

引用格式: A Ruhan, YUAN Xiaobin, MU Xiaodong, et al. Hyperspectral Abnormal Target Detection Based on Extended Multi-attribute Profile and Fast Local RX Algorithm[J]. Acta Photonica Sinica, 2021, 50(9):0910002

阿茹罕,原晓斌,慕晓冬,等. 结合扩展多属性剖面与快速局部RX算法的高光谱异常目标检测[J]. 光子学报, 2021, 50(9): 0910002

结合扩展多属性剖面与快速局部RX算法的高光谱异常目标检测

阿茹罕¹,原晓斌²,慕晓冬¹,王静怡³

(1 火箭军工程大学 作战保障学院, 西安 710025)

(2 中国科学院西安光学精密机械研究所, 西安 710119)

(3 西安石油大学 计算机学院, 西安 710065)

摘要:为进一步提高高光谱异常目标检测的速度与精度,提出一种基于扩展多属性剖面和改进的Reed-Xiaoli算法相结合的快速异常目标检测方法。通过数学形态学变换从高光谱图像中提取扩展多属性剖面,同时提出一种快速局部Reed-Xiaoli算法,利用矩阵求逆引理迭代更新协方差矩阵的逆,从而降低马氏距离的计算复杂度。将扩展多属性剖面与快速局部Reed-Xiaoli算法相结合,充分利用高光谱图像的光谱信息和空间信息,有效提高探测速度与精度。在3个不同的数据集上与其他经典异常目标检测方法进行比较,实验结果表明,所提算法AUC值分别为0.996 7、0.985 6、0.981 6,运算时间分别为21.218 1 s、15.192 8 s、32.337 9 s。该方法在检测精度和速度上都有明显的优势,具有良好的实用价值。

关键词:高光谱图像;异常目标检测;快速局部RX;扩展多属性剖面;Reed-Xiaoli;矩阵求逆引理

中图分类号:TP394.1;TH691.9

文献标识码:A

doi:10.3788/gzxb20215009.0910002

Hyperspectral Abnormal Target Detection Based on Extended Multi-attribute Profile and Fast Local RX Algorithm

A Ruhan¹, YUAN Xiaobin², MU Xiaodong¹, WANG Jingyi³

(1 College of Operational Support, Rocket Force University of Engineering, Xi'an 710025, China)

(2 Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences 710119, China)

(3 School of Computer Science, Xi'an Shiyou University, Xi'an 710065, China)

Abstract: In order to further improve the speed and accuracy of hyperspectral abnormal target detection, a fast anomaly target detection method based on extended multi-attribute profiles and improved Reed-Xiaoli is proposed. Extended multi-attribute Profiles are extracted from the original hyperspectral images by mathematical morphological transformations. Moreover, a novel fast local Reed-Xiao algorithm is also proposed. Iteratively update inverse matrix of covariance using matrix inverse lemma, thereby reducing the computational complexity of the Mahalanobis distance. The combination of extended multi-attribute profiles and fast local Reed-Xiaoli detector effectively utilizes the spectral information and spatial information of hyperspectral images, it greatly improves the detection accuracy and reduce the running time. Experimental results on three real data sets show the AUC value of the algorithm in this paper is 0.996 7, 0.985 6 and 0.981 6 respectively. The operation time is 21.218 1 s, 15.192 8 s and 32.337 9 s respectively. The proposed method has obvious advantages in detection accuracy and speed, and has good

基金项目:国家自然科学基金(Nos.41301480,62002286)

第一作者:阿茹罕(1989—),女,讲师,博士研究生,主要研究方向为遥感图像处理及机器学习。Email: aruhan890309@163.com

导师(通讯作者):慕晓冬(1965—),男,教授,博士,主要研究方向为目标识别、智能算法。Email: Mu_403@163.com

收稿日期:2021-03-08;录用日期:2021-05-06

<http://www.photon.ac.cn>

practical value.

Key words: Hyperspectral image; Anomaly detection; Fast local RX; Extended multi-attribute profiles; Reed-Xiaoli; Matrix inverse lemma

OCIS Codes: 100.4145; 100.4999; 100.2000

0 引言

高光谱遥感图像由于具有较高的分辨率和丰富的光谱信息,被广泛应用于图像分类^[1-2]、光谱解混、图像去噪、变化检测、目标检测和异常目标检测^[3-4]等遥感相关领域。特别是高光谱异常目标检测,已经广泛应用于军事、农业、矿产、环境监测^[5]、公共安全等领域。由于异常目标的先验信息往往难以获取,因此无先验知识的异常目标检测方法已成为研究的热点。

REED I S提出了RX异常探测算法(Reed-Xiaoli Detection, RXD)^[6]。RX算法是经典的异常目标检测算法之一,已成功应用于许多领域。RX方法通过计算待测像素与背景数据均值之间的马氏距离来检测异常目标。有两个版本的RX算法:全局RX(Global RX, GRX)和局部RX(Local RX, LRX)。全局RX算法用整个图像的背景估计统计量,而局部RX算法用局部背景估计统计量。近年来,许多基于RX的改进算法也被提出,如LI Z和ZHANG Y提出了一种基于改进RX的CNN框架高光谱异常检测方法^[7];HIDALGO J A P等提出高效的非线性RX异常检测器^[8];REN L等提出了基于超像素的双窗RX(Superpixel-based Dual Window RX, SPDWRX)异常检测算法^[9];IMANI M提出了净化背景的MML-RX算法^[10],等等。

LI W和DU Q提出一种基于协同表示的异常目标检测(Collaborative Representation Detection, CRD)算法^[11]。CRD也是一种非常经典的异常目标检测算法。与LRX算法类似,CRD在一个滑动双窗中收集背景数据。CRD的基本思想是背景像素可以用周围的数据线性表示,而异常像素不能。CRD通过从原始高光谱图像中减去近似估计的背景来检测异常像素。同时该方法进一步拓展提出核CRD。MA N等在CRD的基础上提出了一种快速迭代的RCRD(Recursive Collaborative Representation Detection, RCRD)算法^[12]。通过两个初等变换矩阵建立相邻像素双窗之间的联系,利用矩阵求逆引理迭代更新协同表示,以此降低计算复杂度,提高检测速度。在CRD算法中,滑动双窗中可能存在异常值,影响背景估计。WU Z和SU H提出了PCARoCRD的高光谱异常检测方法(Collaborative Representation Detector with PCA Remove Outlier, PCARoCRD)^[13],该方法通过主成分分析法对背景数据进行净化。其基本思想为:前几个主成分包含大部分背景信息,后几个主成分包含异常目标信息。选取前几个主成分作为协同表示的样本,去除背景中的异常值,从而有效提高异常目标的检测精度。

除此之外,还有一类基于低秩稀疏矩阵分解的异常目标检测方法^[14]。低秩稀疏矩阵分解(Low-Rank and Sparse Matrix Decomposition, LRaSMD)方法的基本思想是背景图像是低秩的,异常目标的分布是稀疏的,噪声服从高斯分布。利用GoDec算法对异常目标矩阵和背景矩阵进行分离。计算每个像素点与异常目标矩阵均值之间的欧氏距离,结果大于阈值的则认为是异常目标。ZHANG Y等提出了一种基于低秩稀疏矩阵分解的马氏距离(LRaSMD-based Mahalanobis Distance Method for Hyperspectral Anomaly Detection, LSMAD)^[15]。使用LRaSMD算法分离背景矩阵和异常目标矩阵。计算背景矩阵的统计量,利用背景统计量构造马氏距离,并根据马氏距离检测异常目标。SONG S等提出基于图字典的低秩分解与纹理特征提取的高光谱异常检测方法(Graph Dictionary-based Low Rank Decomposition with Texture Feature Extraction, GLRD_TFE)^[16]。该方法利用图像傅里叶变换和图拉普拉斯矩阵构建一个背景字典用于低秩分解。并从高光谱图像中提取纹理特征,与低秩模型相结合,通过分解得到稀疏分量。

数学形态学也被广泛应用于高光谱图像特征提取,BENEDIKTSSON J A等提出扩展形态剖面(Extended Multi-Attribute Profile, EMAP)方法^[17],该方法首先对高光谱图像进行主成分分析,选取前几个主成分,然后通过形态学变换得到每个主成分的形态学剖面(Morphological Profiles, MPs),将所有的形态学剖面叠加在一起形成扩展形态学剖面,然后应用神经网络进行分类。DALLA MURA M和BENEDIKTSSON J A又提出了形态学属性剖面(Attribute Profiles, APs)^[18]。通过形态学属性滤波获得属性剖面,APs可提供图像的多级特征。他们进一步又提出了扩展属性剖面和扩展多属性剖面^[19]。ANDIKA F等提出了一种形态学剖面与属性滤波(Morphological Profile and Attribute Filter, MPAF)算法。该方法采

用熵值法和直方图计数法对高光谱图像进行降维,采用形态学剖面法剔除背景像素,采用属性滤波法对伪异常像素进行区域判定^[20]。

如上所述,RX方法是一种应用广泛且有效的异常目标检测算法。LRX算法通过双窗滑动收集背景数据,然后计算每个像素对应的协方差矩阵的逆。因此,该算法的计算复杂度高,实时性较差。为了有效地减少计算量,对LRX算法进行改进,提出了快速LRX算法。同时,为了充分利用高光谱的空间结构信息,将扩展多属性剖面应用到异常目标检测当中,提出了一种结合多属性剖面与快速LRX的高光谱异常目标检测算法。

1 RX算法

三维的高光谱数据可表示为 $\bar{x} \in R^{m \times n \times J}$,其中, m 为行数, n 为列数, J 为波段数,也可以表示成一个矩阵 $X = [x_1, x_2, \dots, x_M] \in R^{M \times J}$, $M = m \times n$ 为测试像素总数。RX算法假设原始数据服从多元高斯分布,建立二值假设

$$H_0: x \sim (\mu_b, C_b) \quad (1)$$

$$H_1: x \sim (\mu_s, C_b) \quad (2)$$

异常目标与背景服从多元高斯分布,协方差相同但均值不同。 μ_b 和 μ_s 分别代表背景均值和异常目标均值, C_b 表示背景协方差矩阵。在原假设 H_0 下,数据(背景)服从 $N(\mu_b, C_b)$ 分布;在备择假设 H_1 下,数据(异常目标)服从 $N(\mu_s, C_b)$ 分布;RX算法是在样本个数趋于无穷时,根据广义似然比检验推导出来的。RX算法可简化表示为

$$\delta_{RX}(x_i) = (x_i - \mu_b)^T C_b^{-1} (x_i - \mu_b) \quad (3)$$

设定阈值 η ,如果 $\delta_{RX}(x_i) < \eta$,则原假设成立(异常目标不存在);如果 $\delta_{RX}(x_i) > \eta$,则备择假设为真(异常目标存在)。RX方法通过计算待测像素与背景数据均值之间的马氏距离来检测异常目标。由于背景数据收集方法的不同,有两个版本的RX算法:全局RX和局部RX。GRX算法收集所有像素来估计背景均值和协方差,计算方法为

$$\mu_b = \frac{1}{M} \sum_{i=1}^M x_i \quad x_i \in X \quad (4)$$

$$C_b = \frac{1}{M} \sum_{i=1}^M (x_i - \mu_b)(x_i - \mu_b)^T \quad x_i \in X \quad (5)$$

由于异常目标或噪声可能存在于背景中,该方法对背景统计量的估计精度较差。LRX算法建立以被测像素为中心的双窗,通过双窗的滑动收集背景数据。如图1所示,收集外窗与内窗之间的像素作为背景信息 $X_b = [x_1, x_2, \dots, x_s] \in R^{s \times J}$ 。外窗大小 $\omega_{out} \times \omega_{out}$,内窗大小 $\omega_{in} \times \omega_{in}$, $s = \omega_{out} \times \omega_{out} - \omega_{in} \times \omega_{in}$ 是收集样本的

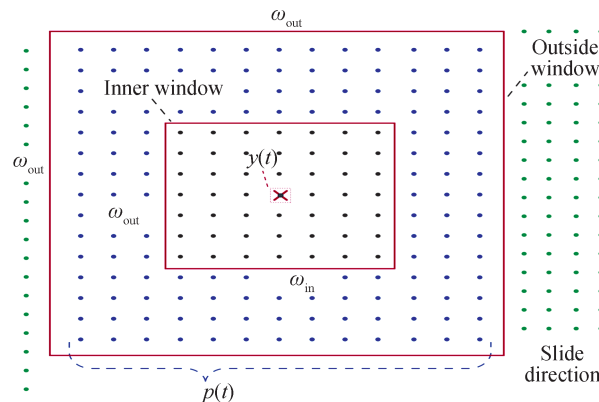


图1 双窗与待测像素

Fig. 1 Local dual-window and the undertest pixel

总数($s \geq J$)。背景统计量的计算表达式为

$$\mu_b = \frac{1}{s} \sum_{i=1}^M x_i \quad x_i \in X \quad (6)$$

$$C_b = \frac{1}{s} \sum_{i=1}^s (x_i - \mu_b)(x_i - \mu_b)^T \quad x_i \in X_b \quad (7)$$

由式(6)和(7)可以看出,异常像素对背景统计量的影响降低,能够有效提高检测精度。但由于需要为每个像素建立一个双窗来收集数据并计算马氏距离,不可避免地增加了计算量。

2 算法介绍

2.1 扩展多属性剖面

为了在异常目标检测中充分利用高光谱图像的空间信息和光谱信息,利用数学形态学变换从图像中提取空间特征,并将其与光谱特征相结合。扩展多属性剖面^[19]是基于多种属性滤波提取出的图像结构特征。属性剖面(AP)是基于属性滤波对输入图像按照一组有序阈值进行多级分解,通过一系列粗化和细化操作得到图像的属性剖面。AP^[19]可被定义为一组粗化操作 $\Pi_{\phi^{T'_i}}$ 和细化操作 $\Pi_{\phi^{T'_j}}$ 的组合,即

$$AP(f) = \Pi_i: \begin{cases} \Pi_i = \Pi_{\phi^{T'_i}}, & \lambda = (n-1+i) & \forall \lambda \in [1, n] \\ \Pi_i = \Pi_{\phi^{T'_j}}, & \lambda = (i-n-1) & \forall \lambda \in [n+1, 2n+1] \end{cases} \quad (8)$$

$T' = \{T_1, T_2, \dots, T_n\}$ 是一组有序的属性阈值, $T_1, T_j \in T', j \geq i$ 且 $T_i \subseteq T_j$ 。高光谱图像维数较高,因此首先对原始图像进行主成分分析,保留包含绝大部分信息的前 q 个主成分(Principal Component, PC)。对每个PC进行形态学属性剖面操作获得AP,并将每个PC的AP进行叠加,得到扩展属性剖面,EAP^[19]可表示为

$$EAP = \{AP(PC_1), AP(PC_2), \dots, AP(PC_q)\} \quad (9)$$

为了获取更多图像结构特征,可以使用多种不同属性滤波运算EAP。将不同属性的EAP合并到一个数据结构中形成EMAP。由 m 个EAP组成的EMAP^[19]可表示为

$$EMAP = \{EAP_{a_1}, EAP'_{a_2}, \dots, EAP'_{a_m}\} \quad (10)$$

式中, a_i 是一个形态学属性, $EAP' = EAP\{PC_1, \dots, PC_q\}$ 。最终的EMAP可表示为 $X_{EMAP} = [x_1, x_2, \dots, x_M] \in R^{M \times d}$, M 是总的样本数, d 与PC的数量以及所用属性相关参数有关。例如,使用4个属性,每个属性会生成9个特征图像,并保留前5个PC,那么 $d = 4 \times 9 \times 5 = 180$ 。

2.2 快速LRX算法

根据矩阵求逆引理^[21],以一种迭代更新协方差矩阵逆的方法来提高探测速度。Sherman与Morrison提出矩阵求逆引理(Sherman-Morrison公式)。令 A 是一个 $n \times n$ 的可逆矩阵,并且 x 和 y 是两个 $n \times 1$ 向量,使得 $(A + xy^T)$ 可逆,则

$$(A + xy^T)^{-1} = A^{-1} - (A^{-1}xy^T A^{-1}) / (1 + y^T A^{-1}x) \quad (11)$$

Woodbury将矩阵求逆引理进一步推广为矩阵之和的求逆公式

$$\begin{aligned} (A + UB)^{-1} &= A^{-1} - A^{-1}UB(B + BVA^{-1}UB)^{-1}BVA^{-1} \\ &= A^{-1} - A^{-1}U(I + BVA^{-1}U)^{-1}BVA^{-1} \end{aligned} \quad (12)$$

或者

$$(A - UV)^{-1} = A^{-1} + A^{-1}U(I - VA^{-1}U)^{-1}VA^{-1} \quad (13)$$

$$(A + UV)^{-1} = A^{-1} - A^{-1}U(I + VA^{-1}U)^{-1}VA^{-1} \quad (14)$$

式中, $B \in R^{n \times n}$, $U \in R^{n \times m}$, $V \in R^{m \times n}$, 矩阵 $I + VA^{-1}U$ 为容量矩阵(capacitance matrix)。若 $U = x$, $V = y^T$, $B = k$ 为一个常数时。Woodbury矩阵求逆引理可表示为

$$(A + \mathbf{xy}^T)^{-1} = A^{-1} - k(A^{-1}\mathbf{xy}^T A^{-1}) / (1 + \mathbf{y}^T A^{-1}\mathbf{x}) \quad (15)$$

具体地说,双窗在图像上滑动,当前像素的双窗与前一像素的双窗之间存在一定关联。当双窗滑动一个像素时,双窗内的大部分像素保持不变,只有少数像素发生改变。如图2,每个点代表一个像素,以当前像素 $x(t)$ 为中心的双窗 $P(t)$ 是红色的,以前一时刻像素 $x(t-1)$ 为中心的双窗 $P(t-1)$ 是蓝色的。当双窗从 $P(t-1)$ 滑动到 $P(t)$ 时,蓝色的点从双窗中移出,红色的点进入双窗,而绿色的点代表没有发生改变的像素。由于这一特性,每个像素的协方差矩阵的逆可以通过矩阵求逆引理迭代更新得到。 $C_b(t)$ 表示当前双窗内的协方差矩阵, $C_b(t-1)$ 表示前一时刻双窗内的协方差矩阵。 q_1 和 q_2 代表图2中从双窗中移除的蓝色点,将 q_1 和 q_2 合并为一个矩阵 $\mathbf{Q}^{J \times (\omega_{out} + \omega_{in})}$, w_1 和 w_2 为进入双窗的红色点,将 w_1 和 w_2 合并为矩阵 $\mathbf{W}^{J \times (\omega_{out} + \omega_{in})}$ 。根据矩阵求逆引理, $C_b(t)^{-1}$ 可通过式(16)和(17)得到。

$$\mathbf{Z}^{-1} = (C_b(t-1) - \mathbf{Q}\mathbf{Q}^T)^{-1} = C_b(t-1)^{-1} + C_b(t-1)^{-1}\mathbf{Q}(I - \mathbf{Q}^T C_b(t-1)^{-1}\mathbf{Q})^{-1}\mathbf{Q}^T C_b(t-1)^{-1} \quad (16)$$

$$C_b(t)^{-1} = (\mathbf{Z} + \mathbf{W}\mathbf{W}^T)^{-1} = \mathbf{Z}^{-1} - \mathbf{Z}^{-1}\mathbf{W}(I + \mathbf{W}^T \mathbf{Z}^{-1}\mathbf{W})^{-1}\mathbf{W}^T \mathbf{Z}^{-1} \quad (17)$$

式中, I 是单位矩阵,该算法需计算初始样本的 $C_b(1)^{-1}$ 。式(17)的结果可以用来计算LRX算法当中的马氏距离,其计算表达式为

$$\delta_{\text{FLRX}}(\mathbf{x}_i) = (\mathbf{x}_i - \boldsymbol{\mu}_b)^T C_b(t)^{-1} (\mathbf{x}_i - \boldsymbol{\mu}_b) \quad (18)$$

设定阈值 η , 如果 $\delta_{\text{FLRX}}(\mathbf{x}_i) < \eta$, 则原假设成立(异常目标不存在); 如果 $\delta_{\text{FLRX}}(\mathbf{x}_i) > \eta$, 则备择假设为真(异常目标存在)。矩阵求逆的复杂度一般为 $O(J^3)$, LRX算法中 $C_b(t)^{-1}$ 的计算量为 $J^3 + sJ^2$, 其中 $s = \omega_{out} \times \omega_{out} - \omega_{in} \times \omega_{in}$ 是双窗内收集样本的总数 ($s \geq J$)。根据式(16)、(17), FLRX算法中 $C_b(t)^{-1}$ 的计算量减少到 $4hJ^2 + 4h^2J + 2h^3$, 其中 $h = \omega_{out} + \omega_{in}$, 远远小于 s 。LRX算法当中的马氏距离, 即式(3)遍历 M 个样本的计算量为 $J^3M + (s+1)J^2M + JM$ 。本文提出的FLRX算法中, 式(18)遍历 M 个样本的计算量为 $(4h+1)J^2M + (4h^2+1)JM + 2h^3M$, 计算复杂度由 $O(J^3)$ 降为 $O(J^2)$ 。双窗在整个图像上滑动, 水平滑动如图2(a), 垂直滑动如图2(b)。

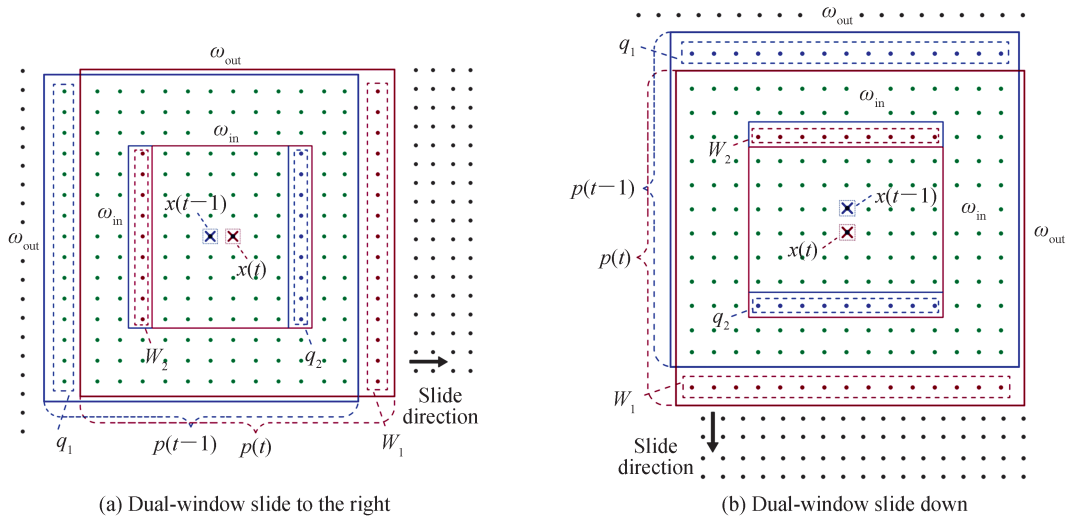


图2 双窗口在高光谱图像上滑动
Fig. 2 Dual-window sliding on HSI

2.3 EMAP-FLRX 算法

为了融合有价值的空间特征和光谱特征, 结合上述两种算法, 提出了结合多属性剖面与快速LRX的高光谱异常目标检测(Extended Multi-Attribute Profiles and Fast LRX-based Anomaly Detector, EMAP-FLRX)算法。利用数学形态学滤波对高光谱图像进行预处理, 提取高光谱图像的空间结构特征, 并将其应

用于快速LRX算法中,提出的EMAP-FLRX方法流程如图3。首先对原始高光谱图像进行主成分分析,保留前 q 个主成分。对每个PC通过一系列粗化和细化操作获得AP,将每个PC的AP堆叠生成EAP,根据不同的属性滤波计算不同的EAP,并将多种不同属性的EAP堆叠拓展成EMAP,即 $X_{EMAP} \in R^{M \times d}$ 。 $X_{EMAP} \in R^{M \times d}$ 取代原始高光谱数据,作为输入数据应用到FLRX算法当中。二元假设不变,式(3)可表示为

$$\delta_{EMAP-FLRX}(x_i) = (x_i - \mu_b)^T C_b(t)^{-1} (x_i - \mu_b) \quad (19)$$

式中, $x_i = [x_{i1}, x_{i2}, \dots, x_{ij}] \in R^{d \times 1}$ 是 X_{EMAP} 中某像素的光谱向量。 $C_b(t)^{-1}$ 根据矩阵求逆引理迭代更新获得。设定阈值 η ,如果 $\delta_{EMAP-FLRX}(x_i) < \eta$,则原假设成立(异常目标不存在);如果 $\delta_{EMAP-FLRX}(x_i) > \eta$,则备择假设为真(异常目标存在)。

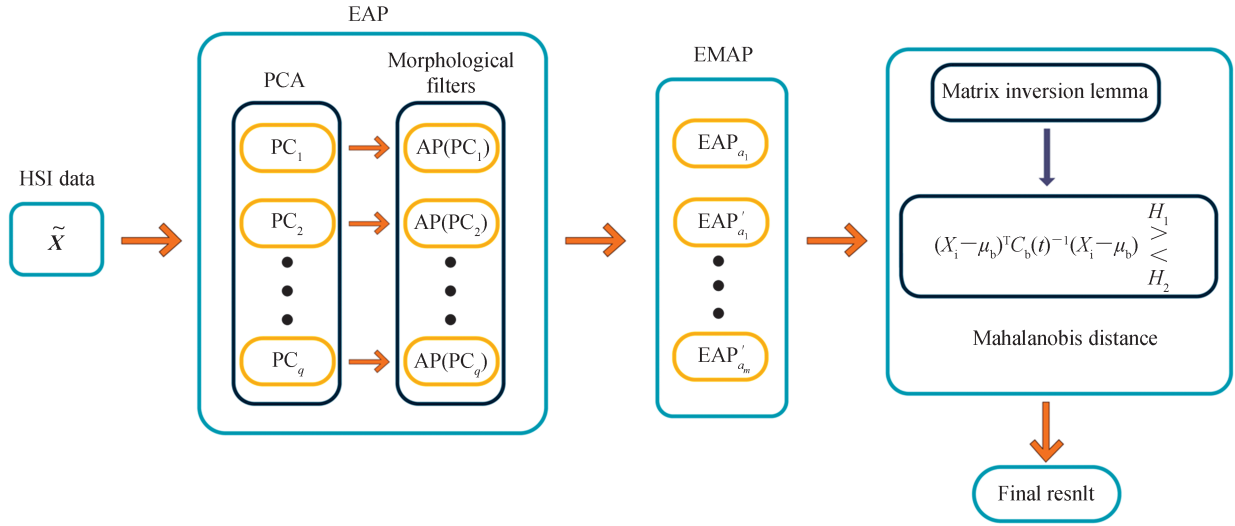


图3 EMAP-FLRX方法流程
Fig. 3 The flowchart of the EMAP-FLRX method

3 实验与分析

3.1 实验数据

为了评价EMAP-FLRX算法的检测性能,在3个数据集上进行实验。数据集详细描述如下:

1) AVIRIS-I: 这是一张由AVIRIS传感器拍摄的圣地亚哥海军机场的高光谱图像。原始图像大小为 $400 \text{ pixel} \times 400 \text{ pixel}$,截取左上角大 120×120 的子图像用于实验。消除低信噪比、受传感器故障影响和水蒸气吸收的波段,保留189个光谱波段,空间分辨率为 3.5 m/pixel 。图中三架飞机被视为异常目标。

2) abu-airport-2: 该数据集来源于Airport-Beach-Urban (ABU)数据集^[22],ABU数据集包含三个场景:机场场景、海滩场景和城市场景。abu-airport-2属于机场场景,由AVIRIS传感器拍摄于洛杉矶,大小为 $100 \text{ pixel} \times 100 \text{ pixel}$,空间分辨率为 7.1 m/pixel ,包含205个波段。在该场景中,两架飞机被视为异常目标。

3) abu-beach-4: 该数据集来源于ABU数据集的海滩场景^[22]。abu-beach-4数据集由ROSIS-03传感器拍摄于帕维亚。图像大小为 $150 \text{ pixel} \times 150 \text{ pixel}$,空间分辨率为 1.3 m/pixel ,包含102个波段。在该场景中,桥上的车辆被视为异常目标。

3.2 评价标准

ROC曲线(Receiver Operating Characteristic Curve, ROC)和ROC曲线下面积AUC(Area under the Curve of ROC, AUC)值常用来评价检测的准确性。ROC是由真阳性率(TPR)和假阳性率(FPR)在不同阈值下对应点形成的连续曲线。TPR和FPR的计算表达式为

$$\text{TPF} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (20)$$

$$FPR = \frac{FP}{TN + FP} \quad (21)$$

式中,TP为真阳性,FN为假阴性,TN为真阴性,FP为假阳性。TPF表示在所有异常像素中正确探测到的像素的比例,而FPR表示在所有背景像素中错误探测到的像素的比例。在ROC空间中, x 轴为FPR, y 轴为TPF;ROC曲线离左上角越近,AUC值越接近1,算法的探测性能越好。除此之外,本文还将根据算法运行时间衡量计算效率。

3.3 实验与结果

为了验证EMAP-FLRX算法的性能,将与GRX、LRX、CRD、LRaSMD、LSMAD和FLRX算法进行比较。对于EMAP-FLRX算法,保留了前5个主成分(累计贡献率95%以上)。使用了四种不同的属性滤波:面积属性、对角线长度属性、灰度值标准差属性和转动惯量属性。为每个属性分别设置四个属性阈值,从而每个属性生成9个特征图像,得到的EMAP表示为 $X_{EMAP} \in R^{M \times d}$,其 $d = 4 \times 9 \times 5 = 180$ 。将 $X_{EMAP} \in R^{M \times d}$ 作为FLRX算法的输入值,而不是原始图像。由于GRX、LRX、CRD、FLRX、EMAP-FLRX算法的性能对双窗的选择很敏感,因此,设定内窗取值范围:3~33,外窗取值范围:5~35,在此范围内通过实验比较不同大小双窗的AUC值来选择算法的最优双窗。对于CRD算法,正则化参数 λ 设置为 10^{-6} 。LRaSMD和LSMAD算法参数设置与文献[15]、[16]一致。EMAP-FLRX算法与其他六种算法的AUC值,见表1,运行时间见表2。为了避免系统脉冲误差对实验结果的干扰,选取5次测试结果的平均值作为实验的最终结果。所有实验均在阿里云服务器(ecs.c6e.large)上进行,2 vCPU, 4GIB内存,软件使用MATLAB 2019a。

表 1 AUC值对比
Table 1 AUC values comparison

Dataset	GRX	LRX	CRD	LRaSMD	LSMAD	FLRX	EMAP-FLRX
AVIRIS-1	0.911 1	0.962 3(31,13)	0.992 5(17,15)	0.820 2	0.977 2	0.961 6(31,13)	0.996 7(23,15)
abu-airport-2	0.840 4	0.976 7(21,17)	0.980 5(19,17)	0.829 5	0.936 2	0.974 9(21,17)	0.985 6(21,17)
abu-beach-4	0.953 8	0.981 0(35,25)	0.978 2(35,23)	0.758 7	0.962 6	0.981 0(35,25)	0.981 6(31,3)

表 2 运行时间对比(秒)
Table 2 Running time comparison (s)

Dataset	GRX	LRX	CRD	LRaSMD	LSMAD	FLRX	EMAP-FLRX
AVIRIS-1	0.000 9	135.543 9	16.791 8	37.453 0	37.521 8	26.707 6	21.2181
abu-airport-2	0.000 9	63.306 0	14.725 9	27.902 5	27.9984	20.476 3	15.192 8
abu-beach-4	0.005 0	60.081 7	3 244.332 2	21.156 5	21.083 4	45.394 7	32.337 9

在AVIRIS-1数据集上,LRX、CRD、FLRX、EMAP-FLRX算法对双窗大小敏感,因此,设定内窗取值范围:3~33,外窗取值范围:5~35,在此范围内通过实验比较不同大小双窗的AUC值来选择算法的最优双窗。通过实验比较LRX、CRD、FLRX、EMAP-FLRX双窗大小分别确定为(31,13)、(17,15)、(31,13)、(23,15)。七种算法的AUC条形图和ROC曲线如图4,结合表1和图4(a)可知,本文提出的EMAP-FLRX算法AUC值为0.9967,远远大于其他算法,除此之外,算法AUC值从大到小依次为CRD、LSMAD、LRX、FLRX、GRX、LRaSMD。如图4(b),FLRX和LRX的ROC曲线基本重叠,左上角略有差异,可见FLRX作为LRX的改进算法保持了原有的探测精度。七种算法中,EMAP-FLRX算法的ROC曲线最接近左上角,其他算法均在其ROC曲线下方,也验证了EMAP-FLRX算法融合形态学特征后探测精度显著提高。七种算法的运行时间如表2所示:GRX由全局数据作为背景估计统计量,计算复杂度低,运行时间最短,但受背景中异常值影响,探测精度较低,AUC值仅为0.9111。FLRX算法通过双窗收集背景数据,降低了异常像素对背景统计量的影响,同时利用矩阵求逆引理迭代更新协方差矩阵的逆,解决了对每个像素建立双窗计算马氏距离所造成的计算量增加的问题。FLRX算法的运行时间为26.7076s,逊于GRX算法的0.0009s,但AUC值为0.9616,远远高于GRX,总体性能明显优于GRX算法。CRD算法运行时间为16.7918s,仅次于GRX。由于双窗大小选择(17,15),双窗内数据规模不大,运行速度较快,但AUC值低于EMAP-FLRX算

法。七种算法中LRX算法耗时最长,由于需要为每个像素建立双窗来收集数据并计算马氏距离,不可避免地增加了计算量。EMAP-FLRX算法耗时21.218 1s,相比LRX、LRaSMD、LSMAD和FLRX算法分别节省了84.35%、43.34%、43.45%、20.55%的运行时间。图5为七种算法的探测结果二值图,由图可知GRX和LRaSMD算法探测失败。LRX、FLRX、CRD和LSMAD算法可以探测出异常目标的位置和形状,但将大量背景像素误判为异常目标。本文提出的EMAP-FLRX算法探测结果最好,能够准确地探测出三架飞机的位置和形状,且背景噪声较小。

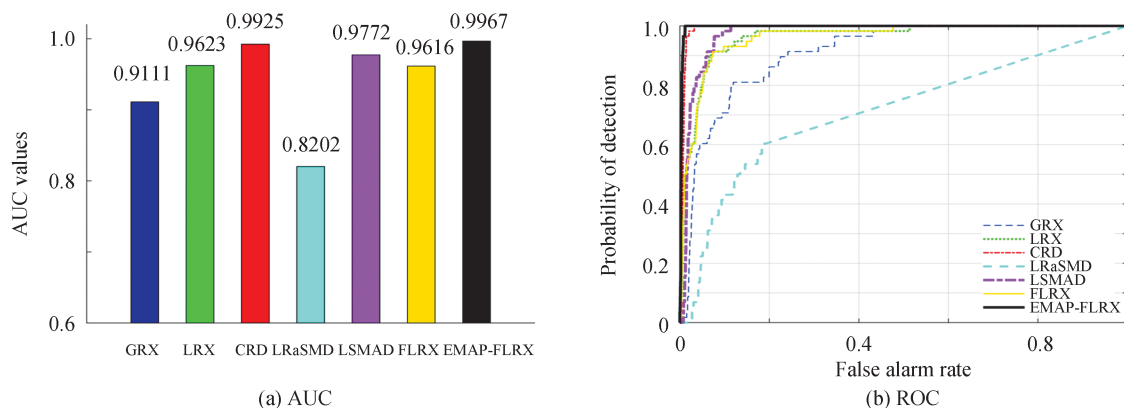


图4 在AVIRIS-I数据集上的探测精度
Fig. 4 Detection accuracy evaluation for the AVIRIS-I dataset




图5 AVIRIS-I不同算法探测结果二值图
Fig. 5 Detection maps obtained by different algorithms for the AVIRIS-I dataset

在abu-airport-2数据集上,通过实验比较LRX、CRD、FLRX和EMAP-FLRX算法的最优双窗口,分别选择(21, 17)、(19, 17)、(21, 17)、(21, 17)。七种算法的AUC条形图和ROC曲线如图6。图6(b)显示,EMAP-FLRX的ROC曲线最接近左上角,其次是CRD、FLRX和LRX。结合表1和图6(a)中的AUC值可知EMAP-FLRX曲线下面积最大,探测性能最佳。FLRX的AUC值为0.974 9,FLRX融合EMAP特征后(EMAP-FLRX)的AUC值为0.985 6,明显优于其他算法,可见在目标探测过程中增加了空间结构信息的利用,目标探测能力有了很大的提升。LRaSMD利用图像分解后的异常成分进行异常检测,探测结果的鲁棒性较差,AUC值最小为0.829 5。由表2可知,GRX运行时间最短,探测精度过低。CRD运行时间次之,探测精度0.980 5,低于EMAP-FLRX。LRaSMD和LSMAD都是基于图像分解的算法运算速度相差不大。LRX和FLRX算法运行时间上存在显著差异,分别为63.306 0 s和20.476 3 s,FLRX算法节省67.655 0%的运行时间。EMAP-FLRX算法耗时15.192 8 s,相比LRX、LRaSMD、LSMAD和FLRX算法分别节省

76.001%、45.55%、45.74%、25.80%的运行时间,可见所提出的EMAP-FLRX算法在探测精度和运行速度上都具备显著优势。由七种算法的探测结果二值图(图7)可知,GRX、CRD和LSMAD算法探测到两架飞机的位置,但形状不完整。LRX、LRaSMD和LFRX算法将大量背景像素误判为异常目标。本文提出的EMAP-FLRX探测到了异常目标的位置和形状,背景相对干净。

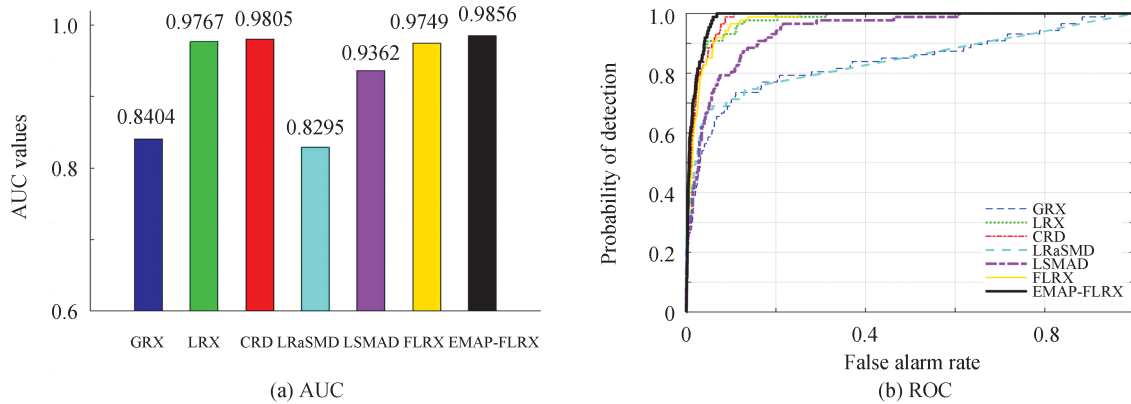


图6 在abu-airport-2数据集上的探测精度

Fig. 6 Detection accuracy evaluation for the abu-airport-2 dataset

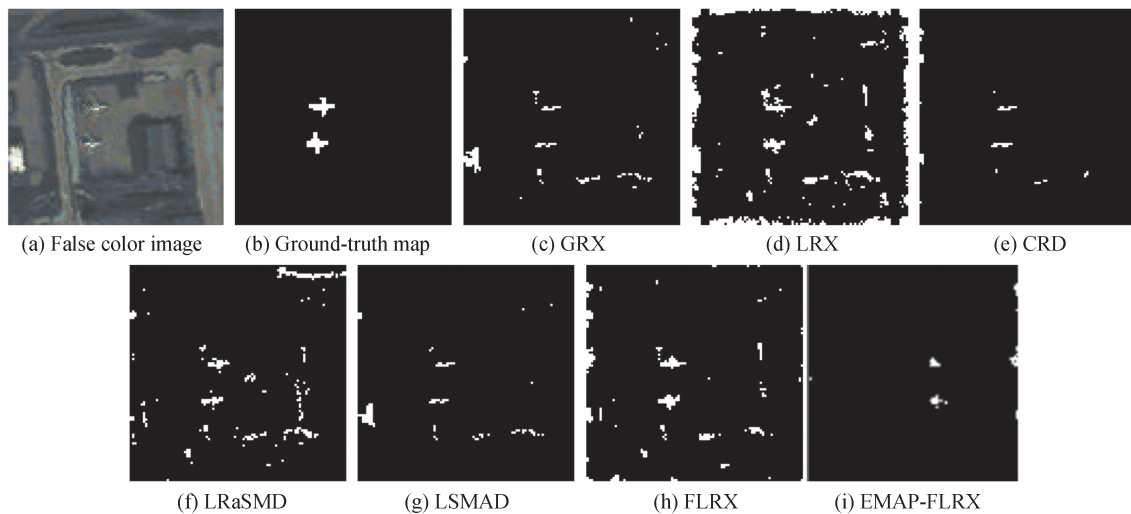


图7 abu-airport-2不同算法探测结果二值图

Fig. 7 Detection maps obtained by different algorithms for the abu-airport-2 dataset

在abu-beach-4数据集上,通过实验对比LRX、CRD、FLRX和EMAP-FLRX算法的双窗,分别选择为(35,25)、(35,23)、(35,25)和(31,3)。七种算法的AUC条形图和ROC曲线如图8。图8(b)中算法ROC曲线目视差异不显著,可结合表1和图8(a)中的AUC对算法性能进行评估,EMAP-FLRX的AUC值最大,其次是LRX和FLRX。CRD探测性能尚可,但运行速度最慢为3244.3s,这取决于目标尺寸大小,目标尺寸越大,运行时间越长。从表2可知,在计算速度方面,GRX算法最快,仅耗时0.005s,但探测精度并不理想。EMAP-FLRX算法耗时32.3379s,相比LRX、CRD和FLRX算法分别节省46.18%、99.00%、28.76%的运行时间。图9为七种算法的探测结果二值图,与其他算法相比,LRX、FLRX和CRD算法只探测到少数异常目标位置且形状不完整。GRX、LRaSMD、LSMAD算法将桥梁误判为异常目标,且LRaSMD探测结果存在大量噪声。EMAP-FLRX算法可以探测出所有异常目标的形状和位置,但背景中存在噪声。

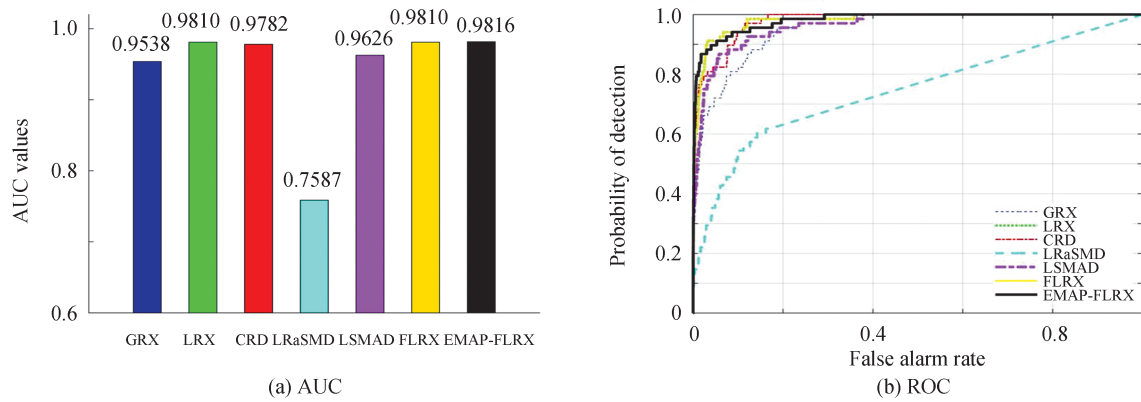


图 8 在 abu-beach-4 数据集上的探测精度

Fig. 8 Detection accuracy evaluation for the abu-beach-4 dataset

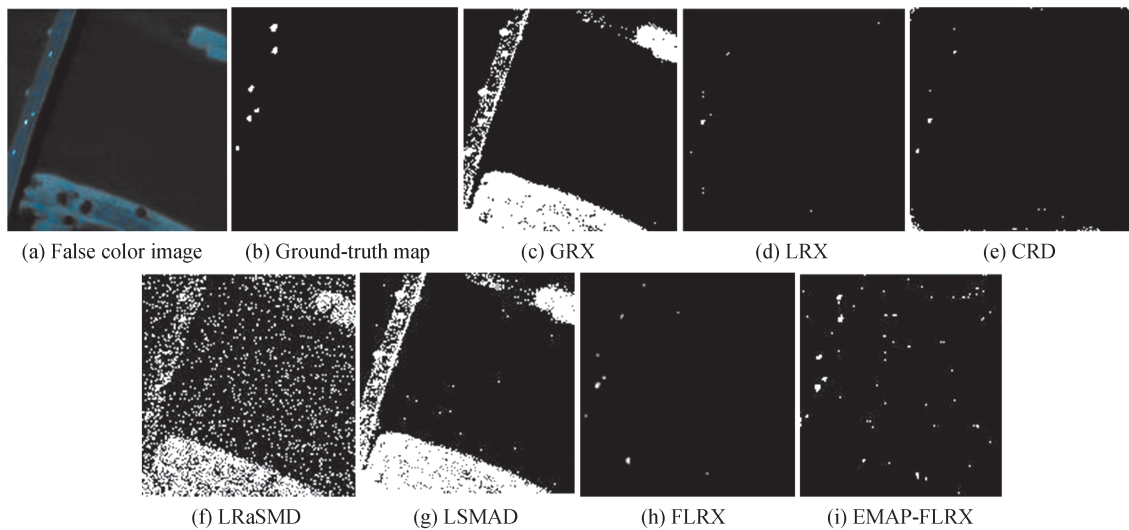


图 9 abu-beach-4 不同算法探测结果二值图

Fig. 9 Detection maps obtained by different algorithms for the abu-beach-4 dataset

4 结论

本文提出了 FLRX 算法,利用矩阵求逆引理迭代更新协方差矩阵,实现了对 LRX 算法的改进,计算量由 $J^3M + (s+1)J^2M + JM$ 减少到 $(4h+1)J^2M + (4h^2+1)JM + 2h^3M$ 。同时从高光谱图像中提取多属性剖面用于 FLRX 算法中,即提出 EMAP-FLRX 异常目标探测算法。将 EMAP-FLRX 与其他算法进行了比较,在 3 个数据集上该算法 AUC 值分别为 0.996 7、0.985 6、0.981 6;运算时间分别为 21.218 1 s、15.192 8 s、32.337 9 s。实验结果证明该算法在探测精度及时间复杂度上都具有优势,其性能优于其他算法。但本方法仍存在一些不足之处,如该方法对双窗选择敏感,需通过实验比较不同尺寸双窗的探测性能来确定算法的最优双窗,对此需要进一步研究与改进。

参考文献

- [1] XU Dongdong, CHENG Deqiang, CHEN Liangliang, et al. Hyperspectral image classification based on hierarchical guidance filtering and nearest regularized subspace [J]. Acta Photonica Sinica, 2020, 49(4): 0410004.
徐冬冬,程德强,陈亮亮,等.基于分层引导滤波与最近邻正则化子空间的高光谱图像分类[J].光子学报,2020,49(4): 0410004.
- [2] GUO Liqiang, MENG Qingchao. Space spectrum classification algorithm based on multi-label shared subspace learning and kernel ridge regression[J]. Acta Photonica Sinica, 2020, 49(5): 0528001.
郭利强,孟庆超.基于多标签共享子空间学习和内核脊回归的空谱分类算法[J].光子学报,2020,49(5): 0528001.
- [3] MA Shixin, LIU Chuntong, LI Hongcai, et al. Improved collaborative algorithm based on spatial-spectral joint clustering for hyperspectral anomaly detection[J]. Acta Photonica Sinica, 2019, 48(1): 0110003.

- 马世欣,刘春桐,李洪才,等.基于空谱联合聚类的改进核协同高光谱异常检测[J].光子学报,2019,48(1):0110003.
- [4] WANG Zhiwei, TAN Kun, WANG Xue, et al. Unsupervised nearest regularized subspace based on spectral space reconstruction for hyperspectral anomaly detection[J]. *Acta Photonica Sinica*, 2020, 49(6): 0630004.
王志威,谭琨,王雪,等.基于光谱空间重构的非监督最近规则子空间的高光谱异常检测[J].光子学报,2020,49(6):0630004.
- [5] XUE Qingsheng, TIAN Zhongtian, YANG Bai, et al. Optical system design of geostationary hyperspectral ocean water color imager with wide coverage[J]. *Acta Photonica Sinica*, 2020, 49(5): 0501001.
薛庆生,田中天,杨柏,等.静止轨道高光谱海洋水色仪光学系统设计[J].光子学报,2020,49(5):0501001.
- [6] REED I S, YU X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution[J]. *IEEE Transactions on Acoustics Speech & Signal Processing*, 1990, 38(10):1760-1770.
- [7] LI Z, ZHANG Y. Hyperspectral anomaly detection based on improved RX with CNN framework[J]. *IEEE International Symposium on Geoscience and Remote Sensing IGARSS*, 2019:2244-2247.
- [8] HIDALGO J A P, PEREZ-SUAY A, NAR F, et al. Efficient nonlinear RX anomaly detectors[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021,18(2):231-235.
- [9] REN L, ZHAO L, WANG Y. A superpixel-based dual window RX for hyperspectral anomaly detection [J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(7):1233-1237.
- [10] IMANI M. RX anomaly detector with rectified background[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(8):1313-1317.
- [11] LI W, DU Q. Collaborative representation for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(3):1463-1474.
- [12] MA N, PENG Y, WANG S. A fast recursive collaboration representation anomaly detector for hyperspectral image[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(4):588-592.
- [13] WU Z, SU H, ZHENG P. hyperspectral anomaly detection using collaborative representation with PCA remove outlier [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018,(11):1-5.
- [14] SUN W, LIU C, LI J, et al. Low-rank and sparse matrix decomposition-based anomaly detection for hyperspectral imagery[J]. *Journal of Applied Remote Sensing*, 2014, 8(1):83641.
- [15] ZHANG Y, DU B, ZHANG L, et al. A low-rank and sparse matrix decomposition-based Mahalanobis distance method for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(3):1-14.
- [16] SONG S, YANG Y, ZHOU H, et al. Hyperspectral anomaly detection via graph dictionary-based low rank decomposition with texture feature extraction[J]. *Remote Sensing*, 2020,12(23):2072-4292.
- [17] BENEDIKTSSON J A, PALMASON J A, SVEINSSON J R. Classification of hyperspectral data from urban areas based on extended morphological profiles [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3):480-491.
- [18] DALLA MURA M, BENEDIKTSSON J A, WASKE B, et al. Morphological attribute profiles for the analysis of very high resolution images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(10):3747-3762.
- [19] DALLA MURA M, BENEDIKTSSON J A, WASKE B, et al. Extended profiles with morphological attribute filters for the analysis of hyperspectral data[J]. *International Journal of Remote Sensing*, 2010, 31(22):5975-5991.
- [20] ANDIKA F, RIZKINIA M. A Hyperspectral anomaly detection algorithm based on morphological profile and attribute filter with band selection and automatic determination of maximum area[J]. *Remote Sensing*, 2020, 12(20):3387.
- [21] HIGHAM N J. Accuracy and stability of numerical algorithms [M]. 2nd. USA: Society for Industrial and Applied Mathematics, 2002.
- [22] KANG X, ZHANG X, LI S, et al. Hyperspectral anomaly detection with attribute and Edge-Preserving filters[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(10):5600-5611.