

基于稀疏表示超像素分类的肿瘤超声图像分割算法

张绿川, 杨 艳

武汉大学物理科学与技术学院, 湖北 武汉 430072

【摘要】目的:图像中目标的识别与分割一直是图像处理的研究热点。本文针对超声图像提出了一种新的基于超像素区域特征的肿瘤识别分割算法。**方法:**首先利用简单线性迭代聚类算法产生超像素,将图像分为多个内部特征相似的图像块,然后提取每个区域的特征组成该区域特征向量,利用稀疏表示分类算法(Sparse Representation Classification, SRC)构造分类器,对超像素进行分类合并,最终识别并分割出完整的感兴趣区域。**结果:**本文的算法在超声图像中肿瘤的识别与分割中取得较为理想的效果,灵敏度指数平均值达到了83.79%,标准化的Hausdorff距离指数平均值达到了4.80%。**结论:**本文的分割算法克服了SRC算法不能获得目标区域完整轮廓的缺陷,并取得了较好的实验结果,为超声图像中肿瘤的识别与分割提供了新思路。

【关键词】稀疏表示;超声图像;肿瘤分割;简单线性迭代聚类

【中图分类号】TP391;R312

【文献标识码】A

【文章编号】1005-202X(2015)06-0855-05

Tumor ultrasound image segmentation algorithm based on sparse representation of superpixel clustering

ZHANG Lü-chuan, YANG Yan

School of Physics and Technology, Wuhan University, Wuhan 430072, China

Abstract: Objective Target recognition and segmentation of image has been a hot research topic in image processing. A new tumor segmentation algorithm based on the superpixel area characteristic in ultrasonic image is proposed. **Methods** Simple linear iterative clustering (SLIC) algorithm was firstly applied to produce superpixel, dividing the image into multiple image blocks with similar characteristics. And then, the feature of each region was extracted as feature vector. Classifier was constructed by sparse representation classification (SRC) algorithm, classifying and merging the superpixels. Finally, the complete interesting regions were identified and segmented. **Results** The algorithm for the tumor identification and segmentation in ultrasound image achieved satisfactory effects. The average value of sensitivity index reached 83.79%, and the average value of normal Hausdorff distance reached 4.80%. **Conclusion** The proposed algorithm overcomes the disadvantage of SRC algorithm which cannot obtain the complete contour of target region, achieving better experimental results and providing a new thought for the tumor recognition and segmentation of ultrasound images.

Key words: sparse representation; ultrasound image; tumor segmentation; simple linear iterative clustering

前言

图像导航的核心任务是准确快速地识别并分割出感兴趣区域。利用图像分割算法实现图像导航的自动化,减少人为干预,不仅可以提高治疗效率,还

可以降低人工划分肿瘤边界的不准确度,提高治疗效果。目前在医学图像中已经研究出很多有关目标的识别与分割的算法^[1],一些算法也因其效果的优越性而应用于治疗设备中。

稀疏表示(Sparse Representation Classification, SRC)算法利用超完备字典从一个全新的角度对信号进行了建模与解释,已经受到了研究人员的广泛关注和深入研究。SRC算法将信号表示为字典中原子线性的组合,再用稀疏编码求解出各个原子相应的系数,实现信号的分解。该算法迅速应用于计算机

【收稿日期】2015-08-19

【基金项目】国家重点基础研究发展计划(973计划)项目(2011CB707900)

【作者简介】张绿川(1989-),硕士,研究方向:医学图像处理。Tel: 18571517210;E-mail: lvchuan@whu.edu.cn。

【通信作者】杨 艳(1964-),博士,副教授,研究方向:信号与图像处理。Tel: 18064033906;E-mail: xhsslc@163.com。

视觉与多媒体交互等多个领域中,如图像压缩^[2]、图像去噪^[3]、人脸识别^[4]等。同时SRC算法也在图像分割中得到了应用,在Rosas-Romero等^[5]的文章中,将SRC算法应用于超声图像,识别与分割出实验鼠的

心内膜,图1是该算法在超声图像肿瘤分割的实验结果。但由于该算法本身基于单个像素点,分割结果只能得到属于肿瘤区域的大部分像素点,不能够得到完整的肿瘤轮廓。




图1 基于单像素点的肿瘤分割

Fig.1 Tumor segmentation based on single pixel

本文受到超像素预分割算法^[6]的启发,将SRC算法从单个像素点扩展到超像素点上,提出了一种新的超声图像中肿瘤的识别与分割算法,克服了SRC算法不能得到目标区域完整轮廓的缺点。利用SRC对超像素进行分类合并时,首先构造初始类别字典,即目标区域字典与非目标区域字典。为了使字典中的原子最大限度地表征超像素的区域特征,本文在原子中加入了超像素的灰度信息、位置信息、统计参数以及其他的结构信息^[7]。然后对目标图像中超像素的特征向量分别使用初始类别字典进行稀疏编码,将特征向量转化为残差向量,计算其模值,找到最小值以及其对应的类别,使用该类别标记超像素,最后将标记为同一类别的超像素合并,得到图像目标区域的完整轮廓。

1 分割算法分析

1.1 简单线性迭代聚类(Simple Linear Iterative Clustering, SLIC)算法预分割

超像素是许多内部灰度相对均匀的小区域,目前有很多分割方法适用于产生超像素,包括基于图的方法如Ncut算法^[8]等和基于梯度上升的方法如均值漂移^[9]、Turbopixels^[10]等。其中SLIC算法具有计算量小、运行速度快、效率高等优点^[11]。因此本文选择SLIC算法来产生超像素。

一幅包含 N 个像素点的灰度图像 $I(x,y)$,产生 K 个超像素,则 N/K 为超像素内包含像素点的平均个数,相邻超像素中心点的平均距 $S = \sqrt{N/K}$ 。在超像

素聚类时首先提取像素点的特征信息 $f_n = [I(x,y), x, y] \in R^3$,其中 x 、 y 、 $I(x,y)$ 为像素点的笛卡尔位置坐标和其对应位置的灰度值。像素点之间的距离 $D_{n_i,j}$ 为:

$$d_g = \sqrt{(I(x_{n_i}, y_{n_i}) - I(x_{n_j}, y_{n_j}))^2} \quad (1)$$

$$d_l = \sqrt{(x_{n_i} - x_{n_j})^2 + (y_{n_i} - y_{n_j})^2} \quad (2)$$

$$D_{n_i,j} = \sqrt{\left(\frac{d_g}{M}\right)^2 + \left(\frac{d_l}{S}\right)^2} \quad (3)$$

其中 d_g 和 d_l 分别是像素间的灰度差(灰度值距离)和几何距离, $D_{n_i,j}$ 是利用平均距归一化后的灰度值距离和坐标距离之和。 M 为一个变量控制了超像素的紧密度,取 $M=2$ 。

聚类时首先在图像中以 S 个像素点为间隔选取 K 个像素点为初始聚类中心 $C = [C_1, C_2, \dots, C_k]^T$ 。在聚类中心周围 $2S \times 2S$ 的正方形邻域内按照距离 D_i 分配与聚类中心距离最近的像素点给每个聚类中心 C_i 。取聚类后属于同一类的所有像素点的坐标的均值作为新的聚类中心。然后交替进行聚类以及聚类中心的更新,文中的迭代次数设为10。

1.2 超像素的分类合并

1.2.1 构造初始字典 不同病人的超声肿瘤图片的特征不尽相同,需要保证训练集图片中先验信息的多样性。本文选取了30位病人的超声肿瘤图片作为训练集,所有的图片均由专家标定出肿瘤区域的完整轮廓,在每幅图片的肿瘤区域与非肿瘤区域提取特

征向量作为相应字典的原子,将原子按列排列组成字典,即肿瘤区域字典和非肿瘤区域字典。

特征向量 $f_i \in R^N$ 包含了超像素 s_i 的特征信息: 灰度信息、统计信息、位置信息。统计各个超像素内像素点的灰度值 $N(s_i) \in R^m$ 、笛卡尔坐标 $O_i \in R^{2 \times n}$, 其中 m 为像素点的个数,再对上述集合进行统计,得到其灰度值的最大值 $\text{Max}(N(s_i))$ 、最小值 $\text{Min}(N(s_i))$ 、众数 $\text{Mode}(N(s_i))$ 、中位数 $\text{Medi}(N(s_i))$ 、平均值 $\overline{N(s_i)}$ 、方差 $\text{std}(N(s_i))$ 以及笛卡尔坐标纵坐标均值 $\overline{O^y(s_i)}$ 、横坐标均值 $\overline{O^x(s_i)}$ 。由于不同尺寸的图片中像素点坐标的取值范围不同,因此需要对坐标值进行标准化,文中图片为8位灰度图像,像素点灰度范围为 $0 \leq n_j \leq 255$, 因此对坐标值进行如下标准化:

$$O_i(s_i) = \begin{bmatrix} O_i^x(s_i) = o_i^x * 255 / \text{len} \\ O_i^y(s_i) = o_i^y * 255 / \text{hig} \end{bmatrix} \quad (4)$$

其中 len, hig 为图片的宽与高。将上述信息首尾相连构成 s_i 的特征向量。

将肿瘤区域和非肿瘤区域提取的所有特征向量分别按列排列,即可以得到初始化的肿瘤区域字典 D_t 与非肿瘤区域字典 D_n 。

1.2.2 稀疏编码 过完备字典 $D \in R^{n \times K} (K > n)$, 是由原子 $\{d_j\}_{j=1}^K \in R^n$ 组成的。信号 x 可以近似地表示为字典中几个原子的线性组合 $y = \sum_{i=1}^K a_i d_i = Da$, 其中向量 $a \in R^K$ 为稀疏表示的系数向量。由于字典 D 为过完备矩阵,系数向量 $a \in R^K$ 有无数组解,为了保证解的确定性,需要加入约束条件:当解中包含非零系数最少时我们可以得到信号最稀疏的分解:

$$\min_a \|a\|_0 \text{ subject to } y = Da \quad (5)$$

多数情况下信号 y 的稀疏分解存在一定的误差,加入边界误差 ε :

$$\min_a \|a\|_0 \text{ subject to } \|y - Da\|_2 \leq \varepsilon \quad (6)$$

其中 $\|\cdot\|_0$ 是 l^0 范数,即系数向量中的非零元素的个数。

精确的求解上述稀疏表示问题已经被证明是NP难解问题,目前最常用的近似算法有MP算法^[12]和OMP算法^[13]。由于OMP算法在递归中对已选择集合进行了正交化处理,保证了每次迭代的结果都是最优的,从而加快收敛速度,提高算法效率。因此本文选择OMP算法进行稀疏编码。

1.2.3 分割算法 信号的稀疏表示可以对信号进行识别分类,利用带有不同先验信息的初始字典分别对

信号 y 进行转换 $y \approx Da = \hat{y}$ 。显然使用不同字典 $\{D_i\}_{i=1}^M \in R^{n \times K}$ 转换信号 y 时,合成信号与原信号之间会存在不同的残差 $r_i(y, D_i)$:

$$r_i(y, D_i) = \min_a [\|y - Da\|_2^2 + \lambda \|a\|_0] \quad (7)$$

其中 $\vec{r}_i(y, D_i)$ 为残差向量,利用 l^2 范数表示信号 y 与合成信号 $\hat{y} = Da$ 之间的误差 $r_i = \|\vec{r}_i(y, D_i)\|_2^2$, 误差 r_i 的大小表示信号 y 与字典 D_i 的相似程度,也就是与类别 i 的近似程度。在误差中 $r = [r_1, r_2, \dots, r_p]^T$ 选取最小的误差,用最小误差对应的类别 p 标记信号 y :

$$\text{label} = \arg \min r_i \quad (8)$$

本文将目标图像中提取的特征向量 f_i 利用SRC算法标记为肿瘤与非肿瘤,然后将特征向量与各自的超像素对应,将所有属于肿瘤区域的超像素合并得到完整的肿瘤区域轮廓。

2 实验结果与分析

本文所提出的方法采用VC++和MATLAB混合编程实现,并且对23幅超声肿瘤图像进行评价。由一位资深放射科医生来完成人工分割,然后与机器分割结果进行对比,评价分割效果。这里主要选择了灵敏度(Sensitivity Index, SI)和标准化的Hausdorff距离(Normal Hausdorff Distance, NormHD)指标来评价分割结果。

SI是基于区域的度量评价,在这里表示机器分割区域与人工分割区域相互重合的比例:

$$\text{SI} = \frac{A_s \cap A_A}{A_s \cup A_A} \quad (9)$$

其中 A_s 表示人工分割的肿瘤区域面积, A_A 表示机器分割的肿瘤区域的面积。

NormHD是基于距离的度量评价,这里表示机器分割轮廓与人工分割轮廓之间的最远距离。平面中点 p 和轮廓 C_q 的距离如下:

$$d(p, C_q) = \min_{p \in C_q} \|p - q\|_2^2 \quad (10)$$

其中 $\|p - q\|_2^2$ 表示点 p 与点 q 之间的二维欧拉距离。所以人工分割肿瘤区域的轮廓 C_s 与机器分割肿瘤区域的轮廓 C_A 之间的NormHD为:

$$\text{HD}(C_s, C_A) = \max \left\{ \max_{p \in C_s} d(p, C_A), \max_{p \in C_A} d(p, C_s) \right\} \quad (11)$$

对其进行如下标准化:

$$\text{NormHD} = \frac{\text{HD}}{|C_s|} \quad (12)$$

其中 $|C_s|$ 表示人工分割轮廓中像素点的数量。表1为23幅分割图片的定量评价统计结果。

表1 评价结果
Tab.1 Evaluation results

Index	SI	NormHD
Mean	89.31%	4.80%
Std	2.27%	2.14%
Min	84.36%	2.72%
Max	92.52%	7.24%

实验结果显示,本文的方法对所有超声肿瘤图片样本的分割结果具有较高的SI以及较低的NormHD,因此本算法可以较准确地识别和分割肿瘤,同时较小的标准偏差表示本算法具有较好的鲁棒性。

选择3幅具有代表性的超声图像来展示本文算法在超声肿瘤分割中的实验结果如图2、图3和图4所示。对于每幅图像a为原图,b为超像素产生图,c为本文算法分割结果,d为分割结果与专家对比图。

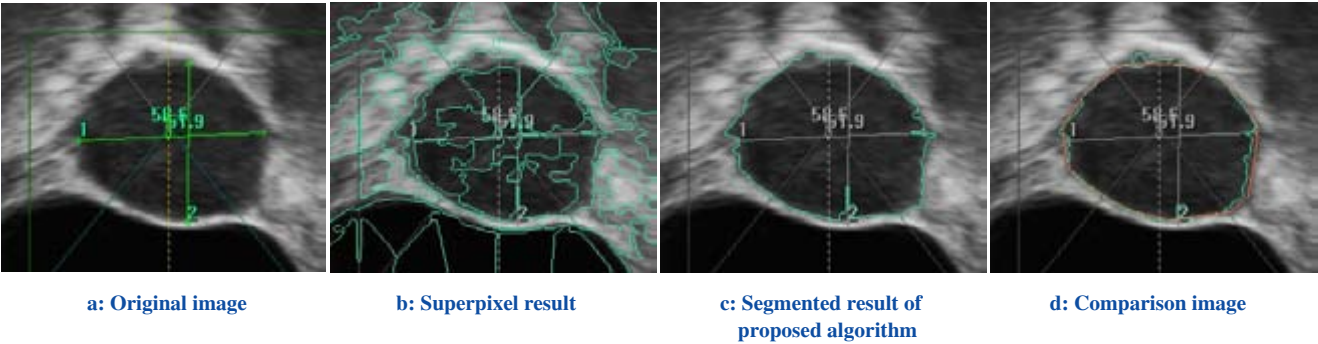


图2 边界清晰的超声图像肿瘤分割
Fig.2 Tumor segmentation in ultrasound image with clear boundary

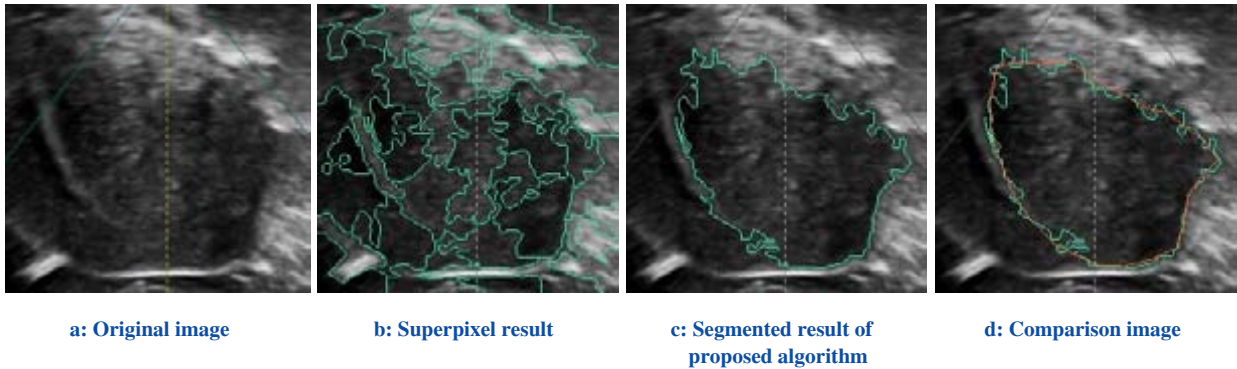


图3 弱边界的超声图像肿瘤分割
Fig.3 Tumor segmentation in ultrasound image with weak boundary

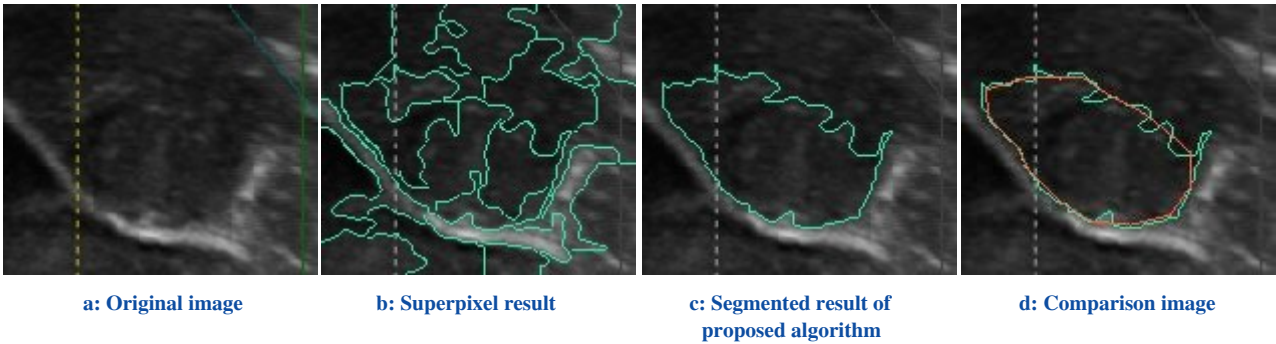


图4 弱边界和混合边界的超声图像肿瘤分割
Fig.4 Tumor segmentation in ultrasound image with weak and mixture boundary

3 讨论

本文设计了一种新的超声图像肿瘤识别分割算法, 克服了SRC算法不能得到肿瘤轮廓的缺点。该算法对于大部分的肿瘤图片均有较好的分割效果, 在肿瘤的认识分割过程中不需要因为病人的不同而更新字典, 为临床医生的治疗提供了方便。

本算法在SRC的过程中, 只用到了初始字典, 在进行分类时并没有使用K-SVD算法等对初始字典进行更新, 这样能减少运行时间, 同时也保证算法的准确性。利用K-SVD对字典进行更新时虽然提取了初始字典的主要成分, 降低了初始字典中的噪声干扰, 但同时也一定程度上抑制了初始字典中的有用特征, 在SRC结果中并不一定会取得更好的效果, 因此本文选择了未训练的初始字典。

【参考文献】

- [1] Noble JA, Boukerroui D. Ultrasound image segmentation: A survey [J]. IEEE Trans Med Imaging, 2006, 25(8): 987-1010.
- [2] Marcellin MW, Gormish MJ, Bilgin A, et al. An overview of JPEG-2000[C]//Proceedings DCC, 2000: 523-541.
- [3] Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing over complete dictionaries for sparse representation[J]. IEEE Trans Signal Proc, 2006, 54(11): 4311-4322.
- [4] Wright J, Yang A, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Trans Pattern Anal Mach Intell, 2009, 31(2): 210-227.
- [5] Rosas-Romero R, Tagare HD. Segmentation of endocardium in ultrasound images based on sparse representation over learned redundant dictionaries[J]. Eng Appl Artif Intel, 2014, 29(3): 201-210.
- [6] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Trans Pattern Anal Mach Intell, 2012, 34(11): 2274-2282.
- [7] Yue Y, Tagare HD. Learning to segment using machine learned penalized logistic models[C]//Proceedings CVPR, 2009: 58-65.
- [8] Shi J, Malik J. Normalized cuts and image segmentation[J]. IEEE Trans Pattern Anal Mach Intell, 2000, 22(8): 888-905.
- [9] Comaniciu D, Meer P. Mean shift: A robust approach toward feature space analysis[J]. IEEE Trans Pattern Anal Mach Intell, 2002, 24(5): 603-619.
- [10] Levinstein A, Stere A, Kutulakos KN, et al. TurboPixels: Fast superpixels using geometric flows[J]. IEEE Trans Pattern Anal Mach Intell, 2009, 31(12): 2290-2297.
- [11] Radhakrishna AS, Smith K. Aurelien ucchi and a.S.S.u. Pascal Fua. SLIC superpixels[R]. EPFL Technical Report, 2010:149300.
- [12] Mallat S, Zhang Z. Matching pursuit with time-frequency dictionaries[J]. IEEE Trans Signal Process, 1993, 41(12): 3397-3415.
- [13] Pati YC, Rezaiifar R, Krishnaprasad PS. Orthogonal matching pursuit: Recursive function approximation with applications to wavelet decomposition[C]. Asilomar Conf Signals Syst Com, 1993: 1.