

基于自适应流形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轨道交通学院, 广东 广州 510650;

² 哈尔滨工程大学信息与通信工程学院, 黑龙江 哈尔滨 150001;

³ 青岛理工大学通信与电子工程学院, 山东 青岛 266520

摘要 滤波器在提取高光谱图像空间纹理信息时往往容易陷入局部的特征提取。针对这一问题, 提出一种自适应流形滤波的高光谱图像分类算法(AMF-SVM)。该方法采用自适应寻优, 先计算第一个流形, 然后根据流形树高度进行递归投射、平滑和聚合处理, 结合处理结果对高光谱进行线性滤波, 得到较好的空间特征, 并由支持向量机(SVM)完成分类, 最后获得最优的分类结果。实验表明, 相比使用光谱信息、高光谱降维、空谱信息结合的SVM分类方法, 边缘保持滤波以及递归滤波的方法, AMF-SVM对高光谱图像的分类精度有较大提高, 充分说明了该方法的有效性。

关键词 图像处理; 高光谱图像; 自适应流形滤波; 空间纹理信息; 全局寻优; 分类

中图分类号 TP753

文献标识码 A

doi: 10.3788/LOP55.041010

Hyperspectral Image Classification Method Based on Adaptive Manifold Filtering

Liao Jianshang¹, Wang Liguo², Hao Siyuan³

¹ School of Rail Transit, Guangdong Communication Polytechnic, Guangzhou, Guangdong 510650, China;

² College of Information and Communication Engineering, Harbin Engineering University,
Harbin, Heilongjiang 150001, China;

³ School of Communication and Electronic Engineering, Qingdao University of Technology,
Qingdao, Shandong 266520, China

Abstract Spatial texture information extraction of hyperspectral image by filter often falls into local texture extraction. According to the problem, an algorithm of hyperspectral image classification based on adaptive manifold filtering (AMF-SVM) is proposed. This method uses adaptive optimization. The first manifold is calculated. Then, hyperspectral image with manifold is recursively splatted, blurred, and sliced according to the height of the manifold tree. Combined with the handling results, hyperspectral image is applied to the linear filtering, the results are classified by support vector machine (SVM), and then the optimal classification is obtained. Experimental results show that the AMF-SVM algorithm is better than original SVM classification methods using the spectrum information, dimensionality reduction, and the spatial-spectral information, and the methods of edge-preserving filtering and recursive filtering. Performance of the classification for hyperspectral image with AMF-SVM is greatly improved, and effectiveness of this method is fully verified.

Key words image processing; hyperspectral image; adaptive manifold filtering; spatial texture information; global optimization; classification

OCIS codes 100.4145; 110.4234; 300.6170; 280.0280; 100.5010

收稿日期: 2017-09-15; 收到修改稿日期: 2017-10-29

基金项目: 国家自然科学基金(61275010, 61675051)、广东省科技计划项目(2017ZC0358)、广州市科技计划项目(201804010262)、广东交通职业技术学院重点科研项目(2017-1-001)

作者简介: 廖建尚(1982—), 男, 硕士, 副教授, 系统分析师, 主要从事高光谱图像处理、模式识别、嵌入式系统方面的研究。

E-mail: liaojianshang@126.com

1 引言

高光谱图像的分辨率高,但是光谱信息的相关性强,冗余度高,如何提升像元分类精度(OA)一直是一个研究难题^[1-3]。近年来,越来越多的学者通过提取空间特征改善高光谱图像的分类性能,空间特征的提取方法主要有马尔科夫随机场空间特征提取方法^[4-5]、形态滤波空间特征提取方法^[6-7]和图像分割的空间特征提取方法^[8-9],其中利用滤波器提取高光谱图像的纹理信息并对其进行有效分类成为一个研究热点。例如,Shen 等^[10]利用 Gabor 滤波器提取空间纹理信息来辅助进行高光谱分类;He 等^[11]通过识别低阶 Gabor 滤波提取高光谱图像的空间特征,提出了DLRGF(discriminative low-rank Gabor filtering)的高光谱图像分类方法;Wang 等^[12]采用了 Gabor 滤波提取空间特征后,提出一种空谱标签传播的 SS-LPSVM (spatial-spectral label propagation based on the SVM)半监督分类算法;Jia 等^[13]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 GS-MTJSRC(Gabor cube selection based multitask joint sparse representation approach)空谱结合分类方法;叶珍等^[14]利用嵌入主成分分析(PCA)的 Gabor 变换对高光谱图像进行特征提取,并用局部 Fisher 判别分析和局部保护非负矩阵分离方法对空间特征进行降维,提出了两种高光谱图像分类算法。Gabor 滤波器的特征提取方法适合纹理特征的表达和分离,但是容易陷入提取图像的局部空间纹理信息。也有部分学者用双边滤波器来提取高光谱空间纹理信息^[15],如廖建尚等^[16]用双边滤波器提取经 PCA 降维后的空间纹理信息,设计一种高光谱像元邻域信息来构建空间相关信息,将其融合后交由支持向量机(SVM)实现分类,并提出了 BS-SVM(bilateral filtering and spatial correlation information based on the SVM)算法;Wang 等^[17]提出了 CS-GC(class-specific graph-cut)分类算法,先用 SVM 分类获取初始分类结果,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 OA;廖建尚等^[18]利用双边滤波和域转换标准卷积滤波分别提取高光谱图像的空间信息,经过自适应寻优得到分类结果,提出了DTBS-SVM(domain transform filtering and bilateral filtering with SVM)高光谱图像分类算法;Kang 等^[19]先用 SVM 获得初步的分类结果,再用双边滤波进行优化,提出了 EPF(edge-preserving filtering)边缘保持的高光谱图像分类方法。还有一些学者用递归滤波提取空间纹理信息^[20],如 Kang 等^[21]先将高光谱数据划分

为多个集合,对每个集合进行融合后再分别用递归滤波提取空间信息,提出 IFRF(image fusion and recursive filter)高光谱图像分类方法,获得较好的分类结果。双边滤波和递归滤波虽然有一定的空间特征边缘保持特性,但是容易丢失高光谱图像的空间相关信息。此外,个别学者对自适应流形滤波进行了应用研究^[22],Nasab 等^[23]采用自适应流形滤波实现了一种图像边界的测量方法;朱书进等^[24]采用自适应流形滤波实现了高效局部立方匹配方法;周冠霖等^[25]用自适应流形滤波实现边缘感知编辑处理;Xie 等^[26]采用自适应流形滤波对高光谱图像进行滤波,并用极限学习机方法进行分类,但该方法没有对流行树高度进行分类寻优,不能更好地适应不同的高光谱图像分类。

将高光谱图像空间纹理信息提取用于分类的研究,取得了一定成效,但是也存在一些不足:1) 滤波器往往通过窗函数提取高光谱图像特征,局限于提取图像的局部空间纹理信息;2) 高光谱图像的地物分布往往具有统一性和连续性,滤波器在提取空间纹理信息时容易去除像元间的空间相关性;3) 在高光谱图像的分类研究中,流形滤波没有对流行树高度进行寻优。为了提高高光谱图像的分类性能,本文利用自适应流形滤波具有较好的边缘保持特性和全局性优化特性,提出了一种自适应流形滤波的高光谱图像分类算法(AMF-SVM)。实验结果表明:用自适应流形滤波提取的空间信息能有效辅助 SVM 分类,分类性能有较大提升。

2 方法

2.1 自适应流形滤波

2.1.1 流形滤波

高光谱图像的线性滤波可表示为

$$F_i = I_i + G_i, \quad (1)$$

式中 I_i 为高光谱第 i 波段的图像辐射强度, G_i 为对第 i 波段图像进行滤波的响应, F_i 为对图像进行线性滤波的结果。

自适应流形滤波是由 Gastal 等^[22]提出的一种高维滤波算法,其对高光谱的滤波过程分为 3 步,即投射、平滑和聚合,具体过程如下:

1) 投射处理。用抛雪球算法将图像中的像素投射到当前流形上,对每个流形进行高斯距离加权, η_{ki} 为高光谱图像的采样像元矩阵, f_i 为高光谱图像的像元矩阵, $\phi_{\frac{R}{2}}$ 为高斯核函数, Σ 为 $R/2$ 中控制高斯核衰变的对角协方差矩阵, $G_w(\eta_{ki})$ 的计算充分利用了像元本身的全局扩散性和空间相关保持特性。

用抛雪球算法将图像中的像素投射到当前流形上,对每个流形进行高斯距离加权,可得

$$\Psi_{\text{splat}}(\boldsymbol{\eta}_{ki}) = \phi_{\frac{R}{2}}(\boldsymbol{\eta}_{ki} - \mathbf{f}_i) \mathbf{f}_i. \quad (2)$$

2) 平滑处理。对(2)式的结果进行平滑滤波,采用域转换递归滤波^[20]方法对 $\Psi_{\text{splat}}(\boldsymbol{\eta}_{ki})$ 进行滤波,得到平滑滤波函数 $\Psi_{\text{blur}}(\boldsymbol{\eta}_{ki})$,即

$$\Psi_{\text{blur}}(\boldsymbol{\eta}_{ki}) = DT(\Psi_{\text{splat}}), \quad (3)$$

式中 DT 代表转换递归滤波。通过平滑处理可获取高光谱图像较好的边缘特性。

3) 聚合处理。通过 $\Psi_{\text{blur}}(\boldsymbol{\eta}_{ki})$ 加权求得每个像元的滤波响应 G_i ,即

$$G_i = \frac{\sum_{k=1}^K w_{ki} \Psi_{\text{blur}}(\boldsymbol{\eta}_{ki})}{\sum_{k=1}^K w_{ki} \Psi_{\text{blur}}^0(\boldsymbol{\eta}_{ki})}, \quad (4)$$

式中 K 为流形节点数; w_{ki} 为高斯距离权重; $\Psi_{\text{blur}}^0(\boldsymbol{\eta}_{ki})$ 为投射处理的模糊版本,可表示为

$$\Psi_{\text{blur}}^0(\boldsymbol{\eta}_{ki}) = \phi_{\frac{R}{2}}(\boldsymbol{\eta}_{ki} - \mathbf{f}_i). \quad (5)$$

将(4)式代入(1)式可获得线性滤波结果,即

$$F_i = I_i + \frac{\sum_{k=1}^K w_{ki} \Psi_{\text{blur}}(\boldsymbol{\eta}_{ki})}{\sum_{k=1}^K w_{ki} \Psi_{\text{blur}}^0(\boldsymbol{\eta}_{ki})}. \quad (6)$$

高光谱自适应流形滤波算法是投射、平滑和聚合处理的递归过程,其中递归过程和流形高度有关。

2.1.2 高光谱流形计算

流形滤波的递归过程和流形高度有关,流形树高度决定递归的层次和流形树节点的数量,在很大程度上影响滤波效果,其中流形计算的递归过程分 6 个步骤,具体方法为:

1) 计算流形节点数 K 和流形树高度 H ,二者的计算式分别为

$$K = 2^H - 1, \quad (7)$$

$$H = n + \max(2, \lceil H_s * L_r \rceil), \quad (8)$$

式中 $\lceil \cdot \rceil$ 是向上取整符号, $n \in 1, 2, \dots, N$, L_r 为距离标准差计算的线性校正, H_s 为滤波器的空间标准差计算高度。 H_s 和 L_r 的计算式为

$$H_s = \lfloor \log_2 \sigma_s \rfloor - 1, \quad (9)$$

$$L_r = 1 - \sigma_r, \quad (10)$$

式中 σ_s 为空间偏差系数, σ_r 为范围偏差系数。先利用(9)、(10)式求得 H_s 和 L_r ,再通过(8)式获得流形树高度 H 。

2) 计算第一个流形,通过低通滤波获得第一个流形 $\eta_1(p_i)$:

$$\eta_1(p_i) = (h_s * f) p_i, \quad (11)$$

式中 h_s 为低通滤波函数; Σ_s 代表协方差矩阵,用于控制高斯核的衰变; p_i 为其中的高光谱图像的一个像元; f 为高光谱的采样像元。

3) 求出 $(f_1 - \eta_1)(f_1 - \eta_1)^T$ 的最大特征值对应的特征向量 v_1 。

4) 将像元分为两类,点积 d_{ot} 的计算式为

$$d_{ot} = v_1^T (f_i - \eta_{1i}), \quad (12)$$

再根据

$$\begin{cases} p_i \in C_- & \text{if } d_{ot} < 0 \\ p_i \in C_+ & \text{else} \end{cases} \quad (13)$$

将高光谱像元分为两种聚类 C_- 和 C_+ 。

5) 计算新流形。通过低通滤波器计算流形 $\eta_-(p_i)$,同理,根据

$$\eta_-(p_i) = \sum_{p_j \in C_-} [W_-(p_j) f_j] / \sum_{p_j \in C_-} W_-(p_j), \quad (14)$$

$$W_-(p_j) = \theta(\eta_{1j} - f_j) h_s(p_i - p_j), \quad (15)$$

$$\theta(\eta_{1j} - f_j) = 1 - G_{w_{1j}}, \quad (16)$$

计算 $\eta_-(p_i)$ 和 $\eta_+(p_i)$,并递归计算流形 $\eta_{+-}(p_i)$, $\eta_{++}(p_i)$ 和 $\eta_{--}(p_i)$ 。

6) 递归计算下一个流形,并进行新的流形高维滤波,直到达到流形树高度后结束。

流形滤波具有较好的全局扩散性以及边缘保持性,越往下层,产生的流形越能适应其所在的局部区域,因此流形滤波具有较好的局部优化能力。用流形滤波对印第安农林数据集的第 10,80,120,180 个波段进行滤波,流形树高度分别选择 3 和 6,如图 1 所示,从左到右依次对应印第安农林数据集的第 10,80,120,180 个波段。从滤波结果看,高维自适应流形滤波能提取较好的空间特征,从流形树高度 3 和 6 的滤波对比来看,高度为 6 比高度为 3 的滤波效果更好,在局部和全局寻优中能获取较为清晰的纹理信息,并能获取较优的全局空间特征,表明流形树高度越高,流形越多,局部和全局的优化能力越强。

为了确定空间偏差系数 σ_s 和范围偏差系数 σ_r ,先评估不同流形以及滤波对分类的影响,采用交叉验证法,选择印第安农林高光谱图像作为实验数据,并选择 5% 的训练样本和 95% 的测试样本进行验证。为了简单起见,将数据集作 PCA 降维^[27],选取前 20 个主成分进行流形滤波处理,先取 $\sigma_r = 0.8$ 和 $\sigma_s = 1 \sim 50$ 分别验证 OA,分类效果如图 2(a)所示,当 $\sigma_s = 3$ 时,整体 OA、Kappa 系数的综合分类性能

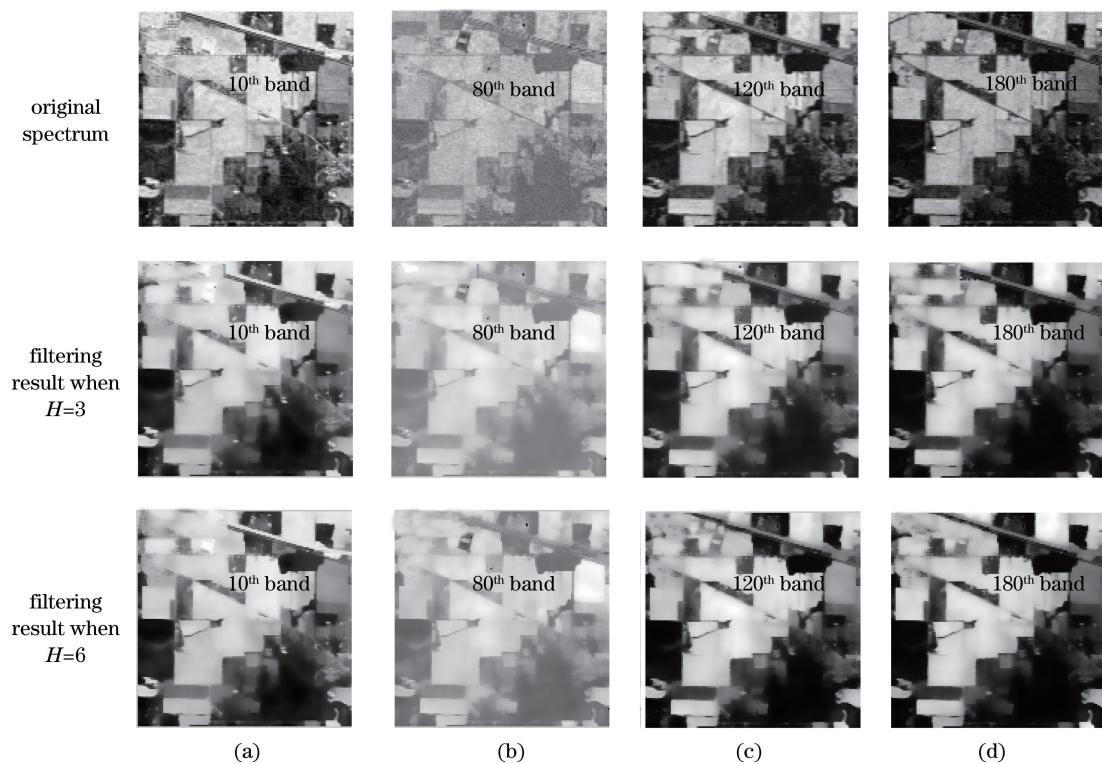


图1 印第安农林数据集的原始光谱和滤波结果。(a)第10个波段;(b)第80个波段;(c)第120个波段;(d)第180个波段

Fig. 1 Original spectrum and filtering results of Indian Pines data sets. (a) 10th band;
(b) 80th band; (c) 120th band; (d) 180th band

较好;其次取 $\sigma_s = 3$ 和 $\sigma_r = 0.1 \sim 5$ 分别验证 OA, 分类效果如图2(b)所示,可以看出当 $\sigma_r = 0.7$ 时,分类

性能最好,综合分类性能较优,因此自适应流形滤波参数分别取 $\sigma_s = 3$ 和 $\sigma_r = 0.7$ 。

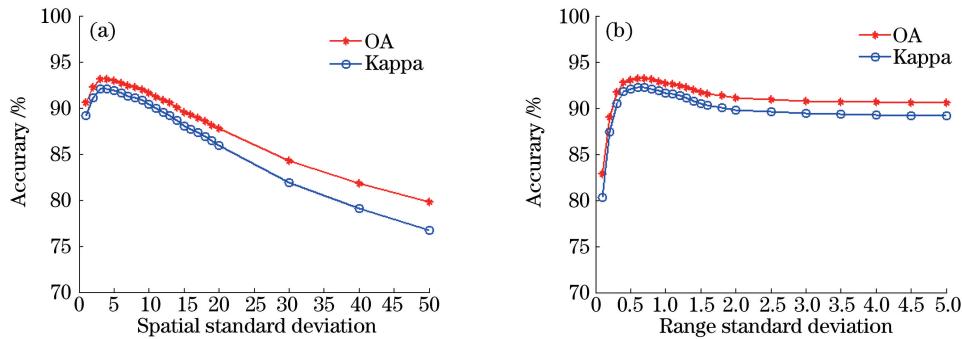


图2 印第安农林数据集的流形滤波系数寻优。(a)空间偏差系数 σ_s ; (b)范围偏差系数 σ_r

Fig. 2 Optimization for manifold filtering coefficient of Indian Pines data sets.
(a) Spatial deviation coefficient σ_s ; (b) range deviation coefficient σ_r

2.2 自适应流形滤波的高光谱分类方法

流形滤波中的流形树高度决定了流形的数量,也决定了递归投射、平滑和聚合的次数,从而影响滤波的效果,因此合适的流形树高度对滤波结果起着重要的作用,通过调整(9)式中的 n 值重新获取流形树高度,然后进行流形滤波得到高光谱图像空间特征,再将空间信息交给 SVM 实现分类,最终获取最优的分类结果,形成了一种自适应流形滤波的

AMF-SVM,其实现过程为:

1) 归一化处理。高光谱中像元的反射强度数值较大,先按照

$$R = \frac{R - V_{\min}}{V_{\max} - V_{\min}}, \quad (17)$$

对波段数为 l 的高光谱数据集进行归一化处理,其中 V_{\min} 为最小值, V_{\max} 为最大值,得到信息量重新分布的高光谱图像数据集 R 。

2) 计算树高度。设定 N , 输入(调整) n , 用(8)式计算高光谱数据集 R 的流形树高度 H 。

3) 计算第一个流形。用低通滤波器 h_s^{Σ} 计算高光谱数据集 R 的第一个流形:

$$\begin{aligned} out[:, n, l] &= R[:, n, l] + \exp(-\sqrt{2}/\sigma_s) \\ & (R[:, n-1, l] - R[:, n, l]), \quad (18) \end{aligned}$$

式中 $R[:, n, l]$ 为某波段中的 n 像元, $out[:, n, l]$ 为低通滤波输出结果。

4) 自适应流形滤波。①投射处理, 用(2)式对流形进行高斯距离加权, 得到 $\Psi_{\text{splat}}(\eta_{ki})$; ②平滑处理, 用(4)式对 $\Psi_{\text{splat}}(\eta_{ki})$ 进行滤波得到 $\Psi_{\text{blur}}(\eta_{ki})$;

- ③聚合处理, 用(5)式计算每个像元的滤波响应 G_i ;
- ④自适应流形递归滤波, 根据递归执行步骤 4), 直到结束, 输出递归结果 G_i 。

5) 线性滤波。利用(7)式获得高光谱图像的滤波结果 F 。

6) SVM 分类。

7) 调整 n 值, 重复步骤 2)~6), 直至 $n=N$, 并进行寻优。

8) 输出最优的分类结果和 n 值。

详细的自适应流形滤波的 AMF-SVM 流程如图 3 所示。

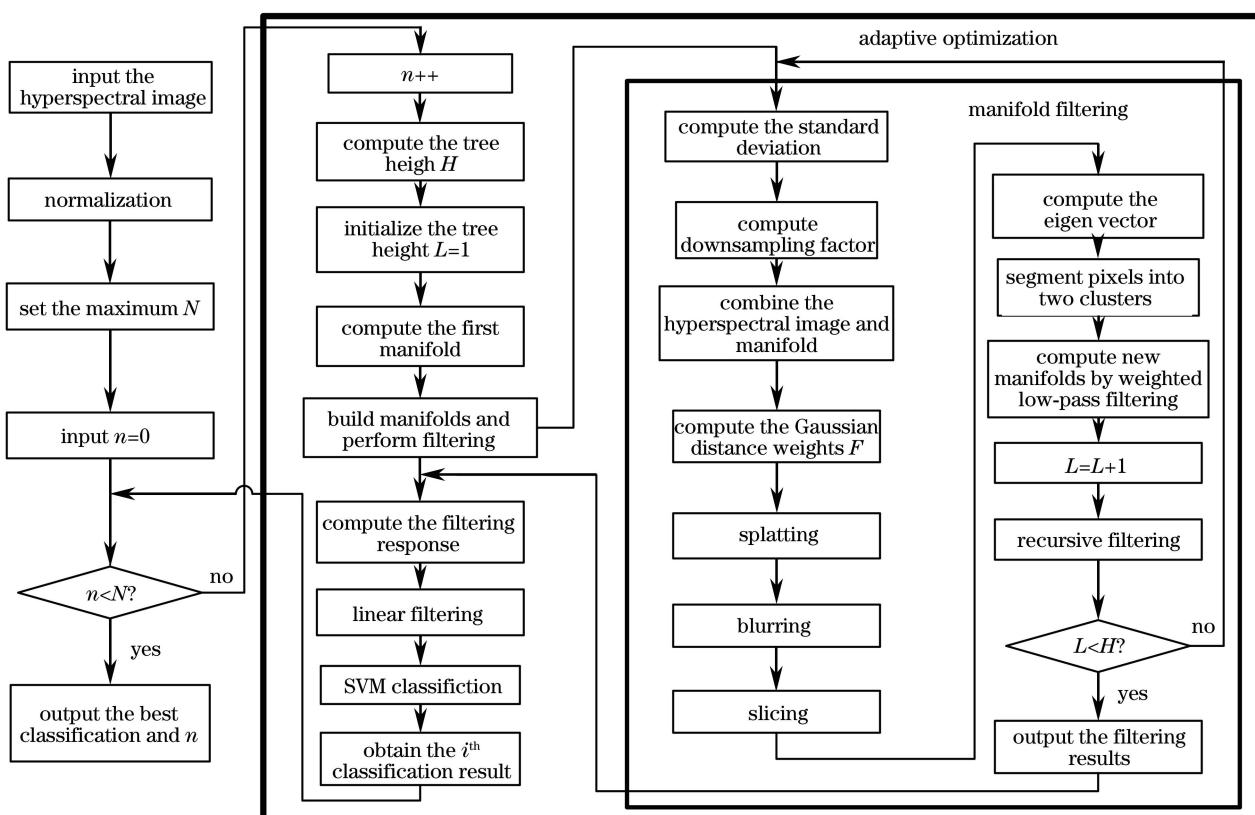


图 3 AMF-SVM 流程

Fig. 3 Flow of AMF-SVM

3 实验数据集

为了验证所提算法的有效性, 采用印第安农林和帕维亚大学 2 个高光谱数据集进行验证^[17], 其特征如下: 1) 印第安农林数据集来自机载可见光红外成像光谱仪, 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, 由于存在噪声, 除去其中的 20 个波段, 剩余 200 个波段, 包含 16 种地物; 2) 帕维亚大学数据集来自机载可见

光红外成像光谱仪, 是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, 同理除去其中的 12 个波段, 剩余 103 个波段, 包含 9 种地物。

4 实验与评价指标

为了验证所提算法在高光谱分类方面的优越性, 将 6 种方法进行比较。方法 1: 利用文献[28]提出的 SVM 进行分类; 方法 2: 利用 PCA 对高光谱数据进行降维后, 用 SVM 进行分类; 方法 3: 先用高光

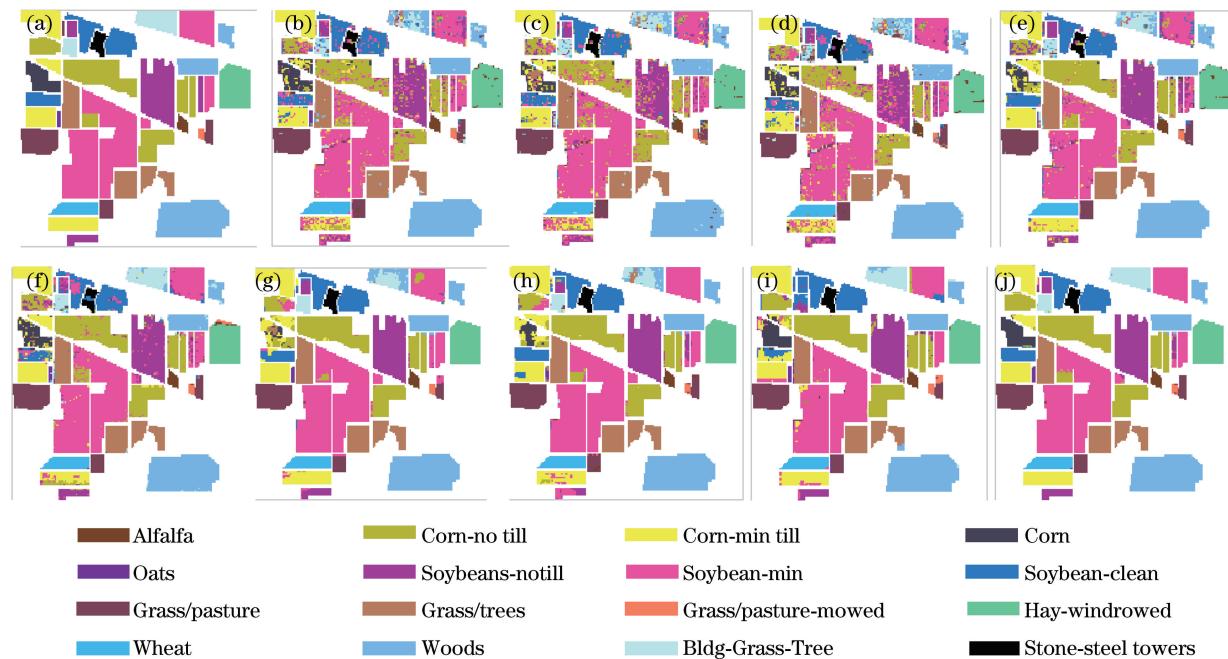


图 4 印第安农林数据集分类情况。(a)真实图像;(b) SVM, OA 为 80.93%;(c) SVM-PCA, OA 为 80.46%;(d) GBF-SVM, OA 为 82.82%;(e) BF-SVM, OA 为 88.99%;(f) GDF-SVM, OA 为 91.08%;(g) EPF-B-g, OA 为 92.99%;(h) EPF-G-g, OA 为 92.83%;(i) IFRF, OA 为 93.64%;(j) AMF-SVM, OA 为 95.16%

Fig. 4 Classification of Indian Pines data sets. (a) Ground truth; (b) SVM, OA is 80.93%; (c) SVM-PCA, OA is 80.46%; (d) GBF-SVM, OA is 82.82%; (e) BF-SVM, OA is 88.99%; (f) GDF-SVM, OA is 91.08%; (g) EPF-B-g, OA is 92.99%; (h) EPF-G-g, OA is 92.83%; (i) IFRF, OA is 93.64%; (j) AMF-SVM, OA is 95.16%

表 2 帕维亚大学数据集图像分类数据统计

Table 2 Classification statistics of Pavia University data sets

Ground truth	Sum	Train /%	Test /%	SVM /%	SVM-PCA /%	GBF-SVM /%	BF-SVM /%	GDF-SVM /%	EPF-B-g /%	EPF-G-g /%	IFRF /%	AMF-SVM /%
Asphalt	6641	2	98	87.84	86.19	88.74	88.23	94.98	98.07	97.49	97.70	98.68
Meadows	18649	2	98	95.81	95.99	96.13	97.03	98.32	99.98	99.91	99.34	99.79
Gravel	2099	2	98	57.87	48.76	54.51	65.01	76.07	72.60	69.39	86.68	90.63
Trees	3064	2	98	88.17	85.01	89.21	91.98	96.19	91.84	92.26	92.78	96.56
Metal sheets	1345	2	98	98.34	98.72	98.84	97.54	98.38	99.85	99.94	99.02	99.40
Soil	5029	2	98	54.33	54.96	56.21	77.91	88.34	60.74	60.32	99.86	97.59
Bitumen	1330	2	98	64.64	64.79	65.89	70.50	82.89	81.27	86.38	96.37	95.12
Bricks	3682	2	98	78.97	79.41	77.88	80.18	91.43	98.47	95.95	73.13	97.05
Shadows	947	2	98	89.33	84.29	90.64	87.82	93.37	95.13	93.20	83.10	94.49
OA /%	—	—	—	84.80	83.96	85.20	89.03	94.20	92.32	91.92	95.31	98.17
Kappa	—	—	—	79.47	78.31	80.00	85.34	92.29	89.57	89.04	93.67	97.57

4.2 实验分析

1) AMF-SVM 对两类数据集的分类结果如图 4、5 所示,表 1 和表 2 分别列出每种方法对数据集的分类结果,其中印第安农林数据集的 OA 为 96.16%,Kappa 系数为 95.62;帕维亚大学数据集的 OA 为 98.17%,Kappa 系数为 97.57。对比表中数据可知,AMF-SVM 对两类数据集的分类结果比

SVM 方法高 13%~15%,比 PCA-SVM 方法高 13%~14%,比 GBF-SVM、BF-SVM、GDF-SVM 方法高 3%~12%,比 EPF 方法高 3%~5%,比 IFRF 方法高 2%~3%,充分验证了 AMF-SVM 对高光谱图像分类的有效性。

2) 印第安农林数据集的分类训练样本比例仅为 7%,但 AMF-SVM 得到的 OA 超过 96%,能有

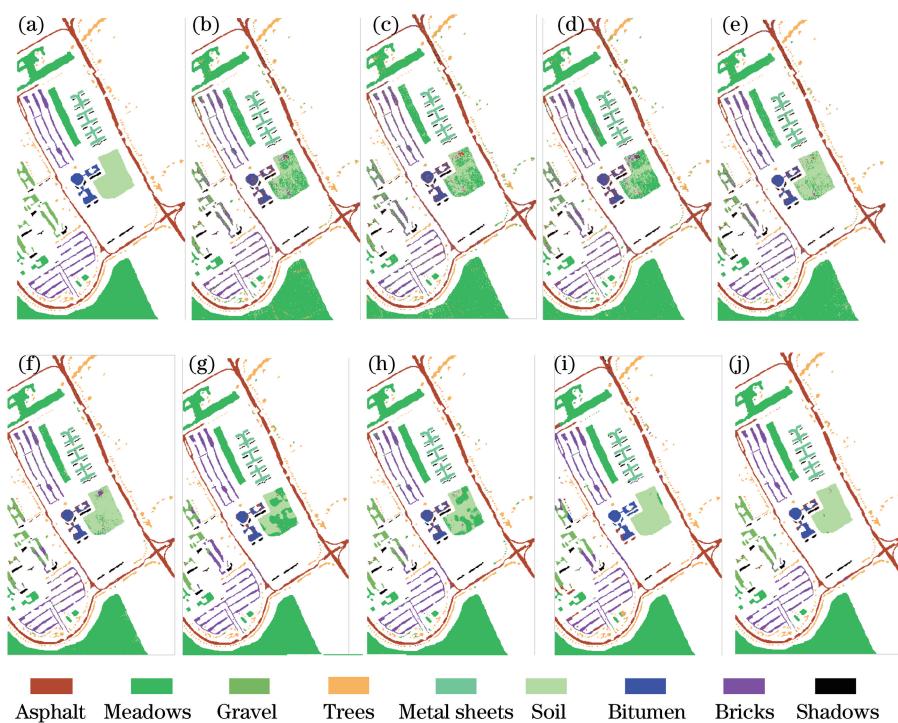


图 5 帕威亚大学数据集分类情况。(a)真实图像;(b) SVM, OA 为 84.80%;(c) SVM-PCA, OA 为 83.95%;(d) GBF-SVM, OA 为 85.20%;(e) BF-SVM, OA 为 89.03%;(f) GDF-SVM, OA 为 94.20%;(g) EPF-B-g, OA 为 91.29%;(h) EPF-G-g, OA 为 91.68%;(i) IFRF, OA 为 95.31%;(j) AMF-SVM, OA 为 97.92%

Fig. 5 Classification for Pavia University. (a) Ground truth; (b) SVM, OA is 84.80%; (c) SVM-PCA, OA is 83.95%; (d) GBF-SVM, OA is 85.20%; (e) BF-SVM, OA is 89.03%; (f) GDF-SVM, OA is 94.20%; (g) EPF-B-g, OA is 91.29%; (h) EPF-G-g, OA is 91.68%; (i) IFRF, OA is 95.31%; (j) AMF-SVM, OA is 97.92%

效去除分布复杂的高光谱图像分类产生的椒盐现象;帕维亚大学图像分类训练样本比例只有 2%, AMF-SVM 同样可以得到较好的分类性能,从图 4 和图 5 可以看出,所提算法对数据集的分类效果提升明显,AMF-SVM 可以有效消除椒盐现象。

3) 为了验证不同监督数据的分类性能,选择逐渐增加训练样本的方法来测试算法分类的稳定

性,如图 6 所示,印第安农林在训练样本比例为 3% 时的 OA 超过了 90%,训练样本比例为 10% 时 OA 达到了 97.19%;帕维亚大学在训练样本比例为 0.1% 时的 OA 接近 70%,训练样本比例为 0.3% 时的 OA 超过了 90%,训练样本比例为 1% 时的 OA 达到了 97.28%,充分说明 AMF-SVM 有较好的稳定性。

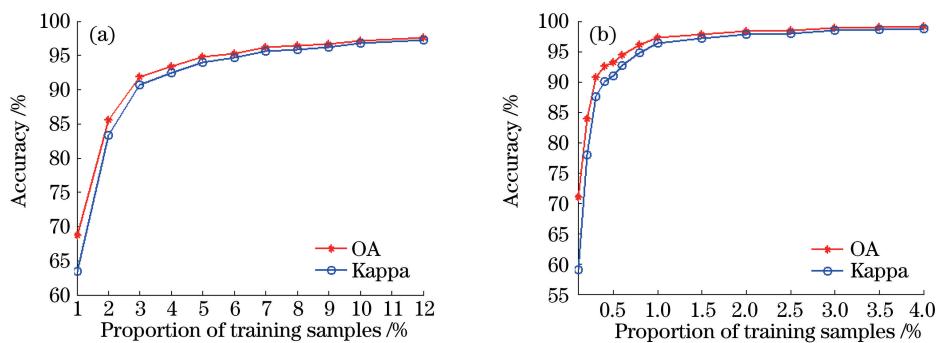


图 6 不同训练样本比例分类后 OA 和 Kappa 系数折线图。(a)印第安农林;(b)帕维亚大学

Fig. 6 Charts of OA and Kappa coefficient with different training samples. (a) Indian Pines; (b) Pavia University

4) AMF-SVM 在少量监督样本的情况下也有一定的优势,印第安农林和帕维亚大学数据集分别

选择 1% 和 0.1% 的监督样本,并用 6 种算法进行分类测试,测试结果如图 7 所示,印第安农林的 OA 为

66.89%，比其他算法高出2%~17%，帕维亚大学的OA接近70%，比其他算法高出5%~10%，说明

AMF-SVM算法相比其他算法在少量监督样本的情况下有一定优势。

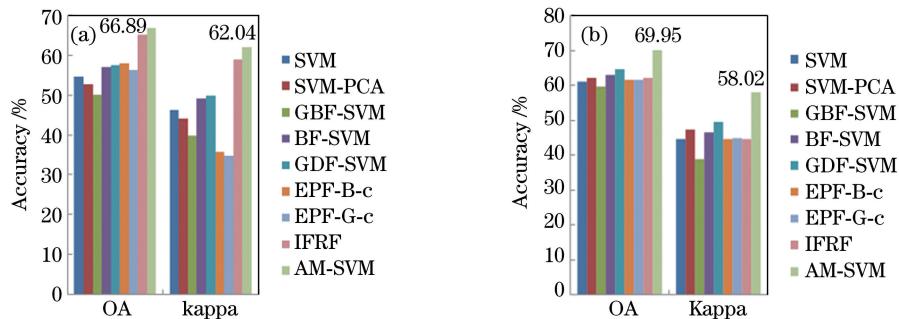


图7 分类算法的OA和Kappa系数。(a)印第安农林1%的训练样本;(b)帕维亚大学0.1%的训练样本

Fig. 7 OA and Kappa coefficient for different classification methods. (a) 1% training sample for Indian Pins; (b) 0.1% training sample for Pavia University

5)高光谱图像分类的实验验证数据如表3所示,为了验证流形树高度对分类的重要性,通过OA和Kappa系数的折线图进一步展示其分类结果,如图8所示。从表3和图8可知,印第安农林和帕维亚大学的最优分类结果OA分别为96.16%和98.14%,流形树高度分别为9和8,其流形数量分别为511和255。最差的分类结果的流形树高度为2,流形数量为3,最好的分类结果的流形树高度和流

形数量比最差的分类结果分别高出0.55%和0.36%,充分说明了流形滤波的流形数量多,提取高光谱图像空间特征的效果较好,也有较好的全局性,对保持空间相关性有较好的作用,能明显提升OA。然而,过多的流形树节点会增加算法复杂度,因此选取适当大小的流形树是获取良好滤波效果和更高效率的关键,这里限制流形树的高度上限为10,流形树节点数为1023。

表3 自适应流形滤波的高光谱分类数据统计

Table 3 Hyperspectral classification data statistics of adaptive manifold filtering

	<i>n</i>	0	1	2	3	4	5	6	7	8
Index	Tree height	2	3	4	5	6	7	8	9	10
	Tree node	3	7	15	31	63	127	255	511	1023
Indian Pines	OA /%	95.61	95.67	95.97	95.61	95.80	96.15	96.04	96.16	96.13
	Kappa	94.98	95.05	95.39	94.99	95.20	95.61	95.47	95.62	95.58
Pavia	OA /%	98.02	98.19	98.14	98.20	98.08	98.17	98.40	98.29	98.17
	Kappa	97.37	97.60	97.53	97.62	97.45	97.58	97.88	97.73	97.57

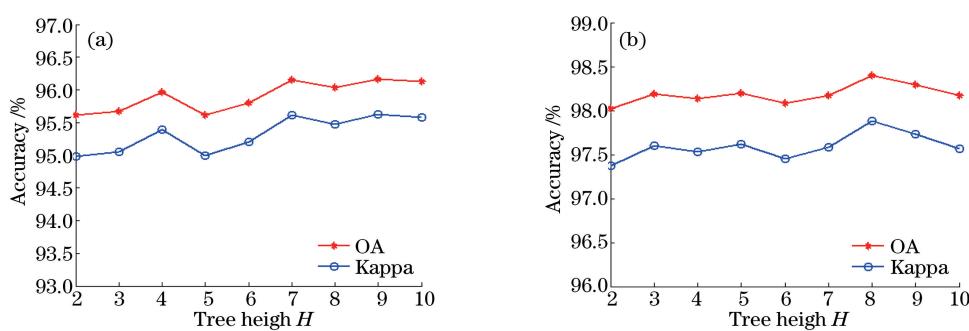


图8 自适应流形滤波的高光谱分类寻优。(a)印第安农林;(b)帕维亚大学

Fig. 8 Optimization for hyperspectral classification of adaptive manifold filtering. (a) Indian Pins; (b) Pavia University

5 结论

提出了一种基于自适应流形滤波的AMF-SVM高光谱图像分类方法,通过一系列实验验证了

AMF-SVM的优越性能。结果表明,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EPF以及IFRF分类算法相比,AMF-SVM得到的OA和Kappa系数都有较大幅度的提高,说明自

适应流形滤波能充分利用高光谱图像波段间的相关性和高光谱像元间的空间相关性提取空间特征,提取的空间特征可以较好地辅助SVM提高OA,该算法有以下特点:1)流形滤波通过投射、平滑和聚合等递归滤波后,能提取较好的局部和全局的空间特征,充分利用了高光谱像元间的空间相关性,获得了较好的高光谱图像的空间特征;2)利用流形滤波提取的高光谱图像空间特征对流行树高度进行自适应寻优,通过SVM分类获取最优分类性能,有效去除椒盐现象。更深入地研究高光谱的空间特征来提高OA是未来的研究方向。

参 考 文 献

- [1] Tong Q X, Zhang B, Zhang L F. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689-707.
- [2] Fan L H, Lü J W, Deng J S. Classification of hyperspectral remote sensing images based on bands grouping and classification ensembles [J]. Acta Optica Sinica, 2014, 34(9): 0910002.
- [3] Liao J S, Wang L G. Hyperspectral image classification method based on fusion with two kinds of spatial information [J]. Laser & Optoelectronics Progress, 2017, 54(8): 081002.
- [4] Chen P, Nelson J D B, Tourneret J Y. Towards a sparse Bayesian Markov random field approach to hyperspectral unmixing and classification [J]. IEEE Transactions on Image Processing, 2017, 26 (1): 426-438.
- [5] Yu H Y, Gao L R, Li J, et al. Spectral-spatial classification based on subspace support vector machine and Markov random field [C]. Geoscience and Remote Sensing Symposium, 2016: 2783-2786.
- [6] 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.
- [7] Bao R, Xia J S, Mura M D, et al. Combining morphological attribute profiles via an ensemble method for hyperspectral image classification [J]. IEEE Geoscience & Remote Sensing Letters, 2016, 13(3): 359-363.
- [8] Song H W, Wang Y. A spectral-spatial classification of hyperspectral images based on the algebraic multigrid method and hierarchical segmentation algorithm[J]. Remote Sensing, 2016, 8(4): 296.
- [9] Cui B G, Ma X D, Xie X Y, 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.
- [10] Shen L L, Bai L. Mutual boost learning for selecting Gabor features for face recognition [J]. Pattern Recognition Letters, 2006, 27(15): 1758-1767.
- [11] He L, Li J, Plaza A, et al. Discriminative low-rank Gabor filtering for spectral-spatial hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(3): 1381-1395.
- [12] Wang L G, Hao S Y, Wang Q M, et al. Semi-supervised classification for hyperspectral imagery based on spatial-spectral label propagation[J]. ISPRS Journal of Photogrammetry & Remote Sensing, 2014, 97: 123-137.
- [13] 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 and Remote Sensing, 2016, 54(6): 3174-3187.
- [14] Ye Z, Bai L, Nian Y J. Hyperspectral image classification algorithm based on Gabor feature and locality-preserving dimensionality reduction[J]. Acta Optica Sinica, 2016, 36(10): 1028003.
- [15] Tomasi C, Manduchi R. Bilateral filtering for gray and color images[C]. Sixth International Conference on Computer Vision, 1998: 839-846.
- [16] Liao J S, Wang L G, Hao S Y. Hyperspectral image classification method combined with bilateral filtering and pixel neighborhood information[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(8): 140-146.
- [17]廖建尚,王立国,郝思媛.基于双边滤波和空间邻域信息的高光谱图像分类方法[J].农业机械学报,2017,48(8):140-146.
- [18] 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.
- [18] Liao J S, Wang L G. Hyperspectral image classification method based on adaptive fusion of spatial information[J]. *Acta Photonica Sinica*, 2017, 46(4): 0410001.
廖建尚, 王立国. 空间信息自适应融合的高光谱图像分类方法[J]. 光子学报, 2017, 46(4): 0410001.
- [19] Kang X D, Li S T, 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.
- [20] 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.
- [21] Kang X D, Li S T, 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.
- [22] Gastal E S L, Oliveira M M. Adaptive manifold for real-time high-dimensional filtering [J]. *ACM Transactions on Graphics (TOG)*, 2012, 31(4): 33.
- [23] Nasab S E, Ramezanpur S, Kasaei S, et al. An efficient inference in meanfield approximation by adaptive manifold filtering (machine learning & data mining) [C]. 4th International eConference on Computer and Knowledge Engineering (ICCKE), 2014: 14825301.
- [24] Zhu S J, Li Y H. A terahertz image denoising algorithm based on adaptive manifold and high-dimensional filtering[J]. *Journal of Terahertz Science and Electronic Information Technology*, 2016, 14(4): 497-501.
朱书进, 李跃华. 基于自适应流形高维滤波的太赫兹图像滤波算法[J]. 太赫兹科学与电子信息学报, 2016, 14(4): 497-501.
- [25] Zhou G L, Hu W, Zhang F, et al. Edge-aware editing based on adaptive manifold filtering [J]. *Computer Engineering*, 2015, 41(1): 231-235.
周冠霖, 胡伟, 张帆, 等. 基于自适应流形滤波的边缘感知编辑[J]. 计算机工程, 2015, 41(1): 231-235.
- [26] Xie W Y, Li Y S, Zhou W P. Hyperspectral image filtering with adaptive manifold for classification[J]. *Journal of Electronic Imaging*, 2017, 26(3): 033025.
- [27] Cheng L Y, Mi G Y, Li S, et al. Quality diagnosis of joints in laser brazing based on principal component analysis-support vector machine model [J]. *Chinese Journal of Lasers*, 2017, 44(3): 0302004.
程力勇, 米高阳, 黎硕, 等. 基于主成分分析-支持向量机模型的激光钎焊接头质量诊断[J]. 中国激光, 2017, 44(3): 0302004.
- [28] 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.