

# 基于局部对比度和多向梯度的高光谱异常检测

武丽<sup>1,2</sup>, 徐星臣<sup>1,2</sup>, 王一安<sup>3</sup>, 任佳红<sup>1</sup>, 张嘉嘉<sup>4</sup>, 赵东<sup>1,2</sup>, 王新蕾<sup>1,2</sup>

(1. 南京信息工程大学 电子与信息工程学院, 江苏 南京 210044; 2. 无锡学院 电子信息工程学院, 江苏 无锡 214105;

3. 西安石油大学 电子工程学院, 陕西 西安 710071; 4. 西安电子科技大学 物理学院, 陕西 西安 710071)

**摘要:** 为了充分利用高光谱图像的空间和光谱信息, 并抑制图像中的噪声, 提出了一种基于局部对比度和多向梯度的高光谱异常检测方法。首先, 为利用局部光谱信息, 提出了一种局部对比度策略, 通过计算目标与背景之间的亮度差异, 获得光谱检测得分图。然后, 为了降低计算的复杂性, 引入了一种光谱融合降维技术对高光谱图像进行处理。此外, 提出了一种局部多向梯度特征方法, 旨在减少图像噪声和保留局部细节特征, 生成多向梯度检测得分图。最后, 通过融合两张得分图, 得到最终的异常结果图。实验结果表明, 在 4 个经典数据集上本文方法能够成功展示异常目标, 并且相较于其他 7 种方法, 其检测精度更高、虚警率更低。

**关键词:** 高光谱图像; 异常检测; 局部对比度; 光谱融合降维; 多向梯度特征

中图分类号: TP751.1 文献标志码: A 文章编号: 1001-8891(2025)05-0601-10

## Hyperspectral Anomaly Detection Based on Local Contrast and Multidirectional Gradients

WU Li<sup>1,2</sup>, XU Xingchen<sup>1,2</sup>, WANG Yian<sup>3</sup>, REN Jiahong<sup>1</sup>, ZHANG Jiajia<sup>4</sup>, ZHAO Dong<sup>1,2</sup>, WANG Xinlei<sup>1,2</sup>

(1. School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210044,

China; 2. School of Electronics and Information Engineering, Wuxi University, Wuxi 214105, China;

3. School of Electronics and Information Engineering, Xi'an Shiyou University, Xi'an 710071, China;

4. School of Physics, Xi'an University of Electronic Science and Technology, Xi'an 710071, China)

**Abstract:** To fully utilize the spatial and spectral information of hyperspectral images and suppress image noise, a hyperspectral anomaly detection method based on local contrast and multidirectional gradient analysis is proposed. First, to leverage local spectral information, a local contrast strategy is introduced, generating a spectral detection score map based on the brightness difference between the target and the background. Then, to reduce computational complexity, a spectral fusion-based dimensionality reduction technique is proposed to process hyperspectral images. In addition, a local multidirectional gradient feature method is proposed to reduce image noise, retain local detail features, and generate a multidirectional gradient detection score map. Finally, the anomaly result map is obtained by fusing the spectral and gradient-based score graphs. Experimental results on four classical datasets demonstrate that the proposed method can successfully display abnormal targets in the result graph, achieving higher detection accuracy and lower false alarm rates compared to seven existing methods.

**Key words:** hyperspectral image, anomaly detection, local contrast, spectral fusion dimensionality reduction, multi-directional gradient features

## 0 引言

高光谱成像 (Hyperspectral Imagery, HSI) 是一个三维的数据立方体<sup>[1]</sup>, 它具有光谱波段宽、光谱分

收稿日期: 2024-04-28; 修订日期: 2024-05-30。

作者简介: 武丽 (1983-), 女, 江苏东台人, 硕士, 副教授, 硕导, 主要研究方向为信号处理、模式识别, E-mail: wuli@cwxtu.edu.cn。

通信作者: 王新蕾 (1980-), 女, 山东潍坊人, 博士, 讲师, 硕导, 主要研究方向为机器学习、模式识别, E-mail: wangxinlei@cwxtu.edu.cn。

基金项目: 国家自然科学基金 (2105258); 江苏省自然科学基金 (BK20210064); 无锡市创新创业资金“太湖之光”科技攻关计划 (基础研究) 项目 (K20221046); 无锡学院人才启动基金 (2021r007)。

分辨率高和空间分辨率低的特点。高光谱异常检测<sup>[2-4]</sup>作为高光谱遥感探测领域的一个分支,不需要先验信息即可实现对特定目标的检测,本质上是一个二分类问题<sup>[5]</sup>,目的是从背景中区分异常目标,广泛应用于战场侦察<sup>[6]</sup>、食品安全<sup>[7]</sup>、环境监测<sup>[8]</sup>等领域。

在高光谱图像中,异常目标区域与背景区域之间具有较大对比度<sup>[9]</sup>,即显著性较强。现有高光谱异常检测算法可大致分为3类:基于统计的算法、基于矩阵分解的算法和基于表达的算法。Reed和Yu提出的全局RX算法<sup>[10]</sup>(Global Reed-Xiaoli, GRX)是基于统计的基准算法,GRX假设背景满足多元高斯分布,通过计算待测像素与背景像素之间的马氏距离来判断异常。然而,在实际应用中,高光谱数据的背景十分复杂,难以符合正态分布假设,异常像素的干扰容易导致检测结果的不准确。因此,为了克服GRX算法的局限性,衍生了多种改进方法。LRX算法<sup>[11]</sup>(Local RX, LXR)采用局部统计模型,提高检测概率。WRX算法<sup>[12]</sup>(Weighted RX, WRX)通过给不同的背景样本赋予不同权重,减少噪声对背景的干扰。KRX算法<sup>[13]</sup>(Kernel RX, KRX)将数据映射到高维空间,利用RX算法对映射后的数据进行检测。

基于矩阵分解的检测算法,通常把HSI作为矩阵或者张量进行分解,然后检测其中的异常目标。Liu等人<sup>[14]</sup>提出的低秩表示(Low-Rank Representation, LRR)算法,通过把高光谱数据分为低秩的背景矩阵和稀疏的异常矩阵,利用数据的稀疏性和背景的低秩性,有效地分离异常目标和背景。Li等<sup>[15]</sup>使用高阶鲁棒主成分分析(Robust Principal Component Analysis, RPCA)把HSI数据划分为低秩张量和稀疏张量两个部分,然后对低秩张量进一步分解,稀疏张量用于估计噪声,对得到的核张量进行解混和异常检测。然而,RPCA算法数据分布在一个单一子空间中,而实际情况下,HSI中的混合像元分布在多元子空间中,导致检测效率受到了一定程度的限制。

基于表达的算法主要分为基于协同表示的检测器(Collaborative Representation-based Detector, CRD)和基于稀疏表示的检测器(Sparse Representation-based Detector, SRD)。Li等人<sup>[16]</sup>在高光谱异常检测中引入协同表示的思想,认为背景像素可以由其周围像素表示,而异常像素则无法由周围像素准确表示。Chen等人<sup>[17]</sup>提出的稀疏表示方法通过构建一个

背景字典,利用这个字典最小化重构误差来检测无法被字典表示的异常目标,但是直接从高光谱图像中获得字典的结构存在不确定性,字典中可能只包含背景像素的光谱信息,导致虚警率高。

针对高光谱数据维度高、信息冗余等特点,以及现有方法中光谱信息和梯度信息利用率不足等问题,本文提出了基于局部对比度和多向梯度的高光谱异常检测(Hyperspectral anomaly detection based on local contrast and multidirectional gradients, HLC-MDG)。本文的创新点总结如下:①提出一种局部光谱对比度的方法,充分利用了光谱信息,能更好地突出目标与背景之间的亮度差异。②提出了一种光谱融合降维方法对高光谱图像进行降维,减少了数据维度和冗余信息,与常用的降维方法相比,能够提高检测精度。③提出了一种局部多向梯度特征方法,充分利用图像的梯度信息,能够抑制噪声并更好地保留图像中的细节和局部特征。

## 1 算法原理

HLC-MDG方法的总流程图如图1所示,该方法主要分为两个部分:高光谱局部对比度(HLC)和多向梯度特征(MDG)。在HLC部分,使用光谱角距离<sup>[18]</sup>公式得到光谱特征图。接着,利用中心块形心光谱角距离、背景块中的最大光谱角距离均值以及背景块的光谱角距离均值计算获取光谱检测得分。在MDG部分,使用光谱融合降维技术得到光谱融合特征。然后,利用梯度均方根、最小梯度值和最大梯度值获取梯度检测得分。最后,融合两种检测得分,获得输出结果图。

### 1.1 局部光谱对比度

如图1所示,高光谱图像的局部窗口W被分为9个网格块。中心块 $B_0$ 代表测试块,而周围的8个网格块则视为背景块。假设异常目标能够被中心块 $B_0$ 完全覆盖,与此同时,其他背景块则被细分为8个不同方向,以便精确地描述中心块 $B_0$ 与周围背景块之间的关系。周围背景块的平均光谱曲线可以由以下公式计算:

$$A = \frac{1}{N} \sum_{i=1}^N a_i \quad (1)$$

式中:N表示 $B_1 \sim B_8$ 的像素点的数量;  $a_i$ 表示背景块中第i个位置处的光谱曲线;  $\Sigma(\cdot)$ 表示求和操作。

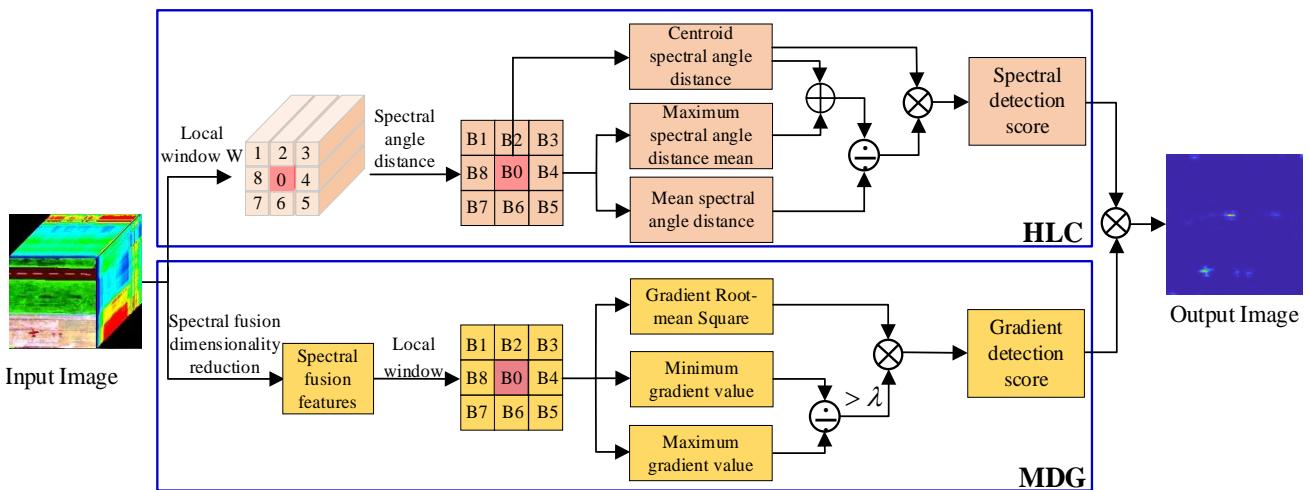


图1 HLC-MDG 方法的总流程图

Fig.1 Overall flow chart of the HLC-MDG method

平均光谱曲线与局部窗口  $W$  中的每根光谱曲线做光谱角距离, 得到光谱角距离矩阵  $\mathbf{D}$  为:

$$\mathbf{D} = \left\{ d_i \mid d_i = \arccos \left( \frac{\mathbf{A} \cdot \mathbf{w}_i}{\|\mathbf{A}\| \cdot \|\mathbf{w}_i\|} \right) \right\} \quad (2)$$

式中:  $\mathbf{w}_i$  表示局部窗口  $W$  中第  $i$  个像素的光谱曲线;  $\arccos(\cdot)$  表示求反余弦操作;  $\cdot$  表示求向量内积操作;  $\|\cdot\|$  表示求向量的 2 范数操作。

假设在中心块  $B_0$  中包含所有的异常目标, 通过比较周围背景块的光谱角距离值, 可以判断中心块  $B_0$  中哪些可能是异常像素。选择光谱角距离最大值  $L_{\max}$  所对应的像素作为异常像素, 其表达式为:

$$L_{\max} = \max(d_j^0) \quad (3)$$

式中:  $d_j^0$  表示中心块  $B_0$  中第  $j$  个位置处的光谱角距离值。

在局部窗口  $W$  中, 背景区域由周围 8 块背景块组成, 背景块中光谱角距离的均值  $m_p$  可以很好地表示背景区域的特征。其表达式为:

$$m_p = \frac{\sum d_j^p}{N_p} \quad (4)$$

式中:  $d_j^p$  表示第  $p$  块背景块中第  $j$  个位置处的光谱角距离值;  $N_p$  表示第  $p$  块背景块中的像素数。

在HSI中, 异常目标通常在局部区域中更容易被检测。受人类视觉系统<sup>[19]</sup>的启发, 对比度是衡量目标显著性的重要参数, 异常目标的对比度通常比周围背景高。因此, 定义局部光谱对比度来表示目标与背景之间的显著性差异:

$$C_i = \begin{cases} 0 & L_{\max} - M_p^{\max} \leq \alpha M_p \\ \frac{L_{\max} - M_p^{\max}}{m_p} & L_{\max} - M_p^{\max} > \alpha M_p \end{cases} \quad (5)$$

式中:  $M_p^{\max}$  表示第  $p$  个背景块中的最大光谱角距离均值。本实验中  $\alpha$  取 0.05, 可以减少噪声的影响。

考虑到异常像素与平均背景像素的光谱角距离通常大于背景像素与平均背景像素的光谱角距离, 筛选区分度更强的对比度, 选择  $C_i$  中的最小值  $c$  作为光谱增强系数, 最小值  $c$  的表达式为:

$$c = \min(C_i) \quad (6)$$

通过选择最佳的光谱增强系数, 可以有效提升目标的清晰度, 从而提升整体视觉效果。测试像素的光谱检测得分  $u$  表达式为:

$$u = c \times L_0 \quad (7)$$

式中:  $L_0$  表示形心光谱角距离值。

## 1.2 光谱融合降维

为提高异常目标与背景的可分离性以及保证降维结果的准确性, 本文提出了光谱融合降维技术, 提取两条光谱曲线来表示异常目标的光谱曲线, 即区域光谱曲线和子块光谱曲线。区域光谱曲线是局部窗口的平均光谱曲线, 提供了异常目标和背景光谱的总体特性, 而子块光谱曲线是中心块  $B_0$  的平均光谱曲线, 提供了更精确的异常目标光谱特性。通过这两条光谱曲线的融合, 能更进一步表示异常目标的光谱信息, 并方便后续对图像进行特征提取。

计算局部窗口中的平均值获得区域光谱曲线  $B_g$  为:

$$B_g = \frac{1}{K} \sum_{i=1}^K w_i \quad (8)$$

式中:  $K$  表示局部窗口内的所有像素点数量;  $\Sigma(\cdot)$  表示求和操作。

由于目标的形状和大小具有不规则性, 子块光谱曲线通过统计的方法得到, 以更好地表示目标。对中心块  $B_0$  中所有像素灰度值进行灰度范围标号, 灰度范围内的总数目为  $Y$ , 灰度范围索引为  $r \in \{0, \dots, Y-1\}$ , 中心块  $B_0$  中第  $i$  个波段的第  $j$  个像素灰度值  $T_i^j$  属于的灰度范围标号为  $R(i,j)$ , 计算公式表示为:

$$R(i,j) = \text{floor}(Y \times T_i^j) \bmod Y \quad (9)$$

式中:  $(i,j)$  表示第  $i$  个波段的第  $j$  个像素;  $\text{floor}(\cdot)$  表示向下取整操作;  $\bmod(\cdot)$  表示取余操作, 在本实验中, 令  $Y=10$ 。

在完成每个灰度值的分组后, 将与灰度范围标号相等的灰度值放入对应的灰度范围内, 记录光谱强度和该范围内像素的数量, 其他灰度值则不计入。

$T_i^j$  的光谱强度特征  $I_r(i,j)$  计算如下:

$$I_r(i,j) = \begin{cases} T_i^j & r = R(i,j) \\ 0 & \text{otherwise} \end{cases} \quad (10)$$

$T_i^j$  的数量特征  $P_r(i,j)$  计算如下:

$$P_r(i,j) = \begin{cases} 1 & r = R(i,j) \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

在同一个波段中的光谱强度特征  $I_r(i)$  和数量特征  $P_r(i)$  计算如下:

$$I_r(i) = \sum_{j=1}^K I_r(i,j) \quad (12)$$

$$P_r(i) = \sum_{j=1}^K P_r(i,j) \quad (13)$$

对于中心块  $B_0$  来说, 异常目标通常会占据大量空间, 而背景占据少量空间, 因此异常目标会集中分布在  $P_r(i)$  最大的那一个灰度范围。故计算每个波段中具有代表性的像素, 得到子块光谱曲线  $B_l$  为:

$$B_l = \left\{ B_{li} \left| B_{li} = \frac{I_{r_{\max}}(i)}{\max(P_r(i))} \right. \right\} \quad (14)$$

式中:  $B_{li}$  表示  $B_l$  在第  $i$  个波段上的子块光谱值;  $I_{r_{\max}}(i)$  表示  $\max(P_r(i))$  所对应的光谱强度;  $\max(\cdot)$  表示最大值操作。

最终光谱  $B_f$  是由一部分区域光谱曲线  $B_g$  与一部分子块光谱曲线  $B_l$  加权融合成的, 其表达式为:

$$B_f = \mu_r \times B_g + (1 - \mu_r) \times B_l \quad (15)$$

式中:  $\mu_r$  是权重参数; 由于异常目标在中心块  $B_0$  中占据大量空间, 最终光谱曲线就更加偏向于子块光谱曲线, 所以子块光谱曲线赋予更大的权重, 本实验中  $\mu_r$  取 0.3。

最后计算降维之后的高光谱图像  $Y$ , 其表达式为:

$$Y = B_f \otimes H \quad (16)$$

式中:  $\otimes$  表示朴素相关操作;  $H$  表示原始高光谱图像。

### 1.3 多向梯度特征

降维后的高光谱图像可以被视为二维离散函数, 图像的梯度<sup>[20]</sup>理解成二维离散函数的导数。对于每个像素, 其梯度值  $\theta$  是由 8 个方向的 8 个分量组成。每个方向上的梯度值  $\theta_n$  是中心块  $B_0$  与周围 8 块  $B_n$  ( $n=1, \dots, 8$ ) 的特征值差:

$$\theta = [\theta_1, \dots, \theta_8] \quad (17)$$

$$\theta_n = \max(F_{\beta_0} - F_{\beta_n}, 0), \quad n = 1, \dots, 8 \quad (18)$$

式中:  $F_{\beta_0}$  是中心块  $B_0$  的特征值均值;  $F_{\beta_n}$  是周围 8 块的特征值均值。 $F_{\beta_0}$  应大于  $F_{\beta_n}$ , 因此, 去除  $\theta_n < 0$  的部分可以有效抑制杂波和噪声的干扰。

异常目标的梯度通常都表现出向中心聚合的趋势, 而边缘背景的梯度通常都向一个方向发散, 相比之下平滑的背景的梯度则相对较小且杂乱。鉴于这些特点, 可以将梯度特征融入到异常检测当中, 丢弃杂乱的边缘。因此, 梯度检测得分图  $v$  可以通过以下公式计算:

$$v_{\max} = \max_{n=1}^8 (\theta_n) \quad (19)$$

$$v_{\min} = \min_{n=1}^8 (\theta_n) \quad (20)$$

$$v = \begin{cases} \frac{1}{8} \sum_{n=1}^8 \theta_n^2 & \frac{v_{\min}}{v_{\max}} > \lambda \\ 0 & \text{otherwise} \end{cases} \quad (21)$$

式中:  $\lambda$  的取值范围是  $(0, 1)$ , 本实验中  $\lambda$  取 0.2。

通过从左到右、从上到下遍历整张图像, 最终的检测结果图  $Z$  由光谱检测总得分图  $U$  和梯度检测总得分图  $V$  融合得到:

$$Z = U \times V \quad (22)$$

## 2 结果与讨论

在本章中, 对本文所提出的方法在 4 个真实数据集上与 7 种最新方法进行性能和优越性比较。比较方法包括: 基于全局 RX 的检测器 (Global Reed-

Xiaoli, GRX)<sup>[10]</sup>、基于局部 RX 的检测器 (Local RX, LRX)<sup>[11]</sup>、基于无稀疏正则项约束的异常检测器 (Low-Rank and Sparse Representation, LRASR)<sup>[21]</sup>、基于低秩和稀疏矩阵分解的马氏距离方法 (Low-Rank and Sparse Matrix Decomposition-Based Mahalanobis Distance, LSMAD)<sup>[22]</sup>、基于协同表示的异常检测器 (Collaborative Representation-based Detector, CRD)<sup>[16]</sup>、图和总变分正则化低秩表示 (Graph and Total Variation Regularized Low-Rank Representation, GTVLRR)<sup>[23]</sup>、抗噪声分层互不相干诱导判别 (Antinoise Hierarchical Mutual-Incoherence-Induced Discriminative, AHMID)<sup>[24]</sup>。首先, 描述实验数据集和评估指标。接着, 对 7 种对比方法和 HLC-MDG 方法的参数设置进行详细分析。然后, 对 4 个数据集的实验结果进行全面的比较和深入分析。最后, 进一步讨论所提出方法的结构有效性。

## 2.1 实验数据集

实验所用数据集的伪彩色图像和地面真实图像如图 2 所示。

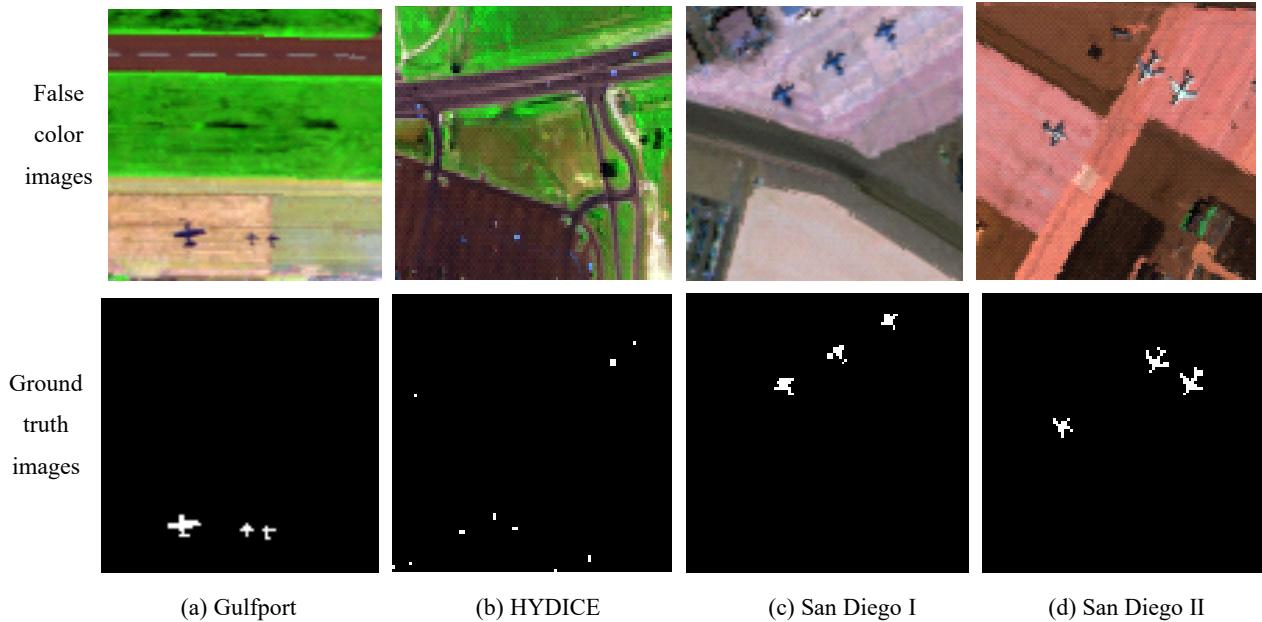


图 2 实验数据集的伪彩图和真实图

Fig.2 False color images and ground-truth images of the experimental data set

## 2.2 评估指标

为了对实验结果进行定量分析, 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<sup>[29]</sup>。ROC 曲线是通过在不同阈值  $\tau$  下, 基于真值图的真阳性率 (TPR) 和假阳性率 (FPR) 来绘制的, 该指标可以从检测精度 ( $P_D$ ) 和虚警率 ( $P_F$ ) 两个方面来评估检测性能。AUC 是 ROC 曲线下的面积, 面积越大表示检测性能越好。

**Gulfport:** 如图 2(a)所示, 该数据集为美国格尔夫波特<sup>[25]</sup>的一个场景。高光谱图像的大小为  $100 \times 100$  像素, 具有 191 个波段, 光谱范围为  $0.4 \sim 2.5 \mu\text{m}$ 。异常目标为图中的 3 架飞机。

**HYDICE:** 如图 2(b)所示, 该数据集是通过高光谱数字图像收集实验传感器从城市地区<sup>[26]</sup>收集的。空间分辨率为 2 m, 原始大小为  $400 \times 400$  像素, 光谱分辨率为  $7 \sim 14 \text{ nm}$ 。在这项研究中, 使用了  $80 \times 100$  的像素, 去除吸水带和低信噪比带后得到 162 个波段。

**San Diego I:** 如图 2(c)所示, 该数据集是美国加利福尼亚州的圣地亚哥机场区域<sup>[27]</sup>。空间分辨率为 20 m, 光谱分辨率为 10 nm。原始的  $100 \times 100$  像素图像包含了 224 个光谱波段, 经过处理后剩余 189 个波段。异常目标被认为是 3 架飞机。

**San Diego II:** 如图 2(d)所示, 该数据集是美国加利福尼亚州的圣地亚哥机场区域<sup>[28]</sup>。空间分辨率为 3.5 m, 该高光谱影像像素为  $400 \times 400$ , 最初的波段数为 224 个, 去除无用的波段后保留 189 个波段。异常目标被认为是 3 架飞机。

## 2.3 参数分析

本节对算法性能密切相关的光谱对比度系数  $\alpha$ 、加权融合系数  $\mu_r$  和梯度特征系数  $\lambda$  进行参数分析。为分析  $\alpha$ 、 $\mu_r$  和  $\lambda$  值变化时对实验结果的影响, 本文采用控制变量法, 即固定其中两个参数, 只改变一个参数来分析每个参数的变化对实验结果的影响。不同参数对 HLC-MDG 方法性能的影响如图 3 所示, 内外窗尺寸对 HLC-MDG 方法性能的影响如图 4 所示。

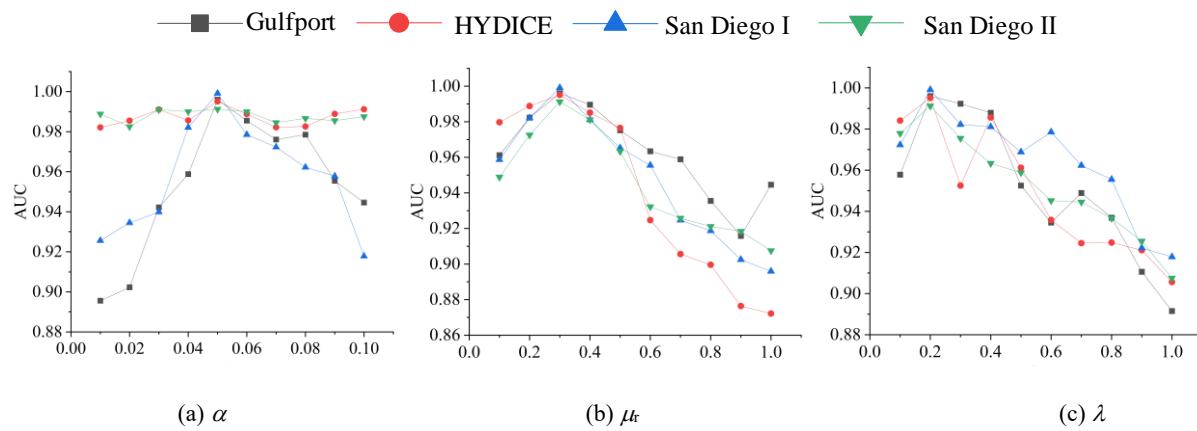


图3 不同参数对 HLC-MDG 方法性能的影响

Fig.3 Effect of different parameters on the performance of HLC-MDG method

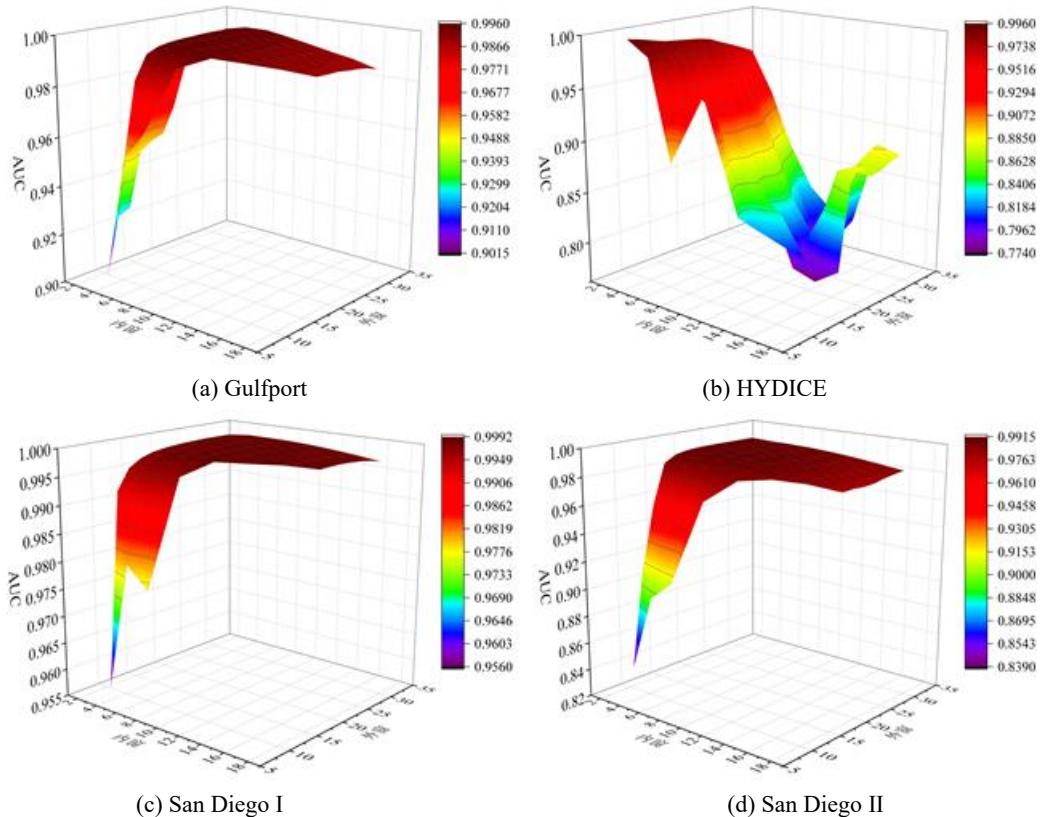


图4 内外窗尺寸对 HLC-MDG 方法性能的影响

Fig.4 Effect of inner and outer window size on the performance of HLC-MDG method

图3(a)为AUC值随 $\alpha$ 值变化的曲线。固定梯度特征系数 $\lambda$ 和加权融合系数 $\mu_r$ ，在HYDICE和San Diego II数据集上保持相对不变的趋势，并在其他数据集上 $\alpha$ 为0.05时显示最佳AUC值。

图3(b)为AUC值随 $\mu_r$ 值变化的曲线。固定光谱对比度系数 $\alpha$ 和梯度特征系数 $\lambda$ ，在4个数据集上总体上呈现先上升再下降的趋势，并在 $\mu_r$ 为0.3时显示最佳AUC值。

图3(c)为AUC值随 $\lambda$ 值变化的曲线。固定光谱对比度系数 $\alpha$ 和加权融合系数 $\mu_r$ ，在San Diego II数据集

上呈现先上升再下降的趋势，在其他数据上有上升下降，再上升再下降的趋势，并在 $\lambda$ 为0.2时显示最佳AUC值。

因此，经验证， $\alpha$ 一般取0.05， $\mu_r$ 一般取0.3， $\lambda$ 一般取0.2时，实验结果最佳。

如图4所示，在Gulfport、San Diego I和San Diego II数据集上，内窗外尺寸较大时显示最佳AUC值，而HYDICE数据集在内窗外尺寸较小时取得最佳AUC值。

## 2.4 实验结果

在本节中, 分析了 HLC-MDG 的检测性能, 并与 7 种最先进的检测方法(包括 GRX<sup>[10]</sup>、LRX<sup>[11]</sup>、LRASR<sup>[21]</sup>、LSMAD<sup>[22]</sup>、CRD<sup>[16]</sup>、GTVLRR<sup>[23]</sup> 和 AHMID<sup>[24]</sup>) 进行比较。所有方法在不同数据集上的检测结果如图 5 所示。

如图 5(a) 所示, 在 Gulfport 数据集上, CRD 方法未能检测到目标。LRX 方法虽然检测出部分目标, 但存在误检现象。其他方法则检测出大量的噪声或背景。HLC-MDG 方法在背景区域有较低的误检率, 因此检测效果比其他方法好。

如图 5(b) 所示, 在 HYDICE 数据集上, LRX 和 HLC-MDG 方法对异常目标的检测效果更好, 但是 LRX 方法存在漏检目标的问题。其他方法虽然能检测出目标, 但是背景未能去除干净。

如图 5(c) 所示, 在 San Diego I 数据集上, GRX、LRX 和 CRD 方法均未能检测出目标。其他方法的背景区域不够干净。HLC-MDG 方法检测效果最佳, 既能精确地检测出异常目标, 又能更好地抑制背景噪声。

如图 5(d) 所示, 在 San Diego II 数据集上, LRX 方法检测出的目标不清晰。HLC-MDG 方法能清晰检

测出目标, 但是存在一定的误检率。与其他方法相比, HLC-MDG 方法的综合表现仍然较好。

从主观评价的角度来看, 与 7 种流行算法相比, 所提出的 HLSC-MDGF 方法的检测效果更优。对于异常目标, HLC-MDG 方法漏检率更低, 异常目标区域与背景区域的对比度更高, 并且误检率较少。

为了进一步证明 HLC-MDG 方法的有效性, 用 ROC 指标评估性能。如图 6 所示的是 4 个数据集上的 ROC 曲线( $P_D, P_F$ ),  $AUC_{(D,F)}$  对应的值如表 1 所示, 其值越大表示性能越好。红色曲线表示 HLC-MDG 方法。在 Gulfport 和 San Diego I 数据集中, HLC-MDG 方法的曲线位于最上方, 包含的面积也是最大的。在 HYDICE 和 San Diego II 数据集中, HLC-MDG 方法的曲线虽然不是最佳, 但非常接近最佳方法。在表 1 中, 用粗体标记了 4 个数据集上的最佳  $AUC_{(D,F)}$  值。可以发现, 在 Gulfport、HYDICE 和 San Diego I 数据集中, HLC-MDG 方法都达到最佳值, 分别是 0.9960, 0.9951 和 0.9991。在 San Diego II 数据集中, 虽然没有达到最佳值, 但是 HLC-MDG 方法的  $AUC_{(D,F)}$  值是 0.9912, 与最佳  $AUC_{(D,F)}$  值相差 0.0045。

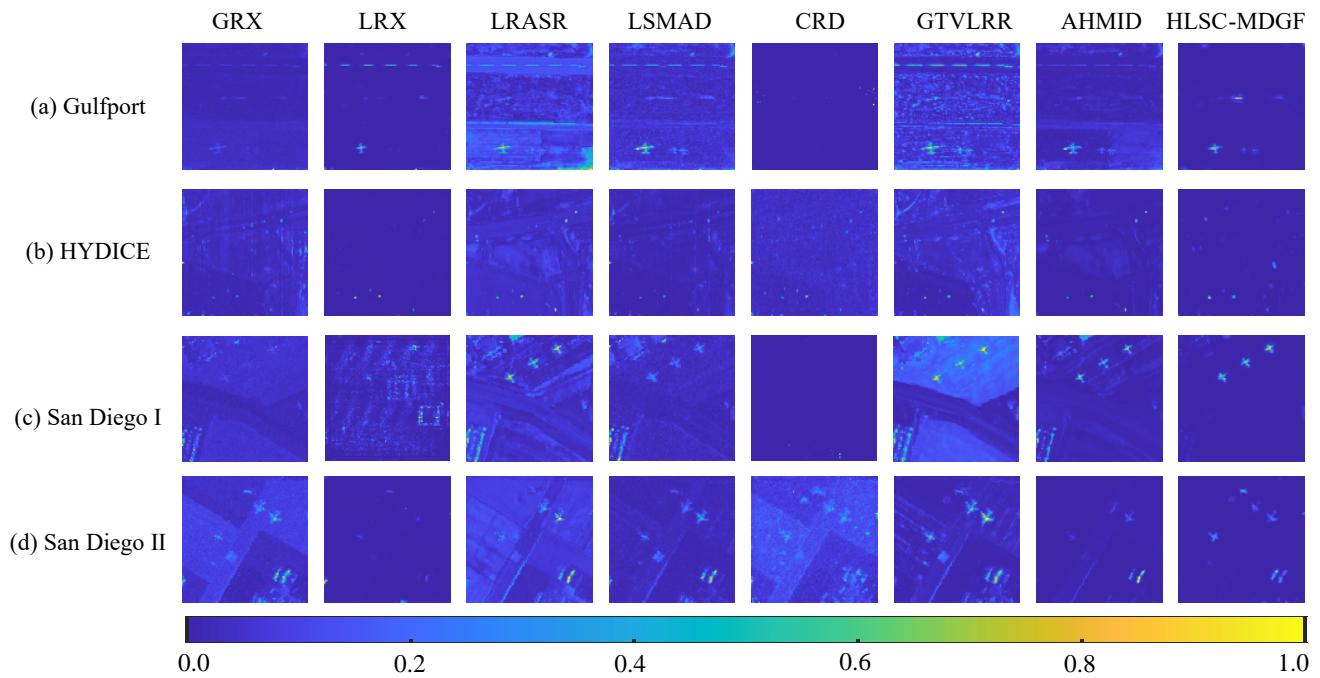


图 5 不同算法对 4 个数据集的检测结果

Fig.5 Detection results of different algorithms on four data sets

如图 7 所示的是 4 个数据集上的 ROC 曲线( $P_D, \tau$ ),  $AUC_{(D,\tau)}$  对应的值如表 2 所示, 其值越大表示性能越好。红色曲线表示所提出的方法。在 4 个数据集中, HLC-MDG 方法的表现均处于前列。表 2 中用粗体显示 4 个数据集上的最佳  $AUC_{(D,\tau)}$  值。可以发现,

在 HYDICE 数据集中, LRASR 方法的表现最佳, HLC-MDG 方法的  $AUC_{(D,\tau)}$  值比 LRASR 方法低 0.1171, 位于第二。在 San Diego I 数据集中 HLC-MDG 方法效果最好。在 Gulfport 和 San Diego II 数据集中, GTVLRR 方法表现最佳, HLC-MDG 方法的

$AUC_{(D,\tau)}$ 值比 GTVLRR 方法的  $AUC_{(D,\tau)}$  值分别低 0.0578 和 0.1779。

如图 8 所示的是 4 个数据集上的 ROC 曲线( $P_F$ ,  $\tau$ ), 对应的值如表 3 所示, 它的值越小表示背景抑制效果越好。红色曲线表示 HLC-MDG 方法。在 Gulfport、HYDICE 和 San Diego II 数据集中的结果明显优于其他方法, 而在 San Diego II 数据集上 HLC-

MDG 方法的曲线处于中间位置。在表 3 中, 用粗体显示四个数据集上的最佳  $AUC_{(F,\tau)}$  值。可以发现, HLC-MDG 方法在 Gulfport、HYDICE 和 San Diego II 数据集上达到了最佳值。尽管在 San Diego II 数据集中没有达到最佳值, 但是 HLC-MDG 方法的  $AUC_{(F,\tau)} = 0.0037$  非常接近 CRD 方法的最佳值  $AUC_{(F,\tau)} = 0.0023$ , 位于第二。

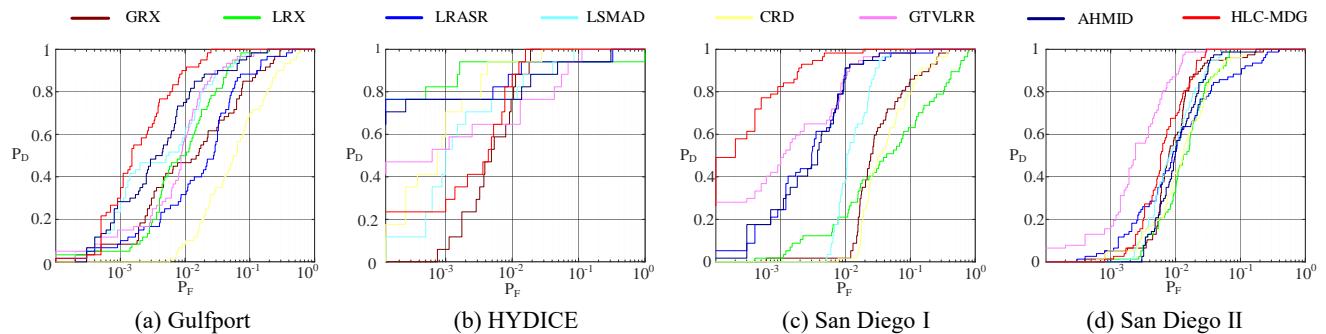


图 6 四个数据集上不同算法的 ROC 曲线 ( $P_D, P_F$ )

Fig.6 ROC curves of different algorithms on four data sets ( $P_D, P_F$ )

表 1 四个数据集上不同算法的  $AUC_{(D,F)}$  值

Table 1  $AUC_{(D,F)}$  values of different algorithms on four datasets

Dataset	Method							
	GRX	LRX	LRASR	LSMAD	CRD	GTVLRR	AHMID	HLSC-MDGF
Gulfport	0.9525	0.9810	0.9563	0.9864	0.8862	0.9843	0.9857	<b>0.9960</b>
HYDICE	0.9931	0.9850	0.9788	0.9902	0.9811	0.9817	0.9770	<b>0.9951</b>
San Diego I	0.9411	0.9748	0.9859	0.9830	0.9298	0.9943	0.9928	<b>0.9991</b>
San Diego II	0.9832	0.9807	0.9661	0.9870	0.9788	<b>0.9957</b>	0.9845	0.9912

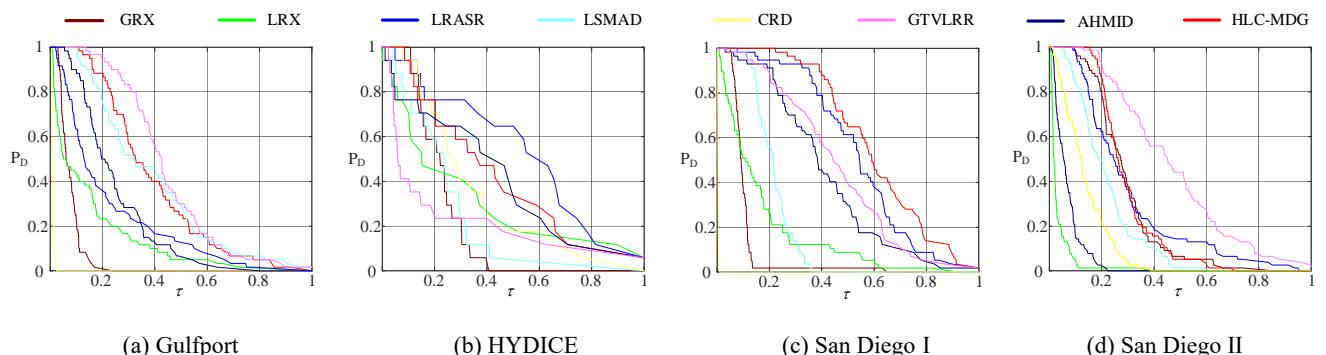


图 7 四个数据集上不同算法的 ROC 曲线 ( $P_D, \tau$ )

Fig.7 ROC curves of different algorithms on four data sets ( $P_D, \tau$ )

表 2 四个数据集上不同算法的  $AUC_{(D,\tau)}$  值

Table 2  $AUC_{(D,\tau)}$  values of different algorithms on four datasets

Dataset	Method							
	GRX	LRX	LRASR	LSMAD	CRD	GTVLRR	AHMID	HLSC-MDGF
Gulfport	0.0736	0.1447	0.2174	0.3797	0.0093	<b>0.4438</b>	0.2436	0.3860
HYDICE	0.2189	0.3031	<b>0.5314</b>	0.2337	0.3384	0.2166	0.3987	0.4143
San Diego I	0.1017	0.1670	0.5425	0.2141	0.0039	0.4536	0.4114	<b>0.6080</b>
San Diego II	0.2889	0.0316	0.3007	0.2136	0.2333	<b>0.4717</b>	0.0657	0.2938

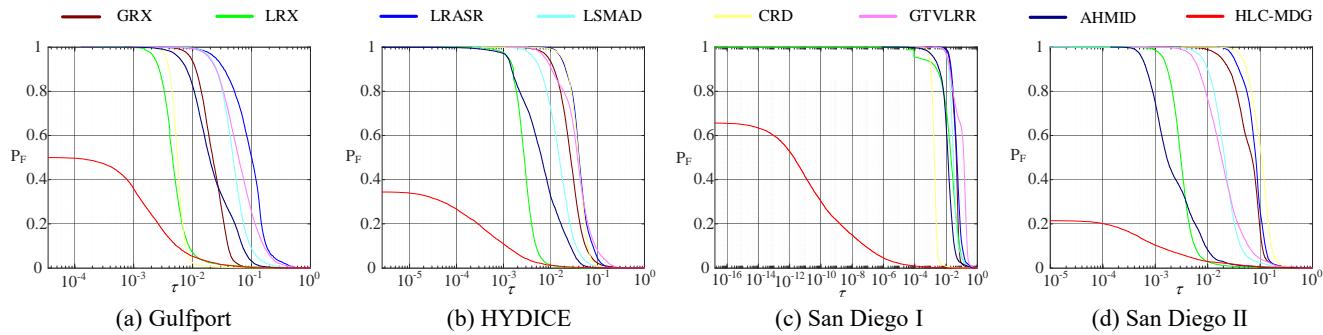


图 8 四个数据集上不同算法的 ROC 曲线( $P_F, \tau$ )

Fig.8 ROC curves of different algorithms on four data sets ( $P_F, \tau$ )

表 3 四个数据集上不同算法的  $AUC_{(F, \tau)}$  值

Table 3  $AUC_{(F, \tau)}$  values of different algorithms on four datasets

Dataset	Method							
	GRX	LRX	LRASR	LSMAD	CRD	GTVLRR	AHMID	HLSC-MDGF
Gulfport	0.0248	0.0076	0.1113	0.0587	0.0063	0.0823	0.0317	<b>0.0032</b>
HYDICE	0.0331	0.0032	0.0466	0.0195	0.0420	0.0471	0.0106	<b>0.0024</b>
San Diego I	0.0470	0.0338	0.0627	0.0404	<b>0.0023</b>	0.1263	0.0212	0.0037
San Diego II	0.0714	0.0046	0.0855	0.0281	0.1110	0.0307	0.0059	<b>0.0032</b>

## 2.5 消融实验

在本节中, 分析局部光谱对比度和多向梯度特征对最终检测结果的影响, 通过 AUC 分数对所有数据集进行了消融研究。

为了验证局部光谱对比度 (Local spectral contrast, LSC) 的有效性, HLC-MDG 方法在有和没有 LSC 的情况下在 4 个数据集上进行 AUC 值对比, 结果如表 4 所示。采用 LSC 方法在 4 个数据集上  $AUC_{(D,F)}$  值有明显的提升, 分别提升了 0.272, 0.208, 0.188 和 0.187。

表 4 HLC-MDG 中有无 LSC 的  $AUC_{(D,F)}$  值

Table 4  $AUC_{(D,F)}$  values of HLC-MDG with and without LSC

Method	$AUC_{(D,F)}$			
	Gulfport	HYDICE	San Diego I	San Diego II
+LSC	0.9960	0.9951	0.9991	0.9912
-LSC	0.9688	0.9743	0.9803	0.9725

为了验证光谱融合降维 (Spectral fusion dimensionality reduction, SFRD) 的有效性, HLC-MDG 方法采用 SFRD 与主成分分析 (Principal Component Analysis, PCA) 以及特征选择 (Feature Selection, FS) 这 3 种降维方法在 4 个数据集上进行了  $AUC_{(D,F)}$  值对比, 结果如表 5 所示。采用 SFRD 的 AUC 值均优于其他两种降维方法。

为了验证局部多向梯度对比度 (Local multi-directional gradient contrast, LMGC) 的有效性, HLC-MDG 方法在有和没有 LMGC 的情况下在 4 个

数据集上进行  $AUC_{(D,F)}$  值对比, 结果如表 6 所示, 对于 Gulfport 和 HYDICE 数据集, 采用 LMGC 分别能提升 0.121 和 0.108; 对于 San Diego I 和 San Diego II 数据集, 效果不明显, 仅分别提升 0.0088 和 0.006。

表 5 SFRD 和两种常用降维方法的  $AUC_{(D,F)}$  值

Table 5  $AUC_{(D,F)}$  values of SFRD and two commonly used dimensionality reduction methods

Method	$AUC_{(D,F)}$			
	Gulfport	HYDICE	San Diego I	San Diego II
SFRD	0.9960	0.9951	0.9991	0.9912
PCA	0.9885	0.9847	0.9922	0.9895
FS	0.9879	0.9920	0.9930	0.9866

表 6 HLC-MDG 中有无 LMGC 的  $AUC_{(D,F)}$  值

Table 6  $AUC_{(D,F)}$  values of HLC-MDG with and without LMGC

Method	$AUC_{(D,F)}$			
	Gulfport	HYDICE	San Diego I	San Diego II
+LMGC	0.9960	0.9951	0.9991	0.9912
-LMGC	0.9839	0.9843	0.9903	0.9852

## 3 结论

本文提出了基于局部对比度和多向梯度的高光谱异常检测方法, 引入局部光谱对比度、光谱融合降维和局部多向梯度特征方法, 以获取高光谱图像的显著性结果, 从而实现高光谱图像的异常检测。通过实验与分析, 得到以下结论: ①局部光谱对比度的方法能够充分利用光谱信息, 在高光谱异常检

测中具有可行性。②光谱融合降维方法对比常用的降维方法，能够显著提高检测精度。③局部多向梯度特征方法能够很好地保留图像中的细节和局部特征，从而有效降低虚警率。

实验结果表明，与其他7种方法相比，HLC-MDG方法在定性和定量评估方面均取得了优越表现。此外，HLC-MDG方法对小目标和背景比较简单场景的检测精度更高。然而，该算法需要调整的参数较多，耗时较长，获得的背景也不够纯净。

因此，在下一步研究中，我们将重点关注如何实现自适应参数和进一步研究对比度算法。

## 参考文献：

[1] 孙帮勇, 赵哲, 胡炳樑, 等. 基于3D卷积自编解码器和低秩表示的高光谱异常检测[J]. 光子学报, 2021, **50**(4): 262-274.

SUN Bangyong, ZHAO Zhe, HU Bingliang, et al. Hyperspectral anomaly detection based on 3D convolutional autoencoder and low rank representation[J]. *Acta Photonica Sinica*, 2021, **50**(4): 262-274.

[2] XU Y, ZHANG L, DU B, et al. Hyperspectral anomaly detection based on machine learning: an overview[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, **15**: 3351-3364.

[3] 李茗欣, 黄远程, 竞霞, 等. 融合视觉注意机制的高光谱RX异常检测算法[J]. 红外技术, 2023, **45**(4): 402-409.

LI Mingxin, HUANG Yuancheng, JING Xia, et al. Hyperspectral RX anomaly detection algorithm with visual attention mechanism[J]. *Infrared Technology*, 2023, **45**(4): 402-409.

[4] 向英杰, 张俭峰, 杨桃, 等. 基于混合噪声估计的高光谱图像异常检测方法[J]. 红外技术, 2017, **39**(8): 734-739.

JIANG Yingjie, ZHANG Jianfeng, YANG Guang, et al. A mixed-noise estimation-based anomaly detection method for hyperspectral image[J]. *Infrared Technology*, 2017, **39**(8): 734-739.

[5] SONG X, LING Z, WU L, et al. Hyperspectral image anomaly detection based on background reconstruction[J]. *Journal of System Simulation*, 2020, **32**(7): 1287-1293.

[6] XIANG P, SONG J, QIN H, et al. Visual attention and background subtraction with adaptive weight for hyperspectral anomaly detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, **14**: 2270-2283.

[7] ZHAO D, Asano Y, GU L, et al. City-scale distance sensing via bispectral light extinction in bad weather[J]. *Remote Sensing*, 2020, **12**(9): 1401.

[8] ZHAO D, ZHOU L, LI Y, et al. Visibility estimation via near-infrared bispectral real-time imaging in bad weather[J]. *Infrared Physics & Technology*, 2024, **136**: 105008.

[9] ZHANG J, XU X, YAN W, et al. Hyperspectral anomaly detection based on local contrast estimation and sub-block background estimation[J]. *Infrared Physics & Technology*, 2023, **135**: 104966.

[10] 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.

[11] Molero J M, Garzon E M, Garcia 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.

[12] 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.

[13] 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.

[14] 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*, 2012, **35**(1): 171-184.

[15] LI S, WANG W, QI H, et al. Low-rank tensor decomposition based anomaly detection for hyperspectral imagery[C]//2015 IEEE International Conference on Image Processing (ICIP). IEEE, 2015: 4525-4529.

[16] LI W, DU Q. Collaborative representation for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **53**(3): 1463-1474.

[17] 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.

[18] WEI J, ZHANG J, XU Y, et al. Hyperspectral anomaly detection based on graph regularized variational autoencoder[J]. *IEEE Geosci. Remote Sens. Lett.*, 2022, **19**: 1-5.

[19] Banks M S, Read J C A, Allison R S, et al. Stereoscopy and the human visual system[J]. *SMPTE Motion Imaging Journal*, 2012, **121**(4): 24-43.

[20] XIE W, FAN S, QU J, et al. Spectral distribution-aware estimation network for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, **60**: 1-12.

[21] XU Y, WU Z, LI J, et al. Anomaly detection in hyperspectral images based on low-rank and sparse representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **54**(4): 1990-2000.

[22] ZHANG Y, DU B, ZHANG L, 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*, 2015, **54**(3): 1376-1389.

[23] CHENG T, WANG B. Graph and total variation regularized low-rank representation for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, **58**(1): 391-406.

[24] GUO T, HE L, LUO F, et al. Anomaly detection of hyperspectral image with hierarchical anti-noise mutual-incoherence-induced low-rank representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: 1-13.

[25] Tu B, Li N, Liao Z, et al. Hyperspectral anomaly detection via spatial density background purification[J]. *Remote Sensing*, 2019, **11**(22): 2618.

[26] Song S, Zhou H, Yang Y, et al. Hyperspectral anomaly detection via convolutional neural network and low rank with density-based clustering[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, **12**(9): 3637-3649.

[27] Xiang P, Ali S, Jung S K, et al. Hyperspectral anomaly detection with guided autoencoder[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, **60**: 1-18.

[28] Arisoy S, Nasrabadi N M, Kayabol K. Unsupervised pixel-wise hyperspectral anomaly detection via autoencoding adversarial networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, **19**: 1-5.

[29] 钱晓亮, 曾银凤, 林生, 等. 融合自适应窗口显著性检测和改进超像素分割的高光谱异常检测[J]. 遥感学报, 2023, **27**(12): 2748-2761.

QIAN Xiaoliang, ZENG Yinfeng, LIN Sheng, et al. Hyperspectral anomaly detection via combining adaptive window saliency detection and improved superpixel segmentation[J]. *National Remote Sensing Bulletin*, 2023, **27**(12): 2748-2761.