

文章编号:1004-4213(2010)10-1830-6

# 一种背景误差累积的高光谱图像异常检测算法\*

赵春晖,胡春梅<sup>†</sup>,包玉刚

(哈尔滨工程大学 信息与通信工程学院 哈尔滨 150001)

**摘 要:**针对背景信息对高光谱图像异常检测的强干扰问题,提出了一种背景误差累积的异常检测算法.该算法通过构造背景子空间,利用各像素到该子空间的正交投影,得到有效抑制背景并突显目标的背景误差数据,用于后续的异常目标检测.最后用真实的高光谱数据进行仿真实验,理论分析比较和实验结果表明该算法具有较好的检测效果.

**关键词:**高光谱图像;主成分分析;正交子空间;背景误差数据;异常检测

中图分类号:TN911.71

文献标识码:A

doi:10.3788/gzxb20103910.1830

## 0 引言

高光谱图像具有“图谱合一”特性,成像波段密集且连续,具有很高的光谱分辨率,所以高光谱遥感成为地面信息获取,低空间分辨率目标检测的有力工具<sup>[1]</sup>.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(Spectral Angle Mapping, SAM)<sup>[2]</sup>、正交子空间算法(Orthogonal Subspace Project, OSP)<sup>[3]</sup>、约束能量最小化算法(Constrained Energy Minimization, CEM)<sup>[4]</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在很多实际情况下难以获得,因此,不需目标先验信息,而能直接检测出与周围景物光谱存在明显差异的光谱信号所在位置作为异常点的异常检测算法更符合实际需求,对于未知场景中光谱特性未知目标的检测识别具有重要意义<sup>[5]</sup>.常用的异常检测算法主要有RX(Reed & Yu)检测算法<sup>[2]</sup>,低概率检测算法(Low Probability Detection, LPD)<sup>[6]</sup>等.

由于高光谱图像成像波段密集且连续,所以相邻波段之间具有很大的相关性,即数据中包含了大量的冗余信息.为了去除这些冗余信息,本文采用了自适应子空间分解(Adapter Subspace Decomposition, ASD)算法,将一组多维的高光谱数

据根据波段间的相关性划分成多组波段子集数据,并分别对每一波段子集进行特征提取,去除波段之间的相关性,这样使得高光谱数据的可分性分散到了各波段子集上.为了减小背景信息对目标检测的干扰,本文利用主成分分析(Principal Component Analysis, PCA)算法获得主成分来构造背景子空间,将每个波段子集的数据分别正交投影到各自的背景子空间上,得到含有丰富目标信息的背景误差数据,继而在背景误差数据上采用非线性核RX算法完成每个波段子集的异常目标检测,最后对这些检测结果进行累积处理,从而达到有效检测目标的目的.

## 1 算法与原理

### 1.1 自适应子空间分解

高光谱图像的光谱分辨率很高,所构成的光谱响应曲线几乎是连续的.这样,邻近波段的高光谱数据在相应的空间位置上具有相近的光谱特性,即相近波段图像具有较大相关性,某个包含数个连续波段的波段子集包含了图像数据中的某些局部光谱特性.本文首先构造各波段光谱向量,即各波段图像上的所有像素构成一个列向量,计算任意两个波段之间的相关系数,得到相关系数矩阵,从相关系数矩阵可以看出,高光谱数据波段之间的相关性呈现块状<sup>[7]</sup>.利用可传递相关向量进行处理,得到相邻波段之间的相关系数(如图1所示).从中提取局部相关的极小值,在相关性极小值小于阈值处,将一组多维的高光谱数据分为若干个波段子集,从而减小相关性较小波段对处理结果的影响.

\* 高等学校博士学科点基金(20060217021)、黑龙江省自然科学基金(ZJG0606-01)和哈尔滨市优秀学科带头人基金(2009RFXG034)资助

<sup>†</sup> Tel:0451-82569810 Email:huchunmei5431@163.com

收稿日期:2009-09-09

修回日期:2009-11-09

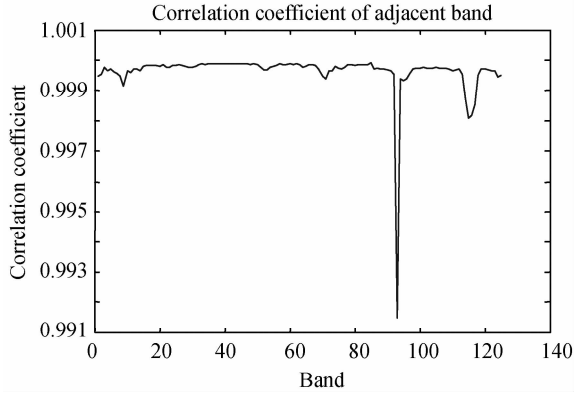


图1 高光谱图像相邻波段之间的相关系数

Fig. 1 Correlation coefficient of adjacent bands for hyperspectral image

## 1.2 主成分分析算法

对高光谱数据进行目标检测时,其数据量往往是惊人的,因此在检测之前,需要进行必要的预处理.根据高光谱数据的特点,可去除其相关性引起的冗余信息.而主成分分析是均方差最小意义上的最佳正交变化,它能使变换后产生的新分量正交或者不相关,均方差最小且能量最集中<sup>[8]</sup>.

原始高光谱数据是一个立方体数据,故必须在PCA之前将其整理成二维数据,各个波段数据均可看作是一个采样向量,采样样本的数目为波段的数目 $L$ ,即将高光谱图像数据整理成 $L \times N$ 矩阵 $\mathbf{X}$ , $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$ ,其中 $\mathbf{x}_i$ 代表一个像素点,每行代表一个波段, $N$ 为每个波段的像素数.估算矩阵 $\mathbf{X}$ 的协方差矩阵 $\mathbf{C}$ ,并将估算的背景协方差矩阵进行特征值分解: $\mathbf{C}=\mathbf{V}\mathbf{\Lambda}\mathbf{V}^T$ ,其中:

$$\mathbf{\Lambda} = \begin{bmatrix} \lambda_1 & & & \\ & \lambda_1 & & \\ & & \dots & \\ & & & \lambda_L \end{bmatrix}, \mathbf{V} = [\mathbf{V}_1, \mathbf{V}_2, \dots, \mathbf{V}_L],$$

$\mathbf{\Lambda}$ 的对角元素为背景协方差矩阵 $\mathbf{C}$ 的非零特征值 $\lambda_i$ , $\mathbf{V}$ 的各列为非零特征值所对应的特征向量 $\mathbf{V}_i$ .由于其特征值是一个对角阵,所以其各特征向量之间是相互正交的,或者是不相关的<sup>[8]</sup>.将采样数据 $\mathbf{X}$ 投影到特征向量 $\mathbf{V}$ 上,得到的新分量 $\mathbf{Y}=\mathbf{V}^T \cdot \mathbf{X}$ 之间即为正交的或者不相关的.

## 1.3 背景误差累积的核RX算法

基于背景误差累积的核RX检测(Kernel RX Based on Background Error Cumulation, BECKRX)算法分为三个步骤:一是背景信息的提取;二是在背景误差数据上进行高维特征空间的核RX检测;三是检测结果的累积操作.该算法不直接提取目标光谱信息,而是通过构造背景正交子空间来间接的突出目标.对于投影到背景正交子空间中

的背景误差数据,将会包含更多的目标信息,呈现明显的异常状态<sup>[9]</sup>,非常有利于异常检测,这将会很好地解决光谱混合带来的背景干扰问题.

各波段子集数据投影到各自的背景正交子空间之后,原始高光谱图像中背景信息则大幅度削弱,得到的是含有丰富目标信息的背景误差数据.在实际检测场景中,异常目标有着较强的稀疏性和异常性,所以,可以合理地假设背景数据中几乎不包含异常目标信息.这样,有关异常目标的信息必然存在于正交投影之后的背景误差数据中,也即异常检测可以在背景误差数据上进行.经过PCA变换之后的数据之间是不相关的,且前几个主分量包含了图像的主要信息,即背景信息,这样可将前几个主分量近似地看作是背景子空间,其中几乎不包含所需要的目标信息.假设背景子空间为 $\mathbf{P}$ , $\mathbf{P}=\{p_1, p_2, \dots, p_M\}$ ,其中 $M$ 为选取的主成分个数.利用式 $\mathbf{P}^\perp = \mathbf{I} - \mathbf{P}(\mathbf{P}^T\mathbf{P})\mathbf{P}^T$ 来构造背景子空间的正交子空间 $\mathbf{P}^\perp$ ,其中 $\mathbf{I}$ 为与 $\mathbf{P}$ 同维的单位矩阵.将原始数据投影到 $\mathbf{P}^\perp$ 上,得到含有丰富目标信息的背景误差数据,从而可以在背景误差数据上采用非线性核RX算法完成异常目标的检测,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,降低了算法的复杂度.

将背景误差数据通过非线性映射函数 $\phi$ 映射到高维(可能是无限维)的特征空间中,从而在高维的特征空间中重新定义RX算法,形成核RX算法<sup>[9]</sup>.

在高维特征空间中存在这样的两种假设:

$$H_{0_\phi}: \phi(\mathbf{x}) = \phi(\mathbf{n}) \quad \text{目标不存在;}$$

$$H_{1_\phi}: \phi(\mathbf{x}) = a_\phi \phi(\mathbf{s}) + \phi(\mathbf{n}) \quad \text{目标存在.}$$

相应的在特征空间中核RX算法可表示为

$$RX(\phi(\mathbf{r})) = (\phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_{b_\phi})^T \hat{\mathbf{C}}_{b_\phi}^{-1} (\phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_{b_\phi}) \quad (1)$$

式中 $\hat{\mathbf{C}}_{b_\phi}$ 和 $\hat{\boldsymbol{\mu}}_{b_\phi}$ 分别为特征空间中背景协方差矩阵和均值的估计,如下式

$$\hat{\mathbf{C}}_{b_\phi} = \frac{1}{N} \sum_{i=1}^N (\phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_{b_\phi})(\phi(\mathbf{x}_i) - \hat{\boldsymbol{\mu}}_{b_\phi})^T$$

$$\hat{\boldsymbol{\mu}}_{b_\phi} = \frac{1}{N} \sum_{i=1}^N \phi(\mathbf{x}_i).$$

式(1)给出了非线性特征空间中核RX算法的表达式,但是由于数据的维数很高(甚至是无限维的),不能直接通过非线性映射函数 $\phi$ 将原始数据映射到高维特征空间中来实现该算法.为了避免直接计算式(1),本文采用核技术<sup>[11]</sup>,用原始数据空间中的核函数来间接地实现高维特征空间中的内积,即用

$$(\mathbf{K})_{ij} = (\phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j)) = k(\mathbf{x}_i, \mathbf{x}_j) \quad (2)$$

来间接的计算式(1).

将估计的背景协方差矩阵进行特征值分解为

$$\hat{C}_{b\phi} = \mathbf{V}_\phi \mathbf{A}_\phi \mathbf{V}_\phi^T \quad (3)$$

式中  $\mathbf{A}_\phi$  的对角元素为特征空间中背景协方差矩阵  $\hat{C}_{b\phi}$  的非零特征值,  $\mathbf{V}_\phi$  为非零特征值所对应的特征向量, 且每个特征向量都可以表示为特征空间中心化输入向量的线性组合, 即

$$\mathbf{V}_\phi = \sum_{i=1}^N \beta_i \phi_c(\mathbf{x}_i) = \mathbf{X}_{b\phi} \boldsymbol{\beta} \quad (4)$$

式中  $\mathbf{X}_{b\phi} = [\phi_c(\mathbf{x}_1), \phi_c(\mathbf{x}_2), \dots, \phi_c(\mathbf{x}_N)]$ ,  $\boldsymbol{\beta} = (\beta^1, \beta^2, \dots, \beta^N)^T$  为经核矩阵  $\mathbf{K}$  相应特征值的平方根归一化之后的特征向量。

将式(4)代入式(3)中并求逆得到

$$\hat{C}_{b\phi}^{-1} = \mathbf{X}_{b\phi} \boldsymbol{\beta} \mathbf{A}_\phi^{-1} \boldsymbol{\beta}^T \mathbf{X}_{b\phi}^T \quad (5)$$

则非线性核 RX 算法可表示为

$$RX(\phi(\mathbf{r})) = (\phi(\mathbf{r}) - \boldsymbol{\mu}_{b\phi})^T \mathbf{X}_{b\phi} \boldsymbol{\beta} \mathbf{A}_\phi^{-1} \boldsymbol{\beta}^T \cdot X_{b\phi}^T(\phi(\mathbf{r}) - \boldsymbol{\mu}_{b\phi}) \quad (6)$$

利用式(2), 式(6)可表示为

$$\begin{aligned} \phi(\mathbf{r})^T \mathbf{X}_{b\phi} &= \phi(\mathbf{r})^T [\phi(\mathbf{x}_1), \phi(\mathbf{x}_2), \dots, \phi(\mathbf{x}_N)] - \\ &= \frac{1}{N} \sum_{i=1}^N \phi(\mathbf{x}_i) = (k(\mathbf{x}_1, \mathbf{r}), k(\mathbf{x}_2, \mathbf{r}), \dots, \\ &= k(\mathbf{x}_N, \mathbf{r})) - \frac{1}{N} \sum_{i=1}^N k(\mathbf{x}_i, \mathbf{r}) = k(\mathbf{X}_b, \mathbf{r}) - \\ &= \frac{1}{N} \sum_{i=1}^N k(\mathbf{x}_i, \mathbf{r}) = \mathbf{K}_r^T \end{aligned} \quad (7)$$

相似的,

$$\begin{aligned} \hat{\boldsymbol{\mu}}_{b\phi}^T \mathbf{X}_{b\phi} &= \frac{1}{N} \sum_{i=1}^N \phi(\mathbf{x}_i)^T ([\phi(\mathbf{x}_1), \phi(\mathbf{x}_2), \dots, \\ &= \phi(\mathbf{x}_N)]) - \frac{1}{N} \sum_{i=1}^N \phi(\mathbf{x}_i) = \frac{1}{N} \sum_{i=1}^N k(\mathbf{x}_i, \mathbf{X}_b) - \\ &= \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N k(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{K}_{rb}^T \end{aligned} \quad (8)$$

利用核 PCA<sup>[12]</sup> 中的关系, 得到这样的等式

$$\mathbf{K}_b^{-1} = \frac{1}{N} \boldsymbol{\beta} \mathbf{A}_\phi^{-1} \boldsymbol{\beta}^T \quad (9)$$

式中  $N$  为背景采样的数目, 是常数, 故可以忽略。

这样将式(7)、(8)、(9)代入式(6), 得到核 RX 算法的形式为

$$RX_K(\mathbf{r}) = (\mathbf{K}_r^T - \mathbf{K}_{rb}^T)^T \mathbf{K}_b^{-1} (\mathbf{K}_r^T - \mathbf{K}_{rb}^T) \quad (10)$$

在各波段子集上分别完成基于背景误差的核 RX 异常检测后生成几幅检测的图像中, 目标像素所对应的点表现得较亮, 背景像素所对应的点则受到一定的削弱而表现得较暗。再对这些检测后的图像进行累积处理<sup>[13]</sup>, 使累积的结果可显示出所有的目标信息, 累积处理操作如式(11)所示。

$$J(i, j) = \prod_{n=1}^k Q_n(i, j) \quad (11)$$

式中  $i, j$  为图像的坐标,  $k$  为所分波段子集的数目,  $Q$  为经过基于背景误差的核 RX 算法检测后得到的图像。

## 2 仿真结果及分析

### 2.1 数据描述

为了验证本文提出的异常检测算法的有效性, 利用先进的机载可见光/红外成像光谱仪 (Airborne Visible Infrared Imaging Spectrometer, AVIRIS) 数据源进行了仿真实验。AVIRIS 为采用推扫成像方式的成像光谱仪, 在 0.4~2.45 的波长范围内获取 224 个波长处的空间图像信息, 波长间隔为 10 nm。本实验所用图像是美国圣地亚哥机场的一部分, 它覆盖了从可见光到近红外的光谱范围, 去除水的吸收带和信噪比较低的波段后, 余下的 126 个波段参与仿真实验。所用实验图像大小为  $1024 \times 1024$ , 图中包含了 38 个待检测目标。所用实验图像的第 10 个波段以及地面真实目标分布如图 2、3。




图2 第10波段  
Fig.2 The tenth band




图3 目标分布图  
Fig.3 Target distribution

### 2.2 实验结果与分析

在实验中, 根据相关性的大小 (如图 1 所示), 在相关性值的极小值满足要求处将高光谱图像分为 5 个波段子集, 波段子集 1 为第 1-8 波段, 波段子集 2 为第 9-70 波段, 波段子集 3 为第 71-94 波段, 波段子集 4 为第 95-114 波段, 波段子集 5 为 96-126 波段。之后在各波段子集上进行主成分分析, 去除波段之间的相关性, 构造背景的正交子空间, 将每个波段子集数据投影到各自的背景正交子空间中, 得到背景误差数据。各波段子集背景误差数据的第一个波段如图 4 所示, 背景误差数据上进行非线性核 RX 检测的检测结果如图 5 所示, 最后将每个波段子集的检测结果进行累积操作, 得到的检测结果如图 6 所示。




图 4 每个波段子集的背景误差数据

Fig. 4 Background error data of every subset




图 5 每个波段子集的检测结果

Fig. 5 The detection result of every subset





图 6 累积后的检测结果

Fig. 6 The detection result after cumulation

在进行核 RX 异常检测时,根据图像的大小和空间分辨率,将核 RX 算法的背景检测窗口大小定为  $3 \times 3$  pixel,目标检测窗口大小定为 像素.本文选择径向基核函数,其表达形式如下


$$k(\mathbf{x}, \mathbf{y}) = \exp(-\|\mathbf{x} - \mathbf{y}\|^2 / \sigma).$$

在核函数选择之后其参数的确定是极其重要的,因为参数的合理选择可以使数据体现我们所需要的非线性特性.本实验中需要确定的参数为径向基核函数的宽度,由于最优参数的选择还没有完善的指导理论,所以文中的参数是通过大量的仿真实验比较确定的,最终本文将径向基核函数的宽度  $\sigma$  定为 0.07.在利用式(10)得到各像素点的检测值之后,由于待检测目标相对较小且都是孤立的,故可采用形态学方法提取出像素点较少的目标区域.最终处理得到的二值图像如图 7(a)所示.



(a)BEEKRX

(b)KRX



(c)BEEKRX

(d)BEKRX

图 7 不同算法在相同检测阈值下的检测结果

Fig. 7 The result of different algorithms at the same threshold

为了便于比较分析,试验中还将原始数据直接通过核 RX 算法(Kernel RX, KRX)、基于背景端元提取的背景正交子空间投影形成背景误差数据的异常检测算法(Kernel RX Based on Background Endmember Error, BEEKRX),以及未进行自适应子空间分解的基于背景误差数据的异常检测算法(Kernel RX Based on Background Error, BEKRX)的检测结果与本文算法进行比较,在相同阈值下其检测结果分别如图 7 所示.

从图 7 的比较结果可以看出,本文提出的算法较之 KRX 算法,明显地提高了检测概率并降低了虚警概率,这是由于直接采用 KRX 算法,忽略了波段之间较强的相关性及背景信息的存在对目标检测的影响;基于背景端元提取的背景正交子空间投影形成的背景误差图像的异常检测算法(BEEKRX)中,由于背景端元的提取受到一定条件的限制,不能完全保证提取到的端元一定为纯粹的背景光谱,所以往往会给后续的背景误差数据带来一定程度的影响,从而导致 BEEKRX 算法检测结果存在较多虚警;未进行自适应子空间分解的基于背景误差数据

的异常检测算法(BEKRX)忽略了波段之间的块状相关性,距离稍远的较小相关性波段对数据的处理造成了影响,使之产生了较多的虚警.经过比较可以明显地看出,本文提出的异常检测算法在提高检测概率和降低虚警概率上都具有明显的优越性.

为了更具体地说明本文提出算法的优越性,在相同的检测阈值下,以高光谱图像检测到的目标个数、目标所占像素数、虚警所占像素数为指标对上述算法的检测结果进行比较,其比较结果如表 1.

表 1 算法性能比较

Table 1 Algorithm performance comparison

Algorithm	Number of targets	Pixels of target	Pixels of false alarm
BEKRX	38	384	116
KRX	35	274	226
BEEKRX	37	284	216
BEKRX	38	345	155

从表 1 的数据中可以明显地比较出,本文提出的算法可检测到较多的目标,具有较高的目标检测率和较低的虚警率,充分地表明了本文提出算法的优越性能.

接收机工作特性(ROC)用于描述不同检测阈值下检测概率  $P_d$  与虚警概率  $P_f$  之间的变化关系,提供算法检测性能的定量分析.将检测概率  $P_d$  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  $P_f$  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.通过考察检测到的异常点是否落入真实目标分布模板区域来判定检测到的是真实目标还是虚警.上述四种算法的接收特性曲线如图 8 所示,从图 8 可以看出本文提出算法较好地改进了 KRX 算法,具有良好的检测性能和较低的虚警率.

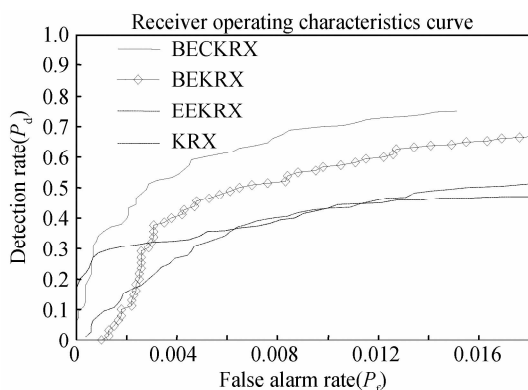


图 8 接收机工作特性曲线

Fig. 8 Receiver operating characteristics curve

### 3 结论

本文综合利用背景抑制和高光谱图像的高维统

计特性,提出了一种背景误差数据累积与 KRX 算法相结合的异常目标检测算法,对高光谱图像进行处理取得了较好的效果.该算法充分地利用了各波段子集内部较高的相关性,有效地抑制了背景信息,减小了背景干扰对目标检测的影响,且充分挖掘了高光谱图像波段间的非线性信息和数据之间的高阶统计信息,具有较好的检测性能和较低的虚警概率.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,而且结构较简单,有效地提高了检测效率.

### 参考文献

- [1] WANG Zhi-ping, YANG Jian-feng, XUE Bin, *et al.* Using hyperspectral data for land cover identification and classification[J]. *Acta Photonica Sinica*, 2008, **37**(3):561-565. 王志平, 杨建峰, 薛彬, 等. 利用高光谱数据进行地物识别分类研究[J]. *光子学报*, 2008, **37**(3):561-565.
- [2] TONG Qing-xi, ZHANG Bing, ZHENG Lan-fen. Hyperspectral remote-Principle, technique and application [M]. Beijing: Higher Education Press, 2006:206. 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, 2006:206.
- [3] HARSANYI J C, CHANG C I. Hyperspectral image classification and dimensionality reduction: An orthogonal subspace projection approach [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1994, **32**(4):779-785.
- [4] XUN Li-na, FANG Yong-hua, LI Xin. Target detection algorithm in hyperspectral image based on CEM[J]. *Opto-Electronic Engineering*, 2007, **34**(7):19-20. 寻丽娜, 方勇华, 李新. 基于 CEM 的高光谱图像小目标检测算法[J]. *光电工程*, 2007, **34**(7):19-20.
- [5] DI Wei, PAN Quan, HE Lin, *et al.* Anomaly detection in multi-band spectral imagery based on multiple-detector maximum entropy fusion[J]. *Acta Photonica Sinica*, 2007, **36**(7):1338-1344. 邸韡, 潘泉, 贺霖, 等. 基于多检测器最大熵融合的多通道光谱图像异常检测[J]. *光子学报*, 2007, **36**(7):1338-1344.
- [6] ZHANG Li-yan, KAN De-rong, LI Shi-yi, *et al.* Research on hyperspectral imagery loss compression method based on low probability detection [J]. *Journal of Projectiles, Rockets, Missiles and Guidance*, 2008, **28**(1):308-309. 张立燕, 堪德荣, 李世义, 等. 基于低概率检测的高光谱图像有损压缩方法研究[J]. *火箭与制导学报*, 2008, **28**(1):308-309.
- [7] HE Lin, PAN Quan, ZHAO Yong-qiang, *et al.* Anomaly detection in hyperspectral imagery based on feature fusion of band subsets[J]. *Acta Photonica Sinica*, 2005, **34**(11):1752-1755. 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.
- [8] 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*, 2004, **23**(4):286-290. 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[J]. *红外与毫米波学报*, 2004, **23**(4):286-290.
- [9] 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*, 2006, **25**(6):473-477. 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[J]. 红外与毫米波学报, 2006, 25(6):473-477.
- [10] HEESUNG K, NASRABADI N M. Kernel RX-algorithm: a nonlinear anomaly detector for hyperspectral imagery [J]. Geoscience and Remote Sensing [J]. *IEEE Transactions on*, 2005, 43(2):388-397.
- [11] SCHOLKOPF B, SMOLA A J. Learning with Kernels[M]. Cambridge: The MIT Press, 2002.
- [12] SCHOLKOPF B, SMOLA A J, MULLER K R. Kernel principal component analysis[J]. *Neural Computation*, 1999, 9(10):1299-1319.
- [13] LI Zhi-yong, KUANG Gang-yao, ZOU Huan-xin, et al. Research of anomaly detection approaches based on feature fusion in hyperspectral imagery [J]. *Journal of Remote Sensing*, 2003, 7(4):304-308.
- 李智勇, 匡纲要, 邹焕新, 等. 基于特征层融合的高光谱图像异常检测算法研究[J]. 遥感学报, 2003, 7(4):304-308.

## A Kind of Anomaly Detection Algorithm for Hyperspectral Image through Background Error Cumulation

ZHAO Chun-hui, HU Chun-mei, BAO Yu-gang

(College of Information & Communication Engineering, Harbin Engineering University, Harbin 150001, China)

**Abstract:** Reckoning on the strong interfere of background information to anomaly detection for hyperspectral image, a kind of anomaly detection algorithm based on background error cumulation is proposed. First, it constructs the background subspace. Then it projects every pixel into this subspace to obtain background error data for later anomaly detection, which suppresses background and makes target stand out. Experiments on real hyperspectral image show that the proposed algorithm outperforms other algorithms, and obtains better detection results.

**Key words:** Hyperspectral image; Principal component analysis; Orthogonal subspace; Background error data; Anomaly detection



**ZHAO Chun-hui** was born in 1965. He is a professor and his research interests focus on intelligent information and image processing, as well as nonlinear and communication signals processing.