

K-means 算法初始聚类中心选择的优化^①

郁启麟

(中国矿业大学 计算机科学与技术学院, 徐州 221116)

摘要: 迄今为止, 在数据挖掘领域, 人们已经实现了多种聚类算法, 其中使用最广泛的当属 K-means 聚类算法。然而, 在数据挖掘中, K-means 算法面临的一个主要问题就是初始中心点选择问题。本文提出了一种结合关系矩阵和度中心性(Degree Centrality)的分析方法, 从而确定 K-means 算法初始的 k 个中心点。与传统方法相比, 本文算法可得到更加优质的聚类结果。实验结果表明该算法的有效性和可行性。

关键词: 数据挖掘; 度中心性; K-means 算法; 聚类

Optimization of Initial Clustering Centers Selection Method for K-Means Algorithm

YU Qi-Lin

(School of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: So far, in the field of data mining, people have achieved a variety of algorithms of clustering. And the most widely used is K-means clustering algorithm. But the main problem of K-means is the initial center selection problem. In this paper, a method is proposed to determine the initial K centers of the K-means algorithm through the relationship matrix and the Degree Centrality. Compared with the traditional algorithm, the proposed algorithm can get the better clustering result. Experimental results have proved the validity and feasibility of this algorithm.

Key words: data mining; degree centrality; K-means algorithm; clustering

1 引言

随着互联网的不断发展, 人们已经进入到大数据时代, 并且已经真正体会到无边际的海量数据。数据挖掘技术的实现, 使人们可以利用这些海量数据, 发掘出可供人们决策的知识。现有的数据挖掘方法有多种, 主要包括关联规则分析、聚类分析、离群点分析、分类等。其中聚类是一种无监督学习的分类技术, 聚类的目的是使同一类中的数据相似度尽可能高, 而且不同类的相异度也尽可能高。从而得到数据中潜在的分类信息。

主要的聚类算法有: 基于划分方法、基于层次方法、基于密度方法、基于网格方法和基于模型方法。K-means 算法是一种基于划分的聚类分析方法, 该算法的运行效率较高, 因此广泛应用于各个领域的聚类分析中, 目前的许多算法都是围绕着它进行创新和拓展。但是, 在传统的 K-means 聚类分析中存在很多缺

陷: (1)在 K-means 算法中, k 是需要事先给定的。(2)在 K-means 算法中, 初始中心的选择对聚类结果影响比较大, 若初始聚类中心选择不合适, 那么就无法得到预期的聚类结果, 这也是 K-means 算法的一个缺点。(3)一些噪声点和孤立点会对最终的聚类结果产生较大的影响。

目前, 针对以上 K-means 算法的缺点, 很多学者提出了对 K-means 算法的优化方法, 如文献[1]采用密度敏感的相似性度量计算对象密度的方法产生初始类中心, 从而优化聚类结果的稳定性; 文献[2]提出一种基于人工鱼群的优化算法 AFS-KM, 利用信息增益对属性进行加权, 从而计算实体之间的距离。文献[3]通过找出相距最远的数据对象作为初始聚类中心, 然后对该聚类进行分裂, 反复迭代直到找出指定个数的初始聚类中心; 文献[4]结合 Ap 算法和最大最小距离算法确定 K-means 算法的最佳聚类个数。文献[5]利用大

^① 收稿时间:2016-08-01;收到修改稿时间:2016-09-23 [doi:10.15888/j.cnki.csa.005733]

数据技术, 结合 Hadoop 平台的 map 和 reduce 框架优化 K-means 算法; 文献[6]提出了一种新的 NDK-means 方法, 它通过标准差确定有效密度半径, 然后挑取高密度区域中的具有代表性的样本点, 用这些样本点作为初始聚类中心; 文献[7]基于结果敏感性和局部最优而提出了一种 K-meansCAN 算法, 利用不同聚类结果的子簇的交集建立带权连通图, 根据图中各节点的连通性合并子簇; 文献[8]将 K-means 算法和蚁群算法相结合, 提高了聚类质量; 文献[9]采用密度方法和对象间的距离确定初始聚类中心, 选择相距最远的 k 个处于高密度区域的点作为初始聚类中心. 文献[10]利用核系数解决非凸问题, 确定合适的聚类个数. 文献[11]利用最大最小距离算法, 根据已经选取到的中心点, 选取与之距离乘机最大的的高密度点作为当前初始中心点.

本文在研究 K-means 算法及其一些改进算法的基础上, 提出一种新的选取初始聚类中心的方法, 该方法与关系对称矩阵和度社会网络分析中的度中心性相结合确定初始聚类中心, 将所得到的聚类中心应用于聚类算法当中, 在稳定聚类结果的同时, 使得聚类结果有了较大提高.

2 K-means算法简介

K-means 算法根据聚类的个数 k , 将已有的数据集划分成 k 个簇. 算法采用迭代更新的方法, 在第一轮中, 根据随机选定的 k 个初始中心点将对象集划分成 k 个初始簇, 之后根据每个簇的中心迭代重新划分每个对象所属的类, 而每个簇的平均值将被作为下一轮迭代的中心点. 直到中心点不再发生改变, 即产生了最后的聚类结果.

2.1 K-means 算法的主要步骤

假设将数据集 D 包含 n 个数据对象. 该算法将 D 中的对象分配到 k 个簇 W_1, W_2, \dots, W_k 中, 每个簇的中心设为 c_1, c_2, \dots, c_k , 其中 $c_i = \frac{1}{n_i} \sum_{x \in w_i} x$, 其中 n_i 是簇 W_i 中数据点的个数. 对象 $x \in w_i$ 与该簇的代表 c_i 之间的欧式距离用 $dist(x, c_i)$ 表示, 聚类效果的好坏用目标函数 $E = \sum_{i=1}^k \sum_{x \in w_i} dist(x, c_i)^2$, 目标函数 E 就是每个数据点与其所在簇的簇中心的距离总和, 随着聚类次数不断增加, E 值也会动态的改变, 理想状况下, E 值会逐渐收缩变小, 簇内对象的相互距离会变小, 簇间的相

互距离会逐渐变大. 因此, 算法通过不断寻求更加小而稳定的 E 值来寻求好的聚类方案, 当 E 逐渐收缩到极小值时, 会产生更好的聚类结果.

2.2 K-means 算法描述

算法: K-means

输入: k : 簇的书目; D : 包含 n 个对象的数据集.

输出: K 个簇的集合.

- (1) 选择 k 个对象作为初始的聚类中心;
- (2) REPEAT;
- (3) 根据簇中对象的均值, 将每个对象分配到最相似的簇;
- (4) 更新簇均值, 即重新计算每个簇的均值;
- (5) 计算 E 值, 直到 E 值不再发生改变.

3 度中心性简介

度中心性(Degree Centrality)是在社会网络分析中分析节点在整个网络中重要程度的一个很重要和直接的方法. 与一个节点相连接的其他节点个数越多, 就表示这个节点的度中心性越高, 那么这个节点在网络中的重要性就越高.

在拥有 N 个节点的无向图 G 中, 节点 i 的度中心性表示该节点与其它 $N-1$ 个节点的联系程度. 即 $C_D(N_i) = \sum_{j=1}^N x_{ij} (i \neq j)$, $\sum_{j=1}^N x_{ij}$ 用于计算节点 i 与其它 $N-1$ 个节点的直接连接数量, $i=j$ 表示节点自身与自身的连接可以忽略不计. 度中心性的计算可以简单地将节点 i 在矩阵中对应的行或列所在的单元格值加总.

度在有向网络图中分为入度和出度, 例如微博中的关注关系. 因为本文将相互距离小于阈值的两个节点看作是相互连接的, 所以关系对称矩阵转化为无向图, 不区分出度和入度.

4 初始中心点的确定

针对初始中心点对聚类结果的影响, 本文提出了一种基于在关系矩阵中测量度中心性的方式优化初始中心点的选择. 首先, 将对象集 N 内的节点计算两两之间的距离, 因为不同的距离计算方法不会对本算法造成大的影响, 所以为了降低计算量, 本文采用曼哈顿距离. 设立一个阈值 L , 根据反复测试, L 取任意两个节点之间平均距离的一半. 两个节点之间的距离如果小于这个阈值, 建立节点之间的关系对称矩阵时,

我们将值设置为 1, 即认为这两个节点在网络中是相互连接的; 如果距离大于阈值, 则设为 0, 即认为这两个节点在网络中是无连接的. 遍历所有对象的行向量, 将度中心性最高的节点设为初始中心点, 并将与之相连的节点从矩阵中删除. 继续迭代遍历剩下的节点, 直到找到 k 个中心点.

设目标对象集 $N=\{X_1, X_2, X_3, \dots, X_n\}$, 包含 n 个对象, 每个对象有 m 个属性, 设每个对象 $X_i=\{x_{i1}, x_{i2}, \dots, x_{im}\}$, 从数据集 N 中选出 k 个中心点.

算法描述如下:

(1) 预处理数据集 N .

(2) 计算所有任意两个对象之间的曼哈顿距离, 设为 $dist(X_i, X_j) = \sum_{k=1}^m |x_{ik} - x_{jk}|$.

(3) 计算平均距离 $avg = \frac{1}{N} \sum_{\substack{X_i \in N \\ X_j \in N \\ i \neq j}} dist(X_i, X_j)$, 并

设阈值 $L=avg/2$, 建立节点之间的距离矩阵

$$R = \begin{pmatrix} d_{11} & \dots & d_{1n} \\ \vdots & \ddots & \vdots \\ d_{n1} & \dots & d_{nn} \end{pmatrix}$$

将节点间距离值 $dist(X_i, X_j)$ 大于阈值

L 的, 在矩阵中将相应的距离改为 0, 即认为这两个节点在矩阵网络中是无连接的, 小于阈值 L 的设为 1, 即认为这两个节点在矩阵网络中是有链接的. 由此距离

矩阵 R 变化为 $\begin{pmatrix} 0 \dots 1 \\ \vdots \ddots \vdots \\ 1 \dots 0 \end{pmatrix}$ 格式的矩阵.

(4) 遍历所有节点, 找出度中心性最高的节点, 然后在矩阵中删除该节点, 由于类中心点相互之间的距离应该尽可能远, 且相互连接的节点是抱团存在的, 所以删除与之相连接的 p 个节点, 所以 n 阶矩阵转变为 $n-p+1$ 阶矩阵.

(5) 在形成的新矩阵中继续找出度中心性最高的节点, 设为第 2 个中心点, 并在方阵中删除与之相连接的节点. 利用迭代算法继续循环遍历直到找出第 k 个中心点.

5 实验仿真分析

图 1 为本文算法的流程图. 为了方便计算, 并能表示出原始算法与改进算法的区别, 所以本文使用 java 语言随机生成 7 维的仿真数据对象, 因为现实数据中每一维的差距有限, 所以将每一维的属性用

0-200 的整数型数字表示. 并用 java 语言生成对象对称关系矩阵. 分别用原始方法选择的初始中心点和本方法选择的初始中心点比较聚类过程消耗的时间和聚类最终的效果.




图 1 实验流程图

图 2 为选取的前 10 个节点根据相互之间的距离和阈值 L 转化而成的 0 和 1 的关系对称矩阵, 由于是无向图, 本文这里将节点本身看作是有连接的, 这样对最终的初始中心点选取结果并不会产生影响.

1	0	0	0	0	0	0	0	0	1	0
0	1	0	0	0	0	0	0	0	0	1
0	0	1	0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0	0	0	0
0	0	0	0	1	0	0	0	0	0	0
0	0	0	0	0	1	0	0	0	0	0
0	0	0	0	0	0	1	0	0	0	0
0	0	0	0	0	0	0	1	0	0	0
1	0	0	0	0	0	0	0	1	0	0
0	1	0	0	0	0	0	0	0	1	0

图 2 选取 10 个节点的关系矩阵

图 3 表示 100 个节点利用如图 2 所示的关系对称生成的社会网络关系图. 我们可以很明显的看出相互之间距离小且连接的节点是抱团存在的; 又因为选取的初始中心点距离应该尽可能的远, 所以我们在选取每个初始中心点后, 因为与之相邻的节点将不会作为我们选取下一个聚类中心的候选节点, 所以我们在矩

阵网络中删除与之相邻的节点。




图 3 包含 100 个节点的网络连接图

本文为了更准确的表示比较结果, 所以将每种算法反复运行 30 次, 用最终的四舍五入后的平均值去表示实验性能和结果。以下实验结果均为反复测试的平均值。

表 1 表示在没有离群点的对象集中测试的实验结果, 本文使用两种方法的运行时间和 E 值来作为衡量指标。这里的 E 值表示所有节点与最终所在的簇中心距离之和, E 值的大小体现了最终子簇成员之间的紧密程度。

表 1 不包含离群点的实验结果

节点数\性能	传统算法 时间(ms)	改进算法 时间(ms)	传统算法最 后 E 值	改进算法最 后 E 值
100	109	156	600683	599652
500	136	317	2951211	3078743
1000	188	516	6766575	6604524
2000	286	823	12609452	12403180

表 2 表示在含有离群点的对象集中分别使用两种方法的运行时间和 E 值对比, 为了说明改进算法的有效性, 我们将添加的离群点设为原算法的其中一个初始中心点。

表 2 包含离群点的实验结果

节点数\性能	传统算法 时间(ms)	改进算法时 间(ms)	传统算法 最后 E 值	改进算法 最后 E 值
100	63	157	736218	647368
500	136	325	4096139	3128189
1000	448	578	7696116	6097973
2000	452	923	16054679	11736896

除了与传统方法比较之外, 本文还与最新的文献中的改进方法进行比较, 本文选取了文献[1], 文献[3]和文献[6]中的优化初始中心选取方法进行实验比较,

实验中使用了包含离群点的 500 个实验对象, 并且使用经过反复实验得到的理想 K 值, 用运行时间、迭代次数和 E 值来表示实验结果, 比较结果如表 3 所示。

表 3 与近期改进算法的比较结果

算法\性能	迭代次数	运行时间(ms)	E 值
文献 1	8	523	3498214
文献 3	9	642	4026472
文献 6	8	488	3726521
本文算法	7	818	2928219

通过表 1 和表 2 我们可以看出, 在平滑的数据集中进行聚类处理, 改进的算法与传统算法在时间性能上的聚类结果上没有优势, 但是在含有离群点数据集中, 改进的算法的聚类结果明显优于传统算法。

通过表 3 可以看出, 本文中提出的算法与近期文献提出的方法相比较而言, 本文提出的改进算法在时间性能上有一定的劣势, 但是在类内距和迭代次数这两个指标上优于近期文献中提出的算法, 可以产生更加稳定和优质的聚类结果。

通过以上实验结果可以得出结论, 由于本文中提出的算法在聚类之前要生成对称矩阵, 并且要迭代计算每个节点的度中心性, 所以造成了大量的时间消耗, 但是通过这种方式可以找到更加优质的初始聚类中心, 从而能够生成更加精确和稳定的聚类结果, 所以本文提出的算法更适合体量小的聚类对象集, 在实际应用中是可行的。

6 结语

传统的 K -means 算法在进行聚类时随机的选取对象集合中的 k 个点作为初始聚类中心, 这导致了该算法失去了稳定性, 容易产生不理想的结果。本文提出了一种利用关系矩阵和度数中心度的方法去优化 K -means 算法中的初始中心节点选择问题, 得到了更加优化的初始中心点。本文通过用 java 代码生成的测试对象集和运行代码, 通过与传统方法以及最新的改进算法进行比较, 证明了本算法的高稳定性。虽然生成矩阵的过程造成了大量的时间消耗, 在处理海量数据的性能上有一定的局限性; 但是从一方面讲, 本算法又减少了聚类过程中的迭代次数, 得到更加稳定和高质量的聚类结果, 所以这些代价是在实际应用中是可以付出的。今后也会进一步完善本文提出的算法。

参考文献

- 1 汪中,刘贵全,陈恩红.一种优化初始中心点的 K-means 算法.模式识别与人工智能,2009,22(2):299-304.
- 2 于海涛,贾美娟,王慧强,等.基于人工鱼群的优化 K-means 聚类算法.计算机科学,2012,39(12):60-64.
- 3 陈光平,王文鹏,黄俊.一种改进初始聚类中心选择的 K-means 算法.小型微型计算机系统,2012,33(6):1320-1323.
- 4 周世兵,徐振源,唐旭清.新的 K-均值算法最佳聚类数确定方法.计算机工程与应用,2010,46(16):27-31.
- 5 赵庆.基于 hadoop 平台下的 k 均值高效算法的研究[硕士学位论文].西安:西安电子科技大学,2014.
- 6 何云斌,刘雪娇,王知强,等.基于全局中心的高密度不唯一的 K-means 算法研究.计算机工程与应用,2016,52(1):48-54.
- 7 雷小锋,谢昆青,林帆,等.一种基于 K-Means 局部最优性的高效聚类算法.软件学报,2008,19(7):1683-1692.
- 8 莫锦萍,陈琴,马琳,等.一种新的 K-Means 蚁群聚类算法.广西科学院学报,2008,24(4):284-286.
- 9 赖玉霞,刘建平.K-means 算法的初始聚类中心的优化.计算机工程与应用,2008,44(10):147-149.
- 10 Yu S, Tranchevent LC, Moor BD, et al. Optimized data fusion for Kernel k-means clustering. IEEE Trans. on Pattern Analysis & Machine Intelligence, 2012, 34(5): 1031-1039.
- 11 Li MJ, Ng MK, Cheung YM, et al. Agglomerative fuzzy k-means clustering algorithm with selection of number of clusters. IEEE Trans. on Knowledge & Data Engineering, 2008, 20(11): 1519-1534.