

DOI:10.3969/j.issn.1005-202X.2023.06.006

医学影像物理

## 基于条件卷积与注意力的肝脏分割算法

赵浩辉<sup>1</sup>, 高永彬<sup>1</sup>, 杨淑群<sup>1</sup>, 胡小军<sup>2</sup>, 范应方<sup>3</sup>

1. 上海工程技术大学电子电气工程学院, 上海 201620; 2. 南方医科大学第五附属医院肝胆外科, 广东 广州 510000; 3. 南方医科大学珠江医院肝胆一科, 广东 广州 510000

**【摘要】**鉴于现有肝脏CT影像分割算法中存在的对比度较低、边界模糊、分割效果差问题,提出一种基于条件参数化卷积与注意力的分割网络(CPat-Net)。首先用条件参数化卷积替代残差网络中的常规卷积,其次将融合后的条件残差卷积模块集成至编码器中,用以提升模型容量和保持高效计算。然后利用特征注意(CPat)模块中的空间和通道注意力获取特征图的语义和细节信息,从而将局部特征与其全局依赖性更好地结合起来,最后利用深度监督进行多尺度语义信息的融合,提升方法的性能与鲁棒性。实验表明,在肝脏CT影像数据集中本文方法的Dice相似系数、交并比、Jaccard系数分别达到了94.1%、90.3%、92.4%。相较于UNet、CENet、CSNet等前沿方法,本文方法在肝部分割上的准确度更为优异。

**【关键词】**肝脏分割;卷积神经网络;条件参数化卷积;CPat-Net

**【中图分类号】**R318;TP391

**【文献标志码】**A

**【文章编号】**1005-202X(2023)06-0701-08

### Liver segmentation algorithm based on conditional parametric attention network

ZHAO Haohui<sup>1</sup>, GAO Yongbin<sup>1</sup>, YANG Shuqun<sup>1</sup>, HU Xiaojun<sup>2</sup>, FAN Yingfang<sup>3</sup>

1. School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China; 2. Department of Hepatobiliary Surgery, the Fifth Affiliated Hospital of Southern Medical University, Guangzhou 510000, China; 3. Hepatobiliary Department 1, Zhujiang Hospital of Southern Medical University, Guangzhou 510000, China

**Abstract:** In view of the low contrast, fuzzy boundary and poor segmentation results in the existing liver CT image segmentation algorithms, a conditional parametric attention network (CPat-Net) is presented. The method uses conditional parametric convolution to replace the conventional convolution in the residual network, and integrates the fused conditional residual convolution module into the encoder for improving model capacity and maintaining efficient computation. Then the spatial and channel attention mechanisms in the CPat module are used to obtain the semantic and detail information of the feature map, so as to better combine the local features with their global dependencies, and finally depth supervision is adopted to fuse multi-scale semantic information for improving the segmentation performance and robustness. The experiment reveals that the method has a Dice similarity coefficient, intersection over union and Jaccard coefficient of 94.1%, 90.3% and 92.4% on the liver CT image data set. Compared with the advanced methods such as UNet, CENet and CSNet, the proposed method has a higher accuracy in liver segmentation.

**Keywords:** liver segmentation; convolutional neural network; conditional parametric convolution; CPat-Net

### 前言

近期由国际癌症研究机构(IARC)发布的全球新

发癌症死亡人数中,中国每年因肝癌致死的人数接近40万,死亡人数高居世界第二<sup>[1]</sup>。肝脏的早期诊断对肝癌的术前诊断及后续治疗方案的制定发挥着重大作用<sup>[2]</sup>。传统的肝癌CT图像分割工作主要是依赖专家对肝脏及肿瘤区域进行手工标注和分割,但这一过程耗时耗力,标注质量也受到专家的经验知识和主观性影响,使得分割的准确性难以稳定。基于深度学习的自动分割算法由于其强大的特征学习与泛化能力已广泛应用于医学图像分割领域并取得显著成效<sup>[3]</sup>。文献[4]提出的UNet网络作为基础模

**【收稿日期】**2023-02-15

**【基金项目】**上海市“科技创新行动计划”社会发展科技攻关项目(21DZ1204900);广州市科技计划项目(202206010093)

**【作者简介】**赵浩辉,硕士研究生,研究方向:医学图像处理, E-mail: gyzh1010@163.com

**【通信作者】**范应方,博士,副教授,研究方向:图像处理、计算机软件, E-mail: fanyf068700@sina.com

型被广泛应用于视网膜血管<sup>[5]</sup>、脑肿瘤<sup>[6]</sup>等医学分割中。UNet利用其U型的编解码器结构获取上下文特征和位置信息,在编解码器间利用跳跃连接将低级和高级语义特征信息集成,从而实现像素级的语义分割,在医学小样本数据上表现优异。莫春梅等<sup>[7]</sup>将改进后的残差模块引入UNet中,增强了网络的特征提取能力,又利用混合损失函数改善类别不平衡问题,从而加快网络收敛。文献[8]提出残差注意网络RAUNet,通过融合残差学习与注意力捕获全局信息,扩大网络深度,抑制输入端中的不相关区域,同时提高局部感兴趣区域(ROI)的特征,突出特定区域的语义特征,使得网络注意集中于局部,加快梯度的反向传播,提升分割效果。虽然在性能上表现良好,但忽略了边缘位置信息的捕捉。文献[9]提出了用于眼血管图像分割的CENet网络模型,该网络利用密集卷积(DAC)模块和多核池化(RMP)模块组成的上下文提取器捕捉空间和高层特征信息<sup>[10]</sup>,同时将空洞卷积应用于卷积层用以扩大感受野<sup>[11]</sup>,有效提升了特征提取能力,减少了上下文提取模块的语义差异,但在多尺度语义信息提取中仍表现不佳。文献[12]提出了用于肝脏医学图像分割的SAR-U-Net,通过引入挤压-激励(Squeeze-and-Excitation)模块、空洞金字塔池化模块(Atrous Spatial Pyramid Pooling)和残差块提取图像特征<sup>[13]</sup>,抑制不确定区域信息,突出分割任务特征,但在多尺度特征融合以及空间通道信息提取上仍表现不佳。其他医学模型例如H-DenseUNet<sup>[14]</sup>和UNet++<sup>[15]</sup>等,虽然在相关分割上表现良好,但一定程度上忽略了多尺度相关的位置和语义信息,从而导致了多尺度特征提取能力不足以及分割精度较低等问题。

针对肝脏难以精确分割的问题,本文提出基于条件卷积与注意力的改进UNet肝脏分割网络(CPat-Net)。该网络将条件参数化卷积(CondConv)融入特征注意模块<sup>[16]</sup>,用以保留肝脏边缘信息。同时将融合后的条件残差卷积集成到特征提取模块,用以增加网络深度,提升模型的尺寸和容量,保持模型高效计算能力,防止网络退化。最后通过在编解码器中引入改进的空间和通道注意力模块,进一步整合局部特征和全局关系,实现多尺度信息融合<sup>[17]</sup>,最终提升肝脏分割精度。

## 1 分割方法

### 1.1 基础网络

UNet是一种能够结合图像深层和浅层分辨率信息的卷积神经网络,被广泛应用于医学小样本分割领域中。UNet主要由编码器(Encoder)、解码器

(Decoder)和跳层连接组成的U型网络。左半部分的编码器由卷积和下采样组成,使用两个 $3\times 3$ 的卷积核和一个池化层,负责对输入图像上下文特征信息进行提取。右半部分的解码器由上采样和解码组成,负责将定位获取的图像恢复原始分辨率并解码为最终分割图,模型结构相互对称。跳层连接则是负责将编码获取的语义信息传送给相应解码端。虽然模型使用跳层连接一定程度上恢复了编码器中损失的信息,但由于上采样的特征信息较为抽象,所用的跳层连接过于单一,导致卷积层之间的特征利用率较低。因此传统的U-Net结构很难提取到足够的特征图信息且相邻像素间的冗余太大,难以满足分割需要。

### 1.2 模型改进

本文方法在UNet架构基础上改进提出了CPat-Net。CPat-Net集成了条件残差卷积、特征注意模块<sup>[18]</sup>和深度监督。网络结构如图1所示。CPat-Net选择强大的U型网络结构作为主干,主要分为3个阶段:特征编码模块、空间和通道注意模块和特征解码模块<sup>[19]</sup>。通过在编码器和解码器中加入一个自注意机制,利用空间和通道两种注意模块来将局部特征和全局相关依赖性关系有效结合起来。鉴于通道间关联的重要性,笔者在跳跃连接中引入了专门的卷积块来实现空间、通道和多尺度的特征映射注意力模块,使网络可以在抑制无关通道同时提高对目标区域的关注,有效去除噪音区域,更好地获取全局环境信息。此外,为了防止梯度爆炸及网络复杂度的增加,特地在网络中加入了残差模块。编码器一般主要用于特征提取,在CPat-Net编码层中使用4个编码模块,每个模块使用条件残差网络作为主干,同时引入最大池化层来扩大接受域,从而提取特定全局特征并进行降维。而CPat模块中的两个平行注意块—通道注意块和空间注意块接收到来自编码器的特征。最后解码器将不同尺度的全局特征信息融合到模型结构中,并将多个中间层产生的特征聚合起来进行预测,从而使用多尺度的全局信息来恢复分割目标。

### 1.3 空间和通道注意模块

传统的医学分割模型多为单维度工作,从而忽略了空间和通道维度的依赖关系,导致语义特征中细节信息的丢失。网络的感受野也被限制在局部,这使得模型无法有效获取更广泛且丰富的背景信息。鉴于此,笔者设计了CPat模块,CPat利用通道和空间两个平行的注意力模块将浅层和深层次的特征图语义信息进行融合,进而更好地表示空间和通道间的依赖关系,并利用条件参数化卷积保持模型高效推理能力,提升肝脏分割精度。CPat模块如图2所示。

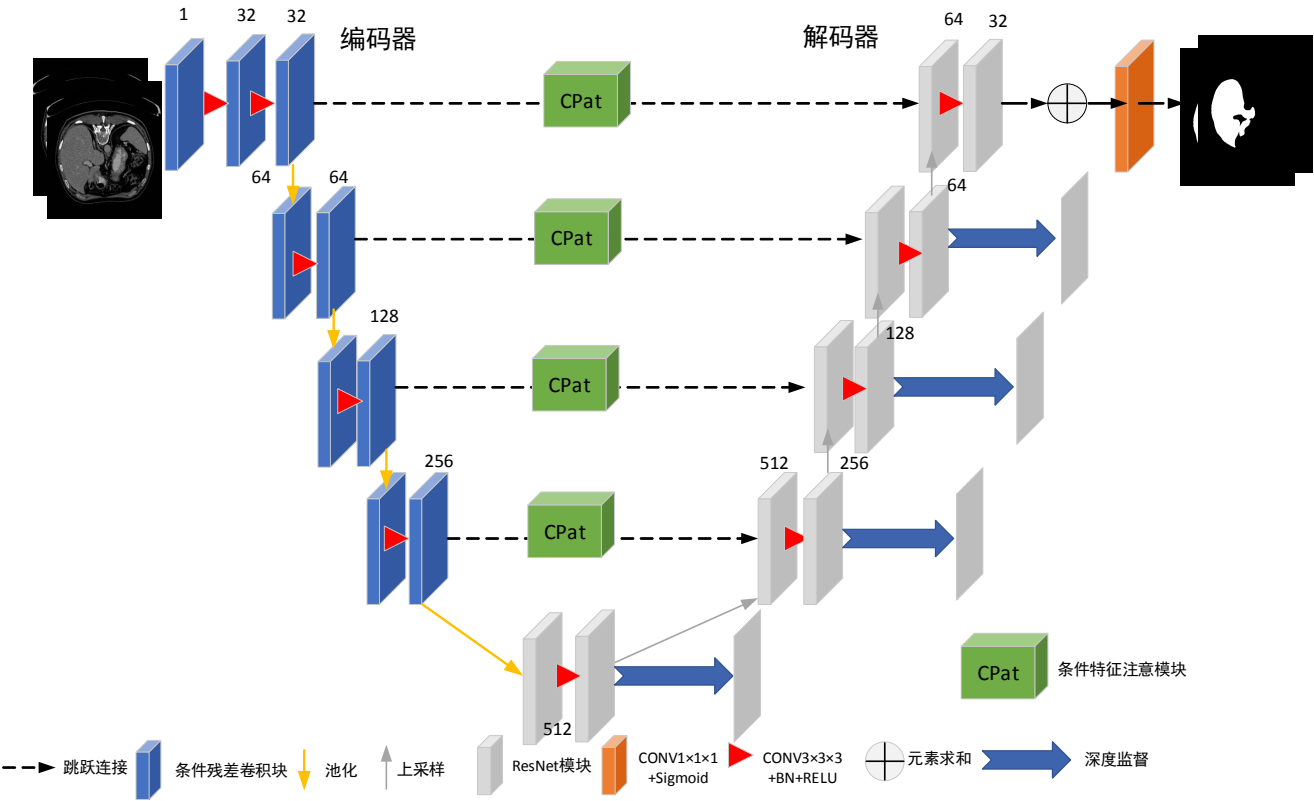


图1 CPat-Net网络结构图

Figure 1 CPat-Net structure

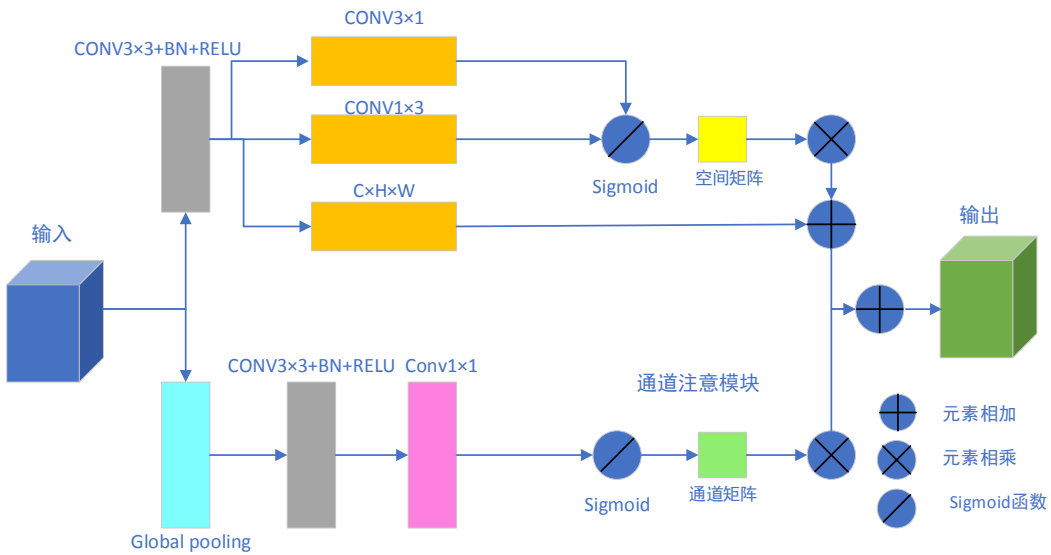


图2 CPat模块结构图

Figure 2 CPat module structure

**1.3.1 空间注意力** 在传统模式中,全卷积网络(FCN)借助像素级的分类,解决了语义级的图像分割问题,但是在局部特征表示方面仍有限制,从而导致图像的错误分类。为了丰富语境模型的局部特征,更好地表示上下文信息的依赖关系,笔者在跳跃连接中引入了空间注意模块,使得模型在训练时有效抑制背景中的无关信息,将注意力集中于目标区域。

通过生成空间注意矩阵<sup>[20]</sup>,对像素间的特征关系进行建模,从而将广泛的上下文信息传入局部特征中,大大提升模型的表达能力。首先将来自编码器的输入特征 $A \in R^{C \times H \times W}$ 和解码器中的特征 $B \in R^{C \times H \times W}$ 进行 $3 \times 3$ 卷积、批归一化和ReLU通道变化处理。其中 $C$ 为通道数, $H$ 和 $W$ 分别为输入特征的高度和宽度。然后用 $1 \times 3$ 和 $3 \times 1$ 的内核卷积生成新的特征图来获取



边缘信息特征,然后将获得的新特征图送入 $1\times 1$ 卷积层并使用Sigmoid函数变换。在空间维度上将获取特征使用矩阵乘法进行特征融合,从而得到新的像素级空间特征。最后将生成的特征进行像素级求和,从而获得最终输出结果。

**1.3.2 通道注意力** 模型通过将来自编码器空间注意中的低级特征和解码器的高级特征进行结合,使得高层特征的每个通道都被视为一个特定类的具体反应。编码器的相关通道主要包含语义信息,解码器则多为低级信息。利用通道图之间的相互依赖性,强调相互依赖的特征图进而改进语义间的特征表示。首先对特征进行全局池化,然后将其送入卷积层进行批标准化和激活处理。经过一系列特征处理后将最终分割图与空间维度中的特征图进行元素求和,从而获得最佳效果。因此笔者引入通道注意力来突出相应的特征通道并抑制不相关的通道,最终提升分割效果。

### 1.4 条件残差卷积(CRC)

除了数据集的真实质量外,医学分割的结果一般取决于模型网络的体积容量与尺寸。因此大多模型会通过扩大卷积核的尺寸以及增加通道的数量进而提升常规卷积的容量大小,最终提升分割网络的

计算能力。但这会导致网络参数量大大增加,造成时间和算力的浪费。针对上述问题,本文用CondConv来代替常规卷积,通过CondConv对输入样本卷积核进行加权计算,从而实现高效运算能力与实验耗时的平衡。常规卷积中所有的输入样本只能够共享同一个卷积核,但CondConv能够为每个样本学习特定的卷积核,通过输入样本函数来动态计算卷积核,最终得到对应卷积核的输出结果。CondConv的计算过程为:

$$\text{Output}(x) = \sigma((\alpha_1 \cdot W_1 + \dots + \alpha_n \cdot W_n) \cdot x) \quad (1)$$

其中, $n$ 为专家数量, $\sigma$ 为激活函数, $\alpha_i$ 为 $x$ 计算后的权重标量( $i=1, \dots, n$ ), $W_i$ 则为卷积核。CondConv在卷积层中设置多个卷积核并将其参数化,通过输入端决定每个卷积核的权重,最后加权求和得到与输入端匹配的卷积核,有效提升模型分割性能。本文将条件参数化卷积与经过 $\text{Conv}1\times 1\times 1$ 的残差模块相结合形成条件残差卷积模块,结构如图3所示。条件残差卷积抑制了模型的复杂度与深度增加,防止卷积层退化,加深了对肝脏信息的感知,提升模型容量的同时保持了高效计算,有效提升肝脏影像的分割能力。




图3 条件残差卷积模块

Figure 3 Convolutional block of conditional residuals

### 1.5 深度监督

Lee 等<sup>[21]</sup>于2015年提出的深度监督网络(Deeply-Supervised Nets)提升了网络隐藏层学习过程的透明度和直接性,并确认可以将深度监督作为性能提升的方法。随着卷积神经网络深度的增加,网络的表征能力也就越强。由于肝脏内部纹理及边缘结构的复杂性,随着分割网络深度的不断增加,导致监督层无法对特征信息进行有效监督,可能会导致神经网络训练困难,造成梯度爆炸或消失。因此笔者除了直接在输出层进行监督以外,还将集成后的直接监督层加至分割网络中间的隐藏层里,然后将不同位置得到的损失按系数求和,并将此监督层得到的额外损失值传回早期层<sup>[22]</sup>。通过此方法充分

训练了模型的浅层特征,加快了模型的收敛速度,有效避免了梯度爆炸现象,最终提升了模型的分割精度。深度监督结构如图4所示。

### 1.6 混合损失函数

基于肝脏医学样本分布不平衡、边缘模糊等特点,本文使用二元交叉熵(Binary Cross Entropy Loss, BCE)损失函数和Dice相似系数(Dice Similarity Coefficient, DSC)函数的混合损失函数用于分割实验,从而缓解肝脏图像类别不平衡问题,加快模型收敛速度,实现高质量分割。本文混合损失函数定义如下:

$$L = \partial_1 L_{\text{DSC}} + \partial_2 L_{\text{BCE}} \quad (2)$$

其中, $L_{\text{DSC}}$ 为DSC函数, $L_{\text{BCE}}$ 为BCE损失函数。 $\partial$ 则作为调试损失函数的权重因子。

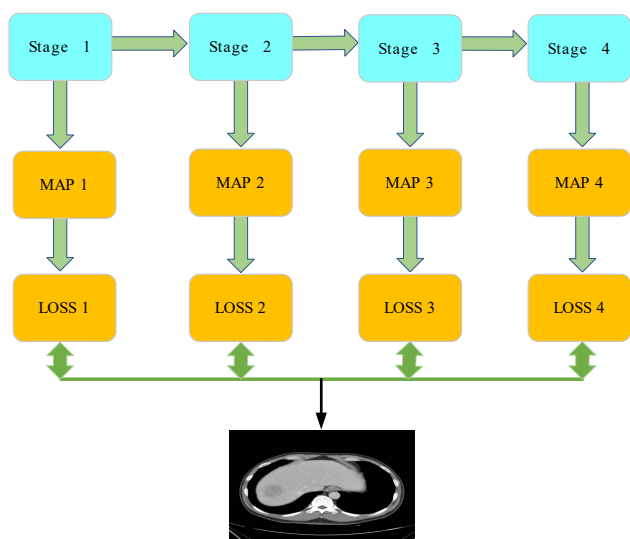


图4 深度监督模块

Figure 4 Deep supervision module

DSC 是一种集合相似度的度量函数,多用于计算两个样本点的相似度。样本间重叠区域越大,说明分割结果越好,被广泛适用于医学图像分割中。DSC 损失函数测量范围为 0~1,当 DSC 为 0 表示样本完全未重叠,越接近 1 表示重叠效果越好,为 1 则表示完整重叠。 $L_{DSC}$  公式如下:

$$L_{DSC} = 2 \frac{\sum_{i=1}^n g \times p(x)}{\sum_{i=1}^n g^2 + \sum_{i=1}^n p(x)^2} \quad (3)$$

BCE 损失函数是图像分割中广泛使用的逐像素分割方法,多用于评估分割网络性能,在医学分割中表现良好。BCE 损失函数多适合于 0/1 二分类问题中,不考虑其邻域标签。BCE 损失函数在使用过程中通过对图像的背景像素和分割像素进行加权,加快了函数的收敛速度,防止了梯度消失时导致的损失函数学习速率下降问题。 $L_{BCE}$  公式如下:

$$L_{BCE} = -g \log p(x) + (1 - g) \log (1 - p(x)) \quad (4)$$

其中, $g$  为专家真实标签概率, $p(x)$  则为实验预测样本概率。

综上,DSC 函数可以改善图像间因类别不平衡造成的影响,使得结果更加真实。BCE 损失函数能够防止梯度消失,保持稳定平滑的梯度。经过多次混合损失实验,笔者发现  $\partial_1=0.7, \partial_2=0.3$  时,肝脏分割表现最为优异。

## 2 实验分析与结果

### 2.1 实验流程

本文方法的实验流程主要分为数据预处理<sup>[23]</sup>、数据增强<sup>[24]</sup>、肝脏及肿瘤特征提取和数据可视化 4 个

部分。首先将数据预处理后的 CT 影像进行肝脏区域的分割裁剪,然后将得到的肝脏分割图作为输入端进行实验,最后将实验结果可视化处理。实验重点为不同肝癌影像中肝脏区域特征的提取。经实验发现,本文方法可以完成复杂环境下的肝脏 CT 影像分割。

### 2.2 实验数据集

本文方法为验证 CPat-Net 在肝癌分割上的有效性,采用了南方医科大学珠江医院 90 例肝癌患者的肝脏 CT 数据。每个病例的 CT 切片数量为 25~298 张,图片尺寸均为 512×512 pixel,图片位深度为 8。通过应用水平翻转、旋转、增加噪声等方法实现数据增强,提升模型的鲁棒性和泛化能力,并按照 7:2:1 的比例分别划分为训练集、验证集和测试集。本文部分影像数据如图 5 所示。



图5 肝脏 CT 影像及分割标准

Figure 5 Liver CT image and segmentation criteria

### 2.3 实验环境与参数

本实验基于 Pytorch 1.10 深度学习框架, Ubuntu16 操作系统, Nvidia GTX1080TI 显卡和 CUDA-10.1 服务器进行网络搭建工作。在实验中采用 Adam 方法来优化模型,并将初始学习率设置为  $1e-4$ , Batch Size 大小设置为 4,总迭代次数(epoch)设为 160,权重衰减指数设置为 0.001,其余参数均为默认值。

### 2.4 评价指标

为了评估 CPat-Net 的有效性,采用交并比 (Intersection Over Union, IOU), DSC, 体素重叠误差 (Volumetric Overlap Error, VOE) 和 Jaccard 系数 (Jaccard Coefficientn, JC) 进行评价。评价指标公式如下所示:

$$IOU = \frac{|PR \cap GT|}{|PR| + |GT| - |PR \cap GT|} \quad (5)$$

$$DSC = \frac{2|PR \cap GT|}{|PR| + |GT|} \quad (6)$$

$$JC = \frac{|PR \cap GT|}{|PR \cup GT|}$$

(7)

$$VOE = 1 - \frac{|PR \cap GT|}{|PR \cup GT|}$$

(8)

其中,PR为实验分割图像;GT为专家真实标注图像;IOU表示预测图像与真实分割结果的交集与并集之比;DSC和JC都是衡量实验分割结果与真实标签之间的相似性程度。DSC、IOU、JC的取值范围为0~1,且越趋向于1则分割性能越好。VOE表示为分割图像与真实标签的体积重叠误差,越接近于0表示分割效果越好。

2.5 实验结果分析

为了验证CPat-Net在肝脏及肿瘤分割中的性能优势,将CPat-Net网络与其他前沿算法采用完全相同的训练方法进行对比实验。实验选择的模型分别为UNet、Attention UNet、CENet、CSNet,并通过计算JC、IOU、DSC等指标进行性能评价,最终

将实验结果可视化处理,效果图如图6所示。如图6所示,第1列为输入端的肝脏图像,第2列为专家标注后的真实图像。第3列为UNet分割结果,可见UNet的结果不尽如人意,与实际有所差别,分割精度也无法满足实际使用。第4、5列分别为CENet、CSNet分割结果。相比于UNet,CENet和CSnet算法的分割效果大幅提升,但在外部轮廓上仍有少许误差,在边缘细节的处理上仍有不足。通过可视化的实验结果图,笔者可以发现CPat-Net相较于其他方法,在肝脏影像分割上性能更佳。肝脏轮廓基本符合标签图像,且没有发生间断现象。相比于其他方法,本文方法的条件残差卷积更好地提取了肝脏信息,特征注意模块更好地结合了全局上下文的细节信息。CPat-Net网络所得到的测试结果与真实标签结果已相当符合,分割效果更佳,肝脏边缘细节更为精准,有效解决了其余方法存在的分割不足和过分割问题。




图6 肝脏分割实验效果图  
Figure 6 Liver segmentation experiment results

从表1的肝脏分割量化结果可见,CPat-Net算法在肝脏分割上的表现更佳。相较于其他前沿方法,本方法在DSC、IOU、JC和VOE中分别达到了94.1%、90.3%、92.4%和0.106,均取得领先。

肝肿瘤分割的可视化结果如图7所示,肿瘤分割结果用红色方框标出。从肿瘤的可视化结果可见,UNet在肝脏轮廓上存在一定误差,且存在着间断现象。CENet的肝脏轮廓较为符合,但肿瘤存在一定过分割问题,而CPat-Net网络的分割结果表现更为出色。

2.6 消融实验

为评估模型方法有效性,选择UNet作为基础网络,分别将CRC、CPat模块和深度监督(DS)加入网络

表1 CPat-Net与其他方法的量化结果  
Table 1 Quantitative results of CPat-Net and other methods

方法	DSC/%	IOU/%	JC/%	VOE
UNet	89.3	85.7	86.5	0.139
ResUNet	91.6	87.4	88.6	0.121
CENet	93.4	88.9	90.9	0.116
CSNet	93.9	89.5	91.8	0.112
CPat-Net	94.1	90.3	92.4	0.106

中进行肝脏分割的消融实验。由表2数据可见,CPat注意力模块引入基础网络后,实验结果的各项指标






图7 肿瘤分割实验效果图

Figure 7 Tumor segmentation experiment results

均有不同程度的提高。其中DSC、IOU、JC和VOE达到93.1%、88.6%、90.2%和0.115。由此可见CPat模块充分结合了特征层中高级与低级的语义信息,并利用空间和通道注意力将局部特征与全局自适应融合<sup>[25]</sup>。CRC模块的引入则扩大模型容量,增强模型的计算能力,各项指标也有所提升。DS模块通过对输出层监督,加强对特征图浅层的学习,优化模型最终分割结果。实验证明,上述模块的引入均不同程度提高分割的准确度,CPat-Net实现了肝脏的精准分割。

表2 消融实验量化结果

Table 2 Quantitative results of ablation experiment

模型	DSC/%	IOU/%	JC/%	VOE
BaseNetwork	89.2	85.6	86.3	0.140
BaseNetwork+CRC	92.7	88.3	89.9	0.119
BaseNetwork+CPat	93.1	88.6	90.2	0.115
BaseNetwork+DS	91.9	87.7	89.3	0.123
CPat-Net	94.1	90.3	92.4	0.106

3 结 论

目前借助CT实现肝部影像的分割已成为术前诊断的重要凭证。因此针对肝脏自动分割能力不足这一问题,本文提出了基于条件卷积与注意力的CPat-Net肝脏分割方法。该方法首先对原始UNet网络进行改进,将条件参数化卷积替代常规卷积融入残差模块,扩大模型容量,获得更多特征的语义信息,从而提升模型计算能力。之后将改进后的残差网络用于基础网络的卷积层和跳跃连接。通过深度监督加快模型浅层信息的学习,并利用两个平行的空间和通道注意力将高层与低层次语义信息在通道间自适应结合起来,从而提升模型特征提取能力,保持分割梯度的一致性。实验证明,CPat-Net在DSC、VOE、IOU等指标上均优于其他先进网络,并利用对

比实验验证了条件参数化卷积和CPat注意模块的有效性。后续会加强对肝癌CT数据的研究,进一步改进肝脏的分割算法。

【参考文献】

[1] Sung H, Ferlay J, Siegel RL, et al. Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. Ca Cancer J Clin, 2021, 71(3): 209-249.

[2] 张欢, 刘静, 冯毅博, 等. U-Net及其在肝脏和肝脏肿瘤分割中的应用综述[J]. 计算机工程与应用, 2022, 58(2): 1-14.

Zhang H, Liu J, Feng YB, et al. Review of U-Net and its application in the segmentation of liver and liver tumor[J]. Computer Engineering and Applications, 2022, 58(2): 1-14.

[3] 宫进昌, 赵尚义, 王远军. 基于深度学习的医学图像分割研究进展[J]. 中国医学物理学杂志, 2019, 36(4): 420-424.

Gong JC, Zhao SY, Wang YJ. Research progress of medical image segmentation based on deep learning[J]. Chinese Journal of Medical Physics, 2019, 36(4): 420-424.

[4] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI). 2015, 9351: 234-241.

[5] 梁礼明, 余洁, 周琬颂, 等. 多尺度密集注意力网络用于视网膜血管分割[J]. 激光与光电子学进展, 2023, 60(6): 112-121.

Liang LM, Yu J, Zhou LS, et al. Multiscale dense attention network for retinal vascular segmentation[J]. Advances in Laser and Optoelectronics, 2023, 60(6): 112-121.

[6] Tjahyaningtjas H. Brain tumor image segmentation in MRI image[C]//2nd International Conference on Vocational Education and Electrical Engineering (ICVEE). 2018: 336.

[7] 莫春梅, 周金治, 李雪, 等. 基于改进U-Net的肝脏分割方法[J]. 中国医学物理学杂志, 2021, 38(5): 571-577.

Mo CM, Zhou JZ, Li X, et al. Liver segmentation method based on improved U-Net[J]. Chinese Journal of Medical Physics, 2021, 38(5): 571-577.

[8] Ni Z, Bian G, Zhou X, et al. RAUNet: residual attention U-Net for semantic segmentation of cataract surgical instruments[C]//26th International Conference on Neural Information Processing (ICONIP) of the Asia-Pacific-Neural-Network-Society (APNNS). 2019, 11954: 139-149.

[9] Gu ZW, Cheng J, Fu HZ, et al. CE-Net: context encoder network for 2D medical image segmentation[J]. IEEE Trans Med Imaging, 2019, 38(10): 2281-2292.

[10] 张学鹏, 王远军. 采用密集多尺度卷积网络的胰腺分割方法[J]. 小型微型计算机系统, 2022, 43(12): 2614-2619.

Zhang XP, Wang YJ. Pancreas segmentation method based on dense multi-scale convolutional network[J]. Small Microcomputer System, 2022, 43(12): 2614-2619.

[11] Wu SQ, Wang Q, Zeng QH, et al. Automatic extraction of outcrop cavity based on a multiscale regional convolution neural network[J]. Computers & Geosciences, 2022, 160: 105038.

[12] Wang JK, Lü PQ, Wang HY, et al. SAR-U-Net: squeeze-and-excitation block and atrous spatial pyramid pooling based residual U-Net for automatic liver segmentation in computed tomography[J]. Computer

- Methods Programs Biomed, 2021, 208: 106268. .
- [13] 史健锋, 高志明, 王阿川. 结合ASPP与改进HRNet的多尺度图像语义分割方法研究[J]. 液晶与显示, 2021, 36(11): 1499-1505.  
Shi JF, Gao ZM, Wang AC. Research on multiscale image semantic segmentation method combining ASPP and improved HRNet[J]. LCD and Display, 2021, 36(11): 1499-1505.
- [14] Li XM, Chen H, Qi XJ, et al. H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes[J]. IEEE Trans Med Imaging, 2018, 37(12): 2663-2674.
- [15] Zhou Z, Siddiquee MM, Tajbakhsh N, et al. UNet++: a nested U-Net architecture for medical image segmentation[C]//4th International Workshop on Deep Learning in Medical Image Analysis (DLMIA)/8th International Workshop on Multimodal Learning for Clinical Decision Support (ML-CDS). 2018, 11045: 3-11.
- [16] Yang B, Bender G, Le QV, et al. CondConv: conditionally parameterized convolutions for efficient inference [C]//33rd Conference on Neural Information Processing Systems (NeurIPS). 2019: 32.
- [17] Zhang B, Wang Y, Ding FC, et al. Multi-scale feature pyramid fusion network for medical image segmentation[J]. Int J Comput Assist Radiol Surg, 2023, 18(2): 353-365.
- [18] 陈弘扬, 高敬阳, 赵地, 等. LFSCA-UNet: 基于空间与通道注意力机制的肝纤维化区域分割网络[J]. 中国图象图形学报, 2021, 26(9): 2121-2134.  
Chen HY, Gao JY, Zhao D, et al. LFSCA-UNet: liver fibrosis region segmentation network based on spatial and channel attention mechanisms[J]. Journal of Image and Graphics, 2021, 26(9): 2121-2134.
- [19] 宣明慧, 张荣国, 胡静, 等. 空间和通道注意力多级别特征网络图像语义分割[J]. 太原科技大学学报, 2021, 42(5): 355-360.  
Xuan MH, Zhang RG, Hu J, et al. Channel and spatial attention multi-level features fusion for image semantic segmentation[J]. Journal of Taiyuan University of Science and Technology, 2021, 42(5): 355-360.
- [20] Cai Y, Wang Y. MA-Unet: an improved version of UNet based on multi-scale and attention mechanism for medical image segmentation[C]//3rd International Conference on Electronics and Communication, Network and Computer Technology (ECNCT). 2022: 12167.
- [21] Lee C, Xie S, Gallagher PW, et al. Deeply-supervised nets[C]//18th International Conference on Artificial Intelligence and Statistics (AISTATS). 2015, 38: 562-570.
- [22] Mishra S, Zhang YZ, Chen DZ, et al. Data-driven deep supervision for medical image segmentation[J]. IEEE Trans Med Imaging, 2022, 41(6): 1560-1574.
- [23] 马金林, 邓媛媛, 马自萍. 肝脏肿瘤CT图像深度学习分割方法综述[J]. 中国图象图形学报, 2020, 25(10): 2024-2046.  
Ma JL, Deng YY, Ma ZP. Review of deep learning segmentation methods for CT images of liver tumors[J]. Journal of Image and Graphics, 2020, 25(10): 2024-2046.
- [24] 陈良臣, 傅德印. 面向小样本数据的机器学习方法研究综述[J]. 计算机工程, 2022, 48(11): 1-13.  
Chen LC, Fu DY. Survey on machine learning methods for small sample data[J]. Computer Engineering, 2022, 48(11): 1-13.
- [25] Gu R, Wang GT, Song T, et al. CA-Net: comprehensive attention convolutional neural networks for explainable medical image segmentation[J]. IEEE Trans Med Imaging, 2021, 40(2): 699-711.

(编辑: 薛泽玲)