

基于局部搜索机制的 K-Means 聚类算法

孙越恒, 李志圣, 何丕廉

(天津大学计算机学院, 天津 300072)

摘要: K-Means 聚类算法的结果质量依赖于初始聚类中心的选择。该文将局部搜索的思想引入 K-Means 算法, 提出一种改进的 KMLS 算法。该算法对 K-Means 收敛后的结果使用局部搜索来使其跳出局部极值点, 进而再次迭代求优。同时对局部搜索的结果使用 K-Means 算法使其尽快到达一个局部极值点。理论分析证明了算法的可行性和有效性, 而在标准文本集上的文本聚类实验表明, 相对于传统的 K-Means 算法, 该算法改进了聚类结果的质量。

关键词: K-Means 聚类算法; 局部搜索机制; KMLS 算法; 文本聚类

K-Means Clustering Algorithm Based on Local Search Mechanism

SUN Yue-heng, LI Zhi-sheng, HE Pi-lian

(School of Computer Science and Technology, Tianjin University, Tianjin 300072)

【Abstract】 The quality of K-Means clustering algorithm depends on the choice of cluster center. This paper introduces the idea of local search mechanism into K-Means and presents a KMLS algorithm. This algorithm uses the local search mechanism to jump out one local critical point obtained by K-Means, and uses K-Means to quickly find another local critical point. Experiments of text clustering in standard document sets show that this algorithm achieves a better clustering result than the traditional K-Means algorithm does.

【Key words】 K-Means clustering algorithm; local search mechanism; KMLS algorithm; text clustering

1 概述

K-Means^[1]是一种基于划分的聚类方法,可看作一个组合优化问题,即如何生成使某一目标函数达到最优的划分 P 的问题。虽然 K-Means 算法以较快的聚类速度、较好的可伸缩性而被广泛采用,但是它的聚类结果依赖于由初始聚类中心出发所遇到的第 1 个局部极值点,因而不同的初始聚类中心对于聚类质量有着较大影响。为此对于 K-Means 算法的研究主要集中在对初始聚类中心的选择优化上,如文献[2]提出的 Buckshot 和 Fractionation 方法,文献[3]提出的 RA 算法以及文献[4]提出的聚类中心初始化算法。这些算法在一定程度上提高了聚类结果的质量,但是它们仍依赖于 K-Means 算法的简单启发机制。

本文将局部搜索的思想引入 K-Means 算法,提出了一个基于局部搜索的 KMLS(K-Means based on Local Search)算法。它将局部搜索机制同 K-Means 算法相结合,使用局部搜索的迭代策略来不断改进 K-Means 算法的聚类结果,同时使用 K-Means 来加速局部搜索的收敛。可以证明 KMLS 算法能得到一个比 K-Means 更优的聚类结果。

2 局部搜索机制及其在文本聚类中的应用

2.1 局部搜索机制

局部搜索^[5]是解决优化问题的常用技术。它基于贪婪思想,利用邻域函数进行搜索,包括以下步骤:(1)把原问题转化成一个优化问题,即在一个可行域上寻求一个目标函数的最优值。(2)要在可行域中定义邻域结构,即事先指明可行域中每个点的邻域包含哪些点。在定义了邻域关系之后,进行迭代操作,具体可分为 3 步:1)在可行域中选择一个初始点,常用的策略是随机选取;2)确定如何在一点的局部邻域中寻找更优点,可采用“见好就走”的贪心策略或沿着最大下

降方向的梯度策略;3)确定对局部极值点的处理策略。如果一个点的邻域中的所有点都不比这个点更好,那么这个点就是一个局部最优解。

局部搜索虽然简单,但却十分有效,究其原因在于它的重复搜索操作——虽然从某个初始点出发成功的可能性很小,但多次重复之后,却能以很大概率求得问题的解。

2.2 基于局部搜索的文本聚类算法

文本聚类实际上是为了寻找一个使目标函数最优的划分,可以使用局部搜索来进行文本聚类。

为说明方便,作以下定义:

(1) $S = \{d_1, d_2, \dots, d_N\}$: 包含 N 个文本的文本集。

(2) $P = (S_1, S_2, \dots, S_K)$: 文本集 S 的一个 K 划分(即一个聚类结果),其中, $S = \cup_{i=1,2,\dots,K} S_i$, $S_i \cap S_j = \emptyset$, 当 $i \neq j$ 时。

(3) $n_i = |S_i|$: 文本集 S_i 中的文本数, $i = 1, 2, \dots, K$ 。

(4) $D = \sum_{d \in S} d$: 文本集 S 中所有文本向量之和。

(5) $c = D / \|D\|$: 文本集 S 的中心向量。

2.2.1 问题的定义

文本聚类问题可转化为:在给定的文本集 S 的 K 划分集 $P = \{P = (S_1, S_2, \dots, S_K) \mid S = \cup_{i=1,\dots,K} S_i \wedge S_i \cap S_j = \emptyset, i \neq j\}$ 中,搜索使目标函数最优的一个 K 划分。文本聚类中一般采用如下函数作为聚类过程的目标函数:

基金项目: 国家自然科学基金资助项目“基于信息几何方法的维数约减和信息抽象模型研究”(60603027)

作者简介: 孙越恒(1974 -),男,讲师、博士,主研方向:自然语言处理,网络信息检索与挖掘;李志圣,博士研究生;何丕廉,教授、博士生导师

收稿日期: 2007-06-20 **E-mail:** yhs@tju.edu.cn

$$E(P) = \sum_{i=1}^K \sum_{d \in S_i} d \cdot c_i \quad (1)$$

2.2.2 邻域的定义

对任意“点” $P = (S_1, S_2, \dots, S_k) \in \mathbf{P}$ ，任意文本 $d \in S$ ， P 的一个邻域点可以定义如下：将一个文本从 S_i 移动到 S_j 时得到的新划分 P' ，即如果 $d \in S_i$ ，那么 P 关于文本 d 的邻域为

$$N_d(P) = \{P\} \cup \{P' = (S'_1, S'_2, \dots, S'_k) \mid S'_i = S_i - \{d\}, S'_j = S_j \cup \{d\}, S'_k = S_k \text{ 当 } k \neq i, j\} \quad (2)$$

2.2.3 搜索策略

本文使用最速下降作为局部搜索策略。它对一个解 P 邻域内的所有解分别做出评估，然后选择那个使目标函数有最大增加的解作为新解。

设 P 的邻域为 $Neighbour(P)$ ，最速下降搜索策略就是要在 $Neighbour(P)$ 搜索一个满足 $P' = \arg \max_{P' \in Neighbour(P)} (E(P') - E(P))$ 的 P' 。即对于任意 $P \in Neighbour(P)$ 都存在：

$$E(P') > E(P) \quad (3)$$

基于上述定义，在此提出了一种基于局部搜索的文本聚类算法(Local Search Algorithm, LSA)，描述如下：

- (1) 对一个聚类划分 $P = (S_1, S_2, \dots, S_k)$ ；
- (2) 设置 $max\Delta = 0$ ， $movedDoc = null$ ， $target = null$ (其中， $movedDoc$ 指要移动的文本， $target$ 指要移动到的类)；
对 S 中的每个文本 $d \in S_i$ ；
对所有的 j ， $j = 1, 2, \dots, K \wedge j \neq i$ ，
计算 $\Delta_j E(P) = E(P') - E(P)$ ；
 $b = \max\{\Delta_j E(P) > 0 \mid j \neq i\}$ ；
 $max\Delta = \max(max\Delta, b)$ ， $movedDoc = d$ ， $target = S_j$ ；
- (3) 如果 $movedDoc \neq null$ (已经找到一个最好解)，则将文本 d 从 S_i 移到 $target$ ，并重新计算 D_i 及 D_{target} ；
- (4) 如果得到 $P' = \arg \max_{P' \in Neighbour(P)} (E(P') - E(P))$ ，则退出；否则，返回(2)和(3)。

3 基于局部搜索的 K-Means 算法

LSA 算法可确切地计算出目标函数的变化，但是在每次迭代过程中，目标函数只会增加一个极小的值；而 K-Means 算法则以高效的迭代而著称。本文结合这 2 种算法的优点，提出了一个基于局部搜索的 KMLS 算法。首先，执行一次 K-Means 操作，当 K-Means 收敛后，执行 LSA 算法来跳出 K-Means 所得到的局部极值点，并再次迭代。

KMLS 算法描述如下：

- (1) 生成一个初始聚类划分 $P = (S_1, S_2, \dots, S_k)$ ；
- (2) K-Means(P)；
- (3) 执行 LSA；
- (4) 如果类 P 没有变化，退出；否则，执行(2)。

该算法结合了 LSA 和 K-Means 的优点。一方面，在每一次局部搜索迭代得到一个解后，K-Means 的迭代优化可以很快得到由这个解出发遇到的第 1 个局部极值点；另一方面，当 K-Means 收敛得到一个局部极值点后，局部搜索的搜索策略又会使 K-Means 从这个局部极值中跳出，以期得到一个更优的解。

4 实验设计与结果分析

4.1 实验设计

本文使用了 3 个标准的文本数据集：Reuters-21578,

20Newsgroups 和 WAP 数据集。在进行聚类实验之前，对所有的数据集都进行了预处理。经过预处理后，各个数据集的统计信息如表 1 所示。

表 1 文本数据集的属性统计表

数据集	类数	文本数	单词数	平均每个文本单词数	平均每个单词的文本频数
Reutes-21578	81	10 377	18 921	44.8	24.6
20Newsgroups	20	18 828	97 820	82.6	15.9
WAP	20	1 560	8 460	138.9	26.6

本文使用熵作为聚类质量的评价指标。设 $C = \{C_1, C_2, \dots, C_m\}$ 表示聚成类的集合； $K = \{K_1, K_2, \dots, K_n\}$ 是文本集中真实类的集合，它是由专家手工建立的，作为评价聚类结果的标准答案。C 的熵定义为

$$Entropy(C) = -\sum_{C_j} \frac{n_j}{N} \sum_i p_{ij} \ln(p_{ij}) \quad (4)$$

其中， n_j 是聚成类 C_j 中的文本数； p_{ij} 是类别 C_j 中实际属于真实类 K_i 的概率； N 表示文本集中的文本总数。熵值越小，表示聚类质量越好。

4.2 实验结果与分析

对上述数据集进行预处理后，进行特征选择并生成文本的特征向量，接着以随机方式生成 10 个不同的初始点，然后针对这些初始点分别运行 KMLS 和 K-Means 算法 10 次，并比较这 10 组结果及其平均值。图 1~图 3 分别是在 3 个数据集上运行 2 种算法后的熵值比较。




图 1 KMLS 和 K-Means 在 Reuters 上的熵值比较




图 2 KMLS 和 K-Means 在 20Newsgroups 上的熵值比较




图 3 KMLS 和 K-Means 在 WAP 上的熵值比较

可以看出, KMLS 几乎总是取得比 K-Means 算法更好的结果。注意到在 Reuters 的第 8 次实验和在 20Newsgroups 上的第 6 次实验中, KMLS 所得结果的熵值比 K-Means 要高, 为此比较了它们各自的目标函数值, 发现 KMLS 所得结果的目标函数值比 K-Means 要高。之所以会出现这种目标函数值同熵值相矛盾的情况, 是因为熵值这个评价标准是以人工分类结果为依据, 而向量空间模型在表示文本时, 并不能完全地将文本的真实主题表示在余弦相似度的度量之中, 因而在某次实验中出现这样的情况是可以接受的。

那么, 局部搜索和 K-Means 算法结合的合理性是什么? 假定 $P = (S_1, S_2, \dots, S_K)$, $P' = (S'_1, S'_2, \dots, S'_K) \in \text{Neighbour}(P)$, 笔者的目标是确定是否可以将一个文本 $d_0 \in S_i$ 移动到 S_j 。

对于 K-Means 算法要检验下面的不等式:

$$\Delta_k = d_0 \cdot (c_j - c_i) > 0 \quad (5)$$

如果 $\Delta_k > 0$, 那么 K-Means 把 d_0 从类 S_i 移动到 S_j , 否则依然把 d_0 留在类 S_i 中。

不同于 K-Means 算法, 本文所介绍的 LSA 算法计算:

$$\Delta_p E(P) = E(P') - E(P) \quad (6)$$

对式(6)进一步推导, 由 $S'_i = S_i - \{d_0\}$ 和 $S'_j = S_j \cup \{d_0\}$ 可以得到:

$$\begin{aligned} \Delta_p E(P) &= \sum_{i=1}^K \sum_{d \in S_i} d \cdot c'_i - \sum_{i=1}^K \sum_{d \in S_i} d \cdot c_i = \\ &= \sum_{d \in S_i} d \cdot c'_i - \sum_{d \in S_i} d \cdot c_i + (\sum_{d \in S_j} d \cdot c'_j - \sum_{d \in S_j} d \cdot c_j) = \\ &= \sum_{d \in S_i} d \cdot c'_i - \sum_{d \in S_i} d \cdot c_i - d_0 \cdot c_i + (\sum_{d \in S_j} d \cdot c'_j - \\ &= \sum_{d \in S_j} d \cdot c_j + d_0 \cdot c_j) = \\ &= \sum_{d \in S_i} d \cdot (c'_i - c_i) + \sum_{d \in S_j} d \cdot (c'_j - c_j) + d_0 \cdot (c_j - c_i) \end{aligned}$$

因而:

$$\Delta_p E(P) = \sum_{d \in S_i} d \cdot (c'_i - c_i) + \sum_{d \in S_j} d \cdot (c'_j - c_j) + \Delta_k \quad (7)$$

由 Cauchy-Schwarz 不等式, 有 $\sum_{d \in S_i} d \cdot c'_i \geq \sum_{d \in S_i} d \cdot c_i$, 因而有:

$$\sum_{d \in S_i} d \cdot (c'_i - c_i) \geq 0 \quad (8)$$

同样:

$$\sum_{d \in S_j} d \cdot (c'_j - c_j) \geq 0 \quad (9)$$

由上面 2 个不等式及式(7)可推出:

$$\Delta_p E(P) \geq \Delta_k \quad (10)$$

式(8)说明, 即使当 $\Delta_k = 0$ 时 K-Means 算法不会改变 d_0 在聚类结果内的从属, KMLS 的目标函数 $\Delta_p E(P)$ 仍然是正的。因此, 虽然 $E(P') > E(P)$, K-Means 算法会错过划分 P' 。而 2 种算法的结合, 则可以避免这种情况的出现, 由此改善了聚类结果的质量。

另外, 笔者也发现虽然 KMLS 对聚类结果的改善是显著的, 但是在大数据集上其改进幅度比在小数据集上要小, 如在 Reuters 数据集上, 熵值最大的改进是第 1 次运行结果, KMLS 比 K-Means 有 4.46% 的改进, 而在 WAP 数据集中, 最小的改进是第 7 次运行结果, 为 11.81%。为进一步验证该结论, 手工从 20Newsgroups 数据集中生成了一个每个类包含 50, 100, 200 的小数据集来重复上述实验, 结果如图 4 所示。它们的熵值改进分别为: 33.93%, 27.12% 和 22.88%。

为从理论上说明这个问题, 回到式(7)。可以认为, 如果把一个文本从一个类移到另一个类时, 可以显著地改变这

2 个类的中心概念向量, 那么 $\Delta_p E(P) - \Delta_k$ 也会有一个较大的改变。当文本集足够大时, 由于每个类内文本数较多, 因此去除或是加入一个文本对于它的中心概念向量的改变并不显著; 然而对于小数据集来说这个改变就非常明显了。




图 4 在 20Newsgroups 小数据集上的熵值比较

与之不同的是, K-Means 算法在面对小数据集时, 考虑一个文本 $d \in S_i$, 对于任意一个类 $S_j \neq S_i$, 由于文本集的文本数很小, 而且文本间余弦相似度的均值很小, 这就造成了 $d \cdot c_j$ 对于任意的初始类而言都只有很小的数量级。但是对于 d 及它所属的类 S_i 而言, 由 $d \cdot d = 1$, 有

$$d \cdot c_i = \frac{1}{\|D_i\|} + \sum_{x \in S_i - \{d\}} \frac{d \cdot x}{\|D_i\|}$$

上式的第 1 项可以解释为文本 d 对类 S_i 的中心向量的贡献。对于一个小而高维稀疏的文本数据而言, 上面的第一项远大于 $d \cdot c_j$, 因而, K-Means 几乎不会在初始类之间移动文本。

5 结束语

本文分析了 K-Means 算法在处理文本数据上的不足, 将局部搜索的思想引入文本聚类, 提出了一种新的 KMLS 文本聚类算法。

实验结果表明, 相对于较大的数据集, KMLS 算法可以更显著地改进小数据集的聚类质量。笔者认为, 除了文本表示模型的问题外, 另一个原因可能是定义的领域对于目标函数的扰动并不敏感。如何使该算法更好地应用于真实情况下的大规模数据集, 有待于进一步研究。

参考文献

- [1] Garcia-Escudero L A, Gordaliza A. Robustness Properties of K-Means and Trimmed K-Means[J]. Journal of the American Statistical Association, 1999, 94(8): 956-969.
- [2] Cutting D, Karger D, Pedersen J, et al. Scatter-gather: A Cluster-Based Approach to Browsing Large Document Collections[C]//Proc. of the 15th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval. Copenhagen, Denmark: [s. n.], 1992: 318-329.
- [3] Larsen B, Aone C. Fast and Effective Text Mining Using Linear-time Document Clustering[C]//Proc. of the 5th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Diego, CA, USA: [s. n.], 1999: 16-22.
- [4] Khan S S, Ahmad A. Cluster Center Initialization Algorithm for K-Means Clustering[J]. Pattern Recognition Letters, 2004, 25(12): 1293-1302.
- [5] Gill P E, Murray W, Wright M H. Practical Optimization[M]. [S. l.]: Academic Press, 1997.