

两类空间信息融合的高光谱图像分类方法

廖建尚¹, 王立国²

¹广东交通职业技术学院计算机工程学院, 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

摘要 针对单一滤波器提取高光谱图像空间特征时不能获得完整的图像空间信息的不足, 提出一种结合非局部均值滤波和导向滤波的高光谱图像分类算法。该方法利用非局部均值滤波提取高光谱全波段图像空间信息, 利用导向滤波提取经由主成分分析(PCA)降维后的高光谱图像的空间边缘信息, 将两种空间信息进行线性融合的结果输入至支持向量机(SVM)完成分类。实验表明, 相比于使用光谱信息、高光谱 PCA 降维、空谱结合的 SVM 分类、边缘保持滤波以及递归滤波等方法, 该算法能够有效提高高光谱图像的分类精度。

关键词 图像处理; 高光谱图像; 非局部均值滤波; 导向滤波; 空间信息融合; 分类

中图分类号 TP753 **文献标识码** A

doi: 10.3788/LOP54.081002

Hyperspectral Image Classification Method Based on Fusion with Two Kinds of Spatial Information

Liao Jianshang¹, Wang Liguo²

¹*Institute of Computer Engineering, Guangdong Communication Polytechnic, Guangzhou, Guangdong 510650, China;*

²*College of Information and Communications Engineering, Harbin Engineering University, Harbin, Heilongjiang 150001, China*

Abstract The full spatial information cannot be obtained by single filter in characteristics extraction of hyperspectral image. We propose a classification method which combines two kinds of information extracted by non-local means filter and guided filter. This method advances a fusion of spatial information for hyperspectral image classification. One kind of spatial information for all bands of hyperspectral image is extracted by the non-local means algorithm, and another kind of spatial information is obtained by guided filter for the same image after reducing dimensionality with principal component analysis (PCA). Two kinds of spatial information are combined, and the classification is done by support vector machine (SVM). Experimental results show that the proposed algorithm is better than the spectrum information, PCA dimensionality reduction, spatial-spectral SVM, edge-preserving filtering and recursive filtering methods, and the classification accuracy of hyperspectral image is effectively improved.

Key words image processing; hyperspectral image; non-local means filter; guided filter; fusion of spatial information; classification

OCIS codes 100.4145; 110.4234; 300.6170; 280.0280; 100.5010

1 引言

高光谱遥感图像由成像光谱仪获得, 可包含几百个波段的光谱, 蕴含丰富的地物信息^[1-2]。将空间信息融入到高光谱图像的分类中能够有效地提高分类器性能。Bao 等^[3]和王佳宁^[4]使用形态滤波提取高光谱空

收稿日期: 2017-02-16; **收到修改稿日期:** 2017-03-25

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

作者简介: 廖建尚(1982—), 男, 硕士, 副教授, 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

间信息;Chen 等^[5]和 Yu 等^[6]采用马尔科夫随机场获取高光谱空间信息;Zhang 等^[7]和 Chen 等^[8]则采用图像分割方法提升高光谱分类性能,并获得了较好的结果。

采用滤波器提取图像空间信息辅助光谱信息进行分类是目前的一个研究热点。Gabor 滤波器^[9]提取纹理信息可以辅助高光谱分类,如叶珍等^[10]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,提出了两种基于 Gabor 特征与局部保护降维的高光谱图像分类算法;Li 等^[11]利用 Gabor 滤波器提取空间信息和最近邻信息(NRS)方法,提出了 Gabor-NRS 算法;Wang 等^[12]采用 Gabor 滤波获取图像空间信息,提出了基于空-谱信息的高光谱图像半监督分类方法(S2ISC);Zhu 等^[13]在文化基因算法的基础上用三维 Gabor 滤波获取高光谱空间特征,提出了基于三维 Gabor 特征提取的高光谱图像分类方法(M3DGF);Jia 等^[14]用 Fisher 判别准则挑出每种类别最有代表性的 Gabor 立方体,联合稀疏表示提出了基于多任务联合稀疏表示的 Gabor 多维特征选择分类方法(GS-MTJSRC)。

另有学者采用双边滤波器^[15-16]提取高光谱空间边缘信息。Sahadevan 等^[17]采用双边滤波提取高光谱空间特征后,用支持向量机(SVM)实现分类;Shen 等^[18]先获取波段子集,再用双边滤波提取空间信息,提出了 Bilateral-Kelm 高光谱图像分类算法;Wang 等^[19]利用双边滤波对 SVM 获得的分类结果进行平滑处理,并采用图形分割构建地物类别的分类方法;Kang 等^[20]利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(EPF)。还有个别学者采用递归滤波^[21]提取空间边缘信息,如 Kang 等^[22]对高光谱数据集分组后融合,用递归滤波提取其空间信息,并用 SVM 实现分类,提出了基于图像融合和递归滤波(IFRF)的高光谱图像分类方法。

利用滤波器提取高光谱图像空间信息,并应用于分类已取得一定成效,但也存在一些不足:1)单一的滤波器难以获取完整的空间信息;2)大多滤波器未考虑全局信息对高光谱图像的结构信息进行捕获。为了充分利用空间信息以提高高光谱图像分类性能,本文提出一种结合非局部均值滤波和导向滤波的高光谱图像分类算法(NLGD-SVM),该算法利用非局部均值滤波提取高光谱图像的空间信息,同时利用导向滤波提取高光谱图像的空间边缘信息,将两者进行线性融合,然后交由 SVM 实现高光谱图像的分类。

2 方 法

2.1 快速非局部均值滤波提取高光谱图像空间信息

非局部均值滤波由 Buades 等^[23]提出。对于有 l 个波段的高光谱图像集 G ,定义第 k 个波段图像的非局部均值滤波为

$$u(i, k) = \frac{1}{Z(i)} \sum_{t \in N(i)} w(i, j) \cdot v(j), \quad (1)$$

式中

$$w(i, j) = \exp[-d(i, j)/\sigma^2], \quad (2)$$

$$Z(i) = \sum_j \exp[-d(i, j)/\sigma^2], \quad (3)$$

$$d(i, j) = \|N(i) - N(j)\|_{2,a}, \quad (4)$$

式中 $d(i, j)$ 为两图像子块之间的欧氏距离, σ 为控制平滑程度的滤波参数, $N(i)$ 为以像元 i 为中心的图像子块,搜索窗口大小为 s , $N(j)$ 为 $N(i)$ 邻域内以像元 j 为中心的子块, $w(i, j)$ 为两个图像子块内像元之间的相似权系数,表征两个图像子块间的相似程度, $Z(i)$ 为归一化常数。

该算法计算量过大,对于高达几百个波段的高光谱图像,运算速度非常慢,因此采用 Darbon 等^[24]提出的快速非局部均值滤波算法对 $w(i, j)$ 的计算过程进行改进,得到

$$w(i, j) = g_h \left\{ \sum_{\delta \in \Delta} G_\sigma(\delta) [v(i + \delta) - v(j + \delta)]^2 \right\}, \quad (5)$$

$$g_h(x) = \exp(-x^2/\sigma^2), \quad (6)$$

式中 G_σ 为方差为 σ^2 的高斯核, g_h 为一个非递增函数,且 $g_h(0) = 1, \lim_{x \rightarrow +\infty} g_h(x) = 0$, Δ 代表在邻域半径为 δ 的离散块区域, h 为滤波半径。非局部均值滤波考虑高光谱图像像元的相似性,进行像元值的加权平均重构高光谱图像。为了获得更好的滤波效果,采用像元边界镜像法对高光谱图像进行扩充,扩充宽度为 P ,高

斯核 $G_s(\delta)$ 采用常量来代替, 因此(5)式可以改写为

$$w(i, j) = g_h \left\{ \sum_{\delta \in \Delta} [v(i + \delta) - v(j + \delta)]^2 \right\}, \quad (7)$$

定义 $d = i - j, \hat{p} = i + \delta$, 可得

$$w(i, j) = g_h \left\{ \sum_{\hat{p}=i-P}^{i+P} [v(\hat{p}) - v(\hat{p} + d)]^2 \right\}, \quad (8)$$

定义

$$S_d(p) = \sum_{k=0}^p [v(k) - v(k + d)]^2, \quad p \in \Omega, \quad (9)$$

从而得到

$$w(i, j) = g_h [S_d(i + P) - S_d(i - P)], \quad (10)$$

最终得到改进的高光谱图像非局部均值滤波

$$u(i, k) = \frac{1}{Z(i)} \sum_{j \in N(i)} g_h [S_d(i + P) - S_d(i - P)] v(j). \quad (11)$$

非局部均值滤波不仅对比像元间的差异, 还考虑图像中结构的冗余, 与当前子块越相似的子块, 赋予其中心像元越大的权重, 反之越小。与传统的滤波算法相比, 非局部均值算法充分考虑图像的自相似性和相关性信息, 其通过比较两个像元邻域分布来确定权值, 可以大幅提升高光谱图像的平滑去噪效果。

图 1 所示为非局部均值滤波对高光谱图像进行滤波的结果, 图中的数据为印第安松林数据集中的第 10、100、130 和 190 波段。对比滤波前后的图像可以发现, 滤波前图像麻点多, 滤波后同类地物的灰度相近, 说明非局部均值滤波对高光谱图像具有较好的平滑去噪效果。




图 1 印第安松林数据集的滤波结果。(a)高光谱图像;(b)非局部均值滤波;(c)导向滤波

Fig. 1 Filtering results for Indian Pines dataset.

(a) Hyperspectral images; (b) non-local means filter; (c) guided filter

为了确定扩充宽度 P 、搜索窗口 s 和滤波半径 h 对分类结果的影响, 采用穷举法, 通过前期实验初步估算, 限定 3 个参数的取值范围: $P \in [50, \dots, 260], s \in [5, \dots, 30], h \in [1, \dots, 15]$, 以印第安松林图像为实验数据集, 获取最优分类结果的 3 个参数值。为了降低运算量, 对有 200 个波段的印第安松林数据集的部分波段进行测试, 平均每 4 个波段挑选 1 个波段, 共 50 个波段组成新数据集, 随机抽取新数据集的 10% 作为训

练样本, 剩余 90% 作为测试样本进行验证。采用整体分类精度(OA)、平均分类精度(AA)以及 Kappa 统计系数衡量分类结果, 实验结果如图 2 所示, 当 $P=170$ 、 $s=23$ 和 $h=8$ 时, 得到的分类结果最优, 此时整体分类结果 OA 为 91.94, 因此非局部均值滤波系数取 $P=170$ 、 $s=23$ 和 $h=8$ 。




图 2 非局部均值滤波分类的参数优化

Fig. 2 Parameter optimization for non-local means filter classification

非局部均值滤波能够充分利用图像的自相似性信息和邻域信息, 在一定程度上获得了高光谱图像的空间相关信息, 但在滤波过程中丢失了高光谱图像的空间边缘信息, 使得图像的边缘信息不清晰。为了克服该缺点, 利用导向滤波提取高光谱图像的空间边缘信息。

2.2 结合两类空间信息的高光谱图像分类

采用由 He 等^[25]提出的导向滤波方法提取高光谱图像空间边缘信息。导向滤波器可以向滤波图像中导入空间结构信息。对有 S 个波段的高光谱图像, 某个波段的导向滤波器定义为

$$F_i = aG_i + b, \quad i = 1, 2, \dots, S, \quad (12)$$

式中 G 为导向图像, a 、 b 为滤波系数。对(12)式两边求导, 可得

$$\nabla F_i = a \nabla G_i. \quad (13)$$

可见, 当导向图像 G 存在不同结构时, 滤波器能够获取图像的空间边缘信息。图 1(c)所示为导向滤波器对印第安松林数据集中的第 10、100、130 和 190 波段的滤波图像, 与原高光谱图像和非局部均值滤波图像相比, 导向滤波后图像结构清晰, 边缘信息突出, 可以较好地弥补非局部均值滤波的不足。

(12)式中的参数 a 、 b 可表示为

$$a = \frac{1}{|\omega|} \left(\sum_{i \in \omega} G_i p_i - \mu \bar{p} \right) / (\sigma^2 + \epsilon), \quad (14)$$

$$b = \bar{p} - a\mu, \quad (15)$$

式中 ϵ 为正则系数, p_i 为高光谱某一波段的滤波图像, \bar{p} 为滤波窗口的均值, ω 为半径为 r 的滤波窗口, μ 和 σ^2 分别为导向图像 G 的均值和方差。

为了充分利用非局部均值滤波提取的空间信息和导向滤波提取的空间边缘信息, 设计了一种两类空间信息融合的高光谱分类方法, 非局部均值滤波用来提取高光谱图像空间信息, 导向滤波用来提取经主成分分析^[26]降维后的高光谱图像空间边缘信息, 将两种信息进行融合, 再由 SVM 完成分类, 形成 NLGD-SVM 分类算法。该算法的具体实现过程如下:

1) 归一化: 高光谱中像元的反射强度数值较大, 对波段数为 l 的高光谱数据集进行归一化处理, 可以得到信息量重新分布的高光谱图像数据集

$$R = (R - R_{\min}) / (R_{\max} - R_{\min}), \quad (16)$$

式中 R_{\min} 为最小值, R_{\max} 为最大值。

2) PCA 降维: 对于数据集 R 进行 PCA 降维, 选择前面 n 维数据组成新的数据集

$$P = \text{PCA}(R). \quad (17)$$

3) 非局部均值滤波提取空间信息: 利用非局部均值滤波对 R 按照(11)式进行滤波, 获取空间信息

$$D_{\text{nl}}^i = \text{NL}(R^i). \quad (18)$$

4) 导向滤波提取空间边缘信息: 对 P 按照(12)式进行导向滤波, 并将 PCA 降维后的第一主成分作为导

向图像获取空间信息

$$D_{gd}^j = GD(P^j). \quad (19)$$

5) 空间信息和空间边缘信息融合: 对 D_{nl} 和 D_{gd} 进行线性融合, 得到

$$H = D_{nl} + D_{gd}. \quad (20)$$

6) 分类:

- ① 以一定比例从 H 中随机抽取训练集 H_s , 其余部分作为测试集 H_t ;
- ② 利用径向基函数支持的 SVM 方法交叉验证, 寻找最优的参数组合;
- ③ 利用径向基函数支持的 SVM 对 H_s 进行训练, 获取训练模型;
- ④ 利用径向基函数支持的 SVM 对测试集 H_t 进行分类。

7) 输出分类结果。

NLGD-SVM 分类算法详细流程如图 3 所示。

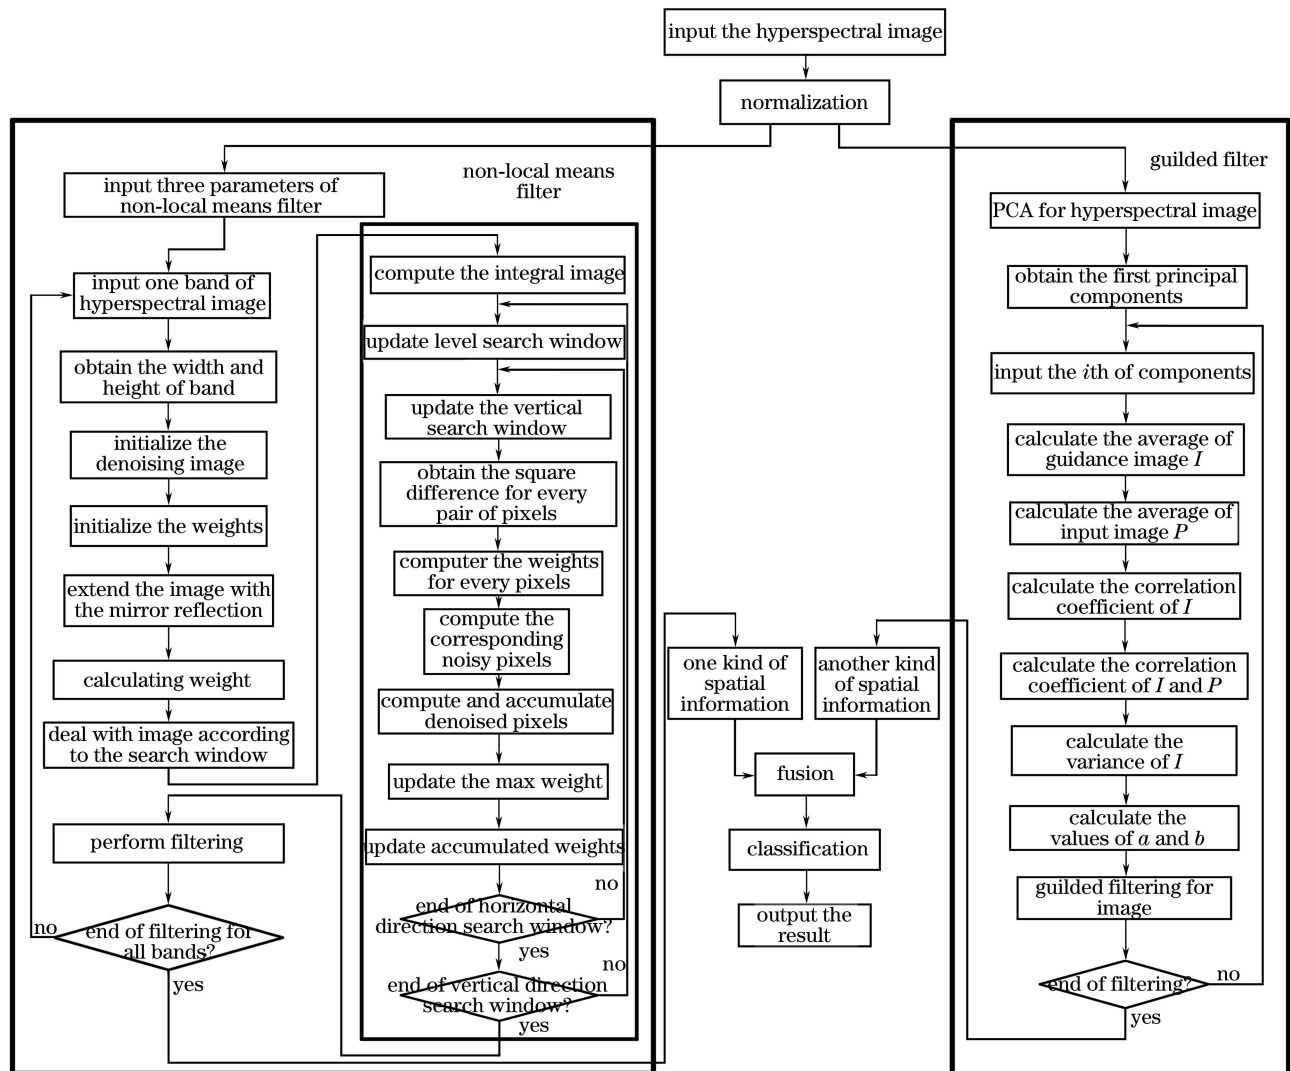


图 3 NLGD-SVM 算法流程图

Fig. 3 Flow of NLGD-SVM algorithm

3 实验数据集

为了验证算法的有效性, 采用印第安松林和帕维亚大学两个高光谱数据集进行验证, 数据集特征如下:

- 1) 印第安松林数据集由成像光谱仪于 1992 年在印第安纳州西北部印第安松林采集, 具有 20 m 的空间分辨

率,包含 144×144 个像元,220 个波段,考虑到噪声和水吸收等因素的影响,除去其中的 20 个波段,剩余 200 个波段,包含 16 种地物,具体地物类别和样本个数参见表 1;2) 帕维亚大学数据集由成像光谱仪采集于帕维亚大学,包含 610×340 个像元,115 个波段,同样考虑到噪声等因素的影响,除去其中的 12 个波段,剩余 103 个波段,包含 9 类地物,具体地物类别和样本个数参见表 2。

4 实验设计与评价指标

为了验证本文算法的优越性,采用 6 种方法进行比较验证,包括:文献[27]提出的 SVM 分类方法;PCA 降维后的 SVM 分类方法;PCA 降维后用 Gabor 滤波器、双边滤波器和导向滤波器分别对前 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,再用 SVM 进行分类,形成的基于 Gabor 滤波的空谱结合的高光谱图像分类方法(SGB-SVM)、基于双边滤波的空谱结合的高光谱图像分类方法(SBL-SVM)以及基于导向滤波的空谱结合的高光谱图像分类方法(SGD-SVM);文献[20]提出的 EPF 分类算法,即 EPF-B-c 和 EPF-G-c;文献[22]提出的域转换递归滤波的 IFRF 方法;本文算法。

采用 OA、AA 以及 Kappa 统计系数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。

4.1 实验验证

利用 6 种方法分别对印第安松林和帕维亚大学数据集进行分类。

1) 印第安松林数据集图像地物分布如图 4(a)所示,选取全部 16 种类别,每类随机选取 8% 样本组成训练集,其余 92% 作为测试集,数量较少的地物选取 24% 作为训练集。印第安松林数据集的分类结果如图 4 所示,分类精度统计如表 1 所示。

2) 帕维亚大学数据集图像地物分布如图 5(a)所示,选取全部 9 种类别,每类随机选取 3% 样本组成训练集。其余 97% 作为测试集,帕维亚大学数据集的分类结果如图 5 所示,分类精度统计如表 2 所示。

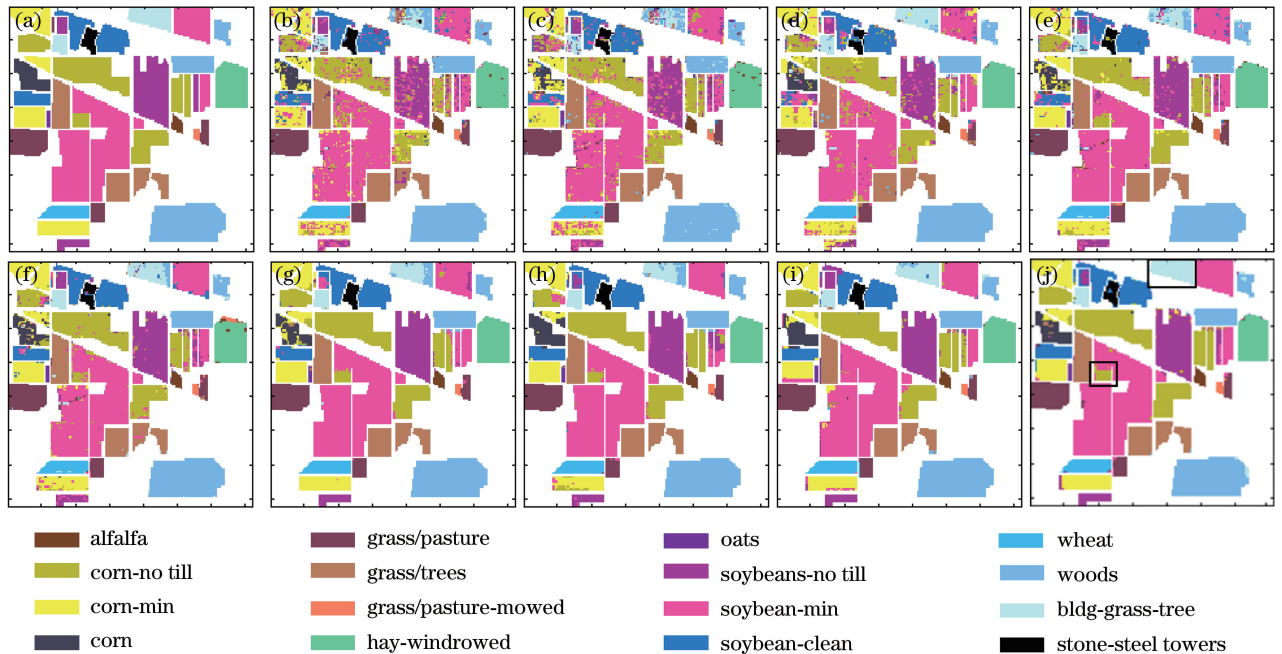


图 4 印第安松林数据集的分类结果。(a)地物分布;(b) SVM,OA 为 81.93%;(c) SVM-PCA,

OA 为 81.24%;(d) SGB-SVM,OA 为 84.10%;(e) SBL-SVM,OA 为 89.99%;(f) SGD-SVM,OA 为 92.22%;(g) EPF-B-c, OA 为 94.24%;(h) EPF-G-c,OA 为 94.37%;(i) IFRF,OA 为 94.54%;(j) NLGD-SVM,OA 为 96.35%

Fig. 4 Classification results for Indian Pines. (a) Gound truth; (b) SVM, OA is 81.93%; (c) SVM-PCA, OA is 81.24%;

(d) SGB-SVM, OA is 84.10%; (e) SBL-SVM, OA is 89.99%; (f) SGD-SVM, OA is 92.22%; (g) EPF-B-c,

OA is 94.24%; (h) EPF-G-c, OA is 94.37%; (i) IFRF, OA is 94.54%; (j) NLGD-SVM, OA is 96.35%

表 1 印第安松林数据集的分类统计结果

Table 1 Classification results of Indian Pines dataset

| Indian | Sample number | | Spectrum | | Dimensionality reduction | | Spatial-spectral | | | Edge-preserving | | Recursive | Spatial fusion |
|-----------------------|---------------|-----------|----------|---------|--------------------------|-------------|------------------|-------------|-------------|-----------------|----------|--------------|----------------|
| | Sum | Train / % | Test / % | SVM / % | SVM-PCA / % | SGB-SVM / % | SBL-SVM / % | SGD-SVM / % | EPF-B-c / % | EPF-G-c / % | IFRF / % | NLGD-SVM / % | |
| Gound truth | 54 | 24 | 76 | 86.51 | 81.39 | 94.45 | 94.64 | 94.42 | 97.62 | 94.58 | 92.71 | 92.08 | |
| Alfalfa | 1434 | 8 | 92 | 73.06 | 72.93 | 78.37 | 86.59 | 88.90 | 94.08 | 92.74 | 90.18 | 96.33 | |
| Corn-no till | 834 | 8 | 92 | 70.31 | 71.75 | 72.43 | 86.42 | 91.48 | 87.16 | 89.60 | 89.44 | 96.63 | |
| Corn-min till | 234 | 8 | 92 | 53.79 | 43.54 | 44.68 | 64.77 | 72.69 | 82.05 | 78.74 | 89.18 | 82.09 | |
| Grass / pasture | 497 | 8 | 92 | 90.88 | 92.35 | 89.70 | 92.07 | 94.02 | 94.12 | 96.30 | 93.77 | 95.45 | |
| Grass / trees | 747 | 8 | 92 | 95.63 | 95.64 | 97.09 | 97.24 | 97.60 | 99.82 | 99.85 | 97.65 | 98.90 | |
| Grass / pasture-mowed | 26 | 24 | 76 | 81.33 | 80.01 | 89.98 | 93.35 | 89.06 | 81.42 | 89.72 | 100.00 | 89.54 | |
| Hay-windrowed | 489 | 8 | 92 | 95.94 | 96.08 | 99.62 | 98.70 | 96.01 | 100.00 | 100.00 | 99.55 | 97.09 | |
| Oats | 20 | 24 | 76 | 94.06 | 86.15 | 84.76 | 93.11 | 92.24 | 73.81 | 72.64 | 100.00 | 82.27 | |
| Soybeans-no till | 968 | 8 | 92 | 70.75 | 67.80 | 68.34 | 84.42 | 87.52 | 85.34 | 88.57 | 89.69 | 93.94 | |
| Soybeans-min till | 2468 | 8 | 92 | 85.05 | 85.81 | 87.41 | 92.78 | 94.28 | 97.92 | 97.30 | 96.90 | 97.77 | |
| Soybeans-clean till | 614 | 8 | 92 | 83.40 | 75.67 | 77.20 | 86.39 | 93.11 | 98.10 | 97.35 | 94.85 | 94.01 | |
| Wheat | 212 | 8 | 92 | 98.41 | 97.80 | 97.55 | 98.00 | 98.30 | 100.00 | 99.55 | 99.18 | 98.17 | |
| Woods | 1294 | 8 | 92 | 97.88 | 97.37 | 98.75 | 97.82 | 98.21 | 99.52 | 99.75 | 99.09 | 99.17 | |
| Bldg-grass-tree | 380 | 8 | 92 | 43.56 | 47.05 | 77.55 | 70.31 | 74.98 | 72.42 | 69.95 | 93.01 | 94.39 | |
| Stone-steel towers | 95 | 8 | 92 | 81.86 | 72.37 | 73.55 | 82.08 | 88.80 | 93.95 | 98.83 | 91.99 | 85.70 | |
| OA / % | — | — | — | 81.93 | 81.24 | 84.10 | 89.99 | 92.22 | 94.24 | 94.37 | 94.54 | 96.35 | |
| AA / % | — | — | — | 81.40 | 78.98 | 83.21 | 88.67 | 90.73 | 91.08 | 91.59 | 94.82 | 93.34 | |
| Kappa | — | — | — | 79.28 | 78.45 | 81.75 | 88.55 | 91.11 | 93.40 | 93.56 | 93.76 | 95.84 | |

表 2 帕维亚大学数据集的分类统计结果

Table 2 Classification results of Pavia University dataset

| Pavia | Sample number | | Spectrum | | Dimensionality reduction | | Spatial-spectral | | | Edge-preserving | | Recursive | Spatial fusion |
|--------------|---------------|-----------|----------|---------|--------------------------|-------------|------------------|-------------|-------------|-----------------|----------|--------------|----------------|
| | Sum | Train / % | Test / % | SVM / % | SVM-PCA / % | SGB-SVM / % | SBL-SVM / % | SGD-SVM / % | EPF-B-c / % | EPF-G-c / % | IFRF / % | NLGD-SVM / % | |
| Asphalt | 6641 | 3 | 97 | 88.53 | 88.48 | 89.55 | 89.58 | 96.13 | 97.39 | 97.88 | 90.23 | 99.19 | |
| Meadows | 18649 | 3 | 97 | 96.25 | 95.96 | 96.30 | 97.92 | 98.70 | 99.99 | 99.92 | 99.64 | 99.55 | |
| Gravel | 2099 | 3 | 97 | 61.89 | 59.19 | 61.24 | 65.83 | 79.02 | 78.63 | 68.34 | 84.16 | 90.35 | |
| Trees | 3064 | 3 | 97 | 86.99 | 86.98 | 88.35 | 94.94 | 96.47 | 94.64 | 93.27 | 91.17 | 98.22 | |
| Metal sheets | 1345 | 3 | 97 | 98.25 | 98.32 | 98.56 | 98.45 | 99.12 | 99.89 | 99.92 | 98.90 | 99.65 | |

| Pavia | Sample number | | Spectrum | | Dimensionality reduction | Spatial-spectral | | | Edge-preserving | | Recursive | Spatial fusion |
|---------|---------------|-----------|----------|---------|--------------------------|------------------|-------------|-------------|-----------------|-------------|-----------|----------------|
| | Sum | Train / % | Test / % | SVM / % | PCA-SVM / % | SGB-SVM / % | SBL-SVM / % | SGD-SVM / % | EPF-B-c / % | EPF-G-c / % | IFRF / % | NLGD-SVM / % |
| Soil | 5029 | 3 | 97 | 58.48 | 59.64 | 63.22 | 83.46 | 92.26 | 67.26 | 70.22 | 99.88 | 96.92 |
| Bitumen | 1330 | 3 | 97 | 66.71 | 62.27 | 69.36 | 71.53 | 87.09 | 90.06 | 88.18 | 92.61 | 95.38 |
| Bricks | 3682 | 3 | 97 | 77.14 | 76.53 | 80.84 | 82.34 | 90.71 | 98.48 | 97.85 | 84.39 | 95.36 |
| Shadows | 947 | 3 | 97 | 89.50 | 89.95 | 89.72 | 88.72 | 94.24 | 94.67 | 93.58 | 60.02 | 97.96 |
| OA / % | — | — | — | 85.62 | 85.30 | 86.83 | 90.79 | 95.28 | 93.75 | 93.40 | 94.41 | 98.11 |
| AA / % | — | — | — | 80.42 | 79.70 | 81.90 | 85.86 | 92.64 | 91.22 | 89.91 | 89.00 | 96.95 |
| Kappa | — | — | — | 80.58 | 80.19 | 82.26 | 87.71 | 93.73 | 91.56 | 91.10 | 92.58 | 97.50 |

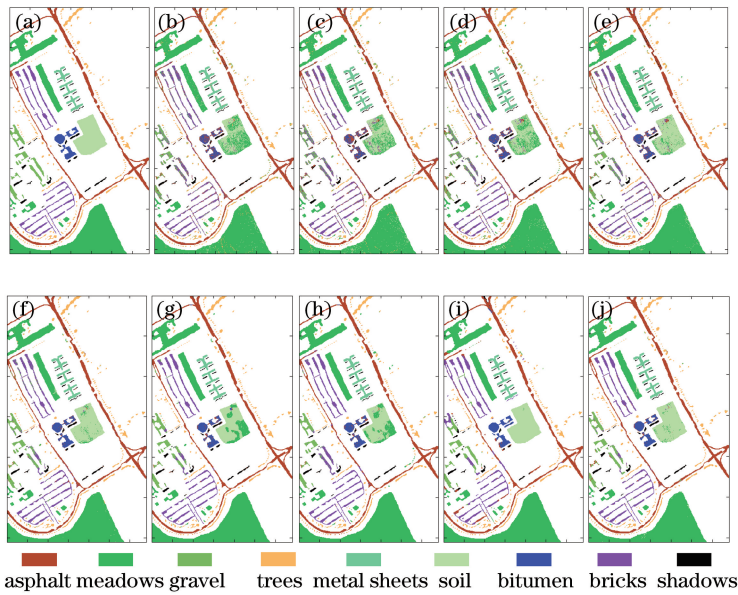


图 5 帕维亚大学数据集的分类结果。(a) 地物分布;(b) SVM,OA 为 85.62%;(c) SVM-PCA, OA 为 85.30%;(d) SGB-SVM,OA 为 86.83%;(e) SBL-SVM,OA 为 90.79%;(f) SGD-SVM,OA 为 95.28%;(g) EPF-B-c, OA 为 93.75%;(h) EPF-G-c,OA 为 93.40%;(i) IFRF,OA 为 94.41%;(j) NLGD-SVM,OA 为 98.11%

Fig. 5 Classification results for Pavia University dataset. (a) Ground truth; (b) SVM, OA is 85.62%; (c) SVM-PCA, OA is 85.30%; (d) SGB-SVM, OA is 86.83%; (e) SBL-SVM, OA is 90.79%; (f) SGD-SVM, OA is 95.28%; (g) EPF-B-c, OA is 93.75%; (h) EPF-G-c, OA is 93.40%; (i) IFRF, OA is 94.41%; (j) NLGD-SVM, OA is 98.11%

4.2 实验分析

1) 利用 NLGD-SVM 对两种数据集进行分类时,分类精度 OA 分别为 96.35%和 98.11%,比 SVM 整体分类精度高出 13%~15%,比 PCA-SVM 整体分类精度高出 13%~15%,比 SGB-SVM、SBL-SVM、SGD-SVM 高出 3%~11%,比 EPF 算法高出 2%~4%,比 IFRF 算法高出 2%,充分验证了 NLGD-SVM 算法处理高光谱图像分类的有效性。

2) 印第安松林数据集地物种类多,分布复杂,从实验结果可知,虽然训练样本仅为 8%,但是 NLGD-SVM 方法的整体分类精度 OA 能超过 96%,分类性能具有较大提升,从图 4(j)可以看出麻点大幅减少,标注黑框部分效果更明显;在训练样本仅有 3%的情况下,NLGD-SVM 方法对帕维亚大学的分类结果比 IFRF 方法提升了接近 4%,充分说明利用相似块和全局信息捕获高光谱图像的结构信息,能够有效提高分类精度。

3) 为了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,结果如图 6 所示。对于印第安松林数据集,训练样本为 4%时,OA 超过 91%,训练样本为 11%时,OA 达到 97.06%;对于帕维亚大学数据集,训练样本为 0.5%时,OA 超过 90%,训练样本为 4.5%时,OA 超过 98%,充分说明 NLGD-

SVM算法在少量监督样本的情况下也可以获得较好的分类精度,同时在较低监督样本下能达到较优的分类效果,进一步验证了算法的稳定性和有效性。

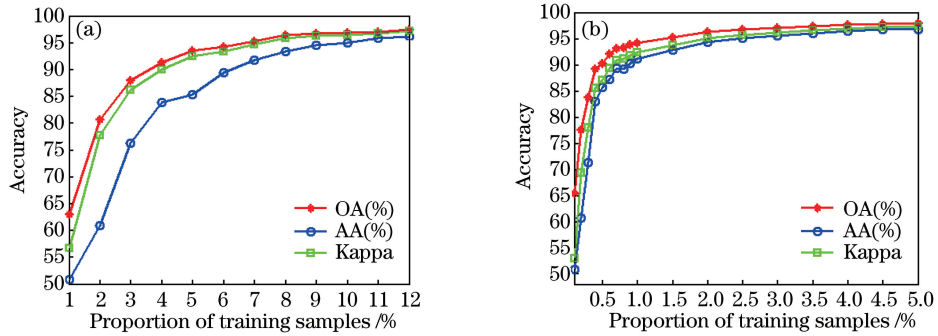


图6 不同训练样本的OA、AA以及Kappa值。(a)印第安松林数据集;(b)帕维亚大学数据集

Fig. 6 OA, AA and Kappa values with different training samples. (a) Indian Pines dataset; (b) Pavia University dataset

5 结 论

提出了非局部均值滤波和导向滤波结合的高光谱图像分类算法(NLGD-SVM),实验结果表明,与光谱信息SVM算法、波段降维的PCA-SVM、空谱结合分类算法(SGB-SVM、SBL-SVM和SGD-SVM)、边缘保持分类算法(EPF-B-c和EPF-G-c)以及IFRF算法等5种方法相比,该算法结果的OA、Kappa和AA值都有大幅提高,即该算法能够获取较完整的高光谱空间信息,并充分利用空间信息提高了高光谱图像的分类精度。

本文算法具有以下特点:非局部均值滤波利用全局信息和邻域相似块进行滤波,获得了较好的平滑去噪效果,也在一定程度上获得了高光谱图像的空间相关信息;导向滤波可以提取较好的空间边缘信息,弥补了非局部均值滤波丢失空间边缘信息的不足;将两者提取的高光谱图像空间信息进行融合,并通过SVM进行分类,得到了较优的分类效果,这是一种有效的高光谱图像分类方法。

提取高光谱空间信息并进一步有效融合是本课题组的未来主要研究方向。

参 考 文 献

- [1] Tong Qingxi, Zhang Bing, Zhang Lifu. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689-707.
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.
- [2] Fan Liheng, Lü Junwei, Deng Jiangsheng. Classification of hyperspectral remote sensing images based on bands grouping and classification ensembles[J]. Acta Optica Sinica, 2014, 34(9): 0910002.
樊利恒, 吕俊伟, 邓江生. 基于分类器集成的高光谱遥感图像分类方法[J]. 光学学报, 2014, 34(9): 0910002.
- [3] Bao R, Xia J S, Dalla Mura M, *et al.* Combining morphological attribute profiles via an ensemble method for hyperspectral image classification[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(3): 359-363.
- [4] Wang Jianing. Hyperspectral image classification based on joint sparse representation and morphological feature extraction[J]. Laser & Optoelectronics Progress, 2016, 53(8): 082801.
王佳宁. 基于联合稀疏表示与形态特征提取的高光谱图像分类[J]. 激光与光电子学进展, 2016, 53(8): 082801.
- [5] Chen P, Nelson J D B, Tournet 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] Yu H Y, Gao L R, Li J, *et al.* Spectral-spatial classification based on subspace support vector machine and Markov random field[C]. IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2016: 2783-2786.
- [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 & Remote Sensing, 2016, 9(2): 640-654.
- [8] Chen J K, Xia J S, Du P J, *et al.* Combining rotation forest and multiscale segmentation for the classification of

- hyperspectral data[J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2016, 9(9): 4060-4072.
- [9] Shen L L, Bai L. MutualBoost learning for selecting Gabor features for face recognition[J]. *Pattern Recognition Letters*, 2006, 27(15): 1758-1767.
- [10] Ye Zhen, Bai Lin, Nian Yongjian. Hyperspectral image classification algorithm based on Gabor feature and locality-preserving dimensionality reduction[J]. *Acta Optica Sinica*, 2016, 36(10): 1028003.
叶 珍, 白 璘, 粘永健. 基于 Gabor 特征与局部保护降维的高光谱图像分类算法[J]. *光学学报*, 2016, 36(10): 1028003.
- [11] Li W, Du Q. Gabor-filtering-based nearest regularized subspace for hyperspectral image classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2014, 7(4): 1012-1022.
- [12] Wang L G, Hao S Y, Wang Y, *et al.* Spatial-spectral information-based semisupervised classification algorithm for hyperspectral imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2014, 7(8): 3577-3585.
- [13] Zhu Z X, Jia S, He S, *et al.* Three-dimensional Gabor feature extraction for hyperspectral imagery classification using a memetic framework[J]. *Information Sciences*, 2015, 298: 274-287.
- [14] 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.
- [15] Tomasi C, Manduchi R. Bilateral filtering for gray and color images[C]. *IEEE International Conference on Computer Vision (ICCV)*, 1998: 839-846.
- [16] Kotwal K, Chaudhuri S. Visualization of hyperspectral images using bilateral filtering[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2010, 48(5): 2308-2316.
- [17] Sahadevan A S, Routray A, Das B S, *et al.* Hyperspectral image preprocessing with bilateral filter for improving the classification accuracy of support vector machines[J]. *Journal of Applied Remote Sensing*, 2016, 10(2): 025004.
- [18] 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]. *IEEE International Geoscience and Remote Sensing Symposium*, 2016: 497-500.
- [19] Wang Y, Song H W, Zhang Y. Spectral-spatial classification of hyperspectral images using joint bilateral filter and graph cut based model[J]. *Remote Sensing*, 2016, 8(9): 748.
- [20] Kang X D, Li S T, Benediktsson J A. Spectral-spatial hyperspectral image classification with edge-preserving filtering[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2014, 52(5): 2666-2677.
- [21] Gastal E S L, Oliveira M M. Domain transform for edge-aware image and video processing[J]. *ACM Transactions on Graphics (TOG)*, 2011, 30(4): 69.
- [22] 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 & Remote Sensing*, 2014, 52(6): 3742-3752.
- [23] Buades A, Coll B, Morel J M. A non-local algorithm for image denoising[C]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, 2005, 2: 60-65.
- [24] Darbon J, Cunha A, Chan T F, *et al.* Fast nonlocal filtering applied to electron cryomicroscopy[C]. *IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, 2008: 1331-1334.
- [25] He K, Sun J, Tang X. Guided image filtering[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2013, 35(6): 1397-1409.
- [26] Cai S, Du Q X Q, Moorhead R, *et al.* Noise-adjusted principle component analysis for hyperspectral remotely sensed imagery visualization[C]. *IEEE Visualization Conference*, 2005: 105.
- [27] Melgani F, Bruzzone L. Classification of hyperspectral remote sensing images with support vector machines[J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2004, 42(8): 1778-1790.