

文章编号: 1001-9014(2004)06-0441-06

基于高光谱图像特征提取与凸面几何体投影变换的目标探测

张兵¹, 陈正超¹, 郑兰芬¹, 童庆禧¹,
刘银年², 杨一德², 薛永祺²

(1. 中国科学院遥感应用研究所 遥感科学国家重点实验室, 北京 100101
2. 中国科学院上海技术物理研究所, 上海 200083)

摘要:在介绍凸面几何体概念和高光谱图像光谱线性模型的基础上,探讨了凸面几何体和高光谱图像的关系,提出了在光谱特性提取的基础上利用凸面几何体投影变换进行高光谱图像目标探测的方法,并成功地应用于亚运村建材市场屋顶板材和亚运村中心地区真假草坪的自动识别和探测中. 试验证明该方法不需要探测目标的任何先验知识就能达到比较好的目标探测效果. 同时试验还表明,由于高光谱图像波谱范围宽,特别是有短波红外、中红外和热红外范围的图像,不仅增加了地物的可分性,而且为探测地物物理性质提供了可能.

关键词:高光谱;目标识别;特征选择;投影变换
中图分类号:P237 **文献标识码:**A

OBJECT DETECTION BASED ON FEATURE EXTRACTION FROM HYPERSPECTRAL IMAGERY AND CONVEX CONE PROJECTION TRANSFORM

ZHANG Bing¹, CHEN Zheng-Chao¹, ZHENG Lan-Fen¹, TONG Qing-Xi¹,
LIU Yin-Nian², YANG Yi-De², XUE Yong-Qi²

(1. Institute of Remote Sensing Applications, Chinese Academy of Sciences, Beijing 100101, China;
2. Shanghai Institute of Technical Physics, Chinese Academy of Sciences, Shanghai 200083, China)

Abstract: After introducing the conception of convex geometry and spectral linear model, the relationship between convex cone and hyperspectral imagery was discussed. A method based on feature extraction and convex cone projection transform for hyperspectral imagery object detection was proposed. The method was tested with hyperspectral data obtained from OMIS-II. Based on the experiments, the capability of detecting object's physical property by hyperspectral imagery was also discussed.

Key words: hyperspectra; target detection; feature selection; projection transformation

引言

高光谱遥感起源于20世纪70年代初的多光谱遥感,它将成像技术与光谱技术结合在一起,在对目标空间特征成像的同时,对每个空间像元经过色散形成几十乃至几百个窄波段以进行连续的光谱覆盖. 同传统遥感技术相比,由于其所获取的图像包含

了丰富的空间、辐射和光谱三重信息,高光谱遥感或成像光谱遥感技术的发展是过去二十年中人类在对地观测方面所取得重大技术突破之一,是当前遥感的前沿技术. 高光谱遥感图像具有图像波段众多(数百甚至上千个)、光谱分辨率更高(高达5~10nm)、覆盖波长范围更宽(从可见到红外)等突出特点,能够做到对图像目标的精细分类和有效识别.

收稿日期:2003-11-14,修回日期:2004-03-01

Received date: 2003-11-14, revised date: 2004-03-01

基金项目:国家863波谱库(2002AA130010)和中科院遥感应用研究所知识创新资助项目(CX020018)

作者简介:张兵(1969-),男,陕西渭南人,博士,研究员,研究方向为高光谱遥感技术与应用,现担任中国空间科学学会空间遥感专业委员会委员、国际光学工程学会(SPIE)亚太环境遥感会议组委会成员.

在高光谱遥感图像的分类和目标识别中,最简单常用的方法是基于整波形特征的光谱曲线匹配方法,通过比较图像光谱和参考光谱的相似度来识别,代表算法是光谱角度匹配(SAM)^[1]. 该种算法充分发挥了“精细”光谱曲线的优势,算法简单有效,但是结果对噪声敏感,而且可能因为参考光谱和图像光谱获取的条件不一致导致错误匹配. 第二类算法是光谱特征参量化方法,这类算法从光谱曲线上提取有意义的光谱特征参量,如吸收光谱的位置和吸收深度,或者是利用不同特征波段的比率参数来识别. 代表性的算法有针对矿物识别的光谱吸收指数法(SAI)^[2]和针对植被识别的归一化植被指数(NDVI)^[2]等等. 该类算法对有典型的吸收(或反射)特征的光谱能够有效的识别,但是必须对光谱曲线进行很好的定标处理,然而目前对光谱的定标很难达到理想要求^[3]. 第三类算法是统计模式识别算法,如最大似然法和 K-Means 等. 这类方法是建立在于处理常规少数波段的遥感图像方法的基础上,随着高光谱图像波段的增加,统计参数的有效估计是个难点,而且会出现著名的 Hughes 现象.

近年来,一种对高光谱图像数据的投影变换(projection transform, projection pursuit)方法越来越引起人们的注意,已经广泛的用于高光谱图像的特征选择、端元提取、混合像元分解、图像分类和识别等方面^[4,5]. 投影变换最早由 Tukey 提出,是一种基于多元数据的探索性分析方法,投影变换的关键在于计算满足一定条件的变化矩阵,变化矩阵的每个行/列向量表示一个投影方向,投影方向的选择是由投影指标(projection index)决定的. 主成分分析(PCA)和最小噪声变换(MNF)是最常用的两种特征提取的方法,也是典型的投影变换. PCA 选择数据方差为投影指标, MNF 选择数据的信噪比为投影指标. 比较典型的还有 Jimenez 和 Landgrebe 用 Bhattacharyya 距离作为投影指标^[5]; Ifarrageri 和 Chang 把光谱数据的概率密度函数和高斯分布的信息差异(information divergence)作为投影指标来分析高光谱图像^[6]; Chiang 和 Chang 等人选择偏斜度(skewness)和峰度(kurtosis)作为投影指标进行高光谱图像异常目标的探测^[7].

但是,对于有几十个乃至上百个波段的高光谱图像数据来说,基于所有波段的投影变换的组合数目是惊人的,运算速度也是难以忍受的. 如果将有 128 波段的 OMIS-I 图像投影到三维空间,可以选择的投影方向有 $C_{128}^3 = 341\ 376$ 种. 因此,在进行投影

变换之前对高光谱图像减维及特征波段的选择是非常必要也是非常有意义的.

本文在地物光谱特征分析的基础上,充分利用了地物在可见光、近红外,尤其是在短波红外、中红外和热红外方面的差异,通过光谱特征选择与特征提取,提出了优化和减维后的投影空间. 在此基础上,本文将基于凸面几何体的投影变换算法成功的应用到了高光谱图像目标分离与识别当中. 在亚运村建材市场屋顶板材和亚运村中心地区真假草坪的自动识别和探测中本文的方法得到了有效的验证.

1 凸面几何体和高光谱图像的关系

凸面几何(convex geometry)是描述和处理凸集(convex sets)的几何. 空间中 n 维凸集定义为一个点的集合,这个集合的所有点都可以用集合边缘的点的线性组成来表示,并且边缘点的权必须为非负,同一个点的组分的所有权值的和为 1. 所谓凸面几何体是指空间几何体内任意两点的连线仍然在几何体内. 欧氏空间中的 n 维凸面几何体是由若干个 $(n-1)$ 维的凸集构成,只有 $(n+1)$ 个顶点的凸面几何体是 n 维空间中最简单的形式,称之为单形体(simplex). 如一维空间中由 2 个点确定的线段、二维空间中由 3 个点确定的三角形、三维空间中由 4 个点确定的四面体^[8].

在一般的情况下,高光谱图像上的单个像元是由几种不同的地物组成,而且通常是假设像元光谱是这些组成成分光谱的线性组成,即光谱线性模型,表示为公式为

$$p_{ij} = \sum_k e_{ik} c_{kj} + \varepsilon, \text{ 且 } \sum_k c_{kj} = 1, c_{kj} \geq 0 \quad (1)$$

其中 p_{ij} 是第 i 波段的第 j 个像元; e_{ik} 是第 i 波段上组成像元的第 k 个组分, c_{kj} 是第 j 个像元的第 k 个组分所占的比率; ε 是高斯随机噪声.

高光谱图像上的每个象素在 n 个波段上的所有 DN 值(反射或者辐射值),在二维空间上是一条连续的光谱反射曲线,在 n 维矢量空间中却是一个点. 由于所有的 DN 值恒为非负值,且满足光谱线性模型,所以一幅有 n 个波段的高光谱图像就是 n 维矢量空间中的一个凸面几何体,且图像中纯像元分布在凸面几何体的顶点附近,几何体内每个点在空间中的坐标值分别是象素在 n 个波段上的 DN 值. 因为同类地物的 DN 值相同或者相近,所以相同地物在凸面几何体内是聚集在一起的. 因此对凸面几何体的处理等价于对高光谱图像的处理. Boardman 和

Kruse 等人将凸面几何体应用于高光谱图像的纯像元的自动提取^[8].

2 基于特征选择的凸面几何体投影变换

高光谱遥感数据大量的光谱波段为我们了解地物提供了极其丰富的遥感信息,但是当光谱特征维数增加时,其特征组合更是呈指数方式增加,其结果导致算法更加复杂、运算效率大大下降甚至成为不可能,所以,光谱特征空间的减少和优化十分必要.特征空间减少的方式可以概括为两种:特征选择和特征提取,其中特征选择的方式可概括为光谱距离统计和光谱特征位置搜索这 2 种方式.特征提取是建立在各光谱波段间的重新组合和优化基础上的,算法不仅需要所有的波段参与运算,而且没有包含对反映地物理化性质的光谱特征分析,减维后得到的新特征空间子集已没有了任何光谱特性的物理含义.

凸面几何体投影变换和特征提取类似,是将高维的几何体投影到感兴趣的低维空间上,以突显和压抑某些特征,实现图像上的目标识别和分类.它是一种正交投影变换,能够用来进行特征选择和提取、高维数据降维等.表达的一般形式为

$$Y = A^T X. \quad (2)$$

其中 X 和 Y 分别是变换前后的数据矩阵, A 是变换矩阵. 经过投影变换后的凸面几何体的特征 1 和 2 得到突显,特征 3~7 被压抑^[9],如图 1 所示. 从图 1 右图可以看出原来的凸面几何体实际上包含 3 种不同性质的散点,即与此凸面几何体对应的图像包含 3 种地物.

投影指标是投影效果的度量,选择不同的投影指标就决定了不同的投影效果和投影方式. 在二维矢量空间中,点与点之间的聚合度和离散度能够很好地描述点的分布情况,本文的方法是将多维的凸面几何体的点投影到二维平面上,所以选择聚合度和离散度作为投影指标. 具体的投影变换方法是:先求出凸面几何体的顶点,平移几何体,分别以每个顶点为突面几何体的原点,以每个顶点的在空间的法线方向为参考投影方向,然后旋转突面几何体,在不同的角度上将多维凸面几何体依次投影到二维平面上. 在二维平面上的类间离散度最大,类内聚合度好的面最优为投影面. 并在该投影面上对地物进行分类. 这种做法的特点是根据地物像元点在多维空间中的分布情况分离,不需要图像的先验知识,在变换的过程中主要是平移和旋转,算法简单.

算法简单描述如下:




图 1 凸面几何体投影变换模型

Fig. 1 The model of convex geometry projection transform

- 1) 原始高光谱图像特征提取.
- 2) 计算突面几何体的顶点
- 3) 对凸面几何体进行平移和旋转,在不同的角度将凸面几何体投影到二维平面.
- 4) 选择最优的投影结果,在投影平面中对投影结果分类.

本文采用 PCA 和 MNF 进行特征提取,采用 N-FINDR 方法来计算凸面几何体的顶点. N-FINDR 方法从任意一个点开始,逐步迭代计算出图像在 n 维空间中有 $(n+1)$ 个顶点的单形体的体积,形成最大体积的点就是凸面几何体的顶点^[10],也就是图像中的端元. 计算体积所用的公式为

$$V(E) = \frac{1}{(L-1)!} \text{abs}(|E|). \quad (3)$$

其中 E 是由端元向量扩展的方阵, $E = \begin{bmatrix} 1 & 1 & \dots & 1 \\ \vdots & \vdots & \dots & \vdots \\ e_1 & e_2 & \dots & e_l \end{bmatrix}$, e_i 是第 i 个端元在所有波段的 DN 值组成的列向量, L 为波段数.

3 试验

利用凸面几何体投影变换进行高光谱图像目标探测和识别的一个典型例子是对北京亚运村建材市场屋顶材料的探测和人工草坪的识别. 试验选用的该地区的高光谱图像是 2000 年 11 月获取的 OMIS-II 航空影像,航高约 1000m,地面分辨率约 3m,重叠度约 60%,扫描速率 15 线/s.

图 2(a) 是奥体公园中心地区的真彩色合成影像,红框内是试验区域屋顶建材,从人眼看来,这块区域都是一样的蓝色建材,没有任何区别. 可是当我们用本文的方法对该区域进行了处理,在人眼看来一样的屋顶建材就“原形毕露”了,被识别为 3 种不同的板材.

具体处理方法的第一步是进行特征选择和提取. 试验用的 OMIS-II 图像有 64 个波段,覆盖了可见近红外至热红外(0.46~12.5 μm)的全部大气窗




图2 亚运村建材市场屋顶材料识别(a)是真彩色显示图像(b)是二维投影面上的散点分布图(c)是分类识别的结果
Fig. 2 The identification of roof boards of Yayun District (a) true color image of test area (b) the scatter plot of the projection (c) the identification result of the roof boards




图3 PCA(左)和MNF(右)变换图像的特征值
Fig. 3 The eigenvalues of the image resulted from PCA(left) and MNF(right)




图4 奥体公园中心地区人工草坪和天然草坪识别(a)图是真彩色显示图像(b)是二维投影面上的散点分布图(c)图是分类识别的结果
Fig. 4 The identification of true grass and artificial grass of Olympic Park, Beijing. (a) true color image of test area (b) the scatter plot of the projection (c) the identification result of the roof boards

口,其中在可见光—近红外波段($0.46 \sim 1.1 \mu\text{m}$)有60个波段,另外的4个较宽的波段分别位于短波红外($1.55 \sim 1.75 \mu\text{m}$, $2.08 \sim 2.35 \mu\text{m}$),中红外($3.0 \sim 5.0 \mu\text{m}$)和热红外($8.0 \sim 12.5 \mu\text{m}$).由于要识别的屋顶在真彩色和假彩色合成影像中几乎完全一样,所

以可以推断屋顶在这个区域内的反射值差别不大.我们统计了屋顶板材在8个典型波段的图像原始像元辐射值(见表1),从表中的数据 and 图像像元光谱曲线可以清楚的看出,屋顶板材在可见光—近红外波段的辐射值只有细小差别,但在短波红外、中红外

表 1 3 种板材的像元辐射值

Table 1 Radiation numbers of three kinds of roofboards

波长 (nm)	498	553	600	1004	1650	2215	4000	10250
板材类型	B	G	R	NIR	SWIR	SWIR	MIR	TIR
国产板材	1291	1499	1784	1024	915	914	238	1098
韩国板材	1211	1353	1871	690	483	380	139	1707
大连浦项制铁板材	1258	1447	2333	945	1260	1258	446	1354

表 2 3 种板材油漆涂层的物理特性

Table 1 Physical characters of different oil layer on three kinds of roofboards

板材类型	油漆涂层	油漆厚度	热导率 (W/m ² ·°C)	材质描述
国产板材	兰色面(上面)	30 μm	1.626	镀锌板
	灰色面(下面)	25 μm	厚度小于测定范围	
韩国板材	兰色面(上面)	50 μm	1.632	镀锌板
	灰色面(下面)	30 μm	1.532	
大连浦项制铁板材	兰色面(上面)	80 μm	1.862	镀锌、锌板
	灰色面(下面)	30 μm	1.537	

和热红外波段相互之间的差异明显增大,这说明图像在可见光—近红外波段内信息大量冗余,因此我们在进行特征选择和提取时,只对可见光—近红外波段范围内的 60 个波段进行 PCA 和 MNF 变换,图 3 是 2 种变换的特征值,从图中可以清楚看出 PCA 变换后图像只有前 4 个波段的特征值较大,而 MNF 变换后的图像的前 10 个波段的特征值都比较大,这说明 PCA 变换对信息量的压缩大于 MNF 变换. 由于我们的特征选择和提取是为后续的工作准备,所以不宜对信息损失过大,因此我们选择 MNF 变换后的前 10 个波段,加上没有参与变换的 3 个波段(短波红外、中红外和热红外),作为特征选择和提取的最后结果.

在特征选择和提取的基础上,用 N-FINDER 方法在特征图像上从试验区域找到 4 类分别聚集的顶点,这说明该区域内主要包含 4 种地物. 分别将凸面几何体平移到每个顶点,以顶点法线方向为轴心在任意方向(试验中每次旋转 5°)上旋转凸面几何体,沿顶点的法线方向进行投影. 在二维投影平面上,选择类间离散度最大、类内聚合度最高的投影结果为最终投影结果,如图 2(b)所示,在投影面上该区域的散点集中在 4 个集群中,每个集群表示是一类地物,对应着图 2(c)图像中不同颜色的屋顶板材和周边地物. 经过实地调查取样,此屋顶确由 3 种不同材料拼成,它们分别是国内某厂家板材(蓝色)、韩国板材(绿色)和大连浦项制铁板材(红色),黄色区域是周边地面. 试验证明了基于特征提取的凸面几何投影变换方法在目标探测方面的有效性.

在试验中,我们还仅仅选择了图像在可见光—

近红外波范围内的 60 个波段来进行屋顶板材的探测,凸面几何投影变换的结果只能是把板材和其它背景分开,而不能将板材分为 3 种类型. 这是因为在以可见光—近红外波段的辐射值形成的凸面几何体中,3 种板材的像素点的原始辐射值差别不大,这些像素在多维空间内聚焦成球形,所以无论从哪个方向投影的效果都差别不大,也就不能将 3 种板材分开. 当加入短波红外波段、中红外波段和热红外波段以后,由于在这些波段 3 种板材的 DN 值大不相同,凸面几何体的形状被拉伸为类似锥体,且 3 种板材分别聚焦在顶点附近,因此选择适当的方向能够将 3 种板材分开. 这表明,高光谱图像当成像波长范围更宽时,尤其是在红外波长内成像,就可以在目标探测和识别方面发挥更大的优势.

从表 1 中可以看出,大连浦项制铁板材的辐射值在热红外波段的辐射值明显低于另外两种板材,这说明这种板材的表面温度略低,可以推断它的保温效果好于另外两种板材,更适合用于屋顶建材. 3 种板材的金属材料同为热的良导体,出现这种现象可能是因为涂在板材表面的不良导体油漆引起了屋顶热辐射的差异. 表 2 给出了 3 种板材油漆涂层的厚度和油漆的热导率,从表中可以看出大连浦项制铁板材的油漆涂层厚度明显厚于其他 2 种,由于油漆是热的不良导体,所以增强了铁板的保温性. 我们的分析结果从建筑商那里也得到证实. 这证明了利用高光谱图像探测地物的材料物理性质是十分有效的.

我们用同样的方法,对奥体公园中心地区的天然草坪和人工草坪地块进行了处理,尽管它们均为绿色,在 RGB 合成图像中是近乎完全一样的,但通过光谱维投影变换,我们仍能够成功地识别出奥体公园中心地区的人工草坪,见图 4. 图中红色为人工草坪、绿色为天然草坪、黄色为塑胶跑道、紫色为运动场入口.

4 结语

通过本文讨论,我们可以总结如下:

将凸面几何体投影变换用于高光谱图像目标的识别和分类,不需要目标的任何先验知识就能达到比较好的效果. 对于波段众多的高光谱图像,先进行特征选择和提取尤为重要,这样不仅减少了运算量,而且使得本来适用于多光谱图像的算法同样适用于高光谱图像. 由于高光谱图像波谱范围宽,特别是有短波红外、中红外和热红外范围的图像,不仅增加地物的可分性,而且为探测地物物理性质提供了可能.

(下转第 450 页)

是迭代 20 次后获得的最终收敛结果. 由试验可以看到, 模型最终轮廓曲线与脑室边缘基本吻合. 图 3(c) 所示为加入均值为 0, 方差为 0.005 的高斯白噪声的脑室分割结果, 使用与上述相同的初始轮廓曲线和迭代次数. 试验表明虽然噪声模糊了脑室的边缘信息, 弱化了边缘梯度场, 分段可变形模型仍然较好的完成了图像分割的任务. 图 4(b) 和图 4(c) 所示的分别是对同一图像进行分割的 Snakes 模型^[2] (迭代 60 次) 和本文提出的模型 (迭代 20 次) 的最终收敛结果. 在相同初始轮廓位置的情况下, 由于脑室边缘附近存在伪边缘, Snakes 模型错误收敛到局部极小值, 而分段可变形模型在复杂背景下进行图像分割的能力和避免陷入局部极小值的能力要强于 Snakes 模型. 在收敛时间方面, Snakes 模型用时约 9s, 而本文提出的模型仅为 6s, 在运算速度上也优于前者.

但是, 从试验结果来看, 模型轮廓曲线进入脑室凹形边缘的能力不太理想, 比较显著的如图 3(b) 中脑室两个上端部分. 这主要是因为模型的外部力场在分割对象的凹边缘处互相抵消, 从而不能将轮廓曲线吸引至精确的边缘. 通过改进模型的外部能量函数或使用新的外部力定义方法, 可以促进模型进入到对象的凹边缘, 这也是未来所要进行改进的部分. 另外, 在分割对象有足够样本的情况下, 也可以结合统计信息对模型的变形进行约束, 增强模型在收敛过程中的稳定性.

4 结语

本文提出了一种仿射不变的分段可变形模型, 通

过使同一段的标记点以仿射变换的形式移动较好的避免了在进行图像分割时容易陷入局部极小值的情况, 使用改进的模型内外部平滑函数在保持模型连续性和平滑性的同时也更加有利于精确的定位对象的边界, 由全局到局部的层次化变形和模型内部平滑能量函数的调整减少了运算时间. 试验表明该算法速度快, 对低信噪比情况下的图像分割有较好的效果.

REFERENCES

- [1] Terzopoulos D, Fleischer K. Deformable models[J]. *The Visual Computer*, 1988, 14(4): 306—331.
- [2] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models[J]. *Int. Journal of Computer Vision*, 1987, 1: 321—331.
- [3] Chenyang Xu, Jerry L Prince. Snakes, Shape, and Gradient VectorFlow[J]. *IEEE Transactions on Image Processing*, 1998, 7(3): 359—369.
- [4] Horace H S Ip, Dinggang Shen. An affine-invariant active contour model (AI-snake) for model-based segmentation[J]. *Image and Vision Computing*, 1998, 16(2): 135—146.
- [5] Xue Z, Li S Z, E K Teoh. Ai-eigensnake: An affine-invariant deformable contour model for object matching[J]. *Image and Vision Computing*, 2002, 20(2): 77—84.
- [6] Shen Dinggang, Davatzikos C. An adaptive-focus deformable model using statistical and geometric information[J]. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 906—913.
- [7] Perrin D, Smith C. Rethinking classical internal forces for active contour models[C]. *Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition. Hawaii, USA*; 2001, 2: 615—620.

(上接第 445 页)

REFERENCES

- [1] CHEN Shu-Peng, TONG Qing-Xi, GUO Hua-Dong. *Mechanism of Remote Sensing Information* [M]. Beijing: Science Press (陈述彭, 童庆禧, 郭华东. 遥感信息机理研究. 北京: 科学出版社), 1988: 166—172.
- [2] PU Rui-Liang, GONG Peng. *Hyperspectral Remote Sensing and Its Applications* [M]. Beijing: High Education Press (浦瑞良, 宫鹏. 高光谱遥感及其应用. 北京: 高等教育出版社), 2000: 47—98.
- [3] Xiuping Jia. Classification techniques for hyperspectral remote sensing image data [D]. PhD thesis of University of New South Wales, 1996: 17—24.
- [4] Ifarraguerrri, Chang C I. Multispectral and hyperspectral image analysis with convex cones analysis[J]. *IEEE Trans. on Geoscience and Remote Sensing*, 1999, 37(2): 756—770.
- [5] Jimenez, Landgrebe. Hyperspectral data analysis and supervised feature reduction via projection pursuit [J]. *IEEE Trans. on Geoscience and Remote Sensing*, 1999, 37(6): 2653—2667.
- [6] Ifarraguerrri, Chang C I. Multispectral and hyperspectral image analysis with projection pursuit[J]. *IEEE Trans. on Geoscience and Remote Sensing*, 2000, 38(6): 2529—2538.
- [7] Chiang S S, Chang C I, Ginsberg I W. Unsupervised sub-pixel target detection for hyperspectral images using projection pursuit [J]. *IEEE Trans. on Geoscience and Remote Sensing*, 2001, 39(7): 1380—1391.
- [8] Boardman J W, Kruse F A, Green R O. Mapping target signatures via partial unmixing of AVIRIS data; in Summaries, Fifth JPL Airborne Earth Science Workshop, JPL Publication[C]. 95-1, 1: 23—26.
- [9] ZHANG Bing. Hyperspectral data mining supported by temporal and spatial information [D]. Ph. D. Dissertation. Institute of Remote Sensing Applications Chinese Academy of Sciences (张兵. 时空信息辅助下的高光谱数据挖掘. 中科院遥感应用研究所博士论文), 2002: 54—56.
- [10] Winter Michael E. N-FINDR: an algorithm for fast autonomous spectral end-member determination in hyperspectral data [J]. *Proc of SPIE, Imaging Spectrometry V*, 1999, 3753: 266—277.