



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: TP751.2 文献标识码: A 文章编号: 1006-8961(2021)08-1940-12

论文引用格式: Fang S, Zhang K, Zhang J, Cao Y and Shi W K. 2021. Hyperspectral image classification with enhanced class separability. Journal of Image and Graphics, 26(08): 1940-1951 (方帅, 张坤, 张晶, 曹洋, 石为开. 2021. 增强类可分性的高光谱图像分类. 中国图象图形学报, 26(08): 1940-1951) [DOI:10.11834/jig.210029]

增强类可分性的高光谱图像分类

方帅^{1,2}, 张坤¹, 张晶^{1*}, 曹洋³, 石为开⁴

1. 合肥工业大学计算机与信息学院, 合肥 230601; 2. 工业安全与应急技术安徽省重点实验室, 合肥 230601;
3. 中国科学技术大学信息科学技术学院自动化系, 合肥 230027; 4. 澳门科技大学计算机技术与应用, 澳门 999078

摘要: **目的** 在高光谱图像分类中, 由于成像空间分辨率较低, 混合像元大量存在。混合像元使得不同类别的光谱特征发生改变, 失去原有的独特性, 类内差异变大, 类间差异变小。针对这一问题, 本文提出基于分组滚动引导滤波的策略。同时针对高光谱图像中存在的“维数灾难”问题, 提出了弹性网逻辑回归分类器的框架。**方法** 通过线性判别分析(linear discriminant analysis, LDA)算法生成具有判别性的引导图, 对高光谱图像的每个波段执行滚动引导, 从而让光谱曲线呈现类内凝聚、类间距离增大的趋势。通过构造逻辑回归目标函数的 L1&L2 范数正则项约束进行嵌入式波段选择, 为每个类别选择出自可分性强的波段, 同时可以使高度相关性的波段保留下来作为分类依据。最后使用邻域优化策略对分类后结果进一步优化, 提升分类精度。**结果** 分别在 3 个实验数据集上与其他分类算法进行对比, 实验结果表明, 本文算法的分类结果取得明显提升。本文算法的总体分类精度(overall accuracy, OA)在 Indian Pines, Salinas 和 KSC(Kennedy Space Center)数据集上分别为 96.61%、98.66% 和 99.04%, 比其他算法平均分别高出 4.8%、3% 和 1%, 同时也在 Indiana Pines 数据集中进行了对比实验以验证增强混合像元光谱可分性和波段可分性算法的有效性, 对比实验结果表明本文算法改善了分类效果。**结论** 分别在光谱特性和波段选择两个环节增强类可分性, 分类精度取得明显提升; 同时, 本文算法适合不同的数据集, 并且在不同数量的训练样本下 OA 均表现较优, 算法具有一定的鲁棒性。

关键词: 遥感; 高光谱图像分类; 增强类可分性; 分组滚动引导滤波; 弹性网逻辑回归

Hyperspectral image classification with enhanced class separability

Fang Shuai^{1,2}, Zhang Kun¹, Zhang Jing^{1*}, Cao Yang³, Shi Weikai⁴

1. School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China;
2. Anhui Province Key Laboratory of Industry Safety and Emergency Technology, Hefei 230601, China; 3. Department of Automation, School of Information Science and Technology, University of Science and Technology of China, Hefei 230027, China;
4. Computer Technology and Application, Macau University of Science and Technology, Macao 999078, China

Abstract: **Objective** Hyperspectral images have been investigated and hyperspectral image classification has been widely used in many fields in recent years. Long-distance remote sensing hyperspectral images have a lot of mixed pixels due to the low spatial resolution. The ground features originally have unique spectral characteristics, but the mixed pixels reduce the

收稿日期: 2021-01-15; 修回日期: 2021-04-13; 预印本日期: 2021-04-20

* 通信作者: 张晶 zhangjing@hfut.edu.cn

基金项目: 国家重点研发计划项目(2018YFC0213104); 国家自然科学基金项目(61872327, 61175033); 中央高校基本科研业务费专项资金资助(JZ2017HGBZ0930, WK2380000001)

Supported by: National Key Research and Development Program of China(2018YFC0213104); National Natural Science Foundation of China(61872327, 61175033); Fundamental Research Funds for the Central Universities(JZ2017HGBZ0930, WK2380000001)

separability of spectral characteristics of different ground, which increases the difficulty of hyperspectral image classification. Observing the spectral curves of long-distance remote sensing hyperspectral images indicates that the spectral curves of the single type show the tendency of larger difference within the class, and the difference between classes becomes smaller because it is mixed with different types of ground features. If the selected samples are insufficient, then misclassification between classes may occur. Moreover, the classification map has “salt and pepper noise”, which leads to low classification accuracy. The traditional method uses the spectral-spatial feature joint classification method to increase the constraint of spatial information for improving the classification accuracy. This way can correct some misclassification results, but it does not improve the problem of difficult classification between classes caused by mixed pixels. Thus, a strategy based on grouped rolling guidance filtering is proposed in this study. The linear discriminant analysis (LDA) algorithm is used to generate a discriminative guidance image, and rolling guidance filtering is performed on each band of the hyperspectral image. Spectral curves show the trend of intra-class condensation given that the guidance image contains the information of classification, and the distance between classes increases. At the same time, hyperspectral images have lots of bands, and many adjacent bands may be heavily redundant and fail to provide additional discriminative information. The generalization capability of the classifier is limited when high-dimensional bands are fed back, that is, the curse of dimensionality, under the condition of insufficient labeled pixels. Reducing the number of bands, that is, dimensionality reduction, is an effective strategy to solve these challenges. The embedded band selection is the best comprehensive performance at present because it solves various matrix-based optimization objectives consisting of different loss functions and regularization terms. However, it exhibits sparsity. If multiple features are useful and highly correlated, then least absolute shrinkage and selection operator (LASSO) tends to keep one and drop the rest. This condition affects the stability. We aim to improve its ability to select groups of correlated variables and utilize its group effect to improve classification accuracy. Thus, we use the framework of elastic net logistic regression to enhance band selection, the respective strongly separable bands are selected for each class, and the strongly correlated bands can be retained at the same time. **Method** We focus on enhancing spectral separability and band separability of mixed pixels in this study. The framework of grouped rolling guidance filtering and elastic net logistic regression is used to enhance class separability in spectral characteristics and band selection. First, the hyperspectral images are divided into groups according to the spectral direction, and the training data of each group by performing the LDA algorithm are used to obtain the first projection vector. The most discriminative guidance image is generated for each group of hyperspectral images. Then, rolling guidance filtering is conducted on each band of the hyperspectral image. Spectral curves show the increasing trend of intra-class condensation and distance between classes. We use the framework of elastic net logistic regression to enhance band selection. By constructing L1 and L2 norm regularization constraints on logistic regression objective function, embedded band selection is performed to select bands with strong separability for each category, and bands with strong correlation can be retained as the classification basis. We use the neighborhood optimization method to improve the classification results. **Result** We compare our algorithms with five state-of-the-art classic algorithms on three public datasets, namely, the India Pines, Salinas, and Kennedy Space Center (KSC) datasets. The quantitative evaluation metrics include overall accuracy (OA), kappa coefficient, and average accuracy. We also provide several classification maps of each method for comparison on India Pines dataset. The experiment is repeated 10 times under each experimental condition to improve its reliability and accuracy, and the average value of the 10 experimental results is taken as the final result. Experimental results show that our model outperforms all other methods on India Pines, Salinas, and KSC datasets. Moreover, the OA of the proposed algorithm has achieved 96.61%, 98.66%, and 99.04% on the Indian Pines, Salinas, and KSC datasets, respectively. These values are 1%—4% higher than those of other optimal algorithms. We conduct a series of comparative experiments on Indian Pines to clearly show the effectiveness of different steps of the proposed algorithm. Comparative experiments with a different number of training samples are also performed. The experiment shows that the OA of the proposed method is always the highest under different datasets. By contrast, other comparison algorithms are unstable over different datasets. Therefore, the proposed algorithm can improve the robustness. **Conclusion** Experiments on three hyperspectral image datasets show that the proposed algorithm enhances class separability in spectral characteristics and band selection compared with other algorithms. The classification accuracy is also significantly improved. The proposed algorithm is suitable for different datasets and has good robustness as well.

Key words: remote sensing; hyperspectral image classification; enhanced class separability; grouped rolling guidance filtering; elastic net logistic regress

0 引言

高光谱图像通常由上百个连续窄波段组成,蕴含着近似连续的地物光谱曲线,使得本来在宽波段成像中不可感知的目标,在高光谱遥感中能被探测。因此,高光谱图像可以实现更加精准的图像解译。

对于机载或星载长距离遥感高光谱成像而言,地面扫描幅宽大,成像空间分辨率较低,导致大量混合像元(彭倩等,2017)的存在。地物目标原本具有独特的光谱曲线,但是混合像元使得不同类别目标光谱特性可分性降低,增加了高光谱分类的难度。通过对长距离遥感高光谱图像的光谱曲线观察发现,同一类别的光谱曲线,由于以不同比例与不同目标混合,呈现出类内差异大、类间不可分的趋势。当选取的样本不够充分时,分类结果易出现跨类别错误,导致分类精度较低,在分类结果图上呈现类似“椒盐噪声”,导致分类精度较低。为了提高分类精度,通过使用空—谱间特征联合分类的方法,如MP(morphological profiles)特征(Fauvel等,2008)、EMEPs(extended multi-extinction profiles)特征(Xia等,2018),取得了比较好的效果。在高光谱图像的边缘区域,光谱特性更为复杂,Li和Du(2014)提出了基于Gabor滤波的最近邻正则化子空间的分类算法。同时还有使用图像分割来探索空间的一致性的方法,如联合稀疏表达(Zhang等,2014)、形状自适应稀疏表达(Fu等,2016)算法。最近,基于边缘保护滤波器的空—谱结合的方法在高光谱图像分类中有着广泛的应用(Kang等,2014;方帅等,2019;Zhang等,2020)。增加空间信息的约束,确实能够校正一部分错误分类结果,但是本质上并没有改善混合像元带来的光谱不可分问题。此外,深度学习也在高光谱图像分类中得到应用,He等人(2019)提出了基于多尺度协方差图特征提取的高光谱图像分类方法。

高光谱数据波段多、数据量大、冗余突出,再加上有限的训练样本,会出现“维数灾难”(Hughes,1968)。因此,波段选择可用来应对这一问题。过滤式波段选择方法是通过计算波段本身的属性进行

评分,例如基于距离准则(Keshava,2004)、基于信息准则(Feng等,2014)。过滤式波段选择主要关注冗余性、相关性和信息完备性,忽略了类可分性。封装式波段选择用选择的波段组合训练分类器,依据分类器的性能评价波段组合(Cao等,2016)。该方法优点是针对给定的分类器评价波段子集,分类性能要好于过滤式波段选择;缺点是多次训练分类器,计算复杂度极大,且分类器训练和波段选择是割裂开进行的。嵌入式波段选择是在训练分类器的过程中自动进行波段选择,最常用的L1正则化,通过系数“稀疏”的特性,起到波段选择的作用。然而,如果不同的可分性波段具有高度相关性,LASSO(least absolute shrinkage and selection operator)算法会从中选取一个波段,因此,不能保留多个高度相关的可分性波段。

根据以上分析,目前遥感高光谱图像分类存在如下问题:1)大量混合像元的存在,使得不同类别光谱可分性减弱,耦合性增强,为分类带来挑战;2)为了避免维数灾难,高光谱分类需要进行波段选择,然而目前效果最好的嵌入式波段选择,由于急于追求“稀疏”,对冗余零容忍,可分性强的波段由于相关性而被剔除,无法保留所有可分性波段。

针对以上两个问题,本文工作主要聚焦于增强混合像元光谱可分性和波段可分性,做出了如下贡献:1)本文提出了分组滚动引导滤波策略增强光谱曲线可分性,使用线性判别分析(linear discriminant analysis, LDA)算法生成一幅最具有判别性的投影图像作为引导图,对每个波段进行滚动引导,由于引导图本身包含了类别的信息,从而让光谱曲线呈现类内凝聚、类间距离增大的趋势。2)针对波段选择存在的问题,本文提出了弹性网逻辑回归分类器,让分类器为每个类别挑选各自具有判别性的波段,不仅实现可分性波段选择,而且可以保留高度相关的可分性波段,更加精准地实现了类属波段选择。

1 高光谱图像分类算法

1.1 光谱可分性增强

1.1.1 问题

混合像元使得目标光谱特征会发生改变,并失

去独特性。与不同地物混合、以不同比例混合, 导致类内光谱具有多样性, 不凝聚; 同时混合也导致类间耦合性加强。以 Indian Pines 数据集为例, 每类随机选取 20 条光谱曲线, 如图 1(a) 所示, 红色曲线是

Corn-notill 类, 黑色曲线是 Grass-pasture-mowed 类。可以看出, Corn-notill 类光谱曲线分布广, 具有多样性, Corn-notill 类与 Grass-pasture-mowed 类之间存在复杂的耦合性。




图 1 滤波处理前后的光谱曲线对比

Fig. 1 Comparison of spectral curves before and after filtering

((a) original image; (b) LDA 10th filtering; (c) LDA 30th filtering; (d) PCA 80th filtering)

1.1.2 解决策略

为增强光谱的可分性, 本文基于 LDA 思想生成具有判别性的图像, 即同类的像素值尽可能接近, 不同类间的差别尽可能大。利用该图像作为引导图, 对高光谱图像的每个波段执行引导滤波 (He 等, 2013), 使每个波段图像都趋向于“更小的类内距离和更大的类间距离”, 从而增强目标光谱曲线的类可分性。

由于 LDA 算法需要用到类标签, 高光谱图像波段数多, 即样本维度高, 但样本不丰富。因此可能会

出现样本维度大于训练样本总数的情况, 这使得类内散度矩阵不可逆, 不满足 LDA 算法条件, 比如 200 波段的高光谱图像, 样本维度 $L = 200$, 训练样本个数 $n = 100$ 。为此, 本文按照波段分组执行 LDA, 假设分为 5 组, 则分别为 1 ~ 40、41 ~ 80、81 ~ 120、121 ~ 160、161 ~ 200, 样本维度从 200 维降为 40 维。因此, 通过分组可以避免类内散度矩阵不可逆。

如图 2 所示, 基于分组滚动引导滤波的策略, 来增强光谱可分性。具体算法包含如下两个步骤:

1) 按照波段方向分组, 每组执行 LDA 算法, 将该




图 2 光谱可分性增强框架

Fig. 2 Spectral separability enhancement framework

组光谱图像投影产生一幅具有判别性的图像,该图像的特点是相同类别的像素值保持高度一致性,不同类别的像素值保证一定的差异性。

2) 步骤1)中生成的图像作为引导图,对组内每个波段图像进行 T 次引导滤波操作,称为分组滚动引导滤波,滤波后的高光谱图像合并生成新的高光谱图像,其中滤波后的训练集用于分类。

图1(c)是经过分组滚动引导滤波处理后的结果,观察红线发现, Corn-notill 类内更加凝聚,与 Grass-pasture-mowed 类之间差异也变大,尤其在 110~140 波段。输入图像、引导图、滤波后图像分别记为 p, g 和 q 。引导滤波假设 q 与 g 在滤波窗口 w_k 上存在局部线性关系,即 $q_i = a_k g_i + b_k$ (在局部窗口内, a_k 和 b_k 是常量),也即对于引导图中的平坦区域,滤波后图像在该区域也会趋于平坦,对于引导图中的变化区域,滤波后图像在该区域也会有相同趋势的变化。LDA 引导图具有类内凝聚类间差异的特性,因此,滤波后的各个波段图像也会呈现该特性。

对比图1(b)(c)可以看出,随着引导的迭代次数增加,类内光谱更加凝聚,类间光谱距离逐渐增大,最终光谱曲线类内凝聚会达到一个稳定态。引导滤波的目标函数 $\sum_{w_k} (a_k g_i + b_k - p_i)^2 + \epsilon a_k^2$,从目标函数可以看出,滤波结果 q 不仅要与引导图 g 具有相同的变化趋势,还要保证与输入图像 p 保持一致。因此,滤波结果 q 受输入图像 p 和引导图像 g 共同约束。若只执行一次引导滤波操作,由于受到输入图像本身的约束,对每个波段图像的改变是有限的。本文采取滚动引导滤波,引导图像不变,滤波结果作为下一次的滤波输入图像,相当于在迭代调整输入图像,使其朝着引导图像分布趋势的方向发展。因此,经过多轮迭代,最终光谱曲线类内凝聚类间差异会达到一个稳定态。

对比图1(c)(d)可以看出,使用 LDA 滚动引导后的光谱曲线相比于 Pan 等人(2017)使用的主成分分析(principal component analysis, PCA)滚动引导后的光谱曲线,类内更加凝聚,类间可分性增强且滚动引导次数更少。

1.2 可分性类属波段选择与分类器

1.2.1 问题

对于高光谱图像的“维数灾难”问题,常见的解

决方案是波段选择。嵌入式波段选择是目前综合性能最好的,通过正则化“稀疏”来实现。遥感图像特定地物目标往往在某些特定波段区间具有明显的可分性,以 Indian Pines 数据集中3类地物为例,如图3所示, Corn 类在 10~50 和 110~140 波段可分性好, Grass-pasture 类在 30~40 和 60~70 波段可分性好,不同类别地物对应不同的可分性好的波段,称之为类属波段。因此,希望为每个类别挑选出该类可分性波段。




图3 类属波段选择

Fig. 3 Label band selection

L1 嵌入式波段选择急于追求“稀疏”,如果有多个高度相关的可分性波段,往往倾向于保留其中一个,不能保留高度相关可区分性波段。然而,希望尽可能保留多个高可分性波段,利用其群体效应,提高分类精度。

1.2.2 解决策略

针对上述波段选择的问题,本文引入弹性网(Zou 和 Hastie, 2005)技术,通过 L1&L2 范数共同约束,在稀疏性和光滑性之间达到一种均衡,可以有效解决特征选择中组效应的问题,尽可能保留高相关的可分性波段。弹性网稀疏性约束能够剔除没有判别性波段,保留“孤立的”高可分波段;光滑性约束通过保留更多的高可分性波段,从而保留了高可分的局部结构信息。由于局部结构信息的引入,进一步提升了分类精度。

本文利用弹性网逻辑回归技术,将波段选择和分类器融合在同一框架。这样做有3个好处:1)通过样本数据学习,同时实现波段选择和分类器学习,选择出类可分性好的波段;2)实现为每个类别选择不同的波段;3)通过弹性网的技术,既实现了可分

性波段选择,又保留了高可分的局部结构信息。

高光谱图像的波段为 L , 含有 N 个像素, $\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_q\} \in \mathbf{R}^{L \times N}$ 。式中每个样本 $\mathbf{X}_i$ 都是一个 L 维的向量, 高光谱图像含有 $k = \{1, 2, \dots, K\}$ 个标签。假设标签 $\mathbf{Y} = \{y_1, y_2, \dots, y_N\} \in \mathbf{R}^{K \times N}$ 为高光谱图像的标签, 其中 y_i 属于 1 到 K 的编码。例如, 如果样本 $\mathbf{X}_i$ 属于第 K 类, 则 $y_i^{(K)} = 1$, 否则, $y_i^{(K)} = 0$ 。滤波处理后的 n 个训练集样本可以表示为 $\mathbf{D} = \{(\mathbf{X}_1, y_1), \dots, (\mathbf{X}_n, y_n)\}$ 。

在多分类逻辑回归模型下, 样本 $\mathbf{X}$ 属于第 i 类的概率可表示为

$$P(y^{(i)} = 1 | \mathbf{X}, \mathbf{w}) = \frac{\exp(\mathbf{w}^{(i)\top} \mathbf{X})}{\sum_{j=1}^K \exp(\mathbf{w}^{(j)\top} \mathbf{X})} \quad (1)$$

式中, 对于 $i \in \{1, 2, \dots, K\}$, $\mathbf{w}_i$ 是第 i 类的权重向量。

在有监督的学习中, $\mathbf{w}$ 是从训练数据集 $\mathbf{D}$ 中学习得到的。对 $\mathbf{w}$ 最大似然估计得到

$$l(\mathbf{w}) = - \sum_{j=1}^n \log P = - \sum_{j=1}^n \left[\sum_{i=1}^K y_j^{(i)} \mathbf{w}^{(i)\top} \mathbf{X}_j - \log \sum_{i=1}^K \exp(\mathbf{w}^{(i)\top} \mathbf{X}_j) \right] \quad (2)$$

为了获得 $\mathbf{w}$ 的稀疏解, 使用弹性网进行约束, 即

$$\mathbf{w} = \arg \min_{\mathbf{w}} l(\mathbf{w}) + \alpha_1 \|\mathbf{w}\|_1 + \alpha_2 \|\mathbf{w}\|_2 \quad (3)$$

式中, α_1, α_2 为弹性网系数。

图 4 是在 α_1 相同下的弹性网和 LASSO 的系数可视化。其中图 4(a)(b) 展现了弹性网回归和 LASSO 回归非零系数的分布。对比图 4(a)(b), 两个回归都为不同类别选择了不同的波段, 起到类属波段选择的作用; LASSO 回归较难选择高相关性的可分性波段, 而弹性网回归克服了这一缺陷, 使得高相关的高可分性波段可以共存。通过对比图 4(c)(d), 进一步比较弹性网回归和 LASSO 系数值, 可以发现弹性网回归通过降低回归系数的值, 保留了更




图 4 Indian Pines 数据集的弹性网和 LASSO 的系数可视化(白色代表非 0 系数)

Fig. 4 Visualization of the elastic net and LASSO coefficients of the Indian Pines(nonzero coefficients are marked with white lines)
((a) sparse visualization of elastic net;(b) sparse visualization of LASSO;(c) weights of elastic net;(d) weights of LASSO)

多的高可分性波段。这与目标函数式(3)的导向一致,当 α_1 保持不变时,增加了2范数的正则项后,目标函数变大,为了能逼近目标函数下界,会减小系数值,但是会导致经验损失增大(式(3)第1项),在弹性网(Zou和Hastie,2005)即2范数和1范数的约束下,会少量增加一些非零系数,即选择更多的波段,相关性高的可分性的波段会大概率被选中。

1.3 分类后处理

图像在空间上平滑性假设被用于分类是非常重要的,对于分类后的结果,使用邻域优化(Luo等,2019)进行后处理。邻域优化是通过像素点周围高置信区间的分类结果对低置信区间进行纠正,进一

步提高分类精度

$$y_{(a,b)} = \arg \max_y \left\{ \sum_{j=1}^k \frac{num(y = y_j)}{s \times s - 1} \right\} \quad (4)$$

式中, (a,b) 代表邻域的中心, s 代表邻域的宽度,本文设置 $s=3$, k 代表类别的总数, $num(\cdot)$ 代表邻域中满足条件的标签个数。

2 实验与分析

2.1 实验数据集

实验数据(http://www.ehu.eus/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes)包括如表1所示的3组,数据显示如图5所示。

表1 数据集说明
Table 1 Dataset description

数据集	采集地点	空间分辨率/m	图像尺寸/像素	波段数	类别数	带标签像素点
Indian Pines	印第安纳州	20 × 20	145 × 145	200	16	10 249
Salinas	加利福尼亚州	3.7 × 3.7	512 × 217	204	16	54 129
KSC	佛罗里达州	18 × 18	512 × 614	176	13	5 211




图5 数据集

Fig. 5 Datasets((a) Indian Pines dataset;(b) Salinas dataset;(c) KSC dataset)

2.2 对比算法和评估标准

本文的对比算法有 EPFs (edge-preserving filtering) (Kang等,2014)、HiFi-We (Pan等,2017)、LCMR (local covariance matrix representation) (Fang等,2018)、CCJSR (correlation coefficient and joint sparse representation) (Tu等,2018)和MSFE (multi-scale feature extraction) (Tu等,2019),其中HiFi-We是基于分层引导滤波的集成分类算法,与本文算法最为接近;EPFs是对分类结果进行引导滤波处理,利用空间信息,提高精度;LCMR是特征提取后使用

(support vector machine, SVM)进行分类的算法;CCJSR和MSFE是最新的空谱联合分类算法。对于分类结果,采用3个常见的分类精度的评价指标:全局准确率(overall accuracy, OA)、卡帕系数(Kappa coefficient, Kappa)以及均值准确率(average accuracy, AA)。

2.3 实验参数设置

实验使用如下参数:1)光谱分组参数 M ,本文设置 $M=4$;2)引导滤波参数(He等,2013),有2个参数 r 、 ε 分别代表引导滤波的窗口半径大小和正则

化参数,由于数据集的空间分辨率不同,3个数据集分别取 $r = 1, \varepsilon = 1; r = 4, \varepsilon = 1; r = 1, \varepsilon = 1$ 。3) 滚动迭代次数 T ,本文设置 $T = 30$ 。4) 弹性网逻辑回归参数 α_1, α_2 ,分别为0.01和0.000 1。对比算法参数均沿用原文参数设置。

2.4 实验设计与结果分析

2.4.1 实验设计

为了验证本文方法的优越性,设计如下实验,同时为体现实验的公平性,实验中所有的算法均采用1.3节中的后处理技术。

实验1:为验证本文光谱可分性增强的有效性,将原始高光谱图像和分组滚动引导后高光谱图像,分别带入到弹性网逻辑回归分类器。

实验2:为体现本文的类属波段选择的有效性,将分组滚动引导后的高光谱图像,分别带入到LASSO逻辑回归分类器和弹性网逻辑回归分类器。

实验3:为体现邻域优化的效果,对比使用邻域后处理前后的分类结果。

实验4:为验证本文算法整体性能,在3个数据集上与其他5个算法进行比较。

实验5:为验证本文算法的鲁棒性,分别在不同训练样本数下与实验3中的算法进行比较。

2.4.2 实验结果与分析

本文的实验结果都是对分类器进行10次实验,表2—表6是对评价指标取平均值和方差。对于实验1和实验2都是以Indian Pines数据集为例,每类随机选取50个样本,不足50个样本的地物选取一半(共697个样本)作为训练样本,进行实验。

实验1:为了验证本文的光谱可分性增强的作用,对比有无光谱可分性增强对实验的影响。分类结果如表2所示,可以看出本文光谱可分性增强,对于分类指标OA、AA和Kappa分别有17.18%、9.18%

表2 原始光谱和光谱增强的比较

Table 2 Comparison of original spectrum and enhanced spectrum

指标	/%	
	原始光谱	增强光谱
OA	79.43(1.64)	96.61(0.66)
AA	89.21(1.08)	98.39(0.31)
Kappa	76.71(1.86)	96.11(0.76)

注:加粗字体为每行最优值,括号内的数字代表方差。

和19.4%的提升。

实验2:为了验证本文的类属波段选择的作用,将分组滚动引导后的高光谱图像,分别代入到相同参数 α_1 下的L1逻辑回归分类器和L1&L2逻辑回归分类器进行实验。分类结果如表3所示,可以看出本文的类属波段选择,对于分类指标OA、AA和Kappa分别有0.66%、0.1%和0.75%的提升。

表3 L1回归与L1&L2回归比较

Table 3 Comparison of L1 and L1&L2 regression

指标	/%	
	L1回归	L1&L2回归
OA	95.95(0.89)	96.61(0.66)
AA	98.29(0.28)	98.39(0.31)
Kappa	95.36(1.01)	96.11(0.76)

注:加粗字体为每行最优值,括号内的数字代表方差。

实验3:为了验证邻域优化的作用,对比邻域优化前后对实验的影响。分类结果如表4所示,可以看出邻域优化对于分类指标都有一定的提升。

表4 邻域优化前后实验结果对比

Table 4 Comparison of before optimization and after optimization

指标	/%	
	邻域优化前	邻域优化后
OA	95.52(0.67)	96.61(0.66)
AA	97.76(0.27)	98.39(0.31)
Kappa	94.86(0.76)	96.11(0.76)

注:加粗字体为每行最优值,括号内的数字代表方差。

实验4:为了验证本文算法的优越性,分别在3个不同的数据集上,随机选取训练集和测试集,对以上算法进行对比实验。对于Indian Pines数据集:每类随机选取50个样本,不足50个样本的地物选取一半(共697个样本)作为训练集,其余的作为测试集,10次实验中随机选择1次分类结果如图6所示,从中可以看出本文算法可以有效解决混合像元带来的影响,尤其是红框所在的位置,分类结果比较好。算法分类定量评价如表5所示。其中,HiFi-We和本文算法在进行分类前,都进行了光谱可分性增强,因此,分类精度较高。本文由于引导图考虑到类间区别,以及分类器的类属波段选择,分类精度最高。LCMR局部协方差特征提取考虑到了类内与类间的距离,分

类效果较好。CCJSR 和 MSFE 是空谱联合分类,EPFs 利用光谱分类,然后对分类结果依赖空间先验进行校正,都会一定程度受到混合像元的影响。本文算法更能减少类内的光谱差异和增加类间的可区分性,如表 5

所示,在 16 类中,本文算法在 8 类上取得了最好的效果。在整体 OA,AA,Kappa 性能上,均取得最优,且方差最小,算法性能更加稳定。其他两个数据集与此类似。由于篇幅所限,表 6 和表 7 只给出了整体性能。




图 6 Indian Pines 分类结果

Fig. 6 Classification results on Indian Pines((a) EPF;(b) HiFi-We;(c) LCMR;(d) CCJSR;(e) MSFE;(f) ours)

表 5 Indian Pines 数据集分类指标对比

Table 5 Comparison of classification indicators on Indian Pines

类别							/%
	EPFs	HiFi-We	LCMR	CCJSR	MSFE	本文	
Alfalfa	81. 83	100	98. 7	87. 6	60. 99	100	
Corn-notill	89. 43	95. 6	96. 16	83. 9	87. 84	96. 39	
Corn-mintill	86. 58	97. 58	96. 42	79. 34	87. 79	95. 64	
Corn	56. 92	99. 82	100	64. 73	76. 82	100	
Grass-pasture	97. 62	97. 71	98. 8	94. 73	94. 93	98. 13	
Grass-trees	96. 49	99. 82	98. 71	94. 85	87. 35	98. 88	
Grass-pasture-mowed	100	97. 62	97. 86	64. 63	70	100	
Hay-windrowed	100	100	100	99. 85	86. 37	100	
Oats	99. 09	100	100	58. 36	10	100	
Soybean-notill	74. 84	95. 93	94. 24	78. 72	91. 04	94. 90	
Soybean-mintill	94. 97	90. 78	90. 91	95. 49	95. 91	93. 07	
Soybean-clean	76. 47	98. 59	96. 21	80. 92	81. 7	98. 67	
Wheat	100	99. 87	99. 35	97. 34	91. 77	100	
Woods	99. 16	99. 67	99. 84	99. 48	97. 35	99. 78	
Buildings-Grass-Trees-Drives	72. 45	99. 66	100	85. 5	89. 71	99. 76	
Stone-Steel-Towers	83. 12	95. 19	99. 77	56. 14	98. 8	99. 07	
OA	87. 90(1. 81)	96. 17(1. 21)	95. 91(0. 76)	88. 22(1. 46)	90. 63(0. 73)	96. 61(0. 66)	
AA	88. 06(2. 28)	97. 99(0. 55)	97. 94(0. 40)	82. 60(1. 47)	81. 15(2. 55)	98. 39(0. 31)	
Kappa	86. 25(2. 01)	95. 62(1. 37)	95. 31(0. 87)	86. 61(1. 63)	89. 27(0. 83)	96. 11(0. 76)	

注:加粗字体为每行最优值,括号内的数字代表方差。

对于 Salinas 数据集,每类随机选取 50 个样本(共 900 个样本)作为训练集,其余的作为测试样本。定量评价如表 6 所示。本文算法在 16 类中,5 类取得了最好的效果,本文算法的 OA,AA 和 Kappa

均高于其他算法,且方差最小,算法性能更加稳定。

对于 KSC(Kennedy Space Center)数据集,由于数据集的样本个数较少,每类随机选取20个样本

表 6 Salinas 数据集分类指标对比
Table 6 Comparison of classification indicators on Salinas

指标	EPFs	HiFi-We	LCMR	CCJSR	MSFE	本文
OA	94.72(0.86)	95.24(0.80)	98.48(0.69)	92.18(1.30)	97.42(0.45)	98.66(0.38)
AA	97.01(0.40)	97.92(0.32)	99.08(0.27)	94.87(0.50)	96.99(0.32)	99.13(0.21)
Kappa	94.12(0.96)	94.70(0.89)	98.31(0.77)	91.30(1.44)	97.67(0.50)	98.51(0.43)

注:加粗字体为每行最优值,括号内的数字代表方差。

表 7 KSC 数据集分类指标对比
Table 7 Comparison of classification indicators on KSC

指标	EPFs	HiFi-We	LCMR	CCJSR	MSFE	本文
OA	97.71(0.75)	98.18(0.83)	99.00(0.44)	96.50(1.01)	98.51(0.44)	99.04(0.28)
AA	96.43(1.03)	98.09(0.77)	98.94(0.43)	95.81(1.36)	97.59(1.04)	98.98(0.52)
Kappa	97.45(0.83)	97.97(0.93)	98.94(0.50)	96.09(1.12)	98.33(0.49)	98.77(0.52)

注:加粗字体为每行最优值,括号内的数字代表方差。

(共 260 个样本)作为训练集,其余的作为测试样本。定量评价如表 7 所示。本文算法在 13 类中,6 类取得了最优,相比于其他算法,本文算法在 OA 和 AA 上取得最优,Kappa 取得次优。

实验 5:为验证本文算法在不同训练样本数下的鲁棒性,在 Indian Pines、Salinas 数据集上分别为每类随机选取 20~60 个样本作为训练集;由于 KSC 数据集样本个数较少,在 KSC 数据集上分别为每类随机选取 8~24 个样本作为训练集,与上述算法做对比。

图 7(a)~(c)是所有算法在 Indian Pines、Salinas 和 KSC 数据集下 OA 的平均值。从图 7 可以看出,随着训练样本的减小,每个算法的 OA 也在下降,由于本文采取了分组的操作,KSC 数据集在样本个数较少时,阻止了 LDA 奇异值的产生。因此,取得较优的结果。在 Indian Pines 和 Salinas 数据集中,本文提出的算法在不同样本量下,OA 均取得最优,在 KSC 数据集上 OA 取得较优,而其他对比算法在不同的数据集上均表现各异。因此本文算法具有一定的鲁棒性。




图 7 不同训练样本量下全局准确率

Fig. 7 Overall classification accuracy with different numbers of training sample((a) Indian Pines;(b) Salinas;(c) KSC)

3 结 论

本文提出了基于增强类可分性策略的高光谱图

像分类的算法,主要解决混合像元导致的类不可分问题和高光谱数据的可分性波段类属波段选择问题。在分类前进行预处理,利用 LDA 产生一个类别差异的引导图,通过滚动引导策略,恢复地物光谱的

可分性。分类器采用弹性网逻辑回归训练分类器,同时,不仅为每个类别选择各自可分性强的波段,还能将高度相关性的波段保留下来作为分类依据,利用群体效应,提高分类精度。通过在3个真实高光谱图像数据集上的实验表明,本文算法相比其他分类算法,分类精度有所改进,且在样本个数较少的时候也有不错的鲁棒性。

本文在对高光谱分类时,为每个类选择具有可分性的类属波段作为特征,考虑的分类特征较为简单,高光谱图像分类特征有很多,如几何特性、植被指数和导数光谱波形等,下一步的研究将构建更有效的分类特性,提高分类精度。

参考文献 (References)

- Cao X H, Xiong T and Jiao L C. 2016. Supervised band selection using local spatial information for hyperspectral image. *IEEE Geoscience and Remote Sensing Letters*, 13 (3): 329-333 [DOI: 10.1109/LGRS.2015.2511186]
- Fang L Y, He N J, Li S T, Plaza A J and Plaza J. 2018. A new spatial-spectral feature extraction method for hyperspectral images using local covariance matrix representation. *IEEE Transactions on Geoscience and Remote Sensing*, 56(6): 3534-3546 [DOI: 10.1109/TGRS.2018.2801387]
- Fang S, Zhu F J, Dong Z Y and Zhang J. 2019. Sample optimized selection of hyperspectral image classification. *Journal of Image and Graphics*, 24 (1): 135-148 (方帅, 祝凤娟, 董张玉, 张晶. 2019. 样本优化选择的高光谱图像分类. *中国图象图形学报*, 24(1): 135-148 [DOI: 10.11834/jig.180437])
- Fauvel M, Benediktsson J A, Chanussot J and Sveinsson J R. 2008. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 46(11): 3804-3814 [DOI: 10.1109/tgrs.2008.922034]
- Feng J, Jiao L C, Zhang X R and Sun T. 2014. Hyperspectral band selection based on trivariate mutual information and clonal selection. *IEEE Transactions on Geoscience and Remote Sensing*, 52 (7): 4092-4105 [DOI: 10.1109/TGRS.2013.2279591]
- Fu W, Li S T, Fang L Y, Kang X D and Benediktsson J A. 2016. Hyperspectral image classification via shape-adaptive joint sparse representation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9 (2): 556-567 [DOI: 10.1109/JSTARS.2015.2477364]
- He K M, Sun J and Tang X O. 2013. Guided image filtering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(6): 1397-1409 [DOI: 10.1109/TPAMI.2012.213]
- He N J, Paoletti M E, Mario Haut J, Fang L Y, Li S T, Plaza A and Plaza J. 2019. Feature extraction with multiscale covariance maps for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57 (2): 755-769 [DOI: 10.1109/TGRS.2018.2860464]
- Hughes G. 1968. On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 14 (1): 55-63 [DOI: 10.1109/TIT.1968.1054102]
- Kang X D, Li S T and Benediktsson J A. 2014. Spectral-spatial hyperspectral image classification with edge-preserving filtering. *IEEE Transactions on Geoscience and Remote Sensing*, 52 (5): 2666-2677 [DOI: 10.1109/TGRS.2013.2264508]
- Keshava N. 2004. Distance metrics and band selection in hyperspectral processing with applications to material identification and spectral libraries. *IEEE Transactions on Geoscience and Remote Sensing*, 42(7): 1552-1565 [DOI: 10.1109/TGRS.2004.830549]
- Li W and Du Q. 2014. Gabor-filtering-based nearest regularized subspace for hyperspectral image classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(4): 1012-1022 [DOI: 10.1109/JSTARS.2013.2295313]
- Luo K Q, Qin Y, Yin D and Xiao H. 2019. Hyperspectral image classification based on pre-post combination process//*Proceedings of the 6th International Conference on Systems and Informatics (ICSAI)*. Shanghai, China: IEEE: 1275-1279 [DOI: 10.1109/ICSAI48974.2019.9010227]
- Pan B, Shi Z W and Xu X. 2017. Hierarchical guidance filtering-based ensemble classification for hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 55(7): 4177-4189 [DOI: 10.1109/TGRS.2017.2689805]
- Peng Q, Zhang B, Sun X, Gao L R and Yu W B. 2017. Hyperspectral unmixing based on spatial and spectral preprocessing prior and constrained non-negative matrix factorization. *Journal of Image and Graphics*, 22(4): 542-550 (彭倩, 张兵, 孙旭, 高连如, 于文博. 2017. 结合空间光谱预处理和约束非负矩阵分解的高光谱图像混合像元分解. *中国图象图形学报*, 22(4): 542-550 [DOI: 10.11834/jig.20170414])
- Tu B, Zhang X F, Kang X D, Zhang G Y, Wang J P and Wu J H. 2018. Hyperspectral image classification via fusing correlation coefficient and joint sparse representation. *IEEE Geoscience and Remote Sensing Letters*, 15 (3): 340-344 [DOI: 10.1109/LGRS.2017.2787338]
- Tu B, Li N Y, Fang L Y, He D B and Ghamisi P. 2019. Hyperspectral image classification with multi-scale feature extraction. *Remote Sensing*, 11(5): #534 [DOI: 10.3390/rs11050534]
- Xia J S, Ghamisi P, Yokoya N and Iwasaki A. 2018. Random forest ensembles and extended multiextinction profiles for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(1): 202-216 [DOI: 10.1109/TGRS.2017.2744662]
- Zhang H, Liu W J and Lyu H H. 2020. Spatial-spectral joint classifica-

tion of hyperspectral image with locality and edge preserving. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 13: 2240-2250 [DOI: 10.1109/JSTARS.2020.2994210]

Zhang H Y, Li J Y, Huang Y C and Zhang L P. 2014. A nonlocal weighted joint sparse representation classification method for hyperspectral imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7(6): 2056-2065 [DOI: 10.1109/JSTARS.2013.2264720]

Zou H and Hastie T. 2005. Regularization and variable selection via the elastic net. Journal of the Royal Statistical Society: Series B, 67(2): 301-320 [DOI: 10.1111/j.1467-9868.2005.00503.x]

作者简介



方帅, 1978 年生, 女, 教授, 主要研究方向为计算机视觉、图像复原。

E-mail: fangshuai@hfut.edu.cn



张晶, 通信作者, 女, 副教授, 主要研究方向为人工智能、数据挖掘。

E-mail: zhangjing@hfut.edu.cn

张坤, 男, 硕士研究生, 主要研究方向为遥感图像分类。

E-mail: zhangk_hfut@163.com

曹洋, 男, 副教授, 主要研究方向为人工智能、计算机视觉。

E-mail: forrest@ustc.edu.cn

石为开, 男, 本科生, 主要研究方向为高光谱图像分类。

E-mail: 18098533i011013@stedent.must.edu.m