

文章编号: 1001-1595(2011)02-0148-08

基于 Contourlet 域 HMT 和 D-S 证据融合的 SAR 图像分割

吴 艳¹, 焦惊眉², 杨晓丽¹, 肖 平², 李 明³

1. 西安电子科技大学 电子工程学院, 陕西 西安 710071; 2. 陕西测绘局, 陕西 西安 710054; 3. 西安电子科技大学 雷达信号处理国家重点实验室, 陕西 西安 710071

Segmentation Algorithm for SAR Images Based on Fusion of HMT in the Contourlet Domain and D-S Theory of Evidence

WU Yan¹, JIAO Jingmei², YANG Xiaoli¹, XIAO Ping², LI Ming³

1. School of Electronics Engineering, Xidian University, Xi'an 710071, China; 2. Shaanxi Bureau of Surveying & Mapping, Xi'an 710054, China; 3. National Key Lab. of Radar Signal Processing, Xidian University, Xi'an 710071, China

Abstract: Considering the Contourlet's advantages of multiscale, localization, directionality and anisotropy, a new segmentation algorithm is proposed for SAR images based on hidden Markov tree in the Contourlet domain and D-S theory of evidence. Firstly, the algorithm extends the hidden Markov tree framework to the Contourlet domain. Then, the clustering and persistence of the Contourlet transform are effectively fused using D-S theory in HMT model, and the maximum a posteriori (MAP) segmentation equation for the new fusion model is deduced in the end. The algorithm has been used to segment the real SAR images, and experimental results show that the proposed algorithm effectively reduces the influence of multiplicative noises, improves the segmentation accuracy and provides a better visual quality for SAR images over the algorithms based on HMT-MRF in the wavelet domain, HMT and MRF in the Contourlet domain, respectively.

Key words: SAR images segmentation; Contourlet transform; hidden Markov tree (HMT); D-S theory of evidence

摘 要: 针对 Contourlet 的多尺度、局部化、方向性和各向异性等优点, 结合隐马尔科夫树 (hidden Markov tree, HMT) 模型和 D-S (Dempster-Shafer) 证据理论, 提出一种新的 SAR 图像分割算法。该算法首先将隐马尔科夫树模型推广到 Contourlet 域, 在多尺度 HMT 上采用 D-S 证据融合理论有效地融合 Contourlet 系数的持续性和聚集性, 最后导出融合后的最大后验多尺度分割公式。本文算法对实测 SAR 图像进行分割试验, 试验结果表明: 与小波域上的 HMT-MRF (Markov random field, MRF) 融合分割及 Contourlet 域上 HMT 和 MRF 分割算法相比, 本文算法在抑制斑点噪声的同时, 可有效地提高 SAR 图像的分割精度。

关键词: SAR 图像分割; Contourlet 变换; 隐马尔科夫树 (HMT); D-S 证据理论

中图分类号: P237 文献标识码: A

基金项目: 国家自然科学基金 (60872137); 国防预研基金 (9140C010307100C01); 航空科学基金 (20080181002)

1 引言

小波理论日益成熟和发展, 并在图像处理领域得到了广泛应用^[4,5]。小波基对含点状奇异的目标函数是最优的基, 但对具有线状奇异的函数, 小波系数则不再稀疏。在高维情况下, 小波分析不能充分利用数据本身特有的几何特征, 不能够很好地挖掘图像中方向边缘信息, 容易产生方块效应和 Gibbs 现象^[2]。同时由一维小波张成的二维离散小波变换只具有有限个方向, 不能“最优”表示含线或者面奇异的二维图像。2002 年, 文献 [6] 提出了一种“真正”的图像二维表示方法——Contourlet 变换。它是利用塔形分解 (LP) 和方

向滤波器组 (DFB) 实现的一种多分辨的、局部的、方向的图像表示方法, 继承了 Curvelet^[7] 变换的各向异性的多尺度关系, 在某种意义上可以认为是 Curvelet 变换的另一种快速有效的数字实现。Contourlet 基的支撑区间具有长宽比随尺度变化的“长条形”结构, 因而能更好地捕捉图像边缘信息, 能够用少量的系数有效地表示平滑轮廓。Contourlet 变换具有小波所具有的多分辨率和时频局部性, 同时具有高度的方向性和各向异性。

合成孔径雷达 (SAR) 图像分割是图像目标识别与解译的重要环节, 它可以提供图像的整体结构信息, 以揭示 SAR 图像的本质, 为 SAR 系统的自动目标识别 (ATR) 建立基础, 并推动 SAR

的应用,近年来这一领域已逐渐成为国际、国内的研究热点。它的目的是将图像中的目标从复杂的背景中提取出来以便进行进一步的分析。SAR 发射的是一系列单波长、同相位的电磁波,通过接收反射雷达信号来获取探测物图像,在此过程中由于电磁波发生相干现象产生大量的斑点噪声,传统的光学图像分割算法无法抑制噪声影响,得不到满意的分割结果。在 SAR 图像中,像素很少独立存在,而是在某个几何区域内,具有相同的特征。如在农业区域中,中心像素和它邻近的像素同属于一个类的概率很高。这就意味着,在 SAR 图像分割过程中,考虑相邻像素丰富的空间信息将会得到更加精确的分割结果。在过去的几十年中,很多的分割方法都考虑了空间邻域的相关信息^[1,2,5]。在图像处理领域,Markov 随机场(MRF)一直占据着重要的地位,原因在于 MRF 中对联合分布密度函数的推理简单。但是 MRF 尺度单一,如果用于图像处理,需要对像素设定不自然的先后顺序,从而导致方向性块效应。为了解决上述问题,多尺度的 Markov 模型应运而生,其重要特点是在树模型上定义了因果 Markov 性。因此,多尺度 Markov 模型具有可变尺度、计算量小(无需迭代)、无需对数据设定不自然的顺序等优点。除邻域的相关信息外,在多尺度分割中,相邻尺度间的像素也存在着丰富的相关信息。描述多尺度相关信息常用的统计模型是隐 Markov 树(HMT)模型^[6,8]。HMT 结合了小波变换与多尺度 Markov 模型,能很好地刻画小波系数的统计特征。但是由于小波基较差的角度分辨率决定了它不能充分捕捉图像的高维奇异性信息,分割图像容易产生方向边缘成分模糊和奇异性扩散现象。该模型已推广到 Contourlet 域,且应用到 SAR 图像分割中^[9],取得了优于小波域 HMT 的分割结果。这种算法虽提高了分割的准确性,但这种基于 HMT 的算法并没有考虑 Contourlet 的聚集性,不能解决斑点噪声的影响。基于信息融合的 D-S(Dempster-Shafer)论证的方法,融合了空间邻域的相关信息,在图像分割中取得较好的分割结果^[10],但该算法在融合的过程中,仅考虑了邻域信息,没有考虑粗尺度和细尺度之间的全局和细节的关系,容易产生误分。

本文分析了 Contourlet 的统计特性,提出了一种基于 Contourlet 域 HMT 和 D-S 证据理论融合的 SAR 图像分割方法。新算法既考虑了 Con-

tourlet 变换的持续性,用含隐类属的 HMT 模型描述尺度内的相关性,又考虑了 Contourlet 变换的聚集性,用 D-S 证据理论融合相关领域信息。新算法采用最大后验分割,并采用张弛处理的方法导出最终的最大后验分割公式。实验结果表明,本文算法有效地抑制了斑点噪声对 SAR 图像分割的影响,减少了误分,提高了分割精度。

2 Contourlet 系数统计分析

Contourlet 变换也称塔型方向滤波器组(PDFB)分解,Contourlet 基的支撑区间具有随尺度而长宽比变化的“长条型结构”,它将多尺度分析和方向分析分开进行。Contourlet 变换对图像应用双重滤波结构,首先由拉普拉斯塔形分解(LP)对图像进行多尺度分解以捕获点状奇异性,然后由方向滤波器组(DFB)将分布在同方向上的奇异点连接成周线结构(contour segment)。Contourlet 变换最终以类似于周线结构来逼近原图像,这也是被称为 Contourlet 的原因。Contourlet 变换每一尺度可以分为 2 的任意次方个子带(如图 1(b)显示了(a)中原图像的两层 Contourlet 变换结果,分别对应了 4 个子带和 8 个子带),这使得 Contourlet 成为唯一一个既能严格采样,又在分解上具有很强灵活性的变换。




图 1 Contourlet 变换示意图

Fig. 1 Schematic diagram for Contourlet transform

若对图 1(b)中最细尺度上的一个子带的系数作统计直方图,可得到图 2(a)所示的结果。从图中可以看到,在零幅度处有陡峭的尖峰且在两边有着长长的拖尾,计算其峰态值为 27.445,比高斯分布的 3 要大得多。测试其他的图像也得到同样的结果,这说明图像在 Contourlet 域的系数分布形式是一种非高斯分布的形式,Contourlet 变换是稀疏的,它的大部分系数为零,其系数分布是非高斯分布,而是条件高斯分布。也就是说,Contourlet 的系数可由混合高斯模型来描述,如

图 2(b) 所示: 边缘分布仅仅描述了单个系数的独立分布而没有考虑系数之间的相关性。既然 Contourlet 系数在图像的边缘或者与图像边缘方向一致时取得最大值, 那么显然 Contourlet 系数存在着相关性。图 3 分别显示了在父代(PX)和邻域(NX) 已知的情况下系数的条件分布情况。观察图 3, 首先, 可以发现这些分布呈现‘蝴蝶结’的形状, 且系数的方差与它们条件系数的幅值相关。其次, 尽管由于 Contourlet 变换的‘过完美’性, 系数之间是相关的, 但它们的条件分布是近似无关的, 因为 Contourlet 系数 X 在 PX 或 NX 已知情况下的条件分布的期望 $E[X | \cdot] \approx 0$ 。因此, 可以得出结论, 自然图像的 Contourlet 系数在局部空间和相邻尺度间具有很强的相关性, 即聚集性和持续性^[6, 8, 12]。




图 2 边缘概率分布图

Fig. 2 Marginal probability distributions




图 3 一子带 Contourlet 系数的条件分布

Fig. 3 Conditional distribution of Contourlet coefficients in one subband

3 基于 Contourlet 域 HMT 和 D-S 证据理论的 SAR 图像融合分割

3.1 Contourlet 变换的 HMT 模型

从上述分析可知: Contourlet 变换是稀疏的, 它的大部分系数为零, 其系数分布是非高斯分布, 但条件高斯分布。也就是说, Contourlet 的系数

可由混合高斯模型来描述^[11]。通常用隐马尔科夫模型 HMMs 来对 Contourlet 系数的联合概率建模。 N 状态的 HMMs 为每一个系数建立一个隐状态变量, 若状态变量已知, 系数服从于某一随机分布。对于 Contourlet 系数, 在隐状态已知的条件下, 系数服从于零均值的高斯分布。那么, 每一个系数可有一个 N 维的状态概率矢量 p 和 N 维的标准差矢量 δ 来刻画。即

$$\left. \begin{aligned} p &= (p_1, p_2, \dots, p_N)^T \\ \delta &= (\delta_1, \delta_2, \dots, \delta_N)^T \end{aligned} \right\} \quad (1)$$

式中, $1, 2, \dots, N$ 表示状态。

在 HMMs 模型中, 系数之间的相关性通过系数的隐状态来建立, 而系数间相互独立。对于任意两个系数 m 和 n , 都有一个 $N \times N$ 的状态转移矩阵 $A_{m,n}$, 其中的一个元素 (k, l) 表示系数 m 的状态是 k , 系数 n 的状态是 l 的概率。为减少参数的数目, 同小波域的 HMMs 一样^[8], 可以把同一尺度上的系数‘捆绑’在一起。

隐马尔科夫树(HMT)通过四叉树的结构来描述数据之间的相关性。准确地说, 是建立父系数和四个子系数隐状态之间的联系。HMT 模型直接建立了父代和子代之间的联系, 通过同一父系数, 间接地建立了相邻系数的联系。对于 J 尺度, 尺度 j 内 m_j , ($j = 1, 2, \dots, J$) 个方向的 Contourlet 变换, 它的 HMT 模型有如下的参数:

$p_{1,k}$, 其中 $k = 1, \dots, m_1$, 表示最粗尺度各个方向的根结点概率矢量;

$A_{j,k}$, 其中 $j = 1, \dots, J, k = 1, \dots, m_j$, 方向子带 k 从尺度 $j-1$ 到尺度 j 的转移概率矩阵;


$\delta_{j,k}$, 其中 $j = 1, \dots, J, k = 1, \dots, m_j$, 子带 k 在尺度 j 的标准差矢量。

状态转移概率矩阵 $A_{j,k}$ 用来描述系数幅值的尺度持续性。对于每一组母子隐状态 $\{S_{p(i)}, S_i\}$, 状态转移概率 $\epsilon_{m'}^{p(i), m}$ 表示当母系数大或者小时, 其子系数大或者小的概率, 其中 $m, m' = S, L$ (S 代表小状态, L 代表大状态)。对于每个位于尺度 j , 方向 k 上的系数 i , 状态转移概率矩阵 $A_{j,k}$ 可表示为

$$A_{j,k} = \begin{bmatrix} \epsilon_s^{p(i), S} & \epsilon_L^{p(i), S} \\ \epsilon_s^{p(i), L} & \epsilon_L^{p(i), L} \end{bmatrix} = \begin{bmatrix} \epsilon_s^{p(i), S} & 1 - \epsilon_s^{p(i), S} \\ 1 - \epsilon_L^{p(i), L} & \epsilon_L^{p(i), L} \end{bmatrix} \quad (2)$$

以上参数可以用 EM (expectation-maximization) 算法估计^[12]。

另外, 与小波域的 HMT 模型不同, Contourlet 域的 HMT 可以考虑方向间的相关性, 而小波域的没有考虑。这个不同如图 4 所示。



(a) 小波域四叉树结构 (b) Contourlet 域四叉树结构

图 4 小波域上和 Contourlet 域上四叉树的不同

Fig. 4 The difference between the quad-tree structures in wavelet and Contourlet domain

如图 4 所示,在小波域 HMT 中,父子系数之间的联系仅体现在三个有限的小波方向上。因此,小波 HMT 模型的系数在每个方向上都是相互独立的。相反,Contourlet 系数四个子系数可以分布在两个可分离的方向子带上。从图 4 可以观察到在 Contourlet 情况下,一个 Contourlet 系数的四个子系数分布在两个子带上,而在小波域 HMT 中,一个父系数的四个子系数只分布在一个子带上。结果,Contourlet HMT 中的相关树在较细子带中可以跨越多个相邻方向,因此,系数间的相关性的建模与局域间的相关性的建模方式相同。也就是说,Contourlet HMT 模型有效地捕捉了尺度间、空间、方向间的相关性。

3.2 基于 D-S 证据理论的 SAR 图像融合分割思想

上文 HMT 对 SAR 图像粗分割,在不同的尺度上得到不同的分割结果。这种分割并没有把粗尺度和细尺度分割结合起来进行类属判断,也没有考虑尺度内空间邻域的相关性。这里采用 D-S 论证推理的方法把粗尺度和细尺度的分割结果结合起来进行类属判断。融合的信息包括两个部分:粗尺度 $j-1$ 上父代的类属和细尺度 j 上邻域的分割信息。以此在每个尺度上融合直到最细尺度 J 。该方法的优点是既考虑了分割的全局性和细节性,又考虑了邻域信息,起到抑制斑点噪声的作用。

D-S 论证推理的基础就是为来源于某一数据源的像素的标示定义一个置信指派函数: $m(A)$, 即像素点的标示为 A 的概率。它的核心是直和,把来源于两个或多个数据源的概率分布综合在一起,以减小不确定性。对于两个数据源来说,直和的定义为

$$m_{12}(z) = \frac{1}{1 - \beta_x \prod_{y=z} m_1(x) m_2(y)} \rightarrow m_1(x) m_2(y), \beta \neq 1 \quad (3)$$

式中,

$$\beta = \sum_{x \cap y = \phi} m_1(x) m_2(y) \quad (4)$$

本文中仅仅考虑四邻域的情况。假设这四邻域的概率密度函数已知。在尺度 j 上,邻域 n 属于类 w_j , 中心像素 g 属于类 w_c 的条件概率定义为

$$m(g \in w_c | n \in w_j) \quad (5)$$

对于 m , 需考虑所有可能的 w_j 值, 则式(5)改为

$$m(g \in w_c | n \in w_j, \forall j) \quad (6)$$

在考虑粗尺度上全局性时, 直接考虑父代本身的类属, 对于尺度 j 中心像素 g , 它的父节点定义为 $c_{\rho(g)}$, 那么, 中心像素 g 属于类 w_c , 父节点 $c_{\rho(g)}$ 属于 w_j 的条件概率定义为

$$m(g \in w_c | c_{\rho(g)} \in w_j, \forall j) \quad (7)$$

中心像素 g 所有可能类的置信指派函数为

$$\langle m_{g, n, c_{\rho(g)}}(w_c) \rangle = \{m(g \in w_1 | n \in w_j, \forall j), \dots, m(g \in w_2 | c_{\rho(g)} \in w_j, \forall j), \theta_n\} \quad (8)$$

式中, θ_n 是加权因子, 控制邻域对中心像素影响的大小。利用直和把四邻域和父节点的信任度函数综合起来, 得到

$$\langle m_g(w_c) \rangle = \langle m_{g, n, c_{\rho(g)}}(w_c) \rangle \quad (9)$$

同其他的空间一致性方法一样, 式(9)同样用迭代的方法求到一个最佳值。第 $(k+1)$ 次迭代为

$$\langle m^{k+1}(w_c) \rangle = \langle m^k(w_c) \rangle \langle m_g^k(w_c) \rangle = \langle m^k(w_c) \rangle \langle \langle m_{g, n, c_{\rho(g)}}(w_c) \rangle \rangle \quad (10)$$

$\langle m^k(w_c) \rangle$ 是中心像素在第 k 次迭代时的概率密度函数。迭代时, 式(10)需设置初始值。初始值设置如下

$$m(g \in w_c | n \in w_j, \forall j) = (1 - \theta_n) \sum_j p_{gn}(w_c | w_j) p_n^k(w_j) \quad (11)$$

$p_{gn}(w_c | w_j)$ 的值采用 Gibbs 分布^[13]的方法得到

$$p_{gn}(w_c | w_j) = \frac{1}{z} \exp\{-U(w_c)\} \quad (12)$$

$$U(w_c) = \sum_{\rho_g} \beta [1 - \xi(w_c, w_{\rho_g})] \quad (13)$$

式中, w_{ρ_g} 表示中心像素 g 的邻域和父节点。

从式(3)可以看出, 一个完全不确定的数据源对结果没有影响, 所以本文通过改变 θ_n 的值来控制循环次数, 即为 θ_n 设置某一初始值, 在循环的过程中以步长 d 增长, 若 $\theta_n = 1$, 则终止循环, 否则继续。本文初始设置 $\theta_n = 0.4, d = 0.125$ 。

3.3 基于最大后验的多尺度融合分割公式的导出

本文采用最大后验分割方法。设图像有 H 个

像素点, 其像素值写成矢量的形式为 $X = \{x^1, x^2, \dots, x^H\}$, 相应的实际分类为 $\Omega = \{w_{c1}, w_{c2}, \dots, w_{cH}\}$, 假设图像共有 C 类, 则 w_{cH} 为 C 类中的任意一个。最大后验分割即是求 Ω 的最优估计 $\hat{\Omega}$, 按照 Bayes 准则^[14]

$$\hat{\Omega} = \underset{\Omega}{\operatorname{argmax}} \{p(X|\Omega)p(\Omega)\} \quad (14)$$

为减少计算复杂度, 只考虑单个像素级上的最大后验。即对于像素 g , 属于类 w_c 的概率, 即是求 $p(w_c|x_g, w_{\partial g})$, $w_{\partial g}$ 表示邻域和父节点类属。则像素 g 的类属 w_{cg} 的估计为

$$\hat{w}_{cg} = \underset{w_c}{\operatorname{argmax}} \{p(w_c|x_g, w_{\partial g})\}, \forall g \quad (15)$$

假设 x_g 与 $w_{\partial g}$ 相互独立, 式(15)可以写为

$$p(w_c|x_g, w_{\partial g}) \propto p(x_g|w_c)p(w_c|w_{\partial g}) \quad (16)$$

则最终的融合分割式为

$$w_{cg} = \underset{w_c \in \{1, 2, \dots, C\}}{\operatorname{argmax}} p(x_g|w_c)p(w_c|w_{\partial g}) \quad (17)$$

4 试验结果及分析

本文在进行 Contourlet 变换时, 采用‘9-7’ LP 滤波器进行多尺度分解, 采用‘pkva’方向选择滤波器进行方向分解。为了证明本文算法的有效性, 分别选择了加噪合成纹理图像和真实的 SAR 图像进行了试验仿真。

首先, 使用两幅加噪合成纹理图像(加均值为 0, 方差为 0.005 乘性斑点噪声) 测试本文的算法

的分割效果。图 5(a) 和图 6(a) 是两幅加了噪声的合成纹理图像, 手工分割结果如图 5(b) 和图 6(b) 所示, 本文算法对其分割的结果分别如图 5(e) 和图 6(e) 所示。为了进一步证明算法的有效性, 还选择了其他两种图像分割算法进行对比, 分别为小波域上 HMT-MRF 模型分割算法和 Contourlet 域上 HMT 模型分割算法, 它们的分割结果分别如图 5(c)、(d) 和图 6(c)、(d) 所示。从图 5 可以看出, 在对中间圆形进行分割时, 三种分割方法都很好地分割出了圆形, 但图 5(c) 所示的小波方法并不能很好地描述轮廓, 而图 5(d) 和图 5(e) 所示的结果边缘定位更准确, 更接近于原始形状; 图 6 也显示了相似的结果, 图 6(c) 的小波方法对有些凹口根本没有分割出来, 直接切掉了, 而图 6(d) 和 (e) 却保持较好。这是由于 2-D 小波是一维小波变换的张量积, 只具有有限个方向(水平、竖直和对角方向), 不能“最优”表示含线或者含面奇异的二维图像。同时也说明 Contourlet 变换比小波变换具有更强的方向性。此外, 图 5(d) 和图 6(d) 所示的 Contourlet 域的 HMT 模型分割方法, 由于未考虑邻域信息, 仍然存在很多误分, 而图 5(e) 和图 6(e) 所示的本文算法既考虑了尺度间系数的持续性又兼顾了尺度内系数的聚集性, 从而弥补了这一缺陷。




图 5 合成纹理图像(a)分割

Fig. 5 The segmentation results of synthetic texture Fig. 5(a)




图 6 合成纹理图像(a)分割

Fig. 6 The segmentation results of synthetic texture Fig. 6(a)

下面以错分概率作为客观评价标准,以手工分割作为真实分割,给出三种分割算法的定量评价。错分概率定义为分割结果中错分像素点数总和与类内像素点总数的比值。两幅合成纹理图像分割的评价见表 1。从表 1 中可以看出,本文算法对图 5 和图 6 分割的错分率分别为 0.015 9 和 0.018 1,均小于其他两种方法所得结果,与主观评价一致。

表 1 两幅合成纹理图像分割结果的错分率评价

Tab. 1 Segmentation misclassification ratios of different algorithms for two texture images

图像	小波域 HMT-MRF	Contourlet 域 HMT	本文算法
合成纹理图 5	0.0174	0.0189	0.0159
合成纹理图 6	0.0300	0.0310	0.0181

其次,合成纹理图像的分割只能说明算法的有效性,不能说明其泛化能力。下面使用实测 SAR 图像测试本文算法的有效性。图 7(a) 是 L 波段,HH 极化的机载 SAR 图像,等效视数 ENL = 1.481 5,图 8(a) 是 Ku 波段的机载 SAR 图像,等效视数 ENL = 3.220 3。它们都包含了两类纹理,分别为海洋和陆地。从原图可以看出,陆地部

分的某些区域与海洋部分有极其相似的统计特性,增加了分割难度。本文算法的分割结果如图 7(e) 和图 8(e) 所示。为了证明算法的有效性,本文选择了其他三种图像分割算法做对比,分别为小波域 HMT-MRF 分割算法、Contourlet 域 MRF 分割算法以及 Contourlet 域 HMT 分割算法,它们的分割结果分别如图 7(b)、(c)、(d) 和图 8(c)、(d)、(e) 所示。首先,对比图 7(b)、(e) 和图 8(b)、(e) 所示的结果,可以得到与合成纹理图像分割相同的结论:本文算法较小波方法具有更好的边缘定位和细节保留能力,这是由 Contourlet 变换更好的方向性决定的。其次,观察图 7(c)、(d) 和图 8(c)、(d) 发现,仅仅考虑邻域信息的 Contourlet 域 MRF 方法不能很好地抑制斑点噪声的影响,产生错分和误分。而仅仅考虑父子相关性的多尺度 Contourlet 域的 HMT 方法,虽然得到了更好一点的结果,但仍然有较多的错分和误分。而图 7(e) 和图 8(e) 所示的本文方法既考虑邻域信息聚集性又考虑多尺度信息的持续性,与前两种方法比较显然能更好地抑制乘性斑点噪声的影响,得到较准确的分割结果。通过以上对比证明了本文分割算法的有效性。




图 7 SAR 图像(a) 分割结果

Fig. 7 The segmentation results of real SAR Fig. 7(a)




图 8 SAR 图像(a) 分割结果

Fig. 8 The segmentation results of real SAR Fig. 8(a)

另外,还可以发现无论是合成纹理图像还是实测 SAR 图像,本文算法的分割结果虽然能更好

地描述轮廓,但是边缘出现了一些毛刺。这是因为本文算法的分割窗口最小只能是 2×2 大小,实

际是一种块状的分割,加上边缘也难免出现少量的误分割,表现为毛刺现象。但这并不影响本文算法优势的体现,在实际应用中的大的遥感影像的分割, 2×2 大小的分割窗口已经足够。

下面本文采用了比值图像(ration image)的定量评估指标作为客观评价标准^[15],以说明实测 SAR 图像的分割效果。比值图像是用原始图像和分割后图像相比得到的一幅图像。根据 SAR 图像广泛使用的伽马分布的斑点噪声模型可知,如果每个像素都除以其真实的雷达界面(radar cross section, RCS)值,比值图应该是一幅包含纯斑点噪声并且服从均值为 1 的伽马分布的图像。图中存在的残余结构则可以用来衡量分割的性能。本文采用比值图像的对数归一化似然比 D 、方差 RI_{var} 以及均值 RI_{mean} 来衡量分割效果。

表 2 实测 SAR 图像分割结果的比值图定量评价

Tab. 2 Ration image of different algorithms for two real SAR images

图像	参量	小波域 HMT-MRF	Contourlet 域 MRF	Contourlet 域 HMT	本文 算法
实测 SAR 图 7	$ D $	1.6807	1.7469	1.8569	1.6788
	RI_{mean}	1.0040	1.0242	1.0099	1.0020
	RI_{var}	0.1976	0.4113	0.2226	0.1977
实测 SAR 图 8	$ D $	1.1790	1.4387	1.4342	1.0027
	RI_{mean}	1.0159	0.9861	1.0170	1.0151
	RI_{var}	0.0172	0.0613	0.0385	0.0094

D 是比值图像的归一化的对数测量值,为非负值,只有当所有的像素都具有相同强度时,它才等于零,因此当 $|D|$ 的值越小,表明分割图的各区域的同质性越好,也即是相应的分割算法的性能较好;比值图的均值 RI_{mean} 则表明分割算法相干斑的抑制情况,值越接近 1 表明分割算法对相干斑噪声的抑制效果越好;而比值图像的方差 RI_{var} 描述比值图像的强度的起伏程度,值越小表明相应的分割性能就越好。表 2 给出了本文算法以及对比算法分割结果的定量评价,从表中可以看出由本文算法得到的各个参量基本都能达到最优,即使不是最优也能与最优值十分接近。这与主观评价是一致的,充分说明了本文算法的有效性和普适性。

从上述分析中可知,本文算法将 Contourlet 域内的 HMT 模型和 D-S 论证理论相结合,融合了尺度内系数的聚集性和尺度间系数的持续性,得到了最优的结果。当然理论上的复杂性往往也

会增加一些算法的复杂度,使运行时间增加。表 3 给出了不同分割算法的运行时间,从表 3 中可以看出本文算法的运行时间与其他算法相比有一定的增加,相对 Contourlet 域 HMT 算法,时间增加约为 3.5 s,但这种时间增加所带来的的是分割精度的有效提高,所选择的也是算法效率与分割效果的一个有效折中。本文算法在计算效率与分割性能的综合考虑上还是最优的。

表 3 实测 SAR 图像分割算法运行时间对比

Tab. 3 Running times of different algorithms for two real SAR images /s

图像	小波域 HMT-MRF	Contourlet 域 MRF	Contourlet 域 HMT	本文 算法
实测 SAR 图 7	11.4287	1.6109	8.7924	12.1199
实测 SAR 图 8	11.8920	1.4247	8.7657	12.2070

5 结 论

Contourlet 变换比小波变换具有更强的方向性和对图像的稀疏表达,能够更有效地捕获图像的结构特征和边缘信息。Contourlet 系数也具有非高斯分布特性,可用混合高斯模型对其进行建模,且在局部聚集性和尺度间持续性上具有马尔科夫性。基于 Contourlet 的这些特性,建立了 Contourlet 域的 HMT 模型,同时,根据 D-S 证据推理,把尺度内系数的聚集性和尺度间系数的持续性进行融合,大大降低了乘性斑点噪声对分割算法带来的影响。本文分别采用了加噪合成纹理图像和实测 SAR 图像测试本文算法的分割效果,同时与其他分割方法的分割结果进行了比较。由于本文算法既考虑了邻域和尺度间的相关性,能够很好地抑制斑点噪声的影响。仿真结果表明本文方法能减少错分和误分,有效提高 SAR 图像分割精度,而且还能更平滑地描述轮廓。

参考文献:

- [1] BOVOLO F, BRUZZONE L. A Detail-preserving Scale-driven Approach to Change Detection in Multitemporal SAR Images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(12): 2963-2972.
- [2] XIE H, PIERCE L E, ULABY F T. SAR Speckle Reduction Using Wavelet Denoising and Markov Random Field Modeling [J]. IEEE Transactions on Geoscience and

- Remote Sensing, 2002, 40(10): 2196-2212.
- [3] WU Y, WANG X, LIAO G S. SAR Images Despeckling via Bayesian Fuzzy Shrinkage Based on Stationary Wavelet Transform[C] // Applied and Numerical Harmonic Analysis: Wavelet Analysis and Applications. Berlin: Birkh user Verlag, 2007: 407-418.
- [4] WU Y, ZHANG Q, WANG X, et al. SAR Images Despeckling Based on Hidden Markov Mixture Model in the Wavelet Domain [C] // Proceedings of CIE International Conference on Radar. Shanghai: [s. n.], 2006: 16-19.
- [5] ZHANG Qiang, WU Yan. Wavelet Markov Random Field Based on Context and Hidden Class Label for SAR Image Segmentation[J]. Journal of Electronics & Information Technology, 2008, 30(1): 211-215. (张强, 吴艳. 基于上下文和隐类属的小波域马尔可夫随机场 SAR 图像分割[J]. 电子与信息学报, 2008, 30(1): 211-215.)
- [6] DO M N, VETTERLI M. Contourlets: a New Directional Multiresolution Image Representation [C] // Conference Record of the Thirty-sixth Asilomar Conference on Signals, Systems and Computers. Rochester:[s. n.], 2002.
- [7] CANDÈS E J, DONOHO D L. Curvelets [R]. Stanford: Stanford University, 1999.
- [8] CHOI H, BARANIUK R G. Multiscale Image Segmentation Using Wavelet-domain Hidden Markov Models[J]. IEEE Transactions on Image Processing, 2001, 10(9): 1309-1321.
- [9] SHA Y H, CONG L, SUN Q, et al. Unsupervised Image Segmentation Using Contourlet Domain Hidden Markov Tree Model[J]. Image Analysis and Recognition, LNCS, 2005, 3656: 32-39.
- [10] RICHARDS J A, JIA X P. A Dempster-Shafer Relaxation Approach to Context Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(5): 1422-1431.
- [11] PO D D Y, DO M N. Directional Multiscale Modeling of Images Using the Contourlet Transform[J]. IEEE Transactions on Image Processing, 2006, 15(6): 1610-1620.
- [12] CROUSE M S, NOWAK R D, BARANIUK R G. Wavelet-based Statistical Signal Processing Using Hidden Markov Models [J]. IEEE Transactions on Signal Processing, 1998, 46(4): 886-902.
- [13] DERIN H, COLE W. Segmentation of Textured Images Using Gibbs Random Fields [J]. Computer Vision, Graphics, and Image Processing, 1986, 35(1): 72-98.
- [14] BOUMAN C A, SHAPIRO M. A Multiscale Random Field Model for Bayesian Image Segmentation[J]. Transactions on Image Processing, 1994, 3(2): 162-177.
- [15] CAVES R, QUEGAN S, WHITE R. Quantitative Comparison of the Performance of SAR Segmentation Algorithms [J]. Transactions on Image Processing, 1998, 7(11): 1534-1546.

(责任编辑:雷秀丽)

收稿日期: 2010-02-01

修回日期: 2010-05-10

第一作者简介: 吴艳(1965—), 女, 博士, 教授, 博士生导师, 主要研究方向为多传感器信息融合、图像分析与理解、雷达目标识别。

First author: WU Yan (1965—), PhD, professor, PhD supervisor, majors in multisensor information fusion, image analysis and understanding, and radar target identification.

E-mail: ywu@mail.xidian.edu.cn

测绘出版社部分新书目录

书名	定价/元	初/重版时间	作者
数字摄影测量学	38.00	2010.08	耿则勋 张保明 范大昭 编著
地图设计与编绘	48.00	2011.01	王光霞 等 编著
数字工程的原理与方法(第二版)	48.00	2011.03	边馥苓 编著
工业测量系统原理与应用	38.00	2011.01	李广云 李宗春 编著
遥感精解(修订版)	59.00	2011.01	日本遥感研究会 编 刘勇卫 译
土地登记与地籍系统	30.00	2011.01	[瑞典] Gerhard Larsson 著 詹长根 黄伟 译
空间大地测量学中的大气折射理论	45.00	2011.04	张捍卫 丁安民 雷伟伟 著