

文章编号: 1001-9014(2010)05-0378-05

# 核加权 RX 高光谱图像异常检测算法

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

(1. 哈尔滨工程大学 信息与通信工程学院, 哈尔滨 黑龙江 150001;

2. 北京理工大学 机电学院, 北京 100081)

**摘要:**提出了一种新的基于混合核函数的加权 RX 算法,用于高光谱图像异常检测.在将原始高光谱数据非线性映射到高维特征空间以挖掘高光谱图像波段间蕴含的非线性信息后,自适应地赋予特征空间 RX 算子中采样协方差矩阵各光谱向量相应的权值.权值的大小与光谱向量到质心的距离成反比,从而削减了协方差矩阵中异常数据比重,使加权协方差矩阵更好地表征背景数据分布.最后利用核函数性质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,并根据高光谱数据特点线性组合新型光谱核函数和径向基核函数以改善算法性能.为验证算法的有效性,利用真实的高光谱数据进行了仿真实验,结果表明该算法优于特征空间的 RX 算法,能检测到更多的异常目标.

**关键词:**高光谱图像;异常检测;加权 RX;核函数

**中图分类号:**TN911.73 **文献标识码:**A

## A KERNEL WEIGHTED RX ALGORITHM FOR ANOMALY DETECTION IN HYPERSPECTRAL IMAGERY

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

(1. College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China;

2. College of Mechanical and Electrical, Beijing Institute of Technology, Beijing 100081, China)

**Abstract:** A new mixed kernel function weighted RX algorithm for anomaly detection in hyperspectral imagery was proposed. First, each spectral pixel was mapped into a high-dimensional feature space by a nonlinear mapping function. Second the nonlinear information between different spectral bands of the hyperspectral imagery was exploited with the RX algorithm in the feature space. In order to optimize the covariance matrix, each pixel in the covariance matrix was weighted according to its centroid distance. In this way the weighted covariance matrix could represent the background distribution better. Finally, the dot product computation in the high-dimensional feature space were converted into the kernel computation in the low dimensional input space. The new spectral kernel function and the radial basis kernel function were composited according to the characteristic of hyperspectral data to improve the performance of the proposed algorithm. To validate the effectiveness of the proposed algorithm, experiments were conducted on real hyperspectral data. The results show that the proposed method can detect more anomaly targets than the RX algorithm in the feature space.

**Key words:** hyperspectral imagery; anomaly detection; weighted RX; kernel functions

### 引言

高光谱图像是图谱合一的数据,具有极高的光谱分辨率,高光谱遥感在地理信息系统、地物分类、精准农业以及目标检测方面有着广泛的应用.目前,高光谱图像目标检测已成为高光谱数据处理最为活跃的研究方向.通常的高光谱检测算法是基于光谱

维处理,在对高光谱数据进行特征提取后由 CFAR (constant false-alarm rate) 准则分离出目标,如 Scharf 提出的 MSD (Match Subspace Detector) 算法<sup>[1]</sup>, Harsanyi 提出的正交子空间算法<sup>[2]</sup>等,这些算法在许多应用中取得了较好的结果,但需要目标的先验光谱信息.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和背景先验

收稿日期:2009-01-14,修回日期:2009-09-10

Received date: 2009-01-14, revised date: 2009-09-10

基金项目:国家自然科学基金(61077079);哈尔滨市优秀学科带头人基金资助(2009RFXXG034)

作者简介:赵春晖(1965-),男,黑龙江哈尔滨人,教授,博士生导师.主要研究领域为高光谱图像处理、智能信息处理技术、图像处理、非线性滤波等. Email: zhaochunhui@hrbeu.edu.cn.

通讯作者: E-mail: lijie@bit.edu.cn.

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,逐渐成为了研究的热点<sup>[3-7]</sup>.异常检测中异常点的光谱特性与邻近点光谱特性不同,由于没有目标光谱信息可以利用,主要依靠计算局部区域的统计变化来实现目标检测.经典的异常检测算法是由Reed和Yu提出的基于广义似然比检验的RX算法<sup>[8]</sup>,在背景和背景满足高斯分布的假设前提下通过计算马氏距离查找异常点;随后Chang等人对RX算法进行了改进,提出了因果RX、实时RX等一系列改进检测算子,有效地提高了目标检测的效率<sup>[9,10]</sup>,但它们都仅利用了高光谱数据的低阶统计特性,忽视了高光谱数据几百个波段中所含有的丰富的非线性信息.为此,Kwon等人提出了基于核的非线性RX算法<sup>[11]</sup>,将高光谱数据映射到高维特征空间后进行异常点的检测,挖掘了高光谱图像波段间的非线性统计特性;但该方法同样存在着一定的缺陷,即若实际背景数据为病态分布或协方差矩阵中异常点数目超过一定的比例时,协方差矩阵将不能很好地表征背景数据的分布;另外在利用径向基核函数对特征空间数据进行转化时,仅考虑了光谱向量的能量差异,忽略了同种地物因光强、阴影等自然因素而引起的能量差异对检测精度的影响.为了解决这些问题,本文提出了一种基于混合核函数的特征空间加权RX异常检测算法.

## 1 RX异常检测算法

RX算法是源于多光谱图像异常检测的经典目标检测算法,本质上可以看作主成分分析(PCA)的逆过程.RX算法假定目标光谱和背景的协方差未知,它以图像中的每个像素为中心,确定局部检测窗口,并建立二值假设: $\mathbf{H}_0$ 代表目标不存在、 $\mathbf{H}_1$ 代表目标存在.

$$\begin{aligned} \mathbf{H}_0: \mathbf{x} &= \mathbf{n} \\ \mathbf{H}_1: \mathbf{x} &= a\mathbf{s} + \mathbf{n} \end{aligned} \quad (1)$$

式中 $a > 0$ , $\mathbf{n}$ 和 $\mathbf{s}$ 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 $N(\boldsymbol{\mu}_b, \mathbf{C}_b)$ 和 $N(\boldsymbol{\mu}_s, \mathbf{C}_s)$ ,其中 $\boldsymbol{\mu}_b$ 、 $\boldsymbol{\mu}_s$ 分别为局部检测窗口内的背景均值和异常目标均值, $\mathbf{C}_b$ 为背景协方差.RX算子简化的判决表达式为

$$\text{RX}(\mathbf{r}) = (\mathbf{r} - \hat{\boldsymbol{\mu}}_b)^T \hat{\mathbf{C}}_b (\mathbf{r} - \hat{\boldsymbol{\mu}}_b) \stackrel{H_1}{\underset{H_0}{\gtrless}} \eta \quad (2)$$

向量 $\mathbf{r}$ 为待检测光谱信号, $\hat{\boldsymbol{\mu}}_b$ 、 $\hat{\mathbf{C}}_b$ 分别为背景均值和

协方差矩阵的估计值, $\eta$ 为判决阈值.通过检测窗口的滑动就可对所有像素点进行判决,进而得到一幅异常点二值图.

## 2 核加权RX算法

RX算法忽视了高光谱图像波段之间很强的相关特性,而且真实场景中数据服从高斯分布的假设很难满足;而将原始输入空间光谱信号非线性映射到高维特征空间中进行异常点检测,一方面可以挖掘光谱波段间的非线性信息;另一方面特征空间中数据的高斯分布假设意味着输入空间数据分布的复杂化,从而更接近真实情况,因而能更好地分离背景和目标.

### 2.1 特征空间加权RX算法

设高光谱图像波段数为 $J$ ,则检测窗口中的 $N$ 个向量可以用一 $J \times N$ 的矩阵 $\mathbf{X}_b = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$ 来表示,其中 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{iJ}]^T$ .在利用非线性映射函数 $\Phi$ 将 $\mathbf{X}_b$ 映射到高维特征空间得 $\Phi(\mathbf{X}_b) = [\Phi(\mathbf{x}_1), \Phi(\mathbf{x}_2), \dots, \Phi(\mathbf{x}_N)]$ 后,相应的特征空间中RX算法的表达式为:

$$\text{KRX}(\Phi(\mathbf{r})) = (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_{b\Phi})^T \hat{\mathbf{C}}_{b\Phi}^{-1} (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_{b\Phi}) \quad (3)$$

式中 $\hat{\mathbf{C}}_{b\Phi}$ 和 $\hat{\boldsymbol{\mu}}_{b\Phi}$ 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:

$$\hat{\mathbf{C}}_{b\Phi} = \sum_{i=1}^N (\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_{b\Phi})(\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_{b\Phi})^T / N \quad (4)$$

$$\hat{\boldsymbol{\mu}}_{b\Phi} = \sum_{i=1}^N \Phi(\mathbf{x}_i) / N \quad (5)$$

通常情况下,异常点数目较少且背景是统计均一的,因此可近似认为检测窗口内数据的协方差矩阵 $\hat{\mathbf{C}}_{b\Phi}$ 就是背景的协方差矩阵.由式(4)可看出:协方差矩阵中各像素被赋予的权值是相等的(都为1),因此当协方差矩阵中异常点数目超过一定的比例或数据呈病态分布时,协方差矩阵将不能很好地表征背景数据的分布,进而降低目标检测性能.为解决这个问题,本文算法以协方差矩阵中各光谱向量与数据质心的距离为衡量准则,自适应地赋予协方差矩阵中各光谱向量不同的权值.权值的大小与距离的远近成反比,因而降低了异常数据在协方差矩阵中所占的比重,使协方差矩阵能更好地表征背景数据分布.改进的加权协方差表达式为:

$$\hat{\mathbf{C}}_w = \sum_{i=1}^N w_i (\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_w)(\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_w)^T / \sum_{i=1}^N w_i \quad (6)$$

$$\hat{\boldsymbol{\mu}}_w = \sum_{i=1}^N q_i \Phi(\mathbf{x}_i) / \sum_{i=1}^N q_i \quad (7)$$

式中 $w_i = 1/(1 + \|\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_w\|)$ 、 $q_i = 1/(1 +$

$\|\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_{w\Phi}\|$ ) 为光谱向量权值. 则特征空间加权 RX 算法表达式为:

$$\text{WRX}(\Phi(\mathbf{r})) = (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_w)^T \hat{\mathbf{C}}_w (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_w) \quad (8)$$

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, 需借助核函数技术对式(8)进行变形, 即利用核函数性质:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j) \quad (9)$$

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.

## 2.2 特征空间加权 RX 算法的核函数化

背景协方差估计矩阵  $\hat{\mathbf{C}}_w$  是一对称阵, 根据谱分解理论<sup>[12]</sup>, 可对其进行特征值分解.

$$\begin{aligned} \hat{\mathbf{C}}_w &= \sum_{i=1}^N w_i (\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_w) (\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_w)^T / \sum_{i=1}^N w_i \\ &= \sum_{i=1}^N [\sqrt{w_i} (\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_w)] [\sqrt{w_i} (\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_w)]^T / W \\ &= \mathbf{V}_\Phi \boldsymbol{\Lambda}_\Phi \mathbf{V}_\Phi^T \quad (W = \sum_{i=1}^N w_i) \quad (10) \end{aligned}$$

式中  $\boldsymbol{\Lambda}_\Phi = \text{diag}([\lambda_1, \lambda_2, \dots, \lambda_N])$  为协方差矩阵  $\hat{\mathbf{C}}_w$  的  $N$  个非零特征值构成的对角阵,  $\mathbf{V}_\Phi = [\mathbf{v}_\Phi^1, \mathbf{v}_\Phi^2, \dots, \mathbf{v}_\Phi^N]$  为对应的特征向量矩阵, 它们的对应关系可描述为:

$$\begin{aligned} \lambda_l \mathbf{v}_\Phi^l &= \hat{\mathbf{C}}_w \mathbf{v}_\Phi^l = \sum_{i=1}^N \Phi_w(\mathbf{x}_i) \Phi_w(\mathbf{x}_i)^T \mathbf{v}_\Phi^l / W \\ &= \sum_{i=1}^N \langle \Phi_w(\mathbf{x}_i), \mathbf{v}_\Phi^l \rangle \Phi_w(\mathbf{x}_i) / W \quad (11) \end{aligned}$$

式(11)表明任一特征向量  $\mathbf{v}_\Phi^l$  均在特征空间加权中心化数据  $\{\Phi_w(\mathbf{x}_i) = \sqrt{w_i} (\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_w)\}_{i=1}^N$  的度量空间内, 即存在系数向量  $\boldsymbol{\alpha}_l = [\alpha_{l1}, \alpha_{l2}, \dots, \alpha_{lN}]$ , 使得

$$\mathbf{v}_\Phi^l = \sum_{i=1}^N \alpha_{li} \Phi_w(\mathbf{x}_i) = \mathbf{X}_{w\Phi} \boldsymbol{\alpha}_l \quad (12)$$

进一步可得  $\mathbf{V}_\Phi = \mathbf{X}_{w\Phi} \mathbf{U}$ , 式中  $\mathbf{U} = [\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \dots, \boldsymbol{\alpha}_N]$ ,  $\mathbf{X}_{w\Phi} = [\Phi_w(\mathbf{x}_1), \Phi_w(\mathbf{x}_2), \dots, \Phi_w(\mathbf{x}_N)]$ . 将式(12)代入式(11), 并在等式两边均乘上  $\Phi_w(\mathbf{x}_n)^T$ , 得

$$\begin{aligned} \lambda_l \sum_{i=1}^N \alpha_{li} \Phi_w(\mathbf{x}_i) \Phi_w(\mathbf{x}_n)^T \\ = \frac{1}{W} \sum_{i=1}^N \alpha_{li} \langle \Phi_w(\mathbf{x}_i), \sum_{j=1}^N \Phi_w(\mathbf{x}_j) \langle \Phi_w(\mathbf{x}_j), \Phi_w(\mathbf{x}_i) \rangle \rangle \quad (13) \end{aligned}$$

定义  $N \times N$  的核矩阵  $\mathbf{K}_w ((\mathbf{K}_w)_{ij} = \langle \Phi_w(\mathbf{x}_i), \Phi_w(\mathbf{x}_j) \rangle)$ , 则可将上式转化为:

$$W \lambda_l \boldsymbol{\alpha}_l = \mathbf{K}_w \boldsymbol{\alpha}_l \quad (14)$$

由此可知核矩阵  $\mathbf{K}_w$  的特征值为协方差矩阵  $\mathbf{C}_w$  特征值的  $W$  倍, 那么对称阵  $\mathbf{K}_w$  的特征值分解可写为:  $\mathbf{K}_w = \mathbf{U} \boldsymbol{\Lambda}_w \mathbf{U}^T = \mathbf{W} \mathbf{U} \boldsymbol{\Lambda}_\Phi \mathbf{U}^T$  ( $\boldsymbol{\Lambda}_w$  为  $\mathbf{K}_w$  的特征值构成的对角阵), 由此可得  $\hat{\mathbf{C}}_w$  伪逆矩阵与  $\mathbf{K}_w$  逆阵的关

系为:

$$\begin{aligned} \hat{\mathbf{C}}_w^\# &= \mathbf{V}_\Phi \boldsymbol{\Lambda}_\Phi^{-1} \mathbf{V}_\Phi^T \\ &= \mathbf{X}_{w\Phi} \mathbf{U} \boldsymbol{\Lambda}_\Phi^{-1} \mathbf{U}^T \mathbf{X}_{w\Phi}^T \quad (15) \\ &= \mathbf{W} \mathbf{X}_{w\Phi} \mathbf{K}_w^{-1} \mathbf{X}_{w\Phi}^T \end{aligned}$$

将式(15)代入式(8), 得:

$$\begin{aligned} \text{WRX}(\Phi(\mathbf{r})) &= (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_w)^T \hat{\mathbf{C}}_w (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_w) \\ &= W (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_w)^T \mathbf{X}_{w\Phi} \mathbf{K}_w^{-1} \mathbf{X}_{w\Phi}^T (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_w) \quad (16) \end{aligned}$$

上式中  $\mathbf{K}_w$  为特征空间加权中心化数据核矩阵, 由于映射函数  $\Phi$  未知, 使  $\Phi_w(\mathbf{x})$  对应的输入空间数据无法获得, 因此需用输入空间未中心化数据  $\mathbf{X}_b$  的核矩阵  $\mathbf{K}_o ((\mathbf{K}_o)_{ij} = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle = k(\mathbf{x}_i, \mathbf{x}_j))$  来计算  $\mathbf{K}_w$ . 由文献[12]中核矩阵运算法则可推得:

$$\begin{aligned} \mathbf{K}_w &= \mathbf{B} (\mathbf{K}_o - \mathbf{K}_o \mathbf{q} / Q - \mathbf{I}^T \mathbf{q}^T \mathbf{K}_o / Q + \mathbf{I}^T \mathbf{q}^T \mathbf{K}_o \mathbf{q} / Q^2) \mathbf{B} \\ &= \mathbf{B} \mathbf{K}_c \mathbf{B} \quad (Q = \sum_{i=1}^N q_i) \quad (17) \end{aligned}$$

式中  $\mathbf{I}$  是元素均为 1 的列向量,  $\mathbf{q} = [q_1, q_2, \dots, q_N]^T$  为均值加权系数列向量,  $\mathbf{B} = \text{diag}([w_1, w_2, \dots, w_N])$  为协方差矩阵中各向量加权系数构成的对角阵.  $q_i$ 、 $w_i$  的大小取决于特征空间数据到对应质心的距离, 将它们转换为低维输入空间的核函数运算, 得:

$$\begin{aligned} w_i &= 1 / (1 + \|\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_w\|) = 1 / (1 + \sqrt{(\mathbf{K}_c)_{ii}}) \\ q_i &= 1 / (1 + \|\Phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_{b\Phi}\|) = 1 / (1 + \sqrt{(\mathbf{K}_c)_{ii}}) \quad \text{其中 } \mathbf{K}_c (\mathbf{K}_c = \mathbf{K}_o - \mathbf{I} \mathbf{I}^T \mathbf{K}_o / N - \mathbf{K}_o \mathbf{I} \mathbf{I}^T / N + \mathbf{I}^T \mathbf{K}_o \mathbf{I} \mathbf{I}^T / N^2) \text{ 为输入空间中心化数据核矩阵}^{[12]}. \end{aligned}$$

分析式(16), 可知  $\Phi(\mathbf{r})^T \mathbf{X}_{w\Phi}$ 、 $\hat{\boldsymbol{\mu}}_w^T \mathbf{X}_{w\Phi}$  也为特征空间的内积, 将其核函数化得:

$$\begin{aligned} \Phi(\mathbf{r})^T \mathbf{X}_{w\Phi} &= \Phi(\mathbf{r})^T ([\Phi(\mathbf{x}_1), \Phi(\mathbf{x}_2), \dots, \Phi(\mathbf{x}_N)] - \hat{\boldsymbol{\mu}}_w) \mathbf{B} \\ &= (\mathbf{K}(\mathbf{X}_b, \mathbf{r})^T - \mathbf{K}(\mathbf{X}_b, \mathbf{r})^T \mathbf{q} / Q) \mathbf{B} = \mathbf{K}_r^T \quad (18) \end{aligned}$$

$$\begin{aligned} \hat{\boldsymbol{\mu}}_w^T \mathbf{X}_{w\Phi} &= \sum_{i=1}^N q_i k(\mathbf{x}_i, \mathbf{r}) / Q ([\Phi(\mathbf{x}_1), \Phi(\mathbf{x}_2), \dots, \Phi(\mathbf{x}_N)] - \hat{\boldsymbol{\mu}}_w) \mathbf{B} \\ &= (\mathbf{K}_o^T \mathbf{q} / Q - \mathbf{q}^T \mathbf{K}_o \mathbf{q} / Q^2) \mathbf{B} = \mathbf{K}_\mu^T \quad (19) \end{aligned}$$

由此可得高维特征空间加权 RX 算法的核函数表达式为:

$$\text{WRX}(\Phi(\mathbf{r})) = W (\mathbf{K}_r^T - \mathbf{K}_\mu^T) \mathbf{K}_w^{-1} (\mathbf{K}_r - \mathbf{K}_\mu) \quad (20)$$

因此只需选择合适的核函数来构造一个正定的核矩阵  $\mathbf{K}_w$ , 就可在映射函数  $\Phi$  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特征空间加权 RX 算法 (WRX 算法) 和未加权 RX 算法 (KRX 算法) 的输出等高线 (代表不同阈值下的决策边界) 图, 可以看出 WRX 算法较 KRX 算法有更好的区分识别能力.




图1 高斯数据下两种算法输出等高线图 (a) WRX (b) KRX

Fig.1 Contour plots of two algorithms for Gaussian data (a) Contour plot of WRX (b) Contour plot of KRX

### 2.3 核函数的改进

核函数的选择对算法的性能非常重要,因为核函数形式和参数的变化会隐式地改变输入空间到特征空间的映射,进而对特征空间的性质产生影响,最终改变核函数方法的性能.常用核函数主要有两种类型:局部性核函数和全局性核函数.

高光谱图像中,光照强度、阴影等自然因素会使同种地物的光谱能量存在较大差异,因此构造核函数时也应考虑地物的光谱形状信息.光谱角函数利用光谱信号之间的夹角来衡量光谱曲线的形状差异,且它对光谱能量是鲁棒的,所以可由其构造新型光谱核函数  $k_s(k_s(\mathbf{x}, \mathbf{x}_i) = \cos^{-1}((\mathbf{x} \cdot \mathbf{x}_i) / (\|\mathbf{x}\| \cdot \|\mathbf{x}_i\|)))$ .  $k_s$  是基于点乘运算的全局核函数,地物光谱曲线差异越大,对应的核函数值越大.本文将 RBF 核函数  $k_r$  和光谱核函数  $k_s$  组合在一起,构造混合核函数  $k_m$ :

$$k_m = \beta k_s + (1 - \beta) k_r \quad (0 < \beta < 1) \quad (21)$$

由上式可以看出核函数  $k_m$  的构造既考虑了地物的光谱能量信息,也考虑了地物的光谱形状信息,因而更符合高光谱数据特性.

### 3 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,去掉受噪声和水汽吸收较明显的谱段,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 波段图像及定位后的目标分布图如图 2 所示.

实验中,在对高光谱数据进行归一化后,根据图像的空间大小和分辨率,将 WRX 算法背景检测窗口大小设为  $11 \times 11$  像素,目标检测窗口设为  $3 \times 3$




图2 高光谱第 1 波段图像及相应的目标分布

Fig.2 First band of hyperspectral imagery and the corresponding distribution of targets




图3 两种方法下的阈值分割图 (a) WRX (b) KRX

Fig.3 Detection results of two methods after thresholding (a) the proposed WRX (b) KRX

像素.在混合核函数形式确定以后,核函数参数的选择是至关重要的,参数选择得当可以使数据的所有变化都体现在核函数中.通过多次实验,文中将混合核函数中径向基核函数的宽度  $c$  定为 40,线性加权系数  $\beta$  置为 0.58.

图 3(a) 描述了本文核加权 RX 算法 (WRX 算法) 最终的异常点二值图.为了便于分析比较,实验中也进行了特征空间传统 RX 算法 (KRX 算法) 实验.其给定阈值下最终检测效果如图 3(b) 所示.由图 3 可看出本文算法所获得的检测结果要好于 KRX 算法,尽管 KRX 算法和 WRX 算法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异常数据对背景协方差矩阵的影响,因而在检测目标数目相同的情况下,WRX 算法有更低的虚警.这充分说明本文 WRX 算法在有效利用高光谱图像非线性信息的同时较好地抑制了异常数据对背景协方差矩阵的干扰.

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.图 4 给出了 WRX 算法和 KRX 算





图4 两种算法的 ROC 比较

Fig. 4 ROC comparison of two algorithms

图5 不同  $\beta$  取值下检测目标数目Fig. 5 The number of detected targets of different  $\beta$ 

法 ROC 特性的比较,可以看出,WRX 算法有效地解决了 KRX 算法中异常数据对表征背景数据分布的协方差矩阵的影响,具有良好的检测性能和较低的虚警。

图 5 绘出了 WRX 算法检测到的真实目标个数随混合核函数加权系数  $\beta$  的变化曲线,可以看出,选择适当的系数  $\beta$ ,可以极大地改善算法的性能,相比与使用单一光谱核函数 ( $\beta = 0$ ) 或单一径向基核函数 ( $\beta = 1$ ),使用混合核函数能检测到更多的真实异常目标。

#### 4 结论

提出了一种基于混合核函数的高光谱图像特征空间加权 RX 算法,通过理论分析和真实数据检验,算法既挖掘了高光谱图像波段间蕴含的非线性信息又抑制了异常点对背景数据分布的干扰,并能有效地降低光照、阴影等自然因素对检测精度的影响,检

测性能和虚警概率相对于特征空间传统 RX 算法有了较大的改善,是一种比较实用的高光谱图像目标异常检测算法。

#### REFERENCES

- [1] Scharf L L, Friedlander B. Matched subspace detectors [J]. *IEEE Trans. on signal processing*, 1994, **42** (8): 2146—2157.
- [2] Harsanyi J C, Chein-I Chang. 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, LIU 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] Reed I S, Yu X. Adaptive Multiple-band CFAR Detection of an optical pattern with unknown spectral distribution [J]. *IEEE Trans. Acoust., Speech Singal Process.* 1990, **38** (10): 1760—1770.
- [9] Chang Chein-I, Chiang Shao-Shan. Anomaly detection and classification for hyperspectral imagery [J]. *IEEE Trans. on Geoscience and Remote Sensing*. 2002, **40** (6): 1314—1325.
- [10] Chein-I Chang, Hsuan Ren, Shao-Shan Chiang. Real-time processing algorithms for target detection and classification in hyperspectral imagery [J]. *IEEE Trans. on Geoscience and Remote Sensing*. 2001, **39** (4): 760—768.
- [11] Heesung Kwon, Nasser M Nasrabadi. Kernel RX- Algorithm: a nonlinear anomaly detector for hyperspectral imagery [J]. *IEEE Trans. Geoscience and Remote Sensing*. 2005, **43** (2): 388—397.
- [12] Taylor J S, Cristianini N. *Kernel Methods for Pattern Analysis* [M]. Cambridge: Cambridge University, 2004.