

# 基于空谱背景重构的半监督高光谱异常检测

李璐瑶<sup>1</sup>, 李忠伟<sup>1\*</sup>, 王雷全<sup>2</sup>, 李娟<sup>2</sup>, 史顺晓<sup>2</sup>

<sup>1</sup>中国石油大学(华东)海洋与空间信息学院, 山东 青岛 266580;

<sup>2</sup>中国石油大学(华东)计算机科学与技术学院, 山东 青岛 266580

**摘要** 为了充分利用高光谱图像的空间和光谱信息,同时缓解训练样本不足的问题,提出一种融合空谱特征的半监督高光谱异常检测模型。首先使用无监督聚类自动构建空谱背景数据集用于网络的训练。然后构建基于自动编码器和生成对抗网络的空谱双路模型分别用于背景光谱特征的学习和波段信息的重建,空间支路同时使用滤波器增大背景和异常间的差异,两路分别得到光谱异常分数和波段异常值。最后融合空谱特征得到异常检测图。在真实高光谱图像上验证该方法的有效性,实验结果表明,该方法优于传统的异常检测方法,平均检测精度达到 99.55%。

**关键词** 高光谱图像; 空谱融合; 异常检测; 自动编码器; 生成对抗网络

中图分类号 TP751

文献标志码 A

DOI: 10.3788/LOP222705

## Semi-Supervised Hyperspectral Anomaly Detection Based on Spatial-Spectral Background Reconstruction

Li Luyao<sup>1</sup>, Li Zhongwei<sup>1\*</sup>, Wang LeiQuan<sup>2</sup>, Li Juan<sup>2</sup>, Shi Shunxiao<sup>2</sup>

<sup>1</sup>College of Oceanography and Space Informatics, China University of Petroleum, Qingdao 266580, Shandong, China;

<sup>2</sup>College of Computer Science and Technology, China University of Petroleum, Qingdao 266580, Shandong, China

**Abstract** To fully utilize the spatial and spectral information of hyperspectral images and alleviate the problem of insufficient training samples, a semi-supervised hyperspectral anomaly detection model fused with spatial-spectral features is proposed. First, unsupervised clustering is used to automatically construct spatial-spectral background datasets for network training. Then, a dual-path model based on automatic encoder and generative adversarial network is built for learning background spectral features and reconstructing band information respectively. The space branch increases the difference between the background and anomaly using a filter, resulting in spectrum anomaly scores and band outliers. Finally, the spatial-spectral characteristics of anomaly detection are fused. The effectiveness of the proposed method is verified on real hyperspectral images. The experimental results show that the proposed method is superior to the conventional anomaly detection method, with an average detection accuracy of 99.55%.

**Key words** hyperspectral image; spatial-spectral fusion; anomaly detection; automatic encoder; generative adversarial network

## 1 引言

高光谱成像<sup>[1]</sup>作为一种先进的地球观测和深空探测手段,在环境监测、资源勘探、精细农业、土地分类等应用领域受到了广泛关注<sup>[2]</sup>。基于这些应用,衍生出各种数据分析方法,包括土地覆盖分类<sup>[3]</sup>、目标检测<sup>[4]</sup>和异常检测<sup>[5]</sup>。在实践中,高光谱图像(HSI)异常检测

存在许多挑战,包括缺乏先验信息、背景类别复杂、样本不平衡<sup>[6-7]</sup>。现有的异常检测算法主要包括基于传统建模的高光谱异常检测算法和基于深度学习的高光谱异常检测算法。

基于传统建模的高光谱异常检测算法大致可细分为两大类:背景建模和背景剔除。最广为人知的背景建模算法是 Reed-Xiaoli(RX)<sup>[8]</sup>算法。RX算法假设背

收稿日期: 2022-10-08; 修回日期: 2022-11-09; 录用日期: 2022-11-29; 网络首发日期: 2023-01-04

基金项目: 国家自然科学基金面上项目(62071491)、国家自然科学基金联合基金资助项目(U1906217)、中央高校基本科研业务费专项资金资助项目(19CX05003A-11)

通信作者: \*li.zhongwei@vip.163.com

景服从多元高斯分布,通过计算每个测试像素与重建背景之间的马氏距离来判断该像素是否为异常像素。然而,在真实 HSI 的场景中, RX 计算的背景模型中均值和方差不可避免地被异常像素干扰,影响检测精度。局部 RX(LRX)<sup>[9]</sup>算法通过局部窗口估计局部统计特征,在一定程度上提升了检测性能,避免了复杂背景的干扰。为了避免异常像素对背景统计的污染,基于背景中的每个像素都可以由其空间邻域近似表示,而异常像素则不能的概念,提出基于表示的背景建模算法,包括稀疏表示<sup>[10]</sup>、协作表示<sup>[11]</sup>和低秩表示<sup>[12]</sup>。基于协同表示的检测器<sup>[13]</sup>构造了一个预测背景,其中,每个被测背景像素可以由其周围像素近似表示,而异常像素则不能。异常像素可以通过预测背景和原始背景之间的距离来获得。考虑到局部几何结构和空间关系,图和总变差正则化低秩表示检测器(GTVLRR)<sup>[14]</sup>将图正则化和总变差引入低秩表示。典型的背景剔除算法采用属性和边缘保留滤波器的检测器<sup>[15]</sup>和基于结构张量和引导滤波器的检测器<sup>[16]</sup>,主要通过属性过滤和差分运算的结合来去除背景,然后通过局部过滤操作来有效地检测异常。总之,对背景或背景与异常之间的关系进行建模对于高光谱异常检测至关重要。然而,随着场景和应用的复杂化,高光谱的背景变得复杂,这限制了传统方法的检测性能。

基于深度学习的高光谱异常检测算法根据标签的可用性可以大致分为 3 类:监督学习、半监督学习和无监督学习<sup>[17]</sup>。监督学习理论上可以通过学习标记样本来实现优越的检测性能,但由于高光谱异常检测存在像素级标注不准确、缺乏目标先验信息等问题,使得其不如无监督<sup>[18]</sup>或半监督<sup>[19]</sup>方法适用。现有的无监督方法大多以自动编码器(AE)<sup>[20]</sup>和生成对抗网络(GAN)<sup>[21]</sup>作为模型的基本架构。前者通过特征提取或重建背景图像和原始图像的残差来检测异常,这意味着预计异常具有较大的重构误差,而背景重构误差则相对较小。后者通过生成器和鉴别器的博弈学习输入数据的分布以生成一些新数据,从而结合其他的检测器来检测异常。Arisoy 等<sup>[22]</sup>使用 3 种不同的深度自动编码对抗网络以无监督的方式训练,在原始图像像素和合成像素之间计算重建误差图。由于缺乏来自标记训练实例的约束<sup>[23]</sup>,无监督的方法对异常谱向量非常敏感,并且存在过度拟合异常的风险,这会削弱模型检测性能。综上所述,现有的监督和无监督异常检测方法都不能很好地处理训练样本不足的问题。

考虑到自动编码器的重构能力和生成对抗网络的泛化能力对高光谱的高维、有限样本的学习潜力以及异常检测任务中标记样本匮乏的问题,本文提出一种半监督空谱背景重构算法。所提算法基于 3 个重要假设:1)与正常样本相比,异常样本往往是稀疏分布的且数量较少;2)高光谱数据集的背景服从多元高斯分布;3)异常出现在高光谱空间域的小范围内,且与周围背

景在光谱域存在较大的差距。所提算法使模型分别在光谱域和空间域更好地学习背景分布规律,进而增大背景和异常的差异,从而更加高效地完成后续异常检测任务。

本文提出一种基于 AE-GAN 的半监督空谱学习方法,用于高光谱异常检测,以充分探索 HSI 中光谱和空间特征之间的互补背景信息。所提框架包括 3 个关键步骤:背景数据集构建、空谱背景信息学习、特征融合。为了在没有任何先验的情况下,在未标记的原始高光谱数据上构建用于空谱学习的背景数据集,提出一种自适应的样本选择算法,以拒绝具有高异常可能性的实例并接受具有高正常可能性的实例并自动构建相对纯净的背景光谱数据集。在光谱背景学习中,采用 GAN 来估计背景分布并利用其强大的表示能力和对抗性训练优势获得光谱域特征。在空间背景学习中,通过重构整个波段来增大异常与背景的分隔度。最后,融合光谱域和空间域的两个特征,得到最终的检测结果,旨在避免只能从单一视角进行检测的限制,并进一步提升检测性能。

## 2 相关算法

### 2.1 高光谱异常检测模型

HSI 是一组三维数据,可以表示为  $\mathbf{Y} \in \mathbf{R}^{M \times N \times B}$ , 可以看成是  $M \times N$  个  $B$  维向量,即  $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_{M \times N}]$ ,  $\mathbf{y}_i \in \mathbf{R}^{B \times 1}$ 。其中,  $M \times N$  表示空间像素数目,  $B$  表示光谱谱段数目。高光谱异常检测模型可以表示为

$$\mathbf{A} = \mathbf{Y} - \mathbf{H}, \quad (1)$$

式中:  $\mathbf{Y}$  为原始的高光谱图像;图像中的异常值  $\mathbf{A} \in \mathbf{R}^{M_1 \times N_1 \times B}$ ;图像中的背景  $\mathbf{H} \in \mathbf{R}^{M_2 \times N_2 \times B}$ ;  $M = M_1 + M_2$ ,  $N = N_1 + N_2$ 。高光谱异常检测可以通过搭建神经网络模型首先学习空谱背景信息,然后利用训练好的模型对原始数据进行重构,最后通过原始数据与重建背景的残差得到初始异常检测图。

### 2.2 空谱联合的高光谱异常检测模型

所提 HSI 异常检测模型如图 1 所示。网络输入为原始的高光谱数据,通过端到端的学习在光谱支路和空间支路上同时学习背景信息光谱分布和空间分布规律。具体来说:光谱背景基于像素点具有连续性,包含背景地物的光谱特征;空间背景基于单个波段,包含空间地物的位置信息,通过模型估计背景光谱分布规律和空间位置信息,通过网络的训练保证原始 HSI 背景信息能够更好地被生成模型重构。背景重构的能力越强,模型的背景异常分离能力就越强,检测的精度就越高。所提方法由两个关键的部分组成:背景数据的粗提取和空谱背景信息半监督学习。前一部分通过一种无监督训练样本构建方法选择背景样本构建较为纯净的背景数据集。后一部分通过一种基于 AE-GAN 的半

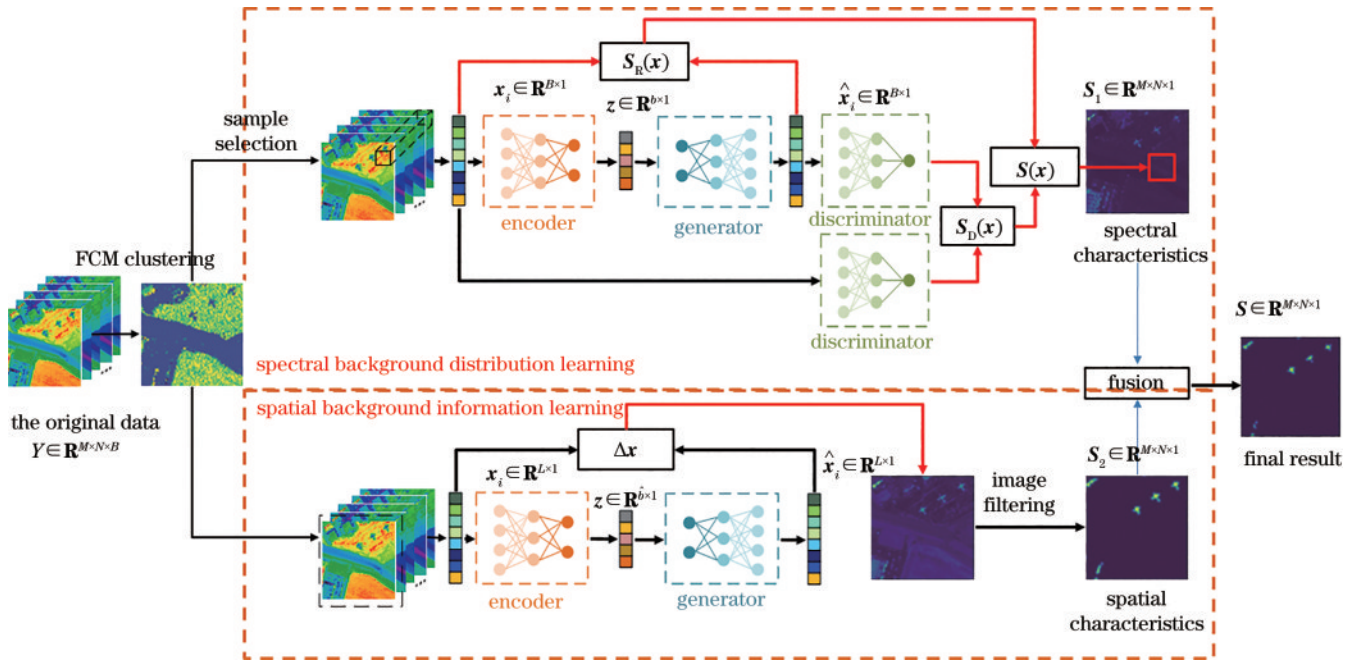


图1 空谱联合的高光谱异常检测模型

Fig. 1 Hyperspectral anomaly detection model combined with spatial-spectrum

监督模型从光谱和空间两部分来估计背景分布,并且可以采用训练好的模型基于原始数据推断空谱特征。具体来说,光谱支路基于像素获得每个像素代表异常的可能性,空间支路重构整个波段的背景信息,获得通道异常,同时利用图像滤波进一步增大异常和背景之间的差距。最后融合两部分的特征生成最终检测图。

### 2.3 背景数据集的构建

由于所提方法旨在学习 HSI 的空谱背景信息,因此关键步骤是获取背景样本。获取背景样本有 3 个要求:1) 由于背景和异常的先验信息是未知的,因此这是一个无监督任务;2) 背景样本要尽可能地包含所有背景类别,如果样本中存在缺失的背景类,就会在检测阶段产生虚警;3) 背景样本应不包含异常样本,如果背景被污染,则会将异常点重构为背景点,降低检测精度。

为了满足上述要求,采用一种基于划分模糊聚类 (FCM) 的方法以无监督的方式选择较为纯净的背景样本。首先确定 HSI 的分类个数  $c$  和隶属度因子  $m$ , 样本  $y_j$  与类中心  $c_i$  的隶属度为  $u_{ij}$ ,  $u_{ij}$  为当前样本属于某个类的可能性。样本与聚类中心的距离为  $d_{ij}$ , 目标函数为

$$J = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \|y_j - c_i\|^2, y_i \in Y (n = M \times N). \quad (2)$$

目标函数迭代地将每个样本朝着隶属度最大的类中心移动,直到收敛。该方法中的聚类数目间接地影响着每个类别中样本数目的多少。一般来说,类的数目越多,每个类别的样本相对较少,而类的数目越少,每类中的样本数目则越多。综上所述,聚类生成的流程图如图 2 所示。首先,HSI 数据在聚类前通过主成分分析进行预处理,以降低计算成本;其次,根据确定的聚类个数和目标函数确定聚类中心和每个聚类类别

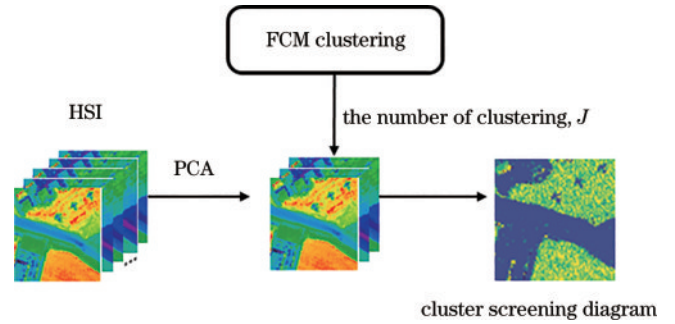


图2 聚类生成流程图

Fig. 2 Flow chart of cluster generation

中样本数目的多少。由于异常具有小尺寸的特点,一旦生成聚类,样本数低于  $\theta \times j$  的孤立点或稀疏聚类就会被剔除。其中,  $\theta$  是属于  $[0, 1]$  中的一个参数。在聚类筛选图的指导下,剔除异常可能性高的样本,可以构建相对纯净的光谱数据集  $x_{spe} \in \mathbf{R}^{B_1 \times L_1}$  和波段数据集  $x_{spa} \in \mathbf{R}^{L_2 \times B_1}$ , 用于空谱背景分布学习。

### 2.4 光谱域背景分布学习

光谱域背景学习旨在学习像素级的背景分布规律。采用从光谱数据集  $x_{spe}$  中采样的背景光谱向量  $x_i \in \mathbf{R}^{B_1 \times 1} (i = 1, 2, \dots, L_1)$  作为基于 AE-GAN 模型的训练数据,以半监督的方式学习背景光谱向量的分布方式。每次从背景光谱数据集随机选取单个向量输入模型,遍历完所有向量。计算相应的损失,回传并更新生成模型参数。测试数据为经过主成分分析的 HSI 数据,按顺序输入所有的谱向量。在测试阶段,将原始 HSI 的所有谱向量输入训练好的模型中,以生成原始 HSI 和重建背景之间的残差,该差值代表光谱域中每个像素异常的可能性。

AE-GAN 的模型旨在学习一个背景分布规律  $p_d$ , 从而拟合真实背景光谱分布  $p_x$ , AE 的重构能力和 GAN 的生成能力使得新生成的像素接近原始背景像素成为可能。引入一个 AE 网络以达到学习重建的目的, 编码器将输入样本映射到潜在特征空间  $z$ , 该特征空间保留了 HSI 的背景信息, 然后将  $z$  馈送到生成器  $G$  以生成重建样本。GAN 首先从服从正态分布的随机噪声中采样噪声向量  $z$  并输入生成器  $G$ , 生成器的输出  $G(z)$  期望服从光谱背景分布  $p_x$ 。鉴别器  $D$  的输入是从光谱背景数据集  $x_{spe}$  中采样的谱向量和生成器  $G$  生成的样本, 输出是单个标量值。在 GAN 的训练期间, 生成器  $G$  和鉴别器  $D$  以对抗的方式同时优化:

$$\min_G \max_D E_{x \sim p_x(x)} [\log D(x)] + E_{z \sim N(0,1)} \times \{\log \{1 - D[G(z)]\}\}, \quad (3)$$

式中:  $E(\cdot)$  表示期望。生成器  $G$  被训练使其输出  $G(z)$  服从原始光谱背景分布  $p_x$ , 并欺骗鉴别器  $D$ ; 而鉴别器  $D$  被训练用来区分输入是从数据集  $x_{spe}$  采样的光谱向量还是由生成器  $G$  生成的样本。然而 GAN 的训练过程中总是存在模式崩溃和梯度消失等问题, 这降低了背景分布的估计精度, 并对后续任务产生负面影响。为了模型训练的稳定性并且更好地重建背景光谱向量, 在半监督网络中添加了潜在特征层约束损失和重构损失, 具体如图 3 所示。

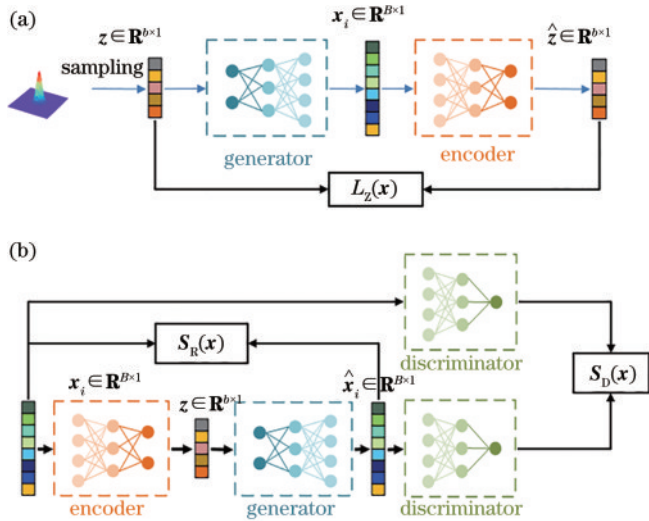


图 3 损失架构图。(a) 潜在特征层约束损失; (b) 重构损失  
Fig. 3 Loss architecture diagrams. (a) Potential feature layer constraint loss; (b) reconstruction loss

为了保证映射到潜在特征层的样本及生成的样本服从光谱背景的正态分布, 潜在特征层约束损失的表达式为

$$L_z(x) = \|z - E[G(z)]\|^2. \quad (4)$$

从正态分布采样的随机噪声向量  $z$  经过生成器  $G$  生成光谱向量, 然后训练 AE 的编码器将其映射回潜

在特征空间, 通过输入样本  $z$  和重构样本的最小均方误差来确保编码器的输出服从标准正态分布。

为了提升生成器对背景向量的生成能力和鉴别器对原始和生成数据的判别能力, 重构损失的表达式为

$$L_R = \alpha \|x - G[E(x)]\|^2 + \beta \|D(x) - D\{G[E(x)]\}\|^2. \quad (5)$$

由于 GAN 不稳定的生成能力, 可能会生成不符合光谱背景分布的伪背景, 为了进一步稳定光谱背景学习并增大正常和异常类别之间的差异, 通过最小化原始输入和生成器的输出来约束网络的生成。但仅仅只依赖于生成器仍然会出现对正常样本不切实际的重建问题, 可以借助鉴别器强大的鉴别能力进一步提升该模型对较小均方误差的正常样本的真实重建能力, 削弱对较大均方误差的异常样本的不真实重建能力。

光谱支路网络训练总损失表示为

$$L_{spe} = L_z + L_{R0} \quad (6)$$

在光谱特征提取过程中, 采用输入的原始光谱向量与其重建版本之间的相似性来衡量光谱特征。光谱特征  $S_1(x)$  在像素级代表某个光谱异常的可能性, 表示为

$$S_1(x) = \alpha \|x - G[E(x)]\|^2 + \beta \|D(x) - D\{G[E(x)]\}\|^2, \quad (7)$$

式中:  $\alpha$  和  $\beta$  是权重系数。

## 2.5 空间域背景信息学习

空间域背景学习旨在学习 HSI 单个波段的背景分布规律。鉴于 HSI 各个波段的空间图像具有灰度不相关的特点, 即单个波段表征的信息独立, 同时为了避免分区域操作缺乏位置信息的交互, 所提方法旨在选择出表征背景信息最优的一个波段。采用从波段数据集  $x_{spa}$  中采样的背景波段向量  $x_i \in \mathbf{R}^{L_1 \times 1}$  ( $i = 1, 2, \dots, B_1$ ) 作为空间 AE-GAN 模型的训练数据。在聚类筛选图的指导下, 剔除异常点, 为了使网络每次的输入维度一致, 对缺失的数据点进行补零填充, 不会干扰对波段背景信息的学习。每次从背景波段数据集随机选取单个向量输入模型, 遍历完所有波段向量。测试数据为主成分分析的波段经过维度变换而成的向量, 通过模型选择空间信息表征最好的单个波段。在测试阶段, 将原始 HSI 以单个波段的形式输入训练好的模型中, 进而重构出空间背景, 两者的残差即代表初始波段异常。为了在增强异常的同时抑制背景, 采用滤波的方法对残差图像进行处理, 得到最后的波段异常图。

波段 AE-GAN 模型旨在更好地重构出波段背景信息, 降低异常被重构的可能性, 如图 1 所示。基于 HSI 的背景信息服从标准正态分布的假设, 引入潜在特征层鉴别器  $D_z$ , 输入分别是编码器的输出  $E(x)$  和从标准正态分布采样的向量  $z$ , 使得潜在特征层以对抗的形式服从正态分布, 有利于背景而不是异常学习和重建。同时为了缩小每次编码的潜在特征层向量的偏

差,引入潜在特征层收缩损失,使得潜在特征层更好拟合对背景分布的估计。为了稳定 GAN 的生成,使用原始输入和输出的重构损失和鉴别器  $D$  以对抗学习的方式提升模型的重构能力。具体架构如图 4 所示。

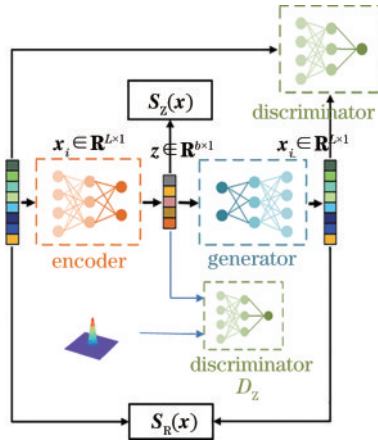


图 4 损失架构

Fig. 4 Loss architecture

波段背景信息重构损失可表示为

$$S_R(\mathbf{x}) = \mathbf{x} - G[E(\mathbf{x})], \quad (8)$$

式中:  $\mathbf{x}$  为输入的原始波段向量;  $G[E(\mathbf{x})]$  为经过模型编码生成的背景向量。

潜在特征层收缩损失可表示为




图 5 空间域滤波结果

Fig. 5 Filtering results in spatial domain

## 2.6 空谱特征融合

HSI 具有丰富的光谱信息和一定的空间信息,前文已经得到光谱域特征图  $S_1(\mathbf{x})$  和空间域特征图  $S_2(\mathbf{x})$ ,即像素级的异常分数和波段的空间异常,需要融合光谱和空间的特征以获得最终的异常检测图。融合特征可表示为

$$S = S_1 \cdot S_2, \quad (13)$$

式中:  $S$  为最终的异常检测结果;  $S_1$  和  $S_2$  分别为光谱域和空间域的特征图,  $S_1 \in \mathbf{R}^{M \times N \times 1}$ 、 $S_2 \in \mathbf{R}^{M \times N \times 1}$ 。采用相乘的方式融合两种特征,即施加光谱域的异常分数于空间域的通道异常图,利用光谱特征增强空间异常的同时抑制背景,两者互补得到异常检测图。

## 3 实验

所提模型运行环境如下: CPU 处理器 Intel(R) Core(TM) i5-9400 CPU @ 2.90 GHz 2.90 GHz, GPU

$$S_z(\mathbf{x}) = \|\mathbf{z}\|^2. \quad (9)$$

空间支路网络训练总损失可表示为

$$L_{spa} = S_z(\mathbf{x}) + S_R(\mathbf{x}). \quad (10)$$

利用原始 HSI 的输入和重建背景的残差即可得到初始的空间异常图  $\Delta\mathbf{x}$ 。为了更好地检测异常并降低误报率,先对初始异常图进行形态学滤波,再利用形态学开闭操作消除零星的异常点并平滑背景,形态学滤波的结果为

$$F_M = |\Delta\mathbf{x} - O(\Delta\mathbf{x})| + |\Delta\mathbf{x} - C(\Delta\mathbf{x})|, \quad (11)$$

式中:  $F_M$  表示形态学滤波的结果;  $O(\Delta\mathbf{x})$  表示形态学打开操作;  $C(\Delta\mathbf{x})$  表示形态学关闭操作;  $|\cdot|$  表示绝对值。

为了进一步突出检测结果的边缘并去除噪声点,使用引导滤波器对形态学滤波的结果进行处理,进一步增强异常并抑制背景。引导滤波可表示为

$$F_{Gi} = a_i F_{Mi} + b_i, F_{Mi} \in F_M, \forall i \in \omega_i, \quad (12)$$

式中:  $F_{Gi}$  为输出像素的值;  $F_{Mi}$  是输入图像的值;  $i$  是像素的索引;  $a_i$  和  $b_i$  是当窗口中心位于  $i$  时该线性函数的系数。所用的引导图像为  $F_M$ 。最后,为了使空间的异常检测效果更加突出,进一步增大异常和背景之间的差距,使用 Oust 阈值算法对  $F_G$  进行处理,将检测结果转化为二值图像,得到最终的空间域特征  $S_2(\mathbf{x})$ ,如图 5 所示。

显卡 NVIDIA GeForce GTX 1650,深度学习框架 PyTorch 1.6。使用 MATLAB R2019b 进行对比实验。

### 3.1 实验数据集介绍

使用 4 个 HSI 的公开数据集对所提算法的有效性进行训练和评估:

1) Sandiego 数据集:该数据集由覆盖圣地亚哥区域的机载可见光/红外成像光谱仪捕获。该数据有 224 个光谱带,剔除包含吸水带和低信噪比的波段之后有 189 个波段可用。图像大小为  $100 \times 100$ ,空间分辨率为 3.5 m。数据集中三架飞机为异常像素,即需要检测的像素点为 57。

2) Texas Coast(TC)数据集:该数据集由覆盖德克萨斯海岸区域的机载可见光/红外成像光谱仪捕获。该数据有两个图像,有 207 个可用波段。图像大小为  $100 \times 100$ ,空间分辨率为 17.2 m。数据集中不同形状的住宅被标记为异常区域,即需要检测的像素点为 67

和 155。

3) Bay Champagne(BC)数据集:该数据集由覆盖海湾香槟区域的机载可见光/红外成像光谱仪捕获。该数据有 188 个可用波段。图像大小为  $100 \times 100$ , 空间分辨率为 4.4 m。数据集中海面物体被标记为异常区域,即需要检测的像素点为 11。

4) ABU 数据集:该数据集由覆盖洛杉矶区域的机载可见光/红外成像光谱仪捕获。该数据有 205 个可用波段。图像大小为  $100 \times 100$ , 空间分辨率为 7.1 m。数据集中两架飞机被标记为异常,即需要检测的像素点为 87。

### 3.2 比较方法和评价标准

实验过程中采用几种流行的异常检测算法与所提算法进行比较,分别为:RX、LRX、low-rank and sparse representation(LRASR)<sup>[24]</sup>、low-rank and sparse matrix decomposition-based Mahalanobis distance method(LSMAD)<sup>[12]</sup>、GTVLRR、robust principal component analysis (PRCA)<sup>[25]</sup>、prior-based tensor approximation (PTA)<sup>[26]</sup>。

RX 检测器通过计算测试像素和图像背景之间的马氏距离来判别异常,是无监督异常检测领域广泛使用的检测器。LRX 是 RX 的改进版本,通过计算测试像素和局部图像背景之间的马氏距离来检测异常。LRASR 是经典的基于表示的异常检测算法,采用字典构建策略对稀疏分量进行建模,并将  $L_2$  范数作为异常指标。LSMAD 同时探索背景的低秩先验特征和异常的稀疏特性,并构建了基于马氏距离的异常检测器。GTVLRR 在利用低秩特性的基础上提出图和总变差

正则化低秩表示来保留 HSI 中的局部几何结构和空间关系。RPCA 将 HSI 分解为低秩背景和稀疏异常,将 RX 应用于稀疏分量以检测异常。PTA 将先验与 HSI 的张量表示的优点相结合,利用  $L_{2,1}$  范数正则化表示异常分量的组稀疏先验。

使用 3 个最常用的异常检测指标来评估不同算法的检测性能。1)背景异常可分离性图,它表示的是检测器将异常和背景分离的能力。异常框和背景框的间隔代表异常和背景的可分性,同时背景框的高度表示检测器对背景的抑制程度。2)接受者操作特性(ROC)曲线,它以基于地面真实值的各种阈值下的检测概率( $R_{PD}$ )和虚警率( $R_{FAR}$ )绘制,计算方法如式(14)所示。在相同虚警率的条件下,高检测率的方法优于低检测率的方法。3)接受者操作特性曲线下面积(AUC),它的数值越接近于 1,模型的检测性能越好。

$$\begin{cases} R_{PD} = \frac{N_D}{N_T} \\ R_{FAR} = \frac{N_F}{N_B} \end{cases}, \quad (14)$$

式中: $N_T$ 是数据集中真实目标像素的总数; $N_D$ 是检测为目标真实目标像素的数量; $N_B$ 是数据集中背景像素的总数; $N_F$ 是确定为目标的背景像素的数量。

### 3.3 实验结果分析

所有实验数据集的视觉检测效果如图 6 所示,相应的 ROC 曲线如图 7 所示,背景异常可分离性图如图 8 所示。表 1 统计了比较方法和所提方法的 AUC 值,突出显示了最优结果和加下划线的次优结果。可以观察到,所提方法取得了令人满意的性能。




图 6 不同方法视觉检测图。(a)Sandiego;(b)ABU;(c)TC-1;(d)TC-2;(e)BC

Fig. 6 Visual inspection maps of different methods. (a) Sandiego; (b) ABU; (c) TC-1; (d) TC-2; (e) BC

对于 Sandiego 数据集,不同方法的视觉检测图如图 6(a)所示。RX、LRX、LSMAD 和 RPCA 并不能很

好检测到异常目标。LRASR 和 GTVLRR 能够完整检测出异常目标,但是存在很多的误报。PTA 能够很

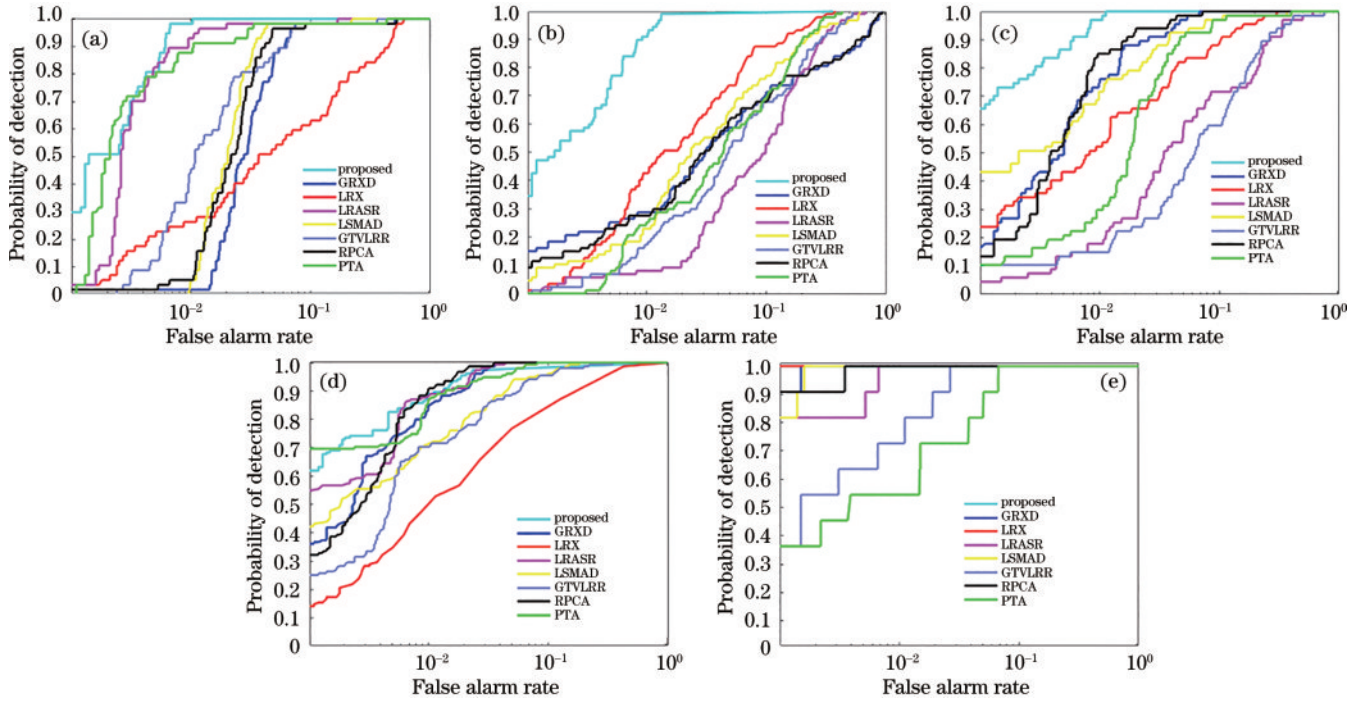


图 7 不同方法 ROC 曲线。(a) Sandiego; (b) ABU; (c) TC-1; (d) TC-2; (e) BC  
 Fig. 7 ROC curves of different methods. (a) Sandiego; (b) ABU; (c) TC-1; (d) TC-2; (e) BC

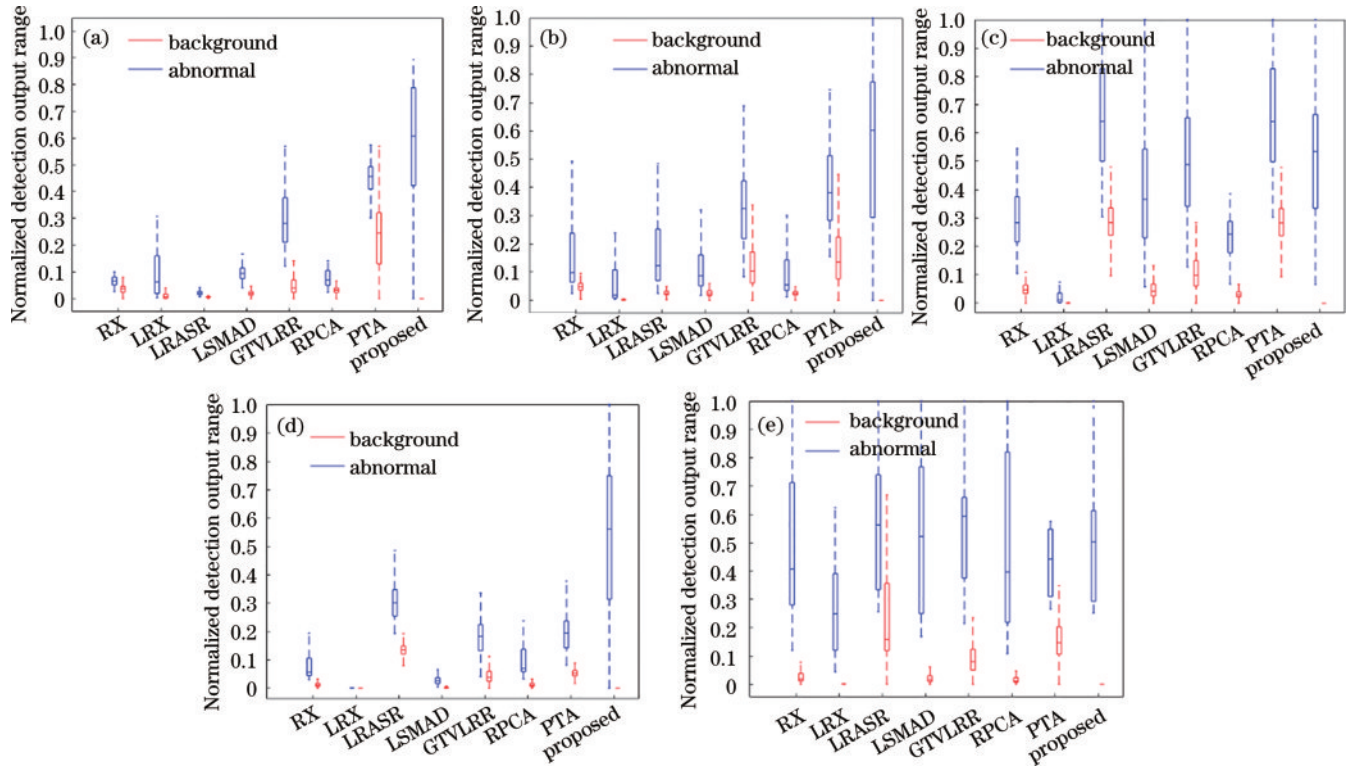


图 8 背景异常分离图。(a) Sandiego; (b) ABU; (c) TC-1; (d) TC-2; (e) BC  
 Fig. 8 Background anomaly separation diagram. (a) Sandiego; (b) ABU; (c) TC-1; (d) TC-2; (e) BC

好地检测出异常目标,但无法抑制背景干扰。所提方法能够完整地检测到目标并能很好抑制背景,同时得到了最高 AUC 分数以及最好的 ROC 曲线。由于飞机场的大部分背景服从高斯分布,AE-GAN 能够很好地学习背景信息并重构,但仍有左上角小部分孤立区域不符合规律被识别为异常。不同方法的背景异常分离

性图如图 8(a) 所示,所提方法背景中值和异常之间的距离最大,意味着所提方法针对异常和背景具有更好的判别性能。

对于 ABU 数据集,不同方法的视觉检测如图 6(b) 所示。RX、LRX、LSMAD 和 RPCA 对目标的检测不完整。LRASR、GTVLRR 和 PTA 能够保持目

表1 不同数据集上 AUC 值

Table 1 AUC values on different datasets

Method	Sandiego	ABU	TC-1	TC-2	BC
RX	0.9600	0.8403	0.9906	0.9945	0.9997
LRX	0.8730	<u>0.9534</u>	0.9661	0.9402	<b>0.9999</b>
LRASR	<u>0.9933</u>	0.8857	0.9850	<u>0.9956</u>	0.9987
LSMAD	0.9756	0.9184	0.9803	0.9852	0.9996
GTVLRR	0.9749	0.8958	0.9773	0.9809	0.9937
RPCA	0.9673	0.8431	<u>0.9922</u>	<b>0.9957</b>	0.9995
PTA	0.9877	0.9176	0.9720	0.9941	0.9823
Proposed method	<b>0.9975</b>	<b>0.9909</b>	<b>0.9983</b>	0.9913	0.9996

标的形状,同时也具有高误报率,更多提取到的是图像的纹理特征。所提方法提供了最显著的检测结果,最接近地面真实值。左下角小区域被识别为异常,但是由于空间滤波器的存在,这部分伪异常被抑制,降低了虚警率。不同方法的背景异常分离性图如图 8(b)所示,所提方法和 LRX 相较于其他对比方法针对背景有更好的抑制效果。

对于 TC 数据集,不同方法的视觉检测图如图 6(c)、(d)所示。RX 可以完全检测到异常,但是 TC-1 中一系列的条带噪声被检测为假警报,GTVLRR 和 LSMAD 受到噪声的影响较大,降低了检测精度。LRX 由于受到窗口大小的限制并不能完整地检测到异常。LRASR 和 PTA 对 TC-1 的检测效果欠佳,存在较多的非异常目标。RPCA 和所提方法在 TC-1 以高检测率和低虚警率检测所有异常,获得了令人满意的性能。在很多比较方法中被识别为异常的梯形区域在数据集构建时被剔除,使得网络更好地学习背景信息,同时与其他方法的对比表明,所提方法对噪声也有一定的抑制作用。对 TC-2 数据集,所提方法对于某些目标点的检测不够突出,但保持着最低的虚警率。不同方法的背景异常分离性图如图 8(c)、(d)所示,所提

方法在 TC-1 数据集上实现了更好的背景异常分离,在 TC-2 上相较于其他方法,背景和异常的差距更大。

对于 BC 数据集,不同方法的视觉检测图如图 6(e)所示。RX 和 LRX 对小目标的检测得到了最高的 AUC 分数。LRASR、GTVLRR 和 PTA 对背景的抑制不明显,不能很好地突出异常目标。LSMAD 和 RPCA 检测效果图存在一定的假警报。所提方法能够完整地检测出小目标同时对背景的抑制效果最明显。不同方法的背景异常分离性图如图 8(e)所示,所提方法异常和背景之间的间隔最大,这表明异常和背景的可分性相较其他方法更好。

总的来说,相较于背景统计的 RX 和 LRX,所提方法在数据集构建时能够有效剔除异常实例,在数据集上受异常的干扰较小,能够取得较低的误报率。相较于背景低秩表示的 LRASR、LSMAD 和 GTVLRR,所提方法利用 AE-GAN 对空谱背景信息进行对抗学习,引入非线性映射,提升了对背景信息的重构能力,进而有效抑制背景、突出异常区域。相较于 RPCA 和 PTA,所提方法利用 GAN 和损失函数来引入高斯分布的先验,进一步提升了模型的学习能力和稳定性。所提方法在这些数据集上整体的表现优于比较方法,原因在于所设计的方法能够很好地提取背景信息、降低虚警率,并且融合了空谱互补特征,进一步提升了检测性能。

所提方法在 TC-2、BC 数据集上检测结果几乎没有虚警,是因为两个数据集背景都比较均匀,有利于模型更好地学习背景分布。在 Sandiego、ABU、TC-1 数据集上存在些许虚警点,是因为这 3 个数据集背景类别较复杂,且有些背景类别的像素点个数与异常目标像素点个数接近,在聚类阶段被剔除,模型无法学习到其对应的背景信息,增加了误报率。故所提方法适用于背景区域均匀且单类背景像素点数较多的场景。

为了促进对空谱背景估计与重构的理解,图 9 和图 10 给出了一些视觉重建的结果。图 9 显示了 4 个有

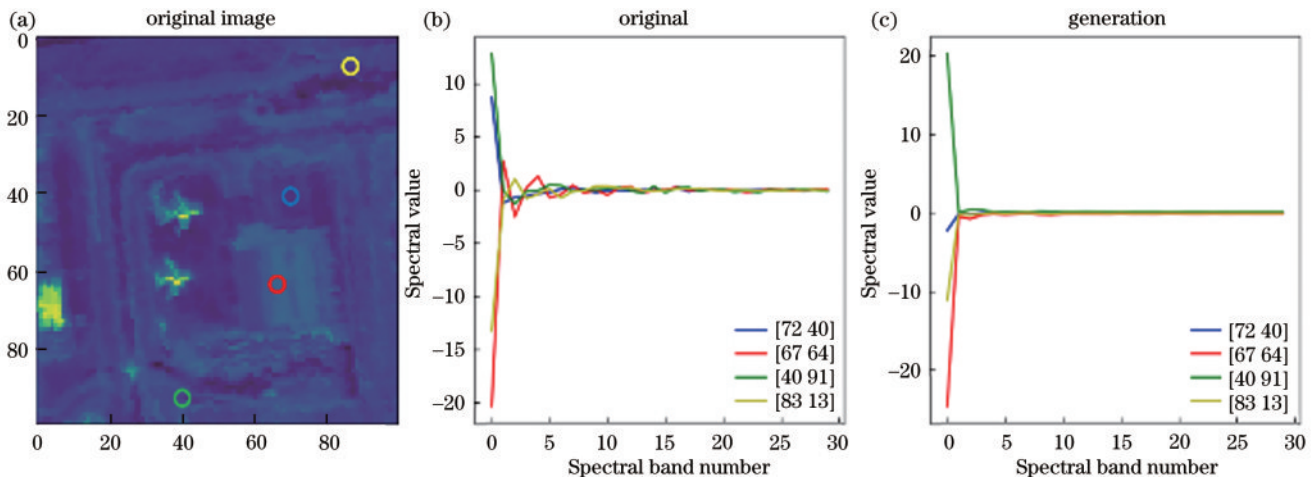


图 9 不同位置光谱重建图。(a)不同位置分布;(b)原始光谱图;(c)重构光谱图

Fig. 9 Spectral reconstruction at different positions. (a) Different position distribution; (b) original spectral diagram; (c) reconstructed spectral map



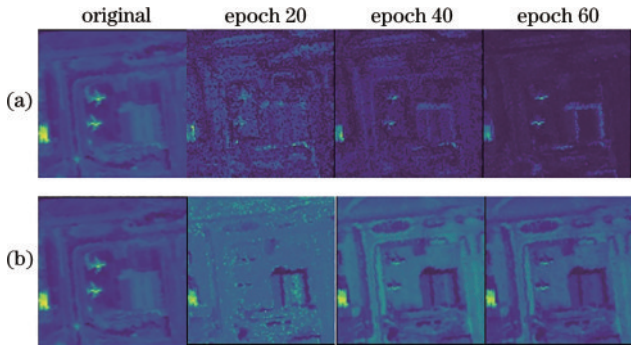


图 10 不同批次重建视觉效果图。(a)光谱;(b)空间  
Fig. 10 Visual effect images reconstructed from different batches. (a) Spectral; (b) spatial

代表性的背景像素的位置和光谱变化。图 9 为经过主成分分析和归一化处理之后的数据结果。经过背景重建后,所提方法不仅很好地保持了背景像素的光谱曲线,还使其趋于更加均匀,同时重建的背景曲线的整体趋势与原始背景大致相同,这意味着重建没有违反 HSI 的物理特性,即重建后的光谱曲线越接近,背景估计的效果就越好。根据图 10 中 ABU 数据集二维视觉结果可知,随着训练批次的增加,模型能够学习到更多的空谱背景信息。背景越均匀,异常与背景的分离度就越好,检测精度提升。

### 3.4 实验参数分析

所提算法有 3 个主要参数:FCM 聚类生成筛选图时聚类的个数  $c$ 、光谱特征生成阶段重构损失和鉴别器

特征残差损失的平衡系数  $\alpha$  和  $\beta$ 。在不同的参数设置下,采用 AUC 系数评估其对算法检测精度的影响。对于聚类个数  $c$ ,将其设置为  $\{5, 10, 15, 20, 25\}$ ,结果如图 11 所示。对于平衡系数  $\alpha$  和  $\beta$ , $\alpha$  设置为  $\{0.6, 0.7, 0.8, 0.9, 1\}$ , $\beta$  设置为  $\{0.8, 0.9, 1, 1.1, 1.2\}$ ,结果如图 12 所示。对于光谱支路的 AE-GAN,编码器的输入和输出分别为  $B_1$  和  $B_2$ , $B_2$  为  $B_1$  的平方根,由三层全连接网络构成。鉴别器的输入和输出为  $B_2$  和 1,同样由三层全连接网络构成。对于空间支路的 AE-GAN,编码器的输入为  $L_1$ ,同样由三层全连接网络构成。表 2 描述了 4 个数据集上所有算法的重要参数设置。相关实验重复 10 次,取平均值作为最终结果。

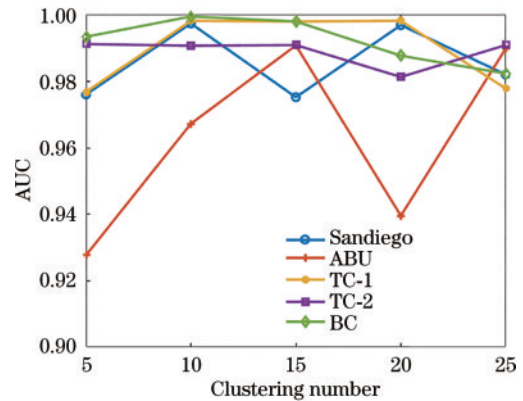


图 11 聚类个数  $c$  对不同数据集的影响  
Fig. 11 Influence of the number of clusters  $c$  on different datasets

表 2 不同数据集上的参数设置  
Table 2 Parameter settings on different datasets

Method	Sandiego	ABU	TC-1	TC-2	BC
LRX	$w_{out} = 25$ $W_{iner} = 23$	$w_{out} = 25$ $W_{iner} = 23$	$w_{out} = 15$ $W_{iner} = 13$	$w_{out} = 25$ $W_{iner} = 23$	$w_{out} = 25$ $W_{iner} = 23$
LRASR	$\lambda = 0.01$ $\beta = 0.005$	$\lambda = 0.2$ $\beta = 0.1$	$\lambda = 0.01$ $\beta = 0.005$	$\lambda = 0.001$ $\beta = 1$	$\lambda = 1$ $\beta = 0.1$
GTVLRR	$\lambda = 0.01$ $\beta = 0.005$ $\gamma = 0.05$	$\lambda = 0.5$ $\beta = 0.2$ $\gamma = 0.02$	$\lambda = 0.01$ $\beta = 0.005$ $\gamma = 0.05$	$\lambda = 0.005$ $\beta = 0.2$ $\gamma = 0.05$	$\lambda = 0.5$ $\beta = 0.2$ $\gamma = 0.05$
PTA	rank 1 $\alpha = 2$ $\beta = 0.05$ $\tau = 0.0001$ $\mu = 0.001$	rank 1 $\alpha = 2$ $\beta = 0.05$ $\tau = 0.1$ $\mu = 0.001$	rank 1 $\alpha = 2$ $\beta = 0.0001$ $\tau = 0.1$ $\mu = 0.001$	rank 1 $\alpha = 2$ $\beta = 0.05$ $\tau = 0.1$ $\mu = 0.001$	rank 1 $\alpha = 2$ $\beta = 0.05$ $\tau = 0.0001$ $\mu = 0.001$
Proposed method	$c=10$ $\theta=0.003$ $\alpha=1$ $\beta=0.9$	$c=15$ $\theta=0.005$ $\alpha=1$ $\beta=0.9$	$c=10$ $\theta=0.003$ $\alpha=0.9$ $\beta=0.8$	$c=10$ $\theta=0.005$ $\alpha=0.9$ $\beta=0.9$	$c=10$ $\theta=0.005$ $\alpha=0.9$ $\beta=0.8$

如第 2.3 节所述,聚类数目通过影响每类中样本数目的多少影响训练数据集的大小。从图 11 可以看出,大多数的数据集在聚类数目为 10 或者 15 时取得了最高的 AUC 系数。 $\theta$  表示剔除不满足条件的样本点

比例。ABU 数据集受聚类数目波动比较大的原因可能是地面背景类别较多,对无监督聚类结果影响较大。如第 2.4 节所述, $\alpha$  和  $\beta$  是平衡重构误差和鉴别器特征残差的关键参数。从图 12 可以看出:当  $\alpha$  和  $\beta$  相对较

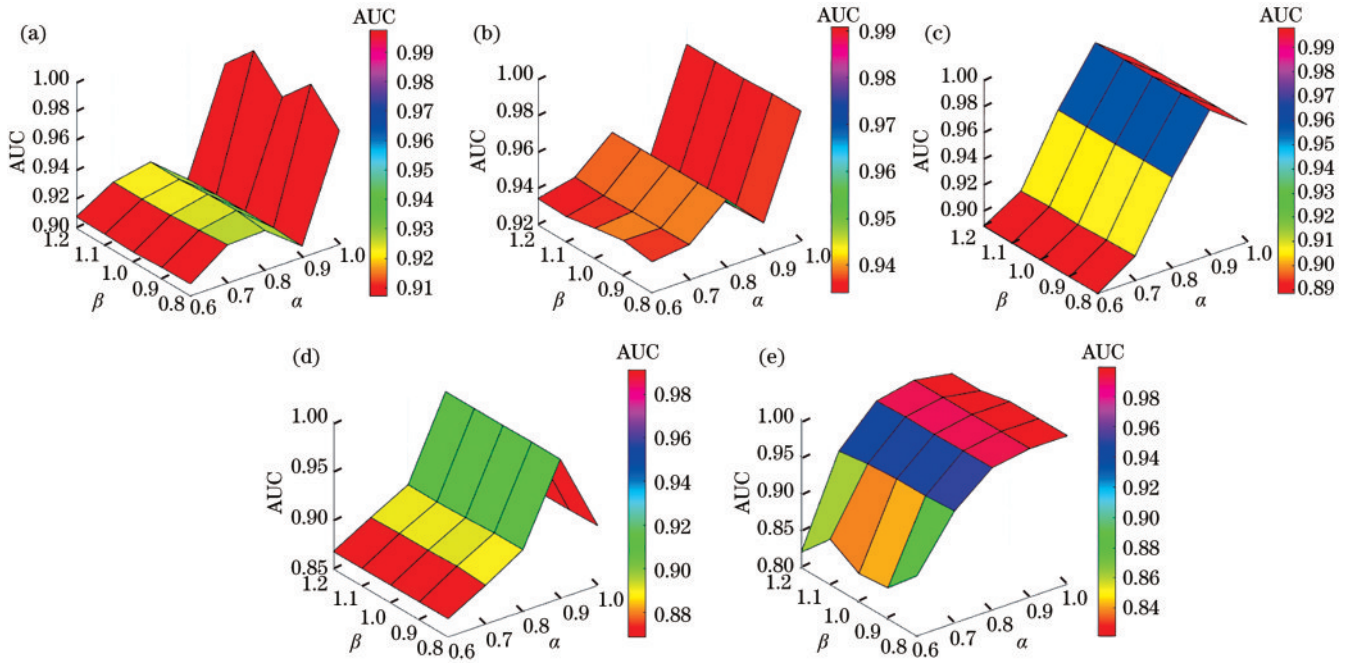


图 12 平衡系数  $\alpha$  和  $\beta$  对不同数据集的影响。(a)Sandiego;(b)ABU;(c)TC-1;(d)TC-2;(e)BC  
 Fig.12 Effects of equilibrium coefficients  $\alpha$  and  $\beta$  on different datasets. (a) Sandiego; (b) ABU; (c) TC-1; (d) TC-2; (e) BC

小时,网络过度拟合训练集,泛化性能较弱;当 $\alpha$ 和 $\beta$ 相对大时,检测精度趋于稳定且有降低的趋势,可能是网络欠拟合,导致AUC系数下降。因此,聚类数目 $c$ 和平衡系数 $\alpha$ 和 $\beta$ 的设置对模型的性能至关重要。

### 3.5 消融实验

为了分析每个模块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。主要的模块包括FCM聚类、光谱GAN、空间GAN、滤波模块。FCM聚类分别用于构建光谱数据集和空间数据集,记

为FCM-1和FCM-2。将光谱GAN和滤波器作为基准方法,由此构建了8组对比实验,分别为:光谱GAN+滤波器、光谱GAN+空间GAN(无滤波)、光谱GAN+空间GAN+滤波器、FCM-1+光谱GAN+滤波器、FCM-1+光谱GAN+空间GAN(无滤波)、FCM-1+光谱GAN+空间GAN+滤波器、FCM-1+光谱GAN+FCM-2+空间GAN(无滤波)、FCM-1+光谱GAN+FCM-2+空间GAN+滤波器,实验结果如表3所示,最优的结果加粗显示。

表3 8个版本的AUC值  
 Table 3 AUC values of the eight versions

Method	Sandiego	ABU	TC-1	TC-2	BC
Spectral GAN + Filter	0.9686	0.9601	0.9669	0.9705	0.9753
Spectral GAN + Spatial GAN	0.9779	0.9615	0.9814	0.9843	0.9854
Spectral GAN + Spatial GAN + Filter	0.9815	0.9788	0.9898	0.9764	0.9805
FCM-1 + Spectral GAN + Filter	0.9696	0.9736	0.9812	0.9814	0.9827
FCM-1 + Spectral GAN + Spatial GAN	0.9735	0.9666	0.9679	0.9766	0.9864
FCM-1 + Spectral GAN + Spatial GAN + Filter	0.9789	0.9789	0.9900	0.9770	0.9931
FCM-1 + Spectral GAN+FCM-2 + Spatial GAN	0.9911	0.9657	0.9836	0.9882	0.9899
FCM-1 + Spectral GAN+FCM-2+ Spatial GAN+ Filter	<b>0.9975</b>	<b>0.9909</b>	<b>0.9983</b>	<b>0.9913</b>	<b>0.9996</b>

为了验证FCM模块构建数据集的有效性,在基准光谱GAN+滤波器和光谱GAN+空间GAN+滤波器实验上增加FCM模块,可以观察到,FCM模块可以显著改善AUC分数,这是因为FCM模块可以有效剔除异常目标,使网络更加高效地学习背景信息。同时空间GAN的引入使网络能更加高效地重构整个波段的信息、更好地抑制背景,也证明了重构波段信

息的有效性。相比之下,所提方法在5个数据集上获得了最高的AUC分数,这也验证了所提方法的有效性。

所有方法的时间成本如表4所示,最优的结果加粗显示。由于设计的模型需要同时用神经网络学习光谱和空间信息,随着训练批次的增加需要消耗大量的时间。从测试数据输入到获取检测结果的时间被视为

表 4 不同方法的时间成本  
Table 4 Time costs of different methods

unit: s

Method	Sandiego	ABU	TC-1	TC-2	BC
RX	<b>0.0301</b>	<b>0.0899</b>	<b>0.0869</b>	<b>0.0946</b>	<b>0.0718</b>
LRX	13.3475	41.5584	32.8602	41.3030	32.5046
LRASR	20.8709	39.1473	41.6164	45.9174	43.5895
LSMAD	5.2790	11.0777	11.8113	11.3911	10.3939
GTVLRR	274.4787	296.2252	191.6086	136.9443	317.7260
RPCA	7.0242	15.3004	7.1714	7.7943	5.5224
PTA	15.4195	35.5699	30.4078	32.2381	29.9787
Proposed method	7.3677	7.5819	6.1355	6.1538	6.3809

计算时间。由表 4 可知,虽然所提方法不是最有效的方法,但是它比 LRX、LRASR、GTVLRR、PTA 更快,检测精度提升的同时是更长的时间开销,如何兼顾时间和精度是未来工作的重心之一。

## 4 结 论

提出一种融合空谱特征的高光谱异常检测算法。FCM 聚类用于空谱背景信息的学习和重构。光谱 GAN 和空间 GAN 分别用于获取光谱异常分数和通道异常,同时空间域的滤波进一步增大了背景和异常目标的差异,最后融合两部分的特征得到最终的检测图。在不同数据集上的相关实验表明,所提算法在定量评估、视觉效果和计算有效性上优于传统算法。但是在一些数据集上,需要进一步降低虚警率,同时如何平衡时间开销和检测精度有待进一步努力。

## 参 考 文 献

- [1] 李智勇, 郁文贤, 匡纲要, 吴昊. 基于高维几何特性的高光谱异常检测算法研究[J]. 遥感技术与应用, 2003, 18(6): 379-383.  
Li Z Y, Yu W X, Kuang G Y, et al. The research of anomaly detection based on high-dimensional geometrical feature in hyperspectral imagery[J]. Remote Sensing Technology and Application, 2003, 18(6): 379-383.
- [2] Plaza A, Benediktsson J A, Boardman J W, et al. Recent advances in techniques for hyperspectral image processing[J]. Remote Sensing of Environment, 2009, 113: S110-S122.
- [3] Wang Q, Lin J Z, Yuan Y. Salient band selection for hyperspectral image classification via manifold ranking[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 27(6): 1279-1289.
- [4] Nasrabadi N M. Hyperspectral target detection: an overview of current and future challenges[J]. IEEE Signal Processing Magazine, 2014, 31(1): 34-44.
- [5] 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.
- [6] Jiang T, Xie W, Li Y, et al. Weakly supervised discriminative learning with spectral constrained generative adversarial network for hyperspectral anomaly detection [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(11): 6504-6517.
- [7] 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): 319-329.
- [8] 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.
- [9] 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.
- [10] Li W, Du Q, Zhang B. Combined sparse and collaborative representation for hyperspectral target detection[J]. Pattern Recognition, 2015, 48(12): 3904-3916.
- [11] Li W, Du Q. Collaborative representation for hyperspectral anomaly detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(3): 1463-1474.
- [12] 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.
- [13] Wang R, Hu H, He F, et al. Self-weighted collaborative representation for hyperspectral anomaly detection[J]. Signal Processing, 2020, 177: 107718.
- [14] Cheng T K, Wang B. Graph and total variation regularized low-rank representation for hyperspectral anomaly detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(1): 391-406.
- [15] 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.
- [16] Xie W Y, Jiang T, Li Y S, et al. Structure tensor and guided filtering-based algorithm for hyperspectral anomaly detection[J]. IEEE Transactions on Geoscience and

- Remote Sensing, 2019, 57(7): 4218-4230.
- [17] Ergen T, Kozat S S. Unsupervised anomaly detection with LSTM neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(8): 3127-3141.
- [18] Li Z W, Shi S X, Wang L Q, et al. Unsupervised generative adversarial network with background enhancement and irredundant pooling for hyperspectral anomaly detection [J]. Remote Sensing, 2022, 14(5): 1265.
- [19] Jiang K, Xie W Y, Li Y S, et al. Semisupervised spectral learning with generative adversarial network for hyperspectral anomaly detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(7): 5224-5236.
- [20] Hinton G E, Zemel R S. Autoencoders, minimum description length and Helmholtz free energy[C]//NIPS'93: Proceedings of the 6th International Conference on Neural Information Processing Systems, November 29, 1993, Denver, Colorado, USA. San Francisco: Morgan Kaufmann, 1993: 3-10.
- [21] Xie W Y, Liu B Z, Li Y S, et al. Autoencoder and adversarial-learning-based semisupervised background estimation for hyperspectral anomaly detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(8): 5416-5427.
- [22] 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: 5502905.
- [23] Su H J, Wu Z Y, Zhang H H, et al. Hyperspectral anomaly detection: a survey[J]. IEEE Geoscience and Remote Sensing Magazine, 2022, 10(1): 64-90.
- [24] 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.
- [25] 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.
- [26] 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.