

基于近邻协同的高光谱图像谱-空联合分类

倪鼎¹ 马洪兵¹

摘要 遥感高光谱成像能够获得丰富的地物光谱信息, 为高精度的地物分析提供了可能. 针对高光谱图像分类中通常面临的数据维数高、标记样本少、计算量大等问题, 提出了一种简单有效的谱-空联合分类方法. 利用高光谱图像丰富的光谱信息和地物分布的空间平滑特性, 该算法首先对光谱数据进行特征提取和空间滤波, 然后利用本文提出的基于近邻协同的支持向量机 (Neighborhood collaborative support vector machine, NC-SVM) 进行分类. 近邻协同进一步利用地物分布的空间平滑特性, 通过联合空间近邻的判决信息进行中心像素的类别判定, 有效减小了只有少量训练样本下的错分概率. 实验表明, 相比已有的相关方法, 该算法在不明显增加计算量的情况下可获得更高的分类正确率, 能够实现少量训练样本下高光谱图像的快速高精度分类.

关键词 分类, 高光谱图像, 特征提取, 空间滤波, 近邻协同

引用格式 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

DOI 10.16383/j.aas.2015.c140043

Spectral-spatial Classification of Hyperspectral Images Based on Neighborhood Collaboration

NI Ding¹ MA Hong-Bing¹

Abstract Hyperspectral imaging can provide rich spectral information about land covers, allowing detailed analysis of the materials on the earth. To address the high dimensionality, lack of sufficient labeled samples, and computationally intensive problems involved in hyperspectral image classification, this article presents a simple and efficient method to realize high accuracy classification with a limited training set. Taking advantage of the rich spectral features and the spatially homogeneous property of land covers' distribution, the proposed method firstly employs feature extraction and spatial filtering to reduce the dimension and the noise of the original hyperspectral data, and then uses the proposed neighborhood collaborative support vector machine (NC-SVM) to classify each pixel. The NC-SVM further exploits the spatially homogeneous property of land covers' distribution by combining the discriminant information of neighboring pixels to make reliable class judgement for the central one. Neighborhood collaboration can efficiently reduce the probability of misclassification when a small training set is available. Experiments show that the proposed algorithm can achieve a higher classification accuracy without significant increment in computational cost than several state-of-the-art methods. It can realize fast and high accuracy classification of hyperspectral images with limited training samples.

Key words Classification, hyperspectral image, feature extraction, spatial filtering, neighborhood collaboration

Citation Ni Ding, Ma Hong-Bing. Spectral-spatial classification of hyperspectral images based on neighborhood collaboration. *Acta Automatica Sinica*, 2015, 41(2): 273-284

与传统遥感成像 (如可见光、多光谱等) 相比, 高光谱遥感能够获得更加丰富的地物光谱信息, 有利于进行更加详细的地物分析^[1], 如目标检测^[2-3]、地物分类、变化检测^[4]、光谱解混等. 高光谱遥感技术在农作物估产、环境监测、灾害评估、污染防治以及军事侦察等领域均具有重要应用, 近几年越来越

受到人们的重视.

许多高光谱数据应用的基础任务是图像分类. 高光谱图像分类往往面临特征维数高、训练样本少等问题, 即所谓的 Hughes 现象^[5]. 基于核的分类器 (如支持向量机) 能够较好地解决高维、小样本学习问题^[6], 因此在高光谱数据分类中得到广泛应用^[7-10]. 特征提取可以减小光谱之间的相关性, 降低特征维数, 在一定程度上也可以缓解 Hughes 现象, 所以在高光谱图像分类中也作为一种常用的数据预处理手段^[11-17].

除了光谱特征, 空间特征在高光谱图像分类中也具有重要作用. 高光谱数据之间不是相互独立的

收稿日期 2014-01-16 录用日期 2014-05-15
Manuscript received January 16, 2014; accepted May 15, 2014
国家高技术研究发展计划 (863 计划) (2007AA12Z149) 资助
Supported by National High Technology Research and Development Program of China (863 Program) (2007AA12Z149)
本文责任编辑 贾云得
Recommended by Associate Editor JIA Yun-De
1. 清华大学电子工程系 北京 100084
1. Department of Electronic Engineering, Tsinghua University, Beijing 100084

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, 即地物分布的空间平滑特性^[18]. 因此, 高光谱图像分类通常是光谱特征和空间特征相结合的谱-空联合分类^[7-10, 19-23]. 空间特性的利用主要有两种途径: 空间特征提取和分类后处理. 前者首先提取空间特征, 然后利用空间特征和光谱特征联合训练分类器进行图像分类. Camps-Valls 等使用空间均值/方差作为空间特征, 通过合成核的方法对光谱特征和空间特征进行融合用于训练支持向量机 (Support vector machine, SVM)^[7]. Gurram 等通过在核 Hilbert 空间取平均引入空间信息, 提出了一种基于核空间嵌入的上下文 SVM 分类方法^[8]. Fauvel 等把图像的扩展形态学特征作为空间特征, 结合光谱特征进行联合分类^[9]. Qian 等利用 3D 小波刻画图像的纹理特征, 使用分解的小波系数设计分类器^[21]. 分类后处理的方法就是先对每个像素单独分类, 然后通过空间后处理消除分类噪声. Tarabalka 等使用马尔科夫随机场对 SVM 的分类图进行噪声消除^[10]. Tarabalka 等先分别进行 SVM 像素分类和 ISODATA/EM 图像分割, 然后通过多数投票对每个分割区域进行分类^[22]. Bai 等首先用 SVM 进行单像素分类, 从中选取可信度较大的像素作为 Graph-cut 的种子点进行图像分割完成图像分类^[23]. 研究表明, 空间特征与光谱特征相结合可以大大减小分类噪声, 得到更加平滑的分类图.

已有的方法主要在分类判决之前或判决之后利用空间信息. 在判决之前提取空间特征, 分类器的性能直接取决于所提取特征的鉴别性, 而目前尚没有一种特征适用于所有图像; 同时, 特征过多也会给分类器的设计造成困难. 在判决之后利用空间特性本质上属于纠错的过程, 即利用地物分布的空间平滑特性来纠正杂散类别分布, 其分类性能同时依赖于前期的分类结果和后处理的可靠性, 分类性能无法保证^[24]. 实际上, 可以在分类判决的过程中直接利用空间信息对每个像素进行类别判定. 对此, 本文提出了一种基于近邻协同的支持向量机分类方法 (Neighborhood collaborative SVM, NC-SVM). 该方法在分类过程中充分利用了地物分布的空间平滑特性, 可以联合空间近邻像素的判别信息对中心像素作出可靠的类别判断.

本文算法首先对高光谱图像进行特征提取和空间滤波, 然后使用 NC-SVM 进行分类, 整个算法的流程如图 1 所示. 特征提取可以消除特征之间的相关性, 在一定程度上缓解 Hughes 现象. 空间滤波可以减小噪声的干扰, 增强特征的稳定性. 实际上, 滤波的过程也是空间特征提取的过程, 类似于文献 [7]

将均值作为空间特征. 在分类阶段, 本文使用基于近邻协同的 SVM 进行分类, 近邻协同在对每个像素进行类别判决时, 不仅考虑该像素自身的判别输出, 而且考虑其近邻的判别输出, 根据其空间邻域的整体输出结果进行类别判决, 因此 NC-SVM 在分类阶段进一步利用了地物分布的空间特性, 这将大大减小错分的概率, 增强分类结果的空间一致性. 与已有的相关算法相比, 本文方法可以在不明显增加计算量的情况下显著提高分类精度; 特别是对于少量训练样本的情况, 本文方法的提升效果更加明显, 充分表明了本文算法的有效性和实用性.

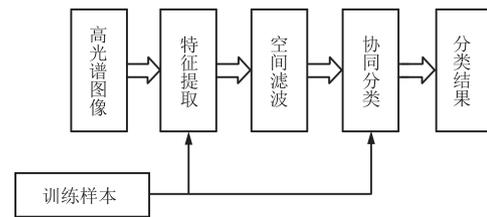


图 1 本文算法的流程

Fig. 1 The flowchart of the proposed algorithm

本文算法主要包括特征提取、空间滤波和协同分类 3 个步骤. 本文组织结构如下: 第 1 节简要介绍本文使用的特征提取方法和空间滤波策略; 第 2 节详细介绍 NC-SVM 的基本原理; 实验分析和对比在第 3 节给出; 最后是总结.

1 特征提取与空间滤波

1.1 特征提取

特征提取可在保留鉴别信息的同时大大降低特征维数, 在一定程度上有助于缓解 Hughes 现象. 另外, 高光谱数据的相邻波段间一般存在较大的相关性, 特征提取可大大减小其信息冗余, 提高分类效率. 因此, 作为一种有效的数据预处理手段, 特征提取在高光谱图像分类中得到广泛应用^[11-17].

本文采用 NWF (Nonparametric weighted feature extraction)^[13] 进行特征提取. NWF 是一种基于 Fisher 度量的有监督特征提取方法, 根据标记样本在特征空间中的分布, 通过赋予类别边界处样本更大的权重, 使不同类别的特征在变换后的特征空间具有更大的分离度, 从而提高所提取特征的区分能力.

设位置加权的类内离散度矩阵为 S_w^{NW} , 类间离散度矩阵为 S_b^{NW} , NWF 的最优线性变换为式 (1) 的前 k 个最大广义特征值对应的特征向量

$$S_b^{NW} \mathbf{v} = \lambda S_w^{NW} \mathbf{v} \quad (1)$$

一般地, 为了避免类内离散度矩阵 S_w^{NW} 的奇异问题, 通常对其进行正则化处理, 即

$$\widehat{S}_w^{NW} = S_w^{NW} + \mu \cdot \text{diag}\{S_w^{NW}\} \quad (2)$$

其中, μ 是一个小的常数 (实验中设置 $\mu = 0.1$), 具体细节可参见文献 [13].

与传统的特征提取方法, 如主成分分析 (Principal component analysis, PCA)、线性判别分析 (Linear discriminant analysis, LDA) 等相比, NWFE 充分考虑了样本在特征空间的位置分布, 因而提取的特征具有更好的鉴别性; 另外, NWFE 不存在 LDA 固有的维数限制 (对 c 类样本最多提取 $c - 1$ 维特征), 能提取更多的鉴别信息. 本文的实验部分也验证了 NWFE 所提取特征的鉴别性要优于其他方法 (见第 3.3 节). 因此, 作为一种有效的数据预处理手段, NWFE 在高光谱图像分类中得到广泛应用^[9, 13].

1.2 空间滤波

由于成像噪声等因素的影响, 同种地物的光谱通常呈现不同程度的波动. 当光谱维数较高时, 这种波动将直接影响特征间的相似性度量, 给少量训练样本下的高精度分类带来严重困难^[25]. Camps-Valls 等^[7] 的实验结果也表明, 结合空间均值特征进行分类可以大大提高分类精度. 因此, 有必要对光谱特征进行空间滤波, 以消除噪声的影响. 然而, 空间滤波要尽量减少不同地物之间的干扰, 否则会造成不同类别边界处像素之间的光谱混叠, 影响分类性能. 对此, 本文使用双边滤波器^[26] 进行空间滤波, 在消除光谱噪声的同时可以在一定程度上有效地保持区域边界.

双边滤波的基本原理如下所示:

$$\tilde{\mathbf{F}}(\mathbf{x}) = \frac{1}{\eta} \int_{\Omega} w(\mathbf{x}, \mathbf{y}) \phi(\mathbf{F}(\mathbf{x}), \mathbf{F}(\mathbf{y})) \mathbf{F}(\mathbf{y}) d\mathbf{y} \quad (3)$$

其中, $w(\mathbf{x}, \mathbf{y})$ 为空间位置权重, $\mathbf{F}(\mathbf{x})$ 为像素 \mathbf{x} 的特征, $\phi(\mathbf{F}(\mathbf{x}), \mathbf{F}(\mathbf{y}))$ 为特征相似性度量, Ω 为以 \mathbf{x} 为中心的邻域. η 为权重归一化因子, 即

$$\eta = \int_{\Omega} w(\mathbf{x}, \mathbf{y}) \phi(\mathbf{F}(\mathbf{x}), \mathbf{F}(\mathbf{y})) d\mathbf{y} \quad (4)$$

一般地, $w(\mathbf{x}, \mathbf{y})$ 和 $\phi(\mathbf{F}(\mathbf{x}), \mathbf{F}(\mathbf{y}))$ 均取为高斯函数, 即

$$w(\mathbf{x}, \mathbf{y}) = e^{-\frac{\|\mathbf{x}-\mathbf{y}\|^2}{2\sigma_s^2}} \quad (5)$$

$$\phi(\mathbf{F}(\mathbf{x}), \mathbf{F}(\mathbf{y})) = e^{-\frac{\|\mathbf{F}(\mathbf{x})-\mathbf{F}(\mathbf{y})\|^2}{2\sigma_w^2}} \quad (6)$$

从式 (3) 可以看出, 双边滤波在进行特征平滑时不仅考虑了近邻的相对位置信息, 还考虑了它们

之间的特征相似性. 对于区域内部像素, 其光谱特征比较相似, 双边滤波相当于高斯空间滤波. 对于区域边界像素, 相同地物的光谱特征差异小, 对应的相似性权重较大; 不同地物的光谱特征差异大, 对应的相似性权重小, 因而可以减小不同地物之间的干扰. 所以, 双边滤波在有效地消除噪声干扰的基础上, 可以尽量减小对区域边界的影响. 实验表明, 使用双边滤波的分类性能要略优于传统的均值/高斯滤波 (分类正确率提高 0.5% ~ 1%).

2 基于近邻协同的支持向量机 (NC-SVM)

本文提出的基于近邻协同的支持向量机是在传统的支持向量机的基础上, 将空间近邻样本的判决信息有效地整合到中心样本的判决函数中, 根据整个邻域的判决信息进行协同分类. 下面首先介绍传统的支持向量机的基本原理, 然后介绍本文的近邻协同的实现方法.

2.1 传统 SVM

对于训练样本 $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$, $\mathbf{x}_i \in \mathbf{R}^d$ 为 d 维的特征向量, $y_i \in \{1, -1\}$ 为类别标签. 核映射 $\Phi(\cdot)$ 将原始特征从低维空间映射到高维的再生核 Hilbert 空间, 对应的核函数为 $K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$ (本文统一采用径向基核函数 (Radial basis function, RBF)). 为使分类间隔最大化, 核支持向量机在再生核 Hilbert 空间求解如下最优化问题.

$$\begin{aligned} \min_{\mathbf{w}, b, \xi_i} & \left\{ \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \right\} \\ \text{s. t.} & y_i (\langle \Phi(\mathbf{x}_i), \mathbf{w} \rangle + b) \geq 1 - \xi_i, \\ & \xi_i \geq 0, \quad \forall i = 1, \dots, n \end{aligned} \quad (7)$$

其中, \mathbf{w} , b 为分类器的系数和偏置, ξ_i 为松弛变量, C 为调节分类器的复杂度和错分容忍度的权重. 核支持向量机的原理如图 2 所示.

应用对偶原理, 上述原问题等价于如下的对偶二次优化问题:

$$\begin{aligned} \max_{\mathbf{a}} & \left\{ \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle \right\} \\ \text{s. t.} & \sum_{i=1}^n y_i a_i = 0, \\ & 0 \leq a_i \leq C, \quad \forall i = 1, \dots, n \end{aligned} \quad (8)$$

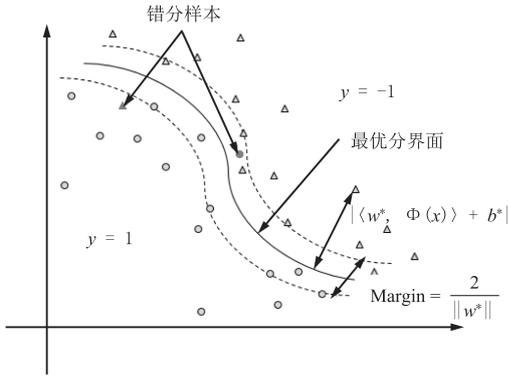


图 2 核支持向量机的原理图
Fig. 2 The schematics of kernel SVM

设对偶问题 (8) 的解为 a_i^* ($i = 1, \dots, n$), 那么原问题 (7) 的解为

$$w^* = \sum_{i=1}^n a_i^* y_i \Phi(x_i) \quad (9)$$

对应的广义最优分类面的判别函数为

$$f(x) = \langle w^*, \Phi(x) \rangle + b^* = \sum_{i=1}^n a_i^* y_i \langle \Phi(x_i), \Phi(x) \rangle + b^* = \sum_{i=1}^n a_i^* y_i K(x_i, x) + b^* \quad (10)$$

传统的 SVM 直接根据 $f(x)$ 的符号进行样本类别的判断. 实际上, $f(x)$ 的大小也包含重要信息: $f(x)$ 绝对值越大, 表明 x 离分界面的距离越远, 那么样本属于对应类别的可信度就越高. 利用该性质本文提出如下的基于近邻协同的 SVM 分类器.

2.2 近邻协同 SVM

当训练样本不足时, 训练得到的分界面并不能全面反映各类的特征在高维空间的分布状况, 导致处于分界面附近的样本极易错分, 尤其是两类特征的区别度不大时, 大量样本位于分界面附近, 这时错分的情况更加严重.

根据遥感图像中地物分布的空间平滑特性, 相邻的像素往往属于同一类别. 如果把邻域像素进行联合分类, 将大大减小中心样本的错分概率, 其基本原理如图 3 所示. 当训练样本不足时, SVM 训练得到的分界面不能全面反映类别特征的分布, 中心像素可能位于分界面的错误一侧 (情况 1); 或中心像素位于不同地物的边界, 由于光谱混叠及噪声干扰使得其光谱特征位于分界面的错误一侧 (情况 3), 在这些情况下使用单个样本进行分类都会导致错分. 然

而, 如果在其附近存在较多的能够正确分类的同类样本, 则可充分借助这些近邻的鉴别力提升中心样本的鉴别力, 从而导出正确的分类. 显然这种策略对单个样本本身就能正确分类的情况不会带来错分风险 (情况 2).

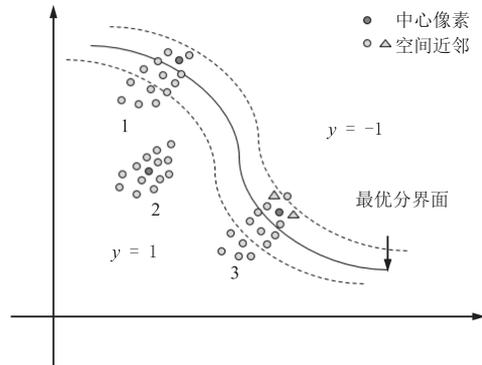


图 3 近邻协同 SVM 的原理图
Fig. 3 The schematics of neighborhood collaborative SVM

由于 SVM 的判别函数 $f(x)$ 的绝对值是样本分类鉴别力 (可信度) 的有效度量, 在对中心样本进行类别判决时除了考虑其自身的 SVM 判别函数输出, 还可以结合其近邻的判别输出, 根据邻域像素整体的输出情况进行综合的类别判断. 对此, 本文提出如下的基于近邻协同的 SVM 分类方法.

设中心像素为 x_0 (为叙述方便, x_0 既可表示像素, 又可表示像素的特征), 其空间近邻构成的集合为 $\Omega(x_0) = \{x_0, x_1, \dots, x_k\}$, 本文定义 NC-SVM 的判别函数为

$$\hat{f}(x_0) = \frac{1}{\eta} \sum_{j=0}^k w_j f(x_j), \quad x_j \in \Omega(x_0) \quad (11)$$

其中, $f(x_j)$ 为像素 x_j 的 SVM 输出 (式 (10)), w_j 为像素 x_j 对应的权重, η 为权重归一化因子. 本文采用自适应的权重

$$w_j = e^{-\frac{\|x_j - x_0\|^2}{2 \cdot \text{med}(\|x_j - x_0\|^2)}} \quad (12)$$

其中, $\text{med}(\cdot)$ 表示取中值. 将方差设置为近邻与中心样本距离的中值, 使得只有约一半的近邻样本提供较大的贡献. 当中心样本位于两类地物的边界时, 可在一定程度上减小非同类样本对其判决的影响.

将式 (10) 代入式 (11), 可得:

$$\hat{f}(x_0) = \frac{1}{\eta} \sum_{j=0}^k w_j \left\{ \sum_{i=1}^n a_i^* y_i K(x_i, x_j) + b^* \right\} =$$

$$\sum_{i=1}^n a_i^* y_i \left\{ \frac{1}{\eta} \sum_{j=0}^k w_j K(\mathbf{x}_j, \mathbf{x}_j) \right\} + b^* = \sum_{i=1}^n a_i^* y_i \hat{K}(\mathbf{x}_i, \Omega(\mathbf{x}_0)) + b^* \quad (13)$$

其中,

$$\hat{K}(\mathbf{x}_i, \Omega(\mathbf{x}_0)) = \frac{1}{\eta} \sum_{j=0}^k w_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (14)$$

式(14)构成本文算法的合成核. 根据 Mercer 定理^[27] 易知, 该合成核仍然是有效的 SVM 核. 最后, 根据 $\hat{f}(\mathbf{x}_0)$ 的符号确定中心像素 \mathbf{x}_0 对应的类别.

从上面的推导过程可以看出, 基于近邻协同的 SVM 分类器与传统的单样本 SVM 分类器相比, 除了核函数的计算不同外, 训练和分类过程完全相同, 因此不会带来设计复杂度的明显提高. 但 NC-SVM 在类别判决过程中能够有效地利用地物分布的空间平滑特性, 将近邻样本的判决信息纳入到中心样本的判别函数中进行协同分类, 可以有效减小错分概率.

以上讨论均为两类分类的情况, 可以运用一对一 (One-versus-one) 或一对多 (One-versus-all) 的策略将其推广到多类的情况. 本文采用一对一策略得到对应的多类 NC-SVM 分类器.

3 实验和分析

3.1 数据集

本实验使用两组高光谱数据集检验本文算法的分类性能.

Indian Pines 数据集: 该数据集为机载可见红外成像光谱仪 (Airborne visible/infrared imaging spectrometer, AVIRIS) 采集的农业区高光谱图像, 图像大小为 145 像素 \times 145 像素, 空间分辨率为 20 m/pixel, 共包含 220 个波段 (波长范围为 0.4 ~ 2.5 μm)¹. 这里去除其中 20 个水吸收严重的波段, 得到包含 200 个波段的高光谱数据^[28]. 图 4 给出了该数据对应的假彩色图像和标记模板. 该数据集包含 16 种已知地物共 10 366 个样本 (具体构成见表 1). 由于该数据集涉及的地物光谱具有很高的相似性, 同时各类样本的数目很不均衡, 给地物的高精度分类带来极大的挑战, 因此被广泛用于高光谱图像分类算法的性能测试.

University of Pavia 数据集: 该数据集为反射光学成像光谱仪 (Reflective optics system imag-

ing spectrometer, ROSIS) 采集的城区高光谱图像, 图像大小为 610 像素 \times 340 像素, 空间分辨率为 1.3 m/pixel, 共包含 115 个波段 (波长范围为 0.43 ~ 0.86 μm). 这里去除其中水吸收严重的 12 个波段, 将其余 103 个波段作为高光谱数据. 图 5 给出了该数据集对应的假彩色图像和标记模板. 该数据集涉及 9 种感兴趣地物, 共 42 776 个样本 (具体构成见表 2). 该数据集也被广泛用于高光谱图像分类算法的性能测试.

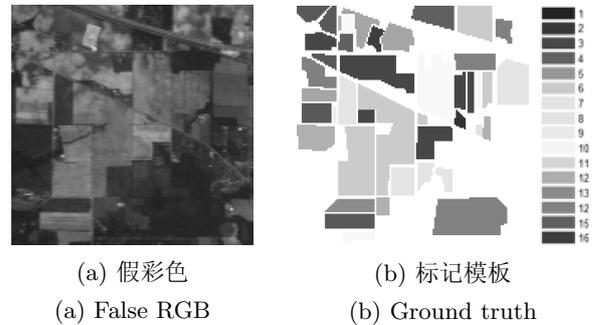


图 4 Indian Pines 数据集

Fig. 4 Indian Pines dataset

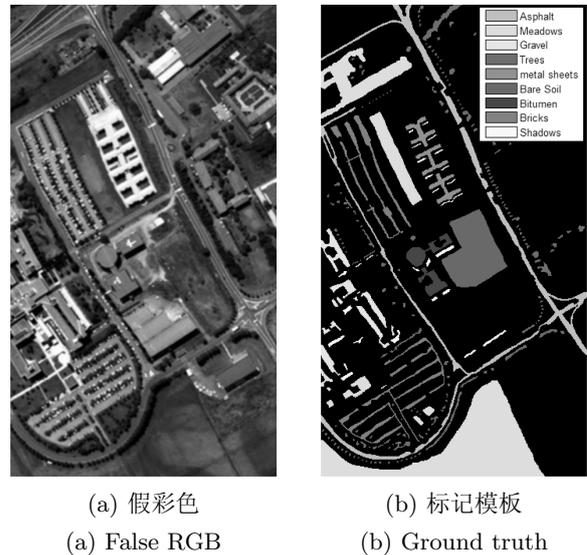


图 5 University of Pavia 数据集

Fig. 5 University of Pavia dataset

3.2 对比算法与评价指标

为测试本文算法的性能, 将本文算法与使用光谱特征的分类方法和结合了空间特性的分类方法进行对比. 使用光谱特征的方法包括 k-近邻 (kNN) 和 SVM; 结合了空间特性的方法包括使用空间均值的方法 (SVM on spatial mean, SVM-s)、基于合成核的方法 (光谱特征和空间均值) (Composite SVM,

¹<http://engineering.purdue.edu/~biehl/MultiSpec/>

表 1 对 Indian Pines 数据集使用 5% 的训练样本各个算法的分类正确率 (%)

Table 1 Classification accuracy for the Indian Pines dataset using 5% training samples per class (%)

#	类别	训练样本	测试样本	kNN	SVM	SVM-s	SVM- μ	CSVM	SVM-EMP	本文方法
1	Alfalfa	3	51	52.75	61.85	61.48	63.89	76.48	82.04	91.30
2	Corn-no till	72	1362	57.11	79.83	93.70	93.55	95.54	88.40	98.01
3	Corn-min till	42	792	57.30	72.39	89.45	89.65	95.16	91.44	96.94
4	Corn	12	222	39.59	61.03	78.93	79.32	87.14	74.79	95.00
5	Grass-pasture	25	472	85.95	91.59	89.64	89.62	93.38	89.64	95.79
6	Grass-trees	38	709	92.09	95.48	98.14	98.19	98.15	96.29	98.89
7	Grass-pasture-mowed	3	24	88.70	86.54	81.15	81.54	91.15	93.85	96.92
8	Hay-windrowed	25	464	96.38	97.10	97.12	97.10	98.00	98.98	100
9	Oats	3	19	69.41	83.50	80.50	81.00	97.50	91.00	85.00
10	Soybean-no till	49	919	69.68	74.91	89.18	89.42	93.08	87.53	96.43
11	Soybean-min till	124	2344	74.03	81.94	92.31	92.04	95.64	90.98	98.12
12	Soybean-clean	31	583	48.68	79.20	88.18	89.35	93.37	82.85	97.48
13	Wheat	11	201	98.26	98.92	95.42	95.66	97.26	98.40	99.20
14	Woods	65	1229	93.92	95.05	96.85	96.66	97.38	98.86	98.95
15	Buildings-grass-trees-drives	19	361	36.62	52.47	76.00	75.61	83.63	91.97	91.34
16	Stone-steel-towers	5	90	90.56	87.79	96.84	96.74	98.53	93.16	89.58
	总体正确率 (OA)			72.26	82.61	91.82	91.83	94.93	91.34	97.51
	平均正确率 (AA)			71.94	81.23	87.81	88.08	93.21	90.63	95.56
	k 系数			68.29	80.18	90.67	90.69	94.23	90.14	97.16
	运行时间 (s)			1.00	7.10	3.87	4.17	201.28	3.39	5.77

表 2 对 University of Pavia 数据集使用 1% 的训练样本各个算法的分类正确率 (%)

Table 2 Classification accuracy for the University of Pavia dataset using 1% training samples per class (%)

#	类别	训练样本	测试样本	kNN	SVM	SVM-s	SVM- μ	CSVM	SVM-EMP	本文方法
1	Asphalt	67	6564	74.48	83.18	93.74	95.01	96.45	90.49	98.96
2	Meadows	187	18462	96.10	95.38	98.44	97.80	99.38	97.53	99.75
3	Gravel	21	2078	48.88	65.48	69.79	78.92	77.21	88.18	86.85
4	Trees	31	3033	70.68	85.35	89.88	89.64	92.13	92.76	93.81
5	Painted metal sheets	14	1331	98.84	98.69	99.81	99.81	99.85	99.56	99.72
6	Bare soil	51	4978	35.18	63.76	85.71	88.64	90.69	79.72	94.13
7	Bitumen	14	1316	69.25	74.32	88.45	92.32	91.74	88.10	98.09
8	Self-blocking bricks	37	3645	75.79	79.74	88.52	88.31	94.96	91.73	97.22
9	Shadows	10	937	88.12	95.74	97.99	98.05	99.51	94.57	90.43
	总体正确率 (OA)			78.77	85.70	93.06	93.86	95.70	92.75	97.43
	平均正确率 (AA)			73.03	82.40	90.26	92.05	93.55	91.41	95.44
	k 系数			70.92	80.80	90.73	91.83	94.26	90.33	96.58
	运行时间 (s)			4.53	12.60	9.72	10.20	334.74	12.67	18.28

SVM- μ)^[7]、基于核空间嵌入的上下文方法 (Contextual SVM, CSVM)^[8] 及形态学特征与光谱特征相结合的方法 (SVM on extended morphological profiles, SVM-EMP)^[9]. 其中 SVM- μ 的合成核采用加权融合的融合方法, SVM-s 和 SVM- μ 的均值特征的窗口大小与本文算法的空间滤波器范围均设置为 7×7 , CSVM 的邻域大小设置为 5×5 , 其他参数与原文献相同, kNN 和 SVM 的最佳参数均通过 5 次交叉验证确定. 对比的方法按原文献实现, 均不涉及特征提取的过程.

本文使用的评价指标包括总体正确率 (Overall accuracy, OA)、平均正确率 (Average accuracy, AA)、kappa 系数^[29] 及计算效率. 为避免抽样偏差, 实验中对各实验条件分别进行 10 次 Monte-Carlo 实验. 每次随机抽取一定数量的标记样本作为训练样本, 其余的作为测试样本, 然后使用各算法进行分类, 将 10 次独立随机实验的平均正确率和标准差作为各算法的分类性能及其稳定性的评价. 实验所用的计算平台为 PC (Intel dual-core 3.4 GHz CPU, 4 G RAM), 操作系统为 Windows 7. 所有算法均使用 Matlab 编写, 其中 SVM 的训练部分使用 Libsvm^[30] 实现.

3.2.1 Indian Pines 数据集

首先检验特征提取对高光谱图像分类的作用, 然后分析 NC-SVM 的近邻协同的邻域范围对算法分类性能的影响, 最后比较不同算法之间的分类性能.

1) 特征提取的作用

为检验特征提取在高光谱图像分类中的作用, 对 Indian Pines 高光谱数据分别使用 PCA、LDA、OLDA (Orthogonal LDA)^[31]、RLDA (Regularized LDA)^[32]、LFDA (Local fisher discriminant analysis)^[33] 和 NWFE 进行特征提取, 然后使用 5% 的标记样本训练 SVM, 对剩下的标记样本进行分类. 对于不同的特征维数, 各种特征提取方法得到的分类正确率如图 6 所示.

当训练样本较少时, LDA 的类内离散度矩阵容易奇异或近似奇异, 使得特征向量的计算不稳定. 尽管可以通过 OLDA 或 RLDA 从数学上得到较稳定的解, 但是通过少量样本估计的类别离散度矩阵并不能全面反映数据在特征空间的分布情况, 使得所提取特征的代表性不足. 另外, LDA、OLDA 和 RLDA 最多只能提取 $c - 1$ 维特征 (c 为类别总数). 当特征维数较高且类别数目较少时, 容易造成大量有用信息的丢失, 使得类别的区分能力下降. 所以, LDA、OLDA 和 RLDA 的分类性能不高. LFDA

使用加权的局部离散度代替总体离散度, 可以解决类别特征为多模态分布情况下的特征提取问题, 同时可提取的特征维数不受类别数目的限制, 因此其分类性能优于基于 LDA 的方法. 但是其实现过程涉及较多的内部参数, 同时从图 6 可以看出其分类性能与特征维数呈非单调关系, 需要通过交叉验证确定最佳特征维数.

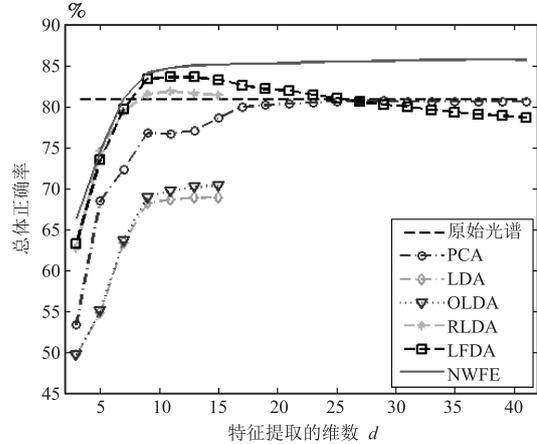


图 6 分类正确率与特征提取维数的关系

Fig. 6 The relationship between classification accuracy and the dimension of extracted features

由于对分类起决定作用的是类别分布边界的样本, NWFE 在计算类别离散度时赋予类别边界样本更大的权重, 使得不同类别的特征在变换后的特征空间具有更大的分离度, 从而提高所提取特征的鉴别力. 由于充分考虑了类别的特征空间分布, NWFE 可以适用于任意分布的数据, 而且可提取的特征维数也不受类别数目的限制. 与 LFDA 相比, NWFE 是一种无参数的特征提取方法, 简便易用. 从图 6 可以看出, 当特征维数超过一定值 (对 Indian Pines 数据集为 30) 时, 其分类性能基本稳定, 因此可以较容易确定其合适的特征维数.

比较 NWFE 和原始光谱的分类结果可以看出, 使用有效的特征提取方法对原始的高光谱数据进行预处理, 可在保留类别鉴别信息的同时减小信息冗余, 在一定程度上缓解 Hughes 现象, 进而提高分类性能. 因此作为一种有效的数据预处理方法, NWFE 在高光谱数据的分类中得到广泛应用 (特征提取一直是模式识别领域的一个研究热点, 目前已经存在多种特征提取方法, 可能存在比 NWFE 更好的方法, 选择其中最优或设计更适用于高光谱数据的特征提取方法已超出了本文的研究范围).

2) NC-SVM 的邻域范围的影响

为检验在少量训练样本情况下, NC-SVM 的邻域范围对算法分类性能的影响, 对 Indian Pines 数

据集的每类地物仅使用 2% 的标记样本进行训练, 其余的样本用于测试. 设置特征提取的维数 $d = 30$, 对于不同的邻域范围得到的分类正确率如图 7 所示.

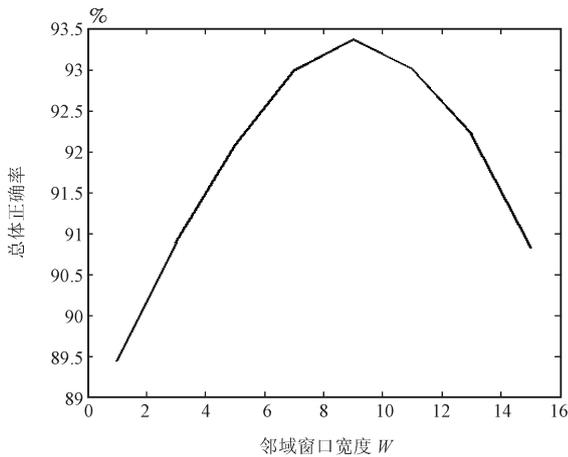


图 7 分类正确率与邻域宽度的关系

Fig. 7 The relationship between classification accuracy and the width of the neighborhood window

从图 7 可以看出, 对于只有少量的训练样本的情况, 本文的基于近邻协同的 SVM 较传统的单像素的 SVM (即 $W = 1$) 的分类正确率有较明显的提高 (大约提高 4%). 说明对于高光谱图像分类问题, 除在分类之前进行空间特征提取等利用空间信息的手段之外, 在分类过程中也应该充分利用地物分布的空间特性, 这样可以进一步提高算法的分类性能. 后面的实验表明, 对于只有少量训练样本的情况, 其重要性更加突出.

图 7 还反映出邻域范围的大小也会对算法的分类性能产生一定的影响. 邻域范围过小, 空间信息利用不充分, 近邻协同的效果不明显; 近邻范围过大会造成异类地物的干扰, 使得算法性能下降. 对于 Indian Pines 数据集, $W = 9$ 为其最佳取值.

3) 结果对比

设置本文算法的特征提取维数 $d = 30$, NC-SVM 邻域宽度 $W = 9$, 对每类地物分别抽取相同比例的标记样本作为训练样本, 其余的作为测试样本, 然后使用各个算法进行分类. 对于不同比例的训练样本, 各算法的分类结果如图 8 所示 (图中竖线代表标准差).

分析图 8 可以发现, 对于只有少量训练样本的情况, 直接使用光谱特征进行分类, 无论使用何种分类器, 其分类正确率均较低, 而结合了空间信息的谱-空联合分类的正确率均有明显提高, 说明除了光谱信息外, 地物分布的空间信息在高光谱图像

分类中也具有重要作用. 将使用空间均值特征的方法 (SVM-s) 与直接使用光谱特征的方法 (SVM) 进行比较, 不难看出, 空间滤波可以获得较大的分类性能提升, 说明事先进行噪声消除以增强特征的稳定性对提高分类精度具有重要意义. 在此基础上, 本文的基于近邻协同的分类方法在分类过程进一步利用了空间信息, 分类性能又有了较大的提升, 特别是对于训练样本较少的情况, 其提升效果更加明显. 所以, 除了在分类之前应该充分利用空间特征之外, 在分类过程中可以进一步利用空间信息提高分类性能, 这对于少量训练样本下的高精度分类至关重要.

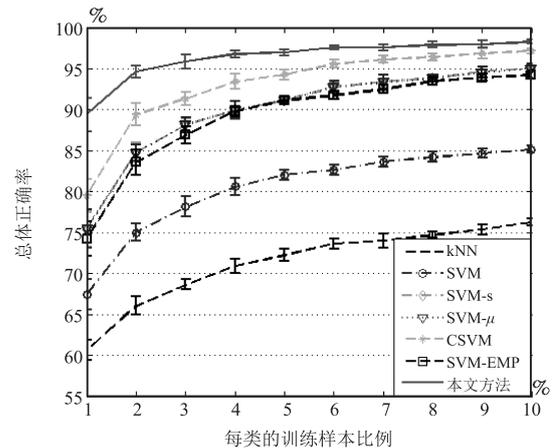


图 8 Indian Pines 数据集: 对不同比例的训练样本各种方法的分类正确率

Fig. 8 Classification accuracy for Indian Pines dataset using different percent of training samples per class

为详细比较各算法对每类的分类情况, 表 1 列出了对 5% 的训练样本各算法的分类结果以及对应的运行时间. 对大多数类别, 本文算法都得到了最高的分类正确率. 计算时间 (从特征提取到分类完成的整体时间) 与其他算法相比并没有明显增加, 且远小于 CSVM 的运行时间.

图 9 为一次随机实验的分类图 (5% 训练样本). 可以看出, 本文方法得到的分类图的分类噪声更少, 地物分布也更加平滑. 另外, 由于本文使用了特征相似性加权的空间滤波和近邻协同的权重自适应调节, 其在引入空间信息的同时仍然能够较好保持地物的边界 (图中黑色框部分).

对个别地物 (如 Oats), 本文算法的结果并不理想 (如图 10 所示), 原因在于该类分布过于狭窄, 每个像素的空间近邻大部分为不同类别地物, 这时引入空间信息反而会带来异类地物的干扰, 导致最终产生错判. 然而对大多数分布面积较大的地物, 本文算法都得到了最高的分类正确率.

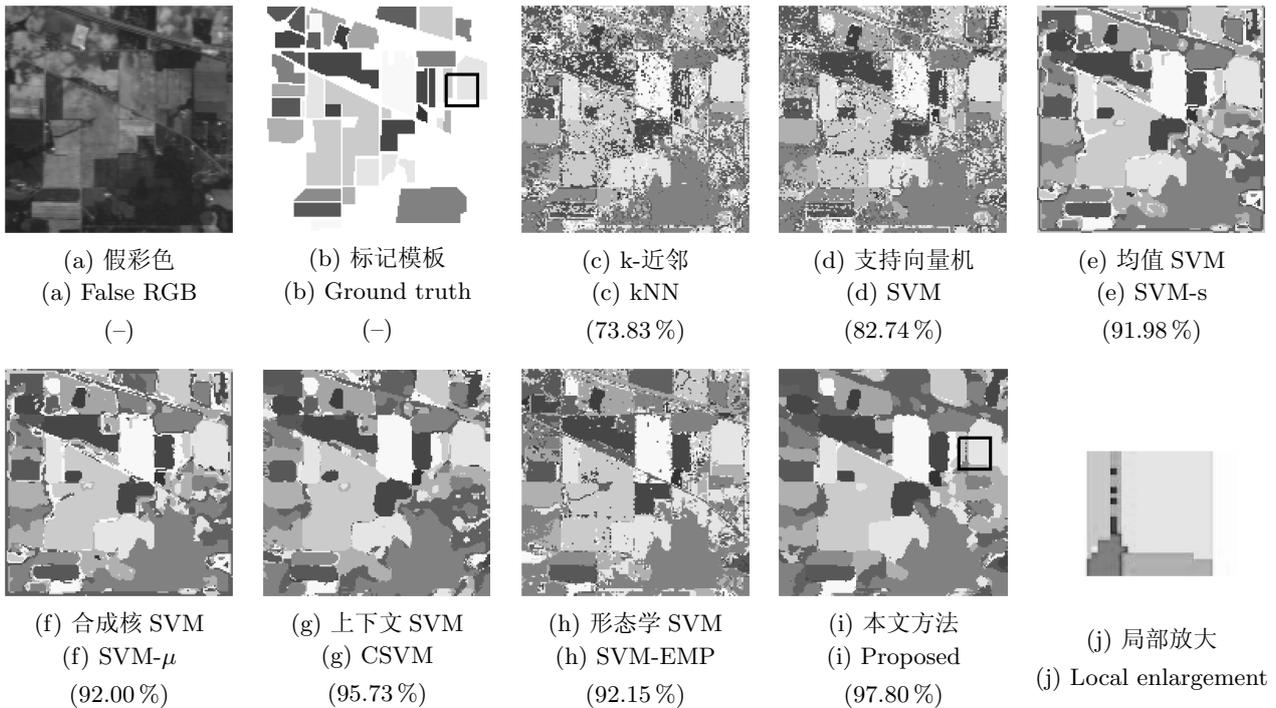


图9 Indian Pines 数据集: 使用 5% 的训练样本各个算法得到的分类图及对应的正确率

Fig. 9 Classification maps and overall accuracy (OA) for the Indian Pines dataset using 5% training samples per class

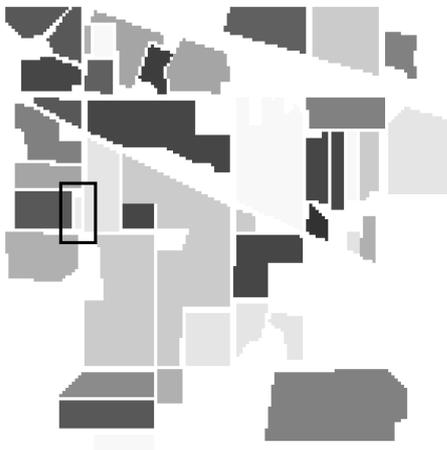


图 10 本文方法结果欠佳的情况 (黑框部分的 Oats)
Fig. 10 The poor case of the proposed algorithm (Oats in the black box)

3.2.2 University of Pavia 数据集

使用上面相同的参数检验方法可得到该数据集的合理取值为: 特征提取的维数 $d = 25$, NC-SVM 的邻域宽度 $W = 7$. 本实验分别采用非平衡的训练集 (即每类的训练样本数量相同) 和平衡的训练集 (即每类的训练样本与各类样本总量成比例), 来检验不同训练集条件下各算法的分类性能.

对于非平衡的训练集, 每类分别抽取相同数量的标记样本来训练分类器. 对不同数量的训练样本, 各个算法得到的分类结果如图 11 所示. 可见, 本文

算法的分类正确率均高于其他方法.

对于平衡的训练集, 每类分别抽取 1% 的标记样本进行训练, 其余的样本用于测试. 各算法得到的分类结果如表 2 所示, 图 12 是某次随机实验得到的分类图. 同样, 本文算法对大多数类别仍然具有最高的分类正确率, 且得到的分类图的分类噪声也更少, 计算时间相比其他算法也没有明显增加, 再次表明本文算法的实用性.

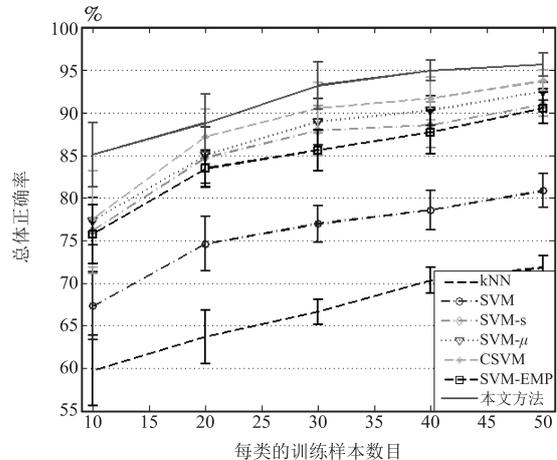


图 11 University of Pavia 数据集: 不同数量的训练样本下各种方法的分类正确率

Fig. 11 Classification accuracy (OA) for the University of Pavia dataset using different number of training samples per class

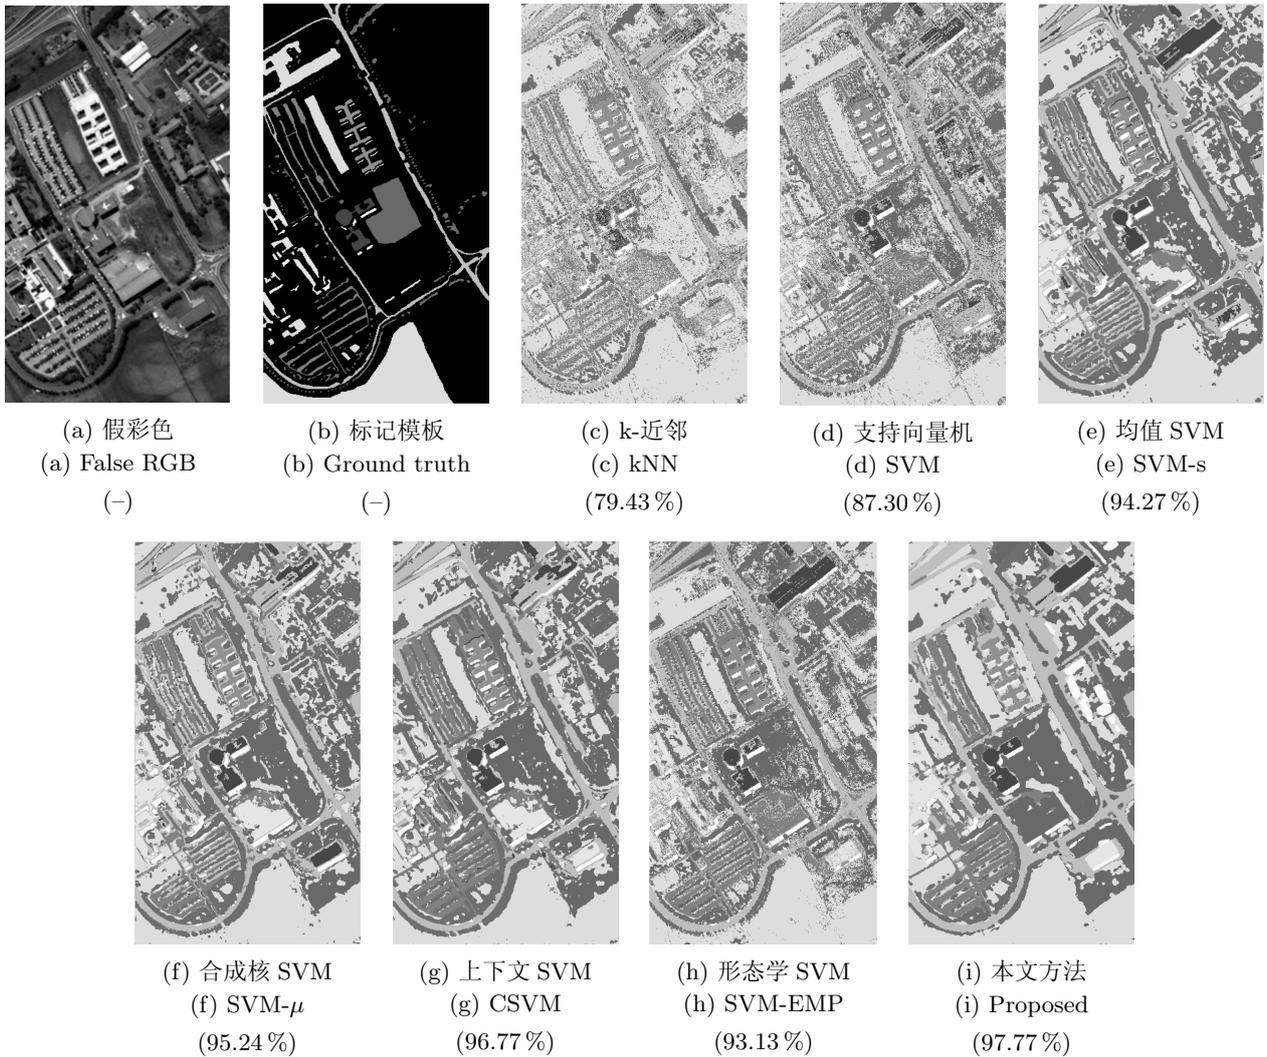


图 12 University of Pavia 数据集: 使用 1% 的训练样本各个算法得到的分类图及对应的正确率
 Fig.12 Classification maps and overall accuracy (OA) for the University of Pavia dataset using 1% training samples per class

4 结论

本文提出了一种简单有效的高光谱图像谱-空联合分类方法, 首先运用 NWFE 进行特征提取, 减小信息冗余; 然后使用双边滤波器进行空间滤波, 消除噪声干扰; 最后使用本文提出的基于近邻协同的 SVM 进行分类. 本文方法除了在分类之前进行有效的空间预处理外, 在分类阶段再次利用了地物分布的空间平滑特性, 弥补了传统方法在分类阶段往往只考虑单个像素而忽略空间信息的不足, 进一步提高了算法的分类性能. 相比已有的相关算法, 本文方法对于只有少量的训练样本的情况具有较明显的分类性能提升, 而且不会带来计算量的明显增加, 可以实现少量训练样本下遥感高光谱图像的快速高精度分类.

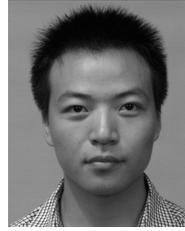
需要指出, 本文算法的近邻协同存在引入异类地物干扰的风险, 特别是当某类地物分布过于狭窄 (如 Indian Pines 数据集中的 Oats 和 University of Pavia 数据集中的 Shadows) 时, 其空间近邻大部分为异类地物, 这时引入空间近邻反而易造成错分. 其本质原因是这些情况下地物分布的空间平滑特性不再成立, 盲目地强加该先验知识会适得其反. 对于这种情况, 可以结合后处理, 或单像素分类和近邻协同分类相结合等方法进行补偿, 这些都是值得继续研究的方向.

References

- 1 Shaw G, Manolakis D. Signal processing for hyperspectral image exploitation. *Signal Processing Magazine*, 2002, 19(1): 12-16

- 2 He Lin, Pan Quan, Di Wei, Li Yuan-Qing. Supervised detection for hyperspectral imagery based on high-dimensional multiscale autoregression. *Acta Automatica Sinica*, 2009, **35**(5): 509–518
(贺霖, 潘泉, 邸韡, 李远清. 高光谱图像高维多尺度自回归有监督检测. *自动化学报*, 2009, **35**(5): 509–518)
- 3 Wang Yan-Qing, Ma Lei, Tian Yuan. State-of-the-art of ship detection and recognition in optical remotely sensed imagery. *Acta Automatica Sinica*, 2011, **37**(9): 1029–1039
(王彦清, 马雷, 田原. 光学遥感图像舰船目标检测与识别综述. *自动化学报*, 2011, **37**(9): 1029–1039)
- 4 Su Juan, Wang Gui-Jin, Lin Xing-Gang, Liu Dai-Zhi. A change detection algorithm for man-made objects based on multi-temporal remote sensing images. *Acta Automatica Sinica*, 2008, **34**(9): 1040–1046
(苏娟, 王贵锦, 林行刚, 刘代志. 基于多时相遥感图像的人造目标变化检测算法. *自动化学报*, 2008, **34**(9): 1040–1046)
- 5 Hughes G. On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 1968, **14**(1): 55–63
- 6 Zhang Xue-Gong. Introduction to statistical learning theory and support vector machines. *Acta Automatica Sinica*, 2000, **26**(1): 32–42
(张学工. 关于统计学习理论与支持向量机. *自动化学报*, 2000, **26**(1): 32–42)
- 7 Camps-Valls G, Gomez-Chova L, Munoz-Mari J, Vila-Frances J, Calpe-Maravilla J. Composite kernels for hyperspectral image classification. *IEEE Geoscience and Remote Sensing Letters*, 2006, **3**(1): 93–97
- 8 Gurram P, Heesung K. Contextual SVM using Hilbert space embedding for hyperspectral classification. *IEEE Geoscience and Remote Sensing Letters*, 2013, **10**(5): 1031–1035
- 9 Fauvel M, Benediktsson J A, Chanussot J, Sveinsson J R. Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46**(11): 3804–3814
- 10 Tarabalka Y, Fauvel M, Chanussot J, Benediktsson J A. SVM- and MRF-based method for accurate classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 2010, **7**(4): 736–740
- 11 Tan Kun, Du Pei-Jun, Wang Xiao-Mei. Impacts of feature dimensionality to the support vector machine classifier for hyperspectral remote sensing image. *Science of Surveying and Mapping*, 2011, **36**(1): 55–57
(谭琨, 杜培军, 王小美. 特征维数对支持向量机分类器性能影响的研究. *测绘科学*, 2011, **36**(1): 55–57)
- 12 Chen Hong-Da, Pu Han-Ye, Wang Bin, Zhang Li-Ming. Image Euclidean distance-based manifold dimensionality reduction algorithm for hyperspectral imagery. *Journal of Infrared and Millimeter Waves*, 2013, **32**(5): 450–455
(陈宏达, 普晗晔, 王斌, 张立明. 基于图像欧氏距离的高光谱图像流形降维算法. *红外与毫米波学报*, 2013, **32**(5): 450–455)
- 13 Kuo B C, Landgrebe D A. Nonparametric weighted feature extraction for classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, **42**(5): 1096–1105
- 14 Chang Y L, Liu J N, Han C C, Chen Y N. Hyperspectral image classification using nearest feature line embedding approach. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(1): 278–287
- 15 Li W, Prasad S, Fowler J E, Bruce L M. Locality-preserving dimensionality reduction and classification for hyperspectral image analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, **50**(4): 1185–1198
- 16 Shi Q, Hang L P, Du B. Semisupervised discriminative locally enhanced alignment for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **51**(9): 4800–4815
- 17 Ly N H, Du Q, Fowler J E. Sparse graph-based discriminant analysis for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, **50**(7): 3872–3884
- 18 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
- 19 Gao Xiao-Jian, Guo Bao-Feng, Yu Ping. Classification of hyperspectral remote sensing image based on spatial-spectral integration. *Laser and Infrared*, 2013, **43**(11): 1296–1300
(高晓建, 郭宝峰, 于平. 高光谱空谱一体化图像分类研究. *激光与红外*, 2013, **43**(11): 1296–1300)
- 20 Gao Heng-Zhen, Wan Jian-Wei, Wang Li-Bao, Xu Zhan. Research on classification technique for hyperspectral imagery based on spectral-spatial composite kernels. *Signal Processing*, 2011, **27**(5): 648–652
(高恒振, 万建伟, 王力宝, 徐湛. 基于谱域-空域组合核函数的高光谱图像分类技术研究. *信号处理*, 2011, **27**(5): 648–652)
- 21 Qian Y T, Ye M C, Zhou J. Hyperspectral image classification based on structured sparse logistic regression and three-dimensional wavelet texture features. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **51**(4): 2276–2291
- 22 Tarabalka Y, Benediktsson J A, Chanussot J. Spectral-spatial classification of hyperspectral imagery based on partitioned clustering techniques. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, **47**(8): 2973–2987
- 23 Bai J, Xiang S M, Pan C H. A graph-based classification method for hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **51**(2): 803–817
- 24 Gustavo C V, Shervashidze N, Borgwardt K M. Spatio-spectral remote sensing image classification with graph kernels. *IEEE Geoscience and Remote Sensing Letters*, 2010, **7**(4): 741–745
- 25 Li W, Tramel E W, Prasad S, Fowler J E. Nearest regularized subspace for hyperspectral classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(1): 477–489
- 26 Tomasi C, Manduchi R. Bilateral filtering for gray and color images. In: *Proceedings of the 6th International Conference on Computer Vision*. Bombay, India: IEEE, 1998. 839–846

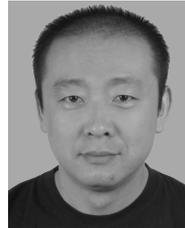
- 27 Cristianini N, John S T. *An Introduction to Support Vector Machines: and Other Kernel-Based Learning Methods*. Cambridge: Cambridge University Press, 2000.
- 28 Tadjudin S, Landgrebe D A. Covariance estimation with limited training samples. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, **37**(4): 2113–2118
- 29 Richards J A, Jia X. *Remote Sensing Digital Image Analysis: An Introduction*. New York: Springer-Verlag, 2006.
- 30 Chang C C, Lin C J. LIBSVM — A Library for Support Vector Machines [Online], available: <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, November 12, 2013
- 31 Ye J. Characterization of a family of algorithms for generalized discriminant analysis on undersampled problems. *Journal of Machine Learning Research*, 2005, **6**(4): 483–502
- 32 Bandos T V, Bruzzone L, Camps-Valls G. Classification of hyperspectral images with regularized linear discriminant analysis. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, **47**(3): 862–873
- 33 Sugiyama M. Dimensionality reduction of multimodal labeled data by local Fisher discriminant analysis. *Journal of Machine Learning Research*, 2007, **8**(5): 1027–1061



倪 鼎 清华大学电子工程系博士研究生. 2012 年获得华中科技大学电子与信息工程系学士学位. 主要研究方向为遥感图像处理, 高光谱分类, 信息处理, 模式识别. 本文通信作者.

E-mail: nid12@mails.tsinghua.edu.cn

(**NI Ding** Ph.D. candidate in the Department of Electronic Engineering, Tsinghua University. He received his bachelor degree from Huazhong University of Science and Technology in 2012. His research interest covers remote sensing image processing, hyperspectral data classification, information processing, and pattern recognition. Corresponding author of this paper.)



马洪兵 清华大学电子工程系副教授. 1999 年获北京大学博士学位. 主要研究方向为图像处理, 模式识别, 空间信息处理与应用.

E-mail: hbma@mail.tsinghua.edu.cn

(**MA Hong-Bing** Associate professor in the Department of Electronic Engineering, Tsinghua University. He received his Ph.D. degree from Peking University in 1999. His research interest covers image processing, pattern recognition, and spatial information processing and application.)