

# 基于调整学习的聚类算法

金萍<sup>1</sup>, 王浩<sup>1</sup>, 宗瑜<sup>2</sup>, 李明楚<sup>2</sup>

(1. 合肥工业大学 计算机与信息学院, 安徽 合肥 230009;

2. 大连理工大学 软件学院, 辽宁 大连 116621)

**摘要:**调整学习是一种逐步求精的近似学习方法,是提高局部搜索解质量的重要途径之一。该方法调用调整算子填平局部最优解陷阱,构造一系列不同粒度的搜索空间,降低局部最优解对解质量的影响。利用调整学习的基本原理设计了聚类算法框架 CAT-L,并给出了适合处理聚类问题的噪声平滑调整算子。实验对比了经典 FCM 算法与 FCM-CAT-L (以 FCM 算法作为 CAT-L 框架的聚类算子)算法的聚类质量。实验结果表明,调整学习方法对提高聚类质量是有效的。

**关键词:**调整学习;调整算子;局部搜索;聚类算法;FCM

中图分类号:TP301.6

文献标识码:A

文章编号:1673-629X(2009)02-0058-04

## Clustering Algorithm Based on Fine-Tuned Learning

JIN Ping<sup>1</sup>, WANG Hao<sup>1</sup>, ZONG Yu<sup>2</sup>, LI Ming-chu<sup>2</sup>

(1. School of Computer and Information, Hefei University of Technology, Hefei 230009, China;

2. School of Software, Dalian University of Technology, Dalian 116621, China)

**Abstract:** Fine-tuned learning, one of the important ways to increase the quality of solution of local search algorithm, is an approximation learning method. A fine-tuned operator is used to create a series of different granularity search spaces in which most traps haven't been smoothed, so the influence of the traps is reduced. In this paper, a clustering algorithm framework CAT-L (Clustering Algorithm based on Fine-tuned Learning), stimulated by fine-tuned learning, is proposed. Simultaneously, a noise smoothing fine-tuned operator, which adapts to deal with clustering problem, is designed. Compared the quality of classical FCM and FCM-CAT-L through experiments, the results show that fine-tuned learning is very effective for increasing the quality of cluster.

**Key words:** fine-tuned learning; fine-tuned operator; local search; clustering algorithm; FCM

### 1 概述

聚类分析是从大规模无先验知识的数据中获取有用信息的重要方法,广泛地应用于工程、商业、计算机科学、生命科学及社会科学等多个领域<sup>[1-3]</sup>。关于聚类的定义并没有统一标准,不同的应用和研究领域有着不同的聚类描述。文中研究的聚类问题是:给定  $N$  个数据对象  $x_i$  组成的数据集  $D$ , 定义一个‘编码’函数:

$$c(i) = k \Rightarrow i \in G_k \quad (1)$$

将数据集  $D$  分成多个簇  $\{G_k\}_{k=1}^K$ , 使得同簇数据对象相似,不同簇数据对象不相似。因此,文中研究的

聚类问题可以看作是给每个数据对象  $x_i (i = 1, 2, \dots, N)$  分配一个簇标号  $k \in \{1, 2, \dots, K\}$ , 从而使得评价函数  $Q(c)$  取值最小。即:

$$c^* = \arg \min_c \{Q(c)\} \quad (2)$$

其中:

$$Q(c) = \sum_{k=1}^K \frac{W_k}{N_k^2} \sum_{c(i)=k} \sum_{c(j)=k} D_{ij} \quad (3)$$

$D_{ij}$  是任意数据对象  $x_i, x_j$  之间的距离(通常是欧式距离),  $N_k = \sum_{i=1}^N I\{c(i) = k\}$  表示簇  $G_k$  中数据对象的个数,  $I(\cdot)$  为指示函数,表示数据对象  $x_i$  属于某个簇的概率。式(3)的  $\{W_k\}_{k=1}^K$  是  $K$  个簇的权重集合,因此  $Q(c)$  是簇内任意对象之间距离的平均加权和。为了便于调整式(2)的簇的粒度,通常将簇的权重  $W_k$  定义为  $N_k$  的函数。例如,  $\{W_k = N_k^2\}_{k=1}^K$  表示式(3)的每对数据对象都具有相同的影响,聚类算法得到了大小相近的聚类结果。设  $C$  是所有满足公式(3)的  $\{c(i)\}_{i=1}^N$  的集合,即  $C$  是所有满足公式(3)的聚类结

收稿日期:2008-05-29

基金项目:国家自然科学基金重大项目(90412007);国家自然科学基金(60503003);安徽省教育厅自然科学基金(KJ2008B133, KJ2008B05ZC)

作者简介:金萍(1978-),女,硕士,讲师,主要研究领域为数据挖掘、智能计算、计算机应用;王浩,教授,硕士生导师,主要研究方向为人工智能与数据挖掘。

果。求  $Q(c)$  取值最小的  $c^*(i)$  是经典的 NP - 难解问题<sup>[4]</sup>。大部分聚类算法并不计算任意点对之间的距离,而是事先设定簇的代表点,如均值<sup>[5]</sup>,中心点<sup>[6,7]</sup>等,再计算数据对象与代表点之间的距离。给每个簇设定代表点的目的是为了简化聚类问题,降低时间复杂度。但是,简化后的  $C$  中仍然包含了  $N^k$  个可能的编码结果。遍历  $C$  获得公式(2)的‘最优’聚类结果是不可行的。 $K$  - means 算法用严格梯度下降算法搜索公式(3)的聚类结果  $c(i)$ ,但是初始解对搜索结果和收敛速度的影响很大。为了避免初始点对聚类质量的影响,Babu 和 Murty 将模拟退火算法引入  $K$  - means 算法优化初始点的选择<sup>[8]</sup>。 $K$  - means 算法采用簇  $G_k$  中所有对象的均值作为该簇的代表点,因此受孤立点的影响很大。Kaufman 和 Rousseeuw 率先提出的 PAM<sup>[6]</sup> 算法以数据集  $D$  的实际数据对象为代表点。PAM 算法从一组初始中心点开始,用一个随机选择的非中心点替换某个初始中心点,如果这种替换能够获得更好的聚类结果,则保留替换。PAM 算法的时间复杂度大,显然不能适应大规模数据的处理。Ng 和 Han 在 PAM 的基础上提出了一种新的启发式搜索算法 CLARANS<sup>[7]</sup>,该算法采用随机重启搜索技术搜索  $C$  的子集发现聚类结果。CLARANS 算法是第一个成功地应用在空间数据挖掘领域的聚类算法,它克服了其它经典聚类算法不能处理大规模数据集的缺点。尽管 CLARANS 算法的执行速度比 PAM 算法快,但是它仍然属于慢速算法<sup>[9]</sup>。与前面介绍的几种聚类算法不同,FCM 算法认为数据对象  $x_i$  属于簇  $G_k$  的概率在  $[0,1]$  之间,即一个数据对象可能属于多个簇。FCM 算法虽然采用模糊数学的思想解决了簇边界数据对象的隶属问题,但是基于距离的度量方法仍然使其受到初始点、孤立点、局部最优等问题的困扰。Yager 和 Filev 在文献<sup>[10]</sup>中提出的 MM 方法能够很好地确定 FCM 的初始解,该算法将满足山脉函数的一组中心点作为候选中心点集合,然后调用 FCM 算法获得最终的聚类结果。一种启发式的相异性度量计算方法可以很好地避免小子簇抢夺大子簇数据对象的问题<sup>[11]</sup>。Kersten 则采用 city block 距离降低 FCM 算法受孤立点的影响<sup>[12]</sup>。前面所描述的聚类算法的本质都是采用局部搜索方法发现  $C$  中使得公式(3)局部最优的聚类结果。但是由于搜索空间  $C$  中布满了局部最优解的‘陷阱’,从而影响了局部最优解的质量,即聚类结果不能满足用户的需求。

图 1 给出了聚类算法的搜索空间及局部最优解。 $X$  轴表示可能的编码结果,即  $\{c(i) = k\}_{i=1}^N$ 。 $Y$  轴表示在编码结果  $\{c(i)\}_{i=1}^N$  下评价函数  $Q(c)$  的取值。从图中可以看出,搜索空间  $C$  中  $Q(c)$  取值的极小点很

多,这些极小点是局部最优解。大量局部最优解混淆了局部搜索算法,使其很难发现全局最优解,从而影响了最终的聚类质量。为了提高聚类质量将逐步求精的调整学习思想引入到聚类算法设计中。逐步求精调整学习通过调用一个设计合理的调整算子,构造原始搜索空间的一系列不同粒度的搜索空间。细粒度搜索空间中大量的局部最优解被‘填平’,从而降低了局部最优解对搜索算法的影响。在细粒度搜索空间中执行搜索算法获得的解作为粗粒度搜索空间搜索算法的输入,引导搜索算法产生新的搜索结果。如此继续直到恢复到原始搜索空间。在逐步求精思想的驱动下,给出了聚类算法框架 CAT - L(Clustering Algorithm based on fine - Tuning Learning),并设计了适合处理聚类问题的噪声平滑调整算子。最后,在 CAT - L 框架下,通过实验对比了经典的 FCM 算法和 FCM - CAT - L 的聚类结果。大量实验证明,CAT - L 算法框架对改进由公式(3)所描述的聚类算法解质量有明显的效果。

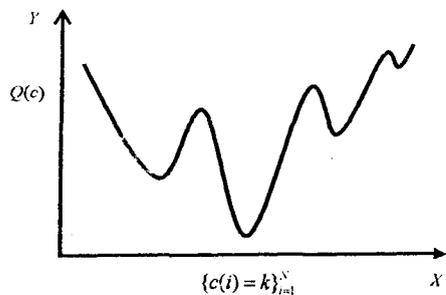


图 1 公式(3)的局部搜索解空间

## 2 调整学习原理及框架

当人们处理具有大量信息的复杂问题时,通常会从问题的一般特性出发,获得问题的概要,然后再对问题的细节进行评价,得到问题的真正答案。就好比观察远处物体一样,刚开始,由于受到距离和视觉失真等因素的影响,仅仅观察到物体的大概轮廓。但是,仍然可以从这个轮廓中得到物体的一些信息,比如物体的大概尺寸、颜色;物体是静止的还是运动的;物体是死的还是活的等概要。如果此时确定这个物体到底是什么,可能会得到错误的答案,但是却有了比较接近的选择范围。随着距离的减少,物体的更多细节信息变的越来越明显。最后,当所有的失真和偏差都移除时,可以知道这个物体到底是什么了。这种观察形式是建立在一系列逐步精化的近似学习的基础上的,称之为调整学习<sup>[13]</sup>。调整学习的基本框架如图 2 所示。从图中的基本框架中可以看出,调整学习的主要思路就是在原始问题的一系列变换问题中搜索问题的解(执行局部搜索)。调整学习方法包含两个重要的部分:问题

变换和局部搜索。调整学习首先对原始问题进行变换,产生一个新的问题,对新问题执行局部搜索,发现其局部最优解。然后将该局部最优解作为下一个变换问题的初始解,引导新一轮局部搜索。如此继续直到变换问题恢复到原始问题为止。调整学习的整个过程可以用图 3 来直观地表示。

- 1 给定原始输入。
- 2 对原始输入执行平均、聚合、近似或平滑操作。
- 3 对步骤 2 产生的输入执行局部搜索。
- 4 如果是原始输入,则退出,否则返回步骤。

图 2 调整学习的基本框架

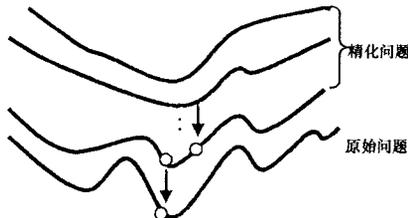


图 3 调整学习的直观表示

### 3 CAT-L 算法基本思想及其框架

调整学习是处理组合优化问题的重要方法之一<sup>[14]</sup>,该方法能够“填充”组合优化问题解空间中局部最优解陷阱,减少局部搜索算法掉入局部最优解的概率,从而达到提高组合优化问题解的质量的目的。由公式(3)所描述的聚类问题是典型的组合优化问题。这类聚类算法在解空间  $C$  中执行局部搜索算法,发现使得  $Q(c)$  取值最小的  $c^*(i) \in C$ 。由于解空间  $C$  中布满了局部最优解的陷阱,严重地影响了聚类算法的解的质量,限制了聚类算法的应用。因此,将调整学习方法应用到聚类算法设计中,给出了基于调整学习的聚类算法 CAT-L。

#### 3.1 CAT-L 算法的基本思想及框架

图 4 给出了 CAT-L 算法的基本步骤:

```

算法 1: CAT-L
输入: 距离矩阵  $X$ , 调整因子初始值  $\alpha_0$ , 阈值  $\tau$  及调整步长  $\lambda$ 
输出: 聚类结果  $c^*(i) \in C$ 

(1)  $d_{ij}^\alpha = d_{ij} \times (1 + \text{ran} \times \alpha)$ 
(2)  $S^\alpha = F\_Tuned(X, \alpha)$ 
(3) 调用公式(3)描述的聚类算法(如 PAM, CLARANS 或 FCM 等)产生初始聚类结果  $c^\alpha(i)$ 
(4) While( $\alpha \geq \tau$ )
    (4.1) 根据  $\lambda$  的调整  $\alpha$  得到新的调整因子  $\alpha'$ 
    (4.2)  $S^{\alpha'} = F\_Tuned(X, \alpha')$ 
    (4.3) 调用公式(3)描述的聚类算法产生聚类结果  $c^{\alpha'}(i)$ 
    (4.4)  $\alpha \leftarrow \alpha'$ 
(5)  $c^*(i) \leftarrow c^{\alpha'}(i)$ 
(6) Return  $c^*(i)$ 
    
```

图 4 算法 CAT-L

①初始化调整因子  $\alpha \leftarrow \alpha_0$ , 调用函数  $F\_Tuned(X, \alpha)$  对表示数据集  $D$  中元素之间关系的距离矩阵  $X$  进行变换,产生新的搜索空间  $S^\alpha$ 。

②在  $S^\alpha$  搜索空间中调用由公式(3)所描述的聚类算法,如 PAM, CLARANS, FCM 等产生初始聚类结果  $c^\alpha(i)$ 。

③以调整步长  $\lambda$ 、调整  $\alpha$ , 产生新的调整因子  $\alpha'$ , 调用  $F\_Tuned(X, \alpha')$  产生搜索空间  $S^{\alpha'}$ ; 以  $c^\alpha(i)$  作为被调用聚类算法的初始解,产生新的聚类结果  $c^{\alpha'}(i)$ , 如此执行直到  $\alpha < \tau$  为止。

函数  $F\_Tuned(\cdot)$  是图 2 所示的调整学习框架中描述的第 2 步的概化。它可以实现平均、聚合、近似或平滑中的任意一个操作。文中给出的  $F\_Tuned$  函数是以噪声平滑思想<sup>[14]</sup>为基础而设计的。图 5 所示的算法 2 描述了基于噪声平滑思想的  $F\_Tuned$  函数框架。

算法 2:  $F\_Tuned$

输入: 距离矩阵  $X$ , 调整因子  $\alpha$   
输出: 噪声平滑空间  $S^\alpha$

```

(1) for each  $d_{ij} \in X$  do
    (1.1) 产生随机数  $\text{ran} \in \{-1, 0, 1\}$ 
    (1.2)  $d_{ij}^\alpha = d_{ij} \times (1 + \text{ran} \times \alpha)$ 
(2) Return  $S^\alpha$ 
    
```

图 5 基于噪声平滑的  $F\_Tuned$  函数

$F\_Tuned$  函数通过向原始搜索空间中数据对象之间的距离  $d_{ij}$  添加由强至弱的噪声来构造一组逐渐平滑的近似搜索空间。对于  $X$  中的每个距离  $d_{ij}$ , 噪声法的基本步骤如下: 首先, 生成一个取值范围  $\{-1, 0, 1\}$  为的随机数; 其次根据噪声因子  $\alpha$  计算变换后的数据对象之间的距离  $d_{ij}^\alpha = d_{ij} \times (1 + \text{ran} \times \alpha)$ 。

#### 3.2 时间复杂度分析

图 5 所示的  $F\_Tuned$  函数处理每个数据对象之间距离  $d_{ij}^\alpha = d_{ij} \times (1 + \text{ran} \times \alpha)$  所需时间为  $O(1)$ , 因此处理  $N^2$  个距离需要时间为  $O(N^2)$ 。

图 4 所示的 CAT-L 算法的步骤(2)调用  $F\_Tuned$  函数对当前搜索空间进行变换操作所消耗的时间为  $O(N^2)$ 。步骤(3)调用聚类算法, 如 PAM, CLARANS 或 FCM 等产生初始聚类结果所需要的时间为  $O(N^2)$ 。步骤(4)完成构造一组平滑搜索空间并执行聚类算法生成对应搜索空间的聚类结果, 其时间复杂度为  $F\_Tuned$  函数的运行时间 + 聚类算法的运行时间。则步骤(4)的时间复杂度为  $((\alpha_0 - \tau) / \lambda) (O(N^2) + O(N^2)) = 2(\alpha_0 - \tau) / \lambda O(N^2)$ 。因此, 算法 CAT-L 算法所需要的时间为:  $2((\alpha_0 - \tau) / \lambda + 1) O(N^2)$ 。

### 4 实验结果及分析

根据图 4 描述的 CAT-L 算法步骤,以噪声平滑思想为基础设计的函数  $F\_Tuned$  为调整算子,以经典的 FCM 算法为聚类算子。实验平台采用 Windows XP, Matlab6.5 语言编程环境, Pentium IV 1.7GHz CPU 时钟频率, 512M 内存。为了更好地比较 FCM 算法和基于 CAT-L 框架的 FCM (FCM-CAT-L) 算法的聚类结果,分别在人工实验数据集和经典的 IRIS 数据集上进行实验。

#### 4.1 人工实验室数据集

通过比较输入数据和输出数据,可以更精确地评价聚类结果。文中在二维空间中随机产生符合不同参数的正态分布实验数据集 Dataset1,如表 1 所示。虽然每个样本所包含的聚类个数不同,但是样本中每个聚类所包含的数据对象个数却是相同的(200 数据对象/聚类)。

表 1 数据集 Dataset 1

标本集大小	1000	2000	3000	4000	5000
包含聚类个数	5	10	15	20	25
标本集大小	6000	7000	8000	9000	10000
包含聚类个数	30	35	40	45	50

采用两种不同的聚类算法对 10 个样本进行聚类,获得的聚类结果用 FCM 算法提供的平均目标函数值来评价,平均目标函数值越小说明聚类结果的质量越好。对实验数据集 Dataset1 中每个实验样本分别执行 20 次 FCM 算法和 FCM-CAT-L 算法,计算目标函数值的平均值,其实验结果如图 6 所示。可以观察到,在基于调整学习框架的聚类算法 FCM-CAT-L 的平均目标函数值有 8 次小于经典 FCM 算法的平均目标函数值。这个现象说明调整学习框架平滑了局部搜索算法 FCM 的搜索空间中的局部最小值陷阱,降低了 FCM 算法调入局部最优解的概率,提高了聚类质量。

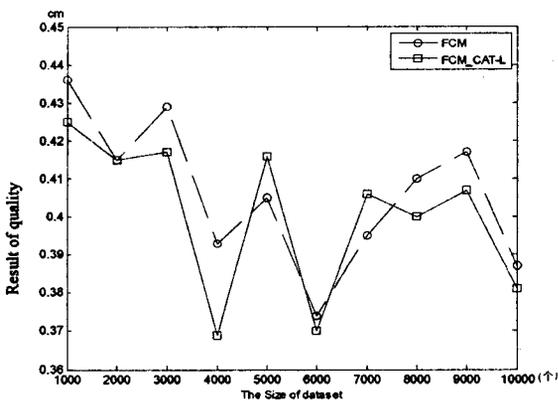


图 6 Dataset1 上的聚类质量对比

#### 4.2 IRIS 数据集

IRIS 数据集是模式识别和机器学习领域中测试

新方法性能的常用数据集。该数据集可以从 <http://www.isc.uci.edu/mllearn/MLRepository.html> 网站下载。IRIS 数据集包含三个子簇,即 iris setosa, iris versicolor 和 iris virginical。其中每个子簇由 50 个数据对象组成,每个数据对象由 4 个属性(sepal length、sepal width、petal length 和 petal width)表示。图 7 给出了在该数据集上分别执行 20 次 FCM 与 FCM-CAT-L 的算法质量对比(仍以目标函数值的均值作为衡量标准)。IRIS 数据集的子簇 iris versicolor 和 iris virginical 无法线性分离,基于调整学习的 FCM-CAT-L 算法仅仅改变了算法搜索空间的光滑程度,并没有改变原始问题的本质,所以同样不能很好地区分这两个子簇。但是从图中可以发现 FCM-CAT-L 算法由于采用调整学习方法来避免局部搜索算法 FCM 掉入局部最优解陷阱的概率,因此聚类质量得到了较好的提高。

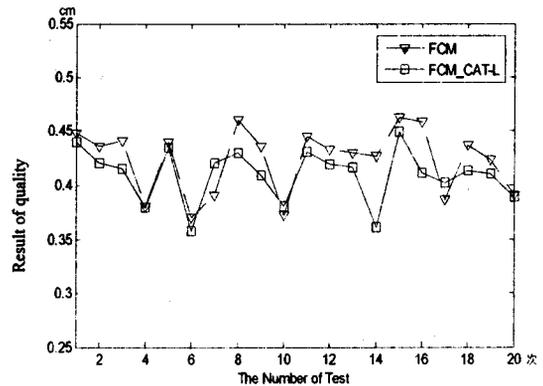


图 7 IRIS 数据集上的聚类质量对比

### 5 结束语

以组合优化模型设计的聚类算法,大多采用局部搜索方法在聚类解空间(搜索空间)中搜索使得公式(3)取值最小的聚类结果。由于解空间中布满了局部最优解陷阱,从而严重地影响了聚类质量。调整学习是一种近似学习方法,该方法调用调整算子构造原始搜索空间的一系列不同粒度的搜索空间。调整算子将搜索空间中大量的局部最优解填平,从而降低了局部搜索算法调入局部最优解的概率,提高了解的质量。文中利用调整学习的基本思想设计了聚类算法框架 CAT-L,并给出了噪声平滑调整算子。在该算法框架下,对经典的 FCM 算法进行了改进。实验结果表明,基于调整学习的聚类算法框架对提高聚类质量十分有效。

#### 参考文献:

[1] Xu Rui, Wunsch D. Survey of Clustering Algorithms[J].

表 1 文中算法和其他算法在取不同值时的比较

噪声标准差	PSNR(dB)							文中算法
	软阈值法	硬阈值法	软阈值法 <sup>[8]</sup>	模平方阈值法 <sup>[9]</sup>	尺度相关法 <sup>[4]</sup>	ENS法 <sup>[7]</sup>	PCA法 <sup>[10]</sup>	
10	22.2829	24.5054	23.9879	24.2307	24.3426	22.6896	23.4820	24.6884
20	21.3636	22.0245	22.3514	22.6754	21.9901	22.1122	22.7218	23.3174
30	20.4338	19.5824	20.5027	20.8775	19.4459	21.3667	21.7062	21.7577

表 2 文中算法分别结合提升小波变换与传统小波变换的比较

噪声标准差	PSNR(dB)		T(s)	
	W-文中算法	L-文中算法	W-文中算法	L-文中算法
10	24.6301	24.6884	2.85901	1.43702
20	23.2724	23.3174	3.08919	1.46612
30	21.7290	21.7577	3.13723	1.47379

上述传统去噪方法中的阈值估计采用  $\lambda(j) = \sigma j + \sqrt{2\log(N)}/\log(j+1)$ , 其中  $\sigma$  是根据中位法估计得到的噪声方差,  $N$  为各个高频子图的大小,  $j$  为分解尺度大小, 文中统一选择 3 层尺度分解。

### 5 结束语

提出了一种通过提升小波结合 DCT 变换的去噪新方法, 实验表明, 该算法很好地去除了高斯白噪声, 更多程度地保留了图像的细节信息, 该算法不依赖于对噪声方差进行估计, 直接利用 DCT 变换对高频各子带进行局部特征提取, 从而估计噪声能量的估计阈值, 而提升小波是一种空间域的小波构造方法, 适合硬件实现, 所以文中算法更具有实用价值。

### 参考文献:

- [1] Dono D L. De-noising by soft thresholding[J]. IEEE Transactions on information theory, 1995, 41(3):613-627.
- [2] 谢杰成, 张大力, 徐文立. 小波图像去噪综述[J]. 中国图象图形学报, 2002, 7(3):209-217.
- [3] Mallat S, Hwang W L. Singularity detection and processing with wavelets[J]. IEEE Transaction on IT, 1992, 38(2):617-643.
- [4] Xu Y, Weaver B, Healy D M. Wavelet transform domain filters: a spatially selective filtration technique[J]. IEEE transaction on Image Processing, 1994, 3(6):217-237.
- [5] Donoho D L, Johnstone I M. Wavelet shrinkage asymptopia [J]. Journal of Royal Statistical Society, 1995, 57(2):301-369.
- [6] Gao. Wavelet Shrinkage denoising using the non-negative-arrote[J]. Jcomput Graph Statist, 1998, 7(4):469-488.
- [7] 傅彩霞, 杨光. 一种新的具有增强效果的小波域图像去噪方法[J]. 中国图象图形学报, 2007, 12(1):51-55.
- [8] 王亚, 吕新华, 王海峰. 一种改进的小波阈值降噪方法及其 Matlab 实现[J]. 微计算机信息, 2006, 22(3):259-261.
- [9] 潘显兵. 一种改进的小波阈值降噪性能分析[J]. 微计算机信息(测控自动化), 2006, 22(7):112-113.
- [10] 芮挺, 王金岩, 沈春林, 等. 基于 PCA 的图像小波去噪方法[J]. 小型微型计算机系统, 2006, 27(1):158-161.
- [11] Daubechies I, Sweldens W. Factoring wavelet transforms into lifting steps[J]. J. Fourier - Annal. Appl, 1998, 4(3):245-267.

(上接第 61 页)

- IEEE Trans on Neural Network, 2005, 16(3):645-678.
- [2] Berkhin P. Survey of clustering data mining techniques[R]. San Jose, CA:[s. n.], 2002.
- [3] 周傲英, 钱卫宁. 从多角度分析现有聚类算法[J]. 软件学报, 2002, 13(8):1382-1394.
- [4] Jain A K, Dubes R C. Algorithms for clustering data[M]. Englewood Cliffs, New Jersey: Prentice Hall, 1998:89-131.
- [5] Hartigan J, Wong M. Algorithm ASI36: A k-means clustering algorithm[J]. Applied Statistics, 1979(28):100-108.
- [6] Kaufman L, Rousseeuw P J. Finding Groups in Data: an Introduction to Cluster Analysis[M]. New York: John Wiley & Sons, 1990.
- [7] Ng R, Han J. CLARANS: A method for clustering objects for spatial data mining[J]. IEEE Trans on Knowl, Data Eng., 2002, 14(5):1003-1016.
- [8] Babu G P, Murty M N. Simulated annealing for selecting optimal initial seeds in the K-means algorithm[J]. Indian Journal of Pure and Applied Mathematics, 1994, 25(1-2):85-94.
- [9] Wang Wei, Yang Jiong, Muntz R. STING: A statistical infor-

- mation grid approach to spatial data mining[C]//In Proceeding of the 23rd VLDB Conference. Athens, Greece:[s. n.], 1997:186-195.
- [10] Yager R, Filev D. Approximate clustering via the mountain method[J]. IEEE Trans. Syst., Man, Cybern., 1994, 24(8):1279-1284.
- [11] Araujo E O. A heuristic adjustment to the calculation of the dissimilarity in the FCM algorithm [C]//IFSA World Congress and 20th NAFIPS International Conference, Joint 9th. Vancouver, BC, Canada:[s. n.], 2001:25-30.
- [12] Kersten P. Implementation issues in the fuzzy c-medians clustering algorithm [C]//In Proc. 6th IEEE Int. Conf. Fuzzy Systems. Barcelona, Spain:[s. n.], 1997:957-962.
- [13] Coy S P, Golden B L, Runger G C, et al. See the Forest Before the Trees: Fine-Tuned Learning and Its Application to the Traveling Salesman Problem[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1998, 28(4):454-464.
- [14] Charon I, Hudry O. The noising method: A new method for combinatorial optimization [J]. Oper. Res. Lett., 1993, 14(3):133-137.