

引用格式: 李欢, 赵嘉豪, 刘广涵, 等. 双层协同结构改进的高光谱异常检测算法[J]. 航空兵器, 2024, 31(4): 121-127.

Li Huan, Zhao Jiahao, Liu Guanghan, et al. Improved Hyperspectral Anomaly Detection Algorithm with Double Layer Collaborative Structure [J]. Aero Weaponry, 2024, 31(4): 121-127. (in Chinese)

双层协同结构改进的高光谱异常检测算法

李欢¹, 赵嘉豪², 刘广涵¹, 石锦辉³, 宋江鲁奇^{1*}, 周慧鑫¹

(1. 西安电子科技大学 物理学院, 西安 710071; 2. 西安邮电大学, 西安 710071;
3. 中国空空导弹研究院, 河南 洛阳 471009)

摘要: 在高光谱目标检测领域, 基于协同表示的算法展现出优异的性能, 但其一直存在异常点对背景字典的污染问题, 这一定程度上影响了算法的检测性能。本文提出了一种改进的协同表示高光谱异常检测算法, 设计了双层协同表示结构, 首先利用第一层协同表示算法将大部分异常点检出, 并用其邻域进行背景纯化, 剔除已检出的异常点对背景字典的污染, 然后用纯化的背景字典来预测背景, 进而在第二层采用协同表示进行异常检测。仿真试验表明, 通过简单的双层协同表示结构可以有效地减轻异常点对背景污染的问题。该算法的检测性能相对基础的协同表示算法有显著的提升, 与现有的算法对比, 具有相对较好的检测效果。

关键词: 高光谱; 异常检测; 目标检测; 背景污染; 协同表示; 双层结构

中图分类号: TJ760; V448.25

文章编号: 1673-5048(2024)04-0121-07

文献标识码: A

DOI: 10.12132/ISSN.1673-5048.2023.0229

0 引言

随着高光谱图像技术的发展, 其技术的应用也得到了快速推广, 目前基于高光谱图像的目标检测技术已经在农业、军事领域展现出广阔的应用前景, 受到了各国科研工作者的广泛关注^[1-2]。基于高光谱的目标检测可分为监督目标检测和异常目标检测, 其中异常检测算法由于不需要先验知识, 具有更好的实用性, 成为检测领域新的研究热点。

近年来, 基于高光谱的异常检测算法被提出, 其中, 最为经典的算法是 RX (Reed - Xiaoli Detection) 算法^[3], 该算法假设高光谱图像背景部分服从多元高斯分布, 利用高光谱图像的光谱向量均值估计参考背景均值向量和协方差矩阵参数, 最后, 以计算的单个像素与参考背景统计特征之间的马尔可夫距离作为最终判断依据。RX 算法在背景相对简单的高光谱图像中显示出良好的检测性能。然而, 对于复杂的高光谱数据集和噪声干扰, 很难正确描述各种地面特征。针对 RX 算法的不足, 相关研究

人员也从不同方面提出了相应的改进方法^[4-8]。

2015 年, Li 等人首次将协同表示方法应用于超光谱图像异常检测领域^[9]。与 RX 算法相比, 该算法没有对背景进行高斯假设。该算法提出背景像素可以由周围像素近似表示, 而异常像素不能, 因此, 可以通过使用相邻像素来重新构造中心像素, 背景字典就由围绕中心像素的一些代表性背景像素组成。该算法使用滑动双窗口来获得背景字典, 中心像素的近似值可以通过背景字典原子的线性组合来获得, 中心像素与其近似值之间的距离用于确定中心像素是否异常。在较多数据集上, CRD (Collaborative - Representation - based Detector) 算法通常能够表现出优异的异常检测性能, 然而在 CRD 算法中一直存在背景字典的异常像素污染问题, 这一定程度上限制了算法的检测性能^[10]。因此, 基于协同表示及其他方法在后来的工作中也得到一定程度的优化及改进^[10-18]。

综上所述, 基础的 CRD 算法可以取得较好的性能, 但由于异常点对背景字典存在污染的问题, 一定程度上影响了算法性能。因此, 如果能够对异常点进行预

收稿日期: 2023-11-24

基金项目: 航空科学基金项目 (ASFC-201901081002); 电磁空间安全全国重点实验室基金项目; 中央高校基本科研业务费 (QTZX23059; QTZX23009); 陕西省自然科学基金基础研究计划 (2023-JC-YB-062; 2021JQ-182); “高等学校学科创新引智计划”111 基地 (B17035)

作者简介: 李欢 (1987-), 男, 江苏丰县人, 讲师。

*通信作者: 宋江鲁奇 (1990-), 男, 河南南阳人, 副教授。



免费获取电子版

检测,得到异常点的分布,对背景字典进行纯化,则可以剔除其对重构背景字典的影响,再使用 CRD 算法进行异常点检测时,可以降低异常点对算法性能的影响,从而提升算法的性能^[10, 18]。基于此,本文提出了一种改进的协同表示的高光谱异常检测算法,设计了双层 CRD 架构 (Twice CRD, TCRD),首先利用协同表示算法将大部分异常点检出,再用异常点邻域进行背景纯化,剔除已检出异常点对背景字典的污染,进而采用协同表示来进行异常检测。仿真试验表明,通过简单的双层协同表示算法可以有效减轻异常点对背景的污染问题,算法的检测性能相对基础的协同表示算法有显著提升。

1 基于协同表示的高光谱异常检测算法

基于协同表示的异常检测算法通过背景字典重构背景,并通过重构与原始图像之间的误差进行判断。基于协同表示的异常检测时,在高光谱图像中局部背景具有一定的相似性,背景可由周围背景成分近似代替,并通过引入双窗口结构,将双窗口之间的像元组成背景字典去重构中心像素。在高光谱数据中,定义一个中心像素 y ,周围存在双窗结构,如图 1 所示,其中内窗大小为 W_{in} ,外窗大小为 W_{out} ,内外窗之间像素个数为 $num_b = W_{out} \times W_{out} - W_{in} \times W_{in}$ 。假设内外窗之间像素属于背景元素,并组成用于重构中心像素的背景字典 A^b ,字典对应权重系数为 x ,则基于字典 A^b 的中心像素可表示为 $A^b x$ 。




图 1 重构原子选择区域图
Fig. 1 Selection region for reconstruction

重构误差定义为

$$E(y) = \|y - A^b x\|_2 \quad (1)$$

式中: $E(y)$ 为中心像素与基于字典表示的近似值之间的误差,当误差小于阈值时可以判定中心待测点为背景,否则为异常点。

在基于协同表示的异常检测方法中,需要解决的关键问题就是寻找最佳权重系数 x ,满足在 $\|x\|_2$ 最小的约束条件下使得误差 $E(y)$ 最小,数学描述为

$$\arg\min_x \|y - A^b x\|_2 + \lambda \|x\|_2 \quad (2)$$

式中: λ 是拉格朗日乘子,进一步有

$$\arg\min_x [x^T ((A^b)^T A^b + \lambda I) x - 2x^T (A^b)^T y] \quad (3)$$

对权重系数 x 求导,且令导数为 0,有

$$x = ((A^b)^T A^b + \lambda I) (A^b)^T y \quad (4)$$

式中: I 为单位矩阵。

在利用背景字典表示中心像素点时,为尽可能接近中心待测点数值,可以考虑给予背景字典各原子不同的权值。当字典中原子和待测点更为相近时,则可以在字典中给予更大的权重比例,而当字典中原子和待测点有较大差异时,应给予其原子更小的权重。根据上述规律

对字典做如式(5)所示的调整。

$$\Gamma_y = \begin{bmatrix} \|y - a_1\|_2 & & 0 \\ & \ddots & \\ 0 & & \|y - a_{num_b}\|_2 \end{bmatrix} \quad (5)$$

式中: $a_1, a_2, \dots, a_{num_b}$ 为字典 A^b 的列向量, $\|y - a_i\|_2$ 为待测点和字典原子之间的欧式距离。不妨令 $y = [y; 1]$, $A^b = [A^b; 1]$, “1”是长为 num_b 的横向量,且向量元素全为 1,可使 x 和为 1,增强算法稳定性,则有

$$\arg\min_{x_i} \|y - A^b x_i\|_2 + \lambda \|\Gamma_y x_i\|_2 \quad (6)$$

对式(6)进一步求解,得

$$x_i = ((A^b)^T A^b + \lambda \Gamma_y^T \Gamma_y)^{-1} (A^b)^T y \quad (7)$$

在得到上述解之后便可以根据式(7)完成重构误差的计算,与设定的阈值 th 比较,完成基于协同表示的异常检测,其判断过程为

$$E(y) = \|y - A^b x_i\|_2 \quad \begin{cases} E(y) \geq th & \text{异常目标} \\ E(y) < th & \text{背景} \end{cases} \quad (8)$$

2 背景纯化

一般地,利用第一层协同表示已经可以得到初步异常信息的分布情况。为降低异常点对背景字典的污染,在原始高光谱图像中,对可能异常点对应坐标处光谱曲线置零清除,对清除后的可能异常点像元用邻域内所有可能背景点的均值向量代替。为保证填充向量的有效性,在进行填充时,利用以可能异常点为中心的窗口大小为 w 的范围内可能背景像素的均值向量对中心可能异常点进行填充,完成背景纯化。设某一像素经第一层协同表示算法确定为异常点 l ,以 l 为中心的窗口大小为 w 的范围内所有背景像素构成集合 B ,则 l 像素纯化对应的计算方法为

$$l = \sum_i \frac{m_i}{N} \quad (9)$$

式中: m_i 为集合 B 中的第 i 个元素; N 为集合 B 中的背景元素的个数。

3 第二层协同表示算法

在完成背景纯化后,使用第二层协同表示算法完成纯化后高光谱图像的重构,其基本方法和原理与公式(1)~(8)一致,输入第二层协同表示的参数包括 λ 以及内外窗口大小 W_{in} 和 W_{out} 。其权重系数的计算公式为

$$x_2 = ((A^b)^T A^b + \lambda \Gamma_y^T \Gamma_y)^{-1} (A^b)^T y \quad (10)$$

进而与设定的阈值 th 比较,完成基于协同表示的异常检测,其判断过程为

$$E(y) = \|y - A^b x_2\|_2 \quad \begin{cases} E(y) \geq th & \text{异常目标} \\ E(y) < th & \text{背景} \end{cases} \quad (11)$$

最终得到检测结果并分析算法性能效果。

4 本文算法流程

本文提出一种基于双层协同表示的高光谱异常检测

算法, 首先利用第一层协同表示算法将大部分异常点检出, 并在构建背景字典时, 将所有已检测出的异常点剔除, 然后用纯化的背景字典来预测背景, 进而在第二层采用协同表示进行异常检测。

算法流程如下:

(1) 输入高光谱数据 H 、参数 λ 以及内外窗口大小 W_{in} 和 W_{out} , 以及误差阈值 th , 利用协同表示算法完成异常点的预检测;

(2) 对可能的异常点像元用内窗邻域内所有可能背景点的均值向量填充, 完成背景纯化;

(3) 使用第二层协同表示算法对纯化后的高光谱图像完成重构, 输入第二层协同表示的参数 λ 以及内外窗口大小 W_{in} 和 W_{out} , 得到重构高光谱图像 Y , 并计算 H 与 Y 的重构误差, 得到检测结果。

5 试验结果与分析

为准确验证算法的性能好坏, 本文对两幅不同的高光谱图像进行仿真试验, 同时为了进行比较分析, 本文选择了 4 种经典的超光谱异常检测算法, 包括 RX^[3]、局部 RX 算法 (LRX)^[19]、基于协同表示的异常检测算法 CRD^[9]、基于白化空间相关滤波的异常检测算法 (WSCF)^[20]、基于鲁棒性主成分分析的异常检测算法 (RPCA - RX)^[21] 和基于核孤立森林的异常检测算法 (KIFD)^[22]。通过比较不同算法的检测结果, 进一步分析了本文算法的优缺点。

(1) Beach_Plane 数据集及分析

Beach_Plane 数据集由机载可见光/红外光谱成像仪采集, 拍摄地点为 Island 海滩, 空间分辨率为 17.2 米/像素, 保留 188 个光谱波段, 空间部分截取后大小为 140×140 。图中主要包含海面、沙滩、海岛等地物目标种类, 其中异常目标为海面上的飞机。该数据伪彩色图像及其异常目标真实位置分布如图 2 所示。这些数据包括海面、海滩、岛屿、飞机和其他物体。海面上的一架飞机是异常物体, 其余的是背景。对于本文的算法, 所涉及的主要参数包括可能的异常对象的阈值 th 、协同表示正则化参数 λ , 以及双层协同表示窗口的内窗 W_{in} 和外窗 W_{out} 的相应大小。试验证明, 正则化参数 λ 对最终结果的影响很小, 并且在协同表示中, 正则化参数 λ 一致设置为 10^{-6} 。第一层的协同表示窗口内窗 W_{in} 和外窗 W_{out} 分别为 17 和 19, 阈值 th 设置为 0.3, 第二层协同表示窗口内窗 W_{in} 和外窗 W_{out} 分别为 3 和 5。




图 2 Beach_Plane 数据集

Fig. 2 Beach_Plane dataset

为分析一次 CRD 并进行背景纯化的效果, 做出了原始数据的伪彩图和一次 CRD 及背景纯化后数据的伪彩图, 如图 3 所示。由图可以看出, 主观视觉上, 原始数据伪彩图和一次 CRD 背景纯化后数据的伪彩图差异较小, 仅从主观视觉上难以观察到其差异。图 4 为这两幅伪彩图的差值。由图 4 可以看出, 其差异主要体现在第一次 CRD 后检出的异常点处, 同时也可以看出, 除了异常点真值处表现出较大差异外, 在左下角沙滩处也表现出了较大的差异, 这主要是因为第一次 CRD 时, 沙滩的光谱信息和海面的光谱信息差异较大, 也被预检为异常点, 从而也被做了邻域均值替代, 表现出与原始数据的差异。




图 3 Beach_Plane 数据集的对比结果

Fig. 3 Comparison results of Beach_Plane dataset



图 4 Beach_Plane 数据集两幅伪彩图差值

Fig. 4 Difference between two pseudo color images of Beach_Plane dataset

各个算法在 Beach_Plane 图像上的试验模拟结果如图 5 所示。图 5(a) 显示了数据集对应的异常对象的真实值, 图 5(b) ~ (h) 显示了每个比较算法和本文算法的异常检测结果。由图可以看出, 所有算法都可以检测到异常对象。然而, 相对来说, RX 算法和 RPCA - RX 算法的检测结果中异常物体的形状轮廓不如其他算法清晰; 在背景抑制方面, RX 算法、WSCF 算法和 KIFD 算法对该数据集的背景抑制效果较差, 存在大量明显的背景残差, 而 LRX 算法的背景抑制效果较好, 但其异常物体的轮廓相对较差。本文算法的异常物体整体保留较好, 同时通过双层协同表示的作用, 很大程度上降低了异常点对背景字典的污染, 表现出对背景良好的抑制效果, 其在左下角处留有极少的背景残留, 如图 5(h) 所示, 相对 CRD 算法 (见图 5(d)) 具有明显的提升。这表明 RX 和 KIFD 算法将存在明显的虚警, 而本文所提出的算法则表现相对较好的性能。

为了更清楚地分析测试结果, 在图 5 的基础上, 对测试结果的三维显示进行进一步的主观分析。图 6(a) 显示了真实异常物体的三维分布, 图 6(b) ~ (h) 显示了所有算法检测结果对应的三维网格。在图 6 的试验结果的




图 5 Beach_Plane 数据集的检测结果

Fig. 5 Detection results for Beach_Plane dataset

3D 网格中,与图 5 的结果类似,可以清楚地看到背景区域的幅度相对较小,表明本文算法和 LRX 算法具有最佳的背景抑制效果,而在该数据集上可以观察到 RX 算法、WSCF 算法和 KIFD 算法相对较为严重的背景残差,仍存在许多海岛背景残差。在 LRX 算法、CRD 算法和本文算法的检测结果中(图 6(c)、(d)和(h)),对异常对象的检测是明显的。与对比度算法相比,本文算法在数据集上的目标检测和背景抑制方面具有更好的主观视觉效果,仅有极小的背景残留。

对本文算法和比较算法的检测结果作进一步的定量参数分析和评价。Beach_Plane 数据集上所有算法的接收机工作特性曲线(ROC 曲线)如图 7 所示,相应曲线下面积的 AUC 值如表 1 所示。

在图 7 的 ROC 曲线结果图中,当虚警率小于 0.05 时,各算法之间的差异较小,其中 RX 算法和 RPCA-RX 相对差一些。当虚警率接近 0.05 时,本文算法的检测概率迅速提高。在固定的虚警率下,检测概率大于其他比较算法。同时,本文的算法最早达到检测概率 1,其次为 CRD 算法。根据表 1 中 AUC 值的汇总可以看出,本文算法的 AUC 值明显高于 RX 算法和 RPCA-RX 算法。




图 6 Beach_Plane 数据集的三维网格检测结果

Fig. 6 Three-dimensional mesh detection results for Beach_Plane dataset




图 7 Beach_Plane 数据集的 ROC 曲线图

Fig. 7 ROC curves for Beach_Plane dataset

表 1 Beach_Plane 数据集的 AUC 值

Table 1 AUC values for Beach_Plane dataset

算法	AUC 值	算法	AUC 值
本文算法	0.998 4	WSCF	0.984 0
RX	0.985 2	RPCA-RX	0.978 7
LRX	0.997 1	KIFD	0.991 0
CRD	0.994 3		

LRX、CRD、KIFD 和本文算法具有良好的检测性能, AUC 值均在 0.99 以上。其中本文算法的 AUC 值相对基础的 CRD 算法也有明显的提高,这表明通过双层协同表示结

构, 预检出异常点的分布, 能够较大程度降低异常点对背景字典的污染问题, 从而提高算法的检测性能。

(2) Road_Vehicle 数据集及结果分析

Road_Vehicle 数据集由机载可见光/红外光谱成像仪采集, 成像场景为郊区道路。数据在原始高光谱数据中截取之后空间大小为 100×100 , 光谱波段数为 186。Road_Vehicle 数据集中主要包含道路、草地、树木等地面目标, 异常目标为道路上的三个载具, 对应伪彩色图像及其异常目标真实位置分布如图 8 所示。对于协作表示中的正则化参数, λ 被设置为 10^{-6} 。第一层的协同表示窗口内窗 W_{in} 和外窗 W_{out} 分别为 11 和 13, 阈值 th 设置为 0.3, 第二层协同表示窗口内窗 W_{in} 和外窗 W_{out} 分别为 3 和 7。




图 8 Road_Vehicle 数据集

Fig. 8 Road_Vehicle dataset

对于 Road_Vehicle 数据集, 为分析一次 CRD 并进行背景纯化的效果, 做了原始数据的伪彩图和一次 CRD 背景纯化后数据的伪彩图, 如图 9 所示。由图可以看出, 主观视觉上, 原始数据伪彩图和一次 CRD 背景纯化后数据的伪彩图差异较小, 仅从主观视觉上难以观察到其差异。为实现更好的观测效果, 这两幅伪彩图的差值如图 10 所示。由图 10 可以看出, 其差异主要表现在第一次 CRD 后检出的异常点处, 同时可以看出, 除了异常点真值处表现出较大差异外, 在右侧处也表现出了较大的差异, 这




图 9 Road_Vehicle 数据集的对比结果

Fig. 9 Comparison results of Road_Vehicle dataset



图 10 Road_Vehicle 数据集两幅伪彩图差值

Fig. 10 Difference between two pseudo color images of Road_Vehicle dataset

主要是因为第一次 CRD 时, 由于其光谱信息差异较大, 也被预检为异常点, 进行了邻域均值替代, 从而表现出与原始数据的差异。

该数据集的试验结果如图 11 所示。图中, 所有算法都没有错过异常检测。在 RX 算法、RPCA - RX 算法和 KIFD 算法的检测图中, 对中间部位异常对象的检测效果并不明显, LRX 算法、CRD 算法和本文算法的检测结果则较为明显。同时, RX 算法和 KIFD 算法在图像右侧有更明显的黄色高亮区域。在背景抑制方面, KIFD 算法的背景抑制效果较差, 有大片的背景残留。所有的算法检测结果中, 右侧都有一个较强的背景残留, 表现为干扰, 这主要是因为右侧这一处物体的光谱信息与其邻域相比差异较大, 难以达到较好的背景抑制, 从而会导致虚警。相对来说, 在 CRD 算法和本文算法的检测结果中, 图像右侧的明显虚警现象和背景残留现象要优于其他算法。CRD 中的对象形状与真实对象有显著差异, 本文算法检测到的对象轮廓形状更接近真实对象的轮廓形状。




图 11 Road_Vehicle 数据集的检测结果

Fig. 11 Detection results for Road_Vehicle dataset

图 12 显示了真实异常物体对应的三维网格以及所有算法的检测结果。由图可以清楚地看到, 在 RX 和 RPCA - RX 算法的检测结果中, 中间异常物体位置的幅度

较小,表明检测效果不好。在 RX 算法和 KIFD 算法的检测结果中,异常物体附近的道路残余部分明显。KIFD 算法检测结果的总体幅度较大,表明背景抑制较差,其虚警会相对较高。对于 LRX 算法、WSCF 算法、CRD 算法和本文算法来说,三个异常物体的幅度都很大,背景残留都相对较小,但 LRX 算法和 WSCF 算法检测结果图中靠近右侧有比较高的虚警,而 CRD 算法和本文算法右侧的虚警则相对较小,CRD 算法和本文算法的异常检出及背景抑制效果相近,其差异从直观上难以观察到。




图 12 Road_Vehicle 数据集的三维网格检测结果

Fig. 12 Three-dimensional mesh detection results for Road_Vehicle dataset

对所有算法的结果作进一步的定量分析和评价。相应的 ROC 曲线如图 13 所示,相应的 AUC 值如表 2 所示。从图 13 可以看出,当虚警率小于 0.05 时,LRX 算法、CRD 算法、WSCF 算法和本文算法的检测概率相近,在固定的虚警率下,检测概率明显大于其他比较算法,尤其是 KIFD 算法的性能明显落后于其他算法。LRX 算法、CRD 算法、WSCF 算法和本文算法最早达到检测概率为 1,其次为 RX 算法和 RPCA-RX 算法。从表 2 中可以看出,LRX 算法、CRD 算法、WSCF 算法和本文算法的 AUC 值都大于 0.99,检测性能相对较好,而 KIFD 算法的检测性能较差,其 AUC 值仅有 0.890 8,这主要是由于其较为严重的背景残留导致的,如图 12(g) 所示。对于基于协同表示的方法,基础的 CRD 算法和本文算法的 AUC 值分别为 0.998 6 和 0.999 4,表明它们都具有较为

优异的检测效果。同时可以看出,在该数据集上,本文算法的检测性能相对于基础的 CRD 算法提升较小,这说明基础的 CRD 算法异常点的污染问题较为轻微(其 AUC 值高达 0.998 6),本文算法虽然通过双层协同表示结果减弱了异常点对背景字典的污染,但检测性能的提升还是较小。




图 13 Road_Vehicle 数据集的 ROC 曲线图

Fig. 13 ROC curves for Road_Vehicle dataset

表 2 Road_Vehicle 数据集的 AUC 值

Table 2 AUC values for Road_Vehicle dataset

算法	AUC 值	算法	AUC 值
本文算法	0.999 4	WSCF	0.998 8
RX	0.990 9	RPCA-RX	0.990 2
LRX	0.999 2	KIFD	0.890 8
CRD	0.998 6		

6 结 论

针对基于协同表示的高光谱异常检测算法中,异常点对背景字典的污染问题,本文提出了一种改进的协同表示高光谱异常检测算法,设计了双层协同表示结构,通过第一层协同表示算法将大部分异常点预检出,并用邻域进行背景纯化,从而减弱异常点对算法性能的影响。仿真试验表明,通过简单的双层协同表示算法可以有效降低异常点对于背景污染问题,尤其在 Beach_Plane 数据集中,本文算法的检测性能相对基础的协同表示算法有显著的提升,与现有的算法对比,也具有相对优异的检测效果。

参考文献:

- [1] 徐清宇,李冬冬,蒯杨柳,等. 快速鲁棒高光谱目标跟踪算法[J]. 航空兵器, 2022, 29(2): 39-44.
- [2] Xu Qingyu, Li Dongdong, Kuai Yangliu, et al. Fast and Robust Hyperspectral Object Tracking Algorithm[J]. Aero Weaponry, 2022, 29(2): 39-44. (in Chinese)
- [3] Wang X Y, Wang L G, Wang J W, et al. Hyperspectral Anomaly Detection via Background Purification and Spatial Difference Enhancement[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 6006005.
- [4] Reed I S, Yu X L. Adaptive Multiple-Band CFAR Detection of an Optical Pattern with Unknown Spectral Distribution[J]. IEEE Transactions on Acoustics Speech and Signal Processing, 1990, 38: 1760-1770.
- [5] Matteoli S, Diani M, Corsini G. Hyperspectral Anomaly Detection with Kurtosis-Driven Local Covariance Matrix Corruption Mitigation[J]. IEEE Geoscience and Remote Sensing Letters, 2011, 8(3): 532-536.
- [6] Gao L R, Guo Q D, Plaza A J, et al. Probabilistic Anomaly Detec-

- tor for Remotely Sensed Hyperspectral Data[J]. Journal of Applied Remote Sensing, 2014, 8(1): 083538.
- [6] Molero J M, Paz A, Garzón E M, et al. Fast Anomaly Detection in Hyperspectral Images with RX Method on Heterogeneous Clusters[J]. The Journal of Supercomputing, 2011, 58(3): 411–419.
- [7] Liu W M, Chang C I. Multiple-Window Anomaly Detection for Hyperspectral Imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2013, 6(2): 644–658.
- [8] 张炎, 华文深, 黄富瑜, 等. 基于空谱联合异常度的高光谱异常目标检测[J]. 光谱学与光谱分析, 2020, 40(6): 1902–1908.
- Zhang Yan, Hua Wenshen, Huang Fuyu, et al. Space-Spectrum Joint Anomaly Degree for Hyperspectral Anomaly Target Detection[J]. Spectroscopy and Spectral Analysis, 2020, 40(6): 1902–1908. (in Chinese)
- [9] Li W, Du Q. Collaborative Representation for Hyper-spectral Anomaly Detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(3): 1463–1474.
- [10] Imani M. Adaptive Window Based Collaborative Representation for Hyperspectral Anomaly Detection with Fusion of Local and Global Information[J]. The Egyptian Journal of Remote Sensing and Space Science, 2023, 26(2): 369–380.
- [11] Xiang P, Zhou H X, Li H, et al. Hyperspectral Anomaly Detection by Local Joint Subspace Process and Support Vector Machine[J]. International Journal of Remote Sensing, 2020, 41(10): 3798–3819.
- [12] Xie W Y, Li Y S, Lei J, et al. Hyperspectral Band Selection for Spectral-Spatial Anomaly Detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(5): 3426–3436.
- [13] Qu Y, Wang W, Guo R, et al. Hyperspectral Anomaly Detection through Spectral Unmixing and Dictionary-Based Low-Rank Decomposition[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(8): 4391–4405.
- [14] Zhang Y, Fan Y G, Xu M M, et al. An Improved Low Rank and Sparse Matrix Decomposition-Based Anomaly Target Detection Algorithm for Hyperspectral Imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13: 2663–2672.
- [15] 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.
- [16] Zhuang L N, Gao L R, Zhang B, et al. Hyperspectral Image Denoising and Anomaly Detection Based on Low-Rank and Sparse Representations[C]//Proceedings of Image and Signal Processing for Remote Sensing XXIII, 2017, 10427: 184–191.
- [17] Verdoja F, Grangetto M. Graph Laplacian for Image Anomaly Detection[J]. Machine Vision and Applications, 2020, 31(1): 1–16.
- [18] 张炎, 华文深, 黄富瑜, 等. 基于背景纯化的改进协同表示的高光谱异常目标检测[J]. 半导体光电, 2019, 40(5): 732–736.
- Zhang Yan, Hua Wenshen, Huang Fuyu, et al. Improved Collaborative Representation for Hyperspectral Anomaly Detection Based on Background Refinement[J]. Semiconductor Optoelectronics, 2019, 40(5): 732–736. (in Chinese)
- [19] Matteoli S, Veracini T, Diani M, et al. A Locally Adaptive Background Density Estimator: An Evolution for RX-Based Anomaly Detectors[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(1): 323–327.
- [20] Gaucel J M, Guillaume M, Bourennane S. Whitening Spacial Correlation Filtering for Hyperspectral Anomaly Detection[C]//Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing, 2005.
- [21] Wright J, Ganesh A, Rao S, et al. Robust Principal Component Analysis: Exact Recovery of Corrupted Low-Rank Matrices via Convex Optimization[EB/OL]. (2009–04–01)[2023–11–23]. <https://www.ideals.illinois.edu/items/100027>.
- [22] Li S T, Zhang K Z, Duan P H, et al. Hyperspectral Anomaly Detection with Kernel Isolation Forest[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(1): 319–328.

Improved Hyperspectral Anomaly Detection Algorithm with Double Layer Collaborative Structure

Li Huan¹, Zhao Jiahao², Liu Guanghan¹, Shi Jinhui³, Song Jiangluqi^{1*}, Zhou Huixin¹

(1. School of Physics, Xidian University, Xi'an 710071, China;

2. Xi'an University of Posts & Telecommunications, Xi'an 710071, China;

3. China Airborne Missile Academy, Luoyang 471009, China)

Abstract: In the field of hyperspectral target detection, algorithms based on collaborative representation have shown excellent performance. However, the pollution of background dictionaries by anomaly has always been a problem, which affects the detection performance of this algorithm partly. This paper proposes an improved collaborative representation algorithm for hyperspectral anomaly detection, and designs a double-layer collaborative representation structure. Firstly, the first layer collaborative representation algorithm is used to detect most of the anomaly. Its neighborhood pixels are used for background purification to eliminate the pollution of the detected anomaly on the background dictionary. Then, the purified background dictionary is used to predict the background, and in the second layer, the collaborative representation is used for anomaly detection. Simulation experiments show that a simple double layer collaborative representation structure can effectively alleviate the background pollution caused by anomaly. The detection performance of this algorithm is significantly improved compared to the basic collaborative representation algorithm, and it also has relatively good detection performance.

Key words: hyperspectral; anomaly detection; target detection; background pollution; collaborative representation; double layer structure