

doi: 10.6046/gtzyyg.2019.01.05

引用格式: 侯增福,刘榕源,闫柏琨,等.基于波段选择与学习字典的高光谱图像异常探测[J].国土资源遥感,2019,31(1),33-41. (Hou Z F, Liu R Y, Yan B K, et al. Hyperspectral imagery anomaly detection based on band selection and learning dictionary [J]. Remote Sensing for Land and Resources, 2019, 31(1), 33-41)

# 基于波段选择与学习字典的高光谱图像异常探测

侯增福<sup>1</sup>, 刘榕源<sup>2</sup>, 闫柏琨<sup>2</sup>, 谭琨<sup>1</sup>

(1. 中国矿业大学国土环境与灾害监测国家测绘地理信息局重点实验室, 徐州 221116; 2. 中国自然资源航空物探遥感中心, 北京 100083)

**摘要:** 针对高光谱影像数据中存在大量冗余,传统异常探测算法应用高光谱所有波段进行探测计算量巨大的问题,提出一种基于波段相似性线性预测与学习字典的异常探测算法。该算法首先通过对波段的相似性进行线性预测,找到最不相似的波段子集;然后,利用学习字典算法获得能够表征图像背景信息的背景字典,并通过低秩分解的算法将影像分解为低秩矩阵与稀疏矩阵;最后,使用经典 RXD(Reed - X detector)探测算法对稀疏影像进行异常探测。实验结果表明,该算法可以在减少计算代价、保持波段原始信息不被破坏的同时,能够较好地实现了高光谱影像的异常探测。

**关键词:** 高光谱; 波段相似性; 线性预测; 学习字典; 异常探测; 低秩分解; 稀疏

**中图法分类号:** TP 79 **文献标志码:** A **文章编号:** 1001-070X(2019)01-0033-09

## 0 引言

高光谱遥感影像不同于全色和多光谱遥感影像,具有光谱分辨率高、图谱合一的特点,在地物目标探测领域具有独特的优势,可广泛应用于环境监测和军事侦察等领域,然而在实际应用中研究者往往很难获得足够的先验知识来表征目标类别的统计信息,因此在没有可用先验信息辅助的情况下完成异常目标的探测,成为了近年来高光谱遥感影像目标探测领域的研究重点<sup>[1]</sup>。

在高光谱影像中,异常像元的光谱往往不同于周围背景像元的光谱信息,这就为异常像元能被探测出来创造了条件。由 Reed 和 Yu 在 1990 年发展起来的 RXD(Reed - X detector)算法<sup>[2]</sup>,通过计算待探测像元与背景的马氏距离来完成异常探测,该算法选取整幅影像作为背景信息,故又称为全局 RX(global RX, GRX),由于使用全图均值和协方差来估计背景均值与协方差矩阵会影响探测精度,故对此改进的使用局部计算代替全局计算的 RX 又称之为局部 RX(local RX, LRX)<sup>[3-5]</sup>。然而在真实高光谱影像中,背景信息复杂,使用估计的协方差与均值向量来表示背景信息并不准确。基于此提出的一些改进算法,如权重

RXD(weighted - RXD, W - RXD)算法<sup>[6]</sup>和基于线性滤波的 RXD(linear filter - based RXD, LF - RXD)算法<sup>[6]</sup>,这 2 种算法均旨在通过提高背景信息的估计来提高影像中异常被探测出的概率。一些基于核理论的探测算法,如较为经典的非线性核心 RX 探测(Kernel RX)算法<sup>[7]</sup>,相比于传统的探测算法<sup>[8]</sup>在异常探测中获得了较好的探测效果。

近年来,基于信号稀疏表示的算法也被应用于高光谱图像目标探测问题上<sup>[9]</sup>。然而这种算法仅仅考虑了影像的光谱信息,并没有顾及空间信息,故将其应用于异常探测中,往往难以取得令人满意的效果<sup>[1]</sup>。一种基于协同表示的异常探测算法<sup>[10]</sup>(collaborative - representation - based detector, CRD)认为每一个背景像元都可以被其空间邻域像元近似表示,而异常像元则不能,并在应用中取得了不错的探测效果。不同于信号稀疏表示的算法,赵锐等<sup>[11]</sup>通过在异常探测器的背景信息构建中引入鲁棒性分析方法,提出了一种在核特征空间中具有鲁棒性的异常探测算法;张乐飞等<sup>[12]</sup>基于张量数据模型和张量代数运算,针对遥感数据多维或高维的特点提出了一种基于张量学习机的遥感影像目标探测算法;彭波等<sup>[13]</sup>基于 Cholesky 分解,将高维矩阵的求

收稿日期: 2017-09-25; 修订日期: 2017-12-06

基金项目: 中国地质调查局地质调查项目“天山—北山重要成矿区带遥感调查”(编号: DD20160068)和徐州市科技基金项目(编号: KC16SS092)共同资助。

第一作者: 侯增福(1991-),男,硕士研究生,主要从事高光谱目标检测和异常探测方面的研究。Email: zephyrou@126.com。

通信作者: 谭琨(1981-),男,教授,主要从事遥感信息处理和高光谱遥感研究。Email: tankuncu@gmail.com。

逆运算转换为求解下三角线性系统,提出了基于 Cholesky 分解的逐像元实时高光谱异常探测算法。

目前,一些关于低秩分解的算法也被应用于高光谱异常探测中,如较为经典的鲁棒性主成分分析 (robust principal component analysis, RPCA) 算法<sup>[14]</sup> 被应用于高光谱图像的异常探测中<sup>[15]</sup>,其中影像部分仅仅为单子空间表示,并没有考虑到高光谱影像中较为复杂的背景地物。针对该情况提出的低秩表示 (low - rank representation, LRR) 模型<sup>[16]</sup>,将低秩矩阵表示为多个子空间的线性组合。然而这种算法在使用时将自身作为字典,对应不同高光谱影像,最优参数往往不同,这是一个非常明显的缺陷。Xu 等<sup>[9]</sup>首次将 LRR 模型引入到高光谱影像的异常探测中,提出了基于低秩和稀疏表示 (low - rank and sparse representation, LRaSR) 的异常探测算法。另一种基于低秩表示与学习字典 (low - rank representation and learned dictionary, LRRaLD) 的算法<sup>[17]</sup>在 LRR 模型的基础之上引入了仅包含背景光谱信息的学习字典,实现了高光谱背景与异常的有效分离,从而提高了算法的鲁棒性。

然而,由于高光谱本身数据的冗余性,使用上述算法进行异常探测时,往往需要较大的计算代价,如何在保留最大有用信息的同时,减少波段数量,从而达到减小计算代价的目的也就成为了研究的热点。基于此产生的数据降维算法可概括为 2 类:特征提取<sup>[18-20]</sup>和波段选择。近些年来,波段选择算法广泛应用于遥感影像的分类研究中,并取得了不错的分类效果,如:基于聚类分析的自组织特征映射神经网络 (self - organizing feature map, SOM)<sup>[21-22]</sup>、流形学习应用于高光谱遥感影像<sup>[23]</sup>和最佳分形波段选择模型<sup>[24]</sup>。目前较为流行的蚁群优化算法也已经被应用于高光谱图像的降维中<sup>[25-28]</sup>。

在考虑到计算的复杂度和时间效率等综合因素后,本文引入了一种基于波段相似尺度的线性预测 (linear prediction and band similarity metric, LPaBS) 算法<sup>[29]</sup>,对原始影像进行预处理,即在原始波段特征空间进行选择,找到波段差异性最大的波段,从而形成原空间的一个子集,在最大程度上保留了波段的原始信息,同时降低了维度;然后对选择的数据子集进行低秩表示与字典学习,并使用传统经典 RXD 算法进行异常探测,旨在减少计算代价的同时提高探测精度,较好地实现高光谱影像的异常探测。

## 1 算法研究

### 1.1 波段选择

高光谱遥感影像所具有的大量光谱波段为更加

精细的地物分类与异常探测提供了极其丰富的信息,随着波段数的增多,其光谱特征组合方式更是以指数形式增长,导致了信息的冗余和数据处理复杂性的提高。分类器和探测器的性能在很大程度上依赖于数据降维的特征提取结果,依赖于这些特征是否能够精确地描述对象的特征<sup>[30]</sup>。本文所引入的 LPaBS 算法,通过在原始波段特征空间进行选择,找到波段差异性最大的波段,从而形成原空间的一个子集。

为了在高光谱影像中选出最具代表性的波段子集,需要某种尺度来衡量波段间的相似程度,常用方法有 JM 距离和空间相关性等,本文基于 LPaBS 算法选出差异性最大的波段  $A_1$  和  $A_2$  作为初始子集  $\emptyset$ ,并通过  $\emptyset$  线性表示出其他波段,再继续通过基于 LPaBS 算法不断更新波段子集  $\emptyset$ ,直到达到所要求的波段数。该方法中有 2 个初始参数,分别为初始波段对  $\emptyset$  和波段数。假设原始影像集共用  $N$  个波段,基于 LPaBS 法则<sup>[29]</sup>为:①寻找初始波段对  $B_1$  和  $B_2$ ,初始子集  $\emptyset = \{B_1, B_2\}$ ;②根据评判标准选出波段  $B_3$ ,并通过  $\emptyset = \emptyset \cup B_3$  升级子集  $\emptyset$ ;③继续步骤②,当子集  $\emptyset$  满足要求时停止。初始波段对的选择算法流程为:①随机选出波段  $A_1$ ,并将其余  $N - 1$  个波段投影到  $A_1$  的正交子空间上,找出最大投影波段记为  $A_2$ ;②将其他的  $N - 1$  个波段投影到  $A_2$  的正交子空间上,找到该投影空间上最大投影波段并记为  $A_3$ ;③若  $A_3 = A_1$ ,则认为  $A_1$  与  $A_2$  是包含最多信息的波段对,停止循环,并将其作为初始波段对  $\emptyset$ ,否则进入步骤④;④对于波段  $A_i$ ,继续步骤②和③,直到  $A_{i-1} = A_{i+1}$ ,则将  $A_{i-1}$  与  $A_i$  作为初始波段对。关于评判波段相似性标准,假设当前波段子集  $\emptyset = \{B_1, B_2\}$ ,通过波段  $B_1$  与  $B_2$  线性预测波段  $B'$ ,即

$$B' = a_0 + a_1 B_1 + a_2 B_2, \quad (1)$$

$$a = (a_0, a_1, a_2)^T = (X^T X)^{-1} X^T y, \quad (2)$$

式中:  $a$  为参数向量,可以最小化线性预测误差;  $X$  为一个  $N \times 3$  维矩阵,第 1 列元素全为 1,第 2 列包含波段  $B_1$  中所有像元,第 3 列包含波段  $B_2$  中所有像元;  $y$  为一个包含波段  $B$  中所有像元的  $N \times 1$  维列向量;波段  $B'$  为对波段  $B$  的线性预测值,通过最小二乘算法求解,即

$$E = \|B - B'\|_2, \quad (3)$$

式中  $E$  为预测波段误差。通过计算所有波段与  $B'$  之间的  $E$ ,并找出最大误差对应的波段  $B_3$ ,  $B_3$  即为所求波段。

## 1.2 低秩与学习字典

高光谱数据存在一个低维线性子空间,通过寻找该空间来实现对高光谱数据的降维处理,如经典的主成分分析(principal component analysis, PCA)算法,然而当高光谱数据中存在较大噪声或异常时,则不能取得理想效果<sup>[31]</sup>。有学者提出了 RPCA<sup>[14]</sup>的算法,基于影像矩阵源于一个子空间的假设,将图像数据分解为低秩部分与稀疏部分<sup>[16]</sup>,即

$$Y = L + S, \quad (4)$$

式中:  $Y, L, S \in \mathbf{R}^{b \times p}$ ,  $p$  为像元个数,  $b$  为波段数;  $L$  表示低秩矩阵;  $S$  表示稀疏矩阵。

不同于 RPCA,假设 LRR 是基于高光谱数据矩阵由多个子空间构成,即

$$Y = DZ + S, \quad (5)$$

式中:  $D \in \mathbf{R}^{b \times m}$  表示字典,  $m$  为字典原子个数;  $Z \in$

$$L = \|J\|_* + \beta \|S\|_{2,1} + \text{tr}[Y_1^T(Y - DZ - S)] + \text{tr}[Y_2^T(Z - J)] + \frac{\mu}{2}(\|Y - DZ - S\|_F^2 + \|Z - J\|_F^2), \quad (9)$$

式中:  $Y_1$  和  $Y_2$  分别为拉格朗日乘子;  $\mu$  为惩罚系数;  $\|\cdot\|_F^2$  表示  $F$  范数的平方。

在解决问题的过程中<sup>[16-17]</sup>,字典起到了很关键的作用,初始字典选取的好坏决定了字典收敛程度与收敛速度,在以往的研究中有些学者提出了使用数据本身作为字典的算法,在这种情况下平衡参数  $\beta$  起到了决定性的作用。若参数过小,探测率不高;若参数过大,虚警率提高,针对这些问题有学者提出使用学习字典算法,这样在很好地解决平衡参数问题的同时提高了探测率,字典学习<sup>[17]</sup>的过程如下:

1) 输入: 数据矩阵  $Y$  和字典原子个数  $m$ 。

2) 初始化:  $m = 200$ ,  $\gamma = 0.01$ ,  $\mu = 10$ ,  $\varepsilon = 10^{-6}$ ,  $D$  为归一化随机正值。

步骤 1: 从高光谱影像中随机选择  $m$  个像元。

步骤 2: 进行稀疏编码,其公式为

$$Z = \underset{Z_i}{\text{argmin}} \|Y_i - DZ_i\|_2 + \gamma \|Z_i\|_1, i=1, 2, \dots, m. \quad (10)$$

$\mathbf{R}^{m \times p}$  为系数矩阵;  $S$  为包含异常值的稀疏矩阵。由于  $\text{rank}(DZ) \leq \text{rank}(Z)$  故公式(5)的求解等价于

$$\min_{Z, E} \text{rank}(Z) + \beta \|S\|_{2,1} \text{ s. t. } Y = DZ + S, \quad (6)$$

式中  $\|\cdot\|_{2,1}$  表示  $l_{2,1}$  范数,为矩阵每列的  $l_2$  范数之和;  $\beta$  为低秩矩阵与稀疏矩阵的权衡因子。为解决上述公式(6)非凸函数问题时,通常使用优化问题求解,即

$$\min_{Z, E} \|Z\|_* + \beta \|S\|_{2,1} \text{ s. t. } Y = DZ + S, \quad (7)$$

式中  $\|\cdot\|_*$  表示核范数,为奇异值之和。为了解决上述凸优化问题引入增广拉格朗日乘法,公式(7)可表示为

$$\min_{Z, E, J} \|J\|_* + \beta \|S\|_{2,1} \text{ s. t. } Y = DZ + S, Z = J, \quad (8)$$

公式(8)的增广拉格朗日函数为<sup>[16-17]</sup>

步骤 3: 升级字典,其公式为

$$D^{(n+1)} = D^{(n)} - \mu \sum_{i=1}^m (D^{(n)} Z_i - Y_i) Z_i^T. \quad (11)$$

步骤 4: 字典  $D$  归一化处理。

步骤 5:  $\mu \rightarrow 0.998\mu$ 。

步骤 6: 检查收敛条件  $\|D^{(n+1)} - D^{(n)}\|_1 < \varepsilon$  是否成立,如果不成立返回步骤 1,否则输出。

3) 输出: 学习字典  $D$ 。

## 1.3 算法流程

提出的异常探测算法流程如图 1 所示,其主要过程为: ①使用线性预测法则对高光谱遥感影像进行波段选择,获得最终的高光谱波段子集; ②将高光谱波段子集转换为二维图像数据; ③利用字典学习过程进行字典学习,获得  $D$ ; ④利用公式(9)将二维数据矩阵分解为  $L$  和  $E$ ; ⑤利用 RXD 算法对  $E$  进行异常探测,获得最终探测结果。

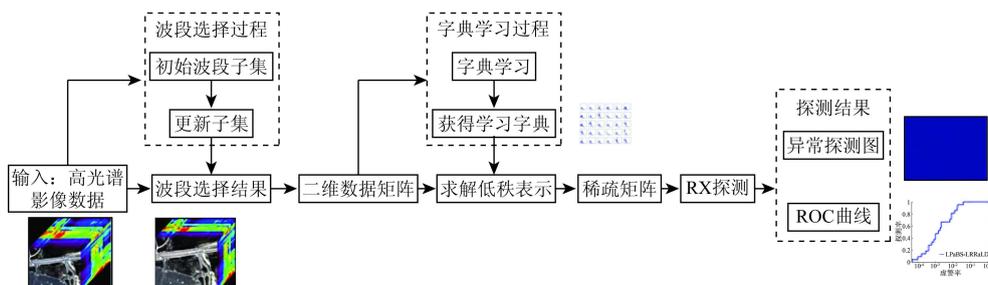


图 1 算法流程

## 2 实验结果

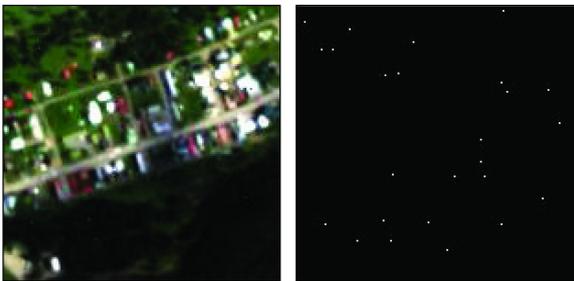
为了对该算法进行验证,使用了4幅高光谱影像进行验证,其中1幅基于HyMap数据的模拟数据和3幅Hyperion, HYDICE, Hypspx 真实高光谱遥感影像数据。

### 2.1 模拟数据

为了更好地验证本文算法效果,首先使用了1幅基于HyMap 机载高光谱成像仪的模拟数据,该影像为2006年6月拍摄于美国马萨诸塞州区域,影像大小为280 像元 × 800 像元,如图2(a)。



(a) B14(R), B8(G), B1(B) 真彩色合成影像



(b) 实验数据区域 (c) 真实异常地物

图2 HyMap 数据集  
Fig.2 HyMap data set

该影像含有126个波段,去除水汽吸收波段后余121个波段,实验中截取影像左侧中间大小150 像元 × 150 像元区域合成模拟数据,如图2(b),选择红色棉布光谱作为异常光谱。基于线性混合模型,使用异常点埋入的方法生成模拟数据,其表达式为

$$z = ft + (1 - f)b \quad (12)$$

式中:  $z$  为合成异常数据;  $f$  为丰度分数;  $t$  为异常光谱;  $b$  为背景光谱。采用埋点的方法随机生成25个异常值,其中丰富分数为从0.05 ~ 1之间以等差数列形式生成25个丰度值。

为了评估本文提出的基于波段相似性尺度线性预测的低秩表示与学习字典(linear prediction and band similarity metric and low - rank representation and learned dictionary, LPaBS - LRRaLD)算法的优越性,分别与GRX,LRX,基于马氏距离的非监督最近邻规则子空间(unsupervised nearest regularized subspace with Mahalanobis distance, UNRS - MD)<sup>[32]</sup>与LRRaLD等算法进行对比分析。

首先通过基于HyMap数据合成的模拟数据来证明提出算法的可行性,模拟数据为121个波段,通过LPaBS算法选出具有代表性的80个波段。各种算法异常探测结果及对应的接收者操作特性曲线(receiver operating characteristic, ROC)如图3所示,表1列出了每种算法的ROC曲线下面积(area under ROC curve, AUC)与运行时间2个定量评价指标。

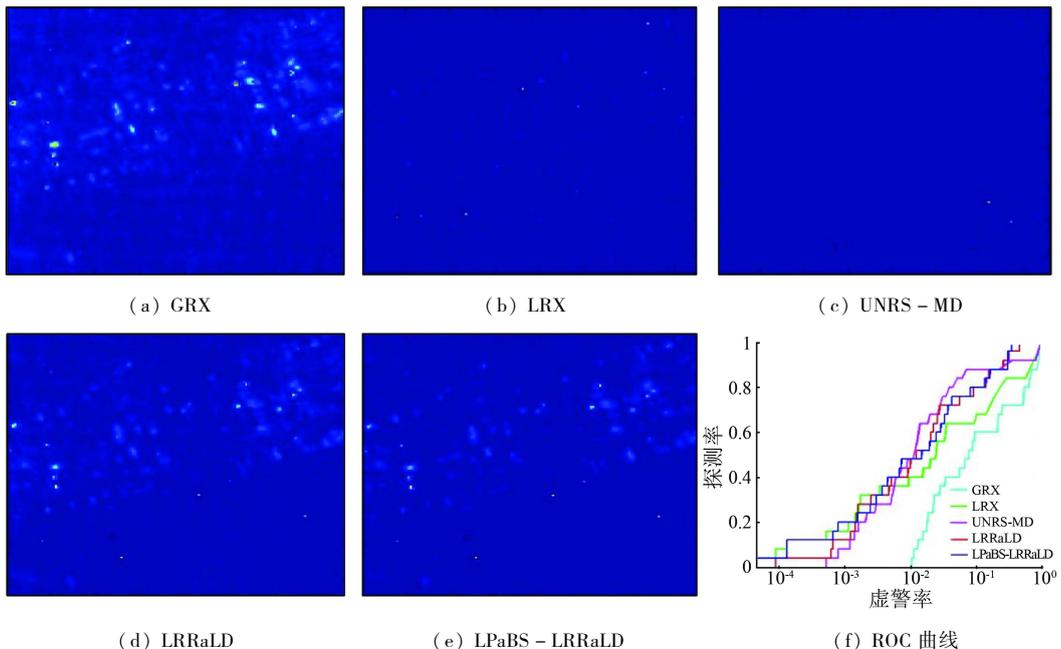


图3 HyMap 模拟数据探测结果及 ROC 曲线

万方数据 Fig.3 Detection results and ROC curves of HyMap simulation data set

**表 1 HyMap 模拟数据 AUC 与耗时性比较**  
**Tab. 1 Comparison of AUC and execution time using HyMap simulation data**

指标	GRX	LRX	UNRS - MD	LRRaLD	LPaBS - LRRaLD
AUC	0.748 35	0.832 27	0.905 54	0.933 74	0.937 00
时间/s	0.538	100.000	165.900	60.300	49.180

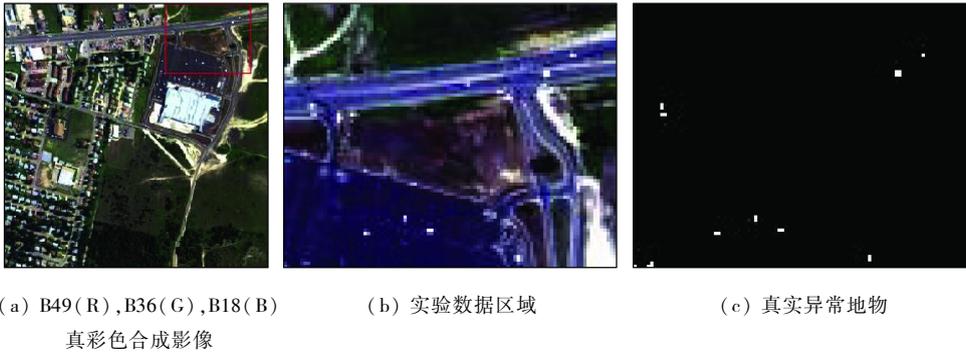
由图 3 与表 1 可以看出,使用 LRRaLD 和 LPaBS - LRRaLD 算法能够获得较好的探测效果,但是 LPaBS - LRRaLD 算法在探测精度与运行时间上都

优于 LRRaLD 算法。

## 2.2 真实数据

### 2.2.1 HYDICE 数据

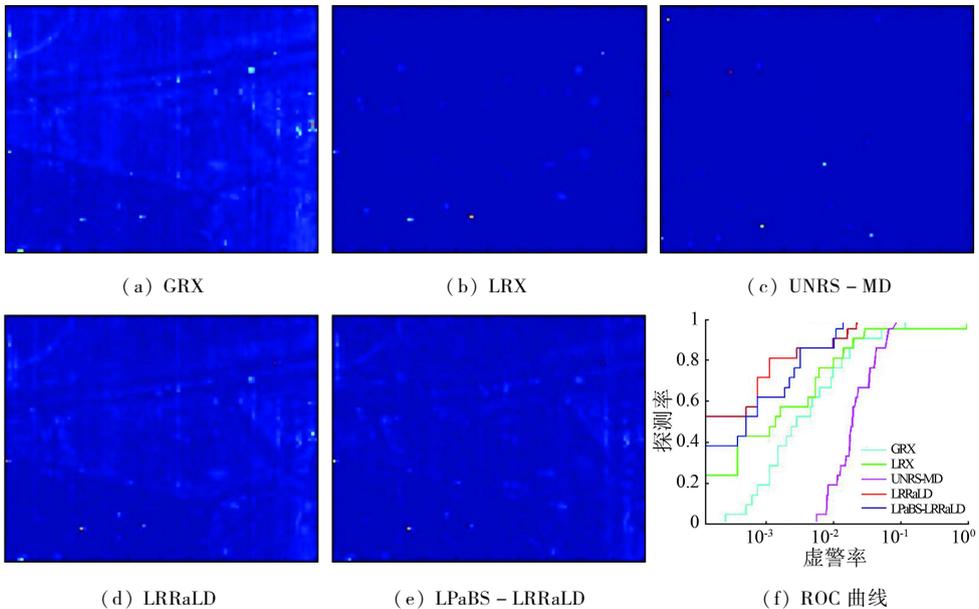
Urban 数据是由 HYDICE 机载高光谱成像仪于城市上空拍摄而得到的空间分辨率近 1 m 的高光谱遥感影像,整幅影像大小为 307 像元 × 307 像元,包含 210 个波段,去除低信噪比与水汽吸收波段后剩余 174 个波段,截取整幅影像右上角 80 像元 × 100 像元的子块与其对应的真实异常地物如图 4 所示。



**图 4 HYDICE 数据集**  
**Fig. 4 HYDICE data set**

为了利用 HYDICE 高光谱成像仪获取的 Urban 数据证明本文提出算法的可行性,首先使用 LPaBS 算法选出具有代表性的 100 个波段,再采用 LR-

RaLD 算法进行异常探测。各种不同算法的异常探测结果及其对应的 ROC 曲线如图 5 所示,表 2 列出了各种算法的 AUC 和运行时间。



**图 5 HYDICE 数据集探测结果及 ROC 曲线**

**Fig. 5 Detection results and ROC curves of HYDICE data set**

**表 2 HYDICE 数据集 AUC 与耗时性比较**  
**Tab. 2 Comparison of AUC and execution time using HYDICE data set**

指标	GRX	LRX	UNRS - MD	LRRaLD	LPaBS - LRRaLD
AUC	0.987 23	0.949 27	0.973 19	0.997 27	0.997 52
时间/s	0.178 1	61.440 0	98.380 0	85.370 0	56.140 0

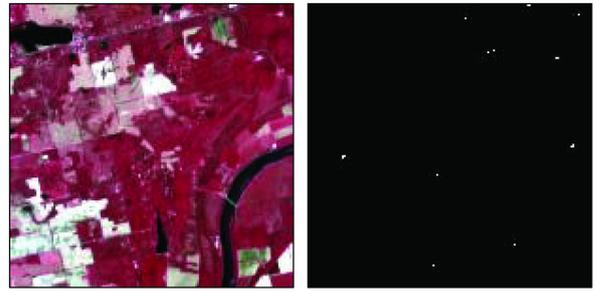
通过图 5 可以看出,在各种算法中,使用 LR-RaLD 和 LPaBS - LRRaLD 算法能够获得较好的探测效果。由表 2 数据可知,GRX 算法运行时间最短,但是探测精度明显低于 LRRaLD 和 LPaBS - LRRaLD 算法,LPaBS - LRRaLD 算法在探测精度与运

行时间上明显优于其他算法。

### 2.2.2 Hyperion 数据

Hyperion 遥感影像数据含有 242 个波段,光谱分辨率为 10 nm,波长范围为 357 ~ 2 576 nm。实验使用的影像数据采集于 2008 年,影像中主要包括美国印第安纳州的农业区。去除低信噪比与未定标波段后余 149 个波段,在实验中使用含有真实异常数据的 150 像元 × 150 像元大小的子区域(如图 6 所示)完成实验,影像中异常值主要为储物仓库和屋顶。同样,为了验证本文算法的有效性,首先基于 LPaBS 算法选出具有代表性的 100 个波段,然后使用学习字典并利用增广拉格朗日公式求解进行异常探测,各种不同算法的探测结果及其对应的 ROC 曲

线如图 7 所示,每种算法的 AUC 与运行时间如表 3 所示。



(a) B29(R), B23(G), B16(B) (b) 真实异常地物  
假彩色合成影像

图 6 Hyperion 数据集  
Fig. 6 Hyperion data set

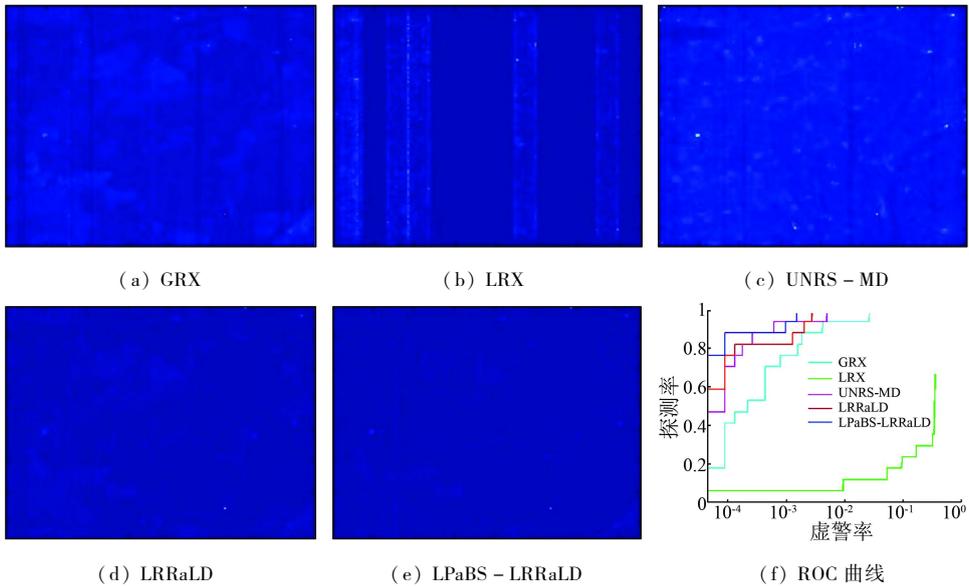


图 7 Hyperion 数据集探测结果及 ROC 曲线

Fig. 7 Detection results and ROC curves of Hyperion data set

表 3 Hyperion 数据集 AUC 与耗时性比较

Tab. 3 Comparison of AUC and execution time using Hyperion data set

指标	GRX	LRX	UNRS - MD	LRRaLD	LPaBS - LRRaLD
AUC	0.997 82	0.730 53	0.999 62	0.999 60	0.999 83
时间/s	0.331 6	176.50	276.60	110.60	83.58

通过图 7 可以看出,使用 Hyperion 数据进行异常探测,除 LRX 算法外,其他探测算法均具有较高的探测精度,其中 LPaBS - LRRaLD 算法探测精度最高。由表 3 数据可知,GRX 算法运行时间最短,但是探测精度均低于 UNRS - MD, LRRaLD 和 LPaBS - LRRaLD 算法,其中 LPaBS - LRRaLD 算法在探测精度与运行时间上明显优于其他算法。

### 2.2.3 Hypex 数据

该数据是由机载 Hypesx 高光谱成像仪于 2014 年 11 月在徐州泉山区附近拍摄的条带影像,包含

160 个可见光波段与 288 个短波红外波段,光谱范围为 415 ~ 2 508 nm,空间分辨率近 1 m,实验中截取条带中 340 像元 × 260 像元区域,其中异常值为彩钢房屋,影像与真实异常地物如图 8 所示。



(a) B63(R), B38(G), B13(B) (b) 真实异常地物  
真彩色合成影像

图 8 Hypex 数据集  
Fig. 8 Hypex data set

在 Hypspx 数据集中,首先基于 LPaBS 算法选出具有代表性的 45 个波段,然后使用学习字典算法进行异常探测。

各种探测算法实验结果及各种算法的 ROC 曲线如图 9 所示,每种算法的 AUC 与运行时间如表 4 所示。

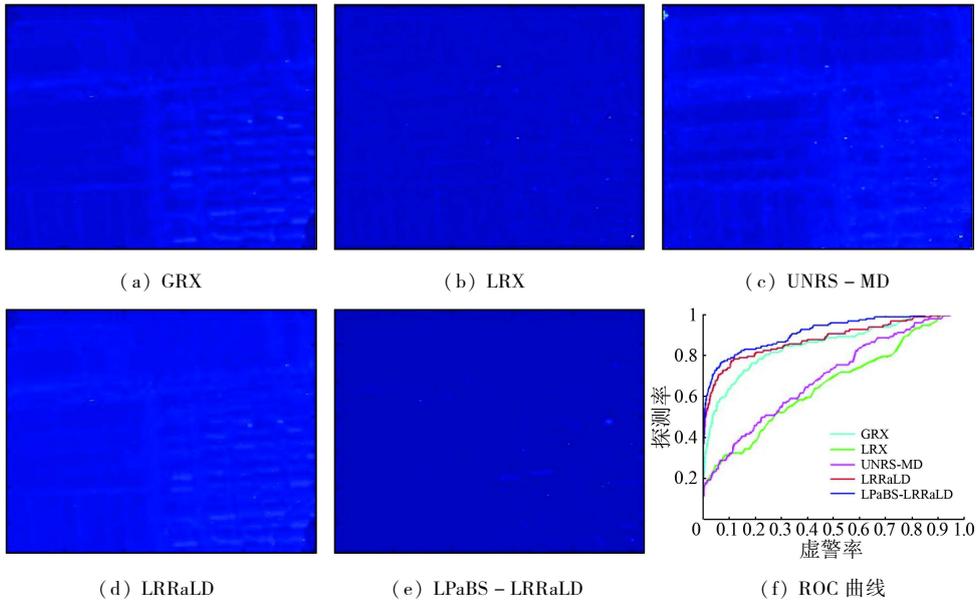


图 9 Hypspx 数据集探测结果及 ROC 曲线

Fig. 9 Detection results and ROC curves of Hypspx data set

表 4 Hypspx 数据集 AUC 与耗时性比较

Tab. 4 Comparison of AUC and execution time using Hypspx data set

指标	GRX	LRX	UNRS - MD	LRRaLD	LPaBS - LRRaLD
AUC	0.848 51	0.654 31	0.692 50	0.877 18	0.910 69
时间/s	5.338	4.494	5.500	430.5	109.5

通过图 9 可以看出,使用 Hypspx 数据进行异常探测,其中的 LPaBS - LRRaLD 算法探测精度明显高于其他算法。由表 4 数据可知,除 GRX 算法运行时间最短外,LPaBS - LRRaLD 算法在探测精度与运行时间上明显优于其他算法。

### 2.3 实验小结

通过模拟数据与真实数据实验,可以看出本文提出算法的可行性,对照实验中所使用的 RXD 算法与最近提出的 UNRS - MD 和 LRRaLD 算法都是基于原始数据进行的异常探测,而本文提出算法在降维的同时探测精度得到了提高,尤其是 Hypspx 数据,波段数从 448 个减少到 45 个,很大程度上去除了信息冗余,在减少计算代价的同时探测精度也得到了提高。

## 3 结论

针对全局高光谱异常,将低秩分解的算法引入到高光谱异常探测中,并通过低秩分解将图像表征

为背景低秩矩阵与稀疏矩阵,在求解背景低秩矩阵过程中采用学习字典来提高背景字典的准确性与鲁棒性,同时顾及维数灾难对高光谱影响异常探测的影响。首先,采用基于波段相似性线性预测的算法进行降维,在保持原有波段信息不变性的同时有效地去除数据冗余;然后,结合学习字典算法在低秩分解过程中提高背景与异常信息可分性的同时,更好地挖掘数据本身的低秩特性,从而达到快速收敛;最后,使用传统的 RXD 算法对稀疏矩阵进行异常探测。

实验表明,本文算法与同类算法相比,在高光谱影像异常探测中,在进一步降低计算代价的同时,提高了异常探测率,因此该算法更具有实际应用意义。由于学习字典的随机性,会使得背景字典中存在异常的小概率事件发生,针对这种情况,如何找到完全不存在异常的背景字典来表征背景矩阵,从而使得背景与异常更加有效地分离将是需要进一步研究的问题;同时也建议尝试其他探测算法对稀疏矩阵进行异常探测,以达到更高精度的探测率。

### 参考文献 (References):

[1] 钮宇斌,王 斌. 基于低秩表示和学习字典的高光谱图像异常探测[J]. 红外与毫米波学报,2016,35(6):731-740.  
Niu Y B, Wang B. Hyperspectral anomaly detection using low-rank representation and learned dictionary[J]. Journal of Infrared and Millimeter Waves, 2016, 35(6):731-740.

[2] 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.
- [3] Matteoli S, Diani M, Corsini G. A kurtosis – based test to efficiently detect targets placed in close proximity by means of local covariance – based hyperspectral anomaly detectors [C]//3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). Lisbon: IEEE, 2011: 1 – 4.
- [4] Molero J M, Garzón E M, García I. Analysis and optimizations of global and local versions of the RX algorithm for anomaly detection in hyperspectral data [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(2): 801 – 814.
- [5] Taitano Y P, Geier B A, Bauer K W. A locally adaptable iterative RX detector [J]. *Eurasip Journal on Advances in Signal Processing*, 2010(1): 1 – 10.
- [6] 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 and Remote Sensing*, 2014, 7(6): 2351 – 2366.
- [7] 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.
- [8] 张兵. 高光谱图像处理与信息提取前沿 [J]. *遥感学报*, 2016, 20(5): 1062 – 1090.  
Zhang B. Advancement of hyperspectral image processing and information extraction [J]. *Journal of Remote Sensing*, 2016, 20(5): 1062 – 1090.
- [9] Xu Y, Wu Z, Li J. 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.
- [10] Li W, Du Q. Collaborative representation for hyperspectral anomaly detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(3): 1463 – 1474.
- [11] 赵锐, 杜博, 张良培. 一种基于核特征空间的鲁棒性高光谱异常探测方法 [J]. *光子学报*, 2013, 42(8): 883 – 890.  
Zhao R, Du B, Zhang L P. An anomaly detection method for hyperspectral imagery in kernel feature space based on robust analysis [J]. *Acta Photonica Sinica*, 2013, 42(8): 883 – 890.
- [12] 张乐飞, 张良培, 陶大程. 张量分类算法的遥感影像目标探测 [J]. *遥感学报*, 2010, 14(3): 519 – 533.  
Zhang L F, Zhang L P, Tao D C. Tensor – based learning machine for remotely sensed image target detection [J]. *Journal of Remote Sensing*, 2010, 14(3): 519 – 533.
- [13] 彭波, 张立福, 张鹏, 等. Cholesky 分解的逐像元实时高光谱异常探测 [J]. *遥感学报*, 2017, 21(5): 739 – 748.  
Peng B, Zhang L F, Zhang P, et al. A real – time sample – wise hyperspectral anomaly detection algorithm using Cholesky decomposition [J]. *Journal of Remote Sensing*, 2017, 21(5): 739 – 748.
- [14] Huang S Y, Yeh Y R, Eguchi S. Robust kernel principal component analysis [J]. *Neural Computation*, 2009, 21(11): 3179 – 3213.
- [15] Chen S Y, Yang S M, Kalpakis K, et al. Low – rank decomposition – based anomaly detection [C]//Proceedings of the SPIE Defense, Security, and Sensing, 2013, 8743.
- [16] Liu G, Lin Z, Yan S, 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.
- [17] Niu Y, Wang B. A novel hyperspectral anomaly detector based on low – rank representation and learned dictionary [C]//IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Beijing: IEEE, 2016.
- [18] Honeine P. Online kernel principal component analysis: A reduced – order model [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(9): 1814 – 1826.
- [19] Wang J, Chang C I. Independent component analysis – based dimensionality reduction with applications in hyperspectral image analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(6): 1586 – 1600.
- [20] Weiland S, Van Belzen F. Singular value decompositions and low rank approximations of tensors [J]. *IEEE Transactions on Signal Processing*, 2010, 58(3): 1171 – 1182.
- [21] Su M C, Chang H T. Fast self – organizing feature map algorithm [J]. *IEEE Transactions on Neural Networks*, 2000, 11(3): 721 – 733.
- [22] 哈斯巴干, 马建文, 李启青, 等. 多波段遥感数据的自组织神经网络降维分类研究 [J]. *武汉大学学报(信息科学版)*, 2004, 29(5): 461 – 465.  
Hasi B G, Ma J W, Li Q Q, et al. Dimension reduction of self – organized neural network classification for multi – band satellite data [J]. *Geomatics and Information Science of Wuhan University*, 2004, 29(5): 461 – 465.
- [23] 杜培军, 王小美, 谭琨, 等. 利用流形学习进行高光谱遥感影像的降维与特征提取 [J]. *武汉大学学报(信息科学版)*, 2011, 36(2): 148 – 152.  
Du P J, Wang X M, Tan K, et al. Dimensionality reduction and feature extraction from hyperspectral remote sensing imagery based on manifold learning [J]. *Geomatics and Information Science of Wuhan University*, 2011, 36(2): 148 – 152.
- [24] 李恒凯, 吴立新, 李发帅. 面向土地利用分类的 HJ – 1 CCD 影像最佳分形波段选择 [J]. *遥感学报*, 2013, 17(6): 1572 – 1586.  
Li H K, Wu L X, Li F S. Optimal fractal band selection on HJ – 1 CCD image for land use classification [J]. *Journal of Remote Sensing*, 2013, 17(6): 1572 – 1586.
- [25] Lu X Q, Li J L. A remote sensing images feature selection approach based on ant colony algorithm [C]//The 2nd International Conference on Industrial Mechatronics and Automation. Wuhan: IEEE, 2010.
- [26] Zhou S, Zhang J P, Su B K. Feature selection and classification based on ant colony algorithm for hyperspectral remote sensing images [C]//The 2nd International Congress on Image and Signal Processing. Tianjin: IEEE, 2009.
- [27] 叶志伟, 郑葆葆, 万幼川, 等. 基于蚁群优化的特征选择新方法 [J]. *武汉大学学报(信息科学版)*, 2007, 32(12): 1127 – 1130.  
Ye Z W, Zheng Z B, Wan Y C, et al. A novel approach for feature selection based on ant colony optimization algorithm [J]. *Geomatics and Information Science of Wuhan University*, 2007, 32(12): 1127 – 1130.
- [28] 周爽. 蚁群算法在高光谱图像降维和分类中的应用研究 [D]

哈尔滨:哈尔滨工业大学,2010.

Zhou S. Research on the Application of Ant Colony Algorithm in the Dimensionality Reduction and Classification for Hyperspectral Image [D]. Harbin: Harbin Institute of Technology, 2010.

[29] Tan K, Li E, Du Q, et al. Hyperspectral image classification using band selection and morphological profile [C]//4th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). Shanghai: IEEE, 2014.

[30] 张兵,高连如. 高光谱图像分类与目标探测 [M]. 北京: 科学出版社, 2011.

Zhang B, Gao L R. Hyperspectral Image Classification and Target Detection [M]. Beijing: Science Press, 2011.

[31] Wold S, Esbensen K, Geladi P. Principal component analysis [J]. Chemometrics and Intelligent Laboratory Systems, 1987, 2(1-3): 37-52.

[32] Li W, Du Q. Unsupervised nearest regularized subspace for anomaly detection in hyperspectral imagery [C]//IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Melbourne: IEEE, 2013.

## Hyperspectral imagery anomaly detection based on band selection and learning dictionary

HOU Zengfu<sup>1</sup>, LIU Rongyuan<sup>2</sup>, YAN Bokun<sup>2</sup>, TAN Kun<sup>1</sup>

(1. Key Laboratory for Land Environment and Disaster Monitoring of NASG, China University of Mining and Technology, Xuzhou 221116, China; 2. China Aero Geophysical Survey and Remote Sensing Center for Natural Resources, Beijing 100083, China)

**Abstract:** With the large quantities of redundant information in the hyperspectral imagery, the traditional anomaly detection algorithm using the overall hyperspectral spectrum should consume a larger amount of computing time. Based on the linear prediction and learning dictionary, the authors put forward a novel algorithm. Compared with other low rank representation methods, the linear prediction method with the similarity of the band is utilized to find the least similar band subsets, and then the learning dictionary is implemented to obtain the learning dictionary which can represent the background information of the imagery. In addition, the imagery is divided into low rank matrix and sparse matrix via the low rank and decomposition. Finally, the traditional RXD (Reed - X detector) detection algorithm is utilized to detect the sparse image anomaly. Compared with other methods, the proposed method performs better with lower computational cost. Experimental results demonstrate that the selection of some bands including original information can achieve a good performance without corrupting the original information. It is a fine technique to apply to the hyperspectral imagery anomaly detection.

**Keywords:** hyperspectral; band similarity; linear prediction; learning dictionary; anomaly detection; low rank decomposition; sparse

(责任编辑: 陈理)