

HW1 第一次作业解答

更新：2026 年 1 月 9 日

Exercise 1

利用切比雪夫不等式求一枚均匀硬币需抛掷多少次才能使样本均值 \bar{X} 落在 0.4 和 0.6 之间的概率至少为 0.9（此处 $X_i = 1$ 表示抛掷硬币出现正面，否则 $X_i = 0, i = 1, 2, \dots, n$ ）？若用中心极限定理计算这个问题，需抛掷的次数又是多少？

定理 0.1 (Chebyshev 不等式) 设随机变量 X 有有限的期望 $\mu = \mathbb{E}(X) < \infty$ 和有限方差 $\sigma^2 = \text{Var}(X) < \infty$ ，则对任意 $\epsilon > 0$ ，均有下列的不等式成立

$$P(|X - \mu| \geq \epsilon) \leq \frac{\sigma^2}{\epsilon^2}$$

证明 设 $p(x)$ 为 X 的概率密度函数（非负），于是有

$$P(|X - \mu| > \epsilon) = \int_{|x - \mu| > \epsilon} p(x) dx$$

因为 $|X - \mu| \geq \epsilon$ 所以 $\frac{(x - \mu)^2}{\epsilon^2} \leq 1$ ，故

$$\int_{|x - \mu| > \epsilon} p(x) dx \leq \int_{|x - \mu| > \epsilon} \frac{(x - \mu)^2}{\epsilon^2} p(x) dx$$

扩大积分区域，有

$$\int_{|x - \mu| > \epsilon} \frac{(x - \mu)^2}{\epsilon^2} p(x) dx \leq \frac{1}{\epsilon^2} \int_{-\infty}^{\infty} (x - \mu)^2 p(x) dx$$

而根据方差的定义，得到

$$P(|X - \mu| > \epsilon) \leq \frac{1}{\epsilon^2} \int_{-\infty}^{\infty} (x - \mu)^2 p(x) dx = \frac{\sigma^2}{\epsilon^2}$$

定理证毕。

解答 设总共投掷了 n 次硬币，其结果分别为 X_1, X_2, \dots, X_n ，设每次硬币正面朝上的概率为 p 显然 $X_i \stackrel{\text{i.i.d.}}{\sim} \text{Bernoulli}(p)$ 。于是均值 $\bar{X} = \sum_{i=1}^n X_i / n$ 的期望和方差分别为

$$\mathbb{E}(\bar{X}) = \frac{1}{n} \cdot n\mathbb{E}(X_1) = p \quad \text{Var}(\bar{X}) = \frac{1}{n^2} \cdot n\text{Var}(X_1) = \frac{p(1-p)}{n}$$

(1) 由 Chebyshev 不等式 0.1 可知

$$P(|\bar{X} - 0.5| \geq 0.1) \leq \frac{\text{Var}(\bar{X})}{0.1^2} = \frac{p(1-p)/n}{0.1^2}$$

若硬币均匀, 则 $p = 0.5$, 所以 $P(|\bar{X} - 0.5| \geq 0.1) = (0.5^2/n)/0.1^2 = 25/n$, 于是

$$P(|\bar{X} - 0.5| < 0.1) = 1 - \frac{25}{n} \geq 0.9$$

解得 $n_{\min} = 250$ 。

(2) 由中心极限定理, 当 n 较大时

$$\frac{\bar{X} - 0.5}{\sqrt{\text{Var}(\bar{X})}} = \frac{\bar{X} - 0.5}{\sqrt{0.5^2/n}} \sim N(0, 1)$$

所以

$$P(|\bar{X} - 0.5| < 0.1) \approx 2\Phi\left(\frac{0.1}{\sqrt{0.5^2/n}}\right) - 1 = 2\Phi(0.2\sqrt{n}) - 1$$

其中 $\Phi(\cdot)$ 为标准正态分布的分布函数。至少为 0.9, 故

$$2\Phi(0.2\sqrt{n}) - 1 \geq 0.9$$

解得 $n \geq 67.64$, 即 $n_{\min} = 68$ 。

Exercise 2

设 X_1, X_2, \dots, X_n 为从下列总体中抽取的简单样本, 利用特征函数试求样本均值 \bar{X} 的分布:

(1) 参数为 λ 的 Poisson 总体 $P(\lambda)$

(2) 参数为 λ 的指数分布 $Exp(\lambda)$

解答 (1) Poisson 分布 $P(\lambda)$ 的特征函数为

$$\varphi(t) = \exp(\lambda(e^{it} - 1))$$

而 X_1, X_2, \dots, X_n 是简单样本, 故它们互相独立, 于是有 $n\bar{X} = \sum_{k=1}^n X_k$ 的特征函数

$$\varphi_{n\bar{X}} = \prod_{k=1}^n \varphi_{X_k}(t) = \prod_{k=1}^n \exp(\lambda(e^{it} - 1)) = \exp(n\lambda(e^{it} - 1))$$

恰为 $P(n\lambda)$ 的特征函数。而随机变量的分布由特征函数唯一确定, 所以 $n\bar{X} \sim P(n\lambda)$, 其分布列为

$$P(\bar{X} = \frac{k}{n}) = \frac{(n\lambda)^k}{k!} e^{-n\lambda}, \quad k = 0, 1, \dots$$

解答 (2) 指数分布 $Exp(\lambda)$ 的特征函数为

$$\varphi(t) = \left(1 - \frac{it}{\lambda}\right)^{-1}$$

与问题 (1) 类似, 且由特征函数的性质, 我们有 $\bar{X} = \sum_{k=1}^n X_k/n$ 的特征函数

$$\varphi_{\bar{X}} = \prod_{k=1}^n \varphi_{X_i}(t/n) = \prod_{k=1}^n \left(1 - \frac{it/n}{\lambda}\right)^{-1} = \left(1 - \frac{it}{n\lambda}\right)^{-n}$$

注意到 $\Gamma(\alpha, \lambda)$ 分布的特征函数为

$$\varphi_{\Gamma}(t) = \left(1 - \frac{it}{\lambda}\right)^{-\alpha}$$

所以 \bar{X} 的分布为 $\Gamma(n, n\lambda)$ 。

注 也可以通过特征函数求出概率密度函数: 当 $\int_{-\infty}^{\infty} |\varphi(t)| dt < \infty$ 时, 概率密度函数为

$$p(x) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{-itx} \varphi(t) dt$$

注 解答 (2) 也可以直接通过 $Exp(\lambda) = \Gamma(1, \lambda)$ 快速发现结果。

Exercise 3

设 r.v. X 服从参数为 α, p 的 Gamma 分布 $\Gamma(p, \alpha)$, 求证

- (1) $\Gamma(p, \alpha)$ 的特征函数为 $\varphi(t) = \left(\frac{\alpha}{\alpha - it}\right)^p$
- (2) $\mathbb{E}(X) = p/\alpha$, $D(X) = p/\alpha^2$
- (3) 若 $X_i \sim \Gamma(p_i, \alpha), i = 1, 2, \dots, k$ 且 X_1, X_2, \dots, X_k 相互独立, 记 $p = \sum_{i=1}^k p_i$, 则 $\sum_{i=1}^k X_i \sim \Gamma(p, \alpha)$
- (4) 若取 $\alpha = 1/2, p = n/2$, 则 $\Gamma(n/2, 1/2)$ 是 χ_n^2 分布。

证明 (1) 由于 X 服从参数为 α, p 的 Gamma 分布 $\Gamma(p, \alpha)$, 故其概率密度函数为

$$f_X(x) = \begin{cases} \frac{\alpha^p}{\Gamma(p)} x^{p-1} e^{-\alpha x}, & x > 0, \\ 0, & x \leq 0. \end{cases}$$

所以, 根据特征函数的定义, 可知

$$\begin{aligned} \varphi_X(t) &= \mathbb{E}(e^{itX}) = \int_0^{\infty} e^{itx} \frac{\alpha^p}{\Gamma(p)} x^{p-1} e^{-\alpha x} dx \\ &= \frac{\alpha^p}{\Gamma(p)} \int_0^{\infty} x^{p-1} e^{-(\alpha - it)x} dx \\ &= \frac{\alpha^p}{\Gamma(p)} \frac{1}{(\alpha - it)^p} \int_0^{\infty} ((\alpha - it)x)^{p-1} e^{-(\alpha - it)x} d(\alpha - it)x \end{aligned}$$

再由 Γ 函数的积分表达式

$$\Gamma(x) = \int_0^{\infty} t^{x-1} e^{-t} dt$$

可知，原式可写作

$$\varphi_X(t) = \left(\frac{\alpha}{\alpha - it} \right)^p \frac{1}{\Gamma(p)} \Gamma(p)$$

所以， X 的特征函数为 $\varphi_X(t) = \left(\frac{\alpha}{\alpha - it} \right)^p$ 命题证毕。

注 上面用到了下面这个结论：

对于含有复参数的积分 $I(\alpha, \beta)$

$$I(\alpha, \beta) = \int_0^{\infty} x^{\alpha-1} e^{-\beta x} dx$$

积分 $I(\alpha, \beta)$ 收敛，当且仅当 α, β 的实部大于 0，即 $\Re(\alpha) > 0, \Re(\beta) > 0$ 。且收敛时有

$$I(\alpha, \beta) = \frac{\Gamma(\beta)}{\alpha^\beta}$$

证明 (2) 使用概率密度函数积分可求一阶矩和二阶矩

$$\begin{aligned} \mathbb{E}(X) &= \frac{\alpha^p}{\Gamma(p)} \int_0^{\infty} x^p e^{-\alpha x} dx = \frac{\alpha^p}{\alpha^{p+1} \Gamma(p)} \int_0^{\infty} (\alpha x)^{(p+1)-1} e^{-\alpha x} d\alpha x \\ &= \frac{1}{\alpha} \frac{\Gamma(p+1)}{\Gamma(p)} = \frac{p}{\alpha} \end{aligned}$$

同理，二阶矩为

$$\begin{aligned} \mathbb{E}(X^2) &= \frac{\alpha^p}{\Gamma(p)} \int_0^{\infty} x^{p+1} e^{-\alpha x} dx = \frac{\alpha^p}{\alpha^{p+2} \Gamma(p)} \int_0^{\infty} (\alpha x)^{(p+2)-1} e^{-\alpha x} d\alpha x \\ &= \frac{1}{\alpha^2} \frac{\Gamma(p+2)}{\Gamma(p)} = \frac{p(p+1)}{\alpha^2} \end{aligned}$$

于是，方差为

$$D(X) = \mathbb{E}(X^2) - (\mathbb{E}(X))^2 = \frac{p(p+1)}{\alpha^2} - \left(\frac{p}{\alpha} \right)^2 = \frac{p}{\alpha^2}$$

综上，命题证毕。

注 也可以使用矩母函数计算。已知特征函数 $\varphi_X(t)$ ，所以可求矩母函数为 $M_X(t) = \varphi_X(-it)$ 。由矩母函数在 0 的 n 阶导 $M_X^{(n)}(0)$ 和 $M_X(0) = 1$ ，可求得 X 的 n 阶矩 $\mathbb{E}(X^n)$ 。

证明 (3) 由 $X_i \sim \Gamma(p_i, \alpha), i = 1, 2, \dots, k$ 且 X_1, X_2, \dots, X_k 相互独立，可得独立和的特征函数

$$\varphi_{\sum_{i=1}^k X_i}(t) = \prod_{i=1}^k \varphi_{X_i}(t) = \prod_{i=1}^k \left(\frac{\alpha}{\alpha - it} \right)^{p_i} = \left(\frac{\alpha}{\alpha - it} \right)^{\sum_{i=1}^k p_i} = \left(\frac{\alpha}{\alpha - it} \right)^p$$

恰为 $\Gamma(p, \alpha)$ 的特征函数，所以 $\sum_{i=1}^k X_i \sim \Gamma(p, \alpha)$ ，命题证毕。

证明 (4) 取 $\alpha = 1/2$, $p = n/2$, 则 $\Gamma(n/2, 1/2)$ 的概率密度函数为

$$f_X(x) = \begin{cases} \frac{(1/2)^{(n/2)}}{\Gamma(n/2)} x^{n/2-1} e^{-(1/2)x}, & x > 0, \\ 0, & x \leq 0. \end{cases}$$

恰为 χ_n^2 分布的概率密度函数。所以 $\Gamma(n/2, 1/2)$ 是 χ_n^2 分布, 命题证毕。

Exercise 4

设 $X_1 \sim N(\mu_1, \sigma_1^2)$, $X_2 \sim N(\mu_2, \sigma_2^2)$ 且 X_1 与 X_2 独立, 用卷积公式证明 $Y = X_1 + X_2 \sim N(\mu, \sigma^2)$ 其中 $\mu = \mu_1 + \mu_2$, $\sigma^2 = \sigma_1^2 + \sigma_2^2$ 。

我们先证明一个引理

引理 0.2 对任意正实数 $a \in \mathbb{R}^+$, 我们有下面的积分结果

$$\int_{-\infty}^{\infty} e^{-ax^2} dx = \sqrt{\frac{\pi}{a}}$$

证明 设 $y = \sqrt{a}x$, 则 $dx = 1/\sqrt{a}dy$, 那么原式变成

$$\int_{-\infty}^{\infty} e^{-ax^2} dx = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} e^{-y^2} dy$$

而通过简单的极坐标变换即可得到 $\int_{-\infty}^{\infty} e^{-y^2} dy = \sqrt{\pi}$, 代入即证。

回到原问题

证明 因为 $X_1 \sim N(\mu_1, \sigma_1^2)$, $X_2 \sim N(\mu_2, \sigma_2^2)$, 所以它们的密度函数为

$$f_{X_1}(x) = \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left(-\frac{(x-\mu_1)^2}{2\sigma_1^2}\right), \quad f_{X_2}(x) = \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left(-\frac{(x-\mu_2)^2}{2\sigma_2^2}\right).$$

且 X_1 和 X_2 相互独立, 所以它们的联合概率密度为

$$f_{X_1, X_2}(x_1, x_2) = f_{X_1}(x_1)f_{X_2}(x_2) = \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{(x_1-\mu_1)^2}{2\sigma_1^2} - \frac{(x_2-\mu_2)^2}{2\sigma_2^2}\right)$$

由于 $Y = X_1 + X_2$, 记 $Z = X_2$, 那么有 $X_1 = Y - Z$, $X_2 = Z$, 该变换的 **Jacobi** 行列式值为

$$|\det J| = \left| \det \begin{pmatrix} \frac{\partial X_1}{\partial Y} & \frac{\partial X_2}{\partial Y} \\ \frac{\partial X_1}{\partial Z} & \frac{\partial X_2}{\partial Z} \end{pmatrix} \right| = \left| \det \begin{pmatrix} 1 & 0 \\ -1 & 1 \end{pmatrix} \right| = 1$$

所以 (Y, Z) 的联合概率密度函数为

$$f_{Y, Z}(y, z) = f_{X_1}(y-z)f_{X_2}(z)$$

从而 Y 的概率密度函数为联合密度函数的边际分布, 即

$$f_Y(y) = \int_{-\infty}^{\infty} f_{Y, Z}(y, z) dz = \int_{-\infty}^{\infty} f_{X_1}(y-z)f_{X_2}(z) dz$$

代入 $f_{X_1}(\cdot)$ 和 $f_{X_2}(\cdot)$ 的函数表达式，可得

$$f_Y(y) = \int_{-\infty}^{\infty} \frac{1}{2\pi\sigma_1\sigma_2} \exp\left(-\frac{((y-z)-\mu_1)^2}{2\sigma_1^2} - \frac{(z-\mu_2)^2}{2\sigma_2^2}\right) dz$$

化简为

$$f_Y(y) = \frac{1}{2\pi\sigma_1\sigma_2} \int_{-\infty}^{\infty} \exp\left[-\left(\frac{1}{2\sigma_1^2} + \frac{1}{2\sigma_2^2}\right) \cdot z^2 + \left(\frac{y-\mu_1}{\sigma_1^2} + \frac{\mu_2}{\sigma_2^2}\right) \cdot z - \left(\frac{(y-\mu_1)^2}{2\sigma_1^2} + \frac{\mu_2^2}{2\sigma_2^2}\right)\right] dz$$

记

$$\begin{cases} A = \frac{1}{2\sigma_1^2} + \frac{1}{2\sigma_2^2} \\ B = \frac{y-\mu_1}{\sigma_1^2} + \frac{\mu_2}{\sigma_2^2} \\ C = \frac{(y-\mu_1)^2}{2\sigma_1^2} + \frac{\mu_2^2}{2\sigma_2^2} \end{cases}$$

被积的指数部分变为

$$-Az^2 + Bz - C = -A\left(z - \frac{B}{2A}\right)^2 - \left(\frac{B^2}{4A} + C\right)$$

注意到 $A > 0$ ，而根据引理 0.2

$$\int_{-\infty}^{\infty} \exp\left(-A\left(z - \frac{B}{2A}\right)^2\right) dz = \sqrt{\frac{\pi}{A}}$$

所以原式转变为

$$\begin{aligned} f_Y(y) &= \frac{1}{2\pi\sigma_1\sigma_2} \sqrt{\frac{\pi}{A}} \exp\left(-\frac{B^2}{4A} - C\right) \\ &= \frac{1}{2\pi\sigma_1\sigma_2} \sqrt{\frac{\pi}{\frac{1}{2\sigma_1^2} + \frac{1}{2\sigma_2^2}}} \exp\left(-\frac{\left(\frac{y-\mu_1}{\sigma_1^2} + \frac{\mu_2}{\sigma_2^2}\right)^2}{4\left(\frac{1}{2\sigma_1^2} + \frac{1}{2\sigma_2^2}\right)} - \frac{(y-\mu_1)^2}{2\sigma_1^2} - \frac{\mu_2^2}{2\sigma_2^2}\right) \\ &= \frac{1}{2\pi\sigma_1\sigma_2} \cdot \frac{\sqrt{2\pi}\sigma_1\sigma_2}{\sqrt{\sigma_1^2 + \sigma_2^2}} \exp\left(\left(\frac{\frac{\sigma_2^2}{\sigma_1^2}(y-\mu_1)^2 + 2(y-\mu_1)\mu_2 + \frac{\sigma_1^2}{\sigma_2^2}\mu_2^2}{2(\sigma_1^2 + \sigma_2^2)}\right) - \left(\frac{(y-\mu_1)^2}{2\sigma_1^2} + \frac{\mu_2^2}{2\sigma_2^2}\right)\right) \end{aligned}$$

其中指数部分可化简为

$$\begin{aligned} & \frac{\sigma_2^4(y-\mu_1)^2 + 2\sigma_1^2\sigma_2^2(y-\mu_1)\mu_2 + \sigma_1^4\mu_2^2 - \sigma_2^2(\sigma_1^2 + \sigma_2^2)(y-\mu_1)^2 - \sigma_1^2(\sigma_1^2 + \sigma_2^2)\mu_2^2}{2\sigma_1^2\sigma_2^2(\sigma_1^2 + \sigma_2^2)} \\ &= \frac{[\sigma_2^4 - \sigma_2^2(\sigma_1^2 + \sigma_2^2)] \cdot (y-\mu_1)^2 + \sigma_1^2\sigma_2^2 \cdot 2(y-\mu_1)\mu_2 + [\sigma_1^4 - \sigma_1^2(\sigma_1^2 + \sigma_2^2)] \cdot \mu_2^2}{2\sigma_1^2\sigma_2^2(\sigma_1^2 + \sigma_2^2)} \\ &= \frac{-\sigma_1^2\sigma_2^2 \cdot [(y-\mu_1)^2 - 2(y-\mu_1)\mu_2 + \mu_2^2]}{2\sigma_1^2\sigma_2^2(\sigma_1^2 + \sigma_2^2)} \\ &= -\frac{(y-\mu_1-\mu_2)^2}{2(\sigma_1^2 + \sigma_2^2)} \end{aligned}$$

从而

$$\begin{aligned}f_Y(y) &= \frac{1}{2\pi\sigma_1\sigma_2} \cdot \frac{\sqrt{2\pi}\sigma_1\sigma_2}{\sqrt{\sigma_1^2 + \sigma_2^2}} \cdot \exp\left(-\frac{(y - \mu_1 - \mu_2)^2}{2(\sigma_1^2 + \sigma_2^2)}\right) \\&= \frac{1}{\sqrt{2\pi}\sqrt{\sigma_1^2 + \sigma_2^2}} \cdot \exp\left(-\frac{(y - \mu_1 - \mu_2)^2}{2(\sigma_1^2 + \sigma_2^2)}\right) \\&= \frac{1}{\sqrt{2\pi}\sigma} \cdot \exp\left(-\frac{(y - \mu)^2}{2\sigma^2}\right)\end{aligned}$$

恰为 $N(\mu, \sigma^2)$ 分布的概率密度函数，所以 $Y = X_1 + X_2 \sim N(\mu, \sigma^2)$ ，命题证毕。

HW2 第二次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设 $X_1, X_2, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} F$, 而 $(X_{(1)}, X_{(2)}, \dots, X_{(n)})$ 是其次序统计量, 已知 $P(X_{(m)} < x) = \sum_{i=m}^n \binom{n}{i} (F(x))^i (1 - F(x))^{n-i}$. 证明如下恒等式:

$$\sum_{i=m}^n \binom{n}{i} (F(x))^i (1 - F(x))^{n-i} = m \binom{n}{m} \int_0^{F(x)} t^{m-1} (1-t)^{n-m} dt$$

证明 记 $F(x) = p \in [0, 1]$, 则原问题变为去证

$$\sum_{i=m}^n \binom{n}{i} p^i (1-p)^{n-i} = m \binom{n}{m} \int_0^p t^{m-1} (1-t)^{n-m} dt$$

再记 $LHS = S(p)$, $RHS = I(p)$, 我们只需要证明 $S(p) \equiv I(p)$, $p \in [0, 1]$. 注意到

$$S'(p) = \sum_{i=m}^n \binom{n}{i} [ip^{i-1}(1-p)^{n-i} - (n-i)p^i(1-p)^{n-i-1}] \quad (1)$$

而由组合数的性质

$$\begin{aligned} i \binom{n}{i} &= n \binom{n-1}{i-1} \\ (n-i) \binom{n}{i} &= (n-i) \binom{n}{n-i} = n \binom{n-1}{n-i-1} = n \binom{n-1}{i} \end{aligned}$$

代回式 1 可得

$$\begin{aligned} S'(p) &= n \sum_{i=m}^n \left[\binom{n-1}{i-1} p^{i-1} (1-p)^{n-i} - \binom{n-1}{i} p^i (1-p)^{n-i-1} \right] \\ &= n \sum_{i=m}^n \binom{n-1}{i-1} p^{i-1} (1-p)^{n-i} - n \sum_{i=m+1}^n \binom{n-1}{i-1} p^{i-1} (1-p)^{n-i} \\ &= n \binom{n-1}{m-1} p^{m-1} (1-p)^{n-m} \end{aligned} \quad (2)$$

下面考虑 $I(p)$ 的导数 $I'(p)$

$$\begin{aligned} I'(p) &= \frac{d}{dp} \left[m \binom{n}{m} \int_0^p t^{m-1} (1-t)^{n-m} dt \right] \\ &= m \binom{n}{m} p^{m-1} (1-p)^{n-m} \end{aligned} \quad (3)$$

注意到

$$n \binom{n-1}{m-1} = n \frac{(n-1)!}{(m-1)!(n-m)!} = \frac{n!}{(m-1)!(n-m)!} = m \binom{n}{m}$$

结合式 2 和 3 有

$$S'(p) = n \binom{n-1}{m-1} p^{m-1} (1-p)^{n-m} = m \binom{n}{m} p^{m-1} (1-p)^{n-m} = I'(p), \quad \forall p \in [0, 1]$$

记 $D(p) = S(p) - I(p)$, $p \in [0, 1]$, 则有

$$D'(p) = S'(p) - I'(p) = 0 \quad \forall p \in [0, 1]$$

那么 $D(\cdot)$ 恒为一个常值函数, 不妨设 $D(p) \equiv c$ 为常数。又注意到 $D(0) = S(0) - I(0) = 0$, 故常值 $c = 0$, 于是 $D(p) \equiv 0$, 即

$$S(p) \equiv I(p), \quad \forall p \in [0, 1]$$

问题证毕。

Exercise 2

设 $X_1, X_2, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(a, \sigma^2)$, 且 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$, $S_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$, 又设 $X_{n+1} \sim N(a, \sigma^2)$ 且与 X_1, X_2, \dots, X_n 独立, 试求统计量

$$T = \frac{X_{n+1} - \bar{X}}{S_n} \sqrt{\frac{n-1}{n+1}}$$

的分布。

解答 首先根据 $X_1, X_2, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(a, \sigma^2)$ 我们可以得到 \bar{X}, S_n^2 的分布

$$\bar{X} \sim N\left(a, \frac{\sigma^2}{n}\right) \quad (4)$$

$$\frac{nS_n^2}{\sigma^2} \sim \chi_{n-1}^2 \quad (5)$$

又因为 $X_{n+1} \sim N(a, \sigma^2)$ 且与 $(X_i)_{i < n+1}$ 独立, 故 X_{n+1} 也与 \bar{X}, S_n^2 独立。于是根据式 4 和 X_{n+1} 的分布可求

$$Z := \frac{X_{n+1} - \bar{X}}{\sigma \sqrt{(n+1)/n}} \sim N(0, 1)$$

为简化式 5, 记 $W = nS_n^2/\sigma^2 \sim \chi_{n-1}^2$, 于是根据 t 分布的性质, 有

$$T = \frac{X_{n+1} - \bar{X}}{S_n} \sqrt{\frac{n-1}{n+1}} = \frac{Z}{\sqrt{W/(n-1)}} \sim t_{n-1}$$

所以, 统计量 $T \sim t_{n-1}$ 。

Exercise 3

设 X_1, X_2, \dots, X_n 独立, 且 $X_i \sim N(0, \sigma_i^2)$, $i = 1, 2, \dots, n$ 。定义

$$\xi = \sum_{i=1}^n \frac{(X_i - Z)^2}{\sigma_i^2} \quad \text{其中 } Z = \sum_{i=1}^n \frac{X_i}{\sigma_i^2} \bigg/ \sum_{i=1}^n \frac{1}{\sigma_i^2}$$

求 ξ 的分布。

解答 记 $w_i = 1/\sigma_i^2$, $W = \sum_{i=1}^n w_i$, 于是有

$$\xi = \sum_{i=1}^n w_i (X_i - Z)^2, \quad Z = \sum_{i=1}^n \frac{w_i X_i}{W}$$

化简 ξ 的表达式

$$\begin{aligned} \xi &= \sum_{i=1}^n w_i (X_i - Z)^2 = \sum_{i=1}^n w_i (X_i^2 - 2ZX_i + Z^2) \\ &= \sum_{i=1}^n w_i X_i^2 - 2Z \sum_{i=1}^n w_i X_i + WZ^2 \\ &= \sum_{i=1}^n w_i X_i^2 - 2Z(WZ) + WZ^2 \\ &= \sum_{i=1}^n w_i X_i^2 - WZ^2 \end{aligned}$$

记 $Y_i = X_i/\sigma_i \Rightarrow Y_i \stackrel{\text{i.i.d.}}{\sim} N(0, 1)$, 且

$$\begin{aligned} \sum_{i=1}^n w_i X_i^2 &= \sum_{i=1}^n w_i \sigma_i^2 Y_i^2 = \sum_{i=1}^n Y_i^2 \\ WZ &= \left(\sum_{i=1}^n w_i \right) \cdot \left(\sum_{i=1}^n \frac{w_i X_i}{W} \right) = \sum_{i=1}^n w_i X_i = \sum_{i=1}^n \frac{Y_i}{\sigma_i} \end{aligned}$$

所以, ξ 可以用 Y_i 表示为

$$\xi = \sum_{i=1}^n Y_i^2 - \frac{1}{W} \left(\sum_{i=1}^n \frac{Y_i}{\sigma_i} \right)^2 \quad (6)$$

如此 ξ 转变为标准正态的 Y_i 的表达, 下面进行变换。

记向量 $Y = (Y_1, Y_2, \dots, Y_n)^T \in \mathbb{R}^n$, 那么根据 Y_i 相互独立且标准正态, 有随机向量 Y 的分布为多元正态 $Y \sim N_n(0_n, I_n)$, 其中 $0_n \in \mathbb{R}^n$, $I_n \in \mathbb{R}^{n \times n}$ 分别表示 n 维分量均为 0 的向量和 $n \times n$ 的单位阵。

作正交变换 $Z = AY \in \mathbb{R}^n$, 其中 $A \in \mathbb{R}^{n \times n}$ 为正交阵。

$$A = \begin{pmatrix} \frac{1}{\sigma_1 \sqrt{W}} & \frac{1}{\sigma_2 \sqrt{W}} & \cdots & \frac{1}{\sigma_n \sqrt{W}} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{pmatrix}_{n \times n}$$

A 可由 Schmidt 正交化构造。于是 $Z \sim N_n(A \cdot 0_n, AI_n A^T) = N_n(0_n, I_n)$ 。

由于

$$Z_1 = \begin{pmatrix} \frac{1}{\sigma_1 \sqrt{W}} & \frac{1}{\sigma_2 \sqrt{W}} & \cdots & \frac{1}{\sigma_n \sqrt{W}} \end{pmatrix} \cdot Y = \sum_{i=1}^n \frac{Y_i}{\sigma_i \sqrt{W}}$$

以及

$$\sum_{i=1}^n Z_i^2 = Z^T Z = (AY)^T (AY) = Y^T A^T A Y = Y^T Y = \sum_{i=1}^n Y_i^2$$

代回式 6 有

$$\xi = \sum_{i=1}^n Z_i^2 - Z_1^2 = \sum_{i=2}^n Z_i^2$$

而根据 $Z \sim N_n(0_n, I_n)$ ，知 $Z_i \sim N(0, 1)$ 且相互独立。于是，由 χ^2 分布的定义知 $\xi \sim \chi_{n-1}^2$ 。

Exercise 4

设 X_1, X_2, \dots, X_n 为取自 Poisson 总体 $P(\lambda)$ 的样本。试证明：

$$\frac{\bar{X}_n - \lambda}{\sqrt{\bar{X}_n/n}}$$

的极限分布为 $N(0, 1)$ 。其中 $\bar{X}_n = n^{-1} \sum_{i=1}^n X_i$ 。

证明 由于 X_1, X_2, \dots, X_n 为取自 Poisson 总体 $P(\lambda)$ 的样本，故

$$\mathbb{E}(X_i) = \mathbb{D}(X_i) = \lambda$$

于是，根据 Khinchin 大数定律 0.1 有

$$\bar{X}_n \xrightarrow{\mathcal{P}} \lambda$$

同理，根据 Lindeberg-Lévy 中心极限定理 0.2 有

$$\frac{\sqrt{n}(\bar{X}_n - \lambda)}{\sqrt{\lambda}} \xrightarrow{\mathcal{L}} N(0, 1)$$

再根据 Slutsky 引理 0.3 有

$$\frac{\bar{X}_n - \lambda}{\sqrt{\bar{X}_n/n}} \xrightarrow{\mathcal{L}} \frac{\bar{X}_n - \lambda}{\sqrt{\lambda/n}} = \frac{\sqrt{n}(\bar{X}_n - \lambda)}{\sqrt{\lambda}} \xrightarrow{\mathcal{L}} N(0, 1)$$

问题证毕。

定理 0.1 (Khinchin 大数定律) 考虑独立同分布的随机变量列 $(X_i)_{i \geq 1}$ 假设 $\mathbb{E}(|X_1|) < \infty$ 。记 $\bar{X}_n = n^{-1} \sum_{i=1}^n X_i$ 且 $\mu = \mathbb{E}(X_1)$ 。则

$$\bar{X}_n \xrightarrow{\mathcal{P}} \mu$$

定理 0.2 (Lindeberg-Lévy 中心极限定理) 考虑独立同分布的随机变量列 $(X_i)_{i \geq 1}$ 记 $\bar{X}_n = n^{-1} \sum_{i=1}^n X_i$ 且 $\mu = \mathbb{E}(X_1)$ 。若 $\sigma^2 = \mathbb{D}(X_1) \in (0, +\infty)$ ，则当 $n \rightarrow \infty$ 时有

$$\frac{\sqrt{n}(\bar{X}_n - \mu)}{\sigma} \xrightarrow{\mathcal{L}} N(0, 1)$$

引理 0.3 (Slutsky 引理) 令 $\{X_n\}$ 和 $\{Y_n\}$ 是两个随机变量的序列, 满足当 $n \rightarrow \infty$ 时,

$$X_n \xrightarrow{\mathcal{L}} X, \quad Y_n \xrightarrow{\mathcal{P}} c$$

其中 $c \in \mathbb{R}$ 为常数。则有:

- (1) $X_n \pm Y_n \xrightarrow{\mathcal{L}} X \pm c$
- (2) $X_n Y_n \xrightarrow{\mathcal{L}} cX$
- (3) $X_n / Y_n \xrightarrow{\mathcal{L}} X/c$

HW3 第三次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设总体 \mathbf{X} 服从双指数分布，其分布函数为

$$F(x) = \begin{cases} 1 - \exp\left(-\frac{x - \mu}{\sigma}\right), & x > \mu, \\ 0, & x \leq \mu. \end{cases}$$

其中 $\mu \in \mathbb{R}$, $\sigma > 0$ ，我们有次序统计量 $X_{(1)} \leq X_{(2)} \leq \cdots \leq X_{(n)}$ 。试证明：

$$\frac{2(n-i+1)}{\sigma}(X_{(i)} - X_{(i-1)}) \sim \chi_2^2, \quad i = 2, 3, \dots, n$$

证明 记总体 $Y = X - \mu$ ，则 Y 的概率密度为

$$f_Y(y) = 1 - \exp\left(-\frac{1}{\sigma}y\right) \mathbb{I}_{\{y>0\}}$$

为指数分布 $\text{Exp}(1/\sigma)$ 。记 $1/\sigma = \lambda$ 即 $Y \sim \text{Exp}(\lambda)$ 。记 Y 的次序统计量为 $Y_{(1)} \leq Y_{(2)} \leq \cdots \leq Y_{(n)}$ ，则有 $X_{(i)} - X_{(i-1)} = Y_{(i)} - Y_{(i-1)} := Z_i$, $i = 2, 3, \dots, n$ ，特别地 $Z_1 = Y_{(1)}$ 。反解出 $Y_{(i)}$ 有

$$Y_{(i)} = \sum_{k=1}^i Z_k, \quad i = 1, 2, \dots, n$$

容易得到 **Jacobi** 阵的行列式的绝对值为 1。

由 Y 的概率密度为 $f_Y(y) = \lambda e^{-\lambda y}$ ，以及次序统计量的联合分布，我们有

$$\begin{aligned} f_{Y_{(1)}, Y_{(2)}, \dots, Y_{(n)}}(y_{(1)}, y_{(2)}, \dots, y_{(n)}) &= n! \cdot f_Y(y_{(1)}) f_Y(y_{(2)}) \cdots f_Y(y_{(n)}) \mathbb{I}_{\{y_{(1)} \leq y_{(2)} \leq \cdots \leq y_{(n)}\}} \\ &= n! \prod_{i=1}^n \lambda e^{-\lambda y_{(i)}} \mathbb{I}_{\{y_{(1)} \leq y_{(2)} \leq \cdots \leq y_{(n)}\}} \\ &= n! \lambda^n \exp\left(-\lambda \sum_{i=1}^n y_{(i)}\right) \mathbb{I}_{\{y_{(1)} \leq y_{(2)} \leq \cdots \leq y_{(n)}\}} \end{aligned}$$

因为 **Jacobi** 阵的行列式的绝对值为 1 以及 $y_{(i)} = \sum_{k=1}^i z_k$, 可以得到 Z_1, Z_2, \dots, Z_n 的联合分布为

$$\begin{aligned} f_{Z_1, Z_2, \dots, Z_n}(z_1, z_2, \dots, z_n) &= n! \lambda^n \exp \left(-\lambda \sum_{i=1}^n \sum_{k=1}^i z_k \right) \mathbb{I}_{\cap_k \{z_k \geq 0\}} \\ &= n! \lambda^n \exp \left(-\lambda \sum_{k=1}^n \sum_{i=k}^n 1 \cdot z_k \right) \mathbb{I}_{\cap_k \{z_k \geq 0\}} \\ &= n! \lambda^n \exp \left(-\lambda \sum_{k=1}^n (n - k + 1) z_k \right) \mathbb{I}_{\cap_k \{z_k \geq 0\}} \end{aligned}$$

注意到 $\prod_{k=1}^n (n - k + 1) = n!$ 有

$$f_{Z_1, Z_2, \dots, Z_n}(z_1, z_2, \dots, z_n) = \prod_{k=1}^n \lambda(n - k + 1) e^{-\lambda(n - k + 1) z_k}$$

其中 $g(z_k) = \lambda(n - k + 1) e^{-\lambda(n - k + 1) z_k}$ 恰为 $\text{Exp}(\lambda(n - k + 1))$ 的概率密度函数。所以

$$\int \lambda(n - k + 1) e^{-\lambda(n - k + 1) z_k} dz_k = 1$$

为求 Z_k 边际分布, 将其他 $l \neq k$ 的 z_l 积分有

$$\begin{aligned} f_{Z_k}(z) &= g(z_k) \int_{z_l \geq 0, l \neq k} \prod_{l \neq k} \lambda(n - k + 1) e^{-\lambda(n - k + 1) z_l} dz_1 \dots dz_{k-1} dz_{k+1} \dots dz_n \\ &= g(z_k) \prod_{l \neq k} \int_{z_l \geq 0} \lambda(n - k + 1) e^{-\lambda(n - k + 1) z_l} dz_l \\ &= g(z_k) \prod_{l \neq k} 1 = g(z_k) \end{aligned}$$

上面的第二个等式是因为 $g(z_l) \geq 0$ 且可积, 使用 **Fubini** 定理交换积分和乘积符号。综上, 我们有

$$Z_k \sim \text{Exp}(\lambda(n - k + 1))$$

由引理: 若 $W \sim \text{Exp}(\theta)$ 则 $2\theta W \sim \chi_2^2$, 我们有

$$2\lambda(n - k + 1)Z_k \sim \chi_2^2$$

又 $Z_i = X_{(i)} - X_{(i-1)}$ 和 $\lambda = 1/\sigma$ 所以

$$\frac{2(n - i + 1)}{\sigma} (X_{(i)} - X_{(i-1)}) \sim \chi_2^2, \quad i = 2, 3, \dots, n$$

命题证毕。

Exercise 2

将指数分布写成指数族的自然形式, 并求出其自然参数空间。

解答 指数分布 $\text{Exp}(\lambda)$ 的联合密度函数为

$$f(x; \lambda) = \lambda e^{-\lambda x} \mathbb{I}_{(0, \infty)}(x)$$

根据指数族形式的定义, 有 $C(\lambda) = \lambda$, $Q(\lambda) = -\lambda$, $T(x) = x$, $h(x) = \mathbb{I}_{(0, \infty)}(x)$ 。下面, 令 $\varphi = Q(\lambda)$ 则有 $\lambda = -\varphi$, 于是 $C(\lambda) = -\varphi = C^*(\varphi)$ 。则指数分布的指数族的自然形式为

$$f(x; \lambda) = -\varphi e^{\varphi x} \mathbb{I}_{(0, \infty)}(x)$$

自然参数空间为

$$\Theta^* = \{\varphi : \int_{\mathcal{X}} e^{\varphi x} \mathbb{I}_{(0, \infty)}(x) dx < \infty\} = \{\varphi : \int_{x>0} e^{\varphi x} dx < \infty\}$$

积分有限, 故 $\varphi < 0$, 所以自然参数空间为 $\Theta^* = \{\varphi : \varphi < 0\}$ 。

Exercise 3

证明指数族的自然参数空间为凸集。即对于自然参数空间

$$\Theta^* = \left\{ \boldsymbol{\theta} = (\theta_1, \theta_2, \dots, \theta_k) : \int_{\mathcal{X}} \exp \left(\sum_{i=1}^k \theta_i T_i(x) \right) h(x) dx < \infty \right\}$$

其中 $h(x) > 0$, 而 \mathcal{X} 为样本空间。结论是: 对于任意 $\boldsymbol{\theta}_1, \boldsymbol{\theta}_2 \in \Theta^*$, 设 $0 < \alpha < 1$, 记 $\boldsymbol{\theta} = \alpha \boldsymbol{\theta}_1 + (1 - \alpha) \boldsymbol{\theta}_2$, 则 $\boldsymbol{\theta} \in \Theta^*$ 。

证明 记 $\mathbf{T}(x) = (T_1(x), T_2(x), \dots, T_k(x))^T \in \mathbb{R}^k$, 则需要证明:

$$\int_{\mathcal{X}} \exp(\boldsymbol{\theta}^T \mathbf{T}(x)) h(x) dx < \infty$$

其中 $\boldsymbol{\theta} = \alpha \boldsymbol{\theta}_1 + (1 - \alpha) \boldsymbol{\theta}_2$ 代入即

$$\exp(\boldsymbol{\theta}^T \mathbf{T}(x)) h(x) = \left[e^{\alpha \boldsymbol{\theta}_1^T \mathbf{T}(x)} h(x)^\alpha \right] \cdot \left[e^{(1-\alpha) \boldsymbol{\theta}_2^T \mathbf{T}(x)} h(x)^{1-\alpha} \right]$$

记 $p = 1/\alpha$, $q = 1/(1 - \alpha)$, 同时记 $\exp(\boldsymbol{\theta}^T \mathbf{T}(x)) h(x) := f(x)g(x)$, 其中

$$f(x) = e^{\frac{1}{p} \boldsymbol{\theta}_1^T \mathbf{T}(x)} h(x)^{\frac{1}{p}} > 0 \quad g(x) = e^{\frac{1}{q} \boldsymbol{\theta}_2^T \mathbf{T}(x)} h(x)^{\frac{1}{q}} > 0$$

由于 $\alpha \in (0, 1) \Rightarrow p, q > 1$ 且 $\frac{1}{p} + \frac{1}{q} = \alpha + (1 - \alpha) = 1$, 所以由 Hölder 不等式 0.2 有

$$\int_{\mathcal{X}} f(x)g(x) dx \leq \left(\int_{\mathcal{X}} f(x)^p dx \right)^{1/p} \left(\int_{\mathcal{X}} g(x)^q dx \right)^{1/q} \quad (1)$$

而

$$\begin{aligned} f(x)^p &= \left(e^{\frac{1}{p} \boldsymbol{\theta}_1^T \mathbf{T}(x)} h(x)^{\frac{1}{p}} \right)^p = e^{\boldsymbol{\theta}_1^T \mathbf{T}(x)} h(x) \\ g(x)^q &= \left(e^{\frac{1}{q} \boldsymbol{\theta}_2^T \mathbf{T}(x)} h(x)^{\frac{1}{q}} \right)^q = e^{\boldsymbol{\theta}_2^T \mathbf{T}(x)} h(x) \end{aligned}$$

又因为 $\theta_1, \theta_2 \in \Theta^*$, 所以

$$\begin{aligned}\int_{\mathcal{X}} f(x)^p dx &= \int_{\mathcal{X}} e^{\theta_1^T \mathbf{T}(x)} h(x) dx < \infty \\ \int_{\mathcal{X}} g(x)^q dx &= \int_{\mathcal{X}} e^{\theta_2^T \mathbf{T}(x)} h(x) dx < \infty\end{aligned}$$

由不等式 1 可知

$$\int_{\mathcal{X}} f(x)g(x) dx = \int_{\mathcal{X}} \exp(\theta^T \mathbf{T}(x)) h(x) dx < \infty$$

即有 $\theta \in \Theta^*$ 证毕。

定理 0.1 (Young 不等式) 设 $a, b \geq 0$, $p, q > 1$ 满足

$$\frac{1}{p} + \frac{1}{q} = 1$$

则有

$$ab \leq \frac{a^p}{p} + \frac{b^q}{q}$$

当且仅当 $a^p = b^q$ 时, 等号成立。

证明 由 $\varphi(x) = e^x$ 为凸函数, 由凸函数的性质或 Jensen 不等式

$$\varphi(\lambda x_1 + (1 - \lambda)x_2) \leq \lambda\varphi(x_1) + (1 - \lambda)\varphi(x_2)$$

令 $\lambda = 1/p$ 由条件 $1 - \lambda = 1/q$ 。下面, 对任意 $a, b > 0$ 取 $x_1 = p \ln a$, $x_2 = q \ln b$, 由上述的 Jensen 不等式

$$e^{\lambda p \ln a + (1 - \lambda)q \ln b} \leq \lambda e^{p \ln a} + (1 - \lambda)e^{q \ln b}$$

而左边

$$e^{\lambda p \ln a + (1 - \lambda)q \ln b} = e^{\frac{1}{p} \cdot p \ln a} \cdot e^{\frac{1}{q} \cdot q \ln b} = ab$$

右边

$$\lambda e^{p \ln a} + (1 - \lambda)e^{q \ln b} = \frac{1}{p} \cdot e^{\ln a^p} + \frac{1}{q} \cdot e^{\ln b^q} = \frac{a^p}{p} + \frac{b^q}{q}$$

综上

$$ab \leq \frac{a^p}{p} + \frac{b^q}{q}$$

定理证毕。

定理 0.2 (Hölder 不等式) 设 $f(x), g(x)$ 为可测函数, $p, q > 1$ 满足

$$\frac{1}{p} + \frac{1}{q} = 1$$

则有

$$\int |f(x)g(x)| dx \leq \left(\int |f(x)|^p dx \right)^{1/p} \left(\int |g(x)|^q dx \right)^{1/q}$$

等号成立当且仅当存在常数 $C > 0$, 使得对几乎处处的 x 有 $|f(x)|^p = C|g(x)|^q$ 成立。

证明 这里只证明不平凡的情形。记

$$A := \int |f(x)|^p dx \in (0, \infty), \quad B := \int |g(x)|^q dx \in (0, \infty)$$

设函数

$$u(x) = \frac{|f(x)|}{A^{1/p}} > 0, \quad v(x) = \frac{|g(x)|}{B^{1/q}} > 0$$

则容易得 $\int u(x)^p dx = \int v(x)^q dx = 1$ 。由 Young 不等式 (定理 0.1), 令 $a = u(x)$, $b = v(x)$, 则

$$u(x)v(x) \leq \frac{u(x)^p}{p} + \frac{v(x)^q}{q}$$

由上式对任意的 x 都成立, 且 $0 < u, v < \infty$, 故积分不等式仍成立

$$\int u(x)v(x) dx \leq \int u(x)^p dx + \int v(x)^q dx = 1$$

即

$$\int \frac{|f(x)|}{A^{1/p}} \frac{|g(x)|}{B^{1/q}} dx = A^{-1/p} B^{-1/q} \int |f(x)g(x)| dx \leq 1$$

代入 A, B 即有

$$\int |f(x)g(x)| dx \leq \left(\int |f(x)|^p dx \right)^{1/p} \left(\int |g(x)|^q dx \right)^{1/q}$$

定理证毕。

Exercise 4

设 r.v. X 的分布函数为 $F(x)$, 密度函数为 $f(x)$, 且 $X_1, X_2, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} f$ 。证明:

$$\int_{a < x_1 < \dots < x_n < b} f(x_1) \cdots f(x_n) dx_1 \cdots dx_n = \frac{1}{n!} [F(b) - F(a)]^n$$

证明 记事件 $A = \{\mathbf{X} \in \mathbb{R}^n : X_i \in (a, b) : i = 1, 2, \dots, n\}$ 和事件 $B = \{\mathbf{X} \in \mathbb{R}^n : a < X_{(1)} < \dots < X_{(n)} < b\}$, 其中 $\mathbf{X} = (X_1, X_2, \dots, X_n)^T$ 中的各个分量 X_i 为相互独立的随机变量。下面我们严格证明: $A = B$ 。

- 对 $\forall \mathbf{X} \in A$, 显然有最小的 $X_{(1)} < X_i < b$ 和最大的 $X_{(n)} > X_i > a$, 即有 $a < X_{(1)} < \dots < X_{(n)} < b$, 即 $\mathbf{X} \in B$, 故 $A \subseteq B$ 。
- 对 $\forall \mathbf{X} \in B$, 则对 $\forall i$ 有 $a < X_{(1)} < X_i < X_{(n)} < b$, 所以 $\mathbf{X} \in A \Rightarrow B \subseteq A$ 。

综上, 有 $A = B$, 进一步 $P(A) = P(B)$ 。而 X_i 相互独立, 所以

$$P(A) = P(\{X_i \in (a, b) : i = 1, 2, \dots, n\}) = P(\{X_i \in (a, b)\})^n = [F(b) - F(a)]^n$$

注意到 n 个次序统计量相互独立, 它们的联合概率密度为

$$f_{X_{(1)}, \dots, X_{(n)}}(x_{(1)}, \dots, x_{(n)}) = n! f(x_{(1)}) \cdots f(x_{(n)})$$

所以

$$\begin{aligned} P(B) &= \int \cdots \int_{a < x_{(i)} < b, \forall i} f_{X_{(1)}, \dots, X_{(n)}}(x_{(1)}, \dots, x_{(n)}) dx_{(1)} \cdots dx_{(n)} \\ &= \int \cdots \int_{a < x_{(i)} < b, \forall i} n! f(x_{(1)}) \cdots f(x_{(n)}) dx_{(1)} \cdots dx_{(n)} \\ &= \int \cdots \int_{a < x_1 < \cdots < x_n < b} n! f(x_1) \cdots f(x_n) dx_1 \cdots dx_n \end{aligned}$$

由 $P(A) = P(B)$, 我们有

$$\begin{aligned} [F(b) - F(a)]^n &= \int \cdots \int_{a < x_1 < \cdots < x_n < b} n! f(x_1) \cdots f(x_n) dx_1 \cdots dx_n \\ \Rightarrow \int \cdots \int_{a < x_1 < \cdots < x_n < b} f(x_1) \cdots f(x_n) dx_1 \cdots dx_n &= \frac{1}{n!} [F(b) - F(a)]^n \end{aligned}$$

命题证毕。

HW4 第四次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设 $\mathbf{X} = (X_1, \dots, X_n)^T$ 且 $X_i \stackrel{\text{i.i.d.}}{\sim} \text{Ge}(\theta)$ 几何分布，试用两种方法证明 $T(\mathbf{X}) = \sum_{i=1}^n X_i$ 是充分统计量

- 充分统计量的定义
- 因子分解定理

证明 (利用充分统计量的定义) 由几何分布 $\text{Ge}(\theta)$ 的定义以及样本的独立性，可得分布族为

$$\mathcal{F} = \{f(\mathbf{x}, \theta) : \theta \in \Theta = (0, 1)\}$$

注：样本空间为 $\mathcal{X} = \mathbb{N}^+ \times \dots \times \mathbb{N}^+$ 。其中概率函数为

$$f_{X_1, \dots, X_n}(\mathbf{x}, \theta) = \theta^n \prod_{i=1}^n (1 - \theta)^{x_i - 1}$$

那么条件概率为

$$P_\theta(X_1 = x_1, \dots, X_n = x_n | T = t) = \frac{P(X_1 = x_1, \dots, X_n = x_n, T = t)}{P(T = t)}$$

由几何分布的分布函数可知

$$\begin{aligned} \text{分子} &= P(X_1 = x_1, \dots, X_n = x_n, T = t) = P(X_1 = x_1, \dots, X_n = t - \sum_{i=1}^{n-1} x_i) \\ &= \left(\theta^{n-1} \prod_{i=1}^{n-1} (1 - \theta)^{x_i - 1} \right) \cdot \left(\theta(1 - \theta)^{t - \sum_{i=1}^{n-1} x_i} \right) \\ &= \theta^n (1 - \theta)^{\sum_{i=1}^{n-1} (x_i - 1) + t - \sum_{i=1}^{n-1} x_i} = \theta^n (1 - \theta)^{t - n} \end{aligned}$$

而

$$\begin{aligned} \text{分母} &= P(T = t) = \sum_{\mathbf{x} \in \mathcal{X}} \prod_{i=1}^n (1 - \theta)^{x_i - 1} \theta \cdot \mathbb{I}_{\{T(\mathbf{x})=t\}}(\mathbf{x}) \\ &= \sum_{\mathbf{x} \in \{\mathbf{x}: T(\mathbf{x})=t\}} \prod_{i=1}^n (1 - \theta)^{x_i - 1} \theta = \sum_{\mathbf{x} \in \{\mathbf{x}: T(\mathbf{x})=t\}} \theta^n (1 - \theta)^{T(\mathbf{x}) - n} \\ &= \sum_{\mathbf{x} \in \{\mathbf{x}: T(\mathbf{x})=t\}} \theta^n (1 - \theta)^{t - n} \end{aligned}$$

将分子分母的结果代回条件概率得

$$\begin{aligned} P_{\theta}(X_1 = x_1, \dots, X_n = x_n | T = t) &= \frac{\theta^n (1 - \theta)^{t-n}}{\sum_{\mathbf{x} \in \{\mathbf{x}: T(\mathbf{x})=t\}} \theta^n (1 - \theta)^{t-n}} = \frac{1}{\sum_{\mathbf{x} \in \{\mathbf{x}: T(\mathbf{x})=t\}} 1} \\ &= \frac{1}{\#\{\mathbf{X} : \sum_{i=1}^n X_i = t\}} \end{aligned}$$

其中 $\#\{\cdot\}$ 代表集合元素。综上可知，条件概率 $P_{\theta}(\mathbf{X} | T(\mathbf{X}) = t)$ 与参数 θ 无关，故 $T(\mathbf{X})$ 是充分统计量。

证明 (利用因子分解定理) 注意到

$$\begin{aligned} f(\mathbf{x}, \theta) &= \theta^n \prod_{i=1}^n (1 - \theta)^{x_i - 1} = \theta^n (1 - \theta)^{\sum_{i=1}^n (x_i - 1)} \\ &= \theta^n (1 - \theta)^{T(\mathbf{x}) - n} := g(T(\mathbf{x}), \theta) h(\mathbf{x}) \end{aligned}$$

其中 $h(\mathbf{x}) \equiv 1$ ，故由因子分解定理， T 为充分统计量。

Exercise 2

设 $X = (X_1, \dots, X_m)$ 为从正态总体 $N(a, \sigma^2)$ 中抽取的简单样本， $Y = (Y_1, \dots, Y_n)$ 为从正态总体 $N(b, \sigma^2)$ 中抽取的简单样本，且两样本独立。记 $\bar{X} = \frac{1}{m} \sum_{i=1}^m X_i$ ， $\bar{Y} = \frac{1}{n} \sum_{j=1}^n Y_j$ 而

$$S^2 = \frac{1}{m+n-2} \left(\sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{j=1}^n (Y_j - \bar{Y})^2 \right)$$

证明： $\mathbf{T}(\mathbf{X}, \mathbf{Y}) = (\bar{X}, \bar{Y}, S^2)^T$ 为充分统计量。

证明 由正态分布的概率密度函数和样本的独立性，我们得到分布族的概率函数为

$$\begin{aligned} f(\mathbf{x}, \mathbf{y}; \theta = (a, b, \sigma^2)^T) &= (2\pi\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^m (x_i - a)^2 \right\} (2\pi\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{j=1}^n (y_j - b)^2 \right\} \\ &= (2\pi\sigma^2)^{-n} \exp \left\{ -\frac{1}{2\sigma^2} \left(\sum_{i=1}^m (x_i - a)^2 + \sum_{j=1}^n (y_j - b)^2 \right) \right\} \end{aligned}$$

注意到

$$\begin{aligned} \sum_{i=1}^m (x_i - a)^2 &= \sum_{i=1}^m (x_i - \bar{x} + \bar{x} - a)^2 \\ &= \sum_{i=1}^m (x_i - \bar{x})^2 + 2 \sum_{i=1}^m (x_i - \bar{x})(\bar{x} - a) + \sum_{i=1}^m (\bar{x} - a)^2 \\ &= \sum_{i=1}^m (x_i - \bar{x})^2 + 2(\bar{x} - a) \sum_{i=1}^m (x_i - \bar{x}) + m(\bar{x} - a)^2 \\ &= \sum_{i=1}^m (x_i - \bar{x})^2 + m(\bar{x} - a)^2 \end{aligned}$$

同理有 $\sum_{j=1}^n (y_j - b)^2 = \sum_{j=1}^n (y_j - \bar{y})^2 + n(\bar{y} - b)^2$ 。代回概率函数有

$$\begin{aligned} f(\mathbf{x}, \mathbf{y}; \boldsymbol{\theta}) &= (2\pi\sigma^2)^{-n} \exp \left\{ -\frac{1}{2\sigma^2} \left(\sum_{i=1}^m (x_i - \bar{x})^2 + m(\bar{x} - a)^2 + \sum_{j=1}^n (y_j - \bar{y})^2 + n(\bar{y} - b)^2 \right) \right\} \\ &= (2\pi\sigma^2)^{-n} \exp \left\{ -\frac{1}{2\sigma^2} ((m+n-2)s^2 + m(\bar{x} - a)^2 + n(\bar{y} - b)^2) \right\} \\ &= g(\bar{x}, \bar{y}, s^2; a, b, \sigma^2) \end{aligned}$$

故概率函数可分解为 $f(\mathbf{x}, \mathbf{y}; \boldsymbol{\theta}) = g(\mathbf{T}(\mathbf{x}, \mathbf{y}), \boldsymbol{\theta})h(\mathbf{x}, \mathbf{y})$ ，其中 $h(\mathbf{x}, \mathbf{y}) \equiv 1$ 。由因子分解定理可知 \mathbf{T} 是充分统计量。

Exercise 3

在指数族的自然形式下，若自然参数空间有内点，求 $\text{Cov}(T_i(X), T_j(X))$ 的表达式。

定理 0.1 设指数族的自然形式中，自然参数空间有内点，其内点集为 Θ_0 。对 $\boldsymbol{\theta} \in \Theta_0$ ，有 $T_i(x)$ 的各阶矩均存在有限，可通过在积分号下求导算出。例如：

$$\begin{aligned} \mathbb{E}(T_i(x)) &= -\frac{\partial \log C^*(\boldsymbol{\theta})}{\partial \theta_i} \\ \text{Cov}(T_i(x), T_j(x)) &= -\frac{\partial^2 \log C^*(\boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} \end{aligned}$$

证明 由概率定义 $\int_{\mathcal{X}} f(x; \boldsymbol{\theta}) = 1$ ，有关系式

$$\frac{1}{C^*(\boldsymbol{\theta})} = \int_{\mathcal{X}} \exp \left\{ \sum_{j=1}^k \theta_j T_j(x) \right\} h(x) dx \quad (1)$$

对式 1 两边对 θ_i 求偏导有

$$-\frac{1}{C^*(\boldsymbol{\theta})^2} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_i} = \int_{\mathcal{X}} T_i(x) \exp \left\{ \sum_{j=1}^k \theta_j T_j(x) \right\} h(x) dx \quad (2)$$

注意到

$$\mathbb{E}(T_i(x)) = \int_{\mathcal{X}} T_i(x) C^*(\boldsymbol{\theta}) \exp \left\{ \sum_{j=1}^k \theta_j T_j(x) \right\} h(x) dx$$

所以

$$\mathbb{E}(T_i(x)) = -\frac{1}{C^*(\boldsymbol{\theta})^2} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_i} \cdot C^*(\boldsymbol{\theta}) = -\frac{\partial \log C^*(\boldsymbol{\theta})}{\partial \theta_i}$$

继续对式 2 关于 θ_j 求偏导有

$$\frac{2}{C^*(\boldsymbol{\theta})^3} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_i} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_j} - \frac{1}{C^*(\boldsymbol{\theta})^2} \frac{\partial^2 C^*(\boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} = \int_{\mathcal{X}} T_i(x) T_j(x) \exp \left\{ \sum_{l=1}^k \theta_l T_l(x) \right\} h(x) dx \quad (3)$$

注意到

$$\begin{aligned}\text{Cov}(T_i(x), T_j(x)) &= \mathbb{E}(T_i(x)T_j(x)) - \mathbb{E}(T_i(x))\mathbb{E}(T_j(x)) \\ &= \int_{\mathcal{X}} T_i(x)T_j(x)C^*(\boldsymbol{\theta}) \exp\left\{\sum_{l=1}^k \theta_l T_l(x)\right\} h(x) dx - \mathbb{E}(T_i(x))\mathbb{E}(T_j(x))\end{aligned}$$

代入式 2 和 $\mathbb{E}(T_i(x)), \mathbb{E}(T_j(x))$ 的表达式得

$$\begin{aligned}\text{Cov}(T_i(x), T_j(x)) &= \left(\frac{2}{C^*(\boldsymbol{\theta})^3} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_i} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_j} - \frac{1}{C^*(\boldsymbol{\theta})^2} \frac{\partial^2 C^*(\boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} \right) \cdot C^*(\boldsymbol{\theta}) \\ &\quad - \left(-\frac{1}{C^*(\boldsymbol{\theta})} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_i} \right) \left(-\frac{1}{C^*(\boldsymbol{\theta})} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_j} \right) \\ &= \frac{1}{C^*(\boldsymbol{\theta})^2} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_i} \frac{\partial C^*(\boldsymbol{\theta})}{\partial \theta_j} - \frac{1}{C^*(\boldsymbol{\theta})} \frac{\partial^2 C^*(\boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} \\ &= -\frac{\partial^2 \log C^*(\boldsymbol{\theta})}{\partial \theta_i \partial \theta_j}\end{aligned}$$

命题证毕。

Exercise 4

设样本 $\mathbf{X} = (X_1, \dots, X_n)^T \in \mathcal{X}$ 的概率函数 $f(\mathbf{x}, \theta) = f(x_1, \dots, x_n; \theta)$ 依赖于参数 θ 。如果 $T = T(\mathbf{X})$ 为 θ 的充分统计量，设 $S(\mathbf{X}) = G(T(\mathbf{X}))$ ，其中 G 为单值可逆函数，用因子分解定理证明 $S(\mathbf{X}) = G(T(\mathbf{X}))$ 也是 θ 的充分统计量。

证明 因为 $T = T(\mathbf{X})$ 为 θ 的充分统计量，所以概率函数 f 可分解

$$f(\mathbf{x}, \theta) = g(T(\mathbf{x}), \theta)h(\mathbf{x})$$

又因为 G 为单值可逆函数，故存在反函数 G^{-1} ，由 $S(\mathbf{X}) = G(T(\mathbf{X}))$ 有

$$T(\mathbf{x}) = G^{-1}(S(\mathbf{x}))$$

代入 $f(\mathbf{x}, \theta)$ 有关系式

$$f(\mathbf{x}, \theta) = g(G^{-1}(S(\mathbf{x})), \theta)h(\mathbf{x}) := \tilde{g}(S(\mathbf{x}), \theta)h(\mathbf{x})$$

所以，由因子分解定理知， $S(\mathbf{X}) = G(T(\mathbf{X}))$ 也是 θ 的充分统计量。

HW5 第五次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设 $\mathbf{X} = (X_1, \dots, X_n) \stackrel{\text{i.i.d.}}{\sim} E(\theta, 1)$ 其中概率密度函数为

$$f(x; \theta) = e^{-(x-\theta)} \cdot \mathbb{I}(x > \theta)$$

其中 $\theta \in \mathbb{R}$ 为位置参数。证明： $T(\mathbf{X}) = X_{(1)}$ 为极小充分完全统计量。

证明 分 3 步证明：先证充分，再证极小，最后证完全。

(1) 充分统计量 样本 (X_1, \dots, X_n) 的联合密度为

$$\begin{aligned} f(\mathbf{x}; \theta) &= \prod_{i=1}^n e^{-(x_i-\theta)} \cdot \mathbb{I}(x_i > \theta) = \exp \left\{ -\sum_{i=1}^n x_i + n\theta \right\} \cdot \mathbb{I} \left(\min_i x_i > \theta \right) \\ &= e^{n\theta} \mathbb{I}(x_{(1)} > \theta) \cdot \exp \left\{ -\sum_{i=1}^n x_i \right\} := g(T(\mathbf{x}), \theta) h(\mathbf{x}) \end{aligned}$$

其中 $T(\mathbf{X}) = X_{(1)}$ 于是 $g(T(\mathbf{x}), \theta) = e^{n\theta} \mathbb{I}(x_{(1)} > \theta)$ ，而 $h(\mathbf{x}) = \exp\{-\sum_{i=1}^n x_i\}$ 。根据因子分解定理， $T(\mathbf{X}) = X_{(1)}$ 为充分统计量。

(2) 极小充分统计量 考虑样本 \mathbf{X} 和 \mathbf{Y} 的联合密度的比为

$$\frac{f(\mathbf{x}; \theta)}{f(\mathbf{y}; \theta)} = \frac{e^{n\theta} \mathbb{I}(x_{(1)} > \theta) \cdot \exp\{-\sum_{i=1}^n x_i\}}{e^{n\theta} \mathbb{I}(y_{(1)} > \theta) \cdot \exp\{-\sum_{i=1}^n y_i\}} = \exp \left\{ -\sum_{i=1}^n x_i + \sum_{i=1}^n y_i \right\} \frac{\mathbb{I}(x_{(1)} > \theta)}{\mathbb{I}(y_{(1)} > \theta)}$$

上式与 θ 无关，等价于 $X_{(1)} = Y_{(1)}$ （否则取 θ 处于 $X_{(1)}$ 和 $Y_{(1)}$ 之间）。于是根据定理 0.1 可知 $T(\mathbf{X}) = X_{(1)}$ 是极小充分统计量。

(2) 极小充分完全统计量 首先 $X_{(1)}$ 为次序统计量，故其概率密度为

$$\begin{aligned} f_{X_{(1)}}(x) &= \binom{n}{1} \left[1 - \int_{\theta}^x e^{-(t-\theta)} dt \right]^{n-1} e^{-(x-\theta)} \cdot \mathbb{I}(x > \theta) \\ &= n e^{-n(x-\theta)} \mathbb{I}(x > \theta) \end{aligned}$$

于是对任一函数 $\varphi(\cdot)$ 有对于任意 θ 有

$$\mathbb{E}_\theta(\varphi(T(\mathbf{X}))) = \mathbb{E}_\theta(\varphi(X_{(1)})) = \int_\theta^\infty \varphi(x) n e^{-n(x-\theta)} dx = n e^{n\theta} \int_\theta^\infty \varphi(x) e^{-nx} dx$$

令 $\mathbb{E}_\theta(\varphi(T(\mathbf{X}))) = 0$, 由于 $n e^{n\theta} > 0$ 有

$$n e^{n\theta} \int_\theta^\infty \varphi(x) e^{-nx} dx = 0 \Rightarrow \int_\theta^\infty \varphi(x) e^{-nx} dx = 0$$

等式对 θ 求导得 $0 - \varphi(\theta) e^{-n\theta} = 0$ 。于是 $\forall \theta$ 有 $\varphi(\theta) \equiv 0$ 。

综上有 $\mathbb{E}_\theta(\varphi(T(\mathbf{X}))) = 0$ 等价于 $\varphi(\cdot) \equiv 0$, 即 $P_\theta(\varphi(T(\mathbf{X})) = 0) = 1$ 。由完全统计量的定义可知 $T(\mathbf{X}) = X_{(1)}$ 为极小充分完全统计量, 命题证毕。

定理 0.1 设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} f(x, \theta)$, $\theta \in \Theta$, 若下面等价条件成立:

$$\frac{f(x, \theta)}{f(y, \theta)} \text{ 不依赖于 } \theta \Leftrightarrow T(x) = T(y)$$

则 T 为极小充分统计量。

Exercise 2

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} U(\theta, 2\theta)$ 其中 $\theta > 0$ 。证明: $(X_{(1)}, X_{(n)})$ 是充分统计量, 但不是完全的。

证明 X_1, \dots, X_n 的联合密度为

$$f(\mathbf{x}; \theta) = \prod_{i=1}^n \frac{1}{\theta} \cdot \mathbb{I}_{(\theta, 2\theta)}(x_i) = \theta^{-n} \mathbb{I}(\theta < x_{(1)} \leq x_{(n)} < 2\theta) := g(T(\mathbf{x}), \theta) h(\mathbf{x})$$

其中 $g(T(\mathbf{x}), \theta) = \theta^{-n} \mathbb{I}(\theta < x_{(1)} \leq x_{(n)} < 2\theta)$ 而 $h(\mathbf{x}) = 1$ 。由因子分解定理, $(X_{(1)}, X_{(n)})$ 是充分统计量。

下面, 令 $Y_i = X_i/\theta$ 则易知 $Y_i \sim U(1, 2)$ 与 θ 无关。于是 $Z = X_{(n)}/X_{(1)}$ 的分布也与 θ 无关, 即 Z 的分布确定。所以, 存在 $a < b$ 使得 $P(Z < a) = P(Z > b) > 0$, 构造函数 $\varphi(\cdot)$ 为

$$\varphi(x_{(1)}, x_{(n)}) = \begin{cases} 1, & x_{(n)}/x_{(1)} < a \\ -1, & x_{(n)}/x_{(1)} > a \\ 0, & \text{其他} \end{cases}$$

于是 $\mathbb{E}_\theta(\varphi(T(\mathbf{X}))) = 0$, 但 $\varphi(\cdot) \not\equiv 0$, 即 $T(\mathbf{X}) = (X_{(1)}, X_{(n)})$ 不是完全统计量。

Exercise 3

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(\mu, \sigma^2)$ 其中 $\mu \in \mathbb{R}$, $\sigma^2 \in \mathbb{R}^+$ 。证明: \bar{X} 和 $(X_{(n)} - X_{(1)})$ 相互独立。

证明 首先, 写出 X_1, \dots, X_n 的联合密度为

$$f(\mathbf{x}; \boldsymbol{\theta}) = (2\pi\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right\}$$

易知可以写成因子分解形式, 故 \bar{X} 为充分统计量。然后写出其自然形式

$$f(\mathbf{x}; \boldsymbol{\theta}) = (2\pi\sigma^2)^{-n/2} e^{n\mu^2/2\sigma^2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 + \frac{\mu}{\sigma^2} \sum_{i=1}^n x_i \right\}$$

注意到自然参数空间为

$$\Theta^* = \left\{ \boldsymbol{\theta} = \left(-\frac{1}{2\sigma^2}, \frac{\mu}{\sigma^2} \right) : -\frac{1}{2\sigma^2} \in (-\infty, 0), \frac{\mu}{\sigma^2} \in (-\infty, +\infty) \right\}$$

指数族中, 由 Θ^* 有内点, 故 $(\sum X_i, \sum X_i^2)$ 为完全统计量。

记 $Y_i = (X_i - \mu)/\sigma$, 于是 $Y_i \sim N(0, 1)$ 与 $\boldsymbol{\theta}$ 无关。注意到 $X_{(n)} - X_{(1)} = Y_{(n)} - Y_{(1)}$ 的分布, 同理与 $\boldsymbol{\theta} = (\mu, \sigma^2)$ 无关。则由 Basu 定理, $X_{(n)} - X_{(1)}$ 和 $(\sum X_i, \sum X_i^2)$ 相互独立, 即有 $\bar{X} \perp\!\!\!\perp (X_{(n)} - X_{(1)})$, 命题证毕。

Exercise 4

设总体 X 服从均匀分布 $U(0, 2\theta)$, 令 X_1, \dots, X_n 为从总体 X 中抽取的简单随机样本。

- 证明 $\hat{\theta}_1 = \bar{X}$ 和 $\hat{\theta}_2 = \frac{(n+1)X_{(n)}}{2n}$ 为 θ 的无偏估计。
- 证明 $\hat{\theta}_1$ 为 θ 的强相合估计, $\hat{\theta}_2 = \frac{X_{(n)}}{2}$ 为 θ 的弱相合估计。
- 求 $\hat{\theta}_1$ 和 $\hat{\theta}_2$ 的方差, 比较它们的有效性。

证明 (a) 由 $X \sim U(0, 2\theta)$ 故其概率密度为

$$f(x; \theta) = \frac{1}{2\theta} \cdot \mathbb{I}_{(0, 2\theta)}(x)$$

于是可求 $\hat{\theta}_1$ 的期望

$$\mathbb{E}(\hat{\theta}_1) = \mathbb{E}(\bar{X}) = \mathbb{E}(X_1) = \int_0^{2\theta} \frac{x}{2\theta} dx = \frac{(2\theta)^2}{4\theta} - 0 = \theta$$

故 $\hat{\theta}_1 = \bar{X}$ 为 θ 的无偏估计。同理求 $\hat{\theta}_2 = \frac{(n+1)X_{(n)}}{2n}$ 的期望。注意到 $X_{(n)}$ 的密度函数为

$$f_{X_{(n)}}(x) = n \left(\frac{x}{2\theta} \right)^{n-1} \frac{1}{2\theta}$$

所以有

$$\begin{aligned} \mathbb{E}(\hat{\theta}_2) &= \mathbb{E} \left(\frac{(n+1)X_{(n)}}{2n} \right) = \frac{n+1}{2n} \int_0^{2\theta} n \left(\frac{x}{2\theta} \right)^{n-1} \frac{1}{2\theta} \cdot x dx \\ &= \frac{n+1}{2} \int_0^{2\theta} \left(\frac{x}{2\theta} \right)^n dx = \frac{n+1}{2} \left[\frac{2\theta}{n+1} \left(\frac{2\theta}{2\theta} \right)^{n+1} - 0 \right] \\ &= \frac{n+1}{2} \frac{2\theta}{n+1} = \theta \end{aligned}$$

于是 $\hat{\theta}_2 = \frac{(n+1)X_{(n)}}{2n}$ 为 θ 的无偏估计, 命题证毕。

证明 (b) 由 $X \sim U(0, 2\theta)$, $\theta > 0$ 知我们只考虑 $X > 0$ 的分布, 即有 $\mathbb{E}(|X|) = \mathbb{E}(X) = \theta < \infty$ 。故由强大数定律可知

$$\hat{\theta}_1 = \bar{X} \xrightarrow{\text{a.s.}} \mathbb{E}(X_1) = \theta$$

即 $\hat{\theta}_1$ 为 θ 的强相合估计。下面证: $\theta_2^* = \frac{X_{(n)}}{2}$ 为 θ 的弱相合估计。

注意到 $X_{(n)}$ 的分布函数为

$$F_{X_{(n)}}(x) = \int_0^{\min\{2\theta, x\}} n \left(\frac{t}{2\theta}\right)^{n-1} \frac{1}{2\theta} dt = \left(\frac{t}{2\theta}\right)^n \Big|_0^{\min\{2\theta, x\}}$$

考虑不平凡的情况 $F_{X_{(n)}}(x) = \left(\frac{t}{2\theta}\right)^n \Big|_0^x \cdot \mathbb{I}(x < 2\theta) = \left(\frac{x}{2\theta}\right)^n \cdot \mathbb{I}(x < 2\theta)$ 。所以对 $\forall \epsilon > 0$ 和不平凡的 $X_{(n)} < 2\theta$ 有

$$\begin{aligned} P(|X_{(n)} - 2\theta| > \epsilon) &= P(X_{(n)} - 2\theta < -\epsilon) = P(X_{(n)} < 2\theta - \epsilon) = F_{X_{(n)}}(2\theta - \epsilon) \\ &= \left(\frac{2\theta - \epsilon}{2\theta}\right)^n = (1 - \epsilon/2\theta)^n \rightarrow 0 \quad \text{as } n \rightarrow \infty \end{aligned}$$

当 $\epsilon < 2\theta$ 成立 (平凡地, 当 $\epsilon > 2\theta$, 显然有 $P(|X_{(n)} - 2\theta| > \epsilon) = 0$ 同样成立)。于是有对 $\forall \epsilon > 0$ 有

$$\lim_{n \rightarrow \infty} P(|X_{(n)} - 2\theta| \leq \epsilon) = 1 \Rightarrow \lim_{n \rightarrow \infty} P(|X_{(n)}/2 - \theta| \leq \epsilon/2) = 1$$

即 $\theta_2^* = X_{(n)}/2 \xrightarrow{P} \theta$, 为 θ 的弱相合估计。

解答 (c) 因为 $X \sim U(0, 2\theta)$ 故有方差为 $\mathbb{D}(X) = \frac{(2\theta-0)^2}{12} = \frac{\theta^2}{3}$ 。所以样本均值的方差为

$$\mathbb{D}(\hat{\theta}_1) = \mathbb{D}(\bar{X}) = \frac{1}{n^2} \sum_{i=1}^n \mathbb{D}(X_i) = \frac{n}{n^2} \cdot \frac{\theta^2}{3} = \frac{\theta^2}{3n}$$

由问题 a 计算的结果 $\mathbb{E}(X_{(n)}) = 2n\theta/(n+1)$, 下面计算 $\mathbb{E}(X_{(n)}^2)$ 有

$$\begin{aligned} \mathbb{E}(X_{(n)}^2) &= \int_0^{2\theta} n \left(\frac{x}{2\theta}\right)^{n-1} \frac{1}{2\theta} \cdot x^2 dx = \int_0^{2\theta} n \left(\frac{x}{2\theta}\right)^n \cdot x dx \\ &= 4n\theta^2 \int_0^{2\theta} \left(\frac{x}{2\theta}\right)^{n+1} d\frac{x}{2\theta} = 4n\theta^2 \cdot \frac{1}{n+2} \cdot 1 = \frac{4n\theta^2}{n+2} \end{aligned}$$

于是有方差为

$$\mathbb{D}(X_{(n)}) = \mathbb{E}(X_{(n)}^2) - [\mathbb{E}(X_{(n)})]^2 = \frac{4n\theta^2}{n+2} - \left(\frac{2n\theta}{n+1}\right)^2 = \frac{4n\theta^2}{(n+1)^2(n+2)}$$

所以 $\hat{\theta}_2$ 的方差为

$$\mathbb{D}(\hat{\theta}_2) = \mathbb{D}\left(\frac{(n+1)X_{(n)}}{2n}\right) = \frac{(n+1)^2}{4n^2} \frac{4n\theta^2}{(n+1)^2(n+2)} = \frac{\theta^2}{n(n+2)}$$

因为二者都是无偏的, 故比较二者方差, 在任意 θ 下有

$$\mathbb{D}(\hat{\theta}_1) = \frac{\theta^2}{3n} \sim O(1/n) \quad \mathbb{D}(\hat{\theta}_2) = \frac{\theta^2}{n(n+2)} \sim O(1/n^2)$$

当 $n > 1$ 时 $\mathbb{D}(\hat{\theta}_2) < \mathbb{D}(\hat{\theta}_1)$, 故 $\hat{\theta}_2$ 比 $\hat{\theta}_1$ 更有效。

HW6 第六次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设 X_1, \dots, X_n 为取自对数级数分布的简单随机样本,

$$P(X = k) = -\frac{1}{\log(1-p)} \cdot \frac{p^k}{k}, \quad k = 1, 2, \dots$$

其中参数 $p \in (0, 1)$, 求 p 的矩估计。

解答 记 k 阶矩为 $\alpha_k = \mathbb{E}\{X^k\}$, 样本 k 阶矩为 $a_{nk} = \sum_{i=1}^n X_i^k/n$, 于是有

$$\alpha_1 = \sum_{k=1}^{\infty} k \cdot P(X = k) = -\frac{1}{\log(1-p)} \sum_{k=1}^{\infty} k \cdot \frac{p^k}{k} = -\frac{1}{\log(1-p)} \sum_{k=1}^{\infty} p^k = -\frac{1}{\log(1-p)} \cdot \frac{p}{1-p}$$

于是使用一阶样本矩估计有

$$a_{n1} = -\frac{1}{\log(1-\hat{p})} \cdot \frac{\hat{p}}{1-\hat{p}} \quad (1)$$

同理求二阶矩

$$\alpha_2 = \sum_{k=1}^{\infty} k^2 \cdot P(X = k) = -\frac{1}{\log(1-p)} \sum_{k=1}^{\infty} k^2 \cdot \frac{p^k}{k} = -\frac{1}{\log(1-p)} \sum_{k=1}^{\infty} k \cdot p^k$$

记 $M_k = -\log(1-p)\alpha_k$, 于是注意到

$$M_2 - p \cdot M_1 = \sum_{k=1}^{\infty} k \cdot p^k - \sum_{k=1}^{\infty} k \cdot p^{k+1} = \sum_{k=1}^{\infty} k \cdot p^k - \sum_{k=2}^{\infty} (k-1) \cdot p^k = p + \sum_{k=2}^{\infty} p^k = p + \frac{p^2}{1-p}$$

于是有

$$\alpha_2 = -\frac{1}{\log(1-p)} \cdot M_2 = -\frac{1}{\log(1-p)} \cdot \frac{p}{(1-p)^2}$$

所以使用二阶样本矩估计有

$$a_{n2} = -\frac{1}{\log(1-\hat{p})} \cdot \frac{\hat{p}}{(1-\hat{p})^2} \quad (2)$$

联合使用 a_{n1}, a_{n2} 进行估计, 即求解方程式 1 和式 2

$$\begin{cases} a_{n1} = -\frac{1}{\log(1-\hat{p})} \cdot \frac{\hat{p}}{1-\hat{p}} \\ a_{n2} = -\frac{1}{\log(1-\hat{p})} \cdot \frac{\hat{p}}{(1-\hat{p})^2} \end{cases}$$

于是有 $a_{n1}/a_{n2} = 1 - \hat{p}$, 即 p 的矩估计为

$$\hat{p} = 1 - \frac{a_{n1}}{a_{n2}} = 1 - \frac{\sum_{i=1}^n X_i}{\sum_{i=1}^n X_i^2}$$

Exercise 2

设 X_1, \dots, X_n 是来自总体 $N(0, \sigma^2)$ 的简单随机样本, 求 σ 的矩估计。

1. 利用 $\mathbb{E}\{|X_1|\} = \sigma\sqrt{2/\pi}$
2. 利用 $\sigma = \sqrt{\mathbb{D}\{X_1\}}$

解答 由 $\mathbb{E}\{|X_1|\} = \sigma\sqrt{2/\pi}$ 故使用有关 $|X_i|$ 的矩进行估计

$$\hat{\sigma}^2 = \sqrt{\frac{\pi}{2}} \cdot \frac{1}{n} \sum_{i=1}^n |X_i|$$

类似地, $\sigma = \sqrt{\mathbb{D}\{X_1\}}$, 利用 m_{n2} 估计 $\mathbb{D}\{X_1\}$ 得到 σ 的估计

$$\hat{\sigma}^2 = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}$$

注 记 $Y_i = |X_i|$, 于是有 Y_i 独立同分布, 且

$$\begin{aligned} \mathbb{E}\{Y_1\} &= \int_{\{y=|x|: x \in \mathbb{R}\}} (2\pi\sigma^2)^{-1/2} e^{-\frac{y^2}{2\sigma^2}} dy \\ &= \int_{\{y=x: x>0\}} (2\pi\sigma^2)^{-1/2} e^{-\frac{y^2}{2\sigma^2}} dy + \int_{\{y=-x: x<0\}} (2\pi\sigma^2)^{-1/2} e^{-\frac{y^2}{2\sigma^2}} dy \\ &= 2 \int_0^\infty (2\pi\sigma^2)^{-1/2} e^{-\frac{y^2}{2\sigma^2}} dy = \sigma\sqrt{2/\pi} < \infty \end{aligned}$$

由强大数定理可知

$$\frac{1}{n} \sum_{i=1}^n |X_i| = \frac{1}{n} \sum_{i=1}^n Y_i \xrightarrow{\text{a.s.}} \mathbb{E}\{Y_1\} = \sigma\sqrt{2/\pi}$$

所以使用 $|X_i|$ 相关矩的矩估计, 其相合性得到保证。

Exercise 3

若 $X = e^\xi$, 而 $\xi \sim N(\mu, \sigma^2)$, 则 X 的分布称为对数正态分布。求 X 的概率密度函数。设 X_1, \dots, X_n 是从总体 X 中抽出的简单随机样本, 求 μ 和 σ^2 的矩估计和 MLE。

解答 由 $\xi \sim N(\mu, \sigma^2)$ 可知 ξ 的概率密度函数为

$$f_{\Xi}(\xi; \mu, \sigma^2) = (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{(\xi - \mu)^2}{2\sigma^2} \right\}$$

而 $\xi = \log X$ 故有 X 的概率密度函数为

$$f_X(x; \mu, \sigma^2) = f_{\Xi}(\xi(x); \mu, \sigma^2) \cdot |d\xi/dx| = (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{(\log x - \mu)^2}{2\sigma^2} \right\} x^{-1}$$

(1) 求解矩估计。 根据密度函数, 可求 k 阶矩 (注意 $X = e^{\xi} > 0$), 例如

$$\begin{aligned} \mathbb{E}\{X\} &= \int_0^{\infty} (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{(\log x - \mu)^2}{2\sigma^2} \right\} dx \\ &\stackrel{\log x=t}{=} \int_{-\infty}^{+\infty} (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{(t - \mu)^2}{2\sigma^2} \right\} e^t dt \\ &= \int_{-\infty}^{+\infty} (2\pi\sigma^2)^{-1/2} \exp \left\{ \frac{2\sigma^2 t - (t^2 - 2\mu t + \mu^2)}{2\sigma^2} \right\} dt \end{aligned}$$

注意到

$$2\sigma^2 t - (t^2 - 2\mu t + \mu^2) = -[t - (\mu + \sigma^2)]^2 + (\mu + \sigma^2)^2 - \mu^2 = -(t - \mu - \sigma^2)^2 + 2\mu\sigma^2 + \sigma^4$$

代回 $\mathbb{E}\{X\}$ 有

$$\mathbb{E}\{X\} = e^{\mu+\sigma^2/2} \int_{-\infty}^{+\infty} (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{(t - \mu - \sigma^2)^2}{2\sigma^2} \right\} dt$$

积分中函数可视为正态分布密度函数在 \mathbb{R} 的积分, 即为 1, 所以 $\mathbb{E}\{X\} = e^{\mu+\sigma^2/2}$ 。类似地, 二阶矩为

$$\begin{aligned} \mathbb{E}\{X^2\} &= \int_0^{\infty} (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{(\log x - \mu)^2}{2\sigma^2} \right\} x^2 dx \\ &\stackrel{\log x=t}{=} \int_{-\infty}^{+\infty} (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{(t - \mu)^2}{2\sigma^2} \right\} e^{2t} dt \\ &= e^{2\mu+2\sigma^2} \int_{-\infty}^{+\infty} (2\pi\sigma^2)^{-1/2} \exp \left\{ -\frac{(t - \mu - 2\sigma^2)^2}{2\sigma^2} \right\} dt \end{aligned}$$

故 $\mathbb{E}\{X^2\} = e^{2\mu+2\sigma^2}$ 。于是解下列方程得到矩和参数的关系

$$\begin{cases} \mu + \sigma^2/2 = \log \mathbb{E}\{X\} \leftarrow \log a_{n1} \\ 2\mu + 2\sigma^2 = \log \mathbb{E}\{X^2\} \leftarrow \log a_{n2} \end{cases}$$

于是得到矩估计为

$$\begin{cases} \hat{\mu} = -\log \sqrt{a_{n2}} = -\log \sqrt{\frac{1}{n} \sum_{i=1}^n X_i^2} \\ \hat{\sigma}^2 = \log \frac{a_{n2}}{a_{n1}^2} = \log \frac{n \sum_{i=1}^n X_i^2}{(\sum_{i=1}^n X_i)^2} \end{cases}$$

特别地, 这里的矩估计不唯一。例如, 如果使用 m_{nk} 估计则得到的表达式不同。

$$e^{2\mu+2\sigma^2} - e^{2\mu+\sigma^2} = \mathbb{E}\{X^2\} - [\mathbb{E}\{X\}]^2 = \mu_2 \leftarrow m_{n2}$$

于是有 $[\mathbb{E}\{X\}]^2(e^\sigma - 1) = e^{2\mu+\sigma^2}(e^\sigma - 1) = \mu_2$, 于是有 $e^\sigma - 1 = \mu_2/\alpha_1^2$, 那么另一种矩估计为

$$\begin{cases} \hat{\mu} = \log \alpha_1 - \frac{1}{2}\hat{\sigma}^2 = \log \bar{X} - \log \left(\sqrt{1 + \frac{n \sum_{i=1}^n (X_i - \bar{X})^2}{(\sum_{i=1}^n X_i)^2}} \right) \\ \hat{\sigma}^2 = \log \left(1 + \frac{m_{n2}}{a_{n1}^2} \right) = \log \left(1 + \frac{n \sum_{i=1}^n (X_i - \bar{X})^2}{(\sum_{i=1}^n X_i)^2} \right) \end{cases}$$

(2) 求解极大似然估计。已知概率密度, 故似然函数为

$$L(\mu, \sigma^2; \mathbf{x}) = (2\pi\sigma^2)^{-n/2} \exp \left\{ \sum_{i=1}^n -\frac{(\log x_i - \mu)^2}{2\sigma^2} \right\} \prod_{i=1}^n x_i^{-1}$$

那么对数似然函数为

$$l(\mu, \sigma^2; \mathbf{x}) = -\frac{n}{2} \log(2\pi\sigma^2) - \sum_{i=1}^n \frac{(\log x_i - \mu)^2}{2\sigma^2} - \sum_{i=1}^n \log x_i$$

分别求偏导有

$$\frac{\partial l(\mu, \sigma^2)}{\partial \mu} = \sum_{i=1}^n \frac{2(\log x_i - \mu)}{2\sigma^2} = 0 \quad \Leftrightarrow \quad \sum_{i=1}^n \log x_i = n\mu$$

所以有 μ 的 MLE 为 $\hat{\mu}_{\text{MLE}} = \frac{1}{n} \sum_{i=1}^n \log X_i$ 。代回对数似然, 并对 σ^2 求偏导有

$$\frac{\partial l(\mu, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2} \frac{2\pi}{2\pi\sigma^2} + \sum_{i=1}^n \frac{2(\log x_i - \hat{\mu}_{\text{MLE}})^2}{4\sigma^4} = 0$$

于是有 σ^2 的 MLE 为 $\hat{\sigma}_{\text{MLE}}^2 = \frac{1}{n} \sum_{i=1}^n (\log X_i - \hat{\mu}_{\text{MLE}})^2$ 。

Exercise 4

设 X_1, \dots, X_n 是来自双参数指数分布

$$f(x; \mu, \sigma) = \frac{1}{\sigma} \exp \left\{ -\frac{x - \mu}{\sigma} \right\} \cdot \mathbb{I}(x \geq \mu)$$

的简单随机样本, 其中 $\mu \in \mathbb{R}$, $\sigma \in \mathbb{R}^+$ 。记 $\theta = (\mu, \sigma)$, 求 μ, σ 和 $P_\theta(X_1 \geq t)$ (其中 $t > \mu$ 已知) 的矩估计和 MLE。

解答 记 $t = (x - \mu)/\sigma$ 于是我们得到下列积分结果

$$\begin{aligned} \mathbb{E}\{X_1\} &= \int_{\mu}^{\infty} \frac{x}{\sigma} \exp \left\{ -\frac{x - \mu}{\sigma} \right\} dx = \int_0^{\infty} (\mu + \sigma t) e^{-t} dt = \mu + \sigma \\ \mathbb{E}\{X_1^2\} &= \int_{\mu}^{\infty} \frac{x^2}{\sigma} \exp \left\{ -\frac{x - \mu}{\sigma} \right\} dx = \int_0^{\infty} (\mu + \sigma t)^2 e^{-t} dt = \mu^2 + 2\sigma\mu + 2\sigma^2 \end{aligned}$$

(1) 求解矩估计: 注意到 $\mathbb{E}\{X_1^2\} = \mu^2 + 2\sigma\mu + 2\sigma^2 = (\mu + \sigma)^2 + \sigma^2 = [\mathbb{E}\{X_1\}]^2 + \sigma^2$, 即 $\sigma^2 = \mathbb{E}\{X_1^2\} - [\mathbb{E}\{X_1\}]^2 = \mu_2$, 于是可得 σ 的矩估计 $\hat{\sigma}_{\text{MM}} = \sqrt{m_{n2}}$ 。代回可得 μ 的矩估计 $\hat{\mu}_{\text{MM}} = a_{n1} - \sqrt{m_{n2}}$ 。下面计算 $P_\theta(X_1 \geq t)$

$$P_\theta(X_1 \geq t) = \int_t^{\infty} \frac{1}{\sigma} \exp \left\{ -\frac{x - \mu}{\sigma} \right\} dx = -\exp \left\{ -\frac{x - \mu}{\sigma} \right\} \Big|_t^{\infty} = \exp \left\{ -\frac{t - \mu}{\sigma} \right\}$$

结合矩估计的性质，可以得到以下矩估计

$$\begin{cases} \hat{\mu}_{\text{MM}} = a_{n1} - \sqrt{m_{n2}} = \bar{X} - \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \\ \hat{\sigma}_{\text{MM}} = \sqrt{m_{n2}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \\ \hat{P}_{\text{MM}}(X_1 \geq t) = \exp \left\{ -\frac{t - \hat{\mu}_{\text{MM}}}{\hat{\sigma}_{\text{MM}}} \right\} \end{cases}$$

(2) 求解似极大然估计：已知概率密度函数，可求似然函数

$$L(\mu, \sigma; \mathbf{x}) = \prod_{i=1}^n \frac{1}{\sigma} \exp \left\{ -\frac{x_i - \mu}{\sigma} \right\} \cdot \mathbb{I}(x_i \geq \mu) = \frac{1}{\sigma^n} \exp \left\{ \sum_{i=1}^n -\frac{x_i - \mu}{\sigma} \right\} \cdot \mathbb{I}(x_{(1)} \geq \mu)$$

于是对数似然为

$$\begin{aligned} l(\mu, \sigma; \mathbf{x}) &= \left(-n \log \sigma - \sum_{i=1}^n \frac{x_i - \mu}{\sigma} \right) \cdot \mathbb{I}(x_{(1)} \geq \mu) \\ &= \left(-n \log \sigma - \sigma^{-1} \sum_{i=1}^n x_i + n\mu\sigma^{-1} \right) \cdot \mathbb{I}(x_{(1)} \geq \mu) \end{aligned}$$

求解下列方程

$$\begin{cases} \frac{\partial l(\mu, \sigma)}{\partial \mu} = n\sigma^{-1} > 0 \\ \frac{\partial l(\mu, \sigma)}{\partial \sigma} = -n\sigma^{-1} + \sigma^{-2} \sum_{i=1}^n x_i - n\mu\sigma^{-2} = 0 \end{cases}$$

由 $\partial l / \partial \mu > 0$ 可知，极大化似然函数，需要 μ 尽可能大，但为了满足 $X_{(1)} \geq \mu$ ，故有 μ 的 MLE 为 $\hat{\mu}_{\text{MLE}} = X_{(1)}$ 。同时，求解第二个方程有 σ 的 MLE 为 $\hat{\sigma}_{\text{MLE}} = \bar{X} - \hat{\mu}_{\text{MLE}} = \bar{X} - X_{(1)}$ 。综上有极大似然估计为

$$\begin{cases} \hat{\mu}_{\text{MLE}} = X_{(1)} \\ \hat{\sigma}_{\text{MLE}} = \bar{X} - X_{(1)} \\ \hat{P}_{\text{MLE}}(X_1 \geq t) = \exp \left\{ -\frac{t - \hat{\mu}_{\text{MLE}}}{\hat{\sigma}_{\text{MLE}}} \right\} \end{cases}$$

HW7 第七次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设 (X_1, \dots, X_n) 是来自均匀分布 $U[\theta, 2\theta]$ 的简单随机样本，其中 $\theta \in (0, +\infty)$ ，求 θ 的 MLE。判断它是否为 θ 的无偏估计。如果不是，试对它略作修改，得到 θ 的一个无偏估计。

解答 由于 $X_i \sim U[\theta, 2\theta]$ ，其概率密度函数为

$$f(x; \theta) = \frac{1}{\theta} \cdot \mathbb{I}(\theta \leq x \leq 2\theta)$$

因此，样本的对数似然函数为

$$l(\theta) = \log L(\theta) = \log \left(\prod_{i=1}^n f(x_i; \theta) \right) = -n \log \theta \cdot \mathbb{I}(\theta \leq x_{(1)} \leq x_{(n)} \leq 2\theta)$$

容易看出，当 $\theta \leq x_{(1)} \leq x_{(n)} \leq 2\theta$ 时， $l(\theta)$ 随 θ 增大而减小，因此， $l(\theta)$ 在区间 $x_{(n)}/2$ 上取得最大值。故 θ 的 MLE 为 $\hat{\theta}_{\text{MLE}} = \frac{X_{(n)}}{2}$ 。

接下来计算 $\hat{\theta}_{\text{MLE}}$ 的期望，由次序统计量的性质可知，最大值 $X_{(n)}$ 的概率密度函数为

$$f_{X_{(n)}}(x) = \frac{n}{\theta^n} (x - \theta)^{n-1} \cdot \mathbb{I}(\theta \leq x \leq 2\theta)$$

因此，

$$\begin{aligned} \mathbb{E}[\hat{\theta}_{\text{MLE}}] &= \mathbb{E} \left[\frac{X_{(n)}}{2} \right] = \int_{\theta}^{2\theta} \frac{x}{2} \cdot f_{X_{(n)}}(x) dx = \int_{\theta}^{2\theta} \frac{x}{2} \cdot \frac{n}{\theta^n} (x - \theta)^{n-1} dx \\ &\stackrel{t=x-\theta}{=} \int_0^{\theta} \frac{t + \theta}{2} \cdot \frac{n}{\theta^n} t^{n-1} dt = \frac{n}{2\theta^n} \int_0^{\theta} t^n dt + \frac{n\theta}{2\theta^n} \int_0^{\theta} t^{n-1} dt \\ &= \frac{n}{2(n+1)}\theta + \frac{1}{2}\theta = \frac{2n+1}{2(n+1)}\theta \end{aligned}$$

故 $\hat{\theta}_{\text{MLE}}$ 不是 θ 的无偏估计。但可以通过修正得到 θ 的一个无偏估计：

$$\hat{\theta}_{\text{U}} = \frac{2(n+1)}{2n+1} \cdot \hat{\theta}_{\text{MLE}} = \frac{n+1}{2n+1} X_{(n)}$$

Exercise 2

设 X_1, \dots, X_n 为取自下列指数分布的简单随机样本,

$$f(x; \mu) = e^{-(x-\mu)} \cdot \mathbb{I}(x > \mu), \quad \mu \in \mathbb{R}$$

- (1) 试求 μ 的极大似然估计 $\hat{\mu}_{\text{MLE}}$ 是 μ 的无偏估计吗? 如果不是, 试对它作修改, 以得到 μ 的无偏估计 $\hat{\mu}_{\text{U}}$ 。
- (2) 试求 μ 的矩估计 $\hat{\mu}_{\text{MM}}$, 并证明它是 μ 的无偏估计。
- (3) 试问 $\hat{\mu}_{\text{U}}$ 和 $\hat{\mu}_{\text{MM}}$ 哪一个更有效?

解答 (1) 样本的对数似然函数为

$$l(\mu) = \log L(\mu) = \log \left(\prod_{i=1}^n f(x_i; \mu) \right) = - \sum_{i=1}^n (x_i - \mu) \cdot \mathbb{I}(\mu < x_{(1)})$$

容易看出, 当 $\mu < x_{(1)}$ 时, $l(\mu)$ 随 μ 增大而增大, 因此, μ 的 MLE 为 $\hat{\mu}_{\text{MLE}} = X_{(1)}$ 。

记 $Y_i = X_i - \mu$, 则 Y_i 的概率密度函数为 $f(y) = e^{-y} \cdot \mathbb{I}(y > 0) \sim \text{Exp}(1)$ 。因此, $Y_{(1)} = X_{(1)} - \mu$ 的概率密度函数为

$$f_{Y_{(1)}}(y) = ne^{-ny} \cdot \mathbb{I}(y > 0) \sim \text{Exp}(n)$$

故 $\mathbb{E}[Y_{(1)}] = 1/n$, 所以

$$\mathbb{E}[\hat{\mu}_{\text{MLE}}] = \mathbb{E}[X_{(1)}] = \mathbb{E}[Y_{(1)}] + \mu = 1/n + \mu$$

故 $\hat{\mu}_{\text{MLE}}$ 不是 μ 的无偏估计。但可以通过修正得到 μ 的一个无偏估计 $\hat{\mu}_{\text{U}} = X_{(1)} - 1/n$ 。

解答 (2) 由 $Y_i \sim \text{Exp}(1)$, 所以有 $\mathbb{E}[Y_i] = 1 = \mathbb{E}[X_i] - \mu$, 因此, μ 的矩估计为 $\hat{\mu}_{\text{MM}} = \bar{X} - 1$ 而

$$\mathbb{E}[\hat{\mu}_{\text{MM}}] = \mathbb{E}[\bar{X}] - 1 = \frac{1}{n} \sum_{i=1}^n \mathbb{E}[X_i] - 1 = \frac{1}{n} \sum_{i=1}^n (\mu + 1) - 1 = \mu$$

显然, $\hat{\mu}_{\text{MM}}$ 是 μ 的无偏估计。

解答 (3) 由于 $\hat{\mu}_{\text{U}}$ 和 $\hat{\mu}_{\text{MM}}$ 都是 μ 的无偏估计, 因此, 只需比较它们的方差即可。由 $Y_{(1)} \sim \text{Exp}(n)$ 可知 $\text{Var}(Y_{(1)}) = 1/n^2$, 因此,

$$\text{Var}(\hat{\mu}_{\text{U}}) = \text{Var}(X_{(1)} - 1/n) = \text{Var}(Y_{(1)}) = 1/n^2$$

又因为 X_i 相互独立同分布,

$$\text{Var}(\hat{\mu}_{\text{MM}}) = \text{Var}(\bar{X} - 1) = \text{Var}(\bar{X}) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{1}{n} \text{Var}(X_i)$$

而 $X_i = Y_i + \mu$, 且 $Y_i \sim \text{Exp}(1)$, 所以 $\text{Var}(X_i) = \text{Var}(Y_i) = 1$ 。因此, $\text{Var}(\hat{\mu}_{\text{MM}}) = 1/n$ 。故有

$$\text{Var}(\hat{\mu}_{\text{U}}) = \frac{1}{n^2} < \frac{1}{n} = \text{Var}(\hat{\mu}_{\text{MM}})$$

故 $\hat{\mu}_{\text{U}}$ 比 $\hat{\mu}_{\text{MM}}$ 更有效。

Exercise 3

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} Ge(\theta)$ 分布族

$$P(X = i) = \theta(1 - \theta)^{i-1}, \quad i = 1, 2, \dots, \theta \in (0, 1)$$

(1) 试证明 $T = \sum_{i=1}^n X_i$ 是 θ 的充分完全统计量, 且服从 **Pascal** (负二项) 分布

$$P_\theta(T = t) = \binom{t-1}{n-1} \theta^n (1 - \theta)^{t-n}, \quad t = n, n+1, \dots$$

(2) 计算 $\mathbb{E}_\theta(T)$, 并由此求 θ^{-1} 的 **UMVUE**。

(3) 试证明 $\psi(X_1) = \mathbb{I}(X_1 = 1)$ 是 θ 的无偏估计, 计算 $\mathbb{E}_\theta(\psi(X_1)|T = t)$, 并由此求得 θ 的 **UMVUE**。

证明 (1) 由 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} Ge(\theta)$ 可知联合概率为

$$P(X_1 = x_1, \dots, X_n = x_n) = \prod_{i=1}^n \theta(1 - \theta)^{x_i-1} = \theta^n (1 - \theta)^{\sum_{i=1}^n x_i - n}$$

所以给定 $T = \sum_{i=1}^n X_i$ 的概率为

$$P(X_1 = x_1, \dots, X_n = x_n | T = t) = \frac{P(X_1 = x_1, \dots, X_n = x_n)}{P(T = t)} = \frac{\theta^n (1 - \theta)^{t-n}}{P(T = t)}$$

而 $T = \sum_{i=1}^n X_i$ 其中 $X_i \geq 1$, 由隔板法可知共 $\binom{t-1}{n-1}$ 个解满足条件。所以

$$P(T = t) = \sum_{\sum_{i=1}^n x_i = t} P(X_1 = x_1, \dots, X_n = x_n) = \binom{t-1}{n-1} \theta^n (1 - \theta)^{t-n}$$

所以 T 服从负二项分布。同时

$$P(X_1 = x_1, \dots, X_n = x_n | T = t) = \frac{\theta^n (1 - \theta)^{t-n}}{P(T = t)} = \frac{\theta^n (1 - \theta)^{t-n}}{\binom{t-1}{n-1} \theta^n (1 - \theta)^{t-n}} = \binom{t-1}{n-1}^{-1}$$

与 θ 无关, 由充分统计量定义可知 $T = \sum_{i=1}^n X_i$ 是 θ 的充分统计量。

解答 (2) 由已知 T 的分布列, 故有

$$\mathbb{E}_\theta(T) = \sum_{t=n}^{\infty} t \binom{t-1}{n-1} \theta^n (1 - \theta)^{t-n}$$

由分布列的性质

$$\sum_{t=n}^{\infty} P(T = t) = 1 \quad \Rightarrow \quad \sum_{t=n}^{\infty} \binom{t-1}{n-1} \theta^n (1 - \theta)^{t-n} = 1$$

记 $S(\theta) = \sum_{t=n}^{\infty} \binom{t-1}{n-1} (1 - \theta)^{t-n} = \theta^{-n}$, 注意到

$$S'(\theta) = - \sum_{t=n}^{\infty} (t-n) \binom{t-1}{n-1} (1 - \theta)^{t-n-1} = - \frac{n}{\theta^{n+1}}$$

于是有

$$\sum_{t=n}^{\infty} t \binom{t-1}{n-1} (1-\theta)^{t-n} = -S'(\theta) \cdot (1-\theta) + nS(\theta) = \frac{n(1-\theta)}{\theta^{n+1}} + \frac{n}{\theta^n}$$

所以

$$\mathbb{E}_{\theta}(T) = \theta^n \left(\frac{n(1-\theta)}{\theta^{n+1}} + \frac{n}{\theta^n} \right) = n(1-\theta)\theta^{-1} + n = n\theta^{-1}$$

同时, 根据 **Lehmann-Scheffe** 定理, T 是充分完全统计量, 而 $\mathbb{E}_{\theta}(T/n) = \theta^{-1}$ 是无偏的, 所以 θ^{-1} 的 **UMVUE** 为 $T/n = \frac{1}{n} \sum_{i=1}^n X_i$ 。

证明 (3) 容易得

$$\mathbb{E}_{\theta}(\psi(X_1)) = \mathbb{E}_{\theta}(\mathbb{I}(X_1 = 1)) = P(X_1 = 1) = \theta$$

所以 $\psi(X_1)$ 是 θ 的无偏估计。而

$$\begin{aligned} \mathbb{E}_{\theta}(\psi(X_1)|T=t) &= 1 \cdot P(X_1 = 1|T=t) = \frac{P(X_1 = 1, X_2 + \cdots + X_n = t-1)}{P(T=t)} \\ &= \frac{P(X_1 = 1)P(T-X_1 = t-1)}{P(T=t)} \end{aligned}$$

而 T 服从负二项分布, 所以

$$\mathbb{E}_{\theta}(\psi(X_1)|T=t) = \frac{\theta \binom{t-2}{n-2} \theta^{n-1} (1-\theta)^{t-n}}{\binom{t-1}{n-1} \theta^n (1-\theta)^{t-n}} = \frac{n-1}{t-1}, \quad t = n, n+1, \dots$$

下面求 $\mathbb{E}_{\theta}(\psi(X_1)|T=t)$ 的期望

$$\mathbb{E}_{\theta}[\mathbb{E}_{\theta}(\psi(X_1)|T=t)] = \sum_{t=n}^{\infty} \frac{n-1}{t-1} \binom{t-1}{n-1} \theta^n (1-\theta)^{t-n} = \sum_{t=n}^{\infty} \binom{t-2}{n-2} \theta^n (1-\theta)^{t-n}$$

由广义二项式展开知

$$\sum_{t=n}^{\infty} \binom{t-2}{n-2} (1-\theta)^{t-n} = \sum_{t=0}^{\infty} \binom{t+n-2}{n-2} (1-\theta)^t = [1 - (1-\theta)]^{-(n-1)}$$

代回则得

$$\mathbb{E}_{\theta}[\mathbb{E}_{\theta}(\psi(X_1)|T=t)] = \theta^n [1 - (1-\theta)]^{-(n-1)} = \theta$$

所以 $g(T) = \mathbb{E}_{\theta}(\psi(X_1)|T=t)$ 是 θ 的无偏估计, 而 T 为充分完全统计量, 结合 **Lehmann-Scheffe** 定理, θ 的 **UMVUE** 为 $g(T) = \mathbb{E}_{\theta}(\psi(X_1)|T=t)$ 。

Exercise 4

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} b(1, p)$ 两点分布, $0 < p < 1$ 是未知参数, 试求:

- (1) p^s 的 **UMVUE**。
- (2) $p^s + (1-p)^{n-s}$ 的 **UMVUE**, 其中 $s \in (0, n)$ 为整数。

解答 (1) 设 $T = \sum_{i=1}^n X_i$, 于是 $T \sim B(n, p)$, 那么

$$\begin{aligned} P(X_1 = x_1, \dots, X_n = x_n | T = t) &= \frac{P(X_1 = x_1, \dots, X_n = t - \sum_{i=1}^{n-1} x_i)}{P(T = t)} \\ &= \frac{(\prod_{i=1}^{n-1} p^{x_i} (1-p)^{1-x_i}) \cdot p^{t - \sum_{i=1}^{n-1} x_i} (1-p)^{1-t + \sum_{i=1}^{n-1} x_i}}{\binom{n}{t} p^t (1-p)^{n-t}} \\ &= \frac{p^t (1-p)^{n-t}}{\binom{n}{t} p^t (1-p)^{n-t}} = \binom{n}{t}^{-1} \end{aligned}$$

与 p 无关, 故 T 为充分统计量。对任意函数 $\varphi(T)$ 的期望为

$$\mathbb{E}_p(\varphi(T)) = \sum_{t=0}^n \varphi(t) \binom{n}{t} p^t (1-p)^{n-t} = (1-p)^n \sum_{t=0}^n \varphi(t) \binom{n}{t} \left(\frac{p}{1-p}\right)^t$$

当 $\mathbb{E}_p(\varphi(T)) = 0$ 对任意 p 成立时, 由多项式的性质, 系数 $\varphi(t) \binom{n}{t} = 0$, 于是 $\varphi(t) = 0$ a.s. P , 于是 T 是充分完全统计量。于是, 由 **Lehmann-Scheffe** 定理, 下面只需寻找 $g(T)$ 使得 $g(T)$ 是无偏估计即可。

对任意 $n \in \mathbb{N}^+$, 定义

$$n^{(s)} = \frac{n!}{(n-s)!} = n(n-1)(n-2) \cdots (n-s+1)$$

当 $n < s$ 时 $n^{(s)} = 0$ 。下面我们断言: $\mathbb{E}(T^{(s)}) = n^{(s)} p^s$ 。

$$\begin{aligned} \mathbb{E}(T^{(s)}) &= \sum_{t=0}^n t^{(s)} \binom{n}{t} p^t (1-p)^{n-t} = \sum_{t=s}^n \frac{t!}{(t-s)!} \cdot \frac{n!}{t!(n-t)!} p^t (1-p)^{n-t} \\ &= \sum_{t=s}^n \frac{n!}{(t-s)!(n-t)!} p^t (1-p)^{n-t} = \sum_{t=s}^n \frac{(n-s)!}{(t-s)!(n-t)!} \cdot \frac{n!}{(n-s)!} p^t (1-p)^{n-t} \\ &= n^{(s)} \sum_{t=s}^n \binom{n-s}{t-s} p^t (1-p)^{n-t} = n^{(s)} p^s \sum_{t=s}^n \binom{n-s}{t-s} p^{t-s} (1-p)^{(n-s)-(t-s)} \\ &= n^{(s)} p^s \sum_{t=0}^{n-s} \binom{n-s}{t} p^t (1-p)^{(n-s)-t} = n^{(s)} p^s [p + (1-p)]^{n-s} = n^{(s)} p^s \end{aligned}$$

断言证毕。于是我们得到 p^s 的 **UMVUE** 为 $g(T) = \frac{T^{(s)}}{n^{(s)}} = \frac{T!(n-s)!}{n!(T-s)!}$ 。

解答 (2) 注意到 $n-T \sim B(n, 1-p)$, 所以与上面同理 $(1-p)^{n-s}$ 的 **UMVUE** 为 $\frac{(n-T)^{(n-s)}}{n^{(n-s)}}$ 。于是 $p^s + (1-p)^{n-s}$ 的 **UMVUE** 为

$$\begin{aligned} \frac{T^{(s)}}{n^{(s)}} + \frac{(n-T)^{(n-s)}}{n^{(n-s)}} &= \frac{T!(n-s)!}{n!(T-s)!} + \frac{s!(n-T)!}{n!(s-T)!} \\ &= \frac{T!(n-s)!}{n!(T-s)!} \cdot \mathbb{I}(T \geq s) + \frac{s!(n-T)!}{n!(s-T)!} \cdot \mathbb{I}(T \leq s) \end{aligned}$$

HW8 第八次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设 $X_1, \dots, X_m \stackrel{\text{i.i.d.}}{\sim} N(a, \sigma^2)$ 以及 $Y_1, \dots, Y_n \stackrel{\text{i.i.d.}}{\sim} N(a, 2\sigma^2)$ 且两样本独立。求 a 和 σ^2 的 UMVUE。

解答 由正态分布，可得概率函数

$$\begin{aligned} f(\mathbf{x}, \mathbf{y}; a, \sigma^2) &= (2\pi\sigma^2)^{-m/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^m (x_i - a)^2\right\} (4\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{4\sigma^2} \sum_{j=1}^n (y_j - a)^2\right\} \\ &= C(a, \sigma^2) \exp\left\{-\frac{1}{2\sigma^2} \left(\sum_{i=1}^m x_i^2 + \frac{1}{2} \sum_{j=1}^n y_j^2\right) + \frac{a}{\sigma^2} \left(\sum_{i=1}^m x_i + \frac{1}{2} \sum_{j=1}^n y_j\right)\right\} \end{aligned}$$

容易证明 $T_1 = \sum_{i=1}^m x_i^2 + \frac{1}{2} \sum_{j=1}^n y_j^2$ 和 $T_2 = \sum_{i=1}^m x_i + \frac{1}{2} \sum_{j=1}^n y_j$ 是 a, σ^2 的充分完全统计量（这是因为有内点）。于是

$$\begin{aligned} \mathbb{E}(T_2) &= \mathbb{E}\left(\sum_{i=1}^m x_i + \frac{1}{2} \sum_{j=1}^n y_j\right) = \left(m + \frac{n}{2}\right) a \\ \text{Var}(T_2) &= \text{Var}\left(\sum_{i=1}^m x_i + \frac{1}{2} \sum_{j=1}^n y_j\right) = \left(m + \frac{n}{2}\right) \sigma^2 \end{aligned}$$

而

$$\begin{aligned} \mathbb{E}(T_1) &= \mathbb{E}\left(\sum_{i=1}^m x_i^2 + \frac{1}{2} \sum_{j=1}^n y_j^2\right) = \mathbb{E}\left(\sum_{i=1}^m (\text{Var}(x_i) + [\mathbb{E}(x_i)]^2) + \frac{1}{2} \sum_{j=1}^n (\text{Var}(y_j) + [\mathbb{E}(y_j)]^2)\right) \\ &= m(\sigma^2 + a^2) + \frac{n}{2}(2\sigma^2 + a^2) = (m + n)\sigma^2 + \left(m + \frac{n}{2}\right) a^2 \end{aligned}$$

于是我们构造

$$\begin{cases} \hat{a} = \frac{2T_2}{2m + n} \\ \hat{\sigma}^2 = \frac{T_1 - \frac{2T_2^2}{2m + n}}{m + n - 1} \end{cases}$$

如此有 $\mathbb{E}(\hat{a}) = a$ 以及注意到

$$\begin{aligned}\mathbb{E}\left(T_1 - \frac{2T_2^2}{2m+n}\right) &= (m+n)\sigma^2 + \left(m + \frac{n}{2}\right)a^2 - \frac{\mathbb{E}(T_2^2)}{m+n/2} \\ &= (m+n)\sigma^2 + \left(m + \frac{n}{2}\right)a^2 - \frac{1}{m+n/2} \cdot \left[\left(m + \frac{n}{2}\right)\sigma^2 + \left(m + \frac{n}{2}\right)^2 a^2\right] \\ &= (m+n-1)\sigma^2\end{aligned}$$

于是有 $\mathbb{E}(\hat{\sigma}^2) = \sigma^2$ 。由 Lehmann-Scheffe 定理知, $\hat{a}, \hat{\sigma}^2$ 为 a, σ^2 的 UMVUE。

Exercise 2

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(0, \sigma^2)$ 其中 $\sigma^2 > 0$ 为未知参数, 试求

1. σ^2 的充分完全统计量
2. σ 和 $3\sigma^4$ 的 UMVUE。

解答 (1) 由 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(0, \sigma^2)$ 可知概率函数为

$$f(\mathbf{x}; \sigma^2) = (2\pi\sigma^2)^{-n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2\right\}$$

自然参数空间在 \mathbb{R} 有内点, 故 $T = \sum_{i=1}^n x_i^2$ 是充分完全统计量。

解答 (2) 设 $Y_i = X_i/\sigma \sim N(0, 1)$ 且相互独立, 故 $T/\sigma^2 = \sum_{i=1}^n Y_i^2 \sim \chi_n^2$ 。所以

$$\mathbb{E}(T/\sigma^2) = n \quad \text{Var}(T/\sigma^2) = 2n$$

于是

$$\mathbb{E}(T^2/\sigma^4) = [\mathbb{E}(T/\sigma^2)]^2 + \text{Var}(T/\sigma^2) = n^2 + 2n$$

于是我们构造

$$\hat{\sigma}^4 = \frac{T^2}{n^2 + 2n}$$

有 $\mathbb{E}(3\hat{\sigma}^4) = 3\sigma^4$, 由 Lehmann-Scheffe 定理知 $3\hat{\sigma}^4 = \frac{3T^2}{n^2+2n}$ 是 $3\sigma^4$ 的 UMVUE。

下面求 σ 的 UMVUE。由于 $Z = T/\sigma^2 \sim \chi_n^2$, 于是 Z 的密度函数为

$$f_Z(z) = \frac{2^{-n/2}}{\Gamma(n/2)} z^{n/2-1} e^{-z/2} \cdot \mathbb{I}(z > 0)$$

于是 \sqrt{Z} 的期望为

$$\begin{aligned}\mathbb{E}(\sqrt{Z}) &= \int_0^\infty \sqrt{z} \cdot \frac{2^{-n/2}}{\Gamma(n/2)} z^{n/2-1} e^{-z/2} dz = \int_0^\infty \frac{2^{-n/2}}{\Gamma(n/2)} z^{\frac{n+1}{2}-1} e^{-\frac{z}{2}} dz \\ &\stackrel{u=z/2}{=} \frac{2^{-1/2}}{\Gamma(n/2)} \int_0^\infty 2u^{\frac{n+1}{2}-1} e^{-u} du = 2^{1/2} \Gamma\left(\frac{n+1}{2}\right) / \Gamma\left(\frac{n}{2}\right)\end{aligned}$$

于是构造

$$\begin{cases} \hat{\sigma} = \frac{\Gamma\left(\frac{n}{2}\right)}{2^{1/2}\Gamma\left(\frac{n+1}{2}\right)}\sqrt{T} \\ 3\hat{\sigma}^4 = \frac{3T^2}{n^2 + 2n} \end{cases}$$

其中 $T = \sum_{i=1}^n X_i^2$ 就有 $\hat{\sigma}, 3\hat{\sigma}^4$ 为 $\sigma, 3\sigma^4$ 的 UMVUE。

Exercise 3

证明均匀分布族 $\mathcal{F} = \{U(0, \theta) : 0 < \theta < \infty\}$ 不是 C-R 正则分布族。

证明 设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} U(0, \theta)$ 均匀分布, 则概率函数为

$$f(\mathbf{x}; \theta) = \theta^{-n} \cdot \mathbb{I}(0 < x_{(1)} \leq x_{(n)} < \theta)$$

对参数 $\theta \in \Theta$, 支撑集为

$$\text{Supp}_{\theta}(f) = \{\mathbf{x} : f(\mathbf{x}; \theta) > 0\} = \{\mathbf{x} : \mathbf{x} \in (0, \theta)^n = (0, \theta) \times (0, \theta) \times \dots \times (0, \theta)\}$$

即支撑集 $\text{Supp}_{\theta}(f)$ 随参数 θ 变化, 不是共同的支撑集, 与 C-R 正则要求相悖。

Exercise 4

设 X_1, \dots, X_n 为自下列总体中抽取的简单样本

$$f(x; \theta) = \theta^{-1} e^{-\theta^{-1}x} \cdot \mathbb{I}(x > 0)$$

其中 $\theta > 0$ 为未知参数, 求 θ 的无偏估计的方差下限和 θ 的 UMVUE, 并比较 θ 的 UMVUE 方差与 C-R 下界。

解答 X_1, \dots, X_n 的似然函数为

$$L(\theta; \mathbf{x}) = \prod_{i=1}^n f(x_i; \theta) = \prod_{i=1}^n \theta^{-1} e^{-\theta^{-1}x_i} \cdot \mathbb{I}(x_i > 0) = \theta^{-n} \exp\left\{-\theta^{-1} \sum_{i=1}^n x_i\right\} \cdot \mathbb{I}(x_{(1)} > 0)$$

于是对数似然为

$$l(\theta) = -n \log \theta - \theta^{-1} \sum_{i=1}^n x_i, \quad x_{(1)} > 0$$

求导

$$\begin{aligned} \frac{dl(\theta)}{d\theta} &= -n\theta^{-1} + \theta^{-2} \sum_{i=1}^n x_i \\ \frac{d^2l(\theta)}{d\theta^2} &= n\theta^{-2} - 2\theta^{-3} \sum_{i=1}^n x_i \end{aligned}$$

注意到 X_i 相互独立, 且 X_i 服从 $\text{Exp}(\theta^{-1})$ 的期望为 θ 。从而 Fisher 信息量为

$$I_1(\theta) = -\mathbb{E} \left(\frac{d^2 l(\theta)}{d\theta^2} \right) = -\mathbb{E} \left(n\theta^{-2} - 2\theta^{-3} \sum_{i=1}^n x_i \right) = -n\theta^{-2} + 2n\theta^{-2} = n\theta^{-2}$$

于是根据 Cramer-Rao 不等式有

$$\text{Var}(\hat{\theta}) \geq \frac{1}{I_1(\theta)} = \frac{\theta^2}{n}$$

又注意到, 设 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ 有

$$\begin{cases} \mathbb{E}(\bar{X}) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) = \frac{1}{n} n\theta = \theta \\ \text{Var}(\bar{X}) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) = \frac{1}{n^2} n\theta^2 = \frac{\theta^2}{n} \end{cases}$$

故 \bar{X} 是 θ 的无偏估计, 且其方差达到 Cramer-Rao 不等式估计的无偏估计的方差下界, 所以 \bar{X} 是 θ 的 UMVUE。

HW9 第九次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(0, \sigma^2)$, 证明

$$\hat{\sigma} = \frac{\Gamma(n/2)}{\sqrt{2}\Gamma((n+1)/2)} \sqrt{\sum_{i=1}^n X_i^2}$$

是 σ 的 UMVUE, 并求其效率。

证明 记 $\hat{\sigma} = \hat{g}(T)$ 而 $T = T(\mathbf{X}) = \sum_{i=1}^n X_i^2$ 。容易知 \mathbf{X} 的概率函数满足指数族, 故 C-R 条件成立, 下面求 C-R 下界。

$$g'(\theta) = \frac{1}{2\sqrt{\theta}} \Rightarrow g'(\sigma^2) = \frac{1}{2\sqrt{\sigma^2}} = \frac{1}{2\sigma}$$

而

$$\begin{aligned} I(\sigma^2) &= \mathbb{E} \left(\frac{\partial \log f_n(\mathbf{x}; \sigma^2)}{\partial \sigma^2} \right)^2 = \mathbb{E} \left[\frac{\partial}{\partial \sigma^2} \left(-\frac{n}{2} \log(2\pi\sigma^2) - \sum_{i=1}^n \frac{x_i^2}{2\sigma^2} \right) \right]^2 \\ &= \mathbb{E} \left(-\frac{n}{2\sigma^2} + \frac{T}{2\sigma^4} \right)^2 = \mathbb{E} \left(\frac{n^2}{4\sigma^4} + \frac{T^2}{4\sigma^8} - \frac{nT}{2\sigma^6} \right) \\ &= \frac{n^2}{4\sigma^4} + \frac{\mathbb{E}(T^2)}{4\sigma^8} - \frac{n\mathbb{E}(T)}{2\sigma^6} \end{aligned}$$

注意到 $T/\sigma^2 \sim \chi_n^2$, 于是有 $\mathbb{E}(T) = n\sigma^2$, $\text{Var}(T) = \mathbb{E}(T^2) - [\mathbb{E}(T)]^2 = 2n\sigma^4$ 。于是 Fisher 信息量为

$$I(\sigma^2) = \frac{n^2}{4\sigma^4} + \frac{2n\sigma^4 + (n\sigma^2)^2}{4\sigma^8} - \frac{n^2\sigma^2}{2\sigma^6} = \frac{n^2 + 2n + n^2 - 2n^2}{4\sigma^4} = \frac{n}{2\sigma^4}$$

于是根据 C-R 不等式得到 C-R 下界为

$$\text{Var}_{\sigma^2}[\hat{g}(T)] \geq \frac{[g'(\sigma^2)]^2}{nI(\sigma^2)} = \frac{1/(4\sigma^2)}{n/(2\sigma^4)} = \frac{\sigma^2}{2n}$$

下面分析 $\hat{\sigma} = \hat{g}(T)$ 的无偏性和有效性。注意到 $T/\sigma^2 \sim \chi_n^2$, 故有

$$\begin{aligned} \mathbb{E}(\sqrt{T}/\sigma) &= \int_0^\infty t^{\frac{1}{2}} \cdot \frac{1}{2^{n/2}\Gamma(n/2)} t^{\frac{n}{2}-1} e^{-\frac{t}{2}} dt = \frac{1}{\Gamma(n/2)} \int_0^\infty \frac{t^{\frac{n-1}{2}}}{2^{n/2}} e^{-\frac{t}{2}} dt \\ &= \frac{\sqrt{2}}{\Gamma(n/2)} \int_0^\infty (t/2)^{\frac{n+1}{2}-1} e^{-\frac{t}{2}} dt/2 = \frac{\sqrt{2}\Gamma((n+1)/2)}{\Gamma(n/2)} \end{aligned}$$

于是有

$$\mathbb{E}(\hat{\sigma}) = \frac{\Gamma(n/2)}{\sqrt{2}\Gamma((n+1)/2)} \cdot \mathbb{E}(\sqrt{T}) = \frac{\Gamma(n/2)}{\sqrt{2}\Gamma((n+1)/2)} \cdot \frac{\sqrt{2}\Gamma((n+1)/2)}{\Gamma(n/2)} \sigma = \sigma$$

所以 $\hat{g}(T) = \hat{\sigma}$ 是 σ 的无偏估计, 又容易得到 T 为充分完全统计量, 故 $\hat{g}(T)$ 是 $g(\sigma^2) = \sqrt{\sigma^2}$ 的 UMVUE。其方差为

$$\begin{aligned} \text{Var}(\hat{\sigma}) &= \left(\frac{\Gamma(n/2)}{\sqrt{2}\Gamma((n+1)/2)} \right)^2 \text{Var}(\sqrt{T}) = \left(\frac{\Gamma(n/2)}{\sqrt{2}\Gamma((n+1)/2)} \right)^2 \{ \mathbb{E}(T) - [\mathbb{E}(\sqrt{T})]^2 \} \\ &= \left(\frac{\Gamma(n/2)}{\sqrt{2}\Gamma((n+1)/2)} \right)^2 \left[n\sigma^2 - \left(\frac{\sqrt{2}\Gamma((n+1)/2)}{\Gamma(n/2)} \sigma \right)^2 \right] \\ &= \left[n \left(\frac{\Gamma(n/2)}{\sqrt{2}\Gamma((n+1)/2)} \right)^2 - 1 \right] \sigma^2 \end{aligned}$$

于是, 结合之前得到的 C-R 下界, 我们有效率为

$$e_{\hat{\sigma}}(\sigma) = \left[n^2 \left(\frac{\Gamma(n/2)}{\Gamma((n+1)/2)} \right)^2 - 2n \right]^{-1}$$

注 此处虽然 \mathbf{X} 分布族为指数族, 且 $\hat{g}(T)$ 是 UMVUE, 但 $\hat{g}(T) = C\sqrt{T}$ 形式不是关于充分完全统计量 T 的线性形式, 故不满足 C-R 不等式取等条件, 效率 $e_{\hat{\sigma}}(\sigma) < 1$ 。

Exercise 2

设 $X_1, \dots, X_m \stackrel{\text{i.i.d.}}{\sim} N(a, \sigma_1^2)$ 和 $Y_1, \dots, Y_n \stackrel{\text{i.i.d.}}{\sim} N(ca, \sigma_2^2)$, 其中 $c \neq 0, \sigma_1^2, \sigma_2^2$ 已知, a 未知, 且 X_1, \dots, X_m 与 Y_1, \dots, Y_n 独立。

1. 试求 a 的 UMVUE。
2. 基于此 UMVUE 构造 a 的一个置信系数为 $1 - \alpha$ 的置信区间。

解答 (1) \mathbf{X}, \mathbf{Y} 的概率函数为

$$\begin{aligned} f_n(\mathbf{X}, \mathbf{Y}; a) &= (2\pi\sigma_1^2)^{-m/2} (2\pi\sigma_2^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma_1^2} \sum_{i=1}^m (X_i - a)^2 - \frac{1}{2\sigma_2^2} \sum_{j=1}^n (Y_j - ca)^2 \right\} \\ &:= C \exp \left\{ -\frac{ma^2}{2\sigma_1^2} - \frac{nc^2a^2}{2\sigma_2^2} + \frac{a}{\sigma_1^2} \sum_{i=1}^m X_i + \frac{ca}{\sigma_2^2} \sum_{j=1}^n Y_j - \frac{1}{2\sigma_1^2} \sum_{i=1}^m X_i^2 - \frac{1}{2\sigma_2^2} \sum_{j=1}^n Y_j^2 \right\} \\ &= C(a) \exp \left\{ a \cdot \left(\frac{m\bar{X}}{\sigma_1^2} + \frac{cn\bar{Y}}{\sigma_2^2} \right) \right\} h(\mathbf{X}, \mathbf{Y}) \end{aligned}$$

其中

$$\begin{cases} C(a) = (2\pi\sigma_1^2)^{-m/2} (2\pi\sigma_2^2)^{-n/2} \exp \left\{ -\frac{ma^2}{2\sigma_1^2} - \frac{nc^2a^2}{2\sigma_2^2} \right\} \\ h(\mathbf{X}, \mathbf{Y}) = \exp \left\{ -\frac{1}{2\sigma_1^2} \sum_{i=1}^m X_i^2 - \frac{1}{2\sigma_2^2} \sum_{j=1}^n Y_j^2 \right\} \end{cases}$$

故 \mathbf{X}, \mathbf{Y} 样本分布族为指数族, 从而容易得到

$$T(\mathbf{X}, \mathbf{Y}) = \frac{m\bar{X}}{\sigma_1^2} + \frac{cn\bar{Y}}{\sigma_2^2}$$

为 a 的充分完全统计量 (指数族形式 \Rightarrow 充分, 自然参数空间有内点 \Rightarrow 完全)。注意到 $c \neq 0, \sigma_1^2, \sigma_2^2$ 已知, 且 $\mathbb{E}(\bar{X}) = a, \mathbb{E}(\bar{Y}) = ca$, 有

$$\mathbb{E}[T(\mathbf{X}, \mathbf{Y})] = \frac{m\mathbb{E}(\bar{X})}{\sigma_1^2} + \frac{cn\mathbb{E}(\bar{Y})}{\sigma_2^2} = \left(\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2} \right) a$$

于是有 a 的无偏估计为

$$\hat{g}(T) = \frac{T}{\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}} = \frac{\frac{m\bar{X}}{\sigma_1^2} + \frac{cn\bar{Y}}{\sigma_2^2}}{\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}}$$

由 T 是充分完全统计量, 以及 Lehmann-Scheffe 定理可知, $\hat{g}(T)$ 是 a 的 UMVUE。

解答 (2) 注意到 $X_i \stackrel{\text{i.i.d.}}{\sim} N(a, \sigma_1^2), Y_j \stackrel{\text{i.i.d.}}{\sim} N(ca, \sigma_2^2)$ 且相互独立, 其中 $c \neq 0, \sigma_1^2, \sigma_2^2$ 已知, 故有

$$\bar{X} \sim N\left(a, \frac{\sigma_1^2}{m}\right) \quad \bar{Y} \sim N\left(ca, \frac{\sigma_2^2}{n}\right)$$

从而 $\hat{g}(T)$ 也服从正态分布, 其中

$$\begin{aligned} \text{Var}[\hat{g}(T)] &= \text{Var}\left[\left(\frac{m\bar{X}}{\sigma_1^2} + \frac{cn\bar{Y}}{\sigma_2^2}\right) / \left(\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}\right)\right] \\ &= \left(\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}\right)^{-2} \left[\left(\frac{m}{\sigma_1^2}\right)^2 \text{Var}(\bar{X}) + \left(\frac{cn}{\sigma_2^2}\right)^2 \text{Var}(\bar{Y})\right] \\ &= \left(\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}\right)^{-2} \left(\frac{m^2}{\sigma_1^4} \cdot \frac{\sigma_1^2}{m} + \frac{c^2n^2}{\sigma_2^4} \cdot \frac{\sigma_2^2}{n}\right) \\ &= \left(\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}\right)^{-2} \left(\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}\right) = \left(\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}\right)^{-1} \end{aligned}$$

结合 $\hat{g}(T)$ 服从正态分布, 于是 a 的 $1 - \alpha$ 置信区间为

$$\text{CI}_a = \left[\hat{g}(T) - z_{1-\alpha/2} \left(\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}\right)^{-1/2}, \hat{g}(T) + z_{1-\alpha/2} \left(\frac{m}{\sigma_1^2} + \frac{c^2n}{\sigma_2^2}\right)^{-1/2} \right]$$

其中 $z_{1-\alpha/2}$ 为标准正态分布的上 $1 - \alpha/2$ 分位数点。

Exercise 3

设 X_1, \dots, X_n 是来自均匀分布 $U(\theta - 1/2, \theta + 1/2)$ 的简单随机样本, 求 θ 的置信系数 $1 - \alpha$ 的置信区间。

解答 设 $Y_i = X_i - (\theta - 1/2)$, 于是 $Y_i \stackrel{\text{i.i.d.}}{\sim} U(0, 1)$ 。从而有 $Y_{(n)}$ 的概率函数为

$$f_{Y_{(n)}}(y) = ny^{n-1} \cdot \mathbb{I}(0 < y < 1)$$

于是有

$$\mathbb{P}(a < Y_{(n)} < b) = \int_a^b ny^{n-1} = b^n - a^n = 1 - \alpha$$

当 $0 < a < b < 1$ 时成立。下面优化区间长度

$$\min_{a,b} |b - a| \quad \text{s.t.} \quad b^n - a^n = 1 - \alpha$$

不难得到 $a^* = \sqrt[n]{\alpha}, b^* = 1$, 于是有

$$\mathbb{P}(\sqrt[n]{\alpha} < Y_{(n)} < 1) = \mathbb{P}(\sqrt[n]{\alpha} < X_{(n)} - (\theta - 1/2) < 1) = 1 - \alpha$$

故 θ 的 $1 - \alpha$ 置信区间为

$$\text{CI}_\theta = [X_{(n)} - 1/2, X_{(n)} - \sqrt[n]{\alpha} + 1/2]$$

其中 $X_{(n)}$ 为 \mathbf{X} 的第 n 个次序统计量。

Exercise 4

设 $X \sim B(m, p_1), Y \sim B(n, p_2)$, 且 m, n 充分大, p_1, p_2 是未知参数, X, Y 独立。基于 X, Y , 求 $p_2 - p_1$ 的置信系数近似为 $1 - \alpha$ 的置信区间。

解答 设 $U_i \stackrel{\text{i.i.d.}}{\sim} B(1, p_1), i = 1, \dots, m$ 和 $V_j \stackrel{\text{i.i.d.}}{\sim} B(1, p_2), j = 1, \dots, n$, 且 U_i 和 V_j 相互独立。因为 m, n 充分大, 故由中心极限定理

$$\frac{\bar{U} - \mathbb{E}(\bar{U})}{\sqrt{\text{Var}(\bar{U})}} \xrightarrow{\mathcal{L}} N(0, 1) \quad \frac{\bar{V} - \mathbb{E}(\bar{V})}{\sqrt{\text{Var}(\bar{V})}} \xrightarrow{\mathcal{L}} N(0, 1)$$

其中 $\mathbb{E}(U_i) = p_1, \mathbb{E}(V_j) = p_2, \text{Var}(\bar{U}) = p_1(1 - p_1)/m, \text{Var}(\bar{V}) = p_2(1 - p_2)/n$, 故有

$$\frac{(\bar{V} - \bar{U}) - (p_2 - p_1)}{\sqrt{\frac{p_1(1 - p_1)}{m} + \frac{p_2(1 - p_2)}{n}}} \xrightarrow{\mathcal{L}} N(0, 1)$$

又因为 \bar{U}, \bar{V} 为求和形式, 由大数定律

$$\bar{U} \xrightarrow{P} \mathbb{E}(U_i) = p_1 \quad \bar{V} \xrightarrow{P} \mathbb{E}(V_j) = p_2$$

其中 p_1, p_2 是常数, 不随机。所以有

$$\sqrt{\frac{\bar{U}(1 - \bar{U})}{m} + \frac{\bar{V}(1 - \bar{V})}{n}} \bigg/ \sqrt{\frac{p_1(1 - p_1)}{m} + \frac{p_2(1 - p_2)}{n}} \xrightarrow{P} 1$$

由 Slutsky 定理知

$$\frac{(\bar{V} - \bar{U}) - (p_2 - p_1)}{\sqrt{\frac{\bar{U}(1 - \bar{U})}{m} + \frac{\bar{V}(1 - \bar{V})}{n}}} \xrightarrow{\mathcal{L}} N(0, 1)$$

注意到 $\bar{U} = X/m, \bar{V} = Y/n$, 从而有 $p_2 - p_1$ 的 $1 - \alpha$ 近似置信区间为

$$\text{CI}_{(p_2 - p_1)} = \left[\left(\frac{Y}{n} - \frac{X}{m} \right) \pm z_{1-\alpha/2} \sqrt{\frac{X(m - X)}{m^3} + \frac{Y(n - Y)}{n^3}} \right]$$

其中 $z_{1-\alpha/2}$ 为标准正态分布的上 $1 - \alpha/2$ 分位数点。

HW10 第十次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} \Gamma(\alpha, \lambda)$, 其中 α 已知, $\lambda > 0$ 。已知总体的密度函数为

$$f(x; \alpha, \lambda) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x}$$

试证明: \bar{X}/α 是 $g(\lambda) = 1/\lambda$ 的有效估计。

证明 先求 $g(\lambda)$ 的 C-R 下界。注意到 $g'(\lambda) = -\lambda^{-2}$; 又 $X \sim \Gamma(\alpha, \lambda)$, 即有 $\mathbb{E}(X) = \alpha/\lambda$, $\text{Var}(X) = \alpha/\lambda^2$ 。从而 Fisher 信息量为

$$\begin{aligned} I(\lambda) &= \mathbb{E}_\lambda \left(\frac{\partial \log f(X; \lambda)}{\partial \lambda} \right)^2 = \mathbb{E}_\lambda \left(\frac{\alpha}{\lambda} - X \right)^2 = \frac{\alpha^2}{\lambda^2} - \frac{2\alpha}{\lambda} \mathbb{E}(X) + \mathbb{E}(X^2) \\ &= \frac{\alpha^2}{\lambda^2} - \frac{2\alpha}{\lambda} \cdot \frac{\alpha}{\lambda} + \left[\frac{\alpha}{\lambda^2} + \left(\frac{\alpha}{\lambda} \right)^2 \right] = \frac{\alpha^2 - 2\alpha^2 + \alpha + \alpha^2}{\lambda^2} = \frac{\alpha}{\lambda^2} \end{aligned}$$

如此, C-R 下界为

$$\text{Var}_\lambda(\hat{g}(\mathbf{X})) \geq \frac{[g'(\lambda)]^2}{nI(\lambda)} = \frac{\lambda^{-4}}{n\alpha/\lambda^2} = \frac{1}{n\alpha\lambda^2}$$

其中 $\hat{g}(\mathbf{X}) = \bar{X}/\alpha$ 。而

$$\text{Var}_\lambda(\bar{X}/\alpha) = \frac{1}{n^2\alpha^2} \text{Var}_\lambda \left(\sum_{i=1}^n X_i \right) = \frac{1}{n^2\alpha^2} \cdot \frac{n\alpha}{\lambda^2} = \frac{1}{n\alpha\lambda^2}$$

即有 $\text{Var}_\lambda(\hat{g}(\mathbf{X}))$ 达到了 C-R 下界, 为 UMVUE。效率为 $e_{\hat{g}}(\lambda) = 1$ 是有效估计。

Exercise 2

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} N(a, \sigma^2)$, 其中 a 已知。证明:

$$\frac{1}{n} \sqrt{\frac{\pi}{2}} \sum_{i=1}^n |X_i - a|$$

为 σ 的无偏估计, 且效率为 $1/(\pi - 2)$ 。

证明 记 $Y_i = (X_i - a)/\sigma$, 于是有 $Y_i \stackrel{\text{i.i.d.}}{\sim} N(0, 1)$ 。从而

$$\mathbb{E}(|Y|) = \int_{-\infty}^{\infty} |y| \frac{1}{\sqrt{2\pi}} e^{-y^2/2} dy = 2 \int_0^{\infty} y \frac{1}{\sqrt{2\pi}} e^{-y^2/2} dy.$$

令 $t = \frac{y^2}{2}$, 则 $dt = y dy$, 因此

$$\mathbb{E}(|Y|) = \frac{2}{\sqrt{2\pi}} \int_0^{\infty} e^{-t} dt = \frac{2}{\sqrt{2\pi}} = \sqrt{\frac{2}{\pi}}$$

而有 $\mathbb{E}(Y^2) = 1$, 因此

$$\text{Var}(|Y|) = \mathbb{E}(|Y|^2) - (\mathbb{E}|Y|)^2 = 1 - \frac{2}{\pi}$$

那么有

$$\begin{aligned} \mathbb{E}(\hat{\sigma}) &= \mathbb{E}\left(\frac{1}{n} \sqrt{\frac{\pi}{2}} \sum_{i=1}^n |X_i - a|\right) = \mathbb{E}\left(\frac{1}{n} \sqrt{\frac{\pi}{2}} \sum_{i=1}^n \sigma |Y_i|\right) \\ &= \sigma \cdot \frac{1}{n} \sqrt{\frac{\pi}{2}} \sum_{i=1}^n \mathbb{E}(|Y_i|) = \sigma \cdot \frac{1}{n} \sqrt{\frac{\pi}{2}} \cdot n \sqrt{\frac{2}{\pi}} = \sigma \end{aligned}$$

故 $\hat{\sigma}$ 是 σ 的无偏估计。同理, 可求 $\hat{\sigma}$ 的方差

$$\text{Var}(\hat{\sigma}) = \frac{1}{n^2} \frac{\pi}{2} \sum_{i=1}^n \sigma^2 \text{Var}(|Y_i|) = \frac{\pi}{2n} \left(1 - \frac{2}{\pi}\right) \sigma^2 = \frac{\pi - 2}{2n} \sigma^2$$

而 C-R 下界为 $[g'(\sigma^2)]^2 [nI(\sigma^2)]^{-1}$, 其中 $g'(\sigma^2) = (\sqrt{\sigma^2})' = 1/(2\sigma)$, 而 Fisher 信息量为

$$\begin{aligned} I(\sigma^2) &= \mathbb{E} \left[\frac{\partial}{\partial \sigma^2} \left(-\frac{1}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} (X - a)^2 \right) \right]^2 = \mathbb{E} \left(-\frac{1}{2\sigma^2} + \frac{1}{2\sigma^4} (X - a)^2 \right)^2 \\ &= \frac{1}{4\sigma^4} - \frac{1}{2\sigma^6} \mathbb{E}(X - a)^2 + \frac{1}{4\sigma^8} \mathbb{E}(X - a)^4 = \frac{1}{4\sigma^4} - \frac{1\sigma^2}{2\sigma^6} + \frac{3\sigma^4}{4\sigma^8} = \frac{1}{2\sigma^4} \end{aligned}$$

于是效率为

$$e = \frac{[g'(\sigma^2)]^2 [nI(\sigma^2)]^{-1}}{\text{Var}(\hat{\sigma})} = \frac{\left(\frac{1}{2\sigma}\right)^2 \left(\frac{n}{2\sigma^4}\right)^{-1}}{\frac{\pi-2}{2n}\sigma^2} = \frac{1}{\pi-2}$$

□

Exercise 3

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} U(0, \theta)$, 其中 $\theta > 0$ 为未知参数。记 $X_{(n)} = \max\{X_1, \dots, X_n\}$, 下面进行假设检验

$$H_0: \theta \geq 2 \quad \leftrightarrow \quad H_1: \theta < 2$$

取拒绝域为

$$W = \{(X_1, \dots, X_n) : X_{(n)} \leq 1.5\}$$

试求此检验犯第一类错误的概率的最大值。

解答 对于 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} U(0, \theta)$, $X_{(n)} = \max\{X_1, \dots, X_n\}$ 的分布函数为

$$F_{X_{(n)}}(x) = \mathbb{P}(X_{(n)} \leq x) = \left(\frac{x}{\theta}\right)^n, \quad 0 \leq x \leq \theta$$

在原假设 $H_0: \theta \geq 2$ 下, 此检验的第一类错误概率为

$$\alpha(\theta) = \mathbb{P}_\theta(X_{(n)} \leq 1.5) = \left(\frac{1.5}{\theta}\right)^n, \quad \theta \geq 2$$

由于函数 $(1.5/\theta)^n$ 在 $\theta \geq 2$ 上严格单调递减, 因此其最大值在 $\theta = 2$ 处取得, 于是

$$\sup_{\theta \in \Theta_0} \alpha(\theta) = \left(\frac{1.5}{2}\right)^n = \left(\frac{3}{4}\right)^n$$

因此, 此检验第一类错误概率的最大值为 $(3/4)^n$ 。

Exercise 4

设 $X_1, \dots, X_m \stackrel{\text{i.i.d.}}{\sim} \text{Poi}(\lambda_1)$ 和 $Y_1, \dots, Y_n \stackrel{\text{i.i.d.}}{\sim} \text{Poi}(\lambda_2)$, 且样本 X_1, \dots, X_m 和 Y_1, \dots, Y_n 相互独立。用大样本方法检验

$$H_0: \lambda_2 - \lambda_1 = 0 \quad \leftrightarrow \quad H_1: \lambda_2 - \lambda_1 \neq 0$$

检验水平 α 给定。

解答 令样本均值为

$$\bar{X} = \frac{1}{m} \sum_{i=1}^m X_i, \quad \bar{Y} = \frac{1}{n} \sum_{j=1}^n Y_j.$$

由中心极限定理, 当 $m, n \rightarrow \infty$ 时

$$\frac{\bar{X} - \lambda_1}{\sqrt{\lambda_1/m}} \xrightarrow{\mathcal{L}} N(0, 1) \quad \frac{\bar{Y} - \lambda_2}{\sqrt{\lambda_2/n}} \xrightarrow{\mathcal{L}} N(0, 1)$$

且两者渐近独立。于是有

$$\frac{(\bar{Y} - \bar{X}) - (\lambda_2 - \lambda_1)}{\sqrt{\frac{\lambda_1}{m} + \frac{\lambda_2}{n}}} \xrightarrow{\mathcal{L}} N(0, 1)$$

构造检验统计量

$$T = \frac{\bar{Y} - \bar{X}}{\sqrt{\frac{\bar{X}}{m} + \frac{\bar{Y}}{n}}}$$

由大数定理 $\bar{X} \xrightarrow{P} \mathbb{E}(X_i) = \lambda_1$, $\bar{Y} \xrightarrow{P} \mathbb{E}(Y_j) = \lambda_2$ 。当 $H_0: \lambda_2 - \lambda_1 = 0$ 成立时, 结合 Slutsky 定理, 有 $T \xrightarrow{\mathcal{L}} N(0, 1)$ 。于是置信水平为 $1 - \alpha$ 的拒绝域为

$$W = \{(\mathbf{X}, \mathbf{Y}) : |T| \geq z_{\alpha/2}\}$$

其中 $z_{\alpha/2}$ 为标准正态分布 $N(0, 1)$ 的上 $\alpha/2$ 分位数点。检验的 p 值为 $\Pr(Z > |T|)$, 其中 $Z \sim N(0, 1)$ 。

HW11 第十一次作业解答

更新：2026 年 1 月 9 日

Exercise 1

设 $X_1, \dots, X_m \stackrel{\text{i.i.d.}}{\sim} N(\mu_1, \sigma^2)$, $Y_1, \dots, Y_n \stackrel{\text{i.i.d.}}{\sim} N(\mu_2, \sigma^2)$, 其中 σ^2 未知。且样本 X_1, \dots, X_m 和 Y_1, \dots, Y_n 相互独立。求下列检验问题水平为 α 的似然比检验

$$H_0 : \mu_2 - \mu_1 = 0 \quad \leftrightarrow \quad H_1 : \mu_2 - \mu_1 \neq 0$$

解答 首先写出似然函数

$$\begin{aligned} L &= (2\pi\sigma^2)^{-m/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^m (X_i - \mu_1)^2 \right\} (2\pi\sigma^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{j=1}^n (Y_j - \mu_2)^2 \right\} \\ &= (2\pi\sigma^2)^{-\frac{m+n}{2}} \exp \left\{ -\frac{1}{2\sigma^2} \left[\sum_{i=1}^m (X_i - \mu_1)^2 + \sum_{j=1}^n (Y_j - \mu_2)^2 \right] \right\} \end{aligned}$$

容易得到在全集 Θ 下的 MLE 为

$$\hat{\mu}_1^\Theta = \bar{X} \quad \hat{\mu}_2^\Theta = \bar{Y} \quad \hat{\sigma}_\Theta^2 = \frac{1}{m+n} \left[\sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{j=1}^n (Y_j - \bar{Y})^2 \right]$$

于是有对应的似然函数为

$$\sup_{\Theta} L = (2\pi\hat{\sigma}_\Theta^2)^{-\frac{m+n}{2}} \exp \left\{ -\frac{1}{2\hat{\sigma}_\Theta^2} \cdot (m+n)\hat{\sigma}_\Theta^2 \right\} = (2\pi\hat{\sigma}_\Theta^2)^{-\frac{m+n}{2}} e^{-\frac{m+n}{2}} = (2\pi e\hat{\sigma}_\Theta^2)^{-\frac{m+n}{2}}$$

在 H_0 对应的 Θ_0 下, 有 $\mu_1 = \mu_2$ 。于是 MLE 为

$$\hat{\mu}^{\Theta_0} = \frac{1}{m+n} \left[\sum_{i=1}^m X_i + \sum_{j=1}^n Y_j \right] \quad \hat{\sigma}_{\Theta_0}^2 = \frac{1}{m+n} \left[\sum_{i=1}^m (X_i - \hat{\mu}^{\Theta_0})^2 + \sum_{j=1}^n (Y_j - \hat{\mu}^{\Theta_0})^2 \right]$$

于是有对应的似然函数为

$$\sup_{\Theta_0} L = (2\pi\hat{\sigma}_{\Theta_0}^2)^{-\frac{m+n}{2}} \exp \left\{ -\frac{1}{2\hat{\sigma}_{\Theta_0}^2} \cdot (m+n)\hat{\sigma}_{\Theta_0}^2 \right\} = (2\pi\hat{\sigma}_{\Theta_0}^2)^{-\frac{m+n}{2}} e^{-\frac{m+n}{2}} = (2\pi e\hat{\sigma}_{\Theta_0}^2)^{-\frac{m+n}{2}}$$

综上，可有似然比为

$$\lambda = \frac{\sup_{\Theta} L}{\sup_{\Theta_0} L} = \left(\frac{\hat{\sigma}_{\Theta_0}^2}{\hat{\sigma}_{\Theta}^2} \right)^{\frac{m+n}{2}} = \left(\frac{\sum_{i=1}^m (X_i - \hat{\mu}^{\Theta_0})^2 + \sum_{j=1}^n (Y_j - \hat{\mu}^{\Theta_0})^2}{\sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{j=1}^n (Y_j - \bar{Y})^2} \right)^{\frac{m+n}{2}}$$

记 $\hat{\mu}^{\Theta_0}$ 为 \bar{Z} 则有

$$\bar{Z} = \frac{m\bar{X} + n\bar{Y}}{m+n}$$

似然比转化为

$$\lambda = \left(\frac{\sum_{i=1}^m (X_i - \bar{X} + \bar{X} - \bar{Z})^2 + \sum_{j=1}^n (Y_j - \bar{Y} + \bar{Y} - \bar{Z})^2}{\sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{j=1}^n (Y_j - \bar{Y})^2} \right)^{\frac{m+n}{2}}$$

记 $(m+n-2)S_p^2 = \sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{j=1}^n (Y_j - \bar{Y})^2$ ，于是有

$$\lambda = \left(\frac{(m+n-2)S_p^2 + m(\bar{X} - \bar{Z})^2 + n(\bar{Y} - \bar{Z})^2}{(m+n-2)S_p^2} \right)^{\frac{m+n}{2}}$$

又注意到 \bar{Z} 的定义，故有

$$m(\bar{X} - \bar{Z})^2 + n(\bar{Y} - \bar{Z})^2 = m \left(\frac{n\bar{X} - n\bar{Y}}{m+n} \right)^2 + n \left(\frac{m\bar{Y} - m\bar{X}}{m+n} \right)^2 = \frac{mn}{(m+n)^2} (\bar{Y} - \bar{X})^2$$

代入 λ 有似然比为

$$\lambda = \left(\frac{(m+n-2)S_p^2 + \frac{mn}{(m+n)^2} (\bar{Y} - \bar{X})^2}{(m+n-2)S_p^2} \right)^{\frac{m+n}{2}} = \left(1 + \frac{mn(\bar{Y} - \bar{X})^2}{(m+n-2)(m+n)^2 S_p^2} \right)^{\frac{m+n}{2}}$$

记检验统计量

$$T = \frac{\bar{Y} - \bar{X}}{S_p \sqrt{\frac{1}{m} + \frac{1}{n}}}$$

于是似然比化为

$$\lambda = \left(1 + \frac{T^2}{(m+n-2)(m+n)} \right)^{\frac{m+n}{2}}$$

于是，似然比 λ 关于 T 单增。则待定拒绝域形如

$$D = \{(\mathbf{X}, \mathbf{Y}) : |T| = |T(\mathbf{X}, \mathbf{Y})| > c\}$$

又因为 T 在 $H_0 : \mu_2 - \mu_1 = 0$ 下服从 t_{df} ，其中自由度 $df = m+n-2$ 。于是 α 水平的拒绝域为

$$D = \{(\mathbf{X}, \mathbf{Y}) : |T| = |T(\mathbf{X}, \mathbf{Y})| > t_{m+n-2}(\alpha/2)\}$$

其中 $t_{m+n-2}(\alpha/2)$ 为 t_{m+n-2} 的上 $\alpha/2$ 分位数点。

Exercise 2

设 $X_1, \dots, X_m \stackrel{\text{i.i.d.}}{\sim} N(\mu_1, \sigma_1^2)$, $Y_1, \dots, Y_n \stackrel{\text{i.i.d.}}{\sim} N(\mu_2, \sigma_2^2)$, 且样本 X_1, \dots, X_m 和 Y_1, \dots, Y_n 相互独立。求下列检验问题水平为 α 的似然比检验

$$H_0 : \sigma_1^2 = \sigma_2^2 \quad \leftrightarrow \quad H_1 : \sigma_1^2 \neq \sigma_2^2$$

解答 首先写出似然函数

$$L = (2\pi\sigma_1^2)^{-m/2} \exp \left\{ -\frac{1}{2\sigma_1^2} \sum_{i=1}^m (X_i - \mu_1)^2 \right\} (2\pi\sigma_2^2)^{-n/2} \exp \left\{ -\frac{1}{2\sigma_2^2} \sum_{j=1}^n (Y_j - \mu_2)^2 \right\}$$

在全集 Θ 下的 MLE 为

$$\begin{aligned} \hat{\mu}_1^\Theta &= \bar{X} & \hat{\mu}_2^\Theta &= \bar{Y} \\ \hat{\sigma}_1^2 &= \frac{1}{m} \sum_{i=1}^m (X_i - \bar{X})^2 := S_X^2 & \hat{\sigma}_2^2 &= \frac{1}{n} \sum_{j=1}^n (Y_j - \bar{Y})^2 := S_Y^2 \end{aligned}$$

对应的似然函数为

$$\sup_{\Theta} L = (2\pi\hat{\sigma}_1^2)^{-\frac{m}{2}} \exp \left\{ -\frac{1}{2\hat{\sigma}_1^2} (m\hat{\sigma}_1^2) \right\} (2\pi\hat{\sigma}_2^2)^{-\frac{n}{2}} \exp \left\{ -\frac{1}{2\hat{\sigma}_2^2} (n\hat{\sigma}_2^2) \right\} = (2\pi e\hat{\sigma}_1^2)^{-\frac{m}{2}} (2\pi e\hat{\sigma}_2^2)^{-\frac{n}{2}}$$

而在 $H_0 : \sigma_1^2 = \sigma_2^2 = \sigma^2$ 对应的 Θ_0 下的 MLE 为

$$\begin{aligned} \hat{\mu}_1^{\Theta_0} &= \bar{X} & \hat{\mu}_2^{\Theta_0} &= \bar{Y} \\ \hat{\sigma}^2 &= \frac{1}{m+n} \left[\sum_{i=1}^m (X_i - \bar{X})^2 + \sum_{j=1}^n (Y_j - \bar{Y})^2 \right] = \frac{mS_X^2 + nS_Y^2}{m+n} \end{aligned}$$

对应的似然函数为

$$\sup_{\Theta_0} L = (2\pi\hat{\sigma}^2)^{-\frac{m}{2}} (2\pi\hat{\sigma}^2)^{-\frac{n}{2}} \exp \left\{ -\frac{1}{2\hat{\sigma}^2} (m+n)\hat{\sigma}^2 \right\} = (2\pi e\hat{\sigma}^2)^{-\frac{m+n}{2}}$$

综上, 似然比为

$$\begin{aligned} \lambda &= \frac{\sup_{\Theta} L}{\sup_{\Theta_0} L} = \frac{(2\pi e\hat{\sigma}_1^2)^{-\frac{m}{2}} (2\pi e\hat{\sigma}_2^2)^{-\frac{n}{2}}}{(2\pi e\hat{\sigma}^2)^{-\frac{m+n}{2}}} = \frac{(\hat{\sigma}_1^2)^{-\frac{m}{2}} (\hat{\sigma}_2^2)^{-\frac{n}{2}}}{(\hat{\sigma}^2)^{-\frac{m+n}{2}}} = \frac{(\hat{\sigma}^2)^{\frac{m+n}{2}}}{(\hat{\sigma}_1^2)^{\frac{m}{2}} (\hat{\sigma}_2^2)^{\frac{n}{2}}} \\ &= \frac{\left(\frac{mS_X^2 + nS_Y^2}{m+n} \right)^{\frac{m+n}{2}}}{(S_X^2)^{\frac{m}{2}} (S_Y^2)^{\frac{n}{2}}} = \frac{\left(\frac{mS_X^2 + nS_Y^2}{m+n} \right)^{\frac{m+n}{2}} (S_Y^2)^{-\frac{m+n}{2}}}{(S_X^2)^{\frac{m}{2}} (S_Y^2)^{\frac{n}{2}} (S_Y^2)^{-\frac{m+n}{2}}} \\ &= \frac{\left(\frac{mS_X^2/S_Y^2 + n}{m+n} \right)^{\frac{m+n}{2}}}{(S_X^2/S_Y^2)^{\frac{m}{2}}} = \frac{\left(\frac{(mS_X^2)/(nS_Y^2) + 1}{m/n + 1} \right)^{\frac{m+n}{2}}}{[(mS_X^2)/(nS_Y^2)]^{\frac{m}{2}} (m/n)^{-\frac{m}{2}}} \end{aligned}$$

记 $F = (mS_X^2)/(nS_Y^2)$ 则有

$$\lambda = \frac{\left(\frac{F+1}{m/n+1} \right)^{\frac{m+n}{2}}}{F^{\frac{m}{2}} (m/n)^{-\frac{m}{2}}} = \frac{(m/n)^{\frac{m}{2}}}{(m/n+1)^{\frac{m+n}{2}}} \frac{(F+1)^{\frac{m+n}{2}}}{F^{\frac{m}{2}}}$$

对 λ 的核部分 λ^* 取对数, 得到

$$\log \lambda^* = \frac{m+n}{2} \log(1+F) - \frac{m}{2} \log F$$

于是有关于 F 的导数为

$$\frac{\partial \log \lambda^*}{\partial F} = \frac{m+n}{2} \frac{1}{1+F} - \frac{m}{2} \frac{1}{F} = \frac{(m+n)F - m(1+F)}{2F(1+F)} = \frac{nF - m}{2F(1+F)}$$

于是有, 当 $F \leq m/n$ 时, λ 随 F 单减; 而当 $F > m/n$ 时, λ 随 F 单增。于是, 检验的拒绝域形如

$$D = \{(\mathbf{X}, \mathbf{Y}) : (F < k_1) \cup (F > k_2)\}$$

其中 $k_1 < k_2$ 待定。不难发现, 在 $H_0 : \sigma_1^2 = \sigma_2^2 = \sigma^2$ 下, 有

$$F = \frac{mS_X^2/\sigma^2}{nS_Y^2/\sigma^2} \sim F_{m-1, n-1}$$

简单起见, 可以取 F 分布的上下 $\alpha/2$ 分位数点。于是检验的 α 水平的拒绝域为

$$D = \{(\mathbf{X}, \mathbf{Y}) : [F < F_{m-1, n-1}(1 - \alpha/2)] \cup [F > F_{m-1, n-1}(\alpha/2)]\}$$

Exercise 3

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} \text{Exp}(\lambda)$, 求

1. $H_0 : \lambda = \lambda_0 \leftrightarrow H_1 : \lambda \neq \lambda_0$
2. $H_0 : \lambda \leq \lambda_0 \leftrightarrow H_1 : \lambda > \lambda_0$

的水平为 α 的似然比检验。

解答 (1) 由指数函数的密度函数 $f(X; \lambda) = \lambda e^{-\lambda X} \cdot \mathbb{I}(X \geq 0)$, 可知似然函数为

$$L(\mathbf{X}; \lambda) = \prod_{i=1}^n f(X_i; \lambda) = \lambda^n \exp \left\{ -\lambda \sum_{i=1}^n X_i \right\} \cdot \mathbb{I}(X_{(1)} \geq 0)$$

容易得到 λ 的 MLE 为 \bar{X}^{-1} 。记 $T = \sum_{i=1}^n X_i = n\bar{X}$, 于是有 $T \sim \Gamma(n, \lambda)$ 。针对检验问题 1, 有似然比为

$$\Lambda = \frac{\sup_{\Theta} L(\mathbf{X}; \lambda)}{\sup_{\Theta_0} L(\mathbf{X}; \lambda)} = \frac{(n/T)^n \exp \{-(n/T)T\} \cdot \mathbb{I}(X_{(1)} \geq 0)}{\lambda_0^n \exp \{-\lambda_0 T\} \cdot \mathbb{I}(X_{(1)} \geq 0)} = \left(\frac{n}{e\lambda_0 T} \right)^n e^{\lambda_0 T}$$

容易得似然函数核部分 Λ^* 的对数为

$$\log \Lambda^* = -n \log T + \lambda_0 T \quad \Rightarrow \quad \frac{\partial \log \Lambda^*}{\partial T} = -\frac{n}{T} + \lambda_0$$

由此可知, 当 $T \leq n/\lambda_0$ 时, 似然比 Λ 关于 T 单减; 而当 $T > n/\lambda_0$ 时, 似然比 Λ 关于 T 单增。所以拒绝域形如

$$D = \{\mathbf{X} : (T < k_1) \cup (T > k_2)\}$$

其中 $k_1 < k_2$ 待定。又因为当 $H_0: \lambda = \lambda_0$ 成立时, 有 $T \sim \Gamma(n, \lambda_0)$, 即有 $2\lambda_0 T \sim \chi_{2n}^2$ 。于是简单起见, 可取水平为 α 的拒绝域为

$$D = \left\{ \mathbf{X} : \left[T < \frac{\chi_{2n}^2(1-\alpha/2)}{2\lambda_0} \right] \cup \left[T > \frac{\chi_{2n}^2(\alpha/2)}{2\lambda_0} \right] \right\}$$

解答 (2) 针对 $H_0: \lambda \leq \lambda_0$, 原假设下的极大对数似然变为

$$\sup_{\Theta_0} L(\mathbf{X}; \lambda) = \begin{cases} \lambda_0^n \exp\{-\lambda_0 T\} \cdot \mathbb{I}(X_{(1)} \geq 0), & \lambda_0 \leq \frac{n}{T} \\ \sup_{\Theta} L(\mathbf{X}; \lambda), & \lambda_0 > \frac{n}{T} \end{cases}$$

于是, 似然比为

$$\Lambda = \begin{cases} \left(\frac{n}{e\lambda_0 T} \right)^n e^{\lambda_0 T}, & \lambda_0 \leq \frac{n}{T} \\ 1, & \lambda_0 > \frac{n}{T} \end{cases}$$

而由之前的推导, 当 $\lambda_0 \leq n/T$ 即 $T \leq n/\lambda_0$ 时, 似然比 Λ 关于 T 单减。于是 Λ 是关于 T 不增的。从而有效用函数为

$$\varphi(\mathbf{X}) = \begin{cases} 1, & \Lambda > c \\ 0, & \Lambda \leq c \end{cases} = \begin{cases} 1, & T < k \\ 0, & T \geq k \end{cases}$$

其中 c, k 待定。注意到 $H_0: \lambda \leq \lambda_0 \Rightarrow \lambda/\lambda_0 \leq 1$, 于是有

$$\mathbb{P}_{H_0} \left(T < \frac{\chi_{2n}^2(1-\alpha)}{2\lambda_0} \right) = \mathbb{P}_{H_0} \left(T < \frac{\chi_{2n}^2(1-\alpha)}{2\lambda} \frac{\lambda}{\lambda_0} \right) \leq \mathbb{P}_{H_0} \left(T < \frac{\chi_{2n}^2(1-\alpha)}{2\lambda} \right) = \alpha$$

其中 $\chi_{2n}^2(1-\alpha)$ 为 χ_{2n}^2 的上 $1-\alpha$ 分位数点。于是我们有该检验的 $1-\alpha$ 水平的拒绝域为

$$D = \left\{ \mathbf{X} : T = T(\mathbf{X}) = \sum_{i=1}^n X_i < \frac{\chi_{2n}^2(1-\alpha)}{2\lambda_0} \right\}$$

Exercise 4

设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} B(1, p)$, 用大样本方法检验

$$H_0: p = p_0 \quad \leftrightarrow \quad H_1: p \neq p_0$$

的水平为 α 的似然比检验。

解答 对于 Bernoulli 实验, 其似然函数为

$$L(\mathbf{X}; p) = \prod_{i=1}^n p^{X_i} (1-p)^{1-X_i} = p^{n\bar{X}} (1-p)^{n-n\bar{X}} \quad X_i \in \{0, 1\}$$

在全集 Θ 下, p 的 MLE 为 \bar{X} 。于是, 得似然比为

$$\lambda = \frac{\sup_{\Theta} L(\mathbf{X}; p)}{\sup_{\Theta_0} L(\mathbf{X}; p)} = \frac{\bar{X}^{n\bar{X}}(1 - \bar{X})^{n-n\bar{X}}}{p_0^{n\bar{X}}(1 - p_0)^{n-n\bar{X}}}$$

取对数有

$$\log \lambda = n\bar{X} \log \bar{X} + (n - n\bar{X}) \log(1 - \bar{X}) - n\bar{X} \log p_0 - (n - n\bar{X}) \log(1 - p_0)$$

关于统计量 \bar{X} 的导数为

$$\begin{aligned} \frac{\partial \log \lambda}{\partial \bar{X}} &= n \log \bar{X} + n - n \log(1 - \bar{X}) - n - n \log p_0 + n \log(1 - p_0) \\ &= n \left(\log \frac{\bar{X}}{1 - \bar{X}} - \log \frac{p_0}{1 - p_0} \right) \end{aligned}$$

故有, 当 $\text{logit} \bar{X} \leq \text{logit} p_0$ 时, λ 关于 \bar{X} 单减; 而当 $\text{logit} \bar{X} > \text{logit} p_0$ 时, λ 关于 \bar{X} 单增。特别地, logit 函数为单增函数, 故上述可等价于: 当 $\bar{X} \leq p_0$ 时, λ 关于 \bar{X} 单减; 而当 $\bar{X} > p_0$ 时, λ 关于 \bar{X} 单增。所以, 容易得到拒绝域形如

$$D = \{\mathbf{X} : (\bar{X} < k_1) \cup (\bar{X} > k_2)\}$$

其中 $k_1 < k_2$ 待定。又由中心极限定理, 当 n 充分大时, 有

$$\frac{\bar{X} - \mathbb{E}(X_i)}{\sqrt{\text{Var}(X_i)}} \xrightarrow{\mathcal{L}} N(0, 1) \quad \Rightarrow \quad \frac{\sqrt{n}(\bar{X} - p)}{\sqrt{p(1 - p)}} \xrightarrow{\mathcal{L}} N(0, 1)$$

于是有

$$\mathbb{P}_{H_0} \left(\left| \frac{\sqrt{n}(\bar{X} - p_0)}{\sqrt{p_0(1 - p_0)}} \right| > z_{\alpha/2} \right) = \alpha$$

其中 $z_{\alpha/2}$ 为标准正态分布的上 $\alpha/2$ 分位数点。综上可知, 水平为 α 的拒绝域为

$$D = \left\{ \mathbf{X} : \left[\bar{X} < p_0 - z_{\alpha/2} \sqrt{\frac{p_0(1 - p_0)}{n}} \right] \cup \left[\bar{X} > p_0 + z_{\alpha/2} \sqrt{\frac{p_0(1 - p_0)}{n}} \right] \right\}$$