



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象 图形学报

2021
09
VOL.26

ISSN1006-8961
CN11-3758/TB



“深度学习+智慧医疗”专刊



第26卷第9期（总第305期）
2021年9月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 吴一戎
编辑出版 《中国图象图形学报》编辑出版委员会
通信地址 北京市海淀区北四环西路19号
邮 编 100190
电子信箱 jig@aircas.ac.cn
电 话 010-58887035
网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱: 北京399信箱 邮编: 100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian | Monthly, Started in 1996

Superintended by Chinese Academy of Sciences
Sponsored by Aerospace Information Research Institute, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong
Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics
Address No. 19, North 4th Ring Road West, Haidian District, Beijing, P. R. China
Zip code 100190
E-mail jig@aircas.ac.cn
Telephone 010-58887035
Website www.cjig.cn


Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China)
Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ


国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



肺部影像解剖结构分割数据集及应用(第2111页)



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(第2121页)



语义拉普拉斯金字塔多中心乳腺肿瘤分割网络(第2193页)

编者按 I

综述

深度医学图像配准研究进展: 迈向无监督学习

马露凡, 罗凤, 严江鹏, 徐哲, 罗捷, 李秀 2037

U-Net网络医学图像分割应用综述

周涛, 董雅丽, 霍兵强, 刘珊, 马宗军 2058

医学图像深度学习技术: 从卷积到图卷积的发展

唐朝生, 胡超超, 孙君顶, 司马海峰 2078

多尺度变换像素级医学图像融合: 研究进展、应用和挑战

周涛, 刘珊, 董雅丽, 霍兵强, 马宗军 2094

数据集论文

肺部影像解剖结构分割数据集及应用

覃文军, 李小硕, 周庆华, 刘盼, 杨金柱 2111

计算机断层扫描图像

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

陈弘扬, 高敬阳, 赵地, 吴忌, 陈金军, 全显跃, 李欣明, 薛峰, 周沐瑶, 柏冰冰 2121

融合上下文和多尺度特征的胸部多器官分割

吉淑滢, 肖志勇 2135

注意力机制下密集空洞卷积的肺部图像分割

郭宁, 柏正尧 2146

融合注意力机制和特征金字塔网络的CT图像肺结节检测

张福玲, 张少敏, 支力佳, 周涛 2156

改进Faster R-CNN模型的CT图磨玻璃密度影目标检测

杨淑莹, 邓东升, 郑清春 2171

融合注意力机制与可变形卷积的多尺度骨病变检测

方成, 柏正尧 2181

磁共振图像

语义拉普拉斯金字塔多中心乳腺肿瘤分割网络

王黎, 曹颖, 郭顺超, 唐雷, 鄧子翔, 王荣品, 王丽会 2193

引入注意力机制和多视角融合的脑肿瘤MR图像U-Net分割模型

罗恺锴, 王婷, 叶芳芳 2208

集成注意力增强和双重相似性引导的多模态脑部图像配准

田梨梨, 程欣宇, 唐堃, 张健, 王丽会 2219

LRUNet: 轻量级脑肿瘤快速语义分割网络

何康辉, 肖志勇 2233

自适应多模态特征融合胶质瘤分级网络

王黎, 曹颖, 田梨梨, 陈祈剑, 郭顺超, 张健, 王丽会 2243

研究应用

面向运动想象脑电图识别的镜卷积神经网络

罗靖, 王耀杰, 刘光明, 王晓帆, 鲁晓峰, 黑新宏 2257

先验权重共享码本下内窥镜图像大肠病变分类

朱霆威, 李胜, 何熊熊 2270

融合空洞卷积与注意力的胃癌组织切片分割

陈颖锲, 李晗, 周雪婷, 万程 2281

视觉显著性的眼底图像视盘检测


吕鹏飞, 王莹, 王思齐, 于晓升, 吴成东 2293

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Pulmonary image anatomical structure segmentation dataset and applications(P2111)



LFSCA-UNet: liver fibrosis region segmentation network based on spatial and channel attention mechanisms(P2121)



Semantic Laplacian pyramids network for multicenter breast tumor segmentation(P2193)

Review

- Deep-learning based medical image registration pathway: towards unsupervised learning
Ma Lufan, Luo Feng, Yan Jiangpeng, Xu Zhe, Luo Jie, Li Xiu 2037
- U-Net and its applications in medical image segmentation:a review
Zhou Tao, Dong Yali, Huo Bingqiang, Liu Shan, Ma Zongjun 2058
- Deep learning-based medical images analysis evolved from convolution to graph convolution
Tang Chaosheng, Hu Chaochao, Sun Junding, Sima Haifeng 2078
- Research on pixel-level image fusion based on multi-scale transformation: progress application and challenges
Zhou Tao, Liu Shan, Dong Yali, Huo Bingqiang, Ma Zongjun 2094

Dataset

- Pulmonary image anatomical structure segmentation dataset and applications
Tan Wenjun, Li Xiaoshuo, Zhou Qinghua, Liu Pan, Yang Jinzhu 2111

Computerd Tomography Image

- LFSCA-UNet: liver fibrosis region segmentation network based on spatial and channel attention mechanisms
Chen Hongyang, Gao Jingyang, Zhao Di, Wu Ji, Chen Jinjun, Quan Xian Yue, Li Xinming, Xue Feng, Zhou Muyao, Bai Bingbing 2121
- Integrated context and multi-scale features in thoracic organs segmentation
Ji Shuying, Xiao Zhiyong 2135
- The integration of attention mechanism and dense atrous convolution for lung image segmentation
Guo Ning, Bai Zhengyao 2146
- Detection of pulmonary nodules in CT images by combining an attention mechanism and a feature pyramid network
Zhang Fuling, Zhang Shaomin, Zhi Lijia, Zhou Tao 2156
- Ground-glass opacity target detection in CT scans based on improved Faster R-CNN model
Yang Shuying, Deng Dongsheng, Zheng Qingchun 2171
- Multi-scale bone lesion detection based on attention mechanism and deformable convolution
Fang Cheng, Bai Zhengyao 2181

Magnetic Resonance Image

- Semantic Laplacian pyramids network for multicenter breast tumor segmentation
WANG Li, CAO Ying, Guo Shunchao, Tang Lei, Kuai Zixiang, Wang Rongpin, Wang Lihui 2193
- U-Net segmentation model of brain tumor MR image based on attention mechanism and multi-view fusion
Luo Kaikai, Wang Ting, Ye Fangfang 2208
- Multimodal brain image registration with integrated attention augmentation and dual similarity guidance
Tian Lili, Cheng Xinyu, Tang Kun, Zhang Jian, Wang Lihui 2219
- LRUNet: a lightweight rapid semantic segmentation network for brain tumors
He Kanghui, Xiao Zhiyong 2233
- Adaptive multi-modality fusion network for glioma grading
Wang Li, Cao Ying, Tian Lili, Chen Qijian, Guo Shunchao, Zhang Jian, Wang Lihui 2243

Research and Application

- Mirror convolutional neural network for motor imagery electroencephalogram recognition
Luo Jing, Wang Yaojie, Liu Guangming, Wang Xiaofan, Lu Xiaofeng, He Xinhong 2257
- Colorectal lesion classification of endoscopic images based on priori weight shared codebook application
Zhu Tingwei, Li Sheng, He Xiongxiang 2270
- The fusing of dilated convolution and attention for segmentation of gastric cancer tissue sections
Chen Yingsi, Li Han, Zhou Xueting, Wan Cheng 2281
- Optic disc detection based on visual saliency in fundus image
Lyu Pengfei, Wang Ying, Wang Siqi, Yu Xiaosheng, Wu Chengdong 2293

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2021)09-2281-12

论文引用格式: Chen Y S, Li H, Zhou X T and Wan C. 2021. The fusing of dilated convolution and attention for segmentation of gastric cancer tissue sections. Journal of Image and Graphics, 26(09): 2281-2292 (陈颖锬, 李晗, 周雪婷, 万程. 2021. 融合空洞卷积与注意力的胃癌组织切片分割. 中国图象图形学报, 26(09): 2281-2292) [DOI: 10. 11834/jig. 200765]

融合空洞卷积与注意力的胃癌组织切片分割

陈颖锬, 李晗, 周雪婷, 万程*

南京航空航天大学电子信息工程学院, 南京 211106

摘要: **目的** 病理组织切片检查是诊断胃癌的金标准, 准确发现切片中的病变区域有助于及时确诊并开展后续治疗。然而, 由于病理切片图像的复杂性、病变细胞与正常细胞形态差异过小等问题, 传统的语义分割模型并不能达到理想的分割效果。基于此, 本文提出了一种针对病理切片的语义分割方法 ADEU-Net (attention-dilated-efficient U-Net ++), 提高胃癌区域分割的精度, 实现端到端分割。**方法** ADEU-Net 使用经过迁移学习的 EfficientNet 作为编码器部分, 增强图像特征提取能力。解码器采用了简化的 U-Net ++ 短连接方式, 促进深层次特征融合的同时减少网络参数量, 并重新设计了其中的卷积模块提高梯度传递能力。中心模块使用空洞卷积对编码器输出结果进行多尺度的特征提取, 增强模型对不同尺寸切片的鲁棒性。编码器与解码器的跳跃连接使用了注意力模块, 以抑制背景信息的特征响应。**结果** 在 2020 年“华录杯”江苏大数据开发与应用大赛 (简称“SEED”大赛) 数据集中与其他经典方法比较, 验证了一些经典模型在该分割任务中难以拟合的问题, 同时实验得出修改特征提取方式对结果有较大提升, 本文方法在分割准确度上比原始 U-Net 提高了 18.96%。在 SEED 数据集与 2017 年中国大数据人工智能创新创业大赛 (brain of things, BOT) 数据集中进行了消融实验, 验证了本文方法中各个模块均有助于提高病理切片的分割效果。在 SEED 数据集中, 本文方法 ADEU-Net 比基准模型在 Dice 系数、准确度、敏感度和精确度上分别提升了 5.17%、2.7%、3.69%、4.08%; 在 BOT 数据集中, 本文方法的 4 项指标分别提升了 0.47%、0.06%、4.30%、6.08%。**结论** 提出的 ADEU-Net 提升了胃癌病理切片病灶点分割的精度, 同时具有良好的泛化性能。

关键词: 胃癌; 病理组织切片; 语义分割; 深度卷积神经网络; 注意力机制; 多尺度特征融合

The fusing of dilated convolution and attention for segmentation of gastric cancer tissue sections

Chen Yingsi, Li Han, Zhou Xueting, Wan Cheng*

College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China

Abstract: Objective As the gold standard for the diagnosis of gastric cancer, pathological section has been a hotspot nowadays. The degree of precise detection of the lesion area in the section has rather beneficial to in-situ diagnosis and follow-up treatment. The pathologists have missed some subtle changes in cancerous cells in their practice. Automated gastric cancer cells segmentation has been aided to diagnose. Deep learning-based pathological section image of stomach have been obtained qualified classification via deep convolutional neural networks (DCNNs). Focused segmentation for pathological

收稿日期: 2020-12-14; 修回日期: 2021-02-19; 预印本日期: 2021-02-26

* 通信作者: 万程 wanch@nuaa.edu.cn

基金项目: 中国博士后科学基金项目 (2019M661832); 江苏省博士后科研资助计划 (2019K226); 江苏高校优势学科建设工程项目

Supported by: Chinese Postdoctoral Science Foundation (2019M661832); Jiangsu Planned Projects for Postdoctoral Research Funds (2019K226)

section has been challenged to some issues as below. First, the color and morphology between gastric cancer cells and normal cells to extract deep features. Second, the different magnifications in pathological section images have been hard to segment in different sizes. A semantic segmentation neural network called attention-dilated-efficient U-Net ++ (ADEU-Net) has been demonstrated rather than original U-Net to facilitate the precision of gastric cancer cell segmentation. **Method** The illustrated framework is an encoder-decoder networks which can achieve end-to-end training. The capability of the encoder has affected the segmentation accuracy based on the deep features of pathological section images interpretation. The featured extraction part of EfficientNet has been adopted as the encoder via qualified classification. The initialized weights of EfficientNet have been pre-trained on ImageNet and its structure have been divided into five stages for the skipped cohesions. The decoder has been designed in terms of the structure of U-Net ++. The encoder and decoder sub-networks have been via the integration of nested, dense skip pathways. An 8 GB GPU model training has been implemented based on the most skip cohesions in U-Net ++. The convolution blocks in the decoder has been re-modified to the gradient transfer issues. An additional module called DBlock has been integrated to enhance the feature extraction capability for multi-sized pathological sections. Three multi-layers dilation rates convolution have been cascaded in DBlock to realize the features in receptive fields. The dilation rates of the stacked dilated convolution layers have been calculated to 1, 2, 5 and the receptive field of each layer has been realized 3, 7, 17 each in terms of the structure of hybrid dilated convolution (HDC). The featured maps have been concatenated by channel and fused via a 1×1 convolution layer to realize multi-scale features simultaneously. The attention mechanism has been used to replace the skip connection between the encoder and the decoder to suppress the feature correspondence of the background region effectively as well. The outputs of the encoder and the decoder of the upper layer have been conducted each based on a 1×1 convolution layer. The optional assigned weights to the parameters of the original feature map have been added together to form the attention gate. deep supervised learning can be altered to solve the low speed convergence in the training process. **Result** The experiments on two datasets called SEED and BOT have been conducted to verify the effectiveness of the method obtained from two gastric cancer cell section segmentation competition. The evaluation metrics of the models have Dice coefficient, sensitivity, pixel-wise accuracy and precision. Different segmentation results have also been calculated visually. First the baseline method has been compared to some classical models on SEED dataset in 18.96% accuracy higher than original U-Net and it has been found that the design of feature extraction has been crucial to the segmentation accuracy. Transfer-learning strategies of the encoder have been improved the results greatly. The further ablation experiments have been performed to each added module to confirm the results of segmentation. The Dice coefficient, sensitivity, accuracy and precision has been increased by 5.17% and 0.47%, 2.7% and 0.06%, 3.69% and 4.30%, 4.08% and 6.08% each compared with the baseline model's results with SEED and BOT. The results have demonstrated the effectiveness of each part of proposed algorithm. The visual segmentation results have more similar to the ground truth label. **Conclusion** A semantic segmentation model called ADEU-Net has been illustrated to the segmentation of pathological sections of gastric cancer task. The involvement of EfficientNet has beneficial to feature extraction, multi-scale features assembling cascade dilated convolution layers and the attention module in replace of the skip connection between the encoder and decoder.

Key words: gastric cancer; pathological section; semantic segmentation; deep convolutional neural network (DCNN); attention mechanism; multi-scale features fusion

0 引言

胃癌作为第5常见的癌症,在所有癌症中致死率位列全球第3(Jin等,2020)。在临床上,内窥镜、影像检查能检测出胃部的异常情况,但只有通过病理组织切片检查才能确诊是否患有胃癌。病理切片需要专业的医师进行检查,然而至2018年,我国有

执照的病理医生仅有一万余人,缺口达90%(卞修武和平轶芳,2019)。不仅如此,由于病理切片图像特征的复杂性,不同的医师可能会得出不同的诊断结果,从而耽误宝贵的治疗时机。

深度卷积神经网络(deep convolutional neural network, DCNN)(Simonyan和Zisserman,2015; Krizhevsky等,2017)在许多图像分类任务中展示了其优越的性能,许多学者也尝试将其应用于病理切

片的任务。Cosatto 等人(2013)使用一种多示例学习(multiple instance learning)的半监督方式对胃癌细胞切片进行分类,达到了90%的分类敏感度;Sharma 等人(2017)通过 AlexNet (Krizhevsky 等, 2017)提取图像特征信息,也实现了对胃癌细胞切片的分类,其中对癌症图像识别准确率为69.90%,细胞坏死识别准确率为81.44%;Liu 等人(2018)对比了多种分类网络在病理组织切片图像上的分类效果,其中效果最优的网络为 ResNet(He 等人,2016),F 值达到96%;Iizuka 等人(2020)结合卷积神经网络和循环神经网络的方式对胃腺癌和腺瘤进行分类,AUC (area under curve)值分别达到了0.97和0.99。

对胃部病理切片图像的分类已经逐步成熟且达到接近医生诊断的准确度,但实际应用中准确定位出病灶点并标注会比单纯的图像分类更直观,从而更有效地辅助医生进行诊断及后续治疗。对医学图像进行手动标注需要高额的成本及时间,因此运用人工智能对医学图像进行语义分割一直是医学图像分析领域的热门内容。全卷积网络(fully convolutional networks, FCN)(Long 等,2015)架构及 U-Net 网络(Ronneberger 等,2015)架构作为两个热门的语义分割架构,在该领域一直有突出的表现。FCN 的架构可以通过单次的前向传播产生完整图像的分割图,实现端到端的图像分割。Roth 等人(2017)将3D全卷积网络运用于腹部电子计算机断层扫描(computed tomography, CT)成像,实现对多器官的分割;Khened 等人(2019)将全卷积网络运用于心脏磁共振成像,实现了心室分割的效果。后期发展的许多语义分割模型均是在 FCN 架构的基础上进行改良的,包括医学图像分割常用的 U-Net 架构。U-Net 在全卷积网络基础上增加了编码器到解码器每一层对称的跳跃连接(skip connection),从而使神经网络能学到多尺度的特征。对于图像分辨率大、样本稀缺的医学图像问题,U-Net 架构有着更好的处理效果。Li 等人(2018)使用混合密集连接的 U-Net,实现了对肝脏肿瘤的分割;Liao 等人(2019)将3D-U-Net 运用于肺部 CT 成像,实现了对肺结节的检测和分割。

尽管医学图像分割已经进行了广泛的研究,但是病理组织切片图像存在特征过于复杂细微、癌症细胞仅具有较小形态变化等难点,以致在其他任务中表现优异的分割模型都难以在分割癌症病变细胞的任务中达到较好的分割效果。基于以上难点,本

文提出了一种针对病理切片图像的语义分割模型 ADEU-Net(融合注意力、空洞卷积、高效率网络与 U-Net++ 的模型,attention dilated efficient U-Net++),本文的研究思路为:

1)针对病理组织切片特征层次较深的问题,搭建了一个端到端的分割网络,解码器采用了简化的 U-Net++,编码器使用了经过迁移学习的 Efficient-Net。该网络通过平衡模型的宽度与深度,在减少训练参数的同时捕捉到更丰富、更复杂的图像特征,增强对病理组织切片的特征提取能力。

2)针对分割目标形态大小各异的问题,网络中心部分采用多系数级联的空洞卷积,在不使用池化方式、保留图像信息的情况下得到多感受野特征,从而提高网络对多分辨率病理切片的特征提取能力及鲁棒性。

3)针对网络参数量过大的问题,简化了 U-Net++ 解码器部分的跳跃连接,减少网络待优化的参数,在保持较高分割精度的情况下提高网络的运算速度。添加直连的方式重新设计解码器部分的卷积模块,增加解码器部分的梯度传递能力。

4)针对网络的可解释性与分割精度问题,编码器与解码器之间的跳跃连接采用注意力模块,抑制每层网络对背景区域的特征响应,提高对分割目标的识别精度。

近年来,许多组织举办了有关病理组织切片的病灶点分割挑战赛,从而挖掘更有效的模型。2020年“华录杯”江苏大数据开发与应用大赛(简称“SEED 大赛”)——癌症风险智能诊断竞赛旨在通过提供大规模经过专业医师标注的胃部组织病理切片图像,选手使用深度学习等方法定位识别出胃部组织病理切片图像中的胃癌恶性病变组织部分(即病灶区域),辅助医生进行诊断,提高病理的检测效率。使用本文提出的 ADEU-Net 在本次大赛的测试集中获得了好成绩。

1 本文方法

1.1 整体网络架构

U-Net 的编码器—解码器结构有助于同时获取图像的上下文信息和位置信息,对大分辨率医学图像的分割有杰出表现。U-Net++(Zhou 等,2018b)通过短连接方式,有效融合了深浅层的特征,进一步

提高了图像分割的准确度。综合考虑细胞病理切片图像特征后,本文搭建了基于 U-Net++ 的分割网络

ADEU-Net。ADEU-Net 网络结构组成为编码器、中间部分和解码器 3 个部分,如图 1 所示。




图 1 ADEU-Net 网络结构

Fig. 1 The architecture of ADEU-Net

绿色部分为采用 EfficientNet 结构的编码器。红色部分为解码器,在原始 U-Net++ 基础上减少了大量的跳跃连接,使每一个节点只保留一次跳跃连接。为了增强对多尺寸目标的识别,ADEU-Net 额外增加了橙色的中间部分,级联多个空洞系数的空洞卷积得到不同感受野的特征。

1.2 编码器设计

ADEU-Net 使用在数据集 ImageNet (Deng 等, 2009) 上预训练的高效率网络 (EfficientNet) (Tan 和 Le, 2019) 作为编码器。针对不同的数据集分辨率和样本数量,编码器可以灵活地替换为不同深度的 EfficientNet 模型。EfficientNet 的特征提取部分被拆分为 5 个阶段,图 2 中以 EfficientNet-b0 为例,每个阶段对输出的特征图采用 3×3 卷积,步长为 2,并保持与原图相同的填充,因此输出特征图的宽和高均缩小一倍。其中编码器的核心模块为移动翻转瓶颈卷积 (mobile inverted bottleneck convolution, MBConv),该模块引入了压缩与激发网络 (squeeze-and-excitation network, SENet) (Hu 等, 2018) 的注意

力思想,对特征图进行通道上的压缩与激发,生成含全局信息的注意力掩膜。将该掩膜与原特征图相乘,从而达到抑制无用通道特征响应的效果。




图 2 ADEU-Net 的 EfficientNet-b0 编码器结构

Fig. 2 EfficientNet-b0 encoder structure of ADEU-Net

1.3 空洞卷积模块

考虑到病理切片图像的复杂性、图像整体的相关性以及每幅数据样本原始分辨率分布的差异,提高网络中心部分特征的感受范围以及对多重感受野的特征融合是十分有意义的。池化方式可以高效地

提高特征图的感受野,但同时也会因为特征图分辨率的下降而丢失重要的空间信息。参考 D-LinkNet (Zhou 等,2018a) 的处理方法,ADEU-Net 的中心部分设计了一个带有跳跃连接的 3 层空洞卷积模块 DBlock 来获得 3 种感受野的特征。该模块的结构如图 3 所示(其中 C 表示编码器的输出通道数),具体定义为

$$d = \psi(C(\sigma(g_1); \sigma(g_2); \sigma(g_3))) \quad (1)$$

式中, g_i 表示第 i 层空洞卷积的输出; σ 为 ELU (exponential linear units) 激活函数,本文中该激活函数的可调参数 α 均设为 1; C 表示将特征图按通道堆叠; $\psi \in \mathbf{R}^{1 \times 1 \times N/2}$ 为卷积参数矩阵,其中 N 为输入 DBlock 模块的特征图大小。

空洞卷积通过在卷积核中注入空洞,在不引入新的参数量的同时有效提高了感受野,具体定义为

$$g[x, y] = \sum_i^M \sum_j^M f[x + r \cdot i, y + r \cdot j] \cdot h[i, j] \quad (2)$$

式中, x, y 表示特征点坐标, i, j 表示卷积点坐标, M 为卷积核大小, r 为空洞系数,在标准的卷积操作中 $r = 1$ 。 f 为输入特征, h 为卷积核, g 为输出特征。

但是,如果在连续的空洞卷积层中采用非互质

的空洞系数设置,会产生特征图采样不连续的问题,即网格效应,从而丢失大量的特征信息。为了避免该效应,并兼顾对大小物体的分割效果,DBlock 的空洞系数设置遵循混合空洞卷积 (hybrid dilated convolution, HDC) (Wang 等,2018) 的设计结构,将 3 层空洞系数分别设为 1、2、5,卷积核大小均为 3×3 ,步长为 1。这样的设置既能使 DBlock 模块的浅层获得特征图的相邻信息,提高对小目标的识别能力;也能使深层获得与特征图相近的感受野,提高对大目标的识别能力。

感受野计算为

$$l_k = l_{k-1} + ((f_k - 1) \times \prod_{i=1}^{k-1} s_i) \quad (3)$$

式中, l_k 为第 k 层每个点的感受野; f_k 为第 k 层卷积核大小; s_i 为第 i 层的卷积步长。通过式(3)计算出每层相对于编码器输出特征图的实际感受野分别为 3、7、17。由于编码器的输出特征图大小为 16×16 ,第 3 层空洞卷积的特征点将覆盖 DBlock 输入特征图中较为完整的信息。另外,ADEU-Net 中的 DBlock 将不同感受野的特征图进行通道堆叠后使用 1×1 卷积替代了通道相加的方式,提高了网络自适应地调整不同感受野特征权重的能力,促进了信息融合。




图3 ADEU-Net 的 DBlock 模块

Fig.3 DBlock module of ADEU-Net

1.4 解码器设计

ADEU-Net 的解码器借鉴了 U-Net ++ 的短连接架构。为了使整体网络参数量保持与 U-Net ++ 相近,且出于细胞病理切片分割任务的实际需求,ADEU-Net 的每一个节点的跳跃连接只保留一次,均连接到最右侧的解码器节点。该方式通过将更多的参数量分配给网络的特征提取部分,在硬件条件

有限的情况下牺牲了适量分割边缘精度来提高对分割目标的识别准确度。为了弥补该部分跳跃连接数量减少所带来的梯度难以传递、且神经元容易死亡的现象,可将 ADEU-Net 解码器部分卷积模块设计为残差块(He 等,2016)的形式,并选择指数线性单元(exponential linear units, ELU) (Clevert 等,2016) 作为激活函数,如图 4 所示。除此之外,ADEU-Net

还可以选择使用深度监督 (Lee 等, 2015) 的方式对网络进行训练。若使用该方式, 解码器的 (上采样 4, 3) 节点将增加一层逆卷积得到 DS (deep supervision) 节点, 输出与分割图的维度一致的特征图并共

同参与损失值计算。该方式只会在训练的过程传递梯度值, 在进行验证的时候 DS 节点将不参与计算。中心部分的 16×16 像素特征图将通过解码器逐层上采样恢复到 512×512 像素的大小, 即产生分割结果。




图 4 ADEU-Net 解码器内的卷积模块

Fig. 4 Convolution module in the decoder of ADEU-Net

1.5 注意力模块

在 ADEU-Net 的编码器设计中引入针对通道的注意力思想, 有效提高了编码器特征提取能力, 从而抑制了冗余特征层的特征表达。除此之外, 由于病理切片图像的目标与背景在空间特征具有一定相似性, 为了弥补编码器在空间上注意力的不足, 有效地抑制特征图中的背景特征响应, ADEU-Net 额外引入针对空间的注意力思想, 将编码器节点的跳跃连接替换为注意力模块 (attention block) (Oktay 等, 2018), 使特征图的注意力集中在目标区域附近。注意力模块简单高效, 且参数量低, 定义如下

$$\alpha_i = \sigma_2(\psi(\sigma_1(W_x x_i + W_g g_i + b_g))) + b_\psi \quad (4)$$

$$\hat{x}_i = \alpha_i \otimes x_i \quad (5)$$

式中, $x_i \in \mathbf{R}^{N \times N \times C_1}$ 为第 i 层的编码器节点的输出矩阵, 其中 N 为特征图的大小, C_1 为编码器输出特征图的通道数; $g_i \in \mathbf{R}^{N \times N \times C_2}$ 为解码器节点的输出矩阵, 其中 C_2 为编码器输出特征图的通道数; $\psi \in \mathbf{R}^{1 \times 1 \times C_2}$ 、 $W_x \in \mathbf{R}^{1 \times 1 \times C_2/2}$ 与 $W_g \in \mathbf{R}^{1 \times 1 \times C_2/2}$ 均为卷积的参数矩阵, $b_g \in \mathbf{R}^{C_2/2}$ 与 $b_\psi \in \mathbf{R}$ 均为卷积的偏置向量; σ_1 与 σ_2 分别为 ELU 激活函数与 Sigmoid 激活函数, 输出的 $\alpha_i \in \mathbf{R}^{N \times N \times 1}$ 即第 i 层的注意力门 (attention gate)。 $\otimes$ 为矩阵点乘操作, $\hat{x}_i$ 为注意力模块输出结果, 具体操作如图 5 所示。图中 N 表示输入特征图的大小, C_1 表示阶段 i 输出的通道数, C_2 表示上采样 $i, 0$ 输出的通道数。




图 5 ADEU-Net 的注意力模块

Fig. 5 Attention block of ADEU-Net

2 实验

实验使用 PyTorch 作为深度学习框架。系统的处理器为 64 位 Intel i7-7700, 内存为 16 GB; 同时使用了 GPU 来加速网络的运算速度, 显卡型号为 NVIDIA GTX 1080, 显存为 8 GB。

2.1 数据集介绍和分析

分别使用了 2020 年“华录杯”江苏大数据开发与应用大赛(简称 SEED 大赛)——癌症风险智能诊断赛道与 2017 年中国大数据人工智能创新创业大赛(brain of things, BOT)——病理切片识别 AI(artificial intelligence)挑战赛提供的数据集来测试本文方法。SEED 数据集与 BOT 数据集分别包含 714 幅和 560 幅带胃癌病灶的病理切片样本。两份数据集均为二分类分割问题, 其中癌症细胞区域被标记为前景, 正常细胞区域及无细胞区域被标记为背景。

与自然图像分割任务, 如 PASCAL VOC(pattern analysis, statistical modelling and computational learning visual object classes)(Everingham 等, 2010)、Cityscapes(Cordts 等, 2016)等相比, 细胞病理切片的分割任务具有以下两个特点: 1) 目标(病变细胞)与背景(正常细胞)之间差异较小, 颜色和形态上都具有高度的相似性, 因此病理切片分割模型所需要依赖的图像特征比自然图像更为复杂; 2) 自然图像分割任务注重于目标边缘轮廓的分割精度, 而病理切片的分割任务并不十分注重精确到像素的目标边缘(实际上在 SEED 癌症风险智能诊断竞赛中, 数据集提供的标签也没有提供精确的目标边缘)。除此之外, SEED 比赛中提供的数据集原始图像分辨率分布差异较大(如图 6 所示, 每个点代表一个样本), 训练集图像分辨率最小为 372×489 像素, 最大为 $12\,047 \times 18\,257$ 像素, 图像均在 20 倍率视野下采集得到。若对图像尺寸进行归一化, 每幅图像的细胞大小相应地会有较大的差异。BOT 数据集所有样本分辨率均为 $1\,024 \times 1\,024$ 像素, 但大部分病灶点区域较小。

2.2 训练细节

对于 SEED 竞赛数据集, 在比赛中为了充分利用所得的数据集, 本文没有对数据进行划分, 仅使用主办方提供的测试结果衡量本文模型。为了进行更充分的对比实验, 赛后将数据集进行了划分, 对




图6 SEED 数据集尺寸分布图

Fig. 6 Image size distribution of SEED dataset

714 幅样本使用交叉验证方式验证模型。为了避免过拟合以及数据量过小的情况, 实验中进行了大量的数据增强, 包括但不限于水平翻转、垂直翻转、随机平移旋转缩放、色彩抖动、亮度对比度变化、模糊处理和增加噪声等。对于 BOT 竞赛数据集, 对 560 幅样本进行五折交叉验证, 数据增强方式与前者相同。两个数据集中的图像均缩放至 512×512 像素大小。

二元交叉熵损失(binary cross entropy, BCE)稳定性较好, 但易受到类别不平衡的问题影响, 定义为

$$L_B = - \sum_i y_i \log \hat{y}_i + (1 - y_i) \log(1 - \hat{y}_i) \quad (6)$$

式中, y_i 表示第 i 个像素的标签值, $\hat{y}_i$ 表示第 i 个像素的预测值。

Dice 损失更关注目标区域, 提高目标分割的效果, 但稳定性较差, 定义为

$$L_D = 1 - \frac{2|\mathbf{y} \cap \hat{\mathbf{y}}|}{|\mathbf{y}| + |\hat{\mathbf{y}}|} \quad (7)$$

式中, $\mathbf{y}$ 表示标签矩阵, $\hat{\mathbf{y}}$ 表示预测矩阵。

为了同时考虑稳定性与类别平衡问题, 本文对所有模型的训练均使用二元交叉熵损失与 Dice 损失的加权和作为总的损失函数, 即

$$L = \sum_{i=1}^N \alpha L_B(\mathbf{y}_i, \hat{\mathbf{y}}_i) + \beta L_D(\mathbf{y}_i, \hat{\mathbf{y}}_i) \quad (8)$$

式中, N 为样本总数, $\mathbf{y}_i$ 与 $\hat{\mathbf{y}}_i$ 分别代表第 i 个标签矩阵与预测矩阵; α 与 β 分别代表两个损失函数的权重, 本文中分别设定为 $\alpha = 0.5$, $\beta = 1$ 。并采用修正自适应矩估计(rectified adaptive moment estimation, RAdam)(Liu 等, 2019)作为所有模型的优化器。本文中参数的设置均为在已有理论及经验的基

础上通过多次实验进行微调后确定,其中学习率初始化为 $5\text{E}-5$,在前 5 个 epochs 线性增长至 $2.5\text{E}-4$ 后使用余弦滚降的策略。训练批次大小均设置为 4,在 200 个 epochs 内网络均达到收敛。

2.3 实验结果

2.3.1 与经典模型对比

首先选取几个经典模型对 SEED 数据集进行实验,包括 U-Net、U-Net++、ResU-Net (Xiao 等,2018) 以及使用 EfficientNet 作为编码器的 U-Net,称之为 EU-Net。其中 EU-Net 分别对比了编码器使用 ImageNet 进行迁移学习前后的结果。在实验中,综合 Dice 系数、平均准确度 (MA)、敏感度 (SE) 和精确率 (PR) 共同作为评价指标,具体计算为

$$f_{\text{Dice}} = \frac{2|y \cap \hat{y}|}{|y| + |\hat{y}|} \tag{9}$$

$$MA = \frac{TP + TN}{TP + FN + TN + FP} \tag{10}$$

$$SE = \frac{TP}{TP + FN} \tag{11}$$

$$PR = \frac{TP}{TP + FP} \tag{12}$$

式中, y 表示标签矩阵, $\hat{y}$ 表示预测矩阵; TP 、 FP 、 FN 、 TN 分别表示真阳性、假阳性、假阴性、真阴性的像素概率。其中 MA 、 SE 与 PR 均通过将预测矩阵以 0.5 为阈值进行二值化后得出。

实验结果如表 1 所示,U-Net 虽然获得了最高的敏感度,但另外 3 项指标与其余模型差距较大。

表 1 经典模型与 EU-Net 在 SEED 数据集上的结果
Table 1 The results of classical algorithms and EU-Net on SEED dataset

模型	Dice	准确度	敏感度	精确度
U-Net	43.89	71.27	92.22	50.61
U-Net++	69.22	81.30	83.42	63.28
ResU-Net	62.25	74.81	85.53	54.12
EU-Net	72.48	85.09	75.85	73.77
EU-Net†	80.77	90.23	85.12	80.94

注:取五折交叉验证的均值作为各模型的评估结果,† 表示使用迁移学习方式,加粗字体为各列最优值。

通过精确度指标可以分析得到,产生该现象的原因是模型倾向于将像素判别为目标,即假阳性过高,在图 7 的 ROC (region of interest) 曲线及 AUC 值

中可以更直观地观察出 U-Net 的不足。原始的 U-Net 编码器较为简单,并没有很好地提取到病理切片图像的深入特征,从而导致模型无法拟合该数据集。将编码器替换为 ResNet 和 EfficientNet,或将编码器的跳跃连接替换为多节点的短连接均对结果有极大的提升,而对编码器的迁移学习也会对 Dice 系数提升 8.29%。其中经过预训练的 EU-Net 有最优的效果。由以上实验可以得出,模型对特征的提取及处理是提高病理切片分割准确度的关键。




图 7 经典模型与 EU-Net 在 SEED 下的 ROC 曲线及 AUC 值

Fig. 7 ROC curve and AUC value of classical algorithms and EU-Net on SEED dataset

2.3.2 各模块消融实验

上述实验中经过预训练的 EU-Net 有着更优的效果,模型也确定了进一步优化的方向,即加强模型特征提取的能力,以及多尺度特征的融合能力。因此在进一步实验中,将使用经过预训练的 EU-Net 作为消融实验的基准模型。本节对以下模型进行了对比:1)将 EU-Net 的解码器替换为与 ADEU-Net 一致的 U-Net++ 结构,实验中称为 EU-Net++ ;2)对模型增加 DBlock 模块,称为 DEU-Net++ ;3)对 DEU-Net++ 增加注意力模块,即 ADEU-Net,并对比 ADEU-Net 采用深度监督学习前后的结果。不同模型在两个数据集上的结果分别如表 2 和表 3 所示。

从评价指标来看,ADEU-Net 在敏感性与精确度指标中表现最优,也就是说该模型对真实病灶区域的识别更为准确,漏判、误判率低;在图像分割常用的 Dice 系数指标和像素准确度中,ADEU-Net 也

表 2 不同模型在 SEED 数据集上的结果

Table 2 The results of different models on SEED dataset

模型	Dice	准确度	敏感度	精确度
EU-Net	80.77	90.23	85.12	80.94
EU-Net++	80.35	89.89	83.77	80.94
DEU-Net++	82.77	90.78	87.98	81.39
ADEU-Net	84.54	92.34	86.70	84.88
ADEU-Net†	85.94	92.93	88.81	85.02

注:取五折交叉验证的均值作为各模型的评估结果,†表示使用深度监督学习方式,加粗字体为各列最优值。

表现最优。在 AUC 指标中, ADEU-Net 模型在 SEED 数据集分数最高, BOT 数据集仅次于 DEU-

表 3 不同模型在 BOT 数据集上的结果

Table 3 The results of different models on BOT dataset

模型	Dice	准确度	敏感度	精确度
EU-Net	75.31	90.79	75.27	73.78
EU-Net++	73.03	89.82	75.42	77.00
DEU-Net++	74.46	90.78	72.70	78.36
ADEU-Net	75.78	90.85	79.57	79.86
ADEU-Net†	75.70	90.71	79.57	79.49

注:取五折交叉验证的均值作为各模型的评估结果,†表示使用深度监督学习方式,加粗字体为各列最优值。

Net++, 证明该模型有较好鲁棒性, ROC 曲线及 AUC 值如图 8 所示。




图 8 不同模型在 SEED 和 BOT 数据集下的 ROC 曲线及 AUC 值

Fig. 8 ROC curve and AUC value of different models on SEED and BOT dataset((a) SEED dataset;(b) BOT dataset)

图 9 中展示了 6 组在不同模型下的分割结果,可以直观地看出,本文提出的 ADEU-Net 对小

目标的分割结果更精细,大面积目标的分割也更完整。




图 9 SEED 和 BOT 数据集分割图

Fig. 9 Segmentation masks of SEED & BOT datasets((a)SEED dataset;(b)BOT dataset)

3 讨论

病理图像分割的难点之一是背景与目标的相似性,因此模型对图像特征的提取比其他分割任务更为关键。EU-Net++在基准模型的基础上增加了编码器到解码器之间的短连接,针对性地增加了网络的特征提取能力,在各项指标上有了明显的提升。短连接有效地融合了深浅层的图像特征,可以使模型保持较高精度的情况下减少解码器的输出通道数。随后该模型增加的空洞卷积模块 DBlock 与注意力模块都更进一步地提取与利用了图像的特征,通过主要的几项指标与分割结果图可以看到模型的效果都有不同程度的提高。DBlock 通过空洞卷积的方式得到更多尺度的感受野,从而使分割目标在整体图像的分割情况更完整准确。如图 9 中 SEED 数据集的第 1 个样本与 BOT 数据集的第 2 个样本所示,DEU-Net++与 ADEU-Net 对大片病灶区域的分割更为完整。注意力模块通过注意力门调整编码器输出特征的方式,提高对目标区域的特征响应,从而对细微目标的识别更为精确。如 BOT 数据集的第 1、第 3 个样本所示,ADEU-Net 在细小目标区域的识别情况更为准确,误判与漏判病灶点的情况较轻。图 10 展示了一组样本在增加 attention 模块前

后的结果以及最后两层 attention gate 参数平均值的热力图。从热力图可见,注意力门将特征区域的响应限制在目标区域周围,与原始特征图相乘后将达到抑制背景区域特征表达的效果,一定程度上避免了对病灶区域的误判和漏判。




图 10 增加 attention 模块前后分割图及热力图

Fig. 10 Segmentation masks and heat maps before and after adding attention module((a)SEED dataset;(b)BOT dataset)

深度监督学习的方式提高了 ADEU-Net 训练初期的收敛速度,如图 11(a)所示。但该方式给模型增加了额外的参数约束,也可能使模型存在无法达到原本的局部最优的情况,如图 11(b)所示。该方式在两个数据集中表现有优有劣,实际应用中应该综合训练的时间成本以及模型的实际表现来衡量是否采用该手段。




图 11 使用深度监督学习前后验证集的 Dice 系数曲线

Fig. 11 Dice coefficient curves of validation sets before and after deep supervision((a)SEED dataset;(b)BOT dataset)

4 结 论

针对病理切片癌症病灶点的分割任务,本文提出了 ADEU-Net 语义分割模型,实现了端到端的病灶分割。通过选用特征提取能力更强的 EfficientNet 作为编码器,结合多尺度特征的空洞卷积作为中心部分,以及有效融合深浅层特征的 U-Net ++ 结构作为解码器并使用 attention 模块抑制背景的特征响应, ADEU-Net 有效地应对了病理切片图像分割的任务难点,比如背景与目标的相似性高、病灶区域大小不一等。ADEU-Net 在两个数据集上相比于使用 EfficientNet 作为编码器的 U-Net 模型分别得到了 5.17% 和 0.47% 的 Dice 系数提升,验证了本文方法的有效性和泛化性。然而在病灶区域的分割完整度以及与病灶区域相似性更高的背景部分, ADEU-Net 仍有一定的误判概率,分割目标的边缘轮廓也与标签存在一定的误差。在接下来的工作中可以在解码器的设计与训练图像的输入方式、预处理方式上做进一步的研究。此外,虽然 ADEU-Net 的设计最初是针对病理切片图像的,但未来可以将其运用在其他图像特征层次深的语义分割任务中做进一步的探究。

参考文献 (References)

- Bian X W and Ping Y F. 2019. Pathology in China: challenges and opportunities. *Journal of Third Military Medical University*, 41(19): 1815-1817 (卞修武, 平轶芳. 2019. 我国病理学科发展面临的挑战和机遇. *第三军医大学学报*, 41(19): 1815-1817) [DOI: 10.16016/j.1000-5404.201909212]
- Clevert D A, Unterthiner T and Hochreiter S. 2016. Fast and accurate deep network learning by exponential linear units (ELUs)//*Proceedings of the 4th International Conference on Learning Representations, ICLR 2016-Conference Track Proceedings*. San Juan, Puerto Rico, USA: ICLR: 1-14
- Cordts M, Omran M, Ramos S, Rehfeld T, Enzweiler M, Benenson R, Franke U, Roth S and Schiele B. 2016. The cityscapes dataset for semantic urban scene understanding//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, USA: IEEE: 3213-3223 [DOI: 10.1109/CVPR.2016.350]
- Cosatto E, Laquerre P F, Malon C, Graf H P, Saito A, Kiyuna T, Marugame A and Kamijo K. 2013. Automated gastric cancer diagnosis on H and E-stained sections; training a classifier on a large scale with multiple instance machine learning//*Proceedings of Medical Imaging 2013: Digital Pathology*. Lake Buena Vista (Orlando Area), USA: SPIE: 867605 [DOI: 10.1117/12.2007047]
- Deng J, Dong W, Socher R, Li L J, Li K and Li F F. 2009. Imagenet: a large-scale hierarchical image database//*Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition*. Miami, USA: IEEE: 248-255 [DOI: 10.1109/CVPR.2009.5206848]
- Everingham M, Van Gool L, Williams C K I, Winn J and Zisserman A. 2010. The pascal visual object classes (VOC) challenge. *International Journal of Computer Vision*, 88(2): 303-338 [DOI: 10.1007/s11263-009-0275-4]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, USA: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- Hu J, Shen L and Sun G. 2018. Squeeze-and-excitation networks//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, USA: IEEE: 7132-7141 [DOI: 10.1109/CVPR.2018.00745]
- Iizuka O, Kanavati F, Kato K, Rambeau M, Arihiro K and Tsuneki M. 2020. Deep learning models for histopathological classification of gastric and colonic epithelial tumours. *Scientific Reports*, 10(1): #1504 [DOI: 10.1038/s41598-020-58467-9]
- Jin P, Ji X Y, Kang W Z, Li Y, Liu H, Ma F H, Ma S, Hu H T, Li W K and Tian Y T. 2020. Artificial intelligence in gastric cancer: a systematic review. *Journal of Cancer Research and Clinical Oncology*, 146(9): 2339-2350 [DOI: 10.1007/s00432-020-03304-9]
- Khened M, Kollerathu V A and Krishnamurthi G. 2019. Fully convolutional multi-scale residual densenets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers. *Medical Image Analysis*, 51: 21-45 [DOI: 10.1016/j.media.2018.10.004]
- Krizhevsky A, Sutskever I and Hinton G E. 2017. Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6): 84-90 [DOI: 10.1145/3065386]
- Lee C Y, Xie S N, Gallagher P, Zhang Z Y and Tu Z W. 2015. Deeply-supervised nets. *Journal of Machine Learning Research*, 38: 562-570
- Li X M, Chen H, Qi X J, Dou Q, Fu C W and Heng P A. 2018. H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes. *IEEE Transactions on Medical Imaging*, 37(12): 2663-2674 [DOI: 10.1109/TMI.2018.2845918]
- Liao F Z, Liang M, Li Z, Hu X L and Song S. 2019. Evaluate the malignancy of pulmonary nodules using the 3-D deep leaky noisy-OR network. *IEEE Transactions on Neural Networks and Learning Systems*, 30(11): 3484-3495 [DOI: 10.1109/TNNLS.2019.2892409]

- Liu B, Yao K, Huang M M, Zhang J H, Li Y and Li R. 2018. Gastric pathology image recognition based on deep residual networks//Proceedings of the 42nd IEEE Annual Computer Software and Applications Conference (COMPSAC). Tokyo, Japan: IEEE: 408-412 [DOI: 10.1109/COMPSAC.2018.10267]
- Liu L Y, Jiang H M, He P C, Chen W Z, Liu X D, Gao J F and Han J W. 2019. On the variance of the adaptive learning rate and beyond [EB/OL]. [2020-05-17]. <https://arxiv.org/pdf/1908.03265.pdf>
- Long J, Shelhamer E and Darrell T. 2015. Fully convolutional networks for semantic segmentation//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, USA: IEEE: 3431-3440 [DOI: 10.1109/CVPR.2015.7298965]
- Oktay O, Schlemper J, Folgoc L L, Lee M, Heinrich M, Misawa K, Mori K, McDonagh S, Hammerla N Y, Kainz B, Glocker B and Rueckert D. 2018. Attention U-net: learning where to look for the pancreas//Proceedings of the 1st Conference on Medical Imaging with Deep Learning. Amsterdam, The Netherlands: 1-10
- Ronneberger O, Fischer P and Brox T. 2015. U-net: Convolutional networks for biomedical image segmentation//Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Roth H R, Oda H, Hayashi Y, Oda M, Shimizu N, Fujiwara M, Misawa K and Mori K. 2017. Hierarchical 3D fully convolutional networks for multi-organ segmentation [EB/OL]. [2020-11-14]. <https://arxiv.org/pdf/1704.06382.pdf>
- Sharma H, Zerbe N, Klempert I, Hellwich O and Hufnagl P. 2017. Deep convolutional neural networks for automatic classification of gastric carcinoma using whole slide images in digital histopathology. Computerized Medical Imaging and Graphics, 61: 2-13 [DOI: 10.1016/j.compmedimag.2017.06.001]
- Simonyan K and Zisserman A. 2015. Very deep convolutional networks for large-scale image recognition//Proceedings of the 3rd International Conference on Learning Representations, ICLR 2015-Conference Track Proceedings. San Diego, USA: ICLR: 1-14
- Tan M X and Le Q V. 2019. Efficientnet: rethinking model scaling for convolutional neural networks [EB/OL]. [2020-11-09]. <https://arxiv.org/pdf/1905.11946v3.pdf>
- Wang P Q, Chen P F, Yuan Y, Liu D, Huang Z H, Hou X D and Cottrell G. 2018. Understanding convolution for semantic segmentation//Proceedings of 2018 IEEE Winter Conference on Applications of Computer Vision (WACV). Lake Tahoe, USA: IEEE: 1451-1460 [DOI: 10.1109/WACV.2018.00163]
- Xiao X, Lian S, Luo Z M and Li S Z. 2018. Weighted res-UNet for high-quality retina vessel segmentation//Proceedings of the 9th International Conference on Information Technology in Medicine and Education (ITME). Hangzhou, China: IEEE: 327-331 [DOI: 10.1109/ITME.2018.00080]
- Zhou L C, Zhang C and Wu M. 2018a. D-LinkNet: linknet with pre-trained encoder and dilated convolution for high resolution satellite imagery road extraction//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Salt Lake City, USA: IEEE: 182-186 [DOI: 10.1109/CVPRW.2018.00034]
- Zhou Z, Siddiquee M M R, Tajbakhsh N and Liang J. 2018b. UNet++: a nested U-Net architecture for medical image segmentation//Stoyanov D, Taylor Z, Carneiro G, Syeda-Mahmood T, Martel A, Maier-Hein L, Tavares J M R S, Bradley A, Papa J P, Belagiannis V, Nascimento J C, Lu Z, Conjeti S, Moradi M, Greenspan H and Madabhushi A, eds. Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. Cham: Springer: 3-11 [DOI: 10.1007/978-3-030-00889-5_1]

作者简介



陈颖锬, 1998年生, 男, 硕士研究生, 主要研究方向为计算机视觉、医学图像处理。

E-mail: vincechan@nuaa.edu.cn



万程, 通信作者, 女, 讲师, 主要研究方向为计算机视觉、医学影像分析。

E-mail: wanch@nuaa.edu.cn

李晗, 女, 硕士研究生, 主要研究方向为计算机视觉、医学图像处理。E-mail: lhlyx_mail@163.com

周雪婷, 女, 硕士研究生, 主要研究方向为计算机视觉、医学图像处理。E-mail: zhxt0919@nuaa.edu.cn