

基于边缘保持滤波的高光谱影像光谱-空间联合分类

张成坤¹ 韩敏¹

摘要 针对高光谱遥感影像分类过程中, 高维数据引起的“维数灾难”以及空间邻域一致性信息没有得到充分利用的问题, 提出一种基于边缘保持滤波 (Edge-preserving filtering, EPF) 的高光谱影像光谱-空间联合分类算法. 该算法首先进行波段子集划分和主成分提取, 构造新的低维特征集, 在保存影像结构信息的前提下降低数据维度; 其次利用支持向量机 (Support vector machine, SVM) 获得低维特征集的初始分类概率图; 然后利用原始影像主成分对初始分类概率图进行边缘保持滤波, 融合光谱信息和空间信息; 最后根据滤波后分类概率图对应像素点值的大小确定每个像素的类别. 在 Indian Pines 和 Pavia University 两组高光谱数据上进行仿真实验, 相同实验条件下, 本文算法都获得最高分类精度和最少的时间消耗. 仿真结果表明本文算法在高光谱遥感影像分类任务中具有明显的优势.

关键词 高光谱, 边缘保持滤波, 支持向量机, 光谱-空间联合分类

引用格式 张成坤, 韩敏. 基于边缘保持滤波的高光谱影像光谱-空间联合分类. 自动化学报, 2018, 44(2): 280-288

DOI 10.16383/j.aas.2018.c160704

Spectral-spatial Joint Classification of Hyperspectral Image with Edge-preserving Filtering

ZHANG Cheng-Kun¹ HAN Min¹

Abstract To deal with the problem of “curse of dimensionality” caused by high dimension and the underutilization of spatial context information in classification of hyperspectral images, a new spectral-spatial joint classification method based on edge-preserving filtering is proposed. The proposed method consists of the following four steps. Firstly, the hyperspectral image is divided into several subsets of bands. By extracting the principal component of each subset, a new low-dimensional feature set is constructed. Secondly, the pre-classification result, which is obtained by support vector machines with the new feature set, is represented as multiple initial probabilistic maps. Then edge-preserving filtering is operated on each initial probabilistic map to merge the spectral and spatial information. Finally, the class of each pixel is determined by the maximum value of the corresponding filtered probabilistic maps. The proposed algorithm is examined by the Indian Pines and Pavia University hyperspectral datasets. On the same experimental conditions, the proposed method achieves the highest classification accuracy and the lowest time consumption, demonstrating obvious advantages in hyperspectral image classification.

Key words Hyperspectral, edge-preserving filtering (EPF), support vector machine (SVM), spectral-spatial joint classification

Citation Zhang Cheng-Kun, Han Min. Spectral-spatial joint classification of hyperspectral image with edge-preserving filtering. *Acta Automatica Sinica*, 2018, 44(2): 280-288

高光谱遥感是一种将成像技术与光谱技术相结合的多维信息获取技术, 它在数百个非常窄且连续

的光谱波段上同时探测目标的几何空间信息与光谱信息, 实现成像与成谱的融合^[1]. 与多光谱遥感成像技术相比, 高光谱遥感的每一个观测像素都可以提取出一条完整且连续的光谱曲线, 为地物信息的提取和分析提供极其丰富的信息, 例如精细分类、混合像元分解、目标探测等^[2-3]. 然而波段数的增多必然导致信息的冗余和数据处理复杂度的增加. 较高的光谱分辨率在增强地物细微差别分辨能力的同时, 也带来“维数灾难”, 严重影响高光谱影像的分类精度^[4]. 因此, 建立适用于高维样本的分类器是高光谱数据分析研究的重点. 旋转森林^[5]、AdaBoost^[6]、支持向量机 (Support vector machine, SVM)^[7]、主动学习^[8] 等适用性更强的分类方法相继提出, 促进了

收稿日期 2016-10-09 录用日期 2017-02-21
Manuscript received October 9, 2016; accepted February 21, 2017

国家自然科学基金 (61773087, 61374154), 中央高校基本科研业务费 (重点类项目) (DUT17ZD216), 国家自然科学基金委科学仪器基础研究专项 (51327004) 资助

Supported by National Natural Science Foundation of China (61773087, 61374154), Fundamental Research Funds for the Central Universities (DUT17ZD216), and Special Fund for Basic Research on Scientific Instruments of the National Natural Science Foundation of China (51327004)

本文责任编辑 桑农

Recommended by Associate Editor SANG Nong

1. 大连理工大学电子信息与电气工程学部 大连 116023

1. Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116023

高光谱遥感影像分类的发展. 其中 SVM 分类器由于核函数的引入能够有效缓解“维数灾难”的影响, 并且使用相对较少的训练样本就能获得较高的分类精度, 因此广泛应用于高光谱影像的分析与处理中. 此外, 在高光谱遥感影像中像素点不是相互独立、无序排列的光谱特征向量, 空间位置相邻的像素往往属于同类地物, 即地物分布具有邻域一致的特性^[9]. 综合利用高光谱影像的光谱特征和空间特征, 构建光谱-空间联合分类模型是遥感影像精确解译的重要突破点^[9-10]. Camps-Valls 等提出组合核支持向量机 (Support vector machine with composite kernels, SVMCK), 通过组合核来融合光谱和空间特征^[11]. Benediktsson 等提出扩展形态学特征 (Extended morphological profiles, EMP), 用来构建光谱-空间特征, 进行联合分类^[12]. Tarabalka 等利用基于分水岭变换的图像分割技术和多数投票机制实现基于对象的分类, 得到更平滑的地物分类图^[13]. 这些方法都成功将不同形式的空间上下文信息融入到支持向量机中, 并获得满意的分类效果. 针对高光谱遥感影像分类过程中的“维数灾难”和“椒盐现象”, 并在相邻波段包含较强冗余信息和相邻像素之间光谱具有很强的相关性两个特点的前提下, 利用波段融合技术和边缘保持滤波 (Edge-preserving filtering, EPF) 技术, 提出一种基于边缘保持滤波的光谱-空间联合分类算法. 通过波段子集划分和主成分提取, 将具有较强相关性的波段子集组合为一个噪声小、蕴含丰富结构信息的特征集, 降低数据维数. 为了充分利用边缘保持滤波器保持邻近地物一致性、并且保留地物边界的优势, 首先训练支持向量机获得每个像素的初始分类概率; 然后提取原始影像主成分作为参考图像, 对由所有像素初始分类概率组成的分类概率图进行边缘保持滤波; 像素点的类别由滤波后分类概率图对应值的大小确定.

本文结构组织如下, 第 1 节简要介绍本文所用的两种边缘保持滤波器; 第 2 节详细阐述初始概率图构造原理和基于边缘保持滤波的高光谱影像分类方法; 第 3 节为实验分析和对比; 最后是结论.

1 边缘保持滤波

高光谱遥感影像在采集、获取以及传输的过程中, 往往会引入不同类型的噪声, 导致同种地物的光谱特征呈现不同程度的波动, 给小训练样本下高光谱遥感影像的精确分类带来了极大的困难. 空间滤波是消除噪声影响的重要手段之一, 可以有效地缓解“同物异谱”现象, 提高分类精度. 近年来边缘保持滤波已成为图像处理领域非常活跃的研究课题并应用在许多方面, 例如立体匹配、图像融合、图像增强、降噪去雾等. 边缘保持滤波也在高光谱影像可

视化中得到成功应用^[14]. 双边滤波和引导滤波是两种典型的边缘保持滤波方法, 它们共同的特点是能够提取参考图像中蕴含边缘信息的空间约束因子对原始图像进行处理, 达到平滑保边的目的.

1.1 联合双边滤波

联合双边滤波器是一种对图像空间距离和像素值相似度进行折衷处理的滤波方法, 它同时考虑空域信息和灰度信息, 进行保边去噪. 其数学原理如下^[14-15]:

$$O_i = \sum_{j \in \omega_i} W_{i,j} I_j$$

$$W_{i,j} = \frac{1}{K_i^b} G(i, j) F(\hat{I}_i, \hat{I}_j) \quad (1)$$

其中, i 是空间邻域 ω_i 中心像素的位置, I_i 是待处理图像第 i 个像素的灰度值, \hat{I}_i 是参考图像对应像素的灰度值, $W_{i,j}$ 为滤波器的权值, $G(i, j)$ 为像素空间距离函数, $F(\hat{I}_i, \hat{I}_j)$ 为像素灰度值相似性函数, K_i^b 为归一化系数, 且 $K_i^b = \sum_{j \in \omega_i} G(i, j) F(\hat{I}_i, \hat{I}_j)$. 一般 $G(i, j)$ 和 $F(\hat{I}_i, \hat{I}_j)$ 为高斯函数, 即

$$G(i, j) = e^{-\frac{\|i-j\|^2}{2\sigma_s^2}}$$

$$F(\hat{I}_i, \hat{I}_j) = e^{-\frac{\|\hat{I}_i - \hat{I}_j\|^2}{2\sigma_w^2}} \quad (2)$$

从式 (2) 可以看出, 对于区域 ω_i 内部的近邻像素点, 其灰度值比较相似, 该滤波器起到平滑邻域空间的作用. 对于处于地物边界上的像素点, 对应的像素灰度值相似性权重小, 因而可以减小不同地物之间的干扰. 所以, 联合双边滤波器在有效消除噪声干扰的基础上, 可以尽可能保留地物边界.

1.2 引导滤波

引导滤波器假设图像是一个二维函数, 并且该滤波函数的输出与输入在一个二维窗口内满足如下线性关系^[15]:

$$O_i = a_k I_i + b_k, \quad \forall i \in \omega_k \quad (3)$$

其中, O_i 是输出图像的像素值, I_i 是输入图像的像素值, ω_k 是以像素点 k 为中心的邻域, a_k 和 b_k 是满足该线性函数的系数. 输入图像既可以是待滤波的图像本身, 也可以是参考图像. 对上式两边取梯度, 可以得到 $\nabla O_i = a_k \nabla I_i$, 即当输入图像 I 在第 i 个像素点有梯度时, 输出 O 也有类似的梯度, 因此引导滤波有边缘保持特性. 线性函数 (3) 系数的解要保证输出值与真实值 p 之间的差距最小, 因此引导滤波器目标函数定义为^[15]

$$E(a_k, b_k) = \sum_{j \in \omega_k} \left((a_k \hat{I}_j + b_k - p_j)^2 + \varepsilon a_k^2 \right) \quad (4)$$

其中, p 是待滤波图像, \hat{I} 是滤波参考图像. ε 用于防止所求 a_k 过大. 第 i 个像素的输出可以表示为

$$O_i = \sum_j W_{i,j} p_j$$

$$W_{i,j} = \frac{1}{|\omega|^2} \sum_{k:(i,j) \in \omega_k} \left(1 + \frac{(\hat{I}_i - \mu_k)(\hat{I}_j - \mu_k)}{\sigma_k^2 + \varepsilon} \right) \quad (5)$$

其中, $|\omega|$ 为邻域 ω 中像素点的个数. 引导滤波器能够像双边滤波器一样保持边缘平滑, 但是它在边缘附近有更好的表现.

2 基于边缘保持滤波的光谱-空间联合分类

2.1 SVM 初始分类概率图构造

传统高光谱影像光谱-空间联合分类主要概括为两种: 1) 提取高光谱影像的空间特征, 然后综合光谱特征进行分类; 2) 对高光谱影像进行超像素分割, 然后利用不同的方法确定超像素的类别, 得到分类结果. Kang 等提出一种利用空间约束因子对分类结果图直接进行分类的方法, 并且通过实验证明方法的可行性^[15]. 该方法直接将高光谱影像分类结果对应的二值图作为各个类别的初始分类概率图, 利用空间约束因子对其进行加权. 由于每个初始分类概率图的像素值只有 $\{0, 1\}$ 两个值, 很大程度上削弱了空间信息的作用强度. 本文采用 One-versus-one 多分类支持向量机 (OVO SVMs) 构造每个类别的初始分类概率图, 既保证初始分类精度, 同时增加空间约束因子作用强度, 加强空间信息的利用程度.

对于数据集 $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)\}$, $\mathbf{x}_i \in \mathbf{R}^d$ 为 d 维特征向量, $y_i \in \{1, -1\}$ 为类别标签. SVM 将 \mathbf{x}_i 映射到线性可分的高维 Hilbert 空间 Φ 中构造二分类问题

$$\min_{\omega, b, \xi_i} \left(\frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l \xi_i \right)$$

$$\text{s.t. } y_i ((\omega \cdot \Phi(\mathbf{x}_i)) + b) \geq 1 - \xi_i$$

$$\xi_i \geq 0, \quad i = 1, \dots, l \quad (6)$$

其中, ω , b 为 SVM 的系数和偏置, $C > 0$ 是惩罚参数, C 越大表示对错误分类的惩罚越大, ξ_i 是松弛因子.

利用拉格朗日乘子法将式 (6) 转换为对偶问题

$$\max_{\alpha} \left(\sum_{j=1}^l \alpha_j - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) \right)$$

$$\text{s.t. } \sum_{i=1}^l y_i \alpha_i = 0$$

$$0 \leq \alpha_i \leq C, \quad i = 1, \dots, l \quad (7)$$

其中, $K(\mathbf{x}_i, \mathbf{x}_j) = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j))$ 为核函数, α_i 为拉格朗日乘子. 最终得出分类决策函数

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^l \alpha_i^* y_i K(\mathbf{x}, \mathbf{x}_i) + b^* \right) \quad (8)$$

其中, α_i^* 为式 (7) 的最优解, b^* 为最优偏置, $\text{sgn}(\cdot)$ 为符号函数^[7].

SVM 最初是为二分类问题设计, 本文采用 One-versus-one 策略构造多分类 SVM 对高光谱遥感影像进行预处理, 在任意两个类别之间训练一个 SVM. 对于有 c 个类别的样本集, 需要训练 $c(c-1)/2$ 个 SVM 完成多分类. 当对一个未知样本进行分类时, 统计所有 SVM 的决策结果, 得票最多的类别为该未知样本的类别, 每一类所得票数的比例视为该样本属于这一类的概率. 利用 OVO SVMs 对高光谱遥感影像进行分类, 根据影像中每个像素点属于第 n 类的概率构造初始分类概率图 P_n ($n = 1, \dots, c$), $P_{i,n} \in [0, 1]$ 为像素点 i 属于第 n 类的概率

$$P_{i,n} = \frac{2N_{i,n}}{c(c-1)} \quad (9)$$

其中, c 为类别数目, $N_{i,n}$ 为 OVO SVMs 中决策结果为第 n 类的 SVM 个数. 利用上述方法获得的初始分类概率图 P_n 既有较高的分类精度, 同时可以保留更多的分类概率信息来增加空间约束因子的作用强度, 加强空间信息的利用程度.

2.2 基于边缘保持滤波的高光谱影像分类

针对高光谱遥感影像分类过程中的“维数灾难”和“椒盐现象”, 在相邻波段包含较强冗余信息和相邻像素之间光谱具有较强相关性两个特点的前提下, 本文提出一种基于边缘保持滤波的光谱-空间联合分类算法. 其中波段子集划分和主成分提取能够有效降低数据维数和去除噪声, 并且能够更好地保存影像结构信息. 边缘保持滤波能够增加局部区域的平滑性, 并突出边缘信息. 其主要流程如图 1 所示.

1) 在高光谱影像中, 由于其较高的光谱采样率, 相邻波段往往具有很强的相关性, 造成数据的冗余. 将相关性较强的波段融合为一个特征既不损失原有信息, 又能降低计算复杂度. 根据式 (10) 将原始影像分割为 K 个波段子集, 第 k 个子集表示为

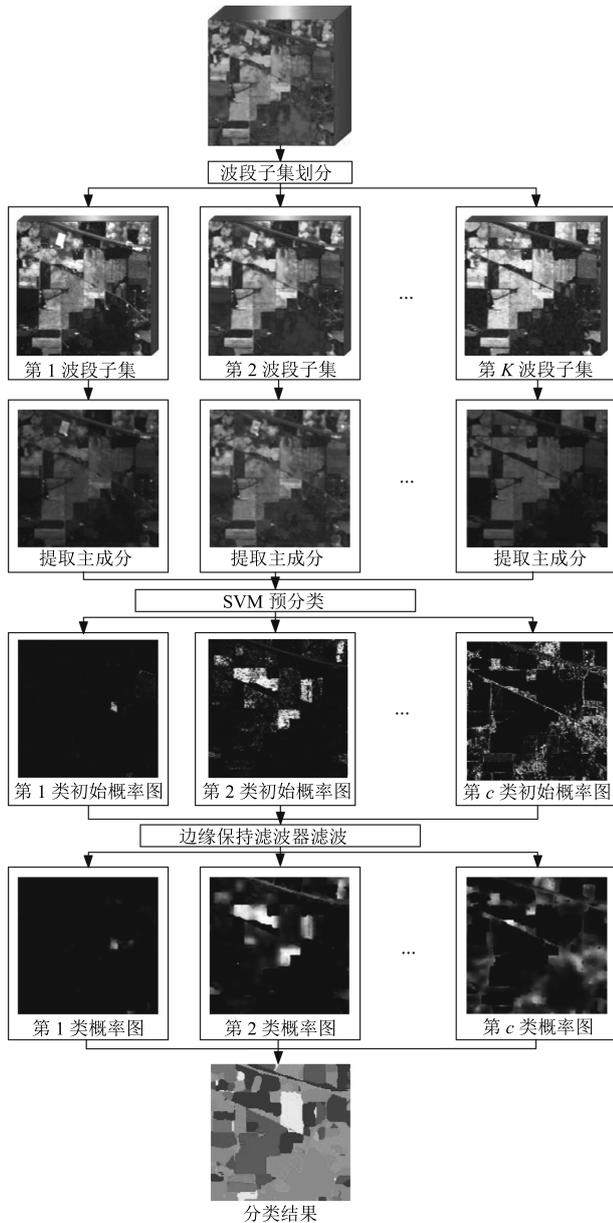


图 1 算法主要流程

Fig. 1 The procedure of the proposed method

$$Q^k = \begin{cases} \{\mathbf{x}_{1+(k-1) \times \lfloor \frac{D}{K} \rfloor}, \dots, \mathbf{x}_{(k \times \lfloor \frac{D}{K} \rfloor)}\}, & \text{若 } k \times \lfloor \frac{D}{K} \rfloor \leq D \\ \{\mathbf{x}_{1+(k-1) \times \lfloor \frac{D}{K} \rfloor}, \dots, \mathbf{x}_D\}, & \text{若 } k \times \lfloor \frac{D}{K} \rfloor > D \end{cases} \quad (10)$$

其中, $X = [\mathbf{x}_1, \dots, \mathbf{x}_D]^T \in \mathbf{R}^{D \times J}$ 表示原始高光谱数据集, D 为波段维数, J 为像素个数, $\lfloor D/K \rfloor$ 表示不大于 D/K 的最大整数. 对每个波段子集进行

主成分分析, 选取第一主成分作为该波段子集的特征, 以最大程度保留原始影像蕴含的信息. 通过提取波段子集中相关性较强波段的主成分, 能够有效去除噪声, 并且更好地保存影像结构信息.

2) 利用 SVM 对光谱信息进行分类得到的图像噪点比较多, 即“椒盐现象”比较明显, 结合边缘保持滤波能够增加局部区域的平滑性, 并突出边缘信息. 为了便于边缘保持滤波处理, 利用 SVM 得到分类概率图 $P_n (n = 1, \dots, c)$, 其中

$$P_{i,n} = \frac{2N_{i,n}}{c(c-1)} \quad (11)$$

3) 对初始分类概率图进行滤波处理, 利用 PCA 提出原始影像主成分, 作为双边滤波器的参考图像, 对初始分类概率图 P_n 进行滤波处理^[15]

$$\hat{P}_{i,n} = \sum_{j \in \omega_i} W_{i,j}(I) P_{j,n} \quad (12)$$

其中, $W_{i,j}$ 为边缘保持滤波器输出权值, 联合双边滤波器和引导滤波器的输出权值如式 (1) 和式 (5) 所示.

4) 每个像素的类别由滤波后所有分类概率图对应像素点值的大小确定, 像素点值最大的分类概率图对应的类别即为该点类别^[15]

$$M_i = \arg \max_n \hat{P}_{i,n} \quad (13)$$

该算法建立在相邻波段包含较强冗余信息和相邻像素之间光谱具有较强相关性两个特点的前提下, 利用波段融合有效去处噪声并保存影像结构信息, 通过边缘保持滤波增加局部区域的平滑性, 并突出边缘信息.

3 实验仿真

为了验证所提分类算法的有效性, 本文在 Indian Pines 和 Pavia University 两组高光谱数据集上进行仿真实验, 验证算法的有效性.

3.1 实验数据

Indian Pines 高光谱遥感影像是由 AVIRIS 传感器采集得到, 该影像地面空间分辨为 20 米, 大小为 145 像素 × 145 像素, 含有 220 个波段, 去除噪声通道频带后保留 200 个波段. 该数据集包含 16 种已知地物共 10 366 个样本. 由于该数据集中地物光谱特征的相似程度很高, 同时各类样本的数目很不均衡, 给高精度分类带来极大的挑战, 因此被广泛用于高光谱影像分类算法的性能测试.

Pavia University 高光谱遥感影像是由 ROSIS 传感器采集得到, 该影像地面空间分辨率为 1.3 米,

大小为 610 像素 × 340 像素, 共包含 115 个波段. 去除其中水吸收严重的 12 个波段, 将其余 103 个波段作为待处理的高光谱数据集. 该数据集涉及 9 种感兴趣地物, 共 42 776 个样本.

3.2 实验分析

为测试本文算法的性能, 将本文算法与代表性的光谱特征和空间特性联合分类的方法进行对比, 包括组合核支持向量机 (SVMCK)^[11]、EPF^[15]. 本文使用的评价指标包括每类的分类精度、总体分类精度 (Overall accuracy, OA)、平均分类精度 (Average accuracy, AA)、Kappa 系数、消耗时间. 实验中将 10 次重复实验的平均精度作为各算法的分类性能评价. 支持向量机和组合核支持向量机的核参数采用网格搜索和五折交叉验证的方法获得. 实验环境为 Windows 10 系统, Intel dual-core 3.5 GHz CPU, 8 GB RAM.

3.2.1 Indian Pines 数据集

在 Indian Pines 数据集上进行仿真实验, 仿真过程中训练和测试样本固定, 如表 1 所示, 其中训练

样本约占 10%, 测试样本约占 90%.

1) 为了从直观上说明边缘保持滤波器的有效性, 首先对 SVM 得到的第 6 个初始分类概率图 (如图 2 (a)) 进行边缘保持滤波, 其中参考滤波图像为原始影像的第一个主成分, $W_{i,j}$ 为双边滤波器输出权重系数, 其结果如图 2 (b) 所示. 可以看出利用双边滤波对分类结果进行后处理能够有效地缓解分类中产生的“椒盐现象”, 并且起到了平滑局部邻域、保留地物边界的效果, 最大程度上保证了分类的合理性与可读性, 这在遥感影像分类中有非常重要的意义.

2) 分析波段子集个数 K 对分类结果的影响. 如图 3 所示, 随着波段子集个数的增加, 分类精度呈现增加的趋势, 当波段子集个数为 30 时, 两种边缘保持滤波方法均取得比较理想的结果. 其中 PC1 代表第一个主成分作为滤波器的参考图像, PC3 代表前三个主成分作为参考图像. 在该影像中, 基于引导滤波的方法最优分类结果要高于基于联合双边滤波的方法, 主要原因是双边滤波器在地物边界连续变化时高斯权重不稳定, 出现“梯度伪影”, 影响了分类精

表 1 Indian Pines 数据集不同方法分类精度

Table 1 Classification accuracy for the Indian Pines dataset using different methods

| 类别 | 训练样本 | 测试样本 | SVM (%) | SVMCK (%) | EPF-B-g (%) | BFSVM-PC1 (%) | BFSVM-PC3 (%) | GFSVM-PC1 (%) | GFSVM-PC3 (%) |
|-------------|------|-------|---------|---------------|---------------|---------------|---------------|---------------|---------------|
| 1 | 8 | 38 | 73.68 | 75.00 | 90.91 | 100.00 | 100.00 | 100.00 | 100.00 |
| 2 | 143 | 1 285 | 77.37 | 89.31 | 93.17 | 99.83 | 99.58 | 99.59 | 99.83 |
| 3 | 83 | 747 | 78.13 | 88.81 | 98.98 | 97.46 | 97.59 | 97.58 | 97.72 |
| 4 | 24 | 213 | 76.27 | 77.25 | 96.30 | 98.98 | 98.98 | 98.51 | 98.53 |
| 5 | 48 | 435 | 92.30 | 94.85 | 99.02 | 98.82 | 98.82 | 99.52 | 98.81 |
| 6 | 73 | 657 | 90.43 | 98.81 | 97.76 | 99.85 | 99.85 | 100.00 | 99.85 |
| 7 | 8 | 20 | 88.88 | 93.75 | 100.00 | 100.00 | 100.00 | 100.00 | 100.00 |
| 8 | 48 | 430 | 97.48 | 98.18 | 100.00 | 100.00 | 100.00 | 100.00 | 100.00 |
| 9 | 8 | 12 | 38.09 | 100.00 | 100.00 | 100.00 | 100.00 | 100.00 | 100.00 |
| 10 | 97 | 875 | 77.05 | 85.30 | 93.61 | 98.74 | 98.89 | 99.13 | 98.76 |
| 11 | 246 | 2 209 | 80.46 | 92.98 | 95.38 | 94.47 | 94.13 | 94.01 | 93.73 |
| 12 | 59 | 534 | 79.34 | 87.16 | 91.58 | 96.32 | 96.15 | 97.94 | 97.94 |
| 13 | 21 | 184 | 87.80 | 97.91 | 99.46 | 100.00 | 100.00 | 100.00 | 100.00 |
| 14 | 127 | 1 138 | 90.93 | 96.82 | 97.76 | 97.14 | 97.15 | 95.90 | 97.57 |
| 15 | 39 | 347 | 74.89 | 73.10 | 94.74 | 96.65 | 96.35 | 96.20 | 97.01 |
| 16 | 9 | 84 | 90.69 | 96.47 | 92.41 | 98.67 | 98.51 | 98.48 | 98.59 |
| OA (%) | | | 82.87 | 91.28 | 95.84 | 97.42 | 97.33 | 97.29 | 97.43 |
| AA (%) | | | 80.86 | 90.36 | 96.32 | 98.56 | 98.50 | 98.55 | 98.65 |
| κ 系数 | | | 0.8038 | 0.9004 | 0.953 | 0.971 | 0.969 | 0.969 | 0.971 |
| 时间 (s) | | | 159.42 | 210.44 | 159.47 | 34.00 | 33.25 | 29.42 | 32.91 |

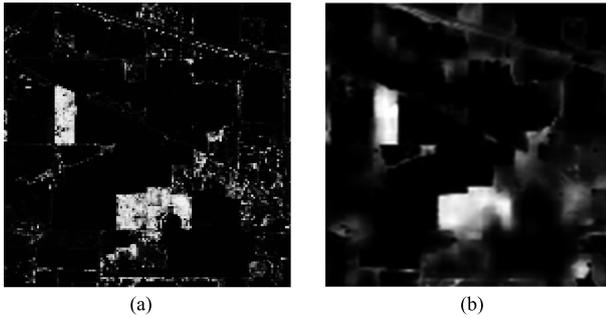
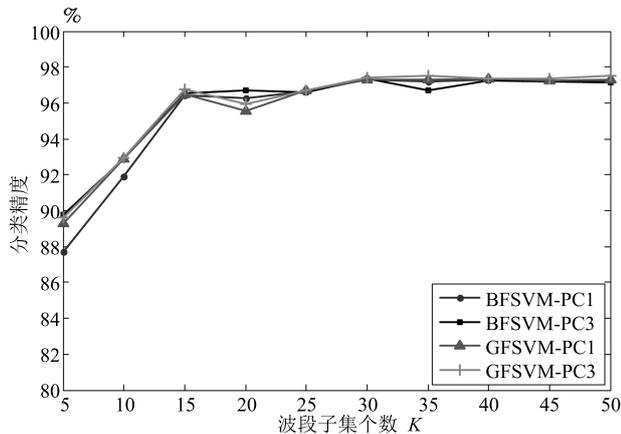


图 2 初始分类概率图双边滤波效果

Fig. 2 Bilateral filtering result of initial probabilistic map

图 3 Indian Pines 数据集波段子集 K 对分类精度的影响Fig. 3 OA of the proposed methods with different numbers of band subsets K in Indian Pines dataset

度. 后续仿真实验均在 $K = 30$ 前提下进行.

3) 分析边缘保持滤波器参数对分类精度的影响. 在联合双边滤波器中, 主要有两个参数 σ_s 和 σ_w 影响分类精度. 选取原始影像的第一个主成分作为滤波参考图像, 固定 $\sigma_w = 0.1$, 研究 σ_s 对分类精度的影响, 如图 4(a) 所示, 随着 σ_s 的增加分类精度先增长后降低; 选取分类精度最高的 σ_s 值 ($\sigma_s = 2$) 研究 σ_w 对分类精度的影响, 如图 4(b) 所示, 当 $\sigma_w = 0.2$ 时获得最优分类精度, 为 97.42%.

对于引导滤波, ω 和 ε 为影响其滤波效果的两个参数, 同样分别对其进行分析, 如图 5 所示, 选取 $\omega = 2$, $\varepsilon = 10^{-1}$ 为最优参数, 对应的分类精度为 97.29%. 后续仿真实验都采用这两组滤波器参数.

4) 表 1 所示为 10% 固定训练样本的情况下, 7 种算法的对比实验, 其中 SVMCK 组合了原始光谱特征和滑动窗均值特征, EPF-B-g 采用双边滤波和灰度图的方式进行分类, BFSVM 是基于双边滤波的分类, GFSVM 是基于引导滤波的双边分类, PC1 代表边缘滤波参考图像为高光谱影像第一个主成分, PC3 参考图像为前三个主成分. 从分类结果可以看出, 本文所提框架下的边缘滤波光谱-空间分类明

显优于 SVMCK 和 EPF, 都取得了比较理想的分类结果. 其中利用前三个主成分构建的 GFSVM 获得了最佳的分类效果, 精度为 97.43%, 并获得 8 个类别的最佳分类精度. 在分类时间上, 本文所提算法由于仅利用较少的特征波段用来分类, 降低了计算复杂度, 因此耗时较少.

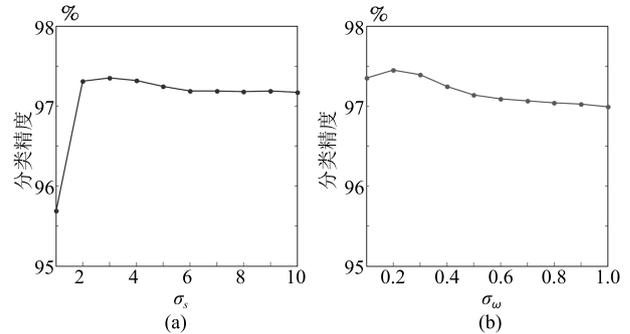


图 4 Indian Pines 影像双边滤波器参数对分类精度的影响

Fig. 4 The influence of the parameters of Bilateral filter in Indian Pines image

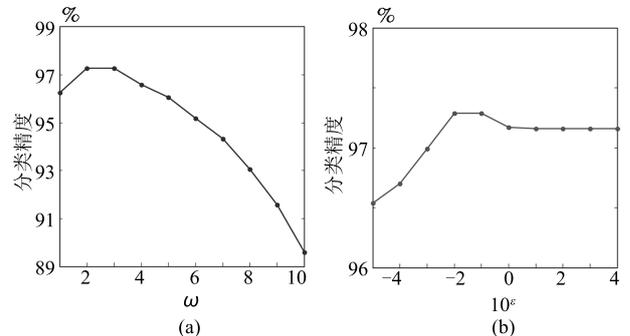


图 5 Indian Pines 影像引导滤波器参数对分类精度的影响

Fig. 5 The influence of the parameters of Guided filter in Indian Pines image

从图 6 可以看出, 不同分类方法的细节分类结果, 其中 SVM 由于没有结合空间特征, 分类图中产生了严重的“椒盐现象”. SVMCK 和 EPF 由于结合了空间特征, 分类结果较 SVM 有明显的提升, 但是分类边界模糊. 本文所提分类方法获得了较理想的分类结果, 既保证了近邻样本类别一致, 并突出了地物分类的边界, 真实可靠地反映了地物分布地实际情况.

3.2.2 Pavia University 数据集

为了进一步验证所提算法的有效性, 在 Pavia University 数据集上进行仿真实验, 仿真过程中训练和测试样本固定, 如表 2 所示, 其中训练样本约占 4%, 测试样本约占 96%.

图 7 所示为 Pavia University 数据集中波段子集个数对分类精度的影响. 随着波段子集个数的增

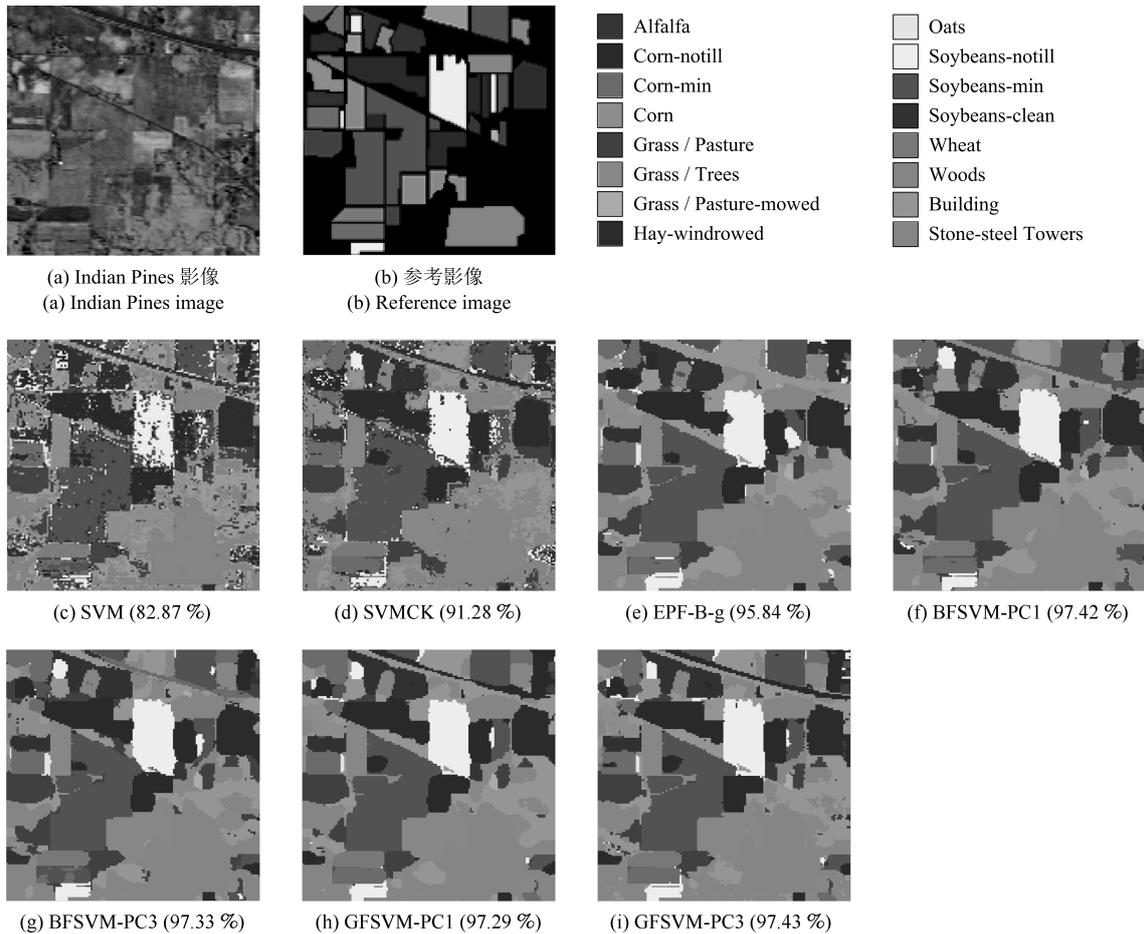


图 6 Indian Pines 数据集不同方法分类效果图

Fig. 6 Classification maps for the Indian Pines dataset using different methods

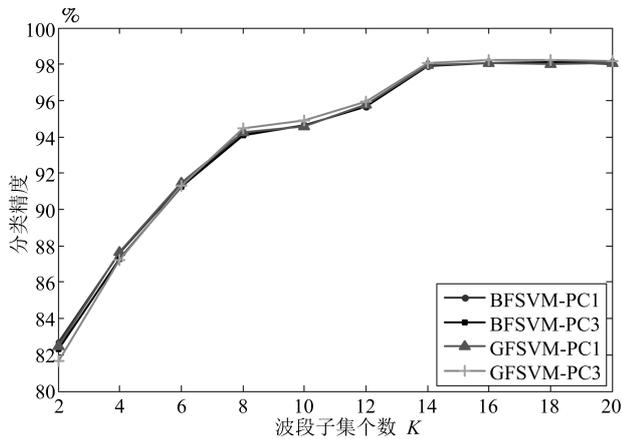


图 7 Pavia University 数据集波段子集 K 对分类精度的影响

Fig. 7 OA of the proposed methods with different numbers of band subsets K in Pavia University dataset

加, 总体分类精度也呈现上升的趋势, 并且两种基于边缘保持滤波的分类方法分类精度基本相同. 当 $K = 16$ 时, 两种方法均取得较高的分类精度. 后续仿

真实验均在 $K = 16$ 下进行.

表 2 所示为 4% 固定样本下 7 种算法的对比实验. SVMCK 由于结合了空间特征, 分类精度相比于 SVM 都有较大的提升. 本文所提的基于边缘保持滤波的分类算法均取得较为理想的分类结果, 并在分类时间上较 SVMCK 和 EPF-B-g 有明显优势. 其中利用原始影像前三个主成分构建的 GFSVM 获得了最高的分类精度. 图 8 为 Pavia University 数据集不同方法分类效果图, SVM 以及结合了空间信息的 SVMCK 分类图中仍具有很多噪点, 并且地物边界模糊. 本文所提方法获得了较理想的分类结果, 既保证了近邻样本类别一致, 并突出了地物分类的边界, 真实可靠地反映了地物分布的实际情况.

4 结论

本文提出一种基于边缘保持滤波的高光谱遥感影像光谱-空间联合分类方法, 1) 对高光谱影像进行波段子集划分, 并提取每个波段子集的主成分作为该子集的特征, 在保留原始影像结构信息的基础

表 2 Pavia University 数据集不同方法分类精度
Table 2 Classification accuracy for the Pavia University dataset using different methods

| 类别 | 训练样本 | 测试样本 | SVM (%) | SVMCK (%) | EPF-B-g (%) | BFSVM-PC1 (%) | BFSVM-PC3 (%) | GFSVM-PC1 (%) | GFSVM-PC3 (%) |
|-------------|------|--------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|
| 1 | 265 | 6 366 | 92.91 | 96.97 | 98.11 | 95.12 | 95.12 | 95.12 | 94.87 |
| 2 | 746 | 17 903 | 96.07 | 99.54 | 97.25 | 99.20 | 99.22 | 99.24 | 99.49 |
| 3 | 84 | 2 015 | 80.97 | 85.51 | 99.94 | 100.00 | 100.00 | 99.83 | 100.00 |
| 4 | 123 | 2 941 | 95.18 | 95.31 | 99.73 | 99.67 | 99.64 | 99.86 | 100.00 |
| 5 | 54 | 1 291 | 98.09 | 99.85 | 100.00 | 100.00 | 100.00 | 99.92 | 99.92 |
| 6 | 201 | 4 828 | 88.72 | 96.21 | 98.87 | 98.64 | 98.64 | 98.73 | 98.75 |
| 7 | 53 | 1 277 | 85.84 | 94.13 | 100.00 | 100.00 | 100.00 | 100.00 | 100.00 |
| 8 | 147 | 3 535 | 86.22 | 92.53 | 91.65 | 92.99 | 93.01 | 92.77 | 93.61 |
| 9 | 38 | 909 | 100.00 |
| OA (%) | | | 92.92 | 97.00 | 97.55 | 98.05 | 98.06 | 98.07 | 98.23 |
| AA (%) | | | 91.56 | 96.56 | 98.39 | 98.40 | 98.40 | 98.39 | 98.52 |
| κ 系数 | | | 0.9061 | 0.9602 | 0.967 | 0.974 | 0.974 | 0.974 | 0.977 |
| 时间 (s) | | | 94.56 | 178.32 | 97.48 | 47.22 | 47.01 | 28.98 | 47.37 |

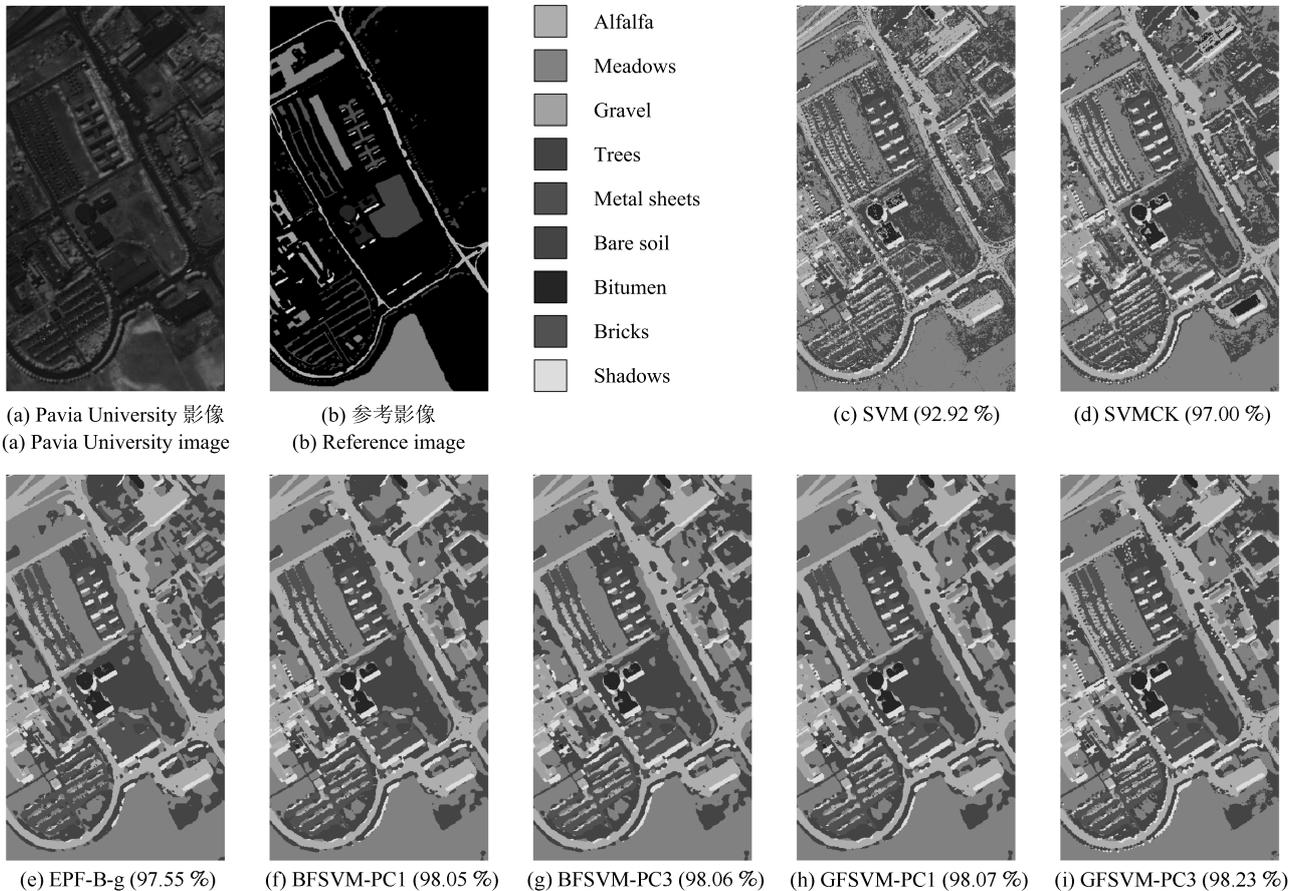


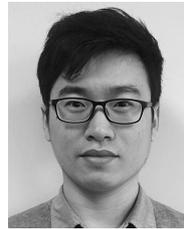
图 8 Pavia University 数据集不同方法分类效果图

Fig. 8 Classification maps for the Pavia University dataset using different methods

上,减少波段数目,降低运算量;2)对由这些特征组成的数据集利用SVM得到初始分类概率图;3)利用原始影像主成分指导边缘保持滤波器的构建,并对所有分类概率图进行滤波;4)由分类概率图对应像素点值的大小确定每个像素的类别.本文所提方法在缓解“椒盐现象”和突出地物边界方面有突出的优点,能够真实可靠地反映地物分布的实际情况.

References

- Pan Zong-Xu, Yu Jing, Xiao Chuang-Bai, Sun Wei-Dong. Spectral similarity-based super resolution for hyperspectral images. *Acta Automatica Sinica*, 2014, **40**(12): 2797–2807 (潘宗序, 禹晶, 肖创柏, 孙卫东. 基于光谱相似性的高光谱图像超分辨率算法. *自动化学报*, 2014, **40**(12): 2797–2807)
- Du B, Zhang L P. Target detection based on a dynamic subspace. *Pattern Recognition*, 2014, **47**(1): 344–358
- Plaza A, Benediktsson J A, Boardman J W, Brazile J, Bruzzone L, Camps-Valls G, Chanussot J, Fauvel M, Gamba P, Gualtieri A, Marconcini M, Tilton J C, Trianni G. Recent advances in techniques for hyperspectral image processing. *Remote Sensing of Environment*, 2009, **113**(S1): S110–S122
- Jia X P, Kuo B C, Crawford M M. Feature mining for hyperspectral image classification. *Proceedings of the IEEE*, 2013, **101**(3): 676–697
- Han M, Liu B. Ensemble of extreme learning machine for remote sensing image classification. *Neurocomputing*, 2015, **149**: 65–70
- Ramzi P, Samadzadegan F, Reinartz P. Classification of hyperspectral data using an AdaBoostSVM technique applied on band clusters. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, **7**(6): 2066–2079
- Ni Ding, Ma Hong-Bing. Spectral-spatial classification of hyperspectral images based on neighborhood collaboration. *Acta Automatica Sinica*, 2015, **41**(2): 273–284 (倪鼎, 马洪兵. 基于近邻协同的高光谱图像谱-空联合分类. *自动化学报*, 2015, **41**(2): 273–284)
- Zhang Z, Pasolli E, Crawford M M, Tilton J C. An active learning framework for hyperspectral image classification using hierarchical segmentation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, **9**(2): 640–654
- Fauvel M, Tarabalka Y, Benediktsson J A, Chanussot J, Tilton J C. Advances in spectral-spatial classification of hyperspectral images. *Proceedings of the IEEE*, 2013, **101**(3): 652–675
- Ji R R, Gao Y, Hong R C, Liu Q, Tao D C, Li X L. Spectral-spatial constraint hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(3): 1811–1824
- Camps-Valls G, Gomez-Chova L, Munoz-Marí J, Vila-Francés J, Calpe-Maravilla J. Composite kernels for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 2006, **3**(1): 93–97
- Benediktsson J A, Palmason J A, Sveinsson J R. Classification of hyperspectral data from urban areas based on extended morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(3): 480–491
- Tarabalka Y, Chanussot J, Benediktsson J A. Segmentation and classification of hyperspectral images using watershed transformation. *Pattern Recognition*, 2010, **43**(7): 2367–2379
- Li X R, Pan J, He Y Q, Liu C S. Bilateral filtering inspired locality preserving projections for hyperspectral images. *Neurocomputing*, 2015, **164**: 300–306
- Kang X D, Li S T, Benediktsson J A. Spectral-spatial hyperspectral image classification with edge-preserving filtering. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(5): 2666–2677



张成坤 大连理工大学电子信息与电气工程学部博士研究生. 主要研究方向为遥感图像处理, 高光谱影像分类.
E-mail: zhangchengkundon@mail.dlut.edu.cn

(ZHANG Cheng-Kun Ph.D. candidate at the Faculty of Electronic Information and Electrical Engineering,

Dalian University of Technology. His research interest covers remote sensing image processing and hyperspectral data classification.)



韩敏 大连理工大学电子信息与电气工程学部教授. 主要研究方向为模式识别, 复杂系统建模与分析及时间序列预测. 本文通信作者.

E-mail: minhan@dlut.edu.cn

(HAN Min Professor at the Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology.

Her research interest covers pattern recognition, modeling and analysis of complex system, and time series prediction. Corresponding author of this paper.)