



综合聚类和上下文特征的高光谱影像分类

鲍蕊^{1, 2, 3} 薛朝辉^{2, 3} 张像源¹ 苏红军⁴ 杜培军^{2, 3}

1 天津市地质调查研究院, 天津, 300191

2 南京大学卫星测绘技术与应用国家测绘地理信息局重点实验室, 江苏南京, 210023

3 南京大学江苏省地理信息技术重点实验室, 江苏南京, 210023

4 河海大学地球科学与工程学院, 江苏南京, 210098

摘要: 常规高光谱影像逐像素分类往往没有考虑空间相关性, 分类结果未体现地物的空间关联和分布特征。为了在分类中充分利用空间特征, 利用聚类信息并结合隐马尔可夫随机场模型讨论了高光谱遥感影像光谱-空间分类方法。首先, 在不同特征提取方法(最小噪声分离、独立成分分析和主成分分析)下, 使用不同聚类方法(k -均值、迭代自组织分析算法和模糊 c -均值算法)借助隐马尔可夫随机场获取优化的分割图; 然后, 采用 4 连通区域标记法对分割区域标记生成图像对象, 并根据支持向量机的逐像素分类结果采用多数投票法对图像对象进行分类; 最后, 借助凹槽窗口邻域滤波技术改进分类结果, 削弱“椒盐”现象。该方法综合了监督分类和非监督分类的优势, 通过聚类引入地物空间相关性信息, 通过隐马尔可夫随机场引入上下文特征, 较好地弥补了单纯基于光谱信息分类的不足。

关键词: 聚类; 隐马尔可夫随机场; 支持向量机; 高光谱影像; 光谱-空间分类; 多数投票

中图法分类号: TP751

文献标志码: A

高光谱影像(hyperspectral image, HSI)具有高光谱分辨率、精细光谱特征、图像-光谱一体化表达的特性, 能够提供丰富的地表信息, 受到国内外学者的广泛关注^[1]。高光谱影像处理内容涵盖影像融合、混合像元分解、分类、目标检测、理化参数估计等方向^[2-3]。目前, 国内外学者提出了大量基于像素的 HSI 分类方法, 比较有代表性的方法包括光谱角制图(spectral angle mapping, SAM)、二值编码、支持向量机(support vector machines, SVMs)、最大似然法、贝叶斯估计法, 决策树法、随机森林、神经网络等^[4]。其中 SVM 具有高泛化能力、低样本需求、高鲁棒性等特点^[5], 是目前 HSI 分类中应用效果最好的方法之一。

高光谱影像连续多波段的性质决定了传统的多光谱分析方法往往不适用于高光谱影像。目前高光谱主要面临两个问题: 光谱降维问题和光谱-空间分类问题^[6]。像素间空间关系的忽略被认为是 SVM 分类方法的最大局限^[7]。光谱和空间信息相结合的分类方法(简称“光谱-空间分类”)同时考虑了 HSI 的光谱特征和邻域像素的空间

关系, 不但可以减弱分类结果中的“椒盐”现象, 而且能提高分类结果的同质度^[6]。一些基于数学形态学^[8]、马尔可夫随机场^[9]以及图像分割^[10]的方法已应用于高光谱影像光谱-空间分类中。

聚类是一种有效利用邻域相关和空间特征的方法, 可以根据一定的准则将影像在光谱维划分为空间相关的区域对象, 利用这些区域对象表征空间信息, 较好地弥补单纯基于光谱信息分类的不足。马尔可夫随机场可提升分割性能^[11]。隐马尔可夫随机场(hidden Markov random field, HMRF)源于马尔可夫随机场, 可以从 2 维或 3 维影像中提取空间信息^[12], 是一种方便而直接的空间先验知识描述方法。Ghamisi 等^[13]利用隐马尔可夫随机场进行了高光谱的光谱-空间分类。

1 光谱-空间分类

本文探讨的融合聚类信息的高光谱影像分类方法主要包含特征提取与聚类、基于隐马尔可夫随机场的图像分割、面向对象分类与优化等 3 个

关键环节。

1.1 高光谱影像聚类

聚类是数理统计中的一种多元分析方法,它根据一定的要求和规律对事物进行区分,其中没有任何先验知识,属于无监督分类的范畴。遥感影像聚类是根据感兴趣的标准或同质化的准则(例如根据灰度或纹理)将影像划分为互不重叠的若干同质化区域,可以较好地定义空间依赖性^[14]。

1.2 基于隐马尔可夫随机场的图像分割

假设用 $x = (x_1, \dots, x_N)^T$ 表示图像空间的隐随机场,即类别标号场。 $y = (y_1, \dots, y_N)^T$ 表示可观测的随机场,即图像的灰度场。 N 为像元的数目, $x_i \in L$, L 为所有可能的类别标签集。根据最大后验概率(MAP)的准则,求解式(1)^[9]:

$$\hat{x} = \underset{x}{\operatorname{argmax}} \{P(y | x, \Theta) P(x)\} \quad (1)$$

式中, $P(x)$ 为先验概率,且满足 Gibbs 分布; $P(y | x, \Theta)$ 为联合似然概率,且服从高斯分布。

求解上述的最大后验概率(MAP)时采用最大期望算法(EM)。其过程如下^[15]。

初始化参数集 Θ^0 ,初始的参数由聚类结果给定。本文中采用 3 种常用且聚类效果相对较好的聚类方法—— k -means、ISODATA 和 FCM 分别实验,并进行了对比。

1) E-step:根据第 t 次迭代的参数分布 $\Theta^{(t)}$,估计未知参数的条件期望值。

$$Q(\Theta | \Theta^{(t)}) = E[\ln P(x, y | \Theta) | y, \Theta^{(t)}] = \sum_{x \in \chi} P(x | y, \Theta^{(t)}) \ln P(x, y | \Theta) \quad (2)$$

式中, χ 为所有可能的标签值。

2) M-step:最大化 $Q(\Theta | \Theta^{(t)})$,获得下一个迭代过程的参数估计:

$$\Theta^{(t+1)} = \arg \max_{\Theta} Q(\Theta | \Theta^{(t)}) \quad (3)$$

令 $\Theta^{(t)} \rightarrow \Theta^{(t+1)}$,返回 E-step。

经简化,参数更新服从式(4)^[9]:

$$\mu_l^{(t+1)} = \frac{\sum_i P^{(t)}(l | y_i) y_i}{\sum_i P^{(t)}(l | y_i)} \quad (4)$$

$$(\delta_l^{(t+1)})^2 = \frac{\sum_i P^{(t)}(l | y_i) (y_i - \mu_l^{(t+1)})^2}{\sum_i P^{(t)}(l | y_i)} \quad (5)$$

式中, $P^{(t)}(l | y_i)$ 可从 MAP 中得到。

1.3 面向对象分类与优化

1.3.1 多数投票对象分类

为了得到图像对象,需要对分割形成的区域进行对象划分和标记。为此,采用四连通区域标记法^[16]将分割结果转化为图像对象。从分割图

中获得图像对象后,根据 SVM 逐像元分类结果,对每一个图像对象采用多数投票的方式确定对象类别^[10]。该方法的思想是以图像对象为处理单元,采用多数投票的思想,根据 SVM 分类图给对象赋以多数像元所属的类别标签。经过该过程,每个对象中的所有像元都被归为同一类。具体过程如图 1 所示。

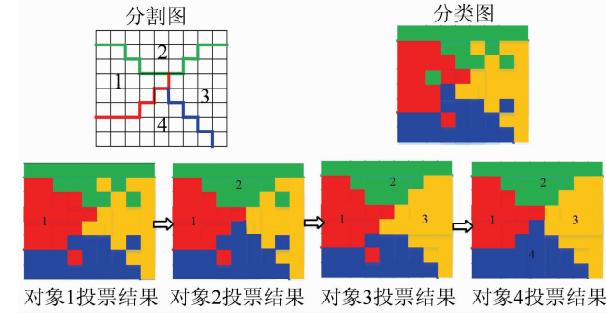


图 1 逐对象多数投票过程

Fig. 1 Graph of Majority Voting for Every Object

1.3.2 分类结果邻域优化(Post-regulation, PR)

为了进一步减少分类图中的噪声,采用 8-邻域和 16-邻域的凹槽窗口掩膜^[10]对整幅图像进行遍历,从而优化分类结果。优化过程分三步进行,具体流程如下。

1) 利用 8-邻域窗口遍历图像,阈值设为 T_1 。如果像元周围的 8 个像素有超过 T_1 个像素的类标签为 L ,并且和中心像元不一致,就将中心像元的类标签改为 L ;

2) 利用 16-邻域的窗口遍历,原理类似,阈值设为 T_2 ;

3) 利用 8-邻域的窗口将图像遍历一遍,阈值设为 T_3 ,由此得到最终的分类结果。

分类结果优化时,窗口的阈值选择应大于邻域像元数目的一半,以确保最终结果的唯一性。实验证明该方法在剔除“椒盐噪声”方面简单有效,特别是对较大区域地物类别内部的噪声有较好的优化效果。

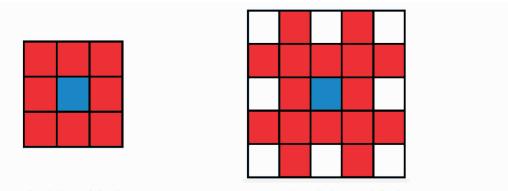


图 2 凹槽邻域窗口

Fig. 2 Chamfer Neighborhoods

1.4 算法实现流程

本文对高光谱影像的光谱-空间分类的多种

策略进行了实验探索。其中,基于隐马尔可夫随机场的综合聚类和上下文特征的光谱-空间分类方法(HMRF-SS)流程如下。

输入: X
输出: Y
步骤 1):聚类信息提取
 $R = \text{cluster}(X)$

步骤 2):基于隐马尔可夫随机场的图像分割
1:特征提取

$F = \text{feature extraction}(X)$

2:边缘检测

$E = \text{canny}(F)$

3:影像分割

$S = \text{HMRF}(R, F, E)$

步骤 3):面向对象分类与优化

1:支持向量机分类

$C = \text{SVM}(X)$

2:对象标记

$OM = 4\text{-neighborhood connectivity}(S)$

3:对象分类

$OC = \text{MV}(C, OM)$

4:分类结果优化(PR)

$Y' = 8\text{-neighborhood filter}(OC, T_3)$

$Y'' = 16\text{-neighborhood filter}(Y', T_2)$

$Y = 8\text{-neighborhood filter}(Y'', T_3)$

其中,本文方法与 Ghamisi 等在文献[13]中分类方法的不同体现在以下几个方面:①在步骤 1)中采用了不同的方法(k -means、ISODATA 和 FCM)进行聚类信息的提取;②在步骤 2)中采用不同特征提取方法(MNF、ICA 和 PCA)获取影像的第一主分量;③在步骤 3)中引入了基于凹槽邻域窗口优化分类结果。

2 实验与讨论

2.1 实验数据

1) ROSIS University of Pavia 数据。该数据是采用 ROSIS (reflective optics spectrographic imaging system) 光谱成像仪采集的意大利帕维亚大学的高光谱遥感影像,影像大小 6610×340 ,空间分辨率为 1.3 m ,含有 115 个波段,波长范围为 $0.43 \sim 0.86\text{ }\mu\text{m}$,通常取去除噪声波段后的 103 个波段进行分类。影像中包含 9 种典型地物的 42776 个样本。图 3 为意大利帕维亚大学数据(以下简称“ROESIS 数据”)。

2) AVIRIS Indian Pines 数据。AVIRIS Indian Pines 数据拍摄于 1992 年,使用 AVIRIS (airborne visible infra-red imaging spectrometer) 成像光谱仪获取,包含印第安那西北区域的某一

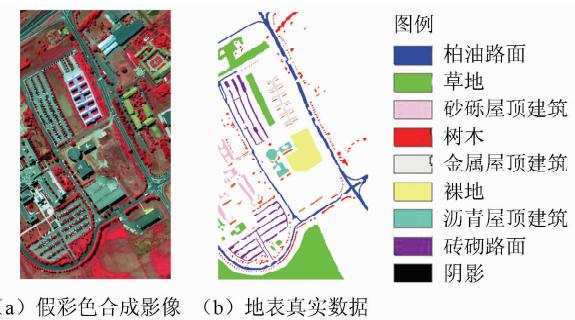


图 3 ROSIS University of Pavia 数据

Fig. 3 ROSIS University of Pavia Data Set

农业区的地表覆盖信息。该数据大小为 145 像素 \times 145 像素,空间分辨率为 20 m ,包括 16 种典型地物的 10366 个样本,光谱范围从 $0.4 \sim 2.5\text{ }\mu\text{m}$ 。该数据包含 220 个波段,本文用去除 20 个水吸收波段后剩余的 200 个波段进行实验。图 4 为 Indian Pines 的高光谱数据(以下简称“AVIRIS 数据”)。

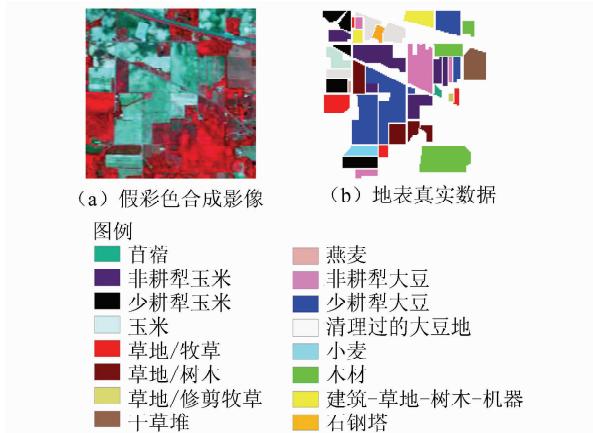


图 4 AVIRIS Indian Pines 数据

Fig. 4 AVIRIS Indian Pines Data Set

2.2 参数设置

采用粒子群优化的 SVM 分类时,ROESIS 和 AVIRIS 高光谱影像数据分别选 5% /类 10% /类的样本进行训练,经过粒子群优化的参数选择分别是 $c = 150$ 、 $g = 1.3703$ 和 $c = 130.2212$ 、 $g = 5.8184$ 。为充分获取信息细节,得到同质度较高的区域对象,分割时允许一定程度的过分割。ROESIS 数据聚类数目设置为 18,AVIRIS 数据聚类数目设置为 30。隐马尔可夫随机场模型求解时 EM 的迭代次数都设为 15。

为方便对比分析,实验中包含的分类方法和简记方式如表 1 所示。实验结果均取 10 次独立实验的平均值,最优的结果用粗体表示。

2.3 ROSIS 数据实验

利用隐马尔可夫随机场模型时,对高光谱影

像特征提取后的第一分量(图 5(a))用 Canny 算子进行边缘探测,图 5(b)为影像在 MNF 变换后对第一主分量探测得到的边缘。

表 1 分类方法的简写

Tab. 1 Abbreviations of Classification Method

分类方法	简记方式
K-Means + SVM	K-SVM
ISODATA+SVM	I-SVM
FCM+SVM	F-SVM
KM + MNF + HMRF + SVM	KHM-SVM
ISODATA + MNF + HMRF + SVM	IHM-SVM
FCM + MNF + HMRF + SVM	FHM-SVM
KM + ICA + HMRF + SVM	KHI-SVM
ISODATA + ICA + HMRF + SVM	IHI-SVM
FCM + ICA + HMRF + SVM	FHI-SVM
KM + PCA + HMRF + SVM	KHP-SVM
ISODATA + PCA + HMRF + SVM	IHP-SVM
FCM + PCA + HMRF + SVM	FHP-SVM



(a) MNF 变换后的第一分量



(b) 图像边缘

图 5 ROSIS 数据边缘检测结果

Fig. 5 Edge Detection Result for ROSIS

图 6(a)是 ROSIS 数据的基于 ISODATA 的隐马尔可夫随机场分割结果。ROSIS 数据 SVM 分类结果如图 6(b)所示。图 6(c)是将分割图和 SVM 分类图用多数投票的方式相结合的结果,较之 SVM 分类图,本文方法地物形状更加平滑规则。

为了进一步优化分类结果,采用凹槽窗口对图像进行优化处理。为了使图像不丢失细节,同时保持窗口的“去噪能力”,经过多次试验,设置窗口阈值的为 $T_1=5, T_2=12, T_3=5$ 。图 6(d)是经过 PR 处理后的最终分类图,与未经 PR 处理的图像相比,“椒盐”现象有所减弱。

为了对比分析不同的特征提取及聚类方法对于高光谱影像光谱-空间分类方法的影响,对不同方法的组合策略分别进行了实验。表 2 给出了在不同的光谱-空间分类方法下,ROSIS 数据的分类精度。从表 2 中可以看出,在 MNF 变换条件下利用隐马尔可夫随机场要比在 ICA 和 PCA 条件下精度高,原因可能是 MNF 变换使主成分按照信噪比而不是方差进行排列,比 PCA 和 ICA 更易分离数据中的噪声。

表 2 不同分类方法对 ROSIS 得到的分类结果

Tab. 2 Classification Results Obtained by Different Methods for the ROSIS Data Set

分类方法	总体精度/%		平均精度/%		Kappa 系数	
	No-PR	PR	No-PR	PR	No-PR	PR
SVM	93.52	95.43	91.99	94.65	0.914	0.952
K-SVM	96.06	97.02	94.28	95.33	0.948	0.960
I-SVM	97.61	98.3	97.22	98.00	0.968	0.977
F-SVM	96.32	97.41	95.51	96.92	0.951	0.966
KHM-SVM	95.78	96.66	94.41	95.21	0.944	0.956
IHM-SVM	97.99	98.53	97.77	98.30	0.973	0.981
FHM-SVM	95.32	96.43	93.82	95.05	0.938	0.953
KHI-SVM	95.53	95.80	92.60	92.99	0.940	0.944
IHI-SVM	96.80	97.14	95.52	95.96	0.957	0.962
FHI-SVM	95.42	96.35	93.02	94.28	0.939	0.951
KHP-SVM	96.8	97.14	95.52	95.96	0.957	0.961
IHP-SVM	95.29	96.09	94.41	95.29	0.937	0.948
FHP-SVM	94.51	95.81	93.54	94.84	0.927	0.943

2.4 AVIRIS 数据实验

AVIRIS 高光谱数据的 SVM 分类结果如图 7(b)所示。基于 ISODATA 聚类的隐马尔可夫随机场的分割图进行多数投票后,其光谱-空间的分类结果如图 7(c)所示。最后,用凹槽窗口遍历整幅分类图,即进行 PR 处理(阈值设置为: $T_1=5, T_2=12, T_3=5$),结果如图 7(d)所示。从图 7(b)到图 7(d),每经过一步处理,分类图同质度都有不同程度的提高。

表 3 是 PR 优化后不同组合策略下 AVIRIS 数据的分类精度。从表 3 可以看出,不同类型和复杂度的地物对应的最佳聚类方法是不同的。对于一些混合地物,在 MNF 聚类条件下利用 ISODATA 的方法相对较好,例如,少耕犁玉米利用 ISODATA 聚类的精度为 90.11%,明显高于 k -means 的 87.54% 和 FCM 的 80.16%,建筑-草地-树木-机器利用 ISODATA 聚类的精度为 81.96%,也要高于 k -means 和 FCM。特征提取采用 MNF 的精度略高于采用 ICA 和 PCA 的精度,这可能是因为 AVIRIS 数据的分辨率较低,含有较多的混合像元和光谱噪声,而最小噪声变换(MNF)具有剔除噪声的性能,而 ICA 和 PCA 变换的第一主成分没有剔除噪声而且仅含有一个特征分量,包含信息相对较少,进而影响了隐马尔可夫随机场的性能;另外,ICA 和 PCA 特征提取方法与 FCM 模糊聚类组合,应用于隐马尔科夫随机场时,得到相对较高的分类精度,这是因为在 ICA 和 PCA 条件下,虽然有光谱噪声的影响,由 FCM 聚类后可得到更多的图像对象,这些对象包含的像元相对较少,和 SVM 的结果多数投票后,正确率会提升,特别是对于小样本数据,例如草

地/修剪牧草和燕麦,在 ICA 和 PCA 条件下,使 FCM 模糊聚类的效果明显要更好。

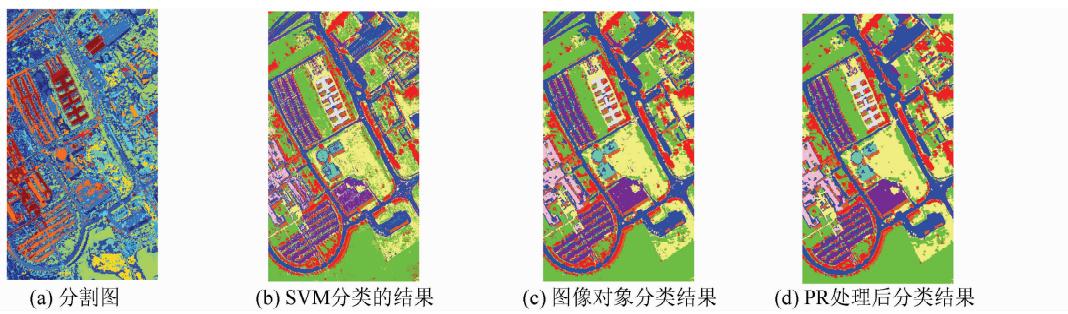


图 6 ROSIS 数据分类结果

Fig. 6 Classification Maps of ROSIS Data Set

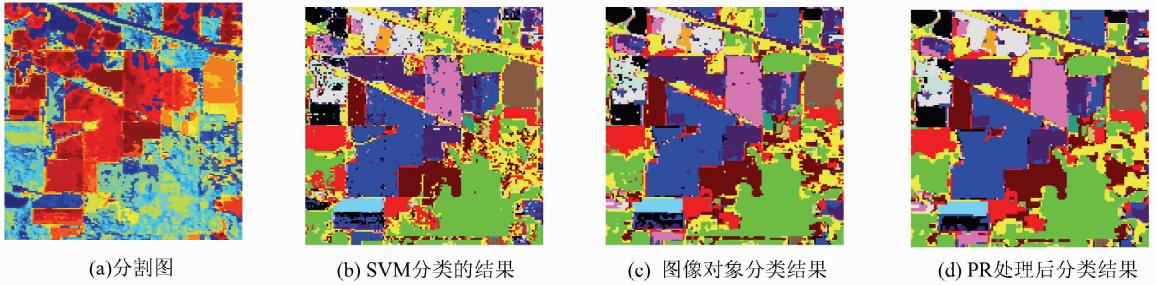


图 7 AVIRIS 数据分类结果

Fig. 7 Classification Maps of AVIRIS Data Set

综合 ROSIS 数据和 AVIRIS 数据的实验来看,可得出如下结论。

1) 在聚类基础上引入隐马尔可夫随机场进行图像分割以获取上下文信息,可有效提高分类精度。

2) 经过 PR 滤波处理后,光谱-空间分类精度

进一步提升。

3) 不同聚类方法和特征提取方法影响隐马尔可夫随机场的分割性能,从而进一步影响光谱-空间分类的效果;影像的分辨率、光谱噪声及样本数量同样会影响到隐马尔可夫随机场。

表 3 不同分类方法对 AVIRIS 得到的分类结果

Tab. 3 Classification Results Obtained by Different Methods for the AVIRIS Data Set

序号	地物 名称	训练 数量	测试 数量	K- SVM	I- SVM	F- SVM	KHM- SVM	IHM- SVM	FHM- SVM	KHI- SVM	IHI- SVM	FHI- SVM	KHP- SVM	IHP- SVM	FHP- SVM
1	苜蓿	5	49	83.93	89.81	98.91	86.77	85.42	71.00	100.00	92.39	92.39	61.96	83.70	82.61
2	非耕犁玉米	143	1 291	87.58	81.32	89.11	89.07	89.37	87.94	79.62	82.95	90.54	84.45	87.18	91.17
3	少耕犁玉米	83	751	85.84	83.97	80.52	87.54	90.11	80.16	74.70	85.95	87.48	74.45	77.83	80.41
4	玉米	23	211	96.71	94.77	88.65	88.40	88.42	86.91	89.16	89.84	85.96	83.34	84.81	85.09
5	草地/牧草	49	448	91.33	91.16	94.30	93.39	90.59	96.00	90.36	92.22	93.28	94.10	93.10	94.87
6	草地/树木	74	673	97.58	97.29	97.73	97.12	95.95	97.65	94.46	93.91	96.89	98.17	94.70	97.66
7	草地/修剪牧草	2	24	96.00	96.00	96.67	98.00	94.00	90.86	94.77	77.14	100.00	90.86	92.72	92.72
8	干草堆	48	441	99.19	99.65	100.00	99.53	98.72	97.12	99.37	99.06	99.58	96.68	98.47	97.61
9	燕麦	2	18	91.86	90.91	84.13	82.64	62.50	64.17	60.00	69.06	92.50	78.10	73.33	85.00
10	非耕犁大豆	96	872	86.71	85.16	84.81	92.38	90.86	88.43	85.61	81.29	85.92	87.26	87.90	88.01
11	少耕犁大豆	246	2 222	90.20	89.66	89.86	92.71	93.31	90.58	89.98	91.26	91.07	91.12	90.84	91.17
12	清理过的大豆地	61	553	87.41	84.88	89.87	87.73	88.56	89.75	90.64	87.33	87.92	90.37	88.29	91.69
13	小麦	21	191	97.60	98.38	99.02	98.09	98.91	99.02	96.56	95.06	97.80	99.03	95.33	99.27
14	木材	129	1 165	95.68	95.16	95.54	95.38	95.51	96.11	94.94	94.69	96.01	95.70	95.02	95.25
15	建筑-草地- 树木-机器	38	342	78.86	76.70	79.91	76.90	81.96	80.25	73.00	72.94	73.72	76.05	71.63	75.17
16	石钢塔	9	86	97.60	98.81	97.33	79.76	89.88	82.55	89.37	80.79	78.90	97.94	93.46	97.94
OA/%				90.52	88.93	90.31	91.66	91.97	90.27	87.70	88.40	90.76	89.16	89.28	90.81
AA/%				91.57	90.85	91.65	88.97	89.63	87.41	87.66	86.62	90.62	87.47	88.02	90.35
Kappa 系数				0.892	0.874	0.889	0.905	0.908	0.889	0.859	0.868	0.895	0.876	0.878	0.895

3 结语

本文针对高光谱影像传统的逐像素分类中缺乏空间邻域信息的现象,探索了一种综合聚类和上下文特征的高光谱遥感影像分类方法。该方法综合聚类和上下文信息获取表征影像空间信息的图像对象,进而进行光谱-空间分类。对两组高光谱数据—ROSIS 和 AVIRI 的实验表明,该方法可有效降低噪声,提高分类精度。

需要指出的是,本文在利用隐马尔可夫随机场获取上下文信息时仅利用特征提取后的第一分量,有一定局限。此外,研究也发现进行分类结果优化时,窗口阈值选择对分类精度有一定影响,也会导致部分边缘像元的错分。为此,后续研究将进一步以隐马尔可夫随机场为驱动,探索综合聚类和上下文特征的高光谱影像光谱-空间分类方法。

致谢:感谢冰岛大学 Benediktsson 教授和 Ghamisi 博士对本文提出的宝贵意见。

参考文献

- [1] Tong Qingxi, Zhang Bin, Zheng Lanfen. Hyperspectral Remote Sensing: the Principle, Technology and Application [M]. Beijing: Higher Education Press, 2006(童庆禧, 张兵, 郑兰芬. 高光谱遥感: 原理、技术与应用[M]. 北京: 高等教育出版社, 2006)
- [2] Plaza A, Benediktsson J A, Boardman J W, et al. Recent Advances in Techniques for Hyperspectral Image Processing [J]. *Remote Sens Environ*, 2009, 113:S110-S122
- [3] Bioucas-Dias J M, Plaza A, Camps-Valls G, et al. Hyperspectral Remote Sensing Data Analysis and Future Challenges[J]. *IEEE Geoscience & Remote Sensing Magazine*, 2013, 1(2):6-36
- [4] Camps-Valls G, Tuia D, Bruzzone L, et al. Advances in Hyperspectral Image Classification [J]. *IEEE Signal Processing Magazine*, 2014, 31(1): 45-54
- [5] Pal M and Mather P M. Support Vector Machines for Classification in Remote Sensing[J]. *International Journal of Remote Sensing*, 2005, 26 (5): 1 007-1 011
- [6] Moser G, Serpico S B. Combining Support Vector Machines and Markov Random Fields in an Integrat-
- ed Framework for Contextual Image Classification [J]. *IEEE Transactions on Geoscience & Remote Sensing*, 2012, 50(5):1-19
- [7] 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
- [8] Plaza A, Martinez P, Perez R, et al. A New Approach to Mixed Pixel Classification of Hyperspectral Imagery based on Extended Morphological Profiles[J]. *Pattern Recognition*, 2004, 37(6):1 097-1 116
- [9] Borhani M, Ghassemian H. Hyperspectral Image Classification Based on Spectral-spatial Features Using Probabilistic SVM and Locally Weighted Markov Random Fields [C]. Intelligent Systems (ICIS), Iran, 2014
- [10] Tarabalka Y, Benediktsson J A, Chanussot J. Spectral-spatial Classification of Hyperspectral Imagery Based on Partitional Clustering Techniques [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(8):2 973-2 987
- [11] Liu Guoying, Mao Lifei, Wang Leiguang, et al. Texture Segmentation Based on a Hierarchical Markov Model in Wavelet Domain[J]. *Geomatics and Information Science of Wuhan University*, 2009, 34(5):531-534 (刘国英, 茅力非, 王雷光, 等. 基于小波域分层 Markov 模型的纹理分割[J]. 武汉大学学报·信息科学版, 2009, 34(5):531-534)
- [12] Elliott R J, Aggoun L, Moore J B. Hidden Markov Models: Estimation and Control Stochastic Modelling and Applied Probability [M]. NY: Springer, 2008
- [13] Ghamisi P, Benediktsson J A, Ulfarsson M O. Spectral-spatial Classification of Hyperspectral Images Based on Hidden Markov Random Fields[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(5): 2 565-2 574
- [14] Gonzalez R C, Woods R E. Digital Image Processing [M]. 2nd ed. Englewood Cliffs, NJ: Prentice-Hall, 2002
- [15] Eddy S R. ProfileHidden Markov Models[J]. *Boeing Informatics Review*, 1998, 14(9):755-763
- [16] Jain A K, Murty M N, Flynn P J. Data Clustering: A Review[J]. *ACM Comput Surv*, 1999, 31(3): 264-323

Classification Merged with Clustering and Context for Hyperspectral Imagery

BAO Rui^{1, 2, 3} XUE Zhaohui^{2, 3} ZHANG Xiangyuan¹ SU Hongjun⁴ DU Peijun^{2, 3}

1 Tianjin Institute of Geological Survey, Tianjin 300191, China

2 Key Laboratory for Satellite Mapping Technology and Applications of National Administration of Surveying, Mapping and Geoinformation of China, Nanjing University, Nanjing 210023, China

3 Jiangsu Provincial Key Laboratory of Geographic Information Science and Technology, Nanjing University, Nanjing 210023, China

4 School of Earth Sciences and Engineering, Hohai University, Nanjing 210098, China

Abstract: The traditional pixel-wised classification methods for hyperspectral image (HIS) only consider spectral information while ignoring the spatial information, resulting in a big limit of classification performance. Clustering which could assemble pixels similar in spectral features into spatial adjacent clusters, thus effectively express similarity and spatial correlation of adjacent pixels. In order to take full advantages of spatial correlation, this paper explore a spectral-spatial classification method for HSI merged with clustering and context. Firstly, under condition of different feature extraction (MNF, ICA and PCA), different clustering methods(k -means, ISODATA and FCM) are used in hidden markov random field to obtain optimized segmentation map containing context features ; secondly, the regions in the segmentation map are labeled by using a four-connected neighborhood labeling method to generate image objects, and a majority voting method is used to classify the objects based on the initial classification map derived from support vector machine (SVM) optimized by particle swarm optimization (PSO). Finally, a Chamfer neighborhood filtering technique is used to regularize the classification map, which partially reduces the noise. This method utilizing spatial information from clustering and introducing context features from HMRF takes advantage of supervised classification and unsupervised classification to gain noise reduction, high-accuracy and high homogeneity, which makes up for the inadequacy of the classification based only on spectral information. Experiment on ROSIS data set and AVIRIS data set respectively illustrate that the method can obtain better performance in terms of classification. The overall accuracy of ROSIS data set reaches to 98.53%, 5.01% higher than that obtained by SVM. Meanwhile the overall accuracy of AVIRIS data set climbs to 91.97%, 7.01% higher than SVM result. We also find that different feature extraction and different clustering will influence the spectral-spatial method using HMRF with edge-protection.

Key words: clustering; hidden Markov random field (HMRF); support vector machines (SVMs); hyperspectral imagery; spectral-spatial classification; majority voting

First author: BAO Rui, master, specializes in hyperspectral imagery. E-mail: baoruijiayou@163.com

Corresponding author: DU Peijun, PhD, professor. E-mail: dupjrs@126.com

Foundation support: The Jiangsu province Science Fund for Distinguished Young Scholars, No. BK2012018; the National Key Scientific Instrument and Equipment Development Project, No. 012YQ050250.