

# 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

张晓慧, 郝润芳, 李廷鱼\*

太原理工大学信息与计算机学院, 山西 太原 030600

**摘要** 异常目标检测在高光谱图像(HSI)处理领域发挥越来越重要的作用。低秩稀疏矩阵分解算法(LRaSMD)可将背景和异常区分开,可以极大地减弱异常目标对背景的污染。基于此,提出一种基于低秩稀疏矩阵分解和稀疏字典表达(LRaSMD-SR)的高光谱异常目标检测算法,通过LRaSMD的方式获取背景集,通过稀疏表达的方式从背景集中构建背景字典模型,最后通过计算重构误差来检测异常点。该算法在模拟和真实数据上都进行了有效性验证,实验结果证明LRaSMD-SR算法具有非常好的异常目标检测性能。

**关键词** 遥感; 异常检测; 高光谱图像; 低秩稀疏矩阵分解; 稀疏字典表达

中图分类号 TP751

文献标识码 A

doi: 10.3788/LOP56.042801

## Hyperspectral Abnormal Target Detection Based on Low Rank and Sparse Matrix Decomposition-Sparse Representation

Zhang Xiaohui, Hao Runfang, Li Tingyu\*

College of Information and Computer Science, Taiyuan University of Technology, Taiyuan, Shanxi 030600, China

**Abstract** Anomaly detection plays a more and more important role in the hyperspectral image (HSI) processing field. Since the low-rank and sparse matrix decomposition (LRaSMD) algorithm can separate the anomalies from the background, it can protect the background model from corruption by anomalies and noises. A novel hyperspectral anomaly detection algorithm is proposed based on low-rank and sparse matrix decomposition-sparse representation (LRaSMD-SR). First, the relatively pure background is obtained by LRaSMD. Then, the background dictionary model is constructed from the pure background by means of sparse representation. Finally, the reconstruction error is employed to detect the anomalies. The effective experimental tests are conducted using both simulated and real datasets, and the experimental results show that the proposed LRaSMD-SR algorithm possesses a very promising performance of anomaly detection.

**Key words** remote sensing; anomaly detection; hyperspectral image; low-rank and sparse matrix decomposition; sparse representation

**OCIS codes** 280.4788; 110.4234; 040.1880; 100.4999

## 1 引言

高光谱遥感技术已经普遍用于地表材料识别和地球观测,与传统的全色和多光谱遥感图像相比,高光谱图像(HSI)可以为地表物质提供连续的光谱曲线<sup>[1-3]</sup>。高光谱异常通常指观测的目标或图像与同质背景具有明显不同的光谱特征。一般来说,异常目标在整幅图像中出现的概率比较低,而且和周围

像素的光谱差异较大。近年来,高光谱异常检测蓬勃发展,已成功应用于矿产勘察、边界监测、搜救等领域<sup>[4]</sup>。

近几十年,大量的异常检测算法被提出。Reed等<sup>[5]</sup>提出的RX算法是高光谱异常目标检测领域的一个基石工作,它假设背景模型服从多元正态分布,并通过计算待检测像素和周围的背景像素之间的马氏距离来判断该像素是否异常。根据估计的统计信

收稿日期: 2018-06-29; 修回日期: 2018-08-14; 录用日期: 2018-09-04

\* E-mail: alffzxh@163.com

息是全局还是局部, RX 算法可以分为: 全局 RX (Global RX, GRX) 和局部 RX (Local RX, LRX)。RX 系列的算法存在以下两个缺点: 1) 大多数实际获取的数据并不满足多元正态分布统计假设; 2) 背景一般会受到异常目标的污染。

为了解决不能准确估计背景统计信息的问题, 基于表达类的算法被提出, 可以分为两大类: 基于稀疏表达<sup>[6]</sup>和基于协同表达<sup>[7]</sup>。基于稀疏表达和基于协同表达的算法都没有对数据的统计分布进行假设。基于稀疏表达的算法首先是学习背景字典, 然后通过背景字典表达待检测像素, 如果重构误差很大则证明待检测像素是异常的, 否则为背景像素。基于协同表达的算法和基于稀疏表达的算法相比, 它只是用待检测像素周围的像素来表达待检测像素。如果背景中存在噪声, 或者被异常目标所污染, 这类算法就存在很高的虚警率。

为了解决上述问题, 文献[8-10]中采用低秩稀疏矩阵分解算法 (LRaSMD) 将矩阵分解为低秩矩阵、稀疏矩阵和噪声矩阵。其中低秩矩阵对应背景矩阵, 稀疏矩阵可以用来检测异常目标, 而且高光谱数据的低秩属性可以通过低秩稀疏矩阵分解算法更好地挖掘。通过低秩稀疏矩阵分解算法, 可以得到比较干净的背景, 因为它已经将噪声和异常矩阵都从原始数据中分离出去了, 这就很好地解决了基于稀疏表达算法遇到的问题。利用 LRaSMD 进行高光谱异常检测, 由于检测决策依赖于稀疏分量, 稀疏分量可能包含稀疏参数的较大值处的一些非异常像素, 所以它们可能会使检测性能变差, 并具有更多的误报。

因此, 本文提出了一种基于低秩稀疏矩阵分解和稀疏字典表达 (LRaSMD-SR) 的高光谱异常目标检测算法。LRaSMD-SR 算法, 通过 LRaSMD 算法获取比较干净的背景, 通过稀疏表达的方式从背景中构建背景字典模型, 最后通过计算重构误差来检测异常目标。

## 2 低秩稀疏矩阵分解

LRaSMD 技术可将一个矩阵分解为低秩矩阵、稀疏矩阵和噪声矩阵。由于 HSI 中的异常目标是低概率出现的, 故可认为这些异常目标是稀疏的。因此, Sun 等<sup>[8]</sup>采用 LRaSMD 分解出来的稀疏矩阵进行异常目标检测, 并取得了非常不错的效果。对 HSI 数据而言, 相邻像素具有相似的光谱特性, 其光谱特征的相关度很高, 即可认为 HSI 的背景部分具有低秩特性<sup>[11]</sup>。因此, 通过 LRaSMD 分解还可得

到低秩矩阵, 可认为其对应背景矩阵。通过获取的背景矩阵, 可对背景模型进行精确地估计, 从而有效解决了噪声和异常对背景模型的污染问题。

高光谱图像  $\mathbf{X} \in \mathbf{R}^{M \times P}$  可通过 LRaSMD 分解为低秩的背景矩阵  $\mathbf{B} \in \mathbf{R}^{M \times P}$ 、稀疏的异常矩阵  $\mathbf{S} \in \mathbf{R}^{M \times P}$  和具有独立分布的高斯噪声矩阵  $\mathbf{N} \in \mathbf{R}^{M \times P}$ , 其中  $M$  代表整幅 HSI 中的总像素数,  $P$  代表 HSI 中的波段数。因此 LRaSMD 在 HSI 领域的分解公式为

$$\mathbf{X} = \mathbf{B} + \mathbf{S} + \mathbf{N}. \quad (1)$$

虽然近几年有很多 LRaSMD 优化算法被提出来, 但是绝大多数的方法依然采用 GoDec 算法来求解低秩背景分量和稀疏分量。GoDec 是一种快速近似算法, 它通过约束背景矩阵  $\mathbf{B}$  的秩和稀疏矩阵  $\mathbf{S}$  的稀疏度来控制重建模型的复杂度。GoDec 算法通过最小化公式(2)中的分解误差来求解背景矩阵  $\mathbf{B}$  和稀疏矩阵  $\mathbf{S}$ :

$$\min_{\mathbf{B}, \mathbf{S}} \|\mathbf{X} - \mathbf{B} - \mathbf{S}\|_{\text{F}}^2, \text{ s.t. } \text{rank}(\mathbf{B}) \leq r, \quad (2)$$

$$\text{card}(\mathbf{S}) \leq kM.$$

式中:  $\|\cdot\|_{\text{F}}$  代表范数;  $\text{rank}$  表示矩阵秩,  $\text{card}$  表示矩阵分量个数;  $r$  表示背景矩阵  $\mathbf{B}$  秩的最大值;  $k$  表示稀疏矩阵  $\mathbf{S}$  的稀疏度, 反映了图像中的稀疏分量, 通常将其定义为  $\mathbf{S}$  的  $l_0$  范数。背景可近似地表示为几个基向量的线性组合, 基向量的数量等于背景分量矩阵的秩。一般来说, 随着迭代次数的增加, 分解误差会单调减少。因此, (2) 式中的优化问题可以转换为交替求解以下两个参数的子问题:

$$\mathbf{B}_t = \underset{\text{rank}(\mathbf{B}) \leq r}{\text{argmin}} \|\mathbf{X} - \mathbf{B} - \mathbf{S}_{t-1}\|_{\text{F}}^2, \quad (3)$$

$$\mathbf{S}_t = \underset{\text{card}(\mathbf{S}) \leq kM}{\text{argmin}} \|\mathbf{X} - \mathbf{B}_{t-1} - \mathbf{S}\|_{\text{F}}^2, \quad (4)$$

式中  $t$  为矩阵维数。利用基于双边随机投影算法 (BRP) 低秩近似理论<sup>[12]</sup>来求解(3)式, 假设

$$\mathbf{Y}_1 = \mathbf{X}\mathbf{A}_1\mathbf{Y}_2 = \mathbf{X}^T\mathbf{A}_2, \quad (5)$$

式中:  $\mathbf{A}_1 \in \mathbf{R}^{B \times r}$  和  $\mathbf{A}_2 \in \mathbf{R}^{M \times r}$  都是随机矩阵。  $\mathbf{A}_1$  可以通过 MATLAB 中 `randn` 函数获得, `randn` 函数可以产生服从标准正态分布的随机矩阵;  $\mathbf{A}_2$  可以通过  $\mathbf{A}_2 = \mathbf{Y}_1 = \mathbf{X}\mathbf{A}_1$  求得。基于 BRP 算法可以得到:

$$\mathbf{B} = \mathbf{Y}_1(\mathbf{A}_2^T\mathbf{Y}_1)^{-1}\mathbf{Y}_2^T. \quad (6)$$

(4) 式中  $\mathbf{S}_t$  取决于  $\mathbf{X} - \mathbf{B}_{t-1}$  的硬阈值, 即

$$\mathbf{S}_t = \mathbf{P}_{\Omega}(\mathbf{X} - \mathbf{B}_{t-1}), \quad (7)$$

$$\Omega: |(\mathbf{X} - \mathbf{B}_{t-1})_{i,j} \in \Omega| \neq 0,$$

式中:  $\mathbf{P}_{\Omega}(\cdot)$  是矩阵在输入集  $\Omega$  上的投影,  $\Omega$  是  $|\mathbf{X} - \mathbf{B}_{t-1}|$  的前  $kM$  个最大项的非零子集。

GoDec 算法步骤如下:

- 1) 输入数据矩阵  $\mathbf{X} \in \mathbf{R}^{M \times B}$ , 容错系数  $\epsilon$ , 最大迭代次数  $M_{\text{iter}}$ ;
- 2) 初始化  $\mathbf{B}_0 = \mathbf{X}, \mathbf{S}_0 = \mathbf{0}, t = 0, \mathbf{A}_1 = \text{randn}(\mathbf{B}, r)$ ;
- 3) 重复进行  $M_{\text{iter}}$  次直到  $\|\mathbf{X} - \mathbf{B}_t - \mathbf{S}_t\|_{\frac{2}{r}}^2 / \|\mathbf{X}\|_{\frac{2}{r}}^2 < \epsilon$ 
  - (a)  $t := t + 1$ ;
  - (b)  $\mathbf{Y}_1 = (\mathbf{X} - \mathbf{S}_{t-1})\mathbf{A}_1, \mathbf{A}_2 = \mathbf{Y}_1, \mathbf{Y}_2 = (\mathbf{X} - \mathbf{S}_{t-1})^T \mathbf{A}_2$ ;
  - (c) 如果  $r(\mathbf{A}_2^T \mathbf{Y}_1) < r$  则  $r := r(\mathbf{A}_2^T \mathbf{Y}_1)$ , 重复(b)步骤;
  - (d)  $\mathbf{B}_t = \mathbf{Y}_1 (\mathbf{A}_2^T \mathbf{Y}_1)^{-1} \mathbf{Y}_2^T$ ;
  - (e)  $\mathbf{S}_t = \mathbf{P}_\Omega(\mathbf{X} - \mathbf{B}_{t-1})$ .

### 3 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

在高光谱异常目标检测任务中, 由于异常情况的多样性, 学习异常目标的字典存在很大挑战, 并且难以实现, 因此采用背景字典进行目标重构。稀疏字典表达模型认为一个待检测样本可以近似用背景训练样本和目标训练样本来线性表达<sup>[13]</sup>。将由背景训练样本和目标训练样本组成的矩阵作为字典  $\mathbf{D}$ 。对于待检测样本可根据目标和背景类别的训练样本来对其进行如下建模:

$$\mathbf{X} \approx \mathbf{D}\boldsymbol{\alpha}, \quad (8)$$

式中:  $\mathbf{X} = [x_1 \ x_2 \ \dots \ x_P]^T$  为具有  $P$  个光谱带的测试像素;  $\mathbf{D}$  为由背景和目标的训练样本组成的字典;  $\boldsymbol{\alpha}$  为稀疏分量, 其对应于  $\mathbf{D}$  中各样本的权重。稀疏分量  $\boldsymbol{\alpha}$  可表示为

$$\boldsymbol{\alpha} = \arg \min \|\mathbf{X} - \mathbf{D}\boldsymbol{\alpha}\|_2 + \lambda \|\boldsymbol{\alpha}\|_1, \quad (9)$$

其中  $\lambda$  为重构误差项和正则项之间的平衡参数。在高光谱异常检测的问题中, 由于目标字典很难获得, 因此, (9) 式中的字典, 只采用背景部分, 而此部分可以通过 LRaSMD 算法获得。如果一个待检测像素不能用背景字典表达, 这个像素就是异常目标; 如果可以用背景字典表达, 那就是背景。因此, 可以通过求解重构误差的算法来进行异常目标检测。重构误差计算公式可表示为

$$r(\mathbf{X}) = \|\mathbf{X} - \mathbf{D}\boldsymbol{\alpha}\|_2. \quad (10)$$

通过 LRaSMD 去掉大部分噪声和异常, 可以获得相对比较干净的背景。基于已经获得的干净背景, 进行背景字典学习, 具体的背景字典学习算法如下。

输入: 数据矩阵  $\mathbf{X}$ , 背景矩阵  $\mathbf{B}$ , 字典基的个数  $N$ , 字典个数  $T$ ;

输出: 学习到的背景字典  $\mathbf{D}_T$ ;

初始化:  $\lambda = 0.005, Q = 200, \mathbf{A}_0 = \mathbf{0}, \mathbf{B}_0 = \mathbf{0}$ , 随机从背景矩阵  $\mathbf{B}$  中选取  $Q$  个样本作为初始背景字典  $\mathbf{A}_0, \mathbf{B}_0$ ;

for  $t = 1 : T$

求解稀疏系数:  $\boldsymbol{\alpha}_t = \arg \min \|\mathbf{x}_t - \mathbf{D}_{t-1}\boldsymbol{\alpha}\|_2 + \lambda \|\boldsymbol{\alpha}\|_1$ ;

更新字典:  $\mathbf{A} := \mathbf{A}_{t-1} + \boldsymbol{\alpha}_t \boldsymbol{\alpha}_t^T, \mathbf{B} := \mathbf{B}_{t-1} + \mathbf{X}\boldsymbol{\alpha}_t^T$ ;

for  $j = 1 : N$

更新第  $j$  列:

$$\boldsymbol{\mu}_j := \frac{1}{\mathbf{A}_{jj}}(\mathbf{b}_j - \mathbf{D}\boldsymbol{\alpha}_j) + \mathbf{d}_j$$

$$\mathbf{d}_j := \frac{1}{\max(\|\boldsymbol{\mu}_j\|_2, 1)}\boldsymbol{\mu}_j$$

end

$$\mathbf{D}_t \triangleq \arg \min \frac{1}{t} \sum_{i=1}^t \frac{1}{2} \|\mathbf{x}_i - \mathbf{D}\boldsymbol{\alpha}_i\|_2 +$$

$\lambda \|\boldsymbol{\alpha}_i\|_1$

end

## 4 实验及分析

从定性和定量两个角度对算法的性能进行评价, 实验使用一组模拟和两组真实的高光谱图像对算法进行验证。

### 4.1 数据描述

第 1 组是模拟数据, 模拟数据集有 105 个光谱带, 大小为  $200 \text{ pixel} \times 200 \text{ pixel}$ 。背景包括 5 种不同的材料, 这些材料选自美国地质调查局植被光谱数据, 分别是风滚草、干长草、草坪草、鼠尾草和黑色的刷叶。模拟场景的假彩色图像的上半部分由干燥的长草和草坪草组成, 而图像的下部则是黑毛叶和鼠尾草的混合而成。在合成过程中, 每种材料的混合比率是随机的。模拟场景上半部分的异常目标是鼠尾草, 下半部分的异常目标是干长草, 并且风滚草作为异常目标散布在整幅图。这 3 种异常目标是纯像元而非混合像元。异常目标的大小分别是  $1 \text{ pixel} \times 1 \text{ pixel}$ ,  $2 \text{ pixel} \times 2 \text{ pixel}$  和  $3 \text{ pixel} \times 3 \text{ pixel}$ 。模拟数据由 12 个稀疏分布在背景中的异常目标组成, 模拟数据如图 1 所示。

第 2 组是真实数据: AVIRIS 数据库。AVIRIS 飞机数据集由美国加州圣地亚哥的机载可见红外成像光谱仪 (AVIRIS) 收集。AVIRIS 高光谱图像是一个大小为  $100 \text{ pixel} \times 100 \text{ pixel}$  的区域, 光谱波段数为 224。光谱波长范围从  $370 \sim 2510 \text{ nm}$ 。考虑




图 1 模拟数据。(a)伪彩色图像;(b)真实图像  
Fig. 1 Simulated data. (a) Pseudo color image;  
(b) ground truth

到吸水区域、低信噪比和坏波段,以下波段(1~6, 33~35, 97, 107~113, 153~166 和 221~224)被去除,只有189个波段信息被保留,图像中的3架飞机




图 2 真实数据。(a) AVIRIS 飞机数据伪彩色图像;(b) AVIRIS 飞机数据真实图像;  
(c) HYDICE 城市数据伪彩色图像;(d) HYDICE 城市数据真实图像

Fig. 2 Real data. (a) Pseudo color image on AVIRIS airplane data; (b) ground truth on AVIRIS airplane data;  
(c) pseudo color image on HYDICE urban data; (d) ground truth on HYDICE urban data

为了验证 LRaSMD-SR 算法的有效性,需要对算法的性能进行定性和定量的验证。接收机工作特性(ROC)曲线可以定性地表征算法的性能,而 AUC(Area Under Curve)为接收机工作特性曲线下所覆盖的面积,使用 AUC 可以定量对检测性能作评价,AUC 的数值越大,表明分类器的工作性能越好。本研究采用 ROC 曲线和 AUC 值从定性和定量的角度对 LRaSMD-SR 算法作有效性评价。为了证明 LRaSMD-SR 算法的性能,选取 4 个算法进行对比实验,分别是:全局 RX(GRX)、局部 RX(LRX)<sup>[5]</sup>、低秩稀疏矩阵分解算法(LRaSMD)和稀

被认为是异常。AVIRIS 飞机数据及其相应的真实图像如图 2 所示。

第 3 组数据也是真实数据,使用的数据是美国德克萨斯州某城郊住宿区的 HYDICE 高光谱图像。原始高光谱图像的尺寸为 307 pixel×307 pixel×210 pixel,光谱波长范围为 400~2500 nm。考虑到吸水区域、低信噪比和坏波段,以下波段(1~4, 76, 87, 101~111, 136~153 和 198~210)被删除,剩余 162 个波段。在本文中只截取右上角 150 pixel×150 pixel 的高光谱图像用于实验,其中汽车和屋顶等目标被视为异常现象。HYDICE 城市数据及其相应的真实图像如图 2 所示。

疏表达算法(SRD)<sup>[14]</sup>。

#### 4.2 模拟数据实验

模拟数据检测结果的可视化参见图 3。从图 3 可以看出,LRaSMD-SR 算法能够检测出所有的异常目标,而且异常目标的强度值都很大。GRX 也可以检测出所有的异常目标,但是很明显它所标记的异常目标的强度值比 LRaSMD-SR 低,这也证明了 LRaSMD-SR 算法的优越性。SRD 算法的性能是比较差的,因为它只检测出一部分的异常目标。LRX 的性能比 SRD 好,但是又比 LRaSMD 和 LRaSMD-SR 算法差。




图 3 模拟数据集上检测结果的可视化图。(a) GRX;(b) LRX;(c) LRaSMD;(d) SRD;(e) LRaSMD-SR

Fig. 3 Visualization of detection results on simulated datasets. (a) GRX; (b) LRX; (c) LRaSMD; (d) SRD; (e) LRaSMD-SR

可视化视图虽然可以直观地看出算法性能的优劣,但是它不能精确地评价算法,因此 ROC 曲线被用来作进一步的对比分析,如图 4 所示。从图 4(a)可以明显看出,GRX 曲线被 LRaSMD-SR 曲线覆

盖,LRX 和 LRaSMD 曲线与 LRaSMD-SR 曲线部分重合,LRaSMD-SR 算法性能比其他所有算法都好,因为其 ROC 曲线在其他算法的 ROC 曲线上。不同算法在模拟数据上的 AUC 值可参考表 1

的第 2 列。GRX 和 LRSMD-SR 算法的 AUC 值都是 1,这个结果和观察所得的可视化图像和 ROC 曲线的结果一致。而且,所有算法在模拟数据上的

AUC 值都比较高,这是因为模拟数据中异常目标和背景的差异性较大。




图 4 ROC 曲线。(a)模拟数据;(b) AVIRIS 飞机真实数据;(c) HYDICE 城市数据

Fig. 4 ROC curves. (a) Simulated data; (b) AVIRIS airplane true data; (c) HYDICE urban data

### 4.3 AVIRIS 飞机真实数据实验

所有算法在真实的 AVIRIS 飞机数据上的可视化如图 5 所示。由图 5 可以看出,GRX 漏检测的异常目标很多。SRD 虽然比 GRX 检测出的异常目标要多,但是还是存在一定的漏检情况。LRX、LRSMD 和 LRSMD-SR 相比于其他 2 个算法都取得了不错的效果,基本都能将异常目标检测出来。但是 LRSMD-SR 算法检测出来的异常目标的形状和真实图像最接近。LRSMD 检测的异常目标强度值比较低,而 LRX 稍微存在一点漏检情况。所有算法在真实的 AVIRIS 飞机数据上的 ROC 曲线如图 4(b)所示。可以明显看出,LRSMD-SR 算法

ROC 曲线在其他算法 ROC 曲线的上面,这可以证明 LRSMD-SR 算法性能比其他算法好。但是 ROC 曲线有交叉部分,所以难以判断其他对比算法的优劣性。因此,为了更加准确地对算法进行评价,计算了所有算法 AUC 值见表 1 的第 3 列。LRSMD-SR 的 AUC 值是 0.9908,这是所有算法中最高的。LRSMD-SR 算法结合利用的 LRSMD 算法产生的背景矩阵作为背景,有效地去除了异常和噪声对背景字典构建的影响。可以从表 1 中看出,LRSMD-SR 算法的 AUC 值比 SRD 提高了不少,SRD 算法的 AUC 值只有 0.9389。




图 5 AVIRIS 数据集上检测结果的可视化图。(a) GRX;(b)LRX;(c) LRSMD;(d) SRD;(e) LRSMD-SR

Fig. 5 Visualization of detection results on AVIRIS dataset. (a) GRX; (b) LRX; (c) LRSMD; (d) SRD; (e) LRSMD-SR

表 1 检测算法 AUC 理论值

Table 1 AUC theoretical value by detection algorithms

Algorithm	Simulated data	AVIRIS airplane	HYDICE urban
GRX	1	0.9357	0.8500
LRX	0.9995	0.9631	0.9071
LRSMD	0.9996	0.9874	0.7277
SRD	0.9141	0.9389	0.9175
LRSMD-SR	1	0.9908	0.9705

### 4.4 HYDICE 城市真实数据实验

所有算法在真实的 HYDICE 城市数据上的可

视化如图 6 所示。由图 6 可以看出 GRX 和 LRSMD 存在漏检情况。SRD 和 LRX 虽然比 GRX 检测出的异常目标要多,但是检测的异常目标强度值比较低。LRSMD 算法检测出来的异常目标的形状和真实图像最接近。所有算法在真实的 HYDICE 数据上的 ROC 曲线如图 4(c)所示,可以明显看出 LRSMD-SR 算法 ROC 曲线在其他算法 ROC 曲线的上面,证明 LRSMD-SR 检测性能比其他算法都好。不同算法在 HYDICE 城市数据上的 AUC 值可参考表 1 的第 4 列,LRSMD-SR 算法 AUC 值为 0.9705,是所有算法中最高的。




图6 HYDICE数据集上检测结果的可视化图。(a) GRX;(b) LRX;(c) LRaSMD;(d) SRD;(e) LRaSMD-SR

Fig. 6 Visualization of detection results on HYDICE dataset. (a) GRX; (b) LRX; (c) LRaSMD; (d) SRD; (e) LRaSMD-SR

#### 4.5 显著性分析

为了分析 LRaSMD-SR 算法检测效果的显著性,对 HYDICE 真实数据进行了 5 组实验,每种算法的 AUC 结果如表 2 所示。SRD 算法由于在构建背景的过程中是随机选择背景像素,有可能将异常像素作为背景像素加入字典中,因此 SRD 算法 5 次实验结果的方差比较大,而 LRaSMD-SR 算法在构建字典时采用的是 LRaSMD 方法获得背景集合,因此 5 次实验结果都比 SRD 方法好,而且方差小。

$F$  分布的临界值为  $F_{0.05}(4, 20) = 2.87$ ,在表 3 中通过对 5 组数据的方差分析计算出  $F = 450 >$

2.87,从而得出 LRaSMD-SR 算法效果是显著的。总体而言,通过分析 ROC 曲线和 AUC 值,LRaSMD-SR 和其他算法相比具有出色的检测性能。

表 2 检测算法的 AUC 实验结果

Table 2 AUC experimental results by detection algorithms

GRX	LRX	LRaSMD	SRD	LRaSMD-SR
0.85	0.9071	0.7184	0.8737	0.9678
0.85	0.9071	0.7132	0.9176	0.9599
0.85	0.9071	0.7159	0.9002	0.9705
0.85	0.9071	0.7277	0.8742	0.9679
0.85	0.9071	0.7009	0.885	0.9651

表 3 显著性分析

Table 3 Significance analysis

Source of variance	Square sum of dispersion	Degree of freedom	Average sum of squares	$F$ value	Significance
Inter-group	0.18	4	0.045	450	*
Intra-group	0.0018	20	0.0001		

## 5 结 论

提出一种基于低秩稀疏矩阵分解和稀疏字典表达(LRaSMD-SR)的高光谱异常目标检测算法,通过 LRaSMD 获得背景样本矩阵,通过稀疏表达的方式将背景分量作为字典,采用重构误差的算法检测异常点。最后对高光谱图像进行实验验证,证明了 LRaSMD-SR 算法可以取得非常好的异常检测结果。

### 参 考 文 献

- [1] Shaw G, Manolakis D. Signal processing for hyperspectral image exploitation [J]. IEEE Signal Processing Magazine, 2002, 19(1): 12-16.
- [2] Fan L H, Lü J W, Deng J S. Classification of hyperspectral remote sensing images based on bands grouping and classification ensembles [J]. Acta Optica Sinica, 2014, 34(9): 0910002.  
樊利恒, 吕俊伟, 邓江生. 基于分类器集成的高光谱遥感图像分类方法 [J]. 光学学报, 2014, 34(9):

0910002.

- [3] Wu Y Q, Zhou Y, Long Y L. Small target detection in hyperspectral remote sensing image based on adaptive parameter SVM [J]. Acta Optica Sinica, 2015, 35(9): 0928001.  
吴一全, 周杨, 龙云淋. 基于自适应参数支持向量机的高光谱遥感图像小目标检测 [J]. 光学学报, 2015, 35(9): 0928001.
- [4] Landgrebe D. Hyperspectral image data analysis [J]. IEEE Signal Processing Magazine, 2002, 19(1): 17-28.
- [5] 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.
- [6] 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.
- [7] Li W, Du Q. Collaborative presentation for hyperspectral anomaly detection [J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(3): 1463-1474.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] Wang Z M, Yang X M, Gu X F. Hyperspectral image denoising based on tensor group sparse representation [J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(5): 614-622.
- 王忠美, 杨晓梅, 顾行发. 张量组稀疏表示的高光谱图像去噪算法[J]. 测绘学报, 2017, 46(5): 614-622.
- [12] 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.
- [13] Wang H G, Li Z Z, Gu Y S, *et al.* Dim target detection method based on multi-scale adaptive sparse dictionary[J]. Infrared and Laser Engineering, 2014, 43(7): 2371-2378.
- 王会改, 李正周, 顾园山, 等. 基于多尺度自适应稀疏字典的小弱目标检测方法[J]. 红外与激光工程, 2014, 43(7): 2371-2378.
- [14] Zhang L L, Zhao C H. A spectral-spatial method based on low-rank and sparse matrix decomposition for hyperspectral anomaly detection[J]. International Journal of Remote Sensing, 2017, 38(14): 4047-4068.