

文章编号 1004-924X(2018)04-0980-09

多核融合多尺度特征的高光谱影像地物分类

王庆超, 付光远*, 汪洪桥, 王 超

(火箭军工程大学 信息工程系, 陕西 西安 710025)

摘要:对于高光谱影像地物分类问题,为更加有效地利用像元空间信息和光谱信息,提高地物分类精度,提出了多核融合多尺度特征的分类方法。首先,通过多尺度空间滤波和 PCA 白化,提取出多尺度特征;接着在核稀疏表示分类器内使用多核方式对分别表示每项特征,在分类器内实现特征自动融合,根据子核与理想核、子核之间距离求取核组合的权重,使用训练集所构成的字典在特征空间内对待测样本进行线性表示,根据每类地物的重构误差确定待测像元所属地物类别。实验结果表明:对于 Indian Pines 影像和 Pavia University 影像总体分类精度分别达到 99.51% 和 97.96%,较传统方法明显提高,并且对于小样本地物识别精度也都能达到 90% 以上。本文算法对于高光谱影像地物具有更强的识别能力,并且具有较强的稳定性和鲁棒性。

关键词:高光谱影像;稀疏表示;多尺度;多核学习;地物分类

中图分类号:P227 文献标识码:A doi:10.3788/OPE.20182604.0980

Fusion of multi-scale feature using multiple kernel learning for hyperspectral image land cover classification

WANG Qing-chao, FU Guang-yuan*, WANG Hong-qiao, WANG Chao

(Department of Information Engineering, Rocket Force Engineering University, Xi'an 710025, China)

* Corresponding author, E-mail: dr_f@21ce.com

Abstract: In order to make full use of the spatial information and spectral information and improve the classification accuracy of hyperspectral imager, a fusion multi-scale feature with multiple kernel learning method was proposed in this paper. Firstly, multi-scale features were extracted by multi-scale spatial filtering and PCA whitening. Then multiple kernels were used to represent the multi-scale feature in the framework of kernel sparse representation classifier. The kernel weight was computed according to the CKTA between the sub-kernels and ideal kernel and the CKTA between sub-kernels. The unlabeled pixels were linearly represented by the training samples in the feature space. According to the reconstruction error of each kind of land cover, the category of unlabeled pixels was determined. The experiment results showed that the overall classification accuracy in Indian Pines images and Pavia University images reached 99.51% and 97.96%, which significantly surpassed the traditional method. The accuracy of object recognition of small sample could also reach more than 90%. It can be seen that

收稿日期:2017-06-15;修订日期:2017-08-15.

基金项目:国家自然科学基金青年基金资助项目(No. 61202332,61403397);陕西省自然科学基金基础研究计划资助项目(No. 2015JM6313)

algorithm proposed has stronger recognition ability for hyperspectral images land cover.

Key words: hyperspectral image; SRC; multi-scale; multiple kernel learning; land cover classification

1 引言

高光谱影像使用几十乃至几百个光谱通道进行遥感成像,能够使不同材质或相同材质不同结构的地物呈现出差异,可以获得对地面信息精细描述,使得高光谱影像较其他遥感影像具有更强的识别的能力。然而维数众多的光谱信息并不会直接导致高的解译精度。一方面由于谱通道的高度相关性和像元的高维性,给数据分析带来困难,另一方面高光谱遥感成像过程中容易受各种因素干扰,从而给准确分类带来困难^[1]。

文献[2]最早将空间信息引入到高光谱影像分类,取得了优于单纯依靠光谱信息的分类精度,此后空谱联合分类方法成为高光谱影像分类的一个研究热点。由于空谱分类方法能够充分挖掘和利用数据的先验信息,对高光谱影像的识别具有明显的提升作用,因此空谱联合分类获得了广泛关注^[3-4]。文献[5]使用联合稀疏表示(Joint Sparse Representation, JSR)模型,通过邻域内像元同时用字典线性表示的方式融合像元的空间信息,提高了分类结果图的平滑性。文献[6]通过特征加权的方式融合光谱特征和空间特征,并且提出使用多核学习(Multiple Kernel Learning, MKL)方法在核空间内融合空谱信息值得深入研究。文献[7]使用了复合核的方式分别构建一个空间核和一个光谱核,使用核稀疏表示分类(Kernel Sparse Representation Classification, KSRC)作为基础分类器,实现了空谱信息在分类器内的

融合,但是核组合的权重如何确定并没有说明。

近年来多尺度分析理论不断完善,通过对多个尺度空间上对高光谱影像进行分析,可以更好地利用像元的空间信息,从而获得更好的分类效果^[8-9]。文献[10]在对高光谱像元进行稀疏表示时使用了多尺度分割的方式,较单一尺度有更好的效果。但在分类结果进行融合时空间信息利用还不够充分。

为了充分利用像元的空间信息和光谱信息,提出了多核融合多尺度特征的高光谱影像稀疏表示分类方法。通过在不同尺度空间上融合邻域内像元的光谱信息,提取出多尺度特征,使用多核方法在核稀疏表示框架内进行特征融合,根据子核与理想核以及子核之间的关系求解核权重,空间信息和光谱信息得到更加有效地利用。实验结果表明使用本文算法可以获得更高的分类精度,并且小样本地物也能准确分类,算法具有更好的稳定性和鲁棒性。

2 高光谱影像分类算法

由于在高光谱成像过程中容易受各种因素影响,可能存在同谱异质和同质异谱的现象,因此单纯依靠光谱信息分类效果不佳,空谱结合的分类方式目前已经广泛应用。本文使用多尺度的空谱特征提取的方式,在不同尺度空间内融合像元邻域内其它像元的光谱特征,使用多核方法融合多尺度特征,使用多核稀疏表示分类器得到地物的分类图。分类过程如图1所示。

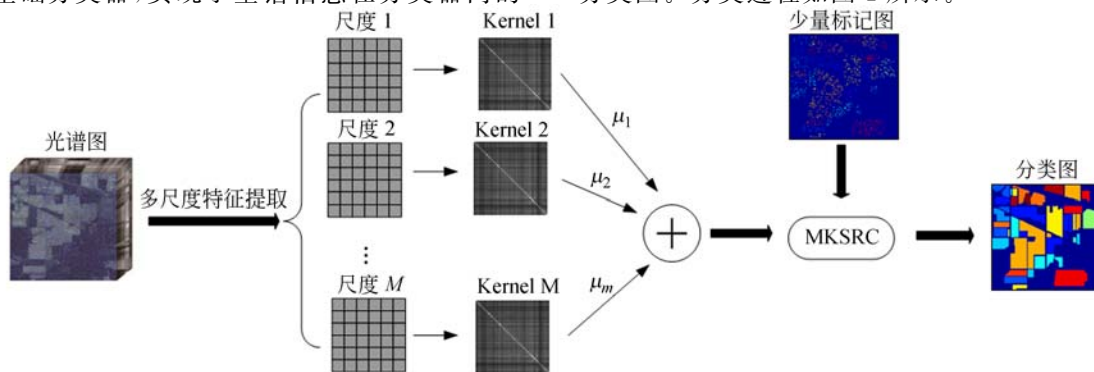


图1 高光谱影像分类过程

Fig. 1 Classification flow chart of hyperspectral image

理想核 \mathbf{Y} 之间的 CKTA 值最大化。CKTA 的计算方式如式(11)所示:

$$\text{CKTA}(\mathbf{K}, \mathbf{Y}) = \frac{\langle \mathbf{K}, \mathbf{Y} \rangle_F}{\sqrt{\langle \mathbf{K}, \mathbf{K} \rangle_F} \sqrt{\langle \mathbf{Y}, \mathbf{Y} \rangle_F}}, \quad (11)$$

其中:

$$\langle \mathbf{K}_p, \mathbf{K}_q \rangle_F = \sum_{i,j} \mathbf{K}_p(\mathbf{x}_i^p, \mathbf{x}_j^p) \cdot \mathbf{K}_q(\mathbf{x}_i^q, \mathbf{x}_j^q).$$

记训练样本 \mathbf{x}_i 的类别为 l_i , 则在该训练集上的理想核 \mathbf{Y} 可以通过式(12)进行计算。

$$\mathbf{Y}_{ij} = \begin{cases} +1, & l_i = l_j \\ -1, & l_i \neq l_j \end{cases}, \quad (12)$$

以向量 \mathbf{a} 表示子核与理想核之间的距离, 以矩阵 \mathbf{S} 表示子核之间的关系, 如式(13)和式(14)所示。

$$\mathbf{a} = (\langle \mathbf{K}_1, \mathbf{Y}\mathbf{Y}^T \rangle_F, \dots, \langle \mathbf{K}_M, \mathbf{Y}\mathbf{Y}^T \rangle_F), \quad (13)$$

$$\mathbf{S}_{ij} = \langle \mathbf{K}_i, \mathbf{K}_j \rangle_F, \quad (14)$$

通过解一个二次规划问题如式(15), 解得向量 \mathbf{v} 。将向量 \mathbf{v} 按照式(16)的方式标准化, 即为各个子核对应的权重:

$$\mathbf{v}^* = \arg \min_{\mathbf{v} \geq 0} \mathbf{v}^T \mathbf{S} \mathbf{v} - 2 \mathbf{v}^T \mathbf{a}, \quad (15)$$

$$\boldsymbol{\mu} = \mathbf{v}^* / \|\mathbf{v}^*\|. \quad (16)$$

2.4 算法流程

使用本文算法对高光谱影像进行地物分类过程可总结为如下步骤:

(1) 对高光谱影像按照 2.1 方法进行多尺度特征提取, 并将样本分为训练集与测试集;

(2) 在每个特征上对训练集计算核矩阵 $\mathbf{K}_1, \mathbf{K}_2, \dots, \mathbf{K}_M$;

(3) 按照式(13)和式(14)计算子核与理想核间距离 \mathbf{a} 和子核间关系 \mathbf{S} ;

(4) 求解式(15)所示二次规划问题, 并归一化得到核权重系数 $\boldsymbol{\mu}$;

(5) 按照公式(3)所示计算合成核矩阵 \mathbf{K} ;

(6) 对每一测试集像元 \mathbf{y} 解 l_1 范数最小化问题(8), 得稀疏向量 $\hat{\boldsymbol{\alpha}}$;

(7) 使用式(9)计算 \mathbf{y} 对每一类的重构误差, 并按照式(10)选择误差最小的一类作为 \mathbf{y} 的预测值。


3 实验与分析

3.1 实验数据与实验设置

为验证本文算法性能, 使用两幅经典的高光

谱影像 Indian Pines 和 Pavia University 进行实验。Indian Pines 数据集由 AVIRIS 成像光谱仪在 Indiana 西北部地区采集的植被影像, 共有 224 个波段, 波段范围为 $0.4 \sim 2.5 \mu\text{m}$, 大小为 145×145 pixel, 空间分辨率为 20 m, 共 16 种地物。除去原始数据中水吸严重和噪声较大的 24 个波段, 将剩余的 200 个波段用作分类实验。Indian Pines 的假彩色图和地面真实数据如图 3 所示。

Pavia University 数据集是由 ROSIS 传感器获取的高光谱影像, 反映的是 Pavia 大学区域状况, 共有 115 个波段 ($0.43 \sim 0.86 \mu\text{m}$), 空间分辨率为 1.3 m, 大小为 610×340 pixel。去除原始数据中水吸严重的 12 个波段, 选择剩余的 103 个波段进行实验。Pavia University 数据集的假彩色图和真实地物图如图 4 所示。




(a) 假彩色图 (b) 地面真实数据
(a) HSI in false color (b) Ground truth

图3 Indian Pines 影像

Fig. 3 Indian Pines image

实验过程中, 从每类地物中随机抽取固定比例的像元作为训练集, 其余作为测试集, 为克服随机抽样对分类精度产生的影响, 每种实验条件下重复 10 次实验, 以平均值作为实验结果。使用总体分类精度 (Overall Accuracy, OA)、平均分类精度 (Average Accuracy, AA) 和 Kappa 系数 3 个指标作为评价标准。

实验中选择 SVM、PCA + SVM、MKSVM^[13]、SRC、JSRC^[7]、MKSRC^[5] 作为对比。在使用本文算法进行分类时, 分别使用 $1 \times 1, 3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9, 11 \times 11$ 以及 13×13 共 7 个尺度进行特征提取, 每个特征使用一个高斯核进行表示。实验在 Intel i7 2.6 GHz CPU, 4 GB RAM 的 PC 机上进行。操作系统为 Windows 7, 使用 Matlab R2012a 作为计算平台。



(a) 假彩色图 (b) 地面真实数据
 (a) HSI in false color (b) Ground truth

图 4 Pavia University 影像

Fig. 4 The Pavia University image

实验中 SVM 分类器使用高斯核,使用一多的方式解决多分类问题,选择置信概率最大的一类作为分类结果。使用 PCA 降维时将光谱维度降至 50 维,再用 SVM 进行分类。MKSVM 使用高斯核+多项式核。MKSRC 选择空间核+光

谱核进行实验,使用文献[7]的 KSSP 算法优化。

为了了解空间信息对于分类效果的影响,在实验中还只使用像元的 (x, y) 坐标,不使用任何光谱信息,使用 SVM 分类器进行了实验(Spatial)。实验中的分类器参数通过交叉验证选择最优参数进行对比实验。

3.2 Indian Pines 实验结果及讨论

随机选取 10% 像元作为训练集,其余 90% 像元为测试集,地物分类结果如图 5 所示。从图 5 可以看出使用 SVM(a)和 SRC 分类器(b),大部分像元可以正确分类,但是每类地物中都有很多孤立的点被错分。使用 PCA 降维(c)和多核方法(图 d)效果略有提高,但分类图中依然存在很多错分的孤立点。说明单纯的谱分类方法并不能很好的解决高光谱影像分类问题。而图(e)~(h)在分类过程中均考虑了空间信息,得到分类图较为平滑,分类精度也得到提高。然而 4 种方法都出现了个别像元受周边异类地物影响,导致被错分的现象,这也是空谱联合分类所普遍存在的缺陷。为了更好地对实验结果进行分析,将每类地物的分类精度和总体分类精度等指标在表 1 中详细列出。

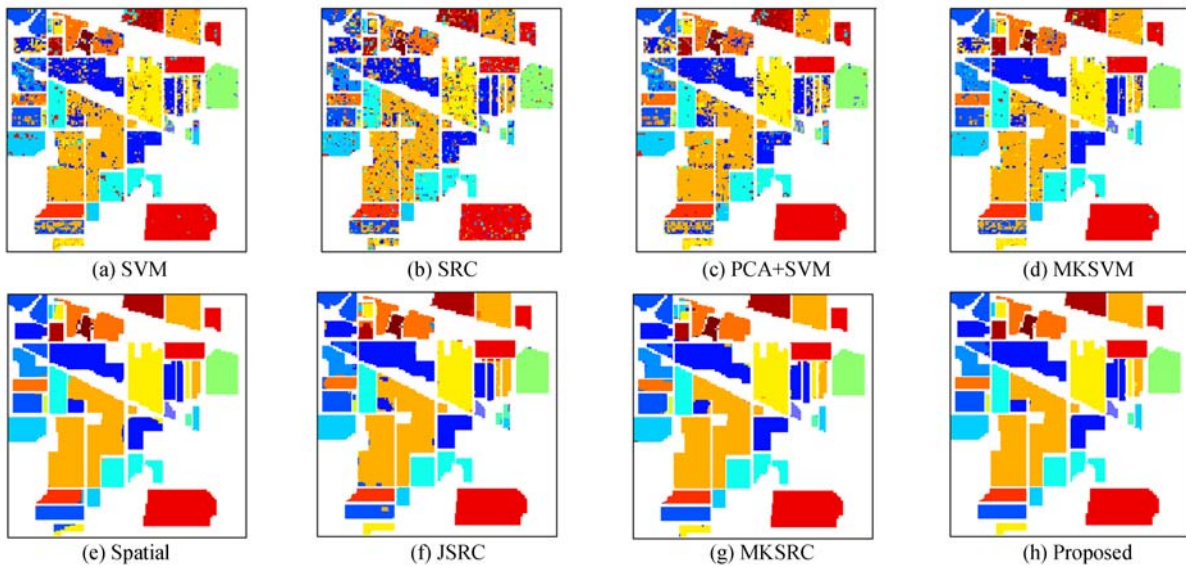


图 5 Indian Pines 影像分类结果

Fig. 5 Classification results of different algorithms in Indian Pines image

Indian Pines 影像存在非常明显的不均衡现象,Oats 和 Grass/mowed 分别只有 20 和 28 个像元,而 Soybeans-min 则共有 2 455 个像元。在

分类过程中这些小样本的地物很难正确分类。从表 1 可以看出使用 SVM 进行分类时,这两类地物的分类精度只有 32% 和 55%,大大拉低了平均

分类精度(AA)。使用 PCA 降维后的分类精度提升并不明显,说明使用简单的线性降维并不能有效的解决高光谱影像高维度的问题。JSRC 和 MKSRC 均为空谱联合分类方法,由于考虑了空间信息,因此分类精度有了明显提高。本文还专门进行了只使用空间信息的分类实验(Spatial),取得了意想不到的效果,总体分类精度高达

98.37%,甚至超过了两种空谱联合分类方法(JSRC 和 MKSRC),说明空间信息在地物分类过程中是非常有用的,而 JSRC 和 MKSRC 对空间信息的利用并不充分。本文算法通过多尺度特征提取,并且用多核在分类器内进行有效融合,使得空间信息和光谱信息得到充分利用,取得 99.51% 分类精度,并且对于小样本的分类结果也很出色。

表 1 Indian Pines 影像分类精度表

Tab. 1 Classification accuracy of different algorithms in Indian Pines image

Class	Train	Test	SVM	SRC	PCA+SVM	MKSVM	Spatial	JSRC	MKSRC	Proposed
Alfalfa	5	41	54.35	36.96	50.00	78.26	100.00	100.00	97.83	100.00
Corn-notill	143	1 285	78.99	76.05	78.71	86.97	97.90	97.20	97.69	98.74
Corn-min	83	747	72.89	65.18	65.78	77.83	98.92	92.05	97.95	98.07
Corn	24	213	56.12	71.31	68.78	79.75	97.47	98.31	96.20	100.00
Grass/pasture	48	435	87.37	83.44	87.78	94.41	100.00	97.10	98.96	100.00
Grass/trees	73	657	95.62	90.27	95.89	98.08	99.45	99.73	100.00	100.00
Grass/mowed	3	25	32.14	71.43	46.43	78.57	100.00	96.43	96.43	100.00
Hay-winrowed	48	430	97.91	92.05	97.70	98.95	100.00	100.00	100.00	100.00
Oats	2	18	55.00	80.00	50.00	90.00	100.00	75.00	100.00	100.00
Soybeans-notill	97	875	77.47	52.88	82.51	86.52	95.58	90.84	96.30	100.00
Soybeans-min	246	2 209	84.56	81.22	83.58	87.94	99.06	97.43	98.86	99.59
Soybeans-clean	59	534	76.39	54.97	79.26	85.67	97.98	93.59	94.94	100.00
Wheat	21	184	99.02	88.78	98.05	99.02	91.22	100.00	99.51	100.00
Woods	127	1 138	95.65	88.06	94.47	97.00	99.92	99.60	100.00	100.00
Bldg-grass-drives	39	347	60.62	64.25	72.28	75.39	100.00	93.52	98.70	100.00
Stone-steel-Towers	9	84	82.80	77.42	86.02	84.95	95.70	87.10	100.00	98.92
OA			81.09	73.46	81.15	85.13	98.37	96.05	98.20	99.51
AA			75.43	73.39	77.33	87.46	98.32	94.86	98.33	99.71
Kappa			0.789	0.707	79.070	0.834	0.981	0.955	0.979	0.994

3.3 Pavia University 实验结果及讨论

Pavia University 影像包含 42 776 个带标记像元,9 种地物,实验数据较为丰富,分布也较 Indian Pines 影像均衡,因此分类也较 Indian Pines 容易,因此在实验过程中训练集占有所有已标记像元的比例调整为 3%。此外 Pavia University 影像同类地物分布较为分散,这对于空谱联合分类可能会产生不利影响。地物分类结果如图 6 所示。

Pavia University 影像中 Meadows 地物占比超过 40%,因此很多其他地物被错误标记为 Meadows,这一现象在 SVM(a)、SRC(b)、PCA+SVM(c) 和 JSRC(d) 中表现的比较明显。MKSVM 表现较好但也存在很多孤立的错分点。Spatial(e)、MKSRC 和本文算法得到的分类结果图较为平滑,与真

实地物分布状况也更为接近。表 2 给出了每类地物的分类精度和总体分类精度等指标。

从表 1 可以看出使用 SVM、SRC 和 PCA 算法的 OA 都能达到 80% 以上,但是对 Gravel、Bare soil 以及 Bitumen 的分类精度很低,这可能是由于一方面这 3 类地物分布较少,另一方面他们光谱特性较为接近,导致分类结果不佳,利用好像元间的位置关系,可以有效地解决这个问题。Spatial 分类的总体精度达到了 95.53% 充分显示了空间信息在分类过程中所起到的作用,但是对于 Shadow 其分类精度只有约 40%,远低于其他方法。这说明 Shadow 相对于其它地物具有独特的光谱特性,谱分类方法已经具有很好的效果。但是其在影像中分布十分分散,空间信息对于其

分类的作用较小。Spatial 方法通常可以达到很高的分类精度, 但却不具有通用性, 必须空谱结合才能达到较好的效果。从总体分类精度上看本文算法取得了最高的 97.96%, 高于其他谱分类、空

谱分类、空间分类算法, 说明本文算法对于空谱信息的利用更加充分。而且对于所有地物的精度均在 90% 以上, 说明本文算法具有很好的通用性和鲁棒性。

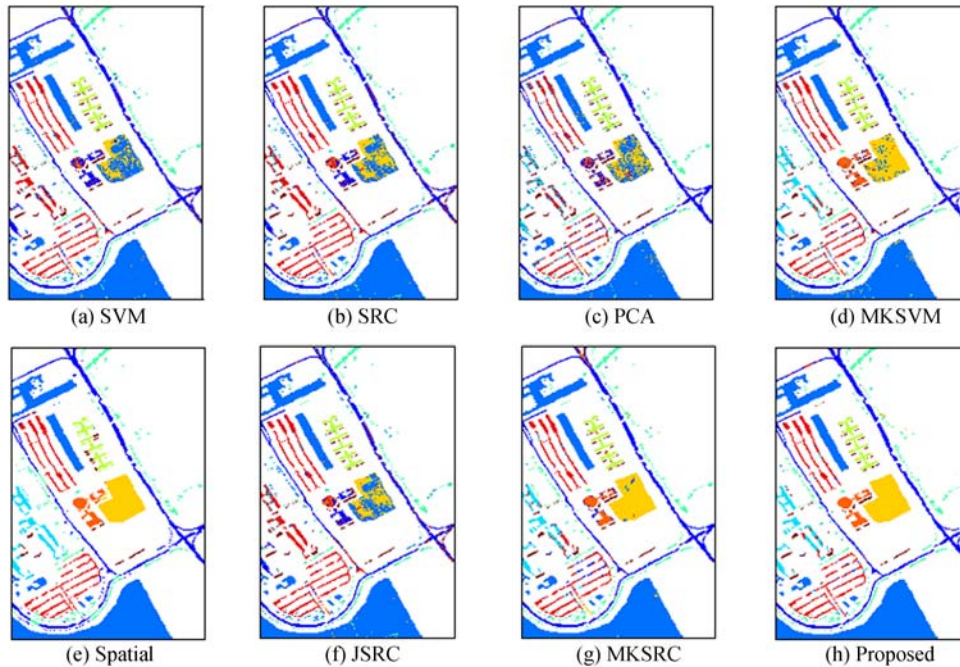


图 6 Pavia University 影像分类结果图

Fig. 6 Classification results of different algorithms in Pavia University image

表 2 Pavia University 影像分类精度表

Tab. 2 Classification accuracy of different algorithms in Pavia University image

Class	Train	Test	SVM	SRC	PCA+SVM	MKSVM	Spatial	JSRC	CKSRC	Proposed
Asphalt	199	6 432	91.77	85.54	91.19	93.02	94.41	87.94	94.27	97.45
Meadows	559	18 090	99.07	98.97	98.45	98.03	99.93	97.38	99.68	99.97
Gravel	63	2 036	14.44	14.15	55.17	83.61	98.90	60.93	80.80	91.42
Trees	92	2 972	86.49	76.31	87.01	94.71	80.87	83.81	97.39	94.32
Metal	40	1 305	99.03	99.18	96.88	98.88	90.41	97.84	95.91	100.00
Bare soil	151	4 878	41.40	54.34	54.15	89.80	99.86	74.71	97.14	99.90
Bitumen	40	1 290	24.59	32.86	44.21	87.89	97.74	43.68	81.43	99.55
Bricks	110	3 572	87.07	95.19	73.49	87.83	96.41	86.20	86.39	92.34
Shadow	28	919	99.68	99.47	90.71	100.00	40.44	99.68	93.35	97.57
OA			82.59	83.32	83.82	93.71	95.53	87.80	95.34	97.96
AA			71.50	72.89	76.80	92.64	88.77	81.35	91.81	96.94
Kappa			0.763	0.770	0.781	0.917	0.940	0.838	0.938	0.973

3.4 时间与空间效率分析

由于本文算法使用了多尺度特征的提取与融合, 因此在一定程度上增大计算时间及存储空间的占用。本节通过实验方式测试本文算法在计算时间及存储空间的使用情况。实验过程中从 In-

dian Pines 数据集中随机选择 90% 的像元作为测试样本, 并从其余 10% 像元中选择一定比例的像元作为训练样本, 不断增大训练样本数量, 观察各个阶段的时间消耗及存储空间使用情况。

图 7 所示为特征提取、核权值计算以及像元

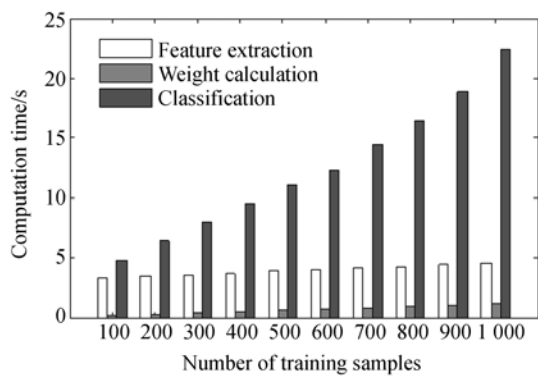


图7 计算时间随训练样本变化图

Fig.7 Computation time with different training set size

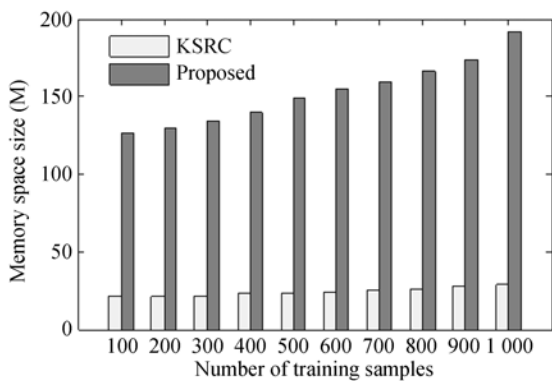


图8 空间占用情况对比图

Fig.8 Memory space size with different training set size

分类3个阶段的所消耗时间随训练样本数量的变化情况。其中第三阶段的时间基本相当于直接使用KSRC分类的时间。从图中可以看出随训练样本数量的增大,计算权值和分类所消耗的时间随变化比较明显,而特征提取的时间并没有太大变化。这是由于特征提取的时间消耗主要在于对多尺度滤波,因此特征提取的时间正比于总体样

参考文献:

- [1] 何芳,王榕,于强,等. 加权空谱局部保持投影的高光谱图像特征提取[J]. 光学精密工程, 2017, 25(1): 263-273.
HE F, WANG R, YU Q, *et al.*. Feature extraction of hyperspectral images of weighted spatial and spectral locality preserving projection (WSSLPP) [J]. *Opt. Precision Eng.*, 2017, 25(1): 263-273. (in Chinese)
- [2] DELLACQUA F, GAMBA P, FERRARI A, *et al.*. Exploiting spectral and spatial information in

本数量,而权值计算的时间正比于训练样本数量,样本分类的时间与训练样本数量和测试样本数量都密切相关。从总的计算时间来看,本文算法较KSRC算法有明显增大,具体增大的情况取决于测试样本数量与训练样本数量的比例。随着训练样本数量的增大,滤波所占时间相较总的计算时间减小。

图8所示为本文算法与传统KSRC算法在运行时的内存使用情况对比。由于高光谱影像通常容量较大,而本文算法在7个尺度上对原始图像进行了空间滤波并存储,并计算7个核矩阵,因此本文算法在存储空间占用上应该是传统算法的7倍左右。从图8可以看出,本文算法的实际内存使用约为KSRC算法的6~7倍。

4 结论

本文针对现有方法对高光谱影像空间信息利用不足的问题提出了多核融合多尺度特征的核稀疏表示算法。分别使用农业种植区高光谱影像 Indian Pines 和城市地区高光谱影像 Pavia University 进行验证。实验发现单纯依靠光谱信息分类效果并不理想,单纯依靠空间位置关系虽然通常可以取得很高的精度,但却丧失了高光谱影像信息量大的优势,通用性也比较差。实验还发现大多空谱联合分类方法对空间信息的利用并不充分影响了分类精度。最终的实验结果表明:本文算法在分类精度上得到明显提升,两个数据集的总体分类精度分别达到99.51%和97.96;对于小样本地物本文算法也取得非常好的分类效果,稳定性和鲁棒性更强,对于高光谱影像的地物分类也更加适用。

hyperspectral urban data with high resolution[J]. *IEEE Geoscience and Remote Sensing Letters*, 2004, 1(4): 322-326.

- [3] YUAN H L, TANG Y Y, LU Y, *et al.*. Spectral-spatial classification of hyperspectral image based on discriminant analysis[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2035-2043.
- [4] 黄鸿,郑新磊. 加权空-谱与最近邻分类器相结合的高光谱图像分类[J]. 光学精密工程, 2016, 24(4): 873-881.

- HUANG H, ZHENG X L. Hyperspectral image classification with combination of weighted spatial-spectral and KNN[J]. *Opt. Precision Eng.*, 2016, 24(4): 873-881. (in Chinese)
- [5] FU W, LI SH T, FANG L Y, *et al.*. Hyperspectral image classification via shape-adaptive joint sparse representation[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(2): 556-567.
- [6] FAUVEL M, TARABALKA Y, BENEDIKTSSON J A, *et al.*. Advances in spectral-spatial classification of hyperspectral images[J]. *Proceedings of the IEEE*, 2013, 101(3): 652-675.
- [7] CHEN Y, NASRABADI N M, TRAN T D. Hyperspectral image classification via kernel sparse representation[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(1): 217-231.
- [8] LI SH SH, NI L, JIA X P, *et al.*. Multi-scale superpixel spectral-spatial classification of hyperspectral images[J]. *International Journal of Remote Sensing*, 2016, 37(20): 4905-4922.
- [9] REININGHAUS J, HUBER S, BAUER U, *et al.*. A stable multi-scale kernel for topological machine learning[C]. *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 2015: 4741-4748.
- [10] 唐中奇, 付光远, 陈进, 等. 基于多尺度分割的高光谱图像稀疏表示与分类[J]. *光学精密工程*, 2015, 23(9): 2708-2714.
TANG ZH Q, FU G Y, CHEN J, *et al.*. Multi-scale segmentation-based sparse coding for hyperspectral image classification[J]. *Opt. Precision Eng.*, 2015, 23(9): 2708-2714. (in Chinese)
- [11] YIN J, LIU ZH H, JIN ZH, *et al.*. Kernel sparse representation based classification[J]. *Neurocomputing*, 2012, 77(1): 120-128.
- [12] CORTES C, MOHRI M, ROSTAMIZADEH A. Algorithms for learning kernels based on centered alignment[J]. *The Journal of Machine Learning Research*, 2012, 13(1): 795-828.
- [13] HE ZH, LI J B. Multiple data-dependent kernel for classification of hyperspectral images[J]. *Expert Systems with Applications*, 2015, 42(3): 1118-1135.

作者简介:



王庆超 (1988—), 男, 河北清河人, 博士研究生, 2014 年于第二炮兵工程大学获得硕士学位, 主要从事视觉目标识别及遥感图像分析方面的研究。E-mail: wangqingchao@yeah.net

导师简介:



付光远 (1966—), 男, 四川简阳人, 教授, 博士生导师, 1993 年于西南交通大学获得硕士学位, 2004 年于第二炮兵工程学院获得博士学位, 主要从事图像匹配精确制导、C4I 系统建模与仿真方面的研究。E-mail: dr-f@21cl.com