

集中不等式, 离散傅里叶变换

请在 12 月 4 日课前提交纸质作业.

1. (10 分) 完成以下关于 Chernoff bound 的证明.

(1) (0 分) 设随机变量 $(X_1, \dots, X_n) \sim (\text{Bern}(p))^n$, 即它们独立地服从 $\text{Bern}(p)$. 对任意 $t > 0$,

$$\Pr\left[\frac{X_1 + \dots + X_n}{n} \geq q\right] = \Pr[e^{t(X_1 + \dots + X_n)} \geq e^{tqn}] \underset{\text{Markov's bound}}{\leq} \frac{\mathbb{E}[e^{t(X_1 + \dots + X_n)}]}{e^{tqn}} = \left(\frac{\mathbb{E}[e^{tX_1}]}{e^{tq}}\right)^n.$$

当 $0 \leq p \leq q \leq 1$ 时, 请选取合适的 t 使得上式最紧. 得到的结果应为

$$\Pr\left[\frac{X_1 + \dots + X_n}{n} \geq q\right] \leq \exp(-n \cdot d(q||p)).$$

Remark: 对称地, 当 $0 \leq q \leq p \leq 1$ 时, 可以证明

$$\Pr\left[\frac{X_1 + \dots + X_n}{n} \leq q\right] \leq \exp(-n \cdot d(q||p)).$$

(2) 设 $(X_1, \dots, X_n) \sim P_1 P_2 \dots P_n$, 即它们相互独立. 每个 P_i 都是 $[0, 1]$ 上的期望等于 p 的分布. 证明当 $0 \leq p \leq q \leq 1$ 时,

$$\Pr\left[\frac{X_1 + \dots + X_n}{n} \geq q\right] \leq \exp(-n \cdot d(q||p)).$$

提示: 比较 $\mathbb{E}_{X \sim P_i}[e^{tX}]$ 和 $\mathbb{E}_{X \sim \text{Bern}(p)}[e^{tX}]$ 的大小.

(3) 有 $m > n$ 个球, 其中 pm 个是白球. 从中无放回的随机选取 n 个球. 用随机变量 (X_1, \dots, X_n) 表示这 n 次选取的结果. $X_i = 1$ 表示第 i 个球是白球, $X_i = 0$ 表示第 i 个球不是白球. 显然 $\mathbb{E}[X_i] = p$. 证明当 $0 \leq p \leq q \leq 1$ 时,

$$\Pr\left[\frac{X_1 + \dots + X_n}{n} \geq q\right] \leq \exp(-n \cdot d(q||p)).$$

2. (10 分) 根据 Sanov's Theorem 我们可以看出, Chernoff bound 对于

$$\Pr_{(X_1, \dots, X_n) \sim (\text{Bern}(p))^n} \left[\frac{X_1 + \dots + X_n}{n} \geq q \right]$$

的估计已经很精确, 指数上的系数是紧的. 这个估计对非 Bernoulli 分布是否也同样精确?

考虑有限个正实数上的分布 P . 记 $\text{Supp}(P) = \{v_1, \dots, v_T\} \subseteq \mathbb{R}^+$. 记 $p_i := P(v_i) > 0$. 这个分布的期望是 $\bar{v} = \sum p_i v_i$. 考虑任意 $b \in (\bar{v}, \max_i v_i)$, 定义

$$Q^* = \arg \min_{\substack{\text{分布 } Q \\ \mathbb{E}_{X \sim Q}[X] \geq b}} D(Q||P).$$

根据 Sanov's Theorem,

$$\Pr_{(X_1, \dots, X_n) \sim P^n} \left[\frac{X_1 + \dots + X_n}{n} \geq b \right] \leq (n+1)^T \cdot \exp(-n \cdot D(Q^*||P)).$$

而根据 Chernoff bound,

$$\Pr_{(X_1, \dots, X_n) \sim P^n} \left[\frac{X_1 + \dots + X_n}{n} \geq b \right] \leq \min_{t>0} \left(\frac{\mathbb{E}_{X \sim P}[e^{tX}]}{e^{tb}} \right)^n.$$

请问是否存在 P 和 $b \in (\bar{v}, \max_i v_i)$ 使得 Chernoff bound 的估计要弱于 Sanov's Theorem?

提示: 拉格朗日乘数.

3. (6 分) 对于一个布尔函数 $f: \{0, 1\}^n \rightarrow \{0, 1\}$, 函数第 i 位的影响被定义为

$$\text{Influence}_i(f) := \Pr_{x \leftarrow \{0, 1\}^n} [f(x) \neq f(x \oplus e_i)],$$

其中 $e_i = (0, \dots, 0, 1, 0, \dots, 0)$ 只在第 i 位等于 1.

- (1) 布尔函数 f 被称为单调 (monotone), 如果 $x \geq y \implies f(x) \geq f(y)$. (这里 $x \geq y$ 表示 $\forall i, x_i \geq y_i$.) 请寻找一个单调的布尔函数 f , 使得 $\sum_i \text{Influence}_i(f)$ 最大, 并证明.
- (2) 布尔函数 f 被称为平衡 (balanced), 如果 $\Pr_{x \leftarrow \{0, 1\}^n} [f(x) = 1] = \frac{1}{2}$. 请寻找一个平衡的布尔函数 f , 使得 $\max_i \text{Influence}_i(f)$ 尽量小, 可以忽略常数系数.

Remark: 证明 $\max_i \text{Influence}_i(f)$ 的下界需要非常有技巧地使用傅里叶变换. 本题不需要证明结果最优.

4. (12 分) 对于函数 $f: \{0, 1\}^n \rightarrow \mathbb{R}$, 用 f 的傅里叶系数表示如下量

- (1) $\hat{g}_s(x)$, 其中 $g_s(x) := f(x \oplus s)$.
- (2) $\hat{g}_y(x)$, 其中 $g_y(x) := (-1)^{\langle x, y \rangle} f(x)$.
- (3) $\hat{f}_i(x)$, 其中 $f_i(x) := f(x) - f(x \oplus e_i)$.
- (4) $\hat{g}_k(x)$, 其中 $g_k(x_1, \dots, x_k) := f(x_1, \dots, x_k, 0, \dots, 0)$.
- (5) $\hat{g}_a(x)$, 其中 $g_a(x_1, \dots, x_k) := \mathbb{E}_{y \leftarrow \{0, 1\}^{n-k}} [f(x, y) \chi_a(y)]$.
- (6) $\text{Var}[f(X)]$, 其中 X 服从均匀分布.

这里约定 $\hat{f}(a) = \mathbb{E}_x [f(x) \overline{\chi_a(x)}]$, $f(x) = \sum_a \hat{f}(a) \chi_a(x)$.

5. (5 分) 对于函数 $f: \{0, 1\}^n \rightarrow \mathbb{R}$, 它的傅里叶系数 $\hat{f}: \{0, 1\}^n \rightarrow \mathbb{R}$ 满足

$$\hat{f}(y) = \frac{1}{2^n} \sum_x f(x) \chi_y(x), \quad f(x) = \sum_y \hat{f}(y) \chi_y(x).$$

考虑一个“噪音算子” $T_\rho: (\{0, 1\}^n \rightarrow \mathbb{R}) \rightarrow (\{0, 1\}^n \rightarrow \mathbb{R})$, 其中 $\rho \in [0, 1]$.

$$T_\rho(f)(x) = \mathbb{E}_{y \sim (\text{Bern}(\rho))^n} [f(x \oplus y)].$$

求 $\widehat{T_\rho(f)}(y)$. 化简后的表达式不应该出现 \sum 或 \mathbb{E} .

6. (10 分) 令 X_1, \dots, X_{2n} i.i.d. 服从 $\text{Bern}(1/2)$ 分布. 我们要选取一组系数 $c_1, \dots, c_{2n} \in \mathbb{Z}$, 使得 $\sum_i c_i X_i$ 接近均匀分布. 当然, 并不存在 \mathbb{Z} 上的均匀分布, 我们实际的要求是统计距离

$$\Delta\left(\sum_i c_i X_i, \sum_i c_i X_i + 1\right) \leq 2^{-\lambda}. \quad (*)$$

一种显然的做法, 是令 $n = \lambda/2$, 令 $c_i = 2^{i-1}$; 这样 $\sum_i c_i X_i$ 服从 $\{0, 1, \dots, 2^\lambda - 1\}$ 上的均匀分布, 而 $\sum_i c_i X_i + 1$ 服从 $\{1, 2, \dots, 2^\lambda\}$ 上的均匀分布, 满足我们对统计距离的要求.

进一步, 假设 X_1, \dots, X_n 中有一半值被泄漏. 要求即使已经看到泄露值, (*) 仍然成立.

为了方便分析, 我们令 c_1, \dots, c_n 是 i.i.d. 从某个分布 P_C 中选取的. 这样不管哪部分值泄露, 分析都相同. 不失一般性, 可以假设前一半值没有泄露. 定义函数

$$\text{Err}(c_1, \dots, c_n) = \Delta\left(\sum_i c_i X_i, \sum_i c_i X_i + 1\right)$$

我们要求当 c_1, \dots, c_n 是从 $(P_C)^n$ 选取时, 以 $1 - 2^{-\lambda}$ 的概率 (这个随机性只依赖于 c_1, \dots, c_n)

$$\text{Err}(c_1, \dots, c_n) \leq 2^{-\lambda}.$$

请根据 λ , 选取合适的 n 以及分布 P_C , 使得要求被满足. 请让 n 的取值尽量小, 可以忽略常数系数. 建议选取 P_C 为 $\{1, 2, 3, \dots, B\}$ 上的均匀分布, 其中 $B = 2^{O(\lambda)}$ 根据 λ 选取.