

空谱结构保持的高光谱图像分类

侯榜焕,姚敏立,贾维敏,沈晓卫,金 伟

(火箭军工程大学 信息工程系,陕西 西安 710025)

摘要: 高光谱遥感图像具有特征(波段)数多、冗余度高等特点,因此特征选择成为高光谱分类的研究热点。针对此问题,提出了空间结构与光谱结构同时保持的高光谱数据分类算法。考虑高光谱图像的物理特性,首先对图像进行加权空谱重构,使图像的空间结构信息自动融入光谱特征,形成空谱特征集;对利用最小二乘回归模型保存数据集的全局相似性结构的基础上,加入局部流形结构正则项,使挑选的特征子集更好地保存数据集的内在本质结构;讨论了窗口大小和正则参数对分类精度的影响。对 Indian Pines、PaviaU 和 Salinas 数据集的实验表明,该算法得到的特征子集的总体分类精度达到 93.22%、96.01% 和 95.90%。该算法不仅充分利用了高光谱图像的空间结构信息,而且深入挖掘了数据集的内在本质结构,从而得到更有鉴别性的特征子集,相比传统方法明显提高了分类精度。

关键词: 高光谱遥感图像分类; 特征选择; 空谱特征; 结构保持

中图分类号: TP751 文献标志码: A DOI: 10.3788/IRLA201746.1228001

Hyperspectral image classification based on spatial-spectral structure preserving

Hou Banghuan, Yao Minli, Jia Weimin, Shen Xiaowei, Jin wei

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

Abstract: Hyperspectral remote sensing image contains the properties of much features (bands) and high redundancy, and the research of hyperspectral image classification focuses on feature selection. To overcome this problem, a hyperspectral image classification algorithm based on spatial and spectral structure preserving was proposed. Considering the physical characteristics of hyperspectral image, the weighted spatial and spectral reconstruction of the image was conducted firstly, in order to incorporate spatial structure information into the spectral feature set automatically, resulting in the spatial-spectral feature set. On the basis that the least square regression model uncovered the global similarity structure and the regularization term revealed the local manifold structure, the intrinsic structure of the spatial-spectral feature set was well preserved by the selected feature subset. The influence of window size and regularization parameter was also analyzed. The experiments on Indian Pines, PaviaU and Salinas datasets show that the classification accuracy of the proposed algorithm reaches 93.22%, 96.01% and 95.90% respectively. The proposed method not only makes full use of the spatial structure information of the

收稿日期:2017-04-07; 修订日期:2017-05-12

基金项目:国家自然科学基金(61401471);中国博士后科学基金(2014M562636)

作者简介:侯榜焕(1985-),男,博士生,主要从事高光谱图像处理方面的研究。Email: chinayouth001@aliyun.com

导师简介:姚敏立(1966-),男,教授,博士生导师,博士,主要从事信号处理方面的研究。Email: yaominli@sohu.com

hyperspectral image but also uncovers the intrinsic structure of the dataset, which contribute to select more discriminant feature subset and obtain higher classification accuracy compared with conventional methods.

Key words: hypersepctral remote sensing image classification; feature selection; spatial-spectral features; structure preserving

0 引言

高光谱遥感图像(数据集)具有光谱分辨率高、特征(波段)数多、信息冗余多和波段间相关性等特点,直接分类时易出现“惠更斯”现象^[1-4]。如何用较少的特征得到较高的地物分类精度,是当前的研究热点之一。

高光谱特征选择根据是否需要标记信息,分为监督、半监督和无监督三大类。特征选择算法包括基于信息量、基于地物类别和基于数据结构等。在基于数据结构的特征选择方法中,数据集的全局相似性结构指训练样本集中每两个样本之间的成对相似性关系。Fisher Score(FS)对每个特征单独评价,但没有考虑特征间的相关性,无法避免冗余信息^[5];为此,有学者在最小二乘回归模型中引入基于 $l_{2,1}$ 范数的正则项,保存了全局相似性结构,能对所有特征进行整体衡量,避免冗余^[5]。在此基础上,Robust Feature Selection(RFS)^[6]对最小二乘回归模型的损失函数和正则项联合使用 $l_{2,1}$ 范数,使之对外点具有更好的鲁棒性。但是,上述算法都没有考虑数据集的局部流形结构。参考文献[5-7]在特征选择时同时考虑数据的全局与局部结构,取得了较好的效果。

以上算法应用于高光谱遥感数据集特征选择时,只利用了图像的光谱信息,忽略了图像特有的空间结构信息。而近来研究表明,联合使用光谱信息和空间信息,能有效提高地物分类精度^[8-12]。目前对联合使用空间结构信息和光谱结构信息进行特征选择的研究很少。已有算法主要是将光谱特征以及提取的纹理特征、数学形态学特征等多种特征进行堆叠,形成新的特征向量,再从中选出特征子集^[8-9]。但在空谱联合特征提取与分类方面,有学者利用高光谱图像的空间一致性,将空间信息融入光谱数据,实现了较好的特征提取和地物分类效果^[10-11]。

针对以上问题,文中提出一种面向高光谱分类

的空间结构和光谱结构同时保持的特征选择算法 (Feature Selection based on Spatial and Spectral Structure Preserving, S³PFS)。该算法首先利用空地一致性原理对高光谱图像进行空谱重构,使空间结构信息自动融入光谱特征,形成空谱数据集(特征集);再通过全局结构与局部结构同时保存的特征选择 (Global and Local Structure Preserving Feature Selection, GLSP),从空谱特征集挑选出特征子集。经 Indian Pines、PaviaU 和 Salinas 数据集的实验表明,该算法具有较高的地物分类精度。

1 文中算法

首先介绍加权空谱重构^[10-13],再给出全局与局部结构同时保存的特征选择算法(GLSP),最后提出 S³PFS 算法。

1.1 加权空谱重构

对包含 N 个样本点高光谱图像,记为 $X \in R^{I \times J \times m}$, $N=I \times J$ 。令 $N(x_{ij})$ 代表像元 $X_{ij} \in R^m$ 的空间近邻区域,即以像元 x_{ij} 为中心的大小为 $\omega \times \omega$ 的正方形空间区域,其中空间窗口 ω 为奇正整数。当像元 x_{ij} 位于图像边缘或角落时,空间窗口内的空缺位置以镜像像元填充。

以 x_{pq} 表示空间近邻区域 $N(x_{ij})$ 内的任一像元,像元 x_{ij} 加权重构后记为 \hat{x}_{ij} ,其定义为:

$$\hat{x}_{ij} = \frac{\sum_{x_{pq} \in N(x_{ij})} v_{pq} x_{pq}}{\sum_{x_{pq} \in N(x_{ij})} v_{pq}} \quad (1)$$

式中: $v_{pq} = \exp(-t \|x_{pq} - x_{ij}\|_2^2)$ 向量的 Euclidean 范数用 $\|\cdot\|_2$ 表示,参数 t 表征不同像元间的相互影响程度。由公式(1)可知, x_{pq} 与 x_{ij} 越相似,权重 v_{pq} 越大,即 x_{pq} 在 x_{ij} 重构过程中的作用越大。加权重构后的数据集,即空谱特征集,记为 $\hat{X} \in R^{I \times J \times m}$ 。

1.2 全局结构与局部结构同时保持的特征选择

参考文献[6]提出的 RFS 算法的目标函数为:

$$\operatorname{argmin}_{W,b} \left\| XW + eb^T - Y \right\|_{2,1} + \lambda \|W\|_{2,1} \quad (2)$$

$$\|W\|_{2,1} = \sum_{i=1}^m \|w^i\|_2 = \sum_{i=1}^m \sqrt{\sum_{j=1}^c w_{ij}^2} \quad (3)$$

式中： $W \in R^{m \times c}$ 为回归系数矩阵，也是权重矩阵； w^i 和 w_j 分别是矩阵 W 的第 i 行和第 j 列。 $Y \in R^{N \times c}$ 是由 0 和 1 构成的类别标记矩阵，列向量 $e \in R^N$ 的元素全为 1， $b^T \in R^c$ 是偏置项。

类别标记矩阵 Y 表示了训练样本中每两个样本间的全局相似关系，即样本集的全局相似性结构。RFS 得到的矩阵 W 具有行稀疏的效果，体现了不同特征在保存数据集全局相似性结构时贡献的大小，达到了特征选择的效果^[5-6]；但它没有保存数据集的局部几何结构，而局部信息在特征选择中也有重要的作用^[5-7]。

为此，文中提出监督的全局结构与局部结构同时保持的特征选择算法，目标函数为：

$$\operatorname{argmin}_{W,b} \left\| XW + eb^T - Y \right\|_{2,1} + \mu \operatorname{Tr}(W^T X^T L X W) + \lambda \|W\|_{2,1} \quad (4)$$

公式(4)第一项表示对全局相似性结构的保存。第二项以局部保持投影^[14](Local Preserving Projection, LPP) 实现，能保存数据集的局部流形结构。基于 LPP 的局部保持项可写为：

$$\min \sum_{i,j=1}^N \|W^T x_i - W^T x_j\|^2 S_{ij} = \min \operatorname{Tr}(W^T X^T L X W) \quad (5)$$

能够使高维空间的近邻关系在低维嵌入中保持不变。式中相似矩阵 S 的计算公式为：

$$S_{ij} = \begin{cases} \exp(-\|x_i - x_j\|^2 / 2\sigma^2) & x_i \in N_k(x_j) \text{ or } x_j \in N_k(x_i) \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

式中： $N_k(x_j)$ 为数据点 x_i 的 k 个近邻点的集合； σ 为高斯核的宽度。定义 $L = D - S$ ，对角矩阵 D 的对角线元素为 $D_{ij} = \sum_{j=1}^N S_{ij}$ 。

求解公式如下：

$$W = \{X^T [G + \mu(L + L^T)] X + \lambda C\}^{-1} (X^T G Y) \quad (7)$$

$$b^T = c(e^T D Y - e^T D X W) \quad (8)$$

式中： $c = (e^T D e)^{-1}$ ， $G = D - c D e e^T D$ 。对角矩阵 $D \in R^{m \times m}$ 和 $C \in R^{m \times m}$ 的对角线的第 i 个元素计算公式分别为 $D_{ii} = 1 / \|u^i\|_2$ 和 $C_{ii} = 1 / \|w^i\|_2$ 。这里 u_i 表示 U 的第 i 行，

$$U = XW + eb^T - Y。$$

1.3 空谱结构保持的特征选择

在空谱重构和 GLSP 的基础上，提出空间结构和光谱结构同时保持的特征选择算法(S³PFS)。S³PFS 首先对高光谱数据集进行加权空谱重构，生成空谱特征集 \hat{X} ， \hat{X} 自动保存了图像的空间结构信息；然后对空谱特征集 \hat{X} 应用 GLSP，选出对内在本质结构保存能力最强的特征子集。

- Background
- Alfalfa(46)
- Corn-notill(1 428)
- Corn-min(830)
- Corn(237)
- Grass/Pasture(483)
- Grass/Trees(730)
- Grass/Pasture-mowed(28)
- Hay-windrowed(478)
- Oats(20)
- Soybean-notill(972)
- Soybean-min(2 455)
- Soybean-clean(593)
- Wheat(205)
- Woods(1 265)
- Blog-Grass-trees-drives(386)
- Stone-steet towers(93)



(a) 假彩色图

(a) False-color image



(b) 真实地物图

(b) Truth ground object map

图 1 Indian Pines 高光谱图像

Fig.1 Indian Pines hyperspectral image

求解时，将 C 和 D 初始化为单位矩阵，根据公式(7)和(8)更新 W 和 b^T ，将 C 、 D 和 W 、 b^T 交替迭代更新，直至收敛。算法收敛性同 RFS 算法。依据 $\|w^i\|_2$ 的

大小将 m 个波段降序排列, 选出前 p 个波段。

2 实验结果和分析

2.1 实验数据集

Indian Pine 数据集: 该图像是 AVIRIS 传感器于 1992 年拍摄的美国印第安纳州的一片农田。图像大小为 145 pixel×145 pixel, 空间分辨率为 20 m; 光谱范围为 400~2 500 nm, 光谱分辨率为 9.7~12 nm; 去除大气吸收和噪声影响严重的波段后, 剩余 200 个波段用于实验。该图像参考数据样本共计 10 249 个, 含有 16 类地物信息。其伪彩色图像、真实地标图和各类地物样本数量如图 1 所示。

PaviaU 数据集: 该图像是 2002 年由 ROSIS 传感器获取的意大利北部 Pavia 大学区域的航空高光谱遥感图像。图像大小为 610 pixel×340 pixel, 空间分辨率为 1.3 m; 包含了 430~860 nm 光谱范围内的 115 个波段, 光谱分辨率为 4~12 nm, 去除噪声影响严重的波段后, 剩余 103 个波段用于实验。该图像参考数据样本共计 42 776 个, 含有 9 类地物信息。

Salinas 数据集: 该图像由 AVIRIS 传感器拍摄于美国加利福尼亚南部 Salinas 山谷区域。图像大小为 512 pixel×217 pixel, 空间分辨率为 3.7 m; 包含了 400~2 500 nm 光谱范围内的 224 个波段, 光谱分辨率为 9.7~12 nm, 去除噪声影响严重的波段后, 剩余 204 个波段用于实验。该图像参考数据样本共计 54 129 个, 含有 16 类地物信息。

2.2 实验设置


实验中, 分别从每类地物随机选取一定数量的训练样本, 剩余所有样本作为测试样本。首先利用训练样本对各特征选择算法进行学习, 进而得到特征子集, 再利用特征子集进行分类实验。以分类精度的高低来评价算法性能的优劣。使用总体精度(Overall Accuracy, OA)、平均精度(Average Accuracy, AA)和 Kappa 系数作为评价指标。为提高实验的精确度和可靠性, 重复运行 10 次, 每次随机选取训练样本, 将 10 次实验的分类精度求平均值。

选用 SVM 分类器, 其核函数选择高斯径向基(Gaussian radial basis function, RBF), 其参数 C 和 γ 分别在 $\{2^6, 2^7 \dots 2^{15}, 2^{16}\}$ 和 $\{2^{-5}, 2^{-4} \dots 2^1, 2^2\}$ 的范围内使用 5 折交叉验证确定。


为验证 S³PFS 的性能, 与 FS、RFS 等算法进行对比。RFS、S³PFS 的参数 λ 、 μ , 都在 $\{0.001, 0.01, 0.1, 1, 10, 100, 1\ 000, 10\ 000\}$ 内取值。

2.3 S³PFS 算法的参数调节

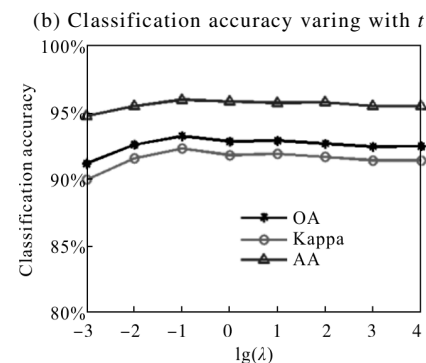
为探索 S³PFS 的参数对性能的影响, 分别从每类地物中选取 30 个训练样本进行实验(若某类地物总样本数少于 80 个, 则只取 10 个样本)。以 Indian Pines 数据集为例给出实验结果。图 2 给出了 S³PFS 的最大分类精度随参数的变化曲线。实验中, ω 、 t 、 λ 和 μ 的默认设置为 13、0.5、0.1 和 0.1。分析某一个参数影响时, 其余参数均采用默认设置。



(a) ω 对分类精度影响

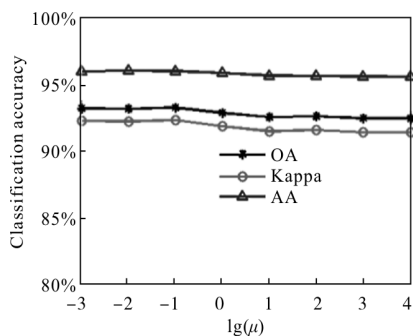


(b) t 对分类精度影响



(c) λ 对分类精度影响

(c) Classification accuracy varying with λ



(d) μ 对分类精度的影响

(d) Classification accuracy varying with μ

图 2 Indian Pines 数据集上参数 ω 、 t 、 λ 和 μ 对最大总体分类精度的影响

Fig.2 Maximum overall classification accuracy varying with different parameters ω , t , λ and μ of Indian Pines dataset

如图 2(a)所示,当空间窗口 ω 为 13 时,分类精度最高。这是由于较小的空间窗口包含的空间信息较少,故分类精度不高;当空间窗口增大时,空谱特征集融入了较多的地物空间分布细节结构信息,有利于提高分类精度;若空间窗口再大,窗口内的异类地物增多,使重构后的像元偏离该地物典型光谱特征,分类精度降低。

光谱因子 t 决定着窗口内各像元权重的相对差异。如图 2(b)所示,当 t 太小或太大时,近邻像元间的权重差异相对变小,异类地物像元的作用相对增强,使总体分类精度降低。

正则参数 λ 决定着对冗余信息的去除能力,取值较小时去除冗余能力较弱,取值过大时部分有用信息也被去除;当选为 0.1 时,分类精度最高。正则参数 μ 控制着局部结构信息影响的强弱,取为 0.1 时分类精度最高。相比空间窗口和光谱因子,这两个参数的影响相对较小。

2.4 Indian Pines 的实验结果及分析

当每类地物选取 30 个训练样本时,图 3 给出了不同特征选择算法在不同特征数下的总体分类精度。当特征数增加时,各算法的总体分类精度逐步升高,且 S³PFS 始终高出 FS、RFS 约 10%~20%。当特征数大于 10 个时,S³PFS 算法已达到较高的分类精度;特征数再增加时,分类精度提升很小。对比其他算法,S³PFS 选取较少的特征,就可以达到较高的分类精度,体现了该算法的优越性。

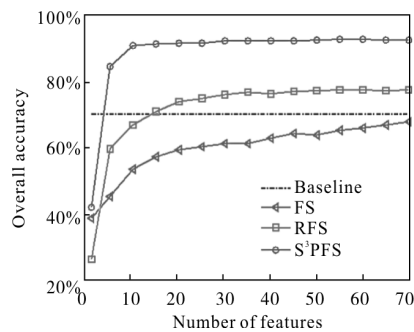


图 3 各算法在不同特征数下的总体分类精度

Fig.3 OA of different algorithms with different number of features

表 1 是各算法在不同训练样本下的最大总体分类精度和标准差(粗体表示最大值)。由表可知,随着训练样本的增加,各算法的总体分类精度不断提高;这是因为训练样本越多,包含的标记信息和局部结构信息越丰富,所选特征能保存更多的全局相似性或局部几何特性信息,故分类精度越高。在不同数量的训练样本下,FS、RFS 和 S³PFS 的分类精度依次提高,且 S³PFS 的分类结果始终优于其他算法。这是因为,FS 和 RFS 所选的特征子集,虽然能保存数据集的全局相似性结构,但都没有利用高光谱图像中地物的空间分布信息;同时,FS 也无法避免冗余信息的影响。而 S³PFS 不仅有效挖掘了高光谱数据的空间结构信息,还同时保存了数据集的全局相似性结构和局部几何结构信息,还最大限度避免了冗余,故取得了较高的分类精度。

表 1 不同训练样本下的分类精度(单位: %)

Tab.1 Classification accuracies varied with different number of train samples(Unit: %)

Train	Baseline	FS	RFS	S ³ PFS
10	57.15±4.19	58.49±2.56	66.92±2.32	83.68±1.85
20	66.19±1.89	65.62±2.30	74.15±1.35	90.03±2.29
30	70.50±1.29	68.22±2.22	77.96±1.74	93.22±1.32
40	73.61±1.30	72.54±2.01	80.15±1.11	94.02±0.99
50	75.48±1.28	73.71±1.90	81.20±1.20	94.94±1.01

表 2 是当每类地物选取 30 个训练样本时,各算法对不同类别地物的分类精度,图 4 是对应的分类识别图。从各地物类别的分类精度看,S³PFS 比 RFS 在“Corn-notill”、“Woods”和“Soybean-notill”等地物类别上的有超过 10%的提高,在少数地物类别如

“soybean -min”、“Bldg -Grass -Trees -Drives”和“Corn-min”上提升幅度超过 20%。这是因为这几类地物主要由大片均匀区域构成，而 S³PFS 所选特征子集充分利用了高光谱图像地物的空间分布结构信息和光谱数据结构信息，故改善了分类效果。

表 2 不同算法对各类地物的分类精度(单位: %)

Tab.2 Class-specific accuracies of several ground object by different algorithms (Unit: %)

Classes	Train	Test	FS	RFS	S ³ PFS
Alfalfa	10	36	76.39	87.22	98.06
Corn-notill	30	1 398	60.69	71.49	90.29
Corn-min	30	800	63.05	71.21	93.58
Corn	30	207	77.54	92.08	98.89
Grass/Pasture	30	453	85.87	91.39	92.08
Grass/Trees	30	700	86.64	94.54	97.66
Grass/Pasture-mowed	10	18	83.33	93.33	98.89
Hay-windrowed	30	448	95.16	97.86	99.53
Orats	10	10	96.00	100.00	100.00
Soybean-notill	30	942	72.95	77.73	92.59
Soybean-min	30	2 425	47.86	63.62	88.32
Soybean-clean	30	563	77.83	85.93	93.64
Wheat	30	175	98.00	99.31	98.69
Woods	30	1 235	81.55	87.04	98.62
Bldg-Grass-Trees-Drs	30	356	54.44	73.48	96.54
Stone-steel towers	30	63	94.13	96.67	98.41
OA	-	-	68.22±1.58	77.96±1.26	93.22±1.32
Kappa	-	-	64.29±1.89	75.10±1.38	92.27±1.49
AA	-	-	78.22±1.96	86.43±0.45	95.99±0.64

由图 4 可知,FS 和RFS 的分类图的“椒盐”现象非常明显;S³PFS 的“椒盐”现象明显减少,尤其是大片同类地物区域内部的错分点较少,分类图比较光滑。





图 4 各算法的分类识别图

Fig.4 Classification maps of different algorithms

2.5 PaviaU 和 Salinas 的实验结果及分析

表 3 和表 4 是不同算法在 PaviaU 和 Salinas 数据集上的分类精度和标准差(粗体表示最大值)。由

表 3 PaviaU 数据集上不同算法的分类精度(单位: %)

Tab.3 Classification accuracies of different algorithms on PaviaU dataset(Unit: %)

Train	Baseline	FS	RFS	S ³ PFS
10	65.72±5.47	68.48±4.89	68.80±5.67	82.22±4.33
20	72.81±4.42	70.92±3.36	77.12±3.47	92.16±2.79
30	79.56±3.32	76.00±2.15	81.70±2.44	96.01±1.27
40	82.30±1.41	76.86±1.95	84.63±1.85	96.10±1.46
50	83.99±1.79	77.74±1.86	85.30±1.66	96.64±1.15

表 4 Salinas 数据集上不同算法的分类精度(单位: %)

Tab.4 Classification accuracies of different algorithms on Salinas dataset(Unit: %)

Train	Baseline	FS	RFS	S ³ PFS
10	82.66±1.59	82.15±1.70	82.91±1.39	92.83±1.01
20	85.61±1.35	84.85±1.40	86.22±1.52	95.06±0.80
30	86.92±1.57	86.69±1.10	87.78±1.50	95.90±0.63
40	88.30±0.94	87.94±1.18	88.62±1.09	96.07±0.59
50	89.28±0.91	89.21±0.90	89.45±0.96	96.66±0.54

表可知,随着训练样本的增加,各算法的总体分类精度不断提高;在不同数量的训练样本下,FS、RFS 和 S³PFS 的分类精度依次提高,这些与 Indian Pines 数据集的分析结论一致。S³PFS 在这两个数据集的分类结果始终优于其它算法约 7%~9%。

2.6 时间复杂度分析

以 n 表示训练样本数量。RFS 的复杂度为 $O(n^2m+(n+c)m^2+2nmc)$ 。S³PFS 的复杂度为 $O(w^2mN+2n^2m+(n+c)m^2+3nmc)$,主要受数据集样本数量 N 、训练样本数量 n 和数据集维数(特征数) m 影响,且与窗口大小 w 密切相关。

表 5 给出了不同算法的运行时间。由表可知,受较大的空间窗口、较多的数据集样本和程序结构设计等因素的影响,S³PFS 的运行时间较长。但由于 S³PFS 的分类精度明显高于 RFS,故此处的时间代价是可以接受的。

表 5 各算法的运行时间(单位:s)

Tab.5 Time cost of different algorithm(Unit:s)

Dataset	FS	RFS	S ³ PFS
Indian Pines	0.2	0.4	5.2

3 结 论

针对高光谱遥感图像数据集特征数多、信息冗余多和特征件相关性强的特点,结合高光谱图像“图谱合一”的物理特性,文中提出了一种的空间结构与光谱结构同时保存的高光谱遥感图像分类算法。该算法充分利用了高光谱图像中地物的空间分布信息,以加权空谱重构的方式将其自动融入光谱特征,形成空谱特征集;在此基础上,以最小二乘回归模型揭示数集的内在本质结构,选出最有鉴别力的特征子集,得到较高的分类精度。实验结果表明,该算法在 Indian Pines、PaviaU 和 Salinas 高光谱遥感数据集上的总体分类精度分别达到 93.22%、96.01%和 95.90%,相比传统光谱算法有了较大幅度的提高。但是,该算法在空谱重构过程中,需要调节窗口大小和光谱因子两个参数。如何实现自适应的空谱重构,是下一步要研究的内容。

参考文献:

[1] Deng Chengzhi, Zhang Shaoquan, Wang Shengqian, et al.

Hyperspectral unmixing algorithm based on L1 regularization [J]. *Infrared and Laser Engineering*, 2015, 44(3): 1092–1097. (in Chinese)
 邓承志, 张绍泉, 汪胜前, 等. L1 稀疏正则化的高光谱混合像元分解算法比较 [J]. 红外与激光工程, 2015, 44(3): 1092–1097.
 [2] Zhao Huijie, Li Mingkang, Li Na, et al. A band selection method based on improved subspace partition [J]. *Infrared and Laser Engineering*, 2015, 44(10): 3155–3160. (in Chinese)
 赵慧洁, 李明康, 李娜, 等. 一种基于改进子空间划分的波段选择方法[J]. 红外与激光工程, 2015, 44(10): 3155–3160.
 [3] Fang Min, Wang Jun, Wang Hongyan, et al. Feature extraction of hyperspectral remote sensing data using supervised neighbor reconstruction analysis [J]. *Infrared and Laser Engineering*, 2016, 45(10): 1028003. (in Chinese)
 方敏, 王君, 王红艳, 等. 应用监督近邻重构分析的高光谱遥感数据特征提取[J]. 红外与激光工程, 2016, 45(10): 1028003.
 [4] Feng Shuyi, Zhang Ning, Shen Ji, et al. Method of cloud detection with hyperspectral remote sensing image based on the reflective characteristic [J]. *Chinese Optics*, 2015, 8(2): 199–205. (in Chinese)
 冯书谊, 张宁, 沈霁, 等. 基于反射率特性的高光谱遥感图像云检测方法研究[J]. 中国光学, 2015, 8(2): 199–205.
 [5] Liu X W, Wang L, Zhang J, et al. Global and local structure preservation for feature selection [J]. *IEEE Transactions on Neural Network and Learning System*, 2014, 25(6): 1083–1095.
 [6] Nie F P, Huang H, Cai X, et al. Efficient and robust feature selection via joint ℓ_1 -norms minimization [C]//Proceedings of Advances in Neural Information Processing System, 2010: 1813–1821.
 [7] Zhu X F, Li X L, Zhang S C, et al. Robust joint graph sparse coding for unsupervised spectral feature selection [J]. *IEEE Transactions on Neural Network and Learning System*, 2017, 28(6): 1263–1275.
 [8] Zhang Q, Tian Y, Yang Y P, et al. Automatic spatial-spectral feature selection for hyperspectral image via discriminative sparse multimodal learning [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(1): 261–279.
 [9] Li H C, Xiang S M, Zhong Z S, et al. Multicenter spatial-spectral unsupervised feature selection for hyperspectral image classification [J]. *IEEE Geoscience and Remote*

- Sensing Letters*, 2015, 12(8): 1660–1664.
- [10] Zhou Y C, Peng J T, Chen C L P. Dimension reduction using spatial and spectral regularized local discriminant embedding for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(2): 1082–1095.
- [11] Huang Hong, Zheng Xinlei. Hyperspectral image classification with combination of weighted spatial–spectral and KNN [J]. *Optics and Precision Engineering*, 2016, 24(4): 873–880. (in Chinese)
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): 873–880.
- [12] He Fang, Wang Rong, Yu Qiang, et al. Feature extraction of hyperspectral images of weighted spatial and spectral locality preserving Projection [J]. *Optics and Precision Engineering*, 2017, 25(1): 263–273. (in Chinese)
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.
- [13] Hao Zhicheng, Wu Chuan, Yang Hang, et al. Image detail enhancement method based on multi–scale bilateral texture filter [J]. *Chinese Optics*, 2016, 9(4): 423–431. (in Chinese)
郝志成, 吴川, 杨航, 等. 基于双边纹理滤波的图像细节增强方法[J]. *中国光学*, 2016, 9(4): 423–431.
- [14] He X, Niyogi P. Locality preserving projections [C]// *Proceedings of the 17th Annual Conference on Neural Information Processing Systems*, 2004, 16: 153–160.