

一种基于随机场模型的高光谱影像目标探测算法

杜 博^{1,2} 张良培³ 李平湘³ 钟燕飞³ 陈 涛⁴

(农业部资源遥感与数字农业重点开放实验室 北京 100081)¹ (武汉大学计算机学院 武汉 430079)²

(武汉大学测绘遥感信息工程国家重点实验室 武汉 430079)³

(中国地质大学地球物理与空间信息学报 武汉 430074)⁴

摘 要 利用随机场模型来描述像元的邻域相关性信息,利用这种相关性缩小待探测区域,然后将这种邻域信息引入到局域异常探测器中,提出了一种利用随机场模型引入能量函数和邻域信息的高光谱遥感影像局域异常目标探测算法。实验证明,该方法将光谱信息与空间信息相结合,不但比传统算法的探测率更高,且可以更有效地探测出较大的异常目标,探测速度更快。

关键词 随机场模型,异常探测,能量函数

中图分类号 TP751 **文献标识码** A

Anomaly Detection Method Based on Random Field for Hyperspectral Imagery

DU Bo^{1,2} ZHANG Liang-pei³ LI Ping-xiang³ ZHONG Yan-fei³ CHEN Tao⁴

(Key Lab of Resource Remote Sensing and Digital Agriculture, Ministry of Agriculture P. R. C, Beijing 100081, China)¹

(Computer School, Wuhan University, Wuhan 430079, China)²

(State Key Lab of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan 430079, China)³

(Institute of Geophysics and Geomatics, China University of Geosciences, Wuhan 430074, China)⁴

Abstract This paper presented an anomaly detection method based on random field model in order to introduce the spatial information between the neighborhood pixels in the hyperspectral imagery into the anomaly detection procedure and reduce the area for detection. In our method, the pixels' neighborhood relationship in the hyperspectral imagery was described by the Random Field model. Then this neighborhood relationship information between pixels was introduced into the local-region anomaly detector which uses a nested dual window to detect probable anomaly pixels. Experiments show that this method performs better than the traditional RX-algorithm, especially for the larger anomaly targets which usually contains several neighborhood pixels and with better efficiency.

Keywords Random field, Anomaly detection, Hyperspectral images

高光谱遥感影像与多光谱、单光谱影像相比,具有更高的光谱分辨率。利用这一特点,高光谱遥感影像可以用来探测那些光谱特性与背景有差异的异常目标。异常目标具有两个显著特点:一是分布数目少、面积小,即所谓的低概率特点;二是在统计特征上背离各种背景地物符合的统计分布。在实际中,异常目标一般是分布于自然场景中的人工目标,如在森林背景中的车辆、人工建筑物等。

从探测的场景范围来分类,高光谱遥感影像的异常目标探测方法分为基于全局模型的异常目标探测算法和基于局部模型的异常目标探测算法。基于全局模型的异常目标探测算法主要是统计一幅场景的全局信息,根据异常目标和背景分布特性进行异常目标探测,如 C. J. Baker 和 D. G. Manolakis 提出的全局统计方法^[1];基于随机最大期望(SEM)算法的探测算法也是一种全局探测算法^[2]。基于局部模型的异常

目标探测算法是现在异常目标探测中使用的主要方法,如 P. B. Chapple 提出的基于局部的统计算法^[3]、Margalit 提出的基于局部的匹配算法^[4]和高斯马尔科夫(GMRF, Gauss-Markov)算法^[5],又如 Reed 和 Yu 两位学者提出的一种多光谱恒虚警率目标探测算法^[6],即 RX 算法,此后又有了许多 RX 的改进算法^[7,8]。

本文采用高斯马尔可夫随机场模型表达相邻像元的相关性,进而缩小带探测区域和利用相关性信息建立异常目标探测算法,提出了一种结合光谱信息和空间信息高效的基于高斯马尔科夫随机场的异常目标探测方法。

1 随机场模型

本文主要应用马尔科夫随机场模型,它拥有两个重要的固有特性:非因果关系和马尔可夫特性。非因果关系是指任

到稿日期:2009-07-16 返修日期:2009-09-29 本文受国家“973”计划资助项目(2009CB723905),国家 863 计划资助项目(2009AA12Z114, 2007AA12Z148),武汉大学博士研究生科研自主基金(2008619020100061),农业部资源遥感与数字农业重点开放实验室开放基金(RDA0801),江西省数字国土重点实验室基金(DLLJ200907),虚拟地理环境教育部重点实验室开放课题,教育部博士点基金新教师项目(200804861058)资助。
杜 博(1983—),男,博士,主要研究方向为数字图像处理、遥感信息提取, E-mail:gunspace@163.com。

一像素点的场受到周围各个方向场的影响,没有占优的依赖方向。把这些性质拓展到适合高光谱影像的三维场,假设描述影像占优背景的高斯过程具有慢变方差结构。把 $I \times J \times K$ 处理窗口格子分成大小为 $N_i \times N_j \times N_k$ 的子块,将这些子块称为马尔可夫窗。我们一般利用所有可利用的光谱波段,则 $N_i = K$ 。我们认为在相同马尔可夫窗内的像素相互之间具有很大的空间相关性,而忽略不同马尔可夫窗内像素之间的空间相关性。在马尔可夫窗 m 内, $\omega_{ijk}^m (1 \leq i, j, k \leq N_i)$ 代表 3D 有限格形场,建立由 Woods 提出的最小均方误差扩展描述的模型。

$$\omega_{ijk}^m = \beta_h (\omega_{i(j-1)k}^m + \omega_{i(j+1)k}^m) + \beta_v (\omega_{(i-1)jk}^m + \omega_{(i+1)jk}^m) + \beta_s (\omega_{ij(k-1)}^m + \omega_{ij(k+1)}^m) + \epsilon_{ijk}^m \quad (1)$$

式中, β_h , β_v 和 β_s 分别是空间和光谱维的预测系数, ϵ_{ijk}^m 是下面将讨论的具有特殊相关结构的预测误差。现假定具有零 Dirichlet 边界条件的一阶 3D 马尔可夫模型。不失一般性,假定背景零均值。实际上,空间变化的均值被局部地估计出来,然后从数据中移除。在一阶 3D 马尔可夫模型中,像素的强度由最邻近的 6 个像强度来表示: 4 个空间近邻像素和 2 个光谱近邻像素。高阶马尔可夫模型定义类似,如图 1 所示。为了简单起见,限定讨论一阶随机场。把大小为 $N_i N_j \times 1$ 的 N_k 个向量 $\omega^m(k)$ 堆在一起,得到背景向量 W_m , 大小为 $N_i N_j N_k \times 1$ 。

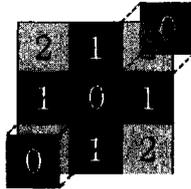


图 1 一阶 3D 马尔可夫模型

对处理窗口中的每个马尔可夫窗重复此过程,得到 n 个数据向量集合。误差向量以 3D 格形预测误差 ϵ_{ijk}^m 开始同样的方式形成。数据可以用矩阵-向量方程简洁地表示:

$$AW_m = \epsilon_m \quad (2)$$

$$A = I_{N_k} \otimes A_1 + H_{N_k} \otimes A_2 \quad (3)$$

式中,“ \otimes ”表示 Kronecker 积,数学定义为 $A \otimes B = [a(m, n) B]$ 。如果 A 的大小是 $M \times N$, B 的大小是 $M \times N$, 那么结果矩阵大小为 $MN \times MN$ 。

研究显示误差向量集合 ϵ_m 是零均值、方差 $\Sigma = \sigma^2 A$ 的高斯噪声过程的样本。GMRF 模型一个主要的优点是背景方差阵的逆 Σ^{-1} 参数可确定得到。背景方差阵的逆与势矩阵是简单的比例关系, $\Sigma^{-1} = (1/\sigma^2)A$ 。用 Kronecker 符号形式,背景方差阵的逆表示为:

$$\Sigma^{-1} = \frac{1}{\sigma^2} I_{N_k} \otimes I_{N_i} \otimes I_{N_j} - \frac{\beta_h}{\sigma^2} I_{N_k} \otimes I_{N_i} \otimes H_{N_j} - \frac{\beta_v}{\sigma^2} I_{N_k} \otimes H_{N_i} \otimes I_{N_j} - \frac{\beta_s}{\sigma^2} H_{N_k} \otimes I_{N_i} \otimes I_{N_j} \quad (4)$$

4 个标量参数 σ^2 , β_h , β_v 和 β_s 由近似最大似然估计得到。

2 基于随机场模型的局域异常目标探测方法

2.1 基于随机场模型确定目标存在区域

随机场模型另外一个重要特点就是可以通过能量函数来

反映邻域相关性信息。在高斯马尔可夫随机场中,通过定义邻域系统子团的能量函数来表达邻域系统的结构信息^[9,10]。根据第 1.1 节中定义的高光谱遥感影像的马尔可夫随机场模型邻域阶数较低的特点,本文采用如下形式的能量函数:

$$U(z) = \sum_{c \in C} \rho(d_c(z)) \quad (5)$$

式中, c 是一个簇,即局部像元的集合,而 C 是影像上所有簇的集合, $d_c(z)$ 是对影像的空域算子运算,由一阶或者二阶的线性差分组成^[14,15]。在高光谱遥感影像中,单一异常目标一般由少数几个像元组成,利用二阶邻域即可包含整个异常目标。本文中选用以下 4 个二阶差分算子来定义能量函数^[11]:

$$d_c^1(z_{x,y}) = z_{x-1,y} - 2z_{x,y} + z_{x+1,y} \quad (6)$$

$$d_c^2(z_{x,y}) = z_{x,y-1} - 2z_{x,y} + z_{x,y+1} \quad (7)$$

$$d_c^3(z_{x,y}) = \frac{1}{\sqrt{2}} [z_{x-1,y-1} - 2z_{x,y} + z_{x+1,y+1}] \quad (8)$$

$$d_c^4(z_{x,y}) = \frac{1}{\sqrt{2}} [z_{x-1,y+1} - 2z_{x,y} + z_{x+1,y-1}] \quad (9)$$

$\rho(\cdot)$ 为 Huber 势能函数,定义为:

$$\rho(i) = \begin{cases} i^2, & |i| \leq \mu \\ 2\mu|i| - \mu^2, & |i| > \mu \end{cases} \quad (10)$$

$\rho(\cdot)$ 为 1 个分段函数,由 1 个二次函数和 1 个线性函数组成。当 μ 趋近于无穷大时,有:

$$\lim_{\mu \rightarrow \infty} \rho(i) = i^2 \quad (11)$$

此时包含了邻域结构信息的能量函数为:

$$U(z) = \sum_{i=1}^4 (d_c^i(z_{x,y}))^2 \quad (12)$$

在高光谱遥感影像中,异常目标与背景地物的差异还突出地表现在其光谱曲线的形状与其他背景地物相比,都有很大差异。因此在相同的波段上面,存在异常目标的地方常常是相邻像元反射率值发生较大突变的地方,用能量函数来表示,即能量值非常大的地方。因此,可以用能量函数的变化来确定异常目标可能出现的位置。RX 等异常目标探测算法,需要计算每个局域窗口范围内的背景协方差矩阵的逆,因此时间代价较大。而能量函数只需经过简单的差分运算即可得到,因此利用能量函数的大小来初步确定异常目标的区域,并缩小探测区域,可以有效地减少时间代价。由于高光谱影像为多波段数据,在实际探测中,逐个波段计算能量函数,记录每个能量函数变化比较大的像元位置;最后将各个波段的结果合并起来,得到最终的能量函数突变的所有像元位置,即可得到异常目标可能出现的所有位置。异常目标在影像中出现的概率通常很小,可以认为其像元数目占影像像元总数的比例一般小于 1%^[7]。在本文的方法中,为防止遗漏异常目标,取每个波段能量最大的 2% 作为可能的异常目标位置记录下来。由于异常目标至少在一个波段上会表现出能量剧变,因此将每个波段上的能量剧变的位置都合并起来,可以保证所有的异常目标的位置均被记录。对这些记录的位置再应用局域异常探测算法,可以大大减少计算代价。

2.2 基于随机场模型的异常探测算子

将邻域信息引入到局域异常探测算法中,发展出基于邻域信息的局域异常探测算法。具体地,将每个输入的光谱信号视为一个由各个波段上的数据组成的多维向量:

$$x(n) = (x_1(n), x_2(n), \dots, x_j(n))^T \quad (13)$$

异常探测的两个假设写为:

$$H_0: x=n(\text{目标出现})$$

$$H_1: x=as+n(\text{目标未出现}) \quad (14)$$

式中,在 H_0 的条件下 $a=0$,而在 H_1 的条件下 $a>0$ 。 n 是一个代表背景噪声的随机过程。 s 是目标信号的光谱向量: $s=(s_1, s_2, \dots, s_j)^T$ 。目标的光谱向量 s 和背景协方差 C_b 都是未知的。此模型假设影像中的所有数据都是来自于两类正态概率密度函数,并且这两类函数拥有相同的协方差矩阵不同的均值。在 H_0 的条件下,背景数据符合这样一个正态分布模型: $N(0, C_b)$,而在 H_1 的条件下数据符合这样的正态模型: $N(s, C_b)$ 。在 RX 算法中,一个关键性的假设就是目标和背景数据都有相同的协方差矩阵。但是一般而言,在探测一个特定的目标结构时,这种假设未必正确。所以更合理的情况应该是假设有两个不同的协方差结构:一个用来描述异常目标点或杂波噪声,一个用来描述背景像元信号。但是,由于完全无法确定异常目标点的统计结构,异常目标点的协方差结构无法得到估计,因而这里将异常目标点与背景采用相同的协方差矩阵。

这样,假设目标点向量为 r ,RX 算子就可以写成:

$$RX(x) = (x - \hat{\mu}_b)^T \left(\frac{M}{M+1} \hat{C}_b + \frac{1}{M+1} (x - \hat{\mu}_b)(x - \hat{\mu}_b)^T \right)^{-1} (x - \hat{\mu}_b) \quad (15)$$

对上式设定阈值 η ,大于 η 时认为目标出现; \hat{C}_b 是从背景数据中得到的协方差矩阵, $\hat{\mu}_b$ 是背景的采样均值。当实验影像中的像元数目较多,即当 $M \rightarrow \infty$ 时,RX 算法收敛于:

$$RX(r) = (r - \hat{\mu}_b)^T \hat{C}_b^{-1} (r - \hat{\mu}_b) \quad (16)$$

将式(4)代入上述公式,得到基于高斯马尔可夫随机场模型的局域异常探测算法:

$$Detector(r) = (r - \hat{\mu}_b)^T \sum_{w=1}^m (r - \hat{\mu}_b) \quad (17)$$

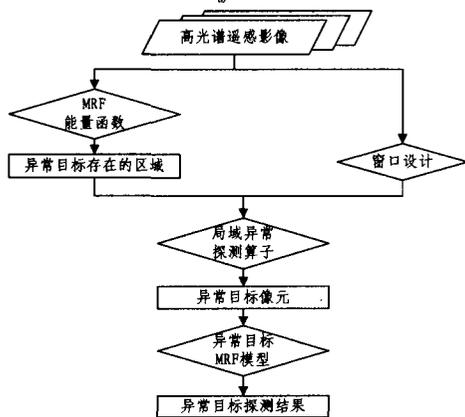


图2 本文算法流程

本文应用此公式时,采用同中心双窗口策略,即内层为目标区域,外层为目标的背景区域。因为所探测目标为亚像元目标,所以内层窗口为一个像元大小;外层窗口的大小选择比较复杂,需要使场景中该外层窗口的范围内非目标点符合高斯分布。在本文中主要采用调整窗口尺寸进行试探,排除微小误差,以符合高斯分布的性质为标准,选择尽可能符合高斯分布的场景范围,即确定外层窗口大小。具体地,利用扭曲度(skewness)或峭度(kurtosis),也就是三阶和四阶矩来确定外层窗口大小。它们是从图像空间角度来描述小目标奇异特性的有效度量。在算法的假设中,认为局部区域内背景均一,那

么背景向量将符合高斯分布。在实际实验中,用外层窗口大小为 N 的同中心双层窗口去遍历整个影像区域,设定阈值为 90%,即保证 90% 以上的区域符合高斯分布,这时的 N 即为所要求的外层窗口尺寸。

本文算法的完整流程如图 2 所示。

3 实验与分析

3.1 模拟数据实验

利用 ENVI 软件标准光谱库中的多种地物光谱合成模拟数据。采用合成模拟数据的原因是为了获得足够的亚像元异常目标,克服真实影像中亚像元目标数目不足的缺点。具体地,使用如下 5 种地物的光谱来合成模拟数据的背景:裸土、鲜草、灌木、枯草和树叶,它们的光谱曲线如图 3 所示。通过将 5 种地物的光谱曲线与标准的 AVIRIS 数据的波段进行匹配,选择质量较高的 100 个波段得到所需的 5 种地物的光谱数据。模拟数据是由 40000 个点组成 200×200 的影像,顺次均匀地分为 4 组:第 1 组由 50% 的裸土和 50% 的鲜草光谱数据混合而成;第 2 组由 50% 的灌木和 50% 的鲜草光谱数据混合而成;第 3 组由 50% 的裸土和 50% 的灌木光谱数据混合而成;第 4 组由 50% 的枯草和 50% 的树叶光谱数据混合而成。

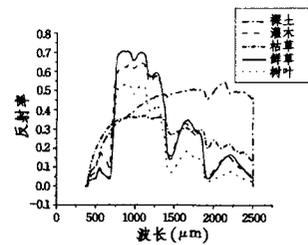


图3 5种地物的光谱曲线

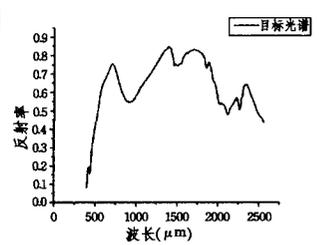


图4 目标光谱曲线

然后,从 ENVI 光谱库中选取矿石光谱视为目标,如图 4 所示,在模拟数据中添加目标光谱生成最终的模拟数据影像。具体方法为:首先将原模拟影像作为背景影像,在影像正中的竖直方向上,从上至下每间隔一个像元依次生成 100 个目标像元,这样就生成了第一幅模拟数据影像,如图 5 左所示。这 100 个目标像元平均分为 5 组,依次含有矿石光谱的比例为 10%,20%,40%,60%,80%;相应目标点上含有背景光谱的比例分别减少到 90%,80%,60%,40%,20%。然后在影像的随机位置用同样的方法加入 100 个目标,这样得到了第二幅模拟数据影像,其外观如图 5 右所示。

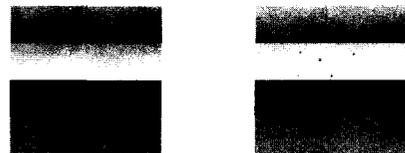


图5 合成数据影像

实验中,使用经典的 RX 算法做对比实验,其实验的结果图在外观上与本文的方法差别不大。采用同样的阈值进行分割,统计两种方法对两幅影像的定量探测结果,如表 1 所列。从表 1 可知,本文算法将第一幅影像中的 100 个目标成功探测出 96 个,探测率达到 96%,虚警率为 0%;将第二幅影像中的 100 个目标中成功探测出 98 个,探测率达到 98%,有两个虚警目标,虚警率为 3%。从表 1 可知,本文的算法比 RX 算法的探测率更高,虚警率更低。在第一幅影像中所有的目标

均是亚像元的单像元目标,本文的算法与RX算法的差别并不明显。下面进一步分析两种算法中对不同大小目标的探测效果。

表1 定量探测结果

方法	探测结果(探测率/虚警率)	
	第一幅	第二幅
本文的方法	96%/0%	98%/3%
RX算法	91%/7%	80%/12%

在第二幅影像中,考察目标的尺寸,发现有5个目标是由两个或多个像元组成的大目标,对这部分目标的探测结果统计如表2所列。从表2可知,本文的方法将包含多个像元的大目标的目标点几乎全部探测出来,而RX算法却只能探测出大目标的部分组成像元。可见,本文的方法探测大目标的效果比RX算法更好。究其原因,主要是由于本文的方法充分地利用了邻近像元的类别相关性,克服了窗口策略的平滑效应;而RX算法是基于中心像元相对于周边窗口区域的统计异常度的,因此常常只能提取局域范围内异常度最大的单个目标点。

表2 探测出大目标像元的数目

目标序号(包含像元数)	1(2)	2(2)	3(3)	4(3)	5(2)
本文的方法	2	1	3	2	2
RX算法	1	0	1	1	1

3.2 真实数据实验

本文使用的真实数据是AVIRIS高光谱遥感影像,影像波段数目为224,影像大小为200×200。该影像主要由红色的氧化玄武岩、流纹岩、沙漠盆地、阴影和植被5种地物组成,其中包含一个由两个像元组成的异常目标,是高光谱遥感目标探测中被普遍使用的一幅影像^[12]。该影像第35波段的图像如图6所示,其中的异常目标用白色圆圈圈出。从图6可知,目标在视觉上无法辨别。实验中,我们剔除大气吸收和低信噪比的波段,得到158个波段,分别应用本文的算法和RX算法进行实验。图7为本文算法对该影像的探测结果,RX算法的探测结果图与其视觉差别不大。图8和图9分别是本文的算法和RX算法经阈值分割后最后的探测结果图,其中的黑色点表示探测出的目标像元。从图8可知,本文的算法将两个像元组成的大异常目标全部探测出,没有虚警目标;而从图9可知,RX算法只将大异常目标中的一个像元探测出,还有一个虚警目标。可见,本文的算法对大于一个像元的异常目标的探测结果确实更好。此外,统计两种方法的时间代价,RX算法为32s,而本文算法为21s,速度提高了52.4%。这主要是本文算法利用领域相关性事先减小了待探测区域,而这种方法仅是差分计算,时间代价较小;RX算法则需要对整个影像进行协方差逆矩阵求解,因而时间代价较大。



图6 真实数据影像



图7 本文算法探测后影像

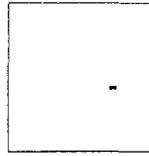


图8 本文算法最终结果

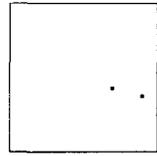


图9 RX算法最终结果

结束语 利用高斯马尔可夫随机场模型可以反映邻域像元相关性的特点,不但减小了待探测区域,而且可利用该模型表达像元的邻域与中心像元的相关性,并将这种相关性引入到局域异常探测算法中。本文提出了一种减小探测区域、充分顾及影像内邻域相关性的高光谱遥感影像局域异常目标探测方法。实验证明,该方法与RX算法相比,可以有效地利用邻域相关性探测出多像元的大异常目标,而且探测速度大大提高。

参考文献

- [1] Baker C J, Pink J M, Toughr J A. A statistical model for radar target detection in clutter [C]// Proceedings of the 1988 IEEE National Radar Conference, 1988: 241-245
- [2] Manolakis D G, Marden D, Kerekes J P, et al. Statistics of hyperspectral imaging data [C]// Proceedings of SPIE, 2001 (4381): 308-316
- [3] Chapple P B, Bertilone D C, Caprari R S, et al. Stochastic model-based processing for detection of small targets in non-Gaussian natural imagery [J]. IEEE Trans. Image Processing, 2001, 10 (4): 554-564
- [4] Margalit A, Reed I S, Gagliardi R M. Adaptive optical target detection using correlated images [J]. IEEE Trans. Aerospace and Electronic Systems, 1985, 21(3): 394-405
- [5] Schweizer S M, Moura J M F. Hyperspectral imagery: clutter adaptation in anomaly detection [J]. IEEE Trans. Information Theory, 2000, 46(5): 1855-1871
- [6] Reed R, Yu X. Adaptive multi-band CFAR detection of an optical pattern with unknown spectral distribution [J]. IEEE Trans. Acoust., Speech, Signal Process, 1990, 38(10): 293-305
- [7] Kwon H, Nasrabadi N M. Kernel RX-Algorithm: a nonlinear anomaly detector for hyperspectral imagery [J]. IEEE Trans. Geosci. Remote Sensing, 2005, 43(2): 388-397
- [8] Chang C I, Chiang S S. Anomaly detection and classification for hyperspectral imagery [J]. IEEE Trans. Geosci. Remote Sensing, 2002, 40(6): 1314-1325
- [9] Pan R, Reeves S J. Efficient Huber-Markov Edge-preserving Image Restoration [J]. IEEE Trans. Image Processing, 2006, 15 (12): 3728-3735
- [10] Schultz R R, Stevenson R L. Extraction of high-resolution frames from video sequences [J]. IEEE Trans. Image Processing, 1997, 5(6): 996-1011
- [11] 沈唤峰. 场景变化条件下的影像超分辨率重建技术研究[D]. 武汉: 武汉大学, 2007
- [12] Chiang S S, Chang C I, Ginsberg I W. Unsupervised Target Detection in Hyperspectral Images Using Projection Pursuit [J]. IEEE Trans. Geosci. Remote Sensing, 2001, 39(7): 1314-1325