

# 基于云模型、图论和互信息的遥感影像分割方法

宋 岚<sup>1,2,3</sup>,文堂柳<sup>1,3</sup>,黎海生<sup>2</sup>,王 杉<sup>2</sup>

(1. 武汉大学软件工程国家重点实验室,武汉大学计算机学院,湖北武汉 430072;

2. 华东交通大学信息工程学院,江西南昌 330013;3. 江西师范大学高性能计算中心,江西南昌 330022)

**摘 要:** 针对传统的基于局部信息搜索的分割方法很少考虑图像的全局信息,而且容易忽略影像分割中的随机性和不确定性,本文提出了一种基于云模型、图论和互信息的影像分割方法.使用云模型来反映像素聚类成区域时的不确定性和随机性,将图论方法引入基于互信息的最优割集的生成从而得到全局最优分割,利用云模型区域概念所呈现出的多维特征,通过云综合异质性度量来改进边界权重的计算,从而实现对区域相异性的区分能力.从实验结果来看,本文提出的方法,能产生有意义的、完整的、内部同质的分割区域,在分割精度上基本能满足人眼的视觉要求.

**关键词:** 云模型;小波降噪;Harris算子;互信息;图论;最小生成树

**中图分类号:** P237.4 **文献标识码:** A **文章编号:** 0372-2112(2015)08-1518-08

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2015.08.008

## Segmentation Method for Remote Sensing Image Based on Cloud Model, Graph Theory and Mutual Information

SONG Lan<sup>1,2,3</sup>, WEN Tang-liu<sup>1,3</sup>, LI Hai-sheng<sup>2</sup>, WANG Shan<sup>2</sup>

(1. State Key Laboratory of Software Engineering, School of Computer, Wuhan University, Wuhan, Hubei 430072, China;

2. School of Information Engineering, East China Jiaotong University, Nanchang, Jiangxi 330013, China;

3. Key Laboratory of High Performance Computing, Jiangxi Normal University, Nanchang, Jiangxi 330022, China)

**Abstract:** The traditional segmentation method which is based on local information search technique gives little regard for the global information of the image and ignores the randomness and uncertainty of image segmentation. In view of this, this paper proposes a new segmentation method which is based on cloud model, graph theory and mutual information. Firstly, we could use the cloud model to reflect the uncertainty and randomness when pixel cluster into regions. Secondly, when the graph theory method is introduced into a quasi-optimal cut sets, we could obtain a globally optimal segmentation. Thirdly, by using the multidimensional characteristics which are showed by regional concept of cloud model, we could use a comprehensive heterogeneity measure to improve border weights, and therefore improve the ability to distinguish regional dissimilarity. From the experimental results, the proposed method can produce meaningful, complete and internal-homogeneity divided region, moreover, the segmentation accuracy can meet the basic human visual requirements.

**Key words:** cloud model; wavelet denoising; harris operator; mutual information; graph theory; minimal spanning tree

### 1 引言

随着高分辨率遥感影像的普及,针对高分辨率影像的信息解译技术已经成为一个研究热点.影像分割技术是实现影像解译的一个基本环节,是将影像分成数量相对较少、内部同质的区域.同质区域能提供利于后续高层处理的更多特征,如几何特征、纹理特征、上下文特征等,这些特征的应用将极大地提高复杂高分辨率影像的解译精度.因此,分割质量对后续的高层处理有很大的

影响.针对不同的应用,人们提出了很多不同的分割方法,这些方法总体上分为四类:阈值分割法、基于边界的方法、基于区域的方法以及二者结合的方法.但简单地应用这些方法并不适合于复杂的高分辨率遥感影像多目标分割,其原因在于:一方面,这些方法通常没有考虑影像分割过程中像素聚类的不确定性,硬性地将其划归为某个类别,而忽视了像素属于其他类别的概率.另一方面,这些方法属于局部信息搜索技术,没有考虑图像的全局信息.

影像分割过程并不是朝着一个“必然和确定”的方向进行,而是存在着随机性和不确定性,致使影像分割显得非常复杂,获得一个令人满意的分割结果常常是比较困难的.例如 Mehnert 和 Jackway<sup>[1]</sup>指出,影像分割过程中存在着像素次序依赖,不同的像素次序可能引起不同的分割结果,这种像素次序依赖反映了影像分割的随机性.另外,在像素聚集形成区域的过程中,像素隶属某个区域的可靠程度不同,并不适合于用“完全隶属”或“完全不隶属”来描述,靠近区域中心的像素,隶属区域的可靠程度较大,远离区域中心的像素,隶属区域的可靠程度较小.这种可靠程度反映了影像分割的不确定性.

云模型是一种概念的形式化表达和分析的新理论,主要反映概念的模糊性和随机性,以及二者之间的关联性,构成定性和定量间的映射<sup>[2,3]</sup>.用云模型表达局部区域概念,能反映像素聚类成区域时所存在的不确定性和随机性.但它仍属于局部搜索技术,不能顾及影像的全局信息.

基于图论的分割技术是图像分割领域一个新的研究热点<sup>[4]</sup>,它将图像映射为带权无向图,把像素视作节点、像素之间的相异性作为边的权值,利用聚类的方法对节点进行划分,从而实现对图像的分割.其中,最小生成树的图论分割方法,以全局最小权值构造最小生成树连通各个节点,能在局部特征和全局特征之间找到一种平衡,使分割过程充分考虑到影像的全局信息.但边界权重的计算仅基于像素光谱,对像素相异性区分能力不够强,且以像素构造图致使数据量较大,不易处理.

互信息的概念源自信息论,它是两个随机变量统计相关性的一种测度.1997年,Maes提出了基于互信息的医学图像配准<sup>[5]</sup>.目前,互信息已经被公认为图像配准领域里的准则之一.本文引入互信息技术作为评价分割影像与原始影像相关性的测度,作为图论方法的割集准则.

考虑到影像分割所存在的随机性和不确定性,同时也为充分利用图像空间分布信息和全局信息,尽可能准确地获得内部较为同质、又相对完整而不破碎的区域,本文提出了一种基于云模型和图论的图像分割方法,包含三个部分:第一部分是改进的基于 Harris 算子的种子点提取.首先,通过对图像小波变换,在小波频域修正小波系数,突出信号、抑制噪声,避开噪声阈值选择这一难点.其次,借鉴 Harris 算法检测角点和边缘点的思想<sup>[6]</sup>,将它加以改进,定义了区域种子点必须满足的三个条件,以精确提取与真实目标相关的种子点.第二部分是云模型区域概念生成与表达.包括基于种子点扩张的云滴组构成、云滴组概念计算以及云模

型生成.第三部分是基于图论和互信息的云综合.包括云综合、云综合异质性度量、图最小生成树构造以及基于互信息的最优割集准则.

## 2 改进的基于 HARRIS 算子的种子点提取

### 2.1 自适应的小波去噪

遥感影像上通常存在大量的噪声,这些噪声对影像解译带来很大的干扰.如果区域种子点落在噪声点上,将会产生错误的分割结果.因此,在影像分割前有必要尽可能地减弱噪声的不利影响.但这将不可避免地导致另一矛盾:噪声消除和细节信息保护上的矛盾.传统的去噪方法不能很好地解决这个矛盾.小波变换是一个良好的时频变换和多分辨率分析工具<sup>[7]</sup>,在图像处理领域,它广泛应用于噪声消除.目前,基于小波变换的去噪技术研究主要集中于选择一个合适的阈值来消除噪声成分.但由于遥感影像的复杂性,选择一个合适的阈值通常是比较困难的.本文借鉴 2 次 Butterworth 低通滤波器思想,提出一个新的自适应的小波去噪方法,避开阈值选择这一难点,其主要步骤如下.

首先,采用 Mallat 算法对原始影像进行小波分解,获得一个低频成分和三个高频成分<sup>[8]</sup>.

其次,计算高频成分的统计特征,用下面的式子计算其均值  $m$  和标准差  $\sigma$

$$m = \frac{1}{n} \sum_{i=1}^n wf_i \quad (1)$$

$$\sigma = \frac{1}{n} \sqrt{\sum_{i=1}^n (wf_i - m)^2}$$

这里,  $wf_i$  是原始小波分解系数.

由于影像信号的小波系数与影像噪声的小波系数相比,具有更大的能量幅值,本文将二次 Butterworth 低通滤波器引入到小波频域来修正小波系数,突出幅值大的属于信号的小波系数,抑制幅值小的属于噪声的小波系数,以滤除噪声.小波系数的修正公式如下:

$$mwf_i = \frac{wf_i}{(1 + (\sqrt{2} - 1) \left( \frac{\sigma}{|wf_i - m|} \right)^2)} \quad (2)$$

这里,  $mwf_i$  是修正后的小波分解系数.最后,使用小波重构算法,从修正后的小波系数重构出影像<sup>[9]</sup>.重构影像中噪声的能量得到极大地削弱,减少了对后续分割的不利影响.

### 2.2 改进的基于 Harris 算子的种子点提取

区域增长算法首先从一个指定的种子点开始,逐渐将与其连通、特征相似的邻近像素聚集在一起,形成一个区域.区域增长的分割结果高度敏感于初始种子点选择,因此,区域增长算法必须考虑的一个首要问题,就是如何选择与地物相关的真实种子点.目前,从

影像上自动地、精确地提取目标种子点仍然是困难的。

Harris 算法是一个经典的角点检测算法,利用微分算子和自相关矩阵反映像素点在任意方向上的灰度强度变化,能够有效地区分角点和边缘点,且具有旋转和仿射不变性<sup>[10]</sup>.本文利用 Harris 算法检测角点和边缘点的思想,将它加以改进,来检测区域内部的质心作为区域增长的种子点.对于影像上每个像素  $(x, y)$ ,其亮度值表示为  $f(x, y)$ ,自相关矩阵通过下式计算

$$R = \begin{vmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{vmatrix} \quad (3)$$

其中,  $I_x, I_y$  分别是水平方向微分算子、垂直方向微分算子计算的梯度幅值.像素  $(x, y)$  的梯度幅度局部变化以角点量  $CIM$  来衡量,角点量按如下公式计算

$$CIM = W \times \frac{I_x^2 I_y^2 - (I_x I_y)^2}{I_x^2 + I_y^2} \quad (4)$$

这里  $W$  是高斯卷积函数.

$$W(x, y) = \frac{1}{2\pi} e^{-(x^2 + y^2)/2\sigma^2} \quad (5)$$

由于区域内部种子点一般具有较小的灰度强度变化,因此可以根据计算的角点量,采用非最小值抑制的方法,检测出区域内部种子点.这种检测效果取决于阈值设置,较大的阈值将检测出较多的区域种子点,其中可能存在一些伪种子点.相反,较小的阈值将检测出较少的区域种子点,一些真实的区域种子点可能会遗漏.为尽可能准确地检测出真实的区域种子点,本文提出了一个自适应的 Harris 检测算法,定义了区域种子点必须满足以下三个条件.

**条件 1** 区域种子点必须具有较小的角点量,应小于一个适当的阈值.

在这里,本文使用 Otsu 法自动地确定这个阈值. Otsu 法计算一个最优阈值,使之能最大化类间差异和类内差异的比值.得到最优区分阈值后,本文将像素的角点量与阈值进行比较,像素的角点量若小于阈值,则保留作为候选种子点,否则,将不作为种子点.

**条件 2** 区域种子点邻域必须具有较小的角点量变化幅度,应小于一个适当的阈值.

对于满足条件(1)的候选种子点  $(x, y)$ ,其角点量表示为  $CIM(x, y)$ ,考虑以该像素为中心  $s \times s$  窗口,求出窗口中最小角点量  $CIM_{\min}$  和均方差  $\delta$ ,计算  $CIM(x, y)$  与  $CIM_{\min}$  的差异值  $d$ .

$$d = |CIM(x, y) - CIM_{\min}| \quad (6)$$

如果差异值  $d$  小于  $\delta$ ,像素  $(x, y)$  继续被保留作为候选种子点,否则,将不作为种子点.

**条件 3** 区域种子点应在其邻域各方向上,具有相近的亮度特征.

对于每一个候选种子点  $s$ ,设其灰度强度为  $f_s$ ,定义一个直径为  $r$  的圆形模板,使模板中心对应到该种子点,计算模板范围内像素  $p_i$  与种子点  $s$  的亮度差异  $b_i = |f_s - f_{p_i}|$ ,统计  $b_i < \delta_i$  的像素点数  $n_s$ ,若  $n_s > A_s/2$ ,则可认为区域种子点  $s$  在其邻域大多数方向上,具有相近的亮度特征,应该保留作为真实的种子点,否则,将不能作为种子点.这里,阈值  $t = k\delta_s$ ,  $\delta_s$  是模板内像素的均方差,系数  $k$  为 1.  $A_s$  是模板内有效像素数.

### 3 云模型生成

在严格地提取出一系列与真实目标相关的种子点后,通过这些种子点创建云模型区域概念,将与种子点连通、特征相似的像素聚集成同一云模型.从云模型生成的过程来看,云模型的生成有一个内在的像素次序依赖,这容易导致云模型以随机的方式而不是以均衡的方式生成,可能造成一些云模型过度增长,而另一些云模型受到抑制,最终造成区域云模型在尺度上不可比较.

本文提出的云模型区域概念生成,包括基于种子点扩张的云滴组构成、云滴组概念计算以及云模型建立.另外,本文也提出了避免像素次序依赖的两个策略.

#### 3.1 云模型与影像分割

云模型是一个关于形式表达和概念分析的新理论,它能反映客观世界与人类认知科学领域概念的随机性和模糊性,以及表示随机性和模糊性之间的关联性,建立定性概念和定量数值之间的映射<sup>[2]</sup>.云模型使用三个数值特征以表达概念特征,分别是期望值  $E_x$ , 熵  $E_n$  以及超熵  $H_e$ .期望值  $E_x$  是云模型表达概念的中心值,它最能有效描述这个定性概念,表达云滴组概念的中心.熵  $E_n$  综合反映概念的模糊性和概率,表达云滴组的离散程度.超熵  $H_e$  度量熵的不确定性,也就是说,它是熵的熵,表达云滴组的偏离程度.

影像分割是将空间相邻、光谱相似的像素聚集成同质区域的过程.如果把区域视作定性概念,就能使用云模型来表达区域概念,区域增长实际上就是云综合的过程,这个过程可以描述如下.首先,利用后向云发生器实现从定量数值到定性概念的转换,定性概念实际上表达一个区域.其次,利用正向云发生器建立云模型.最后,执行云综合处理,使区域概念的数值尺度变大.随着概念的扩张,概念表达的区域也相应增长.

#### 3.2 基于种子点扩张的云滴组构成

单个种子点不能表达其所在区域的整个特征,同样地,单个云滴也不能表达一个定性概念.为了准确表达一个概念,一定数量的数值特征是必要的,可利用一个尺寸为  $w \times w$  的抽样窗口去提取定性概念.但是,一

个简单的抽样窗口不一定能很好地表达一个概念. 本文提出了一个种子点扩张算法来获得一定数量的扩展种子点, 以种子点及其扩展种子点来构造云滴组.

给定一个种子点  $(x, y)$ , 其特征值为  $f(x, y)$ , 对于它的连通像素  $(x_k, y_k)$ , 其特征值为  $f(x_k, y_k)$ , 如果它满足如下条件, 它将被作为扩展种子点

$$\frac{\text{Fdis}(f(x_k, y_k), f(x, y))}{\text{Sdis}((x_k, y_k), (x, y))} \leq T \quad (7)$$

这里,  $\text{Fdis}()$  是特征空间的距离函数,  $\text{Sdis}()$  是几何空间的距离函数,  $T$  是一个阈值. 种子点及其全部扩展种子点将被用来构造云滴组.

### 3.3 云滴组概念计算

后向云发生器是通过统计的方法实现从定量数值特征到定性概念的转换模型, 使用云模型  $C(E_x, E_n, H_e)$  来表示, 并以此来描述这些精确数据所反映的云滴的整体. 利用后向云发生器, 能实现从云滴组到区域概念的转换. 它的基本算法描述如下.

对于每一个种子点及其扩展种子点, 本文按下式计算期望值  $E_x$  和熵  $E_n$

$$E_x = \frac{1}{n} \sum_{i=1}^n x_i \quad (8)$$

$$E_n = \sqrt{\frac{\pi}{2}} \times \frac{1}{n} \sum_{i=1}^n |x_i - E_x|$$

根据期望值  $E_x$  和熵  $E_n$ , 定义云期望曲线方程如下

$$f(x) = e^{-\frac{(x-E_x)^2}{2E_n^2}} \quad (9)$$

本文将云期望方程作为正向云发生器的判断准则, 并且在云模型创建过程中自适应调整这个准则. 因此, 任意像素对于每个邻近云模型的隶属度就可以用该方程计算得到.

### 3.4 云模型生成

利用后向云发生器, 对于每一个云滴组, 已经提取了区域的定性概念, 接下来使用正向云发生器, 可以建立云模型区域概念, 其算法描述如下.

输入: 3 个数字特征  $C(E_x, E_n, H_e)$ , 生成云滴的个数  $N$ .

输出:  $N$  个云滴及其确定度  $\text{drop}(x_i, y_i)$ ,  $i = 1, \dots, N$ .

算法步骤为:

(1) 通过正向云发生器, 计算每一个未处理像素对于其邻近云模型的隶属度.

(2) 比较像素对不同云模型的隶属度, 像素合并到隶属度最大的云模型中.

(3) 重新计算云模型概念的定性特征, 使云模型在扩张过程中实现自适应调整.

(4) 继续执行上述过程, 直到所有像素都已处理.

为避免云模型生成过程对像素次序依赖, 保证所有区域云模型能够以均衡的方式增长, 本文采取了两个策略:

(1) 当一个像素相对几个不同的邻近云模型具有相同的隶属度, 采取的策略是, 该像素分配到尺度最大的云模型.

(2) 当一个云模型生成后, 下一次增长从与上一次特征差异最大的云模型开始, 避免一些云模型过度增长, 而另一些受到抑制.

## 4 基于图论和互信息的云综合

由于高分辨率遥感影像上地物细节信息非常丰富, 以及同物异谱现象的存在, 用云模型表达的区域概念在很多情况下并不能表示一个完整的目标, 而只是目标内部破碎的部分. 而且, 在不同的粒度空间, 区域概念往往不同, 呈现出一种多尺度层次关系. 因此, 需要对云模型表达的区域概念进行多尺度云综合, 以实现不同尺度的遥感影像分割.

云综合是将两朵或多朵相邻子云进行综合, 生成一朵新的高层概念的父云, 属于概念提升范畴<sup>[11]</sup>. 云综合过程有两个关键因素要考虑, 分别是云异质性度量和云综合规则. 对于云异质性度量, 本文根据云模型描述属性, 从期望值、熵以及超熵三个方面来定义云异质性度量. 对于云综合规则, 本文根据图论的最小生成树算法结合互信息技术, 构建目标函数, 选择最优阈值, 设计全局最优割集准则, 以获得图像的最佳分割.

### 4.1 云综合

设两个相邻云模型  $C_1(E_{x1}, E_{n1}, H_{e1})$ ,  $C_2(E_{x2}, E_{n2}, H_{e2})$  云期望曲线方程分别为  $\text{MEC}_{C1}(x)$ ,  $\text{MEC}_{C2}(x)$ , 其云综合为  $C(E_x, E_n, H_e)$ , 云综合后三个数值特征可以用下式计算<sup>[2]</sup>

$$\begin{aligned} E_x &= \frac{E_{x1}E_{n1}' + E_{x2}E_{n2}'}{E_{n1}' + E_{n2}'} \\ E_n &= E_{n1}' + E_{n2}' \\ H_e &= \frac{H_{e1}E_{n1}' + H_{e2}E_{n2}'}{E_{n1}' + E_{n2}'} \end{aligned} \quad (10)$$

其中  $E_{n1}'$ 、 $E_{n2}'$  计算如下

$$E_{n1}' = \frac{1}{\sqrt{2\pi}} \int \text{MEC}_{C1}'(x) dx$$

$$E_{n2}' = \frac{1}{\sqrt{2\pi}} \int \text{MEC}_{C2}'(x) dx$$

$$\text{MEC}_{C1}'(x) = \begin{cases} \text{MEC}_{C1}(x), & \text{MEC}_{C1}(x) \geq \text{MEC}_{C2}(x) \\ 0, & \text{其他} \end{cases}$$

$$\text{MEC}_{C2}'(x) = \begin{cases} \text{MEC}_{C2}(x), & \text{MEC}_{C2}(x) \geq \text{MEC}_{C1}(x) \\ 0, & \text{其他} \end{cases} \quad (11)$$

## 4.2 云综合异质性度量

云模型的三个数值特征分别为期望  $E_x$ 、熵  $E_n$  和超熵  $H_e$ 。期望值  $E_x$  是云模型表达概念的中心值,熵  $E_n$  综合反映概念的模糊性和概率.超熵  $H_e$  可由图斑的面积和周长来计算.云综合过程会产生云异质性变化,最适合的云综合,必须使云异质性变化最小.为提高云模型相异性的区分能力,本文利用云模型所表现出的多维特征,从期望  $E_x$ 、熵  $E_n$  和超熵  $H_e$  三个方面来计算云异质性变化.

(1)期望  $E_x$  异质性变化  $h_{E_x}$

$$h_{E_x} = E_x - (E_{x1} + E_{x2})/2 \quad (12)$$

(2)熵  $E_n$  异质性变化  $h_{E_n}$

$$h_{E_n} = n_m E_n - n_1 E_{n1} - n_2 E_{n2} \quad (13)$$

(3)超熵  $H_e$  异质性变化  $h_{H_e}$

超熵异质性变化  $h_{H_e}$  可以用光滑度异质性变化  $h_{smooth}$  和紧致度异质性变化  $h_{com}$  来计算

$$h_{H_e} = w_{smooth} h_{smooth} + (1 - w_{smooth}) h_{com} \quad (14)$$

其中:光滑度异质性变化  $h_{smooth}$  可以使云综合后边界尽量光滑,紧致度异质性变化  $h_{com}$  可以使云综合后的区域在形状上尽量紧凑,分别定义如下.

$$h_{smooth} = n_m \frac{l_m}{\sqrt{b_m}} - \left[ n_1 \frac{l_1}{\sqrt{b_1}} + n_2 \frac{l_2}{\sqrt{b_2}} \right] \quad (15)$$

$$h_{com} = n_m \frac{l_m}{\sqrt{n_m}} - \left[ n_1 \frac{l_1}{\sqrt{n_1}} + n_2 \frac{l_2}{\sqrt{n_2}} \right]$$

这里,  $n_1, l_1, b_1, n_2, l_2, b_2$  分别表示相邻两个云模型的面积、周长、外接矩形周长,  $n_m, l_m, b_m$  表示云综合后的面积、周长、外接矩形周长.

云综合总的异质性变化  $h_c$  采用期望异质性变化  $h_{E_x}$ 、熵异质性变化  $h_{E_n}$ 、超熵异质性变化  $h_{H_e}$  的加权求和来表示

$$h_c = w_{E_x} h_{E_x} + w_{E_n} h_{E_n} + w_{H_e} h_{H_e} \quad (16)$$

这里  $w_{E_x}, w_{E_n}, w_{H_e}$  表示权重.

## 4.3 互信息

互信息是两幅影像相关性的一个度量,本文认为,分割影像应和原始影像有一个较大的互信息量.给定灰度级影像  $A, B$ ,令  $P_A(a), P_B(b)$  分别表示影像  $A$ 、影像  $B$  的概率密度分布,令  $P_{AB}(a, b)$  表示影像  $A$  和影像  $B$  的联合概率密度分布,则影像的熵可以用下式计算.

$$\begin{aligned} H(A) &= - \sum_a P_A(a) \log P_A(a) \\ H(B) &= - \sum_b P_B(b) \log P_B(b) \end{aligned} \quad (17)$$

$$H(A, B) = - \sum_{a, b} P_{A, B}(a, b) \log P_{A, B}(a, b)$$

这里,  $H(A), H(B)$  分别表示影像  $A$ 、影像  $B$  的熵,  $H(A, B)$  表示影像  $A$  和影像  $B$  的联合熵.影像  $A$  和  $B$

的互信息  $MI(A, B)$  为<sup>[12]</sup>

$$\begin{aligned} MI(A, B) &= H(A) + H(B) - H(A, B) \\ &= \sum_{a, b} P_{A, B}(a, b) \log \frac{P_{A, B}(a, b)}{P_A(a) P_B(b)} \end{aligned} \quad (18)$$

## 4.4 基于最小生成树和互信息的云综合

Baatz<sup>[13]</sup>在分形网络演化算法中采取了一种“局部交互最适合”的合并规则,通过寻求局部最优化的合并来完成对影像的分割.局部交互最适合规则需要选取区域合并的起点序列,导致分割结果存在一定的区域次序依赖.

基于图论的分割技术是近年来图像领域研究的热点,它要求将图像映射为一个带权的无向图,其中像素作为节点,节点之间边的权值表示节点的相异性,通过构造最小生成树,利用最优割集准则得到阈值,实现图像的最优分割<sup>[14]</sup>.基于图论的分割技术利用全局最优割集准则,能在局部特征和全局特征之间找到一种平衡.但是它存在一些问题:首先,将图像中每个像素作为节点,每两个邻接节点之间构造一条边,将使数据量非常大,导致分割速度非常缓慢,该方法属于 NP-hard 问题<sup>[15]</sup>.其次,边的权重基于像素光谱值,对像素相异性区分能力不是很强,无法处理类之间很接近的数据<sup>[16]</sup>.

本文提出基于最小生成树和互信息的云综合方法,将云模型区域概念作为节点,节点之间边的权值用云综合异质性度量计算,通过构造最小生成树,以分割影像与原始影像之间的互信息最大作为最优割集准则,获得图像全局最优分割.它具有以下优点:(1)用云模型区域概念作为节点,不仅反映了像素聚类成区域时的不确定性和随机性,也使求解的规模得到很大减少,(2)节点之间边的权值用云综合的异质性来度量,增加了节点相异性的区分能力;(3)以互信息构造最优割集准则,是一种全局优化求解,得到的是图像全局最优分割.

本文提出的云综合算法描述如下:

### 4.4.1 构造无向图

根据云模型之间的拓扑关系,可以构造无向图  $G = (V, E)$ ,其中节点集  $V$  中的节点是每一个云模型区域概念,边集  $E$  由每两个相邻云模型之间的边构成,边的权值设为相邻云模型云综合时的异质性度量,由公式(12)~(16)计算得到.由于无向图的节点及节点之间的边都是基于云模型,而不是基于像素,数据量得到很大程度减少.

### 4.4.2 构造最小生成树

设无向图  $G = (V, E)$  的最小生成树为  $MT = (V', E')$ ,本文运用 Prim 算法构造最小生成树<sup>[15]</sup>,其主要步骤如下:

(1)从节点集  $V$  中取一节点  $V_0$  放入集合  $V'$ .

(2)在所有  $v' \in V', v \in V - V'$  的边  $(v', v) \in E$  中找一条权值最小的边加入最小生成树的边集  $E'$ , 并将  $v$  加入最小生成树的节点集  $V'$ .

(3)重复上述步骤(2), 直到  $V' = V$ , 就得到无向图的最小生成树.

#### 4.4.3 构造基于互信息的最优割集准则

在最小生成树中, 边权值为相邻云模型云综合时的异质性度量. 边权值越小, 则云综合时异质性变化越小, 相邻云模型越可能执行云综合而成为一个父云. 相反, 边权值越大, 相邻云模型越不可能执行云综合. 给定边权值阈值  $T$ , 将边集中权值大于阈值  $T$  的边删除, 则形成一个森林  $F = \{(V', E') \mid E' = E' - \{e' \mid w(e') > T\}\}$ , 在森林  $F$  中搜索其全部连通子树  $\{(V_i', E_i') \mid i = 1, 2, \dots, n\}$ , 对每一个连通子树按式(10), (11)执行云综合, 获得最终的分割结果. 由此可见, 云综合中所采用的阈值决定着最后的分割结果.

最优的分割结果, 必须满足分割后的每个区域能最大程度对应原始影像上的独立目标, 区域和目标在形状、纹理、光谱上保持一致, 也就是说, 分割影像能最大程度包含原始影像信息, 使得分割影像和原始影像互信息量达到最大. 本文以互信息量为优化目标函数, 以使互信息量最大为优化目标, 将云综合阈值选择问题转化为优化问题, 目标函数如下式,

$$J(T) = MI(S(T), O) = H(S(T)) + H(O) - H(S(T), O) \quad (19)$$

最优分割为  $T = \max \{J(T)\}$  时所对应的分割影像  $S(T)$ , 最优分割阈值可以通过模拟退火算法求解<sup>[17]</sup>.

## 5 实验与分析

分形网络演化算法(Fractal Net Evolution Approach, FNEA)是一种面向对象的图像分割方法, 能实现对遥感图像的多尺度分割. 其基本思想是对相邻影像对象之间的异质性进行定义和度量, 来决定是否进行对象合并. FNEA 已作为当前遥感影像分割软件 eCognition 中的核心分割算法而得到广泛的应用. 因此, 为验证本文所提方法有效性, 将其与 FNEA 算法的分割结果进行了详细的对比分析.

图 1 为 Google Earth 上下载的影像, 大小为  $530 \times 360$  像素. 图 2 是运用分形网络演化算法分割结果, 其中, 光谱差异性权值设置为 0.8、紧致度权值为 0.1、光滑度权值为 0.1, 尺度参数为 50. 图 3 是用本文的方法分割结果, 其中, 期望异质性权值为 0.3、熵  $En$  异质性权值为 0.4、超熵异质性权值为 0.3, 与原图互信息为 0.6608. 对比图 1 和图 3, 本文的方法由于综合了全局

信息和局部特征, 分割结果更符合真实地物形状. 图 4 是 SOPT 影像, 分辨率为 2.5 米, 为  $512 \times 470$  像素. 图 5、图 6 分别是分形网络演化算法和本文的方法分割结果. 由于本文的方法以最大互相信息为最优割集准则并不需要指定特定的尺度参数, 因而更容易分割出独立完整的目标, 如图 6 中道路作为一个完整目标被分割出来. 图 5 是分形网络演化算法尺度参数为 30 的分割, 道路由几个破碎区域组成, 如红色为主干道路一部分. 图 7 是另一幅城区的遥感影像图, 地物类型较为复杂. 图 8 是分形网络演化算法尺度参数为 50 的分割, 虽然亮色道路提取较为完整, 但包含一定程度的非道路成分, 同时, 暗色道路被分割为几个破碎区域. 图 9 是本文方法的分割结果, 分割影像与原始影像互信息为 0.5763, 亮色道路和暗色道路均获得较为完整的分割.

为评估本文方法的分割效果, 选取一幅大小为  $962 \times 960$  像素的 SPOT 影像做分割实验, 如图 10 所示. 分形网络演化算法的分割结果如图 11 所示, 其中, 光谱权值设置为 0.6、紧致度权值为 0.2、光滑度权值为 0.2, 尺度参数为 85, 分割目标数为 680, 用时 18 秒. 本文方法的分割结果如图 12 所示, 期望异质性权值为 0.4、熵异质性权值为 0.2、超熵异质性权值为 0.4, 与原图互信息为 0.6273, 分割目标数为 680, 用时 97 秒, 分割结果如图 12. 因图像中地物尺度相差较大, 分割结果难以完全顾及不同尺度的地物, 但大多数地物都能正确分割. 对比图 11 和图 12, 在分割目标数相同、权值相近的情况下: 本文的方法更能顾及不同尺度的对象, 而分形网络演化算法则将许多不同类别的小尺度对象合并为一个对象. 在计算效率上, 分形网络演化算法优于本文的方法. 为评定本文方法的分割精度, 在分割结果中任意选取一定数量的目标, 用 ERDAS 软件勾画目标轮廓并统计出每个目标的实际像素数  $S$ , 用以下公式计算目标的分割精度  $A = P/S$ ,  $P$  是分割区域的像素数. 最后, 将各类目标的分割精度与目标个数加权统计可以得到总的分割精度, 如表 1 所示. 计算结果表明本文方法分割总精度为 84.3%.

表 1 目标分割精度

目标类别	目标数	平均精度
道路段	18	85.2%
建筑物	39	78.7%
湖泊	5	92.3%
绿化带	32	82.9%
空地	18	94.7%
总精度		84.3%



图1 原始影像



图2 FNEA法分割结果



图3 本文方法分割结果



图4 SPOT影像




图5 FNEA法分割结果



图6 本文方法分割结果



图7 原始影像



图8 FNEA法分割结果




图9 本文方法分割结果



图10 SPOT影像



图11 FNEA法分割结果



图12 本文方法分割结果

## 6 结论

影像分割是遥感影像应用领域的一个重要方面。本文提出了一个新的基于云模型、图论和互信息的影像分割方法。通过云模型表达区域概念,在分割过程中考虑像素聚类的不确定性。通过避免像素次序依赖的两个策略,避免分割过程中的随机性。通过图论最小生成树算法结合互信息准则,将图像局部特征和全局信息综合考虑,是一种全局优化分割。和大多数基于图论的方法一样,本文的算法也存在计算量大的问题,特别是针对大尺寸影像,计算效率问题尤为突出。如何提高算法效率,是本文进一步的研究方向。

### 参考文献

- [1] A Mehnert, P Jackway. An improved seeded region growing algorithm[J]. *Pattern Recognition Letters*, 1997, 18: 1065 - 1071.
- [2] 李德毅, 杜鹁. 不确定性人工智能[M]. 北京: 国防工业出版社, 2005. 137 - 182.  
Li Deyi, Du Yi. *Uncertainty Artificial Intelligence*[M]. Beijing: National Defence Industrial Press, 2005. 137 - 182. (in Chinese)
- [3] 刘玉超, 马于涛, 张海粟, 陈桂生. 高阶高斯分布迭代的云

模型及其数学性质研究[J]. *电子学报*, 2012, 4(10): 1913 - 1919.

- Liu Yuchao, Ma Yutao, Zhang Haisu, Chen Guisheng. Study on characters of cloud model based on high-order gaussian distribution with iterations[J]. *Acta Electronica Sinica*, 2012, 4(10): 1913 - 1919. (in Chinese)
- [4] Felzenszwalb P F, Huttenlocher D P. Efficient graph-based image segmentation[J]. *International Journal of Computer Vision*, 2004, 59(2): 167 - 181.
  - [5] Maes F, Collignon A. Multimodality image registration by maximization of mutual information[J]. *IEEE Trans Medical Image*, 1997, 1(62): 87 - 198.
  - [6] Harris C, Satephens M J. A combined corner and edge detector [J]. *Image Vision Computing*, 1998, 6(1): 121 - 128.
  - [7] 巩萍, 潘冬明. 小波分析及其在图像处理中的应用[J]. *长沙大学学报(自然科学版)*, 2005, 19(2): 52 - 54.  
Gong Ping, Pan Dongming. Wavelet analysis and its application on image processing[J]. *Journal of Changsha University (Natural Science Edition)*, 2005, 19(2): 52 - 54. (in Chinese)
  - [8] S G Mallat. Multiresolution approximations and wavelet orthogonal bases of  $L_2(\mathbb{R})$ [J]. *Trans Amer Math Soc*, 1989, 315(1): 69 - 87.
  - [9] S Mallat. *A Wavelet Tour of Signal Processing*[M]. Boston

Mass: Academic Press, 1998. 299 – 420.

- [10] Harris C, Satephens M J. A combined corner and edge detector [J]. *Image Vision Computing*, 1998, 6(1): 121 – 128.
- [11] 蒋嵘, 李德毅, 范建华. 数值型数据的泛概念树的自动生成方法[J]. *计算机学报*, 2000, 23(5): 470 – 476.
- Jiang Rong, Li Deyi, Fan Jianhua. Automatic generation of pan – concept-tree on numerical data [J]. *Chinese Journal of Computers*, 2000, 23(5): 470 – 476. (in Chinese)
- [12] 马建华, 陈武凡, 黄静, 杨迪, 毕一鸣. 基于最大互信息量熵分割的 CT 金属伪影消除[J]. *电子学报*, 2009, 37(8): 1779 – 1783.
- Ma Jianhua, Chen Wufan, Huang Jing, Yang di, Bi Yiming. Metal artifact reduction in CT based on maximized the difference of mutual information segmentation [J]. *Acta Electronica Sinica*, 2009, 37(8): 1779 – 1783. (in Chinese)
- [13] Baatz, M, Schaape, A. Multiresolution segmentation-an optimization approach for high quality multi-scale image segmentation [A]. *Angewandte Geographische Informations-Verarbeitung XII* [C]. Karlsruhe: Wichmann Verlag, 2000, 12 – 23.
- [14] Murtagh F. A survey of recent advances in hierarchical clustering algorithms [J]. *The Computer Journal*, 1983, 26(4): 354 – 359.
- [15] J Shi, J Malik. Normalizedcuts and image segmentation [J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 888 – 905.
- [16] Pavan M, Pelillo M. A new graph theoretic approach to clustering and segmentation [J]. *Computer Vision and Pattern Recog-*

niton, 2003, 1(6): 145-152.

- [17] Kirkpatrick S, Gelatt C D, Vecchi M P. Optimization by simulated annealing [J]. *Science*, 1983, 220(4598): 671 – 680.

#### 作者简介



宋 岚 女, 1978 年生, 江西南昌人. 博士研究生, CCF 会员. 研究方向为无线传感器网络, 图像处理, 软件的形式化方法.

E-mail: sl130com@gmail.com.



文堂柳 男, 1980 年生, 江西赣州人. 博士研究生, CCF 会员. 研究方向为软件的形式化方法, 图像处理.

黎海生 男, 1974 年生, 江西南昌人, 博士, 研究方向为量子图像处理, 量子计算.

王 杉 男, 1981 年生, 江西南昌人, 博士, 研究方向为图像处理, 细胞识别, 神经网络算法等.