

# 基于方差优化谱聚类的热点区域挖掘算法<sup>\*</sup>

梁卓灵<sup>1</sup>, 元昌安<sup>2</sup>, 覃晓<sup>3\*\*</sup>

(1. 广西大学, 广西南宁 530004; 2. 广西科学院, 广西南宁 530007; 3. 南宁师范大学, 广西南宁 530000)

**摘要:**为改善交通拥堵的情况, 本文利用聚类分析方法对移动轨迹数据进行挖掘, 识别居民出行的热点区域。传统的 Ng-Jordan-Weiss (NJW) 谱聚类算法常使用 K-means 聚类算法来实现最后的聚类操作, 然而 K-means 聚类算法存在对初始值敏感、容易陷入局部最优的缺陷, 影响对热点区域的挖掘结果。因此, 本研究将方差优化初始中心的 K-medoids 聚类算法运用到谱聚类算法最后聚类阶段, 提出基于方差优化谱聚类的热点区域挖掘算法 (Hot Region Mining algorithm based on improved K-medoids Spectral Clustering, HRM-KSC), 然后在真实的轨迹数据集上进行试验。试验结果发现, HRM-KSC 算法聚类结果的轮廓系数更高, 表明 HRM-KSC 算法改善了 NJW 谱聚类算法, 提高了聚类质量。

**关键词:** K-medoids 算法 谱聚类 热点区域 停留点 交通拥堵

中图分类号: TP391 文献标识码: A 文章编号: 1005-9164(2020)06-0616-06

DOI: 10.13656/j.cnki.gxkx.20210119.003

## 0 引言

近年来, 城市的交通拥堵问题日益严重, 影响居民的出行以及城市的发展。为改善交通拥堵的情况, 可以通过聚类分析的方法对城市居民出行轨迹数据进行挖掘, 分析总结居民的出行规律及行为习惯, 从而合理地规划城市的公交线路并优化交通资源的配置, 为居民推荐合理的出行方式<sup>[1,2]</sup>。

Ng-Jordan-Weiss (NJW) 谱聚类算法是由 Ng 等<sup>[3]</sup>提出的, 属于经典的多路谱聚类算法。NJW 谱聚类算法通过样本数据点的相似矩阵和度矩阵计算求得 Laplacian 矩阵, 并由 Laplacian 矩阵的前  $k$  个最

大特征值对应的特征向量建立一个  $n \times k$  阶的矩阵。最后把矩阵中的每一行看作是空间中的点, 用 K-means 聚类算法进行聚类。但 K-means 聚类算法<sup>[4]</sup>利用簇内点的平均值作为簇的中心点, 对孤立点敏感, 且其受初始值影响, 易陷入局部最优解, 不利于对热点区域的聚类挖掘。

轨迹数据是在空间无规则分布的且分布不均匀的数据。K-medoids 聚类算法<sup>[5]</sup>总是选择簇中位置最接近簇中心的对象作为簇的中心点, 能消除对孤立点和噪声点的敏感性, 比 K-means 聚类算法更适用于轨迹数据的聚类。但 K-medoids 聚类算法对初始中心点的选取仍是随机的, 而利用方差优化初始中心

<sup>\*</sup> 国家自然科学基金项目 (61962006, 61802035, 61772091), 广西科技开发项目 (AA18118047, AD18126015) 和广西自然科学基金项目 (2018GXNSFDA138005) 资助。

### 【作者简介】

梁卓灵 (1996—), 男, 在读硕士研究生, 主要从事数据挖掘研究, E-mail: 1104589997@qq.com。

### 【\*\*通信作者】

覃晓 (1973—), 女, 副教授, 主要从事计算机图像处理与数据挖掘研究, E-mail: 7670172@qq.com。

### 【引用本文】

梁卓灵, 元昌安, 覃晓. 基于方差优化谱聚类的热点区域挖掘算法[J]. 广西科学, 2020, 27(6): 616-621.

LIANG Z L, YUAN C A, QIN X. Hot Region Mining Algorithm based on Variance Optimization Spectrum Clustering [J]. Guangxi Sciences, 2020, 27(6): 616-621.

的 K-medoids 聚类算法可改善其对中心点的选取, 实现对于热点区域的挖掘。

本文将方差优化初始中心的 K-medoids 聚类算法<sup>[6]</sup>运用到 NJW 谱聚类算法的最后聚类阶段, 提出基于方差优化谱聚类的热点区域挖掘算法 (Hot Region Mining algorithm based on improved K-medoids Spectral Clustering, HRM-KSC), 然后在真实的轨迹数据集上进行试验, 证明 HRM-KSC 算法的聚类效果。

## 1 K-medoids 聚类算法的基本原理

K-medoids 聚类算法通常用一个代价函数来评估聚类质量的好坏, 以重复迭代的方式寻找到最好的聚簇划分及聚簇中心点。这里使用聚类误差平方和来评估聚类结果质量, 定义如下:

$$E = \sum_{j=1}^k \sum_{x \in C_j} |x - O_j|^2, \quad (1)$$

其中,  $x$  为各个簇类  $C_i$  中的样本,  $O_j$  为其聚类中心。

K-medoids 聚类算法步骤可描述如下:

Step 1: 从数据集中随机选择  $k$  个对象, 作为初始的聚类中心点;

Step 2: 根据与中心点距离的远近, 将数据集中的其他非中心点对象分配到最近中心点所在的簇类;

Step 3: 重新计算每个簇的中心点位置, 使其到该簇其他样本的距离总和最小;

Step 4: 重复执行 Step 2 和 Step 3, 直到聚类误差平方和基本不变, 达到指定要求为止。

一般 K-means 聚类算法是通过计算簇类点的平均值来选取中心点, 其对孤立点敏感, 选取的中心点可能不存在。与 K-means 聚类算法不同, K-medoids 聚类算法在迭代选取中心点时, 总是在中心点的周围选择样本点作为新的中心点, 消除了对孤立点的敏感性。

## 2 基于方差优化初始中心点的 K-medoids 聚类算法

方差优化初始中心点的 K-medoids 聚类算法是对 K-medoids 聚类算法的改进, 称之为 Standard-Deviation as radius of neighborhood (SD\_K-medoids) 算法。该算法利用方差是反映样本分布密集或疏散程度的特性<sup>[7]</sup>, 以方差度量样本分布的密集程度, 采用样本标准差为邻域半径, 从不同的样本分布密集区域中选择样本作为 K-medoids 聚类算法的初始聚类

中心。

### 2.1 基本概念描述

设样本数据集为  $X = \{x_i | x_i \in R^p, i = 1, 2, \dots, n\}$ , 则样本  $x_i$  和  $x_j$  间的欧式距离  $\text{dist}(i, j)$  可定义为

$$\text{dist}(i, j) = \sqrt{\|x_i - x_j\|}. \quad (2)$$

为消除样本之间的差异性, 需对样本进行标准化。本文采用最大最小标准化方法, 将样本的属性值  $x'_{ij}$  映射到  $[0, 1]$  区间, 公式如下所示:

$$x'_{ij} = \frac{x_{i,j} - \min(X_{:,j})}{\max(X_{:,j}) - \min(X_{:,j})}. \quad (3)$$

方差是各个数据与平均数之差的平方和的平均数, 而标准差是方差的算术平方根。因此样本  $x_i$  的方差  $V_i$  和标准差  $\text{std}_i$  可分别定义如下:

$$V_i = \frac{1}{N-1} \sum_{j=1}^N \|x_j - x_i\|^2, \quad (4)$$

$$\text{std}_i = \sqrt{V_i}, \quad (5)$$

其中,  $N$  为样本总数。

SD\_K-medoids 算法以样本的标准差为邻域半径  $r$ , 其值与初始聚类中心相关, 即  $r = \text{std}_i = \sqrt{V_i}$ , 不是固定值。

### 2.2 SD\_K-medoids 算法描述

SD\_K-medoids 算法首先将样本标准化, 然后计算数据集中各样本的方差, 选择方差最小的样本作为第一个初始聚类中心加入中心点集; 然后计算聚类中心的领域半径, 从数据集中删除该样本点及该样本领域中的所有数据样本, 在剩余数据样本中寻找方差最小的数据样本作为中心点, 重复执行, 直到选出  $k$  个初始中心点。剩余步骤则与 K-medoids 聚类算法相同: 将数据集中的样本分配给与其距离最近的中心点, 计算聚类误差平方和, 计算新的中心点位置; 重复执行, 当聚类误差平方和不变, 结束算法。

其中, SD\_K-medoids 算法通过方差反映样本分布的特性, 每次可以在最密集的区域选取到中心点, 使得初始类簇的划分更贴近数据集的真实分布, 降低算法收敛的迭代次数, 增加其收敛到全局最优解的概率。

使用样本标准差作为领域半径, 每次选取一个中心点后, 要把其领域内的样本点去除, 从而避免初始中心点可能位于同一簇类的缺陷, 使初始中心点尽可能地分布在不同的簇类。

所以, 面对轨迹数据无规则分布、分布密度不均

匀的特点时,SD\_K-medoids 算法可以尽快找到好的热点区域初始中心点,加快收敛速度,增加了收敛到全局最优解的可能。

### 3 基于方差优化谱聚类的热点区域挖掘算法

对于居民出行热点区域的挖掘,就是寻找居民频繁出行的区域,发现居民出行停留时间较长的聚集地点,因此需对居民出行停留点进行聚类操作。在聚类操作之前,本文主要借鉴文献[8]的方法,从移动对象的轨迹数据中提取居民出行停留点,详细方法本文不再具体说明。

针对谱聚类最后聚类阶段 K-means 聚类算法的不足,用 SD\_K-medoids 算法来替代,提出基于方差优化谱聚类的热点区域挖掘算法(Hot Region Mining algorithm based on improved K-medoids Spectral Clustering,HRM-KSC)。HRM-KSC 算法的基本思想是把居民出行停留点看作待聚类的空间样本点,在 NJW 谱聚类算法<sup>[9]</sup>中把停留点集映射到相似度矩阵和拉普拉斯矩阵中,并将拉普拉斯矩阵的特征向量构建为特征矩阵,最后改用 SD\_K-medoids 算法对特征矩阵的每行元素进行聚类。

#### 3.1 相似度矩阵的构造

谱聚类把居民出行停留点集看作是一个无向图  $G(V,E,A)$  的顶点集合  $V$ ,由边集  $E$  把停留点连接起来,而图中权重集  $A$  表示停留点间的相似性。通过权重来构建停留点集的相似度矩阵,停留点间的相似性常用高斯函数  $w_{ij}$  来计算:

$$w_{ij} = \begin{cases} \exp(-\text{dist}^2(s_i, s_j)/2\sigma^2), & i \neq j \\ 0, & i = j \end{cases}, \quad (6)$$

其中,  $s_i$  和  $s_j$  分别表示停留点  $i$  和  $j$  的特征向量,  $\sigma$  为尺度参数。

#### 3.2 拉普拉斯矩阵的构造

本文对停留点集的构建采用的是规范的拉普拉斯矩阵  $L_{\text{sym}}$ ,其构造公式如下:

$$L_{\text{sym}} = E - D^{-\frac{1}{2}} W D^{-\frac{1}{2}}, \quad (7)$$

其中,  $W$  为相似度矩阵;  $D$  为图的度矩阵,其主对角线上的元素为相似度矩阵  $W$  的第  $i$  行元素之和,计算如下:

$$D_{ii} = \sum_{j=1}^n W_{ij}. \quad (8)$$

在构建停留点集的相似度矩阵及拉普拉斯矩阵后,将拉普拉斯矩阵前  $k$  个特征向量构建为特征矩阵,最后用 SD\_K-medoids 算法对矩阵的每行元素进

行聚类。

HRM-KSC 算法流程如图 1 所示,具体过程描述如下:

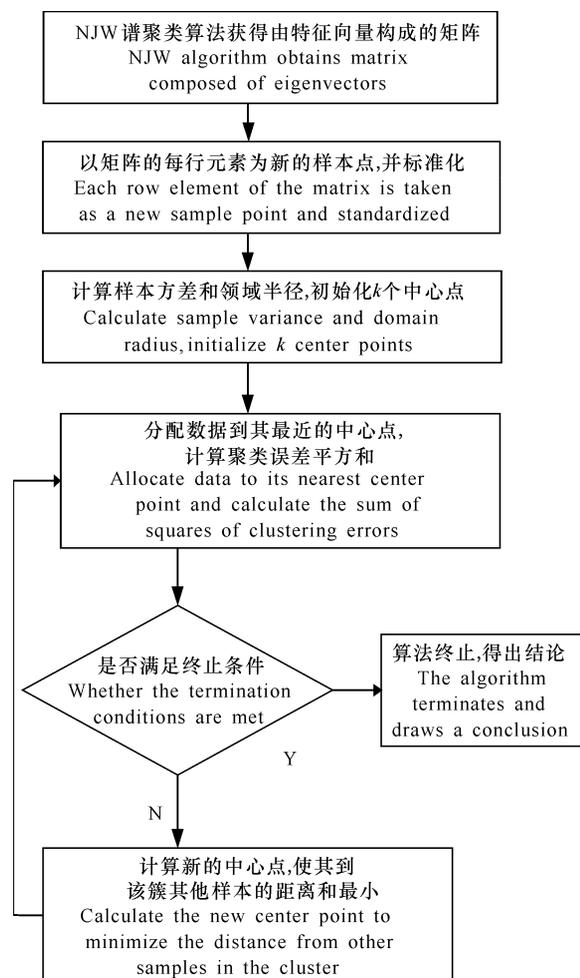


图 1 HRM-KSC 算法流程图

Fig. 1 Flow chart of HRM-KSC

Step 1: 利用公式(6)计算停留点集的相似度矩阵;

Step 2: 利用公式(7)和(8)计算停留点集的拉普拉斯矩阵;

Step 3: 把拉普拉斯矩阵前  $k$  个特征向量组成的特征矩阵归一化为矩阵  $Y = [y_1, y_2, \dots, y_k]$ , 把矩阵  $Y$  的每一行向量作为一个数据点  $y_i'$ ;

Step 4: 把所有数据点  $y_i' (i=1, 2, \dots, k)$  作为新的样本点,根据式(3)对样本进行标准化。

Step 5: 根据式(4)计算数据集中各样本的方差,如  $V_i$  表示第  $i$  个样本的方差值;其次初始化中心点集  $M$  为空,即  $M = \{\}$ 。

Step 6: 从数据集  $X = \{x_1, x_2, \dots, x_n\}$  中寻找方差最小的样本  $x_{\min}$ , 将其作为第一个类簇的初始聚类中心  $C_1$  加入到中心点集中,即  $M = M \cup \{C_1\}$ ; 根据

式(5)计算邻域半径  $r_1$ ,从数据集中删除该样本以及该样本领域中的所有数据样本。

Step 7:重复执行 Step 6,直到选出  $k$  个初始中心点,即  $|M|=k$ 。

Step 8:将数据集中的样本分配给与其距离最近的中心点,由公式(1)计算聚类误差平方和。

Step 9:计算每个簇的新中心点位置,使其到该簇其他样本的距离总和最小。

Step 10:重复执行 Step 8—Step 9,若聚类误差平方和变化不大,结束算法;否则继续迭代。

#### 4 实验分析

为测试 HRM-KSC 算法的性能,本文使用微软亚洲研究院的 geolife 数据集,从 2008 年 8 月到 10 月的轨迹数据中提取出居民出行停留点集。其中,居民停留点的提取参照文献[8]中的方法。本次实验在 Win10 64 bit 操作系统,8 GB 内存,CPU 2.60 GHz 的环境下进行,用 Python 语言实现。

为度量 2 种算法在实验中的表现,采用 SC 轮廓系数作为评价指标。SC 轮廓系数常用于度量未知类别的聚类数据集,表示聚类结果中各簇类的稠密程度及簇间的离散程度。

SC 轮廓系数计算公式如下:

$$SC(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}, \quad (9)$$

其中,  $a(i)$  表示计算样本  $i$  到同簇类其他样本的平均距离,  $b(i)$  表示计算样本  $i$  到其他样本的平均距离。SC 在  $[-1, 1]$  区间内取值。当 SC 越接近 1 时,表示

聚类效果越好。

本次实验测试了 2 种算法在用户停留点集上的聚类效果,在一定区间内选取 3 种较好的结果,如表 1 所示。

表 1 算法在停留点数据集上聚类结果

Table 1 Algorithm of clustering results on stay points dataset

算法 Algorithm	参数 Parameter	SC 轮廓系数 Silhouette coefficient	运行时间 Running time (s)
NJW	$k=3, \sigma=10$	0.616	3.609 3
	$k=4, \sigma=15$	0.603	3.562 5
	$k=5, \sigma=20$	0.628	3.625 0
HRM-KSC	$k=3, \sigma=10$	0.682	5.521 2
	$k=4, \sigma=15$	0.627	5.562 8
	$k=5, \sigma=20$	0.630	5.672 6

观察表 1 中 2 种算法在停留点数据集上的表现,发现 HRM-KSC 算法在选取相同参数的情况下,轮廓系数指标均比 NJW 谱聚类算法高,表明 HRM-KSC 算法的聚类结果中同簇类点更紧密,不同簇类点更高散,聚类结果更合理。

为更进一步展示 2 种算法的聚类结果,采用 Python 的 matplotlib 库,以经纬度为坐标画出不同参数条件下的聚类结果(图 2—4)。从图中可以看出,在相同参数条件下,HRM-KSC 聚类划分结果更合理,尤其在图 2 和图 3 中表现更明显,其原因是 NJW 谱聚类算法在最后阶段所使用的 K-means 算法,对于初始中心点的选取不够理想,影响了聚簇的划分效果。

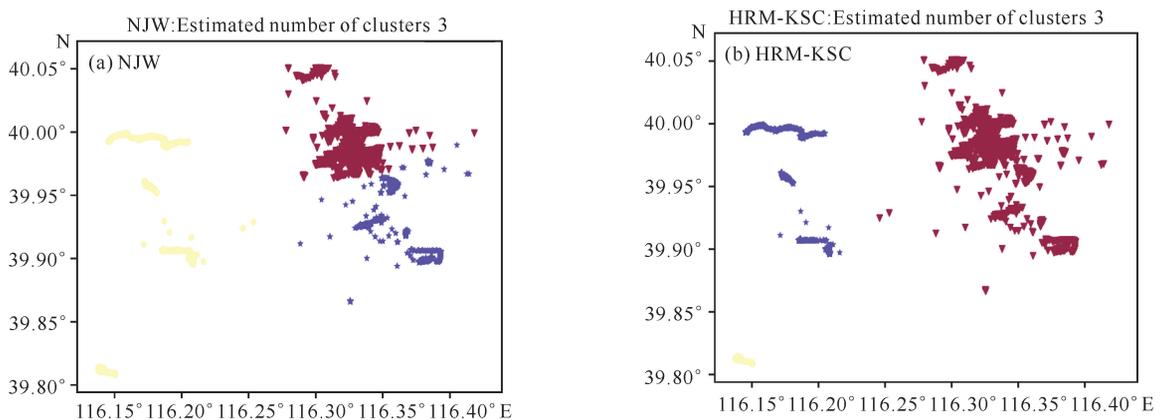
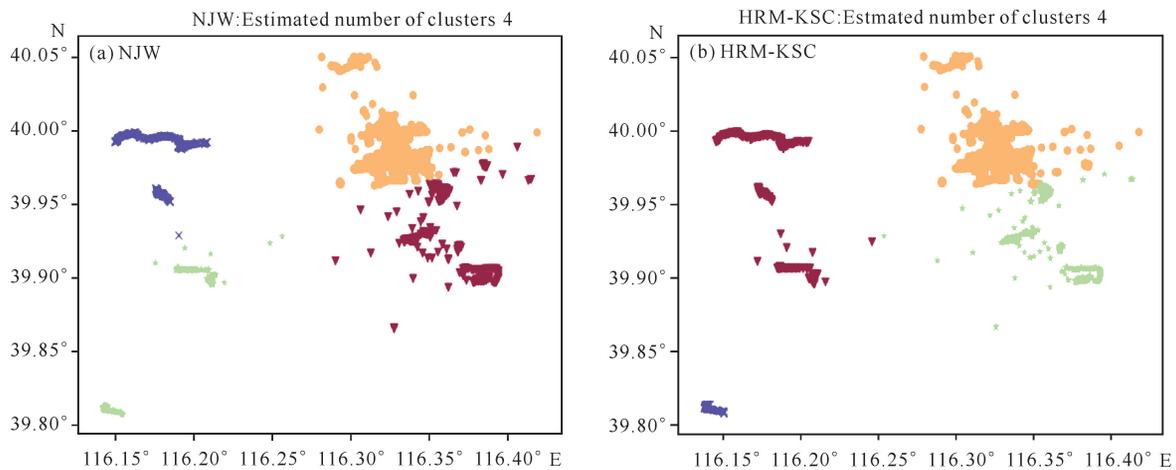
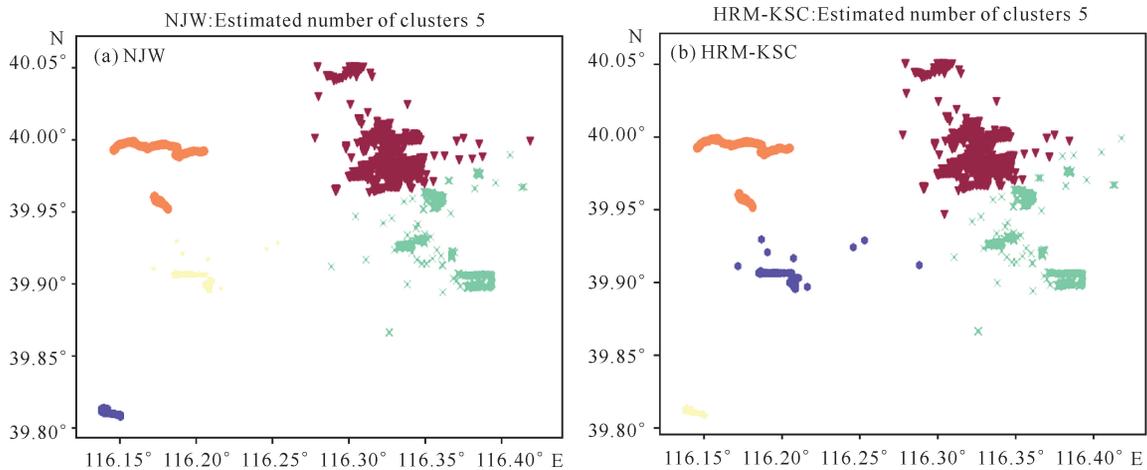


图 2  $k=3, \sigma=10$  时的实验结果

Fig. 2 Experimental results when  $k=3, \sigma=10$

图 3  $k=4, \sigma=15$  时的实验结果Fig. 3 Experimental results when  $k=4, \sigma=15$ 图 4  $k=5, \sigma=20$  时的实验结果Fig. 4 Experimental results when  $k=5, \sigma=20$ 

## 5 结论

本文针对 NJW 谱聚类算法最后阶段的 K-means 聚类算法对初始点敏感的缺陷, 利用 SD\_K-medoids 算法计算样本方差和领域半径, 优化对初始中心点的选取, 提出基于方差优化谱聚类的热点区域挖掘算法 (HRM-KSC)。在居民停留点数据集上进行 HRM-KSC 算法和 NJW 谱聚类算法的对比实验, 结果表明 HRM-KSC 算法的聚类质量更高, 聚类效果更好。后续期望改善谱聚类算法中高斯函数尺度参数的选取, 以及研究如何确定聚类数目, 以进一步提高谱聚类算法的聚类质量。

### 参考文献

[1] WEI W, QI Y. Information potential fields navigation in wireless ad-hoc sensor networks [J]. *Sensors*, 2011, 11(5):4794-4807.

[2] WEI W, XU Q, WANG L, et al. GI/Geom/1 queue based on communication model for mesh networks [J]. *International Journal of Communication Systems*, 2014, 27(11):3013-3029.

[3] NG A Y, JORDAN M I, WEISS Y, et al. On spectral clustering: Analysis and an algorithm [C]. *Neural Information Processing Systems*, 2001:849-856.

[4] ASHBROOK D, STARNER T. Using GPS to learn significant locations and predict movement across multiple users [J]. *Personal and Ubiquitous Computing*, 2003, 7(5):275-286.

[5] 谢娟英, 郭文娟, 谢维信. 基于邻域的 K 中心点聚类算法 [J]. *陕西师范大学学报: 自然科学版*, 2012, 40(4):16-22.

[6] 谢娟英, 高瑞. 方差优化初始中心的 K-medoids 聚类算法 [J]. *计算机科学与探索*, 2015, 9(8):973-984.

[7] 谢娟英, 高瑞. Num-近邻方差优化的 K-medoids 聚类算法 [J]. *计算机应用研究*, 2015, 32(1):30-34.

[8] 张伟玲.基于轨迹数据的城市交通需求热点区域推荐研究[D].兰州:兰州交通大学,2017.

[9] 覃晓,梁伟,元昌安,等.基于遗传优化谱聚类的图形分割方法[J].计算机科学,2017,44(1):100-102,133.

---

## Hot Region Mining Algorithm based on Variance Optimization Spectrum Clustering

LIANG Zhuoling<sup>1</sup>, YUAN Chang'an<sup>2</sup>, QIN Xiao<sup>3</sup>

(1. Guangxi University, Nanning, Guangxi, 530004, China; 2. Guangxi Academy of Sciences, Nanning, Guangxi, 530007, China; 3. Nanning Normal University, Nanning, Guangxi, 530001, China)

**Abstract:** In order to improve the traffic congestion, this article uses the cluster analysis approach to mine the mobile trajectory data and identify the hot region of residents' travel. The traditional Ng-Jordan-Weiss (NJW) spectral clustering algorithm often uses K-means clustering algorithm to achieve the final clustering operation. However, K-means clustering algorithm has the disadvantages of being sensitive to the initial value and easy to fall into the local optimum, which will affect the mining results of hotspot area. Therefore, the K-medoids clustering algorithm of variance optimization initial center is applied to the final clustering stage of the spectral clustering algorithm, and a Hot Region Mining algorithm based on improved K-medoids Spectral Clustering (HRM-KSC) is proposed, and then experiment on real trajectory data sets. The experiment results find that the HRM-KSC algorithm clustering results have higher silhouette coefficient, which indicates that the HRM-KSC algorithm improves the NJW spectral clustering algorithm and the clustering quality.

**Key words:** K-medoids algorithm, spectral clustering, hot region, stop point, traffic congestion

责任编辑:米慧芝



微信公众号投稿更便捷

联系电话:0771-2503923

邮箱:gxkx@gxas.cn

投稿系统网址: <http://gxkx.ijournal.cn/gxkx/ch>