

文章编号:1007-2780(2019)09-0897-08

基于双边滤波的最优波段子空间高光谱 异常目标检测

成宝芝*, 张丽丽

(大庆师范学院 机电工程学院, 黑龙江 大庆 163712)

摘要:针对 KRX 方法对高光谱图像进行异常目标检测时存在检测效率低和虚警率高的问题,在充分分析高光谱图像数据特征基础上,本文提出一种最优波段子空间方法的高光谱图像异常目标检测算法。该算法首先利用双边滤波方法对高光谱图像进行全局滤波,充分利用双边滤波的优点,使得高光谱图像背景信息得到抑制;然后采用经典的自动子空间方法对高光谱图像进行波段子集划分;再利用联合偏度-峰度指标,在每个波段子集内选出最优波段;最后利用这些最优波段构成新的波段最优子空间,在此基础上,在最优波段子空间中利用 Kernel RX 算法进行异常目标检测,从而得到异常检测结果。本文利用真实的高光谱图像进行仿真验证,获得异常目标、检测的虚警数和 ROC 等检测结果。结果表明,该算法具有鲁棒性强、虚警率低和检测精度高等优点。

关键词:高光谱遥感图像;异常目标检测;双边滤波;波段子空间

中图分类号:TP751.1 **文献标识码:**A **doi:**10.3788/YJYXS20193409.0897

Optimal bands subspace anomaly detection for hyperspectral imagery based on bilateral filtering

CHENG Bao-zhi*, ZHANG Li-li

(College of Mechanical and Electrical Engineering, Daqing Normal University,
Daqing 163712, China)

Abstract: In order to overcome the low detection accuracy and high false alarm rate of anomaly target detection in hyperspectral image based on Kernel RX anomaly detector, the new hyperspectral image anomaly target detection algorithm for optimal bands subspace is proposed on the basis of fully analyzing the characteristics of hyperspectral image data. First, the bilateral filtering method is used to filter the hyperspectral image, which makes the background information of hyperspectral images be suppressed by full using of the advantages of bilateral filtering. Then, the band subset of hyperspectral image is divided by adopting the classical ASD method, and then the optimal bands are selected by using the combined skewness-kurtosis index in each band subset. Finally, the Kernel RX algorithm is used to detect anomaly targets by using these optimal bands. The real AVIRIS hyperspectral imagery

收稿日期:2019-04-10;修订日期:2019-06-04.

基金项目:黑龙江省自然科学基金(No. LH2019F040)

Supported by Natural Science Foundation of Heilongjiang(No. LH2019F040).

* 通信联系人, E-mail:chengbaozhigy@163.com

data sets are used in the experiments, and the detection results are obtained by anomaly targets, false alarm number and ROC curve. The results show that the proposed algorithm has strong robustness and lower false alarm probability.

Key words: hyperspectral remote sensing imagery; anomaly target detection; bilateral filtering; bands subspace

1 引言

高光谱遥感图像通过光谱信息和空间信息可以对地面物质进行细微的区分,近年来已经成为各国优先发展的热门遥感技术之一。我国先后发射了高分 4 号和高分 5 号卫星进行对地观测,使我国的遥感技术应用能力大大提高。在高光谱遥感图像应用过程中,对图像质量进行评价、对图像进行修正、对图像中含有的物质进行分类、解混、目标检测等算法的研究已成为重要内容,国内外高光谱研究者在理论研究方面取得了很多成果,同时也转化为实际的应用。在高光谱图像理论分析和实际应用研究中,高光谱遥感图像异常目标检测由于能够从复杂的背景中区分出感兴趣的点,而且不需要先验信息,已成为研究重点。

多年来,研究者提出了大量的有效算法。由于异常目标在高光谱图像中是不同于背景的一些异常点,因此研究的关键在于对高光谱图像的背景进行估计和抑制,从而使异常点突出,提高检测效果。在众多异常目标检测算法中,最有标志性的算法是 RX 异常检测算法^[1]。该算法是利用广义似然比检验(GLRT)得到的恒虚警线性异常检测算法,算法结构采用马氏距离检测异常点与周围环境间的差异度,其假定高光谱图像背景符合多元正态分布^[2],这一假定对于一些背景非常复杂的高光谱图像符合度较低,因此算法存在一定缺陷,检测效果较差。后续很多研究者对于这一算法进行改进,提出了一些效果较好的改进算法。Maryam Imani^[3]提出了一种调整背景数据的新 RX 异常检测算法,由于异常点混杂在背景数据中,该算法利用中值平均值测量方法调整异常点和背景数据区分度,调整背景数据点位置,提高了算法检测精度。Chang 等人提出的 RX-UTD^[4]、Guo 等人提出的背景改善的改进 RX 算法^[5]、Molero 等人提出的 Fast RX^[6]、Schaum 等人提出的 Subspace RX^[7]等异常检测算法都从不同角度

对原有 RX 算法进行改进,得到了较好的异常目标检测结果。非线性方法的引入使得高光谱异常目标的检测进入新阶段,Kernel RX^[8-9]和 SVDD^[10]算法是典型的非线性异常检测算法,分别利用核函数方法和支持向量机方法进行高光谱异常目标检测,检测效果和精确度都高于线性 RX 异常检测方法。近年来,稀疏表示理论^[11-12]和低秩矩阵方法^[13]被引入到高光谱异常目标检测中,并与 RX 异常检测算子和 Kernel RX 异常检测结合也得到了较好的检测效果。总的来说,无论是经典 RX 算法,还是非线性核函数方法都是从高光谱图像光谱特性、空间特性或者光谱-空间结合等方面对图像进行分析和对检测方法进行改进,取得了一系列较好的检测效果,降低了虚警率,提高了检测精度。

本文通过分析高光谱图像固有特征,从增大异常目标点和图像背景区分度、减少波段的冗余性和抑制背景干扰角度考虑,对经典 Kernel RX 算法进行改进,提出了双边滤波的最优波段子集(Bilateral Filtering Optimal Band Subsets, BFOBS-KRX)高光谱异常目标检测算法。该算法利用双边滤波使异常目标点与背景图像区分度增大,然后利用自动子空间方法将高光谱图像按照波段相关性进行分段,形成不同的子空间,再利用峰度-偏度联合作为每个空间中提取最优波段的指标,得到最优波段子集,最后再利用 Kernel RX 异常算子进行异常检测,并进行了仿真验证。

2 方法

2.1 双边滤波

双边滤波是在高斯滤波器基础上,由 Tomasi 等人^[14]进行改进得到的一种非线性的滤波算法。双边滤波考虑了被滤波图像像素的空域信息及其值域信息,相较于其他滤波方法具有边缘保存的优点。在高光谱图像处理中,令高光谱图像集为

Y , 具有 L 个波段, 双边滤波器定义如下^[15]:

$$g^i(x, y) = \frac{\sum_m^n [\omega^i(x, y, m, n) Y^i(m, n)]}{\sum_m^n \omega^i(x, y, m, n)}, \quad (1)$$

给定滤波窗口为 $\mathfrak{R}$, $i=1, 2, \dots, L$, $m, n \in \mathfrak{R}$. $Y^i(m, n)$ 是高光谱图像集 Y 第 i 个波段图像坐标为 (m, n) 中的一个像元, 且 (m, n) 是滤波窗口 $\mathfrak{R}$ 的像元, (m, n) 代表双边滤波器窗口中滤波像元位置。

同时, 定义域核为 $f^i(x, y, m, n)$, 其为高斯

滤波器, 是一个空间邻近度因子, 由像元之间的空间距离决定, 如式(2)所示。

$$f^i(x, y, m, n) = \exp\left(-\frac{(x-m)^2 + (y-n)^2}{2\sigma_f^2}\right), \quad (2)$$

值域核定义为 $h^i(x, y, m, n)$, 其是像元幅度邻近度因子, 由像元之间的反射强度之差决定, 如式(3)所示。

$$h^i(x, y, m, n) = \exp\left(-\frac{\|Y^i(x, y) - Y^i(m, n)\|^2}{2\sigma_h^2}\right), \quad (3)$$

得到权重系数 $\omega^i(x, y, m, n)$:

$$\begin{aligned} \omega^i(x, y, m, n) &= f^i(x, y, m, n) \cdot h^i(x, y, m, n) = \\ &= \exp\left(-\frac{(x-m)^2 + (y-n)^2}{2\sigma_f^2}\right) \cdot \exp\left(-\frac{\|Y^i(x, y) - Y^i(m, n)\|^2}{2\sigma_h^2}\right) = \\ &= \exp\left(-\frac{(x-m)^2 + (y-n)^2}{2\sigma_f^2} - \frac{\|Y^i(x, y) - Y^i(m, n)\|^2}{2\sigma_h^2}\right) \end{aligned} \quad (4)$$

$\omega^i(x, y, m, n)$ 同时考虑了空间域与值域的差别, 参数 σ_f 和 σ_h 分别控制着反射强度因子和空间邻近度因子的衰减程度。

2.2 自动子空间

高光谱图像最突出的特点就是采用几十或者几百个波段来描述地表物质, 在对地表物质清晰展示的同时, 也存在着大量的冗余信息, 使得高光谱图像数据量巨大, 有用信息与大量的不相干信息混杂, 增大了数据处理的难度和虚警率。对高光谱图像进行波段选择, 从而进行降维处理。原则是选择出的波段可以更好地表达有用信息, 增加异常检测的精度。对波段进行选择有基于信息量和基于类间可分性等方法。本文采用基于信息量的自动子空间(ASD^[16])方法进行波段子空间划分, 达到降维的目的。

相关系数表达的是高光谱图像波段间的相关程度, ASD方法正是通过这一特点, 将高光谱图像按照波段间相关系数不同进行子空间划分。每个子空间的维数可能相同也可能不同。假定高光谱图像集 Y 任意两个波段矢量 i 和 j 之间的相关系数 R_{ij} ($0 \leq R_{ij} \leq 1$, R_{ij} 越大说明相关性越强)为

$$R_{ij} = \frac{E\{(y_i - m_i)(y_j - m_j)\}}{\sqrt{E\{(y_i - m_i)^2\}E\{(y_j - m_j)^2\}}}, \quad (5)$$

m_i 和 m_j 为均值矢量; y_i 和 y_j 为灰度值。通过设定一个阈值, 高光谱图像数据按照波段就可以划分为若干个子空间, 每个子空间内的波段具有强相关性。

2.3 联合偏度-峰度指数

偏度描述了随机变量分布的不对称程度, 而峰度则描述了随机变量密度函数曲线的陡峭程度。对标准正态分布而言, 偏度越大, 数据的不对称性越强; 峰度越大, 数据密度函数曲线越陡峭。即偏度和峰度值越大, 说明数据越偏离正态分布, 所含的信息量越大^[17]。联合偏度-峰度指数^[17-18](Joint Skewness-Kurtosis Figure, JSKF)指标, 利用偏度-峰度乘积更加有效地度量数据偏离正态分布的程度。

令高光谱图像集为 Y , 偏度定义为:

$$S = \frac{E[Y - \mu]^3}{\sigma^3}, \quad (6)$$

峰度定义为:

$$K = \frac{E[Y - \mu]^4}{\sigma^4} - 3, \quad (7)$$

式中, $E(Y)$ 是向量 Y 的期望值, μ 是向量 Y 的均值, σ 是向量 Y 的标准差。

联合偏度-峰度指数如式(8)所示:

$$JSKF = S \cdot K. \quad (8)$$

设 $y_1, y_2, \dots, y_n$ 为来自高光谱图像数据的样本数据, 得到偏度的离散形式为:

$$S = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^3 / \left(\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 \right)^{3/2}, \quad (9)$$

式中, $\bar{y} = E(Y)$ 为样本均值。

峰度的离散形式为:

$$K = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^4 / \left(\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 \right)^2 - 3, \quad (10)$$

则 JSKF 的离散形式为:

$$\text{JSKF} = S \cdot K = \left[\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^3 / \frac{1}{n} \left(\sum_{i=1}^n (y_i - \bar{y})^2 \right)^{3/2} \right] \cdot \left[\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^4 / \frac{1}{n} \left(\sum_{i=1}^n (y_i - \bar{y})^2 \right)^2 - 3 \right]. \quad (11)$$

2.4 Kernel RX 算法

Kernel RX 算法是非线性的 RX 算法^[1], 令 X 为高光谱数据, Φ 为核函数, 故核 RX 的算子可以表示为:

$$\text{KRX}(\Phi(r)) = (\Phi(r) - \hat{\mu}_{b\Phi})^T \hat{C}_{b\Phi}^{-1} (\Phi(r) - \hat{\mu}_{b\Phi}), \quad (12)$$

式中: $\hat{\mu}_{b\Phi}$ 和 $\hat{C}_{b\Phi}$ 分别为特征空间中的背景协方差矩阵和均值向量的估计值, 如式(13)和式(14)所示。

$$\hat{\mu}_{b\Phi} = \frac{1}{M} \sum_{i=1}^M \Phi(x_i), \quad (13)$$

$$\hat{C}_{b\Phi} = \frac{1}{M} \sum_{i=1}^M (\Phi(x_i) - \hat{\mu}_{b\Phi}) (\Phi(x_i) - \hat{\mu}_{b\Phi})^T, \quad (14)$$

$\hat{C}_{b\Phi}$ 为对称阵, 利用特征值分解, 可表示为:

$$\hat{C}_{b\Phi} = V_{\Phi} \Lambda_{\Phi} V_{\Phi}^T, \quad (15)$$

式中: $\Lambda_{\Phi} = \text{diag}([\lambda_1, \lambda_2, \dots, \lambda_M])$ 为 $\hat{C}_{b\Phi}$ 的 M 个非零特征值构成的对角阵, $V_{\Phi} = [v_{\Phi}^1, v_{\Phi}^2, \dots, v_{\Phi}^M]$

为对应的特征向量矩阵。

定义 $M \times M$ 中心化核矩阵 $K_c = X_{\Phi_c}^T X_{\Phi_c}$, K_c 的特征值分解可写为

$$K_c = B \Lambda_c B^T, \quad (16)$$

式中: $B = [\beta_1, \beta_2, \dots, \beta_M]$ 为特征向量矩阵, Λ_c 为对角矩阵。

$\hat{C}_{b\Phi}$ 的伪逆与 K_c 逆之间的关系可以用式(17)展开:

$$\hat{C}_{b\Phi}^{\#} = V_{\Phi} \Lambda_{\Phi}^{-1} V_{\Phi}^T = M X_{\Phi_c} K_c^{-1} X_{\Phi_c}^T, \quad (17)$$

将式(17)代入式(12)中, 忽略系数 M , 得

$$\text{KRX}(\Phi(r)) = (\Phi(r) - \hat{\mu}_{b\Phi})^T X_{\Phi_c} K_c^{-1} X_{\Phi_c}^T (\Phi(r) - \hat{\mu}_{b\Phi}). \quad (18)$$

由于特征空间的维数很高, 需要转换成核函数的形式再进行计算:

$$k(x_i, x_j) = \langle \Phi(x_i), \Phi(x_j) \rangle = \Phi(x_i) \cdot \Phi(x_j). \quad (19)$$

由于 $\Phi(r)^T X_{\Phi_c}$ 、 $\hat{\mu}_{b\Phi}^T X_{\Phi_c}$ 为特征空间的内积, 将其核函数化:

$$\begin{aligned} \Phi(r)^T X_{\Phi_c} &= \Phi(r)^T ([\Phi(x_1), \Phi(x_2), \dots, \Phi(x_M)] - \hat{\mu}_{b\Phi} 1_{1 \times M}) = k(r, X_b) - \\ &\quad \left(\frac{1}{M} \sum_{i=1}^M k(r, x_i) \right) 1_{1 \times M} \equiv k_r^T, \end{aligned} \quad (20)$$

同样

$$\begin{aligned} \hat{\mu}_{b\Phi}^T X_{\Phi_c} &= \hat{\mu}_{b\Phi}^T ([\Phi(x_1), \Phi(x_2), \dots, \Phi(x_M)] - \hat{\mu}_{b\Phi} 1_{1 \times M}) = \left(\frac{1}{M} \sum_{i=1}^M k(x_i, X_b) \right) - \\ &\quad \left(\frac{1}{M^2} \sum_{i=1}^M \sum_{j=1}^M k(x_i, x_j) \right) 1_{1 \times M} \equiv k_{\mu_b}^T, \end{aligned} \quad (21)$$

式(20)和式(21)中, $1_{1 \times M}$ 代表所有元素均为 1 的 M 维行向量。基于文献[8]的分析, 得到

$$K_b^{-1} = \beta \Lambda_b^{-1} \beta^T. \quad (22)$$

将式(20)、式(21)和式(22)带入式(18)得到了核 RX 算法的最终表达式为:

$$\text{KRX}(\Phi(r)) = (k_r^T - k_{\mu_b}^T) K_c^{-1} (k_r - k_{\mu_b}). \quad (23)$$

2.5 算法实现流程图

在充分考虑高光谱图像光谱特性和空间特性

基础上,得到的基于双边滤波的最优波段子集高光谱异常目标检测算法流程图,如图1所示。




图1 算法流程图

Fig.1 Algorithm flowchart

3 实验与讨论

3.1 数据集

高光谱异常检测算法的仿真验证一般都是通过真实的高光谱图像或者合成的高光谱图像来完成,本文采用的实验图像是异常检测研究领域比较常用的高光谱图像。美国圣地亚哥海军机场的高光谱图像是一个经典的验证异常检测算法的图像,该图像去除掉被水蒸气等严重干扰的波段后,剩余波段为126个,实验中采用的图像空间尺寸为 100×100 pixel,空间分辨率3.5 m。该图像,共有38个异常目标,如图2(a)所示。图2(b)是(a)区域对应的38个异常目标分布情况。




图2 仿真用的高光谱数据和对应的目标分布。(a)截取的第50波段 100×100 pixel的原始高光谱数据;(b)对应的目标分布。

Fig.2 Hyperspectral imagery and corresponding targets as simulation. (a) The 50th bands hyperspectral image of 100×100 pixels; (b) Truth anomaly targets distribution.

3.2 实验过程与检测结果

高光谱图像异常目标检测过程第一步是先对实验用数据集进行双边滤波处理,得到的图像数据如图3所示。通过双边滤波,使得处理后的图像数据目标点和背景数据区分度更大,相对于背景来说,异常点得到增强。

对原始高光谱图像进行双边滤波之后,利用ASD方法对滤波后的高光谱图像进行自动子空间划分,划分的依据为式(5)的相邻波段间相关系数,阈值选取的是0.9995,如图4所示,从而将整个高光谱波段空间划分为3个子空间,分别是第1个子空间(1~93),第2个子空间(94~116),第3个子空间(117~126)。然后利用联合偏度-峰度指标从每个子空间中选取最优波段,进而构成最优波段子集。

对每个波段子空间中的每个波段计算其偏度




图3 双边滤波后的第50波段高光谱数据

Fig.3 The 50th bands hyperspectral data of bilateral filtering




图 4 相邻波段相关系数曲线

Fig.4 Correlation coefficient curve of adjacent bands

和峰度,从而得到利用联合偏度-峰度指标。通过计算,第 1 个子空间最优波段为 26,第 2 个子空间最优波段为 112,第 3 个子空间最优波段为 122。它们的高光谱图像数据如图 5 所示,构成最优波段数据子集。




图 5 最优波段数据子集

Fig.5 Optimal band data subsets

利用 Kernel RX 算法对该最优波段子集进行异常目标检测,同时也仿真了经典的 KRX 算法和 RX 算法。实验中获取的总像元数是 400。从图 6 中能得知,本文提出的 BFOBS-KRX 算法在相同的检测像元情况下,目标占总像元数为 227 个,虚警占总像元数为 173 个;KRX 算法目标占总像元数为 199 个,虚警占总像元数为 201 个;RX 算法目标占总像元数为 159 个,虚警占总像元数为 241 个。由此可见,本文提出的新的异常检测算法检测精度高于经典 KRX 和 RX 算法。

图 6 是像元总数为 400 时得到的结果。为了




图 6 3 种算法的异常检测结果。(a) BFOBS-RX 算法; (b) KRX 算法; (c) RX 算法。

Fig.6 Anomaly detection results of three algorithms. (a) BFOBS-RX algorithm; (b) KRX algorithm; (c) RX algorithm.

更好地说明 BFOBS-KRX 算法的鲁棒性和有效性,选取间隔变化的像元总数为检测值(本文选取 0~300 之间间隔 25 个,共取值 13 次),选取的检测指标为目标所占数目和虚警所占数目,图 7 为目标所占像元总数图,图 8 为虚警所占像元总数图。从两个图中能得到,BFOBS-KRX 算法鲁棒性和检测精度要优于其他两种算法。




图 7 检测的目标占总像元数目比较

Fig.7 Comparison of the pixel number of detected targets

在高光谱图像异常目标检测性能分析指标中,ROC^[19-20](检测概率 P_d 与虚警概率 P_f 之间的变化关系曲线)是一个重要的指标。定义 P_d 和 P_f 为:




图8 检测的虚警占总像元数目比较

Fig.8 Comparison of the pixel number of false detection




图9 异常检测算法的 ROC 比较

Fig.9 ROC comparison of anomaly detection algorithms

$$P_d = \frac{N_{\text{hit}}}{N_{\text{target}}}, \quad (24)$$

$$P_f = \frac{N_{\text{false}}}{N_{\text{total}}}, \quad (25)$$

参 考 文 献:

- [1] 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.
- [2] ZHAO R, DU B, ZHANG L P. Hyperspectral anomaly detection via a sparsity score estimation framework [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(6): 3208-3222.
- [3] IMANI M. RX anomaly detector with rectified background [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(8): 1313-1317.
- [4] CHANG C I, CHIANG S S. Anomaly detection and classification for hyperspectral imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2002, 40(6): 1314-1325.

式中: N_{hit} 为检测到的真实目标像元数目, N_{target} 为地面真实目标像元数目, N_{miss} 为检测到的虚警像元数目, N_{total} 为整幅图像像元数目总和^[21]。

通过图9中BFOBS-KRX、KRX和RX算法ROC曲线可以看出,BFOBS算法性能明显优于其他两种算法,而且具有很强的鲁棒性。

4 结 论

在高光谱图像数据处理中,异常目标检测不同于其他处理方式,它是在没有先验条件下,从复杂的背景中检测出异常目标点。因此,对高光谱图像光谱特性和空间特性的正确处理和分析具有重要作用。KRX算法和RX算法都是经典的异常目标检测算法,但是它们在处理能力方面都存在一定不足。通过综合利用滤波技术、子空间分解、偏度和峰度等指标、KRX算法等,本文提出了一个新的异常目标检测算法,利用真实的高光谱图像进行仿真验证,证明本文提出的BFOBS-KRX算法检测精度、虚警率和鲁棒性优于经典的KRX、RX算法。该算法具有以下特点:

(1)利用双边滤波和ASD技术,对高光谱图像的光谱特性和空间特性进行有效利用,对高光谱图像的背景信息和波段冗余进行有效处理,增强了图像异常目标检测效果。

(2)利用偏度值和峰度值对数据偏离正态分布的有效描述,得到每个波段子空间中的最优波段,并建立最优波段子空间,利用其提取异常目标点,得到了较好的检测结果。

(3)由于去除了冗余的波段,高光谱图像异常目标的检测效率得到提高,也为今后高光谱图像实时处理提供了良好的基础。

- [5] GUO Q D, ZHANG B, RAN Q, *et al.* Weighted-RXD and linear filter-based RXD: improving background statistics estimation for anomaly detection in hyperspectral imagery [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2351-2366.
- [6] MOLERO J M, PAZ A, GARZÓN E M, *et al.* Fast anomaly detection in hyperspectral images with RX method on heterogeneous clusters [J]. *The Journal of Supercomputing*, 2011, 58(3): 411-419.
- [7] SCHAU A P. Hyperspectral anomaly detection beyond RX [J]. *SPIE*, 2007, 6565: 656502.
- [8] KWON H, NASRABAD 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.
- [9] ZHAO C H, LI J W, MENG M L, *et al.* A weighted spatial-spectral kernel RX Algorithm and efficient implementation on GPUs [J]. *Sensors*, 2017, 17(3): 441.
- [10] 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.
- [11] YUAN Z Z, SUN H, JI K F, *et al.* Local sparsity divergence for hyperspectral anomaly detection [J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(10): 1697-1701.
- [12] LI J Y, ZHANG H Y, ZHANG L P, *et al.* Hyperspectral anomaly detection by the use of background joint sparse representation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2523-2533.
- [13] XU Y, WU Z B, LI J, *et al.* Anomaly detection in hyperspectral images based on low-rank and sparse representation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(4): 1990-2000.
- [14] ZORTEA M, PLAZA A. Spatial preprocessing for endmember extraction [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(8): 2679-2693.
- [15] TOMASI C, MANDUCHI R. Bilateral filtering for gray and color images [C]//Proceedings of the 6th International Conference on Computer Vision. Bombay, India: IEEE, 1998: 839-846.
- [16] ZHANG Y, ZHANG J P, JIN M. Adaptive subspace decomposition and classification for hyperspectral images [J]. *Chinese Journal of Electronics*, 2000, 9(1): 82-88.
- [17] 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.
GUO L, CHANG W W, FU C Y. Band selection of optimal for hyperspectral image fusion [J]. *Journal of Astronautics*, 2011, 32(2): 374-379. (in Chinese)
- [18] 王琪, 杨枕, 张俭峰, 等. 基于局部联合偏度-峰度的高光谱图像波段选择方法[J]. 激光与光电子学进展, 2017, 54(11): 111004.
WANG Q, YANG G, ZHANG J F, *et al.* Band selection based on local joint skewness and kurtosis for hyperspectral image [J]. *Laser & Optoelectronics Progress*, 2017, 54(11): 111004. (in Chinese)
- [19] GAO G. A parzen-window-kernel-based CFAR algorithm for ship detection in SAR images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2011, 8(3): 557-561.
- [20] IMANI M. Hyperspectral anomaly detection using differential image [J]. *IET Image Processing*, 2018, 12(5): 801-809.
- [21] ZHAO R, DU B, ZHANG L P, *et al.* A robust background regression based score estimation algorithm for hyperspectral anomaly detection [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 122: 126-144.

作者简介:



成宝芝(1976—),男,吉林东丰人,博士,副教授,2012年于哈尔滨工程大学获得博士学位,2014年进入哈尔滨工程大学计算机科学与技术博士后流动站,2017年9月出站,主要从事高光谱图像处理与大数据分析方面的研究。E-mail: chengbaozhig@163.com