

多输入卷积神经网络肺结节检测方法研究

赵鹏飞¹ 赵涓涓¹ 强彦¹ 王峰智² 赵文婷¹

(太原理工大学计算机科学与技术学院 太原 030024)¹

(山西省煤炭中心医院 PET/CT 中心 太原 030006)²

摘要 针对传统计算机辅助诊断系统中肺部结节检出过程复杂,检出结果依赖于分类前期每个步骤的性能,以及存在假阳性率高的问题,提出了一种基于卷积神经网络的端到端的肺结节检测方法。该方法首先使用大量带标签的肺结节数据对构建的多输入卷积神经网络进行训练,实现从原始数据到语义标签的有监督学习。然后采用快速边缘检测方法和二维高斯概率密度函数构建候选区域模板,从待检测 CT 序列中获取候选区域并将其作为多输入卷积神经网络的输入数据。最后采用判定阈值实现疑似肺结节区域标注,同时在相邻的 CT 影像中进行重点检测。在 LIDC-IDRI 数据集上的大量实验结果表明,所提方法在肺部 CT 影像中对微、小结节的检出率较高;同时,重点检测模板能够小幅降低微、小结节检测的假阳性率。

关键词 计算机辅助诊断,卷积神经网络,微小结节检测,LIDC-IDRI 数据集预处理

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.01.028

Study on Detection Method of Pulmonary Nodules with Multiple Input Convolution Neural Network

ZHAO Peng-fei¹ ZHAO Juan-juan¹ QIANG Yan¹ WANG Feng-zhi² ZHAO Wen-ting¹

(College of Computer Science and Technology, Taiyuan University of Technology, Taiyuan 030024, China)¹

(PET/CT Center of Shanxi Coal Central Hospital, Taiyuan 030006, China)²

Abstract In view of that the detection process of pulmonary nodules in traditional computer-aided diagnosis system is complex, the detection results depend on the performance of each step in the early stage of classification, and there is a problem of high false positive rate, this paper presented an end-to-end detection method of pulmonary nodules based on convolution neural network. First, it uses a large number of tagged pulmonary nodule data to input the newly constructed multi-input convolution neural network for training, realizing the supervised learning from the raw data to the semantic label. Then, it uses the fast edge detection method and the two-dimensional Gaussian probability density function to construct the candidate region template, and the obtained candidate region from the CT sequence is used as the input data of the multi-input convolution neural network. Finally, it uses a diagnostic threshold to annotate the suspected pulmonary nodule region, which will be emphatically checked in the next frame. A large number of experimental results on LIDC-IDRI data set show that the detection rate of the small nodules in the lung CT image with the proposed method is high, and the candidate region template with key monitor can slightly reduce the false positive rate of the small nodules detection.

Keywords Computer-aided diagnosis, Convolution neural network, Pulmonary nodule detection, LIDC-IDRI dataset pre-processing

1 引言

肺癌是世界上发病率最高的肿瘤,也是中国发病率和死亡率居首位的肿瘤^[1]。近年来,随着医学影像手段的发展,肺部微、小结节的检出率逐渐提高。但是微、小结节的特征不明显,造成假阳性高、确诊困难等一系列问题^[2]。上海市胸科医院廖美琳教授在其专著《微·小结节》中称,通过对微、小结节

的诊断能够在早期发现恶性病变,给予及时手术是达到肺癌治愈的有效手段。

计算机辅助诊断方法在肺癌早期筛查中发挥着重要作用^[3]。Liu J K 等人^[3]将早期肺结节计算机辅助诊断过程分为 4 个步骤:肺实质分割、结节候选检测、特征提取和结节分类,这也是传统的计算机辅助诊断方法的步骤。Javaid M 研究小组^[4]使用直方图阈值选取方法和形态学运算分别进行血

到稿日期:2017-05-08 返修日期:2017-08-11 本文受国家自然科学基金(61373100),虚拟现实技术与系统国家重点实验室开放基金(BUAA-VR-16KF-13),虚拟现实技术与系统国家重点实验室开放基金(BUAA-VR-17KF-15),山西省回国留学人员科研资助项目(2016-038)资助。

赵鹏飞(1993-),男,硕士生,主要研究方向为深度学习、医学图像处理,E-mail:zh_juanjuan@126.com;赵涓涓 博士,教授,博士生导师,CCF 高级会员,主要研究方向为图像识别、深度学习、计算机辅助诊断等,E-mail:zh_juanjuan@126.com(通信作者);强彦 博士,教授,博士生导师,CCF 高级会员,主要研究方向为云计算技术、物联网技术、图像处理、大数据处理、数据库性能优化;王峰智 主要研究方向为神经系统的影像诊断、肿瘤的影像诊断和分子影像学诊断;赵文婷 博士生,主要研究方向为信息管理与管理信息系统。

管粘连和近胸膜结节检测与分割,并使用 SVM 进行结节类型分类。该方案对大结节分类的灵敏度明显高于微、小结节。Manikandan T 等人^[5]提取感兴趣区域的重心偏移和灰度特征进行基于形态学的目标检测,实验结果中假阳率为 0.38。以上算法多针对结节分类的前期过程,当前步骤的优劣依赖于前一步骤的结果;并且特征为手动设计,多针对小样本数据,无法全面表征医学图像中的病灶特征。

医学图像的爆发式增长以及大数据处理技术的成熟,为新时代下的智能医疗带来契机。Kumar 等人^[6]在大数据样本下使用 5 层自编码模型对包含结节的 CT 图像进行分类。近年来,有监督的卷积神经网络(Convolutional Neural Networks, CNN)在图像处理领域应用广泛。Sirinukunwattana 等人^[7]采用空间约束的 CNN 和在测试阶段中重叠贴片的融合方法,在组织病理图像中检测细胞核并分类。Nie D 等人^[8]使用 3D-CNN 技术对大脑多模态核磁影像中的脑灰质、脑白质和脑间质进行了分割。在肺部 CT 图像肺结节检测与分类中,Setio 等人^[9]构建了基于多视角卷积神经网络的肺结节辅助检查系统,使用肺结节 2D 多视角图像进行卷积特征提取和特征融合,最终完成肺结节检测任务。为获取 2D 的多视

角图像,在前期需要建立 3D 肺结节图像,该过程复杂并且受到三维重建过程中插值算法的影响。

深度学习方法将特征表示与目标识别进行联合训练,并以应用准确率作为评价标准来指导特征提取和分类,以减少中间层的数据误差,实现端到端的映射学习。本文提出一种基于卷积神经网络的肺部 CT 图像肺结节检测模型,通过使用卷积神经网络来充分利用 CT 原始数据及序列上下文信息。实验证明,所提方法能够提高肺部微、小结节的检出率,降低微、小结节的假阳率。

2 算法和方法框架

本文提出的基于卷积神经网络的肺部 CT 图像肺结节检测模型主要包括:1)根据先验知识分析提出基于二维高斯概率分布和边缘检测的候选区域选择模型;2)提取候选区域来构建灰度图层、CT 值图层以及灰度增强图层,并使用多输入卷积神经网络框架进行分类;3)根据分类结果对当前 CT 进行标注,并生成候选区域重点监控模板,以指导序列中下一帧图像候选区域的选择。模型框架如图 1 所示。

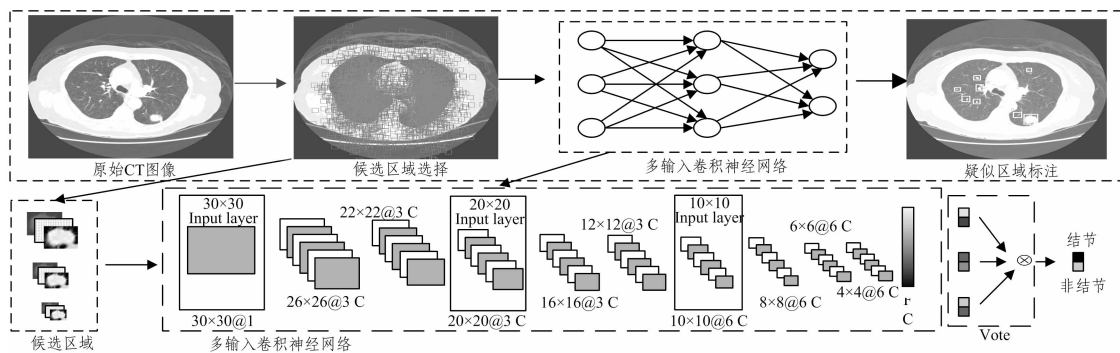


图 1 基于卷积神经网络的肺部 CT 图像肺结节检测模型

Fig. 1 Lung nodule detection model of lung CT image based on convolution neural network

2.1 数据预处理

图像感兴趣区域的纹理特征、轮廓特征等是目标识别与分类的主要依据。本文中 CT 灰度图像是检测模型的输入之一。同时,灰度增强图像是对目标的强调,即增强目标在背景中的对比度,突出目标特征。本文的另一数据源是原始 CT 值,计算机断层扫描图像中 CT 值表征人体组织对 X 射线的穿透能力,其范围依据辐射剂量强度略有不同,居于 -1000Hu 至 +1000Hu 的 2000 个分度之间^[10],密度高的组织穿透力弱,CT 值的分度范围使得不同组织的区别增大,更易于区分多种人体组织。分度范围大所带来的问题是无法直接进行图像表示,但其数据仍然具有使用价值,如图 2(b)所示。

本文使用肺部影像公开数据集 LIDC-IDRI,其中标注的肺结节大小范围为 3~30mm,像素级别的范围为 $6^2 \sim 60^2$ pixel,其中大于 30^2 pixel 的数量不足整体标注数量的 8%。为保证大规模数据下批量训练及数据的原始性,将图片调整为 10^2 pixel, 20^2 pixel, 30^2 pixel 3 个规模。对大于 30^2 pixel 的标注区域,采用双线性插值方法对图像进行调整,并设计多输入卷积神经网络。对于插值方法的选取,文中采用灰度图像信息熵^[11]来选取最优算法。灰度图像 I 的信息熵表达式为:

$$H = - \sum_{i=0}^{\max_{level}} p_i \log p_i \quad (1)$$

其中, p_i 表示像素值为 i 的像素点在图像中所占的概率值。通过比较最近邻插值算法、双线性插值算法、三次卷积插值算法,以图像信息熵差异最小和处理时间最短为衡量标准,最终选定双线性插值算法作为本文的图像插值算法。

2.2 多输入卷积神经网络

本文提出的多输入联合卷积神经网络肺结节图像分类框架将卷积神经网络的部分中间层作为输入层,从当前输入层向输出层传播并反向微调网络参数。多种规模数据的共同训练能够使得各个网络向最优方向靠近,对于整体网络性能具有提升效果。CT 值层数据范围大且存在负值,采用 PReLU




图 2 肺结节 CT 数据

Fig. 2 The pulmonary nodules in CT image

函数^[12]作为激活函数,使得神经元提取的特征范围更加广泛,其公式为:

$$PReLU(y_i) = \begin{cases} y_i, & \text{if } y_i > 0 \\ a_i y_i, & \text{if } y_i \leq 0 \end{cases} \quad (2)$$

其中, a_i 为惩罚因子,当 $a_i = 0$ 时,该函数退化为 ReLU 函数。

卷积神经网络中最为关键的两个步骤为降采样操作和卷积操作。降采样操作的主要功能是减少计算参数数目;卷积操作则通过局部感受野提取旋转不变和平移不变的局部特征。本文采用全卷积神经网络。由于输入图像的规模较小,同时为适应多种规模输入,设计的多输入网络各层参数如表 1 所列。

表 1 多输入卷积神经网络参数

Table 1 The parameters of multi-input convolution neural network

layer	输入数量	各层参数设置	输出大小
Input	1		30^2
Conv1	1	$5^2, 3, PReLU$	26^2
Conv2	3	$5^2, 3, PReLU$	22^2
Conv3	3	$5^2, 3, PReLU$	20^2
Conv4	3	$5^2, 3, PReLU$	16^2
Conv5	3	$5^2, 3, PReLU$	12^2
Conv6	6	$3^2, 6, PReLU$	10^2
Conv7	6	$3^2, 6, PReLU$	8^2
Conv8	6	$3^2, 6, PReLU$	6^2
Conv9	6	$3^2, 6, PReLU$	4^2
FC	6	sigmoid	64×1

设第 n 个卷积层的输入为 $(x_{(n-1,1)}, x_{(n-1,2)}, x_{(n-1,3)}, \dots, x_{(n-1,k)})$, 则该层第 j 个输出为:

$$x_{(n,j)} = \max(0, \sum_{i=1}^k Conv(\omega_{(n,j)}, x_{(n-1,i)}) + b_n) + \delta \min(0, \sum_{i=1}^k Conv(\omega_{(n,j)}, x_{(n-1,i)}) + b_n) \quad (3)$$

其中, δ 为 PReLU 中的 a_i , Conv 为卷积操作, $\omega_{(n,j)}$ 为卷积核矩阵, b_n 为偏置。该表达式为网络中卷积层激活函数与卷积操作的复合公式,在全连接层至输出层采用 sigmoid 函数作为激活函数,产生一个 0~1 之间的非线性输出。

使用分类均方误差梯度反向传播算法微调多输入卷积神经网络,同时微调激活函数 PReLU,按照动量函数对参数 a_i 进行微调。

$$\Delta a_i = \mu \Delta a_i + \xi \frac{\partial \epsilon}{\partial a_i} \quad (4)$$

其中, μ 为动量因子, ξ 为学习率。传统的激活函数均采用固定参数的函数,如 Sigmoid, tanh 函数等。同时,在网络初始化参数时采用 MSRA 方法^[12],即:均值为 0、方差为 $\sqrt{2/n}$ 的高斯函数,其中 n 表示输入神经单元的个数,即卷积核参数的个数。

假设有使用图像组 $(X1, X2, X3)$ 分别代表待检测图像的灰度图层、CT 值图层和灰度增强图层。对于 3 个图层,分别采用独立同结构的卷积神经网络进行检测,则输出的 $(Y1, Y2, Y3)$ 通过投票机制产生最终的检测结果 Y ,如图 1 中 Vote 部分所示。

2.3 候选区域的选择

由先验知识可知:肺结节的位置在 CT 中具有规律,如胸膜牵拉型肺结节在肺实质边缘,同时肺结节的密度高,显

示为高亮区域^[13]。本文提出的候选区域选择使用边缘检测算法来检测肺结节易出现的位置,使用二维高斯函数概率阈值法进行肺实质部分疑似区域的随机检查,联合获取 2000 个候选点,并分别生成 3 种规模的候选区域。该方法对候选区域的选择具有针对性和随机性。采用二维高斯概率密度函数构建的肺实质区域随机获取模板的数学表达式为:

$$f(x, y) = \frac{e^{-\frac{1}{2(1-\rho^2)} \left[\frac{(x-\mu_1)^2}{\sigma_1^2} - 2\rho \frac{(x-\mu_1)(y-\mu_2)}{\sigma_1\sigma_2} + \frac{(y-\mu_2)^2}{\sigma_2^2} \right]}}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \quad (5)$$

其中, (x, y) 为 CT 图像中的坐标值, μ_1 和 μ_2 为期望值, σ_1 和 σ_2 为方差。实验中, $\mu_1 = 170, \mu_2 = 270, \sigma_1 = 40, \sigma_2 = 80$, 效果如图 3(b) 所示。

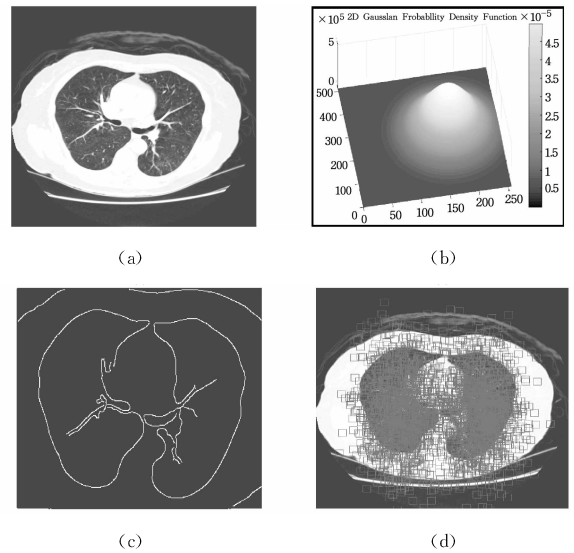


图 3 候选区域选择示意图

Fig. 3 Selection of candidate area

在序列 CT 图像检测中,为降低假阳率,利用上下文信息进行候选模板的补充。即将上一帧 CT 图像的最终检测结果中判定阈值大于 0.8 的疑似区域生成模板与当前帧的 canny 边缘检测和二维高斯概率密度函数构建的候选区域模板合并,作为当前帧的候选区域模板。

3 实验结果与分析

3.1 LIDC-IDRI 数据集

目前,肺部图像数据联盟 LIDC-IDRI 数据集是世界上最大的肺癌公开数据集,由美国于 2001 年 4 月发布,其已由最初的 68 例增长到如今的 1018 例(共计 375590 幅 CT 影像),并由 4 名放射科医师分别对图像进行标注,将结节外轮廓坐标以及结节的 8 种征象信息存放在 xml 文件中^[14]。LIDC 数据集的可读性较差,进行医学图像处理较为困难。为方便获取并查看数据集中的 CT 图像,在前期工作中进行 LIDC 数据库的数据可视化展示平台开发,如图 4 所示。该可视化平台以病例为单位进行显示,将标注的 xml 文件与 CT 图像比对,并在 CT 图像上标注结节的最小外接矩形,统计在单张切片中专家标注的总次数及标注位置的 8 种征象和恶性程度,同时将结节区域图像进行增强显示。




图 4 LIDC-IDRI 可视化展示平台

Fig. 4 Display platform of LIDC-IDRI

根据 Armato S 等人^[15]于 2010 年给出的 LIDC 数据集的统计报告,至少有一名放射科医师标注的结节共计 7371 个,其中直径大于 3mm 的结节共有 2669 个。Messay T 等人^[16]从 465 个 CT 序列中取得 4 名医师共同标注的 432 个结节进行分割实验。与上述统计方案不同,为实现大规模数据下的深度学习相关算法研究,尽可能对标注区域进行图像级别获取(同一结节在 CT 序列中可能存在 10~15 个标注区域),对 LIDC 数据集中 1010 例病例进行统计得到标注的 30008 个区域。其中,对大于 3mm 的结节进行征象的详细描述,结节区域占整体标注的 54.87%;而对小于或等于 3mm 的结节区域或者非结节区域则仅仅标注中心位置,其中结节区域占 15.34%,比例分布如图 5 所示。




图 5 LIDC-IDRI 标注比例分布图

Fig. 5 Proportional distribution chart of label in LIDC-IDRI

3.2 实验分析

本实验将预留 LIDC-IDRI 数据集中的 20 例作为测试集,并将其余的 990 例数据进行结节和非结节区域提取来构建训练集和验证集,其中训练集的数据量为 42304,验证集的数据量为 10330。为保证网络的有效性,在训练集及验证集中结节与非结节区域的数据量基本持平。

由实验结果可知,验证集上的错误率随训练批次的逐渐增加而降低,不同的学习率在本数据集上的收敛结果不同,学习率过小将导致实验结果收敛速度慢,而学习率过大则存在过训练现象,导致无法得到稳定的训练结果。因此经大量实验调整,对 3 个不同的网络设置不同的学习率,将输入数据大小为 30^2 , 20^2 和 10^2 的学习率分别设置为 0.4, 0.3 和 0.2。图 6 给出了输入数据大小为 10^2 pixel 时验证集错误率在不同学习率下随训练批次增加的折线图。




图 6 验证集上的错误率折线图

Fig. 6 Error rate in validation set

实验使用 ROC 曲线 (Receiver Operating Characteristic Curve)^[17]对网络检测性能进行评价。通过修改检测模型中的判定阈值得到多组假阳性率与灵敏度的对应曲线,将其与 LIDC-IDRI 中实际标注结果进行比对并绘制 ROC 曲线图,如图 7 所示。ROC 曲线图显示了 3 种分离网络与本文提出的多输入卷积神经网络的对比结果,本文提出的多输入卷积神经网络在假阳性率为 0.1 时达到 80% 的灵敏度,能够有效检测出肺部序列 CT 中疑似结节区域。分离的卷积神经网络在 30^2 规模时的效果最差,主要原因在于训练数据量少,待训练参数多。因此,训练数据量与待训练的网络参数数量可直接影响卷积神经网络的性能。




图 7 ROC 曲线图

Fig. 7 ROC curve

表 2 列出了使用多输入卷积神经网络对部分病例的检出结果。设定检测模型中判定阈值为 0.95。其中检出覆盖率是正确检出数量与数据集中肺结节数量的比值,检出正确率是正确检出数量与检出数量的比值。将其与文献^[3]和文献^[4]的方法进行对比可知,文献^[3]中检测方法的预处理步骤中使用的阈值分割方法难以检测出胸膜牵拉型结节,对微、小结节的检出率较低,但是 CT 图像中血管增强方法有效降低了假阳性;文献^[4]使用多张连续的 CT 序列进行结节检测,能够降低假阳性,在多个序列中具有稳定的检出覆盖率和检出正确率;多输入卷积神经网络表现出较高的检出率,检测微、小结节时具有较高的敏感性。在判定阈值为 0.95 时,本文方法的平均检出覆盖率达到 85.51%,检出正确率达到 78.4%。同时在肺结节较多的病例上,本文方法检出覆盖率和检出正确率都有较高的值,而对于较少的病例则性能不高;另外,多输入卷积神经网络对一张 CT 图像的检测时间为 17.49s,使用的操作系统环境为 Intel Core i7 CPU, 3.40GHz, Matlab R2014b,在性能提高之后能够适应临床实时的检测需求。

表2 部分实验结果(判定阈值为0.95)

Table 2 Some experimental results (Threshold=0.95)

病例编号	数据集中 大于 3mm 结节/ 小于或等于 3mm 结节	本文方法的 检出覆盖率/%	本文方法的 检出正确率/%	文献[3]的 检出覆盖率/%	文献[3]的 检出正确率/%	文献[4]的 检出覆盖率/%	文献[4]的 检出正确率/%
LIDC-IDRI-0990	8/1	88.89	53.34	77.78	60.00	77.78	54.54
LIDC-IDRI-0993	9/9	83.33	65.22	38.89	63.63	44.44	61.53
LIDC-IDRI-0996	6/1	85.71	30.00	57.14	50.00	71.43	62.50
LIDC-IDRI-0999	14/13	74.07	52.63	77.78	65.62	85.19	76.67
LIDC-IDRI-1001	6/4	80.00	53.33	60.00	46.15	70.00	63.63

另外,通过实验证明,对于基于序列 CT 的肺结节自动检测模型,添加上下文信息能够小幅降低结节检出假阳率,即将上一帧判定阈值大于 0.80 的候选区域传递至下一帧候选区域选择模型中,生成重点监测点。

结束语 本文从微、小结节诊断的必要性出发,分析了当前计算机辅助诊断方法的现状,比较了多种方法在微小结节检测方面的优势及不足,提出了一种基于卷积神经网络的肺部 CT 图像肺结节检测方法。该方法针对传统手工提取特征的不足,使用深度学习网络实现端到端的分类任务。本文利用边缘检测算法和二维高斯概率函数实现候选区域的选取,同时加入上一帧 CT 疑似区域位置并重点监测。采用 LIDC 数据集中的 20 例 CT 图像验证本文算法的性能。实验结果表明,基于卷积神经网络的肺部 CT 图像肺结节检测方法能够提高微、小结节的检出率,对肺结节的检测以及肺癌辅助诊断研究具有重要价值。

本文提出的多输入卷积神经网络肺部 CT 图像肺结节检测方法虽然在结节检出上具有较好的性能,同时相比于其他传统方法能够提高微、小结节的检出率,但是其假阳率较高,特别是对于噪声较高的 CT 图像,其他器官(如血管、各级支气管等)也会对检测造成影响。之后的工作将在多输入卷积神经网络中添加并行网络,去除其他正常组织的干扰,并且使用序列检测结果以降低假阳率。

参考文献

- [1] SIEGEL R L, et al. Cancer Statistics[J]. CA Cancer Journal for Clinicians, 2017, 67(1): 7-30.
- [2] PRUITT S L, LACCETTI A L, XUAN L, et al. Revisiting a longstanding clinical trial exclusion criterion: impact of prior cancer in early-stage lung cancer [J]. British Journal of Cancer, 2017, 116(6): 717-725.
- [3] LIU J K, JIANG H Y, GAO M D, et al. An Assisted Diagnosis System for Detection of Early Pulmonary Nodule in Computed Tomography Images [J]. Journal of Medical Systems, 2017, 41(2): 30.
- [4] JAVAID M, REHMAN M Z, et al. A novel approach to CAD system for the detection of lung nodules in CT images[J]. Computer Methods & Programs in Biomedicine, 2016, 135: 125-139.
- [5] MANIKANDAN T, BHARATHI N. Lung Cancer Detection Using Fuzzy Auto-Seed Cluster Means Morphological Segmentation and SVM Classifier[J]. Journal of Medical Systems, 2016, 40(7): 1-9.
- [6] KUMAR D, WONG A, CLAUSI D A. Lung Nodule Classification Using Deep Features in CT Images[C]//Computer and Robot Vision. IEEE, 2015: 133-138.
- [7] SIRINUKUNWATTANA K, SHAN E A R, TSANG Y W, et al. Locality Sensitive Deep Learning for Detection and Classification of Nuclei in Routine Colon Cancer Histology Images[J]. IEEE Transactions on Medical Imaging, 2016, 35(99): 1.
- [8] NIE D, ZHANG H, ADELI E, et al. 3D Deep Learning for Multi-modal Imaging-Guided Survival Time Prediction of Brain Tumor Patients[C]//Miccai. 2016: 212.
- [9] 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.
- [10] LIANG M, TANG W, XU D M, et al. Low-Dose CT Screening for Lung Cancer: Computer-aided Detection of Missed Lung Cancers[J]. Radiology, 2016, 281(1): 279.
- [11] WEI W Y, ZHANG G C, ZHANG G Z. An image retrieval method using image information entropy and fractal vector[J]. Journal of Northwest Normal University (Natural Science), 2006, 42(1): 32-35. (in Chinese)
魏伟一, 张贵仓, 张国治. 一种基于图像熵及分形维矢量的图像检索技术[J]. 西北师范大学学报(自然科学版), 2006, 42(1): 32-35.
- [12] HE K, ZHANG X, REN S, et al. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification[C]//ICCV 2015. 2015: 1026-1034.
- [13] VAN KLAVEREN R J, OUDKERK M, PROKOP M, et al. Management of lung nodules detected by volume CT scanning [J]. New England Journal of Medicine, 2009, 361(23): 2221-2229.
- [14] MCNITT-GRAY M F, MEYER C R, et al. The Lung Image Database Consortium (LIDC) data collection process for nodule detection and annotation [J]. Academic Radiology, 2007, 14(12): 1464-1474.
- [15] ARMATO S, MCLENNAN G, MCNITT-GRAY M, et al. W-201B-02: The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A Completed Public Database of CT Scans for Lung Nodule Analysis[J]. Medical Physics, 2010, 37(6): 3416-3417.
- [16] MESSAY T, HARDIE R C, TUINSTRAL T R. Segmentation of pulmonary nodules in computed tomography using a regression neural network approach and its application to the Lung Image Database Consortium and Image Database Resource Initiative dataset[J]. Medical Image Analysis, 2015, 22(1): 48.
- [17] ANIRUDH R. Lung nodule detection using 3 D convolutional neural networks trained on weakly labeled data[C]//Pro. SPIE 9785, Medical Imaging: Computer-Aided Diagnosis. 2016: 978532.