

doi: 10.3788/gzxb20174604.0410001

# 空间信息自适应融合的高光谱图像分类方法

廖建尚<sup>1</sup>, 王立国<sup>2</sup>

(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)

**摘 要:**针对单一的滤波器提取高光谱图像空间纹理信息时不能获得完整的图像特征的不足,提出一种结合双边滤波和域转换标准卷积滤波的高光谱图像分类算法.该方法采用空间信息自适应融合的分类寻优,先对高光谱波段进行抽样分组,再用双边滤波和域转换标准卷积滤波对分组后的波段进行滤波,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、空谱结合的支持向量机分类方法和边缘保持滤波以及递归滤波的方法,本文所提算法对高光谱图像的分类精度有较大提高,在训练样本仅为 5% 和 3% 的情况下,对印第安农林和帕维亚大学图像的总体分类精度分别达到了 96.95% 和 97.89%,比其他算法高出 2~13 个百分点,验证了该方法在高光谱图像分类的有效性.

**关键词:**高光谱图像;空间信息;自适应融合;分类;双边滤波;域转换卷积滤波

中图分类号: TP753

文献标识码: A

文章编号: 1004-4213(2017)04-0410001-13

## Hyperspectral Image Classification Method Based on Adaptive Fusion of Spatial Information

LIAO Jian-shang<sup>1</sup>, WANG Li-guo<sup>2</sup>

(1 College of Computer Engineering, Guangdong Communication Polytechnic, GuangZhou 510650, China)

(2 College of Information and Communications Engineering, Harbin Engineering University, Harbin 150001, China)

**Abstract:** The full characteristics cannot be obtained by single filter in spatial information extraction of hyperspectral image. Combining bilateral filter and domain transform filter of normalized convolution, an improved algorithm of classification was proposed. The method advanced an adaptive fusion of spatial information for classification optimization. Firstly, bands of hyperspectral image were sampled into two groups. Secondly, spatial information of the two group images was extracted by the bilateral filter and the normalized convolution respectively. Finally, the two kinds of spatial information were combined and classified by support vector machine. The experiments show that the algorithm is better than original support vector machine with the pure spectrum information, dimensionality reduction, the spatial-spectral information, and the method of edge-preserving filtering and recursive filtering. The performance of hyperspectral image classification algorithm is greatly improved, although training samples were only 5% and 3%, the overall accuracy of Indian and Pavia can reach 96.95% and 97.89% respectively, with 2%~13% higher than other algorithms, and the effectiveness of the method is fully verified.

**Key words:** Hyperspectral image; Spatial information; Adaptive fusion; Classification; Bilateral filter; Domain transform filter of convolution

**OCIS Codes:** 100.4145; 100.5010; 300.6170; 280.0280; 110.4234;

基金项目: 国家自然科学基金项目 (Nos. 61275010, 61675051)、广东省高等职业教育品牌专业建设项目 (No. 2016gzpp044) 资助

第一作者: 廖建尚 (1982-), 男, 副教授, 硕士, 主要研究方向为高光谱图像处理、模式识别、嵌入式系统. Email: liaojianshang@126.com

收稿日期: 2016-10-28; 录用日期: 2016-12-21

<http://www.photon.ac.cn>

## 0 引言

空谱结合可改善高光谱图像的分类性能<sup>[1-3]</sup>,其中空间信息提取方法主要有形态滤波特征提取<sup>[4-5]</sup>、马尔科夫随机场特征提取<sup>[6-7]</sup>和图像分割特征提取<sup>[8-9]</sup>,其中用滤波器提取图像纹理信息来辅助光谱信息进行有效分类更是成为该领域的一个研究热点.

一些学者用 Gabor 滤波器<sup>[10]</sup>提取纹理信息来辅助高光谱分类. Tien 和 Shen 等利用多维 Gabor 滤波器来多角度提取图像的纹理信息,分类精度得到了提升<sup>[11-12]</sup>;Wang 等采用了 Gabor 滤波获取较好的空间特征,提出一种空谱结合的 S2ISC 半监督分类算法<sup>[13]</sup>和一种空谱标签传播的 SS-LPSVM 半监督分类算法<sup>[14]</sup>,Jia 等利用 Gabor 滤波器提取多维数据集特征,并结合稀疏表示提出一种有效的空谱结合分类方法 GS-MTJSRC<sup>[15]</sup>;Rajadell 等用 Gabor 滤波器对选取的部分波段提取空间特征,改善分类性能<sup>[16]</sup>.

另有学者用双边滤波(Bilateral Filter)<sup>[17-18]</sup>来提取高光谱空间纹理信息,如 Wang 等结合导向双边滤波和形态属性特征获取高光谱图像空间文本特征并有效改善分类精度<sup>[19]</sup>;Xia 等用改进的双边滤波器算法提取空间特征,提出了 E-ICA-RGF 算法对高光谱图像进行分类,提高了分类精度<sup>[20]</sup>;Kang 等先用向量机(Support Vector Machine, SVM)初始分类,利用分类结果再用双边滤波对分类进行优化,提出了边缘保持滤波分类方法(Edge-Preserving Filtering, EPF)<sup>[21]</sup>;Soomro 等用弹性网络回归方法获取初始分类结果,并通过双边滤波器获取空间信息,空谱结合后提出了一种有效的分类方法<sup>[22]</sup>.

还有学者用递归滤波<sup>[23]</sup>提取空间纹理信息,如 Kang 等对高光谱进行子集分割并融合,然后用递归滤波提取空间信息,并将其交由 SVM 实现分类,提出了图像融合递归滤波(Image Fusion and Recursive Filtering, IFRF)方法<sup>[24]</sup>,取得不错的效果.

这些研究取得了一定成效,但也存在一些不足:1)高光谱分类过程中未充分获取空间信息;2)单一的空间纹理信息难以获取完整的空间信息;3)利用滤波器提取纹理特征容易丢失像元空间相关性信息.为了利用空间信息提高高光谱分类性能,本文提出了一种结合双边滤波和域转换标准卷积滤波(Domain Transform Filter of Normalized Convolution, DTFONC)的高光谱图像分类算法(Domain Transform Filtering and Bilateral Filtering with SVM, DTBS-SVM),用双边滤波和域转换标准卷积滤波提取较完整的空间信息,以提高分类性能.

## 1 方法

### 1.1 空间纹理信息提取方法

#### 1.1.1 双边滤波器提取高光谱图像空间纹理信息

双边滤波器<sup>[17]</sup>是由 Tomasi 等在高斯滤波器基础上提出的一种改进双边滤波,双边滤波器有两个核函数,分别为空间核函数和强度核函数,对于有  $l$  个波段的高光谱图像集  $G$ ,利用像元在高光谱空间和幅度的相关性,给定滤波窗口  $S$ ,对高光谱图像的双边滤波器定义为

$$F^i(x, y) = \frac{\sum_m^n H^i(x, y, m, n) G^i(m, n)}{\sum_m^n H^i(x, y, m, n)} \quad i = 1, 2, \dots, k \quad m, n \in S \quad (1)$$

式中  $G^i(m, n)$  是高光谱图像集  $G$  第  $i$  个波段图像坐标为  $(m, n)$  中的一个像元,假设给定滤波窗口的半径为  $w$ ,则窗口的大小为  $(2w+1) \times (2w+1)$ ,  $(x, y)$  代表双边滤波器窗口中滤波像元位置,  $H^i(x, y, m, n)$  表达式为

$$H^i(x, y, m, n) = H_s(x, y, m, n) * H_r(x, y, m, n) \quad (2)$$

其中

$$H_s(x, y, m, n) = \exp \left[ -\frac{(m-x)^2 + (n-y)^2}{2\sigma_s^2} \right] \quad (3)$$

$$H_r(x, y, m, n) = \exp \left[ -\frac{|G^i(m, n) - G^i(x, y)|}{2\sigma_r^2} \right] \quad (4)$$

$H_s$  为空间距离核函数,其值由像元之间的空间距离决定,衡量高光谱像元的空间邻近度.  $(m,n)$ 和 $(x,y)$ 距离越大, $H_s$ 的值越小,反之则  $H_s$  越大,因此,在滤波像元的边界附近,距离大的像元不会影响到边界上的像元,参数  $\sigma_s$  控制着  $H_s$  的衰减程度. 反射强度核函数  $H_r$  的值由像元之间的反射强度之差决定,衡量高光谱像元反射强度的相似度.  $|G^i(m,n)-G^i(x,y)|$  的值越大, $H_r$ 的结果越小,  $|G^i(m,n)-G^i(x,y)|$  的值越小,  $H_r$  的结果越大,不同地物,其反射强度不一样,因而不影响不同地物间的边界保存,参数  $\sigma_r$  控制  $H_r$  的衰减程度,  $H_s$  和  $H_r$  通过式(2)共同构成双边滤波核.

滤波窗口对空间分辨率为  $a \times b$  的高光谱图像进行滑动和处理,对于  $(2\tau+1) \times (2\tau+1)$  大小的窗口,首先确定滤波窗口的边界值,横坐标的最小值  $x_{\min}$  和最大值  $x_{\max}$  分别用式(5)和(6)来计算,纵坐标的最小值和最大值  $y_{\min}$  和  $y_{\max}$  分别用式(7)和(8)来计算,Max 为求最大值函数,Min 为求最小值.

$$x_{\min} = \text{Max}(x-\tau, 1) \quad (5)$$

$$x_{\max} = \text{Min}(x+\tau, a) \quad (6)$$

$$y_{\min} = \text{Max}(y-\tau, 1) \quad (7)$$

$$y_{\max} = \text{Min}(y+\tau, b) \quad (8)$$

确定边界后通过移动滤波窗口来确定滤波范围,如图 1,滤波窗口从位置 A 开始滤波,先向左移动,到达 B 完成滤波后,继续向下和向右移动滤波,如图中 C、D、E、F 所示,到达 G 后,滤波结束. 其中位于高光谱图像滤波窗口的像元都参与对滤波窗口中心像元(黑点)的  $H_s$  和  $H_r$  计算,最后通过式(1)实现对窗口中心像元的滤波.

双边滤波通过空间距离核函数和反射强度核函数共同对图像进行滤波,具有良好的边界保持特性和去除噪音的效果,可以提取较为完整的空间纹理信息. 由于高光谱数据集波段多、数据量大,为了获取高光谱图像更全面的空间信息,先对高光谱数据归一化处理,然后对每个波段图像进行双边滤波,图 2 是高光谱图像双边滤波过程.

双边滤波具有较好的空间纹理提取功能,能保持较为完整的边缘信息,但是容易去除空间相关性信息,因此采用域转换标准卷积滤波来弥补双边滤波在高光谱滤波的不足.

### 1.1.2 域转换标准卷积滤波提取空间信息

域转换标准卷积滤波<sup>[23]</sup>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,有较好的离散噪声去除效果,对有  $l$  个波段的高光谱图像,第  $i$  个波段图像  $G_i$  的域转换标准卷积滤波在高光谱的定义为

$$T_i(u) = (1/K_u) \sum_{v \in D(\Omega)} G_i(v) H(f(u), f(v)) \quad (9)$$

式中,  $K_u$  为  $u$  的归一化因子,即

$$K_u = \sum_{v \in D(\Omega)} H(f(u), f(v)) \quad (10)$$

$H(f(u), f(v))$  是滤波核,表示为一个布尔函数,即




图 1 滤波窗口的移动过程

Fig. 1 Moving process of filter window

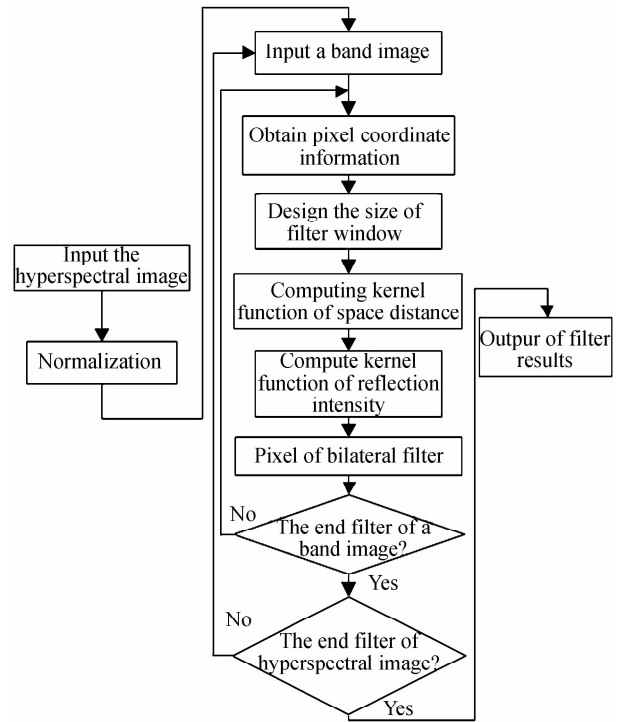


图 2 高光谱图像双边滤波

Fig. 2 Bilateral Filter for hyperspectral image

$$H(f(u), f(v)) = \delta\{|f(u) - f(v)| \leq r\} \quad (11)$$

式(11)表示像元邻域可认为是该像元的同种地物,  $\delta(F)$  为布尔函数, 因此域转换标准卷积滤波具有一定的空间相关性保持特性, 有

$$\delta(F) = \begin{cases} 1 & F \text{ is true} \\ 0 & \text{else} \end{cases} \quad (12)$$

$f(u)$  为对某个高光谱波段图像  $I_k$  求偏微分后的累加求和, 将其变换为递增函数, 二维图像滤波转换为一维图像滤波, 即

$$f(u) = \int_0^u 1 + \frac{\sigma_s}{\sigma_r} \sum_{l=1}^c \left| \frac{\partial I_k(x)}{\partial x} \right| dx \quad (13)$$

$r$  为滤波半径,  $\sigma_s$  为空间偏差系数,  $\sigma_r$  为范围偏差系数,  $\sigma_{J_h}$  表示为第  $h$  次迭代的数值,  $N$  是总迭代次数, 有

$$\sigma_r = \sqrt{3} \sigma_J \quad (14)$$

$$\sigma_{J_h} = \sigma_s \sqrt{3} \frac{2^{N-h}}{\sqrt{4^N - 1}} \quad (15)$$

因高光谱图像的波段多, 能达到几百个, 域转换标准卷积滤波将二维标准卷积滤波转换成一维标准卷积滤波, 并保持像元间的空间距离, 一方面大大提高了高光谱图像中的滤波效率, 另一方面保持了良好的空间相关性. 在滤波前, 先对高光谱数据作归一化处理, 再对每个波段图像进行域转换标准卷积滤波, 图 3 为高光谱域转换卷积的滤波流程.

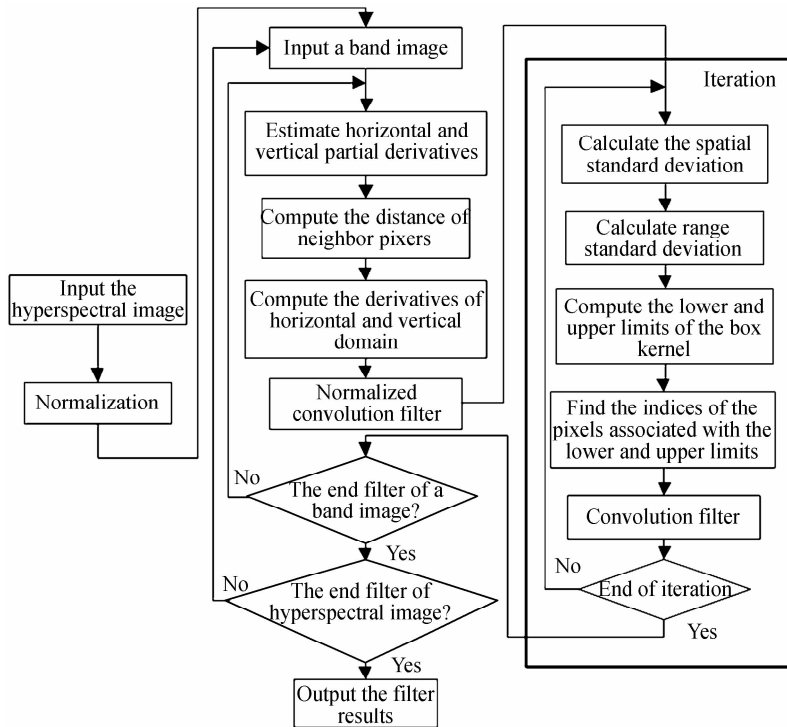


图 3 高光谱图像域转换标准卷积滤波  
Fig. 3 DTFONC for hyperspectral image

为了确定域转换标准卷积滤波空间偏差系数  $\sigma_s$ 、范围偏差系数  $\sigma_r$  和迭代次数  $N$  在分类中的作用, 用交叉验证法, 选择印第安农林图像作为实验数据, 随机抽取 10% 的训练样本和其他 90% 的测试样本进行验证, 为了简单起见, 平均 5 个波段选取 1 个波段降维成新的数据集, 先取  $\sigma_r = 0.3$ 、 $N = 3$ 、 $\sigma_s$  从 1 到 100 分别验证分类精度, 分类效果如图 3(a), 当  $\sigma_s = 60$  时, 整体分类精度 (Overall accuracy, OA)、平均分类精度 (Average accuracy, AA) 和 Kappa 统计系数 (Kappa statistic, Kappa) 综合分类性能较好; 然后取  $\sigma_s = 60$ 、 $N = 3$ 、 $\sigma_r$  从 0.01 到 0.5, 分类效果如图 3(b), 当  $\sigma_r = 0.12$  时分类性能最好, 三种系数综合分类性能较优; 最后取  $\sigma_s = 60$ 、 $\sigma_r = 0.12$ 、 $N$  从 1 到 10, 分类效果如图 3(c), 当  $N > 2$  时分类性能指标趋于平稳, 本文的域转换标准卷积滤波参数分别取  $\sigma_s = 60$ 、 $\sigma_r = 0.12$  和  $N = 4$ .

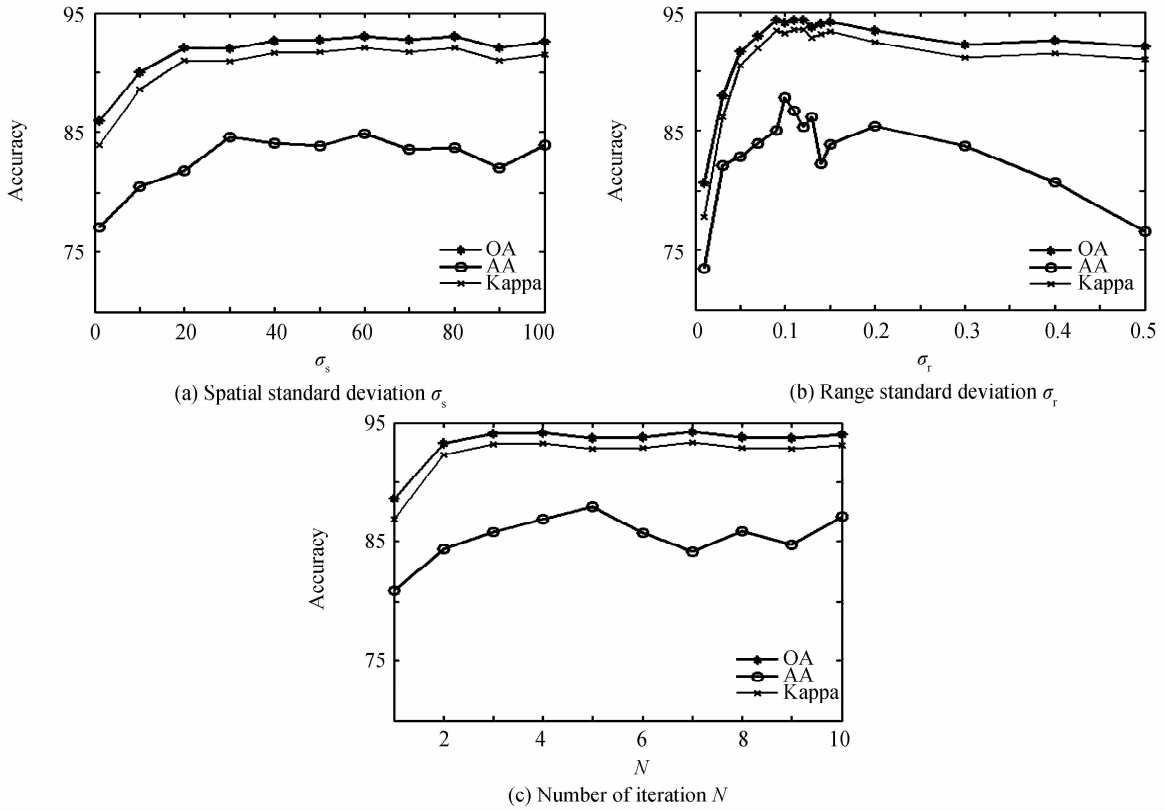


图4 印第安林数据的分类性能验证  
Fig. 4 Classification for Indian Pines data

## 1.2 两种空间信息自适应融合分类

高光谱像元间有较强的空间相关性,为了分析双边滤波和域转换滤波对纹理信息的滤波效果,用两种滤波器分别对第10个波段进行处理,图4(a)为第10个波段图像,(b)为双边滤波图像,(c)为域转换标准卷积滤波图像.从对比图来看,双边滤波可以提取较好的空间纹理信息,但是容易丢失地物空间相关性,域转换卷积能提取一定的纹理信息,也有较好的平滑作用,说明域转换卷积除了能提取纹理信息,还能保持一定的空间相关性.高光谱空间自相关性是空间像元的反射强度值与邻近像元的反射强度相关联的特性,引入Moran于1950年提出的Moran's I指数<sup>[25-26]</sup>来衡量其高光谱中每个波段图像的空间相关性,表达式为

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n \omega_{ij} (X_i - \bar{X})(X_j - \bar{X})}{\sum_{i=1}^n \sum_{j=1}^n \omega_{ij} \sum_{i=1}^n (X_j - \bar{X})^2} \quad (16)$$

式中, $X_i$ 代表高光谱某像元的反射强度, $X_j$ 代表其他像元的反射强度, $n$ 为像元数量, $\bar{X}$ 代表 $X$ 的均值, $\omega_{ij}$ 代表空间比重权重.将指数 $I$ 归一化为 $[-1, 1]$ , $I$ 值越大,代表空间相关性越强, $I$ 值越小,代表空间差异性越大.

为了验证双边滤波和域转换标准卷积滤波对空间自相关性的保持特性,用式(16)计算对印第安林第120个波段滤波后的Moran's I指数,如图5.其中图5(d)为双边滤波后的Moran's I指数,图5(e)为域转换标准卷积滤波的,图5(e)深色部分明显多于图5(d),说明域转换标准卷积滤波后的空间自相关性较好.

为了对比空间自相关性的保持特性,用两种滤波对印第安林数据集波段逐个滤波,计算每个波段的Moran's I指数并求其均值,如图6,从图可以看出,双边滤波比光谱波段的空間相关性还要差,域转换标准卷积滤波大部分Moran's I指数均值要高于双边滤波和光谱波段,验证了域转换标准卷积滤波有较好的空间相关性保持特性.




图 5 对印第安林数据集第 120 波段图像处理  
Fig. 5 The 120th band image processing for Indian Pines data




图 6 印第安林数据集的 Moran's I 指数的均值  
Fig. 6 Average of Moran's I for Indian Pines data

### 1.3 DTBS-SVM 分类算法

为了充分利用滤波器的空间纹理信息和空间自相关信息,将空间纹理信息和空间相关信息进行线性结合,共同构建更为全面的空间信息,为分类提供较好的空间特征.核函数支持的 SVM 将数据从低维空间向高维空间进行非线性映射,形成对特征空间划分的最优超平面,使得类间间隔最大化,从而更好地发挥 SVM 计算复杂度与输入空间映射的核空间维数无关的优势,实现正确分类.

因此,本文设计了一种空间信息自适应融合分类方法,首先用双边滤波提取空间纹理信息,用域转换标准卷积滤波提取空间相关性信息,然后将两种信息按照自适应方法进行提取和线性结合,最后由核函数支持的 SVM 完成分类,形成 DTBS-SVM 分类算法,实现步骤为:

1)归一化:高光谱中像元的反射强度数值较大,先按照式(17)对波段数为  $l$  的高光谱数据集进行归一化处理,得到信息量重新分布的高光谱图像数据集  $R$  为

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

2)高光谱降维与分组:对有  $l$  个波段的高光谱数据集  $R$  进行降维,平均每  $n$  个波段选取一个波段图像,抽取  $k_D$ (或者  $k_E$ )个波段图像组成新的数据集  $D$ ,将其余的波段组成数据集  $E$ ,即

$$k_D = \lfloor l/n \rfloor, n=2,3,\dots,l \quad (18)$$

$$k_E = l - k_D (\text{或 } k_D = l - k_E) \quad (19)$$

其中  $\lfloor \cdot \rfloor$  是向下取整符号.

3)双边滤波提取空间信息:用双边滤波对  $k_D$ (或者  $k_E$ )个波段数据集  $D$  按照式(1)进行双边滤波滤波,获取边缘空间信息  $D_{bs}$  为

$$D_{bs}^i = F(D^i) \quad (20)$$

4)域转换标准卷积滤波提取空间信息:用域转换标准卷积滤波对  $k_E$ (或者  $k_D$ )个波段数据集  $E$  按照式(3)进行滤波,获取空间信息  $E_{ts}$  为

$$E_{ts}^j = T(E^j) \quad (21)$$

5)空间纹理信息融合: $D_{bs}$  和  $E_{ts}$  按照式(16)进行线性结合成  $W$ , 即

$$W = D_{bs} + E_{ts} \quad (22)$$

6)分类:从空间信息数据集  $W$  中以一定比例随机抽取训练集  $W_s$ , 其余部分作为训练集  $W_t$ ; 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;用径向基函数支持的 SVM 对  $W_s$  进行训练,获取训练模型;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.

寻找最优分类性能分两步:1)设置  $Flag=0$ ,先用双边滤波器对抽取的  $k_D$  个波段的数据集滤波,再用域转换滤波对剩余  $k_E$  个波段的数据集滤波,然后按照式(16)进行融合,并交由 SVM 实现分类;2)设置  $Flag=1$ ,先用域转换滤波对抽取的  $k_D$  个波段的数据集滤波,再用双边滤波对剩余  $k_E$  个波段的数据集滤波,然后按照式(16)进行融合,并交由 SVM 实现分类,获得最优分类结果,自适应融合分类算法流程如图 7.

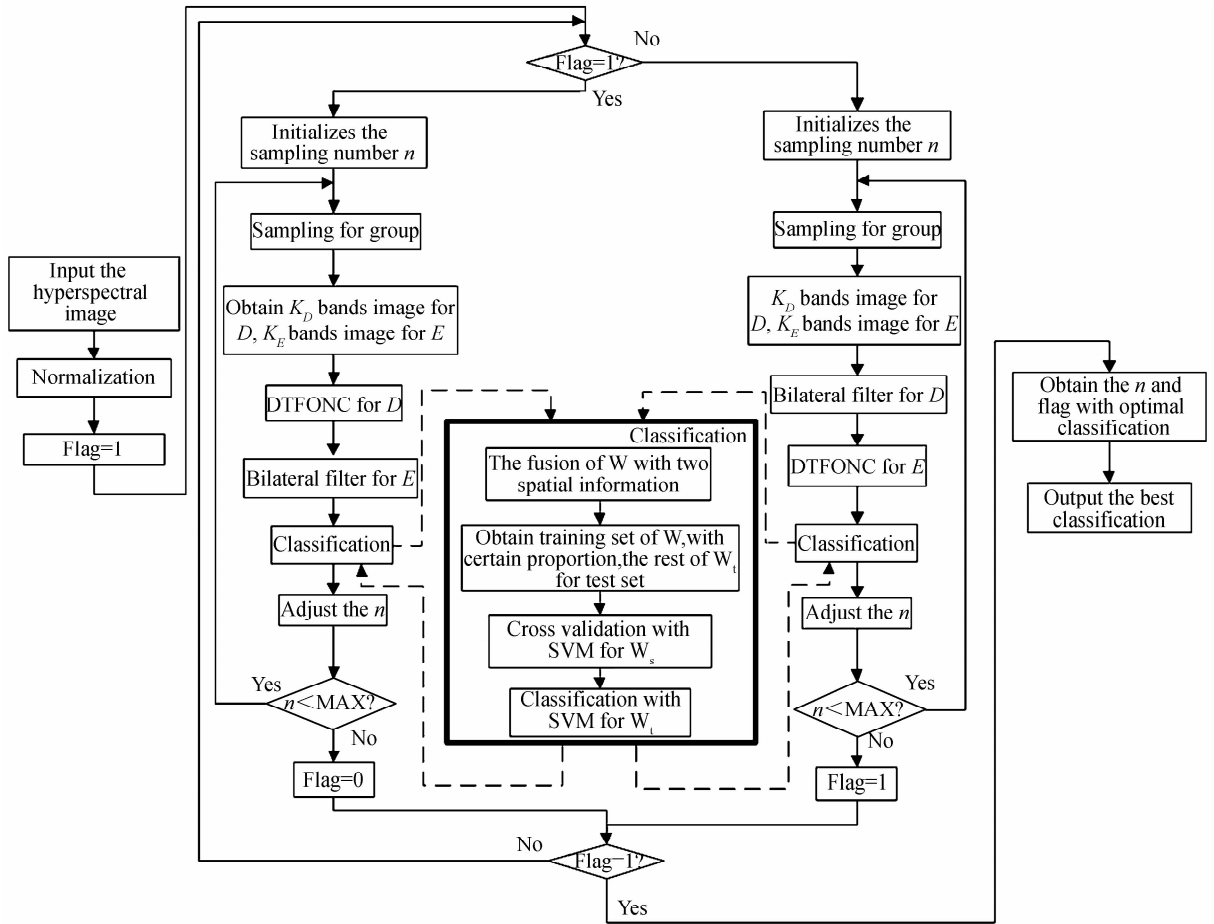


图 7 SGDS-SVM 算法流程图  
Fig. 7 Flow of SGDS-SVM

## 2 实验设计

### 2.1 实验数据集

为了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 2 个高光谱数据集进行验证.印第安农林数据集来自光谱仪 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  $144 \times 144$  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,包含 16 种植被,具体地物类别和样本个数见表 1.帕维亚大学数据集来自光谱仪 Reflective Optics System Imaging Spectrometer,是拍摄于帕维亚大学的高光谱遥感图像,包含  $610 \times 340$  个像元,115 个波段,由于噪声等因素去除其中 12 个波段,剩余的 103 个波段,包含 9 个类别,具体地物类别和样本个数见表 2.

表 1 印第安农林数据集图像分类数据统计  
Table 1 Classification statistics of Indian Pines data

Indian Class	Sample number			Spectrum SVM	Dimension reduce			Spatial-spectral			Edge-preserving		Recursive IFRF	Spatial fusion DTBS-SVM
	Sum	Train /%	Test /%		SVM-PCA	SVM-MDS	SGB-SVM	SBL-SVM	SGD-SVM	EPF-B-c	EPF-G-c			
Alfalfa	54	10	90	70.41	52.81	68.96	70.41	39.69	48.45	95.98	94.49	89.29	90.87	
Corn-no till	1434	5	95	72.30	69.62	70.82	72.30	83.65	85.49	88.57	89.70	91.74	94.37	

Corn-min till	834	5	95	63.80	65.47	62.56	63.80	81.97	87.71	82.26	72.97	85.89	97.73
Corn	234	5	95	32.73	38.21	34.56	32.73	24.84	45.09	43.47	53.82	80.41	87.08
Grass/pasture	497	5	95	84.10	86.62	83.48	84.10	89.54	91.47	91.71	82.49	91.95	92.62
Grass/trees	747	5	95	92.67	92.98	95.82	92.67	96.59	94.78	99.78	99.80	98.68	98.59
Grass/pasture-mowed	26	10	90	53.90	43.54	39.44	53.90	28.89	20.50	75.57	56.25	56.10	60.15
Hay-windrowed	489	5	95	97.46	97.55	96.54	97.46	98.77	96.43	100.00	99.50	99.57	99.57
Oats	20	10	90	31.54	30.55	46.23	31.54	25.51	10.49	8.75	6.88	49.88	67.28
Soybeans-no till	968	5	95	62.62	62.73	60.84	62.62	77.59	79.35	76.06	78.69	89.86	93.85
Soybeans-min till	2468	5	95	83.51	84.54	84.53	83.51	90.44	92.60	96.68	96.87	97.05	96.76
Soybeans-clean till	614	5	95	75.59	72.94	75.27	75.59	84.91	88.19	96.53	93.02	85.42	95.15
Wheat	212	5	95	95.91	94.36	89.71	95.91	98.01	96.47	99.95	89.60	89.35	99.50
Woods	1294	5	95	96.66	97.73	97.70	96.66	98.21	98.63	99.75	98.81	98.92	99.65
Bldg-Grass-Tree	380	5	95	43.09	43.56	34.61	43.09	54.91	63.17	59.64	61.31	90.30	96.23
Stone-steel towers	95	5	95	68.96	79.44	61.44	68.96	64.02	67.10	81.44	88.44	77.52	83.79
OA /%	-	-	-	78.20	78.46	77.73	78.20	85.62	87.88	90.11	89.08	93.08	96.10
AA /%	-	-	-	70.33	69.54	68.91	70.33	71.10	72.87	81.01	78.91	85.75	92.82
Kappa	-	-	-	74.93	75.21	74.34	74.93	83.52	86.13	88.63	87.42	92.09	95.55

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

Pavia	Sample number	Spectrum			Dimension reduce			Spatial-spectral			Edge-preserving		Recursive	Spatial fusion
Class	Sum	Train /%	Test /%	SVM	SVM-PCA	SVM-MDS	SGB-SVM	SBL-SVM	SGD-SVM	EPF-B-c	EPF-G-c	IFRF	DTBS-SVM	
Asphalt	6641	3	97	89.40	89.52	88.05	90.81	89.62	93.71	97.50	98.35	90.34	97.17	
Meadows	18649	3	97	96.54	95.98	96.18	96.60	98.05	99.42	99.99	99.94	99.48	99.78	
Gravel	2099	3	97	65.06	57.98	55.98	68.34	66.32	69.53	69.05	75.34	82.19	93.12	
Trees	3064	3	97	89.03	87.11	89.07	90.60	94.94	96.84	91.55	92.19	90.11	98.11	
Metal Sheets	1345	3	97	98.24	98.67	98.63	99.63	98.84	99.31	99.89	99.92	98.96	99.17	
Soil	5029	3	97	55.02	60.37	60.91	69.84	83.49	94.84	63.48	62.19	99.85	98.57	
Bitumen	1330	3	97	66.89	64.71	69.26	74.17	72.57	80.84	92.47	88.85	93.47	89.93	
Bricks	3682	3	97	78.14	78.61	78.61	79.52	82.98	78.02	98.93	97.27	83.69	94.22	
Shadows	947	3	97	87.72	85.68	90.00	91.56	90.23	91.62	96.26	93.75	65.54	95.68	
OA /%	-	-	-	85.81	85.67	85.87	88.55	91.01	93.77	92.78	92.78	94.27	97.89	
AA /%	-	-	-	80.67	79.85	80.74	84.56	86.34	89.35	89.90	89.76	89.29	96.19	
Kappa	-	-	-	80.83	80.68	80.96	84.65	88.01	91.70	90.21	90.21	92.40	97.20	

## 2.2 实验设计与评价指标

实验使用了 6 种方法进行比较. 方法 1: 利用文献[27]提出的 SVM; 方法 2: 利用文献[28]和[29]提出的主成分分析(Principle Component Analysis, PCA)和多维度分析(Multi-Dimensional Scaling, MDS)高光谱数据进行降维后, 用 SVM 进行分类, 即 SVM-PCA 和 SVM-MDS; 方法 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 降维, 采用前 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; 方法 4: 利用文献[25]提出的 EPF 算法对高光谱图像进行分类, 有 EPF-B-c 和 EPF-G-c; 方法 5: 用文献[28]提出的域转换递归滤波的方法 IFRF; 方法 6: DTBS-SVM.

本文用整体 OA、AA 以及 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, E5800, 6GBRAM.

## 2.3 实验验证

用 6 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, 其中验证方法为: 1) 印第安林数据集图像地物分布如图 8(a), 选取全部 16 个类别, 每类随机选取 5% 样本组成有标签训练集, 其余 95% 作为测试集, 地物数量较少的 10% 作为训练集, 表 1 为各种分类方法对印第安林数据集的分类精度统计, 分类效果如图 8; 2) 帕维亚大学数据集图像地物如图 9(a), 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。

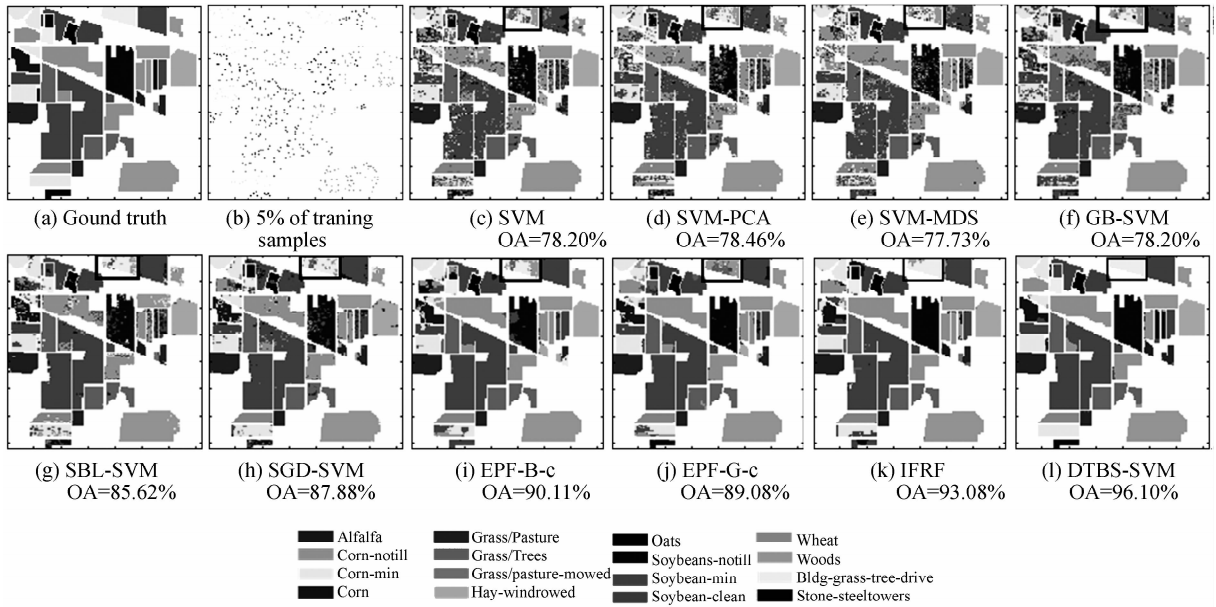


图 8 印第安农林数据集分类  
Fig. 8 Classification for Indian Pines data

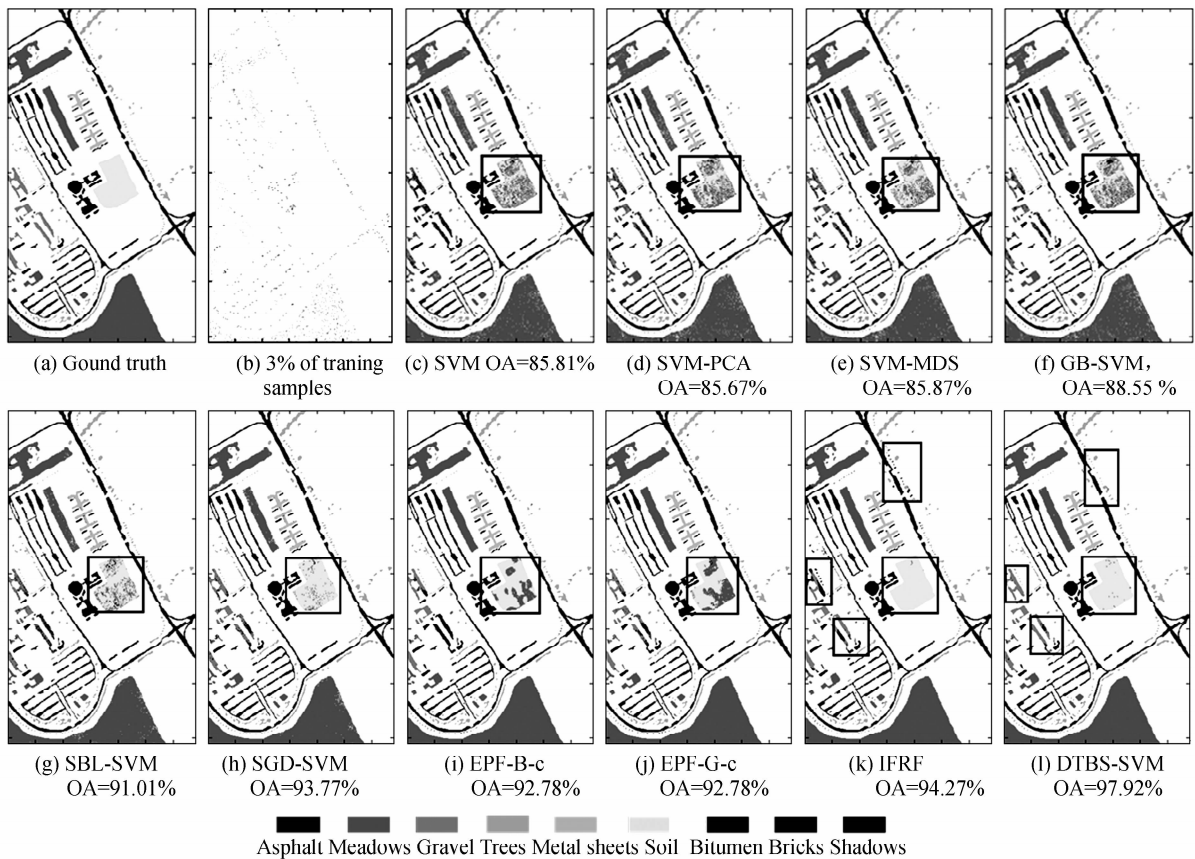


图 9 帕威亚大学数据集分类  
Fig. 9 Classification for Pavia University data

### 3 结果与分析

1) 用 DTBS-SVM 对两种数据集进行分类,其中印第安农林数据集的 OA 为 96.95%,帕维亚大学数据集的 OA 为 97.89%,比 SVM 整体分类精度高出 12~13 个百分点,比 SGB-SVM、SBL-SVM、SGD-SVM 高

出 3~9 个百分点,比 EPF 算法高出 2~8 个百分点,比 IFRF 算法高出 3~4 个百分点,充分验证了 DTBS-SVM 算法的有效性.

2)从印第安农林数据集分类结果可知,在训练样本仅为 5%,但是 OA 超过 96%,说明对地物多、分布复杂的高光谱数据有较好的效果,有效去除椒盐现象,尤其是黑框部分更为明显;帕维亚大学数据集分类训练样本仅为 3%,SGDS-SVM 同样可以达到较优的分类效果,从图 7 和图 8 可以看出,算法对数据集的分类效果提升明显,SGDS-SVM 有效地去除椒盐现象,尤其用方框部分效果更为明显.

3)为了验证 DTBS-SVM 算法的有效性,算法分两步寻优.对于印第安林数据, $n$  分别取集合[2 3 4 5 6 7 8 9 10 15 20 25 40],其中抽取样本数  $k_D$  分别为[100 67 50 40 34 29 25 23 20 15 10 8 5], $k_E$  分别为[100 133 150 160 166 171 175 177 180 185 190 195].图 10 是算法对印第安林的分类情况,训练抽样样本为 5%,从分析结果可以看出,Flag=0 时分类性能普遍好于 Flag=1,整体分类精度最高的是  $n=5$ 、 $k_D=40$  和  $k_E=160$ ,OA、AA 和 Kappa 分别是 96.10%、92.82%和 95.55.对于帕维亚大学, $n$  分别取[2 3 4 5 6 7 8 9 10 15 20 25 40],其中抽取样本数  $k_D$  为[52 35 26 21 18 15 13 12 11 7 6 5], $k_E$  为[51 68 77 82 85 88 90 91 92 96 97 98].图 11 是算法对帕维亚大学的分类情况,训练抽样样本为 3%,同样,Flag=0 时分类性能普遍好于 Flag=1,整体分类精度最好的是  $n=4$ 、 $k_D=26$  和  $k_E=77$ ,其中 OA、AA 和 Kappa 分别是 97.89%、96.19%和 97.20,从算法验证过程可知,Flag=0 时分类性能好于 Flag=1,可以得知,当域转换标准卷积滤波的波段数大于双边滤波时,分类性能较好.

4)从 DTBS-SVM 算法和方法 3 的实验来看,DTBS-SVM 对两类数据集的 OA 比方法 3 高出 3~9 个百分点,说明和单个滤波器提取空间纹理信息相比,采用双边滤波提取的空间纹理信息和域转换标准卷积滤波提取的空间相关信息线性结合后,用 SVM 进行分类的优势明显,验证了空间纹理信息和空间相关信息线性结合的巨大优势.

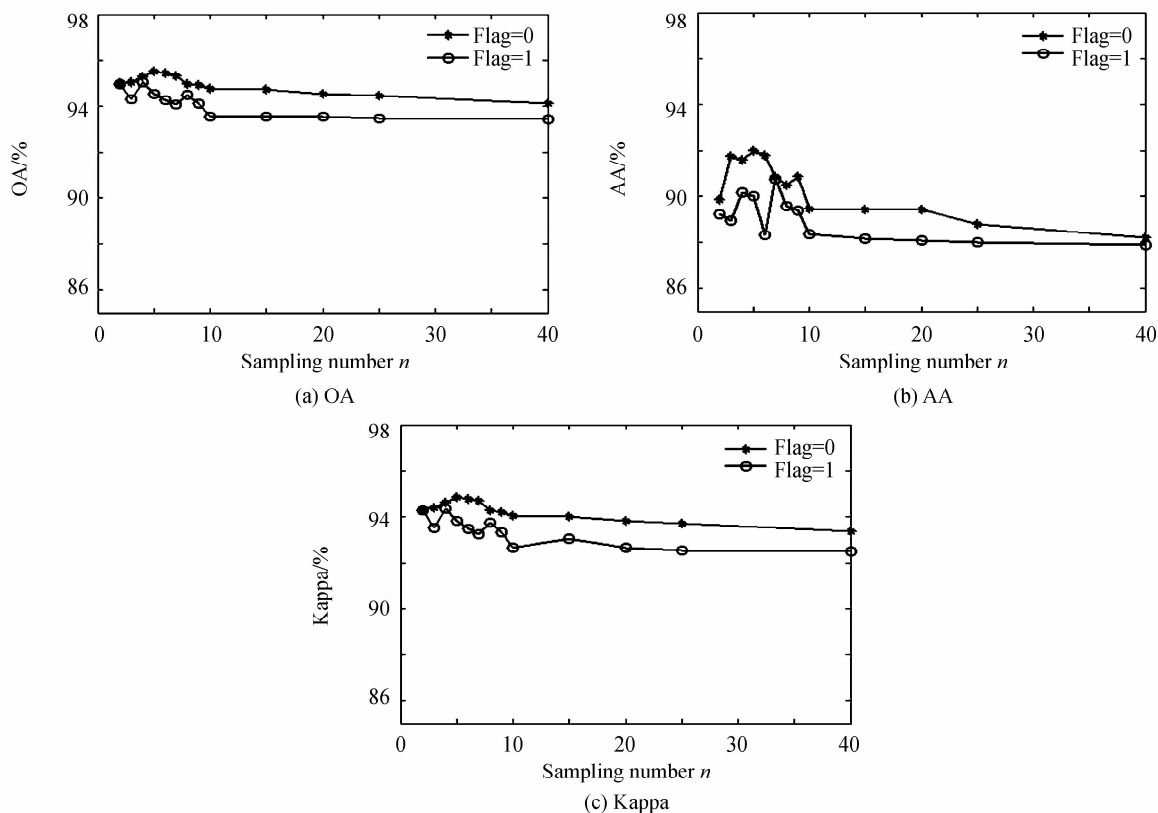


图 10 DTBS-SVM 对印第安林数据的寻优过程

Fig. 10 The optimization of DTBS-SVM for Indian Pines data

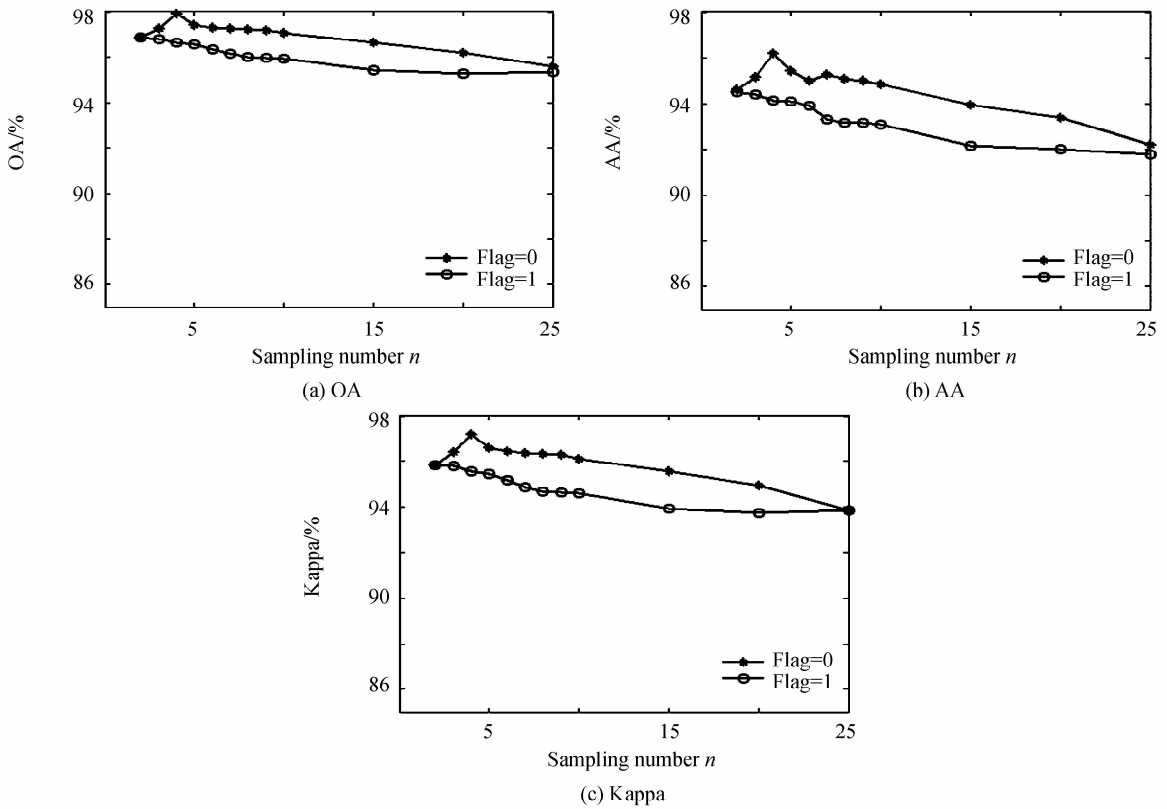


图 11 DTBS-SVM 对帕维亚大学数据的寻优过程  
Fig. 11 The optimization of DTBS-SVM for Pavia University data

5)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,如图 12. 印第安林总体分类精度在训练样本为 2%时提升较快,3%时的训练样本比例 OA 超过 93%;帕维亚大学总体分类精度 OA 在训练样本为 0.4%时超过了 90%,说明 DTBS-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。

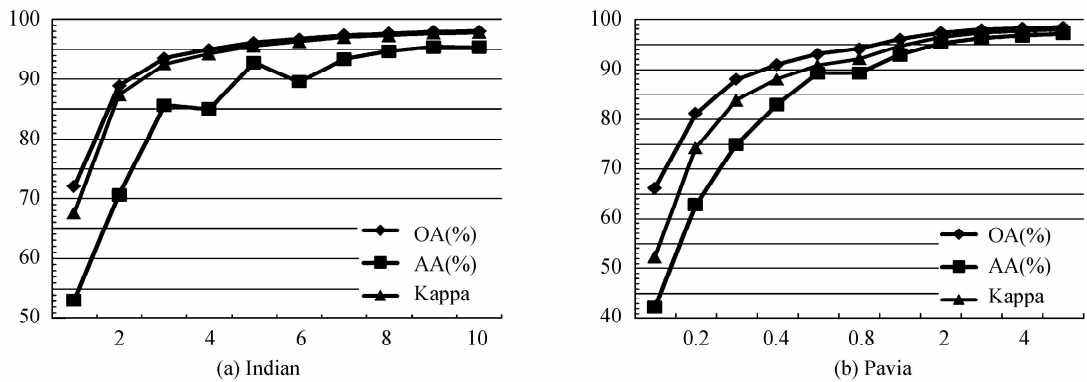


图 12 不同训练样本比例分类后 OA、AA 和 Kappa 折线图  
Fig. 12 Chart of OA, AA and Kappa with different training samples

## 4 结论

本文提出了用双边滤波和域转换标准卷积滤波结合的高光谱图像分类算法(DTBS-SVM),通过实验验证了 DTBS-SVM 算法优越性能.实验结果表明,DTBS-SVM 算法与单纯光谱信息 SVM 算法、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 算法相比,OA、Kappa 和 AA 都有较大幅度提高,对于地物类别较多,且分布较为复杂的高光谱数据更有优势,说明用双边滤波和域转换标准卷积滤波提取空间纹理信息融合后空间信息相互得到补充,能充分利用空间信

息来提高高光谱图像的分类精度。DTBS-SVM 算法有以下特点:1)域转换标准卷积滤波可以提取一定的空间纹理信息,并且保持较好的空间相关性,弥补双边滤波只能提取空间纹理信息的不足;2)双边滤波提取的空间纹理信息和域转换标准卷积滤波提取的空间相关信息线性结合后进行分类,有效利用了两种空间信息线性结合的优势;3)双边滤波和域转换标准卷积滤波提取空间纹理信息自适应融合后,通过核函数支持的 SVM 分类,获取最优分类性能,有效去除椒盐现象,尤其适用于地物较多分布复杂的高光谱数据。

### 参考文献

- [1] ZHANG Chun-sen, ZHENG Yi-wei, HUANG Xiao-bing, *et al.* Hyperspectral image classification based on the weighted probabilistic fusion of multiple spectral-spatial features [J]. *Acta Geodaetica et Cartographica Sinica*, 2015, **44**(8): 909-918.  
张春森, 郑艺惟, 黄小兵, 等. 高光谱影像光谱-空间多特征加权概率融合分类[J]. *测绘学报*, 2015, **44**(8): 909-918.
- [2] LI Tie, SUN Jin-guang, ZHANG Xin-jun, *et al.* Spectral-spatial joint classification method of hyperspectral [J]. *Chinese Journal of Scientific Instrument*, 2016, **37**(6): 1379-1389.  
李铁, 孙劲光, 张新君, 等. 高光谱遥感图像空谱联合分类方法研究[J]. *仪器仪表学报*, 2016, **37**(6): 1379-1389.
- [3] CHEN C, LI W, SU H, *et al.* Spectral-spatial classification of hyperspectral image based on kernel extreme learning machine[J]. *Remote Sensing*, 2014, **6**(6): 5795-5814.
- [4] 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 and Remote Sensing*, 2008, **46**(11): 3804-3814.
- [5] DALLA MURA M, BENEDIKTSSON J A, WASKE B, *et al.* Morphological attribute profiles for the analysis of very high resolution images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48**(10): 3747-3762.
- [6] ZHANG G, JIA X, KWOK N M. Spectral-spatial based super pixel remote sensing image classification[C]. *IEEE Image and Signal Processing (CISP)*, 2011, **3**: 1680-1684.
- [7] GHAMISI P, BENEDIKTSSON J A, ULFARSSON M O. Spectral-spatial classification of hyperspectral images based on hidden Markov random fields[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(5): 2565-2574.
- [8] LI J, BIOUCAS-DIAS J M, PLAZA A. Spectral-spatial hyperspectral image segmentation using subspace multinomial logistic regression and Markov random fields[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, **50**(3): 809-823.
- [9] 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.
- [10] SHEN L, BAI L. MutualBoost learning for selecting Gabor features for face recognition[J]. *Pattern Recognition Letters*, 2006, **27**(15): 1758-1767.
- [11] BAU T C, SARKAR S, HEALEY G. Hyperspectral region classification using a three-dimensional Gabor filterbank [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48**(9): 3457-3464.
- [12] SHEN L, JIA S. Three-dimensional Gabor wavelets for pixel-based hyperspectral imagery classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **49**(12): 5039-5046.
- [13] WANG L, HAO S, WANG Y, *et al.* Spatial-spectral information-based semisupervised classification algorithm for hyperspectral imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, **7**(8): 3577-3585.
- [14] WANG L, HAO S, WANG Q, *et al.* Semi-supervised classification for hyperspectral imagery based on spatial-spectral Label Propagation[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, **97**: 123-137.
- [15] 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.
- [16] RAJADELL O, GARCIA-SEVILLA P, PLA F. Spectral-spatial pixel characterization using Gabor filters for hyperspectral image classification[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, **10**(4): 860-864.
- [17] TOMASI C, MANDUCHI R. Bilateral filtering for gray and color images[C]. *Computer Vision*, 1998. Sixth International Conference on. IEEE, 1998: 839-846.
- [18] KOTWAL K, CHAUDHURI S. Visualization of hyperspectral images using bilateral filtering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48**(5): 2308-2316.
- [19] WANG K, HUANG R, SONG Q. Spectral-spatial hyperspectral image classification using extended multi attribute profiles and guided bilateral filter[C]. *Computer Science and Mechanical Automation (CSMA)*, 2015 International Conference on. IEEE, 2015: 235-239.
- [20] XIA J, BOMBRUN L, ADALI T, *et al.* Spectral-spatial classification of hyperspectral images using ICA and edge-preserving filter via an ensemble strategy[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, **54**(8): 4971-4982.
- [21] KANG X, LI S, 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.
- [22] SOOMRO S H, XIAO L, SOOMRO B N. Hyperspectral image classification via Elastic Net Regression and bilateral filtering[C]. *Progress in Informatics and Computing (PIC)*, 2015 IEEE International Conference on. IEEE, 2015: 56-60.
- [23] GASTAL E S L, OLIVEIRA M M. Domain transform for edge-aware image and video processing [C]. *ACM Transactions on Graphics (TOG)*. ACM, 2011, **30**(4): 69.
- [24] 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.
- [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 J, *et al.* Noise-adjusted principle component analysis for hyperspectral remotely sensed imagery visualization[C]. *IEEE Visualization*. 2005: 105.
- [29] Elder IV J F. Machine Learning, Neural, and Statistical Classification[J]. *Journal of the American Statistical Association*, 1996, **91**(433): 436-439.