

文章编号 1004-924X(2018)05-1211-08

基于三维卷积神经网络的低剂量 CT 肺结节检测

吕晓琪^{1,2}, 吴 凉^{1*}, 谷 宇^{1,2}, 张文莉¹, 李 菁¹

(1. 内蒙古科技大学 信息工程学院, 内蒙古 包头 014010;

2. 上海大学 计算机工程与科学学院, 上海 200444)

摘要:为提高早期肺癌筛查过程中肺结节的检出率,提出利用三维卷积神经网络进行低剂量 CT 肺结节检测。首先采用多方向形态学滤波算法对低剂量序列 CT 图像进行预处理;接着,利用改进三维区域生长与凸包算法相结合进行肺实质分割;然后提取三维候选结节,为了解决卷积神经网络对样本不平衡的敏感问题,对三维候选结节正样本进行旋转和光照处理;最后在不同的网络参数下,对 ELCAP 数据库中 50 个序列低剂量肺癌筛查数据进行 4 组实验。实验结果表明,通过对网络参数的不断优化,准确度、灵敏度、特异度以及 ROC 曲线的 AUC 值分别达到了 84.6%、88.89%、80.32% 及 0.924 4。该方法能够正确地对低剂量 CT 肺结节进行检测,与文献所提出肺结节检测算法相比,准确度、灵敏度和特异度分别平均提高了 5.37%、5.6% 和 10.42%,综合性能较强,可以为肺癌筛查提供有效的帮助。

关键词:肺癌筛查;3D 卷积神经网络;ELCAP;肺结节;平衡

中图分类号: TP391.4;R445.3 **文献标识码:** A **doi:** 10.3788/OPE.20182605.1211

Detection of low dose CT pulmonary nodules based on 3D convolution neural network

LÜ Xiao-qi^{1,2}, WU Liang^{1*}, GU Yu^{1,2}, ZHANG Wen-li¹, LI Jing¹

(1. School of Information Engineering,

Inner Mongolia University of Science and Technology, Baotou 014010, China;

2. School of Computer Engineering and Science, Shanghai University, Shanghai 200444, China)

* Corresponding author, E-mail: wol202305@126.com

Abstract: To improve the detection rate of pulmonary nodules in early lung cancer screening, a low-dose CT pulmonary nodule detection algorithm based on 3D convolution neural network was presented. First, the multi-directional morphological filtering algorithm was used to preprocess low-dose sequence CT image. The improved 3D region growth algorithm combined with the convex hull algorithm was used for lung parenchymal segmentation. Then the 3D candidate nodules were routed and illuminated in order to solve the convolution neural network on the sample imbalance sensitive issues. Finally, in situations of different network parameters, four groups of experiments were performed on the 50 sequences of low-dose lung cancer screening data in ELCAP database. The results showed that accuracy, sensitivity, specificity and ROC curve of the AUC values were 84.6%, 88.89%, 80.32% and 0.924 4 respectively by the constant optimization of

收稿日期:2017-09-04;修订日期:2017-11-06.

基金项目:国家自然科学基金资助项目(No. 61771266, 61179019);内蒙古自治区自然科学基金资助项目(No. 2015MS0604);内蒙古自治区高等学校科学研究项目(No. NJZY145);包头市科技计划项目(No. 2015C2006-14)

network parameters. The proposed algorithm can correctly detect low-dose lung nodules, with the accuracy, sensitivity, and specificity increased by 5.37%, 5.6% and 10.42%, respectively, which is more comprehensive and can provide effective help for lung cancer screening compared with conventional lung nodule detection algorithm.

Key words: lung cancer screening; three dimensional convolution neural network; ELCAP; lung nodule; imbalance

1 引言

肺癌是全球致死率最高的恶性肿瘤之一,是我国发病率最高的癌症,尽早发现可以显著提高病患的长期生存率^[1]。2011年美国国家肺癌筛查试验(National Lung Screening Trial, NLST)的研究结果显示,低剂量CT(Low-dose Computed Tomography, LDCT)可以明显降低肺癌高危人群约20%的死亡率,印证了LDCT在肺癌检出方面的巨大价值^[2]。

肺结节是肺癌在CT图像中最为常见的表现形式,对于肺癌的早期检测即为对肺结节的检测,因此,对肺结节的正确检测具有重要的临床意义^[3]。针对肺结节检测的传统方法有支持向量机(Support Vector Machine, SVM)分类器、模板匹配(Match Template)等。这些传统的肺结节检测方法,往往需要人为选定肺结节的某些特征(例如肺结节的几何特征、位置特征及纹理特征等等),然后根据这些特征编制算法来检测肺结节。但是人为选择的特征不具有代表性,因此在检测的过程中,一些不符合选定特征的肺结节就无法被检测出来,将会导致误诊,延误病情,甚至威胁病人的生命^[4]。

深度学习能够自动提取隐藏在数据间的多层特征表示,已经成功应用于语音识别、图像识别与分类分割等领域^[5]。从2015年开始,由深度学习原理开发的阿尔法围棋(AlphaGo)接连打败人类围棋高手,这引起了更多学者的关注。卷积神经网络(Convolutional Neural Network, CNN)是深度学习算法在图像处理领域的一个应用。近几年已经应用到计算机辅助诊断中,文献^[6]利用2D卷积神经网络进行肺结节检测,通过提取肺结节二维层面上的大量特征,进行训练,该方法肺结节的检测率达到了85.4%以上。文献^[7]利用2D

卷积神经网络,提取二维候选结节,对肺结节进行良恶性分类,正确率达到82.3%。上述方法主要针对常规剂量数据进行处理,图像分辨率较高,对比度比较明显,对肺结节的检测都得到了满意的结果。但是对于肺癌筛查的低剂量数据而言,由于进行低剂量扫描,导致数据中量子噪声增多,图像分辨率降低^[8]。利用上述方法处理可能会导致检出率下降。再者本质上,肺结节是以三维形式存在,上述方法未能充分地利用结节的三维空间信息。为了充分考虑量子噪声的影响以及肺结节三维空间信息,本文提出基于3D卷积神经网络的低剂量肺结节检测算法。

CNN采用了3种基本概念:局部感受野(Local Receptive Fields),共享权重(Shared Weights),和池化(Pooling)^[9]。局部感受野是CNN每一层输出的特征图(Feature Map)上的像素点在原始输入图像上映射的区域大小。由输入层到隐藏层的映射为一个特征映射,定义特征映射的权重即为共享权重。池化的作用主要是简化从卷积层输出的信息^[10]。

2 低剂量CT肺结节检测

本文算法主要分为3个步骤:肺实质分割、肺结节感兴趣区域(ROI)提取和肺结节检测。

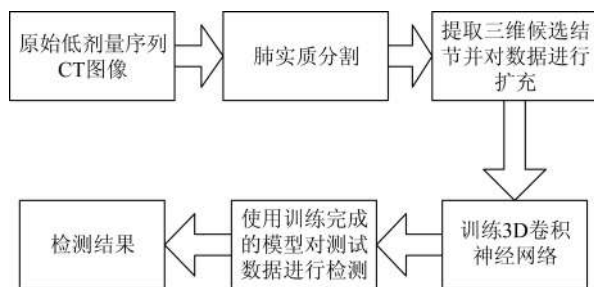


图1 检测流程图


Fig. 1 Process of detection

2.1 数据来源

数据来源于 ELCAP (International Early Lung Cancer Program, I-ELCAP) 公共肺部图像数据库(Public Lung Image Database)^[11]中 50 个低剂量肺癌筛查数据。在 50 组临床数据中,每一组都在 200 层以上,最少的 219 层,最多的达 304 层。管电流为 40 mA,每层数据均为 512×512 pixel,层厚 1.25 mm。1992 年 ELCAP(早期肺癌行动计划)诞生。1999 年,ELCAP 开始主办国际会议,在会议上,制定了允许国际合作并且数据并用的决议。作者声明实验所用数据没有利益冲突,并且是通过公开的肺部 CT 数据库进行实验,该数据库已经移除了病人的个人信息。


2.2 肺实质分割

由于肺结节只存在肺实质内部,为了减少肺实质外的干扰,需要将肺实质分割出来,利用多种方法结合对肺实质进行分割。CT 图像序列的预处理是后期分割、疑似病灶提取、病灶识别的重要前提^[12]。由于低剂量 CT 图像中的量子噪声近似服从泊松分布^[8]。本文选取长度为 3 的线性结构进行多方向形态学滤波处理。首先对图像的 $[0^\circ, 45^\circ, 90^\circ, 180^\circ]$ 4 个不同方向分别利用线性结构进行闭运算,取 4 个方向的最小值,对最小值的 4 个不同方向分别利用线性结构进行开运算,取其最大值即为预处理后的图像;然后利用 Otsu 法、flood-fill 算法去除背景,实现粗分割;接着利用引入霍夫变换的改进三维区域生长算法去除气管和支气管树;最后利用分水岭算法和二维凸包算法实现肺实质细分割(如图 2(b))。



(a) 单层低剂量扫描数据
(a) Single low dose scan data

(b) 肺实质
(b) Lung parenchymal



(c) 二维候选结节

(c) 2D candidate nodes

图 2 候选结节提取图

Fig. 2 Extraction of candidate nodes

2.3 肺结节感兴趣区域(ROI)提取

首先对肺实质区域进行二值化,为了防止漏掉受噪声影响的肺结节,利用阈值法进行二值化,经过大量实验阈值设置在 0.4~0.55 区间可以保证真结节全部在预选范围内;然后利用几何特征(面积、体积、最长直径)提取候选结节;最后利用公式(1)提取三维候选结节(如图 2(c))。

$$\hat{v} = V(x-16 : x+15, y-16 : y+15, z-4 : z+3), \quad (1)$$

其中: \hat{v} 为提取的三维候选结节, V 为肺实质灰度数据, (x, y, z) 为候选结节质心坐标。

对 ELCAP 数据库 50 个低剂量 CT 肺部序列进行处理,提取 2 488 个(其中真结节 435 个,非结节 2 053 个)候选结节。数据库中真结节标记由放射科医生提供^[11]。将前 40 序列作为训练集,其余的为测试集。所取 2 488 个 ROI 中,真结节与非结节比例为 1 : 7.21,卷积神经网络对于不平衡数据非常敏感,为此对数据集进行扩充。由于 CNN 对几何变换、形变及光照具有一定程度的不变性。因此对真结节进行旋转 $90^\circ, 180^\circ$ 和 270° 、光照处理,最终得到训练集 3 476 个(真结节 1 738,非结节 1 738),测试集 630 个(真结节 315、非结节 315)。

2.4 3D CNN 网络搭建

3D CNN 的基本网络结构和 2D CNN 类似,由输入层、卷积层、池化层、全连接层和输出层组成;卷积层和池化层交替设置;全连接层设置在输出层之前。只不过 3D CNN 的卷积层和池化层的输入与输出都是三维的特征体。




图 3 3D CNN 结构图

Fig. 3 Structure of 3D CNN

2.4.1 3D 卷积层

在卷积层,前一层的输出特征图 (Feature map) 与一个可学习的卷积核进行卷积运算,然后通过激活函数 (Activation function), 就可以得到输出特征图。常用的激活函数有 ReLU、Leaky ReLU、Parametric ReLU、Randomized ReLU 等。

为构建 3D 卷积层,首选确定每一个卷积层的 3D 卷积核,抽取堆叠的高层次特征。为了生成新的特征空间,本文在每一个卷积层使用了不同的 3D 卷积核。然后添加偏置项,使用非线性激活函数。

2.4.2 3D 最大池化层

池化 (Pooling) 是卷积神经网络中一个重要操作,它能够在减少特征的同时保证特征的局部不变性,常见的池化操作有:最大池化 (Max pooling)、平均池化 (Mean pooling)。假设 l 层为卷积层, $l+1$ 层则为 3D 池化层。该层的输入为上一层卷积层输出的特征图, $T = [h_1^l, h_2^l, h_3^l, \dots, h_k^l] \in R^{X \times Y \times Z \times K}$ 对于最大池化层操作,它选取立方体内最大值,并生成抽象输出 $T' \in R^{X' \times Y' \times Z' \times K}$, 其中 (X, Y, Z) 和 (X', Y', Z') 分别是最大池化特征抽取前后的尺寸。 K 为特征空间数目。通过池化层后,特征空间将会减少到 $X' = (X - M/S + 1)$ 。

2.4.3 全连接层

全连接层中,每个神经元与邻接层所有的神经元相连。在全连接层之前,首先要将特征空间压平到一个神经元向量,接下来执行向量-矩阵乘法,再加上偏置项以及应用非线性激活函数^[13]。

2.4.4 Softmax 层

Softmax 层就是 3D CNN 的输出层。 h^l 代

表最后一层的神经元向量, C 为目标分类数。通过 Softmax 回归 $p_c(h^l) = \exp(h_c^l) / \sum_c \exp(h_c^l)$ 计算每个分类 c 的概率,其中 h_c^l 是神经元向量的第 c 个元素。Softmax 层的激励函数输出为 $(0, 1)$ 之间的正值,且和为 1^[13]。

2.4.5 权值函数

对于给定的 N 对 3D 训练样本集合 $(I^{(1)}, y^{(1)}), \dots, (I^{(N)}, y^{(N)})$, 其中 $I^{(j)}$ 是输入立方块, $y^{(j)}$ 为对应的真实标签, $\hat{y}^{(j)}$ 为预测标签, θ 代表所有参数。权值函数如下:

$$l(\theta) = -\frac{1}{N} \sum_{j=1}^N \sum_{c=0}^{C-1} \text{indicator}\{y^{(j)} = c\} \log P(\hat{y}^{(j)} = c | I^{(j)}; \theta), \quad (2)$$

其中 indicator 代表指示函数, $P(\hat{y}^{(j)} = c | I^{(j)}; \theta)$ 为样本 $I^{(j)}$ 属于类别 c 的预估概率。通过调整参数使 $l(\theta)$ 最小。

2.4.6 训练过程

权重 θ 根据随机梯度的下降来学习,即每次迭代中参数更新都是根据每次试验的训练样本。网络初始学习率设置为 0.000 1,随着迭代次数的增加,平均每迭代 700 次,学习率衰减 50%。由于实验样本较少,为了防止过拟合,实验引入 dropout 应用到卷积层和全连接层为 0.8^[14]。分别对平衡数据和不平衡数据进行实验,其中不平衡数据进行 3 组实验;平衡数据 8 组实验。

3 实验与结果分析

3.1 网络评估指标

利用准确度 (Accuracy)、灵敏度 (Sensitivity) 和

特异度(Specificity)对网络进行评价。当某类样本很少时,即使在检测过程中,将所有的样本都归于样本多的一类,同样准确度也会很高。因此本文对不平衡数据集做实验时,又引入召回率(Recall)、精确率(Precision)、G-mean 和 F-score 来针对不平衡数据集的实验进行评估^[15]。

在评价医学影像检测方法过程中,通常还使用 ROC(Receive Operating Characteristic,受试者工作特征)曲线来更加全面地评估算法的性能。ROC 曲线下方的面积记为 AUC,AUC 越接近于 1 分类器效果越好。

3.2 实验

首先对不平衡数据进行实验,了解不平衡数据对卷积神经网络的影响;然后从卷积层数、特征图、卷积核大小 3 个方面进行实验,了解这 3 个因素对于卷积神经网络检测肺结节的影响。实验一,对不平衡数据更改卷积层层数进行实验,网络参数如表 1;对平衡数据调整卷积层数、特征图、卷积核大小 3 个条件,网络参数如表 2~3 所示。

表 1 实验一网络参数

Tab. 1 Network parameter of test one

	Test1-1	Test1-2	Test1-3
C1(FM)	12	12	12
C1(kernel)	(5,5,3)	(5,5,3)	(5,5,3)
C2(FM)	无	24	24
C2(kernel)	无	9	9
C3(FM)	无	无	48
C3(kernel)	无	无	1
FC	128	128	128

表 2 实验二网络参数

Tab. 2 Network parameter of test two

	Test2-1	Test2-2	Test2-3	Test2-4
C 层数	2	3	4	5
M 层数	2	3	4	5
FC 层数	128	128	128	128
Softmax 层数	1	1	1	1

表 3 实验三、实验四网络参数

Tab. 3 Network parameter of test three and four

	Test3		Test4	
	Test3-1	Test3-2	Test4-1	Test4-2
C1(FM)	24	24	24	24
C1(kernel)	(5,5,3)	(5,5,3)	(7,7,3)	(7,7,3)
C2(FM)	24	24	24	24
C2(kernel)	9	9	5	5
C3(FM)	无	48	无	48
C3(kernel)	无	1	无	2

3.3 实验结果及分析

对实验一结果计算 Accuracy、G-mean、Recall、Precision、F-score、AUC,结果如表 4;对其余实验计算每组实验的 Accuracy、Sensitivity、Specificity、AUC,结果如表 5。

表 4 实验一结果

Tab. 4 Result of test one

评价指标	Test1-1	Test1-2	Test1-3
Acc	0.862 7	0.894 6	0.850 5
G-mean	0.723 9	0.830 3	0.734 9
Recall	0.548 4	0.731 2	0.580 6
Precision	0.784 6	0.790 7	0.710 5
F-score	0.645 5	0.759 6	0.639 0
AUC	0.843 4	0.902 3	0.834 2

表 5 实验二~实验四结果

Tab. 5 Result of test two, three and four

实验次数	Acc	Sen	Spe	AUC	
Test2	Test2-1	0.795 2	0.822 2	0.769 3	0.907 4
	Test2-2	0.828 6	0.834 9	0.822 2	0.902 9
	Test2-3	0.781 0	0.882 5	0.679 4	0.880 8
	Test2-4	0.814 3	0.793 7	0.834 9	0.868 6
Test3	Test3-1	0.846 0	0.888 9	0.803 2	0.924 4
	Test3-2	0.746 0	0.958 7	0.533 3	0.865 1
Test4	Test4-1	0.815 9	0.860 3	0.771 4	0.902 8
	Test4-2	0.746 0	0.911 1	0.828 6	0.905 9

由实验一不平衡数据实验可以看出,随着卷积层数的增加,准确度基本维持在 85% 以上;但是由召回率和精准度可以看出,真结节检出率偏低,容易漏检;通过 G-mean 和 F-score 可以看出,数据不平衡导致网络综合能力不强,稳健性不高。说明卷积神经网络对于不平衡数据十分敏感。需要对数据进行扩充,使正负样本达到平衡。

实验二分别在卷积层层数为 2、3、4、5 时进行实验,由结果可知,随着卷积层数的增加,准确度和灵敏度先升高后降低(如图 4), ROC 曲线的 AUC 值呈下降趋势(如图 5)。

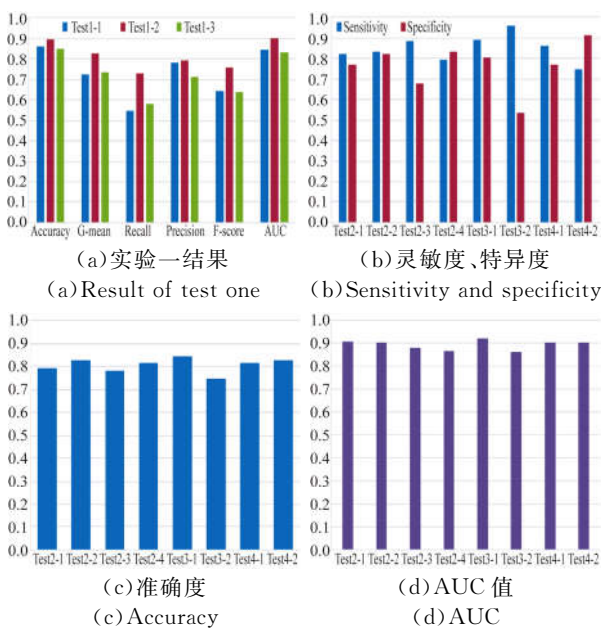


图 4 实验结果对比图

Fig. 4 Result of experimental contrast




图 5 ROC 曲线

Fig. 5 Curve of ROC

根据实验二的结果,对实验二中 1、2 组实验增加第一层卷积层的特征图(Feature map),由实验三对比结果,在卷积层为两层的时候,增加第一个卷积层的 Feature map,三项指标都相应的增加,在卷积层为三层的时候,增加第一个卷积层的 Feature map,虽然灵敏度显著上升,但是特异度急剧下降,很容易导致医生的误诊,将实验三第一组实验与实验二作对比,虽然特异度稍微下降,但准确度和灵敏度都显著上升,结节检出率能达到 88.89% (如图 4), ROC 曲线的 AUC 值达到 0.924 4(如图 5)。

根据实验三的结果,对实验三网络结构增大卷积层的卷积核,由实验四的结果可以看出,随着卷积核的增大,准确率下降,敏感度和特异度不稳定,综合以上实验可以看出在卷积层为两层,特征图为 24 时,能够达到最佳的检测结果(如图 4), 4 项指标分别为 84.6%、88.89%、80.32%、0.924 4。

为了验证算法的有效性,将本文算法的检测结果与国内外先进检测方法进行比较,实验对比结果如表 6 所示。

表 6 不同分类器的分类结果
Tab. 6 Result of different classifiers

数据库	分类器	Acc/%	Sen/%	Spe/%
文献[6]	LIDC 2DCNN	—	85.4	—
文献[7]	LIDC 2DCNN	82.3	79.4	83.8
文献[19]	LIDC 2DCNN	75.01	83.35	66.67
文献[16]	医院 SVM	71.67	73.33	70
文献[17]	ELCAP SVM	82	90.9	73.91
文献[18]	ELCAP 模板匹配	85.15	87.36	55.13
本文算法	ELCAP 3DCNN	84.6	88.89	80.32

文献[17-18]同样采用 ELCAP 数据库数据进行肺结节检测,文献[17]采用传统的 SVM 算法,由表 6,该算法的灵敏度略高于本文算法,但综合 3 项指标,本文算法明显优于 SVM 算法;文献[18]采用模板匹配算法,利用不同的模板对肺结节进行检测,表 6 数据为该文献中最优的一组,该算法准确度和灵敏度都在 85% 以上,但特异度仅 55.13%,极易造成误诊。

为了进一步说明本文算法的有效性,将本文

方法与文献[6,7,16,19]二维卷积神经网络检测算法以及SVM算法进行对比,文献[6,7,19]都是针对LIDC数据库中常规剂量数据处理。低剂量的ELCAP数据集存在大量的量子噪声,图像质量比常规剂量的LIDC数据集比较差。文献[16]采用的是哈尔滨医科大学附属肿瘤医院的临床常规扫描数据。由表6,综合3项指标,本文算法综合性能优于上述文献。

4 结 论

针对低剂量CT图像进行肺结节检测,本文利用3D卷积神经网络通过不断调整网络的参数进行实验。对ELCAP数据库中50例低剂量肺癌筛查数据进行处理,真结节检出率达到88.89%。该算法对于辅助医生诊断有一定的帮助,并具有一定的实际应用价值。

在卷积神经网络结构中,深度越深、特征面数目越多,则网络能够表示的特征空间也就越大、网

络学习能力也越强,但也会使网络的计算更复杂,极易出现过拟合的现象。由于本文选取的实验数据的限制,网络的深度没有进一步增加,根据现有的数据得出的结论网络深度的增加可能会对肺结节检测的正确度有一定的影响,但如果要增加网络深度,必须提供更多的训练样本以防止过度拟合^[5]。因而,在实际应用中应适当选取网络深度、特征面数目、卷积核的大小及卷积时滑动的步长,以便能够获得一个好的模型同时还能减少训练时间。

随着卷积神经网络由二维领域转向三维领域,越来越多的三维信息被应用到图像领域。目前深度学习仍有许多人类未知的潜能未被挖掘,本文主要针对卷积神经网络的深度、卷积核大小、Feature map进行实验,得到了良好的效果。但网络结构以及参数的优化仍有很多方面值得我们继续研究探讨。随着大规模图像数据的产生以及计算机硬件,特别是GPU的飞速发展,卷积神经网络及其改进方法一直在不断地发展^[20]。

参考文献:

- [1] YPSILANTIS P, MONTANA G. Recurrent convolutional networks for pulmonary nodule detection in CT imaging [J]. arXiv:1609.09143, 2016.
- [2] National Lung Screening Trial Research Team, ABERLE D R, ADAMS A M, *et al.*. Reduced lung-cancer mortality with low-dose computed tomographic screening [J]. *The New England Journal of Medicine*, 2011, 365(5): 395-409.
- [3] DECARVALHO FILHO A O, SILVA A C, DE PAIVA A C, *et al.*. 3D shape analysis to reduce false positives for lung nodule detection systems [J]. *Medical & Biological Engineering & Computing*, 2017, 55(8): 1199-1213.
- [4] 杨佳玲, 赵涓涓, 强彦, 等. 基于深度信念网络的肺结节良恶性分类 [J]. *科学技术与工程*, 2016, 16(32): 69-74.
YANG J L, ZHAO J J, QIANG Y, *et al.*. A classification method of pulmonary nodules based on deep belief network [J]. *Science Technology and Engineering*, 2016, 16(32): 69-74. (in Chinese)
- [5] 刘智, 黄江涛, 冯欣. 构建多尺度深度卷积神经网络行为识别模型 [J]. *光学精密工程*, 2017, 25(3): 799-805.
LIU ZH, HUANG J T, FENG X. Action recognition model construction based on multi-scale deep convolution neural network [J]. *Opt. Precision Eng.*, 2017, 25(3): 799-805. (in Chinese)
- [6] SETIO A A, CIOMPI F, LITJENS G, *et al.*. Pulmonary nodule detection in CT images; false positive reduction using multi-view convolutional networks [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(5): 1160-1169.
- [7] DA SILVAG L F, SILVA A C, DE PAIVA A C, *et al.*. Classification of malignancy of lung nodules in CT images using convolutional neural network [J]. *Workshop de Informática Médica*, 2016, 16: 2481-2489.
- [8] 张云逸. 低剂量CT图像的质量改善算法研究 [D]. 郑州: 郑州大学, 2015.
ZHANG Y Y. *Study of image quality improvement algorithm for low-dose CT* [D]. Zhengzhou: Zhengzhou University, 2015. (in Chinese)
- [9] 杜兰, 刘彬, 王燕, 等. 基于卷积神经网络的SAR图像目标检测算法 [J]. *电子与信息学报*, 2016, 38(12): 3018-3025.
DUL, LIU B, WANG Y, *et al.*. Target detection method based on convolutional neural network for SAR image [J]. *Journal of Electronics & Infor-*

- mation Technology, 2016, 38(12): 3018-3025. (in Chinese)
- [10] 熊昌镇, 单艳梅, 郭芬红. 结合主体检测的图像检索方法 [J]. 光学精密工程, 2017, 25(3): 792-798.
XIONG CH ZH, SHAN Y M, GUO F H. Image retrieval method based on image principal part detection [J]. *Opt. Precision Eng.*, 2017, 25(3): 792-798. (in Chinese)
- [11] ELCAP Public Lung Image Database [DB/OL]. <http://www.via.cornell.edu/databases/lungdb.html>.
- [12] 李勇, 苗壮, 王青竹. 纹理引导的稀疏张量表示及在肺 CT 图像中的应用 [J]. 光学精密工程, 2015, 23(2): 550-556.
LI Y, MIAO ZH, WANG Q ZH. Texture-guided sparse tensor representation and its application in lung CT images [J]. *Opt. Precision Eng.*, 2015, 23(2): 550-556. (in Chinese)
- [13] GLOROTX, BORDES A, BENGIO Y. Deep sparse rectifier neural networks [C]. *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics*, PMLR, 2012.
- [14] YANG H, YU H Y, WANG G. Deep learning for the classification of lung nodules [J]. arXiv:1611.06651, 2016.
- [15] DONG Y D, GUO H P, ZHI W M, *et al.*. Class imbalance oriented logistic regression [C]. *Proceedings of 2014 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery*, IEEE, 2014: 187-192.
- [16] 刘露, 刘宛予, 楚春雨, 等. 胸部 CT 图像中孤立性肺结节良恶性快速分类 [J]. 光学精密工程, 2009, 17(8): 2060-2068.
LIU L, LIU W Y, CHU CH Y, *et al.*. Fast classification of benign and malignant solitary pulmonary nodules in CT image [J]. *Opt. Precision Eng.*, 2009, 17(8): 2060-2068. (in Chinese)
- [17] OROZCO H M, VILLEGAS O O V, SÁNCHEZ V G C, *et al.*. Automated system for lung nodules classification based on wavelet feature descriptor and support vector machine [J]. *Biomedical Engineering Online*, 2015, 14: 9.
- [18] FARAGA A, ELHABIAN S Y, ELSHAZLY S A, *et al.*. Quantification of nodule detection in chest CT: a clinical investigation based on the ELCAP study [C]. *Proceedings of the 2nd International Workshop on Pulmonary Image Proceedings in Conjunction with MICCAI 2009*, MICCAI, 2009.
- [19] KUMAR D, WONG A, CLAUSID A. Lung nodule classification using deep features in CT images [C]. *Proceedings of the 12th Conference on Computer and Robot Vision*, IEEE, 2015: 133-138.
- [20] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络 [J]. 自动化学报, 2016, 42(9): 1300-1312.
CHANG L, DENG X M, ZHOUM Q, *et al.*. Convolutional neural networks in image understanding [J]. *Acta Automatica Sinica*, 2016, 42(9): 1300-1312. (in Chinese)

作者简介:



吕晓琪(1963—),男,内蒙古包头人,博士,教授,博士生导师,1984年于内蒙古大学获学士学位,1989年于西安交通大学获硕士学位,2003年于北京科技大学获博士学位,主要从事智能图像处理、医疗信息系统的构建与集成、电子病历及其数据挖掘方面的研究。
E-mail: lxiaoqi@imust.edu.cn



吴凉(1990—),男,山东聊城人,硕士研究生,2015年于泰山医学院获学士学位,主要从事 X 射线成像、模式识别、智能信息处理方面的研究。
E-mail: wl202305@126.com