

基于联合稀疏表示与形态特征提取的高光谱图像分类

王佳宁

陕西学前师范学院计算机与电子信息系, 陕西 西安 710100

摘要 为了进一步提高稀疏表示分类能力,提出了基于联合稀疏表示算法与形态学特征的高光谱图像(HSI)分类算法。该算法对高光谱图像提取主成分特征图,并利用结构元素对主成分特征图进行多维的空间结构特征提取,结合提取的形态学特征与原始光谱特征,利用联合稀疏表示算法将同一空间区域中的像元联合进行稀疏系数矩阵的求解,最终通过最小残差判断准则确定像元类别。在 AVIRIS 与 ROSIS HSI 上的实验结果表明,该算法在分类效果和分类总精度上都有显著提高。

关键词 遥感; 联合稀疏表示算法; 形态学特征; 空谱信息; 高光谱遥感图像; 分类

中图分类号 TP751 文献标识码 A

doi: 10.3788/LOP53.082801

Hyperspectral Image Classification Based on Joint Sparse Representation and Morphological Feature Extraction

Wang Jianing

Department of Computer & Electronic Information, Shaanxi Xueqian Normal University,
Xi'an, Shaanxi 710100, China

Abstract In order to further improve the classification performance of sparse representation classification, a hyperspectral image (HSI) classification algorithm based on joint sparse representation with morphological feature extraction is proposed. To obtain the principle component images, the whole HSI is analyzed by principle component analysis. The closing and opening operations are implemented on principle component images to extract the morphological features. Combining the original spectral and the morphological feature, the pixels in a local region around the central test pixel are simultaneously represented by a set of common atoms of new training dictionary. The classification of HSI is determined by computing the minimum reconstruction error between testing samples and training samples. Experimental results on AVIRIS and ROSIS HSI demonstrate that the effectiveness of the proposed method for improving the classification accuracy and performance.

Key words remote sensing; joint sparse representation algorithm; morphological feature; spatial-spectral information; hyperspectral remote sensing image; classification

OCIS codes 280.4750; 100.4145; 330.6180

1 引言

高光谱遥感技术是利用具有纳米级光谱分辨率的成像光谱仪来获取连续光谱图像的技术^[1]。因此,高光谱图像(HSI)中的每个像元都是一条含有几十甚至上百维光谱信息的光谱曲线,不同的地物类型呈现出不同的光谱曲线特性,使得高光谱分类技术在地物分类、军事勘察、精细农业、环境监控等领域得到了广泛的应用和关注^[2-5]。在有监督分类技术中基于支撑向量机(SVM)的算法在高光谱图像的分类处理中得到了广泛的应用, Melgani 等^[6-7]提出了利用光谱特征作为样本特征的分类算法。樊利恒等^[8]提出了基于光谱波段分组和分类器集成的方法。但是仅仅依赖于单个像元不考虑空间关系的分类方法,常常造成分类结果的不

收稿日期: 2016-01-27; 收到修改稿日期: 2016-03-29; 网络出版日期: 2016-07-25

基金项目: 国家自然科学基金(61201422, 61501287, 31300473)、陕西省教育厅科学研究计划项目(14JK1179)

作者简介: 王佳宁(1982—),女,博士,讲师,主要从事光学图像处理、模式识别与光学遥感影像的智能化处理等方面的研究。E-mail: circuitwang@163.com

平滑性。因此,基于将同一局部区域内的像元认为是同一物质组成的假设,Gustavo 等^[9]利用加窗方法将空间信息引入至复合核 SVM 算法中,有效地提高了高光谱图像分类的精度和分类结果的平滑性。

稀疏表示分类(SRC)算法^[10]首先在人脸识别应用中提出。SRC 算法将每一个待分类的测试样本看成少量已有标记样本的线性叠加,并通过计算测试样本与各类别有标记样本的最小残差判断待测样本的类别。在高光谱遥感图像的分类应用中,Chen 等^[11]将 SRC 模型应用于高光谱图像分类,并考虑了空间四邻域关系。随后为进一步提高分类结果的区域平滑性,Chen 等^[12]提出了联合稀疏表示分类算法(JSRC),JSRC 对位于局部矩形窗口内的像元同时进行稀疏系数矩阵的求解,并通过计算空间样本整体的最小残差确定中心像元的类别。

但是上述算法只是简单地考虑了矩形空间窗口中的像元关系,未能充分挖掘高光谱图像中的结构信息特征。本文在文献[13]与[14]的基础上,通过形态学特征提取方法进一步挖掘空间结构信息,结合 JSRC 良好的平滑特性,提出了一种基于形态学特征提取的 JSRC 高光谱遥感图像分类方法。该算法通过具有一定结构和参数差异性的结构元素对高光谱遥感图像的主成分图进行形态学特征提取,利用 JSRC 方法在具有空谱特性的新特征像元空间上求解稀疏系数矩阵,并通过计算新特征空间下待测样本与各类别样本间的最小残差确定待测样本的类别。在 AVIRIS 与 ROSIS 高光谱遥感图像上的实验结果表明,本文方法不但提高了分类的总精度,而且也提高了分类结果的平滑性。

2 基于 SRC 算法的高光谱图像分类

稀疏表示分类算法的基本思想是将每一个测试样本看成字典原子的线性组合,并通过计算测试样本与各类别的线性重构残差确定测试样本的类别。在高光谱图像的分类应用中,高维的光谱特征为高光谱遥感图像的分类应用提供了有效的类别区分性。因此,在高光谱图像的稀疏表示分类应用中,字典常常直接由具有高维光谱特征的有标记像元(训练样本)构成,假设共有 N 个有标记像元和 L 个不同类别,且用于分类应用的高光谱波段数为 B ,则由训练样本组成的字典可直接记为 $\mathbf{X}=[\mathbf{X}_1, \dots, \mathbf{X}_i, \dots, \mathbf{X}_L]=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbb{R}^{B \times N}$,其中 $\{\mathbf{X}_i\}_{i=1,2,\dots,L}$ 为各类子字典,对于任意一个待测像元 $\mathbf{y} \in \mathbb{R}^B$,可以看成是已有标记像元的线性组合,

$$\mathbf{y} = \mathbf{X}_1 \boldsymbol{\alpha}_1 + \dots + \mathbf{X}_i \boldsymbol{\alpha}_i + \dots + \mathbf{X}_L \boldsymbol{\alpha}_L + \boldsymbol{\varepsilon} = \mathbf{X} \boldsymbol{\alpha} + \boldsymbol{\varepsilon}, \quad (1)$$

式中 $\boldsymbol{\alpha} \in \mathbb{R}^N$ 为待求解的稀疏系数向量, $\boldsymbol{\varepsilon}$ 为随机残差。 $\boldsymbol{\alpha}$ 可通过求解如下表达式得到,

$$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \frac{1}{2} \|\mathbf{y} - \mathbf{X} \boldsymbol{\alpha}\|_2^2, \text{ s.t. } \|\boldsymbol{\alpha}\|_0 \leq K_0, \quad (2)$$

或者

$$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \frac{1}{2} \|\mathbf{y} - \mathbf{X} \boldsymbol{\alpha}\|_2^2 + \lambda \|\boldsymbol{\alpha}\|_1, \quad (3)$$

式中 K_0 为稀疏向量 $\hat{\boldsymbol{\alpha}}$ 中非零系数的个数。 $\lambda > 0$ 在(3)式中主要控制稀疏向量 $\hat{\boldsymbol{\alpha}}$ 的稀疏程度。稀疏向量 $\hat{\boldsymbol{\alpha}}$ 可以分别通过正交匹配追踪算法(OMP)^[14]和 Lasso^[15]算法求得。 \mathbf{y} 的标记则可通过解得的稀疏向量 $\hat{\boldsymbol{\alpha}}$ 与各类子字典之间的最小重构误差而确定

$$\text{Class}(\mathbf{y}) = \underset{i=1,2,\dots,L}{\operatorname{argmin}} \|\mathbf{y} - \mathbf{X}_i \hat{\boldsymbol{\alpha}}_i\|_2, \quad (4)$$

式中 $\hat{\boldsymbol{\alpha}}_i$ 为相应的第 i 类有标记像元所对应的稀疏系数向量。这种仅利用高维光谱特征进行高光谱图像分类的算法往往忽略了像元空间结构与地物之间的形态学特征关系,从而造成分类结果的精度不高以及分类结果中样本的离散错分情况。

3 本文算法

3.1 形态学特征提取

高光谱图像中除高维的光谱特征信息外,二维空间关系也常用于像元分类。本文首先利用主成分分析(PCA)方法对高维的高光谱图像提取主成分分析特征图,然后利用结构元素对所提取的主成分分析特征图

进行多尺度多层次化的形态特征提取,从而为单个像元特征向量引入了空间结构特征,提高了每个像元在空间上的区分性。对于高光谱图像的主成分灰度特征图 I ,其被结构元素 B 进行腐蚀与膨胀的操作分别定义为

$$I \ominus B = \{x \mid (B)_x \subseteq I\}, \quad (5)$$

$$I \oplus B = \{x \mid [(\overset{\triangleright}{B})_x \cap I] \subseteq I\}, \quad (6)$$

式中 $\overset{\triangleright}{B} = \{x \mid x = -b, b \in B\}$ 表示 B 的映像。通过对腐蚀与膨胀运算的组合可实现形态学开运算与闭运算操作。开运算通过先腐蚀后膨胀的方法消除小物体,在纤细点处分离物体。而闭运算通过先膨胀后腐蚀的运算来填充物体内部细小空洞,连接邻近物体。形态学开运算 $O(I)$ 与闭运算 $\rho(I)$ 分别定义为

$$O(I) = I \circ RB = (I \ominus B) \oplus B, \quad (7)$$

$$\rho(I) = I \bullet B = (I \oplus B) \ominus B. \quad (8)$$

本文算法通过不同半径范围的盘状形态学结构元素 B_r ,对主成分分析特征图实现多尺度层级化的形态特征提取。

3.2 联合稀疏表示分类

在高光谱图像分类应用中,基于地物在一个小的邻域空间内具有高度的空间相关特性的假设,利用 JSRC 算法的思想,进一步充分的挖掘相邻像元间的空间相关特性。取 $\sqrt{T} \times \sqrt{T}$ 的邻域窗口,对于中心的目标像元 y 进行特征提取后的空间邻域矩阵可记为 $\tilde{Y} = [\tilde{y}_1, \tilde{y}_2, \dots, \tilde{y}_T] \in \mathbb{R}^{S \times T}$,其中 $S = B + P$ 为光谱特征向量 B 与形态学特征向量 P 的组合,则可将空间矩阵 $\tilde{Y} \in \mathbb{R}^{S \times T}$ 中的每个像元同时看成由有标记像元构成的特征字典上的稀疏系数矩阵的线性组合,即

$$\tilde{Y} = [\tilde{y}_1, \tilde{y}_2, \dots, \tilde{y}_T] = [\tilde{X}\alpha_1, \tilde{X}\alpha_2, \dots, \tilde{X}\alpha_T] = \tilde{X}[\alpha_1, \alpha_2, \dots, \alpha_T] = \tilde{X}A, \quad (9)$$

式中 $\tilde{X} \in \mathbb{R}^{S \times N}$ 为光谱特征与形态特征组合的新特征字典, $A = [\alpha_1, \alpha_2, \dots, \alpha_T] \in \mathbb{R}^{N \times T}$ 为在新特征空间下的稀疏系数矩阵, α_i 为空间邻域矩阵中 y_i 对应的稀疏系数向量,稀疏系数矩阵 A 可通过求解如下优化问题得到

$$A = \arg \min_{A \in \mathbb{R}^{N \times T}} \|\tilde{Y} - \tilde{X}A\|_F, \quad s.t. \|A\|_{\text{row},0} \leq K_0, \quad (10)$$

此处使用的是联合稀疏范数, K_0 为限定的非零行的个数, $\|\cdot\|_F$ 为 Frobenius 范数。 $\|A\|_{\text{row},0}$ 要求稀疏系数矩阵 A 中稀疏系数向量的非零元素应当位于相同的行,也即约束位于同一局部区域内的像元应当是同一类训练特征原子的组合。该优化问题可以通过同时正交匹配追踪算法(SOMP)^[12]进行优化求解。SOMP 算法通过同步迭代得到相关矩阵 $C = \tilde{X}^T R_{k-1}$,其中 R_{k-1} 为 \tilde{Y} 与其近似之间的残差, C 中的第 (i, t) 个元素为字典原子 x_i 与 \tilde{y}_t 的残差向量在第 k 次迭代的相关程度。通过多次迭代不断更新字典原子中能够使残差最小的原子坐标集 η ,可解得稀疏表示矩阵 $A = (\tilde{X}_\eta^T \tilde{X}_\eta)^{-1} \tilde{X}_\eta^T \tilde{Y}$ 。由此,位于邻域中心的目标像元 y 的标记可以通过下式确定

$$\text{Class}(y) = \arg \min_{i=1,2,\dots,L} \|\tilde{Y} - \tilde{X}_i \hat{A}_i\|_F^2, \quad (11)$$

式中 \hat{A}_i 为相应的第 i 类训练样本所对应的稀疏系数矩阵, $\{\tilde{X}_i\}_{i=1,2,\dots,L}$ 为训练样本在新特征空间下的各类子字典。

3.3 本文算法步骤

本文算法充分利用多尺度化的盘状形态学结构元素对高光谱遥感图像提取的前三幅主成分特征图进行形态学特征向量的提取,后基于同一局部区域内的像元由同类物质构成的空间假设,通过 JSRC 算法在空间关系约束上的优势,联合求解位于同一区域内像元的稀疏表示系数,并最终通过计算局部区域内的联合最小残差确定中心样本的像元类别。主要算法步骤如下:

1) 利用主成分分析算法,提取高光谱遥感图像的三幅主要成分灰度特征图 I_0, I_1 和 I_2 。

2) 利用(7)和(8)式,通过选择半径范围为 $1 \sim 10$ 的盘状结构元素 B_r 对主成分灰度特征图 I_0, I_1 和 I_2 提取如下形态学开运算与闭运算特征向量图集;

$$Z_0 = \{Z_0^r(I_i) = O(I_i) = (I_i \ominus B_r) \oplus B_r, \forall r \in [1, R]\}, i = 0, 1, 2, \quad (12)$$

$$\mathbf{Z}_\rho = \{Z_\rho^r(\mathbf{I}_i) = \rho(\mathbf{I}_i) = (\mathbf{I}_i \oplus \mathbf{B}_r) \ominus \mathbf{B}_r, \forall r \in [1, R]\}, i = 0, 1, 2. \quad (13)$$

3) 将提取出的形态学开运算图集与闭运算图集与原高光谱特征向量进行级联, 组成新的特征向量字典集 $\tilde{\mathbf{X}}$ 与待测试样本特征向量 \mathbf{y} 。

4) 根据待测样本位置取 $\sqrt{T} \times \sqrt{T}$ 的邻域窗口, 得到邻域矩阵 $\tilde{\mathbf{Y}} \in \mathbb{R}^{S \times T}$ 。根据(10)式, 求出联合稀疏表示系数矩阵 $\mathbf{A} \in \mathbb{R}^{N \times T}$ 。

5) 根据(11)式计算局部区域内的联合最小残差确定待测中心像元 \mathbf{y} 的类别。

4 实验结果及分析

4.1 实验数据

在实验中主要对 AVIRIS 高光谱遥感数据和 ROSIS 高光谱遥感数据进行分类结果验证。AVIRIS 高光谱遥感数据采集于美国西北部印第安纳松林, 空间分辨率为 20 m, 谱间分辨率为 10 nm, 谱段范围为 0.4 ~ 2.5 μm 。图像大小为 145 pixel \times 145 pixel, 共 200 个光谱波段。整幅图像数据具有 16 种地物类别, 在每类样本中随机选择约 10% 的有标记像元作为训练样本。ROSIIS 高光谱遥感数据采集于意大利帕维亚大学校园, 图像大小为 610 pixel \times 340 pixel, 空间分辨率为 1.3 m/pixel, 波段范围从 0.43 ~ 0.86 μm , 共选取其中 103 个波段进行分类测试, 整幅图像具有 9 种地物类别, 在每类有标记样本中随机选择 50 个有标记样本作为训练样本。表 1 为两幅高光谱图像数据的地物类别、训练样本以及测试样本的数目。

4.2 评价指标与算法参数

本文分类结果主要通过分类总精度(OA)、平均分类精度(AA)以及 Kappa 系数(KC) 三个评价指标进行分类效果的评价与衡量。分类 OA 与 KC 分别由下式计算求得,

$$A_O = \sum_{i=1}^L M_{ii} / n, \quad (14)$$

$$C_K = \left[n \left(\sum_{i=1}^L M_{ii} \right) - \sum_{i=1}^L \left(\sum_{j=1}^L M_{ij} \sum_{j=1}^L M_{ji} \right) \right] / \left[n^2 - \sum_{i=1}^L \left(\sum_{j=1}^L M_{ij} \sum_{j=1}^L M_{ji} \right) \right], \quad (15)$$

式中 \mathbf{M} 为 $L \times L$ 的混淆矩阵, 则 M_{ij} 反映了类别 j 被分类为类别 i 的样本数量。

表 1 不同高光谱图像数据的训练与测试样本数

Table 1 Training and testing number for different hyperspectral image datasets

| Class | Indian Pines | | | Pavia University | | |
|-------|-----------------------------|-------|-------|------------------|-------|-------|
| | Class name | Train | Test | Class name | Train | Test |
| 1 | Alfalfa | 6 | 48 | Asphalt | 50 | 6581 |
| 2 | Corn-no till | 144 | 1290 | Meadows | 50 | 18599 |
| 3 | Corn-min | 84 | 750 | Gravel | 50 | 2049 |
| 4 | Corn | 24 | 210 | Trees | 50 | 3014 |
| 5 | Grass/Pasture | 50 | 447 | Metal sheets | 50 | 1295 |
| 6 | Grass/Trees | 75 | 672 | Bare soil | 50 | 4979 |
| 7 | Grass/Pasture-mowed | 3 | 23 | Bitumen | 50 | 1280 |
| 8 | Hay-windrowed | 49 | 440 | Bricks | 50 | 3632 |
| 9 | Oats | 2 | 18 | Shadows | 50 | 897 |
| 10 | Soybeans-no till | 97 | 871 | | | |
| 11 | Soybeans-min | 247 | 2221 | | | |
| 12 | Soybean-clean | 62 | 552 | | | |
| 13 | Wheat | 22 | 190 | | | |
| 14 | Woods | 130 | 1164 | | | |
| 15 | Building-Grass-Tree-Drivers | 38 | 342 | | | |
| 16 | Stone-steel Towers | 10 | 85 | | | |
| Total | 1043 | 9323 | Total | 450 | 42326 | |

本文算法中的参数主要有局部窗口大小 T 和 JSRC 算法中的稀疏系数 K_0 。图 1 显示了本文算法相对

于 JSRC 算法在不同窗口大小情况下对 OA 的影响。图 2 显示了本文算法相对于 JSRC 算法在不同稀疏度 K_0 情况下对 OA 的影响。可以看出在不同的窗口大小和不同的稀疏度下,本文算法都明显优于原始 JSRC 算法。为得到最佳分类结果,在结果比较中均取窗口与稀疏系数的最优参数。




图 1 窗口大小对 OA 的影响。(a) 印第安纳松林; (b) 帕维亚大学

Fig. 1 Effect of window size versus OA. (a) Indiana pines; (b) Pavia university




图 2 稀疏度 K_0 对 OA 的影响。(a) 印第安纳松林; (b) 帕维亚大学

Fig. 2 Effect of sparseness K_0 versus OA. (a) Indiana pines; (b) Pavia university

4.3 实验结果

本文算法与 SRC 算法、核化的 SVM 算法、核稀疏表示算法(KSRC)^[16]以及 JSRC 算法进行分类比较。其中 SRC 是直接利用高维光谱信息进行分类的算法,采用 Lasso 算法进行稀疏系数的求解。SVM 算法与 KSRC 算法是利用光谱信息进行核变换分类的算法,且均采用径向基函数作为核变换函数,JSRC 是考虑了局部空间关系的分类算法,分类的正确率比较结果如表 2 所示。从实验结果可以看出,本文算法在两幅真实高光谱图像数据上的分类正确率均优于其他比较算法。相较于仅考虑光谱信息的 SRC 算法有 14% 左右正确率的提高,比基于核变换的光谱算法 SVM 与 KSRC 有 12% 左右正确率的提高,比 JSRC 算法也有 3% 左右正确率的提高。

表 2 不同算法的分类正确率比较

Table 2 Comparison of classification accuracy with different algorithms

| | | SRC | SVM | KSRC | JSRC | Proposed |
|------------------------|----|-------|--------|-------|-------|----------|
| AVIRIS Indiana pines | OA | 82.71 | 85.08 | 85.99 | 94.27 | 97.74 |
| | AA | 79.18 | 82.14 | 83.51 | 82.51 | 93.31 |
| | KC | 0.80 | 0.83 | 0.84 | 0.94 | 0.97 |
| ROSIS Pavia university | OA | 74.35 | 78.84 | 77.55 | 91.03 | 97.80 |
| | AA | 79.40 | 84.664 | 81.20 | 92.30 | 97.65 |
| | KC | 0.67 | 0.73 | 0.71 | 0.88 | 0.97 |

图 3 与图 4 分别展示了本文算法与其他算法的分类结果,从图中可以看出, SRC、SVM 和 KSRC 这些基于单个像元而未考虑空间关系的分类算法,在分类结果图上体现了更多的离散错分样本点,从而使分类结果不够平滑以致分类正确率降低。而考虑了空间约束关系的 JSRC 算法在分类结果上体现了较高的平滑

性,减少了离散错分样本的数目,但是由于 JSRC 仅采用加矩形窗的方法进行了空间关系的考虑,所以易导致类别边界处样本错分。从图中可以看出,本文算法在 JSRC 的基础上充分提取了二维图像中的形态学特征,因此有效地提高了地物类别边界处的分类效果。

表 3 不同算法的计算时间比较

Table 3 Comparison of computation time with different algorithms

| | Indiana pines /s | Pavia university /s |
|----------|------------------|---------------------|
| SRC | 9980 | 72631 |
| KSRC | 7995 | 53330 |
| JSRC | 1327 | 13134 |
| Proposed | 1125 | 15731 |

此外,在 Inter(R) Core(TM) i5 处理器,3.2GHz 和 4GB 内存下,通过 Matlab 仿真实验验证比较了各种算法的计算时间,由于 SVM 算法利用到了 C 语言代码所以未作比较。其中,基于原特征的 JSRC 算法的计算复杂度主要产生在相关矩阵 C 的计算过程中,则计算复杂度主要为 $O(BNT)$,本文算法的计算复杂度主要为 $O(SNT)$ 。从表 3 实验结果可以看出,本文算法与 JSRC 算法相比并未显著提高算法的运算时间,却有效地提高了分类的正确率。图 5 为两幅高光谱图像在不同训练样本情况下,不同分类算法之间的分类正确率的比较结果。可以看出,随着训练样本数目的增多,OA 会随之提高。同时,从 OA 的变化曲线能够看出,在不同训练样本比例情况下,本文算法的 OA 均优于其他比较算法。

通过以上实验可以看出,本文算法通过同时考虑了形态学特征、高维光谱特征,并有效地利用了 JSRC 算法的空间约束关系,从而在提高分类正确率的同时保持了分类结果的平滑性,并有效地改善了类别边界处的样本错分情况。

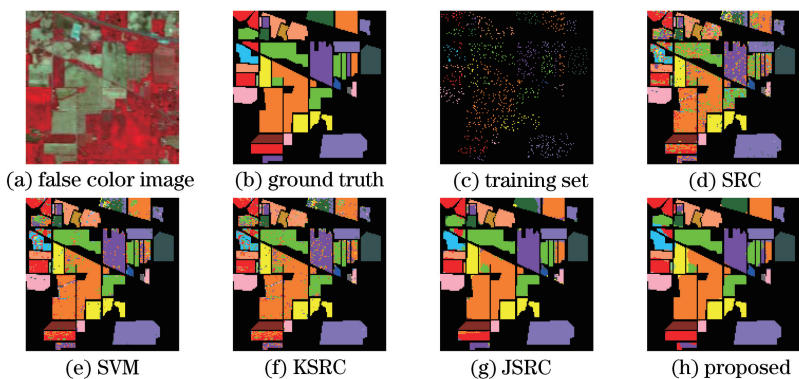


图 3 印第安纳松林高光谱遥感图像各方法的分类结果比较

Fig. 3 Comparison of classification results with different algorithms for Indiana pines hyperspectral remote sensing image

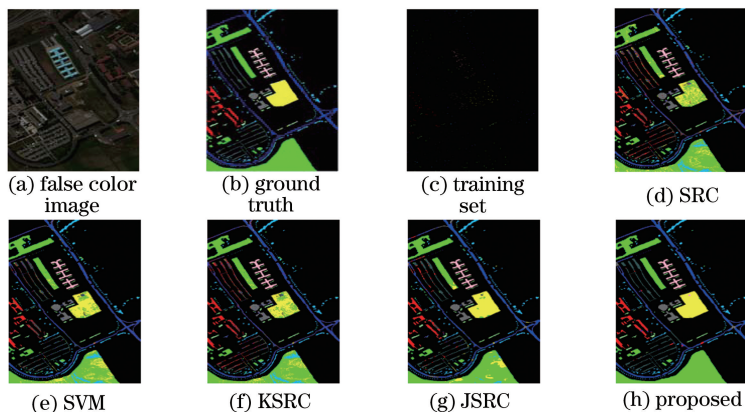


图 4 帕维亚大学高光谱遥感图像各方法的分类结果比较

Fig. 4 Comparison of classification results with different algorithms for Pavia university hyperspectral remote sensing image

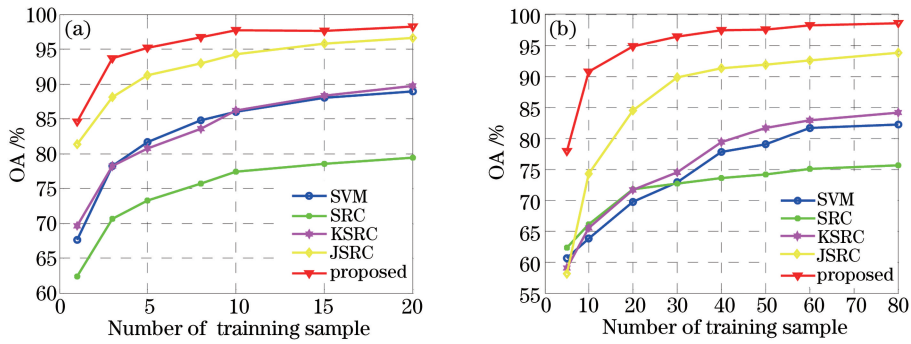


图 5 不同训练样本数对 OA 的影响 (a) 印第安纳松林; (b) 帕维亚大学

Fig. 5 Effect of OA with different training samples. (a) Indiana pines; (b) Pavia university

5 结 论

对于高光谱图像的分类,高维光谱信息常直接用于像元分类,但是其高度相关的空间关系常常在分类过程中被忽略。在充分考虑高维光谱特征的基础上,利用多尺度化的形态学结构元素对高光谱主成分特征图进行形态学特征提取,结合联合稀疏表示算法在空间关系上的约束性,将同一局部区域内的新像元特征向量联合进行稀疏系数求解,并最终通过联合残差最小确定像元样本类别。实验结果表明,本文算法在真实高光谱遥感图像分类应用中,不但提高了分类精度,而且有效提高了分类结果的平滑性,减少了仅利用光谱特征进行分类产生的离散错分样本数。

参 考 文 献

- Wang Yueming, Lang Junwei, Wang Jianyu. Status and prospect of space-borne hyperspectral imaging technology[J]. *Laser & Optoelectronics Progress*, 2013, 50(1): 010008.
王跃明, 郎均慰, 王建宇. 航天高光谱成像技术研究现状及展望[J]. *激光与光电子学进展*, 2013, 50(1): 010008.
- Wang Jinnian, Zhang Bing, Liu Jianguai, *et al.* Hyperspectral data mining-toward target recognition and classification[J]. *Journal of Image and Graphics*, 1999, 4(11): 957-964.
王晋年, 张 兵, 刘建贵, 等. 以地物识别和分类为目标的高光谱数据挖掘[J]. *中国图象图形学报*, 1999, 4(11): 957-964.
- Prasad S, Bruce L M, Chanussot J. *Optical remote sensing: Advances in signal processing and exploitation techniques* [M]. Heidelberg: Springer, 2011.
- Deng Xiaoqin, Zhu Qibing, Huang Min. Variety discrimination for single rice seed by integrating spectral, texture and morphological features based on hyperspectral image[J]. *Laser & Optoelectronics Progress*, 2015, 52(2): 021001.
邓小琴, 朱启兵, 黄 敏. 融合光谱、纹理及形态特征的水稻种子品种高光谱图像单粒鉴别[J]. *激光与光电子学进展*, 2015, 52(2): 021001.
- Shang Kun, Zhang Xia, Sun Yanli, *et al.* Sophisticated vegetation classification based on feature band set using hyperspectral image[J]. *Spectroscopy and Spectral Analysis*, 2015, 35(6): 1669-1676.
尚 坤, 张 霞, 孙艳丽, 等. 基于植被特征库的高光谱植被精细分类[J]. *光谱学与光谱分析*, 2015, 35(6): 1669-1676.
- 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.
- Tarabalka Y, Fauvel M, Chanussot J, *et al.* SVM-and MRF-based method for accurate classification of hyperspectral images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2010, 7(4): 736-740.
- 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.
- Camps-Valls G, Gomez-Chova L, Muñoz-Marí J, *et al.* Composite kernels for hyperspectral image classification[J]. *IEEE*

- Geoscience and Remote Sensing Letters, 2006, 3(1): 93-97.
- 10 Wright J, Yang A Y, Ganesh A, *et al.* Robust face recognition via sparse representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.
 - 11 Chen Y, Nasrabadi N M, Tran T D. Classification for hyperspectral imagery based on sparse representation [C]. Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), 2010: 1-4.
 - 12 Chen Y, Nasrabadi N M, Tran T D. Hyperspectral image classification using dictionary-based sparse representation [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(10): 3973-3985.
 - 13 Benediktsson J A, Pesaresi M, Arnaso K. Classification and feature extraction for remote sensing images from urban areas based on morphological transformations [J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(9): 1940-1949.
 - 14 Benediktsson J A, Palmason J A, Sveinsson J R. Classification of hyperspectral data from urban areas based on extended morphological profiles [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3): 480-491.
 - 15 Tropp J A, Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit [J]. IEEE Transactions on Information Theory, 2007, 53(12): 4655-4666.
 - 16 Tibshirani R. Regression shrinkage and selection via the LASSO [J]. Journal of the Royal Statistical Society Series B: Methodological, 1996, 58(1): 267-288.