

文章编号: 1007-4619(2007)06-0838-07

基于 MRF 随机场和广义混合模型的 遥感图像分级聚类

刘晓云, 王振松, 陈武凡, 李小文
(电子科技大学 自动化工程学院, 四川 成都 610054)

摘 要: 有限混合模型 FM 的分级聚类已广泛应用于不同领域,然而,它的计算复杂度与观测数据的平方成正比,因此,在海量数据方面的应用就受到了限制。另一方面,多光谱图像数据中同时包含有空间和光谱两类信息,但大多数基于像素的多光谱图像聚类方法,仅使用了其频谱信息而忽视了空间信息。本文提出了一种新的基于广义有限混合模型 GFM 的分级聚类方法,该算法把 MRF 随机场和 GFM 模型结合在一起,分类数可以通过 PLIC 准则自动确定。算法在执行过程中,采用 K 均值聚类方式获得过分类图像,分级聚类从过分类图像开始,代替原来从单点类开始的方式,这样可以方便获取 GFM 模型成分密度的初始参数。最后,采用由 Gibbs 采样器生成的仿真测试图对算法的精度进行了定量评价,通过与 K 均值聚类和 FM 聚类的比较说明了本文算法的优越性,同时用荷兰 Flevoland 农业地区的极化 SAR 图像验证了本文算法的有效性。

关键词: FM 模型;广义 Gaussian 混合模型;Markov 随机场;EM 算法;AHC 聚类
中图分类号: TP751.1 **文献标识码:** A

Remote Sensing Images Hierarchical Clustering Using Markov Random Field and Generalized Gaussian Mixture Models

LIU Xiao-yun, WANG Zhen-song, CHEN Wu-fan, LI Xiao-wen

(School of Automation Engineering University of Electronic Science and Technology of China, Sichuan Chengdu 610054, China)

Abstract: Hierarchical clustering based on the finite mixture model (FM) has shown very good performance in a number of fields. However, it generally requires storage and computing at least proportional to the square of the dimension of observations, so that its application to large datasets has been hindered by time and memory complexity. Another, multispectral images provide detailed data with information in both the spatial and spectral domains. But many clustering methods for multispectral images are based on a per-pixel classification, while uses only spectral information and ignores spatial information. In this work, a new hierarchical clustering based on GFM model suitable for large datasets, e.g., multispectral remote sensing images, is proposed. This algorithm integrates with GFM model with Markov random field. The number of clusters is automatically identified by using the pseudolikelihood information criterion (PLIC). An oversegmented image is obtained by a simple K means clustering method. Instead of starting with singleton clusters, hierarchical clustering is applied on the oversegmented image. Initial parameters of component densities of GFM model can be easily extracted. At last, the accuracy of the algorithm is quantitatively evaluated through simulated test image generated by using Gibbs sampler. The experiment shows a superior performance compared to several other methods, such as K means and classical hierarchical clustering based on the classical FM model. Its validity is also illustrated by using a polarimetric SAR image of Flevoland in the Netherlands.

收稿日期: 2006-05-30; 修订日期: 2006-10-12

基金项目: 国家“973”重点基础研究发展规划 (编号: 2003CB716101) 项目。 Publishing House. All rights reserved. <http://www.cnki.net>

作者简介: 刘晓云 (1963—), 女, 副教授。1993年毕业于电子科技大学, 硕士学位。现主要从事遥感图像处理 and 模式识别方面的研究。

已发表论文 20 余篇。E-mail: xy@uestc.edu.cn

Key words finite mixture model generalized gaussian mixture model Markov random field expectation maximization algorithm agglomerative hierarchical clustering

1 引言

近年来, 基于传统的有限混合模型 (Finite Mixture Model FM) 的分级聚类已广泛应用于生物学、动物学、金融、工业数据等不同领域^[1-4]。然而, 它的计算复杂度与观测数据的平方成正比, 因此, 它在海量数据方面的应用就受到了限制^[1, 4]。另一方面, 多光谱图像数据中同时包含有空间和光谱两方面信息, 但大多数基于像素的多光谱图像聚类方法, 仅利用了像元的光谱信息, 没有考虑邻域像元间存在的统计依赖关系^[5, 6]。Markov 随机场模型 (Markov Random Field MRF) 研究的是个体同其周围近邻之间的相互依赖关系, 刻画了大多数随机变量所服从的统计分布^[6, 7]。尤其表达的图像先验分布知识与特定的分类算法一道, 可以优化分类结果, 更提高了算法的鲁棒性。而广义有限混合模型^[8] (Generalized Finite Mixture Model GFM) 修改了传统 FM 模型的像元标号, 这样有助于通过先验分布直接进行标号信息空间关系的模型化。

本文针对海量数据处理时受到计算时间和存储难度的限制, 以及考虑到多光谱图像数据空间和光谱两方面信息的充分利用, 在广义有限混合模型 GFM 的基础上, 提出了一种新的多光谱遥感图像分级聚类算法, 该算法首先用一个像元的多光谱信息构成该像元的特征矢量, 将该特征矢量看作观测数据, 利用凝聚式分级聚类 (Agglomerative Hierarchical Clustering AHC) 获取 GFM 模型的成分密度的初始参数, 然后在 MRF 随机场模型框架下引入先验分布到 GFM 模型中, 最后采用伪似然信息准则 (Pseudo Likelihood Information Criterion PLIC) 自动确定图像的最佳聚类类别数, 使算法满足多光谱遥感图像数据量需求。

2 广义混合模型

2.1 经典有限混合模型

假设一幅具有 d 个波段的多光谱图像包含有 N 个像元

$$X = (x_1^T, \dots, x_N^T)^T$$

式中, x_i 代表第 i 位置像元在每个波段上的灰度值

所构成的一个 d 维随机变量, 称为该像元的特征值。包含 x_i 的 d 维空间称为特征空间。如果 x_i 的概率密度函数能写成 M 个成分密度的和, 即

$$f(x_i | \pi, \theta) = \sum_{j=1}^M \pi_j f_j(x_i | \theta_j) \tag{1}$$

则 x_i 服从有限混合分布, 其对应的模型为 FM 模型^[3]。其中, $\pi = (\pi_1, \pi_2, \dots, \pi_M)$ 是各个成分密度混合的概率, θ_j 是第 j 个成分密度的参数。如果假设所有成分密度都服从高斯分布, 则所对应的模型为高斯混合模型, d 维的高斯混合模型的参数 θ_j 由均值向量 μ_j 和方差矩阵 Σ_j 决定, $\theta_j = (\mu_j, \Sigma_j)$, 那么

$$f_j(x | \theta_j) = \frac{1}{(2\pi)^{d/2} |\Sigma_j|^{1/2}} e^{-\frac{1}{2}(x-\mu_j)^T \Sigma_j^{-1} (x-\mu_j)} \tag{2}$$

参数 π 满足条件

$$\pi_j \geq 0 \forall j \text{ 且 } \sum_{j=1}^M \pi_j = 1 \tag{3}$$

在式 (3) 约束下, 一般采用迭代方法求取 (1) 式参数 π 和 θ 。即先建立样本的最大似然方程, 然后采用 EM 算法 (Expectation Maximization EM) 对类参数及混合参数进行估计。

假设样本集合 $X = (x_1^T, \dots, x_N^T)^T$ 是独立的, 其似然函数可定义为

$$L(\Psi) = \prod_{i=1}^N f(x_i | \Psi) \tag{4}$$

其中, $\Psi = (\pi, \theta)$, 对数似然函数表示为

$$\begin{aligned} \lg(L(\Psi | X)) &= \lg \left(\prod_{i=1}^N f(x_i | \Psi) \right) \\ &= \sum_{i=1}^N \lg \left(\sum_{j=1}^M \pi_j f_j(x_i | \theta_j) \right) \end{aligned} \tag{5}$$

式 (5) 的直接优化比较困难, 通常采用数据添加算法处理, 即在观测数据的基础上, 加上一些不能观测到的“潜在值”组成“完全数据”, 使优化问题变得比较容易^[9]。EM 算法是一种从“不完全数据”中求解模型分布参数的数据添加方法。这里, 把观测数据 X 考虑为不完全数据, 添加“潜在值” W , w_j^i 代表观测 x_i 属于第 j 类的条件概率, 定义 $Z = \{X, W\}$ 为“完全数据”, 若 W 已知, 则 (5) 式可简化为^[9]

$$\lg L(\Psi) = \sum_{j=1}^M \sum_{i=1}^N w_j^i \lg(\pi_j f_j(x_i | \theta_j)) \tag{6}$$

然后对类参数 θ_j 及混合参数 π 进行估计。参数估计的 EM 算法分为 E 步和 M 步, 其中 E 步计算对数似然函数 (6) 式的期望, M 步选择使期

望最大的参数 Ψ , 当 M 步选择好参数后, 再将选择的参数代入 E 步, 计算期望, 如此反复, 直至收敛到最大似然意义上的最优解为止。

用 EM 算法求解高斯混合模型的迭代公式^[9]如下

$$\pi_j^{(k+1)} = \frac{\sum_{i=1}^N w_j^{i(k)}}{N} \quad (7)$$

$$\mu_j^{(k+1)} = \frac{\sum_{i=1}^N w_j^{i(k)} x_i}{N \pi_j^{(k+1)}} \quad (8)$$

$$\sum_j^{(k+1)} = \frac{1}{N \pi_j^{(k+1)}} \sum_{i=1}^N w_j^{i(k)} (x_i - \mu_j^{(k+1)}) (x_i - \mu_j^{(k+1)})^T \quad (9)$$

$$w_j^{i(k)} = \frac{\pi_j^{(k)} f_i(x_i | \theta^{(k)})}{\sum_{i=1}^M \pi_i^{(k)} f_i(x_i | \theta^{(k)})} \quad (10)$$

2.2 广义有限混合模型

通过上一节分析知, 由 EM 算法估计的参数 $\Psi=(\pi, \theta)$ 均是对观测 X 的全局属性的描述, 并未涉及具体像元的类别标记, 在标记中, 一般是根据最大后验概率准则来估计图像的标记。观测 x_i 的类别标记由下式决定

$$\max \text{prob}(p_i^j = 1 | x_i, \theta^j) \quad (11)$$

由贝叶斯准则

$$\text{prob}(p_i^j = 1 | x_i, \theta^j) = \frac{\pi_j f(x_i | \theta^j)}{\sum_{j=1}^M \pi_j f_j(x_i | \theta^j)} \quad (12)$$

其实, (11) 式并不是最优类别标记估计, 因为标记的确定是在基于 $\Psi=(\pi, \theta)$ 的极大似然估计上, 不是对 $\{p_i^j\}$ 自身的 ML(Maximum Likelihood ML)估计。

从上面对 FM 模型讨论知, 需要更加灵活可变, 更适合图像分类的混合模型, 一些文献中已提出了对传统 FM 模型的修改^[8-10], 文献 [8] 中提出了一种更具有普适性的广义有限混合模型 GFM。与 FM 模型一样, 在 GFM 模型中, x_i 代表图像第 i 像素的观测, $\{f_i(x_i | \theta^j)\}$ 是 M 个密度函数集, 每一个都有它自身的参数矢量 θ^j , GFM 模型定义观测 x_i 的密度函数为

$$f(x_i | p^1, \dots, p^N; \theta^1, \dots, \theta^M) = \sum_{j=1}^M p_j^i f_i(x_i | \theta^j) \quad (13)$$

式中, p_j^i 代表第 i 个像素属于第 j 类概率, p_j^i 满足如下约束条件 $0 \leq p_j^i \leq 1, \sum_{j=1}^M p_j^i = 1 \forall i$ 。假设所有样本的集合 $X=(x_1^T, \dots, x_N^T)^T$ 是统计独立的, 其联合条

件密度

$$f(X | p^1, \dots, p^N; \theta^1, \dots, \theta^M) = \prod_{i=1}^N \sum_{j=1}^M p_j^i f_i(x_i | \theta^j) \quad (14)$$

GFM 模型与传统 FM 模型比较, 有以下几个突出优点:

(1) 利用似然函数 (13) 式可以更容易地导出对像元类别标记的直接 ML 估计。

(2) 更便于空间信息引入, 比如可直接将标号信息的空间关系引入到先验分布 $f(p^1, \dots, p^N)$ 中。

(3) GFM 模型中取 $p_j^i = \pi_j \forall i$ 时, 则 GFM 模型变成传统的 FM 模型。

3 基于 MRF 随机场和 GFM 模型的分级聚类算法

3.1 基于模型的分级聚类

AHC 聚类是一种将 N 个样本划分成 C 个类的树状嵌套分类方式, 两个聚类 Γ_i 和 Γ_j 之间相似性度量常用的有: 最近距离、最远距离、均值距离。普通的 AHC 是从 N 个单点类开始, 算法结束在只有一个类别时。AHC 聚类算法的突出优点是聚类的数目不必先验设定, 聚类结果是形成一棵聚类树。在基于模型的聚类方法中, 为了获取 FM 模型的成分密度的初始参数 $\theta^j(j=1 \sim M)$, 文献 [3] 采用了将聚类树从 M 水平截断的方法, 但该方法计算量巨大, 仅适用于小数据量的聚类问题。为了降低计算成本, 文献 [4] 用随机采样方式构成的样本子集代替原始数据。另一种方式是首先把图像划分成一定数量的同质区域, 然后把 AHC 聚类应用于这些同质区域而不是整幅图像。比如文献 [1] 采用最小生成数方式产生同质区域, 文献 [5] 则采用一种多尺度的似然比检验方式形成同质区域。

针对多光谱遥感图像数据量巨大和人类难以实地考察的特点, 初始同质区域的选取应满足: 全自动的无需人工干预, 运行速度应该尽可能快。本文设计的算法是采用收敛速度快的 K 均值聚类方式来产生 AHC 聚类初始的同质区域。

3.2 MRF 与 GFM 的结合

当把传统 FM 应用于图像分类时, 并不是一个非常完善的模型, 因为它仅仅考虑了光谱信息, 而没有利用任何空间信息。为了克服传统 FM 模型的这个缺陷, 便于空间信息的引入, 文献 [8]、[10] 在 Gibbs 随机场 (Gibbs Random Field GRF) 理论的指导下, 成

功地以 Gibbs 能量的形式引入了空间信息,并应用到了 CT 和 MRI 灰度图像分割中。但它们仍然保留了 FM 模型算法的缺点,即计算量大,限制了算法的应用范围。为满足多光谱遥感图像的大数据量需求,本文设计的算法是在文献 [8] 提出的广义有限混合模型 GFM 基础上,结合分级聚类的设计思想提出的。

考虑类别标记概率图像 $\{p^i\}$, 将其看作 Gibbs 随机场, 则可以通过 p^i 的空间相邻标记概率之间依赖关系, 在 GFM 模型中引入空间信息

$$f(p^1, \dots, p^N) = \frac{1}{Z} \exp(-U(p^1, \dots, p^N)) \quad (15)$$

式中, $U(p^1, \dots, p^N) = \beta \sum_{i=1}^N V_{C_i}(p^1, \dots, p^N)$ 称为能量函数, Z 是归一化常数, β 为正则化参数, $V_{C_i}(\cdot)$ 为定义在第 i 像元势团 C_i 上的势函数, 势团 C_i 由第 i 像元的水平和垂直方向上的二元势团组成。

$$V_{C_i}(p^1, \dots, p^N) = \sum_{m \in C_i} g(u_{im}) \quad (16)$$

式中, $g(u)$ 是一个非负的单增函数, 本文选择 $g(u) = \frac{1}{(1+|u|/\gamma)}$, u_{im} 表示两个标号向量 p^i 和 p^m 间的欧氏距离。

$$u_{im} = |p^i - p^m|^2 = \sum_{j=1}^M (p_j^i - p_j^m)^2 \quad (17)$$

给出了先验分布后, 一个后验对数密度函数可以表示为

$$f(\Psi|X) = \sum_{i=1}^N \lg f(x_i|\Psi) + \lg f(p^1, \dots, p^N) \quad (18)$$

与上节类似, 使用 EM 算法对参数 $\{p^i\}$ 和 $\{\theta^j\}$ 进行 MAP 估计 (Maximum A Posteriori MAP) 时, 在 E 步需要计算隐含变量的条件期望值, 有

$$w_j^{i(k)} = \frac{p_j^{i(k)} f(x_i|\theta^{j(k)})}{\sum_{l=1}^M p_l^{i(k)} f(x_i|\theta^{l(k)})} \quad (19)$$

在 M 步将最大化对应完全数据的对数似然函数

$$Q_{\text{MAP}}(\Psi|\Psi^{(k)}) = \sum_{i=1}^N \sum_{j=1}^M w_j^{i(k)} \{ \lg(p_j^i) + \lg(f(x_i|\theta^j)) \} - \beta \sum_{i=1}^N \sum_{m \in C_i} g(u_{im}) \quad (20)$$

这里 k 表示第 k 次迭代, (20) 式分别关于 μ_j 和 Σ_j 求导, 可得成分分布参数迭代公式 (21)–(22)

$$\mu_j^{(k+1)} = \frac{\sum_{i=1}^N w_j^{i(k)} x_i}{\sum_{i=1}^N w_j^{i(k)}} \quad (21)$$

$$\Sigma_j^{(k+1)} = \frac{\sum_{i=1}^N w_j^{i(k)} (x_i - \mu_j^{(k+1)}) (x_i - \mu_j^{(k+1)})^T}{\sum_{i=1}^N w_j^{i(k)}} \quad (22)$$

同理, (20) 式关于 p_j^i 求导并令为零, 得

$$\left[2\beta \sum_{m \in C_i} \dot{g}(u_{im}) \right] (p_j^{i(k+1)})^2 - \left[2\beta \sum_{m \in C_i} \dot{g}(u_{im}) p_j^m \right] = 0 \quad (23)$$

然而, (23) 式中, 邻域 C_i 包含需更新的标号参数向量 $p_j^{m(k+1)}$, 为了获得 p_j^i 的迭代公式, 邻域 C_i 中用 $p_j^{m(k)}$ 近似 $p_j^{m(k+1)}$, 代入 (23) 式中可以解出

$$p_j^{i(k+1)} = \frac{1}{2 \left[\sum_{m \in C_i} \dot{g}(u_{im}) \right]} \left\{ \left[\sum_{m \in C_i} \dot{g}(u_{im}) p_j^m \right] + \left[\left[\sum_{m \in C_i} \dot{g}(u_{im}) p_j^m \right]^2 + \frac{w_j^{i(k)}}{\beta} \left[\sum_{m \in C_i} \dot{g}(u_{im}) \right] \right]^{1/2} \right\} \quad (24)$$

由于从 (23) 式求得 (24) 式过程中邻域 C_i 采用了 $p_j^{m(k)}$ 近似 $p_j^{m(k+1)}$, 故 (24) 式的迭代计算不能确保 p_j^i 满足约束条件 $0 \leq p_j^i \leq 1, \sum_{j=1}^M p_j^i = 1, \forall i$ 。本文采用文献 [10] 中提出的方法, 先构造一个满足约束条件的超平面, 然后把由 (24) 式求出的 $p_j^{i(k+1)}$ 投影在该超平面, 得到满足约束条件的最接近 $p_j^{i(k+1)}$ 的近似解 $\hat{p}_j^{i(k+1)}$, 用数学式子描述为

$$\begin{aligned} \min_p \quad & \sum_{j=1}^M (\hat{p}_j^i - p_j^i)^2 \\ \text{s.t.} \quad & \begin{cases} \sum_{j=1}^M \hat{p}_j^i = 1 \\ \hat{p}_j^i \geq 0, \quad j = 1, \dots, M \end{cases} \end{aligned} \quad (25)$$

(25) 式是一个非线性规划中的一种特殊情形, 它的目标函数是一个二次实函数, 约束条件是线性约束, 采用二次规划算法求解 (25) 式即可求出 $\hat{p}_j^{i(k+1)}$ 。

3.3 具体算法步骤

第一步 初始化过程。首先应用 K 均值算法获得一个初始的过分类图像以及每类的聚类中心, 过分类图像的类别数远超过对象真实类别数, 然后采用 AHC 分级聚类的思想对该过分类图像进行区域的合并, 以便获得覆盖对象真实类别数的具有 m 个模型的模型集, 以及与其对应的每一模型的初始参数 $\theta^j = (\mu_j, \Sigma_j)$, 模型集对应的类别数分别为 $L, L+1, \dots, L+m-1$ 。这里 L 是覆盖对象真实类别数的最小类别数。

第二步 应用 GFM 模型分类。由上一步分级聚类获得的模型集的初始类参数启动 GFM 模型,采用上一节得到的 EM 迭代公式 (21), (22)和 (24)可求出 μ_j , Σ_j 和 $p_j^{i(k+1)}$, 并使用二次规划计算出满足约束条件的最接近 $p_j^{i(k+1)}$ 的近似解 $\hat{p}_j^{i(k+1)}$ 。

第三步 最佳分类数目确定。利用混合模型进行分类,除了前面混合模型的参数需要估计外,还有最佳类别数的确定问题。

传统的基于 FM 模型的聚类方法通常采用贝叶斯信息准则 (Bayesian Information Criterion, BIC)确定最佳类别数^[2]

$$BIC = 2 \lg L(\Psi^{(k)}) - d_k \lg(N)$$

(26)

式中, d_k 代表模型的参数个数。

从 3.1 节和 3.2 节的讨论可知,本文的算法是在 GFM 模型基础上,利用 MRF 随机场把空间信息引入到似然函数中,这时对数似然函数便成为 (20)式,采用伪似然信息准则 PLIC 来确定最佳类别数^[11]

$$PLIC = 2 \lg Q(\Psi) - d_k \lg(N)$$

(27)

式中, $Q(\Psi)$ 由 (20)式确定。

根据 PLIC 准则,在确定最优的类别数时,依次设定类别数为 1, 2, …, 计算 PLIC 值,当 PLIC 值达到第一个局部极大值点或 PLIC 值出现显著变化时,这时的类别数选定为最佳类别数。

4 实验结果

为了验证本文提出的算法相对于经典聚类算法 K 均值及 FM 聚类算法的优越性,本文设计了两组实验,第一组采用人工合成的仿真图像,便于对算法的分类性能进行定量的分析;第二组采用真实的多

光谱遥感图像,进一步对算法进行主观视觉评判,验证算法的有效性。

实验 1:人工合成仿真图实验

图 1 (a)是由 Gibbs Sampler 生成的仿真图像^[7],图像参数 $\beta_1 = \beta_2 = \beta_3 = \beta_4 = 1$,尺寸 128×128 ,类数 3,迭代次数 50。图 1(b)为叠加了噪声水平为 $\sigma^2 = 0.05$ 的零均值高斯白噪声后的实验图像,图 1(c)为采用本文提出的方法对图 1(b)聚类后的结果。实验中初始分类数设定为 20,然后采用本文提出的方法,依次设定类别数从 1 到 6(覆盖真实类别数 3),比较不同聚类数下的 PLIC 值,结果如图 2 所示,由 PLIC 准则,最佳类别数为第一个出现的局部最大值点。由图 2 可知,第一个局部最大值点出现在类别数为 3 处,所以确定出最优的聚类类别数为 3,这与真实的类别数是一致的。由于该实验中人工合成图像的真实对象是完全清楚的,所以可以对算法的分类效果进行精确的定量分析,表 1—表 3 给出了不同噪声水平下几类算法的总分类精度和 Kappa 系数。通过比较可知,本文提出的算法在不同的噪声水平下分类精度都有提高,并且噪声水平越高分类精度的提高越明显,增强了算法的鲁棒性。

表 1 噪声水平 $\sigma^2 = 0.05$ 分类精度比较
Table 1 Comparison of clustering accuracies with noise level $\sigma^2 = 0.05$

分类方法	总精度 /%	Kappa 系数
K 均值	76.73	0.6509
FM 聚类	90.22	0.8536
本文算法	92.89	0.8933




图 1 人工合成仿真图分类结果

(C)1994-2020 China Academic Electronic Journal Service. All rights reserved. http://www.cnki.net
Fig 1 Clustering result of simulated test image by artificial synthesis
(a) Simulated test image by Gibbs Sampler (b) Simulated test image degraded by noises (c) Clustering result of our algorithm




图 2 实验 1 不同类别数对应的 PLIC 值

Fig 2 PLIC values with different cluster numbers for the first test




图 3 由 C、X、L 波段合成的伪彩色图

Fig 3 False-color image from the X-band C-band and L-band

表 2 噪声水平 $\sigma^2=0.08$ 分类精度比较

Table 2 Comparison of clustering accuracies with noise level $\sigma^2=0.08$

分类方法	总精度 /%	Kappa系数
K 均值	69.84	0.5476
FM 聚类	82.23	0.7631
本文算法	86.72	0.8012

表 3 噪声水平 $\sigma^2=0.10$ 分类精度比较

Table 3 Comparison of clustering accuracies with noise level $\sigma^2=0.10$

分类方法	总精度 /%	Kappa系数
K 均值	66.35	0.4954
FM 聚类	71.97	0.5823
本文算法	80.86	0.7141




图 4 实验 2 不同类别数对应的 PLIC 值

Fig 4 PLIC values with different cluster numbers for the second test


对更平滑,边界分类类别更清晰,这实际上也体现了大块农田图像的特点,大面积的目标占据了图像的主要成分。

5 结 论


针对传统 FM 模型和广义 GFM 模型在遥感图像分类中存在的问题,根据遥感图像相邻像元间存在统计依赖关系的特点,借助 MRF 模型和分级聚类思想,本文提出了基于 MRF 随机场和广义混合模型 GFM 的遥感图像分级聚类算法。该方法不但是出于减少计算量的考虑,更主要的是充分考虑了图像数据的二维特性,在分类过程中保持了像素上下左右的关联特性,从而增强了算法的鲁棒性。这样,分类后的孤立点相对减少,平滑了分类结果,更适合于多光谱遥感图像数据。最后通过两组实验证实了本文算法的有效性。

实验 2. 多光谱遥感图像实验


第二组实验采用一幅真实的多光谱遥感图像,图像尺寸为 340×400 ,图像采自荷兰农业地区 1994 年 4 月 14 日的航空 SAR 图像 (SIR-C/X-SAR) 的一部分,如图 3 所示。这是一幅三波段的伪彩色图像,由 X 波段、C 波段和 L 波段合成。实验中初始分类数设定为 50,分类类别数依次设定为 1, 2, ..., 采用本文提出的方法,比较不同聚类数下的 PLIC 值,结果如图 4 所示,由 PLIC 准则可以确定出最优的聚类类别数为 8。图 5 分别显示了本文提出的算法与传统的 K 均值聚类 and 基于 FM 模型的分级聚类算法分类结果的比较,这里所得到的聚类结果均没有分类后处理过程。由于对象的真实类别事前并不知道,从图像主观评价来看,本文提出的方法相



(a)



(b)



(c)

图 5 类别个数为 8 类的聚类结果

(a) K 均值聚类法; (b) FM 聚类法; (c) 本文提出方法的聚类结果

Fig 5 Clustering results with eight cluster number

(a) K means clustering method (b) FM clustering method

(c) Clustering result of our algorithm

参 考 文 献 (References)

- [1] Posse C. Hierarchical Model-based Clustering for Large Datasets [J]. Comput Graph Statist 2001, 10: 464—486.
- [2] Chris Fraley, Adrian E Raftery. Model Based Clustering Discriminant Analysis and Density Estimation [J]. Journal of the American Statistical Association 2002, 97(458): 611—631.
- [3] Chris Fraley. Algorithms for Model-based Gaussian Hierarchical Clustering [J]. SIAM Journal on Scientific Computing 1998, 20: 270—281.
- [4] Wehrens R, Buydens L M G, Fraley C, et al. Model-based Clustering for Image Segmentations and Large Datasets Via Sampling [R]. Department of Statistics University of Washington 2003.
- [5] Thanh N Tran, Ron Wehrens, Dirk H Hoekman, et al. Initialization of Markov Random Field Clustering of Large Remote Sensing Images [J]. IEEE Trans on Geoscience and Remote Sensing 2005, 43(8): 1912—1919.
- [6] Julian Besag. On the Statistical Analysis of Dirty Pictures [J]. Journal of the Royal Statistical Society, Series B (Methodological), 1986, 48(3): 259—302.
- [7] Stan Z Li. Markov Random Field Modeling in Image Analysis [M]. New York: Springer-Verlag Tokyo 2001.
- [8] Sanjay Gopal S, Thomas J Hebert. Bayesian Pixel Classification Using Spatially Variant Finite Mixtures and the Generalized EM Algorithm [J]. IEEE Trans on Image Processing 1998, 7(7): 1014—1028.
- [9] Dempster A P, Laird N M, Rubin D B. Maximum Likelihood for Incomplete Data Via the EM Algorithm [J]. Journal of the Royal Statistical Society, Series B (Methodological), 1977, 39: 1—38.
- [10] Blekas K, Likas A, Galatsanos N P, et al. A Spatially Constrained Mixture Model for Image Segmentation [J]. IEEE Trans on Neural Networks 2005, 16(2): 494—498.
- [11] Derek C Stanford, Adrian E Raftery. Approximate Bayes Factors for Image Segmentation: The Pseudolikelihood Information Criterion (PLIC) [J]. IEEE Trans on Pattern Analysis and Machine Intelligence 2002, 24(11): 1517—1520.