

2022 春信息论 B 第一次习题课补充材料

考察范围： 重要结论和技巧 课程助教： 高源

1. Jensen 不等式。对于给定的凸函数 f 和随机变量 X , 有

$$E[f(X)] \geq f(E[X])$$

- 等号成立当且仅当 X 为常量。

2. 利用 Jensen 不等式证明相对熵非负。

$$\begin{aligned} D(p||q) &= \sum_A p(x) \log \frac{p(x)}{q(x)} \\ &= - \sum_A p(x) \log \frac{q(x)}{p(x)} \\ &\geq - \log \sum_A p(x) \log \frac{q(x)}{p(x)} \\ &= - \log \sum_A q(x) \\ &\geq 0 \end{aligned}$$

- 等号成立当且仅当 p 和 q 同分布。
- 注意, Jensen 不等式在连续情形也是成立的, 连续情形下相对熵非负证明方法相同。

3. 利用相对熵非负证明熵的极值性。

记 $\mu(x) = \frac{1}{|\mathcal{X}|}$ 服从均匀分布. 则有

$$\begin{aligned} D(p||\mu) &= \sum p(x) \log \frac{p(x)}{\mu(x)} \\ &= \sum p(x) \log p(x) + \sum p(x) \log |\mathcal{X}| \\ &= \log |\mathcal{X}| - H(X) \\ &\geq 0 \end{aligned}$$

- 等号成立当且仅当 X 服从均匀分布。

4. 利用相对熵非负证明功率受限条件下正态分布取得最大微分熵。

$$\begin{aligned}
0 &\leq D(g\|\phi_k) \\
&= \int_{-\infty}^{+\infty} g \ln \frac{g}{\phi_k} dx \\
&= -h(g) - \int_{-\infty}^{+\infty} g \left(c - \frac{x^2}{2\sigma^2} \right) dx \\
&= -h(g) - \left(\int_{-\infty}^{+\infty} (g \cdot c) dx - \frac{E[X^2]}{2\sigma^2} \right) \\
&= -h(g) - \left(\int_{-\infty}^{+\infty} (\phi_k \cdot c) dx - \frac{E[X^2]}{2\sigma^2} \right) \\
&= -h(g) + h(\phi_k)
\end{aligned}$$

- 等号成立当且仅当 g 服从正态分布。

5. 利用相对熵非负证明均值受限（取值非负）条件下指数分布取得最大微分熵。

$$\begin{aligned}
0 &\leq D(g\|\phi_\mu) \\
&= \int_0^{+\infty} g \ln \frac{g}{\phi_\mu} dx \\
&= -h(g) - \int_0^{+\infty} g (c - \lambda x) dx \\
&= -h(g) - \left(\int_0^{+\infty} (g \cdot c) dx - \lambda E[X] \right) \\
&= -h(g) - \left(\int_0^{+\infty} (\phi_\mu \cdot c) dx - \lambda E[X] \right) \\
&= -h(g) + h(\phi_\mu)
\end{aligned}$$

- 等号成立当且仅当 g 服从指数分布。

6. 利用相对熵非负证明峰值受限条件下均匀分布取得最大微分熵。

$$\begin{aligned}
0 &\leq D(g\|u) \\
&= \int_a^b g \ln \frac{g}{u} dx \\
&= -h(g) - \int_a^b g \cdot c dx \\
&= -h(g) - \int_a^b g dx \cdot c \\
&= -h(g) - \int_a^b u dx \cdot c \\
&= -h(g) + h(u)
\end{aligned}$$

- 等号成立当且仅当 g 服从均匀分布。

7. 数据处理不等式。若 $X \rightarrow Y \rightarrow Z$, 则有 $I(X; Y) \geq I(X; Z)$.

$$\begin{aligned} I(X; Y, Z) &= I(X; Y) + I(X; Z | Y) \\ &= I(X; Z) + I(X; Y | Z) \end{aligned}$$

- 等号成立当且仅当 $I(X; Y | Z) = 0$ 。
 - 构造一个信息量的不同展开式是一个重要的证明技巧。
8. 利用构造一个信息量的不同展开式方法证明。随机变量 $X_1 X_2 X_3 X_4$ 构成了马尔科夫链 $X_1 \rightarrow X_2 \rightarrow X_3 \rightarrow X_4$. 证明:

$$I(X_1; X_3) + I(X_2; X_4) \leq I(X_1; X_4) + I(X_2; X_3)$$

9. 费诺不等式。对于满足 $X \rightarrow Y \rightarrow \hat{X}$ 的估计量 \hat{X} , 记 $P_e = p\{X \neq \hat{X}\}$, 有

$$H(P_e) + P_e \log |\mathcal{X}| \geq H(X | \hat{X}) \geq H(X | Y)$$

为了构造一个信息量的不同展开式, 引入示性变量 (按照 P_e 的定义提供的提示)

$$E = \begin{cases} 1, & X \neq \hat{X} \\ 0, & X = \hat{X} \end{cases}$$

构造展开式

$$\begin{aligned} H(E, X | \hat{X}) &= H(X | \hat{X}) + H(E | X, \hat{X}) \\ &= H(E | \hat{X}) + H(X | E, \hat{X}) \end{aligned}$$

由示性变量的定义可知, $H(E | X, \hat{X}) = 0$, 又由于

$$H(E | \hat{X}) \leq H(E) = H(P_e)$$

和

$$\begin{aligned} H(X | E, \hat{X}) &= p(E = 1)H(X | E = 1, \hat{X}) + p(E = 0)H(X | E = 0, \hat{X}) \\ &\leq p(E = 1) \log |\mathcal{X}| \\ &= P_e \log |\mathcal{X}| \end{aligned}$$

可得

$$H(P_e) + P_e \log |\mathcal{X}| \geq H(X | \hat{X})$$

- 等号成立条件?

- 引入示性变量结合链式法则是证明和求解问题的重要技巧。

10. 利用示性变量求解并联信道的容量。信道模型

$$X = \begin{cases} X_1, & \text{概率}\alpha \\ X_2, & \text{概率}(1 - \alpha) \end{cases}$$

对于这种输入的随机变量按照一定概率分布组合在一起的问题，一般的处理技巧是引入示性变量。记

$$\theta(X) = \begin{cases} 1, & X = X_1 \\ 2, & X = X_2 \end{cases}$$

引入示性变量的目的是通过构造互信息的分解，简化 $I(X; Y)$ 的表达，从而完成最大值求解。

$$\begin{aligned} I(X; Y, \theta) &= I(X; \theta) + I(X; Y | \theta) \\ &= I(X; Y) + I(X; \theta | Y) \end{aligned}$$

考虑到 $X \rightarrow Y \rightarrow \theta$ 于是有

$$I(X; \theta | Y) = 0$$

进而有

$$\begin{aligned} I(X; Y) &= I(X; \theta) + I(X; Y | \theta) \\ &= H(\theta) - H(\theta | X) + \alpha I(X_1; Y_1) + (1 - \alpha) I(X_2; Y_2) \\ &= H(\alpha) + \alpha I(X_1; Y_1) + (1 - \alpha) I(X_2; Y_2) \end{aligned}$$

通过对 α 求导得到

$$\alpha = \frac{2^{C_1}}{2^{C_1} + 2^{C_2}}$$

于是有

$$C = H\left(\frac{2^{C_1}}{2^{C_1} + 2^{C_2}}\right) + \frac{2^{C_1}}{2^{C_1} + 2^{C_2}} C_1 + \frac{2^{C_2}}{2^{C_1} + 2^{C_2}} C_2 = \log(2^{C_1} + 2^{C_2})$$

达到信道容量时的输入概率分布为

$$X = \begin{cases} X_1 & \text{概率}\frac{2^{C_1}}{2^{C_1} + 2^{C_2}} \\ X_2 & \text{概率}\frac{2^{C_2}}{2^{C_1} + 2^{C_2}} \end{cases}$$

进一步可以推广得到

$$2^C = \sum_{i=1}^n 2^{C_i}$$