



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 4<sup>th</sup> 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)08-1823-13

论文引用格式: Lyu M, Chen T H, Li W, Yang Y, Tu T Q and Li W G. 2021. Tensor-based graph embedding for discriminant analysis of membranous nephropathy hyperspectral data. Journal of Image and Graphics, 26(08): 1823-1835 [吕蒙, 陈天虹, 李伟, 杨悦, 涂天琪, 李文歌. 2021. 膜性肾病诊断的高光谱图像张量嵌入分析. 中国图象图形学报, 26(08): 1823-1835] [DOI: 10.11834/jig.210190]

## 膜性肾病诊断的高光谱图像张量嵌入分析

吕蒙<sup>1</sup>, 陈天虹<sup>1</sup>, 李伟<sup>1\*</sup>, 杨悦<sup>2</sup>, 涂天琪<sup>2</sup>, 李文歌<sup>2</sup>

1. 北京理工大学信息与电子学院, 北京 100081; 2. 中日友好医院肾脏病科, 北京 100029

**摘要:** 目的 高光谱成像技术因其能够获取目标的详细空间和光谱信息, 在医学领域引起了广泛关注。然而, 对于识别任务来说, 高光谱图像的高维特征通常会导致分类器性能不佳。因此, 降维在高光谱图像分析过程中至关重要。为了在低维空间中保留医学高光谱图像的多流形结构信息并增强特征判别能力, 本文提出了一种基于张量表示的拉普拉斯稀疏低秩图嵌入方法 (tensor-based Laplacian regularized sparse and low-rank graph, T-LapSLRG), 用于医学高光谱图像的判别分析。**方法** 在 T-LapSLRG 中, 基于有标签的张量样本, 通过引入稀疏、低秩约束及流形正则项以构造监督张量图。张量表示用于捕获空间结构信息, 稀疏和低秩约束用于保留局部和全局结构信息, 流形正则项用于利用固有的几何信息并增强特征判别能力。通过引入张量图嵌入技术获取数据的低维特征并输入分类器以实现数据的分类及识别。**结果** 实验数据采用膜性肾病数据集, 通过降维方法获取数据的低维特征, 使用支持向量机 (support vector machine, SVM) 分类器对获取的低维特征进行分类。将 T-LapSLRG 获得的实验结果与相关的降维方法获得的实验结果进行性能比较, 以证明 T-LapSLRG 算法的有效性。采用 4 个性能指标, 即各个类别的准确性、总体准确性 (overall accuracy, OA)、平均准确性 (average accuracy, AA) 和 Kappa 系数衡量分类性能。T-LapSLRG 在膜性肾病数据集下的 OA 为 97.14%, AA 为 97.05%, Kappa 为 0.942, 各项性能指标均优于对比方法。其中, OA 高出 1.40% ~ 34.75%, AA 高出 1.46% ~ 36.89%, Kappa 高出 0.031 ~ 0.73。此外, 通过 T-LapSLRG 算法获得的各个患者的分类准确率均达到 90% 以上。**结论** T-LapSLRG 算法在膜性肾病诊断中具有潜在临床价值。

**关键词:** 医学高光谱图像; 膜性肾病; 张量; 降维 (DR); 图嵌入

## Tensor-based graph embedding for discriminant analysis of membranous nephropathy hyperspectral data

Lyu Meng<sup>1</sup>, Chen Tianhong<sup>1</sup>, Li Wei<sup>1\*</sup>, Yang Yue<sup>2</sup>, Tu Tianqi<sup>2</sup>, Li Wen'ge<sup>2</sup>

1. School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China;

2. Department of Kidney Disease, China-Japan Friendship Hospital, Beijing 100029, China

**Abstract:** **Objective** Hyperspectral imaging systems have become promising auxiliary diagnostic tools for intelligent medicine in recent years, especially in disease diagnosis and image-guided surgery. Hyperspectral image (HSI) has hundreds of contiguous narrow spectral bands from visible to infrared electromagnetic spectrum. These bands provide a wealth of information to distinguish different chemical composition of biological tissue. The reflected, fluorescent, and transmitted light

收稿日期: 2021-03-13; 修回日期: 2021-05-03; 预印本日期: 2021-05-10

\* 通信作者: 李伟 liwei089@ieee.org

基金项目: 北京市自然科学基金项目 (JQ20021); 国家自然科学基金项目 (61922013)

Supported by: Beijing Municipal Natural Science Foundation (JQ20021); National Natural Science Foundation of China (61922013)



from tissue captured by HSI carry quantitative diagnostic information about tissue pathology. Wealthy spectral bands also contain redundancy, which not only degrades classification performance but also increases computational complexity. Thus, dimensionality reduction (DR) needs to be conducted to reveal the essence of data by discarding redundant information. However, most of the current DR methods are based on spectral vector input (first-order representation) that ignores important correlations in the spatial domain. Although some spectral-spatial joint technologies have been investigated to overcome this disadvantage, they still consider the spectral-spatial feature into first-order data for analysis and ignore the cubic nature of hyperspectral data. Thus, a novel tensor-based Laplacian regularized sparse and low-rank graph (T-LapSLRG) for discriminant analysis is proposed to preserve the original intrinsic structure information of medical hyperspectral data and enhance the discriminant ability of features. **Method** Sparse and low-rank constraints are suggested in the proposed T-LapSLRG to exploit local and global data structures while tensor analysis is developed to preserve the spatial neighborhood information. Multi-manifold is utilized to enhance the discriminant ability and describe the intrinsic geometric information. Consequently, the proposed method not only can preserve local and global structure information but also can utilize the intrinsic geometric information. Thus, it offers more discriminative power than existing tensor-based DR methods. Vector-based methods treat each pixel as an independent and identically distributed item. By contrast, the samples in T-LapSLRG are represented in the form of a third-order tensor that can preserve the original spatial neighborhood information. In addition, only a small set of the labeled training samples is needed by adopting tensor training samples. With the assumption that the samples belonging to the same class lie on a unique sub-manifold, T-LapSLRG constructs tensor-based within-class graph to characterize the within-class compactness for making the resulting graph more discriminative. In summary, T-LapSLRG jointly utilizes spatial neighborhoods and discriminative and intrinsic structure information that capture the local and global structures and the discriminative information simultaneously and make the resulting graph more robust and discriminative. **Result** To evaluate the effectiveness of the proposed T-LapSLRG, the medical hyperspectral data of membranous nephropathy (MN) is used. The traditional diagnosis methods of MN mainly rely on serological characteristics and renal pathological characteristics, which is tough to reach the intelligent and automated requirements of clinical diagnosis. Two types of MN are used as the experimental verification data, including primary membranous nephropathy (PMN) and hepatitis B virus-related membranous nephropathy (HBV-MN). The microscopic hyperspectral images of PMN and HBV-MN are captured by the line scan hyperspectral imaging system SOC-710 together with the biological microscope CX31RTSF. The SOC-710 system captures 128 spectral bands with  $696 \times 520$  pixels and a spectral wavelength range from 400 to 1 000 nm. The obtained medical HSI dataset consists of 30 HBV-MN images and 24 PMN images, involving 10 HBV-MN patients and 9 PMN patients. Classification is performed on the obtained low-dimensional features by the classical support vector machine classifier to evaluate the performance of the proposed T-LapSLRG. Four objective quality indices (i.e., individual class accuracy, overall accuracy (OA), average accuracy (AA), and kappa coefficient (Kappa)) are used. The proposed T-LapSLRG outperforms other methods by 1.40% to 34.75% in OA, 1.46% to 36.89% in AA, and 0.031 to 0.73 in Kappa. In addition, the classification accuracy obtained by T-LapSLRG for all patients has reached more than 90%. In clinical diagnosis, the type of disease can be determined when the pixel level accuracy reaches 85% or more. **Conclusion** In this study, we proposed a novel tensor-based Laplacian regularized sparse and low-rank graph for discriminant analysis. Experiments on the MN dataset demonstrate that the proposed T-LapSLRG is effective in discriminant analysis with sparse and low-rank constraints and multi-manifold, and significantly improves the classification performance. Experimental results verify the nonnegligible potential of T-LapSLRG for further application in MN identification.

**Key words:** medical hyperspectral image; membranous nephropathy; tensor; dimensionality reduction (DR); graph embedding

## 0 引言

自 20 世纪 80 年代以来, 高光谱成像系统已成为具有广阔应用前景的智能医学辅助诊断工具, 尤

其是在疾病辅助诊断中 (Akbari 等, 2010; Lu 和 Fei, 2014; Lu 和 Mandal, 2014; Carrión-Camacho 等, 2019)。高光谱图像 (hyperspectral image, HSI) 具有许多连续的窄光谱带 (Fang 等, 2017; Wei 等, 2019; Zhang 等, 2021), 可以为区分生物组织的不同化学

成分提供丰富的信息(Lu 和 Fei, 2014)。然而,波段的增加导致数据包大量冗余信息,对分类性能造成负面影响的同时增加了计算复杂度。降维(dimensionality reduction, DR)是解决此类问题的有效技术之一,该技术通过提取包含数据本征信息的低维特征以去除冗余信息。

研究者已提出许多可用于高光谱图像分析的降维方法。基于变换投影的降维方法根据特定的准则将原始空间特征投影到低维子空间中,以保证低维特征包含足够的有效信息。其中,经典的基于投影的线性方法包括主成分分析(principal component analysis, PCA)(Jolliffe 和 Cadima, 2016), Fisher 线性判别分析(Fisher's linear discriminant analysis, LDA)(Yang 和 Yang, 2003)和独立成分分析(independent component analysis, ICA)(Villa 等, 2011; Dalla 等, 2011)。为了有效挖掘数据固有的非线性结构,提出了局部保持投影(locality preserving projection, LPP)(He 和 Niyogi, 2004)和邻域保持嵌入(neighborhood preserving embedding, NPE)(He 等, 2005)等。非参数加权特征提取(nonparametric weighted feature extraction, NWFE)(Kuo 和 Landgrebe, 2004)、局部 Fisher 判别分析(local Fisher discriminant analysis, LFDA)(Li 等, 2012)、核 LFDA(Li 等, 2011)和增强的 Fisher 判别分析(enhanced Fisher discriminant criterion, EFDC)(Gao 等, 2012)等,进一步将 LPP 与 LDA 集成在一起,以有效利用数据的局部信息和标签信息。

Yan 等人(2007)基于图论提出了通用图嵌入(graph embedding, GE)框架,归纳了大多数的变换投影降维方法。在通用图嵌入框架中,无向图用于表征结构信息。目前,获得相对稀疏图的主要技术是  $\varepsilon$  球近邻和  $k$  近邻( $k$ -nearest neighbor, kNN)。然而,这两种方法都对噪声敏感,并且在实践中通常难以设置合适参数。为了自适应地构造适当的图,引入稀疏表示(sparse representation, SR)(Wright 等, 2009, 2010)。通过探索数据的稀疏性,Cheng 等人(2010)提出了一种稀疏图嵌入模型(sparse graph embedding model, SGE)。Ly 等人(2014)利用类标签信息提出了基于稀疏图的判别分析(sparse graph-based discriminant analysis, SGDA)以提升 SGE 的性能。此外,为了降低计算复杂度,协同表示(collaborative representation, CR)(Zhang 等, 2011a)被用于

构建替代图,并提出基于协作图的判别分析(collaborative graph-based discriminant analysis, CGDA)方法及 CGDA 的块形式(block version of CGDA, BCGDA)。通过挖掘同类和异类样本间的基于 CR 的数据流形结构,Lyu 等人(2017)提出了判别流形图嵌入(collaborative discriminative manifold embedding, CDME)。

尽管 SR 和 CR 可以自适应地揭示数据局部结构,但它们忽略了全局结构。为了克服上述缺点,Chen 等人(2012)在图构造过程中引入了低秩表示(low rank representation, LRR)。如果原始空间中的数据位于多个线性子空间的并集上,则 LRR 具有出色的性能(Sumarsono 和 Du, 2015)。然而,现实中的数据并不总是线性的,特别是对于 HSI 数据,这可能导致 LRR 无法有效捕获几何结构(Cai 等, 2011)。为了保留局部几何结构,Liu 等人(2014)提出了 LapLRR(Laplacian regularized LRR)用于子空间聚类。另外,Li 等人(2016)提出一种基于稀疏和低秩图的判别分析方法(sparse and low-rank graph based discriminant approach, SLGDA)及其核形式(Pan 等, 2017b),以同时保留局部和全局结构信息。

然而,上述降维方法都是以向量为输入的,忽略了空间域中的重要相关性。尽管为克服此缺点研究了一些空间光谱联合分析技术(Tarabalka 等, 2010; Zhang 等, 2006, 2011b),但仍将空间光谱特征转换为矢量进行分析,忽略了 HSI 的本质多维结构——张量。为了利用张量数据中的空间光谱信息,研究者已经采用多线性代数开发了基于张量的分析技术(Zhang 等, 2013; Bourennane 等, 2010; An 等, 2016)。局部张量判别分析通过引入张量块,在去除冗余信息的同时充分挖掘数据的空间信息(Zhang 等, 2013)。为了保留低维空间中的光谱和空间结构信息,Deng 等人(2017, 2018)提出了张量局部保持投影(tensor LPP, TLPP)来学习投影矩阵。张量稀疏和低秩图的判别分析(tensor sparse and low-rank graph-based discriminant analysis, TSLGDA)通过在图构造过程中添加稀疏和低秩约束,获得了较好的降维结果(Pan 等, 2017a)。以上基于张量的方法已有效提升了分类精度,但它们缺乏对其他结构特征的有效挖掘(例如固有几何信息)。

在张量分析中,增强判别能力和利用固有结构信息是两个重要的问题。但是,现有的基于张量表示的降维方法通常分开考虑这两个问题,并且仅利

用部分的固有结构信息。本文通过构建一个集成的框架解决这些问题。综合考虑张量分析,多流形信息和判别信息,设计了一种基于张量的拉普拉斯稀疏低秩图(tensor-based Laplacian regularized sparse and low-rank graph, T-LapSLRG)嵌入技术,用于医学 HSI 的判别分析。在 T-LapSLRG 中,利用张量表示来捕获空间信息,同时引入稀疏和低秩约束以利用数据的局部和全局结构。多流形正则化约束用以学习具有判别信息的低维特征,并进一步调整基于张量的权重图以防止目标过拟合,这使得所提出的 T-LapSLRG 比其他基于张量的降维方法更具鲁棒性和鉴别力。本文首次将基于张量图的多流形图嵌入技术应用于医学高光谱图像分析。

慢性肾脏病(chronic kidney disease, CKD)是全球性的公共卫生问题(徐金升等, 2018),其发病率超过 10%。在 CKD 中,膜性肾病(membranous nephropathy, MN)是导致成人肾病综合征的一个常见病因(Ronco 和 Debiec, 2015; van den Brand 等, 2011; 徐金升等, 2018)。据报道,肾活检标本中 MN 的比例在全世界范围内持续升高(Dong 等, 2016; Schweitzer 等, 2015)。膜性肾病的传统诊断方法主要依靠血清学特征和肾脏病理学特征,已经不能满足临床对准确性和智能性的诊断需求。此外,传统光学图像上原发膜性肾病(primary MN, PMN)和乙肝相关膜性肾病(hepatitis B virus-associated MN, HBV-MN)之间的病理特征高度相似,很难用光学显微镜区分。因此本文验证数据采用中日友好医院采集的膜性肾炎数据,其中包含肾脏病科的 19 位不同患者的肾活检组织切片的 54 幅显微高光谱图像(10 名 HBV-MN 患者的 30 幅图像和 9 名 PMN 患者的 24 幅图像)。实验结果表明,所提出的 T-LapSLRG 在膜性肾病诊断中具有潜在的临床应用价值。

## 1 张量基本原理及运算

张量用于定义多维数组(Zhang 等, 2013)。多维数组的维数称为张量的阶数。对于  $N$  阶张量  $\mathcal{X} \in \mathbf{R}^{I_1 \times \cdots \times I_n \times \cdots \times I_N}$ , 其元素表示为  $\mathcal{X}_{i_1 \cdots i_n \cdots i_N}$ , 其中  $1 \leq i_n \leq I_n (1 \leq n \leq N)$ 。下面介绍几个相关的张量基本原理和定义。

定义 1  $k$  模展开。假设  $\mathcal{X} \in \mathbf{R}^{I_1 \times \cdots \times I_n \times \cdots \times I_N}$  是一个  $N$  阶张量,  $\mathbf{X}^{(k)} \in \mathbf{R}^{I_k \times (I_1 \cdots I_{k-1} I_{k+1} \cdots I_N)}$  是  $\mathcal{X}$  的  $k$  模展开, 它由  $\mathcal{X}$  的所有  $k$  模向量按列组成。

定义 2  $k$  模积。将  $\mathcal{Y} = \mathcal{X} \times_k U$  表示为张量  $\mathcal{X}$  和矩阵  $U \in \mathbf{R}^{J \times I_k}$  的  $k$  模积, 其中  $\mathcal{Y} \in \mathbf{R}^{I_1 \times \cdots \times I_{k-1} \times J \times I_{k+1} \times \cdots \times I_N}$ ,  $\mathcal{Y}$  中每一项计算为

$$\mathcal{Y}_{i_1 \cdots i_{k-1} j i_{k+1} \cdots i_N} = \sum_{i_k=1}^{I_k} \mathcal{X}_{i_1 i_2 \cdots i_N} U_{j i_k} \quad (1)$$

张量的展开可用于表示  $k$  模积, 即

$$\mathcal{Y} = \mathcal{X} \times_k U \Leftrightarrow \mathcal{Y}^{(k)} = U \mathbf{X}^{(k)} \quad (2)$$

定义 3 F-范数(Frobenius 范数)。张量  $\mathcal{X}$  的 F-范数为  $\|\mathcal{X}\|_F = (\sum_{i_1 \cdots i_N} (\mathcal{X}_{i_1 \cdots i_N})^2)^{1/2}$ 。

定义 4 张量缩并。张量  $\mathcal{X} \in \mathbf{R}^{I_1 \times \cdots \times I_N \times I'_1 \times \cdots \times I'_N}$  和张量  $\mathcal{Y} \in \mathbf{R}^{I_1 \times \cdots \times I_N \times \cdots \times I'_1 \times \cdots \times I'_N}$  的缩并定义为

$$[\mathcal{X} \otimes \mathcal{Y}; (1:N)(1:N)]_{i_1, i_2, \cdots, i_N} = \sum_{i'_1=1}^{I'_1} \cdots \sum_{i'_N=1}^{I'_N} \mathcal{X}_{i_1, \cdots, i_N, i'_1, \cdots, i'_N} \mathcal{Y}_{i_1, \cdots, i_N, i'_1, \cdots, i'_N} \quad (3)$$

式中,  $[\mathcal{X} \otimes \mathcal{Y}; (1:N)(1:N)] \in \mathbf{R}^{I'_1 \times \cdots \times I'_N \times I'_1 \times \cdots \times I'_N}$ 。张量缩并的必要条件是两个张量维度相同。特别地, 当张量缩并中张量  $\mathcal{X}, \mathcal{Y} \in \mathbf{R}^{I_1 \times \cdots \times I_k \times \cdots \times I_N}$  维度的所有下标中不包含  $k$  时, 该缩并可表示为  $[\mathcal{X} \otimes \mathcal{Y}; (\bar{k})(\bar{k})]$ , 且有

$$[\mathcal{X} \otimes \mathcal{Y}; (\bar{k})(\bar{k})] = \mathcal{X}^{(k)} \mathcal{Y}^{(k)T} \quad (4)$$

## 2 方法

### 2.1 基于张量的拉普拉斯稀疏低秩图构建

医学高光谱图像可自然地视为一个三阶张量  $\mathcal{T} \in \mathbf{R}^{I_1 \times I_2 \times I_3}$ , 其中,  $I_1$  和  $I_2$  表示立方体的空间维尺度,  $I_3 = d$  表示光谱维度。从其中抽取的第  $k$  个张量块可表示为  $\mathcal{X}_k \in \mathbf{R}^{i_1 \times i_2 \times d}$ , 由第  $k$  个像素及其所在空间域中的  $i_1 \times i_2$  个邻接像素组成。假设医学高光谱图像的感兴趣区域包含  $M$  个像素 ( $M \leq I_1 \times I_2$ ), 则由  $M$  个标记块构成的训练集  $\{\mathcal{X}_k\}_{k=1}^M$  可表示为四阶张量  $\mathcal{X}^{(*)} \in \mathbf{R}^{i_1 \times i_2 \times d \times M}$ 。第  $c$  类的张量块集合可表示为  $\{\mathcal{X}_{k,c}\}_{k=1}^{M_c}$ , 也可以表示为四阶张量  $\mathcal{X}^{(c)} \in \mathbf{R}^{i_1 \times i_2 \times d \times M_c}$  的形式, 其中  $M_c$  表示第  $c$  类包含张量块的个数, 且满足  $\sum_{c=1}^C M_c = M (c \in \{1, 2, \cdots, C\})$ 。

为了充分利用数据的标签信息、固有几何结构、低秩和稀疏特性进行高光谱图像分析, 构建基于张



量的拉普拉斯稀疏低秩图模型

$$\min_{\mathbf{W}^{(c)}} \frac{1}{2} \|\mathcal{X}^{(c)} - \mathcal{X}^{(c)} \times_4 \mathbf{W}^{(c)}\|_F^2 + \lambda \|\mathbf{W}^{(c)}\|_* + \beta \|\mathbf{W}^{(c)}\|_1 + \frac{\gamma}{2} \text{tr}(\mathbf{W}^{(c)T} \mathbf{Z}^{(c)} \mathbf{W}^{(c)})$$

s. t.  $\text{diag}(\mathbf{W}^{(c)}) = 0$  (5)

式中,  $\lambda, \beta$  和  $\gamma$  是用于控制各项比重的平衡参数,  $\mathbf{W}^{(c)} \in \mathbf{R}^{M_c \times M_c}$  表示第  $c$  类张量块的权重矩阵,  $\mathbf{Z}^{(c)}$  表示仿射矩阵  $\mathbf{A}^{(c)}$  的拉普拉斯矩阵,  $\times_4$  运算是 4 模积(定义 2)。矩阵  $\mathbf{A}^{(c)}$  的第  $p$  行, 第  $q$  列对应元素的计算式为

$$\mathbf{A}_{pq}^{(c)} = \exp(-\|\mathcal{X}_{p,c} - \mathcal{X}_{q,c}\|_F^2 / \eta_p \eta_q) \quad (6)$$

式中,  $\eta_p = \|\mathcal{X}_{p,c} - \mathcal{X}_{p,c}^{(knn)}\|_F$  是第  $c$  类中第  $p$  个样本  $\mathcal{X}_{p,c}$  的近邻元素的尺度,  $\mathcal{X}_{p,c}^{(knn)}$  表示  $\mathcal{X}_{p,c}$  的第  $k$  个最近邻。全局权重矩阵  $\mathbf{W}$  可表示为

$$\mathbf{W} = \begin{bmatrix} \mathbf{W}^{(1)} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \mathbf{W}^{(C)} \end{bmatrix} \quad (7)$$

采用交替方向乘子法(alternating direction method of multipliers, ADMM) 解决优化问题(5)。为了使目标函数可分离, 引入两个辅助变量  $\mathbf{Q}^{(c)}$ ,  $\mathbf{J}^{(c)}$ 。优化问题(5)可转化为

$$\min_{\mathbf{W}^{(c)}} \frac{1}{2} \|\mathcal{X}^{(c)} - \mathcal{X}^{(c)} \times_4 \mathbf{W}^{(c)}\|_F^2 + \lambda \|\mathbf{Q}^{(c)}\|_* + \beta \|\mathbf{J}^{(c)}\|_1 + \frac{\gamma}{2} \text{tr}(\mathbf{W}^{(c)T} \mathbf{Z}^{(c)} \mathbf{W}^{(c)})$$

s. t.  $\mathbf{W}^{(c)} = \mathbf{Q}^{(c)}, \mathbf{W}^{(c)} = \mathbf{J}^{(c)} - \text{diag}(\mathbf{J}^{(c)})$  (8)

则增广拉格朗日函数为

$$L(\mathbf{Q}^{(c)}, \mathbf{J}^{(c)}, \mathbf{W}^{(c)}, \mathbf{D}_1, \mathbf{D}_2) = \frac{1}{2} \|\mathcal{X}^{(c)} - \mathcal{X}^{(c)} \times_4 \mathbf{W}^{(c)}\|_F^2 + \lambda \|\mathbf{Q}^{(c)}\|_* + \beta \|\mathbf{J}^{(c)}\|_1 + \frac{\gamma}{2} \text{tr}(\mathbf{W}^{(c)T} \mathbf{Z}^{(c)} \mathbf{W}^{(c)}) + \langle \mathbf{D}_1, \mathbf{W}^{(c)} - \mathbf{Q}^{(c)} \rangle + \langle \mathbf{D}_2, \mathbf{W}^{(c)} - \mathbf{J}^{(c)} + \text{diag}(\mathbf{J}^{(c)}) \rangle + \frac{\mu}{2} (\|\mathbf{W}^{(c)} - \mathbf{Q}^{(c)}\|_F^2 + \|\mathbf{W}^{(c)} - \mathbf{J}^{(c)} + \text{diag}(\mathbf{J}^{(c)})\|_F^2) \quad (9)$$

式中,  $\mu$  为参数,  $\mathbf{D}_1, \mathbf{D}_2$  为拉格朗日算子。

为了使函数  $L(\mathbf{Q}^{(c)}, \mathbf{J}^{(c)}, \mathbf{W}^{(c)}, \mathbf{D}_1, \mathbf{D}_2)$  最小化, 通过固定剩余变量来交替更新每个变量。更新规则以如下方法实现

$$\mathbf{Q}_{t+1}^{(c)} = \arg \min_{\mathbf{Q}^{(c)}} \lambda \|\mathbf{Q}^{(c)}\|_* + \langle \mathbf{D}_{1,t}, \mathbf{W}_t^{(c)} - \mathbf{Q}^{(c)} \rangle +$$

$$\frac{\mu_t}{2} \|\mathbf{W}_t^{(c)} - \mathbf{Q}^{(c)}\|_F^2 = \arg \min_{\mathbf{Q}^{(c)}} \frac{\lambda}{\mu_t} \|\mathbf{Q}^{(c)}\|_* + \frac{1}{2} \left\| \mathbf{Q}^{(c)} - \left( \mathbf{W}_t^{(c)} + \frac{\mathbf{D}_{1,t}}{\mu_t} \right) \right\|_F^2 = \Omega_{\frac{\lambda}{\mu_t}} \left( \mathbf{W}_t^{(c)} + \frac{\mathbf{D}_{1,t}}{\mu_t} \right) \quad (10)$$

$$\mathbf{J}_{t+1}^{(c)} = \arg \min_{\mathbf{J}^{(c)}} \beta \|\mathbf{J}^{(c)}\|_1 + \langle \mathbf{D}_{2,t}, \mathbf{W}_t^{(c)} - \mathbf{J}^{(c)} \rangle + \frac{\mu_t}{2} \|\mathbf{W}_t^{(c)} - \mathbf{J}^{(c)}\|_F^2 = \arg \min_{\mathbf{J}^{(c)}} \frac{\beta}{\mu_t} \|\mathbf{J}^{(c)}\|_1 + \frac{1}{2} \left\| \mathbf{J}^{(c)} - \left( \mathbf{W}_t^{(c)} + \frac{\mathbf{D}_{2,t}}{\mu_t} \right) \right\|_F^2 = \mathcal{S}_{\frac{\beta}{\mu_t}} \left( \mathbf{W}_t^{(c)} + \frac{\mathbf{D}_{2,t}}{\mu_t} \right),$$

$$\mathbf{J}_{t+1}^{(c)} = \mathbf{J}_{t+1}^{(c)} - \text{diag}(\mathbf{J}_{t+1}^{(c)}) \quad (11)$$

式中,  $\mu_t$  表示学习率,  $\Omega_{\tau}(\Delta) = \mathbf{Q} \mathcal{S}_{\tau}(\Sigma) \mathbf{V}^T$  表示奇异值阈值算子, 并且软阈值算子表示为  $\mathcal{S}_{\tau}(x) = \text{sgn}(x) \max(|x| - \tau, 0)$  (Cai 等, 2010)。 $\mathbf{W}_{t+1}^{(c)}$  可以在  $\mathbf{Q}_{t+1}^{(c)}$  和  $\mathbf{J}_{t+1}^{(c)}$  固定的情况下获得, 即

$$\mathbf{W}_{t+1}^{(c)} = \arg \min_{\mathbf{W}^{(c)}} \frac{1}{2} \|\mathcal{X}^{(c)} - \mathcal{X}^{(c)} \times_4 \mathbf{W}^{(c)}\|_F^2 + \frac{\gamma}{2} \text{tr}(\mathbf{W}^{(c)T} \mathbf{Z}^{(c)} \mathbf{W}^{(c)}) + \langle \mathbf{D}_{1,t}, \mathbf{W}^{(c)} - \mathbf{Q}_{t+1}^{(c)} \rangle + \langle \mathbf{D}_{2,t}, \mathbf{W}^{(c)} - \mathbf{J}_{t+1}^{(c)} \rangle + \frac{\mu_t}{2} (\|\mathbf{W}^{(c)} - \mathbf{Q}_{t+1}^{(c)}\|_F^2 + \|\mathbf{W}^{(c)} - \mathbf{J}_{t+1}^{(c)}\|_F^2) = (\mathbf{M}^{(c)} + 2\mu_t \mathbf{I} + \gamma \mathbf{Z}^{(c)})^{-1} \times (\mathbf{M}^{(c)} + \mu_t \mathbf{Q}_{t+1}^{(c)} + \mu_t \mathbf{J}_{t+1}^{(c)} - \mathbf{D}_{1,t} - \mathbf{D}_{2,t}) \quad (12)$$

式中,  $\mathbf{I} \in \mathbf{R}^{M_c \times M_c}$  是单位矩阵, 并且  $\mathbf{M}^{(c)} = [\mathcal{X}^{(c)} \otimes \mathcal{X}^{(c)}; (4)(4)]$ 。

在计算所有子相似度矩阵后, 构造全局权重矩阵  $\mathbf{W}$ 。利用集合  $\mathcal{X}$  和权重矩阵  $\mathbf{W}$  构造一种新型的基于张量的拉普拉斯稀疏低秩图  $\mathbf{G} = \{\mathcal{X}, \mathbf{W}\}$ 。

## 2.2 基于张量的图嵌入

基于张量的图嵌入(tensor-based graph embedding, T-GE) 的降维方法是找到变换矩阵  $\{\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_N\}$ , 利用变换矩阵将高维样本  $\mathcal{X}_i$  投影到低维子空间  $\tilde{\mathcal{X}}_i$  中, 其中  $\tilde{\mathcal{X}}_i = \mathcal{X}_i \times_1 \mathbf{U}_1 \times_2 \mathbf{U}_2 \cdots \times_N \mathbf{U}_N$ 。目的是在高维空间中保留图  $\mathbf{G} = \{\mathcal{X}, \mathbf{W}\}$  包含的结构信息。

因此, 将 T-GE 的优化问题构造为

$$\min_{\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_N} \sum_{i,j} \|\tilde{\mathcal{X}}_i - \tilde{\mathcal{X}}_j\|^2 \mathbf{W}_{ij}$$

s. t.  $\sum_{i,j} \|\mathcal{X}_i \times_1 \mathbf{U}_1 \times_2 \mathbf{U}_2 \cdots \times_N \mathbf{U}_N\|^2 \mathbf{B}_{ii} = 1$  (13)

式中,  $\mathbf{B}_{ii} = \sum_j \mathbf{W}_{ij}$ 。

上述优化问题采用迭代方案来解决。假设  $\{U_1, \dots, U_{k-1}, U_{k+1}, \dots, U_N\}$  是固定的, 令  $\mathcal{X}_{i,(k)} = \mathcal{X}_i \times_1 U_1 \cdots \times_{k-1} U_{k-1} \times_{k+1} U_{k+1} \cdots \times_N U_N$ , 优化问题(13)转化为

$$\begin{aligned} \min_{U_k} J(U_k) = & \sum_{i,j} \|\tilde{\mathcal{X}}_{i,(k)} \times_k U_k - \tilde{\mathcal{X}}_{j,(k)} \times_k U_k\|^2 W_{ij} = \\ & \sum_{i,j} \|U_k \tilde{\mathcal{X}}_i^k - U_k \tilde{\mathcal{X}}_j^k\|^2 W_{ij} = \\ & \sum_{i,j} \text{tr}(U_k ((\tilde{\mathcal{X}}_i^k - \tilde{\mathcal{X}}_j^k)(\tilde{\mathcal{X}}_i^k - \tilde{\mathcal{X}}_j^k)^T W_{ij}) U_k^T) = \\ & \text{tr}(U_k (\sum_{i,j} (\tilde{\mathcal{X}}_i^k - \tilde{\mathcal{X}}_j^k)(\tilde{\mathcal{X}}_i^k - \tilde{\mathcal{X}}_j^k)^T W_{ij}) U_k^T) \\ \text{s. t. } & \text{tr}(U_k (\sum_i \tilde{\mathcal{X}}_i^k (\tilde{\mathcal{X}}_i^k)^T B_{ii}) U_k^T) = 1 \quad (14) \end{aligned}$$

式中,  $\tilde{\mathcal{X}}_i^k$  是  $\tilde{\mathcal{X}}_{i,(k)}$  的  $k$  模展开。

通过广义特征值问题

$$\begin{aligned} (\sum_{i,j} (\tilde{\mathcal{X}}_i^k - \tilde{\mathcal{X}}_j^k)(\tilde{\mathcal{X}}_i^k - \tilde{\mathcal{X}}_j^k)^T W_{ij}) u = \\ \lambda (\sum_i \tilde{\mathcal{X}}_i^k (\tilde{\mathcal{X}}_i^k)^T B_{ii}) u \quad (15) \end{aligned}$$

获取的最小  $k$  个特征值对应的特征向量构成了最佳投影矩阵  $U_k$ 。算法 1 中给出了 T-LapSLRG 的详细描述, 算法中  $\mu_0$  为参数  $\mu$  的初始值,  $\mu_{\max}$  为参数  $\mu$  的最大值,  $\rho_0$  为权重常数,  $\varepsilon_1$  和  $\varepsilon_2$  是较小的阈值常数,  $t$  为迭代次数。

算法 1 基于张量的拉普拉斯稀疏低秩图嵌入

输入: 有标签训练数据  $\{\mathcal{X}_k\}_{k=1}^M$ , 参数  $\lambda, \beta$  和  $\gamma$ , 张量块的空间尺寸  $i_1 \times i_2$  和降低维度集合  $\{B_1, B_2, \dots, B_N\}$ 。

初始化:  $Q_0^{(c)} = J_0^{(c)} = W_0^{(c)} = \mathbf{0}$ ,  $D_{1,0} = D_{2,0} = \mathbf{0}$ ,  $\mu_0 = 0.1$ ,  $\mu_{\max} = 10^3$ ,  $\rho_0 = 1.1$ ,  $\varepsilon_1 = 10^{-4}$ ,  $\varepsilon_2 = 10^{-3}$ ,  $t = 0$ ,  $\maxIter = 100$ 。

从  $c = 1, 2, \dots, C$  开始循环, 根据式(10) — 式(12), 计算  $Q_{t+1}^{(c)}, J_{t+1}^{(c)}$  和  $W_{t+1}^{(c)}$ 。

更新拉格朗日乘子:

$$D_{1,t+1} = D_{1,t} + \mu_t (W_{t+1}^{(c)} - Q_{t+1}^{(c)}),$$

$$D_{2,t+1} = D_{2,t} + \mu_t (W_{t+1}^{(c)} - J_{t+1}^{(c)}).$$

更新  $\mu$ :  $\mu_{t+1} = \min(\rho\mu_t, \mu_{\max})$ 。式中,

$$\rho = \begin{cases} \mu_t \max \left( \frac{\|W_{t+1}^{(c)} - W_t^{(c)}\|_F, \|Q_{t+1}^{(c)} - Q_t^{(c)}\|_F, \|J_{t+1}^{(c)} - J_t^{(c)}\|_F}{\|\mathcal{X}^{(c)}\|_F} \right) & < \varepsilon_2 \\ \rho_0 & \\ 0 & \text{其他} \end{cases}$$

检查收敛条件

$$\|W_{t+1}^{(c)} - Q_{t+1}^{(c)}\|_\infty < \varepsilon_1, \|W_{t+1}^{(c)} - J_{t+1}^{(c)}\|_\infty < \varepsilon_1$$

$t \leftarrow t + 1$

当满足收敛条件或  $t > \maxIter$  结束循环。

根据式(7)构造矩阵  $W$ 。

根据式(15)计算投影矩阵  $U_k, k = 1, \dots, N$ 。

输出: 投影矩阵集  $\{U_1, U_2, \dots, U_N\}$ 。

### 3 实验结果

#### 3.1 膜性肾病高光谱数据

利用膜性肾病医学高光谱数据集来评估所提出技术的有效性。为了捕获肾活检组织切片的显微高光谱图像, 将推扫式高光谱成像系统 SOC-710 与生物显微镜 CX31RTSF 结合构造显微高光谱成像系统 (见图 1)。SOC-710 系统捕获具有空间尺寸  $696 \times 520$  的 128 个光谱带, 以 4.69 nm 的分辨率覆盖了 400 ~ 1 000 nm 的光谱范围。



图 1 显微高光谱成像系统

Fig. 1 The microscopic hyperspectral imaging system

该数据集包含从中日友好医院肾脏病科的 19 位不同患者的肾活检组织切片拍摄的 54 幅显微高光谱图像。肾脏病理切片用过碘酸六胺银 + 马松染色 (PASM + M) 染色, 以准确显示和定位肾小球疾病中的各种免疫复合物。获得的医学高光谱图像 (medical HSI, MHSI) 数据集由 10 名 HBV-MN 患者的 30 幅 HBV-MN 图像和 9 名 PMN 患者的 24 幅 PMN 图像组成。为了获得足够的信息, 从每位患者处收集了 3 幅图像。但是, 基于每个图像都包含完整的肾小球的图像获取原理, 其中 2 位 PMN 患者的

图像少于 3 幅。经验丰富的专科肾脏病专家标记了图像上免疫复合物的区域。图 2 展示了分别从 HBV-MN 患者和 PMN 患者获得的伪彩色图像和标记图像的示例,其中白色区域为感兴趣物质标注区域。验证数据的详细信息在表 1 中列出。加粗标记的患者是由临床医生诊断为具有典型临床症状的患者。因此,将 PMN 患者 (ID:15684) 和 HBV-MN 患者 (ID:17472) 用作后续实验的训练数据。




图 2 示例 HBV-MN 和 PMN 的伪彩色图像和相应标注图

Fig.2 The pseudo-color scenes and the corresponding ground truth maps of the HBV-MN and PMN  
( (a) pseudo-color scenes;  
(b) the corresponding ground truth maps)

3.2 参数寻优

T-LapSLRG 方法包含 5 个参数,包括窗口大小  $i_1 \times i_2$ ,平衡参数  $\lambda$ ,  $\beta$  和  $\gamma$  以及降低维度集  $\{B_1, B_2, \cdots, B_N\}$ 。 $\lambda$ ,  $\beta$  和  $\gamma$  分别控制低秩项、稀疏项和流形正则项,参数范围为  $\{10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 10^0, 10^1, 10^2\}$ 。为了评估 T-LapSLRG 的有效性,引入了经典支持向量机分类器 (support vector machine, SVM) (Moughal, 2013) 对提取的低维特征进行分类。分类性能通过总体准确性 (overall accuracy, OA) 进行评估。经初步实验验证,  $\lambda$  和  $\beta$  的影响是相当的,因此展示了  $\lambda = \beta$  时的实验结果。图 3 说明了 MN 数据集上具有不同  $\lambda$ ,  $\beta$  和  $\gamma$  值的 OA。结果表明,将  $\lambda$ ,  $\beta$  和  $\gamma$  设置为  $(10^{-1}, 10^{-1}, 10^1)$  可

表 1 HBV-MN 和 PMN 数据的详细信息

Table 1 Detailed information of the HBV-MN and PMN data

| MN 类型  | 患者编号         | 图像数量     | 标记像素数      |
|--------|--------------|----------|------------|
| PMN    | <b>15684</b> | <b>3</b> | <b>959</b> |
|        | 16295        | 3        | 838        |
|        | 16367        | 1        | 194        |
|        | 16389        | 3        | 776        |
|        | 16442        | 3        | 663        |
|        | 16466        | 3        | 1019       |
|        | 16480        | 3        | 1151       |
|        | 16485        | 3        | 653        |
|        | 17516        | 2        | 319        |
|        | 17002        | 3        | 395        |
|        | 17072        | 3        | 481        |
|        | 17136        | 3        | 453        |
| HBV-MN | 17198        | 3        | 465        |
|        | 17221        | 3        | 417        |
|        | 17276        | 3        | 803        |
|        | 17325        | 3        | 766        |
|        | <b>17472</b> | <b>3</b> | <b>704</b> |
|        | 17559        | 3        | 596        |
|        | 18055        | 3        | 418        |

注:加粗 MN 患者信息为后续实验的训练集。




图 3 T-LapSLRG 中通过不同参数在 MN 数据集上获得的总体准确性

Fig.3 Overall accuracy obtained on MN dataset by different parameters for the proposed T-LapSLRG

获得最佳性能。因此,在以下实验中,选择  $(10^{-1}, 10^{-1}, 10^1)$  作为权衡参数。



假设像素位于窗口的中心,使用固定的空间窗口来提取与每个像素相对应的张量样本,即  $i_1 = i_2 = w$ 。每个张量的标签视为其对应中心像素的标签。窗口的大小起着非常重要的作用,随着窗口大小的增加,张量样本中包含的像素将增加,这将提供更多的空间光谱信息。但是,过大的窗口可能会导致张量样本包含冗余信息。实际上,窗口的尺寸通常根据经验和实验确定。表2列出了以  $(3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9, 11 \times 11)$  作为 MN 数据集窗口获取的实验结果。通过获得的总体准确性(OA),平均准确性(average accuracy, AA)和 Kappa 系数来分析窗口大小的影响。表2显示了分类准确度随窗口大小增加的趋势,并且在  $9 \times 9$  时获得了最佳性能。这意味着不合适的窗口大小无法合理地描述免疫复合物的分布特征。因此,在以下实验中,选择  $9 \times 9$  作为 MN 数据集的窗口大小。

表 2 MN 数据集上 T-LapSLRG 的不同窗口大小时结果比较

Table 2 Comparison of different window sizes for T-LapSLRG on MN dataset

|       | 窗口大小  |       |       |              |         |
|-------|-------|-------|-------|--------------|---------|
|       | 3 × 3 | 5 × 5 | 7 × 7 | 9 × 9        | 11 × 11 |
| OA/%  | 89.21 | 92.68 | 94.79 | <b>97.14</b> | 96.55   |
| AA/%  | 88.95 | 92.42 | 94.62 | <b>97.05</b> | 96.57   |
| Kappa | 0.782 | 0.852 | 0.895 | <b>0.942</b> | 0.931   |

注:加粗字体表示提出算法最优窗口大小下的分类精度。

因实验数据为三阶张量,令降低维度为  $\{B_1, B_2, B_3\}$ 。与 Pan 等人(2017a)实验一致,空间维的降维设置为  $\{1, 1\}$ 。通过固定窗口大小,  $\lambda$ ,  $\beta$  和  $\gamma$  的值来调整光谱尺寸。图4显示了不同降维方法(即 NWFE (Kuo 和 Landgrebe, 2004), EFDC (Gao 等, 2012), LFDA (Li 等, 2012), BCGDA (Ly 等, 2014), CDME (Lyu 等, 2017), TSLGDA (Pan 等, 2017a))将 MN 数据集降维到不同维度后,采用 SVM 分类器对低维特征进行分类的结果。其中, Original 对应未降维数据使用 SVM 分类获取的分类准确性。图4表明大多数降维方法的 OA 随光谱维数的增加而增加,然后变得稳定。此外,与基于向量表示的降维方法(即 NWFE, EFDC, LFDA, BCGDA, CDME)相比,基于张量表示的降维方法(即 TSLG-

DA, T-LapSLRG)可以利用更多的空间结构信息并获得更好的结果。在大多数情况下,除了光谱维数为1的情况外, T-LapSLRG 优于其他降维方法。下列实验使用的空间维度为  $\{1, 1, 10\}$ 。




图4 通过具有不同维度的不同降维方法在 MN 数据集上获得的总体准确性

Fig. 4 Overall accuracy obtained on MN dataset by different DR methods with different dimensions

3.3 分类性能

为了验证所提出的 T-LapSLRG 的有效性,采用 SVM 分类器 (Moughal, 2013) 对获取的低维特征进行分类。将其分类性能与几种降维方法获得的低维特征通过 SVM 获取的分类性能进行比较,以证明 T-LapSLRG 的有效性。4 个质量指标(即各个类别的准确性、总体准确性(OA)、平均准确性(AA)和 Kappa 系数(Kappa))用于衡量分类性能。表3列出了通过所有降维方法获得的 10 维特征的 OA 和 AA,这表明 T-LapSLRG 在这两个类别上均提供了最佳结果。详细而言, T-LapSLRG 的性能优于其他降维方法, OA 高出 1.40% ~ 34.75%, AA 高出 1.46% ~ 36.89%, Kappa 高出 0.031 ~ 0.73。此外,结果证实基于张量表示的降维方法性能优于基于向量表示的降维方法。

表4—表6中列出了更详细的分类准确性评估。表4列出了所有降维方法获得的 HBV-MN 患者每幅图像的 OA。表5列出了通过不同的降维方法获得的来自 PMN 患者的每幅图像的 OA。从表4和表5可以看出, T-LapSLRG 获得的性能优于其他方法。对于图像 17002-3 和 17136-3, T-LapSLRG 的 OA 小于 85%,但并不影响这两名患者的鉴定。表6列出了通过不同方法获得的多幅图像的每个患

表3 使用 HBV-MN 和 PMN 数据进行  
10 维子空间分类的精度

Table 3 Classification accuracy with 10-dimensional  
subspace using the HBV-MN and PMN data

| 方法        | HBV-MN<br>/% | PMN<br>/%    | OA/%         | AA/%         | Kappa        |
|-----------|--------------|--------------|--------------|--------------|--------------|
| Original  | 67.44        | 90.58        | 80.43        | 79.97        | 0.773        |
| NWFE      | 31.77        | 88.54        | 62.39        | 60.16        | 0.212        |
| EFDC      | 92.42        | 95.97        | 94.60        | 94.16        | 0.885        |
| LFDA      | 91.80        | 96.92        | 93.94        | 94.36        | 0.890        |
| BCGDA     | 68.17        | 90.67        | 80.30        | 79.36        | 0.595        |
| CDME      | 91.28        | 96.15        | 93.21        | 93.64        | 0.875        |
| TSLGDA    | 95.41        | 85.87        | 95.60        | 95.59        | 0.911        |
| T-LapSLRG | <b>96.60</b> | <b>98.13</b> | <b>97.14</b> | <b>97.05</b> | <b>0.942</b> |

注:加粗字体表示不同质量指标下的最优分类精度。

者的 OA。每个患者的 OA 指的是患者所有图像中所有像素的分类精度。例如,患者 17002 包括 3 幅 HSI 图像,分类结果则基于这 3 幅测试图像中的所有像素获得。表 6 表明对于大多数患者而言,T-LapSLRG 的识别准确性优于其他降维方法。此外,通过 T-LapSLRG 获得的所有患者的分类准确性均达到 90% 以上。在临床诊断中,可以在像素水平精度达到 85% 或更高时确定疾病的类型。因此得出,对于 MN 实验数据集,T-LapSLRG 能够有效识别 HBV-MN 和 PMN。

在实际医学应用中,可用训练样本的数量通常是有限的,因此研究算法对训练样本量的敏感度至关重要。图 5 展示了通过不同降维方法(即 NWFE, EFDC, LFDA, BCGDA, CDME, TSLGDA, T-LapSLRG)

表4 HBV-MN 患者每幅 HSI 图像的总体准确性

Table 4 Overall accuracy of each HSI image from HBV-MN patients

| 图片编号    | Original | NWFE  | EFDC         | LFDA         | BCGDA        | CDME         | TSLGDA       | T-LapSLRG    |
|---------|----------|-------|--------------|--------------|--------------|--------------|--------------|--------------|
| 17002-1 | 30.09    | 13.43 | 97.22        | 98.15        | 27.32        | 97.22        | <b>100.0</b> | <b>100.0</b> |
| 17002-2 | 75.25    | 3.86  | <b>100.0</b> | <b>100.0</b> | 72.28        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17002-3 | 16.67    | 0.00  | 8.97         | 25.64        | 10.26        | 12.82        | 67.95        | <b>69.23</b> |
| 17072-1 | 67.91    | 66.98 | <b>100.0</b> | <b>100.0</b> | 66.98        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17072-2 | 54.24    | 22.88 | <b>100.0</b> | <b>100.0</b> | 55.93        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17072-3 | 70.27    | 29.73 | <b>100.0</b> | <b>100.0</b> | 65.54        | <b>100.0</b> | 99.32        | <b>100.0</b> |
| 17136-1 | 49.61    | 6.98  | 96.90        | 97.67        | 52.71        | 97.67        | <b>99.23</b> | 97.67        |
| 17136-2 | 98.68    | 48.34 | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17136-3 | 47.40    | 0.00  | 78.61        | 73.41        | 47.40        | 80.93        | 85.55        | 79.19        |
| 17198-1 | 86.16    | 76.73 | <b>100.0</b> | <b>84.91</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17198-2 | 87.10    | 55.65 | 97.58        | 96.77        | 79.84        | 97.58        | <b>100.0</b> | <b>100.0</b> |
| 17198-3 | 82.97    | 23.63 | <b>100.0</b> | <b>100.0</b> | 82.42        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17221-1 | 79.89    | 5.17  | <b>100.0</b> | <b>100.0</b> | 81.61        | <b>100.0</b> | 99.43        | <b>100.0</b> |
| 17221-2 | 97.58    | 62.42 | <b>100.0</b> | <b>100.0</b> | 90.30        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17221-3 | 76.92    | 33.33 | <b>100.0</b> | <b>100.0</b> | 74.36        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17276-1 | 90.03    | 47.04 | <b>100.0</b> | <b>100.0</b> | 90.65        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17276-2 | 80.50    | 12.00 | 99.00        | 99.00        | 77.50        | 98.50        | 99.50        | <b>100.0</b> |
| 17276-3 | 84.75    | 14.89 | 98.94        | 98.58        | 84.75        | 95.03        | 97.52        | <b>99.29</b> |
| 17325-1 | 69.95    | 2.96  | 82.27        | 82.76        | 63.55        | 81.77        | 87.19        | <b>92.61</b> |
| 17325-2 | 86.21    | 56.90 | 85.86        | 84.14        | 80.67        | 81.03        | 89.31        | 93.10        |
| 17325-3 | 60.81    | 16.48 | <b>88.28</b> | 83.15        | 62.64        | 84.62        | 80.59        | 85.71        |
| 17559-1 | 54.27    | 26.22 | 67.68        | 56.71        | 57.32        | 59.76        | <b>96.34</b> | 88.42        |
| 17559-2 | 43.12    | 27.06 | 79.82        | 76.61        | 38.99        | 77.98        | 83.30        | <b>89.91</b> |
| 17559-3 | 45.33    | 8.41  | 94.86        | 92.06        | 47.66        | 92.06        | <b>100.0</b> | 99.53        |
| 18055-1 | 68.63    | 48.04 | 84.14        | 83.33        | 62.75        | 84.31        | <b>94.12</b> | 89.22        |
| 18055-2 | 78.79    | 73.49 | 93.94        | 96.97        | 80.30        | 94.70        | <b>100.0</b> | 99.24        |
| 18055-3 | 70.11    | 66.30 | <b>100.0</b> | <b>100.0</b> | 63.59        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |

注:加粗字体表示不同算法下 HBV-MN 患者的每幅 HSI 图像对应的最优 OA。

表 5 PMN 患者每幅 HSI 图像的总准确性  
Table 5 Overall accuracy of each HSI image from PMN patients

| 图片编号    | /%           |              |              |              |              |              |              |              |
|---------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|         | Original     | NWFE         | EFDC         | LFDA         | BCGDA        | CDME         | TSLGDA       | T-LapSLRG    |
| 16295-1 | 89.58        | <b>93.16</b> | 80.46        | 83.71        | 92.18        | 72.96        | 72.96        | 90.88        |
| 16295-2 | 83.74        | 77.86        | 93.77        | 94.81        | 88.24        | 95.50        | 96.89        | <b>100.0</b> |
| 16295-3 | 64.88        | 69.01        | 86.78        | 87.60        | 66.53        | 89.67        | 76.45        | 88.84        |
| 16367   | 42.78        | 88.14        | 91.37        | 93.81        | 59.28        | 91.24        | 95.88        | <b>98.45</b> |
| 16389-1 | 87.37        | 98.99        | 99.50        | <b>100.0</b> | 88.38        | <b>100.0</b> | <b>100.0</b> | 97.48        |
| 16389-2 | 60.31        | <b>92.22</b> | 72.76        | 79.77        | 65.76        | 81.71        | 86.77        | 86.77        |
| 16389-3 | 70.09        | 92.21        | 98.44        | <b>100.0</b> | 75.39        | 99.38        | 98.75        | <b>100.0</b> |
| 16442-1 | 99.80        | 78.71        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16442-2 | 98.39        | 98.67        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16442-3 | 94.53        | 79.10        | 92.61        | 93.25        | 97.11        | 90.68        | 88.10        | <b>97.43</b> |
| 16466-1 | 96.05        | 87.84        | <b>100.0</b> | <b>100.0</b> | 99.39        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16466-2 | 78.74        | 93.97        | <b>100.0</b> | <b>100.0</b> | 75.58        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16466-3 | 96.05        | 66.96        | <b>100.0</b> | <b>100.0</b> | 97.66        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16480-1 | 78.74        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16480-2 | 97.37        | 99.26        | <b>100.0</b> | <b>100.0</b> | 97.97        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16480-3 | <b>100.0</b> | 70.32        | <b>100.0</b> | <b>100.0</b> | 99.75        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16485-1 | 99.82        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16485-2 | 97.01        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16485-3 | 98.50        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17516-1 | 99.21        | 98.43        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17516-2 | 98.96        | 97.92        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |

注:加粗字体表示不同算法下 PMN 患者的每幅 HSI 图像对应的最优 OA。

表 6 HBV-MN 和 PMN 数据的每个患者的总准确性  
Table 6 Overall accuracy of each patient using the HBV-MN and PMN data

| 图片编号  | /%       |              |              |              |              |              |              |              |
|-------|----------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|       | Original | NWFE         | EFDC         | LFDA         | BCGDA        | CDME         | TSLGDA       | T-LapSLRG    |
| 17002 | 38.99    | 8.35         | 80.51        | 84.30        | 35.44        | 81.27        | 93.37        | <b>93.92</b> |
| 17072 | 65.28    | 44.70        | <b>100.0</b> | <b>100.0</b> | 63.83        | <b>100.0</b> | 99.379       | <b>100.0</b> |
| 17136 | 65.12    | 18.10        | 90.95        | 66.45        | 66.45        | 92.05        | <b>94.47</b> | 91.39        |
| 17198 | 86.16    | 50.32        | 99.36        | 99.14        | 82.58        | 99.36        | <b>100.0</b> | <b>100.0</b> |
| 17221 | 86.33    | 33.09        | <b>100.0</b> | <b>100.0</b> | 83.69        | <b>100.0</b> | 99.76        | <b>100.0</b> |
| 17276 | 85.80    | 27.02        | 99.38        | 99.25        | 85.31        | 97.88        | 98.76        | <b>99.75</b> |
| 17325 | 72.85    | 28.20        | 85.77        | 83.42        | 69.71        | 82.51        | 85.64        | <b>90.34</b> |
| 17559 | 46.98    | 20.13        | 81.88        | 76.68        | 47.15        | 78.02        | 92.79        | <b>92.95</b> |
| 18055 | 72.49    | 64.12        | 94.26        | 94.98        | 68.66        | 94.50        | <b>98.57</b> | 97.13        |
| 16295 | 80.43    | 80.91        | 86.87        | 88.66        | 83.41        | 85.56        | 82.22        | <b>93.44</b> |
| 16367 | 42.78    | 88.14        | 91.24        | 93.81        | 59.28        | 91.24        | <b>95.10</b> | 94.97        |
| 16389 | 71.26    | 93.94        | 90.21        | 93.30        | 75.52        | 93.69        | <b>100.0</b> | 97.48        |
| 16442 | 90.58    | 82.92        | 96.53        | 96.83        | 98.64        | 95.63        | 97.13        | <b>98.79</b> |
| 16466 | 90.58    | 80.92        | <b>100.0</b> | <b>100.0</b> | 90.68        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16480 | 98.87    | 89.31        | <b>100.0</b> | <b>100.0</b> | 98.94        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 16485 | 99.54    | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |
| 17516 | 99.06    | 98.12        | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> | <b>100.0</b> |

注:加粗字体表示不同算法下 MN 患者对应的最优 OA。



获取的低维特征通过 SVM 分类器获得的 OA, 训练样本的百分比从 5% 至 50% 不等。实验结果表明, T-LapSLRG 始终比其他降维方法更有助于提升分类精度, 尤其是在训练样本规模非常小(例如 5%)的情况下。综上, 所有实验结果都证明了 T-LapSLRG 在实际 MN 临床鉴定中具有不可忽视的应用潜力。




图5 使用 HBV-MN 和 PMN 数据以不同百分比的训练样本通过不同的降维方法获得的总体准确性

Fig. 5 Overall accuracy obtained by different DR methods with different percentages of training samples using the HBV-MN and PMN data

## 4 结 论

本文提出了一种基于张量的拉普拉斯稀疏低秩图(T-LapSLRG)嵌入方法,并结合 SVM 分类器对医学高光谱图像进行判别分析。医学高光谱图像立方体被视为三阶张量,而基于张量的图则是通过从立方体中提取局部块(子张量)构建的。通过在目标函数上施加稀疏、低秩约束,T-LapSLRG 可以同时挖掘局部和全局结构。通过引入流形正则项,T-LapSLRG 可以调整图结构并进一步增强所获得的低维特征的判别能力。膜性肾病显微高光谱图像的实验结果表明,除了低维空间维度为 1 时,T-LapSLRG 得到的分类精度都优于其他对比降维方法。当低维空间维度为 10 时,T-LapSLRG 降维后获取的特征用 SVM 分类器对于 PMN 的分类精度为 98.13%,HBV-MN 分类精度为 96.60%,OA 为 97.14%,AA 为 97.05%,Kappa 为 0.942。当训练样本比例从 5% 至 50% 变化时,本文算法得到的分类性能始终优于其他降维方法。即使对于较小的训练样本数

量,T-LapSLRG 方法也是有效的。实验结果证明,本文工作为膜性肾病诊断提供了一种新技术,具有临床应用潜力。然而,T-LapSLRG 求解过程中使用的交替迭代算法时间复杂度较高,未来工作将集中于研究针对张量运算的加速算法。此外,本文算法在样本获取过程中依赖医生标注,这个过程会耗费大量人力成本。未来研究工作也将涉及部分医学样本辅助标记。

## 参考文献 (References)

- Akbari H, Kosugi Y, Kojima K and Tanaka N. 2010. Detection and analysis of the intestinal ischemia using visible and invisible hyperspectral imaging. *IEEE Transactions on Biomedical Engineering*, 57(8): 2011-2017 [DOI: 10.1109/TBME.2010.2049110]
- An J L, Zhang X R and Jiao L C. 2016. Dimensionality reduction based on group-based tensor model for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 13(10): 1497-1501 [DOI: 10.1109/LGRS.2016.2593789]
- Bourennane S, Fossati C and Cailly A. 2010. Improvement of classification for hyperspectral images based on tensor modeling. *IEEE Geoscience and Remote Sensing Letters*, 7(4): 801-805 [DOI: 10.1109/LGRS.2010.2048696]
- Cai D, He X F, Han J W and Huang T S. 2011. Graph regularized non-negative matrix factorization for data representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(8): 1548-1560 [DOI: 10.1109/TPAMI.2010.231]
- Cai J, Candès E J and Shen Z. A singular value thresholding algorithm for matrix completion. 2010. *SIAM Journal on Optimization*, 24: 1956-1982 [DOI:10.1137/080738970]
- Carrión-Camacho M R, Marín-León I, Molina-Doñoro J M and González-López J R. 2019. Safety of permanent pacemaker implantation: a prospective study. *Journal of Clinical Medicine*, 8(1): #35 [DOI: 10.3390/jcm8010035]
- Chen C F, Wei C P and Wang Y C F. 2012. Low-rank matrix recovery with structural incoherence for robust face recognition//*Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition*. Providence, USA: IEEE: 2618-2625 [DOI: 10.1109/CVPR.2012.6247981]
- Cheng B, Yang J C, Yan S C, Fu Y and Huang T S. 2010. Learning with  $\ell^1$ -graph for image analysis. *IEEE Transactions on Image Processing*, 19(4): 858-866 [DOI: 10.1109/TIP.2009.2038764]
- Dalla Mura M, Villa A, Benediktsson J A, Chanussot J and Bruzzone L. 2011. Classification of hyperspectral images by using extended morphological attribute profiles and independent component analysis. *IEEE Geoscience and Remote Sensing Letters*, 8(3): 542-546 [DOI: 10.1109/LGRS.2010.2091253]

- Deng Y J, Li H C, Pan L and Emery W J. 2017. Tensor locality preserving projection for hyperspectral image classification//2017 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Fort Worth, USA: IEEE: 771-774 [DOI: 10.1109/IGARSS.2017.8127066]
- Deng Y J, Li H C, Pan L, Shao L Y, Du Q and Emery W J. 2018. Modified tensor locality preserving projection for dimensionality reduction of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 15(2): 277-281 [DOI: 10.1109/LGRS.2017.2786223]
- Dong H R, Wang Y Y, Cheng X H, Wang G Q, Sun L J, Cheng H and Chen Y P. 2016. Retrospective study of phospholipase A2 receptor and IgG subclasses in glomerular deposits in Chinese patients with membranous nephropathy. *PLoS One*, 11(5): #e0156263 [DOI: 10.1371/journal.pone.0156263]
- Fang L Y, Wang C, Li S T and Benediktsson J A. 2017. Hyperspectral image classification via multiple-feature-based adaptive sparse representation. *IEEE Transactions on Instrumentation and Measurement*, 66(7): 1646-1657 [DOI: 10.1109/TIM.2017.2664480]
- Gao Q X, Liu J J, Zhang H J, Hou J and Yang X J. 2012. Enhanced fisher discriminant criterion for image recognition. *Pattern Recognition*, 45(10): 3717-3724 [DOI: 10.1016/j.patcog.2012.03.024]
- He X F, Cai D, Yan S C and Zhang H J. 2005. Neighborhood preserving embedding//Proceedings of the 10th IEEE International Conference on Computer Vision (ICCV '05). Beijing, China: IEEE: 1208-1213 [DOI: 10.1109/ICCV.2005.167]
- He X F and Niyogi P. 2004. Locality preserving projections. *Advances in Neural Information Processing Systems*, 16: 153-160
- Jolliffe I T and Cadima J. 2016. Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065): #20150202 [DOI: 10.1098/rsta.2015.0202]
- Kuo B C and Landgrebe D A. 2004. Nonparametric weighted feature extraction for classification. *IEEE Transactions on Geoscience and Remote Sensing*, 42(5): 1096-1105 [DOI: 10.1109/TGRS.2004.825578]
- Li W, Liu J B and Du Q. 2016. Sparse and low-rank graph for discriminant analysis of hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 54(7): 4094-4105 [DOI: 10.1109/TGRS.2016.2536685]
- Li W, Prasad S, Fowler J E and Bruce L M. 2011. Locality-preserving discriminant analysis in kernel-induced feature spaces for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 8(5): 894-898 [DOI: 10.1109/LGRS.2011.2128854]
- Li W, Prasad S, Fowler J E and Bruce L M. 2012. Locality-preserving dimensionality reduction and classification for hyperspectral image analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 50(4): 1185-1198 [DOI: 10.1109/TGRS.2011.2165957]
- Liu J M, Chen Y J, Zhang J S and Xu Z B. 2014. Enhancing low-rank subspace clustering by manifold regularization. *IEEE Transactions on Image Processing*, 23(9): 4022-4030 [DOI: 10.1109/TIP.2014.2343458]
- Lu C and Mandal M. 2014. Toward automatic mitotic cell detection and segmentation in multispectral histopathological images. *IEEE Journal of Biomedical and Health Informatics*, 18(2): 594-605 [DOI: 10.1109/JBHI.2013.2277837]
- Lu G L and Fei B W. 2014. Medical hyperspectral imaging: a review. *Journal of Biomedical Optics*, 19(1): #010901 [DOI: 10.1117/1.JBO.19.1.010901]
- Lyu M, Hou Q L, Deng N Y and Jing L. 2017. Collaborative discriminative manifold embedding for hyperspectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 14(4): 569-573 [DOI: 10.1109/LGRS.2017.2660518]
- Ly N H, Du Q and Fowler J E. 2014. Collaborative graph-based discriminant analysis for hyperspectral imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6): 2688-2696 [DOI: 10.1109/JSTARS.2014.2315786]
- Moughal T A. 2013. Hyperspectral image classification using support vector machine. *Journal of Physics: Conference Series*, 439: #012042 [DOI: 10.1088/1742-6596/439/1/012042]
- Pan L, Li H C, Deng Y J, Zhang F, Chen X D and Du Q. 2017a. Hyperspectral dimensionality reduction by tensor sparse and low-rank graph-based discriminant analysis. *Remote Sensing*, 9(5): #452 [DOI: 10.3390/rs9050452]
- Pan L, Li H C, Li W, Chen X D, Wu G N and Du Q. 2017b. Discriminant analysis of hyperspectral imagery using fast kernel sparse and low-rank graph. *IEEE Transactions on Geoscience and Remote Sensing*, 55(11): 6085-6098 [DOI: 10.1109/TGRS.2017.2720584]
- Ronco P and Debiec H. 2015. Pathophysiological advances in membranous nephropathy: time for a shift in patient's care. *The Lancet*, 385(9981): 1983-1992 [DOI: 10.1016/S0140-6736(15)60731-0]
- Schweitzer A, Horn J, Mikolajczyk R T, Krause G and Ott J J. 2015. Estimations of worldwide prevalence of chronic hepatitis B virus infection: a systematic review of data published between 1965 and 2013. *The Lancet*, 386(10003): 1546-1555 [DOI: 10.1016/S0140-6736(15)61412-X]
- Sumarsono A and Du Q. 2015. Low-rank subspace representation for estimating the number of signal subspaces in hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 53(11): 6286-6292 [DOI: 10.1109/TGRS.2015.2438079]
- Tarabalka Y, Benediktsson J A, Chanussot J and Tilton J C. 2010. Multiple spectral-spatial classification approach for hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 48(11): 4122-4132 [DOI: 10.1109/TGRS.2010.2062526]
- van den Brand J A J G, Hofstra J M and Wetzels J F M. 2011. Low-molecular-weight proteins as prognostic markers in idiopathic mem-

- braneous nephropathy. *Clinical Journal of the American Society of Nephrology*, 6(12): 2846-2853 [DOI: 10.2215/CJN.04020411]
- Villa A, Benediktsson J A, Chanussot J and Jutten C. 2011. Hyperspectral image classification with independent component discriminant analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 49(12): 4865-4876 [DOI: 10.1109/TGRS.2011.2153861]
- Wei X L, Li W, Zhang M M and Li Q L. 2019. Medical hyperspectral image classification based on end-to-end fusion deep neural network. *IEEE Transactions on Instrumentation and Measurement*, 68(11): 4481-4492 [DOI: 10.1109/TIM.2018.2887069]
- Wright J, Ma Y, Mairal J, Sapiro G, Huang T S and Yan S C. 2010. Sparse representation for computer vision and pattern recognition. *Proceedings of the IEEE*, 98(6): 1031-1044 [DOI: 10.1109/JPROC.2010.2044470]
- Wright J, Yang A Y, Ganesh A, Sastry S S and Ma Y. 2009. Robust face recognition via sparse representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(2): 210-227 [DOI: 10.1109/TPAMI.2008.79]
- Xu J S, He L and Zhang S L. 2018. Major research advances in chronic kidney disease of 2017. *Clinical Focus*, 33(1): 32-39 (徐金升, 何雷, 张胜雷. 2018. 2017年慢性肾脏病重要研究进展. 临床荟萃, 33(1): 32-39) [DOI: 10.3969/j.issn.1004-583X.2018.01.005]
- Yan S C, Xu D, Zhang B Y, Zhang H J, Yang Q and Lin S. 2007. Graph embedding and extensions: a general framework for dimensionality reduction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(1): 40-51 [DOI: 10.1109/TPAMI.2007.250598]
- Yang J and Yang J Y. 2003. Why can LDA be performed in PCA transformed space? *Pattern Recognition*, 36(2): 563-566 [DOI: 10.1016/S0031-3203(02)00048-1]
- Zhang L, Yang M and Feng X C. 2011a. Sparse representation or collaborative representation: which helps face recognition? // *Proceedings of 2011 IEEE International Conference on Computer Vision (ICCV)*. Barcelona, Spain; IEEE: 471-478 [DOI: 10.1109/iccv.2011.6126277]
- Zhang L P, Huang X, Huang B and Li P X. 2006. A pixel shape index coupled with spectral information for classification of high spatial resolution remotely sensed imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 44(10): 2950-2961 [DOI: 10.1109/TGRS.2006.876704]
- Zhang L P, Zhang L F, Tao D C and Huang X. 2013. Tensor discriminative locality alignment for hyperspectral image spectral-spatial feature extraction. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1): 242-256 [DOI: 10.1109/TGRS.2012.2197860]
- Zhang Q, Plemmons R, Kittle D, Brady D and Prasad S. 2011b. Joint segmentation and reconstruction of hyperspectral data with compressed measurements. *Applied Optics*, 50(22): 4417-4435 [DOI: 10.1364/AO.50.004417]
- Zhang Y Q, Cao G and Li X S. 2021. Multiview-based random rotation ensemble pruning for hyperspectral image classification. *IEEE Transactions on Instrumentation and Measurement*, 70: #5500314 [DOI: 10.1109/TIM.2020.3011777]

## 作者简介



吕蒙, 1989年生, 女, 博士后, 主要研究方向为医学高光谱图像特征提取及分类识别技术。

E-mail: lvmeng0122@163.com



李伟, 通信作者, 男, 教授, 博士生导师, 主要研究方向为高光谱图像处理、目标检测与识别。

E-mail: liwei089@ieee.org

陈天虹, 女, 硕士研究生, 主要研究方向为医学高光谱图像处理。E-mail: TianhongChen2020@163.com

杨悦, 女, 主治医师, 主要研究方向为各类常见肾脏疾病的诊疗。E-mail: yangyue\_nk@126.com

涂天琪, 女, 硕士研究生, 主要研究方向为乙肝相关肾小球肾炎的鉴别和诊疗。E-mail: tianqitu@126.com

李文歌, 男, 主任医师, 主要研究方向为各类原发及继发肾小球疾病的诊疗。E-mail: wenge\_lee2002@126.com