

端到端分布式联合优化的空谱自编码密度估计模型

马纪涛¹, 谢卫莹¹, 雷 杰¹, 方乐缘², 李云松¹

(1. 西安电子科技大学综合业务网理论与关键技术国家重点实验室, 陕西西安 710071;

2. 湖南大学电气与信息工程学院, 湖南长沙 410082)

摘要: 高光谱图像(Hyperspectral Image, HSI)由于其丰富的光谱信息和空间信息,被广泛应用于异常检测任务,在对地观测和深空探测中起到了重要作用. 然而,现有的基于密度估计的高光谱异常检测(Hyperspectral Anomaly Detection, HAD)方法存在如下问题:一是没有联合优化概率密度估计和特征表示这两个不同的目标函数,导致深度神经网络无法学习到更加准确的概率密度函数和包含 HSI 固有信息的低维表示;二是缺乏高层次空间语义信息与低维流行中光谱信息的自适应融合. 此外,随着光谱成像技术的发展,卫星或无人机所获取的 HSI 的体积越来越大,在遥感大数据的背景下,传统框架处理 HSI 变得十分困难,给 HAD 带来了极大的挑战. 本文分别从以上问题出发,提出了端到端联合优化的空谱协同自编码密度估计(End-to-End Spectral-Spatial Cooperative Autoencoding Density Estimation, E2E-SSCADE)模型. 基于二维卷积提取 HSI 空间特征,融合高光谱图像光谱特征和空间特征的低维表示以及重构误差表示,联合密度估计网络进行端到端的优化,并利用分布式学习实现了大体积高光谱图像的异常检测. 实验表明,所提出的 E2E-SSCADE 可以从光谱向量、空间维度以及重构空间三个角度更深层次地挖掘 HSI 固有信息的低维表示,构建更加准确的背景模型,在有效分离背景和异常目标的同时,结合分布式学习实现了快速、准确的大体积高光谱图像的异常检测,在 6 个经典 HAD 数据集上达到了 99.07% 的精度和 3.41 倍的检测速度. 实验代码见 <https://github.com/majitao-xd/E2E-SSCADE.git>.

关键词: 高光谱异常检测;空谱协同;估计网络;端到端优化;分布式学习

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(2023)04-1006-15

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

DOI: 10.12263/DZXB.20220516

End-to-End Spectral-Spatial Cooperative Autoencoding Density Estimation Model

MA Ji-tao¹, XIE Wei-ying¹, LEI Jie¹, FANG Le-yuan², LI Yun-song¹

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

2. College of Electrical and Information Engineering, Hunan University, Changsha, Hunan 410082, China)

Abstract: Hyperspectral image (HSI) is widely used in anomaly detection because of its rich spectral and spatial information, and plays an important role in the earth observation and deep space exploration. However, the existing hyperspectral anomaly detection (HAD) methods based on density estimation have the following problems. First, there is no joint optimization of the two different objective functions of probability density estimation and feature representation, which results in the deep neural network being unable to learn more accurate probability density function and low-dimensional representation containing inherent information of HSI; the other is the lack of adaptive fusion of high-level spatial semantic information and low-dimensional epidemic spectral information. In addition, with the development of spectral imaging technology, the volume of HSI acquired by satellites or unmanned aerial vehicles is increasing. In the context of remote sensing big data, it becomes very difficult for traditional frameworks to process HSI, posing a great challenge to HAD. In this paper, based on the above problems, an end-to-end spectral-spatial cooperative autoencoding density estimation (E2E-SSCADE) model is proposed. The HSI spatial features are extracted based on two-dimensional convolution, and the spectral features and spatial features of hyperspectral images are combined with the low-dimensional representation and reconstruction error representation. The end-to-end optimization is carried out by combining the density estimation network, and the anomaly detection of large hyperspectral images is realized by distributed learning. Experiments show that

the proposed E2E-SSCADE can excavate the low-dimensional representation of HSI intrinsic information from three perspectives of spectral vector, spatial dimension and reconstructed space, and construct a more accurate background model. With distributed training, fast and accurate anomaly detection of hyperspectral images is realized. The proposed method achieves 99.07% accuracy and 3.41 times faster detection on six classical HAD datasets. The code is available at <https://github.com/majitao-xd/E2E-SSCADE.git>.

Key words: hyperspectral anomaly detection; spectral-spatial cooperative; estimation network; end-to-end optimization; distributed learning

Foundation Item(s): National Natural Science Foundation of China (No.62121001, No.62071360); The Young Elite Scientist Sponsorship Program by the China Association for Science and Technology (No.2020QNRC001)

1 引言

高光谱图像(Hyperspectral Image, HSI)涵盖了从可见光到红外范围内的几十至几百个波段的电磁光谱, 包含有不同材料的固有特征信息, 因此在对地观测和深空探测领域中起到举足轻重的作用, 并在此基础上发展了分类、目标检测和异常检测等 HSI 解译技术^[1-4]. 其中, 高光谱异常检测(Hyperspectral Anomaly Detection, HAD)是指在没有任何先验信息的情况下, 对与周围背景在空间和光谱上存在差异的未知目标进行无监督检测, 并将其从背景中分离, 在伪装、隐藏目标检测和深空环境下的未知危险感知等应用中受到广泛关注.

HAD 的目的在于构建一个背景模型以将异常目标分离出来, 其核心思想是背景可以用周围样本表示, 而异常不能, 以及异常是小概率事件. 现有的 HAD 方法可以分为两大类: 传统方法和基于深度学习的方法. 文献[5]提出的 RX (Reed Xiaoli) 算法是传统 HAD 中的经典方法之一, 该算法基于背景样本远大于异常样本且背景模型服从多元高斯分布的假设, 计算待检测光谱和背景模型的马氏距离来作为判断异常目标的标准. 文献[6]在 RX 算法的基础上提出了一种局部异常检测方法 LRX (Local reed xiaoli) 算法, 采用核密度估计方法估计背景概率密度函数, 基于背景对数似然值实现局部高光谱异常检测. 但这两种方法都是基于背景分布是服从高斯分布的假设, 且计算滑动窗口的方法限制了检测对象的大小和形状. 文献[7]提出了一种基于聚类的异常检测方法 CBAD (Cluster-Based Anomaly Detection), 基于像素值在聚类内的分布构建高斯混合模型 (Gaussian Mixture Model, GMM), 作为背景概率密度函数, 可以较好地估计背景分布. 与上述基于统计进行检测的方法不同, 也有很多基于稀疏表示的 HAD 方法被提出, 如文献[8]提出了一种基于协作表示的 HAD 方法 CRD (Collaborative-representation-based detector). 此外, 基于背景的低秩属性和异常的稀疏属性, LRSMD (Low-Rank and Sparse Matrix Decomposition) 利用矩阵分解实现 HAD^[9]. 基于 LRSMD, 文献[10]引用了马氏距离, 提出 LSMAD (LRSMD-based mahalanobis dis-

tance method for hyperspectral anomaly detection). 进一步地, 文献[11]将混合噪声模型与低秩背景相结合, 并采用变分贝叶斯 (Variational Bayes, VB) 算法来推导后验 GMM. 但是, 传统方法在对具有较多波段的 HSI 进行特征提取等预先处理时, 与后续的检测过程割裂, 难以较好地提取包含 HSI 固有特征的低维表示, 在构建一个有效的、分层的、抽象的、高层次的和结合任务的背景表征上的能力有限.

随着深度学习的发展, 以及其在深层特征挖掘上的能力, 基于深度学习的 HAD 越来越受到研究人员的关注^[12-15]. 文献[16]提出了一种基于卷积神经网络 (Convolutional Neural Network, CNN) 和低秩表示 (Low-Rank Representation, LRR) 的 HAD 算法, 通过 CNN 提取特征后利用聚类算法和改进的矩阵分解方法提取异常. 文献[17]将光谱约束策略引入到对抗自编码器 (Adversarial AutoEncoders, AAE)^[18], 并在 AAE 的损失函数中加入了光谱角距离, 增强了光谱的一致性, 利用双层结构来抑制背景, 同时保持异常特征. 文献[19]中使用了一种基于各特征对检测的贡献率的抑制函数迭代优化方法, 采用结构张量矩阵自适应计算各特征的贡献率, 可以进一步降低虚警率. 上述的这些方法通过深度学习提取了 HSI 图像的光谱低维表示, 在一定程度上缓解了维度灾难. 但是, 这些方法仍将 HSI 表征学习和异常检测分开进行, 两次优化目标不一致, 导致降维过程中可能损失对异常检测贡献高的特征, 进而得到次优解. 进一步, 文献[20]中提出了一种深度自编码混合高斯模型 (Deep Autoencoding Gaussian Mixture Model, DAGMM), 通过估计网络将表征学习和密度估计联合进行端到端的优化, 避免了次优解的情况. 在此基础上, 文献[21]提出了一种端到端的固有特征自编码密度估计模型 (End-to-End Local Invariant Autoencoding Density Estimation, E2E-LIADE), 基于重构空间中区分背景和异常的假设, 提取了增广的 HSI 低维表示, 联合表征学习和密度估计进行优化, 但仍需对得到的结果进行背景抑制后处理才能得到较好的检测结果. 上述部分方法利用密度估计网络进行端到端的优化, 在一定程度上解决了次优解的难题, 但这些基于深

度学习的方法只考虑了光谱向量的特征,没有结合 HSI 固有的空间信息.

上述传统方法和基于深度学习的方法在一些经典 HAD 数据集上表现较好,但考虑到实际应用场景中所采集到的 HSI 体积较大,而且随着遥感数据的体积、获取速度和实时处理需求等的增加,遥感数据已经成了大数据.例如:美国宇航局档案中,仅地球科学数据和信息系统(Earth Science Data and Information System, ESDIS)就有超过 7.5 PB 的数据;德国的 EnMAP 卫星传感器每天能采集超过 1.6 TB 的数据^[22];我国的高分一号卫星能够实现 900 Mbps 数据传输能力,意味着该卫星能将大量待处理的数据返回地面.大体积的数据,加上数据中的背景占据了绝大部分,导致 HAD 在进行背景学习时产生了庞大的计算量.在如此大的数据和计算量的情况下,现有的图形处理硬件由于内存和内核的限制,难以高效地完成 HAD 任务.此外,一些基于深度学习的方法也包含了后处理的步骤,这些后处理大多由传统方法实现,难以结合到深度学习中,因此,基于小数据集进行设计、优化的方法难以满足大数据应用场景下的需求.而现阶段,对于遥感大数据的处理是通过云计算和分布式训练的方式^[22-28],但对于利用分布式训练检测大型 HSI 中的异常目标的研究较少.

为了有效利用 HSI 的固有信息,本文提出了一种端到端联合优化的空谱协同自编码密度估计(End-to-End Spectral-Spatial Cooperative Autoencoding Density Estimation, E2E-SSCADE)模型用于 HAD,考虑到后处理无法分布式实现,本文提出的模型完全基于深度学习,并通过分布式训练进行真正的端到端优化,意味着每一个输入的光谱向量对应一个最终的异常程度检测结果.空谱协同则结合了 HSI 的光谱特征和空间特征.主要工作包括:(1)提出了一种 E2E-SSCADE 模型用于 HAD,该模型融合 HSI 光谱向量和空间信息的特征,提取了包含 HSI 丰富固有信息的低维表示用于密度估计,能更好地分离背景和异常目标;(2)基于所提出的模型,利用分布式训练实现 HAD 任务,不同于传统分布式训练,本文考虑到 HSI 的全局特性和分布式训练中的通信瓶颈,利用梯度累加的方法避免边缘效应和频繁的通信;(3)在经典 HAD 数据集上进行了大量实验,结果表明本文提出的方法在检测精度和虚警率方面都优于现有的方法,同时在大型 HSI 数据上进行了大量实验,验证了基于分布式训练的 HAD 的可行性.

2 端到端联合优化的空谱协同增广自编码密度估计模型

如前所述,虽然现有的基于深度学习的 HAD 方法以端到端的方式提取了对 HAD 起到关键作用的信息,

避免了两步法产生次优解的问题,但是在表征学习过程中只针对光谱维输入进行了特征提取,忽略了 HSI 的空间特征,因此输入估计网络的低维表示只保留了部分 HSI 的固有特征信息,难以学习到包含空间特征的 HSI 低维表征.针对该问题,受 E2E-LIAD 算法启发,本文提出了 E2E-SSCADE 模型,该模型以端到端的方式融合空谱信息进行降维和密度估计以完成 HAD 任务. E2E-SSCADE 主要用于生成融合了 HSI 空间特征和光谱特征的低维表征,并与估计网络联合优化,检测 HIS 中的异常区域.图 1 是 E2E-SSCADE 的原理图.

对应图 1,设原始 HSI 为 $\mathbf{X} \in \mathbb{R}^{M \times N \times B}$,其中, $M \times N$ 为图像大小, B 为波段数,设 $\mathbf{x}_i \in \mathbb{R}^{B \times 1}$ 为 \mathbf{X} 中的第 i 个光谱向量,其中, $i = 1, 2, \dots, L, L = M \times N$,因此, \mathbf{X} 也可以表示为 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i, \dots, \mathbf{x}_L] \in \mathbb{R}^{L \times B}$. E2E-SSCADE 模型的整体架构可以分为三个部分:对应图 1 的第一部分, E2E-SSCADE 模型首先对输入 \mathbf{X} 进行空间特征提取得到 $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_i, \dots, \mathbf{y}_L] \in \mathbb{R}^{L \times D}$;对应图 1 的第二部分,将 \mathbf{X} 和 \mathbf{Y} 分别输入两个不同的全连接层的自编码器(Auto Encoder, AE)进行空谱融合的特征提取;对应于图 1 的第三部分,将融合结果输入到估计网络中进行密度估计并优化模型得到异常检测结果.

在对 E2E-SSCADE 模型整体进行优化时,基于密度估计方法的 HAD 会假设 \mathbf{X} 服从一个已知的分布,其概率密度函数为 $f(\mathbf{x}; \Theta)$,其中, Θ 为参数,而异常目标通常位于低密度区域.因此概率密度函数 $f(\mathbf{x}; \Theta)$ 的倒数可以反映出异常程度,参数 Θ 可以使用最大似然估计进行估计,用数学形式可以表达为一个约束优化问题:

$$\max_{\Theta} \sum_{i=1}^L \ln(f(\mathbf{x}_i; \Theta)) \quad \text{s.t. } 0 \leq f(\mathbf{x}; \Theta) \leq 1 \quad (1)$$

但 HSI 的背景分布非常复杂,且不服从多元高斯分布,难以使用简单的分布进行估计,而 GMM 具有强大的拟合能力,基于混合高斯分布可以准确地估计概率密度函数 $f(\mathbf{x}; \Theta)$ 的参数 Θ .多元高斯分布的 GMM 的概率密度函数的数学形式为

$$f(\mathbf{x}; \Theta) = \sum_{k=1}^K \phi_k N(\mathbf{x} | \mu_k, \Sigma_k), \Theta = \{\phi_k, \mu_k, \Sigma_k\} \quad (2)$$

其中, ϕ_k, μ_k 和 Σ_k 分别表示第 k 个高斯混合分量的均值、权重和协方差矩阵,且 ϕ_k 满足 $0 \leq \phi_k \leq 1$ 和 $\sum_{k=1}^K \phi_k = 1$.

GMM 的参数估计方法有多种,其中很多方法都是基于最大似然估计法的,例如期望最大化算法(Expectation Maximum, EM)等,但对于输入的 L 个样本,这些方法都可以表示为一个约束优化问题:

$$\max_{\Theta} \sum_{i=1}^L \ln(f(\mathbf{x}_i; \Theta)) \quad (3)$$

此外, HSI 通常具有较多波段数,部分相同类型背

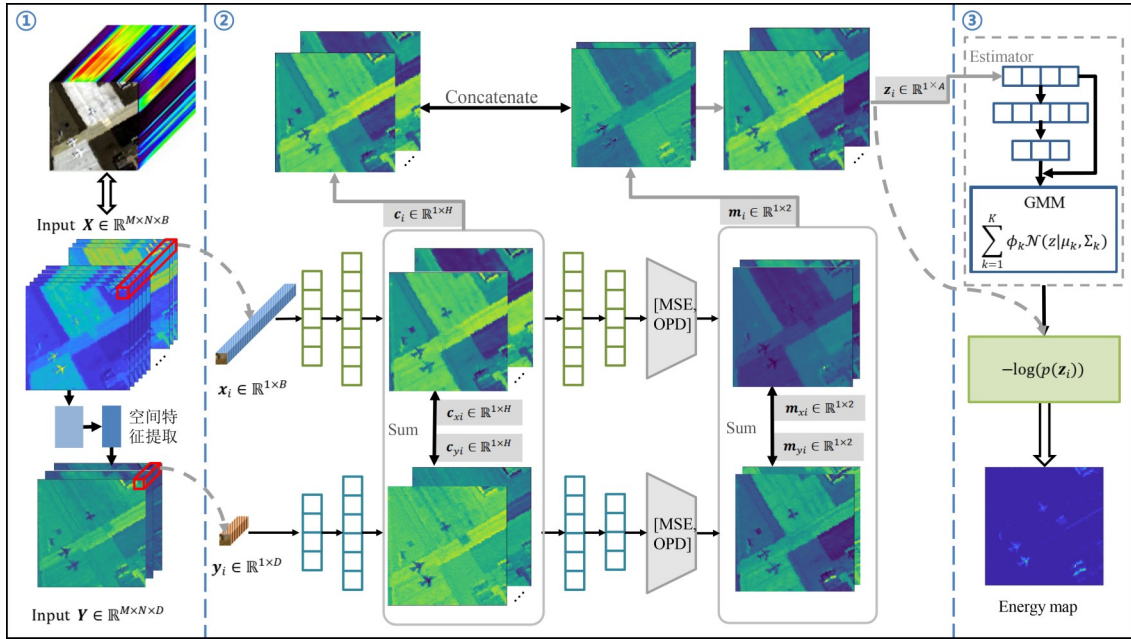


图1 E2E-SSCADE的原理框图

景像素之间也可能存在相对较大的差异,导致GMM很难直接对HSI原始数据进行拟合,因此很多HAD方法都以特征提取作为第一步,异常检测为第二步,E2E-SSCADE模型的第一、二部分的本质作用即为特征提取.

现有的特征提取方法大多基于主成分分析法(Principal Component Analysis, PCA)或全连接层的AE,可以保留大部分光谱向量特征并降低维度.然而,这两种方法只在光谱维度提取重要特征,会丢失部分空间特征,这也是陷入次优解的重要原因之一.因此,本文提出了E2E-SSCADE,提取HSI的高层次特征并学习一种低维表示,保留HSI的光谱特征和空间特征.然而,将特征提取和异常检测作为两步分别进行会导致特征提取过程缺乏后续检测过程的指导,无法保留对HAD起到关键作用的个性化的固有信息,从而产生次优解.因此E2E-SSCADE模型以端到端的方式进行优化,转化为约束优化问题的数学形式为

$$\max_{\theta_{en1}, \theta_{en2}, \theta_{dec1}, \theta_{dec2}, \theta} \frac{1}{L} \sum_{i=1}^L (\|x_i - \hat{x}_i\|^2 + \|y_i - \hat{y}_i\|^2 + \ln(f(z_i; \theta))) \quad (4)$$

其中,函数的前两个分量分别表示光谱和空间特征提取的优化问题,对光谱向量 X 及其对应的空间特征 $Y = [y_1, y_2, \dots, y_i, \dots, y_L] \in \mathbb{R}^{L \times D}$ 进行特征提取并融合,学习HSI的低维表示,函数的第三个分量表示密度估计的优化问题.在本文中,空间特征的计算采用基于二维卷积的AE网络进行特征提取得到空间上下文特征,其计算方法将在下一小节中详细描述.整体表示联合优化特征提取和密度估计,针对HAD任务挖掘HSI的个性化

低维表示,以高斯混合模型拟合背景分布,逼近最优检测结果.下面将分小节详细介绍E2E-SSCADE模型的空间特征提取、空谱特征融合、密度估计三个部分和上述公式中各个字符的具体含义.

2.1 基于二维卷积的空间上下文特征提取

提取HSI空间特征的方法有多种,主要分为空间纹理形态学特征提取、空间邻域信息提取、空间信息后处理和基于深度学习的空间特征提取四类^[29].其中前三种方法都是传统方法,需要大量的先验知识进行参数设置,而且只能从浅层进行处理,基于深度学习的方法则可以有效提取深层空间特征表示.此外,在遥感大数据的背景下,HSI的体积和数量的增加导致传统方法处理受到了限制,而深度学习方法可以在GPU等高性能计算芯片上快速处理.因此,本文基于深度学习方法,利用二维卷积核的局部连接特性提取空间上下文特征作为空间特征,如图2所示.空间上下文特征提取的整体思路是通过一个由二维卷积层组成的AE对三维的HSI图像进行降维和重构,降维的结果即为空间上下文特征.




图2 空间上下文特征提取示意图

其中, AE 的编码器 $\text{Conv}_{\text{en}}(\cdot)$ 和解码器 $\text{Conv}_{\text{de}}(\cdot)$ 都是由一层二维卷积层组成的神经网络, 卷积核大小都为 3×3 , 并以原始高光谱数据集 \mathbf{X} 作为训练数据. 编码器 $\text{Conv}_{\text{en}}(\cdot)$ 的目的是将输入数据 \mathbf{X} 映射为光谱波段数为 D 的空间特征:

$$\mathbf{Y} = \text{Conv}_{\text{en}}(\mathbf{X}; \theta_{\text{sen}}) \quad (5)$$

其中, θ_{sen} 是 $\text{Conv}_{\text{en}}(\cdot)$ 的参数. $\text{Conv}_{\text{en}}(\cdot)$ 的激活函数为 \tanh 函数:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

解码器 $\text{Conv}_{\text{de}}(\cdot)$ 的目的是将 \mathbf{Y} 重构为 \mathbf{X}^s :

$$\mathbf{X}^s = \text{Conv}_{\text{de}}(\mathbf{Y}; \theta_{\text{sdc}}) \quad (7)$$

其中, θ_{sdc} 是 $\text{Conv}_{\text{de}}(\cdot)$ 的参数. 在这两次卷积过程中进行填充操作以保证输出的像素数和原 HSI 相同, 使每个光谱向量都对应一个空间特征. 损失函数的形式为

$$\mathcal{L}_{\text{spatial}} = \frac{1}{L} \sum_{i=1}^L \|\mathbf{x}_i - \mathbf{x}_i^s\|^2 \quad (8)$$

以式(8)作为损失函数对 AE 进行优化, 最终得到的 \mathbf{Y} 即为包含了原 HSI 空间上下文特征的图像, 但由于原始 HSI 存在冗余波段, 直接与空间上下文特征融合会导致检测精度降低, 因此 E2E-SSCADE 将 \mathbf{X} 和 \mathbf{Y} 再同时进行一次特征提取, 以得到空间和谱间信息深度融合的空谱特征.

2.2 空谱协同的特征提取

为了深度融合空谱特征, 获得包含高层次空间语义信息和低维流行光谱信息的低维表示, 提高估计网络的性能, 本文提出空谱协同的自编码(Spectral-spatial cooperative autoencoding, SSCA)网络用于挖掘空谱协同的 HSI 低维表征. SSCA 使用四层全连接层组合的 AE 网络提取光谱向量的特征, 同时使用另一个四层全连接层组合的 AE 网络处理空间特征, 使其在端到端优化过程中可以同时优化光谱特征和空间特征, 实现光谱特征和空间特征的深度自适应协同, 提取到包含丰富光谱信息和空间信息的低维表示.

假设单次输入网络的像素数为 BS, AE 中的编码器 $\text{En}(\cdot)$ 和解码器 $\text{De}(\cdot)$ 都以 \tanh 函数作为激活函数, 通过 $\text{En}(\cdot)$ 得到空间和光谱特征的低维输出:

$$\mathbf{c}_{xi} = \text{En}(\mathbf{x}_i; \theta_{\text{en1}}), \quad \mathbf{c}_{yi} = \text{En}(\mathbf{y}_i; \theta_{\text{en2}}) \quad (9)$$

其中, $\mathbf{c}_{xi} \in \mathbb{R}^{H \times 1}$ 和 $\mathbf{c}_{yi} \in \mathbb{R}^{H \times 1}$ 分别表示光谱向量和空间特征的低维输出, θ_{en1} 和 θ_{en2} 分别表示两个编码器的参数. 通过 $\text{De}(\cdot)$ 将 \mathbf{c}_{xi} 和 \mathbf{c}_{yi} 重构为 $\hat{\mathbf{x}}_i$ 和 $\hat{\mathbf{y}}_i$:

$$\hat{\mathbf{x}}_i = \text{De}(\mathbf{c}_{xi}; \theta_{\text{de1}}), \quad \hat{\mathbf{y}}_i = \text{De}(\mathbf{c}_{yi}; \theta_{\text{de2}}) \quad (10)$$

其中, θ_{de1} 和 θ_{de2} 分别表示两个解码器的参数. 损失函数可以表示为

$$\mathcal{L}_{\text{SSCA}} = \frac{1}{\text{BS}} \sum_{i=1}^{\text{BS}} \|\mathbf{x}_i - \hat{\mathbf{x}}_i\|^2 + \frac{\lambda_1}{\text{BS}} \sum_{i=1}^{\text{BS}} \|\mathbf{y}_i - \hat{\mathbf{y}}_i\|^2 \quad (11)$$

其中, λ_1 是表示空间特征权重的超参数, 该损失函数对应于式(4)的前两项. 上述公式中得到的低维输出需要融合才能输入到估计网络中进行密度估计:

$$\mathbf{c}_i = \mathbf{c}_{xi} + \alpha \mathbf{c}_{yi} \quad (12)$$

其中, α 表示空间特征对空谱特征融合贡献的超参数. 由于在高光谱数据中异常目标的像素数远少于背景, 对 AE 网络的优化贡献较小, 因此异常目标及其重构向量之间通常存在较大的谱重构误差, 将谱重构误差与特征融合可以扩大异常与背景的区别. 在此基础上, 本文从重构空间出发, 同时考虑光谱向量距离和光谱角距离, 将均方误差 (Mean Square Error, MSE) 和正交投影散度 (Orthogonal Projection Divergence, OPD)^[21] 作为谱重构误差:

$$\begin{cases} \mathbf{m}_{xi} = (\text{MSE}(\mathbf{x}_i, \hat{\mathbf{x}}_i), \text{OPD}(\mathbf{x}_i, \hat{\mathbf{x}}_i)) \in \mathbb{R}^{2 \times 1} \\ \mathbf{m}_{yi} = (\text{MSE}(\mathbf{y}_i, \hat{\mathbf{y}}_i), \text{OPD}(\mathbf{y}_i, \hat{\mathbf{y}}_i)) \in \mathbb{R}^{2 \times 1} \end{cases} \quad (13)$$

其中, $\text{MSE}(\cdot)$ 和 $\text{OPD}(\cdot)$ 的数学表达式分别为

$$\begin{cases} \text{MSE}(\mathbf{x}_i, \hat{\mathbf{x}}_i) = \frac{1}{\text{BS}} (\mathbf{x}_i - \hat{\mathbf{x}}_i)^\top (\mathbf{x}_i - \hat{\mathbf{x}}_i) \\ \text{OPD}(\mathbf{x}_i, \hat{\mathbf{x}}_i) = \mathbf{x}_i^\top \mathbf{P}_{\mathbf{x}_i}^\perp \mathbf{x}_i + \hat{\mathbf{x}}_i^\top \mathbf{P}_{\hat{\mathbf{x}}_i}^\perp \hat{\mathbf{x}}_i \\ \mathbf{P}_{\mathbf{x}_i}^\perp = \mathbf{I} - \mathbf{x} (\mathbf{x}^\top \mathbf{x})^{-1} \mathbf{x}^\top |_{\mathbf{x}=\mathbf{x}_i, \hat{\mathbf{x}}_i} \end{cases} \quad (14)$$

其中, \mathbf{I} 是大小为 $\text{BS} \times \text{BS}$ 的单位矩阵, \mathbf{m}_{yi} 中 $\text{MSE}(\cdot)$ 和 $\text{OPD}(\cdot)$ 的数学表达式与式(13)类似. MSE 计算光谱向量差的范数作为谱重构误差, 而 OPD 的思想源于正交子空间投影, 原本的目的是最大限度地分离目标和背景信息, 本文中将 OPD 作为光谱角重构误差, 可以提高 AE 的性能. 因为谱重构误差的维度与特征低维输出的维度不同, 本文使用堆叠融合方法, 即

$$\mathbf{z}_i = (\mathbf{c}_i, \mathbf{m}_{xi} + \mathbf{m}_{yi}) \in \mathbb{R}^{(H+2) \times 1} \quad (15)$$

得到的 \mathbf{z}_i 即为输入的光谱向量 \mathbf{x}_i 对应的空谱低维表示, 为后续估计网络的密度估计提供了多种语义信息, 可以使高斯混合模型更好地拟合背景分布.

2.3 密度估计

如上所述, GMM 具有较强的表征能力, 常被用于分类、检测任务, 可以有效拟合 HSI 复杂的背景分布. 此外, 将 HSI 的低维表示输入到估计网络 (Estimation Network, ENet) 中进行密度估计, 并进行端到端优化, 能够避免 EM 算法产生次优解的问题. 将 SSCA 的输出 $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_i, \dots, \mathbf{z}_{\text{BS}}] \in \mathbb{R}^{\text{BS} \times (H+2)}$ 输入到估计网络 $\text{Est}(\cdot)$ 中可以得到光谱向量 \mathbf{x}_i 属于 GMM 各个分量的概率:

$$\mathbf{r}_i = \text{Est}(\mathbf{z}_i; \theta_{\text{est}}) \in \mathbb{R}^{1 \times K} \quad (16)$$

其中, θ_{est} 是估计网络的参数, K 是 GMM 的混合分量数. $\text{Est}(\cdot)$ 是以 \tanh 函数作为激活函数的多层全连接网络, 最后一层的输出由 softmax 函数进行分类, 进一步进行估计得到 GMM 的数字特征. 对于给定的 BS 个光谱向量对应的低维表示, 第 $k(k=1, 2, \dots, K)$ 个高斯混合分量的数字特征为

$$\begin{cases} \phi_k = \frac{1}{\text{BS}} \sum_{i=1}^{\text{BS}} r_{ik} \\ \mu_k = \frac{\sum_{i=1}^{\text{BS}} r_{ik} z_i}{\sum_{i=1}^{\text{BS}} r_{ik}}, \\ \Sigma_k = \frac{\sum_{i=1}^{\text{BS}} r_{ik} (z_i - \mu_k)(z_i - \mu_k)^T}{\sum_{i=1}^{\text{BS}} r_{ik}} \end{cases} \quad (17)$$

根据估计的参数, 可以推导出光谱向量 \mathbf{x}_i 对应的概率密度:

$$p(z_i) = \sum_{k=1}^K \frac{\phi_k}{\sqrt{|2\pi\Sigma_k|}} e^{-\frac{(z_i - \mu_k)^T \Sigma_k^{-1} (z_i - \mu_k)}{2}} \quad (18)$$

其中, $|\cdot|$ 表示矩阵的行列式. 进一步, 可以求出相应的负对数似然值为

$$E_i = -\log(p(z_i)) \quad (19)$$

相比于背景, 异常出现的概率较小, 位于低概率密度区域, 因此负对数似然值 E_i 大的区域可以认为是异常, E_i 可以表示光谱向量 \mathbf{x}_i 的异常程度, 由所有像素点对应的 E_i 所组成的二维图像矩阵 $\mathbf{E} \in \mathbb{R}^{M \times N}$ 即为异常检测结果的灰度图.

2.4 端到端联合优化

如图 1 所示, 为了提高检测精度, 避免局部最优解, 本文在训练过程中对 SSCA 和 ENet 进行端到端联合优化, 使 SSCA 可以有效提取空间特征和光谱特征, 而融合得到的空谱低维表示可以促进估计网络在良好训练的情况下进行有效的密度估计. 对应于式 (4), E2E-SSCADE 的损失函数可以表示为

$$\begin{aligned} \mathcal{L}_{\text{E2E}} = & \frac{1}{\text{BS}} \sum_{i=1}^{\text{BS}} \|\mathbf{x}_i - \hat{\mathbf{x}}_i\|^2 + \frac{\lambda_1}{\text{BS}} \sum_{i=1}^{\text{BS}} \|\mathbf{y}_i - \hat{\mathbf{y}}_i\|^2 \\ & + \frac{\lambda_2}{\text{BS}} \sum_{i=1}^{\text{BS}} E_i + \frac{\lambda_3}{\text{BS}} \sum_{k=1}^K \sum_{j=1}^{H+2} \frac{1}{\Sigma_{kij}} \end{aligned} \quad (20)$$

其中, λ_2 和 λ_3 是网络的超参数, 分别设为 0.1 和 0.001. 损失函数包含四部分. 第一部分和第二部分是 SSCA 产生的重构误差, 第三部分表示输入样本的概率密度. 联合优化前三项可以建立 SSCA 和 ENet 的最优组合, 使背景和分离的可能性最大, 但是当协方差矩阵的对角线元素都为 0 时会得到平凡解. 因此损失函数第四

部分引入协方差矩阵对角线元素的倒数和, 可以避免平凡解的产生, 保持模型的稳定.

3 分布式训练

分布式训练旨在将大规模训练任务分配给多个节点协同处理以加快训练速度, 本文将其应用在处理大量或大型 HSI 数据, 实现了一个分布式 HAD 框架. 分布式训练的主要思想之一是并行, 按照并行方式分类主要有三种: 数据并行、模型并行和混合并行^[30]. 其中数据并行是将原始数据在训练前根据节点数进行切分, 将切分后的数据分别送入不同节点学习, 每个节点都有相同的网络模型, 因此可以独立的完成前向传播和反向传播的计算过程. 每个节点在完成反向传播后会尝试将自己的梯度信息发送给其他节点, 并从其他节点处接收不同输入数据计算得到的梯度信息, 这一过程也被称为梯度同步, 通常是通过 All-reduce 算法完成的. 对不同输入数据计算得到的梯度相加或求均值并进行优化可以在较短时间内达到在同一节点计算这些数据所达到的效果, 换言之, 在减少了训练数据的同时几乎不会对模型精度产生影响. 此外, 基于深度学习的 HAD 方法的模型通常较小, 而 HSI 由于其多波段的特性导致数据体积较大, 使用数据并行的方法更适合 HAD 任务, 图 3 为本文提出的分布式 HAD 框架原理图. 其基本思想为: 将输入的 HSI 数据 \mathbf{X} 进行空间特征提取得到 \mathbf{Y} , 将 \mathbf{X} 和 \mathbf{Y} 转化为二维图像并归一化, 随后分块输入到不同节点上的网络进行前向传播和反向传播, 得到的梯度矩阵将会通过 Ring All-reduce 算法进行同步, 各节点使用同步的梯度进行优化后便完成了一次迭代.

3.1 基于 Collective 架构的分布式训练

Collective 架构是一种去中心化的架构, 没有传统主从架构中的主节点, 每一个节点都是子节点 (Worker). 本文提出的分布式 HAD 架构使用 GPU 训练, 输入的高光谱数据首先经过空间特征提取、reshape 和归一化, 得到归一化的光谱向量矩阵和空间特征矩阵, 被送入分布式训练框架.

设置 N 个子节点 $\{W_1, W_2, \dots, W_n, \dots, W_N\}$, 在数据读取过程中, 输入数据 \mathbf{X} 和 \mathbf{Y} 被分发到各个子节点上, 子节点 W_n 的输入为 $\mathbf{X}_n \in \mathbb{R}^{\text{BS} \times B}$ 和 $\mathbf{Y}_n \in \mathbb{R}^{\text{BS} \times D}$.

在数据并行模式下, 每个子节点存储相同的模型及参数. 因此, 以 $\text{SSCADE}_f(\cdot)$ 和 $\text{SSCADE}_b(\cdot)$ 分别表示 E2E-SSCADE 的前向传播和反向传播, 节点 W_n 中的计算部分可以描述为

$$\mathcal{L}_{\text{E2E}}^n = \text{SSCADE}_f(\mathbf{X}_n, \mathbf{Y}_n; \theta_m) \quad (21)$$

$$\text{grad}^n = \text{SSCADE}_b(\mathcal{L}_{\text{E2E}}^n; A_m) \quad (22)$$

其中, θ_m 和 A_m 分别表示模型的全部参数和激活, $\mathcal{L}_{\text{E2E}}^n$ 和

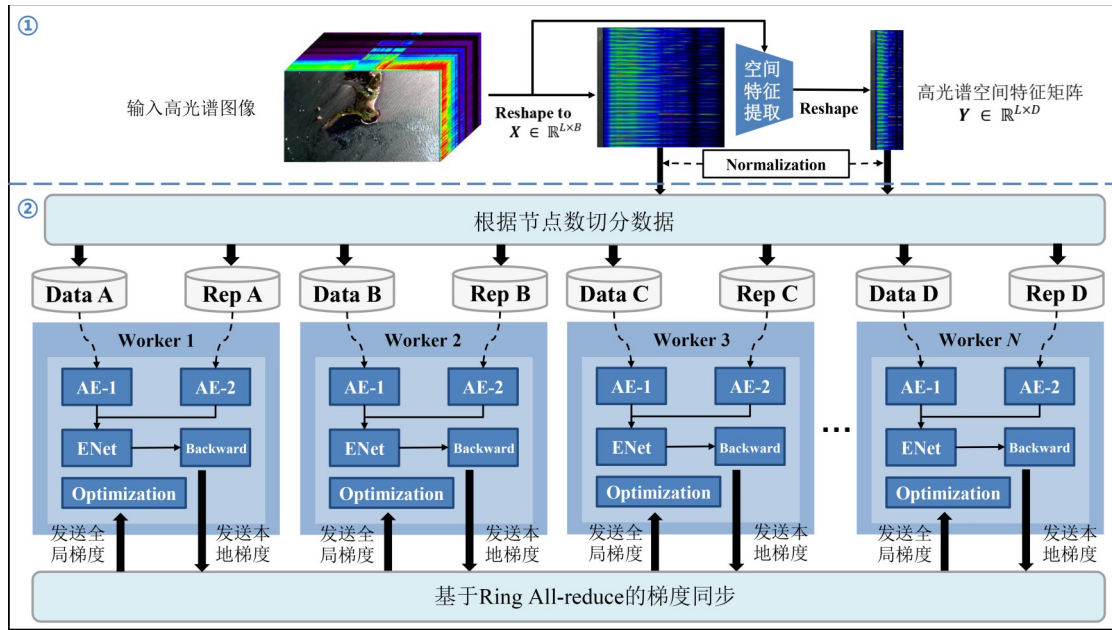


图3 基于分布式训练实现的E2E-SSCADE原理框图

grad^n 分别表示训练过程中节点 W_n 算得的损失和梯度. 每个节点的计算过程是相互独立的, 而节点之间的交互则集中在梯度同步过程.

3.2 基于 Ring All-reduce 的梯度同步

Collective 架构是一种同步训练架构, 各个节点之间的梯度交换是通过点对点通信完成的, 提高训练效率的瓶颈之一是梯度同步过程, 普通 All-reduce 算法如主从架构的 MapReduce 算法通常会在梯度同步过程中耗费大量时间, 特别是随着分布式网络的节点数增加时, 梯度同步所消耗的时间往往会成倍增加. 而 Ring All-reduce 算法对梯度同步过程进行了较好的优化, 大幅减少了因节点数增加而带来的时间成本.

Ring All-reduce 算法主要包括两个步骤, 即 Scatter-reduce 和 All-gather. 首先算法会建立一个环状的有向图, 且每个节点都有一个左邻和右邻, 节点只会向左邻发送数据并只从右邻接收数据. 如图4所示, 子节点 W_n 将本地的梯度矩阵 grad^n 分为 N 个块:

$$\text{grad}^n = [\text{grad}_{n,1}, \text{grad}_{n,2}, \dots, \text{grad}_{n,n}, \dots, \text{grad}_{n,N}] \quad (23)$$

Scatter-reduce 操作中会进行 $N-1$ 次迭代, 每次迭代时 W_n 会进行一次梯度块的传输, 不重复地向其左邻发送一个块, 并接收右邻发送的块, 接收的块将会与本节点对应位置的块相加. 需要注意的是, W_n 第一次迭代时向左邻发送块 $\text{grad}_{n,n}$, 并接收右邻发送的块. 第二次迭代时向左邻发送块 $\text{grad}_{n,(n-1)}$, 并接收右邻发送的块, 以此类推直至发送完块 $\text{grad}_{n,(n+2)}$. 其中, 若下一次发送的梯度块的索引值超出了 n 的取值范围, 则该索引值对 N 求模. 此时节点 W_n 上的块 $\text{grad}_{n,(n+1)}$ 为所有参与

训练节点对应位置块的和, 即

$$\text{grad}'_{n+1} = \sum_{n=1}^N \text{grad}_{i,(n+1)} \quad (24)$$

其中, grad'_{n+1} 包含了所有节点的第 $n+1$ 个梯度块的信息.

如图5所示, 在 All-gather 中, 节点 W_n 同样需要 $N-1$ 次迭代, 每次迭代 W_n 不重复地向左邻发送一个块, 接收右邻发送的块, 并使用接收的块代替本地对应位置的块. 需要注意的是, W_n 第一次迭代时向左邻发送 grad'_{n+1} , 并从右邻接收 grad'_n , 第二次迭代时发送 grad'_n , 以此类推直至发送完 grad'_{n+3} . 此时节点 W_n 上所有的块都包含了完整的梯度信息, 即

$$\text{grad}' = \{\text{grad}'_1, \text{grad}'_2, \dots, \text{grad}'_n, \dots, \text{grad}'_N\} \quad (25)$$

至此, 各节点已完成了梯度同步. 在完成梯度同步后, 各个节点读取新的数据并重复上述过程. 同时, 使用梯度累加操作, 算得的梯度会在本地累加, 直至所有的数据都被输入到模型. 随后, 各节点同时优化本地的模型参数, 由于梯度矩阵和优化器相同, 各节点优化后的模型参数也相同. 此后, 各节点将进行下一次训练迭代, 直至模型收敛. 通过梯度累加操作, 可以避免可能存在的边界效应, 同时可以减少分布式训练过程中的通信频率, 从而提高训练效率.

4 实验分析

为了验证本文所提出的 E2E-SSCADE 的有效性, 本文进行了以下实验.

4.1 数据集介绍

本文的实验使用了4个不同的数据集, 包括7个不

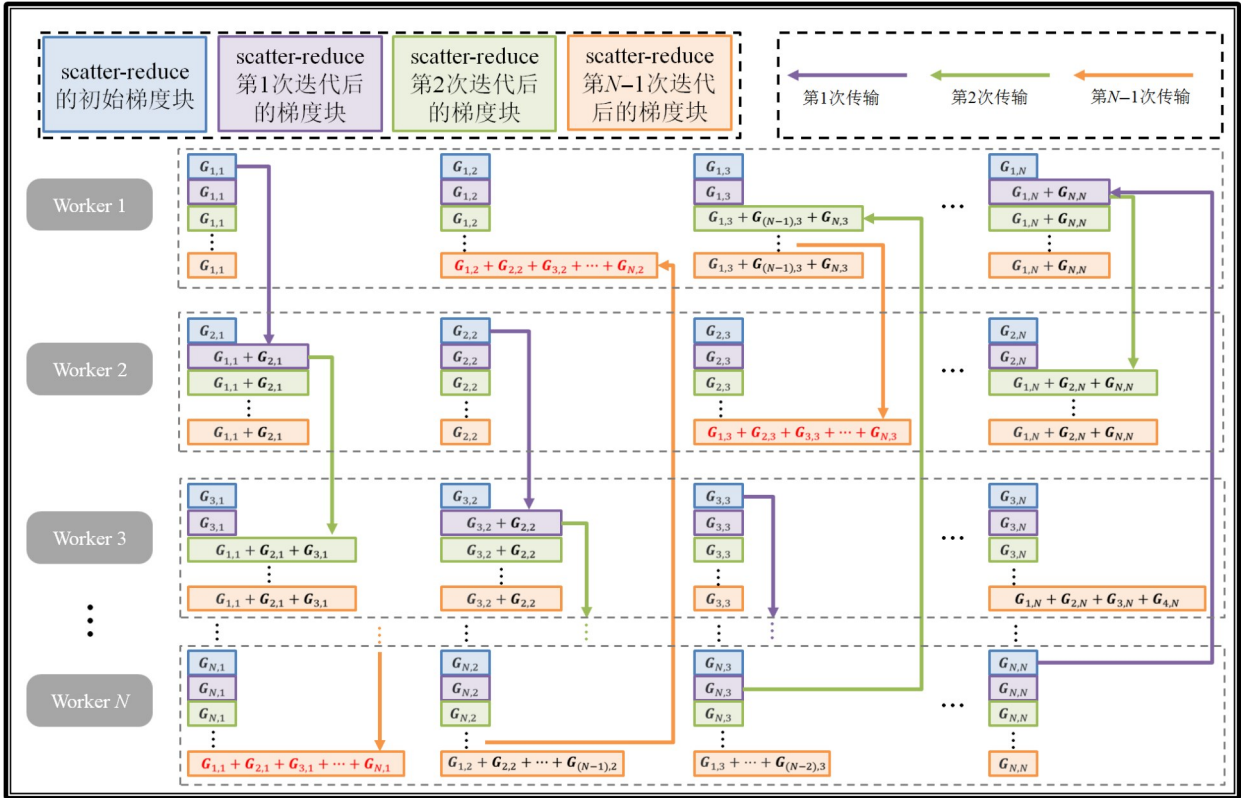


图4 Scatter-reduce 过程示意图(图中的 G_{ij} 对应文中的 $\text{grad}_{i,j}, i, j = 1, 2, \dots, N$)

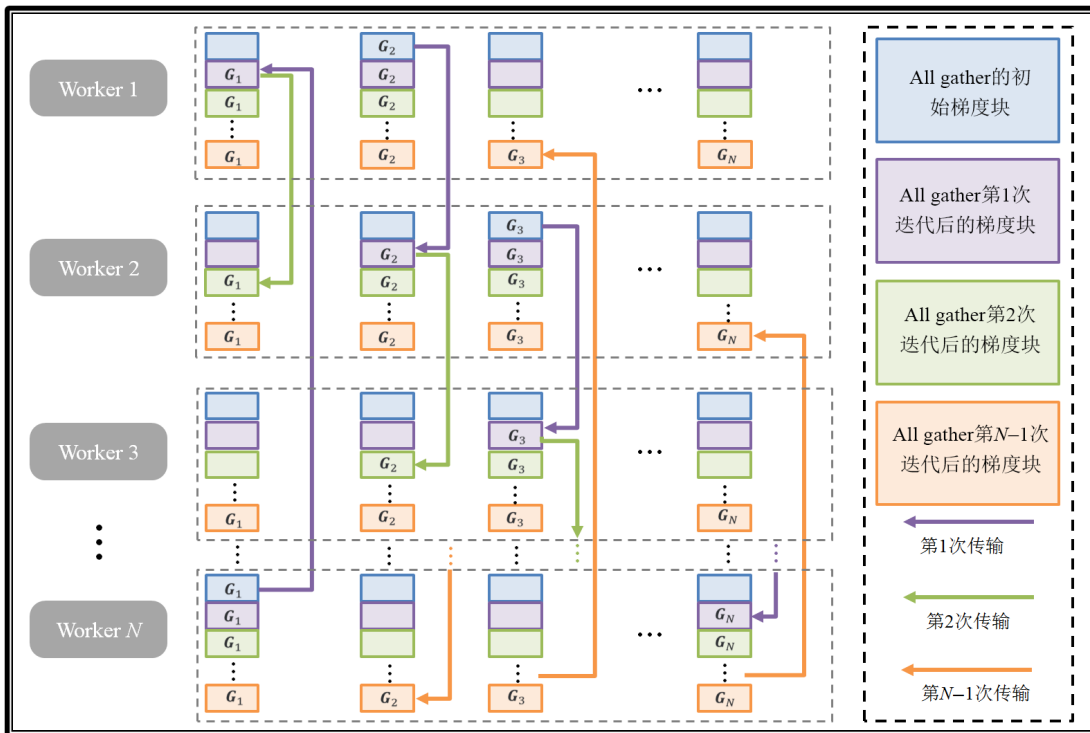


图5 All-gather 过程示意图(图中的 G_i 对应文中的 $\text{grad}_i, i = 1, 2, \dots, N$)

同场景采集的HSI,其中6组高光谱数据集来验证E2E-SSCADE的准确性和有效性,并单独使用了一组体积较

大的高光谱数据集来评估本文提出的模型的分布式实现的性能.

(1) San Diego数据集:该数据集由覆盖圣地亚哥地区的 Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)在机场场景采集,在高光谱研究中得到了广泛的应用.该数据集由两幅图像组成,本文使用 San Diego-1 数据,该数据共有 189 个光谱波段,覆盖了 370~2 510 nm 的波长,具有 100×100 个空间像素.在场景中,机库、停机坪和土壤构成主要背景,覆盖 134 个像素的 3 架飞机被视为异常^[31].数据的伪彩色图像和异常标签如图 6(a)所示.

(2) HYDICE 数据集:该数据集由 Hyperspectral Digital Imagery Collection Experiment (HYDICE)在美国城市地区采集.共有 100×80 个像素和 162 个光谱波段,光谱分辨率为 10 nm,空间分辨率为 1 m.数据主要包括植被、建筑物、道路和车辆,异常是由不同大小几个物体组成,覆盖 19 个像素.数据的伪彩色图像和异常标签如图 6(b)所示.

(3) Airport-Beach-Urban (ABU)数据集^[17]:ABU 数据集包括了 13 幅 100×100 像素、波段数不等的高光谱图像,除了 urban-4 数据集由 Reective Optics System Imaging Spectrometer (ROSIS-03)采集,其他都由 AVIRIS 采集.本文的实验选择其中的 beach-3, urban-1, urban-2 和 urban-4 作为实验的数据集,这四者的波段数分别为 188, 204, 207 和 205 个,异常区域覆盖 11, 67, 115 和 272

个像素,数据集的伪彩色图像和异常标签分别如图 6(c), 6(d), 6(e)和 6(f)所示.

(4) Grand Isle数据集:该数据集是由 AVIRIS 在美国洛杉矶杰斐逊教区的墨西哥湾沿岸的大岛采集的,共有 300×480 个像素和 224 个波段,覆盖了 366~2 496 nm 的波长,空间分辨率约为 4.4 m.场景中主要的背景是岛屿和水,选取水体中占 279 像素的人造物体作为异常目标.数据的伪彩色图像和异常标签如图 7 所示.

4.2 实验环境

4.2.1 对比方法

本文使用 RX, CRD, AED^[32], E2E-LIAD, AAE 作为对比方法,并根据文献[5, 8, 32, 21, 17]选择针对各个数据集的最佳参数.其中, RX 算法基于背景样本远大于异常样本且背景模型服从多元高斯分布的假设,计算待检测光谱和背景模型的马氏距离来作为判断异常目标的标准; CRD 算法基于协作表示检测异常目标; AED 方法通过属性滤波和布尔映射融合方法检测具有特定区域属性和不同光谱特征的像素,然后进行边缘保持滤波,得到异常检测结果; E2E-LIAD 算法基于神经网络和 GMM 得到初检结果,并在后续使用背景抑制; AAE 方法基于对抗自编码器进行特征提取,并依赖后处理进行异常目标的检测.

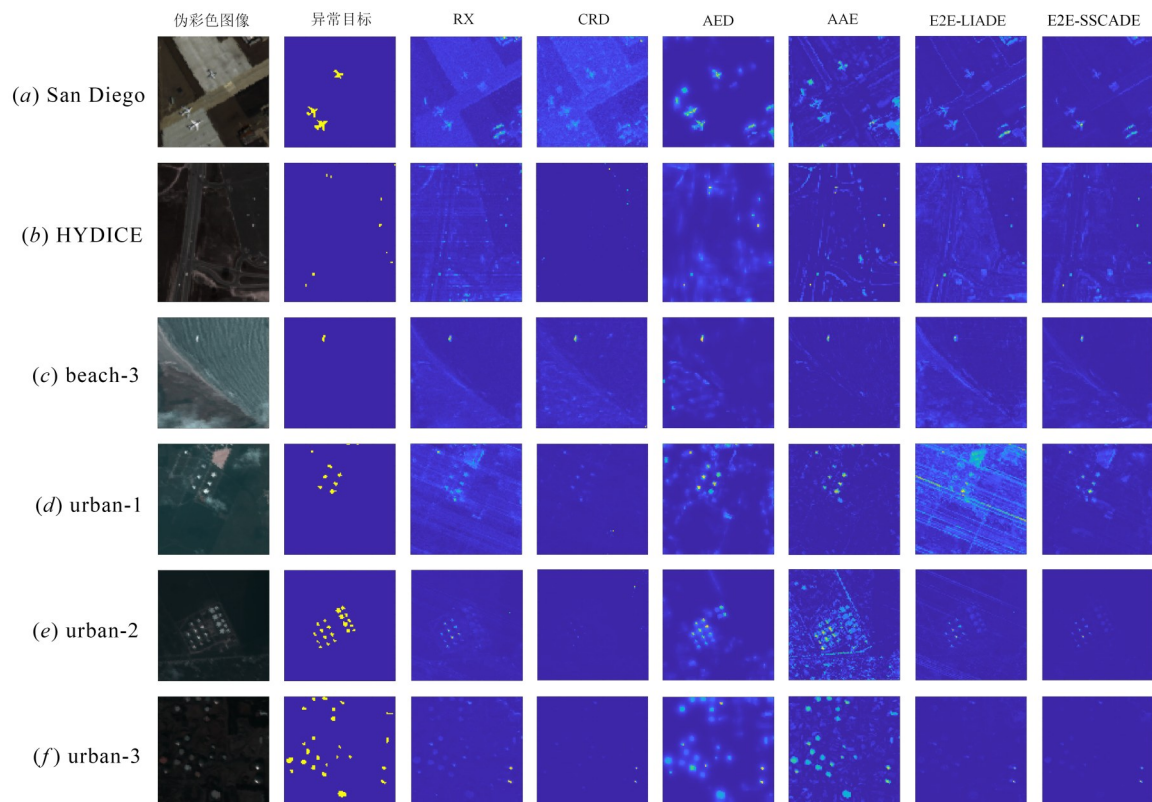


图6 不同数据集的伪彩色图像、异常目标,以及RX, CRD, AED, AAE, E2E-LIAD, E2E-SSCADE方法下的检测结果




图7 Grand Isle数据集检测结果

4.2.2 性能评估指标

在预测结果评估上,受试者工作特征曲线(Receiver Operating Characteristic, ROC)^[33]和ROC曲线下的面积(Area Under the ROC Curve, AUC)^[34]是常用的评估方法. ROC曲线作为HAD中广泛使用的评价标准,由三个参数生成:真阳性率(True Positive Rate, TPR)、假阳性率(False Positive Rate, FPR)和阈值(Threshold, τ). ROC曲线可以描述TPR和FPR之间的变换关系,曲线下的面积AUC,用于定量的评价检测性能, AUC(TPR, FPR)越大表示检测精度越高, AUC(FPR, τ)越小表示虚警率越低.

4.2.3 其他实验细节

本文提出的E2E-SSCADE由SSCA和ENet组成,其中,SSCA中AE的编码器和解码器以及估计网络都是两个全连接层和tanh激活函数组成的,用于谱间特征提取的AE的隐藏节点数为200, H , 200, 用于空间特征提取的AE的隐藏节点数为30, H , 30, 估计网络的隐藏节点数为60, K . 在训练过程中,使用Adaptive moment estimation(Adam)优化器对E2E-SSCADE进行端到端优化,学习率设置为 10^{-4} , batch size设置为10 000, 训练的迭代次数为20次. 本文的实验使用的深度学习框架为Paddlepaddle-gpu 2.2.0, 使用的硬件设备主要包括4块GeForce RTX 2080Ti显卡. 其中, batch size的设置是基于硬件设备的性能,但实验过程中考虑到了HSI的全局性而使用了梯度累加操作,因此实际的batch size是各数据集的像素数. 此外,根据文献[20]的描述,设置E2E-LIAD的batch size为5, 优化器为Stochastic Gradient Descent(SGD), 学习率为 10^{-4} , 迭代次数为1 000. 根据文献[17]的描述,设置AAE的batch size为10 000, 优化器为SGD, 学习率为 10^{-4} , 迭代次数为150. 实验代码见<https://github.com/majitao-xd/E2E-SSCADE.git>.

4.3 分布式训练性能分析

在本实验中, 本文的实验使用Grand Isle数据集评估本文提出的模型的分布式实现的性能, 并分别设置1, 2, 3和4个子节点. 同时, 为了保证模型的稳健性, 本文对每一组实验都执行了5次并将结果取平均值. 图8和表1分别以柱状图和表格的形式展示了本文提出的模型的分布式实现过程中的加速性能和成本. 从

表1中可以看出, 分布式训练在保证精度的前提下有效的加快了E2E-SSCADE的训练速度.

表1 分布式训练中不同数量节点加速性能

节点数/个	时间/s	加速比	AUC(TPR, FPR)
1	17.72	1.00	0.990 5
2	9.70	1.83	0.992 1
3	6.72	2.64	0.989 8
4	5.20	3.41	0.989 0




图8 分布式训练中不同数量节点加速性能比较柱状图

4.4 参数分析

这一小节具体分析参数的变化对性能的影响. H 是光谱向量和空间特征的低维表示的通道数, K 是GMM的混合分量数, α 是表示空间特征对空谱融合贡献的超参数, λ_1 是表示空间特征对模型训练贡献的超参数, λ_2 和 λ_3 是网络的超参数, 分别表示式(20)中对应项对模型训练的贡献, batch size、学习率和epochs分别为分布式训练过程的数据批大小、优化器学习率和迭代次数. 在本实验中, 当对某一参数进行分析时, 将其他参数固定为相应的最优值, 其中 $H=9$, $K=5$, $\alpha=0.1$, $\lambda_1=0.1$, $\lambda_2=0.1$, $\lambda_3=0.001$, batch size为 $M \times N$, 学习率为 10^{-4} , epochs为20. 实验结果如图9所示, 横轴表示对应参数的值, 纵轴为AUC(TPR, FPR).

(1) 如图9(a)所示, H 的取值为从6到12的自然数(包括6和12). 在 H 的取值过小时, 网络提取出的HSI低维表示可能会丢失部分重要信息和类间差异, 而在 H

的取值过大时,网络可能无法抑制 HSI 中的冗余信息和噪声,从而降低检测性能. 当 H 的取值为 9 时,网络可以提取出较好的低维表示.

(2) 如图 9(b)所示, K 的取值为从 3 到 7 的自然数(包括 3 和 7). 对于背景和异常复杂程度不同的 HSI, K 的取值会影响估计网络分离异常和背景的性能. K 的取值过小可能会导致部分异常目标混合在背景中,难以分离,而 K 的取值过大则可能会导致异常目标的过拟合,难以通过最大似然估计分离出来. 当 K 的取值为 5 时,可以较好地拟合 HSI 的背景分布.

(3) 分别如图 9(c)和 9(d)所示, α 和 λ_1 的取值为 0.01, 0.1, 1. 若 α 和 λ_1 的取值过小,则模型无法提取到包含 HSI 空间特征的低维表示,若 α 和 λ_1 的取值过大,空间上下文中的噪声将会影响到模型的密度估计,无法较好地抑制背景.

(4) 分别如图 9(e)和 9(f)所示, λ_2 的取值为 0.01, 0.1, 1 和 10, λ_3 的取值为 0.000 1, 0.001, 0.01 和 0.1. 合适的 λ_2 能保证估计网络收敛到理想状态,从而更好地估计数据的分布. 同时,合适的 λ_3 可以保持模型的稳定.

(5) 分别如图 9(g)、图 9(h)和图 9(i)所示,由于数据集的大小不同, batch size 的取值最大为数据集的像素数,因此分析 batch size 的取值设为总像素数和其 1/2、1/4 和 1/8 时的性能,图中可以看出,由于 HSI 的全局属性, batch size 等于 HSI 总像素数时,综合结果更好,此外,较大的 batch size 也能增加计算设备的利用率. 学习率较大时,网络难以收敛到最优值,学习率较小时,网络收敛速度慢,这些都会导致检测精度降低. Epochs 较大会增加计算时间,且带来的精度增益相对较小, epochs 较小时网络则难以收敛到最优值附近.

4.5 消融实验

为了验证每个所提出的模块对检测性能的影响,本文的实验测试了不同模块的检测性能. 第一次消融实验使用 AE 和 GMM,并通过 EM 算法优化 GMM. 第二次使用 AE 和估计网络联合优化的方法. 第三次使用本文所提出的 E2E-SSCADE. 通过这三次实验验证端到端优化和空谱协同所带来的检测性能上的增益.

表 2 和图 10 是三次消融实验的结果,展示了三个

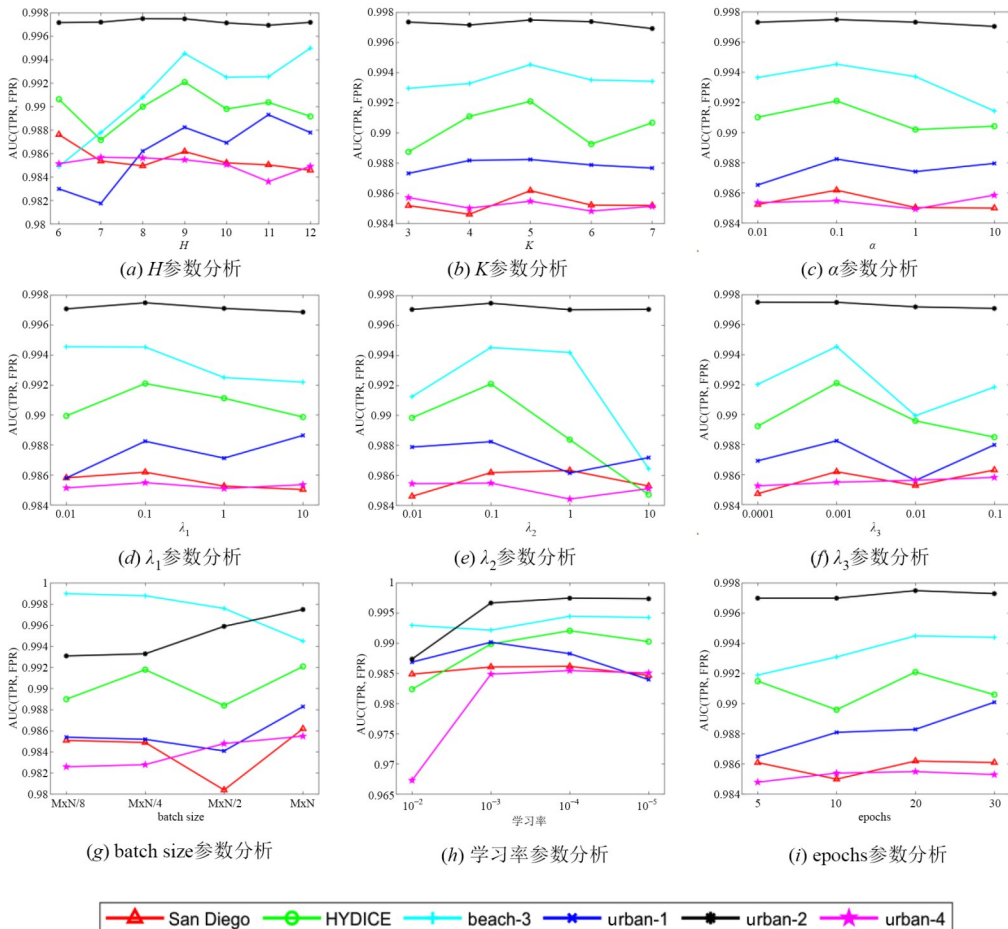


图 9 不同数据集的参数敏感性分析

实验的 AUC(TPR, FPR)、AUC(FPR, τ) 和计算时间,其中计算时间的单位为 s,同时,为了保证实验的公平性,在该部分实验中只使用四张显卡中的同一张. 表 2 中加粗的数据是最优结果. 分析表 2 中数据,在只使用 AE 和 GMM,并通过 EM 算法优化 GMM 的情况下,无法联合进行优化,在特征提取过程中可能会丢失检测异常目标的关键信息,因此得到次优解. 与 AE+GMM_EM 法相比,AE+ENet 通过联合优化,在特征提取过程中保留了检测异常目标的关键信息,同时避免了 EM 算法有可能产生次优解的问题,提高了 HAD 的检测性能. 相比于 AE+ENet 方法,E2E-SSCADE 因为考虑到了空间特征和光谱特征,在提高了检测性能的同时减小了虚警率. 如表 2 所示,E2E-SSCADE 方法小幅度增加了计算量,但检测性能的提升相对更明显.

表 2 消融实验结果

检测方法	AUC(TPR,FPR)	AUC(FPR, τ)	时间/s
AE+GMM_EM	0.961 6	0.048 1	56.35
AE+ENet	0.984 9	0.013 1	17.01
E2E-SSCADE	0.986 2	0.012 5	17.72

4.6 检测性能

各个数据集对应不同HAD方法的检测结果的灰度图如图 6 所示,检测结果的 AUC(TPR, FPR) 和 AUC(FPR, τ) 数值如表 3 和表 4 所示,加粗表示最优结果. ROC 曲线如图 11 所示.

如图 6(a) 所示,对于 San Diego 数据集,本文所提出的方法可以较好地检测出跑道上的飞机,且背景不明显,虚警率较低. RX, CRD, AED 和 AAE 虽然检测出了异常目标的位置,但没有很好地保持原有的飞机的形

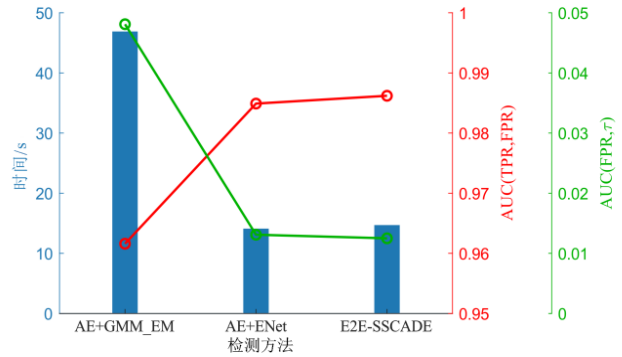


图 10 消融实验结果图

状,且虚警率较高. E2E-LIAD 则误将部分背景的边缘检测为异常目标,导致虚警率相对较高. 表 3 和表 4 表明,本文所提方法的检测结果优于其他方法.

如图 6(b) 所示,对于 HYDICE 数据集,CRD 和 AAE 能在虚警率较低的情况下检测出异常目标,但没有保留目标的边缘细节. RX, AED 和 E2E-LIAD 没有很好地抑制背景. 本文提出的方法则很好地检测出了异常目标.

如图 6(c) 所示,对于 beach-3 数据集, E2E-LIAD 没有很好地检测出异常目标的边缘细节. RX 和 CRD 较好地检测出了异常目标,但背景抑制效果较差,导致虚警率较高. AED, AAE 和本文的方法则在虚警率较低的情况下较好地检测出了异常目标.

如图 6(d) 所示,对于 urban-1 数据集, E2E-LIAD 没有很好地检测出异常目标,且虚警率较高. 其他方法和本文方法则较好地检测出了异常目标.

如图 6(e) 所示,对于 urban-2 数据集,本文方法在虚

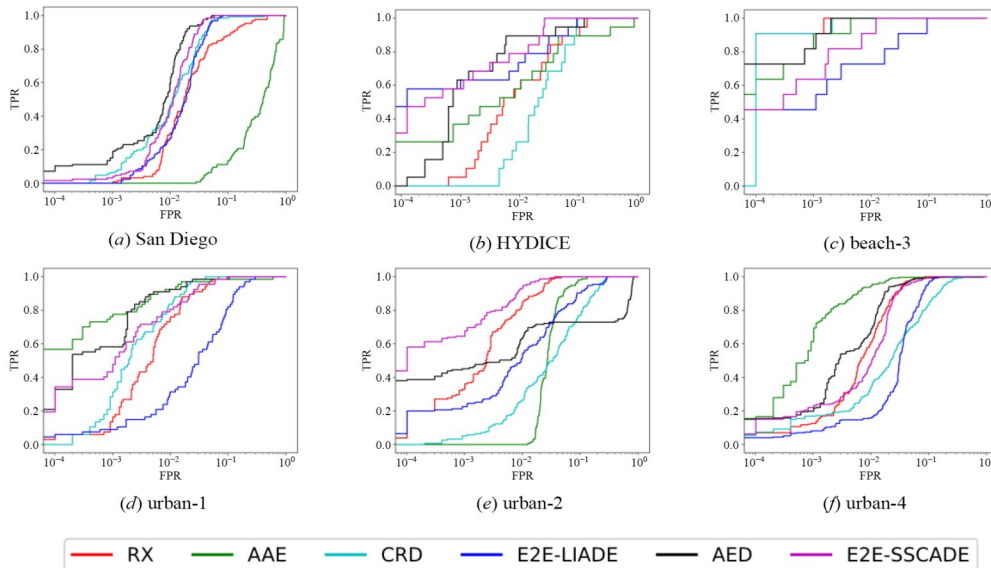


图 11 不同检测方法下的 ROC 曲线

警率较低的情况下较好地检查出了异常目标,并保留了目标的边缘细节. RX, AED, AAE 和 E2E-LIAED 较好地检测出了异常目标,但有较多的背景干扰. CRD 虽然抑制了复杂的背景,但没有很好地保持目标的细节,且有部分目标和背景混淆.

如图 6(f) 所示,对于 urban-4 数据集, RX, AED 和 AAE 较好地检测出了异常目标,但背景明显,虚警率较

高. CRD 和 E2E-LIAED 虽然抑制了背景干扰,但没有保持目标的边缘细节,导致目标和背景混淆,准确率较低. 本文的方法则在保持了较低虚警率的情况下,较好地检测出了异常目标.

图 6、图 11、表 3 和表 4 表明,综合情况下,本文所提方法的检测性能优于其他对比方法,能较好地分离 HSI 的背景和异常目标.

表 3 实验数据集在不同检测算法上的 AUC(TPR, FPR)

数据集	RX	CRD	AED	AAE	E2E-LIAED	E2E-SSCADE
San Diego	0.953 9	0.980 3	0.984 6	0.563 3	0.979 2	0.986 2
HYDICE	0.976 3	0.966 9	0.989 9	0.921 8	0.986 8	0.986 8
beach-3	0.999 8	0.999 7	0.999 7	0.999 4	0.986 8	0.994 5
urban-1	0.990 7	0.994 7	0.996 3	0.989 0	0.945 7	0.988 3
urban-2	0.994 6	0.938 5	0.807 0	0.968 1	0.965 1	0.997 5
urban-4	0.988 7	0.950 7	0.991 3	0.994 9	0.962 7	0.985 5
平均	0.984 0	0.971 8	0.961 5	0.906 1	0.971 0	0.990 7

表 4 实验数据集在不同检测算法上的 AUC(FPR, τ)

数据集	RX	CRD	AED	AAE	E2E-LIAED	E2E-SSCADE
San Diego	0.058 9	0.099 1	0.014 3	0.031 6	0.018 0	0.012 5
HYDICE	0.038 0	0.002 0	0.030 9	0.010 0	0.030 2	0.028 3
beach-3	0.025 9	0.028 9	0.012 7	0.006 1	0.028 4	0.017 2
urban-1	0.055 5	0.008 6	0.024 7	0.009 6	0.133 7	0.023 1
urban-2	0.013 5	0.003 1	0.014 5	0.042 5	0.012 6	0.002 0
urban-4	0.011 4	0.001 1	0.030 4	0.020 5	0.004 5	0.001 4
平均	0.033 7	0.023 8	0.021 3	0.020 1	0.037 9	0.014 1

5 结束语

本文主要提出了基于分布式训练实现的 E2E-SSCADE 用于无监督 HAD, 该模型主要是将 HSI 的光谱输入和空间特征输入融合为一个低维表示, 输入到 ENet 中进行密度估计, 以端到端的方式对整个模型进行优化, 得到和 HSI 输入一一对应的异常检测结果. E2E-SSCADE 主要由几个部分组成: SSCA 将光谱向量和二维卷积得到的空间上下文特征深度融合, 提取出包含光谱和空间信息的 HSI 低维表示; 然后, 利用 ENet 在 SSCA 上估计样本分布, 生成高光谱数据对应的异常程度, 以端到端优化的方式训练 SSCA 和 ENet 以得到最佳参数. 在多个数据集上进行的实验表明, 训练良好的 E2E-SSCADE 在 HAD 任务上表现出了较好的性能. 分布式训练则解决了大型 HSI 难以处理的问题. 并根据 HSI 的全局属性和分布式训练的通信瓶颈对分布式 HAD 进行了优化, 而使用大体积 HSI 进行的实验则验证了分布式训练在 HAD 任务上的可行性和性能.

参考文献

- [1] GHAMISI P, YOKOYA N, LI J, et al. Advances in hyperspectral image and signal processing: A comprehensive overview of the state of the art[J]. IEEE Geoscience and Remote Sensing Magazine, 2017, 5(4): 37-78.
- [2] LI S T, SONG W W, FANG L Y, et al. Deep learning for hyperspectral image classification: An overview[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(9): 6690-6709.
- [3] GONG Z Q, ZHONG P, HU W D. Statistical loss and analysis for deep learning in hyperspectral image classification [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(1): 322-333.
- [4] JIA S, JIANG S G, LIN Z J, et al. A survey: Deep learning for hyperspectral image classification with few labeled samples[J]. Neurocomputing, 2021, 448: 179-204.
- [5] 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.
- [6] MATTEOLI S, VERACINI T, DIANI M, et al. A locally adaptive background density estimator: An evolution for RX-based anomaly detectors[J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(1): 323-327.
- [7] CARLOTTO M J. A cluster-based approach for detecting man-made objects and changes in imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(2): 374-387.
- [8] LI W, DU Q. Collaborative representation for hyperspectral anomaly detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(3): 1463-1474.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] LI W, WU G D, DU Q. Transferred deep learning for anomaly detection in hyperspectral imagery[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(5): 597-601.
- [13] ZHANG L L, CHENG B Z. A stacked autoencoders-based adaptive subspace model for hyperspectral anomaly detection[J]. Infrared Physics & Technology, 2019, 96: 52-60.
- [14] JIANG T, LI Y S, XIE W Y, et al. Discriminative reconstruction constrained generative adversarial network for hyperspectral anomaly detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(7): 4666-4679.
- [15] CHALAPATHY R, CHAWLA S. Deep learning for anomaly detection: A survey[EB/OL]. (2019-01-10) [2022-05]. <https://arxiv.org/abs/1901.03407>.
- [16] SONG S Z, ZHOU H X, YANG Y X, et al. Hyperspectral anomaly detection via convolutional neural network and low rank with density-based clustering[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(9): 3637-3649.
- [17] XIE W Y, LEI J, LIU B Z, et al. Spectral constraint adversarial autoencoders approach to feature representation in hyperspectral anomaly detection[J]. Neural Networks, 2019, 119: 222-234.
- [18] MAKHZANI A, SHLENS J, JAITLY N, et al. Adversarial autoencoders[EB/OL]. (2015-11-18) [2022-02]. <https://arxiv.org/abs/1511.05644>.
- [19] XIE W Y, LIU B Z, LI Y S, et al. Spectral adversarial feature learning for anomaly detection in hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(4): 2352-2365.
- [20] ZONG B, QI S, MIN M R, et al. Deep autoencoding Gaussian mixture model for unsupervised anomaly detection[C]//6th International Conference on Learning Representations. Vancouver: ICLR, 2018: 1-19.
- [21] JIANG K, XIE W Y, LEI J, et al. E2E-LIADE: End-to-end local invariant autoencoding density estimation model for anomaly target detection in hyperspectral image[J]. IEEE Transactions on Cybernetics, 2022, 52(11): 11385-11396.
- [22] HAUT J M, GALLARDO J A, PAOLETTI M E, et al. Cloud deep networks for hyperspectral image analysis[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(12): 9832-9848.
- [23] SEDONA R, CAVALLARO G, RIEDEL M, et al. Enhancing large batch size training of deep models for remote sensing applications[C]//2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS. Brussels: IEEE, 2021: 1583-1586.
- [24] HAUT J M, PAOLETTI M E, MORENO-ÁLVAREZ S, et al. Distributed deep learning for remote sensing data interpretation[J]. Proceedings of the IEEE, 2021, 109(8): 1320-1349.
- [25] HAUT J M, PAOLETTI M E. Cloud implementation of multinomial logistic regression for UAV hyperspectral images[J]. IEEE Journal on Miniaturization for Air and Space Systems, 2020, 1(3): 163-171.
- [26] ZHANG B, CHEN Z C, PENG D L, et al. Remotely sensed big data: Evolution in model development for information extraction [point of view] [J]. Proceedings of the IEEE, 2019, 107(12): 2294-2301.
- [27] WANG L Z, YAN J N, MA Y. Cloud Computing in Remote Sensing[M]. Boca Raton: CRC Press, 2019.

- [28] MA L, LIU Y, ZHANG X L, et al. Deep learning in remote sensing applications: A meta-analysis and review [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 152: 166-177.
- [29] 叶珍, 白璘, 何明一. 高光谱图像空谱特征提取综述[J]. 中国图象图形学报, 2021, 26(8): 1737-1763.
YE Z, BAI L, HE M Y. Review of spatial-spectral feature extraction for hyperspectral image[J]. Journal of Image and Graphics, 2021, 26(8): 1737-1763. (in Chinese)
- [30] LI Y J, PARK J, ALIAN M, et al. A network-centric hardware/algorithm co-design to accelerate distributed training of deep neural networks[C]//2018 51st Annual IEEE/ACM International Symposium on Microarchitecture (MICRO). Fukuoka: IEEE, 2018: 175-188.
- [31] 谢卫莹, 马纪涛, 蒋恺, 等. 基于空谱深度协同的高光谱异常检测方法: CN114445720A[P]. 2022-05-06.
- [32] 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.
- [33] SWETS J A, DAWES R M, MONAHAN J. Better decisions through science[J]. Scientific American, 2000, 283(4): 82-87.
- [34] BRADLEY P. The use of the area under the ROC curve in the evaluation of machine learning algorithms[J]. Pattern Recognition, 1997, 30(7): 1145-1159.

作者简介



马纪涛 男, 1999 年出生, 河北邢台人. 2021 年本科毕业于西安电子科技大学通信工程专业. 现为西安电子科技大学信息与通信工程专业硕博连读生. 主要研究方向为高光谱遥感图像异常检测及分布式深度学习.
E-mail: 21011210271@stu.xidian.edu.cn



谢卫莹(通讯作者) 女, 1988 年出生, 甘肃白银人. 现为西安电子科技大学副教授、博导. 主要研究方向为高光谱遥感图像处理、分布式智能解译以及轻量化实现. 中国电子学会会员
编号: E190022673M.
E-mail: wyxie@xidian.edu.cn