

# 数理统计

统计量: 1. 样本均值  $\bar{x} = \frac{1}{n} \sum_{i=1}^n X_i$

2. 样本方差  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{x})^2$

3. 样本矩  
 ① k阶原点矩  $a_{nk} = \frac{1}{n} \sum_{i=1}^n X_i^k$   
 ② k阶中心矩  $m_{nk} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{x})^k$

4. 二维随机变量中协方差  $Cov(X, Y) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{x})(Y_i - \bar{y})$

相关系数  $r = \frac{Cov(X, Y)}{\sqrt{Var(X)Var(Y)}}$

定义: 设  $X_1, \dots, X_n$  为  $F(x)$  中抽取的  $n$  个样本, 将其按大小排列为  $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$ , 对  $\forall x \in \mathbb{R}$ , 称  $F(x) = \begin{cases} 0 & x < X_{(1)} \\ k/n & X_{(k)} \leq x < X_{(k+1)} \\ 1 & x \geq X_{(n)} \end{cases} \quad k=1, 2, \dots, n-1$

为经验分布函数  $F_n(x) = \frac{1}{n} \sum_{i=1}^n I_{(-\infty, x]}(X_i)$



分布: 离散型: 均匀分布:  $X \sim \text{Discrete } U(a, b), E[X] = \frac{a+b}{2}, Var(X) = \frac{(b-a+1)^2-1}{12}$

二项分布:  $X \sim B(n, p), E[X] = np, Var(X) = np(1-p), \psi(t) = (1-p+pe^{it})^n$

泊松分布:  $X \sim P(\lambda), E[X] = \lambda, Var(X) = \lambda, \psi(t) = e^{\lambda(e^{it}-1)}$

$\sqrt{P}$ 分布:  $P(X=k) = p(1-p)^{k-1}, k=1, 2, \dots$

$E[X] = \frac{1}{p}, Var(X) = \frac{1-p}{p^2}, \phi(t) = \frac{pe^{it}}{1-(1-p)e^{it}}$

超几何分布:  $X \sim H(N, K, n), E[X] = n \frac{K}{N}, Var(X) = n \frac{K}{N} (1 - \frac{K}{N}) \frac{N-n}{N-1}$

连续型: 均匀分布:  $X \sim U(a, b), E[X] = \frac{a+b}{2}, Var(X) = \frac{(b-a)^2}{12}$

正态分布:  $X \sim N(\mu, \sigma^2), E[X] = \mu, Var(X) = \sigma^2, \psi(t) = e^{it\mu - \frac{1}{2}\sigma^2 t^2}$  有可加性:  $X_1, \dots, X_n \sim \Gamma(\alpha_i, \beta)$  则  $Y = X_1 + \dots + X_n \sim \Gamma(\sum_{i=1}^n \alpha_i, \beta)$

Gamma分布:  $X \sim \text{Gamma}(\alpha, \beta), f(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x}, E[X] = \frac{\alpha}{\beta}, Var(X) = \frac{\alpha}{\beta^2}, \psi(t) = (1 - \frac{it}{\beta})^{-\alpha}$

Beta分布:  $X \sim \text{Beta}(\alpha, \beta), f(x) = \frac{1}{B(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1}, E[X] = \frac{\alpha}{\alpha+\beta}, Var(X) = \frac{\alpha\beta}{(\alpha+\beta)^2(\alpha+\beta+1)}, B(\alpha, \beta) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)}$

$\chi^2$ 分布: 若  $X_1, \dots, X_n$  i.i.d.  $1. \sim N(\mu, \sigma^2), \bar{X} \sim N(\mu, \frac{\sigma^2}{n})$

$2. \sim \text{Exp}(\lambda), \bar{X} \sim \text{Gamma}(n, n\lambda) (Exp(\lambda) = \text{Gamma}(1, \lambda) = \lambda e^{-\lambda x})$

$\chi^2$ 分布: 设  $X \sim \chi_n^2$  则 ①  $Z \sim N(0, 1), 则 Z^2 \sim \chi_1^2$

②  $E[X] = n, Var(X) = 2n$

③ 若  $X_1, \dots, X_p$  独立, 且  $X_i \sim \chi_{n_i}^2$ , 则  $X_1, X_2, \dots, X_p \sim \chi_{n_1+n_2+\dots+n_p}^2$

④  $X \sim \text{Gamma}(\frac{n}{2}, \frac{1}{2}), f = \frac{1}{\Gamma(\frac{n}{2}) 2^{\frac{n}{2}}} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}, x > 0$

$X \sim \text{Gamma}(\frac{n}{2}, \frac{1}{2})$

⑤  $kX \sim \text{Gamma}(\frac{n}{2}, \frac{k}{2})$

定理: 若  $X_1, X_2, \dots, X_n$  i.i.d.  $\sim N(\mu, \sigma^2)$  则有 ①  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$

②  $\frac{n-1}{\sigma^2} S^2 \sim \chi_{n-1}^2$

③  $\bar{X}$  与  $S^2$  相互独立

t分布: 若  $X \sim N(0, 1), Y \sim \chi_n^2$  且  $X, Y$  独立  $\Rightarrow T = \frac{X}{\sqrt{Y/n}}$  称为自由度为  $n$  的t分布, 其分布称为自由度为  $n$  的t分布, 记为  $T \sim t_n$

性质: ①  $n=2$  时  $E[T] = 0, n \geq 3$  时  $Var(T) = \frac{n}{n-2}$

$$f_T(x) = \frac{\Gamma(\frac{n+1}{2})}{\Gamma(\frac{n}{2}) \sqrt{n\pi}} (1 + \frac{x^2}{n})^{-\frac{n+1}{2}}, -\infty < x < \infty$$

②  $n=1$  时为 Cauchy 分布,  $f_T(x) = \frac{1}{\pi(1+x^2)}, -\infty < x < \infty$

③  $n \rightarrow \infty$  时为  $N(0, 1)$

F分布:  $X \sim \chi_m^2, Y \sim \chi_n^2, X, Y$  为独立  $F = \frac{X/m}{Y/n}$  为自由度为  $m$  和  $n$  的F分布, 其分布称为自由度为  $m$  和  $n$  的F分布, 记为  $F \sim F_{m,n}$

性质: ① 若  $X \sim F_{m,n}$ , 则  $\frac{1}{X} \sim F_{n,m}$

$$f_{F_{m,n}}(x) = \frac{\Gamma(\frac{m+n}{2})}{\Gamma(\frac{m}{2}) \Gamma(\frac{n}{2})} m^{\frac{m}{2}} n^{\frac{n}{2}} x^{\frac{m}{2}-1} (1+nx)^{-\frac{m+n}{2}}, x > 0$$

②  $n > 2$  时  $E[F] = \frac{n}{n-2}, n > 4$  时  $Var(F) = \frac{2n^2(m+n-2)}{m(n-2)^2(n-4)}$

③ 若  $T \sim t_n$ , 则  $T^2 \sim F_{1,n}$

④  $F_{n,m}(1-\alpha) = (F_{m,n}(\alpha))^{-1}$

$$\frac{n!}{(n-j)!(j-1)!} \checkmark$$

次序统计量: 设  $X_1, \dots, X_n$  i.i.d., 将其按数值大小排列为  $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$ , 则  $X_{(1)}, X_{(2)}, \dots, X_{(n)}$  称为样本  $X_1, \dots, X_n$  次序统计量

1. 样本中位数:  $m_{\frac{n+1}{2}} = \begin{cases} X_{(\frac{n+1}{2})} & n \text{ 为奇} \\ \frac{1}{2}(X_{(\frac{n}{2})} + X_{(\frac{n}{2}+1)}) & n \text{ 为偶} \end{cases}$

4. 样本极差:  $R = X_{(n)} - X_{(1)}$

2. 样本极值:  $X_{(1)}, X_{(n)}$  称为样本下极值与上极值

5. 样本中程数:  $mR = \frac{1}{2}(X_{(1)} + X_{(n)})$

3. 样本分位数:  $X_{(m)}, m = [n\alpha]$   $[n\alpha]$  表示取整部分 (当分位数  $\alpha$  在  $n$  为奇数时为样本中位数)

$$\frac{f(x)}{j-1} \uparrow \frac{f(x)}{n-j}$$

连续型单个: 简单随机样本  $X_1, \dots, X_n$  来自连续型分布函数  $F(x), f(x)$  为  $f_{X_{(j)}}(x) = \frac{n!}{(j-1)!(n-j)!} [F(x)]^{j-1} [1-F(x)]^{n-j} f(x)$

连续型两个联合密度:  $\dots, (X_{(i)}, X_{(j)})$   $i < j$  两联合密度函数为  $f_{ij}(x, y) = \begin{cases} \frac{n!}{(i-1)!(j-i)!(n-j)!} [F(x)]^{i-1} [F(y)-F(x)]^{j-i-1} [1-F(y)]^{n-j} f(x)f(y) & x < y \\ 0 & \text{其它} \end{cases}$

$$\frac{f(x)}{i-1} \uparrow \frac{f(y)}{j-i-1} \downarrow \frac{f(y)}{n-j}$$

特别地, 有相左分布:  $f_{X_{(n)}}(x) = n[1 - F(x)]^{n-1} f(x)$

相左分布:  $f_{X_{(n)}}(x) = n[F(x)]^{n-1} f(x)$

次序统计量的联合密度:  $g(X_{(1)}, \dots, X_{(n)}) = \begin{cases} n! f(x_{(1)}) \dots f(x_{(n)}) & x_{(1)} < \dots < x_{(n)} \\ 0 & \text{其他} \end{cases}$

相左分布: 先求  $V = X_{(j)} - X_{(i)}$  分布, 作变换:  $\begin{cases} z = x_{(i)} \\ v = x_{(j)} - x_{(i)} \end{cases} \Leftrightarrow \begin{cases} x_{(i)} = z \\ x_{(j)} = z + v \end{cases}$  此变换 Jacobian 行列式  $J = \begin{vmatrix} 1 & 0 \\ 0 & 1 \end{vmatrix} = 1$

则有  $(z, v)$  联合密度为  $g_{j,j}(z, v) = \begin{cases} \frac{n!}{(i-1)!(j-i-1)!(n-j)!} [F(z)]^{i-1} [F(z+v)-F(z)]^{j-i-1} [1-F(z+v)]^{n-j} f(z) f(z+v) & v > 0 \\ 0 & \text{其他} \end{cases}$

特别地, 有相左分布: 有  $g_{i,n}(z, r) = \begin{cases} n(n-1) [F(z+v)-F(z)]^{n-2} f(z) f(z+v) & v > 0 \\ 0 & \text{其他} \end{cases}$  则有  $R = X_{(n)} - X_{(i)}$  分布密度为  $g_R(r) = \int_{-\infty}^{\infty} g_{i,n}(z, r) dz$

例:  $X_1, \dots, X_n$  i.i.d.  $\sim U(a, b)$ . 求 ①  $X_{(i)}, i=1, \dots, n$  的 p.d.f. ②  $X_{(1)}, \dots, X_{(n)}$  的联合 p.d.f. ③  $(X_{(i)}, X_{(j)})$   $1 \leq i < j \leq n$  的联合 p.d.f. ④ 相左分布 p.d.f.

有  $F(x) = \begin{cases} 0 & x < a \\ \frac{x-a}{b-a} & a \leq x < b \\ 1 & x \geq b \end{cases}$   $f(x) = \begin{cases} 0 & x < a \\ \frac{1}{b-a} & a \leq x < b \\ 0 & \text{其他} \end{cases}$

①  $f_{X_{(i)}}(x) = \frac{n!}{(n-1)!(i-1)!} x^{i-1} (b-x)^{n-i} I_{(a,b)}(x)$

②  $f_{X_{(1)}, \dots, X_{(n)}}(x) = \begin{cases} n! & a \leq x_{(1)} < x_{(2)} < \dots < x_{(n)} \leq b \\ 0 & \text{其他} \end{cases}$

③  $f_{ij}(x, y) = \begin{cases} \frac{n!}{(i-1)!(j-i-1)!(n-j)!} x^{i-1} (y-x)^{j-i-1} (b-y)^{n-j} & 0 < x < y < b \\ 0 & \text{其他} \end{cases}$

④  $g_{i,n}(z, r) = \begin{cases} n(n-1) z^{n-2} & a \leq z < z+r < b \\ 0 & \text{其他} \end{cases}$  例  $g_R(r) = \int_a^{b-r} n(n-1) z^{n-2} dz = n(n-1) z^{n-1} \Big|_a^{b-r} = (n-1) r^{n-1} I_{(0, b-a)}(r)$

联合:  $f_{i,n}(x, y) = n(n-1) (y-x)^{n-2} \quad 0 < x < y < b$  设  $R = y-x$  例  $J = \begin{vmatrix} 1 & 0 \\ 0 & 1 \end{vmatrix} = 1$  例  $f_{R,r}(z, r) = n(n-1) z^{n-2} I_{(0, b-r)}(z)$

指数族: 定义: 设  $\mathcal{P} = \{f(x; \theta), \theta \in \Theta\}$  是样本空间上的分布族,  $\Theta = \{\theta_1, \dots, \theta_k\}$ ,  $\Theta$  为参数空间, 若其概率密度函数  $f(x; \theta)$  可表示为  $f(x; \theta) = c(\theta) h(x) \exp\left\{\sum_{k=1}^K \eta_k(\theta) T_k(x)\right\}$

非: 支持集与  $\theta$  有关

则称为指数族,  $k \in \mathbb{N}_+$ ,  $c(\theta), h(x) > 0$ ,  $\eta_k(\theta)$  定义在  $\Theta$  上,  $T_k(x)$  定义在  $\mathcal{X}$  上

例: 1. 正态分布  $N(\mu, \sigma^2)$  中抽取  $n$  个简单样本  $X = (X_1, \dots, X_n)$  分布族是指数族

$f(x; \mu, \sigma^2) = \frac{1}{(\sqrt{2\pi}\sigma)^n} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right\}$  记  $\Theta = (\mu, \sigma^2)$ , 例  $\Theta = \{\theta = (\mu, \sigma^2) \mid -\infty < \mu < \infty, \sigma^2 > 0\}$

例  $f(x; \theta) = \frac{1}{(\sqrt{2\pi}\sigma)^n} \exp\left\{\frac{1}{\sigma^2} \sum_{i=1}^n x_i - \frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2\right\}$   $h(x) \equiv 1$ , 由定义知为指数族

2. 二项分布是指数族

$p(x; \theta) = \binom{n}{x} \theta^x (1-\theta)^{n-x} = \binom{n}{x} (1-\theta)^n \exp\{x \ln \frac{\theta}{1-\theta}\}$

3. Poisson 分布是指数族

$p(x; \theta) = \frac{e^{-\theta} \theta^x}{x!} = \frac{e^{-\theta}}{x!} \exp\{x \ln \theta\}$

4. 均匀分布族  $\{U(0, \theta) : \theta > 0\}$  不是指数族

由指数族定义及支撑集  $\{x: f(x; \theta) > 0\} = \{x: h(x) > 0\} \leftarrow$  证非指数族: 支撑集与参数有关  
与  $\theta$  无关, 且  $\{U(0, \theta) : \theta > 0\}$  支撑集为  $\{x: f(x; \theta) > 0\} = (0, \theta)$  与  $\theta$  相关, 故非指数族

定义: 若指数族有以下形式:  $f(x; \eta) = c(\eta) h(x) \exp\left\{\sum_{k=1}^K \eta_k T_k(x)\right\}$  称为指数族自然形式, 此时集合  $\{\eta = (\eta_1, \dots, \eta_K) : 0 < \int_{\mathcal{X}} h(x) \exp\left\{\sum_{k=1}^K \eta_k T_k(x)\right\} dx < \infty\}$  称为自然参数空间

例: 1. 正态分布  $N(\mu, \sigma^2)$  中抽取  $n$  个简单样本  $X = (X_1, \dots, X_n)$  分布族是指数族自然形式, 并由自然参数空间

由原例知令  $\Theta = (\mu, \sigma^2)$  有  $f(x; \mu, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left\{\frac{1}{\sigma^2} \sum_{i=1}^n x_i - \frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2\right\}$   $h(x) \equiv 1$

令  $\eta_1 = \mu, \eta_2 = \frac{1}{\sigma^2}$  求解:  $\sigma^2 = -\frac{1}{2\eta_2}, \frac{1}{\sigma^2} = -\frac{2\eta_2}{1}$  于是  $c(\eta) = \left(\frac{1}{2\eta_2}\right)^{n/2} e^{\frac{1}{2\eta_2}}$ ,  $\eta = (\eta_1, \eta_2)$  已为自然形式  
自然参数空间:  $\Theta^* = \{\eta = (\eta_1, \eta_2) : -\infty < \eta_1 < \infty, -\infty < \eta_2 < 0\}$

充分统计量: 定义: 设  $X$  分布族为  $\{f(x; \theta), \theta \in \Theta\}$   $\Theta$  为参数空间, 令  $T = T(X)$  为一个统计量, 若在给定  $T=t$  条件下, 样本  $X$  的条件分布与参数  $\theta$  无关,

则称  $T(X)$  为  $\Theta$  充分统计量

tip: 1. 定义  $\Leftrightarrow P(X=x_i | T=t)$  不依赖于  $\theta$   $\rightarrow \Theta$  充分统计量与  $\theta$  无关 !!!

取联合 p.d.f.

证明: ① 定义:  $f(x)$  与  $\theta$  无关

② 因子分解定理

不充分: ① 与  $\theta$  有关

② 因子分解法  
 $f(x)$  不能用充分统计量

例: 1. 设  $X = (X_1, \dots, X_n)$  为  $0-1$  分布中抽取  $n$  个简单样本, 则  $T(X) = \sum_{i=1}^n X_i$  为充分统计量 (这里  $\theta = P(X=1) = p$ )

证:  $T = T(X)$ , 只需证明条件概率与  $\theta$  无关, 当  $\sum_{i=1}^n x_i = t$  时有  $\prod_{i=1}^n P(X_i = x_i) = \prod_{i=1}^n \theta^{x_i} (1-\theta)^{1-x_i} = \theta^t (1-\theta)^{n-t}$

$P(X_1 = x_1, \dots, X_n = x_n | T=t) = \frac{P(X_1 = x_1, \dots, X_n = x_n, T=t)}{P(T=t)} = \frac{P(X_1 = x_1, \dots, X_n = x_n, \sum_{i=1}^n x_i = t)}{P(T=t)} = \frac{\theta^t (1-\theta)^{n-t}}{C_n^t \theta^t (1-\theta)^{n-t}} = \frac{1}{C_n^t}$  例  $P(X_1 = x_1, \dots, X_n = x_n | T=t) = \begin{cases} \frac{1}{C_n^t} & \sum_{i=1}^n x_i = t \\ 0 & \sum_{i=1}^n x_i \neq t \end{cases}$  与  $\theta$  无关, 证毕

2. 设  $X_1, \dots, X_n$  i.i.d.  $\sim N(\mu, \sigma^2)$  其中  $\sigma^2 > 0$  已知,  $\mu$  未知,  $T(X) = \bar{X}$ , 证明  $T$  不是充分统计量

$(X_1, \dots, X_n)$  联合密度为  $f(x_1, \dots, x_n) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right\}$  与  $\theta$  有关, 证毕

因子分解定理: 设样本  $X = (X_1, \dots, X_n)$  分布族为  $f(x; \theta)$  依赖于参数  $\theta$ ,  $T = T(X)$  是一个统计量, 则  $T$  为充分统计量充要条件是

$f(x; \theta)$  可以分解为  $f(x; \theta) = g(T; \theta) h(x)$  形式, 证:  $h(x) = h(x_1, \dots, x_n)$  不依赖于  $\theta$ ,  $T$  为充分统计量

推论: 设  $T = T(X)$  为  $\Theta$  充分统计量,  $S = S(T)$  为单值可逆函数, 则  $S = S(T)$  也是  $\Theta$  充分统计量

例: 设  $X = (X_1, \dots, X_n)$  为  $N(a, \sigma^2)$  中抽取  $n$  个简单样本, 令  $\theta = (a, \sigma^2)$  例  $(\bar{X}, S^2)$  为  $\Theta$  充分统计量.

$f(x; \theta) = \frac{1}{(\sqrt{2\pi}\sigma)^n} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - a)^2\right\} = \frac{1}{(\sqrt{2\pi}\sigma)^n} \exp\left\{-\frac{1}{2\sigma^2} \left(\sum_{i=1}^n x_i - na\right)^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \bar{x})^2\right\} = g(\bar{x}, s^2; \theta) \cdot h(x)$   $h(x) \equiv 1$ , 证毕

Theorem (3.1)  
【1】定理 5.4.3 (离散型) 设  $X_1, \dots, X_n$  i.i.d. 取自概率质量函数  $(p, m.f.)$   $P(X = x_i) = p_i$  的离散型总体  $X$ , 其中  $x_1 < x_2 < \dots$  是  $X$  的所有可能的取值. 定义  
 $P_0 = 0, P_1 = p_1, P_2 = p_1 + p_2, \dots$   
 $P_i = p_1 + \dots + p_i, \dots$   
以  $X_{(1)}, \dots, X_{(n)}$  为样本  $X_1, \dots, X_n$  的次序统计量, 则  
 $P(X_{(j)} \leq x) = \sum_{k=0}^j \binom{n}{k} P_0^k (1-P_0)^{n-k}$   
且  $P(X_{(j)} = x) = \sum_{k=0}^j \binom{n}{k} [P_0^k (1-P_0)^{n-k} - P_0^{k+1} (1-P_0)^{n-k-1}]$

例: 设  $X = (X_1, \dots, X_n)$  为从总体  $B(1, \theta)$  中抽取  $n$  个简单样本, 则  $T(X) = \sum_{i=1}^n X_i$  是  $\theta$  的充分统计量.

因  $X$  的  $f(x, \theta) = \prod_{i=1}^n \theta (1-\theta)^{1-x_i} = \theta^n (1-\theta)^{n-T}$   $= g(T, \theta) h(x)$ ,  $h(x) \equiv 1$ . 证毕

**完全统计量: 定义:** 设  $T = T(X)$  是统计量, 其诱导分布族为  $\mathcal{T} = \{g(t, \theta), \theta \in \Theta\}$ . 若对  $\forall t \in \mathcal{T}$  函数  $\varphi(t) = \varphi(t, \theta)$  是其期望  $E_{\theta}[\varphi(t)] = 0, \forall \theta \in \Theta$  可推  $\varphi \equiv 0$ .

证完全: ① 定义:  $E_{\theta}[\varphi] = 0 \Rightarrow \varphi = 0$  则称分布族  $\mathcal{T}$  是完全的,  $T(X)$  为完全统计量

②  $\text{int} \Theta \neq \emptyset$

tip: 1.  $\varphi(t) = 0$  中  $t$  只须考虑  $T(X)$  的所有取值

2. 若  $T$  是完全的, 对  $\forall$  可测函数  $\psi$ , 有  $\psi(T)$  是完全的.

例: 设  $X = (X_1, \dots, X_n)$  为  $B(1, \theta)$  中抽取  $n$  个简单样本, 则  $T(X) = \sum_{i=1}^n X_i$  是完全统计量

证  $\varphi$ : 用  $E[\varphi(T, \theta)] = 0 \Rightarrow \varphi(T, \theta) \equiv 0$ .

证  $\varphi$ : 有  $T(X) \sim B(n, \theta)$ , 则  $P_{\theta}(T(X)=k) = C_n^k \theta^k (1-\theta)^{n-k}, k=0, 1, \dots, n$ .

设  $\varphi(t)$  为任一实函数, 若是  $E_{\theta}[\varphi(T)] = 0, 0 < \theta < 1$ , 即  $\sum_{k=0}^n \varphi(k) C_n^k \theta^k (1-\theta)^{n-k} = 0 \Leftrightarrow \sum_{k=0}^n \varphi(k) C_n^k (\frac{\theta}{1-\theta})^k = 0, 0 < \theta < 1$

令  $\delta = \frac{\theta}{1-\theta}$ , 则上式为  $\sum_{k=0}^n \varphi(k) C_n^k \delta^k = 0, 0 < \delta < \infty$  这是关于  $\delta$  的多项式, 则一定有为  $\delta$  取值为:  $C_n^k \varphi(k) = 0$  对  $k=0, 1, \dots, n, \Rightarrow \varphi(T) = 0$  a.s. 证毕

例: 设  $X \sim F = \{N(\mu, \sigma^2) : \sigma > 0\}$ . ① 证明  $F$  不完备. ② 令  $X = (X_1, \dots, X_n)$  为从总体  $X$  中抽取  $n$  个简单样本, 证明  $T(X) = \sum_{i=1}^n X_i$  诱导分布族是完全的, 从而  $T$  完全

(1) 由于  $N(0, \sigma^2)$  族为正则族, 则  $\exists \varphi(x) = x, E_{\theta}[\varphi(x)] = 0 \Rightarrow \int \varphi(x) \neq 0$  a.s.  $P$  证毕

(2) 由充分性定义知:  $\sum_{i=1}^n (\frac{x_i}{\sigma})^2 \sim \chi_n^2, \dots, 1, 1$

例: 设  $X = (X_1, \dots, X_n)$  为  $U(0, 1)$  中抽取  $n$  个简单样本, 则  $T(X) = X_{(n)}$  为完全统计量

$T(X) = X_{(n)}$  的诱导分布族:  $f(t) = \frac{n! t^{n-1}}{(n-1)!} = n t^{n-1}, 0 < t < 1$  则  $f(x_{(n)}) = \begin{cases} \frac{n!}{(n-1)!} (\frac{x}{\theta})^{n-1} \cdot \frac{1}{\theta} = \frac{n \cdot x^{n-1}}{\theta^n} & 0 < x < \theta \\ 0 & \text{otherwise} \end{cases}$

设  $\varphi(t)$  为任一实函数, 若是  $E_{\theta}[\varphi(T)] = 0, \forall \theta > 0$ , 即  $\int_0^{\theta} \varphi(t) \cdot n t^{n-1} dt = 0$ , 对  $\theta > 0$  恒成立  $\Rightarrow \varphi(t) \theta^n = 0$ , 即  $\varphi(t) = 0$  对  $\forall \theta > 0$ .

即  $\varphi(t) = 0, t > 0$ , 即  $T(X) = X_{(n)}$  为完全统计量, 证毕

练习 设  $X_1, \dots, X_n$  i.i.d.  $\sim N(\mu, \sigma^2), \mu \in \mathbb{R}$  未知,  $\sigma^2 > 0$  已知. 证明:  $T(X) = \sum_{i=1}^n X_i$  是完全统计量. (参考【0】例2.7.2)

有  $T(X) \sim N(n\mu, n\sigma^2)$  为指数族分布, 若  $\mu$  已知, 则非完全统计量

则值参数空间为开区间, 是完全统计量.

### 指数族中统计量的完全性

定理:  $X = (X_1, \dots, X_n)$  的 p.d.f. 为  $f(x, \theta) = c(\theta) h(x) \exp\{\sum_{i=1}^n \theta_i T_i(x)\}, \theta = (\theta_1, \dots, \theta_k) \in \Theta^*$  为指数族自然形, 令  $T(X) = (T_1(X), \dots, T_k(X))$

若自然参数空间  $\Theta^* \subset \mathbb{R}^k$  是有内点 (存在开区间), 则  $T(X)$  为完全统计量

例: 设  $X = (X_1, \dots, X_n)$  为  $B(1, \theta)$  中抽取  $n$  个简单样本, 则  $T(X) = \sum_{i=1}^n X_i$  是完全统计量 (同上节第一例)

$f(x, \theta) = \theta^n (1-\theta)^{n-T} = (1 - e^{-\frac{\theta}{1-\theta}})^n \exp\{n \cdot \frac{\theta}{1-\theta} \cdot \sum_{i=1}^n X_i\}$

自然参数空间为  $\Theta^* = \{t = \frac{\theta}{1-\theta} : -\infty < t < \frac{\theta}{1-\theta} \rightarrow \infty\} = (-\infty, \infty)$  有内点, 由定理知  $T(X)$  为完全统计量

### 有界完全统计量与性质

定义: 对  $\forall$  满足  $E_{\theta}[\varphi(T, \theta)] = 0, \forall \theta \in \Theta$  有界 (a.s. 有界) 函数  $\varphi$ , 有  $\varphi(T, \theta) = 0$  a.s.  $\forall \theta \in \Theta$ , 则称  $T(X)$  为有界完全统计量 (完全  $\Leftrightarrow$  有界完全)

Banach 定理: 设  $F = \{f(x, \theta), \theta \in \Theta\}$  为一分布族,  $\Theta$  为参数空间,  $X = (X_1, \dots, X_n)$  为  $F$  中抽取  $n$  个简单样本, 设  $T(X)$  为有界完全统计量且为充分统计量

若随机变量  $V(X)$  分布与  $\theta$  无关, 则对  $\forall \theta \in \Theta, T(X)$  与  $V(X)$  独立

推论:  $X$  分布族为指数族, 自然形对自然参数空间有内点, 若  $U, V, W$  分布与  $\theta$  无关, 则对  $\forall \theta \in \Theta, T(X) = (T_1(X), \dots, T_k(X))$  与  $V(X)$  独立 (random variable, 随机变量)

例: 设  $X = (X_1, \dots, X_n)$  是  $N(\theta, 1)$  中抽取  $n$  个简单样本,  $R(X) = X_{(n)} - X_{(1)}$  为极差, 则  $T(X) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  与  $R(X)$  独立

有  $N(\theta, 1)$  为指数族, 自然参数空间  $\Theta^* = \{t = -\infty < t < \infty\}$  有内点, 则  $T(X)$  为充分完全统计量

充分:  $f(x, \theta) = (2\pi)^{-n/2} \exp\{-\frac{1}{2} \sum_{i=1}^n (x_i - \theta)^2\} = (2\pi)^{-n/2} \exp\{-\frac{n\theta^2}{2} + \theta \sum_{i=1}^n x_i\} \cdot \exp\{-\frac{1}{2} \sum_{i=1}^n x_i^2\}$  于是由因子分解定理知为充分统计量

完全:  $f(x, \theta) = \frac{1}{C(\theta)} \exp\{\theta \sum_{i=1}^n x_i - \frac{n}{2} \theta^2\} h(x)$  则  $\varphi$  为有界可测,  $\theta$  无内点, 为完全统计量.

令  $T = \sum_{i=1}^n X_i$ , 则  $T \sim N(n\theta, n)$  则  $T_1 = T, T_2 = n - T^2$  于是  $T_1, T_2$  分布与  $\theta$  无关, 又  $R(X) = X_{(n)} - X_{(1)} = T_{(n)} - T_{(1)}$  与  $\theta$  无关, 由 Banach 定理知  $T(X)$  与  $R(X)$  独立

几个推论 (其中用, 内容与上下文无关)	充分: 定义 (条件概率与 $\theta$ 无关), 因子分解定理
1. $X_1, \dots, X_n$ i.i.d. $\sim \text{Exp}(\lambda)$ , 则 $2\lambda \sum_{i=1}^n X_i \sim \chi_{2n}^2$ ( $2\lambda X_i \sim \chi_2^2$ )	注意: $f(x) = \pi f(x)$ 而不是 $f(x) = C_n^k \theta^k \exp\{kx\}$ 的
: (略)	

### 点估计

定义: 设  $X = (X_1, \dots, X_n)$  为从某总体  $F_{\theta}$  中抽取  $n$  个简单样本,  $g(\theta)$  为总体参数  $\theta$  的实函数, 用  $\hat{g}(X)$  作为  $g(\theta)$  的估计, 称为点估计. 此时称  $\hat{g}(X)$  为  $g(\theta)$  的  $F_{\theta}$  估计. 若  $\hat{g}(X)$  为  $g(\theta)$  的  $F_{\theta}$  估计, 则称  $\hat{g}(X)$  为  $g(\theta)$  的  $F_{\theta}$  估计.

### 矩估计

样本  $k$  阶原矩:  $a_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  样本  $k$  阶中心矩:  $m_k = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k$   
 矩估计:  $\dots, \mu_k = E[X - E[X]]^k$

**多元正态分布** 定义: 设有总体分布族  $\{f(x; \theta), \theta \in \Theta\}$ ,  $\Theta$  为参数空间,  $g(\theta)$  为定义在  $\Theta$  上参数  $\theta$  的函数, 可表示为总体分布族某些矩函数, 即  $g(\theta) = G(\mu_1, \dots, \mu_k; \mu_1, \dots, \mu_k)$   
 设  $X = (X_1, \dots, X_n)$  是上述分布族中抽取的简单样本, 将  $\Theta$  中  $\theta = (\theta_1, \dots, \theta_k)$  各分量用 "向量" 多元统计量  $\alpha = (\alpha_1, \dots, \alpha_k)$  代替, 则  $g(\alpha) = G(\alpha_1, \dots, \alpha_k; \mu_1, \dots, \mu_k)$   
 则  $g(\alpha)$  称为  $g(\theta)$  的多元统计量, 这种多元统计量  $g$  又称为矩法.

**例:** 设总体  $X \sim B(1, \theta)$ ,  $X = (X_1, \dots, X_n)$  为  $X$  中抽取的简单样本, 令  $g(\theta) = \theta$ ,  $g(\theta) = \theta(1-\theta)$  多元统计量.  
 $X \sim B(1, \theta) \Rightarrow P(X=x) = \theta^x (1-\theta)^{1-x}$   $x=0,1$ . 则  $E[X] = \alpha_1 = \theta$  于是  $g(\theta) = \alpha_1$  多元统计量为  $g(X_1, \dots, X_n) = \bar{x}$ ,  $g(\theta) = \alpha_1(1-\alpha_1)$  多元统计量为  $g(X_1, \dots, X_n) = \bar{x}(1-\bar{x})$

**例:** 设总体  $X \sim U(0, \theta_2)$ ,  $X = (X_1, \dots, X_n)$  为总体  $X$  中抽取的简单样本, 令  $\theta = (\theta_1, \theta_2)$ ,  $-\infty < \theta_1 < \theta_2 < \infty$ , 求  $\theta_1, \theta_2$  多元统计量  
 $X \sim U(0, \theta_2) \Rightarrow E[X] = \alpha_1 = \frac{1}{2}(\theta_1 + \theta_2)$   
 $D(X) = \mu_2 = \frac{1}{12}(\theta_2 - \theta_1)^2$   $\left. \begin{matrix} \theta_1 = \alpha_1 - \sqrt{3}\mu_2 \\ \theta_2 = \alpha_1 + \sqrt{3}\mu_2 \end{matrix} \right\}$  于是用  $\bar{x}$  与  $m_2$  代入, 得  $\hat{\theta}_1(X_1, \dots, X_n) = \bar{x} - \sqrt{3}m_2 = \bar{x} - \sqrt{3}S_n$ ,  $\hat{\theta}_2(X_1, \dots, X_n) = \bar{x} + \sqrt{3}S_n$   
 $S_n = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{x})^2$

**极大似然估计:** 定义: 设  $f(x; \theta) = f(x_1, \dots, x_n; \theta)$  为样本  $X = (X_1, \dots, X_n)$  的似然函数, 当  $x$  固定时, 把  $f(x; \theta)$  视为  $\theta$  的函数, 称为似然函数, 记为  $L(\theta; x) = f(x; \theta)$ ,  $\theta \in \Theta, x \in X$

**MLE 中  $L = f(x; \theta)$  联合 pdf** 称  $l(\theta; x) = \ln L(\theta; x)$  为对数似然函数  
 即用  $x_1, \dots, x_n$  简单样本估计 tip: 似然函数与概率函数是一回事, 似然函数为关于参数  $\theta$  的函数

**定义:** 设  $X = (X_1, \dots, X_n)$  是从参数分布族  $\{f(x; \theta), \theta \in \Theta\}$  中抽取的简单样本,  $L(\theta; x)$  为似然函数,  $l(\theta; x) = \ln L(\theta; x)$  为对数似然函数, 若存在估计量  $\hat{\theta}^* = \hat{\theta}^*(x)$  有  
 $L(\hat{\theta}^*(x); x) = \max_{\theta \in \Theta} L(\theta; x) \forall x \in X$  或等价地  $l(\hat{\theta}^*(x); x) = \max_{\theta \in \Theta} l(\theta; x)$  则称  $\hat{\theta}^*(x)$  为  $\theta$  的极大似然估计 (MLE). 若似然函数为  $g(\theta)$  则定义  $g(\hat{\theta}^*)$  为  $g(\theta)$  的 MLE.

tip: MLE 有不稳定性: 若  $\theta$  的 MLE 为  $\hat{\theta}^*$ , 则  $\theta$  为不可约函数  $g(\theta)$  的 MLE 为  $g(\hat{\theta}^*)$ , 因此如此其被以上定义中.

**求 MLE:** 1. 定理 (特例): 设  $X_1, \dots, X_n$  i.i.d. 服从有自然参数  $\eta$  的分布  $f(x; \eta) = c(\eta) h(x) \exp\{\frac{\eta}{\tau} T(x)\}$  的指数族分布,  $\eta \in \Theta$ , 对其对数似然函数  $l(\eta) = \ln c(\eta) + \frac{\eta}{\tau} \sum_{i=1}^n T(x_i) + \sum_{i=1}^n \ln h(x_i)$   
 若有一组参数  $\eta^* = \eta^* = 1, \dots, k$  这个方程组中的  $\eta^*$  存在且是自然参数空间  $\Theta$  的内点, 则  $\eta^*$  是  $\eta$  的 MLE.

中  $\frac{\partial l}{\partial \eta} = 0$  求  $x$  (中)  
 验证  $\frac{\partial^2 l}{\partial \eta^2} |_{\eta=\eta^*} < 0$

2. 定义出发.  
**例:** 设  $X = (X_1, \dots, X_n)$  是从两点分布族  $\{B(1, p), 0 < p < 1\}$  中抽取的简单样本, 求  $p$  的 MLE.  
 用定理 似然函数为  $L(p; x) = p^{\sum x_i} (1-p)^{n-\sum x_i}$ , 则  $l(p; x) = \ln L(p; x) = \sum_{i=1}^n x_i \ln p + (n - \sum_{i=1}^n x_i) \ln(1-p)$  则令  $\frac{\partial l(p; x)}{\partial p} = \frac{1}{p} \sum x_i - \frac{1}{1-p} (n - \sum x_i) = 0$   
 求解:  $\hat{p}^* = \frac{1}{n} \sum x_i = \bar{x}$ . 由于  $B(1, p)$  是指数族, 当  $\bar{x} \neq 0, 1$  时  $\hat{p}^* = \bar{x}$  属于自然参数空间  $\Theta^* = (0, 1)$  的内点, 取  $\hat{p}^*$  为  $p$  的 MLE.  
 按定义  $g^*(x) = \hat{p}^*(1-\hat{p}^*) = \bar{x}(1-\bar{x})$

**边界点** tip:  $\bar{x} = 0, 1$  不在  $\Theta^*$  内, 多给条件, 此时  $p$  的 MLE 不存在, 为死板缺陷,  $\hat{p}^* \in \Theta$  时若  $\exists \hat{p}^* \rightarrow \hat{p}^*$  且  $\hat{p}^* \in \Theta$ , 则  $\hat{p}^*$  也称  $p$  的 MLE, 于是此题中  $0, 1$  也可以认为是  $p$  的 MLE

**验证** 例: 设  $X = (X_1, \dots, X_n)$  是均匀分布族  $\{U(0, \theta), \theta > 0\}$  中抽取的简单样本, 求  $\theta$  的 MLE.  
 用定义 样本  $X = (X_1, \dots, X_n)$  的似然函数为  $f(x; \theta) = \begin{cases} \frac{1}{\theta^n} \prod_{i=1}^n X_i & \theta \geq \max X_i \\ 0 & \theta < \max X_i \end{cases}$  其支持集为  $\theta \geq \max X_i$ .  $L(\theta; x) = f(x; \theta)$  作为  $\theta$  的函数不是连续函数, 于是不能求导求  $\theta$  的 MLE.  
 为使  $L(\theta; x)$  达到极大, 由  $L(\theta; x)$  的表达式可见后  $\theta$  应尽可能小, 并记为  $\hat{\theta}^* = X_{(n)}$  即为  $\theta$  的 MLE  
 tip: 若为  $U(0, \theta)$ , 则显然  $\hat{\theta}^*$  不存在, 且由连续型 r.v. 取一点  $p$  为 0, 因此可讨论及计算为  $(0, \theta)$ .

**期中考试界限** 2023.10.28 考试  
 给定  $X$  的似然函数为  $L(\theta; x) = \begin{cases} \theta^n \prod_{i=1}^n X_i & \theta \geq \max X_i \\ 0 & \theta < \max X_i \end{cases}$  于是对  $\forall 0 < \lambda < 1$ ,  $\hat{\theta}^*(x) = \lambda X_{(n)} + (1-\lambda)(X_{(n)} - 1) \lambda \in [0, 1]$  若  $\theta$  的 MLE

**Bayes 估计** 定义: 参数空间  $\Theta$  上  $\theta \in \Theta$  的概率分布称为先验分布, 记为  $F^*(\theta)$ , 在给定条件下用  $X(\theta)$  表示其密度函数

**定义:** 在某简单样本  $X$  下,  $\theta$  的后验分布就是给定  $X = x$  条件下  $\theta$  的条件分布, 后验密度  $\pi(\theta|x)$  有下列计算公式:  $\pi(\theta|x) = \frac{f(x; \theta) \pi(\theta)}{\int_{\Theta} f(x; \theta) \pi(\theta) d\theta}$   
 其中  $f(x; \theta)$  为给定  $\theta$  时样本  $X$  的条件密度函数,  $\pi(\theta)$  为  $\theta$  的先验密度,  $f(x; \theta) = f(x_1, \theta) \pi_1(\theta)$  与  $\lambda$  的联合密度,  $m(x) = \int_{\Theta} f(x; \theta) \pi(\theta) d\theta$  为  $X$  的边缘密度

**定义:** 用后验分布  $\pi(\theta|x)$  作为  $\theta$  的估计量称为  $\theta$  的后验期望估计, 我们本课程中称 Bayes 估计即指后验期望估计, 记为  $\hat{\theta}_B$

**例:** 设  $X \sim N(\theta, \sigma^2)$ ,  $\sigma^2$  已知,  $x = (x_1, \dots, x_n)$  为总体  $X$  中抽取的简单样本, 令  $\theta$  的先验分布  $\pi(\theta)$  为  $N(\mu, \tau^2)$ , 其中  $\mu$  与  $\tau^2$  已知, 求  $\theta$  的后验分布  $\pi(\theta|x)$

给定  $\theta$  时  $X$  的 pdf 为  $f(x; \theta) = (2\pi\sigma^2)^{-\frac{n}{2}} \exp\{-\frac{1}{2\sigma^2} [\sum_{i=1}^n (x_i - \theta)^2 + n(\bar{x} - \theta)^2]\} \propto \exp\{-\frac{1}{2\sigma^2} [A\theta^2 - 2B\theta + C]\}$  其中  $\sigma^2 = \frac{\sigma^2}{n}$   
 令  $A = \frac{1}{\sigma^2} + \frac{1}{\tau^2}$ ,  $B = \frac{\sum x_i}{\sigma^2} + \frac{\mu}{\tau^2}$ ,  $C = \frac{\sum x_i^2}{\sigma^2} + \frac{\mu^2}{\tau^2}$  则有  $\pi(\theta|x) \propto f(x; \theta) \pi(\theta) \propto \exp\{-\frac{1}{2} [\frac{A\theta^2}{\sigma^2} - \frac{2B\theta}{\sigma^2} + \frac{C}{\sigma^2}]\} \propto \exp\{-\frac{1}{2} [A\theta^2 - 2B\theta + C]\}$   
 得到后验分布为  $\pi(\theta|x) = \frac{1}{\sqrt{2\pi} \eta} \exp\{-\frac{1}{2\eta^2} (\theta - \mu_1)^2\}$  其中  $\mu_1 = \frac{\mu}{\sigma^2} + \frac{\sum x_i}{\sigma^2}$ ,  $\eta^2 = \frac{1}{\sigma^2} + \frac{1}{\tau^2}$   
 是  $N(\mu_1, \eta^2)$  密度函数, 记为正则化因子

设  $X = (X_1, \dots, X_n)$  是从正态分布族  $N(\theta, \sigma^2)$  中抽取的简单样本, 其中  $\sigma^2$  已知, 取  $\theta$  的先验为其联合分布  $N(\mu, \tau^2)$ , 求  $\theta$  的 Bayes 估计  
 由上例知  $\theta$  的后验分布  $N(\mu_1, \eta^2)$ , 由于对称性, 故  $\hat{\theta}_B = \mu_1$

**定义:** 设  $\lambda$  为由  $\theta$  的先验分布  $\pi(\theta)$  构成的分布族, 若对  $\forall \lambda \in \Lambda$ , 有  $\pi(\theta|x) \in \Lambda$ , 则称  $\Lambda$  为一个封闭先验分布族

**例:** 设  $X = (X_1, \dots, X_n)$  是从总体  $\Gamma(r, \lambda)$  中抽取的简单样本, 其中  $r$  已知, 限定  $\lambda$  的先验分布为 Gamma 分布  $\Gamma(b, a)$ , 证明给定  $X$  时  $\lambda$  的后验分布仍为 Gamma 分布

**证明:** 给定  $\lambda$  时  $X$  的条件密度为  $f(x; \lambda) = \frac{\lambda^r}{\Gamma(r) \eta^n} \prod_{i=1}^n X_i^{r-1} \exp\{-\lambda \sum_{i=1}^n X_i\} \propto \lambda^r \exp\{-\lambda \sum_{i=1}^n X_i\}$  其中  $\eta = \frac{1}{\lambda}$   
 而  $\lambda$  的先验分布为  $\pi(\lambda) = \frac{a^b}{\Gamma(b)} \lambda^{b-1} \exp\{-a\lambda\} \propto \lambda^{b-1} \exp\{-a\lambda\}$  称  $\Lambda$  (与  $\lambda$  有密切关系)  
 于是  $\pi(\lambda|x) \propto f(x; \lambda) \pi(\lambda) \propto \lambda^{r+b-1} \exp\{-(a + \sum_{i=1}^n X_i)\lambda\}$   $\lambda > 0$ . 这是  $\Gamma(r+b, a + \sum_{i=1}^n X_i)$  的密度函数,  
 故  $\Lambda$  为封闭先验分布, 有后验密度为  $\pi(\lambda|x) = \frac{(a + \sum_{i=1}^n X_i)^{r+b}}{\Gamma(r+b)} \lambda^{r+b-1} \exp\{-(a + \sum_{i=1}^n X_i)\lambda\}$   $\lambda > 0$  证毕



例: 设  $X = (X_1, \dots, X_n)$  为指数分布  $\text{Exp}(\lambda)$  中抽取的简单样本, 用 C-R 定理证明  $\hat{g}(x) = \bar{x} = \frac{1}{n} \sum_{i=1}^n X_i$  为  $g(\lambda) = \frac{1}{\lambda}$  的 UMVUE

3.5.3 指数分布为指数族, 则 C-R 正则条件成立. Fisher 信息函数为  $I(\lambda) = E_{\lambda} \left[ \left( \frac{\partial \ln f_{\lambda}(x; \lambda)}{\partial \lambda} \right)^2 \right] = E_{\lambda} [(X - \lambda)^{-2}] = \text{Var}_{\lambda}(X) = \frac{1}{\lambda^2}$   
 于是 C-R 下界为  $\frac{(g'(\lambda))^2}{n I(\lambda)} = \frac{1}{n \lambda^2}$ ,  $\hat{g}(x) = \bar{x}$  为  $g(\lambda) = \frac{1}{\lambda}$  的无偏估计,  $\text{Var}_{\lambda}(\bar{x}) = \frac{1}{n \lambda^2}$  达到 C-R 下界, 故  $\bar{x}$  为  $\frac{1}{\lambda}$  的 UMVUE

例: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取的简单样本, 其中  $\sigma^2$  已知, 用 C-R 定理证明  $\hat{g}(x) = \bar{x} = \frac{1}{n} \sum_{i=1}^n X_i$  为  $g(\mu) = \mu$  的 UMVUE

3.5.4 正态分布为指数族, C-R 正则条件皆成立, 有  $f(x; \mu) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\{-\frac{1}{2\sigma^2}(x-\mu)^2\}$  于是 Fisher 信息函数为  $I(\mu) = E_{\mu} \left[ \left( \frac{\partial \ln f_{\mu}(x; \mu)}{\partial \mu} \right)^2 \right] = E_{\mu} \left[ \left( \frac{x-\mu}{\sigma^2} \right)^2 \right] = \frac{1}{\sigma^2}$ ,  $\text{Var}_{\mu}(x) = \frac{1}{\sigma^2}$   
 于是其 C-R 下界为  $\frac{(g'(\mu))^2}{n I(\mu)} = \frac{\sigma^2}{n}$ ,  $\text{Var}_{\mu}(\bar{x}) = \frac{\sigma^2}{n}$  达到 C-R 下界, 故  $\bar{x}$  为  $\mu$  的 UMVUE

C-R 定理与正则条件

结论: (1) 若样本分布族非指数族, 则  $g(\theta)$  的无偏估计  $\hat{g}(\theta)$ , 其方差不处处  $(\forall \theta \in \Theta)$  达到 C-R 定理中的下界

(2) 即使样本分布族为指数族, 也只有当  $g(\theta) = E_{\theta}(a(T) + b)$  且  $E_{\theta}(T) = a(\theta) + b$  时才达到 C-R 下界. (条件是  $a(\theta) = f(x, \theta) = C(\theta)h(x) \exp\{Q(\theta)T(x)\}$ )

Corollary (2.3)  
 在定理 2.2 条件下, 如果  $W(X)$  是  $T(\theta)$  的一个无偏估计, 则  $W$  是  $T(\theta)$  的 UMVUE. 如果  $W$  是  $T(\theta)$  的 UMVUE, 则  $W(X) = T(\theta) = g(\theta)$ .  
 这里,  $C(\theta) = f(x, \theta)$  为样本  $X_1, \dots, X_n$  的联合函数.

用于证明是可行的证明 C-R 下界

例: 设  $X = (X_1, \dots, X_n)$  为 Poisson 分布  $P(\lambda)$  中抽取的简单样本, 证明只有  $g(\lambda)$  为  $\lambda$  的线性函数时才存在  $g(\lambda)$  的无偏估计, 其方差处处达到 C-R 下界

3.5.5

简单样本  $X$  的联合分布  $f(x; \lambda) = \frac{\lambda^{x_1+\dots+x_n} e^{-n\lambda}}{x_1! \dots x_n!}$  表示为指数族形式  $f(x; \lambda) = \frac{e^{-n\lambda} \exp\{n\lambda T(x)\}}{x_1! \dots x_n!} = C(\lambda)h(x) \exp\{Q(\lambda)T(x)\}$

由定理 2.2 结论, 当  $g(\lambda) = E[a(T) + b] = a(\lambda) + b = c\lambda + b$ ,  $c, b$  为常数时  $\hat{g}(x) = a(T) + b$  为方差处处达到 C-R 下界, 为  $g(\lambda)$  的 UMVUE. ( $a = \frac{1}{n}$ ,  $b = 0$  时  $\hat{g}(x) = \bar{x}$ , 与 3.5.2 结论相同)

有效性

定义: 设  $\hat{g}_1(x) = \hat{g}_1(x_1, \dots, x_n)$  与  $\hat{g}_2(x) = \hat{g}_2(x_1, \dots, x_n)$  为  $g(\theta)$  的无偏估计, 若  $\text{Var}_{\theta}(\hat{g}_1(x)) \leq \text{Var}_{\theta}(\hat{g}_2(x)) \forall \theta \in \Theta$  且至少存在  $\theta_0 \in \Theta$  使不等号成立, 则称估计量  $\hat{g}_1(x)$  比  $\hat{g}_2(x)$  有效

定义: 设  $\hat{g}_1(x)$  为  $g(\theta)$  的无偏估计, 比  $\hat{g}_2(x) = \frac{g(\theta)}{E_{\theta}(\hat{g}_2(x))}$  称为无偏估计  $\hat{g}_1(x)$  的效能, 且  $0 < e_{\hat{g}_1}(\theta) \leq 1$ . (有效估计一定是 UMVUE)

当  $e_{\hat{g}_1}(\theta) = 1$  时, 称  $\hat{g}_1(x)$  为  $g(\theta)$  的有效估计; 若  $\hat{g}_1(x)$  不是  $g(\theta)$  的有效估计, 且  $\lim_{n \rightarrow \infty} e_{\hat{g}_1}(\theta) = 1$ , 则称  $\hat{g}_1(x)$  为  $g(\theta)$  的渐进有效估计

例: 设  $X = (X_1, \dots, X_n)$  为  $N(a, \sigma^2)$  中抽取的简单样本, (1)  $a$  未知时, 证明样本方差  $S^2$  不是  $\sigma^2$  的有效估计, 且是渐进有效估计.

(2)  $a$  已知时,  $\bar{x}$  为  $a$  的有效估计

(3) 已知  $a$  未知时  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{x})^2$  的方差为  $\frac{2\sigma^4}{n-1}$  不是 C-R 下界  $\frac{\sigma^4}{n-1}$ , 非有效估计. 取  $\hat{g}_2(x) = \frac{1}{n-1} \sum_{i=1}^n (X_i - a)^2$ , 且  $\lim_{n \rightarrow \infty} e_{\hat{g}_2}(\sigma^2) = 1$ , 证明

(4) 令  $S_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - a)^2$ , 有  $nS_n^2/\sigma^2 \sim \chi^2_n$ , 故  $\text{Var}(nS_n^2/\sigma^2) = 2n$ , 即  $\text{Var}(S_n^2) = \frac{2\sigma^4}{n}$  为有效估计. 故有效估计为  $S_n^2$ .

方法二: 空无偏估计法

只需用空无偏

定理 (R-B 引理): 设  $T = T(x)$  是  $g(\theta)$  的充分统计量, 而  $\hat{g}(x)$  为  $g(\theta)$  的无偏估计, 则  $h(T) = E[\hat{g}(x)|T]$  是  $g(\theta)$  的无偏估计, 且  $\text{Var}_{\theta}(h(T)) \leq \text{Var}_{\theta}(\hat{g}(x)) \forall \theta \in \Theta$

等号成立当且仅当  $P_{\theta}(\hat{g}(x) = h(T)) = P_{\theta}(h(T) = h(T)) = 1$  或  $P_{\theta}$  成立 (表明 UMVUE 一定是充分统计量的函数)

例: 设  $X = (X_1, \dots, X_n)$  是二项分布族  $B(n, p)$  中抽取的简单样本, 显然  $X$  是  $p$  的一个充分统计量,  $T(x) = \sum_{i=1}^n X_i$  是  $p$  的充分统计量, 用  $T = T(x)$  构造一个比  $\bar{x}$  方差更小的无偏估计

由 R-B 引理, 有  $h(T) = E[\bar{x}|T] = \frac{p \sum_{i=1}^n C_n^i p^i (1-p)^{n-i}}{P(T=i)} = \frac{p C_n^i p^i (1-p)^{n-i}}{C_n^i p^i (1-p)^{n-i}} = \frac{p}{1-p}$  其方差为  $\frac{p(1-p)}{(1-p)^2}$  即为  $p(1-p)$  满足条件.

定理: 设  $\hat{g}(x)$  是  $g(\theta)$  的一个无偏估计,  $\text{Var}_{\theta}(\hat{g}(x)) < \infty \forall \theta \in \Theta$ . 令  $\mathcal{W} = \{U(\theta) | E_{\theta}[U(\theta)] = 0 \forall \theta \in \Theta\}$  为空无偏估计的集合, 则  $\hat{g}(x)$  为  $g(\theta)$  的 UMVUE  $\Leftrightarrow E_{\theta}[\hat{g}(x) \cdot U(\theta)] = 0 \forall \theta \in \Theta$ .

推论: 设  $T = T(x)$  为  $\theta$  的充分统计量,  $h(T) = h(T(x))$  是  $g(\theta)$  的一个方差有限的无偏估计,  $h(T)$  为  $g(\theta)$  的 UMVUE  $\Leftrightarrow E_{\theta}(h(T) \cdot \delta(T)) = 0$ , 其中  $\delta(T) \in \mathcal{W}(T)$  为关于  $T$  的空无偏估计函数

例: 设  $X = (X_1, \dots, X_n)$  为指数分布  $f(x) = e^{-\lambda x} I(x>0)$  中抽取的简单样本, 用空无偏估计法中参数  $\mu$  的 UMVUE. 空无偏法: (1) 找  $T$  充分

3.5.4

注意到  $T = \sum_{i=1}^n X_i$  为充分统计量,  $f_{X_i}(t) = n e^{-nt} I(t>0)$ , 且只要考虑基于  $T$  的统计量,  $h(T) = T^{-1}$  为  $\mu = \frac{1}{\lambda}$  的一个无偏估计.

设  $\delta(T)$  为任一空无偏估计, 有  $E_{\lambda}[\delta(T)] = \int_0^{\infty} \delta(t) \cdot n e^{-nt} dt = 0 \Leftrightarrow \int_0^{\infty} \delta(t) e^{-nt} dt = 0$ . 对  $\mu$  求导:  $\delta'(t) e^{-t} = 0 \Rightarrow \int_0^{\infty} \delta'(t) e^{-t} dt = 0$ .

于是  $E_{\lambda}[h(T) \cdot \delta(T)] = 0$  则  $h(T)$  为  $\mu$  的 UMVUE

例: 设  $X = (X_1, \dots, X_n)$  为均匀分布  $U(a, b)$ ,  $\theta \in (a, b)$  中抽取的简单样本, 用空无偏估计法中参数  $\theta$  的 UMVUE.

3.5.5

已知  $T = \sum_{i=1}^n X_i$  为充分统计量, 有  $f_{X_i}(t) = n \theta^{-1} e^{-t/\theta} I(t>0)$ , 设  $\delta(T)$  为任一空无偏估计, 有  $E_{\theta}[\delta(T)] = \int_0^{\theta} \delta(t) \frac{n}{\theta} e^{-t/\theta} dt = 0 \Rightarrow \int_0^{\theta} \delta(t) e^{-t/\theta} dt = 0$

对  $\theta$  求导:  $\delta(\theta) \theta^{-2} = 0 \forall \theta > 0$ , 则  $\delta(\theta) = 0 \forall \theta > 0$  于是有  $\int_0^{\theta} \delta(t) e^{-t/\theta} dt = 0$

设  $h(T)$  是  $\theta$  的一个无偏估计, 为  $E_{\theta}[h(T) \cdot \delta(T)] = 0$ , 有  $0 = E_{\theta}[h(T) \cdot \delta(T)] = \int_0^{\theta} h(t) \frac{n}{\theta} e^{-t/\theta} dt = 0 \Rightarrow \int_0^{\theta} h(t) e^{-t/\theta} dt = 0$

考虑  $h(t) = \begin{cases} C & 0 \leq t \leq \theta \\ 0 & t > \theta \end{cases}$  由  $h(t)$  为无偏估计, 代入有  $h(T) = \frac{1}{n} \sum_{i=1}^n I(T_i \leq T)$  为  $\theta$  的 UMVUE

方法三: 充分完全统计量法 —— LS 定理

空无偏法: (1) 找到充分 (2) 无偏估计  $h(T)$

定理 (Lehmann-Scheffe):  $T$  是  $\theta$  的充分完全统计量,  $h(T)$  是  $g(\theta)$  的无偏估计, 则  $h(T)$  是  $g(\theta)$  的唯一 UMVUE.

若有  $W$  为  $g(\theta)$  的无偏估计, 则  $\varphi(T) = E[W|T]$  为  $g(\theta)$  的 UMVUE.

例: 已知  $T = T(x) = \sum_{i=1}^n X_i$  服从二项分布  $B(n, p)$ , 且  $T(x)$  为充分完全统计量, 若  $g(p) = p(1-p)$  的 UMVUE.

3.5.7

设  $\delta(T)$  为  $g(p) = p(1-p)$  的一个无偏估计, 由  $T \sim B(n, p)$  与无偏估计的定义可得  $\sum_{i=0}^n C_n^i \delta(i) p^i (1-p)^{n-i} = p(1-p) \forall 0 < p < 1$

令  $P = \frac{p}{1-p} \Rightarrow p = \frac{P}{1+P}$  代入有  $\sum_{i=0}^n C_n^i \delta(i) P^i (1+P)^{-n-i} = \frac{P}{1+P} \frac{1-P}{1+P} = \frac{P(1-P)}{(1+P)^2} \forall 0 < P < \infty$

对比系数有  $\delta(i) = 0 \forall i = 0, n$   
 $= \frac{C_n^i \delta(i)}{C_n^i} \forall i = 1, \dots, n-1$  }  $\delta(T) = \frac{T(n-T)}{n(n-1)}$  由 LS 定理知其为  $g(p)$  的 UMVUE.

若 UMVUE 为  $T$  的线性函数则能达到 C-R 下界

由另得: 令  $\varphi(x) = I[x_1 = 1, x_2 = 0] \Rightarrow E[\varphi(x)] = P(X_1=1, X_2=0)$  为  $g(p)$  的无偏估计

有  $h(T) = E[\varphi(x)|T] = P(X_1=1, X_2=0|T) = \frac{P(C_n^{T-1} P^{T-1} (1-P)^{n-T+1})}{P(T=T)} = \frac{C_n^{T-1}}{C_n^T} = \frac{T(n-T)}{n(n-1)}$  则  $h(T)$  为  $g(p)$  的 UMVUE.

设  $h(T)$  为  $g(p)$  的无偏估计, 则  $h(T)$  为  $g(p)$  的 UMVUE.

例: 设  $X = (X_1, \dots, X_n)$  为 Poisson 分布  $P(\lambda)$  中抽取的简单样本, 下面  $g(\lambda)$  的 UMVUE: (1)  $g_1(\lambda) = \lambda$  (2)  $g_2(\lambda) = \lambda^2$  (3)  $g_3(\lambda) = \lambda^2$  (4)  $g_4(\lambda) = \lambda^2$  (5)  $g_5(\lambda) = \lambda^2$  (6)  $g_6(\lambda) = \lambda^2$  (7)  $g_7(\lambda) = \lambda^2$  (8)  $g_8(\lambda) = \lambda^2$  (9)  $g_9(\lambda) = \lambda^2$  (10)  $g_{10}(\lambda) = \lambda^2$  (11)  $g_{11}(\lambda) = \lambda^2$  (12)  $g_{12}(\lambda) = \lambda^2$  (13)  $g_{13}(\lambda) = \lambda^2$  (14)  $g_{14}(\lambda) = \lambda^2$  (15)  $g_{15}(\lambda) = \lambda^2$  (16)  $g_{16}(\lambda) = \lambda^2$  (17)  $g_{17}(\lambda) = \lambda^2$  (18)  $g_{18}(\lambda) = \lambda^2$  (19)  $g_{19}(\lambda) = \lambda^2$  (20)  $g_{20}(\lambda) = \lambda^2$  (21)  $g_{21}(\lambda) = \lambda^2$  (22)  $g_{22}(\lambda) = \lambda^2$  (23)  $g_{23}(\lambda) = \lambda^2$  (24)  $g_{24}(\lambda) = \lambda^2$  (25)  $g_{25}(\lambda) = \lambda^2$  (26)  $g_{26}(\lambda) = \lambda^2$  (27)  $g_{27}(\lambda) = \lambda^2$  (28)  $g_{28}(\lambda) = \lambda^2$  (29)  $g_{29}(\lambda) = \lambda^2$  (30)  $g_{30}(\lambda) = \lambda^2$  (31)  $g_{31}(\lambda) = \lambda^2$  (32)  $g_{32}(\lambda) = \lambda^2$  (33)  $g_{33}(\lambda) = \lambda^2$  (34)  $g_{34}(\lambda) = \lambda^2$  (35)  $g_{35}(\lambda) = \lambda^2$  (36)  $g_{36}(\lambda) = \lambda^2$  (37)  $g_{37}(\lambda) = \lambda^2$  (38)  $g_{38}(\lambda) = \lambda^2$  (39)  $g_{39}(\lambda) = \lambda^2$  (40)  $g_{40}(\lambda) = \lambda^2$  (41)  $g_{41}(\lambda) = \lambda^2$  (42)  $g_{42}(\lambda) = \lambda^2$  (43)  $g_{43}(\lambda) = \lambda^2$  (44)  $g_{44}(\lambda) = \lambda^2$  (45)  $g_{45}(\lambda) = \lambda^2$  (46)  $g_{46}(\lambda) = \lambda^2$  (47)  $g_{47}(\lambda) = \lambda^2$  (48)  $g_{48}(\lambda) = \lambda^2$  (49)  $g_{49}(\lambda) = \lambda^2$  (50)  $g_{50}(\lambda) = \lambda^2$  (51)  $g_{51}(\lambda) = \lambda^2$  (52)  $g_{52}(\lambda) = \lambda^2$  (53)  $g_{53}(\lambda) = \lambda^2$  (54)  $g_{54}(\lambda) = \lambda^2$  (55)  $g_{55}(\lambda) = \lambda^2$  (56)  $g_{56}(\lambda) = \lambda^2$  (57)  $g_{57}(\lambda) = \lambda^2$  (58)  $g_{58}(\lambda) = \lambda^2$  (59)  $g_{59}(\lambda) = \lambda^2$  (60)  $g_{60}(\lambda) = \lambda^2$  (61)  $g_{61}(\lambda) = \lambda^2$  (62)  $g_{62}(\lambda) = \lambda^2$  (63)  $g_{63}(\lambda) = \lambda^2$  (64)  $g_{64}(\lambda) = \lambda^2$  (65)  $g_{65}(\lambda) = \lambda^2$  (66)  $g_{66}(\lambda) = \lambda^2$  (67)  $g_{67}(\lambda) = \lambda^2$  (68)  $g_{68}(\lambda) = \lambda^2$  (69)  $g_{69}(\lambda) = \lambda^2$  (70)  $g_{70}(\lambda) = \lambda^2$  (71)  $g_{71}(\lambda) = \lambda^2$  (72)  $g_{72}(\lambda) = \lambda^2$  (73)  $g_{73}(\lambda) = \lambda^2$  (74)  $g_{74}(\lambda) = \lambda^2$  (75)  $g_{75}(\lambda) = \lambda^2$  (76)  $g_{76}(\lambda) = \lambda^2$  (77)  $g_{77}(\lambda) = \lambda^2$  (78)  $g_{78}(\lambda) = \lambda^2$  (79)  $g_{79}(\lambda) = \lambda^2$  (80)  $g_{80}(\lambda) = \lambda^2$  (81)  $g_{81}(\lambda) = \lambda^2$  (82)  $g_{82}(\lambda) = \lambda^2$  (83)  $g_{83}(\lambda) = \lambda^2$  (84)  $g_{84}(\lambda) = \lambda^2$  (85)  $g_{85}(\lambda) = \lambda^2$  (86)  $g_{86}(\lambda) = \lambda^2$  (87)  $g_{87}(\lambda) = \lambda^2$  (88)  $g_{88}(\lambda) = \lambda^2$  (89)  $g_{89}(\lambda) = \lambda^2$  (90)  $g_{90}(\lambda) = \lambda^2$  (91)  $g_{91}(\lambda) = \lambda^2$  (92)  $g_{92}(\lambda) = \lambda^2$  (93)  $g_{93}(\lambda) = \lambda^2$  (94)  $g_{94}(\lambda) = \lambda^2$  (95)  $g_{95}(\lambda) = \lambda^2$  (96)  $g_{96}(\lambda) = \lambda^2$  (97)  $g_{97}(\lambda) = \lambda^2$  (98)  $g_{98}(\lambda) = \lambda^2$  (99)  $g_{99}(\lambda) = \lambda^2$  (100)  $g_{100}(\lambda) = \lambda^2$

原集合中设  $T = T(x) = \sum_{i=1}^n X_i$  为充分完全统计量  
 (1) 令  $h(T) = \frac{T}{n}$ ,  $E[h(T)] = E[\bar{x}] = \lambda$  则  $h(T)$  为  $T$  的函数且为  $\lambda$  的无偏估计, 由 LS 定理知其为  $g(\lambda)$  的 UMVUE.

① 有  $T \sim P(\lambda)$ , 令  $h_2(T) = g_2(\lambda) = \lambda^r$  为充分统计量. 由  $E[h_2(T)] = g_2(\lambda) \Rightarrow \sum_{k=0}^{\infty} h_2(k) \frac{e^{-\lambda} \lambda^k}{k!} = \lambda^r \Rightarrow \sum_{k=0}^{\infty} h_2(k) \frac{\lambda^k}{k!} = \lambda^r e^{-\lambda} = \lambda^r \frac{e^{-\lambda}}{1 - e^{-\lambda}} = \frac{\lambda^r}{1 - e^{-\lambda}}$   
 比较系数有  $h_2(k) = \begin{cases} \frac{e^{-\lambda}}{(k-r)!} & k \geq r \\ 0 & k < r \end{cases}$  即  $E[h_2(T)] = \frac{T(T-1)\dots(T-r+1)}{r!} = \lambda^r$ . 为  $\lambda^r$  充分统计量. 由 L-S 定理知  $h_2(T)$  为  $g_2(\lambda) = U_{MVUE}$ .

寻找无偏 W.  
 $h_2(T) = E[h_2(T) | T] = \lambda^r$

② 有  $g_1(x) = \frac{e^{-\lambda} \lambda^x}{x!} = g_2(\lambda)$  令  $\varphi(x) = I(x, \lambda)$  有  $E[\varphi(x)] = E[g_2(\lambda)] = g_2(\lambda)$  即  $\varphi(x)$  为  $g_2(\lambda)$  充分统计量  
 有  $h_2(T) = E[\varphi(x) | T = t] = P_1(X_1 = x_1 | T = t) = \frac{P_1(X_1 = x_1) P_1(X_2 = t - x_1)}{P_1(X_1 + X_2 = t)} = \frac{e^{-\lambda} \lambda^{x_1} e^{-\lambda} \lambda^{t-x_1}}{e^{-\lambda} \lambda^t} = \frac{(x_1-1)! (t-x_1)!}{t!} = C_{t-1}^{x_1-1} \frac{\lambda^{x_1-1}}{t^{x_1-1}}$   
 由 L-S 定理知  $h_2(T) = C_{t-1}^{x_1-1} \frac{\lambda^{x_1-1}}{t^{x_1-1}}$  为  $g_2(\lambda)$  充分统计量

条件不变 (1) 验证  $\hat{\lambda} = \bar{x}$  与  $\hat{\lambda}^* = S^{-1}$  均为  $\lambda$  充分统计量  $E[C(X)] = E[D(X)] = \lambda$   
 (2) 计算  $Var(\hat{\lambda})$  与  $Var(\hat{\lambda}^*)$ , 说明在均方误差 MSE 意义下哪个估计更好.  
 (3)  $\hat{\lambda}$  是否为  $\lambda$  充分统计量?  $E[C(X)] = E[C(X)] + Var(C(X)) = \lambda^2 + \lambda$ ,  $E[D(X)] = \frac{1}{n} \sum_{i=1}^n E[C(X_i)] + \frac{1}{n} \sum_{i=1}^n E[D(X_i)] = \frac{n}{n} \lambda^2 = \lambda^2$   
 (4)  $E[\hat{\lambda}] = \frac{1}{n} E[\sum_{i=1}^n X_i] = E[X_1] = \lambda$ , 有  $E[\hat{\lambda}^*] = \frac{1}{n-1} E[\sum_{i=1}^n (X_i - \bar{x})^2] = \frac{1}{n-1} (n-1) \lambda = \lambda$  且  $Var(\hat{\lambda}) = \frac{1}{n} Var(X_1) = \frac{1}{n} \lambda$ ,  $Var(\hat{\lambda}^*) = \frac{1}{(n-1)^2} Var(\sum_{i=1}^n (X_i - \bar{x})^2) = \frac{2}{(n-1)^2} n \lambda = \frac{2\lambda}{n-1}$  (计算复杂) 则  $\hat{\lambda}$  更好  
 (5) 是, 且是  $T$  的函数, 且是统计量.

$X \sim \chi_n^2$   
 则  $E[\frac{1}{X}] = \frac{1}{n-2}$

例: 设  $X = (X_1, \dots, X_n)$  为  $N(a, \sigma^2)$  中抽取的简单样本, 记  $\theta = (a, \sigma^2)$  求下面 U, MVUE: ①  $a, \sigma^2$  ②  $g_1(\theta) = \sigma^2$  ③  $g_2(\theta) = \frac{a}{\sigma^2}$   
 由原假设知  $T = (T_1, T_2)$  为充分完全统计量,  $T_1 = \bar{x}, T_2 = \sum_{i=1}^n (X_i - \bar{x})^2$   
 ①  $h_1(T) = \bar{x} = T_1, h_2(T) = \frac{1}{n} T_2$  分别为  $a, \sigma^2$  充分统计量, 由 L-S 定理知  $h_1, h_2$  分别为  $a, \sigma^2$  充分统计量  
 ② 有  $\gamma = \frac{1}{\sigma^2} \sim \chi_{n-1}^2$ , 则  $\sigma^2$  充分统计量与  $T_2$  为充分统计量, 有  $\frac{1}{\sigma^2} E[T_2^2] = 2^2 \frac{\Gamma(\frac{n-1}{2})}{\Gamma(\frac{n-1}{2})} = \frac{1}{\sigma^2}$ , 则  $h_1(T) = \frac{1}{n} T_2$  为  $\sigma^2$  充分统计量  
 ③ 若  $X \sim \chi_n^2$  则  $E[\frac{1}{X}] = \frac{1}{n-2}$ , 又  $T_1, T_2$  相互独立,  $E[\frac{1}{T_1}] = E[\frac{1}{T_1}] E[\frac{1}{T_2}] = \frac{1}{n-2} \frac{1}{T_2}$ , 则  $h_1(T) = \frac{T_1}{T_2}$  为  $\frac{a}{\sigma^2}$  充分统计量

假设检验

定义: 设有一参数分布族  $\{f(x; \theta) | \theta \in \Theta\}$ ,  $\Theta_0 \subset \Theta$ , 有命题  $H_0: \theta \in \Theta_0$  称原假设或原假设; 命题  $H_1: \theta \in \Theta_0^c$  称  $H_0$  的备择假设或对立假设  
 假设检验问题是  $H_0: \theta \in \Theta_0 \leftrightarrow H_1: \theta \in \Theta_0^c$ ; 若  $\Theta_0$  或  $\Theta_0^c$  中只有一个点, 称为简单假设, 否则称为复合假设  
 检验法称为 对正假设检验.

假设: 设  $X = (X_1, \dots, X_n)$  为  $N(a, \sigma^2)$  中抽取的简单样本,  $\sigma^2$  已知, 考虑假设检验问题  $H_0: a = a_0 \leftrightarrow H_1: a \neq a_0$  有  $\bar{x}$  为  $a$  充分统计量  
 若  $|\bar{x} - a_0| > c$ , 则拒绝  $H_0$ , 反之则接受  $H_0$ , 于是可确定一个函数  $A: |\bar{x} - a_0| > A$  时拒绝  $H_0$ ,  $|\bar{x} - a_0| \leq A$  时接受  $H_0$ .

定义: 在上述假设中, 称  $D = \{X = (X_1, \dots, X_n) | |\bar{x} - a_0| > A\}$  为  $H_0$  的拒绝域 (否定域),  $\bar{D} = \bar{x} - D$  为接受域

似然比检验

定义: 设样本  $X$  有概率密度函数  $f(x; \theta)$ ,  $\theta \in \Theta$ ,  $\Theta_0 \subset \Theta$ , 对于检验问题  $H_0: \theta \in \Theta_0 \leftrightarrow H_1: \theta \in \Theta_0^c$ , 似然比  $\lambda(x) = \frac{\sup_{\theta \in \Theta_0^c} f(x; \theta)}{\sup_{\theta \in \Theta_0} f(x; \theta)}$  称为关于检验问题  $H_0: \theta \in \Theta_0 \leftrightarrow H_1: \theta \in \Theta_0^c$  的似然比 (LRT) (统计量)  
 下面定义似然比检验  $\varphi(x) = \begin{cases} 1 & \lambda(x) > c \\ \lambda(x) < c & \text{或 } c \end{cases}$  (c 为临界值) 称为似然比检验问题  $H_0: \theta \in \Theta_0 \leftrightarrow H_1: \theta \in \Theta_0^c$  的一个似然比检验 (LRT)  
 若样本分布为连续分布, 令  $r = \int \varphi(x) dx$  ①  $\lambda(x) > c$  ②  $\lambda(x) < c$  ③  $\lambda(x) = c$  (RMB) 与  $\lambda(x) > c$  表示  $N \Rightarrow \lambda$  计算

例: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取的简单样本, 求下列检验问题的似然比  $H_0: \mu = \mu_0 \leftrightarrow H_1: \mu \neq \mu_0$

$\sigma^2$  未知  $\rightarrow$  t 分布

5.3.1 设  $\theta = (\mu, \sigma^2)$  的似然函数为  $f(x; \theta) = (2\pi\sigma^2)^{-n/2} \exp\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\}$  其中  $\Theta = \{\theta = (\mu, \sigma^2) | -\infty < \mu < \infty, \sigma^2 > 0\}$  检验  $H_0: \mu = \mu_0 \leftrightarrow H_1: \mu \neq \mu_0$   
 在  $\Theta_0$  上  $\lambda$  与  $\sigma^2$  无关 MLE 分别为  $\hat{\mu} = \bar{x}, \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \Rightarrow \sup_{\theta \in \Theta_0} f(x; \theta) = f(x; \hat{\mu}, \hat{\sigma}^2) = \frac{1}{(2\pi\hat{\sigma}^2)^{n/2}} \exp\{-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (x_i - \bar{x})^2\}$   
 在  $\Theta_0^c$  上,  $\sigma^2$  为 MLE 为  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 \Rightarrow \sup_{\theta \in \Theta_0^c} f(x; \theta) = f(x; \hat{\mu}, \hat{\sigma}^2) = \frac{1}{(2\pi\hat{\sigma}^2)^{n/2}} \exp\{-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (x_i - \hat{\mu})^2\}$   
 定义  $T(x) = \frac{\sup_{\theta \in \Theta_0^c} f(x; \theta)}{\sup_{\theta \in \Theta_0} f(x; \theta)} = \frac{1}{(2\pi\hat{\sigma}^2)^{n/2}} \exp\{-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (x_i - \hat{\mu})^2\} \frac{(2\pi\hat{\sigma}^2)^{n/2}}{\exp\{-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (x_i - \bar{x})^2\}} = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \hat{\mu})^2} = 1 + \frac{n(\bar{x} - \hat{\mu})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$   
 拒绝域  $D = \{X = (X_1, \dots, X_n) | \lambda(x) > c\} = \{X | T(x) > c\}$ , 令  $P(T(x) > c | H_0) = \alpha$   
 当  $H_0$  成立时  $T \sim F_{1, n-1}$ , 则  $c = F_{1, n-1}(\alpha)$ , 则  $\varphi(x) = \begin{cases} 1 & T(x) > F_{1, n-1}(\alpha) \\ 0 & T(x) \leq F_{1, n-1}(\alpha) \end{cases}$   
 ① 拒绝  $\Theta_0$  ② 每 MLE 乘积 sup ③ 乘  $\lambda$   $\lambda$  越大,  $H_0$  越可能成立 (即  $H_0$  越合理)  
 拒绝域:  $D = \{X | \lambda(x) > c\}$

$\sigma^2$  已知  $\rightarrow$  正

例: 问题同上, 求检验  $H_0: \mu \leq \mu_0 \leftrightarrow H_1: \mu > \mu_0$  的似然比检验  
 5.3.2  $f(x; \theta)$  与  $\Theta_0$  同上,  $\Theta_0 = \{\theta = (\mu, \sigma^2) | \mu \leq \mu_0, \sigma^2 > 0\}$   $\sup_{\theta \in \Theta_0} f(x; \theta)$  同上,  $\sup_{\theta \in \Theta_0^c} f(x; \theta) = \begin{cases} \sup_{\theta \in \Theta_0} f(x; \theta) & \bar{x} \leq \mu_0 \\ \frac{1}{(2\pi\hat{\sigma}^2)^{n/2}} \exp\{-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (x_i - \hat{\mu})^2\} & \bar{x} > \mu_0 \end{cases}$   
 由于  $\lambda$  为似然比函数, 则拒绝域为  $D = \{X = (X_1, \dots, X_n) | \lambda(x) > c\} = \{X | T > c\}$   
 有  $P(T > c | \mu = \mu_0) = \alpha$ , 当  $\mu = \mu_0$  时  $T \sim t_{n-1}$ , 则  $c = t_{n-1}(\alpha)$ ,  $\varphi(x) = \begin{cases} 1 & T > t_{n-1}(\alpha) \\ 0 & T \leq t_{n-1}(\alpha) \end{cases}$

例: 设  $X = (X_1, \dots, X_n)$  为均匀分布  $U(0, \theta)$  中抽取的简单样本, 求  $H_0: \theta \leq \theta_0 \leftrightarrow H_1: \theta > \theta_0$  的似然比检验其中  $\alpha \leq \theta_0$

f 统计量

5.3.4  $f(x; \theta) = \begin{cases} \theta^{-n} & 0 < x_i < \theta \\ 0 & \text{其他} \end{cases} \Theta = (0, \infty), \Theta_0 = (0, \theta_0]$   
 $\Theta$  的 MLE 为  $\hat{\theta} = \max\{X_1, \dots, X_n\} = X_{(n)}$ ,  $\sup_{\theta \in \Theta_0} f(x; \theta) = \begin{cases} \theta^{-n} & 0 < x_{(n)} \leq \theta_0 \\ 0 & x_{(n)} > \theta_0 \end{cases}$   
 $\Rightarrow \lambda(x) = \begin{cases} 1 & 0 < x_{(n)} \leq \theta_0 \\ 0 & x_{(n)} > \theta_0 \end{cases}$  为  $X_{(n)}$  充分统计量.  
 则  $D = \{X = (X_1, \dots, X_n) | X_{(n)} > c\}$   
 注 5.3.1 为使检验水平等于  $\alpha$ , 将集合  $G = \{x = (x_1, \dots, x_n) | \lambda(x) = 1\}$  分为两部分  $G_1 = \{x | c < x_{(n)} \leq \theta_0\}, G_2 = G - G_1$ , 则  $G_1 \cup G_2 = \{x | \lambda(x) = 1\} = \{x | x_{(n)} > c\}$  为检验问题 (5.3.12) 的拒绝域是合理的.  
 由于  $T = X_{(n)}$  的密度函数为  $g(t) = n t^{n-1} \theta^{-n} I_{(0, \theta)}(t)$ , 故由  $\int_c^{\theta_0} n t^{n-1} \theta^{-n} dt = 1 - (\frac{c}{\theta_0})^n$ , 解出  $c = \theta_0 \sqrt[n]{1 - \alpha}$ , 故拒绝域为  $D = \{X | X_{(n)} > \theta_0 \sqrt[n]{1 - \alpha}\}$ .

Bayes 检验


定义: 设两假设  $\Theta_0, \Theta_1$  的似然比函数分别为  $\alpha_0$  与  $\alpha_1$ , 则  $\frac{\alpha_1}{\alpha_0}$  称为  $H_0$  对  $H_1$  的似然比.  
 $\alpha_0 = P(H_0 | \bar{x}) = P(\Theta_0 | \bar{x}), \alpha_1 = P(\Theta_1 | \bar{x})$ . 检验法则: 若  $\frac{\alpha_1}{\alpha_0} > c$  时拒绝  $H_0$ , 否则接受  $H_0$ .

$\frac{P(\Theta_1 | \bar{x})}{P(\Theta_0 | \bar{x})}$  (似然比分布)

例: 设  $X \sim N(0, \theta)$ , 其中  $\theta = 1$  或  $\theta = 2$ , 令  $X = (X_1, \dots, X_n)$  为简单样本, 求似然比检验  $H_0: \theta = 1 \leftrightarrow H_1: \theta = 2$   
 5.6.2  $\bar{x}$  为充分统计量, 有  $\bar{x} \sim N(0, \frac{\theta}{n})$ , 设  $\theta = 1$  或  $\theta = 2$  的似然比函数分别为  $\alpha_0, \alpha_1$ , 则有  $f_0(\bar{x}) = \frac{1}{\sqrt{2\pi}} \exp\{-\frac{\bar{x}^2}{2}\}, f_1(\bar{x}) = \frac{1}{\sqrt{2\pi}} \exp\{-\frac{\bar{x}^2}{4}\}$   
 有  $\alpha_0 = \frac{f_1(\bar{x})}{f_0(\bar{x})} = \frac{1}{2}, \alpha_1 = \frac{f_0(\bar{x})}{f_1(\bar{x})} = 2$  似然比函数为  $\frac{\alpha_1}{\alpha_0} = \frac{f_1(\bar{x})}{f_0(\bar{x})} = \frac{1}{2}$

例: 设  $X$  服从正态分布  $N(0, \theta)$  中抽取的简单样本, 求似然比检验  $H_0: \theta = 1 \leftrightarrow H_1: \theta = 2$  的似然比检验  
 5.6.3  $H_0: \theta = 1 \leftrightarrow H_1: \theta = 2$

由原假设 \$H\_0: \theta = \theta\_0\$ 后分布为 \$N(\mu\_0, \sigma\_0^2)\$ 其中 \$\mu\_0 = \frac{1}{\sigma\_0^2} \times 15 + \frac{1}{\sigma\_0^2} \times 0 = 1.4286, \sigma\_0^2 = \frac{1}{\sigma\_0^2} = 0.0714 = (0.3081)^2\$  
于是后验概率 \$\alpha = P(\theta = 1 | \pi) = \pi(\frac{1-1.4286}{0.3081}) = 0.0714\$ 后验概率为 \$\frac{1}{\sigma\_0^2} = 0.0714\$ 于是拒绝 \$H\_0\$, 认为 \$\theta > 1\$  
\$\alpha = P(\theta = 1 | \pi) = 1 - \alpha = 0.9286\$



**错误与功效函数**

**定义:** ① \$H\_0\$ 对, 说成 \$H\_0\$ 错, 称为第一类错误  
② \$H\_0\$ 错, 说成 \$H\_0\$ 对, 称为第二类错误

一个功效函数 \$\beta(\theta)\$ 是在 \$\theta \in \Theta\_0\$ 上接近 0

**定义:** 设 \$\varphi(x)\$ 为 \$H\_0: \theta \in \Theta\_0 \leftrightarrow H\_1: \theta \in \Theta\_1\$ 的一个检验函数, 则 \$\beta(\theta) = E\_0[\varphi(x)] \in \Theta\_0\$ 称为 \$\varphi(x)\$ 的功效函数

**定义:** 设 \$0 \le \alpha < 1\$, 称一个功效函数为 \$\beta(\theta)\$ 的检验是水平为 \$\alpha\$ 的检验, 若 \$\sup\_{\theta \in \Theta\_0} \beta(\theta) = \alpha\$  
\$\dots\$ 真值水平为 \$\alpha\$

\$\beta(\theta)\$ 为拒绝 \$H\_0\$ 的概率, 在 \$\Theta\_0\$ 时为第一类错误概率, \$\Theta\_1\$ 时为 \$1 - \alpha\$ 为第二类错误概率

表 5.2.1 单个正态总体均值的假设检验

	\$H_0\$	\$H_1\$	检验统计量及其分布	拒绝域
\$\sigma^2\$ 已知	\$\mu = \mu_0\$	\$\mu \neq \mu_0\$	\$U = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim N(0, 1)\$	\$ U  > u_{\alpha/2}\$
	\$\mu \le \mu_0\$	\$\mu > \mu_0\$		\$U > u_\alpha\$
	\$\mu \ge \mu_0\$	\$\mu < \mu_0\$		\$U < -u_\alpha\$
\$\sigma^2\$ 未知	\$\mu = \mu_0\$	\$\mu \neq \mu_0\$	\$T = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t_{n-1}\$	\$ T  > t_{n-1}(\alpha/2)\$
	\$\mu \le \mu_0\$	\$\mu > \mu_0\$		\$T > t_{n-1}(\alpha)\$
	\$\mu \ge \mu_0\$	\$\mu < \mu_0\$		\$T < -t_{n-1}(\alpha)\$

表 5.2.3 两个正态总体均值差的假设检验

	\$H_0\$	\$H_1\$	检验统计量及其分布	拒绝域
\$\sigma_1^2, \sigma_2^2\$ 已知	\$\mu_2 - \mu_1 = \mu_0\$	\$\mu_2 - \mu_1 \neq \mu_0\$	\$U = \frac{\bar{Y} - \bar{X} - \mu_0}{\sqrt{\sigma_1^2/m + \sigma_2^2/n}} \sim N(0, 1)\$	\$ U  > u_{\alpha/2}\$
	\$\mu_2 - \mu_1 \le \mu_0\$	\$\mu_2 - \mu_1 > \mu_0\$		\$U > u_\alpha\$
	\$\mu_2 - \mu_1 \ge \mu_0\$	\$\mu_2 - \mu_1 < \mu_0\$		\$U < -u_\alpha\$
\$\sigma_1^2, \sigma_2^2\$ 未知	\$\mu_2 - \mu_1 = \mu_0\$	\$\mu_2 - \mu_1 \neq \mu_0\$	\$T_w = \frac{\bar{Y} - \bar{X} - \mu_0}{S_w \sqrt{\frac{m}{m+n} + \frac{n}{m+n}}} \sim t_{m+n-2}\$	\$ T_w  > t_{m+n-2}(\frac{\alpha}{2})\$
	\$\mu_2 - \mu_1 \le \mu_0\$	\$\mu_2 - \mu_1 > \mu_0\$		\$T_w > t_{m+n-2}(\alpha)\$
	\$\mu_2 - \mu_1 \ge \mu_0\$	\$\mu_2 - \mu_1 < \mu_0\$		\$T_w < -t_{m+n-2}(\alpha)\$

表 5.2.2 单个正态总体方差的假设检验

	\$H_0\$	\$H_1\$	检验统计量及其分布	拒绝域
\$\mu\$ 已知	\$\sigma^2 = \sigma_0^2\$	\$\sigma^2 \neq \sigma_0^2\$	\$\chi_\mu^2 = nS_\mu^2/\sigma_0^2\$	\$nS_\mu^2/\sigma_0^2 < \chi_{n-1}^2(1-\alpha/2)\$ 或 \$nS_\mu^2/\sigma_0^2 > \chi_{n-1}^2(\alpha/2)\$
	\$\sigma^2 \le \sigma_0^2\$	\$\sigma^2 > \sigma_0^2\$		\$\chi_\mu^2/\sigma_0^2 > \chi_{n-1}^2(\alpha)\$
	\$\sigma^2 \ge \sigma_0^2\$	\$\sigma^2 < \sigma_0^2\$		\$\chi_\mu^2/\sigma_0^2 < \chi_{n-1}^2(1-\alpha)\$
\$\mu\$ 未知	\$\sigma^2 = \sigma_0^2\$	\$\sigma^2 \neq \sigma_0^2\$	\$\chi^2 = \frac{(n-1)S^2}{\sigma_0^2}\$	\$(n-1)S^2/\sigma_0^2 < \chi_{n-1}^2(1-\alpha/2)\$ 或 \$(n-1)S^2/\sigma_0^2 > \chi_{n-1}^2(\alpha/2)\$
	\$\sigma^2 \le \sigma_0^2\$	\$\sigma^2 > \sigma_0^2\$		\$(n-1)S^2/\sigma_0^2 > \chi_{n-1}^2(\alpha)\$
	\$\sigma^2 \ge \sigma_0^2\$	\$\sigma^2 < \sigma_0^2\$		\$(n-1)S^2/\sigma_0^2 < \chi_{n-1}^2(1-\alpha)\$

表 5.2.4 两个正态总体方差比的假设检验

	\$H_0\$	\$H_1\$	检验统计量及其分布	拒绝域
\$\mu_1, \mu_2\$ 已知	\$\sigma_2^2 = \sigma_1^2\$	\$\sigma_2^2 \neq \sigma_1^2\$	\$F_* = \frac{S_2^2}{S_1^2} \sim F_{m-1, n-1}\$	\$F_* < F_{n-1, m-1}(1-\alpha/2)\$ 或 \$F_* > F_{n-1, m-1}(\alpha/2)\$
	\$\sigma_2^2 \le \sigma_1^2\$	\$\sigma_2^2 > \sigma_1^2\$		\$F_* > F_{n-1, m-1}(\alpha)\$
	\$\sigma_2^2 \ge \sigma_1^2\$	\$\sigma_2^2 < \sigma_1^2\$		\$F_* < F_{n-1, m-1}(1-\alpha)\$
\$\mu_1, \mu_2\$ 未知	\$\sigma_2^2 = \sigma_1^2\$	\$\sigma_2^2 \neq \sigma_1^2\$	\$F = \frac{S_2^2}{S_1^2} \sim F_{n-1, m-1}\$	\$F < F_{n-1, m-1}(1-\alpha/2)\$ 或 \$F > F_{n-1, m-1}(\alpha/2)\$
	\$\sigma_2^2 \le \sigma_1^2\$	\$\sigma_2^2 > \sigma_1^2\$		\$F > F_{n-1, m-1}(\alpha)\$
	\$\sigma_2^2 \ge \sigma_1^2\$	\$\sigma_2^2 < \sigma_1^2\$		\$F < F_{n-1, m-1}(1-\alpha)\$

**一致最优检验 (UMPT)**

**定义:** 设有检验问题 \$H\_0: \theta \in \Theta\_0 \leftrightarrow H\_1: \theta \in \Theta\_1, \alpha = 0 < \alpha < 1\$  
记 \$\pi\_\alpha\$ 为水平为 \$\alpha\$ 的检验函数, 若 \$\varphi \in \pi\_\alpha\$  
且对 \$\forall\$ 检验 \$\varphi \in \pi\_\alpha, \beta(\varphi) \le \beta(\varphi\_0), \theta \in \Theta\_1\$, 则称 \$\varphi\$ 为此问题的 UMPT

**(均匀检验) 定理 (N-P 引理):**

设样本取自独立同分布 \$f(x; \theta)\$, 考虑问题: \$H\_0: \theta = \theta\_0 \leftrightarrow H\_1: \theta = \theta\_1\$, 若一检验函数比拒绝域 \$D\$ 满足如下:  
若 \$f(x; \theta\_1) > k f(x; \theta\_0)\$ 则 \$x \in D\$ 且 \$E\_{\theta\_0}(\varphi(x)) = \alpha\$, 则此检验为此问题的 UMPT

若 \$f(x; \theta\_1) < k f(x; \theta\_0)\$ 则 \$x \in D^c\$ 且 \$E\_{\theta\_0}(\varphi(x)) = \alpha\$, 则此检验为此问题的 UMPT

**例:** 设 \$X = (X\_1, \dots, X\_n)\$ 为独立同分布 \$N(\theta, 1)\$ 中抽取的样本, \$\theta\$ 为未知参数, 检验问题 \$H\_0: \theta = 0 \leftrightarrow H\_1: \theta = \theta\_1 (\theta\_1 > 0)\$, 水平为 \$\alpha\$ 的 UMPT, 其中 \$\theta\_1\$ 与 \$\alpha\$ 给定

由 N-P 引理, 先求 \$f\_0(x)\$ 与 \$f\_1(x): f\_0(x) = (2\pi)^{-n/2} \exp(-\frac{1}{2} \sum\_{i=1}^n x\_i^2)\$  
\$f\_1(x) = (2\pi)^{-n/2} \exp(-\frac{1}{2} \sum\_{i=1}^n (x\_i - \theta\_1)^2)\$  
有拒绝域: \$D = \{x | \lambda(x) > c\} = \{x | \sqrt{n} \bar{x} > c\}\$ 因为 \$\bar{x} \sim N(\theta, 1/n)\$

由 N-P 引理有 \$E\_{\theta\_0}(\varphi(x)) = P(\sqrt{n} \bar{x} > c | \theta = 0) = \alpha \Rightarrow c = u\_{\alpha}\$ 故水平为 \$\alpha\$ 的 UMPT 检验函数为 \$\varphi(x) = \begin{cases} 1 & \bar{x} > \frac{u\_\alpha}{\sqrt{n}} \\ 0 & \bar{x} \le \frac{u\_\alpha}{\sqrt{n}} \end{cases}\$ (与 \$\theta\_1\$ 无关, 故也是 \$H\_0: \theta = 0 \leftrightarrow H\_1: \theta = \theta\_1\$ 的 UMPT)

**例:** 设 \$X = (X\_1, \dots, X\_n)\$ 为 \$B(1, p)\$ 中抽取的样本, \$p\$ 为未知参数, 检验问题 \$H\_0: p = p\_0 \leftrightarrow H\_1: p = p\_1 (p\_1 > p\_0)\$, 水平为 \$\alpha\$ 的 UMPT, 其中 \$p\_0, p\_1\$ 是给定

由 N-P 引理, 先求 \$f\_0(x)\$ 与 \$f\_1(x): f\_0(x) = \binom{n}{k} p\_0^k (1-p\_0)^{n-k}, f\_1(x) = \binom{n}{k} p\_1^k (1-p\_1)^{n-k} \Rightarrow \lambda(x) = \frac{f\_1(x)}{f\_0(x)} = \left(\frac{p\_1}{1-p\_1}\right)^k \left(\frac{1-p\_1}{1-p\_0}\right)^{n-k}\$  
由于 \$T(x)\$ 服从二项分布, 由 N-P 引理检验函数为 \$\varphi(x) = \begin{cases} 1 & T(x) > c \\ 0 & T(x) \le c \end{cases}\$  
有 \$H\_0\$ 拒绝域 \$T(x) > B(n, p\_0)\$, 给定 \$\alpha\$ 时有 \$\alpha = \sum\_{k=c}^n \binom{n}{k} p\_0^k (1-p\_0)^{n-k} \Rightarrow c = \min \{k | \sum\_{i=k}^n \binom{n}{i} p\_0^i (1-p\_0)^{n-i} \le \alpha\}\$

令 \$r = \frac{p\_1(1-p\_0)}{p\_0(1-p\_1)}\$, 则有 \$E\_{\theta\_0}(\varphi(x)) = \alpha + C \binom{n}{c} p\_0^c (1-p\_0)^{n-c} = \alpha\$ 于是有 \$\varphi(x)\$ 为水平为 \$\alpha\$ 的 UMPT (与 \$p\_1\$ 无关, 故也是 \$H\_0: p = p\_0 \leftrightarrow H\_1: p > p\_0\$ 的 UMPT)

**推论:** 设 \$r = X/T\$ 为充分统计量, \$\theta \in \Theta\$ 为未知参数, \$X = (X\_1, \dots, X\_n)\$ 为独立同分布 \$X\$ 中抽取的样本, \$T = T(X)\$ 为充分统计量, 则 \$\varphi(x)\$ 为 \$T(x)\$ 的函数 (由上述引理也可看出)

**定义:** 设 \$X\$ 服从单参数族 \$T(x; \theta), \theta \in \Theta\$, 若对 \$\forall \theta\_0, \theta\_1 \in \Theta\$,  
① \$\theta\_1 \neq \theta\_0\$ 时 \$P(f(x; \theta\_1) \neq f(x; \theta\_0)) > 0\$  
② \$\theta\_1 > \theta\_0\$ 时 \$\exists T(x) = c, \lambda = f(x; \theta\_1)/f(x; \theta\_0)\$ 只是关于 \$T\$ 且是下递增 (非降) 分布族  
则称 \$f(x; \theta)\$ 有单侧 MLR (MLR)

**定理 (Karlin-Rubin):** 考虑检验问题 \$H\_0: \theta = \theta\_0 \leftrightarrow H\_1: \theta = \theta\_1\$, 设 \$T\$ 为充分统计量, 检验函数为 \$g(T; \theta)\$, 对 \$\theta\$ 有非降 MLR, 则检验函数 \$\varphi(T) = \begin{cases} 1 & T \ge c \\ 0 & T < c \end{cases}\$ 对 \$E\_{\theta\_0}(\varphi(x)) = \alpha\$ 为一个水平为 \$\alpha\$ 的 UMPT

**推论:** 考虑检验问题 \$H\_0: \theta \ge \theta\_0 \leftrightarrow H\_1: \theta = \theta\_0\$, 设 \$T\$ 为充分统计量, 检验函数为 \$g(T; \theta)\$, 对 \$\theta\$ 有非降 MLR, 则检验函数 \$\varphi(T) = \begin{cases} 1 & T \ge c \\ 0 & T < c \end{cases}\$ 对 \$E\_{\theta\_0}(\varphi(x)) = \alpha\$ 为一个水平为 \$\alpha\$ 的 UMPT

**推论:** 样本 \$X\$ 分布族为单参数族 \$f(x; \theta) = c(\theta) h(x) \exp\{Q(\theta) T(x)\}, \theta \in \Theta\$, 其中 \$c(\theta), h(x) > 0\$, 有下列结论  
① 检验问题 \$H\_0: \theta = \theta\_0 \leftrightarrow H\_1: \theta = \theta\_1\$  
若 \$Q(\theta)\$ 为单调非降, 则 UMPT: 检验函数 \$\varphi(T) = \begin{cases} 1 & T \ge c \\ 0 & T < c \end{cases}\$ 对 \$E\_{\theta\_0}(\varphi(x)) = \alpha\$  
若 \$Q(\theta)\$ 为单调非增, 则 UMPT: 检验函数 \$\varphi(T) = \begin{cases} 1 & T \le c \\ 0 & T > c \end{cases}\$ 对 \$E\_{\theta\_0}(\varphi(x)) = \alpha\$

**例:** 设 \$X = (X\_1, \dots, X\_n)\$ 为独立同分布 \$N(\theta, 1)\$ 中抽取的样本, \$\theta\$ 为未知参数, 检验问题 \$H\_0: \theta = 0 \leftrightarrow H\_1: \theta = \theta\_1 (\theta\_1 > 0)\$, 水平为 \$\alpha\$ 的 UMPT, 其中 \$\theta\_1\$ 与 \$\alpha\$ 给定

为充分统计量, 样本函数为 \$f(x; \theta) = (2\pi)^{-n/2} e^{-\frac{1}{2} \sum\_{i=1}^n x\_i^2} = c(\theta) h(x) \exp\{Q(\theta) T(x)\}\$ 且 \$Q(\theta) = \theta\$ 为关于 \$T\$ 的增函数, 由推论 \$\varphi(x) = \begin{cases} 1 & T(x) > c \\ 0 & T(x) \le c \end{cases}\$  
由于 \$T(x) = \sum\_{i=1}^n x\_i \sim N(n\theta, n)\$, 故 \$\alpha = E\_{\theta\_0}(\varphi(x)) = P(\sum\_{i=1}^n x\_i > c) = P(\sum\_{i=1}^n x\_i - n\theta\_0 > c - n\theta\_0) = P(\sum\_{i=1}^n x\_i - n\theta\_0 > \frac{c - n\theta\_0}{n}) = \alpha\$ 故 \$\varphi(x) = \begin{cases} 1 & \sum\_{i=1}^n x\_i > \frac{c - n\theta\_0}{n} \\ 0 & \sum\_{i=1}^n x\_i \le \frac{c - n\theta\_0}{n} \end{cases}\$ 为水平为 \$\alpha\$ 的 UMPT

用充分统计量

\$H\_0: \le \Rightarrow\$ MLR 非降 (\$\uparrow\$)  
\$H\_0: \ge \Rightarrow\$ MLR 非增 (\$\downarrow\$)

注意符号

这是 \$T\$ 为充分统计量



$\varphi(u) = \int_0^u \frac{1}{\Gamma(c)} e^{-t} t^{c-1} dt$  其中  $T \sim \Gamma(c, \lambda)$  则有  $P_T(T > u) = 1 - \varphi(u)$

例: 设  $X = (X_1, \dots, X_n)$  为  $P(\lambda)$  中抽取  $n$  个独立样本,  $P$  为未知参数. 构造检验问题  $H_0: \lambda = \lambda_0 \leftrightarrow H_1: \lambda > \lambda_0$ . 设  $\alpha = 0.05$ . 求  $\lambda_0$  的置信度  $1 - \alpha$  的检验函数  $\varphi$ .

解:  $X_i \sim P(\lambda)$  的概率密度函数为  $f(x) = \frac{\lambda^x}{x!} e^{-\lambda}$ . 故  $T = \sum_{i=1}^n X_i \sim P(n\lambda)$ . 故  $T \sim \Gamma(n, \lambda)$ . 故  $P(T > c) = \sum_{k=c}^{\infty} \frac{(n\lambda)^k}{k!} e^{-n\lambda}$ . 令  $r = \frac{(n\lambda)^k}{k!} e^{-n\lambda}$ . 则有  $r_{k+1} = \frac{(n\lambda)^{k+1}}{(k+1)!} e^{-n\lambda} = \frac{n\lambda}{k+1} r_k$ . 故  $r_{k+1} < r_k$  当且仅当  $k > n\lambda - 1$ . 故  $T \sim \Gamma(n, \lambda)$  的分布函数为  $F_T(t) = 1 - \sum_{k=0}^{t-1} \frac{(n\lambda)^k}{k!} e^{-n\lambda}$ . 故  $P(T > c) = \sum_{k=c}^{\infty} \frac{(n\lambda)^k}{k!} e^{-n\lambda} = 1 - \sum_{k=0}^{c-1} \frac{(n\lambda)^k}{k!} e^{-n\lambda}$ . 故  $P(T > c) = 1 - \sum_{k=0}^{c-1} \frac{(n\lambda)^k}{k!} e^{-n\lambda}$ . 故  $P(T > c) = 1 - \sum_{k=0}^{c-1} \frac{(n\lambda)^k}{k!} e^{-n\lambda}$ .

例: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 构造检验问题  $H_0: \mu = \mu_0 \leftrightarrow H_1: \mu > \mu_0$ . 设  $\alpha = 0.05$ . 求  $\mu_0$  的置信度  $1 - \alpha$  的检验函数  $\varphi$ .

解:  $X_i \sim N(\mu, \sigma^2)$  的概率密度函数为  $f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ . 故  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\bar{X} - \mu_0 \sim N(\mu - \mu_0, \frac{\sigma^2}{n})$ . 故  $P(\bar{X} > c) = P(\bar{X} - \mu_0 > c - \mu_0) = P(\frac{\bar{X} - \mu_0}{\frac{\sigma}{\sqrt{n}}} > \frac{c - \mu_0}{\frac{\sigma}{\sqrt{n}}}) = P(Z > \frac{c - \mu_0}{\frac{\sigma}{\sqrt{n}}}) = 1 - \Phi(\frac{c - \mu_0}{\frac{\sigma}{\sqrt{n}}})$ . 故  $P(\bar{X} > c) = 1 - \Phi(\frac{c - \mu_0}{\frac{\sigma}{\sqrt{n}}})$ . 故  $P(\bar{X} > c) = 1 - \Phi(\frac{c - \mu_0}{\frac{\sigma}{\sqrt{n}}})$ .

例: 设  $X = (X_1, \dots, X_n)$  为  $U(a, b)$  中抽取  $n$  个独立样本,  $a$  为未知参数. 构造检验问题  $H_0: a = a_0 \leftrightarrow H_1: a > a_0$ . 设  $\alpha = 0.05$ . 求  $a_0$  的置信度  $1 - \alpha$  的检验函数  $\varphi$ .

解:  $X_i \sim U(a, b)$  的概率密度函数为  $f(x) = \frac{1}{b-a}$ . 故  $X_{(1)} = \min\{X_1, \dots, X_n\} \sim U(a, \frac{b-a}{n} + a)$ . 故  $X_{(1)} - a \sim U(0, \frac{b-a}{n})$ . 故  $P(X_{(1)} > c) = P(X_{(1)} - a > c - a) = P(\frac{X_{(1)} - a}{\frac{b-a}{n}} > \frac{c - a}{\frac{b-a}{n}}) = P(Z > \frac{c - a}{\frac{b-a}{n}}) = 1 - \Phi(\frac{c - a}{\frac{b-a}{n}})$ . 故  $P(X_{(1)} > c) = 1 - \Phi(\frac{c - a}{\frac{b-a}{n}})$ . 故  $P(X_{(1)} > c) = 1 - \Phi(\frac{c - a}{\frac{b-a}{n}})$ .

**(双边假设) 定理:** 设  $X = (X_1, \dots, X_n)$  服从参数为  $\theta$  的分布族, 检验函数为  $\varphi(x) = \int_0^1 I_{\{T \in C\}} dP_{\theta}$ . 其中  $P_{\theta}$  为  $\theta$  的分布函数.

**P值 定义:** 设  $P$  为一个  $1 - \alpha$  的检验函数. 对  $\forall x, 0 \leq P(x) \leq 1$ . 若  $P(x)$  可作为  $H_1$  的置信度, 则  $P(x)$  称为  $H_1$  的置信度. 若  $P(x) = \inf_{\theta \in \Theta_0} P_{\theta}(W(x) \geq P(x))$ , 则  $P(x)$  称为有效  $P$ -值.

表 5.5.1  $p$  值计算公式表

参数	$H_0$	$H_1$	检验统计量及其分布	$p$ 值公式
一样本	$\sigma^2$ 已知	$\mu \neq \mu_0$	$U = \frac{\sqrt{n}(\bar{X} - \mu_0)}{\sigma} \sim N(0, 1)$	$p = P( U  > \sqrt{n} \bar{x} - \mu_0 /\sigma   H_0)$
	同上	$\mu \leq \mu_0$	同上	$p = P(U > \sqrt{n}(\bar{x} - \mu_0)/\sigma   H_0)$
一样本	$\sigma^2$ 未知	$\mu \neq \mu_0$	$T = \frac{\sqrt{n}(\bar{X} - \mu_0)}{S} \sim t_{n-1}$	$p = P( T  > \sqrt{n} \bar{x} - \mu_0 /s   H_0)$
	同上	$\mu \leq \mu_0$	同上	$p = P(T > \sqrt{n}(\bar{x} - \mu_0)/s   H_0)$
两样本	$\sigma_1^2 = \sigma_2^2$	$\mu_1 \neq \mu_2$	$F = \frac{(\bar{X}_1 - \bar{X}_2) / \sqrt{\frac{s_p^2}{n_1} + \frac{s_p^2}{n_2}}}{\sqrt{\frac{s_p^2}{n_1} + \frac{s_p^2}{n_2}}} \sim F_{n_1-1, n_2-1}$	$p = P( F  > \frac{ \bar{x}_1 - \bar{x}_2 }{\sqrt{\frac{s_p^2}{n_1} + \frac{s_p^2}{n_2}}}   H_0)$
	未知	$\mu_1 > \mu_2$	同上	$p = P(F > \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}   H_0)$
两样本	$\mu_1 = \mu_2$	$\sigma_1^2 \neq \sigma_2^2$	$F = \frac{S_1^2/S_2^2}{1} \sim F_{n_1-1, n_2-1}$	$p = P(F > \frac{s_1^2/s_2^2}{1}   H_0)$
	未知	同上	同上	同上

**区间估计**

定义: 设有一个参数  $\theta$  的分布族  $\{f(x; \theta) : \theta \in \Theta\}$ ,  $\theta$  的取值在实数轴上. 设  $X = (X_1, \dots, X_n)$  是分布族中抽取  $n$  个独立样本,  $\bar{x}$  为  $\bar{X}$  的观测值. 为定义在样本空间  $\mathcal{X}$  上的两个统计量  $U$  和  $V$ , 则称  $[U, V]$  为  $\theta$  的一个区间估计.

定义: 设  $[U, V]$  为  $\theta$  的一个区间估计. 则  $[U, V]$  包含  $\theta$  的概率  $P_{\theta}(U \leq \theta \leq V)$  称为此区间估计的置信水平. 若在  $\Theta$  上  $\inf_{\theta \in \Theta} P_{\theta}(U \leq \theta \leq V) = 1 - \alpha$ , 则称此区间估计为置信水平  $1 - \alpha$  的区间估计.

例: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

UMP: 定 T

判出 MLE 为真

K-R 定理

**枢轴量法**

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

定义: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的置信水平  $1 - \alpha$  的区间估计.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的置信水平  $1 - \alpha$  的区间估计为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

注 4.2.1 说这是一个置信系数为 95% 的置信区间, 不是说  $\mu$  有 95% 的概率落在这个区间内 (因为  $\mu$  不是随机变量), 而是说若把这个置信区间重复使用多次, 如使用 100 次, 大约有 95 次能盖住真参数  $\mu$ , 大约有 5 次不能盖住  $\mu$ . 一旦算出具体区间, 如区间估计 [8.292%, 8.388%], 它就是一个具体确定的区间,  $\mu$  是个未知常数, 该区间是否盖住了  $\mu$ , 只有两个答案: “是” 或 “不是”, 没有概率可言, 即不能说有 95% 的机会盖住  $\mu$  了.

**Bayes 区间估计**

定义: 设  $\theta$  为  $\Theta$  上的一个参数,  $\pi(\theta)$  为  $\theta$  的先验分布,  $L(\theta; x)$  为  $\theta$  的似然函数. 设  $\pi(\theta | x)$  为  $\theta$  的后验分布. 设  $\pi(\theta | x) \geq 0$  且  $\int_{\Theta} \pi(\theta | x) d\theta = 1$ . 则称  $[\theta_1, \theta_2]$  为  $\theta$  的 Bayes 可信区间.

例: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数. 求  $\mu$  的 Bayes 可信区间.

解:  $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ . 故  $\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$ . 故  $P(-z_{\alpha/2} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq z_{\alpha/2}) = 1 - \alpha$ . 故  $P(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}) = 1 - \alpha$ . 故  $\mu$  的 Bayes 可信区间为  $[\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}]$ .

**似然函数与区间估计**

定义: 对  $\forall \theta \in \Theta$ , 设  $A(\theta)$  为  $H_0: \theta = \theta_0$  的一个水平为  $\alpha$  的检验函数. 对  $\forall x \in \mathcal{X}$ , 在  $\Theta$  上定义函数  $L(x) = \int_{\Theta} I_{\{A(\theta) \leq \alpha\}} d\pi(\theta)$ . 则  $L(x)$  称为  $\theta$  的似然函数.

例: 设  $X = (X_1, \dots, X_n)$  为  $N(\mu, \sigma^2)$  中抽取  $n$  个独立样本,  $\mu$  为未知参数.

先考虑  $\mu$  已知  $H_0: \mu = \mu_0 \leftrightarrow H_1: \mu > \mu_0$  水平为  $\alpha$  检验统计量  $T = \frac{\sqrt{n}(\bar{x} - \mu_0)}{S} \Rightarrow P_0(|\frac{\sqrt{n}(\bar{x} - \mu_0)}{S}| \leq t_{n-1}(\frac{\alpha}{2}) | H_0) = 1 - \alpha$

由于此为  $\mu = \mu_0$  时最优势, 对  $\mu$  可行, 则  $[\bar{x} - \frac{S}{\sqrt{n}} t_{n-1}(\frac{\alpha}{2}), \bar{x} + \frac{S}{\sqrt{n}} t_{n-1}(\frac{\alpha}{2})]$  为置信水平  $1 - \alpha$  置信区间

对置信下限: 若  $H_0: \mu = \mu_0 \leftrightarrow H_1: \mu > \mu_0$  检验统计  $T = \frac{\sqrt{n}(\bar{x} - \mu_0)}{S}$  即  $P(\frac{\sqrt{n}(\bar{x} - \mu_0)}{S} \leq t_{n-1}(\alpha)) = 1 - \alpha$  即  $\bar{x} - \frac{S}{\sqrt{n}} t_{n-1}(\alpha) \leq \mu_0 < \mu$  其为置信下限, 上同构造

**最短置信区间**

**定理:** 设  $f(x)$  为一个单峰对称连续函数, 若区间  $[a, b]$  满足 (i)  $\int_a^b f(x) dx = 1 - \alpha$  (ii)  $f(a) = f(b) > 0$  (iii)  $f(x)$  在  $a$  和  $b$  上且  $a \leq x \leq b$ , 则  $[a, b]$  为满足 (i) 的最短区间

**定义:** 称基于枢轴统计量  $T$  的区间为最短置信区间.


**例:** 设  $X_1, \dots, X_n \text{ i.i.d. } \sim N(\mu, \sigma^2)$ ,  $\sigma^2 > 0$  已知,  $\mu \in \mathbb{R}$  未知, 求以  $T = \frac{\sqrt{n}(\bar{x} - \mu)}{S}$  水平为  $1 - \alpha$  的最短置信区间.

有  $z = \frac{\sqrt{n}(\bar{x} - \mu)}{S}$  为枢轴量, 对  $P(a \leq z \leq b) = 1 - \alpha \Rightarrow \mu$  区间为  $(\bar{x} - b \frac{S}{\sqrt{n}}, \bar{x} - a \frac{S}{\sqrt{n}})$ ,  $t = (b - a) \frac{S}{\sqrt{n}}$

若  $f$  为单峰, 由于  $N(\mu, \sigma^2)$  为单峰, 令  $a = -t, b = t$ , 最短置信区间为  $[\bar{x} - \frac{S}{\sqrt{n}} t, \bar{x} + \frac{S}{\sqrt{n}} t]$

**例:** 设  $X_1, \dots, X_n \text{ i.i.d. } \sim U(0, \theta)$ ,  $\theta > 0$  未知, 求以  $T = \frac{\bar{x}}{S}$  水平为  $1 - \alpha$  的最短置信区间.

有  $T = \frac{\bar{x}}{S}$  为枢轴量,  $f(t) = n t^{n-1} (1 - t)^{n-1}$  即  $F_T(t) = t^n$  为单峰函数, 最短区间为  $[\frac{1}{n}, 1] \Rightarrow \frac{1}{n}$  最短区间为  $[\frac{\alpha^{1/n}}{\bar{x}_n}, \frac{1}{\bar{x}_n}]$



期末: Bayes 过程, MSE, UMVUE, UMPT, 点估计与区间估计