



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

中国图象学报 中国图形学报

2022
03
VOL.27

ISSN1006-8961
CN11-3758/TB



医学图像及临床应用



第27卷第3期（总第311期）
2022年3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



慢阻肺患者CT图像中肺内血管分割及定量分析(第0762页)



基于特征选择与残差融合的肝肿瘤分割模型(第0838页)



面向乳腺超声计算机辅助诊断的两阶段深度迁移学习(第0898页)

专刊封面展示了上海科技大学生物医学工程学院和上海联影智能医疗科技有限公司合作的脑影像智能分析方向研究成果。

《中国图象图形学报》医学图像及临床应用专刊简介

沈定刚, 刘天明, 周涛, 夏勇, 白相志, 王乾, 李刚, 徐寿平, 刘昊, 韩向娣 0653

综述

中国医学影像人工智能20年回顾和展望

蒋希, 袁奕宣, 王雅萍, 肖振祥, 朱美芦, 陈泽华, 刘天明, 沈定刚 0655

迁移学习在医学图像分类中的研究进展

黎英, 宋佩华 0672

生成对抗式网络及其医学影像应用研究综述

张颖麟, 胡衍, 东田理沙, 刘江 0687

基于深度学习的心脏磁共振影像超分辨率前沿进展

李书林, 冯朝路, 于鲲, 刘鑫, 江鑫, 赵大哲 0704

CT图像肺及肺病变区域分割方法综述

冯龙锋, 陈英, 周滔辉, 胡菲, 易珍 0722

计算机断层扫描图像

结构图注意力网络的新冠肺炎轻重症诊断

刘彦北, 李赫南, 张长青, 肖志涛, 张芳, 陈英, 高耀宗, 石峰, 单飞, 沈定刚 0750

慢阻肺患者CT图像中肺内血管分割及定量分析

赵宏, 李璋, 张杰华, 王琨, 孙家兴, 廖玺铭, 阎昱升, 钟正, 张鑫, 孙健, 于起峰, 葛俊辉 0762

基础信息保持和细节强化的胸部CT图像增强

张余, 张顺利, 白相志, 张利 0774

面向小样本股骨骨折分型的多视角注意力融合方法

张亚东, 汪玲, 兰海, 翟禹樵, 程洪 0784

三维多尺度嵌套U结构CT影像肺结节检测

许正奎, 张少敏, 支力佳, 周涛 0797

融合多尺度残差和注意力机制的特发性肺纤维化进展预测

陈舞, 孙军梅, 李秀梅 0812

COVID-19肺部CT图像多尺度编解码分割

陆倩杰, 柏正尧, 樊圣澜, 周雪, 许祝 0827

基于特征选择与残差融合的肝肿瘤分割模型

乔伟晨, 黄冕, 刘利军, 黄青松 0838

磁共振图像

面向多模态MRI脑胶质瘤区域三维分割与生存期预测的级联U-Net网络

余力, 刘霄雪, 闫朝阳, 李建瑞, 张志强, 黄轲, 徐军 0850

心脏动态MRI图像分割的时空多尺度网络

徐佳陈, 肖志勇 0862

融合跨阶段深度学习的脑肿瘤MRI图像分割

夏峰, 邵海见, 邓星 0873

融入平滑组稀疏化的脑部MRI图像分类

黄帅辉, 王金凤 0885

超声图像

面向乳腺超声计算机辅助诊断的两阶段深度迁移学习

贡荣麟, 施俊, 周玮珺, 汪程 0898

结合注意力机制的乳腺双模态超声分类网络

赵绪, 龚勋, 樊琳, 罗俊 0911

中医图像

视觉Transformer与多特征融合的脑卒中检测算法

赵琛琦, 王华虎, 赵涓涓, 冀伦文, 王麒达, 李慧芝, 赵紫娟 0923

多分支深度特征融合的中医脑卒中辅助诊断

王麒达, 冀伦文, 强彦, 王华虎, 赵琛琦, 李慧芝, 赵紫娟 0935

研究应用

多区域融合注意力网络模型下的核性白内障分类

章晓庆, 肖尊杰, Risa Higashita, 陈婉, 胡衍, 袁进, 刘江 0948

面向高度近视条纹损伤的深监督特征聚合网络

谭晓, 刁逸超, 陈新建, 石霏, 樊莹, 谢嘉受, 朱伟芳 0961

结合目标检测与匹配修正的手腕骨感兴趣区域提取

毛科技, 汪敏豪, 陈立建, 陆伟, 武坤秀, 陈庆章, 赵小敏 0973

面向旷场实验视频分类的特征拼接矩阵学习方法


肖照林, 杨志林, 刘欢, 金海燕 0988

基于图像的介入器械前端变形建模与受力估计


任龙飞, 孟偲, 刘博, 白相志, 周付根 1001

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Segmentation and quantitative analysis of intrapulmonary vasculature in CT images from COPD patients(P0762)



Feature selection and residual fusion segmentation network for liver tumor(P0838)



Two-stage deep transfer learning for human breast ultrasound computer-aided diagnosis(P0898)

Review

- A 20-year retrospect and prospect of medical imaging artificial intelligence in China
Jiang Xi, Yuan Yixuan, Wang Yaping, Xiao Zhenxiang, Zhu Meilu, Chen Zehua, Liu Tianming, Shen Dinggang 0655
- Review of transfer learning in medical image classification
Li Ying, Song Peihua 0672
- A review of generative adversarial networks and the application in medical image
Zhang Yinglin, Hu Yan, Risa Higashita, Liu Jiang 0687
- Critical review of human cardiac magnetic resonance image super resolution reconstruction based on deep learning method
Li Shulin, Feng Chaolu, Yu Kun, Liu Xin, Jiang Xin, Zhao Dazhe 0704
- Review of human lung and lung lesion regions segmentation methods based on CT images
Feng Longfeng, Chen Ying, Zhou Taohui, Hu Fei, Yi Zhen 0722

Computerd Tomography Image

- Diagnosis of COVID-19 by using structural attention graph neural network
Liu Yanbei, Li Henan, Zhang Changqing, Xiao Zhitao, Zhang Fang, Wei Ying, Gao Yaozong, Shi Feng, Shan Fei, Shen Dinggang 0750
- Segmentation and quantitative analysis of intrapulmonary vasculature in CT images from COPD patients
Zhao Hong, Li Zhang, Zhang Jiehua, Wang Kun, Sun Jiaxing, Liao Ximing, Yan Yusheng, Zhong Zheng, Zhang Xin, Sun Jian, Yu Qifeng, Ge Junhui 0762
- Human chest CT image enhancement based on basic information preservation and detail enhancement
Zhang Yu, Zhang Shunli, Bai Xiangzhi, Zhang Li 0774
- Multi-view attention fusion method for few-shot femoral fracture classification
Zhang Yadong, Wang Ling, Lan Hai, Zhai Yuqiao, Cheng Hong 0784
- Detection of pulmonary nodules in three-dimensional multiscale nested U-structure computed tomography images
Xu Zhengxi, Zhang Shaomin, Zhi Lijia, Zhou Tao 0797
- Multi-scale residual and attention mechanism fusion based prediction for the progression of idiopathic pulmonary fibrosis
Chen Wu, Sun Junmei, Li Xiumei 0812
- Multiscale codec network based CT image segmentation for human lung disease derived of COVID-19
Lu Qianjie, Bai Zhengyao, Fan Shenglan, Zhou Xue, Xu Zhu 0827
- Feature selection and residual fusion segmentation network for liver tumor
Qiao Weichen, Huang Mian, Liu Lijun, Huang Qingsong 0838

Magnetic Resonance Image

- Brain glioma tumor segmentation and survival prediction from multi-modality MRIs via cascaded U-Net
Yu Li, Liu Xiaoxue, Yan Chaoyang, Li Jianrui, Zhang Zhiqiang, Huang Yunzhi, Xu Jun 0850
- A spatio-temporal multi-scale network for cardiac dynamic MRI image segmentation
Xu Jiachen, Xiao Zhiyong 0862
- Cross-stage deep-learning-based MRI fused images of human brain tumor segmentation
Xia Feng, Shao Haijian, Deng Xing 0873
- Brain MRI image classification incorporating smooth group sparseness
Huang Shuaihui, Wang Jinfeng 0885

Ultrasound Image

- Two-stage deep transfer learning for human breast ultrasound computer-aided diagnosis
Gong Ronglin, Shi Jun, Zhou Weijun, Wang Cheng 0898
- Attention-based networks of human breast bimodal ultrasound imaging classification
Zhao Xu, Gong Xun, Fan Lin, Luo Jun 0911

Traditional Chinese Medical Image

- Cerebral stroke detection algorithm for visual Transformer and multi-feature fusion
Zhao Chenqi, Wang Huahu, Zhao Juanjuan, Ji Lunwen, Wang Qida, Li Huizhi, Zhao Zijuan 0923
- Multi-branch deep feature fusion method for traditional Chinese medicine intervened Human cerebral stroke aided diagnosis
Wang Qida, Ji Lunwen, Qiang Yan, Wang Huahu, Zhao Chenqi, Li Huizhi, Zhao Zijuan 0935

Research and Application

- Nuclear cataract classification based on multi-region fusion attention network model
Zhang Xiaoqing, Xiao Zunjie, Risa Higashita, Chen Wan, Hu Yan, Yuan Jin, Liu Jiang 0948
- Deep-supervision and feature-aggregation network for linear lesion segmentation of high myopia
Tan Xiao, Diao Yichao, Chen Xinjian, Shi Fei, Fan Ying, Xie Jiamin, Zhu Weifang 0959
- Hand-wrist region of interest extraction based on object detection and matching correction
Mao Keji, Wang Minhao, Chen Lijian, Lu Wei, Wu Kunxiu, Chen Qingzhang, Zhao Xiaomin 0973
- A spliced feature matrices learning method for open field test video classification
Xiao Zhaolin, Yang Zhilin, Liu Huan, Jin Haiyan 0988
- Image-based deformation modeling and force estimation of the front end of vascular interventional surgical apparatus
Ren Longfei, Meng Cai, Liu Bo, Bai Xiangzhi, Zhou Fugen 1001

中图法分类号: TP302 文献标识码: A 文章编号: 1006-8961(2022)03-0873-12

论文引用格式: Xia F, Shao H J and Deng X. 2022. Cross-stage deep-learning-based MRI fused images of human brain tumor segmentation. Journal of Image and Graphics, 27(03): 0873-0884 (夏峰, 邵海见, 邓星. 2022. 融合跨阶段深度学习的脑肿瘤 MRI 图像分割. 中国图象图形学报, 27(03): 0873-0884) [DOI:10.11834/jig.210330]

融合跨阶段深度学习的脑肿瘤 MRI 图像分割

夏峰¹, 邵海见^{1,2*}, 邓星^{1,2}

1. 江苏科技大学计算机学院, 镇江 212003;

2. 东南大学自动化学院复杂工程系统测量与控制教育部重点实验室, 南京 210009

摘要: 目的 磁共振成像(magnetic resonance imaging, MRI)作为一种非侵入性的软组织对比成像方式,可以提供有关脑肿瘤的形状、大小和位置等有价值的信息,是用于脑肿瘤患者检查的主要方法,在脑肿瘤分割任务中发挥着重要作用。由于脑肿瘤本身复杂多变的形态、模糊的边界、低对比度以及样本梯度复杂等问题,导致高精度脑肿瘤 MRI 图像分割非常具有挑战性,目前主要依靠专业医师手动分割,费时且可重复性差。对此,本文提出一种基于 U-Net 的改进模型,即 CSPU-Net(cross stage partial U-Net)脑肿瘤分割网络,以实现高精度的脑肿瘤 MRI 图像分割。**方法** CSPU-Net 在 U-Net 结构的上下采样中分别加入两种跨阶段局部网络结构(cross stage partial module, CSP)提取图像特征,结合 GDL(general Dice loss)和 WCE(weighted cross entropy)两种损失函数解决训练样本类别不平衡问题。**结果** 在 BraTS (brain tumor segmentation) 2018 和 BraTS 2019 两个数据集上进行实验,在 BraTS 2018 数据集中的整体肿瘤分割精度、核心肿瘤分割精度和增强肿瘤分割精度分别为 87.9%、80.6% 和 77.3%,相比于传统 U-Net 的改进模型(ResU-Net)分别提升了 0.80%、1.60% 和 2.20%。在 BraTS 2019 数据集中的整体肿瘤分割精度、核心肿瘤分割精度和增强肿瘤分割精度分别为 87.8%、77.9% 和 70.7%,相比于 ResU-Net 模型提升了 0.70%、1.30% 和 1.40%。**结论** 本文提出的跨阶段局部网络结构,通过增加梯度路径、减少信息损失,可以有效提高脑肿瘤分割精度,实验结果证明了该模块对脑肿瘤分割任务的有效性。

关键词: 脑肿瘤分割;深度学习;U-Net;跨阶段局部网络结构;残差模块

Cross-stage deep-learning-based MRI fused images of human brain tumor segmentation

Xia Feng¹, Shao Haijian^{1,2*}, Deng Xing^{1,2}

1. School of Computer Science, Jiangsu University of Science and Technology, Zhenjiang 212003, China;

2. Key Laboratory of Complex Engineering System Measurement and Control, School of Automation,

Southeast University, Ministry of Education, Nanjing 210009, China

Abstract: **Objective** Human brain tumors are a group of mutant cells in the brain or skull. These benign or malignant brain tumors can be classified based on their growth characteristics and influence on the human body. Gliomas are one of the most frequent forms of malignant brain tumors, accounting for approximately 40% to 50% of all brain tumors. Glioma is classified as high-grade glioma (HGG) or low-grade glioma (LGG) depending on the degree of invasion. Low-grade glioma

收稿日期:2021-05-18;修回日期:2021-10-29;预印本日期:2021-11-05

* 通信作者: 邵海见 jsj_shj@just.edu.cn

基金项目:国家自然科学基金项目(61806087, 61902158)

Supported by: National Natural Science Foundation of China (61806087, 61902158)

(LGG) is a well-differentiated glioma with a prompt prognosis. High-grade glioma (HGG) is a poorly differentiated glioma with a qualified prognosis. Gliomas with varying degrees of differentiation are appeared following the varied degrees of peritumoral edema, edema types, and necrosis. the boundary of gliomas and normal tissues is often blurred. It is difficult to identify the scope of lesions and surgical area, which has a significant impact on surgical quality and patient prognosis. As a non-invasive and clear soft tissue contrast imaging tool, magnetic resonance imaging (MRI) can provide vital information on the shape, size, and location of brain tumors. High-precision brain tumor MRI image segmentation is challenged due to the complicated and variable morphology, fuzzy borders, low contrast, and complicated sample gradients of brain tumors. Manual segmentation is time-consuming and inconsistent. The International Association for Medical Image Computing and Computer-Aided Intervention (MICCAI)'s Brain Tumor Segmentation (BraTS) is a global medical image segmentation challenge concentrating on the evaluation of automatic segmentation methods for human brain tumors. There are four types of automatic brain tumor segmentation algorithms as mentioned below: supervised learning, semi-supervised learning, unsupervised learning, and hybrid learning. Supervised-learning-based algorithm is currently the effective method. Various depth neural network models for computer vision problems, such as Visual Geometry Group Network (VGGNet), GoogLeNet, ResNet, and DenseNet, have been presented in recent years. The above deep neural network model proposes a novel approach to the problem of MRI brain image segmentation, and it significantly advances the development of deep learning-based brain tumor diagnosis methods. As a result, deep learning method is to develop the task of automatic segmentation of brain tumor MRI images. **Method** Our research integrates low resolution information and high resolution information via the U-Net structure of the all convolutional neural network. An improved cross stage partial U-Net (CSPU-Net) brain tumor segmentation network derived from the U-Net network achieves high-precision brain tumor MRI image segmentation. The basic goal of the cross stage partial (CSP) module is to segment the grass-roots feature mapping into two sections as following: 1) Dividing the gradient flow to extend distinct network paths, and then 2) fusing the two portions based on horizontal hierarchy. The conveyed gradient information can have huge correlation discrepancies by alternating series and transition procedures. To extract image features, CSPU-Net adds two types of cross stage partial network structures to the up and down sampling of the U-Net network. The number of gradient routes is increased using the splitting and merging technique. The drawbacks of utilizing explicit feature map replication for connection are mitigated, enhancing the model's feature learning capabilities. To overcome the imbalance issue of sample class, two loss functions, general dice loss and weighted cross-entropy are combined. The cross stage partial structure is final compared to ResU-Net, which adds a residual block, to in identify the effectiveness of cross stage partial structure as ResU-Net in the brain tumor segmentation test. **Result** Our experimental results of the CSPU-Net model in the context of the BraTS 2018 and BraTS 2019 datasets has its priority. The BraTS 2018 dataset yielded 87.9% accuracy in whole tumor segmentation, 80.6% accuracy in core tumor segmentation, and 77.3% accuracy in enhanced tumor segmentation, respectively. This method enhances the segmentation accuracy of brain tumor MRI images by 0.80%, 1.60%, and 2.20% each. In the BraTS 2019 dataset, the whole tumor segmentation accuracy is 87.8%, the core tumor segmentation accuracy is 77.9%, and the improved tumor segmentation accuracy is 70.7%, respectively. This method enhances the segmentation accuracy of brain tumor MRI images by 0.70%, 1.30%, and 1.40%, respectively in comparison of the traditional improved ResU-Net. **Conclusion** This research provides a cross-stage deep learning-based 2D segmentation network for human brain tumor MRI images. Using cross stage partial network structure in U-Net up and down sampling, the model enhances the accuracy of brain tumor segmentation via gradient path expansion and information loss deduction. The demonstrated results illustrate that our model has its potentials on BraTS datasets on 2D segmentation models development and demonstrates the module's efficiency in the brain tumor segmentation task.

Key words: brain tumor segmentation; deep learning; U-Net; cross stage partial network structure; residual module

0 引言

脑肿瘤是在大脑或头骨中生长的异常细胞,在

医学上根据其生长特性以及对人体的影响分为良性脑肿瘤和恶性脑肿瘤,后者比前者具有更高的发病率以及危害性(孙佳伟,2020)。恶性神经胶质瘤是最常见的恶性脑肿瘤类型之一,约占颅脑肿瘤的

40%~50%,根据神经胶质瘤的浸润程度分为高级别脑胶质瘤(high-grade glioma, HGG)和低级别脑胶质瘤(low-grade glioma, LGG)。高级别脑胶质瘤(HGG)为低分化胶质瘤,患者生存预后较差;低级别脑胶质瘤(LGG)为分化良好的胶质瘤,患者预后相对较好(Haris等,2008)。由于不同分化级别的神经胶质瘤通常伴有不同的瘤周水肿程度、水肿类型以及坏死程度,并且与正常组织之间的界限模糊,导致医生难以确定病变的范围和手术区域,严重影响了手术质量和患者预后。因此,在手术前根据影像资料确认肿瘤部位、识别整体肿瘤有助于减少手术中不必要的组织损伤,最大限度地保护神经功能(Işın等,2016)。由于脑肿瘤组织的磁场信号与人体正常脑组织相差无几,并且增强核磁共振注射的造影能清晰地区分恶性肿瘤(马凤,2013),因此增强核磁共振成像(magnetic resonance imaging, MRI)检查是目前脑肿瘤患者检查的主要手段之一,能有效提供有关脑肿瘤的形状、大小和位置等信息(Gondal和Khan,2013),有利于提高临床医生对脑肿瘤的诊断水平。脑肿瘤影像分析的最终目标是提取患者重要的临床信息及诊断特征,并嵌入多维图像数据中,以便在发现疾病后进行相关的指导和监测,进而实施相关干预措施,最终获得相应的临床诊断、分期和治疗方法(Wong,2005),具有非常重要的现实意义。由于在脑肿瘤诊断过程中使用核磁共振图像具有非常多的优点,也使得计算机辅助诊疗脑肿瘤成为医学影像领域最热门的研究问题之一。

国际医学图像计算和计算机辅助干预协会举办的多模态脑肿瘤分割(brain tumor segmentation, BraTS)是一项全球范围的医学图像分割挑战,专注于评估脑肿瘤的自动分割算法。脑肿瘤自动分割算法分为基于监督学习、半监督学习、无监督学习以及混合学习的算法,基于监督学习的算法是目前的主流方法(Guo等,2020)。由于深度神经网络在监督学习领域中展现出强大的自动提取判别特征功能,其在脑肿瘤分割领域的应用也成为计算机视觉任务的研究热点(Litjens等,2017),并提出了用于计算机视觉任务的各种深度神经网络模型,例如VGG-Net(Visual Geometry Group network)(Simonyan和Zisserman,2015),GoogLeNet(Szegedy等,2015),ResNet(He等,2016)和DenseNet(Huang等,2017)。以上深度神经网络模型为解决MRI脑图像分割问

题提供了新思路,极大促进了基于深度学习的脑肿瘤诊断方法的发展(Shaikh等,2018;田伟倩,2020;孙浩,2020)。基于深度学习的图像分割方法主要分为卷积神经网络(convolutional neural network, CNN)和全卷积神经网络(fully convolutional network, FCN)两种。基于卷积神经网络的脑肿瘤分割方法主要采用小尺度图像块的分类方法设计包含单路径和多路径方法的MRI脑肿瘤分割网络。与单路径卷积神经网络相比,多路径卷积神经网络可以从不同路径获取各种信息并进行汇总。Havaei等人(2017)提出一种新颖的卷积神经网络架构,构建多路径网络并使用不同大小的卷积核提取重要的上下文特征,用于分析2D MRI图像中脑肿瘤相关信息。Pereira等人(2016)提出另一种基于VGGNet的 3×3 小卷积核的分割网络,有效降低了模型的过拟合。Zhao和Jia(2016)使用类似的卷积神经网络方法从2D MRI脑胶质瘤图像中自动提取病灶,克服了人工处理存在的费时、重复性差的缺点。Moeskops等人(2016)使用3条具有不同大小感受野的卷积路径,用以获取更多细节特征以及分析空间一致性来进行脑肿瘤分割。但由于卷积神经网络架构是一种基于小图像块的方法,需要较大存储空间并且缺乏空间连续性,导致效率低下,分割效果并不理想。而全卷积神经网络基于编码—解码概念逐像素执行计算的方法,不仅提高了图像分割效率,而且解决了空间连续性问题,是目前图像语义分割任务的重要方法之一(Shelhamer等,2017)。Ronneberger等人(2015)提出一种适用于各种医学图像分割问题的U-Net体系结构,该体系基于编码和解码路径的概念,利用编码路径提取上下文特征,解码路径保证精确跟踪位置,两者之间的横向连接用于减少下采样中带来的信息损失。U-Net非常适合数据量少的多模态医学图像分割任务,已经成为脑肿瘤分割领域的主流算法。Dong等人(2017)提出一种基于U-Net的2D分割网络,并利用实时数据增强的方法,提高了脑肿瘤分割的精度。Kong等人(2018)在U-Net架构中添加了特征金字塔模块,通过集成位置信息和多尺度语义特征提高准确性。Wang等人(2019a)证明使用卷积神经网络和测试时间增强技术(test-time augmentation, TTA)有助于提高脑肿瘤分割的准确性。Isensee等人(2019)通过改进数据预处理过程,在传统U-Net模型基础上提出了NNU-Net,进一步提

高了脑肿瘤分割的精度。Nvidia 团队的 Myronenko (2019) 采用带有 VAE (variational auto encoder) 模块的多分支级联结构, 获得了 BraTS 2018 挑战赛的第 1 名。Jiang 等人 (2020) 设计了一种新型的两阶段级联 U-Net, 在 BraTS 2019 训练数据集中进行端到端训练, 将脑肿瘤图像由粗略到精细进行分割, 在 BraTS 2019 竞赛中获得了第 1 名。

但是, 由于脑肿瘤中复杂的特征分布和医学图像数据集数量的局限性, 相较于整体肿瘤, 小范围的核心肿瘤和增强肿瘤难以实现较高 MRI 图像分割精度的问题仍亟需解决。为了解决这个问题, 需要增强上下采样过程中网络的特征学习能力, 减少下采样过程中的信息损失。Alom 等人 (2019) 提出在 U-Net 中上下采样加入递归残差卷积层 (recurrent residual convolutional neural network, RRCNN), 在视网膜图像血管分割、皮肤癌分割和肺部病变分割等任务皆取得了更好的效果。Li 等人 (2018) 提出使用 dense 结构改进 U-Net 结构中的常规卷积层, 将紧密连接路径的优势与 U-Net 特点相结合, 设计了一类 DenseU-Net 模型来有效地分析肝脏和肿瘤特征。跨阶段局部网络结构 (cross stage partial module, CSP) 是 Wang 等人 (2020) 提出用于增强卷积神经网络学习能力的一种网络结构, 在 ImageNet 数据集上获得了更高的准确率。Bochkovskiy 等人 (2020) 在 YOLO (you only look once) 模型中使用 CSP 方法, 达到了目标检测任务的最优速度和精度。针对上述问题与研究现状, 本文提出在 U-Net 上下采样过程中加入跨阶段局部网络结构 (CSP) 来增强普通卷积核的分析能力, 并提出一种 CSPU-Net (cross stage partial U-Net) 的新型脑肿瘤分割模型。实验结果表明, 相较于原始 U-Net 以及 ResU-Net, 该模型在脑肿瘤分割数据库上取得了更优越的图像分割性能。

本文工作包含 3 部分: 1) 将跨阶段局部网络结构引入脑肿瘤分割任务中, 通过分裂合并策略使梯度路径的数目翻倍, 减轻使用显式特征映射复制进行连接的缺点, 增强模型特征学习能力; 2) 使用 general Dice loss 和 weighted cross-entropy 两种损失函数解决 MRI 脑肿瘤图像类别不平衡问题; 3) 在 BraTS 2018 和 BraTS 2019 数据集上进行实验, 将本文方法分割结果与 U-Net 以及 ResU-Net 进行比较, 证明跨阶段局部网络结构在脑肿瘤分割任务中的有

效性。

1 CSPU-Net 模型结构设计与分析

1.1 数据集

实验使用两个用于脑肿瘤分割的基准数据库: BraTS 2018 以及 BraTS 2019 数据集。BraTS 2018 数据集是来自 285 名胶质瘤患者的脑肿瘤图像合集, 其中训练集包含 210 名高级胶质瘤患者和 75 名低级胶质瘤患者的图像, 验证数据集包括 66 名未知级别的患者的图像。BraTS 2019 数据集包含 335 个胶质瘤病例的训练集, 其中 259 个属于高级胶质瘤, 76 个属于低级胶质瘤, 验证集包含 125 个未知级别案例。数据标签共 4 类, 即肿瘤增强区、水肿区、坏死区以及健康组织。分割结果通过整体 (whole tumor, WT)、核心 (tumor core, TC) 以及增强 (enhance tumor, ET) 等指标评估。WT 包括肿瘤增强区、水肿区以及坏死区, TC 包括肿瘤增强区和坏死区, ET 包括肿瘤增强区。如图 1 所示, 每个患者数据有 5 幅图像, 分别是 flair、T1、T1CE 和 T2 共 4 种 MRI 模式以及专家手动分割用于进行比较的真实标签, 红色部分表示坏死区, 绿色部分为水肿区, 黄色部分为增强肿瘤区, 黑色区域为背景。

1.2 数据预处理

由于脑肿瘤形态和位置的不确定性、界限的模糊以及手动注释偏差, 因此脑肿瘤图像的数据预处理尤为重要。本文采用多模态 3D MRI 脑肿瘤图像, 每个 3D MRI 图像数据的大小 $240 \times 240 \times 155$ 。由于图像包含有效的信息和许多无用的背景部分, 因此首先将 3D 图像的大小调整为 $146 \times 192 \times 152$, 以消除无关背景并降低计算量。进而去除 1% 的最高和 1% 的最低 3D 图像像素强度, 以消除一些极端值的影响。由于本文采用 2D 卷积神经网络框架, 故将每个 3D 图像切片为 2D 图像并提取 128×128 像素大小的有效像素作为模型输入。同时, 使用归一化公式处理相关 MRI 图像, 提高图像预处理的合理性, 具体为

$$x_p = \frac{x - \bar{x}}{\sigma} \quad (1)$$

式中, x 是输入的 3D 图像, x_p 是处理后的归一化图像, $\bar{x}$ 是输入图像的平均值, σ 是输入图像的标准偏差。




图1 脑肿瘤 MRI 图像

Fig. 1 MRI images of brain tumor((a) flair;(b) T1;(c) T1CE;(d) T2;(e) ground truth)

1.3 CSPU-Net 结构

在脑肿瘤分割任务上,大多数情况下可以很容易地检测到异常组织的存在,但是准确、可重复地分割出肿瘤区域边界极为困难(Gordillo 等,2013)。特别是对于具有复杂形态和模糊边界的小规模脑肿瘤,在脑肿瘤分割任务中很难做到高精度的小规模脑肿瘤分割。除此之外,在网络上采样和下采样过程中,由于连续卷积和非线性变换过程导致大量信息损失,使得小规模肿瘤识别任务更为困难。为解决这些问题,本文将 CSP 模块分别应用到 U-Net 模型中的编码器和解码器当中,集成为 CSPU-Net 模型,可以将网络前段所有层的输出特征连接起来作为后面的输入,能够有效地增强信息的表述能力。CSPU-Net 的整体架构如图 2 所示。CSPU-Net 保持了传统的编码器—解码器架构,由图像压缩路径(左侧编码器)和图像扩展路径(右侧解码器)组成。整体网络的输入维度是 $128 \times 128 \times 4$,其中 128×128 像素表示每个图像的尺寸,4 表示输入图像的通道数。编码器和解码器结构分别具有 3 个块。编码器一侧中的每个块由两个卷积层组成,其中第 1 个卷积层使用 CSP 模块替代传统的 3×3 卷积结构,第 2 个卷积层则用于替换传统 U-Net 下采样中的最大池化操作,以减少信息损失、避免梯度消失以及加速网络融合。当每个图像进入编码器块中第 2 个卷积层时,其尺寸将减少到一半且同时通道将扩充一倍。解码器一侧中的每个块由上采样加卷积和 CSP 模块两个部分组成,上采样层中通过步长为 2 的双

线性插值使图像大小翻倍,再经过卷积核数量减半的卷积层使通道数量减半,完成上采样过程。同时,为了增加非线性和模型收敛速度,模型的每个卷积层之后都进行批量标准化和非线性激活函数操作。在模型的最后一个解码器块中额外加入 PReLU(parameteric ReLU)激活函数以及使用 SoftMax 激活函数功能的 1×1 卷积将多通道特征映射到相应的类别。PReLU 和 SoftMax 激活函数计算为

$$PReLU(x_i) = \begin{cases} x_i & x_i > 0 \\ \alpha_i x_i & x_i \leq 0 \end{cases} \quad (2)$$

式中, i 表示不同的通道, α_i 是一个需要学习的参数,其值更新采用带动量的更新方式,对于第 i 个通道, α_i 值是相同的, x_i 表示第 i 个通道的输入矩阵的值。

$$P(y|c) = \frac{e^{h(c_i y_i)}}{\sum_{j=1}^n e^{h(c_j y_j)}} \quad (3)$$

式中, c 表示预测结果类别, y_i 表示预测结果为 c_i 的概率, h 表示元素的指数, n 表示预测结果类别总数,最终求得的 y 表示每个分类被取到的概率,该激活函数常用于多分类问题。

1.4 CSP 模块

ResNeXt 证明了分支路径的数量在提升网络性能方面比宽度和深度的提升更显著。因此,使用 CSP 模块的主要目的是将基层的特征映射分为两部分,通过分割梯度流使梯度流通过不同的网络路径传播,然后通过横级层次结构合并这两部分。通过




图2 CSPU-Net 整体结构图

Fig. 2 Structure of CSPU-Net

交替进行串联和过渡操作,传播的梯度信息可以具有较大的相关性差异。如图3所示,本文使用了先过渡再串联加过渡以及过渡后串联直接输出两种融合方式的 CSP 模块。其中串联操作表示将多个卷积特征提取框架提取的特征沿通道维度进行拼接。图3(a)为先经过过渡操作再串联再进行过渡的融

合方式,可以保证输出图像通道数不变,并且截断梯度流,保证梯度流不会重复使用,由此降低模型参数量。在图3(b)中,路径B的输出将通过过渡层,然后使用路径A的特征映射进行串联,将输出图像通道翻倍。

下采样过程中使用的 CSP 模块结构如图4所示。该模块首先对输入数据进行一个 3×3 的卷积操作,并将网络结构分成两条路径,其中路径A直接与路径B的输出串联起来,形成一种类似于残差网络的结构。路径B则先经过一个卷积核数量减半的 3×3 卷积层,使得通道数减半且参数量减少,随后再分成两条路径,将 3×3 卷积层的输出与上一层输入串联起来。该方法总体思路是最大化梯度组合的差异,通过跨阶段的拆分和合并策略,能够有效减少信息集成过程中复制的可能性。


CSP 模块计算为

$$p(A) = BN(F(x, \omega_i)) \quad (4)$$

$$p(B) = T([F(p(A), \omega_i^l), F(F(p(A), \omega_i^l), \omega_i^l)]) \quad (5)$$

$$csp(x) = BN([p(A), p(B)]) \quad (6)$$

式中, x 为输入图像, $F(x, \omega_i)$ 表示对输入图像进行 3×3 卷积操作,卷积核数目为 ω_i , ω_i^l 表示 ω_i 一半数目的卷积核, T 表示为过渡层操作, $[\cdot, \cdot]$ 表示串联操作。 $p(A)$ 表示路径A的输出结果, $p(B)$ 表示路径B的输出结果, $csp(x)$ 表示该模块最终输出结果。模型中每个 3×3 卷积层之后都添加了



(a) 串联在过渡层之间

(b) 串联在过渡层之后

图3 CSP 模块的两种融合方式

Fig. 3 Two fusion methods of CSP block ((a) concatenate between transitions; (b) concatenate after transition)




图 4 下采样中 CSP 模块结构

Fig. 4 CSP module structure in downsampling

BN(batch normalization)层以及 LeakyReLU 激活函数,用以解决反向传播过程中梯度方向锯齿问题。BN 层的计算为

$$y_i^{(b)} = BN(x_i)^{(b)} = \gamma \cdot \left(\frac{x_i^{(b)} - \mu(x_i)}{\sqrt{\sigma(x_i)^2 + \varepsilon}} \right) + \beta \quad (7)$$

式中, x_i 为 $[x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(m)}]$ 构成的行向量, m 表示每次送入训练的样本数, $x_i^{(b)}$ 表示输入批次中的第 b 个样本时该层第 i 个输入节点的值。 $\mu(x_i)$ 和 $\sigma(x_i)^2$ 分别表示该行向量的均值和方差, ε 为防止除 0 引入的极小值, γ 和 β 为待学习的缩放比例和偏移值参数。

1.5 损失函数

类别不平衡问题是脑肿瘤分割任务中最关键的问题之一。不同类别在 BraTS 2018 数据集的分布及占有区域如表 1 所示。可以看出,各类之间存在明显差异。在脑肿瘤 MRI 中,健康组织的平均占用区域为 98.46%。而水肿、增强肿瘤和非增强肿瘤占据的区域分别为 1.02%、0.29% 和 0.23%。脑肿瘤 MRI 中不同类别的区域占用率的巨大差异对

其分割准确性产生了巨大影响。

为解决类别不平衡问题,添加 general Dice loss (Sudre 等, 2017) 和 weighted cross-entropy (Ren 等, 2019) 两种损失函数,以便更好地评价模型性能,两种损失函数的计算分别为

$$L_{GDL} = 1 - \frac{2 \sum_{c=1}^Q w_c l_c f_c}{\sum_{c=1}^Q w_c (l_c + f_c)} \quad (8)$$

$$L_{WCE} = - \sum_{c=1}^Q \omega_c l_c \log(f_c) \quad (9)$$

式中, L_{WCE} 表示加权交叉熵(weighted cross entropy, WCE)损失函数,该方法是对多类别不平衡问题的良好解决方案,可以降低训练样本和评估度量之间的差异,使网络重视样本占有率较小的类别。 L_{GDL} 表示 general Dice loss 函数,该函数常用于医学图像中的小目标分割,允许模型专注于难以学习的样本。每个标签的权重通过其体积的倒数进行校正,从而减少区域大小与 Dice 分数之间的相关性。 L_{GDL} 负责预测分割区域, L_{WCE} 用于进行组织细胞的分类。 Q 表示标签的总数,在脑肿瘤分割数据集中,标签总数为 4, c 代表标签的序号, ω_c 表示分配给第 c 个标签的权重。 f_c 表示被分割的 2 维图像像素值, l_c 是 2 维图像像素的真实值。完整的损失函数 L 为

$$L = L_{GDL} + L_{WCE} \quad (10)$$

2 实验设计与性能评估

2.1 实验环境与配置

本文模型使用的深度学习框架是以 Tensorflow

表 1 脑肿瘤 MRI 图像中不同类别占用区域

Table 1 Areas occupied by different categories in MRI images of brain tumors

类别	占有区域比重 /%
健康组织	98.46
水肿	1.02
增强肿瘤	0.29
非增强肿瘤	0.23

为后端的 Keras 2.2.4, 硬件环境为 32 GB 内存和 TESLA V100 GPU 的集群。每个模型使用随机梯度下降(stochastic gradient descent, SGD)算法作为优化器, 初始学习率为 0.085, 动量为 0.95, 权重衰减为 $5E-6$ 。模型的输入为 flair、T1、T1CE、T2 共 4 种 MRI 模式图像以及专家手动分割标签图像, 批量大小设置为 10, 训练 5 个周期。

2.2 评价指标

对本文提出模型的性能评估, 采用 Dice 系数 (Dice similarity coefficient, DSC) 作为分割网络的评价指标。Dice 系数主要用于衡量两个集合之间的相似性, 值在 0 ~ 1 之间。目前脑肿瘤分割任务普遍采用 Dice 系数评价模型优劣, 具体为

$$DSC = \frac{2TP}{FP + 2TP + FN} \quad (11)$$

式中, TP (true positive) 表示通过深度学习模型正确归类为脑肿瘤的像素总数, FP (false positive) 为错误分类的像素数。 TN (true negative) 和 FN (false negative) 分别表示模型正确归类为健康组织的像素数和错误归类为健康组织的像素数。

2.3 实验结果与分析

首先使用 BraTS 2018 和 BraTS 2019 两个训练数据集分别训练模型, 再将训练得到的模型验证 BraTS 2018 和 BraTS 2019 验证数据集。随后将验证得到的分割结果上传到官方在线网站, 由网站给出模型最终的分割精度, 并与其他方法得到精度进行对比。最后根据实验结果, 讨论本文使用的基本模块, 即 CSP 模块对模型分割精度的影响。

2.3.1 BraTS 2018 实验结果

首先在 BraTS 2018 验证数据集中评估模型, 在保证同样训练条件与超参数的条件下, 分别在编码器和解码器阶段使用两种 CSP 策略, 并对验证结果进行对比, 评估结果如表 2 所示。CSPU-Net1 在编码和解码阶段都使用图 3(a) 的方法, CSPU-Net2 和 CSPU-Net3 分别在上采样和下采样使用图 3(b) 的融合策略, 即先过渡再融合的方法, 在分割精度上相对于 CSPU-Net1 又有提升。由此可见, 使用先过渡后融合的方法精度最高, 本文最终采用的 CSPU-Net 是在上下采样中皆使用先过渡后融合的方法。

从表 2 可以看出, 本文提出的 CSPU-Net 在模型对比中表现出最佳性能, 在整体肿瘤、核心肿瘤和增强肿瘤上的 DSC 值分别为 87.9%、80.6% 和 77.3%,

表 2 BraTS 2018 验证集的评估结果

Table 2 Evaluation results of BraTS 2018 validation set

网络模型	分割精度		
	整体肿瘤	肿瘤核心	增强肿瘤
U-Net	0.865	0.782	0.743
ResU-Net	0.871	0.790	0.751
CSPU-Net1	0.874	0.797	0.754
CSPU-Net2	0.875	0.800	0.755
CSPU-Net3	0.877	0.801	0.754
CSPU-Net	0.879	0.806	0.773

注: 加粗字体为各列最优结果。

与原始模型 U-Net 相比, 分别提升了 1.40%、2.40% 和 3.00%。与相对于另一组模型 ResU-Net 实现的 87.1%、79.0% 和 75.1% 的 DSC 相比, 本文模型仍有 0.80%、1.60% 和 2.20% 的提升。在增强肿瘤分割结果上, 本文模型表现效果显著, 相比于其他两种方法分别取得了 3.00% 和 2.20% 的提升, 证明了 CSP 模块可以增强网络模型提取图像特征能力以及减少信息损失。

为验证本文方法在小规模脑肿瘤分割任务上的有效性, 将模型在 BraTS 2018 数据集上的分割结果与其他方法进行对比, 结果如表 3 所示, 可以看出, 本文提出的 CSPU-Net 与其他先进方法相比, 在整体肿瘤分割方面表现一般。这主要是由 GPU 显

表 3 BraTS 2018 验证集与其他先进方法的比较

Table 3 Compared with the-state-of-art methods on BraTS 2018 validation set

网络模型	分割精度		
	整体肿瘤	肿瘤核心	增强肿瘤
Shen 等人(2017)	0.833	0.747	0.681
Ma 和 Yang(2019)	0.872	0.773	0.743
Marcinkiewicz 等人(2019)	0.862	0.768	0.723
Wang 等人(2019b)	0.869	0.796	0.733
Hu 等人(2019)	0.882	0.748	0.718
Wang 等人(2019a)	0.873	0.783	0.754
Chen 等人(2019)	0.894	0.831	0.749
冯博文(2020)	0.900	0.730	0.710
Zhou 等人(2020)	0.864	0.773	0.752
本文	0.879	0.806	0.773

注: 加粗字体为各列最优结果。

存大小产生的问题,本文采用的2D网络只能利用脑图像的2D切片进行训练,在整体肿瘤分割上相比于3D网络与2.5D网络尚有一定差距。在核心肿瘤分割方面,CSPU-Net仅次于Chen等人(2019)提出的可分离3D U-Net。但是在增强肿瘤分割方面,本文方法仍取得了最好的表现,这证明了本文方法可以显著提高小规模肿瘤的分割性能。

2.3.2 BraTS 2019 实验结果

使用与 BraTS 2018 数据集上同样的策略在 BraTS 2019 数据集中进行实验评估,验证本文模型性能,实验结果如表4所示。可以看出,在 BraTS 2019 数据集中,本文提出的 CSPU-Net 相比于传统 U-Net 及其改进 ResU-Net,分割精度仍有提升,在整体肿瘤、核心肿瘤和增强肿瘤上的 DSC 值分别为 87.8%、77.9% 和 70.7%,与原始模型 U-Net 相比,分别提升了 1.30%、3.10% 和 2.90%。相对于另一组模型 ResU-Net 实现的 87.1%、76.6% 和 69.3% 的 DSC,本文提出模型仍有 0.70%、1.3% 和 1.40% 的提升。

表4 BraTS 2019 验证集的评估结果

Table 4 Evaluation results of BraTS 2019 validation set

网络模型	分割精度		
	整体肿瘤	肿瘤核心	增强肿瘤
U-Net	0.865	0.748	0.678
ResU-Net	0.871	0.766	0.693
本文	0.878	0.779	0.707

注:加粗字体为各列最优结果。

为进一步验证本文方法在脑肿瘤分割任务中的有效性,将模型在 BraTS 2019 数据集上的分割结果与其他先进方法进行对比,结果如表5所示。相比于2020—2021年提出的2D模型,本文方法在整体肿瘤分割精度上与Ding等人(2020)提出的多路径自适应融合网络基本持平,在其他两项指标上都有明显提高。在增强肿瘤分割精度上略低于Amian和Soltaninejad(2020)使用的3D ResU-Net,但其他两项指标上都明显高于该方法,表明即使与更复杂的3D网络比较,本文提出的2D网络仍具有一定竞争力。

2.4 实验结果展示

最后,分别使用3种网络训练得出的模型对 BraTS 2018 训练集进行分割,模型的输入图像与分

表5 BraTS 2019 验证集与其他先进方法的比较

Table 5 Compared with the-state-of-art methods on BraTS 2019 validation set

网络模型	分割精度		
	整体肿瘤	肿瘤核心	增强肿瘤
Bhalerao 和 Thakur(2020)	0.852	0.709	0.666
Amian 和 Soltaninejad(2020)	0.860	0.770	0.710
Baid 等人(2020)	0.870	0.770	0.700
Guo 等人(2020)	0.872	0.728	0.677
Di Ieva 等人(2021)	0.878	0.731	0.699
Ding 等人(2020)	0.880	0.730	0.670
本文	0.878	0.779	0.707

注:加粗字体为各列最优结果。

割结果如图5所示。可以看出,本文方法对于肿瘤边缘分割更为平滑。从图像1和图像3的分割结果可以看出,U-Net与ResU-Net相较于GT(ground truth)图像,在核心肿瘤区域上都存在过分割问题。在图像3中,U-Net与ResU-Net都将核心肿瘤区域上方的像素错误归类于核心肿瘤,相比之下,本文方法分割出的核心肿瘤区域与GT图像更加接近。

3 结论

本文针对传统U-Net以及ResU-Net在上下采样结构中的不足,通过将跨阶段局部网络结构引入到U-Net中,提出一种新型脑肿瘤分割模型CSPU-Net,通过分裂合并策略分割梯度流,减少信息损失并增强模型特征学习能力,结合general Dice loss和weighted cross-entropy两种损失函数解决脑肿瘤MRI图像类别不平衡问题,从而获得更高的脑肿瘤MRI分割精度。为证明本文方法的有效性,分别使用BraTS 2018和BraTS 2019数据集进行实验。实验结果表明,本文方法在脑肿瘤分割任务上的性能明显优于其他2D分割网络,在整体肿瘤、核心肿瘤和增强肿瘤分割精度上都有显著提升。相较于部分3D分割网络,本文方法在核心肿瘤和增强肿瘤分割精度上仍有一定优势。但是,由于使用2D网络对3D图像数据进行分割本身就具有一定局限性,只能使用2D切片进行训练,导致模型无法获取图层之间的关系信息,造成大量信息损失。因而在




图5 各模型输入图像与分割结果

Fig. 5 Input images and segmentation results of each model

((a) flair; (b) T1; (c) T1CE; (d) T2; (e) ground truth; (f) U-Net; (g) ResU-Net; (h) ours)

整体肿瘤分割精度上,本文提出的2D网络模型相较于3D网络模型仍存在差距。此外,本文仅在脑肿瘤MRI分割任务上验证了本文方法的有效性,并未在新增的肿瘤像素点不确定性评估任务上进行研究。在后续工作中,将使用3D网络模型来有效利用3D图像数据,将本文方法应用于3D网络模型中,并对肿瘤像素点的不确定性评估任务进行尝试,从而进一步提升脑肿瘤MRI分割精度。

参考文献 (References)

- Alom M Z, Yakopcic C, Hasan M, Taha T M and Asari V K. 2019. Recurrent residual U-Net for medical image segmentation. *Journal of Medical Imaging*, 6 (1): #014006 [DOI: 10.1117/1.JMI.6.1.014006]
- Amian M and Soltaninejad M. 2020. Multi-resolution 3D CNN for MRI brain tumor segmentation and survival prediction//*Proceedings of the 5th International MICCAI Brainlesion Workshop*. Shenzhen, China; Springer: 221-230 [DOI: 10.1007/978-3-030-46640-4_21]
- Baid U, Shah N A and Talbar S. 2020. Brain tumor segmentation with cascaded deep convolutional neural network//*Proceedings of the 5th International MICCAI Brainlesion Workshop*. Shenzhen, China; Springer: 90-98 [DOI: 10.1007/978-3-030-46643-5_9]
- Bhalerao M and Thakur S. 2020. Brain tumor segmentation based on 3D residual U-Net//*Proceedings of the 5th International MICCAI Brainlesion Workshop*. Shenzhen, China; Springer: 218-225 [DOI: 10.1007/978-3-030-46643-5_21]
- Bochkovskiy A, Wang C Y and Liao H Y M. 2020. YOLOv4: optimal speed and accuracy of object detection [EB/OL]. [2021-05-03]. <https://arxiv.org/pdf/2004.10934.pdf>
- Chen W, Liu B Q, Peng S T, Sun J W and Qiao X. 2019. S3D-UNet; separable 3DU-Net for brain tumor segmentation//*Proceedings of the 4th International MICCAI Brainlesion Workshop*. Granada, Spain; Springer: 358-368 [DOI: 10.1007/978-3-030-11726-9_32]
- Di Ieva A, Russo C, Liu S D, Jian A N, Bai M Y, Qian Y and Magnusen J S. 2021. Application of deep learning for automatic segmentation of brain tumors on magnetic resonance imaging: a heuristic approach in the clinical scenario. *Neuroradiology*, 63 (8): 1253-1262 [DOI: 10.1007/s00234-021-02649-3]
- Ding Y, Gong L P, Zhang M F, Li C and Qin Z G. 2020. A multi-path adaptive fusion network for multimodal brain tumor segmentation. *Neurocomputing*, 412: 19-30 [DOI: 10.1016/j.neucom.2020.06.078]
- Dong H, Yang G, Liu F D, Mo Y H and Guo Y K. 2017. Automatic brain tumor detection and segmentation using U-Net based fully convolutional networks//*Proceedings of the 21st Annual Conference on Medical Image Understanding and Analysis*. Edinburgh, UK; Springer: 506-517 [DOI: 10.1007/978-3-319-60964-5_44]
- Feng B W. 2020. Research on multi-scale feature segmentation of Brain Tumors MRI based on parallel CNN (冯博文. 2020. 脑肿瘤MRI的并行CNN多尺度特征分割技术研究. 内蒙古: 内蒙古科技大学) [DOI: 10.27724/d.cnki.gnmkgk.2020.000421]
- Gondal A H and Khan M N A. 2013. A review of fully automated techniques for brain tumor detection from MR images. *International Journal of Modern Education and Computer Science*, 5 (2): 55-61 [DOI: 10.5815/ijmecs.2013.02.08]
- Gordillo N, Montseny E and Sobrevilla P. 2013. State of the art survey

- on MRI brain tumor segmentation. *Magnetic Resonance Imaging*, 31(8): 1426-1438 [DOI: 10.1016/j.mri.2013.05.002]
- Guo X T, Yang C S, Ma T, Zhou P Z, Lu S F, Ji N, Li D L, Wang T and Lyu H Y. 2020. Brain tumor segmentation based on attention mechanism and multi-model fusion//*Proceedings of the 5th International MICCAI Brainlesion Workshop*. Shenzhen, China: Springer: 50-60 [DOI: 10.1007/978-3-030-46643-5_5]
- Haris M, Gupta R K, Singh A, Husain N, Husain M, Pandey C M, Srivastava C, Behari S and Rathore R K S. 2008. Differentiation of infective from neoplastic brain lesions by dynamic contrast-enhanced MRI. *Neuroradiology*, 50(6): 531-540 [DOI: 10.1007/s00234-008-0378-6]
- Havaei M, Davy A, Warde-Farley D, Biard A, Courville A, Bengio Y, Pal C, Jodoin P M and Larochelle H. 2017. Brain tumor segmentation with deep neural networks. *Medical Image Analysis*, 35: 18-31 [DOI: 10.1016/j.media.2016.05.004]
- 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 K, Gan Q H, Zhang Y, Deng S H, Xiao F, Huang W, Cao C H and Gao X P. 2019. Brain tumor segmentation using multi-cascaded convolutional neural networks and conditional random field. *IEEE Access*, 7: 92615-92629 [DOI: 10.1109/ACCESS.2019.2927433]
- Huang G, Liu Z, Van Der Maaten L and Weinberger K Q. 2017. Densely connected convolutional networks//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE: 2261-2269 [DOI: 10.1109/CVPR.2017.243]
- Isensee F, Kickingereder P, Wick W, Bendszus M and Maier-Hein K H. 2019. No New-Net//*Proceedings of the 4th International MICCAI Brainlesion Workshop*. Granada, Spain: Springer: 234-244 [DOI: 10.1007/978-3-030-11726-9_21]
- Işın A, Direkçioğlu C and Şah M. 2016. Review of MRI-based brain tumor image segmentation using deep learning methods. *Procedia Computer Science*, 102: 317-324 [DOI: 10.1016/j.procs.2016.09.407]
- Jiang Z Y, Ding C X, Liu M F and Tao D C. 2020. Two-stage cascaded U-Net: 1st place solution to brats challenge 2019 segmentation task//*Proceedings of the 5th International MICCAI Brainlesion Workshop*. Shenzhen, China: Springer: 231-241 [DOI: 10.1007/978-3-030-46640-4_22]
- Kong X M, Sun G X, Wu Q, Liu J and Lin F M. 2018. Hybrid pyramid U-Net model for brain tumor segmentation//*Proceedings of the 10th International Conference on Intelligent Information Processing*. Nanjing, China: Springer: 346-355 [DOI: 10.1007/978-3-030-00828-4_35]
- 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]
- Litjens G, Kooi T, Bejnordi B E, Setio A A A, Ciompi F, Ghafoorian M, Van Der Laak J A W M, Van Ginneken B and Sánchez C I. 2017. A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42: 60-88 [DOI: 10.1016/j.media.2017.07.005]
- Ma F. 2013. 3D Volume Enhanced Scanning Techniques of Magnetic Resonance Imaging Used in Intracranial Tumors. Yinchuan: Ningxia Medical University (马凤. 2013. 磁共振三维容积增强扫描技术在颅内肿瘤中的应用. 银川: 宁夏医科大学) [DOI: 10.7666/d.D421508]
- Ma J and Yang X P. 2019. Automatic brain tumor segmentation by exploring the multi-modality complementary information and cascaded 3D lightweight CNNs//*Proceedings of the 4th International MICCAI Brainlesion Workshop*. Granada, Spain: Springer: 25-36 [DOI: 10.1007/978-3-030-11726-9_3]
- Marcinkiewicz M, Nalepa J, Lorenzo P R, Dudzik W and Mrukwa G. 2019. Segmenting brain tumors from MRI using cascaded multi-modal U-Nets//*Proceedings of the 4th International MICCAI Brainlesion Workshop*. Granada, Spain: Springer: 13-24 [DOI: 10.1007/978-3-030-11726-9_2]
- Moeskops P, Viergever M A, Mendrik A M, de Vries L S, Benders M J N L and Išgum I. 2016. Automatic segmentation of MR brain images with a convolutional neural network. *IEEE Transactions on Medical Imaging*, 35(5): 1252-1261 [DOI: 10.1109/TMI.2016.2548501]
- Myronenko A. 2019. 3D MRI brain tumor segmentation using autoencoder regularization//*4th International MICCAI Brainlesion Workshop*. Granada, Spain: Springer: 311-320 [DOI: 10.1007/978-3-030-11726-9_28]
- Pereira S, Pinto A, Alves V and Silva C A. 2016. Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE Transactions on Medical Imaging*, 35(5): 1240-1251 [DOI: 10.1109/TMI.2016.2538465]
- Ren X X, Xing Z C, Xia X, Lo D, Wang X Y and Grundy J. 2019. Neural network-based detection of self-admitted technical debt: from performance to explainability. *ACM transactions on software engineering and methodology*, 28(3): #15 [DOI: 10.1145/3324916]
- Ronneberger O, Fischer P and Brox T. 2015. U-Net: convolutional networks for biomedical image segmentation//*Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention*. Munich, Germany: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Shaikh M, Anand G, Acharya G, Amrutkar A, Alex V and Krishnamurthi G. 2018. Brain tumor segmentation using dense fully convolutional neural network//*Proceedings of the 3rd International MICCAI Brainlesion Workshop*. Quebec City, Canada: Springer: 309-319 [DOI: 10.1007/978-3-319-75238-9_27]
- Shelhamer E, Long J and Darrell T. 2017. Fully convolutional networks

- for semantic segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4): 640-651 [DOI: 10.1109/TPAMI.2016.2572683]
- Shen H C, Wang R X, Zhang J G and McKenna S. 2017. Multi-task fully convolutional network for brain tumour segmentation//*Proceedings of the 21st Annual Conference on Medical Image Understanding and Analysis*. Edinburgh, UK: Springer: 239-248 [DOI: 10.1007/978-3-319-60964-5_21]
- Simonyan K and Zisserman A. 2015. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2021-05-03]. <https://arxiv.org/pdf/1409.1556.pdf>
- Sudre C H, Li W Q, Vercauteren T, Ourselin S and Cardoso M J. 2017. Generalised Dice overlap as a deep learning loss function for highly unbalanced segmentations//*Proceedings of the 3rd International Workshop on Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. Québec City, Canada: Springer: 240-248 [DOI: 10.1007/978-3-319-67558-9_28]
- Sun H. 2020. Research on Classification and Segmentation of MRI of Brain Tumor based on Deep Learning. Hangzhou: Zhejiang University (孙浩. 2020. 基于深度学习的脑肿瘤 MRI 分类与分割技术研究. 杭州: 浙江大学) [DOI: 10.27461/d.cnki.gzjdx.2020.000444]
- Sun J W. 2020. Application of Deep Learning Methods in Brain Tumors. Ji'nan: Shandong University (孙佳伟. 2020. 深度学习在脑肿瘤中的应用. 济南: 山东大学) [DOI: 10.27272/d.cnki.gshdu.2020.004996]
- Sun L, Zhang S T, Chen H and Luo L. 2019. Brain tumor segmentation and survival prediction using multimodal MRI scans with deep learning. *Frontiers in Neuroscience*, 13: #810 [DOI: 10.3389/fnins.2019.00810]
- Szegedy C, Liu W, Jia Y Q, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V and Rabinovich A. 2015. Going deeper with convolutions//*Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, USA: IEEE: 1-9 [DOI: 10.1109/CVPR.2015.7298594]
- Tian W Q. 2020. The Study of Medical Image Segmentation based on Convolution Neural Network. Baoding: Hebei University (田伟倩. 2020. 基于卷积神经网络的医学图像分割算法研究. 保定: 河北大学) [DOI: 10.27103/d.cnki.ghebu.2020.001097]
- Wang C Y, Liao H Y M, Wu Y H, Chen P Y, Hsieh J W and Yeh I H. 2020. CSPNet: a new backbone that can enhance learning capability of CNN//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Seattle, USA: IEEE: 1571-1580 [DOI: 10.1109/CVPRW50498.2020.00203]
- Wang G T, Li W Q, Ourselin S and Vercauteren T. 2019a. Automatic brain tumor segmentation using convolutional neural networks with test-time augmentation//*Proceedings of the 4th International MIC-CAI Brainlesion Workshop*. Granada, Spain: Springer: 61-72 [DOI: 10.1007/978-3-030-11726-9_6]
- Wang W, Yu K C, Hugonot J, Fua P and Salzmann M. 2019b. Recurrent U-Net for resource-constrained segmentation//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV)*. Seoul, Korea (South): IEEE: 2142-2151 [DOI: 10.1109/ICCV.2019.00223]
- Wong K P. 2005. Medical image segmentation: methods and applications in functional imaging//*Handbook of Biomedical Image Analysis*. Boston, USA: Springer: 111-182 [DOI: 10.1007/0-306-48606-7_3]
- Zhao L Y and Jia K B. 2016. Multiscale CNNs for brain tumor segmentation and diagnosis. *Computational and Mathematical Methods in Medicine*, 2016: #8356294 [DOI: 10.1155/2016/8356294]
- Zhou Z X, He Z S, Shi M F, Du J L and Chen D D. 2020. 3D dense connectivity network with atrous convolutional feature pyramid for brain tumor segmentation in magnetic resonance imaging of human heads. *Computers in Biology and Medicine*, 121: #103766 [DOI: 10.1016/j.combiomed.2020.103766]

作者简介



夏峰, 1997 年生, 男, 硕士研究生, 主要研究方向为机器学习、计算机视觉。
E-mail: 209070060@stu.just.edu.cn



邵海见, 通信作者, 男, 副教授, 主要研究方向为机器学习、计算机视觉。
E-mail: jsj_shj@just.edu.cn

邓星, 女, 副教授, 主要研究方向为机器学习、计算机视觉。
E-mail: xdeng@just.edu.cn