

CH03 点估计

更新: 2026 年 1 月 9 日

目录

1 点估计	2
1.1 点估计的含义	2
1.2 无偏性	2
1.3 有效性	3
1.4 相合性	3
2 矩估计 MM	4
2.1 矩法和矩估计	4
2.2 矩估计的无偏性和渐近无偏性	5
2.3 矩估计的相合性	5
2.4 矩估计的渐近正态性	7
3 极大似然估计 MLE	8
3.1 定义及求解	8
3.1.1 极大似然估计的定义	8
3.1.2 MLE 求解: 根据微积分中求极值	9
3.1.3 MLE 求解: 根据定义	11
3.2 极大似然估计的性质	11
3.2.1 极大似然估计的无偏性和相合性	11

3.2.2 极大似然估计与充分统计量	12
3.2.3 极大似然估计的相合渐近正态性	12
4 一致最小均方误差估计	14
5 一致最小方差无偏估计 UMVUE	15
5.1 充分完全统计量法	17
5.2 零无偏估计法	20
5.3 Cramer-Rao 不等式	22
5.3.1 单参数 C-R 不等式	22
5.3.2 C-R 不等式等号成立条件	24
5.3.3 多参数 C-R 不等式	25
5.3.4 有效估计和估计的效率	26

1 点估计

1.1 点估计的含义

定义 1.1 (点估计) 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从某个总体中抽取的样本, $\hat{g}(\mathbf{X}) = \hat{g}(X_1, \dots, X_n)$ 是样本的函数, 用 $\hat{g}(\mathbf{X})$ 作为参数的函数 $g(\theta)$ 的估计, 称为点估计 (point estimation)。

1.2 无偏性

定义 1.2 (无偏性) 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从总体 $\{f(x, \theta) : \theta \in \Theta\}$ 中抽取的样本, $g(\theta)$ 是定义在参数空间 Θ 上的已知函数。 $\hat{g}(\mathbf{X})$ 是 $g(\theta)$ 的一个估计量, 若

$$\mathbb{E}_\theta\{\hat{g}(\mathbf{X})\} = g(\theta), \quad \theta \in \Theta$$

则称 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的一个无偏估计 (unbiased estimation), 记 $\hat{g}(\mathbf{X}) = \hat{g}_n(\mathbf{X})$ 。若 $\mathbb{E}_\theta\{\hat{g}_n(\mathbf{X})\} \neq g(\theta)$ 但

$$\lim_{n \rightarrow \infty} \mathbb{E}_\theta\{\hat{g}_n(\mathbf{X})\} = g(\theta), \quad \theta \in \Theta$$

则称 $\hat{g}_n(\mathbf{X})$ 为 $g(\theta)$ 的渐近无偏估计 (asymptotically unbiased estimation)。

例 1.1 设 X_1, \dots, X_n 是取自期望为 μ , 方差为 σ^2 的总体的一个样本。显然样本均值 \bar{X} 是 μ 的无偏估计。证明: 样本方差 $S^2 = \sum_{i=1}^n (X_i - \bar{X})^2 / (n - 1)$ 是 σ^2 的无偏估计。

证明 显然

$$\begin{aligned}\mathbb{E}(S^2) &= \frac{1}{n-1} \left[\sum_{i=1}^n \mathbb{E}(X_i^2) - n\mathbb{E}(\bar{X}^2) \right] = \frac{n}{n-1} [\mathbb{E}(X_1^2) - \mathbb{E}(\bar{X}^2)] \\ &= \frac{n}{n-1} [(\sigma^2 + \mu^2) - (\sigma^2/n + \mu^2)] = \sigma^2\end{aligned}$$

故 S^2 是 σ^2 的无偏估计。

1.3 有效性

定义 1.3 (有效性) 设 $\hat{g}_1(\mathbf{X})$ 和 $\hat{g}_2(\mathbf{X})$ 为 $g(\theta)$ 的两个不同的无偏估计, 若

$$\mathbb{D}_\theta\{\hat{g}_1(\mathbf{X})\} \leq \mathbb{D}_\theta\{\hat{g}_2(\mathbf{X})\}, \quad \forall \theta \in \Theta$$

且至少存在一个 $\theta \in \Theta$ 使得不等号严格成立, 则称 $\hat{g}_1(\mathbf{X})$ 比 $\hat{g}_2(\mathbf{X})$ 有效。

1.4 相合性

定义 1.4 对 $n \in \mathbb{N}$, $\hat{g}_n(\mathbf{X})$ 是 $g(\theta)$ 的一个估计量, 若 $\hat{g}_n(\mathbf{X})$ 依概率收敛到 $g(\theta)$, 即对任意 $\theta \in \Theta$ 及 $\epsilon > 0$ 有

$$\lim_{n \rightarrow \infty} P_\theta(|\hat{g}_n(\mathbf{X}) - g(\theta)| \geq \epsilon) = 0$$

则称 $\hat{g}_n(\mathbf{X})$ 为 $g(\theta)$ 的弱相合估计 (weakly consistent estimation)。若对任意 $\theta \in \Theta$ 有

$$P_\theta \left(\lim_{n \rightarrow \infty} \hat{g}_n(\mathbf{X}) = g(\theta) \right) = 1$$

即几乎处处收敛, 则称 $\hat{g}_n(\mathbf{X})$ 为 $g(\theta)$ 的强相合估计 (strongly consistent estimation)。

注 无偏性是小样本性质; 相合性和渐近正态性是大样本性质。无偏 $\not\Rightarrow$ 相合; 有偏也可以相合 (e.g. $\bar{X} + 1/n$)。强相合 \Rightarrow 弱相合, 反之不必对。

例 1.2 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从均匀分布 $U(0, \theta)$ 中抽取的简单随机样本, θ 为未知参数。证明: $T(\mathbf{X}) = (\prod_{i=1}^n X_i)^{1/n}$ 是 $g(\theta) = \theta e^{-1}$ 的强相合估计。

证明 令 $Y_i = \log X_i$ 则 Y_i 相互独立, 且联合密度为

$$f(y, \theta) = \frac{1}{\theta} e^y \cdot \mathbb{I}_{(-\infty, \log \theta)}(y)$$

且

$$\mathbb{E}(Y_1) = \frac{1}{\theta} \int_{-\infty}^{\log \theta} y e^y dy = \frac{1}{\theta} \left[y e^y \Big|_{-\infty}^{\log \theta} - \int_{-\infty}^{\log \theta} e^y dy \right] = \log \theta - 1$$

由强大数定律可知

$$\log T(\mathbf{X}) = \frac{1}{n} \sum_{i=1}^n \log X_i = \frac{1}{n} \sum_{i=1}^n Y_i = \bar{Y} \xrightarrow{\text{a.s.}} \mathbb{E}(Y_1) = \log \theta - 1$$

因此有

$$T(\mathbf{X}) = \exp(\bar{Y}) \xrightarrow{\text{a.s.}} \exp(\log \theta - 1) = \theta e^{-1}$$

故, $T(\mathbf{X}) = (\prod_{i=1}^n X_i)^{1/n}$ 是 $g(\theta) = \theta e^{-1}$ 的强相合估计。

2 矩估计 MM

2.1 矩法和矩估计

定义 2.1 (原点矩和中心矩) 设样本 X_1, \dots, X_n 是从总体 X 中抽取的简单随机样本。

- 总体 k 阶原点矩为

$$\alpha_k = \mathbb{E}\{X^k\}$$

- 样本 k 阶原点矩为

$$a_{nk} = \frac{1}{n} \sum_{i=1}^n X_i^k$$

- 总体 k 阶中心矩为

$$\mu_k = \mathbb{E}\{[X - \mathbb{E}(X)]^k\}$$

- 样本 k 阶中心矩为

$$m_{nk} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k$$

定义 2.2 (矩估计) 设有总体分布族 $\{f(x; \theta) : \theta \in \Theta\}$, Θ 是参数空间, $g(\theta)$ 是定义在 Θ 上参数 θ 的函数, 它可以表示为总体分布的某些矩的函数, 即

$$g(\theta) = G(\alpha_1, \dots, \alpha_k; \mu_2, \dots, \mu_s)$$

设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从上述分布族中抽取的简单样本, 用样本矩代替总体矩得到

$$\hat{g}(\mathbf{X}) = G(a_{n1}, \dots, a_{nk}; m_{n2}, \dots, m_{ns})$$

则 $\hat{g}(\mathbf{X})$ 作为 $g(\theta)$ 的估计量, 称为 $g(\theta)$ 的矩估计量 (moment estimate)。

例 2.1 (Maxwell 分布) 设总体分布有概率密度

$$f(x, \theta) = 2\sqrt{\theta/\pi} \exp(-\theta x^2) \cdot \mathbb{I}(x > 0)$$

其中 θ 为未知参数。设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从这个分布中抽取的简单随机样本, 求 $g(\theta) = 1/\theta$ 的矩估计量。

解答 求总体一阶矩 α_1

$$\alpha_1 = \mathbb{E}(X) = 2\sqrt{\frac{\theta}{\pi}} \int_0^\infty x e^{-\theta x^2} dx = \frac{1}{\sqrt{\pi\theta}}$$

解得 $g(\theta) = 1/\theta = \pi\alpha_1^2$, 将 α_1 用 $a_{n1} = \bar{X}$ 代替, 有矩估计 $\hat{g}(\theta) = \hat{g}_1(\mathbf{X}) = \pi\bar{X}^2$ 。

类似地, 求总体二阶矩

$$\alpha_2 = \mathbb{E}(X^2) = 2\sqrt{\frac{\theta}{\pi}} \int_0^\infty x^2 e^{-\theta x^2} dx = \frac{1}{2\theta}$$

所以可以用 $a_{n2} = \sum_{i=1}^n X_i^2/n$ 得到另一个矩估计 $\hat{g}(\theta) = \hat{g}_2(\mathbf{X}) = 2a_{n2}$ 。

由此可知, 矩估计不唯一。但注意到

$$\mathbb{E}\{\hat{g}_1(\mathbf{X})\} = \pi \mathbb{E}\{\bar{X}^2\} = \pi(\text{Var}(\bar{X}) + (\mathbb{E}(\bar{X}))^2) = \pi \left(\frac{1}{n} \left(\frac{1}{2\theta} - \frac{1}{\pi\theta} \right) + \frac{1}{\pi\theta} \right) = \left(1 - \frac{1}{n} + \frac{\pi}{2n} \right) \frac{1}{\theta}$$

不是无偏的, 而

$$\mathbb{E}\{\hat{g}_2(\mathbf{X})\} = \frac{2}{n} \mathbb{E}\left\{\sum_{i=1}^n X_i^2\right\} = \frac{2}{n} n \frac{1}{2\theta} = \frac{1}{\theta}$$

为无偏估计。

2.2 矩估计的无偏性和渐近无偏性

命题 2.1 样本 k 阶原点矩 a_{nk} 是总体 k 阶原点矩 α_k 的无偏估计, 即

$$\mathbb{E}\{a_{nk}\} = \mathbb{E}\left\{\frac{1}{n} \sum_{i=1}^n X_i^k\right\} = \frac{1}{n} \sum_{i=1}^n \mathbb{E}\{X_i^k\} = \mathbb{E}\{X_1^k\} = \alpha_k$$

命题 2.2 对 $k \geq 2$, 样本 k 阶中心矩 m_{nk} 不是总体 k 阶中心矩 μ_k 的无偏估计, 需要调整

$$\begin{aligned}\mathbb{E}\{S^2\} &= \mathbb{E}\left\{\frac{n}{n-1} \cdot m_{n2}\right\} = \mu_2 \\ \mathbb{E}\{m_{n3}^*\} &= \mathbb{E}\left\{\frac{n^2}{(n-1)(n-2)} \cdot m_{n3}\right\} = \mu_3 \\ \mathbb{E}\{m_{n\nu}\} &= \mu_\nu + O(1/n), \quad \forall \nu \geq 4\end{aligned}$$

即矩估计一般具有渐近无偏性。

2.3 矩估计的相合性

定理 2.3 矩估计均有强相合性, 即 $a_{nk} \xrightarrow{\text{a.s.}} \alpha_k$ 以及 $m_{nk} \xrightarrow{\text{a.s.}} \mu_k$

证明 由强大数定律可知

$$a_{nk} = \frac{1}{n} \sum_{i=1}^n X_i^k \xrightarrow{\text{a.s.}} \frac{1}{n} \cdot n \mathbb{E}(X_1^k) = \alpha_k$$

下面证明 m_{nk} 的相合性。由

$$\begin{aligned}m_{nk} &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k = \frac{1}{n} \sum_{i=1}^n \sum_{r=0}^k \binom{k}{r} X_i^r (-\bar{X})^{k-r} \\ &= \frac{1}{n} \sum_{r=0}^k \binom{k}{r} (-1)^{k-r} \bar{X}^{k-r} \sum_{i=1}^n X_i^r \\ &= \sum_{r=0}^k \binom{k}{r} (-1)^{k-r} \bar{X}^{k-r} \left(\frac{1}{n} \sum_{i=1}^n X_i^r \right) \\ &= \sum_{r=0}^k \binom{k}{r} (-1)^{k-r} a_{n1}^{k-r} a_{nr}, \quad a_{n0} = 1 \\ &:= f(a_{n1}, \dots, a_{nk})\end{aligned}$$

而 $a_{nk} \xrightarrow{\text{a.s.}} \alpha_k$, 由下面的引理 2.4 可知

$$m_{nk} = f(a_{n1}, \dots, a_{nk}) \xrightarrow{\text{a.s.}} f(\alpha_1, \dots, \alpha_k)$$

又注意到

$$\begin{aligned} \mu_k &= \mathbb{E}\{[X - \mathbb{E}(X)]^k\} = \mathbb{E}\left\{\sum_{r=0}^k \binom{k}{r} X^r (-\mathbb{E}(X))^{k-r}\right\} \\ &= \sum_{r=0}^k \binom{k}{r} (-1)^{k-r} \mathbb{E}\{X^r\} \mathbb{E}(X)^{k-r} \\ &= \sum_{r=0}^k \binom{k}{r} (-1)^{k-r} \alpha_1^{k-r} \alpha_r \\ &= f(\alpha_1, \dots, \alpha_k) \end{aligned}$$

所以 $m_{nk} \xrightarrow{\text{a.s.}} \mu_k$, 命题证毕。

引理 2.4 (*) 设函数 $f(y_{n1}, \dots, y_{nk})$ 在 (c_1, \dots, c_k) 处连续, 若 $y_{ni} \xrightarrow{\text{a.s.}} c_i$ 对任意 $i = 1, \dots, k$ 成立, 则有 $f(y_{n1}, \dots, y_{nk}) \xrightarrow{\text{a.s.}} f(c_1, \dots, c_k)$ 。

证明 (*) 由 f 在 (c_1, \dots, c_k) 处连续, 故有 $\forall \epsilon > 0, \exists \delta > 0$ 使得对 $\forall (y_1, \dots, y_k)$

$$\max_{1 \leq i \leq k} |y_i - c_i| < \delta \Rightarrow |f(y_1, \dots, y_k) - f(c_1, \dots, c_k)| < \epsilon \quad (1)$$

对每个 i 和固定的 δ 构造集合

$$B_{i,\delta} = \{\omega : \exists N \in \mathbb{N}, \text{ s.t. } \forall n \geq N, |y_{ni}(\omega) - c_i| < \delta\} \subseteq \Omega$$

其中 Ω 为全集。 $B_{i,\delta}$ 代表了所有满足下面条件的 ω 构成的集合:

$$\exists N \in \mathbb{N}, \text{ s.t. } \forall n \geq N, |y_{ni}(\omega) - c_i| < \delta \Leftrightarrow \lim_{n \rightarrow \infty} y_{ni}(\omega) = c_i$$

即 $B_{i,\delta} = \{\omega : \lim_{n \rightarrow \infty} y_{ni}(\omega) = c_i\}$ 。由 $y_{ni} \xrightarrow{\text{a.s.}} c_i$ 对任意 $i = 1, \dots, k$ 成立, 有

$$P(\{\omega : \lim_{n \rightarrow \infty} y_{ni} = c_i\}) = 1, \quad i = 1, \dots, k$$

故 $P(B_{i,\delta}) = 1$ 对任意 $i = 1, \dots, k$ 。取有限交 $B_\delta = \bigcap_{i=1}^k B_{i,\delta}$, 依旧有 $P(B_\delta) = 1$ 。换言之, 对任意 $\omega \in B_\delta$ 都有 $\exists N_i(\omega) \in \mathbb{N}$ 使得 $\forall n \geq N_i(\omega)$ 时 $|y_{ni}(\omega) - c_i| < \delta$, 对 $i = 1, \dots, k$ 。于是, 我们取

$$N(\omega) = \max_{1 \leq i \leq k} N_i(\omega)$$

那么对于 $\forall n \geq N(\omega)$ 都有 $|y_{ni}(\omega) - c_i| < \delta$, 即 $\max_{1 \leq i \leq k} |y_{ni}(\omega) - c_i| < \delta$ 。由式 1 可知

$$|f(y_{n1}(\omega), \dots, y_{nk}(\omega)) - f(c_1, \dots, c_k)| < \epsilon \quad (2)$$

综上, 对 $\forall \epsilon > 0$ 都存在 $\delta > 0$, 使得对 $\forall \omega \in B_\delta$ 存在 $N(\omega)$, 对 $\forall n \geq N(\omega)$ 有式 2 成立。而 $\omega \in B_\delta$ 满足 $P(B_\delta) = 1$, 即由几乎处处收敛的定义 $\Rightarrow f(y_{n1}, \dots, y_{nk}) \xrightarrow{\text{a.s.}} f(c_1, \dots, c_k)$ 。

定理 2.5 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从总体 F 中抽取的简单随机样本, 待估函数 $g(\theta) = G(\alpha_1, \dots, \alpha_k, \mu_1, \dots, \mu_s)$, 其矩估计为 $\hat{g}_n(\mathbf{X}) = G(a_{n1}, \dots, a_{nk}, m_{n1}, \dots, m_{ns})$, 且 G 为其变元的连续函数, 则 $\hat{g}_n(\mathbf{X})$ 为 $g(\theta)$ 的强相合估计。

2.4 矩估计的渐近正态性

定义 2.3 (相合渐近正态估计) 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从总体 $\{f(x; \theta) : \theta \in \Theta\}$ 中抽取的简单随机样本。若存在与样本空间大小 n 相关的, 定义于参数空间 Θ 上的函数 $A_n(\theta)$ 和 $B_n(\theta)$, 其中 $B_n(\theta) > 0, \forall \theta \in \Theta$, 使得

$$\frac{\hat{g}_n(\mathbf{X}) - A_n(\theta)}{B_n(\theta)} \xrightarrow{\mathcal{L}} N(0, 1), \quad \text{as } n \rightarrow \infty$$

且 $\hat{g}_n(\mathbf{X})$ 是 $g(\theta)$ 的弱相合估计, 则称 $\hat{g}_n(\mathbf{X})$ 为 $g(\theta)$ 的相合渐近正态估计 (consistent asymptotic normal estimation, CAN 估计)。

定理 2.6 (δ 方法) 设映射 $\phi : D \subseteq \mathbb{R}^k \rightarrow S \subseteq \mathbb{R}^m$ 在 θ 处可微。若 $\exists r_n \rightarrow \infty$ 有

$$r_n(T_n - \theta) \xrightarrow{\mathcal{L}} T$$

则有

$$r_n(\phi(T_n) - \phi(\theta)) \xrightarrow{\mathcal{L}} \phi'(\theta) \cdot T$$

其中 $\phi'(\theta) \in \mathbb{R}^{m \times k}$ 为

$$\phi'(\theta) = \left(\frac{\partial \phi_i}{\partial \theta_j} \right)_{i=1, \dots, m; j=1, \dots, k} \in \mathbb{R}^{m \times k}$$

证明 下面给出不严格的证明: 由于 ϕ 在 θ 处可微, 由 Taylor 展开

$$\phi(T_n) \approx \phi(\theta) + \phi'(\theta)(T_n - \theta)$$

所以有 $r_n(\phi(T_n) - \phi(\theta)) = \phi'(\theta) \cdot r_n(T_n - \theta) \xrightarrow{\mathcal{L}} \phi'(\theta) \cdot T$, 命题证毕。

定理 2.7 (矩估计的近似正态性) 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从总体 $\{f(x; \theta) : \theta \in \Theta\}$ 中抽取的简单随机样本, $g(\theta)$ 是定义在 Θ 上的实函数, 它可以表示为 $g(\theta) = G(\alpha_1, \dots, \alpha_k)$, 这是因为 μ_s 可由 $(\alpha_1, \dots, \alpha_k)$ 表出。记 $\hat{g}_n(\mathbf{X}) = G(a_{n1}, \dots, a_{nk})$ 为 $g(\theta)$ 的矩估计。再设总体的 $2k$ 阶原点矩存在, 且 G 对其各变元的一阶偏导数存在连续, 令

$$\begin{aligned} \mathbf{B} &= (b_{ij})_{i,j=1, \dots, k} \in \mathbb{R}^{k \times k} \\ \mathbf{d} &= (d_1, \dots, d_k)^T \in \mathbb{R}^k \end{aligned}$$

其中 $b_{ij} = \alpha_{i+j} - \alpha_i \alpha_j$ ($i, j = 1, \dots, k$) 及 $d_i = \partial G(\alpha_1, \dots, \alpha_k) / \partial \alpha_i$ ($i = 1, \dots, k$)。

结论: $\hat{g}_n(\mathbf{X})$ 为 $g(\theta)$ 的 CAN 估计, 即 $\hat{g}_n(\theta)$ 为 $g(\theta)$ 的弱相合估计, 且

$$\sqrt{n}(\hat{g}_n(\mathbf{X}) - g(\theta)) \xrightarrow{\mathcal{L}} N(0, b^2) \quad n \rightarrow \infty$$

其中 $b^2 = \mathbf{d}^T \mathbf{B} \mathbf{d} \in \mathbb{R}$ 。

证明 由定理 2.3 可知, 矩估计都是强相合估计, 那必是弱相合估计。下面证明渐近正态性。

由 $\mathbb{E}\{a_{ni}\} = \alpha_i, \forall i = 1, \dots, k$, 所以由中心极限定理

$$\sqrt{n}(\mathbf{a} - \boldsymbol{\alpha}) \xrightarrow{\mathcal{L}} T \sim N(0, \mathbf{A})$$

其中 $\mathbf{a} = (a_{n1}, \dots, a_{nk})^T \in \mathbb{R}^k$ 而 $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_k)^T \in \mathbb{R}^k$ 。而 $\mathbf{A} = n[\text{Cov}(a_{ni}, a_{nj})]_{i,j=1,\dots,k} \in \mathbb{R}^{k \times k}$ 为协方差阵。那么由 δ 方法 2.6

$$\sqrt{n}[G(\mathbf{a}) - G(\boldsymbol{\alpha})] \xrightarrow{\mathcal{L}} [G'(\boldsymbol{\alpha})]^T \cdot T \sim N(0, [G'(\boldsymbol{\alpha})]^T \mathbf{A} [G'(\boldsymbol{\alpha})])$$

注意到 $\mathbf{a} = (a_{n1}, \dots, a_{nk})^T$ 实则是 \mathbf{X} 的函数, 故 $G(\mathbf{a}) = \hat{g}_n(\mathbf{X})$ 。而 $g(\theta) = G(\alpha_1, \dots, \alpha_k) = G(\boldsymbol{\alpha})$, 故有

$$\sqrt{n}(\hat{g}_n(\mathbf{X}) - g(\theta)) \xrightarrow{\mathcal{L}} N(0, [G'(\boldsymbol{\alpha})]^T \mathbf{A} [G'(\boldsymbol{\alpha})])$$

于是, 我们只需证 $[G'(\boldsymbol{\alpha})]^T \mathbf{A} [G'(\boldsymbol{\alpha})] = b^2$ 。首先注意到

$$G'(\boldsymbol{\alpha}) = [\partial G(\alpha_1, \dots, \alpha_k) / \partial \alpha_i]_{i=1,\dots,k}^T = (d_1, \dots, d_k)^T = \mathbf{d}$$

所以 $[G'(\boldsymbol{\alpha})]^T \mathbf{A} [G'(\boldsymbol{\alpha})] = \mathbf{d}^T \mathbf{A} \mathbf{d}$, 于是我们只需证 $\mathbf{A} = \mathbf{B}$ 即可。注意到

$$\begin{aligned} \text{Cov}(a_{ni}, a_{nj}) &= \mathbb{E}(a_{ni}a_{nj}) - \mathbb{E}(a_{ni})\mathbb{E}(a_{nj}) = \mathbb{E}\left\{\left(\frac{1}{n} \sum_{l=1}^n X_l^i\right) \cdot \left(\frac{1}{n} \sum_{l=1}^n X_l^j\right)\right\} - \alpha_i \alpha_j \\ &= \frac{1}{n^2} \mathbb{E}\left\{\sum_{l_1=1}^n \sum_{l_2=1}^n X_{l_1}^i X_{l_2}^j\right\} - \alpha_i \alpha_j \\ &= \frac{1}{n^2} \mathbb{E}\left\{\sum_{l_1=l_2=l} X_l^{i+j} + \sum_{l_1 \neq l_2} X_{l_1}^i X_{l_2}^j\right\} - \alpha_i \alpha_j \end{aligned}$$

由于当 $l_1 \neq l_2$ 时 $X_{l_1} \perp\!\!\!\perp X_{l_2}$ 故

$$\begin{aligned} \text{Cov}(a_{ni}, a_{nj}) &= \frac{1}{n^2} \left[\sum_{l_1=l_2=l}^n \mathbb{E}(X_l^{i+j}) + \sum_{l_1 \neq l_2} \mathbb{E}(X_{l_1}^i) \mathbb{E}(X_{l_2}^j) \right] - \alpha_i \alpha_j \\ &= \frac{1}{n^2} \left[\sum_{l_1=l_2=l}^n \alpha_{i+j} + \sum_{l_1 \neq l_2} \alpha_i \alpha_j \right] - \alpha_i \alpha_j \\ &= [n\alpha_{i+j} + n(n-1)\alpha_i \alpha_j]/n^2 - \alpha_i \alpha_j = [\alpha_{i+j} - \alpha_i \alpha_j]/n \end{aligned}$$

所以有 $\mathbf{A} = n[\text{Cov}(a_{ni}, a_{nj})]_{i,j=1,\dots,k} = (\alpha_{i+j} - \alpha_i \alpha_j)_{i,j=1,\dots,k} = \mathbf{B}$, 综上命题证毕。

3 极大似然估计 MLE

3.1 定义及求解

3.1.1 极大似然估计的定义

定义 3.1 (似然函数) 设 $f(\mathbf{x}; \boldsymbol{\theta}) = f(x_1, \dots, x_n; \boldsymbol{\theta})$ 为样本 $\mathbf{X} = (X_1, \dots, X_n)$ 的概率函数。当 $\boldsymbol{\theta}$ 固定时, 将 $f(\mathbf{x}; \boldsymbol{\theta})$ 看成 $\boldsymbol{\theta}$ 的函数, 称为似然函数 (likelihood function)。记为

$$L(\boldsymbol{\theta}; \mathbf{x}) = f(\mathbf{x}; \boldsymbol{\theta}), \quad \boldsymbol{\theta} \in \Theta, \mathbf{x} \in \mathcal{X}$$

其中 Θ 为参数空间, \mathcal{X} 为样本空间。称 $\log L(\boldsymbol{\theta}; \mathbf{x})$ 为对数似然函数, 记作 $l(\boldsymbol{\theta}; \mathbf{x})$ 。

定义 3.2 (极大似然估计) 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从总体 $\mathcal{F} = \{f(\mathbf{x}; \boldsymbol{\theta}) : \boldsymbol{\theta} \in \Theta\}$ 中抽取的简单随机样本, $L(\boldsymbol{\theta}; \mathbf{x})$ 是似然函数, 若存在统计量 $\hat{\boldsymbol{\theta}}^* = \hat{\boldsymbol{\theta}}^*(\mathbf{X})$, 满足条件

$$L(\hat{\boldsymbol{\theta}}^*; \mathbf{x}) = \sup_{\boldsymbol{\theta} \in \Theta} L(\boldsymbol{\theta}; \mathbf{x}), \quad \mathbf{x} \in \mathcal{X}$$

或等价地

$$l(\hat{\boldsymbol{\theta}}^*; \mathbf{x}) = \sup_{\boldsymbol{\theta} \in \Theta} l(\boldsymbol{\theta}; \mathbf{x}), \quad \mathbf{x} \in \mathcal{X}$$

则称 $\hat{\boldsymbol{\theta}}^*(\mathbf{X})$ 为 $\boldsymbol{\theta}$ 的极大似然估计 (maximum likelihood estimation, MLE)。若待估函数是 $g(\boldsymbol{\theta})$, 则定义 $g(\hat{\boldsymbol{\theta}}^*(\mathbf{X}))$ 为 $g(\boldsymbol{\theta})$ 的 MLE。

估计 MLE 可以采用 2 种方法: (1) 根据微积分中求极值; (2) 根据极大似然估计的定义。

3.1.2 MLE 求解: 根据微积分中求极值

(1) 根据微积分中求极值的方法: 设 $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)^T \in \mathbb{R}^k$ 为参数向量, 若 $l(\boldsymbol{\theta}; \mathbf{x})$ 的极大值在参数空间 Θ 的内点处 (而非边界点) 达到, 则此点必满足

$$\frac{\partial l(\boldsymbol{\theta}; \mathbf{x})}{\partial \theta_i} = 0, \quad i = 1, \dots, k$$

除此之外, 还需要验证 Hessian 阵的负定性, 即

$$\mathbf{H}(\boldsymbol{\theta}) = \left(\frac{\partial^2 l(\boldsymbol{\theta}; \mathbf{x})}{\partial \theta_i \partial \theta_j} \right)_{i,j=1, \dots, k} \in \mathbb{R}^{k \times k}$$

满足 $\mathbf{v}^T \mathbf{H} \mathbf{v} < 0$ 对任意 $\mathbf{v} \in \mathbb{R}^k$ 。

定理 3.1 (指数族的 MLE) 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从指数族中抽取的简单随机样本,

$$f(\mathbf{x}; \boldsymbol{\theta}) = C(\boldsymbol{\theta}) \exp \left\{ \sum_{i=1}^k \theta_i T_i(\mathbf{x}) \right\} h(\mathbf{x}), \quad \boldsymbol{\theta} \in \Theta$$

设 Θ_0 是 Θ 的内点集, 记 $L(\boldsymbol{\theta}; \mathbf{x})$ 是其似然函数, $l(\boldsymbol{\theta}; \mathbf{x})$ 是对应的对数似然函数。要求 (T_1, \dots, T_k) 以概率为 1 线性独立。则有若

$$\frac{\partial l(\boldsymbol{\theta}; \mathbf{x})}{\partial \theta_i} = 0, \quad i = 1, \dots, k$$

在 Θ_0 中有解 $\hat{\boldsymbol{\theta}}$, 则其必唯一, 且为 $\boldsymbol{\theta}$ 的 MLE。

证明 先证明解的唯一性, 然后证明其为最优的。

(1) 唯一性 若设 $\boldsymbol{\theta}_0$ 和 $\boldsymbol{\theta}_1$ 为满足 $l'(\boldsymbol{\theta}) = 0$ 的 2 个不同的解。由之前证明的性质: 指数族参数空间的内点集 Θ_0 必是凸集, 有

$$\hat{\boldsymbol{\theta}} \triangleq t \cdot \boldsymbol{\theta}_0 + (1 - t) \cdot \boldsymbol{\theta}_1 \in \Theta_0, \quad t \in [0, 1]$$

记 $l(t\boldsymbol{\theta}_0 + (1-t)\boldsymbol{\theta}_1) = H(t)$, 注意到 $l'(\boldsymbol{\theta}_0) = 0$, $l'(\boldsymbol{\theta}_1) = 0$, 以及 $H'(t) = (\boldsymbol{\theta}_0 - \boldsymbol{\theta}_1)^T l'(\hat{\boldsymbol{\theta}})$ 。其中 $l'(\hat{\boldsymbol{\theta}}) \in \mathbb{R}^k$ 。于是有 $H'(0) = H'(1) = 0$ 。由 Rolle 定理 3.2, 存在 $t_0 \in (0, 1)$ 使得 $H''(t_0) = 0$ 。

而 $H''(t) = (\boldsymbol{\theta}_0 - \boldsymbol{\theta}_1)^T l''(\hat{\boldsymbol{\theta}})(\boldsymbol{\theta}_0 - \boldsymbol{\theta}_1)$, 其中 $l''(\hat{\boldsymbol{\theta}}) \in \mathbb{R}^{k \times k}$ 。由之前关于指数族性质的证明可知

$$l''(\hat{\boldsymbol{\theta}}) = n \left[\frac{\partial^2 \log L(\boldsymbol{\theta})}{\partial \theta_i \partial \theta_j} \right]_{i,j=1,\dots,k} = n \left[\frac{\partial \log C(\boldsymbol{\theta})}{\partial \theta_i \theta_j} \right]_{i,j=1,\dots,k} = n [-\text{Cov}(T_i, T_j)]_{i,j=1,\dots,k} \in \mathbb{R}^{k \times k}$$

所以容易得到 $\forall t$ 都有 $l''(\hat{\boldsymbol{\theta}}) = l''(t\boldsymbol{\theta}_0 + (1-t)\boldsymbol{\theta}_1) = n [-\text{Cov}(T_i, T_j)]_{i,j=1,\dots,k} \prec \mathbf{0}$ 。这是因为协方差阵总是半正定, 而这里有 (T_1, \dots, T_k) 以概率为 1 线性独立。

于是若 $\boldsymbol{\theta}_0 \neq \boldsymbol{\theta}_1$, 则 $H''(t) < 0, \forall t \in (0, 1)$ 。与存在 $t_0 \in (0, 1)$ 使得 $H''(t_0) = 0$ 矛盾。故 $\boldsymbol{\theta}_0 = \boldsymbol{\theta}_1$, 唯一性证毕。

(2) MLE 设 $\boldsymbol{\theta}_0$ 为唯一解, 使得 $l'(\boldsymbol{\theta}_0) = 0$ 。那么对于 $\forall \tilde{\boldsymbol{\theta}} \in \Theta$, 沿用 (1) 对 $H(t) = l(t\boldsymbol{\theta}_0 + (1-t)\tilde{\boldsymbol{\theta}})$ 的定义。

有 $H'(1) = 0$ (注 $H'(0)$ 的性质不知), 以及 $H''(t) < 0$ 对 $t \in (0, 1)$ 。于是 H' 在 $(0, 1)$ 单调递减, 那么 $H'(t) > H'(1) = 0, \forall t \in (0, 1)$ 。于是 H 在 $(0, 1)$ 单调递增, 那么 $H(1) > H(0)$, 即 $l(\boldsymbol{\theta}_0) > l(\tilde{\boldsymbol{\theta}})$ 对任意 $\tilde{\boldsymbol{\theta}} \in \Theta$, 即唯一解 $\boldsymbol{\theta}_0$ 是 MLE。

注 对于随机向量 $\mathbf{X} = (X_1, \dots, X_k) \in \mathbb{R}^k$, 记 $\boldsymbol{\mu} = \mathbb{E}\{\mathbf{X}\}$, 则有 $\text{Cov}(\mathbf{X}) \succeq 0$ 即协方差阵半正定。

证明 对任意向量 $\mathbf{v} \in \mathbb{R}^k$, 有

$$\begin{aligned} \mathbf{v}^T \text{Cov}(\mathbf{X}) \mathbf{v} &= \mathbf{v}^T \mathbb{E}\{(\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})^T\} \mathbf{v} = \mathbb{E}\{\mathbf{v}^T (\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})^T \mathbf{v}\} \\ &= \mathbb{E}\{[(\mathbf{X} - \boldsymbol{\mu})^T \mathbf{v}]^T [(\mathbf{X} - \boldsymbol{\mu})^T \mathbf{v}]\} := \mathbb{E}\{\mathbf{y}^T \mathbf{y}\} \geq 0 \end{aligned}$$

其中 $\mathbf{y} = (\mathbf{X} - \boldsymbol{\mu})^T \mathbf{v}$ 。所以 $\text{Cov}(\mathbf{X}) \succeq 0$ 。

定理 3.2 (Rolle 定理) 令 f 在闭区间 $[a, b]$ 上连续, 在开区间 (a, b) 上可导。假如 $f(a) = f(b)$, 则在开区间 (a, b) 中存在至少一个点 c , 满足 $f'(c) = 0$ 。

证明 由于 f 在 $[a, b]$ 上连续, 根据闭区间上连续函数的最值定理, f 在 $[a, b]$ 上必能取得最大值 M 和最小值 m 。

如果 $M = m$, 则 f 在 $[a, b]$ 上是常数函数, 于是在 (a, b) 内任意一点 c 都有 $f'(c) = 0$, 结论成立。

如果 $M > m$, 因为 $f(a) = f(b)$, 所以最大值 M 和最小值 m 中至少有一个在 (a, b) 内某点 c 取得。不妨设 $f(c) = M$, 其中 $c \in (a, b)$ 。我们来证 $f'(c) = 0$ 。由于 f 在 c 处可导, 考虑导数定义:

$$f'(c) = \lim_{h \rightarrow 0} \frac{f(c+h) - f(c)}{h}.$$

当 $h > 0$ 时, $\frac{f(c+h) - f(c)}{h} \leq 0$ (因为 $f(c)$ 是最大值), 所以

$$f'(c) = \lim_{h \rightarrow 0^+} \frac{f(c+h) - f(c)}{h} \leq 0.$$

当 $h < 0$ 时, $\frac{f(c+h)-f(c)}{h} \geq 0$, 所以

$$f'(c) = \lim_{h \rightarrow 0^-} \frac{f(c+h) - f(c)}{h} \geq 0.$$

因此 $f'(c) \geq 0$ 且 $f'(c) \leq 0$, 只能 $f'(c) = 0$ 。如果最小值 m 在 (a, b) 内取到, 同理可证该点处导数为零。综上, 总存在 $c \in (a, b)$ 使得 $f'(c) = 0$ 。

使用微积分中求极值的方法, 其流程相对比较简单, 只需求出似然函数, 以最大化似然函数为目标, 对参数进行优化即可。

3.1.3 MLE 求解: 根据定义

当似然函数不可微, 甚至不连续时, 只能通过极大似然的定义进行求解。

例 3.1 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从均匀分布族 $\{U(\theta, \theta + 1) : \theta \in \mathbb{R}\}$ 中抽取的简单随机样本, 求 θ 的 MLE。

解答 给定样本 \mathbf{x} 时的似然函数为

$$L(\theta; \mathbf{x}) = \mathbb{I}(\theta < x_{(1)} \leq x_{(n)} < \theta + 1) = \mathbb{I}(x_{(n)} - 1 < \theta < x_{(1)})$$

似然函数最大只能为 1, 需要满足 $x_{(n)} - 1 < \theta < x_{(1)}$, 所以有 $\hat{\theta} = t(X_{(n)} - 1) + (1 - t)X_{(1)}$ 其中 $t \in (0, 1)$ 均为 θ 的 MLE。所以此时满足极大似然估计的 $\hat{\theta}$ 有无穷多个。

3.2 极大似然估计的性质

3.2.1 极大似然估计的无偏性和相合性

极大似然估计可能无偏, 也可能有偏。极大似然估计可能相合, 也可能不相合。下面给出极大似然估计强相合性的结果。

定理 3.3 (*) 设 $\mathbf{X}_n = (X_1, \dots, X_n)$ 是从分布族 $\mathcal{F} = \{f(x; \theta) : \theta \in \Theta\}$ 中抽取的简单随机样本, 其中 Θ 为任一开区间, 若有下面的条件成立:

1. 分布族 \mathcal{F} 是可识别的, 即对 Θ 中任意的 $\theta_1 \neq \theta_2$, 都有 $f(x; \theta_1) \neq f(x; \theta_2)$ 。
2. 对任意 $x \in \mathcal{X}$, $\theta \in \Theta$ 有 $f(x; \theta) > 0$, 且一阶偏导数 $\partial f(x; \theta) / \partial \theta$ 存在、连续。那么在任一 P_θ 下, 以概率为 1 当 n 充分大时, 对数似然函数方程:

$$\sum_{i=1}^n \frac{\partial f(x_i; \theta)}{\partial \theta} = 0$$

存在一个解。

那么解 $\hat{\theta}_n$ 是强相合的, 即 $\hat{\theta}_n \xrightarrow{\text{a.s.}} \theta$, $n \rightarrow \infty$ 。

3.2.2 极大似然估计与充分统计量

定理 3.4 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从总体 $\{f(x; \theta) : \theta \in \Theta\}$ 中抽取的简单随机样本, $T(\mathbf{X})$ 是参数 θ 的充分统计量。若 θ 的极大似然估计 $\hat{\theta}_{\text{MLE}}$ 存在, 则它必为充分统计量 T 的函数, 即 $\hat{\theta}_{\text{MLE}} = \hat{\theta}_{\text{MLE}}(T(\mathbf{X}))$ 。

证明 由因子分解定理可知样本 \mathbf{X} 的概率函数, 即似然函数可表示为

$$L(\theta, \mathbf{x}) = \prod_{i=1}^n f(x_i; \theta) = g(T(\mathbf{x}), \theta)h(\mathbf{x})$$

若 θ 的 MLE 存在, 记为 $\hat{\theta}_{\text{MLE}}$, 则它满足

$$L(\hat{\theta}_{\text{MLE}}, \mathbf{x}) = \sup_{\theta \in \Theta} L(\theta, \mathbf{x}) \Rightarrow g(T(\mathbf{x}), \hat{\theta}_{\text{MLE}}) = \sup_{\theta \in \Theta} g(T(\mathbf{x}), \theta)$$

上式中 $g(T(\mathbf{x}), \hat{\theta}_{\text{MLE}}) = \sup_{\theta \in \Theta} g(T(\mathbf{x}), \theta)$ 左右式都只与 $T(\mathbf{X})$ 和 $\hat{\theta}_{\text{MLE}}$ 有关, 故 $\hat{\theta}_{\text{MLE}}$ 可以写成 $T(\mathbf{X})$ 的函数。

3.2.3 极大似然估计的相合渐近正态性

只考虑参数 θ 为一维的情形。设 $\mathcal{F} = \{f(x; \theta) : \theta \in \Theta\}$ 为一概率函数族, $\Theta = (a, b)$ 为 \mathbb{R} 上开区间, \mathcal{F} 是可识别的。设 $f(x; \theta)$ 满足下列条件:

- (1) 对一切 $\theta \in \Theta$, $x \in \mathcal{X}$ 有 $f(x; \theta) > 0$, 且 $f(x; \theta)$ 有直到 2 阶的连续偏导数。
- (2) 对任一给定的 θ_0 , 存在它的一个邻域 $U(\theta_0)$ 和可能依赖于该 θ_0 的函数 $g(x) > 0$ 和 $G(x) > 0$, 对该邻域内的任一 θ , 有

$$\left| \frac{\partial f(x; \theta)}{\partial \theta} \right| < g(x) \quad \left| \frac{\partial^2 f(x; \theta)}{\partial \theta^2} \right| < g(x) \quad \left| \frac{\partial^2 f(x; \theta)}{\partial \theta^2} - \frac{\partial^2 f(x; \theta_0)}{\partial \theta^2} \right| \leq G(x)(\theta - \theta_0)^2$$

且

$$\int_{-\infty}^{\infty} g(x) dx < \infty \quad \mathbb{E}_{\theta_0}[G(x)] = \int_{-\infty}^{\infty} G(x) f(x; \theta_0) dx < \infty$$

- (3) 对一切 $\theta \in \Theta$, 有

$$0 < I(\theta) \triangleq \mathbb{E} \left[\left(\frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 \right] = \int_{-\infty}^{\infty} \left(\frac{\partial \log f(X; \theta)}{\partial \theta} \right)^2 f(x; \theta) dx < \infty$$

这里 $I(\theta)$ 称为 Fisher 信息量。

定理 3.5 (MLE 的渐近正态性定理) 设 $\mathbf{X} = (X_1, \dots, X_n)$ 为自分布族 \mathcal{F} 中抽取的简单随机样本, 若上述条件 (1) (2) (3) 满足, 则对任何 $\theta_0 \in \Theta$, 对数似然方程

$$\sum_{i=1}^n \frac{\partial f(x_i; \theta)}{\partial \theta} = 0$$

有一根 $\hat{\theta}_n = \hat{\theta}(\mathbf{X})$, 则其满足

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{\mathcal{L}} N(0, I^{-1}(\theta_0)), \quad \theta \in \Theta$$

且 $\hat{\theta}_n$ 为 θ_0 的弱相合估计。

证明 由 Taylor 展开, 我们有

$$l'(\hat{\theta}_n) = l'(\theta_0) + l''(\theta_0)(\hat{\theta}_n - \theta_0) + \frac{l'''(\tilde{\theta})}{2}(\hat{\theta}_n - \theta_0)^2$$

其中 $l(\theta)$ 为对数似然函数, $\tilde{\theta}$ 位于 $\hat{\theta}_n$ 和 θ_0 之间。而由 MLE 的定义, 有 $l'(\hat{\theta}_n) = 0$, 于是将上式变形

$$\sqrt{n}(\hat{\theta}_n - \theta_0) = \frac{\frac{1}{\sqrt{n}}l'(\theta_0)}{-\frac{1}{n}l''(\theta) - \frac{1}{2n}l'''(\tilde{\theta})(\hat{\theta}_n - \theta_0)} \quad (3)$$

(A) 注意到 $l(\theta) = \sum_{i=1}^n \log f(x_i; \theta)$, 而

$$\mathbb{E}\left(\frac{\partial \log f(x; \theta)}{\partial \theta}\right) = \mathbb{E}\left(\frac{f'(x; \theta)}{f(x; \theta)}\right) = \int \frac{f'(x; \theta)}{f(x; \theta)} \cdot f(x; \theta) dx = \int f'(x; \theta) dx$$

而 $\frac{\partial}{\partial \theta} \int f(x; \theta) dx = \frac{\partial}{\partial \theta} 1 = 0$, 故上式 $\int f'(x; \theta) dx = 0$ 。容易推出 $\mathbb{E}[l'(\theta) = 0]$ 。而 $l(\theta)$ 又是求和形式, 故有中心极限定理知

$$\sqrt{n}\left(\frac{l'(\theta_0)}{n} - \mathbb{E}\left[\frac{l'(\theta_0)}{n}\right]\right) \xrightarrow{\mathcal{L}} N(0, \text{Var}(l'(\theta_0)))$$

注意到 $\mathbb{E}\left[\frac{l'(\theta_0)}{n}\right] = 0$, 有

$$\text{Var}(l'(\theta_0)) = \mathbb{E}\left[\left(\frac{\partial \log f(x; \theta_0)}{\partial \theta}\right)^2\right] = I(\theta_0)$$

综上就有

$$\frac{1}{\sqrt{n}}l'(\theta_0) \xrightarrow{\mathcal{L}} N(0, I(\theta_0)) \quad (4)$$

(B) 先证明下面的结论

$$-\mathbb{E}\left[\frac{\partial^2 \log f(x; \theta)}{\partial \theta^2}\right] = \mathbb{E}\left[\left(\frac{\partial \log f(x; \theta)}{\partial \theta}\right)^2\right]$$

由密度函数的性质 $\int f(x; \theta) dx = 1$ 可以得到 $\int f'(x; \theta) dx = \int f''(x; \theta) dx = 0$, 于是有

$$\begin{aligned} -\mathbb{E}\left[\frac{\partial^2 \log f(x; \theta)}{\partial \theta^2}\right] &= -\int \left(\frac{f''(x; \theta)f(x; \theta) - [f'(x; \theta)]^2}{[f(x; \theta)]^2}\right) \cdot f(x; \theta) dx \\ &= 0 + \int \left(\frac{f'(x; \theta)}{f(x; \theta)}\right)^2 \cdot f(x; \theta) dx \\ &= \int \left(\frac{\partial \log f(x; \theta)}{\partial \theta}\right)^2 \cdot f(x; \theta) dx \\ &= \mathbb{E}\left[\left(\frac{\partial \log f(x; \theta)}{\partial \theta}\right)^2\right] \end{aligned}$$

结论得证。又注意到 $l''(\theta_0)$ 是求和的形式, 于是根据大数定律有

$$\frac{1}{n}l''(\theta_0) = \frac{1}{n} \sum_{i=1}^n \frac{\partial^2 \log f(x; \theta)}{\partial \theta^2} \xrightarrow{P} \mathbb{E}\left[\frac{\partial^2 \log f(x; \theta)}{\partial \theta^2}\right] = -I(\theta_0) \quad (5)$$

(C) 由条件 (2) 和大数定律

$$\frac{1}{n}l'''(\tilde{\theta}) \xrightarrow{P} \mathbb{E}(l'''(\tilde{\theta})) < \infty \quad (6)$$

有限, 不妨设 $\frac{1}{n}l'''(\tilde{\theta}) \rightarrow M$ 。

综合 (A)(B)(C), 结合条件 (1)(2)(3) 均满足, 容易得到 $\hat{\theta}_n$ 是相合的, 故 $\hat{\theta}_n - \theta_0 \rightarrow 0, n \rightarrow \infty$ 。于是将式 4 式 5 和式 6 代入式 3 中, 结合 Slutsky 定理

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{\mathcal{L}} \frac{N(0, I(\theta_0))}{I(\theta_0) - M \cdot (\hat{\theta}_n - \theta_0)} \rightarrow N(0, I^{-1}(\theta_0))$$

当 $n \rightarrow \infty$ 时, 命题证毕。

例 3.2 设 X_1, \dots, X_n 是取自正态总体 $N(\mu, \sigma^2)$ 的样本, 则 μ, σ^2 的 MLE 分别具有渐近正态性。

证明 显然正态分布满足条件 (1)(2)(3), 所以可以使用定理 3.5 证明:

(1) 在 σ^2 已知时, μ 的 MLE 为 $\hat{\mu} = \bar{X}$, 由于

$$f(x; \mu) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(x - \mu)^2}{2\sigma^2}\right\}$$

故有对数概率密度为

$$\log f(x; \mu) = -\frac{1}{2} \log 2\pi - \frac{1}{2} \log \sigma^2 - \frac{(x - \mu)^2}{2\sigma^2}$$

所以

$$I_1(\mu, \sigma^2) = \mathbb{E}\left[\left(\frac{\partial \log f(x; \mu)}{\partial \mu}\right)^2\right] = \mathbb{E}\left[\frac{(x - \mu)^2}{\sigma^4}\right] = \frac{1}{\sigma^2}$$

故由定理 3.5 可知,

$$\sqrt{n}(\hat{\mu} - \mu) \xrightarrow{\mathcal{L}} N(0, \sigma^2)$$

即 $\hat{\mu}$ 的渐近分布为 $N(\mu, \sigma^2/n)$ 。

(2) 在 μ 已知时, σ^2 的 MLE 为 $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$, 而

$$I_2(\mu, \sigma^2) = \mathbb{E}\left[\left(\frac{\partial \log f(x; \sigma^2)}{\partial \sigma^2}\right)^2\right] = \mathbb{E}\left[\left(-\frac{1}{2\sigma^2} + \frac{(x - \mu)^2}{2\sigma^4}\right)^2\right] = \frac{1}{2\sigma^4}$$

故由定理 3.5 可知,

$$\sqrt{n}(\hat{\sigma}^2 - \sigma^2) \xrightarrow{\mathcal{L}} N(0, 2\sigma^4)$$

即 $\hat{\sigma}^2$ 的渐近分布为 $N(\sigma^2, 2\sigma^4/n)$ 。

4 一致最小均方误差估计

设一参数分布族 $\mathcal{F} = \{f(x; \theta) : \theta \in \Theta\}$, 其中 Θ 为参数空间。设 $g(\theta)$ 为定义在 Θ 上的实函数, $\mathbf{X} = (X_1, \dots, X_n)$ 为自 \mathcal{F} 的简单样本, $\hat{g}(\mathbf{X}) = \hat{g}(X_1, \dots, X_n)$ 为 $g(\theta)$ 的一个估计量。

定义 4.1(均方误差) 设 $\hat{g}(\mathbf{X})$ 为 $g(\theta)$ 的估计量, 则称 $\mathbb{E}_\theta[\hat{g}(\mathbf{X}) - g(\theta)]^2$ 为 $\hat{g}(\mathbf{X})$ 的均方误差 (Mean Square Error, MSE)。

定义 4.2(一致最小均方误差估计) 设 $\hat{g}_1(\mathbf{X})$ 和 $\hat{g}_2(\mathbf{X})$ 为 $g(\theta)$ 的两个不同的估计量, 若

$$\mathbb{E}_\theta[\hat{g}_1(\mathbf{X}) - g(\theta)]^2 \leq \mathbb{E}_\theta[\hat{g}_2(\mathbf{X}) - g(\theta)]^2 \quad \forall \theta \in \Theta$$

且不等号至少对某个 $\theta \in \Theta$ 成立, 则称在 MSE 准则下 $\hat{g}_1(\mathbf{X})$ 优于 $\hat{g}_2(\mathbf{X})$ 。

若存在 $\hat{g}^*(\mathbf{X})$, 使得对 $g(\theta)$ 的任一估计量 $\hat{g}(\mathbf{X})$, 都有

$$\mathbb{E}_\theta[\hat{g}^*(\mathbf{X}) - g(\theta)]^2 \leq \mathbb{E}_\theta[\hat{g}(\mathbf{X}) - g(\theta)]^2 \quad \forall \theta \in \Theta$$

则称 $\hat{g}^*(\mathbf{X})$ 为 $g(\theta)$ 的一致最小均方误差估计。

可惜的是, 一致最小均方误差估计常不存在。从直观上想, 在一个大的估计类中, 一致最优估计量不存在, 把估计类缩小, 就有可能存在一致最优的估计量。我们可以把估计类缩小为无偏估计类来考虑。

存在这样的情形, 参数 $g(\theta)$ 的无偏估计不存在, 如下例:

例 4.1 设样本 X 服从二项分布 $B(n, p)$ 时, 其中 n 已知而 p 未知。令 $g(p) = 1/p$, 则参数 $g(p)$ 的无偏估计不存在。

证明 用反证法: 若不然, $g(p)$ 有无偏估计 $\hat{g}(X)$ 。由于 X 只取 $0, 1, \dots, n$ 这些值, 而假设 $\hat{g}(X)$ 无偏, 应有

$$\mathbb{E}_p[\hat{g}(X)] = \sum_{x=0}^n \hat{g}(x) \binom{n}{x} p^x (1-p)^{n-x} = \frac{1}{p}$$

即多项式方程

$$\sum_{x=0}^n \hat{g}(x) \binom{n}{x} p^{x+1} (1-p)^{n-x} - 1 = 0$$

对任意 $p \in (0, 1)$ 成立。但这是至多 $n+1$ 阶多项式, 根据多项式的性质, 至多有 $n+1$ 个根, 显然无法满足任意 $p \in (0, 1)$ 均成立, 矛盾。

5 一致最小方差无偏估计 UMVUE

定义 5.1(可估) 参数的无偏估计若存在, 则称此参数为可估参数; 若参数函数的无偏估计存在, 则称此函数为可估函数 (estimable function)。因此可估函数的无偏估计类是非空的。

定义 5.2(一致最小方差无偏估计 UMVUE) 设 $\mathcal{F} = \{f(x; \theta) : \theta \in \Theta\}$ 是一个参数分布族, 其中 Θ 为参数空间, $g(\theta)$ 为定义在 Θ 上的可估函数。设 $\hat{g}^*(\mathbf{X}) = \hat{g}^*(X_1, \dots, X_n)$ 为 $g(\theta)$ 的一个无偏估计, 若对 $g(\theta)$ 的任一无偏估计 $\hat{g}(\mathbf{X}) = \hat{g}(X_1, \dots, X_n)$, 都有

$$\text{Var}_\theta[\hat{g}^*(\mathbf{X})] \leq \text{Var}_\theta[\hat{g}(\mathbf{X})] \quad \theta \in \Theta$$

则称 $\hat{g}^*(\mathbf{X})$ 是 $g(\theta)$ 的一致最小方差无偏估计 (uniformly minimum variance unbiased estimation, UMVUE)。

对给定参数分布族, 寻找可估函数的 UMVUE 有如下的几种方法:

1. 零无偏估计法
2. 充分完全统计量法
3. Cramer-Rao 不等式

下列的定理提供了一个改进无偏估计的方法。

定理 5.1 (Rao-Blackwell 定理) 设 $T = T(\mathbf{X})$ 是一个充分统计量, 而 $\hat{g}(\mathbf{X})$ 是 $g(\theta)$ 的一个无偏估计, 则

$$h(T) = \mathbb{E}[\hat{g}(\mathbf{X})|T]$$

是 $g(\theta)$ 的一个无偏估计, 并且

$$\text{Var}_\theta[h(T)] \leq \text{Var}_\theta[\hat{g}(\mathbf{X})] \quad \theta \in \Theta$$

其中等号当且仅当 $P_\theta(\hat{g}(\mathbf{X}) = h(T)) = 1$, 即 $\hat{g}(\mathbf{X}) = h(T)$ a.s. P_θ 成立。

这个定理提供了一个改进无偏估计的方法: 即一个无偏估计 $\hat{g}(\mathbf{X})$ 对充分统计量 $T(\mathbf{X})$ 的条件期望 $\mathbb{E}[\hat{g}(\mathbf{X})|T]$ 将能导出一个新的无偏估计, 且它的方差不会超过原估计量 $\hat{g}(\mathbf{X})$ 的方差。

这个定理还表明 **UMVUE** 一定是充分统计量的函数, 否则可以通过充分统计量, 按定理 5.1 的方法构造出一个具有更小方差的无偏估计。

证明 (A) 先证 $h(T)$ 的无偏性。由 $T(\mathbf{X})$ 为充分统计量, 按定义, 给定 T 时 \mathbf{X} 的条件分布与 θ 无关。因此 $h(T) = \mathbb{E}(\hat{g}(\mathbf{X})|T)$ 与 θ 无关。所以 $h(T)$ 是统计量, 可作为 $g(\theta)$ 的估计量, 且有

$$\mathbb{E}_\theta[h(T)] = \mathbb{E}_\theta[\mathbb{E}(\hat{g}(\mathbf{X})|T)] = \mathbb{E}_\theta(\hat{g}(\mathbf{X})) = g(\theta)$$

(重期望公式) 因此 $h(T)$ 是 $g(\theta)$ 的无偏估计。

(B) 再证不等式关系成立, 即 $h(T)$ 的方差不增。注意到

$$\begin{aligned} \text{Var}_\theta(\hat{g}(\mathbf{X})) &= \mathbb{E}_\theta\{\hat{g}(\mathbf{X}) - g(\theta)\}^2 = \mathbb{E}_\theta\{[\hat{g}(\mathbf{X}) - h(T)] + [h(T) - g(\theta)]\}^2 \\ &= \mathbb{E}_\theta[\hat{g}(\mathbf{X}) - h(T)]^2 + \text{Var}_\theta[h(T)] + 2\mathbb{E}_\theta\{[\hat{g}(\mathbf{X}) - h(T)][h(T) - g(\theta)]\} \end{aligned}$$

由 $h(T) = \mathbb{E}(\hat{g}(\mathbf{X})|T)$, 同样由重期望公式

$$\begin{aligned} \mathbb{E}_\theta\{[\hat{g}(\mathbf{X}) - h(T)][h(T) - g(\theta)]\} &= \mathbb{E}_\theta\{\mathbb{E}_\theta[(\hat{g}(\mathbf{X}) - h(T))(h(T) - g(\theta))|T]\} \\ &= \mathbb{E}_\theta\{[h(T) - g(\theta)]\mathbb{E}_\theta[(\hat{g}(\mathbf{X}) - h(T))|T]\} \\ &= \mathbb{E}_\theta\{[h(T) - g(\theta)][\mathbb{E}(\hat{g}(\mathbf{X})|T) - h(T)]\} = 0 \end{aligned}$$

代回原式可得

$$\text{Var}_\theta(\hat{g}(\mathbf{X})) = \mathbb{E}_\theta[\hat{g}(\mathbf{X}) - h(T)]^2 + \text{Var}_\theta[h(T)] \geq \text{Var}_\theta[h(T)] \quad \square$$

(C) 最后证明等号成立条件。等号成立等价于

$$\mathbb{E}_\theta[\hat{g}(\mathbf{X}) - h(T)]^2 = 0$$

即 $\hat{g}(\mathbf{X}) = h(T)$ a.s. P_θ 成立。

例 5.1 对于 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} B(1, p)$ 的简单随机样本, X_1 是 p 的无偏估计。设 $T = \sum_{i=1}^n X_i$, 利用统计量 T 构造具有比 X_1 估计更小方差的无偏估计。

解答 使用定理 5.1 定理, 容易构造 $h(T)$

$$\begin{aligned} h(t) &= \mathbb{E}(X_1|T=t) = 1 \cdot P(X_1=1|T=t) + 0 \cdot P(X_1=0|T=t) \\ &= \frac{P(X_1=1, T=t)}{P(T=t)} = \frac{P(X_1=1, X_2+\dots+X_n=t)}{P(T=t)} \\ &= \frac{p \cdot \binom{n-1}{t-1} p^{t-1} (1-p)^{n-t}}{\binom{n}{t} p^t (1-p)^{n-t}} = \frac{t}{n} = \bar{x} \end{aligned}$$

显然 $\text{Var}(h(T)) = \text{Var}(\bar{X}) = p(1-p)/p < p(1-p) = \text{Var}(X_1)$, 当 $n > 1$ 时 \bar{X} 的方差更小, 且为无偏估计。

5.1 充分完全统计量法

定理 5.2 (Lehmann-Scheffe 定理) 设 $X \sim \{f(x; \theta) : \theta \in \Theta\}$, Θ 为参数空间。令 $\mathbf{X} = (X_1, \dots, X_n)$ 为从总体 X 中抽取的简单样本, $g(\theta)$ 为定义于参数空间 Θ 上的可估函数, $T(\mathbf{X})$ 为一个充分完全统计量。若 $h[T(\mathbf{X})]$ 为 $g(\theta)$ 的一个无偏估计, 则 $h[T(\mathbf{X})]$ 是 $g(\theta)$ 的唯一的 UMVUE。唯一性是指: 设 \hat{g} 和 \hat{g}_1 是 $g(\theta)$ 的两个估计量, 若 $P_\theta(\hat{g} = \hat{g}_1) = 1$, 对一切 $\theta \in \Theta$, 则视 \hat{g} 和 \hat{g}_1 是同一个估计量。

证明 先证唯一性。设 $\hat{g}[T(\mathbf{X})], \hat{g}_1[T(\mathbf{X})]$ 为 $g(\theta)$ 的无偏估计, 令 $\delta[T(\mathbf{X})] = \hat{g}[T(\mathbf{X})] - \hat{g}_1[T(\mathbf{X})]$, 则

$$\mathbb{E}_\theta\{\delta[T(\mathbf{X})]\} = \mathbb{E}_\theta\{\hat{g}[T(\mathbf{X})]\} - \mathbb{E}_\theta\{\hat{g}_1[T(\mathbf{X})]\} = 0 \quad \theta \in \Theta$$

由于 $T(\mathbf{X})$ 为完全统计量, 故 $\delta[T(\mathbf{X})] = 0$ a.s. P_θ 成立, 即 $\hat{g}[T(\mathbf{X})] = \hat{g}_1[T(\mathbf{X})]$ a.s. P_θ 成立, 唯一性证毕。

再证一致最小方差性。设 $\varphi(\mathbf{X})$ 为 $g(\theta)$ 的任一无偏估计, 记 $h[T(\mathbf{X})] = \mathbb{E}[\varphi(\mathbf{X})|T]$ 。由 $T(\mathbf{X})$ 为充分统计量, 故 $h[T(\mathbf{X})]$ 与 θ 无关, 即为统计量。由定理 5.1 可知, $h[T(\mathbf{X})]$ 也是 $g(\theta)$ 的无偏估计, 且

$$\text{Var}_\theta\{h[T(\mathbf{X})]\} \leq \text{Var}_\theta\{\varphi(\mathbf{X})\} \quad \theta \in \Theta$$

即 $h[T(\mathbf{X})]$ 是最小方差的无偏估计, 即 UMVUE, 证毕。

例 5.2 设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} B(1, p)$, 故容易得 $T = T(\mathbf{X}) = \sum_{i=1}^n X_i$ 服从二项分布 $B(n, p)$, 且 T 为充分完全统计量。求 $g(p) = p(1-p)$ 的 UMVUE。

解答 (方法一) 令 $\varphi(\mathbf{X}) = \mathbb{I}(X_1=1, X_2=0)$, 则有 $\mathbb{E}[\varphi(\mathbf{X})] = P(X_1=1, X_2=0) = p(1-p)$, 即 $\varphi(\mathbf{X})$ 为 $g(p)$ 的无偏估计。又注意到 $T = \sum_{i=1}^n X_i \sim B(n, p)$ 和 $\sum_{i=3}^n X_i \sim B(n-2, p)$, 于是

可以由定理 5.1 定理改进 $g(p)$ 的无偏估计

$$\begin{aligned} h(t) &= \mathbb{E}[\varphi(\mathbf{X})|T=t] = P(X_1, X_2 = 0|T=t) \\ &= \frac{P(X_1 = 1, X_2 = 0, \sum_{i=3}^n X_i = t-1)}{P(T=t)} = \binom{n-2}{t-1} / \binom{n}{t} = \frac{t(n-t)}{n(n-1)} \end{aligned}$$

仍然是 $g(p)$ 的无偏估计。而 $h(T)$ 又是充分完全统计量 $T(\mathbf{X})$ 的函数，由定理 5.2 可知 $h(T)$ 是 $g(p)$ 的 UMVUE。

解答 (方法二) 设 $\delta(T)$ 为 $g(p) = p(1-p)$ 的一个无偏估计，从而由 $T \sim B(n, p)$ 可以得到

$$\mathbb{E}[\delta(T)] = \sum_{t=0}^n \binom{n}{t} \delta(t) p^t (1-p)^{n-t} = p(1-p) \quad p \in (0, 1)$$

令 $\rho = p(1-p)$ ，故有 $p = \rho/(1+\rho)$ ，代入有

$$\sum_{t=0}^n \binom{n}{t} \delta(t) \rho^t = \rho(1+\rho)^{n-2} \quad \rho \in (0, \infty)$$

使用二项式公式展开 $(1+\rho)^{n-2}$ 可以得到

$$\sum_{t=0}^n \binom{n}{t} \delta(t) \rho^t = \sum_{t=1}^{n-1} \binom{n-2}{t-1} \rho^t \quad \rho \in (0, \infty)$$

由多项式的性质，比较系数有

$$\delta(t) = \begin{cases} 0 & t = 0, n \\ \binom{n-2}{t-1} / \binom{n}{t} & t = 1, \dots, n-1 \end{cases}$$

既有

$$\delta(T) = \frac{T(n-T)}{n(n-1)}$$

为 $g(p) = p(1-p)$ 的无偏估计，而其为充分统计量的函数，由定理 5.2 可知 $\delta(T)$ 为 UMVUE。

例 5.3 设 $X = (X_1, \dots, X_n)$ 为从 Poisson 分布 $\text{Poi}(\lambda)$ 中抽取的简单样本，求

1. $g_1(\lambda) = \lambda^r, r \in \mathbb{N}^+$ 的 UMVUE。
2. $g_2(\lambda) = P_\lambda(X_1 = x)$ 的 UMVUE。

解答 (1) 容易得到 $T = T(\mathbf{X}) = \sum_{i=1}^n X_i \sim \text{Poi}(n\lambda)$ 为充分完全统计量。设 $h_1(T)$ 为 $g_1(\lambda) = \lambda^r$ 的无偏估计，故有

$$\mathbb{E}[h_1(T)] = \sum_{t=0}^{\infty} h_1(t) \frac{e^{-n\lambda} (n\lambda)^t}{t!} = \lambda^r$$

将 $e^{n\lambda}$ 作 Taylor 展开有

$$\lambda^r e^{n\lambda} = \sum_{l=r}^{\infty} \frac{n^{t-r} \lambda^t}{(t-r)!} = \sum_{t=0}^{\infty} h_1(t) \frac{n^t \lambda^t}{t!}$$

比较系数可得

$$h_1(T) = \frac{T(T-1)\cdots(T-r+1)}{n^r}$$

且其为 $g_1(\lambda) = \lambda^r$ 的无偏估计, 又为充分完全统计量的函数, 由定理 5.2 可知 $h_1(T)$ 为 $g_1(\lambda)$ 的 UMVUE。

解答 (2) 设 $\varphi(X_1) = \mathbb{I}(X_1 = x)$, 则 $\mathbb{E}\lambda[\varphi(X_1)] = P_\lambda(X_1 = x)$, 因此 $\varphi(X_1)$ 为 $g_2(\lambda)$ 的无偏估计。又注意到 $T = \sum_{i=1}^n X_i \sim \text{Poi}(n\lambda)$ 和 $\sum_{i=2}^n X_i \sim \text{Poi}((n-1)\lambda)$, 故有

$$\begin{aligned} h_2(t) &= \mathbb{E}[\varphi(X_1)|T=t] = P(X_1 = x|T=t) = \frac{P(X_1 = x, T=t)}{P(T=t)} \\ &= \frac{P(X_1 = x)P(\sum_{i=2}^n X_i = t-x)}{P(\sum_{i=1}^n X_i = t)} = \frac{(n-1)^{t-x}t!}{n^t(t-x)!x!} \end{aligned}$$

由定理 5.1 可知, $h_2(T)$ 是 $g_2(\lambda)$ 的无偏估计。又因为其为充分完全统计量 T 的函数, 由定理 5.2 可知 $h_2(T)$ 是 $g_2(\lambda)$ 的 UMVUE。

例 5.4 设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从正态分布 $N(a, \sigma^2)$ 中抽取的简单随机样本, 记 $\boldsymbol{\theta} = (a, \sigma^2)$ 。求

1. $g_1(\boldsymbol{\theta}) = \sigma^r$, $r > 0$ 的 UMVUE。
2. $g_2(\boldsymbol{\theta}) = a/\sigma^2$ 的 UMVUE。

解答 (1) 容易得 $\mathbf{T} = (T_1, T_2) = (\bar{X}, \sum_{i=1}^n (X_i - \bar{X})^2)$ 是 $\boldsymbol{\theta}$ 的充分完全统计量。又注意到 $T_2/\sigma^2 \sim \chi_{n-1}^2$, 于是

$$\begin{aligned} \mathbb{E}\left(\frac{T_2}{\sigma^2}\right)^{r/2} &= \int_0^\infty y^{\frac{r}{2}} \cdot \frac{1}{2^{\frac{n-1}{2}} \Gamma((n-1)/2)} y^{\frac{n-1}{2}-1} e^{-\frac{y}{2}} dy \\ &= 2^{\frac{r}{2}} \Gamma\left(\frac{n+r-1}{2}\right) / \Gamma\left(\frac{n-1}{2}\right) \triangleq \frac{1}{K_{n-1,r}} \end{aligned}$$

因此构造

$$h_1(\mathbf{T}) = K_{n-1,r} \cdot T_2^{r/2} = T_2^{r/2} \cdot \Gamma\left(\frac{n-1}{2}\right) / \left[2^{\frac{r}{2}} \Gamma\left(\frac{n+r-1}{2}\right)\right]$$

为 σ^r 的无偏估计, 又为充分完全统计量 \mathbf{T} 的函数, 故由定理 5.2 可知 $h_1(\mathbf{T})$ 是 $g_1(\boldsymbol{\theta})$ 的 UMVUE。

解答 (2) 断言: 若 $Y \sim \chi_n^2$ 则 $\mathbb{E}(1/Y) = 1/(n-2)$ 。注意到 $T_1 \sim N(a, \sigma^2/n)$, $T_2/\sigma^2 \sim \chi_{n-1}^2$ 且 $T_1 \perp T_2$, 故

$$\mathbb{E}\left(\frac{T_1}{T_2}\right) = \mathbb{E}(T_1) \cdot \mathbb{E}\left(\frac{1}{T_2}\right) = \frac{a}{(n-3)\sigma^2}$$

于是构造 $h_2(\mathbf{T}) = (n-3)T_1/T_2$ 即为 $g_2(\boldsymbol{\theta})$ 的无偏估计, 而又是充分完全统计量 \mathbf{T} 的函数。故由定理 5.2 可知 $h_2(\mathbf{T})$ 是 $g_2(\boldsymbol{\theta})$ 的 UMVUE。

5.2 零无偏估计法

即使使用充分完全统计量构造无偏估计，配合 Lehmann-Scheffe 定理 5.2 寻找 UMVUE 十分常见。但仍然存在难以构造的情况，例如无法找到充分完全统计量，构造无偏估计困难等。下面的例子就展示了这种情况。

例 5.5 设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} U(0, \theta)$ ，但 $\theta > 1$ ，求 θ 的 UMVUE。

解答 这里我们证明： $T = X_{(n)}$ 不是 θ 的完全统计量。假设 $\varphi(T)$ 满足 $\mathbb{E}[\varphi(T)] = 0$ ，即

$$\begin{aligned}\mathbb{E}[\varphi(T)] &= \int_0^\theta \varphi(t) \cdot \frac{nt^{n-1}}{\theta^n} dt = 0 \\ \Rightarrow \int_0^1 \varphi(t) t^{n-1} dt + \int_1^\theta \varphi(t) t^{n-1} dt &= 0\end{aligned}$$

可以构造 $\varphi(T) = [(n+1)T - n] \cdot \mathbb{I}_{(0,1)}(T)$ 就有

$$\int_0^1 \varphi(t) t^{n-1} dt + \int_1^\theta \varphi(t) t^{n-1} dt = t^{n+1} - t^n \Big|_0^1 + \int_1^\theta 0 \cdot t^{n-1} dt \equiv 0$$

于是 $\varphi(T)$ 满足 $\mathbb{E}[\varphi(T)] = 0$ ，但 $\varphi(T) \neq 0$ a.s. P ，即 $T = X_{(n)}$ 是不完全的。此时无法继续使用定理 5.2 构造 UMVUE。

于是，这里引入求解 UMVUE 的另一个方法，即零无偏估计法。

定理 5.3 (零无偏估计法) 设 $\hat{g}(\mathbf{X})$ 是 $g(\theta)$ 的一个无偏估计， $\text{Var}_\theta(\hat{g}(\mathbf{X})) < \infty$ ， $\forall \theta \in \Theta$ 。令

$$\mathcal{U} = \{U(\mathbf{X}) : \mathbb{E}_\theta[U(\mathbf{X})] = 0, \forall \theta \in \Theta\}$$

为零无偏估计的集合。则 $\hat{g}(\mathbf{X})$ 是 $g(\theta)$ 的 UMVUE 的充分必要条件为

$$\text{Cov}_\theta[\hat{g}(\mathbf{X}), U(\mathbf{X})] = \mathbb{E}_\theta[\hat{g}(\mathbf{X}) \cdot U(\mathbf{X})] = 0 \quad \forall \theta \in \Theta, \forall U(\mathbf{X}) \in \mathcal{U}$$

证明 (A) 先证明 \Leftarrow ，即已知 $\text{Cov}[\hat{g}(\mathbf{X}), U(\mathbf{X})] = 0, \forall U(\mathbf{X}) \in \mathcal{U}$ 。设 $\hat{g}_1(\mathbf{X})$ 为 $g(\theta)$ 的任一无偏估计，且 $\hat{g}_1(\mathbf{X}) \neq \hat{g}(\mathbf{X})$ ，记 $U(\mathbf{X}) = \hat{g}_1(\mathbf{X}) - \hat{g}(\mathbf{X})$ ，则有 $\mathbb{E}[U(\mathbf{X})] = 0$ ，即 $U(\mathbf{X}) \in \mathcal{U}$ 。那么根据条件有

$$\begin{aligned}\text{Var}[\hat{g}_1(\mathbf{X})] &= \text{Var}[\hat{g}(\mathbf{X}) + U(\mathbf{X})] = \text{Var}[\hat{g}(\mathbf{X})] + \text{Var}[U(\mathbf{X})] + 2\text{Cov}[\hat{g}(\mathbf{X}), U(\mathbf{X})] \\ &= \text{Var}[\hat{g}(\mathbf{X})] + \text{Var}[U(\mathbf{X})] \geq \text{Var}[\hat{g}(\mathbf{X})]\end{aligned}$$

故 $\hat{g}(\mathbf{X})$ 方差最小，且无偏，为 UMVUE。

(B) 再证明 \Rightarrow ，即已知 $\hat{g}(\mathbf{X})$ 为 UMVUE。若对任意 $U(\mathbf{X}) \in \mathcal{U}$ ，即 $\mathbb{E}[U(\mathbf{X})] = 0$ ，那么有 $\hat{g}(\mathbf{X}) + \lambda \cdot U(\mathbf{X})$ 仍然无偏，对任意 λ 成立。又因为 $\hat{g}(\mathbf{X})$ 为 UMVUE，有

$$\begin{aligned}\text{Var}[\hat{g}(\mathbf{X})] &\leq \text{Var}[\hat{g}(\mathbf{X}) + \lambda \cdot U(\mathbf{X})] \\ \Rightarrow \text{Var}[\hat{g}(\mathbf{X})] &\leq \text{Var}[\hat{g}(\mathbf{X})] + \lambda^2 \text{Var}[U(\mathbf{X})] + 2\lambda \text{Cov}[\hat{g}(\mathbf{X}), U(\mathbf{X})] \\ \Rightarrow \text{Var}[U(\mathbf{X})] \cdot \lambda^2 + 2\text{Cov}[\hat{g}(\mathbf{X}), U(\mathbf{X})] \cdot \lambda &\geq 0 \quad \forall \lambda\end{aligned}$$

注意到这是关于 λ 的二次函数，且有根 $\lambda_1 = 0$ 使得函数取 0。则另一个根必须为 0，使得函数恒正，即

$$\lambda_2 = -\frac{2\text{Cov}[\hat{g}(\mathbf{X}), U(\mathbf{X})]}{\text{Var}[U(\mathbf{X})]} = 0$$

故有 $\text{Cov}[\hat{g}(\mathbf{X}), U(\mathbf{X})] = 0$ ，命题证毕。

推论 1 设 $T = T(\mathbf{X})$ 为 θ 的充分统计量，设 $h(T) = h[T(\mathbf{X})]$ 是 $g(\theta)$ 的一个方差有限的无偏估计。令 \mathcal{U}_T 是基于充分统计量 T 的零无偏估计的集合

$$\mathcal{U}_T = \{U(T) : \mathbb{E}_\theta[U(T)] = 0, \forall \theta \in \Theta\}$$

则 $h(T)$ 是 $g(\theta)$ 的 UMVUE 的充分必要条件为

$$\text{Cov}_\theta[h(T), \delta(T)] = \mathbb{E}_\theta[h(T) \cdot \delta(T)] = 0 \quad \forall \theta \in \Theta, \forall \delta(T) \in \mathcal{U}_T$$

例 5.6 设 $X_1, \dots, X_n \stackrel{\text{i.i.d.}}{\sim} U(0, \theta)$ ，但 $\theta > 1$ ，求 θ 的 UMVUE。

解答 在例 5.5 中，无法根据充分完全统计量法求 θ 的 UMVUE，于是，这里使用零无偏估计法求 θ 的 UMVUE。

注意到 $T = X_{(n)}$ 是一个充分统计量。设 $U(T)$ 满足 $\mathbb{E}_\theta[U(T)] = 0$ 对任意的 $\theta > 1$ 成立。根据例 5.5 的结论，有

$$\int_0^1 U(t)t^{n-1} dt + \int_1^\theta U(t)t^{n-1} dt = 0$$

对 θ 求导有 $U(\theta) = 0$ 任意的 $\theta > 1$ 成立。

下面考虑：构造 $\hat{g}(T)$ 使得 $\mathbb{E}_\theta[\hat{g}(T), U(T)] = 0$ ，即

$$\int_0^1 \hat{g}(t)U(t)t^{n-1} dt + \int_0^1 \hat{g}(t) \cdot 0 \cdot t^{n-1} dt = 0 \quad \Rightarrow \quad \int_0^1 \hat{g}(t)U(t)t^{n-1} dt = 0$$

不妨构造

$$\hat{g}(T) = C \cdot \mathbb{I}_{(0,1)}(T) + Bt \cdot \mathbb{I}_{(1,\theta)}(T)$$

其中 C, B 待定。于是易得 $\int_0^1 \hat{g}(t)U(t)t^{n-1} dt = 0$ ，即 $\mathbb{E}_\theta[\hat{g}(T), U(T)] = 0$ 。继续，寻找 C, B 使得 $\mathbb{E}_\theta[\hat{g}(T)] = \theta$ ，即

$$\begin{aligned} \int_0^1 Cn \frac{t^{n-1}}{\theta^n} dt + \int_i^\theta Btn \frac{t^{n-1}}{\theta^n} dt &= \theta \\ \Rightarrow \frac{C}{\theta^n} + \frac{n}{n+1} B \left(\theta - \frac{1}{\theta^n} \right) &= \theta \end{aligned}$$

取 $B = \frac{n+1}{n}$, $C = 1$ 即成立。故根据定理 5.3 的推论 1 可知， $\hat{g}(T) = \mathbb{I}_{(0,1)}(X_{(n)}) + \frac{n+1}{n} X_{(n)} \cdot \mathbb{I}_{(1,\theta)}(X_{(n)})$ 是 $g(\theta) = \theta$ 的 UMVUE。

5.3 Cramer-Rao 不等式

Cramer-Rao 不等式是判别一个无偏估计量是否为 UMVUE 的主要方法之一。这一方法的思想如下：设 \mathcal{U}_g 是 $g(\theta)$ 的一切无偏估计构成的类。 \mathcal{U}_g 中估计量的方差有一个下界，如果 $g(\theta)$ 的一个无偏估计量 \hat{g} 的方差达到这个下界，则 \hat{g} 就是 $g(\theta)$ 的一个 UMVUE。

定义 5.3 (C-R 正则分布族, C-R 正则条件) 若单参数概率函数族 $\mathcal{F} = \{f(x; \theta) : \theta \in \Theta\}$ 满足下列条件：

- (1) 参数空间 Θ 是直线上的某个开区间
- (2) 对任何 $x \in \mathcal{X}$ 及 $\theta \in \Theta$, $f(x; \theta) > 0$, 即分布族具有共同支撑
- (3) 对任何 $x \in \mathcal{X}$ 及 $\theta \in \Theta$, $\partial f(x; \theta)/\partial \theta$ 存在
- (4) 概率函数 $f(x; \theta)$ 的积分与微分运算可交换, 即

$$\frac{\partial}{\partial \theta} \int f(x; \theta) dx = \int \frac{\partial}{\partial \theta} f(x; \theta) dx$$

若 $f(x; \theta)$ 为离散随机变量的概率分布, 上述条件改为无穷级数和微分运算可交换

- (5) 下列数学期望存在, 且

$$0 < I(\theta) = \mathbb{E}_\theta \left[\frac{\partial \log f(X; \theta)}{\partial \theta} \right]^2 < \infty$$

则称该分布族为 **C-R 正则分布族**, 其中 (1)-(5) 称为 **C-R 正则条件**。 $I(\theta)$ 称为该分布的 **Fisher 信息量** (或称为 Fisher 信息函数)。

5.3.1 单参数 C-R 不等式

定理 5.4 (Cramer-Rao 不等式) 设 $\mathcal{F} = \{f(x; \theta) : \theta \in \Theta\}$ 是 C-R 正则分布族, $g(\theta)$ 是定义于参数空间 Θ 上的可微函数。设 $\mathbf{X} = (X_1, \dots, X_n)$ 是由总体 $f(x; \theta) \in \mathcal{F}$ 中抽取的简单随机样本, $\hat{g}(\mathbf{X})$ 是 $g(\theta)$ 的任一无偏估计, 且满足下列条件

- (6) 积分

$$\int \cdots \int \hat{g}(\mathbf{x}) f(\mathbf{x}; \theta) d\mathbf{x}$$

可在积分号下对 θ 求导数 (此处 $d\mathbf{x} = dx_1 \cdots dx_n$)

则有不等式成立

$$\text{Var}_\theta[\hat{g}(\mathbf{X})] \geq \frac{[g'(\theta)]^2}{nI(\theta)} \quad \forall \theta \in \Theta$$

称为 **Cramer-Rao 不等式**, 简称 **C-R 不等式**。

证明 记 $S(\mathbf{x}; \theta) = \partial \log f_n(\mathbf{x}; \theta) / \partial \theta$, 其中 $f_n(\mathbf{x}; \theta)$ 为联合密度函数。容易得

$$\begin{aligned}\mathbb{E}[S(\mathbf{x}; \theta)] &= \mathbb{E}\left[\frac{\partial \log f_n(\mathbf{x}; \theta)}{\partial \theta}\right] = \mathbb{E}\left[\sum_{i=1}^n \frac{\partial \log f(x_i; \theta)}{\partial \theta}\right] = \mathbb{E}\left[\sum_{i=1}^n \frac{\partial f(x_i; \theta)}{\partial \theta} \frac{1}{f(x_i; \theta)}\right] \\ &= \sum_{i=1}^n \int_{\mathcal{X}} \frac{\partial f(x_i; \theta)}{\partial \theta} \cdot \frac{1}{f(x_i; \theta)} \cdot f(x_i; \theta) dx_i = \sum_{i=1}^n \int_{\mathcal{X}} \frac{\partial f(x_i; \theta)}{\partial \theta} dx_i \\ &= \sum_{i=1}^n \frac{\partial}{\partial \theta} \int_{\mathcal{X}} f(x_i; \theta) dx_i = \sum_{i=1}^n \frac{\partial}{\partial \theta} 1 = 0\end{aligned}$$

又注意到

$$\begin{aligned}\text{Var}_{\theta}[S(\mathbf{x}; \theta)] &= \text{Var}_{\theta}\left[\sum_{i=1}^n \frac{\partial \log f(x_i; \theta)}{\partial \theta}\right] = \sum_{i=1}^n \text{Var}_{\theta}\left[\frac{\partial \log f(x_i; \theta)}{\partial \theta}\right] \\ &= \sum_{i=1}^n \mathbb{E}_{\theta}\left[\frac{\partial \log f(x_i; \theta)}{\partial \theta}\right]^2 = nI(\theta)\end{aligned}$$

而

$$\begin{aligned}\text{Cov}_{\theta}[\hat{g}(\mathbf{X}), S(\mathbf{X}; \theta)] &= \mathbb{E}_{\theta}[\hat{g}(\mathbf{X}) \cdot S(\mathbf{X}; \theta)] = \int_{\mathcal{X}} \hat{g}(\mathbf{x}) \left[\frac{1}{f_n(\mathbf{x}; \theta)} \frac{\partial f_n(\mathbf{x}, \theta)}{\partial \theta}\right] f_n(\mathbf{x}; \theta) d\mathbf{x} \\ &= \int_{\mathcal{X}} \hat{g}(\mathbf{x}) \frac{\partial f_n(\mathbf{x}, \theta)}{\partial \theta} d\mathbf{x} = \frac{\partial}{\partial \theta} \int_{\mathcal{X}} \hat{g}(\mathbf{x}) f_n(\mathbf{x}, \theta) d\mathbf{x} \\ &= \frac{\partial}{\partial \theta} \mathbb{E}_{\theta}[\hat{g}(\mathbf{X})] = \frac{\partial}{\partial \theta} g(\theta) = g'(\theta)\end{aligned}$$

然后, 由 Cauchy-Schwarz 不等式

$$\text{Var}_{\theta}[\hat{g}(\mathbf{X})] \cdot \text{Var}_{\theta}[S(\mathbf{X}; \theta)] \geq \{\text{Cov}_{\theta}[\hat{g}(\mathbf{X}), S(\mathbf{X}; \theta)]\}^2$$

代入既有

$$\begin{aligned}\text{Var}_{\theta}[\hat{g}(\mathbf{X})] \cdot [nI(\theta)] &\geq [g'(\theta)]^2 \\ \Rightarrow \text{Var}_{\theta}[\hat{g}(\mathbf{X})] &\geq \frac{[g'(\theta)]^2}{nI(\theta)} \quad \forall \theta \in \Theta\end{aligned}$$

□

等号成立条件, 由 Cauchy-Schwarz 不等式决定。

注 若 $g(\theta)$ 的无偏估计 $\hat{g}(\mathbf{X})$ 的方差 $\text{Var}_{\theta}[\hat{g}(\mathbf{X})]$ 达到了 C-R 不等式的下界, 则一定是 UMVUE; 但未达到下界, 不能说明不是 UMVUE。

例 5.7 设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从 $N(a, \sigma^2)$ 中抽取的简单随机样本, 其中 σ^2 已知。证明 \bar{X} 为 a 的 UMVUE。

证明 由正态分布为指数族, C-R 正则条件满足。 $N(a, \sigma^2)$ 的密度函数为

$$f(x; a) = (2\pi\sigma^2)^{-1/2} \exp\left\{-\frac{(x-a)^2}{2\sigma^2}\right\}$$

从而, Fisher 信息量为

$$I(a) = \mathbb{E}_a\left[\frac{\partial \log f(X; a)}{\partial a}\right]^2 = \mathbb{E}_a\left[\frac{(X-a)^2}{\sigma^4}\right] = \frac{\text{Var}_a(X)}{\sigma^4} = \frac{1}{\sigma^2}$$

故 C-R 下界为 $1/[nI(a)] = \sigma^2/n$ 。而 $\text{Var}(\bar{X}) = \sigma^2/n$ 达到 C-R 下界, 且为无偏估计。由定理 5.4 可知, \bar{X} 是 a 的 UMVUE。

5.3.2 C-R 不等式等号成立条件

定理 5.5 (C-R 不等式等号成立条件) C-R 不等式等号成立条件, 需考虑特定的分布族:

1. 若样本分布族为 非指数族, 则其关于 $g(\theta)$ 的无偏估计之方差 一定不能达到 C-R 下界 ($\forall \theta \in \Theta$)。
2. 若样本分布族为 指数族, 则其关于 $g(\theta)$ 的无偏估计之方差 不一定能到达 C-R 下界 ($\forall \theta \in \Theta$)。

只有当样本分布族为指数族 $f(\mathbf{x}; \theta) = C(\theta) \exp\{Q(\theta)T(\mathbf{x})\}h(\mathbf{x})$, 且

$$\hat{g}(\mathbf{X}) = aT(\mathbf{X}) + b \quad \mathbb{E}_\theta[\hat{g}(\mathbf{X})] = \mathbb{E}_\theta[aT(\mathbf{X}) + b] = g(\theta)$$

此时方可取到 C-R 下界, 其中 $a \neq 0$ 和 b 是与 θ 无关的常数。

评论 非指数族 \Rightarrow 一定不能达到 C-R 下界; 指数族 \Rightarrow 不一定能达到 C-R 下界。

证明 由 Cauchy-Schwarz 不等式的取等条件, Cramer-Rao 不等式取等, 即有

$$S(\mathbf{X}; \theta) = a(\theta)\hat{g}(\mathbf{X}) + b(\theta) \quad a(\theta) \neq 0$$

下面, 我们断言:

$$S(\mathbf{X}; \theta) = a(\theta)\hat{g}(\mathbf{X}) + b(\theta) \Leftrightarrow f_n(\mathbf{X}; \theta) = C(\theta) \exp\{Q(\theta)\hat{g}(\mathbf{X})\}h(\mathbf{X})$$

其中 $f_n(\mathbf{X}; \theta)$ 为概率密度函数。

(A) 先证 \Rightarrow 。注意到 $S(\mathbf{X}; \theta) = \partial \log f_n(\mathbf{X}; \theta) / \partial \theta$, 于是对任意 $\theta \in \Theta$, 作积分

$$\int_{\theta_0}^{\theta} S(\mathbf{X}; t) dt = \int_{\theta_0}^{\theta} \frac{\partial \log f_n(\mathbf{X}; t)}{\partial t} dt = \hat{g}(\mathbf{X}) \int_{\theta_0}^{\theta} a(t) dt + \int_{\theta_0}^{\theta} b(t) dt$$

$$\Rightarrow \log f_n(\mathbf{X}; \theta) - \log f_n(\mathbf{X}; \theta_0) := Q(\theta)\hat{g}(\mathbf{X}) + R(\theta)$$

$$\Rightarrow f_n(\mathbf{X}; \theta) = e^{R(\theta)} \exp\{Q(\theta)\hat{g}(\mathbf{X})\}f_n(\mathbf{X}; \theta_0)$$

其中 $Q(\theta) = \int_{\theta_0}^{\theta} a(t) dt$, $R(\theta) = \int_{\theta_0}^{\theta} b(t) dt$ 。于是 $f_n(\mathbf{X}; \theta)$ 能写成指数族的形式, 证毕。

(B) 再证 \Leftarrow 。已知 $f_n(\mathbf{X}; \theta)$, 于是可求 $S(\mathbf{X}; \theta)$

$$\begin{aligned} S(\mathbf{X}; \theta) &= \frac{\partial \log f_n(\mathbf{X}; \theta)}{\partial \theta} = \frac{\partial}{\partial \theta} [\log C(\theta) + Q(\theta)\hat{g}(\mathbf{X}) + \log h(\mathbf{X})] \\ &= \frac{\partial \log C(\theta)}{\partial \theta} + Q'(\theta)\hat{g}(\mathbf{X}) \triangleq a(\theta)\hat{g}(\mathbf{X}) + b(\theta) \end{aligned}$$

其中 $a(\theta) = Q'(\theta) \neq 0$, $b(\theta) = \partial \log C(\theta) / \partial \theta$, 证毕。

例 5.8 设 $\mathbf{X} = (X_1, \dots, X_n)$ 为自 Poisson 分布 $\text{Poi}(\lambda)$ 中抽取的简单样本。证明只有 $g(\lambda)$ 是 λ 的线性函数时, 才存在 $g(\lambda)$ 的无偏估计, 其方差能处处达到 C-R 下界 (即 $\forall \theta \in \Theta$)。

证明 样本 $\mathbf{X} = (X_1, \dots, X_n)$ 的联合概率函数为

$$\begin{aligned} f(\mathbf{x}; \lambda) &= \prod_{i=1}^n f(x_i; \lambda) = \frac{\lambda^{\sum_{i=1}^n x_i} e^{-n\lambda}}{x_1! \cdots x_n!} \\ &= \frac{e^{-n\lambda} \exp\{n\bar{x} \log \lambda\}}{x_1! \cdots x_n!} \\ &= C(\lambda) \exp\{Q(\lambda)T(\mathbf{x})\}h(\mathbf{x}) \end{aligned}$$

为指数族, 其中 $C(\lambda) = e^{-n\lambda}$, $Q(\lambda) = \log \lambda$, $T(\mathbf{X}) = n\bar{x} = \sum_{i=1}^n x_i$, $h(\mathbf{x}) = 1/(x_1! \cdots x_n!)$ 。由 C-R 不等式取等条件, 即定理 5.5 可知, 只有当

$$g(\lambda) = \mathbb{E}_\lambda[aT(\mathbf{X}) + b] = a\mathbb{E}_\lambda[\sum_{i=1}^n x_i] + b = an \cdot \lambda + b$$

为 λ 的线性函数时, 无偏估计 $\hat{g}(\mathbf{X}) = aT(\mathbf{X}) + b$ 的方差才能达到 C-R 下界, 且为 $g(\lambda)$ 的 UMVUE。

例如: 取 $g(\lambda) = \lambda$, 此时取 $a = 1/n$, $b = 0$, 就有 $\hat{g}(\mathbf{X}) = \bar{X}$ 为 UMVUE。

5.3.3 多参数 C-R 不等式

定理 5.6 (多参数 C-R 不等式) 设 $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k) \in \mathbb{R}^k$, 总体概率函数记作 $f(x; \boldsymbol{\theta})$, 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从总体 $f(x; \boldsymbol{\theta})$ 中抽取的简单随机样本。设 $\hat{\boldsymbol{\theta}} = \hat{\theta}(\mathbf{X}) = (\hat{\theta}_1, \dots, \hat{\theta}_k) \in \mathbb{R}^k$ 是 $\boldsymbol{\theta}$ 的一个无偏估计。记 $\text{Cov}_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}})$ 为 $\hat{\boldsymbol{\theta}}$ 的协方差阵

$$\text{Cov}_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}}) = \mathbb{E}_{\boldsymbol{\theta}} \left[(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T \right] \in \mathbb{R}^{k \times k}$$

为非负定阵。则此时的 Cramer-Rao 不等式为

$$\text{Cov}_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}}) \geq [n\mathbf{I}(\boldsymbol{\theta})]^{-1}$$

其中 $\mathbf{I}(\boldsymbol{\theta})$ 是总体的 Fisher 信息矩阵

$$\mathbf{I}(\boldsymbol{\theta}) = \mathbb{E}_{\boldsymbol{\theta}} \left[\left(\frac{\partial \log f(\mathbf{X}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \right) \left(\frac{\partial \log f(\mathbf{X}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \right)^T \right] \in \mathbb{R}^{k \times k}$$

特别地, 若记 $\mathbf{I}^*(\boldsymbol{\theta}) = [\mathbf{I}(\boldsymbol{\theta})]^{-1}$, 则有

$$\text{Var}_{\boldsymbol{\theta}}(\hat{\theta}_i) \geq \frac{\mathbf{I}_{ii}^*(\boldsymbol{\theta})}{n} \quad i = 1, 2, \dots, k \quad (7)$$

其中 $\mathbf{I}_{ii}^*(\boldsymbol{\theta})$ 表示 $\mathbf{I}^*(\boldsymbol{\theta})$ 的第 i 个对角元素。

注 Fisher 信息矩阵还可以表示为

$$\mathbf{I}(\boldsymbol{\theta}) = \mathbb{E}_{\boldsymbol{\theta}} \left[- \left(\frac{\partial^2 \log f(\mathbf{X}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} \right) \right] \in \mathbb{R}^{k \times k}$$

注 式 7 成立, 需要证明如下结论

$$\mathbf{A} \geq 0 \quad \Rightarrow \quad \mathbf{A}_{ii} \geq 0$$

这个结论是显然的: 由非负定的性质, 任意向量 \mathbf{v} 都有 $\mathbf{v} \mathbf{A} \mathbf{v}^T \geq 0$ 。只要取 $\mathbf{v} = \mathbf{e}_i = (0, \dots, 1, \dots, 0)$, 其中 \mathbf{e}_i 表示第 i 个分量为 1, 其他分量为 0。于是有 $\mathbf{e}_i \mathbf{A} \mathbf{e}_i^T = A_{ii} \geq 0$, 证毕。

例 5.9 设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从正态总体 $N(a, \sigma^2)$ 中抽取的简单样本, 记 $\boldsymbol{\theta} = (a, \sigma^2)$, 其中 $\theta_1 = a$, $\theta_2 = \sigma^2$ 。求 $\boldsymbol{\theta}$ 的两个分量无偏估计方差的 C-R 下界, 并将其与 θ_1 和 θ_2 的无偏估计 \bar{X} 和 S^2 的方差进行比较。

解答 正态随机变量的密度函数为

$$f(x; \boldsymbol{\theta}) = (2\pi\theta_2)^{-1/2} \exp\left\{-\frac{(x-\theta_1)^2}{2\theta_2}\right\}$$

可知

$$\frac{\partial \log f(x; \boldsymbol{\theta})}{\partial \theta_1} = \frac{x-\theta_1}{\theta_2} \quad \frac{\partial \log f(x; \boldsymbol{\theta})}{\partial \theta_2} = \frac{-\theta_2 + (x-\theta_1)^2}{2\theta_2^2}$$

由此计算信息矩阵

$$\mathbf{I}_{11}(\boldsymbol{\theta}) = \frac{1}{\sigma^2} \quad \mathbf{I}_{22}(\boldsymbol{\theta}) = \frac{1}{2\sigma^4} \quad \mathbf{I}_{12}(\boldsymbol{\theta}) = \mathbf{I}_{21}(\boldsymbol{\theta}) = 0$$

故有

$$n\mathbf{I}(\boldsymbol{\theta}) = \begin{pmatrix} \frac{n}{\sigma^2} & 0 \\ 0 & \frac{n}{2\sigma^4} \end{pmatrix} \quad [n\mathbf{I}(\boldsymbol{\theta})]^{-1} = \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{pmatrix}$$

记 $\hat{\theta}_1 = \bar{X}$, $\hat{\theta}_2 = S^2$, 则由 Cramer-Rao 不等式可知

$$\text{Cov}_{\boldsymbol{\theta}}(\hat{\boldsymbol{\theta}}) = \text{Cov}_{\boldsymbol{\theta}} \begin{pmatrix} \hat{\theta}_1 \\ \hat{\theta}_2 \end{pmatrix} \geq \begin{pmatrix} \frac{\sigma^2}{n} & 0 \\ 0 & \frac{2\sigma^4}{n} \end{pmatrix}$$

注意到 $\text{Var}_{\boldsymbol{\theta}}(\hat{\theta}_1) = \sigma^2/n$ 达到 C-R 下界, 故 $\hat{\theta}_1 = \bar{X}$ 是 $\theta_1 = a$ 的 UMVUE。而根据 $(n-1)S^2/\sigma^2 \sim \chi_{n-1}^2$ 知

$$\text{Var}_{\boldsymbol{\theta}}(\hat{\theta}_2) = 2(n-1) \cdot \frac{\sigma^4}{(n-1)^2} = \frac{2\sigma^4}{n-1} > \frac{2\sigma^4}{n}$$

故 $\hat{\theta}_2 = S^2$ 的方差大于 C-R 下界, 不是 $\theta_2 = \sigma^2$ 的 UMVUE。

5.3.4 有效估计和估计的效率

定义 5.4 (有效估计) 设 $\hat{g}_n(\mathbf{X})$ 是 $g(\theta)$ 的无偏估计, 则比值

$$e_{\hat{g}_n}(\theta) = \frac{[g'(\theta)]^2/[nI(\theta)]}{\text{Var}_{\boldsymbol{\theta}}[\hat{g}_n(\mathbf{X})]}$$

称为无偏估计 $\hat{g}_n(\mathbf{X})$ 的效率 (efficiency)。显然 $0 < e_{\hat{g}_n}(\theta) \leq 1$, 当 $e_{\hat{g}_n}(\theta) = 1$ 时, 称 $\hat{g}_n(\mathbf{X})$ 是 $g(\theta)$ 的有效估计 (effective estimation)。若 $\hat{g}_n(\mathbf{X})$ 不是 $g(\theta)$ 的有效估计, 但 $\lim_{n \rightarrow \infty} e_{\hat{g}_n}(\theta) = 1$, 则称 $\hat{g}_n(\mathbf{X})$ 是 $g(\theta)$ 的渐近有效估计 (asymptotically effective estimation)。

例 5.10 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从 $N(a, \sigma^2)$ 中抽取的简单随机样本。

1. 当 a 未知时, 证明样本方差 S^2 不是 σ^2 的有效估计, 但是渐近有效估计。
2. 当 a 已知时, 求 σ^2 的有效估计。

证明 (1) 当 a 未知时, 由例 5.9 可知 S^2 的方差为 $2\sigma^4/(n-1)$ 达不到 C-R 下界 $2\sigma^4/n$, 故不是有效估计。估计的效率为 $e_{S^2}(\sigma^2) = (n-1)/n < 1$, 但是

$$\lim_{n \rightarrow \infty} e_{S^2}(\sigma^2) = \lim_{n \rightarrow \infty} \frac{n-1}{n} = 1$$

故 S^2 是 σ^2 的渐近有效估计。

解答 (2) 当 a 已知, 设 $S_n^2 = \sum_{i=1}^n (X_i - a)^2 / n$, 容易得 $nS_n^2 / \sigma^2 \sim \chi_n^2$, 于是有

$$\text{Var}(S_n^2) = \frac{\sigma^4}{n^2} \cdot \text{Var}\left(\frac{nS_n^2}{\sigma^2}\right) = \frac{\sigma^4}{n^2} \cdot 2n = \frac{2\sigma^4}{n}$$

达到了 C-R 下界, 故此时 σ^2 的 UMVUE 为 S_n^2 。

例 5.11 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从下列含有位置参数的指数分布族中抽取的简单样本,

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

求 a 的 UMVUE。

解答 容易证 $X_{(1)}$ 是 a 的充分完全统计量, 且密度函数为 $f_{X_{(1)}}(x) = ne^{-n(x-a)} \cdot \mathbb{I}(x > a)$, 于是

$$\mathbb{E}_a(X_{(1)}) = n \int_a^\infty x e^{-n(x-a)} dx = a + \frac{1}{n}$$

故 $X_{(1)} - 1/n$ 是 a 的无偏估计, 由 Lehmann-Scheffe 定理 5.2 可知 $X_{(1)} - 1/n$ 是 a 的 UMVUE。

但是, 概率函数 $f_n(\mathbf{x}; a) = \exp\{-\sum_{i=1}^n (x_i - a)\} \cdot \mathbb{I}(x_{(1)} > a)$ 的支撑集 $\{\mathbf{x} : f_n(\mathbf{x}; a) > 0\} = \{\mathbf{x} : \forall x_i > a\}$ 与参数 a 有关。所以, 不满足 C-R 正则条件, 不能讨论有效性。