

基于3D ResUnet网络的肺结节分割

张倩雯¹, 陈明^{1,2}, 秦玉芳^{1,2}, 陈希¹

1. 上海海洋大学信息学院, 上海 201306; 2. 农业部渔业信息重点实验室, 上海 201306

【摘要】目的:将深度残差结构和U-Net网络结合形成新的网络ResUnet,并利用ResUnet深度学习网络结构对胸部CT影像进行图像分割以提取肺结节区域。**方法:**使用的CT影像数据来源于LUNA16数据集,首先对CT图像预处理提取出肺实质,然后对其截取立体图像块并进行数据增强来扩充样本数,形成相应的肺结节掩膜图像,最后将生成的样本输入到ResUnet模型中进行训练。**结果:**本研究模型最终的精度和召回率分别为35.02%和97.68%。**结论:**该模型能自动学习肺结节特征,为后续的肺癌自动诊断提供可靠基础,减少临床诊断的成本并节省医生诊断的时间。

【关键词】肺结节;分割;深度残差结构;召回率;ResUnet

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2019)11-1356-06

Lung nodule segmentation based on 3D ResUnet network

ZHANG Qianwen¹, CHEN Ming^{1,2}, QIN Yufang^{1,2}, CHEN Xi¹

1. College of Information Technology, Shanghai Ocean University, Shanghai 201306, China; 2. Key Laboratory of Fisheries Information, Ministry of Agriculture, Shanghai 201306, China

Abstract: Objective To propose a novel network ResUnet by combining deep residual structure with U-Net network, and to extract lung nodule region by segmenting the chest CT image with the use of ResUnet deep learning network structure. **Methods** The CT image data used in the study were derived from LUNA16 dataset. The lung parenchyma was firstly extracted from CT image preprocessing, and then, the stereo image block was intercepted and the simple size was expanded by data enhancement, thereby obtaining the corresponding lung nodule mask image. Finally, the obtained simple were imported into ResUnet model for training. **Results** The final accuracy and recall rate of the proposed model were 35.02% and 97.68%, respectively. **Conclusion** The proposed model can automatically learn the characteristics of pulmonary nodules and provide a reliable basis for the subsequent automatic diagnosis of lung cancer, thus reducing the cost of clinical diagnosis and shortening the time for diagnosis.

Keywords: pulmonary nodule; segmentation; deep residual structure; recall rate; ResUnet

前言

工业化水平的提高在改善人类生活质量的同时也带来了环境污染的问题^[1]。近几十年来,肺癌的发病率和死亡率在不断上升,同时,肺癌具有发病时间短、疾病致因复杂、转移速度快的特点,在发病早期大多数表现为肺结节,常常因为它不容易被察觉而耽误患者治疗的最佳时间。所以,及时发现并提早治疗可以大大增加患者的治愈率和生存几率^[2]。在

肺结节检测与识别中,候选结节提取检测是关键步骤^[3],候选结节提取检测的目的是从肺实质中定位结节所在的区域,由于肺结节与周围的血管、组织等在形态特征、像素值上相似度很高,特别是粘连型结节,这为研究带来了困难。Ko等^[4]提出多阶段阈值法来识别肺部边界,并评估肺内可能含有结节区域的形状、大小和位置。阈值法往往通过设置阈值来分成若干类,从而分离结节区域,这些区域通常会与肺部其他组织灰度重叠,导致分割效果不好。董林佳等^[5]通过构建类球形滤波器来提取疑似肺结节,从而滤除其他形状的区域,虽然形态学方法能有效提取结节,但是也会出现漏检、多检的情况。Kanazawa等^[6]提出一种基于聚类的方法来提取候选结节区域,同时减少假阳性,但是这种方法的计算量较大,检测效率低下。Lassen等^[7]使用区域生长法提取候选结

【收稿日期】2019-07-15

【基金项目】国家自然科学基金青年科学基金(61702325)

【作者简介】张倩雯,硕士研究生,研究方向:图像处理、深度学习,E-mail: 718905052@qq.com

【通信作者】陈明,博士,教授,研究方向:数据仓库与数据挖掘、嵌入式系统、传感器技术等,E-mail: mchen@shou.edu.cn

节,但是区域生长的起始种子点需要手工标注选取,基于传统方法的局限性,目前主要采用的方法是将传统的方法和机器学习的算法结合起来,或者采用基于深度学习的方法,如R-CNN系列^[8]、U-Net^[9]等,严忱君^[10]采用U-Net网络提取候选区域实现早期肺结节检测,并取得较好的效果。方俊炜^[11]将U-Net网络的输入改成3D图像来检测肺结节,最终达到预期效果。

随着深度学习兴起,深度卷积神经网络开始应用在医疗图像^[11-14]上,但由于深度学习模型依赖大量的样本量以及对计算机性能要求高,导致开发成本高,严重限制这一技术在肺结节检测与识别领域的应用,因此在这个过程中仍然存在着许多值得研究的地方。针对这一现象以及为了改善深度学习中梯度消失现象,本研究基于U-Net模型在医疗图像分割^[15]领域的表现,将U-Net网络和ResNet结合形成新的网络ResUnet,并将其应用在肺结节疑似区域提取中,并将输入扩展成3D,输出分割后的结节区域,有效地将非结节区域剔除,从而减少肺结节的假阳性,使之可用于后续的真假结节筛选。

1 肺结节分割方法

1.1 原始U-Net模型

与卷积神经网络相比,为了使获得的结果更好,在保留高级语义信息的同时使用低层次的信息是非常重要的^[16-18],但是当可用的数据集有限时,训练这样的深度神经网络是非常困难的。解决这一问题的一种常见的方法就是使用预先训练的网络,在目标数据集上对其进行微调;还有一种方法就是采用数据增强技术。此外,有些网络的架构本身也有助于减轻训练问题,U-Net就是基于全卷积神经网络的一个用于图像分割的经典网络,它是建立在全卷积神经网络架构上的,U-Net包括两部分,左侧的特征提取部分和右侧的上采样部分,网络结构左右对称,呈U形,网络结构如图1所示。

1.2 深度残差网络

在图像的分类和识别^[19]中,神经网络的深度对最后的效果有着很大的影响。因此,将网络设计得越来越深,随之带来的矛盾就是,随着网络加深,出现明显的梯度消失现象,网络的训练效果不佳,但是浅层的网络对效果提升又起不到明显的作用。为了解决这一问题,残差神经网络^[20]被提出,残差神经网络由一系列堆叠的残差单元组成。

假设神经网络的输入是 x ,输出是 $H(x)$,需要学习的函数为 $F(x) = H(x) - x$,即输出和输入的差,而

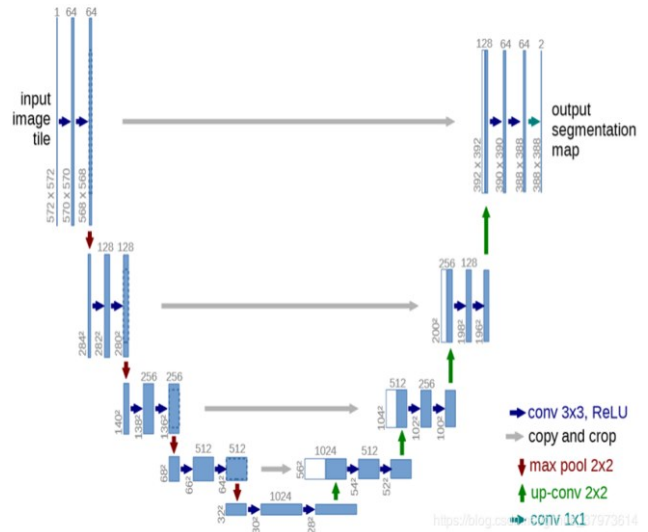


图1 U-Net网络结构图

Fig.1 Diagram of U-Net network structure

不再是 $H(x)$,这就是一个残差学习单元,此时通过在浅层网络的基础上增加一个 $y = x$ 即恒等映射来将原始函数转换 $F(x) + x$ 成的层被称为一个残差单元,如图2所示,而多个残差单元级联成一个神经网络。




图2 残差单元

Fig.2 Residual unit

因此网络中残差的表达式可以统一写成如下公式:

$$y = F(x, \{w_i\}) + w_s x \quad (1)$$

其中, w_s 只有在特征图维度不同的时候才用到,可以通过零填充增加维度,也可以通过 1×1 卷积实现。当残差用于两层全连接层的时候,其 $F = W_2 \sigma(W_1 x)$,网络单元如图3所示。

将两个 3×3 的卷积替换成了图3b的卷积层。首先在 1×1 卷积层下降维,然后在另一个 1×1 卷积层下还原,这能够起到调节维度的作用,从而令 3×3 卷积可以在较低维度的输入上进行,在非常深的网络中,该设计可大幅减少计算量。残差模块的引入有效缓解了梯度消失的影响,使得网络模型层数可以大大增加。

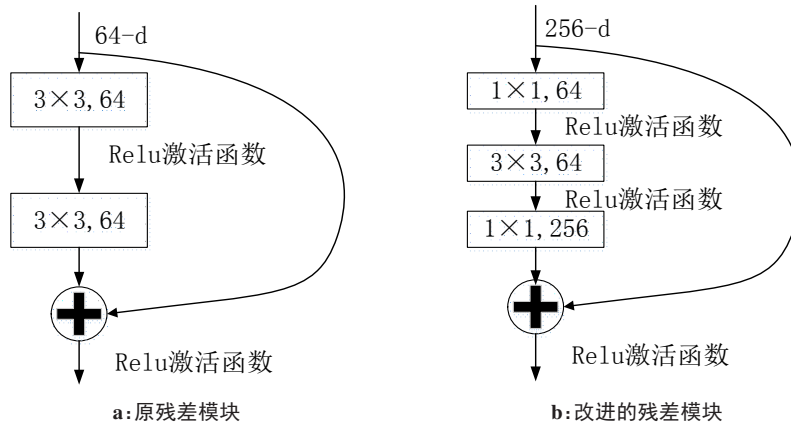


图3 两种残差模块
Fig.3 Two residual modules

1.3 3D 深度 ResUnet 网络模型

将 U-Net 网络和 ResNet 结合形成新的网络 ResUnet, 这充分结合了两个网络的优势: (1) 残差结

构会简化网络的训练; (2) 在残差单元内的跳跃连接以及网络的低层次和高层次之间将促进信息传播而不会出现梯度消失。图4为两种不同结构的比较。

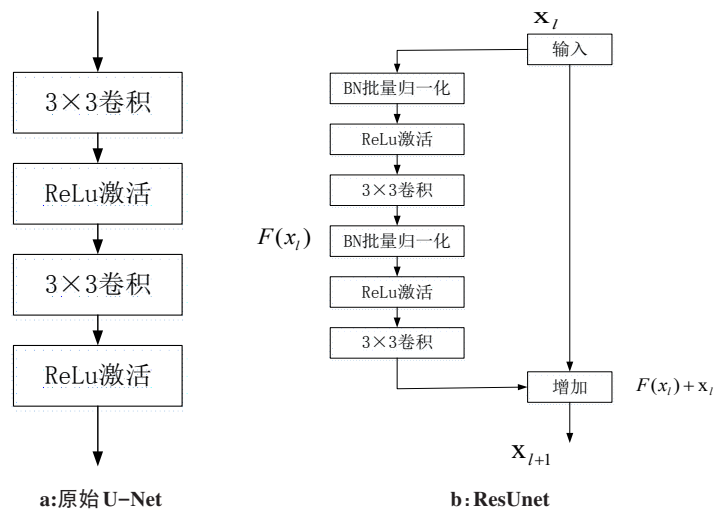


图4 原始 Unet 和 ResUnet 结构比较
Fig.4 Comparison of original U-Net and ResUnet structures

网络中每个残差单元可以表示为一般形式:

$$y_1 = h(x_1) + F(x_1, w_1) \tag{2}$$

$$x_{l+1} = f(y_1) \tag{3}$$

其中, x_l 和 x_{l+1} 是第 l 层残差单元的输入和输出; $F(\cdot)$ 是残差函数; $f(y_1)$ 是激活函数; $h(x_l)$ 是恒等映射函数, 最典型的是 $h(x_l) = x_l$ 。

整体网络如图5所示, 本研究将此网络扩展成3D网络, 利用深度7层网络架构进行肺结节区域提取, 该网络由编码、桥接、解码这3部分组成。编码部分包括将输入图像编码成更加严谨的表示; 桥接部分就像连接编码和解码的桥一样; 解码部分恢复成像素分类。所有这3部分都是由一个卷积块表示的,

包括输入、BN层、两个 3×3 的卷积、ReLU 激活层、恒等映射连接单元、输出。编码部分有3个残差单元, 在每个单元中对特征映射图进行下采样而不是池化操作, 第一个卷积块的大小将减少一半; 相应地, 解码部分也由3个残差单元组成, 在每个单元之前, 对来自较低级别的特征图进行上采样, 并使用相应编码路径的特征映射级联。在解码的最后一层, 使用 1×1 卷积和 Sigmoid 激活层将多通道特征图映射到所需要的分割中。与 U-Net 相比, ResUnet 总共只有15个卷积层并且删除了剪切。

此外, 损失函数用 `dice_coef_loss` 定义, 其中, 两个区域的相似程度用 DSC 表示, A 和 B 表示两个轮廓区域所包含的点的集合, 定义公式见式(4)。

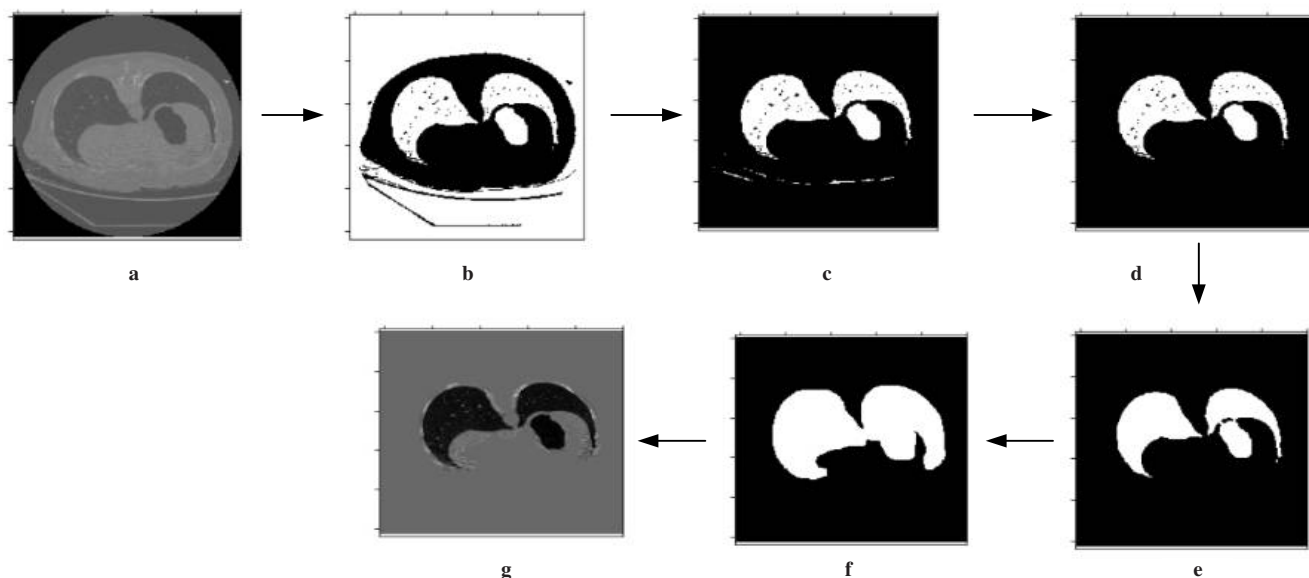


图7 图像预处理过程
Fig.7 Image preprocessing

似程度,从图中可以看出该模型能较好地预测到肺结节的位置。模型的损失函数如图9,在训练集上

loss 值能快速下降,但在验证集不稳定,主要原因是由于数据集有限,模型存在过拟合现象。




图8 本文分割结果图
Fig.8 Segmentation results obtained by the proposed method

左边的图表示输入的图片,中间的图是根据标注的文件生成的肺结节的掩膜,代表标签值,最右边的图是模型预测的结果

本研究提出的方法主要通过精度和召回率进行评估,将训练结果最好的模型作为最终的结果。精度指

的是在模型预测结节的所有结果中,预测正确的比例;召回率指的是真实值是肺结节的所有结果中,预测正




图9 3D ResUnet模型训练过程

Fig.9 3D ResUnet model training process

确的比例。严忧君^[10]采用二维 U-Net 原模型对肺结节进行分割并使用 VGG 算法识别,其中图 8 分割结果图中最左边的是输入的肺实质,中间的是标注的结节的位置,右边的是预测的结节图,可以看到预测图中有很多假阳性结节,最终得到 2.7% 的精度和 87.1% 的召回率,天池医疗大赛冠军组采用基于 3D U-Net 模型来进行肺结节的语义分割,获得 62.18% 的精度和 97.83% 的召回率。本研究采用基于 3D ResUnet 的肺结节分割方法,最终的精度和召回率分别为 35.02% 和 97.68%。该模型主要是为了将不属于肺结节的区域剔除,使得推荐的肺结节位置较少,同时召回率又保持较高。

3 结论

本研究将深度残差学习和 U-Net 网络结合,把 ResUnet 应用在肺结节图像语义分割中,并将输入扩展成 3D,通过对 CT 图像预处理提取出肺实质,对得到的图像以肺结节中心为坐标的区域附近截取立体图像块并进行数据增强生成 3D ResUnet 网络的输入样本,最后通过训练模型得到肺结节分割结果,本研究的方法具有较高的召回率,能有效将非结节区域剔除,为后面的真假阳性结节分类打下好的基础。

【参考文献】

[1] 杨承佳. 工业化进程、产业结构升级与环境污染的关系研究[D]. 郑州: 华北水利水电大学, 2017.
YANG C J. Research on the relationship between industrialization process, industrial structure upgrading and environmental pollution [D]. Zhengzhou: North China University of Water Resources and Hydropower, 2017.

[2] 邢召龙. 基于深度学习的肺癌检测模型[D]. 长春: 吉林大学, 2018.
XING Z L. Lung cancer detection model based on deep learning [D]. Changchun: Jilin University, 2018.

[3] 刘迪, 王艳娇, 徐慧. 基于深度学习的医学图像肺结节检测[J]. 微电子学与计算机, 2019, 36(5): 11-15.
LIU D, WANG Y J, XU H. Pulmonary nodule detection of medical image base on deep learning [J]. Microelectronics & Computer, 2019, 36(5): 11-15.

[4] KO J P, BETKE M. Chest CT: automated nodule detection and assessment of change over time-preliminary experience[J]. Radiology, 2001, 218(1): 267-273.

[5] 董林佳, 强彦. 基于三维形状指数的肺结节自动检测方法[J]. 计算机应用, 2017, 37(11): 3182-3187.
DONG L J, QIANG Y. Automatic detection method of pulmonary nodules based on three-dimensional shape index [J]. Journal of Computer Applications, 2017, 37(11): 3182-3187.

[6] KANAZAWA K, KAWATA Y, NIKI N, et al. Computer-aided diagnosis for pulmonary nodules based on helical CT images [J]. Comput Med Imaging Graph, 1998, 22(2): 157-167.

[7] LASSEN B C, JACOBS C, KUHNIGK J M, et al. Robust semi-automatic segmentation of pulmonary subsolid nodules in chest computed tomography scans[J]. Phys Med Biol, 2015, 60(3): 1307-1323.

[8] 唐思源, 杨敏, 白金牛. 基于深度卷积神经网络的肺结节检测与识别[J]. 科学技术与工程, 2019, 19(22): 241-248.
TANG S Y, YANG M, BAI J N. Lung nodules detection and recognition based on deep convolutional neural networks [J]. Science Technology and Engineering, 2019, 19(22): 241-248.

[9] 徐峰, 郑斌, 郭进祥, 等. 基于 U-Net 的结节分割方法[J]. 软件导刊, 2018, 17(8): 165-168.
XU F, ZHENG B, GUO J X, et al. Method of lung nodule segmentation based on U-Net [J]. Software Guide, 2018, 17(8): 165-168.

[10] 严忧君. 基于机器视觉的肺结节初筛算法研究与实现[D]. 杭州: 浙江大学, 2018.
YAN C J. Study and implementation of vision based pulmonary nodules filtering algorithm [D]. Hanzhou: Zhejiang University, 2018.

[11] 方俊炜. 基于深度学习的肺结节检测研究[D]. 广州: 广州大学, 2018.
FANG J W. Research on lung nodule detection based on deep learning [D]. Guangzhou: Guangzhou University, 2018.

[12] DOYLE S, AGNER S, MADABHUSHI A, et al. Automated grading of breast cancer histopathology using spectral clustering with textural and architectural image features [J]. Proceedings, 2015, 29: 496-499.

[13] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]// International Conference on Neural Information Processing Systems. Curran Associates Inc, 2012: 1097-1105.

[14] 王柯力, 袁红春. 基于迁移学习的水产动物图像识别方法[J]. 计算机应用, 2018, 38(5): 1304-1308.
WANG K L, YUAN H C. Aquatic animal image classification method based on transfer learning [J]. Journal of Computer Applications, 2018, 38(5): 1304-1308.

[15] 李昊轩. 基于深度学习的医疗图像分割[J]. 电子制作, 2019, 369(4): 55-57.
LI H X. Medical image segmentation based on deep learning [J]. Practical Electronics, 2019, 369(4): 55-57.

[16] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [C]// Medical Image Computing and Computer-Assisted Intervention, PT III, 9351, 2015.

[17] KAMNITSAS K, LEDIG C, NEWCOMBE V F, et al. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation [J]. Med Image Anal, 2017, 36: 61-78.

[18] GINNEKEN B V, SETIO A A, JACOBS C, et al. Off-the-shelf convolutional neural network features for pulmonary nodule detection in computed tomography scans [C]// IEEE International Symposium on Biomedical Imaging, 2015.

[19] 衣世东. 基于深度学习的图像识别算法研究[J]. 网络安全技术与应用, 2018, 1: 39-41.
YI S D. Research on image recognition algorithm based on deep learning [J]. Network Security Technology and Application, 2018, 1: 39-41.

[20] 王一宁, 秦品乐, 李传朋, 等. 基于残差神经网络的图像超分辨率改进算法[J]. 计算机应用, 2018, 38(1): 246-254.
WANG Y N, QIN P L, LI C P, et al. Improved image super-resolution algorithm based on residual neural network [J]. Journal of Computer Applications, 2018, 38(1): 246-254.

(编辑: 谭斯允)