

# 结合注意力机制的自监督高光谱图像异常检测

陈婷婷<sup>1</sup>, 胡兴<sup>1,2</sup>, 刘德权<sup>3</sup>, 蒋林华<sup>4</sup>, 张大伟<sup>1</sup>

(1. 上海理工大学 光电信息与计算机工程学院, 上海 200093; 2. 云南省科学技术院, 昆明 650228; 3. 华北科技学院, 廊坊 065201; 4. 巴黎高等电子学院-索邦联合实验室, 巴黎 92130)

**摘要:** 高光谱图像异常检测广泛应用于农业、军事、地质、生物等领域。针对高光谱异常检测中数据样本少和空谱特性利用不足的问题, 提出了一种结合注意力机制的自监督高光谱图像异常检测算法。首先, 通过 2D 卷积自监督网络提取高光谱图像的光谱特征和空间特征来重构背景, 引入注意力机制自适应的学习特征通道权重, 实现特征优化; 其次, 考虑背景重构后图像信息量的减少问题, 在损失函数中引入图像信息熵对特征编码进行约束, 改善网络性能; 最后, 使用马氏距离实现异常值计算。将所提算法在两组来自不同场景的高光谱图像数据集上进行实验, 并与 7 种同类算法进行了对比。结果表明, 该算法在检测结果的 AUC 指标上均取得了最高值。

**关键词:** 高光谱图像; 异常检测; 自监督网络; 注意力机制

**中图分类号:** TP 751.1 **文献标志码:** A

## Anomaly detection in hyperspectral images combining self-supervision and attention mechanism

CHEN Tingting<sup>1</sup>, HU Xing<sup>1,2</sup>, LIU Dequan<sup>3</sup>, JIANG Linhua<sup>4</sup>, ZHANG Dawei<sup>1</sup>

(1. School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Yunnan Provincial Academy of Science and Technology, Kunming 650228, China; 3. North China Institute of Science and Technology, Langfang 065201, China; 4. Institut supérieur d'électronique de Paris-Sorbonne Joint Research Lab, Paris 92130, France)

**Abstract:** Hyperspectral image anomaly detection is widely used in agriculture, military, geology, biology, and other fields. To solve the problem of few samples and insufficient utilization of space spectrum characteristics, an anomaly detection algorithm for hyperspectral images combining self-supervision and attention mechanism was proposed. Firstly, a 2D convolutional self-supervised network

收稿日期: 2023-10-19

基金项目: 国家自然科学基金资助项目(62175037); 云南省科技厅科技人才与平台计划(202305AF150143)

第一作者: 陈婷婷(1995-), 女, 硕士研究生。研究方向: 高光谱图像异常检测。E-mail: 1142025423@qq.com

通信作者: 蒋林华(1963-), 男, 教授。研究方向: 智能视觉图像处理。E-mail: 11594@zjhu.edu.cn

引文格式: 陈婷婷, 胡兴, 刘德权, 等. 结合注意力机制的自监督高光谱图像异常检测[J]. 上海理工大学学报, 2025, 47(1): 45-53.

Citation: CHEN Tingting, HU Xing, LIU Dequan, et al. Anomaly detection in hyperspectral images combining self-supervision and attention mechanism[J]. Journal of University of Shanghai for Science and Technology, 2025, 47(1): 45-53.

was used to extract the spectral and spatial features of hyperspectral images to reconstruct the background. The attention mechanism adaptive learning feature channel weights were introduced in the network to optimize the feature. In addition, considering the reduction of image information after background reconstruction, image information entropy was added to the loss function to restrict the feature coding and improve the network performance. Finally, the anomaly value was calculated by the Mahalanobis distance. The proposed algorithm was experimented on two datasets of hyperspectral images from different scenes and compared with seven similar algorithms. The results show that the proposed algorithm has the highest value on area under curve (AUC).

**Keywords:** *hyperspectral image; anomaly detection; self-supervised network; attention mechanism*

高光谱异常目标是指光谱分布与探测区域背景有显著差异且占有比例小的地物目标<sup>[1]</sup>。高光谱图像异常检测是遥感应用中的重要研究内容之一,广泛应用于军事侦察、环境监测等领域。

早期经典的高光谱异常检测是基于统计模型来识别异常像元,包括 Reed 等<sup>[2]</sup>提出的 RX 算法以及 Chen 等<sup>[3]</sup>提出的局部 RX 算法等,这些算法认为背景数据服从高斯分布,而偏离分布的像元即为异常像元。但实际场景更加复杂,难以保证分布的准确性,因而 He 等<sup>[4]</sup>提出了递归 RX 算法,该算法结合高光谱图像的空间特征实现异常检测,但增加了计算要求。

近年来,在图像压缩感知技术的推动下,一些基于像元表示的算法不断被提出。Li 等<sup>[5]</sup>提出协同表示法,即使用待测像元周围的像元对其进行重新描述。胡静等<sup>[6]</sup>为降低协同表示过程中潜在异常对背景特性的影响,通过衡量降质后图像与原图的差异,实现了粗定位,提高了协同表示的精度。与协同表示法不同, Huang 等<sup>[7]</sup>和宋晓瑞等<sup>[8]</sup>利用高光谱图像的低秩性,通过预分析高光谱数据,构建了背景字典,对待测像元进行描述。Lin 等<sup>[9]</sup>对背景和异常分量施加双重协同约束,充分利用高光谱图像的全局和局部特征构建鲁棒字典,以提高异常检测能力。

随着深度学习技术的发展,基于学习的方法在高光谱图像异常检测中成为了一种新趋势<sup>[10]</sup>。相比于像元表示,深度学习网络可以学习更深层次的图像特征,利于对背景像元的表示。在有监督网络应用中,为获得较好的学习特征,需要大规模的数据收集和标注来进行参数训练<sup>[11-12]</sup>。然而,在高光谱图像异常检测领域,缺乏充足的数据集,难以发挥有监督学习的优势。而且,有

效的背景表示利于区分背景和异常,这是影响异常检测精度的关键因素。因此,大量研究人员采用了自监督网络学习自身属性来重构图像背景<sup>[13-15]</sup>。Ojha 等<sup>[14]</sup>和 Song 等<sup>[15]</sup>使用变分编码器提取潜在特征,将每个像元独立输入网络以满足训练要求,但损失了高光谱图像的空间特性。

为了保证网络能够学习高光谱图像的空间特性和光谱特性,本文提出了一种结合注意力机制的自监督高光谱图像异常检测算法。该算法使用 2D 卷积设计自编码网络,并在网络中引入注意力机制以及在损失函数中引入信息熵进行约束,改善了网络性能。将该算法在来自机场和城市两种场景的高光谱图像数据集上进行实验,并与同类 7 种算法进行对比,验证了该算法的有效性。

## 1 算法总体框架

本文提出了一种结合注意力机制的自监督高光谱图像异常检测算法,算法流程如图 1 所示, $B$  为光谱通道数。将预处理后的高光谱图像输入自监督网络进行编码和解码操作重构背景。在自监督网络中,使用通道注意力机制(channel attention mechanism, CAM)获取特征通道权重,且使用均方根误差、光谱角和信息熵构建损失函数,从而提高网络性能。最后,依次提取输入高光谱图像像元,并计算与重构背景的马氏距离,获得各像元的异常程度,实现异常检测。

## 2 相关工作

### 2.1 自监督网络

自监督网络是一种由编码器和解码器组成的

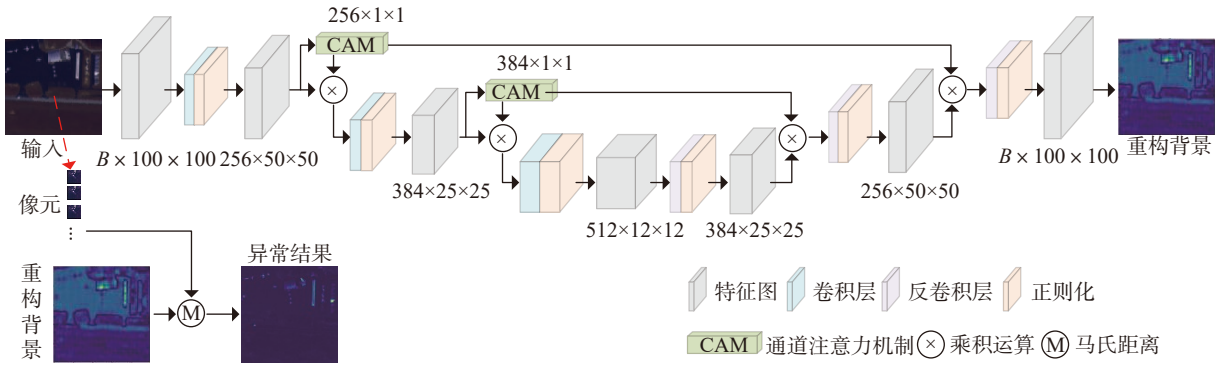


图 1 算法流程图

Fig.1 Flow chart of the proposed algorithm

前馈人工神经网络, 用于生成与输入数据尽可能相似的数据, 以及提取输入的潜在特征<sup>[16]</sup>。高光谱图像异常检测可通过自监督网络学习输入数据的潜在背景特征并进行特征恢复, 从而在一定程度上滤除异常, 实现高光谱数据的背景表示。自监督网络的编码器  $f(\cdot)$  用于对输入数据进行下采样, 获取编码特征  $Z$ ; 解码器  $g(\cdot)$  用于对编码特征  $Z$  进行上采样, 生成与输入结构相同的数据<sup>[16]</sup>。假设  $H \in \mathbb{R}^{M \times K \times B}$  表示长为  $M$ 、宽为  $K$ 、波段数为  $B$  的高光谱图像, 则编码和解码过程如下:

$$Z = f(wH + b) \quad (1)$$

$$\hat{H} = g(w'Z + b') \quad (2)$$

式中:  $\hat{H}$  为经自监督网络获得的输出数据;  $w$ 、 $w'$  分别为编码器和解码器的权重矩阵;  $b$ 、 $b'$  分别为编码器和解码器的偏置向量。

### 2.2 注意力机制

注意力机制如同人类视觉捕捉场景目标, 会有选择地将注意力集中在重要部分, 而抑制其他不相关信息<sup>[17]</sup>。CAM 作为注意力机制的一种, 在深度学习任务中可以自适应地学习各个特征通道间的关系, 实现特征优化。

高光谱图像拥有大量的光谱波段, 相邻波段间互相影响, 具有较强的相关性, 信息冗余性高。因此, 在自监督网络学习中可通过引入 CAM

模块提升网络性能。CAM 的网络结构如图 2 所示, 输入特征图为  $X \in \mathbb{R}^{C \times W \times L}$ , 其中,  $C$  为特征通道数,  $W \times L$  为特征图尺寸。首先, 将输入特征图分别进行最大值池化 Maxpool 和平均值池化 Avgpool。其中, Maxpool 用于提取特征明显和突出的信息, 输出结果记作  $F_{\max}(X)$ ; Avgpool 用于提取特征的综合信息, 输出结果记作  $F_{\text{avg}}(X)$ 。然后, 使用全连接结构设计的感知器  $G(\cdot)$  对  $F_{\max}(X)$  和  $F_{\text{avg}}(X)$  进行处理, 该感知器仅含有一个隐藏层, 其尺寸为  $(C/16) \times 1 \times 1$ 。最后, 将两条分支的输出特征向量相加, 并经过 Sigmoid 函数处理获得最终的特征通道权重  $W_{\text{ch}}$ 。具体可用如下公式表示:

$$W_{\text{ch}} = \text{Sigmoid}(G(F_{\max}(X)) + G(F_{\text{avg}}(X))) \quad (3)$$

当通过 CAM 模块学习输入特征每个通道的权重后, 将输出权重与相应通道进行点乘可分配各个通道的重要性。即

$$X' = W_{\text{ch}}X \quad (4)$$

式中,  $X'$  为输入特征  $X$  经 CAM 优化后的结果。

### 2.3 结合注意力机制的自监督网络

高光谱图像数据是一种三维立方体结构, 其在二维平面上描述了地物的空间分布, 光谱维度描述了地物丰度的光谱信息<sup>[18]</sup>。为此, 使用 2D 卷积结构设计自监督网络, 期望能够学习高光谱图




图 2 通道注意力网络结构

Fig.2 Structure of the channel attention network

像的空间信息和光谱信息。同时,增加CAM模块以自适应学习特征通道权重,优化学习特征。

如图1所示,在结合注意力机制的自监督网络中,将预处理后的高光谱数据输入网络,光谱通道数为 $B$ ,图像尺寸为 $100 \times 100$ 像素。在编码阶段,经3组卷积层后提取 $512 \times 12 \times 12$ 的稀疏编码特征,将其送入解码器,采用3组反卷积层输出

重构图像。编码器在第1次和第2次卷积生成中间特征后,将中间特征输入到CAM模块中,获得 $256 \times 1 \times 1$ 和 $384 \times 1 \times 1$ 的特征通道权重,权重值表示对应特征通道的重要性。在获得特征权重后,为保留自监督网络的对称性,在编码和解码阶段均使用特征通道权重对输入特征进行优化,具体的网络参数如图3所示。

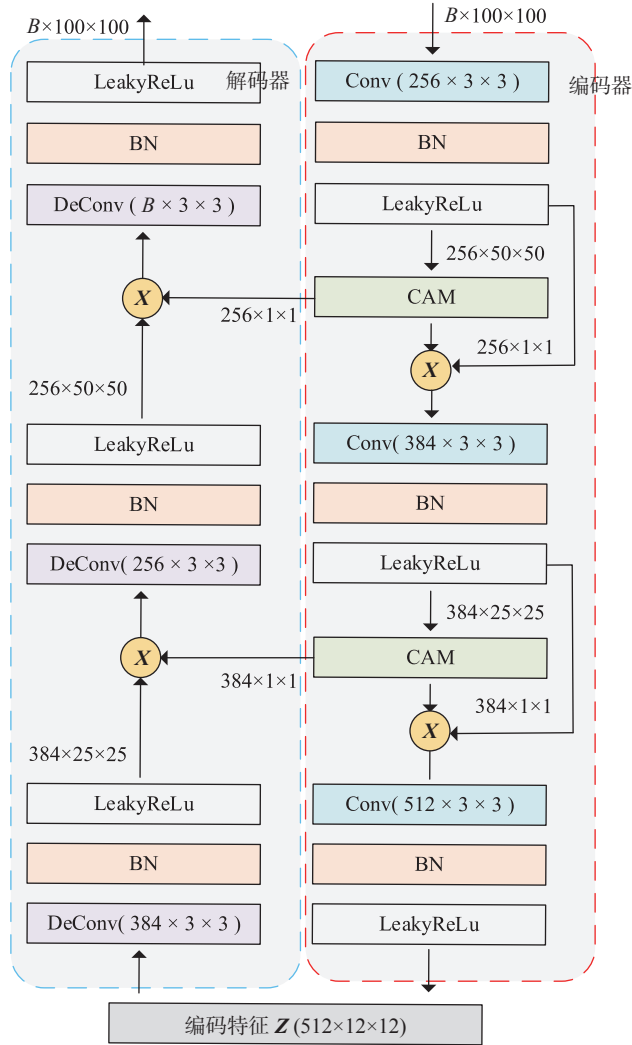


图3 结合注意力机制的自监督网络参数

Fig.3 Parameters of self-supervised networks combined with attention mechanisms

自监督网络被用于生成与输入数据尽可能相似的数据网络。因此,在训练阶段,以输入与输出数据之间的误差为损失函数,并通过减小误差来学习网络参数。在测试阶段,使用学习的参数捕捉图像属性并进行重建。在高光谱图像中,常使用均方误差(mean square error, MSE)和光谱角制图(spectral angle mapper, SAM)来表述输入与输出数据的差距,即

$$J_{\text{MSE}}(\mathbf{H}, \widehat{\mathbf{H}}) = \sum_{i,j} \|\widehat{\mathbf{H}}(i,j) - \mathbf{H}(i,j)\|^2 \quad (5)$$

$$J_{\text{SAM}}(\mathbf{H}, \widehat{\mathbf{H}}) = \sum_{i,j} \left\| \frac{1}{\pi} \arccos \left( \frac{\mathbf{H}(i,j) \widehat{\mathbf{H}}(i,j)}{\|\mathbf{H}(i,j)\| \|\widehat{\mathbf{H}}(i,j)\|} \right) \right\| \quad (6)$$

自编码网络是为了尽可能滤除前景,以获得更为纯净的背景,因而,在背景学习中期望编码特征的丰富度逐步降低。本文在损失函数中进一



步引入信息熵以约束特征的丰富性, 限制编码特征可表达的范围。编码特征的信息熵计算如式 7 所示。在计算前, 先通过 Softmax 函数将编码特征映射至 0~1。

$$J_{\text{Info}}(\mathbf{Z}) = \sum_k \left( \sum_{i,j} \mathbf{Z}_k^{(i,j)} \log(\mathbf{Z}_k^{(i,j)}) \right) \quad (7)$$

式中,  $k$  为编码特征  $\mathbf{Z}$  的第  $k$  个通道。因此, 损失函数定义由 MSE、SAM 和编码特征的信息熵 3 部分构成, 即

$$\min J(\mathbf{w}, \mathbf{b}, \mathbf{w}', \mathbf{b}') = \min \left( J_{\text{MSE}}(\mathbf{H}, \widehat{\mathbf{H}}) + J_{\text{SAM}}(\mathbf{H}, \widehat{\mathbf{H}}) + J_{\text{Info}}(\mathbf{Z}) \right) \quad (8)$$

## 2.4 异常检测

高光谱异常检测是寻找与背景显著不同的像元, 在获得背景图像后, 通过距离度量待测像元与背景的差异性。马氏距离是在异常检测中常用的距离度量方法, 相较于欧式距离, 其计算更加复杂, 但避免了变量间的相关性干扰。本文在使用自监督学习获得背景图像后, 使用马氏距离计算各像元的异常程度, 并以此决定异常像元, 公式如下:

$$\text{MS}(\mathbf{H}(i, j)) = (\mathbf{H}(i, j) - \mu)^T P^{-1} (\mathbf{H}(i, j) - \mu) \quad (9)$$

式中,  $\mu$ 、 $P$  分别为重构后数据的均值和协方差, 计算公式如下:

$$\mu = \frac{1}{S} \sum_{i,j} \widehat{\mathbf{H}}(i, j) \quad (10)$$

$$P = \frac{1}{S} \sum_{i,j} (\widehat{\mathbf{H}}(i, j) - \mu)(\widehat{\mathbf{H}}(i, j) - \mu)^T \quad (11)$$

式中,  $S$  为像元个数。

## 3 实验与结果分析

### 3.1 实验数据

为验证本文算法的有效性, 从公共数据集分别获取机场和城市两种场景共 4 幅校正后的高光谱图像进行实验<sup>[19]</sup>。机场场景是来自于 Los Angeles 机场, 以飞机为异常目标; 城市场景分别来自 Gainesville 和 Los Angeles, 以占有不同比例的建筑或物体为异常目标。所有场景均采用 AVIRIS 传感器获取的像素大小为 100×100 的高光谱图像, 经校正后的机场 I、机场 II、城市 I 和城市 II 场景的波段数量分别为 205、205、191 和 205。

### 3.2 评价指标

为量化异常检测性能, 选取 ROC(receiver operating characteristic) 曲线和 AUC(area under the curve) 作为检测结果的评价指标。其中, ROC 曲线以虚警率(false alarm rate, FAR)为横坐标, 以检测率(probability of detection, PD)为纵坐标。ROC 曲线上升越快, 说明异常检测性能越好。AUC 是指 ROC 曲线下方的面积, 可以定量描述异常检测性能, AUC 越接近于 1, 说明异常检测性能越好。PD 和 FAR 的定义为

$$P_d = \frac{N_d}{N_t} \quad (12)$$

$$F_{\text{ar}} = \frac{N_f}{N} \quad (13)$$

式中:  $P_d$  为检测率;  $F_{\text{ar}}$  为虚警率;  $N_d$  为被准确检测出的异常像元数;  $N_t$  为图像中真实异常像元数;  $N_f$  为检测到的虚警像元数;  $N$  为图像的总像元数。

### 3.3 对比实验

为说明本文方法的有效性, 在实验中将本文方法与 RX<sup>[2]</sup>、CRD<sup>[5]</sup>、FEBPAD<sup>[20]</sup>、FRFE-RX<sup>[21]</sup>、LSDMMOG<sup>[22]</sup>、DAEAD<sup>[23]</sup> 和 KNJCR<sup>[24]</sup> 7 种算法进行对比。DAEAD 为将每个像元独立送入网络的基于学习的检测方法。同时为保证对比结果的可靠性, 将对比算法进行了参数优化。网络训练时, 学习率设置为 0.008, 最大训练次数为 300, 当连续 5 次出现损失下降小于 0.000 5 时, 提前结束训练以防止过度拟合。

图 4 和图 5 为机场场景的异常检测结果图。图中选取了输入高光谱数据的第 37 波段、第 36 波段和第 8 波段进行 RGB 伪彩色合成, 以显示场景信息。异常真值图是以黄色像元标记异常像元, 可见, 异常像元仅占较小比例。检测结果图中, 像元灰度表示像元异常值大小, 颜色越深表明异常值越大。从图中可以直观看出, 各算法在异常像元处均有较高的灰度。检测结果图不能准确地评价检测效果好坏, 如果检测结果中某些异常数值明显偏高, 那么在图像显示归一化处理, 就难以观察出异常值较低的像元, 如图 4 中 CRD 的检测结果和图 5 中本文方法的检测结果。

因此, 为定量分析检测结果, 生成如图 6 所示的 ROC 曲线。由图 6(a) 机场 I 场景可以看出, 在 PD 较低时, 本文算法得到的 ROC 曲线略低于部分算法, 其上升速度较快, 当 PD 为 0.8 时, 本




图4 机场I场景异常检测结果

Fig.4 Anomaly detection results of the airport I scene

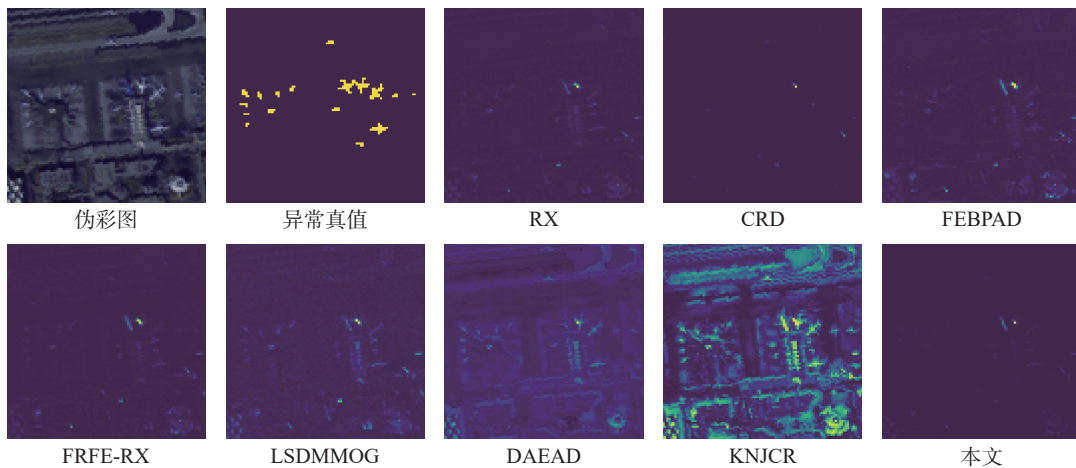


图5 机场II场景异常检测结果

Fig.5 Anomaly detection results of the airport II scene

文算法的 FAR 明显小于其他算法，且在 FAR 约为 0.1 时，本文算法的 PD 率先接近 1。表 1 记录了各算法的 AUC。从表 1 可以看出，在机场 I 场景中，本文算法的 AUC 最高为 0.9563。由图 6(b) 机场 II 场景可以看出，本文算法得到的 ROC 曲线与 CRD 算法相近，且明显高于其他算法。同样在 FAR 约为 0.1 时，本文算法和 CRD 算法的 PD 率先接近 1。而且，从表 1 的 AUC 可以看出，机场 II 场景中，本文算法的 AUC 为 0.9621，略高于 CRD 算法，明显高于其他方法。

图 7 和图 8 为城市场景的检测结果，可以看出，各算法在异常像元处均有较高的灰度。由图 9(a) 城市 I 场景中的 ROC 曲线可以看出，在 PD 小于 0.8 时，CRD 算法得到的 ROC 曲线明显优于其他，但其上升速度较慢。本文算法得出的 ROC 曲线上升速度较快，且 PD 率先接近 1；在 PD 大于

0.8 时，本文算法的 FAR 小于其他算法。由表 1 可以看出，本文算法检测的城市 I 场景的 AUC 为 0.9814，明显高于其他算法。由图 9(b) 城市 II 场景的 ROC 曲线可以看出，本文算法曲线一直居于高处。由表 1 可以看出，本文算法对应的 AUC 为 0.9769，明显高于其他算法。

### 3.4 消融实验

为说明 CAM 和图像信息熵的有效性，对所提出算法进行消融实验。表 2 为各场景使用 4 种不同配置时的 AUC。其中，CNN 表示使用卷积结构；图像信息熵表示损失函数中引入图像信息熵对编码特征进行约束；CAM 表示网络结构中增加通道注意力机制。从表中结果可以看出，以 2D 卷积为基础，在损失函数中引入图像信息熵或者网络结构中使用 CAM 能够改善检测结果。同时使用信息熵和 CAM 检测，机场 I、机场 II、城市 II 场

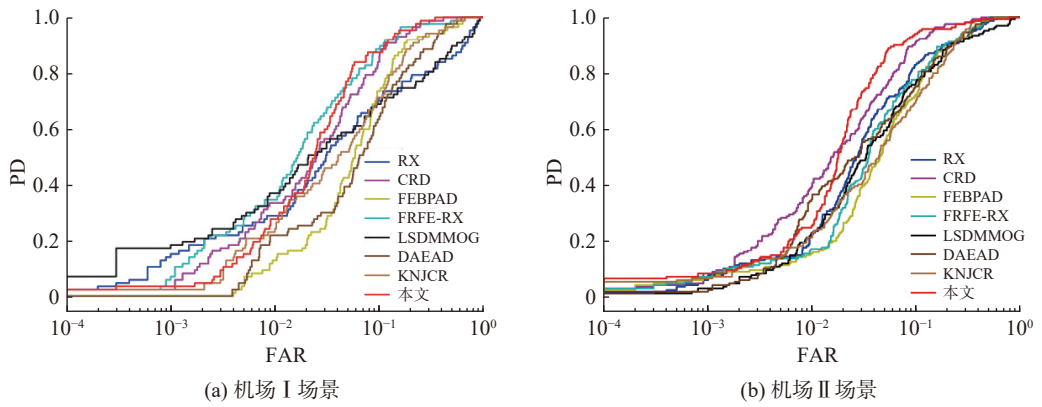


图 6 机场场景的 ROC 曲线

Fig.6 ROC curves of the airport scene

表 1 各场景下不同算法的 AUC

Tab.1 AUC by different methods at different scenes

场景	RX	CRD	FEBPAD	FRFE-RX	LSDMMOG	DAEAD	KNJCR	本文
机场 I	0.8402	0.9486	0.9034	0.9543	0.8450	0.8866	0.9107	<b>0.9563</b>
机场 II	0.9287	0.9601	0.9165	0.9265	0.9052	0.9248	0.9153	<b>0.9621</b>
城市 I	0.9511	0.9628	0.9407	0.9561	0.9489	0.8532	0.9302	<b>0.9854</b>
城市 II	0.9691	0.9710	0.9189	0.9637	0.9564	0.9546	0.9437	<b>0.9769</b>




图 7 城市 I 场景异常检测结果

Fig.7 Anomaly detection results of the urban I scene

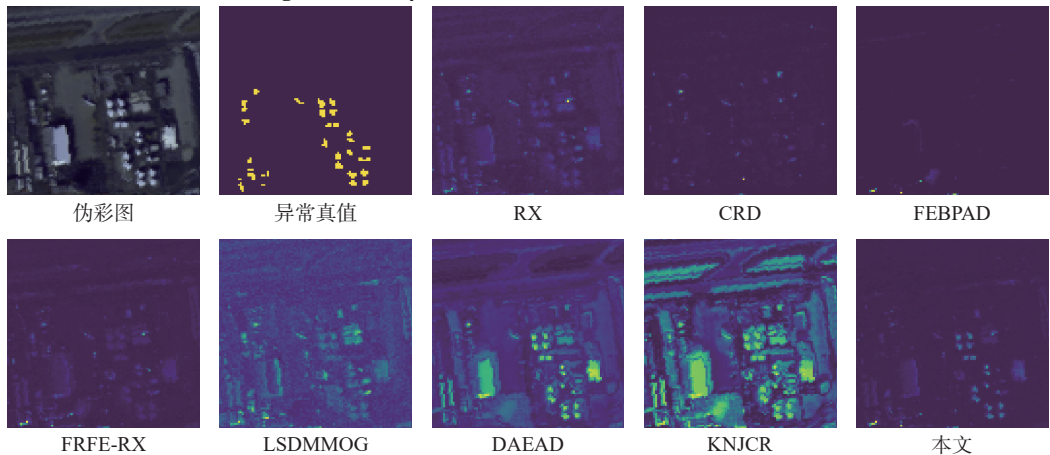


图 8 城市 II 场景异常检测结果

Fig.8 Anomaly detection results of the urban II scene

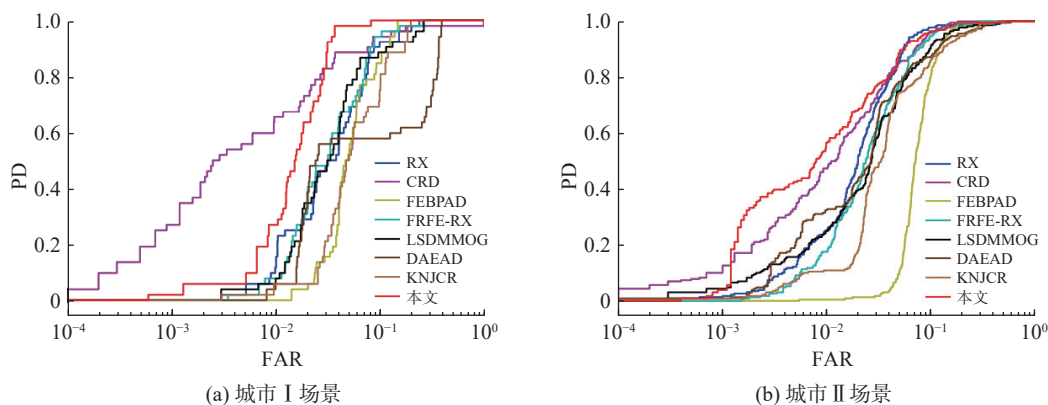


图9 城市场景的 ROC 曲线

Fig.9 Roc curves of the urban scenes

表2 不同配置下的 AUC

Tab.2 AUC under different configurations

场景	CNN	图像信息熵	CAM	AUC
机场 I	√			0.891 5
	√	√		0.914 2
	√		√	0.917 5
	√	√	√	<b>0.956 3</b>
机场 II	√			0.950 8
	√	√		0.955 7
	√		√	0.951 4
	√	√	√	<b>0.962 1</b>
城市 I	√			0.983 5
	√	√		0.983 3
	√		√	<b>0.987 2</b>
	√	√	√	<b>0.985 4</b>
城市 II	√			0.972 7
	√	√		0.975 1
	√		√	0.976 3
	√	√	√	<b>0.976 9</b>

景的结果最优，尤其是机场 I 场景下效果明显。而城市 I 场景中仅使用 CAM 的结果最好，但与其他检测结果相近。因此，相比于仅使用 2D 卷积编码结构，在损失函数中引入图像信息熵和网络结构中增加 CAM，能够进一步提升检测性能。

## 4 结论

本文针对高光谱图像数据复杂、可用带标记数据样本少等问题，提出了一种结合注意力机制

的自监督高光谱图像异常检测算法。利用 2D 卷积构建自编码学习输入数据的空谱特征，实现重建背景。为了获取较为纯净的背景，引入注意力机制筛选特征通道，强化学习过程中背景的重要性。从图像信息角度出发，考虑重构背景信息的单一性，在损失函数中引入信息熵来约束学习。最后，利用马氏距离实现异常值计算。通过两组场景数据对算法性能进行测试，并把该算法与其他同类算法进行对比，验证了算法的优越性，消融实验说明了 CAM 和图像信息熵的有效性。本算法不需要进行繁琐的人工参数调整，具有更好的场景适应性；但对于占有像元数量较多、与多数背景不同的非异常像元，如图 4 中机场 I 场景左中部像元，不具备较好的处理效果。因此，在后期研究中可考虑局部计算异常或采用数据抑制的方法进行优化。

### 参考文献:

- [1] XU Y T, ZHAO K, ZHANG L G, et al. Hyperspectral anomaly detection with vision transformer and adversarial refinement[J]. *International Journal of Remote Sensing*, 2023, 44(13): 4034–4057.
- [2] 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.
- [3] CHEN J Y, REED I S. A detection algorithm for optical targets in clutter[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 1987, 23(1): 46–59.
- [4] HE F, YAN S, DING Y, et al. Recursive RX with extended multi-attribute profiles for hyperspectral anomaly detection[J]. *Remote Sensing*, 2023, 15(3): 589.
- [5] LI W, DU Q. Collaborative representation for hyperspectral



- anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(3): 1463–1474.
- [6] 胡静, 赵明华, 李鹏, 等. 粗定位和协同表示的高光谱图像异常检测 [J]. *中国图象图形学报*, 2021, 26(8): 1871–1885.
- [7] HUANG J, LIU K, LI X L. Locality constrained low rank representation and automatic dictionary learning for hyperspectral anomaly detection[J]. *Remote Sensing*, 2022, 14(6): 1327.
- [8] 宋晓瑞, 邹玲, 吴玲达, 等. 基于背景重建的高光谱图像异常检测 [J]. *系统仿真学报*, 2020, 32(7): 1287–1293.
- [9] LIN S, ZHANG M, CHENG X, et al. Dual collaborative constraints regularized low-rank and sparse representation via robust dictionaries construction for hyperspectral anomaly detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 2009–2024.
- [10] 张国建, 刘胜震, 孙英君, 等. 基于弱监督鲁棒性自编码的高光谱异常检测 [J]. *自然资源遥感*, 2023, 35(2): 167–175.
- [11] YU X H, CHEN P F, WU D, et al. Object localization under single coarse point supervision[C]//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 4868–4877.
- [12] 蔡贤杰, 丁德锐, 魏国亮, 等. 融合多尺度特征和子空间注意力的黏膜下肿瘤检测 [J]. *上海理工大学学报*, 2023, 45(5): 477–487.
- [13] ZHAO C H, LI C, FENG S, et al. Spectral–spatial anomaly detection via collaborative representation constraint stacked autoencoders for hyperspectral images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 5503105.
- [14] OJHA N, SINHA I K, SINGH K P. VAE-AD: unsupervised variational autoencoder for anomaly detection in hyperspectral images[C]//Proceedings of the 29th International Conference on Neural Information Processing. New Delhi: Springer Nature Singapore, 2023: 126–137.
- [15] SONG Y J, SHI S K, CHEN J. Deep-RX for hyperspectral anomaly detection[C]//Proceedings of 2023 IEEE International Geoscience and Remote Sensing Symposium. Pasadena: IEEE, 2023: 7348–7351.
- [16] WANG S Y, WANG X Y, ZHANG L P, et al. Auto-AD: autonomous hyperspectral anomaly detection network based on fully convolutional autoencoder[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5503314.
- [17] 刘熠翕, 江旻珊, 张学典. 融合金字塔切分注意力模块的视杯视盘分割 [J]. *上海理工大学学报*, 2022, 44(6): 532–539.
- [18] 宋尚真, 杨怡欣, 王会峰, 等. 高光谱图像稀疏约束与自编码器特征提取相结合的异常检测方法 [J]. *测绘学报*, 2023, 52(6): 932–943.
- [19] TU B, LI N Y, LIAO Z L, et al. Hyperspectral anomaly detection via spatial density background purification[J]. *Remote Sensing*, 2019, 11(22): 2618.
- [20] MA Y, FAN G H, JIN Q W, et al. Hyperspectral anomaly detection via integration of feature extraction and background purification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(8): 1436–1440.
- [21] TAO R, ZHAO X D, LI W, et al. Hyperspectral anomaly detection by fractional Fourier entropy[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(12): 4920–4929.
- [22] 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*, 2020, 51(9): 4363–4372.
- [23] TAGHIPOUR A, GHASSEMIAN H. Unsupervised hyperspectral target detection using spectral residual of deep autoencoder networks[C]//Proceedings of the 4th International Conference on Pattern Recognition and Image Analysis. Tehran: IEEE, 2019: 52–57.
- [24] CHANG S Z, GHAMISI P. Nonnegative-constrained joint collaborative representation with union dictionary for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5534913.

(编辑: 董伟)