

基于局部灰度最大和改进 Mahalanobis 距离分类的肺结节检测算法

魏颖 郭薇 孙月芳 季策

(东北大学信息科学与工程学院, 沈阳 110004)

摘要 CT图像中肺结节检测一直是肺癌CAD系统的关键和难点。提出了一种孤立性肺结节自动检测算法,首先对原始CT图像进行有效、准确的肺实质分割;采用寻找局部灰度最大值方法对ROI进行初始分割;再对分割出的各ROI进行特征提取,利用SVM方法对每个特征进行定量描述,根据SVM单特征分类准确率对Mahalanobis距离进行加权改进,最后采用基于改进的Mahalanobis距离进行肺结节分类。实验结果表明,该算法可以较好地提取出CT图像中的孤立性肺结节,具有较高的灵敏度和较低的漏诊率,可以为医生诊断早期肺癌病灶提供帮助信息。

关键词 肺癌CAD 孤立性肺结节 局部灰度最大 加权的Mahalanobis距离 分类

中图法分类号:TP391.4 文献标识码:A 文章编号:1006-8961(2008)09-1720-07

A Lung Nodule Detection Algorithm Based on Local Maximum Gray Segmenting and Improved Mahalanobis Distance Classifying

WEI Ying, GUO Wei, SUN Yue-fang, JI Ce

(College of Information Science and Engineering, Northeastern University, Shenyang 110004)

Abstract It is hard to detect lung nodules automatically from CT images for lung CAD system. A detection algorithm is proposed for solitary pulmonary nodules (SPNs) in thoracic CT images in this paper. Firstly, lung field is segmented from original CT image effectively and accurately. Secondly, areas of local maximum gray are found, to segment regions of interest (ROIs) roughly. Then, features of each ROI are extracted, each feature is described quantitatively by the accuracy of SVM classification with each single feature separately, and Mahalanobis distance is weighted by the quantitative parameters. Finally, ROIs are classified to nodule or non-nodule with the improved Mahalanobis distance. Experiment results indicated that the algorithm can detect SPNs effectively, it is with relatively high sensitivity and low false neglected rate, and it can provide doctors helpful information to diagnose lesions in early stage of lung cancer.

Keywords lung cancer CAD, solitary pulmonary nodule, local gray maximum, weighted Mahalanobis distance, classification

1 引言

肺癌已跃居世界癌症死亡率的首位,是对人类健康威胁最大的恶性肿瘤。CT扫描是早期肺癌筛查和诊断重要的手段,但是CT扫描产生的图像量

很大,大量的CT图像导致医生工作量的增加,从而也增加了漏诊和误诊几率。基于医学影像的肺癌计算机辅助检测/诊断(computer-aided detection/diagnosis, CAD)技术,结合医学知识,通过对肺部CT图像进行高效、准确的处理和分析,可以为医生提供诊断辅助信息,能有效地降低医生由于阅片疲

基金项目:国家自然科学基金资助项目(60671050);辽宁省自然科学基金资助项目(20052021,20072025)

收稿日期:2008-01-23;改回日期:2008-05-28

第一作者简介:魏颖(1968~),女,副教授。2001年获东北大学检测技术与自动化装置专业博士学位。主要研究方向为图像处理与模式识别。E-mail: weiyang@ise.neu.edu.cn

劳造成的漏诊和误判,帮助检出各种潜在的早期肺癌病灶,提示患者及时进行针对性治疗,提高患者在5年内的生存率^[1,2]。

多数肺癌是以肺结节的形式表现的,肺结节通常是指直径小于3cm 的类圆形病灶,肺结节的检测是肺癌 CAD 中的核心问题之一。但是,肺结节具有形态各异、分布位置不定、易与其他组织粘连等特点,在 CT 图像上特征不明显,有时即使是好的医生也难以做出判断。因此,肺结节检测算法是肺部 CAD 系统中的关键和难点。

传统的图像分割算法并不能取得肺结节检测满意的效果,已有的肺结节检测算法大都基于各种假设模型,如 Okumura 等人使用一种可变 N 环滤波器应用于 2 维和 3 维常规图像^[3],其本质是一种数学形态学滤波的方法;Wiemker 等人采用阈值分割方法绘制和测量肺结节^[4];McCulloch 等人采用了多个分割算法提取异常显著区域,再利用 Bayesian 统计模型确定在肺内各层上解剖结构概率并检测结节^[5];Lee 等人用改进的遗传算法模板匹配方法进行结节检测^[6];Arimura 等人先采用两个滤波器处理,然后使用多阈值技术初选结节,再采用基于规则、多层 MTANN (massive training artificial neural network) 神经网络和 LDA (linear discriminant analysis) 分类器进一步去除假阳性。以上这些方法都是基于各种假设得出的结果,并不是所有的肺部 CT 图像都满足假设条件,因而有一定的局限性。

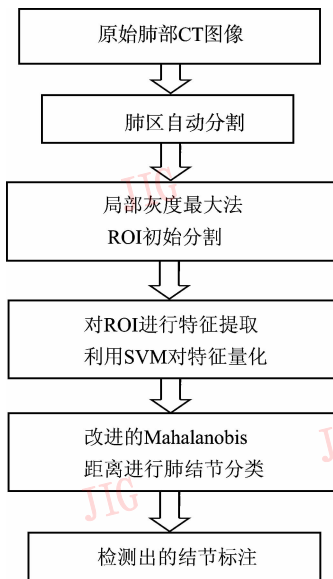


图1 本文算法流程图
Fig.1 Flow chart of the algorithm

本文提出一种孤立性肺结节 (solitary pulmonary nodule, SPN) 自动检测算法,首先对原始图像进行肺区自动分割,然后采用基于局部灰度最大方法对感兴趣区域(region of interest, ROI)进行初始分割,再对分割出的各 ROI 根据医学征象进行特征提取,利用 SVM(support vector machine)方法对每个特征进行定量描述,根据单特征分类准确率对肺结节分类距离进行加权,最后采用基于加权改进的 Mahalanobis 距离进行肺结节分类,算法流程如图 1 所示。

2 肺结节检测算法

2.1 肺实质分割

在进行肺结节检测之前,为了减少运算量、缩短运算时间,首先要将肺实质分割出来^[7,8]。本文主要采用阈值分割、不同尺度的形态学滤波、轮廓提取、形态学“滚球法”修补、曲率计算等,对肺实质进行有效、准确的分割。一个肺实质分割过程图像如图 2 所示。




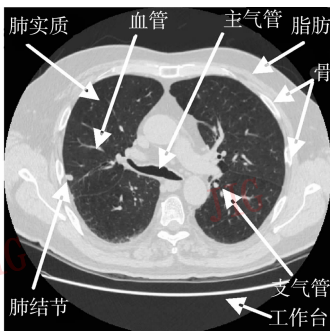
图2 肺实质分割过程图像

Fig.2 Images in the procedure of lung parenchyma segmentation

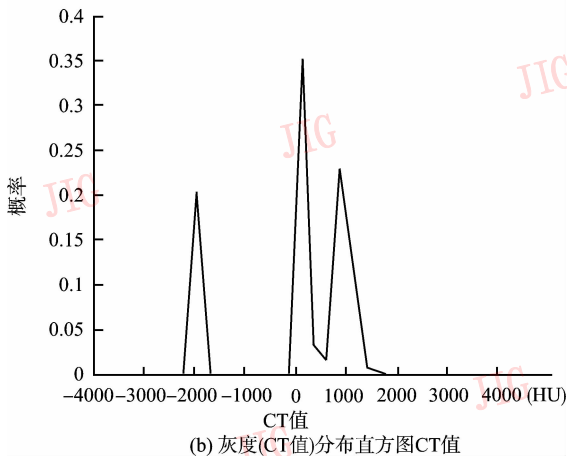
本文的肺实质分割算法可以快速、准确地实现肺实质分割,具有以下 3 个优点:(1)可以去掉靠近肺实质的主气管;(2)有效进行边界修补;(3)可以分开粘连的左右肺。

2.2 局部灰度最大的 ROI 初始分割

在胸部 CT 图像中,肺结节和其他组织如气管、血管等的 CT 值分布范围较广(一幅胸部 CT 图像及其直方图分布如图 3 所示),表现在图像上,灰度分布范围很大,如果采用单一阈值分割,分割结果受阈值的影响很大,且容易造成 ROI 的丢失和遗漏,因而多阈值分割方法是可行的方案。



(a) 胸部CT图像中各组织示意图



(b) 灰度(CT值)分布直方图CT值

图 3 胸部 CT 图像灰度分布

Fig. 3 Gray distribution in a thoracic CT image

对于面向肺癌 CAD 而言, ROI 为所有疑似结节病灶的区域,包括代表结节、血管、气管等解剖结构的区域或种子点^[9-11]。在肺实质图像中, ROI 与肺实质组织相比较,是灰度较大区域。本文通过迭代多阈值方法寻找局部灰度最大值,确定的局部灰度最大区域作为初始分割出的 ROI。

设原图像有 M 行,对每一行 $i(i = 1, 2, \dots, M)$ 都按照下面的步骤寻找局部灰度最大的像素:

(1) 找出此行的最大灰度值 G_{\max} ,并设一个初

始阈值 T_0 ,这个初始阈值定为 $T_0 = G_{\max} - 10$;

(2) 找出此行所有灰度值大于 T_0 的像素,并将这些灰度大于阈值的像素中连续像素个数超过 2 的记录为初始检测的目标(其数目 ≥ 1),进行下面的迭代;

(3) 递减阈值,设上步阈值为 T_{pre} ,步长设为 10,当前阈值为 T_{curr} ,则 $T_{\text{curr}} = T_{\text{pre}} - 10$;

(4) 找出此行所有灰度值大于 T_{curr} 的像素,并将这些灰度大于阈值的像素中连续像素个数超过 2 的记录为当前得到的候选目标;

(5) 每次检测到的目标是一个或多个,对于每个候选目标判断是否满足如下两个条件:

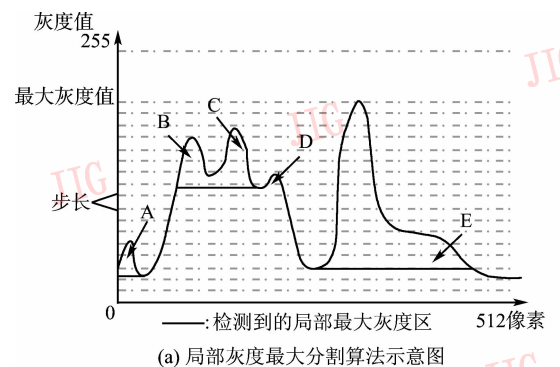
① 上次检测到目标的起始位置 $>$ 当前检测到目标的起始位置,上次检测到目标的终止位置 $<$ 当前检测到目标的终止位置;

② 当前检测到目标的最大灰度值 $> T_{\text{curr}} + 10$ 。

满足这两个条件的候选目标就认为是局部灰度最大区域,是当前检测到的目标。

(6) 循环步骤(3)~步骤(5),直到当前阈值 T_{curr} 达到预设的灰度值(能够将 ROI 提取出来的阈值,这里设成 100)。

对图像的所有行都按上述步骤寻找局部灰度最大像素作为检测到的目标。算法过程示意如图 4(a)所示,图中 A、B、C、E 为检测到的目标,D 不满足条件、不是目标。对肺实质分割后的图像采用



(a) 局部灰度最大分割算法示意图



(b) 局部灰度最大法分割结果

(c) 单阈值法分割结果

图 4 局部灰度最大法 ROI 初始分割

Fig. 4 Original segmentation of ROI using local gray maximum

局部灰度最大方法进行 ROI 初始分割,结果如图 4(b)所示,单阈值法(阈值设为 130)分割结果如图 4(c)所示,可以看出,其分割结果要明显好于后者。局部灰度最大分割方法可以滤掉由于噪声干扰等形成的孤立高亮度小区域,这是单阈值法所不能实现的。

2.3 ROI 的特征提取和量化

2.3.1 ROI 的特征提取

ROI 特征参数提取的优劣将直接影响肺结节的识别结果,合理的特征选取方案应当结合医学表象,并使得同类样本在特征空间中相距较近,异类样本则相距较远。根据孤立性肺结节在 CT 图像中表现形态,在纹理特征方面提取了面积、灰度均值、方差、斜度、峭度等特征,在形状特征方面提取了圆形度、紧凑度、傅里叶描述子、低阶不变矩描述子等特征,这样共提取了 11 个原始特征。原始提取的特征对后续的分类贡献大小不同,而大多数分类器都无法处理具有大量无关或冗余特征的数据,需要对原始提取的特征进行选择,即保留能较好区分不同类别的重要的特征,舍去那些对分类并无多大贡献的特征,以充分利用有用的信息,改善分类的效果。本文采用基于概率分布的可分性进行特征选择^[8],经过分析,选取了对分类贡献大的 6 个特征:圆形度、紧凑度、傅里叶描述子、3 个低阶不变矩,特征定义如下:

(i) 圆形度 (Circularity)

$$Circularity = 4\pi \frac{S}{L} \quad (1)$$

式中, L 为 ROI 区域周长, S 为 ROI 区域面积,圆形度 *circularity* 特征反映了 ROI 接近圆形的程度。

(ii) 紧凑度 (Compactness)

$$Compactness = \frac{R_{inside}}{R_{outside}} \quad (2)$$

式中, R_{inside} 为 ROI 区域内切圆的半径, $R_{outside}$ 为外接圆的半径,如图 5 所示。紧凑度 *Compactness* 特征的范围为 0 ~ 1,越接近 1,表明 ROI 越紧凑、越接近于圆形。




图 5 ROI 的内切圆和外接圆

Fig. 5 Inscribed and circumscribed circles of ROI

(iii) 傅里叶描述子 FF (Fourier descriptor)

将 ROI 轮廓放在复平面上研究,设轮廓包括按顺时针顺序排列的 N 个点写成 $Z_i = x_i + jy_i (i = 0, 1, \dots, N-1)$, 傅里叶系数定义为 $A(k) = \frac{1}{N} \sum_{i=0}^{N-1} Z_i \cdot \exp\left(-\frac{j2\pi ki}{N}\right), k = 0, 1, \dots, N-1$ 。 i 代表空间离散点, k 代表频域离散点。先进行傅里叶快速变换,然后计算归一化的傅里叶系数 $\hat{A}(t)$,

$$\hat{A}(t) = \begin{cases} 0 & t = 0 \\ A(t) & t = 1, 2, \dots, \frac{N}{2} \\ A(t+N) & t = -1, -2, \dots, -\frac{N}{2} + 1 \end{cases}$$

定义傅里叶描述子 *FF* 为

$$FF = \frac{\sum_{t=-N/2+1}^{N/2} \frac{\|\hat{A}(t)\|}{|t|}}{\sum_{t=-N/2+1}^{N/2} \|\hat{A}(t)\|} \quad (3)$$

傅里叶描述子 *FF* 特征反映边界的形状特征, *FF* 值越小,边界的曲折越大,越粗糙。

(iv) 低阶不变矩描述子 (Moment Invariants)

不变矩特征反应了图像的统计特征,可以很好地描述目标的形状,并且具有旋转、平移和伸缩不变的特性,在目标识别、分类中得到广泛应用。为了表征目标轮廓边界特征,这里定义基于目标轮廓的边界矩。设 ROI 边界上点集为 (P_1, P_2, \dots, P_N) 。这样,ROI 轮廓可以由其边界像素 $p(i)$ 到其质心的距离在 $d(i)$ 表示。则 s 阶边界矩 m_s 和 s 阶中心矩 M_s 定义为

$$m_s = \frac{1}{N} \sum_{i=1}^N [d(i)]^s, M_s = \frac{1}{N} \sum_{i=1}^N [d(i) - m_1]^s$$

采用 Gupta 3 个低阶矩表述边界特征:

$$F_1 = \frac{(M_2)^{\frac{1}{2}}}{m_1} = \frac{\left[\frac{1}{N} \sum_{i=1}^N [d(i) - m_1]^2\right]^{\frac{1}{2}}}{\frac{1}{N} \sum_{i=1}^N d(i)} \quad (4)$$

$$F_2 = \frac{(M_3)^{\frac{1}{3}}}{m_1} = \frac{\left[\frac{1}{N} \sum_{i=1}^N [d(i) - m_1]^3\right]^{\frac{1}{3}}}{\frac{1}{N} \sum_{i=1}^N d(i)} \quad (5)$$

$$F_3 = \frac{(M_4)^{\frac{1}{4}}}{m_1} = \frac{\left[\frac{1}{N} \sum_{i=1}^N [d(i) - m_1]^4\right]^{\frac{1}{4}}}{\frac{1}{N} \sum_{i=1}^N d(i)} \quad (6)$$

式中, m_1 为一阶边界矩, M_2 、 M_3 、 M_4 分别为二阶、三阶、四阶中心距。

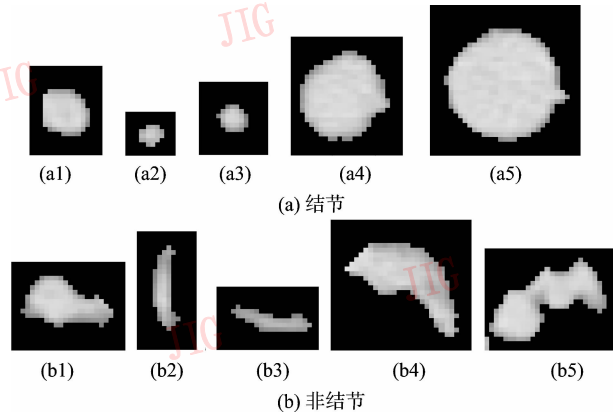


图 6 ROI 的图像

Fig 6 ROI images

图 6 给出了 10 个 ROI 图像, 其中有 5 个为结节、5 个为非结节, 表 1 给出了提取出 10 个 ROI 图像的 6 个特征参数。

表 1 ROI 的特征参数表

Tab. 1 Feature parameters of the ten ROI images

	圆形度	紧凑度	FF	一阶 不变矩	二阶 不变矩	三阶 不变矩
图 6(a1)	1.35	0.94	0.79	7.15	17.87	26.91
图 6(a2)	1.97	0.99	0.79	7.09	18.11	24.81
图 6(a3)	1.73	0.86	0.80	7.10	18.32	26.86
图 6(a4)	1.34	0.79	0.78	7.18	18.96	30.22
图 6(a5)	1.31	0.70	0.80	7.21	22.39	27.64
图 6(b1)	0.97	0.38	0.73	6.79	14.51	21.92
图 6(b2)	0.66	0.21	0.73	6.19	12.63	20.79
图 6(b3)	0.64	0.20	0.76	6.01	12.23	20.62
图 6(b4)	0.83	0.42	0.73	6.65	14.13	21.04
图 6(b5)	0.70	0.37	0.69	6.57	13.76	22.24

2.3.2 基于 SVM 单特征分类准确性的特征参数量化

SVM 最早由 Vapnik 提出^[12], 是以训练误差最小作为优化问题的约束条件, 以置信范围值最小化作为优化目标, 即 SVM 是一种基于结构风险最小化原理的机器学习方法。SVM 的基本思想可以概括为: 首先通过非线性变换将输入空间变换到一个高维空间, 然后在这个新空间中求取最优线性分类面, 而这种非线性变换是通过定义适当的内积函数实现的。

对 ROI 样本的每一个特征参数向量, 分别采用

SVM 进行分类, SVM 的内积核函数选用多项式核函数, 得到的分类准确率反映出该特征对分类贡献大小的定量指标。前述选择出的 6 个特征的分类准确率由高到低依次为: 紧凑度、二阶不变矩、圆形度、一阶不变矩、三阶不变矩、傅里叶描述了, 如表 2 所示。将 SVM 单特征分类准确率作为特征权值参数应用到后继的分类距离公式中, 使得对分类贡献大的特征在分类距离公式中起到较大的作用。

表 2 SVM 单特征分类准确率表

Tab. 2 Classification accuracies by single feature using SVM

特征	紧凑度	二阶 不变矩	圆形度	一阶 不变矩	三阶 不变矩	傅里叶 描述子
准确率	94.486 7	92.175 6	91.304 3	90.909 1	87.213 7	85.687 0

单位%

2.4 基于加权改进的 Mahalanobis 距离的肺结节分类

在模式识别中, 常利用样本间的距离表示其间的差异, 根据样本间的距离远近来判断样本所属的类别。如前所述, 提取的 ROI 特征参数具有不同的数量级(如表 1 所示), 采用传统的欧氏距离判别, 会导致变差大的变量(特征)在距离中的贡献大, 影响 ROI 识别的正确性。Mahalanobis 距离与各量所用纲单位无关, 适用于具有不同类型特征值的分类问题, 而且 Mahalanobis 距离具有 3 个优秀的性质: 平移不变性、旋转不变性和仿射不变性。

设 \mathbf{y} 是一个测试样本, \mathbf{X} 是总体样本, 则 Mahalanobis 距离为

$$D^2(\mathbf{y}, \mathbf{X}) = (\mathbf{y} - \boldsymbol{\mu})^T \cdot \mathbf{v}^{-1} \cdot (\mathbf{y} - \boldsymbol{\mu}) \quad (7)$$

其中, $\boldsymbol{\mu}$ 是 \mathbf{X} 的均值, \mathbf{v} 是 \mathbf{X} 的协方差, \mathbf{y} 是 $1 \times n$ 维向量(n 是特征向量的个数, 本文为 6), \mathbf{X} 是 $m \times n$ 维矩阵(m 是总样本个数), $\boldsymbol{\mu}$ 是 $1 \times n$ 维向量, \mathbf{v} 是 $n \times n$ 维矩阵。

将 Mahalanobis 距离公式中引入各特征分类准确率, 使特征对分类贡献大小在计算距离时反应出来, 以得到更准确的分类。定义加权改进的 Mahalanobis 距离如下:

$$\hat{D}^2(\mathbf{y}, \mathbf{X}) = [(\mathbf{y} - \boldsymbol{\mu})^T \cdot \mathbf{W}] \cdot \mathbf{v}^{-1} \cdot [\mathbf{W} \cdot (\mathbf{y} - \boldsymbol{\mu})] \quad (8)$$

其中, \mathbf{W} 是 SVM 分类准确率加权矩阵, 定义为 $\mathbf{W} = \text{diag}\left[\frac{1}{w_1}, \frac{1}{w_2}, \dots, \frac{1}{w_n}\right]$, w_i ($i = 1, 2, \dots, n$) 为第 i 个特征 SVM 分类准确率, 即对角线上元素为 SVM 单特

征分类准确率的倒数、其余元素为零的 $n \times n$ 维对角矩阵。式(8)中,对于第 i 个特征,其分类准确率越大,得到的加权的 Mahalanobis 距离 \hat{D} 越小。

这里将 ROI 分为结节和非结节两类,故总样本为结节样本 X_0 和非结节样本 X_1 两类,对测试样本进行分类时,分别计算测试样本到结节总样本的距离 \hat{D}_{w_0} 和到非结节总样本的距离 \hat{D}_{w_1} ,比较距离 \hat{D}_{w_0} 和距离 \hat{D}_{w_1} ,哪个距离小说明测试样本更接近该类。因而定义测试样本而到两类距离的差值作为分类的决策函数:

$$f_w(y) = D^2(y, X_0) - D^2(y, X_1) \quad (9)$$

如果 $f_w(y)$ 小于零,说明测试样本到结节样本 X_0 的距离小,将其分类为结节,否则归为非结节。

$f_w(y)$ 是基于加权 Mahalanobis 距离的决策函数,反映了测试样本到两类总样本的类间差值,其值越大(绝对值),则类间差别越大、越有利于分类。为了比较,类似式(9)定义基于 Mahalanobis 距离的决策函数

$$f(y) = D^2(y, X_0) - D^2(y, X_1) \quad (10)$$

表3给出了如图6所示10个测试样本的 $f_w(y)$ 以及 $f(y)$ 值,可以看出, $f_w(y)$ 的绝对值明显大于 $f(y)$,说明基于加权改进的 Mahalanobis 距离比 Mahalanobis 距离具有更好的分类性能。

表3 $f_w(y)$ 和 $f(y)$ 的比较

Tab. 3 Comparison between $f_w(y)$ and $f(y)$

决策值	图像									
	图 6(a1)	图 6(a2)	图 6(a3)	图 6(a4)	图 6(a5)	图 6(b1)	图 6(b2)	图 6(b3)	图 6(b4)	图 6(b5)
$f(y)$	-47.462	-49.253	-46.136	-62.991	-213.941	23.588	125.881	162.372	42.766	68.036
$f_w(y)$	-51.082	-52.562	-50.443	-69.158	-243.179	25.968	138.843	178.531	47.359	75.763

3 实验结果与分析

对本文提出的肺结节检测算法进行验证,实验数据来自于某大型医院放射科实际临床影像,选取

20个病例,每个病例中不包含肺部最上端和最下端部分图像,共计776幅DICOM格式图像。经医生诊断,这些图像中共有肺结节205个。其中3幅图像的检测结果如图7所示,图7(a)组图像为原始CT图像,图7(b)图像为采用局部灰度最大法ROI初始




图7 3幅图像的肺结节检测结果

Fig 7 Three images of the detection of pulmonary nodules

分割结果,图 7(c)组图像为基于加权改进 Mahalanobis 距离分类检测到的肺结节,图 7(d)组图像为在原图像上标记。

算法对肺结节检测的性能通过准确率(Accuracy)、灵敏度(Sensitivity)、漏诊率(即假阴性率(false negative rate, FNR))3个指标来评价,各指标定义如下:

$$Accuracy = \frac{TP}{TP + FP + FN} \quad (11)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (12)$$

$$FNR = 1 - sensitivity = \frac{FN}{TP + FN} \quad (13)$$

其中,TP为检测出的真阳性结节,FP为检测出的假阳性,FN为没有检测出来的真阳性肺结节即假阴性。好的检测算法应具有较高的准确率、灵敏度和较低的漏诊率。

利用本文算法可以检测出直径范围在 4mm 到 40mm 的类圆形孤立性疑似肺结节,实验结果如表 4 所示,假阴性 FN(漏诊)主要发生在结节为非圆形、与血管粘连等情况,假阳性 FP 主要为与扫描成像平面垂直的、在 CT 图像上表现为圆形的气管或血管。可以看出,该检测算法具有较高的灵敏度、较低的漏诊率和相对较低的准确率。算法获得较低的漏诊率,可以作为医生的辅助工具减少漏诊的发生。为获得较高的准确率,需要从 3 维分析进一步区分结节和血管。

表 4 算法实验结果

Tab. 4 Experiment results

图像数	结节数	检测结果			准确 率	灵敏 度	漏诊 率
		TP	FP	FN			
776	205	194	206	11	47.2%	94.6%	5.4%

4 结 论

本文对原始 CT 图像进行有效、准确的肺实质分割,采用基于局部灰度最大方法对 ROI 进行初始分割,再对分割出的各 ROI 根据医学征象进行特征提取,利用 SVM 方法对每个特征进行定量描述,根据单特征分类准确率对肺结节分类距离进行加权,最后采用基于加权改进的 Mahalanobis 距离进行肺结节分类。提出了一种 CT 图像孤立性肺结节自动

检测算法,实验结果表明,该算法具有较高的灵敏度、较低的漏诊率,可以作为医生的辅助工具减少漏诊的发生。算法稳定、可靠,不依赖于图像的整体灰度值,具有较强的适应性,有利于面向肺癌 CAD 实际临床应用。

参考文献 (References)

- Yamamoto S. Image processing algorithm of computer-aided diagnosis in Lung cancer screening by CT [J]. System and Computers in Japan, 2005, **36**(7):40~53.
- Li Q. Recent progress in computer-aided diagnosis of Lung nodules on thin-section CT [J]. Computerized Medical Imaging and Graphics, 2007, **31**(3):248~257.
- Okumura T, Miwa T, Kako J, et al. Automatic detection of Lung cancers in chest CT images by variable N-Quoit filter [A]. In: Proceedings of the Fourteenth International Conference on Pattern Recognition [C], Piscataway, NJ, USA, 1998:1671~1673.
- Wiemker R, Zwarkuis A. Optimal thresholding for 3D segmentation of pulmonary nodules in high resolution CT [A]. In: Proceedings of the 17th International Congress and Exhibition of Computer Assisted Radiology and Surgery (CARS 2001) [C], Berlin, Germany, 2001: 653~658.
- McCulloch C C, Kaucic R A, Mendonca P R S. Model-based detection of Lung nodules in computed tomography exams [J]. Academic Radiology, 2004, **11**(3): 258~266.
- Lee Y, Hara T, Fujita H, et al. Automated detection of pulmonary nodules in helical CT images based on an improved template-matching technique [J]. IEEE Transactions on Medical Imaging, 2001, **20**(7):595~604.
- Chen Xu, Zhuang Tian-Ge. Automatic segmentation of pulmonary parenchyma thoracic high resolution CT [J]. Journal of Shanghai Jiaotong University, 2002, **36**(7):946~948. [陈旭, 庄天戈. 胸部高分辨率 CT 图像中肺实质的自动分割[J]. 上海交通大学学报, 2002, **36**(7):946~948.]
- Xue Yi-feng, Bao Xu-dong, Ma H L, et al. Computer-aided diagnosis for pulmonary nodules based on CT Images [J]. Chinese Journals of Medical Physics, 2006, **23**(2):93~96. [薛以锋, 鲍旭东, 马汉林等. 基于 CT 图像的肺结节计算机辅助诊断系统[J]. 中国医学物理杂志, 2006, **23**(2):93~96.]
- Zhao B S. Automatic detection of small Lung nodules on CT utilizing a local density maximum algorithm [J]. Journal of Applied Clinical Medical Physics, 2003, **4**(3): 248~260.
- Shi Yu, Chao Xiao-guang, Zhang Hong, et al. Study of Automatic detection algorithm for Lung nodules [J]. Chinese Journal of Scientific Instrument, 2006, **27**(6): 2265~2267. 石羽, 曹晓光, 张弘等. 肺结节自动检测算法研究[J]. 仪器仪表学报, 2006, **27**: 2265~2267.
- Hu S Y, Hoffman E A, Joseph M Reinhardt. Automatic Lung segmentation for accurate quantitation of volumetric X-Ray CT images [J]. IEEE Transaction on Medical Imaging, 2001, **20**(6): 490~498.
- Vapnik V N. The Nature of Statistical Learning Theory [M]. New York, NY, USA: Springer-Verlag, 1995:120~126.