



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


中国图象图形学报

2021

08

VOL.26

ISSN1006-8961
CN11-3758/TB



“高光谱图像处理与应用”专刊



第26卷第8期 (总第304期)

2021年8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



高光谱图像在生物医学中的应用(第1764页)



HSRS-SC:面向遥感场景分类的高光谱图像数据集(第1809页)



多尺度超像素分割和奇异谱分析的高光谱影像分类(第1978页)

序言 何明一 I

编者按 II

综述

高光谱图像空谱特征提取综述

叶珍, 白璘, 何明一 1737

高光谱图像在生物医学中的应用

李伟, 吕蒙, 陈天虹, 楚照耀, 陶然 1764

高光谱成像技术新进展

近红外高光谱图像数据预测技术

梅少辉, 张博威, 马明阳, 贾森 1786

低成本便携式多光谱成像系统的研发及优化

朱豪男, 胡孟晗, 张健, 李庆利 1796

数据集论文

HSRS-SC:面向遥感场景分类的高光谱图像数据集

徐科杰, 邓培芳, 黄鸿 1809

高光谱医学诊断

膜性肾病诊断的高光谱图像张量嵌入分析

吕蒙, 陈天虹, 李伟, 杨悦, 涂天琪, 李文歌 1823

傅里叶变换通道注意力网络的胆管癌高光谱图像分割

郑少佳, 邱崧, 李庆利, 周梅, 胡孟晗, 于观贞 1836

高光谱图像目标检测与识别

局部梯度轮廓变换的高光谱异常检测

胡静, 张钰婧, 赵明华, 李鹏, 李云松 1847

结合孪生网络和像素配对的高光谱图像异常检测

王德港, 饶伟强, 孙旭, 渠瀛, 刘雪梅, 高连如 1860

粗定位和协同表示的高光谱图像异常检测

胡静, 赵明华, 李鹏, 李云松 1871

高光谱图像深度模糊核聚类的洋底锰结核识别

张启忠, 郑恩迪, 王叶剑, 高发荣 1886

高光谱图像融合与恢复

波段自适应细节注入的高分五号与Sentinel-2遥感影像空谱融合

王海荣, 郭擎, 李安 1896

基于频率加权张量核范数的高光谱图像复原

刘盛, 曾海金, 孔文凤, 张鹏丹 1910

高光谱图像分类

面向高光谱图像分类的内容引导卷积深度网络并行实现

刘启超, 肖亮, 杨劲翔 1926

增强类可分性的高光谱图像分类

方帅, 张坤, 张晶, 曹洋, 石为开 1940

高光谱图像分类的自适应决策融合方法

叶珍, 董睿, 陈浩鑫, 白璘 1952

跨数据集评估的高光谱图像分类

潘尔婷, 马泳, 黄珺, 樊凡, 李峰, 马佳义 1969

多尺度超像素分割和奇异谱分析的高光谱影像分类

付航, 孙根云, 赵云华, 潘兆杰, 胡光, 张爱竹 1978

结合倒置特征金字塔和U-Net的高光谱图像分类

程嵩阳, 熊玉洁, 姚瑶, 李庆利 1994

高光谱图像小样本分类的卷积神经网络方法

吴鸿昊, 王立国, 石瑶 2009


3D卷积自编码器高光谱图像分类模型

石延新, 何进荣, 李照奎, 曾志高 2021

封面素材由重庆大学光电工程学院黄鸿教授提供

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS



Application of a hyperspectral image in medical field: a review (P1764)



HSRS-SC: a hyperspectral image dataset for remote sensing scene classification (P1809)



Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification (P1978)

Review

- Review of spatial-spectral feature extraction for hyperspectral image
Ye Zhen, Bai Lin, He Mingyi 1737
- Application of a hyperspectral image in medical field: a review
Li Wei, Lyu Meng, Chen Tianhong, Chu Zhaoyao, Tao Ran 1764

Advances in Hyperspectral Imaging

- Predicting near-infrared hyperspectral images from visible hyperspectral images
Mei Shaohui, Zhang Bowei, Ma Mingyang, Jia Sen 1786
- Development and optimization of a low-cost and portable multispectral imaging system
Zhu Haonan, Hu Menghan, Zhang Jian, Li Qingli 1796

Dataset

- HSRS-SC: a hyperspectral image dataset for remote sensing scene classification
Xu Kejie, Deng Peifang, Huang Hong 1809

Medical Hyperspectral Imagery

- Tensor-based graph embedding for discriminant analysis of membranous nephropathy hyperspectral data
Lyu Meng, Chen Tianhong, Li Wei, Yang Yue, Tu Tianqi, Li Wen'ge 1823
- Fourier transform channel attention network for cholangiocarcinoma hyperspectral image segmentation
Zheng Shaojia, Qiu Song, Li Qingli, Zhou Mei, Hu Menghan, Yu Guanzhen 1836

Hyperspectral Target Detection and Recognition

- Transformation of local gradient profiles for hyperspectral anomaly detection
Hu Jing, Zhang Yujing, Zhao Minghua, Li Peng, Li Yunsong 1847
- Siamese network with pixel-pair for hyperspectral image anomaly detection
Wang Degang, Rao Weiqiang, Sun Xu, Qu Ying, Liu Xuemei, Gao Lianru 1860
- Rough location and collaborative representation for hyperspectral image anomaly detection
Hu Jing, Zhao Minghua, Li Peng, Li Yunsong 1871
- Recognition of ocean floor manganese nodules by deep kernel fuzzy C-means clustering of hyperspectral images
Zhang Qizhong, Zheng Endi, Wang Yejian, Gao Farong 1886

Hyperspectral Image Fusion and Restoration

- Spatial-spectral fusion based on band-adaptive detail injection for GF-5 and Sentinel-2 remote sensing images
Wang Hairong, Guo Qing, Li An 1896
- Hyperspectral image restoration based on frequency-weighted tensor nuclear norm
Liu Sheng, Zeng Haijin, Kong Wenfeng, Zhang Pengdan 1910

Hyperspectral Image Classification

- Parallel implementation of content-guided deep convolutional network for hyperspectral image classification
Liu Qichao, Xiao Liang, Yang Jinxiang 1926
- Hyperspectral image classification with enhanced class separability
Fang Shuai, Zhang Kun, Zhang Jing, Cao Yang, Shi Weikai 1940
- Adjustive decision fusion approaches for hyperspectral image classification
Ye Zhen, Dong Rui, Chen Haoxin, Bai Lin 1952
- Hyperspectral image classification evaluated across different datasets
Pan Erting, Ma Yong, Huang Jun, Fan Fan, Li Hao, Ma Jiayi 1969
- Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification
Fu Hang, Sun Genyun, Zhao Yunhua, Pan Zhaojie, Hu Guang, Zhang Aizhu 1978
- Hyperspectral image classification using an inverted feature pyramid network with U-Net
Cheng Songyang, Xiong Yujie, Yao Yao, Li Qingli 1994
- Convolution neural network method for small-sample classification of hyperspectral images
Wu Honghao, Wang Liguang, Shi Yao 2009
- Hyperspectral image classification model based on 3D convolutional auto-encoder
Shi Yanxin, He Jinrong, Li Zhaokui, Zeng Zhigao 2021

中图法分类号: TP751 文献标识码: A 文章编号: 1006-8961(2021)08-1860-11

论文引用格式: Wang D G, Rao W Q, Sun X, Qu Y, Liu X M and Gao L R. 2021. Siamese network with pixel-pair for hyperspectral image anomaly detection. *Journal of Image and Graphics*, 26(08): 1860-1870 (王德港, 饶伟强, 孙旭, 渠瀛, 刘雪梅, 高连如. 2021. 结合孪生网络和像素配对的高光谱图像异常检测. *中国图象图形学报*, 26(08): 1860-1870) [DOI:10.11834/jig.210073]

结合孪生网络和像素配对的高光谱图像异常检测

王德港^{1,2}, 饶伟强^{1,2}, 孙旭^{1*}, 渠瀛³, 刘雪梅⁴, 高连如¹

1. 中国科学院空天信息创新研究院数字地球重点实验室, 北京 100094; 2. 中国科学院大学, 北京 100049;
3. 田纳西大学诺克斯维尔分校, 田纳西州 37996, 美国; 4. 航天飞行器生存技术与效能评估实验室, 北京 100085

摘要: **目的** 高光谱遥感中,通常利用像素的光谱特征来区分背景地物和异常目标,即通过二者之间的光谱差异来寻找图像中的异常像元。但传统的异常检测算法并未有效挖掘光谱的深层特征,高光谱图像中丰富的光谱信息没有被充分利用。针对这一问题,本文提出结合孪生神经网络和像素配对策略的高光谱图像异常检测方法,利用深度学习技术提取高光谱图像的深层非线性特征,提高异常检测精度。**方法** 采用像素配对的思想构建训练样本,与原始数据集相比,配对得到的新数据集数量呈指数增长,从而满足深度网络对数据集数量的需求。搭建含有特征提取模块和特征处理模块的孪生网络模型,其中,特征处理模块中的卷积层可以专注于提取像素对之间的差异特征,随后利用新的训练像素对数据集进行训练,并将训练好的分类模型固定参数,迁移至检测过程。用滑动双窗口策略对测试集进行配对处理,将测试像素对数据集送入网络模型,得到每个像素相较于周围背景像素的差异性分数,从而识别测试场景中的异常地物。**结果** 在异常检测的实验结果中,本文提出的孪生网络模型在 San Diego 数据集的两幅场景和 ABU-Airport 数据集的一幅场景上,得到的 AUC (area under the curve) 值分别为 0.993 51、0.981 21 和 0.984 38,在 3 个测试集上的表现较传统方法和基于卷积神经网络的异常检测算法具有明显优势。**结论** 本文方法可以提取输入像素对的深层光谱特征,并根据其特征的差异性,让网络学习到二者的区分度,从而更好地赋予待测像素相对于周围背景的异常分数。本文方法相对于卷积神经网络的异常检测方法可以有效地降低虚警,与传统方法相比能够更加明显地突出异常目标,提高了检测率,同时也具有较强的鲁棒性。**关键词:** 高光谱图像;异常检测;深度学习;孪生神经网络;像素配对策略;滑动双窗口

Siamese network with pixel-pair for hyperspectral image anomaly detection

Wang Degang^{1,2}, Rao Weiqiang^{1,2}, Sun Xu^{1*}, Qu Ying³, Liu Xuemei⁴, Gao Lianru¹

1. Key Laboratory of Digital Earth Science, Aerospace Information Research Institute (AIR), Chinese Academy of Sciences, Beijing 100094, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China; 3. The University of Tennessee, Knoxville, TN 37996, USA; 4. Spacecraft Survival Technology and Effectiveness Evaluation Laboratory, Beijing 100085, China

Abstract: **Objective** The continuous improvement in spectral resolution promotes the development and progress of hyperspectral remote sensing technology. Hyperspectral remote sensing technology has broad application scenarios and great application value and is a major research topic in the field of remote sensing. Anomaly detection of the hyperspectral image is an important branch in the field of hyperspectral remote sensing, and it is widely used in the industry, geological exploration.

收稿日期: 2021-02-09; 修回日期: 2021-05-17; 预印本日期: 2021-05-24

* 通信作者: 孙旭 sunxu@aircas.ac.cn

基金项目: 国家自然科学基金项目(42030111, 41871245)

Supported by: National Natural Science Foundation of China(42030111, 41871245)

tion, and other fields. The number of anomalies in the scene is usually small, and the spatial and spectral characteristics are different from the surrounding background. In the hyperspectral field, the spectral characteristics of pixels are usually used to distinguish the background and anomalous targets, that is, the anomalous pixels in the image are searched through the spectral differences. The detection methods based on a statistical model and traditional machine learning will have difficulty building the background model because of the complexity of background pixels. They will also have difficulty selecting the form of kernel function and building the background dictionary due to the lack of prior knowledge. Moreover, traditional anomaly detection algorithms do not effectively mine the deep features of the spectrum, and the rich spectral information in hyperspectral images is not fully utilized. Deep learning has great advantages in processing complex hyperspectral images, and anomaly detection method using deep learning is still a frontier area worthy of exploration and has gradually become the focus of research. Therefore, this study proposes a hyperspectral image anomaly detection method based on siamese neural network with pixel-pair strategy. It uses deep learning technology to extract the deep nonlinear features of hyperspectral images. This method aims to improve the accuracy of anomaly detection and promote the development of hyperspectral image processing and application technology.

Method The method of anomaly detection in the hyperspectral image based on siamese neural network with pixel-pair feature (PPF-SNN) is divided into three steps. First, the idea of pixel-pair is adopted to amplify training samples because of the scarcity of hyperspectral data samples with real labels and the need for a large number of training data of the deep network model. Specifically, two pixels are randomly selected from the reference data containing multiple types of ground materials for matching. If they come from the same labeled class, then the pair is labeled as 0; if they come from different labeled classes, then the label is 1. Compared with the original datasets, the number of new datasets obtained by pairing increases exponentially to meet the demand of a deep network for the number of datasets. Second, we build a siamese network model with a feature extraction module and feature processing module. The branch network of the feature extraction module adopts the convolutional neural network (CNN) structure with weight sharing, which contains 10 convolutional layers. The feature processing module concatenates the input feature pairs and then extracts the difference features of pixel pairs through a convolutional layer, while the pixel pairs are classified through the fully connected layers. The module uses the extracted pixel pair features to measure the similarity of the input pairs. Then, the new training dataset is used to train the model, and the trained classification model is transferred to the detection process with fixed parameters. Third, the sliding dual-window strategy is used to pair the test set, and the test pixel pair dataset is sent to the network model. Next, the difference score of each pixel compared with the surrounding background pixels is obtained. If the score is close to 1, then the pixel under test tends to be anomalous. If the score is close to 0, then the pixel under test is close to the background. Using this principle, we can identify the anomalous targets in the test scene.

Result To verify the effectiveness of the proposed algorithm, the experimental part selects two scenes from the San Diego dataset and one scene from the ABU-Airport dataset and uses the traditional algorithms like global RXD (GRXD), local RXD (LRXD), and collaborative representation-based detector (CRD) and the anomaly detection algorithm based on convolutional neural network with pixel-pair feature (PPF-CNN) as the comparative algorithms. The receiver operating curve (ROC) of each algorithm is drawn, and the corresponding area under the ROC curve (AUC) value is calculated as an evaluation index of algorithm performance. In the anomaly detection experimental results of the three scenes, the proposed PPF-SNN has the highest AUC values of 0.993 51, 0.981 21, and 0.984 38, respectively. It can ensure the highest detection rate while keeping the false alarm rate low. The performance of PPF-SNN has obvious advantages over traditional algorithms and PPF-CNN algorithm.

Conclusion The proposed hyperspectral image anomaly detection method based on siamese neural network can extract the deep spectral characteristics of the input pixel pair. According to the difference in its characteristics, the network will learn the distinction between the two. Thus, it can effectively provide the anomaly score of the pixel under test relative to the surrounding background. Compared with PPF-CNN, the proposed method can effectively reduce false alarms. It can also highlight anomalous targets more obviously, improve the detection rate, and exhibit stronger robustness than traditional methods.

Key words: hyperspectral image; anomaly detection; deep learning; siamese neural network; pixel-pair strategy; sliding dual-window

0 引言

在光学遥感中,光谱分辨率的逐渐提高,推动了高光谱遥感技术的形成和发展(童庆禧等,2016)。高光谱图像的处理与分析(Khan等,2018a)在地质勘察、食品和农业等领域有很多应用,如小麦黄锈病的检测(Zhang等,2019)、油墨文件的伪造检测(Khan等,2018b)等。高光谱遥感技术具有广阔的应用场景和巨大的应用价值,是当前遥感领域的研究热点之一。作为高光谱图像处理及应用技术中的重要一环,高光谱图像的异常检测在没有已知地物光谱信息的前提下,可以对图像直接进行检测,其应用范围非常广泛。

如何利用高光谱图像丰富的光谱信息、如何有效地衡量异常目标与周围背景的差异是进行异常地物检测的关键问题。传统方法中最为典型的是RX(Reed-Xiaoli)异常检测算法(Reed和Yu,1990),该方法首先假设背景地物满足正态分布,而异常目标与背景在分布上存在差异,因此,可以通过马氏距离进行区分。由于经典算法在复杂背景下的计算精度不高,因而有很多改进算法,如邻域RXD(segmented-Reed-Xiaoli detector, SRXD)算法(张兵和高连如,2011),首先对整幅图像进行K均值聚类,然后利用每个像元同类且不间断的最大邻域,完成均值向量和协方差矩阵的估计,从而进行异常检测;Guo等人(2014)提出了加权RXD(weighted-RXD, W-RXD)算法以及线性滤波RXD(linear filter-based RXD, LF-RXD)算法,前者将背景像元赋予较高的权重,将异常和噪声像元赋予较低的权重,后者基于滤波理论进行检测,提出的算法均实现较高的检测率和较低的虚警率。但基于概率统计模型的RX检测算法仍然存在一些问题,比如只利用了图像的低阶统计信息,没有利用到高光谱图像的高维潜在信息。

随后,国内外学者提出了基于机器学习中核函数思想的非线性检测方法,取得了较好的效果。其中核RXD(kernel RXD, KRXD)算法(Kwon和Nasrabadi,2005)可以将高光谱数据映射到高维空间,这样即可在高维线性空间计算马氏距离,进行RX异常检测,较非核化异常检测算法能够获得更高的检测精度。由于传统的核函数检测算法会存在核函数选取较难和计算复杂的问题,Zhou等人(2016)提

出基于背景像素聚类的KRXD算法,极大地提升了检测速度。也有学者将稀疏表示应用到了高光谱图像的异常检测当中,Li和Du(2014)提出的基于协同表示的异常探测器(collaborative representation-based detector, CRD)构建了背景字典,但异常像元不能近似线性表示。为了可以利用到空间信息,马世欣等人(2019)提出了空谱联合协同表示的异常检测算法,其检测性能明显高于只利用光谱信息的算法。如何合理利用高光谱图像的空间信息也成为研究的热点。目前基于统计模型和传统机器学习的异常检测方法已经十分成熟。

深度学习采用端到端的训练方式,在处理复杂的高光谱图像上表现出很大的优势,其深层结构可以很好地提取深层、稳定可靠的非线性光谱特征,从而用于检测和识别(赵永强等,2020),利用深度学习方法进行异常检测仍是一个值得探索的前沿领域,并逐渐成为研究的重点。

在非监督学习算法中最经典的是基于自编码器(autoencoder, AE)的检测算法(Bati等,2015),这也是首次将深度学习应用在高光谱图像异常检测中,该算法通过评估每个像素处的编码重构误差,并将其作为异常的度量,能够比较容易地捕捉到高光谱数据中的主要光谱特征。Ma等人(2018)提出了基于自适应权重深度置信网络(deep belief network, DBN)的高光谱图像异常检测算法,有效地统计更新技术可自适应地生成邻域权重,提高了检测的准确率。随后很多学者通过不同的方式改进了堆栈式自编码器,从而进行高光谱图像的目标探测,其中,由多层去噪自编码器组成的网络(Zhao等,2017)可应用在复杂背景的目标检测中;基于低秩稀疏矩阵分解的堆栈式自编码器(Zhao等,2018)同时利用了空间和光谱信息,其性能要优于仅使用光谱特征的方法;加入了目标和背景之间距离约束的堆栈式稀疏自编码器(Shi等,2019)可以更好地提取光谱特征,用于后续的异常检测。然而,非监督学习的相关算法对噪声和异常光谱向量比较敏感,可能会导致对异常的过度拟合,进而影响检测精度(Jiang等,2020)。

监督式的方法主要是基于卷积神经网络(convolutional neural network, CNN)的检测算法,CNN利用局部连接从图像中提取稳定深层特征,网络的复杂性通过共享权重的方式大大降低,目前已经广泛应

用于高光谱图像的处理分析中。但是监督学习的算法在高光谱图像的分类、异常检测等领域会存在带标签训练样本严重不足的问题,因此样本增广策略显得尤其重要。最有代表性的就是像素配对特征(pixel-pair features, PPFs)策略,像素配对的思想可以很好地解决深层网络需要大量训练数据的问题,用少量的参考标记样本就可以生成大量的训练数据集,用于网络的训练,从而更好地提取像素对特征。CNN模型利用该策略可以完成高光谱图像的分类任务(Li等,2017a),也可以通过迁移学习应用到异常检测当中(Li等,2017b),其效果相对于传统方法都有一定的提升。

基于卷积神经网络的异常检测方法(PPF-CNN)中,网络的输入为像素对之间的光谱差异值,而光谱相减可能会丢失部分能够有效区分像素向量的光谱特征;同时在高光谱图像中,相同地物的光谱在数值上可能会存在较大的差异,如果将这种情况下的像素对光谱差异值输入到网络中,可能会得到一个较高的异常预测值,从而影响检测性能。而本文提出的结合孪生神经网络(siemese neural network, SNN)和像素配对特征的高光谱图像异常检测方法(PPF-SNN)可以直接对原始像素对进行特征提取,尽可能多地利用像素向量中具有区分性的光谱特征信息,进而更好地识别异常目标。与此同时,采用滑动双窗口策略来构建测试像素对,将其输入至特征提取模块获得用于二分类的像素对特征,并经过特征处理模块得到测试像素的异常预测值。通过3幅真实高光谱数据的实验表明,本文提出的PPF-SNN方法相较于传统的异常检测算法如GRXD(global RXD)、LRXD(local RXD)、CRD以及PPF-CNN方法具有更好的检测效果。

1 方法

本文提出的结合孪生网络和像素配对特征的异常检测方法基本流程如图1所示。

1.1 像素配对策略

像素配对策略需要一个带有地面真值图的高光谱参考数据,该数据有多种不同的地物类型,且每类含有大量样本,用于像素的配对(Li等,2017b)。现假设参考数据有 n 类地物,并将该数据记为 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$,其中 $\mathbf{x}_i (i = 1, 2, \dots, n)$ 表示第 i 类




图1 结合孪生网络和像素配对特征的异常检测流程图

Fig. 1 Flowchart of anomaly detection based on siamese neural network with pixel-pair features

标签下的样本集合,对应的标签为 $l_i \in \{1, 2, \dots, n\}$ 。从 $\mathbf{X}$ 中随机抽取两个像元 $\mathbf{P}_a$ 和 $\mathbf{P}_b$ 构成像素对 $\mathbf{P}_{ab}$,而像素对的标签定义方式为

$$\text{Label}(\mathbf{P}_{ab}) = \begin{cases} 0 & l_a = l_b = l \ (l = 1, 2, \dots, n) \\ 1 & l_a \neq l_b \end{cases} \quad (1)$$

式中, l_a 和 l_b 分别为像元 $\mathbf{P}_a$ 和 $\mathbf{P}_b$ 的标签,式(1)表示:若抽取的像元来自同一类别,则像素对的标签定义为0,若来自不同类别,则定义为1。图2展示了像素配对策略的基本思路。可以看出,从高光谱图像的参考数据里随机选取两个像元,二者若来自同一类别,则在光谱曲线上具有很强的相似性;如果来自不同类别,则二者的光谱曲线差异性较大。

通过这种方式可以构建一个数量呈指数型增长的新数据集,将新数据集中的像素对输入到孪生神经网络中,利用网络来学习输入样本的差异性特征。其中训练好的分类器模型可以辨别输入样本的特征差异,将其迁移到异常检测中,可以用于区分异常目标和背景地物。

1.2 像素配对特征孪生神经网络

孪生神经网络(SNN)是衡量输入数据之间相似性的有力工具,主要思想是:两个样本经过成对的神经网络后可以在低维空间映射成两个特征向量,通过判断二者特征是否相似来衡量输入数据的匹配程度,原始的SNN一般采用基于所提取特征向量欧氏距离的对比损失函数来优化网络,基本结构如图3所示。本文对原始SNN结构中的低维特征向量决策层进行改进,并没有使用对比损失函数进行网络参数的学习,而是将两个特征进行了整合并利用网




图2 像素配对策略

Fig. 2 Pixel-pair strategy




图3 孪生神经网络(SNN)

Fig. 3 Siamese neural network




图4 像素配对特征孪生神经网络(PPF-SNN)

Fig. 4 Siamese neural network with pixel-pair features

络来学习输入对的差异性,更加有效地衡量像素对的相似程度。由于本文所设计的网络模型保留了原始SNN中利用两个共享网络提取成对输入特征的主体结构,并且最终的输出反映了配对像素的差异性,所以仍可以视为一种孪生网络。本文设计的用于高光谱图像异常检测的孪生神经网络称为像素配对特征孪生神经网络(PPF-SNN),结构如图4所示,其中主要包含两个模块:特征提取模块和特征处理模块。特征提取模块的分支网络采用了共享权值的CNN结构,特征处理模块利用卷积层和全连接层进行分类任务。

作为像素向量特征提取器的CNN结构如图5所示,该模块一共包含10个卷积层,其中第1~9个卷积层(C1~C9)均采用 1×3 的卷积核,且后面都有批量归一化(batch normalization, BN)层和ReLU激活函数,用于加速随机梯度下降算法的收

敛以及保证网络可以适当稀疏,并在一定程度上防止网络训练时出现过拟合的现象。CNN的输入是大小为 1×224 的像素光谱信息,由于输入样本为1维数据,因此网络模型采用了1维卷积操作。其中第1和第2个卷积层(C1和C2)采用了8个大小为 1×3 的卷积核,滑动步长为1,为了保证输出特征图的深度不变,实验采用了周围填充的方式,因此可以得到8个大小为 1×224 的特征图。在这里选取了滑动步长为2的卷积层(例如C3,C5,C7等)作为降采样层,将得到的光谱特征图深度减半,这将带来光谱信息的损失,因此进行降维操作的同时,也伴随着特征图数目的增加(从8增大为16、32以及64)。随着网络的深度增加,输入像素的非线性特征可以被提取出来,并且最后得到的特征更具代表性。经过第9个卷积层(C9)后,可得到64个特征图,尺寸为 1×14 ,然后采用 1×1 的卷积核进行特

征图通道间的整合,最终得到 1×14 的输入像素光谱特征。至此,输入像素的特征提取工作已经完成。




图5 特征提取模块

Fig. 5 Feature extraction module

将像素对输入孪生网络的特征提取模块即可得到两个大小为 1×14 的像素特征,若输入标签为0的像素对,即来自同一类别的像素,经过CNN可以得到相似的特征对,而输入标签为1的像素对会得到有一定差异的特征对。如图6所示的特征处理模块位于特征提取模块之后,其中,通过一个简单的神经网络(本文采用了一个卷积层)来学习特征之间差异性,并利用全连接层将特征对映射为一个数,用来反映像素对的差异性,使卷积层专注于特征对中具有可分性特征的提取。该模块首先将输入的特征对进行样本级的拼接,得到通道数为2、大小为 1×14 的像素对特征,可以将其看成 $1 \times 14 \times 2$ 的张量,经过4个大小为 $1 \times 3 \times 2$ 、步长为2的卷积核,进而提取像素对之间的差异特征,并希望利用后面的全连接层进行正确分类。其中全连接层采用了两层(节点数分别为28和14),完成像素对的二分类,最后经过sigmoid层将数值约束到 $[0, 1]$ 范围内,将数据非线性地归一化,同时给出像素对的差异性分数,即类别不同的概率。




图6 特征处理模块

Fig. 6 Feature processing module

将新数据集中同类的像素对样本输入孪生网络,可以得到接近于0的异常概率,而不同类的样本输出接近于1。将训练好的二分类网络迁移到异常检测,用于区分测试集中的背景和异常像素。

1.3 滑动双窗口检测模型

在高光谱图像中,背景和异常目标的光谱维信息在很大程度上会有一些不同,而上述模型可以鉴别成对像素的特征差异性,并分类为相似类和不同类,因此,可以将训练好的二分类网络模型的参数固定,然后迁移至检测模块。与构造训练样本的方法类似,需要对测试数据进行像素配对,但需要采用一些规律性手段,有效地利用地物分布特点来选取配对像元。由于异常目标在场景图中分布不集中,且所占比例较小,因此可采取局部检测的思想,利用滑动双窗口模型(Li等,2017b),重点分析中心像素和外窗像素之间的差异性,并作为判定异常的基准。

滑动双窗口检测模型如图7所示,以 3×5 双窗口为例,其中内窗中的像素作为缓冲区不参与检测,中心像素 T 为待测像素,外窗上的像素作为周围背景像素,与中心像素进行配对。外窗一共有16个像素,记为 $n(n=1, 2, \dots, 16)$,因此每次移动双窗口框架可得到16组像素对,记为 $\{T-1, T-2, \dots, T-16\}$ 。将测试像素对输入训练好的孪生网络模型,可以产生16个异常分数 $\{t_1, t_2, \dots, t_{16}\}$,其范围在 $[0, 1]$ 之间,分别表示每个周围背景像素和待测像素之间的差异性分数,输出的分数越接近于1,说明二者之间不相似程度越高。最后对其进行均值化处理,可以得到中心像素的异常预测值 $D(T)$,而 $D(T)$ 代表了待测像素和周围像素的不相似性,将其与提前设置的阈值 η 进行比较,若高于阈值,则待测像素 T 的表现倾向于异常,反之亦然。计算为

$$D(T) = \frac{1}{16} \sum_{i=1}^{16} t_i \quad (2)$$




图7 滑动双窗口检测模型

Fig. 7 Sliding double window detection model

2 实验结果与分析

受迁移学习同源性的限制,实验中选取的测试集和训练集要在波段数上保持一致,其波段范围大致相同,并且尽可能来自同一传感器。因此,实验部分选用的高光谱数据均由机载可见光/红外成像光谱仪 (airborne visible infrared imaging spectrometer, AVIRIS) 传感器采集得到,其中参考数据为 Salinas 场景,通过像素配对策略构建大量的像素对,用于网络的训练;测试数据分别为 San Diego 数据中的两幅高光谱真实场景图和 Airport-Beach-Urban (ABU)-Airport 数据中的一幅真实场景图,通过滑动双窗口检测模型构建测试像素对,用于异常目标的检测。实验中的对比算法有 GRXD、LRXD、CRD 以及 PPF-CNN,以 ROC(receiver operating characteristic) 曲线以及 ROC 曲线下面积(area under the curve, AUC) 作为算法对比的评价指标,其中越靠近左上角的曲线对应的 AUC 值越大,说明算法的异常检测效果越好。

本文提出的 PPF-SNN 异常检测算法使用 Adam 优化器 (weight_decay=0.001)、ReLU 激活函数以及带有 sigmoid 层的二进制交叉熵损失 (BCEWithLogitsloss) 函数,学习率设置为 0.001。进行实验的操作系统为 Ubuntu 16.04, CPU 为 Intel Core i7-5930K,内存为 128 GB, GPU 为 GTX 1080Ti 11 GB,

深度学习框架为 Pytorch。其中传统的异常检测算法 GRXD、LRXD 以及 CRD 则是使用 MATLAB 实现。

2.1 实验数据

Salinas 数据集获取于加利福尼亚州的萨利纳斯谷,原始图像由 512×217 个像素构成,含有 224 个波段,波长范围为 $0.4 \sim 2.45 \mu\text{m}$,光谱分辨率达到 10 nm,空间分辨率为 3.7 m。该场景共包含 16 类地物,主要由庄稼、蔬菜等植物构成,如图 8 所示。




图8 Salinas 场景图像

Fig. 8 Salinas scene image((a) pseudocolor image of Salinas scene (using bands 70, 40, and 20); (b) Salinas ground truth map)

San Diego 数据集获取于加利福尼亚州圣地亚哥机场区,原始图像空间大小为 400×400 像素,空间分辨率为 3.5 m。San Diego 机场主要包含飞机、草地以及道路等地物,实验中选取了两幅大小为 100×100 像素带有飞机的子场景作为测试数据,并记为 San Diego-1 和 San Diego-2,其假彩色图像和地面真值图像分别如图 9 以及图 10(a)(b) 所示。




图9 San Diego-1 数据集的异常检测结果图

Fig. 9 Results of anomaly detection on San Diego-1 dataset

((a) pseudocolor; (b) ground truth; (c) GRXD; (d) LRXD; (e) CRD; (f) PPF-CNN; (g) PPF-SNN(ours))




图 10 San Diego-2 数据集的异常检测结果图

Fig. 10 Results of anomaly detection on San Diego-2 dataset

((a) pseudocolor; (b) ground truth; (c) GRXD; (d) LRXD; (e) CRD; (f) PPF-CNN; (g) PPF-SNN(ours))

ABU-Airport 数据集获取于美国密西西比州的格尔夫波特, 图像空间大小为 100×100 像素, 空间

分辨率为 3.4 m, 其主要异常目标为 3 个飞机, 如图 11(a) (b) 所示。




图 11 ABU-Airport 数据集的异常检测结果图

Fig. 11 Results of anomaly detection on ABU-Airport dataset

((a) pseudocolor; (b) ground truth; (c) GRXD; (d) LRXD; (e) CRD; (f) PPF-CNN; (g) PPF-SNN(ours))

2.2 实验结果分析

从 Salinas 参考数据中, 选取不同类的像素进行配对, 构成负样本, 选取来自相同类的配对像素构成正样本, 二者数量比为 1 : 1, 利用正负样本及其标签来训练网络, 其中 PPF-CNN 使用正负样本的像素对差值进行训练, 而 PPF-SNN 直接使用正负样本的像素对。通过滑动双窗口模型构建 3 幅真实场景的测试数据集, 将其输入到训练好的网络, 即可得到异常检测结果, 而其余传统的检测算法均不需要训练, 可对高光谱图像直接进行处理和检测。

在所有算法中, 除 GRXD 以外的方法均采用了局部双窗口的思想, 模型的检测性能与设置的窗口大小密切相关, 因此在实验中, 选取了不同大小的双窗口模型来直接或间接地进行高光谱图像的异常检测。如表 1—表 3 所示, 分别为 San Diego-1、San Diego-2 和 ABU-Airport 数据集在不同大小窗口下不同算法的 AUC 值对比, 从表中可以得到以下结论: 1) 在 3 个数据集中, 传统算法均在窗口较大时具有较好的检测性能, 而基于深度学习的方法在不同的数据集上实现最佳的检测效果时, 所使用的窗口大小不固定。2) 基于深度学习的方法, 特别是本文所提出的 PPF-SNN 算法在 San Diego-1 和 ABU-Airport

数据集上, 使用不同大小的双窗口均可以得到较高的 AUC, 网络的鲁棒性要优于其他算法。上述现象出现的原因可能是真实场景的地物复杂且分布不均匀, 传统方法受其影响较大, 不同大小的窗口所得到的背景估计使检测结果有一定差别, 而神经网络的检测能力受窗口尺寸的影响较小, 表现较为稳定。

在 3 个数据集上分别选取大小合适的窗口, 得到 PPF-SNN 和其他对比算法的最佳检测结果, 如

表 1 在 San Diego-1 数据集上不同大小窗口下不同算法的 AUC 值

Table 1 AUC values of different algorithms under different window sizes on San Diego-1 dataset

窗口大小	算法				
	GRXD	LRXD	CRD	PPF-CNN	PPF-SNN
3 × 5		0.560 38	0.783 90	0.964 31	0.987 21
5 × 7		0.545 85	0.810 41	0.973 60	0.990 52
7 × 9	0.909 15	0.638 09	0.835 40	0.980 00	0.992 22
9 × 11		0.736 94	0.916 52	0.982 24	0.992 51
11 × 13		0.801 16	0.966 80	0.988 07	0.992 87
13 × 15		0.798 30	0.981 11	0.990 05	0.993 51

注: 加粗字体为每列最优值。

表 2 在 San Diego-2 数据集上不同大小窗口下
不同算法的 AUC 值

Table 2 AUC values of different algorithms under different window sizes on San Diego-2 dataset					
窗口大小	算法				
	GRXD	LRXD	CRD	PPF-CNN	PPF-SNN
3 × 5		0.768 73	0.915 51	0.967 10	0.981 21
5 × 7		0.808 56	0.933 44	0.962 43	0.971 30
7 × 9		0.800 04	0.938 18	0.960 44	0.966 16
9 × 11	0.953 52	0.797 34	0.946 48	0.951 29	0.951 94
11 × 13		0.823 15	0.957 07	0.951 20	0.932 88
13 × 15		0.856 80	0.970 70	0.952 48	0.915 86
15 × 17		0.877 61	0.978 56	0.947 73	0.900 29

注:加粗字体为每列最优值。

表 3 在 ABU-Airport 数据集上不同大小窗口下
不同算法的 AUC 值

Table 3 AUC values of different algorithms under different window sizes on ABU-Airport dataset					
窗口大小	算法				
	GRXD	LRXD	CRD	PPF-CNN	PPF-SNN
3 × 5		0.830 85	0.783 51	0.949 51	0.981 46
5 × 7		0.879 57	0.868 15	0.949 49	0.984 28
7 × 9		0.847 03	0.762 40	0.942 13	0.982 46
9 × 11	0.952 6	0.889 45	0.884 29	0.952 07	0.983 94
11 × 13		0.945 41	0.927 95	0.945 73	0.984 38
13 × 15		0.951 00	0.948 43	0.945 33	0.981 07
15 × 17		0.962 85	0.967 46	0.948 05	0.978 51

注:加粗字体为每列最优值。

图 9—图 11 所示,并绘制不同检测算法的 ROC 曲线,如图 12—图 14 所示,从中可以得到以下结论:1)提出的 PPF-SNN 算法与其他方法相比,在 3 幅真实场景中均可以实现最高的检测精度,AUC 值可以分别达到 0.993 51、0.981 21 和 0.984 38,相对于 PPF-CNN 具有较大的提升。2)传统算法的高光谱图像异常检测结果图中,虚警区域较少,同时检测出的异常目标(飞机)像元也相对较少,例如传统的方法无法检出 ABU-Airport 数据集上右侧的两个小飞机;而监督式的深度学习算法会产生部分虚警区域,主要是一些道路和房屋建筑边界,原因是这些地物与周围背景在光谱上存在一定的差异,双窗口中心的待测像

素容易被网络识别为异常。3)本文提出的 PPF-SNN 异常检测算法在一定程度上可以抑制虚警,




图 12 San Diego-1 数据集上不同检测算法的 ROC 曲线

Fig. 12 ROC curves of different detection algorithms on San Diego-1 dataset




图 13 San Diego-2 数据集上不同检测算法的 ROC 曲线

Fig. 13 ROC curves of different detection algorithms on San Diego-2 dataset




图 14 ABU-Airport 数据集上不同检测算法的 ROC 曲线

Fig. 14 ROC curves of different detection algorithms on ABU-Airport dataset

更加突出检测所发现的异常目标,从而进一步提高检测率。上述现象充分说明了本文提出的 PPF-SNN 算法可以提取输入像素对中具有区分性的特征,并可以有效地实现其异常度的判定,进而取得更好的检测效果。

滑动双窗口检测模型在不同大小窗口条件下构建的测试集像素对数量不同,输入到神经网络得到检测结果的时间也不相同,表 4 展示了各个异常检测算法(多数采用局部思想)在不同大小窗口条件下检测相同场景所消耗的时间。其中传统算法是在 MATLAB 上运行检测,而基于深度学习的算法是在 GPU(graphics processing unit)上训练测试。由于全局检测方法 GRXD 计算量较小,计算复杂度较低,因此其测试消耗时间最短;局部检测中深度学习的算法耗时比 LRXD 短,同时随着检测的图像尺寸和所选择的窗口的增大,深度学习算法的时间复杂度优势不断增加,因为神经网络大量的数据运算转移到 GPU 上,计算速度有了很大的提升。由于 PPF-CNN 算法的输入数据只有一组(差值),而 PPF-SNN 的输入数据有两组,其加载测试数据消耗时间较长,因此,两种深度学习算法的检测过程存在 12 s 左右的时差。

表 4 不同异常检测算法在实验数据集上的测试时间
Table 4 Processing time of different anomaly detection algorithms on experimental dataset

算法	/s	
	3 × 5 窗口	13 × 15 窗口
GRXD	0.156	
LRXD	49.869	81.920
CRD	2.441	8.682
PPF-CNN	25.722	31.560
PPF-SNN	37.297	44.416

注:加粗字体为最优值。

3 结 论

高光谱图像中存在的同物异谱、异物同谱问题,是限制高光谱图像异常检测效果提升的主要因素,而传统的异常检测算法无法充分挖掘高光谱图像的深层光谱特征,难以克服这一问题。因此,本文提出了结合孪生网络和像素配对特征的异常检测算法,

利用深度网络强大的特征挖掘能力,直接将配对像素中具有区分度的特征提取出来,而不是利用像素对之间的差异值进行处理分析,从而更好地判定异常,进一步提高检测精度,同时也可以缓解监督学习算法带来检测结果中虚警较多的问题。实验表明,本文算法得到的 AUC 值要高于其他对比算法,得到了更好的检测结果。未来的研究将专注于如何有效抑制监督学习算法带来的虚警,并且更加突出检测所发现的异常目标;消除迁移时同源性的限制问题,进一步提高网络的泛化能力。

参考文献 (References)

- Bati E, Çalışkan A, Koz A and Alatan A A. 2015. Hyperspectral anomaly detection method based on auto-encoder//Proceedings of SPIE 9643, Image and Signal Processing for Remote Sensing XXI. Toulouse, France; SPIE: #96430 [DOI: 10.1117/12.2195180]
- Guo Q D, Zhang B, Ran Q, Gao L R, Li J and Plaza A. 2014. Weighted-RXD and linear filter-based RXD: improving background statistics estimation for anomaly detection in hyperspectral imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7 (6): 2351-2366 [DOI: 10.1109/JSTARS.2014.2302446]
- Jiang K, Xie W Y, Li Y S, Lei J, He G and Du Q. 2020. Semisupervised spectral learning with generative adversarial network for hyperspectral anomaly detection. IEEE Transactions on Geoscience and Remote Sensing, 58 (7): 5224-5236 [DOI: 10.1109/TGRS.2020.2975295]
- Khan M J, Khan H S, Yousaf A, Khurshid K and Abbas A. 2018a. Modern trends in hyperspectral image analysis: a review. IEEE Access, 6: 14118-14129 [DOI: 10.1109/ACCESS.2018.2812999]
- Khan M J, Yousaf A, Abbas A and Khurshid K. 2018b. Deep learning for automated forgery detection in hyperspectral document images. Journal of Electronic Imaging, 27 (5): #053001 [DOI: 10.1117/1.JEI.27.5.053001]
- Kwon H and Nasrabadi N M. 2005. Kernel RX-algorithm: a nonlinear anomaly detector for hyperspectral imagery. IEEE Transactions on Geoscience and Remote Sensing, 43 (2): 388-397 [DOI: 10.1109/TGRS.2004.841487]
- 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]
- Li W, Wu G D, Zhang F and Du Q. 2017a. Hyperspectral image classification using deep pixel-pair features. IEEE Transactions on Geoscience and Remote Sensing, 55 (2): 844-853 [DOI: 10.1109/TGRS.2016.2616355]

- Li W, Wu G D and Du Q. 2017b. Transferred deep learning for anomaly detection in hyperspectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 14(5): 597-601 [DOI: 10.1109/LGRS.2017.2657818]
- Ma N, Peng Y, Wang S J and Leong P H W. 2018. An unsupervised deep hyperspectral anomaly detector. *Sensors*, 18(3): #693 [DOI: 10.3390/s18030693]
- Ma S X, Liu C T, Li H C, He Z X and Wang H. 2019. Improved collaborative algorithm based on spatial-spectral joint clustering for hyperspectral anomaly detection. *Acta Photonica Sinica*, 48(1): #0110003 (马世欣, 刘春桐, 李洪才, 何祯鑫, 王浩. 2019. 基于空谱联合聚类的改进核协同高光谱异常检测. *光子学报*, 48(1): #0110003) [DOI: 10.3788/gzxb20194801.0110003]
- 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]
- Shi Y Z, Lei J, Yin Y P, Cao K L, Li Y S and Chang C I. 2019. Discriminative feature learning with distance constrained stacked sparse autoencoder for hyperspectral target detection. *IEEE Geoscience and Remote Sensing Letters*, 16(9): 1462-1466 [DOI: 10.1109/LGRS.2019.2901019]
- 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]
- Zhang B and Gao L R. 2011. *Hyperspectral Image Classification and Target Detection*. Beijing: Science Press: 1-298 (张兵, 高连如. 2011. *高光谱图像分类与目标探测*. 北京: 科学出版社: 1-298)
- Zhang X, Han L X, Dong Y Y, Shi Y, Huang W J, Han L H, González-Moreno P, Ma H Q, Ye H C and Sobeih T. 2019. A deep learning-based approach for automated yellow rust disease detection from high-resolution hyperspectral UAV images. *Remote Sensing*, 11(13): #1554 [DOI: 10.3390/rs11131554]
- Zhao C H, Li X Y and Zhu H F. 2017. Hyperspectral anomaly detection based on stacked denoising autoencoders. *Journal of Applied Remote Sensing*, 11(4): #042605 [DOI: 10.1117/1.JRS.11.042605]
- Zhao C H and Zhang L L. 2018. Spectral-spatial stacked autoencoders based on low-rank and sparse matrix decomposition for hyperspectral anomaly detection. *Infrared Physics and Technology*, 92: 166-176 [DOI: 10.1016/j.infrared.2018.06.001]

- Zhao Y Q, Rao Y, Dong S P and Zhang J Y. 2020. Survey on deep learning object detection. *Journal of Image and Graphics*, 25(4): 0629-0654 (赵永强, 饶元, 董世鹏, 张君毅. 2020. 深度学习目标检测方法综述. *中国图象图形学报*, 25(4): 0629-0654) [DOI: 10.11834/jig.190307]

- Zhou J, Kwan C, Ayhan B and Eismann M T. 2016. A novel cluster kernel RX algorithm for anomaly and change detection using hyperspectral images. *IEEE Transaction on Geoscience and Remote Sensing*, 54(11): 6497-6504 [DOI: 10.1109/TGRS.2016.2585495]

作者简介



王德港, 1997年生, 男, 博士研究生, 主要研究方向为高光谱图像异常检测与目标探测。
E-mail: wangdegang20@mails.ucas.ac.cn



孙旭, 通信作者, 男, 副研究员, 主要研究方向为高光谱遥感图像处理与信息提取。
E-mail: sunxu@aircas.ac.cn

饶伟强, 男, 博士研究生, 主要研究方向为高光谱图像异常检测与目标探测算法及其硬件化设计。

E-mail: raowq@radi.ac.cn

渠瀛, 女, 博士后, 主要研究方向为遥感信息处理、图像处理、机器学习。E-mail: yqu3@vols.utk.edu

刘雪梅, 女, 研究员, 主要研究方向为遥感图像目标探测与伪装总体设计。E-mail: liuxm109@gmail.com

高连如, 男, 研究员, 主要研究方向为高光谱遥感图像处理与信息提取。E-mail: gaolr@aircas.ac.cn