

点估计的评价

续本达

清华大学 工程物理系

2023-11-20

点估计的评价

续本达

复习

评价标准

相合性

无偏性

有效性

例：最小二乘
估计

例：截尾分布

复习

点估计

用一个数值作为未知参数的估计值 (estimate)

设总体 X 的分布函数的形式已知, θ 是待估参数, X_1, X_2, \dots, X_n 为总体的一个样本, 点估计就是要构造一个适当的统计量 $\hat{\theta}(X_1, X_2, \dots, X_n)$, 用它的观察值 $\hat{\theta}(x_1, x_2, \dots, x_n)$ 作为待估参数的近似值。

定义 (矩估计)

用样本 k 阶矩作为总体 k 阶矩的估计量, 建立含待估参数的方程, 从而解出待估参数。

- ① 设 X 为离散型随机变量, 其分布律为

$$P(X = x) = p(x, \theta), x = u_1, u_2, \dots, \theta \in \Theta$$

样本 X_1, X_2, \dots, X_n 的联合概率分布为

$$P(X_1 = x_1, \dots, X_n = x_n) = p(x_1, \theta)p(x_2, \theta) \cdots p(x_n, \theta) = L(\vec{x}, \theta)$$

- ② 设 X 是连续型变量, 取 $f(X, \theta)$ 为 X 的密度函数, 似然函数定义为

$$L(\vec{x}, \theta) = \prod_{i=1}^n f(x_i, \theta)$$

最大似然法: maximum likelihood estimation (MLE)

$$\hat{\theta}(\vec{x}) = \arg \max L(\vec{x}; \theta)$$

称为 **最大似然估计值**。称统计量 $\hat{\theta}(X_1, X_2, \dots, X_n)$ 为参数 θ 的 **最大似然估计量**。

点估计的评价

续本达

复习

评价标准

相合性

无偏性

有效性

例：最小二乘
估计

例：截尾分布

评价标准

对于同一个未知参数, 不同的方法得到的估计量可能不同, 于是提出问题:

- ① 应该选用哪一种估计量?
- ② 用何标准来评价一个估计量的好坏?

预告：评判标准与数字特征紧密相关

估计量判别	数字特征
无偏性	数学期望
有效性	方差
相合性	依概率收敛

对于同一个未知参数, 不同的方法得到的估计量可能不同, 于是提出问题:

- ① 应该选用哪一种估计量?
- ② 用何标准来评价一个估计量的好坏?

预告：评判标准与数字特征紧密相关

估计量判别	数字特征
无偏性	数学期望
有效性	方差
相合性	依概率收敛

点估计的评价

续本达

复习

评价标准

相合性

无偏性

有效性

例：最小二乘
估计

例：截尾分布

相合性

相合性 consistency 又称 **一致性**

定义

设 $\hat{\theta}(X_1, X_2, \dots, X_n)$ 是总体参数 θ 的估计量. 若

$$\forall \theta \in \Theta (\hat{\theta} \xrightarrow{P} \theta)$$

则称 $\hat{\theta}$ 是 θ 的 **相合估计量**.

估计量 $\hat{\theta}$ 实际上依赖于样本容量 n , 可以将 $\hat{\theta}_n$ 看作随机变量序列, 相合性要求 $\hat{\theta}_n$ 依概率收敛于真值 θ . 相合性是好的估计量的基本要求. 若不具备相合性, 则无论样本容量 n 取多大, 都无法将估计量估计得足够精确.

相合性 consistency 又称 **一致性**

定义

设 $\hat{\theta}(X_1, X_2, \dots, X_n)$ 是总体参数 θ 的估计量. 若

$$\forall \theta \in \Theta (\hat{\theta} \xrightarrow{P} \theta)$$

则称 $\hat{\theta}$ 是 θ 的 **相合估计量**.

估计量 $\hat{\theta}$ 实际上依赖于样本容量 n , 可以将 $\hat{\theta}_n$ 看作随机变量序列, 相合性要求 $\hat{\theta}_n$ 依概率收敛于真值 θ . 相合性是好的估计量的基本要求. 若不具备相合性, 则无论样本容量 n 取多大, 都无法将估计量估计得足够精确.

相合性 consistency 又称 **一致性**

定义

设 $\hat{\theta}(X_1, X_2, \dots, X_n)$ 是总体参数 θ 的估计量. 若

$$\forall \theta \in \Theta (\hat{\theta} \xrightarrow{P} \theta)$$

则称 $\hat{\theta}$ 是 θ 的 **相合估计量**.

估计量 $\hat{\theta}$ 实际上依赖于样本容量 n , 可以将 $\hat{\theta}_n$ 看作随机变量序列, 相合性要求 $\hat{\theta}_n$ 依概率收敛于真值 θ . 相合性是好的估计量的基本要求. 若不具备相合性, 则无论样本容量 n 取多大, 都无法将估计量估计得足够精确.

定理 (期望方差)

设 $\hat{\theta}_n(X_1, \dots, X_n)$ 是 θ 的一个估计量。若

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta, \quad \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$$

则 $\hat{\theta}_n$ 是 θ 的相合估计量。

定义 (均方误差 mean-square error, MSE)

$$\text{MSE}(\hat{\theta}_n) = E(\hat{\theta}_n - \theta)^2 = \text{Var}(\hat{\theta}_n) + [E(\hat{\theta}_n) - \theta]^2$$

定理条件可以写为 $\lim_{n \rightarrow \infty} \text{MSE}(\hat{\theta}_n) = 0$

定理 (期望方差)

设 $\hat{\theta}_n(X_1, \dots, X_n)$ 是 θ 的一个估计量。若

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta, \quad \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$$

则 $\hat{\theta}_n$ 是 θ 的相合估计量。

定义 (均方误差 mean-square error, MSE)

$$\text{MSE}(\hat{\theta}_n) = E(\hat{\theta}_n - \theta)^2 = \text{Var}(\hat{\theta}_n) + [E(\hat{\theta}_n) - \theta]^2$$

定理条件可以写为 $\lim_{n \rightarrow \infty} \text{MSE}(\hat{\theta}_n) = 0$

定理 (函数的相合性)

若 $\hat{\theta}_{n1}, \dots, \hat{\theta}_{nk}$ 分别是 $\theta_1, \dots, \theta_k$ 的相合估计量, $\eta = g(\theta_1, \dots, \theta_k)$ 是 $\theta_1, \dots, \theta_k$ 的连续函数, 则 $\hat{\eta} = g(\hat{\theta}_{n1}, \dots, \hat{\theta}_{nk})$ 是 η 的相合估计量。

例

设 X_1, \dots, X_n 是抽样自总体 $X \sim U(0, \theta)$ 的样本。证明 θ 的最大似然估计量是相合估计量。

θ 的最大似然估计量为 $\hat{\theta}_n = \max(X_1, \dots, X_n)$ 。需要证明 $\hat{\theta}_n$

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta, \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$$

需要知道 $\hat{\theta}_n$ 服从的分布函数。由独立同分布的随机变量的最大值的分布知， $\hat{\theta}_n$ 服从分布 $F_Y(y) = [F(y)]^n$ ，其中

$$F(y) = \begin{cases} 0, & y < 0 \\ \frac{y}{\theta}, & 0 < y < \theta \\ 1, & y > \theta \end{cases}$$

例

设 X_1, \dots, X_n 是抽样自总体 $X \sim U(0, \theta)$ 的样本。证明 θ 的最大似然估计量是相合估计量。

θ 的最大似然估计量为 $\hat{\theta}_n = \max(X_1, \dots, X_n)$ 。需要证明 $\hat{\theta}_n$

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta, \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$$

需要知道 $\hat{\theta}_n$ 服从的分布函数。由独立同分布的随机变量的最大值的分布知， $\hat{\theta}_n$ 服从分布 $F_Y(y) = [F(y)]^n$ ，其中

$$F(y) = \begin{cases} 0, & y < 0 \\ \frac{y}{\theta}, & 0 < y < \theta \\ 1, & y > \theta \end{cases}$$

例

设 X_1, \dots, X_n 是抽样自总体 $X \sim U(0, \theta)$ 的样本。证明 θ 的最大似然估计量是相合估计量。

θ 的最大似然估计量为 $\hat{\theta}_n = \max(X_1, \dots, X_n)$ 。需要证明 $\hat{\theta}_n$

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta, \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$$

需要知道 $\hat{\theta}_n$ 服从的分布函数。由独立同分布的随机变量的最大值的分布知， $\hat{\theta}_n$ 服从分布 $F_Y(y) = [F(y)]^n$ ，其中

$$F(y) = \begin{cases} 0, & y < 0 \\ \frac{y}{\theta}, & 0 < y < \theta \\ 1, & y > \theta \end{cases}$$

例

设 X_1, \dots, X_n 是抽样自总体 $X \sim U(0, \theta)$ 的样本。证明 θ 的最大似然估计量是相合估计量。

θ 的最大似然估计量为 $\hat{\theta}_n = \max(X_1, \dots, X_n)$ 。需要证明 $\hat{\theta}_n$

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta, \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$$

需要知道 $\hat{\theta}_n$ 服从的分布函数。由独立同分布的随机变量的最大值的分布知， $\hat{\theta}_n$ 服从分布 $F_Y(y) = [F(y)]^n$ ，其中

$$F(y) = \begin{cases} 0, & y < 0 \\ \frac{y}{\theta}, & 0 < y < \theta \\ 1, & y > \theta \end{cases}$$

$\hat{\theta}_n$ 分布的概率密度函数

$$f_Y(y) = \begin{cases} \frac{ny^{n-1}}{\theta^n}, & 0 < y < \theta \\ 0, & \text{其他} \end{cases}$$

$$E(\hat{\theta}_n) = \int_0^\theta y \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{n+1} \theta \xrightarrow{n \rightarrow \infty} \theta$$

$$E(\hat{\theta}_n^2) = \int_0^\theta y^2 \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{n+2} \theta^2$$

$$\text{Var}(\hat{\theta}_n) = E(\hat{\theta}_n^2) - E^2(\hat{\theta}_n) = \frac{n}{(n+1)^2(n+2)} \theta^2 \xrightarrow{n \rightarrow \infty} 0$$

所以 $\hat{\theta}_n$ 是相合估计量。

$\hat{\theta}_n$ 分布的概率密度函数

$$f_Y(y) = \begin{cases} \frac{ny^{n-1}}{\theta^n}, & 0 < y < \theta \\ 0, & \text{其他} \end{cases}$$

$$E(\hat{\theta}_n) = \int_0^\theta y \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{n+1} \theta \xrightarrow{n \rightarrow \infty} \theta$$

$$E(\hat{\theta}_n^2) = \int_0^\theta y^2 \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{n+2} \theta^2$$

$$\text{Var}(\hat{\theta}_n) = E(\hat{\theta}_n^2) - E^2(\hat{\theta}_n) = \frac{n}{(n+1)^2(n+2)} \theta^2 \xrightarrow{n \rightarrow \infty} 0$$

所以 $\hat{\theta}_n$ 是相合估计量。

$\hat{\theta}_n$ 分布的概率密度函数

$$f_Y(y) = \begin{cases} \frac{ny^{n-1}}{\theta^n}, & 0 < y < \theta \\ 0, & \text{其他} \end{cases}$$

$$E(\hat{\theta}_n) = \int_0^\theta y \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{n+1} \theta \xrightarrow{n \rightarrow \infty} \theta$$

$$E(\hat{\theta}_n^2) = \int_0^\theta y^2 \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{n+2} \theta^2$$

$$\text{Var}(\hat{\theta}_n) = E(\hat{\theta}_n^2) - E^2(\hat{\theta}_n) = \frac{n}{(n+1)^2(n+2)} \theta^2 \xrightarrow{n \rightarrow \infty} 0$$

所以 $\hat{\theta}_n$ 是相合估计量。

$\hat{\theta}_n$ 分布的概率密度函数

$$f_Y(y) = \begin{cases} \frac{ny^{n-1}}{\theta^n}, & 0 < y < \theta \\ 0, & \text{其他} \end{cases}$$

$$E(\hat{\theta}_n) = \int_0^\theta y \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{n+1} \theta \xrightarrow{n \rightarrow \infty} \theta$$

$$E(\hat{\theta}_n^2) = \int_0^\theta y^2 \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{n+2} \theta^2$$

$$\text{Var}(\hat{\theta}_n) = E(\hat{\theta}_n^2) - E^2(\hat{\theta}_n) = \frac{n}{(n+1)^2(n+2)} \theta^2 \xrightarrow{n \rightarrow \infty} 0$$

所以 $\hat{\theta}_n$ 是相合估计量。

点估计的评价

续本达

复习

评价标准

相合性

无偏性

有效性

例：最小二乘
估计

例：截尾分布

无偏性

定义

若 $E(\hat{\theta}) = \theta$ 则称 $\hat{\theta}$ 是 θ 的无偏估计量。

我们不可能要求每一次由样本得到的估计量与真值都相等，但可以要求这些估计量的期望与真值相等。

- 样本均值 \bar{x} 是总体期望 $E(X)$ 的无偏估计量。
- 样本二阶原点矩 $A_2 = \frac{1}{n} \sum_{i=1}^n X_i^2$ 是总体二阶原点矩 $\mu_2 = E(X^2)$ 的无偏估计量。

定义

若 $E(\hat{\theta}) = \theta$ 则称 $\hat{\theta}$ 是 θ 的无偏估计量。

我们不可能要求每一次由样本得到的估计量与真值都相等，但可以要求这些估计量的期望与真值相等。

- 样本均值 \bar{X} 是总体期望 $E(X)$ 的 **无偏估计量**。
- 样本二阶原点矩 $A_2 = \frac{1}{n} \sum_{i=1}^n X_i^2$ 是总体二阶原点矩 $\mu_2 = E(X^2)$ 的 **无偏估计量**。
- $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ 是 $\text{Var}(X)$ 的 **无偏估计**。
- $S_n^2 = \frac{n-1}{n} S^2$ 是 $\text{Var}(X)$ 的 **渐进无偏估计**。

定义

若 $E(\hat{\theta}) = \theta$ 则称 $\hat{\theta}$ 是 θ 的无偏估计量。

我们不可能要求每一次由样本得到的估计量与真值都相等，但可以要求这些估计量的期望与真值相等。

- 样本均值 \bar{X} 是总体期望 $E(X)$ 的 **无偏估计量**。
- 样本二阶原点矩 $A_2 = \frac{1}{n} \sum_{i=1}^n X_i^2$ 是总体二阶原点矩 $\mu_2 = E(X^2)$ 的 **无偏估计量**。
- $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ 是 $\text{Var}(X)$ 的 **无偏估计**。
- $S_n^2 = \frac{n-1}{n} S^2$ 是 $\text{Var}(X)$ 的 **渐进无偏估计**。

定义

若 $E(\hat{\theta}) = \theta$ 则称 $\hat{\theta}$ 是 θ 的无偏估计量。

我们不可能要求每一次由样本得到的估计量与真值都相等，但可以要求这些估计量的期望与真值相等。

- 样本均值 \bar{X} 是总体期望 $E(X)$ 的 **无偏估计量**。
- 样本二阶原点矩 $A_2 = \frac{1}{n} \sum_{i=1}^n X_i^2$ 是总体二阶原点矩 $\mu_2 = E(X^2)$ 的 **无偏估计量**。
- $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ 是 $\text{Var}(X)$ 的 **无偏估计**。
- $S_n^2 = \frac{n-1}{n} S^2$ 是 $\text{Var}(X)$ 的 **渐进无偏估计**。

定义

若 $E(\hat{\theta}) = \theta$ 则称 $\hat{\theta}$ 是 θ 的无偏估计量。

我们不可能要求每一次由样本得到的估计量与真值都相等，但可以要求这些估计量的期望与真值相等。

- 样本均值 \bar{X} 是总体期望 $E(X)$ 的 **无偏估计量**。
- 样本二阶原点矩 $A_2 = \frac{1}{n} \sum_{i=1}^n X_i^2$ 是总体二阶原点矩 $\mu_2 = E(X^2)$ 的 **无偏估计量**。
- $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ 是 $\text{Var}(X)$ 的 **无偏估计**。
- $S_n^2 = \frac{n-1}{n} S^2$ 是 $\text{Var}(X)$ 的 **渐进无偏估计**。

回顾相合性判定定理

定理 (期望方差)

设 $\hat{\theta}_n(X_1, \dots, X_n)$ 是 θ 的一个估计量。若

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta, \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$$

则 $\hat{\theta}_n$ 是 θ 的相合估计量。

前一个条件正是 $\hat{\theta}_n$ 的渐进无偏性。

相合性与（渐进）无偏性的区别

相合性不能推出渐进无偏性，只有渐进无偏性也不能推出相合性。

回顾相合性判定定理

定理 (期望方差)

设 $\hat{\theta}_n(X_1, \dots, X_n)$ 是 θ 的一个估计量。若

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta, \lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$$

则 $\hat{\theta}_n$ 是 θ 的相合估计量。

前一个条件正是 $\hat{\theta}_n$ 的渐进无偏性。

相合性与（渐进）无偏性的区别

相合性不能推出渐进无偏性，只有渐进无偏性也不能推出相合性。

例

设 (X_1, X_2, \dots, X_m) 是总体 $X \sim B(n, p)$ 的一个样本, $n > 1$, 求 p^2 的无偏估计量.

$$E(\bar{X}) = E(X) = np$$

$$E\left(\frac{1}{m} \sum_{i=1}^m X_i^2\right) = E(X^2) = (np)^2 + np(1-p) = (n^2 - n)p^2 + E(\bar{X})$$

$$\Rightarrow p^2 = \frac{1}{n^2 - n} \left[E\left(\frac{1}{m} \sum_{i=1}^m X_i^2\right) - \bar{X} \right] = E\left[\frac{1}{(n^2 - n)m} \sum_{i=1}^m X_i(X_i - 1) \right]$$

$$\Rightarrow \hat{p}^2 = \frac{1}{(n^2 - n)m} \sum_{i=1}^m X_i(X_i - 1)$$

是无偏估计量。

例

设 (X_1, X_2, \dots, X_m) 是总体 $X \sim B(n, p)$ 的一个样本, $n > 1$, 求 p^2 的无偏估计量.

$$E(\bar{X}) = E(X) = np$$

$$E\left(\frac{1}{m} \sum_{i=1}^m X_i^2\right) = E(X^2) = (np)^2 + np(1-p) = (n^2-n)p^2 + E(\bar{X})$$

$$\Rightarrow p^2 = \frac{1}{n^2-n} \left[E\left(\frac{1}{m} \sum_{i=1}^m X_i^2\right) - \bar{X} \right] = E\left[\frac{1}{(n^2-n)m} \sum_{i=1}^m X_i(X_i-1) \right]$$

$$\Rightarrow \hat{p}^2 = \frac{1}{(n^2-n)m} \sum_{i=1}^m X_i(X_i-1)$$

是无偏估计量。

例

设 (X_1, X_2, \dots, X_m) 是总体 $X \sim B(n, p)$ 的一个样本, $n > 1$, 求 p^2 的无偏估计量.

$$E(\bar{X}) = E(X) = np$$

$$E\left(\frac{1}{m} \sum_{i=1}^m X_i^2\right) = E(X^2) = (np)^2 + np(1-p) = (n^2-n)p^2 + E(\bar{X})$$

$$\Rightarrow p^2 = \frac{1}{n^2-n} \left[E\left(\frac{1}{m} \sum_{i=1}^m X_i^2\right) - \bar{X} \right] = E\left[\frac{1}{(n^2-n)m} \sum_{i=1}^m X_i(X_i-1) \right]$$

$$\Rightarrow \hat{p}^2 = \frac{1}{(n^2-n)m} \sum_{i=1}^m X_i(X_i-1)$$

是无偏估计量。

例

设 (X_1, X_2, \dots, X_m) 是总体 $X \sim B(n, p)$ 的一个样本, $n > 1$, 求 p^2 的无偏估计量.

$$E(\bar{X}) = E(X) = np$$

$$E\left(\frac{1}{m} \sum_{i=1}^m X_i^2\right) = E(X^2) = (np)^2 + np(1-p) = (n^2-n)p^2 + E(\bar{X})$$

$$\implies p^2 = \frac{1}{n^2-n} \left[E\left(\frac{1}{m} \sum_{i=1}^m X_i^2\right) - \bar{X} \right] = E\left[\frac{1}{(n^2-n)m} \sum_{i=1}^m X_i(X_i-1) \right]$$

$$\implies \hat{p}^2 = \frac{1}{(n^2-n)m} \sum_{i=1}^m X_i(X_i-1)$$

是无偏估计量。

点估计的评价

续本达

复习

评价标准

相合性

无偏性

有效性

例：最小二乘
估计

例：截尾分布

有效性

定义

设 $\hat{\theta}_1(X_1, X_2, \dots, X_n)$ 和 $\hat{\theta}_2(X_1, X_2, \dots, X_n)$ 都是总体参数 θ 的无偏估计量, 且 $\text{Var}(\hat{\theta}_1) < \text{Var}(\hat{\theta}_2)$ 则称 $\hat{\theta}_1$ 比 $\hat{\theta}_2$ 更**有效**.

一致最小方差无偏估计 UMVUE

如果一个估计量比任何其它估计量都有效, 则称之为**一致最小方差无偏估计** uniformly minimum variance unbiased estimator UMVUE

定义

设 $\hat{\theta}_1(X_1, X_2, \dots, X_n)$ 和 $\hat{\theta}_2(X_1, X_2, \dots, X_n)$ 都是总体参数 θ 的无偏估计量, 且 $\text{Var}(\hat{\theta}_1) < \text{Var}(\hat{\theta}_2)$ 则称 $\hat{\theta}_1$ 比 $\hat{\theta}_2$ 更 **有效**.

一致最小方差无偏估计 UMVUE

如果一个估计量比任何其它估计量都有效, 则称之为 **一致最小方差无偏估计** uniformly minimum variance unbiased estimator UMVUE

定理 (Cramer-Rao 下限)

$L(X; \theta)$ 是带参数 θ 的总体 X 的似然函数。任何 θ 的无偏估计量 $\hat{\theta}_n$ 满足

$$\text{Var}(\hat{\theta}_n) \geq \frac{1}{n \text{E} \left(\frac{\partial \log L(X; \theta)}{\partial \theta} \right)^2}$$

达到 Cramer-Rao 理论极限的估计量称为 **有效估计量**。

以下重要结论是 **最大似然估计量** 应用的理论支撑。证明较难，不做细致讨论

- ① 如果参数存在有效无偏估计量，那么它一定是最大似然估计量
- ② 一般情况下，最大似然估计量是一致的
- ③ 最大似然估计量渐进服从正态分布

以下重要结论是 **最大似然估计量** 应用的理论支撑。证明较难，不做细致讨论

- ① 如果参数存在有效无偏估计量，那么它一定是最大似然估计量
- ② 一般情况下，最大似然估计量是一致的
- ③ 最大似然估计量渐进服从正态分布

以下重要结论是 **最大似然估计量** 应用的理论支撑。证明较难，不做细致讨论

- ① 如果参数存在有效无偏估计量，那么它一定是最大似然估计量
- ② 一般情况下，最大似然估计量是一致的
- ③ 最大似然估计量渐进服从正态分布

例

设 X_1, \dots, X_n 是取自某总体的样本，记总体均值和方差分别为 μ 和 σ^2 。 μ 的两个估计量分别定义为 $\hat{\mu}_1 = X_1$, $\hat{\mu}_2 = \bar{X}$ 。哪个估计量更有效？

$$E(\hat{\mu}_1) = E(X_1) = \mu, E(\hat{\mu}_2) = E(\bar{X}) = \mu$$

两者都无偏。

$$\text{Var}(\hat{\mu}_1) = \sigma^2, \text{Var}(\hat{\mu}_2) = \frac{\sigma^2}{n}$$

当 $n > 1$ 时, $\text{Var}(\hat{\mu}_1) > \text{Var}(\hat{\mu}_2)$, $\hat{\mu}_2$ 更有效。

启示

- ① 用全部数据的平均估计总体均值要比只使用部分数据更有效。
- ② 数据积累，估计量的方差越来越小，参数越来越精确，信息量越来越大。

例

设 X_1, \dots, X_n 是取自某总体的样本，记总体均值和方差分别为 μ 和 σ^2 。 μ 的两个估计量分别定义为 $\hat{\mu}_1 = X_1$, $\hat{\mu}_2 = \bar{X}$ 。哪个估计量更有效？

$$E(\hat{\mu}_1) = E(X_1) = \mu, E(\hat{\mu}_2) = E(\bar{X}) = \mu$$

两者都无偏。

$$\text{Var}(\hat{\mu}_1) = \sigma^2, \text{Var}(\hat{\mu}_2) = \frac{\sigma^2}{n}$$

当 $n > 1$ 时， $\text{Var}(\hat{\mu}_1) > \text{Var}(\hat{\mu}_2)$ ， $\hat{\mu}_2$ 更有效。

启示

- ① 用全部数据的平均估计总体均值要比只使用部分数据更有效。
- ② 数据积累，估计量的方差越来越小，参数越来越精确，**信息量** 越来越大。

点估计的评价

续本达

复习

评价标准

相合性

无偏性

有效性

例：最小二乘
估计

例：截尾分布


例：最小二乘估计

- 最小二乘估计法 (Least Square Method, LSE) 是自古以来最广泛使用的参数估计法之一，源于天文学和测地学上的应用。
- 当总体分布的函数形式并不严格知道、无法进行最大似然估计时，运用最小二乘法往往十分方便。
- 由 Legendre 和 Gauss 在同一时代发现。

- 假设某个随机变量 Y 与 X 和未知参数 θ 有关：

$$Y = f(X; \theta)$$

- 为了估计参数 θ ，在 X 的不同取值 x_1, \dots, x_N 测量 Y ，得到对应的测量值 y_1, \dots, y_N 。然后用函数 $y = f(x, \theta)$ “拟合” 数据。
- 直观来说，如果得到的“拟合”曲线与每个数据点距离越小，则该曲线所对应的参数越好。



- “数据拟合”常用实现方法是最小二乘法。


$$\chi^2(\theta) \equiv \sum_{i=1}^N [y_i - f(x_i; \theta)]^2$$

取最小值的 $\hat{\theta}$ 为估计量。

- 若在不同 x_i 处测量得到的 y_i 的精度不同，假设 y_i 的方差为 σ_i^2 ，则 $\chi^2(\theta)$ 定义为

$$\chi^2(\theta) \equiv \sum_{i=1}^N \frac{[y_i - f(x_i; \theta)]^2}{\sigma_i^2}$$

y_i 经常近似服从正态分布，则 $\chi^2(\theta)$ 近似服从卡方分布。



一定条件下，最小二乘法与最大似然法等价。

假设每次测量独立，观测值 $Y_i \sim N(\eta_i, \sigma_i^2)$ ，其中真值 η_i 未知。

N 次观测 $\vec{Y} = (Y_1, \dots, Y_N)$ 的似然函数为

$$L = \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(Y_i - \eta_i)^2}{2\sigma_i^2}} \propto e^{-\frac{1}{2} \sum_{i=1}^N \left(\frac{Y_i - \eta_i}{\sigma_i}\right)^2}$$

要使 L 取最大，则要 $\sum_{i=1}^N \left(\frac{Y_i - \eta_i}{\sigma_i}\right)^2$ 最小

- **指数族分布** 包含正态分布、泊松分布、二项分布、伽马分布
- 在指数族分布的参数估计中，**迭代重加权最小二乘法** 等价于最大似然法。

实验物理学家的三个境界

- ① 不管随机变量的分布 → 无脑使用最小二乘法
- ② 重视随机变量的分布 → 无脑使用最大似然法
- ③ 理解参数估计理论，上过《概率统计分析及量测技术》 → 批判地选择最有效的方法

- **指数族分布** 包含正态分布、泊松分布、二项分布、伽马分布
- 在指数族分布的参数估计中，**迭代重加权最小二乘法** 等价于最大似然法。

实验物理学家的三个境界

- ① 不管随机变量的分布 → 无脑使用最小二乘法
- ② 重视随机变量的分布 → 无脑使用最大似然法
- ③ 理解参数估计理论，上过《概率统计分析及量测技术》 → 批判地选择最有效的方法

点估计的评价

续本达

复习

评价标准

相合性

无偏性

有效性

例：最小二乘
估计

例：截尾分布

例：截尾分布

“卡一个窗口拟合”，需要注意

- ① 窗口也是参数。
- ② 卡窗口之后，应重新归一。