

引用格式: XU Dong-dong, CHENG De-qiang, CHEN Liang-liang, *et al.* Hyperspectral Image Classification Based on Hierarchical Guidance Filtering and Nearest Regularized Subspace[J]. *Acta Photonica Sinica*, 2020, **49**(4):0410004

徐冬冬,程德强,陈亮亮,等.基于分层引导滤波与最近邻正则化子空间的高光谱图像分类[J].光子学报,2020,**49**(4):0410004

# 基于分层引导滤波与最近邻正则化子空间的高光谱图像分类

徐冬冬,程德强,陈亮亮,寇旗旗,唐守锋

(中国矿业大学 信息与控制工程学院,江苏 徐州 221116)

**摘 要:**针对高光谱图像中同质异谱现象造成的分类精度较低以及边缘像元在联合空间光谱信息分类时特征易混淆的问题,提出了基于分层引导滤波与最近邻正则化子空间的分类方法.利用主成分分析获得高光谱图像的第一主成分.以第一主成分为引导图像对高光谱图像执行分层引导滤波操作,引导滤波的边缘保护特性,有效阻隔了边缘处类间光谱信息的混淆,并减小了局部区域类内光谱的差异,最后将预处理后的高光谱图像送至最近邻正则化子空间分类器进行分类识别.在 Indian Pines, Salinas 以及 GRSS\_DFC\_2013 高光谱数据集上与现有的方法进行对比实验.结果表明,本文提出的方法在三个数据集上分别取得了 98.63%, 99.13% 与 99.42% 的总体分类准确率,有着更优的分类精度与可视化效果.

**关键词:**高光谱图像;引导滤波;边缘保护;协同表示;分类

中图分类号: TP751

文献标识码: A

doi:10.3788/gzxb20204904.0410004

## Hyperspectral Image Classification Based on Hierarchical Guidance Filtering and Nearest Regularized Subspace

XU Dong-dong, CHENG De-qiang, CHEN Liang-liang, KOU Qi-qi, TANG Shou-feng

(School of Information and Control Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

**Abstract:** Aiming at the problems of low classification accuracy caused by the phenomenon that homogeneous pixels have different spectrum in the hyperspectral image and the characteristics of edge pixels being easily confused when combining spatial and spectral information, a method based on hierarchical guidance filtering and nearest regularized subspace is proposed in this paper. Firstly, the principal component of the hyperspectral image is obtained by principal component analysis, and then the hierarchical guidance filtering is performed with the guidance image, the first principal component. The edge-preserving characteristic of the guided filtering, effectively prevents the mixing of spectral information in edge area, and reduces the difference of the homogeneous spectrum at local regions. Finally, the nearest regularized subspace classifier is applied to classify the preprocessed hyperspectral image. Compared with the existing methods on Indian Pines, Salinas and GRSS\_DFC\_2013 hyperspectral datasets, the results show that the method proposed in this paper has achieved overall classification accuracy of 98.63%, 99.13% and 99.42% on the three datasets respectively, with better classification accuracy and visualization.

**Key words:** Hyperspectral image; Guided filtering; Edge preserving; Collaborative representation;

基金项目:国家自然科学基金面上项目(No.51774281),国家重点研发计划(No.2018YFC0808302)

第一作者:徐冬冬(1997-),男,硕士研究生,主要研究方向为图像处理与模式识别. Email:xs\_cumt@163.com

通讯作者:程德强(1979-),男,教授,博导,主要研究方向为图像智能检测与模式识别. Email:chengdq@cumt.edu.cn

收稿日期:2019-12-03;录用日期:2020-02-14

Classification

OCIS Codes: 100.5010; 100.3008; 100.4145; 110.4234

## 0 引言

由成像光谱仪得到的高光谱图像,有着数百条连续的光谱波段,包含了丰富的图像信息与光谱信息,已成功应用于环境保护,异常检测,矿物勘探与分析<sup>[1-5]</sup>等领域.高光谱图像的分类是其应用过程中的重要问题,一直是研究的热点.

因同质异谱现象的存在,仅利用光谱信息进行分类已难以满足高精度的分类要求.近年来,联合空间光谱信息的分类方法取得了不错的效果.CAMPS-VALLS G 等<sup>[6]</sup>串联空间信息与光谱信息的非线性变换,在核空间中利用支持向量机进行分类.TARABALKA Y 等<sup>[7]</sup>利用空间上下文信息来细化支持向量机的分类结果.CHEN Yi 等<sup>[8]</sup>将稀疏表示引入高光谱图像分类中.ZHANG Hong-yan 等<sup>[9]</sup>考虑空间邻域像素的结构相似性,提出了非局部加权联合稀疏模型.稀疏表示的原理是基于  $l_1$  正则化的最小二乘方法,求解稀疏系数是一个耗时的过程,而协同表示是基于  $l_2$  正则化的最小二乘方法,协同系数有解析解.由此,大量的基于协同表示的分类方法被提出.LI Wei 等<sup>[10]</sup>将 Tikhonov 矩阵<sup>[11]</sup>引入协同表示的正则化项,提出了最近邻正则化子空间分类器(Nearest Regularized Subspace, NRS).为利用像元的邻域空间信息,LI Wei 等<sup>[12]</sup>联合固定大小的窗口内的邻域像素,提出了四种联合协同表示模型(Joint Collaborative Representation, JCR).相比稀疏表示的分类方法,NRS 有着更快的计算速度.相比协同表示的方法,NRS 中 Tikhonov 矩阵的引入,使样本在表示时确定了更为均衡有效的协同系数.

最近,边缘保护滤波器在图像处理方面得到大量的应用<sup>[13-15]</sup>,其基本原理是抑制图像噪声的同时保护了图像的大尺度结构.KANG Xu-dong 等<sup>[16]</sup>将边缘保护滤波器引入高光谱图像分类中,对分类概率图进行边缘保护滤波以确定最终的样本标签.PAN Bin 等<sup>[17]</sup>提出了基于分层引导滤波(Hierarchical Guidance Filtering, HGF)的集成学习分类方法,对高光谱图像迭代地执行引导滤波<sup>[18]</sup>(Guided Filtering, GF)以获得不同尺度的光谱空间特征,在决策级采用权重投票的策略进行分类.

NRS 作为一种传统的逐像素分类器,空间信息的利用有所限制.理想情况下,同质地物应有着一致的光谱信息,实际中数据常伴有同质异谱现象,造成测试样本在协同表示时产生较大的冗余误差,从而产生分类的偏差.

为充分利用空间信息来减小类内光谱的差异性并保持类间光谱的可区分性,从而克服同质异谱现象带来的分类精度较低的问题,本文提出了基于分层引导滤波与最近邻正则化子空间的分类方法,简称 HGF-NRS.HGF 的边缘保护特性,使其在平滑局部光谱差异的同时有效的阻止边缘处异类光谱信息的混淆,进而在原光谱特征的基础上引入了有效的空间信息,接着利用 NRS 对滤波后的数据进行高效的分类识别.与 HiFi-We 方法不同的是,本文仅选用最终的分层引导滤波输出作为待分类数据,数据的体量与维度与原高光谱数据保持一致,避免了多特征集成学习带来的特征冗余与时间上的开销.HGF-NRS 结合了 HGF 的边缘保护特性与 NRS 的协同特性,选用了三个公开的高光谱数据集进行实验,与现有的联合空间光谱信息的方法相比较,以验证提出的方法的有效性.

## 1 相关方法

### 1.1 分层引导滤波

HGF 的原理为固定引导图像  $g$ , 循环地对输入图像执行引导滤波(Guided Filtering, GF)操作,以前一次的滤波输出  $q$  作为新一轮滤波的输入图像  $p$ .GF 是由局部线性模型演化而来,滤波输出会考虑引导图像的内容信息,具有平滑作用的同时能够将引导图像的边缘结构传递至输出图像.引导滤波的输出图像  $q$  为引导图像  $g$  的线性变换,输入图像的像素  $p_i$  的引导滤波输出  $q_i$  为

$$q_i = a_k g_i + b_k, \forall i \in \omega_k \quad (1)$$

式中,  $\omega_k$  是以像素  $k$  为中心的边长为  $2r+1$  的正方形窗口.  $a_k, b_k$  为窗口内待估计的线性系数.对式(1)求导有

$$\nabla q_i = a_k \nabla g_i, \forall i \in \omega_k \quad (2)$$

图像的边缘处会有较大的梯度值,根据式(2), $\mathbf{g}$ 的边缘在 $\mathbf{q}$ 中得以保存.接着通过最小化损失函数式(3)来确定线性系数 $a_k, b_k$ .

$$E(a_k, b_k) = \sum_{i \in \omega_k} [(a_k g_i + b_k - p_i)^2 + \epsilon a_k^2] \quad (3)$$

正则化系数 $\epsilon$ 惩罚 $a_k$ ,式(3)保证了输出与输入图像的相似性,并抑制了噪声与细小的纹理.线性回归模型(3)的解为

$$a_k = \frac{1}{|\tau\omega|} \frac{\sum_{i \in \omega_k} g_i p_i - \mu_k \bar{p}_k}{\sigma_k^2 + \epsilon} \quad (4)$$

$$b_k = \bar{p}_k - a_k \mu_k \quad (5)$$

式中, $|\tau\omega|$ 为窗口 $\omega_k$ 内的像素个数, $\mu_k$ 与 $\sigma_k^2$ 分别为引导图像 $\mathbf{g}$ 在窗口 $\omega_k$ 内的像素值的均值与方差. $\bar{p}_k$ 为 $\omega_k$ 内输入图像像素值的均值.因 $p_i$ 属于多个重叠的窗口,会产生多个 $a_k, b_k$ ,采用重叠窗口的平均策略来权衡所有可能的 $a_k, b_k$

$$\bar{a}_i = \frac{1}{|\tau\omega|} \sum_{k \in \omega_i} a_k \quad (6)$$

$$\bar{b}_i = \frac{1}{|\tau\omega|} \sum_{k \in \omega_i} b_k \quad (7)$$

得到线性系数 $a_k, b_k$ 后,即可计算引导滤波的输出图像 $q_i = \bar{a}_i g_i + \bar{b}_i$ .

## 1.2 最近邻正则化子空间分类器

NRS分类器,其本质是以Tikhonov正则化为惩罚项的协同表示.相比稀疏表示的相关方法,NRS有解析解,有着更高的运算速度,适用于高维数据的运算.

设数据集 $X = \{x_i\}_{i=1}^n$ 中有 $C$ 类标记样本,样本总数为 $n$ . $\mathbf{X}_l = [\mathbf{x}_{l,1}, \mathbf{x}_{l,2}, \dots, \mathbf{x}_{l,n_l}]$ 为第 $l$ 类训练样本,则训练样本集可表示为 $\{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_C\}$ .待分类象元 $\mathbf{y}$ 分别由各类训练样本协同表示,其协同系数 $\boldsymbol{\alpha}_l = [\alpha_{l,1}, \alpha_{l,2}, \dots, \alpha_{l,n_l}]^T$ 使用Tikhonov正则化的最小二乘方法进行求解

$$\boldsymbol{\alpha}_l = \arg \min_{\boldsymbol{\alpha}} \|\mathbf{y} - \mathbf{X}_l \boldsymbol{\alpha}\|_2^2 + \lambda \|\boldsymbol{\Gamma}_{l,y} \boldsymbol{\alpha}\|_2^2 \quad (8)$$

正则化参数 $\lambda > 0$ ,在最小化过程中平衡冗余误差项与正则化项,降低过拟合风险. $\boldsymbol{\Gamma}_{l,y}$ 为 $\mathbf{y}$ 对应于第 $l$ 类训练样本的偏重Tikhonov对角矩阵,其表达式为

$$\boldsymbol{\Gamma}_{l,y} = \begin{bmatrix} \|\mathbf{y} - \mathbf{x}_{l,1}\|_2 & & 0 \\ & \ddots & \\ 0 & & \|\mathbf{y} - \mathbf{x}_{l,n_l}\|_2 \end{bmatrix} \quad (9)$$

式(8)的解析解为

$$\boldsymbol{\alpha}_l = (\mathbf{X}_l^T \mathbf{X}_l + \lambda^2 \boldsymbol{\Gamma}_{l,y}^T \boldsymbol{\Gamma}_{l,y})^{-1} \mathbf{X}_l^T \mathbf{y} \quad (10)$$

在确定了协同表示系数后,可得到待分类象元 $\mathbf{y}$ 的各组别的重建值 $\tilde{\mathbf{y}}_l$ ,以残差最小原则确定 $\mathbf{y}$ 的类别归属

$$\text{class}(\mathbf{y}) = \arg \min_{l=1,2,\dots,C} \|\mathbf{y} - \tilde{\mathbf{y}}_l\|_2^2 \quad (11)$$

## 2 基于分层引导滤波与最近邻正则化子空间的高光谱图像分类

为减小同质地物的光谱差异,本文从数据源出发,采取HGF对HSI数据的进行预处理,与其他边缘保护滤波器相比,引导滤波在图像边缘处有着更好的表现<sup>[18]</sup>,其会根据引导图像局部区域像素的相似性来平滑输入图像.式(4)中,当引导图像 $g$ 与正则化参数 $\epsilon$ 确定后,窗口 $\omega_k$ 内的 $\mu_k$ 与 $\sigma_k^2$ 不变,随着HGF迭代过程的深入,滤波的平滑作用使得平坦区域内的像素 $p_i$ 逐渐逼近邻域均值 $\bar{p}_k$ ,如此, $a_k$ 与 $b_k$ 也趋于稳定.又由式(2)可知,引导图像的边缘结构逐渐在输出图像上固化,通过获取能够可靠表达地物边缘结构的引导图像,可达到削弱类内像元光谱差异与保护类间光谱可区分性的目的,从而提高分类精度.

图像的第一主成分很好地表达了图像地边缘结构信息,故选用图像的第一主成分为引导图像.以Salinas

数据集中两类位置相邻的地物 Stubble 与 Celery 的部分光谱特征为例,原始光谱特征与引导滤波 10 次、20 次后的光谱特征如图 1 所示.图 1 中虚线轮廓内为光谱特征(108~204 波段)的局部细节图,可以看出,滤波后类内的光谱特征更为聚拢,随着迭代过程的深入,类内光谱的差异逐渐缩小,HGF 有效区分了原混合的信号波段.HSI 经 HGF 预处理后,以引导图像的强梯度响应为边界的局部区域内,输入图像像元间的相似性增加,进而数据的可分性增强,需要的训练样本也将减小.




图 1 滤波前后光谱特征对比

Fig.1 Comparison of spectral feature before and after filtering

将经过 HGF 预处理的 HSI 送至 NRS 进行分类,NRS 分类器是通过比较各组别训练样本对测试样本的重建误差来确定测试样本的归属.本文提出的 HGF-NRS 可分为 3 个步骤,流程图如图 2 所示,首先通过 PCA 变换获得高光谱数据的第一主成分,以此作为引导滤波的引导图像;然后,迭代地执行  $T$  次引导滤波操作;最后将第  $T$  次滤波后的数据送至 NRS 分类器进行分类识别.

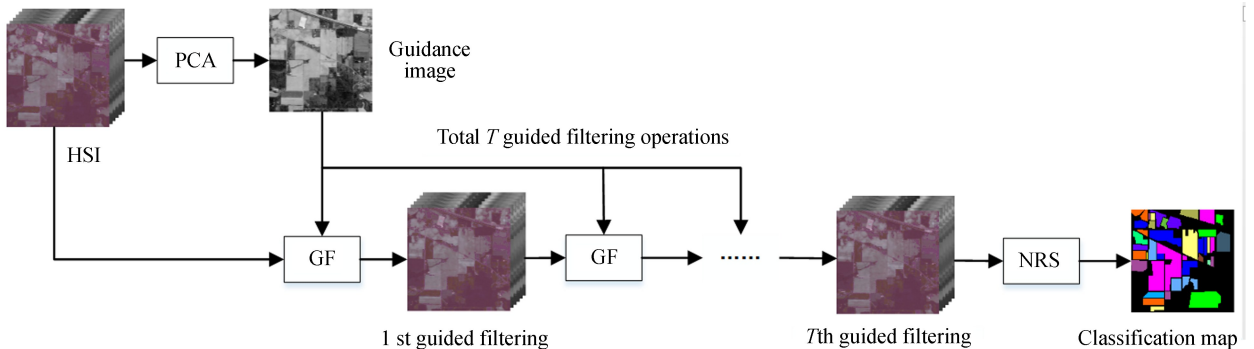


图 2 HGF-NRS 算法流程图

Fig.2 The flowchart of HGF-NRS

算法的具体执行为

1)输入:

HSI 数据  $I$ , 引导滤波的正则化参数  $\epsilon$ , 滤波迭代次数  $T$  与窗口半径  $r$ , 协同表示的正则化参数  $\lambda$ .

2)数据预处理:

(a)确定滤波的引导图像  $g$ :使用主成分分析获得  $I$  的第一主成分  $P_c$ , 将其固定为引导图像  $g = P_c$ .

(b)分层引导滤波 HGF: 对输入图像  $I$  迭代地执行  $T$  次引导滤波操作,  $q^T = GF(p^T, g)$ ,  $p^T = q^{T-1}$ ,  $p^1 = I$ .  $GF(\cdot)$  为引导滤波函数, 由式(1)~(7)计算得到.保留第  $T$  次的滤波输出, 送至分类器.

3)分类:

(a) 随机选择训练样本集  $X_{train}$  与测试样本集  $X_{test}$ .

(b) 对于每一个测试样本  $y \in X_{test}$ , 利用式(8)~(11)计算各组训练样本  $X_i$  对测试样本  $y$  的重建误差, 以误差最小原则确定测试样本的标签.

4)输出:



HSI 数据的地物分类结果.

以 Salinas 数据集的组 1 中某一测试样本为例,NRS,Gabor-NRS<sup>[19]</sup>,HGF-NRS 分类时各组别的归一化的重建误差如图 3 所示.三种方法都取得了正确的分类,与 NRS 和与 Gabor-NRS 相比,HGF-NRS 有着更小的重建误差,注意到其他各组的重建误差仍保持与 NRS 一致的趋势,说明 HGF 区域性的增强了类内光谱的相似性并有效阻止了类间光谱信息的混淆.

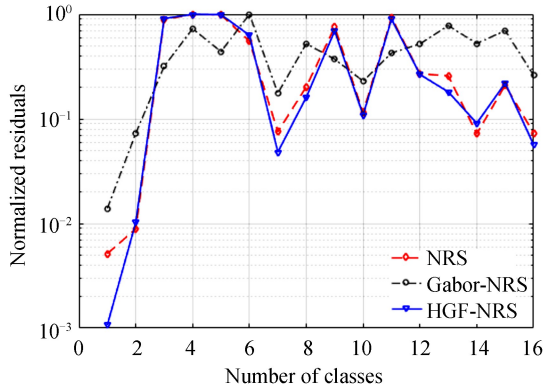


图 3 测试样本的重建误差

Fig.3 Reconstruction residuals of a test sample

### 3 实验与分析

本文将在三个公开的高光谱遥感数据集上进行对比试验,来验证 HGF-NRS 的有效性.相关的对比的方法有 NRS<sup>[10]</sup>,JCR2<sup>[12]</sup>,Gabor-NRS<sup>[19]</sup>,HiFi-We<sup>[17]</sup>以及 EPF-G-g<sup>[16]</sup>.JCR2 是通过平均邻域像元来联合空间光谱信息的协同表示分类模型,Gabor-NRS 是对高光谱数据执行 Gabor 滤波来引入空间信息.HiFi-We 是联合了多尺度分层引导滤波输出的集成学习分类方法.EPF-G-g 通过对 SVM 的分类概率图进行引导滤波以确定像元的类别归属.全局准确率 OA,平均准确率 AA 和 Kappa 系数作为算法性能的评价指标.

#### 3.1 实验数据

实验数据集 Indian Pines,由 AVIRIS 传感器采集于印第安纳州的农业区,其高光谱图像尺寸为  $145 \times 145$  像素,220 个光谱波段,波长范围为  $0.4 \sim 2.5 \mu\text{m}$ .包含 16 种不同的地物类别,共 10 249 个标记像素,空间分辨率为 20 m.移除 20 个低信噪比的波段后,利用剩余 200 个波段进行实验.

实验数据集 Salinas,由 AVIRIS 传感器摄取于加利福尼亚萨利纳斯,其高光谱图像有 224 个光谱波段,16 种不同类别的地物,图像尺寸为  $512 \times 217$  像素,空间分辨率为 3.7 m.移除 20 个低信噪比的波段后,余下的 204 个波段用于实验.

实验数据集 GRSS\_DFC\_2013,为 2013 IEEE GRSS 数据融合竞赛所用,本文将其中的高光谱数据集用于实验,其高光谱图像摄取于休斯顿大学及其周围的城区,由 144 个光谱波段组成,图像尺寸为  $349 \times 1 905$ ,空间分辨率为 2.5 m.标记有 15 种不同的地物类别.

#### 3.2 参数设置

引导滤波的正则化参数  $\epsilon$  与窗口半径  $r$  影响着滤波输出的平滑程度,为保护图像有效的边缘结构,避免过度平滑使空间距离较远的像元混杂光谱信息, $r$  与  $\epsilon$  不宜设置的太大.协同表示的正则化参数  $\lambda$  平衡冗余误差项与正则化项,引导滤波的迭代次数  $T$  影响着邻域像元的相关性.本文分别在三个数据集的训练集上,采用交叉留一验证调节以上 4 个参数.

$\epsilon$  与  $r$  对全局分类准确率的影响如图 4 所示,为公平对比,令  $T=10, \lambda=0.1$ .适当的增加窗口半径  $r$  与正则化参数  $\epsilon$ ,有利于组内光谱的聚拢, $r$  与  $\epsilon$  过大时会使大尺度的边缘结构被平滑,造成边缘处像元光谱特征的丢失,从而准确率下降.由此获得三个数据集上最优的  $\epsilon$  与  $r$ .




图4 不同的  $\epsilon, r$  对 OA 的影响  
Fig.4 The influence of varying  $\epsilon$  and  $r$  on OA

$\lambda$  与  $T$  对全局分类准确率的影响如图 5 所示.在调节时  $\lambda$  与  $T$  时,  $\epsilon, r$  设置为已获得的最优值.曲线初段,分类准确率有较大的上升,表明引导滤波的局部线性变换引入了有效的空间信息.随着  $T$  的增加,滤波输出趋于稳定,分类准确率也趋于稳定.HGF-NRS 的最优参数设置如表 1 所示,对比方法的相关参数延用了原文的参数设置.

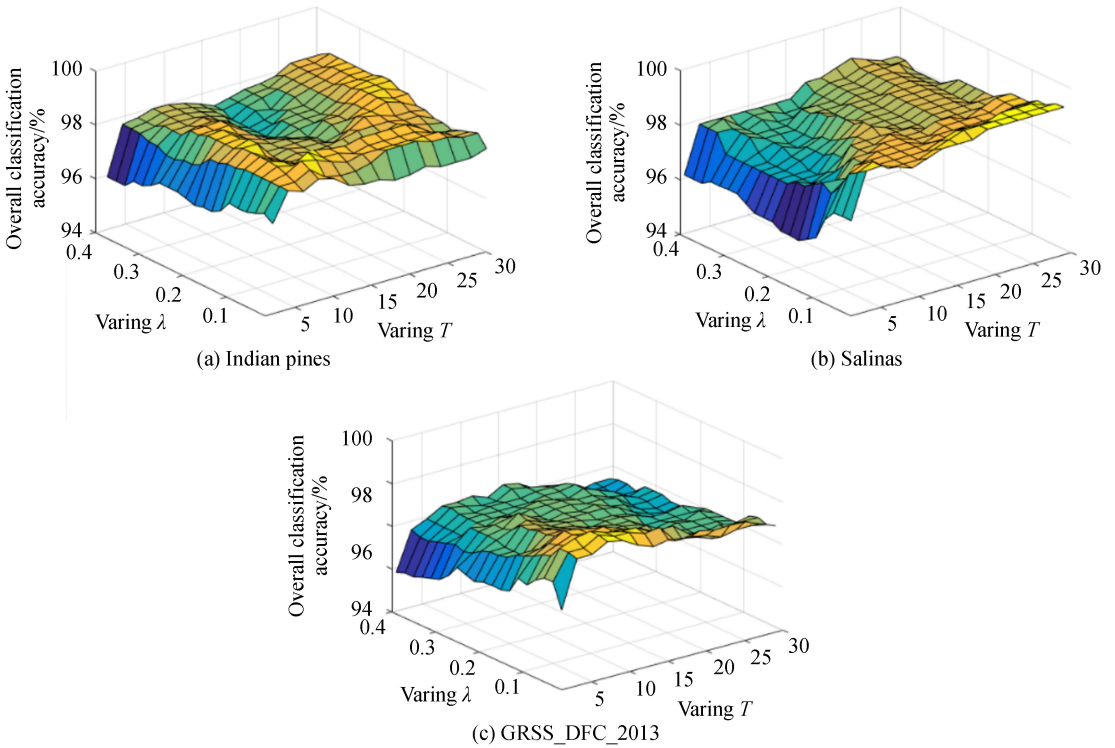


图5 不同的  $\lambda, T$  对 OA 的影响  
Fig.5 The influence of varying  $\lambda$  and  $T$  on OA

表 1 实验参数设置  
Table 1 Experimental parameters setting

	$g$	$r$	$T$	$\lambda$
Indian Pines	0.01	2	8	0.05
Salinas	0.000 5	2	18	0.01
GRSS_DFC_2013	0.000 1	1	7	0.03

### 3.3 实验结果与分析


随机选择训练与测试的样本,分别在三个数据集上进行对比实验,本文提出的方法以及对比方法的实验结果如表 2~7 所示.

对于 Indian Pines 数据集,随机选择样本总数的 10% 作为训练,其余的作为测试样本.由表 2 可见,本文提出的方法在 OA, AA 和 Kappa 上都取得了最优,半数以上的类别取得了最高的准确率.对比单纯利用原始

表 2 分类性能对比 (Indian Pines)

Table 2 Classification performance comparison (Indian Pines)

Class	Train	Test	NRS <sup>[10]</sup>	Gabor-NRS <sup>[19]</sup>	JCR2 <sup>[12]</sup>	HiFi-We <sup>[17]</sup>	EPF-G-g <sup>[16]</sup>	HGF-NRS
Alfalfa	24	22	95.45	<b>100.0</b>	16.20	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>
Corn-N	90	1338	78.68	90.15	95.83	93.39	94.22	<b>97.93</b>
Corn-M	80	750	76.57	93.42	<b>99.44</b>	93.60	96.66	95.05
Corn	68	169	47.16	95.48	95.83	<b>100.0</b>	78.97	98.83
Grass-P	71	412	90.87	97.54	99.50	98.78	97.53	<b>100.0</b>
Grass-T	74	656	97.62	98.18	97.57	99.69	99.24	<b>99.70</b>
Grass-P-M	14	14	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	92.85	<b>100.0</b>	<b>100.0</b>
Hay-W	70	408	99.03	<b>100.0</b>	99.51	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>
Oats	10	10	81.82	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>
Soybean-N	79	893	75.95	98.03	97.79	92.37	85.07	<b>98.07</b>
Soybean-M	109	2346	80.48	92.52	95.75	97.62	95.84	<b>98.81</b>
Soybean-C	69	524	83.16	94.14	98.53	98.09	94.45	<b>99.05</b>
Wheat	68	137	99.28	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	97.86
Woods	85	1180	95.63	<b>100.0</b>	<b>100.0</b>	99.06	98.62	<b>100.0</b>
Buildings-G-T-D	68	318	69.95	85.99	95.56	<b>100.0</b>	85.31	<b>100.0</b>
Stone-S-T	46	47	97.87	86.79	82.35	<b>100.0</b>	92.16	94.0
OA	-	-	82.85	94.58	96.14	96.87	94.57	<b>98.63</b>
AA	-	-	85.59	95.77	92.12	97.84	94.88	<b>98.71</b>
Kappa	-	-	80.27	93.74	95.55	96.39	93.75	<b>98.43</b>



Alfalfa	Corn-N	Corn-M	Corn
Grass-P	Grass-T	Grass-P-M	Hay-W
Oats	Soybean-N	Soybean-M	Soybean-C
Wheat	Woods	Buildings-G-T-D	Stone-S-T

图 6 各算法在 Indian Pines 数据集上的分类效果

Fig.6 Classification results of algorithms on Indian Pines dataset



光谱信息分类的 NRS 方法,联合空间光谱信息的方法均取得了更好的分类效果,其中本文提出的方法在全局分类精度上提高了约 16%.对比平均邻域光谱信息的 JCR2 方法,本文提出的方法有效保护了小块区域 (Alfalfa) 的光谱特征.对比联合多尺度滤波输出的 HiFi-We 方法,HGF-NRS 优选了特征,有着更为有效的特征表达,从而获得了更高的分类精度.EPF-G-g 方法执行引导滤波对分类概率图做纠正处理,其仍然是利用原始光谱数据做预分类,未能从根本上克服“同质异谱”现象带来的影响,而 HGF-NRS 的数据预处理策略有效的减小了类内光谱的差异,全局分类精度高出 EPF-G-g 约 4%.实验数据集 Indian Pines 第一主成分  $P_c$  与地物真值图如图 6 的(a)与(b)所示,与表 2 相对应的分类效果图如图 6(c)~(h)所示.

对于 Salinas 数据集,随机从每组中选择 30 个样本作为训练,剩余部分用作测试.由表 3 可见,本文提出的算法的 OA,AA和Kappa均明显高于其他算法,且三者均达到了99%.同比其他方法,HGF-NRS分别高


表 3 分类性能对比 (Salinas)

Table 3 Classification performance comparison (Salinas)


Class	Train	Test	NRS <sup>[10]</sup>	Gabor-NRS <sup>[19]</sup>	JCR2 <sup>[12]</sup>	HiFi-We <sup>[17]</sup>	EPF-G-g <sup>[16]</sup>	HGF-NRS
Broccoli-G-W-1	30	1979	99.95	<b>100.0</b>	<b>100.0</b>	99.24	<b>100.0</b>	<b>100.0</b>
Broccoli-G-W-2	30	3696	99.81	99.11	99.70	99.86	<b>99.95</b>	99.92
Fallow	30	1946	95.15	96.38	<b>100.0</b>	99.79	94.95	<b>100.0</b>
Fallow-R-P	30	1364	97.63	95.29	96.51	<b>98.97</b>	97.36	96.06
Fallow-S	30	2648	99.77	99.06	99.58	99.16	99.89	<b>100.0</b>
Stubble	30	3929	99.95	<b>100.0</b>	<b>100.0</b>	99.23	99.92	<b>100.0</b>
Celery	30	3549	99.30	99.66	<b>100.0</b>	99.04	<b>100.0</b>	<b>99.94</b>
Grapes-U	30	11241	81.48	94.50	92.30	82.93	90.56	<b>99.94</b>
Soil-V-D	30	6173	99.44	98.88	99.80	99.96	99.13	<b>99.97</b>
Corn-S-G-W	30	3248	90.82	95.79	97.99	89.28	91.44	<b>99.16</b>
Lettuce-R-4	30	1038	94.86	88.19	99.81	<b>100.0</b>	94.70	<b>100.0</b>
Lettuce-R-5	30	1897	98.91	99.95	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>
Lettuce-R-6	30	886	99.66	99.44	<b>100.0</b>	98.87	<b>100.0</b>	<b>100.0</b>
Lettuce-R-7	30	1040	98.04	90.43	98.38	96.82	<b>98.47</b>	93.88
Vinyard-U	30	7238	58.04	79.50	80.98	88.31	77.03	<b>95.98</b>
Vinyard-V-T	30	1777	95.81	98.88	<b>100.0</b>	99.38	99.33	99.83
OA	-	-	88.11	94.48	95.36	93.86	93.67	<b>99.13</b>
AA	-	-	94.29	95.94	97.82	96.93	96.42	<b>99.04</b>
Kappa	-	-	86.81	93.87	94.83	93.17	92.96	<b>99.03</b>

(a)  $P_c$ 

(b) Ground truth




(c) NRS



(d) Gabor-NRS





Brocoli-G-W-1	Brocoli-G-W-2	Fallow	Fallow-R-	PFallow-S	Stubble	Celery	Grapes-U
Soil-V-D	Corn-S-G-W	Lettuce-R-4	Lettuce-R-5	Lettuce-R-6	Lettuce-R-7	Vinyard-U	Vinyard-V-T

图7 各算法在 Salinas 数据集上的分类效果图

Fig.7 Classification results of algorithms on Salinas dataset


出 NRS, Gabor-NRS, JCR2, HiFi-We, EPF-G-g 约 11%, 4.6%, 3.8%, 5%, 5%。并且 HGF-NRS 的各组分类准确率均在 90% 以上, 有着更为稳定的输出。实验数据集 Salinas 第一主成分  $P_c$  与地物真值图如图 7 的 (a) 与 (b) 所示, 与表 3 相对应的分类效果图如图 7(c)~(h) 所示。

对于 GRSS\_DFC\_2013 数据集, 随机选择的训练与测试的样本数如表 4 所示。该数据有着较高的分辨率, 各算法的分类精度相对较高。HGF-NRS 仍然具有更好的表现, 所有种类地物分类均取得了最高的分类


表 4 分类性能对比 (GRSS\_DFC\_2013)

Table 4 Classification performance comparison (GRSS\_DFC\_2013)


Class	Train	Test	NRS <sup>[10]</sup>	Gabor-NRS <sup>[19]</sup>	JCR2 <sup>[12]</sup>	HiFi-We <sup>[17]</sup>	EPF-G-g <sup>[16]</sup>	HGF-NRS
Healthy grass	99	1152	99.20	99.65	97.04	92.10	99.03	<b>99.91</b>
Stressed grass	95	1159	98.29	97.22	<b>99.91</b>	95.85	96.71	<b>99.91</b>
Synthetic grass	96	601	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	98.83	<b>100.0</b>	<b>100.0</b>
Trees	94	1150	97.87	98.83	99.74	88.08	99.48	<b>100.0</b>
Soil	93	1149	97.60	99.91	<b>100.0</b>	99.65	98.63	<b>100.0</b>
Water	91	234	<b>100.0</b>	87.64	89.65	97.86	<b>100.0</b>	<b>100.0</b>
Residential	98	1170	84.82	93.19	93.66	82.64	97.04	<b>97.73</b>
Commercial	95	1149	91.59	96.82	97.40	62.83	97.37	<b>99.56</b>
Road	96	1156	77.34	87.53	93.58	88.06	96.84	<b>97.22</b>
Highway	95	1132	95.96	98.57	99.55	96.11	97.66	<b>100.0</b>
Railway	90	1145	93.23	97.82	98.06	89.95	93.59	<b>99.13</b>
Parking lot 1	96	1137	93.05	99.27	<b>100.0</b>	86.10	94.59	<b>100.0</b>
Parking lot 2	92	377	57.96	93.70	94.68	93.37	87.61	<b>99.47</b>
Tennis court	90	338	99.40	<b>100.0</b>	94.41	<b>100.0</b>	95.48	<b>100.0</b>
Running track	93	567	<b>100.0</b>	96.76	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>
OA	-	-	91.86	96.68	97.67	89.70	97.10	<b>99.42</b>
AA	-	-	92.42	96.46	97.18	91.43	96.94	<b>99.53</b>
Kappa	-	-	91.19	96.41	97.48	88.85	96.86	<b>99.37</b>




(a)  $P_c$




(b) Ground truth




(c) NRS




(d) Gabor-NRS




(e) JCR2



(f) HiFi-We



(g) EPF-G-g



(h) HGF-NRS

Healthy grass	Stressed grass	Synthetic grass	Trees	Soil	Water	Residential	Commercial
Road	Highway	Railway	Parking lot1	Parking lot2	Tennis court	Running track	

图8 各算法在 GRSS\_DFC\_2013 数据集上的分类效果图

Fig.8 Classification results of algorithms on GRSS\_DFC\_2013 dataset

精度,15组地物中更是有8组实现了100%的准确率,且OA,AA与Kappa再一次达到了99%.实验数据集GRSS\_DFC\_2013第一主成分 $P_c$ 与地物真值图如图8的(a)与(b)所示,与表4相对应的分类效果图如图8(c)~(h)所示.从分类效果图6~8可以看出,整体上,HGF-NRS的分类效果图更为准确平滑;细节上,HGF-NRS在容易产生错误分类的边缘处也有着更为准确的表现.

在某些应用场景下,可使用的训练样本非常有限.为探究算法在不同训练样本数下的鲁棒性,在

表5 不同训练样本比例下的全局准确率(Indian Pines)

Table 5 Overall classification accuracy in varying proportion of training samples(Indian Pines)

	Proportion of training samples/%				
	1	2	3	4	5
NRS <sup>[10]</sup>	58.78(3.57)	66.71(1.93)	72.28(2.03)	74.46(1.10)	76.40(1.48)
Gabor-NRS <sup>[19]</sup>	58.40(3.54)	71.50(2.11)	81.13(1.85)	84.75(2.73)	88.38(1.97)
JCR2 <sup>[12]</sup>	68.42(3.98)	79.45(3.79)	87.27(1.09)	89.88(1.34)	92.49(1.06)
HiFi-We <sup>[17]</sup>	74.74(2.31)	85.66(1.98)	87.73(3.16)	91.72(1.11)	93.40(1.03)
EPF-G-g <sup>[16]</sup>	64.34(3.69)	74.63(4.00)	83.02(2.96)	86.30(0.74)	88.54(1.42)
HGF-NRS	<b>79.66(4.04)</b>	<b>89.47(1.60)</b>	<b>92.75(0.94)</b>	<b>94.19(1.29)</b>	<b>96.38(0.66)</b>

表6 不同训练样本比例下的全局准确率(Salinas)

Table 6 Overall classification accuracy in varying proportion of training samples(Salinas)

	Proportion of training samples/%				
	0.4	0.5	0.6	0.7	0.8
NRS <sup>[10]</sup>	85.33(1.94)	87.32(1.74)	87.18(1.02)	87.52(1.13)	87.77(1.23)
Gabor-NRS <sup>[19]</sup>	90.20(0.97)	91.67(0.76)	92.42(1.33)	92.77(1.30)	93.61(0.56)
JCR2 <sup>[12]</sup>	91.30(1.54)	92.32(0.61)	92.90(1.34)	93.48(1.26)	94.22(1.36)
HiFi-We <sup>[17]</sup>	91.78(1.43)	91.78(0.94)	92.40(1.32)	92.50(1.32)	93.19(1.14)
EPF-G-g <sup>[16]</sup>	89.03(3.39)	89.23(1.77)	91.58(2.71)	91.77(2.70)	91.34(3.07)
HGF-NRS	<b>96.28(0.79)</b>	<b>96.86(0.88)</b>	<b>98.40(0.51)</b>	<b>98.42(0.50)</b>	<b>98.93(0.43)</b>

表7 不同训练样本比例下的全局准确率(GRSS\_DFC\_2013)

Table 7 Overall classification accuracy in varying proportion of training samples (GRSS\_DFC\_2013)

	Proportion of training samples/%				
	1	2	3	4	5
NRS <sup>[10]</sup>	80.46(1.67)	86.24(1.23)	88.70(1.09)	90.22(0.56)	90.85(0.58)
Gabor-NRS <sup>[19]</sup>	75.19(1.60)	84.76(1.35)	88.96(0.85)	91.21(0.98)	93.21(0.78)
JCR2 <sup>[12]</sup>	84.92(1.33)	91.15(0.95)	93.85(1.08)	95.41(0.94)	96.52(0.69)
HiFi-We <sup>[17]</sup>	80.43(2.62)	85.22(1.71)	86.71(1.66)	88.08(1.03)	88.72(0.63)
EPF-G-g <sup>[16]</sup>	78.08(2.75)	87.00(1.60)	90.87(2.08)	93.11(0.66)	93.74(0.61)
HGF-NRS	<b>86.14(2.13)</b>	<b>93.00(1.66)</b>	<b>95.18(1.03)</b>	<b>96.71(0.74)</b>	<b>97.61(0.74)</b>

Indian Pines 与 GRSS\_DFC\_2013 数据集上选取样本总数的 1%~5% 做训练样本,在 Salinas 数据集上选取样本总数的 0.4%~0.8% 做训练样本,与前述的方法进行对比实验.每种方法在不同训练样本比例下均进行 10 次实验,表 5~7 是 OA 的均值与标准差.从表 5~7 可以看出,随着训练样本数的减少,各算法的 OA 随之下降,其中 HGF-NRS 在不同数量的训练本数下均取得了更高了 OA 且具有明显的优势,而对比的方法在不同的数据集上表现各异.由此可知,本文提出的方法有着更好的稳定性与通用性.

最后,在前述的三个数据集上对各分类算法的计算时间进行比较,选用的训练与测试样本数目与表 2~4 相对应.实验环境为 windows10, CPU 2.6GHz, RAM 16GB, MATLAB2016b.实验结果如表 8 所示,HiFi-We 用时最长,主要用于分层引导滤波过程与多尺度特征联合投票分类.本文所提方法与 HiFi-We 相比,HGF-NRS 仅保留最终的滤波输出用于分类,数据体量与原始待分类的高光谱数据一致,滤波迭代次数更少,且利用了分类效率较高的 NRS 分类器,整体时间开销相对较少.EPF-G-g 方法主要耗时在 SVM 的分类阶段,其需要对图像内所有像元进行预分类以获得分类概率图,此操作会随着高光谱图像尺寸的增加而产生明显的时间开销,分类概率图的后处理阶段因待滤波的数据量较少并未产生明显的耗时,总体上仍有较高的效率.在 NRS 的基础上,JCR2 的平均邻域像元的操作步骤产生少量的耗时.Gabor-NRS 因采取了波段选择策略,减小了待分类数据的维度,获得了相对较高的效率.由此,HGF-NRS 可通过高效的波段遴选方法加速分类过程以提高其效率,此将作为进一步的工作内容.

表 8 各算法的计算时间(s)  
Table 8 Computing time of algorithms (s)

	NRS <sup>[10]</sup>	Gabor-NRS <sup>[19]</sup>	JCR2 <sup>[12]</sup>	HiFi-We <sup>[17]</sup>	EPF-G-g <sup>[16]</sup>	HGF-NRS
Indian Pines	48.3	33.10	49.5	589.5	7.9	53.4
Salinas	136.6	91.32	140.2	647.26	13.7	179.9
GRSS_DFC_2013	90.9	86.6	103.6	1 208.4	108.5	270.4

## 4 结论

本文提出了基于分层引导滤波与最近邻正则化子空间的高光谱图像分类算法,利用分层引导滤波的边缘保护特性对高光谱图像进行预处理,有效地平滑了类内光谱的差异,并避免了边缘处类间光谱信息的混淆.利用最近邻正则化子空间分类器的协同特性,对预处理后的数据进行分类.三个真实的高光谱数据集的实验结果表明,本文提出的方法在分类精度与可视化的分类结果上均取得了更优的效果,且在样本数较少时也有着较好的表现.分层引导滤波会考虑引导图像的边缘,区域性的平滑输入图像,滤波输出依赖于引导图像的边缘位置与边缘强弱.现有的边缘保护滤波多以图像的第一主成分作为引导图像,下一步的研究内容是获得边缘信息更为有效的引导图像,实现边缘位置更加准确的引导滤波,从而进一步提高分类效果.

## 参考文献

- [1] BRUNET D, SILLS D. A generalized distance transform: theory and applications to weather analysis and forecasting[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, **55**(3): 1752-1764.
- [2] SU Hong-jun, WU Zhao-yue, DU Qian, et al. Hyperspectral anomaly detection using collaborative representation with outlier removal[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, **11**(12): 5029 - 5038.
- [3] LI Shu-tao, ZHANG Kun-zhong, HAO Qian-bo, et al. Hyperspectral anomaly detection with multiscale attribute and edge-preserving filters[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, **15**(10): 1605-1609.
- [4] CARRINO T A, CRÓSTA A P, TOLEDO C L B, et al. Hyperspectral remote sensing applied to mineral exploration in southern Peru: A multiple data integration approach in the Chapi Chiara gold prospect[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2018, **64**: 287-300.
- [5] KUMAR C, CHATTERJEE S, OOMMEN T. Mapping hydrothermal alteration minerals using high-resolution AVIRIS-NG hyperspectral data in the Hutti-Maski gold deposit area, India[J]. *International Journal of Remote Sensing*, Taylor & Francis, 2019, **41**(2): 1-19.
- [6] CAMPS-VALLS G, GOMEZ-CHOVA L, MUÑOZ-MARÍ J, et al. Composite kernels for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2006, **3**(1): 93-97.
- [7] TARABALKA Y, FAUVEL M, CHANUSSOT J, et al. SVM- and MRF-based method for accurate classification of hyperspectral images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2010, **7**(4): 736-740.
- [8] CHEN Yi, NASRABADI N M, TRAN T D. Hyperspectral image classification using dictionary-based sparse



- representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **49**(10): 3973-3985.
- [9] ZHANG Hong-yan, LI Jia-yi, HUANG Yuan-cheng, *et al.* A nonlocal weighted joint sparse representation classification method for hyperspectralimagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, **7**(6): 2057-2066.
- [10] LI Wei, TRAMEL E W, PRASAD S, *et al.* Nearest regularized subspace for hyperspectralclassification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(1): 477-489.
- [11] BELL J B, TIKHONOV A N, ARSENIN V Y. Solutions of Ill-Posed Problems.[J].*Mathematics of Computation*, 1978, **32**(144): 1320-1322.
- [12] LI Wei, DU Qian. Joint within-class collaborative representation for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, **7**(6): 2200-2208.
- [13] JAIN P, TYAGI V. A survey of edge-preserving image denoising methods[J]. *Information Systems Frontiers*, 2016, **18**(1): 159-170.
- [14] LI Zheng-guo, ZHENG Jing-hong. Edge-preserving decomposition-based single image haze removal [J]. *IEEE Transactions on Image Processing*, 2015, **24**(12): 5432-5441.
- [15] PARK D, HAN D K, KO H. Single image haze removal with WLS-based edge-preserving smoothing filter [C]. ICASSP, *IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 2013: 2469-2473.
- [16] KANG Xu-dong, LI Shu-tao, BENEDIKTSSON J A. Spectral-spatial hyperspectral image classification with edge-preserving filtering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(5): 2666-2677.
- [17] PAN Bin, SHI Zhen-wei, XU Xia. Hierarchical guidance filtering-based ensemble classification for hyperspectral images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, **55**(7): 4177-4189.
- [18] HE Kai-ming, SUN Jian, TANG Xiao-ou. Guided image filtering[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, **35**(6): 1397-1409.
- [19] LI Wei, DU Qian. Gabor-filtering-based nearest regularized subspace for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, **7**(4): 1012-1022.