

## 基于图正则化低秩协同表示的高光谱异常检测

吴琪<sup>1\*</sup>, 樊彦国<sup>1</sup>, 樊博文<sup>2</sup>, 禹定峰<sup>3</sup><sup>1</sup>中国石油大学(华东)海洋与空间信息学院, 山东 青岛 266580;<sup>2</sup>哈尔滨工程大学水声工程学院, 黑龙江 哈尔滨 150001;<sup>3</sup>齐鲁工业大学(山东省科学院)海洋仪器仪表研究所, 山东 青岛 266061

**摘要** 高光谱异常检测是检测出与周围背景像素的光谱具有明显差异的目标的过程。研究学者针对高光谱异常检测提出了多种算法,其中低秩协同表示检测器(LRCRD)不仅能够考虑所有像素之间的高光谱相关性,而且用低秩和 $L_2$ 范数最小化约束字典的系数矩阵,背景字典不需要过度完备,可以更好地表示背景。然而,LRCRD模型并没有考虑到高光谱数据的局部几何信息对于区分背景和异常像素的重要性。将图拉普拉斯正则项引入LRCRD模型中,提出了一种基于图正则化低秩协同表示的异常检测方法,分析数据中的非线性几何信息。该方法保持高光谱图像的局部几何结构,提高了检测精度。在合成和真实高光谱数据集上对所提方法进行了实验验证,实验结果证明了所提方法的可行性。

**关键词** 遥感; 高光谱图像; 异常探测; 图拉普拉斯正则化; 流形结构; 低秩协同表示

中图分类号 TP751

文献标志码 A

DOI: 10.3788/LOP202259.1228003

## Graph Regularized Low-Rank and Collaborative Representation for Hyperspectral Anomaly Detection

Wu Qi<sup>1\*</sup>, Fan Yanguo<sup>1</sup>, Fan Bowen<sup>2</sup>, Yu Dingfeng<sup>3</sup><sup>1</sup>College of Oceanography and Space Informatics, China University of Petroleum (East China),

Qingdao 266580, Shandong, China;

<sup>2</sup>College of Underwater Acoustic Engineering, Harbin Engineering University, Harbin 150001, Heilongjiang, China;<sup>3</sup>Institute of Oceanographic Instrumentation, Qilu University of Technology (Shandong Academy of Sciences),

Qingdao 266061, Shandong, China

**Abstract** The aim of hyperspectral anomaly detection is to find targets that are spectrally distinct from their surrounding background pixels. Many algorithms for hyperspectral anomaly detection have been proposed by researchers. Among these, the low-rank and collaborative representation detector (LRCRD) can not only analyze the hyperspectral correlation between all pixels but also constrain the coefficient matrix of the dictionary using low-rank and  $L_2$  norms minimization, which does not require an over-complete dictionary and is more useful for background modeling. However, the LRCRD model ignores the significance of the hyperspectral data's local geometric information to distinguish between background and anomalous pixels. In this paper, the graph-Laplacian regularization is incorporated into the LRCRD formulation and a novel anomaly detection method is proposed based on the graph regularized LRCRD model to analyze nonlinear geometric information. The proposed preserves local geometrical structure in hyperspectral images, thereby improving detection accuracy. The experiments on synthetic

收稿日期: 2021-03-25; 修回日期: 2021-05-22; 录用日期: 2021-06-10

基金项目: 山东省重点研发计划(2019GHY112017)

通信作者: \*wqzwy0825@163.com

and real hyperspectral datasets demonstrate the feasibility of the proposed method.

**Key words** remote sensing; hyperspectral image; anomaly detection; graph Laplace regularization; manifold structure; low-rank and collaborative representation

## 1 引言

高光谱遥感图像具有光谱分辨率高、图谱合一的特点,可以更好地识别地物。高光谱目标检测根据目标先验知识是否已知分为监督目标检测和异常目标检测<sup>[1]</sup>,然而在实际情况中,目标光谱的先验知识很难获得,因此不需要任何先验知识的异常目标探测成为研究热点,被广泛应用于军事和精准农业等领域<sup>[2]</sup>。

Reed 等<sup>[3]</sup>提出的 Reed-Xiaoli 检测器(RXD)是最为经典的高光谱异常检测算法。RX 算法分为全局 RX(GRX)和局部 RX(LRX)<sup>[4]</sup>。RX 算法有两个缺点,一是高光谱图像的背景并不完全服从高斯分布,二是在计算背景协方差矩阵时会受到异常像素的影响。针对 RX 算法的缺点,不需要任何分布假设的基于表示的高光谱异常检测算法被提出,主要包括协同表示检测器(CRD)、稀疏表示检测器(SRD)和低秩表示(LRR)。稀疏表示已被用于高光谱分类<sup>[5]</sup>、目标检测<sup>[6]</sup>和异常检测<sup>[7-8]</sup>中。Li 等<sup>[9]</sup>提出了基于协同表示的异常检测方法,该方法易于实现,并且在  $l_2$  范数最小化的约束下具有较高的检测精度,但是没有考虑异常像素对邻域的影响。Liu 等<sup>[10]</sup>提出的 LRR 算法处理包含离群值的数据时从单个子空间扩展到多个子空间,能有效地揭示数据的全局结构。在此基础上,Wu 等<sup>[11]</sup>提出了一种结合低秩和协同表示的高光谱异常检测器(LRCRD),该方法用低秩和  $l_2$  范数最小化约束背景,具有稀疏性的异常,受  $l_{2,1}$  范数最小化约束。LRCRD 算法虽然可以从全局角度描述所有像素之间的关系,但没有考虑数据中的非线性几何结构,因此在学习过程中可能会丢失像元之间的局部性和相似性信息。许多研究表明,高维数据通常存在于嵌入在高维观测空间的低维流形上<sup>[12]</sup>,整体和局部结构对于表征过程都是必不可少的<sup>[13-14]</sup>。

在上述分析的基础上,本文提出了一种基于图正则化低秩协同表示的高光谱异常检测方法(GLRCRD),在低秩协同表示模型中加入图拉普拉斯正则化项,不仅可以表示全局低维结构,而且可以捕获数据中的固有非线性几何信息。该方法通

过建立一个  $k$ -近邻图来表示高光谱数据中的局部流形信息,图拉普拉斯算子被用来保持数据的局部几何流形结构,从而有助于 GLRCRD 从自然背景中分离异常,进一步提高检测精度。

## 2 相关算法

### 2.1 低秩协同表示

高光谱图像  $\mathbf{Y} \in \mathbf{R}^{b \times n}$  可通过 LRR 模型分为背景  $\mathbf{B} \in \mathbf{R}^{b \times n}$  和异常  $\mathbf{E} \in \mathbf{R}^{b \times n}$  两部分,其中  $n$  表示像素数目, $b$  表示波段数。由于高光谱图像背景具有同质性,所以背景  $\mathbf{B}$  可以由背景字典  $\mathbf{D} \in \mathbf{R}^{b \times m}$  和低秩系数矩阵  $\mathbf{S} \in \mathbf{R}^{m \times n}$  线性表示,其中  $m$  表示背景字典中原子的数量。异常目标小且与背景具有显著差别,具有稀疏性。因此,LRR 模型的目标函数<sup>[10]</sup>为

$$\min_{\mathbf{S}, \mathbf{E}} \|\mathbf{S}\|_* + \|\mathbf{E}\|_{2,1} \text{ s.t. } \mathbf{Y} = \mathbf{D}\mathbf{S} + \mathbf{E}, \quad (1)$$

式中: $\|\cdot\|_*$  是低秩的凸解。 $l_{2,1}$  范数使  $\mathbf{E}$  的列和为零,从而约束稀疏性。

将表示系数矩阵的低秩约束集成到 CRD 框架,LRCRD 的目标函数<sup>[11]</sup>为

$$\min_{\mathbf{S}, \mathbf{E}} \|\mathbf{S}\|_* + \lambda \|\mathbf{S}\|_2 + \gamma \|\mathbf{E}\|_{2,1} \text{ s.t. } \mathbf{Y} = \mathbf{D}\mathbf{S} + \mathbf{E}, \quad (2)$$

式中: $l_2$  范数使得所有字典原子能够参与背景表示,并且每个系数都很小;惩罚系数  $\lambda > 0, \gamma > 0$ 。

### 2.2 基于图的流形学习

LRR 和 LRCRD 模型都只考虑数据空间中的全局结构,许多研究已经表明,局部几何结构对检测也很重要。为了保持数据空间中的局部几何结构,原始数据空间中的邻近点在表示空间中也应该有相似的表示<sup>[15]</sup>,即如果两个像素  $\mathbf{y}_i$  和  $\mathbf{y}_j$  具有相似的光谱特征,那么它们的表示系数  $\mathbf{s}_i$  和  $\mathbf{s}_j$  也应该接近。图 1 显示了应用主成分分析后高光谱实验(HYDICE)数据集中所有像素的散点图(图中 PC 表示数据的主成分)。从图 1 可以明显看出,并不是所有的像素都位于相同的流形结构上。因此,如果同时考虑到数据的全局低秩性和局部几何结构,异常和背景像素之间的可分性将得到进一步提高。

给定一组像素  $\mathbf{y}_1, \mathbf{y}_2, \dots$ ,首先通过将每个像素  $\mathbf{y}_i$  视为节点来构建最近邻图  $\mathbf{G}$ 。设  $\mathbf{W}$  为图  $\mathbf{G}$  的权矩




图 1 HYDICE 数据集中所有像素的散点图

Fig. 1 Scatter plot of all the pixels in HYDICE data set

阵,如果  $y_i$  在  $y_j$  的  $k$  近邻中,  $y_j$  在  $y_i$  的  $k$  近邻中,则

$$W_{ij} = \exp\left(-\frac{\|y_i - y_j\|_2^2}{\sigma}\right), \quad (3)$$

式中:权矩阵  $W$  通过 heat kernel<sup>[12]</sup> 计算;  $\sigma$  是标量参数。上述问题可转化为求解目标函数的最小化问题<sup>[12]</sup>:

$$\frac{1}{2} \sum_{i,j=1}^N \|s_i - s_j\|_2^2 W_{ij} = \text{Tr}(SLS^T), \quad (4)$$

式中:图拉普拉斯矩阵  $L = D_1 - W$ ,  $D_1$  为对角矩阵。

### 3 基于图正则化低秩协同表示的高光谱异常检测算法

#### 3.1 目标函数

将式(4)中的图正则化项结合到式(2)的目标函数中,则 GLRCRD 模型的目标函数为

$$\min_{S,E} \|S\|_* + \lambda \|S\|_2 + \beta \text{Tr}(SLS^T) + \gamma \|E\|_{2,1}, \quad (5)$$

s.t.  $Y = DS + E,$

式中:  $\lambda, \beta, \gamma$  是该模型的正则化系数,分别表示系数矩阵的稀疏性约束项、图正则项、稀疏噪声约束项与低秩性分量之间的平衡。式(5)将 LRCRD 模型和图正则化集成到一起,同时考虑了高光谱图像中的高光谱相关性和内在几何流形结构。因此, GLRCRD 模型可以更准确地表示背景和异常。

#### 3.2 算法优化

LRCRD 模型的数值优化算法主要包括加速近

似梯度(APG)法和交替方向法(ADM)。ADM 来源于增广拉格朗日乘法,将目标函数分解为多个子函数,通过固定其他变量来求解子函数。Lin 等<sup>[16]</sup>提出了具有自适应惩罚的线性化交替方向方法(LADMAP),它对优化问题进行一阶泰勒展开,并增加一个邻近项来逼近解。

为了使模型可分离,引入辅助变量  $J$ ,模型转化为

$$\min_{S,J,E} \|S\|_* + \lambda \|J\|_2 + \beta \text{Tr}(SLS^T) + \gamma \|E\|_{2,1}$$

$$\text{s.t. } Y = DS + E, S = J. \quad (6)$$

式(6)的增广拉格朗日函数为

$$f(S, J, E, Y_1, Y_2, \mu) = \|S\|_* + \lambda \|J\|_2 + \beta \text{Tr}(SLS^T) + \gamma \|E\|_{2,1} + \langle Y_1, Y - DS - E \rangle + \langle Y_2, S - J \rangle + \frac{\mu}{2} (\|Y - DS - E\|_F^2 + \|S - J\|_F^2), \quad (7)$$

式中:  $\langle \cdot, \cdot \rangle$  表示矩阵的内积;惩罚系数  $\mu > 0$ ;  $Y_1$  和  $Y_2$  是拉格朗日乘子;  $\|\cdot\|_F$  表示矩阵的  $F$  范数。本文采用 LADMAP 来求解此模型,通过固定其他变量,依次优化一个变量,直到整个优化过程收敛。

1) 固定其他变量,更新  $S_{k+1}$

$$\min_S \|S\|_* + \langle \nabla_{S_k}, S - S_k \rangle + \frac{\eta_1 \mu_k}{2} \|S - S_k\|^2,$$

其中,  $\nabla_{S_k} = \beta(S_k S^T + S_k L) + \mu_k(S_k - J_k + \frac{Y_2^k}{\mu_k}) + \mu_k D^T(DS_k - Y + E_k - \frac{Y_1^k}{\mu_k})$ ,因此

$$S_{k+1} = \Theta_{(\eta_1 \mu_k)^{-1}}(S_k - \nabla_{S_k} / \eta), \quad (8)$$

式中:  $\eta = \|D\|_2^2$ ;  $\Theta(\cdot)$  表示奇异值阈值算子(SVT)<sup>[17]</sup>。

2) 固定其他变量,更新  $J_{k+1}$

$$J_{k+1} = (\mu_k S_{k+1} + Y_{2,k}) / (\mu_k + 2\lambda). \quad (9)$$

3) 固定其他变量,更新  $E_{k+1}$

$$E_{k+1} = \Omega_{\lambda(\mu_k)^{-1}}(Y - DS_{k+1} + Y_{1,k} / \mu_k), \quad (10)$$

式中:  $\Omega(\cdot)$  表示  $l_{2,1}$  最小化算子<sup>[10]</sup>。

4) 更新拉格朗日乘子  $Y_1$  和  $Y_2$

$$\begin{cases} Y_{1,k+1} = Y_{1,k} + \mu_k (Y - DS_{k+1} - E_{k+1}) \\ Y_{2,k+1} = Y_{2,k} + \mu_k (S_{k+1} - J_{k+1}) \end{cases}. \quad (11)$$

5) 更新惩罚系数  $\mu_{k+1}$

$$\begin{cases} \mu_{k+1} = \min(\mu_{\max}, \rho_k \mu_k) \\ \rho_k = \begin{cases} \rho_0, & \mu_k \cdot \max\left\{\eta \|S_k - S_{k-1}\|_F, \|J_k - J_{k-1}\|_F, \|E_k - E_{k-1}\|_F\right\} \leq \epsilon_2 \\ 1, & \text{otherwise} \end{cases} \end{cases} \quad (12)$$

基于图正则化低秩协同表示的高光谱异常检测算法流程如图 2 所。

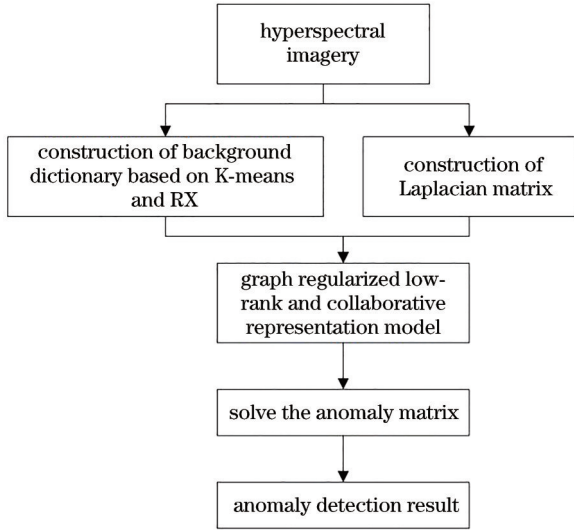


图 2 基于图正则化低秩协同表示的高光谱异常检测算法流程图

Fig. 2 Flow chart of hyperspectral anomaly detection based on graph regularized low-rank and collaborative representation

### 3.3 背景字典构建

在所提算法中,字典  $D$  起着非常重要的作用,在高光谱异常检测中,背景字典  $D$  通常是未知的。为了更好地区分异常与背景,字典原子应该覆盖所有的背景材料,且不受异常像素的污染。许多异常检测研究选择原始数据矩阵本身或者从影像中随机选择一些像素来构成字典,但是前者会增加计算的复杂性,后者不能保证构造的字典覆盖所有的背景类别,因此可能会降低检测精度。

采用文献 [18] 中提出的字典构建方法。该方法主要包括三个步骤:首先,使用 K-means 将所有像素分成  $K$  类  $Y = \{Y^1, Y^2, \dots, Y^K\}$ ;将 RX 算法应用于每个聚类,计算每个聚类中测试像素和局部背景均值之间的马氏距离;在每个聚类中马氏距离最小的  $P$  个像素可以被视为背景像素,被用来构成背景字典  $D$ ,在文献 [18] 中  $P=20$ 。

在本实验中,聚类  $K$  的大小对检测性能有一定的影响,Hysime 算法 [19] 可用于估计背景类别的实际数量,该算法对三个数据集的估计结果如图 3 所示。




图 3 三种数据集中端元数分析。(a) 合成数据; (b) HYDICE 数据集; (c) Gulfport 数据集

Fig. 3 Analysis of endmember number on three datasets. (a) Simulated dataset; (b) HYDICE dataset; (c) Gulfport dataset

## 4 实验验证

在实验中,使用合成的高光谱数据集以及两幅真实的高光谱数据集对算法进行验证。将所提 GLRCRD 算法与 RX、CRD、低秩稀疏表示 (LRASR)、低秩稀疏矩阵分解 (LSMAD)、LRCRD 算法进行比较。

### 4.1 高光谱实验数据

#### 4.1.1 高光谱合成数据

第一个数据集是合成的高光谱数据集,是基于真实场景生成的,其基础影像 AVIRIS 传感器获取的 Salinas 影像。研究区域影像大小为  $120 \times 120 \times 204$ ,

如图 4(a) 所示,主要地物有蔬菜、葡萄以及休耕地。利用 RX 算法对影像进行检测,选择与研究区背景像素差别大的像素作为合成数据的异常目标。

采用目标埋入方法 [20] 将异常目标埋入到 Salinas 影像中,合成数据和目标点分布位置如图 4(b)、图 4(c) 所示。在实验中,随机选择 25 个像素点作为异常目标分布点,合成异常像元:

$$z = f \times t + (1 - f) \times b, \quad (13)$$

式中:  $t$  为异常目标光谱;  $b$  为背景光谱;  $f$  为特定的丰度因子(从 0.04 到 1,步长为 0.25)。

#### 4.1.2 真实高光谱数据

第一个真实高光谱影像数据是由 HYDICE 传感






图 4 高光谱合成数据集。(a) 研究区域原始影像;(b) 模拟数据集的假彩色图像;(c) 异常目标点分布

Fig. 4 Hyperspectral synthetic dataset. (a) Original image of the study area; (b) false-color image of simulated dataset; (c) ground-truth map

器收集的,主要包括植被区、建筑区、道路以及一些车辆,空间分辨率为 1 m。整幅数据大小为  $307 \times 307 \times 210$ ,如图 5(a)所示。选取影像右上角的  $80 \times 100 \times$

175 区域作为研究区域,如图 5(b)所示。将研究区中不同大小的车辆和屋顶作为异常检测目标,总共 21 个像素,异常目标的地面真实分布如图 5(c)所示。




图 5 HYDICE 数据集。(a) 全图场景;(b) 所选区域的假彩色图像;(c) 异常目标真实分布

Fig. 5 HYDICE dataset. (a) Whole image scene; (b) false-color image of the selected region; (c) ground-truth map

第二个真实高光谱影像实验数据为 Gulfport 的一个场景,由 AVIRIS 传感器获得,共 191 个波段,空间分辨率为 3.4 m,图像大小为  $100 \times 100 \times 191$ ,异常目标为图中的三架飞机。Gulfport 数据的假彩色影像和异常目标真实分布如图 6 所示。

GLRCRD 模型中还有另外三个参数,即权衡参数  $\beta$ 、最近邻数  $k_n$  和标量参数  $\sigma$ 。在固定  $(\lambda, \gamma)$  的同时,进行实验找到  $(\beta, k_n, \sigma)$  的最佳数值。因此,GLRCRD 的经验参数设置为  $\lambda = 0.05, \gamma = 1, \beta = 0.02, k_n = 5, \sigma = 1$ 。




图 6 Gulfport 数据集。(a) 假彩色影像;(b) 异常目标真实分布

Fig. 6 Gulfport dataset. (a) False-color image; (b) ground-truth map

#### 4.2 实验参数设置与评价指标

由于所提模型是在 LRCRD 模型基础上进行改进的,在原有模型上添加了拉普拉斯正则项,因此在该模型中的参数进行选择时,首先要找到 LRCRD 模型的最佳参数  $(\lambda, \gamma)$ 。除这两个参数外,

为了研究 GLRCRD 中的参数对检测精度的影响,改变一个参数,同时固定其他参数。图 7 给出了检测精度相对于每个参数如何变化的折线图。为了对实验结果进行科学、定量的分析,采用接收机工作特性曲线(ROC)和曲线下面积(AUC)对检测精度进行评估。如果 ROC 曲线较直,AUC 值较小,说明算法的检测精度比较低;如果 ROC 曲线向左上方弯曲较多,AUC 值较大,说明算法的检测精度较高。AUC 值范围为 0~1。

#### 4.3 实验结果分析

不同算法在三种数据集上的检测结果如图 8~10 所示,六种算法在不同高光谱数据集上的 ROC 曲线如图 11 所示,AUC 值如表 1 所示。

对于高光谱合成数据集,聚类数  $K$  设置为  $K = 13$ 。检测结果如图 8 所示,在所有的检测算法中,




图 7 不同参数设置下, GLRCRD 对模拟数据集的检测精度。(a)  $\lambda$  变化; (b)  $\gamma$  变化; (c)  $\beta$  变化; (d)  $k_n$  变化; (e)  $\sigma$  变化  
 Fig. 7 Detection accuracy of GLRCRD on the simulated dataset under different parameters. (a)  $\lambda$  variation; (b)  $\gamma$  variation; (c)  $\beta$  variation; (d)  $k_n$  variation; (e)  $\sigma$  variation




图 8 六种算法在合成数据集上的检测结果。(a) RX; (b) CRD; (c) LRASR; (d) LSMAD; (e) LRCRD; (f) GLRCRD  
 Fig. 8 Detection results obtained by six algorithms on the simulated dataset. (a) RX; (b) CRD; (c) LRASR; (d) LSMAD; (e) LRCRD; (f) GLRCRD

GLRCRD 能提供更明显的异常检测图。图 11(a) 的 ROC 曲线和表 1 和 AUC 值说明, 可以定量分析所有检测器的检测性能, 可以明显看出, 当虚警概率大于  $10^{-2}$  时, 与其他检测算法相比, GLRCRD 的目标检出率更高。表 1 中 GLRCRD 算法的 AUC 值为

0.9709, 在所有检测算法中效果最好。

对于 HYDICE 数据集, 聚类数  $K$  设置为  $K=16$ 。检测结果如图 9 所示, 在所有的检测算法中, GLRCRD 不仅能提供明显的异常检测图, 而且能有效地抑制背景。从图 11(b) 可以看出, 当虚警概率




图 9 六种算法在 HYDICE 数据集上的检测结果。(a) RX; (b) CRD; (c) LRASR; (d) LSMAD; (e) LRCRD; (f) GLRCRD

Fig. 9 Detection results obtained by six algorithms on the HYDICE dataset. (a) RX; (b) CRD; (c) LRASR; (d) LSMAD; (e) LRCRD; (f) GLRCRD




图 10 六种算法在 Gulfport 数据集上的检测结果。(a) RX; (b) CRD; (c) LRASR; (d) LSMAD; (e) LRCRD; (f) GLRCRD

Fig. 10 Detection results obtained by six algorithms on the Gulfport dataset. (a) RX; (b) CRD; (c) LRASR; (d) LSMAD; (e) LRCRD; (f) GLRCRD

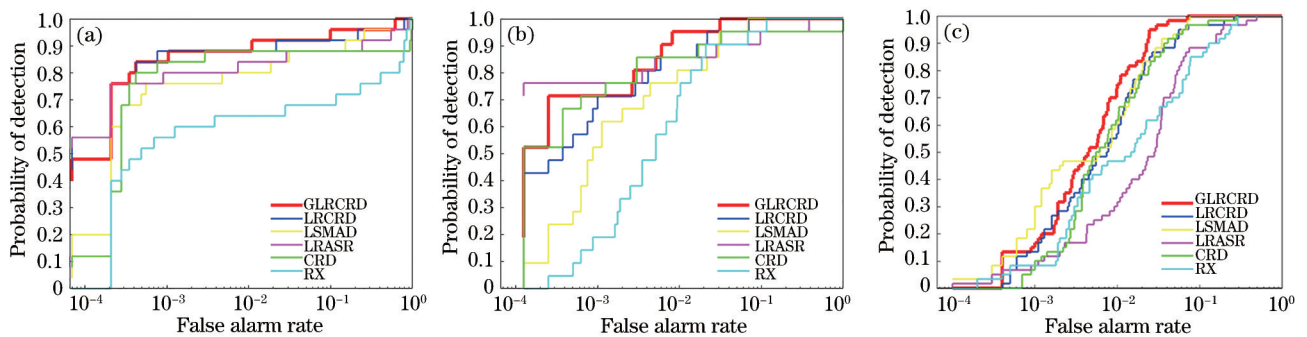


图 11 六种算法的 ROC 曲线。(a) 合成数据集; (b) HYDICE 数据集; (c) Gulfport 数据集

Fig. 11 ROC curves obtained by six algorithms. (a) Simulated dataset; (b) HYDICE dataset; (c) Gulfport dataset



表 1 不同异常检测算法的 AUC 值

Table 1 AUC values obtained by different anomaly detection algorithms

Dataset	RX	CRD	LRASR	LSMAD	LRCRD	GLRCRD
Simulated dataset	0.8074	0.8592	0.9299	0.9505	0.9586	0.9709
HYDICE	0.9857	0.9506	0.9765	0.9905	0.9944	0.9970
Gulfport	0.9526	0.9767	0.9532	0.9861	0.9812	0.9910

大于  $10^{-3}$  时, GLRCRD 的目标检测概率明显高于其他算法。从整体性能来看, 所提 GLRCRD 算法具有最优的检测效果。GLRCRD 算法的 AUC 值为 0.9970, 在所有检测算法中最好。

对于 Gulfport 数据集, 聚类数  $K$  设置为  $K=18$ 。检测结果如图 10 所示, GLRCRD 的检测性能比 LRCRD、LSMAD 和 LRASR 都要好一些, 这表明

引入局部几何流形结构后更有利于算法区分背景和异常目标。图 11(c) 中 GLRCRD 的 ROC 曲线明显优于其他算法, 表 1 中 GLRCRD 的 AUC 值为 0.9910, 获得了最佳的整体检测结果。

从表 2 可以看出, 所提算法比其他算法运行时间长, 但是运行时间在实际性应用中也在可以接受的范围内, 以后的研究将进一步降低计算成本。

表 2 不同异常检测算法的运行时间

Table 2 Computation time of different anomaly detection algorithms

unit: s

Dataset	RX	CRD	LRASR	LSMAD	LRCRD	GLRCRD
Simulated dataset	0.2254	14.053	86.469	21.216	148.109	350.27
HYDICE	0.1592	7.6372	47.618	9.4717	81.724	233.87
Gulfport	0.1758	9.4595	55.811	13.162	97.930	260.89

综上, 所提 GLRCRD 检测算法充分利用高光谱图像的特性, 即高光谱相关性和局部几何结构, 检测精度进一步得到提高。另外, 在字典构造中聚类数  $K$  可以通过 Hysime 算法自动确定, 其他参数都是固定的设置, 参数设置比较简单, 取得了比较好的检测效果。

## 5 结 论

提出了基于 GLRCRD 模型的高光谱异常检测方法。为了充分利用高光谱遥感图像的特性, 综合考虑了三个方面: 通过 LRCRD 模型对表示系数进行全局低秩和局部协同约束; 在 LRCRD 模型中字典的系数矩阵受低秩和  $l_2$  范数最小化的约束,  $l_2$  范数的优点在于不需要过度完备的字典; 为了保持高光谱数据中的局部几何流形结构, 引入图拉普拉斯正则项。

通过考虑这三点, GLRCRD 算法可以更好地区分背景和异常。实验结果表明, 与其他方法相比, GLRCRD 算法具有较低的虚警率, 能够提供更精细的异常检测图。所提算法对小目标和背景比较简单的场景的检测精度更高一些, 在以后的研究中将进一步研究计算成本低且具有普适性的高光谱异常检测算法。

## 参 考 文 献

- [1] 耿修瑞. 高光谱遥感图像目标探测与分类技术研究[D]. 北京: 中国科学院遥感应用研究所, 2005.  
Geng X R. Target detection and classification for hyperspectral imagery[D]. Beijing: Institute of Remote Sensing Applications, Chinese Academy of Sciences, 2005.
- [2] Wang Y L, Wang L, Yu C Y, et al. Constrained-target band selection for multiple-target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(8): 6079-6103.
- [3] 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.
- [4] Taitano Y P, Geier B A, Bauer K W. A locally adaptable iterative RX detector[J]. EURASIP Journal on Advances in Signal Processing, 2010, 2010: 341908.
- [5] Chen Y, Nasrabadi N M, Tran T D. Hyperspectral image classification using dictionary-based sparse representation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(10): 3973-3985.
- [6] Wu X, Zhang X, Wang N, et al. Joint sparse and low-rank multi-task learning with extended multi-



- attribute profile for hyperspectral target detection[J]. *Remote Sensing*, 2019, 11(2): 150.
- [7] 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.
- [8] Zhang L L, Cheng B Z. Sparse representation and modified tensor projection for hyperspectral anomaly detection[J]. *Infrared Physics & Technology*, 2020, 106: 103256.
- [9] Li W, Du Q. Collaborative representation for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(3): 1463-1474.
- [10] Liu G C, Lin Z C, Yan S C, et al. Robust recovery of subspace structures by low-rank representation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(1): 171-184.
- [11] Wu Z Y, Su H J, Du Q. Low-rank and collaborative representation for hyperspectral anomaly detection [C]//IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium, July 28-August 2, 2019, Yokohama, Japan. New York: IEEE Press, 2019: 1394-1397.
- [12] Belkin M, Niyogi P. Laplacian eigenmaps and spectral techniques for embedding and clustering[C]//Advances in Neural Information Processing Systems: Natural and Synthetic, December 3-8, 2001, Vancouver, British Columbia, Canada. Cambridge: The MIT Press, 2002.
- [13] Yin M, Gao J B, Lin Z C. Laplacian regularized low-rank representation and its applications[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(3): 504-517.
- [14] Cheng T K, Wang B. Graph and total variation regularized low-rank representation for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(1): 391-406.
- [15] Xu S, Shen W W. Hyper-Laplacian regularized low-rank collaborative representation classification[C]//2020 12th International Conference on Advanced Computational Intelligence (ICACI), August 14-16, 2020, Dali, China. New York: IEEE Press, 2020: 512-516.
- [16] Lin Z C, Liu R S, Su Z X. Linearized alternating direction method with adaptive penalty for low-rank representation[C]//25th Annual Conference on Neural Information Processing Systems 2011, December 12-14, 2011, Granada, Spain. New York: Curran Associates, 2011: 612-620.
- [17] Cai J F, Candès E J, Shen Z W. A singular value thresholding algorithm for matrix completion[J]. *SIAM Journal on Optimization*, 2010, 20(4): 1956-1982.
- [18] 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.
- [19] Bioucas-Dias J M, Nascimento J M P. Hyperspectral subspace identification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(8): 2435-2445.
- [20] 马东雷. 基于多特征信息的低秩表示高光谱影像异常探测[D]. 徐州: 中国矿业大学, 2017.
- Ma D L. Hyperspectral anomaly detection based on multiple feature low-rank representation[D]. Xuzhou: China University of Mining and Technology, 2017.