



中国多媒体大会(ChinaMM2020)专刊



第26卷第7期（总第303期）

2021年7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



类别语义相似性监督的小样本图像识别(第1594页)



像素聚合和特征增强的任意形状场景文本检测(第1614页)



时序特征融合的视频实例分割(第1692页)

综述

面向上行流媒体的压缩感知视频流技术前沿

刘浩, 黄荣, 袁浩东 1545

图像处理和编码

耦合保持投影哈希跨模态检索

闵康凌, 张国宾, 王磊, 李丹萍 1558

面向视觉搜索的空间局部敏感哈希方法

黄小燕, 孙彬, 杨展源, 朱映映, 田奇 1568

图像分析和识别

融合视觉关系检测的电力场景自动危险预警

高明, 左红群, 柏帆, 田清阳, 葛志峰, 董兴宁, 甘甜 1583

类别语义相似性监督的小样本图像识别

徐鹏帮, 桑基韬, 路冬媛 1594

局部双目视差回归的目标距离估计

张羽丰, 李昱希, 赵明璧, 喻晓源, 占云龙, 林巍峭 1604

像素聚合和特征增强的任意形状场景文本检测

师广琛, 巫义锐 1614

相位一致性指导的全参考全景图像质量评价

夏雨蒙, 王永芳, 王闯 1625

图像理解和计算机视觉

特征金字塔结构的时序行为识别网络

何嘉宇, 雷军, 李国辉 1637

多模态多层次事件网络的谣言检测

李莎, 张怀文, 钱胜胜, 方全, 徐常胜 1648

多模态零样本人体动作识别

吕露露, 黄毅, 高君宇, 杨小汕, 徐常胜 1658

足球视频球员感知跟踪算法

冯思佳, 宋子恺, 于俊清, 何云峰, 管涛 1668

融合时空图卷积的多人交互行为识别

成科扬, 吴金霞, 王文杉, 荣兰, 詹永照 1681

时序特征融合的视频实例分割

黄泽涛, 刘洋, 于成龙, 张加佳, 王轩, 漆舒汉 1692

医学图像处理

多尺度深度特征提取的肝脏肿瘤CT图像分类

毛静怡, 宋余庆, 刘哲 1704

3D多尺度深度卷积神经网络肺结节检测


孙华聪, 彭延军, 郭燕飞, 张晓庆 1716

结合多通道注意力的糖尿病性视网膜病变分级

顾婷菲, 郝鹏翼, 白琮, 柳宁 1726

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS



Few shot image recognition based on class semantic similarity supervision(P1594)



Arbitrary shape scene-text detection based on pixel aggregation and feature enhancement (P1614)



Video instance segmentation based on temporal feature fusion (P1692)

Review

Survey on compressive sensing video stream for uplink streaming media

Liu Hao, Huang Rong, Yuan Haodong 1545

Image Processing and Coding

Structure-preserving hashing with coupled projections for cross-modal retrieval

Min Kangling, Zhang Guobin, Wang Lei, Li Danping 1558

Locality-sensitive hashing approach based on semantic space for visual retrieval

Huang Xiaoyan, Sun Bin, Yang Zhanyuan, Zhu Yingying, Tian Qi 1568

Image Analysis and Recognition

Visual relationship detection-based emergency early-warning description generation in electric power industry

Gao Ming, Zuo Hongqun, Bai Fan, Tian Qingyang, Ge Zhifeng, Dong Xingning, Gan Tian 1583

Few shot image recognition based on class semantic similarity supervision

Xu Pengbang, Sang Jitao, Lu Dongyuan 1594

Object distance estimation based on stereo regional disparity regression

Zhang Yufeng, Li Yuxi, Zhao Mingbi, Yu Xiaoyuan, Zhan Yunlong, Lin Weiyao 1604

Arbitrary shape scene-text detection based on pixel aggregation and feature enhancement

Shi Guangchen, Wu Yirui 1614

Phase consistency guided full-reference panoramic image quality assessment algorithm

Xia Yumeng, Wang Yongfang, Wang Chuang 1625

Image Understanding and Computer Vision

Temporal action detection based on feature pyramid hierarchies

He Jiayu, Lei Jun, Li Guohui 1637

Multi-modal multi-level event network for rumor detection

Li Sha, Zhang Huaiwen, Qian Shengsheng, Fang Quan, Xu Changsheng 1648

Multimodal-based zero-shot human action recognition

Lyu Lulu, Huang Yi, Gao Junyu, Yang Xiaoshan, Xu Changsheng 1658

Players-aware tracking algorithm in soccer video

Feng Sijia, Song Zikai, Yu Junqing, He Yunfeng, Guan Tao 1668

Multi-person interaction action recognition based on spatio-temporal graph convolution

Cheng Keyang, Wu Jinxia, Wang Wenshan, Rong Lan, Zhan Yongzhao 1681

Video instance segmentation based on temporal feature fusion

Huang Zetao, Liu Yang, Yu Chenglong, Zhang Jiajia, Wang Xuan, Qi Shuhan 1692

Medical Image Processing

CT image classification of liver tumors based on multi-scale and deep feature extraction

Mao Jingyi, Song Yuqing, Liu Zhe 1704

3D multi-scale deep convolutional neural networks in pulmonary nodule detection

Sun Huacong, Peng Yanjun, Guo Yanfei, Zhang Xiaoqing 1716

Diabetic retinopathy grading based on multi-channel attention

Gu Tingfei, Hao Pengyi, Bai Cong, Liu Ning 1726

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2021)07-1716-10

论文引用格式: Sun H C, Peng Y J, Guo Y F and Zhang X Q. 2021. 3D multi-scale deep convolutional neural networks in pulmonary nodule detection. *Journal of Image and Graphics*, 26(07): 1716-1725 (孙华聪, 彭延军, 郭燕飞, 张晓庆. 2021. 3D 多尺度深度卷积神经网络肺结节检测. *中国图象图形学报*, 26(07): 1716-1725) [DOI: 10. 11834/jig. 200501]

3D 多尺度深度卷积神经网络肺结节检测

孙华聪, 彭延军*, 郭燕飞, 张晓庆

山东科技大学, 青岛 266590

摘要: **目的** 肺结节是肺癌的早期存在形式。低剂量 CT (computed tomography) 扫描作为肺癌筛查的重要检查手段, 已经大规模应用于健康体检, 但巨大的 CT 数据带来了大量工作, 随着人工智能技术的快速发展, 基于深度学习的计算机辅助肺结节检测引起了关注。由于肺结节尺寸差别较大, 在多个尺度上表示特征对结节检测任务至关重要。针对结节尺寸差别较大导致的结节检测困难问题, 提出一种基于深度卷积神经网络的胸部 CT 序列图像 3D 多尺度肺结节检测方法。**方法** 包括两阶段: 1) 尽可能提高敏感度的结节初检网络; 2) 尽可能减少假阳性结节数量的假阳性降低网络。在结节初检网络中, 以组合了压缩激励单元的 Res2Net 网络为骨干结构, 使同一层卷积具有多种感受野, 提取肺结节的多尺度特征信息, 并使用引入了上下文增强模块和空间注意力模块的区域推荐网络结构, 确定候选区域; 在由 Res2Net 网络模块和压缩激励单元组成的假阳性降低网络中对候选结节进一步分类, 以降低假阳性, 获得最终结果。**结果** 在公共数据集 LUNA16 (lung nodule analysis 16) 上进行实验, 实验结果表明, 对于结节初检网络阶段, 当平均每例假阳性个数为 22 时, 敏感度可达到 0.983, 相比基准 ResNet + FPN (feature pyramid network) 方法, 平均敏感度和最高敏感度分别提高了 2.6% 和 0.8%; 对于整个 3D 多尺度肺结节检测网络, 当平均每例假阳性个数为 1 时, 敏感度为 0.924。**结论** 与现有主流方案相比, 该检测方法不但提高了肺结节检测的敏感度, 还有效地控制了假阳性, 取得了更优的性能。

关键词: 肺结节检测; 卷积神经网络 (CNN); 多尺度; 区域推荐网络; 上下文增强; 空间注意力; 假阳性降低

3D multi-scale deep convolutional neural networks in pulmonary nodule detection

Sun Huacong, Peng Yanjun*, Guo Yanfei, Zhang Xiaoqing

Shandong University of Science and Technology, Qingdao 266590, China

Abstract: **Objective** Pulmonary nodules are early forms of lung cancer, one of the most threatening malignancies for human health and life. As an important means of lung cancer screening, low-dose computerized tomographic scanning has been widely used in health examinations. However, a large amount of computed tomography (CT) data brings a heavy workload to doctors and radiologists, and high-intensity work can result in misdiagnosis. With the rapid development of artificial intelligence technology, computer-aided lung-nodule detection based on deep learning has attracted much attention. As the size of pulmonary nodules varies greatly, representing features on multiple scales is critical for nodule detection tasks. To solve the problem of difficulty in detection caused by the large difference in size of nodules, this paper proposes a 3D multi-scale pulmonary nodule detection method in chest CT sequence images based on deep convolutional neural network.

收稿日期: 2020-08-22; 修回日期: 2021-01-16; 预印本日期: 2021-01-23

* 通信作者: 彭延军 pengyanjuncn@163.com

基金项目: 国家自然科学基金项目 (61976126); 山东省自然科学基金项目 (ZR2019MF003, ZR2020MF044)

Supported by: National Natural Science Foundation of China (61976126)

Method The method mainly consists of two stages: 1) nodule candidate detection stage that maximizes system sensitivity, and 2) false positive reduction stage that minimizes the number of false positive nodules. Specifically, a series of preprocessing operations is performed on the original CT images first, and the regions of interest (ROIs) of lung nodules are obtained by cropping. In the training phase of the nodule candidate detection network, after the preprocessing steps, data augmentation is performed by randomly rotating, flipping, and scaling. Then, nodule cubes and non-nodule cubes with a size of $128 \times 128 \times 128$ are randomly cropped out and input to the network. The nodule candidate detection network uses the combination of the squeeze-and-excitation units and the Res2Net modules as the backbone structure, so that the convolutions of the same layer have a variety of receptive fields. Thus, the network can extract the multi-scale feature information of pulmonary nodules. In addition, the nodule candidate detection network also uses the region proposal network structure that introduces context enhancement module and spatial attention module to identify region candidates. In the test phase of the nodule candidate detection network, the preprocessed CT image is divided into several small patches of size $208 \times 208 \times 208$, which are used as the inputs of the network, and adjacent small patches overlap 32 pixels. For each CT image, the nodule candidates obtained from all small patches are summarized, and the nodules with higher overlap are merged through non-maximum suppression with an intersection over union (IOU) threshold of 0.1 to obtain the detection results. In the training phase of the false positive reduction network, because the average number of false positive nodules per scan is 22 obtained through experiments in the nodule candidate detection network, the positive samples are augmented by 22 times to balance the number of positive and negative samples. The augmentation methods are consistent with the methods in the training phase of the nodule candidate detection network. The false positive reduction network mainly consisting of Res2Net modules and squeeze-and-excitation units further classifies nodule candidates to reduce the number of false positives. The testing phase of the false positive reduction network takes the nodule candidate coordinates obtained by the nodule candidate detection network as the centers, and crops cubes of size $48 \times 48 \times 48$ as the inputs of the false-positive reduction network. The outputs of the false-positive reduction network are the confidences of nodule candidate cubes. Among them, the squeeze-and-excitation unit can capture the channel dependence comprehensively, which makes the channel weight that contains abundant nodule information significant, and makes the channel weight without nodule information small. Res2Net module increases the receptive field of each output feature map without increasing the computational load, which causes the network to have stronger multi-scale representation ability. The region proposal network can take images of any scale as input and output a series of region candidates with scores, which are robust. Context enhancement module can fuse high-level semantic information and low-level position information. Its structure is simple, the implementation is easy, and the calculation cost is low, but it has good performance. The spatial attention module enables the network to pay more attention to the ROIs, which can reduce the difficulty of accurately distinguishing because of the visual similarity between pulmonary nodules and the structures such as blood vessels and shadows around the pulmonary nodules. The effectiveness of this method is validated on the publicly available dataset LUNA16 (lung nodule analysis 16) and extensive ablation validation experiments are conducted to demonstrate the contribution of each key component to our proposed framework. The LUNA16 dataset is a subset of LIDC-IDRI (lung image database consortium and image database resource initiative), the largest public dataset of lung nodules. The LUNA16 dataset excludes CT images with slice thickness greater than 2.5 mm from the LIDC-IDRI dataset. A total of 888 CT images remain, with slice thickness of 0.6 ~ 2.5 mm, spatial resolution of 0.46 ~ 0.98 mm, and average diameter of 8.3 mm. The criteria for judging a nodule in the LUNA16 dataset is that at least three of the four radiologists believe that the diameter of the nodule is greater than 3 mm. Therefore, a total of 1 186 positive nodules are annotated in the dataset. The evaluation metric, FROC (free-response receiver operating characteristic curves), is the average recall rate at the average number of false positive nodules at 0.125, 0.25, 0.5, 1, 2, 4, and 8 per scan, which is the official evaluation metric for the LUNA16 dataset. **Result** The experimental results show that in the nodule candidate detection stage, the sensitivity can reach 0.983 when the average number of false positives per scan is 22. Compared with the benchmark ResNet + FPN (feature pyramid network) method, the average sensitivity and the maximum sensitivity are increased by 2.6% and 0.8%, respectively. For the entire 3D multi-scale pulmonary nodule detection network, when the average number of false positives per scan is 1, the sensitivity is 0.924. **Conclusion** Compared with the state-of-the-art methods, our method not only improves the sensitivity of pulmonary nodule detection but also effectively controls the

number of false positives and achieves better performance. As this method can only output the position information of nodules, in actual lung cancer screening, the growth position, edge shape, and internal structure of the nodules are all significant for clinical diagnosis. Analysis of the characteristics of the nodules can make this method more practical.

Key words: pulmonary nodule detection; convolutional neural network (CNN); multi-scale; region proposal network; context enhancement; spatial attention; false positive reduction

0 引言

肺癌是对人类健康和生命威胁最大的恶性肿瘤之一 (Bray 等, 2018)。根据医学临床经验, 一旦肺癌的临床症状显现, 治愈率就非常低, 因此尽早发现肺结节对降低肺癌死亡率具有重要意义 (Wood 等, 2018)。低剂量 CT (computed tomography) 扫描作为对高危人群进行肺癌筛查的重要检查手段已大规模用于健康体检, 但巨大的 CT 数据给医生和放射学家带来大量工作, 高强度的工作容易造成医生误诊。随着人工智能技术的快速发展, 基于深度学习的计算机辅助检测引起了人们关注 (Murphy 等, 2018)。

深度学习在胸部 CT 序列图像肺结节检测领域取得了优异成绩。Zhu 等人 (2018) 使用具有双路径块和 U-Net 型编解码器结构的 Faster R-CNN (region convolutional neural network) (Ren 等, 2017) 进行候选结节检测, 在 LUNA16 (lung nodule analysis 16) 数据集 (Setio 等, 2017) 7 个假阳性数 (0.125, 0.25, 0.5, 1, 2, 4, 8) 下的平均敏感度为 0.842。Dou 等人 (2017a) 使用 3 维全卷积网络 (Shelhamer 等, 2017) 进行肺结节初始检测, 在 LUNA16 数据集的平均敏感度为 0.839, 利用残差网络 (He 等, 2016) 进行假阳性降低, 在平均每例假阳性个数为 1 时, 敏感度达到 0.905。Khosravan 和 Bagci (2018) 提出一种名为 S4ND (single-shot single-scale lung nodule detection) 的肺结节检测网络, 由密集连接卷积块组成, 以端到端的方式进行训练, 不需要任何后处理来完善检测结果, 在 LUNA16 数据集上达到 0.897 的平均敏感度。Xie 等人 (2019) 通过两个区域推荐网络和一个反卷积层对 2D Faster R-CNN 结构进行调整, 检测候选结节, 在 LUNA16 数据集上最高敏感度可达 0.864, 并用 3 种 2D 模型分别训练 3 种位置不同的切片, 降低假阳性, 平均敏感度为 0.790。Dou 等人 (2017b) 通过将不同大小的 CT 图像立方体作为输入, 提出了用于假阳性降低的多级上下文 3D 卷积

神经网络, 在 LUNA16 数据集上平均敏感度为 0.827。Wang 等人 (2019) 合并 3 个相邻的轴向切片, 构建 3D RGB 图像用于结节检测, 在 LUNA16 数据集上, 当平均每例候选结节数为 60.23 时, 最高敏感度可达 0.968, 通过感受野不同的两种 Inception-v4 网络 (Szegedy 等, 2017) 降低假阳性, 平均敏感度为 0.903。以上这些方法, 虽然对于特定大小的肺结节检测已取得较好效果, 但在肺结节多尺度检测提高敏感度和降低假阳性等方面仍存在改善空间, 如何利用 CT 序列图像数据特性设计更高效的网络结构是提高计算机辅助检测系统性能的关键。

本文基于深度卷积神经网络 (deep convolution neural network, DCNN), 以提高系统敏感度和降低假阳性为目标, 首先使用结节初检网络检测候选结节, 然后利用假阳性降低网络对候选结节进一步分类, 获得最终结果。本文的主要贡献有: 1) CT 图像由连续的序列切片组成, 3D CNN 能更好地捕获 CT 序列图像的空间信息, 提取到更丰富的特征。因此, 设计两种 3D DCNN, 分别用于检测候选结节与去除假阳性结节。2) 通过将压缩激励单元 (Hu 等, 2020) 嵌入到多个感受野在同一粒度水平的多尺度 Res2Net (Gao 等, 2021) 网络模块, 创建了一种 3D 多尺度肺结节检测网络, 并引入融合多尺度特征的上下文增强模块和使网络更加关注感兴趣区域的空间注意力模块 (Qin 等, 2019), 提高检测性能。3) 基于多尺度 Res2Net 网络模块与压缩激励单元, 创建了一种 3D 假阳性降低网络, 将假阳性降低网络得到的预测概率与检测网络得到的预测概率加权平均, 得到最终结果。4) 在公共大型 LUNA16 数据集上进行验证, 实验结果表明: 所提出的方法与几种先进的网络相比具有一定的竞争力。此外, 进行了多种消融验证实验, 证明算法的有效性。

1 3D 多尺度肺结节检测网络

自动肺结节检测可以看做是一项输入为 CT 影

像 I , 输出为肺结节位置 $[x, y, z, d]$ 的目标检测任务。其中, x, y, z 表示肺结节立方体包围盒的中心坐标, d 表示肺结节的直径。实质上, 就是构造一个从 I 到 $[x, y, z, d]$ 的映射 F 。为了达到这一目标, 提

出一种 3D 多尺度肺结节检测网络, 如图 1 所示(图中, $\otimes$ 表示矩阵对应元素相乘)。该网络由基本模块 Bottle2SEneck 构成, 包括结节初检网络和假阳性降低网络两部分。




图1 3D多尺度肺结节检测网络结构

Fig. 1 3D multi-scale pulmonary nodule detection network structure

((a)nodule candidate detection network;(b>false positive reduction network)

1.1 Bottle2SEneck

Bottle2SEneck 由 Res2Net 网络模块与压缩激励单元组合而成, 模块结构如图 2 所示(图中, $\oplus$ 表示矩阵元素相加), 其中, $x_i, y_i (i = 1, 2, 3, 4)$ 表示拆分特征图, $3 \times 3 \times 3$ 表示卷积核大小为 $3 \times 3 \times 3$ 的卷积层, 每个卷积层后面都有一个批归一化层和一个 ReLU 层。

Bottle2SEneck 首先利用一组 $3 \times 3 \times 3$ 的滤波器从输入特征图 X 中提取特征, 并将输出特征图根据通道维度平均拆分为 4 个组, 在图 2 中表示为 x_1, x_2, x_3, x_4 (x_1, x_2, x_3, x_4 的空间尺寸相同)。然后

将特征图子集 x_i 与上一组滤波器 K_{i-1} 的输出 y_{i-1} 相加, 送入滤波器 K_i , 得到输出特征图 y_i , 具体为

$$y_i = \begin{cases} K_i x_i & i = 1 \\ K_i (y_{i-1} + x_i) & 2 \leq i \leq 3 \\ x_i & i = 4 \end{cases} \quad (1)$$

然后, 再将 y_1, y_2, y_3, y_4 在通道维度拼接起来。在 Bottle2SEneck 中, 不需对第 4 个分块进行卷积, 这可使特征得到重用; 使用多个卷积核大小为 $3 \times 3 \times 3$ 、通道数为 $C/4$ 的小滤波器替代一个卷积核大小为 $3 \times 3 \times 3$ 、通道数为 C 的大滤波器, 增加了每个输出特征图的感受野范围, 使网络能够充分提取全局




图2 Bottle2SEneck 结构

Fig. 2 The structure of Bottle2SEneck module

和局部特征,具有更强的多尺度表示能力,同时还能保持与大滤波器相似的计算负载。拆分和级联策略,有利于使卷积更有效地处理特征。

压缩激励单元结构如图3所示,由压缩和激励两个过程组成。压缩过程通过自适应平均池化来整合全局特征;激励过程通过全连接层 FC1—ReLU—全连接层 FC2—Sigmoid 结构实现,其中, r 是一个缩放参数,取值为 16。激励过程可根据压缩过程中汇聚的信息,全面捕获通道依赖性,使得含有丰富结节信息的通道权重高,不含有结节信息的通道权重小。最后,将激励过程产生的输出(每个通道的权重)与最初的输入中对应通道的特征图相乘,以强调肺结节的特征。

1.2 结节初检网络

1.2.1 网络结构

本文提出的用于在低剂量 CT 扫描中检测候选结节的初检网络,如图 1(a) 所示,采用区域推荐网络结构(Yuan 等, 2019; Tong 等, 2019; Yang 等, 2019),并根据检测任务的特点,将网络候选区域尺度设置为 5, 10, 20 三种。具体来说,该网络由骨干部分 Res2SENet 和检测部分两部分组成,输入是裁剪的 CT 图像立方体,维度(长 × 宽 × 高 × 通道数)为 $128 \times 128 \times 128 \times 1$ 。

骨干部分 Res2SENet 包括 5 个阶段,第 1 阶段




图3 压缩激励单元的结构

Fig. 3 The structure of squeeze-and-excitation unit

包括两个卷积层,第 2—5 阶段分别包括 1 个最大池化层和若干个 Bottle2SEneck 模块,具体模块个数如图 1(a) 所示。最大池化层用来下采样,减小特征图的尺寸。Bottle2SEneck 模块用来更改通道数,并不改变特征图尺寸。此处,用 c_i 表示阶段 i 的输出特征图。

由于特征金字塔网络(feature pyramid network, FPN)(Lin 等, 2017)结构涉及许多额外的卷积和检测分支,增加了计算成本并导致巨大的运行时间延迟。因此,在网络的检测部分,引入上下文增强模块(context enhancement module, CEM)和空间注意力模块(spatial attention module, SAM)。CEM 可聚合多尺度特征信息,增强特征的区别性。在 CEM 中,将 c_4 和 c_5 分别通过反卷积进行上采样得到的特征图与 c_3 在通道维度进行合并。与先前的 FPN 结构相比较,CEM 仅涉及 2 个反卷积层和 1 个特征图拼接操作,在保证网络效果的同时降低了计算成本。SAM 对从高层得到的特征图做 softmax,得到空间注意力图,并将此注意力图与低层特征图相乘,使得网络对感兴趣区域有更多的关注。在 SAM 后添加 2 个 Bottle2SEneck 模块,并设置丢弃(dropout)层(Lim, 2021)以防止过拟合现象发生。最后,将 dropout 层

的输出作为区域推荐网络的输入,区域推荐网络的输出包括候选结节包围盒中包含结节的概率 p 以及候选结节的空间信息,即坐标 (x,y,z) 和直径 d 。

1.2.2 损失函数

每个候选区域的二进制类标签根据其是否与目标结节的交并比(intersection over union, IoU)分配。如果 $\text{IoU} > 0.5$,则将该候选区域标记为正样本;如果 $\text{IoU} < 0.02$,则将该候选区域标记为负样本;其他既不属于正样本也不属于负样本的候选区域在训练过程中忽略。损失函数由分类损失和回归损失共同组成。对标记的每个候选结节,多任务损失函数定义为

$$L(p_i, t_i) = \lambda L_{\text{cls}}(p_i, p_i^*) + p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (2)$$

式中, λ 是权重参数,设置为0.5。 $L_{\text{cls}}(p_i, p_i^*)$ 是用二值交叉熵损失函数($\text{CrossEntropy}_{\text{binary}}$)计算的分类损失, $L_{\text{reg}}(t_i, t_i^*)$ 是用 smooth_{l_1} 损失函数计算的回归损失,分别定义为

$$L_{\text{cls}}(p_i, p_i^*) = p_i^* \log_2(p_i) + (1 - p_i^*) \log_2(1 - p_i) \quad (3)$$

$$L_{\text{reg}}(t_i, t_i^*) = \begin{cases} 0.5(t_i - t_i^*)^2 & |t_i - t_i^*| < 1 \\ |t_i - t_i^*| - 0.5 & \text{其他} \end{cases} \quad (4)$$

式中, p_i 和 p_i^* 分别表示候选区域的预测概率和分类标签。正样本的标签 $p_i^* = 1$,负样本的标签 $p_i^* = 0$ 。可以看出,只有标记 $p_i^* = 1$ 的正样本才考虑回归损失。 t_i 和 t_i^* 分别表示候选区域的预测相对坐标和回归标签,定义为

$$t_i = \left(\frac{x - x_\alpha}{d_\alpha}, \frac{y - y_\alpha}{d_\alpha}, \frac{z - z_\alpha}{d_\alpha}, \log_2\left(\frac{d}{d_\alpha}\right) \right) \quad (5)$$

$$t_i^* = \left(\frac{x^* - x_\alpha}{d_\alpha}, \frac{y^* - y_\alpha}{d_\alpha}, \frac{z^* - z_\alpha}{d_\alpha}, \log_2\left(\frac{d^*}{d_\alpha}\right) \right) \quad (6)$$

式中, (x,y,z,d) 为预测得到的结节在原始空间的坐标和尺寸, (x^*,y^*,z^*,d^*) 为真实结节在原始空间的坐标和尺寸, $(x_\alpha,y_\alpha,z_\alpha,d_\alpha)$ 为对应候选区域的坐标和尺寸。

1.3 假阳性降低网络

在结节初检阶段,通常会产生很多假阳性,为了从大量候选结节中准确区分真实结节,设计了一个3维深度卷积神经网络,对初检阶段产生的候选结节进一步分类以降低假阳性,网络结构如图1(b)所示。

该网络由5个阶段组成,将阶段 i 的输出特征图用 m_i 表示,则 m_i 的尺寸(长×宽×高×通道数)显示在图中阶段 i 的下方。在该网络中,使用卷积层和Bottle2SEneck模块更改通道数;使用最大池化层进行下采样,减小特征图的尺寸;使用dropout层避免过拟合;使用二值交叉熵损失函数进行优化。

2 实验

2.1 数据集

LUNA16数据集是最大的肺结节公开数据集LIDC-IDRI(lung image database consortium and image database resource initiative)(Armato III等,2011)的子集。LUNA16数据集从LIDC-IDRI数据集中剔除了切片厚度大于2.5 mm的CT图像,剩下的CT图像共888幅,切片厚度为0.6~2.5 mm,空间分辨率为0.46~0.98 mm,平均直径为8.3 mm。LUNA16数据集中结节的判定标准为4名放射科专家中至少3名认为该结节直径大于3 mm,该数据集中共注释了1 186个阳性结节。

2.2 预处理

对输入的CT影像采用自动预处理,具体步骤如下:

1)为便于神经网络从中抽取有效的图像特征,将肺结节可能出现的体素值范围从原来的 $[-1\ 200, 600]$ 归一化到 $[0, 1]$,具体为

$$\overline{val} = \begin{cases} 0 & val < -1\ 200 \\ \frac{val - (-1\ 200)}{600 - (-1\ 200)} & -1\ 200 \leq val \leq 600 \\ 1 & val > 600 \end{cases} \quad (7)$$

式中, val 表示变换前的CT值, $\overline{val}$ 表示变换后的CT值。

2)根据LUNA16数据集给出的原始CT肺实质区域分割文件,去除背景。

3)将CT图像 X 、 Y 、 Z 方向的像素间距统一为 $[1, 1, 1]$ mm。

4)根据CT肺实质区域自动截取肺结节感兴趣区域。

预处理前后的CT图像如图4所示。

2.3 实验过程

实验所用训练平台使用8块主频为2.20 GHz

的 Intel (R) Xeon (R) Silver 4210 CPU, 内存为 64 GB。所有实验均采用 2.2 节所述的预处理操作。所有网络模型使用 Python 2.7 搭建, 通过 Pytorch 并行计算框架在 2 块 NVIDIA GeForce RTX 2080Ti 显卡上进行加速。网络训练均使用随机梯度下降 (stochastic gradient descent, SGD) 优化方法, 其中, 初始学习率设置为 0.01, 动量参数设置为 0.9, 权重衰减设置为 0.000 1。对 LUNA16 数据集进行 10 折交叉验证。




图 4 预处理前后的 CT 图像

Fig. 4 CT images before and after preprocessing
(a) CT images before preprocessing;
(b) CT images after preprocessing)

在结节初检网络的训练阶段, 经预处理后, 通过随机旋转、翻转和比例在 0.75 ~ 1.25 之间的缩放进行数据增强, 并最终随机裁剪为 $128 \times 128 \times 128$ 像素尺寸的结节和非结节立方体输入到网络中进行训练。批处理大小设置为 8, 共训练 150 次, 每经过 50 次训练, 将学习率调整为原来的 1/10。在结节初检网络的测试阶段, 将预处理之后的 CT 图像分割成 $208 \times 208 \times 208$ 的小块作为网络输入, 相邻小块间重叠 32 个像素。对每个 CT 图像, 汇总所有小块得到候选结节, 并通过 IoU 阈值为 0.1 的非极大值抑制 (non-maximum suppression, NMS) (Rothe 等, 2015) 将重叠度较高的结节合并, 从而得到检测结果。

在假阳性降低网络的训练阶段, 由于结节初检网络的平均每例假阳性个数为 22, 为了平衡正负样本的数量, 对正样本进行 22 倍数据扩增, 扩增方法与结节初检网络中的数据增强方法一致。批处理大小设置为 128, 共训练 40 次, 在训练 10 次后, 将学习率设置为 0.001, 在训练 20 次后, 将学习率设置为 0.000 1。在假阳性降低网络的测试阶段, 将假阳性降低网络得到的预测概率与结节初检网络得到的

预测概率加权平均, 得到最后的分类结果, 计算为

$$p = \sum_{i=1}^2 \omega_i p_i \quad (8)$$

式中, ω_i 为网络预测概率 p_i 的权重, 将结节初检网络的预测概率所占权重设置为 0.2, 假阳性降低网络的预测概率所占权重设置为 0.8。

2.4 评价标准

将 FROC (free-response receiver operating characteristic curves) 曲线在 7 个不同误报数 (0.125, 0.25, 0.5, 1, 2, 4, 8) 下对应的敏感度 (sensitivity) 平均值作为算法性能的评价结果。敏感度计算为

$$S = \frac{TP}{TP + FN} \quad (9)$$

式中, TP 代表真阳性结节数量, 真阳性结节的判定标准是预测出的结节坐标位于真实结节半径范围内。 FN 代表假阴性结节数量, 假阴性结节即未检测出的真实结节。

2.5 实验结果

利用 FROC 曲线、平均敏感度、最高敏感度以及平均每例假阳性个数对结节初检网络和整个 3D 多尺度肺结节检测网络的性能进行评价。网络的 FROC 曲线如图 5 所示, 其中, 曲线是对真实预测值进行插值得到的。




图 5 网络的 FROC 曲线

Fig. 5 FROC curves

为了验证所提出的网络结构中 CEM、SAM 以及 Res2SENet 骨架网络的有效性, 在 LUNA16 数据集上, 对不同 3D 结节初检网络的平均敏感度、最高敏感度以及达到最高敏感度时的平均每例假阳性个数进行了相应的对比实验, 实验结果如表 1 所示。可以看出, 为了验证 CEM 的有效性, 在实验中分别用 FPN、CEM 与残差网络 (residual network, ResNet)

(Xie 等,2019)组合进行比较,实验结果表明,Res-Net 与 CEM 的组合比 ResNet 与 FPN 的组合最高敏感度低,但平均敏感度高,表明结构简单的 CEM 与 FPN 具有相当的性能。为了验证 SAM 的有效性,在 CEM 之后添加 SAM,实验结果表明,使用 SAM 的结节初检网络平均敏感度提高了 0.7%,最高敏感度提高了 2.5%,且平均每例假阳性个数约减少了 5 个,说明 SAM 能有效提升结节检测性能。为了验证 Res2SENet 骨架网络的性能,用 Res2SENet 替代 ResNet,与 CEM 和 SAM 进行组合,实验结果表明,使用 Res2SENet 为骨架网络的结节初检网络比使用 ResNet 为骨架网络的结节初检网络平均敏感度提高了 1.6%,且平均每例假阳性个数约减少了 4 个,证明了 Res2SENet 骨架网络的有效性。

表 1 不同 3D 结节初检网络性能比较
Table 1 Performance comparison of different
nodule candidate detection networks

网络模型	平均 敏感度	最高 敏感度	达到最高敏感度 时的平均每例 假阳性个数
ResNet + FPN	0.846	0.975	18
ResNet + CEM	0.849	0.958	31
ResNet + CEM + SAM	0.856	0.983	26
本文	0.872	0.983	22

注:加粗字体表示各列最优结果。

为了验证提出的整个肺结节检测网络的有效性,在 LUNA16 数据集中,将本文方法与现有主流方法在平均敏感度方面进行比较,结果如表 2 所示。可以看出,本文方法的平均敏感度为 0.923,高于现有主流方法,说明所提方法的优越性。

图 6 对检测结果进行了展示。但由于 CT 图像的 3 维特性,只能显示检测中心所在的横断面,又因为肺结节在横断面中相对较小,所以只截取以检测中心为中心,边长为 64 的正方形区域来进行可视化。其中,图 6(a)是检测到的真阳性结节(绿色圆圈),图 6(b)是检测到的假阳性结节(红色圆圈),具有与真阳性结节非常相似的特征,图 6(c)是未检测到的真实结节(黄色圆圈),即假阴性结节,基本尺寸极小,对其进行特殊的数据增强,可提高检测性能。本文方法不仅对实性结节检测效果良好,对磨玻璃结节的效果也很好。

表 2 整个肺结节检测网络性能比较
Table 2 Performance comparison of different
methods for pulmonary nodules detection

网络模型	平均敏感度
Khosravan 和 Bagci (2018)	0.897
Xie 等人(2019)	0.790
Wang 等人(2019)	0.903
Ding 等人(2017)	0.891
Pezeshk 等人(2019)	0.832 ± 0.011
Li 等人(2019)	0.912
本文	0.923

注:加粗字体表示最优结果。




图 6 检测结果

Fig. 6 Detection results((a) true positive nodules;
(b) false positive nodules;(c) false negative nodules)

3 结 论

本文提出一种基于深度卷积神经网络的 3D 多尺度肺结节检测方法,由结节初检和假阳性降低两个阶段组成。为了能够充分提取肺结节的多尺度特征,将 Res2Net 网络模块与压缩激励单元组合,搭建

结节初检网络和假阳性降低网络。此外,在结节初检网络中,为了融合深层次的语义信息与低层次的位置信息,提出一种结构简单但性能优异的上下文增强模块。同时,为了使网络对感兴趣区域有更多关注,在上下文增强模块之后引入了空间注意力模块。与现有主流肺结节检测方法相比,本文算法平均敏感度较高,假阳性较低,在胸部 CT 序列图像肺结节检测领域具有较高的实用价值。

由于提出的 3D 多尺度肺结节检测方法仍然存在少数尺寸极小结节漏诊情况,未来需对其进行进一步优化,以提高系统的检测性能。例如,对尺寸极小的结节进行特殊的数据增强。此外,该系统只能输出结节的位置信息,但在实际的肺癌筛查中,结节的生长部位、边缘形态及内部结构等都对临床诊断具有重要意义,今后可对结节的大小、类型和特征等进行分析,为后续工作提供建议。最后,实验是直接使用 LUNA16 数据集提供的肺实质区域分割文件去除背景,但对 CT 原图像,需要进行区域分割预处理才能得到。因此,未来还需对本文方法进一步完善,使其具有更强的实践意义。

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, Gupta S, Sallam M, Heath M D, Kuhn M H, Dharaia 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*, 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: A Cancer Journal for Clinicians*, 68 (6): 394-424 [DOI: 10.3322/caac.21492]
- 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: 559-567 [DOI: 10.1007/978-3-319-66179-7_64]
- 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]
- Gao S H, Cheng M M, Zhao K, Zhang X Y, Yang M H and Torr P. 2021. Res2Net: a new multi-scale backbone architecture. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 43 (2): 652-662 [DOI: 10.1109/TPAMI.2019.2938758]
- 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. Las Vegas, USA: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- Hu J, Shen L, Albanie S, Sun G and Wu E H. 2020. Squeeze-and-excitation networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42 (8): 2011-2023 [DOI: 10.1109/TPAMI.2019.2913372]
- Khosravan N and Bagci U. 2018. S4ND: single-shot single-scale lung nodule detection//Proceedings of the 21st International Conference on Medical Image Computing and Computer Assisted Intervention. Granada, Spain: Springer: 794-802 [DOI: 10.1007/978-3-030-00934-2_88]
- Li F, Huang H Y, Wu Y W, Cai C B, Huang Y and Ding X H. 2019. Lung nodule detection with a 3D ConvNet via IoU self-normalization and maxout unit//Proceedings of 2019 International Conference on Acoustics, Speech and Signal Processing. Brighton, UK: IEEE: 1214-1218 [DOI: 10.1109/ICASSP.2019.8683537]
- Lim H I. 2021. A study on dropout techniques to reduce overfitting in deep neural networks. *Lecture Notes in Electrical Engineering*, 716: 133-139 [DOI: 10.1007/978-981-15-9309-3_20]
- Lin T Y, Dollár P, Girshick R, He K M, Hariharan B and Belongie S. 2017. Feature pyramid networks for object detection//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 936-944 [DOI: 10.1109/CVPR.2017.106]
- Murphy A, Skalski M and Gaillard F. 2018. The utilisation of convolutional neural networks in detecting pulmonary nodules: a review. *The British Journal of Radiology*, 91 (1090): #20180028 [DOI: 10.1259/bjr.20180028]
- Pezeshk A, Hamidian S, Petrick N and Sahiner B. 2019. 3-D convolutional neural networks//Proceedings of the 20th International Conference on Medical Image Computing and Computer Assisted Intervention. Quebec City, Canada: Springer: 559-567 [DOI: 10.1007/978-3-319-66179-7_64]

- tional neural networks for automatic detection of pulmonary nodules in chest CT. *IEEE Journal of Biomedical and Health Informatics*, 23(5): 2080-2090 [DOI: 10.1109/JBHI.2018.2879449]
- Qin Z, Li Z M, Zhang Z N, Bao Y P, Yu G, Peng Y X and Sun J. 2019. ThunderNet: towards real-time generic object detection on mobile devices//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision*. Seoul, Korea (South): IEEE: 6717-6726 [DOI: 10.1109/ICCV.2019.00682]
- Ren S Q, He K M, Girshick R and Sun J. 2017. Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6): 1137-1149 [DOI: 10.1109/TPAMI.2016.2577031]
- Rothe R, Guillaumin M and Van Gool L. 2015. Non-maximum suppression for object detection by passing messages between windows//*Proceedings of the 12th Asian Conference on Computer Vision*. Singapore, Singapore: Springer: 290-306 [DOI: 10.1007/978-3-319-16865-4_19]
- 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, Kotov V, Lin J Y H, Manders J T M C, Sñora-Mengana A, García-Naranjo J, 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]
- 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]
- Szegedy C, Ioffe S, Vanhoucke V and Alemi A A. 2017. Inception-v4, inception-ResNet and the impact of residual connections on learning//*Proceedings of the 31st AAAI Conference on Artificial Intelligence*. San Francisco, USA: AAAI: 4278-4284
- Tong G F, Chen H R, Li Y, Du X C and Zhang Q C. 2019. Object detection for panoramic images based on MS-RPN structure in traffic road scenes. *IET Computer Vision*, 13(5): 500-506 [DOI: 10.1049/iet-cvi.2018.5304]
- Wang J, Wang J W, Wen Y F, Lu H B, Niu T Y, Pan J F and Qian D H. 2019. Pulmonary nodule detection in volumetric chest CT scans using CNNs-based nodule-size-adaptive detection and classification. *IEEE Access*, 7: 46033-46044 [DOI: 10.1109/ACCESS.2019.2908195]
- Wood D E, Kazerooni E A, Baum S L, Eapen G A, Ettinger D S, Hou L F, Jackman D M, Klippenstein D, Kumar R, Lackner R P, Leard L E, Lennes I T, Leung A N C, Makani S S, Massion P P, Mazzone P, Merritt R E, Meyers B F, Midthun D E, Pipavath S, Pratt C, Reddy C, Reid M E, Rotter A J, Sachs P B, Schabath M B, Schiebler M L, Tong B C, Travis W D, Wei B, Yang S C, Gregory K M and Hughes M. 2018. Lung cancer screening, version 3. 2018, NCCN clinical practice guidelines in oncology. *Journal of the National Comprehensive Cancer Network*, 16(4): 412-441 [DOI: 10.6004/jnccn.2018.0020]
- 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]
- Yang D M, Zou Y X, Zhang J and Li G. 2019. C-RPNs: promoting object detection in real world via a cascade structure of region proposal networks. *Neurocomputing*, 367: 20-30 [DOI: 10.1016/j.neucom.2019.08.016]
- Yuan J R, Xue B, Zhang W S, Xu L, Sun H Y and Zhou J H. 2019. RPN-FCN based rust detection on power equipment. *Procedia Computer Science*, 147: 349-353 [DOI: 10.1016/j.procs.2019.01.236]
- 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]

作者简介



孙华聪, 1995年生, 女, 硕士研究生, 主要研究方向为计算机视觉、深度学习。

E-mail: 1123541829@qq.com



彭延军, 通信作者, 男, 教授, 博士生导师, 主要研究方向为深度学习、图像处理、虚拟现实。

E-mail: pengyanjuncn@163.com

郭燕飞, 女, 博士研究生, 主要研究方向为医学影像处理、计算机视觉。E-mail: guo_1992_fei@163.com

张晓庆, 女, 讲师, 主要研究方向为医学影像处理、计算机视觉。E-mail: zxq801003@163.com