

基于端元提取和低秩稀疏矩阵分解的高光谱图像异常目标检测

杨国亮, 龚家仁*, 习浩, 喻丁玲

江西理工大学电气工程与自动化学院, 江西 赣州 341000

摘要 为了抑制高光谱图像(HSI)混合像元和噪声在复杂背景中对异常目标检测的干扰,充分提取和利用 HSI 的光谱特征和空间特征,提出了一种基于端元提取和低秩稀疏矩阵分解的 HSI 异常目标检测算法。首先,对原始 HSI 进行最优分数阶傅里叶变换。然后,采用连续最大角凸锥算法对变换后的 HSI 进行端元提取,得到端元和相应的丰度矩阵,并通过行约束的低秩稀疏矩阵分解方法将丰度矩阵分解为具有低秩特性的背景分量和具有稀疏特性的异常分量。最后,构建背景协方差矩阵,通过马氏距离检测异常目标。实验结果表明,本算法在 HSI 异常目标检测中具有很好的检测性能。

关键词 遥感; 高光谱图像; 连续最大角凸锥; 最优分数阶傅里叶变换; 低秩稀疏矩阵分解; 异常目标检测

中图分类号 TP751.2

文献标志码 A

doi: 10.3788/LOP202158.2228003

Hyperspectral Image Abnormal Target Detection Based on End-Member Extraction and Low-Rank and Sparse Matrix Decomposition

Yang Guoliang, Gong Jiaren*, Xi Hao, Yu Dingling

School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China

Abstract In this study, to suppress the interference of mixed pixels and noise in hyperspectral images (HSI) on abnormal target detection in a complex background and fully extract and utilize the spectral and spatial features of HSI, a HSI abnormal target detection algorithm based on end-member extraction and low-rank and sparse matrix decomposition is proposed. First, optimal fractional-order Fourier transform is applied to the original HSI. Then, the sequential maximum angle convex cone algorithm is used to extract the endmembers of the transformed HSI; subsequently, the end members and corresponding abundance matrix are obtained. The abundance matrix is decomposed into a low-rank background component and an abnormal component with sparse characteristics using the solution of the low-rank and sparse matrix decomposition method with row constraints. Finally, the background covariance matrix is constructed and abnormal targets are detected using the Mahalanobis distance. Experimental results show that the proposed algorithm exhibits good performance in HSI abnormal target detection.

Key words remote sensing; hyperspectral images; sequential maximum angle convex cone; optimal fractional-order Fourier transform; low-rank and sparse matrix decomposition; abnormal target detection

OCIS codes 010.0280; 300.6320; 300.630

1 引言

高光谱图像(HSI)异常检测在遥感领域具有重

要地位,在军事领域及其他领域引起了人们的高度重视。HSI 可以对同一地物进行连续遥感成像,从而表现出各类地物丰富的细节信息,具有光谱分辨

收稿日期: 2020-11-28 修回日期: 2020-12-30; 录用日期: 2021-01-21

基金项目: 国家自然科学基金(51365017)

通信作者: *964331424@qq.com

率高、空间分辨率低、波段数多及波段宽度窄而连续的特点。HSI 数据的空间信息在二维空间表示,光谱信息在一维空间表示。HSI 上每个像素的光谱特征都由一条密集均匀采样的连续光谱响应曲线来表示,受天气环境、地理位置和自身材料组成的影响,不同地物的辐射强度和反射率不同,导致不同地物的光谱响应曲线也不同。HSI 的高光谱分辨率可以更精确地区分不同地物之间的细微差异,使其在地面目标的分类和检测中得到了广泛应用^[1-3]。

HSI 异常像素出现在复杂背景中的概率较低,在空间上表现为稀疏性,而背景像素通常具有空间相似性,各像素之间的相关性较强,在空间上表现为低秩性。因此,HSI 的异常目标检测可看作是一个二分类问题,将 HSI 分为稀疏异常分量 and 低秩背景分量,从而对背景进行建模,无需先验信息,就能将异常目标从背景和噪声中分离出来,从而完成异常目标检测。在诸多高光谱异常目标检测算法中,Reed 等^[4]提出的 RX 检测算法是最常用的算法之一,RX 检测又可分为全局 RX (GRX) 检测和局部 RX (LRX) 检测。GRX 假设 HSI 背景的概率密度函数服从均匀高斯随机分布,估计了整张图像的背景统计量,但容易污染背景,影响检测性能。LRX 检测利用滑动双窗口获取局部背景信息,估计背景的高斯分布,减小了异常和噪声对背景估计的影响,但无法完全消除。上述检测算法都是在均匀高斯随机分布的基础上完成异常目标的检测,不符合实际情况。Kwon 等^[5]考虑到 HSI 中的非线性因素,提出了一种基于核的非线性 RX (KRX) 算法,该算法利用了光谱波段之间的高阶相关性,但计算过程复杂、时间成本较高。基于表示的异常目标检测算法也常用于 HSI 异常目标的检测,可分为基于稀疏表示 (SR) 和协同表示的异常目标检测算法,Chen

等^[6]提出了基于 SR 的无监督异常目标检测算法,在此基础上,Xu 等^[7]提出了一种低秩稀疏表示 (LRASR) 算法,采用无监督学习方式进行异常目标检测。Li 等^[8]提出了一种协同表示检测 (CRD) 算法,用于 HSI 异常目标的检测,该算法是一种非参数监督的异常目标检测算法,通过求解残差估计检测异常。为了更好地分离异常和背景,Sun 等^[9]提出了一种低秩稀疏矩阵分解 (LRaSMD) 算法,避免了背景模型被异常和噪声污染,并提高了算法的检测性能。张晓慧等^[10]提出了一种基于稀疏字典表达的 HSI 异常目标检测算法,通过稀疏表示构造一个背景字典,然后通过计算重构误差检测异常目标。Zhang 等^[11]提出了一种基于马氏距离的低秩稀疏矩阵分解 (LSMAD) 异常目标检测算法,提高了稀疏分量的稳定性。为了构造一个稀疏分量稳定的子集,Ma 等^[12]根据稀疏分量的行稀疏性提出了行约束的低秩稀疏矩阵分解算法,通过对低秩稀疏矩阵的分解进行行约束,固定一个子集构造稀疏分量,进一步提高了异常检测的稳定性。

本文考虑了 HSI 中混合像元对异常检测算法性能的影响,提出了一种基于端元提取和低秩稀疏矩阵分解的 HSI 异常目标检测算法。采用合成高光谱数据和真实高光谱数据对本算法的性能进行了实验验证和分析,结果表明,本算法可以有效减少噪声污染,进一步增强对异常和背景的区分能力。

2 算法原理

2.1 高光谱图像最优分数阶傅里叶变换

本算法的实现框架如图 1 所示,其中,SAMCC 为连续最大角凸锥算法。高光谱原始信号由包含反射谱和傅里叶域信息的中间域表示,进而采用分数阶傅里叶变换 (FrFT) 对高光谱数据进行预处理,以

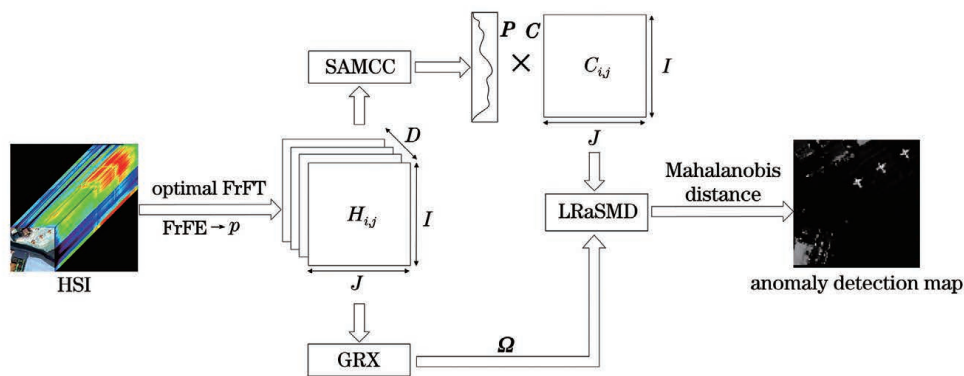


图 1 本算法的框架

Fig. 1 Framework of our algorithm

抑制噪声^[13],增强异常和背景的分辨力,提取显著特征,并进一步结合分数阶傅里叶熵(FrFE)^[14]自动确定最优分数变换阶次。

将三维 HSI 数据表示为向量 $\mathbf{X} = [\mathbf{X}_1, \dots, \mathbf{X}_N]^T \in \mathbf{R}^{N \times D}$, 其中, N 为像素数量, D 为光谱波段

数。FrFT 域中的每个像素可表示为

$$\mathbf{x}_p(u) = (1/D) \sum_{s=1}^D \mathbf{x}(s) K_p(s, u), 0 < p < 1, \quad (1)$$

式中, $\mathbf{x}(s)$ 为每个像素的原始频谱, p 为 FrFT 的分数阶次, 变换核函数 $K_p(s, u)$ 可表示为

$$K_p(s, u) = \begin{cases} A_\phi \exp[j\pi(s^2 \cot \phi - 2s u \csc \phi + u^2 \cot \phi)], \phi \neq n\pi \\ \delta(s - u), \phi = 2n\pi \\ \delta(s + u), \phi = (2n \pm 1)\pi \end{cases}, \quad (2)$$

式中, n 为整数, $\phi = p\pi/2$ 为旋转角, $\delta(s - u)$ 和 $\delta(s + u)$ 分别为旋转角度 $\phi = 2n\pi$ 和 $\phi = (2n \pm 1)\pi$ 时的冲激函数, A_ϕ 可表示为

$$A_\phi = \frac{\exp[-j\pi \operatorname{sgn}(\sin \phi)/4 + j\phi/2]}{|\sin \phi|^{1/2}}, \quad (3)$$

式中, $\operatorname{sgn}(\cdot)$ 为符号函数。可以发现, 当 $p=0$ 时, $\mathbf{x}_p(s)$ 为原始频谱; 当 $p=1$ 时, $\mathbf{x}_p(s)$ 为传统傅里叶

变换域频谱。选择合适的分数阶次 p 可以更好地结合原始反射谱和傅里叶域信息, 抑制噪声, 从而区分背景和异常。基于 FrFE 策略确定分数阶 p , p 阶 FrFE 可表示为

$$\mathbf{E}_p^{\text{FrFE}} = \mathbf{E} \cdot \mathbf{X}_p, \quad (4)$$

式中, \mathbf{E} 为香农熵算子, \mathbf{X}_p 为 FrFT 得到的谱向量。FrFT 域中香农熵的不确定性可定义为

$$E[|\mathbf{x}_p(u)|^2] + E[|\mathbf{x}_p(s)|^2] \geq \ln[\pi e \cdot |\sin(p)|], \quad (5)$$

式中, $\mathbf{x}(u)$ 为 $\mathbf{x}(s)$ 的傅里叶变换, 得到的最优分数阶次可表示为

$$p = \operatorname{argmax}_p \mathbf{E}_p^{\text{FrFE}}, \text{ s. t. } E[|\mathbf{x}_p(u)|^2] + E[|\mathbf{x}_p(s)|^2] \geq \ln[\pi e \cdot |\sin(p)|]. \quad (6)$$

2.2 连续最大角凸锥端元提取

Gruninger 等^[15]提出了一种基于凸锥模型表示矢量数据端元提取的方法, 即 SAMCC 算法。SAMCC 算法采用凸分解方法进行光谱分解, 提取端元光谱子集对地物类型和自动变化进行建模, 通过对局部端元光谱特征的描述选取出异常光谱作为候选异常谱, 用于异常目标的检测中。

SAMCC 算法认为高光谱数据可通过分配光谱通道的矩阵行和场景像素的光谱列表示为一个数据矩阵。假设通过 FrFT 得到的数据矩阵为 \mathbf{H} , 元素 $H_{i,j}$ 为第 j 个像素在第 i 个通道的亮度, \mathbf{H} 的每一行为一个通道图像, 每一列包含一个像素光谱, 则

$$H_{i,j} = \sum_{l=1}^L C_{i,l}^l P_{l,j} + R_{i,j}^l, \quad (7)$$

展开系数 $C_{i,l}^l$ 满足

$$\begin{cases} C_{i,l}^l \geq 0 \\ \sum_{l=1}^L C_{i,l}^l = 1 \end{cases}, \quad (8)$$

式中, L 为行展开长度, 矩阵 \mathbf{P} 为 \mathbf{H} 图像矩阵中的单通道图像矩阵, 即端元图像矩阵, \mathbf{C}^l 为展开系数

矩阵, 包含了 L 个端元图像对每个数据图像的贡献度, 矩阵 \mathbf{R}^l 为残差矩阵。采用 AMGS(Augmented modified gram schmidt)增广修正的顺序正交化方法对一组极值向量进行凸分解, 可得到相应的端元光谱矩阵、丰度矩阵和残差矩阵。

2.3 低秩稀疏矩阵分解

采用 LSMAD 算法检测 HSI 的异常目标, 该算法认为 HSI 数据的背景图像是低秩的, 每个波段图像中的异常目标是稀疏的, 可基于马氏距离完成异常目标检测。高光谱背景图像和异常目标可表示为

$$\mathbf{X} = \mathbf{L} + \mathbf{S} + \mathbf{Z}, \quad (9)$$

式中, $\mathbf{L} = [\mathbf{L}_1, \dots, \mathbf{L}_N]^T \in \mathbf{R}^{N \times D}$ 为背景矩阵, 每一行代表一个光谱向量的背景分量, $\mathbf{S} = [\mathbf{S}_1, \dots, \mathbf{S}_N]^T \in \mathbf{R}^{N \times D}$ 为异常矩阵, 每一行代表一个光谱向量的异常分量, $\mathbf{Z} = [\mathbf{Z}_1, \dots, \mathbf{Z}_N]^T \in \mathbf{R}^{N \times D}$ 为噪声矩阵, 每一行代表一个光谱向量的噪声分量。背景和异常矩阵的每一列代表单波段图像背景分量和异常分量的光谱。

HSI 异常检测可以表示为约束优化问题, 即

$$\operatorname{argmin}_{\mathbf{B}, \mathbf{S}} \|\mathbf{X} - \mathbf{L} - \mathbf{S}\|_F^2, \text{ s. t. } \operatorname{rank}(\mathbf{L}) \leq r, \operatorname{card}(\mathbf{S}) \leq kN, \quad (10)$$

式中, $\|\cdot\|_F$ 为 Frobenius 范数, r 为背景矩阵的最大秩, k 为稀疏矩阵的最大稀疏度。通过 SAMCC 端元提取可得到相应的端元和丰度矩阵, 因此, 将(10)式变换为

$$\operatorname{argmin}_{\mathbf{B}, \mathbf{A}} \|\mathbf{C} - \mathbf{B} - \mathbf{A}\|_F^2, \text{ s. t. } \operatorname{rank}(\mathbf{B}) \leq r, \operatorname{card}(\mathbf{A}) \leq kN, \quad (11)$$

式中, \mathbf{C} 为丰度矩阵, \mathbf{B} 为低秩背景矩阵, \mathbf{A} 为稀疏异常矩阵。可将(11)式转换为两个优化子问题, 即

$$\begin{cases} \mathbf{B}_t = \operatorname{arg} \min_{\operatorname{rank}(\mathbf{B}) \leq r} \|\mathbf{C} - \mathbf{B} - \mathbf{A}_{t-1}\|_F^2 \\ \mathbf{A}_t = \operatorname{arg} \min_{\operatorname{card}(\mathbf{A}) \leq k} \|\mathbf{C} - \mathbf{B}_t - \mathbf{A}\|_F^2 \end{cases}, \quad (12)$$

式中, t 为优化迭代的次数。可采用基于双边随机投影 (BRP) 低秩近似的 GoDec 分解方法^[16] 求解(12)式, 为了防止 \mathbf{C} 的奇异值衰减过慢, 采用奇异值衰减更快的矩阵 $\tilde{\mathbf{C}} = (\mathbf{C}\mathbf{C}^T)^q \mathbf{C}$ (q 为指数) 计算 BRP, 当 $\lambda_i(\tilde{\mathbf{C}}) = \tilde{\mathbf{C}}^{2q+1}$ (λ_i 为矩阵第 i 个最大奇异值) 时, $\tilde{\mathbf{C}}$ 的 BRP 可表示为

$$\mathbf{Y}_1 = \tilde{\mathbf{C}}\mathbf{U}_1, \mathbf{Y}_2 = \tilde{\mathbf{C}}^T\mathbf{U}_2. \quad (13)$$

通过给定的 BRP 和 $m \times n$ 的稠密矩阵 \mathbf{C} ($m \geq n$) 得到 $\mathbf{Y}_1 = \mathbf{C}\mathbf{U}_1, \mathbf{Y}_2 = \mathbf{C}^T\mathbf{U}_2$ 。其中, \mathbf{U}_1 和 \mathbf{U}_2 为随机矩阵, $\mathbf{U}_1 \in \mathbf{R}^{n \times r}, \mathbf{U}_2 \in \mathbf{R}^{m \times r}$ 。为了提高近似精度,

利用得到的右随机投影 \mathbf{Y}_1 构建更好的左投影矩阵 \mathbf{U}_2 ; 同理, 用 \mathbf{Y}_2 构建 \mathbf{U}_1 , 当 $\mathbf{Y}_1 = \mathbf{C}\mathbf{U}_1$, 将 \mathbf{U}_2 更新为 \mathbf{Y}_1 , 然后计算左投影矩阵 $\mathbf{Y}_2 = \mathbf{C}^T\mathbf{U}_2$, 再将 \mathbf{U}_1 更新为 \mathbf{Y}_2 , 并计算右投影矩阵 $\mathbf{Y}_1 = \mathbf{C}\mathbf{U}_1$, 得到 $\tilde{\mathbf{C}}$ 的 BRP 低秩近似为

$$\tilde{\mathbf{B}} = \mathbf{Y}_1(\mathbf{U}_2^T\mathbf{Y}_1)^{-1}\mathbf{Y}_2^T. \quad (14)$$

通过计算 \mathbf{Y}_1 和 \mathbf{Y}_2 的正交 (QR) 分解得到 \mathbf{C} 的低秩近似为

$$\mathbf{Y}_1 = \mathbf{Q}_1\mathbf{R}_1, \mathbf{Y}_2 = \mathbf{Q}_2\mathbf{R}_2, \quad (15)$$

式中, \mathbf{Q}_1 和 \mathbf{Q}_2 为正交单位矩阵, \mathbf{R}_1 和 \mathbf{R}_2 为上三角矩阵, 则 \mathbf{C} 的低秩近似可表示为

$$\mathbf{B} = (\tilde{\mathbf{B}})^{\frac{1}{2q+1}} = \mathbf{Q}_1[\mathbf{R}_1(\mathbf{U}_2^T\mathbf{Y}_1)^{-1}\mathbf{R}_2^T]^{\frac{1}{2q+1}}\mathbf{Q}_2^T. \quad (16)$$

若 $q=0$, 不执行 QR 分解; 若 $q>0$, 执行 QR 分解。得到的 \mathbf{B}_t 和 \mathbf{A}_t 可表示为

$$\begin{cases} \mathbf{B}_t = \mathbf{Q}_1[\mathbf{R}_1(\mathbf{U}_2^T\mathbf{Y}_1)^{-1}\mathbf{R}_2^T]^{\frac{1}{2q+1}}\mathbf{Q}_2^T \\ \mathbf{A}_t = \mathbf{P}_\Omega(\mathbf{C} - \mathbf{B}_t) \\ \mathbf{P}_\Omega(\mathbf{C} - \mathbf{B}_t) = \mathbf{C} - \mathbf{B}_t, p_i \geq T \\ \mathbf{P}_\Omega(\mathbf{C} - \mathbf{B}_t) = \mathbf{0}, p_i < T \\ \Omega: |(C - B_t)_{i,j \in \Omega}| \neq 0, |(C - B_t)_{i,j \in \bar{\Omega}}| \geq |(C - B_t)_{i,j \in \bar{\Omega}}|, |\Omega| \leq k, \bar{\Omega} = \sup(\mathbf{A}_{t-1}) \end{cases}, \quad (17)$$

式中, Ω 为 $(\mathbf{C} - \mathbf{B}_t)$ 前 k 个最大非 0 子集, $\mathbf{P}_\Omega(\mathbf{C} - \mathbf{B}_t)$ 为 $(\mathbf{C} - \mathbf{B}_t)$ 在 Ω 上的投影, $\bar{\Omega}$ 为矩阵 \mathbf{A}_{t-1} 的非 0 项集合, p_i 为第 i 个像素的异常概率, T 为异常概率阈值。分解需要对各变量进行初始化, 初始化设置 $\mathbf{B}_0 = \mathbf{C}, \mathbf{A}_0 = \mathbf{0}, t = 0$, 交替计算低秩矩阵 \mathbf{B} 和稀疏矩阵 \mathbf{A} 。分解误差随着迭代次数的增加单调减小, 当 $\|\mathbf{C} - \mathbf{B} - \mathbf{A}_{t-1}\|_F^2 / \|\mathbf{C}\|_F^2$ 小于设定容许误差限 ϵ 或 t 大于最大迭代次数 M_{iter} 时, 停止迭代。

为了构造更稳定的稀疏矩阵子集, 文献[12]中考虑了稀疏矩阵 \mathbf{A} 的行稀疏性, 对稀疏矩阵 \mathbf{A} 进行了行约束, 再用处理过的 HSI 构建一个更加稳定的子集。设置异常概率阈值, 若第 i 个像素的异常概率大于或等于该阈值, 则 $\mathbf{P}_\Omega = \mathbf{C} - \mathbf{B}_t$; 若

小于阈值, 则 $\mathbf{P}_\Omega = \mathbf{0}$ 。通过建立一个背景原子字典, 得到一个协方差矩阵 Σ , 将得到的稀疏矩阵 \mathbf{A} 和低秩近似矩阵 \mathbf{B} 分别平铺为向量 $[\mathbf{A}_1, \dots, \mathbf{A}_N]^T$ 和 $[\mathbf{B}_1, \dots, \mathbf{B}_N]^T$, $\bar{\mathbf{A}}$ 和 $\bar{\mathbf{B}}$ 为分别为向量 \mathbf{A} 和 \mathbf{B} 的均值, 则基于马氏距离检测异常的过程可表示为

$$\begin{cases} d_i = \sqrt{(\mathbf{A} - \bar{\mathbf{A}})^T \Sigma^{-1} (\mathbf{A} - \bar{\mathbf{A}})} \\ \Sigma = \frac{1}{N} (\mathbf{B} - \bar{\mathbf{B}})^T (\mathbf{B} - \bar{\mathbf{B}}), \end{cases} \quad (18)$$

式中, d_i 为第 i 个像素的异常值, 异常值越大, 表明像素为异常像素的概率越高。当 d_i 大于设定异常阈值时, 表明检测到异常目标; 当 d_i 小于设定异常时, 则认为是背景图像。本算法在各数据集上的参数如表 1 所示。

表 1 本算法在不同数据集上的参数

Table 1 Parameters of our algorithm on different datasets

Parameter	Salinas	SpecTIR	HYDICE	San Diego	ABU-A4	ABU-B3	ABU-U1
r	7	8	6	1	4	5	3
k	0.7	0.8	0.65	0.45	0.7	0.7	0.1
q	0	0	0	0	0	0	0
M_{iter}	100	100	100	100	100	100	100
ϵ	0.001	0.001	0.001	0.001	0.001	0.001	0.001

3 实验结果与分析

实验采用合成数据和真实数据对本算法进行验证,并对比了不同算法检测后实际输出的灰度图像、接收者操作特性(ROC)曲线、ROC 曲线下与坐标轴围成的面积(AUC)和检测时间,以验证本算法的有效性。所有算法程序均在 Matlab2019b 上实现,计算机的中央处理器为 Inter(R) CORE I5-6300HQ CPU@2.30 GHz,运行内存 RAM 为 8.00 GB。

3.1 合成数据

第一组实验数据来自机载可见红外光谱仪 AVIRIS 在 Salinas Valley 生成的合成数据 Salinas。原始数据集包括蔬菜、裸露的土壤和葡萄园,图像尺寸为 512 pixel×217 pixel,包含 224 个波段,空间分辨率为 3.7 m,去除 20 个大气和吸水波段(108~112、154~167 和 224)后,裁剪得到一个尺寸为 120 pixel×120 pixel 的子图像,植入异常目标后的合成图像如图 2 所示。




图 2 Salinas 合成数据。(a) 伪彩色图像;(b) 真值图
Fig. 2 Salinas synthetic dataset. (a) False-color image;
(b) ground-truth map

3.2 真实数据描述

SpecTIR 数据:第二组实验数据采用 SpecTIR 高光谱机载 Rochester 实验的真实数据,图像尺寸为 180 pixel×180 pixel,包含 120 个波段,空间分辨率为 1 m。图像场景的背景主要由道路和植被构成,异常目标由不同的人造彩色方形织物组成,伪彩

色图像和真值图像如图 3 所示。




图 3 SpecTIR 数据。(a) 伪彩色图像;(b) 真值图
Fig. 3 SpecTIR dataset. (a) False-color image;
(b) ground-truth map

HYDICE 数据:第三组实验数据采用的是 HYDICE 城市场景真实数据,图像尺寸为 80 pixel×100 pixel,空间分辨率为 1 m,去除吸水和不良波段后共包含 175 个波段,有 21 个异常目标,表示为汽车和屋顶,伪彩色图像和真值图像如图 4 所示。




图 4 HYDICE 城市数据。(a) 伪彩色图像;(b) 真值图
Fig. 4 HYDICE urban dataset. (a) False-color image;
(b) ground-truth map

AVIRIS 数据:第四组实验数据采用机载可见红外光谱仪 AVIRIS 采集的真实数据,分别为 ABU 数据集和 San Diego 数据集。其中,San Diego 数据集中的图像尺寸为 100 pixel×100 pixel,包含 224 个波段,去除吸水和不良波段(1~6、33~35、97、107~113、153~166 和 221~224)后,共有 189 个波段,伪彩色图像和真值图像如图 5 所示。ABU 数据集图像的尺寸为 100 pixel×100 pixel,




图 5 San Diego 数据。(a) 伪彩色图像; (b) 真值图
Fig. 5 San Diego dataset. (a) False-color image;
(b) ground-truth map

ABU-A4 的采集地点为 Gulfport, 去除不良波段后共有 191 个波段, 空间分辨率为 3.4 m; ABU-B3 的采集地点为 Sandiego, 去除不良波段后共有 188 个波段, 空间分辨率为 7.5 m; ABU-U1 的采集地点为

Texas Coast, 去除不良波段后共有 204 个波段, 空间分辨率为 17.2 m。

3.3 分析与讨论

将实验输出的灰度图像和参考真值图像进行对比, 以分析不同算法的检测效果, 输入图像为原始高光谱图像, 用伪彩色图像表示, 参考图像为地面目标真值图像。图 6 为不同算法在不同 HSI 数据集上的检测效果, 综合考虑不同图像数据集上的检测效果发现, 本算法在各个图像数据集上输出的灰度图像和参考真值图像最接近, 可以很好地区分背景和异常, 检测出异常目标, 其他算法的检测效果一般, 难以区分背景和异常。由于仅分析检测图像无法对比不同算法的优劣性, 因此还需要对算法的 ROC 曲线、AUC 值和检测时间进行对比。

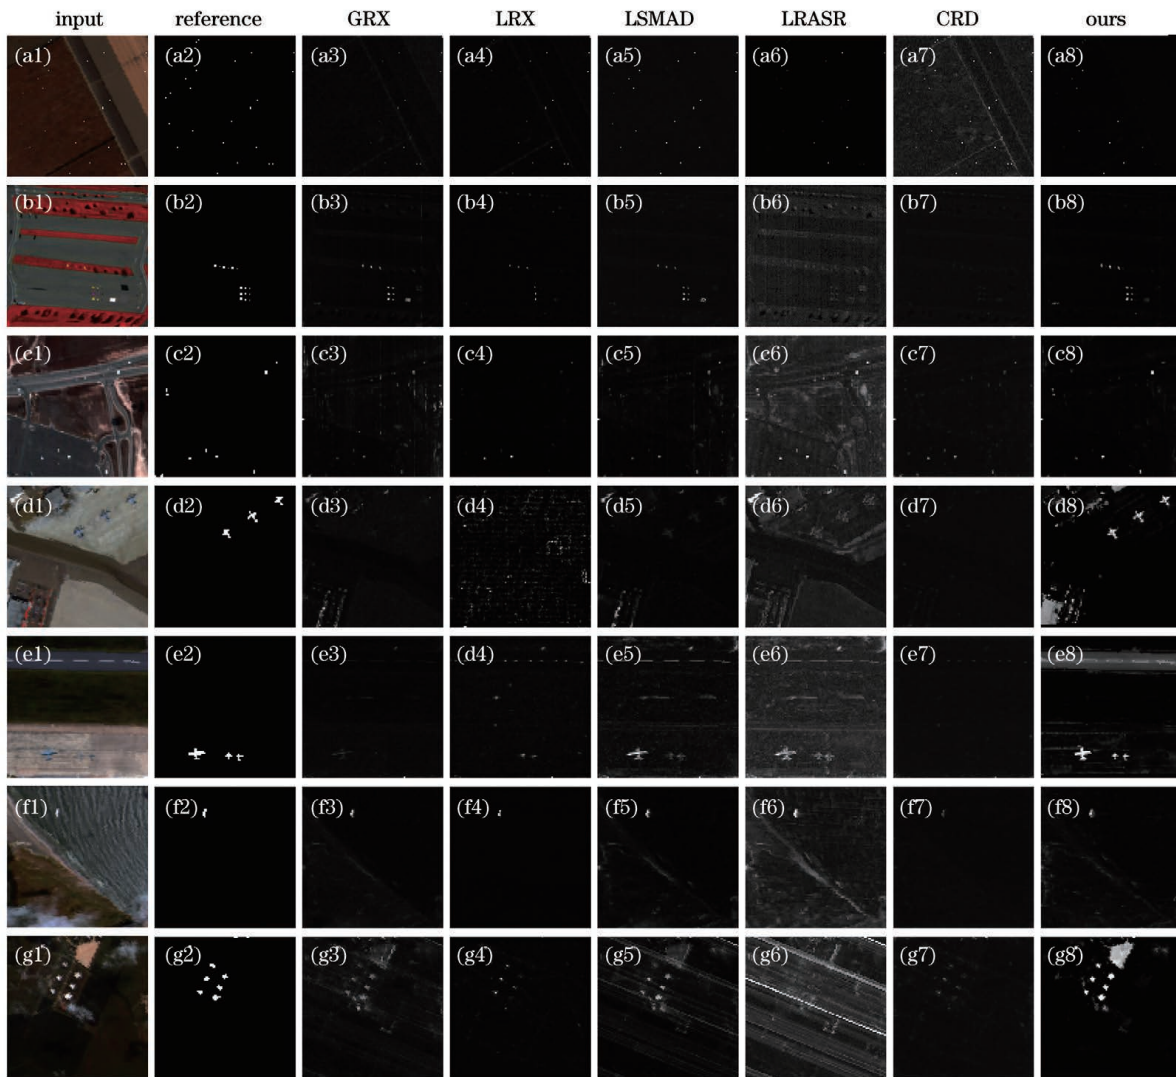


图 6 不同算法的输出结果。(a) Salinas; (b) SpecTIR; (c) HYDICE; (d) San Diego; (e) ABU-A4; (f) ABU-B3; (g) ABU-U1
Fig. 6 Output results of different algorithms. (a) Salinas; (b) SpecTIR; (c) HYDICE; (d) San Diego; (e) ABU-A4;
(f) ABU-B3; (g) ABU-U1

ROC 曲线是对异常检测算法检测性能的定性评价指标,可反映异常目标检测算法的检测性能,其中,横轴表示虚警率,纵轴表示检测率。图 7 为不同算法在 Salinas 合成数据集上的 ROC,可以发现,本算法在虚警率相同的情况下检测率高于其他算法。图 8 和图 9 为不同算法在 SpecTIR 数据集和 HYDICE 数据集上的 ROC 曲线,图 10、图 11、图 12 和图 13 分别为不同算法在 AVIRIS 数据集上的 ROC,可以发现,在真实数据集上,本算法在同一虚

警率下的检测率基本优于其他算法。在 SpecTIR 和 HYDICE 数据集上,本算法的 ROC 基本高于其他算法;在 ABU-U1 数据集上,本算法和 GRX、LSMAD 算法的检测性能基本一致,但在较低虚警率下,本算法的检测率可达到 100%。此外,不同算法在 ABU-B3 数据集下都表现出了优越的检测性能,在较低虚警率下检测率几乎都可以达到 100%。综合来看,本算法不论是在合成数据还是真实数据上都表现出优越的检测性能。

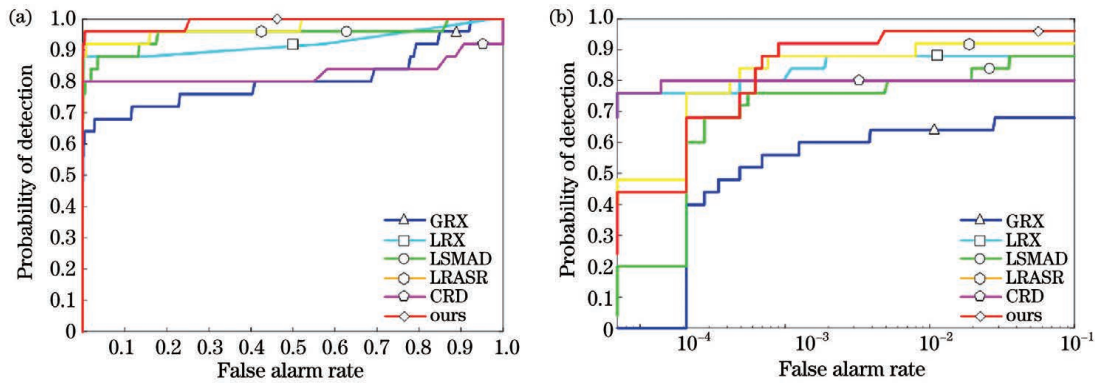


图 7 不同算法在 Salinas 合成数据集上的 ROC 曲线。(a)ROC 曲线;(b)对数型 ROC 曲线

Fig. 7 ROC curves of different algorithms on Salinas synthetic dataset. (a) ROC curve; (b) logarithmic ROC curve

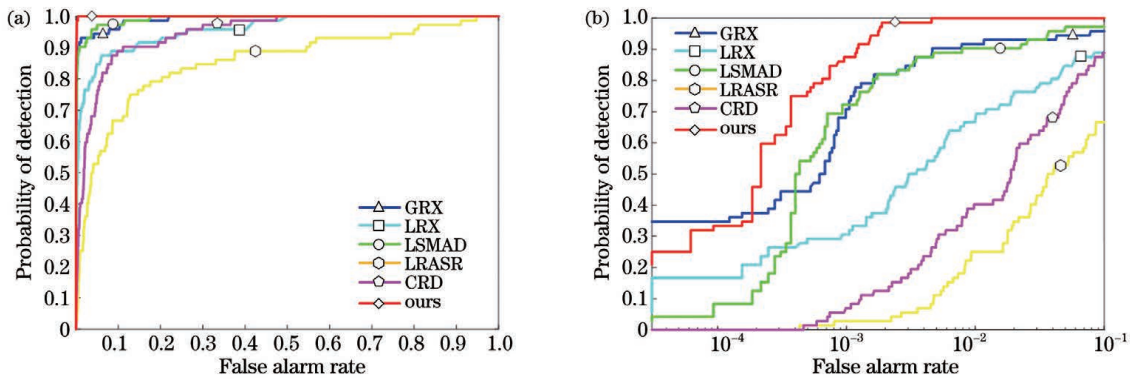


图 8 不同算法在 SpecTIR 数据集上的 ROC 曲线。(a)ROC 曲线;(b)对数型 ROC 曲线

Fig. 8 ROC curves of different algorithms on SpecTIR dataset. (a) ROC curve; (b) logarithmic ROC curve

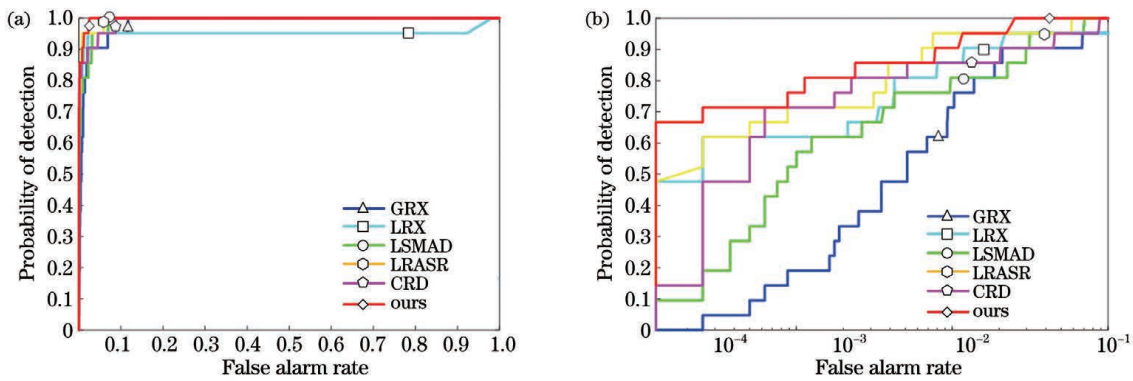


图 9 不同算法在 HYDICE 城市数据集上的 ROC 曲线。(a)ROC 曲线;(b)对数型 ROC 曲线

Fig. 9 ROC curves of different algorithms on HYDICE urban dataset. (a) ROC curve; (b) logarithmic ROC curve

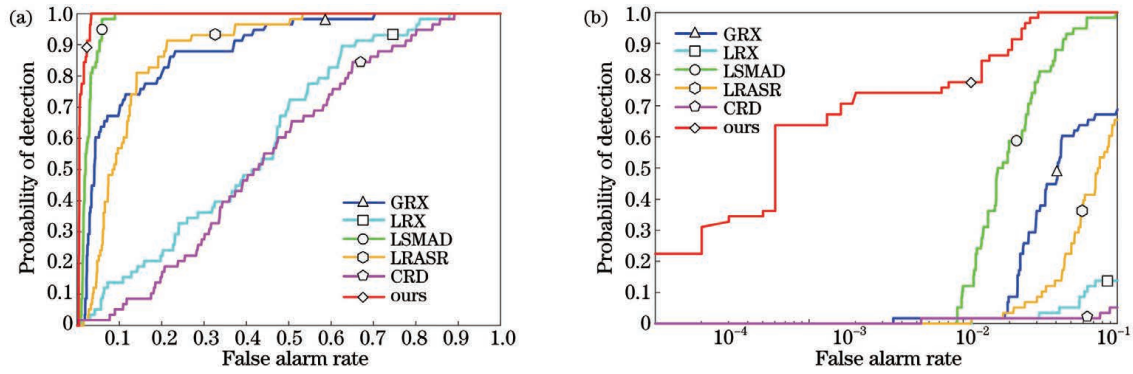


图 10 不同算法在 San Diego 数据集上的 ROC 曲线。(a)ROC 曲线;(b)对数型 ROC 曲线

Fig. 10 ROC curves of different algorithms on San Diego dataset. (a) ROC curve; (b) logarithmic ROC curve

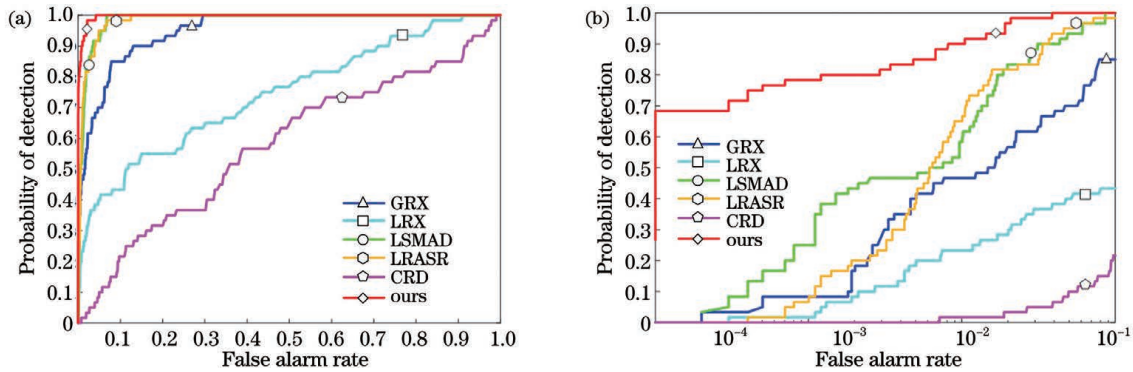


图 11 不同算法在 ABU-A4 数据集上的 ROC 曲线。(a)ROC 曲线;(b)对数型 ROC 曲线

Fig. 11 ROC curves of different algorithms on ABU-A4 dataset. (a) ROC curve; (b) logarithmic ROC curve

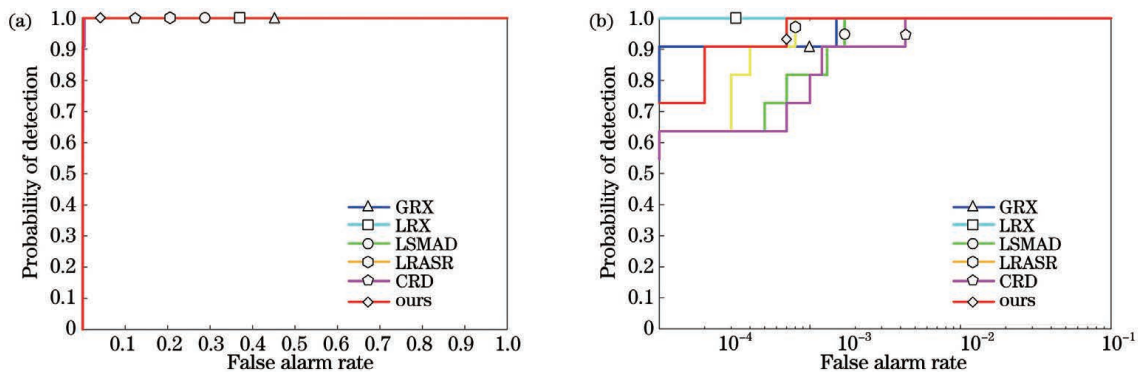


图 12 不同算法在 ABU-B3 数据集上的 ROC 曲线。(a)ROC 曲线;(b)对数型 ROC 曲线

Fig. 12 ROC curves of different algorithms on ABU-B3 dataset. (a) ROC curve; (b) logarithmic ROC curve

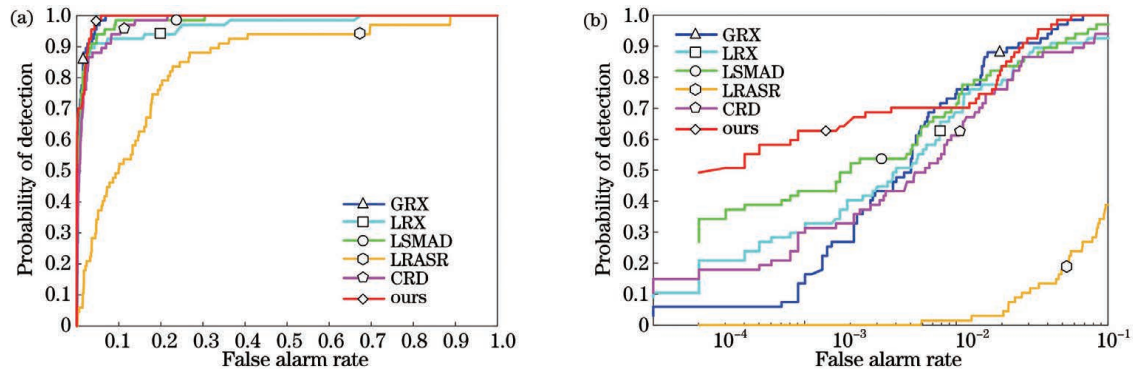


图 13 不同算法在 ABU-U1 数据集上的 ROC 曲线。(a)ROC 曲线;(b)对数型 ROC 曲线

Fig. 13 ROC curves of different algorithms on ABU-U1 dataset. (a) ROC curve; (b) logarithmic ROC curve

AUC 值也是评价异常检测算法检测性能的定量指标,可反映算法的检测性能。AUC 值指 ROC 的下面积,AUC 值越高,表明算法的检测性能越好,检测真实性越高。表 2 为不同算法的 AUC 值,可以

发现,本算法除了在 ABU-B3 数据集上的 AUC 值略低于 LRX 算法外,在其余数据集上都是最高的,但在 ABU-B3 数据集上的 AUC 值也达到了 99.98%,检测率几乎达到 100%,表现出优越的检测性能。

表 2 不同算法的 AUC 值

Table 2 AUC values of different algorithms

Algorithm	Salinas	SpecTIR	HYDICE	San Diego	ABU-A4	ABU-B3	ABU-U1
GRX	0.9725	0.9914	0.9857	0.8886	0.9526	0.9998	0.9907
LRX	0.9232	0.9592	0.9524	0.6246	0.7434	1.0000	0.9674
LSMAD	0.9505	0.9729	0.9914	0.9725	0.9859	0.9996	0.9851
LRASR	0.9725	0.8275	0.9959	0.8804	0.9876	0.9998	0.8160
CRD	0.8273	0.9493	0.9921	0.5605	0.5792	0.9993	0.9803
Ours	0.9896	0.9995	0.9975	0.9943	0.9974	0.9998	0.9919

检测时间可反映算法的时间计算成本,检测时间越短,表明算法的时间计算成本越低。表 3 为不同算法的计算时间,可以发现,检测时间最短的是 GRX 算法,其次是本算法,但 GRX 算法的

AUC 值低于本算法。检测时间最长的是 LRASR 算法,其次是 LRX 算法。综上所述,本算法在 HSI 异常目标的检测性能和检测时间上都具有优越性。

表 3 不同算法的检测时间

Table 3 Detection time of different algorithm

unit: s

Algorithm	Salinas	SpecTIR	HYDICE	San Diego	ABU-A4	ABU-B3	ABU-U1
GRX	0.3	0.3	0.1	0.2	0.1	0.1	0.1
LRX	60.2	52.2	24.1	44.9	40.7	44.1	45.9
LSMAD	24.8	29.1	9.1	15.3	15.4	15.7	16.9
LRASR	87.5	209.9	39.7	60.5	54.6	60.9	60.5
CRD	27.9	65.3	14.9	19.8	19.9	19.8	20.8
Ours	6.4	7.5	6.7	6.9	6.8	7.1	7.0

4 结 论

提出了一种基于端元提取和低秩稀疏矩阵分解的 HSI 异常目标检测算法,考虑了混合像元对异常目标检测的干扰,从而提取到更显著的特征;且具有更强的噪声抑制能力,能很好地预防背景受到的污染。实验结果表明,本算法具有良好的检测效果和检测性能,更容易从背景中区分出异常目标,且计算时间成本较低。综合分析可知,本算法在 HSI 异常目标检测上具有优越性和可行性。

参 考 文 献

[1] Ji L, Zhang X, Zhang L M, et al. Hyperspectral image classification algorithm based on space-spectral weighted nearest neighbor[J]. Laser & Optoelectronics

Progress, 2020, 57(6): 061013.

纪磊, 张欣, 张丽梅, 等. 基于空谱加权近邻的高光谱图像分类算法[J]. 激光与光电子学进展, 2020, 57(6): 061013.

[2] Li F Y, Huo H T, Li J, et al. Hyperspectral image classification via multiple-feature-based improved sparse representation[J]. Acta Optica Sinica, 2019, 39(5): 0528004.

李非燕, 霍宏涛, 李静, 等. 基于多特征和改进稀疏表示的高光谱图像分类[J]. 光学学报, 2019, 39(5): 0528004.

[3] Zhang Q, Dong A G, Song R. Hyperspectral image classification based on multiple features and an improved autoencoder[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081010.

张倩, 董安国, 宋睿. 基于多特征和改进自编码的高光谱图像分类[J]. 激光与光电子学进展, 2020, 57

- (8): 081010.
- [4] 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.
- [5] Kwon H, Nasrabadi 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.
- [6] Chen Y, Nasrabadi N M, Tran T D. Sparse representation for target detection in hyperspectral imagery [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2011, 5(3): 629-640.
- [7] 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.
- [8] Li W, Du Q. Collaborative representation for hyperspectral anomaly detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(3): 1463-1474.
- [9] Sun W W, Liu C, Li J L, et al. Low-rank and sparse matrix decomposition-based anomaly detection for hyperspectral imagery [J]. *Journal of Applied Remote Sensing*, 2014, 8(1): 083641.
- [10] Zhang X H, Hao R F, Li T Y. Hyperspectral abnormal target detection based on low rank and sparse matrix decomposition-sparse representation [J]. *Laser & Optoelectronics Progress*, 2019, 56(4): 042801.
张晓慧, 郝润芳, 李廷鱼. 基于低秩稀疏矩阵分解和稀疏字典表达的高光谱异常目标检测 [J]. *激光与光电子学进展*, 2019, 56(4): 042801.
- [11] Zhang Y X, Du B, Zhang L P, 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): 1376-1389.
- [12] Ma Y, Fan G H, Jin Q W, et al. Hyperspectral anomaly detection via integration of feature extraction and background purification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(8): 1436-1440.
- [13] Yang G L, Lu H R, Tang J, et al. Non-local image denoising with iterative log threshold weighted RPCA [J]. *Journal of Jiangxi University of Science and Technology*, 2016, 37(1): 57-62.
杨国亮, 鲁海荣, 唐俊, 等. 基于迭代对数阈值的加权 RPCA 非局部图像去噪 [J]. *江西理工大学学报*, 2016, 37(1): 57-62.
- [14] Tao R, Zhao X D, Li W, et al. Hyperspectral anomaly detection by fractional Fourier entropy [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(12): 4920-4929.
- [15] Gruninger J H, Ratkowski A J, Hoke M L. The sequential maximum angle convex cone (SMACC) endmember model [J]. *Proceedings of SPIE*, 2004, 5425: 1-14.
- [16] Zhou T, Tao D. GoDec: randomized low-rank & sparse matrix decomposition in noisy case [C]// *Proceedings of the 28th International Conference on Machine Learning*, June 28-July 2, 2011, Bellevue, Washington D.C., USA. Trier: DBLP, 2011: 33-40.