



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: TP391.4 文献标识码: A 文章编号: 1006-8961(2022)03-0797-15

论文引用格式: Xu Z X, Zhang S M, Zhi L J and Zhou T. 2022. Detection of pulmonary nodules in three-dimensional multiscale nested U-structure computed tomography images. Journal of Image and Graphics, 27(03): 0797-0811 [许正玺, 张少敏, 支力佳, 周涛. 2022. 三维多尺度嵌套 U 结构 CT 影像肺结节检测. 中国图象图形学报, 27(03): 0797-0811] [DOI: 10. 11834/jig. 210422]

三维多尺度嵌套 U 结构 CT 影像肺结节检测

许正玺¹, 张少敏^{1,2,3*}, 支力佳^{1,2,3}, 周涛^{1,3}

1. 北方民族大学计算机科学与工程学院, 银川 750021; 2. 宁夏回族自治区人民医院医学影像中心, 银川 750000;
3. 北方民族大学图像图形智能处理国家民委重点实验室, 银川 750021

摘要: **目的** 肺结节检测在低剂量肺部计算机断层扫描 (computed tomography, CT) 筛查肺癌中具有重要意义。但由于结节大小、形状和密度的变化十分复杂, 导致难以在低假阳性率下保证高的灵敏度, 这限制了深度学习算法在常规临床实践中的肺结节自动诊断, 建立具有良好结节检测性能的深度学习模型仍然是一个挑战。针对此问题, 本文提出了一种基于 3D Residual U (3D RSU) 块的嵌套 U 结构的肺结节检测框架。**方法** 3D RSU 块通过混合不同大小的感受场获得多尺度特征来丰富特征信息。而嵌套 U 结构允许网络获得更大分辨率的特征图, 从而具有多层次深度特征, 获得丰富的局部和全局信息, 增强网络区分前景和背景的能力, 进而提高微小结节等非显著性目标的检测性能。**结果** 该框架在公共肺结节 (lung nodule analysis 16) 挑战数据集上进行了评价。方法能够准确地检测出肺结节, 灵敏度达到了 97.2%, 与基准方法相比, 该方法灵敏度提高了 2.6%, 具有很高的灵敏度和特异性, 在 0.125、0.25、0.5、1、2、4、8 共 7 个假阳性率的灵敏度平均值为 86.4%, 尤其是在每扫描 0.25 个假阳性上, 灵敏度达到 80.9%, 优于基准算法 76.9% 的结果。**结论** 本文所提出的结节检测模型, 由于在低假阳性率上有较高的灵敏度, 可以使本网络在常规临床实践中为医生辅助诊断提供更加可靠清晰的早期肺癌参考信息。

关键词: 肺结节检测; 嵌套结构; 特征金字塔网络; 非显著性目标检测; 10 折交叉验证

Detection of pulmonary nodules in three-dimensional multiscale nested U-structure computed tomography images

Xu Zhengxi¹, Zhang Shaomin^{1,2,3*}, Zhi Lijia^{1,2,3}, Zhou Tao^{1,3}

1. School of Computer Science and Engineering, North Minzu University, Yinchuan 750021, China;
2. Medical Imaging Center, Ningxia Hui Autonomous Region People's Hospital, Yinchuan 750000, China; 3. Key Laboratory of Images & Graphics Intelligent Processing of State Ethnic Affairs Commission, North Minzu University, Yinchuan 750021, China

Abstract: **Objective** Lung cancer is one of the most common diseases in humans and mainly causes the rising mortality rate. Medical experts believe that the early diagnosis of lung cancer can reduce mortality by screening for lung nodules through computed tomography (CT). Checking a large number of CT images can reduce lung cancer risk. However, CT scan images contain a large volume of information about nodules, and as the number of images increases, accuracy becomes

收稿日期: 2021-06-22; 修回日期: 2021-12-04; 预印本日期: 2021-12-11

* 通信作者: 张少敏 zhangshaomin_nun@sina.com

基金项目: 国家自然科学基金项目 (61561002, 62062003); 宁夏自然科学基金项目 (2020AAC03213, 2021AAC03198); 宁夏自治区重点研发计划项目 (2020BEB04022); “图像与智能信息处理创新团队”国家民委创新团队项目 (PY1606, PY1905); 宁夏医学影像临床研究中心创新平台建设项目 (2018DPG05006); 北方民族大学一般科研项目 (2021XYZJK04)

Supported by: National Natural Science Foundation of China (61561002, 62062003); Ningxia Natural Science Foundation, China (2020AAC03213, 2021AAC03198); Key Research and Development Project of Ningxia Autonomous Region (2020BEB04022)

a very challenging task for radiologists. Therefore, an effective computer-aided diagnosis (CAD) system should be designed. However, the high false-positive rate remains a challenging problem. In response, this paper proposes a new lung nodule detection framework based on 3D ResidualU-blocks (3D RSU) module and nested U structure. **Method** This paper trains an end-to-end lung nodule detection model for one stage. The whole system can shorten the processing time of pulmonary nodule detection without reducing the accuracy of early detection. The 3D deep convolutional neural network (CNN) proposed in this paper is based on the region proposal network (RPN) of the Faster R-CNN Network. The 3D CNN can make full use of the spatial information of CT images. The problem of missed detection by the nodule and the large number of false-positive nodules during detection of nodules with small diameter nodules can be solved by dividing the front back-ground information and enhancing the ability to detect non-salient objects in the image. In this paper, the 3D RSU was designed to capture multi-scale features within the stage. The symmetrical codec structure can be used to learn how to extract and encode multi-scale context information. By using the different layers of 3D RSU, the network can allow feature maps of any spatial resolution as input elements to extract elements at multiple scales. This process reduces the loss of detail caused by large-scale direct up-sampling. The 3D RSU was embedded into the network to form a nested u-shaped structure. This structure allows the network to obtain larger resolution feature maps, thus providing multiple levels of deep features. High-level semantic features can be transitioned to supplement low-level conventional features. Improve the detection performance of non-important targets such as calcification and ground glass. If high-resolution feature maps only are used for prediction, a large amount of lung nodule position information contained in low-resolution feature maps will be lost. Therefore, a feature pyramid network was designed in the decoding structure to integrate low-level high-resolution features. In addition to the strong high-level semantic features, the location details and strong semantics of nodule detection are enriched, and the detection of small nodules is realized. **Result** The framework was evaluated on the public lung nodule analysis (LUNA16) challenge data set containing 888 patient lung nodule labels. A total of 10 folds were observed in the entire data set. This article used a 10-fold cross-validation method to compare performance indicators. Our network training uses a stochastic gradient descent optimizer. The initial learning rate is 0.01. After reaching 1/3 and 2/3 of the total number of iterations, the learning rate was adjusted to 0.001 and 0.000 1, respectively, and the weight attenuation is 1×10^{-4} . The batch size is 8, the number of model iterations is 120, one round of training takes approximately 620 s, and the training of a model takes approximately 20 h. Through ablation and comparative experiments, this paper discusses the advantages of 3D RSU module in pulmonary nodule detection performance compared with Res18, and the structural advantages of nested U structure over traditional U structure. Fewer false-positives means more correct nodules are identified with fewer errors, and more immediate help for doctors. Compared with the 3D ResNet-18 module, the 3D RSU module proposed in this paper has a significant improvement in low false positives. It shows that the 3D RSU module reduces the detail loss caused by large-scale direct-up sampling through codec structure and cascade operation. The semantic features of pulmonary nodules were used to obtain the highest number of low-level features of pulmonary nodules, to allow the network to directly extract multiple proportion features from each residual block. Therefore, compared with 3D Resnet-18 block, 3D RSU block can obtain feature map with richer semantics and clearer location information. Notably, a low false-positive rate is important for the system to identify acceptable modules with less false-positive results. Therefore, the 3D RSU module has a more extensive clinical application value. In comparison with the traditional U-NET structure, the nested U structure proposed in this paper has a slightly higher parameter value than the Res18_FPN_RPN network, and the gap in the test time is almost negligible, indicating that although the structure of this article is more complex, the nested U structure does not remarkably increase the computational overhead. In comparison with benchmark experiments, our method can accurately detect lung nodules with a sensitivity of 97.1%, and the sensitivity increased by 2.5%. This method has high sensitivity and specificity. The average sensitivity of the seven false alarm rate points of 0.125, 0.25, 0.5, 1, 2 and 8 is 86.4%, especially when 0.25 false alarms are scanned per scan, in which the sensitivity reaches 80.9%, which is better than the result of 76.9%. **Conclusion** The nodule detection model proposed in this paper has high sensitivity in the low false-positive rate, thus allowing this network to provide more reliable and clear reference information for early lung cancer diagnosis in routine clinical practice for doctors.

Key words: pulmonary nodule detection; nested structure; feature pyramid network; insignificant target detection; 10-fold cross-validation

0 引言

早期发现肺结节对肺癌的早期诊断具有重要意义(Bray等,2018)。2020年全球癌症死亡病例996万例,其中肺癌死亡180万例,远超其他癌症类型,位居癌症死亡人数第一。早期发现肺结节,及时治疗,5年生存率可提高到55%。因此,早期发现潜在癌性肺结节对降低肺癌死亡率具有重要意义。胸部计算机断层扫描(computed tomography, CT)图像是检测肺结节最常用的成像方式之一。但是CT对于单个患者产生的医疗切片数量通常很多,范围从230~360。由放射科医生对每个切片进行分析将增加工作量并且费时,且易造成直径小于10 mm结节的缺失或误诊。而深度模型在图像领域的进展,有效推动了医学图像处理领域内的很多研究(黄凯奇等,2014;Russakovsky等,2015)。因此在海量医学数据的背景下,如何利用深度学习技术实现一个更高效的计算机辅助系统成为医学领域面临的新挑战。

利用人工智能医学成像技术诊断肺结节是医学领域的重要组成部分,计算机辅助检测(computer-aided diagnosis, CAD)系统的实现是常规临床实践中优化效率和成本的标志性努力。当前肺结节检测算法主要分为基于手动提取特征算法和基于深度神经网络算法。传统的计算机辅助设计系统,首先提取肺结节的灰度和纹理特征,然后利用支持向量机等分类器对提取的特征进行分类和训练,检测出肺结节。Lin等人(2005)根据肺结节和血管的像素值较高且呈圆形的先验知识,通过对图像直方图的分析,找出灰度较高的像素值作为可疑结节的候选点。随着技术的进步,Firmino等人(2016)采用分水岭和直方图技术,结合支持向量机算法对420例肺癌患者进行肺结节检测训练,获得了94.3%的准确率。然而,这些方法都有其固有的缺点,传统的支持向量机算法假设所有特征对目标分类的影响是相同的,因此上述算法适用于小规模数据集,而不适用大规模医学数据集。此外,传统方法提取的特征在表示大量不同的结节特征方面缺乏一致性,而基于深度神经网络可以从训练数据中自动学习出更高效、更有鉴别性的特征。因此,许多学者将深度学习方法应用于图像识别领域,取得了较好的效果。学者们开发了基于卷积神经网络(convolutional neural net-

work, CNN)的两阶段CAD系统用于肺结节检测。一般来说,这些方法包括两步(Polat等,2018),首先,从输入的CT影像中分割出肺部区域,目的是提取病变可能性高的结节。然后降低假阳性,从大量疑似结节中鉴别真结节。Setio等人(2017)提出利用二阶段2D多视图卷积网络来学习肺结节检测的代表性特征。定义了3个探测器来探测实体结节、亚实体结节和大结节,可以结合相对较宽的空间信息进行检测。该方法在LIDC-IDRI(The Lung Image Database Consortium)(Armato等,2011)数据集的基准上,对每一个被试的1.0个假阳性检测灵敏度达到了85.4%,证明了卷积网络在这项任务中的有效性。Cao等人(2020)提出了面向低剂量CT影像的二阶段恶性肺结节检测方法,使用DeepLab-V3 plus模型进行语义分割,证明了对结节进行分类之前添加语义分割阶段可以显著提高准确性,与标准U-Net及其最新版本相比,在LUNA16(lung nodule analysis 16)测试集上,平均交并比(mean intersection over union, MIoU)提高了60%。基于2D卷积的方法尽管取得较大进步,但效果仍然不令人满意,究其原因在于CNNs的解决方案仍然不能充分利用肺部结节的3维空间背景信息,将其从复杂的硬模拟环境中分离出来。毕竟,从容积CT扫描中检测肺结节本质上是一个3D物体检测问题。Zhang等人(2021)提出基于3维密集网络的肺结节检测方法,基于3D U-Net使用密集链接块替代普通卷积层,构建适用于肺结节检测的3D Dense U-Net网络,最大化地保证层与层之间的信息流通对于小结节的检测更加灵敏,而且计算效率也有所提高。基于结节与其邻近像素高度相关的特性,Sori等人(2021)提出了一种具有高效特征融合的双程卷积神经网络(two-path convolutional neural network, DFD-Net)。为解决3维卷积神经网络在训练过程中耗费大量时间和内存的问题,采用了双向前进的2维卷积网络,这两条路径侧重于局部和全局特征的联合集成。每条路径采用不同大小的感受野,建立局部和全局依赖性模型。使用判别相关分析来拼接更具代表性的特征,平衡感受野大小效应,提供更具代表性的特征,适应结节形状和大小之间的不一致性。

尽管二阶段方法有着较高的灵敏度,但伴随而来的是较高的成本和时间等问题,因此提出了越来越多的单阶段CAD系统。Faster R-CNN(王厚华,

2018)作为基于深度学习的目标检测算法,是目前在通用物体检测中精度最高的算法之一,这一算法为一阶段肺结节检测提供了思路而且能真正实现端到端检测。即同时预测边界框和类概率,或者在不生成建议的情况下预测默认框的类概率。Zhu 等人(2018)提出了一阶段基于深度学习的全自动肺癌 CT 诊断系统,3D Faster R-CNN 生成候选结节,然后将其送入 3 维双路径网络(dual path network,DPN)进行深层特征提取,获得了较好的分类效果,在 LUNA16 数据集上获得灵敏度为 95.8%,竞争性指标(competition performance metric,CPM)为 0.842。Li 和 Fan(2020)又在 3D 区域建议网络(region proposal network,RPN)的基础上与具有挤压和激发结构的 SEnet 相结合,提出了一种新型网络,有效地利用多尺度上下文图像信息,使用动态缩放的交叉熵损失,解决 LUNA16 数据集中正样本和负样本的不平衡问题,获得了不错的结果,证明了 RPN 结构在肺结节检测上的优越性。结节可以出现在肺内或肺壁上,导致 3 维肺结节的特征提取过于复杂。因此如何处理全局和局部特征成为提升肺结节检测灵敏度的关键,Shi 等人(2021)提出了一种基于 3 维改进残余结构的肺结节检测模型。扩展感受野的同时降低模型计算量。使用矩形卷积核来扩展卷积运算的接受域,采用分组卷积来降低模型的计算量。同时,采用预激活的方法来提高正则化程度,骨干网络采用改进的 U-Net 网络(U-Net-Like),不仅扩展卷积运算的感受野而且降低模型的计算量,在 LUNA16 数据集上灵敏度为 96.37%,CPM 值为 83.75%。针对当前医学影像分析领域普遍存在的训练样本不足的问题,陈道争和江倩(2021)提出了一种基于卷积神经网络和迁移学习的肺结节检测算法。在 JSRT(Japanese Society of Radiological Technology)数据集上进行验证,得到了较高的灵敏度和较少的假阳性数,证明微调部分网络层有助于提升模型分类性能的结论,验证了迁移学习的有效性。从以上方法可以看出,U-Net 网络在当前肺结节检测网络中的优越性以及一阶段的肺结节检测方法在较低模型参数量和推理时间的情况下,仍有较好的效果(周涛等,2021)。然而,多数一阶段方法依然难以解决假阳性过高的问题,其中最主要的问题集中在难以准确检测直径 3~10 mm 的小结节,当前主流网络均是充分利用现有主干网提取的深度特征,例如 AlexNet(Krizhevsky 等,

2012),VGG(Visual Geometry Group)(Simonyan 和 Zisserman,2014),ResNet(He 等,2016),ResNeXt(Xie 等,2017),DenseNet(Huang 等,2017)等方法。它们提取具有语义含义的特征,却不能同时获取局部信息和全局信息,但这对肺结节检测却十分重要(周涛等,2021),原因有两点:1)肺结节在大小、形状和位置上有很大的变化。2)由于肺结节的不同类型,其周围的环境往往是多样化的,如孤立性结节、磨玻璃样阴影结节、空洞结节和胸膜结节。这些硬模拟物的存在将严重阻碍检测过程。并且现有主干网络通常通过牺牲高分辨率的特征映射来实现更深层次的体系结构,导致运行这些网络模型往往付出较高负担的内存和计算成本。尽管最新的网络结构在 CT 影像中准确地发现肺结节方面取得了良好的进展,但假阳性率仍然很高,这限制了模型在临床上的应用。

针对以上问题从肺结节大小、特征的多样性、算法复杂度、处理速度和临床应用上考虑,提出了一种 3 维一阶段融合 3D ReSidual U(3D RSU)块的嵌套 U 结构的肺结节检测模型。通过 3D RSU 块的嵌套 U 结构可以有效地提取阶段内多尺度特征以及聚合阶段间多尺度特征,能够较好地解决结节检测中 3~10 mm 小结节漏检等非显著性目标的检测问题,并有效提高每扫描 0.25~1 个假阳性上结节检测灵敏度,可以更有效地支撑临床诊断。

1 本文方法

本文提出的肺结节检测方法主要包括以下步骤:

1)图像预处理采用阈值化加形态学操作进行肺实质的分割,将结果作为神经网络的输入图像。

2)设计了 3D ReSidual U(3D RSU)块结构,扩展卷积运算的接受域,可以捕捉更多的上下文信息,融合不同尺度的感受野特征。

3)网络模型使用嵌套的网络结构,将 3D RSU 结构嵌入网络中,允许网络达到更高的图像分辨率,而不会显著增加内存和计算成本。

4)在解码阶段构建基于特征金字塔的多尺度联结预测。联结预测可以更有效地发挥区域建议网络 RPN 的优势,使多尺度特征图提供更加准确的肺结节位置信息和更为广泛的语义信息进而提高检测效果。

1.1 基于阈值方法的数据预处理

CT 影像进行预处理的步骤如下:

1) 进行原始CT影像的重采样, 解决原始CT影像数据来自不同的医疗设备, 并且每组CT影像数据的像素间距不同的问题。

2) 根据肺部的 Hounsfield unit (HU) 值约为 -500 这一点, 将体素值裁剪为 $[-1\ 200, 600]$, 然后归一化为 $[0, 255]$ 。

3) 将左右肺部即掩码进行膨胀操作, 去除肺部黑洞。

4) 原始CT数据是世界坐标, 将步骤1) 处理后获得的新分辨率的数据转换为体素坐标。

5) 提取肺实质, 采用阈值化加形态学操作进行肺实质的提取, 减少搜索空间。

1.2 嵌套U的网络结构

LUNA16 数据集中大约有 $1/5$ 的结节直径在 $3 \sim 5\text{ mm}$, 而结节本身可以存在于肺内或肺壁上, 且很难与阴影、血管和肋骨区分开来。这些都导致了结节检测灵敏度低且假阳性高等问题。当前主流深度神经网络方法和模型普遍以 U-Net 为网络结构, 并添加更复杂的模块和策略来提升骨干网络提取特征的能力, 使得神经网络结构愈发复杂。针对以上问题, 本文设计了一个两层嵌套的 U 型结构。结节检测网络结构如图 1 所示, 主要由数据预处理模块、4 级编码器、3 级解码器和肺结节检测模块 4 部分组成。编码器和解码器构成肺结节特征提取网络, 近年来嵌套 U 结构无论是在自然图像 (Qin 等, 2020) 上, 还是医学影像 (Zhou 等, 2018) 上均表现出了良好性能。因此本文使用一个两层嵌套的 U 型结构作为肺结节特征提取网络的网络结构。允许网络更深入地获得高分辨率, 而不会显著增加内存和计算成本。在内层设计了 3D RSU 结构, 它不仅能在不降低特征图分辨率的情况下提取级内多尺度特征, 还可以捕获肺结节的 3 维上下文信息; 在外层, 设计了改进的 U-Net 结构, 整个 U-Net 由 3D RSU 块填充。因此, 嵌套的 U 结构使得模块内多尺度特征的提取和模块间多层特征的聚合更有效。肺结节检测模块由 RPN 网络构成, 实现了一阶段端到端的检测, 即同时预测边界框位置以及是否为肺结节的概率, 相比于常用的二阶段算法, 过程更加简洁, 更符合临床上的应用需求。

编码器模块如图 1 所示, 在编码器 $C1, C2, C3$ 和 $C4$ 中, 分别设计了 3D RSU5, 3D RSU4, 3D RSU4F。其中, “5” 和 “4” 表示 3D RSU 块的高度。

参数的依据来源于肺结节图像的空间分辨率。对于 $C1$ 和 $C2$, 3D RSU 块的输入图的分辨率分别为 $48 \times 48 \times 48$ 和 $24 \times 24 \times 24$, 同时两个模块最底层特征图最低分辨率均为 $6 \times 6 \times 6$ 。5 层 3D RSU 块和 4 层 3D RSU 块的设计可以帮助网络捕获更多大规模信息。而对于 $C3$ 和 $C4$ 来说, 模块的输入图中特征图的分辨率是 $12 \times 12 \times 12$ 和 $6 \times 6 \times 6$ 相对较低, 由于肺结节具有形状小、语义特征少的特点, 对于这些特征图使用下采样操作有可能导致有用上下文的丢失。因此, 在 $C3$ 和 $C4$ 中, 使用扩张卷积用于代替合并和上采样运算, 并对低层特征进行重用, 为检测任务提供像素级特征, 这意味着在整个模块中的所有中间特征图都具有与其输入特征图相同的分辨率, 命名为 3D RSU4F。

解码器模块如图 1 所示, 解码器由 $D1, D2, D3$ 组成, 整体解码器阶段与编码器模块是对称的结构, 分别设计了 3D RSU5, 3D RSU4, 3D RSU4F, 其中 3D RSU4F 的使用情况与在编码阶段 $C3, C4$ 类似。不同的是每个解码器阶段将来自前一级的上采样特征映射和来自其对称编码器阶段的特征映射的级联作为输入。级联层通过高层次特征和低层次特征的结合, 可以获得更多的目标区域特征信息, 从而实现对目标区域的检测目的, 更好地修复目标细节, 最终得到一个语义层次高、位置信息丰富的特征图。由于在 LUNA16 数据集中, 结节的直径为 $3 \sim 30\text{ mm}$ 不等, 造成了大量的假阳性。因此, 设计从大体积 CT 扫描中检测小体积结节的方法, 并将结节与 CT 影像中表现相似的组织区分开来, 显得尤为重要。为更加充分利用解码器模块得到的特征图, 本文将 $C1, D1, D2$ 的特征图与 $D3$ 相联结构成特征金字塔, 将低层次的高分辨率特征添加到高层次的强语义特征中, 丰富了结节检测的位置细节和强语义, 实现了小结节的检测, 而多尺度特征预测则保证了大范围的结节检测, 全方面减少了假阳性的比例。

肺结节检测模块的输出层是 $1 \times 1 \times 1 \times 64$ 和 $1 \times 1 \times 1 \times 15$ 的卷积层, 结构如图 1 所示, 将解码模块获得的 $48 \times 48 \times 48 \times 60$ 的特征图通道转为 $48 \times 48 \times 48 \times 15$ 。之后将 4D 输出张量调整为 $48 \times 48 \times 48 \times 3 \times 5$, 其中 3 表示锚框的个数, 5 表示回归框的参数个数。根据 LUNA16 数据集中肺结节的直径分布, 网络设置了 $5\text{ mm}, 10\text{ mm}$ 和 20 mm 等 3 个不同比例的锚, 分别对应于 3 个边界框。模型的输出包




图1 肺结节检测网络结构

Fig. 1 Network structure of pulmonary nodule detection

括5个回归值,分别是结节预测概率(o)、结节的3维空间位置(dx, dy, dz)、结节的直径(dr),即为(o, dx, dy, dz, dr)。

1.3 3维残差U型模块

对于直径小于5 mm的微小结节,由于其与周围的噪声具有相似的灰度,导致在检测时容易发生结节漏检和产生大量假阳性结节,因此,较好地划分前景和背景信息、增强图像非显著性目标检测的能力是非常重要的。由于LUNA16数据集较为庞大,导致使用LUNA16数据集进行实验的骨干网络例如3D ResNet-18往往倾向于 1×1 或者 3×3 的卷积核来提取特征信息,因为这样所需要消耗的内存小而且效率高。但由于块内无法获得多尺度特征,导致浅层的输出特征图仅包含局部特征。而使用扩大的卷积来扩大接收场以提取局部和非局部特征,以原始分辨率在输入特征图上(尤其是在早期阶段)进行多次卷积需要太多的计算和内存资源。为了解决以上问题设计了3D ReSidualU(3D RSU)块以捕获阶段内多尺度特征。

3D RSU-L(C_i, M, C_o)中的 C_i, M 和 C_o 分别代表

输入层,中间层和输出层的通道数, L 是编码器中的层数。模块的算法流程可以分为3个部分:

1)将特征图($L \times H \times W \times C_i$)通过卷积核大小为 $3 \times 3 \times 3$ 的输入卷积层,得到通道为 C_o 的中间图 $f_1(x)$ 。作用是提取当前特征图的局部特征。

2)高度为 L 的类似U-Net的对称编解码器结构,将中间特征映射 $f_1(x)$ 作为输入,并学习提取和编码多尺度上下文信息 $U(f_1(x))$ 。3D RSU5的结构如图2(b)所示,其中5表示3D RSU块的层数。在网络中使用池化操作作为特征降维的手段,多个池化操作可以缓解LUNA16数据集正负样本比例失衡造成的过拟合问题。值得说明的是,对于本网络使用的3D RSU5和3D RSU4,模块最底层特征图的分辨率均为 $6 \times 6 \times 6$,与整个网络最底层特征图分辨率保持一致。这样的设置,解决了检测区域定位不清、偏差大的问题,提高了对于直径较小的肺结节的检测精度。针对传统3D U-Net从低层次的角度分析目标信息的多尺度性,不能充分利用低层次的网络信息,同时,很少考虑特征的连续性,忽略了图像本身与目标的关系,造成大量结节漏检的情况。

模块通过上采样、级联和卷积将多尺度特征编码成高分辨率的特征图。减少特征丢失, 以此提高肺结节的检出准确性。

3) 通过残差连接将其与之前的特征图相加, 从而融合局部与多尺度信息。

为了说明3D RSU块的设计理念, 在图2中将3D RSU块与3D ResNet-18块(Zhu等, 2018)的性能进行了比较。3D ResNet-18模块中的运算表达式为

$$H(\mathbf{x}) = f_2(f_1(\mathbf{x})) + \mathbf{x} \quad (1)$$


式中, $H(\mathbf{x})$ 表示输入特征 $\mathbf{x}$ 的期望映射; f_2 、 f_1 表示权重层, 是指在网络中的卷积操作。3D RSU和3D ResNet-18之间的设计差异在于, 3D RSU块中使用MaxPooling作为下采样的手段, 而多个下采样操作使得3D RSU块具有更大的接受场范围和更丰富的局部细节以及全局信息。在肺内任何地方都有结节, 它们附近的像素高度相关, 一些正常组织在CT影像中具有与结节相似的形态学表现。因此丰富的局部和全局特征不仅可以降低假阳性, 还能提高网络对于这些难检结节的检测效果。其次3D RSU用类似U-Net的结构替换了普通的单流卷积, 原始3D ResNet-18的输出是输入的原始特征加上局部特征, 而3D RSU模块是权重层变换的局部特征替换了原始特征, 3D RSU模块的运算表达式为

$$HR(\mathbf{x}) = U(f_1(\mathbf{x})) + f_1(\mathbf{x}) \quad (2)$$


式中, U 表示图2(b)中所示的多层U结构, 通过编码解码的结构以及级联的操作, 大大减轻了由大尺度直接上采样造成的精细细节的损失。最大限度地利用肺结节的语义特征, 获取肺结节的低层特征, 使网络能够直接从每个残差块提取多个比例的特征。因此3D RSU块相比于3D ResNet-18块可以得到语义更加丰富、位置信息更加清晰的特征图, 进而网络可以检索到更多的结节。更值得注意的是, 由于大多数操作应用于下采样的特征图, 3D RSU结构并没有明显增加计算开销, 这一点将在后续的实验中加以证明。

1.4 损失函数

本文的损失函数由分类损失 L_{ce} 和回归损失 L_{sl} 两部分组成。为了计算损失, 本文设定交并比(intersection over union, IoU)作为计算候选区域是否有结节的标准, 当候选区域与标签所设定区域的IoU值大于0.5时, 将此区域判定为正样本, 当候选区域与标签所设定区域的IoU值小于0.2时, 将此区域判定为负样本。候选区域的分类误差的损失函数采



(a) 3D ResNet-18



(b) 3D RSU5

图2 网络模块

Fig. 2 Network module((a) 3D ResNet-18; (b) 3D RSU5)

用交叉熵(cross entropy)损失函数。

交叉熵的定义为

$$L_{ce} = l(\mathbf{x}, \mathbf{y}) \in \{l_1, l_2, \dots, l_n\} \quad (3)$$

$$l_n = -w_n [y_n \log \hat{y}_n + ((1 - y_n) \log (1 - \hat{y}_n))] \quad (4)$$

式中, n 是批次大小, w_n 是权重, y_n 是锚定框的正标签, $\hat{y}_n$ 是预测的概率。

回归损失 smooth L1-norm 的定义为

$$S(d, \hat{d}) = \begin{cases} |d - \hat{d}| & |d_k - \hat{d}| > 1 \\ (d - \hat{d})^2 & \text{其他} \end{cases} \quad (5)$$

$$L_{sl} = \sum_{k \in (x, y, z, r)}^n S(d_k, \hat{d}) \quad (6)$$

式中, d_k 为候选区域在结节样本标注值, $\hat{d}$ 为对应位置的回归输出值。总损失为分类损失和回归损失之和, 定义如下

$$L = L_{ce} + L_{sl} \quad (7)$$

2 实验与结果分析

2.1 数据集

功能齐全的计算机断层 CT 扫描库可以用于肺结节检测, 分类和定量评估计算机辅助诊断 CAD 方法的开发。本文实验数据集使用从公开的肺图像数据库联盟 (LIDC) 数据集中筛选出 888 幅 CT 影像组成 LUNA16 数据集 (Setio 等, 2017)。

LUNA16 数据集包括 888 名患者的 1 186 个结节标签。丢弃掉切片厚度大于 2.5 mm 的扫描, 以 Hounsfield 单位 (HU) 为单位的 12 bit 灰度分辨率。由 4 位经验丰富的胸科放射科医生采用两阶段手工标记法收集肺结节的注释。

2.2 实验设置

本实验将 Ubuntu18.04 作为操作系统, 使用 3 GHz 的 Intel (R) Xeon (R) Gold 6154 CPU, 内存为 256 GB, 使用 Python3.6 搭建深度学习神经网络, 通过 Pytorch 在显存为 32 GB 的 Tesla V100-SXM2 显卡上展开实验。网络训练采用了随机梯度下降优化器, 初始学习率为 0.01, 在达到总迭代次数的 1/3 和 2/3 后, 学习率分别调整为 0.001、0.000 1, 权重衰减为 1×10^{-4} , batchsize 大小为 8, 模型迭代次数为 120, 训练一轮需要约 620 s, 训练一个模型需要约 20 h。

模型的训练和测试采用 10 折交叉验证 (10-fold cross validation) 的方法, 将数据集分成 10 份, 轮流将其中 9 份做训练剩余 1 份做验证, 每次试验都会得出相应的正确率。10 次结果的均值作为最终的算法精度。此外, 针对 LUNA16 数据集中数据不平衡的问题, 本文采用多种数据增强手段, 例如左右翻

转变、旋转变换、图像尺度的变换和难例挖掘机制等方法对数据集进行了增强。提高了模型的泛化能力和鲁棒性。

在测试部分, 首先因原始图像的尺寸 ($512 \times 512 \times 141$) 过大, 使用滑动窗口的方式在预处理好的 CT 影像的肺实质区域截取 $208 \times 208 \times 208$ 的图像块进行测试。因为标签锚框具有不同的大小 [5, 10, 20], 为尽可能保证测试图像的完整性, 在截取图像之间设置 32 个像素的重叠, 来消除卷积计算时的不期望的边界影响, 再将所有图块组合成完整的 CT 概率图, 概率图中每个体素的值代表该点是肺结节的概率。对于每例图像, 将所有 patch 的预测结果合并, 通过非极大值抑制方法将重叠度高的预测边界框移除, 输出每个结节最优的预测边界框。

本文基准算法为 3D Faster R-CNN (Zhu 等, 2018), 3D Faster R-CNN 为只采用 3D ResNet-18 模块、U-Net 结构的结节检测网络。本文在此基础上进行了改进, 初次改进为在 3D Faster R-CNN 算法基础上将 3D ResNet-18 模块更换为效果更好的 3D RSU 模块, 其次为了更好地发挥 3D RSU 模块的优势将网络架构更改为嵌套结构并在解码阶段增加特征金字塔结构, 在减轻网络负担的同时在各个不同尺寸的特征图上进行联结预测, 记为 3D RSU_FPN_RPN, 也就是本文提出的融合 3D RSU 模块的嵌套 U 结构的结节检测算法。

2.3 评价标准

本文采用无限制受试者操作特征 (free-response receiver operating characteristic, FROC) 来衡量算法的性能。对于肺结节检测任务, 通过在预测概率上设置不同的阈值, 计算了每扫描 [1/8, 8] 假阳性范围内的 FROC 曲线。FROC 曲线的横轴表示每次扫描中的平均假阳性个数 (false positives per scan), 记为 FPs/scan。纵轴代表正确肺结节与所有肺结节的比率, 即召回率。FROC 曲线得分越高, 系统性能越好。此外, 灵敏度在临床医学中广泛应用于衡量肺结节检测算法性能的研究 (张福玲和张少敏, 2020)。灵敏度计算为

$$S = \frac{TP}{TP + FN} \quad (8)$$

式中, TP 为其阳性, 是检测有结节且实际有结节; FN 为假阴性, 是检测无结节, 但实际上有结节。

模型的总体性能由竞争性能指标 (CPM) 进行

评估,该指标测量 FROC 曲线 7 个工作点的平均灵敏度:1/8、1/4、1/2、1、2、4 和 8 个假阳性。CPM 值一般作为评价肺结节检测网络的一个指标,CPM 值越高,肺结节检测性能越好。

目前临床使用的大多数 CAD 系统的内部阈值设置在平均每次扫描 1 个假阳性和 4 个假阳性(大多数系统不允许用户改变阈值)。在低假阳性下即在平均每次扫描 0.125、0.25、0.5、1 个假阳性这 4 种条件下,较低的假阳性率对深度学习模型提出更高的挑战,这就决定了一个系统是否可以在很少错误的情况下识别更多正确的结节,也会为医生提供更加直接的帮助,是提高现有计算机辅助诊断系统的自动化水平的关键。

2.4 实验验证

为了验证本文提出的 3D RSU_FPN_RPN 的有效性,在块相融实验里将 3D RSU_FPN_RPN 中除了编解码体系结构外的 3D RSU 模块用 3D ResNet-18 模块代替,记为 Res18_FPN_RPN。将 3D RSU_FPN_RPN 与 Res18_FPN_RPN 从肺结节检测效果以及肺结节检测时间两方面进行对比分析。

2.4.1 模型性能对比

表 1、表 2 和表 3 是 3D RSU_FPN_RPN 与

Res18_FPN_RPN 在肺结节检测性能上的比较,验证了本文提出的 3D RSU 块在即使极低的假阳性率下也能保持令人满意的灵敏度。

表 1、表 2 和表 3 中的结果是两个模型在平均假阳性在 0.125、0.25、0.5、1、2、4、8 时的检测灵敏度以及在这 7 个点的灵敏度的平均值,即 CPM。由于时间关系,本文只在 fold0、fold1 和 fold2 上将不同设计方法进行了实验验证。尽管 Zhu 等人(2018)方法获得了不错的敏感性分数,但模型将承受大约 8 个假阳性,这妨碍了它们在常规临床实践中的应用。而一些极低的假阳性率,对于系统是否能够识别出假阳性极少的可接受模块具有重要意义,在这种情况下,本文提出的 3D RSU 模块相比于 3D ResNet-18 模块,在 3 个数据集的平均假阳性为 0.125、0.25、0.5、1 上的灵敏度分别平均提高了 1.5%、2.7%、2%、0.6%。在保持令人满意的灵敏度的同时,在减少误报方面表现出很强的能力。值得注意的是,尽管在 fold 1 中 3D RSU 块在 CPM 值上略低于 3D ResNet-18 块,但在平均假阳性为 0.125 和 0.25 上的灵敏度仍高于 3D ResNet-18 块,证明了 3D RSU 模块在低假阳性下的性能是高于 3D ResNet-18 的。

表 1 本文方法与 RES 模块在 fold0 中的性能比较

Table 1 This method is compared with RES module in fold0

模块	0.125	0.25	0.5	1	2	4	8	CPM
3D ResNet-18	0.701	0.796	0.853	0.907	0.928	0.946	0.964	0.876
3D RSU	0.760	0.833	0.872	0.923	0.938	0.947	0.955	0.887

表 2 本文方法与 RES 模块在 fold1 中的性能比较

Table 2 This method is compared with RES module in fold1

模块	0.125	0.25	0.5	1	2	4	8	CPM
3D ResNet-18	0.757	0.823	0.869	0.906	0.908	0.928	0.938	0.877
3D RSU	0.764	0.830	0.863	0.890	0.905	0.919	0.921	0.863

表 3 本文方法与 RES 模块在 fold2 中的性能比较

Table 3 This method is compared with RES module in fold2

模块	0.125	0.25	0.5	1	2	4	8	CPM
3D ResNet-18	0.568	0.700	0.782	0.835	0.862	0.887	0.887	0.797
3D RSU	0.546	0.738	0.829	0.853	0.884	0.884	0.884	0.809

2.4.2 嵌套 U 结构实验验证

为了验证本文采用的嵌套体系结构性能,在

表 4 给出了采用堆叠结构的 Res18_FPN_RPN 网络和本文算法在参数量和消耗时间上的对比。图 3 给

出了两个模型的训练 loss 曲线。

表 4 中的时间是模型测试一幅图像所需要的时间。由表 4 中的结果可知,本文算法的参数量略高于 Res18_FPN_RPN 网络,而测试时间上的差距几乎可以忽略不计。因为网络在 LUNA16 数据集的 10 个子数据集上的收敛趋势基本相同,图 3 只给出了两个网络在 fold2 上的损失曲线作为代表。从图 3 中可知本文算法与 Res18_FPN_RPN 算法在模型收敛速度上几乎相同。因此本文算法在不显著增加计算代价的情况下,有效提高了检测精度,具有较高的检测效率和能力。

表 4 模型参数数量和单幅图像测试时间比较
Table 4 Comparison of model parameters and training time of single picture

方法	参数量	时间/s
3D ResNet-18	6 307 243	13.74
3D RSU	6 484 043	15.68




图 3 本文算法与 3D Res18 的收敛曲线

Fig. 3 The algorithm is similar to Res18_FPN_RPN convergence curve

2.5 与基准实验比较 10 折交叉验证结果

图 4 将本文提出的结节检测算法与 Zhu 等人 (2018) 提出的 Res18_Faster_R-CNN 模型进行了性能比较。

由图 4(a) 可以看出,在 10 折交叉验证的总体结果下,3D RSU 算法的在每一折上的灵敏度都高于所比较的基准实验数据。值得注意的是在 fold6、fold7 和 fold8 共 3 个数据集子集上,灵敏度达到了 100%。3D Faster R-CNN 算法的灵敏度平均值为 95.54%,3D RSU 算法的灵敏度平均值为 97.2%,相比于 3D Faster R-CNN 提高了 1.66%。

图 4(b) 为 3D RSU 与基准算法 3D Faster R-CNN 在 10 折交叉验证下竞争性能指标 (CPM) 上的比较,可以看出本文算法 3D RSU 算法在每一折上的 CPM 得分都高于基准算法,尤其是在 fold6 和 fold7 上的 CPM 得分达到了 0.90。3D Faster R-CNN 算法的 CPM 平均值为 0.833。3D RSU 算法的 CPM 平均值为 0.864,相比较 3D Faster R-CNN 提高了 3.1%。证明了相比于 3D ResNet-18 模块,3D RSU 模块可以在不同的假阳性下具有更高的灵敏度。





图 4 本文算法与基准算法在评价指标上的比较

Fig. 4 Comparison of the evaluation index between the proposed algorithm and benchmark algorithm((a) sensitivity;(b) CPM)

2.6 对不同大小结节的检测效果

本文算法主要针对一阶段算法假阳性高的问题,解决问题的关键在于提高小结节 (3 ~ 10 mm) 的检测效果,表 5 比较了本文算法与基准算法对于不同大小结节的检测效果。在 LUNA16 数据集中,总计 1 186 个结节,其中 3 ~ 5 mm 结节有 272 个,5 ~ 10 mm 结节有 633 个,10 mm 及以上结节有 281 个。3D Faster R-CNN (Zhu 等, 2018) 方法在 3 ~ 5 mm 检测到了 251 个,3D RSU 方法检测到了 263 个,相比较于 3D Faster R-CNN 增加了 12 个结节,本文方法在 3 个尺寸上的肺结节检出率相比于 3D

表5 肺结节检测系统对不同大小结节的检测效果

Table 5 Detection effect of pulmonary nodule detection system on nodules of different sizes

方法	直径(3~5 mm)		直径(5~10 mm)		直径(大于10 mm)		检测到的 总结节数	灵敏度/%
	数量	检出率/%	数量	检出率/%	数量	检出率/%		
3D Faster R-CNN(Zhu 等,2018)	251	92.2	604	95.4	267	95.0	1 122	94.6
本文	263	96.6	616	97.3	275	97.8	1 154	97.2

Faster R-CNN 分别提高了4.4%、1.9%和2.8%,在LUNA16数据集中,对小结节的检测准确率在90%以上,表明本文算法可以有效提高小结节的检测效果。表5中的灵敏度指标是算法在10折交叉验证后所得到的最高灵敏度值。表5的结果表明,相比传统的3D ResNet-18,本文所提出的3D RSU模块通过类U-Net结构可以提取更加丰富的全局和局部特征,从而更加全面地检测到直径较小的结节,在灵敏度上提高了2.6%。

2.7 实验结果比较

为了进一步评估该方案的性能,将本文算

法与现有的基于LUNA16数据集的方法在不同假阳性率下不同大小肺结节下检测准确率进行比较。

2.7.1 与其他方法比较

表6总结了所比较的不同方法的性能。结果表明,本文方法得到了最高的CPM值。假阳性率达到4后,检测率趋于稳定。尤其是本文采用一阶段肺结节检测算法的情况下每次扫描假阳性个数为0.125~1个假阳性上的灵敏度高于其他的肺结节检测算法。说明模型可以在较低假阳性实现高灵敏度,为医生提供更有效的帮助。

表6 肺结节检测性能比较

Table 6 Comparison of detection performance of pulmonary nodules

方法	0.125	0.25	0.5	1	2	4	8	CPM
Dou 等人(2017b)	0.677	0.737	0.815	0.848	0.879	0.907	0.922	0.827
Setio 等人(2016)	0.636	0.727	0.792	0.844	0.876	0.905	0.916	0.814
Dou 等人(2017a)	0.659	0.745	0.819	0.865	0.906	0.933	0.946	0.839
Polat 等人(2018)	0.588	0.669	0.749	0.831	0.863	0.892	0.913	0.786
Zhu 等人(2018)	0.692	0.769	0.824	0.865	0.893	0.917	0.933	0.845
Zuo 等人(2019)	0.672	0.694	0.714	0.739	0.766	0.787	0.822	0.742
Xie 等人(2019)	0.493	0.688	0.796	0.852	0.864	0.864	0.864	0.775
高慧明 等人(2019)	0.673	0.739	0.817	0.849	0.880	0.909	0.921	0.827
戚永军 等人(2020)	0.692	0.782	0.832	0.867	0.889	0.918	0.925	0.844
Sun 等人(2021)	0.467	0.602	0.730	0.812	0.877	0.920	0.931	0.762
洪敏杰 等人(2021)	—	—	—	—	—	—	—	0.816
本文	0.712	0.809	0.854	0.889	0.915	0.930	0.942	0.864

注:加粗字体为每列最优值,“—”表示相关论文无此数据。

2.7.2 与组合方法比较

随着对网络结构理解的不断深入,越来越多的网络模型从特征融合的角度提升肺结节检测效果,表7比较了本文算法与DeepSEED(Li和Fan,2020)和Bottle2Seneck(Sun等,2021)在不同假阳性率下的检测准确率。DeepSEED是将SE-net(squeeze-

and-excitation networks)插入到3D ResNet-18模块上,并针对样本不平衡问题使用Focal loss作为分类损失函数。Bottle2Seneck(Sun等,2021)在肺结节检测模块,与DeepSEED同样在网络中组合了SE-net模块,并且在区域建议网络中,引入上下文增强模块(context enhancement module,CEM)和空间注意力

表 7 与当前性能较好的组合方法比较

Table 7 Compared with the current combination methods with better performance

方法	0.125	0.25	0.5	1	2	4	8	CPM
Li 和 Fan(2020)	0.739	0.803	0.858	0.888	0.907	0.916	0.920	0.862
Sun 等人(2021)	-	-	-	-	-	-	-	0.872
本文	0.712	0.809	0.854	0.889	0.915	0.930	0.942	0.864

注:“-”表示相关论文无此数据。

模块(spatial attention module,SAM)。上述两种方法均是组合方法,都是从加强特征通道之间的相互依赖关系以及对特征信息进行补充的角度去提高检测效果。本文算法提出的3D RSU 模块的优势在于,仅仅依靠高效简洁的网络结构,便获得了语义层次高、位置信息丰富的特征图,从而获得了较好的结果,并不是组合方法。本文模型并没有使用任何的注意力机制便获得了近似甚至更高的 CPM 值,足以证明本算法的潜力和价值。

2.8 肺结节检测结果可视化

为了进一步证明该模型的有效性,将检测结果可视化。首先读取原始 CT 影像的信息,其中包含了 CT 影像的全部信息。根据原始图像的标记信息,对肺结节在 CT 影像切片中的位置进行标记,即所谓的金标准。其次,根据模型生成的预测结果圈出各个结节的位置。

可视化结果如图 5 所示,肺结节的大小、形态有明显差异。前 3 行是根据结节的密度,分为固体、磨




图 5 肺结节检测结果

Fig. 5 Pulmonary nodule detection results((a) gold standard;(b) 3D Faster R-CNN;(c) ours)

玻璃和部分固体结节。后两行根据肺结节的位置分为近血管结节和近肺壁结节。在图5中,第1列是金标准图中不同表征的肺结节。第2列是3D Faster R-CNN 预测的各肺结节位置。第3列是本文方法中对于不同表征的肺结节的检测结果。在这3列的可视化结果中,尽管3D Faster R-CNN 模型和本文模型都能检测出肺结节。但在检测近肺壁结节中,3D Faster R-CNN 模型的假阳性率高于本文方法。由此可见,本文模型减少了肺结节检测中假阳性的数量。在检测磨玻璃的肺结节中,由于不能与周围组织区分,磨玻璃结节很难检出。3D Faster R-CNN 算法的结节检测精度只有0.90。而本文方法检测精度为0.99,证明本文方法对于较难检验出的肺结节仍有较好的检测结果,且具有较高的置信度。

3 结 论

由于肺部结节在直径大小、形状和密度的变化十分复杂,导致现有的深度学习模型难以在低假阳性率下保证高的灵敏度,这限制了深度学习算法在常规临床实践中的肺结节自动诊断。针对此问题,本文提出了基于3D RSU 块的嵌套U结构的深度网络肺结节检测算法。在LUNA16数据集上进行10折交叉验证的结果表明,本文所提出的深度网络在灵敏度、CPM、平均假阳性等多项评价指标上均优于对比的结节检测算法及主流检测框架,尤其是在极低的假阳性率(每次扫描1,0.5,0.25,0.125个假阳性),保持令人满意的灵敏度的同时,在减少误报方面表现出很强的能力,提高了现有计算机辅助诊断系统的自动化水平,为放射科医生在临床实践中提供了更加有效的帮助。

本文算法仍有改进的空间,因为受限于资源和时间,本文仅使用LUNA16数据集作为本实验的数据源,所有的肺部CT影像均在相同的扫描参数下获得,且均是低剂量CT影像。但是,在实际的临床应用中,各个医院可能会使用不同层数的螺旋扫描仪,采集参数并不相同,导致需要不同的核函数和分辨率重建图像,使得最终获得的CT影像不尽相同。为了使网络更符合临床上的需求,在之后的研究中,会采用更加多样化的数据集,增强深度学习网络的泛化能力,获得更准确、有效的模型。

当前有关医学影像的人工智能领域,在医院的

电子病历、影像归档和通信系统(picture archiving and communication systems, PACS)中存在大量未标记的医学影像,因此缺乏大型注释数据集是医学影像研究中的一个共同挑战。在最近的研究中,小样本学习方法在医学图像领域展现出了较大的潜力。在后续工作中将探究如何利用小样本学习去减轻网络对于大量数据集的依赖,设计假阳性低、鲁棒性强以及准确率更高等性能的网络。在临床应用方面,提出了放射组学研究用于各种临床应用,它提取大量定量的图像特征,然后进行数据挖掘,预测肿瘤反应,从而更可靠、准确地预测局部控制和总体生存期。例如利用保角球参数化的面积失真度量来量化结节上的刺状,手工制作结节轮廓,实现了高精度的肿瘤半自动分割。在之后的工作中也会探究放射组学在肺结节检测中的作用以提高检测精度。

参考文献 (References)

- Armato III S G, McLennan G, Bidaut L, McNitt-Gray M F, Meyer C R, Reeves A P, Zhao B S, Aberle D R, Henschke C I, Hoffman E A, Kazerooni E A, MacMahon H, Van Beek E J R, Yankelevitz D, Biancardi A M, Bland P H, Brown M S, Engelmann R M, Laderach G E, Max D, Pais R C, Qing D P Y, Roberts R Y, Smith A R, Starkey A, Batra P, Caligiuri P, Farooqi A, Gladish G W, Jude C M, Munden R F, Petkovska I, Quint L E, Schwartz L H, Sundaram B, Dodd L E, Fenimore C, Gur D, Petrick N, Freymann J, Kirby J, Hughes B, Castele A V, Gupte S, Sallam M, Heath M D, Kuhn M H, Dharaiya E, Burns R, Fryd D S, Salganicoff M, Anand V, Shreter U, Vastagh S, Croft B Y and Clarke L P. 2011. The lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans. *Medical Physics*, 2011, 38(2): 915-931 [DOI: 10.1118/1.3528204]
- Bray F, Ferlay J, Soerjomataram I, Siegel R L, Torre L A and Jemal A. 2018. Global cancer statistics 2018: globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries. CA, USA: A Cancer Journal for Clinicians, 68(6): 394-424 [DOI: 10.3322/caac.21492]
- Cao H C, Liu H, Song E M, Ma G Z, Xu X Y, Jin R C, Liu T Y and Hung C C. 2020. A two-stage convolutional neural networks for lung nodule detection. *IEEE Journal of Biomedical and Health Informatics*, 24(7): 2006-215 [DOI: 10.1109/JBHI.2019.2963720]
- Chen D Z and Jiang Q. 2021. Pulmonary nodule detection based on convolutional neural networks with transfer learning. *Computer Engineering and Design*, 42(1): 240-247 (陈道争, 江倩. 2021. 基于卷积神经网络和迁移学习的肺结节检测. 计算机工程与设计)


- 计, 42(1): 240-247 [DOI: 10.16208/j.issn1000-7024.2021.01.035]
- Dou Q, Chen H, Jin Y M, Lin H J, Qin J and Heng P A. 2017a. Automated pulmonary nodule detection via 3D ConvNets with online sample filtering and hybrid-loss residual learning//Proceedings of the 20th International Conference on Medical Image Computing and Computer-Assisted Intervention. Quebec City, Canada: Springer; 630-638 [DOI: 10.1007/978-3-319-66179-7_72]
- Dou Q, Chen H, Yu L Q, Qin J and Heng P A. 2017b. Multilevel contextual 3-D CNNs for false positive reduction in pulmonary nodule detection. *IEEE Transactions on Biomedical Engineering*, 64(7): 1558-1567 [DOI: 10.1109/TBME.2016.2613502]
- Firmino M, Angelo G, Morais H, Dantas M R and Valentim R. 2016. Computer-aided detection (CADE) and diagnosis (CADx) system for lung cancer with likelihood of malignancy. *BioMedical Engineering OnLine*, 15(1): #2 [DOI: 10.1186/s12938-015-0120-7]
- Gao H M, Zhao J J, Liu J H, Tang X X and Wang P. 2019. Multi-scale convolutional neural network for pulmonary nodule false positive reduction. *Computer Engineering and Design*, 40(9): 2718-2724 (高慧明, 赵涓涓, 刘继华, 唐笑先, 王磐. 2019. 多尺度卷积神经网络用于肺结节假阳性降低. *计算机工程与设计*, 40(9): 2718-2724) [DOI: 10.16208/j.issn1000-7024.2019.09.054]
- 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]
- Hong M J, Wu G, Liu X C, Jia J C and Yang X H. 2021. Detection algorithm of lung nodule based on attention mechanism. *Computer Engineering and Design*, 42(1): 83-88 (洪敏杰, 吴刚, 刘星辰, 贾俊铨, 杨歆豪. 2021. 基于注意力机制的肺结节检测算法. *计算机工程与设计*, 42(1): 83-88) [DOI: 10.16208/j.issn1000-7024.2021.01.013]
- 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 (CVPR). Honolulu, USA: IEEE; 2261-2269 [DOI: 10.1109/CVPR.2017.243]
- Huang K Q, Ren W Q and Tan T N. 2014. A review on image object classification and detection. *Chinese Journal of Computers*, 37(6): 1225-1240 (黄凯奇, 任伟强, 谭铁牛. 2014. 图像物体分类与检测算法综述. *计算机学报*, 37(6): 1225-1240) [DOI: 10.3724/SP.J.1016.2014.01225]
- Krizhevsky A, Sutskever I and Hinton G E. 2012. ImageNet classification with deep convolutional neural networks//Advances in Neural Information Processing Systems. Lake Tahoe, USA: NIPS; 1106-1114
- Li Y M and Fan Y. 2020. DeepSEED: 3D squeeze-and-excitation encoder-decoder convolutional neural networks for pulmonary nodule detection//Proceedings of the 17th IEEE International Symposium on Biomedical Imaging (ISBI). Iowa City, USA: IEEE; 1866-1869 [DOI: 10.1109/ISBI45749.2020.9098317]
- Lin D T, Yan C R and Chen W T. 2005. Autonomous detection of pulmonary nodules on CT images with a neural network-based fuzzy system. *Computerized Medical Imaging and Graphics*, 29(6): 447-458 [DOI: 10.1016/j.compmedimag.2005.04.001]
- Polat G, Dogrusoz Y S and Halici U. 2018. Effect of input size on the classification of lung nodules using convolutional neural networks//Proceedings of the 26th Signal Processing and Communications Applications Conference (SIU). Izmir, Turkey: SIU; 1-4
- Qi Y J, Gu J H, Zhang Y J, Wang F and Tian Z P. 2020. Deep mixed convolution model for pulmonary nodule detection. *Journal of Computer Applications*, 40(10): 2904-2909 (戚永军, 顾军华, 张亚娟, 王锋, 田泽培. 2020. 基于深度混合卷积模型的肺结节检测方法. *计算机应用*, 40(10): 2904-2909) [DOI: 10.11772/j.issn.1001-9081.2020020192]
- Qin X B, Zhang Z C, Huang C Y, Dehghan M, Zaiane O R and Jagersand M. 2020. U²-Net: going deeper with nested U-structure for salient object detection. *Pattern Recognition*, 106: #107404 [DOI: 10.1016/j.patcog.2020.107404]
- Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, Huang Z H, Karpathy A, Khosla A, Bernstein M, Berg A C and Li F F. 2015. ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 115(3): 211-252 [DOI: 10.1007/s11263-015-0816-y]
- Setio A A A, Ciompi F, Litjens G, Gerke P, Jacobs C, Van Riel S J, Wille M M W, Naqibullah M, Sánchez C I and Van Ginneken B. 2016. Pulmonary nodule detection in CT images: false positive reduction using multi-view convolutional networks. *IEEE Transactions on Medical Imaging*, 35(5): 1160-1169 [DOI: 10.1109/TMI.2016.2536809]
- Setio A A A, Traverso A, De Bel T, Berens M S N, Van Den Bogaard C, Cerello P, Chen H, Dou Q, Fantacci M E, Geurts B, Van Der Gugten R, Heng P A, Jansen B, De Kaste M M J, Kotov V, Lin J Y H, Manders J T M C, Sñora-Mengana A, García-Naranjo J C, Papavasileiou E, Prokop M, Saletta M, Schaefer-Prokop C M, Scholten E T, Scholten L, Snoeren M M, Torres E L, Vandemeulebroucke J, Walasek N, Zuidhof G C A, Van Ginneken B and Jacobs C. 2017. Validation, comparison, and combination of algorithms for automatic detection of pulmonary nodules in computed tomography images: the LUNA16 Challenge. *Medical Image Analysis*, 42: 1-13 [DOI: 10.1016/j.media.2017.06.015]
- Shi L K, Ma H Q and Zhang J. 2021. Automatic detection of pulmonary nodules in CT images based on 3D Res-I network. *The Visual Computer*, 37(6): 1343-1356 [DOI: 10.1007/s00371-020-01869-7]
- Simonyan K and Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition//Proceedings of the 3rd International Conference on Learning Representations. San Diego, USA: ICLR

- Sori W J, Feng J, Godana A W, Liu S H and Gelmecha D J. 2021. DFD-Net: lung cancer detection from denoised CT scan image using deep learning. *Frontiers of Computer Science*, 15 (2): #152701 [DOI: 10.1007/s11704-020-9050-z]
- Sun L M, Wang Z R, Pu H, Yuan G H, Guo L, Pu T and Peng Z M. 2021. Attention-embedded complementary-stream CNN for false positive reduction in pulmonary nodule detection. *Computers in Biology and Medicine*, 133: #104357 [DOI: 10.1016/j.combiomed.2021.104357]
- Wang H H. 2018. Deep Learning Based Pulmonary Nodule Detection Algorithms for Medical Images. Xi'an: Xidian University (王厚华. 2018. 基于深度学习的医学图像肺结节检测算法研究. 西安: 西安电子科技大学)
- Xie H T, Yang D B, Sun N N, Chen Z N and Zhang Y D. 2019. Automated pulmonary nodule detection in CT images using deep convolutional neural networks. *Pattern Recognition*, 85: 109-119 [DOI: 10.1016/j.patcog.2018.07.031]
- Xie S N, Girshick R, Dollár P, Tu Z W and He K M. 2017. Aggregated residual transformations for deep neural networks//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, USA: IEEE: 5987-5995 [DOI: 10.1109/CVPR.2017.634]
- Zhang F L and Zhang S M. 2020. Review of deep learning methods applied to lung nodule detection in CT images. *Computer Engineering and Applications*, 56(13): 20-32 (张福玲, 张少敏. 2020. 应用于CT图像肺结节检测的深度学习方法综述. 计算机工程与应用, 56(13): 20-32) [DOI: 10.3778/j.issn.1002-8331.2002-0051]
- Zhang G, Lin L and Wang J X. 2021. Lung nodule classification in CT images using 3D DenseNet. *Journal of Physics: Conference Series*, 1827: #012155 [DOI: 10.1088/1742-6596/1827/1/012155]
- Zhou Z W, Siddiquee M R, Tajbakhsh N and Liang J M. 2018. UNet++: a nested U-Net architecture for medical image segmentation//4th Deep Learning in Medical Image Analysis. Granada: MICCAI: 3-11
- Zhou T, Dong Y L, Huo B Q, Liu S and Ma Z J. 2021. Overview of the application of u-net network in medical image segmentation. *Journal of Image and Graphics*, 26 (9): 2058-2077 (周涛, 董雅丽, 霍兵强, 刘珊, 马宗军. 2021. U-Net 网络医学图像分割应用综述. 中国图象图形学报, 26(9): 2058-2077)
- Zhou T, Liu S, Dong Y L, Huo B Q and Ma Z J. 2021. Multiscale transform pixel level medical image fusion: research progress, applications and challenges. *Journal of Image and Graphics*, 26 (9): 2094-2110 (周涛, 刘珊, 董雅丽, 霍兵强, 马宗军. 2021. 多尺度变换像素级医学图像融合: 研究进展、应用和挑战. 中国图象图形学报, 26(9): 2094-2110)
- Zhu W T, Liu C C, Fan W and Xie X H. 2018. DeepLung: deep 3D dual path nets for automated pulmonary nodule detection and classification//Proceedings of 2018 IEEE Winter Conference on Applications of Computer Vision (WACV). Lake Tahoe, USA: IEEE: 673-681 [DOI: 10.1109/WACV.2018.00079]
- Zuo W X, Zhou F Q, Li Z X and Wang L. 2019. Multi-resolution CNN and knowledge transfer for candidate classification in lung nodule detection. *IEEE Access*, 7: 32510-32521 [DOI: 10.1109/ACCESS.2019.2903587]

作者简介



许正玺, 1996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: 2804410046@qq.com



张少敏, 通信作者, 女, 副教授, 硕士生导师, 主要研究方向为计算机视觉、医学图像分析处理。
E-mail: zhangshaomin_nun@sina.com

支力佳, 男, 讲师, 硕士生导师, 主要研究方向为计算机视觉、医学图像分析处理。E-mail: zhlj@nun.edu.cn

周涛, 男, 教授, 硕士生导师, 主要研究方向为医学图像分析处理、深度学习、大数据、云计算。

E-mail: zhoutaonxmu@126.com