

深度展开网络的高光谱异常探测

李晨玉^{1,2}, 洪丹枫^{1,3}, 张兵^{1,2,4}

1. 中国科学院空天信息创新研究院, 北京 100094;

2. 东南大学 数学学院, 南京 210089;

3. 中国科学院大学 电子电气与通信工程学院, 北京 100049;

4. 中国科学院大学 资源与环境学院, 北京 100049

摘要: 在现有基于物理模型的高光谱异常探测HAD (Hyperspectral Anomaly Detection) 方法中, 低秩表示LRR (Low-Rank Representation) 模型以其强大的背景和目标特征分离能力而受到广泛的关注和采用。然而, 由于依赖手动参数的选择以及较差的泛化性, 导致其实际应用受到限制。为此, 本文将LRR模型与深度学习技术相结合, 提出了一种新的适用于HAD的基础深度展开网络, 称为LRR-Net。该方法借助交替方向乘法ADMM (Alternating Direction Method of Multipliers) 优化器高效地求解LRR模型, 并将其求解步骤耦合至深度网络中以指导其搜索过程, 为深度网络提供了一定的理论基础, 具有较强的可解释性。此外, LRR-Net以端到端的方式将一系列正则化的参数转换为可学习的网络参数, 从而避免了手动调参。4组不同的高光谱异常探测实验证明了LRR-Net的有效性, 与其他无监督的异常探测方法相比, LRR-Net具有较强的泛化性和鲁棒性, 能够提高HAD的精度。

关键词: 高光谱遥感影像, 异常探测, 深度展开, 低秩表示 (LRR), 交替方向乘法 (ADMM)

中图分类号: P2

引用格式: 李晨玉, 洪丹枫, 张兵. 2024. 深度展开网络的高光谱异常探测. 遥感学报, 28(1): 69-77

Li C Y, Hong D F and Zhang B. 2024. Deep unfolding network for hyperspectral anomaly detection. National Remote Sensing Bulletin, 28(1): 69-77 [DOI: 10.11834/jrs.20233075]

1 引言

相比传统的遥感影像, 高光谱遥感影像可以获取更广泛范围内物体表面的反射光谱信息 (Vane and Goetz, 1988), 具有较高的光谱分辨率。丰富的光谱信息有助于提升不同地物间的区分度, 可以提供更加详细、精准的目标信息 (童庆禧等, 2016), 这使得高光谱遥感影像在军事和民用领域中被越来越广泛使用, 例如在环境监测 (Hong等, 2023)、资源勘察 (张兵, 2016)、城市规划 (张兵, 2018) 等方面都有重要的作用。基于异常像素与周围背景像素往往具有不同的光谱反射率这一理论基础, HAD可以被看作是在没有任何先验信息的情况下, 通过特定的光谱或特征从观测数据中分离出背景和异常目标 (张炎等, 2019; Manolakis和Shaw, 2002)。近年来, 在研究人员不

断的努力下, 相继提出了大量基于高光谱影像异常探测的算法。根据驱动方法的不同, HAD技术可以分为两大类: 基于模型和基于深度学习。

在HAD方法研究的早期阶段, 大多算法基于模型被广泛使用 (Molero等, 2013; Chang等, 2022), 根据理论体系的不同, 这类方法通常被划分为以下4类: 第一类是基于概率统计的方法, 较为经典的是1990年提出的Reed-xiaoli (RX) (Reed和Yu, 1990) 算法, 它假设背景像素遵循高斯多元分布, 并利用目标像素与背景像素之间的马氏距离的平方值来估计背景协方差矩阵来识别异常。然而, 在实际应用中, 土地覆盖分布通常是较为复杂的, 而必须要服从分布假设的基于统计探测方法往往并不适用 (Huyan等, 2019), 为克服先验假设的问题, 第二类基于表示的算法相继被提出, 如鲁棒性分析RPCA (Robust Principal Component

收稿日期: 2023-03-15; 预印本: 2023-12-01

基金项目: 国家自然科学基金(编号:42241109, 42271350)

第一作者简介: 李晨玉, 研究方向为遥感大数据。E-mail: lichenyu@seu.edu.cn

通信作者简介: 洪丹枫, 研究方向人工智能, 多模态遥感大数据。E-mail: hongdf@aircas.ac.cn

Analysis) (Chen 等, 2013), 低秩稀疏表示 LRASR (Low-Rank and Sparse Representation) (Xu 等, 2016)。由于背景像素之间具有很强的相关性, 具有一定的低秩性, 而异常目标往往具有一定的稀疏性, 这意味着观测数据可以通过 LRR 很好地分解为背景部分和异常部分 (Liu 等, 2013)。为了挖掘更多可利用的特征信息, 基于空间-光谱信息的特征重构算法和基于距离计算的异常探测算法相继被提出, 如基于协作表示的探测器 CRD (Collaborative-Representation-Based Detector) (Li 和 Du, 2015; 朱德辉 等, 2020)。然而, 随着复杂性的增加, 传统模型遇到了泛化性问题, 大量手工调参的整个过程阻碍了模型探测性能的进一步提高。

另一方面, 一些基于深度学习的方法通过影像重建的角度来解决 HAD 问题, 例如自编码器 AE (AutoEncoder) (Wang 等, 2022)、卷积神经网络 CNN (Convolutional Neural Networks) (Wu 等, 2023)、生成对抗网络 GAN (Global Area Network) (Jiang 等, 2020) 等。与迭代优化算法相比, 深度神经网络通过反向传播对其参数进行训练, 可以自适应获取参数。然而, 由于深度网络模型的黑盒特性, 缺乏一定的可解释性和理论保证, 因此, 这种完全基于数据驱动的端到端的训练方式可能会产生一些不可控的结果 (Shen 等, 2022)。

近年来, 深度展开技术因为被视为模型驱动和数据驱动技术的结合, 能够继承这两种技术的优点, 因此已成为可解释性网络设计的一个有潜力的解决方案, 并在高光光谱图像的解混 (Xiong 等, 2022a)、去噪 (Xiong 等, 2022b)、融合 (Xie 等, 2019) 以及计算成像 (Xu 等, 2016) 领域得到了广泛应用。深度展开网络是通过迭代求解器将目标任务映射到优化问题中, 将迭代求解器的每一步都转化为相对应的网络操作, 每个变量由多个网络操作构建的网络模块计算得到, 最终, 再将这些网络模块连接在一起, 形成整个网络。文献 (Yang 等, 2020) 表明, 由迭代算法展开的网络比原始迭代算法具有更好的性能。

鉴于以上, 本文为 HAD 任务创新性的提出了一种基于深度展开的基础网络, 命名为 LRR-Net。该方法将 LRR 模型的 ADMM 求解步骤展开成一系列的网络模块, 以端到端方式实现了传统模块和网络运算符之间的精确逐步对应, 显示表达 HAD 的迭代过程。此外, LRR-Net 将正则化参数转换

为一系列可学习参数, 从而降低了模型对手动参数选择的极度依赖性, 并通过严格的闭式解更新待优化变量, 提高了网络的泛化能力。

2 基于深度展开的异常探测网络

针对传统模型的数百次迭与大量人工手动调参过程, 以及深度学习的黑盒操作带来的不稳定问题, 本文结合模型驱动与数据驱动的优势, 对 LRR 模型的 ADMM 求解过程进行深度展开, 将模型作为先验知识引导深度网络的求解方向。

2.1 模型建立及优化求解

假定 $X = [x_1, \dots, x_i, \dots, x_N] \in \mathbb{R}^{L \times N}$ 是一幅具有 $N=H \times W$ 个像元数、 L 个光谱波段的高光谱影像, 其中, $x_i (i = 1, \dots, i, \dots, N)$ 表示输入数据空间的第 i 个 L 维的光谱向量。根据 LRR 模型理论, 被观测影像 X 可以被表示为

$$X = DA + S \quad (1)$$

式中, $D = [D_1, \dots, D_i, \dots, D_{2k}] \in \mathbb{R}^{L \times 2k}$ 表示字典, 由 K-means 计算得到。 $A = [D_1, \dots, D_i, \dots, D_L] \in \mathbb{R}^{2k \times L}$ 和 $S = [S_1, \dots, S_i, \dots, S_L] \in \mathbb{R}^{L \times n}$ 分别表示背景和异常像素。

为保证背景的低秩性与异常目标的稀疏性, 通常对影像使用核范数和 $l_{2,1}$ 范数进行约束。对于包含两组可分离自变量, 且存在线性等式约束的优化问题, 首先对目标函数进行增广, 将原始优化问题转化为

$$\min_{A,S} \frac{1}{2} \|X - DA - S\|_F^2 + \|A\|_* + \lambda \|S\|_{2,1} \quad (2)$$

式中, $\|A\|_*$ 代表权重矩阵的核范数 $A \in \mathbb{R}^{2k \times N}$,

$$\|S\|_{2,1} = \sum_{i=1}^L \sqrt{\sum_{j=1}^N (S_{i,j})^2} \text{ 表示 } l_{2,1} \text{ 约束下的异常矩阵 } S。$$

此外, $\lambda \geq 0$ 为正则化参数来控制背景像素的低秩属性。

通过引入一个辅助变量 J 来代替 A , 即 $A=J$, 使等式 (2) 可分离, 其增广拉格朗日函数为

$$\begin{aligned} \mathcal{L}_v(J, S, A, d) = & \frac{1}{2} \|X - DA^k - S^k\|_F^2 + \|J\|_* + \\ & \lambda \|S\|_{2,1} + \frac{\mu}{2} \|A^k - J^k - d^k\|_F^2 + l_r^*(J) \end{aligned} \quad (3)$$

依据 ADMM 求解器更新未知参数 (Boyd 等, 2011; Lin 等, 2011; Yang 等, 2017), 等式的增广拉格朗日函数 (3) 在第 $(k+1)$ 迭代中可分为以下子问题:

$$S^{k+1} = \operatorname{argmin}_S \lambda \|S\|_{2,1} + \frac{1}{2} \|X - DA^k - S^k\|_F^2 \quad (4)$$

$$J^{k+1} = \operatorname{argmin}_J \|J\|_* + \frac{\mu}{2} \|A^k - J^k - d^k\|_F^2 \quad (5)$$

$$A^{k+1} = \operatorname{argmin}_A \frac{1}{2} \|X - DA^k - S^k\|_F^2 + \frac{\mu}{2} \|A^k - J^k - d^k\|_F^2 \quad (6)$$

$$d^{k+1} \leftarrow d^k - \mu(A^k - J^k) \quad (7)$$

式中, d 为拉格朗日乘子, $\mu > 0$ 为惩罚参数, $\|\cdot\|_F$ 为 Frobenius 范数。

2.2 深度展开网络

LRR-Net 网络的每次更新都由四个模块组成, 分别对应式 (2) 的子变量求解过程, 如图 1 所示, 显示了每个模块的具体输入和输出变量。




图 1 LRR-Net 流程图

Fig. 1 The flow diagram of LRR-Net framework

(1) S 更新。该模块的更新对应于式 (4), 具体定义如下:

$$S^k = L_\lambda \left(\|X - DA^{k-1}\|_2 - \lambda^{-1} I \right) \quad (8)$$

式中, $\|\cdot\|_2$ 表示对每一列进行 l_2 范数计算。根据软阈值函数的定义, 可将其等价于 L_λ 模块的操作符, 即 $L_\lambda(x) = \operatorname{sign}(x) \max(0, |x| - \lambda)$ 。式 (8) 的过程与修正线性单元 (ReLU) 操作相同 (Goodfellow 等, 2016), 可用 $\operatorname{ReLU}(\cdot)$ 表示。

(2) J 更新。根据式 (5), 变量 J 模块的更新规则如下:

$$J^k = L_\theta(\operatorname{svd}(A^{k-1} - d^{k-1}) - \lambda^{-1} I) \quad (9)$$

式中, 与变量 S 模块的更新类似, $L_\theta(J)$ 操作符是根据奇异值阈值算子 SVT (Singular Value Thresholding) 进行求解的 (Liu 等, 2013), 具体步骤如下:

1) 输入一个秩为 r 的矩阵 M , 并考虑奇异值分解 SVD (Singular Value Decomposition), 有

$$M = U \times \Sigma \times V, \Sigma = \operatorname{diag}(\{\sigma_k\}_+)$$

2) 对应于每个 $\theta \geq 0$, 操作符 L_θ 的定义为

$$D(M) = U \times L_\theta \times V, L_\theta = \operatorname{diag}(\{\sigma_k - \theta\}_+) \quad (10)$$

由此, $\|A\|_*$ 可以通过 $L_\theta(J)$, $\theta = \frac{\lambda}{\mu}$ 得到。此外, 式 (10) 中的 $\{\cdot\}_+ = \max(0, x)$, 与式 (8) 的表示类似, 该过程使用 $\operatorname{ReLU}(\cdot)$ 表示。

(3) A 更新。根据式 (6) 对变量 A 的第 k 次迭代的 A^k 进行展开

$$A^k = W^{k-1}(X - S^k) + B^{k-1}(J^k + d^{k-1}) \quad (11)$$

式中, $W = (D^T D + \mu I)^{-1} D^T$, $B = (D^T D + \mu I)^{-1} \mu$, LRR-Net 将该操作等价于两个不同的线性层操作。




图 2 LRR-Net 网络更新组件

Fig. 2 LRR-Net network stage update component

(4) d 更新。传统模型中通常将式 (7) 中的步长 μ 设定为固定的参数。为提高网络的泛化性, 本文将步长 μ 作为一个可学习的参数, 定义为

$$d^k = d^{k-1} - \mu(A^k - J^k) \quad (12)$$

式中, 参数 μ 通过更新 $(\max \mu, \mu \beta)$ 来进行更新, 同时, 为满足模型的物理属性, 本文将该变量的

初始值设置为 1, LRR-Net 的总体算法流程为

输入: 观测数据 X , 变量 D, A, S, J, d ; 参数 λ, M, θ ;

输出: 背景 A , 异常 S ;

初始化: $J = A, d = 0, \lambda = 0.5, \mu = 1$;

while

do

固定变量 J, A, d , 更新 S

$$L_\lambda(\|X - DA^k\|_2 - \lambda^k I);$$

固定变量 S, A, d , 更新 J

$$L_\theta(\text{svd}(A^k - d^k) - \lambda^k I);$$

固定变量 J, S, d , 更新 A

$$W^k(X - S^{k+1}) + B^k(J^{k+1} + d^k);$$

固定变量 J, S, A , 更新 d

$$d^k - \mu(A^k - J^k);$$

是否满足条件:

If $\mathcal{R}_{\text{loss}} < \zeta$

停止迭代

Else

$k \leftarrow k + 1$

End

End

2.3 训练与损失

考虑到算法的鲁棒性, 同时也为了加速训练过程, 我们使用与 ADMM 算法相关联的原始参数来初始化网络参数的方法, 网络中的每个迭代块——对应于 ADMM 算法的迭代过程。通过连接 k 迭代块来

构建前馈神经网络, 与 ADMM 算法相关的模型参数 ($A, S, J, d, \lambda, \mu, \beta$) 可以被每个神经网络层中的可学习参数 ($\lambda, \mu, \theta, W, B$) 所取代, 进而以端到端的形式模拟现实的替代了 ADMM 的 k 次迭代。

LRR-Net 的训练通过标准均方误差 (MSE) 以完全无监督的方式进行训练, 损失函数由

$$\mathcal{R}_{\text{loss}} = \text{MSE}(X, \hat{X}) = \frac{1}{N} \sum_{i=1}^N \|x_i - \hat{x}_i\|^2 \quad (13)$$

式中, X 是由 N 个反射光谱 x_i 构成的原始观测影像, $\hat{X}$ 是由 $\hat{x}_i$ 个向量构成的估计值, 即重构影像。

3 实验结果与分析

3.1 实验数据

为验证 LRR-Net 方法的有效性, 实验选取了 4 组高光谱影像数据集来进行测试, 下面给出的数据集描述。

AVIRIS 数据。第 1、2 组数据集 (图 3 (a) 和 (b)), 于 2010 年, 由空中可见光/红外成像光谱仪 (AVIRIS) 传感器在收集, 涵盖了美国密西西南部 Gulfport 的一个区域, 波长间隔为 0.40—2.50 nm。实验中, 第 1 组数据去除了低信噪比的波段, 使用了剩下的 191 个波段, 其空间分辨率为 3.4 m, 具有 100×100 个像素点。第 2 组影像的大小为 100×100 像素, 空间分辨率为 3.5 m, 具有 186 个光谱波段。两组影像中的 3 架飞机被视为异常, 占比 1.43%。




图 3 实验数据的假彩色图像显示

Fig. 3 The pseudocolor image of experimental data

AIR-Vehicle 数据。第 3、4 组数据 (图 3 (c) 和 (d) 所示), 由中国科学院上海技术物理研究所在中国雄安新区设计的可见光和近红外成像光谱仪

采集得到。该数据飞行高度为 2000 m, 空间分辨率为 0.525 m, 包含 3751×2746 个像素, 在 400—1000 nm 的光谱范围内有 253 个波段。本实验将该

数据分割为两组子数据集 AIR-Vehicle-I 和 AIR-Vehicle-II，大小分别为 80×100 和 80×120 像素，数据中若干车辆定为城市场景中的异常目标。两组数据异常像素点的数量分别为 124、166 个，分别占为 1.55% 和 1.73% 的像素比。

3.2 参数配置

LRR-Net 在 Windows 10 操作系统中使用 Pytorch 框架实现的。该网络使用 Adam 优化器进行训练，使用 3.80 GHZ 高级微设备（AMD）锐龙 7 5800X 中央处理单元（CPU）和 NVIDIA RTX 3060Ti 图形处理单元（GPU）。采用以下超参数进行训练：初始学习率为 0.001，批量大小设置为 15，更新层数为 6，当有效损失不再下降时，提前停止前的优化步骤为 500，并采用 0.01 参数化的 l_1 -范数正则化方法来提高网络的泛化能力。

在评价指标方面，实验使用接收机工作特性曲线 ROC（Receiver Operating Characteristic）反映探测概率 PD（Probability of Detection）和误报率 FAR（False Alarm Rate）之间的关系。ROC 曲线下的面积，即 AUC 来计算不同算法间的异常探测效率（Khazai 等，2011）。

3.3 结果分析与对比

在对比方法中，我们使用了 GRX（Reed 和 Yu，1990），CRD（Li 和 Du，2015），LRASR（Xu 等，2016），以及 Auto-AD（Wang 等，2022）这 4 种较为典型的算法与 LRR-Net 进行比较。参照各算法的原始文献，并针对本文实验所采用的数据集进行算法调优。对于 GRX 方法，首先根据整个图像计算一个协方差矩阵，然后将其输入到每个块中，计算每个像素的马氏距离。根据 LRASR 原文章的描述，将聚类数 K 和选择的像素数分别设置为 15 和 20，4 个实验数据集的正则化参数 β 和 λ 设置为 0.1。对于 CRD，实验使用 $\mathbf{W}_{in} = [3, 5, 7, 9, 11, 13, 15, 17, 19]$ 和 $\mathbf{W}_{out} = [5, 7, 9, 11, 13, 15, 17, 19, 21, 23]$ ，正则化参数 λ 被设置为 $\lambda = 10^{-6}$ 。

表 1 给出了 5 种算法在不同数据集中的 AUC 数值，总的来说 LRR-Net 获得了最好的性能。同时，表 2 给出了各算法在多组数据集中运行的时间。实验在图 3、4 中对异常值的探测结果进行了可视化显示，其中，探测图的颜色范围从深蓝色到亮红色，倾向于亮红色的。

表 1 不同算法之间的异常探测性能的比较

Table 1 Anomaly detection performance comparison between different algorithms

方法	GRX	CRD	LRASR	Auto-AD	LRR-Net
AVIRIS-I	82.21	90.77	77.36	89.96	94.25
AVIRIS-II	91.10	81.35	94.27	97.20	99.33
AIR-Vehicle-I	58.45	86.94	75.72	90.94	95.93
AIR-Vehicle-II	64.14	82.76	69.29	83.24	96.65

表 2 不同算法之间的异常探测时间的比较

Table 2 Anomaly detection times comparison between different algorithm

方法	GRX	CRD	LRASR	Auto-AD	LRR-Net
AVIRIS-I	0.10	4.17	21.36	51.36	39.25
AVIRIS-II	0.06	3.08	15.11	45.20	34.33
AIR-Vehicle-I	0.12	4.56	18.39	43.54	25.43
AIR-Vehicle-II	0.08	5.28	22.54	56.11	27.89

AVIRIS-I 数据。在数据质量方面，该组数据的空间分辨率只有 10 m，从目视效果即可看出该数据集的分辨率较差，部分异常目标的边缘信息较为模糊。其次，由于空间分辨率较低等原因导致数据中存在很多混合像素，异常目标的和背景的区分度不明显，对探测算法的精度带来了一定的挑战。除异常目标自身探测难度较大以外，从图 4 给出的异常探测的结果来看，右上角的房顶具有较高的反射率，且与周围地形物相差较大，使大多探测结果出现了较高的误检率。但与 GRX、CRD 和 LRASR 相比，背景的复杂度和噪声对 Auto-AD 和 LRR-Net 的负面影响更小，尤其是后者。

从表 1 的数据来看，LRR-Net 比 GRX、CRD、LRASR 和 Auto-AD 分别高出 12.04%、3.48%、16.89%、5.29%，取得了较好的结果。图 5（a）给出了该数据下不同方法探测结果的 ROC 曲线，由该曲线可以看出 LRR-Net 在最开始时的探测性能较为普通，但在 PAR 达到 0.03 后，出现了明显的优势，尤其当 FAR 达到 0.07 左右时，LRR-Net 的 PD 也达到了 0.9，但其他大多数方法的 PD 都低于 0.7 左右，比其他方法表现得更好。

AVIRIS-II 数据。与图 4 的第一组数据集相比较，第 2 组数据集明显含有相对较少的强干扰信息，但依旧避免不了高亮建筑目标的影响，尤其是左上角的建筑物的干扰，令 5 种算法都出现了较高的虚警率。GRX 和 CRD 两种方法对该数据集的

3架飞机敏感度较差, LRR-Net无论是对异常目标的敏感度还是对背景干扰信息的抑制作用都表现

得最优秀。图5(b)的ROC曲线图也证明了这一观点, 在FAR为0.06时就已达到峰值。




图4 G-RX、CRD、LRASR、Auto-AD和LRR-Net等5种方法在AVIRIS-I和AVIRIS-II数据上的异常探测结果

Fig. 4 Anomaly detection results of G-RX, CRD, LRASR, Auto-AD and LRR-Net methods different methods on AVIRIS-I and AVIRIS-II datasets




图5 AVIRIS-I, AVIRIS-II, AIR-Vehicle-I和AIR-Vehicle-II数据集ROC曲线

Fig. 5 The ROC curves of AVIRIS-I, AVIRIS-II, AIR-Vehicle-I, and AIR-Vehicle-II

从表1的数据来看, LRR-Net比GRX、CRD、LRASR和Auto-AD也分别高出8.20%、17.98%、5.06%、2.13%,取得了较好的结果。根据视觉比较,紫色的Auto-AD比其他3个基于传统模型的算法具有更好的探测性能, LRR-Net在所有探测器中表现出最高的分数,甚至约为0.99以上。另外,针对该数据而言,基于深度的异常探测方法具有相对较为稳定的性能。

AIR-Vehicle-I数据。在该数据集中,位于十字路口的几辆不同形状、颜色、材质的汽车被视为异常目标,周围的绿植、阴影和马路被视为背景。就视觉效果而言,尽管大多数探测器的虚警率较低,但可以发现GRX和CRD未能探测到完整的异常情况,而LRASR受到了绿植的严重干扰。总体来说, LRR-Net在所有比较的方法中无疑取得了最好的探测结果,异常车辆的边缘和结构都

是最清晰的。此外,从表1的数据来看, LRR-Net比比GRX、CRD、II和Auto-AD也分别高出37.48%、8.99%、20.219%、4.99%,取得了较好的结果。

由图5(c)描述的ROC曲线可以看出,在该数据集中LRR-Net与其他方法的探测结果相比具有较明显的优势,尤其在FAR达到0.05之前,玫红色的曲线急剧上升,并且比其他方法更快地到达最大。

AIR-Vehicle-II数据。如图6所示,在视觉方面, LRASR对背景的抑制效果最差, GRX、CRD、Auto-AD和LRR-Net对背景噪声的抑制效果相对较好,但GRX表现出来的虚警率较高,降低了其探测性能。CRD、Auto-AD和LRR-Net的探测结果中都出现了7辆异常车辆,但CRD的完整度相对较差,而Auto-AD和LRR-Net呈现了较为完整的车辆形状,但很明显LRR-Net的抗干扰能力较强,能较好的突出目标、抑制背景。




图6 G-RX、CRD、LRASR、Auto-AD和LRR-Net方法在AIR-Vehicle-I和AIR-Vehicle-II数据集的异常探测结果

Fig. 6 Anomaly detection results of G-RX, CRD, LRASR, Auto-AD and LRR-Net methods on AIR-Vehicle-I and AIR-Vehicle-II datasets

图5(d)给出了AIR-HI-Vehicle-II数据集下各方法的ROC曲线。在所有的探测器中,提出的LRR-Net在所有的FAR中实现了最高的PD值,对应于表1给出的AIR-HI-Vehicle-II数据集的AUC值。即使在背景信息干扰较强的情况下,所提的方法也可以抑制背景噪声,取得一个相对稳定的结果。

总的来说,深度学习网络具有强大的学习能力,在处理不同复杂度的数据集上,与传统模型相比具有较强的鲁棒性。然而,尽管深度学习数据拟合能力很强,但缺乏必要的先验信息,这往往会使得算法陷入局部最优中,这导致了深度学习无法保证HAD结果的稳定性。而基于模型的算

法则可以较好的弥补这一缺陷,它的通过提高背景和目标之间的可分离性往往能得到更好的结果。尽管如此,这些基于LRR的方法由于它们的表示能力有限,无法有效地抑制背景噪声,如复杂场景中的阴影、树和边缘,探测效果的波动性相对较大。本文提出的LRR-Net结合了以上两种方法的优势,4个典型场景的实验结果表明了通过深度展开技术,利用模来指导神经网络中最优参数的搜索能够以一种自适应的方式有效地解决HAD问题,更具有物理意义。

4 结 论

本文基于深度展开网络引入了一种新的高光

谱异常探测方法,建立了模型驱动和深度学习技术之间的联系。与以往基于自编码网络不同的是,提出的 LRR-Net 利用 ADMM 优化器有效地求解 LRR 模型,并将所得到的解作为先验知识来指导网络参数的优化,为网络的有效运算提供了理论指导。本文的主要贡献可归纳如下:

(1) 针对 HAD 任务我们首次利用深度展开技术,链接了物理模型和深度学习技术,提出了一种具有可解释性的深度网络 LRR-Net。

(2) LRR-Net 在 ADMM 框架下展开,通过对每个变量的子问题求解,将求结过程作为先验知识指导深度网络的搭建和参数优化,为深度网络赋予了可解性。

(3) 借助深度学习的强大数据拟合能力,使物理模型能够以端到端无监督的方式自适应地学习模型正则化参数和变量估计,很大程度上解决了手动调参的模型实际应用和迁移困难。

最后通过实验验证了所提方法的有效性,结果表明, LRR-Net 在探测性能上优于迭代的 HAD 方法。在我们未来的工作中,我们将会对将稀疏约束以及有效的字典空间学习进行研究,利用深度展开嵌入至模型中提高 HAD 的探测性能。

参考文献(References)

Boyd S, Parikh N, Chu E, Peleato B and Eckstein J. 2011. Distributed optimization and statistical learning via the alternating direction method of multipliers. *Foundations and Trends® in Machine Learning*, 3(1): 1-122 [DOI: 10.1561/22000000016]

Chang C I. 2022. Effective anomaly space for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5526624 [DOI: 10.1109/TGRS.2022.3161632]

Chen S Y, Yang S M, Kalpakis K and Chang C I. 2013. Low-rank decomposition-based anomaly detection//*Processing of SPIE 8743, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XIX*. Baltimore: SPIE: 87430N [DOI: 10.1117/12.2015652]

Goodfellow I, Bengio Y and Courville A. 2016. *Deep Learning*. Cambridge: MIT Press

Hong D F, Zhang B, Li H, Li Y X, Yao J, Li C, Werner M., Chanussot J., Zipf A., Xiao X X. Cross-city matters: A multimodal remote sensing benchmark dataset for cross-city semantic segmentation using high-resolution domain adaptation networks. *Remote Sensing of Environment*, 299(15): 0034-4257 [DOI: 10.1016/j.rse.2023.113856]

Hong D F, Zhang B, Li X, Li Y, Li C, Yao J, Yokoya N, Li H, Jia X, Plaza A, Gamba P, Benediktsson J, Chanusso J. "SpectralGPT: Spectral Foundation Model." *arXiv preprint arXiv:2311.07113*, 2023.

Huyan N, Zhang X R, Zhou H Y and Jiao L C. 2019. Hyperspectral

anomaly detection via background and potential anomaly dictionaries construction. *IEEE Transactions on Geoscience and Remote Sensing*, 57(4): 2263-2276 [DOI: 10.1109/TGRS.2018.2872590]

Jiang T, Li Y S, Xie W Y and Du Q. 2020. Discriminative reconstruction constrained generative adversarial network for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 58(7): 4666-4679 [DOI: 10.1109/TGRS.2020.2965961]

Khazai S, Homayouni S, Safari A and Mojaradi B. 2011. Anomaly detection in hyperspectral images based on an adaptive support vector method. *IEEE Geoscience and Remote Sensing Letters*, 8(4): 646-650 [DOI: 10.1109/LGRS.2010.2098842]

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]

Lin Z C, Liu R S and Su Z X. 2011. Linearized alternating direction method with adaptive penalty for low-rank representation//*Proceedings of the 24th International Conference on Neural Information Processing Systems (NIPS)*. Granada: Curran Associates Inc.: 612-620

Liu G C, Lin Z C, Yan S C, Sun J, Yu Y and Ma Y. 2013. Robust recovery of subspace structures by low-rank representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(1): 171-184 [DOI: 10.1109/TPAMI.2012.88]

Manolakis D and Shaw G. 2002. Detection algorithms for hyperspectral imaging applications. *IEEE Signal Processing Magazine*, 19(1): 29-43 [DOI: 10.1109/79.974724]

Molero J M, Garzon E M, Garcia 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]

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]

Shen H F, Jiang M H, Li J, Zhou C X, Yuan Q Q and Zhang L P. 2022. Coupling model- and data-driven methods for remote sensing image restoration and fusion: improving physical interpretability. *IEEE Geoscience and Remote Sensing Magazine*, 10(2): 231-249 [DOI: 10.1109/MGRS.2021.3135954]

Tong Q X, Zhang B and Zhang L F. 2016. Current progress of hyperspectral remote sensing in China. *Journal of Remote Sensing*, 20(5): 689-707 (童庆禧, 张兵, 张立福. 2016. 中国高光谱遥感的前沿进展. *遥感学报*, 20(5): 689-707) [DOI: 10.11834/jrs.20166264]

Vane G and Goetz A F H. 1988. Terrestrial imaging spectroscopy. *Remote Sensing of Environment*, 24(1): 1-29 [DOI: 10.1016/0034-4257(88)90003-X]

Wang S Y, Wang X Y, Zhang L P and Zhong Y F. 2022. Auto-AD: autonomous hyperspectral anomaly detection network based on fully convolutional autoencoder. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5503314 [DOI: 10.1109/TGRS.2021.3057721]

Wu X, Hong D F and Chanussot J. 2023. UIU-Net: U-Net in U-Net for infrared small object detection. *IEEE Transactions on Image Processing*, 32: 364-376 [DOI: 10.1109/TIP.2022.3228497]

Xie Q, Zhou M H, Zhao Q, Meng D Y, Zuo W M and Xu Z B. 2019.

- Multispectral and hyperspectral image fusion by MS/HS fusion net//IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach: IEEE: 1585-1515 [DOI: 10.1109/CVPR.2019.00168]
- Xiong F C, Zhou J, Tao S Y, Lu J F and Qian Y T. 2022a. SNMF-Net: learning a deep alternating neural network for hyperspectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5510816 [DOI: 10.1109/TGRS.2021.3081177]
- Xiong F C, Zhou J, Tao S Y, Lu J F, Zhou J T and Qian Y T. 2022b. SMDS-Net: model guided spectral-spatial network for hyperspectral image denoising. *IEEE Transactions on Image Processing*, 31: 5469-5483 [DOI: 10.1109/TIP.2022.3196826]
- 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]
- Yang L L, Li C, Han J G, Chen C, Ye Q X, Zhang B C, Cao X B and Liu W Q. 2017. Image reconstruction via manifold constrained convolutional sparse coding for image sets. *IEEE Journal of Selected Topics in Signal Processing*, 11(7): 1072-1081 [DOI: 10.1109/JSTSP.2017.2743683]
- Yang Y, Sun J, Li H B and Xu Z B. 2020. ADMM-CSNet: a deep learning approach for image compressive sensing. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(3): 521-538 [DOI: 10.1109/TPAMI.2018.2883941]
- Zhang B. 2016. Advancement of hyperspectral image processing and information extraction. *Journal of Remote Sensing*, 20(5): 1062-1090 (张兵. 2016. 高光谱图像处理与信息提取前沿. *遥感学报*, 20(5): 1062-1090) [DOI: 10.11834/jrs.20166179]
- Zhang B. 2018. Remotely sensed big data era and intelligent information extraction. *Geomatics and Information Science of Wuhan University*, 43(12): 1861-1871 (张兵. 2018. 遥感大数据时代与智能信息提取. *武汉大学学报(信息科学版)*, 43(12): 1861-1871) [DOI: 10.13203/j.whugis20180172]
- Zhang Y, Hua W S, Yan Y, Cui Z H and Suo W K. 2019. Progress in hyperspectral anomaly target detection. *Laser Journal*, 40(7): 6-9 (张炎, 华文深, 严阳, 崔子浩, 索文凯. 2019. 高光谱异常目标检测算法研究进展. *激光杂志*, 40(7): 6-9) [DOI: 10.14016/j.cnki.jgzz.2019.07.006]
- Zhu D H, Du B and Zhang L P. 2020. Band selection-based collaborative representation for anomaly detection in hyperspectral images. *Journal of Remote Sensing*, 24(4): 427-438 (朱德辉, 杜博, 张良培. 2020. 波段选择协同表达高光谱异常探测算法. *遥感学报*, 24(4): 427-438) [DOI: 10.11834/jrs.20209187]

Deep unfolding network for hyperspectral anomaly detection

LI Chenyu^{1,2}, HONG Danfeng^{1,3}, ZHANG Bing^{1,2,4}

1. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China;

2. School of Mathematics and Statistics, Southeast University, Nanjing 210089, China;

3. School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049, China;

4. College of Resources and Environment, University of Chinese Academy of Sciences, Beijing 100049, China

Abstract: Hyperspectral Anomaly Detection(HAD) is one of the most critical topic in hyperspectral remote sensing and has been extensively addressed in the literature over the past decade. Among them, Low-Rank Representation(LRR) models are widely used owing to their powerful separation ability for the background and targets. But their applications in practical situations still remain limited due to the extreme dependence on manual parameter selection and relatively poor generalization ability. To this end, this paper combines the LRR model with deep learning techniques to propose a new underlying network for HAD, called LRR-Net. This method efficiently solves the LRR model with the help of the Alternating Direction Method of Multipliers (ADMM) optimizer, and incorporates the solution as a priori knowledge into the deep network to guide the optimization of parameters, providing a theoretical basis for deep networks. In addition, LRR-Net converts a series of regularized parameters into learnable network parameters in an end-to-end manner, thus avoiding manual tuning of parameters. Experimental results obtained from publicly available datasets and our datasets demonstrate that the LRR-Net method outperforms many state-of-the-art model-based and deep-based algorithms of hyperspectral anomaly detection. Overall, deep learning networks are powerful in learning and are robust compared to traditional models in processing datasets with different complexity. However, despite the strong fitting ability of deep learning data, the necessary prior information is lacking, which often makes the algorithm fall into the local optima, which leads to the failure of deep learning to guarantee the stability of HAD results. The model-based algorithm can better make up for this defect, which can often get better results by improving the separability between the background and the target. Nonetheless, these LRR-based methods are unable to effectively suppress background noise due to their limited representation power, such as shadows, trees, and edges in complex scenes, with relatively large volatility in detection effects. The LRR-Net presented in this paper combines the advantages of the above two methods, and the experimental results of four typical scenarios show that the search of the optimal parameters in the neural network can effectively solve the HAD problem in an adaptive way, which is more physically meaningful.

Key words: hyperspectral remote sensing image, anomaly detection, deep unfolding, Low-Rank Representation (LRR), Alternating Direction Multiplier Method (ADMM)

Supported by National Natural Science Foundation of China (No. 42241109, 42271350)