

文章编号: 1007-4619(2006)01-0058-08

# 一种顾及上下文的遥感影像模糊聚类

张 路<sup>1, 2</sup>, 廖明生<sup>1</sup>

(1. 武汉大学 测绘遥感信息工程国家重点实验室, 湖北 武汉 430079; 2. 香港中文大学地球信息科学联合实验室, 香港)

**摘 要:** 模糊聚类是非监督分类中的一类重要方法。传统的模糊聚类方法应用于遥感影像的非监督分类时, 均未考虑到邻域像元间的统计依赖关系即上下文信息。针对这一缺陷, 在 Markov 随机场模型框架下, 引入了空间隶属度概念, 提出了一种顾及上下文信息的模糊聚类算法, 有效地提高了聚类精度和抗噪声能力。针对需要预先指定聚类个数的问题, 采用了一种兼顾类别内部紧密程度和类别之间分离程度的评价指标, 用以检验聚类结果的有效性, 从而找出最优的聚类个数, 在一定程度上提高了聚类结果的客观性。最后通过实验验证了本文算法的有效性。

**关键词:** 模糊聚类; 上下文信息; 空间隶属度; CWBS 指数; 遥感影像

**中图分类号:** TP751.1 **文献标识码:** A

## Contextual Fuzzy Clustering of Remote Sensing Imagery

ZHANG Lu<sup>1, 2</sup>, LIAO Ming-sheng<sup>1</sup>

(1. State Key Laboratory for Information Engineering in Surveying, Mapping and Remote Sensing

Wuhan University, Wuhan 430079, China;

2. Joint Laboratory for Geoinformation Science, the Chinese University of Hong Kong, Hong Kong, China)

**Abstract:** Fuzzy clustering is an important method in unsupervised classification. In application of traditional fuzzy clustering algorithm to unsupervised classification of remote sensing imagery, pixels are assumed to be independent of each other and their fuzzy memberships are determined individually, so that context information, i.e. statistical dependencies among neighboring pixels, are not taken into account. Aiming at this problem, an improved fuzzy clustering algorithm considering context information is put forward by incorporating the concept of spatial fuzzy membership under MRF framework. In this way, accuracy and reliability of clustering can be improved upon traditional ones.

To evaluate the quality of clustering results, a validation index considering both intra-cluster compactness and inter-cluster separation is introduced. Furthermore, it is employed to find out naturally optimal cluster numbers and promote objectivity of clustering results. Finally, an experiment on real remote sensing imagery is carried out to demonstrate the effectiveness of our proposed scheme.

**Key words:** fuzzy clustering; context information; spatial fuzzy membership; CWBS index; remote sensing imagery

## 1 引 言

遥感影像分类一直都是遥感应用领域的热点问

题。常用的分类方法可归纳为监督分类和非监督分类两大类型,前者精度一般比较高,但需要高质量的训练样本,而很多情况下训练样本难以获取;后者无需训练样本数据,直接根据待分数据个体间的相似

收稿日期: 2004-07-20; 修订日期: 2004-10-08

基金项目: 国家重点基础研究发展计划 (编号 2003CB415205)

作者简介: 张 路 (1975—), 男, 武汉大学摄影测量与遥感专业在读博士研究生。现为香港中文大学地球信息科学联合实验室博士后研究员, 主要从事遥感数据处理和应用方面的研究。已公开发表论文 5 篇。E-mail: zhangh@mail.iesmars.wtustm.edu.cn

性测度进行类别划分,再由人工识别所得各类别对应的实际地物类型,因而自动化程度较高,但难以保证分类精度<sup>[1]</sup>。模糊聚类是非监督分类中的一种重要方法,它以 Zadeh 创立的模糊集和模糊数学理论<sup>[2]</sup>为基础,认为待分数据集中的每个样本都以一定的隶属度归属于每个类别,隶属度越大,归属程度越高,通过迭代计算可以估计出各类别的中心位置和隶属度,然后可按一定的规则去模糊化,将模糊聚类结果转化为确定性分类。这种方法已经在模式识别领域得到了广泛应用<sup>[3-5]</sup>。

遥感影像反映了地球表面信息,由于地球表层系统的复杂性和开放性,遥感信息传递过程中的局限性以及遥感信息之间的复杂相关性造成了遥感信息的多维多解和不确定性<sup>[6]</sup>。因此,遥感影像的像元所包含的光谱信息往往是多种地物目标的综合反映,从而具有模糊性,适合于采用模糊聚类方法对其进行分类。例如程涛等提出了“模糊空间目标”的概念,用以表达地理目标的复杂性和多样性<sup>[7]</sup>。Zhang JX 等应用模糊聚类方法对遥感影像中的市郊土地覆盖进行了分类,并通过对比实验证实模糊聚类比传统的硬聚类具有优势<sup>[8]</sup>。但传统模糊聚类方法应用于遥感影像的分类时存在一个明显的问题,那就是只利用了像元的光谱信息进行聚类,各像元隶属度的确定是相互独立的,而事实上在遥感影像中,相邻的像元趋向于属于相同或相近的地物类型,也就是说相邻像元间存在着统计意义上的相互依赖关系,通常称为上下文信息<sup>[9,10]</sup>。若能充分利用上下文信息,就可以在在一定程度上提高模糊聚类的结果精度。一种常见的策略是先在光谱空间中做聚类,再在地理空间中对聚类结果进行后处理,可选用平滑滤波、概率松弛、数学形态学等手段<sup>[11,12]</sup>,这种策略的缺陷在于没有直接在动态聚类过程中利用空间相关性,因而得到的聚类中心可能出现偏差。

$$\begin{cases} m_j^{t+1} = \frac{\sum_{i=1}^n [\mu^t(i, j)]^b x_i}{\sum_{i=1}^n [\mu^t(i, j)]^b}, & j = 1, 2, \dots, c \\ \mu^{t+1}(i, j) = \frac{\left( \frac{1}{\|x_i - m_j^{t+1}\|^2} \right)^{1/(b-1)}}{\sum_{k=1}^c \left( \frac{1}{\|x_i - m_k^{t+1}\|^2} \right)^{1/(b-1)}}, & i = 1, 2, \dots, n; j = 1, 2, \dots, c \end{cases} \quad (2)$$

式中的上标  $t$  和  $t+1$  分别代表当前和下一次迭代过程。在计算隶属度时,当某个样本与一个聚类中心重合时,将该样本对这个类别的模糊隶属度设为 1,

本文采用了一种不同的策略,借助 Markov Random Field (MRF) 模型来描述上下文信息,相应地构造了一种新的空间隶属度,并与普通的光谱隶属度相结合,得到总体隶属度用于迭代更新聚类中心。此外,传统模糊聚类中聚类个数通常是人为指定的,带有很强的经验性,不一定能够反映真实的地物类别数目。为此,本文引入了一种聚类结果有效性的评价指标,用于确定最优的聚类个数,以提高模糊聚类结果的客观性。最后通过实验验证了本文方法的有效性。

## 2 传统模糊聚类

在阐述顾及上下文信息的模糊聚类方法之前,有必要先回顾一下传统的模糊 C 均值聚类算法<sup>[3]</sup>。

标准的模糊 C 均值聚类算法 (Fuzzy C Means FCM) 定义如下:给定  $n$  个  $d$  维观测样本  $\{x_1, x_2, \dots, x_n\}$ , 要将它们划分成  $c$  ( $c \geq 2$ ) 个类别,  $m = \{m_1, m_2, \dots, m_c\}$  为这  $c$  个类别的中心,模糊隶属度矩阵  $U$  (大小为  $n \times c$ ) 的每个元素  $\mu(i, j)$  ( $i=1, 2, \dots, n; j=1, 2, \dots, c$ ) 代表样本  $x_i$  对于类  $j$  的隶属度,在  $[0, 1]$  区间上取值,并且满足归一化条件  $\sum_{j=1}^c \mu(i, j) = 1$ ,  $i=1, 2, \dots, n$ 。聚类的准则是最小化目标函数

$$J(m, U) = \sum_{j=1}^c \sum_{i=1}^n [\mu(i, j)]^b \|x_i - m_j\|^2 \quad (1)$$

这个函数表示了所有样本到所有聚类中心的模糊化距离平方和,式中参数  $b$  ( $b > 1$ ) 为模糊化程度调节因子,称为模糊度参数,  $\|x_i - m_j\|$  表示样本  $x_i$  到聚类中心  $m_j$  的距离,通常采用欧式距离。使目标函数最小化的聚类中心和隶属度矩阵采用期望最大化算法 (Expectation Maximization, EM) 来迭代求解,计算公式如下:

而对其他类别的隶属度则设为 0。参数  $c$  和  $b$  由用户在算法运行前人为指定。聚类中心  $m$  的初始值可以随机选取或人为指定。迭代过程收敛时得到的

$m$  和  $U$  值就是模糊聚类的结果,可以通过去模糊化处理得到确定性分类结果。

在待样本集包含野值 (Outliers) 的情况下,由于隶属度归一化条件的作用,标准的模糊  $C$  均值聚类算法得到的结果可能不理想,因此人们提出了一种改进的模糊  $C$  均值聚类算法<sup>[3]</sup>,以提高聚类算法的稳健性 (Robustness)。改进算法的基础是放松的归一化

条件,使得  $\sum_{j=1}^c \sum_{i=1}^n \mu(i, j) = n$ , 即所有样本对各类的隶属度总和为  $n$ 。在此条件下,更新聚类中心的计算公式不变,而计算更新隶属度的公式变为:

$$\mu^{t+1}(i, j) = \frac{n \left[ \frac{1}{\|x_i - m_j^{t+1}\|^2} \right]^{1/(b-1)}}{\sum_{k=1}^c \sum_{l=1}^n \left[ \frac{1}{\|x_l - m_k^{t+1}\|^2} \right]^{1/(b-1)}}, \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, c \quad (3)$$

### 3 顾及上下文的模糊聚类

无论是标准的还是改进的模糊  $C$  均值聚类算法,在用于遥感影像非监督分类时,只利用了像元的光谱信息,而没有考虑邻域像元间的统计相关性,即上下文信息。如果在聚类过程中对这一信息加以利用,就有可能提高聚类结果的可靠性。这里我们采用了 Markov 随机场模型 (Markov Random Field, MRF) 来表达和处理上下文信息。MRF 研究的是个体同其周围近邻之间的相互依赖关系,描述的是一种局部特征,很适合于数字图像处理,在图像分割、图像分类、图像模拟、图像恢复等方面都得到了广泛应用<sup>[9, 13]</sup>。MRF 本身没有显式的表达式,然而根据 Hammersley-Clifford 定理, MRF 与 Gibbs 随机场模型 (Gibbs Random Field, GRF) 之间存在一一对应关系,因此可用确定 Gibbs 分布的能量函数来描述 MRF 的局部特征,从而简化了 MRF 模型<sup>[9]</sup>。

在 MRF 模型框架下,引入一种新的隶属度,称为空间隶属度 (Spatial Membership),用以表述上下文信息,相应地,称由像元光谱信息得到的隶属度为光谱隶属度 (Spectral Membership)。空间隶属度实际上是一个像元在给定邻域各像元状态下属于一个聚类的条件概率,定义如下:

$$\mu_{\text{spat}}(i, j) = \frac{1}{Z} \exp\{-\beta E_N(j)\} \quad (4)$$

式中  $E_N(j) = \sum_{N_k \in N} E(N_k, j)$  为 MRF 能量函数,它等于邻域内所有簇 (Clique)  $N_k$  相对于类  $j$  的势函数之

和。所谓“簇”就是指由邻域及中心像元组成的区域中相邻像元所构成的集合,像元的个数称为簇的元数。 $\beta$  是一个调节邻域信息影响程度的权重参数, $\beta=0$  意味着不考虑空间上下文信息。 $Z$  是归一化因子,用来确保空间隶属度的取值范围与普通的隶属度一致。簇  $N_k$  相对于类  $j$  的势函数  $E(N_k, j)$  定义为

$$E(N_k, j) = \beta_k \sum_{x \in N_k} \{1 - \mu_{\text{spec}}(x, j)\} \quad (5)$$

其中,  $\mu_{\text{spec}}(x, j)$  就是前述的光谱隶属度,  $x$  为  $i$  的属于簇  $N_k$  的邻域像元,  $\beta_k$  为簇  $N_k$  的权重参数。为简单起见,这里只考虑二元簇,并且对邻域内所有簇赋予相等的权值  $1/|N|$ , 其中  $|N|$  表示邻域  $N$  中的像元个数。这样就得到简化的能量函数

$$E_N(j) = \frac{1}{|N|} \sum_{x \in N} \{1 - \mu_{\text{spec}}(x, j)\} \quad (6)$$

从以上定义可以看出,中心像元的空间隶属度是由邻域像元的状态,即光谱隶属度来决定的。当邻域中的像元对同一类具有较高的隶属度时,中心像元对该类的空间隶属度也较高,反之亦然,这也就是说同质区域比异质区域出现的概率大,因而可以起到抑制噪声和平滑的作用<sup>[14]</sup>。

在模糊聚类的每一次迭代中,先由像元光谱值计算各像元的光谱隶属度,再按 (6) 式由光谱隶属度计算得到空间隶属度,然后将两种隶属度结合起来,生成总体隶属度以用于下一次迭代估计各聚类中心。总体隶属度的计算公式为:

$$\mu(i, j) = \frac{\mu_{\text{spec}}(i, j) \mu_{\text{spat}}(i, j)}{\sum_{k=1}^c \mu_{\text{spec}}(i, k) \mu_{\text{spat}}(i, k)}, \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, c \quad (7)$$

其中  $\mu_{\text{spec}}(i, j)$  和  $\mu_{\text{spat}}(i, j)$  分别代表像元  $x_i$  对于类  $j$  的光谱和空间隶属度。这样得到的聚类算法我们称为顾及空间上下文的模糊  $C$  均值聚类 (Spatial-contextual Fuzzy C-Means, SFCM)。

### 4 聚类结果评价

模糊聚类是一种非监督分类方法,聚类类别个数是预先由人为指定的,不一定与真实的类别数相同,因此其聚类结果的有效性需要客观的验证评价。一个好的聚类结果通常应该具有以下两点性质:(1)各类别内部的密度尽可能大,即同类样本集中程度高;(2)不同类别之间的距离尽可能大,即异类样本分离程度高。据此,我们引入了一种综合了这

两条准则的评价指标函数,以比较选取不同类别个数的情况下所得到的聚类结果的有效性,从而确定最优的聚类类别个数。在这一比较过程中,除类别个数之外的参数都固定不变,以保证可比性。

我们选取的评价指标函数是由 M. Ramze Rezaee等提出的,称为 CWBS 指数 (Compose Within and Between Scattering), 记作  $V_{CWBS}$ 。这一评价指标的有效性和相对于其他常用评价指标的优越性已经通过实验得到了证实<sup>[15]</sup>。这个指数定义如下:

$$V_{CWBS}(m, U) = \alpha \text{Scat}(c) + \text{Dist}(c) \quad (8)$$

式中  $c$  为类别个数。公式左边的参数  $m$  和  $U$  分别代表模糊聚类算法得到的聚类中心和模糊隶属度矩阵,右边由两部分组成,  $\text{Scat}$  代表的是类别内部的平均密度,值越小表示密度越大,紧密程度越高;  $\text{Dist}$  则表示了类别之间的平均距离,值越小表示距离越大,分离程度越高;  $\alpha$  是权重因子,用于平衡两项指标,取值为最大聚类类别个数所对应的  $\text{Dist}$  值。  $\text{Scat}$  和  $\text{Dist}$  指标的计算公式为:

$$\begin{cases} \text{Scat}(c) = \frac{1}{c} \sum_{i=1}^c \frac{\|\sigma(m_i)\|}{\|\sigma(X)\|} \\ \text{Dist}(c) = \frac{D_{\max}}{D_{\min}} \sum_{k=1}^c \left[ \sum_{z=1}^c \|\mathbf{m}_k - \mathbf{m}_z\| \right]^{-1} \end{cases} \quad (9)$$

式中  $\sigma(X)$  和  $\sigma(m_i)$  分别表示样本总体和属于类别  $i$  (聚类中心为  $m_i$ ) 的样本在各维上的方差构成的向量,  $\|\cdot\|$  为求向量的范数操作。  $D_{\max}$  和  $D_{\min}$  分别表示聚类中心之间的最大和最小距离。

寻找最优聚类类别个数,实际上就是在合理的范围内找出对应于最小的  $V_{CWBS}$  值的类别个数,作为最终的聚类类别个数,这样就在一定程度上提高了聚类结果的客观性。

## 5 实验结果与讨论

我们从 Erdas Imagine 软件附带的示例遥感影像数据中,选取了覆盖美国 Lanier 地区的一幅 Landsat5 TM 影像作为实验数据,选用的波段为 TM3, TM4, TM5, 裁剪出大小为  $256 \times 256$  像元的研究区域影像,采用 TM5, TM4, TM3 波段假彩色合成显示如图 1。通过直观的目视判读可以看出,研究区域内包含 3 种基本的地物覆盖类型:城镇、植被和水体。

为了验证本文提出的顾及空间上下文的模糊 C 均值聚类算法相对于传统的模糊 C 均值聚类算法

的优越性,我们设计了一组实验,分别实现了这两种算法。首先通过计算比较不同聚类个数下的 CWBS 指数,来确定最优的聚类类别数。然后按照这一最优聚类类别数分别采用 FCM 和 SFCM 方法进行聚类。聚类过程中选用了多组模糊度参数  $b$  和权重参数  $\beta$  的取值,以考察这两个参数对聚类结果的影响。同时为了检验这两种聚类算法对噪声的敏感性,通过添加随机噪声,合成了两幅被噪声污染的影像,也分别采用这两种算法进行了聚类。

为了确定最优的聚类个数,我们依次设定聚类个数  $c$  为 2, 3, ..., 10, 在  $c$  的每个取值下,对原始影像分别进行 FCM 和 SFCM 聚类,聚类过程中除  $c$  以外的参数均保持不变。对所有这些聚类结果,按照公式 (8) 和 (9), 分别计算其 CWBS 指数,得到如图 2 所示趋势图。图中上下两条折线分别表示了随着聚类个数的不同, FCM 和 SFCM 聚类结果所对应的  $V_{CWBS}$  指数值的变化趋势。由图 2 容易看出,对于两种模糊聚类算法, CWBS 指数均在聚类个数  $c$  为 3 时达到最小,这意味着聚类个数为 3 时聚类结果的有效性最好,因此最优聚类类别数应为 3。随后的模糊聚类实验都是在分为 3 类的前提下展开的。同时,在聚类个数和其他参数均相同的情况下, SFCM 聚类结果的  $V_{CWBS}$  指数值较 FCM 聚类结果更小,这初步说明了 SFCM 相对于 FCM 更为合理有效。

Erdas Imagine 软件同时也提供了一幅该试验区的参考分类图<sup>[16]</sup>,如图 3。图中分别以不同的灰度级表示了 3 种地物类别,最亮一级代表城镇,最暗的为水体,灰色的代表植被。这一参考分类图被用来进行聚类结果的精度评估。

为了比较验证两种模糊聚类算法对随机噪声的稳健性,我们对原始影像分别添加了标准偏差为 8 的加性高斯白噪声 (White Gaussian Noise) 和标准偏差为 0.77 的乘性斑点噪声 (Speckle Noise), 生成了两幅被噪声污染的影像,作为对比实验数据,分别如图 4(a) 和图 4(b) 所示。这两幅影像均采用 TM5, TM4, TM3 波段假彩色合成显示。

在聚类个数为 3 的前提下,对原始影像和两幅噪声污染的影像分别都采用 FCM 和 SFCM 进行了聚类。为提高计算速度起见,各聚类中心的初值由人工从影像中挑选出的三个像元来确定。事实上,模糊聚类算法对聚类中心的初值选取不敏感,实验证明,采用随机选取初始值的方法得到的聚类结果与人工确定初始值得到的结果基本一致,但聚类过程要求的迭代次数会增多,相应的运算时间也会大



图 1 试验区原始影像数据

Fig 1 Original image data of test site

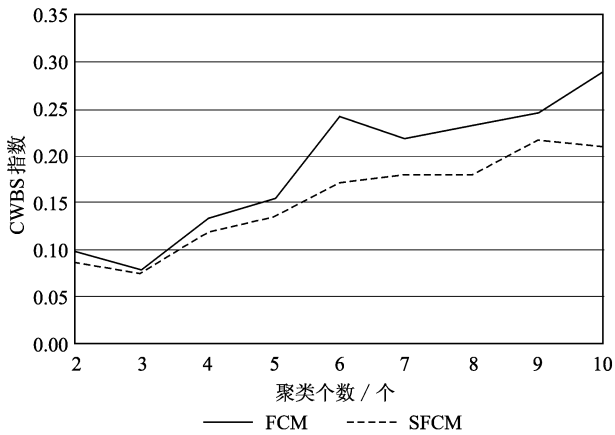




图 2 不同聚类个数的聚类结果评价

Fig 2 Evaluation of clustering results with different cluster numbers



(a)



(b)

图 4 随机噪声污染的影像数据

Fig 4 Image data degraded by random noises





图 3 试验区参考分类图


Fig 3 Reference classification map of test site

大增加。隶属度的初始值由公式(2)中第二式计算得到。


图 5(a)~(f) 依次为三幅实验影像分别采用 FCM 和 SFCM 得到的一组聚类结果图, 聚类算法中的模糊度参数  $b$  取值均为 1.5, 权重参数  $\beta$  取值均为 4, 以便于比较。其中 (a), (c), (e) 为 FCM 聚类结果, 而 (b), (d), (f) 为 SFCM 聚类结果。这些结果图都是经过了去模糊化处理得到的, 即对于任一像元, 如果其对于各类别的隶属度中的最大值高于某一指定阈值, 则将其标记为对应最大隶属度的类别, 否则标记为无法识别类, 这里我们将去模糊化阈值取为 0.6。结果图中那些零星的黑点即为无法确




(a)




(b)




(c)



(d)



(e)



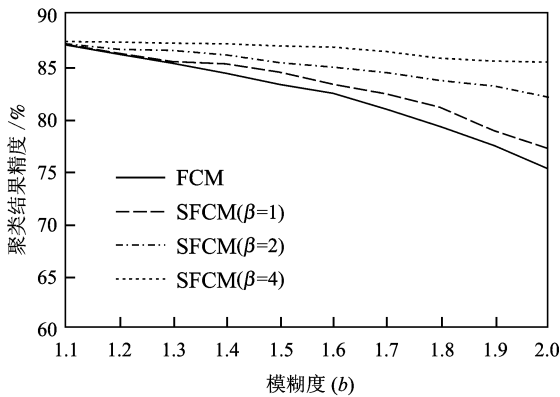
(f)

图 5 FCM 和 SFCM 模糊聚类结果图 ( $b=1.5, \beta=4$ )


Fig 5 Result maps of FCM and SFCM algorithms ( $b=1.5, \beta=4$ )

定类别的像元。对比两种模糊聚类算法的结果图,可以清楚地看出在同样的参数条件下, SFCM 聚类结果中无法确定类别的像元数量较 FCM 的结果大为减少,对于两幅噪声污染的影像这一点尤为明显。这就说明了 SFCM 相对于 FCM 更为稳健有效。


图 6(a)–(c) 分别描述了不同参数取值下两种算法对三幅影像聚类结果的精度,这里的精度是



(a) 原始影像



(b) 高斯噪声污染影像



(c) 斑点噪声污染影像

图 6 不同参数取值下 FCM 和 SFCM 模糊聚类的结果精度

Fig 6 Clustering accuracies of FCM and SFCM with different parameter values

通过将聚类结果与参考分类图进行比较后统计得到的。可以看出,在同样的模糊度参数取值下, SFCM 均较 FCM 的精度高,尤其是存在随机噪声污染时,这就说明了 SFCM 的有效性和抗噪声能力。同时,随着模糊度参数  $b$  逐渐增大,两种算法的聚类结果精度通常都会降低;对于 SFCM,模糊度参数固定时,权重参数  $\beta$  越大,聚类结果精度相对越高,但当  $\beta$  越来越大时,聚类精度将趋于饱和,无法进一步提高,甚至会出现下降的情况。当然这些结果都是在有限的实验数据和参数取值范围内获得的,需要进一步的实验验证。而最优的模糊度参数  $b$  和权重参数  $\beta$  的选取问题也尚待深入研究。

## 6 结 论

针对传统模糊聚类方法在遥感影像非监督分类时存在的问题,根据遥感影像相邻像元间存在统计依赖关系的特点,借助 MRF 模型,引入了空间隶属度的概念,得到了一种顾及空间上下文的模糊聚类算法。此外,针对模糊聚类需要预先指定聚类类别个数的问题,引入了一种兼顾了类别内部紧密程度和类别之间分离程度的评价指标,用以验证聚类结果的有效性,从而找出最优的聚类类别个数。最后通过实验证实了本文算法的有效性。

## 参 考 文 献 (References)

- [1] Jensen J R. Introductory Digital Image Processing: A Remote Sensing Perspective[M]. New Jersey: Prentice Hall, 1996.
- [2] Zadeh L A. Fuzzy Sets[J]. Information and Control, 1965, 8(3): 338–353.
- [3] Bian Z Q, Zhang X G, Zhang C S, et al. Pattern Recognition [M]. Beijing: Tsinghua University Press, 2000. [边肇祺, 张学工, 张长水等. 模式识别 [M]. 北京: 清华大学出版社, 2000.]
- [4] Baraldi A, Blonda P. A Survey of Fuzzy Clustering Algorithms for Pattern Recognition: Part I[J]. IEEE Transactions on Systems, Man, and Cybernetics Part B: Cybernetics, 1999, 29(6): 778–785.
- [5] Baraldi A, Blonda P. A Survey of Fuzzy Clustering Algorithms for Pattern Recognition: Part II[J]. IEEE Transactions on Systems, Man, and Cybernetics Part B: Cybernetics, 1999, 29(6): 786–801.
- [6] Chen S P. Spatio-temporal Dimension for Earth Observing with Remote Sensing[J]. Journal of Remote Sensing, 1997, 1(3): 167–171. [陈述彭. 遥感地学分析的时空维 [J]. 遥感学报, 1997, 1(3): 167–171.]
- [7] Cheng T, Lin H. Concept Models and Applications of Fuzzy

- Objects[J]. *Journal of Remote Sensing*, 2001, **5**(4): 248—253 [程涛, 林晖. 模糊目标的概念模型和应用[J]. 遥感学报, 2001, **5**(4): 248—253 ]
- [ 8 ] Zhang J X, Foody G M. A Fuzzy Classification of Sub-urban Land Cover from Remotely Sensed Imagery [ J ]. *Int J Remote Sensing*, 1998, **19**(14): 2721—2738.
- [ 9 ] Tso B, Mather P M. Classification Methods for Remotely Sensed Data[M]. Basingstoke: Taylor & Francis, 2001.
- [ 10 ] Richards A J, Jia X P. Remote Sensing Digital Image Analysis An Introduction, 3rd Edition[M]. New York: Springer, 1999.
- [ 11 ] Wu F Y. The Potts Model[J]. *Reviews of Modern Physics* 1982, **54**(1): 235—268.
- [ 12 ] Liew A, Leung S H, Lau W H, et al. Segmentation of Color Lip Images by Spatial Fuzzy Clustering[J]. *IEEE Trans on Fuzzy Systems* 2003, **11**(4): 542—549.
- [ 13 ] Zheng Z B. Markov Random Field Method for Image Analysis[M]. Wuhan: W TUSM Press, 2000 [郑肇葆. 图像分析的马尔科夫随机场方法[M]. 武汉: 武汉测绘科技大学出版社, 2000 ]
- [ 14 ] Hilger K B, Nielsen A A, Larsen R, et al. A Scheme for Initial Exploratory Data Analysis of Multivariate Image Data [ A ]. Proceeding of the 12th Scandinavian Image Analysis Conference [ C ]. Bergen, Norway, June 2001.
- [ 15 ] Rezaee A R, Lelieveldt B P F, Reiber J H C. A New Cluster Validity Index for the Fuzzy C-mean [ J ]. *Pattern Recognition Letters* 1998, **19**(3): 237—246.
- [ 16 ] Leica Geosystems GIS & Mapping LLC. Erdas Imagine Tour Guide [ R ]. Atlanta: Leica Geosystems GIS & Mapping LLC, 2003.