



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 Xianxue, 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, Hei 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: TP391.4 文献标识码: A 文章编号: 1006-8961(2021)09-2156-15

论文引用格式: Zhang F L, Zhang S M, Zhi L J and Zhou T. 2021. Detection of pulmonary nodules in CT images by combining an attention mechanism and a feature pyramid network. Journal of Image and Graphics, 26(09): 2156-2170 (张福玲, 张少敏, 支力佳, 周涛. 2021. 融合注意力机制和特征金字塔网络的 CT 图像肺结节检测. 中国图象图形学报, 26(09): 2156-2170) [DOI: 10.11834/jig.210160]

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 针对现有肺结节检测算法存在的因肺部计算机断层扫描(computed tomography, CT)图像肺结节与周边组织复杂性导致结节本身结构差异性不明显的问题, 以及特征提取网络多次下采样造成图像分辨率降低进而导致检测结果差、仅使用网络顶层特征图进行预测造成图像空间信息丢失进而导致小结节漏检等问题, 提出了一种基于注意力机制和特征金字塔的肺结节检测算法。**方法** 根据语义与空间特征补偿机制以及卷积神经网络中网络深度所提取特征的信息量不同, 在以 ResNet 为骨干网络的特征提取网络中设计通道—空间注意力机制, 尽可能同时获取含有较多上下文语义以及空间位置信息的特征信息。在网络预测部分设计特征金字塔网络, 将高维带有丰富语义信息的特征图与低维带有位置信息的特征图融合进行多尺度预测, 增强网络对于小结节以及近血管结节等非显著性目标的检测性能。**结果** 在 LUNA16(lung nodule analysis 16)数据集上进行十折交叉验证显示, 当平均假阳性个数为 25.99 时敏感度达到了 97.13%, 与基准方法相比, 敏感度提高了 2.53%, 平均假阳性降低了 28.54, 实现了高敏感度低假阳性; 在 0.125、0.25、0.5、1、2、4、8 这 7 个假阳性率的敏感度平均值为 0.854, 其中在每个扫描 4 次和 8 次假阳性时敏感度分别达到了 0.940 和 0.951, 其效果优于主流的结节检测方法。**结论** 提出的结节检测模型, 可以提高对 3~10 mm 小结节、近血管结节等非显著性目标的检测性能, 并具有较低的假阳性率。

关键词: 肺结节检测; 注意力机制; 特征金字塔网络(FPN); 非显著性目标检测; 十折交叉验证

Detection of pulmonary nodules in CT images by combining an attention mechanism and a feature pyramid network

Zhang Fuling¹, 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. The Key Laboratory of Images & Graphics Intelligent Processing of State Ethnic Affairs Commission, North Minzu University, Yinchuan 750021, China

Abstract: **Objective** The different structure of the nodules have not been clear in terms of the lung computer tomography (CT) images interpretation level for lung nodules and surrounding tissues. The detected image resolution has been reduced

收稿日期: 2021-03-05; 修回日期: 2021-04-13; 预印本日期: 2021-04-20

* 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, 61962002); 宁夏自然科学基金项目(2020AAC03213, 2021AAC03198); “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); 北方民族大学“计算机视觉与虚拟现实”创新团队项目; 北方民族大学一般科研项目(2021XYZJK04); 宁夏医学影像临床研究中心创新平台建设项目(2018DPG05006)

Supported by: National Natural Science Foundation of China (61561002, 62062003, 61962002)

due to multiple downsampling of the feature extraction network. The feature map of the network top-layer has been predicted to the losses of spatial information and missing nodules. A algorithm called attention_FPN_RPN (attention_feature pyramid networks-region proposal network) for lung nodule detection have been demonstrated via attention mechanism and feature pyramid network. **Method** The detection performance has been improved for an end-to-end lung nodule detection model training via integrating nodule candidate detection and false positive reduction into a model for joint training. At the beginning, the lung parenchyma has been segmented to form the image dataset for training and testing via threshold and morphology. The designated nodule detection model has been based on the region proposal network (RPN) of the faster R-CNN (region convolutional neural network) network. The network model has been illustrated based on the U-Net network structure using low-dose chest CT thin-slice plain scan images as input and outputs candidate nodules position and probability information. Next, the channel-spatial attention mechanism in multi-layers network has been designed in the feature extraction network via the backbone network—ResNet in terms of the semantic and spatial feature compensation mechanism and the amount of extracted feature information. Multi-layers features have been refined to retain feature information each. The integration of lower and higher dimensional features have been spatially interpreted to obtain feature information with more contextual semantics and spatial location information. The semantic information has been qualified via the top-layer of feature map for prediction though the losses of spatial information extracted. The 3D spatial information in CT sequence has not been be fully utilized. The feature pyramid network has been fused high-dimensional feature maps via rich semantic information and low-dimensional feature maps with location information. Multi-scale information network-based detection for insignificant targets like small nodules and proximal vascular nodules has been enhanced. Data enhancement and hard negative data mining has been adopted to optimize the dataset. The sliding window analysis has been used to crop $208 \times 208 \times 208$ patch in the preprocessed CT image-based lung parenchymal area. The step size has been consistent with the size of the nodule probability map based on network analysis. Based on convolution calculation, an overlap of 32 pixels amongst the divided blocks have been cropped to eliminate the undesired boundary. At the end, the probability map of the obtained small image block has been refilled into the CT image space to obtain the final probability based on the same size of the graph and the input CT image. Each voxel in the probability graph has illustrated the intended area of lung nodule. For the output result of each small block, the 100 nodules with the highest probability have been retained. Based on summing all patches to obtain candidate nodules, the candidate nodules with high overlap have merged via non-maximum suppression (NMS) method with a threshold of 0.5 for each image. The nodule based on the highest probability has been opted for each group of candidate nodules in the context of a high degree of overlap. **Result** 10-fold cross-validation on the lung nodule analysis 16 (LUNA16) dataset has shown that the sensitivity of the proposed model can be reached 97.13% under the average of 25.99 false positives per scan. In the benchmark, the sensitivity has been increased by 2.53%. The false positive average value has been reduced simultaneously to achieve high sensitivity low false positive, the average sensitivity value of the seven false positive rate points has acquired 0.125, 0.25, 0.5, 1, 2, 4, and 8 respectively. The sensitivity of the proposed model has reached 0.940 and 0.951 respectively under the average of 4, 8 false positives per scan, which is better than mainstream nodule detection methods. **Conclusion** In the context of fewer false positives, the demonstrated nodule detection model has improved the detection results of insignificant targets like 3 ~ 10 mm small nodules and proximal vessel nodules based on non-false positive reduction measures. A precise detection for tiny lung nodules has prior to the existing pulmonary nodule detection. The setup of an automatic screening system for small lung nodules and a clinical auxiliary diagnosis system for lung nodules have been benefited from the research.

Key words: pulmonary nodule detection; attention mechanism; feature pyramid network (FPN); insignificant target detection; 10-fold cross-validation

0 引言

在全球范围内,肺癌是发病率和死亡率位居癌

症首位的恶性肿瘤,而肺结节是其在临床上的早期症状表现,因此对肺结节进行早期检测的意义重大。目前,计算机断层扫描(computed tomography, CT)是医生筛查肺结节的主要技术,但是随着CT扫描层

数的增加,放射科医生的负担也随之加重。肺癌早期的症状并不明显,早期患者身体没有异样,等出现异样的时候,已经处于肺癌中期或者晚期,由于目前医学水平的限制,很多晚期患者会放弃治疗,但是早期患者可以通过临床手术的方式治疗,并且具有很高的存活率。因此,尽早诊断对肺癌患者来说特别重要,定期体检就显得尤为重要。在医学上,肺结节称为肺内类球形病灶,其直径一般在 3 ~ 30 mm。根据肺结节的空间位置信息,可以把肺结节分为孤立型肺结节、近肺壁结节以及近血管结节。

基于深度学习的自然图像检测算法在医学图像上也表现出了巨大的潜能。以机器学习和深度学习为基础的计算机辅助检测系统 (computer-aided detection, CAD) 可以自动分析影像数据,定位可疑的病灶区域,从手动设计特征、用机器学习方法对结节进行简单的良恶性分类到利用深度学习方法进行精确识别结节, CAD 技术越来越成熟。典型的基于深度学习的肺结节检测框架有两个主要任务。任务 1 是检测候选结节,尽可能从 CT 扫描图像中检测出所有的真实结节,结果通常包括大量的假阳性。任务 2 是区分结节和非结节,用于减少前一步产生的大量假阳性。这种检测方法称为两阶段的肺结节检测算法。而将结节候选检测和假阳性减少整合到一个模型中共同训练,使用一个端到端的结节检测框架进行肺结节检测更加符合临床应用。

深度学习方法中典型的结节检测网络模型主要包括卷积神经网络 (convolutional neural network, CNN)、YOLO (you only look once)、全卷积神经网络 (fully convolutional networks, FCN)、区域卷积神经网络 (region-CNN, R-CNN)、更快速的区域卷积神经网络 (faster R-CNN) 和特征金字塔网络 (feature pyramid networks, FPN) 等 (张福玲和张少敏, 2020)。例如 Ramachandran 等人 (2018) 提出的检测框架使用了目前流行的目标检测体系结构 YOLO 来检测 CT 扫描中的结节。通过使用单个 CNN 同时预测多个边界框以及这些框的类概率来优化回归问题,该算法在 LIDC-IDRI (the lung image database consortium) 数据集上进行评测,在每个扫描有 6 个假阳性时敏感度为 89%。Ding 等人 (2017) 采用 2D faster R-CNN 网络模型实现肺结节的检测,在 LUNA16 (lung nodule analysis 16) 数据集上进行十折交叉验证,结果表明在每个扫描 1 次和 4 次假阳性时,检测

敏感度分别为 92.2% 和 94.4%。Xie 等人 (2019) 为了整合结节的 3D 信息和学习结节不同的特征,分别采用 3 种不同方向的切片训练了 3 种 faster R-CNN 检测模型,最后将这 3 种模型融合获得最终检测模型,此方法在 LUNA16 数据集上验证,检测敏感度为 86.42%,竞争性能指标 (challenge performance metric, CPM) 为 0.775。Liao 等人 (2019) 设计 3 维区域生成网络来实现肺结节的检测,网络骨干采用 U-Net 网络,在 DSB (data science bowl) 数据集上 CPM 为 0.856 2。在 LUNA16 挑战赛中,Guo 等人 (2017) 提出的结节检测框架分别使用 2 维轴向切片和 3 维 CT 图像训练卷积神经网络来检测候选结节,在 LUNA16 数据集进行十折交叉验证评估模型,该框架在结节检测任务上表现出了较好的性能,CPM 为 0.949 9。赵鹏飞等人 (2018) 采用不同大小输入的卷积神经网络进行结节检测,在 LIDC-IDRI (the lung image database consortium-image database resource initiative) 数据集上评估模型,当假阳性率为 0.1 时达到 80% 的敏感度,平均检出率为 85.51%。Zhu 等人 (2018a) 提出了一阶段的结节检测算法,通过端到端地训练 3 维深度双路径网络 (dual path nets, DPN),敏感度为 95.8%,CPM 为 0.842;提出的 3D faster R-CNN 结节检测算法敏感度为 94.6%,CPM 为 0.834。Tang 等人 (2020) 基于迁移学习的多尺度特征,建立了具有多尺度特征结构的 3D U-Net 卷积神经网络模型,可以从包含背景和噪声的胸腔区域检测肺结节。在 LUNA16 和阿里天池 17 (TIANCHI17) 数据集上进行五折交叉验证,对小型结节的检测准确率达到 70% 以上。Fu 等人 (2020) 提出了一种改进的 3D U-Net 深度学习模型,用于在胸部 CT 图像上自动检测肺结节。该模型在 LIDC-IDRI 数据集的 89 例 CT 扫描上进行验证,CPM 为 0.947,在日本一家城市大学医院提供的 450 例胸部 CT 扫描上进行验证,CPM 为 0.833,表明改进 3D U-Net 深度学习模型在肺结节检测性能上具有很好的鲁棒性。高智勇等人 (2020) 提出的基于特征金字塔网络的肺结节检测方法在平均每个扫描中的候选结节数为 46.7 时,检测敏感度为 95.7%。而刘秀玲等人 (2020) 在 VGG16 (Visual Geometry Group Network 16) 网络上设计了具有 3 层模块结构的多尺度肺结节检测方法,平均检测精度达到 90.9%。曹宇等人 (2020) 也是通过对 VGG16

的改进实现对肺结节的检测。特征金字塔以及多尺度的方法在小结节的检测上表现出潜力。Liao 等人(2019)、赵鹏飞等人(2018)、Zhu 等人(2018a)以及 Tang 等人(2020)均采用了一阶段的检测方法,证明了一阶段方法在降低模型复杂度以及推理时间的情况下可以提高结节检测性能,在肺结节检测上表现出了巨大的潜力。

但是由于肺内环境复杂、肺结节体积变化大、形状各异,存在小结节(3~10 mm)漏检以及检测结果的低敏感度高假阳性的问题。针对以上问题,从算法复杂度、处理速度和计算效率上考虑,抛弃了传统的两阶段模式,提出了一个融合注意力机制和特征金字塔的端到端的肺结节检测模型。通过设计的基于通道—空间注意力机制的特征提取模块与基于特征金字塔的联结预测结构,能够较好解决结节检测问题中3~10 mm小结节漏检、近血管结节等非显著性目标的检测问题。

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)采用阈值化加形态学操作进行肺实质的分割,构成训练和测试的图像数据集。

2)设计通道—空间注意力的特征提取模块,有

效区分结节与正常组织、其他病变区,并且提高对实性结节、亚实性结节、非实性结节(磨玻璃结节)以及近血管、近肺壁结节的检测能力。

3)将融合有前馈路径特征信息的特征图尺寸分别为 $6 \times 6 \times 6$ 、 $12 \times 12 \times 12$ 以及 $24 \times 24 \times 24$ 的输出特征图构成特征金字塔,输出多个尺度融合下的预测结果。

融合注意力和特征金字塔可以从特征提取和结果预测两方面双管齐下提高对小结节的检测性能。

1.1 基于阈值方法的数据预处理

CT图像进行预处理步骤如下:

1)重采样。将所有CT图像重新采样到 $1 \text{ mm} \times 1 \text{ mm} \times 1 \text{ mm}$,以消除扫描仪分辨率的差异。

2)设定HU(Hounsfield unit,亨氏单位)阈值(石陆魁等,2020)。对肺部CT图像进行处理时,根据肺的CT值进行划分,肺的灰度值HU值为-500,所以保留HU值在 $[-1\,000, 400]$ 的肺部区域,将其他无关的部分舍去。

3)将原始数据的体素值裁剪到 $[-1\,200, 600]$ 范围,并归一化为 $[0, 255]$ 。

4)分割肺实质。采用阈值化加形态学操作进行肺实质的分割。

1.2 肺结节检测网络结构

肺结节检测网络结构如图1所示,主要由数据预




图1 肺结节检测网络结构

Fig. 1 Network structure diagram of lung nodule detection

处理模块、注意力特征提取模块、特征金字塔多尺度预测模块和肺结节检测模块4部分组成。整体网络由U-Net主干和区域建议网络(region proposal network, RPN)输出层组成,U-Net主干使网络能够捕获多尺度信息,对肺部CT图像的精细层和粗糙层信息进行结合使模型能做出遵从全局结构的局部预测,以提升小结节的检测效果,RPN的输出格式使网络可以直接生成建议框,输出结节的位置和概率信息。

经过数据预处理模块后,输入图像块的像素数量为 $96 \times 96 \times 96$ 。注意力特征提取模块是网络的前馈路径,以2个具有24个通道的 $3 \times 3 \times 3$ 卷积层开始,结构如图1(a),接着是由平均池化与最大池化组成的通道注意力模块,将通道注意力(channel attention, CA)的输出和原特征图相乘,然后是4个3D残差块和4个3D最大池化层(池化核大小为 $2 \times 2 \times 2$,步长为2)交错排列。前两个3D残差块由2个残差单元组成,后两个3D残差块由3个残差单元组成,具体结构如图1(b)。所有前馈路径的卷积核的大小为 $3 \times 3 \times 3$,在该部分的结束是一个空间注意力模块,用原特征图与空间注意力(spatial attention, SA)的输出相乘。

特征金字塔多尺度预测模块是网络的反馈路径,由两个反卷积层和两个合并单元组成。每个反卷积层的步长为2,卷积核大小为 $2 \times 2 \times 2$ 。每个合并单元将前馈块和反馈块连结起来,并将输出发送到残差块。在第2个组合单元中,将patch的裁切位置信息(x, y, z)作为额外的输入,该组合单元的特征图的尺寸为 $24 \times 24 \times 24 \times 131$ (131为通道数)。分别融合有前馈路径特征信息的 $6 \times 6 \times 6$ 、 $12 \times 12 \times 12$ 以及 $24 \times 24 \times 24$ 输出特征图上构成特征金字塔,共享最后的输出层进行分类和回归。

肺结节检测模块中的输出层由两个通道分别为64和15的 $1 \times 1 \times 1$ 卷积组成,结构如图1(c),输出层的结果为 $24 \times 24 \times 24 \times 15$ 。将4D输出张量调整为 $24 \times 24 \times 24 \times 3 \times 5$,最后两个维度分别对应于anchor的个数和回归框的参数个数。在RPN的启发下,该网络在每个位置都具有3个不同比例的anchor,分别对应于3个边界框,它们的长度分别为5 mm、10 mm和20 mm。因此,总共有 $24 \times 24 \times 24 \times 3$ 个anchor boxes。模型的输出包括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 基于通道—空间注意力机制的特征提取模块

由于肺部CT图像肺结节周边的组织复杂,在检测时容易发生结节漏检并产生大量假阳性结节,因此,需较好地划分前背景信息以及增强近血管结节、磨玻璃结节的检测能力,故本文根据语义与空间特征补偿机制,设计基于通道—空间注意力机制的特征提取模块。

如图1所示,注意力特征提取模块以2个具有24个通道的 $3 \times 3 \times 3$ 卷积层开始,之后通道个数递增至32和64。24个通道的特征是低维度特征,包含更多结节的空间位置信息。随着不断地卷积和池化,64个通道的特征图包含图像更多的语义信息。低维特征在保留结节空间信息的情况下应激活更多的语义信息,高维特征在保留结节语义信息的情况下应激活更多的空间信息。如图1所示,采用通道注意力机制对通道为24、特征图大小为 $96 \times 96 \times 96$ 的低维特征信息自适应激活,即通过响应图像的语义信息,增强结节的显著性特征通道;对于通道为64、特征图大小为 $6 \times 6 \times 6$ 的高维特征信息采用空间注意力自适应激活,获取结节的空间位置信息。通过如此特征补偿机制,来提高对亚实性结节、非实性结节(磨玻璃结节)、近血管结节以及近肺壁结节的检测准确率。

1.3.1 通道注意力

如图2(a)所示,通道注意力(CA)采用自适应平均池化与自适应最大池化压缩特征图在空间维度(通道)上的数值信息,自适应平均池化对特征图上的每一个像素点都有反馈,而自适应最大池化在进行梯度反向传播计算时,只有特征图中响应最大的地方有梯度的反馈。两个连续的全连接层之后采用Sigmoid激活函数。表达为

$$A_{out} = fc_2(\delta(fc_1(avgpool(F)))) \quad (1)$$

$$M_{out} = fc_2(\delta(fc_1(maxpool(F)))) \quad (2)$$

$$CA = \sigma(A_{out} + M_{out}) \quad (3)$$

$$CA = \sigma(fc_2(\delta(fc_1(avgpool(F)))) + fc_2(\delta(fc_1(maxpool(F)))))) \quad (4)$$

式中, A_{out} 表示平均池化输出, M_{out} 表示最大池化输出, $avgpool()$ 为平均池化操作, $maxpool()$ 为最大池化操作, σ 表示Sigmoid激活函数, fc 表示FC全连接层, fc_1 和 fc_2 构成共享多层感知机,即一个




图2 注意力机制

Fig. 2 Attention mechanism((a) channel attention(CA);(b)spatial attention(SA))

encoder-decoder 结构, δ 表示 ReLU 函数, F 表示输入的特征图, 最后用原特征图 F 与 CA (通道注意力) 的输出相乘, F' 为输出特征图。

1.3.2 空间注意力

如图 2(b) 所示, 空间注意力 (SA) 首先将输入特征 F 在空间维度上进行最大池化和平均池化, 在通道维度上分别做 mean 和 max 操作, 并将两种池化后的结果进行 Cat 连接; 接着通过一个 $7 \times 7 \times 7$ 的卷积核对接接后的结果进行卷积, 要保证最后得到的特征在空间维度上与输入的特征图一致; 之后采用 Sigmoid 激活函数进行正规化处理。采用的空间注意力为

$$SA = \sigma(\text{conv}(\text{mean}(F) + \text{max}(F))) \quad (5)$$

式中, σ 表示 Sigmoid 激活函数, F 表示输入的特征图, 最后用原特征图 F 与 SA 的输出相乘。

1.4 基于特征金字塔的多尺度预测模块

网络顶层特征在不断卷积池化过程中容易忽略小物体的一些信息, 若只采用顶层特征图进行预测, 对于肺结节来说, 尤其是 $3 \sim 10 \text{ mm}$ 的结节很容易漏检。因此本文通过构造特征金字塔结构来提高小结节的检测性能。特征金字塔通过不同层次的特征

融合, 使得小物体的信息也能够比较完整地反映出来。

在 $6 \times 6 \times 6$ 、 $12 \times 12 \times 12$ 和 $24 \times 24 \times 24$ 的特征图上进行联结预测, 并且预测是在每个融合后的特征图上单独进行的。如图 3 所示, 左边自顶向下的部分是卷积神经网络的前向过程, 进行特征提取。但是随着特征维度的上升, 可以看出高维度特征更多是一个语义信息, 包含全局图像的内在含义。而在右边自底向上的数据流向中, 高维特征信息将其通过上采样降低维度信息, 语义信息减少, 在此过程中采用跳层连接来引导自顶向下的数据流特征还原检测目标细节信息。将语义信息和位置信息在对




图3 特征金字塔结构

Fig. 3 Feature pyramid structure

应层的特征金字塔网络中进行融合后,语义信息和位置信息都得到了增强。

为了突出特征金字塔对 3~10 mm 小结节的检测性能的影响,本文对只采用特征金字塔进行多尺度预测的模块进行了实验,实验模型名称为 U_FPN_RPN,将在实验部分详细讨论实验结果。

1.5 损失函数

网络的预测误差分为两部分,一部分为候选区域是否包含结节的分类误差;另一部分为候选区域中心点位置与结节位置偏移量的回归误差。分类误差的损失函数采用 cross entropy,回归误差的损失函数使用 smooth L1。

cross entropy 计算为

$$L_{cls} = p_A \log(p) + (1 - p_A) \log(1 - p) \quad (6)$$

$$p = \frac{1}{1 + \exp(-o)} \quad (7)$$

式中, L_{cls} 表示分类损失, $p_A \in \{0,1\}$,为 anchor box 的标签,正样本为 1,负样本为 0, p 为相同位置的预测概率 o 在经过 Sigmoid 函数之后的值。

回归损失 smooth L1 计算为

$$L_{reg} = \sum_{k \in \{x,y,z,r\}} S(d_k, \hat{d}_k) \quad (8)$$

式中, L_{reg} 表示回归损失, d_k 为球形候选区域在标签矩阵中的值, $\hat{d}_k$ 为相同位置的网络预测值。 S 是平滑的一阶正则函数,表达式为

$$S(d_k, \hat{d}_k) = \begin{cases} |d_k - \hat{d}_k| - 0.5 & |d_k - \hat{d}_k| > 1 \\ 0.5(d_k - \hat{d}_k)^2 & \text{其他} \end{cases} \quad (9)$$

总损失为分类损失和回归损失之和,表达式为

$$L = L_{cls} + L_{reg} \quad (10)$$

2 实验与结果分析

2.1 数据集

本文实验使用公开数据集 LUNA16,LUNA16 数据集(Setio 等,2017)是最大的公用肺结节数据集 LIDC-IDRI 的子集,包含 888 例低剂量胸部 CT 薄层平扫图像,结节的直径大小为 3~30 mm,平均直径大小 8.31 mm,分为 10 个子集,其中每套 CT 影像包含胸腔的多个轴向切片。

在 888 例 CT 影像中,共有 36 378 个结节被标出,由 1、2、3 或 4 位放射科医师标注的结节个数为

2 290、1 602、1 186 和 777。LUNA16 数据集选取至少由 3 位专家标注的 1 186 个结节作为最后要检测的区域,也就是做实验时下载的数据,其中直径在 3~10 mm 的结节有 905 个,10~20 mm 结节有 231 个,大于 20 mm 结节有 50 个,3~10 mm 结节占总结节数的 76.3%,因此对小结节的检测决定了模型的检测性能,结节直径分布直方图如图 4 所示。




图 4 结节直径分布直方图

Fig. 4 Histogram of nodule diameter distribution

2.2 实验设置

实验使用的操作系统为 Ubuntu18.04 系统,主频 3 GB Hz 的 Intel(R) Xeon(R) Gold 6154 CPU,内存为 256 GB,网络模型使用 Python2.7 搭建,通过 Pytorch 并行计算框架在显存为 12 GB 的 NVIDIA TITAN V 显卡上展开实验。网络训练均使用 SGD (stochastic gradient descent) 优化方法,初始学习率为 0.01,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 700 s,训练一个模型需要约 23 h,完成一个模型的十折交叉验证需要约一个月的时间。由于实验对显存的消耗很大,模型训练和测试需要花费很长时间,但是相比较两阶段的肺结节检测方法,一阶段的检测算法显著降低了模型复杂度和时间成本。

整个训练与测试采用十折交叉验证的方法。LUNA16 数据集有 10 个子集,任意选择 9 组作为训练集,剩下的 1 组作为测试集。下一折验证的时候从上次 9 组训练集里面选取 1 组用做测试集,剩下的 9 组用做训练集,依次迭代,直到所有的子集都做测试,最终将所有测试集的结果汇总。针对数据不平衡问题,采用了数据增强和难例挖掘机制的方法对数据集进行了增强。

测试阶段,将肺部 CT 扫描裁剪为 $208 \times 208 \times$

208 的图像块,在裁剪的时候使分割块之间有 32 个像素的重叠,来消除卷积计算时的不期望的边界影响。然后对这些图像块分别继续预测,此步骤将输出目标结节的预测边界框 $\{x_i, y_i, z_i, r_i, p_i\}$, 其中 x_i, y_i, z_i 代表预测边界框的中心, r_i 代表半径, p_i 代表置信度。最后将得到的小图像块的概率图填充回 CT 图像空间,得到完整 CT 图像的概率图,其大小与输入的 CT 图像相同,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, 2018a), 3D faster R-CNN 为只采用 ResNet 网络、U-Net 结构的结节检测网络;在此基础上进行了改进,初次改进为在 3D faster R-CNN 算法基础上设计了特征金字塔结构,联合不同尺度特征图做输出预测,记为 U_FPN_RPN,其次在 U_FPN_RPN 基础上设计了通道—空间注意力机制,记为 attention_FPN_RPN,也就是本文提出的融合注意力机制和特征金字塔的结节检测算法。

2.3 评价标准

敏感度(sensitivity)是指预测正确的正样本数目与所有正样本数目的比值,在机器学习中常称为召回率(recall),也称为检出率。敏感度指标计算为

$$f_{\text{sen}} = \frac{TP}{TP + FN} \quad (11)$$

式中, TP 表示预测正确的正样本的数目(真阳性), FN 表示预测错误的正样本的数目(假阴性)。敏感度取值范围为 $[0, 1]$, 值越大,表示检测出的结节个数越多,检测结果越好。

采用无限制受试者操作特征(free-response receiver operating characteristic, FROC)曲线验证检测模型的性能,并在图 5(d)中加以总结,其中横坐标是每幅 CT 切片中假阳率点(false positives per scan),记为 FPs/scan , $\text{FPs}/\text{scan} \in \{0.125, 0.25, 0.5, 1, 2, 4, 8\}$ 。

竞争性能指标(challenge performance metric, CPM)是指 FROC 曲线中 7 个假阳率点(FPs/scan) (0.125, 0.25, 0.5, 1, 2, 4, 8)敏感度值的平均值,也就是平均假阳性个数下的平均敏感度,如将在平均

每个 CT 扫描含有 0.125 个假阳性的敏感度记为 $\text{Sen}(0.125)$, 竞争性能指标计算为

$$f_{\text{CPM}} = (\text{Sen}(0.125) + \text{Sen}(0.25) + \text{Sen}(0.5) + \text{Sen}(1) + \text{Sen}(2) + \text{Sen}(4) + \text{Sen}(8))/7 \quad (12)$$

2.4 通道—空间注意力机制设计方法实验验证

表 1 给出了在特征提取网络的不同层设计注意力机制的实验效果,验证了本文提出的基于通道—空间注意力机制方法实验效果最好。表 1 中结果分别为 CPM 值和敏感度值。

在数据集的 Fold0 和 Fold1 上将不同设计方法进行了实验验证,例如 $(6 \times 6 \times 6, 64)$ CA 表示在大小为 $6 \times 6 \times 6$ 、维度为 64 的特征图后添加通道注意力机制,可以看到,在大小为 $96 \times 96 \times 96$ 、维度为 64 的特征图后添加通道注意力,在大小为 $6 \times 6 \times 6$ 、维度为 24 的特征图后添加空间注意力的实验效果最好。这样低维特征在保留自身空间信息的情况下应激活更多的语义信息,高维特征在保留自身语义信息的情况下应激活更多的空间信息。

2.5 与基准实验比较十折交叉验证结果

图 5 将本文提出的结节检测算法与基准算法进行了性能比较。

图 5(a)为在十折交叉验证下,10 个 Fold 的敏感度指标的比较。U_FPN_RPN 算法和 attention_FPN_RPN 算法的每折数据相比较基准实验 3D faster R-CNN 算法提高了敏感度得分,且在 4 个 Fold 上敏感度达到了 100%, 3D faster R-CNN 算法的敏感度平均值为 95.54%, U_FPN_RPN 算法的敏感度平均值为 96.89%, 相比较 3D faster R-CNN 提高了 1.35%; attention_FPN_RPN 算法的敏感度平均值为 97.18%, 提高了 0.29%。

图 5(b)为 U_FPN_RPN、attention_FPN_RPN 与基线算法 3D faster R-CNN 在竞争性能指标(CPM)上的十折数据比较。可以看出本文算法 U_FPN_RPN 的每折数据都提高了竞争性能指标 CPM 得分, attention_FPN_RPN 算法明显提高了 Fold0、Fold1、Fold3、Fold7 和 Fold8 的 CPM 得分, 3D faster R-CNN 算法的 CPM 平均值为 0.833, U_FPN_RPN 算法的 CPM 平均值为 0.853, attention_FPN_RPN 算法的 CPM 平均值为 0.857, 相比较 3D faster R-CNN 提高了 0.040。说明特征金字塔结构比注意力机制更能




图5 本文算法与基准算法性能比较

Fig. 5 Performance comparison between the proposed algorithm and the benchmark algorithm

((a) sensitivity; (b) CPM; (c) false positives per scan; (d) FROC curves of U_FPN_RPN model)

表1 通道—空间注意力机制设计方法实验验证

Table 1 Experimental verification of channel-spatial attention mechanism design method

方法	Fold0		Fold1	
	CPM	敏感度	CPM	敏感度
3D faster R-CNN	0.848 2	0.964 2	0.853 8	0.945 3
U_FPN_RPN	0.864 8	0.982 1	0.854 9	0.961 0
(6×6×6,64)CA	0.829 0	0.955 4	—	
(6×6×6,64)SA	训练精度很差		训练精度很差	
(96×96×96,24)SA	0.813 8	0.928 6	—	
(96×96×96,24)CA	训练精度很差		训练精度很差	
(96×96×96,24)SA, (6×6×6,64)SA	0.840 6	0.973 2	—	
(96×96×96,24)CASA, (6×6×6,64)CASA	训练精度很差		训练精度很差	
(96×96×96,24)SA, (6×6×6,64)CA	0.831 6	0.964 3	0.834 8	0.953 1
(96×96×96,24)CA, (6×6×6,64)SA	0.880 1	1.000 0	0.876 1	0.953 1

注:将 CPM 值低于 80 以及 SEN 值低于 90 的结果标记为“训练精度很差”;“—”代表无数据,加粗字体代表每列最优结果。

提升结节检测性能。

图 5(c) 为各个算法在平均假阳性个数上的数据对比,1—7 折数据中有 89 个病人,所以平均假阳性的值为每折数据中的假阳性总数/89,8—9 折数据中有 88 个病人。数据显示,本文算法 attention_FPN_RPN 在提高了检出率的同时,降低了假阳性率,性能最优。

图 5(d) 以 attention_FPN_RPN 算法为例给出每一个 Fold 在 7 个假阳率点的敏感度的分布,除了 Fold2 和 Fold3 在 0.125、0.25 假阳率点具有低的敏感度之外,其他 Fold 均获得了不错的敏感度。

整体分析得出,采用注意力特征金字塔的算法 attention_FPN_RPN 明显提高了结节检测的准确率,有效解决了结节检测问题中低敏感度高假阳性的问题。

2.6 对不同大小结节的检测效果

本文算法主要是为了提高小结节(3~10 mm)的检测效果,表 2 比较了肺结节检测系统对不同大

小结节的检测效果。在 LUNA16 数据集中, 总共有 1 186 个结节, 其中 3 ~ 10 mm 结节有 905 个, 3D faster R-CNN 方法检测到了 855 个, U_FPN_RPN 算

法检测到了 876 个, attention_FPN_RPN 方法检测到了 882 个, 相比较 3D faster R-CNN 增加了 27 个结节。表明该算法可以提高小结节的检测性能。

表 2 肺结节检测系统对不同大小结节的检测效果

Table 2 The effect of lung nodule detection system on nodules of different sizes

方法	检测到的 结节数量 (3 ~ 10 mm)	检测到的 结节数量 (10 ~ 20 mm)	检测到的 结节数量 (> 20 mm)	检测到的 结节总数	敏感 度/%	假阳性 结节数量 /FPs	平均假阳性 /(FPs/scan)
3D faster R-CNN(Zhu 等, 2018a)	855	220	47	1 122	94. 60	48 422	54. 53
CNN_MIP(Zheng 等, 2020)	856	225	50	1 131	95. 36	16 985	19. 13
U_FPN_RPN(本文)	878	223	46	1 147	96. 70	23 946	26. 97
attention_FPN_RPN(本文)	882	223	47	1 152	97. 10	23 084	25. 99

注: 结节总数: 1 186 (3 ~ 10 mm: 905; 10 ~ 20 mm: 231; > 20 mm: 50), CT scan 数量: 888。

表 2 中的敏感度为该肺结节检测算法在进行十折交叉验证后得到的最高敏感度值, 假阳性个数为获得此最高敏感度时的假阳性结节个数。平均假阳性是假阳性结节总数(FPs)/CT 总数(888), 可以看出, 在使用了特征金字塔结构和注意力机制后, 敏感度提高了 2. 5%, 平均每例 CT 中假阳性个数减少了 28. 54 个, 这得益于 FPN 结构中上采样结构以及通道—空间注意力机制的加入, 使得网络能充分利用不同尺度的结节特征并且增强对于非显著性目标区域的分类, 提高了对不同大小结节的检测率, 同时降低了假阳性。

2.7 与其他检测方法比较

表 3 将基于机器学习方法和基于深度学习方法的肺结节检测算法性能进行了比较。主要选取敏感度、平均假阳性、候选结节总数以及平均候选结节数指标。候选结节总数指的是网络预测出来的所有结果, 其中包括结节和非结节; 平均候选结节数是候选结节总数/CT 总数。Murphy 等人(2009)、Jacobs 等人(2014)、Torres 等人(2015)以及 Tan 等人(2011)采用了经典的机器学习方法, Zhang 等人(2018)、Setio 等人(2017)、Zhu 等人(2018a)、Zheng 等人(2020)等以及本文算法均采用了深度学习方法。可以看出, 深度学习方法的结节检测敏感度表现更优。Zhang 等人(2018)和 Setio 等人(2017)提出方法获得了高检测率, 但是产生了大量假阳性。本文方法在每次扫描的候选结节数目较少的情况下获得

了较优的敏感度。

为了进一步验证所提模型的有效性以及综合搜索能力, 将本文算法与其他方法在 CPM 指标上进行了比较。表 4 比较了不同检测模型在平均假阳性分别为 0. 125, 0. 25, 0. 5, 1, 2, 4, 8 时的检测敏感度以及在这 7 个点的敏感度平均值(CPM), 其中, 本文检测模型显著提高了平均假阳性为 1、2、4、8 这几个点的敏感度, 分别达到了 0. 918、0. 940 和 0. 951 的高检测敏感度, 且最终 CPM 为 0. 854, 比参与对比的方法获得了更好的性能, 表明模型在低假阳性的情况下实现了高敏感度, 提高了结节的检测性能。而在 0. 125, 0. 25, 0. 5 这 3 个点, 虽然实验结果比基准实验 Deep 3D Res18(Zhu 等, 2018a) 的敏感度高, 但是低于戚永军等人(2020)的结果, 戚永军等人(2020)采用 2 维与 3 维相结合的深度混合卷积的检测模型, 可以在假阳率非常低的情况下有较好的敏感度。本文采用的是一阶段结节检测方法, 并没有专门去假阳, 因此在 0. 125, 0. 25, 0. 5 这几个点的敏感度偏低, 表明算法在降假阳方面仍有欠缺, 需进一步提高。

2.8 肺结节检测结果可视化

图 6 使用 FROC 曲线对本文提出的肺结节检测方法 attention_FPN_RPN 和基准算法 3D faster R-CNN 在 LUNA16 数据集上的结节检测性能进行了比较。可以看到, 本文算法结节检测性能更优。

表3 基于机器学习方法和基于深度学习方法的肺结节检测算法性能对比

Table 3 Comparison of the performance of lung nodule detection algorithms based on machine learning methods and deep learning methods

方法	敏感度/%	平均假阳性/(FPs/scan)	候选结节总数	平均候选结节数
Murphy 等人(2009)	85.60	—	298 256	335.87
Tan 等人(2011)	92.90	—	295 686	332.98
Jacobs 等人(2014)	36.10	—	258 075	290.63
Torres 等人(2015)	76.80	—	19 687	22.17
Setio 等人(2016)	90.10	4.0	—	—
Firmino 等人(2016)	94.40	7.0	—	—
Setio 等人(2017)	96.90	1.0	—	—
Dou 等人(2017)	90.70	4.0	—	—
Jiang 等人(2018)	94.00	15.1	—	—
Zhang 等人(2018)	97.20	4.0	45 939	51.73
Zhu 等人(2018a)	94.60	54.53	54 346	61.20
高慧明(2019)	96.40	608.7	548 518	617.7
高智勇等人(2020)	95.70	—	41 470	46.7
曹宇等人(2020)	94.44	—	—	—
李莉等人(2020)	96.24	—	—	—
Zheng 等人(2020)	95.36	19.13	18 115	20.40
戚永军等人(2020)	92.40	8.0	—	—
U_FPN_RPN(本文)	96.71	26.97	29 285	32.98
attention_FPN_RPN(本文)	97.13	25.99	28 363	31.94

注:“—”代表无数据。

表4 不同肺结节检测方法的检测敏感度比较

Table 4 Sensitivity performance comparison of different lung nodule detection methods

方法	平均假阳性							CPM
	0.125	0.25	0.5	1	2	4	8	
DIAG_ConvNet(Setio 等,2016)	0.692	0.771	0.809	0.863	0.895	0.914	0.923	0.838
ZENT(Berens 等,2016)	0.661	0.724	0.779	0.831	0.872	0.892	0.915	0.811
Aidence(Lung Nodule Analysis 2016,2016)	0.601	0.712	0.783	0.845	0.885	0.908	0.917	0.807
MOT_M5Lv1(Setio 等,2016)	0.597	0.670	0.718	0.759	0.788	0.816	0.843	0.742
VisiaCTLung(Lung Nodule Analysis, 2016)	0.577	0.644	0.697	0.739	0.769	0.788	0.793	0.715
Resnet(Dou 等,2017)	0.659	0.745	0.819	0.865	0.906	0.933	0.946	0.839
Deep 3D DPN26(Zhu 等,2018a)	0.692	0.769	0.824	0.865	0.893	0.917	0.933	0.842
Deep 3D Res18(Zhu 等,2018a)	0.662	0.746	0.815	0.864	0.902	0.918	0.932	0.834
高慧明(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
U_FPN_RPN(本文)	0.687	0.776	0.839	0.878	0.912	0.930	0.945	0.852
attention_FPN_RPN(本文)	0.678	0.772	0.836	0.884	0.918	0.940	0.951	0.854

注:加粗字体为所在列最优值。




图6 平均FROC曲线

Fig. 6 Average FROC curves

不同类型肺结节的检测结果如图7所示,从LUNA16数据集中随机选取了实性结节、亚实性结节、纯磨玻璃结节(非实性结节)、近血管结节以及近肺壁结节,并以这些结节为例给出不同算法的检测结果。

第1行为肺结节位置金标准图,接下来分别为3D faster R-CNN、U_FPN_RPN以及attention_FPN_RPN算法的检测结果,包括预测边界框(框的中心位置即为结节的位置)和预测为结节的置信度。对于图7(a)实性结节,3D faster R-CNN算法的预测边界框偏右,不如本文算法的检测结果;图7(b)亚实




图7 不同类型结节检测结果

Fig. 7 Detection results of different types of nodules

((a)solid nodules; (b)sub-solid nodules; (c)pure ground-glass nodules; (d)juxta-pleural nodules; (e)juxta-vascular nodules)

性结节,attention_FPN_RPN算法检测结果最好;图7(c)纯磨玻璃结节,检测这个类型的结节是有难度的,3D faster R-CNN算法的检测精度为0.995,相比本文算法检测结果略差;图7(d)近血管结节,检测这个类型的结节是有很大难度的,可以看到,3D faster R-CNN算法的结节检测精度只有0.864,本文算法U_FPN_RPN检测结果最好;对于图7(e)近肺壁结节,几种算法都很好地产出了结节。

综合比较,可以看出本文算法对不同类型结节均具有较好的检测结果,且具有较高的置信度。虽

然有效提升了小结节的检测性能,但依然存在结节漏检情况(检测失败图像)。通过分析,漏检的结节主要集中在结节直径大小在3~10 mm范围内,且空间位置不明显,多是近肺壁结节、近血管结节、磨玻璃结节等,这类结节属于高难度检测结节,检测模型需要在这方面再次进行突破。

3 结论

根据肺结节的特点以及结节检测存在的问题,

提出了一种基于通道—空间注意力机制和特征金字塔结构的肺结节检测方法。首先在基准算法上构造特征金字塔网络,采用自顶向下(top-down)结构以及横向连接,将分辨率低但具有丰富语义信息的较深的网络层产生的特征图与高分辨率但是语义信息不丰富的网络层产生的特征图融合,避免了只采用顶层特征做预测而忽略小物体信息的问题,以此来提高对3~10 mm小结节的检测性能。然后通过理论研究与实验验证,在特征提取网络的不同层上设计合理的通道注意力与空间注意力,形成空间信息与语义信息的信息补偿,以解决由于多次下采样操作带来的分辨率降低导致检测结果差的问题,提高对磨玻璃结节、近血管结节和近肺壁结节等非显著性目标的检测性能。在LUNA16数据集888个病人上进行了十折交叉验证,结果表明,本文方法的敏感度、CPM、平均假阳性等多项评价指标结果均优于对比的结节检测算法及主流检测框架,可以有效提高小结节的检测性能,对微小肺结节自动筛查系统和临床肺结节辅助诊断系统建立具有十分重要的作用。

考虑到实际临床需求,后续工作会将深度学习方法与电子病历(electronic medical record, EMR)以及影像归档等医学材料相结合进行半监督学习,例如DeepEM(Zhu等,2018b)结节检测算法挖掘电子病历中的弱监督信息实现肺结节的检测以及FocalMix(Wang等,2020)算法采用半监督学习(semi-supervised learning, SSL)实现3D医学图像检测的方法都表现出了巨大的潜力,降低对金标准数据的依赖,进一步改善了肺结节计算机辅助诊断系统并发展其对肺癌治疗的作用。

参考文献(References)

- Berens M, Van Der Gugten R, De Kaste M, Manders J and Zuidhof G. 2016. ZNET-lung nodule detection [EB/OL]. [2021-03-05]. <https://www.scribd.com/document/429578776/ZNET-NDET-160831>
- Cao Y, Xing S X, Pang J L, Wang X Y, Wang Y, Pan Z Y and Shen N. 2020. Detection of pulmonary nodules based on improved VGG-16 convolution neural network. Chinese Journal of Medical Physics, 37(7): 940-944 (曹宇, 邢素霞, 逢键梁, 王孝义, 王瑜, 潘子妍, 申楠. 2020. 基于改进的VGG-16卷积神经网络的肺结节检测. 中国医学物理学杂志, 37(7): 940-944) [DOI: 10.3969/j.issn.1005-202X.2020.07.026]
- Ding J, Li A X, Hu Z Q and Wang L W. 2017. Accurate pulmonary nodule detection in computed tomography images using deep convolutional neural networks//Proceedings of the 20th International Conference on Medical Image Computing and Computer-Assisted Intervention. Quebec City, Canada: Springer, Cham: 559-567 [DOI: 10.1007/978-3-319-66179-7_64]
- Dou Q, Chen H, Jin Y M, Li H J, Qin J and Heng P A. 2017. 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]
- Firmino M, Angelo G, Morais H, Dantas M and Valentim R. 2016. Computer-aided detection (CAdE) and diagnosis (CAdx) system for lung cancer with likelihood of malignancy. BioMedical Engineering OnLine, 15, 1 (2016-01-06), 2016, 15(1): #2 [DOI: 10.1186/s12938-015-0120-7]
- Fu R, Chai Y F, Zhang J T, Zhang T, Chen X K, Dong S, Yan H H, Yang X N, Huang M P, Wu Y L, Zhuang J and Zhong W Z. 2020. Three-dimensional printed navigational template for localizing small pulmonary nodules: a case-controlled study. Thoracic Cancer, 11(9): 2690-2697 [DOI: 10.1111/1759-7714.13550]
- Gao H M. 2019. Research on Detection and Benign and Malignant Classification Method of Pulmonary Nodules Based on Convolutional Neural Network. Taiyuan: Taiyuan University of Technology (高慧明. 2019. 基于卷积神经网络的肺结节检测及良恶性分类方法研究. 太原: 太原理工大学)
- Gao Z Y, Huang J Z and Du C G. 2020. Pulmonary nodule detection based on feature pyramid networks. Journal of Computer Applications, 40(9): 2571-2576 (高智勇, 黄金镇, 杜程刚. 2020. 基于特征金字塔网络的肺结节检测. 计算机应用, 40(9): 2571-2576) [DOI: 10.11772/j.issn.1001-9081.2019122122]
- Guo H C, Wei Y X, Han Y, Hong L J, Lin Y H, Hai Q X and Yang D Z. 2017. Deep convolution neural networks for pulmonary nodule detection in CT imaging [EB/OL]. [2021-8-13]. https://grand-challenge-public-prod.s3.amazonaws.com/t/challenge/71/101b150c-88c5-4f9d-a374-d8d3fc166aff/20171222_073722_JianpeiCAD_NDET.pdf
- Jacobs C, van Rikxoort E M, Twellmann T, Scholten E T, de Jong P A, Kuhnigk J M, Oudkerk M, de Koning H J, Prokop M, Schaefer-Prokop C and van Ginneken B. 2014. Automatic detection of sub-solid pulmonary nodules in thoracic computed tomography images. Medical Image Analysis, 18(2): 374-384 [DOI: 10.1016/j.media.2013.12.001]
- Jiang H Y, Ma H, Qian W, Gao M D and Li Y. 2018. An automatic detection system of lung nodule based on multigroup patch-based deep learning network. IEEE Journal of Biomedical and Health Informatics, 22(4): 1227-1237 [DOI: 10.1109/JBHI.2017.

- 2725903]
- Li L, Qiao L and Zhang H Y. 2020. Automatic detection algorithm of pulmonary nodules based on deep learning. *Computer Applications and Software*, 37(7): 95-100 (李莉, 乔璐, 张浩洋. 2020. 基于深度学习的肺结节自动检测算法. *计算机应用与软件*, 37(7): 95-100) [DOI: 10.3969/j.issn.1000-386x.2020.07.015]
- 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 X L, Qi S S, Xiong P, Liu J, Wang H R and Yang J L. 2020. An automatic pulmonary nodules detection algorithm with multi-scale information fusion. *Journal of Biomedical Engineering*, 37(3): 434-441 (刘秀玲, 戚帅帅, 熊鹏, 刘京, 王洪瑞, 杨建利. 2020. 融合多尺度信息的肺结节自动检测算法. *生物医学工程学报*, 37(3): 434-441) [DOI: 10.7507/1001-5515.201910047]
- Lung Nodule Analysis 2016. 2016. LUNA16-Results [EB/OL]. [2021-03-05]. <https://luna16.grand-challenge.org/Results/>
- Murphy K, van Ginneken B, Schilham A M R, de Hoop B J, Gietema H A and Prokop M. 2009. A large-scale evaluation of automatic pulmonary nodule detection in chest CT using local image features and k-nearest-neighbour classification. *Medical Image Analysis*, 13(5): 757-770 [DOI: 10.1016/j.media.2009.07.001]
- 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]
- Ramachandran S S, George J, Skaria S and Varun V V. 2018. Using YOLO based deep learning network for real time detection and localization of lung nodules from low dose CT scans//*Proceedings of SPIE 10575, Medical Imaging 2018: Computer-Aided Diagnosis*. Houston, USA: SPIE: #10575 [DOI: 10.1117/12.2293699]
- 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, S6? ora-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, Zhang C Z and Fan S Y. 2020. Detection method of pulmonary nodules based on improve residual structure. *Journal of Computer Applications*, 40(7): 2110-2116 (石陆魁, 马红祺, 张朝宗, 樊世燕. 2020. 基于改进残差结构的肺结节检测方法. *计算机应用*, 40(7): 2110-2116) [DOI: 10.11772/j.issn.1001-9081.2019122095]
- Tan M, Deklerck R, Jansen B, Bister M and Cornelis J. 2011. A novel computer-aided lung nodule detection system for CT images. *Medical Physics*, 38(10): 5630-5645 [DOI: 10.1118/1.3633941]
- Tang S Y, Yang M and Bai J N. 2020. Detection of pulmonary nodules based on a multiscale feature 3D U-Net convolutional neural network of transfer learning. *PLoS One*, 15(8): #0235672 [DOI: 10.1371/journal.pone.0235672]
- Torres E L, Fiorina E, Pennazio F, Peroni C, Saletta M, Camarlinghi N, Fantacci M E and Cerello P. 2015. Large scale validation of the M5L lung CAD on heterogeneous CT datasets. *Medical Physics*, 42(4): 1477-1489 [DOI: 10.1118/1.4907970]
- Wang D, Zhang Y, Zhang K X and Wang L W. 2020. FocalMix: semi-supervised learning for 3D medical image detection//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA: IEEE: 3951-3960 [DOI: 10.1109/CVPR42600.2020.00401]
- 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]
- 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的方法综述. *计算机工程与应用*, 56(13): 20-32) [DOI: 10.3778/j.issn.1002-8331.2002-0051]
- Zhang J J, Xia Y, Zeng H Y and Zhang Y N. 2018. NODULe: combining constrained multi-scale LoG filters with densely dilated 3D deep convolutional neural network for pulmonary nodule detection. *Neurocomputing*, 317: 159-167 [DOI: 10.1016/j.neucom.2018.08.022]
- Zhao P F, Zhao J J, Qiang Y, Wang F Z and Zhao W T. 2018. Study on detection method of pulmonary nodules with multiple input convolutional neural network. *Computer Science*, 45(1): 162-166 (赵鹏飞, 赵涓涓, 强彦, 王峰智, 赵文婷. 2018. 多输入卷积神经网络肺结节检测方法研究. *计算机学报*, 45(1): 162-166) [DOI: 10.11896/j.issn.1002-137X.2018.01.028]
- Zheng S Y, Guo J P, Cui X N, Veldhuis R N J, Oudkerk M and van Ooijen P M. 2020. Automatic pulmonary nodule detection in CT scans using convolutional neural networks based on maximum inten-

sity projection. IEEE Transactions on Medical Imaging, 39 (3): 797-805 [DOI: 10.1109/TMI.2019.2935553]

Zhu W T, Liu C C, Fan W and Xie X H. 2018a. DeepLung: deep 3D dual path nets for automated pulmonary nodule detection and classification//Proceedings of 2018 IEEE Winter Conference on Applications of Computer Vision. Lake Tahoe, USA: IEEE: 673-681 [DOI: 10.1109/WACV.2018.00079]


Zhu W T, Vang Y S, Huang Y F and Xie X H. 2018b. DeepEM: deep 3D convnets with EM for weakly supervised pulmonary nodule detection//Proceedings of the 21 st International Conference on Medical Image Computing and Computer-Assisted Intervention. Granada, Spain: Spring: 812-820 [DOI: 10.1007/978-3-030-00934-2_90]

作者简介



张福玲,1994年生,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:2430530276@qq.com



张少敏,通信作者,女,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: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:zhilj@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