一阶段的肝脏分割结果生成感兴趣区域(ROI),将 ROI 作为输入进行肿瘤的分割,这样能有效避免不相关信息带来的影响。本文提出的特征融合方法贯穿了两个阶段,其中通道注意力用于获取通道间的高频信息,空间注意力有助于图像空间信息和上下文信息的利用;然后在跳跃连接部分将得到的两个输出特征图进行特征融合;最后,通过深度监督将融合后的特征信息进行多尺度结合,进一步提高分割的精度。实验主要以 DSC、VOE 和 RVD 作为评价标准,其中肝脏和肿瘤的 DSC 分别为 0.957 和 0.676,基本实现了肝脏肿瘤的准确分割。

关键词 图像处理; 医学图像分割; 深度学习; 深度监督网络; 特征融合

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.1417001

Automatic Segmentation Algorithm of Liver Tumor Based on Feature Fusion

Liu Yiming, Xiao Zhiyong*

School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi, Jiangsu 214122, China

Abstract In view of the blurred boundary and low contrast of abdominal organs as well as the different liver and tumor shapes, a feature fusion-based method for automatic segmentation of liver and tumor is proposed in this article. The method is trained in two stages. The first stage uses an improved U-Net for liver segmentation. The second stage generates the area of interest (ROI) with the result of the first stage of liver segmentation, using ROI as input for tumor segmentation, which effectively avoids the effects of non-relevant information. The proposed method is run through two stages in which channel attention is used to obtain high-frequency information between channels, and spatial attention is helpful in using image spatial and contextual information. Then, feature fusion of two output feature images is completed in jump connection section. Finally, their feature information is combined via deeply-supervised net to further improve the segmentation accuracy. In the experiment, DSC, VOE, and RVD are mainly used as the evaluation criteria in which the liver and tumor of DSC are 0.957 and 0.676, respectively, realizing an accurate segmentation of liver tumor.

Key words image processing; medical image segmentation; deep learning; deeply-supervised net; feature fusion

OCIS codes 100.2000; 100.3008; 200.4260

1 引言

恶性肝肿瘤对人们的健康造成了极大危害,它的诊断结果直接影响着后续治疗方案,因此,准确高

效地实现肝脏肿瘤的分割就显得尤为重要。早期的肝脏肿瘤分割主要是依靠医生的专业知识和经验进行手动分割,往往需要多次重复勾画出肝脏肿瘤区域,不仅耗时耗力,而且容易受医生的主观影响,对

收稿日期: 2020-09-11; 修回日期: 2020-10-19; 录用日期: 2020-11-14

基金项目: 江苏省优秀青年基金(BK20190079)

通信作者: *zhiyong.xiao@jiangnan.edu.cn

分割的准确性造成了较大影响。传统的自动分割算法主要有基于图谱^[1]、形变模型^[2]和区域生长^[3]的分割方法。但这几种自动分割方法的鲁棒性较差,不能很好地用于分割,因此基于深度学习的肝脏肿瘤自动分割方法成为上述问题的一个解决方法。

自 Ronneberger 等^[4]于 2015 年提出 U-Net 以来,该方法极大地促进了医学图像分割的研究。与先前加利福尼亚大学伯克利分校研究团队^[5]提出的全卷积网络(FCN)相比,U-Net 是一种编码-解码模式的网络结构,编码器逐渐减少池化层的空间维度,解码器逐步修复图像的细节和空间维度。Kalava 等^[6]提出了利用 2D 密集连接卷积神经网络进行电子计算机断层扫描(CT)图像的 2D 切片分割方法。尽管这些基于 2D 卷积的方法取得了一定的分割效果,但这些方法忽略了 CT、磁共振成像(MRI)等医学图像的空间关联性,容易产生不光滑、不连续的分割结果。为了更好地利用医学图像的空间信息,Çiçek 等^[7]在 U-Net 的基础上,将 2D 卷积操作替换为 3D 卷积操作,提出了 3D U-Net。同样,Milletari 等^[8]采用三维卷积来处理 MRI 图像,得到的分割结果也优于各种 2D 方法。使用 3D 卷积^[7-10]进行医学图像的分割是一种有效的方法。Christ 等^[11]利用级联 FCN 实现了肝脏肿瘤的分割,但该方法没有结合高等级和低等级的语义信息。针对这一问题,Oktay 等^[12]提出了基于注意力机制的 U-Net 模型,该模型通过注意力模型捕获图像的空间信息来提高对图像特定区域的关注度,虽然取得了一定效果,但仍没有结合空间位置信息和通道间的关联性。

为解决目前存在的问题,实现肝脏肿瘤的高效准确分割,本文提出了一种以 U-Net 为基础框架的特征融合方法。首先,通道注意力用于学习通道间的关联性,空间注意力用于捕获图像的空间位置信息。其次,考虑到 CT 图像中肝脏肿瘤的大小及形状变化,加入了深度监督^[13-14],用于学习不同层次下的特征表示,从而增强网络的学习能力。同时,在编码和解码模块间使用空洞卷积^[15]和残差模块^[16]。用空洞卷积代替普通卷积可以提升感受野;残差模块在增加网络深度的同时可以避免梯度爆炸,从而在一定程度上解决了网络退化问题。

2 相关工作

2.1 深度监督

由于腹部器官的形状和大小的变化较大,因此随着分割网络中间特征层的增多,位于网络结

构末尾的监督层不能对中低层特征的提取过程进行直接监督,从而大大增加了网络对中低层有效特征的训练难度。为解决这个问题,本文方法在网络的每个隐藏层添加了额外的 Loss,并将监督得到的 Loss 传播回早期层,而不仅仅在输出层进行监督。对各层得到的特征损失进行集成学习,可以提高模型的分割性能。深度监督网络结构如图 1 所示。通过在网络中加入深度监督来学习多尺度下生成的特征图在不同层次下的特征,然后将各层得到的 Loss 按照系数比例进行合并,就可以使浅层得到更加充分的训练,从而提高网络的识别能力。

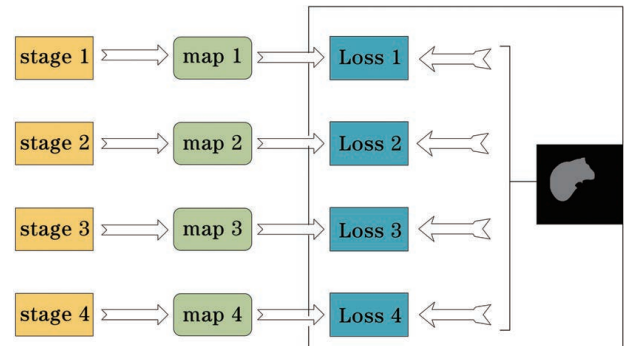


图 1 深度监督网络结构

Fig. 1 Structure of deeply-supervised net

2.2 空洞卷积

随着空洞卷积(Dilated/Atrous Convolution)广泛在语义分割与目标检测等任务中大显身手以及 Deeplab 系列^[17]的提出,研究人员对空洞卷积进行了深入思考;同时,目标检测中的 SSD^[18]与 RFBNet^[19]也同样使用了空洞卷积。受上述研究的启发,针对医学图像分割领域存在的问题,本文引入了三维空洞卷积(3D Dilated Convolution)。普通的三维卷积为了在扩大感受野的同时降低计算量,往往进行降采样(Pooling 或 s2/conv),这样做虽然能够使感受野增加,但却降低了空间分辨率。使用空洞卷积能在不丢失分辨率的同时扩大感受野,有效解决了普通卷积存在的问题。空洞卷积实际卷积核的大小和感受野的计算公式为

$$K = k + (k - 1)(r - 1), \quad (1)$$

$$F_r = (2^{r+1} - 1)(2^{r+1} - 1)(2^{r+1} - 1), \quad (2)$$

式中: k 为原始卷积核的大小; r 为空洞卷积参数——空洞率; K 为卷积核的实际大小; F_r 为最终的感受野大小。此外,为了捕获多尺度的上下文信息,本文使用 $r = 1, 2, 4$ 的空洞率组合作为一个模块,这样可以在获取更广阔像素信息的同时避免空

洞卷积存在的棋盘效应。

3 本文算法的原理

3.1 整体概括

用于肝脏肿瘤分割的整体框架流程图如图 2 所




图 2 实验流程图

Fig. 2 Flow chart of our experiment

3.2 网络模型

为了高效准确地进行肝脏肿瘤的分割,本文在原来 U-Net 的基础上加入了基于通道注意力机制的方法,对空间和通道上的特征进行结合。本文所提网络结构图如图 3 所示,本文网络主要分为编码和解码两个模块。编码模块包含了 5 组卷积模块和 4 次下采样操作,相对应的解码模块包含了 4 组卷积模块和 4 次上采样操作。为更好地表示,每组卷积模块都用一个卷积块来表示两次卷积操作。编码部分的每一层包含了 3 组卷积操作 (Conv $3 \times 3 \times 3$ + BN + ReLU) 和一次跳

跃连接,所示框架包含了两个主要部分。第一部分是对预处理后得到的 CT 图像进行肝脏的分割,然后将得到的肝脏区域作为感兴趣区域 (ROI),将在此区域随机裁剪得到的数据作为输入数据。实验结果表明,本文算法能够实现各种复杂 CT 图像的肝脏肿瘤分割。

跃连接的结构,接下来的几层为了更好地捕获更多的感受野信息,采用空洞卷积进行感受野的扩充,即:每层第一组卷积操作的卷积核为 $3 \times 3 \times 3$,第二组卷积操作进行的是卷积核为 $3 \times 3 \times 3$ 、膨胀系数 $r=2$ 的空洞卷积,第三组卷积操作进行的是卷积核为 $3 \times 3 \times 3$ 、膨胀系数 $r=4$ 的空洞卷积。通过膨胀系数 $r=1,2,4$ 的组合,能够从更广阔的像素范围内获取信息;下采样使用的池化层大小为 $2 \times 2 \times 2$,步长为 2。此外,本文在网络中加入了残差模块,用以抑制网络深度增加可能导致的梯度消失/梯度爆炸。

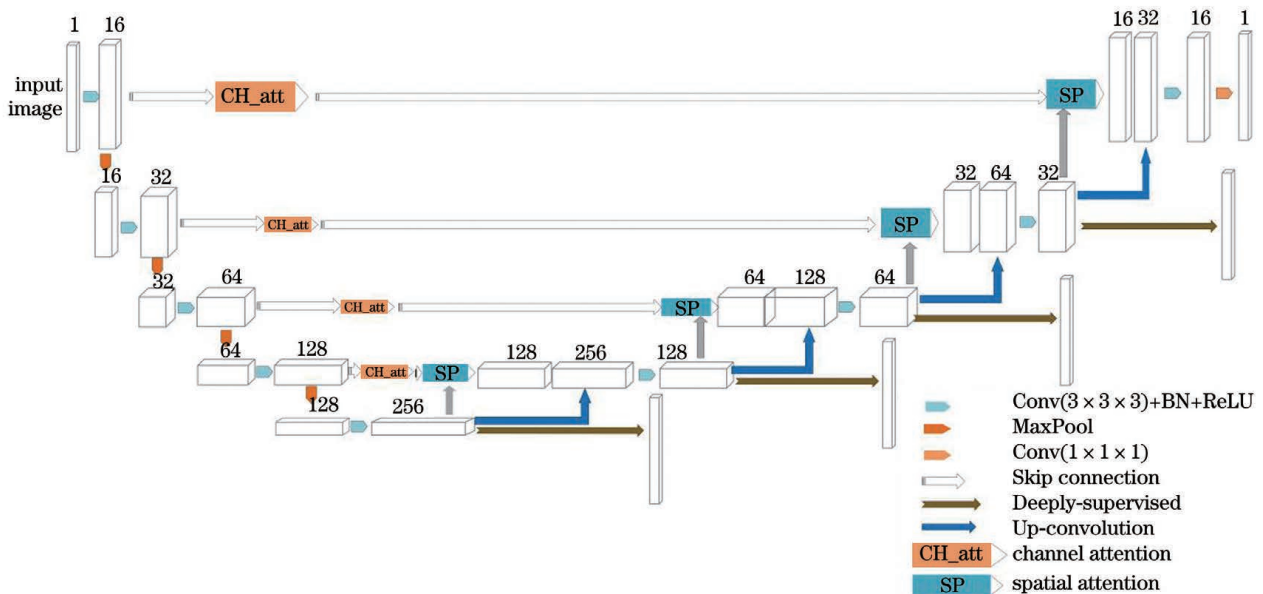


图 3 本文所提网络结构图

Fig. 3 Network structure proposed in this paper

考虑到通道间关联的重要性,在跳跃连接上加入了一种基于通道注意力机制 (Channel attention) 的方法^[20-21],使网络能够放大有价值的

特征通道同时抑制无用通道,进而关注含有高频信息的通道。如图 4(a)所示,首先对输入的图像进行全局池化 (Globalpooling),以便完成特征压

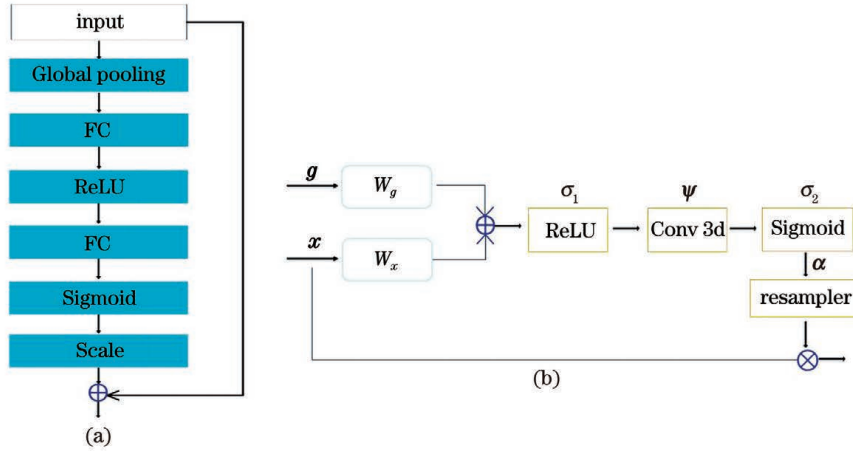


图 4 注意力模块图。(a)通道注意力模块;(b)空间注意力模块

Fig. 4 Attention module diagrams. (a) Channel attention module; (b) spatial attention module

缩,输出的结果为 $1 \times 1 \times C$ 数据;再把输出结果输入到两个全连接层(FC),在通过第一个全连接层时对数据进行压缩,以降低计算量;经过一系列卷积、激活得到了一个权重值,再把这个值作为 Scale 乘到输入的 C 个通道上,作为下一层的输入。这样做可在增强重要特征的同时减弱不重要特征的影响,从而使提取的特征指向性更强。

解码部分包含了 4 个卷积模块和 4 次上采样操作;每层的结构和编码部分都是 3 组卷积操作(Conv $3 \times 3 \times 3 + \text{BN} + \text{ReLU}$),上采样操作使用的是三线性插值方法,最后一组卷积本文采用的是 $1 \times 1 \times 1$ 的卷积核,采用的激活函数为 Sigmoid。因为肿瘤与肝脏相比往往是微小的,所以本文使用原始分辨率的 CT 图像进行训练,没有对其进行插值或者缩放操作,从而避免了一些细节信息的丢失。

为了提高网络对目标区域的关注,本文在跳跃连接中加入了空间注意力机制。Oktay 提出空间注意力^[12]是为了结合不同层次的特征信息。这种注意力门控模型在进行训练时能够抑制那些背景中不相干的信息,使得到的注意力系数聚焦在需要分割的局部区域,突出显示对任务有用的显著特征,同时结合了高层部分和低层部分的信息。具体的流程如图 4(b)所示。其中 x 是来自编码部分的特征图, g 为解码部分的特征图。首先将 g 和 x 分别进行 $1 \times 1 \times 1$ 卷积(W_g, W_x),然后通过逐元素相加操作进行融合,并利用 ReLU 激活函数进行激活,接着再进行 $1 \times 1 \times 1$ 卷积,之后利用 Sigmoid 函数得到值在 $[0, 1]$ 间的权重系数矩阵。权重系数的求导公式为

$$q_{\text{att}}^l = \psi^T [\sigma_1 (W_x^T x_i^l + W_g^T g_i + b_g)] + b_\psi, \quad (3)$$

$$\alpha = \sigma_2 [q_{\text{att}}^l(x_i^l, g_i)], \quad (4)$$

式中: g_i 为解码部分的矩阵; x_i^l 为编码部分的矩阵; W_x 和 W_g 为 $1 \times 1 \times 1$ 的卷积核; σ_1 为 ReLU 激活函数; σ_2 为 Sigmoid 激活函数; α 为所得的权重矩阵; b_g 和 b_ψ 为卷积过程中的偏置项,用于更好地拟合数据。此时将 x^l 与得到的权重系数相乘,就可使目标区域的值变大,抑制不相关区域的干扰,进而提升模型的性能。

3.3 损失函数

本文选用 Dice 损失函数,该函数的本质是衡量两个样本的重叠部分,重叠部分越大,Dice 越大,分割效果就越好。Dice 损失函数的定义为

$$f_{\text{Dice}} = \sum_{b=1}^n \left(1 - \frac{2 \cdot Y_{pb} \cdot Y_g}{Y_{pb} + Y_g} \right), \quad (5)$$

式中: Y 表示 Flatten 后的预测概率图; Y_{pb} 表示第 b 层生成的预测图; Y_g 代表金标准(Ground truth)。

在训练过程中本文采用深度监督来进行模型的优化。深度监督将解码部分各个阶段得到的特征图还原成金标准大小,再将各层得到的输出结果与金标准进行损失(Loss)计算,得到每层的 Loss 后再将各个阶段得到的 Loss 按照一定的系数比例相加,得到最终的 Loss。所以由深度监督得到的最终 Loss 的定义为

$$L_{\text{ms}}(Y, \hat{Y}) = \beta \sum_{b=1}^4 \left(1 - \frac{2 \cdot Y_{pb} \cdot Y_g}{Y_{pb} + Y_g} \right) + \left(1 - \frac{2 \cdot Y_{p5} \cdot Y_g}{Y_{p5} + Y_g} \right), \quad (6)$$

式中: \hat{Y} 表示 Flatten 后的金标准; β 为系数,这里取 0.33。

4 实验结果与分析

4.1 实验数据集

本文的实验数据来自 Codalab 数据集(<https://competitions.codalab.org/competitions/17094>), 该数据集包含了来自 6 个不同临床机构共 201 个增强对比(contrast-enhanced)的 CT 图像, 将其中 131 个带标签的图像作为训练集, 70 个不带标签的作为测试集, 图像横断面的分辨率都是 512 pixel \times 512 pixel。但横断面(transverse plane)上的切片数量不同, 并且由于数据集来自不同的医院和研究机构, 它们的体素间距(voxel spacing)也存在差异, 因此对其进行预处理使数据规范化对模型的训练很重要。将处理后的训练集中 70% 的样本作为训练集, 剩余的 30% 作为验证集。网络模型的测试结果在 Codalab 上进行线上提交。

4.2 实验环境和参数设置

本文所提网络采用 Kaiming_normal 进行权重的初始化, 使用 Adam 优化器, 参数为 beta1=0.9 和 beta2=0.99, 学习率设为 1×10^{-4} , 训练的 Batch size 设为 2 和 6 (肝脏分割和肿瘤分割的 Batch size)。模型的训练在配备了 NVIDIA RTX2080Ti GPU (两块) 和 Intel Core i7 处理器上的服务器上进行, 实验平台为 Pytorch。

4.3 评价指标

为了衡量模型的泛化能力和表现性能, 本文采用医学图像分割领域几种流行的评价指标, 即相关性系数(DSC)、体积重叠误差(VOE)和体素相对误差(RVD)作为肝脏肿瘤分割结果的评价指标。

DSC 表示实验预测结果(P)与真实标签(G)的重合程度, 其定义为

$$\alpha_{\text{DSC}} = \frac{2|P \cap G|}{|P| + |G|} \quad (7)$$

体积重叠误差(VOE)是预测结果(P)和真实标签(G)交集的体素数除以预测结果(P)和真实标签(G)并集中的体素数的误差, 其定义为

$$\alpha_{\text{VOE}} = 1 - \frac{|P \cap G|}{|P \cup G|} \quad (8)$$

RVD 表示预测结果(P)与真实标签(G)在体积上的差异, 其定义为

$$\alpha_{\text{RVD}} = \left(\frac{P}{G} - 1\right) \times 100\% \quad (9)$$

4.4 实验结果

4.4.1 样本预处理对实验结果的影响

对 CT 图像进行预处理能够排除不相干器官的干扰, 同时获得视觉上的清晰。在进行阈值截取后可以获取整个 CT 图像序列中的有效部分, 即排除不包含肝脏的区域。图 5 为预处理前后的图像对比。图像中不同组织的亨氏单位(HU)的值不同,

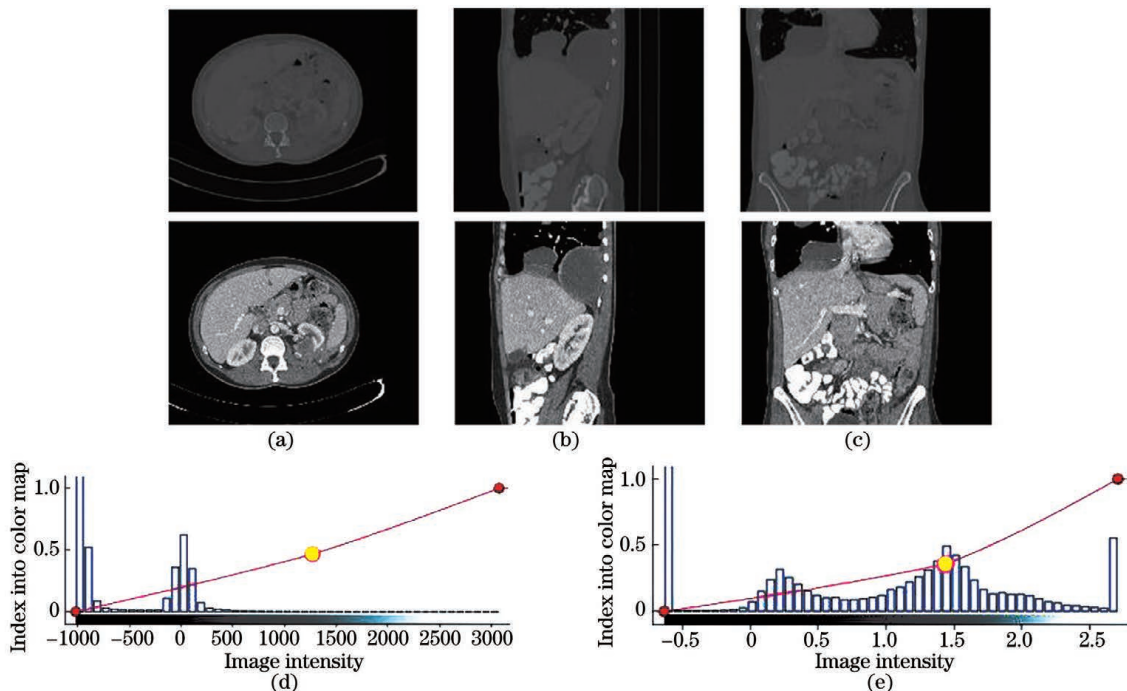


图 5 预处理前后的图像对比图。(a)横断面;(b)矢状面;(c)冠状面;(d)预处理前的 HU 值分布;(e)预处理后的 HU 值分布
Fig. 5 Comparison before and after pretreatment. (a) Transverse plane; (b) sagittal plane; (c) coronal plane; (d) HU distribution before pretreatment; (e) HU distribution after pretreatment

HU 值分布范围广。未处理图像 HU 值的差距较大,不利于网络的收敛。预处理排除了其他器官的干扰,得到的 HU 值分布均匀。此外,为了使网络能够更好地收敛,本文加入了 Z-score 标准化处理,它能防止数据在规范化时被压缩。

图 5(a)、(b)、(c)代表了 CT 图像各个切面上的示意图,(d)、(e)是预处理前后 HU 值的分布情况,可以看出,预处理后各个器官的对比度显著提高了。为了说明实验预处理的重要性,本文对比了不同预处理下的输入大小对分割结果的影响,结果如表 1 所示。

表 1 不同输入大小下的分割结果

Table 1 Segmentation results at different input sizes

Input solution	Voxel spacing /mm	Slice	Stride	DSC
128×128×32	3	10	5	0.913
128×128×32	3	15	3	0.921
256×256×32	3	15	3	0.944
256×256×48	2	15	3	0.957

由表 1 可以看出,不同的输入大小对实验结果的影响是较大的。将体素间距(voxel spacing)统一

表 2 各种网络结构的分割结果比较

Table 2 Comparison of segmentation results of various network structures

Model	Liver			Tumor		
	DSC	VOE	RVD	DSC	VOE	RVD
U-Net	0.939	0.112	0.007	0.547	0.411	-0.070
U-Net+deeply-supervised net	0.952	0.089	0.001	0.589	0.390	-0.104
U-Net+deeply-supervised net+spatial attention	0.955	0.084	-0.006	0.643	0.375	-0.091
U-Net+deeply-supervised net+FF	0.957	0.081	0.003	0.676	0.341	-0.064

为了更好地说明所提方法的性能,本文随机选取了肝脏和肿瘤各两个样本在不同模型下的分割结果进行展示,如图 6 所示。可以看出:直接使用 U-Net 对肿瘤进行分割,分割效果不是很好;在加入深度监督后,肿瘤的分割结果有了一定提升,但仍存在欠分割的问题;图 6(f)在图 6(e)的基础加入了空间注意力,使模型更加关注目标区域的输出,在一定程度上提升了肿瘤的分割效果。图 6(c)为本文算法的分割结果,可以看出,将特征融合和多尺度学习集成到模型后,得到的分割结果明显优于其他方法,进一步体现了本文方法的有效性。

为了说明本文两级分割策略的有效性,将肝脏和肿瘤同时进行训练得到的结果与本文所提方法的

到 2 mm 时,在获取有效区域后再向外多扩张 15 张切片,同时每间隔三张切片进行数据的裁剪,由此得到的分割效果最好,进一步说明了预处理的必要性。

4.4.2 网络模型对实验结果的影响

本文使用基于 U-Net 改进策略的多种方法进行分割,并对分割结果进行对比。不同方法的分割结果比较如表 2 所示。由分割结果可知,本文所提基于特征融合(FF)和多尺度学习的模型的分割结果明显优于其他模型。本文将特征融合和多尺度学习运用到网络模型中(特征融合使模型能够结合不同层的空间信息和通道信息),使网络在获取不同通道权重值的同时加强了对图像不同位置的关注程度。同时,考虑到医学图像中目标区域的多变性,本文利用深度监督对不同层次的信息进行集成训练,以增强模型对肝脏和肿瘤形状、大小多变的适应能力,进一步强化分割效果。采用深度监督的模型虽然比不上特征融合和深度监督结合对分割结果带来的提升,但与原始网络相比,它结合了不同尺度的信息进行训练,在一定程度上也强化了分割结果。

结果进行了对比,对比结果如表 3 所示,分割结果如图 7 所示。

表 3 本文方法与直接分割策略的对比

Table 3 Comparison between proposed method and

One-stage

Model	Liver			Tumor		
	DSC	VOE	RVD	DSC	VOE	RVD
Proposed	0.957	0.081	0.003	0.676	0.341	-0.064
One-stage	0.944	0.114	0.017	0.585	0.380	-0.081

在整个 CT 图中,肝脏相对于肿瘤来说大很多,直接对整个 CT 图像进行分割,对肝脏分割的结果影响较小,但由于肿瘤的大小及形状多变,直接对其




图 6 不同方法的分割结果。(a)原始图像;(b)金标准;(c)本文方法;(d)U-Net;(e)U-Net+深度监督网络;(f)U-Net+深度监督网络+空间注意力分割

Fig. 6 Segmentation results of different methods. (a) Raw image; (b) Ground truth; (c) proposed method; (d) U-Net; (e) U-Net+deeply-supervised net; (f) U-Net+deeply-supervised net+spatial attention




图 7 本文方法与直接分割策略的对比

Fig. 7 Comparison between proposed method and One-stage

进行分割会降低网络模型对肿瘤的关注度,还可能会遗漏一些小的肿瘤,使分割效果较差。本文提出的两级分割策略首先在整个图像上对肝脏进行分割,在得到的结果中提取出 ROI 作为第二阶段的输入,从而能够大大排除图像中不相关信息的干扰,使模型在分割过程中对肿瘤的关注度提升,提高肿瘤的分割准确率。

4.4.3 与其他方法的比较

为了更好地验证模型的性能,本文基于 LITS 数据集对不同方法的分割结果进行了对比,如表 4 所示。Kaluva 等^[6]采用 2D 密集连接的方法进行肝脏和肿瘤的分割,没有考虑 CT 图像的空间关联性,分割时会丢失部分空间信息。Jin 等^[22]在原来 U-

Net 的基础上利用注意力机制来关注显著区域,但没有考虑肝脏肿瘤在 CT 图像中形状和大小的变化,所以肿瘤分割效果不理想。Chen 等^[23]虽然利用通道注意力来增强通道间的关联性,在抑制无用通道信息的同时加强了重要的通道特征,但它没有考虑图像多尺度间的空间位置信息。Jiang 等^[24]首先利用肝脏定位网络来确定肝脏的大致位置,然后进行肝脏肿瘤的分割,他也用注意力机制对低层语义信息和高层语义信息进行结合,但没考虑网络通道间的关联性,忽略了通道域上的信息。本文方法加入了通道注意力和空间注意力进行通道域信息和空间位置信息的特征融合,实验结果表明,本文所提方法在 DSC 等多个指标上都能取得较好的结果。

表 4 不同分割方法的比较

Table 4 Comparison of different segmentation methods

Model	Liver			Tumor		
	DSC	VOE	RVD	DSC	VOE	RVD
Bi, et al	0.959	—	—	0.500	—	—
MEDDIIR	0.950	0.094	0.047	0.658	0.380	-0.12
Kaluva, et al ^[6]	0.912	0.150	-0.008	0.492	0.411	19.70
Jin, et al ^[22]	0.961	0.074	0.002	0.595	0.389	-0.152
Chen, et al ^[23]	—	—	—	0.650	—	—
Jiang, et al ^[23]	0.953	—	—	0.668	0.135	0.012
Our method	0.957	0.081	0.003	0.676	0.341	-0.064

Notes: the first and second rows of data come from Codalab dataset.

5 结 论

针对肝脏肿瘤的分割,本文提出了一种基于注意力机制的特征融合方法,该方法利用通道注意力机制学习通道间的关联性,利用空间注意力机制使网络能结合高层与低层语义的位置信息。同时,考虑到 CT 图像中器官形状和大小的多变性,加入深度监督来学习多尺度下生成的特征图,使网络浅层可以更好地学习。此外,加入的三维空洞卷积能扩大感受野,从而捕获更多的图像特征,提升边界模糊的肝脏肿瘤区域的分割效果。实验结果表明,本文方法能够有效分割出肝脏肿瘤区域,有助于医生高效准确地发现病灶区域,进而提高诊断效率。同时,本文方法也为医学图像分割的其他任务提供了思路。

参 考 文 献

- [1] Liu W, Jia F C, Hu Q M, et al. Atlas based automatic liver 3D CT image segmentation [J]. Beijing Biomedical Engineering, 2011, 30(5): 457-461.
刘伟, 贾富仓, 胡庆茂, 等. 基于图谱的肝脏 CT 三维自动分割研究[J]. 北京生物医学工程, 2011, 30(5): 457-461.
- [2] Jia T, Wei Y, Wu C D. 3D lung vessel image segmentation scheme based on geometric active contour model [J]. Chinese Journal of Scientific Instrument, 2010, 31(10): 2296-2301.
贾同, 魏颖, 吴成东. 基于几何形变模型的三维肺血管图像分割方法[J]. 仪器仪表学报, 2010, 31(10): 2296-2301.
- [3] Li R Z, Liu Y Y, Yang M, et al. Three-dimensional point cloud segmentation algorithm based on improved region growing[J]. Laser & Optoelectronics Progress, 2018, 55(5): 051502.
李仁忠, 刘阳阳, 杨曼, 等. 基于改进的区域生长三维点云分割[J]. 激光与光电子学进展, 2018, 55(5): 051502.
- [4] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Cham: Springer, 2015, 9351: 234-241.
- [5] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 3431-3440.
- [6] Kaluva K C, Khened M, Kori A, et al. 2D-densely connected convolution neural networks for automatic liver and tumor segmentation [EB/OL]. (2018-01-05) [2020-09-08]. <https://arxiv.org/abs/1802.02182>.
- [7] Çiçek Ö, Abdulkadir A, Lienkamp S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation [C]//Ourselin S, Joskowicz L, Sabuncu M R, et al. Medical image computing and computer-assisted intervention-MICCAI 2016. Cham: Springer, 2016, 9901: 424-432.
- [8] Milletari F, Navab N, Ahmadi S A. V-net: fully convolutional neural networks for volumetric medical image segmentation [C]//2016 Fourth International Conference on 3D Vision (3DV), October 25-28, 2016, Stanford, CA, USA. New York: IEEE Press, 2016: 565-571.
- [9] He C E, Xu H J, Wang Z, et al. Automatic

- segmentation algorithm for multimodal magnetic resonance-based brain tumor images[J]. *Acta Optica Sinica*, 2020, 40(6): 0610001.
- 何承恩, 徐慧君, 王忠, 等. 多模态磁共振脑肿瘤图像自动分割算法研究[J]. *光学学报*, 2020, 40(6): 0610001.
- [10] Feng B W, Lü X Q, Gu Y, et al. Three-dimensional parallel convolution neural network brain tumor segmentation based on dilated convolution [J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 141009.
- 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.
- [11] Christ P F, Ettliger F, Grün F, et al. Automatic liver and tumor segmentation of CT and MRI volumes using cascaded fully convolutional neural networks [EB/OL]. (2017-02-20) [2020-09-08]. <https://arxiv.org/abs/1702.05970>.
- [12] Oktay O, Schlemper J, Folgoc L L, et al. Attention U-Net: learning where to look for the pancreas [EB/OL]. (2018-05-11) [2020-09-08]. <https://arxiv.org/abs/1804.03999>.
- [13] Lee C Y, Xie S N, Gallagher P, et al. Deeply-supervised nets [EB/OL]. (2014-09-18) [2020-09-08]. <https://arxiv.org/abs/1409.5185v2>.
- [14] Zhou Z, Siddiquee M M R, Tajbakhsh N, et al. UNet++: a nested U-Net architecture for medical image segmentation [J]. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, 2018, 11045: 3-11.
- [15] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions [EB/OL]. (2015-11-23) [2020-09-08]. <https://arxiv.org/abs/1511.07122>.
- [16] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [17] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848.
- [18] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]//Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016*. Cham: Springer, 2016, 9905: 21-37.
- [19] Liu S T, Huang D, Wang Y H. Receptive field block net for accurate and fast object detection[M]//Ferrari V, Hebert M, Sminchisescu C, et al. *Computer vision-ECCV 2018*. Cham: Springer, 2018, 11215: 404-419.
- [20] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [21] Liu K W, Ma Y, Xiong H X, et al. Medical-image super-resolution reconstruction method based on residual channel attention network [J]. *Laser & Optoelectronics Progress*, 2020, 57(2): 021014.
- 刘可文, 马圆, 熊红霞, 等. 基于残差通道注意力网络的医学图像超分辨率重建方法[J]. *激光与光电子学进展*, 2020, 57(2): 021014.
- [22] Jin Q, Meng Z, Sun C, et al. RA-UNet: a hybrid deep attention-aware network to extract liver and tumor in CT scans [J]. *Frontiers in Bioengineering and Biotechnology*, 2020, 8: 605132.
- [23] Chen X Y, Zhang R, Yan P K. Feature fusion encoder decoder network for automatic liver lesion segmentation[C]//2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019), April 8-11, 2019, Venice, Italy. New York: IEEE Press, 2019: 430-433.
- [24] Jiang H Y, Shi T, 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, 7: 24898-24909.