

基于改进的VGG-16卷积神经网络的肺结节检测

曹宇¹, 邢素霞¹, 逢键梁², 王孝义¹, 王瑜¹, 潘子妍¹, 申楠¹

1. 北京工商大学计算机与信息工程学院, 北京 100048; 2. 空军特色医学中心, 北京 100048

【摘要】针对肺结节特征复杂、人工提取特征困难的问题,提出基于改进的VGG-16卷积神经网络的肺结节检测模型。首先采用阈值分割与处理最大连通区域后的图像进行掩模运算,得到肺实质部分。然后通过Regionprops标记每个连通区域序号分割出所有疑似结节;采用核函数极限学习机而不是Softmax函数作为VGG-16结构中的分类器。最后利用改进后的VGG-16模型去除假阳性结节,完成对肺结节检测。在LIDC-IDRI数据集上进行的实验表明改进后的模型能达到92.56%的准确率和94.44%的高敏感度。该模型可用于辅助医生进行肺结节诊断,具有一定的临床应用价值。

【关键词】肺结节;VGG-16;极限学习机;卷积神经网络

【中图分类号】R318;R563.9

【文献标志码】A

【文章编号】1005-202X(2020)07-0940-05

Detection of pulmonary nodules based on improved VGG-16 convolution neural network

CAO Yu¹, XING Suxia¹, PANG Jianliang², WANG Xiaoyi¹, WANG Yu¹, PAN Ziyang¹, SHEN Nan¹

1. School of Computer and Information Engineering, Beijing Technology and Business University, Beijing 100048, China; 2. Air Force Medical Center, Beijing 100048, China

Abstract: Aiming at the complex features of pulmonary nodules and the difficulties of extracting features manually, a pulmonary nodule detection model based on improved VGG-16 convolution neural network is proposed. Firstly, the lung parenchyma is obtained by threshold segmentation and mask operation after processing the image of the maximum connected area. Then, the serial number of each connected area is labeled by Regionprops for obtaining all suspected nodules. Kernel extreme learning machine instead of Softmax function is taken as classifier in VGG-16 architecture. Finally, the improved VGG-16 model is used to remove false positive nodules and complete the detection of pulmonary nodules. The proposed method is tested on LIDC-IDRI dataset, and the results showed that the improved model can achieve an accuracy of 92.56% and a sensitivity up to 94.44%. The proposed model can be used to assist doctors in the diagnosis of pulmonary nodules, and has a certain clinical value.

Keywords: pulmonary nodule; VGG-16; extreme learning machine; convolutional neural network

前言

目前肺癌是世界上发病率和死亡率最高的癌症之一,国家癌症中心发布的癌症报告显示,2015年肺癌的发病人数为73.3万,死亡人数接近61万,是致死率最高的恶性肿瘤^[1]。较早地发现癌症能够有效地提高生存率,英国癌症研究机构的研究数据显示,I期肺癌患者的5年生存率为87%,而IV期肺癌患者的5年生存率仅为19%^[2]。

肺结节是肺癌的早期表现形式,计算机断层扫描技术(Computed Tomography, CT)拥有较高的分辨

率 and 对比度,是检测早期肺癌的有效方法^[3]。然而,一例病例通常包含100~300张断层图像,并且胸腔内部环境复杂,肺结节可能分布在胸腔内不同的位置,仅靠医生的肉眼难以保证不会出现漏诊的情况。因此,有研究者提出计算机辅助检测系统,以辅助医生检测肺结节,减轻医生负担,提高准确率,并降低假阳性率^[4]。

国内外专家也提出了许多肺结节检测的算法,Gu等^[5]提出了多尺度肺结节预测策略,包括多尺度立方体预测和立方体聚类,从胸部CT扫描中分离肺部,采用多尺度预测的3D深度卷积神经网络(Convolutional Neural Network, CNN)检测肺部结节。Woźniak等^[6]通过计算原始图像的每个像素的局部方差来获得具有与原始图像相同大小的输出图像(方差图像),在方差图像中,找到局部最大值,然后通过使用原始图像中这些最大值的位置,发现肺组

【收稿日期】2020-02-20

【基金项目】首都卫生发展科研专项(首发2018-2-5122)

【作者简介】曹宇,硕士,研究方向:图像处理,E-mail:694750411@qq.com

【通信作者】邢素霞,博士,副教授,研究方向:图像处理,E-mail: xing-suxia@163.com

织中可能的结节的轮廓,从而定位和提取肺结节。Santos等^[7]使用高斯混合模型用于结节的区域分割,使用支持向量机(Support Vector Machine, SVM)、Tsallis熵和Shannon熵测量的假阳性更低。Xie等^[8]通过两个区域建议网络和一个反卷积层调整快速R-CNN的结构来检测结节候选,从而定位和提取肺结节。尽管已经提出了许多的肺结节检测的方法,但仍然没有达到临床应用的标准。为了更精确地检测出肺结节,本研究提出并使用改进的VGG-16模型对大量的CT切片数据进行训练,并建立一个预测模型来检测CT切片中是否含有肺结节,从而帮助医生有效提高诊断效率,并降低漏诊率、误诊率。

1 肺结节的检测

本研究对肺结节的检测主要分为3个步骤,分别为:肺实质的分割、候选结节提取、假阳性去除。




图1 肺实质分割实验结果
Fig.1 Experimental results of lung parenchyma segmentation

1.2 候选结节提取

在获得肺实质图像后,需要对感兴趣区域进行提取。肺结节通常表现为3~30 mm之间的肺内圆形或类圆形致密影,疑似结节的提取常用方法主要有阈值法、形态学方法、聚类法、区域生长法等。

本研究候选结节提取的步骤为:①用最大熵分割法完成肺实质内背景与目标的分离;②对感兴趣

1.1 肺实质的分割

在肺CT断层图像中,图像主要由空气、脏器、骨骼、肌肉和肺实质组成,其中肺结节仅存在于肺实质中。因此,为减少不必要的干扰和计算复杂度,在后续工作(如提取肺结节感兴趣区域)之前,需要从CT图像中分割出肺实质。肺实质分割是从CT图像中确定双肺边界,然后去除双肺边界的外部区域,以消除不相关的干扰,为准确提取肺结节的相关区域提供依据。

肺实质分割的详细步骤为:①通过全局自适应阈值法将已预处理的CT图像转换为二值图像;②选用最大连通分量法,将最大的连通区域视为肺部轮廓,再将肺实质内的较小黑色组织置为白色;③通过肺部轮廓得到初步的肺实质的掩模;④对肺部轮廓使用腐蚀膨胀操作,得到最终的肺部轮廓;⑤对肺实质掩模与最初已处理的CT图像做掩模运算,最终得到肺实质部分。肺实质提取具体步骤如图1所示。

区图像进行8连通域标记,采用Regionprops函数标记每个连通区域序号,将白色连通区域视为候选肺结节;③用标记的区域与原图像做相应的掩模运算,选肺结节的质心为中心点,切割出50×50的小块儿图像,并将其视为疑似结节区域,最后将所有的疑似结节区域均保存下来。候选结节提取实验过程如图2所示。




图2 结节提取
Fig.2 Nodule extraction

1.3 假阳性去除

假阳性去除即训练出一个能分类结节与非结节的模型,本研究使用VGG-16深度模型来对上一步提

取的候选结节提取深度特征,并使用极限学习机(Extreme Learning Machine, ELM)对提取的深度特征进行分类,最终完成肺结节检测的任务。

1.3.1 VGG-16卷积神经网络 2014年,牛津大学计算机视觉组和Google DeepMind公司研究员一起研发出VGG卷积神经网络^[9],该模型简单实用,成为当时最流行的卷积神经网络模型,并且该网络模型在图像分类和目标检测任务中都取得了很好的效果。而VGG-16的表现又尤为突出,张璟^[10]提出了使用深度可分离卷积模块,VGG-16模型在真实场景下的交通标志图像数据集GTSRB的识别准确率达98.38%;陈丹^[11]针对低分辨率车牌汉字符的结构退化导致的难以识别的问题,采用VGG-16提取车牌更具鲁棒性的深度特征,在汉字部分具有高达98%的识别准确率。故本研究选用VGG-16

卷积神经网络模型进行肺结节的检测任务。

VGG-16卷积神经网络模型由13个卷积层(被5个max-pooling层分割)和3个全连接层以及最后的Softmax分类层组成,网络宏架构图如图3所示^[12]。大部分卷积层采用3×3过滤器,小部分卷积层采用1×1过滤器,这样可在不影响输入输出特征维数的情况下对输入图像特征进行线性变换,然后进行非线性变换,以提高模型的非线性表达能力。池化层采用2×2过滤器,通过减少网络参数可以完成更多的非线性映射操作,从而提高模型的拟合能力。VGG-16的感受野为224×224,具有较好的执行效果。




图3 VGG-16卷积神经网络宏架构图

Fig.3 Macro-architecture of VGG-16 convolutional neural network

1.3.2 ELM ELM是一种单隐层前馈神经网络的学习算法,与传统的前馈神经网络相比,具有学习速度快、泛化性能好等优点。ELM算法随机生成输入层和隐层之间的连接权值和隐层神经元的阈值,在训练过程中,不需要调整,只需要设置隐藏层神经元的数量,即可得到唯一的最优解^[13]。

本研究提出一种改进的VGG-16模型,VGG-16模型通常由两部分组成,即VGG-16特征抽取器和SoftMax分类器。本研究采用核函数极限学习机(Kernel function Extreme Learning Machine, KELM)而不是Softmax函数作为VGG-16体系结构中的分类

器,以提高分类性能。因为KELM擅长以极快的速度逼近任何目标连续函数,但无法学习复杂的不变性。选择删去网络的最后一个1 000维的分类层,可以得到VGG-16的4 096维输出特征,这样保留的网络被视为特征提取器。并使用ELM来替代SoftMax分类器,对提取的深度特征进行分类。图4显示了改进的VGG-16网络架构图。

图5显示了ELM分类器的结构,假设输入 x 是选定特征的 $n \times d$ 矩阵, n 是样本数, d 是样本的维数, L 是隐藏节点数。隐层输入 $\omega_{d \times L}$ 的权重由概率分布随机产生。 $h(x) = [h_1(x), \dots, h_L(x)]$ 被称为ELM特

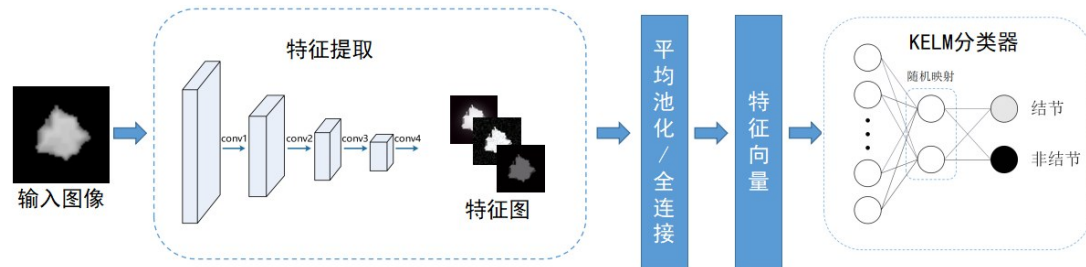


图4 改进VGG-16网络架构图

Fig.4 Improved VGG-16 network architecture

征映射,具有普遍的内部近似能力^[14]。对于每个 $h_i(x)$,可将其描述为:

$$h_i(x) = h(\omega_i x + b_i) \quad (1)$$

其中, b 是每个权重的偏差, h 是非线性分段连续函数。 $h_i(x)$ 由未知参数 $\beta = [\beta_1, \dots, \beta_L]$ 线性组合,以确定每类的目标函数:

$$f_L(x) = \sum_{i=1}^L \beta_i h(\omega_i, b_i, x) \quad (2)$$

对于每个类,计算出一个输出函数。可通过解决以下最小化问题来获得近似解:

$$\arg \min_{\beta} \|Y - H(x)\beta\|_2 \quad (3)$$

$H(x) = [h(x_1), \dots, h(x_n)]$ 是所有训练数据的 ELM 特征映射, Y 是训练数据的标签矩阵。式(3)为标准最小二乘问题,其解可用正交投影法求得:

$$\hat{\beta} = H^T (HH^T)^{-1} Y \quad (4)$$

$$\hat{\beta} = H^+ Y \quad (5)$$

在大多数情况下, HH^T 是非奇异的,因此式(4)可以转换为式(5)。 H^+ 是一个 Moore-Penrose 广义逆矩阵。 $\hat{\beta}$ 是 β 的计算值。

KELM 是一种采用内核函数作为 ELM 特征映射的 ELM 形式^[15]。采用 RBF 内核作为映射函数,由于 RBF 核函数可以将特征映射到有限维空间中,从而进一步增强特征分布的可分性。KELM 的特征映射可以用 $h(x) = [k(\mu_1, \sigma_1, \gamma, x), \dots, k(\mu_L, \sigma_L, \gamma, x)]$ 表示。函数 K 表示为:

$$K(\mu_i, \sigma_i, \gamma, x) = \exp\left(-\frac{\gamma \|x - \mu_i\|^2}{\sigma_i^2}\right) \quad (6)$$

其中, μ 是输入层到隐藏层的随机权重; σ^2 是 μ 的方差; γ 是决定径向尺寸的超参数。

可以用同样的方法,通过式(4)和式(5)求解参数 β 。只要得到 $\hat{\beta}$ 的值,就可以得到前馈预测结果 C :

$$C = H(x_{\text{test}}) \hat{\beta} \quad (7)$$

其中, C 是所有测试数据分类结果的输出矩阵。

2 实验结果与分析

本研究使用的服务器操作系统为 CentOS 7.4, GPU 显卡为 NVIDIA Titan Xp。以 LIDC-IDRI (Lung Image Database Consortium) 数据库为样本集^[16],对肺 CT 切片进行训练和测试。LIDC-IDRI 数据库是由美国国家癌症协会 (National Cancer Institute, NCI) 为早期癌症研究收集和发布的,是应用最广泛的肺 CT 图像数据库之一,包含 1 018 例患者的完整肺 CT 切片图像及其标记信息,包括肺结节的位置、大小和其他一些特征。




图5 ELM的结构

Fig.5 Structure of extreme learning machine

$\omega_{d \times L}$ 是由概率分布随机生成的, $\beta_{L \times k}$ 可以根据最小二乘法求解

实验使用从 200 个病人的 CT 图像中提取出的 1 500 张结节与 2 500 张非结节图像作为数据集进行训练和验证,训练集和测试集的比例为 7:3。图 6 展示了 VGG-16 模型改进前后的训练过程,可以看到本研究所采用的 VGG-16 卷积神经网络模型在 100 轮较小的迭代次数中很好地“学习”肺结节图像的特征,在训练集和验证集上分别达到了 95.91% 和 92.56% 的高准确率,比改进前的准确率分别高了 1.38% 和 1.35%。

为进一步分析本文方法的检测性能,选取目前肺结节检测领域中较为常见的方法进行比较,进行准确率、敏感度、特异度的对比。

准确率 (Accuracy) 反映了在所有的检测结果中,检测正确的样本占全部样本的比值,定义为:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (8)$$

其中, TP 为真阳性、TN 为真阴性、FP 为假阳性、FN 为假阴性。

敏感度 (Sensitivity) 又称真阳性率,反映了对真实肺结节样本的检测性能,定义为:

$$\text{Sensitivity} = \frac{TP}{TP + FN} \times 100\% \quad (9)$$

特异度 (Specificity) 反映了对非肺结节样本的检测性能,定义为:

$$\text{Specificity} = \frac{TN}{TN + FP} \times 100\% \quad (10)$$

基于改进的 VGG-16 模型方法可达到 92.56% 的准确率、94.44% 的敏感度、90.44% 的特异度,准确率和敏感度指标均高于其他算法,特异度相对较低(表 1)。




图6 模型改进前后训练过程

Fig.6 Training process before and after model improvement

表1 本文算法与其他方法肺结节检出率比较(%)

Tab.1 Comparison of detection rate of pulmonary nodules between the proposed method and other methods (%)

方法	实验方法	准确率	敏感度	特异度
文献[17]	CNN	87.10	77.00	93.00
文献[18]	CNN+RF	91.80	88.70	92.40
文献[19]	VGG-16	89.30	92.53	-
文献[20]	VGG-16+SVM	87.20	88.20	-
本文方法	VGG-16+KELM	92.56	94.44	90.44

3 结 论

本研究将人工智能的思想应用到了医学辅助检测当中,提出了一种改进的VGG-16卷积神经网络进行肺结节检测实验,采用VGG-16深度模型提取深度特征,并采用KELM而不是Softmax函数作为VGG-16体系结构中的分类器,将改进前后的模型在数据集上进行对比实验,证明改进后模型的准确率有所提高。并与其他文献的对比发现本文模型在各项评价指标上基本优于其他模型,得到92.56%的准确率和94.44%的高敏感度,但特异性偏低,对非肺结节样本的检测能力还不算强,未来有待进一步研究,继续改进算法,提高各项评价指标,以实现在临床中的应用。

【参考文献】

[1] CHEN W, ZHENG R, BAADE P D, et al. Cancer statistics in China, 2015[J]. CA Cancer J Clin, 2016, 66(2): 115-132.

[2] TORRE L A, SIEGEL R L, JEMAL A. Lung cancer statistics[J]. Adv Exp Med Biol, 2015, 893: 1-19

[3] MEDEIROS A G, GUIMARÃES M T, PEIXOTO S A, et al. A new fast morphological geodesic active contour method for lung CT image segmentation[J]. Measurement, 2019, 148: 106687.

[4] KUHNIGK J M, DICKEN V, BORNEMANN L, et al. Morphological segmentation and partial volume analysis for volumetry of solid pulmonary lesions in thoracic CT scans[J]. IEEE Trans Med Imaging, 2006, 25(4): 417-434.

[5] GU Y, LU X Q, YANG L D, et al. Automatic lung nodule detection using a 3D deep convolutional neural network combined with a multi-scale prediction strategy in chest CTs[J]. Comput Biol Med, 2018,

103: 220-231.

[6] WOŹNIAK M, POŁAP D, CAPIZZI G, et al. Small lung nodules detection based on local variance analysis and probabilistic neural network[J]. Comput Methods Programs Biomed, 2018, 161: 173-180.

[7] SANTOS A M, DE CARVALHO FILHO A O, SILVA A C, et al. Automatic detection of small lung nodules in 3D CT data using Gaussian mixture models, Tsallis entropy and SVM[J]. Eng Appl Artif Intell, 2014, 36: 27-39.

[8] XIE H T, YANG D B, SUN N N, et al. Automated pulmonary nodule detection in CT images using deep convolutional neural networks[J]. Pattern Recognit, 2019, 85: 109-119.

[9] 高慧明. 基于卷积神经网络的肺结节检测及良恶性分类方法研究[D]. 太原: 太原理工大学, 2019.

GAO H M. Research on detection and benign and malignant classification method of pulmonary nodules based on convolutional neural network[D]. Taiyuan: Taiyuan University of Technology, 2019.

[10] 张璟. 基于改进卷积神经网络的交通标志牌识别研究[J]. 电脑知识与技术, 2019, 15(21): 195-197.

ZHANG J. Research on traffic signs recognition based on improved convolutional neural network [J]. Computer Knowledge and Technology, 2019, 15(21): 195-197.

[11] 陈丹. 低分辨率车牌识别算法研究[D]. 西安: 西安理工大学, 2019.

CHEN D. Research on low resolution license plate recognition algorithm[D]. Xi'an: Xi'an University of Technology, 2019.

[12] 李源熠. 基于深度学习的图片匹配算法实现[D]. 北京: 北京交通大学, 2018.

LI Y Y. Image matching algorithm based on deep learning[D]. Beijing: Beijing Jiaotong University, 2018.

[13] HUANG G B, CHEN L, SIEW C K. Universal approximation using incremental constructive feed forward networks with random hidden nodes[J]. IEEE Trans Neural Netw, 2006, 17(4): 879-892.

[14] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1-3): 489-501.

[15] HUANG G B. What are extreme learning machines? Filling the gap between Frank Rosenblatt's dream and John von Neumann's puzzle[J]. Cognit Comput, 2015, 7(3): 263-278.

[16] PEHRSON L M, NIELSEN M B, LAURIDSEN C A. Automatic pulmonary nodule detection applying deep learning or machine learning algorithms to the LIDC-IDRI database: a systematic review [J]. Diagnostics, 2019, 9(1): 29.

[17] SHEN W, ZHOU M, YANG F, et al. Multi-crop convolutional neural networks for lung nodule malignancy suspiciousness classification[J]. Pattern Recognit, 2017, 61(SI): 663-673.

[18] 林春伟. 基于卷积神经网络的肺结节检测方法研究[D]. 广州: 华南理工大学, 2017.

LIN C W. Research on pulmonary nodule detection based on convolutional neural networks [D]. Guangzhou: South China University of Technology, 2017.

[19] SHIN H C, ROTH H R, GAO M, et al. Three aspects on using convolutional neural networks for computer-aided detection in medical imaging[C]. Deep Learning and Convolutional Neural Networks for Medical Image Computing, Hawaii: IEEE Computer Society, 2017: 113-136.

[20] SHI Z H, HAO H, ZHAO M H, et al. A deep CNN based transfer learning method for false positive reduction[J]. Multimed Tools Appl, 2019, 78(1): 1017-1033.

(编辑:谭斯允)