

DOI:10.19651/j.cnki.emt.2209163

# 基于密集连接和 Inception 模块的前列腺图像分割

许瑶瑶 单剑锋

(南京邮电大学电子与光学工程学院 南京 210023)

**摘要:** 针对目前磁共振影像上前列腺组织区域的自动分割存在分割精度较低和过分割等问题,提出了一种基于密集连接和 Inception 模块的 U-Net 分割算法。首先采用对比度受限的自适应直方图均衡化方法对前列腺图像进行处理,增强信息的可检测性。此外,该算法将密集连接思想引入到 U-Net 模型中,改进原有编码器和解码器的连接方式,实现多尺度语义信息的融合和传播。同时,使用由空洞卷积驱动 Inception 模块代替原有的级联卷积操作,以增加网络的宽度,增强对不同尺寸目标的特征提取与表达能力。最后,针对非组织目标存在的过分割问题,设计了一种具有分类引导功能的校正器,以减少假阳性预测。通过对 NCI-ISBI 2013 Challenge 公开数据集进行测试,以 Dice 相似系数、准确率和假阳率作为评价标准,其均值分别可达 86.12%、97.96% 和 1.11%。实验结果表明,与其他分割算法相比,该算法具有更好的分割效果。

**关键词:** 磁共振影像;前列腺分割;深度学习;密集连接

**中图分类号:** TP391 **文献标识码:** A **国家标准学科分类代码:** 510.4050

## Prostate image segmentation based on dense connections and Inception module

Xu Yaoyao Shan Jianfeng

(School of Electronic and Optical Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

**Abstract:** Aiming at the problems of low segmentation accuracy and over-segmentation in the current automatic segmentation of prostate tissue regions on magnetic resonance images, a U-Net segmentation algorithm combining dense connections and Inception modules was proposed. Firstly, the contrast-limited adaptive histogram equalization method was used to process the prostate image to enhance the detectability of the information. In addition, the algorithm introduces the idea of dense connection into the U-Net model, improves the connection method of the original encoder and decoder, and realizes the fusion and dissemination of multi-scale semantic information. Meanwhile, the Inception module driven by atrous convolution is used to replace the original concatenated convolution operation to increase the width of the network and enhance the feature extraction and expression capabilities for objects of different sizes. Finally, for the over-segmentation problem of non-organized objects, a corrector with classification-guided function is designed to reduce false positive predictions. By testing on the public dataset of NCI-ISBI 2013 Challenge, using Dice similarity coefficient, accuracy rate and false positive rate as evaluation criteria, the mean values can reach 86.12%, 97.96% and 1.11%, respectively. The experimental results show that this algorithm has better segmentation effect than other segmentation algorithms.

**Keywords:** magnetic resonance imaging; prostate segmentation; deep learning; dense connections

## 0 引 言

前列腺癌是全世界最常见的癌症之一,根据统计数据<sup>[1]</sup>显示,前列腺癌在男性癌症中所占比例约 26%,致死率约 8%<sup>[1]</sup>。在我国,前列腺癌患者 5 年生存率仅为 53.5%,而美国前列腺癌患者的 5 年生存率高达 98%。其中主要的

因素在于中国超 70% 的前列腺癌患者,初诊时已经是中晚期,丧失了根治的机会<sup>[2]</sup>。因此前列腺疾病早发现并及时接收治疗可以有效降低前列腺癌患者的死亡率。磁共振成像(magnetic resonance imaging, MRI)技术是检查前列腺疾病的有效手段,从 MR 图像中分割和提取前列腺组织可以帮助医生诊断和评估前列腺疾病<sup>[3]</sup>。因此,图像分割

收稿日期:2022-03-04

在生物医学工程领域具有十分重要的意义和应用价值。

初期,为了实现医学图像的自动分割,研究人员提出基于传统的图像处理算法进行图像分割,例如基于区域的分割算法<sup>[4]</sup>、基于水平集的分割算法<sup>[5]</sup>和基于图谱的分割算法<sup>[6]</sup>,缺点是医学图像通常具有对比度低、组织纹理复杂和边界区域模糊等特点,极大地限制了此类图像分割算法的效果和应用场景。

随着计算机技术的快速发展,深度学习技术已广泛应用于图像处理,并且在医学图像分割领域取得了很大的进展。卷积神经网络(convolutional neural network, CNN)是深度学习中经典的网络结构,一般由卷积层、池化层和全连接层组成,可以在数据中自动提取特征且泛化能力较强,广泛应用于图像分类、图像分割和目标检测等领域。Long 等<sup>[7]</sup>提出了一种全卷积网络(fully convolutional networks, FCN)用于图像语义分割,通过将 CNN 中的全连接层替换为卷积核为 1 的卷积,实现了端到端、像素到像素的网络训练,无需任何额外的后处理即可输出分割结果,成为深度学习在语义分割应用中的开山之作。Ronneberger 等<sup>[8]</sup>在 FCN 基础上进行扩展,提出了编解码对称的 U-Net 网络结构,创新性的提出跳跃连接操作,将低分辨率和高分辨率的特征图进行融合,有效地避免了因下采样操作而导致的空间信息丢失的问题,且在只有较少的训练数据时,仍可以获得很好的性能。赵斐<sup>[9]</sup>提出一种基于金字塔注意力机制的语义分割模型,编码部分通过基于通道注意力机制的金字塔池化结构从多元数据中提取多层次特征,解码部分对所得的多层次特征逐一前向融合,优化分割边界。为了扩展网络的深度,加强上下语义信息的传播,研究人员将密集连接思想引入到分割任务中,其应用类型可分为两类:一类为局域密集连接,即在传统的卷积内部引入密集块,例如 Guan 等<sup>[10]</sup>提出的 Full Dense-UNet,但这种密集连接方式并没有考虑不同尺度特征的联系,具有信息传播的局限性;另一类为全局密集连接,即将当前层特征与其他层特征进行连接,例如 Zhou 等<sup>[11]</sup>提出了一种 U-Net++ 网络,通过集成不同深度的 U-Net,增强了网络对各种尺寸对象的分割质量,但该模型当前层只与更高层的特征进行融合,缺少浅层语义信息,并且由于模型中间涉及大量的卷积运算,因此其计算成本较大。

以上所提及的网络模型使用的是常规卷积,具有感受野较小的缺点,影响网络对形状可变目标的学习。另一方面,对于生物医学图像分割任务而言,分割网络浅层常出现背景噪声的干扰,由此引起了对不含目标图像的过度分割问题。为了解决上述问题,本文主要有以下几点改进:

1)为了增加网络的宽度,丰富特征的表达,设计了带有空洞卷积的 Inception 模块,用来代替传统的卷积操作。

2)基于 U-Net 网络架构重新设计并实现了真正意义上的全局多尺度密集连接网络,即空洞密集连接 U 型网络(atrous dense connections UNet, ADC-UNet),以实现更多

目标信息和像素信息的融合,改善网络的分割结果。

3)针对医学图像假阳性率较高的问题,设计了一种基于残差网络<sup>[12]</sup>的分类校正器,用于区分图像是否含有前列腺组织,通过在分割模型后嵌入此模块,减少过度分割问题。

## 1 方法论

本文的算法流程如图 1 所示。首先在训练阶段,对输入的图像进行预处理,接着将处理完毕的训练样本输入到分类校正器和 ADC-UNet 分割模型中进行训练,得到最优的模型。然后在测试阶段,将测试图像预处理后送入到已训练好的分类校正器和 ADC-UNet 模型中,分别获得图像是否存在前列腺组织以及分割预测图,将二者相乘,得到最终的分割结果。

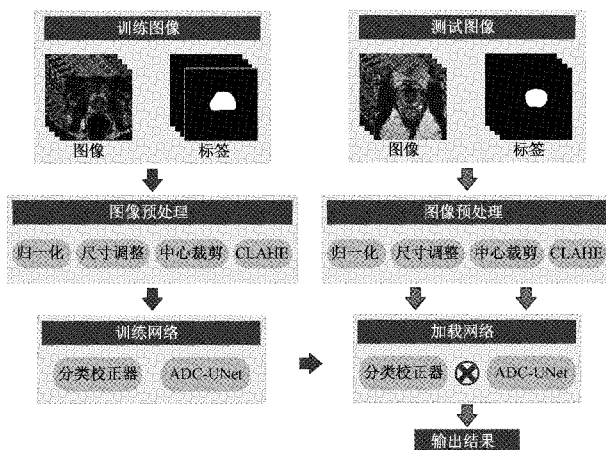


图 1 算法流程

### 1.1 由空洞卷积驱动的 Inception 模块

在前列腺图像分割任务中,我们所感兴趣的区域往往是可变的,这就要求分割网络应具有良好的鲁棒性,能够分析出不同尺寸对象。Szegedy 等<sup>[13]</sup>提出 Inception 模块,通过对不同尺度卷积核进行并行操作,然后将提取到的特征图进行拼接,达到检测图像不同尺寸区域的目的。但 Inception 模块感受野仍受限制,如果直接扩大卷积核,将导致模型复杂和参数增加。

受空洞卷积<sup>[14]</sup>的启发,在 Inception 模块中引入带有膨胀系数的空洞卷积,可实现在不增加额外参数的前提下,扩大模型感受野,以增强网络对复杂语义信息的学习能力。由空洞卷积驱动的 Inception 模块结构如图 2 所示,首先对输入特征图进行 3 次空洞卷积,其卷积核为 3,膨胀系数分别为 1、3、5,然后再进行常规卷积操作。为了获取不同特征图之间的相关性,将 3 个不同尺度的特征输出进行拼接,即可得到更丰富的特征信息,最后通过卷积核为 1 的卷积操作和线性整流函数(linear rectification function, ReLU)激活后输出。

考虑到前列腺 MR 图像具有尺寸大小可变以及噪声干扰等特点,将 U-Net 模型中的连续双卷积层替换为本文提

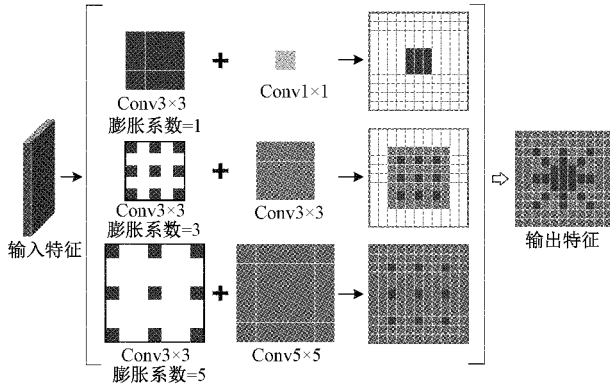


图 2 由空洞卷积驱动的 Inception 模块

出的带有空洞卷积的 Inception 模块,既增强了网络对不同尺寸目标的分析能力,又可以加深网络深度,更有效地提取深层次的特征。

### 1.2 多尺度密集连接

为了加强网络当前层的特征传播,提高分割精度,本文基于 U-Net 架构,通过在编码器、译码器以及跳跃连接引入密集连接机制,以促进不同尺度的特征融合,改善编码器和译码器间上下文信息的传播。

经典 U-Net 的编码器和译码器结构如图 3(a)所示,其中  $X^l$  和  $Y^l$  表示编码器和译码器当前层的输出,  $X^{l-1}$  和  $Y^{l-1}$  表示编码器和译码器上一层的输出。编码器端运算如式(1)和(2)所示,将  $X^{l-1}$  进行下采样得到  $X^{l-down}$ ,之后进行卷积操作可得到当前层编码器的输出  $X^l$ 。

$$X^{l-down} = Downsample(X^{l-1}) \quad (1)$$

$$X^l = Conv(X^{l-down}) \quad (2)$$

译码器端运算如式(3)~(5)所示,将上一层的输出  $Y^{l-1}$  进行上采样得到  $Y^{l-up}$ ,之后与对应层的编码器输出  $X^l$  进行通道拼接得到  $Y^{l-concat}$ ,最后通过卷积操作即可获得译码器输出  $Y^l$ 。

$$Y^{l-up} = Upsample(Y^{l-1}) \quad (3)$$


$$Y^{l-concat} = Concat(X^l, Y^{l-up}) \quad (4)$$

$$Y^l = Conv(Y^{l-concat}) \quad (5)$$


本文基于此结构进行扩展,得到了具有多尺度特征融合的编码器、跳跃连接和译码器,如图 3(b)所示,其中  $n$  代表与之前层融合的层数,起到调节网络密集程度的作用,例如当  $n = 1$  时,等效于图 3(a)所示的结构。具体来说,对于编码器部分,在对  $X^{l-down}$  进行卷积操作前,先将之前  $n$  层的输出进行逐元素相加得到  $X^{l-add}$ ,如式(6)所示。接着进行卷积操作即可得到编码器的输出  $X^l$ 。

$$X^{l-add} = Add(X^{l-down}, \dots, X^{l-down}) \quad (6)$$

译码器部分,在将对应层的编码器输出  $X^l$  与  $Y^{l-up}$  进行拼接前,将  $X^l$  与编码器上一层输出  $X^{l-1}$  和下一层输出  $X^{l+1}$  以及译码器之前层输出进行逐元素相加得到  $Y^{l-add}$  再进行拼接操作,如式(7)和(8)所示。最后将拼接后的  $Y^{l-concat}$  进



(a) 经典的编码器、译码器结构



(b) 改进后的的编码器、译码器结构

图 3 改进前后的编码器和译码器结构图

行卷积操作,得到译码器当前层的输出  $Y^l$ 。

$$Y^{l-add} = Add(X^{l-1}, X^l, X^{l+1}, Y^{l-up}, \dots, Y^{l-up}) \quad (7)$$

$$Y^{l-concat} = Concat(Y^{l-add}, Y^{l-up}) \quad (8)$$

其中,需要注意的是,当译码器处于第一层时,只融合译码器上一层的输出和对应层的编码器输出,如式(9)所示。当译码器处于最后一层时,则融合译码器之前所有层的输出以及编码器对应层和下一层的输出,如式(10)所示。

$$Y^{l-first} = Add(X^{l-1}, X^l) \quad (9)$$

$$Y^{l-last} = Add(X^l, X^{l+1}, Y^{l-up}, \dots, Y^{l-up}) \quad (10)$$

改进后的空洞密集连接 U 型网络(ADC-UNet)结构如图 4 所示。引入密集连接机制的 U-Net 模型整体上继承了 U-Net 网络的对称结构,不同的是网络的每一层输入都由之前层的输出组成,使得更深层次的网络层可以重复利用前层中提取的特征。

### 1.3 分类校正模块

由于医学图像具有模糊、噪声干扰和边界不清楚等特点,导致对其进行分割时,很容易出现假阳性预测,针对这一问题,本文在分割网络后增加一个额外的分类器,即分类校正器(classification corrector module, CCM),对分割结果进行后处理,缓解分割网络对不含前列腺组织图像的过分割问题。

其结构如图 5 所示,首先通过使用 ResNet101<sup>[12]</sup>作为

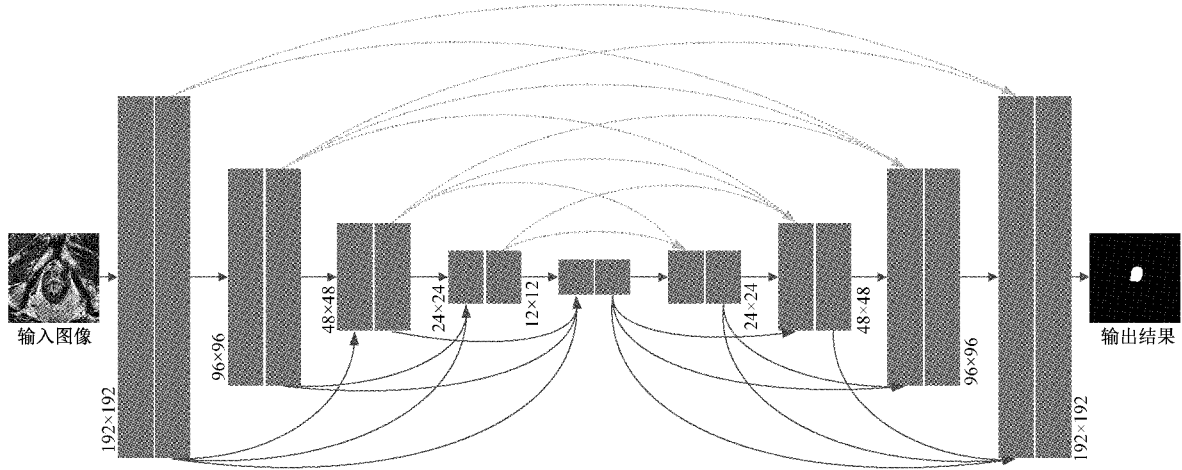


图 4 空洞密集连接 U 型网络(ADC-UNet)结构图

骨干网络对输入的图像进行特征提取,然后经过卷积核为 1 的卷积运算将通道数压缩为 2,再经过最大池化和激活后输出一个二维向量,用来表示有无前列腺组织的概率,例如图中的[0.8,0.2]中的 0.8 表示图像不含有前列腺组织的概率。反之,0.2 表示图像中含有前列腺组织的概率。将此向量与标签向量进行二分类交叉熵函数优化。训练好的分类校正器,即可判断一个图像是否包含前列腺组织。最后将 ADC-UNet 分割模型输出的结果与分类校正器的结果相乘,实现对不含前列腺组织错误分割的校正功能。




图 5 分类校正器结构图

### 1.4 损失函数

损失函数是衡量真实值和模型预测值之间概率分布差异的函数,帮助模型在训练期间寻找最优的权重参数。本文分割算法需要模型预测出每个像素点是属于背景还是前景,属于二分类问题,其常用的损失函数是二分类交叉熵(binary cross entropy, BCE)函数,但其在处理前景像素远小于背景像素时,会使得模型偏向于背景,导致性能变差。而在前列腺图像分割任务中,前列腺组织只占整张图像的小部分,甚至有的图像不包含前列腺组织。针对这一问题,本文采用 Dice Loss 函数<sup>15</sup>来代替二分类交叉熵函数,其定义如下:

$$Loss(P, G) = 1 - \frac{2 \sum_{i=1}^N p_i g_i + \epsilon}{\sum_{i=1}^N p_i + \sum_{i=1}^N g_i + \epsilon} \quad (11)$$

其中,  $N$  表示像素点个数,  $p_i \in [0, 1]$  表示分割结果图中像素点  $i$  的概率值,  $g_i \in [0, 1]$  表示像素点  $i$  的标签值,  $\epsilon$  表示光滑算子,用于避免分母为 0 的情况。

## 2 实验设置

### 2.1 数据集与预处理

本文实验采用的 NCI-ISBI 2013 公开数据集<sup>16</sup>由训练集、验证集和测试集 3 个部分组成,各部分包含不同的病例样本。其中训练集含有 60 个病例共 1 544 张切片,用于训练网络模型;验证集含有 10 个病例共 261 张切片,用于调整模型的超参数;测试集含有 10 个病例共 271 张切片,用于评估算法性能。

由于医学图像具有尺寸不同、对比度低和噪声干扰等特点,因此对其进行预处理是很有必要的。本文对数据集进行的预处理措施如下:

1) 计算原始图像  $Z$  的像素平均值  $\mu$  和标准差  $\delta$ , 即:

$$\mu = \frac{\sum_{i=1}^N Z_i}{N} \quad (12)$$

$$\delta = \sqrt{\frac{\sum_{i=1}^N (Z_i - \mu)^2}{N}} \quad (13)$$

其中,  $N$  表示图像像素数量。

2) 将原始图像中的每一个像素减去平均值  $\mu$ , 再除以标准差  $\delta$ , 完成归一化处理, 即:

$$x = \frac{Z - \mu}{\delta} \quad (14)$$

其中,  $x$  表示处理后的像素值。

3) 进行图像尺寸调整, 通过使用最近邻插值算法将图像统一缩放到  $320 \times 320$  像素大小。

4) 计算能够包含数据集中所有切片的前列腺组织的最小边界框为  $192 \times 192$  像素。然后, 将图像中心裁剪为  $192 \times 192$ , 保证所有的前列腺组织都被包含在边界框内。

5)采用自适应直方图均衡化(CLAHE)对裁剪后的图像进行处理,增加图像的亮度及对比度。

预处理前后的图像如图 6 所示,可以看出,经过预处理后的图像亮度和对比度得到增强。并且图像进行统一的中心裁剪之后,既方便网络模型处理,又可以减少背景负样本的干扰,节约计算资源。




图 6 预处理前后图像

## 2.2 实验环境

实验的硬件环境为 NVIDIA RTX A4000 显卡, Intel(R) Xeon(R) Gold 5320 处理器, 32 GB 的运行内存。软件环境为 Ubuntu 20 环境, 使用 PyTorch 1.8.1 深度学习框架搭建神经网络。训练过程中, Batch 为 32, 设置 epoch 为 200, 使用 Adam 优化器更新参数, 初始学习率为 0.000 1, 当验证集的损失连续两个训练周期不再降低时, 学习率衰减为原来的 1/10。

## 2.3 评价指标

为了客观衡量所提算法的分割性能, 本文选用 Dice 相似性系数 (dice similarity coefficient, DSC)、准确率 (accuracy, ACC) 以及假阳率 (false positive rate, FPR) 对算法的分割结果进行评测, 各公式定义如下:

$$DSC = \frac{2TP}{2TP + FP + FN} \quad (15)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (16)$$

$$FPR = \frac{FP}{FP + TN} \quad (17)$$

其中, 真阳性 (true positive, TP), 表示网络输出的前列腺组织, 实际上也是前列腺组织。真阴性 (true negative, TN), 表示网络输出的背景区域, 实际上也是背景区域。假阳性 (false positive, FP), 表示网络输出的前列腺组织, 实际上是背景区域。假阴性 (false negative, FN), 表示网络输出的背景区域, 实际上是前列腺区域。

## 3 实验结果与分析

### 3.1 消融实验

为了验证本文算法的改进策略, 本节做了以下 3 个部分的对比实验, 分析分类校正器、带有空洞卷积的 Inception 模块以及密集连接机制对算法分割性能的影响, 分割结果如表 1 所示。

3 种改进措施使得准确率、DSC 值和假阳率均有提升。

表 1 不同改进策略对分割结果的影响 %

方法	ACC	DSC	FPR
U-Net	97.18±0.52	83.65±2.93	1.78±0.15
U-Net+CCM	97.30±0.49	84.21±2.81	1.67±0.14
ADC-UNet(n=1)	97.66±0.51	84.43±3.15	1.50±0.29
ADC-UNet(n=2)	97.78±0.41	85.22±2.49	1.41±0.19
ADC-UNet(n=3)	97.90±0.48	85.77±2.41	1.21±0.22
ADC-UNet(n=4)	97.93±0.34	85.93±2.12	1.12±0.31
本文+CCM	<b>97.96±0.34</b>	<b>86.12±2.01</b>	<b>1.11±0.29</b>

第 1 部分测试分类校正器效果: 通过将 U-Net 模型和本文提出的 ADC-UNet 模型输出结果经过分类校正器处理, 假阳率的平均值分别减小到 1.67% 和 1.11%, 准确率和 DSC 值也有所提升, 说明在分割模型中加入分类校正器可以缓解对不含前列腺组织图像的过分割问题, 提升分割精度。第 2 部分验证带有空洞卷积的 Inception 模块: 当 ADC-UNet 模型密集程度  $n=1$  时, 模型结构等效于 U-Net 模型, 但卷积操作替换为由空洞卷积驱动的 Inception 模块。由实验结果可知, DSC 值提升最为显著, 达到了 84.43%, 准确率和假阳率也有所提升, 分别达到 97.66% 和 1.50%, 这是因为此模块具有 3 个不同尺度的特征提取能力, 可以增强模型对不同尺寸目标的分割能力。在此基础上, 引入不同膨胀系数的空洞卷积, 在不增加参数的前提下扩大感受野, 进一步提高模型分割精度。第 3 部分讨论密集连接机制的密集程度  $n$  对分割结果的影响, 由结果可知,  $n$  取值越大, 密集程度越高, 分割精度越好, 准确率、DSC 值和假阳率平均值分别可达 97.93%、85.93% 和 1.21%。这是因为通过将高层次和低层次的不同尺度的语义信息相融合, 可以提高特征的重用性, 从而获得更好的分割结果。

### 3.2 与其他分割算法比较

为了更好地验证本文算法的分割性能, 本文将与经典的 FCN<sup>[7]</sup>、U-Net<sup>[8]</sup>、PSPNet<sup>[18]</sup> 和 U-Net++<sup>[11]</sup> 算法进行对比。不同分割算法的结果如表 2 所示。

表 2 不同分割算法的结果对比 %

方法	ACC	DSC	FPR
FCN <sup>[7]</sup>	96.28±0.84	78.86±3.30	3.19±1.09
U-Net <sup>[8]</sup>	97.18±0.52	83.65±2.93	1.78±0.15
PSPNet <sup>[18]</sup>	97.51±0.30	83.41±2.17	1.57±0.23
U-Net++ <sup>[11]</sup>	97.78±0.29	85.15±1.61	1.38±0.16
本文算法	<b>97.96±0.34</b>	<b>86.12±2.01</b>	<b>1.11±0.29</b>

由结果可知, 本文算法准确率、DSC 值和假阳率的平均值分别为 97.96%、86.12% 和 1.11%, 均优于其他算法, 说明本文提出的分割模型有利于前列腺分割。为了更直观地说明本文算法的分割性能, 选择了 5 个不同病例的切片 A、B、C、D、E 在不同算法上的分割结果, 如图 7 所示。

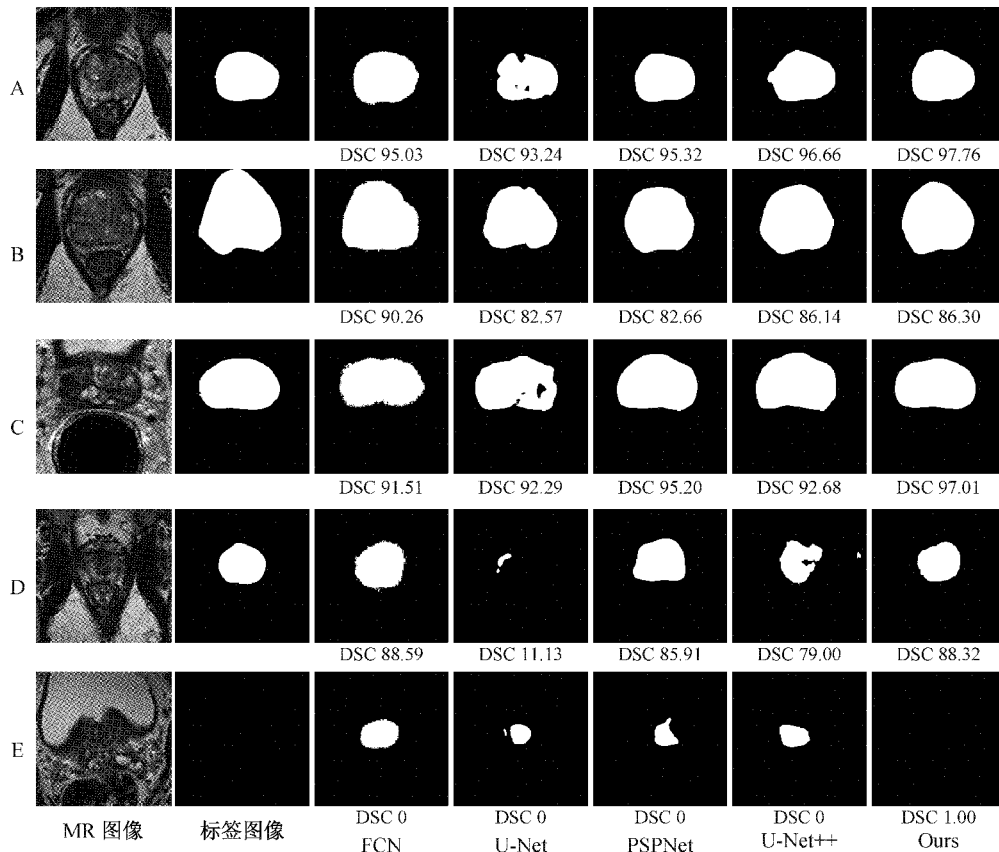


图 7 不同算法的分割结果图对比

切片 A 中的 MR 图像比较清晰,边界也较为明显,因此各个算法的分割结果均属良好,本文的分割算法 DSC 值甚至可高达 97.76%,但是 U-Net 的结果图出现了比较明显的漏割问题,同时 U-Net++ 结果图左侧出现了过分割的问题,使得分割边缘不够平滑。

切片 B 中与切片 A 类似,不过前列腺组织面积更大,考验算法对于大目标的分割性能。由结果可知,虽然本文算法在客观指标上弱于 FCN 算法,但 FCN 分割结果的边缘出现大量的毛刺,而本文算法结果主观上更贴近于标签图像,因此本文算法针对大目标的分割性能要优于 FCN 以及其他算法。

切片 C 的边界相较于 A 和 B 两张切片更为模糊,且前列腺组织内含有噪声干扰,各个算法对其进行分割的客观指标良好,但 FCN 分割结果边缘依旧出现了大量毛刺和 U-Net 分割结果图存在欠分割问题。而本文所提出的分割算法结果图不管是客观指标还是主观上都表现最优。

对于切片 D 的分割难度是最大的,其图像模糊,组织边界也不明显,导致各个算法对其分割的表现都不太出色,尤其是 U-Net 和 U-Net++ 的分割结果出现严重的欠分割问题,综合客观指标和主观感受而言,本文提出的算法结果较优。

切片 E 中不含前列腺组织,除本文算法外,其他四种算法均出现了不同程度的假阳性预测,这是因为本文提出的分类校正器经过训练,可以很好的对图像是否含有前列腺组织进行判断,通过将此模块嵌入到本文模型后,可以减少分割模型的过分割问题。

## 4 结 论

在本文中,针对常规卷积感受野受限的问题,提出了由空洞卷积驱动的 Inception 模块,扩大卷积感受野,充分提取有效的语义信息。模型架构方面,通过在 U-Net 中引入密集连接机制,扩展了编码器和译码器的连接方式,实现了全局性的多尺度密集连接网络。此外,针对生物医学图像分割假阳性较高的问题,本文提出了一种分类校正器,修正对不含前列腺组织图像过分割的问题。最后,通过实验可知,本文模型密集程度越高,分割性能越强,与其他算法相比,对具有不同尺寸目标和有噪声干扰图像的分割效果更好,可以更有效地分割前列腺组织。但是本文算法只针对一个数据集进行了性能评估,针对不同数据集的泛化能力仍需进一步的验证。

## 参考文献

- [1] 2017 中国城市癌症最新数据报告[J]. 记者观察, 2017(5):62-64.

- [2] SIEGEL R L, MILLER K D, FUCHS H E, et al. Cancer statistics, 2021[J]. CA: A Cancer Journal for Clinicians, 2021, 71(1), DOI:10.3322/caac.21654.
- [3] SHARP G, FRITSCHER K D, PEKAR V, et al. Perspectives on automated image segmentation for radiotherapy[J]. Medical Physics, 2014, 41(5), DOI: 10.1118/1.4871620.
- [4] QIU W, YUAN J, UKWATTA E, et al. Dual optimization based prostate zonal segmentation in 3D MR images [J]. Medical Image Analysis, 2014, 18(4): 660-673.
- [5] 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, 237(9): 146-152.
- [6] MEYER A, RAKR M, SCHINDELE D, et al. Towards patient-individual PI-RADS v2 sector map: CNN for automatic segmentation of prostatic zones from T2-Weighted MRI [C]. 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI), IEEE, 2019: 696-700.
- [7] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [8] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[J]. Springer International Publishing, 2015, 234-241.
- [9] 赵斐. 基于金字塔注意力机制的遥感图像语义分割[J]. 国外电子测量技术, 2019, 38(8): 150-154.
- [10] GUAN S, KHAN A A, SIKDAR S, et al. Fully dense UNet for 2-D sparse photoacoustic tomography artifact removal[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 24(2): 568-576.
- [11] ZHOU Z, SIDDIQUEE M, TAJBAKHS N, et al. UNet++: A nested U-Net architecture for medical image segmentation[C]. 4th Deep Learning in Medical Image Analysis Workshop, 2018: 3-11.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [13] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [14] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions [J]. Arxiv Preprint, 2015, Arxiv: 1511.07122.
- [15] 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), IEEE, 2016: 565-571.
- [16] CLARK K, VENDT B, SMITH K, et al. The cancer imaging archive(TCIA): Maintaining and operating a public information repository[J]. Journal of Digital Imaging, 2013, 26(6): 1045-1057.
- [17] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2881-2890.

### 作者简介

许瑶瑶, 硕士研究生, 主要研究方向为人工智能、深度学习、生物医学图像处理等。

单剑锋, 工学博士, 副教授, 主要研究方向为无线通信系统中的信号处理技术、智能信息处理、目标识别等。

E-mail: 1020020921@njupt.edu.cn