

文章编号: 0253-2239(2007)12-2155-8

一种基于单似然检验的高光谱图像小目标检测器 *

贺 霖^{1,2} 潘 泉² 邱 韶² 赵永强²

(¹ 华南理工大学自动化科学与工程学院, 广州 510641)
(² 西北工业大学自动化学院, 西安 710072)

摘要: 针对背景和目标的先验光谱特征未知的条件, 给出一种基于单似然检验的高光谱图像小目标检测器。小目标相对于背景的低概率性使得高光谱图像数据对目标光谱信号的矩特征几乎不施加约束, 可在最大熵条件下将广义似然比检验简化为对背景似然的单似然检验; 利用全部数据样本建立无参估计模型以充分利用样本信息, 从而得到基于单似然检验的高光谱图像小目标检测器。该检测器避免了统计模型误差和不明确物理含义特征对实际高光谱图像数据检测带来的影响。使用可见光/近红外波段机载 I 型实用型模块化成像光谱仪(OMIS-I)高光谱图像进行了实验, 实验结果及相应理论分析表明该算法可有效检测高光谱图像中的空间低概率目标。

关键词: 信息处理技术; 高光谱图像处理; 目标检测; 单似然检验

中图分类号: TP391.4 文献标识码: A

A Small-Target Detector Based on Single Likelihood Test for Hyperspectral Imagery

He Lin^{1,2} Pan Quan² Di Wei² Zhao Yongqiang²

(¹ College of Automation Science and Engineering, South China University of Technology, Guangzhou 510641)
(² College of Automation, Northwestern Polytechnical University, Xian 710072)

Abstract: A small-target detector based on single likelihood test for hyperspectral imagery is presented to detect target when there is no a priori spectral signal of background and target, which presume the maximum entropy character of target. Because of the low-probability occurrence of target compared with that of background, it can be assumed that there is no constraint by hyperspectral imagery data on the moments of target signal. Accordingly, the generalize likelihood ratio test can be simplified to test background likelihood solely under maximum entropy of target. Then, nonparametric estimation is utilized to obtain the probability density of background, which can extract information from samples more effectively. The single likelihood test based detector weakens the effect of statistic model discrepancy and avoids effect of implicit physical meaning on detection. Theoretic analysis and the experimental results on visible/near-infrared OMIS-I hyperspectral imagery verify that these algorithms are effective to detect spatial low-probability targets.

Key words: information processing technology; hyperspectral imagery processing; target detection; single likelihood test

1 引言

高光谱图像成像波段密集且连续, 可进行图谱

合一的测量^[1], 能够反映出观测场景中不同对象光谱信号的细微差异^[1,2], 提供更多观测场景中的信

* 国家自然科学基金重点项目(60634030)、国家自然科学基金(60475004, 60602056, 60372085)、航空科学基金(2006ZC53037)、遥感科学国家重点实验室开放基金(SK050013)、教育部新世纪人才基金(NCET-04-0816)和广东省自然科学基金团队项目(04205783)资助课题。

作者简介: 贺 霖(1973—), 男, 天津人, 讲师, 博士, 主要从事复杂环境目标检测识别, 高光谱图像处理, 信息融合、多元信号处理等方面的研究。E-mail: herain33@gmail.com

导师简介: 潘 泉(1961—), 男, 上海人, 教授, 博士, 主要从事动态系统建模、多目标跟踪与识别、信息融合、智能监控、C³I 技术、多尺度估计理论等方面的研究。E-mail: quanpan@nwpu.edu.cn

收稿日期: 2006-11-29; 收到修改稿日期: 2007-04-26

息,在对缺少形状等信息的小目标及信号微弱的目标进行检测和识别方面具有独特优势。因此,高光谱图像目标检测技术自 20 世纪 80 年代末出现后引起了许多相关研究机构的重视,被应用于矿藏探测、农作物品种识别、伪装车辆检测、地雷探测和近海潜艇探测等许多方面^[3~6]。当背景和目标的先验光谱特征未知时,高光谱图像目标检测须以异常检测的方式进行,常用的高光谱图像异常检测算法主要包括两类,一类算法是将不符合背景统计特性的统计异常点判为目标,RX 检测器(RXD)^[7~9]是这类算法中的代表性算法,它以背景数据的空间白化多元正态随机过程为基础进行统计异常检测,类似算法还有均匀目标检测器(UTD)^[9~11],该算法把 RX 检测器中的匹配信号由量测信号替换为均匀向量;另一类算法是在高光谱图像中寻找背景或是目标的光谱特征,然后利用子空间投影等匹配的方法进行检测^[9~13],低概率检测器(LPD)^[9~11]是这类算法中的代表性算法,它将高维量测数据的主成分作为背景特征进行正交子空间投影。

利用统计性方法进行高光谱图像目标检测问题可转化为二值假设检验问题,其检验形式根据一定的准则来确定。当目标和背景的统计特性及误判代价未知时,可通过聂尔曼-皮尔逊(Neyman-Pearson)准则得到的广义似然比来构造检测器。常用的如 RX 检测器和均匀目标检测器一类的高光谱图像异常检测算法通常是在数据服从某种参量化统计模型的基础上来进行构造的,模型与量测数据之间的差异会影响实际数据的检测结果;而低概率检测一类算法应用了没有明确物理含义的特征,也会影响检测效果。针对这些问题,给出了一种基于单似然检验的小目标检测器。考虑到目标相对于背景通常具有空间的低概率性,将高光谱图像数据对目标样本矩特征施加的约束近似视为零约束,并利用最大熵条件,在目标信源提供最大信息量且不会引入多余的主观性假设的情况下求得目标统计模型,并利用该模型将广义似然比检验简化为对背景似然的单似然检验;利用目标的低概率特性还可将高光谱图像量测数据样本近似视为全部来自于背景总体,建立无参估计模型;最后,构造出检测具有空间低概率特性的异常目标的一类检测器,并讨论了样本总体为核函数的情况。本文给出的检测器不依赖于参量化统计模型且具有明确的物理含义,可充分利用被检测数据所反映出的统计特性,实现对低概率异常目标的有效检测。

2 数据模型

高光谱图像是一个图像立方体,可视为经过配准的多源图像。对于空间大小为 N 个像素、波段数为 B 的高光谱图像,可用矩阵形式表示为

$$\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_k, \dots, \mathbf{x}_N],$$

其中 $\mathbf{x}_k = [x_{k_1}, x_{k_2}, \dots, x_{k_B}]^T$, 表示高光谱图像的第 k 像素位置处的量测样本向量。背景地物的光谱特征信号可用矩阵形式表示为

$$\mathbf{S}_b = [\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_k, \dots, \mathbf{b}_P],$$

其中 $\mathbf{b}_k = [b_{k_1}, b_{k_2}, \dots, b_{k_B}]^T$ 为第 k 种背景地物的光谱信号向量, P 为背景地物种数, 目标的光谱信号可用矩阵形式表示为

$$\mathbf{S}_t = [t_1, t_2, \dots, t_k, \dots, t_Q],$$

其中 $t_k = [t_{k_1}, t_{k_2}, \dots, t_{k_B}]^T$ 为第 k 种目标的光谱信号向量, Q 为目标的种类数。

3 低概率目标单似然检验

高光谱图像目标检测通常是利用量测数据,通过统计性方法确定某一空间像素位置是否为目标。假定背景数据和目标数据服从不同的高维分布 $p_0(x)$ 和 $p_1(x)$, 对任一像素位置的量测样本向量 x 有假设模型:

$$H_0: x \sim p_0(x), \quad H_1: x \sim p_1(x). \quad (1)$$

目标和背景出现的先验概率、量测的似然函数未知且判决代价难以确定时,根据 Neyman-Pearson 准则,检测目标的最优决策可化为广义似然比检验的形式:

$$\Lambda(x) = \frac{L_1(x)}{L_2(x)} = \frac{p(x|H_1)}{p(x|H_0)} = \begin{cases} \frac{p_1(x)}{p_0(x)} & \geq \lambda, \text{ target} \\ & < \lambda, \text{ background} \end{cases} \quad (2)$$

其中 λ 为阈值。

根据最大熵原理^[14], 通过最大熵准则估计得到的分布包含了最大的信息量且体现了最大的客观程度。

将目标和背景总体视为两个信源。假设 $\Theta \subset \mathbb{R}^B$ 为目标总体 $p_1(x)$ 的样本空间, 则目标总体的熵为^[14,15]

$$H(p_1) = - \int_{\Theta} \Theta p_1(x) \log_a p_1(x) dx. \quad (3)$$

目标总体的熵是随机变量概率分布 $p_1(x)$ 的函数,与 x 的取值无关。

对于目标总体,在其所有可能的概率密度函数

中寻找使得其熵值最大的概率密度函数分布,可表示为寻找函数:

$$\hat{p}_1(\mathbf{x}) = \arg \left\{ \max_{p_1} [H(p_1)] \right\}, \quad (4)$$

其中 $\hat{p}_1(\mathbf{x})$ 满足非负性、积分为 1 性,且存在 m 阶矩。

对于低概率目标,难以从其样本中得到目标总体分布的矩信息,可认为对没有施加约束。

利用拉格朗日乘数法建立目标函数^[14]:

$$\begin{aligned} J(\hat{p}_1) = & - \int_{\Theta} \hat{p}_1(\mathbf{x}) \ln \hat{p}_1(\mathbf{x}) d\mathbf{x} + \\ & \lambda_0 \left[1 - \int_{\Theta} \hat{p}_1(\mathbf{x}) d\mathbf{x} \right] + \\ & \sum_{i=1}^m \lambda_i \left[\alpha_i - \int_{\Theta} \hat{p}_1(\mathbf{x}) r_i(\mathbf{x}) d\mathbf{x} \right] = \\ & - \int_{\Theta} \hat{p}_1(\mathbf{x}) \ln \hat{p}_1(\mathbf{x}) d\mathbf{x} + \\ & \lambda_0 \left[1 - \int_{\Theta} \hat{p}_1(\mathbf{x}) d\mathbf{x} \right], \end{aligned} \quad (5)$$

其中 $\lambda_0, \lambda_1, \dots, \lambda_m$ 为拉格朗日乘子, $\alpha_i (1 \leq i \leq m)$ 为总体概率密度估计的各阶矩, $r_i(\mathbf{x})$ 为样本 \mathbf{x} 的各阶矩的计算表达式。利用(5)式可得 $\hat{p}_1(\mathbf{x})$ 的极大值:

$$\hat{p}_1(\mathbf{x}) = \exp(\lambda_0 - 1), \quad (6)$$

其中 $\mathbf{x} \subset \Theta$ 。

根据(6)式和 $\hat{p}_1(\mathbf{x})$ 的积分为 1 性可得

$$\lambda_0 = 1 - \ln \int_{\Theta} d\mathbf{x}. \quad (7)$$

将(7)式代入(6)式得到

$$\hat{p}_1(\mathbf{x}) = 1 / \int_{\Theta} d\mathbf{x}. \quad (8)$$

当目标样本空间 Θ 确定时,目标总体相对于高维空间 \mathbf{R}^B 的概率密度函数为

$$\hat{p}_1(\mathbf{x}) = \begin{cases} 1 / \int_{\Theta} d\mathbf{x}, & \mathbf{x} \subset \Theta \\ 0, & \text{other} \end{cases} \quad (9)$$

因此,由式(9)可将式(2)所示的似然比检验形式化简为

$$\Lambda_1(\mathbf{x}) = \frac{1}{p_0(\mathbf{x}) \int_{\Theta} d\mathbf{x}} \begin{cases} \geq \lambda_1, & \text{target} \\ < \lambda_1, & \text{background} \end{cases} \quad (10)$$

其中 λ_1 为阈值。对(10)式进一步简化为

$$\Lambda_2(\mathbf{x}) = p_0(\mathbf{x}) \begin{cases} \leq \lambda_2, & \text{target} \\ > \lambda_2, & \text{background} \end{cases} \quad (11)$$

其中 $\lambda_2 = 1 / \lambda_1 \int_{\Theta} d\mathbf{x}$ 为检测阈值,根据虚警率

$$P_F = \int_{\Lambda_2(\mathbf{x}) | H_0}^{\infty} f_{\Lambda_2(\mathbf{x}) | H_0} [\Lambda_2(\mathbf{x}) | H_0] d\Lambda_2(\mathbf{x}) = \alpha$$

$f_{\Lambda_2(\mathbf{x}) | H_0} [\Lambda_2(\mathbf{x}) | H_0]$ 为 $\Lambda_2(\mathbf{x})$ 的概率密度函数。(11)式将(2)式中利用背景和目标两个似然的似然比检验形式简化为只利用背景似然进行检验的单似然检验形式。

4 基于背景单似然检验的检测器

要使用(11)式的单似然检验对目标进行检测,必须获取背景总体的概率密度函数 $p_0(\mathbf{x})$ 。在空间低概率目标条件下,高光谱图像的所有观测样本可以近似视为全部来自于背景总体。因此,可使用全部高光谱图像数据样本对背景总体的概率密度进行估计。

实际的高光谱图像量测数据复杂多变,难以用确定的统计模型进行描述,模型与实际数据之间存在的模型误差通常是导致运算结果不理想的一个重要原因^[16,17]。为在背景似然估计的过程中充分利用高光谱图像样本信息,减小对参量统计模型的依赖,实现对任意形式的背景总体统计分布进行有效估计,可利用每个已出现的高光谱图像像素点构造无参密度估计模型,假设高光谱图像数据样本来自于 N 个总体,第 i 个总体的概率密度在样本 \mathbf{x} ($i = 1, 2, \dots, N$) 处具有最大值,则可将高光谱图像背景总体概率密度的估计值表示为

$$\hat{p}_0(\mathbf{x}) = \sum_{i=1}^N \alpha_i p_i(\mathbf{x} | \mathbf{x}_i), \quad \mathbf{x} \in \Omega \quad (12)$$

其中 α_i 是样本 \mathbf{x}_i 对概率密度估计的贡献率, Ω 为背景总体样本空间, $p_i(\mathbf{x} | \mathbf{x}_i)$ 为 \mathbf{x}_i 的总体的概率密度函数。(12)式所示的背景总体概率密度估计模型主要依赖于观测样本及每个样本对应的总体分布特性。对于高光谱图像中的 N 个观测样本,它们是同时出现的,则 $\alpha_i = 1/N (i = 1, 2, \dots, N)$ 。此时,(12)式简化为

$$\hat{p}_0(\mathbf{x}) = \frac{1}{N} \sum_{i=1}^N p_i(\mathbf{x} | \mathbf{x}_i), \quad \mathbf{x} \in \Omega, \quad (13)$$

对于(12)式和(13)式所示高光谱图像背景概率密度函数的估计 $\hat{p}_0(\mathbf{x})$,为衡量其估计的准确程度可定义高光谱图像样本筹权估计累积均方差

$$\begin{aligned} & \int_{\Omega} E[\hat{p}_0(\mathbf{x}) - p_0(\mathbf{x})]^2 d\mathbf{x} = \\ & \int_{\Omega} \text{var}[\hat{p}_0(\mathbf{x})] d\mathbf{x} + \int_{\Omega} \{\text{bias}[\hat{p}_0(\mathbf{x})]\}^2 d\mathbf{x} + \\ & 2 \int_{\Omega} E[E\hat{p}_0(\mathbf{x})E p_0(\mathbf{x}) - E\hat{p}_0(\mathbf{x})p_0(\mathbf{x})] d\mathbf{x} = \\ & \int_{\Omega} \text{var}[\hat{p}_0(\mathbf{x})] d\mathbf{x} + \int_{\Omega} \{\text{bias}[\hat{p}_0(\mathbf{x})]\}^2 d\mathbf{x}, \quad (14) \end{aligned}$$

其中 var 表示方差, bias 表示偏移。由(14)式可知, 高光谱图像样本等权估计累积均方差可分解为高光谱图像累积背景估计方差和高光谱图像累积背景估计平方偏移。

要使用背景无参估计模型进行高光谱图像背景密度估计, 在样本权重相等的情况下, 还需要确定样本总体的具体形式, 考虑到运算方便, 可以将所有样本总体取相同的单模形式, 为充分利用样本信息, 样本总体概率密度的模的位置应由相对于该样本的极大似然来确定, 即某一样本对应的样本总体概率密度的模的位置应在样本处。

若取样本总体概率密度函数为

$$p(\mathbf{x} | \mathbf{x}_i) = \frac{1}{h_B} \Phi\left(\frac{\mathbf{x} - \mathbf{x}_i}{h}\right), \quad (15)$$

其中 h 为带宽参量, 且 $\Phi(\mathbf{x})$ 满足核函数条件, 则(12)式成为核密度估计^[17,18]的形式。利用(14)式、(15)式及多元泰勒展开公式可将高光谱图像等权估计累积均方差可化简为^[18,19]

$$\begin{aligned} A_{\text{HBMISE}}(\hat{p}_0) &= \left\{ \int_{\Omega} \Phi(t)[p_0(\mathbf{x} - ht) - p_0(\mathbf{x})] dt \right\}^2 + \frac{1}{N} \left\{ \int_{\Omega} w(\mathbf{x}, t)^2 p_0(\mathbf{x}) d\mathbf{x} - \left[\int_{\Omega} w(\mathbf{x}, t) p_0(\mathbf{x}) d\mathbf{x} \right]^2 \right\} = \\ & \frac{1}{4} h^4 \left[\int_{\Omega} \Phi(t) t^T t dt \right]^2 \int_{\Omega} [H_{p_0}(\mathbf{x})]^2 d\mathbf{x} + \frac{1}{Nh^B} \int_{\Omega} \Phi(\mathbf{x})^2 d\mathbf{x}, \quad (16) \end{aligned}$$

其中 H_{p_0} 为 $p_0(\mathbf{x})$ 相对于 \mathbf{x} 的海森(Hessian)矩阵。

令(16)式为零, 可以得到使高光谱图像等权估计累积均方差最小的最优带宽参量为

$$h_{\text{opt}} = \left\{ B \int_{\Omega} \Phi(\mathbf{x})^2 d\mathbf{x} \left[\int_{\Omega} \Phi(\mathbf{x}) \mathbf{x}^T \mathbf{x} d\mathbf{x} \right]^{-2} \left[\int_{\Omega} H_{p_0}(\mathbf{x})^2 d\mathbf{x} \right]^{-1} N^{-1} \right\}^{-B-4}, \quad (17)$$

利用(16)和(17)式可求解得到使得等权估计累积均方差最小的核函数:

$$\Phi_e(\mathbf{x}) = \begin{cases} \frac{1}{2} c_B^{-1} (B+2) (1 - \mathbf{x}^T \mathbf{x}), & \mathbf{x}^T \mathbf{x} < 1 \\ 0, & \text{other} \end{cases} \quad (18)$$

其中 c_B 为 B 维空间的单位球体体积。(18)式所示的使高光谱图像等权估计累积均方差最小的函数具有 Epanechnikov 核函数^[18,19]的形式。

虽然在理论推导上, (18)式所示的核函数是最优的, 但与带宽参量 h 的选择相比核函数的选择并不重要, 带宽参量 h 的选择比核函数的选择重要得多, 在核密度估计时, 核函数的选取通常只从运算的简单性等方面考虑, 可选择高斯核等其他形式的核函数^[16]。

此外, 由于(17)式所示的理想带宽表达式中含有待估计的概率密度, 导致理想带宽 h_{opt} 是无法得到的。实际应用中, 带宽参量 h 的选择可以利用高光谱等权估计累积均方差, 根据多种准则近似确定, 这些准则包括最大平滑定理法(MSP)和经验法

(ROT)等^[18,19]。最大平滑定理法就是使用真实概率密度函数平方积分的下界获取估计量, 由高光谱图像等权估计累积均方差准则的渐近形式求得带宽; 经验法使用方差已被规范化为样本方差的一个参考分布函数替代真实概率密度函数, 由高光谱图像等权估计累积均方差准则的渐近形式求得带宽。

样本总体除了可以选取(18)式所示的标准核函数, 还可以从待处理数据的特点、处理方法的计算代价及处理方法的统计特性等角度选取其它形式。

如果将样本总体取为(15)式所示的形式, 利用(11)式所示的低概率目标单似然检验形式和(12)式、(13)式所示的无参估计模型, 并根据求取带宽参量 h 的不同可得如下的无参估计低概率目标检测器:

$$\delta'_{\text{MSP}}(\mathbf{x}) = \frac{1}{Nh_{\text{MSP}}^B} \sum_{i=1}^N \Phi\left(\frac{\mathbf{x} - \mathbf{x}_i}{h_{\text{MSP}}}\right) \begin{cases} < \eta_{\text{MSP}}, & \text{target} \\ \geq \eta_{\text{MSP}}, & \text{background} \end{cases} \quad (19)$$

$$\delta'_{\text{ROT}}(\mathbf{x}) = \frac{1}{Nh_{\text{ROT}}^B} \sum_{i=1}^N \Phi\left(\frac{\mathbf{x} - \mathbf{x}_i}{h_{\text{ROT}}}\right) \begin{cases} < \eta_{\text{ROT}}, & \text{target} \\ \geq \eta_{\text{ROT}}, & \text{background} \end{cases} \quad (20)$$

其中 h_{MSP} 和 h_{ROT} 分别是最大平滑定理法和经验法准则求取的核密度估计带宽, η_{MSP} 和 η_{ROT} 为相应检测阈值。

为与一般的似然比检测器大于阈值时判定为目标的形式相一致, 将(19)式及(20)式的检测器变换为

$$\delta_{\text{MSP}}(\mathbf{x}) = \frac{-1}{Nh_{\text{MSP}}^B} \sum_{i=1}^N \Phi\left(\frac{\mathbf{x} - \mathbf{x}_i}{h_{\text{MSP}}}\right) \begin{cases} \geq \xi_{\text{MSP}}, & \text{target} \\ < \xi_{\text{MSP}}, & \text{background} \end{cases} \quad (21)$$

$$\delta_{\text{ROT}}(\mathbf{x}) = \frac{-1}{Nh_{\text{ROT}}^B} \sum_{i=1}^N \Phi\left(\frac{\mathbf{x} - \mathbf{x}_i}{h_{\text{ROT}}}\right) \begin{cases} \geq \xi_{\text{ROT}}, & \text{target} \\ < \xi_{\text{ROT}}, & \text{background} \end{cases} \quad (22)$$

其中 ξ_{MSP} 和 ξ_{ROT} 为检测阈值, 分别由最低虚警率

$$\int_{\xi_{\text{MSP}}}^{+\infty} f_{\delta_{\text{MSP}}(\mathbf{x})|H_0}(\delta_{\text{MSP}}(\mathbf{x})|H_0) d\delta_{\text{MSP}}(\mathbf{x}) = \alpha_{\text{MSP}}$$

和

$$\int_{\xi_{\text{ROT}}}^{+\infty} f_{\delta_{\text{ROT}}(\mathbf{x})|H_0}(\delta_{\text{ROT}}(\mathbf{x})|H_0) d\delta_{\text{ROT}}(\mathbf{x}) = \alpha_{\text{ROT}}$$

确定, $f_{\delta_{\text{MSP}}(\mathbf{x})|H_0}$ 和 $f_{\delta_{\text{ROT}}(\mathbf{x})|H_0}$ 分别为 δ_{MSP} 和 δ_{ROT} 的检测变换输出对应的概率密度函数。

像段范围 $0.4\sim1.7\mu\text{m}$, 处于可见光和近红外波段, 前 64 个波段光谱范围为 $0.4\sim1.1\mu\text{m}$, 光谱分辨力为 10 nm, 后 16 个波段光谱范围为 $1.06\sim1.7\mu\text{m}$, 光谱分辨力为 40 nm, 图像大小为 $100\text{ pixel}\times100\text{ pixel}$, 原始图像数据灰度阶数 12 bits。图 2 给出了该 80 波段高光谱图像数据的第 5 波段、第 19 波段、第 37 波段和第 78 波段对应的图像, 其中图 2(a)中的两个白色箭头标示出了两个地面车辆目标 t_1 和 t_2 的位置。

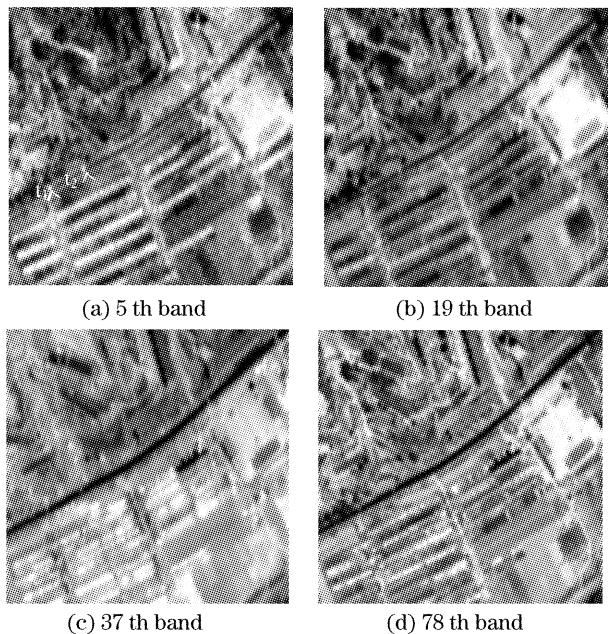


图 2 OMIS-I 不同波段图像

Fig. 2 OMIS-I image of different bands

图 3 是各种算法对 OMIS-I 高光谱图像进行检测得到的结果, 其中图 3(1a)至图 3(5a)是各种算法以最低虚警率检测到目标 t_1 时的结果, 图 3(1b)至图 3(5b)是各种算法以最低虚警率检测到目标 t_2 时的结果。各图具体描述如下, 图 3(1a)和图 3(1b)是使用 RX 检测器运算得到的结果, 其中检测阈值分别为 244.8923 和 244.4946; 图 3(2a)和图 3(2b)是使用均匀目标检测器得到的检测结果, 其中阈值分

5 算法框图

本文的基于单似然检验的检测算法框图如图 1 所示。

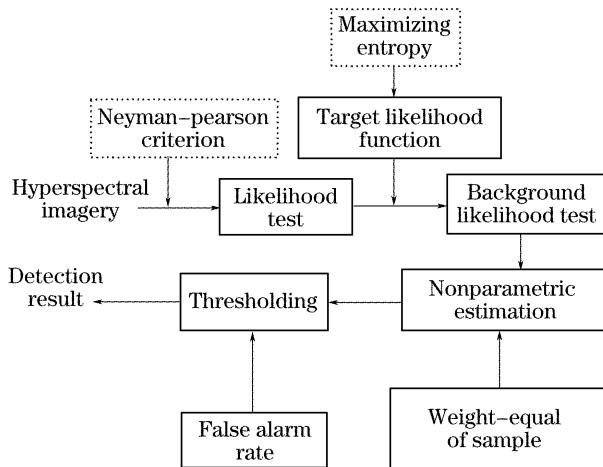


图 1 算法的流程示意图

Fig. 1 Flow chart of this algorithm

6 实验及其分析

实验对象为一套机载 I 型实用型模块化成像光谱仪(OMIS-I)航拍并经辐射定标等处理后得到的高光谱反射率图像数据, 航拍高度为 1200 m 左右, 地面空间分辨力为 3.6 m 左右, 数据共包含 80 个波段, 成

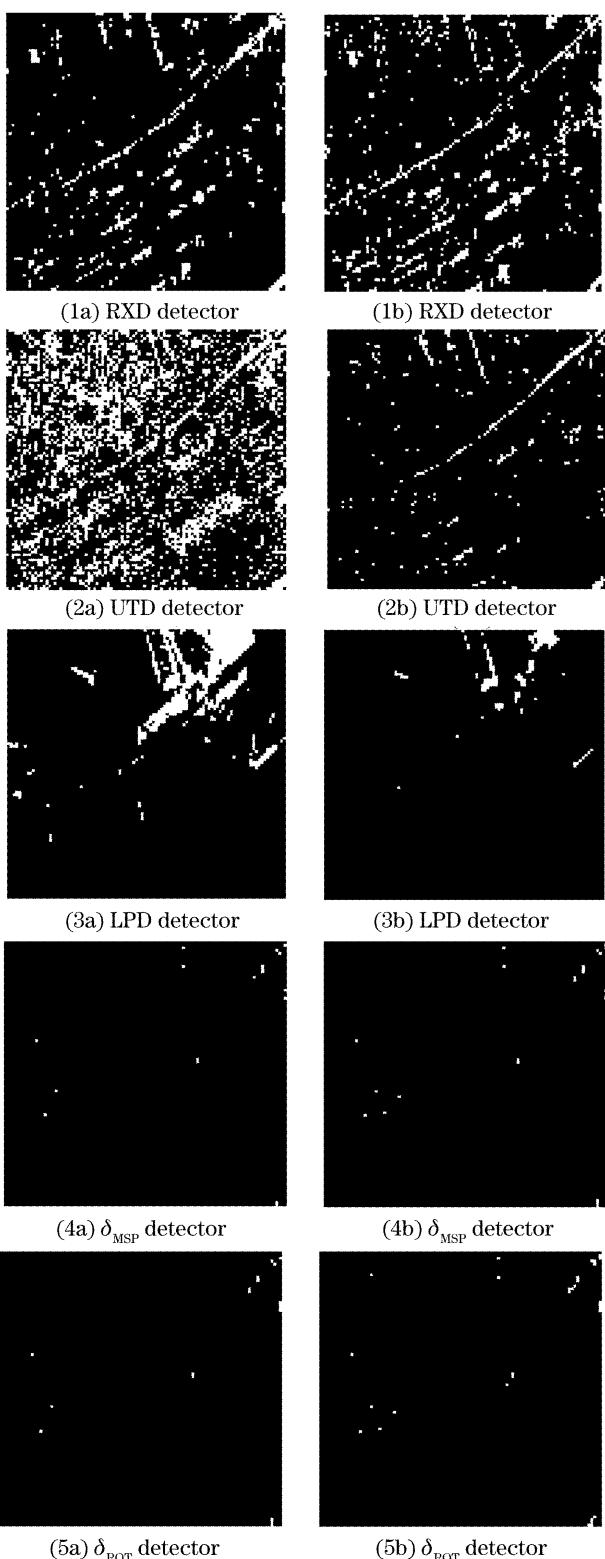


图 3 不同算法的检测结果

Fig. 3 Detection results by different algorithms

别为 3.1676 和 17.9627; 图 3(3a) 和图 3(3b) 是使用低概率检测器并取波段维相关阵主成分方差能量贡献率为 95% 时得到的检测结果, 其中阈值分别为 306.7645 和 375.4578; 图 3(4a) 和图 3(4b) 是使用 Epanechnikov 核的 δ_{MSP} 检测器得到的检测结果, 检

测阈值分别为 8.2160×10^{-182} 和 1.0204×10^{-181} ; 图 3(5a) 和图 3(5b) 是使用 Epanechnikov 核的 δ_{ROT} 检测器得到的检测结果, 检测阈值分别为 1.7244×10^{-156} 和 1.7202×10^{-156} 。

表 1 给出了几种算法分别检测到目标 t_1 和 t_2 时的最低虚警率。从图 3 和表 1 所示的各种算法的检测结果可以看出, 使用 δ_{MSP} 和 δ_{ROT} 检测到目标的最低虚警率明显的低于 RX 检测器、均匀目标检测器、低概率检测器这几种算法检测到目标的最低虚警率。这说明与其它几种算法相比, δ_{MSP} 和 δ_{ROT} 检测器只需很低的虚警率就可以检测到目标。

表 1 几种算法的虚警率(10^{-3})Table 1 False alarm rate of different algorithms (10^{-3})

Detector	t_1	t_2
RXD	90.5	91.2
UTD	308.5	35.3
LPD	69.4	15.3
δ_{MSP}	1.8	2.9
δ_{ROT}	1.7	2.2

为更直观地对各种算法的处理结果进行比较, 图 4(a)~图 4(e) 给出了各算法未经阈值分割得到的高光谱图像数据样本检测变换数值的核密度估计曲线(估计算法使用高斯核和经验法准则)与目标样本检测变换值杆图的合成图。高光谱图像经检测器变换后的输出的概率密度分布由连续曲线表示, 横坐标表示检测变换值(已被规范化到 0~1 之间), 纵坐标表示检测变换值的概率密度, 两个具有圆形和三角形标识的虚杆线分别标出目标 t_1 和 t_2 经检测器变换后的输出值在横轴的位置。当分别取这两个杆线所对应的检测变换值为阈值时, 可实现以最低虚警率恰好检测到目标 t_1 或目标 t_2 。从图 4(a)~图 4(e) 所示各图可看出, δ_{MSP} 和 δ_{ROT} 这两种检测器对应的目标样本检测变换值位于背景检测变换输出值的概率密度分布尾部的较远处, 当取它们为阈值刚好检测到目标时, 产生的虚警数较少, 当所取阈值向左变小时, 在检测到目标的前提下, 这三种算法对应的虚警率增加的速度较慢。对于小目标检测问题, 图 4 中的概率密度曲线可近似视为由背景数据样本的检测变换值估计得到的, δ_{MSP} 和 δ_{ROT} 检测器对应的杆线位置离概率密度曲线的模的位置较远, 这说明经这三种检测器的变换后目标与背景的分离度较大。因此, 图 4 也说明 δ_{MSP} 和 δ_{ROT} 检测器的性能优于其余几种检测器。

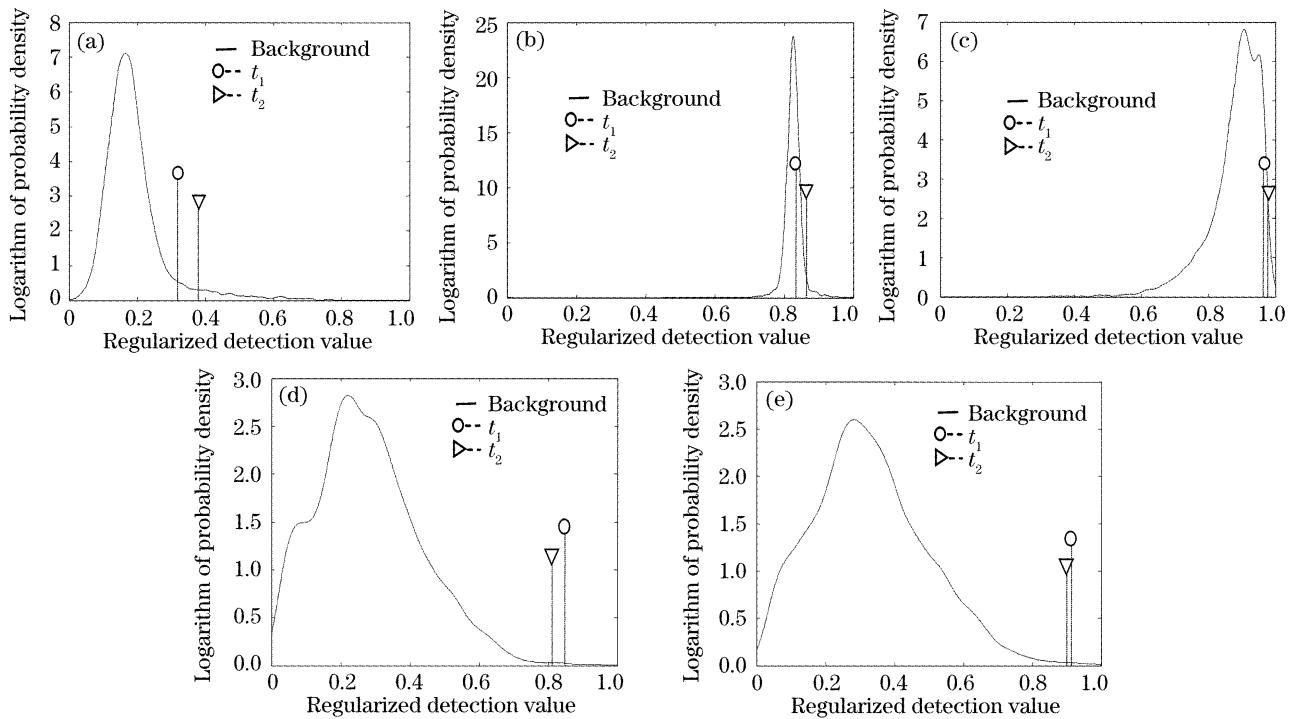


图 4 不同算法的检测值分布

Fig. 4 Distribution of detection value by different algorithm

以上实验中的基于单似然检验的检测器 δ_{MSP} 和 δ_{ROT} 的性能优于RX检测器等算法的原因是：RX检测器以高斯模型为基础，与实际数据之间存在模型误差；均匀目标检测器对均匀分布光谱特征进行匹配，而实际目标光谱特征难以符合这一条件；低概率检测器中提取的主成分以图像数据的全局方差为基础，与实际背景的光谱特征没有直接而确切的对应关系，这些因素的影响使得它们的检测效果较差。本文的基于单似然检验的检测器利用目标的空间低概率特性，通过最大熵定理将Neyman-Pearson准则下的广义似然比检验简化为对原假设下背景似然的单似然检验，并使用无参估计模型对该背景似然进行估计，更有效和充分地利用了高光谱图像数据样本所提供的信息，减小了参量化统计模型误差带来的影响且具有明确的物理含义。

7 结 论

在背景和目标先验光谱特征未知条件下对高光谱图像低概率小目标进行检测时，目标的空间低概率性使得高光谱图像数据样本难以对目标数据统计模型施加约束，在最大熵条件下利用目标样本矩特征的零约束估计得到目标统计模型，将广义似然比检验简化为对于背景似然的单似然检验；根据目标的空间低概率性，还可将高光谱图像量测数据全部视为来自背景总体，利用全部观测样本构造无参

估计模型构造出基于单似然检验的检测器。本文算法充分利用了高光谱图像数据样本提供的统计信息，避免了参量化模型误差并具有明确的物理含义，理论分析和实验结果都表明本文算法优于常用的RX检测器、均匀目标检测、低概率检测算法。

本文算法也有一些问题需要注意。由于算法以目标的空间低概率特性为前提条件，适合于检测稀疏分布的小目标，对于大量出现的目标及面积较大的目标，其检测效果会受到影响；由于算法本质上是一种异常检测，没有利用目标的先验光谱特征进行匹配，如果因成像传感器等原因在高光谱图像中出现突变的异常噪声点或是坏点，检测器可能将其误判为小目标。

参 考 文 献

- 1 David Landgrebe. Hyperspectral image data analysis[J]. *IEEE Signal Processing Magazine*, 2002, 19(1): 17~28
- 2 Zhao Jiewen, Zhang Haidong, Liu Muhua. Preprocessing methods of near-infrared spectra for simplifying prediction model of sugar content of apples[J]. *Acta Optica Sinica*, 2006, 26(1): 136~140 (in Chinese)
- 3 S. M. Bergman. The utility of hyperspectral data to detect and discriminate actual and decoy target vehicles[R]. AD report A327453, 1996
- 4 D. Stein, Jon Schoonmaker, Eric Coolbaugh. Hyperspectral imaging for intelligence, surveillance, and reconnaissance[R]. AD report A434124, 2001
- 5 Capt Peterson Erin D. Surface and buried landmine scene

- generation and validation using the digital imaging and remote sensing image generation (DIRSIG) model [R]. AD report A424769, 2004
- 6 Office of the Secretary of Defense, U. S. Department of Defense. Unmanned Aircraft Systems Roadmap 2005~2030[R]. 2005. 47~59
- 7 X. L. Yu, I. S. Reed, A. D. Stocker. Comparative performance analysis of adaptive multispectral detectors [J]. *IEEE Transactions on Signal Processing*, 1993, **41**(8): 2639~2656
- 8 He Lin, Pan Quan, Zhao Yongqiang et al.. Anomaly detection in hyperspectral imagery based on feature fusion of band subsets [J]. *Acta Photonica Sinica*, 2005, **34**(11): 1752~1755 (in Chinese)
贺霖,潘泉,赵永强等. 基于波段子集特征融合的高光谱图像异常检测[J]. 光子学报, 2005, 34(11): 1752~1755
- 9 C. I. Chang, S. S. Chiang. Anomaly detection and classification for hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2002, **40**(6): 1314~1325
- 10 Chein-I Chang, Shao-Shan Chiang, Irving W. Ginsberg. Anomaly detection in hyperspectral imagery[C]. *Proc. SPIE*, 2001, **4383**: 43~50
- 11 He Lin, Pan Quan, Zhao Yongqiang et al.. An automatic target detection algorithm for hyperspectral imagery based on feature-level fusion[C]. *Proc. SPIE*, 2005, **6043**: 164~169
- 12 He Lin, Pan Quan, Zhao Yongqiang et al.. CFAR target detection in unkown background based on subspace projection in aerial hyperspectral imagery [J]. *Acta Aeronautica et Astronautica Sinica*, 2006, **27**(4): 657~662 (in Chinese)
贺霖,潘泉,赵永强等. 基于子空间投影的未知背景航拍高光谱图像恒虚警目标检测[J]. 航空学报, 2006, 27(4): 657~662
- 13 He Lin, Pan Quan, Zhao Yongqiang. Target detection in hyperspectral imagery based on linear mixing model reconstructed from measurements[J]. *Acta Electronica Sinica*, 2007, **35**(1): 23~27 (in Chinese)
贺霖,潘泉,赵永强. 量测重构线性混合模型高光谱图像目标检测[J]. 电子学报, 2007, 35(1): 23~27
- 14 T. M. Cover, J. A. Thomas. *Elements of Information Theory* [M]. New York: Wiley-Interscience Press, 1991. 266~278
- 15 Guo Haitao, Tian Tan, Wang Lianyu et al.. Image segmentation using the maximum entropy of the two dimensional bound histogram[J]. *Acta Optica Sinica*, 2006, **26**(4): 506~509 (in Chinese)
郭海涛,田坦,王连玉等. 利用二维属性直方图的最大熵的图像分割方法[J]. 光学学报, 2006, 26(4): 506~509
- 16 David B. Marden, Dimitris Manolakis. Modeling hyperspectral imaging data[C]. *Proc. SPIE*, 2003, **5093**: 253~262
- 17 Dimitris Manolakis, David Marden, John Kerekes et al.. On the statistics of hyperspectral imaging data[C]. *Proc. SPIE*, 2001, **4381**: 308~316
- 18 D. W. Scott. Multivariate density estimation and visualization. <http://www.stat.rice.edu/~scottdw/multidens.ps>
- 19 B. A. Turlach. Bandwidth selection in kernel density estimation: A review. <http://citeseer.ist.psu.edu/214125.html>