

结合区域引导和双注意力机制的高光谱目标检测 判别式学习网络

钟佳平¹, 李云松^{1*}, 谢卫莹¹, 雷 杰¹, Paolo Gamba²

(1. 西安电子科技大学综合业务网全国重点实验室, 陕西西安 710071; 2. 帕维亚大学, 意大利帕维亚 27100)

摘 要: 高光谱图像(HyperSpectral Images, HSIs)具有高光谱分辨率和丰富的光谱信息,其具有的大量窄波段电磁波有利于获取感兴趣目标的理化信息,并根据对应的光谱特征对不同物质进行有效区分,从而完成目标检测任务. 然而有限样本、少量先验信息、高维相似背景及不同类别差异小所导致的目标和背景混淆问题使得高光谱目标检测(Hyperspectral Target Detection, HTD)面临挑战. 为此,本文提出结合区域引导和双注意力机制的高光谱目标检测判别式学习网络(Region-guided and dual-Attention Discriminative learning Network, RADN),以缓解标记样本少的条件下不同类别相似度高和相同类别差异性大导致的背景和背景不易区分的问题,减少高维冗余特征带来的计算复杂度,同时提升检测精度. 本文使用经验性区域引导网络训练,采用光谱约束的无监督聚类方法确定网络输入,选择性地关注高光谱图像中的显著性特征和感兴趣区域. 此外,本文在网络中添加双通道注意力机制来辅助复杂背景分布的估计,并在网络中引入不同类别光谱先验损失函数,进一步减少高维复杂背景以及光谱变化对于目标的干扰. 实验结果和分析表明,RADN在不同数据集上的性能优于现有先进的算法.

关键词: 高光谱目标检测; 无监督聚类; 通道注意力机制; 感兴趣区域; 光谱分辨率

基金项目: 国家自然科学基金(No.62121001, No.U22B2014); 中国科协青年人才托举工程(No.2020QNRC001)

中图分类号: TP183; TP751.1

文献标识码: A

文章编号: 0372-2112(2024)05-1716-14

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20221126

Region-Guided and Dual Attention Discriminative Learning Network for Hyperspectral Target Detection

ZHONG Jia-ping¹, LI Yun-song^{1*}, XIE Wei-ying¹, LEI Jie¹, Paolo Gamba²

(1. State Key Laboratory of Integrated Services Networks, Xidian University, Xi'an, Shaanxi 710071, China;

2. University of Pavia, Pavia, Lombardia 27100, Italy)

Abstract: Hyperspectral images (HSIs) have high spectral resolution and rich spectral information, which can obtain the physical and chemical information of the target of interest by using a large number of narrow-band waves. HSIs can effectively distinguish different substances by corresponding spectral features, and complete the task of target detection. However, the problem of target and background confusion caused by limited samples, a small amount of prior information, high dimensional similar background, and differences between different classes make hyperspectral target detection (HTD) still face challenges. To this end, we propose a region-guided and dual-attention discriminative learning network (RADN) for HTD to solve the problem of intra-class differences and inter-class similarities under a few samples. It can reduce the computational complexity caused by high-dimensional redundant features and improve detection accuracy. In this paper, we introduce the empirical region-guided network for training. We employ the spectrally constrained unsupervised clustering network to determine the network input. To selectively focus on salient features and regions of interest, we add a dual-channel attention mechanism in the generator and discriminator to assist in the estimation of complex background distributions; We introduce an inter-class spectral prior loss function in the network and further reduce the interference of high-dimensional complex background and spectral changes to the target. Experimental results and analysis show that RADN outperforms existing state-of-the-art algorithms on different datasets.

Key words: hyperspectral target detection; unsupervised clustering; channel attention mechanism; region of interest; spectral resolution

Foundation Item(s): National Natural Science Foundation of China (No.62121001, No.U22B2014); Young Elite Scientist Sponsorship Program by the China Association for Science and Technology (No.2020QNRC001)

1 引言

高光谱图像(HyperSpectral Images, HSIs)包含丰富的空间、辐射和光谱维度信息,其内在和固有特征提供的深度光谱信息为目标的多特征分析提供了稳定和可靠的数据基础^[1]. HSI在目标检测、异常检测、医学图像处理、超分辨率及多模态任务等领域均具有广泛的应用^[2,3]. 其中,高光谱目标检测(Hyperspectral Target Detection, HTD)作为高光谱成像应用中的重要任务之一,能够在具有已知光谱特征的高光谱场景中定位和检测所有目标像素^[4,5]. 然而,由于复杂场景中数据的高维特性和来自背景的干扰,获取足够的光谱先验信息和捕获包含丰富地物信息的目标特征仍然具有挑战性. 此外,采集到的光谱是不同材料物质光谱的组合,这就导致在实验室环境中测量的目标光谱与实际场景之间存在差异^[6,7].

现有的HTD方法可以分为3类,包括基于概率和统计量的方法、基于正交子空间投影的方法和基于表示的方法. 基于概率和统计量的模型假设HSI中的光谱向量符合一定的概率分布,经典的假设检验方法包括似然比检验(Likelihood Ratio test, LR)和广义似然比检验(Generalized Likelihood Ratio Test, GLRT),文献[8]基于GLRT和多元高斯分布的假设提出RX检测算法. 基于统计量的代表性算法还包括自适应相干估计(Adaptive Coherence Estimation, ACE)^[9]和自适应匹配滤波器(Adaptive Matched Filter, AMF)^[10],其基本思想是将待测像素投影到子空间中,以增加目标与背景之间的差异实现目标检测. 正交子空间投影(Orthogonal Subspace Projection, OSP)^[11]方法将每个像素向量投影到与已检测到的目标特征光谱向量正交的子空间上,迭代地计算出每次在图像中表现为亮度最大的像元作为待检测目标,该算法除了需要知道目标的先验信息外,还需要背景物质的先验信息. 基于表示的方法不假设任何数据分布,包括约束能量最小化(Constrained Energy Minimization, CEM)^[12]、分层CEM(hierarchical CEM, hCEM)^[13]、基于集成学习的CEM算法(ensemble-based cascaded Constrained Energy Minimization, eCEM)^[14],以及基于稀疏表示(Sparse Representation, SR)的方法^[15,16]. 其中,CEM设计有限脉冲响应(Finite-Impulse Response, FIR)线性滤波器,可以最大限度地提高对于目标的响应,同时抑制对于背景的响应. Zou等人^[13]提出分级抑制的hCEM方法,将CEM算法分层运算并使

用非线性抑制函数来抑制背景并提升性能. 基于ST的检测器将待测像素表示为过完备字典中少数目标和背景原子的线性组合,如组合稀疏和协同表示方法(Combined Sparse and Collaborative Representation, CSCR)^[17],结合稀疏表示和协同表示,通过目标库和背景库来表示测试像素实现目标检测.

基于深度学习的方法由于非线性特征表示的能力强,在包括分类、分割、超分辨率和检测等HSI处理任务中的应用十分广泛. 与其他HSI处理任务相比,基于深度学习的HTD方法存在标记样本不足、目标样本和背景样本非均衡的问题. 具体来说,基于深度学习的目标检测方法使用少数目标样本作为训练集,一定程度上需要扩展训练集从而提高网络生成能力和检测性能^[18]. 文献[19]基于卷积神经网络(Convolutional Neural Network, CNN)实现高光谱目标检测,通过CNN提取目标和背景像元的信息特征,生成参考数据集的像素对特征(Pixel Pair Features, PPF)之间的差异扩充样本,以此定量衡量样本之间的相似度或不相似度. 文献[20]将一组不同的空间窗口嵌套起来,实现在光谱和空间上对特征不同目标的提取.

无监督方法可以对高维特征进行深入挖掘,并自适应地进行判别性特征提取^[21]. 但平衡每个波段和像素的贡献可能会由于非目标和冗余的像素而使现有性能受限,特别是光谱冗余可能会增加同一类别内的差异和类别之间的相似性,而空间冗余可能会导致神经网络不能关注到显著性区域. 为了解决假设背景光谱服从高斯分布仅在某些条件下表现良好,而目标和背景样本数量不平衡的问题,文献[4]提出基于非对称加权逻辑度量学习(Asymmetric Weighted Logistic Metric Learning, AWLML)的目标检测方法,将逻辑度量学习方法构建为具有半正定约束的目标函数,从一组标记样本中学习度量矩阵,并采用非对称加权策略来改善目标和背景样本数量之间的不平衡问题. 为了解决正交子空间投影(Orthogonal Subspace Projection, OSP)的性能受先验目标信息和背景建模的准确性影响较大的问题,文献[12]使用数据球化和低秩稀疏矩阵分解(Low-Rank and Sparse Matrix Decomposition, LRaSMD)来扩展OSP以提高其性能. 数据球化的方式通过去除一阶和二阶统计量数据来抑制背景,LRaSMD将背景和背景分离在分别以低秩矩阵和稀疏矩阵为特征的两个子空间中,然后通过低秩矩阵抑制背景,提高OSP对目标的可

检测性和对背景的抑制性。文献[22]提出基于加权柯西距离图和局部自适应协同表示的高光谱目标检测算法,该算法既可以避免背景服从高斯分布的假设导致的检测率低的问题,又可以充分利用先验目标像素与待测试像素之间的关系,减少目标像素对高光谱背景模型的影响。该方法自适应地利用空间和光谱信息,根据被测像素与目标光谱的欧几里得距离及相关性来调整检测概率。针对基于迁移学习的高光谱目标检测算法泛化能力弱、对新任务的适应能力差以及训练深度神经网络训练样本有限的问题,文献[23]提出基于元学习的方法,使用连体网络(Meta-Learning based hyperspectral target detection using Siamese Network, MLSN)进行高光谱目标检测。为了解决现有方法中标记样本少、冗余光谱高维性及背景和背景混淆的问题,本文提出结合区域引导和双注意力机制的HTD判别式学习网络。首先,通过无监督光谱约束K-均值聚类获得显著性特征及感兴趣区域,由经验区域选择伪输入向量引导网络训练解决标记样本不足的问题。此外,采用注意力机制添加到生成器和判别器中,减少高光谱高维特性下冗余光谱对精度的影响。本文还在网络中添加判别扩大距离损失函数,计算已知光谱和重构光谱之间的距离,以增加判别式学习能力。总体而言,本文设计联合的区域引导和双注意力机制的高光谱目标检测判别式学习网络(Region-Guided and Dual-Attention Discriminative Learning Network, RADN)增强了目标和背景特征的判别式重构。

基于以上分析,本文提出的HTD判别式学习模型在不假设数据分布的情况下,使用权重特定注意力机制辅助检测感兴趣目标,提升了高维冗余光谱向量条件下的检测精度,提高了整个网络对目标和背景的光谱判别式学习能力,避免目标像素对背景统计量估计的影响。具体来讲,本文选择性地关注高光谱图像中的显著性特征和感兴趣区域,而忽略其他部分,以提高判别特征表示能力,生成不同类别训练样本,获得网络判别性输入,克服缺少先验信息和精确标签的问题,提出光谱约束无监督聚类方法获得显著性区域,使用此经验性区域引导网络训练。此外,本文对生成域和判别域添加通道注意力机制,以更大的权重突出感兴趣区域,辅助复杂背景分布的估计,分配更多计算资源。本文自适应地选择与经验区域近似的代表性特征,输出不同通道和不同局部区域的重要性权重,解决了不同通道所代表特征的重要性程度以及不同局部区域的显著性程度不同的问题,从而根据经验区域提升光谱信息表征的充分性和有效性。本文还结合先验光谱信息,引入判别距离扩大损失函数来增强不同类别之间的差异,采用光谱约束的无监督聚类方法确定网络输入,解决

目标空间分布稀疏,相邻空间位置通常代表同类像素,难以通过空间先验知识提升检测精度的问题,进一步减少高维复杂背景以及光谱变化对于目标的干扰,增加背景和背景之间的距离。

在6个真实的高光谱基准数据集上,将本文算法与6种先进的算法进行比较,实验结果和分析证明了本算法在检测精度和背景抑制能力方面的有效性。

2 相关的工作

2.1 注意力机制

注意力机制是将注意力转移到图像中最重要的区域而忽略不相关部分的方法。人类视觉系统使用该方法有效地分析和理解复杂场景。在计算机视觉中,注意力机制可以被看作动态选择的过程,根据输入的重要性对特征进行自适应加权,从而忽略无关信息而关注有用信息。注意力机制在许多视觉任务中都起到重要作用,例如图像分类、物体检测、语义分割、人脸识别、医学图像处理等^[24,25]。

根据是否可微分,注意力机制分为强注意力机制(hard attention)和软注意力机制(soft attention)。其中,软注意力机制是可微的过程,而强注意力机制是不可微的过程。软注意力机制可以视为 $[0, 1]$ 之间的连续分布问题,使用从0到1之间的分数作为权重,表示对每个区域的关注程度。而强注意力机制是0,1的离散问题。现有的注意力机制模型主要基于软注意力,经过加权后聚合有用信息,从而分离出重要信息,并避免这些信息受到不重要信息的干扰,提高任务实现的准确性。软注意力机制更加关注区域或通道,同时它是可微分的,通过神经网络计算梯度,注意力通过前向传播和反向传播进行加权^[26,27]。

根据关注区域的不同,注意力机制可以分为空间域、通道域、层域、混合域和时域注意力机制。单通道信息严格采用标量编码,同时尽可能多地保持整个通道的表示能力。文献[28]首先提出了通道注意力的概念,并提出了SENet(Squeeze-and-Excitation Net),采用挤压-激励块的方式收集全局信息、捕获通道关系和提高表示能力。由于特征建模的简单性和有效性,通道注意力机制可直接通过学习为不同的通道分配重要性不同的权重,这一特性使其成为深度学习中广泛应用的工具^[29-31]。

为了减少HSI中的光谱冗余,本文为HTD设计特征方差感兴趣区域关注权重值,采用通道注意力重新校准具有不同权重的频谱通道^[32-34],从而降低不同信息之间相互作用的复杂度,提升学习的有效性。

2.2 基于深度学习的HTD

基于深度学习的方法由于具有较强的非线性特征表

示能力在 HSI 处理中为许多传统方法取得了突破性进展^[35,36]. 与其他 HSI 处理任务相比,在基于深度学习的 HTD 算法中,由于目标类别的比例远小于背景类别而存在两个问题:标记样本数量有限和不同类别间样本不平衡^[37]. 因此,将现有的深度神经网络应用于 HTD 具有一定难度. 另一方面,仅使用未标记数据来提取代表性特征的无监督学习为基于深度学习的 HTD 提供了有价值的思路. 然而,这些无监督模型性能依赖于未标记数据,检测性能仍需提升^[38]. 因此,本文先通过无监督聚类算法获得模型的输入,使用从先前标记的 HSI 数据中获得的相似度量来引导网络的训练,其中包括对未标记目

标像素的 HSI 进行经验性区域的检测,从而进一步扩大网络对背景和目標重构的差异性.

3 本文方法

3.1 总述

本文基于 HSI 中目标数量少且与背景服从本质不同分布的假设,构建了区域引导的双通道注意力机制 HTD 算法,主要包括 3 个部分:无监督光谱约束聚类算法、区域引导的自适应背景学习、基于属性滤波和引导滤波的目标检测,目的是促进背景重构的有效性,减少目标对背景建模的干扰,模型示意图及算法流程分别如图 1 和图 2 所示.

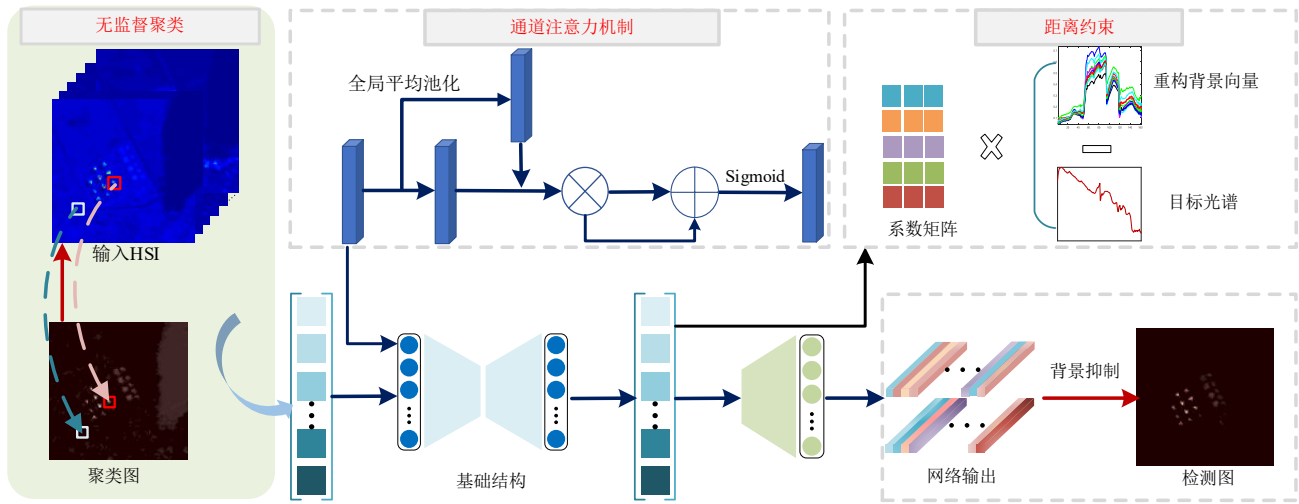


图 1 RADN 高光谱目标检测算法流程

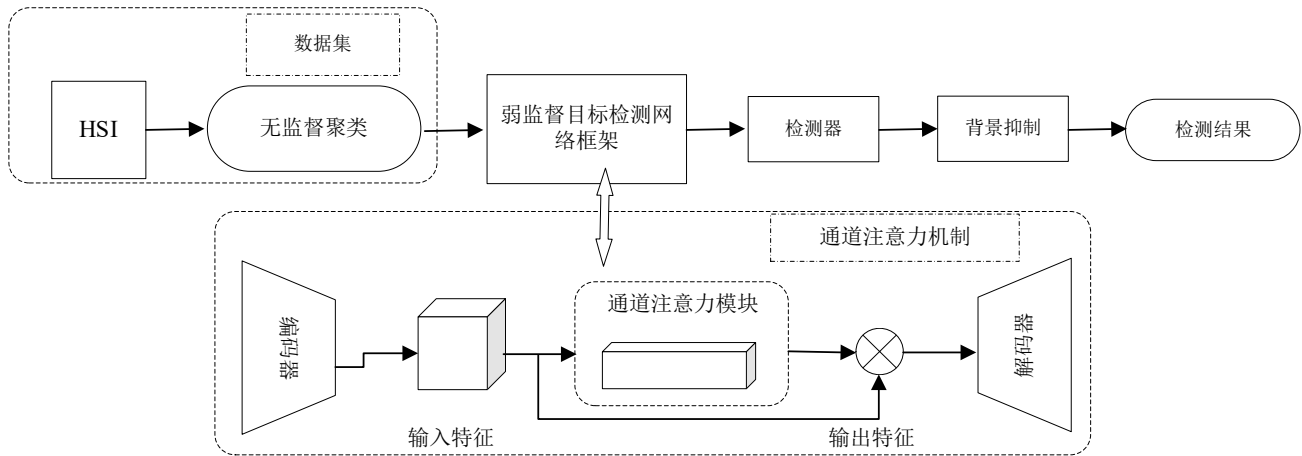


图 2 本文算法流程

3.2 从聚类中获得的感兴趣的区域

K-均值聚类算法易于实现、原理简单且聚类速度快,在处理高光谱图像等大规模数据集时具有独特的优势. 本文基于经典的 K-均值聚类算法设计了光谱约束无监督聚类算法,从中获得感兴趣区域并生成训练样本^[39].

K-均值算法将样本划分为 n 组,并选取聚类中心 μ_i ,划分聚类数为 $Y = \{Y_1, Y_2, \dots, Y_n\}$,考虑样本集 Y_i 所有可能的聚类,使平方误差最小化并找到最优解,这是 NP 困难问题(Non deterministic Polynomial,非确定性多项式问题). 通过最小化输入 x 与平均值 μ_i 之间的平方误差使得聚类误差最小,平方误差表示如下:

$$E = \sum_{i=1}^k \sum_{x \in p_i} \|x - \mu_i\|_2^2 \quad (1)$$

其中, μ_i 代表聚类 p_i 的均值向量; k 代表聚类的数量; μ_i 周围的聚类样本在一定程度上比较接近. E 的值越小, 聚类样本间的相似性越高.

本文首先在给定高光谱向量样本集 $X = \{x_1, x_2, \dots, x_n\}$ 的基础上, 将数据集作为光谱向量划分为 k 组, 并选择初始的 k 个聚类中心. 假设聚类数为 k , 首先从 X 中随机选择 k 个样本作为初始平均向量 $\{\mu_1, \mu_2, \dots, \mu_k\}$, 令 $p_i = \varphi, i = \{1, 2, \dots, k\}$, 对于 $j = \{1, 2, \dots, M\}$, 计算样本 x_j 与每个平均向量 μ_i 之间的距离, 从而根据距离最近的平均向量确定 x_j 的聚类标签 λ_j , 并将样本 x_j 划入相应的簇, $p_{\lambda_j} = p_{\lambda_j} \cup \{x_j\}$, 接着计算新的均值向量来更新当前的均值向量, 当达到最大迭代次数时停止迭代, 输出为聚类结果 $P = \{p_1, p_2, \dots, p_k\}$. 当样本分配到簇的过程不再变化时, 算法就会呈现收敛.

本文采用欧氏距离度量数据, 给定两个样本 $X = [x_1 x_2 \dots x_n]$ 和 $Y = [y_1 y_2 \dots y_n]$, 其中, n 为特征数, X 和 Y 之间的欧氏距离表示 $\text{dist}_{\text{ed}}(X, Y) = \|X - Y\|^2 = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2}$. 均方误差函数可以表示为 $\text{MSE} = \sum_{i=1}^K \sum_{x \in p_i} (p_i - x)^2$, 为了得到最大解, 对误差函数求解一阶导数 $\frac{\partial}{\partial p_k} \text{MSE} = \frac{\partial}{\partial p_k} \sum_{i=1}^K \sum_{x \in p_i} (p_i - x)^2 = \sum_{x \in p_k} 2(p_k - x) = 0$. 聚类的均值向量可以表示为 $P = \left(\frac{x_{11} + x_{12} + \dots + x_{1n}}{m}, \dots, \frac{x_{m1} + x_{m2} + \dots + x_{mn}}{m} \right)$, 其中, m 为聚类中的点数; P 的解是 x_i 的均值向量. 在聚类的迭代过程中, 样本点被划分为最近邻簇时, MSE 的值会降低, 然后继续重新优化中心点, 从而得到模型的输入, 并表示如下:

$$D_f = f_{\text{kmeans}}(H) \quad (2)$$

其中, 聚类得到的初始检测图 D_f 是使误差函数最小的聚类结果, 也是背景和兴趣区域位置的引导图, 作为经验区域来获得训练样本, 引导模型训练, 表示如下:

$$D_f = \text{Set}_{\text{Tm}} + \text{Set}_{\text{Tar}} \quad (3)$$

$$\text{Set}_{\text{Tm}} = \{(b_i, l_i) | i = 1, 2, \dots, n\} \quad (4)$$

$$\text{Set}_{\text{Tar}} = \{(t_i, l_i) | i = 1, 2, \dots, n\} \quad (5)$$

在获得感兴趣区域后, 进一步生成目标和背景候选向量, 并将它们映射到原始图像上获得背景和兴趣区域

向量进行网络训练.

3.3 双通道注意力机制判别式学习网络

通道注意力机制使用标量来表示和评估每个通道的重要性, 被广泛应用于神经网络中. 每个特征通道上的权重矩阵表示不同目标区域所代表的图像分量, 即不同信道分量与目标区域的关键信息区域之间的相关性. 通过计算相关性关注 HSI 的关键部分, 减少无用的信息. 区域引导的双通道注意力机制模块主要包括以下 3 个步骤: (1) 将编码器提取到的特征输入全局协方差池化函数中, 得到一个通道的权值; (2) 对每个通道进行此操作, 以生成相应的特征权重矩阵; (3) 以此为特征加权突出显示感兴趣特征信息, 输入 S 型函数来生成 $[0, 1]$ 之间的注意力机制的权值.

本文将通道注意力机制模块加入生成器和判别器中, 判别器注意力机制模块旨在引导生成器关注对于生成接近真实分布重要的区域, 生成器中的注意力机制模块主要目的是突出感兴趣区域中不同于输入的其他区域. 该生成器专注于训练输入训练样本的注意力机制特征图区域, 它们与测试阶段不同, 因此可以确定目标图像是真还是假. 通道注意力机制的流程如图 3 所示. 通常, 全局平均池化因简单和有效成为一种广泛的压缩方法. 此外, 还有一些压缩方法, 如全局最大池化和全局标准差池化, 同样也得到了广泛的应用. 具体来说, 本文采用全局协方差池化, 相比传统的平均池化或最大池化, 利用二阶统计结合光谱和空间信息的联合分布建模.

$$S_{r-1} = \text{pool}_{\text{var}}(X_{r-1}) \quad (6)$$

其中, $\text{pool}_{\text{var}}(\cdot)$ 表示协方差池; $S_{r-1} \in \mathbb{R}^{1 \times 1 \times C}$ 为输出统计量; $X_{r-1} = f_{\text{trans}}(F_{r-1})$.

假设: $X \in \mathbb{R}^{C \times H \times W}$ 为图像特征, C, H, W 分别为通道数、特征的高度及特征的宽度. 本文将通道注意力机制中的标量表示视为压缩问题, 因为使用标量表示通道, 从而将注意力机制写为

$$X_{\text{att}} = \text{sigmoid}(f_c(\text{compress}(X))) \quad (7)$$

其中, X_{att} 是注意力机制输出的特征向量; $\text{sigmoid}(\cdot)$ 是激活函数; $f_c(\cdot)$ 表示全连接层; $\text{compress}(\cdot)$ 表示全局协方差池化. 在获得所有 C 个通道的注意力机制输出向量后, 输入 X 的每个通道按照相应的注意力权值进行加权.

3.4 判别式学习扩大损失函数

扩大背景与目标之间的距离可以在特征空间中提高对目标的检测能力, 本文在 RADN 网络的优化过程中引入已知目标向量与重构背景向量之间的距离约束损失函数, 此扩展损失函数能够提高识别能力.




图3 注意力机制示意图

$$\max_{\theta, \beta} \sum_{j=1}^q s_j \|b'_j - d\|_2^2 \quad (8)$$

$$s_j = \exp\left(-\frac{\|b_j - d\|_2^2}{\sigma_1}\right) \quad (9)$$

其中, d 为目标光谱向量; σ_1 为自适应参数; $b'_j = f(\theta b_j + \beta)$ 为编码器输出的背景向量, $\theta \in \mathbb{R}^{K \times L}$, $\beta \in \mathbb{R}^{K \times 1}$; s_j 为自适应因子调节距离约束. 一般来说, σ_1 越小, 在重构特征空间中目标与背景之间的距离越大.

3.5 检测目标

本文模型由背景光谱向量训练, 以 H 作为测试数据的输入, 输出图像可以很好地重建背景光谱向量, 但对类间差异性的优化不佳. 除了这种对抗性学习之外, 使用马氏距离来检测背景被抑制数据中的目标

$$D = (x'_i - \mu)^\top \Gamma^{-1} (x'_i - \mu) \quad (10)$$

其中, D 为粗检测结果; $x'_i \in \mathbb{R}^{L \times 1}$, 为 X' 中第 i 个向量; $\mu \in \mathbb{R}^{L \times 1}$ 和 $\Gamma \in \mathbb{R}^{L \times L}$ 分别为 X' 的均值和协方差矩阵.

4 实验结果与分析

本节配置实验设置和参数, 利用由不同传感器捕获的 6 张高光谱遥感图像, 包括 HYDICE、San Diego、Segundo 和机场-海滩-城市 (Airborne-Beach-Urban, ABU) 数据集, 验证本算法和对比算法的性能, 具体情况描述如下.

4.1 数据描述

4.1.1 HYDICE 数据集

此数据集由高光谱数字图像采集实验 (HYperspectral Digital Imagery Collection Experiment, HYDICE) 传感器在美国加州城市地区上空获得, 每个波段对应的空间维度为 80×100 , 在总共 210 个波段中去除噪声波段后使用 162 个波段实验, 其中 21 个汽车和屋顶像素被

视为目标, 该数据集的伪彩图及其对应参考图如图 4 所示.

4.1.2 San Diego 数据集

此数据集由 AVIRIS (Airborne Visible/InfraRed Imaging Spectrometer) 传感器拍摄, 空间分辨率为 3.5 m, 光谱分辨率为 10 nm, 覆盖美国加州圣地亚哥机场区域, 嵌入背景的 3 个机场的 134 个像素被视为要检测的目标, 数据集的空间大小为 100×100 , 在总共 224 个光谱波段中消除噪声波段, 保留 189 个波段. 该数据集的伪彩图及其对应参考图如图 4 所示.

4.1.3 EI Segundo 数据集

此数据集由 AVIRIS 传感器拍摄, 空间分辨率为 7.1 m, 波长范围为 366~2 496 nm, 覆盖美国加州的 EI Segundo 区域, 包括炼油区、居民区、公园和校园, 其中储油罐和塔等被视为目标. 数据集的空间大小为 250×300 , 具有 224 个光谱通道, 该数据集的伪彩图及其对应参考图如图 4 所示.

4.1.4 机场-海滩-城市 (ABU) 数据集

ABU 数据集是公开数据集, 包括飞机、城市和海滩场景. 这些图像包含 100×100 或 150×150 空间像素. 其中一个海滩的场景是由反射光学系统成像光谱仪 (Reflective Optics System Imaging Spectrometer, ROSIS-03) 传感器捕获的, 该数据集的伪彩图及其对应参考图如图 4 所示.

4.2 比较方法

通过对比 ACE、BLTSC^[35]、CEM、hCEM、eCEM、CSCR、WSLHTD^[39] 等算法, 验证了本文所提算法的有效性. 其中, CEM, eCEM 和 hCEM 方法作为基于 CEM 方法的典型代表和变体, hCEM 分层运行, eCEM 以级联方式运行. ACE 代表基于统计的方法, 而 CSCR 进行低秩模型分解和稀疏矩阵分解. BLTSC 则是一种先进的基于深度学习的具有背景学习模型的方法. 为了对检测

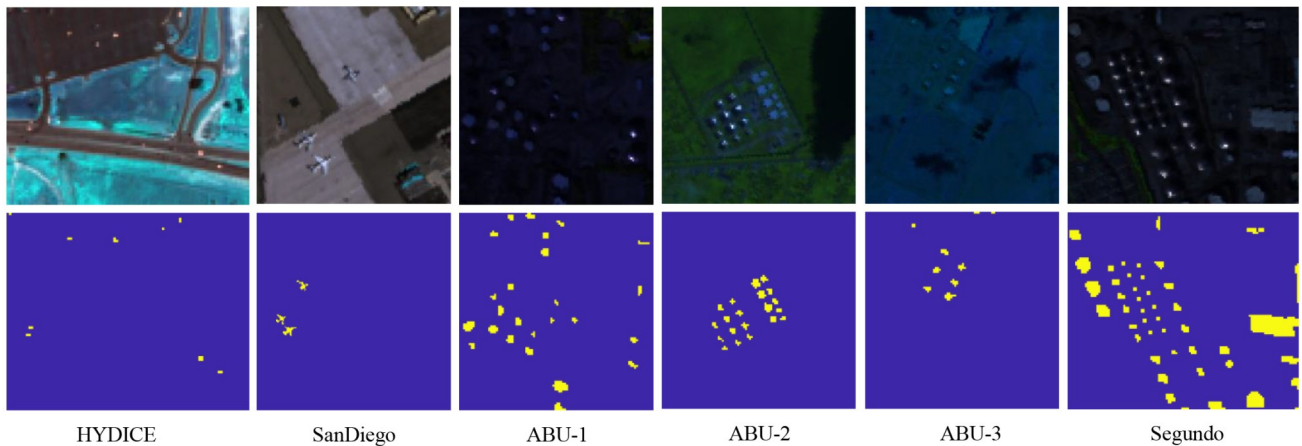


图4 实验所用不同高光谱数据集的伪彩图及参考图

性能进行更详细的定量分析,本文采用基于3DROC分析的评估方法,该方法扩展了传统的2DROC分析,并将NP检测器中使用的阈值作为独立参数^[2].

本文利用由不同传感器捕获的6张高光谱遥感图像,包括HYDICE, San Diego, Segundo和ABU数据集,验证本算法和对标算法的性能.

4.3 参数设置

4.3.1 主要参数

本算法主要涉及4个主要参数:无监督光谱聚类的聚类数、隐藏层节点数、特征维数和距离约束损失函数平衡因子.聚类的数量可能会影响无监督光谱聚类结果,聚类数量设置为2,分别代表背景和目标类.在本算法中,设置基于数据集质心集为10.此外,还分析了目标距离约束权重以及潜在空间中隐藏层和节点数对实验结果的影响.

4.3.2 目标约束损失函数的系数

当目标约束损失函数的系数 α 在两个时间间隔内从0.025变化到0.4时, $AUC_{(D,F)}$ 、 $AUC_{(F,r)}$ 和 $AUC_{(D,r)}$ 的2D-ROC值的变化表明了不同的性能.在不同的数据集上进行实验,约束变量只改变目标距离约束损失函数.从图中可以看出,当 α 为0.05时,实验数据集的效果最好.全连接层的数量从1变化到5,以达到网络体系结构的最佳性能.随着层数的增加, $AUC_{(D,F)}$ 也有增加的趋势.当层数分别为3、4、5时, $AUC_{(D,F)}$ 趋于稳定.考虑到性能和计算成本的平衡,层数设置为3层.潜在空间中隐藏节点的数量从250个变化到2000个,使得网络的收敛速度加快,图5为系数对检测精度的影响.

4.3.3 对比方法中的参数

将5种经典的检测算法和1种基于深度学习的方法用于性能对比,CEM和ACE方法中除了先验已知的目标光谱外,不需要其他参数,并且对于所有数据集参数都保持不变.在CSCR中,不同数据集双窗口的大小不同^[17].对于hCEM检测器,所有数据集将 λ 设置为




图5 损失函数系数对不同数据集检测精度的影响

200. eCEM中的扫描窗口设置为 $\left\{\frac{1}{4}D, \frac{2}{4}D, \frac{3}{4}D, D\right\}$,其中, D 为频带数.在BLTSC方法中,设置网络层数为2,设置第一个隐藏层的节点数为50.

4.4 检测结果

4.4.1 定量分析

在HYDICE, San Diego, EI Segundo和ABU数据集上所有对比算法的检测精度如表1和表2所示,最优结果使用粗体字显示,次优结果采用下划线显示.本方法在大多数数据集上获得了2D-ROC和3D-ROC值的最优性能.验证了本方法目标检测和背景抑制,检测结果表明有效性.

观察实验统计数据可以得出结论,RADN在ABU数据集和Segundo数据集上比其他方法显示出更优越的检测能力,但对于HYDICE和San Diego数据集,本方法的指标稍差,如hCEM和eCEM具有更低的虚警率.然而,RADN的 AUC_{BS} 与其他算法相比在几乎所有的数据集都达到最好的或者第二好的,这说明了本方法

具有较好的抑制和减少背景干扰能力. 例如, 在 HYDICE 上, RADN 中的 AUC_{BS} 是 0.999 0, hCEM 值为 0.998 9; 在 San Diego 数据集上, RADN 中的 AUC_{BS} 为 0.989 1, WSL 中的 AUC_{BS} 为 0.991 5. 实验结果表明, RADN 可以通过注意力机制关注难以检测的背景而非所有像素, 从而利用最丰富、最突出的目标导向信息进行目标检测. 如果参数选择适当, 本方法表现更好, 虚警率较低而检测率更高. 此外, 模型中使用了注意力机制模块和目标距离约束也能使性能达到更好. 以 ABU-1 数据集为例, $AUC_{(D,F)}$ 和 $AUC_{(F,\tau)}$ 分别达到 0.998 8 和 0.000 1, 说明该方法具有较好的检测性能, 略高于效果较好的 CSCR (0.997 5 和 0.003 1), 表示本方法基本能够实现较低的虚警率, AUC_{TD} 值、 AUC_{BS} 值及 AUC_{SNPR} 值分别为 0.998 2、1.136 1 和 203.03, 相比于其他算法对于目标检测性能较好, 对于背景抑制的能力更优, 信噪比的概率比大. 此外, 本文算法在 HYDICE 及 ABU 数据集上 AUC_{BS} 值均达到最优, 在 San Diego 和 Segundo 数据集上均达到第二优, 表明本文算法在背景抑制能力上性能较好, 有利于区分易混淆的背景和目标, 达到更好的检测效果.

4.4.2 定性分析

与 ACE, BLTSC, CEM, eCEM, hCEM 和 CSCR 相比, 本方法的检测结果图与参考图之间的差异较小, 如图 6 所示. 与 RADN 相比, hCEM 和 eCEM 在 HYDICE 和 San Diego 数据集上的目标检测能力略好, 在数据集 ABU-3 上, RADN 显示了较好的边缘区域混合像素的检测能力. 具体来说, hCEM 由于背景相关估计会面临目标和背景的误检. 相比之下, RADN 不需要对背景做出假设. 然而, 特别是对于 ABU 数据集, 基于深度学习的方法 BLTSC 和 RADN 方法没有很好地抑制来自背景干扰的虚警像素. 由于背景的干扰和多元高斯分布的假设, ACE 存在一定的光谱失真和对于目标像素的漏检. CEM 对于包含结构信息的目标检测效果较差. 从图 6 中的 San Diego 数据集可以观察到, hCEM 和 eCEM 能够学习 HSI 的光谱判别性信息, 然而存在不稳定性. 通过分析图 6 中的 ABU-3 数据集的视觉检测图可以发现, CSCR 比 CEM 检测率略低, 虽然空间结构保存较好, 但检测图在背景中显示出较高的值, 使得难以从视觉上识别目标. 综上所述, 本方法对背景抑制效果显著, 能够更有效地处理边缘区域的目标, 在保留目标和抑制背景方面取得了较好的性能.

表 1 3 个数据集的 3 个 2D-ROC 计算出的 AUC 值

数据集	方法	$AUC_{(D,F)}$	$AUC_{(F,\tau)}$	$AUC_{(D,\tau)}$	AUC_{TD}	AUC_{BS}	AUC_{SNPR}
HYDICE	ACE	0.986 4	0.241 7	0.650 2	1.636 6	0.744 7	2.690 3
	CEM	0.982 4	0.021 9	0.447 1	1.429 6	0.960 6	20.447
	eCEM	0.980 2	0.003 0	0.160 4	1.140 6	0.977 2	53.842
	hCEM	0.999 9	0.001 0	0.470 4	1.470 3	0.998 9	460.32
	BLTSC	0.982 4	0.012 3	0.445 4	1.427 8	0.970 3	36.211
	CSCR	0.986 5	0.003 4	0.067 7	1.054 1	0.983 1	19.942
	WSL	0.999 2	0.001 3	0.396 9	1.000 5	0.997 9	302.25
	RADN	0.999 0	0.407 2	0.011 4	1.406 1	0.987 5	35.670
San Diego	ACE	0.973 3	0.194 4	0.461 2	1.434 5	0.778 9	2.372 5
	CEM	0.966 2	0.034 1	0.303 5	1.269 7	0.932 0	8.898 6
	eCEM	0.872 5	0.003 5	0.110 6	0.983 1	0.868 9	31.396
	hCEM	0.958 7	0.129 6	0.378 7	1.337 4	0.829 1	2.922 7
	BLTSC	0.967 0	0.002 1	0.140 5	1.107 5	0.964 9	66.702
	CSCR	0.907 7	0.114 5	0.244 9	1.152 6	0.793 1	2.138 7
	WSL	0.992 9	0.001 4	0.219 7	0.994 2	0.991 5	161.20
	RADN	0.992 2	0.003 1	0.084 8	1.077 1	0.989 1	27.008
Segundo	ACE	0.893 4	0.301 1	0.509 6	1.403 0	0.592 3	1.692 0
	CEM	0.876 8	0.066 6	0.300 0	1.176 8	0.810 2	4.502 3
	eCEM	0.813 8	0.000 2	0.007 6	0.821 3	0.813 6	36.365
	hCEM	0.926 3	0.020 2	0.344 9	1.271 3	0.906 1	17.060
	BLTSC	0.876 7	0.049 6	0.296 5	1.173 3	0.827 2	5.981 2
	CSCR	0.642 0	0.058 9	0.163 7	0.805 7	0.583 1	2.778 5
	WSL	0.995 5	0.003 7	0.268 7	0.999 2	0.991 8	71.829
	RADN	0.991 9	0.001 0	0.037 7	1.029 7	0.990 9	36.644

表2 从ABU数据集的3个2D-ROC中计算出的AUC值

数据集	方法	$AUC_{(D,F)}$	$AUC_{(F,\tau)}$	$AUC_{(D,\tau)}$	AUC_{TD}	AUC_{BS}	AUC_{SNPR}
ABU-1	ACE	0.959 4	0.183 3	0.466 6	1.425 9	0.776 1	2.545 9
	CEM	0.941 1	0.015 0	0.215 9	1.157 0	0.926 1	14.384
	eCEM	0.990 3	0.031 5	0.614 2	1.604 5	0.958 8	19.508
	hCEM	0.960 2	0.002 6	0.407 8	1.368 1	0.957 7	159.07
	BLTSC	0.946 5	0.005 0	0.176 2	1.122 8	0.941 6	35.298
	CSCR	0.997 5	0.003 1	0.054 0	1.051 5	0.994 4	17.475
	WSL	0.996 9	0.000 9	0.182 2	0.997 9	0.996 0	193.58
	RADN	0.998 8	0.000 7	0.137 2	1.136 1	0.998 2	203.03
ABU-2	ACE	0.736 1	0.169 9	0.360 6	1.096 6	0.566 2	2.122 5
	CEM	0.856 0	0.011 9	0.188 8	1.044 8	0.844 1	15.835
	eCEM	0.950 0	0.003 2	0.179 8	1.129 9	0.946 8	55.939
	hCEM	0.846 1	0.002 1	0.194 0	1.040 2	0.844 1	94.468
	BLTSC	0.871 5	0.013 3	0.199 7	1.071 2	0.858 2	14.992
	CSCR	0.974 6	0.073 7	0.359 2	1.333 9	0.900 9	4.874 4
	WSL	0.981 0	0.000 8	0.161 6	0.981 8	0.980 2	209.59
	RADN	0.999 1	0.000 8	0.057 8	1.057 0	0.998 4	74.735
ABU-3	ACE	0.843 1	0.152 3	0.323 6	1.166 7	0.690 9	2.125 1
	CEM	0.866 9	0.022 3	0.202 4	1.069 3	0.844 6	9.087 5
	eCEM	0.880 7	0.035 1	0.179 6	1.060 3	0.845 6	5.111 0
	hCEM	0.910 1	0.013 7	0.255 1	1.165 2	0.896 4	18.680
	BLTSC	0.866 9	0.005 6	0.171 1	1.038 0	0.861 3	30.556
	CSCR	0.818 8	0.044 3	0.185 5	1.004 3	0.774 5	4.186 5
	WSL	0.981 1	0.001 5	0.164 8	0.982 7	0.979 6	107.27
	RADN	0.995 1	0.000 7	0.045 4	1.040 5	0.994 4	66.816




图6 各方法在6个HSI数据集上典型场景的视觉定性分析

4.5 可分离度分析

图7为背景-目标区分度的分析,从中可以看出表示目标分布范围的位置相对较高,而表示背景分布范围的位置相对较低.与CEM, hCEM, eCEM, CSCR, BLTSC, ACE方法相比,本方法的目标和背景值的分布范围更集中,两者的差距也较大,这表明本方法可以更大程度上从大量背景中分离出少量的目标,从而有利于有效地检测出目标. CSCR算法也能很好地区分目标,但对于某些特定数据集,如HYDICE和San Diego,分离的显著程度较为不足,从而导致较高的虚警率. 总体而言,本文方法可以使目标与背景的区分程度更加显著,主观和客观实验结果的分析与结论一致.

4.6 ROC评价

3D-ROC曲线和2D-ROC曲线被用于评估整体检测性能,为了使视觉评价更有说服力,本文采用3D-ROC曲线进行定量分析、目标保留和背景抑制的效果. 从图8和图9中可以看到,本方法在San Diego和Segundo数据集上具有比其他方法更优越的检测能力. 对于ABU-1和HYDICE数据集, RADN在虚警率低的条件下表现略差于某些方法. 同时使用3条2-DROC曲线进行可靠性评价,其中, $AUC_{(D,F)}$ 的2D-ROC曲线用于评价整体检

测性能,而 $AUC_{(F,e)}$ 和 $AUC_{(D,e)}$ 的2D-ROC曲线分别用于评价目标保存和背景抑制对目标检测的影响.

4.7 消融实验

本文采用消融实验评估本架构的有效性,对以RADN为基础的3个变形网络进行比较,其中,一个网络只采用编解码器的生成模型,一个网络只使用隐层和重构空间添加判别器的架构,如图9所示. 这3种变形形式都没有采用通道注意力机制. 此外,本文对不添加无监督聚类以及不增加扩大损失函数的情况进行实验,实验结果如表3所示. 具体来说,第一种形式利用RADN中传统的自动编码器,没有加入判别器,仅提取潜在空间中的特征,结果相对较差. 第二种形式利用RADN中预测场景解析模型的判别器,其性能优于第一种. 第三种形式也比第二种表现得更好,并增加了判别器. 然而,它们都没有添加注意力机制,相应地限制了目标的生成能力,因此本文算法仍具有更好的性能. 与这些变形形式相比, RADN取得了最好的性能,这是由于注意力机制和两种在潜层空间和重构空间中学习到的互补和目标引导信息具有很强的表征能力. 结果证实,在RADN中添加两个具有通道注意力机制的判别器的结构是有效的,无监督聚类算法及扩大损失函数均具有一定有效性.

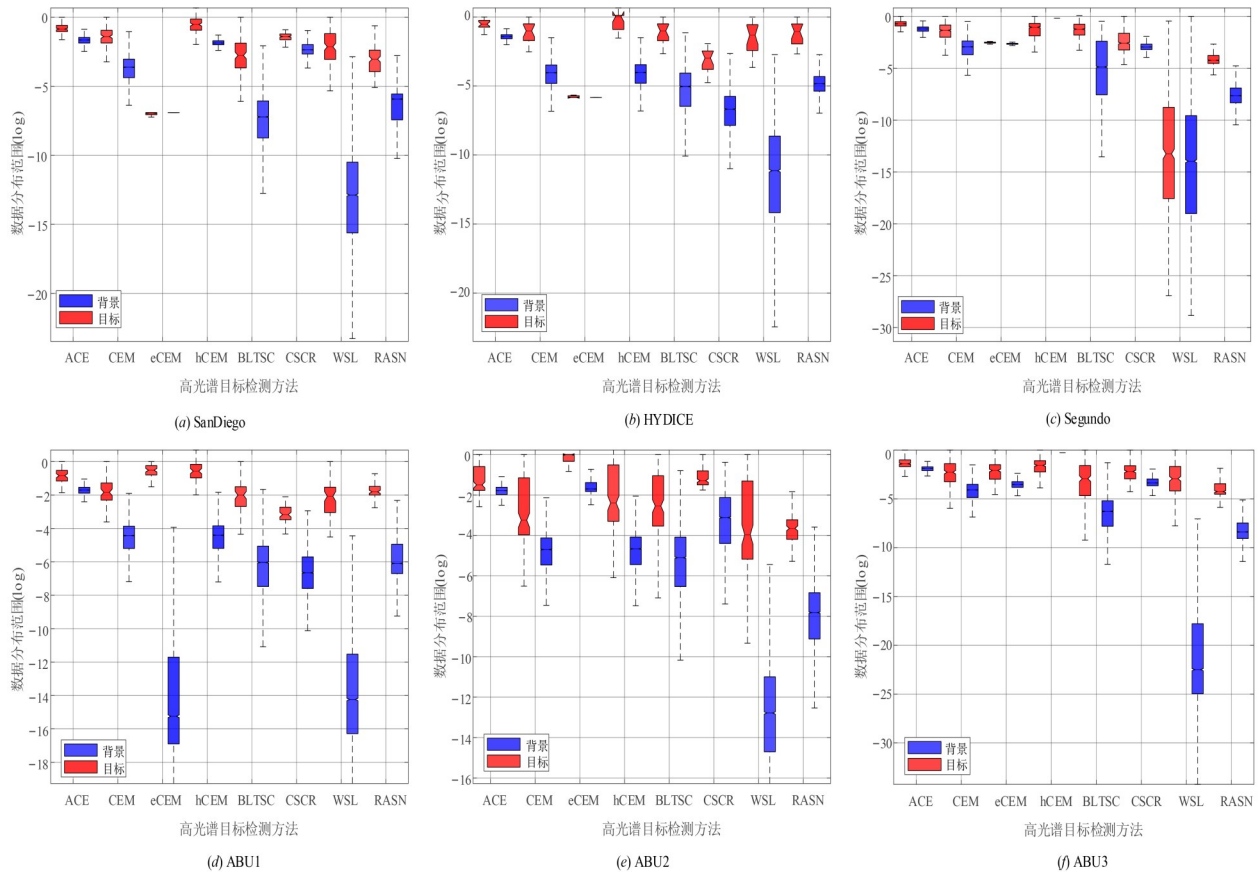


图7 各方法在6个数据集上的背景和目标区分度分析

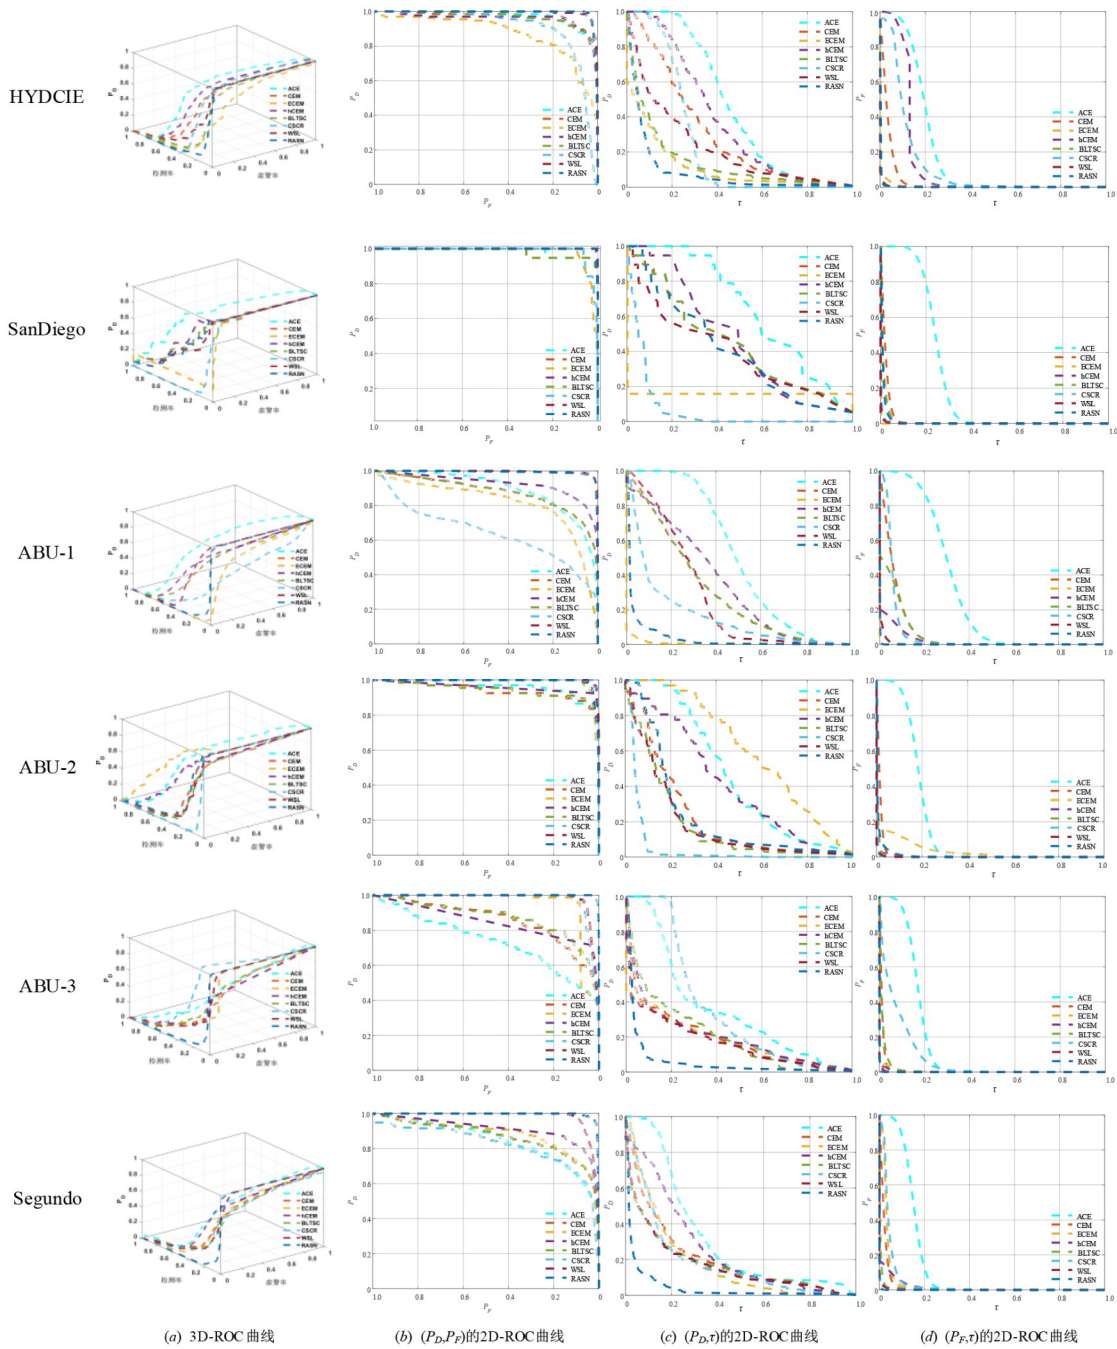


图 8 各项对比方法在 6 个数据集上的 3D-ROC 曲线和 2D-ROC 曲线

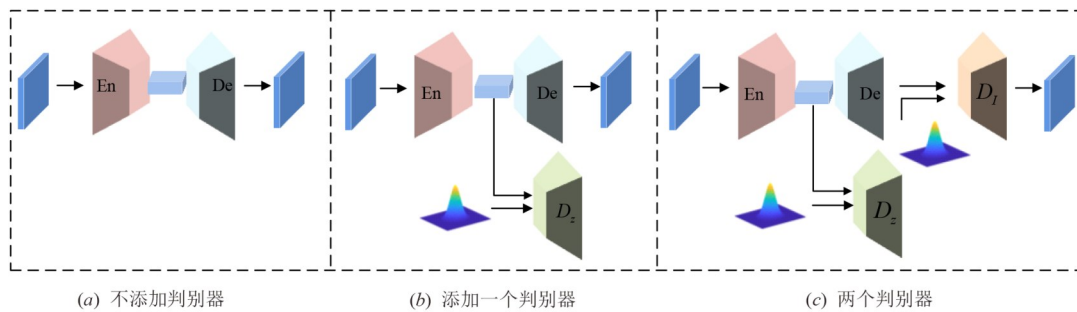


图 9 判别网络不同变形形式示意图

表3 RADN不同场景的AUC值比较

数据集	方案	$AUC_{(D,F)}$	$AUC_{(F,t)}$
HYDICIE	不添加判别器	0.986 5	0.016 5
	添加一个判别器	0.987 3	0.008 9
	不添加无监督聚类	0.993 4	0.015 5
	不添加扩大损失函数	0.957 4	0.039 9
	本文算法	0.998 9	0.011 4
Sandiego	不添加判别器	0.955 9	0.035 8
	添加一个判别器	0.977 7	0.007 8
	不添加无监督聚类	0.983 7	0.001 6
	不添加扩大损失函数	0.986 4	0.013 9
	本文算法	0.992 2	0.003
ABU	不添加判别器	0.723 5	0.014 6
	添加一个判别器	0.983	0.013 8
	不添加无监督聚类	0.967 8	0.002 0
	不添加扩大损失函数	0.993 6	0.009 3
	本文算法	0.992 9	0.008 9

5 结束语

本文提出区域引导的通道注意力机制光谱判别网络,突破了未标记训练样本对于性能的限制,从几个方面对提出的框架进行了评估:无监督的频谱约束聚类方法选择最优的训练候选集,基于对应的按升序排序的优先级列表确定向量序列。双通道注意力机制模块突出了提取的特征中的目标像素,从不足和混合的训练样本中找出感兴趣的区域。与以往的方法不同,本文以一种无监督的方式增强所添加注意力机制的特征。结果表明,RADN在较少的光谱冗余下获得了较好的性能,使光谱信息更充分。此外,判别损失函数扩大了目标样本与背景样本之间的差异。实验结果表明,该RADN具有较高的检测精度,性能优于现有技术。

参考文献

- [1] 童庆禧,张兵,张立福.中国高光谱遥感的前沿进展[J].遥感学报,2016,20(5):689-707.
TONG Q X, ZHANG B, ZHANG L F. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689-707. (in Chinese)
- [2] CHANG C I. Hyperspectral target detection: Hypothesis testing, signal-to-noise ratio, and spectral angle theories[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 3069716.
- [3] 张良培.高光谱目标探测的进展与前沿问题[J].武汉大学学报(信息科学版),2014,39(12):1387-1394,1400.
ZHANG L P. Advance and future challenges in hyperspectral target detection[J]. Geomatics and Information Science of Wuhan University, 2014, 39(12): 1387-1394, 1400. (in

Chinese)

- [4] DONG Y N, SHI W Z, DU B, et al. Asymmetric weighted logistic metric learning for hyperspectral target detection [J]. IEEE Transactions on Cybernetics, 2022, 52(10): 11093-11106.
- [5] ZARE A, JIAO C Z, GLENN T. Discriminative multiple instance hyperspectral target characterization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(10): 2342-2354.
- [6] YANG X C, DONG M Z, WANG Z Y, et al. Data-augmented matched subspace detector for hyperspectral sub-pixel target detection[J]. Pattern Recognition, 2020, 106: 107464.
- [7] 贺霖,潘泉,邸鞅,等.高光谱图像目标检测研究进展[J].电子学报,2009,37(9):2016-2024.
HE L, PAN Q, DI W, et al. Research advance on target detection for hyperspectral imagery[J]. Acta Electronica Sinica, 2009, 37(9): 2016-2024. (in Chinese)
- [8] CHANG C I, CHEN J. Orthogonal subspace projection using data sphering and low-rank and sparse matrix decomposition for hyperspectral target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(10): 8704-8722.
- [9] 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.
- [10] JIN X Y, PASWATERS S, CLINE H. A comparative study of target detection algorithms for hyperspectral imagery[C]//Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XV. Florida: SPIE, 2009: 682-693.
- [11] HARSANYI J C, CHANG C I. Hyperspectral image classification and dimensionality reduction: An orthogonal subspace projection approach[J]. IEEE Transactions on Geoscience and Remote Sensing, 1994, 32(4): 779-785.
- [12] CHANG C I. Hyperspectral Data Processing: Algorithm Design and Analysis[M]. New York: John Wiley & Sons, 2013.
- [13] ZOU Z X, SHI Z W. Hierarchical suppression method for hyperspectral target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(1): 330-342.
- [14] ZHAO R, SHI Z W, ZOU Z X, et al. Ensemble-based cascaded constrained energy minimization for hyperspectral target detection[J]. Remote Sensing, 2019, 11(11): 1310.
- [15] DU B, ZHANG Y X, ZHANG L P, et al. Beyond the

- sparsity-based target detector: A hybrid sparsity and statistics-based detector for hyperspectral images[J]. *IEEE Transactions on Image Processing*, 2016, 25(11): 5345-5357.
- [16] ZHU D H, DU B, ZHANG L P. Single-spectrum-driven binary-class sparse representation target detector for hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(2): 1487-1500.
- [17] LI W, DU Q, ZHANG B. Combined sparse and collaborative representation for hyperspectral target detection[J]. *Pattern Recognition*, 2015, 48(12): 3904-3916.
- [18] QIN H N, XIE W Y, LI Y S, et al. Weakly supervised adversarial learning via latent space for hyperspectral target detection[J]. *Pattern Recognition*, 2023, 135: 109125.
- [19] DU J M, LI Z Y, SUN H. CNN-based target detection in hyperspectral imagery[C]//*IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium*. Piscataway: IEEE, 2018: 2761-2764.
- [20] LI W, WU G D, DU Q. Transferred deep learning for hyperspectral target detection[C]//*2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*. Piscataway: IEEE, 2017: 5177-5180.
- [21] YANG X, DENG C, ZHENG F, et al. Deep spectral clustering using dual autoencoder network[C]//*2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE, 2019: 4061-4070.
- [22] ZHAO X B, LI W, ZHAO C H, et al. Hyperspectral target detection based on weighted cauchy distance graph and local adaptive collaborative representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5527313.
- [23] WANG Y L, CHEN X, WANG F C, et al. Meta-learning based hyperspectral target detection using Siamese network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5527913.
- [24] WANG X X, CHEN X Y, GOU S P, et al. Hyperspectral target detection via deep multiple instance self-attention neural network[C]//*IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium*. Piscataway: IEEE, 2019: 2284-2287.
- [25] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook: Curran Associates Inc., 2017: 6000-6010.
- [26] 陈文俊, 杨春玲. 图像压缩感知的特征域优化及自注意力增强神经网络重构算法, *电子学报*, 2022, 50(11): 2629-2637.
- CHEN W J, YANG C L. Feature-space optimization-inspired and self-attention enhanced neural network reconstruction algorithm for image compressive sensing[J]. *Acta Electronica Sinica*, 2022, 50(11): 2629-2637. (in Chinese)
- [27] 朱张莉, 饶元, 吴渊, 等. 注意力机制在深度学习中的研究进展[J]. *中文信息学报*, 2019, 33(6): 1-11.
- ZHU Z L, RAO Y, WU Y, et al. Research progress of attention mechanism in deep learning[J]. *Journal of Chinese Information Processing*, 2019, 33(6): 1-11. (in Chinese)
- [28] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//*2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Piscataway: IEEE, 2018: 7132-7141.
- [29] HAUT J M, PAOLETTI M E, PLAZA J, et al. Visual attention-driven hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(10): 8065-8080.
- [30] MEI X G, PAN E T, MA Y, et al. Spectral-spatial attention networks for hyperspectral image classification[J]. *Remote Sensing*, 2019, 11(8): 963.
- [31] DAI T, CAI J R, ZHANG Y B, et al. Second-order attention network for single image super-resolution[C]//*2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE, 2019: 11057-11066.
- [32] ZHANG Y L, LI K P, LI K, et al. Image super-resolution using very deep residual channel attention networks[C]//*European Conference on Computer Vision*. Cham: Springer, 2018: 294-310.
- [33] PENG Y X, HE X T, ZHAO J J. Object-part attention model for fine-grained image classification[J]. *IEEE Transactions on Image Processing*, 2018, 27(3): 1487-1500.
- [34] FUKUI H, HIRAKAWA T, YAMASHITA T, et al. Attention branch network: Learning of attention mechanism for visual explanation[C]//*2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE, 2019: 10697-10706.
- [35] XIE W Y, ZHANG X, LI Y S, et al. Background learning based on target suppression constraint for hyperspectral target detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 5887-5897.

- [36] CHIANG S S, CHANG C I, GINSBERG I W. Unsupervised target detection in hyperspectral images using projection pursuit[J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(7): 1380-1391.
- [37] ZHU D H, DU B, ZHANG L P. Two-stream convolutional networks for hyperspectral target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(8): 6907-6921.
- [38] KAUFMAN J R, EISMANN M T, CELENK M. Assessment of spatial-spectral feature-level fusion for hyperspectral target detection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2015, 8(6): 2534-2544.
- [39] LIU X W, ZHU X Z, LI M M, et al. Multiple kernel k-means with incomplete kernels[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(5): 1191-1204.

作者简介



钟佳平 女,1996年生,陕西咸阳人。现为西安电子科技大学博士研究生。主要研究方向为高光谱图像处理及深度学习。
E-mail: jpzhang@stu.xidian.edu.cn



李云松 男,1974年生,辽宁葫芦岛人。现为西安电子科技大学教授、博士生导师。主要研究方向为图像和视频处理和高性能计算。
E-mail: ysli@mail.xidian.edu.cn



谢卫莹 女,1988年生,甘肃白银人。现为西安电子科技大学副教授、博士生导师。主要研究方向为分布式智能解译以及轻量化。中国电子学会会员编号:E190022673M。
E-mail: wyxie@xidian.edu.cn



雷杰 男,1981年生,陕西渭南人。现为西安电子科技大学教授、博士生导师。主要研究方向为遥感图像编码、高光谱图像实时处理、嵌入式视觉处理、FPGA高级综合。
E-mail: jielei@mail.xidian.edu.cn