

DOI:10.16136/j.joel.2022.05.0426

基于多尺度空洞分离卷积的 U-Net 分割前列腺图像

邵党国^{1*}, 黄俊辉¹, 徐 慧²

(1. 昆明理工大学 信息工程与自动化学院, 云南 昆明 650500; 2. 昆明医科大学 第一附属医院, 云南 昆明 650500)

摘要: 前列腺核磁共振(magnetic resonance, MR)影像切片后发现有些影像没有有效的边缘信息, 这导致无法明确定位边缘位置, 进而无法分割出前列腺。同时, 传统的卷积网络需要参数量庞大占用模型的存储空间过多。本文提出了一种结合多尺度空洞可分离卷积和通道注意力的 U-Net 来分割前列腺的方法。首先, 对 50 个 3 维(three-dimensional, 3D)前列腺样品进行切片并对切片后图像进行对比度增强。随后, 将处理后数据输入到残差 U-Net 中, 使用多尺度空洞卷积和通道注意力作为编码-解码单元来提取特征信息。最后, 使用 Dice 系数和豪斯多夫距离(Hausdorff distance, HD)来评估分割结果。实验在 PROMISE12 挑战赛数据集验证, 最终 Dice 系数和 HD 分别为 88.13%、14.17 mm, 参数量和存储空间降低 57%。结果表明, 本文方法不仅可以分割出没有有效边缘的前列腺区域提高其分割精度而且能有效的降低参数量和存储空间, 能够应用于模糊边缘的医学图像中。

关键词: 数字图像处理; 空洞可分离卷积; 多尺度特征提取; 通道注意力; 图像分割

中图分类号: TP391.7 **文献标识码:** A **文章编号:** 1005-0086(2022)05-0554-07

Segmentation of prostate image based on U-Net of multi-scale dilated separable convolution

SHAO Dangguo^{1*}, HUANG Junhui¹, XU Hui²

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming, Yunnan 650500, China; 2. First Affiliated Hospital of Kunming Medical University, Kunming, Yunnan 650500, China)

Abstract: After prostate magnetic resonance (MR) image slices, it is found that some images do not have effective edge information, which makes it impossible to clearly locate the edge position, and thus cannot segment the prostate. At the same time, the traditional convolutional network requires a large amount of parameters and takes up too much storage space of the model. This paper proposes a method to segment the prostate using U-Net that combines multi-scale dilated separable convolution and channel attention. First, slice 50 three-dimensional (3D) prostate samples and perform contrast enhancement on the sliced images. Subsequently, the processed data is input into the residual U-Net, and the multi-scale dilated convolution and channel attention are used as the encoding-decoding unit to extract the feature information. Finally, the Dice coefficient and Hausdorff distance (HD) are used to evaluate the segmentation results. The experiment was verified on the PROMISE12 challenge dataset, and the final Dice coefficient and HD were 88.13% and 14.17 mm, respectively, and the parameter amount and storage space were reduced by 57%. The results show that this method can not only segment the prostate area without effective edges to improve its segmentation accuracy, but also effectively reduce the parameter amount and storage

* E-mail: 23014260@qq.com

收稿日期: 2021-06-20 修订日期: 2021-08-14

基金项目: 国家博士后面上科学基金(2016M592894XB)、云南省基础研究面上专项(202001AT070047)资助项目

space, and can be applied to medical images with blurred edges.

Key words: digital image processing; dilated separable convolution; multi-scale feature extraction; channel attention; image segmentation

1 引言

前列腺癌是危害男性健康的疾病,因此帮助医生准确判断病情尤为重要。当医生对患者的前列腺疾病诊断之前,首先需要准确定位出前列腺组织的具体位置,才能进一步对前列腺组织区域进行分析与处理^[1,2]。因此,对前列腺组织区域的分割是进行前列腺疾病诊断基础且重要的一步,如果无法得到正确的前列腺组织区域分布,那后续的病理学疾病分析将无法进行。但是人工分割磁共振图像不仅需要时间和精力,而且在很大程度上依赖于经验。不仅如此,不同医生手工分割的结果也存在差异。因此,研究者们提出了许多方法来辅助医生分割医学图像^[3,4]。

LONG 等^[5]提出了全卷积神经网络(fully convolutional networks, FCN)成功的将神经网络应用到图像分割领域,从此研究者们广泛研究基于深度学习的医学图像分割方法。TIAN 等^[6]采用改进的 FCN 结构并取得了不错的前列腺分割效果。ZHU 等^[7]提出了一种用于磁共振前列腺图像分割的双向卷积递归层深度神经网络。除了利用切片内的上下文和特征,所提出的模型还将前列腺切片视为数据序列,并利用切片间的上下文来辅助分割。RONNEBERGER 等^[8]提出 U 型神经网络(U-Net)应用于细胞影像分割,该神经网络可以在小数据集上训练并取得良好的效果。MILLETARI 等^[9]基于 U-Net 提出了 V-Net 结构,并将其成功的应用到前列腺磁共振成像(magnetic resonance imaging, MRI)分割中。YU 等^[10]提出混合残差连接的 3 维神经网络架构用于前列腺 MRI 分割。该架构利用 3D 空间上下文信息来执行高效、精确和体积到体积的预测和利用残差连接来提高网络的训练效率和鉴别能力,从而提高了前列腺区域的分割精度。WANG 等^[11]开发了一种新颖的深度神经网络,其利用注意机制来选择性地利用前列腺分割的多级特征来减少噪音的影响,并以相似的强度抑制前列腺周围的组织。这些方法使用标准的卷积神经网络(convolutional neural network, CNN)导致模型冗余度高、参数量大,保存模型所需的存储空间大。为了轻量化神

经网络结构,CHOLLET^[12]提出了用深度可分离卷积代替传统的卷积。CHEN 等^[13]提出了一种基于深度可分离卷积的空间金字塔池化模块,并将其应用于语义图像分割。虽然这些方法在有限数据下提高了网络和训练效率的表示能力,但是在缺乏边界信息的顶点和基本区域的切片中获得准确的分割仍然是具有挑战性的问题。

针对上述问题,本文提出了一种具有结合多尺度空洞可分离卷积(multi-scale dilated separable convolution, MDSC)和通道注意力机制 U-Net 的方法。该方法将深度可分离卷积与空洞卷积的优点结合起来形成空洞可分离卷积,该结构既能扩大感受野同时还能减少参数。同时,该方法将 MDSC 和通道注意力结合起来应用于残差 U-Net,该结构能有效提高模糊边缘图像的边缘分割能力。本文在国际医学影像计算和计算机辅助干预会议 2012(MICCAI2012)主办的前列腺影像分割挑战赛的数据集上评估。

2 方法

2.1 MDSC 和通道注意力的残差 U-Net 建立

医生手动获得并分割的轮廓如图 1 所示。从图 1 中可以发现,不同位置的前列腺切片的边缘模糊程度不同,有些位置普通人用肉眼很难区分边界,有些部分可能医生都会看漏,所以对于计算机辅助分割而言也是一个重要挑战。为了在前列腺切片图像没有有效的边缘信息的情况下,任然能够较为准确的定位边缘位置,进而辅助医生准确的分割出前列腺。本文提出了 MDSC 和通道注意力的残差 U 型全卷积网络的模型。




图 1 由有经验的放射科医生
手动获得并分割的轮廓(白色曲线标记)

Fig. 1 The contour manually obtained and segmented by an experienced radiologist (marked by white curve)

多尺度空洞分离卷积和通道注意力机制 U 型全卷积网络结构如图 2 所示,主要由 3 部分组成,分别是主网络结构、MDSC 和通道注意力。主网络结构使用残差 U-Net 结构,该网络可以有效提取图像的深层和浅层特征,并将不同层次的特征信息拼接起来。MDSC 结构使用扩张率分别为 1、2 和 3 的深度卷积来提取图像特征,通过扩大感受野提高网络提取特征的能力同时降低模型冗余度。通道注意力通过给输入特征图重新分配权重进而提高分割性能。

2.2 主网络结构

残差 U-Net 结构,主要分为 3 部分:下采样、上采样及跳跃连接,首先将该网络分为左右部分来分

析,左边是下采样的过程,即编码器。编码器通过 MDSC block 和池化来实现,图像尺寸经过编码器后减小,编码器提取一些浅显的特征。右边部分是上采样的过程,即解码器。解码器通过 MDSC block 和反卷积来实现,图像尺寸经过解码器后增大,通过卷积和上采样来获取一些深层次的特征。中间通过 concat 的方式,将编码阶段获得的特征图同解码阶段获得的特征图拼接在一起,目的是结合深层次和浅层次的特征,细化图像。本文使用的下采样层和上采样层都是 7 层,为了防止网络退化现象,本文采用残差网络结构来处理这个问题,同时残差结构还能加快网络的收敛^[14]。




图 2 多尺度空洞可分离卷积和通道注意力机制 U 型全卷积网络结构

Fig. 2 Multi-scale dilated separable convolution and channel attention mechanism U-Net structure

2.3 多尺度空洞可分离卷积

最初开发空洞卷积是在 *algorithm à trous* 中,为了做小波分解^[15]。空洞卷积的主要思想是在卷积核中插入孔洞,孔洞的值用“0”来填充以增加图像的分辨率,从而可以在神经网络中提取致密特征。深度可分离卷积最早应用^[12],并不同于标准卷积操作。其分 2 步进行,第一步用与输入通道数相同数量的

卷积核对每个输入通道分别进行卷积,这样在 1 次卷积后,输出层具有与输入层相同数量的特征图,这称为深度卷积,从上述可以得出深度卷积无法增加输出特征图,并且这种运算对输入层的每个通道独立进行卷积运算,没有有效的利用不同通道在相同空间位置上的特征信息。多尺度空洞可分离卷积结构如图 3 所示。因此需要点卷积来将不同通道的相




图 3 多尺度空洞可分离卷积结构

Fig. 3 Multi-scale dilated separable convolution (MDSC) structure

同空间位置的特征信息进行融合与组合生成新的特征图。

MDSC 模块主要思想是在深度可分离卷积上使用不同的扩张率来扩大感受野,为了防止卷积核的不连续问题,本文使用多尺度的方法将扩张率分别为 1、2 和 3 的深度空洞卷积并联用以提取不同层次的特征信息,并将不同尺度的卷积结果拼接起来,最后使用点卷积融合特征信息。

在 1 维的空洞卷积被定义为:

$$y[i] = \sum_k f[i + l \cdot k] \omega[k], \quad (1)$$

式中, $f[i]$ 表示输入信号, $y[i]$ 表示输出信号, $\omega[k]$ 表示长度为 k 的滤波器, l 对应于 $f[i]$ 的扩张率,在标准的卷积中 $l=1$ 。

在图像处理中,2 维空洞卷积是通过在卷积核中插入数值为 0 的孔来实现的。对于尺度为 $k \times k$ 的卷积核,扩张后的卷积核尺度为 $k_d \times k_d$,其中 $k_d = k + (k-1) \times (l-1)$ 。

2.4 通道注意力机制

squeeze-and-excitation networks(SENNet)是由

HU 等^[16]提出的。本文通道注意力模型基于 SENet 结构进行修改。点卷积层用于代替 SENet 的全连接层,可以输入任意数量和大小特征图。通道注意力模型如图 4 所示。SENet 是一个由 3 部分组成的模块,分别是挤压操作、激励操作和重新加权操作。首先是挤压操作,目的是对每个输入特征通道进行信息压缩,减少卷积层参数误差造成估计均值的偏移,并保留更多的纹理信息。本文将经过深度卷积和批归一化后的特征图作为输入进行全局最大池化,从而得到具有全局感受野的一个实数。输出实数的个数和输入的特征通道数相匹配。全局最大池化可以表示为:

$$z_c = \max u_c(i, j), i, j \in D, z \in R^C, \quad (2)$$

式中, D 表示输入通道特征的尺寸, $u_c \in U, U \in R^{D \times D \times C}, U = [u_1, u_2, \dots, u_c]$ 表示输入特征图。

其次是激励操作,该操作主要是为每个特征通道生成权重。它由 2 个点卷积层组成,第 1 个点卷积层对输入特征通道降维,第 2 个点卷积层将压缩的特征通道数还原。挤压与激励操作可表示为:

$$s = \sigma(T_2 \text{ReLU}(T_1 z)), \quad (3)$$




图 4 通道注意力模型

Fig. 4 Channel attention model

式中, $T_1 \in R^{\frac{C}{r} \times C}, T_2 \in R^{C \times \frac{C}{r}}$, 点卷积采用的“valid”的填充方式来保证结果都是基于没有缺失上下文特征得到的。

最后一个是重新加权操作,激励的输出权重值就表示特征通道的重要性,将激励输出的权重与输入特征图做乘法,完成在通道维度上对原始特征的重标定。重新加权操作描述为:

$$x_c = F_{\text{scale}}(u_c, s_c) = s_c \times u_c, \quad (4)$$

式中, $X = [x_1, x_2, \dots, x_c]$ 为通道注意力机制模型输出特征图。 $F_{\text{scale}}(u_c, s_c)$ 指的是标量 s_c 和特征图 u_c 之间的通道乘法。

3 实验内容与结果分析

3.1 实验数据

本文使用 PROMISE12 挑战数据集来验证该方法的有效性, PROMISE12 仅提供 50 个患者样本作为训练集。由于 PROMISE12 样本数量较少,将 50 个患者样本分为 45 个训练集和 5 个测试集。测试集可以任意设置为 {05, 15, 25, 35, 45}。之后,对每个样本进行切片并将每个切片的大小调整为 256×256 。在预处理部分提高了切片图像的对比度。使用对比度限制自适应直方图均衡进行直方图均衡。

此外,为了使像素分布更均匀,对每个图像使用曲率驱动的图像去噪。最后,计算训练集的均值和标准差,并使用计算出的均值和标准差对训练集和测试集进行标准化。

PROMISE12 的训练集样本切片后大约有 1 250 张图像,这对于深度学习而言训练的数据量是不够的,因此需要对数据进行增强。使用随机旋转、移位、缩放、反转和弹性变形方法将对训练集进行数据增强。

3.2 实验环境

本文实验只调整模型结构,其余部分保持原样。使用反向传播算法来训练模型,优化器选择 Adam,学习率设置为 0.000 1,动量设为 0.9,dropout 率设置为 0.8。当训练的准确率经过 5 代后都没有提高 0.001 时,训练结束,将测试集准确率最高的训练结果保存并用其来评估模型。输入图像批次为 12。

本文实验平台是基于 Keras 2.3.1 版本,以 Tensorflow-GPU2.1.0 版本为后端在 python3.7 框架下进行实验,硬件平台是 NVIDIA GeForce RTX 2060 GPU (6 GB RAM) 和 AMD Ryzen 5 3600 6-Core 处理器 3.59 GHz (16 GB RAM),用 CuDNN 7.6 库作为基准函数启用以确保使用最快的算法。

3.3 评价指标

在医学图像分割中,目标区域通常仅占整张图像的一小部分,这种现象是属于样本分布不均匀,在这种情况下使用 Dice 系数作为损失函数具有更好的分割效果^[17]。Dice 系数源于二分类,本质上是衡量 2 个样本的重叠部分。该指标范围从 0% 到 100%,其中 100% 表示分割结果与真实标签完整的重叠。其计算式表示为:

$$Dice(y, \hat{y}) = \frac{2 \sum_{i=1}^N y_i \cdot \hat{y}_i}{\sum_{i=1}^N y_i + \sum_{i=1}^N \hat{y}_i}, \quad (5)$$

式中, y 表示真实标签的元素, $\hat{y}$ 表示预测分割图的元素, N 表示分割图的总元素个数, i 表示分割图中第 i 个元素。

仅仅使用 Dice 系数来评估分割的效果是不够的,因为 Dice 系数不能判断分割轮廓的效果。在此,本文引入豪斯多夫距离来评估分割结果的轮廓与真实标签轮廓的相似性。

豪斯多夫距离 (Hausdoff distance, HD) 可以判断分割结果与真实标签边界的相似度,表达式为:

$$d_H(X, Y) = \max\{d_{XY}, d_{YX}\} = \max\left\{\max_{x \in X} \min_{y \in Y} d(x, y), \max_{y \in Y} \min_{x \in X} d(x, y)\right\}, \quad (6)$$

式中, Y 表示真实标签边缘轮廓的点集 $Y = \{y_1, \dots, y_m\}$, X 表示分割结果边缘轮廓的点集 $X = \{x_1, \dots, x_n\}$ 。HD 表示分割结果轮廓与真实标签轮廓最大不匹配程度。

当 $d_H(X, Y) = 0$ 时表示分割结果轮廓与真实标签轮廓完全重合,即 HD 越小越好。

$$d(x, y) = \|x - y\|, \quad (7)$$

式中,算符 $\|\cdot\|$ 表示点集间的距离。 x 表示 X 点集中的元素, y 表示 Y 点集中的元素。

3.4 实验结果及分析

本文选择的对比方法分别是 U-Net, U-Net 的改进版残差 U-Net (ResU-Net) 和 ResU-Net + SENet。表 1 显示了本文方法与对比方法在 PROMISE12 数据集上的测试结果,各种方法的分割轮廓如图 5 所示。从表 1 中不难得出本文提出方法在指标上均优于其他方法。本文提出方法 Dice 系数值最高为 88.13%, 平均 HD 值最低为 14.17 mm, 模型所需的参数量最少为 233 865 20, 占用的存储空间最小为 274 MB。U-Net 的 Dice 系数为 83.70%, 平均 HD 为 16.48 mm, 参数量 346 331 29, 存储空间为 406 MB。ResU-Net 的 Dice 系数为 84.94%, 平均 HD 为 19.62 mm, 参数量 532 497 54, 存储空间为 624 MB。ResU-Net + SENet 的 Dice 系数为 86.02%, 平均 HD 为 19.18 mm, 参数量 536 940 08, 存储空间为 630 MB。

从图 5 中可以得到,在边缘信息较为明显的 case1 和 case2 中,本文方法的优势不明显。在边缘信息较为模糊的 case3 和 case4 中,可以明显得出本文方法的分割效果明显优于其他方法。U-Net 和 ResU-Net 方法在 case3 中无法分割出目标区域, ResU-Net + SENet 方法在 case3 中的边缘分割效果差于本文方法。ResU-Net + SENet 方法在 case4 中无法分割出目标区域, U-Net 和 ResU-Net 方法在 case4 中无法捕捉模糊边缘信息,其分割效果差。本文方法在 case4 中较好的获取模糊边缘信息。

对比 U-Net 和 ResU-Net 的结果,使用残差网络结构使 U-Net 的 Dice 系数提高了 1.24%, 即提高分割的准确率。但是 HD 变大了 3.14 mm, 即分割结果轮廓与真实标签轮廓不匹配程度变大, 同时,参数量显著变多,模型所需的存储空间显著变大。残差网络结构在模型结构较深的情况下能够提高准确率,但是输入图像会随着残差结构直接传递到最后的卷积层,导致边缘信息噪声增加。同时残差结构增加中间层的特征图数量导致模型的参数量显著增

加进而消耗的存储空间增大。

对比 ResU-Net 和 ResU-Net+SENet 的结果,使用通道注意力机制使 Dice 系数增加 1.08%,HD

降低 0.44 mm,参数量和存储空间没有显著增加,说明通道注意力机制能够通过给中间特征重新分配权重提高图像分割效果并不会增加过多的参数量。




图 5 白色曲线代表预测的前列腺轮廓,而黑色曲线代表由有经验的放射科医生手动获得并分割轮廓
Fig. 5 The white curve representing the predicted prostate contour, while the black curve representing the contour manually obtained and segmented by an experienced radiologist

表 1 不同方法在 PROMISE12 数据集上的测试结果

Tab. 1 Test results of different methods on PROMISE12 dataset

Method	Dice(%)	Mean HD(mm)	Parameter	Storage(MB)
U-Net	83.70	16.48	34633129	406
ResU-Net	84.94	19.62	53249754	624
ResU-Net+SENet	86.02	19.18	53694008	630
Our method	88.13	14.17	23386520	274

消融实验选择 ResU-Net+SENet 和本文方法进行对比,将 ResU-Net 中的标准卷积结构换成本文的 MDSC 结构,从表 1 结果可以得出,本文方法比 ResU-Net+SENet 方法的 Dice 系数提高了 2.11%,HD 降低 5.01 mm,模型的参数量和存储空间降低了 57%,实验结果充分说明了在深度可分离卷积上使用不同的扩张率来扩大感受野用以提取不同层次的特征信息,并将这些特征信息拼接起来通过点卷积融合特征信息可以有效的提高分割效果并使分割结果的轮廓与真实结果更加相近,而且还有有效的降低参数量和存储空间。

4 结 论

针对前列腺 MRI 切片后发现有些影像没有有效的边缘信息,导致分割结果不准确和传统卷积占用过多的存储空间问题。本文提出了一种结合 MD-SC 和通道注意力机制的 U 型残差全卷积网络来分割前列腺的方法。该方法使用多尺度方法将扩张率分别为 1、2 和 3 的深度空洞卷积并联,将提取不同层次的特征信息结果拼接起来通过点卷积融合特征信息后使用通道注意力给特征信息重新分配权重,使重要的特征信息凸显,从而达到更好的分割效果,同

时还能减少模型参数量。在 PROMISE12 挑战赛数据集上验证,结果表明,该方法不仅可以分割出没有有效边缘的前列腺区域,提高其分割精度,而且能有效的降低参数量和存储空间,在模糊边缘的医学图像和小型化设备中有良好的应用前景。

参考文献:

- [1] TIAN Z, LI X, CHEN Z, et al. Interactive prostate MR image segmentation based on ConvLSTMs and GGNN[J]. *Neurocomputing*, 2021, 438: 84-93.
- [2] ZHU Q, DU B, YAN P. Boundary-weighted domain adaptive neural network for prostate MR image segmentation [J]. *IEEE Transactions on Medical Imaging*, 2019, 39(3): 753-763.
- [3] ALMEIDA G, TAVARES J M R S. Deep learning in radiation oncology treatment planning for prostate cancer: A systematic review[J]. *Journal of Medical Systems*, 2020, 44(10): 1-15.
- [4] HAMBARDE P, TALBAR S, MAHAJAN A, et al. Prostate lesion segmentation in MR images using radiomics based deeply supervised U-Net [J]. *Biocybernetics and Biomedical Engineering*, 2020, 40(4): 1421-1435.
- [5] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 39(4): 640-651.
- [6] TIAN Z, LIU L, ZHANG Z, et al. PSNet: prostate segmentation on MRI based on a convolutional neural network[J]. *Journal of Medical Imaging (Bellingham, Wash.)*, 2018, 5(2): 021208.
- [7] ZHU QI, DU B, TURKBAY B, et al. Exploiting interslice correlation for MRI prostate image segmentation, from recursive neural networks aspect[J]. *Complexity*, 2018, 2018: 4185279.
- [8] 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, October 5-9, 2015, Munich, Germany. Berlin, Heidelberg: Springer-Verlag, 2015: 234-241.
- [9] MILLETARI F, NAVAB N, AHMADI S A. V-Net: Fully convolutional neural networks for volumetric medical image segmentation [C]// 4th International Conference on 3D Vision, October 25-28, 2016, Stanford, CA, USA. New York: IEEE, 2016: 565-571.
- [10] YU L, YANG X, CHEN H, et al. Volumetric ConvNets with mixed residual connections for automated prostate segmentation from 3D MR images[C]// Thirty-first AAAI Conference on Artificial Intelligence, February 4-9, 2017, San Francisco, California, USA. Menlo Park: AAAI Press, 2017: 66-72.
- [11] YI W, DENG Z, HU X, et al. Deep attentional features for prostate segmentation in ultrasound[C]// International Conference on Medical Image Computing and Computer-Assisted Intervention, September 16-20, 2018, Granada, Spain. Berlin, Heidelberg: Springer-Verlag, 2018: 523-530.
- [12] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]// IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 1251-1258.
- [13] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]// European Conference on Computer Vision, September 8-14, 2018, Munich, Germany. Berlin: Springer, 2018: 801-818.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 770-778.
- [15] HOLSCHNEIDER M, KRONLAND-MARTINET R, MORLET J, et al. A real-time algorithm for signal analysis with the help of the wavelet transform[M]// COMBES J-M, GROSSMANN A, TCHAMITCHIAN P. *Wavelets*. Berlin, Heidelberg: Springer, 1990: 286-297.
- [16] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]// IEEE Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 7132-7141.
- [17] EELBODE T, BERTELS J, BERMAN M, et al. Optimization for medical image segmentation: theory and practice when evaluating with dice score or jaccard index[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(11): 3679-3690.

作者简介:

邵党国 (1979—),男,博士研究生,副教授,硕士生导师,主要从事医学信号与图像处理,人工智能与模式识别,深度学习与文本处理,数据分析与处理方面的研究。