



高光谱遥感图像小目标探测的基本原理

耿修瑞^{①②③*} 赵永超^{②③④}

(① 北京师范大学地理学与遥感科学学院, 北京 100875; ② 中国科学院遥感科学国家重点实验室, 北京 100101;
③ 中国科学院电子学研究所, 北京 100080; ④ Center for Assessment and Monitoring of Forest and Environmental
Resources and Division of Ecosystem Sciences, University of California Berkeley, Berkeley CA 94720-3114, USA)

摘要 概括性总结了高光谱遥感图像小目标探测算法的研究进展, 揭示了图像白化处理是诸多算法能够成功应用于小目标探测的本质原因所在; 提出了基于样本加权自相关矩阵把大目标转化为“小”目标从而进行有效探测的思想和算法.

关键词 高光谱 白化 目标探测

目标探测技术是遥感理论与应用中一个重要领域, 由于受到地面采样距离(GSD)的限制, 在很多情况下我们感兴趣的目标都以亚像元的形式存在, 即在一个图像像元中不但含有感兴趣目标, 而且还包含有其他地物. 此时, 利用传统的遥感手段很难对这些小目标进行有效探测, 高光谱遥感以其波段多、光谱分辨率高、信息量大的特点为这一问题提供了新的技术手段.

高光谱图像中的小目标一般有如下几个特点: 第一, 从物性上来说, 我们所感兴趣的目标一般不同于图像中的其他背景地物, 因而其相应的光谱标签应该与别的地物有着不同的特征, 这是小目标得以有效探测的物质基础; 第二, 从几何上来讲, 在线形混合模型成立或者近似成立的基础上, 由于感兴趣目标不同于别的背景地物, 因而在图像的特征空间中其相应的端元应该位于具有单形体结构分布的数据云团的一个顶点, 这是感兴趣目标能够有效探测的几何基础; 第三, 从信息量上来说, 小目标在图像中往往只占几个像元, 甚至只以亚像元的形式存在, 这一方面加大了从图像空间直接对其进行有效探测的难度. 但另一方面, 由于其分布数量少加上其在特征空间中特殊的几何特性, 导致小目标像元本身没

有复杂的分布结构并且游离于大的数据云团之外, 这是小目标探测的信息基础或者结构基础.

本文将首先概括高光谱遥感图像目标探测技术的发展概况, 接着提出了基于图像白化小目标探测的研究思路及算法, 揭示了图像的白化处理是诸多小目标探测算法能够取得显著效果的关键所在, 提出了基于样本加权自相关矩阵把大目标转化为“小”目标从而进行有效探测的思想和算法. 然后我们用 ENVI 自带的 AVIRIS 数据和 2004 年在西安获取的 OMIS2 数据为例来验证我们的想法.

1 目标探测技术的发展

根据已知条件可以把现有的研究归结为 4 个方面:

1.1 低维空间情况

高光谱图像通常都具有几十甚至上百个波段, 对如此大的数据量进行处理往往需要以时间为代价, 尤其是当这些数据需要传输的时候还要求传输介质有足够的带宽(比如星上数据下传), 所以很多情况下, 在保证目标与背景有足够分离度的基础上先对原始数据进行降维操作, 这其实也是一个特征提取的过程. 在遥感图像分析中, 特征提取可以从两个意义上实施: 一种是按照一定的准则直接从原始特征空

收稿日期: 2006-04-24; 接受日期: 2006-11-21

国家自然科学基金(批准号: 40501041, 40202031)和中国科学院知识创新工程重要方向性项目(编号: KZCX3-SW-338-1)资助

* E-mail: gengxr@sina.com.cn

间中选出一个子集(即子空间), 光学遥感中的波段选择即属于这一类. 另一种是找到一个映射关系 $\mathbf{P}: \mathbf{X} \rightarrow \mathbf{Y}$. 将原始特征空间 $\mathbf{X} = \{x_1, x_2, \dots, x_m\}$ 映射到维数降低了的特征空间 \mathbf{Y} 上去, 其中 $\mathbf{Y} = \{y_1, y_2, \dots, y_n\}$, $n < m$. 高光谱遥感图像特征提取包含的内容非常广泛, 提取方法也很多, 光谱维特征提取和空间维特征提取是表现图像特征提取的两个方面. 主成分分析(PCA)是一种把原来多个指标化为少数几个互不相关的综合指标的一种分析技术. 应用 PCA 可以在基本保持数据信息量的基础上把海量的高光谱数据投影到仅有少数几个主分量所构成的正交子空间中. Jia 和 Richards^[1]发展的分块主成分分析法用于特征提取, 取得了一定的分类和显示效果, 他们将全部波段的相关矩阵按照相邻波段的相关性分成若干块. 一般高度相关的块沿对角线分布, 而相关性低的远离对角线. 块矩阵本身集合了相邻波段间相关性高的波段. 因此沿相关矩阵对角线可分成若干块(波段组), 并对每组进行主成分变换, 最后将每组的重要特征(主成分)再重新组合在一起作为进一步主成分分析与特征选择之用. 典范分析也是将较多的变量化为少数几个典范变量, 通过这较少的典范变量之间的相关性来综合地描述两个多元随机变量之间关系的一种数学方法. PCA 主要想最大限度地不同类别分开, 而典范分析则是在低维变量间寻找能代表高维变量的相关性, 以达到分类、识别目标的目的. 刘建贵^[2]在分析 K-L 变换性质的基础上, 根据高光谱数据用于城市目标识别提取的特点, 提出了面向分类的特征提取的规范分析(CA)改进方法, 设法使原特征空间的各类的样本点在光谱维上的投影能使类间距离与类内距离的比值达到最大. 根据这一原则来决定变换矩阵的选择. 刘建贵^[2]用这种改进的方法实施对北京沙河镇城市地物特征的提取, 取得了较好的结果.

1.2 已知目标、已知背景

在目标端元与背景端元都知道的情况下, 最简单的目标提取方法是直接利用目标光谱对图像中的像元逐一匹配, 从而得到目标在图像中的分布情况. 通常的整波形匹配算法主要有以下 4 种: 根据光谱之间的距离, 如最小距离匹配; 根据光谱之间的夹角, 代表性的算法是光谱角度填图(SAM); 根据光谱之间的相似系数, 如交叉相关光谱匹配技术(CCSM); 编

码匹配算法, 如二值编码匹配算法. 整波形匹配的缺陷在于它对噪声非常敏感, 因而要求图像光谱有很高的信噪比. 实际上, 对图像光谱定标和反射率转换的精度往往很难达到光谱匹配的要求. 注意到, 上述算法并没有用到已知的背景信息, 从而只能在没有抑制背景的情况下定性得到目标地物的大致覆盖区域, 如果要定量的得到感兴趣目标在图像中各个像元中所占的比例, 需要引入混合像元模型. 线性混合模型是其中应用最为广泛的模型, 它假定: 在一定的条件下, 高光谱图像中每个像元都可以近似认为是图像中各个端元的线性混合像元. 因此, 在已经知道图像所有端元(包括目标与背景)的前提下, 可以利用线性解混定量地得到目标地物在图像中每个像元中所占的百分比. 常用的光谱解混算法包括最小二乘法、正交子空间投影算法(OSP)^[3]、前景背景分析算法(FBA)、滤波向量算法(Filter vector)^[4]等.

1.3 已知目标、未知背景

在仅知道目标端元的光谱而未知背景的情况下, 可以通过 3 条途径来进行目标提取. 第一种就是前面所讲的简单的匹配算法, 由于这种方法既没有用到目标与背景的信息量分布的差别, 也没有利用高光谱图像在其特征空间目标与背景的相对位置的差别, 因而探测结果易于受到背景地物的影响; 第二种途径就是利用一组正交基底代替背景, 然后再通过光谱解混, OSP, FBA 和滤波向量等方法得到目标在图像中的定量分布结果, 这就归结为第二种情形. 比较常用的正交变换方法包括 PCA 及奇异值分解(SVD); 第三种途径则是利用样本相关矩阵(或者协方差矩阵)的性质对目标进行半解混(Partial Unmixing)提取, 匹配滤波(MF)、约束能量最小化算法(CEM)^[5,6]是应用最为广泛的小目标提取算法, 与基于混合像元模型侧重于从目标与背景在特征空间相对位置的差异入手的目标提取算法相比, CEM(与 MF 形式上是相同的)主要从能量(信息量)的角度来压制背景继而提取目标. 混合调制匹配滤波器(MTMF)^[7]则结合了两种算法的优点.

1.4 未知目标、未知背景

在满足线性混合的条件下, 图像中的每个像元都可以由其中的所有端元线性混合而成, 因此高光谱数据端元的提取是理解高光谱数据、继而对数据进

行进一步分析(比如解混、填图等)的前提条件. 如何从高光谱图像中提取端元一直是一个热点问题, 在这方面, 已经有很多成熟的方法被提出和应用, Boardman^[8]创造性地提出了利用凸面几何学分析的方法提取图像端元的雏形, 他认为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粹像元(端元)为顶点的单形体所包围, 并与 Boardman 等^[9]在一起发展了纯像元指数(PPI)提取端元的算法. Craig 提出了最小体积变换(MVT)算法, 通过求取包围整个高光谱数据“云团”的具有最小体积的单形体来获得端元. Bateson 和 Curtiss^[10]利用主分量分析和多维可视化软件提出了一种人机交互提取纯粹像元的算法(MEST). N-FINDR 利用高光谱数据在特征空间中的凸面单形体结构, 通过寻找具有最大体积的单形体从而自动获取图像中的所有端元^[11]. ORASIS 是一种自动地、实时地从图像中提取端元的算法, 它首先通过一个叫做示范选择(exemplar selection)的过程, 根据一定的准则(比如光谱间的夹角)在保持光谱多样性的同时给原始数据去冗余, 然后通过一个改进的施密特正交化过程获得一组比原始数据维数更低的一组基底, 再把示范光谱投影到此基底所张成的子空间上, 通过最小体积变换得到此空间上的一个单形体, 从而获得图像中的所有端元. 迭代误差分析(IEA)^[12]是一种不需要对原始数据进行降维或者去冗余, 而直接对数据处理的端元提取算法, 它首先给定一个初始向量(一般为所有光谱的均值向量), 然后对图像逐次进行线性解混, 每次解混处理均可从误差图像中得到一个端元, 然后新的端元再加入到下一步的解混操作中, 直至在某种准则条件下求出图像中的所有端元. 为了解释端元光谱的可变性, Roberts 等^[13]提出了多端元光谱混合分析(MESMA), 其核心思想是: 每一个端元均由一组向量而不是一个唯一的向量来表示, 当解混的时候, 对于每个像元, 从代表各自端元的向量组中各选取一个最合适的向量, 以使得均方误差最小, 其中端元可以从图像中和该区域的光谱库中选取. Bateson 等^[14]也基于端元的可变性提出了端元束(bundles)的概念, 并且利用模拟退火算法来生成端元束. Plaza 等^[15]提出了一种利用形态学方法自动提取端元的算法, 算法的优点是在利用光谱信息的同时, 很好地利用了像素在空间上的相关性. 在获得了图像中的所有端元之后, 目标探测的工作则可以归结为前几种情形.

2 基于图像白化处理的小目标探测

前面所概括的小目标探测算法可以归结为如下 3 类: 简单的匹配算法、基于目标在图像特征空间中几何性质的探测算法以及基于目标信息量分布的探测算法. 其中简单的匹配算法是直接利用目标光谱对图像中的像元逐一匹配, 从而得到目标在图像中的分布情况. 前面所讲的整波形匹配算法(SAM, CCSM, SSF 等)均属于此类. 这种算法的最大缺点是不能有效利用背景信息, 因而目标探测结果容易受到背景地物的影响. 在线性混合模型成立的情况下, 高光谱图像中的像元在其特征空间都以散点的形式分布于一个以图像中各个端元为顶点的单形体结构之中. 充分利用高光谱图像所具有的这一相对位置信息, 可以有效地对目标进行探测. 凸面几何学分析、正交子空间投影技术(OSP)以及以其为基础的算法、独立成分分析(ICA)和投影寻踪变换(PP)等诸多算法都可以归为此类. 此类方法的优点是充分利用了目标与背景的相对位置信息, 从而可以一定程度减少背景对探测结果的影响, 不足之处是没有充分利用目标在图像中分布信息量少、分布结构简单这一特点. 而 CEM 和 RXD 等基于目标信息分布的探测算法则从图像的二阶统计量、信息分布的角度入手, 从图像中提取低概率分布目标. 通常情况下, 此类算法在小目标探测方面有前两类方法不可比拟的优势. 下面将给出此类小目标探测算法之所以有效的本质原因, 在此之前先给出图像的白化处理过程.

假设 $S=\{r_1, r_2, \dots, r_N\}$ 为所有样本数据集, r_i 为图像中的 $L(L$ 为波段数)维光谱向量 $\mu = \frac{1}{N} \sum_{i=1}^N r_i$ 为样本均值向量, K 为样本协方差矩阵, 矩阵 F 为 K 的白化矩阵. 则有

$$F^T K F = I, F^T F = \Delta^{-1}, \quad (1)$$

其中 $\Delta = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_L\}$ 为由 K 的特征值组成的对角矩阵(不妨设 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L$). 实际上 $F = E \Delta^{-1/2}$, 这里矩阵 E 由 K 的特征向量组成, 满足 $E^T K E = \Delta$. 则 $W = \{w_1, w_2, \dots, w_N\} = \{F^T r_1, F^T r_2, \dots, F^T r_N\}$ 为白化数据. 显然图像经过白化处理之后各个波段的方差为 1, 各个波段之间的相关性为 0. 这相当于在特征空间中图像分布信息量比较大的方向上乘以一个缩减比例因子, 而在信息量分布比较大的方向上乘以一个扩张比例因子, 以使得各个方向上图像有相同的方差. 经

过这样的处理之后, 原本信息量比较大、分布相对较为稀疏的方向上的信息得以压缩而变得稠密; 而原来信息量比较小、分布较为密集的方向上的信息得以膨胀开来, 尤其是当此方向上有游离于稠密的数据云团之外的小目标时, 经过白化之后, 此目标将远远的孤立于以其他地物为背景的数据云团之外. 此时用前面所讲的很多种简单匹配算法都能轻易的将目标与背景区别开来.

下面进一步分析 CEM 与 RXD 算法, CEM 算子的表示方式如下:

$$w^* = \frac{\mathbf{R}^{-1}\mathbf{d}}{\mathbf{d}^T \mathbf{R}^{-1}\mathbf{d}}, \quad (2)$$

其中 \mathbf{R} 为图像自相关矩阵, 不妨设图像的均值向量为零向量, 则有 $\mathbf{R}=\mathbf{K}$. 将 CEM 算子作用于图像中的任一像元:

$$(w^*)^T r_i = \frac{r_i^T \mathbf{R}^{-1}\mathbf{d}}{\mathbf{d}^T \mathbf{R}^{-1}\mathbf{d}} = \frac{r_i^T \mathbf{F}\mathbf{F}^T \mathbf{d}}{\mathbf{d}^T \mathbf{F}\mathbf{F}^T \mathbf{d}} = \frac{(\mathbf{F}^T r_i)^T \mathbf{F}^T \mathbf{d}}{\mathbf{d}^T \mathbf{F}\mathbf{F}^T \mathbf{d}} \quad (3)$$

$$= c(\mathbf{F}^T r_i)^T \mathbf{F}^T \mathbf{d},$$

其中 $c = \frac{1}{\mathbf{d}^T \mathbf{F}\mathbf{F}^T \mathbf{d}}$ 为一与目标 \mathbf{d} 相关的常数. 去除常数项的影响, 可以看到 CEM 算子为数据白化后的内积. 同样可以得到 RXD 算子为数据白化后的距离.

由上面的分析可以看出, 小目标本身所具有的物性、几何、信息和结构特点使得图像白化处理成为小目标得以有效探测的关键所在. 一般地, 经过白化处理, 图像中的小目标就会很容易与背景地物分离开来, 这对于小目标提取无疑是非常有利的. 值得注意的是, 大目标(在图像中分布较多)一般情况下不具备小目标所特有的信息量小, 结构简单的特点, 所以上述算法不适用于大目标的提取. 另外, 当小目标恰好分布在图像信息量较大的方向时, 上述算法将失效, 但由于图像的白化使得图像中各个方向的方差相等, 因而只要从某一个信息量小的方向看去, 感兴趣目标是游离于数据云团之外的, 我们的算法仍然适用.

泛函分析中有两大类最为基本的空间: 巴拿赫(Banach)空间和希尔伯特(Hilbert)空间. 巴拿赫空间是引入了范数(距离)的完备线性空间, 而希尔伯特空间则是引入内积的完备线性空间. 欧氏空间既是巴拿赫空间又是希尔伯特空间, 因而欧氏空间同时具有距离和内积这两大基本度量手段, 这同时决定了

欧氏空间中元素的相似性或者差异性度量要以距离和内积为基础. 我们所处理的高光谱数据一般都处于 L (L 为波段数)维欧氏空间, 因而, 距离和内积必定是进行目标探测最为基本的手段. 事实上, 很多高光谱目标探测算法都是以这两个手段或者他们的组合为基础, 比如 SAM, CEM, RXD, CSAM 等等. 但是由于自然界中地物分布信息的不对称性, 即一景图像中有的地物多, 有的地物少. 当分布比较少的小目标与其他目标区分特征不明显时, 很难单纯依靠距离和内积或者他们的组合对其进行有效探测. 而图像白化则是一种信息平衡的有效手段, 通过白化, 大多数小目标均能够与背景得以有效的分离, 此时再通过一些简单的手段即可得到小目标在图像中分布情况. 因而小目标探测的本质在于白化, 而不是距离、内积或者它们的任意组合.

事实上, 由于公式(2)中样本自相关矩阵 \mathbf{R} 是由图像中所有像元构成的, 因此图像白化在压制背景的同时也压制目标本身. CEM, RXD 等算子之所以对小目标有效, 只不过是目标对 \mathbf{R} 几乎没有影响的缘故, 这同时也是白化操作不适用于大目标探测的原因. 通过改造 \mathbf{R} 的结构为 \mathbf{R}^* , 使之不依赖于目标而尽可能只由背景像元组成, 这相当于大目标被一定程度“小”化, 从而也可以通过前面的小目标探测算法对其进行有效提取.

$$\mathbf{R}^* = c \sum_{i=1}^N f(g(r_i, \mathbf{d})) r_i r_i^T, \quad (4)$$

其中 $f(0)=0$, $f(x)$ 为单调递增函数($x \geq 0$), c 为一常数, $g(x, y)$ 为度量向量 x, y 相似度的函数, $g(x, y)$ 的值随向量 x, y 相似度的增加而减小, 比如可以取 $g(x, y)$ 为向量 x 与 y 的欧氏距离, 即 $g(x, y) = \|x - y\|$. 这样, 当感兴趣目标作为背景参与运算时, 它对 \mathbf{R}^* 的贡献为零; 与感兴趣目标差异越大(距离越大)的像元对 \mathbf{R}^* 的贡献越大. 显然, \mathbf{R}^* 的引入也可以一定程度上降低小目标的虚警. 在下面的实验中, 我们取 $f(x)=x$, $g(x, y) = (\|x-y\|)^4$.

3 实验验证

3.1 实验一

以 2003 年西安煤航 OMIS2 数据为例验证我们的算法. 其中 OMIS2 是由中国科学院上海技术物理研究所研制的第二代摆扫型成像光谱仪, 它可以获取

从可见光到热红外 64 个波段的高光谱图像(不包括夜航的一个热红外波段), 当天飞行数据地面分辨率 3.6 m. 我们截取其中的局部区域(200×200)作为研究对象, 在这块区域中分布着用人工材料模拟周围环境

(植被、土壤等)的小目标像元. 另外图像已经经过了辐射纠正. 我们首先用基于体积的端元提取算法得到感兴趣目标端元^[16](图 1(b)), 然后用下面各种目标匹配算法得到相应探测结果.

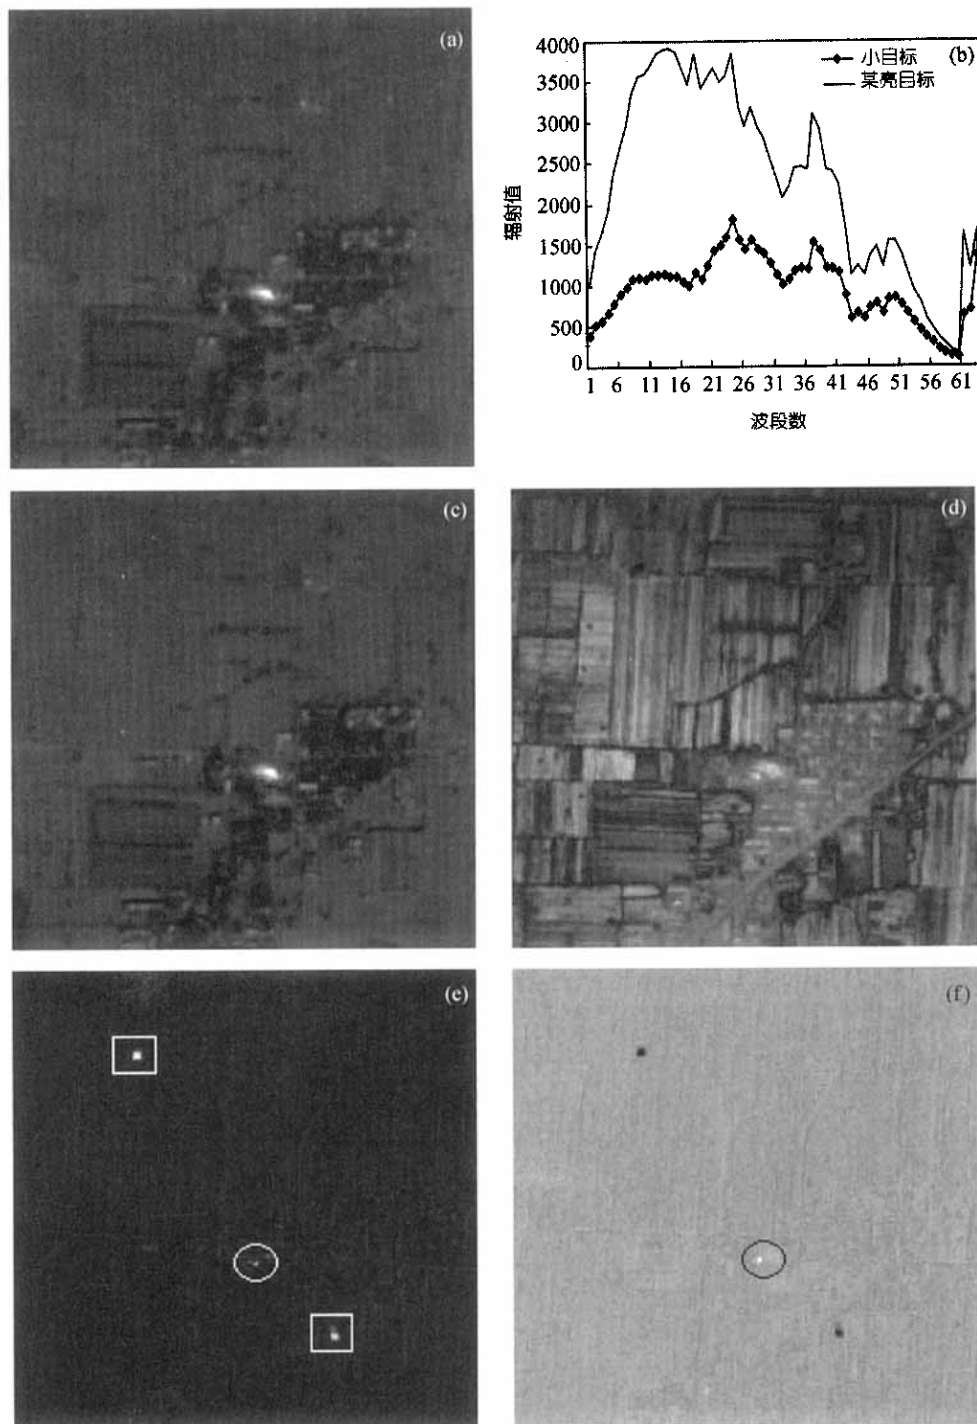


图 1 小目标探测结果

(a) 原始 64 个波段图像之和; (b) 小目标和虚警光谱; (c) 内积探测结果; (d) SAM 探测结果; (e) 白化后内积(CEM)探测结果(方框内为目标, 圆框内为虚警); (f) 白化后 SAM 探测结果(虚警被剔除)

根据实验结果可以看出,直接用内积法做匹配得到结果(图 1(c))与原始图像(图 1(a))差别不大,因而无法实现对感兴趣目标的探测;应用 SAM 算法也无法直接对小目标进行有效探测(图 1(d));但经过图像白化处理之后,应用内积方法可以很好的探测到小目标(图像中最亮的两处位置),但是探测结果易受图像中具有高亮度区域像元(图 1(b)中红色光谱曲线)的影响,因而会产生虚警目标(图 1(e));而把 SAM 算法用于白化后的图像,不但可以很好的提取小目标(两个最暗的位置),而且有效地去除了虚警。

3.2 实验二

利用 ENVI 上自带的在 Cuprite 获取的 AVIRIS 数据进行大目标探测的实验(如图 2)。AVIRIS 是一种高质量低噪声的高光谱仪器,包含 224 个波段(波长范围为 400~2500 nm),这里我们将选取其中短波红外的 50 个连续的波段(1978~2478 nm, 400×350)进行实验。

从图 2 中可以看出,加权自相关矩阵 R^* 的引入可以很好的把大目标转化为小目标,从而提高探测效果(图 2(d))。这开辟了一条仅知道目标光谱的情况下利用小目标探测算法进行大目标探测的新思路。在所提供的目标光谱为端元的情况下,利用白化后再内积的方法得到的目标探测分布图的数值一般情况下均小于 1,而只有目标端元本身所对应的值为 1。我们选取图像中的部分已知分布的明矾石(图 2(a)圆圈内部分紫色区域部分像元:横坐标 84:92、纵坐标 304:310 共 63 个像元)来验证算法。从图 3 可以看出,在各个阈值情况下,我们算法的误分率均低于 CEM 算法。

4 结论

由于传感器地面分辨率的限制,小目标探测一直是遥感探测的一个热点和难题,高光谱遥感为这一问题提供了新的技术手段。本文在概括前人工作的基础上,从小目标本身所具有的物性、几何、信息、




图 2 大目标探测实验

(a) 用于处理的 Cuprite 区域的 AVIRIS 数据假彩色合成图; (b) 从图像中提取出来的端元光谱(明矾石); (c) 直接用 CEM 探测结果; (d) 基于本文算法的探测结果




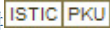
图 3 错误率曲线比较

结构几个特点出发, 揭示了图像的白化处理是有效探测小目标的关键所在, 而 CEM 和 RXD 等诸多不同的小目标、异常目标探测算法均可以统一于如上认识. 同时提出了加权自相关矩阵的思想, 克服了经典小目标探测算法不能有效提取大目标的缺陷, 使得我们在仅知道目标光谱的情况下对大目标进行有效探测. 另外我们的观点也已经成功地应用于 PHI 数据和 OMIS 数据的小目标提取. 可以预期高光谱遥感在目标探测技术方面的技术研究在新世纪将会有更大的发展和更广阔的应用前景.

致谢 感谢西安煤航万余庆所长在高光谱数据方面的支持.

参 考 文 献

- Jia X, Richards J A. Segmented principal components transformation for efficient hyperspectral remote image display and classification. *IEEE Trans Geosci Remote Sens*, 1999, 37(1): 538—542
- 刘建贵. 高光谱城市地物及人工目标识别与提取. 博士学位论文. 北京: 中国科学院遥感应用研究所, 1999
- Harsanyi J C, Chang C I. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach. *IEEE Trans Geosci Remote Sens*, 1994, 32: 779—785
- Bowles J, Antoniadis M, Baumbach J M, et al. Use of filter vectors in hyperspectral data analysis. In: *Proc SPIE Infrared Spaceborne Remote Sensing III*. Washington: SPIE Pub, 1995. 148—157
- Harsanyi J C. Detection and classification of subpixel spectral signatures in hyperspectral image sequences. Dissertation for the Doctoral Degree. Baltimore: University of Maryland, 1993
- Farrand W, Harsanyi J C. Mapping the distribution of mine tailing in the coeur d'Alene river valley, Idaho, through the use of constrained energy minimization technique. *Remote Sens Environ*, 1997, 59: 64—76
- Boardman J W. Leveraging the high dimensionality of AVIRIS data for improved sub-pixel target unmixing and rejection of false positives: mixture tuned matched filtering. In: *7th JPL Airborne Geoscience Workshop*. Pasadena: JPL Pub, 1998. 55—56
- Boardman J W. Automated spectral unmixing of AVIRIS data using convex geometry concepts. In: *4th JPL Airborne Geoscience Workshop*. Pasadena: JPL Pub, 1993. 11—14
- Boardman J W, Kruse F A, Green R O. Mapping target signatures via partial unmixing of AVIRIS data. In: *15th JPL Airborne Geoscience Workshop*. Pasadena: JPL Pub, 1995. 23—26
- Bateson C A, Curtiss B. A tool for manual endmember selection and spectral Unmixing. In: *4th JPL Airborne Earth Science Workshop*. Pasadena: JPL Pub, 1993. 3—6
- Winter M E. N-FINDR: an algorithm for fast autonomous spectral end-member determination in hyperspectral data. *Proc SPIE*, 1999, 3753: 266—275
- Staenz K, Szeredi T, Schwarz J. ISDAS—A system for processing/analyzing hyperspectral data. *Can J Remote Sens*, 1998, 24: 99—113
- Roberts D A, Gardner R, Church R, et al. Mapping chaparral in the santa monica mountains using multiple endmember spectral mixture models. *Remote Sens Environ*, 1998, 65: 267—279
- Bateson C A, Asner G P, Wessman C A. Endmember Bundles: a New Approach to Incorporating Endmember Variability into Spectral Mixture Analysis. *IEEE Trans Geosci Remote Sens*, 2000, 38: 1083—1094
- Plaza A, Martinez P, Perez R M. Spatial/spectral endmember extraction by multidimensional morphological operations. *IEEE Trans Geosci Remote Sens*, 2002, 40(9): 2025—2041
- 耿修瑞. 高光谱遥感图像目标探测与分类技术研究. 博士学位论文. 北京: 中国科学院遥感应用研究所, 2005

作者: 耿修瑞, 赵永超
作者单位: 耿修瑞(北京师范大学地理学与遥感科学学院, 北京, 100875;中国科学院遥感科学国家重点实验室, 北京100101;中国科学院电子学研究所, 北京, 100080), 赵永超(中国科学院遥感科学国家重点实验室, 北京100101;中国科学院电子学研究所, 北京, 100080;Center for Assessment and Monitoring of Forest and Environmental Resources and Division of Ecosystem Sciences, University of California Berkeley, Berkeley CA 94720-3114, USA)
刊名: 中国科学D辑 
英文刊名: SCIENCE IN CHINA (SERIES D)
年, 卷(期): 2007, 37 (8)
被引用次数: 6次

参考文献(16条)

1. Harsanyi J C; Chang C I [Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach](#) [外文期刊] 1994 (4)
2. 刘建贵 [高光谱城市地物及人工目标识别与提取](#) [学位论文] 1999
3. 耿修瑞 [高光谱遥感图像目标探测与分类技术研究](#) [学位论文] 2005
4. Plaza A; Martinez P; Perez R M [Spatial/spectral endmember extraction by multidimensional morphological operations](#) 2002 (09)
5. Bateson C A; Asner G P; Wessman C A [Endmember Bundles: a New Approach to Incorporating Endmember Variability into Spectral Mixture Analysis](#) [外文期刊] 2000 (2)
6. Roberts D A; Gardner R; Church R [Mapping chaparral in the Santa Monica mountains using multiple endmember spectral mixture models](#) [外文期刊] 1998
7. Boardman J W; Kruse F A; Green R O [Mapping target signatures via partial unmixing of AVIRIS data](#) 1995
8. Boardman J W [Automated spectral unmixing of AVIRIS data using convex geometry concepts](#) 1993
9. Boardman J W [Leveraging the high dimensionality of AVIRIS data for improved sub-pixel target unmixing and rejection of false positives: mixture tuned matched filtering](#) 1998
10. Farrand W; Harsanyi J C [Mapping the distribution of mine tailing in the Coeur d'Alene river valley, Idaho, through the use of constrained energy minimization technique](#) 1997
11. Harsanyi J C [Detection and classification of subpixel spectral signatures in hyperspectral image sequences](#) 1993
12. Bowles J; Antoniadis M; Baumback J M [Use of filter vectors in hyperspectral data analysis](#) 1995
13. Jia X; Richards J A [Segmented principal components transformation for efficient hyperspectral remote image display and classification](#) [外文期刊] 1999 (01)
14. Staenz K; Szeredi T; Schwarz J [ISDAS-A system for processing/ analyzing hyperspectral data](#) 1998
15. Winter M E [N-FINDR: an algorithm for fast autonomous spectral end-member determination in hyperspectral data](#) 1999
16. Bateson C A; Curtiss B A [A tool for manual endmember selection and spectral Unmixing](#) 1993

引证文献(6条)

1. 于宏, 黄树桃, 刘京晶 [基于光谱知识库对高光谱影像目标快速识别方法](#) [期刊论文] - [世界核地质科学](#) 2011 (1)
2. 粘永健, 张志, 王力宝, 万建伟 [基于FastICA的高光谱图像目标分割](#) [期刊论文] - [光子学报](#) 2010 (6)
3. 辛勤, 粘永健, 万建伟, 何密 [基于FastICA的高光谱图像压缩技术](#) [期刊论文] - [电子科技大学学报](#) 2010 (5)
4. 张文希, 郑茂, 李纲 [基于端元提取的超光谱图像目标检测算法](#) [期刊论文] - [电光与控制](#) 2010 (8)
5. [面向目标检测的高光谱图像压缩技术](#) [期刊论文] - [计算机技术与发展](#) 2009 (11)
6. 刘德连, 王博, 张建奇 [期望最大化聚类的高光谱亚像素目标检测](#) [期刊论文] - [西安电子科技大学学报 \(自然科学版\)](#) 2009 (3)