

基于空谱多路自编码器的高光谱图像异常检测

贾森^{1,2,3}, 刘宽¹, 徐萌^{1,2,3}, 朱家松²

1. 深圳大学 计算机与软件学院, 深圳 518060;

2. 自然资源部大湾区地理环境监测重点实验室, 深圳 518060;

3. 粤港澳智慧城市联合实验室, 深圳 518060

摘要: 高光谱图像异常检测作为一种无监督的目标检测, 主要存在异常目标类型多样化、异常与背景不易区分、以及检测精度受场景影响大等难题。针对以上问题, 本文提出了一种基于空谱多路自编码器的高光谱图像异常检测方法。首先, 提出一种加权空谱 Gabor 滤波方法, 提取高光谱图像的多尺度空谱特征; 其次, 采用多路自编码器降低多尺度空谱特征在光谱维的冗余度, 提取空谱特征中的主要信息; 最后, 利用得到的主要空谱特征, 结合形态学滤波与双曲正切函数进行特征增强, 以提高异常与背景噪声的区分度。本文提出的方法是一种即插即用的异常检测方法, 无需额外的参数输入; 多路自编码器提取了多尺度主要空谱特征, 以应对异常目标类型多样化的难题; 通过特征增强提高了背景与异常的区分度。将本文提出的方法与 9 种流行的异常检测方法相比, 在 5 个高光谱数据集上进行验证, 通过对比异常检测结果图、接收机操作特性 (Receiver Operating Characteristic, ROC) 曲线、ROC 曲线下覆盖的面积 AUC (Area Under Curve) 以及异常像元与背景像元的箱型图等评价指标, 证明了本文方法优于其他 9 种方法。

关键词: 高光谱图像, 异常检测, 多路自编码器, 加权空谱 Gabor, 双曲正切函数, 特征增强

中图分类号: TP701/P2

引用格式: 贾森, 刘宽, 徐萌, 朱家松. 2024. 基于空谱多路自编码器的高光谱图像异常检测. 遥感学报, 28(1): 55–68

Jia S, Liu K, Xu M and Zhu J S. 2024. Hyperspectral anomaly detection based on spatial-spectral multichannel autoencoders. National Remote Sensing Bulletin, 28(1):55–68[DOI:10.11834/jrs.20242398]

1 引言

高光谱图像 HSI (Hyperspectral Image) 具有光谱分辨率高和对地物在可见光到红外波段范围内连续覆盖的优点, 能够识别地物更加精细的特征。由于不同地物反射的光谱曲线具有差异性, 因此通过光谱信息可以反演出地物的属性特征 (Rasti 等, 2020)。高光谱图像包含了丰富的光谱信息和空间信息, 具有“图谱合一”的特点。高光谱图像异常检测可以视为一个二分类的无监督任务, 旨在找到不同于背景的异常目标, 在各个应用领域都具有重要的研究意义, 如环境监测 (韩竹等, 2020), 精准农业 (袁静文等, 2020; Vanegas 等, 2018), 军事侦察与国防安全 (Ren 等, 2020;

Chang, 2000) 等。

在高光谱图像异常检测方法中, 最经典的是基于统计的 RX (Reed-Xiaoli) 算法, 大量方法都是基于该方法进行了改进。RX 算法也被称为全局 RX 即 GRX (Global RX) 算法, 它假设背景空间满足多元高斯分布, 忽略异常像元对背景均值的影响, 通过背景空间计算背景均值和背景协方差矩阵, 进而利用马氏距离计算待测像元与背景均值之间的偏离程度。将这种偏离程度作为判别待测像元是异常像元的概率 (Reed 和 Yu, 1990)。但是, 异常像元通常会影响背景均值的估计, 而且背景空间一般情况下不满足多元高斯分布。为了得到更加准确的背景均值和背景协方差矩阵, 局部 RX 即 LRX (Local RX) 算法通过滑动双窗策略

收稿日期: 2022-08-09; 预印本: 2022-12-19

基金项目: 国家自然科学基金 (编号: 62271327, 41971300, 42271336); 广东省基础与应用基础研究基金 (编号: 2022A1515011290, 2021A1515011413); 深圳市科技计划 (编号: RCJC20221008092731042, JCYJ20220818100206015, KQTD20200909113951005)

第一作者简介: 贾森, 研究方向为人工智能和遥感信息处理。E-mail: senjia@szu.edu.cn

通信作者简介: 徐萌, 研究方向为高光谱图像云检测和去除。E-mail: m.xu@szu.edu.cn

进行局部异常检测,使得局部背景均值与协方差矩阵更加准确,从而提高异常检测的效果(Molero等,2013)。双窗策略中窗口大小无法自适应确定,需要人为设定。基于核的RX即KRX(Kernel RX)算法利用高维空间中特征间非线性关系更易获得的特点,将高光谱图像映射到高维空间中,在一定程度上缓解了数据分布不均导致虚警率高的问题(Zhou等,2016)。

除了基于统计的方法外,基于表示的方法也是高光谱图像异常检测方法中的研究热点。基于表示的方法包括协同表示、低秩和稀疏矩阵分解以及基于深度学习的表示方法。基于协同表示CRD(Collaborative Representation-based Detector)的方法通过定位与邻域背景存在明显差异的像元进行异常检测(Li和Du,2015)。当异常目标由多个像元组成时,基于协同表示的方法无法很好的区分异常像元与背景像元,导致虚警率过高,检测精度不理想。Sun等(2014)首次提出了低秩和稀疏矩阵分解LRaSMD(Low-Rank and Sparse Matrix Decomposition)方法,将高光谱图像分解为同等大小的低秩矩阵和稀疏矩阵后进行异常检测。与之相似的方法还有RPCA(Chen等,2013)和RSRPCA(Sun等,2018),这些方法都假设异常不存在背景的列式子空间中,后者利用随机列式子空间和鲁棒主成分分析对原始高光谱图像中的异常进行检测。此外,基于LRaSMD的马氏距离法通过低秩稀疏矩阵分解技术将背景与异常分开,并探索背景的低秩先验知识,通过马氏距离检测异常(Xu等,2016;Pagare和Risodkar,2018)。低秩矩阵主要由背景像元构成,稀疏矩阵主要由异常像元构成。这是因为在高光谱图像中,背景像元占主要部分,且背景像元具有相似性而满足低秩性;而异常目标具有小而稀少的特点,导致异常像元具有稀疏性。利用低秩矩阵构建背景字典或者利用稀疏矩阵进行异常检测是该方法的常用手段。从数据预处理的角度考虑,由于原始高光谱数据缺乏抑制噪声的能力,可以利用分数阶傅里叶变换FrFT(Fractional Fourier Transform)增强信号(Tao等,2019)。Ma等(2021)联合分数阶傅里叶变换与低秩稀疏分解方法,利用低秩稀疏分解得到低秩矩阵,通过原子选择构建背景矩阵,再利用马氏距离对经过分数阶傅里叶变换的高光谱图像进行异常检测。由于高光谱图像波段数量多

且波段间相关性高,传统的表示方法无法很好表征高维信息,因此基于深度学习的表示方法逐渐兴起。基于深度学习的方法通常是对高光谱图像的光谱向量进行重建,利用重建误差定位异常目标(Chang等,2019;Fan等,2022)。

基于统计和表示的方法都只考虑了高光谱图像的光谱异常。而高光谱图像的异常目标可以分为空间异常和光谱异常(成宝芝等,2021)。从空间角度出发,有学者将形态属性滤波引入到高光谱图像异常检测领域,通过不同的属性滤波器对图像进行滤波,可以得到高光谱图像的结构信息,进而经过优化后得到最终的异常检测结果(Kang等,2017;Imani,2018)。从光谱角度出发,基于统计的方法和基于表示的方法都充分利用了高光谱图像丰富的光谱信息进行异常检测。

已有研究通常仅考虑高光谱的空间或光谱特征,没有充分挖掘高维数据的隐含非线性信息。因此,本文拟从空间和光谱2个维度考虑异常目标,针对异常目标类型多样化和异常与背景不易区分的难题,提出一种基于空谱多路自编码器的高光谱图像异常检测方法。首先,本文提出一种加权空谱Gabor滤波方法,利用不同尺度和方向的加权空谱Gabor核提取高光谱图像中的空间和光谱特征,构成高维空谱特征空间;其次,多路自编码器降低了多尺度空谱特征在光谱维的冗余度,提取高维空谱特征空间的主要特征,将其转换为主要特征表示空间;最后,提出一种基于双曲正切函数的特征增强方法,结合形态学滤波,对主要特征表示空间的每一个波段进行特征增强,以提高背景噪声和异常目标的区分度。本文提出的方法流程图如图1所示。

2 自编码器和三维Gabor

2.1 自编码器

自编码器AE(Autoencoder)是一种将输出训练成输入的无监督神经网络,包括编码器和解码器2个部分。编码器对输入数据进行编码,在隐藏层对输入的数据进行降维;解码器对编码后的数据进行解码,是一个数据还原过程(Kingma和Welling,2019)。

当输入向量 $\mathbf{x} \in \mathbb{R}^L$,编码器对向量 $\mathbf{x}$ 映射过程可以表示为

$$z = h^{(e)}(W^{(e)}x + b^{(e)}) \quad (1)$$

式中, $h^{(e)}(\cdot)$ 是编码器的映射函数, $z \in \mathbb{R}^l$ 是向量 x 经

过编码器中的映射函数之后的向量, l 是编码向量的长度, $W^{(e)} \in \mathbb{R}^{l \times L}$ 是权重矩阵, $b^{(e)} \in \mathbb{R}^l$ 是偏差向量。




图1 本文提出方法的流程图(G 为 k 个Gabor核与图像卷积幅值组成的高维特征空间; G' 为 G 的主要特征)

Fig. 1 The flowchart of the proposed method in this study (G is a high-dimensional feature space composed of k Gabor kernels and image convolution amplitude; G' is the main characteristics of G)

在解码器中, 向量 z 被映射为输入向量的估计:

$$y = h^{(d)}(W^{(d)}z + b^{(d)}) \quad (2)$$

式中, $h^{(d)}(\cdot)$ 是解码器的映射函数, $W^{(d)} \in \mathbb{R}^{L \times l}$ 是权重矩阵, $b^{(d)} \in \mathbb{R}^L$ 是偏差向量, 向量 y 是向量 x 的重建向量。

2.2 三维 Gabor

Gabor 滤波作为一种传统的特征提取方法, 已经在高光谱图像处理领域应用广泛 (Liu 等, 2021; Jia 等, 2022)。相较于其他特征, Gabor 特征更能符合人眼的习惯。其中, 二维 Gabor 通常应用于 RGB 图像, 而高光谱图像具有丰富的光谱信息, 因此, 可以将二维 Gabor 扩展到三维 Gabor, 同时提取空间特征与光谱特征。三维 Gabor 核的构造公式如下:

$$\begin{aligned} \Psi_{f,\varphi,\theta}(x,y,b) &= \mu(x,y,b) \times v(x,y,b) = \\ &= \frac{1}{s} \times \exp\left(-\frac{x^2 + y^2 + z^2}{2\sigma^2}\right) \times \\ &\quad \exp(j2\pi(\alpha x + \beta y + \gamma b)) \end{aligned} \quad (3)$$

式中, $\mu(x, y, b)$ 是高斯包络函数, $v(x, y, b)$ 是正弦波函数, (x, y, b) 表示相对于 Gabor 核中心的坐标位置, $s = 2\pi^{3/2}\sigma^3$ 是一个归一化值, σ 是高斯包络在三维空间的宽度。 α, β, γ 分别被定义为

$$\begin{cases} \alpha = f \sin \varphi \cos \theta \\ \beta = f \sin \varphi \sin \theta \\ \gamma = f \cos \theta \end{cases} \quad (4)$$

式中, f 是正弦波的中心频率, φ 和 θ 是矢量波在频域的角度。 $f = f_{\max}/2^i$, $\varphi = j\pi/4$, $\theta = k\pi/4$ 。其中, $(i, j, k) \in \{0, 1, 2, 3\}$, $f_{\max} = 0.5$ 。每一个三维 Gabor 核都可由 (i, j, k) 唯一确定, 因此, 三维 Gabor 核可以被表示为 $\Psi_{i,j,k}$ 。当 $j = 0$ 时, $k = 0$ 。因此, 对于每一个中心频率 f , 存在 13 个方向尺度的 Gabor 核, 进而三维 Gabor 核可以被表示成 Ψ_t , 其中, $t = 1, 2, \dots, K$, $K = 4 \times 13 = 52$ 。利用三维 Gabor 提取高光谱图像的空谱特征的过程为

$$F_t = |\Psi_t \otimes H| \quad (5)$$

式中, $\otimes$ 表示卷积, $H \in \mathbb{R}^{m \times n \times L}$ 表示高光谱图像, $|\cdot|$ 表示对卷积结果取绝对值, 即 F_t 表示三维 Gabor 对高光谱图像卷积结果的幅值。

3 研究方法

3.1 基于多路自编码器提取主要特征表示空间

众多学者致力于利用自编码器重建更加精确的光谱向量, 接着利用重建光谱向量与原光谱向量的残差定位异常目标 (Chang 等, 2019; Fan 等, 2022)。自编码器在重建光谱向量时, 异常像元的

重建难度是大于背景像元的, 即异常像元重建残差大于背景像元重建残差, 从而可以利用残差实现异常像元的定位。

本文构建多路自编码器将高维空谱特征空间转换为主要特征表示空间。其中, 多路自编码器由具有相同结构的自编码器构成, 高维空谱特征空间由高光谱图像进行加权空谱 Gabor 滤波得到。本文对于加权空谱 Gabor 核的定义为

$$\Xi_i = \Psi_i \times \omega(x, y, b) = \mu(x, y, b) \times v(x, y, b) \times \omega(x, y, b) \quad (6)$$

式中, $\mu(x, y, b)$ 为正弦波函数, $v(x, y, b)$ 为高斯包络函数, 权函数 $\omega(x, y, b)$ 的定义为

$$\omega(x, y, b) = \frac{1}{\sqrt{x^2 + y^2 + b^2 + \varepsilon}} \quad (7)$$


式中, ε 为常数, 本文设置为 1, (x, y, b) 表示相对于加权空谱 Gabor 核中心的坐标位置。

加权空谱 Gabor 对高光谱图像的滤波过程, 本质上是核与高光谱图像进行滑动卷积的过程, 可表示为:


$$G_i = |\Xi_i \otimes H| \quad (8)$$

式中, G_i 表示加权空谱 Gabor 对高光谱图像卷积结果的幅值。

图 2 展示了高光谱图像利用加权空谱 Gabor 与三维 Gabor 提取高维空谱特征之后异常检测效果的对比。以 Gulfport 高光谱数据集为例, 图 2 (a) 和 (b) 分别展示了 Gulfport 数据集利用三维 Gabor 和加权空谱 Gabor 在核大小为 3、7 和 11 时提取特征之后的异常检测图。




(a) Three-dimensional Gabor (b) Weighted spatial-spectral Gabor



(c) 精度对比(AUC值)

(c) Detection accuracy (AUC value)



(d) 异常与背景区分度对比

(d) Distinction of anomaly and background

图 2 Gulfport 数据集在 Gabor 核大小为 3, 7 和 11 时的对比

Fig. 2 Comparison of anomaly detection results on Gulfport data set at Gabor kernel size is 3, 7 and 11

如图 2 (a) 所示, 当三维 Gabor 核越大时, 提取的目标特征越模糊。如图 2 (b) 所示, 当加权空谱 Gabor 核增大时, 目标依旧可以保证一定的边

缘特征, 而且与图 2 (a) 相比, 加权空谱 Gabor 特征的背景噪声更少。图 2 (c) 和 (d) 分别展示了三维 Gabor 特征和加权空谱 Gabor 特征的异常检测

精度和背景与异常的分离图。就检测精度而言，加权空谱 Gabor 是优于三维 Gabor 的；就背景与异常的分离图而言，加权空谱 Gabor 提权的特征包含更少背景噪声且背景与异常之间更容易被区分。

加权空谱 Gabor 在约束目标边缘特征的同时，微小目标的特征也会被削弱，此时，可以通过增大核来提高微小目标特征的显著性。这种方法在三维 Gabor 中是不适用的，因为三维 Gabor 滤波得到的特征随着核的增大，目标的边缘特征被逐渐模糊化，导致异常目标无法清晰辨别。因此，通过设置一个较大的核来控制加权空谱 Gabor 提取的空谱特征，使它保留目标边缘特征的同时，能得到较为清晰的小目标特征。

对于高光谱图像 H ，与 K 个不同的加权空谱 Gabor 核进行卷积操作之后，可以得到 K 个与高光谱图像大小相等的空谱特征矩阵 G_i 。这些空谱特征矩阵共同构成了高维空谱特征空间。然而，该空间在光谱维度上存在波段冗余的情况，且在空间维度上存在背景噪声干扰的问题。其中，自编码器作为一种可以重建数据的网络结构，在数据降维和提取主要特征方面表现优异 (Zhao 等, 2017)。本文对光谱维的波段进行降维之后，剔除了大部分干扰项，对于背景噪声，本文受到空间特征处理方法 (Kang 等, 2017) 的启发，提出了一种特征增强的方法，对异常与背景进行区分。多路自编码器筛选出主要波段后，降低了区分异常与背景噪声的计算复杂度。因此，本文提出了多路自编码器提取主要特征表示空间的方法，并为解决空间维度上背景噪声干扰的问题做了数据准备。

本文将自编码器在隐藏层的节点数设置为 5，即 $l = 5$ 。同时，本文利用单层的自编码器对原始高光谱图像进行训练，损失函数为重建光谱向量与原光谱向量的均方误差，迭代次数为 200。训练后得到自编码器在该高光谱图像上的权重矩阵和偏差向量，多路自编码器共享权重与偏差向量。

多路自编码器由多个初始自编码器构成，将编码部分的输出作为多路自编码器的输出，工作过程表示如下：

$$f_u = \text{cat}(h^{(e)}(G_i)) \quad (9)$$

式中， $f_u \in \mathbb{R}^{m \times n \times J}$ 是主要特征表示空间， $J = l \times K$ ， $\text{cat}(\cdot)$ 表示将编号为 $t = 1, 2, \dots, K$ 的特征矩阵的

主要成分在光谱维上进行拼接。在 f_u 的空间维度上依旧存在背景噪声的干扰问题，为了显著区分背景与异常，接下来，本文提出了一种特征增强方法，用以突出异常目标。

3.2 特征增强

将 Gabor 核与高光谱图像进行滑动卷积操作可以提取高光谱图像空谱特征，但是，其中包含众多局部特征，既有异常目标特征，也有背景噪声。本文提出一种基于双曲正切函数的特征增强方法，将背景噪声与异常目标进行显著区分。

特征增强的过程结合了形态学滤波的方法，其中形态学滤波常用于 RGB 图像的空间特征提取，包括腐蚀、膨胀、开运算和闭运算等。在高光谱图像异常检测过程中，可以利用空间异常对光谱异常进行补充 (Imani, 2018)。本文利用开运算和闭运算提取高光谱图像的空间异常特征，结构元素均为 $[0, 1, 0; 1, 1, 1; 0, 1, 0]$ ，具体过程可以表示为

$$M_i = |X_i - O(X_i)| + |X_i - C(X_i)| \quad (10)$$

式中， M_i 表示 X_i 的空间异常特征矩阵， X_i 表示从高光谱图像中提取出来的第 i 波段， $O(\cdot)$ 表示形态学开操作， $C(\cdot)$ 表示形态学闭操作。利用式 (10) 可以提取高光谱图像的细节信息，用于异常检测 (Kang 等, 2017)。

通过主成分分析 PCA (Principal Component Analysis) 选出高光谱图像中前 l 个主要波段，然后提取每个波段的空间异常特征。最后将 l 个空间异常特征矩阵求和取平均得到最终的空间异常特征图谱 S ，计算过程为

$$S = \frac{\sum_{i=1}^l M_i}{l} \quad (11)$$

利用最终的空间异常图谱计算特征增强过程中的增强权重 $\delta \in \mathbb{R}^{m \times n}$ ：

$$\delta = \tanh(\beta S') \quad (12)$$

式中， $\tanh$ 表示双曲正切函数， β 被设置为 3， $S' = \text{GF}(S)$ ， $\text{GF}(\cdot)$ 表示高斯滤波。

主要特征表示空间 f_u 是由多路自编码器得到，在 f_u 的空间维度上中包含异常目标特征和背景噪声。本文利用增强权重对 f_u 进行特征增强，来提高异常与噪声的区分度，具体过程为

$$Y^i = \delta \times f_u^i, i = 1, 2, \dots, J \quad (13)$$

式中, f_u^i 表示主要特征表示空间的第 i 个波段, Y 是由 f_u 经过特征增强之后所得的融合矩阵。

3.3 异常检测

融合特征矩阵 $Y \in \mathbb{R}^{m \times n \times J}$, 可以被表示为 $\{y_{ij}, i=1, 2, \dots, m; j=1, 2, \dots, n\}$, $y_{ij} \in \mathbb{R}^{J \times 1}$ 是 Y 在空间位置 (i, j) 处的向量, 利用马氏距离对融合特征中的每一个向量 y_{ij} 进行背景与异常的判别, 表示过程为

$$r_{ij} = (y_{ij} - \eta)^T A^{-1} (y_{ij} - \eta) \quad (14)$$

式中, $\eta \in \mathbb{R}^{J \times 1}$ 和 $A \in \mathbb{R}^{J \times J}$ 分别表示 Y 的波段均值和协方差矩阵。 r_{ij} 是衡量向量 y_{ij} 与均值 η 偏离程度的值。当 r_{ij} 值越大时, 向量 y_{ij} 被认定为异常的概率越大。

当融合特征矩阵中所有的向量都被计算出对应的偏离值之后, 这些偏离值构成了的异常检测图 $r = \{r_{ij}, i=1, 2, \dots, m; j=1, 2, \dots, n\}$ 。

高斯滤波对图像进行平滑处理, 可以消除高斯噪声, 但是会存在一种情况, 若异常被当作高斯噪声消除, 则会影响检测结果, 这就导致了检测精度的下降。为了防止这一情况出现, 本文在利用高斯滤波做平滑处理后, 与处理前的结果做平均, 以排除异常被消除的可能。同时, 引入高斯滤波做平滑处理可以一定程度上降低背景噪声对判断异常的影响。本文利用高斯滤波对结果进行优化, 过程如下:

$$r' = \frac{r + \text{GF}(r)}{2} \quad (15)$$

式中, r' 是通过高斯滤波与原异常检测结果进行修正之后的结果。归一化后得到最终的异常检测结果为

$$r^* = \frac{r' - \min(r')}{\max(r') - \min(r')} \quad (16)$$

4 实验结果与分析

4.1 实验数据集的获取

本研究获得的 5 个实验数据集特征信息详见表 1。具体阐述如下:

(1) Los Angeles 数据集。第一个数据集由 AVIRIS 传感器在 Los Angeles 地区获取。实验数据是空间大小为 100×100 的高光谱图像, 包含了 205 个波段, 光谱范围为 400—2500 nm, 空间分辨率为 7.1 m。图像中有 2 个飞行器被标记异常目标, 共

包含 87 个异常像素点。

表 1 5 种高光谱数据集的信息

Table 1 The information of five hyperspectral data sets

数据集	空间大小/ 像素	波段数/ 个	异常像素总数/ 个	空间分辨率/ 米
Los Angeles	100×100	205	87	7.1
Gulfport	100×100	191	60	3.4
Pavia Center	150×150	102	68	1.3
San Diego	100×100	189	134	3.5
Salinas syn	100×100	204	181	3.7

(2) Gulfport 数据集。该数据集来自 AVIRIS 传感器在 Gulfport 地区获取的高光谱图像, 截取其中大小为 $100 \times 100 \times 191$ 的区域作为实验数据, 空间分辨率为 3.4 m, 光谱范围为 400—2500 nm。图像中有 3 个飞行器被标记异常目标, 共包含 60 个异常像素点。

(3) Pavia Center 数据集。该实验数据来自于 ROSIS 传感器获取的 Pavia Center 高光谱图像。该高光谱图像的光谱范围为 430—860 nm, 空间分辨率为 1.3 m, 通过人工方法去除低信噪比波段和水汽吸收波段之后, 剩余 102 个波段。实验数据的空间大小为 150×150 , 共包含 68 个异常像素点。

(4) San Diego 数据集。第 4 个实验数据由 AVIRIS 传感器在 San Diego 海军机场获得。该实验数据在 370—2510 nm 的光谱范围之间共包含 224 个波段, 在去除低信噪比波段和水汽吸收波段之后, 剩余 189 个波段。在空间大小为 100×100 的范围内共包含 134 个异常像素点, 它的空间分辨率为 3.5 m。

(5) Salinas syn 数据集。第 5 个实验数据是一个合成高光谱数据集, 包含人为制造的异常目标像素和图像中真实存在的异常目标像素, 它的空间大小为 100×100 , 共包含 204 个波段, 空间分辨率为 3.7 m, 其中含有 181 个异常像素。高光谱图像的伪彩色图以及异常目标的参考图如图 3 所示。

4.2 高光谱异常检测方法对比

本文与 9 种主流的高光谱异常检测方法进行对比, 详述如下:

(1) GRX (Reed 和 Yu, 1990) 全局 RX 算法是高光谱图像异常检测的基准方法, 利用待测光谱向量与背景均值向量的马氏距离衡量该待测像元的异常概率。其优点在于检测速度快和无需额外参数输入, 缺点在于该算法假设背景数据空间满足多元高斯分布。




图3 5个数据集的伪彩色图和真值图

Fig. 3 The false color images and ground truth of five public data sets

(2) LRX (Molero 等, 2013) 局部 RX 算法利用双窗之间的像元构建局部背景, 进而计算背景协方差矩阵和背景均值。由于局部背景受到异常像元的影响更小, 因此在检测效果上要优于全局 RX 算法。但是, 该算法在不同的高光谱数据中窗口大小是不一样的, 导致该方法的泛化能力较弱。在本文实验所用的 5 个高光谱图像中, 将内窗大小设置在 $[3, 19]$ 之间, 外窗大小设置在 $[5, 21]$ 之间, 都以 2 为间隔进行取值, 内窗大小始终小于外窗大小, 在每个高光谱数据集中, 本文选择最优的参数作为该方法的输入参数。

(3) CRD (Li 和 Du, 2015) 协同表示方法的基本思想是若待测像元能被邻域像元组所表示, 则该待测像元是背景像元, 否则该待测像元为异常像元。该方法的双窗尺寸参数在每个高光谱数据中是不同的, 导致该方法的泛化能力较弱。在本文实验所用的 5 个高光谱数据中, 内窗大小和外窗大小的取值范围和间隔取值与 LRX 算法设置相同。本文选择每个高光谱数据的最优双窗参数作为该方法的输入参数, 同时, 正则化参数被设置为 10^{-6} 。

(4) RPCA (Chen 等, 2013) 利用高光图像在光谱维上的高相关性和异常的稀疏性, 建立一个凸优化问题, 使得背景子空间核范数最小和异常子空间的范数最小化, 从而将高光图像分解为低秩背景子空间和稀疏异常子空间。从稀疏异常子空间中分离出异常, 而不是逐像素检测异常。

(5) FrFE-RX (Tao 等, 2019) 算法通过分数

阶傅里叶变换对高光谱图像进行预处理, 突出光谱维度的异常特征。利用熵值自适应确定最优傅里叶变换阶数, 使得该算法没有额外的参数输入, 从而增强了该算法的泛化能力。该算法从光谱角度考虑了异常的情况, 结合马氏距离得到最终的异常检测结果。

(6) FEBPAD (Ma 等, 2021) 方法结合了分数阶傅里叶变换与低秩稀疏分解方法, 能够突出异常值。FEBPAD 方法在低秩矩阵的基础上进行背景纯化, 从而构建出更加纯净的背景空间。由背景空间计算得到背景均值和背景协方差矩阵, 继而利用马氏距离对待测像元进行异常检测。

(7) KIFD (Li 等, 2020) 方法是一种孤立森林的核方法, 充分利用高光谱图像的全局和局部信息, 更好地将异常从背景中分离出来, 利用局部森林对初始异常检测图进行细化, 以突出高光谱图像中的异常目标。

(8) AE 自编码器在高光谱图像异常检测领域内应用广泛, 其中最常见的是利用自编码器的重建图像与原图像的重建误差去表征异常的概率。本文利用稀疏自编码器对高光谱图像进行重建, 将重建光谱向量与原光谱向量的残差平方作为该像元是异常像元的概率。

(9) RGAE (Fan 等, 2022) 是一种基于鲁棒图自编码器的高光谱异常检测算法, 由于自编码器在训练过程中对噪声和异常非常敏感, 像素之间的相关性容易丢失, 为了使 AE 在训练中更好地处理噪声和异常值, 利用 $L_{1,2}$ 范数进行优化。最后,

利用重建残差表示高光谱图像的异常情况。

4.3 实验结果分析

本文在4个真实的高光谱数据集和1个合成的高光谱数据集上进行实验,并将实验结果进行对比分析,从而比较算法的优劣。实验结果从以下4个方面进行评价:(1)异常检测结果图;(2)接收机操作特性曲线;(3)ROC曲线下覆盖面积;(4)异常像元与背景像元的箱型图。

异常检测是一种非数值评价指标,可以直观地定位异常目标,但有时会混入背景噪声,当异常目标越显著时,表明该算法在该数据集上表现越好。ROC曲线是当验证集中虚警率到达不同值时,相对应的检测概率与虚警率形成的曲线。当检测概率 p_d 达到1时,虚警率 p_f 越小,则说明该异常检测算法越好。检测概率 $p_d = N_d/N_T$ 和虚警率 $p_f = N_f/N$,式中, N_d 、 N_T 、 N_f 和 N 分别为给定一个阈值下检测到的目标像素数、真实异常像素总数、虚警像素数和高光谱图像中的像素数。AUC值表示ROC曲线的覆盖面积,是衡量一个算法在某个高光谱数据集上异常检测效果优劣的常用指标,AUC值越大表明该算法表现越好。对于异常像元与背景像元的箱型图,当异常像元矩形箱与背景像元矩形箱之间的距离越远时,表明异常像元与背景像元越容易被区分,则该算法表现越好。

图4展示了10种异常检测方法在5个高光谱数据集上的异常检测结果。可见从上到下,对应的数据集依次为Los Angeles、Gulfport、Pavia Center、San Diego和Salinas syn。具体如下:对于Los Angeles数据集,GRX、CRD、RPCA、FrFE-RX和FEBPAD方法可以检测到异常目标,但是失去了异常目标的边缘信息,且存在过多背景噪声,导致对于异常目标的判断会存在偏差;LRX、AE和RGAE方法在Los Angeles数据集上的背景噪声较少,可以判断出异常目标的位置,但是依然存在丢失异常目标边缘的情况;KIFD方法可以清晰的显示图像中的2个飞行器目标,但是存在较多的背景噪声;本文提出的方法在Los Angeles数据集上也存在噪声的影响,但是目标信息被很好的保存下来且与噪声存在明显的区别。对于Gulfport数据集,1个大的飞行器和2个小的飞行器被视为异常目标,GRX、LRX、CRD、RPCA、FrFE-RX和FEBPAD方法都可以检测到大的飞行器,但都无法检测到

小的飞行器;AE和RGAE方法没有检测到直观的异常目标;KIFD方法可以检测到3个飞行器,同时,也检测到道路线等背景噪声,检测图的噪声较多;本文提出的方法可以很好地检测到3个异常目标。对于Pavia Center数据集,GRX、LRX、RPCA和FrFE-RX方法的检测图噪声少,异常目标更直观,但是与异常目标参考图相比,可以得知,这3种方法都丢失部分异常目标;CRD、FEBPAD和本文提出的方法都存在过多噪声,影响了异常目标的判断;AE和RGAE方法的检测图可以清楚分辨出异常目标;KIFD方法在此数据集中失效,无法检测到明显异常目标。对于San Diego数据集,3个飞行器被视为异常目标,GRX、CRD、RPCA、FrFE-RX、FEBPAD、KIFD、AE、RGAE和本文提出的方法都可以检测异常目标,而且本文提出的方法可以清晰地区分出异常目标;LRX方法在San Diego数据集上无法得到直观的异常检测图。对于Salinas syn数据集,GRX、RPCA和FrFE-RX方法无法得到直观的异常检测图;LRX、CRD和FEBPAD方法丢失部分异常目标;KIFD方法由于噪声的影响,无法判断异常检测情况;AE、RGAE方法和本文提出的方法可以得到清晰的异常检测图。因此,就异常检测图而言,本文提出的方法优于其他9种方法,能够保证异常目标边缘特征的基础上,还可以明显区分异常目标与背景噪声。

图5展示了10种方法在5个数据集上的ROC结果。可见:对于高光谱数据集Los Angeles、Gulfport、Pavia enter和Salinas syn,可以很直观地看到本文提出的方法在检测概率 p_d 达到1时,虚警率 p_f 是最小的;对于San Diego数据集,当检测概率 p_d 达到1时,RGAE方法的虚警率 p_f 是最小的。综上所述,就ROC曲线而言,本文提出的方法在5个数据集上的表现优于其他9种方法。

表2展示了10种方法在5个高光谱数据集上AUC值的情况。AUC值的取值范围为 $[0, 1]$,且保留4位小数。表2中每一行加粗的值是该行中的最优值,即10种方法中对该数据集进行异常检测时的最优方法。通过表中数据,可以直观地看到,在Los Angeles和Gulfport数据集中,LRX方法对应AUC值接近本文提出方法的AUC值,但是依旧小于本文提出的方法所对应的AUC值。在San Diego数据集中,本文提出的方法排名第三,KIFD和

RGAE 方法的 AUC 值大于本文提出的方法。在 Salinas syn 数据集中, AE 方法对应的 AUC 值接近但小于本文提出方法所对应的 AUC 值。本文提出的方法在 5 个数据集中的 AUC 值依次是 0.9910、0.9912、0.9968、0.9806、0.9812。对于每种异常

检测方法而言, 在 5 个数据上的 AUC 值的平均值依次为 0.8955、0.9429、0.9253、0.9012、0.9259、0.9372、0.8201、0.8130、0.8699、0.9882。可以看出, 本文提出的方法的鲁棒性是优于其他方法的, 且在总体表现上是最好的。




图4 10种方法在5个数据集上的异常检测结果图

Fig. 4 Anomaly detection maps of ten methods on five data sets




图5 不同方法在5个数据集上的ROC曲线

Fig. 5 ROC curves of different methods on five data sets

表2 不同高光谱异常检测方法在5个数据集上的AUC值
Table 2 The AUC values of different anomaly detection methods on the five data sets

数据集	GRX	LRX	CRD	RPCA	FrFE-RX	FEBPAD	KIFD	AE	RGAE	本文方法
Los Angeles	0.8404	0.9847	0.9654	0.8474	0.9224	0.9175	0.9750	0.7224	0.7468	0.9910
Gulfport	0.9526	0.9853	0.9630	0.9536	0.9790	0.9217	0.9720	0.5605	0.7567	0.9912
Pavia Center	0.9538	0.9545	0.9396	0.9603	0.9107	0.9494	0.8141	0.8523	0.9041	0.9968
San Diego	0.9403	0.8655	0.9411	0.9318	0.9740	0.9774	0.9928	0.9528	0.9919	0.9806
Salinas syn	0.7906	0.9245	0.8175	0.8127	0.8432	0.9201	0.3468	0.9772	0.9499	0.9812
平均	0.8955	0.9429	0.9253	0.9012	0.9259	0.9372	0.8201	0.8130	0.8699	0.9882

注：加粗AUC值表示该高光谱图像在各种方法中最优的检测结果。

图6展示了背景像元与异常像元的箱型图。箱型图可以直观反映背景像元与异常像元之间的区别程度，当背景像元矩形箱与异常像元矩形箱之间的距离越大时，表明异常像元与背景像元越容易被区分，从而使得异常像元更直观。由图6可见

在5个高光谱数据集中，本文提出方法的异常像元矩形箱与背景像元矩形箱之间的距离都是最大的。因此，对于背景像元与异常像元的箱型图，本文提出的方法是最优的，本文提出的方法可以很好地区分异常像元与被误检的背景噪声。




图6 不同异常检测方法在5个数据集上的箱型图
Fig. 6 The box-plots of different anomaly detection methods on five data sets

表3展示了不同方法在5个数据集上的运行时间，利用每种方法在5个数据集上的平均运行时间表示该方法的计算效率，GRX方法表现最好，本文提出的方法仅优于RGAE方法。虽然本文提出的

方法在计算效率上的优势不明显，但结合表2可知，本文提出方法的平均检测精度最高，并且计算时间在可接受范围内，因此本文提出的方法仍具有竞争性。

表3 不同方法在5个数据集上的运行时间
Table 3 The run time of different anomaly detection methods on five data sets

/s

数据集	GRX	LRX	CRD	RPCA	FrFE-RX	FEBPAD	KIFD	AE	RGAE	本文方法
Los Angeles	0.08	50.95	12.75	6.63	18.62	2.99	55.56	15.81	125.03	104.63
Gulfport	0.08	47.02	15.58	3.24	16.79	2.91	58.55	18.65	116.56	102.32
Pavia Center	0.06	53.26	8.61	3.76	14.67	3.37	75.97	4.35	171.29	98.36
San Diego	0.09	47.01	12.20	3.28	18.72	2.95	56.12	18.12	114.06	103.48
Salinas syn	0.11	50.51	6.49	3.40	19.56	3.10	59.72	31.25	120.37	104.13
平均	0.08	49.75	11.13	4.06	17.67	3.06	61.18	17.64	129.46	102.58

图7展示了10种方法在5个数据集上异常检测结果的二值化图像，本文将阈值设置为0.5。对于Los Angeles数据集，本文提出的方法和KIFD方法可以检测出两个异常目标，本文提出的方法背景噪声更少。对于Gulfport数据集，只有本文提出的方法还可以检测出一个大的飞行器目标。对于Pavia Center数据集，只有本文提出的方法可以检测出6个异常目标中的4个，且不存在背景噪声的干扰。对于San Diego数据集，本文提出的方法和KIFD方法可以检测到被标记的三个异常目标，其中，本文提出的方法背景噪声更少。对于Salinas syn数据集，LRX、CRD、RGAE和本文提出的方法可以得到清晰的异常分割图，其中，LRX方法丢失4个小目标，CRD方法丢失2个小目标，本文提出的方法丢失3个小目标，RGAE可以检测到小的异常目标，但是所有方法都没检测到参考图中的最大的异常目标。综上所述，本文提出的方法

在5个数据集上的检测结果的二值化图像表现最好，即本文提出的方法的检测结果可以更容易定位异常目标。

表4展示了10种异常检测方法在5个数据集上二值化阈值分割影像（阈值为0.5）的AUC值，每一行加粗的值为10种方法中的最优值。对于Los Angeles、Gulfport、Pavia Center和San Diego这四个数据集，本文提出的方法表现最好，AUC值分别为0.8082、0.7655、0.8984和0.8800。对于Salinas syn数据集，表现最好的方法是RGAE，比本文提出的方法高0.0238。通过比较各方法在5个数据集平均AUC值可知，本文提出的方法鲁棒性优于其他9种对比方法。通过图7可知，在进行阈值分割时，二值化影像漏检了部分异常像素。对比表4与表2中的AUC值，当目标像素被漏检或者背景像素被误检，都会造成检测概率降低和虚警率升高，导致AUC值下降。

表4 5个数据集上检测结果二值化图像的AUC值
Table 4 The AUC values of binarized images of detection results on five data sets

数据集	GRX	LRX	CRD	RPCA	FrFE-RX	FEBPAD	KIFD	AE	RGAE	本文方法
Los Angeles	0.6331	0.6163	0.6508	0.6203	0.6201	0.6114	0.7787	0.6209	0.6209	0.8082
Gulfport	0.6074	0.6121	0.6075	0.6073	0.6170	0.6170	0.6660	0.6072	0.6068	0.7655
Pavia Center	0.8768	0.8755	0.8831	0.8739	0.8768	0.8763	0.8785	0.8752	0.8764	0.8984
San Diego	0.6527	0.6565	0.6486	0.6574	0.6483	0.6564	0.8635	0.6673	0.6717	0.8800
Salinas syn	0.5717	0.6324	0.6276	0.5716	0.5717	0.5724	0.5678	0.5720	0.6770	0.6532
平均	0.6683	0.6786	0.6835	0.6661	0.6668	0.6668	0.7509	0.6685	0.6906	0.8011

注：加粗AUC值表示该高光谱图像在各种方法中最优的二值化结果。

通过观察10种方法在5个高光谱数据集上的实验结果，就异常检测图，ROC曲线，AUC值和箱型图这四种评价指标以及二值化图像而言，本文提出的方法优于其他9种对比方法。

4.4 消融实验及分析

在消融实验的过程中，存在5种状态方法，在

评价5种消融状态的优劣时，本文采用AUC值来对比各个方法的效果。当AUC值越大时，表明该方法检测效果越好。每种状态方法的解释如下：

MAF：表示形态学滤波的结果；3DGabor_PCA：表示利用三维Gabor在提取到高光谱图像的空谱特征之后，利用主成分分析方法提取主要特征，最后利用马氏距离进行异常检测的方法；

3DGabor_AE: 与3DGabor_PCA相比, 采用了多路自编码器的方法提取三维Gabor特征的主要成分; 3DGabor_AE_tanh: 在3DGabor_AE的基础上, 引入特征增强模块; 本文方法: 与3DGabor_AE_tanh相比, 该方法利用了本文提出的加权空谱Gabor提取高光谱图像的空谱特征。

如表5所示, 在5个高光谱数据集中, 本文提出方法的检测效果(AUC)是最优的。通过3DGabor_PCA与3DGabor_AE方法在5个数据集上检测效果的对比, 除了San Diego数据集之外, 其他四个数据的效果都有所提升, 说明利用多路自编码器提取高维空谱特征的主要成分更有利于高光谱图像的异常检测。通过3DGabor_AE_tanh与3DGabor_AE在5个数据集上的比较, 可以看出, 基于双曲正切函数和形态学率波的特征增强方法有利于区分异常与背景噪声, 从而提高异常检测精度。通过本文方法与3DGabor_AE_tanh在5个数据集上的结果对比可知, 本文提出的加权空谱Gabor方法能提取更强的高维空谱特征, 有利于异常检测精度的提升。

表5 消融实验结果(AUC值)

Table 5 The results of ablation experiments (AUC values)

数据集	MAF	3DGabor_PCA	3DGabor_AE	3DGabor_AE_tanh	本文方法
Los Angeles	0.9432	0.9751	0.9760	0.9780	0.9910
Gulfport	0.9112	0.9880	0.9880	0.9902	0.9912
Pavia Center	0.9821	0.9658	0.9704	0.9840	0.9968
San Diego	0.9761	0.9654	0.9637	0.9775	0.9806
Salinas syn	0.8603	0.9300	0.9324	0.9745	0.9812

注:加粗的AUC值表示消融实验过程中的最优结果。

通过消融实验可知, 相较于三维Gabor, 加权空谱Gabor提取了更显著的空谱特征, 有助于提高检测精度; 多路自编码器将高维空谱特征空间转换为主要特征表示空间, 降低了高维空谱特征空间在光谱维的冗余度, 相比于传统的主成分分析方法, 多路自编码器更有利于高光谱图像的异常检测; 基于双曲正切函数的特征增强方法, 提高了异常检测过程结果中背景噪声与异常的区分度, 从而提高了检测精度。

5 结 论

本文基于高光谱图像“图谱合一”特性, 提出了一种基于空谱多路自编码器的高光谱图像异

常检测方法。主要研究结论如下:

(1) 本文提出的方法可以从高光谱图像中提取更加显著的空谱特征, 更全面地捕捉和分析图像中的信息以应对异常类型的多样化, 并构成高维空谱特征空间, 有助于提高算法的鲁棒性。

(2) 多路自编码器将高维空谱特征空间转换为主要特征表示空间, 可以很好地降低光谱维波段冗余度, 降低了异常检测过程中的计算复杂度, 能够更迅速、更准确地识别和处理各种异常情况。

(3) 基于双曲正切函数的特征增强方法可以显著提高空间维异常与背景噪声的区分度, 从而清晰地定位异常目标。本文提出的方法相比于其他9种方法更具鲁棒性。

虽然本文在5个数据集上的检测效果优于其他9种常用方法, 但本文提出的方法依旧存在不足之处, 首先, 加权空谱Gabor并不能完全消除卷积过程带来的边缘模糊问题; 其次, 选择过小的Gabor核, 无法提取到显著的稀疏小目标的特征, 选择过大的Gabor核, 又会产生目标边缘模糊以及计算量增加等诸多问题。因此, 如何更好地处理核大小、边缘模糊以及稀疏异常小目标三者之间的关系仍然有待进一步研究。

参考文献(References)

- Chang C I. 2000. An information-theoretic approach to spectral variability, similarity, and discrimination for hyperspectral image analysis. *IEEE Transactions on Information Theory*, 46(5): 1927-1932 [DOI: 10.1109/18.857802]
- Chang S Z, Du B and Zhang L P. 2019. A sparse autoencoder based hyperspectral anomaly detection algorithm using residual of reconstruction error//IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama: IEEE: 5488-5491 [DOI: 10.1109/IGARSS.2019.8898697]
- Chen S Y, Yang S M, Kalpakis K and Chang C I. 2013. Low-rank decomposition-based anomaly detection//Proceedings Volume 8743, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XIX. Baltimore: SPIE: 171-177 [DOI: 10.1117/12.2015652]
- Cheng B Z, Zhao C H and Zhang L L. 2021. Research advances of anomaly target detection algorithms for hyperspectral imagery. *Electronics Optics and Control*, 28(5): 56-59, 65 (成宝芝, 赵春晖, 张丽丽. 2021. 高光谱图像异常目标检测算法研究进展. *光电与控制*, 28(5): 56-59, 65) [DOI: 10.3969/j.issn.1671-637X.2021.05.013]
- Fan G H, Ma Y, Mei X G, Fan F, Huang J and Ma J Y. 2022. Hyper-

- spectral anomaly detection with robust graph autoencoders. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5511314 [DOI: 10.1109/TGRS.2021.3097097]
- Han Z, Gao L R, Zhang B, Sun X and Li Q T. 2020. Nonlinear hyperspectral unmixing algorithm based on deep autoencoder networks. *Journal of Remote Sensing*, 24(4): 388-400 (韩竹, 高连如, 张兵, 孙旭, 李庆亭. 2020. 高分五号高光谱图像自编码网络非线性解混. *遥感学报*, 24(4): 388-400) [DOI: 10.11834/jrs.20209188]
- Imani M. 2018. Anomaly detection using morphology-based collaborative representation in hyperspectral imagery. *European Journal of Remote Sensing*, 51(1): 457-471 [DOI: 10.1080/22797254.2018.1446727]
- Jia S, Liao J H, Xu M, Li Y, Zhu J S, Sun W W, Jia X P and Li Q Q. 2022. 3-D Gabor convolutional neural network for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5509216 [DOI: 10.1109/TGRS.2021.3087186]
- Kang X D, Zhang X P, Li S T, Li K L, Li J and Benediktsson J A. 2017. Hyperspectral anomaly detection with attribute and edge-preserving filters. *IEEE Transactions on Geoscience and Remote Sensing*, 55(10): 5600-5611 [DOI: 10.1109/TGRS.2017.2710145]
- Kingma D P and Welling M. 2019. An introduction to variational autoencoders. *Foundations and Trends® in Machine Learning*, 12(4): 307-392 [DOI: 10.1561/22000000056]
- Li S T, Zhang K Z, Duan P H and Kang X D. 2020. Hyperspectral anomaly detection with kernel isolation forest. *IEEE Transactions on Geoscience and Remote Sensing*, 58(1): 319-329 [DOI: 10.1109/TGRS.2019.2936308]
- Li W and Du Q. 2015. Collaborative representation for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 53(3): 1463-1474 [DOI: 10.1109/TGRS.2014.2343955]
- Liu C Y, Li J, He L, Plaza A, Li S T and Li B. 2021. Naive Gabor networks for hyperspectral image classification. *IEEE Transactions on Neural Networks and Learning Systems*, 32(1): 376-390 [DOI: 10.1109/TNNLS.2020.2978760]
- Ma Y, Fan G H, Jin Q W, Huang J, Mei X G and Ma J Y. 2021. Hyperspectral anomaly detection via integration of feature extraction and background purification. *IEEE Geoscience and Remote Sensing Letters*, 18(8): 1436-1440 [DOI: 10.1109/LGRS.2020.2998809]
- Molero J M, Garzón E M, García I and Plaza A. 2013. Analysis and optimizations of global and local versions of the RX algorithm for anomaly detection in hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(2): 801-814 [DOI: 10.1109/JSTARS.2013.2238609]
- Pagare M S and Risodkar Y R. 2018. Low-rank and sparse representation for anomaly detection in hyperspectral images//2018 International Conference on Advances in Communication and Computing Technology (ICACCT). Sangamner: IEEE: 594-597 [DOI: 10.1109/ICACCT.2018.8529636]
- Rasti B, Hong D F, Hang R L, Ghamisi P, Kang X D, Chanussot J and Benediktsson J A. 2020. Feature extraction for hyperspectral imagery: the evolution from shallow to deep: overview and toolbox. *IEEE Geoscience and Remote Sensing Magazine*, 8(4): 60-88 [DOI: 10.1109/MGRS.2020.2979764]
- Reed I S and Yu X L. 1990. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 38(10): 1760-1770 [DOI: 10.1109/29.60107]
- Ren L, Zhao L Y and Wang Y L. 2020. A superpixel-based dual window RX for hyperspectral anomaly detection. *IEEE Geoscience and Remote Sensing Letters*, 17(7): 1233-1237 [DOI: 10.1109/LGRS.2019.2942949]
- Sun W W, Liu C, Li J L, Lai Y M and Li W Y. 2014. Low-rank and sparse matrix decomposition-based anomaly detection for hyperspectral imagery. *Journal of Applied Remote Sensing*, 8(1): 083641 [DOI: 10.1117/1.JRS.8.083641]
- Sun W W, Yang G, Li J L and Zhang D F. 2018. Randomized subspace-based robust principal component analysis for hyperspectral anomaly detection. *Journal of Applied Remote Sensing*, 12(1): 015015 [DOI: 10.1117/1.JRS.12.015015]
- Tao R, Zhao X D, Li W, Li H C and Du Q. 2019. Hyperspectral anomaly detection by fractional Fourier entropy. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(12): 4920-4929 [DOI: 10.1109/JSTARS.2019.2940278]
- Vanegas F, Bratanov D, Powell K, Weiss J and Gonzalez F. 2018. A novel methodology for improving plant pest surveillance in vineyards and crops using UAV-based hyperspectral and spatial data. *Sensors*, 18(1): 260 [DOI: 10.3390/s18010260]
- Xu Y, Wu Z B, Li J, Plaza A and Wei Z H. 2016. Anomaly detection in hyperspectral images based on low-rank and sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 54(4): 1990-2000 [DOI: 10.1109/TGRS.2015.2493201]
- Yuan J W, Wu C, Du B, Zhang L P and Wang S G. 2020. Analysis of landscape pattern on urban land use based on GF-5 hyperspectral data. *Journal of Remote Sensing*, 24(4): 465-478 (袁静文, 武辰, 杜博, 张良培, 王树根. 2020. 高分五号高光谱遥感影像的城市土地利用景观格局分析. *遥感学报*, 24(4): 465-478) [DOI: 10.11834/jrs.20209252]
- Zhao C H, Li X Y and Zhu H F. 2017. Hyperspectral anomaly detection based on stacked denoising autoencoders. *Journal of Applied Remote Sensing*, 11(4): 042605 [DOI: 10.1117/1.JRS.11.042605]
- Zhou J, Kwan C, Ayhan B and Eismann M T. 2016. A novel cluster kernel RX algorithm for anomaly and change detection using hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 54(11): 6497-6504 [DOI: 10.1109/TGRS.201622585495]

Hyperspectral anomaly detection based on spatial–spectral multichannel autoencoders

JIA Sen^{1,2,3}, LIU Kuan¹, XU Meng^{1,2,3}, ZHU Jiasong²

1. Shenzhen University, College of Computer Science and Software Engineering, Shenzhen 518060, China;
2. Key Laboratory for Geo-Environmental Monitoring of Coastal Zone of the Ministry of Natural Resources, Shenzhen 518060, China;
3. Guangdong-Hong Kong-Macau Joint Laboratory for Smart Cities, Shenzhen 518060, China

Abstract: Hyperspectral anomaly detection is a type of unsupervised target detection that is crucial in the national economy and attracts the attention of numerous researchers. However, hyperspectral anomaly detection faces several challenges, such as diversified anomaly targets, difficulty in distinguishing anomalies from the background, and low detection accuracy. A hyperspectral anomaly detection method based on multichannel autoencoders is proposed to form a high-dimensional spatial-spectral feature space to address the above challenges. First, weighted spatial-spectral Gabor kernels with different scales and directions are proposed to extract the spatial-spectral features from hyperspectral images. These Gabor kernels are then redefined to increase the gap between the central and surrounding values in the kernels. The spatial-spectral features are extracted by weighted spatial-spectral Gabor kernels to form a high-dimensional spatial-spectral feature space. Second, multichannel autoencoders reduce the redundancy of multiscale spatial-spectral features in spectral dimension, extract the principal features from high-dimensional spatial-spectral feature space, and transform them into the principal feature representation space. Finally, a feature enhancement method based on hyperbolic tangent function and morphological filters is proposed to improve the distinction between abnormal targets and background noise and address the background noise in the spatial dimension. Mahalanobis distance is used to detect anomalies in the enhanced principal feature representation space. The proposed method is compared with nine state-of-the-art anomaly detection methods on five hyperspectral data sets. Anomaly Detection Maps (ADMs), Receiver Operating Characteristics (ROCs), Area Under Curves (AUCs), and box plots between abnormal and background pixels are used to evaluate the performance of the compared methods. AUC is a quantitative evaluation method, and the others are qualitative evaluation methods. The anomaly detection maps obtained by the proposed method easily locates abnormal targets compared with other methods. The ROC curves on five hyperspectral data sets show that the proposed method has a superior performance. The AUC values of five hyperspectral data sets are 0.9910, 0.9912, 0.9968, 0.9806, and 0.9812. The box plots show that the proposed method increases the gap between the anomalies and the background. The ablation experiments show that weighted spatial-spectral Gabor can extract more significant spatial-spectral features than three-dimensional Gabor. The principal feature representation space obtained by multichannel autoencoders is highly conducive to hyperspectral anomaly detection and improves detection accuracy. The feature enhancement method based on hyperbolic tangent function can improve the distinction between abnormal targets and background noise. The proposed method can extract significant spatial-spectral features from hyperspectral images to address the diversification of anomaly types and form a high-dimensional spatial-spectral feature space. The multichannel autoencoders convert the high-dimensional spatial-spectral feature space into the principal feature representation space, which can effectively reduce band redundancy in the spectral dimension and decrease the computational complexity in the anomaly detection process. The feature enhancement method based on hyperbolic tangent function can significantly improve the distinction between anomalies and background noise to locate the abnormal target.

Key words: hyperspectral image, anomaly detection, multichannel autoencoders, weighted spatial-spectral Gabor, hyperbolic tangent function, feature enhancement method

Supported by National Natural Science Foundation of China (No. 62271327, 41971300, 42271336); The Project of Department of Education of Guangdong Province (No. 2023KCXTD029); The Guangdong Basic and Applied Basic Research Foundation (No. 2022A1515011290, 2021A1515011413); Shenzhen Science and Technology Program (No. RCJC20221008092731042, JCYJ20220818100206015, KQTD20200909113951005)