

文章编号: 1001 - 9014 (2009) 06 - 0450 - 05

一种基于 Contourlet 变换的多尺度 纹理分割的新算法

刘国英^{1,2}, 秦前清¹, 王雷光¹, 梅天灿³, 张飞燕¹

(1. 武汉大学 测绘遥感信息工程国家重点实验室, 武汉 430079;

2. 长沙理工大学 计算机与通信工程学院, 长沙 410076;

3. 武汉大学 电子信息学院, 武汉 430079)

摘要: 受到基于模型的纹理分析方法的启发, 提出了一种新的特征提取方法—有限混合纹理模式 (Finite Texture Mixture Pattern, FIMP). FIMP 是一个二元组的集合, 可以通过聚类的方法进行计算. 首先, 基于 Contourlet 变换计算纹理的多尺度多方向变化信息; 其次, 对各尺度、各方向的变化信息分别进行聚类. 这些聚类中心以及它们所占的比例组成的二元组的集合就构成了纹理图像的 FIMP, 反应了不同尺度不同方向的主要变化信息. 这种纹理特征的计算方法充分利用了基于模型方法的基本思想, 但却避免了复杂的参数计算. 在 FIMP 的基础上, 本文给出相应的纹理分割框架 CFIMP_{seg}, 并通过定量和定性实验验证了所提算法的有效性.

关键词: Contourlet 变换; 有限混合纹理模式; 局部变化模式; 纹理分割

中图分类号: TP751.1 **文献标识码:** A

NEW ALGORITHM OF MULTISCALE TEXTURE IMAGE SEGMENTATION BASED ON CONTOURLET TRANSFORM

LU Guo-Ying^{1,2}, QN Qian-Qing¹, WANG Lei-Guang¹, MEI Tian-Can³, ZHANG Fei-Yan¹

(1. State Key Laboratory of Information Engineering in Surveying, Mapping and Remote

Sensing, Wuhan University, Wuhan 430079;

2. College of Computer and Communication Engineering, Changsha University of Science & Technology, Changsha 410076;

3. School of Electronic Information, Wuhan University, Wuhan 430079)

Abstract: A new feature extraction method, finite texture mixture pattern (FIMP), was proposed inspired by the basic idea of pattern-based texture analysis methods. FIMP was a two-tuplet set, which could be obtained by clustering methods. Firstly, the multi-scale and multi-direction variations were calculated based on the Contourlet transform. Secondly, these variation information at different scale and in different direction were clustered into groups respectively. The centers and their corresponding proportion made up FIMP, which reflected the primary information's variations of different scales and different directions. Such a feature extraction method made full use of the idea of pattern-based method, but avoided the complicated parameter estimation and expression computation. Thus a supervised multi-scale texture image segmentation algorithm based on Contourlet transform-CFIMP_{seg} was proposed based on FIMP, and its effectiveness was proven by quantitative and qualitative experiments.

Key words: Contourlet transform; finite texture mixture pattern; local variable pattern; texture segmentation

引言

纹理可视为像素亮度局部变化的重复模式^[1], 不同类型的纹理由不同的亮度局部变化模式组成. 亮度的局部变化包括不同方向和不同尺度上的变

化, 如何表示这种变化模式是纹理分析的一个重要问题. 主要有三类方法表示这种变化模式: 基于特征的方法、基于模型的方法和基于结构的方法^[2]. 基于特征的方法常在某种邻域内进行, 采用给定窗口内的一种或几种统计量表示局部变化模式, 最常见

收稿日期: 2008 - 09 - 23, 修回日期: 2009 - 05 - 31

Received date: 2008 - 09 - 23, revised date: 2009 - 05 - 31

基金项目: 国家重点基础研究发展计划 (973 计划) 课题 (2006CB701303); 优秀国家重点实验室项目 (40523005); 863 计划资助 (2006AA12Z132)

作者简介: 刘国英 (1979-), 男, 河南郑州人, 博士研究生, 主要研究方向为遥感影像处理与分析, E-mail: lgydatabase@163.com.

的方式是使用向量形式将这些统计量组合在一起描述纹理,比如灰度级共生矩阵^[3]、窗口内的平均纹理能量^[4]、多参数多尺度纹理特征^[5]等.基于模型的方法使用模型参数表示纹理的局部变化模式,采用模型表达式将各种局部变化模式结合在一起表示纹理,如高斯马尔可夫场模型(Gauss Markov Random Field, GMRF)^[6]、多分辨率马尔可夫模型(MultiResolution Markov Random Field, MRMRF)^[7]和隐马尔可夫树模型(Hidden Markov Tree, HMT)^[8]等.这种方法具有良好的理论基础,但是参数的训练和模型的表达都非常复杂.基于结构的方法认为复杂的纹理可以使用简单的纹理基元以一定的形式重复排列而成^[9].纹理基元表示亮度局部变化模式,排列规则代表了局部变化模式的组合方式.这种方法常用来表示规则纹理.

受到基于模型的纹理表示方法的启发,本文提出了一种新的特征提取方法—有限混合纹理模式(Finite Texture Mixture Pattern, FIMP).这种特征计算方法充分利用了基于模型方法的思想,从根本上避免了基于模型方法的参数计算复杂的问题.基于该模式,本文提出了 Contourlet域的分类框架—CFIMPseg,并通过实验验证了算法的有效性.

1 有限混合纹理模式

模式识别将模式定义为能够区别事物的信息^[10].如何提取纹理模式就成为纹理分割的关键所在.为了后续介绍的方便,进行如下的定义:

定义 1:给定同质的纹理区域,像素亮度在多尺度、多方向上的一种变化信息就称为一种局部变化模式(Local Variable Pattern, LVP),记为 M .

不同类型纹理包含的 LVP可能不同,包含的 LVP的个数也可能不同.但是每种类型的纹理的 LVP总存在几个主要的变化模式 PLVP(Primary Local Variable Pattern),它们反映了该纹理主要的局部变化信息,能够反映纹理的基本特性.

定义 2:假设纹理可以表示为有限种的 PLVP按照一定比例的混合,则称 PLVP以及其所占的比例构成的二元组集合为该类型纹理的有限纹理混合模式(Finite Texture Mixture Pattern, FIMP),记为 T .

$$T = \left\{ (M_s^k, R_s^k) \mid R_s^k = 1; k = 1, 2, \dots, K_s; s = 1, 2, \dots, S \right\}, \quad (1)$$

其中 S 表示尺度数, M_s^k 表示该类型纹理中尺度 s 上的第 k 种 PLVP, K_s 表示尺度 s 上的 M_s^k 的个数, R_s^k 表示 M_s^k 在该类型纹理的尺度 s 上的混合比例.

基于公式(1)的定义,一幅由多种纹理组成的纹理影像可以表示为:

$$\text{Image} = \{ T_c \mid c = 1, 2, \dots, N_c \}, \quad (2)$$

其中 T_c 表示第 c 种 FIMP, N_c 表示纹理类型的数目,纹理分割的过程就是确定每一个像素使用哪一个 T_c 进行表示的过程.

2 Contourlet域 FIMP特征提取

2.1 基于 Contourlet变换的 LVP计算

假设纹理图像 y 定义在大小为 $N \times N$ 的格网上,进行 s 层 Contourlet变换,每层取 4 个方向,则形成 $4 \times S$ 个子带的 Contourlet系数 $w_{s,b}$,其中 $s = 1, 2, \dots, S$ 为 Contourlet变换的层次, $b = 1, 2, 3, 4$ 表示对应的子带,对每个高频子带提取能量特征^[4],定义在 $(2u+1) \times (2u+1)$ 窗口中的纹理能量为:

$$e_{s,b}(i,j) = \frac{1}{(2u+1)^2} \sum_{k=i-u}^{i+u} \sum_{l=i-u}^{i+u} |w_{s,b}(k,l)|. \quad (3)$$

将同一尺度不同子带相同位置的纹理能量结合起来,构造一个四维的特征向量,

$$e_s(i,j) = [e_{s,1}(i,j), e_{s,2}(i,j), e_{s,3}(i,j), e_{s,4}(i,j)], \quad (4)$$

用来表示该位置处的局部变化模式 LVP.

给定图 1(a)所示的纹理图像,进行 1 级 Contourlet变换,取 4 个方向,对每一高频子带分别在大小为 9×9 的窗口内计算能量特征,并取其中三个方向的高频子带的能量特征作为红、绿、蓝三个波段进行伪彩色显示,如图 1(b)所示,对应的特征空间图像如图 1(c)所示.

2.2 FIMP特征的计算

每一尺度、每一位置的 LVP反应了该位置的局部信息变化的幅值.同质的纹理图像中大部分区域的纹理是均匀的, LVP取值非常接近,主要集中在以

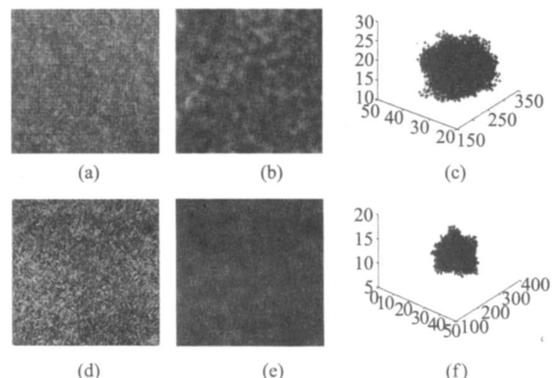


图 1 纹理图像及其 Contourlet 能量特征 (a) (d) 纹理图像 (b) (e) 特征图像 (c) (f) 特征空间图像

Fig 1 Texture image and its Contourlet energy (a) (d) texture images (b) (e) feature images (c) (f) feature space images

均值为中心的一个球体内;但图像具有非平稳性且含有少量相对不均匀的纹理区域,它们的变化情况较为特殊,计算出的 LVP与均匀区域的 LVP偏差较大,主要分布在球体的外围.基于这种分析可以得出结论:每一尺度上的 PLVP有两种,一种对应于球体内,另一种对应于球体外.因此,可以在欧氏空间中,将每一尺度的 LVP通过两个中心的聚类来计算对应的 PLVP,从而计算整幅纹理图像的 FIMP特征.

为了寻找给定 LVP集合的最优聚类划分,使得基于类内误差或者类间误差的聚类准则函数为最优,本文采用聚类中心数目为 2 的 C均值聚类算法来确定 PLVP. C均值聚类算法简单、收敛速度快且局部搜索能力强,但对初始值比较敏感.为此,本文根据经验设计了一个简单的初值获取方法:首先,计算总的 LVP平均矢量 m ;然后,计算每一个 LVP与 m 的最大的距离 d_{max} ;最后,将与 m 距离小于 $t=0.8 \times d_{max}$ 的 LVP的均值作为球体内 PLVP的初始值,距离大于 t 的 LVP的均值作为球体外 PLVP的初始值.取最大距离的 0.8 作为两种 LVP的分界线,主要是考虑到大部分的 LVP位于球体内部.这种初值设定方法能够保证 C均值聚类算法能够快速、稳定地获取合适的聚类结果.

假设尺度 s 上的 LVP 集合为 $e_s = \{e_s(1), e_s(2), \dots, e_s(N_s)\}$, 共有 N_s 个 LVP, 计算出的 PLVP 的集合为 $\{M_s^k \mid k=1, 2\}$, 表示尺度 s 中有两个 PLVP, M_s^k 表示尺度 s 上的第 k 个 PLVP. 按照最小距离的原则, 可以将距离 M_s^k 最近的 LVP 集合表示为 $\{e_s^k(i) \mid i=1, 2, \dots, N_s^k\}$, 满足 $\sum_{k=1}^2 N_s^k = N_s$. 在 C均值聚类中, M_s^k 用对应的聚类中心来表示, 即 $M_s^k = (1/N_s^k) \times \sum_{i=1}^{N_s^k} e_s^k(i)$.

算法收敛以后可以根据最小距离原则将每一 LVP 划归到相应 PLVP 描述的子集中, 根据每一子集的大小 N_s^k 可以计算对应的混合比例 R_s^k ,

$$R_s^k = \frac{N_s^k}{N_s} \quad (5)$$

对所有尺度的 Contourlet 能量计算后, 完成给定纹理图像的 FIMP 特征的计算, 即

$$T = \left\{ \left(M_{s_s}^k, R_s^k \right) \mid R_s^k = 1; k = 1, 2, \dots, K_s; s = 1, 2, \dots, S \right\}.$$

3 基于 FIMP 的多尺度纹理分割框架

给定纹理图像, 纹理分割是为每一像素选择合

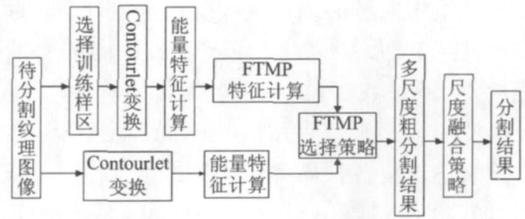


图 2 基于 FIMP 特征的多尺度纹理分割框架
Fig 2 The multi-scale segmentation scheme of texture image based on FIMP

适的 FIMP 表示的过程. 首先需要通过训练样本计算每一类纹理的 FIMP 特征表示, 然后对待分割图像的每一像素点计算对应的 LVP, 按照一定的选择策略寻找最合适的 FIMP, 这个像素点的标记即为该 FIMP 的标记. 整个过程可以用图 2 进行表示.

3.1 FIMP 的选择策略

假设第 c 类训练样本进行 S 层 Contourlet 变换, 计算每一层上的 LVP, 通过聚类计算该类纹理的 FIMP 特征 $T_c = \{ (M_s^{c,k}, R_s^{c,k}) \}$, 其中 $k=1, 2$ 表示每一尺度上 PLVP 的个数, $s=1, 2, \dots, S$ 为 Contourlet 变换尺度, $M_s^{c,k}, R_s^{c,k}$ 分别为该类纹理在尺度 s 上的第 k 种 PLVP 及其比例, 且 $\sum_k R_s^{c,k} = 1$. 待分割图像进行相同的 Contourlet 变换, 并计算每一层上的 LVP 特征, 根据 FIMP 选择策略以计算多尺度粗分割的结果. 假设待分割图像尺度 s 上位置 (i, j) 处的 LVP 为 $e_s(i, j)$, 可以采用下式选择合适的 FIMP 特征,

$$\text{sim}_{s(i,j)}(c) = \sum_{k=1}^2 R_s^{c,k} \times e^{-e_s(i,j) \cdot M_s^{c,k}} \quad (6)$$

$$x_s(i, j) = \arg \max_c \{ \text{sim}_{s(i,j)}(c) \} \quad (7)$$

其中, $\text{sim}_{s(i,j)}(c)$ 表示尺度 s 上 (i, j) 位置处的 LVP 与第 c 类纹理对应的 FIMP 特征的相似度, $x_s(i, j)$ 为每一位置的 LVP 按照式 (6) 计算获得的初始分割结果. 因为没有考虑尺度之间的相互关系, 因此称为粗分割结果.

3.2 多尺度分割结果融合

粗分割结果并没有考虑尺度间的作用关系, 为了获取更为可信的分割结果, 需要融合多尺度分割结果. 在计算同样大小的窗口内的 LVP 时, 大尺度的能量特征计算因为考虑了更大范围的系数而更为稳定, 相应计算出的 FIMP 特征也更为可靠. 因此, 待分割图像根据 FIMP 特征选择策略计算出的粗分割结果也更为稳定, 能够获取较好的轮廓, 但是边缘位置因为 LVP 不够准确而使得分割结果不够可靠, 需要采用下一尺度的信息进行优化.

本文所采用的 Contourlet变换上下尺度的格网位置之间存在一对四的关系,将上尺度的位置记为父节点,下一尺度的 4 个位置记为子节点, (i, j) 和 $\{c(i, j)\}$ 分别表示 (i, j) 位置的父节点和子节点位置集合,同一尺度上的邻域节点集合记为 $\partial(i, j)$. 进行尺度间分割结果融合需要进行边界位置的定义:如果某一位置的父节点标记与它的 8 个二阶邻域位置标记不完全相同,则该位置为边界位置,即

$$b_s(i, j) = \begin{cases} 1 & \partial(i, j) \neq x(i, j) \\ 0 & otherwise \end{cases} \quad (8)$$

尺度间分割结果的融合主要是边界位置分割结果的进一步判断.

尺度 s 上, (i, j) 位置的 LVP 及其父节点的 LVP 与第 c 类纹理对应的 FIMP 特征的相似度分别记为 $sim_{s(i, j)}(c)$ 和 $sim_s(i, j)(c)$, 考虑上一尺度影响的相似度计算公式如 (9),

$$\tilde{sim}_s(i, j)(c) = \begin{cases} sim_s(i, j)(c), & b_s(i, j) = 0 \\ \alpha sim_{s(i, j)}(c) + (1 - \alpha) sim_s(i, j)(c), & b_s(i, j) = 1 \end{cases} \quad (9)$$

其中, $\alpha \in [0, 1]$ 表示边界位置处当前节点的相似度对最终相似度的影响程度. 通过选择最大的 $\tilde{sim}_s(i, j)(c)$ 就可以得到上下尺度融合后的分割结果,即

$$\tilde{x}_s(i, j) = \arg \max_c \{ \tilde{sim}_s(i, j)(c) \} \quad (10)$$

3.3 CFIMPseg 分割算法

为了进一步阐述基于 Contourlet 域 FIMP 特征的多尺度分割过程,下面给出了详细步骤.

步骤 1: 选择训练样区,大小为 $2^n \times 2^n$;

步骤 2: 对每一训练样区进行 $S(1 \leq S \leq n)$ 层 Contourlet 变换,每层选择 4 个方向,计算 FIMP 特征 $T_c := \{ (M_s^{c, k}, R_s^{c, k}) \mid s = 1, 2, \dots, S; k = 1, 2 \}$;

步骤 3: 对待分割图像执行相同的 Contourlet 变换,计算所有尺度的 LVP 特征;

步骤 4: 根据公式 (6) 计算每一尺度 LVP 相对于步骤 2 中计算出的 FIMP 特征的相似度 $sim_s(i, j)(c)$;

步骤 5: 根据公式 (7) 计算各尺度粗分割结果;

步骤 6: 各尺度分割结果融合;

步骤 6.1: 选择一个分割结果可靠的最高的尺度 $s = J(J \leq S)$ 开始多尺度融合;

步骤 6.2: $s = s - 1$, 如果 $s = 0$, 则执行步骤 6.3, 否则算法结束,获取最终的分割结果;

步骤 6.3: 根据公式 (8) 计算尺度 s 上的边缘位置;

步骤 6.4: 根据公式 (9) 计算尺度 s 上受 $s + 1$ 尺度影响的相似度 $\tilde{sim}_s(i, j)(c)$;

步骤 6.5: 根据公式 (10) 计算尺度 s 优化后的分割结果; 转步骤 6.2

4 分割结果分析

实验 1: C 均值初值设定有效性实验

本实验用以验证本文初值设定方法的有效性. 以图 1 中 (a) 和 (d) 两幅图像为例进行分析, 采用“9-7 塔形分解和方向滤波器组, 分解 2 层, 每层取 4 个方向. 在包括原始分辨率尺度的三个尺度上计算 9×9 窗口对应的 LVP 特征. 在每个尺度上, 分别用设定为 2 个类别的 C 均值聚类算法进行聚类, 采用两种初值设定方法: 本文方法和随机方法, 记录迭代次数和目标函数取值 (所有样本的类内距离总和). 实验结果在表 1 中列出. 从表中可以很容易看出, 本文方法所需的迭代次数更少, 而目标函数取值更优. 这表明, 本文方法能够保证计算出的初始聚类中心距离最优值更近, 从而能在较少的迭代次数之内收敛到最优取值.

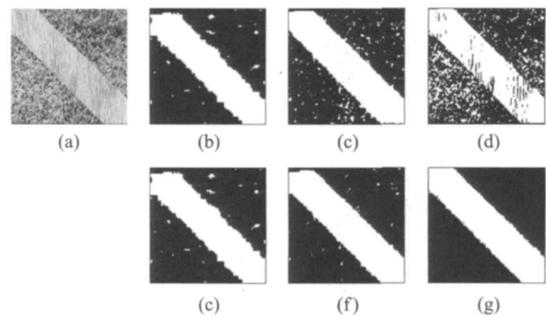


图 3 (a) 测试图像 (b)~(d) 尺度 2~尺度 0 的粗分结果 (e)~(g) 尺度 2~尺度 0 的最终分割结果

Fig 3 (a) Test image (b)~(d) raw segmentations of scale 2~0 (e)~(g) final segmentations of scale 2~0

表 1 不同初始化方法性能比较

Table 1 The comparison between different initialization methods

尺 度	图 1(a)		图 1(b)					
	随机初始化	本文方法	随机初始化	本文方法	随机初始化	本文方法		
迭代 次数	目标 函数	迭代 次数	目标 函数	迭代 次数	目标 函数	迭代 次数	目标 函数	
2	59	2605700	15	91368	52	248350	18	87177
1	76	4237300	20	223220	71	4732700	25	233530
0	34	9800100	22	628340	47	1293500	19	741960

实验 2:多尺度融合有效性实验

对图 3(a)所示的大小为 256 ×256的纹理图像使用 CFIMP_{seg}算法进行纹理分割,记录粗分结果和融合后的最终分割结果.实验中训练和分割均采用与实验 1相同的 Contourlet变换,且设定 $\lambda = 0.3$.分割结果如图 3(b)~(g)所示.

从图中可以看出,相对于粗分结果,CFIMP_{seg}在区域性和边缘保持性两个方面都有所提高.

实验 3: CFIMP_{seg}分类性能实验

为了检验 CFIMP_{seg}的分类性能,采用实验 2中相同设置,与以下方案进行了对比实验,实验结果

如图 4所示.图中第 1幅和第 2幅图像为合成的纹理影像,第 3~第 5幅为遥感影像,大小均为 256 × 256.

方案 1: Contourlet能量 +C均值聚类:对待分割图像做 2层 Contourlet变换后,采用 9 ×9的窗口计算各子带系数能量特征,将包括原始分辨率尺度在内的各尺度上对应位置的特征串起来构成特征向量,使用 C均值算法进行聚类,结果如图 4(f)~(j);

方案 2: GMRF特征参数 +C均值聚类:对原始图像提取大小为 9 ×9窗口内的 GMRF模型参数作

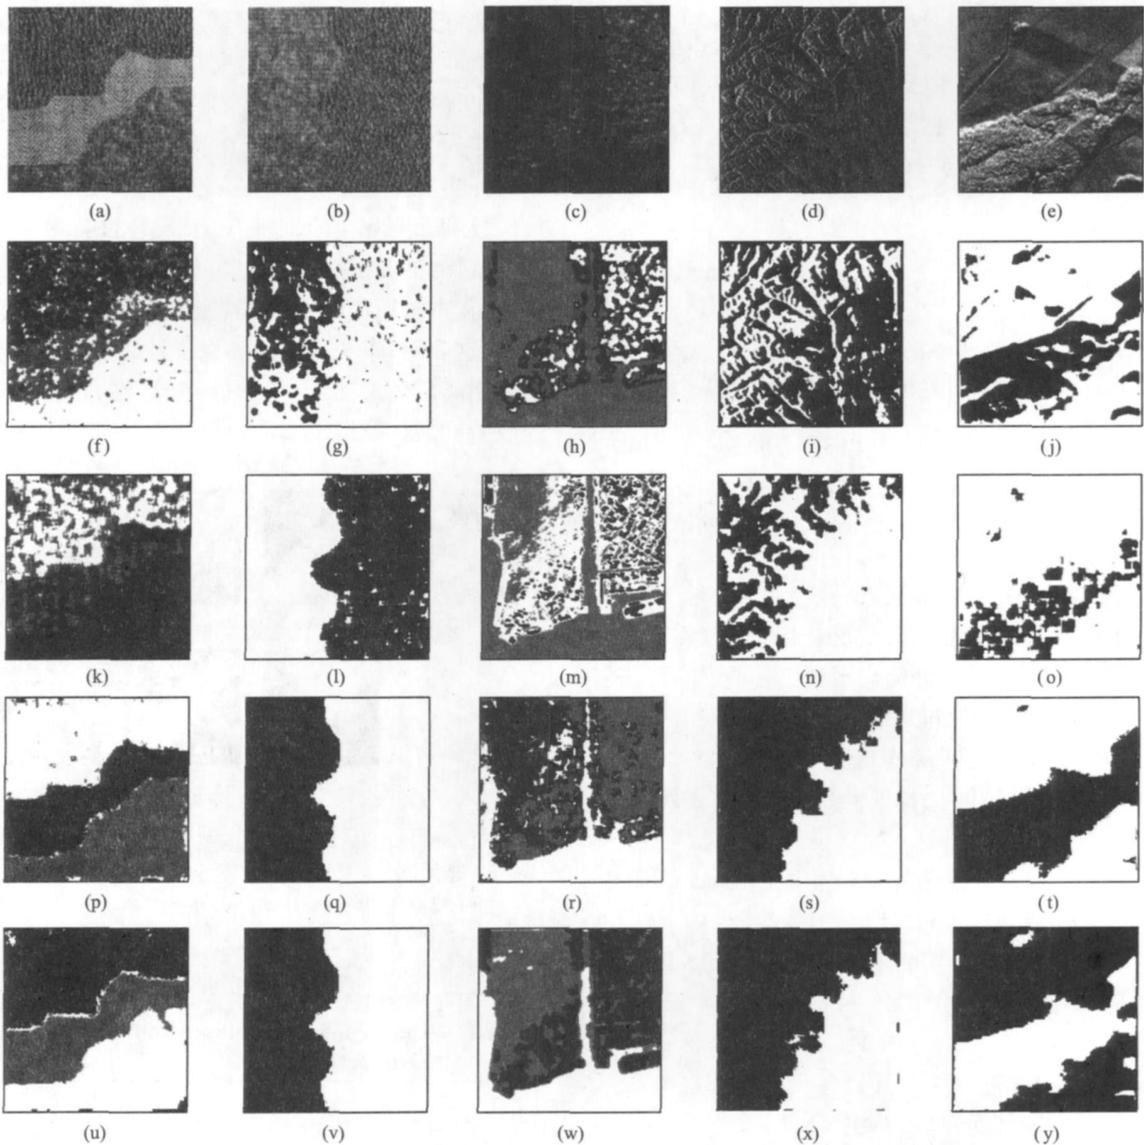


图 4 分割结果 (a)~(e)测试图像 (f)~(j)方案(1)分割结果 (k)~(o)方案(2)分割结果 (p)~(t)方案(3)分割结果 (u)~(y)方案(4)分割结果

Fig 4 Segmentation result (a)~(e) test images (f)~(j) segnencation results of scheme(1) (k)~(o) results of scheme(2) (p)~(t) results of scheme(3) (u)~(y) results of scheme(4)

为纹理特征,采用 C均值算法进行分割,结果如图 4(k)~(o);

方案 3:采用 C均值聚类计算 FIMP 特征的 CFIMP_{seg}算法,结果如图 4(p)~(t);

方案 4:采用模糊 C均值聚类计算 FIMP 特征的 CFIMP_{seg}算法,结果如图 4(u)~(y).

从图 4可以看出,不论是采用 C均值聚类还是模糊 C均值聚类,CFIMP_{seg}算法因为充分利用了多尺度信息而具有更好的分割性能.方案 1 虽然利用了多尺度信息,但它不能考虑不同特征表达区域和边界的优缺点,因而效果较差;因为单一尺度的观测数据难以表现纹理的非平稳性,因此方案 2 提取出的特征不能很好表达纹理的局部变化情况,导致分割结果不够理想;方案 3 和 4 的分割结果不论在区域一致性还是在边界保持性都有优越性,在保持边缘的同时,能够形成大范围一致的纹理区域,但是两种方案的结果没有太大差别.从表 2 也可以看出,方案 3 和 4 的分类精度相对于 1 和 2 有明显提高,但是二者非常接近.这说明,CFIMP_{seg}算法不论是采用 FCM 算法还是 C均值算法均具有相似的结果.但因为 C均值聚类算法更为简洁,本文在设计算法时采用了后者.

从计算效率上来看,CFIMP_{seg}避免了基于模型方法的复杂的参数计算过程,每一尺度上只通过简单的 2 中心聚类来计算相应的纹理特征,因此在上述实验中提取 FIMP 特征比提取 GMRF 参数模型参数特征要快得多,在 Window Xp 操作系统下,Matlab R2007b 的编程环境中,对大小为 256 × 256 的图像运算时间分别为 33 s 和 93 s 所以,本文所提的 FIMP 特征在保证较好的描述纹理的条件下,具有较高的运行效率.

5 结论及展望

本文提出一种新的特征提取方法—有限混合纹理模式 FIMP,并在该模式的基础上提出了一个 Contourlet 域的纹理分割算法 CFIMP_{seg} 通过实验验证分析了该方法在初始值选择、多尺度融合和分割性能上的优越性.在 CFIMP_{seg} 中,关键的问题有三个:(1)局部变化模式的计算方法;(2)相似度的定义方式,这决定了粗分割结果的好坏;(3)上下尺

表 2 算法分割性能比较 (%)

Table 2 The comparison of the segmentation performance

图像	方案 1	方案 2	方案 3	方案 4
(a)	77.4	75.3	91.6	91.9
(b)	69.1	91.4	96.8	96.8
(c)	45.2	47.9	90.1	91.4
(d)	66.7	72.3	97.8	97.0
(e)	85.3	82.6	93.0	91.8

度融合的方法,这将影响最终的分割结果.如何对上述的三个问题做进一步的研究以获得更好的分割结果是今后研究的一个重要方向.

REFERENCES

- [1] Lam B, Ciesielski V. Discovery of Human-Competitive Image Texture Feature Extraction Programs Using Genetic Programming [C]. *Genetic and Evolutionary Computation Conference*, Seattle: 2004, 2: 1114—1125.
- [2] Reed T R, Hans du Buf J M. A review of recent texture segmentation and feature extraction techniques[J]. *Graphic Model and Image Understanding*, 1993, 57(3): 359—372.
- [3] Haralick R M, Shanmugan K, Dinstein I H. Texture features for image classification[J]. *IEEE Transactions on System, Man, and Cybernetics*, 1973, SM C-3(6): 610—621.
- [4] WU Gao-Hong, ZHANG Yu-Jin, LN Xing-Gang. Texture segmentation with wavelet transform and feature weighting [J]. *Journal of Image and Graphics* (吴高洪,章毓晋,林行刚.利用小波变换和特征加权进行纹理分割.中国图象图形学报), 2001, 6A(4): 333—337.
- [5] Li Y, Gong P. An efficient texture image segmentation algorithm based on the GMRF model for classification of remotely sensed imagery [J]. *International Journal of Remote Sensing*, 2005, 26(22): 5149—5159.
- [6] Panjwani D K, Healey G. Markov random field models for unsupervised segmentation of textured color images [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1995, 17(10): 939—954.
- [7] Liu G Y, Wang L G, Xie W, et al. New texture segmentation approach based on multiresolution MRFs with variable weighting parameters in wavelet domain [C]. *SPIE: MIP-PR*, Wuhan, 2007, 6786(6786 D): 1—8.
- [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] Shapiro L S G. *Computer Vision* [M]. Prentice Hall, 2001.
- [10] BAN Zhao-Qing, ZHANG Xue-Gong. *Pattern recognition* (2nd edition) [M]. Beijing: Tsinghua University Press (边肇祺,张学工.模式识别(第二版).北京:清华大学出版社), 1999.