

结合双树复小波变换和改进密度峰值快速搜索聚类的乳腺 MR 图像分割

范 虹¹, 张程程¹, 侯存存¹, 朱艳春², 姚若侠¹

(1. 陕西师范大学计算机科学学院, 陕西西安 710062; 2. 中国科学院深圳先进技术研究院生物医学与健康工程研究所, 广东深圳 518055)

摘 要: 针对乳腺 MR 图像组织复杂、灰度不均匀、难分割的特点, 本文提出双树复小波(DTCWT)变换结合密度聚类的图像分割方法. 首先利用复小波域双变量模型结合各向异性扩散函数对图像进行去噪处理; 进而通过简单线性迭代聚类(SLIC)算法将图像划分成一定数量的超像素区域, 根据事先设置的阈值搜索每个超像素的近邻, 从而降低基于 K 近邻的密度峰值快速搜索聚类(KNN-DPC)算法寻找每个样本近邻的时间; 最终, 引入超像素区域的近邻信息度量样本密度, 采用 KNN-DPC 算法的分配策略自适应聚类. 仿真和临床数据分割结果表明, 所提算法能有效的实现乳腺 MR 图像的分割.

关键词: 乳腺 MR 图像分割; 双树复小波变换; 双变量模型; 超像素分类; 密度峰值快速搜索聚类

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2019)10-2149-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.10.017

Dual-Tree Complex Wavelet Transform and Improved Density Peak Fast Search and Clustering Method for Breast MR Image Segmentation

FAN Hong¹, ZHANG Cheng-cheng¹, HOU Cun-cun¹, ZHU Yan-chun², YAO Ruo-xia¹

(1. School of Computer Science, Shaanxi Normal University, Xi'an, Shaanxi 710062, China;

2. Institute of Biomedical and Health Engineering, Shenzhen Institutes of Advanced Technology, The Chinese Academy of Sciences, Shenzhen, Guangdong 518055, China)

Abstract: Breast MR image segmentation is difficult because of complex organization and intensity inhomogeneity. This paper proposes a segmentation method based on dual-tree complex wavelet transform and density clustering. Firstly, the image is denoised by using complex wavelet domain bivariate model combined with anisotropic diffusion function; Then simple linear iterative clustering (SLIC) algorithm is used to obtain the neighbors of each superpixel, thereby reducing the time of searching for the nearest neighbor of each sample in KNN-DPC algorithm. Finally, nearest neighbor sample density information of superpixel region is introduced, and distribution strategies from KNN-DPC algorithm are used for adaptive clustering. The segmentation results of simulation and clinical data show that the proposed algorithm can segment breast MR images effectively.

Key words: breast MR image segmentation; dual tree complex wavelet transform; bivariate model; hyper pixel classification; density peak fast search clustering

1 引言

乳腺癌居女性恶性肿瘤发病率之首, 已经成为全球危及妇女健康和生命的第一“杀手”. 我国女性乳腺癌的形势也不容乐观, 据最新数据显示, 每年新诊断和死亡的乳腺癌比例分别是 12.2% 和 9.6%^[1]. 尽管乳腺

癌的确切发病原因尚不明确, 但发现的时间决定它能否治愈以及治疗后生存率的高低, 因此早发现、早诊断、早治疗是目前乳腺癌治疗的主要方针. 磁共振成像(MRI, Magnetic Resonance Imaging)因具有高对比度、任意切片成像、无骨骼伪像和非侵入性等优势^[2], 在临床上的应用日益得到认可. 但其每次成像获取的数据量

大,且图像存在灰度不均匀、弱边界、噪声等问题,使图像的处理成为临床应用的一个难题,因此乳腺 MR 图像的分割逐渐成为近年来业内的研究热点。

目前应用于医学图像的主流分割方法有人工神经网络^[3]、模糊集^[4,5]、水平集^[6,7]和图割法^[8]等。其中 k-means^[9]算法在乳腺 MR 图像上的应用相对较多,其主要思想是从 K 个初始聚类中心开始,然后通过优化目标函数将每个对象迭代地分配给“最接近”的簇。然而,大多数 k-means 算法需事先设定聚类个数,对于没有专业知识的人来说,自主确定图像类簇数是非常困难的。虽然后期有学者做了改进^[10,11],但仍不能较好地适用于乳腺 MR 图像的分割。2014 年,文献[12]提出了能够检测任意簇,并且不需要指定类簇数作为分区算法的密度峰值快速搜索聚类算法(Clustering Fast Search and Find of Density Peaks, DPC),算法简单有效,后经文献[13]的改进,取得了更好的聚类结果,本文尝试将其引入 MR 图像中进一步展开研究。

MR 图像通常伴有强烈的噪声,直接影响临床诊断结果。为了更好地分割出病变区域,对图像做去噪预处理是很有必要的一项工作。目前,基于小波理论的图像去噪方法被广泛使用^[14],但传统小波变换在对信号进行基本的“有效”区分时伴随着变换域混叠效应、奇异点的系数震荡和缺乏移位性等缺点,因此, Nick Kingsbury^[15]提出了双树复小波的概念来改进传统离散小波。后来, Sendur and Selesnick 以小波系数之间的相关性为理论基础提出复小波域双变量模型(CWT-Bishrink)^[16],该方法引入小波父子系数 Laplacian 模型的 MAP 估计量,改进 Chang^[17]等人提出的小波域广义高斯模型。因 CWT 的输出是复数,很难进行重构,有学者^[18]将双树复小波和双变量模型相结合解决复小波的重构问题。

针对乳腺 MR 图像因噪声大、灰度不均匀、边界模糊等导致分割难的问题,本文引入各向异性扩散函数的思想改进复小波域双变量模型,并将其应用于图像预处理;通过简单线性迭代聚类(SLIC)算法对图像的划分,降低 KNN-DPC 算法寻找每个样本 K 近邻的时间开销,从而提高整个算法的性能;最终,引入超像素区域的近邻信息度量样本密度,采用 KNN-DPC 算法中两种不同的分配策略自适应聚类,完成乳腺 MR 图像的分割。

2 相关工作

2.1 双树复小波域双变量模型

一般复小波变换可以解决传统离散小波的局限性,但是当解决多层复杂小波变换时,复小波变换导入的系数是复数形式,因此,很难找到对应于复小波变换

的完美重构滤波器。为了解决此问题, Nick Kingsbury^[15]等人提出双树复小波变换(DTCWT),该变换根据一定规则设计了双树滤波器,不仅保留了一般复小波的优点,还可以实现完美重建。

2002 年, Sendur 等人首次提出了复小波域双变量模型(CWT-BS)的概念^[16],其使用联合系数作为双变量先验模型。具体实现步骤如下。

首先考虑同一方向实部与虚部小波系数之间相关性,构造双变量模型为

$$\begin{cases} y_1 = x_1 + n_1 \\ y_2 = x_2 + n_2 \end{cases} \quad (1)$$

其中 y_1 和 y_2 是含噪图像同一方向的实部和虚部小波系数, x_1 和 x_2 是对应原图像小波系数的实部和虚部, n_1 和 n_2 是对应噪声小波系数的实部和虚部。

假设图像被加性高斯白噪声污染,则观测到的图像用向量表示为

$$y = x + n \quad (2)$$

式中: y 为观测图像的小波变换系数; x 为原始图像的小波变换系数; n 为噪声的小波变换系数。其中 $x = (x_1, x_2)$, $y = (y_1, y_2)$, $n = (n_1, n_2)$ 。

然后根据观测图像 y 估计原始图像 x , 由贝叶斯最大后验概率(MAP)^[16]得出

$$\begin{aligned} \hat{x}(y) &= \operatorname{argmax}_x [p_{Y|X}(y|x)p_X(x)] \\ &= \operatorname{argmax}_x [p_N(y-x)p_X(x)] \end{aligned} \quad (3)$$

但是运用该法则的前提条件是已知噪声的概率密度函数 $p_N(y-x)$ 和原始图像小波系数的先验概率密度函数 $p_X(x)$ 。Levent^[16]等人利用曲线拟合的方法,得出 x 的联合概率密度函数,能较好地表示向量 x 的分布:

$$p_X(x) = \frac{3}{2\pi\sigma^2} \exp\left(-\frac{\sqrt{3}}{\sigma} \sqrt{x_1^2 + x_2^2}\right) \quad (4)$$

式中: σ 为待估计图像 x 的方差。

假设噪声是独立同分布的高斯白噪声,这种噪声在经过双树复小波变换后仍服从高斯分布,即概率密度函数为

$$p_N(y-x) = \frac{1}{2\pi\sigma_N^2} \exp\left(-\frac{(y_1-x_1)^2 + (y_2-x_2)^2}{2\sigma_N^2}\right) \quad (5)$$

其中 σ_N^2 为噪声小波系数的方差。

最后通过噪声图像 y 可以得出实部系数 x_1 的 MAP 估计(\hat{x}_1)为

$$\hat{x}_1 = \frac{\left[\sqrt{y_1^2 + y_2^2} - \frac{\sqrt{3}\sigma_n}{\sigma}\right]_+}{\sqrt{y_1^2 + y_2^2}} y_1 \quad (6)$$

其中, $[f]_+$ 的定义如下

$$[f]_+ = \begin{cases} 0, & f < 0 \\ f, & f \geq 0 \end{cases} \quad (7)$$

同理,虚部系数 x_2 的 MAP 估计(\hat{x}_2):

$$\hat{x}_2 = \frac{\left[\sqrt{y_1^2 + y_2^2} - \frac{\sqrt{3}\sigma_n}{\sigma} \right]_+}{\sqrt{y_1^2 + y_2^2}} y_2 \quad (8)$$

其中, σ_n 是采用 Donoho^[19] 鲁棒中值方法估计的噪声小波系数方差.

2.2 KNN-DPC 算法

2014 年 Rodriguez 等人提出密度峰值快速搜索聚类算法(DPC)^[12],该算法能快速发现任意形状数据集的密度峰值点(即类簇中心),并高效进行样本点分配和离群点剔除,适用于大规模数据的聚类分析. DPC 算法对于样本点 i 的局部密度 ρ_i 与距离 δ_i 的定义如式(9)和式(10)所示:

$$\rho_i = \sum_{j \neq i} \chi(d_{ij} - d_c) \quad (9)$$

$$\delta_i = \min_{j: \rho_j > \rho_i} (d_{ij}) \quad (10)$$

其中, d_{ij} 表示样本 i, j 之间的距离; d_c 表示截断距离,当 $x < 0$ 时, $\chi(x) = 1$, 否则, $\chi(x) = 0$; δ_i 表示样本 i 到密度比其大且距离最近样本 j 的距离,当样本 i 的局部密度 ρ_i 为最大时, $\delta_i = \max_j d_{ij}$. 由局部密度 ρ_i 的计算公式可知,截断距离 d_c 很大程度上会影响样本 i 的局部密度 ρ_i (数据集规模越小,影响越大),且针对不同规模数据集,作者使用了不同的局部密度计算公式,但是目前数据集规模的界定没有一个准确的定义. 同一数据集使用不同计算方法,最终聚类结果差异很大. 作者进行了一系列 DPC 算法性能的验证,发现该算法存在不容忽视的问题,即 DPC 算法的分配策略可能会出现样本错分连带效应.

2016 年谢娟英等人^[13]通过实验验证了 DPC 算法确实存在以上所提及问题,并针对存在的缺陷提出一种基于 K 近邻的快速密度峰值搜索算法(KNN-DPC)实现样本的高效分配. 该算法利用样本的 K 近邻信息重新定义了样本的局部密度 ρ_i :

$$\rho_i = \sum_{j \in KNN(i)} (-d_{ij}) \quad (11)$$

其中, $KNN(i)$ 表示样本 i 的 k 个近邻样本的集合. 由式(11)可知, KNN-DPC 算法将 DPC 算法中对于局部密度的计算从全局收缩到样本 i 的 k 个近邻,且样本 i 到其 k 近邻的距离越小,其局部密度越大,反之亦然.

为了规避数据集中离群点样本对最终结果的影响, KNN-DPC 根据样本 i 的 k 近邻信息重新给出了离群点的定义,公式如下

$$k_{\text{dist}}(i) = \max_{j \in KNN(i)} \{d_{ij}\} \quad (12)$$

$$\text{threshold} = \frac{1}{N} \sum_{i=1}^N k_{\text{dist}}(i) \quad (13)$$

$$\text{Outlier} = \{o \mid k_{\text{dist}}(o) > \text{threshold}\} \quad (14)$$

$k_{\text{dist}}(i)$ 表示样本 i 的 KNN 距离, threshold 定义阈值,当且仅当 $k_{\text{dist}}(o) > \text{threshold}$, 该点为离群点, N 表示数据集中全部样本数的个数.

KNN-DPC 算法提出适应于不同规模数据集的样本局部密度度量准则,并将样本 K 近邻信息引入,提出两种新的样本分配策略. 依次完成样本分配,避免了 DPC 算法样本分配策略潜在的缺陷. KNN-DPC 算法的估计准则,能准确快速地发现数据集类簇中心,基于 K 近邻的样本分配策略克服了 DPC 算法样本分配策略的连带错分效应,能发现数据集样本的真实类簇分布.

3 基于 DTCWT 和改进 KNN-DPC (DTCWT + IKNN-DPC) 的乳腺 MR 图像分割

3.1 KNN-DPC 算法图像分割的问题

文献[13]提出的 KNN-DPC 算法已经被证明在 UCI 真实数据集和 Olivetti 人脸数据集上是一种非常有效的自适应聚类算法,能准确地发现类簇中心,并分配样本到合适的类簇. 然而, KNN-DPC 算法应用于图像时却不尽人意,如图 1、图 2 所示的分割结果. 实验所用图像来自 Berkeley 图像库. 由于 KNN-DPC 的输入为图像像素点之间的近邻信息矩阵,矩阵维数较大且不易计算,因此为了保证分割结果的有效性,仅截取原图一部分进行分割,但其分割时间依然很长,如表 1 所示. 实验平台为: Windows10、Intel (R) Core (TM) i5-6600 3.30GHz CPU、8G RAM,所有算法均在 MATLAB 2013b 上实现. 分割结果的评价主要从视觉、时间与 Dice 系数^[20]三方面进行. 其中,视觉评价主要从图像是否错分、区域是否一致、边缘保持是否完整等几方面判断.



图1 KNN-DPC算法分割bird结果



图2 KNN-DPC算法分割airplane结果

表 1 DPC 和 KNN-DPC 分割精度和时间对比

图片	大小	Dice 系数/%		时间/s	
		DPC	KNN-DPC	DPC	KNN-DPC
图 1	91 × 82	89.96	95.89	2349.14	2253.94
图 2	61 × 62	95.50	79.14	295.13	311.00

从图 1、图 2 的分割结果和表 1 中 Dice 系数值来看, DPC 算法对图 2 的分割效果优于 KNN-DPC 算法, 但是未明确分割出图 1 中鹰尾这一部分; KNN-DPC 算法能将图 1 中鹰的边缘分割明确, 但是对于图 2 这种前景与背景差异不明显的图像分割效果很差, 因此 KNN-DPC 算法对于图像的分割具有不稳定性.

究其原因这是由于 KNN-DPC 算法在进行图像分割时存在如下缺陷: (1) 由于 KNN-DPC 算法需要遍历图像中每个像素点的 K 近邻, 而图像中含有大量的像素点, 导致无论是计算像素点间的距离, 还是遍历像素点的近邻个数, 算法都需花费大量的时间; (2) KNN-DPC 算法对图像直接进行处理时, 通常输入的是包含图像颜色信息的像素值, 没有包含图像的空间位置信息, 因而不能很好的反映像素点之间的近邻信息; (3) 由于图像中像素点的分布是不均匀的, 而在 KNN-DPC 算法中引入的是样本的 K 近邻信息, 一定范围内不同位置像素点的近邻个数是不相同的. 依此思想进行图像分割, 不仅增加计算复杂度, 还会影响最终聚类结果.

3.2 DTCWT + IKNN-DPC 算法

3.2.1 改进 DTCWT-BS 的图像去噪

MR 图像存在大量噪声干扰, 为了有效分割图像, 须对 MR 图像进行必要的降噪处理. 由于传统复小波域双变量模型只对高频分量做了处理, 而经双树复小波变换后的图像低频分量同样含有少量的噪声, 若不做处理, 同样会降低图像的质量, 因此本文提出使用各向异性扩散滤波对低频分量进行处理以改进复小波域双变量去噪模型.

设待处理图像为 I , 定义区域 $\Omega \in R \times R$ 是扩散初始区域, 经各向异性扩散模型算法从内向外扩散, 即获得平滑图像 I . 各向异性扩散函数如下:

$$\begin{cases} \frac{\partial I}{\partial t} = \text{div}[c(\|\nabla I\|) \cdot \nabla I] \\ I(t=0) = I_0 \end{cases} \quad (15)$$

式中, div 为散度算子; ∇ 为梯度算子; $\|\cdot\|$ 表示幅度; $c\|\nabla I\|$ 为扩散函数; t 为引入的时间算子, 表示降噪过程与扩散持续时间相关. 其中, Perona 和 Malik^[21] 根据传统模型提出两个扩散函数, 即 P-M 各向异性扩散系数

$$\begin{cases} g(\|\nabla I\|) = \exp\left(-\left(\frac{\|\nabla I\|}{k}\right)^2\right) \\ g(|\nabla I|) = \frac{1}{1 + \left(\frac{\|\nabla I\|}{k}\right)^2} \end{cases} \quad (16)$$

式中 k 是区别边缘和噪声的扩散门限系数. 由扩散系数可知, 梯度算子和扩散函数成反比关系, 这样就可以在滤除噪声的同时在一定程度上保持边缘特征.

3.2.2 SLIC 算法改进的 KNN-DPC 算法 (IKNN-DPC)

KNN-DPC 算法应用于图像分割时会出现 3.1 节所提到的问题, 因此本文在用 KNN-DPC 做图像分割之前首先使用 SLIC (Simple Linear Iterative Clustering) 算法^[22] 把图像划分成若干个超像素块, 然后给定一个阈值距离, 对每一个超像素块, 分别遍历与其邻接的超像素, 并计算两者之间的欧式距离, 当计算所得的距离小于事先给定的阈值时, 则认为此超像素为该超像素块的一个近邻, 并保存两者之间的距离. SLIC 算法是由 Achanta 等人于 2010 年提出的简单线性迭代聚类, 算法描述详见参考文献[22].

由于用给定阈值判断两个超像素是否是彼此的近邻, 所以本文算法得到的每个超像素块的近邻个数并不是都相等. 寻找近邻结束后, 再利用 KNN-DPC 算法对超像素块进行聚类分割. 其中, 超像素块分配策略依然沿用文献[13]中的策略. 具体步骤如下.

输入: 待分割图像, 超像素个数 K , 加权因子 a , 阈值 ξ
输出: 分割结果图像

Step1. 首先使用加权因子 a 将图像分割成 K 个超像素, 并且根据中值色彩值计算超像素属性, 得到分割的每个超像素块的信息以及与其邻接的超像素块;

Step2. 根据步骤 1 的结果, 对每一个超像素块遍历与其邻接的超像素块, 计算两者之间的欧氏距离 distance, 然后计算的 distance 和阈值 ξ 进行比较, 如果 $\text{distance} < \xi$, 则将其作为此超像素块的一个近邻, 并进行保存;

Step3. 根据式(11)和(10)计算超像素块的局部密度值 ρ 与距离 δ 值;

Step4. 从由 ρ 和 δ 构成的决策图中选择出类簇中心 CI ;

Step5. 根据式(12)~(14)发现离群点超像素块;

Step6. 对除类簇中心外的非离群点超像素块按照分配策略 1 进行分配;

Step7. 对离群点和策略 1 未分配的非离群超像素块按照分配策略 2 进行分配;

Step8. 对于第 6、7 两步未分配的极少量超像素块, 归并其到距离最近的已分配超像素块所在类簇;

Step9. 根据步骤 8 所得到的最终聚类结果将对应的聚类标签还原到超像素中.

3.2.3 DTCWT + IKNN-DPC 算法实现

本文算法针对乳腺 MR 图像噪声高、组织内部灰度不均匀的特性, 首先使用双树复小波变换进行预处理, 去除大部分噪声; 然后采用 SLIC 超像素算法进行初步分割, 获取超像素块及其近邻信息; 最终根据 KNN-DPC 算法分配策略, 对图像进行最终分割. 经多次实验证明, 图 3 中所取超参数中阈值 ξ 可使分辨率较大的图像获

得较好分割结果,而针对分辨率较小的图像,应该选取偏小的阈值. 具体流程如图 3 所示.

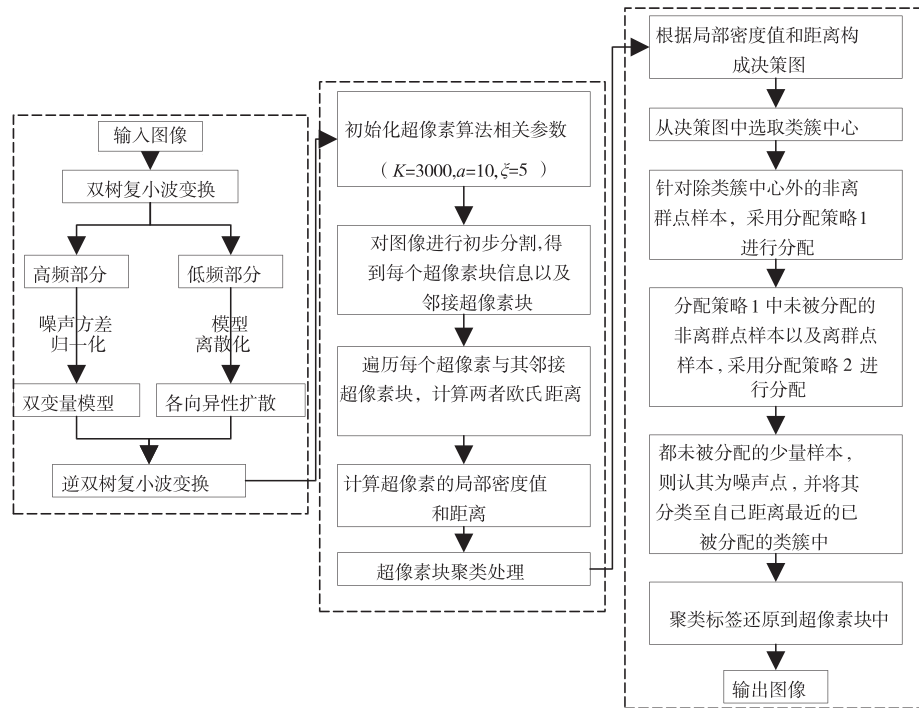


图3 DTCWT+IKNN-DPC算法流程

4 算法性能分析

为了验证本文所提算法的性能,本节将从去噪性能、分割精度以及时间复杂度几个方面进行分析. 实验平台同 3.1 节.

4.1 去噪性能分析

由于在 MR 成像过程中,信号的实部和虚部同时被非相关零均值,相同方差的高斯噪声干扰,使得 MR 图像的噪声常常表现为 Rician 分布^[7]. 为了定量分析所提方法的有效性,文中在对图像去噪的同时分别采用峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 和结构相似度 (Structural Similarity, SSIM) 对去噪结果进行客观评价,并与传统 P-M 方法、DTCWT + P-M 方法和 DTCWT-BS 方法进行对比,结果如图 4 和表 2 所示. 被分析的 Lena 图像大小为 256×256 ,并添加标准差为 20 的 Rician 噪声^[23].




图4 lena图去噪结果比较

由图 4 的结果可以看出本文方法去噪后的图像复原效果较好且保持了很好的图像细节. 根据表 2 可知,虽然本文算法去噪过程中会对边缘部分进行平滑处

理,PSNR 和 SSIM 值还是优于其他算法,表明本文方法在去噪的同时可以很好地保留边缘和细节信息,而边缘和细节是后期乳腺肿瘤识别的重要特征.

表 2 对比算法去噪结果

图像 Lena	PSNR	SSIM
P-M	22.20	0.43
DTCWT + P-M	27.08	0.77
DTCWT-BS	26.53	0.76
本文算法	27.76	0.79

4.2 分割精度分析

本节将 IKNN-DPC 算法应用于图 1、图 2 的截取图像中验证算法精度,其中阈值 $\xi = 2$. 由于算法使用 SLIC 超像素算法,因此在聚类过程结束时,可能会保留一些与其聚类中心不相同的“孤立”像素,为了对此进行校正,强制将这些像素分配到最近聚类中心,导致图像边缘细节分割效果较差,对于尺寸较小的图像尤为明显,如图 5 所示.




图5 IKNN-DPC算法分割截取图像

从图 5 的结果来看,IKNN-DPC 算法虽对边缘分割不明确,还是可以将物体与背景分割开. 根据分割结果

的 dice 系数,发现该算法对于两图的分割精度分别为 93.08%、94.22%,且算法对于上面两图的分割时间都不足 1s,远远优于 KNN-DPC 算法的分割时间,表明 IKNN-DPC 算法分割稳定且效率高.

为了进一步验证本文所提算法,将算法应用于图 6 的分割,同图还给出了自适应 k-means 算法和 IKNN-DPC 算法的分割结果,其中 IKNN-DPC 算法和本文算法的阈值 $\xi = 5$. 为模拟真实 MR 图像,向原图中添加标准差为 20 的 Rician 噪声进行分割对比.

表 3 给出了分割的 Dice 系数. 表中数据显示自适应 k-means 算法对于背景颜色单一的图像(如 goose、bird)聚类效果较好,而对于 flower、horse 和 airplane 这种背景和颜色复杂的图像,聚类效果并不理想. 结合图 6 和表 3 数据,得出 IKNN-DPC 算法的分割效果虽优于自适应 k-means 算法,但是由于噪声影响,对图像边缘的分割效果较差;反观本文算法,对于五幅图像的分割精度都略高于 IKNN-DPC 算法,对背景颜色单一的图像的分割精度略高于自适应 k-means 算法,但对背景复杂图像的分割效果明显优于自适应 k-means 算法,且本文算法具有较好的去噪性能,能在去噪的同时保持图像边缘良好,使算法分割结果优于 IKNN-DPC 算法. 因此,本文算法的分割性能良好.

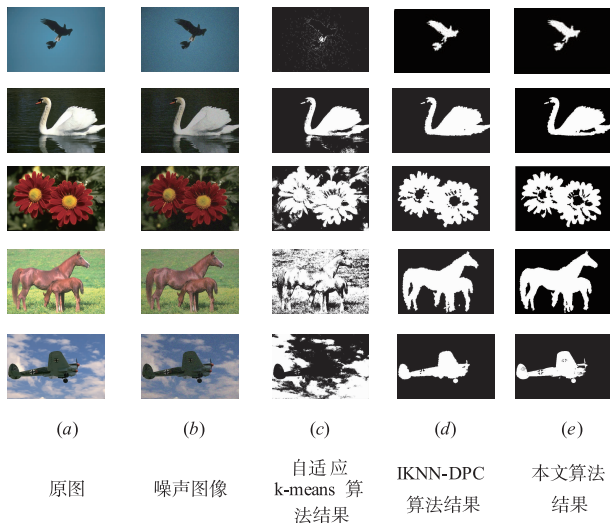


图6 自然图像分割结果

表 3 Dice 系数

图像	自适应 k-means	IKNN-DPC	本文算法
bird	86.44%	98.50%	99.20%
goose	94.99%	96.39%	97.86%
flower	73.23%	90.13%	91.69%
horse	62.12%	95.87%	96.70%
airplane	65.94%	97.85%	98.89%

4.3 时间复杂度分析

对于像素点个数为 N 的图像,在本文算法中,若假设超像素数目为 C ,设定阈值为 a ,则其时间复杂度主要来源于:(1)去噪的时间复杂度 $O(N)$;(2)SLIC 的时间复杂度 $O(N)$;(3)计算超像素块间距离的时间复杂度 $O(C^2)$;(4)计算每个超像素块的密度 ρ ,需要寻找超像素块 i 在阈值 a 范围内近邻个数,时间复杂度 $O(C)$,则搜索 C 个超像素块近邻的时间复杂度 $O(C^2)$;(5)计算每个超像素块的 δ 距离,时间复杂度 $O(C^2)$;(6)分配超像素块:时间复杂度 $O(C^2)$,其中,策略 1 类似于图的广度优先搜索遍历,时间复杂度 $O(C_1(|C|) + 1)$ (C_1 为非离群点超像素块, $|C|$ 表示类簇数);策略 2 的时间复杂度主要取决于第 2 步,时间复杂度 $O(|C|C_2 + C_2)$ ($C_2 = C - C_1$),因此,整个分配策略的时间复杂度为 $O(C^2)$;因此,本文所提算法的时间复杂度量级为 $O(NC^2)$. 可见,本文算法的时间复杂度与像素个数 N 和超像素块数 C 有关.

表 4 给出了自适应 k-means 算法、IKNN-DPC 算法及本文算法对图 6 的分割运行时间对比情况. 从表中的分割时间也可以看出本文算法相对于自适应 k-means 算法和 IKNN-DPC 算法来说耗时稍长. 如果对于实时性要求不是很高的图像分割领域,用相对较长的时间换取分割精度较大提高的算法也是有意义的.

表 4 聚类算法对自然图像分割的运行时间

图像	大小	运行时间/s		
		自适应 k-means	IKNN-DPC	本文算法
bird	481 × 321	1.00	36.43	36.98
goose	481 × 321	0.80	50.11	50.71
flower	481 × 321	0.87	44.85	45.21
horse	481 × 321	0.79	58.10	58.54
airplane	481 × 321	0.77	48.44	48.94

5 临床乳腺 MR 图像分割分析

虽然第 4 节已通过自然图像验证了本文所提算法的性能,但由于临床乳腺 MR 图像具有灰度不均匀、边界弱化等一系列特点,所以,本节将本文算法再次应用于不同病人的临床乳腺 MR 图像的分割,验证算法性能. 其中,图 7 为截取图像,图 8 为原图.

图像数据来源于康奈尔大学 Weill 医学院放射科,成像仪器为德国西门子 1.5T 标准双乳线圈磁共振扫描仪,实验图为注入造影剂增强后病人的三维 T1 加权梯度回波序列图. 扫描成像时病人采用俯卧位,双侧乳腺自然悬垂于乳房线圈的空洞内,各参数分别为:重复时间 TR = 5.6ms,回波时间 TE = 2.76ms,层间距 0.3mm,层厚 1.2mm,FOV = 34cm × 34cm,图像大小为

512 × 512, 重复扫描 5 次, 每次扫描时间为 60s. 选取图像所在序列共 88 帧图像, 本文采用了经临床医生判断肿瘤特征较为明显的第 48 帧图像作为最终实验图像, 以便观察文中所提算法的性能, 图中白色圆圈为肿瘤区域.

从 3.1 节已知 KNN-DPC 算法应用到较大图像上会出现一系列的问题, 所以对 512 × 512 的实验乳腺 MR 图像, 使用 KNN-DPC 算法难以对其全图进行分割, 因此本节仅截取图像中含有肿瘤病灶的部位, 分别用 DPC、KNN-DPC 算法、IKNN-DPC 算法和本文算法进行分割, 阈值 $\xi = 2$. 结果如图 7 和表 5 所示.




图7 截取乳腺图像分割结果

表 5 聚类算法对截取图像分割的运行时间

图像	大小	运行时间/s			
		DPC	KNN-DPC	IKNN-DPC	本文算法
截取图 1	82 × 82	1846.78	2015.48	2.97	3.01
截取图 2	77 × 77	1338.50	1364.96	2.95	2.98

根据图 7 的分割结果和表 5 的运行时间, DPC 算法和 KNN-DPC 算法对于乳腺 MR 图像分割的时间效率不高, 且 DPC 算法对不同病人的截取图像均未能分割出肿瘤病灶部分; KNN-DPC 算法虽能将图像中肿瘤区域分割出来, 但对周围其他组织的分割出现了一定的错分; IKNN-DPC 算法和本文算法的运行时间较短, 但 IKNN-DPC 算法由于受到 MR 图像噪声影响, 对肿瘤边缘形状分割较差; 而本文算法对于两幅截取图像都基本能将肿瘤划为一类. 由此可见本文算法在临床 MR 图像分割方面的性能优于原始 KNN-DPC 算法.

图 8 所示为本文算法和自适应 k-means 算法、AP 算法、IKNN-DPC 算法分割图 7(a) 中原图像的结果, 其中阈值 $\xi = 5$. 为了更加清晰地显示分割结果, 图 8 的第二行和第四行分别放大了图像中与肿瘤相关的一侧乳房的分割情况, 第四行图的右下角还给出了所分割肿瘤形状的放大效果. 表 6 给出了各算法的运行时间.

由表 6 可知本文算法相比于其他两种算法需要花费较多的时间, 但从图 8 中可以明显看出, 自适应 k-means 算法对于第一幅乳腺 MR 图像未能分割出肿瘤




图8 临床乳腺MR图像分割

病灶部分, 而是将其与周围其他组织划分为一类; IKNN-DPC 算法虽能分割出肿瘤部分, 但其边缘保持性较差. 而本文算法, 不仅准确分割出肿瘤部位, 且病变周围区域基本划分正确, 轮廓也较为清晰. 分割结果再一次说明本文算法在临床 MR 图像的分割方面也具有较好的性能.

表 6 聚类算法对临床乳腺 MR 图像分割的运行时间

图像	大小	运行时间/s		
		自适应 k-means	IKNN-DPC	本文算法
临床图 1	512 × 512	1.04	46.18	48.32
临床图 2	512 × 512	0.93	45.56	46.75

6 结论

本文提出一种基于双树复小波变换和密度峰值聚类算法相结合的乳腺 MR 图像分割方法. 算法借鉴各向异性扩散函数对图像去除噪声的同时能很好地保护边缘的特性, 克服复小波域双变量模型只对高频部分噪声处理的缺陷; 在聚类过程中引入简单线性迭代聚类算法, 将图像划分成一定数量的超像素区域后再搜索近邻, 有效降低了现有 KNN-DPC 算法对高维数据处理时寻找样本 K 近邻的时间开销. 仿真和临床图像分割结果表明, 所提算法不仅具有良好的去噪性能而且分割精度较高, 能够较为有效地实现 MR 图像的分割.

参考文献

- [1] FAN L, STRASSER-WEIPPL K, LI J J, et al. Breast cancer in China [J]. The Lancet Oncology, 2014, 15 (7): e279 - e289.
- [2] 包尚联, 杜江, 高嵩. 核磁共振骨皮质成像关键技术研究进展 [J]. 物理学报, 2013, 62 (8): 088701.

- BAO Shang-Lian, DU Jiang, GAO Song. Review of the ultrashort echo time magnetic resonance imaging of cortical bone[J]. *Acta Phys Sin*, 2013, 62(8):088701. (in Chinese)
- [3] OKTAY O, FERRANTE E, KAMNITSAS K, et al. Anatomically constrained neural networks (ACNNs): Application to cardiac image enhancement and segmentation[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(2):384.
- [4] QIAN S, WENG G. Medical image segmentation based on FCM and level set algorithm[A]. *The 7th IEEE International Conference on Software Engineering and Service Science (ICSESS)* [C]. US: IEEE, 2016. 225–228.
- [5] 陈志彬, 邱天爽, SU Ruan. 一种基于 FCM 和 Level Set 的 MRI 医学图像分割方法[J]. *电子学报*, 2008, 36(9):1733–1737.
- CHEN Zhi-Bin, QIU Tian-Shuang, SU Ruan. FCM and level set based segmentation method for brain MR images[J]. *Acta Electronica Sinica*, 2008, 36(9):1733–1737. (in Chinese)
- [6] 王顺风, 冀晓娜, 张建伟, 等. 局部熵驱动的 GAC 模型在生物医学图像分割中的应用[J]. *电子学报*, 2013, 41(12):2487–2492.
- WANG Shun-feng, JI Xiao-na, ZHANG Jian-wei, et al. Application of GAC model driven by the local entropy on medical image segmentation[J]. *Acta Electronica Sinica*, 2013, 41(12):2487–2492. (in Chinese)
- [7] 范虹, 朱艳春, 王芳梅, 等. 多分辨率水平集算法的乳腺 MR 图像分割[J]. *物理学报*, 2014, 63(11):118701.
- FAN Hong, ZHU Yan-Chun, WANG Fang-Mei, et al. Segmentation of breast MR images based on multiresolution level set algorithm[J]. *Acta Phys Sin*, 2014, 63(11):118701. (in Chinese)
- [8] 葛婷, 牟宁, 李黎. 基于 softmax 回归与图割法的脑肿瘤分割算法[J]. *电子学报*, 2017, 45(3):644–649.
- GE Ting, MU Ning, LI Li. A brain tumor segmentation method based on softmax regression and graph cut[J]. *Acta Electronica Sinica*, 2017, 45(3):644–649. (in Chinese)
- [9] VESAL S, RAVIKUMAR N, ELLMAN S, et al. Comparative Analysis of Unsupervised Algorithms for Breast MRI Lesion Segmentation [M]. Berlin: Springer, 2018. 257–262.
- [10] KANG D, SHIN S Y, SUNG C O, et al. An improved method of breast MRI segmentation with Simplified K-means clustered images [A]. *Proceedings of the 2011 ACM Symposium on Research in Applied Computation* [C]. US: ACM, 2011. 226–231.
- [11] MOFTAH H M, AZAR A T, AL-SHAMMARI E T, et al. Adaptive k-means clustering algorithm for MR breast image segmentation[J]. *Neural Computing & Applications*, 2014, 24(7–8):1917–1928.
- [12] RODRIGUEZ A, LAIO A. Clustering by fast search and find of density peaks [J]. *Science*, 2014, 344(6191):1492.
- [13] 谢娟英, 高红超, 谢维信. K 近邻优化的密度峰值快速搜索聚类算法[J]. *中国科学: 信息科学*, 2016, 46(2):258–280.
- XIE J Y, GAO H C, XIE W X. A density peak fast search clustering algorithm for K nearest neighbor optimization [J]. *Chinese Science: Information Science*, 2016, 46(2):258–280. (in Chinese)
- [14] 刘金华, 余堃. 基于双树复小波与波原子的图像扩散滤波[J]. *物理学报*, 2011, 60(12):124203.
- LIU Jin-Hua, SHE Kun. Image diffusion filtering based on dual tree complex wavelet and wave atoms[J]. *Acta Phys Sin*, 2011, 60(12):124203. (in Chinese)
- [15] SELESNICK I W, BARANIUK R G, KINGSBURY N C. The dual-tree complex wavelet transform[J]. *IEEE Signal Processing Magazine*, 2005, 22(6):123–151.
- [16] SENDUR L, SELESNICK I W. Bivariate shrinkage functions for wavelet-based denoising exploiting interscale dependency[J]. *IEEE Transactions on Signal Processing*, 2002, 50(11):2744–2756.
- [17] CHANG S G, YU B, VETTERLI M. Adaptive wavelet thresholding for image denoising and compression[J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2002, 9(9):1532–1546.
- [18] LI M, JIA Z, YANG J, et al. An algorithm for remote sensing image denoising based on the combination of the improved bishrink and DTCWT[J]. *Procedia Engineering*, 2011, 24(6):470–474.
- [19] DONOHO D, JOHNSTONE I. Adapting to unknown smoothness via wavelet shrinkage[J]. *Publications of the American Statistical Association*, 1995, 90(432):1200–1224.
- [20] DICE L R. Measures of the amount of ecologic association between species [J]. *Ecology*, 1944, 26(3):297–302.
- [21] PERONA P, MALIK J. Scale-space and edge detection using anisotropic diffusion[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2002, 12(7):629–639.
- [22] ACHANTA R, SHAJI A, SMITH K, et al. Slic superpixels [J]. *Ecole Polytechnique Fédéral de Lausanne (EPFL), Tech Rep*, 2010, 149300:155–162.
- [23] 余丽玲, 阳维, 冯衍秋, 等. Rician 噪声水平场的估计及其在 MR 图像去噪中的应用[J]. *中国生物医学工程学报*, 2013, 32(5):532–538.

YU Li-Ling, YANG Wei, FENG Yan-Qiu, et al. Estimation of spatially variable level field of rician noise and its application to MR image denoising[J]. Chinese Journal of

Biomedical Engineering, 2013, 32(5): 532 – 538. (in Chinese)

作者简介



范 虹 女,1969 年出生,宁夏平罗人. 博士,教授,CCF 会员,主要研究领域为图像处理、模式识别、智能信息处理.
E-mail: fanhong@snnu.edu.cn



张程程 女,1994 年出生,山东济宁人. 硕士生,主要研究领域为医学图像处理.