




JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象学报 图形学报

2022
10
VOL.27

ISSN1006-8961
CN11-3758/TB



图像数据受限



第27卷第10期（总第318期）
2022年10月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 吴一戎
编辑出版 《中国图象图形学报》编辑出版委员会
通信地址 北京市海淀区北四环西路19号
邮 编 100190
电子信箱 jig@aircas.ac.cn
电 话 010-58887035
网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱: 北京399信箱 邮编: 100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian | Monthly, Started in 1996


Superintended by Chinese Academy of Sciences
Sponsored by Aerospace Information Research Institute, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong
Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics
Address No. 19, North 4th Ring Road West, Haidian District, Beijing, P. R. China
Zip code 100190
E-mail jig@aircas.ac.cn
Telephone 010-58887035
Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China)
Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ


国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



MRI脑肿瘤图像的超像素/体素分割及发展现状(第2897页)



融合多尺度特征与全局上下文信息的X光违禁物品检测(第3043页)



融合多尺度旋转锚机制的海洋中尺度涡自动检测(第3092页)

图像数据受限

《中国图象图形学报》图像数据受限专栏简介

刘怡光, 孙显, 赵启军, 魏秀参, 王琦, 陈秀妍 2801

数据受限条件下的多模态处理技术综述

王佩瑾, 闫志远, 容雪娥, 李俊希, 路晓男, 胡会扬, 严启炜, 孙显 2803

图像数据受限下的处理与分析

刘怡光 2835

面向跨模态行人重识别的单模态自监督信息挖掘

吴岸聪, 林城桔, 郑伟诗 2843

小样本条件下的RGB-D显著性物体检测

何静, 傅可人 2860

综述

面向目标检测的对抗样本综述

袁珑, 李秀梅, 潘振雄, 孙军梅, 肖蕾 2873

MRI脑肿瘤图像的超像素/体素分割及发展现状

方玲玲, 王欣 2897

图网络层级信息挖掘分类算法综述

魏文超, 蔺广逢, 廖开阳, 康晓兵, 赵凡 2916

个性化图像美学评价的研究进展与趋势

祝汉城, 周勇, 李雷达, 赵佳琦, 杜文亮 2937

视盘和视杯分割在计算机辅助青光眼诊断中的应用综述

方玲玲, 张丽榕 2952

图像处理和编码

多监督损失函数光滑化图像超分辨率重建

孟志青, 张晶, 邱健数 2972

轻量级注意力约束对齐网络的视频超分重建

靳雨桐, 宋慧慧, 刘青山 2984

面向图像修复的增强语义双解码器生成模型

王倩娜, 陈焱 2994

图像分析和识别

动态模态交互和特征自适应融合的RGBT跟踪

王福田, 张淑云, 李成龙, 罗斌 3010

采用Transformer网络的视频序列表情识别

陈港, 张石清, 赵小明 3022

对抗型半监督光伏面板故障检测

卢芳芳, 牛然, 杜海舟, 杨振辰, 陈菁菁 3031

融合多尺度特征与全局上下文信息的X光违禁物品检测

李晨, 张辉, 张邹铨, 车爱博, 王耀南 3043

高速公路场景的车路视觉协同行车安全预警算法

汪长春, 高尚兵, 蔡创新, 陈浩霖 3058

结合卷积神经网络与曲线拟合的人体尺寸测量

马燕, 殷志昂, 黄慧, 张玉萍 3068

医学图像处理

U-Net支气管超声弹性图像纵膈淋巴结分割

刘羽, 吴蓉蓉, 唐璐, 宋宁宁 3082

遥感图像处理

融合多尺度旋转锚机制的海洋中尺度涡自动检测

杜艳玲, 刘倩倩, 王丽丽, 徐鑫, 魏泉苗, 宋巍 3092

集成注意力机制和扩张卷积的道路提取模型

王勇, 曾祥强 3102

空域协同自编码器的高光谱异常检测


樊港辉, 马泳, 梅晓光, 黄珺, 樊凡, 李峰 3116

自适应权重金字塔和分支强相关的SAR图像舰船检测


郭伟, 申磊, 曲海成, 王雅萱, 林畅 3127

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



The review of superpixel/voxel segmentation of MRI brain tumor images(P2897)



Integrated multi-scale features and global context in x-ray detection for prohibited items(P3043)



Multi-scale rotating anchor mechanism based automatic detection of ocean mesoscale eddy(P3092)

Limited Image Data

Review of multimodal data processing techniques with limited data

Wang Peijin, Yan Zhiyuan, Rong Xuee, Li Junxi, Lu Xiaonan, Hu Huiyang, Yan Qiwei, Sun Xian ... 2803

The processing and analyzing derived of limited image data

Liu Yiguang 2835

Single-modality self-supervised information mining for cross-modality person re-identification

Wu Ancong, Lin Chengzhi, Zheng Weishi 2843

RGB-D salient object detection of using few-shot learning

He Jing, Fu Keren 2860

Review

Review of adversarial examples for object detection

Yuan Long, Li Xiumei, Pan Zhenxiong, Sun Junmei, Xiao Lei 2873

The review of superpixel/voxel segmentation on MRI brain tumor images

Fang Lingling, Wang Xin 2897

Survey of graph network hierarchical information mining for classification

Wei Wenchao, Lin Guangfeng, Liao Kaiyang, Kang Xiaobing, Zhao Fan 2916

The review of personalized image aesthetics assessment

Zhu Hancheng, Zhou Yong, Li Leida, Zhao Jiaqi, Du Wenliang 2937

The review of optic disc and optic cup segmentation applications in computer-aided glaucoma diagnosis

Fang Lingling, Zhang Lirong 2952

Image Processing and Coding

Multi-supervision loss function based smoothed super-resolution image reconstruction

Meng Zhiqing, Zhang Jing, Qiu Jianshu 2972

Super-resolution Video frame reconstruction through lightweight attention constraint alignment network

Jin Yutong, Song Huihui, Liu Qingshan 2984

Enhanced semantic dual decoder generation model for image inpainting

Wang Qianna, Chen Yi 2994

Image Analysis and Recognition

RGBT tracking based on dynamic modal interaction and adaptive feature fusion

Wang Futian, Zhang Shuyun, Li Chenglong, Luo Bin 3010

Video sequence-based human facial expression recognition using Transformer networks

Chen Gang, Zhang Shiqing, Zhao Xiaoming 3022

Generative adversarial networks based semi-supervised fault detection for photovoltaic panel

Lu Fangfang, Niu Ran, Du Haizhou, Yang Zhenchen, Chen Jingjing 3031

Integrated multi-scale features and global context in x-ray detection for prohibited items

Li Chen, Zhang Hui, Zhang Zouquan, Che Aibo, Wang Yaonan 3043

Vehicle-road visual cooperative driving safety early warning algorithm for expressway scenes

Wang Changchun, Gao Shangbing, Cai Chuangxin, Chen Haolin 3058

The convolution neural network and curve fitting based human body size measurement

Ma Yan, Yin Zhiang, Huang Hui, Zhang Yuping 3068

Medical Image Processing

U-Net-based mediastinal lymph node segmentation method in bronchial ultrasound elastic images

Liu Yu, Wu Rongrong, Tang Lu, Song Ningning 3082

Remote Sensing Image Processing

Multi-scale rotating anchor mechanism based automatic detection of ocean mesoscale eddy

Du Yanling, Liu Qianqian, Wang Lili, Xu Xin, Wei Quanmiao, Song Wei 3092

Road extraction model derived from integrated attention mechanism and dilated convolution

Wang Yong, Zeng Xiangqiang 3102

Spatial-coordinated autoencoder for hyperspectral anomaly detection

Fan Ganghui, Ma Yong, Mei Xiaoguang, Huang Jun, Fan Fan, Li Hao 3116

Ship detection in SAR images based on adaptive weight pyramid and branch strong correlation

Guo Wei, Shen Lei, Qu Haicheng, Wang Yaxuan, Lin Chang 3127

中图法分类号: TP751.1 文献标识码: A 文章编号: 1006-8961(2022)10-3116-11

论文引用格式: Fan G H, Ma Y, Mei X G, Huang J, Fan F and Li H. 2022. Spatial-coordinated autoencoder for hyperspectral anomaly detection. Journal of Image and Graphics, 27(10): 3116-3126 (樊港辉, 马泳, 梅晓光, 黄珺, 樊凡, 李皞. 2022. 空域协同自编码器的高光谱异常检测. 中国图象图形学报, 27(10): 3116-3126) [DOI: 10.11834/jig.210246]

空域协同自编码器的高光谱异常检测

樊港辉¹, 马泳^{1,2}, 梅晓光^{1,2*}, 黄珺^{1,2}, 樊凡^{1,2}, 李皞³

1. 武汉大学电子信息学院, 武汉 430072; 2. 武汉大学宇航科学与技术研究院, 武汉 430079;
3. 武汉轻工大学数学与计算机学院, 武汉 430023

摘要: **目的** 自编码器作为一种无监督的特征提取算法,可以在无标签的条件下学习到样本的高阶、稠密特征。然而当训练集含噪声或异常时,会迫使自编码器学习这些异常样本的特征,导致性能下降。同时,自编码器应用于高光谱图像处理时,往往会忽略掉空域信息,进一步限制了自编码器的探测性能。针对上述问题,本文提出一种基于空域协同自编码器的高光谱异常检测算法。**方法** 利用块图模型优良的背景抑制能力从空域角度筛选用于自编码器训练的背景样本集。自编码器采用经预筛选的训练样本集进行网络参数更新,在提升对背景样本表达能力的同时避免异常样本对探测性能的影响。为进一步将空域信息融入探测结果,利用块图模型得到的异常响应构建权重,起到突出目标并抑制背景的作用。**结果** 实验在3组不同尺寸的高光谱数据集上与5种代表性的高光谱异常检测算法进行比较。本文方法在3组数据集上的AUC(area under the curve)值分别为0.990 4、0.988 8和0.997 0,均高于其他算法。同时,对比了不同的训练集选择策略,与随机选取和使用全部样本进行对比。结果表明,本文基于空域响应的样本筛选方法相对对比方法具有较明显的优势。**结论** 提出的基于空域协同自编码器的高光谱异常检测算法从空域角度筛选样本以提升自编码器区分异常与背景的能力,同时融合了光谱域和空域信息,进一步提升了异常检测性能。

关键词: 高光谱图像(HSI); 异常检测; 块图模型; 自编码器(AE); 空谱特征融合

Spatial-coordinated autoencoder for hyperspectral anomaly detection

Fan Ganghui¹, Ma Yong^{1,2}, Mei Xiaoguang^{1,2*}, Huang Jun^{1,2}, Fan Fan^{1,2}, Li Hao³

1. Electronic Information School, Wuhan University, Wuhan 430072, China; 2. Institute of Aerospace Science and Technology, Wuhan University, Wuhan 430079, China; 3. College of Mathematics and Computer Science, Wuhan Polytechnic University, Wuhan 430023, China

Abstract: **Objective** Hyperspectral imagery (HSI) consists of hundreds of narrow spectral bands and provides richer spectral information than infrared and multispectral images. Its features can distinguish targets from the background, and has been widely applied in many remote-sensing tasks, such as intelligent agriculture and mineral exploration. In many circumstance, however, targets are hard to be detected because of the existed prior spectral information is related to the background or targets. Anomaly detection can detect potential targets that differ from the surrounding background in an unsupervised manner. Anomalies focus on small scaled manual objects embedded in the surrounding background, and they differ

收稿日期: 2021-04-13; 修回日期: 2021-06-10; 预印本日期: 2021-06-17

* 通信作者: 梅晓光 meixiaoguang@gmail.com

基金项目: 国家自然科学基金项目(61903279); 湖北省自然科学基金项目(2019CFB162, 2018CFA006)

Supported by: National Natural Science Foundation of China (61903279); Natural Science Foundation of Hubei Province, China (2019CFB162, 018CFA006)

from the background in terms of spectral information. As a typical unsupervised non-linear feature extractor, autoencoder (AE) contexts are applied in hyperspectral anomaly detection tasks. AE-based anomaly detection framework is getting more and more attention and many algorithms are developed to improve the detection performance. However, those AE-based anomaly detectors are hard to distinguish anomalies from the background due to lots of noise or outliers in training set. To minimize the objective function, the AE tends to learn the features of these noise and outliers. We facilitate spatial-coordinated autoencoder (ScAE) tackle these two issues mentioned above. **Method** Thanks to infrared patch-image model in suppressing the background and highlighting weak targets, a patch-image model is designed for hyperspectral images to be introduced in ScAE. Specifically, the patches are extended to form a matrix based on the first three components of HSI, the low-rank and sparse matrix decomposition (LRaSMD) is developed. The sparse part contains the target information and the background is suppressed. Thus, the training samples are opted based on the response of the decomposed sparse part, pixels with lower values and vice versa. The picked training samples are more clearly than utilizing the entire dataset or random selection strategy, and these samples are employed to update the weights of AE networks. The traditional gradients descend method and the backward propagation strategy is used to fine-tune AE. After some iterations, the vanilla AE is upgraded to be an effective hyperspectral anomaly detector. The reconstruction residual is utilized as the criterion to determine whether a pixel under the test (PUT) is anomalous or not. In order to take full advantage of the spatial information, a spatial-responses non-negative weight of patch-image model is introduced to increase the discrimination between the background and anomalies further, and the final detection result is obtained via fusing the spectral result and the weight matrix with Hadamard product. **Result** We evaluate our ScAE detector on three challenging hyperspectral image datasets with different size, namely Sandiego-1, Sandiego-2 and Botanical Garden. First, we design a set of experiment to figure out the issue of influential parameters for the final detection result. There are three parameters which are closely related with the detection performance. After extensive experiments, we found that ScAE is cohesive to the trade-off parameter and patch-related parameter, but is less to the number of hidden layers. Then, we conduct an ablation study to clarify the feasibility of the ScAE framework. The detection performance illustrates that patch-image model is optimal in suppressing the background while highlighting weak anomalies compared to attribute filter (AF). Our selection strategy gains higher area under the curve (AUC) values than randomly selection strategy. It is worth noting that a weight matrix related spatial and spectral information fusion can improve the detection result, as AUC values demonstrated. Finally, we compare our ScAE detector to three classical anomaly detectors and two popular hyperspectral anomaly detector, namely global Reed-Xiaoli (GRX), LRaSMD-based Mahalanobis distance method (LSMAD), traditional AE, fractional Fourier entropy (FrFE) and feature extraction and background purification anomaly detector (FEBPAD), respectively. Such parameters are set to get optimal detection performance for the six detectors all. The corresponding AUC values of ScAE are 0.990 4, 0.988 8 and 0.997 0 for Sandiego-1, Sandiego-2 and Botanical Garden, respectively. The detection result illustrates that ScAE obtains the highest AUC values amongst the six hypersepctral anomaly detectors. Moreover, ScAE generates the lowest false alarm rate (FAR) when all of the anomalous pixels are detected in three datasets all. **Conclusion** A novel AE-based hyperspectral anomaly detection algorithm is developed that spectral-detected spatial information can enhance the segmentation ability between anomalies and the background. The comparative experiments demonstrate our ScAE detector has its feasibility and potentials for hyperspectral anomaly detection.

Key words: hyperspectral imagery (HSI); anomaly detection; patch-image model; autoencoder (AE); spatial-spectral feature fusion

0 引言

高光谱图像(hyperspectral imagery, HSI)是由上百幅窄波段图像堆叠而成的3维立方体,包含比红外和多光谱图像更为丰富的光谱信息,广泛应用

于矿物探测、农业和国防(Ma等,2019;Mei等,2019;刘康等,2020)等领域。异常检测是高光谱遥感探测领域中的一个重要组成部分,目的在于能自动搜寻场景中潜在的目标,尤其在目标的光谱特性无法获取的场景下具有十分重要的研究意义和实用价值。

对高光谱异常检测的算法大致分为基于统计的

方法和基于表示的方法两类。基于统计的方法(Reed 和 Yu, 1990; 李普煌 等, 2018)从概率统计的角度对背景进行建模, 通过计算各样本点与模型分布的拟合程度判断是否为异常样本。基于表示的方法(Xu 等, 2016; 朱德辉 等, 2020)针对背景和异常各自的特点, 通过优化理论求解满足这些特点的矩阵, 从而分离出异常。这两类方法模型简单、易于理解, 探测效果较好且计算量较小, 但仍存在以下问题: 1) 算法的探测效果取决于模型假设是否符合真实场景的统计分布, 当不相符时会导致模型失效(Imani, 2017); 2) 只利用了原始数据的浅层特征(如均值、协方差矩阵等), 没有利用更深层次的特征。此外, Chang 等人(2019)指出波段冗余现象, 尤其对于高维数据, 会进一步降低异常与背景之间的可分性。高光谱数据一般包含上百波段, 数据冗余导致的异常探测性能下降效应尤为明显。

自编码器(autoencoder, AE)作为一种无监督的神经网络模型, 通过最小化重构误差获得更抽象、深层的特征, 已成功应用于高光谱图像处理相关领域(Su 等, 2019; Shi 等, 2019)。在高光谱异常检测方面, 自编码器更倾向于学习到能代表背景样本的低维特征, 而忽略小部分代表异常的样本, 故可通过样本重构误差对样本分类。然而, 高光谱图像不仅包含光谱信息, 同时也包含空间信息, 具有图谱合一的特点。上述方法只利用了高光谱图像数据的光谱维, 而抛弃了目标像素间的空间关系, 限制了算法的探测性能。针对以上问题, 学者对 AE 进行改进。Lu 等人(2020)鉴于流形能保持相似样本之间在低维子空间的相似性, 将流形约束嵌入到 AE 的损失函数中, 从而保证 AE 学到的低维表示能保持原数

据之间的相似性关系。Xie 等人(2019)基于光谱约束下的对抗自编码器, 利用像素点的 8 邻域表示该数据点, 并利用对抗自编码器重构原始数据样本, 通过重构误差筛选出场景中可能存在的异常。上述方法在一定程度上利用了图像的空间信息, 提高了算法在高光谱异常检测方面的性能, 但对噪声较为敏感, 对微弱目标的检测能力不高。同时, 绝大多数基于 AE 的异常检测算法将整幅高光谱图像视为训练样本, 可能致使 AE 学习到异常的一些特征, 不能很好地分离出异常。

鉴于上述分析, 本文提出一种基于空域协同自编码器的高光谱异常检测算法, 框架如图 1 所示。首先, 为了引入空域信息, 借助块图模型以突出弱小目标。具体来说, 通过主成分分析(principal component analysis, PCA)对原始图像进行降维处理并分块展开, 利用低秩稀疏矩阵分解算法得到稀疏部分, 经重构得到异常检测的空间响应 D_1 。在光谱域上, 为了给 AE 提供更纯净的背景训练集, 将 D_1 得到的先验探测结果用于指导纯净样本集的构建, 经筛选构建出的训练集更适合于高光谱异常检测任务。由该样本集训练 AE 得到光谱域的探测结果 D_2 。为了将空域信息融合进探测结果, 利用 D_1 构建了一种加权方式, 进一步突出目标、抑制背景, 得到最终探测结果 D 。本文的创新点主要体现在: 1) 针对 AE 模型存在的对训练集的强噪声和异常样本敏感问题, 提出从空域角度筛选并构建样本集的策略。引入红外图像处理中的块图模型以抑制背景, 保证构建样本集内尽可能只包含背景而不包含异常。2) 设计了一种非负权重以进一步抑制背景, 该权重在保留异常响应的同时惩罚背景响应。同时, 该非负




图1 本文算法流程图

Fig. 1 Flowchart of the proposed algorithm

权重还将空域信息引入到最终的探测结果,增大了异常与背景之间的区分度,进一步提升了自编码器算法的异常检测性能。

1 本文算法

1.1 自编码器

自编码器作为一种无监督特征提取算法,由多层神经网络组成,包含 1 个输入层、1 个输出层及若干隐含层。在高光谱异常检测任务中,由于样本数较少,为防止过拟合,本文设置隐含层层数为 1,隐含层节点个数为 n_{hid} 。从高光谱数据立方体 $\mathbf{X} \in \mathbf{R}^{M \times N \times L}$ 中选取光谱数据 $\mathbf{x}$,其中 M 、 N 和 L 分别为高光谱图像的长、宽及波段数。编码阶段将原始数据 $\mathbf{x}$ 压缩为更本质的低维特征 $\mathbf{z}$,解码阶段则根据 $\mathbf{z}$ 重构原始数据 $\hat{\mathbf{x}}$ 。其数学表达式为

$$\begin{aligned} \mathbf{z} &= g^{(1)}(\mathbf{W}^{(1)}\mathbf{x} + \mathbf{b}^{(1)}) \\ \hat{\mathbf{x}} &= g^{(2)}(\mathbf{W}^{(2)}\mathbf{z} + \mathbf{b}^{(2)}) \end{aligned} \quad (1)$$

式中, $\mathbf{W}$ 和 $\mathbf{b}$ 分别为自编码器的权重和偏置, $g(\cdot)$ 为某种非线性激活函数,本文设置为 sigmoid 函数。在训练阶段,以重构误差为代价函数,利用梯度下降法及反向传播算法更新权重及偏置参数,直至满足迭代终止条件。在测试阶段,由于 AE 学习占比更大的背景的特征,对异常的重构结果通常较差。因此,可以利用重构误差作为准则判断某输入样本是否属于异常。然而,传统的基于 AE 的异常检测算法利用所有样本构建训练集,其中包含异常样本。因此,为进一步降低残差,自编码器会学习异常样本的特征,从而降低背景和异常之间的区分度。同时,传统的 AE 没有考虑高光谱图像的图谱合一特性,丢失了空域信息,进一步限制了算法的性能。

1.2 块图模型

针对传统自编码器存在的上述问题,本文提出从空域的角度筛选纯净背景像元的策略。由于背景存在非局部自相似性,而目标具有稀疏特性。Gao 等人(2013)利用红外图像数据具有的这种结构,提出红外块图(infrared-patch image, IPI)模型,将红外小目标检测问题转化为低秩稀疏矩阵的求解问题。实验表明, IPI 模型在信杂比增益(gain of signal-to-clutter ratio, GSCR)和背景抑制因子(background suppress factor, BSF)两个指标上明显优于传统红外小目标检测算法,如最大中值滤波器、局部对比度方

法等(王好贤 等,2019)。受此启发,本文将块图模型引入高光谱异常检测算法,用于得到异常像素的空间响应,如图 2 所示。首先,为避免高光谱数据维度过大导致的计算量问题,对高光谱图像在光谱域进行 PCA 处理并取前 3 维,PCA 前 3 维保留了图像大部分空域信息。然后,在空域上通过滑窗取出图像块并展开成列后拼接成矩阵 $\mathbf{P}$ 。记窗口大小为 a ,移动步长设为 b ,且 $a > b$ 。借助背景图像的非局部自相似性以及异常像素点的稀疏特性,这个矩阵可以看做是包含背景的低秩矩阵 $\mathbf{L}$ 与包含小目标的稀疏矩阵 $\mathbf{S}$ 之和。最后,通过重构稀疏部分 $\mathbf{S}$,得到异常检测结果。




图 2 块图模型及求解过程

Fig. 2 Patch-image model and the solution procedure

上述问题可转化为优化问题的求解,其数学形式表示为

$$\begin{aligned} \min_{\mathbf{L}, \mathbf{S}} \quad & \text{rank}(\mathbf{L}) + \lambda \|\mathbf{S}\|_1 \\ \text{s. t.} \quad & \mathbf{P} = \mathbf{L} + \mathbf{S} \end{aligned} \quad (2)$$

式中, $\text{rank}(\cdot)$ 表示矩阵的秩, $\|\cdot\|_1$ 为矩阵的 L_1 范数, λ 为非负调节因子。然而,问题(2)是 NP 难题,需对其进行凸近似,即

$$\begin{aligned} \min_{\mathbf{L}, \mathbf{S}} \quad & \|\mathbf{L}\|_* + \lambda \|\mathbf{S}\|_1 \\ \text{s. t.} \quad & \mathbf{P} = \mathbf{L} + \mathbf{S} \end{aligned} \quad (3)$$

式中, $\|\cdot\|_*$ 称为矩阵的核范数,是矩阵的奇异值之和。为便于求解,列出式(3)的增广拉格朗日函数,具体为

$$\begin{aligned} f(\mathbf{L}, \mathbf{S}, \mathbf{Y}, \mu) = & \|\mathbf{L}\|_* + \lambda \|\mathbf{S}\|_1 + \langle \mathbf{Y}, \mathbf{P} - \mathbf{L} - \mathbf{S} \rangle + \\ & \frac{\mu}{2} \|\mathbf{P} - \mathbf{L} - \mathbf{S}\|_F^2 \end{aligned} \quad (4)$$

式中, $\langle \cdot \rangle$ 为矩阵内积操作符, $\mathbf{Y}$ 为拉格朗日乘子, μ 为正的惩罚因子。最小化式(4)可通过 ADMM (alternative direction method of multipliers) 算法迭代

求解。求解过程如下:

1) 固定其他参数,更新 L 。目标函数为

$$\min_L f(L) = \min_L \|L\|_* + \frac{\mu}{2} \left\| P - L - S + \frac{Y}{\mu} \right\|_F^2 \quad (5)$$

该问题的解可由奇异值阈值(singular value thresholding, SVT)算子(Cai 等, 2010)得到。

2) 固定其他参数,更新 S 。目标函数为

$$\min_S f(S) = \min_S \|S\|_1 + \frac{\mu}{2\lambda} \left\| P - L - S + \frac{Y}{\mu} \right\|_F^2 \quad (6)$$

该问题可由软阈值算子(Donoho, 1995)求解。

3) 固定其他参数,通过梯度上升法更新 Y , 具体为

$$Y = Y + \mu(P - L - S) \quad (7)$$

迭代更新求解目标函数式(5)–(7),直至收敛。

1.3 基于空域协同自编码器的异常检测算法

自编码器以重构误差为判决准则,原理简单且易实现,在数据异常检测方面的性能与传统算法相当,甚至优于传统算法。但自编码器对高强度噪声及异常数据较为敏感,在训练阶段需要纯净的背景光谱数据。同时,传统的 AE 框架没有考虑空域信息,进一步约束了算法的探测性能。为避免自编码器的上述缺陷,本文从空域角度筛选背景样本,并引入块图模型抑制背景,用于指导自编码器背景训练集的构建。具体来说,首先从空域角度出发,利用块图模型得到空域异常响应结果 D_1 。按 D_1 各像元值由低到高从原始高光谱数据集中选择占比为 $k \times 100\%$ 的样本作为 AE 的训练样本集。由于块图模型具备优良的背景抑制能力,指导选择出的样本有更高的置信度为背景,相比于随机选取训练样本具有更明显的优势。简单起见, k 值固定为 50,即选取一半样本作为 AE 的训练集。自编码器利用块图模型指导选择出的样本集进行训练,并以重构误差作为判断准则,得到光谱域的探测结果 D_2 。

为了进一步提升算法的探测性能,充分利用块图模型在空域的结果,构造权重 w , 满足

$$w = 1 - e^{-10 \cdot d} \quad (8)$$

式中, d 为样本点在块图模型探测结果 D_1 对应坐标位置处的响应值。 w 随空域响应 d 的变化曲线如图 3 所示。可以发现, d 值越小,该样本点有越大概率为背景,对应的权重越小; d 值越大,该样本点越可

能为异常,权重逐渐趋近于 1。因此,权重 w 可进一步抑制背景,增大异常与背景之间的区分度。




图 3 w 随空域响应 d 的变化曲线

Fig. 3 Shape of function w with respect to d

综上,得到权重矩阵 W ,最终的探测结果 D 为

$$D = W \circ D_2 \quad (9)$$

式中,“ $\circ$ ”为 Hadamard 积。

本文提出的基于矩阵分解和自编码器的高光谱异常检测算法总体流程如下:

输入:高光谱图像 $H \in \mathbf{R}^{M \times N \times L}$;块图模型相关参数 λ 、 a 和 b ;自编码器相关参数 n_{hid} 和 k 。

1) 对高光谱图像 H 从光谱域进行 PCA 并取前 3 维,按图 2 构建块图模型;

2) 迭代求解问题(5)–(7),得到稀疏部分 S , 重构后在光谱维求平均,得到空域异常响应 D_1 ;

3) 由 D_1 选择值最小的 $k \times 100\%$ 个像元对应的光谱数据作为自编码器的训练集,更新网络;

4) 将高光谱图像逐像素投入训练好的自编码器,以重构残差为准得到光谱域异常响应 D_2 ;

5) 由空域响应 D_1 构造权重矩阵 W ;

6) 由式(9)得到最终探测结果 D 。

2 实验结果及分析

2.1 数据集

为验证本文方法的高光谱异常检测效果,使用 3 组不同尺寸的高光谱图像进行实验。1) Sandiego-1 数据集,通过 AVIRIS (airborne visible infrared imaging spectrometer) 传感器于美国加州圣地亚哥上空拍摄,图像尺寸为 $100 \times 100 \times 189$,光谱分辨率为 10 nm,空间分辨率为 3.5 m/像素,波长范围为

370 ~ 2 510 nm。2) SanDiego-2 数据集, 由 AVIRIS 传感器采集, 图像尺寸为 200 × 200 像素, 波长范围为 370 ~ 2 510 nm, 去掉低信噪比等波段后, 剩余 189 个波段用于实验。3) Botanical Garden 数据集, 由 GaiaSkymini 传感器拍摄, 波长范围为 400 ~ 1 000 nm, 共 176 个波段。从中选取 400 × 350 像素的子图像作为数据集。在其中植入 25 个大小为 6 × 6 像素的异常, 异常丰度占比按 20% 逐列增加, 异常像素占比 0.64%。图 4 展示了 3 组高光谱数据集的伪彩色图像及其真实异常图像, 在 SanDiego-1 数据集中, 3 架飞机标注为异常, 占比 0.335%。在 SanDiego-2 数据集中, 同样有 3 架飞机标注为异常, 占比 0.57%。




图 4 3 组高光谱数据集的伪彩图像及其异常真值图

Fig. 4 Pseudo color and ground truth of three HSI datasets

((a) SanDiego-1; (b) SanDiego-2; (c) Botanical Garden)

2.2 参数分析

影响算法探测性能的相关参数主要包括调节因子 λ 、图像块尺寸 a 及滑动步长 b 、隐含层的节点个数 n_{hid} 以及选取的主成分个数 p 。在验证各参数的影响之前, 将 D_1 进行滤波器尺寸为 3 × 3 的最大值滤波。简单起见, 引入图像块相关参数 c , 设置滑动步长 $b = \text{floor}(c \times \min(M, N))$, $\text{floor}(\cdot)$ 为向下取整符号, 图像块窗口大小 $a = 2b - 1$ 。

2.2.1 调节因子 λ

由优化函数式(3)可知, 调节因子 λ 用于权衡低秩部分和稀疏部分所占整体信息的多少。 λ 越大, 对 S 的惩罚越重, 低秩部分 L 占有更多的信息; 相反, λ 越小, 稀疏部分 S 占有更多的信息。图 5 展示了 λ 分别取 10^{-4} 、 10^{-2} 和 10^0 时分解得到低秩部分和稀疏部分的结果。合适的 λ 能增强稀疏矩阵 S

对背景的抑制, 而过大的 λ 会丢失目标信息。




图 5 λ 取不同值时得到的低秩部分和稀疏部分

Fig. 5 The low-rank part and sparse part when λ is different

((a) $\lambda = 10^{-4}$; (b) $\lambda = 10^{-2}$; (c) $\lambda = 10^0$)

为进一步分析 λ 对最终探测结果的影响, 设 λ 从 $\{10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 10^0\}$ 中选取, 参数 c 设置为 0.05, n_{hid} 设为 100。探测结果如图 6 所示。纵坐标 AUC (area under curve) 用来衡量优劣随着 λ 增大, 算法探测性能逐渐提升。因为矩阵分解过程中对稀疏部分的惩罚加重, 使得矩阵 S 保留更显著的目标信息, 同时抑制非目标稀疏噪声。但当 λ 过大时, 对 S 的惩罚加重, 使 S 丢失目标信息, 算法探测性能下降。本文将 SanDiego-1 和 Botanical Garden 数据集的 λ 均设置为 10^{-2} , SanDiego-2 数据集的 λ 设置为 10^{-1} 。




图 6 λ 对最终探测性能的影响

Fig. 6 Influences of parameter λ on the final detection result

2.2.2 图像块相关参数 c

由于不同图像中目标的大小存在差异, 块图模型中图像块尺寸会影响矩阵分解的求解效果。同

时,图像块尺寸 a 和滑动步长 b 决定所构造矩阵的规模,进而影响块图模型背景抑制的能力以及算法的运行效率。本文通过参数 c 分析 a 和 b 对结果的影响。 c 从 0.01 按 0.01 递增直至 0.1。算法最终探测结果如表 1 所示。从表 1 的结果可知,参数 c 既影响算法的探测结果,也影响算法的运行效率。因为图像块参数 c 影响图像块包含目标信息的多少,同时决定了所构造矩阵的尺寸。兼顾算法的性能和效率,本文设置 3 组数据集的参数 c 均为 0.06。

表 1 参数 c 对最终探测性能的影响
Table 1 Influences of parameter c on the final detection result

c	Sandiego-1		Sandiego-2		Botanical Garden	
	AUC	耗时/s	AUC	耗时/s	AUC	耗时/s
0.01	0.988 6	12.1	0.865 3	54.4	0.998 4	232.2
0.02	0.989 0	11.4	0.933 2	58.0	0.997 4	229.5
0.03	0.989 6	12.3	0.951 6	59.5	0.997 0	398.3
0.04	0.989 5	14.5	0.978 1	71.1	0.997 9	258.1
0.05	0.989 4	13.5	0.983 6	61.4	0.998 0	233.0
0.06	0.990 1	13.6	0.988 6	55.5	0.996 9	236.7
0.07	0.98 9	13.3	0.980 6	68.0	0.998 0	222.4
0.08	0.990 4	13.6	0.972 0	55.0	0.997 9	204.6
0.09	0.990 1	13.0	0.938 7	54.5	0.998 5	206.1
0.1	0.989 8	12.6	0.906 1	52.5	0.997 6	209.3

注:加粗字体表示各列最优结果。

2.2.3 自编码器隐含层节点个数 n_{hid}

自编码器的隐含层节点个数 n_{hid} 决定了隐空间保留的原始数据信息的多少。过少的隐含层节点个数会丢失背景的光谱信息,不利于正常样本点和异常样本点的分离;而过多的隐含层节点个数没有起到提取有区分度特征的作用。结合 2.2.1 节和 2.2.2 节,设置调节因子 λ 在 3 个数据集上的值分别为 10^{-2} 、 10^{-1} 和 10^{-2} ,图像块相关参数 c 均取 0.06。设 n_{hid} 从 {20, 40, 60, 80, 100, 120, 140, 160} 中选取,探测结果如图 7 所示。由图可知,当 $n_{hid} \geq 40$ 时,算法的最终探测结果趋于最佳且相对保持稳定,当 $n_{hid} < 40$ 时,探测性能相对较差。因为过小的隐含层节点个数导致 AE 无法有效学习到正常样本的特征,导致正常样本的重构误差增大,加大了区分背景和异常目标的难度。简单起见,本文设

置 3 组数据集的参数 n_{hid} 均为 100。




图 7 n_{hid} 对最终探测性能的影响

Fig. 7 Influences of parameter n_{hid} on the final detection result

2.2.4 选取的主成分个数 p

在块图模型中,选取的主成分个数 p 决定了所保留的信息量的多少。 p 值过小,会丢失大量原有信息; p 值过大,会增加冗余计算。因此,为探究 p 不同取值对算法性能和耗时的影响,同时兼顾性能和耗时,设置 p 从 {1, 2, 3, 5, 10} 中选取,探测结果如表 2 所示。由表 2 可知,当选取的主成分个数为 1 时,探测性能最低。随着选取主成分个数的增加,算法的探测性能变化较小,但耗时增加。因为选取的主成分用于空域响应提取,当个数达到一定阈值时,得到的空域响应保持一致,但由于待分解矩阵的规模增大,导致耗时增加。兼顾性能和耗时,本文选取的主成分个数设置为 3。

表 2 选取的主成分个数对算法性能和耗时的影响
Table 2 Influences of parameter p on the final detection performance and the execution time

p	Sandiego-1		Sandiego-2		Botanical Garden	
	AUC	耗时/s	AUC	耗时/s	AUC	耗时/s
1	0.969 16	14.6	0.977 31	58.5	0.995 90	266.9
2	0.990 08	17.5	0.988 77	62.0	0.996 63	275.0
3	0.990 16	18.3	0.988 36	63.0	0.996 80	277.4
5	0.990 22	19.0	0.987 09	70.0	0.996 63	280.6
10	0.990 30	20.3	0.985 77	75.5	0.996 52	350.5

注:加粗字体表示各列最优结果。

2.3 算法架构分析

为验证本文提出的基于空域协同自编码器的高

光谱异常检测算法的合理性, 设置了多组对比算法进行实验, 通过对比不同算法在3组高光谱数据集上AUC值的大小来衡量算法的优劣。本文算法通过块图模型从空域筛选背景数据集, 并充分利用空域信息协同自编码器以提升算法检测性能。实验采用的对比算法包括: 1) 通过属性滤波(attribute filter, AF)替代块图模型以验证块图模型在空域对背景抑制方面的优势, 称为AF-AE方法。AF是一种高光谱目标探测的空域算法, 并得到广泛的研究和应用(张香萍, 2017; Kang等, 2017)。2) AER(autoencoder random-sampling)方法。采用随机采样的方式选取自编码器的训练样本, 以得到单独采用AE模型得到的异常检测结果。采样的样本个数与本文算法一致, 均为样本总体的一半。3) D_1 和 D_2 , 这是本文算法中块图模型得到的空域异常响应及AE得到的光谱域异常检测结果。值得注意的是, 这里的 D_2 与块图模型得到的结果 D_1 相关。实验中通过调参使上述算法均能达到最优的异常检测性能, 利用高光谱数据集进行性能评估, 探测结果如表3所示。由表3分析可知, 本文算法在3组高光谱数据集上均能取得最优的探测性能。相比于AF-AE算法, 块图模型能够适应复杂的异构背景, 更适用于对地遥感监测及相关任务。对比AER和 D_2 的结果可以发现, 经过块图模型在空域选择背景样本集的策略, 相比于随机选取而言在基于AE探测高光谱图像场景中的异常目标方面具有明显优势。实验结果表明, 本文算法充分利用了空域结果, 通过权重的方式将空域信息融合到最终的探测结果中, 提升了算法的异常检测性能。

表3 各对比算法在3组数据集上的AUC值
Table 3 The AUC values of different methods on three HSI datasets

算法	Sandiego-1	Sandiego-2	Botanical Garden
AF-AE	0.982 1	0.912 0	0.982 9
AER	0.931 4	0.938 3	0.990 8
D_1	0.977 2	0.926 7	0.991 6
D_2	0.987 2	0.943 6	0.994 9
本文	0.990 2	0.988 6	0.997 0

注: 加粗字体表示各列最优结果。

2.4 与其他算法比较

为验证本文算法在高光谱异常检测中的优越

性, 与高光谱异常检测领域经典的GRX(global Reed-Xiaoli)算法(Reed和Yu, 1990)、LSMAD(lrasmd-based Mahalanobis distance method)算法(Zhang等, 2016)和AE算法以及两种最近提出的具有较高异常检测性能的前沿算法FrFE(fractional Fourier entropy)(Tao等, 2019)和FEBPAD(feature extraction and background purification anomaly detector)(Ma等, 2021)进行对比。需要说明的是, 本节中AE算法使用整个高光谱数据作为训练集, 而本文算法参数按2.2节设置。本文算法中自编码器采用的是软件自带的trainAutoencoder()函数。设置学习步长为0.01, 不加任何约束项(权重约束项系数和稀疏约束项系数均设置为0), 迭代次数为100, batch设置为50, 激活函数为sigmoid函数。其余算法参数均按获得最佳探测效果设置。

各算法的探测主观效果图如图8所示。可以看出, 各算法均能较为有效地突出目标, 并能一定程度上抑制背景。但GRX和LSMAD算法由于没有提取光谱的高维本质特征, 其背景抑制效果不明显。而AE和FEBPAD算法在光谱域所张成的子空间或变换域中提取具有区分度的特征, 但是由于没有考虑到空域信息, 导致算法的异常检测性能受限。本文提出的基于空域协同自编码器的异常检测算法既提取了光谱的低维本质特征, 避免数据冗余导致的性能下降, 同时保留了空域信息, 从而可以更好地抑制背景, 易于将异常从背景中分离出来。

评价算法性能的参数为ROC(receiver operating characteristic)曲线图、AUC值和耗时, 实验结果如图9和表4所示。从图9可知, 对于Sandiego-1数据集, 在低虚警率下, 本文算法的探测概率低于LSMAD。但在检测出所有目标的前提下(探测率为1), 所提基于空域协同自编码器的异常检测算法在3组数据集上均具有最低的虚警率。从表4可以看出, 本文算法的AUC值明显高于其他算法, 这是因为本文算法同时考虑了块图模型带来的空域信息, 以及AE得到的低维本质光谱特征。结合3.3节 D_2 的结果可以注意到, D_2 的AUC值高于AE算法的结果, 分析认为, 块图模型良好的背景抑制能力可以为AE模型提供更为纯净的训练集, 从而保证AE模型在重构背景样本的同时避免学习到异常样本的特征。表4同时列出了各种算法的耗时, 本文算法虽然耗时较长, 但在所列算法中探测性能最佳。




图 8 不同数据集异常检测主观效果图

Fig. 8 Anomaly detection maps for different datasets

((a)ground truth;(b)GRX;(c)LSMAD;(d)AE;(e)FrFE;(f)FEBPAD;(g)ours)




图 9 各种算法在 3 个数据集上的 ROC 曲线

Fig. 9 ROC curves of hyperspectral anomaly detectors on three datasets((a)Sandiego-1;(b)Sandiego-2;(c)Botanical Garden)

表 4 各算法在 3 个数据集上的 AUC 值及耗时

Table 4 The AUC values and execution time on three HSI datasets

算法	Sandiego-1 (100 × 100 像素)		Sandiego-2 (200 × 200 像素)		Botanical Garden (400 × 350 像素)	
	AUC	耗时/s	AUC	耗时/s	AUC	耗时/s
GRX	0.905 5	0.3	0.887 0	0.7	0.843 2	2.2
LSMAD	0.986 1	43.4	0.941 2	155.1	0.949 2	543.6
AE	0.985 6	27.3	0.949 5	111.6	0.976 8	349.8
FrFE	0.979 5	1.4	0.959 1	5.0	0.826 7	18.8
FEBPAD	0.988 8	8.5	0.967 6	30.2	0.986 7	102.6
本文	0.990 4	13.7	0.988 8	58.7	0.997 0	223.7

注:加粗字体表示各列最优结果。

值得注意的是,由于本文算法中训练集只占高光谱所有样本数的一半,相比用 AE 算法直接对所有样本训练,其耗时可缩短一半以上。

3 结 论

本文提出一种基于空域协同自编码器的高光谱异常检测算法。该算法针对 AE 对训练集中异常样本敏感的问题,从空域角度出发,利用块图模型在背景抑制方面的优势,为自编码器提供纯净的背景训练集。同时,算法通过构造权重的方式以充分利用块图模型包含的空域信息,进一步提升算法的探测性能。该方法主要分为以下 3 个步骤:1)利用块图模型为自编码器提供纯净的训练样本;2)通过 AE 提取高光谱图像中目标的光谱域信息;3)利用块图模型的异常响应构造权重以将空域信息融合进探测结果中。实验数据包含 3 组不同尺寸的高光谱数据集,与经典、前沿的高光谱异常检测算法进行比较分析。实验结果表明,本文算法在高光谱异常探测上得到了最高的 AUC 值,且能以更低的虚警率实现所有异常像元的探测,说明了本文算法的有效性和优越性。但同时需要注意,该算法需要调整的参数较多,限制了在实际中的进一步应用。因此,在下一步研究中将重点关注如何实现部分参数的自动调整。

参考文献 (References)

- Cai J F, Candès E J and Shen Z W. 2010. A singular value thresholding algorithm for matrix completion. *SIAM Journal on Optimization*, 20(4): 1956-1982 [DOI: 10.1137/080738970]
- Chang S Z, Du B and Zhang L P. 2019. A sparse autoencoder based hyperspectral anomaly detection algorithm using residual of reconstruction error//2019 IEEE International Geoscience and Remote Sensing Symposium. Yokohama, Japan; IEEE: 5488-5491 [DOI: 10.1109/IGARSS.2019.8898697]
- Donoho D L. 1995. De-noising by soft-thresholding. *IEEE Transactions on Information Theory*, 41(3): 613-627 [DOI: 10.1109/18.382009]
- Gao C Q, Meng D Y, Yang Y, Wang Y T, Zhou X F and Hauptmann A G. 2013. Infrared patch-image model for small target detection in a single image. *IEEE Transactions on Image Processing*, 22(12): 4996-5009 [DOI: 10.1109/TIP.2013.2281420]
- Imani M. 2017. RX anomaly detector with rectified background. *IEEE Geoscience and Remote Sensing Letters*, 14(8): 1313-1317 [DOI: 10.1109/LGRS.2017.2710618]
- Kang X D, Zhang X P, Li S T, Li K L, Li J and Benediktsson J A. 2017. Hyperspectral anomaly detection with attribute and edge-preserving filters. *IEEE Transactions on Geoscience and Remote Sensing*, 55(10): 5600-5611 [DOI: 10.1109/TGRS.2017.2710145]
- Li P H, Li M, Fan X N and Zhang X W. 2018. Hyperspectral anomaly detection algorithm based on iterative analysis with relative density. *Journal of Image and Graphics*, 23(2): 219-228 (李普煌, 李敏, 范新南, 张学武. 2018. 迭代分析相对密度的高光谱异常检测. *中国图象图形学报*, 23(2): 219-228) [DOI: 10.11834/jig.170243]
- Liu K, Zhou Z, Li S Y, Liu Y F, Wan X, Liu Z W, Tan H and Zhang W F. 2020. Scene classification dataset using the Tiangong-1 hyperspectral remote sensing imagery and its applications. *Journal of Remote Sensing*, 24(9): 1077-1087 (刘康, 周壮, 李盛阳, 刘云飞, 万雪, 刘志文, 谭洪, 张万峰. 2020. 天宫一号高光谱遥感场景分类数据集及应用. *遥感学报*, 24(9): 1077-1087) [DOI: 10.11834/jrs.20209323]
- Lu X Q, Zhang W X and Huang J. 2020. Exploiting embedding manifold of autoencoders for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 58(3): 1527-1537 [DOI: 10.1109/TGRS.2019.2944419]
- Ma Y, Fan G H, Jin Q W, Huang J, Mei X G and Ma J Y. 2021. Hyperspectral anomaly detection via integration of feature extraction and background purification. *IEEE Geoscience and Remote Sensing Letters*, 18(8): 1436-1440 [DOI: 10.1109/LGRS.2020.2998809]
- Ma Y, Jin Q W, Mei X G, Dai X B, Fan F, Li H and Huang J. 2019. Hyperspectral unmixing with Gaussian mixture model and low-rank representation. *Remote Sensing*, 11(8): #911 [DOI: 10.3390/rs11080911]
- Mei X G, Pan E T, Ma Y, Dai X B, Huang J, Fan F, Du Q L, Zheng H and Ma J Y. 2019. Spectral-spatial attention networks for hyperspectral image classification. *Remote Sensing*, 11(8): #963 [DOI: 10.3390/rs11080963]
- Reed I S and Yu X. 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]
- Shi Y Z, Li J J, Yin Y P, Xi B B and Li Y S. 2019. Hyperspectral target detection with macro-micro feature extracted by 3-D residual autoencoder. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(12): 4907-4919 [DOI: 10.1109/JSTARS.2019.2939833]
- Su Y C, Li J, Plaza A, Marinoni A, Gamba P and Chakravorty S. 2019. DAEN: deep autoencoder networks for hyperspectral unmixing. *IEEE Transactions on Geoscience and Remote Sensing*, 57(7): 4309-4321 [DOI: 10.1109/TGRS.2015.247929]
- Tao R, Zhao X D, Li W, Li H C and Du Q. 2019. Hyperspectral anom-

- aly detection by fractional Fourier entropy. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 12(12): 4920-4929 [DOI: 10.1109/JSTARS.2019.2940278]
- Wang H X, Dong H and Zhou Z Q. 2019. Review on dim small target detection technologies in infrared single frame images. Laser and Optoelectronics Progress, 56(8): #080001 (王好贤, 董衡, 周志权. 2019. 红外单帧图像弱小目标检测技术综述. 激光与光电子学进展, 56(8): #080001) [DOI: 10.3788/LOP56.080001]
- Xie W Y, Lei J, Liu B Z, Li Y S and Jia X P. 2019. Spectral constraint adversarial autoencoders approach to feature representation in hyperspectral anomaly detection. Neural Networks, 119: 222-234 [DOI: 10.1016/j.neunet.2019.08.012]
- 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]
- Zhang X P. 2017. Hyperspectral Image Anomaly Detection Method by Fusing Spatial and Spectral Information. Changsha: Hunan University: 19-20 (张香萍. 2017. 联合空间与光谱信息的高光谱图像异常目标检测方法研究. 长沙: 湖南大学: 19-20)
- Zhang Y X, Du B, Zhang L P and Wang S G. 2016. A low-rank and sparse matrix decomposition-based mahalanobis distance method for hyperspectral anomaly detection. IEEE Transactions on Geoscience and Remote Sensing, 54(3): 1376-1389 [DOI: 10.1109/TGRS.2015.247929]
- 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]

作者简介

樊港辉,男,硕士研究生,主要研究方向为高光谱图像处理和机器学习。E-mail: fan_ganghui@whu.edu.cn

梅晓光,通信作者,男,副教授,主要研究方向为高光谱图像处理、机器学习和模式识别。

E-mail: meixiaoguang@gmail.com

马泳,男,教授,主要研究方向为红外热成像、红外超光谱和机器视觉。E-mail: mayong@whu.edu.cn

黄琚,男,副教授,主要研究方向为红外成像及应用、图像处理、超光谱成像和嵌入式系统。

E-mail: junwong@whu.edu.cn

樊凡,男,讲师,主要研究方向为信号处理、红外图谱成像、红外与遥感信息处理。E-mail: fanfan@whu.edu.cn

李皞,男,副教授,主要研究方向为红外光谱、信号处理和环境遥感。E-mail: lihao@whpu.edu.cn