



(12) 发明专利

(10) 授权公告号 CN 101609548 B

(45) 授权公告日 2011.04.06

(21) 申请号 200810150926.3

G01S 13/90 (2006.01)

(22) 申请日 2008.09.12

(56) 对比文件

(73) 专利权人 西安电子科技大学

CN 1296861 C, 2007.01.24, 全文 .

地址 710071 陕西省西安市太白路 2 号

CN 1329874 C, 2007.08.01, 全文 .

(72) 发明人 侯彪 刘佩 徐婧 王爽 焦李成
张向荣 马文萍

US 2008/0069456 A1, 2008.03.20, 全文 .

(74) 专利代理机构 陕西电子工业专利中心

JP 特开 2004-318365 A, 2004.11.11, 全文 .

61205

CN 1251145 C, 2006.04.12, 全文 .

代理人 王品华 黎汉华

EP 0898245 A1, 1999.02.24, 全文 .

(51) Int. Cl.

审查员 董立波

G06T 5/00 (2006.01)

G06T 7/00 (2006.01)

G06K 9/62 (2006.01)

G01C 11/00 (2006.01)

权利要求书 2 页 说明书 6 页 附图 4 页

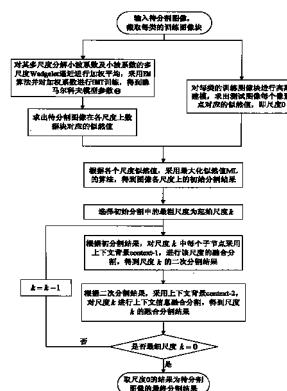
(54) 发明名称

基于 Wavelet 和 Wedgelet 变换 HMT 模型的图像分割方法

(57) 摘要

CN 101609548 B

本发明公开了一种基于 Wavelet 和 Wedgelet 变换 HMT 模型的图像分割方法，它涉及图像处理领域。主要解决传统分割方法边缘保持差的缺点。其过程为：提取待分割图像每类的训练图像块，对其多尺度分解小波系数及小波系数的多尺度 Wedgelet 逼近进行加权平均，根据加权系数估计模型参数 Θ ，求出待分割图像在各尺度上数据块对应的似然值和每个像素点的似然值，即后融合所需的似然值 $likelihood_k^c$ ，从而获得各尺度上的初分割结果；选择初分割中最可靠层作为起始尺度，对每个尺度依次根据第一种上下文信息 context-1 和第二种上下文信息 context-2 进行后融合分割，直到尺度 0 为止；取最细尺度的分割结果作为最终分割结果。本发明具有区域一致性和边缘保持性好的优点，可用于合成纹理图像，SAR 图像和航拍图像的分割。



1. 一种基于 Wavelet 和 Wedgelet 变换 HMT 模型的图像分割方法, 包括如下过程:

(1) 输入待分割图像, 从输入图像中截取 N_c 类具有均一区域的训练图像块, 其中 N_c 为待分割图像的类别数;

(2) 对每类训练图像块分别进行小波变换, 并对小波变换各个子带的系数分别进行多尺度 Wedgelet 逼近, 对原小波系数和多尺度 Wedgelet 逼近的系数进行加权平均;

(3) 采用期望最大化 EM 算法对每类训练图像块的加权系数进行训练, 得到隐马尔可夫模型参数 Θ ;

(4) 输入待分割的测试图像, 对测试图像进行小波变换, 并对小波变换各个子带的系数分别进行多尺度 Wedgelet 逼近, 将原小波系数和多尺度 Wedgelet 逼近的系数进行加权平均, 根据模型参数 Θ , 求出测试图像在各尺度下图像子块对应的似然值 $likelihood^I$, $I > 0$, I 表示似然值对应的尺度;

(5) 对每类的训练图像块进行高斯建模, 求出测试图像每个像素点对应的似然值 $likelihood^0$;

(6) 根据各个尺度似然值 $\{likelihood^k | k = 0, 1, 2, \dots, K\}$, 采用最大化似然值的算法, 得到图像 $K+1$ 个尺度上的初分割结果, $k = 0$ 表示像素级的似然值, $k = K$ 表示最粗尺度的似然值;

(7) 对各个尺度的初分割结果进行修正, 即从初分割的最粗尺度开始, 对最粗尺度先采用第一种上下文 context-1 模型, 通过最大化序列的后验概率法对该尺度初分割结果进行二次分割, 再利用第二种上下文 context-2 模型, 通过最大化序列的后验概率法对该尺度的二次分割结果进行三次分割, 得到最粗尺度的最终分割结果, 然后以同样方法进行下一尺度的分割, 直到完成最细尺度 0 的分割停止, 取该最细尺度的分割结果为待分割图像最终的分割结果:

所述的从初分割的最粗尺度开始, 对最粗尺度先采用第一种上下文 context-1 模型, 通过最大化序列的后验概率法对该尺度初分割结果进行二次分割, 按如下过程进行:

(7a) 选取第一种上下文 context-1 模型, 即提取每个子节点对应的父节点的类标为背景向量 V_1 , 同时选择以父节点为中心的 3×3 邻域内的主类标为背景向量 V_2 ;

(7b) 根据初分割结果, 利用第一种上下文 context-1 模型得到父节点的类标背景向量 V_1 和以父节点为中心的 3×3 邻域内的主类标背景向量 V_2 , 计算子节点的背景向量 V ;

(7c) 根据子节点的背景向量 V 和初分割时得到的似然值 $likelihood^k$, 计算条件后验概率:

$$p(c_i | d_i^k, v_i^k) = \frac{e_{k,c} \cdot \alpha_{k,v_i,c} \cdot likelihood^k}{\sum_{c=1}^{N_c} e_{k,c} \cdot \alpha_{k,v_i,c} \cdot likelihood^k}$$

式中 d_i^k 表示尺度 k 上位置 i 处的特征系数, v_i^k 表示尺度 k 上位置 i 处的背景向量, c_i 为位置 i 上的像素点所属的类标, $e_{k,c}$ 表示尺度 k 上取类标为 c 的概率, $\alpha_{k,v_i,c}$ 表示尺度 k 上背景向量为 v_i 下取类标为 c 的概率;

(7d) 利用下式更新 $e_{k,c}$ 和 $\alpha_{k,v_i,c}$ 的值:

$$e_{k,c} = \frac{1}{2^{2k}} \sum_i p(c_i | d_i^k, v_i^k)$$

$$\alpha_{k,v_i,c} = \frac{1}{2^{2k} \cdot e_{k,c}} \sum_{i \text{ with } v_i^k = v_i} p(c_i | d_i^k, v_i^k)$$

式中, v_i 为背景向量 V 的确切取值, 对于 N_c 类纹理 v_i 有 N_c^2 种取值, $p(c_i | d_i^k, v_i^k)$ 为步骤 (7c) 计算得到的条件后验概率;

(7e) 重复步骤 (7c) ~ 步骤 (7d), 满足迭代停止条件, 即达到允许误差为止, 得到二次分割结果;

所述的利用第二种上下文 context-2 模型, 通过最大化序列的后验概率法对最粗尺度的二次分割结果进行三次分割, 按如下过程进行:

(7f) 选取第二种上下文 context-2 模型, 即提取每个子节点对应的父节点的类标为背景向量 V_1 , 分别选择以父节点为中心的 3×3 邻域内的主类标为背景向量 V_2 和以样本点为中心的 3×3 邻域内的主类标为背景向量 V_3 ;

(7g) 根据二次分割结果, 利用第二种上下文 context-2 模型分别得到父节点的类标背景向量 V_1 、以父节点为中心的 3×3 邻域内的主类标背景向量 V_2 和以样本点为中心的 3×3 邻域内的主类标背景向量 V_3 , 计算子节点的背景向量 V ;

(7h) 根据子节点的背景向量 V 和初分割时得到的似然值 likelihood^k, 计算条件后验概率:

$$p(c_i | d_i^k, v_i^k) = \frac{e_{k,c} \cdot \alpha_{k,v_i,c} \cdot \text{likelihood}^k}{\sum_{c=1}^{N_c} e_{k,c} \cdot \alpha_{k,v_i,c} \cdot \text{likelihood}^k}$$

(7i) 利用下式更新 $e_{k,c}$ 和 $\alpha_{k,v_i,c}$ 的值:

$$e_{k,c} = \frac{1}{2^{2k}} \sum_i p(c_i | d_i^k, v_i^k)$$

$$\alpha_{k,v_i,c} = \frac{1}{2^{2k} \cdot e_{k,c}} \sum_{i \text{ with } v_i^k = v_i} p(c_i | d_i^k, v_i^k)$$

(7j) 重复步骤 (7h) ~ 步骤 (7i), 直到满足迭代停止条件, 达到允许误差为止, 得到三次分割结果, 即最粗尺度的最终分割结果。

2. 根据权利要求 1 所述的图像分割方法, 其中步骤 (2) 按如下过程进行:

(2a) 对步骤 (1) 所得到的每幅训练图像块, 选择 ‘haar’ 小波, 分别进行 4 层小波分解, 得到分解的小波系数;

(2b) 对分解得到的小波系数的各个子带分别进行多尺度 Wedgelet 逼近;

(2c) 将分解得到的小波系数与多尺度 Wedgelet 逼近后的小波系数进行加权平均, 得到加权平均后的系数, 该加权小波系数选取 $0.7 \sim 0.9$ 。

基于 Wavelet 和 Wedgelet 变换 HMT 模型的图像分割方法

技术领域

[0001] 本发明属于图像处理技术领域,涉及一种图像分割方法,可用于对纹理图像、航拍图像和 SAR 图像的分割。

背景技术

[0002] 图像分割是把一幅图像按照给定的准则划分为若干有意义的区域。图像分割在图像处理、分析和理解中是十分重要的技术环节,图像分割的质量的优劣、区域界限定位的精度直接影响后续的区域描述以及图像的分析和理解。

[0003] 近年来,小波分析已广泛应用于图像处理和分析中。小波对含点状奇异的目标函数而言是最优的基,但对具有线状奇异的函数,小波系数则不再稀疏,所以小波在 SAR 图像压缩和边缘检测中并不能够很好地表示图像中的轮廓边缘信息。多尺度几何分析是致力于构建最优逼近意义上的高维函数表示方法,能够更优的表示图像的边缘信息,在图像处理中被广泛的应用。其中, Wedgelet 变换是美国学者 David L. Donoho 在研究从含噪数据中恢复原图像的问题时提出的一种方向信息检测模型。Wedgelet 采用二进剖分的思想把各种位置,尺度和方向上的二进楔型区域上的特征函数作为基元素,它提供了“水平模型”的近于最优的表示,并用极小极大描述长度来度量,同时 Donoho 也研究了星型集合上的特征函数的模型的 Wedgelet 逼近问题,表明基于惩罚复杂度的 Wedgelet 剖分达到了极小极大风险估计。

[0004] 随着多尺度几何分析的发展,在多尺度变换域下结合一些特定理论、方法和工具的分割技术得到了相应的发展。2001 年,韩国的 Choi 提出了小波域隐马尔科夫树模型的图像分割方法 WD-HMTseg。该方法中, HMT 模型利用了小波的的多尺度特性,使系数之间的关系转变成隐状态的归属问题,并进行了在不同尺度上的分析并结合最大后验概率对图像进行分割。该方法的弊端在于区域没有良好的一致性,且边缘不够光滑。2005 年,中国的孙强提出一种改进的 WD-HMT 模型。他采用了一种新的上下文模型,充分结合了父节点邻域和子节点邻域的信息进行上下文的融合分割。该模型减少了小波产生的杂块信息,增强了边缘信息,但该方法仅限于遥感图的分割,有一定的局限性。2006 年,中国的金海燕根据小波系数对点奇异目标的最优性和 Wedgelet 系数的特点,并将其与 HMT 模型结合,提出一种新的模型 WWHMM。该模型因为 Wedgelet 的引入,使得对图像边缘的描述清晰,较小波域 HMT 模型能更好的划分测试图像的边缘区域。2007 年,中国的宋锦萍提出了一种基于小 波域多状态隐马尔科夫树模型的自适应文本图像分割方法。该方法从微分算子的角度,并结合小波尺度系数提出了一种图像分割算法,由于文本图像特征单一,分布规则,应用于 SAR 图像的效果不佳。

发明内容

[0005] 本发明的目的在于克服上述现有技术不足,提出了一种基于 Wavelet 变换和 Wedgelet 变换的 HMT 模型的图像分割方法,以得到较好的图像分割结果,并将其应用于纹

理图像、航拍图像和 SAR 图像。

[0006] 实现本发明目的的技术方案是：利用 Wavelet 变换和 Wedgelet 变换对图像处理的优点，将小波系数和小波系数的多尺度 Wedgelet 表示进行加权平均，并通过高斯混合模型对其进行 HMT 的建模，用 WWHMT 模型进行训练图像的参数训练、利用训练得到的参数进行最大似然函数的分类和用最大后验概率的分类。具体实现过程如下：

[0007] (1) 输入待分割图像，从输入图像中截取 N_c 类具有均一区域的训练图像块，其中 N_c 为待分割图像的类别数；

[0008] (2) 对每类训练图像块分别进行小波变换，并对小波变换各个子带的系数分别进行多尺度 Wedgelet 逼近，对原小波系数和多尺度 Wedgelet 逼近的系数进行加权平均；

[0009] (3) 采用期望最大化 EM 算法对每类训练图像块的加权系数进行训练，得到隐马尔可夫模型参数 Θ ；

[0010] (4) 输入待分割的测试图像，对测试图像进行小波变换，并对小波变换各个子带的系数分别进行多尺度 Wedgelet 逼近，将原小波系数和多尺度 Wedgelet 逼近的系数进行加权平均，根据模型参数 Θ ，求出测试图像在各尺度下图像子块对应的似然值 likelihood¹， $1 > 0$ ，1 表示似然值对应的尺度；

[0011] (5) 对每类的训练图像块进行高斯建模，求出测试图像每个像素点对应的似然值 likelihood⁰；

[0012] (6) 根据各个尺度似然值 {likelihood^k | $k = 0, 1, 2, \dots, K$ }，采用最大化似然值 (ML) 的算法，得到图像 $K+1$ 个尺度上的初分割结果， $k = 0$ 表示像素级的似然值， $k = K$ 表示最粗尺度的似然值；

[0013] (7) 对各个尺度的初分割结果进行修正，即从初分割的最粗尺度开始，对最粗尺度先采用第一种上下文 context-1 模型，通过最大化序列的后验概率法对该尺度初分割结果进行二次分割，再利用第二种上下文 context-2 模型，通过最大化序列的后验概率法对该尺度的二次分割结果进行三次分割，得到最粗尺度的最终分割结果，然后以同样方法进行下一尺度的分割，直到完成最细尺度 0 的分割停止，取该最细尺度的分割结果为待分割图像最终的分割结果。

[0014] 本发明与现有的技术相比具有以下优点：

[0015] 1、由于本发明利用 Wavelet 变换和 Wedgelet “水平模型”的特点，将 Wavelet 系数和 Wavelet 系数的多尺度 Wedgelet 表示进行加权平均，弥补了小波域隐马尔科夫树分割方法对线性奇异的非稀疏的缺点，使分割结果有较好的区域一致性；

[0016] 2、由于本发明结合 HMT 模型，采用两种上下文模型对各个尺度的结果进行后融合，充分利用上下文之间的关系，可以得到较好的分割效果；

[0017] 3、仿真结果表明，本发明方法较 WD-HMTseg 方法的分割结果，对于航拍图和 SAR 图的处理效果有明显改进。

附图说明

[0018] 图 1 是本发明的流程示意图；

[0019] 图 2 是本发明使用的第一种上下文模型 context-1 示意图；

[0020] 图 3 是本发明使用的第二种上下文模型 context-2 示意图；

- [0021] 图 4 是本发明用于纹理图像的仿真分割结果图；
- [0022] 图 5 是本发明用于 SAR 图像的仿真分割结果图；
- [0023] 图 6 是本发明用于航拍图像的仿真分割结果图。

具体实施方式

- [0024] 参照图 1, 本发明的具体实现过程如下：
 - [0025] 步骤 1, 输入待分割图像, 从输入图像中截取 N_c 类具有均一区域的训练图像块, 其中 N_c 为待分割图像的类别数。该输入待分割图像可分为 N_c 类, 则截取 N_c 幅训练图像块, 每幅训练图像块大小为 : 64×64 。
 - [0026] 步骤 2, 对每类训练图像块分别进行小波变换, 并对小波变换各个子带的系数分别进行多尺度 Wedgelet 逼近, 对原小波系数和多尺度 Wedgelet 逼近的系数进行加权平均, 其具体实施步骤如下：
 - [0027] (2. 1) 对步骤 1 所得到的每幅训练图像块, 选择 ‘haar’ 小波, 分别进行 4 层小波分解, 得到分解的小波系数；
 - [0028] (2. 2) 对分解得到的小波系数的各个子带分别进行多尺度 Wedgelet 逼近；
 - [0029] (2. 3) 将分解得到的小波系数与多尺度 Wedgelet 逼近后的小波系数进行加权平均, 得到加权平均后的系数, 该加权小波系数一般选取 $0.7 \sim 0.9$ 。
 - [0030] 步骤 3, 采用期望最大化 EM 算法对每类训练图像块加权平均后的系数进行训练, 得到隐马尔可夫模型参数 Θ ；
 - [0031] 步骤 4, 输入待分割的测试图像, 对测试图像进行小波变换, 并对小波变换各个子带的系数分别进行多尺度 Wedgelet 逼近, 将原小波系数和多尺度 Wedgelet 逼近的系数进行加权平均, 根据隐马尔可夫模型参数 Θ , 求出测试图像在各尺度下图像子块对应的似然值 $likelihood^l$, $l > 0$, 其中 : l 表示似然值对应的尺度；
 - [0032] 步骤 5, 对每类的训练图像块进行高斯建模, 求出测试图像每个像素点对应的似然值 $likelihood^0$ ；
 - [0033] 步骤 6, 根据各个尺度似然值 $\{likelihood^k \mid k = 0, 1, 2, \dots, K\}$, 采用最大化似然值的算法, 得到图像 $K+1$ 个尺度上的初分割结果, 其中 : $k = 0$ 表示像素级的似然值, $k = K$ 表示最粗尺度的似然值；
 - [0034] 步骤 7, 对初分割的结果的最粗尺度, 即起始尺度, 根据第一种上下文 context-1 模型对起始尺度进行后融合分割, 得到二次分割结果, 具体实施步骤如下：
 - [0035] (7. 1) 提取每个子节点对应的父节点的类标为背景向量 V_1 , 同时选择以父节点为中心的 3×3 邻域内的主类标为背景向量 V_2 , 组成第一种上下文模型 context-1, 如图 2 所示；
 - [0036] (7. 2) 根据初分割结果, 利用第一种上下文 context-1 模型得到父节点的类标背景向量 V_1 和以父节点为中心的 3×3 邻域内的主类标背景向量 V_2 , 计算子节点的背景向量 V ；
 - [0037] (7. 3) 根据子节点的背景向量 V 和初分割时得到的似然值 $likelihood^k$, 计算条件后验概率：

$$[0038] \quad p(c_i | d_i^k, v_i^k) = \frac{e_{k,c} \cdot \alpha_{k,v_i,c} \cdot likelihood^k}{\sum_{c=1}^{N_c} e_{k,c} \cdot \alpha_{k,v_i,c} \cdot likelihood^k} \quad (1)$$

[0039] 其中, d_i^k 表示尺度 k 上位置 i 处的特征系数, v_i^k 表示尺度 k 上位置 i 处的背景向量, c_i 为位置 i 上的像素点所属的类标, $e_{k,c}$ 表示尺度 k 上取类标为 c 的概率, $\alpha_{k,v_i,c}$ 表示尺度 k 上背景向量为 v_i 下取类标为 c 的概率;

[0040] (7.4) 利用下式更新 $e_{k,c}$ 和 $\alpha_{k,v_i,c}$ 的值:

$$[0041] \quad e_{k,c} = \frac{1}{2^{2k}} \sum_i p(c_i | d_i^k, v_i^k) \quad (2)$$

$$[0042] \quad \alpha_{k,v_i,c} = \frac{1}{2^{2k} \cdot e_{k,c}} \sum_{i \text{ with } v_i^j = v_l} p(c_i | d_i^k, v_i^k) \quad (3)$$

[0043] 其中, v_l 为背景向量 V 的确切取值, 对于 N_c 类纹理 v_l 有 N_c^2 种取值, $p(c_i | d_i^k, v_i^k)$ 为式(1)计算的条件后验概率;

[0044] (7.5) 重复步骤(7.2)~步骤(7.3), 直到满足迭代停机条件, 达到允许误差为止, 得到二次分割结果;

[0045] 步骤8, 对最粗尺度二次分割的结果, 根据第二种上下文 context-2 模型对起始尺度进行后融合分割, 得到三次分割结果, 具体实施步骤如下:

[0046] (8.1) 提取每个子节点对应的父节点的类标为背景向量 V_1 , 分别选择以父节点为中心的 3×3 邻域内的主类标为背景向量 V_2 和以样本点为中心的 3×3 邻域内的主类标为背景向量 V_3 , 以组成第二种上下文模型 context-2, 如图3所示;

[0047] (8.2) 根据二次分割结果, 利用第二种上下文 context-2 模型分别得到父节点的类标背景向量 V_1 、以父节点为中心的 3×3 邻域内的主类标背景向量 V_2 和以样本点为中心的 3×3 邻域内的主类标背景向量 V_3 , 计算子节点的背景向量 V ;

[0048] (8.3) 根据子节点的背景向量 V 和初分割时得到的似然值 $likelihood^k$, 计算条件后验概率:

$$[0049] \quad p(c_i | d_i^k, v_i^k) = \frac{e_{k,c} \cdot \alpha_{k,v_i,c} \cdot likelihood^k}{\sum_{c=1}^{N_c} e_{k,c} \cdot \alpha_{k,v_i,c} \cdot likelihood^k} \quad (4)$$

[0050] 其中, d_i^k 表示尺度 k 上位置 i 处的特征系数, v_i^k 表示尺度 k 上位置 i 处的背景向量, c_i 为位置 i 上的像素点所属的类标, $e_{k,c}$ 表示尺度 k 上取类标为 c 的概率, $\alpha_{k,v_i,c}$ 表示尺度 k 上背景向量为 v_i 下取类标为 c 的概率;

[0051] (8.4) 利用下式更新 $e_{k,c}$ 和 $\alpha_{k,v_i,c}$ 的值:

$$[0052] \quad e_{k,c} = \frac{1}{2^{2k}} \sum_i p(c_i | d_i^k, v_i^k) \quad (5)$$

$$[0053] \quad \alpha_{k,v_i,c} = \frac{1}{2^{2k} \cdot e_{k,c}} \sum_{i \text{ with } v_i^j = v_l} p(c_i | d_i^k, v_i^k) \quad (6)$$

[0054] 其中, v_1 为背景向量 V 的确切取值, 对于 N_c 类纹理 v_1 有 N_c^2 种取值, $p(c_i | d_i^k, v_i^k)$ 为式(4)计算的条件后验概率;

[0055] (8.5) 重复步骤(8.2)~步骤(8.3), 直到满足迭代停机条件, 达到允许误差为止, 得到最粗尺度的最终分割结果。

[0056] 步骤9, 按照从最粗尺度到最细尺度的顺序, 对每一尺度, 分别重复步骤7~步骤8, 直到最细尺度 $k = 0$ 为止, 得到每个尺度的最终分割结果。

[0057] 步骤10, 取尺度0对应的最终分割结果作为待分割图像的最终分割结果。

[0058] 本发明的效果可以通过以下仿真结果进一步说明。

[0059] 1. 仿真内容: 应用本发明方法与 WD-MTseg 方法, 分别对两幅合成纹理图像, 两幅 SAR 图像及两幅航拍图像进行分割, 并给出了合成纹理图像的错分率作为客观评价标准, 错分率 Pe 定义为图像总错分像素点个数与图像总像素点个数的百分比。

[0060] 2. 仿真结果

[0061] 图4为本发明方法应用于合成纹理图像的分割结果。其中, 图4(a)为第一幅合成纹理图像, 含有两类纹理, 图4(b)为WD-HMT方法对第一幅合成纹理图像的分割结果, 图4(c)为本发明方法对第一幅合成纹理图像的分割结果, 图4(d)为第二幅合成纹理图像, 含有三类纹理, 图4(e)为WD-HMT方法对第二幅合成纹理图像的分割结果, 图4(f)为本发明方法对第二幅合成纹理图像的分割结果, 从图4可以看出, 本发明方法由于利用了Wedgelet 良好的“线”和“面”特性, 结合了小波和 Wedgelet 的优点, 在合成纹理图像的分割上, 较 WD-HMT 分割方法, 在分割结果区域一致性有所改善的同时, 在分割结果的边缘上结果也有明显改善。本发明方法与 WD-HMT 方法对合成纹理图错分率的对比如表1所示。

[0062] 表1 WD-HMT方法和本发明方法分割结果的错分率比较

[0063]

比较方法		WD-HMT 方法	本发明方法
错分率	图 4(a)	1.4191	1.3367
Pe(%)	图 4(d)	13.663	11.499

[0064] 从表1的错分率可以看出, 本文方法的错分率略小于 WD-HMT 方法。

[0065] 图5为本发明方法应用于SAR图像的分割结果。其中, 图5(a)和图5(d)为SAR图像原图, 图5(b)和图5(e)为WD-HMT方法对图像的分割结果, 图5(c)和图5(f)为本发明方法对图像的分割结果。

[0066] 图6为本发明方法应用于航拍图像的分割结果。其中, 图6(a)和图6(d)为航拍图像原图, 图6(b)和图6(e)为WD-HMT方法对图像的分割结果, 图6(c)和图6(f)为本发明方法对图像的分割结果。

[0067] 从图5和图6的分割结果可以看出, 对SAR图像和航拍图像, WD-HMT方法由于小波变换的特点, 会产生很多杂块效应, 表现为分割结果存在大量的杂块, 且边缘分割效果不够好。由于对小波系数的Wedgelet逼近的引入, 利用Wedgelet良好的“线”和“面”特性, 分割结果的杂块信息明显减少, 且区域一致性得到明显的提高, 轮廓更加清晰。

[0068] 综上, 本发明利用Wavelet变换和Wedgelet逼近的特点, 弥补了小波域隐马尔科

夫树分割方法对线性奇异的非稀疏的缺点,利用 Wedgelet 良好的“线”和“面”的逼近特性以及选择适当背景的上下文信息指导后融合充分保留细尺度上边缘信息并减少分割结果中的杂块效应,特别是使用本发明的方法对于 SAR 图像和航拍图像的处理效果有明显改进。

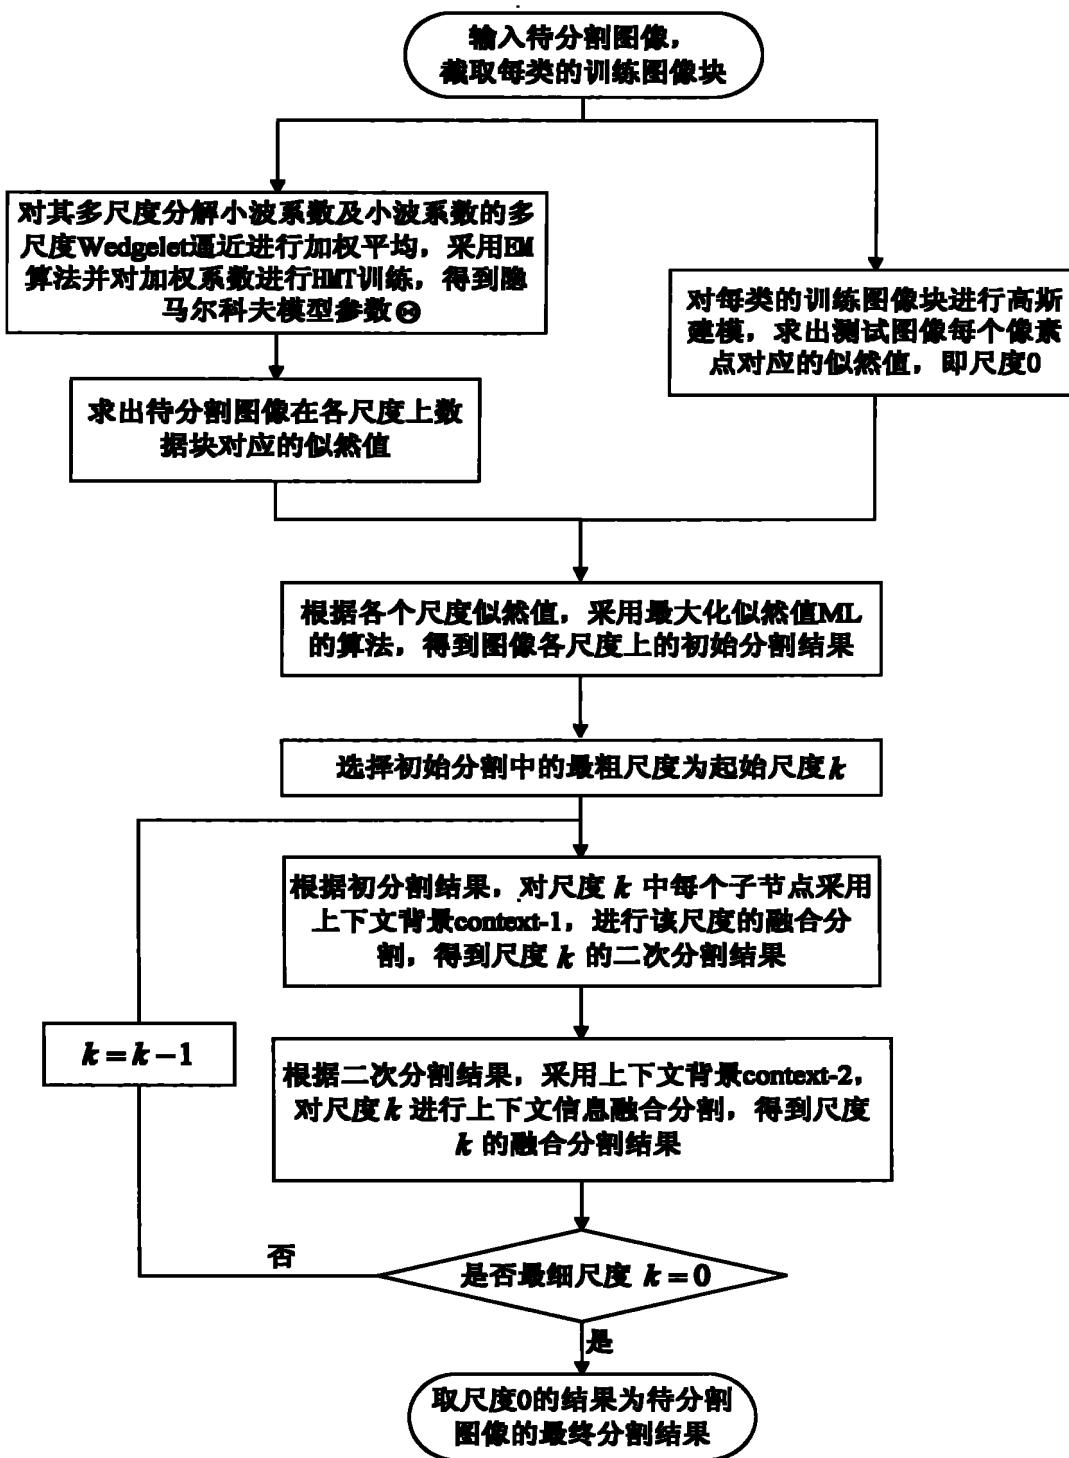


图 1

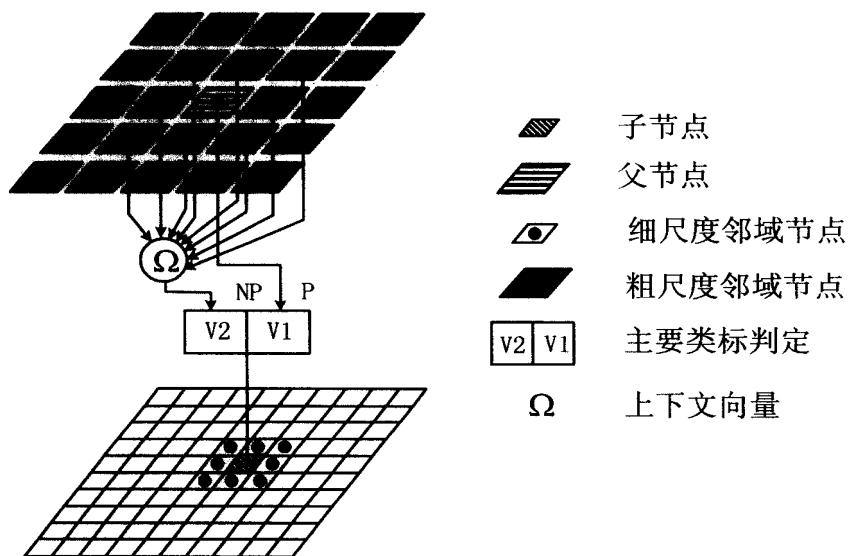


图 2

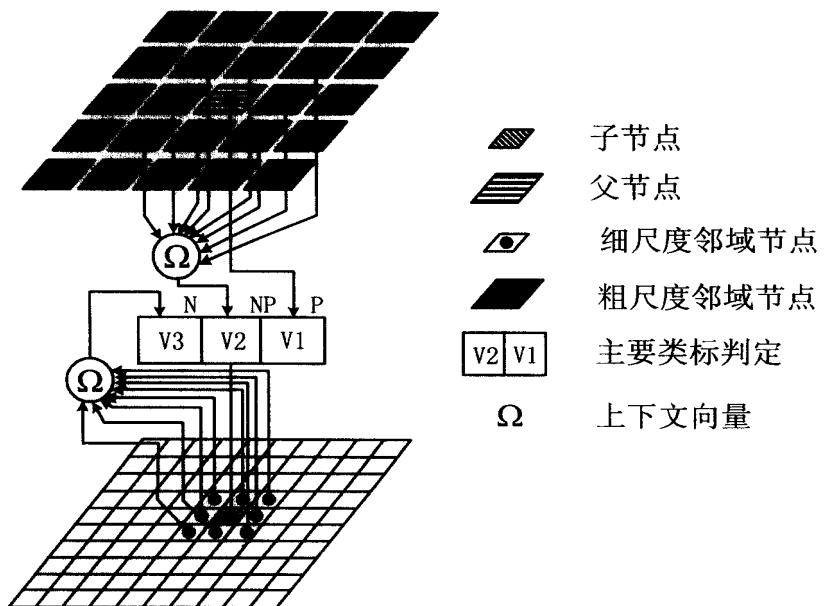


图 3

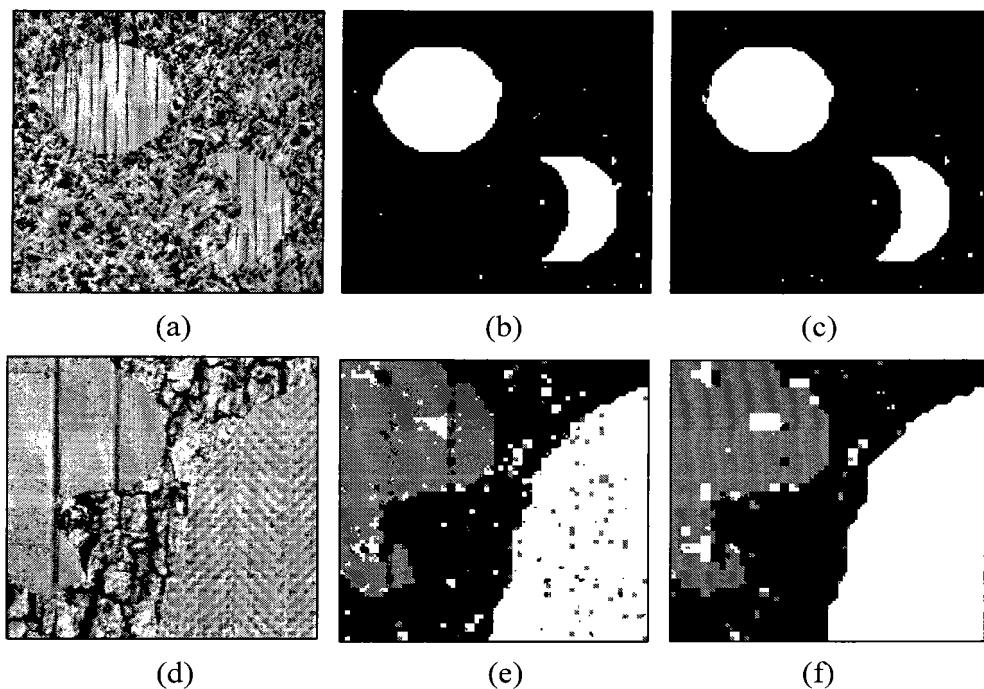


图 4

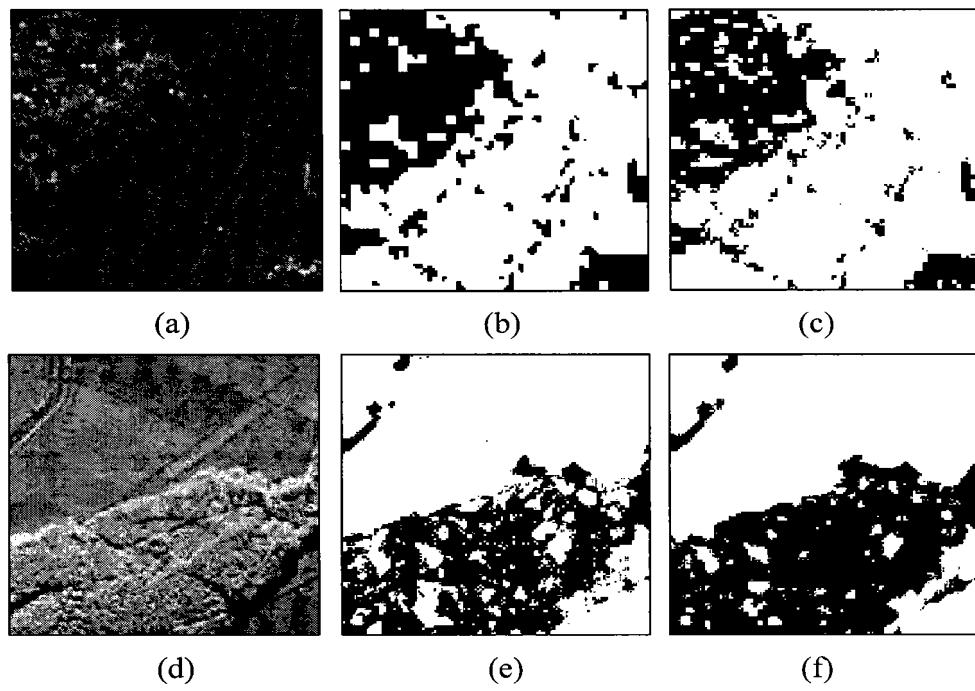


图 5

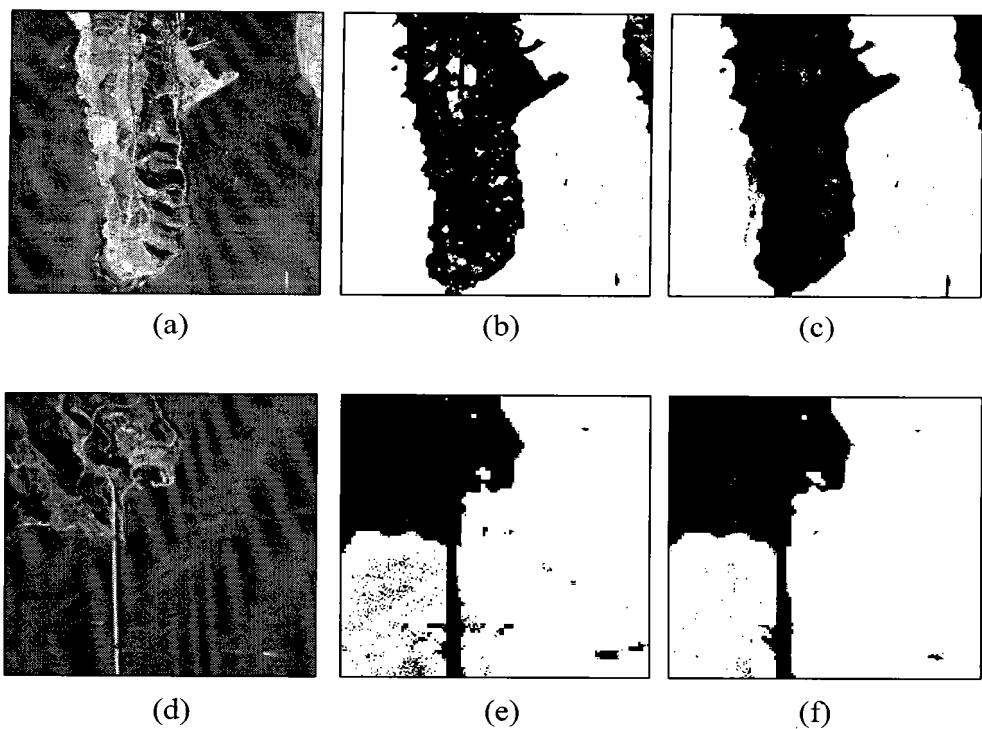


图 6