

引用格式:丁才富,杨晨,纪秋浪,等. MCA-Net: 多尺度综合注意力 CNN 在医学图像分割中的应用[J]. 微电子学与计算机, 2022,39(3):71-77. [DING C F, YANG C, JI Q L, et al. MCA-Net: Multi-scale comprehensive attention application of CNN in medical image segmentation [J]. Microelectronics Computer, 2022,39(3):71-77.] DOI:10. 19304/J. ISSN1000-7180. 2021. 0950

MCA-Net: 多尺度综合注意力 CNN 在医学 图像分割中的应用

丁才富,杨 晨,纪秋浪,王 阳,张 兵

(贵州大学 大数据与信息工程学院,贵州 贵阳 550025)

摘 要: 医学图像自动分割技术具有辅助临床医学诊断的功能. 为改善 CNN 模型在医学图像分割中存在感受野小及细节特征不敏感等问题,基于多尺度策略以及注意力机制,提出一种多尺度综合注意力的 U 形网络架构,以提升医学图像分割质量. 首先,提出一个新的双路径因式分解多尺度融合块,以扩展图像特征的感受野,进一步提取图像特征的细节信息. 其次,在架构中融入通道和空间融合自注意力块,利用注意力机制的特性,抑制不相关的部分或背景以突显深层特征的空间信息. 最后,引入多尺度注意力块. 该模块通过融合多个尺度的特征信息,以突出不同尺度中最显著的特征图来适应当前分割对象的大小. 为验证模型的可靠性,将所提出的网络模型应用于肺部、细胞轮廓及肝脏等医学图像分割任务. 实验结果表明,所提方法在准确率、Dice 系数、AUC 及灵敏度等评估指标上均优于目前用于医学图像分割的主流方法.

关键词: 医学图像分割;因式分解;双路径融合块;通道注意力;空间注意力;多尺度注意力块

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2022)03-0071-07

MCA-Net: Multi-scale comprehensive attention applicaton of CNN in medical image segmentation

DING Caifu, YANG Chen, JI Qiulang, WANG Yang, ZHANG Bing

(College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China)

Abstract: The automatic segmentation technology of medical images has the function of assisting clinical medical diagnosis. In order to improve the CNN model in medical image segmentation, such as small receptive fields and insensitive detail features, a multi-scale integrated attention U-shaped network architecture is proposed to improve medical image segmentation quality, which is based on multi-scale strategies and attention mechanisms. First, a new dual-path factorization multi-scale fusion block is proposed to expand the receptive field of image features and further extract the detailed information of image features. Secondly, integrate channel and space fusion self-attention blocks into the architecture, and use the characteristics of the attention mechanism to suppress irrelevant parts or background to highlight the spatial information of deep features. Finally, a multi-scale attention block is introduced. The module fuses feature information of multiple scales to highlight the most prominent feature maps in different scales to adapt to the size of the current segmentation object. In order to verify the reliability of the model, the proposed network model is applied to medical image segmentation tasks such as lungs, cell contours, and liver. Experimental results show that the proposed method is superior to the current mainstream methods for medical image segmentation in terms of accuracy, Dice coefficient, AUC, and sensitivity. It is the mainstream method currently used for medical image segmentation.

收稿日期: 2021-07-10; 修回日期: 2021-08-10

基金项目: 国家自然科学基金(62065003); 半导体功率器件可靠性教育部工程研究中心开放基金(黔科合平台人才 20176103)

Key words: medical image segmentation; factorization; dual-path fusion block; channel attention; spatial attention; multi-scale attention block

1 引言

医学图像分割是对图像中感兴趣区域像素进行标记的任务,可以辅助医疗诊断^[1]. 目前基于深度学习的图像分割^[2]是医学图像分析的主流方法,其能够高效地提取图像特征,在医学图像分析领域被研究者广泛关注.

近年来,卷积神经网络(Convolutional Neural Network, CNN)模型^[3]是较为常见的医学图像分析方法之一. 其中,编解码结构在医学图像分割任务中取得重要的突破^[4]. 2015 年, Ronneberger 等^[5]提出用于医学图像分割的 U-Net 模型,利用跳跃连接对浅层与深层特征进行拼接,以改善图像特征定位精度,提高图像分割准确率. 尽管 U-Net 在分割医学图像方面具有出色的性能,但目前基于 U-Net 框架的医学图像分割方法仍然存在以下问题:普通卷积层的设计,在特征处理上缺乏空间关注度,处理小目标会导致网络性能降低; U-Net 通常会提取多尺度特征以处理不同尺度的对象,但对分割特定图像缺乏最佳尺度的意识^[6]. 因此,基于 U-Net 框架,研究者提出多种改进机制以提高 CNN 模型的性能^[4]. 其中, Chen 等人^[7]提出用于脑肿瘤分割的 Res U-Net 模型,其利用残差机制以提高图像特征的利用率,也缓解了深层网络中的梯度消失问题. 同时, Gu 等人^[8]提出用于医学图像分割的 Ce-Net 模型,其利用空洞卷积机制以改变模型的接受域大小并减少特征的信息大量丢失问题,该机制不仅实现简单,且所需参数量少. Zhou 等人^[9]提出用于医学图像分割任务的 U-Net++ 模型,该模型重新设计的跳跃连接旨在减小编码器和解码器子网特征图之间的语义差距. 此外, Oktay 等^[10]提出用于腹部器官分割的 Attention U-Net 模型,该模型使用注意力机制,以关注特征图中感兴趣区域的信息,而抑制背景,提高图像分割性能. 纪等人^[11]提出 MFA-Net,其利用多视野特性用于视网膜血管分割,取得较好的分割效果.

综上所述,在以 U-Net 为骨干网络的模型中,引入注意力机制的网络模型能够有效增强其分割能力. 受到相关研究的启发,本文以 U-Net 为骨干网络做出以下工作:(1)将双路径因式分解多尺度融合

块嵌入跳跃连接,实现编-解码器输出特征的有效拼接来提高通道特征利用率;(2)将通道和空间融合自注意力块与编-解码器集成,以充分捕捉深层特征图的空间位置信息及加强图像特征上下文信息的联系;(3)将多尺度注意力块连接于模型末端,融合不同尺度特征以获取适合当前分割对象的最优尺度特征图.

2 网络模型

提出的网络模型(MCA-Net)是在 U-Net^[5] 架构上进行改进,其结构如图 1 所示. 该网络主要有以下三个特点:(1)受因式分解通道注意力块^[12]的启发,本文提出双路径因式分解多尺度融合块(Dual Path factor decomposition multi-scale Fusion block, DPF),该模块用来校准网络中低层特征和高层特征的连接,从而使更多的细节特征信息被捕捉;(2)通过通道和空间融合自注意力块(Spatial and Channel self-attention modules, SCA)^[13]来增强特征图上的感兴趣区域,同时抑制潜在的背景或不相关的部分;(3)利用多尺度注意力块(Multi-scale Attention Module, MSA)^[14]来突出分割对象最相关尺度的特征.

如图 1 所示,该网络结构主要由编码器、解码器、DPF、SCA 及 MSA 等五部分组成,且每一层处理的图像维度已标出. 在图像分割过程中:首先,将图像输入编码器以获取高级语义特征;其次,将编码器每层输出的特征图通过 DPF 以获取更丰富的特征信息,同时将编码器最后一层输出结果通过 SCA 以捕获特征图的空间位置信息;而后,解码器得到的特征图与 DPF 的输出进行拼接以校正特征权重获得更精确的特征图;最后,利用 MSA 自适应地融合不同尺度特征图以得到最终的分割结果.

2.1 DPF

U-Net 框架的跳跃连接是将编-解码器输出特征进行直接拼接,导致特征细节信息的保留度相对较低,从而影响图像的分割质量. 为提高特征信息的保留度,以使较多的特征细节信息被捕获. 如图 1 所示,在 U-Net 跳跃连接处嵌入 DPF 模块,以突显更相关的特征信息及提高特征的表征能力从而保留更多的细节特征信息.




图 1 网络模型

Fig. 1 Network model

DPF 结构如图 2 所示,该模块集成了一维因式分解卷积和多尺度空洞卷积两种机制.在特征处理过程中,一维因式分解卷积通过学习输入和输出特征图之间的差异来获取更相关的特征信息,与二维卷积相比,不仅可以有效保留规则二维卷积核的空间信息,还以较少计算量保持精度;多尺度空洞卷积可以增强图像相关特征信息的关联性,扩展图像特征的感受野,以提高网络细节特征的识别能力.




图 2 DPF 结构

Fig. 2 Structure of DPF

假设输入特征图分别为浅层特征 F_l 和深层特征 F_h ,利用转置卷积将深层特征 F_h 尺寸进行扩张,保持与浅层特征 F_l 尺寸相同.因此 DPF 的输出公式如式(1)所示:

$$\text{Out}_{\text{DPF}} = \text{Conv1d}(F_l) +$$

$$\text{cat}[\text{Conv2d}^r(\text{ConvTranspose2d}(F_h))] \quad (1)$$

式中, r 为空洞卷积扩张率,本文采用空洞卷积扩张率分别为 1、3、5.

2.2 SCA

由于传统医学图像分割模型中深层卷积块的接受域较小,限制了特征图空间信息的保留以及高级语义特征的捕获.为解决传统卷积神经网络的局限性,在当前较主流研究^[13,15]的究启发下,本文在图 1 所示的编-解码器底部之间引入 SCA 以获取深层特征图的空间位置信息,并在 SCA 中增加密集空洞卷积块(Dense Atrous Convolution module, DAC)^[8]以扩展深层卷积的接受域.

SCA 结构如图 3 所示,该模块由空间注意力块、通道注意力块以及 DAC 等三部分组成.该模块的主要作用是获取深层特征图的空间位置信息,自适应地将局部特征与其全局依赖性结合起来以利于细小特征信息的捕捉及表征.其中特征图在空间注意力块的引导下有选择地将全局上下文信息聚合到学习特征中.通道注意力模块先将特征图进行重塑,以获取相同特征不同维度的通道特征权重,其中中间分支会经过置换操作,置换是为了更进一步组合图像不同维度的特征信息,以突显特征通道间更相似的权重.再将其加权聚合到原始特征通道中,以突显最相关的通道特征信息. DAC 用不同扩张率的空洞卷积进行级联以提取具有不同感受野的特征图,其结构如图 4 所示.




图 3 SCA 结构

Fig. 3 Structure of SCA




图 4 DAC 结构

Fig. 4 Structure of DAC

DAC 有四个级联分支,随着空洞卷积的数量逐渐增加,从 1 到 1、3、5,那么每个分支的感受野将是 3、7、9、19. 通过结合不同扩张率的空洞卷积, DAC 模块能够为各种尺寸的对象提取特征. 该模块是将原始特征与经过空洞卷积的特征融合来获得信息更丰富的特征图.

SCA 的主要流程如下:首先由编码器最后一层输出的特征同时经过空间注意力块、通道注意力块以及 DAC,然后将三个模块输出的特征进行融合以得到空间通道融合特征图.

2.3 MSA

U-Net 在医疗图像分割过程中通过提取多尺度特征以处理不同尺度的对象,但对于特定的对象,不同尺度的特征图可能与该对象的相关性存

在差异. 为确定每个像素的比例权重,以便网络可以自适应地给定输入相应的比例. 如图 1 所示,在本文网络末端引入 MSA 以学习每个尺度特征图像的特定权重来校准不同尺度上的特征,MSA 结构如图 5 所示.




图 5 MSA 结构

Fig. 5 Structure of MSA

在图 1 中,利用双线性插值将解码器获得的不同尺度特征图($f=1,2,3,4$)上采样到与原始图像相同的尺寸,并用 1×1 卷积将这些特征图压缩成 4 个通道再进行拼接,以作为 MSA 的输入,如图 5 所示. 该输入先经过平均池化(P_{avg})、最大池化(P_{max})与多层感知器(MLP)相结合的模块,以获取每个尺度最相关的系数 γ ,该系数为与特征通道信息最接近的权重(即尺度注意力系数)^[13],可利用其自适应地调整分割对象的尺度特征信息. 该系数与输入相乘再相加以得到最终的尺度注意特征图. 其最终输出如式(2)所示:

$$\text{Out}_{\text{MSA}} = F + F * \gamma \quad (2)$$

$$\gamma = (\text{softmax}(P_{avg}(F) + P_{max}(F)))$$

式中, F 为不同尺度特征图重采样后拼接得到的特征图, γ 为尺度注意力系数.

2.4 损失函数

在医学图像分割领域,Dice 损失函数^[16]常被用来计算回归损失,该函数可对每个像素区域独立评价后再对网络参数进行反馈. 同时,为避免本文所提网络产生过拟合现象,在 Dice 损失函数基础上,增加正则化损失函数^[17]. 本文的损失函数如式(3)所示:

$$L_{\text{dice}} = 1 - \frac{\sum_k \frac{2\omega_k \sum_i^N p(k,i)g(k,i)}{\sum_i^N p^2(k,i) + \sum_i^N g^2(k,i)}}{2}$$

$$L_{\text{loss}} = L_{\text{dice}} + L_{\text{reg}} \quad (3)$$

式中, N 是像素数, $p(k,i) \in [0,1]$ 和 $g(k,i) \in \{0,1\}$ 分别表示预测概率和真实标签, k 表示类别; L_{reg}

表示正则化损失函数.

3 实验结果及分析

3.1 实验环境

本文实验均在 PyTorch 框架下实现,训练和测试的平台是 Intel Core i5-3470 处理器,显卡 Tesla k40c (显存 12G)的 Ubuntu18. 04 (64 位)系统. 网络的训练参数设置:使用 Adam 优化器,初始学习率为 0. 001,批量大小为 4,将 epoch 设置为 60.

3.2 数据集及评估指标

为评估网络性能,本文在肺部分割^[18]、细胞轮廓分割^[19]以及肝脏分割^[20]等公共数据集对网络性能进行测试,他们分别包含 267、400 和 30 个尺寸为 512×512(pixel)的二维样本图像. 在实验中采用 8: 2 的比例划分训练集与测试集. 为避免训练过程中出现过拟合的现象,本文首先对将要分割的图像进行数据预处理以扩充数据集. 预处理手段有随机翻转、裁剪及缩放等.

为评估图像分割质量,本文采用准确率 (Acc)、灵敏度 (Sen)、Dice 系数 (Dice) 以及 Jaccard 指数 (IoU)等评估指标. 其计算方式如式(4)所示:

$$\begin{aligned} \text{Acc} &= \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{FN} + \text{TN}} \\ \text{Sen} &= \frac{\text{TP}}{\text{TP} + \text{FN}} \\ \text{Dice} &= \frac{2\text{TP}}{2\text{TP} + \text{FP} + \text{FN}} \\ \text{IoU} = \text{Sen} &= \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \end{aligned} \tag{4}$$

式中,TP 表示真阳性,FP 表示假阳性,TN 表示真阴性,FN 表示假阴性. 除此之外,还利用曲线下面积(AUC)来评估改进网络的性能. 以上评估指标的衡量标准是值越大说明网络性能越好,且该值不大于 1.

3.3 实验结果

将所提出的网络模型与当前主流模型(如 U-Net、Attention-Unet (A-Unet)、UNet++ 和 CeNet)进行比较. 所有模型均采用相同的数据格式、预处理手段以及训练参数.

3.3.1 肺部分割结果

肺部分割结果如表 1 所示,在评估指标上,本文方法均优于当前主流网络模型. 与 U-Net 相比,其 Dice 与 IoU 等评估指标均提升了一到两个百分点. 说明在 U-Net 框架上引入注意力机制用于肺部分割是可行的.

表 1 肺部图像分割性能比较

Tab. 1 Comparison of lung image segmentation performance

方法	评估指标/%				
	Acc	Sen	Dice	AUC	IoU
U-Net	98. 58	97. 35	96. 54	98. 26	94. 04
A-Unet	98. 85	98. 09	97. 13	98. 67	95. 19
Unet++	98. 85	97. 88	97. 15	98. 60	95. 22
CeNet	98. 77	97. 56	96. 96	98. 43	94. 84
Ours	99. 26	98. 56	98. 39	99. 01	96. 83

3.3.2 细胞轮廓分割结果

细胞轮廓分割的结果如表 2 所示,根据数据比较得到,本文方法在细胞轮廓分割任务上的性能均优于所比较的网络模型. 与 U-Net 相比,提升效果最明显,其中 IoU 提升了 4. 18%. 说明本研究网络在特征细节上捕捉能力更强,在细胞轮廓分割任务中具有很好的分割性能.

表 2 细胞轮廓分割性能比较

Tab. 2 Comparison of cell contour segmentation performance

方法	评估指标/%				
	Acc	Sen	Dice	AUC	IoU
U-Net	87. 14	92. 57	91. 69	80. 74	84. 69
A-Unet	90. 55	94. 29	93. 86	86. 16	88. 45
UNet++	86. 63	84. 52	90. 62	88. 97	82. 89
CeNet	89. 45	93. 37	93. 14	84. 85	87. 17
Ours	90. 89	94. 87	94. 10	86. 25	88. 87

3.3.3 肝脏分割结果

肝脏分割的结果如表 3 所示,根据评估结果来看,本文网络相对于当前主流的网络模型在分割性能上有提升,但与肺部和细胞轮廓的提升相比效果不明显. 与当前主流的网络模型相比,其 Sen、Dice、AUC 以及 IoU 提升效果不是很大,且 Acc 低于 UNet. 这是由于肝脏图像特征形状的多样性以及轮廓较模糊而导致分割难度大.

表 3 肝脏分割性能比较

Tab. 3 Comparison of liver segmentation performance

方法	评估指标/%				
	Acc	Sen	Dice	AUC	IoU
U-Net	99. 49	92. 30	94. 70	96. 03	90. 56
A-Unet	99. 42	92. 73	94. 33	96. 19	89. 79
UNet++	99. 39	93. 91	94. 84	96. 74	90. 45
CeNet	99. 72	97. 43	97. 87	98. 62	95. 86
Ours	99. 24	97. 68	98. 27	98. 93	96. 77

为更直观地对比本研究网络在三个医学图像分割任务上的分割表现,分别随机抽取上述三个医学

图像分割图以进行展示,不同模型的分割效果如图 6 所示,可以看出,虽然所有模型的分割结果与标签

很接近,但本文提出的网络模型在整体上有更好的分割表现.




图 6 数据可视化
Fig. 6 Data visualization

本文所提出的网络架构在三个数据集上进行测试,通过测试结果可以得知,本文在 U-Net 基础上引入注意力机制能够有效提升不同医学图像的分割质量,且其分割性能都优于近年来主流的网络架构.

4 结束语

医学图像分割在医学图像分析中占有重要地位. 本文提出一种以 U-Net 为骨干网络的端到端 CNN 框架用于医学图像分割. 首先,在骨干网络跳跃连接处嵌入 DPF 突显出更相关的特征信息,提高了特征的表征能力. 其次,在编-解码器之间引入 SCA,以保留更多的特征空间信息,提高网络学习能力. 最后,在网络末端用一种多尺度策略 MSA,将不同级别的语义信息进行组合,从而聚合相关的上下文特征. 实验结果表明,该方法能够改善不同领域的医学图像分割,如肺部分割,细胞轮廓分割和肝脏分割等,且优于当前主流的网络模型分割性能,具有较高的分割准确率.

参考文献:

[1] LÊ M, UNKELBACH J, AYACHE N, et al. GPSSI:

gaussian process for sampling segmentations of images [C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer, 2015: 38-46. DOI: 10.1007/978-3-319-24574-4_5.

[2] HESAMIAN M H, JIA W J, HE X J, et al. Deep learning techniques for medical image segmentation: achievements and challenges[J]. Journal of Digital Imaging, 2019, 32(4): 582-596. DOI: 10.1007/s10278-019-00227-x.

[3] ANWAR S M, MAJID M, QAYYUM A, et al. Medical image analysis using convolutional neural networks: a review [J]. Journal of Medical Systems, 2018, 42 (11): 226. DOI: 10.1007/s10916-018-1088-1.

[4] LIU L L, CHENG J H, QUAN Q, et al. A survey on U-shaped networks in medical image segmentations [J]. Neurocomputing, 2020, 409: 244-258. DOI: 10.1016/j.neucom.2020.05.070.

[5] 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

- tion. Munich: Springer, 2015; 234-241. DOI: 10.1007/978-3-319-24574-4_28.
- [6] 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. DOI: 10.1109/TPAMI.2017.2699184.
- [7] CHEN H, DOU Q, YU L Q, et al. VoxResNet: deep voxelwise residual networks for brain segmentation from 3D MR images[J]. NeuroImage, 2018(170): 446-455. DOI: 10.1016/j.neuroimage.2017.04.041.
- [8] GU Z W, CHENG K, FU H Z, et al. CE-Net: context encoder network for 2D medical image segmentation[J]. IEEE Transactions on Medical Imaging, 2019, 38(10): 2281-2292. DOI: 10.1109/TMI.2019.2903562.
- [9] ZHOU Z W, RAHMAN SIDDIQUEE M, TAJBA-KHSH N, et al. UNet++: a nested u-net architecture for medical image segmentation[C]//4th International Workshop on Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Granada: Springer, 2018; 3-11. DOI: 10.1007/978-3-030-00889-5_1.
- [10] OKTAY O, SCHLEMPER J, LE FOLGOC L, et al. Attention U-Net: learning where to look for the pancreas[C]//1st Conference on Medical Imaging with Deep Learning. Amsterdam, [s.l.], 2018: 1-10.
- [11] 纪玲玉, 高永彬, 卫子然. MFA-Net: 基于多视野上下文关注的视网膜血管分割[J]. 微电子学与计算机, 2021, 38(3): 14-20. DOI: 10.19304/j.cnki.issn1000-7180.2021.03.003.
- J I L Y, GAO Y B, WEI Z R. MFA-Net: retinal vessel segmentation based on multi-view context attention[J]. Microelectronics & Computer, 2021, 38(3): 14-20. DOI: 10.19304/j.cnki.issn1000-7180.2021.03.003.
- [12] SINGH V K, ABDEL-NASSER M, RASHWAN H A, et al. FCA-Net: adversarial learning for skin lesion segmentation based on multi-scale features and factorized channel attention[J]. IEEE Access, 2019(7): 130552-130565. DOI: 10.1109/ACCESS.2019.2940418.
- [13] FU J, LIU J, TIAN H J, et al. Dual attention network for scene segmentation[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019; 3141-3149. DOI: 10.1109/CVPR.2019.00326.
- [14] GU R, WANG G T, SONG T, et al. CA-Net: comprehensive attention convolutional neural networks for explainable medical image segmentation[J]. IEEE Transactions on Medical Imaging, 2021, 40(2): 699-711. DOI: 10.1109/TMI.2020.3035253.
- [15] MOU L, ZHAO Y T, CHEN L, et al. CS-Net: channel and spatial attention network for curvilinear structure segmentation[C]//22nd International Conference on Medical Image Computing and Computer Assisted Intervention. Shenzhen, China: Springer, 2019; 721-730. DOI: 10.1007/978-3-030-32239-7_80.
- [16] 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. Stanford: IEEE, 2016; 565-571. DOI: 10.1109/3DV.2016.79.
- [17] HOERL A E, KENNARD R W. Ridge regression: biased estimation for nonorthogonal problems[J]. Technometrics, 1970, 12(1): 55-67. DOI: 10.2307/1271436.
- [18] ARMATO III S G, MCLENNAN G, BIDAUT L, et al. The lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans[J]. Medical Physics, 2011, 38(2): 915-931. DOI: 10.1118/1.3528204.
- [19] CARDONA A, SAALFELD S, PREIBISCH S, et al. An integrated micro- and macroarchitectural analysis of the drosophila brain by computer-assisted serial section electron microscopy[J]. PLoS Biology, 2010, 8(10): e1000502. DOI: 10.1371/journal.pbio.1000502.
- [20] BILIC P, CHRIST P F, VORONTSOV E, et al. The liver tumor segmentation benchmark (LiTS)[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 1-43.

作者简介:

丁才富 男,(1996-),硕士研究生.研究方向为医学图像处理.

杨晨(通讯作者) 男,(1982-),博士,教授.研究方向为图像处理与应用. E-mail: eliot. c. yang@163. com

纪秋浪 女,(1996-),硕士研究生.研究方向为医学图像处理.

王阳 男,(1994-),博士研究生.研究方向为图像处理.

张兵 男,(1995-),硕士研究生.研究方向为医学图像处理.