

高分辨率遥感图像的聚类¹

邓湘金 王彦平 彭海良

(中国科学院电子学研究所 北京 100080)

摘要 高分辨率遥感图像中的细小目标(如道路等)使图像的同类区域表现变得不一致,从而增加了高分辨率图像聚类的难度。本文提出了一种高分辨率遥感图像的聚类方法,其聚类过程包括如下三个步骤:第一步,在滑动窗口内使用消除次要成分法处理遥感图像,该处理过程使用一维形态学分水岭技术获得直方图中的左侧阈值和右侧阈值,再根据这两个阈值滤除图像中的次要成分;第二步,计算滑动窗口内的图像特征;第三步根据图像特征量利用 BPC(Back Propagation and Competitive)网络进行图像聚类。三组试验(本文提出的聚类算法,最邻近距离聚类法, K 均值聚类法)表明本文提出的图像聚类方法可以有效实现高分辨率遥感图像的聚类。

关键词 累量, 消除次要成分, BPC 网络, 高分辨率遥感图像, 聚类
中图分类号 TP751

1 引言

20 世纪 50 年代以来,图像聚类一直是同行们研究的热点^[1]。在近期的图像聚类研究中, A. Banerjee 等提出了一种基于 Polya Urn 模型的图像分割方法^[2],该方法主要利用的是单点灰度信息,对于灰度表现比较复杂的图像并不能取得较好的效果; G. Kuntimad 和 H. S. Ranganath 建议了一种基于脉冲对神经网络的数字图像分割方法^[3],该方法只有两个输出:背景和目标; Y. A. Tolias 和 S. M. Panas 提出了一个用于图像分割的自适应模糊聚类分割(AFCS)算法^[4],该方法对噪声和其它干扰比较敏感; Y. Dong 等使用 Markov 随机场模型对 SAR 图像进行分割和分类^[5],该方法在预处理过程中使用 Markov 模型对图像进行预分类,然后根据预分类的情况第二次构造 Markov 模型,该方法对中、低分辨率的 SAR 图像的分类能获得较好的效果; S. R. Seethalakshmy 提出了一个使用 Hopfield 神经网络的多模式图像分割方法^[6],该方法使用一个经过插值后的阈值表面(threshold surface)作为神经网络的输入,再利用神经网络寻找分割阈值,该方法对于有大量灰度重叠的区域不能实现正确的聚类; J. E. Koss 等使用纹理变换和 Hopfield 神经网络对腹部器官进行分割^[7],该方法使用纹理变换法对图像进行预处理,再利用多个区域统计量作为网络输入并进行图像分类,它可以较好地实现腹部多个器官/组织的分类。

在遥感应用中,图像聚类一般是在中低分辨率的图像中进行。但是随着技术的发展,高分辨率的遥感图像的应用范围在逐步扩大。中低分辨率遥感图像的聚类主要适合应用于评估某类目标发展的大致情况,而不适合于检测小面积目标的变化。而高分辨率遥感图像的聚类不但可以评估某类目标发展的大致情况,也可以检测小面积目标和单个目标的存在和变化^[8,9]。但是,包含细小目标的高分辨率遥感图像的内在特性及外在表现特性表明,应用前人提出的针对一般图像的聚类方法无法有效实现高分辨率遥感图像聚类。高分辨率遥感图像中,道路等细小目标表现得非常清晰,从而降低了图像的同类区域的一致性,增加了图像聚类的难度。对于高分辨率遥感图像的聚类,文献[8]使用人工提取森林区域中的道路,以改善滑动窗口统计特性的稳定性;文献[10]使用了形态学中的“开”运算和“闭”运算滤除滑动窗口中的小面积异类目标以增加统计特征的稳定性。人工去除异类目标对区域特性的影响会极大地降低工作效率。根据形

¹ 2002-01-24 收到, 2002-06-17 改回

态学原理^[11]，在图像中直接使用“开”运算和“闭”运算虽然能滤除小面积的异类目标，但同时也会破坏图像主要表现成分的纹理结构。

本文提出一种根据形态学原理，自动阈值处理直方图，来滤除滑动窗口中小面积异类目标的方法。该方法可以有效滤除各种形状的小面积异类目标，并增加滑动窗口图像统计特征量的稳定性。这个处理方法本文称之为消除次要成分法。在使用图像统计特征量进行图像聚类时，本文提出了一种综合利用 BP(Back Propagation) 网络与竞争 (Competitive) 网络进行高分辨率遥感图像聚类的方法，我们把这种综合网络称为 BPC(Back Propagation and Competitive) 网络。该方法以能量、熵、多个中心矩信息和多个累量信息作为图像特征量，其聚类过程包括如下三个步骤：首先在滑动窗口内使用消除次要成分法处理遥感图像，然后计算滑动窗口内的图像特征，最后根据图像特征量利用 BPC 网络进行图像聚类。图像中的人造目标区域 (如，城区、农田等) 的灰度统计特性都不服从高斯分布规律。本文聚类方法中的图像特征量不仅使用了常用的一些图像统计量 (如，能量、熵和中心矩信息)，还使用了一些高阶累量信息。高阶累量不但可以度量某类目标分布与高斯分布的差异程度，而且可以增加聚类过程的抗高斯干扰能力。

本文的内容安排如下：第 2 节介绍了消除次要成分的方法；第 3 节中讲述了用于聚类过程的图像特征量的选取；第 4 节介绍了 BPC 网络模型结构及其权值的更新算法；在第 5 节中，我们把本文提出的聚类方法与其它常用聚类方法进行了三组试验比较。第 6 节是结论部分。

2 消除次要成分

次要成分是指在滑动窗口中与图像的主要表现特性相差比较大的小目标。这些次要成分在滑动窗口中只占有小部分像素，但会对图像的特征量产生较大的干扰。在高分辨率的遥感图像中，道路及城镇中的绿化带皆清晰可见。以分辨率为 $10 \times 10\text{m}$ 的全色 SPOT 图像为例，道路在图像中表现为 1~10 个像素宽的线条。其中很多道路表现为 2~4 个像素宽的线条，所以并不能把道路作为一类。比较合适的方法是：把农田之间的道路规划为农田区域的一部分，把居民区中的街道也作为居民区的一部分。所以我们把农田区域中的道路、居民区中的街道等这样不是滑动窗口内图像主要表现特性的小目标都看作次要成分。

根据形态学原理^[11]，在图像中直接使用“开”运算和“闭”运算虽然能滤除小面积的异类目标，但同时也会破坏图像主要表现成分的纹理结构。本文根据形态学原理自动阈值处理直方图，然后根据阈值处理后的直方图分布，再滤除滑动窗口中的小面积异类目标。该方法可以有效滤除各种形状的小面积异类目标，并且不会破坏图像主要表现成分的纹理结构，从而增加滑动窗口图像统计特征量的稳定性。

图 1 是使用一维形态学分水岭技术消除次要成分的示意图。图 1(a) 是一块农田区域在消除次要成分前的原始图像，图像中有一条高速公路 (灰度值较亮的线条)。在该区域中，道路部分属于次要成分，农田是图像的主要表现成分 (同样，如果统计区域的主要表现为房屋时，则统计区域内的街道、小片的草地等则属于次要成分了)。图 1(b) 是图 1(a) 的灰度直方图，在主要表现灰度的右侧有一个由道路表现灰度所产生的矮凸起。

次要成分在图像的直方图中表现为：图像主要表现成分分布的两侧 (头部或尾部) 的小凸起。如图 1(b) 右侧的一个小凸起是农田区域中一条高速公路 (见图 1(a)) 的灰度表现。

一维形态学分水岭技术是实现消除次要成分的关键技术，它能够自动寻找直方图中的“谷”，通过确定“谷”的最低位置以实现直方图的自动阈值分析。它的实现原理是：对直方图进行交互次序滤波^[12]；在滤波后的信号中寻找局部极小值，如图 1(c) 所示。主要表现灰度左侧的极小值为左侧阈值，右侧的极小值为右侧阈值。左侧阈值左边的灰度和右侧阈值右边的灰度都是次要目标的表现灰度，即需要滤除的部分。

图 1(c) 是图 1(b) 使用一维形态学分水岭获得的右侧阈值。由于该图中没有较暗的次要目标, 所以左侧阈值在默认值——零灰度级处。图 1(d) 是对原始图像滤除右侧阈值右侧的灰度后的结果图像。




图 1 消除次要成分前、后的结果比较

消除次要成分可以用如下 4 个步骤来完成:

第一步 对滑动窗口进行直方图统计。

第二步 使用一维形态学分水岭技术, 对直方图进行自动阈值分析。

第三步 根据自动阈值分析结果, 确定需要滤除的灰度部分 (小面积异类目标的直方图分布部分)。

第四步 在滑动窗口中消除小面积异类目标, 并将其像素赋值于直方图中最主要的表现灰度。

消除次要成分后, 就可以在滑动窗口中计算图像的各个特征量。在分辨率为 $10\text{m} \times 10\text{m}$ 的 SPOT (Satellite Positioning and Tracking) 图像中, 由于大滑动窗口 (大于 40×40 的窗口) 覆盖的地面目标比较多, 尤其在城市郊区的图像中, 它的图像统计特征反而不太稳定。当滑动窗口较小时, 又不能充分反映该区域的图像特性。在分辨率为 $10\text{m} \times 10\text{m}$ 的 SPOT 图像中, 我们发现, 使用滑动窗口为 20×20 像素进行居民点和农田的分类是比较合适的。

3 图像特征量的选取及计算

图像特征量是指能代表各个类别内在属性和外在表现形式的一组参量。图像特征量的合理选取是正确进行图像聚类的基础。在遥感图像聚类中, 灰度分布的能量、熵和各阶中心矩一直是图像的重要特征量^[13-15]。大量的实验中, 我们发现, 偏度和峰度等参量在高分辨率遥感图像的各个类中的表现并不稳定, 而共生矩阵的计算量非常庞大。高阶累量不但可以度量某类目标分布与高斯分布的差异程度, 而且可以增加聚类过程的抗高斯干扰能力^[16,17]。为此, 本文选取一组能量、熵、与多个中心矩及多个累量有关的向量作为图像特征量。

在灰度级为 256 的灰度图像中, 能量可以表达为

$$\text{ENERGY} = \sum_{I=0}^{255} (p(i))^2 \quad (1)$$

式中 $p(i)$ 是灰度级 i 在统计区域 (滑动窗口) 内的出现概率。

熵可以表达为

$$\text{ENTROPY} = - \sum_{I=0}^{255} [p(i) \log_2(p(i))] \quad (2)$$

对于均值 μ 的灰度分布的 r 阶中心矩为

$$\eta_r = \sum_{i=0}^{255} (i - \mu)^r p(i) \quad (3)$$

累量可以度量随机变量偏离高斯分布的程度。理论证明, 高斯随机变量的三阶及三阶以上累量为零^[16,17]。因此, 应用高阶累量处理信号可有效抑制加性高斯噪声。一至四阶累量的表达式如(4)式所示:

$$\left. \begin{aligned} C_1 &= m_1 = E[x] \\ C_2 &= m_2 - m_1^2 = E[(x - m_1)^2] \\ C_3 &= m_3 - 3m_1m_2 + 2m_1^3 = E[(x - m_1)^3] \\ C_4 &= m_4 - 3m_2^2 - 4m_1m_3 + 12m_1^2m_2 - 6m_1^4 \end{aligned} \right\} \quad (4)$$

式中 C_1, C_2, C_3, C_4 分别代表一、二、三、四阶累量, x 为统计区域(滑动窗口)中的图像像素值, $m_n = E[x^n], n = 1, 2, 3, 4$ 。一阶累量是图像的均值, 二、三阶累量即是二、三阶中心矩, 四阶累量不同于四阶中心矩。本文使用的特征向量是一个与能量, 熵, 均值, 二、三、四阶中心矩及四阶累量相关的向量。

实验中, 我们发现, 三、四阶中心矩要比均值和方差(二阶中心矩)大一个、甚至是几个数量级。所以, 如果对图像特征量归一化, 则均值和方差的影响就会变得非常弱。为了改善这种情况, 我们选取 $\sqrt[r]{\eta_r} (r = 2, 3, 4)$ 和 $\sqrt[r]{C_r} (r = 1, 4)$ 作为图像的特征量。 $\sqrt[r]{C_r} (r = 1)$ 和 $\sqrt[r]{\eta_r} (r = 2)$ 分别是均值和偏差。我们把 $\sqrt[r]{\eta_r} (r = 3, 4)$ 和 $\sqrt[r]{C_r} (r = 4)$ 分别称为三阶偏差、四阶偏差和四阶累量偏差。

本文使用的图像特征向量 \mathbf{X} 为

$$\mathbf{X} = [\text{ENERGY}, \text{ENTROPY}, \eta_1, \sqrt[2]{\eta_2}, \sqrt[3]{\eta_3}, \sqrt[4]{\eta_4}, \sqrt[4]{C_4}] \quad (5)$$

4 BPC 网络

在人工神经网络的实际应用中, 80-90% 的人工神经网络模型均是采用 BP 网络或它的变化形式, 它也是前向网络的核心部分, 体现了人工神经网络最精华的部分。在本文中, 我们采用一个 BP 网络与竞争网络的综合网络(BPC 网络), 其中 2 个隐含层都使用对数 sigmoid 型激活函数的改进 BP 网络, 在输出层使用自组织竞争网络, 其结构形式如图 2 所示。




图 2 BPC 网络结构

设 $x_i(n)$ 是第 n 组输入向量的第 $i(i = 1, \dots, N)$ 个元素。 $h_{1i}(n)$ 是隐含层 1 中, 第 $i(i = 1, \dots, M)$ 个神经元对第 n 组输入向量的输出。 $h_{2i}(n)$ 是隐含层 2 中, 第 $i(i = 1, \dots, K)$ 个神经元对第 n 组输入向量的输出。 2 个隐含层的激活函数都是对数 sigmoid 型激活函数, 用 f_s 表示。 $y_i(n)$ 是第 $i(i = 1, \dots, L)$ 个竞争神经元对第 n 组输入向量的输出, 它的激活函数用 f_c 表示。

隐含层 1 中第 i 个神经元的输出为

$$h_{1i}(n) = f_s \left(\sum_{j=1}^N w_{1ij} x_j(n) + b_{1i} \right), \quad i = 1, \dots, M \quad (6)$$

式中 w_{1ij} 表示 $x_j(n)$ 到隐含层 1 中第 i 个神经元的权值, b_{1i} 表示隐含层 1 中第 i 个神经元的偏差。

隐含层 2 中第 i 个神经元的输出为

$$h_{2i}(n) = f_s \left(\sum_{j=1}^M w_{2ij} h_{1j}(n) + b_{2i} \right), \quad i = 1, \dots, K \quad (7)$$

式中 w_{2ij} 表示 $h_{1j}(n)$ 到隐含层 2 中第 i 个神经元的权值, b_{2i} 表示隐含层 2 中第 i 个神经元的偏差。

输出层的输出为

$$y_i(n) = f_c \left(\sum_{j=1}^K w_{3ij} h_{2j}(n) + b_{3i} \right), \quad i = 1, \dots, K \quad (8)$$

式中 w_{3ij} 表示 $h_{2j}(n)$ 到输出层中第 i 个神经元的权值, b_{3i} 表示输出层中第 i 个神经元的偏差。

定义误差函数为

$$E = \frac{1}{2} \sum_{i=1}^L (y_i(n) - t_i(n))^2 \quad (9)$$

式中 $t_i(n)$ 是输出层中 i 个神经元的期望输出。

由于输出层的功能实际上选择隐含层 2 中有最大输出的神经元, 所以隐含层 2 的权值调整公式为:

如果

$$\left. \begin{aligned} E(k) &< \alpha E(k-1) \\ \Delta w_{2ij}(k+1) &= l_{rin} \times (1+l_r) \times [(1-m_c)\eta\delta_{ij}x_j(n) + m_c\Delta w_{2ij}(k)] \\ \Delta b_{2i}(k+1) &= l_{rin} \times (1+l_r) \times (1-m_c)\eta\delta_{ij} + m_c\Delta b_{2i}(k) \end{aligned} \right\} \quad (10a)$$

如果

$$\left. \begin{aligned} E(k) &\geq \alpha E(k-1) \\ \Delta w_{2ij}(k+1) &= l_{rde} \times (1+l_r) \times [(1-m_c)\eta\delta_{ij}x_j(n) + m_c\Delta w_{2ij}(k)] \\ \Delta b_{2i}(k+1) &= l_{rde} \times (1+l_r) \times (1-m_c)\eta\delta_{ij} + m_c\Delta b_{2i}(k) \end{aligned} \right\} \quad (10b)$$

式中 k 为训练次数; m_c 为动量因子, 一般取 0.95 左右; $E(k)$ 为第 k 次训练后网络输出与期望输出之间的误差; α 为比例常数; η 为步长, 一般取 1; l_r 为初始学习速率, 大的学习速率可能导致网络不稳定, 而较小的学习速率会降低收敛速度, 一般在 0.01 至 0.20 之间; l_{rin} 为递增乘因子, 一般在 1.01 至 1.10 之间; l_{rde} 为递减乘因子, 一般在 0.5 至 0.99 之间; $\delta_{ij} = (t_i(n) - h_{2i}(n))f'_s$.

隐含层 1 的权值调整公式与 (10) 式相似, 只是 $\delta_{ij} = (f'_s)^2 \times \sum_{k=1}^M ((t_k(n) - h_{2k}(n))w_{2ki})$.

5 实验结果

以北京地区的全色 SPOT 图像为例 (图像分辨率为 $10m \times 10m$), 它大致可以分为居民区、农田、河流 (湖泊)、山地等 4 个类别, 而作为 BPC 网络输入的是具有 7 个元素组成的图像特征向量。所以本文使用的 BPC 网络的输入层有 7 个输入量 ($N = 7$)。根据经验, 隐含层 1 采用 7 个神经元, 即 $M = 7$ 。由于输出层采用竞争网络, 它有 4 个神经元 ($L = 4$), 所以隐含层 2 也有 4 个神经元 ($K = 4$)。

为了验证本文提出的聚类方法的效果, 我们进行了三组实验, 在第一组实验中, 我们使用本文提出的聚类方法对试验图像进行聚类。在第二、三组试验中, 我们使用最邻近距离聚类法和 K 均值聚类法^[15] 对试验图像进行聚类。本文提出的聚类法、最邻近距离聚类法和 K 均值聚类法的初始聚类中心都使用相同的图像样本进行计算。需要注意的是: 在图像样本中计算最邻近距离聚类法和 K 均值聚类法的聚类特征时没有进行消除次要成分处理。本试验中使用的各个类别的聚类中心是该类别特征样本的均值, 一个图像样本可以得到一个相应类别的特征样本, 各个类别特征样本数为 20~25 个。图 3(a) 是两个相邻集镇区域的原始图像, 它的组成包括居民区 (厂房区域也作为居民区的一部分) 和农田两类。

在进行试验比较之前, 我们定义三个误差概念:

误聚误差: 农田类误聚为居民区类的面积与实际居民区类面积的比值。

漏聚误差: 居民区类误聚为农田类的面积与实际居民区类面积的比值。

聚类误差: 误聚误差与漏聚误差之和称为聚类误差。

实验结果中: 本文提出的方法则能比较正确地实现这种区域的分类, 该聚类法的聚类误差为 25.74%, 其中误聚误差为 10.74%, 漏聚误差为 15.00% (见表 1), 聚类结果如图 3(b) 所示, 图 3(b) 中灰度较亮的部分表示居民区类, 而较暗的区域则表示农田类, 在图中, 我们发现该方法比较准确地检测到了小厂房区; 最邻近距离聚类法聚类误差为 85.68%, 其中误聚误差为 85.66%, 漏聚误差为 0.02% (见表 1), 聚类结果如图 3(c) 所示; K 均值聚类法聚类误差为 74.34%, 其中误聚误差为 74.32%, 漏聚误差为 0.02% (见表 1) 聚类结果如图 3(d) 所示。图 3(c) 和图 3(d) 中灰度较亮的部分表示居民区类, 而较暗的区域则表示农田类, 在这两个图中, 居民区周围的农田区类被误聚为居民区类。

在本实验中, $l_r = 0.1$, $l_{rin} = 1.05$, $l_{rde} = 0.7$, $\alpha = 5$, $\eta = 1$, $m_c = 0.95$, 期望误差为 0.05, 最大循环数: 2000 次。

表 1 聚类误差

	误聚误差	漏聚误差	聚类误差
最邻近距离聚类法	85.66%	0.02%	85.68%
K 均值聚类法	74.32%	0.02%	74.34%
本文聚类法	10.74%	15.00%	25.74%

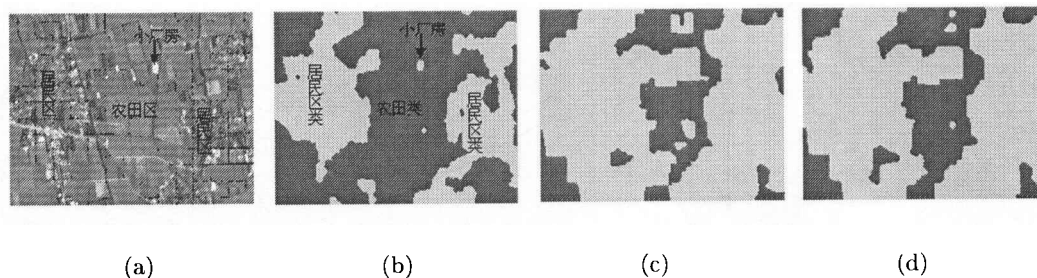


图 3 实验结果比较图

6 结 论

高分辨率遥感图像中的细小目标(如道路等)使同类区域的图像表现变得不一致,从而增加了高分辨率图像聚类的难度。本文提出了一种利用 BPC 网络进行高分辨率遥感图像聚类的方法,该方法中的图像特征量使用了高阶累量信息,高阶累量不但可以度量某类目标分布与高斯分布的差异程度,而且可以增加聚类过程的抗高斯干扰能力。在常用聚类算法与本文提出的聚类算法的比较结果中,我们发现:最邻近距离聚类法聚类误差为 85.68%,其中误聚误差为 85.66%,漏聚误差为 0.02%; K 均值聚类法聚类误差为 74.34%,其中误聚误差为 74.32%,漏聚误差为 0.02%。这两个常用聚类法会把居民区周围的农田区类误聚为居民区类。而本文提出的聚类算法则能够比较正确地反映原始图像中居民区与农田的分布,比较正确地实现这种区域的分类,该聚类法的聚类误差为 25.74%,其中误聚误差为 10.74%,漏聚误差为 15.00%,在检测结果图中,我们发现该方法比较准确地检测到了小厂房区。

本文提出的聚类方法可以用于评估城区的发展,检测居民小区、厂区和其它小建筑群的变化情况等。

参 考 文 献

- [1] 骆剑承,周成虎,杨艳,神经网络遥感影像分类模型及其与知识集成方法研究,遥感学报,2001,5(2),122-129.
- [2] A. Banerjee, P. Burlina, F. Alajaji, Image segmentation and labeling using the Polya Urn model, IEEE Trans. on Image Processing, 1999, 8(9), 1243-1253.
- [3] G. Kuntimad, H. S. Ranganath, Perfect image segmentation using pulse coupled neural networks, IEEE Trans. on Neural Networks, 1999, 10(3), 591-598.
- [4] Y. A. Tolias, S. M. Panas, Image segmentation by a fuzzy clustering algorithm using adaptive spatially constrained membership functions, IEEE Trans. on Syst., Man, and Cybernetics, part A: Syst. and Humans, 1998, 28(3), 359-369.
- [5] Y. Dong, A. K. Milne, B. C. Forster, Segmentation and classification of vegetated areas using polarimetric SAR image data, IEEE Trans. on Geoscience and Remote Sensing, 2001, 39(2), 321-329.
- [6] S. R. Seethalakshmy, P. Srivastava, J. Majumdar, Multi-modal image segmentation using a modified Hopfield neural network, Pattern Recognition, 1998, 31(6), 743-750.
- [7] J. E. Koss, F. D. Newman, T. K. Johnson, D. L. Kirch, Abdominal organ segmentation using texture transforms and a Hopfield neural network, IEEE Trans. on Medical Imaging, 1999, 18(7), 640-648.
- [8] T. Nelson, K. O. Niemann, M. Wulder, Spatial statistical techniques for aggregating point objects extracted from high spatial resolution imagery, IEEE IGARSS(International Geoscience and Remote Sensing Symposium), 2001, (from the CD-ROM of 2001 IEEE IGARSS).

- [9] Q. Zhang, J. Wang, P. Gong, P. Shi, Texture analysis for urban spatial pattern study using SPOT imagery, IEEE IGARSS(International Geoscience And Remote Sensing Symposium), 2001. (from the CD-ROM of 2001 IEEE IGARSS)
- [10] J. A. Bendiktsson, M. Pesaresi, Feature extracted and classification of urban high-resolution satellite imagery based on morphological preprocessing, IEEE IGARSS(International Geoscience And Remote Sensing Symposium), 2001, (from the CD-ROM of 2001 IEEE IGARSS).
- [11] P. Soille, Morphological Image Analysis: Principles and Applications, New York, Springer-Verlag, 1999, 1-158.
- [12] Cris L. Luengo Hendriks, Marjolein van der Glas, Lucas J. van Vliet, Image Analysis, CSP: Computer Service Labs, Delft University, Holland, November 6, 2001, 28-30.
- [13] Chris Oliver, Shaun Quegan, Understanding Synthetic Aperture Radar Images, Boston/London, Artech House, Inc., 1998, 195-295.
- [14] M. B. Charles, F. D. Timothy, D. Kevin, Automatic land-cover classification of a Barrier Island in the Virginia coast, IEEE IGARSS(International Geoscience And Remote Sensing Symposium), 2001, (from the CD-ROM of 2001 IEEE IGARSS).
- [15] 边肇祺, 等编著, 模式识别, 北京, 清华大学出版社, 1988, 216-284.
- [16] 姚天任, 孙洪著, 现代数字信号处理, 武汉, 华中科技大学出版社, 1999, 183-201.
- [17] 邹谋炎, 反卷积和信号复原, 北京, 国防工业出版社, 1999, 12-63.

THE CLUSTERING OF HIGH RESOLUTION REMOTE SENSING IMAGERY

Deng Xiangjin Wang Yanping Peng Hailiang

(*Institute of Electronics, Chinese Academy of Sciences, Beijing 100080, China*)

Abstract The technology of clustering high resolution imagery is difficult, due to the fact that the minor components, such as roads, make the appearance of the same category region non-uniform. This paper proposes a new approach to cluster high resolution remote sensing imagery. The clustering approach includes three steps. First, eliminate the minor components in moving windows. The process uses 1-D morphological watershed technique to find the left threshold and the right threshold in the histogram. The gray levels beyond the two thresholds which result from minor components will be replaced by the principle gray level. This process can improve the statistic measures when the moving windows contain some small hetero-objects. Second, compute the image characteristics in moving windows. Third, apply BPC neural network, which is combined by a back-propagation network and a competitive network, to cluster images according to the images characteristics. Three approaches are tested using SPOT images for clustering residential areas and agricultural areas in the suburb of Beijing. The experimental results show that the new clustering approach has the highest clustering accuracy.

Key words Cumulant, Eliminating the minor components, BPC neural network, High resolution remote sensing imagery, Clustering

邓湘金: 男, 1974年生, 博士生, 从事图像处理、模式识别的研究工作。

王彦平: 男, 1976年生, 博士生, 从事雷达信号处理、干涉 SAR 的研究工作。

彭海良: 男, 1939年生, 研究员, 博士生导师, 从事雷达系统与信号处理、微波遥感应用等方面的研究工作。