

文章编号: 1007-4619(2007)04-0460-08

一种多 高光谱遥感图像端元提取的凸锥分析算法

褚海峰¹, 翟中敏¹, 赵银娣², 李平湘¹, 张良培¹

(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 中国矿业大学 环境与测绘学院, 江苏 徐州 211006)

摘要: 凸锥分析方法常用于多光谱和高光谱遥感图像的端元提取。遥感图像中的每个像元都可以看作一个多维向量, 整幅影像看作由离散的非负向量构成的凸锥, 通过寻找凸锥的角点来自动获取图像的端元。本文提出了一种自动选择最佳凸锥角点的方法, 应用到传统的凸锥分析方法中, 提高了凸锥分析方法的效率。利用模拟数据和真实数据实验验证了算法的可行性。

关键词: 端元提取; 高光谱图像; 光谱分解

中图分类号: TP752.1 **文献标识码:** A

A Convex Cone Analysis Method for Endmember Selection of Multispectral and Hyperspectral Images

CHU Hai-feng, ZHAI Zhong-min, ZHAO Yin-di, LI Ping-xiang, ZHANG Liang-pai

(1 State Key Laboratory of Information Engineering in Surveying, Mapping, Remote Sensing, Wuhan University, Hubei Wuhan 430079, China; 2 School of Environment Science and Spatial Information, China University of Mining and Technology, Jiangsu Xuzhou 211006, China)

Abstract: Convex Cone Analysis (CCA) method can be applied to endmember selection from multispectral and hyperspectral imagery. Each pixel on multispectral and hyperspectral imagery can also be regarded as one vector and the whole image is a convex cone formed by a number of nonnegative discrete vectors, so endmember selection is equivalent to search for the vertices of a convex cone. A method of automatically selecting best corners (vertices) is presented, which improves the traditional CCA method. Experiments on simulated data and real data verify the validity of CCA method.

Key words: endmember selection, hyperspectral imagery, spectral unmixing

1 引 言

端元 (End Member) 作为描述线性混合模型的主要参数, 代表某种具有相对固定光谱的特征地物。通过端元提取来获得图像中的基本信息, 在光谱分解、目标检测、变化检测和图像分类等领域是一项极有意义的工作。

1993年, Boardman首先提出将凸面几何体应用于高光谱图像的纯净像元的自动提取, 高光谱图像

的所有数据, 在其特征空间中, 均由图像中所有地物所对应的纯净像元 (端元) 为顶点的单形体所包围^[1]。凸锥分析方法 (Convex Cone Analysis, CCA) 是一种应用于多光谱和高光谱图像分类和混合像元分解的方法^[2]; N-FNDR方法利用高光谱数据在特征空间中的凸面单形体的特殊结构, 通过寻找具有最大体积的单形体, 自动获取图像中的所有端元^[3]; 逐次最大角凸锥体 (Sequential Maximum Angle Convex Cone, SMACC) 是一种基于凸锥模型的自动获取图像中端元并提供端元丰度 (Abundance) 图像

收稿日期: 2006-05-23 修订日期: 2007-01-07

基金项目: 国家重点基础研究发展规划 (973 计划) 项目 (编号: 2006CB701302); 国家自然科学基金资助项目 (编号: 40523005, 40471088)。

作者简介: 褚海峰 (1982—), 男, 硕士。毕业于武汉大学遥感信息工程国家重点实验室。主要研究领域: 遥感图像处理 and 地理信息系统系统开发。已发表论文 1 篇, 专著 1 部。

的方法^[4]。顶点组分分析 (Vertex Component Analysis VCA)方法是一种同时利用单形体和凸锥进行端元提取的方法^[5]。

凸锥分析方法通过遥感图像的物理特性找到凸锥的边界点即顶点(角点)进而获得端元进行遥感影像的分类或混合像元分解。通过 CCA方法得到的凸锥角点个数往往大于端元个数,尤其当端元数大于三个的时候,角点数目会增长得很快,需要从角点中选择和端元数相同的角点作为最佳角点,从而确定图像上的端元,进行光谱分解或分类。传统的 CCA方法在选取角点时通过将图像数据和角点投影到特征平面,通过目视法寻找距离“数据云”近的角点作为最佳角点。这种方法需要人为的干预,在角点数目很多时效率很低,不是一种自动的方法。本文提出了一种自动选择最佳凸锥角点的方法,并将它应用到传统的凸锥分析方法中,提高了凸锥分析方法的效率。

2 凸锥分析算法与端元提取

多光谱和高光谱遥感图像本身具有一些物理特性,如辐射值和反射值的非负性等;图像中的每个像元属性都可以用一个多维向量表示,维数等于波段数。由各个波段光谱灰度值或反射值形成的向量,它们分布在一个非负的凸区域内,可以被表示为非负组分(用来进行分类或分解的目标,这里含义等同于端元)的线性组合^[6]。

2.1 凸锥分析算法

凸锥分析方法的目的是找到凸锥的角点,获得端元光谱,进行遥感影像的分解和分类。寻找凸锥的角点是根据凸锥的一个基本性质:一个 l 维向量,如果它有 $c-1$ (c 为组分数)个分量为 0 其他分量非负,则该向量为凸锥的角点。进行 CCA 计算,首先要对图像数据进行预处理。主要包括数据标准化和去掉数据中的负值。数据标准化是使每个像元的范数归一,当数据中有较少的负值时(小于千分之一)可以直接将其赋为零,否则去掉负值较多的波段或者去掉相应的像元。

给定一幅遥感图像,图像宽度为 n 图像高度为 m 波段数等于 l 则该图像可以视为一个 $m \times n \times l$ 列的矩阵 S 矩阵 S 中的每一行对应于图像像元光谱特征,每一列对应于图像所有像元的某一波段灰度值。凸锥分析方法主要包括以下几方面内容:凸锥的构造、基于获得的凸锥计算角点及凸锥的应用。

2.1.1 构造凸锥

多 高光谱遥感数据大量的光谱波段为了解地物提供了极其丰富的遥感信息,然而波段的增多也导致信息的冗余和数据处理复杂性的增加。因此需要进行特征选择,将高光谱数据投影到它的子空间,这样既节省了处理时间,又提高了数据的信噪比。利用公式 (1) 和公式 (2) 进行特征选择:

$$C = S^T S \quad (1)$$

$$C = P D P^T \quad (2)$$

式中, C 是大小 $l \times l$ 的相关矩阵,矩阵 D 和 P 的维数与 C 相同; P 是矩阵 C 的特征向量构成的规范正交阵; D 是对角阵,正对角线元素是由对应于 P 的特征向量的特征值构成的,其余元素均为零。对特征值从大到小进行排序,选择最大的特征值,利用特征选择后的结果构造凸锥。

$$x = p_1 + a_1 p_2 + \dots + a_{c-1} p_c \geq 0 \quad (3)$$

假定先验的组分数为 c 则 p_1 是对应于 c 个最大特征值的特征向量, 0 为零向量。 x 为 p_1 的线性凸组合,可以通过乘以一个常数使向量 p_1 的系数为 1 其他的 $c-1$ 个参数 a_i 为任意常数, x 是严格非负的。 p_1 对应于最大的特征值,该特征向量只包含非负数值,同时,因为特征向量是相互垂直的,所以剩下的特征向量必然包含负值。因此,可以找到一组系数集 $\{a_i\}_{i=1}^{c-1}$ 使得 x 的 $c-1$ 个分量为 0 所有其他分量非负,这样的点也就是凸锥的角点。图 1 为一个三维凸锥,特征向量 EV_1, EV_2, EV_3 作为轴,由相关矩阵得到,对应于 p_1, p_2, p_3 。




图 1 三维凸锥

Fig 1 Three dimensional convex cone

2.1.2 计算凸锥角点

在 CCA 算法中,提出了可以计算具有任意个数组分(组分数为 c)的凸锥。为了说明该算法,将 (3) 式写成如下形式:

$$x = [P_1 \dots P_c] \begin{bmatrix} 1 \\ a_1 \\ \vdots \\ a_c \end{bmatrix} = P_a \geq 0 \quad (4)$$

式中, P_i 为 b 维列向量。当 $b > c$ 时, 将 P_i 的元素看作系数, 将 a_i 看作变量, 存在如下形式的 b 个等式:

$$P_1 + a_1 P_2 + \dots + a_{c-1} P_c = 0 \quad j = 1, \dots, b \quad (5)$$

从上面 b 个等式中任意选择 $c-1$ 个方程组合成一个方程组, 该方程组的结果为 $a_i (i=1, 2, \dots, c-1)$, 由 $a_i (i=1, 2, \dots, c-1)$ 构成的 $P_i (i=1, 2, \dots, c)$ 的线性组合 x 满足有 $c-1$ 个分量为零。

上面求得的 x 如果同时满足 (3) 式 (≥ 0), 或等价于:

$$\min(x) = 0 \quad (6)$$

则此时的 x 即为凸锥的角点。

对于 b 个等式 $c-1$ 个系数, 有 C_b^{c-1} 种组合, 每种组合对应于一个 $x(P_a)$, 即候选角点, 如果角点满足条件 (6) 式, 即为凸锥的角点。

当 $b > 1$ 时, 算法寻找所有波段组合的可能获得系数 $a_i (i=1, 2, \dots, c-1)$ 满足 (3) 式, r^i 表示波段的某种组合。

2.1.3 应用凸锥

当得到凸锥, 便可以使用凸锥的角点光谱作为端元进行分类或混合像元分解。在 CCA 方法中, 对于分类使用下面的匹配滤波:

$$m = x^T P_{1:c} D_{1:c}^{-1} P_{1:c}^T \quad (7)$$

式中, x 是角点光谱; $P_{1:c} D_{1:c}^{-1} P_{1:c}^T$ 是相关矩阵 C 的一种降秩的逆矩阵。该逆矩阵的计算只使用了对应于 c 个最大特征值的特征向量 $P_{1:c}$ 。该滤波操作等价于光谱角映射方法。当像元光谱和 x 越类似时, 它的结果 m 值越高, 否则越低。在分类时, 图像中的像元光谱与哪个端元的光谱计算出的 m 值最高, 就被分为哪一类。

对于光谱分解的情形, CCA 采用最小二乘回归的方法, 具体公式如下:

$$U = (X^T X)^{-1} X^T \quad (8)$$

式中, X 是一个大小 $b \times c$ 的矩阵, 它的列即是上面计算得到的角点; 分离运算符 U 是一个 $c \times b$ 矩阵, 将该运算符应用于像元光谱, 产生的结果是组分丰度估计矩阵。

2.2 角点的自动选择

通过 CCA 方法中计算凸锥过程得到的凸锥的角点个数往往大于端元的个数, 尤其当端元数大于

三个的时候, 角点的数目会增长得很快, 这时需要从角点中选择和端元数相同的角点作为最佳角点, 从而确定图像上的端元, 进行光谱分解或分类。传统的 CCA 方法在选取角点时通过将图像数据和角点投影到特征平面, 通过目视法寻找距离“数据云”近的点作为最佳角点。这种方法需要人为的干预, 在角点数目很多时效率很低, 不是一种自动的方法。

在所有的角点中, 有的角点和其他的角点之间的光谱角很小, 最佳角点要保证彼此之间具有较大的光谱角, 最佳角点的个数与端元的个数相同。本文使用一种自动寻找最佳角点的方法。首先, 将所有的角点分成 c 类 (c 为端元的数目), 然后在每一类角点中找出与图像上的像元匹配最好 (使用光谱角匹配法) 的角点作为最佳角点, 图像上与之对应的像元作为端元。具体步骤如下:

(1) 将角点投影到特征空间, 得到向量 $G_p(i)$ 。

$$G_p(i) = \text{Comer}(i) P_{1:c} \quad (i=1, 2, \dots, NC) \quad (9)$$

式中, $\text{Comer}(i)$ 为第 i 个角点的光谱向量 ($1 \times b$ 维, b 为波段数); NC 为角点的个数; $P_{1:c}$ 为 c 个最大的特征值对应的特征向量构成的矩阵 ($b \times c$ 维); $G_p(i)$ ($1 \times c$ 维) 是由 $\text{Comer}(i)$ 和 $P_{1:c}$ 点积运算得到, 为投影到特征空间的角点向量, 向量的每个分量对应于角点投影到每个特征空间的值。

(2) 从 NC 个 $G_p(i)$ 中找出 c 个的构成最大体积的 $G_p(k)$ 作为角点分类初始点, 每一个 $G_p(k)$ 代表一类角点。通过实验发现, 构成最大体积的 c 个向量 $G_p(k)$ 彼此之间的距离最大, 可以作为角点分类的初始点。

$$G = (G_p(k_1)^T, G_p(k_2)^T, \dots, G_p(k_c)^T) \quad (10)$$

G 为 c 个列向量 $G_p(k)^T$ 构成的矩阵。

$$V = \frac{1}{(n-1)!} \sqrt{|G^T G|} \quad (11)$$

式中, V 是以原点为顶点的 c 个向量 $G_p(k)$ 构成的单形体的体积^[7]。

(3) 遍历每个角点, 计算其与每个角点分类初始点 $G_p(k)$ 之间的光谱角, 并将其归为最小光谱角值对应的角点 $G_p(i)$ 哪一类。

(4) 将每类角点中的每个角点与图像上的像元进行匹配 (光谱角匹配)。每一类中与图像像元匹配最好的那一个像元为最佳角点, 与之对应的图像上的像元即为相应的端元。

通过上述方法, 将凸锥分析方法计算得到的角点自动分成 c 类, 在每类角点中找到最佳的角点, 同时得到相对应的 c 个端元。该方法使用编程很容易

实现, 是一种全自动的角点选择方法。

根据前面的介绍, 本文采用的端元自动提取方法的流程图如图 2 所示。

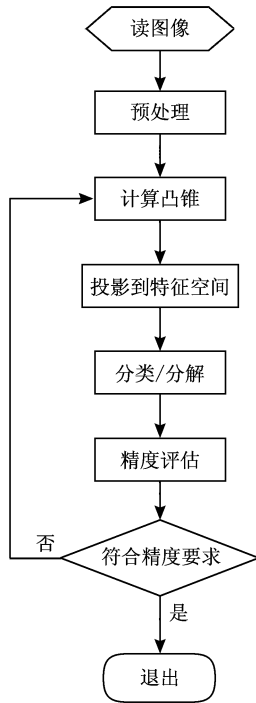


图 2 端元自动提取流程图

Fig 2 Flowchart of endmember selection




图 3 模拟数据三类对象光谱曲线

Fig 3 Spectra corresponding to three objects of simulated data

相对应的图像上的点为端元。利用找到的端元通过光谱角匹配方法进行分类, 分类结果与实际情况相同。按照传统的角点选择方法, 通过目视法^[8]观察该特征平面投影图(图 4), 寻找距离数据云最近的角点, 很容易看出角点 2 1和 7为最佳角点, 与自动选择角点的方法结果相同。




图 4 模拟数据特征平面投影图

Fig 4 Projections of simulated data spectra to the eigenvector space

3 实验与结果分析

3.1 模拟数据实验

3.1.1 分类实验

通过对模拟数据的分类来验证凸锥分析方法的可行性。

(1)数据准备。模拟图像是一个由大小 64×64 的背景及上面两个大小 24×24 不同的目标共三类对象构成的图像, 他们都是 10 个波段, 分别以 4 5 6 为中心的 Gaussian 函数产生的曲线。三类对象的光谱曲线如图 3 所示, 计算三类光谱之间的光谱角值为 0.78。由三类对象光谱构成的一幅多光谱图像, 将 1/40 的白高斯噪声 (即 $SNR=40$) 加入该图像, 该图像为本实验的源图像。

(2)分类。通过本文提出的自动选择最佳凸锥角点的方法进行计算, 得到的最佳角点为 2 1 7。具体过程如下: 首先利用式 (9) — (11) 计算出构成最大体积的角点为 2 4 5 根据光谱角最小的原则将角点分成三类, 然后找出每一类中与图像上匹配最好的三个角点, 它们分别为 2 1 7 与这三个角点

3.1.2 混合像元分解实验

模拟数据混合像元分解实验, 可以通过预先设定的端元及端元丰度 (Abundance) 利用线性光谱模型进行数据模拟, 模拟后的数据相当于已知混合像元中每个端元的光谱和端元的丰度值, 并将混合后的图像上加上适当的噪声。通过该实验, 验证凸锥分析方法的可行性。

(1)数据准备。模拟图像是由 5 类端元经过线

性光谱模型混合生成,这 5 个端元都具有 10 个波段,分别以 3 4 5 6 7 为中心的高斯函数产生的曲线,并且保证图像上至少有 5 个与之对应的纯净端元。5 类对象的光谱曲线如图 5 所示。图像大小为 64 像元×64 像元,将 1/40 的白高斯噪声(即 SNR=40)加入该图像,合成的模拟图像为本实验的源图像。




图 5 5 类端元光谱曲线

Fig 5 Spectra of five endmembers

(2) 端元提取。通过凸锥分析方法,共找到了 17 个角点,它们投影到特征空间的分布图如图 6 所示,可以看到,这时通过目视法寻找距离数据云较近的最佳角点是很困难的。利用本文提出的自动寻找最佳角点的方法,找到了 5 个最佳角点,并最终准确地找出了图像上的纯净端元,与实际的端元位置完全一致。

(3) 分解。依据找到的端元利用最小二乘方法进行线性光谱分解。利用双变量分布统计方法^[8,9]对分解结果进行评价,结果见表 1(端元标号与角点编号并非一一对应),它们的 RMSE 值越小,本次分

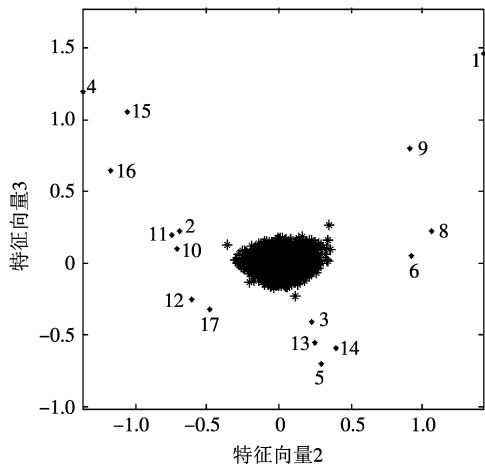


图 6 模拟数据特征平面投影图

Fig 6 Projections of simulated data spectra to the eigenvector space

表 1 分解结果的双变量分布统计

Table 1 Bivariate value of unmixing result

端元	RMSE 值
1	0.0085148
2	0.016697
3	0.018724
4	0.015535
5	0.0092039

解实验的结果越好。

本文使用商业软件 Env 中提供的 SMACC^[4]功能从图像中找 5 个端元的光谱曲线如图 7 所示,很明显其中有一个端元与实际情况不符。错误的端元选取必将导致它比凸锥分析方法的分解效果要差,对它的评价与上面的方法类似,这里省略了对其进行的分解精度评价过程。




图 7 SMACC 方法端元提取结果

Fig 7 Endmembers selected by SMACC method

3.2 真实数据实验

真实数据并不像模拟数据那样,因为地表实际情况往往很复杂,本文为了验证算法的实用性,对真实数据进行了端元提取及混合像元分解实验。

(1) 数据介绍。实验的影像数据为江苏省常州市夏桥的一个农场,获取于 1999 年 9 月,传感器为机载推帚式成像光谱仪(Pushbroom Hyperspectral Imager HI)。本次飞行航高为 2000m,地面空间分辨率 3m,波长范围在 0.42—0.85μm,光谱分辨率 5nm,共有 80 个波段数据。实验区的经度 119°22'11",纬度是 31°41'44"。主要地物类型有道路、水体、水稻和菜地等。为减少计算量,本文从中截取了大小为 200 像元×200 像元一块区域的 20 个波段进行实验。图 8 是该区域的图像立方体。




图 8 PHI 图像立方体
Fig 8 PHI image cube




图 9 MNF 变换特征图
Fig 9 Result of MNF transform

(2) 端元提取。通过 MNF 变换特征图 (图 9) 可以看出图像中有 4 类具有典型特征的地物。利用凸锥分析方法可以获得 24 个角点, 通过本文提出的方法自动选取了 4 个最佳角点, 并找到了图像上与之对应的端元, 4 类端元的光谱如图 10 所示。




图 10 端元光谱曲线
Fig 10 Spectra of endmembers

(3) 进行线性光谱分解实验, 结果如图 11 所示。凸锥分析方法能够找出图像中的 4 类端元, 图 11(a), (b), (c) 和 (d) 分别为道路、水稻、蔬菜、水系的丰度图, 与实际情况基本一致; 图 11(e) 为计算得到的均方根误差 (RMSE) 影像。




图 11 PHI 分解结果图

Fig 11 Unmixing result of PHI image

同样使用 Env 中提供的 SMACC 提取图像上的 4 个端元, 端元光谱如图 12 所示。根据地面数据可以知道它们分别为道路、蔬菜、水和分布在水里的未知地物, SMACC 方法未能找到水稻。根据真实数据分析可知, 由于水稻和蔬菜的光谱很接近, 因此 SMACC 未能将它们分开。进行线性光谱分解, 图 13(a), (b), (c) 和 (d) 分别为道路、蔬菜、水和未知地物的丰度图, 图 13(e) 为均方根误差 (RMSE) 影像。

表 2 为 CCA 方法和 SMACC 方法提取 4 个端元进行线性光谱分解后误差的定量比较。由表中可以看出, CCA 方法 RMSE 的平均值较小且标准偏差小于 SMACC 方法, CCA 方法找出的 4 个端元进行线性光谱分解的效果更好。




图 12 端元光谱曲线

Fig 12 Spectra of endmembers




图 13 PHI 分解结果图

Fig 13 Unmixing results of PHI image

表 2 CCA 和 SMACC 方法误差比较

Table 2 RMSE comparison of CCA and SMACC methods

	最小值	最大值	平均值	标准偏差
CCA	0.000000	11.899428	0.530584	0.190293
SMACC	0.000000	3.504625	0.784105	0.319807

4 结论与讨论

凸面几何可用于多光谱和高光谱图像的端元提

取。凸锥分析方法利用凸锥的几何性质寻找端元, 不需要目标的任何先验知识, 可以实现自动的端元提取。通过模拟实验验证了凸锥分析方法的可行性, 寻找的端元与实际类别对应, 进行分类或线性光谱分解效果较好。真实实验中, 自动选取的端元与实际地物相对应, 线性光谱分解的效果较理想。本文采用了一种自动选取角点的方法, 当角点数目很多时, 可以自动的获得最佳角点, 提高了凸锥分析方法的效率。同时, 与 Env 中提供的 SMACC 方法进

行了比较, 由凸锥分析方法寻找出的端元进行线性分解的效果更理想。

参考文献 (References)

- [1] Boardman J W. Automated Spectral Unmixing of AVIRIS Data Using Convex Geometry Concepts in Summaries [A]. Summaries of 4th JPL Airborne Geoscience Workshop [C]. JPL Publication 1993 261993, vol 4, 11—14.
- [2] Agustín Farraguerri, Chén-I Chang. MultiSpectral and Hyperspectral Image Analysis with Convex Cone [J]. IEEE Transactions on Geoscience and Remote Sensing 1999 37(2): 756—770.
- [3] Winter M E. N-FNDR: An Algorithm for Fast Autonomous Spectral Endmember Determination in Hyperspectral Data [A]. Proc SPIE Imaging Spectrometry V, Washington, SPIE Publ [C], 1999.
- [4] Günzinger J A, Raikowski J, Hoke M L. The Sequential Maximum Angle Convex Cone (SMACC) Endmember Model [A]. Proceedings SPIE Algorithms for MultiSpectral and Hyperspectral and UltraSpectral Imagery [C], 2004, 5425-1.
- [5] MP Nascimben, MB Dias. Vertex Component Analysis: A Fast Algorithm to Unmix Hyperspectral Data [J]. IEEE Transactions on Geoscience and Remote Sensing 2005 43(4): 898—910.
- [6] Mavrounjotis M L, Harper A M, Farraguerri A. Classification of Pyrolysis Mass Spectra of Biological Agents Using Convex Cone [J]. J Chromatographs 1994 8: 305—333.
- [7] Geng X B, Zhang B, Zhang X, et al. A Unmixing Method for Hyperspectral Imagery Based on High-dimensional Convex Simplex [J]. Nature Science Development 2004 14(7): 810—814. [耿修瑞, 张兵, 张霞等. 一种基于高维空间凸面单形体体积的高光谱图像分解算法 [J]. 自然科学进展, 2004 14(7): 810—814]
- [8] Liu W G, Wu E Y. Comparison of Non-linear Mixture Models Sub-pixel Classification [J]. Remote Sensing of Environment 2005 9(4): 145—154.
- [9] Wu B. Study on Automated Decomposition of Mixture Pixels and Its Extension Model [D]. 2005 [吴波. 混合像元自动分解及其扩展模型研究 [D]. 学位论文, 2005]