

文章编号:1001-9014(2011)01-0091-06

基于小波域 TS-MRF 模型的监督图像分割方法

刘国英^{1,2}, 王爱民¹, 陈荣元², 秦前清²

(1. 安阳师范学院 计算机与信息工程学院,河南 安阳 455002;
2. 武汉大学 测绘遥感信息工程国家重点实验室,湖北 武汉 430079)

摘要: 定义在单一空间分辨率上的树结构马尔可夫场(Tree-Structured Markov Random Field, TS-MRF)模型能够表达图像的分层结构信息,但难以描述图像的非平稳性。针对该问题,提出小波域的 TS-MRF 图像建模方法—WTS-MRF 模型。按照图像分类层次树的结构形式,该模型将一系列的 MRF 嵌套定义在多分辨率的小波域中:每一个树节点对应于定义在不同分辨率上的一个 MRF 集合,并通过条件概率的形式将相邻分辨率上的 MRF 间的作用关系考虑进来;同时相同分辨率的父子节点对应的 MRF 通过区域约束嵌套定义。基于 WTS-MRF 模型,给出了一个监督图像分割的递归算法,通过给定的分类层次树表示先验信息,并通过训练数据给出叶子节点在各分辨率上的统计参数。它在尺度内和尺度间两个层次上进行递归:首先,在最低分辨率上执行尺度内递归,即采用 ICM 算法从树的根节点到叶子节点依次对 MRF 进行递归估计;然后执行尺度间递归,即在相邻的更高分辨率尺度上,通过直接投影的方式依次获取每一 MRF 的初始估计,并采用 ICM 算法递归优化;最后,原始分辨率的 MRF 估计完成,获取最终分割结果。两组实验从视觉效果和定量指标(整体分类正确率和 Kappa 系数)两个方面验证了算法的有效性。

关 键 词: 小波变换; 图像分割; 树结构马尔可夫场; 小波域树结构马尔可夫场

中图分类号: TP391 **文献标识码:** A

Supervised image segmentation method based on tree-structured Markov random field in wavelet domain

LIU Guo-Ying^{1,2}, WANG Ai-Min¹, CHEN Rong-Yuan², QIN Qian-Qing²

(1. School of Computer and Information Engineering, Anyang Normal University, Anyang 455002, China;
2. State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing,
Wuhan University, Wuhan 430079, China)

Abstract: The tree-structured Markov Random Field (TS-MRF) model defined on a single spatial resolution, which is capable of expressing the hierarchical structure implied in the image to be segmented, fails to describe its non-stationary property. In order to solve this problem, a new image modeling method in Wavelet domain—WTS-MRF was proposed. In this model, a sequence of MRFs were hierarchically defined in the format of the classification tree structure. Each node was associated with a set of MRFs defined on different resolutions, wherein the correlation between neighbor MRFs with different resolutions was considered in the form of conditional probability. The child MRF was nested in the region of the parent one on the same resolution. Based on the WTS-MRF model, a supervised recursive segmentation algorithm was proposed. The classification hierarchical tree was manually set as the priori information, and the corresponding statistics for each leaf node were obtained by the training data on each resolution. The implementation of this algorithm was both on the inner-scale and inter-scale level. The inner-scale recursion was executed on the lowest resolution, where the MRF corresponding to each node was sequentially and recursively estimated by the ICM algorithm from the root to leaves. The inter-scale recursion was implemented on the next finer resolution, in which the estimation of MRFs was sequentially initialized by the direct projection from the next lower resolution and recursively refined by the ICM algorithm. The final segmentation was obtained when the MRFs were estimated on the primary resolution. Two experiments verify the validity of the proposed method in terms of both visual quality and quantitative indicators (e.g. overall accuracy and Kappa coefficient).

Key words: wavelet transform; image segmentation; tree-structured Markov Random Field (TS-MRF); tree-structured Markov Random Field in wavelet domain (WTS-MRF)

PACS: 45.05. + x

收稿日期:2010-03-21,修回日期:2010-12-18

Received date: 2010-03-21, revised date: 2010-12-18

基金项目:国家973项目(2006CB701303);国家自然科学基金项目(41001251,40971219);测绘国家重点实验室开放研究基金(遥感数据高性能处理的理论与方法研究);遥感软件体系架构及标准规范研究(904170803);湖南省自然科学基金资助项目(10jj2050)

作者简介:刘国英(1979-),男,河南郑州人,博士,主要从事遥感图像多尺度分析与识别的研究,E-mail:lgydatabase@163.com.

引言

数字图像尤其是遥感图像体现出很强的层次特征,如何在图像的分类过程中充分利用这种关系一直是研究的一个热点问题。树结构化的马尔可夫场(Tree-Structured Markov Random Field, TS-MRF)模型^[1~4]能够在一定程度上解决这个问题。它采用一个树结构约束的二值马尔可夫随机场序列来建模数字图像,通过节点之间的相互关系来表达图像本身的分层结构信息。由于每一个节点对应的MRF的相关参数都是通过局部的信息进行估计的,TS-MRF具有一定的描述图像局部信息的能力。

然而,在TS-MRF模型中,所有随机场均定义在单一分辨率的格网位置集合上,很难描述图像的非稳态特性。另外,基于TS-MRF模型进行图像分割时,当前节点的分割结果对于它的祖先节点的分割结果依赖性非常严重,如果祖先节点的分割结果不好,它的分割结果也会较差。祖先节点分割结果的好坏主要取决于有关特征和参数是否能够准确表达其统计特性,所以,提高模型的表达能力就成为改善分割结果的关键所在。

基于此,本文采用小波域多尺度图像分割^[5~7]的思想,将TS-MRF引入到小波空间中,利用小波变换的多尺度、多方向表达能力^[8,9]来弥补TS-MRF建模能力上的不足,提出了小波域TS-MRF模型——WTS-MRF,并基于该模型提出了相应的监督分割算法。

1 WTS-MRF 模型及图像建模

假设不同尺度上的小波系数具有相同的分类层次结构,并采用图1所示的分类层次树进行描述。在WTS-MRF模型中包含两个层次结构的嵌套:分类层次树和小波系数的四叉树,分别记为T和WT。假设数字图像 $Y=y$ 进行 $J-1$ 次小波变换,每一级小波变换包含四个频带: $LL(n), LH(n), HL(n), HH(n)$ 。每一个频带同一位置的小波系数可以构成一个四维向量,从而形成该尺度上的特征向量图像 $w^{(n)}$ ($1 \leq n \leq J-1$)。如果假设 $w^{(0)}=y$,则多尺度观测图像可记为 $w=\{w^{(n)} | 0 \leq n \leq J-1\}$,其中 $w^{(0)}$ 表示原始图像, $w^{(J-1)}$ 表示进行 $J-1$ 次小波分解获得的小波系数向量图像。假设尺度 n 上的格网位置集合表示为 $S^{(n)}$,则所有尺度的格网位置集合可以表示为 $S=\{S^{(n)} | 0 \leq n \leq J-1\}$ 。因为一个低分辨率的格网位置对应四个相邻的高分辨率格网位置,由此便形成了小波系数向量的四叉树结构。

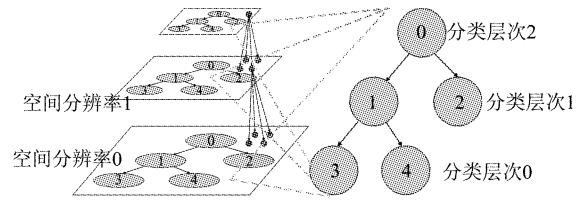


图1 WTS-MRF 模型示意图
Fig. 1 The analogy of the WTS-MRF model

在WTS-MRF模型中,每一尺度上的分类层次树T是相同的。如图1所示,每一尺度的分层信息都采用图中右侧所示的分类层次树结构,它共包含三个层次的分类信息。在T中每一个节点 t 用对应的节点序号来表示,根节点的序号为0,其它节点按照树的深度从左到右依次计数来表示。每一个非根节点都只有一个父节点 $u(t)$,每一非叶子节点的子节点集合记为 $c(t)=\{t' | u(t')=t\}$ 。如果记叶子节点的集合为 $T=\{T | T \in T, c(t)=\phi\}$,则中间节点集合可以记为 $\bar{T}=T-T$ 。在尺度 n ($0 \leq n \leq J-1$)上,T的节点 t 与如下的内容相关联:

- i. 尺度 n 上格网集合 $S^{(n)}$ 的一个子集 $S^{n,t}: S^{n,t} \subseteq S^{(n)}$,尺度 n 上与T的根节点对应的格网位置集合为 $S^{(n,0)}=S^{(n)}$;
- ii. 尺度 n 上的一个马尔可夫随机场 $X^{(n,t)}: X^{(n,t)}=\{X_s^{(n,t)}: s \in S^{n,t}\}$,对应的邻域系统记为 $\eta^{(n,t)}$,其中 $x_s^{(n,t)} \in c(t)$;
- iii. 一组定义随机场 $X^{n,t}$ 所需要的参数集合 $\theta^{(n,t)}$:如果用Gibbs分布来表示,则 $\theta^{n,t}$ 主要是指表示 $X^{(n,t)}$ 所需的势函数 $V_c^{(n,t)}(\cdot)$ 的取值。

基于上述的定义,分类层次树T中的节点 t 对应于如下内容: J 个格网位置集合 $\{S^{(n,t)} | 0 \leq n \leq J-1\}$; J 个马尔可夫随机场 $\{X^{n,t} | 0 \leq n \leq J-1\}$; J 个分辨率上的参数集合 $\{\theta^{n,t} | 0 \leq n \leq J-1\}$ 。使用不同分辨率上的小波系数向量特征和不同大小的邻域约束,WTS-MRF能够描述分类层次树中节点对应的MRF的非稳态性,从而更好地建模图像。

WTS-MRF模型对每一尺度的随机场进行了如下约束: $S^{(n,t)} \subseteq S^{(n,u(t))}$,即节点 t 对应的MRF必须定义在它的父节点 $u(t)$ 对应的格网位置集合内。在这个约束条件下,尺度 n 上T的内部节点 $t \in \bar{T}$,必须满足如下:

$$S^{(n,t')} = \{s | s \in S^{(n,t)}, x_s^{(n,t)} = t', 0 \leq n \leq J-1\}, \quad (1)$$

其中 $t' \in c(t)$ 表示 t 的一个孩子节点。因此,与分类层次树T对应的WTS-MRF模型 X^{WT} 可以表示:

$$X^{WT} = \bigcup_{0 \leq n \leq J-1} \bigcup_{t \in \bar{T}} X^{(n,t)}, \quad (2)$$

它的一个现实为 $x^{WT} = \bigcup_{0 \leq n \leq J-1} \bigcup_{t \in T} U_x^{(n,t)}$ 的联合分布为:

$$\begin{aligned} p(x^{WT}) &= p(x^{(n,t)} | n \in \{0, 1, \dots, J-1\}; t \in \bar{T}) \\ &= \underbrace{p(x^{(J-1,0)})}_{\text{root node of } T} \prod_{0 \leq n \leq J-2} p(x^{(n,0)} | x^{(n-1,0)}) \underbrace{\prod_{t \in T \text{ 且 } t \neq 0} p(x^{(J-1,t)} | x^{(J-1,u(t))})}_{\text{other nodes in } \bar{T}} \prod_{0 \leq n \leq J-2} \prod_{t \in T \text{ 且 } t \neq 0} p(x^{(n,t)} | x^{(n-1,t)}, x^{(n,u(t))}) \quad , \quad (3) \end{aligned}$$

上式考虑了两种约束:区域约束和分辨率约束。区域约束是指同一分辨率上父子节点对应 MRF 之间的约束,即 $x^{(n,u(t))} \rightarrow x^{(n,t)}$;分辨率约束是指相邻分尺度上对应同一节点的两个 MRF 的交互关系,即当前尺度上的 MRF 将会受到来自相邻的上一尺度上对应的 MRF 的约束,即 $x^{(n-1,t)} \rightarrow x^{(n,t)}$ 。在公式中通过三个条件概率的来表示这两种约束: $p(x^{(n,0)} | x^{(n-1,0)})$ 、 $p(x^{(J,t)} | x^{(J,u(t))})$ 和 $p(x^{(n,t)} | x^{(n-1,t)}, x^{(n,u(t))})$,它们均为相应 MRF 的联合分布。 $p(x^{(n,0)} | x^{(n-1,0)})$ 可以通过将尺度 $(n-1)$ 可以通过将尺度 $(n-1)$ 上节点 0 对应的 MRF 直接投影到尺度 (n) 上来近似; $p(x^{(J,t)} | x^{(J,u(t))})$ 限定 $x^{(J,t)}$ 必须定义在 $S^{(J,u(t))}$ 内;而 $p(x^{(n,t)} | x^{(n-1,t)}, x^{(n,u(t))})$ 通过将 $x^{(n-1,t)}$ 投影到 $S^{(n,u(t))}$ 上并作为 $x^{(n,t)}$ 的初始值来近似求值。

分层分类树的每一节点在每一分辨率上对应的

$$p(w^{(n)}, x^{(n)}) = \begin{cases} f(w^{(n,0)} | x^{(n,0)}) p(x^{(n,0)}) \times \\ \prod_{t \in T} f(w^{(n,t)} | x^{(n,t)}) p(x^{(n,t)} | x^{(n,u(t))}), & n = J-1 \\ f(w^{(n,0)} | x^{(n,0)}) p(x^{(n,0)} | x^{(n-1,0)}) \times \\ \prod_{t \in T} f(w^{(n,t)} | x^{(n,t)}) p(x^{(n,t)} | x^{(n,u(t))}, x^{(n-1,t)}), & n \neq J-1 \end{cases} \quad (7)$$

式中, $f(w^{(n,t)} | x^{(n,t)})$ 表示相应的概率密度函数。

2 基于 WTS-MRF 模型的图像分割和参数估计

通过极大化多分辨率观测场 w 和 X^{WT} 的联合分布可以估计各尺度上的分割结果:

$$\hat{x}^{WT} = \arg \max_{x^{WT}} p(w, x^{WT}) \quad , \quad (8)$$

这相当于对式(6)中的每一项都取最大化,即

$$\hat{x}^{(n,t)} = \arg \max_{x^{(n,t)}} f(w^{(n,t)} | x^{(n,t)}) p(x^{(n,t)} | \cdot) \quad , \quad (9)$$

当 $n = J-1$ 时,“ \cdot ”表示 $0 \leq n < J-1$;当 $0 \leq n < J-1$ 时,“ \cdot ”表示 $x^{(n,u(t))}$ 和 $x^{(n-1,t)}$ 。

在满足分辨率约束和区域约束的条件下,如果给定邻域系统 $\eta^{(n,t)}$ 和参数集合 $\theta_s^{(n,t)}$,则可以采用 Potts 模型表示 $x^{(n,t)}$ 的概率分布,

$$\begin{aligned} P(x_s^{(n,t)} | \eta^{(n,t)}, \theta_s^{(n,t)}) \\ = \frac{\exp(-\beta_s^{(n,t)} \times n(x_s^{(n,t)}))}{\sum_{x_s^{(n,t)} \in c(u(t))} \exp(-\beta_s^{(n,t)} \times n(x_s^{(n,t)}))} \quad , \quad (10) \end{aligned}$$

MRF 均可以采用 Gibbs 分布来表示,即上述的三个条件概率均可以表示为 Gibbs 分布的形式,

$$p(x^{(n,t)} | \cdot) = \frac{1}{z(x^{(n,t)})} \exp\left(-\frac{1}{T} U(x^{(n,t)})\right) \quad , \quad (4)$$

其中, $z(x^{(n,t)}) = \sum_{x^{(n,t)}} \exp(-U(x^{(n,t)})/T)$ 为拆分函数; $U(\cdot)$ 为能量函数,

$$U(x^{(n,t)}) = \sum_{c \in C} V_c(x^{(n,t)}) \quad , \quad (5)$$

C 为定义在邻域系统 $\eta^{(n,t)}$ 上的基团的集合,(\cdot)为基团 c 的能量。

x^{WT} 与各个分辨率的观测值 w 的联合分布可以表示为:

$$p(w, x^{WT}) = \prod_{1 \leq n \leq J} p(w^{(n)}, x^{(n)}) \quad , \quad (6)$$

其中,

$$\begin{aligned} &n = J-1 \\ &\text{其中 } n(x_s^{(n,t)}) \text{ 表示在 } s \in S^{n,t} \text{ 的邻域 } \eta_s^{(n,t)} \text{ 中与具有} \\ &\text{标记 } x_s^{(n,t)} \text{ 的标记个数, } \beta^{(n,t)} \text{ 为双点势函数.} \end{aligned} \quad (7)$$

如果假设每一尺度的观测值满足类条件独立假设,则 $f(w^{(n,t)} | x^{(n,t)}) = \prod_{s \in S^{(n,t)}} f(w_s^{(n,t)} | x_s^{(n,t)})$, 其中 $x_s^{(n,t)} \in c(u(t))$. $f(w_s^{(n,t)} | x_s^{(n,t)})$ 表示对应的后验概率密度函数,

$$f(w_s^{(n,t)} | x_s^{(n,t)}) = \max_{l \in \gamma(x_s^{(n,t)})} \{f(w_s^{(n)} | x_s^{(n,t)} = l)\} \quad , \quad (11)$$

其中 $\gamma(t)$ 表示节点 t 对应的叶子节点的集合, $f(w_s^{(n)} | x_s^{(n,t)} = l)$ 用高斯概率密度函数来表示。

公式(8)的最大化可以通过从低分辨率尺度到高分辨率尺度的递归(尺度间递归)来实现,在每一尺度上的分割也是一个沿着分类层次树从顶层向底层的递归(尺度内递归)过程:

(1) 令 $n = J-1$, 执行如下操作:

(1.1) 初始化:令 $t = 0, \beta^{(n,0)} = 0$, 通过下式计算 $x^{n,0}$:

$$\begin{aligned} &(\hat{x}^{(n,0)}, \hat{\beta}^{(n,0)}) \\ &= \arg \max_{(x^{(n,0)}, \beta^{(n,0)})} f(w^{(n,0)} | x^{(n,0)}) p(x^{(n,0)} | \beta^{(n,0)}) \quad , \quad (12) \end{aligned}$$

(1.2) 令 $t = t + 1$, 判断 \bar{T} 中的所有节点在当前尺度上是否遍历完毕; 如果完毕, 则步骤(1)运算结束, 执行步骤(2); 否则, 转步骤(1.3);

(1.3) 通过下面的式子计算 $x^{(n,t)}$ 和 $\beta^{(n,t)}$, 并转步骤(1.2):

$$\begin{aligned} & (\hat{x}^{(n,t)}, \hat{\beta}^{(n,t)}) \\ &= \arg \max_{(x^{(n,t)}, \beta^{(n,t)})} f(w^{(n,t)} | x^{(n,t)}) p(x^{(n,t)} | \beta^{(n,t)}) \end{aligned} \quad (13)$$

(2) 令 $n = n - 1$, 判断 $n < 1$ 是否成立, 如果不成立, 则转步骤(3); 否则结束.

(3) 执行如下操作:

$$(\hat{x}^{(n,t)}, \hat{\beta}^{(n,t)}) = \arg \max_{(x^{(n,t)}, \beta^{(n,t)})} f(w^{(n,t)} | x^{(n,t)}) p(x^{(n,t)} | x^{(n,u(t)}), x^{(n-1,t)}, \beta^{(n,t)}) \quad (15)$$

并转步骤(3.2).

通过上述步骤可以实现图像分割和参数估计. 在计算 $x^{n,t}$ 和 $\beta^{n,t}$ 时可以采用 Poggi 等的优化策略^[3]. 在分类的过程中有可能会出现不同分辨率之间的分类冲突, 即并非当前参与迭代的所有像素位置均能获取一个合适的初始分类. 此时, 该算法主要依赖已经获取初始分类结果的像素获取初始的类别参数, 然后再根据观测数据的似然及其邻域关系获取初始结果, 从而使迭代可以较好地执行.

3 实验与分析

分别使用合成图像和遥感图像进行分割实验. 采用四种实验方案进行对比实验:(1) 极大似然分类; (2) ICM 算法分割; (3) 基于 TS-MRF 的图像分割^[3]; (4) 基于 WTS-MRF 的图像分割. 两个实验均采用“haar”小波变换, 进行两层分解. 采用分类正确率和 kappa 系数两个指标来衡量分类结果的好坏.

实验一: 合成图像分割

合成噪声图像如图 2(a) 所示, 大小为 128×128 . 根据目视判别图中主要包含 4 个类别, 并定义层次树如图 2(b) 所示, 手工选定训练样本及真实分割结果分别如图 2(c) 和图 2(d) 所示. 因为这是一幅噪声污染的合成图像, 训练样本的个数不能太少, 太少了的样本统计出的类别参数不能反映该类别的特点. 四个类别选取的样本个数分别为 212、217、315 和 502. 分割结果如图 3 所示, 对应的分类指标如表 1 所示.

ML 算法只采用像素的灰度值进行分类, 并没有考虑像素之间的空间相邻关系, 各个类别之间的混分都非常严重, 分割效果最差, 分类正确率不到 63%, Kappa 系数只有 56%. ICM 算法通过 MRF 模

(3.1) 初始化: 令 $t = 0$, $\beta^{(n,0)} = \beta^{(n-1,0)}$, 通过下式计算 $x^{(n,0)}$ 和 $\beta^{(n,0)}$:

$$\begin{aligned} & (\hat{x}^{(n,0)}, \hat{\beta}^{(n,0)}) \\ &= \arg \max_{(x^{(n,0)}, \beta^{(n,0)})} f(w^{(n,0)} | x^{(n,0)}) p(x^{(n,0)} | x^{(n-1,0)}, \beta^{(n,0)}) \end{aligned} \quad (14)$$

(3.2) 令 $t = t + 1$, 判断当前分辨率上 \bar{T} 中的所有节点是否遍历完毕. 如果遍历完毕, 则步骤(3)执行完毕, 转步骤(2)继续执行; 否则, 转步骤(3.3), 继续进行;

(3.3) 通过下面的式子计算 $x^{n,t}$ 和 $\beta^{(n,t)}$:

$$(x^{(n,t)}, \beta^{(n,t)}) = \arg \max_{(x^{(n,t)}, \beta^{(n,t)})} f(w^{(n,t)} | x^{(n,t)}) p(x^{(n,t)} | x^{(n,u(t)}), x^{(n-1,t)}, \beta^{(n,t)}) \quad (15)$$

型将邻域的约束关系引入到了图像的分类过程中来, 将分类正确率提高到了 97.26%, Kappa 系数也提高到了 96.14%. 然而由于 ICM 算法不能反映图像的局部特点, 而且单一尺度上的像素灰度值也不能描述图像非稳态特性, 这导致分割结果不很理想, 尤其是边界位置的偏离较大. TS-MRF 能够在一定程度上反映图像的局部特征, 分类正确率和 Kappa 系数分别提高到了 98.08% 和 97.30%. WTS-MRF 模型将 TS-MRF 定义在小波域中, 可以较好地描述节点对应图像区域的非稳态性质, 从而更好地建模图像, 分类结果具有最好的区域性和边界保持性, 具有最高的分类正确率和 Kappa 系数, 分别为 98.47% 和 97.84%.

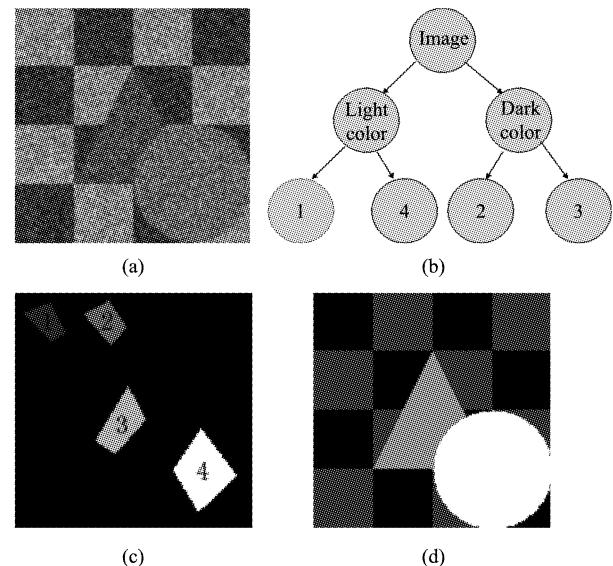


图 2 实验一数据: (a) 合成图像 (b) 手工设定的分类层次树 (c) 训练数据 (d) 真实分割结果

Fig. 2 the data for experiment 1 (a) a synthetic noisy image (b) the classification hierarchical tree manually set (c) the training data (d) the real segmentation result

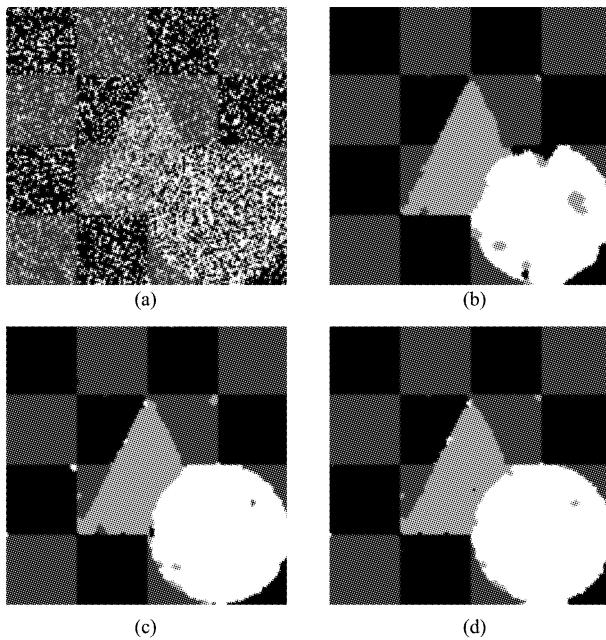


图3 实验一分割结果:(a)ML 算法 (b)ICM 算法 (c)TS-MRF 算法 (d)WTS-MRF 算法

Fig. 3 Segmentation results for experiment 1: (a) ML algorithm (b) ICM algorithm (c) TS-MRF-based algorithm (d) WTS-MRF-based algorithm

表1 合成图像分割性能比较

Table 1 The comparison between segmentation results of the synthetic image

	ML	ICM	TS-MRF	WTS-MRF
分类正确率	0.6282	0.9726	0.9808	0.9847
Kappa 系数	0.5600	0.9614	0.9730	0.9784

实验二:遥感图像分割

为了进一步分析小波域 TS-MRF 建模方法的分类性能,本文采用一幅大小为 2437×1793 的 Quickbird 卫星遥感影像进行了分割实验,图像包含三个可见光的波段数据。从图像中截取如图 4(a)所示的一幅大小为 512×512 区域进行实验。通过目视判别该图像共分为 9 类:水体、谷物、草、灌木、红色屋顶、蓝色屋顶、暗色屋顶、裸地和道路。并根据日常的分类习惯定义如图 4(b)所示的层次树结构,对应的训练数据和测试数据分别如图 5(a)和 5(b)所示。该实验图像较为清晰,少量的训练样本即能反映类别的统计特征。分割结果如图 6 所示,对应的分类指标如表 2 所示。

从图 6(a)可以看出,ML 算法的分割结果非常细碎,存在大量孤立的分类点,分割结果的区域性较差。从图 6(b)可以看出,采用 ICM 算法可以方便地清除孤立的分类噪声点。从图 6(c)可以看出,基于

表2 遥感图像分割性能比较

Table 2 The comparison between the segmentation results of the remote sensing image

	ML	ICM	TS-MRF	WTS-MRF
分类正确率	0.7396	0.7689	0.7846	0.8114
Kappa 系数	0.7174	0.7474	0.7635	0.7908

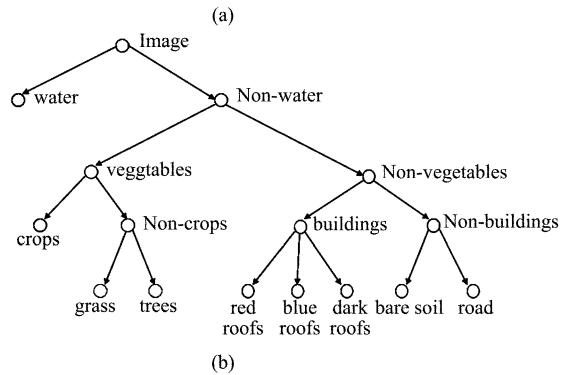
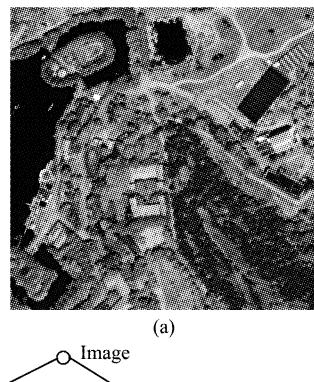


图4 实验二数据 (a)Quikbird 图像(512×512) (b)手工设定的分类层次树

Fig. 4 The data for experiment 2 (a) a Quickbird image(512×512) (b) the classification hierarchical tree manually set

TS-MRF 模型的分割算法能够在保持边界性的同时进一步提高分割结果的区域性。但从图 6(a)~(c) 中对应的分割结果可以看出,灌木、裸地、谷物、灌木、草地等地物之间混分相当严重。这是因为这些地物目标具有较强的纹理特征,它们表现出明显的非平稳性,单一空间分辨率的图像模型难以对其进行合理的表示。基于 WTS-MRF 的分割算法对这几类地物的分类有明显改善,这从图 6(d)可以看出。从表 2 中的定量指标也可以分析得到相同的结论。

与 TS-MRF 相比,本文算法的复杂度的增加主要体现在小波分解及多个尺度的尺度内迭代上。但因为最低分辨率尺度上的数据量相比原始分辨率尺度来说非常小,尺度内的迭代操作可以很快完成,而这个结果又为更高分辨率尺度提供了一个较好的初始结果,从而使得高分辨率尺度上的迭代也能够在较短的时间内达到局部的最优取值。在本文的两个实验中,每一迭代均没有超过 10 次以上,WTS-MRF

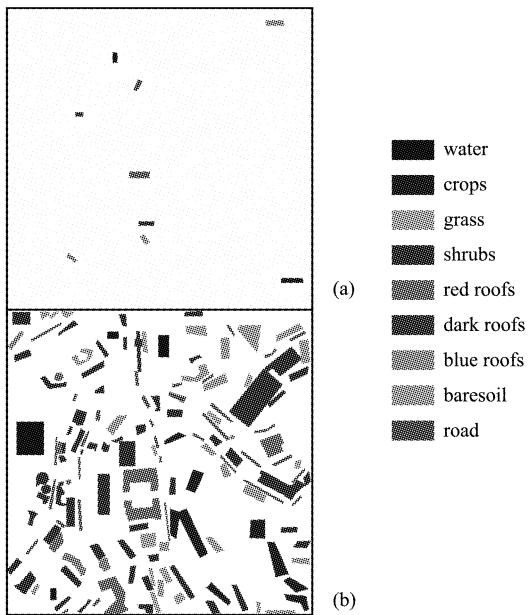


图 5 实验二样本数据: (a)训练数据 (b)测试数据
 Fig. 5 The sample data for experiment 2 (a) the training data
 (b) the test data

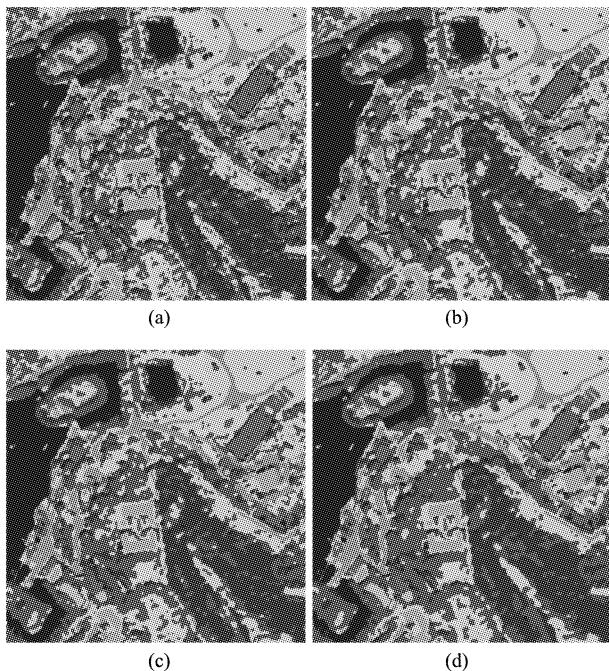


图 6 实验二分割结果: (a) ML 算法 (b) ICM 算法 (c) TS-MRF 算法 (d) WTS-MRF 算法

Fig.6 Segmentation results for experiment 2 (a) ML algorithm
 (b) ICM algorithm ; (c) TS-MRF-based algorithm (d) WTS-MRF-based algorithm

算法和 TS-MRF 算法的运算时间也相当。

4 结论

提出了一个小波域的 TS-MRF 图像建模方法—WTS-MRF，并基于此模型给出了监督方式的图像分割算法。采用合成图像和遥感影像分别进行了分割实验，表明 WTS-MRF 模型能够在表示图像的结构信息的同时较好地建模图像的非稳态性，在一定程度上克服了单一空间分辨率上的 TS-MRF 模型表达图像统计特性能力不足的缺点；它能够结合 TS-MRF 模型描述图像分层结构信息的优势以及小波变换的多分辨率、多方向的表达能力，从多分辨率、多分类层次的角度对图像进行建模。在后续的研究中，我们将继续探索更为精确的模型实现方法，并将之逐步引入到其它的子波域中进一步对图像进行多尺度、多层次的分析。

REFERENCES

- [1] Poggi G, Ragozini R P. Image segmentation by tree-structured Markov random fields [J]. *Signal Processing Letters*, 1999, **6**(7) :155—157.
 - [2] D'Elia C, Poggi G, Scarpa G. A tree-structured Markov random field model for Bayesian image segmentation [J]. *IEEE Transactions on Image Processing*, 2003, **12** (10) : 1259—1273.
 - [3] Poggi G, Scarpa G, Zerubia J B. Supervised segmentation of remote sensing images based on a tree-structured MRF model [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(8) :1901—1911.
 - [4] Poggi G, Scarpa G, Z. J. Segmentation of remote-sensing images by supervised TS-MRF: IEEE International Conference on Image Processing, 2004 [C]. Singapore, 2000 (3) :1867—1870.
 - [5] Krishnamachari S, Chellappa R. Multiresolution Gauss-Markov random field models for texture segmentation [J]. *IEEE Transactions on Image Processing*, 1997, **6**(2) :251—267.
 - [6] LIU Guoying, LUO luncai, TIAN canmei, et al. A Multispectral Textured Image Segmentation Method Based on MRMRF [J]. *Geometrics and Information Science of Wuhan University*(刘国英, 等. 基于 MRMRF 的多光谱纹理影像分割方法. 武汉大学学报(信息科学版)), 2008, **33** (9) : 963—966.
 - [7] Myunghee Jung, Eui-Jung Yun, Kim C S. Multiresolution Approach for Texture Segmentation Using MRF Models: Geoscience and Remote Sensing Symposium, 2005 [C]. Seoul, Korea, 2005 : 3971-3974.
 - [8] Daubechies, I. Ten lectures on wavelets. 1992: SIAM.
 - [9] YNG Fu-Sheng. *The Analysis and Application of Wavelet Transformation on Engineering* [M]. China Science Press (杨福生. 小波变换的工程分析与应用. 1999: 北京: 科学出版社).