

可变类空间约束高斯混合模型遥感图像分割

赵泉华, 石雪, 王玉, 李玉

(辽宁工程技术大学测绘与地理科学学院遥感科学与应用研究所, 辽宁 阜新 123000)

摘 要: 针对传统高斯混合模型 (GMM, Gaussian mixture model) 难以自动获取类属数和对噪声敏感问题, 提出了一种基于可变类空间约束 GMM 的遥感图像分割方法。首先在构建的 GMM 中, 将像素类属性建模为马尔可夫随机场 (MRF, Markov random field), 并在此基础上定义其先验概率; 结合邻域像素类属性的后验概率和先验概率, 定义噪声平滑因子, 以提高算法的抗噪性; 在参数求解过程中, 分别采用可逆跳变马尔可夫链蒙特卡罗 (RJCMC, reversible jump Markov chain Monte Carlo) 方法和最大似然 (ML, maximum likelihood) 方法估计类属数和模型参数; 最后以最小化噪声平滑因子为准则获取最终分割结果。为了验证提出的分割方法, 分别对模拟图像和全色遥感图像进行了可变类分割实验。实验结果表明提出方法的可行性和有效性。

关键词: 高斯混合模型; 空间约束; 最大似然估计; 可逆跳变马尔可夫链蒙特卡罗; 遥感图像分割

中图分类号: TP391.41

文献标识码: A

Remote sensing image segmentation based on spatially constrained Gaussian mixture model with unknown class number

ZHAO Quan-hua, SHI Xue, WANG Yu, LI Yu

(Institute for Remote Sensing Science and Application, School of Geomatics, Liaoning Technical University, Fuxin 123000, China)

Abstract: In view of the traditional Gaussian mixture model (GMM), it was difficult to obtain the number of classes and sensitive to the noise. A remote sensing image segmentation method based on spatially constrained GMM with unknown number of classes was proposed. First, in the built GMM, prior probability that represented the membership between a pixel and one class was modeled as a Markov random field (MRF). In order to improve the sensitivity of noise, the smoothing factor was defined by combining the a posterior probability and the prior probability of neighboring pixels. For estimating the number of classes and the parameters of model, the reversible jump Markov chain Monte Carlo (RJCMC) and maximum likelihood (ML) estimation were employed, respectively. Finally, by minimizing the smoothing factor the final segmentation was obtained. In order to verify the proposed segmentation method, the synthetic and real panchromatic images were tested. The experimental results show that the proposed method is feasible and effective.

Key words: Gaussian mixture model (GMM), spatially constrained, maximum likelihood (ML), reversible jump Markov chain Monte Carlo (RJCMC), remote sensing image segmentation

1 引言

随着遥感传感器技术的飞速发展, 遥感图像的空间分辨率不断提高, 所包含的信息更加丰富, 因而广泛应用于众多领域。但由于分辨率的提高, 同类地物光谱异质性增强, 导致对遥感图像的处理过程更

加困难^[1,2]。图像分割是图像处理过程中的关键环节, 其结果对图像处理的后续工作具有重要影响^[3,4]。遥感图像分割涵盖 2 个基本任务: 确定遥感图像中欲分割区域内包含的地物目标数(像素的类属数)以及精准分割各地物目标区域。在现代遥感图像分割中, 由于空间分辨率的提高、地物种类繁多、背景

收稿日期: 2016-07-21; 修回日期: 2016-11-23

基金项目: 国家自然科学基金资助项目 (No.41301479, No.41271435); 辽宁省自然科学基金资助项目 (No.2015020090)

Foundation Items: The National Natural Science Foundation of China (No.41301479, No.41271435), The Natural Science Foundation of Liaoning Province (No.2015020090)

环境复杂、实地考察困难等原因,造成人工判读遥感图像中覆盖的地物类属数比较困难^[5]。如果不能正确地指出地物类属数,必将导致错误的分割结果。此外,高分辨率使遥感图像表达所覆盖地表的细节能力增强,但另一方面,过度的细节表达将导致同类地物目标内像素光谱测度的差异性增大(表现为噪声性增大),为其分割造成了极大的困难。因此,自动确定类属数以及提高算法抗噪性一直是高分辨率遥感图像分割研究中的重要任务^[6]。

在目前众多的遥感图像分割方法中,统计学框架下的分割方法是最为有效的方法,而其中基于混合模型的分割方法以多个概率分布加权之和拟合待分割图像,每个混合分量的概率分布描述特定目标类内像素光谱测度的概率统计分布规律^[7]。其中,高斯混合模型(GMM, Gaussian mixture model)由于原理简单、结构直观、易于实现等特点,广泛应用于遥感图像分割中^[8,9]。但在传统的 GMM 中仅利用了图像的灰度信息,没有引入邻域像素间的空间关系,这导致分割结果对图像噪声非常敏感。

为了解决 GMM 算法易受图像噪声影响的问题,许多学者将空间约束引入到遥感图像分割算法的设计中。其中,融合马尔可夫随机场(MRF, Markov random field)的 GMM 成为了图像分割领域的研究热点^[10,11]。文献[10]提出了一种空间可变有限混合模型(SVFMM, spatially variant finite mixture model)图像分割方法。该算法在 GMM 的基础上,将高斯分量权重系数表示为各像素隶属于各类的先验概率;并采用 Gibbs 分布建模该先验概率的空间相关性,以提高算法的抗噪性。虽然该方法降低了分割结果对图像噪声的敏感性,但是,由于先验分布中的控制平滑噪声能力参数 β 设为常数,导致该算法在平滑噪声方面不具有灵活性。为了进一步提高算法的抗噪性,克服 SVFMM 算法的缺陷,文献[11]在 SVFMM 算法的基础上,提出了自适应空间可变混合模型(A-SVFMM, adaptive spatially variant finite mixture model)。该算法采用 MRF 重新建模先验分布,假设先验概率服从均值为 0,具有一定方差的正态分布,并设定其方差为与类属标号有关的随机变量。采用最大似然函数(ML, maximum likelihood)方法求解模型参数,由于需要满足先验概率的约束条件,导致求解先验概率解析式的过程比较复杂。该方法虽然提高了算法抗噪的灵活性,但增加了模型参数求解的困

难程度。同时,以上方法对高分辨率遥感图像的分割结果精度不高。

虽然以上方法在一定程度上提高了算法的抗噪性,但是,没有实现图像类属数的自动确定。对于自动确定类属数问题,许多学者提出了基于高斯混合模型的可变类图像分割方法^[12,13]。文献[12]提出一种基于多元高斯混合模型的可逆跳变马尔可夫链蒙特卡罗(RJMCMC, reversible jump Markov chain Monte Carlo)方法的图像分割算法。该算法的采样模拟过程操作包括标号场采样、高斯分布参数采样、混合权重系数采样、MRF 参数采样和类属数采样。该算法可以确定图像最可能的类属数,并估计出模型参数以达到图像分割的目的。但是,该算法仅应用于彩色图像分割,没有应用于高分辨率遥感图像。同时,该算法所采用的 RJMCMC 方法步骤较多,实现起来较为困难。文献[13]提出一种贝叶斯理论框架下结合 GMM 和 MRF 的遥感图像分割算法,以最大化后验概率^[14](MAP, maximization a posterior)为参数求解准则,以达到图像分割的目的。该算法通过提出一种新的能量函数刻画像素光谱测度值之间的差异和元素之间的距离,提高了分割算法的抗噪性,但是能量函数形式复杂,且不具有普遍适用性;为了自动确定类属数,该方法在一定可能范围内预先指定若干类属数,并对每一指定的类属数实现与之相应的最优分割。逐一计算最优分割的熵函数,采用最大熵准则^[15]确定最优类属数,即逐个类属数进行运算得到相对应的熵值,从中选出熵值收敛点所对应类属数即为最优类属数。虽然最大熵准则可以确定图像类属数,但是确定类属数的过程需执行多次固定类属数分割,导致该算法计算量大、效率低。为了实现类属数的自动确定,文献[5]提出一种基于 ISODATA 的自动确定类属数图像分割方法,为了提高算法的抗噪性,采用隐式马尔可夫随机场^[16](HMRF, hidden Markov random field)方法以刻画邻域像素的空间位置关系。该算法虽然实现了类属数的自动确定,但仍存在不足,如算法比较复杂、效率比较低;虽然该算法考虑了邻域像素之间的关系,但对于噪声较多的复杂高分辨率遥感图像,该算法分割结果精度不是很好,难以确定图像类属数。

为了解决高分辨率遥感图像自动确定类属问题,本文提出一种新的自动确定类属数的图像分割方法,即可变类空间约束的 GMM 遥感图像分割方

法。本文算法不但实现了类属数的自动确定，而且对于复杂的高分辨率遥感图像可以得到较高精度的分割结果。在分割模型建立过程中，为了提高算法抗噪性，提出算法结合邻域像素的后验概率和先验概率定义噪声平滑因子，并将其作用于 GMM 的高斯分量权重系数；在 GMM 参数求解过程中，对于在目标函数中具有显式表达的高斯分量参数和高斯分量权重系数，在均值场近似条件下，采用 ML 求解；对于隐含表达的高斯分量数，采用 RJMCMC 算法求解。这种参数组合估计方案不仅可以准确、自动地确定高斯分量个数，而且极大提高了算法效率。

2 算法描述

2.1 混合模型建立

设图像 $\mathbf{x}=\{x_i; i=1, 2, \dots, N\}$ ，其中， i 为像素索引， x_i 为像素 i 的灰度值， N 为总像素数。在基于统计理论的图像处理框架下， \mathbf{x} 可视为特征场 $X=\{X_i; i=1, 2, \dots, N\}$ 的实现，其中， X_i 为表征像素 i 灰度值的随机变量。

利用 GMM 刻画像素 X_i 的概率分布，则其实现 x_i 的概率密度为

$$p(x_i | \boldsymbol{\pi}_{(i)}, \boldsymbol{\theta}, k) = \sum_{j=1}^k \pi_{ij} \Phi(x_i | \boldsymbol{\theta}_j) = \sum_{j=1}^k \pi_{ij} \frac{1}{(2\pi\sigma_j^2)^{\frac{1}{2}}} \exp\left[-\frac{(x_i - \mu_j)^2}{2\sigma_j^2}\right] \quad (1)$$

其中， k 为高斯分量数，对应图像类属数，并设其为随机变量； j 为类属数索引； $\Phi(x_i | \boldsymbol{\theta}_j)$ 为高斯分量 j 的概率分布； $\boldsymbol{\theta}=\{\boldsymbol{\theta}_j; j=1, 2, \dots, k\}$ ， $\boldsymbol{\theta}_j=(\mu_j, \sigma_j)$ 为高斯分量 j 的参数矢量， μ_j 和 σ_j 为其均值和标准差； $\boldsymbol{\pi}_{(i)}=\{\pi_{ij}; j=1, 2, \dots, k\}$ ， π_{ij} 为高斯分量权重系数，且满足约束条件： $\pi_{i1} + \dots + \pi_{ik} = 1$ 。

假设图像中表征像素灰度的随机变量 X_i 相互独立，则图像或然率模型可定义为

$$p(X | \boldsymbol{\Pi}, \boldsymbol{\theta}, k) = \prod_{i=1}^N \sum_{j=1}^k \pi_{ij} \Phi(x_i | \boldsymbol{\theta}_j) = \prod_{i=1}^N \sum_{j=1}^k \pi_{ij} \frac{1}{(2\pi\sigma_j^2)^{\frac{1}{2}}} \exp\left[-\frac{(x_i - \mu_j)^2}{2\sigma_j^2}\right] \quad (2)$$

其中， $\boldsymbol{\Pi}=\{\boldsymbol{\pi}_{(i)}; i=1, 2, \dots, N\}$ 。

如将 $\boldsymbol{\pi}_{(i)}$ 看作定义在像素格点 i 上的随机矢量，则 $\boldsymbol{\Pi}$ 可以看作是定义在图像域上的随机场。为了建

模空间关系，假设 $\boldsymbol{\Pi}$ 为 MRF。根据 Hammersley-Clifford 定理， $p(\boldsymbol{\Pi}|k)$ 的概率分布可定义为如下 Gibbs 分布

$$p(\boldsymbol{\Pi} | k) = A^{-1} \exp\left[-\frac{1}{T} U(\boldsymbol{\Pi} | k)\right] \quad (3)$$

其中， $U(\boldsymbol{\Pi}|k)$ 为随机场 $\boldsymbol{\Pi}$ 的能量函数， A 为归一化常数， T 为温度系数。为了减少图像噪声的影响，定义能量函数 $U(\boldsymbol{\Pi}|k)$ 为

$$U(\boldsymbol{\Pi} | k) = \sum_{i=1}^N \sum_{j=1}^k G_{ij} \log \pi_{ij} \quad (4)$$

其中， G_{ij} 为噪声平滑因子。噪声平滑因子的引入将传统上由先验分布对数和定义的随机场能量函数变为先验分布对数加权；一方面，式(4)可视为广义随机场能量函数，传统的能量函数只是 $G_{ij} = 1$ 的一种特例，更重要的是增强了随机场能量函数定义的灵活性，即通过定义不同形式的噪声平滑因子，可将各种影响因素纳入到随机场能量函数中，以分别体现它们在图像分割中的作用。为此，本文将噪声平滑因子定义为像素 i 的邻域像素的高斯分量权重系数(先验概率)、后验概率和均值的负指数，而不是仅考虑先验概率(如 SVFMM 算法中的先验概率分布)或后验概率，起到了线性平滑噪声的作用。其公式为

$$G_{ij} = \exp\left[-\frac{\beta}{2N_i} \sum_{m \in \partial_i} (z_{mj} + \pi_{mj})\right] \quad (5)$$

其中， β 为常数，表示控制平滑噪声的能力； ∂_i 为像素 i 的邻域像素集； m 为邻域像素索引； N_i 为像素 i 的邻域像素数； π_{mj} 为像素 m 属于高斯分量 j 的权重系数； z_{mj} 为像素 m 属于高斯分量 j 的后验概率。

由式(3)~式(5)可以看出， z_{mj} 和 π_{mj} 越大，因子 G_{ij} 越小， $p(\boldsymbol{\Pi}|k)$ 越大，同时，噪声平滑因子是在高斯分量权重系数和后验概率的共同作用下提高抗噪性，其形式简化了模型的求解。

假设图像中像素类属数 k 为随机变量，且满足均值为 λ 的泊松分布，其概率密度函数为

$$p(k) = \frac{\lambda^k}{k!} e^{-\lambda} \quad (6)$$

为实现图像分割，需要得到已知图像 \mathbf{x} 和 $\boldsymbol{\theta}$ 条件下 $\boldsymbol{\Pi}$ 和 k 的联合概率密度函数。根据贝叶斯定理，该条件联合概率密度函数为

$$p(\boldsymbol{\Pi}, k | X, \boldsymbol{\theta}) \propto p(X | \boldsymbol{\Pi}, \boldsymbol{\theta}, k) p(\boldsymbol{\Pi} | k) p(k) = \prod_{i=1}^N \sum_{j=1}^k \pi_{ij} \Phi(x_i | \boldsymbol{\theta}_j) A^{-1} \exp\left(\frac{1}{T} \sum_{i=1}^N \sum_{j=1}^k G_{ij} \log \pi_{ij}\right)$$

$$\frac{\lambda^k}{k!} e^{-\lambda} \quad (7)$$

式(7)中参数包括：类属数 k 、均值矢量 $\boldsymbol{\mu}=\{\mu_j; j=1, 2, \dots, k\}$ 、标准差矢量 $\boldsymbol{\sigma}=\{\sigma_j; j=1, 2, \dots, k\}$ 、高斯分量权重系数 $\boldsymbol{\Pi}=\{\pi_j; j=1, 2, \dots, k\}$ 和 $\boldsymbol{\pi}_j=\{\pi_{ij}; i=1, 2, \dots, N\}$ 。设参数集为 $\boldsymbol{\varphi}=\{\boldsymbol{\mu}, \boldsymbol{\sigma}, \boldsymbol{\Pi}\}$ 。

2.2 模型参数求解

采用 RJMCMC 方法进行参数求解时,设计的移动操作包括:改变参数矢量操作、改变权重系数操作、增加或删除参数矢量操作。但该方法实现起来比较复杂,效率较低。因此,本文提出一种结合 RJMCMC 方法和 ML 方法的参数估计方法,可有效地求解模型参数。在类属数 k 固定的条件下,可显式表达在式(7)中的参数(如均值、方差和高斯分量权重系数)采用 ML 方法求解。ML 算法的作用和 RJMCMC 算法中改变参数矢量操作,改变权重系数操作的作用等同,都是在迭代过程中达到优化参数的目的;对于类属数 k ,由于隐含表达在式(7)中,其变化将导致参数集 $\boldsymbol{\varphi}=\{\boldsymbol{\mu}, \boldsymbol{\sigma}, \boldsymbol{\Pi}\}$ 的维度发生改变,因此,采用 RJMCMC 方法求解。

2.2.1 RJMCMC 方法求解 k

由于 k 的改变可以通过增加或合并高斯分量实现,因此,设计的移动操作包括增加或合并高斯分量,其实现过程如下。

增加高斯分量。设当前高斯分量数为 k 。增加高斯分量意味着增加一组新参数,记为 $\boldsymbol{\varphi}_{k+1}^*=\{\mu_{k+1}^*, \sigma_{k+1}^*, \boldsymbol{\pi}_{k+1}^*\}$, 其中, $\boldsymbol{\pi}_{k+1}^*=\{\pi_{ik+1}^*; i=1, 2, \dots, N\}$ 表示 N 个像素对应高斯分量 $k+1$ 权重系数集合。以等概率在 $\{1, 2, \dots, k\}$ 中抽取任意高斯分量,如 r 及其分布参数 (μ_r, σ_r) 。从 μ_r (σ_r) 为均值, σ_μ (σ_σ) 为标准差的正态分布中抽取 μ_{k+1}^* (σ_{k+1}^*)。其中, σ_μ (σ_σ) 为指定常数,即 $\mu_{k+1}^* \sim N(\mu_r, \sigma_\mu)$, $\sigma_{k+1}^* \sim N(\sigma_r, \sigma_\sigma)$ 。设 $\boldsymbol{\pi}_r$ 为抽取的高斯分量权重系数矢量,为了满足权重系数的约束条件,增加高斯分量操作后,第 r 个和 $k+1$ 个高斯分量权重系数矢量满足: $\boldsymbol{\pi}_{k+1}^* + \boldsymbol{\pi}_r^* = \boldsymbol{\pi}_r$, 新的高斯分量数 $k^*=k+1$ 。然后,对新的参数集 $\boldsymbol{\varphi}^*=\{(\mu_j^*, \sigma_j^*, \boldsymbol{\pi}_j^*); j=1, 2, \dots, k+1\}$ 进行迭代优化,即根据 ML 方法所求解得公式进行参数更新。增加高斯分量的接受率计算如下

$$a(\boldsymbol{\varphi}, \boldsymbol{\varphi}^*) = \min\{1, R\} \quad (8)$$

其中,式(8)中的 R 为

$$R = \frac{\prod_{i=1}^N \sum_{j=1}^{k+1} \pi_{ij}^* \left\{ (2\pi\sigma_j^{*2})^{-\frac{1}{2}} \exp\left[-\frac{(x_i - \mu_j^*)^2}{2\sigma_j^{*2}}\right] \right\}}{\prod_{i=1}^N \sum_{j=1}^k \pi_{ij} \left\{ (2\pi\sigma_j^2)^{-\frac{1}{2}} \exp\left[-\frac{(x_i - \mu_j)^2}{2\sigma_j^2}\right] \right\}} \cdot \frac{\exp\left\{ \sum_{i=1}^N \sum_{j=1}^{k+1} G_{ij} \log \pi_{ij}^* \right\}}{\exp\left\{ \sum_{i=1}^N \sum_{j=1}^k G_{ij} \log \pi_{ij} \right\}} \quad (9)$$

合并高斯分量。由于均值越相近的高斯分量越有可能归属于同一类别,因此,为实现合并操作,抽取均值最接近的高斯分量对(如 r 和 r'),其参数分别为 (μ_r, σ_r) 和 $(\mu_{r'}, \sigma_{r'})$, 与之相对应的高斯分量权重系数矢量分别为 $\boldsymbol{\pi}_r$ 和 $\boldsymbol{\pi}_{r'}$ 。合并后新的高斯分量的均值和标准差分别为 $\mu_r^* = \frac{\mu_r + \mu_{r'}}{2}$ 和 $\sigma_r^* = \frac{\sigma_r + \sigma_{r'}}{2}$ 。高斯分量权重系数矢量为 $\boldsymbol{\pi}_r^* = \boldsymbol{\pi}_r + \boldsymbol{\pi}_{r'}$ 。合并操作后新的高斯分量个数 $k^*=k-1$,然后,对新的参数集 $\boldsymbol{\varphi}^*=\{(\mu_j^*, \sigma_j^*, \boldsymbol{\pi}_j^*); j=1, 2, \dots, k-1\}$ 进行迭代优化,即根据 ML 方法所求解得公式进行参数更新。合并高斯分量为增加高斯分量的对偶操作,则其接受率定义为

$$a(\boldsymbol{\varphi}, \boldsymbol{\varphi}^*) = \min\left\{1, \frac{1}{R}\right\} \quad (10)$$

其中, R 由式(9)计算。

2.2.2 ML 估计求解 $\boldsymbol{\varphi}$

在 k 固定条件下,参数集 $\boldsymbol{\varphi}$ 可由最大化对数或然率得到。对或然率函数取对数,得到对数或然率函数

$$\begin{aligned} L(\boldsymbol{\Pi}, k | \mathbf{X}, \boldsymbol{\theta}) &= \log[p(\boldsymbol{\Pi}, k | \mathbf{X}, \boldsymbol{\theta})] \\ &= \log p(\mathbf{X} | \boldsymbol{\Pi}, k, \boldsymbol{\theta}) + \log p(\boldsymbol{\Pi} | k) + \log p(k) \\ &= \sum_{i=1}^N \log \left[\sum_{j=1}^k \pi_{ij} \Phi(x_i | \boldsymbol{\theta}_j) \right] - \log A + \\ &\quad \frac{1}{T} \sum_{i=1}^N \sum_{j=1}^k G_{ij} \log \pi_{ij} + \log p(k) \end{aligned} \quad (11)$$

以式(11)为目标函数进行参数求解。但由于式(11)中包含和的对数项,难以求得其最大化参数解,因此需进一步简化目标函数。

对给定随机变量 X , 对任意凹随机函数 $f(X)$, Jensen 不等式可表达为: $E[f(Y)] \leq f(E[Y])$, 其中, $E[\cdot]$ 为期望函数,当且仅当 Y 为常数时等式成立。

对给定 x_i , 令 $Y_{ij} = \frac{\pi_{ij}\Phi(x_i|\theta_j)}{z_{ij}}$, $j = 1, \dots, k$, $\{Y_{i1}, \dots,$

$Y_{ik}\}$ 为随机变量 Y_i 的 k 采样, 而 z_{ij} 可看作取得 Y_{ij} 的概

率。由此, 式(11)中 $\log\left[\sum_{j=1}^k \pi_{ij}\Phi(x_i|\theta_j)\right]$ 项可写为

$$\begin{aligned} \log\left(\sum_{j=1}^k \pi_{ij}\Phi(x_i|\theta_j)\right) &= \log\left(\sum_{j=1}^k z_{ij} \frac{\pi_{ij}\Phi(x_i|\theta_j)}{z_{ij}}\right) \\ &= \log\left(\sum_{j=1}^k z_{ij} Y_{ij}\right) = \log(E[Y_i]) \end{aligned}$$

由于 $\log(\cdot)$ 函数为凹函数, 根据 Jensen 不等式有

$$\log(E[Y_i]) \geq E[\log(Y_i)] = \sum_{j=1}^k z_{ij} \log\left(\frac{\pi_{ij}\Phi(x_i|\theta_j)}{z_{ij}}\right)$$

综上所述, 并设 $A=1$, $T=1$, 忽略式(11)中与待求参数 φ 无关项, 则有

$$\begin{aligned} L(\Pi, k|X, \theta) &\geq \\ &\sum_{i=1}^N \sum_{j=1}^k z_{ij} \log\left(\frac{\pi_{ij}\Phi(x_i|\theta_j)}{z_{ij}}\right) + \sum_{i=1}^N \sum_{j=1}^k G_{ij} \log \pi_{ij} \end{aligned} \quad (12)$$

为了确保估计参数使式(12)中对数或然率函数 $L(\Pi, k|X, \theta)$ 取得最大值, 定义式(12)右端函数为目标函数, 即

$$\begin{aligned} L(\Pi, k|X, \theta) &= \\ &\sum_{i=1}^N \sum_{j=1}^k z_{ij} \log\left(\frac{\pi_{ij}\Phi(x_i|\theta_j)}{z_{ij}}\right) + \sum_{i=1}^N \sum_{j=1}^k G_{ij} \log \pi_{ij} \end{aligned} \quad (13)$$

由于式(12)取等式的条件为函数项 $\frac{\pi_{ij}\Phi(x_i|\theta_j)}{z_{ij}}$ 等

于常数 c , 可以推导出 $z_{ij} = \frac{\pi_{ij}\Phi(x_i|\theta_j)}{c}$, 由于后验概

率满足条件 $\sum_{j=1}^k z_{ij} = 1$, 则 $c = \sum_{j=1}^k \pi_{ij}\Phi(x_i|\theta_j)$, 后验概率公式为

$$z_{ij} = \frac{\pi_{ij}\Phi(x_i|\theta_j)}{\sum_{j=1}^k \pi_{ij}\Phi(x_i|\theta_j)} \quad (14)$$

即式(5)噪声平滑因子中的 z_{mj} 由式(14)计算求得。

虽然简化后的目标函数易于求导, 但该目标函数最大值并非对数或然率函数最大值。为此, 采用迭代方法, J 为 L 的下界, 先固定参数 θ , 调整 z_{ij} 使下界 J 上升至与 L 在此点 θ 处相等, 再调整 θ 使下界 J 达到最大值, 不断重复直到收敛到对数或然率函数最大值处。因此, 最大化对数或然率函数等同于最大化目标函数。

由式(5)可知, G_{ij} 是 z_{ij} 和 π_{ij} 的函数, 利用式(13)求解参数较为困难。为简单起见, 采用均值场近似, 能量函数重写为

$$\begin{aligned} U(\Pi|k) &= \sum_{i=1}^N \sum_{j=1}^k G_{ij}^{(t)} \log \pi_{ij}^{(t+1)} \\ &= \sum_{i=1}^N \sum_{j=1}^k \exp\left[-\frac{\beta}{2N_i} \sum_{m \in \partial_i} (z_{mj}^{(t)} + \pi_{mj}^{(y)})\right] \log \pi_{ij}^{(t+1)} \end{aligned} \quad (15)$$

其中, t 为迭代指示器, 由式(15)可以看出, 能量函数与上一次迭代噪声平滑因子无关, 因此, 在求解高斯分量权重系数 π_{ij} 时可以不考虑噪声平滑因子项。因此, 将式(13)改写为

$$\begin{aligned} L(\Pi, k|X, \theta) &= \sum_{i=1}^N \sum_{j=1}^k z_{ij}^{(t)} \log(\pi_{ij}\Phi(x_i|\theta_j^{(t+1)})) - \\ &\sum_{i=1}^N \sum_{j=1}^k z_{ij}^{(t)} \log(z_{ij}^{(t)}) + \sum_{i=1}^N \sum_{j=1}^k G_{ij}^{(t)} \log \pi_{ij}^{(t+1)} \end{aligned} \quad (16)$$

忽略式(16)中与参数求解无关项, 得到简化后的目标函数

$$\begin{aligned} J(\Pi, k|X, \theta) &= \sum_{i=1}^N \sum_{j=1}^k z_{ij}^{(t)} \log(\pi_{ij}\Phi(x_i|\theta_j^{(t+1)})) + \\ &\sum_{i=1}^N \sum_{j=1}^k G_{ij}^{(t)} \log \pi_{ij}^{(t+1)} \end{aligned} \quad (17)$$

将式(17)目标函数分别对 μ_j 、 σ_j^2 求偏导数, 令其等于 0, 解得

$$\mu_j^{(t+1)} = \frac{\sum_{i=1}^N z_{ij}^{(t)} x_i}{\sum_{i=1}^N z_{ij}^{(t)}} \quad (18)$$

$$\left(\sigma_j^{(t+1)}\right)^2 = \frac{\sum_{i=1}^N z_{ij}^{(t)} (x_i - \mu_j^{(t+1)})^2}{\sum_{i=1}^N z_{ij}^{(t)}} \quad (19)$$

由于先验分布需要满足约束条件 $\pi_{i1} + \dots + \pi_{ik} = 1$ 。因此, 引入拉格朗日乘法, 对先验概率参数求偏

导，并令其等于 0，解得

$$\pi_{ij}^{(t+1)} = \frac{z_{ij}^{(t)} + G_{ij}^{(t)}}{\sum_{j'=1}^k (z_{ij'}^{(t)} + G_{ij'}^{(t)})} \quad (20)$$

2.3 图像分割解

为了实现图像分割，以最小化噪声平滑因子 G_{ij} 为准则，确定像素类属性，即取像素 i 的最小 G_{ij} 所对应的类属标号 j 作为该像素的类属，因此，像素 i 的类属可定义为

$$y_i = \arg \min_j (G_{ij}), i = 1, 2, \dots, N \quad (21)$$

其中， y_i 为像素 i 的类属标号。

2.4 算法流程

综上所述，算法流程可总结如下：

- 1) 设置常数 $\lambda, \mu_\mu, \mu_\sigma, \sigma_\mu, \sigma_\sigma, \beta$;
- 2) 初始化参数 k 和 $\{\Pi, \theta\}$ ，其中， k 由式(6)产生， $\mu_j \sim N(\mu_\mu, \sigma_\mu)$ ， $\sigma_j \sim N(\mu_\sigma, \sigma_\sigma)$;
- 3) 依据式(14)估计后验概率 $z_{ij}^{(t)}$;
- 4) 依据式(5)更新因子 $G_{ij}^{(t)}$;
- 5) 依据式(18)~式(20)分别更新 $\mu_j^{(t)}$ 、 $(\sigma_j^{(t)})^2$ 、 $\pi_{ij}^{(t)}$;
- 6) 重复步骤 3)~步骤 5)，达到最大预设循环次数跳出迭代，以优化参数 $\{\Pi, \theta\}$;
- 7) 执行增加或合并高斯分量操作，更新 $k^{(t+1)}$;
- 8) 重复步骤 3)~步骤 7)，类数 k 收敛后，执行步骤 3)~步骤 6)，直至目标函数收敛，或达到最大预设循环次数;
- 9) 依据平滑因子矩阵 $\mathbf{G}=[G_{ij}]_{N \times k}$ ，取像素最小的 G_{ij} 所对应的类属号 j 作为该像素的类属，从而获得最终图像分割结果。

3 实验结果和讨论

为了验证本文提出的图像分割算法的可行性和有效性，在 Intel Core i5-3470 3.20 GHz, 4 GB 内存，Matlab R2012a 环境下分别对模拟图像和高分辨率全色遥感图像进行了可变类分割实验。

图 1(a) 为生成模拟图像的模板，由图 1(a) 生成了分布参数已知的 5 个同质区域模拟图像。表 1 列出了各个同质区域的高斯分布参数。为了验证本文算法的有效性，在构建模拟图像时，不同的同质区域对应的高斯分布参数选择了较为接近的数值，如同质区域 II 和 III 设定相近的均值，同质区域 I 和 V 设定相同的标准差，模拟图像如图 1(b) 所示。




图 1 几何模板和模拟图像

表 1 模拟图像各同质区域的高斯分布参数

参数	I	II	III	IV	V
μ	50	100	120	150	200
σ	10	7	5	12	10

为了验证本文算法的分割结果不受初始类属数的影响，分别设置大于实际类属数和小于实际类属数的初始类属数进行分割实验。控制平滑噪声能力参数设为 4。图 1(b) 所示模拟灰度图像的实际类属数为 5，因此，初始类属数分别设置为 2、3、6 和 7。图 2 所示分割过程中类属数随迭代次数变化，仅显示取前 1 000 次迭代过程中类属数的变化情况(在后续迭代中类属数均不发生变化)。从图 2 中可以看出，类属数经过 400~800 次迭代均能收敛到正确类属数，说明本文可变类分割算法的分割结果在类属数确定上不受所设定初始类属数的影响。




图 2 类属数随迭代次数变化

为了从视觉上评估分割结果，采用本文算法对模拟图像(图 1(b))进行分割实验。图 3(a) 为类属数收敛后得到的分割结果，提取图 3(a) 的轮廓线，将轮廓线叠加在模拟图像上，如图 3(b) 所示。从轮廓线的叠加结果可以看出，本文算法可以得到很高的分割精度。尽管区域 II 和 III 有相近的均值，区域 I

和 V 有相同的标准差,但本文算法仍然能够准确地区分它们。




图 3 模拟图像实验结果

图 4 为图像像素灰度直方图、各同质区域不同高斯分量分布曲线和 GMM 分布曲线。从图 4 中可以看出,所有分布曲线均能很好地拟合各同质区域直方图。




图 4 拟合曲线

表 2 列出了本文算法估计得到的模拟图像各同质区域高斯分量分布参数值(μ_e, σ_e)及估计值相对误差(e_μ, e_σ)。其中,均值的相对误差在 0.4%以下,标准差的相对误差在 8%以下,说明本文算法可以得到较高的参数估计精度。

表 2 同质区域高斯分布参数估计值及相对误差值

指标	I	II	III	IV	V
μ_e/e_μ	50.0%/0	100.4%/0.4%	120.4%/0.3%	150.3%/0.2%	199.9%/0.05%
σ_e/e_σ	9.9%/1%	7.0%/0	4.6%/8%	11.3%/6%	9.9%/1%




图 5 添加噪声图像和对应分割结果

此外,为了定量评价本文算法,根据几何模板(图 1(a))和分割结果(图 3(a)),生成混淆矩阵,由混淆矩阵分别计算用户精度、产品精度、总精度和 Kappa 值,结果如表 3 所示。其中,用户精度均达到 99.66%以上,产品精度均达到 99.70%以上,总精度达到 99.87%,Kappa 值为 99.85%。上述定量分析结果证明本文提出算法的准确性。

表 3 用户精度、产品精度、总精度和 Kappa 值

精度指标	I	II	III	IV	V
用户精度	100%	99.99%	99.66%	99.90%	99.92%
产品精度	100%	99.83%	99.94%	99.90%	99.70%
总精度	99.87%				
Kappa	99.85%				

为了验证噪声平滑因子的有效性,对模拟图像(图 1(b))添加 5%的椒盐噪声,如图 5(a)所示。分别采用本文提出的噪声平滑因子、仅包含后验概率的噪声平滑因子和仅包含先验概率的噪声平滑因子的算法进行分割实验,实验结果如图 5(b)~图 5(d)所示。从分割结果可以看出,本文提出的噪声平滑因子可以有效地平滑图像噪声,很好地拟合各个区域的边界,得到较好的分割结果。而对比算法的分割结果中存在错分割现象(图 5(c)、图 5(d)区域 I 和区域 II),某些区域存在噪声(如图 5(c)区域 IV 和图 5(d)区域 V)。以上结果说明本文算法提出的噪声平滑因子的有效抗噪性。

图 6(a)~图 6(d)为 256×256 像素全色遥感图像,图 6(b)、图 6(c)是分辨率为 2.5 m 的 CARTOSAT-1 图像,图 6(a)、图 6(d)是分辨率为 0.7 m 的 EROS-B 图像。其中,图 6(a)为房屋;图 6(b)为运动场;图 6(c)为农田;图 6(d)为工厂。

为了验证本文算法自动确定类属数和去噪的有效性,对图 6(a)~图 6(d)的遥感图像添加 1%的椒盐噪声,如图 7(a)~图 7(d)所示。采用本文算法和对比算法对图 7 遥感图像进行分割实验。对比算法分

别采用文献[10]提出的 SVFMM 算法; 为了保证参数 β 和本文算法的一致性, 对比算法采用文献[11]中 A-SVFMM 模型, 以及文献[5]提出的隐马尔可夫随机场模糊 ISODATA(FISODATA, Fuzzy ISODATA) 可变类遥感图像分割算法。




图 6 全色遥感图像




图 7 添加噪声的图像

采用本文算法和对比算法进行分割实验, 分割结果如图 8 所示。其中, 图 8(a)为采用 SVFMM 算法进行分割实验得到的结果; 图 8(b)为采用 A-SVFMM 算法进行分割实验得到分割结果。由于 SVFMM 算法和 A-SVFMM 算法为固定类属数分割算法, 因此, 通过目视判读对图像设置类属数, 分别为 3、3、4、4。图 8(c)为采用 FISODATA 算法进行分割实验得到的结果。图 8(d)为采用本文算法进行分割实验, 类属数收敛后对应的分割结果。采用本文算法进行分割实验时, 设置不同的初始类属数, 经过有限次迭代类属数分别收敛到 3、3、4、4, 平均运算时间为 19 min。

比较图 8 的分割结果, SVFMM 算法和 A-SVFMM 算法对噪声都具有一定程度的平滑效果, 但与本文算法相比较, SVFMM 算法和 A-SVFMM 算法对某些区域有误差分割现象, 如图 8(a)中的农田和工厂图像和图 8(b)中的运动场和农田。A-SVFMM 算法的分割结果存在较多的噪声点, 如图 8(b)中的房屋和运动场, 而且不能很好地拟合目标区域的边界, 如图 8(b)中的运动场。FISODATA 算法虽然实现了自动确定类属数, 但是 FISODATA 算法的分割结果中存在较多的噪声点, 如图 8(c)中的运动场和农田。由于图像噪声的影响使 FISODATA 算法的分割精度较低。而本文算法在自动确定类数的同时, 提高了算法的抗噪性, 分割结果精度高于 FISODATA 算法。通过算法分割结果比

较, 说明本文算法在自动确定类属数的同时, 有较好的抗噪性, 可以得到较高精度的分割结果。

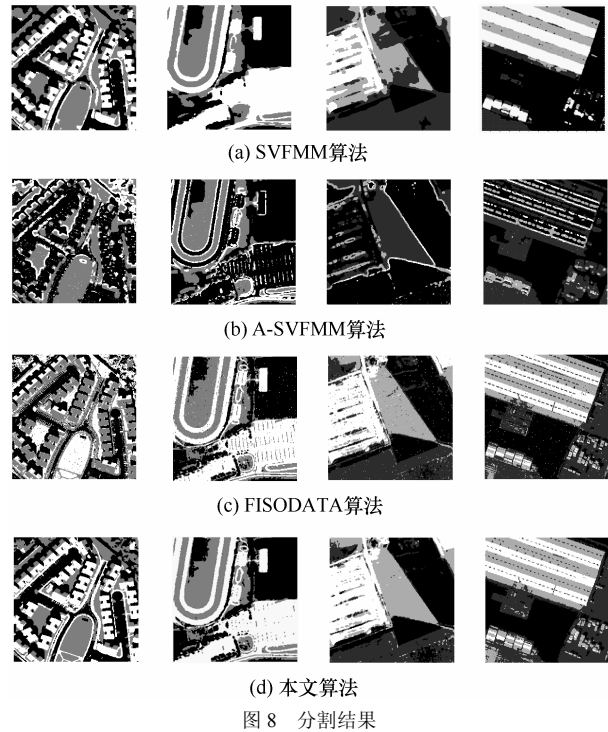


图 8 分割结果

图 9(a)~图 9(d)为图像像素灰度直方图、估计参数为分布参数的 GMM 分布曲线和各高斯分量的分布曲线拟合结果。曲线拟合结果可以说明, 本文算法估计出的模型参数可以很好地拟合图像的直方图。进一步说明本文算法有较好的分割效果。

图 10(a)~图 10(d)为本文算法分割过程中类属数随迭代次数变化曲线。对 4 幅图像分别设定不同的初始类数, 取前 1 000 次迭代。从图 10 可以看出, 随迭代数的改变, 类属数均达到稳定值, 分别是 3、3、4、4。进一步说明本文算法达到了自动确定图像最优类属数的目的。

4 结束语

可变类图像分割是目前遥感图像分割的主要研究任务之一。为此, 本文提出了一种可变类空间约束 GMM 遥感图像分割方法, 该算法通过噪声平滑因子将先验概率和后验概率结合, 充分考虑邻域像素的相互作用, 达到了减少图像噪声的效果, 同时易于求解; 对可显式表达的参数采用 ML 方法估计, 隐含表达的高斯分量数采用 RJMCMC 方法估计, 实现了准确的自动确定图像类属数的同时, 获得较高精度的分割结果。采用本文算法对模拟图像

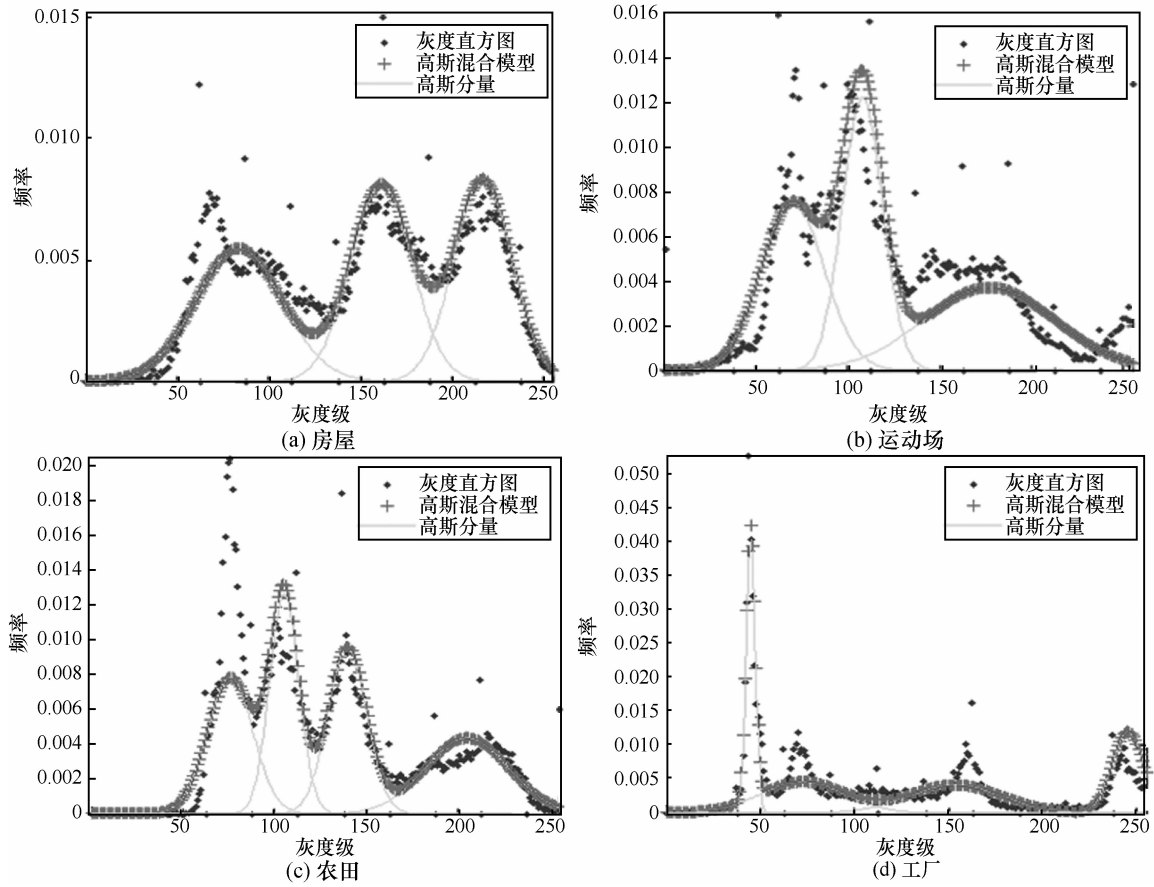


图9 像素灰度直方图、GMM 分布曲线和各高斯分量分布




图10 类属数随迭代数变化

和全色遥感图像进行可变类分割实验, 实验结果验证了本文算法的可行性和有效性。在分割过程中, 每一个高斯分量对应一个类别, 下一步将每一个类别分别建模为多个高斯分量的混合模型, 以准确刻画地物目标内像素光谱测度统计分布特征; 为了提高算法的灵活性, 将进一步优化对控制平滑噪声能力参数 β 的设置。

参考文献:

- [1] 王春艳, 徐爱功, 杨本臣. 基于区间二型模糊模型的高分辨率遥感影像分割方法[J]. 仪器仪表学报, 2016, 37(3): 658-666.
WANG C Y, XU A G, YANG B C. High resolution remote sensing image segmentation based on the interval type-2 fuzzy model[J]. Chinese Journal of Scientific Instrument, 2016, 37(3): 658-666.
- [2] 常生鹏, 马亿昨, 蔡立军. 一种基于 Hadoop 的高分辨率遥感图像处理办法[J]. 计算机工程与应用, 2015, 51(11): 167-171.
CHANG S P, MA Y W, CAI L J. A kind of high resolution remote sensing image processing method based on Hadoop[J]. Computer Engineering and Applications, 2015, 51(11): 167-171.
- [3] 王露, 刘庆元. 高分辨率遥感影像多尺度分割中最优尺度选取办法综述[J]. 测绘与空间地理信息, 2015, 38(3): 166-169.
WANG L, LIU Q Y. The methods summary of optimal segmentation scale selection in high-resolution remote sensing images multi-scale segmentation[J]. Geomatics & Spatial Information Technology, 2015, 38(3): 166-169.
- [4] 孔凡壮, 蒋艳凰, 刘芸. 遥感图像分割技术综述[C]//2005 通信理论与技术新进展——第十届全国青年通信学术会议. 2005: 790-792.
KONG F Z, JIANG Y H, LIU Y. A survey on remote image segmentation methods[C]//2005 New Progress in Communication Theory and Technology, The 10th National Youth Communication Conference Proceedings. 2005: 790-792.
- [5] 赵泉华, 赵雪梅, 李玉. 结合 HMRF 模型的模糊 ISODATA 高分辨率遥感图像分割[J]. 信号处理, 2016, 32(2): 157-166.
ZHAO Q H, ZHAO X M, LI Y. A fuzzy ISODATA approach combining hidden Markov random field model for high resolution remote sensing image segmentation[J]. Journal of Signal Processing, 2016, 32(2): 157-166.
- [6] ZHAO Q H, LI Y, WANG Y. SAR image segmentation with unknown number of classes combined Voronoi tessellation and RJMCMC algorithm[J]. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, 12(19): 119-124.
- [7] MCLACHLAN G J, PEEL D. Finite mixture models[M]. New York: John Wiley & Sons, 2000: 7-35.
- [8] 卢洁, 杨学志, 郎文辉. 区域 GMM 聚类的 SAR 图像分割[J]. 中国图象图形学报, 2011, 16(11): 2088-2094.
LU J, YANG X Z, LANG W H. SAR image segmentation with region-based GMM[J]. Journal of Image and Graphics, 2011, 16(11): 2088-2094.
- [9] 王荔霞, 谢维信, 裴继红. 多高斯模型特征空间覆盖学习的海洋航摄影像分割[J]. 电子学报, 2014, 42(10): 2117-2122.
WANG L X, XIE W X, PEI J H. Aerial ocean image segmentation using multi-Gauss model characteristic space cover learning[J]. Acta Electronica Sinica, 2014, 42(10): 2117-2122.
- [10] SANJAY-GOPAL S, HEBERT T J. Bayesian pixel classification using spatially variant finite mixtures and the generalized EM algorithm[J]. IEEE Transactions on Image Processing, 1998, 7(7): 1014-1028.
- [11] NIKOU C, GALATSANOS N P, LIKAS A C. A class-adaptive spatially variant mixture model for image segmentation[J]. IEEE Transactions on Image Processing, 2007, 16(4): 1121-1130.
- [12] KATO Z. Segmentation of color images via reversible jump MCMC sampling[J]. Journal Image and Vision Computing, 2006, 26(3): 361-371.
- [13] HOU Y, YANG Y, RAO N, et al. Mixture model and Markov random field-based remote sensing image unsupervised clustering method[J]. Opto Electronics Review, 2011, 19(1): 83-88.
- [14] COMER M, BOUMAN C A, GRAEF M, et al. Bayesian methods for image segmentation[J]. Journal of the Minerals, Metals and Materials Society, 2011, 63(7): 55-57.
- [15] WU N. The maximum entropy method[M]. Springer Science & Business Media, Berlin Heidelberg, 2012: 1-9.
- [16] CHATZIS S P, VARVARIGOU T A. A fuzzy clustering approach toward hidden Markov random field models for enhanced spatially constrained image segmentation[J]. IEEE Transactions on Fuzzy Systems, 2008, 16(5): 1351-1361.

作者简介:



赵泉华 (1978-), 女, 河北承德人, 博士, 辽宁工程技术大学副教授、博士生导师, 主要研究方向为随机几何、空间统计学、模糊集理论等在遥感图像建模、解译及其在海洋环境遥感中的应用。

石雪 (1992-), 女, 辽宁阜新人, 辽宁工程技术大学硕士生, 主要研究方向为影像信息提取理论与办法。

王玉 (1990-), 女, 辽宁本溪人, 辽宁工程技术大学硕士生, 主要研究方向为图像处理。

李玉 (1963-), 男, 吉林长春人, 博士, 辽宁工程技术大学教授、博士生导师, 主要研究方向为遥感图像处理。