

中图法分类号: TP391 文献标志码: A 文章编号: 1006-8961(2011)11-2088-07

论文索引信息: 卢洁, 杨学志, 郎文辉, 左美霞, 徐勇. 区域 GMM 聚类的 SAR 图像分割[J]. 中国图象图形学报, 2011, 16(11): 2088-2094

区域 GMM 聚类的 SAR 图像分割

卢洁, 杨学志, 郎文辉, 左美霞, 徐勇

(合肥工业大学计算机与信息学院, 合肥 230009)

摘要: 高斯混合模型(GMM)聚类算法近年来广泛应用于图像分割领域。但在 SAR 图像分割中, 由于忽略了图像像素间的空间相关性, 使其对相干斑噪声十分敏感。提出一种基于区域的 GMM 聚类算法, 它将空间相关性引入聚类分类中, 利用分水岭分割得到基本同质区域, 计算区域的灰度均值作为 GMM 聚类算法的输入样本, 将聚类特征从像素水平提升到区域水平, 减少了噪声对分割结果的影响; 并将自身反馈机制引入期望最大化(EM)算法中, 进一步提高了 GMM 模型参数估计的精度。还对合成图像和真实 SAR 图像进行了分割实验, 结果表明新算法可有效地提高分割的准确性。

关键词: 图像分割; 分水岭; 高斯混合模型; EM 算法

SAR image segmentation with region-based GMM

Lu Jie, Yang Xuezhi, Lang Wenhui, Zuo Meixia, Xu Yong

(School of Computer and Information, Hefei University of Technology, Hefei 230009 China)

Abstract: Gaussian mixture model (GMM) clustering algorithm is widely used in image segmentation during recent years. The algorithm is however quite sensitive to speckle noise since spatial correlations between pixels are ignored. This paper presents a region-based GMM clustering algorithm for SAR image segmentation featured by incorporating spatial correlations. The watershed algorithm is first used to generate primitive homogeneous regions. Regional mean values are then calculated as input samples of the GMM clustering process. The impact of noise on the segmentation result can therefore be reduced in the space of regions instead of pixels. A feedback mechanism is further introduced into the expectation-maximization (EM) algorithm to improve the precision of parameter estimation. The efficiency of the proposed algorithm has been demonstrated on the segmentation of synthetic SAR images and real SAR images, where the segmentation accuracy has been substantially improved in contrast to pixel-based the GMM algorithm.

Keywords: image segmentation; watershed; Gaussian mixture model; EM algorithm

0 引言

合成孔径雷达(SAR)以其全天时、全天候等诸

多优点在军事侦查、卫星遥感、海洋与陆地观测等方面得到了广泛应用^[1-2]。它特有的相干成像系统能提供较光学图像信息量更丰富的高分辨率图像, 但也同时不可避免地伴有相干斑噪声, 这些相干斑噪

收稿日期: 2010-09-25; 修回日期: 2010-12-01

基金项目: 国家自然科学基金项目(41076120, 60672120, 60890075); 安徽省优秀青年科技基金项目(10040606Y09); 合肥工业大学计算机与信息学院人才培养计划项目(2010HGJX0017); 安徽省人才开发基金项目(2008Z054); 教育部留学回国人员科研启动基金项目。

第一作者简介: 卢洁(1986—), 女。合肥工业大学计算机与信息学院信号与信息处理专业硕士研究生, 主要研究方向为数字图像分析与处理。E-mail: jiezi0101@126.com。

通讯作者: 杨学志, E-mail: hfut.cv@gmail.com。

声严重影响着对 SAR 图像分割的效果。

现有的用于 SAR 图像分割的方法包括直方图阈值法^[3]、聚类方法^[4]、区域增长和合并^[5]、边缘检测^[6]以及基于模型的方法^[7]等。其中高斯混合模型(GMM)聚类算法^[1,8]是一种比较常用的聚类分割算法,它能够较好地逼近真实的复杂分布。它首先提取图像中每一像素的某个特征要素(通常情况下是灰度特征),再利用高斯混合模型将这些特征作为对象进行聚类,最终得到分割结果。由于传统的 GMM 聚类算法是基于像素的,只利用到了像素级特征空间的信息,而忽略了像素之间的空间相关性,从而导致该算法对噪声较为敏感。

针对 SAR 图像的特点,将形态学分水岭^[9]算法与 GMM 聚类算法相结合,提出一种基于区域的高斯混合模型(RGMM)聚类分割算法。新算法充分利用分水岭算法的过分割特点得到多个同质区域,并应用 GMM 聚类算法实现区域与区域的合并。新算法中选取区域的灰度均值作为聚类样本,有效地减少了因噪声影响而造成的同质区域像素之间的差异,与现有的基于像素的 GMM 聚类算法相比较,具有较强的抗噪声能力。由于 EM 算法对参数的初始值依赖性很强,在新算法中引入了自身反馈机制,通过以初始参数估计值反馈指导最终的参数估计来优化 EM 算法,使其逼近全局最优解,更进一步提高了 SAR 图像分割的准确性。

1 高斯混合模型及 EM 算法

有限混合分布理论认为 SAR 图像的分布是多个密度分布的混合体,利用一个加权混合的概率密度函数可表示该分布,其权值为每类像素在整体像素集中所占的比例。当每个类别的密度分布为高斯分布时就称为高斯混合模型,概率密度函数可表示为

$$f(x; \theta) = \sum_{i=1}^n \alpha_i f_i(x; \theta_i) \quad (1)$$

式中, n 为密度分支的个数; $\alpha_1, \dots, \alpha_n$ 为各高斯密度分布的权重,也可看做先验概率,其和为 1; f_i 表示第 i 类单高斯分布的密度,如式(2)所示; θ_i 为第 i 类高斯分布的未知参数(即均值 μ_i 和标准差 σ_i)。

$$f_i(x; \theta_i) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{1}{2}\left(\frac{x - \mu_i}{\sigma_i}\right)^2\right] \quad (2)$$

一般采用极大似然法来求解混合参数 θ , 其中, N 为图像的总像素个数。

$$L(x_1, \dots, x_N; \theta) = \prod_{i=1}^N f(x_i; \theta) \quad (3)$$

$$\theta^* = \arg \max L(x_1, \dots, x_N; \theta) \quad (4)$$

传统的直接求偏导得极大值的方法只适用于一些简单分布,对于复杂的混合密度通常会采用 EM 算法来估计未知参数。

EM 算法^[10-11]是 Dempster 等人于 1977 年提出的计算参数极大似然估计的一种方法,它是通过处理完全数据 $Z = (X, Y)$ 来解决不完全数据 X 的问题。从本质上看,EM 算法是个迭代算法,首先初始化参数 $\theta^{(0)}$; 然后进行 EM 迭代:

E 步 通过观察数据和当前解 $\theta^{(t)}$ ($t = 0, 1, 2, \dots$) 来计算完全数据的期望值

$$Q(\theta | \theta^{(t)}) = \sum_{i=1}^n E[\lg f(\theta; Z) | X, \theta^{(t)}] \quad (5)$$

M 步

$$\theta^{(t+1)} = \arg \max Q(\theta | \theta^{(t)}) \quad (6)$$

最后设定适当的停止规则实现迭代终止。由于 EM 算法能较好地估计高斯混合模型的参数,近年来在模式识别和图像处理领域得到了广泛的应用。

2 基于区域的高斯混合模型聚类

新算法的总体流程如图 1 所示。




图 1 新算法流程图

Fig. 1 Flow chart of the proposed algorithm

算法具体步骤如下:

- 1) 输入 SAR 图像,求解梯度图像;
- 2) 在梯度图像上进行形态学分水岭分割形成基本区域;
- 3) 计算每个基本区域上所有像素的灰度平均值,将其作为该区域的特征;
- 4) 将区域特征作为高斯混合模型聚类的输入样本,实现区域和区域的合并,最终得到 SAR 图像分割结果。参数估计时使用自身反馈初始化方法。

2.1 梯度图像及分水岭分割

图像的梯度值能平滑平均区域, 凸显边缘, 所以通常选择图像的梯度图作为分水岭算法的输入。文中首先用 Canny 算子^[12]来求取 SAR 图像的梯度, 再对梯度图像进行分水岭分割。

Vincent 和 Soille 在 1991 年以沉浸算法定义了分水岭算法, 其主要原理是: 把整幅图像看做是一个地形图的表面, 想像在数字图像上各个区域的极小值位置扎个洞。将水从每个洞口注入, 让水不断上升, 浸没整个地形, 当不同的聚水盆地的水将要聚合时修建大坝, 该大坝用单像素来表示。不断延续这个过程直到达到水位的最大值, 即图像灰度的最大值。沉浸过程的结果是达到每个最小值都由大坝完全包围, 从而形成相关联的集水盆地, 这些大坝就对应于分水岭算法的分水线。

分水岭算法是一种简单有效的区域提取方法, 它计算速度快, 定位准确, 具有空间一致性, 能形成封闭的目标轮廓线。然而梯度操作对噪声较为敏感, 使得图像容易产生过分割现象, 即将本应该属于同一区域的像素划分成多个小区域。新算法中, 过分割的缺点变成了优点, 为后续的高斯混合模型聚类算法提供了封闭的同质区域。

2.2 区域特征提取

传统的高斯混合模型是基于像素的, 对于灰度图像来说就是考虑各像素的灰度值, 但是由于 SAR 图像具有相干斑噪声, 如果只考虑单个像素的特征, SAR 图像中的大量相干斑噪声会直接影响分割结果, 造成很大程度的误分。而分水岭分割所得的基本区域具有同质性^[13], 区域的像素灰度均值是该区域像素灰度宏观属性的基本反映, 可以利用该值作为区域特征代表所属区域进行聚类, 这样可防止所属区域中的相干斑噪声对分割结果的干扰, 提高分割算法的抗噪声能力。分水岭分割有效的保持了边缘信息, 区域均值化减小了相干斑噪声对分割结果的影响。

2.3 基于区域的高斯混合模型的参数估计

假设由分水岭分割算法得到 N 个同质区域, 分别计算每个区域的像素灰度平均值 \bar{x} , 将所有的平均值作为 GMM 聚类的输入样本。基于区域的高斯混合模型参数估计的计算过程为

1) 初始化参数 $\theta^{(0)}$ 以及先验概率 $\alpha^{(0)}$;

2) 设第 k 步的混合参数估计为 $\theta^{(k)}$ 、 $\alpha^{(k)}$, 利用下面的迭代过程实现极大似然估计。

E 步 根据当前参数 $\theta^{(k)}$ 、 $\alpha^{(k)}$, 计算经过第 k 次迭代后第 j 个区域属于第 i 类的后验概率 $p_{ij}^{(k+1)}$

$$p_{ij}^{(k+1)} = \frac{\alpha_i^{(k)} f_i(\bar{x}_j; \theta_i^{(k)})}{\sum_{i=1}^n \alpha_i^{(k)} f_i(\bar{x}_j; \theta_i^{(k)})} \quad (7)$$

M 步

$$\alpha_i^{(k+1)} = \frac{1}{N} \sum_{j=1}^N P_{ij}^{(k+1)} \quad (8)$$

$$\mu_i^{(k+1)} = \frac{\sum_{j=1}^N P_{ij}^{(k+1)} \bar{x}_j}{\sum_{j=1}^N P_{ij}^{(k+1)}} = \frac{1}{N \alpha_i^{(k+1)}} \sum_{j=1}^N P_{ij}^{(k+1)} \bar{x}_j \quad (9)$$

$$\sigma_i^{(k+1)} = \sqrt{\frac{\sum_{j=1}^N P_{ij}^{(k+1)} (\bar{x}_j - \mu_i^{(k+1)})^2}{\sum_{j=1}^N P_{ij}^{(k+1)}}} = \sqrt{\frac{1}{N \alpha_i^{(k+1)}} \sum_{j=0}^N P_{ij}^{(k+1)} (\bar{x}_j - \mu_i^{(k+1)})^2} \quad (10)$$

在每一步迭代过程中求解区域特征的能量值

$$E^{(k+1)} = \sum_{j=0}^N (-\log(\sum_{i=0}^N P_{ij}^{(k+1)})) \quad (11)$$

式中 $E^{(k+1)}$ 表示第 $k+1$ 步后的能量值。EM 算法的实质就是使概率最大, 对每个区域的后验概率取负对数并求和就等效于整幅图像物理意义上的能量, 负对数函数是减函数, 概率的不断增大就对应于能量的不断减小。从物理意义上来说, 能量越大的物体越不稳定, 能量越小的物体越稳定。所以在迭代过程中用区域特征的能量值 E 作为比较的标准, E 越小参数估计越准确。

EM 算法的结果受初始值的影响较大, 容易陷入局部极值, 这个问题可以通过优化初始值来改善。在 EM 算法作为参数估计算法提出时, 使用随机方法对其初始化, 但该方法具有很大的随机性, 所得结果非常不稳定。现在应用较多的是 K-means 算法, 它是聚类分析中应用最广泛的划分算法。主要过程为: 首先随机选择 k 个对象作为初始聚类中心, 再计算其他对象与聚类中心的距离, 根据相似度(最小距离)聚类, 再计算新的聚类中心, 迭代更新, 直到目标函数(一般为均方差)收敛达到较优结果。

为了进一步提高参数估计的准确性, 引入自身反馈机制生成最优初始值, 从而优化 EM 算法。该方法借鉴了控制论中的负反馈原理, 即将系统的输

出重新返回到输入端并以某种方式改变输入,使系统输出与目标的误差减小,系统趋于稳定。具体步骤如图 2 所示:首先将 EM 算法看做一个输入输出控制系统,随机得到 M 个 EM 算法的初始估计参数 $\theta_m^{(0)}$ 和先验概率为 $a_m^{(0)}$,其中 $m = 1, \dots, M$ 。为了平衡准确率和速度,文中 M 取 60;然后将该 M 个参数输入 EM 算法控制系统,得到 M 个估计结果 θ_m, a_m 和后验概率 p_{ijm} ;最后针对第 m 个估计结果根据式 (11) 计算区域特征的能量值 E_m ,比较得出最优结果作为初始化参数实现基于区域的高斯混合模型的参数最终估计。




图 2 自身反馈初始化

Fig. 2. Self-feedback initialization process

3 实验结果与分析

3.1 分割性能评价指标

用整体准确率和 Kappa 系数来衡量分割算法的准确性。整体准确率是指像素正确标记的正确率。Kappa 系数是用来评价分类效果和分割算法准确性的参数,其计算式为

$$Kappa = \frac{P(A) - P(E)}{1 - P(E)} \quad (12)$$

式中, $P(A)$ 为整体分类精度, $P(E)$ 为期望分类精度。通常, Kappa 系数的范围为 $[-1, 1]$, 当系数值位于 $[0.41, 0.6]$ 中时为中等一致, 当系数值位于 $[0.61, 0.8]$ 中时为大体一致, 当数值大于 0.8 时为几乎完全一致。

3.2 合成 SAR 图像的分割

首先利用合成 SAR 图像来进行实验。选取的原始合成图像包括不同半径的圆形、不同宽度的直线和波纹线, 其大小为 512×512 , 对该图像加上不同视数的相干斑噪声获得一组合成 SAR 图像, 视数 L 分别为: 50, 25, 20, 15, 10, 5, 3, 2。

首先验证提出的自身反馈初始化方法的有效性。将本文方法与 K-means 聚类初始化法分别应用到 EM 算法中, 利用基于像素的 GMM 聚类算法对合成图像进行分割, 并比较结果的准确性, 如表 1 所

示。提出的自身反馈初始化方法要明显优于 K-means 初始化方法, 特别是在相干斑噪声较大的情况下。

表 1 初始化方法性能比较

Tab. 1 Performance comparison of initialization methods

L	初始化方法(整体准确率/Kappa 系数)	
	K-means	自身反馈
50	99.812/0.994 0	99.812/0.994 0
25	98.087/0.940 5	98.087/0.940 5
20	95.273/0.862 0	96.775/0.901 3
15	76.884/0.494 8	87.249/0.675 2
10	69.302/0.494 8	72.764/0.433 2
5	54.640/0.229 6	66.941/0.348 2
3	56.035/ -0.267 2	62.754/ -0.223 2
2	60.088/ -0.233 3	61.290/ -0.226 0

将已证明有效的自身反馈初始化方法应用到 RGMM 聚类算法中, 并选取下面两种分割方法与其进行对比, 分别为: 基于像素的 GMM 聚类, 即对图像直接建立高斯混合模型实现聚类分割; 基于区域的 K-means 聚类(RK-means), 即先用分水岭算法得到基本区域, 再利用 K-means 算法实现区域的合并。

表 2 列出了 3 种分割算法对不同相干斑噪声水平的合成图像进行分割所得的分割准确性。在所有的不同相干斑噪声水平下, RK-means 聚类和提出的 RGMM 聚类的准确性都要高于基于像素的 GMM 聚类, 特别是在噪声较大时, 这种优势更加明显。这说明区域水平的聚类在抗噪声能力方面要强于像素水平的聚类, 其主要原因是原始图像经过分水岭分割之后, 虽然形成的是过分割区域, 但每个区域的内部特征基本相似, 可归结为一个类, 这样就缓解了由于

表 2 分割准确性比较(整体准确率/Kappa 系数)

Tab. 2 Comparison of segmentation accuracy

(overall accuracy / Kappa coefficient)

L	像素 CMM	基于区域水平	
		RK-means	RGMM
50	99.812/0.994 0	99.960/0.998 7	99.888/0.996 5
25	98.087/0.940 5	99.754/0.992 3	99.672/0.989 7
20	96.775/0.901 3	99.603/0.987 6	99.546/0.985 7
15	87.249/0.675 2	99.233/0.976 1	99.309/0.978 2
10	72.764/0.433 2	98.038/0.940 1	98.858/0.964 0
5	66.941/0.348 2	92.482/0.790 9	97.511/0.921 5
3	62.754/ -0.223 2	85.634/0.639 8	95.136/0.862 5
2	61.290/ -0.226 0	77.185/0.490 9	92.218/0.772 3

局部不同噪声给分割带来的误差。当视数大于 15 时,即相干斑噪声较小时,RK-means 聚类要略优于 RGMM 聚类;当视数小于 15 时,即相干斑噪声较大时, RGMM 聚类明显优于 RK-means 聚类。

3 种方法对噪声图像的分割结果如图 3 所示。对图 3(a)添加视数为 5 的相干斑噪声,所得的噪声图像如图 3(b)所示。在图 3(c)中,由

于相干斑的影响,大量的细节被错误得划分。在图 3(d)中,虽然采取了基于区域的方法,但由于聚类中心的随机选择性也造成了较多的误分区域。而在图 3(e)中,首先基于区域的表示方法可以有效地抵抗相干斑噪声的影响,然后在 EM 算法初始化的方面采取自身反馈机制,使得分割结果更加准确。

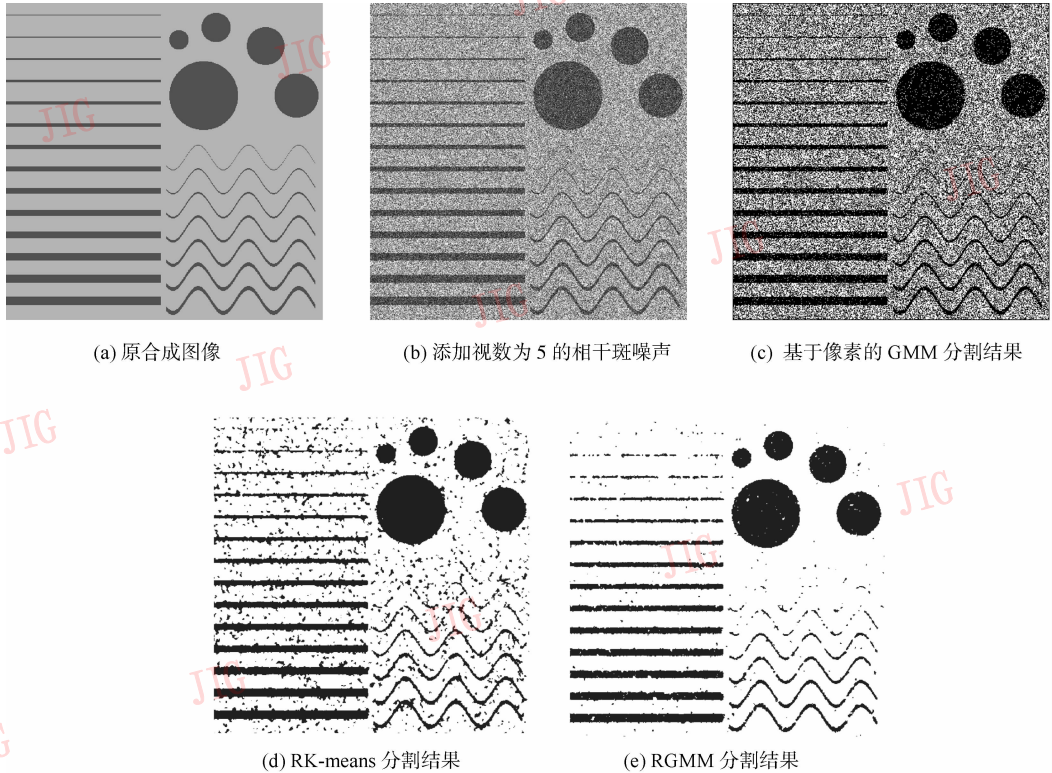


图 3 合成 SAR 图像的分割结果

Fig. 3 Segmentation results of synthetic SAR image

3.3 真实 SAR 图像的分割

将提出的算法应用到两幅 SAR 图像的分割上以证实其在实际应用中的价值,如图 4 和图 5 所示。

图 4(a)是工作在 ScanSAR C-频段模式的 RADARSAT-1 卫星在 1997 年 10 月 13 日拍摄的 Beaufort 海的 SAR 海冰图像,分辨率为 100 m,大小为 1024×768 。其中,图像中左下方是海水,右边较亮的区域为灰冰,其他区域表示新冰。为了更好地比较分割细节,图(f)一(i)为对应图(a)一(d)中方框对应的细节放大图。由图可看出,基于像素的 GMM 分割由于噪声的影响,得到的图像依然保留着很多斑点,产生大量的孤立误分小区域。而 RK-means 聚类分割以及 RGMM 分割,由于采用区域的方式来代替像素,其准确率有了明显的提高。

图 4(c)一(d)的分割效果相差不大,主要原因是真实 SAR 图像相干斑噪声的等效视数为 42,噪声强度较小,使得区域水平的聚类结果近似。

图 5(a)是 RADARSAT-2 卫星在 2008 年 5 月 10 日拍摄的缅甸西南海岸的 SAR 图像,其极化方式为 HH 极化,分辨率为 3 m,大小为 381×512 。图像中上半部分和右下角为海岸,中间部分为海水。图中的海岸部分由于相干斑噪声的影响造成区域的一致性非常差,存在很多孤立的误分类别点。由于采用了区域的方法,图 5(c)(d)较图 5(b)的抗噪声能力要提高很多。本幅真实 SAR 图像的相干斑噪声强度较大,其等效系数为 7,此时 RGMM 要更优于 RK-means,特别是在海岸部分,图 5(d)在保持边缘的情况下使得同质区域的误分大大少于图 5(c)。




图 4 Beaufort 海 SAR 海冰图像的分割结果

Fig. 4 Segmentation results of sea ice SAR image (Beaufort Sea)

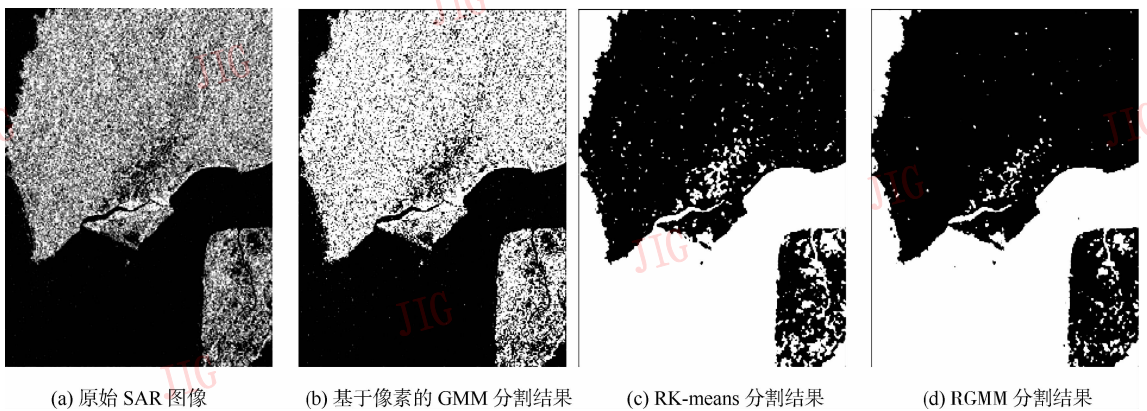


图 5 缅甸西南海岸的 SAR 图像的分割结果

Fig. 5 Segmentation results of SAR image (the southwest coast of Myanmar)

4 结 论

结合分水岭区域化和 GMM 聚类提出一种有效的区域聚类算法用于分割 SAR 图像。新算法引入区域特征表征像素间相关性,克服了传统的 GMM 算法只考虑像素自身特征、对噪声较为敏感的缺点;利用自身反馈机制优化 EM 算法,提高了参数精度。新算法在提高图像分割准确性的同时达到了降噪的效果。

将本文算法运用到合成图像和两幅真实 SAR 图像中,实验证明该算法的可行性和准确性,特别是在相干斑噪声较强的 SAR 图像上有很大的实用价值。所采用的区域特征是灰度均值信息,如何结合区域其他特征以及区域之间的相互关系来进行聚类值得进一步研究。

参考文献 (References)

- [1] Song Jianshe, Zheng Yongan, Yuan Lihai. Understanding and Applications of Synthetic Aperture Radar Images [M]. Beijing: Science Press, 2008 :8,105-123. [宋建社, 郑永安, 袁礼海. 合成孔径雷达图像理解与应用 [M]. 北京: 科学出版社, 2008 :8,105-123.]
- [2] Oliver C, Quegan S. Understanding Synthetic Aperture Radar Image [M]. Boston London: Assech House, 1998.
- [3] Otsu N. A threshold selection method from gray-Level histograms [J]. IEEE Transactions on Systems, Man and Cybernetics, 1979, 9(1) :62-66.
- [4] Coleman G B, Andrews H C. Image segmentation by clustering

- [J]. Proceedings of the IEEE, 1979, 67(5) :773-785.
- [5] Adams R, Bischof L. Seeded region growing [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1994, 16(6) :641-647.
- [6] Bovik A C. On detecting edges in speckle imagery [J]. IEEE Transactions on Acoustics, Speech and Signal Processing, 1988, 36(10) :1618-1627.
- [7] Wang Xiaofeng, Zhang Xiaoping. A new localized superpixel Markov random field for image segmentation [C] // 2009 IEEE International Conference on Multimedia and Expo. New York: IEEE Computer Society, 2009 :642-645.
- [8] Fraley C, Raftery A E. How many clusters ? Which clustering method ? Answers via model-based cluster analysis [J]. The Computer Journal, 1998, 41(8) :578-588.
- [9] Vincent L, Soille P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991, 13(6) :583-598.
- [10] Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm [J]. Journal of the Royal Statistical Society Series B (Methodological), 1977, 39(1) :1-38.
- [11] Biernacki C. Initializing EM using the properties of its trajectories in Gaussian mixtures [J]. Statistics and Computing, 2004, 14(3) :267-279.
- [12] Canny J. A computational approach to edge detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986, PAMI-8(6) :679-698.
- [13] Ren Xiaofeng, Malik J. Learning a classification model for segmentation [C] // Proceedings of the ninth IEEE International Conference on Computer Vision. Nice, France: Institute of Electrical and Electronics Engineers Inc. , 2003, 1 :10-17.