

基于稀疏表示和随机游走的磨玻璃型肺结节分割

李祥霞¹ 李彬¹ 田联房¹ 张莉¹ 朱文博²

摘要 肺结节是早期肺癌在影像学上的表现形式. 磨玻璃型 (Ground glass opacity, GGO) 肺结节被认为是恶变可能性最大的一类结节之一. 针对 GGO 结节边缘模糊、大小各异、形状不规则和灰度不均匀等造成分割准确率低问题, 本文提出了一种基于稀疏表示和随机游走模型的分割算法. 首先, 利用测地距离和局部搜索策略, 自动地选取了种子点. 其次, 联合 8-邻域和稀疏表示的 K-最近邻算法建立了新的图, 避免了噪声的干扰. 结合灰度、纹理、空间距离和稀疏系数构建了新的加权矩阵. 最后, 将标签限制项引入到随机游走的能量函数中. 该算法分割准确性较高, 鲁棒性较强.

关键词 磨玻璃型肺结节, 结节分割, 随机游走算法, 稀疏表示, 加权矩阵

引用格式 李祥霞, 李彬, 田联房, 张莉, 朱文博. 基于稀疏表示和随机游走的磨玻璃型肺结节分割. 自动化学报, 2018, 44(9): 1637–1647

DOI 10.16383/j.aas.2018.c170420

Segmentation of Ground Glass Opacity Pulmonary Nodules With Sparse Representation and Random Walk

LI Xiang-Xia¹ LI Bin¹ TIAN Lian-Fang¹ ZHANG Li¹ ZHU Wen-Bo²

Abstract Pulmonary nodules are the radiographic manifestation of lung cancer in early stages. Ground glass opacity (GGO) pulmonary nodules are considered to be one of the most likely nodules of malignancy. To address the low accuracy segmentation problem caused by blurred boundaries, different sizes, irregular shapes and inhomogeneous intensities of GGO nodules, a segmentation algorithm with the sparse representation and random walk model is proposed. Firstly, the geodesic distance and local search strategy are introduced to automatically select seeds. Secondly, 8-neighbor and sparse representation K-nearest neighbor algorithm are combined to build a new graph which avoids the interference of image noise. To construct a new weighted matrix, intensity, texture, spatial distance and sparse coefficients are incorporated. Finally, a label constraint term is added to the energy function of random walker. The proposed algorithm can obtain a high accuracy and strong robustness.

Key words GGO pulmonary nodules, nodule segmentation, random walk algorithm, sparse representation, weighted matrix

Citation Li Xiang-Xia, Li Bin, Tian Lian-Fang, Zhang Li, Zhu Wen-Bo. Segmentation of ground glass opacity pulmonary nodules with sparse representation and random walk. *Acta Automatica Sinica*, 2018, 44(9): 1637–1647

收稿日期 2017-07-28 录用日期 2018-02-07
Manuscript received July 28, 2017; accepted February 7, 2018
国家自然科学基金 (61305038, 61273249), 广东省自然科学基金 (S2012010009886, S2011010005811), 海洋公益性行业科研专项经费资助项目 (201505002), 广东省科技计划项目资助 (2017B020210002), 华南理工大学中央高校基本科研业务费重点项目 (2015ZZ028), 自主系统与网络控制教育部重点实验室资助
Supported by National Natural Science Foundation of China (61305038, 61273249), Natural Science Foundation of Guangdong Province (S2012010009886, S2011010005811), The Public Science and Technology Research Funds Projects of Ocean (201505002), Science and Technology Planning Project of Guangdong Province (2017B020210002), The Fundamental Research Fund for the SCUT Central Universities (2015ZZ028), The Key Laboratory of Autonomous Systems and Network Control of Ministry of Education

本文责任编辑 张道强
Recommended by Associate Editor ZHANG Dao-Qiang
1. 华南理工大学自动化科学与工程学院 广州 510641 2. 佛山科学技术学院自动化学院 佛山 528231
1. School of Automation Science and Engineering, South China University of Technology, Guangzhou 510641 2. School of Automation, Foshan University, Foshan 528231

肺癌已经成为最高致死率的恶性肿瘤疾病之一. 临床数据表明, 早发现、早治疗能够有效地提高生存率和降低患者死亡率^[1]. 肺结节是肺癌的早期影像学表现形式. 目前, 电子计算机断层扫描 (Computed tomography, CT) 是最广泛应用于肺癌的影像学诊断方法^[2]. 传统的分割方法是医生获取病人的某一断层数据, 进行手动地分割肺结节. 然而, 这不仅费时费力, 而且往往容易受到主观因素的影响. 因此, 肺结节的自动分割已经成为研究的热点. 对于实性肺结节的分割, 国内外均有大量的文献报道. 但是, 对于磨玻璃型 (Ground glass opacity, GGO) 结节分割文献仍报道甚少. 不幸地, 与实性结节相比, GGO 结节更具有发展为恶性肿瘤的潜力^[3]. 因此, GGO 结节的分割对于早期肺癌的筛选和诊断更具有临床应用价值. 然而, GGO 肺结节的分割一直是一个挑战性的任务,

这是因为 GGO 结节具有形状不规则、边界模糊和结节内部灰度分布不均匀等特性。

随机游走 (Random walker, RW) 是将图像分割看成网格图上标签安排问题. 首先需要用户在图像上标记合适数量的目标和背景种子点, 然后计算每个未标记顶点首次到达给定类种子点的概率值. 随后, 将未标记顶点归类到最大概率值所对应的类别中, 从而实现最终的分割. RW 只需求解一个稀疏线性方程组, 因此其无需迭代, 操作简单快速. RW 在处理弱边缘时能够取得较好的结果. 然而, 大部分 RW 算法采用了固定的邻域结构来构建网格图. 然而, 由于图像噪声、伪影等诸多因素的影响, 这种邻域结构可能捕捉了不恰当的邻域关系, 从而降低了分割的准确性. 此外, RW 仅仅采用了灰度信息构建加权矩阵, 这对于对比度低、灰度不均匀的 GGO 结节较难直接分割.

为了解决这些问题, 本文提出了基于稀疏表示和随机游走 (SRRW) 的算法对 GGO 肺结节进行自动分割. 首先, 根据图像的信息自动地选取种子点, 避免人为的干预和减少操作的时间; 其次, 本文构造了一个新的图来替代传统的无向加权图, 利用 8-邻域和稀疏表示的 K-最近邻 (K-nearest neighbor, K-NN) 算法解决了加权图对噪声的敏感性问题. 最后, 引入标签限制项到 RW 的能量函数中, 惩罚了预测标签与给定标签的不一致性, 从而提高了分割的准确性. 本文采用了美国肺部影像数据库 LIDC 来验证提出算法的准确性和有效性. 实验结果表明, 提出的算法极大地提高了 GGO 肺结节分割的有效性和准确性.

1 相关工作

在过去几十年里, 众多学者已经提出了大量的肺结节分割方法^[4], 主要可分为两类: 基于灰度的分割方法和基于形状的分割方法. 基于灰度的分割方法是利用图像的灰度信息实现对肺结节的分割, 例如阈值法^[5], 区域增长^[6-7], 聚类^[8]. 这类分割算法对灰度均匀的实性结节的分割效果较好, 但是对于胸膜粘连型、血管粘连型和 GGO 结节较难分割. 基于形状的分割方法通过整合了结节的几何和形态信息来提高结节分割的准确性, 例如形态学^[9-10]、局部形状分析^[11-12]、活动轮廓^[13-15]. 目前, 已经有一些学者对 GGO 结节分割进行了研究, 并取得了一定的成果. 例如, Zhu 等^[16] 提出了基于马尔科夫随机场的算法进行 GGO 结节的分割. Li 等^[17] 提出了改进的模糊聚类算法进行 GGO 结节的分割. Li 等^[18-19] 提出了基于自适应局部区域能量函数的活动轮廓进行 GGO 结节的分割. 近年来, 一些学者已经将深度学习用于肺结节的分割. 例如, Cheng

等^[20] 提出了基于深度学习的肺结节计算机辅助诊断系统. Wang 等^[21] 提出了中心聚焦卷积神经网络对肺结节进行分割.

基于图论的随机游走算法是近年来近年来逐渐兴起的交互式图像分割算法, 它首先被 Grady 等^[22] 引入图像分割的领域. Eslami 等^[23] 提出了导向随机游走的方法进行左心室的分割. Onoma 等^[24] 利用相邻像素点之间的欧氏距离来决定参数的取值, 并将标签的概率密度整合到 RW 能量函数中, 从而提高了病变组织分割的准确性. Wang 等^[25] 利用拓扑细化方法自动地选择种子点. Mi 等^[26] 将肿瘤的增长预测信息整合到 RW 能量函数进行肿瘤的自动分割, 从而提高了分割的性能.

稀疏表示 (Sparse representation, SR) 已经被引入到图构建中. 例如, Fan 等^[27] 提出了稀疏正则化半监督学习算法. Liu 等^[28] 提出了低秩表示 (Low-rank representation, LRR) 进行子空间的聚类. Li 等^[29] 提出了一种稀疏平衡图构建方法. Fu 等^[30] 提出了张量低秩表示和基于稀疏编码的子空间聚类算法. Zhuang 等^[31] 提出了一种新的半监督图学习方法进行数据的半监督分类. Liao 等^[32] 提出了图正则化自动编码器进行数据的聚类. 这些方法都是基于稀疏表示来构建稀疏图, 并将构造的图应用到谱聚类、子空间表示、子空间聚类等.

2 基于稀疏表示和随机游走的 GGO 肺结节自动分割

本文提出了基于稀疏表示和随机游走 (SRRW) 的 GGO 肺结节分割的算法. 算法的流程图如图 1 所示.

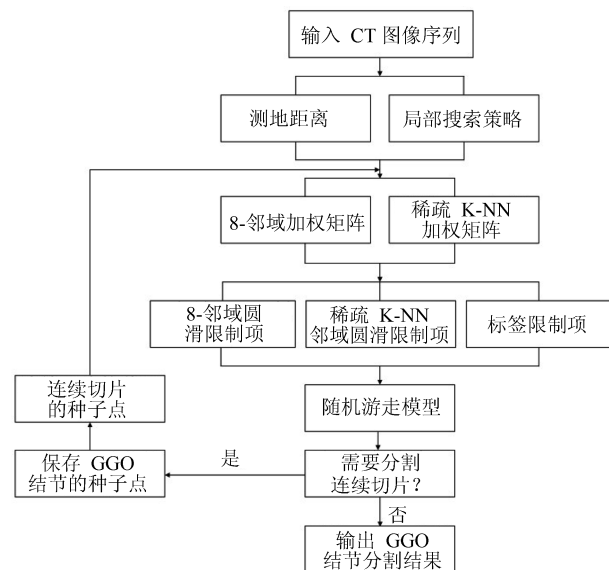


图 1 SRRW 算法的流程图

Fig. 1 The flowchart of the SRRW algorithm

3 基于稀疏表示的加权矩阵的构建

在随机游走算法中, 图的构建是一个至关重要的环节. 大部分 RW 算法采用了 4-邻域或者 8-邻域搜索策略来构建图. 然而, 以这种方式构建的图对噪声比较敏感. 为了解决这个问题, 本文将 8-邻域和基于稀疏表示的 K-NN 方法结合起来, 构建了一个可靠的新图. 新的图能够更好地描述顶点的邻域关系, 提高了对噪声的鲁棒性. 它也能够更好地传递种子点的标签信息到未标记顶点, 提高了分割的准确性.

3.1 基于 8-邻域的加权矩阵构建

给定一个包含 $n = W \times H$ 个像素点的图像, 其中 W 和 H 分别是图像的宽度和高度. 然后, 将输入图像表示为一个无向加权图 $G = (V, E, W)$, 其中 V 是图的顶点集, E 是图的边集. 每个图像像素点对应着图的一个顶点 $i \in V$, 每条边 $e_{ij} \in E \subseteq V \times V$ 连接一对相邻顶点 i 和 j . 每一条边 $e_{ij} \in E$ 被赋予一个非负权值 $w_{ij} \in W$, 衡量了一对相邻顶点之间的特征差异性. 本文利用了 Gabor 函数将图像变成频域上的幅度谱, 进行纹理特征的提取. 图 2 是一个 GGO 结节 CT 图像中感兴趣区域 (Region of interest, ROI) 纹理的分析. 图 2(a) 和 2(b) 分别是原始的 CT 图像和纹理图像. 图 2(d) 和 2(e) 是在结节和背景的 ROIs (如图 2(c) 所示) 中像素的纹理值. 正如图 2(d) 和 2(e) 所示, 结节和背景像素的纹理值存在着明显的差异, 因此可以将纹理作为特征来区分结节和背景.

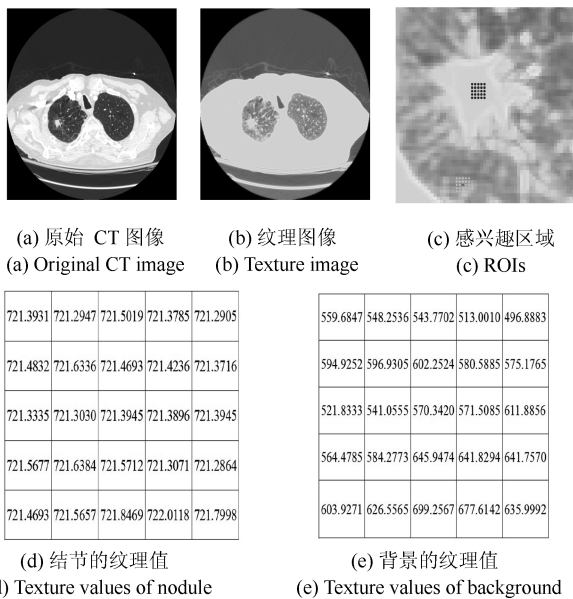


图 2 一个 GGO 结节 CT 图像纹理的分析

Fig. 2 Texture analysis in a CT image with GGO nodule

纹理特征提取后, 对于每一个图像像素点, 本文整合了灰度、纹理和空间位置坐标构造了一个特征

向量, 如式 (1) 所示.

$$\mathbf{a}_i = (I_i, T_i, x_i, y_i)^T \quad (1)$$

其中, (x_i, y_i) 是像素点 i 的空间坐标. I_i 和 T_i 分别是像素点 i 的灰度值和纹理值. 本文利用 Min-max 标准化方法将灰度值和纹理值分别映射到 $[0, 1]$ 之间, 表达式如式 (2)~(3) 所示.

$$I_i^* = \frac{I_i - I_{\min}}{I_{\max} - I_{\min}} \quad (2)$$

$$T_i^* = \frac{T_i - T_{\min}}{T_{\max} - T_{\min}} \quad (3)$$

其中, I_{\min} 和 I_{\max} 分别是像素灰度值的最大值和最小值. T_{\min} 和 T_{\max} 分别是像素纹理值的最大值和最小值. 归一化的特征向量的表达式如式 (4) 所示.

$$\mathbf{a}_i = \left(I_i^*, T_i^*, \frac{x_i}{W}, \frac{y_i}{H} \right)^T \quad (4)$$

本文采用了高斯核函数来计算一对 8-邻域顶点 i 和 j 之间的加权值 w_{ij}^8 , 表达式如式 (5) 所示.

$$w_{ij}^8 = \exp\left(-\alpha \|\mathbf{a}_i - \mathbf{a}_j\|^2\right), \quad e_{ij} \in E^8 \quad (5)$$

其中, \mathbf{a}_i 和 \mathbf{a}_j 分别是顶点 i 和 j 的特征向量. E^8 表示 8-邻域关系的相邻顶点彼此相连接所组成的边集. α 是一个参数, 在整个实验中被设置为 90.

3.2 基于稀疏表示的 K-NN 的加权矩阵构建

RW 算法的分割性能在一定程度上依赖于构造的图. 传统的邻域顶点选择方法主要包括两种: 基于 4-或者 8-邻域, 基于 K-最近邻. 以这些方式选择的邻域顶点依赖于邻域大小参数的选择, 然而, 最优参数的选择并不是一件容易的事. 此外, 这些方法是通过计算了两个顶点之间的欧氏距离来决定邻域顶点, 因此对噪声比较敏感. 为了解决这些问题, 本文将稀疏表示 (Sparse representation, SR) 引入到图构建中. 与传统方法构建的图相比, 基于 SR 方法构建的图能够自适应地捕捉图的邻域结构, 因此对噪声具有很强的鲁棒性. 不同于 Yuan 等^[33] 采用 K-NN 来选择与目前顶点欧氏距离最小的 K 个顶点, 本文采用了 SR 方法来选择 K 个邻域顶点. 首先, 利用稀疏表示的能量函数计算了每一个顶点的最佳稀疏重构系数, 然后, 利用 K-NN 算法将数据点的搜索限制在空间的局部邻域内, 极大地减少了计算的复杂性. 最后, 用得到的稀疏矩阵定义了一个新的加权矩阵.

对于一个给定的 CT 图像, 假设 $X = [\mathbf{a}_1, \dots, \mathbf{a}_n]$ 表示数据矩阵. 在特征空间中, 一个数据点 \mathbf{a}_i 可以由其他 K 个邻域数据点线性表

示. 本文利用数据点本身作为一个字典, 即字典可以表示为 $A = [\mathbf{a}_1, \dots, \mathbf{a}_n]$, 它的每一列对应着一个数据点的特征向量. 稀疏表示是寻找数据在字典下的最稀疏的线性表示, 目标函数定义如式 (6) 所示.

$$\begin{aligned} \min_C & \|C\|_1 + \eta \|A - AC\|^2, \\ \text{subject to } & C \geq 0, C_{ii} = 0 \end{aligned} \quad (6)$$

其中, $C = [C_1, \dots, C_n]$ 是一个稀疏矩阵, 它的每个元素 C_i 对应着数据点 \mathbf{a}_i 的稀疏表示. $\|\cdot\|_1$ 是矩阵的 L_1 -范数. $\|\cdot\|$ 是欧式距离. η 是一个权衡参数. 本文添加了限制条件 $C_{ii} = 0$, 去除了数据点由自身线性表示的平凡解情况. 式 (6) 主要有两项组成: 判别项和重构误差项. 判别项是为了约束重构稀疏具有稀疏性, 重构误差项迫使了在稀疏表示时重构误差被最小化. 本文采用了交替方向乘子法 (Alternating direction method of multipliers, ADMM) 算法来寻求凸函数 (6) 的最优解. ADMM 算法引入了附加变量 Z , 方程 (6) 等价式 (7).

$$\begin{aligned} \min_Z & \|Z\|_1 + \eta \|A - AZ\|^2, \\ \text{subject to } & C \geq 0, C_{ii} = 0, C = Z \end{aligned} \quad (7)$$

式 (7) 对应的增广拉格朗日方程表示如式 (8) 所示.

$$\begin{aligned} J(Z, C, Y_1, Y_2, u) = & \|Z\|_1 + \langle Y_1, A - AZ \rangle + \\ & \langle Y_2, C - Z \rangle + \frac{u}{2} \left(\|A - AZ\|_F^2 + \|C - Z\|_F^2 \right) \end{aligned} \quad (8)$$

其中, Y_1 和 Y_2 是拉格朗日乘子, $u > 0$ 是惩罚参数. 第三项是 ADMM 算法加入的 Frobenius 范数惩罚项. 更新迭代变量 C, Y_1, Y_2, u , 直到满足收敛条件, 变量 C 的迭代公式如式 (9) 所示.

$$C^{t+1} = (A^T A + I)^{-1} \times \left[A^T A + Z^{t+1} + \frac{(A^T Y_1^t - Y_2^t)}{u^t} \right] \quad (9)$$

最终得到最优的稀疏矩阵 C^* . 然后, 利用 K-NN 将当前顶点的邻域搜索限制在局部邻域内, 即选择 K 个顶点来表示当前顶点, 从而得到最终的稀疏矩阵 C^* . 因为稀疏矩阵 C^* 测量了成对顶点的相似性, 因此用其构造了一个新加权矩阵. 加权值 w_{ij}^{SE} 计算公式如式 (10) 所示.

$$w_{ij}^{SR} = \frac{c_{ij}^* + c_{ji}^*}{2}, \quad e_{ij} \in E^{SR} \quad (10)$$

其中, E^{SR} 表示当前顶点与稀疏表示的 K-NN 选取的邻域顶点彼此相连接组成的边集合. 图 3 是构建

的新的加权图 $G = (V, E^{8\&SR})$. 每一个实心圆圈表示一个顶点, 各实心圆圈分别表示当前的顶点, 当前顶点的 8-邻域顶点和基于稀疏的 K-NN 选择的邻域顶点.




图 3 新加权图
Fig. 3 A new weighted graph

4 种子点的自动获取和 SRRW 能量函数的定义

众所周知, RW 对种子点的位置和数量非常敏感. 传统 RW 需要用户在感兴趣的区域手动地选取种子点. 然而, 人工选取种子点是费时和冗余的. 本文提出了自动获取种子点的策略, 包括两个主要的步骤: 初始的肺结节分割, 基于测地距离和局部搜索策略的种子点的选取. 首先, 自适应阈值和形态学开运算等方法进行粗略地分割肺结节, 分割结果被表示为 R . 然后, 利用测地距离 (Geodesic distance, GD)^[10] 获取了 R 的一个小区域 R_0 . 本文通过设定一个合适的阈值 T , 计算从 R 的边界到结节中心的最大测地距离 D . 最后, 将区间 $[D - T, D]$ 范围内的像素点作为肺结节的种子点, 如图 4 (b) 所示. 由于 GGO 结节存在形状不规则和边缘模糊等特性, 基于测地距离产生的结节种子点易陷入均匀的区域. 为了解决这个问题, 一个局部搜索策略被提出, 来选取更多的结节种子点. 本文利用了灰度和 Gabor 纹理特征来定义相似性函数, 指数函数被引入来强调灰度值的重要性, 如式 (11) 所示.

$$S_{ij} = e^{\|I_i - I_j\|^2} \times \|T_i - T_j\|^2, \quad j \in N_i \quad (11)$$

其中, i 是区域 R 的边缘上的像素点, N_i 是像素点 i 的 8-邻域像素集. F_0 表示初始的肺结节种子点集. 如果相似性函数满足下面准则式 (12), 那么 F_0 被迭代更新, 即像素 j 被纳入到肺结节种子集 F 中.


$$F = F_0 \cup \{j\} \text{ 若 } S_{ij} < \kappa \text{ 且 } S_{jk} < \kappa,$$

$$i \in \partial R, k \in R_0, j \in N_i \quad (12)$$

其中, κ 是预定义的阈值, 凭经验设定为 10. 当全部的边界像素点被历遍, 搜索停止. 图 4(c) 展示了全部肺结节种子点 F . 本文利用提出的局部搜索策略来获取背景种子点. B_0 表示初始的背景种子点集. 如果相似性函数满足下面准则式 (13).

$$\begin{aligned} B &= B_0 \cup \{j, l\} \text{ 若 } S_{ij} > \gamma, S_{jk} > \gamma, i \in \partial R, \\ k \in R_0, j \in R_b \setminus R_0, S_{j,l} > \gamma, S_{lk} > \gamma, l \in N_j \end{aligned} \quad (13)$$

其中 R_b 表示从肺结节的中心到区域 R 的预先定义距离 T_b ($T_b > M$) 的一个区域. 当没有新的像素点被纳入到背景种子点集 B 时, 迭代停止. 图 4(c) 显示了全部的种子点 $S = F \cup B$. 结节内部和外部标记点分别表示肺结节种子点和背景种子点. 考虑到在连续断层 CT 图像上肺结节位置特征以及当前切片与相邻的上下切片对应的特征的相似性和相关性, 本文从第 k 张切片分割的肺结节中找到肺结节的中心位置, 然后将对应的肺结节和背景的种子点反馈到第 $k+1$ 张 CT 切片的分割工作中, 进行下一张连续 CT 切片的分割过程中. 本文提出的算法在分割多帧连续的断层图像时无需反复选取种子点, 大大减少了计算复杂性.



(a) 原始 CT 图像 (b) 测地距离的结节种子点 (c) 全部种子点
(a) Original CT image (b) Nodule seeds of GD (c) Total seeds

图 4 种子点的自动获取
Fig. 4 Automatic acquisition of seeds

在种子点自动获取后, 将获取的种子点注入到提出的 SRRW 算法中. 本文引入标签限制项到原始 RW 能量函数中来提高分割的准确性. 标签限制项迫使预测的种子点概率与给定的种子点概率的一致性. 改进的能量函数如式 (14) 所示.

$$\begin{aligned} E(f_i, f_j) &= \frac{1}{2} \sum_{e_{ij} \in E^8} w_{ij}^8 (f_i - f_j)^2 + \\ &\frac{1}{2} \sum_{e_{ij} \in E^{SR}} w_{ij}^{SR} (f_i - f_j)^2 + \\ &\lambda \left(\sum_{i=1}^{|S|} (f_i - b_i)^2 \right) \end{aligned} \quad (14)$$

其中, f_i 和 f_j 代表的是顶点 i 和对应的邻域顶点 j 的概率. λ 是一个参数. $|S|$ 表示种子点集 S 中元素

的个数. b_i 表示顶点 i 的指示函数, 如式 (15) 所示.

$$b_i = \begin{cases} -1, & \text{如果 } i \in B \\ 1, & \text{如果 } i \in F \end{cases} \quad (15)$$

式 (14) 的第一项和第二项是圆滑限制项, 分别鼓励了在 E^8 和 E^{SR} 中邻域顶点之间概率的一致性. 第三项是标签限制项, 惩罚了在最优能量框架下预测的种子点概率与给定的种子点概率不一致性. 式 (14) 可以表示为式 (16).

$$\begin{aligned} E(f_i, f_j) &= \frac{1}{2} \sum_{e_{ij} \in E^8} w_{ij}^8 (f_i^2 - 2f_i f_j + f_j^2) + \\ &\frac{1}{2} \sum_{e_{ij} \in E^{SR}} w_{ij}^{SR} (f_i^2 - 2f_i f_j + f_j^2) + \\ &\lambda \sum_{i=1}^{|S|} (f_i^2 - 2f_i b_i + b_i^2) \end{aligned} \quad (16)$$

将式 (16) 转化为矩阵形式, 如式 (17) 所示.

$$\begin{aligned} E(\mathbf{f}) &= \text{tr}(\mathbf{f}^T (W^8 + W^{SR}) \mathbf{f}) + \\ &\lambda (\mathbf{f} - \mathbf{b})^T M (\mathbf{f} - \mathbf{b}) = \\ &\text{tr}(\mathbf{f}^T L \mathbf{f}) + \lambda (\mathbf{f} - \mathbf{b})^T M (\mathbf{f} - \mathbf{b}) \end{aligned} \quad (17)$$

其中, $\mathbf{f} = (f_1, f_2, \dots, f_n)^T$ 和 $\mathbf{b} = (b_1, b_2, \dots, b_n)^T$ 分别表示概率和指示向量. $(\cdot)^T$ 表示矩阵的转置. $M = \text{diag}\{m_1, \dots, m_n\}$ 是一个对角矩阵. 如果顶点是种子点, 那么它的对角元素是 1, 否则为 0. $L = W^8 + W^{SR}$ 是一个 Laplacian 矩阵, 它的定义如式 (18) 所示.

$$L_{ij} = \begin{cases} W^8 + W^{SR}, & \text{如果 } i = j \\ W^8, & \text{如果 } e_{ij} \in E^8 \\ W^{SR}, & \text{如果 } e_{ij} \in E^{SR} \\ 0, & \text{否则} \end{cases} \quad (18)$$

最后, 将式 (17) 求关于 \mathbf{f} 的导数来解稀疏线性方程式, 从而获得未标记顶点的概率值. 本文将概率值 $f_i \geq 0$ 的未标记顶点安排到结节类. 反之, 将概率 $f_i < 0$ 的未标记顶点安排到背景类, 从而获得图像的最终分割结果. 求解的计算式如式 (19) 所示.

$$\mathbf{f} = (L + \lambda M)^{-1} \lambda M \mathbf{b} \quad (19)$$


5 实验结果和分析

本文采用数据库 LIDC^[34] 验证提出算法的准确性和有效性. 该数据库共收录了 1018 个病例. 对于每一个病例的 XML 文件, 记录了 4 位经验丰富的胸部放射科医生对直径大于 3 毫米的肺结节轮


廓点的坐标. 本文将 4 位医生勾画结果经协商达成一致所对应的结节轮廓作为金标准. 本文从 LIDC 中随机地选取 100 个带有不同形状、大小和纹理的 GGO 结节图像. 全部图像像素点的灰度值范围被归一化在 0~255 之间. 实验硬件环境为 CPU Intel (R) Xeon (R) E3-1225 v5, 主频 3.30 GHz; 内存 4.00 GB; 显卡 Intel (R) Ethernet Connection (2) 1219-LM. 实验软件环境为 MATLAB R2016b 开发平台.

5.1 SRRW 算法的参数设置

为了设置合理的参数值, 本文通过对参数设置不同参数值进行了对比实验. 在种子点自动获取过程中, 主要有四个参数: 阈值 T , κ , γ 和 T_b . 参数 T 决定了在小区域 R_0 像素的个数. 参数 κ 决定了在区域 R 的边缘上像素点的个数. 图 5 显示了在参数 T 和 κ 选取不同值时, 结节种子点的选取情况. 图 5(a) 和图 5(b) 分别是在 $T = 1, \kappa = 5$ 和 $\kappa = 10$ 时结节种子点个数. 图 5(c) 和图 5(d) 分别是在 $T = 4, \kappa = 5$ 和 $\kappa = 10$ 时结节种子点情况. 图 5(e)~(h) 是 SRRW 算法所对应的分割结果. 从图 5(e) 中可以看出, 当结节种子点远远小于背景种子点时, SRRW 算法会出现严重的过分割现象. 但是, 当增加 κ 值时, 过分割现象会得到一定程度上缓解. 因此, 参数 κ 设置为 10 时, 能够产生好的分割结果. 在本文中, 参数 T 设置范围为 3 毫米到 35 毫米, 覆盖所有大小结节. 在背景种子点选取过程中, 参数 T_b 设定范围很广泛, 在本文所有实验中设定为 100. 类似于此对比实验方法, 参数 γ 经多次试验设定为 5.



(a) $T = 1, \kappa = 5$ (b) $T = 1, \kappa = 10$ (c) $T = 4, \kappa = 5$ (d) $T = 4, \kappa = 10$
 (a) $T = 1, \kappa = 5$ (b) $T = 1, \kappa = 10$ (c) $T = 4, \kappa = 5$ (d) $T = 4, \kappa = 10$




(e) (a) 的结果 (f) (b) 的结果 (g) (c) 的结果 (h) (d) 的结果
 (e) Result of (a) (f) Result of (b) (g) Result of (c) (h) Result of (d)


图 5 T 和 κ 取不同值时结节种子点选取和对应的分割结果
 Fig. 5 Seed selection and the corresponding segmentation results when using different T and κ

在能量函数定义中, 式 (14) 中参数 λ 控制标签限制项的作用. 当 λ 设定为 0 时, SRRW 算法的标


签限制项不起作用. 图 6 显示了不同 λ 值时 SRRW 算法获取的分割结果. 图 6(b)~(d) 分别是 $\lambda = 10, \lambda = 100$ 和 $\lambda = 1000$ 时 SRRW 算法分割结果. 从图 6(b) 结果可以看出, 结节分割可能会出现过分割现象, 这是因为标签限制项起到很小的作用. 随着 λ 的增大, 标签限制项的作用会越来越大. 当 $\lambda = 100$ 时可以得到更准确的分割结果, 如图 6(c) 所示. 但是, 当 λ 取值过大时, 结节分割会出现严重的分割错误, 如图 6(d) 所示. 因此, 经多次实验, 本文设定 $\lambda = 100$, 执行了所有实验.




(a) 原始 CT 图像
 (a) Original CT images



(b) $\lambda = 10$ 时 SRRW 获取的分割结果
 (b) Results obtained by SRRW with $\lambda = 10$



(c) $\lambda = 100$ 时 SRRW 获取的分割结果
 (c) Results obtained by SRRW with $\lambda = 100$



(d) $\lambda = 1000$ 时 SRRW 获取的分割结果
 (d) Results obtained by SRRW with $\lambda = 1000$

图 6 不同 λ 时本文提出的 SRRW 算法分割的结果
 Fig. 6 Segmentation results of the proposed SRRW algorithm with different λ

5.2 定性 SRRW 算法分割结果的分析与对比

为了验证本文提出的局部搜索策略获取的结节种子点的有效性, 本文在选取不同的结节种子点时, 利用提出的 SRRW 算法对 GGO 结节进行分割. 结节种子点获取方法分别是测地距离方法和测地距离、局部搜索策略联合. 图 7 是一个典型 GGO 肺结节分割的过程. 图 7(a) 是原始 CT 图像, 图 7(b) 和 7(c) 分别显示了局部搜索策略获取的背景种子点和测地距离获取的结节种子点, 图 7(d) 显示了测地

距离、局部搜索策略联合所获取的全部结节种子点. 图 7(e) 和 7(f) 分别是利用图 7(c) 和 7(d) 结节种子点时 SRRW 算法的分割结果. 从图 7(c) 可以观察到, 测地距离获取的结节种子点集中于 GGO 肺结节灰度均匀区域, 导致了分割结果不理想(图 7(e) 所示). 相反, 利用图 7(d) 的结节种子点, SRRW 算法能够获取更准确的分割结果, 如图 7(f) 所示. 实验结果表明, 本文提出的局部搜索策略获取的结节种子点能够提高 SRRW 算法的准确性.

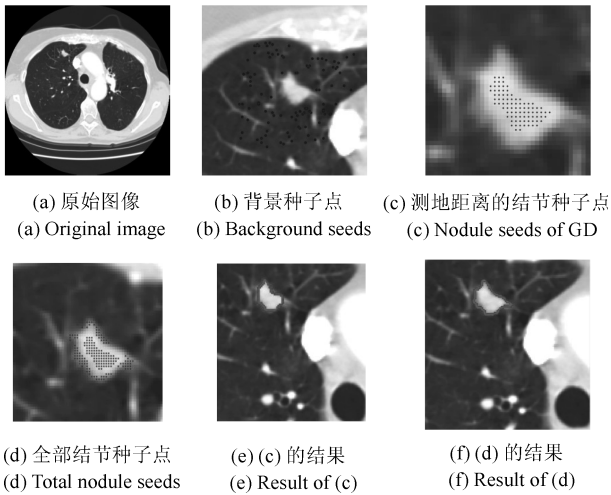


图 7 不同的结节种子点时 SRRW 算法的 GGO 结节分割
Fig. 7 GGO nodule segmentation of SRRW algorithm using different nodule seeds

为了验证 SRRW 算法分割的准确性, 本文采用了传统 RW^[22]、RWR^[35]、SubRW 算法^[36] 与 SRRW 算法进行了一个对比实验. 为了公平起见, 所有算法均采用了本文获取的种子点. 图 8(a)~(d) 分别是 RW、RWR、SubRW 和 SRRW 算法所分割结果的放大图. 从图 8(a) 中可以观察到, RW 对 GGO 结节进行分割时产生边界泄露问题. 这是因为 RW 仅采用了 4-或 8-邻域的搜索策略进行图构建, 且仅利用灰度信息描述相邻顶点之间的相似性, 这对结节内部灰度分布不均匀且变化较大的 GGO 结节分割来说是无效的. RWR 算法获得了更好的分割结果, 如图 8(b) 所示. 这是因为 RWR 从一个顶点出发, 以一定的概率转移到其邻域点, 并且反复迭代, 这使得算法能够捕捉图的整体结构信息, 提高了分割的准确性. 由于 SubRW 引入了标签先验知识, 其获得了更好的分割结果, 如图 8(c) 所示. 然而, SubRW 仍然未解决噪声敏感性问题. 本文提出的 SRRW 算法的分割结果更接近于结节边界, 如图 8(d) 所示. 这是因为提出的算法联合了 8-邻域和稀疏表示的 K-最近邻算法, 获得了更可靠的顶点邻域关系, 捕捉了更多的结构信息, 从而提高了肺结节分割的准确性.




图 8 RW、RWR、SubRW 和 SRRW 对 GGO 结节分割结果

Fig. 8 Segmentation results of GGO nodule by using RW, RWR, SubRW and SRRW

为了进一步验证 SRRW 算法的准确性, 本文随机地选择 4 个具有不同大小和形状的 GGO 结节图像. 图 9 显示了肺结节的分割结果. 图 9(a) 是原始 CT 图像, 图 9(b) 是 SRRW 分割结果的放大图和金标准. 从图 9(b) 中可以观察到, SRRW 算法的分割结果视觉上几乎接近于金标准. 实验结果表明了本文提出的 SRRW 算法能够准确分割各式各样的 GGO 肺结节.

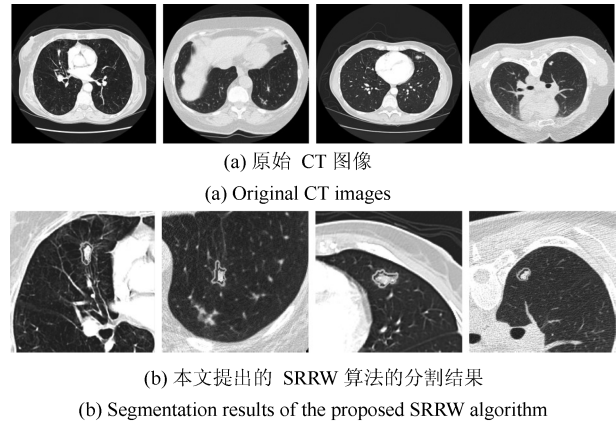


图 9 SRRW 算法分割结果

Fig. 9 Segmentation results of the SRRW algorithm

为了验证 SRRW 算法对一个 CT 图像序列的分割性能, 本文利用了提出的 SRRW 算法对含有 GGO 肺结节的所有 CT 切片进行分割. 首先, 利用 SRRW 算法对单张肺结节切片进行分割. 然后, 考虑到在连续断层 CT 图像上肺结节位置特征以及当前切片与相邻的上下切片对应的特征的相似性, 本

文从单片分割的肺结节寻找肺结节的中心位置, 然后选取相应的结节和背景种子点进行连续切片的分割. 图 10 显示了提出的 SRRW 算法对一个 CT 序列图像的 GGO 结节的分割结果. 图 10 (a) 和 10 (b) 分别是带有 GGO 肺结节的 CT 序列图像和对应放大的结节区域. 图 10 (c) 是提出的 SRRW 算法的分割结果和金标准. 从图 10 (c) 我们可以观察到, 提出的算法能够准确地分割一个 GGO 肺结节序列图像.

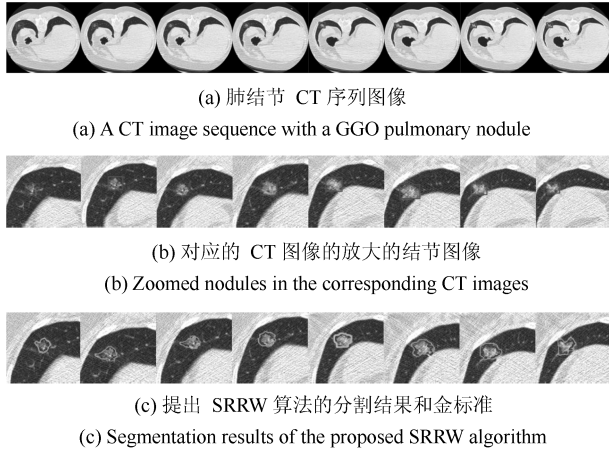


图 10 本文提出 SRRW 算法对 GGO 结节序列图像分割
Fig. 10 Segmentation of the proposed SRRW algorithm in a CT image sequence with a GGO nodule

5.3 定量 SRRW 算法分割结果的分析与对比

为了定量地验证本文提出 SRRW 算法的准确性和有效性, 本文采用了 *Overlap* 作为分割的评价指标. 它测量了算法的分割结果和金标准之间的重叠面积比, 计算公式如式 (20) 所示.

$$Overlap = \frac{|S_A \cap S_{GT}|}{|S_A \cup S_{GT}|} \quad (20)$$

其中, S_A 和 S_{GT} 分别是算法分割结果和金标准. $|S_A \cap S_{GT}|$ 是既包含 S_A 又包含 S_{GT} 的像素个数. $|S_A \cup S_{GT}|$ 表示包含 S_A 或 S_{GT} 或包含两者的像素个数. 在理想情况下, 一个分割结果越准确, *Overlap* 值越接近 1.

首先, 本文从 LIDC 数据库中随机地选取 100 个带有 GGO 肺结节的 CT 图像进行一个对比实验. 为了验证提出算法能够分割不同样式的 GGO 肺结节, 选取的 100 个图像尽可能包含大小各异、形状各异、纹理不同及灰度分布不均的 GGO 结节. 本文在 100 个数据样本结果中随机地选取 10 个数据的 *Overlap* 值列举在表 1. 从表 1 中可以看出, 与传统 RW 算法^[22]、SubRW 算法^[36], 本文提出的 SRRW 算法获得了较高 *Overlap* 平均值和较低方差值. 实验结果表明, 提出的 SRRW 算法具有较高的分割准确性和较强的鲁棒性.

为了统计提出的算法在种子点选取过程中的执行时间, 本文从 100 个样本分割结果中随机选取 10 个样本的种子点选取的执行时间列举在表 2. 从列表 2 中可以看出, 提出的种子点的选取在 10 个数据上执行时间平均为 0.2136 秒. 实验结果表明了提出的自动种子点选取策略的有效性.

表 1 SRRW、RW 和 SubRW 算法的 *Overlap* 值对比
Table 1 Comparison results of *Overlap* values among SRRW、RW and SubRW algorithms

CT 图像	SRRW 算法	RW 算法	SubRW 算法
LIDC-000498	0.9145	0.8534	0.8942
LIDC-000058	0.9324	0.9164	0.9632
LIDC-000125	0.8652	0.8432	0.8223
LIDC-000043	0.8942	0.9473	0.9024
LIDC-000074	0.9724	0.9636	0.9475
LIDC-000119	0.8148	0.7647	0.8086
LIDC-000063	0.9025	0.8437	0.8946
LIDC-000054	0.9438	0.9421	0.9676
LIDC-000106	0.8142	0.7642	0.8247
LIDC-000116	0.9798	0.9075	0.9248
Mean	0.9034	0.8746	0.8950
Std.	0.0583	0.0725	0.0590

表 2 本文的种子点选择策略的执行时间

Table 2 Execution times of seed selection strategy

序列号	执行时间 (s)	序列号	执行时间 (s)
1	0.2554	6	0.2054
2	0.2087	7	0.2081
3	0.2122	8	0.2225
4	0.2069	9	0.2041
5	0.2067	10	0.2060

5.4 定量 SRRW 算法与其他分割算法的对比

为了进一步定量地验证 SRRW 算法的有效性, 本文采用了 *Overlap* 作为分割精度的评价指标, 用本文提出的算法与其他分割算法进行了一个对比. 表 3 列出了不同分割算法的 *Overlap* 平均值. Okada K 等^[37] 获得了相对较低的 *Overlap* 平均值 (0.45), 这是因为该算法将肺结节模拟为椭圆形, 不能很好地处理形状不规则的 GGO 肺结节. Kostis 等^[38] 也获取了较低的 *Overlap* 平均值 (0.57). Kuhnigk 等^[9] 采用了形态学开运算方法分割形状规则的小肺结节, 也不能很好地处理 GGO 肺结节. Kubota 等^[7] 提出了扩散竞争和区域增长混合算法, 获得的 *Overlap* 平均值为 0.66, 相比于 Kuhnigk 等提出算法的分割结果具有较大提高. 最近, Messay 等^[39] 提出了回归神经网络算法, 获取了较高的分割性能. 该算法获得的 *Overlap* 平均值为 0.77. 然而, 算法需

要人工提供控制点, 达到提高分割精度的目的. 本文提出的 SRRW 算法获取 Overlap 值为 0.91, 得到了较为满意的 Overlap 值. 实验结果表明了 SRRW 算法对 GGO 肺结节分割的有效性.

表 3 不同肺结节分割算法的 Overlap 值的对比

Table 3 Comparisons of Overlap values among different pulmonary nodule segmentation algorithms

分割算法	Overlap
Kostis ^[38]	0.57 ± 0.20
Okada 等 ^[37]	0.45 ± 0.21
Kuhnigk 等 ^[9]	0.56 ± 0.18
Kubota 等 ^[7]	0.66 ± 0.18
Messay 等 ^[39]	0.77 ± 0.09
本文提出的 SRRW 算法	0.91 ± 0.04

6 结论


本文提出了基于稀疏表示和随机游走 (SRRW) 算法对磨玻璃型肺结节进行分割. 本文提出了自动选取结节和背景种子点方法, 减少了人工干预. 采用基于 8-邻域和稀疏表示的 K-NN 方法构建了一个新加权图, 避免了 CT 图像噪声和伪影干扰. 通过整合灰度、纹理和空间距离和稀疏系数构建了一个新加权矩阵, 更有效地衡量了相邻顶点之间的相似性关系. 最后, 引入标签限制项到 RW 能量函数中, 提高了对 GGO 肺结节分割的准确性. 通过定量和定性对比实验可以看出, 本文提出的算法对 GGO 肺结节分割的准确性和有效性. 下一步研究主要集中于进一步优化提出的模型, 并将该算法扩展到对任意类型肺结节的分割.

References

- Aberle D R, Adams A M, Berg C D, Black W C, Clapp J D, Fagerstrom R M, et al. Reduced lung-cancer mortality with low-dose computed tomographic screening. *New England Journal of Medicine*, 2011, **365**(5): 395–409
- Lambin P, Rios-Velazquez E, Leijenaar R, Carvalho S, van Stiphout R G P M, Granton P, et al. Radiomics: extracting more information from medical images using advanced feature analysis. *European Journal of Cancer*, 2012, **48**(4): 441–446
- Henschke C I, Yankelevitz D F, Mirtcheva R, McGuinness G, McCauley D, Miettinen O S. CT screening for lung cancer: frequency and significance of part-solid and nonsolid nodules. *American Journal of Roentgenology*, 2002, **178**(4): 1053–1057
- Han Guang-Hui, Liu Xia-Bi, Zheng Guang-Yuan. Automated detection of lesion regions in lung computed tomography images: a review. *Acta Automatica Sinica*, 2017, **43**(12): 2071–2090
(韩光辉, 刘峡壁, 郑光远. 肺部 CT 图像病变区域检测方法. 自动化学报, 2017, **43**(12): 2071–2090)
- Reeves A P, Chan A B, Yankelevitz D F, Henschke C I, Kressler B, Kostis W J. On measuring the change in size of pulmonary nodules. *IEEE Transactions on Medical Imaging*, 2006, **25**(4): 435–450
- Dehmeshki J, Amin H, Valdivieso M, Ye X J. Segmentation of pulmonary nodules in thoracic CT scans: a region growing approach. *IEEE Transactions on Medical Imaging*, 2008, **27**(4): 467–480
- Kubota T, Jerebko A K, Dewan M, Salganicoff M, Krishnan A. Segmentation of pulmonary nodules of various densities with morphological approaches and convexity models. *Medical Image Analysis*, 2011, **15**(1): 133–154
- Nithila E E, Kumar S S. Segmentation of lung nodule in CT data using active contour model and Fuzzy C-mean clustering. *Alexandria Engineering Journal*, 2016, **55**(3): 2583–2588
- Kuhnigk J M, Dicken V, Bornemann L, Bakai A, Wormanns D, Krass S, et al. Morphological segmentation and partial volume analysis for volumetry of solid pulmonary lesions in thoracic CT scans. *IEEE Transactions on Medical Imaging*, 2006, **25**(4): 417–434
- Aoyama M, Li Q, Katsuragawa S, Li F, Sone S, Doi K. Computerized scheme for determination of the likelihood measure of malignancy for pulmonary nodules on low-dose CT images. *Medical Physics*, 2003, **30**(3): 387–394
- Diciotti S, Lombardo S, Falchini M, Picozzi G, Mascali M. Automated segmentation refinement of small lung nodules in CT scans by local shape analysis. *IEEE Transactions on Biomedical Engineering*, 2011, **58**(12): 3418–3428
- Ye X J, Lin X Y, Dehmeshki J, Slabaugh G, Beddoe G. Shape-based computer-aided detection of lung nodules in thoracic CT images. *IEEE Transactions on Biomedical Engineering*, 2009, **56**(7): 1810–1820
- Sun Wen-Yan, Dong En-Qing, Cao Zhu-Lou, Zheng Qiang. A robust local segmentation method based on fuzzy-energy based active contour. *Acta Automatica Sinica*, 2017, **43**(4): 611–621
(孙文燕, 董恩清, 曹祝楼, 郑强. 一种基于模糊主动轮廓的棒棒局部分割方法. 自动化学报, 2017, **43**(4): 611–621)
- Chen Kan, Li Bin, Tian Lian-Fang. A segmentation algorithm of pulmonary nodules using active contour model based on fuzzy speed function. *Acta Automatica Sinica*, 2013, **39**(8): 1257–1264
(陈侃, 李彬, 田联房. 基于模糊速度函数的活动轮廓模型的肺结节分割. 自动化学报, 2013, **39**(8): 1257–1264)

- 15 Keshani M, Azimifar Z, Tajeripour F, Boostani R. Lung nodule segmentation and recognition using SVM classifier and active contour modeling: a complete intelligent system. *Computers in Biology and Medicine*, 2013, **43**(4): 287–300
- 16 Zhu Y J, Tan Y Q, Hua Y Q, Zhang G Z, Zhang J G. Automatic segmentation of ground-glass opacities in lung CT images by using Markov random field-based algorithms. *Journal of Digital Imaging*, 2012, **25**(3): 409–422
- 17 Li C F, Nie S D, Wang Y J, Sun X W, Zhang B. Segmentation of sub-solid pulmonary nodules based on improved fuzzy C-means clustering. *Journal of Image and Graphics*, 2013, **18**(8): 1019–1030
- 18 Li B, Chen K, Peng G M, Guo Y X, Tian L F, Ou S X, et al. Segmentation of ground glass opacity pulmonary nodules using an integrated active contour model with wavelet energy-based adaptive local energy and posterior probability-based speed function. *Materials Express*, 2016, **6**(4): 317–327
- 19 Li B, Chen Q L, Peng G M, Guo Y X, Chen K, Tian L F, et al. Segmentation of pulmonary nodules using adaptive local region energy with probability density function-based similarity distance and multi-features clustering. *Biomedical Engineering Online*, 2016, **15**(1): 49–77
- 20 Cheng J Z, Ni D, Chou Y H, Qin J, Tiu C M, Chang Y C, et al. Computer-aided diagnosis with deep learning architecture: applications to breast lesions in US images and pulmonary nodules in CT scans. *Scientific Reports*, 2016, **6**: 24454
- 21 Wang S, Zhou M, Liu Z Y, Liu Z Y, Gu D S, Zang Y L, et al. Central focused convolutional neural networks: developing a data-driven model for lung nodule segmentation. *Medical Image Analysis*, 2017, **40**: 172–183
- 22 Grady L. Random walks for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, **28**(11): 1768–1783
- 23 Eslami A, Karamalis A, Katouzian A, Navab N. Segmentation by retrieval with guided random walks: application to left ventricle segmentation in MRI. *Medical Image Analysis*, 2013, **17**(2): 236–253
- 24 Onoma D P, Ruan S, Thureau S, Nkhali L, Modzelewski R, Monnehan G A, et al. Segmentation of heterogeneous or small FDG PET positive tissue based on a 3D-locally adaptive random walk algorithm. *Computerized Medical Imaging and Graphics*, 2014, **38**(8): 753–763
- 25 Wang Q, Lu L, Wu D J, El-Zehiry N, Zheng Y F, Shen D G, et al. Automatic segmentation of spinal canals in CT images via iterative topology refinement. *IEEE Transactions on Medical Imaging*, 2015, **34**(8): 1694–1704
- 26 Mi H M, Petitjean C, Vera P, Ruan S. Joint tumor growth prediction and tumor segmentation on therapeutic follow-up PET images. *Medical Image Analysis*, 2015, **23**(1): 84–91
- 27 Fan M Y, Gu N N, Qiao H, Zhang B. Sparse regularization for semi-supervised classification. *Pattern Recognition*, 2011, **44**(8): 1777–1784
- 28 Liu G C, Lin Z C, Yan S C, Sun J, Yu Y, Ma Y. Robust recovery of subspace structures by low-rank representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, **35**(1): 171–184
- 29 Li S, Fu Y. Learning balanced and unbalanced graphs via low-rank coding. *IEEE Transactions on Knowledge and Data Engineering*, 2015, **27**(5): 1274–1287
- 30 Fu Y F, Gao J B, Tien D, Lin Z C, Hong X. Tensor LRR and sparse coding-based subspace clustering. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, **27**(10): 2120–2133
- 31 Zhuang L S, Zhou Z H, Gao S H, Yin J W, Lin Z C, Ma Y. Label information guided graph construction for semi-supervised learning. *IEEE Transactions on Image Processing*, 2017, **26**(9): 4182–4192
- 32 Liao Y Y, Wang Y, Liu Y. Graph regularized auto-encoders for image representation. *IEEE Transactions on Image Processing*, 2017, **26**(2): 2839–2852
- 33 Yuan H X, Wu S Q, Cheng P H, An P, Bao S D. Nonlocal random walks algorithm for semi-automatic 2D-to-3D image conversion. *IEEE Signal Processing Letters*, 2015, **22**(3): 371–374
- 34 Armato S G, McLennan G, Bidaut L, McNitt-Gray M F, Meyer C R, Reeves A P, et al. The lung image database consortium (LIDC) and image database resource initiative (IDRI): a completed reference database of lung nodules on CT scans. *Medical Physics*, 2011, **38**(2): 915–931
- 35 Kim T H, Lee K M, Lee S U. Generative image segmentation using random walks with restart. In: *Proceedings of the 10th European Conference on Computer Vision*. Marseille, France: Springer-Verlag, 2008. 264–275
- 36 Dong X P, Shen J B, Shao L, van Gool L. Sub-Markov random walk for image segmentation. *IEEE Transactions on Image Processing*, 2016, **25**(2): 516–527
- 37 Okada K, Comaniciu D, Krishnan A. Robust anisotropic Gaussian fitting for volumetric characterization of Pulmonary nodules in multislice CT. *IEEE Transactions on Medical Imaging*, 2005, **24**(3): 409–423

- 38 Kostis W J, Reeves A P, Yankelevitz D F, Henschke C I. Three-dimensional segmentation and growth-rate estimation of small pulmonary nodules in helical CT images. *IEEE Transactions on Medical Imaging*, 2003, **22**(10): 1259–1274
- 39 Messay T, Hardie R C, Tuinstra 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. *Medical Image Analysis*, 2015, **22**(1): 48–62



李祥霞 华南理工大学自动化科学与工程学院博士研究生. 主要研究方向为医学图像处理与模式识别.

E-mail: lixiangxia8888@163.com

(**LI Xiang-Xia** Ph.D. candidate at the School of Automation Science and Engineering, South China University of Technology. Her research interest covers

medical image processing and pattern recognition.)



李彬 博士, 华南理工大学自动化科学与工程学院副教授. 主要研究方向为医学图像处理与模式识别. 本文通信作者.

E-mail: binlee@scut.edu.cn

(**LI Bin** Ph.D., associate professor at the School of Automation Science and Engineering, South China University of Technology. His research interest covers

medical image processing and pattern recognition. Corresponding author of this paper.)



田联房 博士, 华南理工大学自动化科学与工程学院教授. 主要研究方向为医学图像处理与模式识别.

E-mail: chlftian@scut.edu.cn

(**TIAN Lian-Fang** Ph.D., professor at the School of Automation Science and Engineering, South China University of Technology. His research interest covers medical image processing and pattern recognition.)




张莉 华南理工大学自动化科学与工程学院博士研究生. 主要研究方向为医学图像处理与模式识别.

E-mail: 88zhangli0622@163.com

(**ZHANG Li** Ph.D. candidate at the School of Automation Science and Engineering, South China University of Technology. Her research interest covers

medical image processing and pattern recognition.)



朱文博 佛山科学技术学院自动化学院助教. 主要研究方向为医学图像处理与模式识别.

E-mail: zhuwenbo@fosu.edu.cn

(**ZHU Wen-Bo** Assistant professor at the School of automation, Foshan University. His research interest covers medical image processing and pattern

recognition.)