

聚类

秦睿哲

一、k-Means

1、Voronoi Diagrams

考虑一个集合 $S = \{s_1, s_2, \dots, s_k\} \subset R^d$ ，我们想知道这些点是如何分割空间 R^d 的。Voronoi 图将 R^d 分解为 k 个区域，每个区域对应一个 Voronoi 单元。这样就定义了点 s_i 的区域：

$$R_i = \{x \in R^d \mid \phi_S(x) = s_i\}$$

其中 $\phi_S(x)$ 就是指对于点 $x \in R^d$ ， S 中到它距离最近的点： $\phi_S(x) = \arg \min_{s_i \in S} \|x - s_i\|$

2、Lloyd's Algorithm

具体来说，k-Means 聚类问题是找到有 k 个聚类的集合 S ，最小化

$$\text{cost}(X, S) = \sum \| \phi_S(x) - x \|^2$$

考虑给定的点集 $P \subseteq R^d$ ， $|P| = n$ ，需要划分的聚类个数 $k \in Z^+$ 。

Lloyd's Algorithm(n,d,k) 算法过程：

① 随机取 k 个聚类中心 $\{c_1, c_2, \dots, c_k\} \subseteq P$

② 迭代过程：

(1) 计算每一个点到聚类中心的距离，选取最小值划分到 k 类（Voronoi Diagrams）

(2) 更新聚类中心 $c_i = \frac{1}{|C_i|} \sum_{p \in C_i} p$

重复 (1) (2) 过程，直到损失函数达到最小保持不变，或者其他的终止条件。

([1] MATHEMATICAL FOUNDATIONS FOR DATA ANALYSIS)

遗憾的是，无论如何选择收敛条件，该算法都不能保证找到最优的集合，很容易陷入局部最小值，这种情况在 k 很大的情况下比较常见。也就是说，Lloyd's Algorithm 的结果可能是任意差的。

3、k-Means 的 hardness 结论

① 即使在低维空间 (k 是一个常数) 中，仍是一个 NP-hard 问题；

② 在高维空间 (k 不是一个常数)，即使 $k=2$ ，也是 NP-hard 问题。

总的来说, 参数 (n, d, k) 中, d 和 k 只要有一个不是常数, k -Means 都是 NP-hard 问题。

4、k-Means++ ([2] K-Means++: The Advantages of Careful Seeding)

由于 k -means 算法的分类结果会受到初始点的选取而有所区别, 因此提出这种算法的改进 k -means++。这个算法是对初始点的选择进行改进, 其他步骤都一样。初始类中心选取的基本思路就是, 初始的聚类中心之间的相互距离要尽可能的远。

算法主要分成两部分: (a) 和 (b)

(a) 如何选取初始类中心 $\{c_1, c_2, \dots, c_k\}$

(b) Lloyd's Algorithm

关于 (a) 的算法:

① 令 $C = \emptyset$, 随机取 $c_1 \in P, C = \{c_1\}$;

② 对于 $j = 2 \sim k$

1) 对每一个 $u \in P$, 定义: $D(u, C) = \min\{\|u - c_i\| \mid 1 \leq i \leq j-1\}$ 和概率

$$f(u) = \frac{D(u, C)^2}{\sum_{u' \in P} D(u', C)^2}$$

2) 基于概率 f , 从 P 中选取下一个类中心点 c_j

整个过程 (a) 的时间复杂度为 $\Theta(k \cdot n \cdot d)$, 这与 Lloyd's Algorithm 一次循环的复杂度相等。

k -Means 的近似比的期望为 $\Theta(\log k)$ 。

考虑一个简单的情况:

假设 $\{A_1, A_2, \dots, A_k\}$ 为最优的 k 个类, 在每一个 A_j , 随机选取一个点为 c_j 。

定义

$$m(A_j) = \frac{1}{|A_j|} \sum_{u \in A_j} u,$$

$$\text{cost}(A_j, u_0) = \sum_{u \in A_j} \|u - u_0\|^2$$

$$\begin{aligned}
E[\text{cost}(A_j, u_0)] &= \sum_{u_0 \in A_j} \frac{1}{|A_j|} \left(\sum_{u \in A_j} \|u - u_0\|^2 \right) \\
&= \frac{1}{|A_j|} \sum_{u_0 \in A_j} \sum_{u \in A_j} \|u - u_0\|^2 \\
&= \frac{1}{|A_j|} \sum_{u_0 \in A_j} \sum_{u \in A_j} \|u - m(A_j) + m(A_j) - u_0\|^2 \\
&= 2 \sum_{u \in A_j} \|u - m(A_j)\|^2
\end{aligned}$$

⇒ 近似比的期望为 2。

二、k-Median

Center-Based Clustering: 核心是找到 k 个类中心点 $\{c_1, c_2, \dots, c_k\}$

(1) k-Means: 计算 $\sum_{u \in P} \min_{1 \leq j \leq k} \|u - c_j\|^2$

(2) k-Median: 计算 $\sum_{u \in P} \min_{1 \leq j \leq k} \|u - c_j\|$

考虑 k=1 的情况下，两种方法在几何上的差异。

k-Means: $c_1 = \frac{1}{|P|} \sum_{u \in P} u$ 几何上为找点的重心。

类似的，k-Median 找的 c_1 是几何上点的 Fermat 点。

结论: Lloyd Algorithm 和 k-Means++ 都可以扩展到 k-Median。

假设我们找到的类中心点为 $\{c_1, c_2, \dots, c_k\}$ ，则在 k-Means++ 中， $f(u_0) = \frac{D(u_0, C)^2}{\sum_{u' \in P} D(u', C)^2}$

同样的，我们就可以在 k-Median++ 中计算概率 $f(u_0) = \frac{D(u_0, C)}{\sum_{u' \in P} D(u', C)}$

三、k-Center

1、k-Center 算法的目标是最小化 $\max_{u \in P} \left\{ \min_{1 \leq j \leq k} \|u - c_j\| \right\}$ 。我们使用的方法是 Gonzalez 算法 ([1] MATHEMATICAL FOUNDATIONS FOR DATA ANALYSIS)。

Gonzalez 算法 ($P \subseteq R^d, k$)

- (1) 初始化 $C = \emptyset$ ，任取 P 中的一个点，令其为 c_1 ， $C = \{c_1\}$;
- (2) $j = 2$ ；循环下列步骤直到 $j = k$ ：
 - ① 取 $c_j = \arg \max_{u \in P} \left\{ \min_{1 \leq i \leq j-1} \|u - c_i\| \right\}$;
 - ② $C = C \cup \{c_j\}$ ， $j = j + 1$.


*注：

- Gonzalez(n,d,k)算法的复杂度为 $\Theta(k \cdot n \cdot d)$
- 算法的质量保证： $\frac{\text{我们得到的半径}}{\text{最优解的半径}} \leq 2$

2、【定理】Gonzalez 算法输出 2 倍近似比的 k-Center 聚类结果。

证明：假设最优的聚类结果为 A_1, A_2, \dots, A_k ，对应的类中心为 a_1, a_2, \dots, a_k

情况 1: $\{c_1, c_2, \dots, c_k\}$ 恰好落在 A_1, A_2, \dots, A_k 里，记作 $c_1 \in A_1, c_2 \in A_2, \dots, c_k \in A_k$ 。考虑以 a_j 为球心包住整个 A_j ，所需的半径为 r_j ；而以 c_j 为球心包住整个 A_j ，所需的半径为 r'_j



从图上可以看出，显然有 $r'_j \leq 2r_j$ ，从而近似比 ≤ 2

情况 2: $\{c_1, c_2, \dots, c_k\}$ 中存在两个类中心落在同一类中。不失一般性，我们假设

$c_1 \in A_1, c_2 \in A_2, \dots, c_i \in A_i, c_{i+1} \in A_i, 1 \leq t \leq i$ 。

则 $\min_{1 \leq j \leq i} \|c_{i+1} - c_j\| \geq \max_{u \in \bigcup_{j=i+1}^k A_j} \left\{ \min_{1 \leq j \leq i} \|u - c_j\| \right\}$ (由 Gonzalez 算法中心点的选择可知, c_{i+1}

是当前最远的点)

不等式左侧 $\|c_{i+1} - c_i\| \leq \|c_{i+1} - a_t\| + \|a_t - c_i\| \leq 2r_{\text{opt}}$ 其中 r_{opt} 为最优半径

不等式右侧 $\max_k \left\{ \min_{1 \leq j \leq i} \|u - c_j\| \right\} \leq 2r_{\text{opt}}$, 这意味着 $A_{i+1}, A_{i+2}, \dots, A_k$ 中的点到 $\{c_1, c_2, \dots, c_i\}$ 的距离 $\leq 2r_{\text{opt}}$ 。同时与情况 1 相同的是, A_1, A_2, \dots, A_i 中的点到 $\{c_1, c_2, \dots, c_i\}$ 的距离 $\leq 2r_{\text{opt}}$ 。因此, 可以推出 $\{c_1, c_2, \dots, c_k\}$ 导致的近似比 ≤ 2 。

3、关于 k-Center 聚类 Hardness 结论: 任何近似比 < 2 的结果都是 NP-hard 的问题, 即使 $d = \Theta(1)$ 。

参考文献:

[1] Jeff M. Phillips. *MATHEMATICAL FOUNDATIONS FOR DATA ANALYSIS*.
Section 8 Clustering.

[2] Arthur D, Vassilvitskii S. *K-Means++: The Advantages of Careful Seeding*[C]//
Eighteenth Acm-siam Symposium on Discrete Algorithms. ACM, 2007.