

结合产生式模型和 RCC 方法的极化 SAR 图像分类算法

张宇, 何楚, 冯倩, 徐新

(武汉大学 电子信息学院, 430072 武汉)

摘要: 为了充分利用图像中的上下文信息对空间关系进行推理, 提出了一种基于产生式模型和区域连接演算 (Region Connection Calculus, RCC) 的新模型——GM-RCC 模型 (Generative Model based on RCC), 用于合成孔径雷达 (SAR) 图像的分类研究. 首先, 通过建立图像金字塔将一幅 SAR 图像过分割成多尺度的超像素, 然后利用层次 RCC 模型对这些超像素的空间关系进行描述, 其中 RCC 关系的学习和推理都是在产生式模型的框架下进行的. 在模型的推理过程中采用了迭代策略以获得更加精细的分类结果. 实验选用了极化特征及其他典型特征, 并在 SAR 图像集上进行了实验, 实验结果证明了该算法的有效性.

关键词: 图像处理; 合成孔径雷达; 图像分类; 产生式模型; 区域连接算法; 极化特征

中图分类号: TN911.11 **文献标志码:** A **文章编号:** 0367-6234(2013)11-0118-07

An improved algorithm of SAR image classification based on generative model and RCC

ZHANG Yu, HE Chu, FENG Qian, XU Xin

(School of Electronic Information, Wuhan University, Wuhan 430072, China)

Abstract: To take full use of context information to learn the spatial relationship of the image, a novel model based on Generative Model and Region Connection Calculus (RCC) is proposed in this paper. We name it GM-RCC model, which is used for SAR image classification. Firstly, a SAR image is over-segmented into multi-scale super pixels via adopting the image pyramid. Then the hierarchical RCC model is utilized to describe the spatial relationships among these super pixels. All hierarchical RCC relationships are learned and reasoned under the Generative Model reasoning framework. The experiments are carried out on SAR image datasets and polarimetric features are selected with other typical features. The results reveal the efficient performances and superiorities of the proposed algorithm.

Key words: image processing; synthetic aperture radar; image classification; generative model; region connection calculus; polarimetric features

合成孔径雷达 (Synthetic Aperture Radar, SAR) 系统^[1] 由于具有全天候、全天时等独特优势, 在军民两方面应用中发挥着越来越大的作用. 其中, SAR 图像解译是研究的热点, 图像解译的主流方法包括特征描述子和模型两个方面. 目前

使用较为广泛的特征描述子有统计特征, 如 Fisher 分布和 α -stable 分布等^[2-3]; 纹理特征, 如 GLCM、Gabor 和 SIFT 等^[4-6] 以及通过对极化 SAR (PolSAR) 数据和极化干涉 SAR (PolInSAR) 数据提取不同分解参数所获得的极化特征^[7]. 用于图像解译的模型主要有: 描述式模型、判别式模型和产生式模型等 3 类. 产生式模型因为其通用性、灵活性及清晰的分层结构, 学习得到的模型很容易满足模型解释要求等优越特性而获得广泛使用.

近年来, 诸如概率潜在语义分析 (Probabilistic Latent Semantic Analysis, pLSA) 和潜

收稿日期: 2012-10-29.

基金项目: 国家重点基础研究发展计划资助项目 (2013CB733404); 国家自然科学基金资助项目 (41371342, 61331016).

作者简介: 张宇 (1988—), 男, 博士研究生;
徐新 (1967—), 男, 教授, 博士生导师.

通信作者: 何楚, chuhe@whu.edu.cn.

在狄力克雷分布 Latent Dirichlet Allocation(LDA) 等^[8-9]的产生式模型在文本分析和信息检索方面获得了很大的成功. 受此激发, E.B.Sudderth 等^[10]提出了一系列的层次产生式模型, 对目标、组成目标的部分以及目标周围的场景进行建模; 李菲菲等^[11]也提出了一种能够将场景分类、目标分割以及图像标注这 3 大任务在一个统一的框架中实现的层次产生式模型. 然而, 由于产生式模型对目标空间结构描述不够全面, 传统的诸如 MRF(马尔科夫场、Markov Random Field) 模型等的上下文模型也只考虑空间中的邻域先验信息, 因此需要一种能够对空间关系进行全面推理的技术, 并将其嵌入到产生式模型当中, 两者结合用于 SAR 图像的解译. J.Inglada 等^[12]提出一种用于描述遥感图像中复杂目标的空间推理技术, 并将其应用于目标检测. 该方法采用区域连接演算(RCC)对一幅图像中的目标(区域)之间的关系建立一种基于

图的描述. 这种推理方法能够对图像分析中的上下文信息进行充分的利用. 因此本文采用 RCC 模型来进行空间关系的推理并结合从图像中提取的极化特征来进行 SAR 图像的解译.

1 GM-RCC 算法框架

本文所提出的 GM-RCC 模型的算法框架如图 1 所示. 首先, 对一幅原始的 SAR 图像建立图像金字塔, 并对金字塔的每一层进行 MeanShift 过分割, 然后对过分割后的图像提取各个区域之间的 RCC 特征以及各个区域的极化特征, 其中 RCC 特征为模型提供先验信息, 极化特征通过产生式模型提供似然信息, GM-RCC 模型利用这些信息对图像进行初步的分类, 得到第 1 次迭代输出的结果, 最后, 本文采用了一个迭代策略, 每一次实验的结果作为下次实验的输入, 得到了最终的分类结果.

图 1 GM-RCC 模型算法框架

1.1 过分割和特征提取

为了在一幅多尺度 SAR 图像中建立一个层次 RCC 模型, 本文用下采样创建了一个图像的金字塔. 图像金字塔中的每一层都采用 MeanShift 算法过分割为同质区域(超像素), 超像素的最小面积为 400 像素. 每一个超像素可以视为一个不可分割的单位, 在这个单位里所有的像素具有相同的类别. 一个超像素里的所有像素的 PolSAR 和 PolInSAR 特征与这个超像素的特征所起的作用是相同的.

同时, 为了对某一特定类别的散射过程进行

描述, 本文对 PolSAR 数据和 PolInSAR 数据进行了各种不同的目标分解. 极化分解技术将接收到的信号分成 3 个相互独立的散射过程, 并分别赋予不同的权值. 与此同时, 不同的技术将极化信息转换成不同类别的散射机制, 这可以用来描述地面覆盖目标的不同属性.

在复杂的场景中, 利用大量这种分解的组合所提供的带有判别性的能量是十分有利的. 在本文的研究中, 本文将这些分解参数形成了一个特征向量, 即极化特征. 表 1 列出了本文所采用的 PolSAR 和 PolInSAR 分解.

表 1 极化 SAR/极化干涉 SAR 特征

| 方法 | 特征描述 | 数目 | |
|--------|----------|----------------|---|
| 极化 SAR | Pauli | 3 | |
| | 相干分解 | Krogager SDH | 3 |
| | | Cameron | 3 |
| | | Huynen | 3 |
| | 非相干分解 | Barnes | 3 |
| | | Four-Component | 4 |
| | | Freeman | 3 |
| | | Holm | 3 |
| | | Cloud | 3 |
| | 极化干涉 SAR | LeeOpt | 2 |
| 向量干涉 | | Neumann | 5 |
| | | NRFF | 3 |
| | | OptimalCoh | 3 |

1.2 RCC 关系

本文采用 $Rcc^{[14]}$ 来提取目标的空间信息。RCC 基于空间中成对区域之间的连接的概念,用以定性的描述空间属性和关系。 RCC_8 使用 8 个穷举且不相交的关系来描述两个空间区域之间的拓扑关系。这 8 种拓扑关系分别是不连接(DC)、外部连接(EC)、部分交迭(PO)、正切真部分(TPP)、非正切真部分(NTPP)、反正切真部分(TPPi)、反非正切真部分(NTPPi)和相等(EQ)。图 2 描述了区域连接演算 RCC_8 的空间对象 A 和 B 的 8 种基本关系。

图 2 RCC_8 关系描述

由于在无向图模型中,TPPi 和 NTPPi 的意义与 TPP 和 NTPP 是相同的,因此可以去掉它们,又因为 DC 表示两个区域之间没有任何关系,因此也可以采用文献[12]的方法去掉。所以只有 5 种关系—— RCC_5 保留下来。根据原始图像中一对超像素的相对位置, RCC_5 中的一种形式将被选来描述这两个超像素之间的关系。

为了推理的方便,本文将层次 RCC 模型实质化为一种特征,它是包含了 7 个单元的局部先验特征向量。其中单元 1-5 是 0 或者 1,分别代表 EC、EQ、NTPP/NTPPi、TPP/TPPi 和 PO 这几种

RCC 关系;单元 6-7 分别是 X、Y 轴上类别分别为 c_{k1}, c_{k2} 的超像素 s_{k1}, s_{k2} 的归一化均值,其中 $I = \{S_i\}$ 表示一幅图像, $C = \{c_k\}$ 表示标签序列。本文采用了 Stephen Gould 提供的 Quasi-Newton 方法对这个问题进行优化。

1.3 产生式模型

在统计学上,产生式模型是一种代表性地给定一些隐参数,随机产生观测数据的模型。它对观测测量和标号序列的联合概率分布进行建模。在机器学习中,产生式模型被用来对数据直接进行建模,或者作为中间步骤构建一个条件概率密度函数。产生式模型可以用来仿真(产生)模型中任何变量的值。

pLSA 模型是一种最早用于文本检索的产生式模型,其原理如图 3(a) 所示。其中, z 是主题,为隐含变量,表示词汇 w 和文档 d 之间有潜在的语义作为中间变量。LDA 模型的原理是一个 3 层的贝叶斯模型,如图 3(b) 所示。模型的生成通过数据采样自动完成,判别过程需要用期望最大化(EM)算法来进行贝叶斯参数估计。本文所采用的产生式模型如图 3(c) 所示,它是一种改进的 LDA 模型。从产生过程来看,该模型首先产生区域描述子,随后再产生标签。

图 3 pLSA、LDA 和本文的产生式模型

2 GM-RCC 模型

2.1 GM-RCC 模型

本文所提出的 GM-RCC 模型如图 4 所示,它包含两个主要成分:RCC 模型和产生式模型。 β 是 RCC 模型的先验。 X 是 RCC 的区域描述子,由 z_1 产生, $z_1 = \{z_{11}, z_{12}, \dots, z_{1n}\}$ 表示 RCC 产生的该图像的隐藏因子。模型中的参数 α, μ, σ 和 η 均为狄

力克雷先验项, $z_2 = \{z_{21}, z_{22}, \dots, z_{2n}\}$ 是产生式模型产生的该图像的隐藏因子. $y = \{y_1, y_2, \dots, y_m\}$ 是在 $1 \sim N$ 之间均匀取值的离散索引变量. 本文先从一个 LDA 模型中产生 N 个区域描述子 r_n , 然后对于 M 个标签中的每一个, 从图像中选择一个区域, 基于产生这个区域的因子本文就可以得到相应的一个标签 w_n .

图 4 GM-RCC 模型具体说明

基于 N 和 M , 产生式模型和 RCC 模型所构成的 GM-RCC 模型的产生过程如下:

- 1) 由 RCC 模型可以得到一组隐变量 z_1 .
- 2) 由 z_1 产生基于区域的 RCC 特征 X .
- 3) 对 $\theta \sim \text{Dir}(\alpha)$ 进行采样.
- 4) 对每个图像区域 $r_n, n \in \{1, \dots, N\}$.
 - ① 对 $z_{2n} \sim \text{Mult}(\theta)$ 进行采样.
 - ② 从一个基于 z_{2n} 的多变量高斯分布中对 r_n
- 5) 对于每一个类别 $w_m, m \in \{1, \dots, M\}$.
 - ① 对 $y_m \sim \text{Unif}(1, \dots, N)$ 进行采样.
 - ② 从基于因子 z_{1y_m}, z_{2y_m} 的联合多项式分布中

对 $w_m \sim p(w | y_m, z_1, z_2, \eta)$ 进行采样.

图像区域、类别和隐变量的联合分布表示为

$$p(r, x, w, \theta, z_1, z_2, y) = p(\theta | \alpha) \cdot \prod_{n=1}^N \left(p(z_{1n}) \left(\prod_{j=1}^{A_r} p(X_{nr} | z_{1n}, \rho) \right) p(z_{2n} | \theta) \cdot \left(\prod_{i=1}^{N_f} p(r_{ni} | z_{2n}, \mu, \sigma) \right) \right) \cdot \left(\prod_{m=1}^M p(y_m | N) p(w_m | y_m, z_1, z_2, \beta) \right).$$

2.2 模型学习

对于模型中参数的学习, 给定一幅图像, 本文通过变分 EM 步骤来获得模型参数的最大似然估

针对一幅具体的 SAR 图像, 图 4 给出了 GM-RCC 模型的详细说明, 图中的 SAR 图像是经过过分割之后得到的图像, z_1, z_2 分别对应图像中的隐藏因子, X 对应两个区域之间关系描述子, r 为某一个区域的描述子, w 对应图像中的 5 个类别. h (RCC 模型) 对应本文采用的迭代策略.

计. 在 E 步, 通过当前设定的参数值计算出每幅图像和类别的变分后验; 在 M 步, 从变分分布下得到的期望完全统计中找到模型参数的最大似然估计. 变分 EM 算法在两步之间交替进行直到期望的 log 似然收敛.

2.3 模型的推理

由于 GM-RCC 模型基于改进的 LDA 模型, 精确的概率推理是不容易得到的, 因此, 本文采用变分推理来估计隐变量上的后验分布. 特别地, 本文定义隐变量的因式化分布为

$$q(\theta, z_1, z_2, y) = q(\theta | \gamma) \left(\prod_{n=1}^N q(z_{1n} | \phi_{1n}) q(z_{2n} | \phi_{2n}) \right) \cdot \left(\prod_{m=1}^M q(y_m | \lambda_m) \right).$$

式中: γ, ϕ 和 λ 分别为变分参数. 其中: γ 为 K 维狄力克雷参数; ϕ_n 为 N 个 K 维多项式参数; λ_m 为 M 个 N 维多项式参数.

由变分估计的一般准则可知, 估计值要使这个因式化的分布与真实的后验分布之间的 KL 分歧最小. 对变分参数求导, 可以得到算法如下:

- 1) 更新后验狄力克雷参数为

$$\gamma_i = \alpha_i + \sum_{n=1}^N \phi_{ni}.$$

- 2) 对于每个区域, 更新因子上的后验概率分

布.注意到这个更新需要考虑每种类别是由区域中相同因子产生的:

$$\varphi_{ni} \propto p(r_n | z_{2n} = i, \mu, \sigma) p(X_n | z_{1n} = j, \rho) \exp\{E_q[\log \theta_i | \gamma]\} \cdot \exp\left\{\sum_{m=1}^M \lambda_{mn} \log p(w_m | y_m = n, z_{1m} = j, z_{2m} = i, \eta)\right\}.$$

式中: $E_q[\log \theta_i | \gamma] = \Psi(\gamma_i) - \Psi(\sum \gamma_j)$; Ψ 为双伽玛函数.

3) 对每种类别, 更新区域上的近似后验分布为

$$\lambda_{nm} \propto \exp\left\{\sum_{i=1}^K \varphi_{ni} \log p(w_m | y_m = n, z_{1n} = i, z_{2n} = j, \eta)\right\}.$$

4) 更新一直进行下去, 直到 KL 分歧的变化很小才停止. 得到近似后验分布后就可以找到联合分布 $p(w, r, x)$ 的下界.

5) 标签的条件概率为

$$p(w | r, x) = \sum_{n=1}^N \sum_{z_n} (q(z_{2n} | \phi_{2n}) p(w | z_{2n}, \eta)) \cdot (q(z_{1n} | \phi_{1n}) p(w, z'_{1n} | z_{1n}, \eta)).$$

3 实验

3.1 数据

本文所进行的实验都是在一个 $1\ 300 \times 1\ 200$ 像素的 ESAR 图像上进行的, 该图像显示的是德国的某个地方. 通过使用 ArcGIS 软件, 本文将相应的地面真实图像进行人工标记, 得到 5 个类别: 耕地、林地、建筑、道路和其他陆地覆盖物, 如图 5(b) 所示, 图 5(a) 为原始图像. 实验过程中, 每一类数据的 50% 用来训练, 50% 用来测试. 采用 Meanshift 过分割后的最小过分割区域(超像素)的面积为 400 像素, 从各个超像素中提取的特征包含表 1 中的 PolSAR 和 PolInSAR 特征.

图 5 实验图像对比

实验引进了 EM 迭代策略, 由于 RCC 模型可以看成一种表示迭代信息的特征描述, 这种迭代信息可以视为 RCC 迭代的局部先验特征 (RCC-ILP). RCC-ILP 特征可以从先前的迭代分类结果中提取. RCC-ILP 特征包含 5 个部分, 分别对应 RCC_5 中的 5 种关系. 举例来说, 如果是 PO 关系, 超像素 S_i 的 PO 部分是先前迭代分类结果中的像素的一个归一化标号直方图, 同时这些像素属于当前迭代的超像素集合 $s' = \{s_j \in PO(s_i)\}$, 也就是说 s_j 是先前迭代结果中与先前迭代中的超像素

s_i 有着 PO 关系的第 j 个超像素. 每一次迭代的标号信息都来自于先前的迭代结果, 初始化的标号信息则来自于混合模型的结果. 迭代步骤一直重复直到满足收敛条件为止.

3.2 结果与讨论

本文首先对提出的 GM-RCC 模型进行实验, 同时, 为了说明 GM-RCC 模型的有效性, 本文还进行了一系列对比实验, 分别为无 RCC 先验信息的产生式模型实验、基于 SVM 的分类方法实验以及监督马尔科夫随机场 (MRF) 分类方法实验.

GM-RCC 模型实验得到的分类结果和混淆矩阵分别如图 5(f) 和表 2 所示. 可以看出每个类别的分类准确率都比较高, 对例如道路等比较复杂和精细的结构也能够很好的进行分类.

表 2 GM-RCC 分类混淆矩阵

| 分类 | 耕地 | 建筑 | 林地 | 道路 | 其他 |
|----|-------|-------|-------|-------|-------|
| 耕地 | 0.860 | 0.012 | 0.110 | 0.006 | 0.012 |
| 建筑 | 0.002 | 0.904 | 0.041 | 0.022 | 0.032 |
| 林地 | 0.062 | 0.039 | 0.850 | 0.012 | 0.038 |
| 道路 | 0.013 | 0.033 | 0.045 | 0.727 | 0.182 |
| 其他 | 0.006 | 0.021 | 0.020 | 0.026 | 0.927 |

为了说明 RCC 模型在 GM-RCC 模型中所起的作用, 本文基于无 RCC 先验信息的产生式模型做了一个对比实验. 实验条件和 GM-RCC 模型中的实验完全相同, 不同的是, 这个实验只用了邻域先验信息. 分类结果和混淆矩阵分别如图 5(e) 和表 3 所示. 从图 5(e)、(f) 中可以看出, 模型 GM-RCC 模型由于 RCC 先验的存在, 使得 SAR 图像中许多复杂的细节能够从背景中分辨出来.

表 3 无 RCC 的产生式模型分类混淆矩阵

| 分类 | 耕地 | 建筑 | 林地 | 道路 | 其他 |
|----|---------|-------|-------|-------|-------|
| 耕地 | 0.572 0 | 0.007 | 0.157 | 0 | 0.265 |
| 建筑 | 0.000 9 | 0.806 | 0.062 | 0.043 | 0.089 |
| 林地 | 0.082 0 | 0.054 | 0.810 | 0.008 | 0.046 |
| 道路 | 0.024 0 | 0.054 | 0.027 | 0.423 | 0.472 |
| 其他 | 0.006 0 | 0.017 | 0.015 | 0.049 | 0.913 |

本文也选择了传统的基于 SVM 的分类方法来进行对比实验. 采用每一类中 50% 的像素来进行训练, 其余的用作测试. 之所以在实验中采用 SVM S 形核分类器是因为它在文献[7]中结果最好. 分类结果和混淆矩阵分别如图 5(c) 和表 4 所示. 从图 5(c) 中可以看出该方法得到的分类效果并不好, 耕地、道路等精细结构都被错分到林地和“其他”类别当中.

表 4 SVM 分类混淆矩阵

| 分类 | 耕地 | 建筑 | 林地 | 道路 | 其他 |
|----|-------|-------|-------|-------|-------|
| 耕地 | 0.254 | 0.053 | 0.276 | 0.013 | 0.404 |
| 建筑 | 0.012 | 0.495 | 0.162 | 0.023 | 0.308 |
| 林地 | 0.014 | 0.087 | 0.813 | 0.011 | 0.074 |
| 道路 | 0.006 | 0.068 | 0.097 | 0.342 | 0.488 |
| 其他 | 0.008 | 0.048 | 0.031 | 0.027 | 0.886 |

实验的另外一个对比实验是一种监督马尔科夫随机场(MRF)分类方法, 它是一种具有上下文信息的传统描述模型. 在训练阶段, 本文采用相同的方法获取图像中的超像素以及 Pol/PolInSAR

特征. 接着, 训练特征数据被用来训练 SVM S 形核分类器. 给定一幅测试图像, SVM 分类器可以预测每个超像素属于每个类别的概率. 本文也采用了 GraphCut 算法^[15]来平滑模型的优化, 结果如图 5(d) 和表 5 所示. 从图 5(d) 中可以看出使用该方法使得大量例如道路等的精细结构都没有分辨出来, 而是被分类到“其他”这一类别.

表 5 SVM+MRF 分类混淆矩阵

| 分类 | 耕地 | 建筑 | 林地 | 道路 | 其他 |
|----|---------|---------|-------|---------|-------|
| 耕地 | 0.187 0 | 0.004 0 | 0.362 | 0 | 0.447 |
| 建筑 | 0.000 6 | 0.777 0 | 0.064 | 0.000 7 | 0.158 |
| 林地 | 0 | 0.058 0 | 0.854 | 0.000 1 | 0.088 |
| 道路 | 0 | 0.046 0 | 0.093 | 0.206 0 | 0.655 |
| 其他 | 0.000 2 | 0.022 0 | 0.022 | 0.003 0 | 0.953 |

表 6 列出了所有方法的分类准确率以进行直观的对比, 从表 6 中可以看出除了“其他”类别以外, GM-RCC 模型对每一个类别的分类准确率都是最高的, 而之所以采用 MRF 得到的“其他”类别的分类准确率最高, 但平均准确率低, 则正是因为它将许多类别错分到其他类别中.

表 6 分类准确率对比

| 准确率 | 耕地 | 建筑 | 林地 | 道路 | 其他 | 平均 |
|--------------|-------|-------|-------|-------|-------|-------|
| SVM | 0.254 | 0.495 | 0.813 | 0.342 | 0.886 | 0.695 |
| SVM+MRF | 0.187 | 0.777 | 0.854 | 0.206 | 0.953 | 0.759 |
| 无 RCC 的产生式模型 | 0.572 | 0.806 | 0.810 | 0.423 | 0.913 | 0.791 |
| GM-RCC 模型 | 0.860 | 0.904 | 0.850 | 0.727 | 0.927 | 0.879 |

从算法的时间复杂度去考虑, 4 种分类方法中, 直接采用 SVM 分类的方法之间从特征出发构造分类器, 时间效率最高, 而 MRF+SVM 的方法和无 RCC 的产生式模型的方法在时间复杂度上相似, 而本文提出的 GM-RCC 的方法相对于其他的方法而言计算代价较高, 但尚在可接受的范围内, 因此综合分类精度和时间复杂度的考虑, 本文提出的 GM-RCC 的方法的适用性更强.

产生式模型和 RCC 模型后结合能够得到更好的分类效果, 是因为一般的产生式模型没有金字塔, 基于金字塔构建 RCC 可以得到更为全面的多层信息, 再与产生式模型结合后对空间信息获取更为全面和精确. 模型的改进并不是简单的把两个算法并行或者串行, 而是实质性地融合.

4 结 论

1) 在产生式模型的框架下, GM-RCC 模型利用 RCC 模型对 SAR 图像中目标空间结构进行描述. 这种空间结构被转换成一种先验信息, 与基本

的特征联合在一起对产生式模型进行学习和推理。

2)GM-RCC 模型中的多尺度推理策略可以通过 SAR 图像中的不同尺度(分辨率)对分类信息进行有效的改善.模型同时考虑了低分辨率图像的全局分类信息以及高分辨率图像的局部分类信息.它描述和推理的对象是 SAR 图像中的多重上下文关系,而不是 MRF 模型中的传统上下文信息,传统的上下文信息倾向于去除区域之间的噪声或者对分类结果进行平滑.

参考文献

- [1] MAITRE H. Processing of Synthetic Aperture Radar Image [M]. 孙洪,译.北京:电子工业出版社,2005: 1-10.
- [2] TISON C, NICOLAS J M, TUPIN F, *et al.* A new statistical model for Markovian classification of urban areas in high-resolution SAR images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(10): 2046-2057.
- [3] ACHIM A, TSAKALIDES P, BEZERIANOS A. SAR image denoising via Bayesian wavelet shrinkage based on heavy-tailed modeling [J]. IEEE Transactions of Geoscience and Remote Sensing, 2003, 41(8): 1773-1784.
- [4] NYSTUEN J A, Jr GARCIA F W. Sea ice classification using SAR backscatter statistics[J]. IEEE Transactions on Geoscience and Remote Sensing, 1992, 30(3): 502-509.
- [5] SIRMACEK B, UNSALAN C. Urban area detection using local feature points and spatial voting [J]. IEEE Geoscience and Remote Sensing Letters, 2010, 7(1): 146-150.
- [6] SIMACEK B, UNSALAN C. Urban-area and building detection using SIFT keypoints and graph theory [J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(4): 1156-1167.
- [7] SHIMONI M, BORGHYS D, HEREMANS R, *et al.* Fusion of PolSAR and PolInSAR data for land cover classification[J]. International Journal of Applied Earth Observation and Geoinformation, 2009, 11(3): 169-180.
- [8] HOFMANN T. Probabilistic latent semantic indexing [C]//Proceedings of the Twenty-Second Annual International SIGIR Conference on Research and Development in Information Retrieval (SIGIR-99). New York, NY: ACM, 1999: 50-57.
- [9] BLEI D M, Ng A Y, JORDAN M I. Latent dirichlet allocation[J]. Journal of Machine Learning Research. 2003, 3: 993-1022.
- [10] SUDDERTH E B. Graph Model for Visual Object Recognition and Tracking [D]. Cambridge, MA: Massachusetts Institute of Technology, 2006.
- [11] LI Lijia, SOCHER R, LI Feifei. Towards total scene understanding: classification, annotation and segmentation in an automatic framework [C]// Proceedings of Computer Vision and Pattern Recognition(CVPR). Miami, FL: IEEE, 2009.
- [12] INGLADA J, MICHEL J. Qualitative spatial reasoning for high-resolution remote sensing image analysis [J]. IEEE Transactions on Geoscience and Remote Sensing, 2009, 47(2): 599-612.
- [13] COMANICIU D, MEER P. Mean shift: a robust approach toward feature space analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(5): 603-619.
- [14] GOTTSS N M, GOODAY J M, COHN A G. A connection based approach to common-sense topological description and reasoning [J]. Monist, 1996, 79(1): 51-75.
- [15] BOYKOV Y, VEKSLER O, Zabih R. Fast approximate energy minimization via graph cuts [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(11): 1222-1239.

(编辑 张红)