

# 基于分水岭分割和稀疏表示的高光谱图像分类方法

舒 速 杨 明

(南京师范大学计算机科学与技术学院 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。但光谱图像可能存在“同物异谱”和“同谱异物”的情况,这给高光谱图像的精确分类带来了一定挑战。针对该问题,提出了利用分水岭分割得到的空间信息与稀疏表示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,然后以区域为单位,对每个区域的样本进行分类。在两幅图像上对该方法的有效性进行了验证,结果表明该方法优于其它一些同类方法。

**关键词** 高光谱图像,稀疏表示,分类,分水岭

**中图分类号** TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.2.020

## Hyperspectral Image Classification Method Based on Watershed Segmentation and Sparse Representation

SHU Su YANG Ming

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

**Abstract** In recent years, the classification has attracted wide attention. Many machine learning methods have been applied in hyperspectral image classification, such as SVM, neural network and decision tree. But in the hyperspectral image, different materials may have the same spectra and the same material in different locations may have different spectra, consequently bringing a challenge for accurate classification of hyperspectral image. So, we made use of the spatial information extracted from the watershed segmentation and the sparse representation to get a more accurate classification results. Firstly, we extracted regional information from hyperspectral image by watershed segmentation, then classified all the samples in a region once. The effectiveness of our proposed method was evaluated via two images. And the results show that it exhibits state-of-the-art performance.

**Keywords** Hyperspectral image, Sparse representation, Classification, Watershed

在获取高光谱图像时,成像光谱技术将反映物质本质的光谱信息与反映物质所处空间格局的空间信息完美地结合起来,达到了谱像合一的目的,即对图片空间中的每个像元都赋予具有本身特点的光谱信息。成像光谱仪可以在电磁波谱的紫外、可见光、近红外和中红外区域中,获取许多非常窄且光谱连续的图像数据。它可以为图像中的每个像元提供数十到数百个波段<sup>[1-3]</sup>。通常不同材质会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,光谱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。

最初人们对高光谱图像进行分类时,只根据高光谱图像中每个像素的光谱信息将其划分为某个已知的类别<sup>[4]</sup>,常见的方法有:K 邻近法(K-Nearest Neighbor)<sup>[5]</sup>、决策树法(Decision Tree Classifier)<sup>[6,7]</sup>、贝叶斯分类法(Bayesian Classifier)<sup>[8-10]</sup>、神经网络<sup>[11-13]</sup>和 SVM 分类<sup>[14-17]</sup>。SVM 一般都是基于核的,在数据维数高、训练样本有限的情况下,SVM 和其它一些基于核的分类方法<sup>[18-20]</sup>仍能保持较好的性能,但其参数

的选择对分类的精度影响很大。

随着高光谱遥感技术的发展,对高光谱遥感图像分类精度的要求也越来越高。为了克服只使用光谱信息时出现的类别不确定现象、椒盐现象,或者是图像本身存在的“同物异谱”和“异物同谱”<sup>[21]</sup>现象,学者们在分类时同时考虑了光谱信息和空间信息,大大提高了高光谱图像的分类度。

早期 Landgrebe 和 Kettig 提出了利用光谱和空间信息的 ECHO 分类方法<sup>[22]</sup>,MRF 模型在遥感图像的分类上也体现了很好的性能<sup>[23,24]</sup>。近年来稀疏表示在图像分类方面得到了很好的应用,展示出良好的前景,因此,学者们纷纷将稀疏表示与高光谱图像的空间相结合来对高光谱图像分类,以期得到更好的分类效果<sup>[25-29]</sup>。但以上方法大多使用固定窗邻域,这涉及到窗口大小应如何选择,尤其当图像中包含许多大小不一或者复杂的区域结构时,我们不可能选择出一个适合图像中所有结构的窗口。分水岭分割是一个很好的分割算法,它可以得到图像中各点的自适应邻域,因此不存在使用固定窗邻域时的问题。分水岭分割会产生过分割现象,但它是对图像的梯度图像进行分割,所以其得到的分割结果中,一个

到稿日期:2015-03-27 返修日期:2015-05-20 本文受国家自然科学基金(61272222, 61003116),江苏省自然科学基金(BK2011782, BK2011005)资助。

舒 速(1987-),女,硕士,主要研究方向为机器学习、模式识别,E-mail:shusu510@126.com;杨 明(1964-),男,博士,教授,博士生导师,主要研究方向为数据挖掘、机器学习、模式识别,E-mail:05354@njnu.edu.cn。

区域中的梯度变化非常小。因此,可以合理地认为一个区域中的所有点属于同一个类别。Tarabalkat 等<sup>[30]</sup>充分利用了该特性,使用分水岭分割的结果对 SVM 得到的分类结果进行后处理,取得了很好的分类结果。本文也将分水岭分割与稀疏表示相结合,根据一个区域中是否存在类别已知的样本而采用不同的策略对该区域的所有点进行分类。

本文第 1 节介绍高光谱图像的分水岭分割;第 2 节介绍如何利用分水岭分割与稀疏表示对图像进行分类;第 3 节介绍实验结果与分析;最后对本文工作进行总结并对将来工作进行展望。

## 1 分水岭分割

分水岭分割是数学形态学的分割方法,是图像分割的有力工具。分水岭变换的思想来源于地形学,考虑的是二维单值图像的地理起伏状态,图像中每个像素点的值对应该点的海拔高度<sup>[30]</sup>。在一幅图像中,每一个局部极小值点及其影响区域为该极小值的集水盆地,将每个集水盆地分开的分界线作为分水岭线<sup>[31]</sup>。图 1 给出了一幅单值图像的地形。




图 1 单值图像的地形

分割的目的是将图像分成各具特色的区域,即提取出图像中物体的边缘,由于图像的梯度描述了图像的灰度变化,且边缘的灰度变化很大,因此通常先求出图像的梯度图像,再在梯度图像上进行分水岭分割。如此得到的每个区域的梯度变化都不明显,而且分水岭会产生过分割现象,这样可以合理地假设分水岭分割得到的一个区域中的所有点都属于同一个类别。




图 2 一维数据上的分水岭转换

许多学者对如何得到图像的分水岭变换进行了深入的研究<sup>[32-35]</sup>。本文采用 Vincent 和 Soille 提出的经典方法<sup>[32]</sup>,即浸没法。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)和分水岭线(小块区域间的边界),图 2 展示了一维数据上分水岭变换的一个例子。图中包含了局部极小值和其对应的区域。最大值代表区域间的边界。

上文所述为在标准的单波段图像上的分水岭转换,本文所研究的高光谱图像具有多个光谱段,每个像素点不再只是对应一个简单的数字,而是一个光谱向量。设一幅高光谱图像中含有  $b$  个波段,那么图像中的任意一点  $x = [x_1, x_2, \dots, x_b]^T$ 。此时,对于这样的图像,求其分水岭转换需要解决的最根本问题就是如何求得其梯度图像。文献<sup>[30]</sup>提出了多种求高光谱图像的梯度图像的方法,本文主要采用其中的两种方法:RCMG 和多维梯度(SumBands)。

## 2 基于分水岭分割与稀疏表示的分类

### 2.1 将分水岭的边界点划分到某个区域

分水岭分割中得到的分水岭边界点不属于任何一个区域,为了使图中的每个点都属于一个确定的区域,本文仍然采用文献<sup>[30]</sup>中的方法,将边界点划分到与其相邻的某个区域中。设某一个区域中包含  $g$  个点, $g$  个点组成集合  $S = \{s_1, s_2, \dots, s_g\}$ ,按照式(1)求出该区域的中值向量  $S_{vm}$ 。

$$S_{vm} = \arg \min_{s \in S} \left\{ \sum_{j=1}^g \|s - s_j\|_1 \right\} \quad (1)$$

对每个区域都按式(1)求得其中值向量,对任一边界点求出它与自己相邻区域的中值向量间的距离,将边界点划分到距离最小的中值向量所属的区域。

### 2.2 稀疏表示基本理论

文献<sup>[27]</sup>对稀疏表示的基本理论作出了详细的介绍,稀疏表示的基本假设是:属于同一类别的点应该可以由类别相同的其它点来近似表示。假设共  $H$  个类,第  $h$  类有  $N_h$  个训练样本,该类的训练样本组成了该类的子字典  $A^h = [a_1^h, a_2^h, \dots, a_{N_h}^h] \in R^{b \times N_h}$ ,其中  $a_j^h \in R^b, j=1, 2, \dots, N_h$  表示第  $h$  类的一个训练样本。那么如果高光谱图像中的某一个点  $x = [x_1, x_2, \dots, x_b]^T \in R^b$  属于第  $h$  类,则  $x$  应该可以由  $A^h$  中的点近似表示。

$$\begin{aligned} x &\approx \beta_1^h a_1^h + \beta_2^h a_2^h + \dots + \beta_{N_h}^h a_{N_h}^h \\ &= [a_1^h, a_2^h, \dots, a_{N_h}^h] [\beta_1^h, \beta_2^h, \dots, \beta_{N_h}^h]^T \\ &= A^h \beta^h \end{aligned} \quad (2)$$

其中,  $\beta^h \in R^{N_h}$  是未知的系数向量,其中的元素  $\beta_j^h (j=1, 2, \dots, N_h)$  表示子字典中的原子  $a_j^h$  在近似表示  $x$  时的权重。在稀疏表示模型中  $\beta^h$  是稀疏向量,只有少数的元素不为零。

我们将  $H$  个类的子字典组合在一起形成字典  $A = [A^1, A^2, \dots, A^H] \in R^{b \times N}$ ,其中  $N = \sum_{j=1}^H N_j$ ,根据以上理论,一个类别未知的样本  $x$  可以表示如下:

$$\begin{aligned} x &= A^1 \beta^1 + A^2 \beta^2 + \dots + A^H \beta^H \\ &= [A^1, A^2, \dots, A^H] [\beta^1, \beta^2, \dots, \beta^H]^T \\ &= A \beta \end{aligned} \quad (3)$$

如果  $x$  属于第  $h$  类,那么理想情况下  $\beta^j = 0, j=1, 2, \dots, H, j \neq h$ ,所以使用字典对图像中的任一点进行表示时,其所对应的系数向量  $\beta$  中都只有极少数的元素不为零。稀疏表示的目的就是得到稀疏的系数向量  $\beta$ 。可以通过求解以下模型求得所需要的系数向量  $\beta$ 。

$$\beta = \arg \min \|A\beta - x\|_2 + \lambda \|\beta\|_1 \quad (4)$$

式中的第一项表示重构误差,第二项表示  $\beta$  的稀疏程度,  $\lambda$  用于平衡误差与稀疏程度。

利用式(4)求出系数向量之后,  $x$  的类别可以直接由系数向量得出。定义第  $h$  类对应的残差如下:

$$r^h(x) = \|A^h \beta^h - x\|_2, h=1, 2, \dots, H \quad (5)$$

其值表示用第  $h$  类的训练样本表示  $x$  时的重构误差, 应将  $x$  划分到残差最小的类别中, 即:

$$\text{class}(x) = \arg \min_{h=1, 2, \dots, H} r^h(x) \quad (6)$$

### 2.3 基于分水岭和稀疏表示的分类

以上的稀疏表示是对图像的某个点求出其稀疏系数, 然后利用求得的系数对该点进行分类。但在高光谱图像中, 由于存在“同物异谱”和“异物同谱”的现象, 使得只使用光谱信息的分类方法存在较多错分。为了提高分类精度, 需要在分类时考虑图像中含有的空间信息。本文利用分水岭分割得到图像的空间信息, 进而得到更准确的分类结果。

由于分水岭分割是对梯度图像分割, 且分水岭分割会产生过分割现象, 因此我们可以合理地认为分水岭分割之后, 一个区域中的所有点应属于同一类别。

根据一个区域中是否有训练样本而使用不同的方法进行分类。如果一个区域中含有类别已知的样本, 且所有已知样本的类别相同, 那么将该区域的所有点标记为已知样本的类别, 否则使用稀疏表示对该区域的所有样本进行分类。

对某个包含  $g$  个点的区域  $S = \{s_1, s_2, \dots, s_g\}$ , 为了合理地利用空间相邻的点来约束当前点的系数, 使用联合稀疏的思想。以  $s_j (j=1, 2, \dots, g)$  为中心的  $3 \times 3$  的方窗中的所有点构成了  $s_j$  的空间邻域  $S_{jN} = [s_j, s_{j1}, s_{j2}, \dots, s_{j8}]$ 。  $S_{jN}$  用字典表示如下:

$$S_{jN} = [A\beta, A\beta_{j1}, \dots, A\beta_{j8}] = A\beta_{jN} \quad (7)$$

$S_{jN}$  中的所有点属于同一类别的可能性极大, 所以它们应该用字典中相同的原子来表示, 即它们的系数向量中不为零的元素的标应相同。但当  $S_{jN}$  中包含边界点时, 其中的所有点并不属于同一类, 所以在进行稀疏表示之后, 应该尽可能保留图像原来的边界信息。基于以上两点考虑, 提出以下模型:

$$\beta_{jN} = \arg \min \|A\beta_{jN} - S_{jN}\|_F + \lambda \|A\beta_{jN}l - c\|_2 + \omega \|\beta_{jN}\|_{2,1} \quad (8)$$

其中,  $l = [1, -\frac{1}{8}, -\frac{1}{8}, -\frac{1}{8}, -\frac{1}{8}, -\frac{1}{8}, -\frac{1}{8}, -\frac{1}{8}, -\frac{1}{8}]^T$ , 式中第一项表示重构误差, 第二项是拉普拉斯保持项,  $c$  为原图像的拉普拉斯图与  $s_j$  相对应的点, 即位置相同的点。在类与类边界处, 若第一、三两项强制联合稀疏, 则第二项的值会变大, 因此, 这一项可以平衡在边界强制联合稀疏的问题, 在边界处也可以达到每类的样本由每类的字典原子表示的效果。第三项是  $l_{2,1}$  范数, 使得  $\beta_{jN}$  中的列向量中稀疏的位置相同。  $\lambda, \omega$  是平衡因子, 可以通过调节得到。

得到以上模型的解之后, 取出  $s_j$  的系数向量  $\beta_j$ , 对区域中的所有点都利用模型(8)得到其系数向量。最终得到区域中所有点的系数  $B = [\beta_1, \beta_2, \dots, \beta_g]$ 。此时第  $h$  类的残差可定义为:

$$r^h(S) = \|S - A^h B^h\|_F, h=1, 2, \dots, H \quad (9)$$

将该区域的所有点标记为残差最小的类别。

## 3 实验结果与分析

为了验证本文方法的有效性, 分别在两个高光谱数据集上进行了实验, 并将本文方法的分类结果与其它一些的方法进行比较, 对比的方法有: 标准的 SVM 和使用组合核的 SVM-CK<sup>[36]</sup>, 它们的参数为  $C=1024, \gamma=2^{-7}$ ; 文献[27]中的

方法 SPS、SSP 和 SOMP, 它们的参数与文献[27]保持一致。本文所用评价准则有如下 3 种:

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, 即所有类精度的平均值。

3) Kappa 系数, 可更好地检测分类结果的正确性。

### 3.1 Indian Pines 数据集上的实验结果与分析

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, 图像由  $145 \times 145$  个像素点构成, 空间分辨率为 20m/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。其中一共包含 16 个类, 从每个类中随机抽取 10% 的样本作为训练样本, 其它作为测试样本。实验中的参数通过交叉验证得到:  $\lambda=0.06, \omega=0.1$ 。表 1 列出了每个类别的名称及对应类的样本数量。图 3 为图像的分类分布。

表 1 Indian Pines 中样本类别及数目

class	sample
1—Alfalfa	46
2—Corn-notill	1428
3—Corn-mintill	830
4—Corn	237
5—Grass-pasture	483
6—Grass-trees	730
7—Grass-pasture-mowed	28
8—Hay-windrowed	478
9—Oats	20
10—Soybean-notill	972
11—Soybean-mintill	2455
12—Soybean-clean	593
13—Wheat	205
14—Woods	1265
15—Bldg-Grass-Tree-Drives	386
16—Stone-Steel-Towers	93



图 3 Indian Pines 的分类分布

在本数据集上按文献[11]中的方法计算 3 种梯度: SumBands、Sum4PCA、RCMG, 算法中所有参数与文献[11]保持一致。SumBands、Sum4PCA 和 RCMG 所对应的区域数分别为 1205、1240 和 1247。表 2 显示了在 Indian Pines 上使用本文方法及一些对比方法的实验结果精度。表 2 中, 后三列表示本文方法的结果。由表 2 中 SVM 的分类精度可知, 当只使用图像的光谱信息进行分类时, 分类精度并不理想。而从 SVM-CK 的分类精度可以看出, 在分类过程中加入图像的空间信息可以有效地提高分类精度。而对于加入空间信息的分类方法而言, 本文方法分类效果最好。其最主要原因是其它加入空间信息的方法都是使用固定窗邻域, 通常窗口的大小很难确定。而本文使用分水岭分割得到样本的自适应邻域, 从而避免了固定窗邻域所存在的问题。因此本文方法相较于其它方法, 分类精度都有明显提高。

表2 Indian Pines 上的分类精度(%)

class	SVM	SVM-CK	SP-S	SSP	SOMP	分水岭分割+SP		
						SumBand	Sum4PCA	RCMG
1	58.54	95.83	87.50	89.58	85.42	<b>97.56</b>	<b>97.56</b>	<b>97.56</b>
2	74.47	<b>96.67</b>	91.94	95.04	94.88	91.21	92.45	92.45
3	54.35	90.93	82.53	92.93	<b>94.93</b>	94.91	94.78	93.98
4	40.85	85.71	70.95	85.24	91.43	<b>96.24</b>	95.77	94.84
5	91.26	93.74	94.41	92.17	89.49	<b>97.7</b>	<b>97.7</b>	97.24
6	96.50	97.32	99.26	98.81	98.51	99.85	<b>100</b>	<b>100</b>
7	64.00	69.57	47.83	73.91	91.30	<b>100</b>	<b>100</b>	<b>100</b>
8	96.98	98.41	99.77	99.55	99.55	<b>100</b>	<b>100</b>	<b>100</b>
9	16.67	55.56	94.44	0	0	<b>77.78</b>	<b>77.78</b>	27.78
10	65.60	93.80	86.80	88.98	89.44	94.29	93.03	<b>94.86</b>
11	85.20	94.37	93.38	97.34	97.34	<b>99.82</b>	<b>99.82</b>	99.14
12	53.93	93.66	84.24	86.59	88.22	87.64	<b>96.82</b>	85.21
13	92.39	99.47	<b>100</b>	99.47	<b>100</b>	99.46	<b>100</b>	98.91
14	96.66	99.14	98.28	98.88	99.14	<b>100</b>	<b>100</b>	<b>100</b>
15	55.04	87.43	69.30	97.37	<b>99.12</b>	88.18	89.63	94.24
16	92.86	<b>100</b>	95.29	85.88	96.47	<b>100</b>	<b>100</b>	<b>100</b>
OA	78.33	94.86	91.16	94.79	95.28	96.35	<b>96.99</b>	96.27
AA	70.09	90.73	87.25	86.36	88.45	95.29	<b>95.96</b>	92.26
Kappa	75.07	94.1	89.90	94.0	94.6	95.82	<b>96.55</b>	95.74

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

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

表 3 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 4 为图像的类别分布情况。

表3 PU 中样本类别及数目

class	train	test
1—Asphalt	548	6083
2—Meadows	540	18109
3—Gravel	392	1707
4—Trees	524	2540
5—Painted metal sheets	265	1089
6—Bare Soil	532	4677
7—Bitumen	375	955
8—Self-Blocking Bricks	514	3166
9—Shadows	231	716




图4 PU 的类别分布图

用 Sumbands、Sum4PCA 和 RCMG 所得到的区域数分别为 10558、10639 和 11905。表 4 显示了在 PU 上使用本文方法及一些对比方法的实验结果精度。其中后三列为本文所提方法。

表4 PU 上的分类精度(%)

class	SVM	SVM-CK	SP-S	SSP	SOMP	分水岭分割+SP		
						SumBand	Sum4PCA	RCMG
1	85.80	79.85	83.79	69.59	59.33	99.31	<b>99.57</b>	99.54
2	88.40	84.86	72.35	72.31	78.15	98.00	<b>98.25</b>	98.03
3	75.16	81.87	71.85	74.10	83.53	98.59	<b>99.30</b>	97.95
4	97.24	96.36	98.94	95.33	96.91	99.45	<b>99.57</b>	99.41
5	100	99.37	100	99.73	99.46	<b>100</b>	99.81	99.91
6	87.21	93.55	92.63	86.72	77.41	99.44	<b>99.82</b>	99.13
7	91.10	90.21	91.44	90.32	98.57	99.69	<b>99.79</b>	98.43
8	86.74	92.81	95.57	90.46	89.09	95.23	96.28	<b>96.69</b>
9	<b>99.44</b>	95.35	98.24	90.94	91.95	98.88	98.74	98.88
OA	88.31	87.18	82.09	78.39	79.00	98.38	<b>98.70</b>	98.45
AA	90.12	90.47	89.42	85.50	86.04	98.73	<b>99.01</b>	98.66
Kappa	84.33	83.3	77.2	72.4	72.8	97.79	<b>98.23</b>	97.89

从表 4 可以得出,本文方法相较于 SOMP 和 SSP 在精度上有明显的提高。从图 4 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。而本文方法则使用自适应的区域大小,因此本文方法所得到的结果更好。

**结束语** 根据高光谱的特点,针对其存在的问题,提出了利用分水岭得到的空间信息和稀疏表示来提高分类精度的方法。从实验结果可以看出,本文方法优于其它一些分类方法。

本文使用的稀疏表示需要花费大量的运行时间,而对分水岭分割中的各个区域进行分类时,每个区域都可能是独立进行的,因此可以考虑用并行的方法来提高算法的效率。

## 参 考 文 献

- [1] 常庆瑞,周勇,申光荣,等. 遥感技术导论[M]. 北京:科学出版社,2004:1-8
- [2] 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,2006:38-46
- [3] Chen Jin. On classification method of hyperspectral images[D]. Changsha: National University of Defense Technology, 2010 (in Chinese)  
陈进. 高光谱图像分类方法研究[D]. 长沙:国防科技大学,2010
- [4] David L. Hyperspectral image data analysis [J]. IEEE Signal Processing Magazine, 2002, 19(1): 17-28
- [5] Li Ma, Crawford M M, Tian Jin-wen. Local Manifold Learning-Based k-Nearest-Neighbor for Hyperspectral Image Classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(11): 4099-4109
- [6] Goel P K, Prasher S O, Patel R M, et al. Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn[J]. Computers and Electronics in Agriculture, 2003, 39(2): 67-93
- [7] Zhou H, Mao Z, Wang D. Classification of coastal areas by airborne hyperspectral image [C] // Proceedings of SPIE. 2005, 5832: 471-476
- [8] Landgrebe D A. Signal Theory Methods in Multispectral Remote Sensing[M]. Wiley, New York, 2003
- [9] Chen C H, Ho P-G P. Statistical pattern recognition in remote sensing[J]. Pattern Recognition, 2008, 41(9): 2731-2741
- [10] Bali N, Mohammad-Djafari A. Bayesian approach with hidden Markov modeling and mean field approximation for hyperspectral data analysis[J]. IEEE Transactions on Image Processing, 2008, 17(2): 217-225
- [11] Subramanian S, Gat N, Sheffield M, et al. Methodology for hyperspectral image classification using novel neural network[C] // Proceedings of SPIE. 1997, 3071: 128-137
- [12] Yang F H, Meer F V D, Bakker W, et al. A back-propagation neural network for mineralogical mapping from AVIRIS data [J]. International Journal of Remote Sensing, 1999, 20(1): 97-110
- [13] Hernández-Espinosa C, Fernández-Redondo M, Torres-Sospedra J. Some experiments with ensembles of neural networks for classification of hyperspectral images[C] // International Symposium on Neural Networks (ISNN 2004). 2004: 912-917
- [14] Pal M, Mather M. Support vector machines for classification in remote sensing [J]. International Journal of Remote Sensing, 2005, 26(5): 1007-1011
- [15] Fauvel M, Benediktsson J A, Chanussot J, et al. Spectral and spatial classification of hyperspectral data using svms and morphological profiles [J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(11): 3804-3814
- [16] Heikkinen V, Tokola T, Parkkinen J, et al. Simulated multispectral imagery for tree species classification using support vector machines [J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(3): 1355-1364
- [17] Mountrakis G, Im J, Ogole C. Support vector machines in remote sensing: A review [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2011, 66(3): 247-259
- [18] Camps-Valls G, Bruzzone L. Kernel-based methods for hyperspectral image classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(6): 1351-1362
- [19] Fauvel M, Chanussot J, Benediktsson J A. Evaluation of kernels for multiclass classification of hyperspectral remote sensing data [C] // Proceedings of ICASSP. 2006: 813-816
- [20] Guo B, Gunn S R, Damper R I, et al. Customizing kernel functions for SVM-based hyperspectral image classification [J]. IEEE Transactions on Image Processing, 2008, 17(4): 622-629
- [21] Yang Shu-yuan, Qiao Yu, Yang Li-xia, et al. Hyperspectral Image Classification Based on Relaxed Clustering Assumption and Spatial Laplace Regularizer [J]. IEEE Geoscience and Remote Sensing Letters, 2014, 11(5): 901-905
- [22] Kettig R L, Landgrebe D A. Classification of multispectral image data by extraction and classification of homogeneous objects [J]. IEEE Transactions on Geoscience Electronics, 1976, 14(1): 19-26
- [23] Descombes X, Sigelle M, Preteux F. GMRF parameter estimation in a non-stationary framework by a renormalization technique; Application to remote sensing imaging [J]. IEEE Transactions on Image Processing, 1999, 8(4): 490-503
- [24] Jia X, Richards J A. Managing the spectral-spatial mix in context classification using Markov random fields [J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5(2): 311-314
- [25] Song Ben-qin, Li Jun, Mura M D, et al. Remotely Sensed Image Classification Using Sparse Representations of Morphological Attribute Profiles [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(8): 5122-5138
- [26] Sun Le, Wu Ze-bin, Wei Zhi-hui, et al. Supervised Hyperspectral Image Classification Combining Sparse Unmixing and Spatial Constraint [C] // Computer Vision in Remote Sensing (CVRS). 2012: 110-115
- [27] Chen Yi, 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
- [28] Yuan Hao-liang, Lu Yang, Yang Li-na, et al. Sparse Representation Using Contextual Information for HyperSpectral Image Classification [C] // IEEE International Conference on Cybernetics (CYBCONF). 2013: 138-143
- [29] Tang Yuan-yan, Yuan Hao-liang, Li Luo-qing. Manifold-Based Sparse Representation for Hyperspectral Image Classification [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(12): 7606-7618
- [30] Tarabalka Y, Chanussot J, Benediktsson J A. Segmentation and classification of hyperspectral images using watershed transfor-

mation[J]. Pattern Recognition, 2010, 43(7): 2367-2379

- [31] Wang Guo-quan, Zhou Xiao-hong, Yu Li-lei. Image Segmentation Based on Watershed Algorithm[J]. Computer Simulation, 2006, 26(5): 255-258 (in Chinese)  
王国权, 周小红, 蔚立磊. 基于分水岭算法的图像分割方法研究[J]. 计算机仿真, 2006, 26(5): 255-258
- [32] Vincent L, Soille P. Watersheds in digital spaces: an efficient algorithm based on immersion simulations[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991, 13(6): 583-598
- [33] Meyer F. Topographic distance and watershed lines[J]. Signal

Process, 1994, 38(1): 113-125

- [34] Stoev S, Rafsi—a fast watershed algorithm based on rainfalling simulation[C]// Proceedings of the Eighth International Conference on Computer Graphics, Visualization, and Interactive Digital Media, 2000: 100-107
- [35] Osma-Ruiz V, Godino-Llorente J I, Sáenz-Lechón N, et al. An improved watershed algorithm based on efficient computation of shortest paths[J]. Pattern Recognition, 2007, 40(3): 1078-1090
- [36] Camps-Valls G, Gomez-Chova L, Muñoz-Mari J, et al. Composite Kernels for Hyperspectral Image Classification[J]. IEEE Geoscience and Remote Sensing Letters, 2006, 3(1): 93-97

(上接第 59 页)

算法(GDLRec)要优于单独考虑任意一个的情况(GDLRec1、GDLRec2);而两种局部社交关系均不考虑时(GDLRec3)与只引入明确关系时(GDLRec2)的推荐效果非常接近。这说明:(1)明确关系与隐含关系的结合使算法的推荐精度有很大的提升;(2)在不考虑明确关系时,隐含关系对算法有一定的作用,但并不明显;(3)在不考虑隐含关系时,明确关系对算法几乎没有影响。

**结束语** 本文从全局、局部的角度研究如何将社交关系应用于推荐系统中,主要着眼于局部社交关系里的明确关系(explicit relation)和隐含关系(implicit relation);并提出结合用户全局与局部信息的社交推荐系统(GDLRec)。全局社交关系体现在用户声誉值系数的引入;局部社交关系的两类关系对应于在 PMF 里加入的正则项。通过在 Douban, Epinions 数据集上的实验,验证了本文基于声誉的局部关系细分推荐算法在推荐精度上有很好的表现。与现有的算法相比,本文提出的算法具有更好的可解释性和更高的推荐精度。

随着社交网络的普及,社交推荐的研究工作显得尤为重要。未来关于社交推荐的研究主要围绕以下几个方面展开:(1)继续探讨全局关系在社交推荐中的作用,尝试用不同方法得到声誉系数;(2)由于框架中的明确关系单独作用不是很明显,可以尝试用其他方法计算用户之间的明确关系的关系强度。

## 参 考 文 献

- [1] Mcpherson M, Smith-Lovin L, Cook J M. Birds of a feather: Homophily in social networks[J]. Annual Review of Sociology, 2001, 15(4): 344-349
- [2] Tang J, Hu X, Gao H, et al. Exploiting local and global social context for recommendation[C]// Proceedings of the Twenty-Third international joint conference on Artificial Intelligence. AAAI Press, 2013: 2712-2718
- [3] Marsden P V, Friedkin N E. Network studies of social influence[J]. Sociological Methods & Research, 1993, 22(1): 127-151
- [4] Zhang Yan-ping, Zhang Shun, Qian Fu-lan, et al. Robust Collaborative Recommendation Algorithm Based on User's Reputation[J]. Acta Automatica Sinica, 2015(5): 1004-1012 (in Chinese)

张燕平,张顺,钱付兰,等.基于用户声誉的鲁棒协同推荐算法[J].自动化学报,2015(5):1004-1012

- [5] Zhou Y B, Lei T, Zhou T. A robust ranking algorithm to spamming[J]. EPL (Europhysics Letters), 2011, 94(4): 1034-1054
- [6] Ha I, Oh K J, Hong M D, et al. Social filtering using social relationship for movie recommendation[M]// Computational Collective Intelligence: Technologies and Applications. Springer Berlin Heidelberg, 2012: 395-404
- [7] Ha I, Oh K J, Jo G S. Personalized advertisement system using social relationship based user modeling[J]. Multimedia Tools and Applications, 2013, 74(20): 8801-8819
- [8] Yao W, He J, Huang G, et al. Modeling dual role preferences for trust-aware recommendation[C]// Proceedings of the 37th international ACM SIGIR conference on Research & development in information retrieval. ACM, 2014: 975-978
- [9] Fazeli S, Loni B, Bellogin A, et al. Implicit vs. explicit trust in social matrix factorization[C]// Proceedings of the 8th ACM Conference on Recommender systems. ACM, 2014: 317-320
- [10] Ma H. An experimental study on implicit social recommendation[C]// Proceedings of the 36th international ACM SIGIR conference on Research and development in information retrieval. ACM, 2013: 73-82
- [11] Zhao T, Hu J, He P, et al. Exploiting homophily-based implicit social network to improve recommendation performance[C]// 2014 International Joint Conference on Neural Networks (IJCNN). IEEE, 2014: 2539-2547
- [12] Ma H, Yang H, Lyu M R, et al. Sorec: social recommendation using probabilistic matrix factorization[C]// Proceedings of the 17th ACM conference on Information and knowledge management. ACM, 2008: 931-940
- [13] Jamali M, Ester M. A matrix factorization technique with trust propagation for recommendation in social networks[C]// Proceedings of the fourth ACM conference on Recommender systems. ACM, 2010: 135-142
- [14] Ma H, Zhou D, Liu C, et al. Recommender systems with social regularization[C]// Proceedings of the Fourth ACM International Conference on Web Search and Data Mining. ACM, 2011: 287-296
- [15] Salakhutdinov R, Mnih A. Probabilistic Matrix Factorization[C]// NIPS. 2012: 1257-1264