

DOI: 10.20189/j.cnki.CN/61-1527/E.202501001

基于拉普拉斯矩阵图的高光谱图像异常目标检测方法

张峰干¹, 何芳¹, 肖磊², 李婷¹

(1. 火箭军工程大学, 陕西 西安 710025;

2. 北京市委办公厅, 北京 100007)

摘要: 为提高高光谱图像异常目标检测的精度, 提出一种基于拉普拉斯矩阵图的异常目标检测方法 (Laplacian Matrix Graph for Anomaly Detection, LGD)。通过构造全连接图和高斯核函数构造的近邻矩阵, 将高光谱图像中异常目标的位置和光谱信息进行联合处理, 实现了高光谱数据不同波段之间的信息融合; 利用图的傅里叶变换和拉普拉斯矩阵性能, 将图信号的总变差作为判断异常目标的评价函数, 实现了异常目标像素点的准确检测, 避免了常规检测算法中的矩阵求逆问题, 降低了算法的复杂度。在异常检测常用的 AVIRIS-I、AVIRIS-II、ABU-urban-2、ABU-urban-4 和 EI Segundo 5 种高光谱数据集上, 进行了算法性能验证。实验结果表明: 该算法在 5 种数据集上异常目标检测的 AUC 值与 ROC 曲线均优于其他算法, 在检测精度上具有明显优势。

关键词: 高光谱图像; 异常目标检测; 图信号; 拉普拉斯矩阵;
图傅里叶变换

中图分类号: TP394.1

文献标志码: A

开放科学标识码(OSID):

文章编号: 2097-2741(2025)01-001-12



听语音
与作者互动
聊科研

Laplacian Matrix Graph-based Anomaly Target Detection Method for Hyperspectral Graphs

ZHANG Fenggan¹, HE Fang¹, XIAO Lei², LI Ting¹

(1. Rocket Force University of Engineering, Xi'an 710025, China;

2. General Office of the Beijing Municipal Committee, Beijing 100007, China)

ABSTRACT: To further improve the accuracy of anomaly target detection for hyperspectral graphs, an anomaly target detection method based on Laplacian matrix graph was proposed. First, by constructing a full-connection graph and a nearest neighbor matrix obtained by the Gaussian kernel function, the method connected the information fusion between different bands of hyperspectral data, and jointly processed the position and spectral information of the anomaly target in hyperspectral graphs. Second, by utilizing the Fourier transform and Laplacian matrix of

收稿日期: 2024-04-25

第一作者: 张峰干 (1985—), 男, 副教授, 主要从事机器学习、阵列优化等方向的研究和教学工作。E-mail: zfg417@163.com

引用格式: 张峰干, 何芳, 肖磊, 等. 基于拉普拉斯矩阵图的高光谱图像异常目标检测方法[J]. 火箭军工程大学学报, 2025, 39 (1): 1-12. ZHANG Fenggan, HE Fang, XIAO Lei, et al. Laplacian matrix graph-based anomaly target detection method for hyperspectral graphs[J]. Journal of Rocket Force University of Engineering, 2025, 39 (1): 1-12.

the graph, the total variation in the graph signal was used as an evaluation function to determine the anomaly target. Accordingly, the accurate detection of anomaly target pixels was realized simultaneously, the matrix inversion calculation in the conventional detection algorithms was avoided and complexity of the algorithm was reduced. Finally, the proposed algorithm was validated on five hyperspectral data sets commonly used for anomaly detection: AVIRIS-I, AVIRIS-II, ABU-urban-2, ABU-urban-4, and EI Segundo. The experimental results showed that the AUC values and the ROC curves of the proposed algorithm on the five data sets for anomaly target detection outperform other algorithms, indicating that this method has advantage in detection accuracy.

KEYWORDS: hyperspectral graph; anomaly detection; graph signal; Laplacian matrix; graph Fourier transform

高光谱遥感是一种重要的对地观测技术, 该技术将体现地物几何空间信息的二维图像与地物近似连续的一维光谱信息创造性地结合在一起, 打破了“图中无谱”“谱中无图”的局限性。高光谱遥感数据具有光谱分辨率高、图谱合一、光谱通道多的特点, 可以在目标检测与识别上发挥优势, 被广泛应用于环境监测、精准农业、地质勘探、军事侦察等领域^[1]。

异常目标检测是在高光谱图像中搜索未知光谱信号的稀疏像素^[2]。对异常目标的定义没有统一标准, 通常认为是光谱特征与周围像素的光谱特征有明显区别且以低概率出现的像素点。由于异常目标检测不需要提供先验信息, 因此具有很强的实用性^[3]。随着高光谱遥感技术的发展, 针对高光谱数据量大、维数高的特点, 研究人员提出了很多异常检测算法, 大致可分为 5 类。一是基于概率分布的异常检测方法。此类的经典算法是 RX (Reed-Xiaoli) 算法^[4], 最早由 Reed 和 Yu 在 1990 年提出。假设高光谱图像数据的背景服从多元高斯分布, 用整个图像的背景来估计统计量, 因此也被称为全局 RX (Global RX, GRX) 算法。该方法计算量小, 针对简单场景也取得了较好的效果, 被普遍认为是高光谱异常检测的基准方法。但多元高斯分布的假设不能完全而真实地描述实际场景的情况。因此, 学者们在此基础上进行了多种改进研究。Local-RX (LRX) 算法降低了背景中噪声信息的干扰, 能提高背景模型估计的准确性^[5-6]。Weighted-RX 算法通过减少异常点信号和噪声信号对背景估计的影响, 提高了算法性能^[7-8]。近几年来, RX 的变异算法仍然层出不穷^[9-12]。二是基于几何模型的异常检测方法, 是将高光谱数据投影到背景的正交子空间上, 达到抑

制背景、突出异常目标的目的, 低概率检测 (Low Probability of Detection, LPD) 法是这类算法的典型代表^[13]。三是基于协同表示的异常目标检测 (Collaborative Representation Detection, CRD) 算法^[14]。这类算法采用一个滑动双窗来收集背景数据, 其基本思想是背景像素可以用周围的数据线性表示, 而异常像素不能, 但滑动双窗中可能存在异常目标像素, 影响背景估计的准确性。四是基于低秩矩阵分解模型的异常检测方法 (LowRank and Sparse Matrix Decomposition, LRSMD), 是将三维高光谱数据转化为二维矩阵, 并对异常目标矩阵和背景矩阵进行分离^[15-17]。比较典型的算法是基于马氏距离的低秩和稀疏矩阵分解的异常检测 (LRSMD-based Mahalanobis Distance Method for Hyperspectral Anomaly Detection, LS-MAD) 算法^[18]、基于低秩和稀疏表示 (LowRank and Sparse Representation, LRASR) 的异常检测算法^[19]等。以上异常检测算法主要是从高光谱数据的光谱信息中来提取异常像素的有效内容, 没有充分利用数据中的空间位置信息。五是从空间信息和光谱信息联合的角度实现的异常目标检测, 其精度更高。典型算法有 Dalla 等^[20]提出的扩展形态剖面方法、形态学属性剖面、扩展属性剖面和扩展多属性剖面以及 Li 等^[21]提出的形态学剖面与属性滤波相结合的检测算法、刘忠雨等^[22]提出的谱-空深度支持向量数据描述算法等。

然而, 高光谱图像中不仅有光谱信息, 还有空间位置信息, 且光谱信息与空间位置结构本质上是密切关联的。上述算法主要使用光谱信息或位置信息进行异常检测, 实际上还可以从挖掘光谱信息与空间结构的相互关系入手, 研究新的检测算法, 从而获得更高的异常目标检测精度。据

此, 本文基于图论提出了一种拉普拉斯矩阵图的异常检测算法 (Laplacian Matrix Graph for Anomaly Detection, LGD), 最后在 5 种高光谱图像数据集上, 将 LGD 算法与 GRX、LRX、CRD、LRaSMD、LSMAD 算法的异常检测结果进行了验证对比。

1 代表性异常检测算法

1.1 RX 算法

RX 算法是建立在背景和异常目标服从协方差相同但均值不同的多变量高斯分布的假设基础上, 统计模型异常检测算法的典型代表。

对于高光谱图像数据集 $\tilde{X} \in \mathbf{R}^{m \times n \times b}$, m 、 n 和 b 分别表示图像的行数、列数和波段数, 总计有 b 幅大小为 $N = m \times n$ 像素的高光谱图像; 其矩阵形式可写为 $X = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbf{R}^{b \times N}$, 其中 $\mathbf{x}_i \in \mathbf{R}^{b \times 1}$ 表示某一像素的光谱向量, 总共包含 b 个波段。RX 算法使用高光谱数据的均值向量 $\boldsymbol{\mu}_b$ 和协方差矩阵 $\mathbf{C}_b$ 来估算背景像素。

异常目标在图像中出现的概率低、占据的能量小, 通常出现在协方差矩阵的小特征值对应的特征向量的方向上。RX 算法有 2 点不足: 一是背景信息往往很复杂, 虽然服从多元高斯分布的这种假设, 但不能完全而真实地描述实际场景的情况; 二是当用均值向量和协方差矩阵作为背景特征来估计背景信息时, RX 算法会带入异常点和噪声信号, 造成背景估计的不准确。

1.2 CRD 算法

CRD 算法是几何模型异常检测算法的代表, 通过建立双窗获取待测像素的邻近像素集, 而后利用邻近像素集的线性组合来重构待测像元, 根据重构误差的大小判定待测像素是否为异常像素。

以待测像素 $\mathbf{r}$ 为中心, 建立 2 个大小不同的正方形窗, 内窗大小为 $w_{in} \times w_{in}$, 外窗大小为 $w_{out} \times w_{out}$, 待测像素的邻近像素集 $\mathbf{X}_s = \{\mathbf{x}_i\} (i = 1, 2, \dots, s)$ 是由内窗和外窗之间的像素组成, $s = w_{out} \times w_{out} - w_{in} \times w_{in}$ 。CRD 算法的目标是找到一个权值向量 $\mathbf{a}$, 在满足 $\|\mathbf{a}\|_2^2$ 最小约束条件下, 使得 $\|\mathbf{r} - \mathbf{X}_s \mathbf{a}\|_2^2$ 最小, 其目标函数可表示为 $\min_{\mathbf{a}} \|\mathbf{r} - \mathbf{X}_s \mathbf{a}\|_2^2 + \lambda \|\mathbf{a}\|_2^2$, 其中, λ 为正则化参数, $\|\cdot\|_2^2$ 表示向量的 L_2 范数的平方, 例如 $\|\mathbf{x}\|_2^2 = \mathbf{x}^T \mathbf{x}$ 。为提高算法检测精度, 目标函数中可以增加基于

距离权值的 Tikhonov 正则化矩阵来调整 $\mathbf{a}$ 的取值。

CRD 算法重点强调每个元素的贡献价值, 使用 L_2 范数约束权值向量, 算法的求解过程简单, 探测性能相对 RX 算法更加优异。

1.3 基于低秩矩阵分解的异常检测算法

低秩矩阵分解的异常检测算法认为高光谱数据具有很强的相关性, 因此数据呈现低秩特性, 而异常目标出现的概率较小, 所以具有稀疏特性。在此假设条件下, 将高光谱数据分解为背景矩阵、异常目标矩阵和噪声矩阵 3 个部分。

LSMAD 算法使用背景矩阵来获得探测结果。背景矩阵中不包含异常目标信息, 因此可用其来估计 RX 算法中的 $\boldsymbol{\mu}_b$ 、 $\mathbf{C}_b$, 而后采用 RX 算法的检测算子进行异常目标检测, 可极大提升检测精度。

LRaSMD 算法使用异常目标矩阵 $\mathbf{S}$ 获得探测结果。像素的异常度可通过异常目标矩阵 $\mathbf{S}$ 中列向量 $\mathbf{s}_i$ 与列均值向量 $\boldsymbol{\mu}_s$ 的欧氏距离 d_i 来计算。 d_i 越大, 对应像素是异常目标的可能性就越大。但算法利用图像分解后的成分进行异常检测, 探测结果的鲁棒性较差。

这些经典的异常检测算法通常只使用了高光谱的光谱信息, 普遍存在检测精度不高、计算复杂度较大的问题。

2 基于拉普拉斯图信号处理的检测算法

2.1 拉普拉斯矩阵图分析

图 1 所示的基本图形, 是由顶点集合 V 和边集合 E 构成的, 可表示为 $G = (V, E, S)$ 。其中, S 为边的权重, 也称为近邻矩阵, 可以衡量节点之间的相似度。




图 1 基本图形的结构

Fig. 1 Structure of a basic graph

在图 1 中, 顶点集合 $V = \{v_1, v_2, v_3, v_4, v_5, v_6\}$, 边集合 $E = \{(v_1, v_2), (v_1, v_3), (v_1, v_5), (v_2, v_3), (v_2, v_5), (v_2, v_6), (v_3, v_4), (v_5, v_6)\}$ 。如果一条边连接顶点 v_i 和 v_j , 则称 v_j 是 v_i 的邻居, 记 v_i 的所有邻居为集合 $N(v_i)$ ^[22]。

常用的构图法主要有 3 种, 分别是 k 近邻法、 ε 近邻法以及全连接法。 k 近邻法和 ε 近邻法都属于稀疏图, 每个顶点只和少部分的点建立联系, 因此计算量较小, 但参数的选取对图以及后续的检测结果影响很大; 全连接图的构造比较简单, 将每个顶点与其他顶点都用边相连接, 而且每一条边上都具有一个权值, 即存在一个可以求导的权值函数, 有利于算法的求解。

除了选取所连接的顶点之外, 还需要确定各条边上的权值, 从而构建近邻矩阵 S 。边的权值需要能够反映出节点之间的相似性, 通常会采用以下 3 种方法来确定。

1) 欧氏距离的倒数

$$S_{ij} = \frac{1}{\|\mathbf{x}_i - \mathbf{x}_j\|_2}$$

式中: $\mathbf{x}_i, \mathbf{x}_j \in \mathbb{R}^{b \times 1}$ 表示某一像素的光谱向量, $i \geq 1, j \leq N$ 。

2) Cauchy 函数

$$S_{ij} = \frac{1}{1 + \left(\frac{\mu_i - \mu_j}{\alpha} \right)^2}$$

式中: μ_i, μ_j 为 2 类节点对应的均值; 参数 α 为比例因子, 通常可设置为所有类节点的均值, 即

$$\alpha = \frac{1}{m} \sum_{i=1}^m \mu_i$$

3) 高斯核函数

$$S_{ij} = \exp \left[-\|\mathbf{x}_i - \mathbf{x}_j\|_2^2 / (2\sigma^2) \right] \quad (1)$$

式中: σ 为热核参数。

在获得近邻矩阵 S 后, 可得到对应的拉普拉斯矩阵 $L = D - S$ 。其中, D 是对角矩阵, 对角线上的元素为 $d_i = \sum_j S_{ij}$, 表示节点上的度。

拉普拉斯矩阵来源于拉普拉斯算子, 而拉普拉斯算子描述了图像中心像素与局部上、下、左、右四邻居像素的差异, 这种性质通常被用来当作图像上的边缘检测算子。同理, 在图信号中, 拉普拉斯算子也被用来描述中心节点与邻近节点之间的信号差异, 可表示为^[23]

$$L\mathbf{x} = (D - S)\mathbf{x} = [\cdots, \sum_{v_j \in N(v_i)} (x_i - x_j), \cdots]$$

式中: $\mathbf{x} = [x_1, x_2, \cdots, x_i, \cdots, x_b]^T$ 为列向量。

拉普拉斯矩阵是一个反映图信号局部平滑度的算子。根据该矩阵, 可定义图信号的总变差 $T_V(\mathbf{x})$ 为

$$T_V(\mathbf{x}) = \mathbf{x}^T L\mathbf{x} = \sum_{v_i, v_j \in N(v_i)} x_i (x_i - x_j) = \sum_{e_{ij} \in E} (x_i - x_j)^2$$

式中: $T_V(\mathbf{x})$ 是一个标量, 表示各条边上信号的差值之和。和值越小, 表明图信号越平滑; 反之, 则表明相邻节点的差异越大, 图信号整体越不平滑。总变差的大小刻画了图信号整体的平滑度, 若图像中存在异常点像素, 那么异常像素点会破坏图信号的局部平滑, 从而增大图信号的总变差。

拉普拉斯矩阵 L 是一个对称矩阵, 可以被正交对角化, 因此可得 $L = U\Lambda U^T$ 。其中 $U \in \mathbb{R}^{N \times N}$ 是一个正交矩阵, 即 $UU^T = I$ 。 $U = [u_1, u_2, \cdots, u_N]$ 表示矩阵 L 的 N 个特征向量, 且这些特征向量都是线性无关的单位向量; 矩阵 Λ 是一个对角矩阵, 对角线上的第 k 个元素 λ_k 是第 k 个特征向量 u_k 对应的特征值。

定义图的傅里叶变换^[24]: 对于任意一个在图 G 上的信号 $\mathbf{x}$, 其图傅里叶变换为

$$\tilde{\mathbf{x}} = U^T \mathbf{x} \quad (2)$$

对式 (2) 两边同乘矩阵 U , 得:

$$U\tilde{\mathbf{x}} = UU^T \mathbf{x} = \mathbf{x}$$

此时, 总变差 $T_V(\mathbf{x})$ 可改写为

$$T_V(\mathbf{x}) = \mathbf{x}^T L\mathbf{x} = \mathbf{x}^T U\Lambda U^T \mathbf{x} = (U\tilde{\mathbf{x}})^T U\Lambda U^T (U\tilde{\mathbf{x}}) =$$

$$\tilde{\mathbf{x}}^T U^T U\Lambda U^T U\tilde{\mathbf{x}} = \tilde{\mathbf{x}}^T \Lambda \tilde{\mathbf{x}} = \sum_{k=1}^N \lambda_k \tilde{x}_k^2$$

图信号的总变差 $T_V(\mathbf{x})$ 与图的特征值 λ_k 之间有着非常直接的线性对应关系, 即总变差是图的所有特征值的一个线性组合。若将图信号的特征值按照从小到大的顺序进行排列, 即 $\lambda_1 \leq \lambda_2 \leq \cdots \leq \lambda_N$, 那么特征值实质上是对图信号的平滑度做出的一种梯度刻画。特征值越大, 图的总变差也会越大, 代表图的整体越不平滑, 相近节点上的图信号值会非常不一致, 异常像素点也会越多; 相反, 特征值越小, 图的总变差也会越小, 代表图的整体越平滑, 相近节点上的信号值趋于一致, 异常像素点会更少。

基于此, 对总变差设置阈值。若总变差大于阈值, 则判断该信号对应的像素是异常像素; 否则, 就是正常像素。与异常检测算法中常用的 CRD 算法、LRaSMD 算法、LSMAD 算法、GRX 算法以及 LRX 算法相比, 该方法无需对协方差矩阵进行求逆运算, 可极大地减少计算量。另外, 采用图论的方法, 可以将高光谱数据中某一空间位置处的多个光谱信息进行构图联接, 从而实现高光谱数据的位置信息和光谱信息的联合, 有利

于实现异常目标的快速、准确检测。

2.2 LGD检测算法

LGD算法主要分为5步: 构图、确定权向量、计算拉普拉斯矩阵、计算图信号的总变差、判断检测异常点。对于高光谱图像数据集 $\tilde{X} \in \mathbf{R}^{m \times n \times b}$, 其矩阵形式 $X = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbf{R}^{b \times N}$, 算法具体步骤如下。

Step1 数据预处理。计算数据集 X 的均值 μ 。

Step2 采用全连接法构图 G 。为保留高光谱图像中的有用信息, 在每个波段上采用全连接法进行构图, 也就是矩阵 X 中的每一行作为图 G 上的一个节点, 每个节点之间相互连接。图 G 上共有 b 个节点, 每个节点互相连接, 从而实现高光谱图像数据集上各光谱波段之间的联通。

Step3 采用高斯核函数来确定权向量矩阵 S 。二维高斯核函数具有旋转对称性, 利用该函数实现的高斯滤波器在各个方向上的平滑程度是相同的。一般来说, 一幅图像中的异常目标位置事先是未知的, 因此, 在滤波前是无法确定一个方向上比另一方向上需要更多的平滑, 旋转对称性意味着高斯核函数在后续异常检测中不会偏向任一方向。另外, 高斯函数是单值函数。高斯滤波器可使用像素邻域的加权均值来代替该点的像素值, 而每一邻域像素点权值是随该点与中心点的距离单调增减的。异常目标是一种图像局部特征, 如果平滑运算对离算子中心很远的像素点仍然有很大作用, 那么平滑运算会使图像失真。因此, 算法选取高斯核函数(式(1))来确定图的权向量矩阵 $S \in \mathbf{R}^{b \times b}$, 更利于异常目标的检测。

Step4 计算拉普拉斯矩阵 L 。根据Step2构造的近邻矩阵 S , 可得到对应的拉普拉斯矩阵 $L = D - S$, 其中 D 是对角矩阵, 对角线上的元素为 $d_i = \sum_j S_{ij}$, $L \in \mathbf{R}^{b \times b}$ 。对拉普拉斯矩阵 L 进行归一化对称化处理, 有

$$L^{\text{sym}} = D^{-1/2} L D^{-1/2}$$

矩阵 L^{sym} 具有非常重要的性质, 其特征值为非负, 而且变化范围在 $[0, 2]$ 。

Step5 对数据集 X 上的每一个待测像素点 $\mathbf{x}_i$ 计算其总变差为

$$T_V(\mathbf{x}_i) = (\mathbf{x}_i - \mu)^T L^{\text{sym}} (\mathbf{x}_i - \mu)$$

Step6 检测像素点 $\mathbf{x}_i$ 是否为异常目标像素点。当 $T_V(\mathbf{x}_i)$ 大于给定的阈值 η 时, 判定 $\mathbf{x}_i$ 是异常目标像素点, 否则就是正常像素。

3 实验与分析

3.1 高光谱图像数据集

为评价LGD算法的性能, 分别在5种高光谱图像数据集上进行实验, 数据集的基本情况如下。

1) AVIRIS-I: 来源于AVIRIS传感器拍摄的圣地亚哥海军机场的高光谱图像^[25]。空间分辨率为3.5 m/像素, 光谱波长为370~2 510 nm, 每个波段波长差为10 nm, 总共有224个波段, 去除低信噪比、水蒸汽吸收等波段和频谱图像效果不佳的波段, 最后保留189个光谱波段(1~6, 33~35, 97, 107~113, 153~166, 221~224)。一幅光谱原始图像为400像素×400像素, 截取左上角120像素×120像素的子图像用于实验。子图像中3架飞机(总计58个像素点)被视为需要检测出来的异常目标。

2) AVIRIS-II: 来源于圣地亚哥海军机场的高光谱图像^[25]。与AVIRIS-I相比, 该数据集从大小为400像素×400像素的原始光谱图像的中间部位截取100像素×100像素的子图像。子图像中有134个像素点表示的飞机被视为需要检测出来的异常目标。

3) ABU-urban-2: 来源于Airport-Beach-Urban (ABU) 数据集^[26], ABU数据集包含3个场景: 机场场景、海滩场景和城市场景。ABU-urban-2属于城市场景, 由AVIRIS传感器拍摄于德克萨斯州的一处海岸区域, 也被称为Texas Coast图像数据集。大小为100像素×100像素, 空间分辨率为17.2 m/像素, 包含207个波段, 覆盖0.45~1.35 nm的波长范围。由于受到严重的条带噪声污染, 该数据是一个具有挑战性的异常目标检测数据集。数据中的主要地物包括农田、公路和若干建筑。其中, 建筑物被视为待检测的异常目标, 异常目标共包含155个像素点。

4) ABU-urban-4: 来源于ABU数据集的城市场景^[26]。ABU-urban-4数据集是由AVIRIS成像系统在美国洛杉矶的一个城区拍摄获得, 也被称为Los Angeles图像数据集。大小为100像素×100像素, 空间分辨率为7.1 m/像素, 包含205个波段, 炼油厂的储罐、炼油塔等特殊材料的建筑物是需检出的异常目标, 共占2 281个像素。

5) EI Segundo: 由AVIRIS光谱成像仪采集, 成像地点位于加利福尼亚州的埃尔塞贡多地区。

原始图像大小为 250 像素×300 像素，空间分辨率为 7.1 m/像素，包含 224 个波段。图像场景主要由一个炼油厂区域、一个居民区、一个公园和一个学校组成。在该场景中，炼油厂的储罐、炼油塔等特殊材料的建筑物被视为需要检测出来的异常目标^[26]，共占 2 048 个像素。

3.2 评价指标

不同异常检测算法的性能可以采用定性和定量的方法进行衡量。其中，异常检测结果的彩色图是一种定性的衡量方法，而受试者工作特征 (Receive Operating Characteristic, ROC) 曲线以及 ROC 曲线下的面积 (Area under ROC Curve, AUC) 是对异常检测算法的一种定量衡量方法。

在进行异常点检测时，根据预测结果和真实情况可划分为 4 种结果，分别是真正例 (True Positive, TP)、假正例 (False Positive, FP)、真反例 (True Negative, TN)、假反例 (False Negative, FN)，令 T_P 、 F_P 、 T_N 、 F_N 分别表示其对应的样例数，则有 $T_P + F_P + T_N + F_N = \text{样例总数}$ 。分类结果的混淆矩阵如表 1 所示。

表 1 分类结果混淆矩阵

Tab. 1 Confusion matrix of the classification result

真实情况	预测结果	
	正例	反例
正例	T_P (真正例)	F_N (假反例)
反例	F_P (假正例)	T_N (真反例)

ROC 曲线是由真正例率 (True Positive Rate, TPR) 和假正例率 (False Positive Rate, FPR) 在不同阈值下对应点形成的连续曲线，其中 TPR 和 FPR 分别又被称为检测概率和虚警率，计算表达式分别为

$$TPR = \frac{T_P}{T_P + F_N}$$

$$FPR = \frac{F_P}{T_N + F_P}$$

AUC 值则是 ROC 曲线与横轴 FPR 包围起来的面积。因此，优秀的异常检测算法在相同的 FPR 下对应的 TPR 值应当较高，而 AUC 值也应当比较大，即 ROC 曲线越靠近左上角，表明算法性能越优秀。

3.3 实验与结果分析

实验中，LGD 算法的性能验证是在多个数据集上，与 GRX、LRX、CRD、LRaSMD、LS-MAD 这 5 种算法的异常检测结果对比来完成的。LRX、CRD 算法对双窗的大小比较敏感，通过实验比较，当 LRX、CRD 双窗大小分别确定为 (13, 11)、(15, 13) 时，在 5 种高光谱数据集上对应的 AUC 值最优；对于 CRD 算法，正则化参数 λ 设置为 10^{-6} ；LRaSMD 和 LSMAD 算法参数设置与文献 [26, 28] 一致；LGD 算法中设热核参数 $\sigma = 1$ 。所有实验均在 win10 系统上进行，主频为 3.8 GHz 的 Intel 酷睿 i7 CPU，32 GB 内存，软件使用 MATLAB 2017。

不同算法在 AVIRIS-I 数据集上的检测结果如图 2 所示。




图 2 不同算法在 AVIRIS-I 数据集上的检测结果

Fig. 2 Detection results on AVIRIS-I dataset obtained by different algorithms

由图2可以看出, GRX、LRX和LRaSMD算法基本没有探测到异常目标; LSMAD算法虽可以探测出异常目标, 但形状非常模糊; CRD和LGD算法可以准确地探测出异常目标的位置和形状, 但CRD算法将大量背景像素也误判为异常目标, LGD算法则能够准确地检测出3架飞机, 且背景噪声较小。

6种探测算法的AUC条形图和ROC曲线如图3所示。可以看出, 在检测精度方面, CRD、LSMAD、LGD的AUC值均大于0.97, 且LGD精度最好。文献[27]中提出的2DCTV-RPCA (2-D Correlated Total Variation Improved by Robust Principle Component Analysis) 和3DCTV-RPCA的AUC也只有0.988 1和0.991 4, 均低于LGD的0.991 8。6种算法中, LGD算法的ROC曲线最接

近左上角, 其他算法均在其下方, 验证了LGD算法融合数据空谱特征后探测精度显著提高。

不同算法在AVIRIS-II数据集上的检测结果如图4所示。可以看出, LRX、CRD基本没有探测到异常目标; LLaSMD和LSMAD算法虽可以探测出异常目标, 但形状非常模糊; GRX和LGD算法可以准确地探测出异常目标的位置和形状, 但GRX算法探测结果中包含大量的背景像素, 而LGD算法探测到的异常目标位置和形状清晰, 背景像素也较少。

6种探测算法的AUC条形图和ROC曲线如图5所示。可以看出, 在检测精度方面, LSMAD和LGD算法的AUC值均大于0.97, 且LGD精度最好。在该数据集上, 文献[28]所提的PTA (Prior-Based Tensor Approximation) 算法的AUC精度




图3 不同算法在AVIRIS-I数据集上的检测精度

Fig. 3 Detection accuracies of different algorithms on AVIRIS-I dataset




图4 不同算法在AVIRIS-II数据集上的检测结果

Fig. 4 Detection results on AVIRIS-II dataset obtained by different algorithms

为 0.970 8, 文献 [29] 所提的 LRR-EAS 算法的 AUC 精度为 0.983 2, 均低于 LGD 的 AUC 值 0.986 0。6 种算法中, 依然是 LGD 算法的 ROC 曲线最接近左上角, 其他算法得到的结果均在其 ROC 曲线下方。

不同算法在 ABU-urban-2 数据集上的检测结果如图 6 所示。可以看出, GRX、LRX、CRD、LRaSMD 和 LSMAD 算法探测到的异常目标都只有一部分, 且形状非常模糊; GRX 由于采用全局数据作为背景估计统计量, 检测出的异常目标相对比较多, 但并不全; 6 种算法中, 只有 LGD 算法能够准确地探测出所有异常目标的位置和形状, 背景像素干扰也较小。

6 种探测算法的 AUC 条形图和 ROC 曲线如图 7 所示。可以看出, 在检测精度方面, GRX、

CRD、LSMAD 和 LGD 的 AUC 值均大于 0.97, 且 LGD 精度为 0.999 1; 在 ROC 曲线中, 依然是 LGD 算法的 ROC 曲线最接近左上角, 其他算法均在其 ROC 曲线下方, 其中 GRX、CRD、LSMAD 的 ROC 曲线较为接近。

不同算法在 ABU-urban-4 数据集上的检测结果如图 8 所示。可以看出, LRX、CRD、LRaSMD 和 LSMAD 算法探测到的异常目标都只有一部分, 且形状非常模糊; GRX 和 LGD 算法探测出异常目标的位置和形状相对较为准确, 且背景像素的干扰也非常小。

6 种探测算法的 AUC 条形图和 ROC 曲线如图 9 所示。在检测精度方面, 可以看出, GRX、LSMAD 和 LGD 的 AUC 值均大于 0.97, 且 LGD 精度最好, 达到了 0.993 6; 6 种算法中, 依然是 LGD




图 5 不同算法在 AVIRIS-II 数据集上的检测精度

Fig. 5 Detection accuracies of different algorithms on AVIRIS-II dataset




图 6 不同算法在 ABU-urban-2 数据集上的检测结果

Fig. 6 Detection results on ABU-urban-2 dataset obtained by different algorithms




图 7 不同算法在 ABU-urban-2 数据集上的检测精度

Fig. 7 Detection accuracies of different algorithms on ABU-urban-2 dataset




图 8 不同算法在 ABU-urban-4 数据集上的检测结果

Fig. 8 Detection results on ABU-urban-4 dataset obtained by different algorithms




图 9 不同算法在 ABU-urban-4 上的检测精度

Fig. 9 Detection accuracies of different algorithms on ABU-urban-4 dataset

算法的 ROC 曲线最接近左上角, 其他算法均在其 ROC 曲线下方。

不同算法在 EI Segundo 数据集上的检测结果

如图 10 所示。可以看出, 6 种算法探测到的异常目标都只有一部分, 且探测出的异常目标形状非常模糊, 但 LGD 算法探测出的异常目标数量最

多, 形状也较为清晰。

6种探测算法的AUC条形图和ROC曲线如图11所示。可以看出, 在检测精度方面, GRX、LSMAD和LGD算法的AUC值均大于0.97, 且

LGD算法精度最好, 达到了0.991 0。6种算法中, 依然是LGD算法的ROC曲线最接近左上角, 其他算法均在其ROC曲线下方, 且LGD算法的ROC曲线显著优于其他算法。




图 10 不同算法在EI Segundo数据集上的检测结果

Fig. 10 Detection results on EI Segundo dataset obtained by different algorithms




图 11 不同算法在EI Segundo上的检测精度

Fig. 11 Detection accuracies of different algorithms on EI Segundo dataset

4 结论

本文所提的LGD算法通过构建全连接图, 建立了高光谱数据集空间位置与光谱信息之间的联系, 利用构图生成的拉普拉斯矩阵计算得到的总变差作为异常目标检测的评价函数, 实现了高光谱数据中的异常目标检测。与传统的异常检测算法相比, LGD算法不需要进行矩阵的逆运算, 将高光谱数据中的空间位置和光谱信息进行了联接。

实验结果表明, LGD算法在AVIRIS-I、AVIRIS-II、ABU-urban-2、ABU-urban-4、EI Segundo5种数据集上的AUC值分别为0.991 8、0.986 0、0.999 1、0.993 6、0.991 0, 其ROC曲线均在其他算法上方, 表明该算法在探测精度方面具有较大优势, 其性能明显优于其他算法。然而, 由于LGD算法在构图过程中采用的是全连接法, 导致图的结构相对复杂, 造成计算量增加。对此, 后续研究中可考虑采用 k 近邻法和 ε 近邻法构图, 以进一步优化算法的性能。

参考文献

- [1] SHIMONI M, HAELTERMAN R, PERNEEL C. Hyperspectral imaging for military and security applications: Combining myriad processing and sensing techniques[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2019, 7(2): 101-117.
- [2] GUO Q, CEN Y, ZHANG L F, et al. Hyperspectral anomaly detection based on spatial-spectral cross-guided mask autoencoder[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 9876-9889.
- [3] 刘嘉诚, 王爽, 刘伟华, 等. 显著性权重RX高光谱异常点检测[J]. *遥感学报*, 2019, 23(3): 418-430.
- LIU J C, WANG S, LIU W H, et al. Saliency weighted RX hyperspectral imagery anomaly detection[J]. *Journal of Remote Sensing*, 2019, 23(3): 418430.
- [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(10): 1760-1770.
- [5] 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.
- [6] MOLERO J M, GARZÓN E M, GARCÍA I, et al. 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.
- [7] GUO Q D, 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.
- [8] 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.
- [9] LI Z, ZHANG Y. Hyperspectral anomaly detection based on improved RX with CNN framework [C]//IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium. Piscataway, NJ, USA: IEEE, 2019: 2244-2247.
- [10] PADRÓN HIDALGO J A, PÉREZ-SUAY A, NAR F, et al. Efficient nonlinear RX anomaly detectors[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(2): 231-235.
- [11] REN L, ZHAO L Y, WANG Y L. A superpixel-based dual window RX for hyperspectral anomaly detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(7): 1233-1237.
- [12] LI W, DU Q. Collaborative representation for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(3): 1463-1474.
- [13] VAFADAR M, GHASSEMIAN H. Anomaly detection of hyperspectral imagery using modified collaborative representation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(4): 577-581.
- [14] 刘万军, 武小杰, 曲海成, 等. 改进协同表示的高光谱图像异常检测算法[J]. *计算机应用研究*, 2018, 35(12): 3824-3827, 3840.
- LIU W J, WU X J, QU H C, et al. Improved collaborative representation for hyperspectral imagery anomaly detection algorithm[J]. *Application Research of Computers*, 2018, 35(12): 3824-3827, 3840.
- [15] 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.
- [16] ZHAO C H, LI C, FENG S, et al. Enhanced total variation regularized representation model with endmember background dictionary for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5518312.
- [17] XIAO Q J, ZHAO L Y, CHEN S H, et al. Hyperspectral anomaly detection via enhanced 3DTV and sparse reweighted regularization[J]. *IEEE Geoscience and Remote Sensing Letters*, 2024, 21: 5508505.
- [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] LI L, LI W, DU Q, et al. Low-rank and sparse decomposition with mixture of gaussian for hyperspectral anomaly detection[J]. *IEEE Transactions on Cybernetics*, 2021, 51(9): 4363-4372.
- [20] DALLA MURA M, ATLI BENEDIKTSSON J,

- WASKE B, et al. Morphological attribute profiles for the analysis of very high resolution images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(10): 3747-3762.
- [21] LI K, LING Q, QIN Y, et al. Spectral-spatial deep support vector data description for hyperspectral anomaly detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5522316.
- [22] 刘忠雨, 李彦霖, 周洋. 深入浅出图神经网络: GNN原理解析[M]. 北京: 机械工业出版社, 2020.
- [23] 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 Geo-science and Remote Sensing, 2016, 54(3): 1376-1389.
- [24] KANG X D, ZHANG X P, LI S T, et al. Hyperspectral anomaly detection with attribute and edge-preserving filters[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(10): 5600-5611.
- [25] 张坤忠. 基于属性滤波和孤立森林的高光谱图像异常检测[D]. 长沙: 湖南大学, 2020.
- ZHANG K Z. Hyperspectral image anomaly detection with attribute filters and isolation forest[D]. Changsha: Hunan University, 2020.
- [26] SONG S Z, YANG Y X, ZHOU H X, et al. Hyperspectral anomaly detection via graph dictionary-based low rank decomposition with texture feature extraction[J]. Remote Sensing, 2020, 12(23): 3966.
- [27] PENG J J, WANG Y, ZHANG H Y, et al. Exact decomposition of joint low rankness and local smoothness plus sparse matrices[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(5): 5766-5781.
- [28] LI L, Li W, Qu Y, et al. Prior-based tensor approximation for anomaly detection in hyperspectral imagery[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(3): 1037-1050.
- [29] CHANG C I. Constrained energy minimization (CEM) for hyperspectral target detection: theory and generalizations[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5522921.
- (编辑: 于福兴)