

基于自适应字典的小样本高光谱图像分类方法

虎晓红 司海平

(河南农业大学信息与管理科学学院, 郑州 450046)

摘要: 在有限标记样本下, 为了有效协同空谱信息提高高光谱图像的分类性能, 提出了一种基于自适应字典的小样本高光谱图像分类方法。首先, 对高光谱图像进行熵率超像素分割, 分析标记样本的超像素区域和光谱近邻, 将鉴别力高的样本扩展至标记样本集; 然后, 在扩展的标记样本集上分析测试样本的空谱信息, 对不同的测试样本精简标记样本集, 形成自适应字典; 最后, 在自适应字典上, 协同空谱信息重构测试样本, 在协同表示中同时考虑重构字典中空谱信息的竞争性。实验结果表明, 对比传统的基于光谱的方法和固定窗口尺寸下融合空谱特征的高光谱图像分类方法, 在印地安农林数据集上, 当训练样本数目仅为样本集数目 2% 时, 本文方法总体分类精度为 91.45%, 比其他方法高 3.48~39.52 个百分点; 在训练样本数为 1% 的帕维亚大学数据集上, 该方法的总体分类精度达到 95.54%, 比其他方法高 2.45~21.63 个百分点, 验证了本文方法的有效性。

关键词: 高光谱图像分类; 自适应字典; 小样本; 超像素分割; 空谱重构

中图分类号: TP751 文献标识码: A 文章编号: 1000-1298(2021)01-0154-08

OSID:



Hyperspectral Image Classification Method with Small Sample Set Based on Adaptive Dictionary

HU Xiaohong SI Haiping

(College of Information and Management Science, Henan Agricultural University, Zhengzhou 450046)

Abstract: To effectively utilize the spectral and spatial information of limited labeled training samples in hyperspectral image (HSI) classification, a HSI classification approach with small sample set based on adaptive dictionary was proposed. Firstly, discriminating pixels of each labeled sample were extracted from spatial information with entropy rate segmented superpixels and spectral neighborhood, the training set was then extended by adding the discriminating pixels. Furthermore, the spatial-spectral information of each test sample was analyzed, and its adaptive dictionary was constructed by simplifying the extended training sample set. Finally, the spatial-spectral reconstruction was performed on the adaptive dictionary of each test pixel, where the collaboration and competition among dictionary elements were both considered. To evaluate the performance of the proposed approach, it was compared with some traditional methods by using spectral information and the state-of-the-art methods incorporated traditional information of fixed window size, experimental results on Indian Pines dataset with only 2% training set demonstrated that the overall accuracy of the proposed approach was 91.45%, which was 3.48~39.52 percentage points higher than that of other methods, and the results on Pavia University HSI with 1% training set showed that the overall accuracy of the proposed approach reached 95.54%, which was 2.45~21.63 percentage points higher than that of others, indicating the effectiveness of the proposed approach.

Key words: hyperspectral image classification; adaptive dictionary; small sample set; superpixel segmentation; spatial-spectral reconstruction

0 引言

高光谱图像的光谱分辨率高, 不仅能辨识不同

地物光谱间差异较大的地物类别, 而且能辨识不同地物光谱间只存在细微差异的地物类别, 在农业规划、环境监测和资源勘察等领域得到了广泛的应

用^[1-5]。对高光谱图像分类技术的研究可促进高光谱遥感的应用,近年来,高光谱图像分类已成为遥感、机器视觉和机器学习领域的研究热点,并取得了大量的研究成果。

高光谱图像分类研究主要包括高光谱图像的表达和分类器设计两方面。在高光谱图像的表达中,早期只采用光谱特征进行分类,由于缺乏空间信息,分类效果受到限制。为了更好地体现高光谱图像“图谱合一”的特点,空间信息在高光谱图像分类中得到了应用^[6],空间滤波和区域分割等空间信息表达方法拓展了高光谱图像的应用领域^[7-9],空谱融合方式的不断改进有效提高了高光谱图像的分类性能^[10]。在高光谱图像分类的分类器设计方面,传统基于统计学习的支持向量机(Support vector machine, SVM)、融合空间信息的复合核支持向量机(Support vector machine with composite kernels, SVMCK)^[11]取得了较好的分类效果;近年来,基于字典学习的稀疏分类器(Sparse representation based classification, SRC)^[12]和协同分类器(Collaborative representation classification, CRC)^[13]在高光谱图像分类中表现出良好的潜力,并得到广泛关注。文献[14]结合 SRC 和空间信息提出了高光谱图像的联合稀疏分类器(Joint sparse representation based classification, JSRC);文献[15]采用局部空间语义窗口平均特征,提出联合协同分类器(Joint collaborative representation based classification, JCRC),应用在高光谱图像分类中;文献[16]在 JSRC 中加入相关系数,提出了融合相关系数的联合稀疏表示(Correlation coefficient and joint sparse representation, CCJSR)。在空谱融合中相关系数的引入使基于字典的高光谱图像分类效果在联合空间信息的基础上得到了进一步改善^[14-16]。

然而,高光谱图像分类仍然存在一些问题:其一,在实际应用中,标注工作通常需要实地采样,相比普通相机采集的图像,标注工作更加困难,且代价更高昂,因此可利用的训练样本数量非常有限,“小样本问题”极大地影响了高光谱图像的分类性能;其二,在基于字典学习的高光谱图像分类中,当构成字典的原子数目不足时,分类性能直接受到影响,若由大量的元素创建字典进行样本重构,构成字典的原子间又会因信息冗余、字典原子间的相互干扰和字典原子数量过多而导致分类时间过长和分类效果下降。因此,如何高效地协同高光谱图像的空谱信息来进一步提升分类性能,是高光谱图像分类及其应用中亟待解决的问题。

针对这些问题,本文提出基于自适应字典的小

样本高光谱图像分类方法。通过对有限标记的训练样本空谱信息进行分析,采用伪标注方法扩展标记样本数量,并针对不同的测试样本构建其自适应字典,在自适应的空谱字典下协同重构样本,同时在协同表示中增加自适应空谱协同字典中的竞争关系,以期挖掘样本的本征,在小样本下提升高光谱图像的分类性能。

1 研究方法

1.1 高光谱图像超像素分割

在高光谱图像分类中,图像局部空间子块信息得到了广泛的采用^[11,14-16],但无论是预处理中采用的均值滤波,还是像素级高光谱图像分类后,在固定窗口尺寸上进行的空谱融合,通常无法有效地保持高光谱图像目标区域的边界。而超像素^[17]作为在一幅图像中有意义的不规则区域,通过将相似的相邻像素合并而产生,能更好地保持高光谱图像的局部细节。同时,熵率超像素分割^[18]有利于形成结构均匀、紧凑和尺寸基本一致的超像素区域,据此,本文采用熵率方法对高光谱图像进行超像素分割,分割流程如图 1 所示。

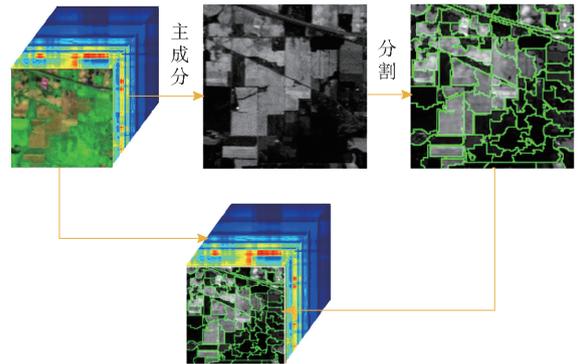


图 1 高光谱图像超像素分割

Fig. 1 Superpixel segmentation of HSI

设高光谱图像 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n] \in \mathbf{R}^{d \times n}$, d 为波段数, n 为图像像素数,图像尺寸为 $M \times N$,在对 \mathbf{X} 进行熵率超像素分割前,对 \mathbf{X} 进行主成分分析,提取高光谱图像 \mathbf{X} 的第一主成分 $\mathbf{\Gamma}$,由 $\mathbf{\Gamma}$ 的像素点构建图 $G = (V, E)$,其中 V 为 $\mathbf{\Gamma}$ 的像素点构成的顶点集, E 为描述图 G 中顶点相似性的边集,从而将图像分割转换为图的划分问题,优化目标为

$$E_s^* = \arg \max_{E_s} \{H(E_s) + \mu B(E_s)\} \quad (E_s \subseteq E) \quad (1)$$

式中 E_s, E_s^* ——选择的边集及其最优值

$H(\cdot)$ ——随机游走熵率

$B(\cdot)$ ——平衡项

μ ——平衡系数

由贪心算法^[18]求解式(1),可得到高光谱图像的第一主成分 $\mathbf{\Gamma}$ 被分割为

$$\Gamma = \bigcup_{i=0}^p T_i \quad (T_i \cap T_j = \emptyset, i \neq j) \quad (2)$$

式中 T_i, T_j —— Γ 中的第 i, j 个超像素
 p —— Γ 中的超像素数目

由此,可得到高光谱图像 X 的超像素分割。

1.2 自适应字典构建

高光谱图像在像素的局部空间上,满足较好的局部一致性,属于相同类标的概率大^[19-23];依据像素局部空间的类别关联性,可增加标记样本数量,缓解分类中的小样本问题。设高光谱图像中的标记样本 $X^L = \{x_1, x_2, \dots, x_m\}$, 标记为 $\{l_1, l_2, \dots, l_m\}$, $l_i \in \{1, 2, \dots, c\}$, $1 \leq i \leq m$, c 为类别数目。既在 x_i 的超像素区域中的像素,又在 x_i 的光谱近邻的像素,定义为

$$Z(x_i) = \{x | x \in \Omega(x_i) \cap x \in \Psi(x_i)\} \quad (3)$$

式中 $Z(\cdot)$ ——空间近邻和光谱近邻交集

$\Omega(\cdot)$ ——所在的超像素空间近邻

$\Psi(\cdot)$ —— X 中的前 q 个光谱近邻

虽然 X 的超像素区域多为类别一致性区域,但对 x_i 的不规则超像素区域 $\Omega(x_i)$, 由于受到背景点、噪声和超像素分割算法的影响,导致 $\Omega(x_i)$ 中的一些像素不具备和 x_i 相同的类标,即这些 x_i 的空间近邻对 x_i 类别的代表性相对较弱。因此,本文在扩展超像素局部空间像素点至标记样本集时,通过增加光谱近邻 $\Psi(x_i)$ 来过滤掉背景点、噪声点和分割算法的影响,将 $Z(x_i)$ 中的像素点添加至标记样本集,其标记为 x_i 的标记,形成新的标记样本集 \hat{X}^L , 满足

$$\hat{X}^L = Z(x_i) \cup X^L \quad (1 \leq i \leq m) \quad (4)$$

\hat{X}^L 扩展了原始标记样本集 X^L 的数量,在一定程度上可缓解小样本问题,但随着标记样本的增多,高光谱图像分类的时间随之增长,标记样本间的信息冗余又会影响分类效果;为了提升高光谱图像分类的效率和精度,对不同的测试样本,精简训练样本集,形成自适应训练样本集。对于测试样本 $x_j \in \mathbf{R}^d$, 其自适应样本集 A_j^* 满足

$$A_j^* = (\hat{X}^L \cap \Omega(x_j)) \cup \hat{\Psi}^L(x_j) \quad (5)$$

式中 $\hat{\Psi}^L(\cdot)$ —— \hat{X}^L 中前 q 个光谱近邻

对 X 中的每个测试样本点 x_j 分别在 \hat{X}^L 上筛选出 x_j 的超像素空间近邻 $\Omega(x_j)$ 和光谱近邻 $\hat{\Psi}^L(x_j)$, 形成自适应字典 $A_j = [a_{j1}, a_{j2}, \dots, a_{jk}, \dots, a_{jt}] \in \mathbf{R}^{d \times t}$, $a_{jk} \in A_j^*$, $1 \leq k \leq t$, a_{jk} 为自适应字典中的第 k 个原子。

1.3 空谱信息的协同竞争重构

近年来,稀疏分类采用过完备字典原子间的竞争关系来重构样本,在信号处理和模式识别领域得到了广泛应用,协同分类将稀疏分类求解最优化问

题中的 L_1 范数约束改进为 L_2 范数,在降低稀疏分类计算复杂度的同时又更好地反映了字典原子的协同作用^[24-27]。在高光谱图像分类中,对测试样本 x_j , 传统的协同分类在全体训练样本上构建字典 $\bar{X}^L = [x_1, x_2, \dots, x_m]$, 协同表示 x_j , 使得 $x_j = \bar{X}^L S_j + \varepsilon$, 其中 $S_j = [S_{j1}, S_{j2}, \dots, S_{jm}]^T$, 为了使容错率 ε 最小,协同分类表示为

$$S_j^* = \arg \min_{S_j} \|x_j - \bar{X}^L S_j\|_2^2 + \lambda \|S_j\|_2^2 \quad (6)$$

式中 S_j, S_j^* —— x_j 的协同系数及其最优值

λ ——正则化参数

传统的协同分类较好地表示了重构字典原子间的协同性,但忽略了字典原子间的竞争性,造成测试样本在重构时本征特性未能更好地表达,从而影响了分类的效果。为了在高光谱图像的空谱协同分类中增加测试样本重构原子间的竞争性,同时减少字典间的信息冗余,设 $\bar{A}_j = [\bar{a}_{j1}, \bar{a}_{j2}, \dots, \bar{a}_{jk}, \dots, \bar{a}_{jt}]$, 定义新的优化目标

$$\hat{S}_j^* = \arg \min_{S_j} \|x_j - A_j \hat{S}_j\|_2^2 + \lambda \|\hat{S}_j\|_2^2 + \lambda_1 \|x_j - \bar{A}_j \hat{S}_j\|_2^2 \quad (7)$$

其中 $\bar{a}_{jk} = \begin{cases} a_{jk} & (\bar{a}_{jk} \in (\hat{X}^L \cap \Omega(x_j)) \cap \hat{\Psi}^L(x_j)) \\ 0 & (\text{其他}) \end{cases}$

(8)

式中 \hat{S}_j, \hat{S}_j^* —— x_j 的协同竞争系数及其最优值

λ_1 ——竞争参数

\bar{A}_j ——从 A_j 竞争出的子字典

\bar{a}_{jk} —— \bar{A}_j 中的第 k 个字典原子

可见,式(7)由式(5)得到的自适应字典 A_j 替代传统协同分类中字典 \bar{X}^L , 式(7)求解为

$$\hat{S}_j^* = (\lambda I + A_j^T A_j + \lambda \bar{A}_j^T \bar{A}_j)^{-1} (A_j^T + \lambda_1 \bar{A}_j^T) x_j \quad (9)$$

式中 I —— t 阶单位矩阵

1.4 标记判别

在高光谱图像分类中,测试样本 x_j 的类标依据自适应字典 A_j 上的协同竞争系数 \hat{S}_j^* 进行判别。设 x_j 与 A_j 中的第 v ($1 \leq v \leq c$) 类样本重构残差为 $\gamma^v(x_j)$, 满足

$$\gamma^v(x_j) = \|x_j - A_j^v \hat{S}_j^{*v}\|_2 \quad (10)$$

式中 A_j^v —— A_j 中的第 v 类

\hat{S}_j^{*v} —— x_j 第 v 类的协同竞争系数

x_j 的类别标记 l_j 计算式为

$$l_j = \arg \min_{v=1,2,\dots,c} \gamma^v(x_j) \quad (11)$$

1.5 算法流程

本文算法步骤如图2所示:①对高光谱图像进行熵率超像素分割。②对带标记的小样本在高光谱图像中计算光谱近邻,并结合超像素分割结果通过

式(4)扩展标记样本,形成新的标记样本集。③计算测试样本在扩展标记样本上的光谱近邻,同时结合扩展样本和超像素分割结果根据式(5)生成测试样本的自适应样本集并构建自适应字典。④采用式(9)计算测试样本在自适应字典上的协同竞争表示。⑤依据协同竞争表示系数和自适应字典的类别标记,通过式(10)计算测试样本的类别残差。⑥通过式(11)计算最小类别残差得到高光谱图像的分类结果。

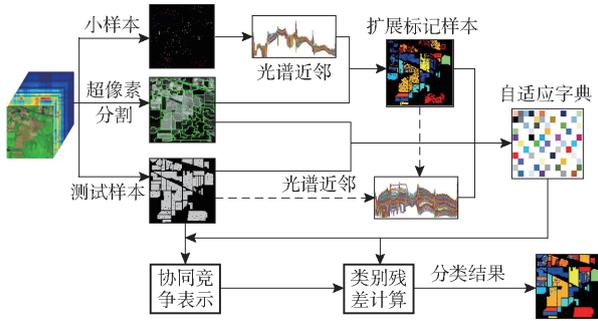


图 2 自适应字典的小样本 HSI 分类流程图

Fig. 2 Flowchart of HSI classification with small sample set based on adaptive dictionary

2 实验数据集

本文采用印地安农林和帕维亚大学 2 个高光谱数据集进行实验,图 3 和图 4 分别为这 2 个数据集的假彩色图像和实际地物图。

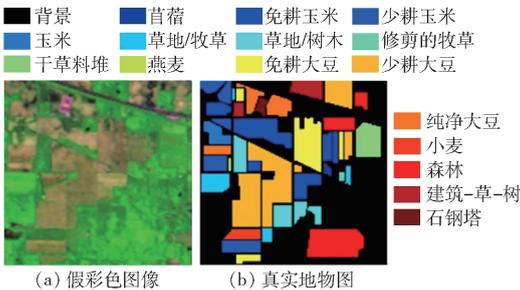


图 3 印地安农林高光谱图像

Fig. 3 False-color image and ground-truth map on Indian Pines HSI

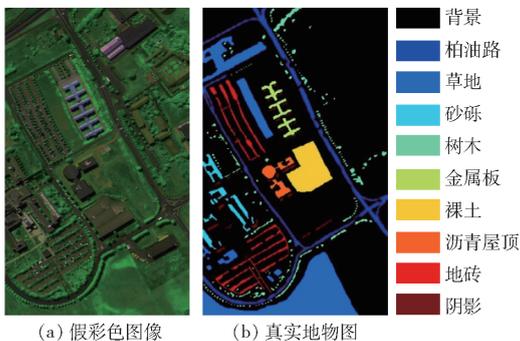


图 4 帕维亚大学高光谱图像

Fig. 4 False-color image and ground-truth map on Pavia University HSI

印地安农林是由机载可见光/红外成像光谱仪 (AVIRIS 型) 采集的一片农田区域高光谱影像,采集时间为 1992 年 6 月,空间分辨率 20 m,影像尺寸为 145 像素 × 145 像素,波长范围为 400 ~ 2 450 nm,光谱分辨率为 10 nm,波段数为 220,去除受噪声或水气吸收影响的第 104 ~ 108 波段和第 150 ~ 163 波段以及第 220 波段,余下的 200 波段用于实验,共包含 16 类不同的农业对象。该影像种类分布不均匀并且存在样本稀少类别,混合了种植作物、林地、草地等,同时影像中种植作物尚处于生长阶段,裸露的土壤与种植作物残渣增加了分类的难度。

帕维亚大学高光谱图像是由机载成像光谱仪 (ROSIS 型) 采集的大学周围影像,采集时间为 2002 年 7 月,空间分辨率为 1.3 m,影像尺寸为 610 像素 × 340 像素,波长范围为 430 ~ 860 nm,共 115 个波段,去除 12 个受噪声影响严重的波段,余下 103 个波段用于实验,共包含 9 种地物类别。

3 实验结果及分析

3.1 实验设计及评价指标

在印地安农林和帕维亚大学高光谱图像中,为了获取足够的样本信息进行分类,传统训练样本数量取值通常为印地安农林图像中每类 10% 采样,不足 10 个训练样本的类别选取 10 个训练样本,余下样本作测试,帕维亚大学图像每类 5% 采样,剩余为测试样本。为了减少采样训练样本的数量,在印地安农林图像上按照每类 2% 随机选取标签训练样本,不足 10 个训练样本的类别选取 10 个训练样本,剩余约 98% 数据作为测试集;在帕维亚大学图像上按照每类 1% 随机采样,余下 99% 的数据为测试样本。在 Intel i7-8550U CPU,主频为 1.8 GHz,内存为 8 GB 的硬件环境,Matlab2015b 软件平台下进行 10 次实验,取 10 次实验结果的平均值作为实验结果。

为了验证本文所提方法的有效性,将本文方法与 K 近邻 (K-nearest neighbor, KNN)、SVM、SVMCK^[11]、SRC^[12]、CRC^[13]、JSRC^[14]、JCRC^[15]、CCJSR^[16] 方法进行对比,选取生产者精度 (Producer's accuracy, PA)、生产者精度均值 (Average accuracy, AA)、总体分类精度 (Overall accuracy, OA) 和 Kappa 系数 (K_c) 作为评价准则。

3.2 参数对分类精度的影响

在本文所提出的算法中,有 4 个参数需要分析,自适应协同竞争表示中的正则化参数 λ 、竞争参数 λ_1 、超像素分割区域数 p 以及光谱近邻数 q 。图 5a 为印地安农林图像在分割区域数 p 为 80,光谱近邻

数为 290, λ_1 、 λ 分别在 $\{10^{-3}, 10^{-2}, 10^{-1}, 1, 10, 10^2, 10^3\}$ 上进行取值所对应 OA 的影响结果, 图 5b 为帕维亚大学图像在分割区域数 p 为 30, 光谱近邻数为 5, λ 和 λ_1 所对应的 OA 结果。由图 5 可见, 2 幅高光图像均在图的最右边 ($\lambda = 10^3, \lambda_1 = 10^{-3}$), 即在取值区间 λ 取最大值, λ_1 取最小值时, OA 值最小; 然后, 随着 λ 的降低和 λ_1 的增大, OA 值在 2 幅图中均快速提升, 随即达到较宽泛平稳的 OA 最高值。 λ_1 较小时, 分类结果不能体现自适应样本间的竞争性, 不足以表达样本本征, 导致 OA 在不同的 λ 取值上波动较大, λ_1 的引入, 协同样本的竞争信息增加, 能有效改善分类结果受传统协同表示参数 λ 的大幅度波动, 减少分类结果对参数的敏感性。

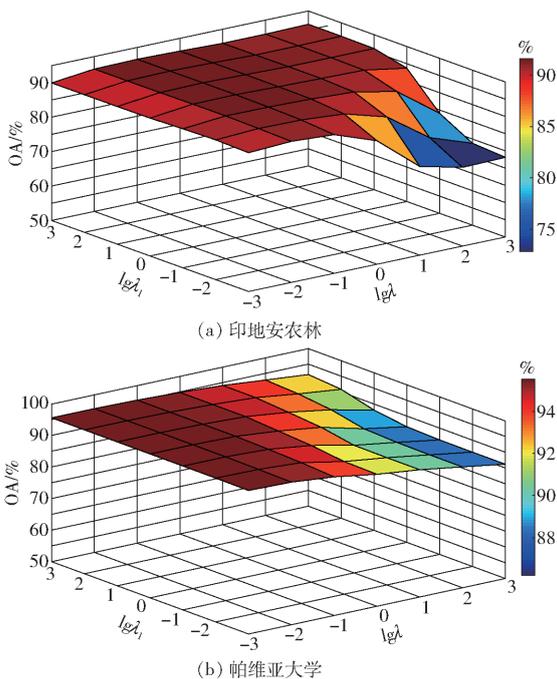


图 5 不同 λ 和 λ_1 参数取值对 OA 的影响

Fig. 5 Parameter tuning of λ and λ_1 on OA

为了探究超像素分割区域数 p 对高光光谱遥感图像分类的影响, 在印地安农林和帕维亚大学 2 幅图像中分别对分割区域数 $[10, 200]$ 间隔为 10 进行实验参数取值, 其中 λ_1 为 0.1, λ 为 0.01, 光谱近邻数 q 分别为 290 和 5, 图 6 为区域数 p 对 OA 的影响。从图中可见, 印地安农林图像和帕维亚大学图像分别在 $[10, 80]$ 和 $[10, 30]$ 超像素分割数目区间随着分割区域数 p 的增加, 可运用的空间信息逐步丰富, OA 迅速提升; 然后印地安农林图像和帕维亚大学图像在 OA 达到各自的最大值后随着分割区域数 p 的继续增加, 过多的空间信息对分类精度形成干扰, OA 缓慢下降。

图 7 为 2 幅高光光谱图像中不同光谱近邻数 q 对 OA 的影响, 其中 2 幅图像的 λ_1 为 0.1, λ 为

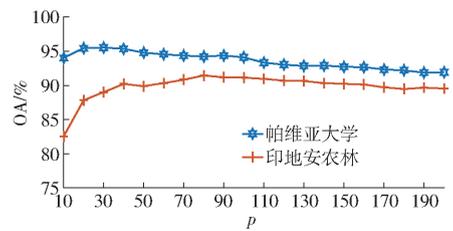
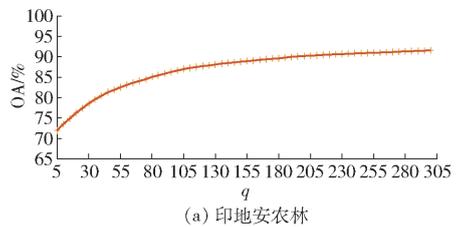
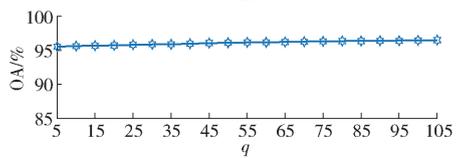


图 6 不同分割区域数 p 对 OA 的影响

Fig. 6 Parameter tuning of segmentation number p on OA



(a) 印地安农林



(b) 帕维亚大学

图 7 不同光谱近邻数 q 对 OA 的影响

Fig. 7 Parameter tuning of spectral number q on OA

0.01, 印地安农林和帕维亚大学 2 幅图像的分割区域数 p 分别为 80 和 30。从图 7a 可知, 印地安农林图像在 q 取值 $[5, 130]$ 区间, 可运用的光谱信息逐步增多, OA 增加相对较快; 在 q 达到 130 之后, 随着光谱近邻数的进一步增加, OA 持续缓慢增加。从图 7b 可知, 帕维亚大学图像对光谱近邻参数 q 不敏感, 变化相对平稳。 q 在 $[5, 105]$ 区间, 随着光谱近邻数的增加, 更多光谱信息的引入, OA 增加非常缓慢, 几近不变; 但尺寸为 610 像素 \times 340 像素的帕维亚大学图像, 像素数目超过 20 万, 随着更多光谱近邻像素点的引入, 在空谱协同时的运行时间势必加长; 在 q 为 5 时的运行时间为 391 s, 在 q 为 40 时运行时间为 2 283 s, 在 q 超过 75 后, 运行时间超过 3 600 s。面对对 q 不敏感的 OA 增长, 在 OA 和运行时间之间进行平衡, 本文对帕维亚大学图像取相对较小的 q 值 5。对比图 7a 和图 7b 可见, 帕维亚大学图像超像素中的样本较为丰富, 反映出其地物分布更密集, 因此具有更高的空间特征利用率。

3.3 对比实验结果及分析

表 1 和表 2 为不同方法分别在印地安农林和帕维亚大学高光光谱图像的 PA、AA、OA、 K_c 和运行时间的结果对比。由表 1 和表 2 可知, 本文方法在 2 个数据集上的总体分类精度分别为 91.45% 和 95.54%, 相较于其他方法, 本文方法在 2 幅高光光谱图像中均有最高的 AA、OA 和 K_c , 在印地安农林图

像上 OA 高出其他方法 3.48 ~ 39.52 个百分点, 在帕维亚大学数据集上 OA 高出其他方法 2.45 ~ 21.63 个百分点; 同时, 在大部分地物中具有较高的分类精度。尤其对印地安农林图像的“草地/牧草”和“建筑-草-树”2 类, 其训练样本数偏少, 仅为 10

个样本, 本文方法相比于其他方法中的最高地物分类精度分别提高了 9.33、9.50 个百分点; 对帕维亚大学图像的砂砾、裸土和地砖 3 类图像, 本文方法相比于其他方法中的最高地物分类精度分别提高了 17.70、7.60、7.79 个百分点。

表 1 不同方法在印地安农林高光谱图像的分类效果对比

Tab. 1 Classification results with different methods on Indian Pines HSI

类别	训练样本数/个	测试样本数/个	PA/%								
			KNN	SVM	SVMCK	SRC	CRC	JSRC	CCJSR	JCRC	本文方法
苜蓿	10	36	80.56	83.61	92.78	78.06	64.44	98.89	98.61	97.78	98.33
免耕玉米	29	1 399	43.06	60.01	69.22	43.64	45.46	82.87	83.50	88.00	87.97
少耕玉米	17	813	39.09	45.56	55.66	28.25	23.97	75.61	82.42	78.59	82.58
玉米	10	227	37.40	47.22	60.70	21.19	17.05	90.35	90.35	87.97	89.25
草地/牧草	10	473	66.53	70.21	71.54	60.57	65.35	75.39	75.94	81.14	90.47
草地/树木	15	715	76.29	86.18	92.11	84.70	75.83	82.81	91.12	93.58	99.16
修剪的牧草	10	18	90.56	90.56	94.44	88.89	75.56	100	100	100	97.22
干草料堆	10	468	69.68	82.35	90.77	68.40	45.62	95.43	96.41	96.47	100
燕麦	10	10	78.00	92.00	99.00	80.00	60.00	80.00	87.00	98.00	100
免耕大豆	19	953	44.42	53.95	66.25	30.14	30.89	78.52	81.64	75.93	89.18
少耕大豆	49	2 406	62.64	68.97	77.49	71.94	56.57	88.17	87.83	94.95	92.56
纯净大豆	12	581	25.34	33.55	42.25	20.84	24.27	69.16	73.20	63.56	79.43
小麦	10	195	90.77	94.10	97.59	93.64	86.10	87.44	98.36	97.90	99.49
森林	25	1 240	81.29	87.76	93.15	90.97	87.53	94.98	96.48	96.48	97.64
建筑-草-树	10	376	24.12	30.77	55.35	21.25	25.77	81.62	79.47	82.10	91.60
石钢塔	10	83	87.11	87.95	97.59	87.47	78.67	83.49	95.30	97.11	95.06
AA/%			62.30	69.67	78.49	60.62	53.94	85.30	88.60	89.35	93.12
OA/%			56.74	65.40	74.22	57.59	51.93	84.38	86.56	87.97	91.45
K_c			0.506	0.604	0.705	0.507	0.447	0.822	0.847	0.862	0.902
运行时间/s			0.178	0.282	1.183	9.328	0.425	27.82	131.68	22.27	123.61

表 2 不同方法在帕维亚大学高光谱图像的分类效果对比

Tab. 2 Classification results with different methods on Pavia University HSI

类别	训练样本数/个	测试样本数/个	PA/%								
			KNN	SVM	SVMCK	SRC	CRC	JSRC	CCJSR	JCRC	本文方法
柏油路	66	6 565	80.91	87.26	91.19	80.18	72.21	59.13	39.73	97.73	86.77
草地	186	18 463	91.11	95.87	98.36	97.84	96.38	98.34	98.40	99.90	99.74
砂砾	21	2 078	50.25	68.84	74.25	61.42	34.00	71.64	68.65	74.15	91.95
树木	31	3 033	71.94	87.72	90.87	82.55	80.79	77.46	84.76	80.44	82.31
金属板	13	1 332	99.02	99.12	99.59	99.71	99.79	99.42	99.54	99.79	99.83
裸土	50	4 979	50.06	76.84	91.27	39.73	34.44	76.03	71.31	87.83	98.87
沥青屋顶	13	1 317	73.36	75.54	81.21	25.79	1.59	92.22	44.42	70.77	95.22
地砖	37	3 645	76.16	80.50	85.17	47.98	60.89	90.93	85.80	85.31	98.72
阴影	10	937	99.78	99.79	99.71	83.13	34.72	22.34	84.67	79.46	89.26
AA/%			76.95	85.72	90.18	68.70	57.20	76.39	75.25	86.15	93.63
OA/%			79.93	88.62	93.09	78.59	73.91	84.36	80.65	92.87	95.54
K_c			0.730	0.848	0.908	0.705	0.641	0.790	0.740	0.904	0.941
运行时间/s			3.648	4.643	17.58	276.03	4.048	465.15	1 358.92	443.89	391.64

图 8 和图 9 分别为实验中印地安农林和帕维亚大学高光谱图像一次随机抽样的训练样本图、测试样本的真实地物类别图以及采用不同方法进行分类后的地物分类效果。从图 8 和图 9

可见, 在 2 幅高光谱图像上, 和仅用光谱信息的 KNN、SVM、SRC、CRC 相比, 加入空间信息的 SVMCK、JSRC、CCJSR、JCRC 和本文方法分类效果明显更为光滑, 错分点相对较少。由图 8 可

知,在印地安农林图像上,虽然本文分类效果图仍存在点状噪声,但块状噪声相对较少。为了进行对比,在4个方法(JSRC、CCJSR、JCRC和本文方法)的效果图上绘制了3个白色矩形框,这3个矩形框中的地物样本较少,地物周围种类较为复杂,在测试样本受局部空间多类别样本干扰

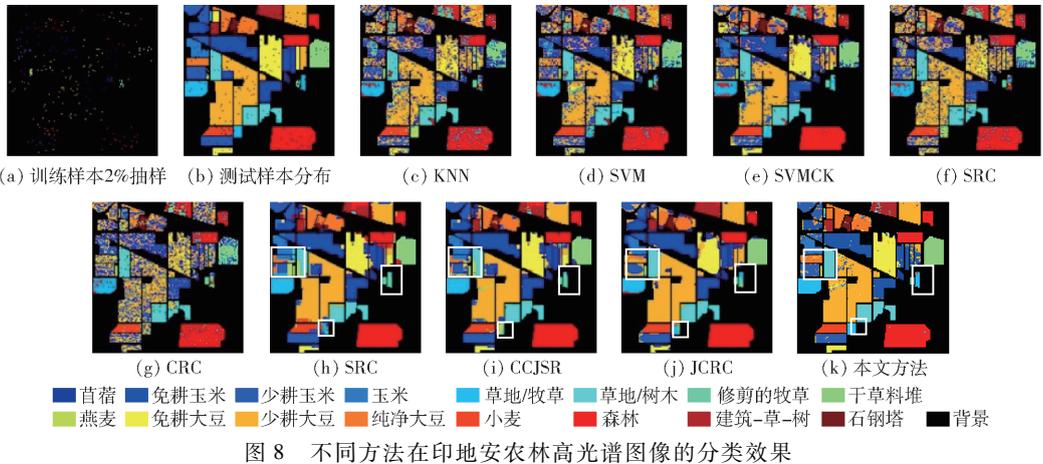


图8 不同方法在印地安农林高光谱图像的分类效果

Fig. 8 Classification maps with different methods on Indian Pines HSI

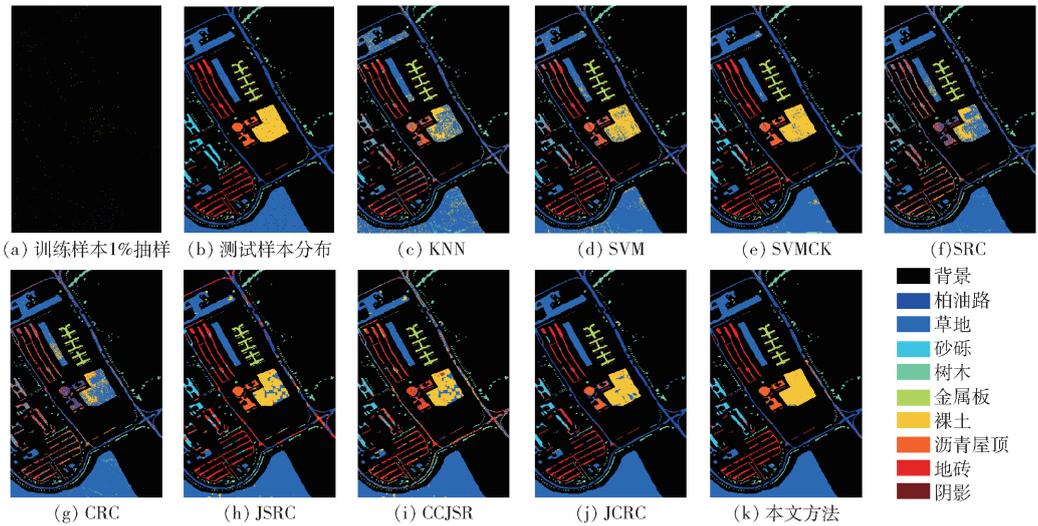


图9 不同方法在帕维亚大学高光谱图像的分类效果

Fig. 9 Classification maps with different methods on Pavia University HSI

4 结论

(1) 针对小样本下提高高光谱图像分类性能问题,提出了高光谱图像分类的自适应字典分类方法。通过协同扩展小样本构建的自适应字典原子,可以缓解小样本问题,在小样本下印地安农林图像数据集总体分类精度为91.45%,比其他方法提高3.48~39.52个百分点,在帕维亚大学数据集上总体分类精度达到95.54%,比其他方法提高2.45~21.63个百分点。

时,本文方法尤其显示出了更好的分类效果,错分率明显低于其他3种方法。由图9可见,在帕维亚大学高光谱图像上,JSRC、CCJSR、JCRC由于固定的块状空间滤波,均呈现出大量大块的噪声点,而本文超像素分割更贴近地物细节,地物分类结果图中噪声点相对较少。

(2) 与固定窗口尺寸的空间信息表达相比,在高光谱图像分类中运用超像素表示局部空间信息,能在分类结果中更好地保持图像的局部细节,降低分类中的块状噪声。

(3) 在高光谱图像分类中,过多的超像素分割数对分类形成干扰,导致分类精度下降,光谱近邻数的增加影响分类时间,空谱自适应字典原子间竞争性的表达可以弥补协同表示在高光谱图像分类中的不足。

参 考 文 献

- [1] BIUCAS-DIAS J M, PLAZA A, CAMPS-VALLS G, et al. Hyperspectral remote sensing data analysis and future challenges [J]. IEEE Geoscience and Remote Sensing Magazine, 2013, 1(2): 6-36.

- [2] 童庆禧,张兵,张立福.中国高光谱遥感的前沿进展[J].遥感学报,2016,20(5):689-707.
TONG Qingxi, ZHANG Bing, ZHANG Lifu. Current progress of hyperspectral remote sensing in China[J]. Journal of Remote Sensing, 2016, 20(5): 689-707. (in Chinese)
- [3] ZHANG X, SUN Y L, SHANG K, et al. Crop classification based on feature band set construction and object-oriented approach using hyperspectral images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2016, 9(9):4117-4128.
- [4] PETROPOULOS G P, KALAITZIDIS C, VADREU K P. Support vector machines and object-based classification for obtaining land-use/cover cartography from Hyperion hyperspectral imagery[J]. Computers & Geosciences, 2012, 41(4): 99-107.
- [5] LIAO W, BELLENS R, PIZURICA A, et al. Classification of hyperspectral data over urban areas using directional morphological profiles and semi-supervised feature extraction[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(4): 1177-1190.
- [6] GHAMISI P, MAGGIORI E, LI S, et al. New frontiers in spectral-spatial hyperspectral image classification: the latest advances based on mathematical morphology, markov random fields, segmentation, sparse representation, and deep learning[J]. IEEE Geoscience and Remote Sensing Magazine, 2018, 6(3): 10-43.
- [7] GHAMISI P, MURA M D, BENEDIKTSSON J A. A survey on spectral-spatial classification techniques based on attribute profiles[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(5): 2335-2353.
- [8] GHAMISI P, SOUZA R, BENEDIKTSSON J A, et al. Extinction profiles for the classification of remote sensing data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(10): 5631-5645.
- [9] 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.
- [10] MARYAM I, HASSAN G. An overview on spectral and spatial information fusion for hyperspectral image classification: current trends and challenges[J]. Information Fusion, 2020, 59(7): 59-83.
- [11] CAMPS-VALLS G, GOMEZ-CHOVA L, MUNOZ-MARI J, et al. Composite kernels for hyperspectral image classification [J]. IEEE Geoscience and Remote Sensing Letters, 2006, 3(1): 93-97.
- [12] WRIGHT J, MA Y, MAIRAL J, et al. Sparse representation for computer vision and pattern recognition[J]. Proceedings of the IEEE, 2010, 98(6): 1031-1044.
- [13] ZHANG Lei, MENG Yang, FENG Xiangchu. Sparse representation or collaborative representation: which helps face recognition? [C]//IEEE International Conference on Computer Vision, 2011: 6-11.
- [14] 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.
- [15] LI W, DU Q. Joint within-class collaborative representation for hyperspectral image classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2200-2208.
- [16] TU B, ZHANG X, KANG X, et al. Hyperspectral image classification via fusing correlation coefficient and joint sparse representation[J]. IEEE Geoscience & Remote Sensing Letters, 2018, 15(3): 340-344.
- [17] 班志华. 超像素分割及快速实现方法研究[D]. 武汉: 华中科技大学, 2018.
BAN Zhihua. Research on superpixel segmentation and fast implementation methods[D]. Wuhan: Huazhong University of Science & Technology, 2018. (in Chinese)
- [18] LIU M Y, TUZEL O, RAMALINAM S, et al. Entropy rate superpixel segmentation[C]//Proceedings of the CVPR, 2011: 20-25.
- [19] PENG Jiangtao, JIANG Xue, CHEN Na, et al. Local adaptive joint sparse representation for hyperspectral image classification [J]. Neurocomputing, 2019, 334(1): 239-248.
- [20] HUANG H, DUAN Y, HE H, et al. Local linear spatial-spectral probabilistic distribution for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(2): 1259-1272.
- [21] 黄鸿,陈美利,段宇乐,等.空-谱协同流形重构的高光谱影像分类[J].光学精密工程,2018,26(7):1827-1836.
HUANG Hong, CHEN Meili, DUAN Yule, et al. Hyperspectral image classification using spatial-spectral manifold reconstruction[J]. Optics and Precision Engineering, 2018, 26(7): 1827-1836. (in Chinese)
- [22] 廖建尚,王立国.面向空间自相关信息的高光谱图像分类方法[J/OL].农业机械学报,2018,49(6):215-224.
LIAO Jianshang, WANG Ligu. Classification method of hyperspectral image based on spatial autocorrelation information [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(6): 215-224. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180625&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.06.025. (in Chinese)
- [23] HUANG Hong, DUAN Yule, HE Haibo, et al. Spatial-spectral local discriminant projection for dimensionality reduction of hyperspectral image[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 156(10): 77-93.
- [24] LIU N, LI W, DU Q. Unsupervised feature extraction for hyperspectral imagery using collaboration-competition graph[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 6(12): 1491-1503.
- [25] 袁培森,李润隆,任守纲,等.表示学习技术研究进展及其在植物表型中应用分析[J/OL].农业机械学报,2020,51(6):1-14.
YUAN Peisen, LI Runlong, REN Shougang, et al. State-of-the-art review for representation learning and its application in plant phenotypes[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6): 1-14. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20200601&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2020.06.001. (in Chinese)
- [26] YUAN Haoliang, LI Xuecong, XU Fangyuan, et al. A collaborative-competitive representation based classifier model[J]. Neurocomputing, 2018, 275(1): 627-635.
- [27] TU Bing, LI Nanyang, FANG Leyuan, et al. Hyperspectral image classification with a class-dependent spatial-spectral mixed metric[J]. Pattern Recognition Letters, 2019, 123(5): 16-22.