

引用格式: SUN Bangyong, ZHAO Zhe, HU Bingliang, et al. Hyperspectral Anomaly Detection Based on 3D Convolutional Autoencoder and Low Rank Representation[J]. Acta Photonica Sinica, 2021, 50(4):0410003

孙帮勇,赵哲,胡炳樑,等. 基于 3D 卷积自编解码器和低秩表示的高光谱异常检测[J]. 光子学报, 2021, 50(4):0410003

# 基于 3D 卷积自编解码器和低秩表示的高光谱异常检测

孙帮勇<sup>1,2</sup>, 赵哲<sup>1</sup>, 胡炳樑<sup>2</sup>, 于涛<sup>2</sup>

(1 西安理工大学 印刷包装与数字媒体学院, 西安 710048)

(2 中国科学院西安光学精密机械研究所 光谱成像技术重点实验室, 西安 710119)

**摘要:**针对高光谱影像数据维度高、空间和光谱信息利用不足以及局部结构特征表达有限等问题,提出了一种基于 3D 卷积自编解码器和低秩表示的高光谱异常检测算法。首先,通过 3D 卷积自编解码器提取高光谱影像的空谱特征,并针对高光谱图像的局部区域强相关性,设计了一种新的损失函数来约束中心像素和周围像素,以提取判别性较强的特征图;然后,针对所提取的特征图,通过基于密度的空间聚类算法构建背景字典,并利用低秩表示分离出异常区域;最后,融合由 3D 卷积自编解码器得到的重构误差和异常区域检测结果,得到最终检测图并为异常目标关键信息的挖掘提供依据。为了验证所提算法的有效性,在两个真实的机场高光谱数据集上进行飞机等目标检测实验,ROC、AUC 量化指标和主观分析等实验结果表明,与其它 6 种异常检测算法相比,本文算法具有更高的异常目标检测精度。

**关键词:**高光谱影像;异常检测;3D 卷积;自编解码器;低秩表示

中图分类号: TP751.1

文献标识码: A

doi: 10.3788/gzxb20215004.0410003

## Hyperspectral Anomaly Detection Based on 3D Convolutional Autoencoder and Low Rank Representation

SUN Bangyong<sup>1,2</sup>, ZHAO Zhe<sup>1</sup>, HU Bingliang<sup>2</sup>, YU Tao<sup>2</sup>

(1 College of Printing, Packaging and Digital Media, Xi'an University of Technology, Xi'an 710048, China)

(2 Key Laboratory of Spectral Imaging Technology CAS, Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences, Xi'an 710119, China)

**Abstract:** Due to the challenge of high dimensionality, insufficient utilization of spatial-spectral information and limited local structure property expression in hyperspectral images, a hyperspectral anomaly detection algorithm based on 3D convolutional autoencoder and low rank representation is proposed in this paper. Firstly, the spectral-spatial features of hyperspectral images are extracted by 3D convolutional autoencoder. In order to precisely represent the local similarity, a new loss function is proposed to constrain the central pixel and its surrounding pixels to extract more discriminative features. And then, the Density Based Spatial Clustering of Applications with Noise (DBSCAN) algorithm is used to construct the background dictionary, and the abnormal region is separated by low rank representation on the feature map. Finally, the detection result is obtained by fusing the reconstruction error obtained by 3D convolution autoencoder and abnormal region detection result. We carry out objective and subjective anomaly detection

**基金项目:** 国家自然科学基金 (No. 62076199), 国防科技创新项目 (No. XXX-ZT-00X-014-01), 中国博士后科学基金 (No. 2019M653784), 中国科学院光谱成像技术重点实验室基金 (No. LSIT201801D)

**第一作者:** 孙帮勇 (1980-), 男, 副教授, 博士, 主要研究方向为多光谱快速成像技术。Email: sunbangyong@xaut.edu.cn

**通讯作者:** 于涛 (1980-), 男, 副研究员, 博士, 主要研究方向为光谱成像技术。Email: yutao@opt.ac.cn

**收稿日期:** 2020-12-16; **录用日期:** 2021-01-04

<http://www.photon.ac.cn>

experiments on two real hyperspectral datasets. The results demonstrate that the proposed algorithm detect abnormal targets more accurately compared with other algorithms.

**Key words:** Hyperspectral imagery; Anomaly detection; 3D Convolution; Autoencoder; Low rank representation

**OCIS Codes:** 100.4145; 110.4234; 100.4999

## 0 引言

高光谱图像(Hyperspectral Imagery, HSI)是一个三维的数据立方体,其中两维表达空间关系,另一维表达地物在不同波段上的反射或者辐射强度。高光谱图像包含远高于RGB图像的信息量,具有纳米级的光谱分辨率,每个像元都可以形成一条连续的光谱曲线,从而能够区分不同地物的光谱差异,所以广泛应用于战场侦察、食品安全、环境监测等领域。异常检测通常是指检测出与预期分布具有显著差异的样本,受益于HSI丰富的空谱信息,HSI异常检测因其不需要先验信息符合实际需求等优势,近年来吸引了大量学者关注。

高光谱异常目标通常是指与周围背景光谱分布存在显著差异、在空间上稀疏分布或出现概率较低的目标<sup>[1]</sup>。现有高光谱异常检测算法大致分为以下四类:基于统计模型的检测算法、基于表达模型的检测算法、基于矩阵分解的检测算法以及基于深度学习的检测算法。由REED S等<sup>[2]</sup>提出的RX(Reed-Xiao li Detection, RXD)算法是基于统计模型检测方法的基准算法,其假设背景服从多元正态分布,通过计算待检测像素与背景之间的马氏距离来确定异常程度。不过,由于实际情况中高光谱数据背景复杂、很难满足正态分布假设,在检测过程中的协方差矩阵计算时,易受到异常像素的污染,因此,提出了多种基于RX算法改进方法,如:LRX算法(Local RX, LRX)<sup>[3]</sup>、WRX算法(Weighted RX, WRX)<sup>[4]</sup>、KRX算法(Kernel RX, KRX)<sup>[5]</sup>等。

基于表达模型的检测算法主要基于协同表达(Collaborative Representation-based Detector, CRD)和稀疏表达(Sparse Representation-based Detector, SRD)。LI Wei等<sup>[6]</sup>将协同表达思想引入到高光谱异常检测,认为背景像素可以较好的由其周围像素表示,而异常像素则很难由周围像素直接表示。相比于统计模型,该方法不需要对背景进行分布假设、且具有封闭解,但计算量较大,算法时间复杂度高且局部区域易受异常像素污染。基于此,MA Ning等<sup>[7]</sup>通过构建滑动窗口之间的关系,提出了一种快速的CRD算法;SU Hongjun等<sup>[8]</sup>对局部窗口中的元素进行预处理,减少了异常像素对双窗口区域的污染;LI Jiay等<sup>[9]</sup>通过构建背景字典来对背景建模,将每个像元表示成字典原子的线性形式,然后计算重构误差来进行异常检测。

基于矩阵分解的检测算法,通常把HSI图像作为矩阵或者张量进行分解,然后检测其中的异常目标。采用的数据分解方式主要有三种:1)RPCA(Robust Principal Component Analysis, RPCA)算法。LI Shuangjiang等<sup>[10]</sup>先用高阶RPCA把HSI分解成低秩张量和稀疏张量,其中稀疏张量估计噪声,再对低秩张量进行Tucker分解,在得到的核张量上进行解混和异常检测,不过由于RPCA算法假设数据分布在单一的子空间里,与实际中HSI混合像元的多元子空间分布不符,导致检测效率偏低;WANG Wei等<sup>[11]</sup>先对原始数据进行解混,然后在得到的丰度矩阵上采用RPCA分解为低秩部分和稀疏部分,最后在稀疏部分上进行异常检测,同样由于RPCA会将孤立的噪声点视为异常像素,常导致较高的虚警。2)GoDec(Go Decomposition, GoDec)算法。此算法主要解决噪声对异常检测的影响,将数据分解成背景部分、异常部分以及噪声部分<sup>[12]</sup>,首先对噪声进行估计,然后在稀疏部分上进行异常检测,由于噪声和异常往往很难区别,在预先估计噪声时,有的异常像素被误判成噪声,导致检测精度不高。3)LRR(Low Rank Representation, LRR)方法。LRR方法通过构建背景字典对背景进行建模,采用原始数据和重构背景得到残差图像进行异常检测;文献<sup>[13-14]</sup>先对原始HSI进行解混,然后在丰度矩阵上用LRR模型把异常部分从背景数据中分离出来。

近年来,深度学习方法受到大批学者关注,成为高光谱异常检测的重要方法之一。DU Qian等<sup>[15]</sup>将CNN应用到高光谱异常检测,通过度量待检测像素与周围像素的相似度来进行异常检测,不过需要大量标记的像素对来训练网络;MA Ning等<sup>[16]</sup>将自编解码器(Autoencoder, AE)应用到高光谱异常检测,通过计算重构误差来获取最终检测结果;ZHAO Chunhui等<sup>[17]</sup>通过降噪堆叠自编解码器进行异常检测。以上方法主要基于异常的光谱特性进行检测,最近的一些研究<sup>[18-19]</sup>表明,同时考虑异常像素的空间特性和光谱特性能够有效地提高检测精度。ZHAO Chunhui等<sup>[18]</sup>结合堆叠自编解码器和低秩稀疏矩阵分解进行空谱异常检测;LEI Jie等<sup>[19]</sup>通过DBN(Deep Belief Network, DBN)先对HSI进行特征提取,在得到的特征数据上分别用

RX算法和形态学滤波从光谱和空间两个角度进行异常检测,取得了较好的检测结果。

基于AE的方法将每个像素单独送入网络进行特征提取,虽然能够提取到有用特征,但是会导致原图像各像素空间关系的丢失,而且以上空谱结合的方法将空间信息和光谱信息分开考虑,这样破坏了空谱关系。3D卷积<sup>[20]</sup>因其同时提取时空特征的优势,广泛的应用于视频和医学图像处理,近年来也被引入到HSI处理领域;MEI Shanhui等<sup>[21]</sup>将3D卷积应用到高光谱分类,先通过3D-CAE(3D Convolutional Autoencoder, 3D-CAE)提取空谱特征,然后在特征图像上用SVM(Support Vector Machine, SVM)对HSI分类;SHI Yanzi等<sup>[22]</sup>结合3D卷积和残差学习进行高光谱目标检测,能够准确检测出目标对象。

针对高光谱影像数据维度高、信息量冗余等特点以及现有异常检测算法空谱信息利用不足、局部表达有限等问题,本文提出了一种基于3D-CAE和LRR的高光谱异常检测算法。首先通过3D-CAE提取HSI的空谱特征,3D卷积在保留空谱关系的同时能够有效的提取到更具判别性的空谱特征;为了更好的表达HSI的局部相似性,本文在训练3D-CAE时,在损失函数中加入欧式距离来约束中心像素与其周围像素的关系。其次,使用DBSCAN算法<sup>[23]</sup>在由3D-CAE提取到的潜在特征上构建背景字典,通过LRR分离出稀疏区域得到初始检测结果。最后,融合由3D-CAE得到的重构误差和初始检测结果得到最终检测结果。

## 1 基于3D-CAE和LRR的高光谱异常检测原理

本文算法流程主要有以下三步:首先,通过3D-CAE提取原始HSI的空谱特征,增大异常区域与背景区域的可分性;然后,采用DBSCAN算法在提取到的特征图上构造背景字典,在DBSCAN算法对提取的特征进行聚类后,计算每一类原子与局部均值之间的马氏距离,选取距离最小的 $P$ 个原子作为这一类的代表,要是某一类原子数目少于 $P$ ,则舍弃这一类,所有类别原子构成最终背景字典;最后,通过LRR模型分离出异常部分得到初始检测结果,再融合由3D-CAE得到的重构误差和初始检测结果得到最终结果。具体流程如图1所示。

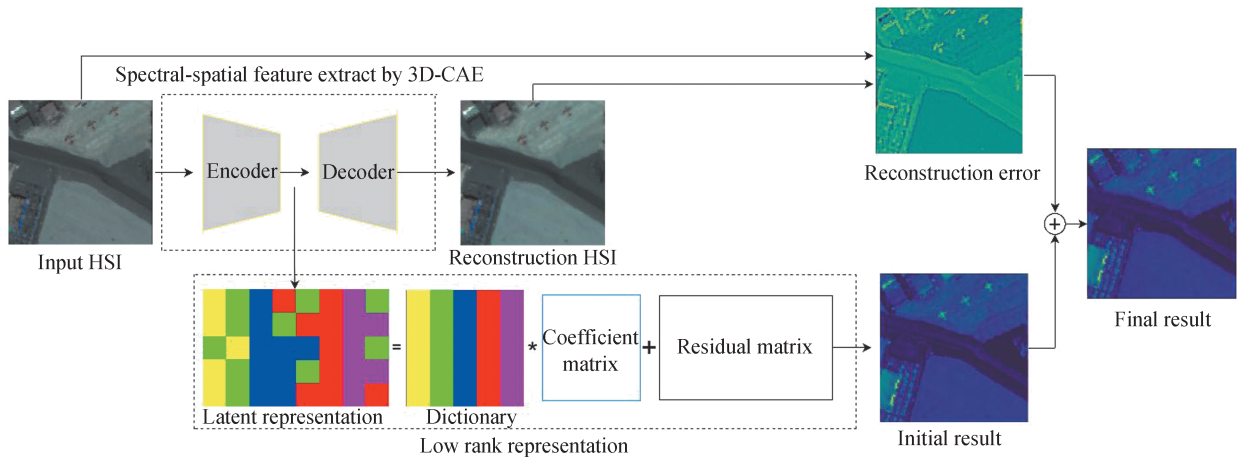


图1 本文算法流程

Fig. 1 Framework of the proposed method

### 1.1 3D-CAE 提取特征

由于高维度HSI图像存在显著冗余性,如何有效提取图像特征是后续异常目标检测的关键。本文采用3D-CAE来提取HSI特征,3D卷积能同时提取空间和光谱特征,而空谱结合能够有效提高异常检测精度。与传统AE结构相似,CAE也是由编码器、解码器和损失函数组成,不同之处是CAE层与层之间由卷积操作连接<sup>[23]</sup>,而不是传统AE层与层之间的全连接。假设第 $l-1$ 层的特征图为 $A_{l-1}$ ,第 $l$ 层的第 $i$ 个特征在位置 $(x, y, z)$ 处的值表示为

$$A_{l,i}^{xyz} = f \left( \sum_{c=0}^{C_{l-1}} \sum_{h=0}^{H_{l-1}-1} \sum_{w=0}^{W_{l-1}-1} \sum_{d=1}^{D_L} \theta_{l,i}^{chwd} A_{l-1}^{c(x+h)(y+w)(z+d)} + b_{l,i} \right) \quad (1)$$

式中, $\theta_{l,i}^{chwd}$ 表示连接到第 $l$ 层的第 $i$ 个卷积核在位置 $(h, w, d)$ 处的值, $c$ 表示第 $l-1$ 层送入到第 $l$ 层的特征图,

$H$ 、 $W$ 和 $D$ 分别表示3D卷积核的高、宽以及在光谱维上的深度, $b_{l,i}$ 表示第 $i$ 个特征图在第 $l$ 层的偏置, $f(\cdot)$ 表示激活函数,使用的激活函数是LReLU<sup>[24]</sup>。

假设 $\mathbf{X} \in \mathbb{R}^{M \times N \times B}$ 表示一个HSI, $M$ 、 $N$ 和 $B$ 分别代表HSI的长、宽以及波段数,像素 $\mathbf{X}(x, y) \in \mathbb{R}^{B \times 1}$ ,其中 $(x, y) | x = 1, 2, \dots, M; y = 1, 2, \dots, N$ 表示HSI的空间索引,使用在原始HSI上以像素 $\mathbf{X}(x, y)$ 为中心的立方体 $\mathbf{I}_{(x,y)} \in \mathbb{R}^{s \times s \times B}$ 来提取像素 $\mathbf{X}(x, y)$ 的空谱特征,其中 $s \times s$ 表示以像素 $\mathbf{X}(x, y)$ 为中心的邻域大小,实验中设定 $s = 5$ 。则采用3D-CAE提取原始HSI特征的过程表示为

$$\mathbf{X}_L = f(\Theta_{en} \cdot \mathbf{X} + b_{en}) \quad (2)$$

$$\hat{\mathbf{X}} = f(\Theta_{de} \cdot \mathbf{X}_L + b_{de}) \quad (3)$$

式中, $\mathbf{X}_L \in \mathbb{R}^{M \times N \times b}$  ( $b \ll B$ )表示由编码器提取到的特征, $b$ 为特征图的波段数, $\Theta_{en}$ 和 $b_{en}$ 代表编码器的权值和偏置; $\hat{\mathbf{X}} \in \mathbb{R}^{M \times N \times B}$ 表示由解码器重构的HSI, $\Theta_{de}$ 和 $b_{de}$ 分别表示解码器的权值和偏置。

传统AE大多以均方误差作为损失函数,然而均方误差易导致图像模糊<sup>[25]</sup>,不能很好地表达HSI特征。由于HSI较低的空间分辨率,其局部区域往往具有较强的相关性,为了有效表达这种关系,本文采用欧式距离来约束中心像素与其周围像素的关系,来描述其局部相似性。同时,为了解决欧式距离度量带来的图像模糊问题,本文采用光谱角度量输入像素与重构像素的光谱相似性<sup>[26]</sup>,因此,本文3D-CAE的损失函数为

$$L(x) = \sum_{i=1}^t \|\mathbf{X}_c - \hat{\mathbf{X}}_i\|^2 + \alpha \times \frac{1}{t} \times \frac{1}{\pi} \sum_{i=1}^t \arccos \left( \frac{\mathbf{X}_i \hat{\mathbf{X}}_i}{\|\mathbf{X}_i\|_2 \|\hat{\mathbf{X}}_i\|_2} \right) + \beta \|\mathbf{w}\|^2 \quad (4)$$

式中, $t$ 表示每个输入立方体的像素数目,本文采用 $5 \times 5$ 的邻域大小,所以 $t = 25$ , $\mathbf{X}_i$ 表示输入立方体中第 $i$ 个像素, $\hat{\mathbf{X}}_i$ 表示其对应的重构像素, $\mathbf{X}_c$ 表示输入像素立方体的中心像素, $\mathbf{w}$ 为连接权重, $\alpha$ 和 $\beta$ 用来控制各个部分的权重。需要指出的是,本文所提损失函数的第一项不同于均方误差,均方误差用欧式距离来度量输入像素与其对应的重构像素,并不包含中心像素与周围像素的关系,而本文所提损失函数主要基于HSI局部相似性这一特点来进行设计,用来挖掘HSI的局部信息,从而便于后续处理,而第二项光谱角(余弦相似性)度量,主要是为了解决欧式距离度量带来的图像模糊问题。实验中对所有数据集设置 $\alpha = 1, \beta = 0.005$ ,在2.2节将分析不同取值对最终检测结果的影响。

本文所设计的3D-CAE网络结构如表1所示,为了减少网络参数、加快网络收敛<sup>[27]</sup>,把 $3 \times 3 \times 3$ 的卷积

表1 3D-CAE网络结构  
Table 1 The Architecture of 3D-CAE

Block	Layer	Input size	Kernel size	Strides	Output size
Encoder	Conv1	189×5×5×1	1×3×3	1×1×1	189×3×3×12
	BN+LReLU	—	—	—	189×3×3×12
	Conv2	189×3×3×12	3×1×1	3×1×1	63×3×3×24
	BN+LReLU	—	—	—	63×3×3×24
	Conv3	63×3×3×24	1×3×3	1×1×1	63×1×1×36
	BN+LReLU	—	—	—	63×1×1×36
	Conv4	63×1×1×36	3×1×1	3×1×1	21×1×1×48
	BN+Sigmoid	—	—	—	21×1×1×48
Decoder	Deconv1	21×1×1×48	3×1×1	3×1×1	63×1×1×36
	BN+LReLU	—	—	—	63×1×1×36
	Deconv2	63×1×1×36	1×3×3	1×1×1	63×3×3×24
	BN+LReLU	—	—	—	63×3×3×24
	Deconv3	63×3×3×24	3×1×1	3×1×1	189×3×3×12
	BN+LReLU	—	—	—	189×3×3×12
	Deconv4	189×3×3×12	1×3×3	1×1×1	189×5×5×1
	BN	—	—	—	—

核拆分成 $1 \times 3 \times 3$ 和 $3 \times 1 \times 1$ 的卷积核,每次卷积后加上BN层和激活函数,其中编码器的最后一层使用Sigmoid激活,其余均为LReLU激活函数。

## 1.2 DBSCAN算法构造字典

近几年来,研究人员提出了大量构造字典的方法,其中大多数是基于聚类思想,将数据进行聚类处理后,在每一类中取一定数量的原子作为代表,最终所有类别的代表原子构成了背景字典。XU Yang等<sup>[28]</sup>基于K-means算法来构造背景字典,首先把原始HSI聚类成K类,为了保证获取到的字典原子包括所有背景像素,所设K值一般大于实际的地物数,然后通过计算马氏距离选取各类中的原子作为背景原子,不过该方法中K值往往难以精确设定;QU Ying等<sup>[14]</sup>先用解混算法得到原始HSI的丰度矩阵和端元矩阵,然后在丰度矩阵上用Mean-Shift算法进行聚类,在聚类结束以后,选取每一类的中心像素和离中心像素最远的像素构造字典,相比于K-means算法,Mean-Shift算法不需要确实类别数K,但是需要提前定义带宽或者窗口(bandwidth)。

为进一步提高聚类效率,本文采用DBSCAN算法通过在潜在特征 $X_L$ 上聚类构造背景字典。DBSCAN算法是一种基于密度的聚类算法,根据样本分布的紧密程度进行分类,其优点在于不需要提前定义类别数并且适用于任意形状的数据,由于场景中的背景密度远远高于异常区域密度,因此DBSCAN算法是HSI聚类的理想模型。DBSCAN算法聚类过程的伪代码如算法1所示。

算法1:DBSCAN

输入:

$X$ :一个包含 $n$ 个样本的待聚类数据

eps:参数半径

MinSample:邻域密度阈值

输出:

基于密度的簇(类)集合

方法:

1. 标记所有样本 $n$ 为 unvisited
2. 随机选择一个样本 $p$ ,并标记为 visited
3. if  $p$  的邻域 eps 内至少有 MinSample 个样本
4.     创建一个新的簇  $C$ ,并且把  $p$  添加到  $C$
5.     假设  $N$  表示  $p$  的 eps 邻域内样本的集合
6.     for  $N$  中每个样本  $p'$
7.         if  $p'$  是 unvisited
8.             标记  $p'$  为 visited
9.             if  $p'$  的 eps 邻域至少有 MinSample 的样本
10.                 把这些样本添加到  $N$
11.             if  $p'$  还不是任何簇成员,则把  $p'$  添加到  $C$
12.     end for
13.     输出  $C$
14. else 标记  $p$  为噪声
15. until 没有 unvisited 样本

在聚类结束后,计算每一个像素与其所属类别区域均值之间的马氏距离,选择每一类距离最小的 $p$ 个像素代表这一类,最终所有类别组成背景字典 $D=[d_1, d_2, \dots, d_m] \in \mathbb{R}^{b \times m}$ ,其中 $m$ 表示字典原子数目。

## 1.3 LRR获取初始检测结果

通常来说,HSI中大多数像素为背景像素,由于空间分辨率较低、地物种类少,背景像素之间存在很强的相关性,因此背景具有低秩性,而异常像素相比于背景像素只占少部分、发生概率低,在空间上具有稀疏性<sup>[24]</sup>,基于HSI如上特点,LRR模型可以用于异常检测。然而,由于HSI的光谱分辨率较高,大量的波段信

息在为检测、分类等任务带来便利的同时,也带来了大量的数据冗余、噪声等,所以有效地减少波段冗余和噪声,能够为后续处理带来便利。卷积神经网络通过多层非线性网络作用可以从复杂的数据中提取更具判别性的信息,所以本文通过3D-CAE来学习原始高维HSI在低维空间的流形结构,相比于原始图像空间,低维特征空间在保留原始图像空间结构的同时(即正常样本占据大多数,具有低秩属性,而异常样本稀疏分布在背景中),使得异常样本和背景样本更具判别性,进而更加容易区分。基于上述分析,本文通过在特征图像上进行LRR来分离出稀疏部分,并得到初始检测结果。

假设  $X_L \in \mathbb{R}^{b \times w}$  ( $W = M \times N$ , 表示特征图的像素个数) 表示由3D-CAE提取的特征图像,  $D = [d_1, d_2, \dots, d_m] \in \mathbb{R}^{b \times m}$  表示DBSCAN算法构建的字典,基于LRR模型的检测过程可描述为

$$X_L = DS + E \quad (5)$$

式中,  $DS$  表示背景部分,  $E \in \mathbb{R}^{b \times w}$  表示异常部分,  $S \in \mathbb{R}^{m \times w}$  是对应的系数矩阵。由于HSI的背景具有低秩性,而异常部分具有稀疏性,所以式(5)可以转化为以下优化问题

$$\min_{S, E} \text{rank}(S) + \lambda \|E\|_{2,1} \quad \text{s.t. } X_L = DS + E \quad (6)$$

式中,  $\text{rank}(\cdot)$  表示秩函数,  $\lambda > 0$  是调节参数,用来平衡低秩部分和稀疏部分,  $\|\cdot\|_{2,1}$  表示矩阵的  $l_{2,1}$  范数。公式(6)属于一个NP难的问题,通过文献<sup>[29]</sup>可以将其转化为以下优化问题。

$$\min_{S, E} \|S\|_* + \lambda \|E\|_{2,1} \quad \text{s.t. } X_L = DS + E \quad (7)$$

式中,  $\|\cdot\|_*$  表示矩阵核范数,当目标函数达到最优时,可以得到最优结果  $E^*$ 。具体求解过程可以参考文献<sup>[28]</sup>。

#### 1.4 异常检测

最终的异常检测结果由3D-CAE的重构误差和LRR分离出的异常部分检测结果共同决定,第  $i$  个像素的异常检测结果表示为

$$D(i) = (1 - \eta) R_i + \eta E_i \quad (8)$$

式中,  $\eta > 0$  为调节参数,本文中对于两个数据集设定  $\eta = 0.5$ ,  $R_i$  和  $E_i$  分别为重构误差和由LRR分离出来的异常部分检测结果,表示为

$$\begin{cases} R_i = 1 - e^{-r_i} \\ r_i = \frac{1}{B} \sum_{j=1}^B (X_i - \hat{X}_i)^2 \end{cases} \quad (9)$$

$$E_i = \|[E^*]_{:,i}\|_2 = \sqrt{\sum_k ([E^*]_{k,i})^2} \quad (10)$$

式中,  $X_i \in \mathbb{R}^{1 \times B}$  表示输入的第  $i$  个像素,  $\hat{X}_i \in \mathbb{R}^{1 \times B}$  表示对应的重构像素,  $\|[E^*]_{:,i}\|_2$  表示  $E^*$  第  $i$  列的  $l_2$  范数。

## 2 实验与讨论

为了验证所提算法的有效性,本文选取了两个常用的高光谱数据集进行实验分析,并与以下算法进行对比:RX、LRX、CRD、LRASR、DAEAD<sup>[31]</sup>和RC-LRaSMD<sup>[32]</sup>。不同算法的定量评价指标采用ROC曲线(Receiver Operating Characteristic, ROC)和ROC曲线下面积AUC值(Area Under Curve, AUC)。3D-CAE网络训练时,设置学习率为0.0001, BatchSize为128,当损失在连续5个epoch内下降小于0.0005时,提前停止训练以防止过拟合,同时为了公平对比,其他对比算法都优化到最佳结果。

### 2.1 数据集

实验所用两组高光谱影像来自于圣地亚哥飞机场数据(San Diego Airport Dataset),此数据集是由AVIRIS传感器获取的美国圣地亚哥飞机场,波长范围为370~2510 nm,空间分辨率为3.5 m,共有224个波段,空间大小为400×400像素,去除相应的水汽波段、低信噪比波段,用剩余的189个波段进行实验。

第一个实验数据(AVIRIS-1),选取原始数据左上角120×120大小区域,三架飞机作为异常目标,图2(a)和(b)分别为实验数据的伪彩色图和对应的标签。

第二个实验数据(AVIRIS-2),选取原始数据中心区域100×100像素,同样三架飞机作为异常目标,图

3(a)和(b)分别为实验数据的伪彩色图和对应的标签。




图2 AVIRIS-1数据集  
Fig. 2 The AVIRIS-1 dataset




图3 AVIRIS-2数据集  
Fig. 3 The AVIRIS-2 dataset

## 2.2 参数优化

本文方法有三种类型参数,包括3D-CAE损失函数中的调节参数 $\alpha$ 和 $\beta$ 、构造字典时DBSCAN算法中的 $\epsilon$ 和MinSample以及每一类选取原子的数目 $p$ 、求解LRR时式(8)中的 $\gamma$ 和 $\lambda$ 。为了简化参数分析,本文保留原始LRR求解过程中的 $\gamma$ 和 $\lambda$ 的设置,即 $\gamma = \lambda = 0.1$ ,然后分别对其它两类参数进行分析。

为了分析不同的 $\alpha$ 和 $\beta$ 对最终实验的影响,当固定 $\alpha = 1$ 时, $\beta$ 对最终检测结果的影响如图4所示,而图5展示了当 $\beta = 0.005$ ,不同取值的 $\alpha$ 对最终检测结果的影响。由图4可以看出,不同的 $\beta$ 对两个数据集的检测结果影响不大,而当 $\beta = 0.005$ 时,在两个数据集上具有较好的检测结果。由图5可以看出,随着 $\alpha$ 的变化,AVIRIS-1数据集的检测精度比较稳定,而AVIRIS-2数据集相对影响较大,当 $\alpha = 1$ 时,在两个数据集本文算法取得了最好的检测结果。

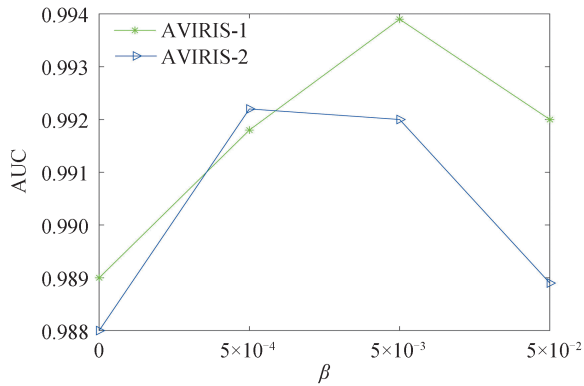


图4 当 $\alpha = 1$ 时,不同 $\beta$ 在两个数据集上的AUC值  
Fig. 4 The AUC value of two datasets under

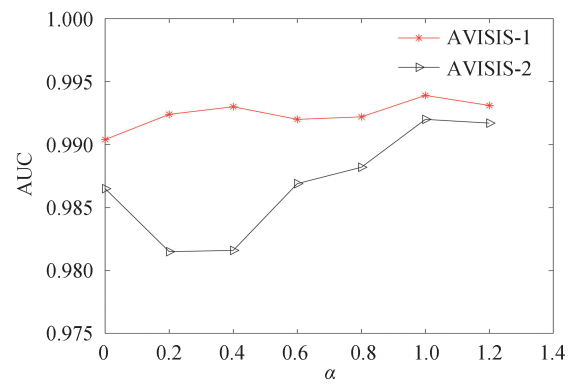


图5 当 $\beta = 0.005$ 时,不同 $\alpha$ 在两个数据集上的AUC值  
Fig. 5 The AUC value of two datasets under

为了分析 $\epsilon$ 、MinSample和 $p$ 对实验结果的影响,在两个数据集上固定 $\alpha = 1$ 、 $\beta = 0.005$ 、 $\gamma = \lambda = 0.1$ 。设定 $p$ 取 $\{8, 9, 10, 11, 12\}$ , $\epsilon$ 取 $\{0.01, 0.011, 0.012, 0.013, 0.014\}$ 、MinSample取 $\{8, 9, 10, 11, 12\}$ ,图6~图10分别表示 $p = 8$ 、 $p = 9$ 、 $p = 10$ 、 $p = 11$ 以及 $p = 12$ 时,两个数据集在不同 $\epsilon$ 和MinSample组合下的AUC值,图11表示当 $\epsilon = 0.012$ ,MinSample=10在不同 $p$ 值时两个数据集的AUC值。

实验发现,AVIRIS-1数据集对三个参数不敏感,检测精度比较稳定,当 $p = 8$ , $\epsilon = 0.012$ ,MinSample=12时,得最高的AUC值为0.9939;AVIRIS-2数据集对参数 $p$ 不敏感,但是易受另外两个参数影响,当 $p = 9$ , $\epsilon = 0.011$ ,MinSample=8时,取得最高的AUC值为0.9920。由于AVIRIS-1数据集对参数不敏感,为了与AVIRIS-2参数一致并且同时保证最终结果稳定,本文对所有数据集取 $p = 10$ , $\epsilon = 0.012$ ,MinSample=10,此时AVIRIS-1数据集的AUC值为0.9932,AVIRIS-2数据集AUC值为0.9914。

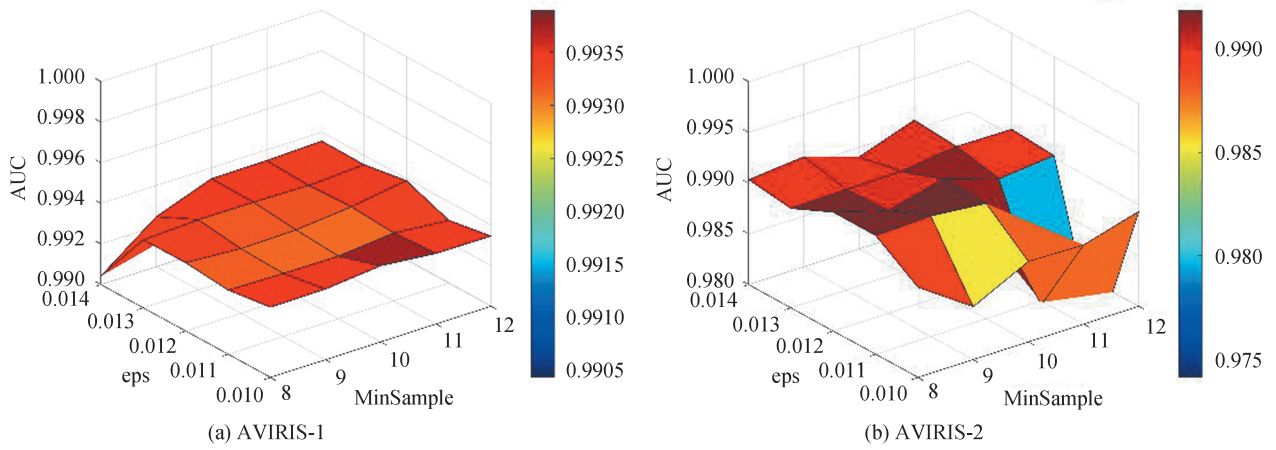


图 6  $p=8$  时, 两组数据在不同 eps 和 MinSample 组合下的 AUC 值  
 Fig. 6 The AUC value of two datasets under different eps and MinSample when  $p$  equal 8

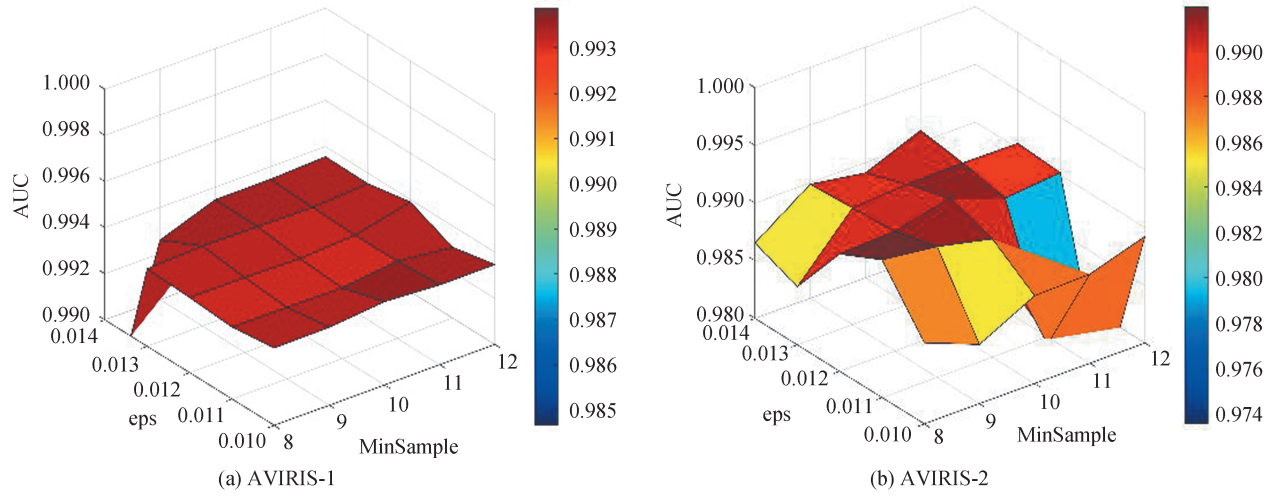


图 7  $p=9$  时, 两组数据在不同 eps 和 MinSample 组合下的 AUC 值  
 Fig. 7 The AUC value of two datasets under different eps and MinSample when  $p$  equal 9

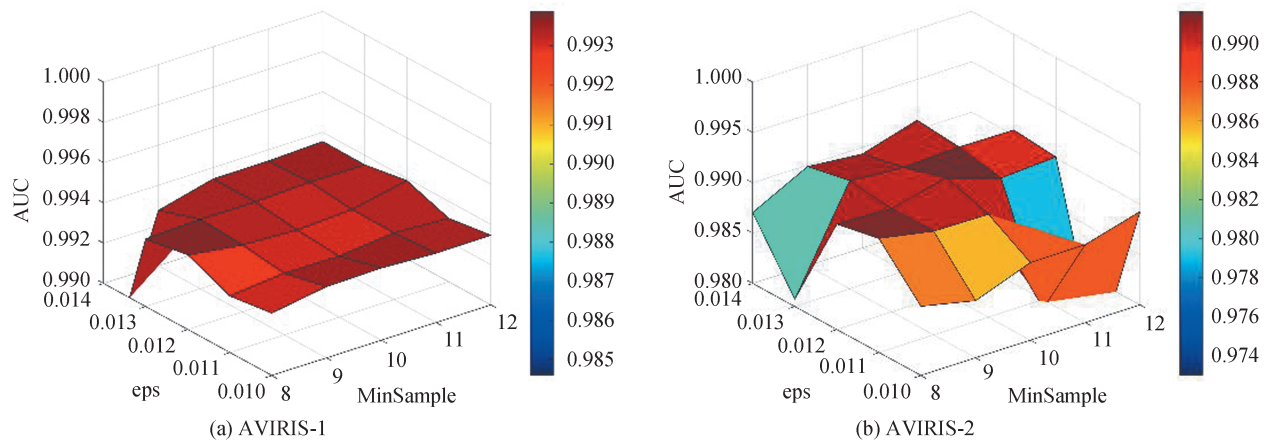


图 8  $p=10$  时, 两组数据在不同 eps 和 MinSample 组合下的 AUC 值  
 Fig. 8 The AUC value of two datasets under different eps and MinSample when  $p$  equal 10



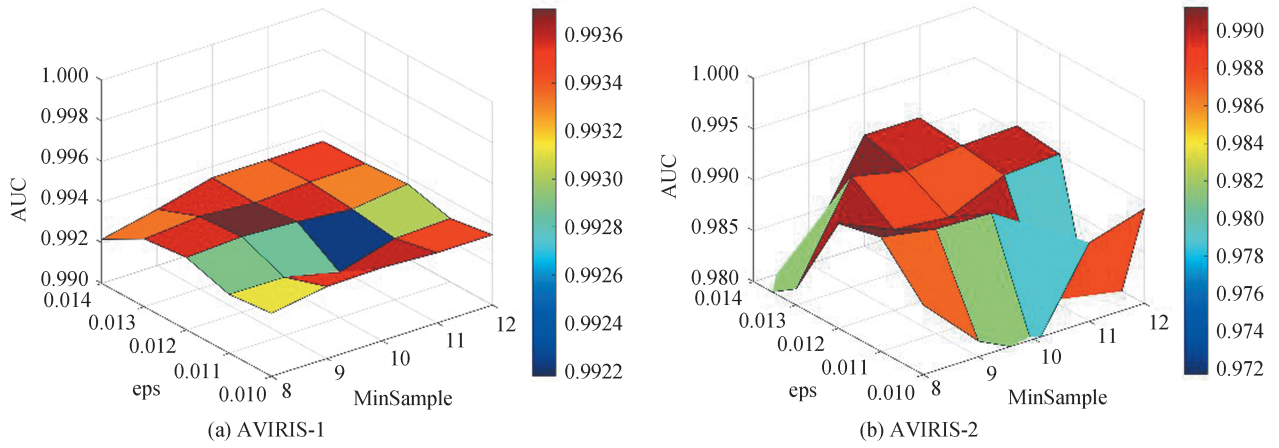


图 9  $p=11$  时,两组数据在不同 eps 和 MinSample 组合下的 AUC 值  
 Fig. 9 The AUC value of two datasets under different eps and MinSample when  $p$  equal 11

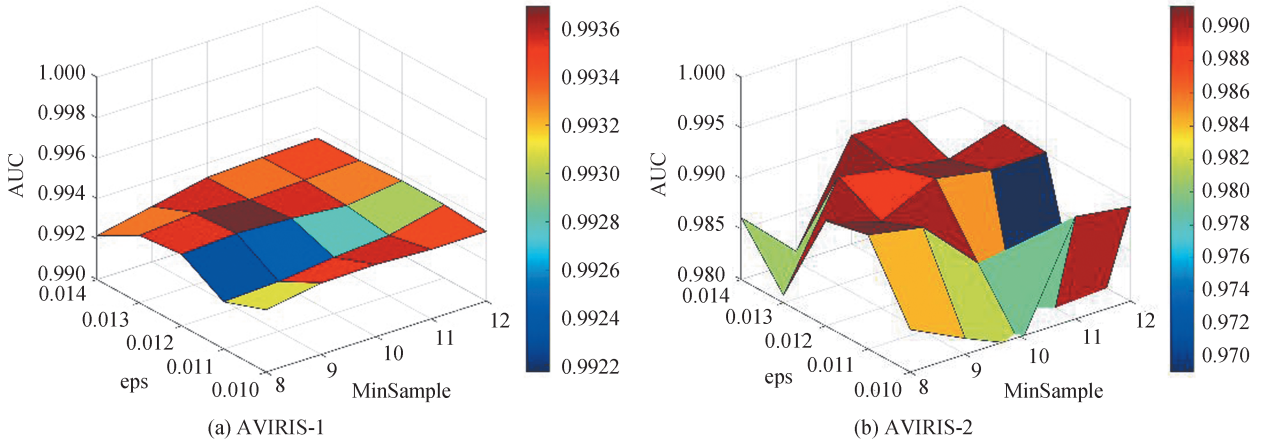


图 10  $p=12$  时,两组数据在不同 eps 和 MinSample 组合下的 AUC 值  
 Fig. 10 The AUC value of two datasets under different eps and MinSample when  $p$  equal 12




图 11 eps=0.012、MinSample=10 时两组数据在不同  $p$  值下的 AUC 值  
 Fig. 11 The AUC value of two datasets under different  $p$  when eps equal 0.012 and MinSample equal 10

### 2.3 异常检测结果和分析

以下列举了 6 种主流算法与本文提出的方法进行比较,其中 LRX 和 CRD 算法易受双窗口尺寸的影响,为了公平对比,我们让两种算法的内窗口尺寸从 3 变化到 39,外窗口从 5 变化到 55。对于 AVIRIS-1 数据集,LRX 和 CRD 的最优双窗口尺寸分别为 (13, 25) 和 (19, 23),在 AVIRIS-2 数据集上,LRX 和 CRD 最优双窗口尺寸分别为 (37, 55) 和 (19, 21)。

图 12 为 7 种算法在 AVIRIS-1 数据集上的检测结果。从图中可以看出, RX、LRX、CRD 以及 RC-LRaSMD 算法能够较好的抑制背景, 但是异常目标不能很好地检测出来, 尤其是 LRX 算法, 对于异常目标的响应很弱, 主要原因在于 AVIRIS-1 数据集相对较大, 所以背景信息更加复杂, 而 LRX 算法的检测精度很容易受到双窗口尺寸的影响。LRASR、DAEAD 以及本文算法都能很好的检测出异常目标, 但相比于其它两种方法, 所提算法检测出来的异常目标轮廓更加清晰, 而且与背景的可分性更高。因此, 对于 AVIRIS-1 数据集, 本文在抑制背景的同时, 能够精确的检测出异常目标。




图 12 AVIRIS-1 数据集各算法检测结果

Fig. 12 Detection results of various detection algorithms in AVIRIS-1 dataset

AVIRIS-2 数据集的检测结果如图 13 所示。LRX 和 CRD 算法能够很好的抑制背景, 但是对于异常目标的响应较弱, 主要原因在于 LRX 和 CRD 算法的检测精度依赖于双窗口尺寸的选取, 对于背景复杂的数




图 13 AVIRIS-2 数据集各算法检测结果

Fig. 13 Detection results of various detection algorithms in AVIRIS-2 dataset

据,双窗口中的像素易受异常像素和噪声的影响,其余算法都能够检测出异常目标,但是对于右下角的背景抑制不够好;相比而言,RC-LRaSMD算法和所提算法检测效果更好,RC-LRaSMD算法在抑制背景方面优于所提算法,但是相比于RC-LRaSMD算法,所提算法检测出的异常目标轮廓更加清晰,而且异常目标的响应值更高,所以获得了最高的AUC值。

图14和表2分别为各种算法在两个数据集上的ROC曲线和AUC值。ROC曲线越靠近左上方则检测效果越好、同时AUC值也越大。在两个数据集上,所提算法都取得了最高的AUC值。对于AVIRIS-1数据集,所提算法的ROC曲线几乎包括了所有曲线,说明了所提算法在抑制背景和检测异常目标方面优于所有对比算法;对于AVIRIS-2数据集,由于RC-LRaSMD算法能够有效抑制背景信息,所以虚警率较低,但是当虚警率大于 $10^{-2}$ 时,本文算法明显优于RC-LRaSMD算法。综合而言,在两个数据集上,相比于其它检测算法,本文所算法具有较好的检测结果。

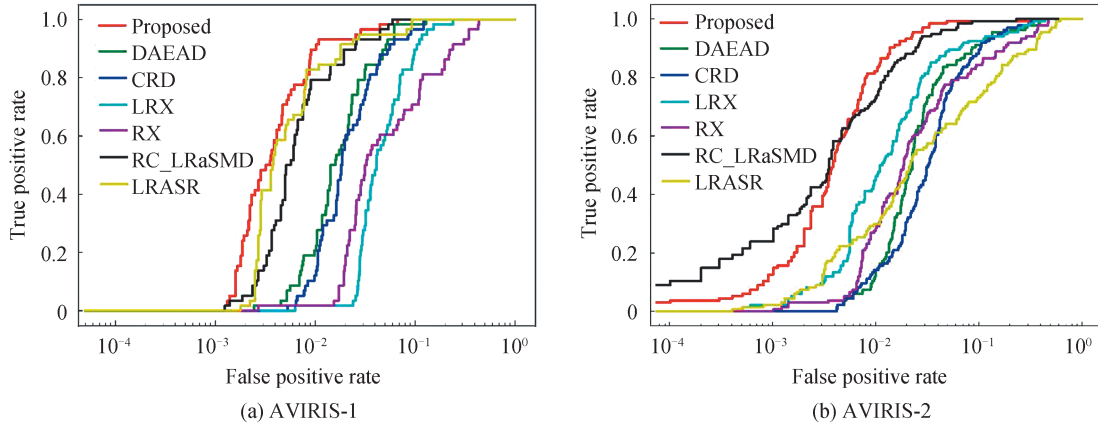


图14 两组数据集的ROC曲线  
Fig. 14 ROC curves of two datasets

表2 不同算法在两个数据集上的AUC值  
Table 2 The AUC value of different methods in two datasets

Dataset	RXW	WLRX <sub>4</sub>	CRD	LRASR	DAEAD	RC-LRaSMD	Proposed
AVIRIS-1	0.911 1	0.944 5	0.972 5	0.989 6	0.977 4	0.989 9	0.993 2
AVIRIS-2	0.940 3	0.967 5	0.951 2	0.909 6	0.957 3	0.990 1	0.991 4

## 2.4 消融实验结果分析

为了验证本文所提损失函数以及各个步骤的有效性,我们做了如下消融实验,其中3D-Conv表示3D卷积,RE表示由3DCAE生成的重构误差,MSE表示损失函数为均方误差。表3中的①表示直接在3DCAE提取的潜在特征上用RX算法得到的检测结果,②表示在潜在特征上由LRR检测得到的初始结果,③表示将构建字典的算法换成K-means算法的检测结果,④表示当训练的损失函数采用均方误差时得到的检测结果,⑤是本文算法框架的完整步骤。具体结果如表3所示。

①和②相比,可以看出在本文算法框架下LRR相比于RX更有效,尤其在AVIRIS-1数据集上,能够显

表3 分析不同步骤对本文算法结果的影响  
Table 3 Analysis of the results of different steps of the Proposed algorithm

Method	AVIRIS-1(AUC)	AVIRIS-2(AUC)
① 3D-Conv+RX	0.954 0	0.962 2
② 3D-Conv+LRR	0.991 6	0.988 9
③ 3D-Conv+LRR(K-means)+RE	0.990 8	0.990 1
④ 3D-Conv(MSE)+LRR+RE	0.977 2	0.977 4
⑤ 3D-Conv+LRR+RE	0.993 2	0.991 4

著提高最终检测结果,需要指出的是,相比于原始的RX算法,在由3DCAE提取的潜在特征上使用RX算法获得了更高的AUC值,同样在潜在特征上使用LRR也优于原始LRASR算法,能够说明3D卷积对最终检测精度的正面作用。由②和⑤可以看出,融合由3DCAE得到的重构误差能够进一步提高检测精度,这也说明了重构误差能够反映背景和异常的重构情况,相比于异常区域,背景区域具有较小的重构误差。③和⑤相比可以看出,当聚类算法采用DBSCAN时,能够获取更高的AUC值,这说明在本文算法框架下,DBSCAN算法更适合构造背景字典。④和⑤相比,可以看出本文所提损失函数的有效性,也反映出待检测像素与周围像素具有一定的相关性,而探索这种相关性能够提高异常检测精度。

### 3 结论

3D卷积能够同时提取空间和光谱信息,有效提高了异常检测目标的特征提取。本文基于3D卷积,利用AE结构来进行无监督特征提取,同时结合LRR来进行异常检测。为了验证所提算法的有效性,我们在两个常用的真实高光谱数据集上同6种异常检测算法进行对比分析,实验结果表明,在两个数据集上与其它算法相比,本文算法取得了最好的检测结果。同时为了验证本文所提损失函数以及各个步骤对最终检测结果的影响,我们做了对应的参数分析实验和消融实验,实验结果表明,DBSCAN算法的两个主要参数对构造字典具有较大影响,而消融实验结果表明,本文算法框架的每一步都能提高最终检测精度,也证明了将3D卷积和LRR结合起来的合理性。另外,本文算法仍有一些不足,比如超参数太多等问题,在未来工作中,我们将简化模型参数,提高模型的鲁棒性,并测试更多的数据集来进一步探索3D卷积在异常检测方面的应用。

#### 参考文献

- [1] ZHANG Xing, WEN Gongjian, DAI Wei. A tensor decomposition-based anomaly detection algorithm for hyperspectral image[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10): 5801-5820.
- [2] Reed S, YU Xiaoli. 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] MOLERO J, GARZON E, GARCIA I, et al. Analysis and optimizations of global and local versions of the RX algorithm for anomaly detection in hyperspectral data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2013, 6(2): 801-814.
- [4] GUO Qiandong, ZHANG Bing, RAN Qiong, et al. Weighted-RXD and linear filter-based RXD: Improving background statistics estimation for anomaly detection in hyperspectral imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2351-2366.
- [5] KWON H, NASRABADI N. Kernel RX-algorithm: a nonlinear anomaly detector for hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 43(2): 388-397.
- [6] LI Wei, DU Qian. Collaborative representation for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(3): 1463-1474.
- [7] MA Ning, PENG Yu, WANG Shaojun. A fast recursive collaboration representation anomaly detector for hyperspectral image[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 16(4): 588-592.
- [8] SU Hongjun, WU Zhaoyue, DU Qian, et al. Hyperspectral anomaly detection using collaborative representation with outlier removal[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(12): 1-10.
- [9] LI Jiayi, ZHANG Hongyan, ZHANG Liangpei, et al. Hyperspectral anomaly detection by the use of background joint sparse representation[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(6): 2523-2533.
- [10] LI Shuangjiang, WANG Wei, QI Hairong, et al. Low-rank tensor decomposition based anomaly detection for hyperspectral imagery[C]. 2015 IEEE International Conference on Image Processing, 2015, 4525-4529.
- [11] WANG Wei, LI Shuangjiang, QI Hairong, et al. Identify anomaly component by sparsity and low rank[C]. 2015 IEEE 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 2015, 7(6): 1-4.
- [12] ZHANG Yuxiang, DU Bo, ZHANG Liangpei, 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*, 2015, 54(3): 1376-1389.
- [13] SONG Shangzhen, ZHOU Huixin, YANG Yixin, 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.
- [14] QU Ying, WANG Wei, GUO Rui, et al. Hyperspectral anomaly detection through spectral unmixing and dictionary-

- based low-rank decomposition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(8): 4391-4405.
- [15] DU Qian, LI Wei, WU Guodong. Transferred deep learning for anomaly detection in hyperspectral imagery[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(5): 597-601.
- [16] MA Ning, PENG Yu, WANG Shaojun, et al. An unsupervised deep hyperspectral anomaly detector[J]. *Sensors*, 2018, 18(3): 693.
- [17] ZHAO Chunhui, LI Xueyuan, ZHU Haifeng. Hyperspectral anomaly detection based on stacked denoising autoencoders[J]. *Journal of Applied Remote Sensing*, 2017, 11(4): 042605
- [18] ZHAO Chunhui, ZHANG Lili. Spectral-spatial stacked autoencoders based on low-rank and sparse matrix decomposition for hyperspectral anomaly detection[J]. *Infrared Physics & Technology*, 2018, 92: 166-176.
- [19] LEI Jie, XIE Weiyang, YANG Jian, et al. Spectral-spatial feature extraction for hyperspectral anomaly detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(10): 8131-8143.
- [20] JI Shuiwang, XU Wei, YANG Ming, et al. 3D convolutional neural networks for human action recognition[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2012, 35(1): 221-231.
- [21] MEI Shaohui, JI Jingyu, GENG Yunhao, et al. Unsupervised spatial-spectral feature learning by 3d convolutional autoencoder for hyperspectral classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(9): 6808-6820.
- [22] SHI Yanzi, LI Jiaojiao, YIN Yaping, et al. Hyperspectral target detection with macro-micro feature extracted by 3-D residual autoencoder[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2019, 12(12): 4907-4919.
- [23] ESTER M, KRIEGER H, SANDER J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise[J]. In *Kdd*, 1996, 9634: 226-231.
- [24] ZHANG Xiaohu, ZOU Yuexian, SHI Wei. Dilated convolution neural network with LeakyReLU for environmental sound classification[C]. In *2017 22nd International Conference on Digital Signal Processing*, 1-5.
- [25] YANG Qingsong, YAN Pingkun, ZHANG Yanbo, et al. Low-dose CT image denoising using a generative adversarial network with Wasserstein distance and perceptual loss[J]. *IEEE transactions on medical imaging*, 2018, 37(6): 1348-1357.
- [26] KRUSE F, LEFKOFF A, BOARDMAN W, et al. The spectral image processing system (SIPS) -interactive visualization and analysis of imaging spectrometer data[C]. In *AIP Conference Proceedings*, 1993, 283(1): 192-201.
- [27] LI Ailin, SHANG Zhaowei. A new spectral-spatial pseudo-3d dense network for hyperspectral image classification[C]. *2019 International Joint Conference on Neural Networks (IJCNN)*, IEEE, 2019: 1-7.
- [28] XU Yang, WU Zebin, LI Jun, 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.
- [29] CANDÈS E, LI Xiaodong, MA Yi, et al. Robust principal component analysis? [J]. *Journal of the ACM (JACM)*, 2011, 58(3): 1-37.
- [30] SUN Weiwei, LIU Chun, LI Jialin, et al. Low-rank and sparse matrix decomposition-based anomaly detection for hyperspectral imagery[J]. *Journal of Applied Remote Sensing*, 2014, 8(1): 083641.
- [31] TAGHIPOUR A, GHASSEMIAN H. Unsupervised hyperspectral target detection using spectral residual of deep autoencoder networks[C]. In *2019 4th International Conference on Pattern Recognition and Image Analysis (IPRIA)*, IEEE, 2019: 52-57.
- [32] MA Yong, FAN Ganghui, JIN Qiwen, et al. Hyperspectral anomaly detection via integration of feature extraction and background purification[J/OL]. *IEEE Geoscience and Remote Sensing Letters*, DOI: 10.1109/LGRS.2020.2998809.