

# 基于高斯云变换的遥感图像多粒度聚类

刘旋 王国胤 罗小波

(重庆邮电大学计算智能重庆市重点实验室 重庆 400065)

**摘要** 遥感图像技术的迅猛发展,使得传统聚类方法的局限性日益凸显。针对其信息量大、结构复杂等特点,从多粒度、多层次的角度来分析与理解地学现象,能够更好地解决遥感图像的自适应聚类问题。基于云模型与混合高斯相结合的高斯云变换是一种求解多粒度问题的新方法,能够解决问题域中多粒度的生成问题,但是其时间复杂度较高以及对噪声敏感等缺点,导致对遥感图像的聚类结果不理想。因此提出一种改进的高斯云变换方法,首先通过 K-Means 聚类优化初始粒度的选择,其次结合幅度云综合对粒度跃升策略进行改进,然后使用一种隶属度距离进行粒度的区域划分,最终对遥感图像进行聚类。实验结果验证了所提方法的正确性和有效性。

**关键词** 遥感图像,高斯云变换,多粒度,图像聚类

**中图分类号** TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.09.004

## Multi-granularity Clustering of Remote Sensing Image Based on Gaussian Cloud Transformation

LIU Xuan WANG Guo-yin LUO Xiao-bo

(Chongqing Key Laboratory of Computational Intelligence, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

**Abstract** With the development of remote sensing image technology, the limitation of the traditional image analysis methods have become increasingly prominent. From the perspective of multi-granularity and multi-level, we can solve the adaptive clustering problem of remote sensing images better, with large amount of information and complex structures. Gaussian cloud transformation which is based on cloud model and Gaussian mixture model is a new model of multi-granularity method. It can extract multiple concepts from different granularities in a problem domain. However, due to its time complexity and noise sensitivity, the clustering result of remote sensing images is not ideal. An improved Gaussian cloud transformation method was proposed in this thesis. First, K-Means is used to optimize the selection of initial grain size and amplitude cloud comprehensive is used to modify the adaptive concept abstraction strategy. Then, the granularity division is gotten by using a membership distance. Finally, the method is applied to remote sensing images. The experimental results show the correctness and effectiveness of the proposed method.

**Keywords** Remote sensing image, Gaussian cloud transformation, Multi-granularity, Image clustering

## 1 引言

近年来,随着遥感技术的迅猛发展,人们获取遥感图像数据的手段和能力越来越强。遥感图像以其覆盖面积大、时效性强等特点,成为了重要的数据来源<sup>[1]</sup>。然而,遥感图像自动化处理技术远远落后于信息获取技术的发展,据统计,获取的遥感图像数据被计算机处理的总量不足5%,远远不能满足应用领域对遥感图像日益增长的应用需求,而如何提高遥感图像的分类精度是最迫切的问题之一<sup>[2]</sup>。

多粒度理论是模拟人们处理复杂问题时从不同层次观察问题的一种策略。其中云模型作为粒计算的重要理论之一<sup>[3]</sup>,因在处理不确定性和多粒度方面展现出了优势而被用于图像聚类分析中。目前,云模型已经在图像处理、遥感图像地物提取等领域得到了成功的应用。马鸿耀等利用云模型实

现了彩色图像的多粒度聚类<sup>[4]</sup>;王国胤、许昌林等提出了一种新的逆向云变换算法,该算法在图像聚类中取得了较好的效果<sup>[5]</sup>;王佐成等利用云模型实现了遥感图像中模糊对象的表达,对图像的灰度和梯度等数字特征生成云模型<sup>[6]</sup>;巫兆聪等提出了一种顾及几何特征的云模型遥感图像分割方法<sup>[7]</sup>。但是上述方法没有考虑到遥感图像的多粒度、多尺度、结构复杂等特点,而且遥感图像上地物种类众多,且呈现层次性、结构化特征,不同地物类别区域的粒度存在较大差异,导致在不同粒度下的分类和精度显著不同<sup>[8]</sup>。因此,从多粒度、多层次来分析与理解地学现象能够更好地解决遥感图像中的粒度和不确定性问题,实现遥感图像的自动化信息提取。而自适应高斯云变换<sup>[12]</sup>是研究多粒度解决问题的新方法,主要处理问题求解时粒度的选择和不同粒度之间的转换,能够解决遥感图像的自动化信息提取问题,但是由于其处理大规模数据时运

到稿日期:2016-07-04 返修日期:2016-09-23 本文受国家自然科学基金(61272060)资助。

刘旋(1991-),男,硕士生,主要研究方向为智能信息处理、多粒度模型等;王国胤(1970-),男,博士,教授,博士生导师,主要研究方向为粗糙集理论、数据挖掘、不确定性人工智能、认知计算等;罗小波(1980-),男,博士,主要研究方向为遥感图像处理等。

算效率较低,而且对噪声敏感,导致对最终概念的提取不准确。因此本文提出一种基于改进的高斯云变换的遥感图像多粒度聚类方法。首先通过结合 K-Means 聚类和高斯混合模型来提升算法效率,对遥感图像进行不同粒度空间下的信息粒化;然后结合一种概念云综合方法优化多粒度层次结构,通过粒间的交叠程度来合并粒度;最后使用一种加权距离公式对遥感图像进行不同粒度下的概念抽取,从而实现遥感图像的自动聚类。

## 2 高斯云变换模型

### 2.1 高斯云模型

云模型是一个定性、定量的双向变换认知模型,能够很好地描述定性概念与定量数据之间的转换关系,其通过概率统计研究人类认知过程的模型和方法。其中基于高斯分布的高斯云具有普适性,大量社会和自然科学中定性知识的云期望曲线都近似服从高斯分布。云模型的定义描述如下。

定义 1<sup>[3]</sup>  $C$  是论域  $U$  上的定性概念,定量值是定性概念  $C$  的一次随机实现,则  $x$  对应的确定度  $\mu(x) \rightarrow [0, 1]$  是有稳定倾向的随机数,如式(1)所示:

$$\begin{aligned} \mu: U \rightarrow [0, 1] \\ \forall x \in U, x \rightarrow \mu(x) \end{aligned} \quad (1)$$

则  $x$  在论域  $U$  上的分布称为云,记为  $C(x)$ ,每一个  $x$  称为一个云滴。高斯云用期望  $Ex$ 、熵  $En$  和超熵  $He$  3 个数字特征来表征一个概念,熵和超熵是概念的不确定性度量。与高斯分布相比,高斯云引入超熵来衡量标准差的不确定性,其中熵是标准差的期望,超熵是标准差的标准差,熵和超熵共同构成了高斯云偏离高斯分布的衡量指标<sup>[9]</sup>。因此,可以利用超熵和熵来衡量高斯云所表征概念形成共识的程度。在云模型理论的定义中,论域  $U$  可以是一维或多维的。云模型既反映了隶属程度的不确定性,又反映了样本出现的随机性,较好地揭示了模糊性和随机性之间的关联。例如,在给定  $Ex=0, En=3, He=0.3, n=1000$  生成云时,得到的高斯云如图 1 所示。




图 1 高斯云

由云模型的定义可知,云滴对概念的贡献度是不同的,而高斯云的云滴根据其贡献程度可以划分为骨干元素、基本元素、外围元素和弱外围元素<sup>[3]</sup>。论域中对定性概念有贡献的云滴主要落在区间  $[Ex-3En, Ex+3En]$ ,这就是高斯云的“3En 规则”。高斯云在表征概念时,定义  $3He/En$  为一个概念的含混度(Confusion Degree, CD),用来衡量概念外延的交叠程度。若含混度为 0,则概念外延汇聚,形成共识,是一个成熟概念;若含混度为 1,则概念外延严重发散,难以形成共识,概念雾化。云模型作为一个概念认知模型,主要

研究含混度 CD 在 0~1 之间的情况,  $CD > 1$  时的云滴群已经不能称为一个概念<sup>[9]</sup>。按照含混度的范围,可分为骨干元素交叠、基本元素交叠、外围元素交叠和弱外围元素交叠,在保证每个概念的含混度  $CD \leq 0.5004$  时,它与相邻概念之间的基本区域不交叠,即概念划分清晰。

云变换是指在论域中按照既定的规则将数据的频率分布函数进行数学变换,生成多个原子云的叠加集合。数学表达式如下<sup>[10]</sup>:

$$f(x) \rightarrow \sum_{i=1}^n (a_i \cdot C(Ex_i, En_i, He_i)) \quad (2)$$

其中,  $a_i$  表示幅度系数,  $n$  表示变换后云模型的数量。

### 2.2 自适应高斯云变换

高斯混合模型(GMM)是概率统计中的一种重要方法,可以将问题域中整个频率分布函数转换成多个高斯分布的叠加。由  $M$  个高斯分布叠加而成的 GMM 的数学形式如下:

$$p(x|\Theta) = \sum_{i=1}^M a_i p_i(x|\theta_i) \quad (3)$$

其中,  $p_i(x|\theta_i)$  是高斯密度函数,  $\theta_i$  为每个高斯分布的参数,即  $\theta_i = (\mu_i, \sigma_i)$ ;  $\Theta = (a_1, a_2, \dots, a_M, \theta_1, \theta_2, \dots, \theta_M)$  是待计算参数。  $\mu_i$  为期望,  $\sigma_i$  为方差,  $a_i$  为幅度系数。根据计算阈值和迭代次数,使用最大期望 EM 算法计算出 GMM 的参数  $\Theta$ , 实现从数据分布到多粒度概念的生产。其中, GMM 需要初始输入信息,这里根据文献[11]中的参数  $\Theta$  设定;而高斯云中的概念含混度 CD 延伸到高斯混合模型中,用于衡量概念间的交叠程度,从而构建高斯云变换算法<sup>[12]</sup>,其具体实现如下。

对于 GMM 变化后的第  $k$  个高斯分布,分别计算其与相邻高斯分布间的重叠程度,如果它们的弱边界不重叠,则含混度  $CD_k = 0$ ;否则说明此概念与相邻概念之间有交叠区域,此时分别计算其与左、右两侧相邻概念间不重叠的缩放比例  $\alpha_1, \alpha_2$ , 满足:

$$\begin{aligned} \mu_{k-1} + 3 \times \alpha_1 \times \sigma_{k-1} &= \mu_k - 3 \times \alpha_1 \times \sigma_k \\ \mu_k + 3 \times \alpha_2 \times \sigma_k &= \mu_{k+1} - 3 \times \alpha_2 \times \sigma_{k+1} \end{aligned} \quad (4)$$

则第  $k$  个高斯分布的标准差变化指数  $\alpha_k = \min(\alpha_1, \alpha_2)$ 。然后计算第  $k$  个概念的高斯云参数,如下所示:

$$\begin{aligned} Ex_k &= \mu_k \\ En_k &= \sigma_k - (1 - \alpha_k) \times \sigma_k / 2 \\ He_k &= (1 - \alpha_k) \times \sigma_k / 6 \\ CD_k &= (1 - \alpha_k) / (1 + \alpha_k) \end{aligned} \quad (5)$$

基于上述理论的自适应高斯云变换(A-GCT)<sup>[12]</sup>无需预先指定概念数量,根据概念含混度制定高斯云变换策略,能够模拟人类的认知规律,实现数据的自动聚类。算法的具体流程如算法 1 所示。

#### 算法 1 A-GCT

- Step1 输入数据集  $\{x_i | i=1, 2, \dots, N\}$  和含混度上限  $\beta$ 。
- Step2 计算样本数据集频率分布  $p(x_i)$  的波峰数  $M$ , 并将其作为初始粒度的数量。
- Step3 根据式(3),用 GMM 将数据样本转换为  $M$  个高斯分布:  $G(\mu_k, \sigma_k) | k=1, 2, \dots, M$ 。
- Step4 对于第  $k$  个高斯分布,根据式(4)和式(5)计算标准差缩放比例  $\alpha_k$  以及高斯云参数  $Ex_k, En_k, He_k, CD_k$ , 并且按照含混度对高斯云进行排序。

Step5 按顺序对每个高斯云的含混度进行判断,如果  $He_k/En_k > \beta$ ,  $k=1,2,\dots,M$ ,则粒度数  $M=M-1$ 。

Step6 循环 Step3-Step4,形成  $M$  个含混度小于或等于  $\beta$  的高斯云  $C(Ex_k, En_k, He_k)$ ,  $k=1,2,\dots,m$ 。

### 3 基于遥感图像聚类改进的高斯云变换

自适应高斯云变换(A-GCT)为多粒度模型提供了一种粒度和层次的优化方法,能够将问题域中的数据分布自动转换为多粒度的不同概念。但其在针对数据分布复杂的遥感图像时,运算效率较低,且采取删除粒度的自适应策略而忽略了对相邻粒度的影响,造成对噪声敏感,粒度寻优的结果不准确。因此针对遥感图像聚类,本文考虑从以下3个方面对A-GCT进行改进。

#### 3.1 算法效率的改进

原A-GCT中将数据频度分布中的波峰数作为初始粒度数  $M$ ,但在遥感图像数据分布中,多数峰值是由光谱异质性和纹理引起的,因此导致  $M$  的值过大,增加了迭代次数,从而降低了算法的效率。这里用K-Means聚类<sup>[13]</sup>进行初始细粒度的选择,为GMM提供优化后的先验信息,通过减少初始粒度数量来减少迭代次数并提升算法效率。

K-Means是一种快速、简单且对大数据集有较高效率的聚类方法,以欧氏距离为相似度测量,求初始聚类中心向量  $V$  的最优分类,使得评价指标  $J$  最小。令  $X=\{x_1, x_2, \dots, x_n\}$  表示  $n$  个数据集的集合,  $V=\{\mu_1, \mu_2, \dots, \mu_c\}$  表示  $c$  个聚类中心的集合,则目标函数如下:

$$J = \sum_{j=1}^n \sum_{i=1}^c \|x_j - \mu_i\|^2 \quad (6)$$

具体改进方法:1)用K-Means算法对数据样本  $X$  进行聚类,得到  $c$  个初始细粒度  $C(\mu_i, \sigma_i, a_i)$ ,  $i=1,2,\dots,c$ ;2)将  $C(\mu_i, \sigma_i, a_i)$  的参数信息  $\mu_i, \sigma_i, a_i$  作为GMM的初始输入,然后根据式(3)转换得到  $c$  个高斯分布。

对于初始粒度数量  $c$  的选取,本文定义一种策略:1)统计数据频率分布图中的所有波峰和波谷的均值,分别定义为  $c_1$  和  $c_2$ ,定义阈值  $d=|c_1 - c_2|/2$ ;2)遍历频率分布图,如果一个波峰与它相邻的任意波谷的差值大于阈值  $d$ ,那么初始粒度  $c=c+1$ 。

#### 3.2 自适应策略的改进

原A-GCT算法的自适应策略:计算相邻概念间的含混度,如果最大含混度超过阈值  $\beta$ ,则删除这个交叠程度最大的概念,然后根据以上规则不断迭代,最终形成含混度小于  $\beta$  的多个概念。对于遥感图像边界的不确定性和模糊性,A-GCT的删除策略忽略了相邻粒度信息,使得每一层的粒度空间信息传递不准确,影响后续迭代的稳定性,进而影响最终概念的提取。这里引入一种幅度云综合<sup>[14]</sup>进行自适应概念的跃升,利用综合信息的策略来代替删除策略,进而更加丰富、精确地保留每一层的粒度信息,使得粒度空间信息的传递更加清晰和准确。其云综合的具体过程如下:

(1)定义截断熵  $En_i'$

$$M_{c_2}'(x) = \begin{cases} a_i \cdot M_{c_1}(x), a_i \cdot M_{c_1}(x) > a_j \cdot M_{c_j}(x), \\ j \neq i \\ 0, & \text{other} \end{cases}$$

$$En_i' = \frac{1}{\sqrt{2\pi}} \int M_{c_i}'(x) dx \quad (7)$$

(2)计算合并后云模型的数字特征和云幅度  $a$

$$Ex = \frac{Ex_1 \cdot En_1' + Ex_2 \cdot En_2'}{En_1' + En_2'}$$

$$En = \frac{En_1'}{a_1} + \frac{En_2'}{a_2} \quad (8)$$

$$He = \frac{He_1 \cdot En_1' + He_2 \cdot En_2'}{En_1' + En_2'}$$

$$a = \frac{En_1' + En_2'}{En}$$

其中,  $M_{c_i}(x)$  是云模型  $c_i$  的期望曲线方程;  $En_1'$  和  $En_2'$  为截断熵,是  $M_{c_1}'(x)$  和  $M_{c_2}'(x)$  的不重叠部分。

具体改进方法:1)利用GMM将数据样本集转换为  $M$  个高斯分布;2)按照含混度大小对通过高斯云变换计算出的  $M$  个高斯云进行排序;3)如果含混度最大的高斯云  $C_1(Ex_1, En_1, He_1, a_1)$  超出阈值  $\beta$ ,说明该高斯云与相邻高斯云  $C_2(Ex_2, En_2, He_2, a_2)$  的交叠程度最大,此时根据式(7)和式(8)将  $C_1$  与  $C_2$  进行幅度云综合得到新的云概念  $C_3(Ex_3, En_3, He_3, a_3)$ ,且  $M=M-1$ ;4)对得到的  $M$  个粒度信息  $C_k(Ex_k, En_k, He_k, a_k)$ ,令  $\mu_k = Ex_k, \sigma_k = En_k, k=1,2,\dots,(M-1)$  作为步骤1中GMM的输入,然后循环上述步骤1)一步骤4)。

#### 3.3 粒度划分的改进

图像聚类是根据图像特征对感兴趣的目标区域进行提取,从而得到若干不同的区域。A-GCT采用正向高斯云算法计算像素点对概念的确定度,通过比较像素点对不同概念的确定度大小来判断其属于哪个概念,从而进行聚类。其中像素点  $x$  对概念粒度  $C(Ex, En, He, a)$  的确定度  $u(x)$  的计算如下:

$$u(x) = e^{-\frac{(x-Ex)^2}{2y^2}} \quad (9)$$

其中,  $y = \text{NORM}(Ex, He^2)$ ,是以  $Ex$  为期望、 $He^2$  为方差的一个正态随机数。但在对遥感图像进行划分时,仅利用确定度会使粒度间的划分对噪声敏感,而像素点到粒度中心的欧氏距离能够反映图像中不同类别间的实际差异,因此本文将确定度与欧氏距离结合,引入一种加权距离来划分交叠区域。

具体改进方法:本文根据云模型特征,提出一种粒度划分策略:1)每个粒度基本区域  $[Ex - En, Ex + En]$  内的像素点完全属于该粒度;2)对于相邻粒度间的交叠区域内的像素点  $x$ ,使用一种加权距离来判断其所属粒度,如式(10)所示:

$$D_i(x) = d_i(x) * (1 - u_i(x)), i=1,2,\dots,n \quad (10)$$

其中,  $d_i$  为粒度  $i$  的期望中心,  $u_i(x)$  为  $x$  对粒度  $i$  的确定度<sup>[3]</sup>,  $n$  为概念数量。然后通过选取最短距离来确定  $x$  的所属粒度。上述方法既保证了粒度基本区域划分的正确性,又能更准确地对交叠区域进行划分,而且只计算交叠区域的距离,提升了运算效率。

#### 3.4 改进算法的流程

Step1 输入数据集  $\{x_i | i=1,2,\dots,N\}$  和含混度上限  $\beta$ 。

Step2 使用K-Means聚类对数据样本进行聚类,从而得到  $M$  个初始细粒度  $C(\mu_k, \sigma_k, a_k) | k=1,2,\dots,M$ 。

Step3 将粒度信息  $C$  作为式(3)的输入,利用GMM将

数据样本集转换为  $M$  个高斯分布:  $G(\mu_k, \sigma_k) | k=1, 2, \dots, M$ 。

Step4 对于第  $k$  个高斯分布, 根据式(4)和式(5)计算其标准差缩放比例  $\alpha_k$  以及高斯云参数  $E_{x_k}, E_{n_k}, H_{e_k}, CD_k$ , 并且按照含混度对高斯云进行排序。

Step5 按顺序对每个高斯云的含混度进行判断, 如果  $H_{e_k}/E_{n_k} > \beta, k=1, 2, \dots, M$ , 则将  $CD_k$  最大的两个相邻粒度进行幅度云综合, 且  $M=M-1$ 。

Step6 循环 Step3—Step5, 形成  $M$  个含混度小于或等于  $\beta$  的高斯云  $C(E_{x_k}, E_{n_k}, H_{e_k}), k=1, 2, \dots, m$ 。

Step7 根据 3.3 节中的划分策略将数据集划分到  $M$  个粒度概念中。

#### 4 实验结果与分析

本文以 Landsat4-5TM 卫星数据影像中的 TM5 波段为例进行验证, 该波段处于水的吸收波段, 用于水质研究, 选取其中多幅特征明显的图像进行实验。实验开发环境为 MATLAB R2013b。为了定量比较聚类结果, 用误分率 (Misclassification Error, ME) 作为评判准则, ME 以人工标准分割结果作为标准参考, 将测试算法结果与标准结果相比, 计算被误分的像素集合占整幅图像的比例。

本文方法以所有像素点的灰度值作为数据集, 自适应聚类出多个粒度概念, 然后根据得到的粒度信息对图像进行划分。如图 2 所示, 左侧曲线为每个高斯云概念的期望曲线, 右侧为对应的图像聚类结果。一幅图的初始粒度群数  $n=9$ , 此时粒度数较多, 地物信息间交叠复杂; 对交叠严重的粒进行合并, 以保证生成的每个粒度清晰, 粒度间的转变形成新的中间层次的粒度, 通过各层信息间的粒度寻优, 最终形成  $n=2$  个粒度群。至此便实现了 9 个概念到 2 个概念的变粒度过程, 完成了人类认知中从多层次、细粒度到高层次、粗粒度的变粒度概念的自动聚类过程。

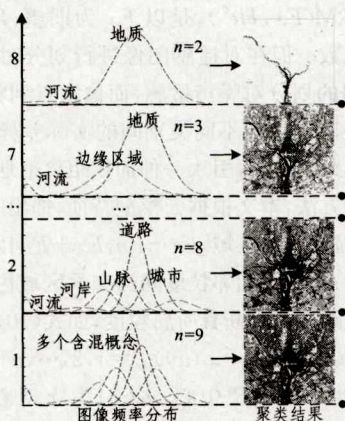


图2 多粒度寻优过程

根据文献[12]中不同的含混度上限  $\beta$ , 分别在图 3 所示的真彩色遥感图像下进行实验。当  $\beta=0.6354$  (骨干区不交叠) 时得到 6 个细粒度概念, 概念间交叠严重, 地物信息过于细致; 当  $\beta=0.5004$  (基本区不交叠) 时得到 3 个概念, 此时清晰地聚类出了海水、建筑、草地信息; 在  $\beta=0.2$  (外围区不交叠) 时得到 2 个粗粒度概念, 仅能得到水、陆两个信息, 概念的提取不完备。




图3 不同粒度层次下的聚类结果

综上, 本文方法能够实现对遥感图像从细粒度到粗粒度的逐层抽取, 得到包含不同地物特征的聚类结果, 进而实现对遥感图像的自动化信息提取; 从多个层次分析理解遥感图像, 解决了以往聚类方法需要先验信息和仅能得到单一粒度层次结果的问题。为了比较聚类精度, A-GCT 和本文方法的含混度上限均取  $\beta=0.5004$ , 即保证相邻概念之间的基本区域不交叠, 亦即概念划分清晰<sup>[9]</sup>。本文选取初始 K-Means 的迭代次数为 10, 即可获得稳定解。

#### 4.1 本文方法与 A-GCT 的对比

图 4 中, 从上到下依次为“河流 1”图像、“河流 2”图像、“湖泊”图像。其中, 图 4(a) 和图 4(b) 所示分别为原始遥感图像和人工聚类后的遥感图像, 图 4(c) 和图 4(d) 所示分别为 A-GCT 和本文方法的图像聚类结果。




图4 本文方法与 A-GCT 的聚类结果

图 5(a) 和图 5(b) 所示为 A-GCT 的多粒度聚类过程, 而本文方法的多粒度聚类过程如图 5(c) 和图 5(d) 所示。其中外围曲线 (实线) 为图像的灰度直方图分布, 内部曲线 (虚线) 为每个粒度的高斯云分布。过程类似图 2 的泛概念树<sup>[3]</sup>, 显示了从初始细粒度到最终粗粒度的变粒度概念的自动聚类过程。

在算法效率方面, 本文方法减少了初始粒度数量, 使迭代次数大大减少, 而且 K-Means 的时间复杂度比 GMM 算法的低, 经过数次迭代即可获得稳定解; 通过 K-Means 得到的初始粒度信息克服了 GMM 中 EM 算法对初始值敏感的缺点,

使 EM 算法更快收敛,得到更加准确的初始概念,从而克服了 A-GCT 初始粒度选取峰值数的盲目性。图 5(b)和表 1 中

A-GCT 对 3 幅图像的平均初始粒度数  $c=35$ ,而本文方法的初始粒度数  $c=9$ ,而且本文方法的耗时是 A-GCT 的一半。

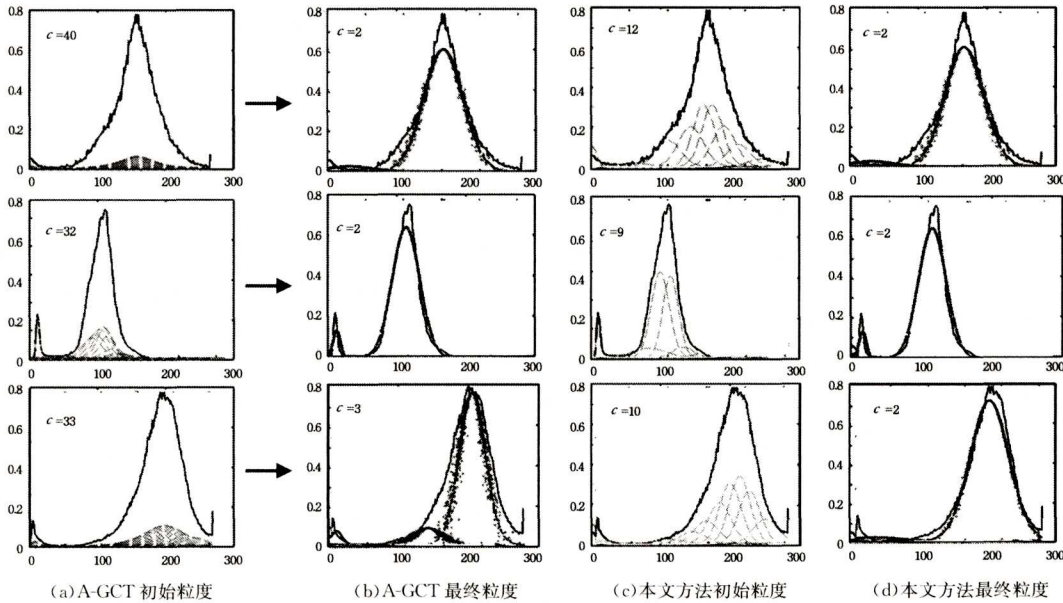


图 5 本文方法与 A-GCT 的聚类过程

表 1 本文方法与 A-GCT 的对比结果

	平均初始粒度	平均误分率/%	平均耗时/s
A-GCT	35	2.35	2.86
改进后	9	1.22	1.39

聚类结果方面,A-GCT 的粒度提取和聚类结果分别如图 3(c)和图 4(b)所示,对“河流”聚类概念间的交叠区域如水体和地质的划分不清晰;而对“湖泊”的粒度提取中出现了过分类,即粒度寻优不准确。而本文方法利用幅度云综合,加入了相邻粒度信息,对每一层粒度的信息提取、各层粒度空间的传递更加准确,因此本文方法提取的粒度数量和特征优于 A-GCT,由图 3(e)和图 4(c)的结果可知,本文方法对图像中水体的提取更加符合人的认知。从表 1 也可以看出,本文方法对水体区域的误分率和耗时均低于 A-GCT。

#### 4.2 本文方法与其他方法的对比

图 6(a)所示为 3 幅原始遥感图像,图 6(b)和图 6(c)所示分别为一般化的模糊 C 均值算法(RFPCM)<sup>[15]</sup>以及均值漂移(Mean-Shift)<sup>[16]</sup>算法的聚类结果,而本文方法的图像聚类结果如图 6(d)所示。其中 RFPCM 的聚类数设为 2;Mean-Shift 的空间带宽设为 5。

图 6(b)中 RFPCM 需要确定聚类数目和聚类中心,且对噪声敏感,很多地质区域被误分类;而 Mean-Shift 的聚类数过多,聚类结果不清晰,如图 6(c)中地质区域出现过分类;而本文方法能够自适应地进行粒度寻优,得到符合实际地物信息的聚类结果,如图 5(d)中准确提取了前两幅图像的水体概念,清晰地反映了水域、陆地信息,而对第 3 幅图像的聚类准确地反映了海水、海岸过渡带和陆地 3 个概念,更清晰地提取了水体信息,从而克服了以往方法难以准确自动化聚类的缺陷。从表 2 的统计中也可以看出,本文方法对水体区域的平均误分率和耗时均低于其他两种方法,从而证明了本文方法的有效性。

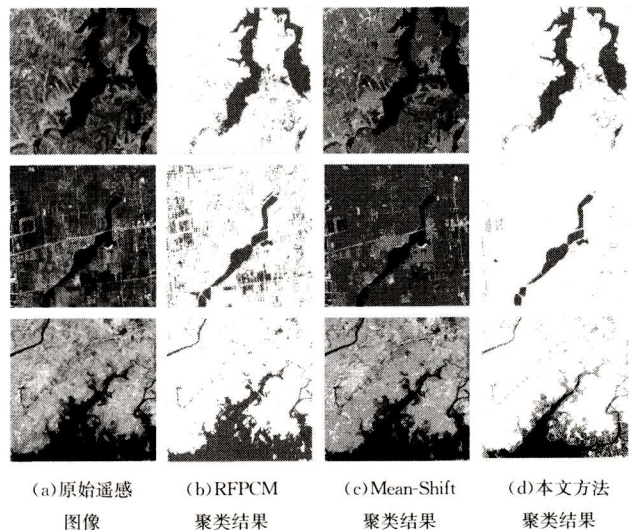


图 6 本文方法与其他方法的聚类结果

表 2 本文方法与 A-GCT 的对比结果

聚类方法	平均误分率 ME/%	平均耗时/s
RFPCM	4.39	2.32
Mean-Shift	2.74	8.68
本文方法	2.21	1.55

**结束语** 遥感图像信息的自动化提取一直是一个难题。本文结合多粒度模型对遥感图像进行聚类,通过改进一种自适应高斯云变换的多粒度模型对遥感图像进行处理,有效解决了遥感图像的多层次、多粒度的自适应的聚类问题。通过与一些现有的聚类方法进行对比和提取遥感图像水路信息的实验,进一步说明了本文方法的正确性及有效性。针对遥感图像中的空间复杂性和多尺度性等问题,如何综合多波段、多尺度进行聚类分析<sup>[17]</sup>,以及如何清晰且全面地提取超分辨率下遥感图像中的复杂地物信息,将多粒度模型结合到其他

- [3] KEGL B, KRZYŻAK A, et al. A polygonal Line algorithm for constructing principal curves[C]//Proceedings of Neural Information Processing System. Denver Colorado, USA; Computer Press, 1999; 501-507.
- [4] VERBEEK J J, VLASSIS N, KROSE B. A k-segments algorithm for finding principal curves[J]. Pattern Recognition Letters, 2002, 23(8): 1009-1017.
- [5] VERBEEK J J, VLASSIS N, KROSE B. A soft k-segments algorithm for principal curves[M]//Artificial Neural Networks—ICANN 2001. Springer Berlin Heidelberg, 2001; 450-456.
- [6] DELICADO P. Another look at principal curves and surfaces [J]. Journal of Multivariate Analysis, 2001, 77(1): 84-116.
- [7] ZHANG J P, WANG Y. An Overview of Principal Curves[J]. Chinese Journal of Computers, 2003, 26(2): 129-146. (in Chinese)  
张军平, 王珏. 主曲线研究综述[J]. 计算机学报, 2003, 26(2): 129-146.
- [8] BAS E, ERDOGMUS D. Principal curves as skeletons of tubular objects; locally characterizing the structures of axons[J]. Neuroinformatics, 2011, 9(2/3): 181-191.
- [9] WANG H N, LEE T C M. Extraction of curvilinear features from noisy point patterns using principal curves[J]. Pattern Recognition Letter, 2008, 29(16): 2078-2084.
- [10] REINHARD K, NIRANJAN M. Parametric subspace modeling of speech transitions[J]. Speech Communication, 1999, 27(1): 19-42.
- [11] ZHANG J P, WANG X D, KRUGER U, et al. Principal curve algorithms for partitioning high-dimensional data spaces [J]. IEEE Transactions on Neural Networks, 2011, 22(3): 367-380.
- [12] ZHANG H Y, MIAO D Q, XIA F C, et al. Automatic Recognition System of Bills Based on Principal Curves[J]. Journal of Information and Computational Science, 2004, 1(2): 199-204.
- [13] ZHANG J P, CHEN D W, KRUGER U. Adaptive constraint k-segment principal curves for intelligent transportation systems [J]. IEEE Transactions on Intelligent Transportation Systems, 2008, 9(4): 666-677.

(上接第 27 页)

方法中进行处理, 都是值得深入研究的课题, 也是本文下一步的工作重点。

### 参 考 文 献

- [1] BLASCHKE T. Object based image analysis for remote sensing [J]. Isprs Journal of Photogrammetry and Remote Sensing, 2010, 65: 2-16.
- [2] GONG P. Some essential questions in remote sensing science and technology[J]. Journal of Remote Sensing, 2009, 13(1): 13-22. (in Chinese)  
官鹏. 遥感科学与技术中的一些前沿问题[J]. 遥感学报, 2009, 13(1): 13-22.
- [3] LI D Y, DU Y. Artificial Intelligence with Uncertainty[M]. Beijing: National Defense Industry Press, 2014. (in Chinese)  
李德毅, 杜鹁. 不确定性人工智能[M]. 北京: 国防工业出版社, 2014.
- [4] MA H Y, WANG G Y, ZHANG Q H, et al. Multi-granularity Color Image Segmentation Based on Cloud Model[J]. Computer Engineering, 2012, 38(20): 184-187. (in Chinese)  
马鸿耀, 王国胤, 张清华, 等. 基于云模型的多粒度彩色图像分割 [J]. 计算机工程, 2012, 38(20): 184-187.
- [5] WANG G Y, XU C L, LI D Y. Generic normal cloud model[J]. Information Sciences, 2014, 280(280): 1-15.
- [6] WANG Z C, LI Y S, XUE L X, et al. Representation of Fuzzy Objects in the Remote Sensing Image[J]. Journal of Image & Graphics, 2007, 12(11): 2081-2085. (in Chinese)  
王佐成, 李永树, 薛丽霞, 等. 遥感图像中模糊对象表达[J]. 中国图象图形学报, 2007, 12(11): 2081-2085.
- [7] WU Z C, QIN M Y, ZHANG X. A Cloud-Model-Based Remote Sensing Image Segmentation Concerned with Geometrical Features[J]. Geomatics & Information Science of Wuhan University, 2008, 33(9): 939-942. (in Chinese)  
巫兆聪, 覃茂运, 张潇. 一种顾及几何特征的云模型遥感图像分割方法[J]. 武汉大学学报(信息科学版), 2008, 33(9): 939-942.
- [8] WU Z C, YI L, ZHANG G F. Uncertainty analysis of object location in multi-source remote sensing imagery classification[J]. International Journal of Remote Sensing, 2009, 30: 5473-5487.
- [9] LIU Y C. Research on particle computing based on cloud model [D]. Beijing: Tsinghua University, 2013. (in Chinese)  
刘玉超. 基于云模型的粒计算研究方法[D]. 北京: 清华大学, 2013.
- [10] QIN K, WANG P. New method of curve fitting based on cloud transform[J]. Computer Engineering and Applications, 2008, 44(23): 56-74
- [11] WANG P B, CAI Z M, LIU W S. EM estimation of PDF parameters for Gaussian mixture processes[J]. Technical Acoustics, 2007, 26(3): 298-502. (in Chinese)  
王平波, 蔡志明, 刘旺锁. 混合高斯概率密度模型参数的期望最大化估计[J]. 声学技术, 2007, 26(3): 298-502.
- [12] LIU Y C, LI D Y, HE W, et al. Granular computing based on Gaussian cloud transformation [J]. Fundamenta Informaticae, 2013, 127: 385-398.
- [13] MACQUEEN J B. Some methods for classification and analysis of multivariate observations[C]//Proc. of Berkeley Symposium on Mathematical Statistics and Probability. 1967; 281-297.
- [14] MENG H, WANG S L, LI D Y. Concept extraction and concept hierarchy construction based on cloud transformation[J]. Journal of Jilin University, 2010, 40(3): 782-787. (in Chinese)  
孟晖, 王树良, 李德毅. 基于云变换的概念提取及概念层次构建方法[J]. 吉林大学学报, 2010, 40(3): 782-787.
- [15] MAJI P, PAL S K. Rough set based generalized fuzzy C-means algorithm and quantitative indices [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, 2007, 37(6): 1529-1540.
- [16] COMANICIU D. Mean shift: A robust approach toward feature space analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(5): 603-619.
- [17] YI L, LIU P, QIAO X, et al. Multi-granularity synthesis segmentation for high spatial resolution Remote sensing images [J]. Iop Conference Series Earth & Environmental Science, 2014, 17(1): 682-691.