

# 采用多项式递归核的高光谱遥感异常实时检测算法

赵春晖<sup>1</sup> 尤 伟<sup>1</sup> 齐 滨<sup>2</sup> 王 佳<sup>1</sup>

<sup>1</sup>哈尔滨工程大学信息与通信工程学院,黑龙江 哈尔滨 150001

<sup>2</sup>哈尔滨工程大学水声工程学院,黑龙江 哈尔滨 150001

**摘要** 高光谱遥感目标检测是遥感信号处理领域的热点问题,基于核机器学习的KRX算法能充分利用高光谱波段间的非线性光谱特性,在原始光谱的特征空间进行探测,能够获得较好的检测效果。针对KRX算法检测过程计算复杂、不能满足快速处理要求的缺陷,引入了卡尔曼滤波器的递归思想,提出了一种核递归的高光谱异常目标检测算法。从光谱分析的角度,应用Woodbury引理从上一时刻的状态迭代更新当前像元的Gram核矩阵,避免了高维矩阵数据重复计算。实验结果表明,与传统RX、因果RX和KRX等算法相比,在检测精度有所提高的同时,大大缩短了算法检测时间,提高了异常目标检测效率。

**关键词** 遥感; 高光谱; 核机器学习; 异常检测

**中图分类号** TP751.1 **文献标识码** A

**doi:** 10.3788/AOS201636.0228002

## Real-Time Anomaly Detection Algorithm for Hyperspectral Remote Sensing by Using Recursive Polynomial Kernel Function

Zhao Chunhui<sup>1</sup> You Wei<sup>1</sup> Qi Bin<sup>2</sup> Wang Jia<sup>1</sup>

<sup>1</sup>College of Information and Communication Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China

<sup>2</sup>College of Underwater Acoustic Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China

**Abstract** Hyperspectral target detection is a great deal of attention in the field of remote sensing signal processing. The KRX algorithm based on kernel machine learning can make full use of nonlinear spectral characteristics among hyperspectral bands. Therefore, it can get better detection results in the original spectral feature space. Aimed at the defect that the complexities of KRX algorithm is high in calculating the detection process and unable meet the requirement of rapid processing. A real-time anomaly detection method is proposed based on recursive kernel function. The recursive thought of Kalman filter is introduced, which puts forward a nuclear recursive hyperspectral anomaly target detection algorithm. From the perspective of spectral analysis, with Woodbury's lemma, the kernel matrices can be updated by the kernel matrices of last pixel. It avoids repeat computation of high-dimensional data matrices. Experimental results show that the accuracy of anomaly detection is improved and testing time of the algorithm is reduced at the same time when compared with the traditional RX, causal RX and KRX algorithm.

**Key words** remote sensing; hyperspectral; kernel machine learning; anomaly detection

**OCIS codes** 280.1100; 100.4145; 100.3190; 100.5010

## 1 引 言

近年来,伴随着遥感和成像光谱仪技术的发展,具有更高光谱分辨率的高光谱遥感技术获得了广泛关注,并应用于地质勘探、国际搜救行动、军事伪装目标识别等多个领域<sup>[1-3]</sup>。高光谱遥感具有一种图谱合一的新型

收稿日期: 2015-06-30; 收到修改稿日期: 2015-09-18

基金项目: 国家自然科学基金(61571145, 61405041)、黑龙江省自然科学基金重点项目(ZD201216)、哈尔滨市优秀学科带头人基金项目(RC2013XK009003)、中国博士后基金项目(2014M551221)、中央高校基础研究基金项目(HEUCF1508)

作者简介: 赵春晖(1965—),男,教授,博士生导师,主要从事高光谱遥感处理技术方面的研究。

E-mail: zhaochunhui@hrbeu.edu.cn

遥感数据,融合了二维空间成像技术和光谱探测技术<sup>[4-6]</sup>,借助其丰富的光谱信息,可以发现传统纹理、边缘等空间特征无法描述或者难以探测的地物目标。因而高光谱遥感在目标探测与识别等方面具有广泛的应用。

根据是否需要先验知识,现有的高光谱目标检测算法可分为需要先验目标或背景信息的光谱匹配检测算法和无需任何已知信息或先验知识的异常探测算法<sup>[7-8]</sup>。在实际中,由于难以获取准确的地物反射光谱,且缺少比较完备的光谱数据库,获取先验光谱信息就变得非常困难,无需任何先验信息的异常目标检测因而具有较强的实用性,更符合实际应用的需求。

早在20世纪90年代,Reed等<sup>[9]</sup>提出了RX算子,它源自多光谱检测和分析技术,成为了目前使用最广泛的经典异常探测算法之一。该算法是在一些简化的假设条件下,其渐进意义是通过求解目标与背景均值向量的马氏距离,构造全局似然比检测算子对高光谱的逐一像素进行检测。随后Chang等提出了具有因果特性的基于相关矩阵的RX异常检测算法,检测精度有所提高。

2013年,Acito等<sup>[10]</sup>提出了一种RX局部异常检测算法。由于RX算法采用了局部统计模型假定数据服从正态分布,不能全面地符合实际情况,从而导致了很高的虚警概率,且在算法流程中需要计算样本协方差矩阵,而协方差矩阵的维数随波段数增加而迅速增加,这将带来巨大的计算量,导致了算法计算效率不高<sup>[11]</sup>。随后,Hsueh等<sup>[12-18]</sup>在RX算法的基础上进行了研究和改进,提出了高光谱目标实时检测RX算法,利用迭代思想大大加快了计算速度,提高了算法效率,但尚未从算法本身提高检测精度。为降低虚警概率,Kwon等<sup>[17]</sup>进一步地提出了一种基于核机器学习的非线性RX改进算法,该算法利用核函数将原始输入空间的非线性分析映射为高维特征空间的线性分析,更好地利用了高光谱波段之间的非线性统计特性,从结构上改进了算法,加入了大量非线性核函数的运算,然而该方法以牺牲计算时间来换取较高的检测概率。

在实际异常检测应用(例如搜救行动和军事目标探测),实现异常目标的实时探测是非常重要的,所以研究如何进一步提高核方法高光谱目标检测效率是很有必要的。为此,本文提出了一种基于核递归的高光谱异常目标检测快速算法,在保证核RX方法检测精度的前提下实现了递归运算,提高了检测效率,本文给出了该方法的高光谱目标检测结果,并将该方法与RX方法、实时RX方法和核RX方法进行了比较。

## 2 高光谱异常目标检测算子

在文献[9]中,Reed等最早提出了一种基于广义似然比检验的异常检测算子,称之为RX算子。针对RX算子检测精度不高的缺点,Kwon等<sup>[17]</sup>利用核机器学习的思想提出了基于非线性核映射的高光谱异常检测算子,称之为KRX算子。核函数的引入大大降低了算法效率,为此,引入递归思想以实现异常目标的快速检测。

### 2.1 RX异常检测算子

设具有 $L$ 个波段的高光谱像元的光谱向量可表示为一个 $L$ 维列向量 $\mathbf{r}_i = [r_{1i}, r_{2i}, \dots, r_{Li}]^T$ ,假设已知光谱信号为 $\mathbf{s} = [s_1, s_2, \dots, s_L]^T$ ,令 $\mathbf{a} = [a_1, a_2, \dots, a_L]^T$ 为信号丰度,则二元假设检验可表示为

$$\begin{cases} H_0: \mathbf{r} = \mathbf{n} \\ H_1: \mathbf{r} = \mathbf{a}\mathbf{s} + \mathbf{n} \end{cases}, \quad (1)$$

式中 $H_0$ 代表目标不存在, $H_1$ 代表目标存在, $\mathbf{n}$ 是背景噪声信号,这里采用加性模型。通过广义似然比检验并经过一系列化简可以得出RX检测器,给出RX简化形式为

$$\delta_{\text{RXD}} = (\mathbf{r} - \boldsymbol{\mu})^T \mathbf{K}^{-1} (\mathbf{r} - \boldsymbol{\mu}) \begin{cases} \geq \eta, H_1 \\ < \eta, H_0 \end{cases}, \quad (2)$$

式中 $\mathbf{r}$ 为 $L$ 维待检测像元的光谱向量, $\boldsymbol{\mu}$ 为高光谱数据样本均值向量, $\mathbf{K} = \frac{1}{N} \sum_{i=1}^N (\mathbf{r}_i - \boldsymbol{\mu})(\mathbf{r}_i - \boldsymbol{\mu})^T$ 为高光谱数据样本协方差矩阵, $\eta$ 为检测阈值, $N$ 为高光谱数据中观测样本的总数, $L$ 为高光谱数据的波段总数。

基于相关矩阵的因果RX异常检测算子:

$$\delta_{\text{CRRXD}} = \mathbf{r}_n^T \mathbf{R}(n)^{-1} \mathbf{r}_n \begin{cases} \geq \eta, H_1 \\ < \eta, H_0 \end{cases}, \quad (3)$$

$$\mathbf{R}(n) = \frac{1}{n} \sum_{i=1}^n \mathbf{r}_i \mathbf{r}_i^T, \quad (4)$$

式中  $r_n$  是当前待检测像元 ( $n^{\text{th}}$ ) 的光谱特性,  $\mathbf{R}(n)$  是采样数据的相关矩阵, 该相关矩阵由当前像元之前的所有像元光谱求相关性而得, 具有因果特性, 因此称之为因果 RX 算子。

利用 RX 算子对高光谱遥感数据进行光谱分析和检测, 不需要任何光谱信息, 并且算子构造简单, 易于实现<sup>[16-17]</sup>, 但是由于高光谱数据高数据维和波段间的高相关性, 该算子直接用于高光谱数据处理会产生很高的虚警概率。

## 2.2 KRX 异常检测算子

核 RX 是 Kwon 等针对 RX 算子存在的问题提出的改进算法, 并在其基础上发展而来的, 克服了 RX 算法的不足。将原始高光谱数据中线性不可分的信息, 通过非线性核映射到高维的特征空间, 从而线性可分, 进而实现背景和目標的有效分离, 它是一种非线性的 RX 算法。

采用非线性函数  $\Phi$  将原始的高光谱遥感数据映射到高维特征空间中, 得到特征空间中 KRX 算法可表示为

$$\text{KRX}[\Phi(r)] = [\Phi(r) - \hat{\mu}_{\text{B}\Phi}]^T \hat{\mathbf{C}}_{\text{B}\Phi}^{-1} [\hat{\mathbf{C}}_{\text{B}\Phi} - \hat{\mu}_{\text{B}\Phi}], \quad (5)$$

式中  $\hat{\mathbf{C}}_{\text{B}\Phi}$  和  $\hat{\mu}_{\text{B}\Phi} = \sum_{i=1}^N \Phi(r_i)/N$  为特征空间背景的协方差矩阵和均值向量的估计值。  $\hat{\mathbf{C}}_{\text{B}\Phi}$  为对称阵, 利用特征值分解可表示为  $\hat{\mathbf{C}}_{\text{B}\Phi} = \mathbf{V}_{\Phi} \mathbf{\Lambda}_{\Phi} \mathbf{V}_{\Phi}^T$ 。 (5) 式是 KRX 检测算子方程, 由该式可以看出, 在其特征空间中, 该算子具有较高的计算复杂度。通过特征值分解, 再将特征空间的点积使用核技巧转化为输入空间的核函数, 即:

$$k(x, y) = [\Phi(x), \Phi(y)] = \Phi(x)' \cdot \Phi(y), \quad (6)$$

化简最终得到 KRX 算子的最终算子表达式:

$$\text{KRX}[\Phi(r)] = [\Phi(r) - \hat{\mu}_{\text{B}\Phi}]^T \hat{\mathbf{K}}_{\text{B}}^{-1} [\Phi(r) - \hat{\mu}_{\text{B}\Phi}] \eta, \quad (7)$$

式中  $\hat{\mu}_{\text{B}\Phi}$  是估计均值,  $\mathbf{K}_{\text{B}} = \mathbf{K}(\mathbf{P}_{\text{B}}, \mathbf{P}_{\text{B}})$  为定义  $N \times N$  中心化 Gram 核矩阵,  $\hat{\mathbf{K}}_{\text{B}} = \mathbf{K}_{\text{B}} - \mathbf{K}_{\text{B}} \mathbf{I}_N - \mathbf{I}_N \mathbf{K}_{\text{B}} + \mathbf{I}_N \mathbf{K}_{\text{B}} \mathbf{I}_N$  表示一个中心化的 Gram 矩阵, 通过非中心化的 Gram 矩阵得到。

选择合适的核函数对核机器学习算法的性能具有重要的影响, 目前常用的核函数有多项式核函数、高斯径向基核函数、Sigmoid 核函数和 B-样条核函数。但是复杂的核函数容易导致计算复杂度变大, 影响计算速度, 因此采用了多项式函数, 其表达方式为

$$k(x, x_i) = (x^T x_i)^d, d \in N. \quad (8)$$

由 (8) 式可知, 多项式核函数在检测中将光谱匹配映射到高维空间, 用合适的分界面就可以区分目标和背景, 最后得到检测结果。

## 3 递归的 KRX 异常检测算子

RX 算子和 KRX 算子都是基于高光谱数据的二次协方差矩阵或者核矩阵进行异常目标检测的。但由于计算协方差矩阵或者核矩阵需要完整的高光谱数据信息, 且计算复杂度较高, 时效性就比较差, 为提高速度需要实现像元递归更新和算子求逆的递归运算。

### 3.1 Woodbury 引理

在矩阵理论中, Woodbury 恒等式指出, 某些具有  $k$  阶修正因子的矩阵的逆矩阵可以通过原始矩阵的逆矩阵以及  $k$  阶修正因子表示出来<sup>[19]</sup>。该准则又被称为矩阵的逆矩阵引理或者 Woodbury 引理。引理可表示为

$$(\mathbf{A} + \mathbf{UCV}^T)^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1} \mathbf{U} (\mathbf{C}^{-1} + \mathbf{V} \mathbf{A}^{-1} \mathbf{U})^{-1} \mathbf{V} \mathbf{A}^{-1}, \quad (9)$$

式中  $\mathbf{A}, \mathbf{U}, \mathbf{C}, \mathbf{V}$  都是具有特定维数的矩阵,  $\mathbf{A}$  是  $n \times n$  矩阵,  $\mathbf{U}$  是  $n \times k$  矩阵,  $\mathbf{C}$  是  $k \times k$  矩阵,  $\mathbf{V}$  是  $k \times n$  矩阵。如果矩阵  $\mathbf{C}$  的维数远远小于矩阵  $\mathbf{A}$  的维数, 则该等式的效率会远远高于直接计算  $(\mathbf{A} + \mathbf{UCV}^T)^{-1}$ 。尤其是当  $\mathbf{C}$  是  $1 \times 1$  的单位矩阵时, (9) 式可以化简成如下形式:

$$(\mathbf{A} + \mathbf{UV}^T)^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1} \mathbf{U} (\mathbf{1} + \mathbf{V}^T \mathbf{A}^{-1} \mathbf{U})^{-1} \mathbf{V}^T \mathbf{A}^{-1}. \quad (10)$$

此等式在已知  $\mathbf{A}^{-1}$  且需要计算  $(\mathbf{A} + \mathbf{UV}^T)^{-1}$  时, 可以有效避免协方差矩阵和核矩阵的逆矩阵的计算, 实现逆矩阵的递归更新。

### 3.2 递归算子

(8)式给出了多项式核函数表达式,将背景光谱代入核函数表达式得到如下形式:

$$\mathbf{K}_B(n) = k[X_B(n), X_B(n)] = \begin{bmatrix} \beta_{11}(n) & \beta_{12}(n) & \cdots & \beta_{1L}(n) \\ \beta_{21}(n) & \beta_{22}(n) & \cdots & \beta_{2L}(n) \\ \vdots & \vdots & \ddots & \vdots \\ \beta_{L1}(n) & \beta_{L2}(n) & \cdots & \beta_{LL}(n) \end{bmatrix}, \quad (11)$$

式中  $\beta_{ij}(n) = \sum_{k=1}^n r_{ik} r_{jk} = \sum_{k=1}^{n-1} r_{ik} r_{jk} + r_{in} r_{jn}$ , 高光谱像元可表示为  $r_i = [r_{i1}, r_{i2}, \dots, r_{iL}]^T$ ,  $L$  是波段数。根据上式可以得到如下核矩阵:

$$\mathbf{K}_B(n) = k[X_B(n), X_B(n)] = \left\{ \begin{bmatrix} \beta_{11}(n-1) & \cdots & \beta_{1L}(n-1) \\ \beta_{21}(n-1) & \cdots & \beta_{2L}(n-1) \\ \vdots & \ddots & \vdots \\ \beta_{L1}(n-1) & \cdots & \beta_{LL}(n-1) \end{bmatrix} + \begin{bmatrix} r_{1n} r_{1n} & \cdots & r_{1n} r_{Ln} \\ r_{2n} r_{1n} & \cdots & r_{2n} r_{Ln} \\ \vdots & \ddots & \vdots \\ r_{Ln} r_{1n} & \cdots & r_{Ln} r_{Ln} \end{bmatrix} \right\}^d = [\mathbf{K}_B(n-1) + r_n^T r_n]^d, \quad (12)$$

根据逆矩阵性质,由(12)式可得:

$$[\mathbf{K}_B(n)]^{-1} = \left\{ [\mathbf{K}_B(n-1) + r_n^T r_n]^d \right\}^{-1} = \left\{ [\mathbf{K}_B(n-1) + r_n^T r_n]^{-1} \right\}^d, \quad (13)$$

令  $\mathbf{A} = \mathbf{K}_B(n-1)$ ,  $\mathbf{U} = \mathbf{V} = r_n^T$ , 引入 Woodbury 恒等式引理, 则有:

$$[\mathbf{K}_B(n)]^{-1} = [\mathbf{K}_B(n-1)]^{-1} - \frac{[\mathbf{K}_B(n-1)]^{-1} r_n^T r_n [\mathbf{K}_B(n-1)]^{-1}}{1 + r_n [\mathbf{K}_B(n-1)]^{-1} r_n^T}. \quad (14)$$

由(14)式可知,当前时刻像元对应的背景核矩阵  $\mathbf{K}_B(n)$  的逆矩阵可以由上一时刻像元核矩阵  $\mathbf{K}_B(n-1)$  的逆矩阵递归更新给出,从而避免了重复求解核矩阵及其逆矩阵。则计算实时算子(RTKRXD),

$$\delta_{\text{RTKRXD}}[\Phi(r_n)] = [\Phi(r_n) - \hat{\mu}_{\Phi}]^T \left\{ [\mathbf{K}_B(n-1)]^{-1} - \frac{[\mathbf{K}_B(n-1)]^{-1} r_n^T r_n [\mathbf{K}_B(n-1)]^{-1}}{1 + r_n [\mathbf{K}_B(n-1)]^{-1} r_n^T} \right\} [\Phi(r_n) - \hat{\mu}_{\Phi}] \preceq \eta, \quad (15)$$

该 RTKRXD 递归算子的优点如下:

- 1)  $\mathbf{K}_B(n)$  只需要当前时刻像元  $r_n$  之前的背景光谱信息,没有用到之后的像元信息,因此可以实现高光谱边下行传输边处理的过程。
- 2) 无需重复计算  $\mathbf{K}_B(n)$  及其逆矩阵,可以大大减少算法计算时间,提高了效率。
- 3) 计算  $\mathbf{K}_B(n)$  只需要  $\mathbf{K}_B(n-1)$  和  $r_n$ ,因此在计算过程中,系统只需要存储  $\mathbf{K}_B(n-1)$  和  $r_n$ ,而无需存储已有的像元,可大大减少算子所需要的存储空间。

在递归更新等式中,由于计算当前时刻  $[\mathbf{K}_B(n)]^{-1}$  需要前一时刻的  $[\mathbf{K}_B(n-1)]^{-1}$ ,因而需要给定一个初始化的  $[\mathbf{K}_B(i)]^{-1}$ 。然而,为防止核矩阵奇异性过大,初始化像元总数必须大于高光谱数据波段数  $L$ 。

## 4 模拟数据实验及分析

在实际情况下,由于不能精确地获取真实高光谱数据真实地物分布情况,所以只能采用模拟数据对算法进行定量评价。为研究算法的抗噪声性能采用了两种模拟数据;1)采用高光谱目标嵌入型(TE)数据,为研究算法对于实际地物分布和目标大小的适应性;2)采用高光谱目标植入型(TI)数据,模拟数据是根据真实高光谱数据的光谱特性曲线合成的针对不同实验目的的高光谱数据。

### 4.1 AVIRIS 模拟数据

图 1 是一幅真实的高光谱遥感数据,实验数据取自美国圣地亚哥海军基地,该 AVIRIS 高光谱数据有 126 个波段,数据共有 400 pixel × 400 pixel。图中圈出了四种地物的地理分布,该四种地物分别是油桶、房屋、树木和飞机,分别以 G, H, T, P 表示。




图1 四类目标在高光谱真实数据中的分布

Fig.1 Distribution of four types of targets in real hyperspectral images.

该数据首先合成具有高斯分布的背景光谱信息,在背景数据上叠加了四种物质作为四种异常目标,每行异常目标由同种物质构成,每个目标都是  $3 \text{ pixel} \times 3 \text{ pixel}$  大小。其中第一列由纯像元构成,第二列包含了75%异常像元光谱特性和25%背景光谱特性,第三列包含了50%异常像元光谱特性和50%背景光谱特性,第四列包含了25%异常像元光谱特性和75%背景光谱特性,每个像元均是其对应波段的光强反射值乘以上述系数。该图可用于不同背景干扰下的多种异常目标探测。图2即为模拟数据与目标分布。

图3是采用目标植入式得到的模拟数据,首先选用森林作为背景数据,将图1中的四种地物分别插入到森林数据中(图3白色方框),每行异常目标由同种物质组成,其中第一列是由纯像元构成  $4 \times 4$  大小的目标,第二列包含了75%异常像元光谱特性和25%背景光谱特性  $3 \times 3$  大小的目标,第三列包含了50%异常像元光谱特性和50%背景光谱特性  $2 \times 2$  大小的目标,第四列包含了25%异常像元光谱特性和75%背景光谱特性  $1 \times 1$  大小的目标。该图可用于实际地物分布下多种不同大小目标的异常探测。

#### 4.2 实验及结果分析




图2 嵌入型数据第100波段灰度图和目标分布

Fig.2 Grey-scale map of 100 band image and the target distribution for TE data




图3 植入型数据第100波段灰度图和目标分布

Fig.3 Grey-scale map of 100 band image and the target distribution for TI data

利用多项式核函数,经多次实验对比,多项式阶次大于2时,检测性能趋向于一致,因此为了降低算法的计算复杂度,实验选取为阶次  $d=2$ 。需要注意的是,由于初始化过程需要计算矩阵的逆矩阵,为防止矩阵奇异性增大而出现病态矩阵,初始的像元总数必须大于高光谱数据的波段总数  $L$ 。

图4给出了6种算法对目标嵌入型数据的检测结果,其中传统RX算法全局和局部算法以及因果RX的全局和局部算法来源于参考文献中,KRX算法和RTKRXD算法选用的都是  $d=2$  的多项式核函数。对于全局RX和全局因果RX算法,最后一列没有检测到目标,其抗噪声能力是最差的,图4(d)、(e)是加窗之后的局部检测算法,虽然检测目标数有所增多,但是目标边缘容易淹没到噪声中。与RX算法相比,KRX算法和本文算法具有更强的抗噪声能力。

选用目标植入型数据,6种算法检测结果3D峰度图如图5所示。图5(a)中经典的RX算法检测到的目标数是最少的,增加了双窗模型的局部RX算子可以检测到更多的目标,但是双窗的大小难以确定。图5(c)、(d)由于选择窗口过小而导致检测概率低,而增大窗口尺寸则会导致协方差矩阵奇异性过大,检测精度降低,因此局部RX算法适应性不强。引入核机器学习的KRX算法可以充分地利用光谱各波段之间的非线性信息,通过非线性特性将目标和背景有效地分离,所使用的核函数仍然采用  $d=2$  的多项式核函数,KRX和RTKRXD可以有效地抑制背景,突出目标。




图4 嵌入型数据检测结果二值图。(a) RXD-global; (b) CRRXD-global; (c) KRX; (d) RXD-local; (e) CRRXD-local; (f) RTKRXD

Fig.4 Detection results of binary image contrast for TE data. (a) RXD-global; (b) CRRXD-global; (c) KRX; (d) RXD-local; (e) CRRXD-local; (f) RTKRXD

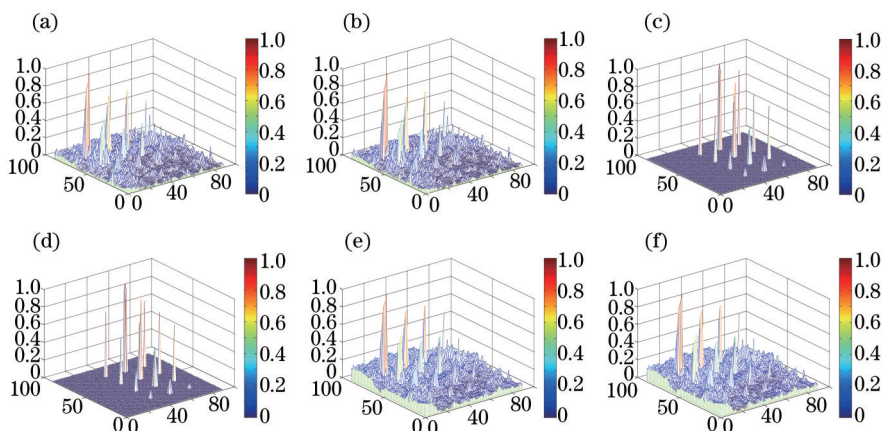


图5 植入型数据检测结果3D峰度图。(a) RXD-global; (b) CRRXD-global; (c) RXD-local; (d) CRRXD-local; (e) KRX; (f) RTKRXD

Fig.5 Detection results of 3D kurtosis image contrast for TI data. (a) RXD-global; (b) CRRXD-global; (c) RXD-local; (d) CRRXD-local; (e) KRX; (f) RTKRXD

接收机工作特性(ROC)曲线。来源于雷达中的接收机工作特性曲线,通过变化门限阈值,表述检测概率  $P_d$  与虚警概率  $P_f$  之间变化关系。虚警概率保持一致时,算法检测概率越高,其检测性能越好,因此,ROC曲线是检测性能定量分析中常用的方法。

对算法的定量评价如图6、7所示,相对于RX算法,KRX算法在同等虚警概率下具有较高的检测概率。在图6中,迭代算法和KRX算法具有相同的检测精度,图7是根据目标植入型数据得到的ROC曲线,由于背景更加复杂,检测效果都不是很理想,相比之下,RTKRXD算法的检测结果与KRX算法基本相同,检测精度较高,具有较好的稳健性。

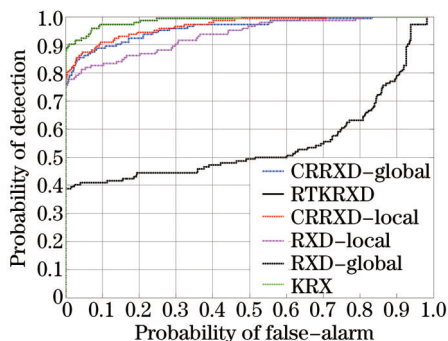


图6 嵌入型数据ROC曲线比较

Fig.6 Comparison of ROC curve for TE data

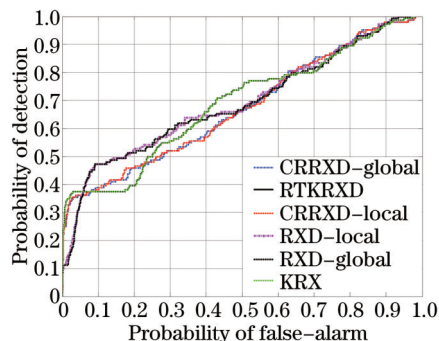


图7 植入型数据ROC曲线比较

Fig.7 Comparison of ROC curve for TI data

## 5 真实数据实验及分析

为验证算法在实际高光谱遥感数据中的适应性和有效性,采用真实高光谱数据为检测性能作定性分析,为算法的高效性作定量评价分析。

### 5.1 HYMAP 真实数据

图 8 是在 2006 年采集于美国蒙大拿州库克城市的高光谱遥感数据,该 HYMAP 高光谱成像仪覆盖了 0.45~2.5  $\mu\text{m}$  光谱范围,共计 126 个波段,该数据尺寸为  $280 \times 800$ ,地物分辨率为 3 m。




图 8 HYMAP 高光谱遥感数据

Fig.8 HYMAP hyperspectral remote sensing data

### 5.2 实验及结果分析

实验给出了 HYMAP 高光谱遥感真实数据的检测结果,其中局部算子采用了外窗大小  $13 \times 13$ ,内窗大小  $5 \times 5$  的双层窗口模型,其他算法参数与模拟数据实验相同。由于实际数据无法获得真实地物分布,所以无法通过 ROC 曲线定量评价,图 9 (a)~(f)分别为 6 种不同算法检测结果,其中图 9(a)传统全局 RX 算法结果中有很多虚警,且对目标的提取不理想,利用相关矩阵的因果 RX 算法具有较少的虚警点,但同时检测目标数也有所减少。局部 RX 算法可以有效地提取目标周围的背景信息,但是由于窗口重叠也导致了虚警点,且将边缘误检为目标。提出的 RTKRXD 算法与传统多项式核函数 KRX 算法具有基本相同的检测结果。




图 9 不同方法异常检测结果

Fig.9 Anomaly detection results by different methods

仿真实验采用的计算机硬件配置处理器为 Intel Core I7-4770,主频为 3.5 GHz,内存为 DDR3 16G,仿真软件为 Matlab 2014 版本。本文算法大大降低了检测过程中的计算复杂度,运行时间对比如图 10 所示,因为传统 KRX 算法检测利用之前像元信息,随着像元数据增多核矩阵的运算越来越复杂,所以传统的 KRX 算法运行时间随像元数的增加而线性增加,而提出的算法实现了核矩阵的迭代更新,避免了维度越来越高的运算,因此运

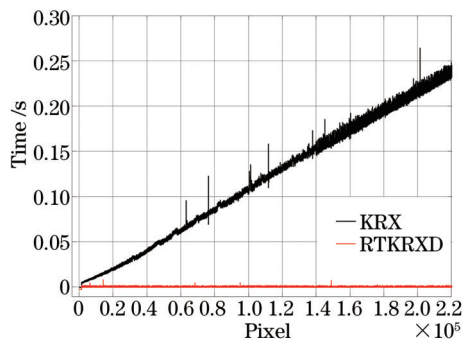


图 10 时间复杂度对比

Fig.10 Comparison of time complexity

行时间不会随像元数增加而增加,大大减少了算法执行时间。

## 6 结 论

提出了一种基于核机器学习的核递归高光谱目标快速检测算法,该方法引入了卡尔曼滤波递归思想,实现了核矩阵的递归更新,避免了核矩阵高维度计算。实验结果表明,与传统全局RX算法、局部RX算法、因果RX算法和传统基于高斯径向基核函数的KRX算法相比,在检测精度方面:本文算法在较低的虚警概率下具有较高的检测概率,可以从海量光谱信息中提取到更多的目标。在算法时间方面:本文算法大大减少了KRX算法检测的执行时间,且不会随着数据量的增大而增大,适应于尺寸更大、范围更广的高光谱遥感数据。此外,本文方法是一种不需要先验知识的异常检测算法,具有检测精度高、适应性好等特点。对于异常目标而言,检测过程中精度变化不大,但在非异常目标情况下,目标出现概率的增加和尺寸的增大将会导致检测精度的下降,进一步的工作考虑克服这种情况。

## 参 考 文 献

- 1 Tong Qingxi, Zhang Bing, Zheng Lanfen. Hyperspectral Remote Sensing—Principles, Techniques and Application[M]. Beijing: Higher Education Press, 2006: 228–234.  
童庆禧, 张 兵, 郑兰芬. 高光谱遥感—原理、技术与应用[M]. 北京: 高等教育出版社, 2006: 228–234.
- 2 Wu Yiquan, Zhou Yang, Long Yunlin. Small target detection in hyperspectral remote sensing image based on adaptive parameter svm [J]. Acta Optica Sinica, 2015, 35(9): 0928001.  
吴一全, 周 杨, 龙云淋. 基于自适应参数支持向量机的高光谱遥感图像小目标检测[J]. 光学学报, 2015, 35(9): 0928001.
- 3 Tang Yi, Wan Jianwei, Nian Yongjian. Distributed near lossless compression of hyperspectral images[J]. Acta Optica Sinica, 2015, 35(3): 0310001.  
汤 毅, 万建伟, 粘永健. 高光谱图像的分布式近无损压缩[J]. 光学学报, 2015, 35(3): 0310001.
- 4 Wang Xiaofei, Yan Qiuqing, Zhang Junping, *et al.*. Super-resolution reconstruction algorithm based on relevance vector machine for hyperspectral image[J]. Chinese J Lasers, 2014, 41(s1): s114001.  
王晓飞, 阎秋静, 张钧萍, 等. 基于相关向量机的高光谱图像超分辨率算法[J]. 中国激光, 2014, 41(s1): s114001.
- 5 Wang Xiaofei, Yan Qiuqing. An ensemble learning algorithm for one-class classification of hyperspectral images[J]. Acta Optica Sinica, 2014, 34(s2): s211002.  
王晓飞, 阎秋静. 基于集成学习的高光谱图像一类分类算法[J]. 光学学报, 2014, 34(s2): s211002.
- 6 Fan Liheng, Lv Junwei, Deng Jiangsheng. Classification of hyperspectral remote sensing images based on bands grouping and classification ensembles[J]. Acta Optica Sinica, 2014, 34(9): 0910002.  
樊利恒, 吕俊伟, 邓江生. 基于分类器集成的高光谱遥感图像分类方法[J]. 光学学报, 2014, 34(9): 0910002.
- 7 Zhang L, Zhang L, Tao D, *et al.*. Hyperspectral remote sensing image subpixel target detection based on supervised metric learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(8): 4955–4965.
- 8 Yuan Y, Wang Q, Zhu G. Fast Hyperspectral Anomaly Detection via High-Order 2-D Crossing Filter[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(2): 620–630.
- 9 Reed I S, Yu X L. Fast 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.
- 10 Acito N, Matteoli S, Diani M, *et al.*. Complexity-aware algorithm architecture for real-time enhancement of local anomalies in hyperspectral images[J]. Journal of Real-Time Image Processing, 2013, 8(1): 53–68.
- 11 Wang T, Du B, Zhang L. A kernel-based target-constrained interference-minimized filter for hyperspectral sub-pixel target detection [J]. Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2013, 6(2): 626–637.
- 12 Hsueh M, Chang C I. Adaptive causal anomaly detection for hyperspectral imagery[C]. IEEE International Symposium on Geoscience and Remote Sensing, Anchorage, 2004, 5: 3222–3224.
- 13 Matteoli S, Veracini T, Diani M, *et al.*. A locally adaptive background density estimator: An evolution for rx-based anomaly detectors[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(1): 323–327.
- 14 Chen S Y, Wang Y, Wu C C, *et al.*. Real-time causal processing of anomaly detection for hyperspectral imagery[J]. IEEE Transactions on Aerospace and Electronic Systems, 2014, 50(2): 1511–1534.



- 15 Wang Y, Zhao C, Chang C I. Anomaly detection using sliding causal windows[C]. IEEE International Symposium on Geoscience and Remote Sensing, Anchorage, 2014: 4600-4603.
- 16 Du Q, Nekovei R. Fast real-time onboard processing of hyperspectral imagery for detection and classification[J]. Journal of Real-Time Image Processing, 2009, 4(3): 273-286.
- 17 Kwon H, Nasrabadi N. Fast real-time onboard processing of hyperspectral imagery for detection and classification[J]. IEEE Geoscience and Remote Sensing Letters, 2006, 3(2): 271-275.
- 18 Gu Y, Zhang L. Rare signal component extraction based on kernel methods for anomaly detection in hyperspectral imagery[J]. Neurocomputing, 2013, 108(2): 103-110.
- 19 Zhang Xianda. Matrix Analysis and Applications[M]. Beijing: Tsinghua University Press, 2004.  
张贤达. 矩阵分析与应用[M]. 北京: 清华大学出版社, 2004.

栏目编辑: 苏 岑