

Journal of System Simulation

Volume 33 | Issue 12

Article 13

1-13-2022

Hyperspectral RX Anomaly Detection Method Based on the Fusion of Spatial and Spectral Feature

Liu Xuan

Rocket Force University of Engineering, Xi'an 710025, China;

Xiangyang Li

Rocket Force University of Engineering, Xi'an 710025, China;

He Fang

Rocket Force University of Engineering, Xi'an 710025, China;

Jianwei Zhao

Rocket Force University of Engineering, Xi'an 710025, China;

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Hyperspectral RX Anomaly Detection Method Based on the Fusion of Spatial and Spectral Feature

Abstract

Abstract: To address the problem that the hyperspectral anomaly detection algorithm does not make full use of the spatial information of the hyperspectral image and the detection accuracy is limited, a FSSRX (*Fusing Spatial and Spectral Reed-Xiaol*) anomaly detection algorithm that fuses spatial and spectrum information is proposed to improve the accuracy of hyperspectral anomaly detection. In FSSRX algorithm, the spatial feature of hyperspectral images is firstly extracted by the EMAP(Extended Multi-attribute Profile) method and the abnormal score of each pixel in spatial features is then calculated with RX detector. Meanwhile, RX anomaly detection is carried out directly on the original hyperspectral image to calculate the abnormal score of each pixel in the spectral feature. The anomaly scores obtained in spatial and spectral features are effectively combined to improve the detection accuracy. Simulation results show that FSSRX algorithm can effectively improve the detection accuracy and reduce the false alarm rate. Compared with other algorithms, FSSRX algorithm can achieve better detection performance.

Keywords

hyperspectral image (HSI), fusing spatial and spectral feature, EMAP, anomaly detection, RX detector

Authors

Liu Xuan, Xiangyang Li, He Fang, Jianwei Zhao, and Fenggan Zhang

Recommended Citation

Liu Xuan, Li Xiangyang, He Fang, Zhao Jianwei, Zhang Fenggan. Hyperspectral RX Anomaly Detection Method Based on the Fusion of Spatial and Spectral Feature[J]. Journal of System Simulation, 2021, 33(12): 2891-2900.

基于空谱特征融合的高光谱 RX 异常检测方法

刘轩, 李向阳, 何芳, 赵建伟, 张峰干

(火箭军工程大学, 陕西 西安 710025)

摘要: 针对高光谱异常检测算法没有充分利用高光谱图像的空间信息, 检测精度受到限制的问题, 提出一种融合空谱信息的 RX (*Fusing Spatial and Spectral Reed-Xiaoli, FSSRX*) 异常检测算法来提高高光谱的异常检测精度。FSSRX 算法利用 EMAP (*Extended Multi-attribute Profiles*) 方法提取出高光谱图像的空间特征, 在空间特征上进行 RX 异常检测, 计算空间特征中每个像素点的异常得分; 直接对原始高光谱图像进行 RX 异常检测, 计算在光谱特征中每个像素点的异常得分; 将在空间特征和光谱特征中得到的异常得分进行有效融合, 以提高检测精度。仿真结果显示, FSSRX 算法能够有效提高检测精度, 降低虚警率, 与其他几种算法相比, 检测性能更佳。

关键词: 高光谱图像; 空谱融合; RX 算法; EMAP 特征; 异常检测

中图分类号: TP795;TP391.9 文献标志码: A 文章编号: 1004-731X (2021) 12-2891-10

DOI: 10.16182/j.issn1004731x.joss.21-FZ0780

Hyperspectral RX Anomaly Detection Method Based on the Fusion of Spatial and Spectral Feature

Liu Xuan, Li Xiangyang, He Fang, Zhao Jianwei, Zhang Fenggan

(Rocket Force University of Engineering, Xi'an 710025, China)

Abstract: To address the problem that the hyperspectral anomaly detection algorithm does not make full use of the spatial information of the hyperspectral image and the detection accuracy is limited, a FSSRX (*Fusing Spatial and Spectral Reed-Xiaoli*) anomaly detection algorithm that fuses spatial and spectrum information is proposed to improve the accuracy of hyperspectral anomaly detection. In FSSRX algorithm, the spatial feature of hyperspectral images is firstly extracted by the EMAP(*Extended Multi-attribute Profile*) method and the abnormal score of each pixel in spatial features is then calculated with RX detector. Meanwhile, RX anomaly detection is carried out directly on the original hyperspectral image to calculate the abnormal score of each pixel in the spectral feature. The anomaly scores obtained in spatial and spectral features are effectively combined to improve the detection accuracy. Simulation results show that FSSRX algorithm can effectively improve the detection accuracy and reduce the false alarm rate. Compared with other algorithms, FSSRX algorithm can achieve better detection performance.

Keywords: hyperspectral image (HSI); fusing spatial and spectral feature; EMAP; anomaly detection; RX detector

引言

高光谱图像(Hyperspectral Image, HSI)是由机载或星载成像光谱仪在特定波长范围内对同一场景进行连续扫描成像获取的遥感图像^[1-2]。随着成

像技术的不断发展, 高光谱图像信息处理技术也应运而生, 包括数据降维, 图像压缩, 分类, 聚类, 光谱解混, 目标检测等^[3-4]。其中, 高光谱图像目标检测技术在军事侦察, 地质勘探, 环境监测, 食

品质量检测等领域发挥了重要的作用^[5-6]。

根据是否利用目标的先验信息,高光谱目标检测技术可以分为有监督和无监督2类。监督目标检测方法的本质是光谱识别,通常利用光谱匹配的方法判断某一未知像元归属于已知地物光谱的确认概率。监督目标检测有2个重要环节:建立目标光谱库或者光谱字典;定量化处理高光谱图像。在实际情况下,由于受到地物种类和自然环境变换的影响,完备又实用的地物光谱数据库难以获得,而且目前也没有任何精准的反射率反演算法可以囊括所有复杂多变的环境因素^[7-8]。因此,有监督的目标检测技术在实际应用中困难重重。相反,无监督的目标检测方法又称为异常检测,不需要利用任何的先验信息就可以将高光谱图像中的所有像素点分成两类“背景和异常”,其中数量较少的那一类就属于异常目标^[9]。高光谱异常检测技术更具有实用性,成为了高光谱遥感领域的研究热点,在民用和军事等领域都发挥了重要的作用,如农业、林业、地质调查、环境监测和战场目标侦察等方面^[4]。

高光谱异常检测算法的研究受到了国内外学者的广泛关注。Reed等提出的RX(Reed-Xiaoli, RX)算法可以认为是高光谱异常检测中的基准算法,该算法假设图像中的样本点服从高斯分布,首先计算出高光谱图像数据的均值和协方差,然后利用得到的均值和协方差计算所有像元的马氏距离得到每个像素点的异常得分,最后设定阈值,异常得分高于该阈值则可判定该像素点为异常目标^[10]。在RX基础上,衍生了许多改进的RX算法。例如,Kwon等提出核RX异常检测方法(Kernel-RX, KRX),该方法利用核学习方法将传统RX方法投影到高维核特征空间中以提升背景目标和异常目标的可分性^[11];Carlotto等提出基于聚类的异常检测方法(Cluster-based Anomaly Detector, CBAD),该方法考虑到样本的类别信息,首先对高光谱图像进行聚类,然后在每一类中进行RX异常检测^[12];Guo等提出加权RX异常检测方法(Weighted RX, WRX),该方法为每一个像素点分配一个特殊的权

重对背景进行建模^[13]。Du等提出基于随机背景像元选择的高光谱遥感影像异常检测方法(Random-Selection-based Anomaly Detector, RSAD),该方法采用伪随机迭代方式选择出高光谱影像中具有代表性的背景地物,以得到排除异常目标干扰的RX参量估计^[14]。Zhou等提出一种新的基于聚类的核RX异常检测算法(Cluster Kernel RX, CKRX)^[15],该方法首先对样本像素点进行聚类,然后采用一种快速特征值分解算法完成异常检测。

此外,许多基于表示的异常检测算法近年来也得到了广泛关注。Li等提出基于协同表示的异常检测(Collaborative Representation-based Anomaly Detection, CRD)方法,该方法认为背景像素可以在局部双窗中的其他像素近似表示,而异常目标不能^[16]。Sun等提出低秩稀疏矩阵(Low-Rank and Sparse Matrix Decomposition, LRaSMD)算法,该方法认为背景像素具有低秩特性,而异常目标具有稀疏特性^[17]。在LRaSMD基础上,Zhang等进一步提出LSMAD(Low-rank and Sparse Matrix Decomposition-based Mahalanobis Distance)算法,该方法利用背景像素具有低秩分布这一先验知识计算背景分布并利用马氏距离检测异常点^[18]。

大多数异常检测算法是利用高光谱图像的光谱信息进行分析,而高光谱图像具有空谱合一的特点,充分利用高光谱图像的空间信息有利于提高探测器的性能^[19-20]。EMAP(Extended Multi-attribute Profiles)方法在高光谱图像目标检测技术中的研究较少,近两年,有研究者构建多特征异常检测模型,将EMAP特征,光谱特征,纹理特征,EAP特征结合构建多特征异常检测模型,提高了异常检测精度^[21]。本文构建一个基本的空谱结合的异常检测模型,融合空谱信息的RX(Fusion Spatial and Spectral RX, FSSRX)异常检测算法,利用EMAP方法提取出高光谱图像的空间特征,对其进行RX检测计算空间特征的异常得分。同时,对原始光谱图像直接进行RX检测得到光谱特征的异常得分,将空间特征和光谱特征的异常得分进行有效融合,以

提高检测精度。

1 空谱融合 RX 方法

1.1 RX 算法

RX 算法作为异常检测中的基准算法, 假设背景像素服从多元高斯分布, 利用样本的相关矩阵检测背景中的异常点, 在信号处理, 图像处理中具有广泛的应用。RX 算法有 2 个基本变形: 全局 RX (Global RX, GRX) 算法和局部 RX (Local RX, LRX) 算法。其中, GRX 算法的具体实现过程如下:

高光谱图像可表示为 $X \in \mathbb{R}^{d \times n}$, d 为样本的维数, n 为样本点的个数。GRX 算法需要区分以下 2 个相互竞争的假设:

$$\begin{cases} H_0: x \sim N(\mu_b, C_b) \\ H_1: x \sim N(\mu_s, C_b) \end{cases} \quad (1)$$

式中: μ_b 和 μ_s 分别为背景点和异常点的均值向量; C_b 为背景的协方差矩阵。

根据这 2 个假设, 异常目标可以通过设置合适的阈值 τ 进行确定:

$$\begin{cases} H_0: s_i < \tau \quad (i=1, 2, \dots, n) \\ H_1: s_i > \tau \end{cases} \quad (2)$$

如果 s_i 大于阈值 τ , 那么第 i 个像素可以判断为异常点, 反之, 如果 s_i 小于阈值 τ , 那么第 i 个像素可以认为是背景点。 s_i 是第 i 个像素点的异常得分, 可通过式(3)进行计算:

$$s_i = (\mathbf{x}_i - \boldsymbol{\mu})^T \mathbf{C}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}) \quad (3)$$

式中: $\boldsymbol{\mu}$ 和 \mathbf{C} 估计背景分布的均值和协方差矩阵, 分别可以通过式(4), (5)进行计算:

$$\boldsymbol{\mu} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad (4)$$

$$\mathbf{C} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^T \quad (5)$$

1.2 EMAP 特征

扩展的多属性剖面(Extended Multi-attribute Profile, EMAP)方法是基于多形态学属性滤波, 通过多层次分析的方法, 提取出样本的空间信息。

EMAP 方法首先采用主成分分析(Principal Component Analysis, PCA)方法获取 c 个主成分图像, 然后基于前 c 个主成分图像和形态学滤波方法, 利用形态学属性滤波器在每一个主成分(Principal Component, PC)图像上生成扩展的形态学属性(Extended Attribute Profiles, EAPs)。进一步地, EAPs 扩展到 EMAP, EMAP 拥有 4 个不同的属性: 区域面积、区域大小、区域伸长度、区域同质性。对于每一个属性, 计算一个 EAP。将所有属性得到的 EAP 连接起来生成 EMAP 特征^[19-21]。

EMAP 方法以扩展的属性剖面为基础, 可以在从原始的高光谱数据中提取的 c 个主成分上计算得到:

$$EAP = \{AP(PC_1), AP(PC_2), \dots, AP(PC_c)\} \quad (6)$$

式中: $AP(PC_c)$ 是由属性滤波器得到的输入图像的多层次分解。 AP 可以被定义为一系列的变厚操作 $\Pi_{\phi\lambda}$ 和变薄操作 $\Pi_{r\lambda}$ 。

$$AP(f) = \prod_i \begin{cases} \Pi_i = \Pi_{\phi\lambda}, \lambda = (n-1+i), \\ \forall \lambda \in [1, n]; \\ \Pi_i = \Pi_{r\lambda}, \lambda = (i-n-1), \\ \forall \lambda \in [n+1, 2n+1]. \end{cases} \quad (7)$$

EMAP 在一个单一的数据结构中合并不同的 EAPs, 可以定义为

$$EMAP = \{EAP'_{a_1}, EAP'_{a_2}, \dots, EAP'_{a_m}\}, \quad (8)$$

式中: $EAP' = EAP \{PC_1, PC_2, \dots, PC_c\}$ 。

考虑 4 种不同的属性, 区域的面积、尺寸、延伸率、同质性, 在每一个属性上计算 EAP。然后, 每一个像素的 EMAP 特征可以被建立通过连接所有属性剖面。EMAP 特征矩阵可以表示为 $\tilde{X} \in \mathbb{R}^{d_4 \times n}$, 其中 d_4 与属性滤波器的参数和主成分的个数有关。每一个属性可以产生 9 个特征, 如果仅用图像中的前 3 个主成分, 则 $d_4=9 \times 4 \times 3=108$ 。

EMAP 算法的步骤为:

输入: 高光谱数据 $X \in \mathbb{R}^{d \times n}$, 主成分个数 c 。

利用主成分分析技术 PCA 生成 c 个主成分图像, PC_1, PC_2, \dots, PC_c ;

在每一个主成分图像上利用形态学属性滤波器生成扩展的属性剖面;

在4种不同的属性(区域的面积、尺寸、延伸率、同质性)上将EAP进化为EMAP。

输出: EMAP 特征矩阵 $\tilde{X} \in \mathbb{R}^{d_4 \times n}$, 其中 $d_4 = 9 \times 4 \times c$ 。

由EMAP方法提取出的高光谱图像数据用 \tilde{X} 表示, 相应的均值、协方差为

$$\tilde{\mu} = \frac{1}{n} \sum_{i=1}^n \tilde{x}_i \quad (9)$$

$$\tilde{C} = \frac{1}{n} \sum_{i=1}^n (\tilde{x}_i - \tilde{\mu})(\tilde{x}_i - \tilde{\mu})^T \quad (10)$$

得到了均值 $\tilde{\mu}$ 和协方差 \tilde{C} 后, 利用 RX 探测器完成目标检测, 得到的异常得分为

$$\tilde{s}_i = (\tilde{x}_i - \tilde{\mu})^T \tilde{C}^{-1} (\tilde{x}_i - \tilde{\mu}) \quad (11)$$

1.3 空谱融合 RX 异常检测方法

本文提出一种融合空谱 RX(FSSRX)的高光谱异常检测方法, 具体流程如图 1 所示。首先采用 EMAP 方法提取出高光谱图像的 EMAP 特征 \tilde{X} , 然后对 \tilde{X} 进行 RX 异常检测计算每个像元的异常得分 \tilde{s}_i , 同时计算原始高光谱图像经过 RX 异常检测后每个像元的异常得分 s_i 。最后, 采用式(12)将 s_i 和 \tilde{s}_i 进行有效融合, 以提高检测精度。

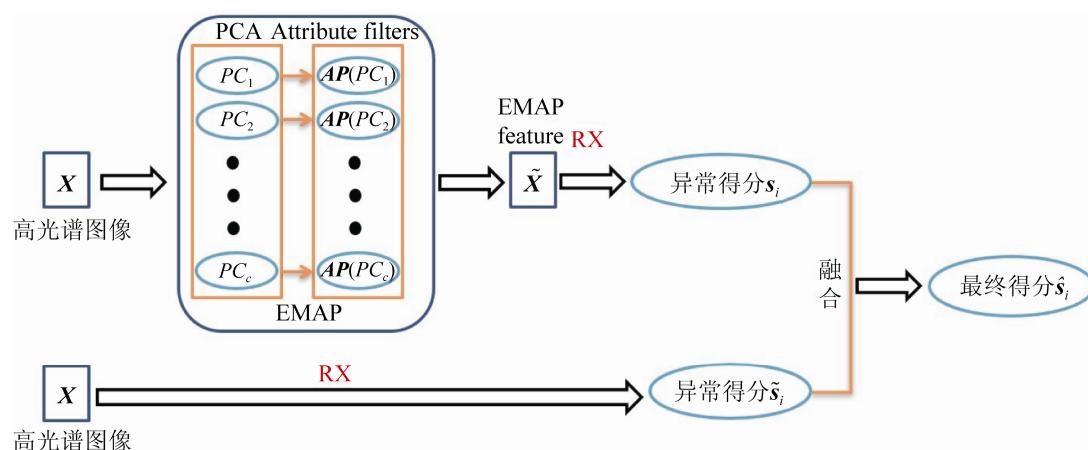


图 1 FSSRX 算法流程图
Fig. 1 Flow chart of FSSRX algorithm

$$\hat{s}_i = t\tilde{s}_i + (1-t)s_i \quad (12)$$

式中: $t \in [0,1]$ 为权重参数, 衡量空间特征和光谱特征的贡献。

从式(12)可知, FSSRX 算法中有一个权重参数 t , 它衡量空间特征和光谱特征的贡献, 因此, t 的取值对于算法性能的影响较大。本实验中, t 的取值范围为 $\{0.1, 0.2, \dots, 1\}$, 在 4 组数据库上对应的 FSSRX 算法的 AUC 值如图 2 所示。

可以看出, 随着 t 的变化, AUC 值也在不断发生变化, 不同数据库上, AUC 值最大时对应的 t 的取值也不同。在 abu-airport-2 数据库上, $t=1$ 时, AUC 能达到最大值 0.978 0, 说明了在 abu-airport-2 数据库上, 只利用了 EMAP 特征就能实现较好的检测性能。在 abu-beach-4 数据库上, $t=1$ 时, AUC 能达到最大值 0.992 8, 再次说明了 EMAP 特征的重要性。在 Cri 和 Salinas 数据库上, AUC 值随着 t 的增大呈现先增大后减小的变化。在 Cri 数据库上, $t=0.6$ 时, AUC 能达到最大值 0.989 7; 在 Salinas 数据库上, $t=0.8$ 时, AUC 能达到最大值 0.974 1。这些结果都表明了权重参数 t 对 FSSRX 算法的检测性能影响较大, 在不同数据库上的取值也不同, 需要精细调节以实现算法性能最佳。

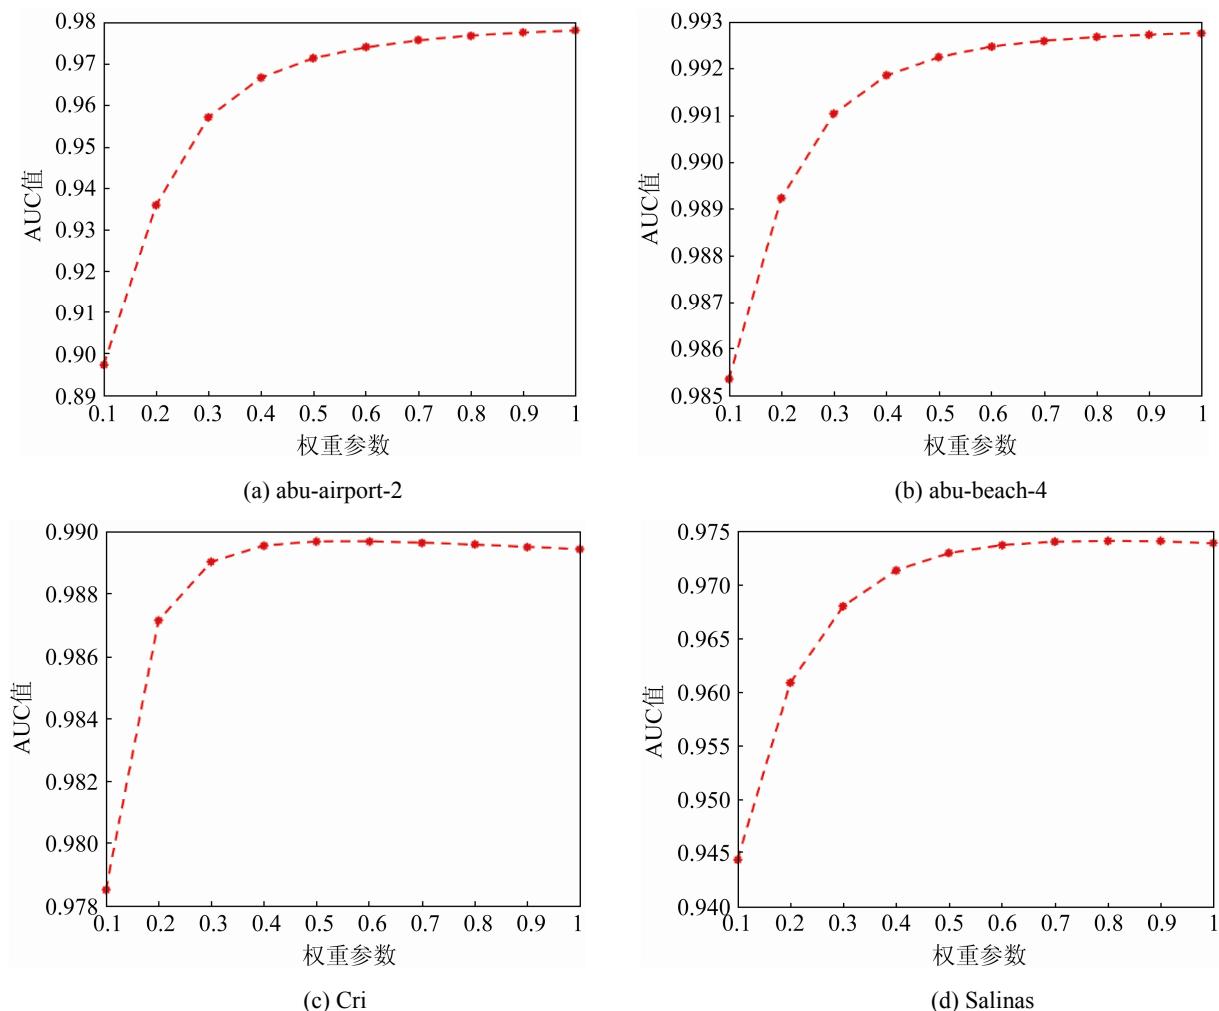


图 2 四组数据库上权重参数对 AUC 值的影响
Fig. 2 Effects of the weighted parameters on the AUC values for the abu-beach-4 data set

2 实验

2.1 数据介绍

为验证本文所提算法的有效性, 在如下 4 组高光谱数据库上进行实验, 其中, ABU 数据集是由湖南大学康旭东团队提供的。根据不同的场景分成了 3 类, 分别是机场场景、海洋场景和城市场景。这些场景中大部分的数据都是手动从由 AVIRIS (Airborne Visible Infra-Red Imaging Spectrometer) 传感器获取的大图像中截取 100×100 小图像获得的^[8]。

(1) abu-airport-2: 该数据库是 ABU 数据集中的机场场景, 图像中有建筑建筑, 草地还有跑道, 但是异常目标为飞机, 对应的假彩色图像及其地物分布如图 3(a), (e) 所示。

(2) abu-beach-4: 该数据库是 ABU 数据集中的海洋场景, 异常目标为海上的船只, 渔场, 还有跨江大桥的车辆, 对应的假彩色图像及其地物分布如图 3(b), (f) 所示。

(3) Cri: 该数据库是由 Nuance Cri hyperspectral 传感器获取的。图像尺寸为 400×400 , 波段数目为 46。异常目标为石头, 对应的假彩色图像及其地物分布如图 3(c), (g) 所示^[18,21]。

(4) Salinas: 该数据库是由 AVIRIS 传感器获得, 移除 20 个被污染的波段后, 剩下 204 个波段用于实验分析, 原始影像的大小为 512×217 。从整个图像中裁剪出 180×180 的子图像作为 Salinas 数据集, 对应的假彩色图像及其地物分布如图 3(d), (h) 所示。

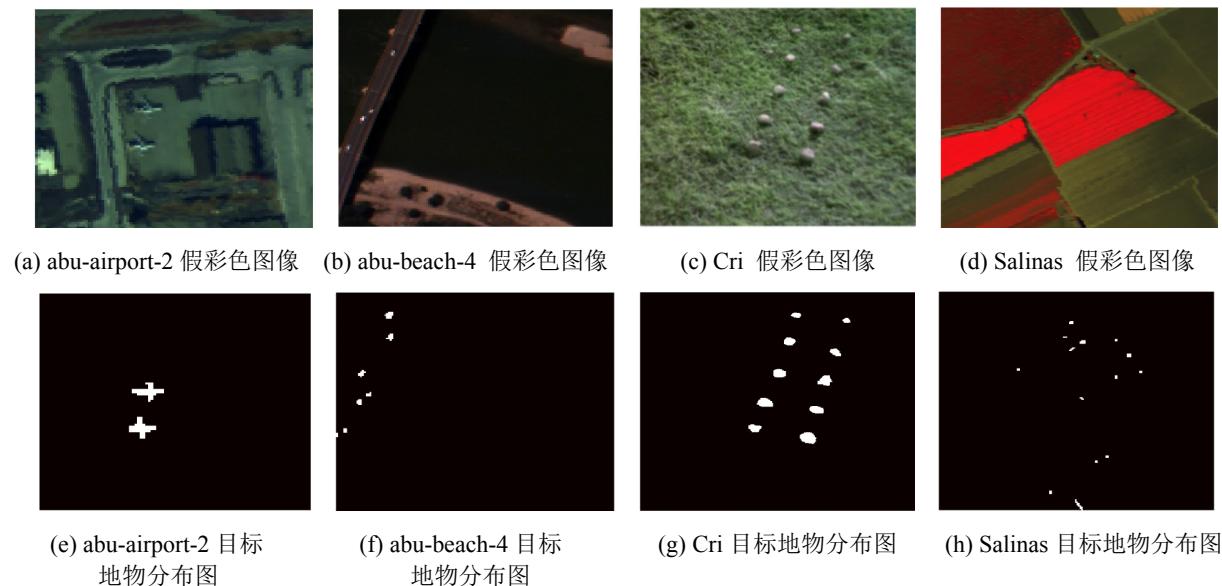


图3 四组数据库的假彩色图像及目标地物分布图
Fig. 3 False color images and the ground truth maps on four datasets

2.2 实验结果

为了验证本文所提算法的有效性,在上述四组数据库上,将所提算法与5种先进的异常检测算法(GRX^[10], LRX, CRD^[16], LRaSMD^[17]和LSMAD^[18])进行对比。其中,在4组数据库上,CRD的内外窗口尺寸分别设为9和13,LRX的内外窗口尺寸分别为9和11。主要性能衡量指标为接收机操作特性(ROC)曲线及ROC曲线下面积(AUC)值。ROC曲线是衡量目标检测算法的重要指标,表示在不同虚警率条件下的检测率变化,该曲线越靠近左上角,则该检测算法的性能越优。AUC值越接近于1,表明算法的性能越好。

在abu-airport-2数据库上的ROC曲线和AUC值如图4所示,可以看出由FSSRX得到的ROC曲线更靠近左上角,对应的AUC值比其他几种算法得到的AUC值都高,达到了0.978 0,比GRX算法高出了0.137 6,比LSMAD探测器高出了0.038 4。图5直观地给出了探测结果图,可以看到,6种方法均能将异常目标的位置检测出来,但是FSSRX检测出的形状更加接近,而其他几种算法检测出的飞机形状较为模糊。因此,本文提出的FSSRX探测器对于异常目标的检测性能更好。

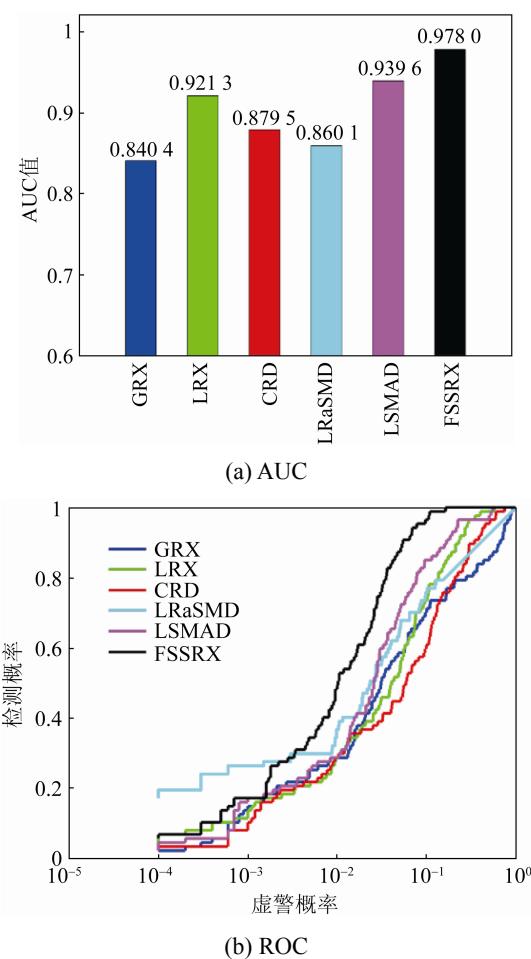


图4 6种算法在abu-airport-2数据库上的AUC值及ROC曲线
Fig. 4 AUC values and ROC curves on abu-airport-2 data set for six algorithms

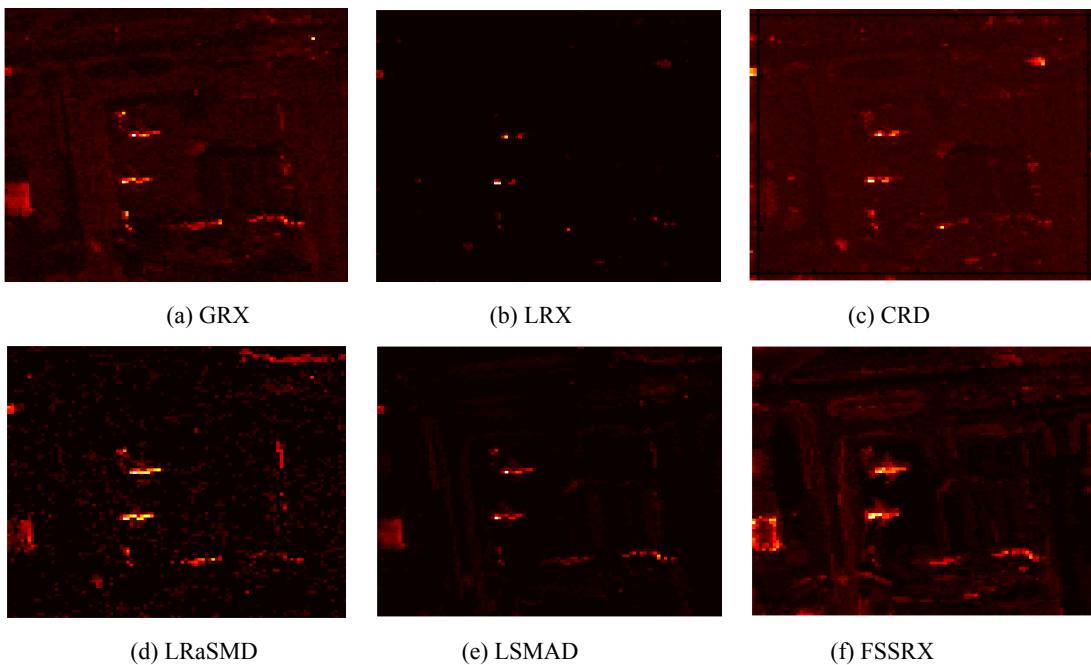
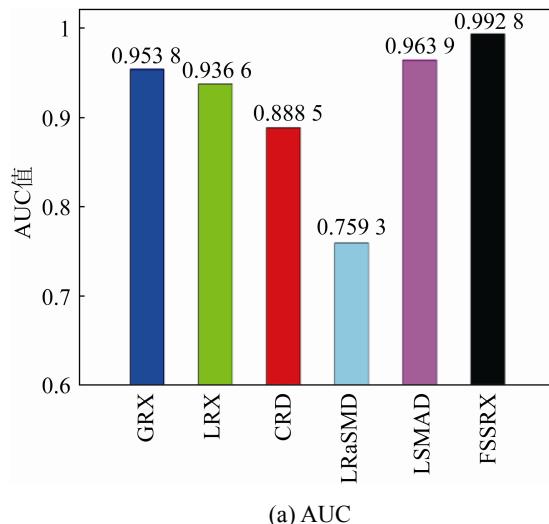


图 5 6 种算法在 abu-airport-2 数据库上的检测结果图

Fig. 5 Color detection maps obtained by six algorithms for the abu-airport-2 data set

在 abu-beach-4 数据库上得到的 ROC 曲线和 AUC 值如图 6 所示, 与其他 5 种方法相比, 由 FSSRX 得到的 ROC 曲线更靠近左上角, 对应的 AUC 值比其他几种算法得到的 AUC 值都高, 达到了 0.992 8, 比 GRX 算法高出了 0.039, 比排名第二的 LSMAD 算法高出了 0.028 9。



(a) AUC

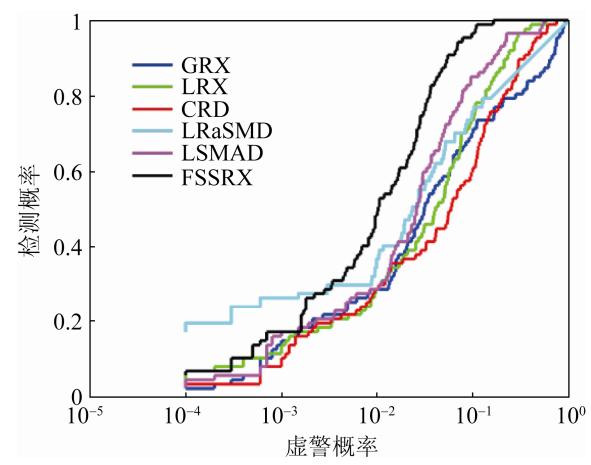


图 6 6 种算法在 abu-beach-4 数据库上的 AUC 值及 ROC 曲线

Fig. 6 AUC values and ROC curves obtained by six algorithms for the abu-beach-4 data set

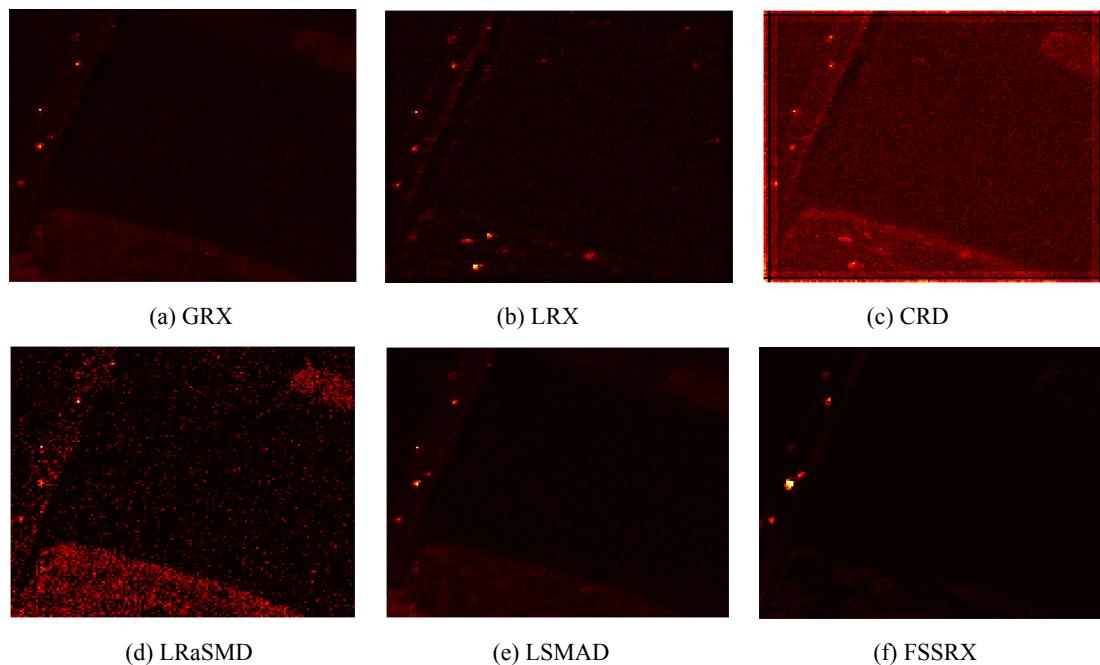
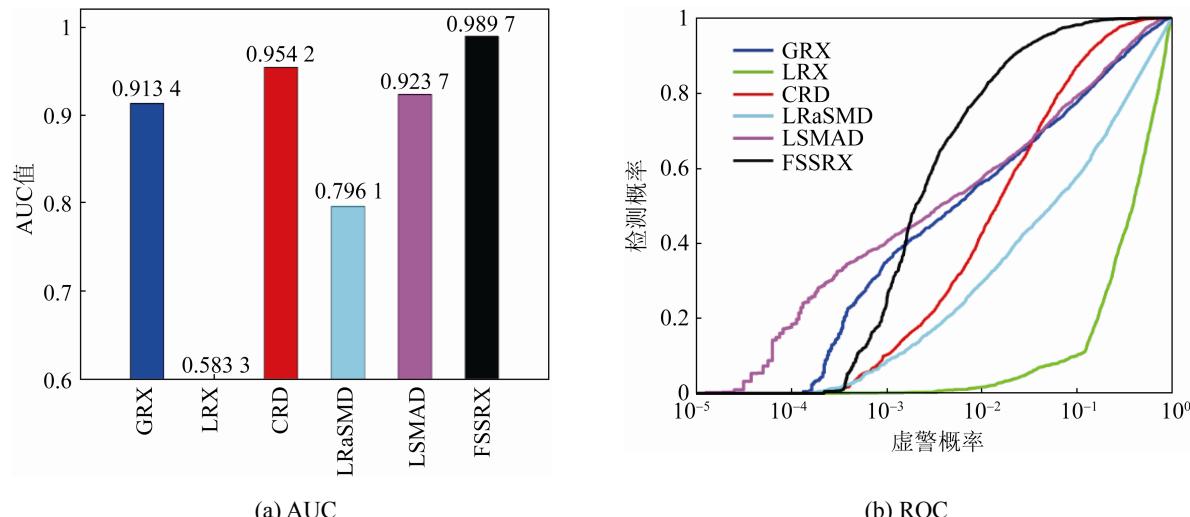


图 7 6 种算法在 abu-beach-4 数据库上的检测结果图

Fig. 7 Color detection maps obtained by six algorithms for the abu-beach-4 data set

在 Cri 数据库上得到的 ROC 曲线和 AUC 值如图 8 所示,与其他 5 种方法相比,由 FSSRX 得到的 ROC 曲线更靠近左上角,对应的 AUC 值达到了 0.989 7,比 GRX 算法高出了 0.076 3,比排名第二的 CRD 高出了 0.035 5,表明了本文所提算法具有一定的优越性。

图 8 6 种算法在 Cri 数据库上的 AUC 值及 ROC 曲线
Fig. 8 AUC values and ROC curves obtained by six algorithms for the abu-beach-4 data set

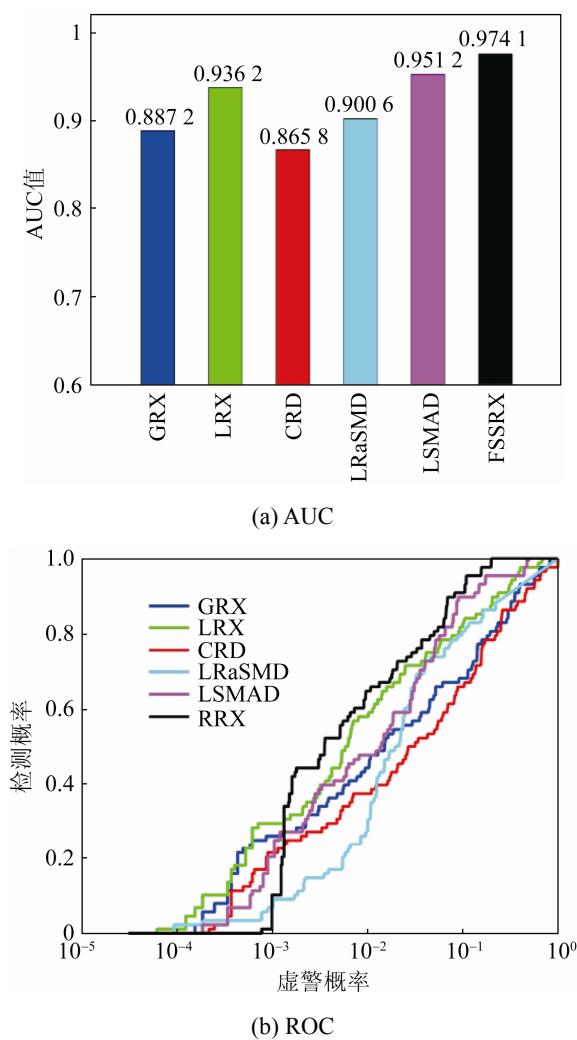


图9 6种算法在Salinas数据库上的AUC值及ROC曲线

Fig. 9 AUC values and ROC curves obtained by six algorithms for the Salinas data set

3 结论

传统的RX异常检测算法只利用了高光谱图像的光谱信息而忽略了其空间信息,本文提出了一种融合空谱信息的RX(Fusion spatial and spectral RX, FSSRX)异常检测算法,利用EMAP方法提取出高光谱图像的空间特征,在空间特征上进行RX异常检测计算空间特征的异常得分。同时,对原始高光谱图像直接进行RX检测得到光谱特征的异常得分。引入权重参数 t 来平衡空间特征和光谱特征的贡献,将空谱信息进行有效融合,以提高检测精度。在4组真实数据库上的实验结果表明,由FSSRX算

法得到的曲线下面积较传统RX算法分别提高了0.1376, 0.039, 0.0763和0.0869,能够有效提高检测精度,降低虚警率,性能也优于其他几种先进的异常检测算法,证明本文所提算法具有更佳的检测性能。

参考文献:

- [1] 张良培. 高光谱遥感影像处理[M]. 北京: 科学出版社, 2014.
Zhang Liangpei. Hyperspectral Remote Sensing Image Processing[M]. Beijing: Science Press, 2014.
- [2] 宋晓瑞, 邹玲, 吴玲达, 等. 基于背景重建的高光谱图像异常检测[J]. 系统仿真学报, 2020, 32(7): 1287-1293.
Song Xiaorui, Zou Ling, Wu Lingda, et al. Hyperspectral Image Anomaly Detection Based on Background Reconstruction[J]. Journal of System Simulation, 2020, 32(7): 1287-1293.
- [3] 宋义刚, 吴泽彬, 孙乐, 等. 一种新的空谱联合稀疏高光谱目标检测方法[J]. 兵工学报, 2014, 35(6): 834-841.
Song Yigang, Wu Zebin, Sun Le, et al. A Novel Spectral-spatial Sparse Method for Hyperspectral Target Detection[J]. Acta Armamentarii, 2014, 35(6): 834-841.
- [4] 刘一博. 基于背景数据优化的高光谱图像异常检测算法研究[D]. 哈尔滨: 哈尔滨工程大学, 2017.
Liu Yibo. The Research of Hyperspectral Anomaly Detection Algorithm Based on Background Data Optimized[D]. Harbin: Harbin Engineering University, 2017.
- [5] 马世欣, 刘春桐, 李洪才, 等. 基于高光谱图像探测与感知的伪装效果评估方法[J]. 兵工学报, 2019, 40(7): 1485-1494.
Ma Shixin, Liu Chunlong, Li Hongcai, et al. Camouflage Effect Evaluation Based on Hyperspectral Image [J]. Detection and Visual Perception, 2019, 40(7): 1485-1494.
- [6] 李肖. 高光谱异常检测算法研究[D]. 西安: 西安电子科技大学, 2015.
Li Xiao. Study on Anomaly Detection Algorithm of Hyperspectral Imagery[D]. Xi'an: Xidian University, 2015.
- [7] 王鑫鹏. 基于背景纯化的高光谱异常目标检测研究[D]. 哈尔滨: 哈尔滨工程大学, 2017.
Wang Xinpeng. Research on Hyperspectral Remote Sensing Anomaly Detection Based on Background

- Refinement[D]. Harbin: Harbin Engineering University, 2017.
- [8] Hosseiny B, Shah-Hosseini R. A Hyperspectral Anomaly Detection Framework Based on Segmentation and Convolutional Neural Network Algorithms[J]. International Journal of Remote Sensing (S0143-1161), 2020, 41(18): 6946-6975.
- [9] 张香萍. 联合空间与光谱信息的高光谱图像异常目标检测方法研究[D]. 长沙: 湖南大学, 2018.
Zhang Xiangping. Hyperspectral Image Anomaly Detection Method by Fusing Spatial and Spectral Information[D]. Changsha: Hunan University, 2018.
- [10] 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 (S0096-3518), 1990, 38(10): 1760-1770.
- [11] Kwon H, Nasrabadi N M. Kernel RX-algorithm: a Nonlinear Anomaly Detector for Hyperspectral Imagery[J]. IEEE Transactions on Geoscience and Remote Sensing (S0196-2892), 2005, 43(2): 388-397.
- [12] Carlotto M J. A Cluster-based Approach for Detecting Man-made Objects and Changes in Imagery[J]. IEEE Transactions on Geoscience & Remote Sensing (S0196-2892), 2005, 43(2): 374-387.
- [13] Guo Q, 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 & Remote Sensing (S1939-1404), 2014, 7(6): 2351-2366.
- [14] Du B, Zhang L. Random-Selection-Based Anomaly Detector for Hyperspectral Imagery[J]. IEEE Transactions on Geoscience and Remote Sensing
- (S0196-2892), 2011, 49(5): 1578-1589.
- [15] Zhou J, Kwan C, Ayhan B, et al. A Novel Cluster Kernel RX Algorithm for Anomaly and Change Detection Using Hyperspectral Images[J]. IEEE Transactions on Geoscience and Remote Sensing (S0196-2892), 2016, 54(11): 1-8.
- [16] Li W, Du Q. Collaborative Representation for Hyperspectral Anomaly Detection[J]. IEEE Transactions on Geoscience and Remote Sensing (S0196-2892), 2015, 53(3): 1463-1474.
- [17] 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 (S1931-3195), 2014, 8(1): 083641.
- [18] 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 (S0196-2892), 2016, 54(3): 1376-1389.
- [19] Dalla M M, Atli B J, Waske B, et al. Morphological Attribute Profiles for the Analysis of Very High Resolution Images[J]. IEEE Transactions on Geoence & Remote Sensing (S0196-2892), 2010, 48(10): 3747-3762.
- [20] Mura M D, 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 (S0143-1161), 2010, 31(22): 5975-5991.
- [21] Wang R, Nie F, Wang Z, et al. Multiple Features and Isolation Forest-Based Fast Anomaly Detector for Hyperspectral Imagery[J]. IEEE Transactions on Geoence and Remote Sensing (S0196-2892), 2020, 58(9): 1-13.