论 文

带方向特征的 Contourlet HMT 模型

王相海^{①②③*}, 陈明莹^①, 宋传鸣^{①②}, 徐孟春^①, 方玲玲^③

① 辽宁师范大学计算机与信息技术学院, 大连 116029

② 南京大学计算机软件新技术国家重点实验室, 南京 210093

③ 苏州大学江苏省计算机信息处理技术重点实验室, 苏州 215006

* 通信作者. E-mail: xhwang@lnnu.edu.cn

收稿日期: 2012-04-18; 接受日期: 2012-08-07

国家自然科学基金 (批准号: 41271422)、辽宁省自然科学基金 (批准号: 20102123)、辽宁“百千万人才工程” (批准号: 2008921036) 和计算机软件新技术国家重点实验室 (南京大学) 开放课题 (批准号: KFKT2011B09, KFKT2011B11) 资助项目

摘要 根据 Shannon 信息理论将纹理的方向特征定义为: 图像中信号取值为随机分布的奇异值时方向变量的取值特征. 根据这一定义, 并结合 Tamura 方向特征的求取方法, 文中对 Contourlet 变换系数的方向概率分布进行了研究, 获得方向特征在 Contourlet 变换的父子子带间形成传递这一结论, 在此基础上结合 Contourlet 隐 Markov 树 (HMT) 模型, 建立了以隐状态变量分布为条件的方向隐变量的概率分布模型, 即带方向特征的 Contourlet HMT 模型, 给出了该模型的结构和训练方法. 此外, 通过基于所提出模型的无监督结合上下文信息的图像分割算法对合成图像和遥感图像的目标分割实验验证了所提出模型的有效性.

关键词 方向特征 Contourlet HMT 带方向特征的 Contourlet HMT 无监督纹理分割 隐状态变量分布

1 引言

纹理作为反映物体表面的一种重要信息一直是图像分类、图像分析等研究领域的热点之一. 它通常具有局部的随机性和整体的统计规律性. 纹理分析中的随机模型法便是利用纹理在统计上的规律性和像素间存在的相互关系, 建立参数模型以刻画图像中主要信息. 常用的随机模型包括 Markov 随机场、Gibbs 随机场和隐 Markov 随机模型 (HMM, hidden Markov random model) 等, 其中 Crouse 等提出的小波域隐 Markov 模型 (WD-HMM's, wavelet domain hidden Markov model) [1], 因其有效地描述了实际信号小波系数的统计特性——尺度间系数的持续性 (persistence) 和尺度内系数的聚集性 (clustering), 而成为纹理分析领域的一种新颖、有效的模型框架. 在此基础上 Duncan 和 Minh 利用 Contourlet 变换的多尺度和多方向特性, 从分析系数的概率分布和系数间的互信息入手, 建立了 Contourlet 隐 Markov 树 (HMT, hidden Markov tree) 模型 [2], 使得系数间的依赖关系从尺度内扩大到尺度间及方向子带之间. 文献 [3] 结合 JMCMS (a joint multicontext and multiscale) 模型 [4] 提出一种改进的 Contourlet 域 HMT 模型的图像分割方法, 该方法对模型参数初始化进行了估计, 即结合多尺度变换系数层间和层内的关系计算初始值, 然而在模型训练方面仅仅依靠估计初始值是不能很好地分析出图像的纹理走向

引用格式: 王相海, 陈明莹, 宋传鸣, 等. 带方向特征的 Contourlet HMT 模型. 中国科学: 信息科学, 2013, 43: 626–643, doi: 10.1360/112010-1288

及隐含的细节信息. 此外, 文献 [5] 提出一种基于 Contourlet HMT 和 Gauss-Markov 模型的混合模型来反映尺度间和邻域间的系数关系, 并将其应用于 SAR 降噪; 文献 [6] 采用了一种基于 Contourlet 上下文的隐 Markov 模型, 有效利用了层内与层间的相互作用, 从而增强了基于上下文设计进程的互信息, 使得在图像去噪的应用上取得了不错的效果; 文献 [7] 采用非下采样 Contourlet 变换 NSCT (non subsampled contourlet transform) 来捕捉高频信息中的多方向纹理细节信息, 以便更好的确定文字分割区域; 文献 [8] 结合非下采样 Contourlet 的平移不变性和多向膨胀性, 给出了一种新的基于上下文的 HMT 模型, 用以分割图像并融合精细尺度上的信息, 获得了更好的边缘信息; 文献 [9, 10] 拓展了 Contourlet 域的 HMT 框架, 将 D-S 证据理论和 MRF(Markov random field) 模型结合到框架中, 提高了 SAR 图像的分割精度. 综上, 目前的 Contourlet HMT 模型大都比较关注尺度内和尺度间系数的概率分布及互信息, 而在一定程度上忽视了图像中纹理隐含的方向特性所能带来的指导作用, 而使得在诸如图像分割等实际应用中图像的很多边缘细节信息被过滤掉或被错误识别. 本文在 Contourlet HMT(CHMT) 模型的基础上建立了一个新的具有方向概率的 Contourlet HMT 模型, 该模型将图像中的纹理信息作为一整体直接按照可能隐含的状态进行训练, 然后获取不同状态下纹理所给出的信息. 它能够更好地融合各个方向子带的纹理特征, 更加全面地表征纹理的方向特征; 同时将该模型应用到非监督、结合上下文背景的纹理分割算法中, 取得了很好的效果. 实验结果证实了本文提出的带有方向概率的 Contourlet HMT 模型在纹理方向特征的表现上要优于同等情况下的 Contourlet HMT 模型. 该模型可广泛应用于基于纹理特征的图像处理与分析应用领域中.

本文的组织如下: 第 2 节介绍 Contourlet HMT 模型相关理论及其构建的基本算法; 第 3 节首先将阐述具有方向概率的 Contourlet HMT 模型的构建思想, 进一步给出了该模型的结构及训练方法; 第 4 节将所提出的带有方向概率的 Contourlet HMT 模型应用到非监督、结合上下文背景的纹理分割中, 给出该模型的实际应用过程; 第 5 节给出实验结果及分析, 第 6 节为小结.

2 Contourlet HMT 模型

Contourlet 变换是继小波变换出现后的又一变换, Minh 等在对其进行统计分析后建立了广泛应用于各领域的 Contourlet 模型.

2.1 Contourlet 变换系数的概率统计特性

自然图像大多具有光滑的纹理线条, 为了更好地对这些光滑曲线进行逼近, Minh 等提出了一种“真正”的二维图像的稀疏表示方法——Contourlet 变换^[2], 它不仅继承了小波变换的多分辨率时频分析特征, 而且拥有良好的各向异性特征. 因为具有抛物线式的尺度关系 (parabolic scaling) 保证了具有线形或矩形支撑集的基沿着曲线敷设, 所以 Contourlet 变换仅用少量系数就能有效地逼近平滑奇异曲线, 进一步, Minh 等对 Contourlet 变换的系数进行了边缘统计和联合统计分析^[11]:

(1) 边缘统计特性分析

从系数分布直方图可以发现, 变换系数的边缘分布具有非 Gauss、高峰度和长拖尾等特点, 此特性说明 Contourlet 变换具有稀疏性;

(2) 联合统计分析

对于当前系数 X , 定义如下广义邻域相关系数:

PX(父系数): 处于 X 上一级尺度、对应方向子带上, 与 X 的空间位置一致的唯一系数.

NX(邻域系数): 与 X 处于同一尺度、同一方向子带上, X 周围的 8 个相邻系数.

CX(堂兄弟系数): 与 X 处于同一尺度、不同方向子带上, 与 X 的空间位置一致的若干系数.

①当以 PX , NX , CX 分别取某些特定值 px , nx , cx 为条件时, 系数 X 的分布 $P(X|PX = px)$, $P(X|NX = nx)$, $P(X|CX = cx)$ 的峰度值接近标准 Gauss 分布的峰度值 $Kurtosis_{\text{Gaussian}} = 3$. 因而尽管 Contourlet 系数的边缘分布具有明显非 Gauss 性, 但在广义邻域系数条件下, 依然可以用混合 Gauss 分布模型 (Gaussian mixture model) 对其进行建模.

②用如下互信息

$$I(X; Y) = \int \int p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy, \quad (1)$$

对系数之间的相关性进行估计. 可得出以单个广义邻域系数为研究对象的条件下, 各种广义邻域系数的互信息具有如下关系: $I(X, PX) > I(X, NX_i) > I(X, CX_i)$, 此特性说明在各种广义邻域系数关系中父系数对子系数具有较强的预测能力.

2.2 Contourlet HMT 模型的建立

在前面 Contourlet 变换系数统计特性的基础上, 文献 [11] 借鉴 WD-HMM's 模型建立了 Contourlet HMT 模型, 其建模过程如下:

首先, 建立每个系数的 Gauss 混合 N 状态的概率模型 (GMM, Gaussian mixture probability model). N 状态 Gauss 混合模型定义为

$$f_{w_i}(w_i) = \sum_{m=1, \dots, N} f_{s_i}(m) f_{w_i|s_i}(w_i/s_i = m), \quad (2)$$

其中 s_i 表示控制系数选取何种隐状态的隐状态变量, $f_{s_i}(m)$ 为系数取大小状态的概率, 并且

$$\sum_{m=1, \dots, N} f_{s_i}(m) = 1, \quad (3)$$

$$f_{w_i|s_i}(w_i|s_i = m) = \frac{1}{\sqrt{2\pi\sigma_{im}^2}} \exp \left[-\frac{(w_i - \mu_{im})^2}{2\sigma_{im}^2} \right] = g(w_i; \mu_{im}, \sigma_{im}^2),$$

为系数取某一隐状态条件下, 对应 Gauss 模型的概率分布密度函数.

然后, 用 HMT 模型来表现尺度间的相关性. 在 HMT 模型中尺度系数的相关性是通过隐状态的 Markov 链来建立的.

以一个两状态、由粗到细尺度上方向子带的个数依次为 4, 4, 8, 8 的 Contourlet 变换为例, 其 CHMT 概率图模型如图 1 所示.

CHMT 模型的相关参数如下:

(1) $\pi_{S', d}$ ($d = 1, \dots, D_1$, D_1 为最粗尺度上方向子带的个数, S' 为最粗尺度上的隐状态变量) 是各个方向子带根节点隐状态变量概率分布组成的向量, 其中 d 方向子带上的隐状态分布为 $\pi_m = f(s'_i = m)$, ($m = 1, \dots, N$ 为隐状态变量的取值).

(2)

$$A_d^j = \begin{bmatrix} \varepsilon_{i, p(i)}^{s_1, s_2} & \cdots & \varepsilon_{i, p(i)}^{s_1, s_N} \\ \vdots & & \vdots \\ \varepsilon_{i, p(i)}^{s_N, s_1} & \cdots & \varepsilon_{i, p(i)}^{s_N-1, s_N} \end{bmatrix}$$

图 1 Contourlet 变换 HMT 模型示例图

Figure 1 Diagram of Contourlet HMT model

是 j 尺度 d 方向子带和 $(j-1)$ 尺度上它的父子带之间的状态转移概率. 其中, $j = 2, \dots, J$, J 为分解的尺度级数; $d = 1, \dots, D_j$ 为各分解级上方向子带的个数, $\varepsilon_{i,p(i)}^{m,n} = f(s_i = m | s_{p(i)} = n)$ 是已知父节点 $p(i)$ 的状态变量 $s_{p(i)}$ 的值为 n 时, 子节点 i 的状态变量 s_i 的值为 m 的条件概率.

(3) 已知 j 尺度 d 方向子带上隐状态变量 s_i 的取值时, Contourlet 系数的 Gauss 分布的方差和均值为 $\mu_{s^j,d}, \sigma_{s^j,d}$.

3 带有方向概率的 Contourlet HMT 模型

由上面的 CHMT 模型可知, 经 Contourlet 变换的系数具有较强的方向性, 且具有一定的概率性, 为此进行了分析, 给出了带方向概率的 CHMT 模型, 并给出了其训练过程.

3.1 Contourlet 系数方向特征的概率分布特点

依据 Shannon 信息理论, 图像的纹理信息主要是由发生概率较小, 即具有奇异性的点和线所提供的. 如果将纹理看做是由奇异点和线在空间上的随机分布所组成的一簇信号, 那么 Contourlet HMT 模型便是通过求取 Contourlet 变换后系数的隐状态发生的概率来估计图像中奇异点发生的概率, 进而对纹理信息进行描述. 然而我们仅仅通过奇异点发生的概率这一信息对纹理形成的认识依然是很抽象的, 并且对于不同的纹理区域它们的奇异点和线发生的概率也很可能是相同的. 所以我们希望通过方向这一纹理的主要特征来对纹理有更加确切的描述和认识. 根据 Shannon 信息理论本文将纹理的方向特征定义为: 图像中信号取值为随机分布的奇异值时方向变量的取值特征. 对于捕获图像中的方向信息, 人们进行了大量的研究, 文献 [11] 已经证明利用 Contourlet 变换方向滤波器组对纹理方向有很好的逼近, 在此不再赘述. 这里我们所关心的是方向变量的取值特征, 即对于 Contourlet 变换后的系数其方向特征在概率分布上具有哪些特点. 为此我们将 Tamura 纹理方向求取方法 [12] 应用到 Contourlet 系数之上.

首先按模板求取变换后 3×3 大小的窗口上系数的方向值, 再用直方图的方法对各个分解尺度和分解方向上的系数方向特征进行统计. 图 2 给出纹理图像 “Bubbles” 经过由粗到细方向子带个数分别为 4, 4, 8, 8 的 Contourlet 变换后按该统计方法所得到的方向直方图. 由图 2 可以看出, 如果我们以最粗尺度上的方向子带作为根节点, 那么具有相同根节点的那些子带上的方向特征有着相近似的概率分布直方图, 特别是具有父子关系的子带它们的方向概率分布直方图近似程度更大. 表 1~3 分别列出了纹理图像 Bubbles、自然图像 Lenna 和遥感图像 San Diego (Shelter Island) 经过从粗到细方向子带

图 2 Bubbles 图像及其 Contourlet 子带方向直方图

Figure 2 “Bubbles” and its direction histogram of Contourlet subbands. (a) Original “Bubbles”; (b) direction histogram of directional subbands’ coefficients from coarse to fine scales

表 1 Bubbles 图像各个父子带之间的方向特征直方图的相似度距离

Table 1 Similarity between each pair of parent-child subbands’ direction histograms of “Bubbles”

	P1	P2	P3	P4	P5	P6	P7	P8	Mean
C1	0.0535	0.0673	0.0645	0.0569	0.0701	0.0643	0.0534	0.0678	0.0622
C2	0.0589	0.0549	0.0561	0.0580	0.0542	0.0497	0.0507	0.0571	0.0550
C3	0.0648	0.0586	0.0503	0.0579	0.0542	0.0481	0.0534	0.0555	0.0554
C4	0.0611	0.0561	0.0498	0.0596	0.0436	0.0530	0.0570	0.0554	0.0544
C5	0.0707	0.0524	0.0517	0.0698	0.0549	0.0539	0.0594	0.0621	0.0594
C6	0.0731	0.0694	0.0562	0.0730	0.0552	0.0552	0.0599	0.0611	0.0629
C7	0.0598	0.0551	0.0467	0.0581	0.0515	0.0500	0.0474	0.0594	0.0535
C8	0.0688	0.0567	0.0482	0.0602	0.0469	0.0537	0.0541	0.0586	0.0559

表 2 Lenna 图像各个父子带之间的方向特征直方图的相似度距离

Table 2 Similarity between each pair of parent-child subbands’ direction histograms of “Lenna”

	P1	P2	P3	P4	P5	P6	P7	P8	Mean
C1	0.0184	0.0566	0.0180	0.053	0.0188	0.0495	0.0195	0.0425	0.0345
C2	0.0651	0.0247	0.0646	0.0328	0.0718	0.0308	0.0667	0.0390	0.0494
C3	0.0201	0.0412	0.0194	0.0379	0.0244	0.0339	0.0220	0.0274	0.0283
C4	0.0405	0.0252	0.0387	0.0180	0.0463	0.0162	0.0421	0.0158	0.0304
C5	0.0229	0.0523	0.0225	0.0506	0.0228	0.0469	0.0192	0.0400	0.0347
C6	0.0417	0.0190	0.0403	0.0209	0.0476	0.0182	0.0426	0.0183	0.0311
C7	0.0172	0.0465	0.0198	0.0445	0.0209	0.0408	0.0171	0.0349	0.0302
C8	0.0420	0.0259	0.0399	0.0212	0.0461	0.0205	0.0440	0.0206	0.0326

个数分别为 4, 4, 8, 8 的 Contourlet 变换后, 最细尺度上各个方向子带同它们上一级尺度的各个父子带之间的方向特征直方图通过欧式距离得到的相似度, 距离越小, 相似度越高, 其中 C1~C8 为最细尺度子带直方图, P1~P8 为 C1~C8 的父子带直方图, Mean 为距离均值. 可以看出, 同一方向子带与上一级尺度上的各个方向子带间的相似度距离中, 父子带的相似度距离较小, 基本上低于平均相似度距

表 3 San Diego (Shelter Island) 遥感图像各个父子带之间的方向特征直方图的相似度距离

Table 3 Similarity between each pair of parent-child subbands' direction histograms of "San Diego (Shelter island)"

	P1	P2	P3	P4	P5	P6	P7	P8	Mean
C1	0.0215	0.0531	0.0223	0.0504	0.0264	0.0317	0.0267	0.0223	0.0318
C2	0.0290	0.0266	0.0359	0.0283	0.0525	0.0223	0.0531	0.0288	0.0346
C3	0.0272	0.0607	0.0199	0.0557	0.0174	0.0368	0.0209	0.0261	0.0331
C4	0.0320	0.0267	0.0376	0.0182	0.0586	0.0224	0.0607	0.0301	0.0358
C5	0.0280	0.0617	0.0228	0.0567	0.0194	0.0388	0.0229	0.0284	0.0348
C6	0.0302	0.0241	0.0353	0.0197	0.0563	0.0203	0.0582	0.0286	0.0341
C7	0.0268	0.0594	0.0248	0.0576	0.0241	0.0397	0.0211	0.0289	0.0353
C8	0.0225	0.0328	0.0283	0.0273	0.0459	0.0183	0.0475	0.0223	0.0306

离. 我们对大量的纹理图像进行了相同的实验, 得出了同样的结果, 这一概率特点也符合 Markov 链的定义. 由此, 我们获得如下结论: Contourlet 子带系数的方向特征继承了其父子带的相关性, 即方向特征在 Contourlet 变换的父子子带间进行了传递.

3.2 带有方向概率的 Contourlet HMT 模型结构

3.1 小节实验中所用的 Tamura 方法求取的方向特征只是对变换系数 (或图像像素的灰度值) 按照一定的规则向方向特征所做的一种近似映射, 而事实上纹理取哪些方向值事先是未知的, 这样可将方向变量也看成是一个隐状态变量, 即隐方向变量作为隐状态的隐状态. 为了区分 Contourlet HMT 中原有的隐状态变量, 我们用隐方向变量 θ 来表示这个二次隐状态. $\theta_i \in D_{ir}$ 为信号在位置 i 处的方向值, D_{ir} 为方向空间. 下面利用 Contourlet 变换后系数隐状态的概率来估计图像中奇异点发生的概率, 进而对纹理信息进行描述. 我们将位置 i 处纹理的方向特征定义为当信号的状态变量 s_i 取某一隐状态值的条件下隐方向变量 θ_i 的概率分布, 记为 $p(\theta_i = d | s_i = m)$. 特别地, 对于给定 j 尺度上概率参数模型 Θ^j 、Contourlet 系数观察值 T_1 及隐状态变量的取值, 将隐方向变量取某一特定值的概率记为 $p(\theta_i^j = d | s_i^j = m, T_1, \Theta^j)$, 则由 Bayes 定理可得到

$$p(\theta_i^j = d | s_i^j = m, T_1, \Theta^j) = \frac{p(\theta_i^j = d | T_1, \Theta^j) p(s_i^j = m | \theta_i^j = d, T_1, \Theta^j)}{\sum_d p(\theta_i^j = d | T_1, \Theta^j) p(s_i^j = m | \theta_i^j = d, T_1, \Theta^j)}, \quad (4)$$

其中, $p(s_i^j = m | \theta_i^j = d, T_1, \Theta^j)$ 为给定模型参数、系数观察值和隐方向变量取值条件下隐状态变量的概率分布.

如果我们将隐方向变量取值的方向空间 D_{ir} 定义为 Contourlet 变换后各个方向子带所代表的方向值的集合, 那么 $p(s_i^j = m | \theta_i^j = d, T_1, \Theta^j)$ 就可以通过 Contourlet HMT 模型中各个方向子带上的隐状态变量的概率分布来替代, 从而大大简化了计算, 使得对隐方向变量的概率分布估计成为可能. 进而隐方向变量的先验概率 $p(\theta_i^j = d | T_1, \Theta^j)$ 就成为了在给定模型参数和系数观察值的条件下, 隐方向变量取某一方子带所代表的方向值的概率. 把该概率看作是权值, 那么联合概率 $\sum_d p(\theta_i^j = d | T_1, \Theta^j) p(s_i^j = m | \theta_i^j = d, T_1, \Theta^j)$ 就可以通过各个方向子带上隐状态取值的概率以按权求和的形式获得. 这样我们就得到了一个双重隐 Markov 过程: 由 3.1 小节中的结论可知隐方向变量在上下尺度间具有相关

图 3 带有方向特征的 Contourlet HMT 模型示意图, 其中阴影方框部分是训练方向的新模型

Figure 3 Diagram of Contourlet HMT model with directional features, in which the shadowed square denotes our proposed model for training direction

性, 且隐方向作为一个隐性的状态求取后以其变量取得某一方向值作为权值的条件下, 联合隐状态变量的取值过程。

综上, 我们建立了带有方向概率的 Contourlet HMT 模型结构. 它由两个树型隐 Markov 结构构成, 第一部分通过原有的 Contourlet HMT 模型求取各个方向子带上隐状态变量的概率, 第二部分则用一个联合隐状态变量将各个方向子带的隐状态概率按照隐方向变量先验概率这一权值进行结合, 并通过隐方向变量在上下尺度间的相关性建立尺度间的 Markov 链结构. 在实际模型的建立过程中, 为了保证模型训练的可行性和隐方向变量取值的一致性, 我们将隐方向变量的个数定为最粗尺度上方向子带的个数, 即 Contourlet HMT 模型根节点的个数. 利用树形结构的概率图模型, 以最粗子带上的隐方向变量为根结点, 建立树形结构的 HMT 模型 (图 3), 其中隐方向变量的 HMT 模型参数如下:

(1) $\pi_{\theta^1, m}$ ($m = 1, \dots, N$, N 为隐状态变量的个数, θ^1 为最粗尺度上的隐状态变量) 是各个隐状态树根节点的隐方向变量概率分布所组成的向量, 其中隐状态树 m 的初始隐方向变量分布为 $\pi_d = f(\theta_i^1 = d)$, 这里 $d = 1, \dots, D$ 为隐方向变量的取值.

(2)

$$A_m^j = \begin{bmatrix} \varepsilon_{i, p(i)}^{d_1, d_2} & \cdots & \varepsilon_{i, p(i)}^{d_1, d_D} \\ \vdots & & \vdots \\ \varepsilon_{i, p(i)}^{d_D, d_1} & \cdots & \varepsilon_{i, p(i)}^{d_{D-1}, d_D} \end{bmatrix}$$

($j = 2, \dots, J$, J 为分解的尺度级数) 是隐状态树 m , 尺度 j 上的节点 i 和尺度 $(j-1)$ 上其父节点 $p(i)$ 之间的状态转移概率, 其中, $\varepsilon_{i, p(i)}^{d, t} = f(\theta_i = d | \theta_{p(i)} = t)$ 是已知父节点 $p(i)$ 的隐方向变量 $\theta_{p(i)}$ 的值为 t 时, 子节点 i 的状态变量 θ_i 的值为 d 的条件概率. d_1 表示子节点方向变量, d_2 表示父节点方向变量.

(3) $\mu_{m, d}^j$, $\sigma_{m, d}^j$ 分别为隐状态树 m 尺度 j 上的节点 i 的隐方向变量 θ_i 的取值为 d 时, 节点的方差和均值.

3.3 隐方向变量 HMT 模型的参数估计

对于隐方向变量 HMT 的参数估计, 我们借鉴对隐状态变量参数进行估计的 HMT-EM 算法^[1,13], 根据新的参数得到如下计算过程:

设 l 为初始化迭代次数.

步骤 1: E 步骤. 采用上向 — 下向算法计算如下隐方向变量的联合后验分布函数.

$$p(\theta_i = d | s_i = m, T_1, \Theta^l), p(\theta_i = d, \theta_{p(i)} = t | s_i = m, T_1, \Theta^l). \quad (5)$$

E1. 定义 T_i 为以节点 i 为根结点的观察值 (联合隐状态变量) 的子树, T_i 包含 s_i 及其所有后代. 如果 T_j 是 T_i 的一棵子树, 那么定义 $T_{i \setminus j}$ 为将 T_j 从 T_i 中除去后余下的所有联合隐状态变量. 特别地, T_1 表示整个联合隐状态变量树.

E2. 引入中间变量.

联合概率: $\alpha_i(d) = p(\theta_i = d, s_i | \Theta)$ 为给定参数下, 方向与状态的联合概率.

条件似然: $\beta_i(d) = f(s_i | \theta_i = d, \Theta)$ 为给定隐方向变量取某一方向值的条件下隐状态变量的概率; $\beta_{i,p(i)}(d) = f(s_i | \theta_{p(i)} = d, \Theta)$ $\beta_{p(i) \setminus i}(d) = f(s_{p(i) \setminus i} | \theta_{p(i)} = d, \Theta)$ 为联合隐状态变量树上的父节点对应隐方向变量取某一方向值的条件下, 以父节点为根的树上除去以当前节点为根的子树外其他节点的概率分布. 根据 HMT 的性质, 对于给定隐方向变量 θ_i , 树 T_i 和 T_1 是独立的, 故有

$$p(\theta_i = d, T_1 | \Theta) = \alpha_i(d) \beta_i(d), \quad (6)$$

$$p(\theta_i = d, \theta_{p(i)} = t, s_1 | \Theta) = \beta_i(d) \varepsilon_{i,p(i)}^{d,t} \alpha_{p(i)}(t) \beta_{p(i) \setminus i}(t), \quad (7)$$

其中, $\varepsilon_{i,p(i)}^{d,t} = p(\theta_i = d | \theta_{p(i)} = t)$.

似然值:

$$f(T_1 | \Theta) = \sum_{d=1}^D p(\theta_i = m, T_1 | \Theta) = \sum_{d=1}^D \beta_i(m) \alpha_i(m). \quad (8)$$

进一步应用 Bayes 规则, 获得如下条件概率

$$p(\theta_i = d | T_1, \Theta) = \frac{\alpha_i(d) \beta_i(d)}{\sum_{d=1}^D \alpha_i(d) \beta_i(d)}, \quad (9)$$

$$p(\theta_i = d, \theta_{p(i)} = t | T_1, \Theta) = \frac{\beta_i(d) \varepsilon_{i,p(i)}^{d,t} \alpha_{p(i)}(t) \beta_{p(i) \setminus i}(t)}{\sum_{d=1}^D \sum_{t=1}^D \beta_i(d) \varepsilon_{i,p(i)}^{d,t} \alpha_{p(i)}(t) \beta_{p(i) \setminus i}(t)}. \quad (10)$$

E3. 上向步骤.

①初始化: 对最细尺度 $j = 1$ 的各个方向子带的隐状态变量进行初始化: $\beta_{i,d}(m) = g(w_{id}; \mu_{imd}, \sigma_{imd}^2)$, 并对所有隐方向变量 $\theta_i = d$ 计算

$$\beta_i(d) = \frac{g(w_{id}; \mu_{imd}, \sigma_{imd}^2)}{\sum_{d=1}^D g(w_{id}; \mu_{imd}, \sigma_{imd}^2)}. \quad (11)$$

②沿树形结构移至上一个尺度, 令 $j = j + 1$.

③对尺度 j 上所有的隐方向变量 θ_t , 计算 $\theta_t = d$ 时的

$$\beta_{p(t)}(d) = \frac{p(s_i^j = m | \theta_i^j = d, T_1, \Theta^j)}{\sum_d p(s_i^j = m | \theta_i^j = d, T_1, \Theta^j)} \prod_{t \in p(t)} \beta_{p(t) \setminus t}(d). \quad (12)$$

④若 $j = J$, 则停止, 否则返回步骤②.

E4. 下向步骤.

对尺度 $j = J$ 上所有隐方向变量 θ_t 设置的 $\alpha_t(d) = p_{\theta_t}(d)$, 其中 $d = 0, 1, \dots, D$.

①沿树形结构移向下一个尺度, 令 $j = j - 1$.

②为尺度 j 上所有隐方向变量 θ_t 计算 $d = 0, 1, \dots, D$ 时的

$$\alpha_t(d_1) = \sum_d \varepsilon_{t,p(t)}^{d_1 d_2} \alpha_{p(t)}(d_2) \beta_{p(t) \setminus t}(d_2). \quad (13)$$

③若 $j = 1$, 则停止, 否则返回步骤①.

表 4 给出了图像 Lenna 通过 EM 算法训练得到的模型参数.

步骤 2: M 步骤. 进行参数 Θ^j 的更新和设置.

经过步骤 1 的 E 步骤计算, 方向概率分布已经确定, 此时 Θ^j 参数更新为

$$p_{\theta_i}^j(d) = \frac{1}{N_k} \sum_{i=1}^{N_k} p(\theta_i^j = d | \Theta), \quad (14)$$

$$\varepsilon_{i,p(i)}^{d,t(j)} = \frac{\sum_{i=1}^{N_k} p(\theta_i^{(j)} = d, \theta_{p(i)}^j = t | \Theta)}{N_k \cdot p_{\theta_{p(i)}}^{(j)}(d)}, \quad (15)$$

$$\mu_{id}^{(j)} = \frac{\sum_{i=1}^{N_k} w_i^{(j)} p(\theta_i^j = d | \Theta)}{N_k \cdot p_{\theta_i}^{(j)}(d)}, \quad (16)$$

$$\sigma_{jid}^2 = \frac{\sum_{i=1}^{N_k} (w_i^j - \mu_{id}^{(j)})^2 p(\theta_i^j = d | \Theta)}{N_k \cdot p_{\theta_i}^{(j)}(d)}, \quad (17)$$

表 4 带方向的 Contourlet HMT 模型参数

Table 4 Model parameters of Contourlet HMT with directionality

(a) Model parameters of Contourlet HMT

		$K = 1$		$K = 2$		$K = 3$		$K = 4$	
		State1	State2	State1	State2	State1	State2	State1	State2
$P_{1,k}$		0.70	0.30	0.41	0.59	0.46	0.54	0.98	0.02
$A_{2,k}$	State1	0.74	0.08	0.84	0.36	0.38	0.62	0.68	0.00
	State2	0.26	0.92	0.16	0.64	0.62	0.38	0.32	1.00
$A_{3,2k-1}$	State1	0.99	0.37	0.61	0.00	0.63	0.01	0.96	0.15
	State2	0.01	0.63	0.39	1.00	0.13	0.88	0.04	0.85
$A_{3,2k}$	State1	0.01	0.59	0.44	1.00	0.38	0.98	0.09	0.75
	State2	0.99	0.41	0.56	0.00	0.62	0.02	0.91	0.25
$A_{4,2k-1}$	State1	0.03	0.86	0.17	0.99	0.74	0.00	0.01	0.80
	State2	0.97	0.14	0.83	0.01	0.26	1.00	0.99	0.20
$A_{4,2k}$	State1	0.91	0.01	0.99	0.09	1.00	0.21	0.82	0.02
	State2	0.09	0.99	0.01	0.91	0.00	0.79	0.18	0.98
$\sigma_{1,k}$		219.53	311.9	268.29	164.30	49.75	137.97	148.32	66.94
$\sigma_{2,k}$		129.04	123.73	81.72	78.75	49.85	53.43	50.72	121.25
$\sigma_{3,2k-1}$		26.98	25.62	40.78	33.90	39.49	21.85	18.22	22.62
$\sigma_{3,2k}$		63.89	43.82	23.70	20.03	17.21	17.31	25.45	20.93
$\sigma_{4,2k-1}$		23.67	5.11	4.17	18.20	15.68	3.25	15.13	3.13
$\sigma_{4,2k}$		27.09	4.85	4.14	17.11	3.15	15.14	14.16	2.75

(b) HMT model parameters of hidden direction variables

		State1				State2			
		$K = 1$	$K = 2$	$K = 3$	$K = 4$	$K = 1$	$K = 2$	$K = 3$	$K = 4$
$P_{1,s}$		0.16	0.17	0.49	0.18	0.16	0.15	0.67	0.02
$A_{2,s}$	$K = 1$	0.73	0.00	0.25	0.07	0.61	0.00	0.07	0.00
	$K = 2$	0.00	0.16	0.00	0.08	0.00	0.19	0.26	0.00
	$K = 3$	0.16	0.49	0.21	0.03	0.31	0.81	0.37	0.00
	$K = 4$	0.11	0.35	0.54	0.82	0.08	0.00	0.30	1.00
$A_{3,s,1}$	$K = 1$	0.95	0.10	0.01	0.03	0.55	0.00	0.02	0.09
	$K = 2$	0.01	0.72	0.50	0.06	0.00	0.47	0.02	0.19
	$K = 3$	0.00	0.00	0.42	0.00	0.41	0.51	0.96	0.12
	$K = 4$	0.04	0.18	0.07	0.91	0.04	0.03	0.00	0.60
$A_{3,s,2}$	$K = 1$	0.00	0.66	0.00	0.02	0.04	0.52	0.08	0.45
	$K = 2$	0.51	0.00	0.38	0.15	0.30	0.00	0.02	0.13
	$K = 3$	0.40	0.34	0.25	0.82	0.19	0.00	0.02	0.29
	$K = 4$	0.09	0.00	0.37	0.01	0.47	0.48	0.89	0.13
$A_{4,s,1}$	$K = 1$	0.00	0.00	0.01	0.00	0.00	0.39	0.00	0.71
	$K = 2$	0.99	0.00	0.80	0.80	0.04	0.00	0.00	0.12
	$K = 3$	0.01	0.57	0.12	0.00	0.31	0.00	0.86	0.14
	$K = 4$	0.00	0.43	0.07	0.20	0.65	0.61	0.14	0.03
$A_{4,s,3}$	$K = 1$	0.00	0.00	0.00	0.01	0.98	0.00	0.21	0.00
	$K = 2$	0.00	1.00	0.00	0.23	0.00	0.00	0.14	0.00
	$K = 3$	0.40	0.00	1.00	0.18	0.00	0.88	0.15	0.00
	$K = 4$	0.60	0.00	0.00	0.58	0.02	0.12	0.50	1.00
$\sigma_{1,s}$		2.00	1.32	0.79	2.33	1.24	1.77	0.75	1.03
$\sigma_{2,s}$		1.41	3.46	1.44	1.13	1.70	1.40	1.03	1.14
$\sigma_{3,s,1}$		1.60	1.33	1.77	1.18	1.52	2.03	1.03	1.37
$\sigma_{3,2,2}$		2.46	1.52	1.07	1.56	1.67	1.87	1.68	1.06
$\sigma_{4,s,1}$		16.54	0.96	1.28	1.06	2.03	3.18	1.12	1.66
$\sigma_{4,s,2}$		17.68	1.47	1.07	1.55	1.62	4.02	1.56	1.03

其中 N_k 为第 k 个子带中系数的个数.

步骤 3: 如果参数收敛则停止, 否则返回步骤 1.

4 带方向特征的 Contourlet HMT 模型在纹理分割中的应用

4.1 基于带方向特征的 CHMT 模型的非监督初始分割

文献 [14] 中 HMT 模型的非监督初始分割算法在建立模型时将纹理所属的类别作为 HMT 模型的隐状态, 经过训练后给出了各个系数的类属概率 $f(C_i^j = c|T_i^j, \Theta)$, 其中 $c \in \{1, \dots, M_c\}$, 进一步取各

个类属概率中最大值所对应的那个类作为数据块的类标 $c = \arg \max_{c \in \{1, 2, \dots, M_c\}} f(C_i^j | T_i^j, \Theta)$. 在文献 [12] 等多数分割算法中都假设各个方向子带之间是相互独立的, 因而有

$$f(C_i^j | T_i^j, \Theta) = \prod_d^D f(C_{i,d}^{(j)} | T_{i,d}^{(j)}, \Theta). \quad (18)$$

尽管这一假设简化了 HMT 模型描述系数统计特性的过程, 但该假设忽略了相应各个方向子带之间所存在的相关性, 进而降低了纹理描述的准确性. 利用本文所提出的带方向特征的 CHMT 模型的联合类属概率则可在一定程度上解决这一问题. 它可以通过按照隐方向变量取得与方向子带所代表的方向值一致的概率作为权值来对不同方向子带上的类属概率进行加权来获得, 该方法中数据块的类属概率可通过如下公式确定:

$$f(C_i^j | T_i^j, \Theta) = \sum_d^D P_d \cdot P_c \cdot f(C_{i,d}^{(j)} | T_{i,d}^{(j)}, \Theta) \cdot f(\theta_i^j = d | T_i^j, \Theta), \quad (19)$$

其中 P_d 为统计每个加权后的方向子带在同一层的概率, P_c 为统计每个类别在整个类别中的概率.

上述方法通过各个方向子带之间的相关性, 更加合理的将各个方向子带的类属信息结合在一起, 在一定程度上提高了对纹理描述的准确性.

4.2 基于上下文背景信息融合的多尺度图像分割

由于 Contourlet 对于图像数据块的统计描述最小只能达到 2×2 大小, 为了使分割更加准确, 我们首先通过 Gauss 混合模型 (GMM) 建模的方法 [14] 获取像素级的最大似然分割, 进一步通过以下基于上下文背景信息融合的方法实现从 HMT 模型粗分割到像素级分割的融合.

(1) 上下文背景信息的类属概率.

对数据块 T_i^j 的上下文背景 V_i^j , 我们沿用文献 [12] 中的定义, 即由数据块的父节点、自身的 8 个邻域以及父节点的 8 个邻域组成, 分别记为 $V_p(i)$, $V_n(i)$, $V_{pn}(i)$. 按照上述上下文背景的定义, V_i^j 的类属概率可确定为

$$f(C_{V_p(i)}^j) = \prod_d^D f(C_{p(x),p(y),d}^{(j-1)} | T_{p(x),p(y),d}^{(j-1)}, \Theta) \cdot f(\theta_{p(x),p(y)}^{(j-1)} = d | T_{p(x),p(y)}^{(j-1)}, \Theta), \quad (20)$$

$$\begin{aligned} f(C_{V_{pn}(i)}^j) &= \frac{1}{8} \sum_{u=p(x)-1}^{p(x)+1} \sum_{v=p(y)-1}^{p(y)+1} f(C_{u,v,d}^{(j-1)} | T_{u,v,d}^{(j-1)}, \Theta) \cdot f(\theta_{u,v}^{(j-1)} = d | T_{u,v}^{(j-1)}, \Theta) \\ &\quad - \frac{1}{8} \sum_{u=p(x)-1}^{p(x)+1} \sum_{v=p(y)-1}^{p(y)+1} f(C_{p(x),p(y),d}^{(j-1)} | T_{p(x),p(y),d}^{(j-1)}, \Theta) \cdot f(\theta_{p(x),p(y)}^{(j-1)} = d | T_{p(x),p(y)}^{(j-1)}, \Theta), \end{aligned} \quad (21)$$

$$\begin{aligned} f(C_{V_n(i)}^j) &= \frac{1}{8} \sum_{u=x-1}^{x+1} \sum_{v=y-1}^{y+1} (f(C_{u,v,d}^j | T_{u,v,d}^j) \cdot f(\theta_{u,v}^j = d | T_{u,v}^j, \Theta) \\ &\quad - f(C_{x,y,d}^j | T_{x,y,d}^j, \Theta) \cdot f(\theta_{x,y}^j = d | T_{x,y}^j, \Theta)), \end{aligned} \quad (22)$$

其中 (x, y) 为当前数据块所对应的位置下标, $p(x) = \lfloor x/2 \rfloor$, $p(y) = \lfloor y/2 \rfloor$.

(2) Bayesian 图像分割方法

基于融合上下文背景信息的 Bayesian 图像分割^[15]的关键是如何确定使条件概率 $f(C_i^j|T_i^j, V_i^j)$ 达到最大的数据块 T_i^j 的类标 C_i^j 值. 由 Bayes 规则可知

$$f(C_i^j|T_i^j, V_i^j) = \frac{f(T_i^j|C_i^j, V_i^j) f(C_i^j|V_i^j)}{f(T_i^j|V_i^j)}. \quad (23)$$

由于 $f(T_i^j|V_i^j)$ 与 C_i^j 无关, 所以数据块 T_i^j 的类标 C_i^j 可由下式决定:

$$c_i^j = \arg \max_c f(T_i^j|C_i^j = c, V_i^j) f(C_i^j = c|V_i^j). \quad (24)$$

由于 T_i^j 在已知 C_i^j 的情况下独立于 V_i^j ^[15], 故有

$$f(T_i^j|C_i^j, V_i^j) = f(T_i^j|C_i^j). \quad (25)$$

在初始分割过程中, 似然性函数 $f(T_i^j|C_i^j)$ 已经确定, 因此计算 c_i^j 的关键在于确定如下概率:

$$f(C_i^j|V_i^j) = \frac{f(V_i^j|C_i^j) f(C_i^j)}{\sum_c f(V_i^j|C_i^j) f(C_i^j)}, \quad (26)$$

其中记 $e_{i,n} := f(C_i^j = n)$; $\alpha_{j,\overline{V_m},n} := p(V_i^j = \overline{V_m}|C_i^j = n)$, $\overline{V_m}$ 为上下文背景邻域信息.

对于 $\forall i, J(i) = j, m, n \in \{1, \dots, C\}$, 并通过以下过程求取 $P = \{e_{j,n}, \alpha_{j,\overline{V_m},n}\}$:

步骤 1: 初始化. 设置计数器 $I = 0$ 和初始参数集 P^I , 其中 P^I 由当前融合子带的上一级“初始分割”参数 (参见 4.1 小节) 组成, 具体在最大化 $f(C_{V(i)}^j)$ (其中 $V(i) = \{V_p(i), V_n(i), V_{pn}(i)\}$) 后获得其类标, 通过加权形式对当前数据块进行标注, 并将父亲层的轮廓信息融合到当前层.

步骤 2: E 步骤. 给定 P^I , 计算

$$f(C_i^j = n|T_i^j, V_i^j) = \frac{e_{i,n} \alpha_{j,v_i^j,n} \cdot f(T_i^j|C_i^j = n)}{\sum_{c=1, \dots, M_c} e_{j,c} \alpha_{j,v_i^j,c} \cdot f(T_i^j|C_i^j = c)}, \quad (27)$$

其中 n 是数据块 T_i^j 的类别, M_c 是待分割图像的纹理类数.

步骤 3: M 步骤. 计算 P_{I+1} :

$$e_{i,n} = \frac{1}{2^{2j}} \sum_i p(C_i^j = n|V_i^j, T_i^j), \alpha_{j,\overline{v_m},n} = \frac{1}{2^{2j} \cdot e_{j,n}} \sum_{i \text{ with } V_i^j = \overline{V_m}} p(C_i^j = n|V_i^j, T_i^j). \quad (28)$$

步骤 4: 如果收敛, 则停止, 否则, 设置 $I = I + 1$, 转向步骤 2.

最后通过最大化 $p(C_i^j = n|V_i^j, T_i^j)$ 实现基于背景的 Bayes 分类, 确定每一数据块的类标, 从而完成多尺度初始分割的上下文关系融合.

5 实验结果及分析

我们分别对文献 [9,13]、原始的 Contourlet HMT 模型以及本文提出的带方向概率的 Contourlet HMT 模型依据上述算法进行了无监督融合上下文关系的纹理图像分割. 实验中先选取了 4 种不同方

图 4 合成纹理图像的 Contourlet HMT 和带方向概率的 Contourlet HMT 分割结果

Figure 4 Segmentation results comparison of synthesized texture images between Contourlet HMT model and our proposed CHMT model

图 5 合成纹理图像的 Contourlet HMT、文献算法和带方向概率的 Contourlet HMT 分割结果

Figure 5 Segmentation results comparison among Contourlet HMT model, the models in [9] and [13], and our proposed CHMT model

向边界的合成纹理图像和一幅二纹理遥感影像图, 模型采用结合上下文信息的非监督 HMT 分割算法, 并且选用相同的融合迭代次数获得如图 4, 5 所示的分割结果.

表 5 分割结果的错分概率统计

Table 5 Error probability comparison of segmentation results

Error probability	The first type of texture	The second type of texture	Average error probability
Figure 4(a)	CHMT	0.0593	0.3224
	Proposed CHMT	0.0978	0.1039
Figure 4(b)	CHMT	0.0143	0.4106
	Proposed CHMT	0.0118	0.0510
Figure 4(c)	CHMT	0.3071	0.0009
	Proposed CHMT	0.1006	0.0305
Figure 5(a)	Model in [9]	0.0693	0.0002
	CHMT	0.0104	0.0093
	Proposed CHMT	0.0190	0.0059
Figure 5(b)	Model in [13]	0.0173	0.0485
	CHMT	0.0008	0.0409
	Proposed CHMT	0.0055	0.0374

进一步,以“错分概率”,即错分像素的点数总和与类内像素总数的比值(此值越小说明错分越少,分割的效果越好)作为客观评价标准,以此对图 4,5 中五幅图像(按行由上至下的顺序分别标记为图 4(a)~(c),图 5(a)和(b))应用相关文献的方法、Contourlet HMT 模型和带方向概率的 Contourlet HMT 模型分割结果的错分概率进行了统计和对比,结果参见表 5。

从表 5 可以看出前三幅图像中新模型的错分概率要明显小于 CHMT 模型,且从视觉上也不难发现,不论是纹理内部还是纹理边缘,分割效果都优于 CHMT 模型,这说明在训练 CHMT 模型和方向新模型过程中数据逐步收敛到接近理想值状态,之后利用该方向信息指导 CHMT 进行分类,并经过多尺度融合得到纹理区域内部一致性增强、边缘连贯性有效提高的分割结果。此外又分别与一幅合成纹理图像和二纹理遥感图像进行了比较,从视觉效果来看不管在边缘还是区域上,带方向的 CHMT 模型都获得了良好的分割结果,因为在 Contourlet 比小波更能刻画纹理方向趋势的基础之上,从各个尺度上渗透方向分布信息,再加上尺度间父子子带之间的信息融合,将细节信息补充进来,进而优化了纹理的分类。从错分概率上看,尽管 CHMT 略微小一点,但是会产生不固定的孤立点,影响区域的一致性,甚至边缘的光滑程度,而本文模型的错分概率比其他方法要小且与 CHMT 相比误差也很小,能很好地权衡跳跃信号和平稳信号的出现。

此外,为了进一步考察所提出的模型应用于实际图像分割的情况,我们对一系列遥感和 SAR 图像进行实验,并与文献 [8,9,13]、CHMT 模型分别进行了对比,所得到的分割结果参见图 6~8。其中,五幅遥感图像分别来自美国圣地亚哥地区的航拍遥感图像, L 波段 HH 极化机载 SAR 图像, Ku 波段的机载 SAR 图像, L 波段的机载 SAR 图像和百度百科的某港湾的遥感图像。

从图 6~8 不难看出, CHMT 模型算法过于强调边缘,从而令较细的点容易孤立。文献 [8] 算法在细节上演绎的较为突出,但是在某一类区域中出现的次要的颗粒状奇异点不能被很好地抑制,而带方向的 Contourlet HMT 模型可优化分割效果的边缘和区域之间的关系。文献 [9] 中的分割方法虽能有效去除颗粒状奇异点,将连续区域聚类到一起,可难免会带来不期的略粗的边缘效果,而带方向的 CHMT 模型能够利用隐方向的分布很好地体现了 Contourlet 较强的方向性,从而抑制了边缘的锯齿现象,使边缘更加精细且保持良好的区域一致性。

图 6 遥感图像的 Contourlet HMT、带方向概率的 Contourlet HMT 以及文献 [8] 算法的分割结果

Figure 6 Segmentation results comparison. (a) Original image; (b) the model in [8]; (c) contourlet HMT; (d) our proposed CHMT

图 7 遥感图像的 Contourlet HMT、带方向概率的 Contourlet HMT 以及文献 [9] 算法的分割结果

Figure 7 Segmentation results comparison. (a) Original image; (b) the model in [9]; (c) contourlet HMT; (d) our proposed CHMT

通过上面对合成纹理和遥感、SAR 图像的实验结果可以看出, 由于增加了隐方向这一特征, 使得基于带方向的 Contourlet HMT 模型的图像分割算法对纹理特性的捕捉更加精确, 图像中一些必要的细节信息得以保留, 同时使目标的分割轮廓更加清晰; 此外, 在尽可能地分割出目标实体的同时, 可很好的剔除多余的背景信息, 有效地克服了传统模型将目标区域膨胀化和目标分割的边缘模糊等现象.

图 8 遥感图像的 Contourlet HMT、带方向概率的 Contourlet HMT 以及文献 [13] 算法的分割结果

Figure 8 Segmentation results comparison. (a) Original image; (b) the model in [13]; (c) contourlet HMT; (d) our proposed CHMT

6 结论

本文结合 Tamura 方向特征的求取方法, 对 Contourlet 变换系数的方向概率分布进行了分析, 获得了 Contourlet 子带系数的方向特征在 Contourlet 变换的父子子带间进行传递这一结论, 在此基础上结合 Contourlet HMT 模型, 建立了以隐状态变量分布为条件的方向隐变量的带方向特征的 Contourlet HMT 模型. 此外, 提出了一种基于所提出模型的无监督结合上下文信息的图像分割算法, 并通过对大量合成图像和遥感图像的目标分割实验, 表明所提出的算法在对图像纹理特性的捕捉、目标轮廓的分割和对背景信息的处理等方面更加有效.

致谢 感谢中国科学院遥感应用研究所彭玲老师所提供的帮助.

参考文献

- 1 Crouse M S, Nowak R D, Baraniuk R G. Wavelet-based statistical signal processing using hidden Markov models. *IEEE Trans Signal Process*, 1998, 46: 886–902
- 2 Do M N, Vetterli M. Contourlets: a new directional multiresolution image representation. *Signal Syst Comput*, 2002, 1: 497–501
- 3 Jiao L C, Hou B, Xu J. Image segmentation using Contourlet domain hidden Markov model based on parametric initialization. *SciencePaper Online*, 2009. 1–8[焦李成, 侯彪, 徐婧. 基于参数初始化 Contourlet HMT 模型的图像分割. 中国科技论文在线, 2009. 1–8]
- 4 Fan G L, Xia X G. A joint multi-context and multi-scale approach to Bayesian image segmentation. *IEEE Trans Geosci Remote Sens*, 2001, 39: 2680–2688
- 5 Chen G Z, Liu X Z. Contourlet-based despeckling for SAR image using hidden Markov tree and Gaussian Markov models. In: 1st Asian and Pacific Conference on Synthetic Aperture Radar (APSAR 2007). Huangshan, 2007. 784–787
- 6 Long Z L, Nicolas H Y. Statistical image modeling in the Contourlet domain using contextual hidden Markov models. *Signal Process*, 2009, 89: 946–951
- 7 Gopalan C, Manjula D. Contourlet based approach for text identification and extraction from heterogeneous textual images. *Int J Comput Sci Eng*, 2008, 2: 202–211
- 8 Xin F F, Jiao L C, Wan H L. Unsupervised image segmentation based on nonsubsampling Contourlet hidden Markov trees model. In: 2nd Asian-Pacific Conference on Synthetic Aperture Radar (APSAR 2009), Xi'an, 2009. 485–488

- 9 Wu Y, Li M, Zong H T, et al. Fusion segmentation algorithm for SAR images based on HMT in Contourlet domain and D-S theory of evidence. In: The 4th IEEE Conference on Industrial Electronics and Applications (ICIEA 2009). LNCS, 5593. Berlin: Springer-Verlag, 2009. 937–951
- 10 Wu Y, Xiao P, Zong H T, et al. Fusion segmentation algorithm for SAR images based on the persistence and clustering in the Contourlet domain. In: 2009 International Conference on Artificial Intelligence and Computational Intelligence, Shanghai, 2009. 402–406
- 11 Po D D Y, Do M N. Directional multiscale modeling of images using the contourlet transform. In: IEEE Workshop on Statistical Signal Processing, St. Louis, 2003. 262–265
- 12 Tamura H, Mori S, Yamawaki T. Texture features corresponding to visual perception. IEEE Trans Syst Man Cybern, 1978, 8: 460–473
- 13 Peng L. Research on texture classification in remote sensing image with wavelet-based hidden Markov tree models. Doctoral Dissertation. Beijing: Institute of Chinese Academy of Sciences, 2005[彭玲. 基于小波域隐 Markov 树模型的遥感图像纹理分类研究. 博士论文. 北京: 中国科学院研究生院, 2005]
- 14 Ye Z, Lu C C. Wavelet-based unsupervised SAR image segmentation using hidden Markov tree models. In: Proceedings of the 16th International Conference on Pattern Recognition(ICPR'02), Quebec, 2002. 729–732
- 15 Choi H, Baraniuk R G. Multiscale image segmentation using wavelet-domain hidden Markov models. IEEE Trans Image Process, 2001, 10: 1309–1321

Contourlet HMT model with directional feature

WANG XiangHai^{1,2,3*}, CHEN MingYing¹, SONG ChuanMing^{1,2}, XU MengChun¹ & FANG LingLing³

1 College of Computer and Information Technology, Liaoning Normal University, Dalian 116029, China;

2 State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210093, China;

3 Provincial Key Laboratory for Computer Information Processing Technology, Soochow University, Suzhou 215006, China

*E-mail: xhwang@lnnu.edu.cn

Abstract According to Shannon's information theory, the directional feature of texture is defined as the value of directional variable when an image signal attains a singularity of random distribution. In terms of this definition, we calculate the texture's directional features using Tamura's method and study the directional probability distribution of Contourlet coefficients. Then we find that the directional features tend to be conveyed across parent and child subbands. Based on this conclusion, we establish a novel probability distribution model of hidden direction variables under the condition of hidden state variable's distribution, named Contourlet HMT model with directional feature. The structure and training method of the model are presented as well. Moreover, an unsupervised context-based image segmentation algorithm is proposed on the basis of the proposed model. Its effectiveness is verified via extensive experiments carried out on several synthesized images and remote sensing images.

Keywords directional feature, Contourlet HMT, Contourlet HMT with directional feature, unsupervised texture segmentation, hidden state variable's distribution

WANG XiangHai was born in 1965. He received the Ph.D. degree in computational mathematics from Jilin University, Changchun, in 1999. Currently, he is a distinguished Professor at the College of Computer and Information Technology, Liaoning Normal University. His research interests include multimedia information processing and computer graphics. Prof. Wang is a senior member of China Computer Federation (CCF), as well as members of CCF Technical Committee of Multimedia Technology and Technical Committee of Information Storage Technology, and Fellow of Liaoning Province Graphics Society.

CHEN MingYing was born in 1985. She received the master's degree in Computer College of Information and Technology from the Liaoning Normal University, Dalian, in 2011. Currently, she is an assistant lecturer at Guangdong Vocational School of Electronic Technology. Her research interests include image information processing.

SONG ChuanMing was born in 1980. He received the Ph.D. degree in computer applied technology from the Nanjing University, Nanjing, in 2010. Currently, he is a Lecturer at the College of Computer and Information Technology, Liaoning Normal University. His research interests include image and video coding, and digital watermarking of multimedia. Dr. Song is a member of China Computer Federation (CCF), as well as Academic Secretary of CCF Young Computer Scientists & Engineers Forum Dalian (YOCSEF Dalian).

XU MengChun was born in 1984. She received the master's degree in Computer College of Information and Technology from the Liaoning Normal University, Dalian, in 2010. Her research interests include image retrieval and recognition.