

基于选择性分段行-列二维主成分分析的 高光谱图像异常检测

杨枕^{1**}, 向英杰^{2*}, 王琪³, 田张男¹

¹空军航空大学航空作战勤务学院, 吉林 长春 130022;

²中国人民解放军 78102 部队, 四川 成都 610031;

³中国人民解放军 93116 部队, 辽宁 沈阳 110100

摘要 高光谱图像具有越来越高的空间和光谱分辨率,其带来了数据量大、相关性强和冗余度高的问题,使得异常检测结果精度不高。为了选择更加有利于异常检测的图像,运用二维主成分分析(2DPCA)方法降维,并引入局部联合偏度-峰度指数进行图像选择,提出了一种基于选择性分段 2DPCA 的高光谱图像异常检测方法。首先利用相关系数对原始图像进行分段,然后通过旋转数据结构在每个波段子空间中实现行-列二维主成分降维;再选择合适大小的窗口,遍历每个降维结果的主成分,计算窗口内的局部联合偏度-峰度指数,并以此作为指标选择用于异常检测的图像。实验结果表明,所提方法的接收机工作特性(ROC)曲线、曲线下面积(AUC)值和 Bhattacharyya 距离值均优于其他传统的方法,因此具有更好的检测性能。

关键词 图像处理; 高光谱图像; 异常检测; 二维主成分分析; 偏度; 峰度

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/LOP55.081002

Anomaly Detection Based on Selective Segmentation Row-Column Two-Dimensional Principal Component Analysis for Hyperspectral Images

Yang Guang^{1**}, Xiang Yingjie^{2*}, Wang Qi³, Tian Zhangnan¹

¹Institute of Aviation Operation Service, Aviation University of Air Force, Changchun, Jilin 130022, China;

²NO. 78102 Troops of PLA, Chengdu, Sichuan 610031, China;

³NO. 93116 Troops of PLA, Shenyang, Liaoning 110100, China

Abstract Hyperspectral image have higher and higher spatial and spectral resolution, resulting in a large amount of data, strong correlation and high redundancy, which makes the low accuracy of anomaly detection result. In order to select the image which is more favorable for anomaly detection, we use the two-dimensional principal component analysis (2DPCA) method to reduce the dimension, and introduce the local joint skewness-kurtosis index to image selection. A method based on selective segmentation 2DPCA for hyperspectral image anomaly detection is proposed. Firstly, the original image is segmented by the correlation coefficient, and then the row-column two-dimensional principal component dimension reduction is realized in each band subspace by rotating the data structure. Then, we select an appropriate size window to traverse all the principal components of each dimension reduction result. Meanwhile, the local joint skewness-kurtosis index is calculated in this window, which is regard as an indicator to select the image for anomaly detection. The experimental result shows that the receiver operating characteristic (ROC) curve, the area under the curve (AUC) value and Bhattacharyya distance value of the proposed method are better than other traditional methods, so that it has a better detection performance.

Key words image processing; hyperspectral image; anomaly detection; two-dimensional principal component analysis; skewness; kurtosis

OCIS codes 100.2000; 100.2960; 100.4994

收稿日期: 2017-12-11; 修回日期: 2018-02-08; 录用日期: 2018-03-01

基金项目: 吉林省教育厅“十二五”科研项目(2015448)、吉林省科技发展计划资助项目(20140101213JC)

* E-mail: xyjandsy@163.com; ** E-mail: yg2599@126.com

1 引言

高光谱传感器能够同时获取目标区域的二维几何空间信息与一维光谱信息,因此高光谱数据具有“图像立方体”的形式和结构,体现出“图谱合一”的特点和优势,从而大大提高了定性和定量观察、观测地表的能力^[1-2]。异常检测算法不需要利用光谱的先验知识,而能直接检测出与周围景物光谱存在的明显差异,对于地物目标的识别具有重要意义。但是,由于高分辨率、宽波长覆盖范围和丰富的空间信息,使得高光谱图像存在数据冗余、数据处理困难和维数灾难等问题^[3]。如果直接对获取的高光谱数据进行异常检测,庞大的数据量将会严重影响目标检测的效率和精度,因此需要对数据进行前期的降维处理。

目前,主成分分析(PCA)已经广泛应用于高光谱遥感影像的降维。但是 PCA 方法需要将图像矩阵展开为向量,这就带来了巨大的计算量,同时忽略了各波段图像矩阵的结构信息。与 PCA 不同, Yang 等^[4]提出的二维主成分分析(2DPCA),直接在二维图像矩阵上进行特征提取,既保留了图像空间结构又减少了运算量,能够很好地用于高光谱图像降维。它们都是通过变换将能量最大应用于异常检测,这就忽略了局部微小的异常目标,导致检测结果不准确。偏度和峰度分别度量了随机变量分布的不对称性和陡峭程度,偏度越大,不对称性越强,峰度越大越陡峭^[5]。它们可以度量随机变量偏离正态分布的程度,即高光谱图像中的异常信息丰富程度,因此非常适合作为高光谱图像异常检测前的图像降维指标。基于这种思想,郭雷等^[6]提出联合偏度-峰度指数(JSKF)模型,即利用偏度与峰度的乘积作为指标衡量偏离正态分布信息量的大小,并以此为依据进行波段选择。赵春晖等^[7]提出了采用选择性分段 PCA 算法的高光谱图像异常检测方法,将偏度和峰度作为选择波段的指标,并用于高光谱图像异常检测。但是一维的 PCA 方法越来越难以满足高光谱数据的处理需求,计算整幅图像的 JSKF 忽略和掩盖了局部重要异常信息,从而影响后续的异常检测精度。

为了更好地选择用于异常检测的主成分图像,本文结合 2DPCA 和局部 JSKF 模型,提出了一种基于选择性分段 2DPCA 的高光谱图像异常检测方法。利用波段间相关性进行波段子空间划分,然后在各个子空间中进行 2DPCA 变换,实现高光谱图像降维,然后在降维结果子空间中选择适合大小的目标窗口,计算局部 JSKF,并求出累积局部 JSKF

值,然后进行波段选择,最后将选择的波段应用于异常检测。

2 2DPCA

2DPCA 是将高光谱图像每个波段看成二维矩阵,然后直接对各个波段进行处理。设一幅高光谱图像有 L 个波段,每个波段的图像大小为 $m \times n$,则一幅 $m \times n \times L$ 的高光谱数据可表示为 $\mathbf{A} = \{\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_k, \dots, \mathbf{A}_L\}$,其中 \mathbf{A}_k 表示图像 \mathbf{A} 的第 k 波段。2DPCA 高光谱图像降维步骤如下:

1) 计算高光谱影像各波段的平均图像 $\bar{\mathbf{A}}$

$$\bar{\mathbf{A}} = E(\mathbf{A}) = \frac{1}{L} \sum_{k=1}^L \mathbf{A}_k. \quad (1)$$

2) 计算 \mathbf{A} 的协方差矩阵

$$\mathbf{G}_t = E\{[\mathbf{A} - E(\mathbf{A})]^T [\mathbf{A} - E(\mathbf{A})]\} = \frac{1}{L} \sum_{k=1}^L [(\mathbf{A}_k - \bar{\mathbf{A}})^T (\mathbf{A}_k - \bar{\mathbf{A}})], \quad (2)$$

式中 \mathbf{G}_t 为 $n \times n$ 的非负定矩阵。

3) 计算 \mathbf{G}_t 的特征值,选取前 d 个最大的特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$ 及其与之对应的特征向量 $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_d$,令 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_d]$, \mathbf{X} 称为最优投影矩阵。

4) 分别将每个波段图像投影到 \mathbf{X} 上

$$\mathbf{Y}_{kj} = \mathbf{A}_k \mathbf{X}_j, k = 1, 2, \dots, L, j = 1, 2, \dots, d, \quad (3)$$

式中 $\mathbf{Y}_{k1}, \mathbf{Y}_{k2}, \dots, \mathbf{Y}_{kd}$ 为波段 \mathbf{A}_k 的主成分,每个波段图像的前 d 个主成分都可以组成一个 $m \times d$ 维矩阵。

5) 图像重构

由于 $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_d$ 正交,重构图像为

$$\tilde{\mathbf{A}} = \sum_{j=1}^d \mathbf{Y}_{kj} \mathbf{X}_j^T, k = 1, 2, \dots, L, \quad (4)$$

式中 d 的大小通常通过主成分的累计贡献率来确定。

3 偏度和峰度

随机变量的偏度 S 可以用三阶标准化矩阵来表示

$$S = \frac{E(x - \mu)^3}{\sigma^3}, \quad (5)$$

式中 $E(x)$ 是随机变量 x 的期望, μ 是 x 的均值, σ 是 x 的标准差。

随机变量的峰度 K 用随机变量的 4 阶中心距与方差平方的比值表示

$$K = \frac{E(x - \mu)^4}{\sigma^4} - 3. \quad (6)$$

JSKF^[7],即偏度和峰度系数的乘积,能够联合三阶累积量和4阶累积量,更加全面有效地度量数据偏离正态分布的程度。JSKF模型可以表示为

$$V_{\text{JSKF}} = S \cdot K, \quad (7)$$

将(5)、(6)式代入(7)式,得到JSKF的计算表达式为

$$V_{\text{JSKF}} = \frac{1}{\sigma^7} [E(x - \mu)^4 - 3\sigma^4] \cdot E(x - \mu)^3. \quad (8)$$

设 x_1, x_2, \dots, x_n 为来自总体的样本数据,则JSKF的离散形式为

$$V_{\text{JSKF}} = \left\{ \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3 \left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{\frac{2}{3}} \right\}.$$

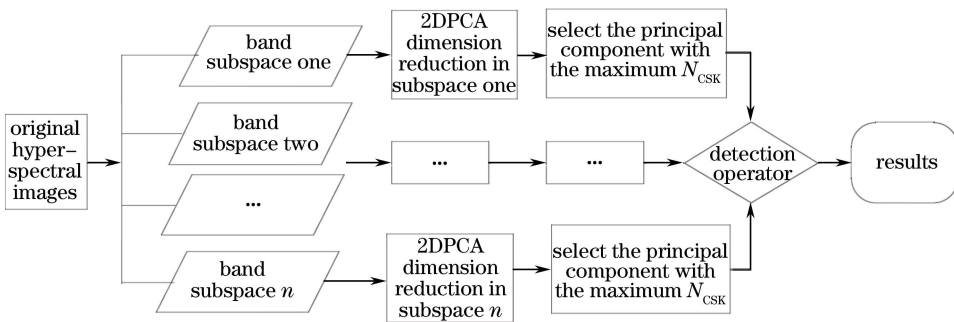


图1 算法流程图

Fig. 1 Flowchart of proposed algorithm

4.1 子空间划分

对高光谱影像整体进行2DPCA变换时,一些局部的重要波段由于在前几个主成分中的作用不是特别明显,可能会在波段选择中被忽略,导致结果不准确。因此需要将高光谱影像按照相关性进行波段子空间的划分,然后进行2DPCA,本文采用相关系数对高光谱影像进行分段。

子空间具体划分过程为:设阈值为 T ,以第一波段为初始波段,计算第一波段与后面波段的相关系数 $\rho_{1,i}$,若 $\rho_{1,i} > T$,则将波段分入第一波段所在组,然后计算 $\rho_{1,i+1}$,用相同的方法进行分组;若出现相关系数小于阈值,则将该波段作为第二组的第一波段,计算此波段与后面波段的相关系数并合并分组。以此类

推,直到检测完所有波段,完成波段分组。

4.2 高光谱数据模型转换

高光谱源图像数据结构通常按照波段顺序(BSQ)结构储存,如图2(a)所示。从前往后依次为第一波段,第二波段, ..., 第 L 波段,每个波段是大小为 $m \times n$ 的图像矩阵,从而形成图2(a)所示的“立方体”。将此源图像进行2DPCA变换,每个波段图像被压缩成 $m \times d$ 的矩阵,明显不是降维的结果,还需要复杂的矩阵运算进行图像重构。为此,需要将高光谱源图像数据结构进行转换。

图2(a)表示高光谱源图像数据结构,将此源图像沿着 m 轴向左旋转 90° ,得到如图2(b)所示的结构。此时,高光谱影像变成大小为 $m \times L \times n$ 的三




图2 高光谱图像数据结构。(a)原始数据;(b)旋转后数据;(c)进一步旋转后数据

Fig. 2 Data structure of hyperspectral images. (a) Original data; (b) data after rotating; (c) data after further rotating

维数据,仍将其看成 BSQ 储存形式,从前往后看,每个波段大小为 $m \times L$,共 n 个波段。将每个波段进行 2DPCA 变换,得到 d 个大小为 $m \times 1$ 的向量,从而实现了原始高光谱影像列方向的压缩。然后将图 2(b)所示的数据结构以底边 L 为轴向向前旋转 90° ,得到大小为 $n \times L \times m$ 的三维数据,如图 2(c)所示。仍将其看成 BSQ 储存形式,从前往后看,每个波段大小为 $n \times L$,共 m 个波段。将每个波段进行 2DPCA 变换,得到 d 个大小为 $n \times 1$ 的向量,从而实现了原始高光谱影像行方向的集中。

4.3 行-列二维主成分变换

将图 2(b)中的数据结构进行 2DPCA 变换,实现了影像行方向的集中,消除了行的相关性,但忽视了列的相关性。将图 2(c)中的数据结构进行 2DPCA 变换,实现了影像列方向的压缩,消除的是列的相关性,遗留了行的相关性。但行和列两个方向的信息是同等重要的,需要将行-列两个方向的主成分进行融合得到最终的降维结果。加权平均的融合方法简单实用,能够去除高光谱图像中的噪声,并且能保留波段中的互补信息^[8]。同时考虑到运算时间因素,因此本文采用加权平均的融合方法。

4.4 基于局部 JSKF 的波段选择

首先在进行 2DPCA 降维后的子空间中,选择适当大小的窗口模板,计算窗口区域内的局部 JSKF 值,并设定适当的阈值,当该窗口局部 JSKF 值大于该阈值时,则认为该区域内的非高斯性越强,对需要选择的波段越有利。以此窗口为单位,遍历子空间中每个主成分图像,并计算每个主成分图像的累积局部 JSKF 值(记为 N_{CSK}),并将累积局部 JSKF 值作为波段选择的依据。即在遍历每个主成分图像时,当窗口内的局部 JSKF 值大于阈值,则 N_{CSK} 值加 1,直到遍历所有的波段。最后,选择子空间中 N_{CSK} 值最大所对应的主成分图像。

4.5 RX 算子

RX 算法是在目标和背景未知的情况下,假设图像数据服从均值不同但是协方差矩阵相同的正态分布,即

$$\begin{cases} H_0: \mathbf{x} = \mathbf{n} \\ H_1: \mathbf{x} = a\mathbf{s} + \mathbf{n} \end{cases}, \quad (10)$$

式中:假设 H_0 代表目标不存在, H_1 代表目标存在; \mathbf{x} 为待检测的光谱向量, \mathbf{n} 代表噪声向量, \mathbf{s} 代表目标光谱向量; a 为系数,当 $a=0$ 时,满足假设 H_0 , 当 $a>0$ 时,满足假设 H_1 。

在二元假设的基础上,定义的马氏距离检测算

子为

$$\delta^{\text{RX}}(\mathbf{x}) = (\mathbf{x} - \mu_0)^T \mathbf{C}^{-1} (\mathbf{x} - \mu_0) \begin{cases} \geq \eta, & H_1 \\ < \eta, & H_0 \end{cases}, \quad (11)$$

式中 μ_0 为背景均值, \mathbf{C} 为背景协方差矩阵, η 为判别阈值。RX 利用这个算子进行检测,当某一像素点的 $\delta^{\text{RX}}(\mathbf{x})$ 值超过判别阈值时,则认为是异常像素。对图像逐点地进行检测,最终得到检测结果。

5 实验验证

5.1 实验数据

实验数据 1:该数据为模拟数据实验,采用的模拟数据是在真实高光谱数据 Salinas 影像基础上合成的。Salinas 影像由 AVIRIS 传感器拍摄于美国加利福尼亚州萨利纳斯山谷。该遥感影像包含 224 个波段,原始大小为 $512 \text{ pixel} \times 217 \text{ pixel}$,空间分辨率为 3.7 m ,去除覆盖水吸收区域的 20 波段,剩余 204 个波段用于实验。截取大小为 $100 \text{ pixel} \times 100 \text{ pixel}$ 的背景较为单一的区域用于构成模拟数据。

本实验图像中模拟了亚像素和纯像元两种类型异常目标。亚像素异常目标合成采用文献[9]的方法,即通过目标植入方法来仿真异常像素。基于线性混合模型,合成的亚像素异常目标光谱 z 由特定丰度 f 的所需异常光谱 t 和背景光谱 b 组成,表达式为

$$z = f \cdot t + (1 - f)b. \quad (12)$$

本实验中,异常光谱 t 是从截取的 $100 \text{ pixel} \times 100 \text{ pixel}$ 区域以外的 Salinas 影像中获取的,丰度 f 取 0.4。同样,模拟纯像元异常目标采用的光谱与 t 相同,合成的异常目标有 2×2 和 3×3 两种大小。实验合成了 9 个异常目标,它们均是采用光谱 t ,如图 3 所示。图中第一行三个异常目标为亚像素目标,第二行和第三行分别为大小 2×2 和 3×3 的纯像元目标。

实验数据 2:该数据为真实高光谱数据实验,采




图 3 模拟数据。(a)原始图像;(b)模拟图像;
(c)真实目标分布图

Fig. 3 Simulation data. (a) Original image;
(b) simulation image; (c) real target distribution map

用美国 AVIRIS 传感器在 1998 年获取的圣迭戈机场数据作为实验数据。该图像有 220 个波段,地面分辨率为 3.5 m。去掉大气吸收和低信噪比的波段,剩下用于实验的图像总共有 189 个波段。此时的图像大小为 400 pixel \times 400 pixel,截取大小为 100 pixel \times 100 pixel 的区域。图像的第 20 波段和地面真实目标图如图 4 所示。




图 4 真实高光谱实验。

(a)真实高光谱数据;(b)地面目标分布图

Fig. 4 Real hyperspectral experiment. (a) Real hyperspectral data; (b) ground target distribution map

5.2 实验结果与分析

根据本文算法的实现步骤,将数据 1 波段划分为 1-22、23-38、39-106、107-114、114-148 和 149-203 共 6 个子空间。同时根据多次实验经验和实验数据大小,选择大小为 10 pixel \times 10 pixel 的窗口来遍历主成分,最后采用 RX 算子进行异常检测。为了有效验证所提算法的检测性能,实验基于 PCA 的两种方法和基于 2DPCA 的两种方法,总共 4 种方法。它们的检测输入分别为 PCA 结果中第一主成分波段(记为 PCA)、PCA 结果中 N_{CSK} 值最大的波段(记为 SS-PCA)、2DPCA 结果中第一主成分(记为 2DPCA)和 2DPCA 结果中 N_{CSK} 值最大的波段(记为 SS-2DPCA)。4 种方法的异常检测结果二值图分别如图 5 所示。从图 5(b)和图 5(d)可以看出,基于偏度-峰度选择的两种方法,异常检测结果优于其他两种方法。其中,所提方法的异常检测性能最好。




图 5 数据 1 异常检测结果。(a) PCA;(b) 2DPCA;(c) SS-PCA;(d) SS-2DPCA

Fig. 5 Anomaly detection results of data 1. (a) PCA; (b) 2DPCA; (c) SS-PCA; (d) SS-2DPCA

为了定量地验证本文算法的性能,绘制了 4 种方法的 ROC 曲线,并计算了曲线下面积(AUC)。同时,为了衡量异常目标与背景区分开的能力,文献[10]提出了真实异常像素与背景像素的检测分数直方图 Bhattacharyya 距离(BD)指标。本文也采用 BD 值作

为辅助衡量指标。数据 1 的 4 种方法的 ROC 曲线以及 AUC 和 BD 值柱状图分别如图 6(a)、(b)所示。可以看出,所提方法的 ROC 曲线、AUC 和 BD 值均优于其他三种方法。实验结果表明,所提方法能够很好地用于仿真高光谱图像异常检测。





图 6 数据 1 结果定量评价。(a) ROC 曲线;(b) AUC 和 BD 值柱状图

Fig. 6 Quantitative evaluation of results of data 1. (a) ROC curves; (b) histograms of AUC and BD

和数据 1 步骤一样,数据 2 采用真实高光谱数据进行实验,将数据 2 波段划分为 1-30、31-37、38-96、97-135 和 136-189 共 5 个子空间,同样选择

10 pixel \times 10 pixel 的窗口模板来遍历子空间中的主成分,最后实现了 4 种方法(即 PCA、SS-PCA、2DPCA 和 SS-2DPCA)的异常检测,其结果如图 7

所示。可以看出,基于偏度-峰度选择的两种方法(即 SS-PCA 和 SS-2DPCA)异常检测结果优于其他两种方法。具体地,由于降维效果更好,2DPCA 方

法的异常检测结果要优于 PCA 方法;SS-2DPCA 方法的检测结果优于 SS-PCA 方法。实验结果表明,所提方法的检测结果最好。



图 7 实验数据 2 的异常检测结果。(a) PCA;(b) 2DPCA;(c) SS-PCA;(d) SS-2DPCA

Fig. 7 Anomaly detection results of data 2. (a) PCA; (b) 2DPCA; (c) SS-PCA; (d) SS-2DPCA

同时,绘制 ROC 曲线以及 AUC 和 BD 值柱状图如图 8 所示。从整体来看,数据 2 的 ROC 曲线结果较数据 1 更好;同时,实验 2 的 AUC 值和 BD 值大于实验 1。这是由于实验 2 包含较少的飞机目

标,且目标较大,检测效果较好。具体地,SS-2DPCA 方法的 ROC 曲线、AUC 和 BD 值均优于其他三种方法,说明本文方法能够很好地用于真实高光谱图像的异常检测。




图 8 实验数据 2 结果定量评价。(a) ROC 曲线;(b) AUC 和 BD 值柱状图

Fig. 8 Quantitative evaluation of results of experimental data 2. (a) ROC curves; (b) histograms of AUC and BD

6 结 论

提出了一种基于选择性分段 2DPCA 的高光谱图像异常检测算法,该方法用 2DPCA 进行降维,并引入局部 JSKF 进行异常检测波段选择。在两次旋转高光谱数据结构的基础上,分别实现行和列的 2DCPA 变换,减少了计算量。将局部 JSKF 作为指标,选择包含更多异常信息的主成分,最终将选择的波段用于异常检测并得到检测结果。模拟和真实高光谱数据实验结果均表明,与选用 PCA 和 2DPCA 结果中第一主成分图像用于异常检测的方法相比,所提方法具有更好的检测性能。ROC 曲线以及 AUC 和 BD 值柱状图表明,所提方法检测结果具有更低的虚警率。

参 考 文 献

[1] Zhang B. Advances of hyperspectral image processing and information extraction [J]. Journal of Remote Sensing, 2016, 20(5): 1062-1090.

张兵. 高光谱图像处理与信息提取前沿 [J]. 遥感学报, 2016, 20(5): 1062-1090.

[2] Tong Q, Xue Y, Zhang L. Progress in hyperspectral remote sensing science and technology in China over the past three decades [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(1): 70-91.

[3] Pu H Y, Wang B, Zhang L M. New dimensionality reduction algorithms for hyperspectral imagery based on manifold learning [J]. Infrared and Laser Engineering, 2014, 43(1): 232-237.

普哈啤, 王斌, 张立明. 基于流形学习的新高光谱图像降维算法 [J]. 红外与激光工程, 2014, 43(1): 232-237.

[4] Yang J, Zhang D, Frangi A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137.

[5] Zhou Y, Li X R, Zhao L Y. Modified linear-prediction based band selection for hyperspectral

- image [J]. *Acta Optica Sinica*, 2013, 33 (8): 0828002.
- 周杨, 厉小润, 赵辽英. 改进的高光谱图像线性预测波段选择算法 [J]. *光学学报*, 2013, 33 (8): 0828002.
- [6] Guo L, Chang W W, Fu Z Y. Band selection of optimal for hyperspectral image fusion[J]. *Journal of Astronautics*, 2011, 32(2): 374-379.
- 郭雷, 常威威, 付朝阳. 高光谱图像融合最佳波段选择方法 [J]. *宇航学报*, 2011, 32(2): 374-379.
- [7] Zhao C H, Hu C M, Shi H. Anomaly detection for a hyperspectral image by using a selective section principal component analysis algorithm[J]. *Journal of Harbin Engineering University*, 2011, 32(1): 109-113.
- 赵春晖, 胡春梅, 石红. 采用选择性分段 PCA 算法的高光谱图像异常检测 [J]. *哈尔滨工程大学学报*, 2011, 32(1): 109-113.
- [8] Kang X D, Li S T, Jon A B. Feature extraction of hyperspectral images with image fusion and recursive filtering [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(6): 3742-3752.
- [9] Stefanou M S, Kerekes J P. A method for assessing spectral image utility [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(6): 1698-1706.
- [10] Yuan Y, Wang Q, Zhu G K. Fasthyperspectral anomaly detection via high-order 2-D crossing filter [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 53(2): 620-630.