

文章编号: 1001 - 9014 (2010) 02 - 0150 - 06

# 利用背景残差数据检测高光谱图像异常

李杰<sup>1</sup>, 赵春晖<sup>2</sup>, 梅锋<sup>2</sup>

(1. 北京理工大学 机电学院, 北京 100081; 2. 哈尔滨工程大学 信息与通信工程学院, 黑龙江 哈尔滨 150001)

**摘要:** 针对高光谱图像微小目标检测中存在的严重背景干扰问题, 提出了一种基于背景残差数据的非线性异常检测算法. 首先利用提取的背景光谱端元对图像各像元进行光谱解混, 实现了目标信息和复杂背景信息的分离; 接着将含有丰富目标信息的解混残差数据非线性映射到高维特征空间, 可以充分挖掘高光谱图像波段间隐含的非线性信息, 并在特征空间利用 RX 算子完成目标的检测, 从而在抑制大概率背景信息的基础上有效地利用了高光谱图像波段间的非线性统计特性. 为了验证算法的有效性, 利用真实的 AVIRIS 数据进行了实验研究, 并与经典 RX 算法、未抑制背景的特征空间核 RX 算法的检测结果相比较, 结果表明基于背景残差数据的检测算法具有良好的检测性能和较低的虚警, 且运算复杂度较低.

**关键词:** 高光谱图像; 异常检测; 光谱解混

**中图分类号:** TN911.73 **文献标识码:** A

## DETECTING HYPERSPECTRAL ANOMALY BY USING BACKGROUND RESIDUAL ERROR DATA

LI Jie<sup>1</sup>, ZHAO Chun-Hui<sup>2</sup>, MEI Feng<sup>2</sup>

(1. College of Mechanical and Electrical, Beijing Institute of Technology, Beijing 100081, China;

2. College of Information and Communication, Harbin Engineering University, Harbin 150001, China)

**Abstract:** In order to overcome the serious background interferences for small target detection of hyperspectral imagery, a nonlinear anomaly detection algorithm based on background residual error data was proposed. After the background endmembers were extracted, spectral unmixing technique was applied to all mixed spectral pixels to separate target information from complicated background clutter. Then, the unmixing residual error data that included abundant target information was mapped into a high-dimensional feature space by a nonlinear mapping function. Nonlinear information between the spectral bands of hyperspectral imagery was exploited and the anomaly targets could be detected by using RX operator in the feature space. Thus, the nonlinear statistical characteristics between the hyperspectral bands were used effectively on the basis of suppressing the large probability background information. Numerical experiments were conducted on real AVIRIS data to validate the effectiveness of the proposed algorithm. The detection results were compared with those detected by the classical RX algorithm and KRX which did not suppress the background information. The results show that the proposed algorithm has better detection performance, lower false alarm probability and lower computational complexity than other detection algorithms.

**Key words:** hyperspectral imagery; anomaly detection; spectral unmixing

### 引言

利用高光谱图像进行目标检测与识别是遥感图像处理领域的研究热点之一. 高光谱图像具有极高的光谱分辨率, 它能够借助丰富的光谱信息, 反映目标间的细微差异, 从而发现用纹理、边缘等空间特征无法或难以探测的地面目标. 传统的目标检测算法

一般是在假设数据服从某种统计或几何模型的基础上构造检测算子, 并根据先验信息估计算子中的统计参量, 如光谱匹配算法<sup>[1]</sup>、正交子空间算法<sup>[2]</sup>等. 然而, 在实际应用中, 由于缺少完备的光谱数据库和准确的反射率反演算法使得目标的先验光谱信息的获得变得非常困难, 因此, 不需目标先验信息的异常检测算法更符合实际需求, 逐渐成为研究的热

收稿日期: 2009 - 01 - 14, 修回日期: 2009 - 02 - 25

Received date: 2009 - 01 - 14, revised date: 2009 - 02 - 25

基金项目: 高等学校博士学科点基金 (20060217021); 黑龙江省自然科学基金重点项目资助 (ZJG0606-01)

作者简介: 李杰 (1969-), 男, 湖北人, 博士, 副教授, 从事信号与信息处理、目标检测与模式识别等方面研究. E-mail: lijie@bit.edu.cn

通讯作者: 赵春晖, E-mail: zhaochunhui@hrbeu.edu.cn

点<sup>[3-7]</sup>. Schweizer等人利用高斯马尔科夫模型来模拟数据的统计分布<sup>[8]</sup>,进行异常检测.该方法综合了光谱信息和几何信息,是一种非线性的处理方法,但高斯马尔科夫随机场无法对较小空间尺寸的区域进行描述,无法较好地检测仅占几个像素的微小异常目标,且统计模型参数的估计比较复杂. Kwon等人将经典RX异常检测算法<sup>[9]</sup>与核机器理论相结合,提出了基于核函数的非线性RX改进算法<sup>[10]</sup>,该算法将光谱信号映射到高维特征空间后利用核函数的性质进行异常点的检测,较好地利用了高光谱图像波段间的非线性统计特性,但其忽略了因低空间分辨率造成的混合像素给目标检测带来的严重的背景干扰.而本文把背景抑制和高光谱图像波段间的高维统计特性综合起来考虑,提出了一种基于背景残差数据的非线性异常检测算法.利用所提取的背景光谱端元和光谱解混技术得到高光谱图像中各像元所含背景端元的混合系数向量后,将背景信息从原始高光谱图像中去除得到含丰富目标信息的背景残差数据,进而将残差数据映射到高维特征空间以完成微小目标的异常检测,这样不仅不需要对高光谱数据进行特征提取,而且可以充分发掘高光谱图像波段间隐含的非线性信息.通过真实的AVRIS数据实验验证了该算法的有效性.

## 1 基于背景残差数据的目标检测算法

高光谱图像虽然具有极高的光谱分辨率,但其空间分辨率是有限的,因而在一个瞬时视场中往往包含几种不同的地物,也就是存在光谱混合现象.不同类别背景和异常目标的光谱混合使得目标在图像中呈现亚像素态,几乎无法辨识,使得简单的多元高斯统计模型不能较好地描述数据的分布状态,降低了已有目标检测算法的性能.实际情形下对异常目标的伪装、遮蔽等处理也可以看作是背景干扰.有效地去除背景干扰,将目标信息从光谱图像中分离出来,对高光谱图像的后续处理是非常有利的.

在高光谱图像处理中,光谱解混技术可用来预测像元内包含目标的比例成分.在线性混合模型的求解过程中需要事先已知或者通过端元提取方法获得物质光谱信息.高光谱图像中异常小目标由于其亚像素特性使得目标光谱信息难以获取,而数目众多的背景光谱则很容易通过端元提取获得,因此对背景类别的解混不仅较易实现,而且能够获得精确的结果.这样,可以认为解混后去除背景信息的残差数据中含有丰富的目标信息,可在背景残差数据上

进行目标的异常检测.

### 1.1 线性光谱解混

线性混合模型是混合像元分解中常用的数据模型,定义为:像元在某一波段的反射率是由构成像元的端元的反射率以其所占像元面积比例为权重系数的线性组合.一个像元矢量的光谱信号用线性混合模型描述为

$$x = Sa + w \quad (1)$$

其中, $x$ 是一个 $L$ ( $L$ 代表高光谱图像的波段数)维的观测光谱列向量; $S = [s_1, s_2, \dots, s_p]$ 是一个 $L \times p$ ( $p$ 为端元数)的矩阵,它的每一列代表着一个纯地物端元的光谱向量 $s_i$ ; $a = [a_1, a_2, \dots, a_p]$ 是 $p$ 维的混合系数向量,描述了各个纯地物端元在某个像元中的混合比例; $w$ 是 $L$ 维存在于像元 $x$ 各个谱段中的噪声向量.对于图像数据中的 $N$ 个像元向量,式(1)的矩阵形式为:

$$X = SA + W \quad (2)$$

其中, $X = [x_1, x_2, \dots, x_N]$ , $A = [a_1, a_2, \dots, a_p]$ , $W = [w_1, w_2, \dots, w_N]$ .

在线性混合模型中,端元和混合系数是主要的未知参数,利用端元提取方法从图像数据中得到端元光谱 $S$ ,接着估计出混合系数向量 $a$ ,计算的结果表现为各端元的分量值和以均方根误差表示的残余误差图像.两个未知参数中混合系数 $a$ 的求解比较简单,通常采用最小二乘原理进行估计求解<sup>[11]</sup>.假如附加噪声向量为零且波段数大于端元数,则 $a$ 的非限制性最小二乘估计为:

$$\hat{a} = (S^T S)^{-1} S^T x \quad (3)$$

式中,上标 $T$ 和 $-1$ 分别代表矩阵转置和矩阵求逆.在实际环境中,为保证获得的比例具有一定的物理意义,通常给混和系数 $a$ 加上两个约束条件,分别是非负性约束条件 $a_i \geq 0$ ( $i = 1, 2, \dots, p$ )和归一化约束条件 $\sum a_i = 1$ .它们的物理意义十分明显:一是光谱是一种能量,不可能存在负值;二是混合能量的大小是限定的,不可能无限大.

相对于混合系数 $a$ 的求解,线性光谱解混中所需的背景光谱端元 $S$ 的提取则显得复杂一些.考虑到这里仅需对背景类别进行线性解混,且背景具有数目众多、分布面积较大的特点,本文设计了一种以光谱相似度为判决准则的分块端元快速提取方法.具体步骤为:

a) 对高光谱图像进行分块处理,将其划分为 $k$ 个大小为 $m \times n$ 的子块,分块的尺寸可根据图像的空间分辨率和检测目标大小进行设定.

b) 计算各个子块中光谱向量的均值. 均值向量由两部分组成: 一部分是背景地物光谱向量  $b$ , 另一部分是目标光谱向量  $t$ . 设某个子块的光谱向量均值为  $\mu$ , 则  $\mu$  可以写为:

$$\mu = \frac{N_1}{N_1+N_2+N_3} x_i / N_1 = \frac{N_2}{N_1+N_2+N_3} b_i / N_1 + \frac{N_3}{N_1+N_2+N_3} t_i / N_1, \quad (4)$$

式中,  $N_1 = m \times n$ ,  $N_2 = N_3$ . 高光谱图像中目标数  $N_3$  较少,  $N_3 / N_1$  的值与零非常接近, 所以目标像元对子块均值光谱向量  $\mu$  的贡献极小, 可合理地假设它是一个较小的误差数据. 这个误差数据对均值光谱向量曲线的形状影响微弱, 也就是均值光谱曲线与背景地物的光谱曲线在形状上是极其相似的.

c) 以子块为处理单元, 计算子块中各光谱向量与均值向量的相似度, 采用的相似度计算公式为:

$$(\mu, x_i) = \cos^{-1} [(\mu \cdot x_i) / (\|\mu\| \cdot \|x_i\|)]. \quad (5)$$

d) 设置相似度阈值  $\theta_1$ , 并计算子块中相似度小于阈值  $\theta_1$  的光谱向量的能量 (光谱向量中像素值的平方和), 选取其中能量最大的光谱向量作为该子块的背景端元, 目的是为了减弱同种地物光谱能量差异 (阴影等自然因素引起的光照不均造成的) 对均值向量的影响, 更好地满足混合系数  $a$  的两个约束条件.

e) 对提取出来的  $k$  个子块的背景端元进行再一次相似度计算和能量计算, 将相似度和能量均相近的归为同一类背景地物, 选择其中能量最大的作为该类背景地物的最终光谱端元, 其中分类时的相似度阈值  $\theta_2$  应远小于  $\theta_1$ .

## 1.2 非线性异常检测算法

在光谱解混之后, 将背景信息从原始高光谱图像中去除, 得到的是含有丰富目标信息的背景残差数据. 传统的异常目标检测算法大多是线性的, 忽视了高光谱图像波段之间很强的相关特性; 这些算法在目标检测之前需要依据某种准则对高光谱数据 (这里是背景残差数据) 进行特征选择或特征提取来降低高光谱图像的维数, 大大增加了算法的运算量. 本文算法将背景误差数映射到高维特征空间后, 采用文献 [10] 中的非线性核 RX 算法 (KRX 算法) 来完成异常目标检测, 不仅有效地利用了高光谱图像波段间的高阶统计特性和非线性信息, 而且避免了对高维数据的特征提取, 从而降低了算法的复杂度.

传统的 RX 算法起源于多光谱图像异常检测, 本质上可以看作主成分分析 (PCA) 的逆过程. RX 算法以图像中的每个像素为检测中心, 确定局部检

测窗口, 并建立二值假设:  $H_0$  代表目标不存在、 $H_1$  代表目标存在.

$$H_0: x = n \quad H_1: x = at + n, \quad (6)$$

式中,  $a > 0$ ,  $n$  和  $t$  分别表示背景噪声向量和目标光谱信号. 进一步假定两种情况下数据分布具有相同的协方差和不同的均值, 分别服从高斯分布  $N(\mu_b, C_b)$  和  $N(\mu_s, C_s)$ , 其中  $\mu_b$ 、 $\mu_s$  分别为局部检测窗口内的背景均值和异常目标均值,  $C_b$  为背景协方差. RX 算子简化的判决表达式为

$$RX(r) = (r - \hat{\mu}_b)^T \hat{C}_b^{-1} (r - \hat{\mu}_b) \underset{H_0}{\overset{H_1}{>}} \tau, \quad (7)$$

向量  $r$  为待检测光谱信号,  $\hat{\mu}_b$ 、 $\hat{C}_b$  分别为背景均值和协方差矩阵的估计值,  $\tau$  为判决阈值.

非线性核 RX 算法 (KRX 算法) 就是特征空间的 RX 算法. 在利用非线性映射函数  $\phi$  将局部检测窗口的  $N$  个光谱向量矩阵  $X_b = [x_1, x_2, \dots, x_N]$  映射到高维特征空间得  $(X_b) = [\phi(x_1), \phi(x_2), \dots, \phi(x_N)]$  后, 相应的特征空间中 RX 算法的表达式为:

$$KRX(r) = (r - \hat{\mu}_b)^T \hat{C}_b^{-1} (r - \hat{\mu}_b), \quad (8)$$

式中,  $\hat{C}_b$  和  $\hat{\mu}_b$  为特征空间背景协方差矩阵和均值向量的估计值, 它们的表达式为:

$$\hat{C}_b = \frac{1}{N} \sum_{i=1}^N (\phi(x_i) - \hat{\mu}_b)(\phi(x_i) - \hat{\mu}_b)^T, \quad (9)$$

$$\hat{\mu}_b = \frac{1}{N} \sum_{i=1}^N \phi(x_i). \quad (10)$$

由于非线性映射函数  $\phi$  未知, 所以无法直接在特征空间进行数据运算, 需借助核函数理论对式 (8) 进行变形, 即利用核函数性质:

$$k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j). \quad (11)$$

将高维特征空间的内积运算转化为低维输入空间的核函数计算, 最终得到特征空间 RX 算法的核函数表达式为:

$$KRX(r) = (K_r^T - K_b^T)^T K_b^{-1} (K_r^T - K_b^T), \quad (12)$$

式中特征空间数据的中心化 Gram 核矩阵  $K_b$  可借助原始输入空间数据的核矩阵  $K$  ( $K_{ij} = k(x_i, x_j)$ ) 表示为

$$K_b = K - \mathbf{1}_N K - K \mathbf{1}_N + \mathbf{1}_N K \mathbf{1}_N, \quad (13)$$

其中,  $\mathbf{1}_N$  为  $N \times N$  维的矩阵, 其元素均为  $1/N$ . 另外矩阵  $K$  和  $K_b$  的核函数表达式为

$$K_r^T = (k(x_1, r), k(x_2, r), \dots, k(x_N, r)) - \frac{1}{N} \sum_{i=1}^N k(x_i, r), \quad (14)$$

$$K_b^T = \frac{1}{N} \sum_{i=1}^N (k(x_i, x_1), k(x_i, x_2), \dots, k(x_i, x_N)) - \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^N k(x_i, x_j) / N^2, \quad (15)$$

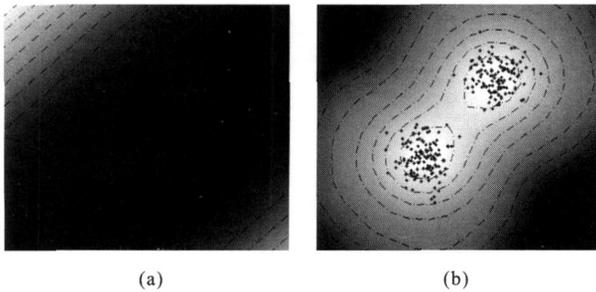


图1 高斯数据下两种算法输出等高线图 (a)RX (b) KRX  
Fig.1 Contour plots of two algorithms for Gaussian data (a) RX (b) KRX

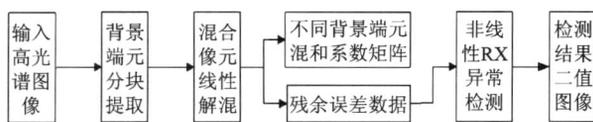


图2 算法流程图  
Fig.2 Flow chart of the proposed algorithm

因此只需选择一个合适的核函数,就可在映射函数未知的情况下进行高维特征空间数据的计算.图1给出了两高斯分布合成数据下 KRX算法和传统多光谱 RX算法的输出等高线(代表不同阈值下的决策边界)图,从图中可以看出 KRX算法较 RX算法有更好的区分识别能力.

在利用非线性 RX检测算子求得各像素点在特征空间的投影向量的检测值之后,输出的是一副灰度图像.为了利于检测结果的判读,利用阈值分割法将灰度图像转化为二值图像,其中白色像素点对应的是可能存在的目标物.图2给出了本文算法的流程图.

## 2 实验与结果分析

为了检测所提算法的有效性,利用真实 AVIRIS 高光谱数据进行了仿真实验.该图像是美国圣地亚哥机场的一部分,去掉噪声和水汽吸收较明显的波段,选取了126个波段作为研究对象.截取的各波段图像大小为  $100 \times 100$ ,含有38个待检测目标.其第1波段图像及真实目标分布如图3所示.

线性光谱解混前,利用提出的分块端元快速提取方法进行背景端元的提取,提取时根据图像的空间分辨率和检测目标尺寸将图像分成16个  $25 \times 25$  的子块,并设置相似度阈值  $\gamma_1$  为0.3,  $\gamma_2$  为0.01,最终提取出的四类背景端元曲线如图4所示.

利用所提取的背景端元反解出各像元的混合系数后,将背景信息从原始高光谱图像中去除,得到残

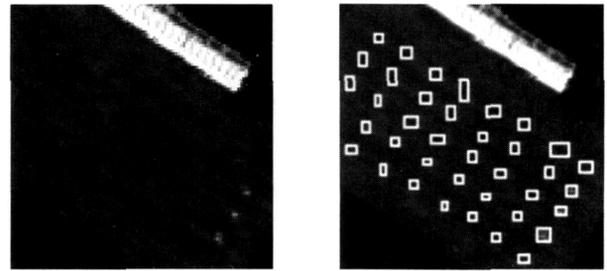


图3 高光谱第1波段图像及相应的目标分布  
Fig.3 The hyperspectral imagery of first band and the corresponding distribution of targets

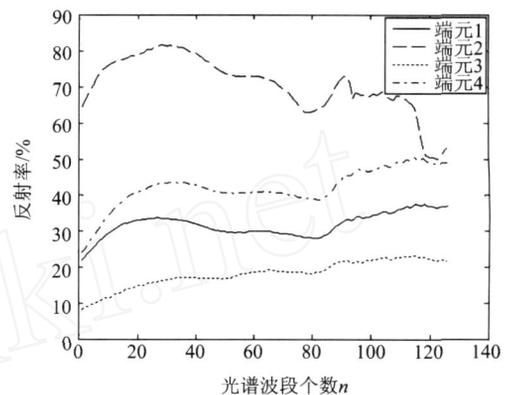


图4 背景端元光谱曲线  
Fig.4 Spectral profile of background endmembers

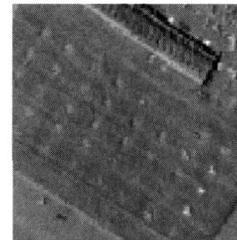


图5 高光谱第1波段的误差图像  
Fig.5 First band of hyperspectral error imagery

余残差数据.图5所示的就是原始高光谱图像第1波段的背景残差数据图像.

高光谱图像微小目标的异常检测是在归一化的背景残差数据上进行的.实验中,依据图像的空间大小和分辨率,将 KRX算法的检测窗口设为  $11 \times 11$  像素,目标检测窗口设为  $3 \times 3$  像素.核函数采用径向基核函数,其表达形式如下:

$$k(x, y) = \exp\left[-\frac{\|x - y\|^2}{c}\right], \quad (16)$$

上式中,径向基核函数的宽度  $c$  的选择至关重要,根据多次实验将所使用的径向基核函数的宽度  $c$  设为40.图6给出了不同算法的检测结果二值图像,除本

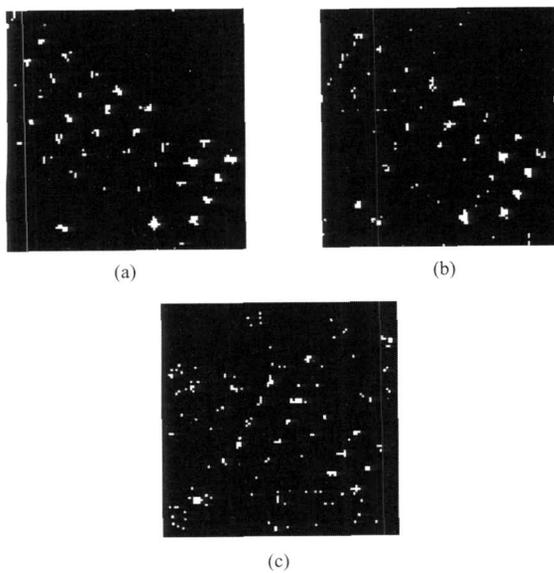


图 6 3种方法下的阈值分割图 (a)本文算法 (b) KRX (c) RX

Fig 6 Detection results of three methods after thresholding (a) the proposed algorithm (b) KRX (c) RX

文算法(记为 WRX 算法)外,实验中也利用传统的多光谱 RX 算法、非线性 KRX 算法对目标进行了检测。

由图 6 可看出,本文算法所获得的检测结果要好于其它两种算法,由于 RX 算法起源于多光谱图像检测,将它直接用于高光谱图像则忽略了高光谱图像波段间很强的相关特性,产生较多虚警。KRX 算法和 WRX 算法虽然都利用了光谱波段间蕴含的高阶统计特性,但 WRX 算法能够很好地抑制背景信息干扰,因而在检测目标数目相同的情况下,WRX 算法有更低的虚警。

为了更形象说明 WRX 算法的优越性,以高光谱图像检测到的目标个数、目标所占像素数、虚警个数和虚警所占像素数为指标对 KRX 算法和 WRX 算法进行比较。WRX 算法检测到 34 个真实异常目标(占有 181 个像素)和 4 个虚警(占有 19 个像素);KRX 算法虽然也检测到了 34 个真实异常目标(占有 169 个像素),但虚警数目相对较多,为 13 个(占有 31 个像素)。这些数据充分说明,WRX 算法在有效利用高光谱图像非线性信息的同时很好地抑制了复杂背景信息的干扰,从而提高了目标检测的性能,降低了检测的虚警概率。

接收机操作特性(ROC)用于描述检测概率  $P_d$  与虚警概率  $P_f$  之间的变化关系,能够提供算法检测性能的定量分析。根据地面真实图可以获得每个目

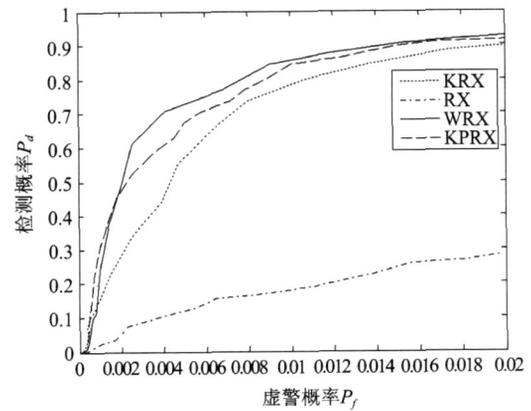


图 7 4种算法的 ROC 比较

Fig 7 ROC comparison of four algorithms

标所包含的像素区域坐标,通过考察检测到的异常点是否落入真实图的目标区域可以来判定检测到的是真实目标还是虚警。将检测概率定义为检测到的真实目标像素数目与地面真实目标像素数目的比值;虚警概率定义为检测到的虚警像素数目同整幅图像像素数目总和的比值。图 7 给出了 WRX 算法、KRX 算法、RX 算法和文献<sup>[8]</sup>中异常检测算法(记为 KPRX 算法)的 ROC 特性的比较,可以看出,WRX 算法有效地改进了传统 RX 算法的性能,在抑制大概率复杂背景的同时突出了小概率目标,因而虚警概率较 RX 算法和 KRX 算法低。对于 KPRX 算法,由于它也是利用解混后的残差数据和图像波段间的非线性信息进行异常检测,因而检测性能与 WRX 算法相当,但 KPRX 算法利用核主成分分析(KPCA)对背景残差数据进行特征提取,其计算量较大,耗费时间较长,并且对进行矩阵运算的计算机性能要求较高。对于一幅含  $L$  个波段,大小为  $a \times b$  的高光谱图像,在 KPCA 运算中,生成的核矩阵将含有  $(a \times b) \times (a \times b)$  个像素,也就是说对于一幅大小为  $100 \times 100$  的高光谱图像,在 KPCA 运算中至少需要 0.8G 的内存来存储核矩阵(矩阵中每个像素至少以 8 位表示,则内存需求量为  $8 \times 10000 \times 10000$ )。另外在对核矩阵的中心化和特征分解过程中生成的矩阵也与核矩阵大小一样,普通的计算机无法进行如此大规模数据量的运算,而且随着图像像元个数的增大,内存的需求量将以图像像元个数的平方形式增加。本文算法在将高维空间的内积运算转化为低维空间的核函数运算时,生成的核矩阵为  $L \times L$ ,仅与高光谱图像的波段数有关,与图像的像元个数毫无关系,而高光谱图像的波段数与图像所含的像元个数相比相差非常大,运算中所需的计算机内存是有

限的,很大程度上降低了算法的复杂度和运行时间.

### 3 结论

本文提出了一种基于背景残差数据的非线性微小目标检测算法,对高光谱数据进行处理取得了较好的结果.该方法有效地将背景光谱信息和目标光谱信息分离,很好地抑制了背景干扰,充分挖掘了高光谱图像波段间的非线性信息,具有较好的检测性能和较低的虚警概率.由于只需对背景端元进行提取,使得端元提取算法的复杂度大大降低,采用分块端元快速提取算法进一步减少了端元提取中的运算量.通过与其它目标检测算法的比较,可以看出本文算法不仅目标检测性能较好,而且结构简单,计算量相对较少,对硬件系统的要求较低,便于实现.

### REFERENCES

- [1] Thai B, Healey G. Invariant subpixel target identification in hyperspectral imagery[C]//*Anon. Algorithms for Multispectral and Hyperspectral Imagery V*. Orlando, FL, USA: SPIE-Int Soc Opt Eng, 1999. 14—24.
- [2] Harsanyi J C, Chang C I. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection[J]. *IEEE Trans on Geoscience and Remote Sensing* 1994, **32**(4): 779—785.
- [3] Shaw G, Mankolakis D. Signal processing for hyperspectral image exploitation[J]. *IEEE Signal Processing Magazine*, 2002, **19**(1): 12—16.
- [4] HE Lin, PAN Quan, DI Wei. Multicategory targets detection of hyperspectral imagery based on adaptive structured background and shape-feature subspace[J]. *J. Infrared Millim. Waves* (贺霖,潘泉,邸韡.自适应结构化背景和形状特征子空间高光谱图像多类目标检测.红外与毫米波学报), 2007, **26**(5): 353—358.
- [5] ZHANG Bing, CHEN Zheng-Chao, ZHENG Lan-Fen, et al. Object detection based on feature extraction from hyperspectral imagery and convex cone projection transform[J]. *J. Infrared Millim. Waves* (张兵,陈正超,郑兰芬,等.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.红外与毫米波学报), 2004, **23**(6): 441—445.
- [6] LI Zhi-Yong, KUANG Gang-Yao, YU Wen-Xian, et al. Algorithm on small target detection base on principal component of hyperspectral imagery[J]. *J. Infrared Millim. Waves* (李智勇,匡纲要,郁文贤,等.基于高光谱图像主成分分量的小目标检测算法研究.红外与毫米波学报), 2004, **23**(4): 286—290.
- [7] GU Yan-Feng, LU Ying, JIA You-Hua, et al. Anomaly detection algorithm of hyperspectral images based on spectral analyses[J]. *J. Infrared Millim. Waves* (谷延锋,刘颖,贾友华,等.基于光谱解译的高光谱图像奇异检测算法.红外与毫米波学报), 2006, **25**(6): 473—477.
- [8] Schweizer S M, Moura J M F. Efficient detection in hyperspectral imagery[J]. *IEEE Trans On Image Processing* 2001, **10**(4): 584—597.
- [9] Reed IS, Yu X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution[J]. *IEEE Trans Acoust, Speech Signal Process* 1990, **38**(10): 1760—1770.
- [10] Kwon H, Nasrabadi N M. Kernel RX-Algorithm: A nonlinear anomaly detector for hyperspectral imagery[J]. *IEEE Trans Geoscience and Remote Sensing* 2005, **43**(2): 388—397.
- [11] Keshave N, Mustard J F. Spectral unmixing[J]. *IEEE Signal Processing Magazine* 2002, **19**(1): 44—57.
- [10] Nencini F, Garzelli A, Baronti S, et al. Remote sensing image fusion using the curvelet transform[J]. *Information Fusion*, 2007, **8**(2): 143—156.
- [11] Ranchin T, Wald L. Fusion of high spatial and spectral resolution images: the ARSIS concept and its implementation[J]. *Photogrammetric Engineering and Remote Sensing*, 2000, **66**(1): 49—61.
- [12] Wang Z, Ziou D, Amenakis C, et al. A comparative analysis of image fusion methods[J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2005, **43**(6): 1391—1402.
- [13] Dou W, Chen Y H, Li X B, et al. A general framework for component substitution image fusion: An implementation using the fast image fusion method[J]. *Computers and Geosciences*, 2007, **33**(2): 219—228.
- [14] DOU Wen. Research on the Universal Theoretical Framework for Multi-source Remotely Sensed Data Fusion[D]. Beijing: Beijing Normal University, 2006 (窦闻.多源遥感数据像素级融合统一理论框架研究[D].北京:北京师范大学, 2006).
- [15] Otazu X, Gonzalez-Audicana M, Fors O, et al. Introduction of sensor spectral response into image fusion methods: Application to wavelet-based methods[J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2005, **43**(10): 2376—2385.
- [16] DOU Wen, CHEN Yun-Hao, HE Hui-Ming. Theoretical Framework of Optical Remotely Sensed Image Fusion[J]. *Acta Geodaetica et Cartographica Sinica* (窦闻,陈云浩,何辉明.光学遥感影像像素级融合的理论框架.测绘学报), 2009, **38**(2): 131—137.
- [17] Wald L, Ranchin T, Mangolini M. Fusion of satellite images of different spatial resolutions: Assessing the quality of resulting images[J]. *Photogrammetric Engineering and Remote Sensing*, 1997, **63**(6): 691—699.
- [18] Aiazzi B, Alparone L, Baronti S, et al. MTF-tailored multiscale fusion of high-resolution MS and pan imagery[J]. *Photogrammetric engineering and remote sensing*, 2006, **72**(5): 591—596.
- [19] Wang Z, Bovik A. A universal image quality index[J]. *IEEE Signal Processing Letters*, 2002, **9**(3): 81—84.

(上接 144页)