

Johnson-Lindenstrass Transform (JL 变换)

秦睿哲

【JL-定理】 令 $\varepsilon \in (0,1)$, 给定 R^d 中的包含 n 个点的点集 P , $k = \frac{1}{\varepsilon^2} \log n$ (与 d 无关),

那么存在一个从 R^d 到 R^k 的 Lipschitz 映射 f , 对于 $\forall u, v \in P$ 有

$$(1-\varepsilon)\|u-v\|^2 \leq \|f(u)-f(v)\|^2 \leq (1+\varepsilon)\|u-v\|^2$$

Lipschitz 映射 f : 构造一个矩阵 $B \in R^{k \times d}$, 得到 $f(u) = Bu$ 。

映射的构造方法: $B = \frac{1}{\sqrt{k}} A$, 其中 A 是一个 $k \times d$ 维矩阵, 且它的每一个元素均独立同分布于高斯分布 $N(0,1)$ 。

布于高斯分布 $N(0,1)$ 。

【JL-定理的证明】

我们的证明过程主要参考了 ([1] Random Projections) 的思想。

要证明对于 $\forall u, v \in P$ 有 $(1-\varepsilon)\|u-v\|^2 \leq \|f(u)-f(v)\|^2 \leq (1+\varepsilon)\|u-v\|^2$, 将 $u-v$ 看作 x ,

也就是要证明 $\left\| \frac{1}{\sqrt{k}} A \cdot x \right\|^2 \in (1 \pm \varepsilon) \|x\|^2$ 。令 $y = \frac{1}{\sqrt{k}} Ax$, 首先证明 $E[\|y\|^2] = \|x\|^2$ 。

记 $A = \begin{bmatrix} A_1 \\ \vdots \\ A_k \end{bmatrix}$, 其中 A_j 是 A 的第 j 行, 则 y 的第 j 个元素是 $\frac{1}{\sqrt{k}} A_j \cdot x$ 。

$$\|y\|^2 = \frac{1}{k} \sum_{j=1}^k (A_j \cdot x)^2$$

$$\Rightarrow E[\|y\|^2] = \frac{1}{k} \sum_{j=1}^k E[(A_j \cdot x)^2]$$

$$\begin{aligned} E[(A_j \cdot x)^2] &= E\left[\left(\sum_{i=1}^d A_{ji} x_i\right)^2\right] \\ &= E\left[\sum_{i,i'} A_{ji} A_{ji'} x_i x_{i'}\right] \end{aligned}$$

注意到当 $i \neq i'$ 时 $E[A_{ji}A_{j'i'}x_i x_{i'}] = 0$, 因此

$$\begin{aligned} E[(A_j x)^2] &= E\left[\sum_{i=1}^d A_{ji}^2 x_i^2\right] \\ &= \sum_{i=1}^d x_i^2 = \|x\|^2 \end{aligned}$$

所以 $E[\|y\|^2] = \|x\|^2$.

接下来, 目标是证明 $\text{Prob}(\|y\|^2 \geq (1+\varepsilon)\|x\|^2)$ 足够小。

$$\|y\|^2 = \frac{1}{k} \|Ax\|^2 \geq (1+\varepsilon)\|x\|^2 \quad \Leftrightarrow \quad \frac{\|Ax\|^2}{\|x\|^2} \geq (1+\varepsilon)k$$

$$\frac{\|Ax\|^2}{\|x\|^2} = \sum_{j=1}^k \frac{(A_j x)^2}{\|x\|^2} = \sum_{j=1}^k Z_j^2, \quad \text{这里我们定义 } Z_j = \frac{A_j x}{\|x\|}.$$

因此, 我们的目标等价于证明 $\text{Prob}\left(\sum_{j=1}^k Z_j^2 \geq (1+\varepsilon)k\right)$ 足够小。

$$\begin{aligned} &\text{Prob}\left(\sum_{j=1}^k Z_j^2 \geq (1+\varepsilon)k\right) \\ &= \text{Prob}\left(e^{\lambda \sum_{j=1}^k Z_j^2} \geq e^{(1+\varepsilon)k\lambda}\right) \\ &\leq \frac{1}{e^{(1+\varepsilon)k\lambda}} E\left[e^{\lambda \sum_{j=1}^k Z_j^2}\right] \\ &\leq \frac{1}{e^{(1+\varepsilon)k\lambda}} \left(E[e^{\lambda Z_1^2}]\right)^k \end{aligned}$$

*这里注意到 $Z_j = \frac{A_j x}{\|x\|} = \sum_{i=1}^d A_{ji} \frac{x_i}{\|x\|}$ 符合高斯分布, 因此

$$E[Z_j] = 0, E[Z_j^2] = 1. E[e^{\lambda Z_1^2}] = \frac{1}{\sqrt{1-2\lambda}}.$$

$$\begin{aligned} &\Rightarrow \frac{1}{e^{(1+\varepsilon)k\lambda}} \left(E[e^{\lambda Z_i^2}] \right)^k \\ &= \frac{1}{e^{(1+\varepsilon)k\lambda}} \left(\frac{1}{1-2\lambda} \right)^{\frac{k}{2}} \quad \left(\lambda = \frac{\varepsilon}{2(1+\varepsilon)} \right) \\ &= \left((1+\varepsilon)e^{-\varepsilon} \right)^{\frac{k}{2}} \leq e^{-\frac{k}{4}(\varepsilon^2-\varepsilon^3)} \end{aligned}$$

所以得到 $\text{Prob}\left(\|y\|^2 \geq (1+\varepsilon)\|x\|^2\right) \leq e^{-\frac{k}{4}(\varepsilon^2-\varepsilon^3)}$ 。

同理， $\text{Prob}\left(\|y\|^2 \leq (1-\varepsilon)\|x\|^2\right) \leq e^{-\frac{k}{4}(\varepsilon^2-\varepsilon^3)}$ 。

所以， $\text{Prob}\left(\|y\|^2 \in (1 \pm \varepsilon)\|x\|^2\right) \geq 1 - 2e^{-\frac{k}{4}(\varepsilon^2-\varepsilon^3)}$ 。

【JL 变换与 PCA 的对比】

时间上，JL 为 $\Theta\left(n \cdot d \cdot \frac{\log n}{\varepsilon^2}\right) < \text{PCA 的 } \Theta(n \cdot d^2)$ 。

JL 变换的优点为适合并行计算/分布式计算，通常用于流数据的操作和隐私保护等方面。

【其他 JL 变换】

• 基于高斯分布的 JL 变换的缺点：

投影矩阵为稠密矩阵， $A \cdot x$ 的计算时间为 $\Theta(k \cdot d)$ 。如果可以将 A 变成稀疏矩阵，那么计算时间与 A 中非零元素的个数相关。因此，为了优化 JL 变换，提出了其他的 JL 变换投影矩阵的构造方法。

• 其他 JL 变换的构造方法：

1、用 0/1 矩阵构造 ([2] Database-friendly random projections: Johnson–Lindenstrauss with binary coins)

$$A \in \mathbb{R}^{O\left(\frac{\log n}{\varepsilon^2}\right) \times d}$$

$$A_{ij} = \begin{cases} 1 & \text{with prob } \frac{1}{2} \\ -1 & \text{with prob } \frac{1}{2} \end{cases} \text{ 或者 } A_{ij} = \begin{cases} +1 & \text{with prob } \frac{1}{6} \\ 0 & \text{with prob } \frac{2}{3} \\ -1 & \text{with prob } \frac{1}{6} \end{cases}$$

*该方法实际效果比较好，运行时间较短。

2、Fast JL 变换 ([3] Faster dimension reduction)

$$\text{投影矩阵 } \Phi = P \cdot H \cdot D, \quad k = O\left(\frac{\log n}{\epsilon^2}\right)$$

$$\text{其中(1) } P \in R^{k \times d} \text{ 是一稀疏矩阵 } P_{ij} = \begin{cases} N(0, \frac{1}{q}) & \text{with prob } q \\ 0 & \text{with prob } 1 - q \end{cases}$$

$$q = \min\left\{\Theta\left(\frac{\log^2 n}{d}\right), 1\right\} \Rightarrow \text{与矩阵中的非零个数相关}$$

(2) $H \in R^{d \times d}$ 是归一化的 Hadamard 矩阵

$$H_{ij} = d^{-\frac{1}{2}}(-1)^{\langle i, j \rangle}, \text{ 其中 } \langle i, j \rangle \text{ 是用二进制表示的位向量 } i, j \text{ 的点积 (模 2)}。$$

(3) $D \in R^{d \times d}$ 为对角矩阵，每一个 D_{ii} 独立地从 $\{-1, 1\}$ 中取值，概率均为 $\frac{1}{2}$ 。

参考文献:

- 1、 Sham Kakade and Greg Shakhnarovich. Random Projections. CMSC 35900 (Spring 2009).
- 2、 Achlioptas, D. Database-friendly random projections: Johnson–Lindenstrauss with binary coins. *J. Comput. Syst. Sci.* 66, 4 (2003), 671–687.
- 3、 Ailon N, Chazelle B. Faster dimension reduction. *Communications of the Acm*, 2010, 53(2):97-104.