

doi:10.3788/gzxb20134208.0883

一种基于核特征空间的鲁棒性高光谱异常探测方法

赵锐^a, 杜博^b, 张良培^a

(武汉大学 a. 测绘遥感信息工程国家重点实验室; b. 计算机学院, 武汉 430079)

摘 要:传统高光谱异常探测器的背景统计信息易受异常目标干扰,鲁棒性较差,且难以探测非线性混合的异常目标.针对此问题,运用核特征投影理论,在异常探测器的背景信息构建中引入鲁棒性分析方法,提出了一种在核特征空间中具有鲁棒性的异常探测方法.该方法可以在不需要确定具体的非线性映射函数下,将高光谱数据从低维空间映射到高维特征空间,背景和异常目标在特征空间中可以用线性模型表示,并在特征空间中构造鲁棒性的探测器.该方法揭示了地物光谱间的高阶特性,可以较好地反映地物分布复杂的目标光谱特性.通过高光谱真实影像和模拟数据的实验证明:1)本文提出的异常探测方法具有更优的受试者工作特征曲线和曲线下面积统计值,目标和背景的分离度更大;2)在核特征空间内,排除异常目标对背景统计信息的干扰,有助于进一步提高探测准确度;3)特征提取可以更好地利用目标和背景的光谱区分性,是异常探测的重要步骤.

关键词:异常探测;核空间理论;鲁棒分析;高光谱图像

中图分类号:TP751.1

文献标识码:A

文章编号:1004-4213(2013)08-0883-8

An Anomaly Detection Method for Hyperspectral Imagery in Kernel Feature Space Based on Robust Analysis

ZHAO Rui^a, DU Bo^b, ZHANG Liang-pei^a

(a. State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing,

b. School of Computer Science, Wuhan University, Wuhan 430079, China)

Abstract: Traditional hyperspectral anomaly detectors background statistics are easily contaminated by anomalies and not robust that is difficult to detect anomalies of nonlinear mixed. In response to these problems, the Kernel feature projection theory is utilized, robustness analysis method is introduced in the construction of the anomaly detector background information, and a robust anomaly detection method is proposed. Using this method, c hyperspectral data from low-dimensional space can be mapped to high dimensional feature space without specific nonlinear mapping function, the background and anomaly targets can be expressed by a linear model, and a robust detector is constructed in the feature space. This method reveals high-order features between the objects on ground surface and can reflect complex spectral characteristics of target and surface features distribution. Experiments of real hyperspectral images and simulated data can prove: 1) the proposed anomaly detection method has a better receiver operating characteristic (ROC) curve and area under the curve (AUC) statistics and has a greater degree of separation of the target and background; 2) in kernel feature space, exclusion of anomalies contamination on statistics of the background improve the detection accuracy; 3) feature extraction can make better utilizing spectral diversity distinguish anomalies and background, which is an important step of anomaly detector.

基金项目:国家重点基础研究发展计划(Nos. 2012CB719905, 2011CB707105)、国家自然科学基金(No. 61102128)、中国博士后科学基金(No. 211-180788)和湖北省自然科学基金(No. 2011CDB455)资助

第一作者:赵锐(1989-),男,硕士研究生,主要研究方向为高光谱遥感影像异常目标探测. Email:759572276@qq.com

导师(通讯作者):杜博(1983-),男,副教授,博士后,主要研究方向为光学成像与信息处理、高光谱遥感、模式识别. Email:gunspace@163.com

收稿日期:2013-02-25; **录用日期:**2013-05-14

Key words: Anomaly detection; Kernel feature space theory; Robust analysis; Hyperspectral imagery

0 引言

高光谱遥感技术是一种新式的对地观测技术. 与传统全色、多光谱遥感数据不同, 高光谱遥感数据空间维和光谱维结合, 呈三维影像立方体形式^[1]. 光谱维使高光谱影像包含了细致丰富的地物光谱^[2-4], 这为高光谱异常探测技术的发展提供了保障. 异常探测本质上是二类问题, 即将影像分为背景和异常目标两类, 异常目标是指光谱与大部分背景地物有很大差异的目标像元. 在探测过程中, 异常探测技术不需要目标和背景地物的先验光谱信息. 在很多应用中我们很难获得影像覆盖区域中地物光谱, 异常探测技术不需要先验光谱信息的特点使其获得广泛的应用. 近年来, 高光谱异常探测技术在很多领域中得到成功应用, 如矿物勘测、边境监察、搜索营救等, 因此成为遥感影像处理的一个研究热点^[5].

目前国内外学者对高光谱异常探测技术做了大量研究, Reed 和 Yu 提出的一种恒虚警率异常探测算法(Reed-Xiaoli, RX)是异常探测技术中最经典的基于马氏距离统计的线性探测算法^[6], 已被广泛应用于多光谱和高光谱遥感影像. 但由于异常点干扰了背景模型统计的稳定性, 使 RX 算法探测性能较差^[7]. 国内外学者针对探测器稳定性的增强已经进行了初步研究, 如基于稳健背景子空间的高光谱异常探测方法^[8], Billor, Hadi 等人针对 RX 探测算法稳定性差的特点将鲁棒性分析技术引入异常探测, 提出了封闭自适应高效异常探测器(Blocked Adaptive Computationally efficient Outlier Nominators, BACON)^[9], BACON 可以很好地抑制了异常目标对背景模型统计变量的干扰. 由于高光谱影像空间分辨率较低, 影像区域中地物也往往比较复杂, 混合像元现象普遍存在. 一般认为, 电磁波在地表单次反射成像, 这时, 如 RX 和基于聚类信息(Cluster-Based Anomaly Detection, CBAD)^[10]的异常探测算法以线性混合模型为基础构建的异常探测器可以很好地对数据进行描述. 然而, 高光谱遥感传感器在接收地物信号过程中, 可能会经多种地物表面多次反射^[11]. 这使影像中包含了大量非线性信息, 传统线性混合模型不能准确地描述高光谱遥感影像生成过程, 基于传统线性混合模型的异常探测器解译效果很差. 对非线性信息进行解缠, 应用非线性异常探测算法对影像进行探测可能会得到更好的探测结果^[12]. Kwon 等人在 2005 年将核空间理论应用到异常探测技术中, 提出了 Kernel-RX 探测算法^[13]. 近年来,

非线性异常探测和目标探测算法研究在逐步扩展, 相较于线性算法可以得到更好的探测结果^[14-18].

本文提出了一种核特征空间的鲁棒性异常探测器(Kernel Robust Anomaly Detector, KRAD). 该方法可以在不需要确定具体的非线性映射函数下, 将高光谱数据从低维空间映射到高维特征空间, 背景和异常目标在特征空间中可以用线性模型表示, 并在特征空间中构造鲁棒性的探测器. 该方法揭示了地物光谱间的高阶特性, 可以较好地反映地物分布复杂的目标光谱特性.

1 核特征空间鲁棒性异常探测器

理想的高光谱遥感影像数据被认为是各向同性(homogeneous), 即服从同一模型^[9,19]. 在高光谱异常探测技术中, 通常假设数据服从于单峰正态高斯分布^[11]. 但一般来讲, 高光谱传感器获取的影像数据基本都不会达到理想影像的标准, 异常目标的存在和背景地物的复杂性使得单峰正态高斯模型不能描述高光谱数据的实际分布情况. 影像数据复杂性对异常探测造成的问题主要包括: 1) 异常目标对探测统计的干扰; 2) 多种地物组成的背景无法看作各向同性; 3) 像元光谱并非简单的多种地物光谱线性混合, 如图 1(a)所示, 传感器信号在地物中多次反射、折射和影像地物复杂性可能使高光谱影像背景和异常目标呈非线性混合分布, 如图 1(b)所示. 本文提出的 KRAD 算法运用鲁棒分析技术和核空间理论可以解决上述问题.




图 1 光谱混合模型

Fig. 1 Spectral mixture model

高光谱遥感影像异常目标探测技术最常用的探测机理是基于马氏距离(Mahalanobis-Distance, MD)统计探测值, 其中应用最广泛的是由 Reed 和 Xiaoli 提出的 RX 异常探测算法^[6], RX 探测器基于异常探测二元假设检验和最大似然比模型建立^[1].

$$H_0: x \rightarrow N(\mu, \Gamma_x), x \text{ 为背景像元} \quad (1)$$

$$H_1: x \rightarrow N(s, \Gamma_x), x \text{ 为目标像元}$$

$$RX(x) = (x - \mu)^T (\Gamma_x)^{-1} (x - \mu) \begin{matrix} > \\ < \end{matrix} \eta \quad (2)$$

$$H_1$$

$$H_0$$

式(1)表示异常探测二元假设检验,式(2)为RX探测器构造.两式中, x 为当前探测像元, μ 、 s 、 Γ_x 分别为影像背景均值、异常目标均值、协方差矩阵, η 是分割阈值.

当影像中异常目标像元数量较多时,基于MD的统计变量,包括均值、协方差,会受到异常目标的干扰,统计得到的均值和协方差会严重偏离表征背景像元集的均值及协方差.图2中以简化的二维空间代表高光谱数据空间,空心点代表背景像元,实心点代表异常目标,虚线代表探测决策面.图2(a)中所示的探测决策面为MD统计不受异常目标干扰得到的理想决策面,图2(b)中所示的探测决策面为MD统计受异常目标干扰后发生的偏移.可见RX算法一般对多异常目标探测稳定性较差^[9,19].




图2 异常目标对MD统计探测的干扰

Fig. 2 Interference with anomalies to detection statistics of MD

KRAD算法采用如下的背景统计特征构建策略:通过迭代运算在数据中找到不含异常目标的数据集,以数据集中的少量背景像元为基准数据集,而后进入迭代运算.每次迭代中通过马氏距离统计和差分分布包容条件向背景像元集加入背景点,直至没有新的背景点加入背景像元集为止,最终找到的数据集中均为背景点数据,这样避免了异常目标对数据的干扰.将这种统计策略运用到高光谱异常探测技术中在影像中找到不包含异常目标的背景像元集合,可以避免异常目标对探测统计的干扰.

为克服影像上存在的非线性数据混合问题,KRAD方法引入了核学习理论^[20].如图3(左)所示,通过核空间理论也称核机器学习方法可以解决数据现行不可分问题.图3表现核机器学习理论(Kernel Machine Learning)在高光谱遥感影像异常探测中的应用.图3(左)用二维空间代表高光谱影像原始低维空间,在低维空间中可以很明显看出由于地物折射或多次反射产生的非线性光谱混合使得高光谱数据中的背景(空心点)不服从高斯分布,运用核机器学习理论可以将高光谱原始低维空间投影到某一高维特征空间使高光谱数据服从全局或局域单峰高斯分布,从而使数据更利于应用于异常探测,图3(右)用三维空间代表投影后的高维核特征空间.




图3 高光谱异常探测中非线性数据在原始空间和核特征空间分布情况

Fig. 3 Nonlinear data distribution in original space and kernel feature space for hyperspectral anomaly detection

核机器学习是通过选定的核函数将原始低维空间投影到某一高维核特征空间,使作用于原始空间的线性方法拓展为作用于高维核特征空间的非线性方法.运用这样一种非线性投影和特定的核函数可以在没有真正通过非线性映射 Φ 投影的情况下,将数据看作转换到了维数更高(可能为无穷大)的核特征空间^[20].核机器学习的精髓在于核技巧(Kernel trick)的运用.下面将介绍核机器学习的一般过程.

假设,数据位于低维数据空间($\chi \in \mathcal{R}^l$)中,令 Ψ 为某一维数更高的特征空间, Ψ 需满足 Hilbert 空间具有的特点,令 Φ 为 \mathcal{R}^l 投影到 Ψ 的非线性映射,则非线性映射可表示为

$$\begin{aligned} \Phi: \chi &\rightarrow \Psi \\ x &\rightarrow \Phi(x) \end{aligned} \quad (3)$$

式中, x 为数据中的数据元向量($x \in \chi$),在式中被投影到一个维数更高的特征空间,通过非线性映射 Φ 将数据投影到高维空间 Ψ 后,因为投影的方式不确定,作用于 Ψ 的算法无法在计算机中实现.运用核技巧可以通过用数据间的核函数运算来代替低维空间中数据的点积运算来避免算法无法实现的问题. Kernel trick 表达式为

$$K(x_i, x_j) = K\langle \Phi(x_i), \Phi(x_j) \rangle = \Phi(x_i) \cdot \Phi(x_j) \quad (4)$$

式(4)在核机器学习理论中称为核技巧(kernel trick),式中 x_i, x_j 为低维空间数据向量, $\Phi(x_i), \Phi(x_j)$ 为高维核特征空间数据向量, $K(\cdot, \cdot)$ 为核函数.本文提出的KRAD算法运用的核函数是高斯径向基核函数(RBF Kernel Function).

综上所述,KRAD算法是在高维核特征空间中运用鲁棒性迭代统计策略对高光谱遥感影像进行异常目标探测.具体操作流程如下:

- 1) 首先对高光谱数据进行全局 Kernel-RX 探测^[13],由探测值最小的一些像元建立初始背景集,初始背景集容量为波段数的3~4倍;
- 2) 基于差分分布由波段数计算得到初始包容因子 thr,进入迭代运算;
- 3) 在每一次迭代中,由影像像元总数、波段数

和当前背景集容量计算本次迭代的容量改正因子 C_{npr} (如式(3)所示, n 为影像像元总数), $\text{thr} * C_{npr}$ 为本次迭代的包容因子, 再由当前背景集统计得到核矩阵 Gram Matrix^[13], 然后计算剩余像元的核化马氏距离探测值^[19], 将核化探测值小于包容因子的像元加入到背景集中, 即

$$c_{npr} = c_{np} + c_{hr} \quad (5)$$

式中

$$c_{np} = 1 + \frac{p+1}{n-p} + \frac{1}{n-h-p}$$

$$c_{hr} = \max\{0, (h-r)/(h+r)\}$$

$$h = [(n+p+1)/2]$$

r = 当前背景集容量

4) 在迭代中若有新的像元加入到背景集, 那么需要重新计算迭代容量改正因子得到新的包容因子进入下一次迭代, 若在某次迭代中没有背景集没有改变, 那么判定迭代运算终止, 可得到最终的背景集;

5) 由最终背景集统计得到的核矩阵 Gram Matrix 对影像整体进行 Kernel-RX 探测, 输出探测值图像;

6) 设置阈值, 得到探测结果.

图 4 为 KRAD 算法流程框图.

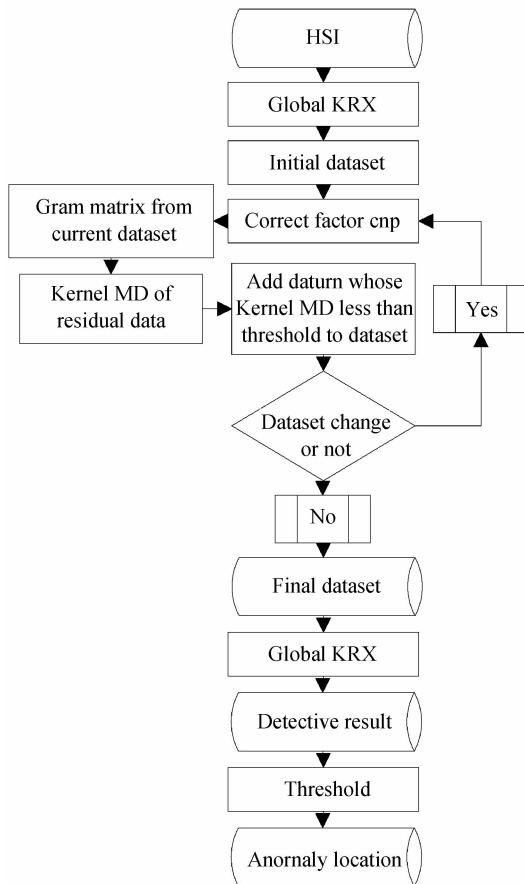


图 4 KRAD 算法流程框图
Fig. 4 Flow chart of KRAD

在使用 Kernel-RX 和迭代运算中都需要统计核矩阵 Gram Matrix, 但 Kernel-RX 和迭代运算的核矩阵统计方法不同, Kernel-RX 中核矩阵是以 K 均值分类的聚类中心计算得到^[19], 迭代运算中的核矩阵是对当前迭代背景集采样得到统计像元. 核矩阵 Gram Matrix 在核特征空间中可表征影像数据特征, 对 Gram Matrix 进行背景特征提取可提高探测器的探测结果, 这部分操作可在实验中得到验证.

2 实验结果及分析

2.1 核矩阵 (Gram Matrix) 特征提取验证实验

该部分实验数据为 AVIRIS 采集到的美国内华达州月亮火山湖地区高光谱数据集 (如图 5 所示), 该数据原有 224 个波段, 光谱覆盖范围是 0.2~2.4 μm , 光谱分辨率为 9.72 nm, 空间分辨率为 20 m. 数据大小为 200×200 像素, 在去除水蒸气吸收和低信噪比 (SNR) 波段后剩余 169 个波段. 影像中围绕 (74,75) 的 9 个像元为异常目标.




图 5 月亮湖 (Lunarlake) 高光谱数据集第一波段
Fig. 5 First band of Lunarlake hyperspectral dataset

特征提取前后探测纹理如图 6、7 所示. 图 8 表明核化算法中若没有进行核矩阵 Gram Matrix 特征提取, 异常目标的探测值可能会位于背景探测值分布中或与背景探测值分布有重叠, 这样会降低探测率, 甚至可能出现探测率为 0 的结果. 核矩阵特征提取预处理可以明显地拉大异常目标与背景之间的分离度, 降低探测器对核参数的敏感度, 提高探测器性能.




图 6 核矩阵特征提取前探测纹理
Fig. 6 Detected result without Gram Matrix feature extraction




图 7 核矩阵特征提取后探测纹理

Fig. 7 Detected result with Gram Matrix feature extraction

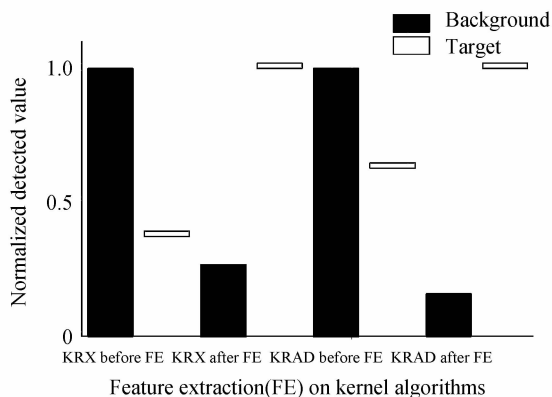


图 8 探测结果分离度

Fig. 8 Degree of separation in detected result

2.2 非线性高光谱模拟数据实验

本实验模拟数据如图 9 所示,大小为 100×100 像素,植入了 9 个 3×3 大小异常目标,目标中心分别位于 $(25, 25)$, $(25, 50)$, $(25, 75)$, $(50, 25)$, $(50, 50)$, $(50, 75)$, $(75, 25)$, $(75, 50)$, $(75, 75)$, (如图 9 (b)所示). 背景和异常目标光谱均来自 ENVI 4.7 光谱库,背景光谱由自然植被光谱库 `veg_lib` 中 `usgs_veg.sli` 文件里的三个植被光谱 `Aspen_Leaf` (白杨树)、`Blue_Spruce` (云杉)、`Pinon_Pine` (松树) 作为背景的 3 个端元,目标光谱来自矿物光谱库 `usgs_min.sli` 文件里的一种矿物岩石 `Actinolite` (阳起石) 为异常目标端元,端元光谱如图 10 所示.

本实验用 Hapker 近似方程来模拟非线性的训练样本. 通常假设遥感测量的光谱数据具有二向性反射率,因此用如下表达式将二向性反射率近似转




图 9 非线性高光谱模拟数据

Fig. 9 Nonlinear simulated hyperspectral data

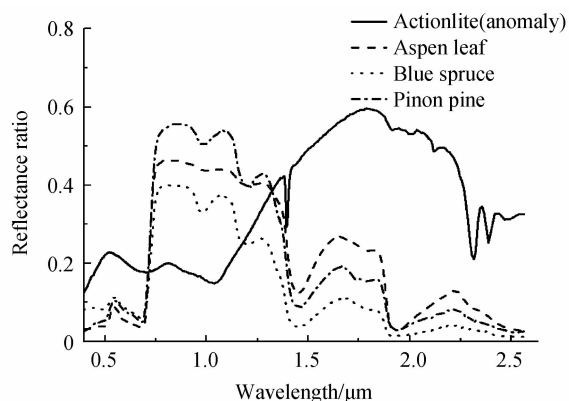


图 10 模拟数据端元光谱

Fig. 10 Spectrum of endmembers in simulated data

化为单一散射反照率 (SSA).

$$R(i, e) = \frac{\omega H(\mu) H(\mu_0)}{4(\mu + \mu_0)} \quad (6)$$

式中, i 入射角, e 为视角, $\mu = \cos i$, $\mu_0 = \sin i$, $H(\mu)$ 表示地物间多向散射的函数, 即

$$H(\mu) = \frac{1 + 2\mu}{1 + 2\mu \sqrt{1 - \omega}} \quad (7)$$

非线性数据模拟具体步骤如下:

- 1) 把典型地物的光谱值转化为相应的反射率;
- 2) 利用式 (6)、(7) 把反射率转换为单一散射反照率 ω_i ;
- 3) 背景像元: 在 $[0, 1]$ 之间产生 3 个随机数 c_i , 并且使得 $\sum_{i=1}^3 c_i = 1$, 目标像元: 与背景像元相似, 控制目标组分小于 25%, 随即选取 ω_i 的 1 次或 2 次方作为数据背景端元光谱, 目标端元光谱统一设定为 ω_1 的 2 次方, 则混合反射率为

$$\text{背景: } \rho = \sum_{i=1}^3 c_i \omega_i \quad (8)$$

$$\text{目标: } \rho = \sum_{i=1}^4 c_i \omega_i \quad (9)$$

- 4) 利用式 (6)、(7) 把混合反照率 ρ 转化为混合反照率 R . 再在 R 附加正态随机噪声, 利用式 (10) 计算模拟数据 \hat{R} .

$$\hat{R} = R \left(1 + \frac{N(0, 1)}{\text{SNR}} \right) \quad (10)$$

式中 SNR 为信噪比, $N(0, 1)$ 为 0 均值, 方差为 1 的正态随机矢量.

为了考察算法对包含不同组分异常端元的目标的探测性能, 在生成数据时设定 9 组目标异常组分分别为 10%~90%.

图 11 表明 RX 和 BACON 算法对非线性数据背景抑制较差, 这是由于在原始空间中数据不呈正态单峰高斯分布, 使得原始空间中特征值与目标相似的背景没有被抑制. KRX 和 KRAD 结果图中背

景和目标的对比度增大,即 KRX 和 KRAD 可以更好地抑制非线性数据中的背景信息. 图 12 中受试者工作特征 (Receiver Operating Characteristic, ROC) 曲线表明 KRAD 对非线性数据探测性能远优于 KRX、BACON 和 RX 算法,非线性数据投影到核特征空间后再通过鲁棒性迭代分析,既可以使投影后的数据呈高斯正态分布,也可以在投影后抑制异常目标对探测统计的干扰.




图 11 模拟数据探测结果
Fig. 11 Detected result simulated data

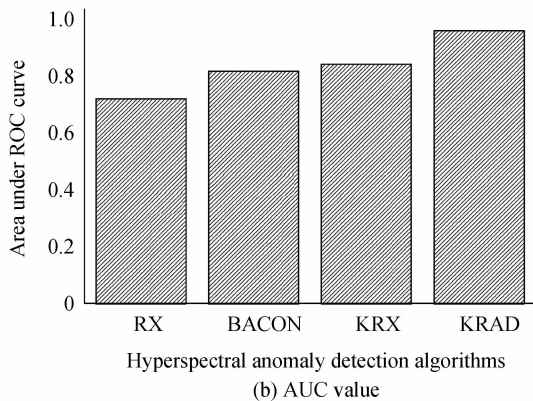



图 12 非线性高光谱模拟数据探测精度评估
Fig. 12 Detection accuracy evaluation of nonlinear simulated hyperspectral data

2.3 真实高光谱遥感影像实验

本实验数据的原始数据集为 AVIRIS 采集到的洛杉矶机场高光谱数据集(如图 13),大小为 400×400 像素,包含 224 个波段. 将小飞机作为异常目标,截取数据集左下角 60×60 像素大小的数据子集(如图 14 (a)),并去除低信噪比和水蒸气吸收波段 (1-6,33-35,97,107-113,153-166 和 221-224),剩余的 189 个波段用于实验. 同时对数据中小飞机目标做掩膜(如图 14 (b))以便评价算法探测性能^[21].



图 13 圣地亚哥机场原始高光谱数据集第一波段
Fig. 13 First band of original hyperspectral dataset of San Diego airport




图 14 圣地亚哥机场区域裁剪高光谱数据
Fig. 14 Subset of San Diego hyperspectral dataset

该影像中,波段间的相关性强,波段数多,一般采用 KPCA(Kernel-PCA)^[21]进行预处理. 对预处理后的数据进行 RX、BACON、KRX、KRAD 探测,探测结果和探测精度评估如图 15、16.




图 15 真实影像探测纹理
Fig. 15 Detected result of real hyperspectral image

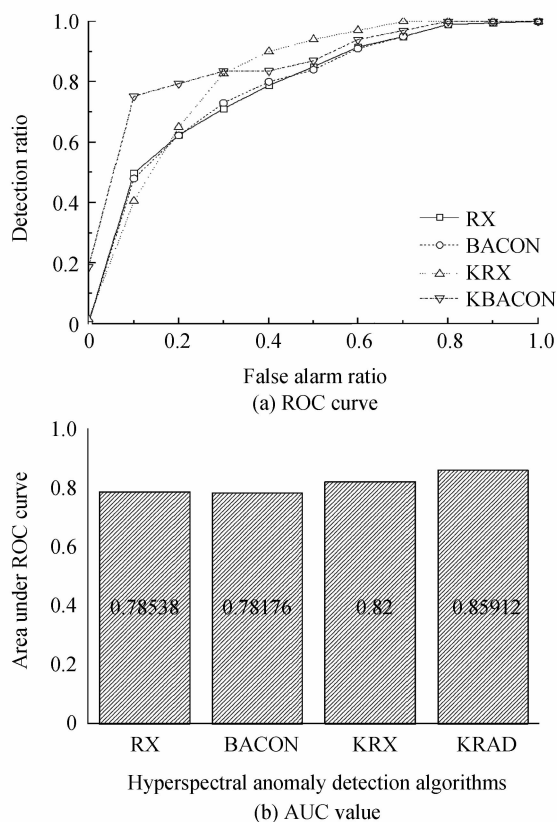


图 16 高光谱真实影像探测精度评估

Fig. 16 Detection accuracy evaluation of real hyperspectral image

实验中,影像上有少部分房屋建筑物地物,光谱曲线如图 17,其与背景的光谱差异很大,因此也很容易被视作异常目标.由图 15 可以看出,RX 和 BACON 对房屋建筑物抑制能力很差,对应的核化算法对房屋建筑物抑制能力较好,KRAD 抑制能力最强.KRAD 在四种算法中最能拉大背景和目标之间的分离度,图 16 中 ROC 曲线也表明 KRAD 探测性能优于 RX、BACON、KRX.

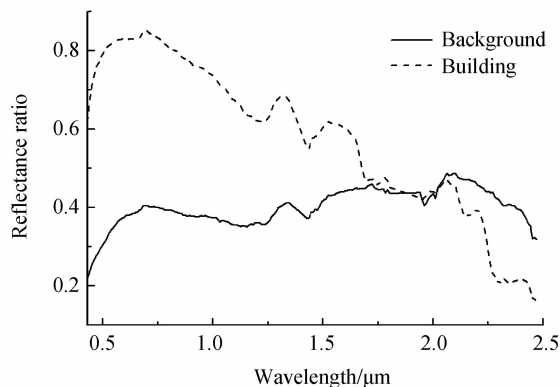


图 17 影像主要地物光谱

Fig. 17 Primary surface features in image

3 结论

本文提出了一种高光谱遥感影像核特征空间鲁棒性异常探测算法(Kernel Robust Anomaly

Detection).通过引入核机器学习理论和鲁棒性分析技术使 KRAD 算法在高维核特征空间中数据投影更接近正态单峰高斯分布的同时可以抑制异常目标对背景统计的影响.利用核机器学习理论避免了实际计算原始空间到高维空间的映射,同时也解译了数据中的非线性信息.真实高光谱影像和非线性模拟数据实验证明,本文提出的 KRAD 算法探测性能比传统方法更优,背景特征构建方式具有较强的鲁棒性,为非线性高光谱遥感数据异常探测提供了有效途径.

参考文献

- [1] STEIN D W J, BEAVEN S G, HOFF L E, *et al.* Anomaly detection from hyperspectral imagery[J]. *Signal Processing Magazine, IEEE*, 2002, **19**(1): 58-69.
- [2] MANOLAKIS D, SHAW G. Detection algorithms for hyperspectral imaging applications [J]. *Signal Processing Magazine, IEEE*, 2002, **19**(1): 29-43.
- [3] DU Bo, ZHANG Liang-pei. Random-selection-based anomaly detector for hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **49**(5): 1578-1589.
- [4] DU Bo, ZHANG Le-fei, ZHANG Liang-pei, *et al.* Discriminant manifold learning approach for hyperspectral image dimension reduction[J]. *Acta Photonica Sinica*, 2013, **42**(3): 320-325.
- [5] MATTEOLI S, DIANI M, CORSINI G. A tutorial overview of anomaly detection in hyperspectral images[J]. *Aerospace and Electronic Systems Magazine, IEEE*, 2010, **25**(7): 5-28.
- [6] REED I S, YU X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution [J]. *IEEE Transactions on Acoustics, Speech and Signal Processing*, 1990, **38**(10): 1760-1770.
- [7] ZHAO Chun-hui, HU Chun-mei, BAO Yu-gang. A kind of anomaly detection algorithm for hyperspectral image through background error cumulation [J]. *Acta Photonica Sinica*, 2010, **39**(10): 1830-1835.
- [8] 赵春晖,胡春梅,包玉刚.一种背景误差累积的高光谱图像异常检测算法[J]. *光子学报*, 2010, **39**(10): 1830-1835.
- [9] PU Xiao-feng, LEI Wu-hu, HUANG Tao, *et al.* Robust background subspace based anomaly detection algorithm for hyperspectral imagery[J]. *Acta Photonica Sinica*, 2010, **39**(12): 2224-2228.
- [10] 蒲晓丰,雷武虎,黄涛,等.基于稳健背景子空间的高光谱图像异常检测[J]. *光子学报*, 2010, **39**(12): 2224-2228.
- [11] BILLOR N, HADI A S, VELLEMAN P F. BACON: blocked adaptive computationally efficient outlier nominators [J]. *Computational Statistics & Data Analysis*, 2000, **34**(3): 279-298.
- [12] CARLOTTO M J. A cluster-based approach for detecting man-made objects and changes in imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(2): 374-387.
- [13] BANERJEE A, BURLINA P, DIEHL C. A support vector method for anomaly detection in hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, **44**(8): 2282-2291.
- [14] WANG Ting, DU Bo, ZHANG Liang-pei. Kernel orthogonal

- subspace projection for target detection give consideration to local information[J]. *Geomatics and Information Science of Wuhan University*, 2013, **38**(2): 200-203.
- 王挺,杜博,张良培. 顾及局域信息的核化正交子空间投影目标探测方法[J]. 武汉大学学报信息科学版,2013, **38**(2): 200-203.
- [13] HEESUNG KWON, NASRABADI N M. Kernel RX-algorithm: a nonlinear anomaly detector for hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(2): 388-397.
- [14] HEESUNG KWON, NASRABADI N M. Kernel orthogonal subspace projection for hyperspectral signal classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(12): 2952-2962.
- [15] HEESUNG KWON, NASRABADI N M. Kernel matched signal detectors for hyperspectral target detection[C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005.
- [16] HEESUNG KWON, NASRABADI N M. Kernel matched subspace detectors for hyperspectral target detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, **28**(2): 178-194.
- [17] GURRAM P, HEESUNG KWON, HAN T. Sparse kernel-based hyperspectral anomaly detection [J]. *Geoscience and Remote Sensing Letters, IEEE*, 2012, **9**(5): 943-947.
- [18] MEI Feng, ZHAO Chun-hui, SUN Yan, *et al.* A novel spectral similarity measurement kernel based anomaly detection method in hyperspectral imagery [J]. *Acta Photonica Sinica*, 2009, **38**(12): 3165-3170.
- 梅锋,赵春晖,孙岩,等. 基于新型光谱相似度量核的高光谱异常检测算法[J]. 光子学报,2009, **38**(12): 3165-3170.
- [19] EDISANTER L, INGRAM J. Hyperspectral anomaly detection based on minimum generalized variance method[C]. *SPIE*, 2008, **6966**: 1-7.
- [20] HIRSH R G. A performance characterization of kernel-based algorithms for anomaly detection in hyperspectral imagery [D]. Maryland: University of Maryland, 2007.
- [21] GU Yan-feng, LIU Ying, ZHANG Ye. A selective KPCA algorithm based on high-order statistics for anomaly detection in hyperspectral imagery[J]. *Geoscience and Remote Sensing Letters, IEEE*, 2008, **5**(1): 43-47.