

结合超像素和图的点积表示的遥感影像分割算法

张大明^{1,2*}, 张学勇^{1,2}, 刘华勇¹, 李璐¹

¹安徽建筑大学数理学院, 安徽 合肥 230022;

²安徽省建筑声环境重点实验室, 安徽 合肥 230601

摘要 基于分裂-合并的图像分割方法可以克服传统基于像素的遥感影像分割算法易受噪声干扰、分割效率低、分割效果差等缺点。结合超像素和图的点积表示算法,提出一种新的基于分裂-合并的遥感影像分割方法。首先,采用简单线性迭代聚类(SLIC)算法对图像进行超像素分割;其次,测量每个超像素块的纹理特征,并考虑空间邻近性,计算每两块之间的距离;然后,将每个超像素块视为图中一个顶点,构建相似矩阵,采用修正的图的点积表示算法将每个顶点重新映射为新的向量,并进行基于角度的k-means方法聚类,得到最后的分割结果。实验结果表明,所提方法分割结果稳定,同时有效地提高了分割精度,取得较好的分割视觉效果。

关键词 图像处理; 遥感影像; 简单线性迭代聚类; 超像素分割; 图的点积表示; 基于角度的k均值

中图分类号 P237

文献标志码 A

DOI: 10.3788/LOP202259.1210015

Remote Sensing Image Segmentation Using Super-Pixel and Dot Product Representation of Graphs

Zhang Daming^{1,2*}, Zhang Xueyong^{1,2}, Liu Huayong¹, Li Lu¹

¹School of Mathematics & Physics, Anhui Jianzhu University, Hefei 230022, Anhui, China;

²Key Laboratory of Architectural Acoustic Environment of Anhui Higher Education Institutes, Hefei 230601, Anhui, China

Abstract The image segmentation method using division-combination mitigates the limitations of the traditional pixel-based remote sensing image segmentation algorithm, such as noise interference, low segmentation efficiency, and poor segmentation effect. Thus, this paper proposes a new split-merge-based remote sensing image segmentation method using the super-pixel and dot product representation of graphs. First, the image is divided into super-pixels using the simple linear iterative clustering (SLIC) algorithm. Second, the texture feature of each super-pixel area is measured and distance between any two areas is calculated with respect to spatial proximity. Third, each super-pixel area is mapped as a vertex of the graph. Therefore, the dot product representation of graphs is modified and used to construct a similarity matrix; thereafter, all vertices (i. e., super-pixel areas) are mapped as new vectors clustered by angular-based k-means algorithm to get the final segmentation results. The experimental results show that the proposed method has stable segmentation results, improves the accuracy of the segmentation, and achieves a better visual segmentation effect.

Key words image processing; remote sensing image; simple linear iterative cluster; super-pixel segmentation; dot product representation of graphs; angular-based k-means

收稿日期: 2021-05-21; 修回日期: 2021-06-27; 录用日期: 2021-07-28

基金项目: 国家自然科学基金(61471003)、安徽省高校自然科学基金(KJ2018A0518, KJ2020A0484, KJ2019JD17)、安徽省重点实验室开发课题(IBES2018KF04)

通信作者: *zhang_daming@aliyun.com

1 引言

高分辨率多光谱遥感影像具有丰富的光谱信息和地物纹理特征,具有地物目标轮廓清晰和边界信息明显的优点,在使用上更具便利性和时效性,在灾害监测、农作物分类、城市规划和军事侦查等方面具有广泛应用^[1-3]。而影像分割对后续的信息提取和目标识别等任务具有基础性的作用,分割质量的好坏很大程度上影响着后续遥感信息处理的结果。

传统的图像分割方法大致可分为基于阈值、基于边缘、基于区域、基于聚类和基于图论等几类^[4]。这些方法一般而言又都是基于像素的,例如基于图论的方法^[5]就是将每个像素视为图上的一个顶点。一方面,图像像素一般至少是以百万级计的,所以基于像素的方法往往计算量巨大,实时性较差。例如,基于谱聚类的方法就是往往由于大型相似度矩阵特征分解的计算困境而被限制了应用。另一方面,遥感影像不可避免地会受到各种噪声的干扰,直接基于像素的图像分割方法往往很难兼顾噪声抑制和分割效果。例如,因为噪声和边缘都包含高频内容,传统基于边缘的方法若强调抗噪性,则图像边缘、轮廓处多会产生较大误差;若过于强调边缘的精确度,则会产生很多伪边界。所以,传统基于像素的方法分割质量和实时性往往都不够理想。

近年来,人们在遥感图像分割中经常采用的分裂-合并策略则在一定程度上有效地克服了传统基于像素的图像分割方法的缺陷。所谓分裂-合并法^[6],即先用某种算法对图像进行初始的分割,然后按照某种相似性准则将初始分割的区域自下而上合并,得到最终分割结果。人们从预分割方案、区域度量方法和区域融合方法等方面进行了广泛深入的研究^[7-9]。这类方法将像素级的图像分割问题转换为初始分割区域的合并问题,使得计算量得以迅速下降。分裂-合并方法是基于区域的方法,其基础便是图像的连续性,也就是根据一些特定的规则(如具有相似的灰度、颜色或纹理)将图像分为若干个区域。所以,这类算法一个优点是在合并过程中充分利用区域连续性特征和空间特征,得到相互连续的图像区域,且不受图像中区域数量的限制。分裂-合并算法有一个共同特点,即其分割结果的好坏依赖于初始分割

结果的好坏。尽管人们提出了许多改进方法^[7,9],仍然没有一种初始分割方法可以完全克服噪声的影响,而这在一定程度上影响了区域合并的效果。

因为超像素块更能反映图像的拓扑结构,近年来,人们经常采用超像素分割算法^[10-12]替代传统的方法(如分水岭算法)进行初始的预分割。2012年 Achanta 等^[13]提出一种通过计算像素点距离和颜色相似度聚类生成超像素的方法,称为简单线性迭代聚类(SLIC)算法,相比其他超像素分割算法^[14-16],SLIC 算法在边界拟合度、计算复杂度、区域紧致度等方面均表现更加优异;同时超像素的大小调节方便,具有较好的抗噪性;而且它的算法思想简单,处理速度快,是当前应用最广泛的超像素分割方法。在区域融合阶段,超像素块经常被视为图的顶点,采用流形的基于图论的聚类算法进行区域合并^[17-18],但往往只以预分割阶段的特征为基础,没有整合更多的特征,限制了分割效果。

近几年比较流行的遥感图像处理软件 eCognition 中的分形网络演化算法(FNEA)^[19]也是基于自下而上的策略。它是一种面向对象的多尺度分割方法,综合利用影像的光谱相似性和形状相似性度量对象之间的异质度,通过控制异质度,将对象自下而上的逐层合并,得到最终分割结果。但是该方法对尺度参数敏感,不同的尺度参数下得到的分割结果差异较大。而且为了获得满意的分割结果,还需要调节其他的参数。另一种被广泛使用的自下而上图像分割方法是多尺度联合分组(MCG)算法^[20]。MCG 算法将不同尺度下的分割结果整合,因此可以兼顾多尺度下的图像特征,具有较稳定且合理的分割结果。

基于随机点积图的理论,Scheinerman 等^[21]提出了图的点积表示算法,寻求图中顶点的表示向量,使其点积逼近连接顶点的边上的权值(似然概率)。尽管在社会网络的聚类分析等应用中取得了较好的效果^[22],但由于随机点积图对随机向量有服从某种概率分布的事先假设,图的点积表示算法的聚类效果被限制。

基于以上文献分析,本文提出了一种新的基于分裂-合并方案的遥感影像分割方法。首先,在初始分割阶段,采用 SLIC 算法对影像进行超像素分割;其次,在特征提取阶段,把每个超像素视为图上一个顶点,构建同时包含光谱信息、纹理信息和空间信息的区域特征提取和度量方法,并引入修正的图

的点积表示算法,把每个顶点的特征向量降维表示;最后,对降维后的特征向量进行聚类,即对超像素块进行合并,得到最终的分割图像。本文工作主要有以下贡献:将图的点积表示应用于图像分割,提出了修正的图的点积表示算法,并验证了这种修正在聚类问题中的重要性;基于最小生成树,构建了将光谱信息、纹理信息和空间信息整合的特征提取方法;构建了一种结合超像素和图的点积表示的遥感图像分割方案。

2 修正的图的点积表示方法

2.1 图的点积表示

Scheinerman 等^[21]于 2010 年提出了图的点积表示概念。对于图 $G=(V, E)$, S 是图的相似矩阵,其元素 s_{ij} 表示连接顶点 v_i 和 v_j 的边 E_{ij} 的权值,现赋予每个顶点一个 d 维向量 $X=[x_1, x_2, \dots, x_n] \in \mathbf{R}^{d \times n}$,

使得点积 $x_i \cdot x_j$ 与 s_{ij} 尽量接近,即满足代价函数:

$$\min_X \sum_{i \neq j} (x_i \cdot x_j - s_{ij})^2 = \min_X \|X^T X - S - E \circ (X^T X)\|_F^2, \quad (1)$$

式中: E 是 n 阶单位阵; \circ 为矩阵 Hadamard 乘法算子; $\|\cdot\|_F^2$ 为 Frobenius 范数。基于矩阵的特征分解, Scheinerman 等^[21]设计了一种迭代算法,如表 1 所示,该算法可以快速收敛到局部最优解。

图 G 经常是建立在高维数据集上的,即 p 很大,那么当 $d \ll p$ 时,上述的点积表示式(1)也可以理解为在点积意义下 $Y \rightarrow X$ 的一种降维方法。

在向量点积的定义下,角度的意义显得更为重要。Scheinerman 等^[21]将一般的 k-means 算法中向量间的欧氏距离替换为向量间的角度大小,结合图的点积表示,给出了基于角度的 k-means 聚类方法。

表 1 图的点积表示算法流程

Table 1 Flowchart of dot product representation of graphs

Input: data set $Y=[y_1, y_2, \dots, y_n] \in \mathbf{R}^{p \times n}$; similarity matrix $S \in \mathbf{R}^{n \times n}$; positive integer d
Output: matrix $X=[x_1, x_2, \dots, x_n] \in \mathbf{R}^{d \times n}$
1. Initialize matrix D to be $n \times n$ zero matrix
2. $S = S + D$
3. Compute the d th largest eigen-values λ_i of matrix S and the corresponding eigen-vectors $\mu_i, i = 1, \dots, d$
4. Let $X=[x_1, x_2, \dots, x_n]$, where
$x_j = (\sqrt{\lambda_1} \mu_{1j}, \dots, \sqrt{\lambda_n} \mu_{nj})^T, j = 1, \dots, n$
5. Let $D = I \circ X^T X$, where I is identity matrix, \circ is multiplication that elements of matrix multiplied by elements of matrix
6. Turn to step 2. until convergence
7. Output matrix X

2.2 修正的图的点积表示

在表 1 图的相似矩阵中,一般用高斯核函数 $s_{ij} = \exp(-\|y_i - y_j\|^2 / 2\sigma^2)$ 计算的相似度(其中 σ 为带宽参数),可以理解为顶点 v_i 和 v_j 属于同一类的概率,那么相应的向量之间夹角 $\theta_{ij} \in [0, \pi/2]$ 。对于基

于角度的聚类任务而言,发现向量将聚集于一个相对较小的范围内(第一象限),不利于聚类。为改善这个问题,舍弃相似度的概率意义,将相似度修正为 $s'_{ij} \in [-1, 1]$,这样基于点积表示,向量间的角度扩大至 $\theta'_{ij} \in [0, \pi]$,如表 2 所示。

表 2 相似度修正前后的对比

Table 2 Similarity before modification versus similarity after modification

Parameter	Before modification	After modification
Distance	D_{IS}	$D_{ISN} = D_{IS} / T_{\text{threshold}}$
Range of similarity	$s_{ij} \in [0, 1]$	$s'_{ij} \in [-1, 1]$
Range of angular	$\theta_{ij} \in [0, \pi/2]$	$\theta'_{ij} \in [0, \pi]$
Calculation formula	$s_{ij} = \exp(-\ y_i - y_j\ ^2 / 2\sigma^2)$	$s'_{ij} = \frac{2}{\pi} \arctan(\ln D_{ISN} / \ln \epsilon)$

具体做法是:先对某种常用的距离 D_{IS} (如欧氏距离)做归一化处理,即

$$D_{IS\ N} = D_{IS} / T_{\text{threshold}}, \quad (2)$$

式中:阈值 $T_{\text{threshold}}$ 为最大类间距离(实际中可以依据经验手动选择)。这样同类向量间的距离一般介于 0 和 1 之间,而异类向量距离则大于 1 至无穷。然后计算修正后的相似度,表达式为

$$s'_{ij} = \frac{2}{\pi} \arctan(\ln D_{IS\ N} / \ln \epsilon), \quad (3)$$

式中: $\epsilon \in (0, 1)$ 是一个尺度参数。三种不同尺度参数情形下的函数曲线如图 1 所示,实验均选择 $\epsilon = 0.9$ 。这样 $s'_{ij} \in [-1, 1]$, 同类向量的相似度大于零且趋向于 1, 而异类向量的相似度小于零且趋向于 -1。将由 s'_{ij} 得到修正后的相似度矩阵 S' 替换表 1 图的点积表示算法中的相似矩阵 S , 即可由表 1 中的算法得到修正后的图的点积表示。

图 2 和图 3 分别是 Swiss Roll 数据和 UMIST Face Database^[23] 的人脸图像的降维实验。其中图 2(a) 和图 3(a) 是原始数据,图 2(b) 和图 3(b) 是三




图 1 函数 $\frac{2}{\pi} \arctan(\ln D_{IS\ N} / \ln \epsilon)$ 的图像

Fig. 1 Graph of function $\frac{2}{\pi} \arctan(\ln D_{IS\ N} / \ln \epsilon)$

维 Swiss Roll 数据和高维人脸数据按照修正前的图的点积表示方法分别降维到二维空间后的分布情况,图 2(c) 和图 3(c) 是修正后的分布情形。可以看到,当原始高维数据降维投影到二维空间中后,相比修正之前,修正后的相似度数据在角度上分布的范围更广,这显然会有利于后续基于角度的聚类。




图 2 Swiss Roll 数据实验。(a) 原始数据; (b) 修正前的降维数据; (c) 修正后的降维数据

Fig. 2 Experimental results of Swiss Roll data. (a) Original data; (b) dimensionality reduction data before correction; (c) dimensionality reduction data after correction




图 3 UMIST Face Database 实验。(a) 原始数据; (b) 修正前的降维数据; (c) 修正后的降维数据

Fig. 3 Experimental results of UMIST Face Database. (a) Original data; (b) dimensionality reduction data before correction; (c) dimensionality reduction data after correction

3 基于超像素分割和图的点积表示的图像分割算法

首先介绍超像素分割的 SLIC 算法,其次给出基于区域的特征提取和度量方法,最后给出所提算法的流程。

3.1 SLIC 算法

SLIC 超像素分割算法的步骤如下^[13]。

1) 初始化种子点

假设图像中有 N 个像素点,初始设置图像分为 h 个大小大致相同的超像素,则每个超像素的大小是 N/h ,将初始划分矩形网格中心处的像素作为超像素的种子点。为避免种子点落在边缘处,在初始位置周围 $3 \text{ pixel} \times 3 \text{ pixel}$ 空间内搜索种子点,以确保种子点能够落在初始位置周边梯度最小的地方。

2) 相似度测量

将 RGB 彩色图像空间转换为 Lab 颜色空间,再加上每个像素点的坐标 (x, y) ,组合成 5 维向量 (l, a, b, x, y) ,这样可以计算当前像素点 i 和种子点 j 之间的颜色距离 d_c 和空间距离 d_s ,公式分别为

$$d_c = \sqrt{(l_i - l_j)^2 + (a_i - a_j)^2 + (b_i - b_j)^2}, \quad (4)$$

$$d_s = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}. \quad (5)$$

再综合考虑颜色距离和空间距离,将两个距离组合为单个测度,

$$D = \sqrt{\left(\frac{d_c}{\rho_1}\right)^2 + \left(\frac{d_s}{q}\right)^2}, \quad (6)$$

式中:两个加权参数 $q = \sqrt{N/h}$,表示类内最大空间距离; ρ_1 为常数,且 $1 \leq \rho_1 \leq 40$,是最大颜色距离的简化处理,用于平衡颜色距离和空间距离的重要性。

3) 迭代聚合与连通性处理

SLIC 算法采用修正的 k-means 算法进行聚类,直到聚类结果稳定,或达到最大迭代次数才停止迭代。对于一些面积过小或孤立点,将其重新分配到空间距离最近的超像素中生成紧致连通的超像素。

3.2 区域特征的提取与度量

经 SLIC 算法处理得到的超像素块已经含有光谱信息和部分像素级的空间信息,所以在此提取每个超像素块区域特征时,着眼于纹理特征。Gabor 滤波器能够很好地兼顾信号在空间域和频率域中的分辨能力,且具有多方向性和多分辨率性,与人

类视觉系统特性相似,能充分描述图像的纹理信息。这里采用 Gabor 滤波器提取每个区域的纹理特征。具体地,由二维 Gabor 函数 $g(x, y)$ ^[24] 构造多尺度和多方向的 Gabor 滤波器组 $g_{m'n'}(x, y)$:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left[-\frac{1}{2}\left(\frac{x^2}{\sigma_x^2} + \frac{y^2}{\sigma_y^2}\right) + 2\pi j\omega x\right], \quad (7)$$

$$g_{m'n'}(x, y) = a^{-m'} g(x', y'), \quad (8)$$

$$\begin{cases} x' = a^{-m'}(x \cos \theta + y \sin \theta) \\ y' = a^{-m'}(-x \cos \theta + y \sin \theta) \end{cases}, \quad (9)$$

$$\theta = n'\pi/k, \quad (10)$$

式中: k 为方向数, $n' = 0, 1, \dots, k-1$; M 为尺度数, $m' = 1, 2, \dots, M$ 。给定图像 $I(x, y)$, 利用 Gabor 变换对该图像与 Gabor 滤波器组进行卷积,得到

$$W_{m'n'}(x, y) = I(x, y) \otimes g_{m'n'}(x, y). \quad (11)$$

则由滤波后的图像 $W_{m'n'}$ 可得均值 $\mu_{m'n'}$ 和标准差 $\sigma_{m'n'}$, 这样将不同尺度参数和方向参数组合起来得到该区域的纹理特征向量,

$$[\mu_{11}, \sigma_{11}, \mu_{12}, \sigma_{12}, \dots, \mu_{m'n'}, \sigma_{m'n'}], \quad (12)$$

共计 $2m'n'$ 维。实验中,取 3 个尺度,8 个方向,即 $k=8, M=3$,所以纹理特征为 48 维向量。

基于上述测量的纹理特征,可以计算任意两个区域 i 和区域 j 之间的欧氏距离:

$$D_{\text{ISE}}(i, j) = \sum_{m'} \sum_{n'} \sqrt{(\sigma_{m'n'}^i - \sigma_{m'n'}^j)^2 + (\mu_{m'n'}^i - \mu_{m'n'}^j)^2}. \quad (13)$$

式(13)虽然度量了超像素块的纹理特征距离,并没有考察超像素间的空间信息。实际上,如果两个超像素块空间上邻近,则它们属于同一类的可能性较大。因此,基于图的最小生成树,给出同时融合光谱信息、纹理信息和空间信息的距离计算方法。

最小生成树是完全无向图的一个子图,它覆盖所有顶点,同时具有最小的权值和。最小生成树不仅包含了边的权值的信息,而且包含了顶点之间空间距离的信息^[25]。将每一个超像素块视为图上的顶点,构建区域邻接图 $G=(V, E)$, V 是顶点集合 $V=\{v_1, v_2, \dots, v_n\}$, E 是边的集合,连接顶点 v_i 和 v_j 的边 E_{ij} 的权值即为式(13)中的 $D_{\text{ISE}}(i, j)$ 。在此图的最小生成树上,寻找任意两顶点 v_i 和 v_j 的路径 $\{v_i, v_{i+1}, \dots, v_j\}$, 其中 v_p 和 v_{p+1} 是路径中的两相邻

顶点,这样基于最小生成树,构建的新的距离计算方法为

$$D_{IS\ MST}(i, j) = \sum_{p=i}^j D_{IS\ E}(p, p+1). \quad (14)$$

可以看到,式(14)中的距离度量同时包含了 SLIC 算法中的光谱信息、Gabor 纹理信息、最小生成树所蕴含的空间信息,这将有利于改善分割效果。

3.3 所提算法

将式(14)得到的距离 $D_{IS\ MST}$ 替代式(2)中的 D_{IS} , 计算得到规范化距离 $D_{IS\ N} = D_{IS\ MST} / T_{threshold}$, 然后经过修正后的基于图的点积表示算法,表示超像素块的特征向量得以重新降维表示,再通过基于角度的 k-means 聚类就可以完成区域合并,得到最终的分割结果。基于以上讨论,给出所提算法的流程图,如图 4 所示。

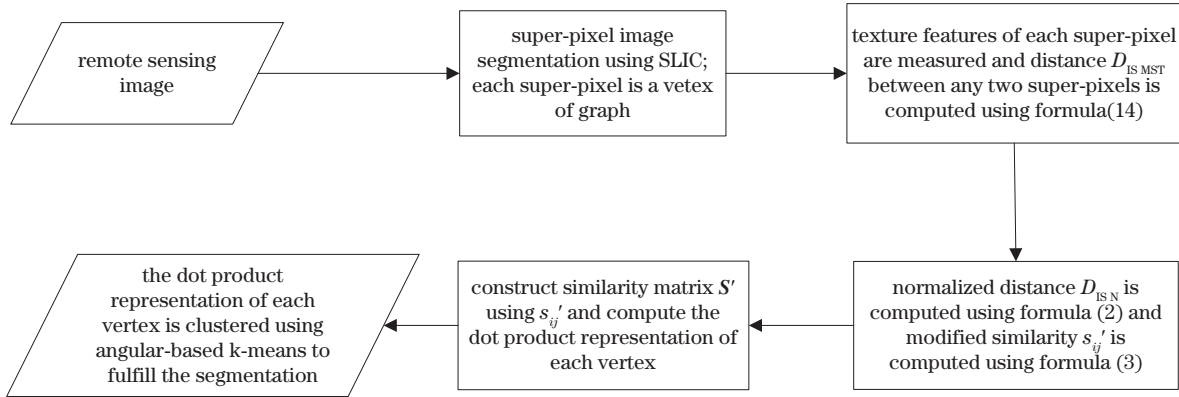


图 4 所提多光谱遥感图像分割算法流程

Fig. 4 Flow chart of the proposed multispectral remote sensing image segmentation algorithm

4 实验结果及其讨论

为了验证所提算法的有效性,进行了多光谱遥感影像分割的实验和分析。所有的实验都在主频为 2.8G 的 Pentium 4 处理器、8G 内存、Windows10 操作系统的 PC 机上进行,软件环境为 MatlabR2014a 和 eCognition Developer。为评价分割效果,采用了目视判别法和 P-R 方法^[26]进行定量评价。

$$P_{precision} = N_{TP} / (N_{TP} + N_{FP}), \quad (15)$$

$$R_{recall} = N_{TP} / (N_{TP} + N_{FN}), \quad (16)$$

式中: N_{TP} 为正确分割的地物目标像素样本数; N_{FP} 为被误分为地物目标的背景像素样本数; N_{FN} 为被误分为背景的地物目标像素样本数。分割精确度 $P_{precision}$ 值越大,精度越高;边界召回率 R_{recall} 值越大,边界附着效果越好。其中参考图像 Ground Truth 为手工标注。

4.1 实验分析一

所提算法中主要有三个参数需要设置:图的点积表示中的维数 d ; 类别数 K ; SLIC 算法中的参数 q 。对于各种谱聚类算法^[27-28], 维数的设置一般依据经验,而且维数对聚类结果影响不大;降维的目的

就是揭示数据在低维空间中的结构,降低计算量,因此一般都设置较小。实验中显示当 d 从 3 变化到 10 时,分割结果没有明显的差异。此处,本课题组没有给出相关实验图像。本实验中统一设置 $d=3$ 。类别数的选取是聚类问题中一直没有解决的问题,对于图像分割而言,过小的类别数,会导致欠分割的问题;过大的类别数,也会产生过分割,进而产生伪边界。虽然有一些讨论类别数的方法^[29-30],但实际的图像分割是非常复杂的聚类问题,大多数情况下仍是根据经验手动选择。实验中发现,所提算法对类别数 K 的选择不十分敏感,在一个大致合理的范围内(常见的取 $3 \leq K \leq 8$),分割结果都比较接近。因此在实验中根据地物目标的多少,手动选择类别数 K 。

SLIC 超像素预分割中,控制超像素大小的参数 q 对分割结果有一定影响。通过如下实验讨论和分析这种影响。

实验图像来自 NWPU VHR-10 数据集^[31],它由 715 幅采集自 Google Earth,空间分辨率为 0.5~2 m 的 RGB 图像和 85 幅来自 Vaihingen 数据经过 pan-锐化,空间分辨率为 0.08 m 的红外图像组成。目标包括飞机、舰船、油罐、棒球场、网球场、篮球场、田径场、港口、桥梁、车辆 10 个类别。实验 1 的图像为其

中编号为 178 的局部图像,大小为 266 pixel \times 385 pixel,该局部图中包括桥梁、建筑物、水体、植被、船只等地物目标,如图 5(a)所示。图 5(b)是手

工标注的分割图像。图 6(a)~(d)分别是参数 $q=5, 10, 20, 50$ 时的超像素预分割结果,图 6(e)~(h)则是相应的最终分割结果。



图 5 实验 1。(a)原图像;(b) Ground Truth

Fig. 5 Experiment 1. (a) Original image; (b) Ground Truth

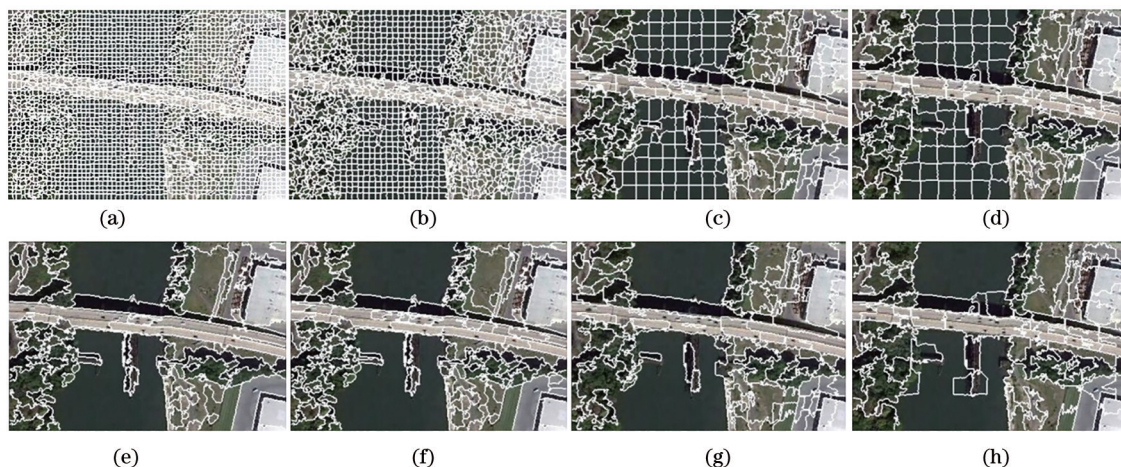


图 6 实验 1,参数 q 取不同值时的分割结果。(a) $q=5$; (b) $q=10$; (c) $q=20$; (d) $q=50$; (e)~(h) 对应的分割结果

Fig. 6 Segmentation results under parameter q in experiment 1. (a) $q=5$; (b) $q=10$; (c) $q=20$; (d) $q=50$; (e)~(h) corresponding segmentation results

由于所提算法基于分裂-融合的分割策略,前期的预分割结果直接影响着最终的合并结果。此处若控制超像素大小的参数 q 设置越小,超像素块越小,数目越多,会体现更多的细节特征;若设置过大,则超像素块较大,则后续合并出的分割结果较为粗糙。在图 6(d)中,由于参数 q 取值较大,预分割超像素块较大,这样最终合并的分割结果[图 6(h)]过于粗糙,甚至有明显的误分割;随着参数 q 取值减小,情况逐步改善,如图 6(g)所示;而当参数 q 取值小于等于 10 时,可以较好地避免上述问题,而且结果相对稳定,如图 6(e)、(f)所示。从表 3 的 P-R 指标变化也能得到类似判断。后续的实验中统一设置 $q=5$,以便更好地兼顾整体和局部的分割视觉效果。

表 3 实验 1 的评价结果

Table 3 Evaluation results of experiment 1

Parameter	$q=5$	$q=10$	$q=20$	$q=50$
Precision	0.8729	0.8698	0.8236	0.7172
Recall	0.8763	0.8791	0.8367	0.7461

4.2 实验分析二

实验 2 图像是 NWPU VHR-10 数据集^[31]中编号为 73 的 RGB 图像的局部,图片大小为 300 pixel \times 191 pixel,该局部图中包括飞机、跑道、地物标志、植被等地物目标,如图 7(a)所示。图 7(c)是 SLIC 算法的超像素预分割结果,其中参数 $q=5$ 。

设计该实验的目的是进一步验证所提算法中图的点积表示中相似度修改的必要性。图 7(d)、




图7 实验2的分割结果。(a)原图像;(b) Ground Truth;(c) SLIC的分割结果;(d)修正前所提算法的分割结果;(e)修正后所提算法的分割结果

Fig. 7 Segmentation results of experiment 2. (a) Original image; (b) Ground Truth; (c) segmentation result of SLIC; (d) segmentation result of proposed algorithm before correction; (e) segmentation result of proposed algorithm after correction

(e)分别为相似度修正前后所提算法的分割结果。二者的类别数依据经验统一手动设置为 $K=6$, 图的点积表示中的维数 $d=3$ 。通过目视的比较判别容易看到,修正后所提算法可以较好地克服修正之前分割图像中出现的地物目标过分割和误分割的问题,分割效果提高明显。从表4的P-R定量评价中也可以看出,相似度修正后的分割结果的Precision指标和Recall指标均有较大程度提高。

表4 实验2的评价结果

Table 4 Evaluation results of experiment 2

Parameter	Before correction	After correction
Precision	0.7729	0.8651
Recall	0.8132	0.9264

4.3 实验分析三

为了进一步验证所提算法的有效性,与另外两种自下而上的图像分割算法比较,即eCognition developer 软件中的 FNEA 算法^[19]和 MCG 算法^[20]。

实验3的实验图像为 QuickBird 卫星在 2010 年 11 月 5 日拍摄的刚完工不久的美国胡佛水坝旁路 (Hoover Dam Bypass) 的局部,其分辨率为 0.6 m, 大小为 428 pixel \times 461 pixel^[32],地物特征包括水坝、水体、公路、建筑物、山体等,如图 8(a) 所示。图 8(c)、(d) 分别是 FNEA 算法尺度参数分别设置为 100 和 150 的分割结果,其中形状异质度设置为

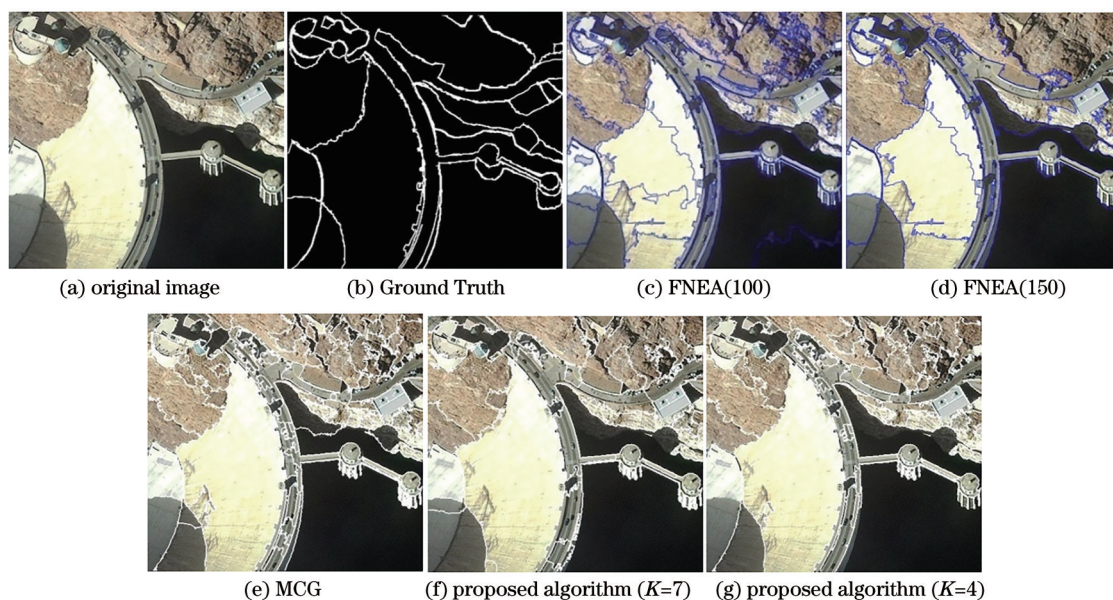


图8 实验3的分割结果

Fig. 8 Segmentation results of experiment 3

0.1 和紧致度设置为 0.5。图 8(e) 是 MCG 算法分割结果, 所有参数取默认值。图 8(f) 是所提算法在参数设置为 $K=7$ 、 $q=5$ 、 $d=3$ 时的分割结果, 为

了说明类别数对聚类结果的影响, 图 8(g) 给出了所提算法在 $K=4$ (其他参数不变) 时的分割结果。表 5 为实验 3 的评价结果。

表 5 实验 3 的评价结果

Table 5 Evaluation results of experiment 3

Parameter	FNEA(100)	FNEA(150)	MCG	Proposed algorithm ($K=7$)	Proposed algorithm ($K=4$)
Precision	0.7729	0.7548	0.8498	0.8592	0.8636
Recall	0.8761	0.8827	0.9563	0.9681	0.9507

实验 4 的实验图像是 NWPU VHR-10 数据集^[31] 中 167 号图像的局部图, 图像大小为 301 pixel \times 301 pixel, 包括水体、公路、植被、建筑物等地物目标, 目视判别分辨率较低, 如图 9(a) 所示。与图 8 类似, 图 9(c)、(d) 分别是 FNEA 算法尺度参数分别设

置为 50 和 100 时的分割结果, 其中形状异质度和紧致度也都设置为和上面相同的默认值, 图 9(e) 是 MCG 算法分割结果, 图 9(f)、(g) 分别是所提算法在类别数 K 分别设置为 7 和 4、 $q=5$ 、 $d=3$ 时的分割结果。表 6 为实验 4 的评价结果。

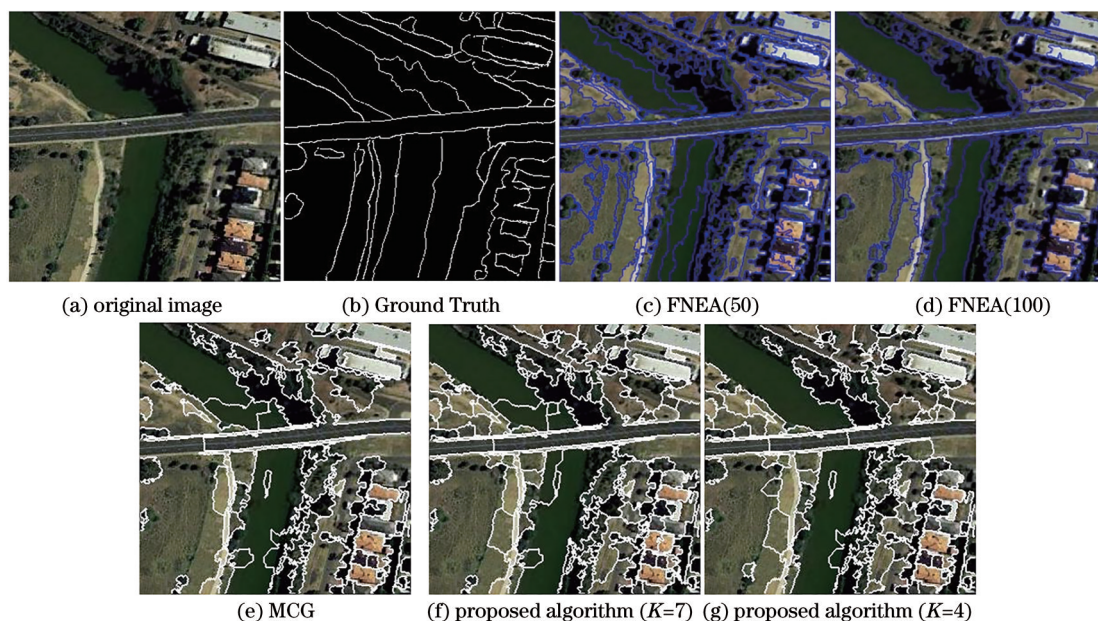


图 9 实验 4 的分割结果

Fig. 9 Segmentation results of experiment 4

表 6 实验 4 的评价结果

Table 6 Evaluation results of experiment 4

Parameter	FNEA(50)	FNEA(100)	MCG	Proposed algorithm ($K=7$)	Proposed algorithm ($K=4$)
Precision	0.7149	0.7283	0.8559	0.8337	0.8472
Recall	0.8132	0.8362	0.9317	0.9119	0.9326

从图 8(c)、(d) 可以看到, FNEA 方法在尺度参数由小到大变化时, 过分割的现象逐步得到改善, 但与此同时, 却存在两个无法克服的问题。其一是仍然无法消除一些明显的过分割和误分割情况 (如水坝坝体部分); 其二, 在一些小尺度的部分, 过分割消除的同时, 也产生了欠分割问题 (如右上角山体部分的地物目标)。这些问题也同样

出现在分辨率较低的图 9(c)、(d) 中。由于水体光谱相似度较大, FNEA 方法难以完全准确进行区分, 产生了比较严重的误分割和过分割问题; 而植被的光谱异质度较大, 也产生较明显的过分割; 建筑物的光谱信息“同谱异物”的情况比较显著, 所以在小尺度情形下, 过分割严重, 而在大尺度情形下, 又产生了欠分割。MCG 算法是一种自下而上

的多尺度图像分割方法,将不同尺度下的分割结果组合成最终分割结果,所以可以较好地兼顾各种尺度下的图像特征。

所提算法在前期 SLIC 超像素分割考虑了光谱特征基础上,又整合了超像素的纹理特征和空间邻近性。从图 8(f)、(g) 可以看到,所提算法较好地平衡了在不同尺度下过分割与欠分割的矛盾,在同一图像的不同部分,能够产生合理的分割结果,误分割情况大大减少,其分割结果与 MCG 算法结果比较接近。同时注意到,所提算法对类别数 K 的选择不是非常敏感,只要 K 大致在一个合理的范围内,分割结果相对稳定,如图 8(f)、(g) 和图 9(f)、(g) 所示。表 5 和表 6 的定量比较结果也可以反映出以上结论。

但是,所提算法对图像的分辨率似乎较敏感,如图 9(f)、(g) 中的分割结果相对图 8(f)、(g) 而言显得略差,仍然出现了一些较明显的误分割。这一方面分辨率影响 SLIC 超像素分割结果;另一方面,分辨率较低也会导致纹理特征测量较为粗糙,影响合并的结果。

5 结 论

在分裂-合并的框架下,将超像素和修正的图的点积算法表示相结合,提出了一种新的遥感影像分割方法。该方法利用 SLIC 算法对影像进行初步预分割,得到超像素块,将每一个超像素块看作图中一个顶点,用修正的图的点积表示方法将其映射为新的向量,并利用基于角度的 k -means 算法进行聚类合并,得到分割结果。算法中两个主要工作,对图的点积表示的修正和对光谱信息、纹理信息和空间信息的融合,都对分割质量的提高至关重要。通过含有各类地物目标的不同多光谱遥感图像分割实验,将所提算法与 MCG 算法、不同参数的 FNEA 算法进行定性和定量比较,验证了所提算法分割结果稳定,可以较好地避免过分割、欠分割和误分割等情况,获得了整体视觉效果较好的影像分割结果。

图的点积表示本质上仍是一种基于矩阵谱特征的降维算法,所提算法只是修正了相似度使其更利于聚类,而没有像很多谱聚类算法从计算效率^[33-34]上加以考虑,加之要计算纹理特征,所以算法的计算量较大,速度较慢。借鉴已有的一些思路,如并行计算^[35],对算法进行改进是下一步的工作目标。

参 考 文 献

- [1] Chehata N, Orny C, Boukir S, et al. Object-based change detection in wind storm-damaged forest using high-resolution multispectral images[J]. *International Journal of Remote Sensing*, 2014, 35(13): 4758-4777.
- [2] 包诗薇, 陈洪耀, 张黎明, 等. 基于灰阶靶标的光学遥感器绝对辐射定标及反射率反演验证[J]. *光学学报*, 2021, 41(4): 0428001.
Bao S W, Chen H Y, Zhang L M, et al. Absolute radiometric calibration of optical sensor based on gray-scale targets method and reflectance inversion validation[J]. *Acta Optica Sinica*, 2021, 41(4): 0428001.
- [3] 韩子硕, 王春平, 付强, 等. 基于空间分离表征 GAN 的遥感图像模式互转[J]. *光学学报*, 2021, 41(7): 0728003.
Han Z S, Wang C P, Fu Q, et al. Remote sensing image mode translation based on spatial disentangled representation GAN[J]. *Acta Optica Sinica*, 2021, 41(7): 0728003.
- [4] 黄鹏, 郑淇, 梁超. 图像分割方法综述[J]. *武汉大学学报(理学版)*, 2020, 66(6): 519-531.
Huang P, Zheng Q, Liang C. Overview of image segmentation methods[J]. *Journal of Wuhan University (Natural Science Edition)*, 2020, 66(6): 519-531.
- [5] Peng B, Zhang L, Zhang D. A survey of graph theoretical approaches to image segmentation[J]. *Pattern Recognition*, 2013, 46(3): 1020-1038.
- [6] 章毓晋. 中国图像工程: 2020[J]. *中国图象图形学报*, 2021, 26(5): 978-990.
Zhang Y J. Image engineering in China: 2020[J]. *Journal of Image and Graphics*, 2021, 26(5): 978-990.
- [7] Fan S C, Sun Y H, Shui P L. Region-merging method with texture pattern attention for SAR image segmentation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 18(1): 112-116.
- [8] Zhang L P, Zhang Y, Chen Z Z, et al. Splitting and merging based multi-model fitting for point cloud segmentation[J]. *Journal of Geodesy and Geoinformation Science*, 2019, 2(2): 78-89.
- [9] Lassalle P, Inglada J, Michel J, et al. A scalable tile-based framework for region-merging segmentation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(10): 5473-5485.
- [10] 张永梅, 孙海燕, 胥玉龙. 一种改进的基于超像素的多光谱图像分割方法[J]. *国土资源遥感*, 2019, 31(1): 58-64.

- Zhang Y M, Sun H Y, Xu Y L. An improved multispectral image segmentation method based on super-pixels[J]. *Remote Sensing for Land & Resources*, 2019, 31(1): 58-64.
- [11] 黄亮, 姚丙秀, 陈朋弟, 等. 高分辨率遥感影像超像素的模糊聚类分割法[J]. *测绘学报*, 2020, 49(5): 589-597.
- Huang L, Yao B X, Chen P D, et al. Superpixel segmentation method of high-resolution remote sensing image based on fuzzy clustering[J]. *Acta Geodaetica et Cartographica Sinica*, 2020, 49(5): 589-597.
- [12] An J Q, Shi Y C, Han Y H, et al. Extract and merge: superpixel segmentation with regional attributes[M]//Vedaldi A, Bischof H, Brox T, et al. *Computer Vision-ECCV 2020. Lecture notes in computer science*. Cham: Springer, 2020, 12375: 155-170.
- [13] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(11): 2274-2282.
- [14] 国强, 彭龙. 基于三维卷积神经网络与超像素分割的高光谱分类[J]. *光学学报*, 2021, 41(22): 2210001.
- Guo Q, Peng L. Hyperspectral classification based on 3D convolutional extension network and super pixel segmentation[J]. *Acta Optica Sinica*, 2021, 41(22): 2210001.
- [15] Xu H L, Zhang H Y, He W, et al. Superpixel-based spatial-spectral dimension reduction for hyperspectral imagery classification[J]. *Neurocomputing*, 2019, 360: 138-150.
- [16] 宋熙煜, 周利莉, 李中国, 等. 图像分割中的超像素方法研究综述[J]. *中国图象图形学报*, 2015, 20(5): 599-608.
- Song X Y, Zhou L L, Li Z G, et al. Review on superpixel methods in image segmentation[J]. *Journal of Image and Graphics*, 2015, 20(5): 599-608.
- [17] Kang X J, Zhu L, Ming A L. Dynamic random walk for superpixel segmentation[J]. *IEEE Transactions on Image Processing*, 2020, 29: 3871-3884.
- [18] Ban Z H, Liu J G, Cao L. Superpixel segmentation using Gaussian mixture model[J]. *IEEE Transactions on Image Processing*, 2018, 27(8): 4105-4117.
- [19] Karydas C, Jiang B. Scale optimization in topographic and hydrographic feature mapping using fractal analysis[J]. *ISPRS International Journal of Geo-Information*, 2020, 9(11): 631.
- [20] Pont-Tuset J, Arbelaez P, Barron J T, et al. Multiscale combinatorial grouping for image segmentation and object proposal generation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(1): 128-140.
- [21] Scheinerman E R, Tucker K. Modeling graphs using dot product representations[J]. *Computational Statistics*, 2010, 25(1): 1-16.
- [22] Athreya A, Fishkind D E, Levin K, et al. Statistical inference on random dot product graphs: a survey [EB/OL]. (2017-09-16) [2021-01-03]. <https://arxiv.org/abs/1709.05454>.
- [23] UMIST 人脸数据库[EB/OL]. [2021-05-20]. https://download.csdn.net/download/shanshuizui/7533797?utm_source=bbsseo.
- UMIST facial database[EB/OL]. [2021-05-20]. https://download.csdn.net/download/shanshuizui/7533797?utm_source=bbsseo.
- [24] Li W T, Mao K Z, Zhang H, et al. Selection of Gabor filters for improved texture feature extraction [C]//2010 IEEE International Conference on Image Processing, September 26-29, 2010, Hong Kong, China. New York: IEEE Press, 2010: 361-364.
- [25] Trudeau R J. *Introduction to graph theory*[M]. North Chelmsford: Courier Corporation, 2013.
- [26] Unnikrishnan R, Pantofaru C, Hebert M. Toward objective evaluation of image segmentation algorithms [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, 29(6): 929-944.
- [27] Shi J B, Malik J. Normalized cuts and image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 888-905.
- [28] Bengio Y, Paiement J, Vincent P, et al. Out-of-sample extensions for LLE, Isomap, MDS, eigenmaps, and spectral clustering[C]//Advances in Neural Information Processing Systems 16 Neural Information Processing Systems, December 8-13, 2003, Vancouver and Whistler, British Columbia, Canada. Cambridge: The MIT Press, 2003: 177-184.
- [29] Fujita A, Takahashi D Y, Patriota A G. A non-parametric method to estimate the number of clusters [J]. *Computational Statistics & Data Analysis*, 2014, 73: 27-39.
- [30] Fu W, Perry P O. Estimating the number of clusters using cross-validation[J]. *Journal of Computational and Graphical Statistics*, 2020, 29(1): 162-173.
- [31] Cheng G, Zhou P C, Han J W. Learning rotation-invariant convolutional neural networks for object

- detection in VHR optical remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(12): 7405-7415.
- [32] 11月5日胡佛水坝旁路QuickBird卫星地图[EB/OL]. (2010-11-10)[2020-12-19]. http://www.godeyes.cn/html/2010/11/10/download_10397.html. QuickBird satellite map of Hoover Dam bypass on November 5[EB/OL]. (2010-11-10)[2020-12-19]. http://www.godeyes.cn/html/2010/11/10/download_10397.html.
- [33] Yan D H, Huang L, Jordan M I. Fast approximate spectral clustering[C]//Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, June 28-July 1, 2009, Paris, France. New York: ACM Press, 2009: 907-916.
- [34] Wang R, Nie F P, Yu W Z. Fast spectral clustering with anchor graph for large hyperspectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(11): 2003-2007.
- [35] Song Y Q, Chen W Y, Bai H J, et al. Parallel spectral clustering[M]//Daelemans W, Goethals B, Morik K. Machine learning and knowledge discovery in databases. Lecture notes in computer science. Heidelberg: Springer, 2008, 5212: 374-389.