doi:10.6041/j.issn.1000-1298.2018.01.005

结合 Beltrami 流和递归滤波的高光谱图像分类方法

廖建尚[1]　王立国[2]　郝思媛[3]

(1.广东交通职业技术学院计算机工程学院,广州 510650;2.哈尔滨工程大学信息与通信工程学院,哈尔滨 150001;
3.青岛理工大学通信与电子工程学院,青岛 266520)

摘要:提出一种结合 Beltrami 流滤波和域转换递归滤波的高光谱图像分类算法(BFRF-SVM)。分别利用 Beltrami 流对主成分分析(PCA)降维后的高光谱图像滤波方法和域转换递归滤波方法对全光谱波段进行滤波,两种空间信息进行线性融合后交由支持向量机(SVM)完成分类。实验表明,相比使用光谱信息、高光谱降维、空谱结合的 SVM 分类方法,以及边缘保持滤波和递归滤波以及形态学滤波特征方法,本文提出的 BFRF-SVM 方法对高光谱图像的分类精度有较大提高,验证了该方法的有效性。

关键词:高光谱图像;空间信息;分类;Beltrami 流;域转换递归滤波

中图分类号:TP753　　**文献标识码**:A　　**文章编号**:1000-1298(2018)01-0042-09

Hyperspectral Image Classification Method Combined Beltrami Flow and Recursive Filter

LIAO Jianshang[1]　WANG Liguo[2]　HAO Siyuan[3]

(1. *School of Computer Engineering*, *Guangdong Communication Polytechnic*, *Guangzhou* 510650, *China*
2. *College of Information and Communication Engineering*, *Harbin Engineering University*, *Harbin* 150001, *China*
3. *College of Communication and Electronic Engineering*, *Qingdao University of Technology*, *Qingdao* 266520, *China*)

Abstract: In the past, spatial feature extraction of hyperspectral image was usually limited to one feature extraction, and the more comprehensive spatial feature was not obtained. An improved scheme was put forward according to existent methods. An algorithm of classification (BFRF-SVM) was proposed, which was combined with spatial information obtained by Beltrami flow and domain transform recursive filter. Firstly, the spatial feature was extracted by Beltrami flow on hyperspectral data whose dimensions were reduced by principal component analysis (PCA), and the spatial correlation feature was obtained by domain transform recursive filter for all bands. Secondly, the two kinds of feature were combined, which were classified by SVM. The BFRF-SVM classification method was implemented on the hyperspectral data of Indian Pines and Pavia. The following results were obtained. In the first place, the overall accuracy (OA) of Indian Pines was 96.01% and that of Pavia was 97.46%, which were 12 ~ 15 percentage points higher than that of SVM, 12 ~ 16 percentage points higher than that of PCA-SVM, 2 ~ 12 percentage points higher than that of SGB-SVM, SBL-SVM and SGD-SVM, 4 ~ 5 percentage points higher than that of EPF, 1 ~ 3 percentage points higher than that of IFRF, and 2 ~ 6 percentage points higher than that of SMP-SVM, respectively, showing very good performance in hyperspectral classification. In the second place, although the training samples were only 7% of Indian Pines and 3% of Pavia, the OA of both can reach 96.01% and 97.46%, respectively, which removed the salt and pepper noise in the classification map obviously. In the last place, although the training samples were reduced to 4% and 0.5% for Indian Pines and Pavia, the OA can be over 91% and 90%, respectively. When the training samples were increased to 10% and 4.5%, the OA can exceed 97% and 98%, respectively. The effectiveness of BFRF-SVM was fully verified in the hyperspectral classification with

收稿日期:2017-05-31　修回日期:2017-06-23

基金项目:国家自然科学基金项目(61275010、61675051)、国家星火计划项目(2014GA780056)、广东省科技计划项目(2017ZC0538)、广东交通职业技术学院校级重点科研项目(2017-1-001)和广东省高等职业教育品牌专业建设项目(2016gzpp044)

作者简介:廖建尚(1982—),男,副教授,主要从事高光谱图像处理研究,E-mail:liaojianshang@126.com

good stability. The experiments showed that the BFRF－SVM algorithm was better than original SVM with the pure spectrum information, dimensionality reduction, the spatial-spectral information, the method of edge-preserving filtering and recursive filtering, and the morphological feature based method. The performance of hyperspectral image classification algorithm, i. e. BFRF－SVM, was greatly improved, and the effectiveness of the method was fully verified. The method can be applied into the field of classification and identification for agriculture and forest.

Key words: hyperspectral image; spatial information; classification; Beltrami flow; domain transform recursive filter

0　引言

通过成像光谱仪可以获得达到几百个波段光谱信息的高光谱遥感图像，具有波段多、光谱分辨率高的优点，但是分类结果中椒盐噪声严重影响高光谱图像分类的应用[1－2]。近年来，越来越多学者对在高光谱图像分类中融入空间特征进行了深入研究，目前常见的空间特征提取方法有，形态滤波特征提取[3－4]、马尔科夫随机场特征提取[5－6]、图像分割特征提取[7－8]，其中用滤波器提取高图像纹理信息进行分类逐渐成为一个研究热点。有部分学者用 Gabor 滤波器[9]提取纹理信息来辅助高光谱分类，HE 等[10]通过识别低阶 Gabor 滤波提取高光谱图像的空间特征，提出了判别式低阶 Gabor 滤波（Discriminative low-rank gabor filtering, DLRGF）的高光谱图像分类方法；IMANI 等[11]采用灰度共生矩阵、Gabor 滤波器和形态学滤波器提取空间纹理信息、外形特征和像元邻域信息，并通过不同的特征结合寻找最优的分类算法；JIA 等[12]利用 Gabor 滤波器提取多维数据集特征，联合稀疏表示提出一种有效地空谱结合分类方法 GS－MTJSRC；冯逍等[13]按照纹理对不同地物响应的区分度逐一加入三维 Gabor 纹理特征并辅助光谱信息，用支持向量机（Support vector machine, SVM）进行分类。也有一些学者用双边滤波器[14]来提取高光谱空间纹理信息，如 WANG 等[15]先用概率 SVM 获取初始分类结果，然后用双边滤波进行平滑处理，最后用图像分割的方法获取高光谱的分类结果，提高了分类精度。KANG 等[16]先用 SVM 初始分类，再用双边滤波对分类结果进行优化，提出了边缘保持滤波分类方法（Edge-preserving filtering, EPF）；SHEN 等[17]用双边滤波器对空谱信息子集提取空间纹理信息，融合后再用极端学习机器对其进行有效分类。还有一些学者用递归滤波[18]提取空间纹理信息，如 KANG 等[19]用递归滤波对高光谱子集融合后提取空间信息，交由 SVM 实现分类，提出了图像融合和递归滤波的高光谱图像分类方法（Image fusion and recursive filtering, IFRF），获得较好的分类结果。另外有不少学者采用了 Beltrami 流滤波[20－24]进行了研究，Beltrami 流应用广泛，但目前没有应用在高光谱图像处理方面的研究报道。

过去在高光谱图像空间纹理信息提取并分类的研究中取得了一定成效，但也存在一些不足：高光谱图像空间分辨率低，空间纹理信息还有待进一步挖掘；地物分布往往具有统一性，在提取空间纹理信息时容易去除像元间的空间相关性。为提高高光谱图像的分类性能，本文提出一种结合 Beltrami 流滤波和域转换递归滤波的高光谱图像分类算法（BFRF－SVM），充分利用 Beltrami 流滤波提取的边缘结构特征和域转换递归滤波提取的空间相关信息，有效辅助 SVM 进行分类。

1　空间特征提取方法

1.1　Beltrami 流滤波提取空间纹理信息

Beltrami 流滤波是一种定义在图像流形上的热扩散方程，有清晰的几何意义，可以获取较好的图像边缘信息，对有 n 个波段的高光谱图像，第 i 个波段图像 R^i 的 Beltrami 流滤波在高光谱的定义为

$$R_t^i = \frac{\partial R^i}{\partial t} = \frac{1}{\sqrt{g}}\mathrm{div}\left(\frac{\nabla R^i}{\sqrt{g}}\right) \quad (i = 1, 2, \cdots, n) \tag{1}$$

其中

$$\nabla R^i = (R_x^i, R_y^i) = \left(\frac{\partial R^i}{\partial x}, \frac{\partial R^i}{\partial y}\right) \tag{2}$$

$$g = 1 + |\nabla R^i|^2 \tag{3}$$

式中　R_t^i——图像 R^i 对时间 t 的导数

∇、div——梯度算子、散度算子

g——度量张量，表示图像曲面的第一基本形式的行列式

R_x^i、R_y^i——高光谱波段图像 R^i 在 x、y 方向的梯度

$1/\sqrt{g}$——曲面的法向矢量的投影，边缘保持指标

Beltrami 流滤波是一种最小化扩散的有效保持图像边缘、结构特点的噪声滤波方法，在图像的噪声平滑与边缘保持方面取得很好的平衡，式（1）的偏微分方程实现基于有限差分离散化，采用欧拉向前

差分逼近 I_t 和中间偏差逼近空间导数,重新获得 Beltrami 流滤波公式

$$R_k^i = R_{k-1}^i + h_t \frac{R_{xx}^i(1+R_y^i) + R_{yy}^i(1+R_x^i) - R_x^i R_y^i R_{xy}^i}{(1+R_x^{i2}+R_y^{i2})^2} \tag{4}$$

其中 $R_{xx}^i = \dfrac{\partial^2 R^i}{\partial x^2}$ $R_{yy}^i = \dfrac{\partial^2 R^i}{\partial y^2}$ $R_{xy}^i = \dfrac{\partial^2 R^i}{\partial xy}$

式中 R_k^i——图像 R^i 的第 k 次迭代

h_t——时间步长

图 1 所示为印第安林高光谱图像第 10 波段以及经 PCA 降维后的第 1、2、3 主成分滤波前后图像,图 2 所示为 Beltrami 流滤波对印第安林高光谱图像第 10 波段以及经 PCA 降维后的第 1、2、3 主成分滤波后图像,由图 1、2 可以看出,Beltrami 流滤波有较好的去噪效果,并能有效获取高光谱边缘结构特性。

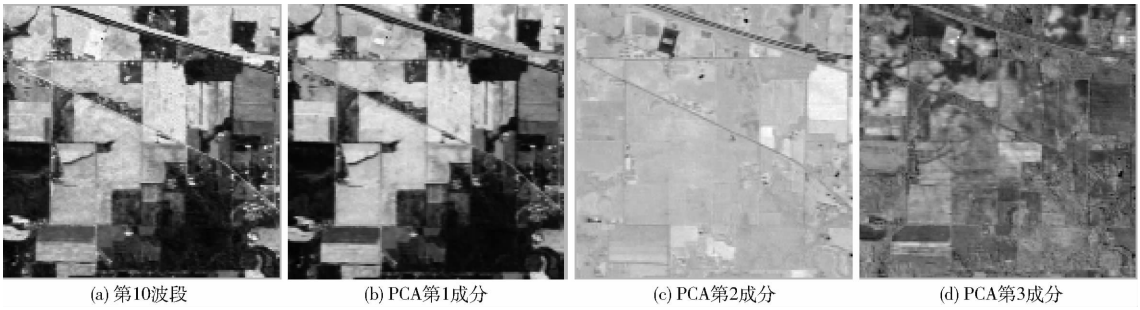

(a) 第10波段 (b) PCA第1成分 (c) PCA第2成分 (d) PCA第3成分

图 1 印第安林高光谱图像

Fig. 1 Hyperspectral images of Indian Pines

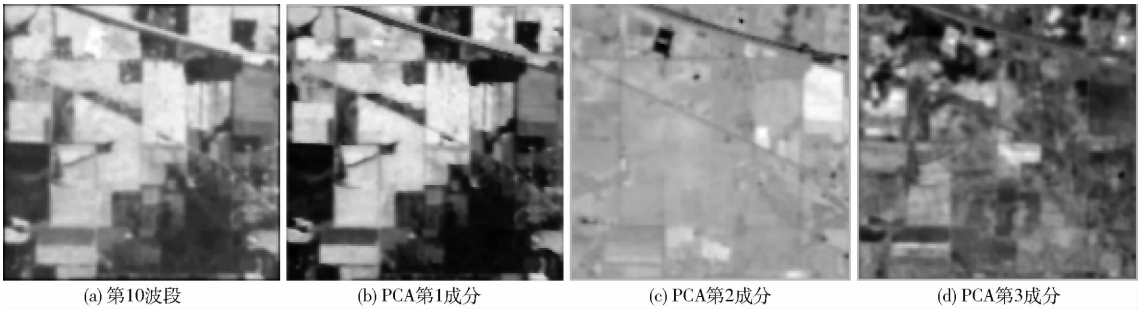

(a) 第10波段 (b) PCA第1成分 (c) PCA第2成分 (d) PCA第3成分

图 2 印第安林的 Beltrami 流滤波

Fig. 2 Beltrami flow filtering for Indian Pines

Beltrami 流滤波具有较好的图像边缘保持特性,但是在保持边缘的同时容易去除空间相关性信息,本文将用域转换递归滤波[18]来获取空间相关性信息,弥补 Beltrami 流滤波在图像处理中的不足。

1.2 域转换递归滤波提取空间相关信息

域转换递归滤波是 2011 年由 Gastal 等提出的图像特征提取算法,可以将二维的滤波转换为一维的特征提取滤波,对第 i 个波段的高光谱图像的域转换递归滤波 $D_i(n)$ 在高光谱上的定义为

$$D_i(n) = (1-a^d)I[n] + a^d D_i[n-1] \tag{5}$$

其中

$$d = f(y_n) - f(y_{n-1}) \tag{6}$$

$$f(y_n) = \int_0^{y_n} \left(1 + \frac{\sigma_s}{\sigma_r}\sum_{i=1}^{c} |R_i'(x)|\right) \mathrm{d}x \tag{7}$$

$$\sigma_r = \sqrt{3}\sigma_H \tag{8}$$

$$\sigma_{H_t} = \sigma_s \sqrt{3}\frac{2^{N-t}}{\sqrt{4^N-1}} \tag{9}$$

$$a = \mathrm{e}^{-\sqrt{2}/\sigma_H} \tag{10}$$

式中 a^d——反馈系数

$I[n]$——高光谱图像

$D_i[n-1]$——第 $n-1$ 次递归滤波

d——两个相邻像元 y_n 和 y_{n-1} 在转换域 Ω_w 中的距离

$f(y_n)$——某高光谱波段图像 R_i 求偏微分后的累加求积分变换为递增函数,将二维图像滤波转换为一维图像滤波

r——滤波半径

σ_s——空间标准偏差

σ_r——范围标准偏差

σ_{H_t}——第 t 次迭代的数值

N——总迭代次数

该滤波是一个指数衰减的无限冲击响应滤波,当 d 增大即两像元距离增大时,a^d 趋于 0,阻止链接传播,因此可以保持边缘特性,式(5)并不对称,依赖输入和输出,是一个因果滤波器,为了滤波对称,式(5)需要执行 2 次,先从左边到右边,再从右边到左边,或者从顶部到底部,再从底部到顶部。

图 3 所示为域转换递归滤波对印第安林高光谱图像第 10 波段以及经 PCA 降维后的第 1、2、3 主成分滤波后的图像，由图 3 可以看出，滤波后的图像同类地物灰度相近，说明有一定的相关性。

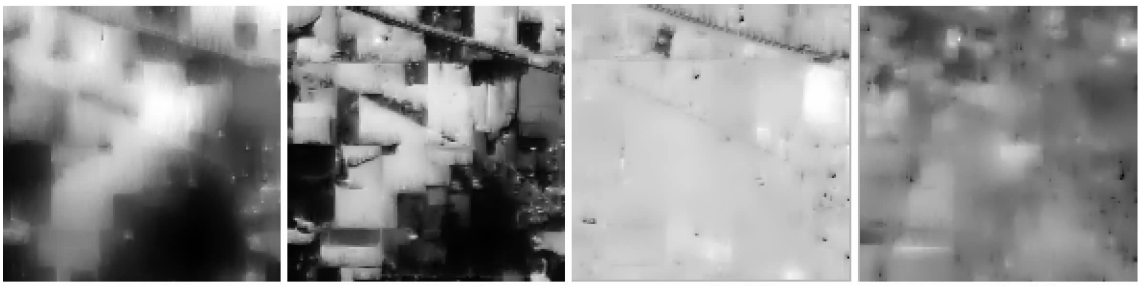

(a) 第10波段　(b) PCA第1成分　(c) PCA第2成分　(d) PCA第3成分

图 3　印第安林的域转换递归滤波

Fig. 3　Domain transform recursive filtering for Indian Pines

高光谱像元间有较强的空间相关性，为了分析 Beltrami 流滤波和域转换递归滤波对空间相关性的保持特性，本文引入 Moran 于 1950 年提出的 Moran's I 指数[25-26]来衡量其高光谱图像滤波前后的空间自相关性，表达式为

$$I=\frac{m\sum_{i=1}^{m}\sum_{j=1}^{m}\alpha_{ij}(S_i-\bar{S})(S_j-\bar{S})}{\sum_{i=1}^{m}\sum_{j=1}^{m}\alpha_{ij}\sum_{i=1}^{m}(S_i-\bar{S})^2} \tag{11}$$

式中　S_i——高光谱某像元的反射强度

S_j——其他像元的反射强度

m——某波段的像元数量

$\bar{S}$——S 的均值

α_{ij}——空间比重权重

I 大代表空间相关性强，I 小代表空间差异性大。为了对比两类滤波器对空间自相关性的保持特性，分别对印第安林数据集滤波并计算滤波后的 Moran's I 指数且求其均值。如图 4 所示，域转换递归滤波的大部分 Moran's I 指数均值要高于 Beltrami 流滤波和光谱波段，因此域转换递归滤波可以有效弥补 Beltrami 流滤波在图像滤波中的不足。

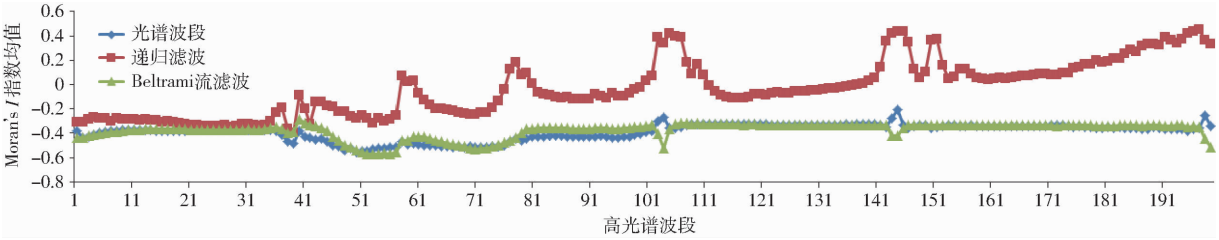

图 4　印第安林数据集的 Moran's I 指数的均值

Fig. 4　Average of Moran's I for Indian Pines

1.3　两种空间信息自适应融合分类

本文用 Beltrami 流滤波提取的空间纹理信息和域转换递归滤波提取的空间相关性信息，两种信息提取和融合后，由 SVM 完成分类，形成 BFRF－SVM 分类算法，实现过程如下：

(1)高光谱 PCA 降维：对于有 l 个波段的高光谱数据集 R 进行 PCA 降维，选择前面维度的数据组成新的数据集 B。

$$B=P_{ca}(R) \tag{12}$$

(2)提取空间信息 1：用 Beltrami 流滤波对 PCA 降维后的数据集 H 按照式(4)进行滤波，获取空间信息 D_{mp}。

$$D_{mp}^{i}=F(H^{i}) \tag{13}$$

(3)域转换递归滤波提取空间信息 2：用域转换递归滤波对高光谱数据集 R 按照式(5)作域转换标准卷积滤波，获取空间信息 D_{ts}。

$$D_{ts}^{i}=T(R^{i}) \tag{14}$$

(4)空间信息线性叠加：D_{mp} 和 D_{ts} 按照

$$W=D_{mp}+D_{ts} \tag{15}$$

结合成 W。

(5)分类：①从空间信息数据集 W 中以一定比例随机抽取训练集 W_s，其余部分作为测试集 W_t。②用径向基函数支持的 SVM 方法交叉验证，寻找最优参数组合。③用径向基函数支持的 SVM 对 W_s 进行训练，获取训练模型。④获取模型后，用径向基函数支持的 SVM 对测试集 W_t 进行分类。

BFRF－SVM 分类算法流程如图 5 所示。

2　实验数据集

为验证本文提出算法的有效性，采用印第安农林和帕维亚大学的 2 个高光谱数据集进行验证，其特征如下：①印第安农林高光谱数据集来自机载可

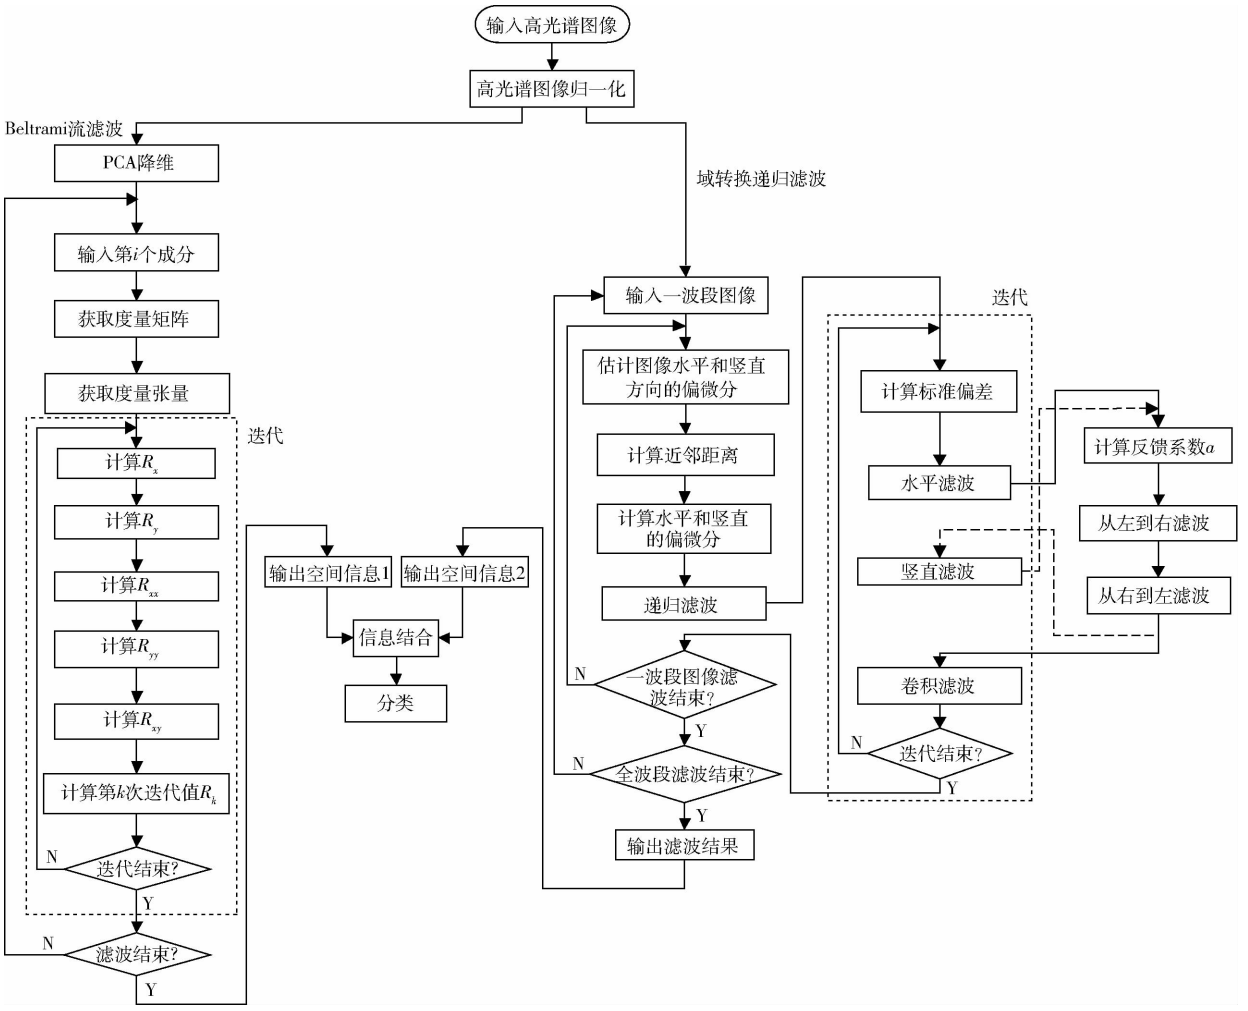

图 5 BFRF－SVM 算法流程图

Fig. 5 Flow chart of BFRF－SVM

见红外成像光谱仪(Airborne visible infrared imaging spectrometer),是 1992 年在印第安纳州西北部印第安农林收集到的高光谱遥感图像,具有 20 m 的空间分辨率,包含 144×144 个像元,220 个波段,由于噪声和水吸收等因素除去其中的 20 个波段,剩余 200 个波段,共有 16 种地物。②帕维亚大学数据集来自反射式光学系统成像光谱仪(Reflective optics system imaging spectrometer),拍摄于帕维亚大学的高光谱遥感图像,包含 610×340 个像元,115 个波段,由于噪声等因素去除其中的 12 个波段,剩余 103 个波段,共有 9 个类别。

3 实验设计与评价指标

为验证本文所提算法在高光谱分类的优越性,使用 7 种方法进行比较:①利用文献[27]提出的 SVM 算法。②利用 PCA 对光谱信息降维后,用 SVM 进行分类。③用 Gabor 滤波器、双边滤波器和导向滤波器分别对高光谱数据用 PCA[27] 降维后的前 20 个主成分提取空间信息,并将获取的空间信息和光谱信息线性结合后,用 SVM 进行分类,形成 SGB－SVM、SBL－SVM、SGD－SVM。④文献[15]提出的 EPF 算法对高光谱图像进行分类,有 EPF－B－c 和 EPF－G－c。⑤文献[19]提出的域转换递归滤波方法 IFRF。⑥文献[29]提出的形态学滤波方法 SMP－SVM。⑦BFRF－SVM。

本文用整体分类精度(Overall accuracy, OA)、平均分类精度(Average accuracy, AA)以及 Kappa 统计系数(Kappa statistic, Kappa)来衡量分类算法的精度,为了避免随机偏差,每个实验重复 10 次记录平均结果,验证平台采用 Matlab R2012b,i7－6700 CPU,8GB RAM 实验平台。

3.1 参数寻优验证

为了确定 Beltrami 流滤波参数迭代次数 k 和时间步长 h_t,本文采用穷举法,通过前期实验初步估算,限定取值范围,分别为 $k \in [10, 11, \cdots, 100]$,$h_t \in [0.01, 0.02, \cdots, 0.2]$,采用印第安农林图像作为实验数据集,分别获取最优分类结果的参数值。先对印第安林数据集进行 PCA 降维后取前 30 个主成分作为测试数据集,然后随机抽取数据集的 8% 作为训练样本和数据集的 92% 作为测

试样本进行验证，实验结果如图 6 所示。当 $k=36$、$h_t=0.04$，得到分类结果最优：整体分类精度为 94.23%，因此本文 Beltrami 流滤波系数取 $k=36$、$h_t=0.04$。

为了确定域转换递归滤波空间标准偏差 σ_s、范围标准偏差 σ_r、总迭代次数 N，使得分类效果达到最优，采用穷举法，限定域转换递归滤波 3 个参数的取值范围，分别为 $\sigma_s \in [10,14,\cdots,250]$，$\sigma_r \in [0.10,0.11,\cdots,0.20]$，$N \in [3,4,\cdots,10]$，同样采用印第安农林图像作为实验数据集，获取最优分类结果的参数值。随机抽取实验数据集的 8% 作为训练样本和实验数据集的 92% 作为测试样本进行验证，实验结果如图 7 所示，当 $\sigma_s=170$，$\sigma_r=0.18$，$N=6$ 时，得到的分类结果最优：整体分类精度为 94.94%，因此域转换递归滤波系数取 $\sigma_s=170$，$\sigma_r=0.18$，$N=6$。

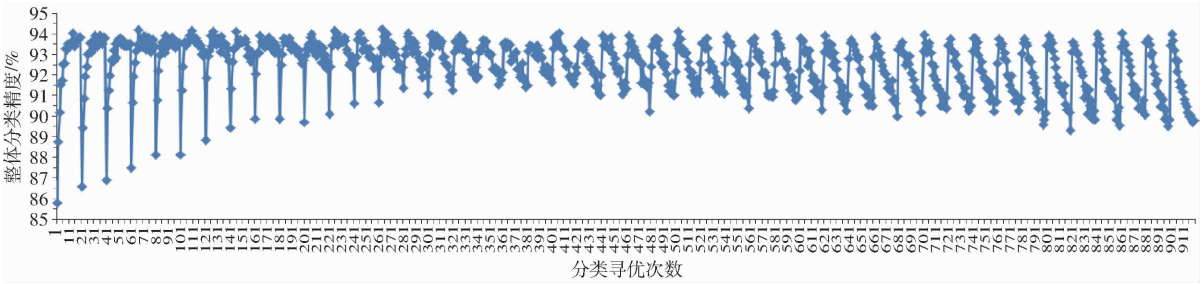

图 6　Beltrami 流滤波分类参数寻优

Fig. 6　Parameter optimization of Beltrami flow filtering for classification

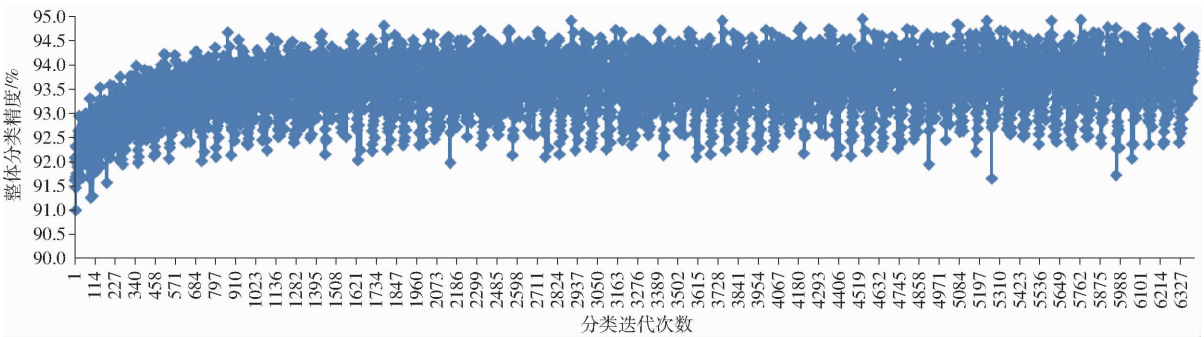

图 7　域转换递归滤波分类参数寻优

Fig. 7　Parameter optimization of domain transform recursive filtering for classification

3.2　实验验证

用 7 种方法分别对印第安林和帕维亚大学数据集进行分类对比验证，其中验证方法如下：①印第安农林数据集图像，地物分布如图 8a 所示，选取全部 16 个类别，每类随机选取 7% 的样本组成有标签训练集，其余 93% 作为测试集，地物数量较少的 3 类随机抽

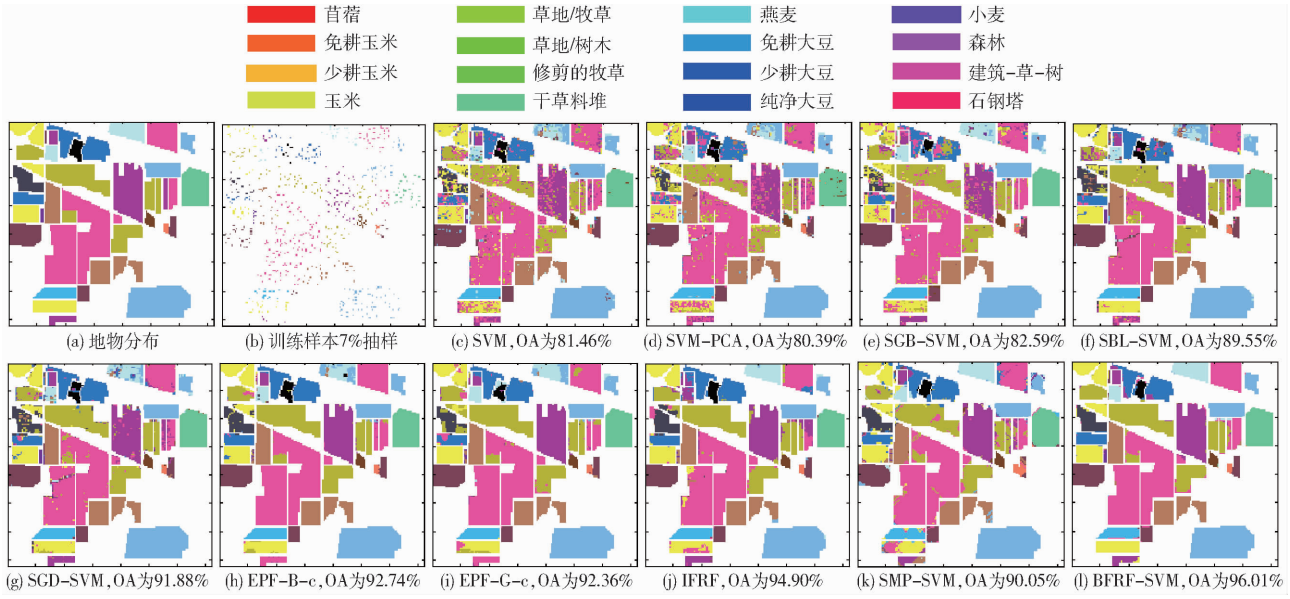

图 8　印第安农林数据集分类

Fig. 8　Classification for data set of Indian Pines

取 21% 作为训练集。表 1 为各种分类方法对印第安农林数据集的分类精度统计,分类效果如图 8 所示。

②帕维亚大学数据集图像,地物如图 9a 所示,选取全部 9 个类别,每类随机选取 3% 样本组成训练集,其余 97% 作为测试集,表 2 为各种分类方法对帕维亚大学数据集的分类精度统计,分类效果如图 9 所示。

表 1 印第安农林数据集图像分类数据统计

Tab. 1 Classification statistics for data set of Indian Pines

地物	样本			SVM	SVM-PCA	SGB-SVM	SBL-SVM	SGD-SVM	EPF-B-c	EPF-G-c	IFRF	SMP-SVM	BFRF-SVM
	总数	训练/%	测试/%										
苜蓿	54	21	79	78.95	68.00	93.55	80.97	90.27	94.59	94.05	96.53	82.59	92.65
免耕玉米	1434	7	93	72.32	73.31	78.51	86.21	90.04	92.16	92.64	94.20	88.32	94.10
少耕玉米	834	7	93	70.62	69.99	67.14	87.65	90.06	88.85	84.00	92.42	88.98	96.33
玉米	234	7	93	52.50	39.12	39.92	59.68	64.32	49.08	58.38	90.66	55.47	88.91
草地/牧草	497	7	93	89.30	89.43	88.50	92.43	93.53	95.26	95.48	96.36	92.76	95.20
草地/树木	747	7	93	96.18	95.83	96.19	96.63	97.47	99.90	99.94	97.56	97.04	98.71
修剪的牧草	26	21	79	70.53	72.07	70.70	71.75	85.13	71.98	80.89	85.39	86.11	89.09
干草料堆	489	7	93	96.03	97.00	99.58	98.58	96.22	100.0	99.78	99.56	97.44	98.65
燕麦	20	21	79	64.48	47.46	78.57	76.60	81.19	43.70	80.58	87.67	77.52	76.46
免耕大豆	968	7	93	70.06	64.71	63.61	83.86	87.79	86.02	81.64	95.19	84.20	92.80
少耕大豆	2468	7	93	84.53	84.92	87.96	92.12	94.37	97.79	98.19	97.16	92.88	97.82
纯净大豆	614	7	93	80.36	77.21	69.09	88.86	91.94	95.47	95.19	91.66	84.37	95.30
小麦	212	7	93	97.10	96.04	97.61	98.11	98.16	91.52	99.54	83.21	98.04	98.66
森林	1294	7	93	97.58	98.11	98.55	97.98	98.27	99.88	99.75	98.08	97.63	99.16
建筑-草-树	380	7	93	48.76	42.31	79.13	65.05	72.63	67.97	59.19	85.68	89.40	90.15
石钢塔	95	7	93	80.18	84.32	65.34	84.16	86.33	75.61	95.17	69.09	89.36	80.39
OA/%				81.46	80.39	82.57	89.55	91.88	92.74	92.36	94.90	90.73	96.01
AA/%				78.09	74.99	79.62	85.04	88.61	84.36	88.40	91.28	87.63	92.77
Kappa				78.74	77.48	79.93	88.05	90.73	91.68	91.23	94.18	89.41	95.44

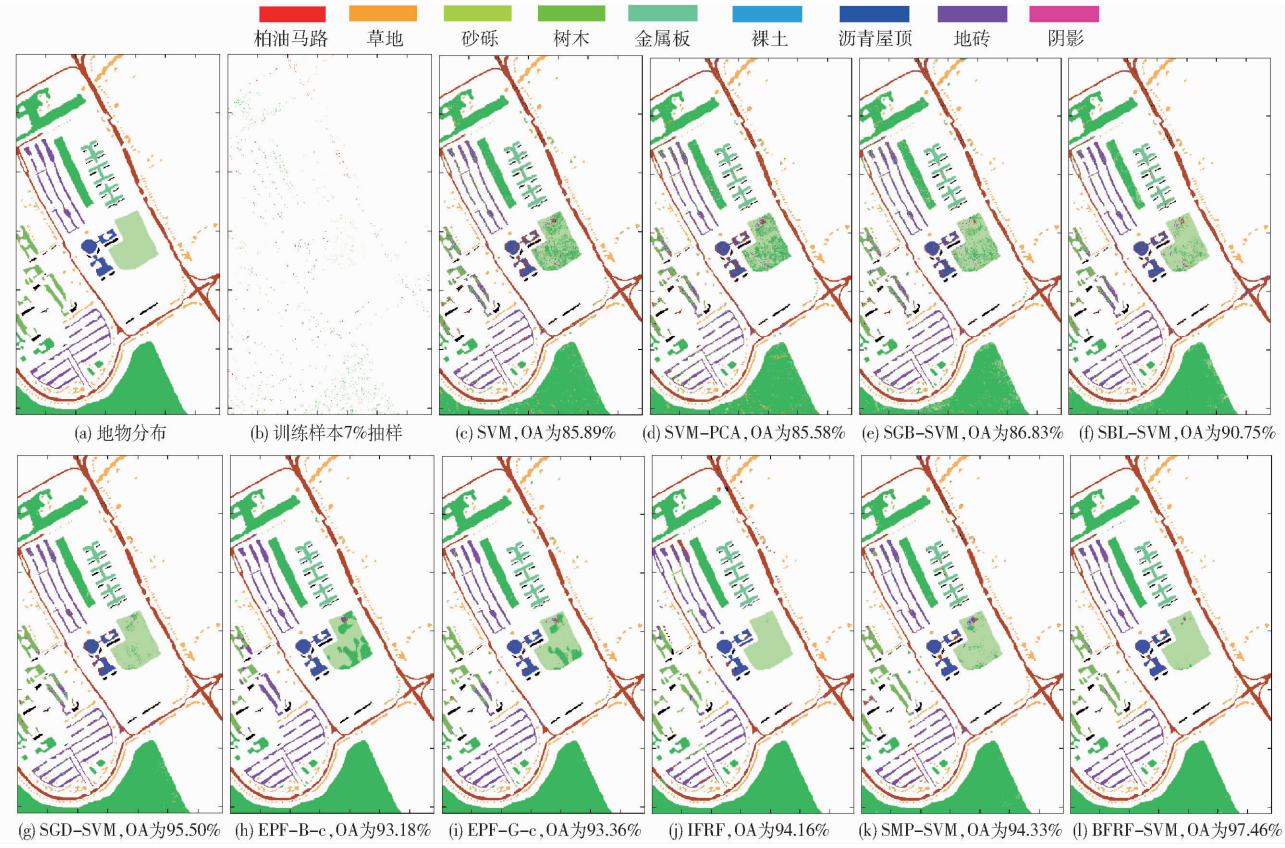

图 9 帕维亚大学数据集分类

Fig. 9 Classification for data set of Pavia University

表 2　帕维亚大学数据集图像分类数据统计

Tab. 2　Classification statistics for data set of Pavia University

地物	样本			SVM	SVM－PCA	SGB－SVM	SBL－SVM	SGD－SVM	EPF－B－c	EPF－G－c	IFRF	SMP－SVM	BFRF－SVM
	总数	训练/%	测试/%										
柏油马路	6641	3	97	88.68	88.70	88.45	90.11	96.24	97.82	98.17	90.39	92.25	97.36
草地	18649	3	97	95.96	95.84	95.79	97.86	98.73	100.00	99.92	99.52	98.82	99.75
砂砾	2099	3	97	59.20	58.95	65.01	64.55	80.99	69.71	74.28	86.28	81.84	87.64
树木	3064	3	97	88.18	87.37	90.48	94.88	96.99	94.81	93.74	88.96	97.26	97.77
金属板	1345	3	97	99.09	98.81	98.72	98.45	98.29	99.87	99.92	99.21	97.74	98.89
裸土	5029	3	97	58.52	60.97	62.30	83.42	92.34	65.94	67.54	99.84	91.27	98.19
沥青屋顶	1330	3	97	68.94	66.80	76.11	72.90	89.31	87.54	87.91	94.13	81.55	91.54
地砖	3682	3	97	81.12	77.21	79.48	82.30	91.10	98.80	96.65	80.41	89.61	91.83
阴影	947	3	97	88.79	85.73	92.60	85.95	92.51	94.50	94.24	65.44	86.50	98.39
OA/%				85.89	85.58	86.83	90.75	95.50	93.18	93.36	94.16	94.33	97.46
AA/%				80.94	80.04	83.22	85.60	92.94	89.89	90.26	89.35	90.76	95.71
Kappa				80.97	80.58	82.30	87.66	94.02	90.78	91.03	92.25	92.46	96.64

3.3　实验分析

(1)用 BFRF－SVM 对 2 种数据集进行分类,其中印第安农林数据集的 OA 为 96.01%,帕维亚大学数据集的 OA 为 97.46%,比 SVM 整体分类精度高出 12～15 个百分点,比 PCA－SVM 整体分类精度高出 12～16 个百分点,比 SGB－SVM、SBL－SVM、SGD－SVM 高出 2～12 个百分点,比 EPF 算法高出 4～5 个百分点,比 IFRF 算法高出 1～3 个百分点,比 SMP－SVM 算法高出 2～6 个百分点,充分验证了 BFRF－SVM 算法的有效性。

(2)印第安农林数据集的训练样本仅为 7%,分类精度 OA 超过 96%,可知 BFRF－SVM 对分布复杂的高光谱数据有较好的效果;帕维亚大学数据集分类训练样本仅为 3%,分类精度 OA 超过 97%,由图 8、9 可以看出,算法对数据集的分类效果提升明显,有效去除了椒盐现象。

(3)为验证监督数据对算法的影响,选择不同的训练样本测试算法的分类精度。由图 10a 可以看出,印第安农林总体分类精度在 4% 的训练样本比例时,OA 超过了 91%,10% 的训练样本时,OA 超过了 97%;由图 10b 可以看出,帕维亚大学总体分类精度 OA 在训练样本为 0.5% 时超过了 90%,在 4.5% 的训练样本时 OA 超过了 98%,验证了 BFRF－SVM算法在低训练样本的情况下也能得到较优的总体分类精度,且有一定的稳定性。

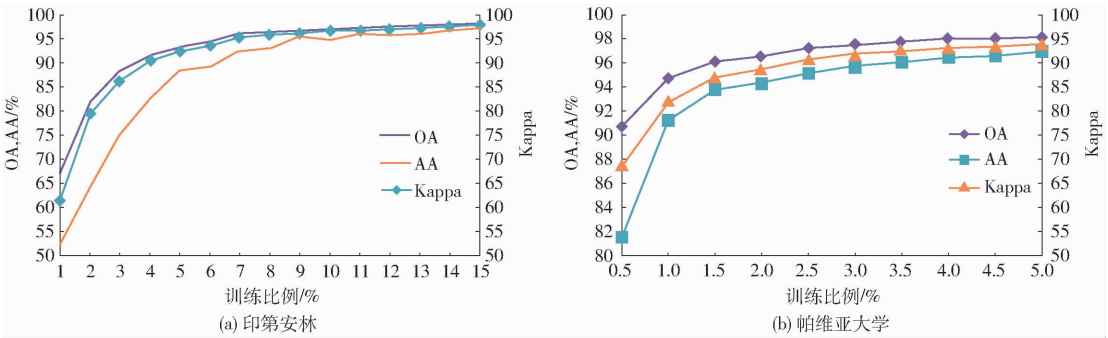

图 10　不同训练样本比例分类后 OA、AA 和 Kappa 折线图

Fig. 10　Curves of OA、AA and Kappa with different training samples for classification

4　结束语

提出了用 Beltrami 流滤波和域转换递归滤波结合的高光谱图像分类算法(BFRF－SVM),通过一系列实验,验证了 BFRF－SVM 算法优越性。实验结果表明,本文提出的 BFRF－SVM 算法与单纯光谱信息 SVM 算法、空谱结合分类算法、边缘保持分类算法、递归滤波分类算法、形态学滤波算法相比,OA、Kappa 和 AA 都有较大幅度提高,说明了用 Beltrami 流滤波和域转换递归滤波提取空间信息结合后,能有效提高高光谱图像的分类精度,该算法有以下特点:①用两种滤波器将高光谱图像光谱信息提取为空间信息并进行分类,有效利用了边缘结构信息和空间相关性信息。②Beltrami 流滤波提取高光谱图像的边缘结构信息,有效辅助 SVM 进行像元分类。③域转换递归滤波获得高光谱图像的空间相关信息,弥补 Beltrami 流滤波中的不足,结合后有效提高了高光谱图像的分类精度。

BFRF－SVM 算法为高光谱遥感提供了一种有效的分类方法,可以应用于农作物的精准分类与识别领域。

参 考 文 献

1 童庆禧, 张兵, 张立福. 中国高光谱遥感的前沿进展[J]. 遥感学报, 2016, 20(5): 689 - 707.
TONG Qingxi, ZHANG Bing, ZHANG Lifu. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689 - 707. (in Chinese)

2 王俊淑, 江南, 张国明, 等. 高光谱遥感图像 DE-self-training 半监督分类算法[J/OL]. 农业机械学报, 2015, 46(5): 239 - 244. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20150534&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2015.05.034.
WANG Junshu, JIANG Nan, ZHANG Guoming, et al. Semi-supervised classification algorithm for hyperspectral remote sensing image based on DE-self-training [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(5): 239 - 244. (in Chinese)

3 IMANI M, GHASSEMIAN H. Edge patch image-based morphological profiles for classification of multispectral and hyperspectral data[J]. IET Image Processing, 2017, 11(3): 164 - 172.

4 BAO R, XIA J, MURA M D, et al. Combining morphological attribute profiles via an ensemble method for hyperspectral image classification[J]. IEEE Geoscience & Remote Sensing Letters, 2017, 13(3): 359 - 363.

5 CHEN P, NELSON J D B, TOURNERET J Y. Toward a sparse bayesian markov random field approach to hyperspectral unmixing and classification[J]. IEEE Transactions on Image Processing, 2017, 26(1): 426 - 438.

6 CAO X, XU L, MENG D, et al. Integration of 3-dimensional discrete wavelet transform and Markov random field for hyperspectral image classification[J]. Neurocomputing, 2017, 226: 90 - 100.

7 ZHANG Z, PASOLLI E, CRAWFORD M M, et al. An active learning framework for hyperspectral image classification using hierarchical segmentation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(2): 640 - 654.

8 CUI B, MA X, XIE X, et al. Classification of visible and infrared hyperspectral images based on image segmentation and edge-preserving filtering[J]. Infrared Physics & Technology, 2017, 81: 79 - 88.

9 SHEN L, BAI L. Mutual Boost learning for selecting Gabor features for face recognition[J]. Pattern Recognition Letters, 2006, 27(15): 1758 - 1767.

10 HE L, LI J, PLAZA A, et al. Discriminative low-rank gabor filtering for spectral-spatial hyperspectral image classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 55(3): 1381 - 1395.

11 IMANI M, GHASSEMIAN H. GLCM, gabor, and morphology profiles fusion for hyperspectral image classification[C]// Iranian Conference on Electrical Engineering, 2016.

12 JIA S, HU J, XIE Y, et al. Gabor cube selection based multitask joint sparse representation for hyperspectral image classification [J]. IEEE Transactions on Geoscience & Remote Sensing, 2016, 54(6): 3174 - 3187.

13 冯逍, 肖鹏峰, 李琦, 等. 三维 Gabor 滤波器与支持向量机的高光谱遥感图像分类[J]. 光谱学与光谱分析, 2014, 34(8): 2218 - 2224.
FENG Xiao, XIAO Pengfeng, LI Qi, et al. Hyperspectral image classification based on 3-D Gabor filter and support vector machines[J]. Spectroscopy and Spectral Analysis, 2014, 34(8): 2218 - 2224. (in Chinese)

14 TOMASI C, MANDUCHI R. Bilateral filtering for gray and color images[C]// ICCV, 1998: 839 - 846.

15 WANG Y, SONG H, ZHANG Y. Spectral-spatial classification of hyperspectral images using joint bilateral filter and graph cut based model[J]. Remote Sensing, 2016, 8(9): 748.

16 KANG X, LI S, BENEDIKTSSON J A. Spectral-spatial hyperspectral image classification with edge-preserving filtering[J]. IEEE Transactions on Geoscience & Remote Sensing, 2014, 52(5): 2666 - 2677.

17 SHEN Y, XU J, LI H, et al. ELM-based spectral-spatial classification of hyperspectral images using bilateral filtering information on spectral band-subsets[C]// IGARSS 2016—2016 IEEE International Geoscience and Remote Sensing Symposium, 2016: 497 - 500.

18 GASTAL E S L, OLIVEIRA M M. Domain transform for edge-aware image and video processing[C]// ACM Transactions on Graphics (TOG), 2011, 30(4): 69: 1 - 69: 12.

19 KANG X, LI S, BENEDIKTSSON J A. Feature extraction of hyperspectral images with image fusion and recursive filtering[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(6): 3742 - 3752.

20 SOCHEN N, DERICHE R, PEREZ L L. The Beltrami flow over implicit manifolds[C]// IEEE International Conference on Computer Vision, 2003: 832.

21 SHI Y, LAI R, WANG D J, et al. Metric optimization for surface analysis in the Laplace-Beltrami embedding space[J]. IEEE Transactions on Medical Imaging, 2014, 33(7): 1447 - 1463.

22 FERNANDEZ J J, MARTINEZ J A. Three-dimensional feature-preserving noise reduction for real-time electron tomography[J]. Digital Signal Processing, 2010, 20(4): 1162 - 1172.

23 MISHRA K N. An efficient Laplace-Beltrami Spectra based technique for online iris image compression and identification[C]// 2016 International Conference on Control, Computing, Communication and Materials (ICCCCM), 2016: 1 - 6.

24 TAN M, QIU A. Spectral laplace-beltrami wavelets with applications in medical images[J]. IEEE Transactions on Medical Imaging, 2014, 34(5): 1005 - 1017.

25 MORAN P A P. The interpretation of statistical maps[J]. Journal of the Royal Statistical Society. Series B (Methodological), 1948, 10(2): 243 - 251.

26 MORAN P A P. Notes on continuous stochastic phenomena[J]. Biometrika, 1950, 37(1/2): 17 - 23.

27 MELGANI F, BRUZZONE L. Classification of hyperspectral remote sensing images with support vector machines[J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(8): 1778 - 1790.

28 CAI S, DU Q, MOORHEAD R, et al. Noise-adjusted principal component analysis for hyperspectral remotely sensed imagery visualization[C]// 16th IEEE Visualization Conference (Vis2005), 2005: 119 - 120.

29 FAUVEL M, BENEDIKTSSON J A, CHANUSSOT J, et al. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles[J]. IEEE Transactions on Geoscience & Remote Sensing, 2008, 46(11): 3804 - 3814.