

基于分水岭的高光谱图像分类方法

舒 速, 杨 明, 赵振凯

(南京师范大学计算机科学与技术学院, 江苏 南京 210023)

[摘要] 近年来, 高光谱图像的分类受到了广泛的关注, 许多机器学习的方法都在高光谱图像上得到了应用, 如 SVM、神经网络、决策树等. 为了提高分类精度, 通常将图像的光谱信息与空间信息结合起来进行分类. 本文提出了如何利用分水岭分割得到的空间信息来得到更精确的分类结果. 首先利用分水岭得到图像区域信息, 然后根据一个区域中是否含有训练样本而采取不同的策略得到该区域中所有点的类别. 本文在两幅图像上分别用 SVM 和联合稀疏表示对该方法的有效性进行验证, 实验结果表明该方法优于其他一些同类方法.

[关键词] 分水岭, 高光谱, 图像分类

[中图分类号] TP751 [文献标志码] A [文章编号] 1001-4616(2015)01-0091-07

Hyperspectral Image Classification Method Based on Watershed

Shu Su, Yang Ming, Zhao Zhenkai

(School of Computer Science and Technology, Nanjing Normal University, Nanjing 210023, China)

Abstract: Hyperspectral image classification has attracted a great deal of attention. Many machine learning methods have been applied in hyperspectral image classification, such as SVM, neural network and decision tree, etc. In order to increase classification performances, people usually integrate of spatial information into the classification process. In this paper, we will present how to use spatial information obtained by watershed segmentation to obtain a more accurate classification results. We obtained the regional information by watershed segment and then adopted different strategies to get the category of the points in an area according to the area whether it contains the training sample. SVM and the joint sparse representation are used on two images to verify the effectiveness of the proposed method. Experimental results show that our algorithm outperforming some other similar methods.

Key words: watershed, hyperspectral, image classification

在高光谱图像中, 每一个像素点都记录了其详细的光谱信息, 其光谱范围是从可见光到红外光谱区域. 通常不同材质在特定的波段反映不同的电磁能量, 从而可以通过光谱的不同来区分不同的物质, 为分析不同材料的物理性质提供了宝贵的信息来源. 高光谱图像在军事监视、环境监测、矿物识别等领域得到了广泛的应用, 其中分类是高光谱图像分析的重要内容之一.

在最初的高光谱图像分类应用中, 都是利用某一个像素点的光谱信息将其划分为某一个类别, 如最大似然或 Bayesian 估计法^[1,2]、神经网络^[3]、决策树^[4]、基于核的方法, 典型的如 SVM^[5-7]. SVM 分类时可以解决高维数问题, 而且在只有少数训练集时, 其性能仍然较好, 但其参数的选择对分类的精度影响很大.

为了进一步提高分类精度, 通常的做法都是将空间信息与光谱信息结合起来进行分类. 可用形态滤波器^[8]和马尔可夫随机^[9]将空间信息融入到分类器中, 而且实验证明此类方法也确实可以提高分类的精度, 但这些方法几乎都是采用固定窗口大小的邻域, 这涉及到窗口大小如何选择, 特别是当图像包含一些小的或者复杂的结构时, 几乎不可能找出一个适合所有结构的窗口. 而在 SVM 中, 通常使用由空间信息和光谱信息形成的组合核^[10], 从而由于包含了空间信息而提高了分类精度.

图像分割是另一种获取空间信息的有力方法, 图像分割将得到大小不一的自适应空间邻域, 进行图像分割的方法有多种, 本文应用分水岭算法. 由于分水岭会产生过分割, 所以可以合理地假设分水岭得到一

收稿日期: 2014-09-30.

基金项目: 国家自然科学基金重点、面上 (61432008、61272222).

通讯联系人: 舒速, 硕士, 研究方向: 机器学习、模式识别. E-mail: shusu510@126.com

个小区域中的所有像素点应属于同一个类. Tarabalkat 等^[11]充分利用了该特性,使用分水岭得到高光谱图像的分割图,再使用 SVM 对高光谱图像进行分类,得到图像的分类图,最后将分割图与分类图结合起来,对分割图中的每个区域利用 SVM 分类结果对其进行投票,使该区域所有像素点被划分为该区域中大多数像素点所属的类别.

以上投票法中,在进行投票时,区域中的所有样本都是同等对待.而实际上,训练样本的标记十分准确.所以,我们根据一个区域中是否有训练样本而采用不同的策略得到该区域所有样本的标记信息.

本文接下来的安排如下:第一部分介绍高光谱图像的分水岭分割,第二部分介绍如何得到最终的分类结果,第三部分是实验结果分析与比较,第四部分是对本文工作的总结及对将来工作的展望.

1 分水岭分割

分水岭转换是基于数学形态学的技术,是图像分割的有力工具.分水岭转换根据二维单值图像中的每个点的值将一幅图分为若干个积水盆地,每个积水盆地都跟图像的一个极小值有关.图1给出了一个单波段图像上的地形表示^[11].

分水岭转换通常运用在一幅图像的梯度图像上,得到的每个区域的梯度变化都不明显,这样可以将图像分为有意义的区域,分水岭线代表物体的边缘.

很多文献都描述了如何计算图像的分水岭变换^[12-15].本文采用 Vincent 和 Soille 提出的经典方法^[12]—浸没法.分水岭变换得到的结果是将原图分割成小块的区域(与同一个局部极小值连在一起的点集)和山脊线(小块区域间的边界),图2展示了一维数据上分水岭转换的一个例子^[11].图中包含了局部极小值和其对应的区域,两个最大值代表区域间的边界.

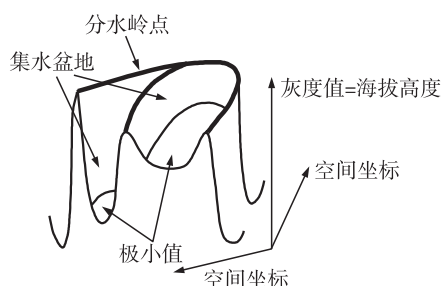


图1 单波段图像的分水岭

Fig. 1 Topographic representation of a one-band image

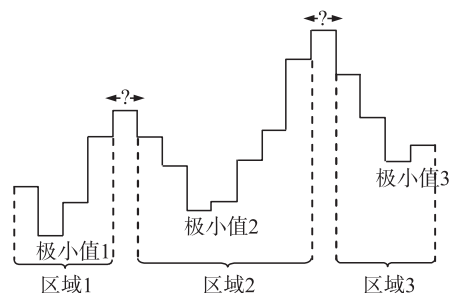


图2 一维数据上的分水岭转换

Fig. 2 Example of watershed transformation in dimension

如前所述,分水岭转换一般应用于图像的梯度图像,要求输入为单波段图像,得到的也是对应于一个波段上的分割图.但高光谱图像含有 B 个波段,为了解决这个问题,文[11]中阐述了多种如何得到高光谱图像的分水岭分割的方法,主要是通过不同的方法得到图像的梯度图像.本文主要使用文[11]中的两种方法:RCMG 和多维梯度(SumBands).

2 分类方法

2.1 将分水岭的边界划分到一区域中

分水岭得到的结果包含区域和边界(分水岭点),本文采用文[11]中的方法将边界点也划分到其中的一个区域中,首先对每个区域求出其中值向量

$$S_{VM} = \operatorname{argmin}_{s \in S} \left\{ \sum_{j=1}^l \|s - s_j\|_1 \right\}, \quad (1)$$

求出分水岭点与相邻区域的中值向量的距离,将分水岭点划到距离最小的那个区域中.得到分水岭的分割图之后,下文将描述如何应用分水岭分割的结果来提高分类精度.

2.2 分水岭与分类方法的结合

分水岭分割是对梯度图像进行分割,而且会产生过分割,所以它得到的一区域中的梯度变化是非常小的,可以合理地假设分水岭分割中一个区域的所有样本都属于同一类,本文利用该特性及已标记样本的标签很准确的特点来提高分类精度.本文采用两种分类方法:SVM 和联合稀疏表示.

2.2.1 分水岭与 SVM 的结合

得到分割图和 SVM 的分类图之后,利用分水岭分割中一个区域的所有样本都属于同一类的特性.文[11]用投票法把分割结果与分类结合起来,即根据分水岭分割所得的结果,计算出一个区域中的点对应于 SVM 的分类结果,大多数像素点属于哪个类,则该区域中的所有点都属于该类.但在此投票过程中,已标记样本的标签和通过 SVM 得到的样本标签都是同等对待.而实际上已标记样本的标签的准确率是 100%,而 SVM 得出的标签有一定的错误率.所以,当一个区域中存在已标记样本时,应该让已标记样本的标签对该区域的所有样本标签的预测起主导作用.

所以,本文的基本思想是,首先判断一个区域中是否有已标记的样本,如有且所有已标记样本的标记都相同,那么将该区域的所有样本都标记为已标记样本的类别.否则利用 SVM 在该区域的分类结果进行投票,使该区域的所有样本为大多数样本的类别.

Pre_classification+SVM+Majority 算法的流程如下:

步骤 1 首先利用分水岭得到相应的分割图,对分界进行区域的指定,得到最终的分割结果.

步骤 2 判断每个区域是否有已标记样本且标记的类别唯一,若满足条件则将该区域所有样本都标记为已标记样本的类别.

步骤 3 利用 SVM 将剩下的未标记样本进行分类,从而得到所有样本的标记.

步骤 4 利用步骤 1 得到的分割图和步骤 3 得到的分类图,对每个分割区域进行投票,得到最终的结果.

图 3 给出了分类过程的一个具体例子.

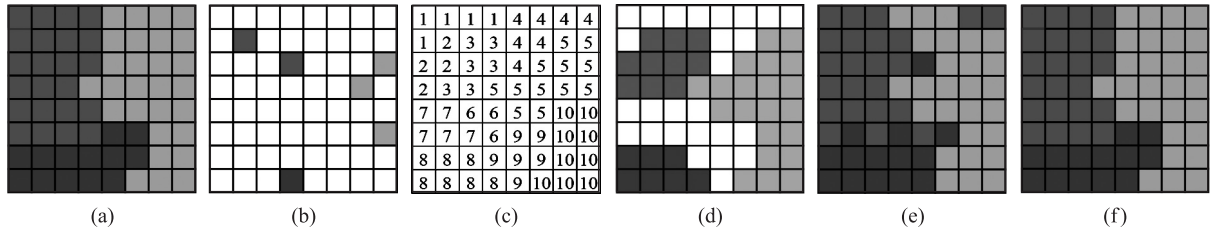


图 3 分类过程

(a) 图像的真实类别,共 3 类;(b) 随机抽取的已标记样本;(c) 图像的分割结果,共 10 个区域;(d) 通过 (b) 和 (c),执行步骤 2 之后的结果;(e) 步骤 3 的结果;(f) 步骤 4 的结果

Fig. 3 The process of classification

(a) the true classification include 3 classes; (b) the labeled instances which are randomly selected; (c) the segmentation results include 10 regions; (d) the result of step 2; (e) the result of step 3; (f) the result of step 4

2.2.2 分水岭与联合稀疏表示相结合

联合稀疏表示^[16]的主要思想是,在一个小的空间邻域内的点,应该由字典中的相同元子来表示,只是系数不同,下面简单介绍一下联合稀疏分类的原理.

对于一个给定的字典 $A \in \mathbf{R}^{B \times N}$,考虑由相同物质组成的包含 M 个点的邻域,该邻域用 $B \times M$ 的矩阵 $X = [x_1, x_2, \dots, x_M]$ 表示,其用字典可表示如下:

$$X = [x_1, x_2, \dots, x_M] = [A\beta_1, A\beta_2, \dots, A\beta_M] = A[\beta_1, \beta_2, \dots, \beta_M] = AS, \quad (2)$$

那么向量 $\{\beta_t\}_{t=1,2,\dots,T}$ 中不为零的元素的下标应相同.

从而得到联合稀疏表示的模型

$$S' = \operatorname{argmin} \|AS - X\|_F + z * \|S\|_{\text{row},0}, \quad (3)$$

其中 z 是正则化参数,用于平衡重构误差和稀疏程度.由于零范数是非凸的,为了便于求解将(3)简化为:

$$S' = \operatorname{argmin} \|AS - X\|_F + z * \|S\|_{2,1}. \quad (4)$$

文[16]中的 X 是以某点为中心的方窗内的所有点,每个点的邻域大小都一样,即 X 中样本的个数需事先确定.由于图像中可能包含各种大小不一的结构,只使用统一大小的方窗,无法得到更准确的邻域信息.所以,为了得到自适应邻域,本文使用分水岭的一个区域作为一个相应的邻域, X 是由分水岭中一个区域的所有点构成.本文用刘俊的稀疏包来求得(4)的解.得到解 S' 后,计算每个类对应的残差

$$r^m(X) = \|X - A^m S'^m\|_F \quad m = 1, 2, \dots, M, \quad (5)$$

其中 S'^m 表示第 m 类子字典 A^m 相对应的系数. 将该区域内的所有点标记为残差最小的类

$$\text{class}(X) = \underset{m=1, \dots, M}{\operatorname{argmin}} r^m(X). \quad (6)$$

分水岭 (SumBands、Sum4PCA、RCMG) + JSR 算法的流程如下:

步骤 1 首先利用分水岭得到相应的分割图,对边界进行区域的指定,得到最终的分割结果.

步骤 2 判断每个区域是否有已标记样本且标记的类别唯一,是则进行步骤 3,否则进行步骤 4.

步骤 3 将该区域所有样本都标记为已标记样本的类别.

步骤 4 对该区域的样本利用公式 (4) 求出联合稀疏解,利用公式 (5) 求出所有点对应于每类的残差,利用公式 (6) 将该区域的所有点分类.

本方法与文 [16] 的不同在于采用了更合理的邻域进行联合稀疏表示,而且文 [16] 中,是对每个点求一个联合稀疏表示,然后一次只对一个点进行分类,而本文中经过步骤 3 之后,只剩下很少的一部分点需要分类,且每次对一个区域所有点求一个联合稀疏系数,对所有点进行一次分类,相比文 [16] 大大地减少了运行时间.

3 实验结果与分析

为了验证所提出的方法的有效性,我们分别在两个数据集上进行了实验. 在使用 SVM 的实验中分别与文 [11] 中的方法进行对比,同时与使用组合核的 SVM 作比较 (定义为 SVM-CK)^[10],其中 SVM 的参数 γ_1 和 C 、组合核中的 μ 都是通过交叉验证得到 ($C = 1.024$, $\gamma = 2^{-7}$). 联合稀疏表示中的参数 $z = 0.03$,与文 [16] 中用到的方法 (SP, OMP, SSP, SOMP) 作比较.

3.1 AVIRIS Data Set; Indian Pines 上的实验结果与分析

3.1.1 数据集: AVIRIS Data Set; Indian Pines

该图像是由 AVIRIS 遥感设备拍摄的印第安纳州西北部的印度松树测试地,由 145×145 个像素点构成,空间分辨率为 20 m 每像素,包含 220 个波段,移除 20 个吸水带波段后,本文使用剩下的 200 个波段进行实验. 一共包含 16 个类,并从每个类中随机抽取 10% 的样本作为训练,其他作为测试样本. 表 1 中列出了每个类别的名称及对应类的样本数量.

表 1 Indian Pines 中样本类别及数目
Table 1 Class information of Indian Pines

class	sample	class	sample	class	sample
1—Alfalfa	46	7—Grass-pasture-mowed	28	13—Wheat	205
2—Corn-notill	1 428	8—Hay-windrowed	478	14—Woods	1 265
3—Corn-mintill	830	9—Oats	20	15—Bldg-Grass-Tree-Drives	386
4—Corn	237	10—Soybean-notill	972	16—Stone-Steel-Towers	93
5—Grass-pasture	483	11—Soybean-mintill	2 455		
6—Grass-trees	730	12—Soybean-clean	593		

3.1.2 实验结果与分析

在本数据上按文 [11] 中的方法计算 3 种梯度: SumBands、Sum4PCA、RCMG,所有参数跟文 [11] 保持一致.

得出分割结果之后,SumBands、Sum4PCA 和 RCMG 所对应的区域数分别为 1 205、1 240 和 1 247. 本文使用以下 3 种评价准则:

(1) OA, 总体精度,即所有分类正确的样本数与总样本数的比值.

(2) AA, 平均精度,所有类精度的平均值.

(3) Kappa 系数,更好地检测分类结果的正确性.

图 4 列出了 Indian Pines 的地表真实情况和一些分类方法所得的结果. 其中 (a) 代表图像真实的地面情况, (b) ~ (d) 分别是不同方法所得到的分类结果. (b) 中由于没有结合空间信息,只靠光谱信息进行分类,其得到的分类效果比较差. (c) 为文 [11] 中的方法,由于结合了空间信息,大大地改善了分类性能. 但我们仍然可以看到图中左下角的两个区域几乎没有得到什么改善,其主要原因是 SVM 将该区域的大多数样本都进行了错分. 而在 (d) 中采用本文的方法可以明显看到左下角的两个区域分类效果比 (c) 好.

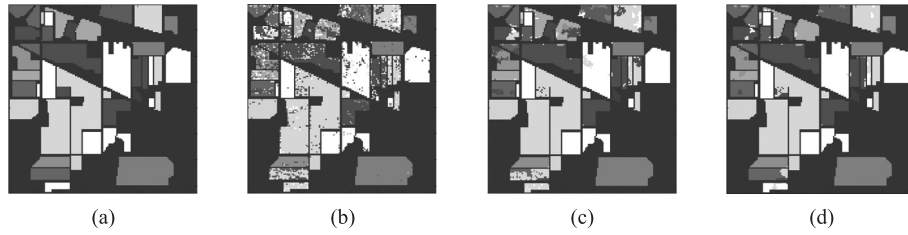


图 4 Indian Pines

(a) 图像真实的类别; (b) SVM 的分类结果图; (c) 利用投票法将 SumBands 分割与 SVM 分类结合起来得到的分类结果图; (d) 利用本文的方法将 SumBands 分割与 SVM 分类结合起来得到的分类结果图

Fig. 4 Indian Pines

(a) Ground truth; (b) Classification map for the SVM classification; (c) Classification map for SumBands + SVM + Majority; (d) Classification map for pre-classification + SVM + Majority

表 2 显示了在 Indian Pines 上使用分水岭与 SVM 结合及一些对比方法的实验结果精度,表 2 中,后 3 列表示本文方法的结果,本文方法相较于其他方法,分类精度都有明显的提高. 表 3 显示了在 Indian Pines 上用分水岭与联合稀疏表示结合及一些对比方法所得到的实验结果精度,该方法与 SOMP 和 SSP 相比,分类精度有一定的提高. 而相较于其他方法,分类精度有明显的提高.

由图 4 中的(a)可以看到,此图像包含大块的区域结构,区域性很强. 因此 SOMP 和 SSP 使用方窗邻域也可以得到较好的分类效果.

表 2 SVM 与分水岭结合的方法及对比方法在 Indian Pines 测试数据集上的分类精度

class	SVM	SVM-CK	SVM+Majority			Pre_classification+SVM+Majority (ours)		
			SumBands	Sum4PCA	RCMG	SumBands	Sum4PCA	RCMG
1	58.54	95.83	97.56	97.56	97.56	97.56	97.56	97.56
2	74.47	96.67	88.40	86.85	84.59	92.76	92.37	91.44
3	54.35	90.93	61.18	58.37	60.64	88.09	91.70	89.69
4	40.85	85.71	68.08	68.54	73.24	93.43	95.77	92.96
5	91.62	93.74	96.78	96.55	96.78	97.93	97.70	96.78
6	96.50	97.32	100	100	100	99.85	100	99.39
7	64.00	69.57	100	100	100	100	100	100
8	96.98	98.41	100	98.14	100	100	98.14	100
9	16.67	55.56	0	0	16.67	77.78	77.78	44.44
10	65.60	93.80	76.69	75.43	76.34	92.57	90.29	91.77
11	85.20	94.37	94.21	93.80	95.20	98.87	98.42	99.05
12	53.93	93.66	79.03	83.71	77.90	93.26	95.69	94.38
13	92.39	99.47	99.46	98.37	97.83	99.46	98.37	97.83
14	96.66	99.14	97.98	98.42	97.72	99.65	99.91	99.65
15	55.04	87.43	77.81	70.03	70.89	93.08	94.24	96.54
16	92.68	100	100	100	100	100	100	100
OA	78.33	94.86	88.23	87.50	87.63	96.03	96.11	95.94
AA	70.09	90.73	83.57	82.68	84.09	95.27	95.50	93.22
Kappa	75.07	94.10	86.46	85.60	85.76	95.46	95.55	95.36

3.2 The University of Pavia(PU)上的实验结果与分析

3.2.1 数据集:PU

此图像是用 ROSIS-03 设备拍摄的是帕维亚大学,图像由 610×340 个像素点构成,空间分辨率为 1.3 m 每像素. 共 115 个波段,波长范围为 $0.43 \mu\text{m} \sim 0.86 \mu\text{m}$. 去除 13 个噪声波段,本文的实验在剩下的 103 个波段上进行.

3.2.2 实验结果与分析

用 Sumbands、Sum4PCA 和 RCMG 所得到的区域数分别为 10 558、10 639 和 11 905. 表 4 列出了关于该图的类别和每类的样本数及实验中所用的训练样本数和测试样本数. 图 5 表示图像真实的地面情况. 表 5 显示在 PU 上使用分水岭与 SVM 结合及一些对比方法的实验结果精度,表 6 显示在 PU 上用分水岭与联合稀疏表示结合及一些对比方法所得到的实验结果精度. 由表 5 可知,本文的方法与其他的 SVM 方法相比精度有一定的提升. 从表 6 可以得出,本文的方法相较于 SOMP 和 SSP 在精度上有明显的提高. 从图 5

中可以观察到,此图包含了许多大小不等的区域和一些小而复杂的区域结构,而 SOMP 和 SSP 只用固定大小的方窗来寻求空间区域信息,很难找到一个适当的方窗尺寸,而且统一大小的方窗也不能代表图中的所有区域大小.而本文的方法则使用自适应的区域大小,所以本文方法所得到的结果更好.

表 3 分水岭与稀疏结合的方法及对比方法在 Indian Pines 的测试数据集上的分类精度

Table 3 Classificaion accuracy in percentage of sparse based on watershed and other classifications for Indian Pines								%
class	SVM-CK	SP	OMP	SSP	SOMP	SumBands+JSR	Sum4PCA+JSR	RCMG+JSR
1	95.83	68.75	68.75	89.58	85.42	97.56	97.56	97.56
2	96.67	74.65	65.97	95.04	94.88	91.67	92.37	91.67
3	90.93	63.20	60.67	92.93	94.93	92.24	91.43	92.50
4	85.71	40.00	38.57	85.24	91.43	96.24	95.77	96.71
5	93.74	89.04	89.49	92.17	89.49	97.70	97.70	94.94
6	97.32	95.98	95.24	98.81	98.51	99.54	100	99.70
7	69.57	21.74	21.74	73.91	91.30	100	100	100
8	98.41	99.09	97.05	99.55	99.55	100	100	100
9	55.56	61.11	33.33	0	0	77.78	77.78	33.33
10	93.80	70.72	68.20	88.98	89.44	95.66	94.86	92.23
11	94.37	77.94	75.96	97.34	97.34	99.37	98.87	98.96
12	93.66	61.23	54.53	86.59	88.22	85.96	98.31	85.39
13	99.47	100	100	99.47	100	99.46	98.37	98.91
14	99.14	95.62	92.87	98.88	99.14	99.65	99.65	99.65
15	87.43	48.25	41.23	97.37	99.12	88.76	90.20	94.81
16	100	92.94	94.12	85.88	96.47	100	100	100
OA	94.86	78.10	74.78	94.79	95.28	96.07	96.68	95.66
AA	90.73	72.52	68.61	86.36	88.45	95.10	95.81	92.27
Kappa	94.10	74.90	71.20	94.00	94.60	95.52	96.21	95.05

表 4 PU 的类别及样本数

Table 4 Class informations and number of train and test samples in PU		
class	train	test
1—Asphalt	548	6 083
2—Meadows	540	18 109
3—Gravel	392	1 707
4—Trees	524	2 540
5—Painted metal sheets	265	1 089
6—Bare Soil	532	4 677
7—Bitumen	375	955
8—Self-Blocking Bricks	514	3 166
9—Shadows	231	716

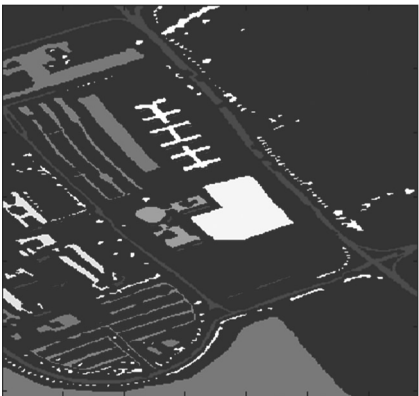


图 5 PU 的地表类别
Fig.5 Groundtruth of PU

表 5 SVM 与分水岭结合的方法及对比方法在 PU 的测试数据集上的分类精度

Table 5 Classification accuracy in percentage of SVM based on watershed and other classifications for PU								%
class	SVM	SVM-CK	SVM+Majority			Pre_classification+SVM+Majority (ours)		
			SumBands	Sum4PCA	RCMG	SumBands	Sum4PCA	RCMG
1	85.80	79.85	95.79	95.15	95.96	97.35	97.40	97.17
2	88.40	84.86	94.51	94.34	94.65	96.06	96.44	96.18
3	75.16	81.87	86.64	87.23	83.95	98.18	98.30	97.36
4	97.24	96.36	98.62	98.50	98.43	99.13	99.17	98.74
5	100	99.37	100	100	100	100	99.81	99.91
6	87.21	93.55	98.29	98.42	98.38	99.40	99.67	99.60
7	91.10	90.21	99.90	100	98.64	99.90	100	98.64
8	86.74	92.81	98.90	99.18	98.71	99.40	99.21	99.37
9	99.44	95.35	98.74	98.60	98.74	98.74	98.60	98.74
OA	88.31	87.18	95.79	95.67	95.71	97.47	97.67	97.42
AA	90.12	90.47	96.82	96.83	96.38	98.69	98.74	98.41
Kappa	84.33	83.30	94.30	94.14	94.20	96.57	96.84	96.50

表 6 分水岭与稀疏结合的方法及对比方法在 PU 的测试数据集上的分类精度

class	SVM-CK	SP	OMP	SSP	SOMP	SumBands+JSR	Sum4PCA+JSR	RCMG+JSR
1	79.85	69.70	68.07	69.59	59.33	97.99	98.39	97.83
2	84.86	67.69	67.07	72.31	78.15	97.54	97.44	97.19
3	81.87	67.11	65.45	74.10	83.53	98.48	98.71	97.60
4	96.36	97.46	97.32	95.33	96.91	99.57	99.65	99.53
5	99.37	99.82	99.73	99.73	99.46	100	99.81	99.91
6	93.55	75.79	73.29	86.72	77.41	99.49	99.38	99.67
7	90.21	88.79	87.26	90.32	98.57	99.69	99.79	98.43
8	92.81	84.96	81.90	90.46	89.09	98.55	97.95	98.55
9	95.35	93.58	94.72	90.94	91.95	98.88	98.74	98.88
OA	87.18	74.45	73.27	78.39	79.00	98.24	98.20	98.00
AA	90.47	82.77	81.65	85.50	86.04	98.91	98.87	98.62
Kappa	83.30	67.50	66.10	72.40	0.728	97.60	97.55	97.28

4 结语

本文根据高光谱图像的特点,针对传统的分类方法只考虑了光谱信息,而没有考虑空间信息这一现象,提出了利用分水岭分割获得空间信息,并利用该信息来提高分类精度的方法,使得分类精度有了大大的提高。但本文的分类精度与分水岭分割的结果关系密切,所以可以考虑改善分水岭分割的结果,从而得到更精确的分类结果。

[参考文献]

- [1] Chen C H, Peter Ho P G. Statistical pattern recognition in remote sensing[J]. Pattern Recognition, 2008, 41(9): 2 731-2 741.
- [2] Bali N, Mohammad-Djafari A. Bayesian approach with hidden Markov modeling and mean field approximation for hyperspectral data analysis[J]. IEEE Trans on Image Process, 2008, 17(2): 217-225.
- [3] Hernández-Espinosa C, Fernández-Redondo M, Torres-Sospedra J. Some experiments with ensembles of neural networks for classification of hyperspectral images[J]. ISNN, 2004(1): 912-917.
- [4] Zhou H, Mao Z, Wang D. Classification of coastal areas by airborne hyperspectral image[J]. Proceedings of SPIE, 2005, 5 832: 471-476.
- [5] Pal M, Mather M. Support vector machines for classification in remote sensing[J]. Int J Remote Sens, 2005, 26(5): 1 007-1 011.
- [6] Heikkinen V, Tokola T, Parkkinen J, et al. Simulated multispectral imagery for tree species classification using support vector machines[J]. IEEE Trans on Geosci Remote Sens, 2010, 48(3): 1 355-1 364.
- [7] Giorgos M, Jungho I, Caesar O. Support vector machines in remote sensing: A review[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2011, 66: 247-259.
- [8] Fauvel M. Spectral and spatial methods for the classification of urban remote sensing data[D]. Reykjavik, Iceland: France and Faculty of Electrical and Computer Engineering, University of Iceland, 2007.
- [9] Farag A, Mohamed R, El-Baz A. A unified framework for map estimation in remote sensing image segmentation[J]. IEEE Trans on Geosci Remote Sens, 2005, 43(7): 1 617-1 634.
- [10] Camps-Valls G, Gomez-Chova L, Muñoz-Marí J, et al. Composite kernels for hyperspectral image classification[J]. IEEE Geosci Remote Sens Lett, 2006, 3(1): 93-97.
- [11] Tarabalka Y, Chanussot J, Benediktsson J A. Segmentation and classification of hyperspectral images using watershed transformation[J]. Pattern Recognition, 2010, 43(2): 2 367-2 379.
- [12] Vincent L, Soille P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations[J]. IEEE Trans Pattern Anal Mach Intell, 1991, 13(6): 583-598.
- [13] Meyer F. Topographic distance and watershed lines[J]. Signal Process, 1994, 38(1): 113-125.
- [14] Stoev S. Rafsi—a fast watershed algorithm based on rainfallo simulation[C]//Proceedings of the Eighth International Conference on Computer Graphics, Visualization, and Interactive Digital Media. Plzen, Czech Republic: WSCG, 2000.
- [15] Osma-Ruiz V, Godino-Llorente J I, Saénz-Lechoñ N, et al. An improved watershed algorithm based on efficient computation of shortest paths[J]. Pattern Recognition, 2007, 40(3): 1 078-1 090.
- [16] Chen Y, Nasrabadi N M, Trac D, et al. Hyperspectral image classification using dictionary-based sparse representation[J]. IEEE Trans on Geosci Remote Sens, 2011, 49(10): 3 973-3 985.

[责任编辑:黄 敏]