

# 第一节 参数的点估计

- 点估计概念
- 求估计量的方法
- 估计量的评选标准

# 一、矩估计

定义 用样本原点矩估计相应的总体原点矩，又用样本原点矩的连续函数估计相应的总体原点矩的连续函数，这种参数点估计法称为矩估计法。

理论依据：辛钦大数定律

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{P} E(X) = \mu$$

$$A_k = \frac{1}{n} \sum_{i=1}^n X_i^k \xrightarrow{P} E(X^k) = \mu_k \quad (k = 1, 2, \dots)$$

$$g(A_1, A_2, \dots, A_k) \xrightarrow{P} g(\mu_1, \mu_2, \dots, \mu_k)$$

其中  $g$  为连续函数。



设总体的分布函数中含有 $k$ 个未知参数 $\theta_1, \theta_2, \dots, \theta_k$ ,

Step 1 计算总体的矩

$$EX^i = g_i(\theta_1, \theta_2, \dots, \theta_k) = \mu_i \quad i=1, 2, \dots, k$$

Step 2 解方程组

$$\theta_j = h_j(\mu_1, \mu_2, \dots, \mu_k) \quad j=1, 2, \dots, k$$

Step 3 用样本矩 $A_i$ 估计总体矩 $\mu_i$

即可得诸 $\theta_j$ 的矩估计量:

$$\hat{\theta}_j = h_j(A_1, A_2, \dots, A_k) \quad j=1, 2, \dots, k$$

矩估计量的观察值称为矩估计值。



## 二. 最大似然法估计

### 最大似然法的理论依据---极大似然原理

极大似然原理的直观想法是：一个随机试验如有若干个可能的结果  $A$ 、 $B$ 、 $C$ ，……。若在一次试验中，结果  $A$  出现，则一般认为试验条件对  $A$  出现有利，也即  $A$  出现的概率最大。



# 求参数的最大似然估计的一般步骤

## Step1. 计算样本的似然函数

1) 若总体是离散型R.V, 似然函数为样本的联合概率

$$L(\theta) = P(X_1 = x_1, \dots, X_n = x_n)$$

2) 若总体是连续型R.V, 似然函数为样本的联合密度

$$L(\theta) = L(\theta; x_1, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta)$$

Step2. 求似然函数或对数似然函数的极大值点  $\hat{\theta}_L$

$$L(\hat{\theta}_L; x_1, \dots, x_n) = \max_{\theta \in \Theta} L(\theta; x_1, \dots, x_n)$$

$$\ln L(\hat{\theta}_L; x_1, \dots, x_n) = \max_{\theta \in \Theta} \ln L(\theta; x_1, \dots, x_n)$$



# 求函数极大值的常用方法

## 1. 驻点法：求似然函数或对数似然函数的驻点

一阶导数为0，二阶导数小于0的点为函数的极大值点

$$\frac{dL(\theta)}{d\theta}\Big|_{\hat{\theta}} = 0, \frac{d^2L(\theta)}{d\theta^2}\Big|_{\hat{\theta}} < 0 \quad \frac{d\ln L(\theta)}{d\theta}\Big|_{\hat{\theta}} = 0, \frac{d^2 \ln L(\theta)}{d\theta^2}\Big|_{\hat{\theta}} < 0$$

若  $\theta$  是向量，上述方程必须用方程组代替。

## 2. 分析似然函数的单独性

如果似然函数是单调函数，则在区间端点处取到极值



例5 设总体  $X \sim N(\mu, \sigma^2)$ ,  $\mu, \sigma^2$  未知.  $x_1, \dots, x_n$

是来自  $X$  的样本值, 试求  $\mu, \sigma^2$  的最大似然估计量.

解:  $X$  的概率密度为  $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$ ,  $-\infty < x < \infty$

$$\text{似然函数为 } L(\mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x_i-\mu)^2}{2\sigma^2}}$$

$$= (2\pi)^{-n/2} (\sigma^2)^{-n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right]$$

$$\text{于是 } \ln L = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

$$\text{令 } t = \sigma^2$$

$$t = \sigma^2$$

$$\frac{\partial}{\partial \sigma^2} \ln L = \frac{\partial}{\partial t} \ln L = -\frac{n}{2t} + \frac{1}{2t^2} \sum_{i=1}^n (x_i - \mu)^2 = 0$$



$$\ln L = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

$$\text{令 } \frac{\partial}{\partial \mu} \ln L = \frac{1}{\sigma^2} \left( \sum_{i=1}^n x_i - n\mu \right) = 0$$

$$\frac{\partial}{\partial \sigma^2} \ln L = -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 = 0$$

$$\text{解得 } \mu = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x} \quad \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

$\mu, \sigma^2$  的最大似然估计量为

$$\mu = \bar{X}, \quad \sigma^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$



例6 设 $X_1, X_2, \dots, X_n$ 是取自总体 $X$ 的一个样本

$$X \sim f(x) = \begin{cases} \theta x^{\theta-1}, & 0 < x < 1 \\ 0, & \text{其它} \end{cases} \quad \text{其中 } \theta > 0,$$

求  $\theta$  的极大似然估计.

解: 似然函数为

$$L(\theta) = \prod_{i=1}^n \theta x_i^{\theta-1} = \theta^n \left( \prod_{i=1}^n x_i \right)^{\theta-1} \quad \begin{matrix} (0 < x_i < 1) \\ 1 \leq i \leq n \end{matrix}$$

对数似然函数为  $\ln L(\theta) = n \ln \theta + (\theta - 1) \sum_{i=1}^n \ln x_i$

求导并令其为0  $\frac{d \ln L(\theta)}{d \theta} = \frac{n}{\theta} + \sum_{i=1}^n \ln x_i = 0$

得  $\theta^* = -n / \sum_{i=1}^n \ln x_i$  即为  $\theta$  的MLE.



例7 设 $X_1, X_2, \dots, X_n$ 是取自总体 $X$ 的一个样本

$$X \sim f(x) = \begin{cases} \frac{1}{\theta} e^{-(x-\mu)/\theta}, & x \geq \mu \\ 0, & \text{其它} \end{cases} \quad \theta, \mu \text{ 为未知参数}$$

其中 $\theta > 0$ , 求 $\theta, \mu$ 的最大似然估计.

解: 似然函数为

$$\begin{aligned} L(\theta, \mu) &= \prod_{i=1}^n \frac{1}{\theta} e^{-(x_i - \mu)/\theta}, \quad x_i \geq \mu \quad i=1, 2, \dots, n \\ &= \frac{1}{\theta^n} e^{-\frac{1}{\theta} \sum_{i=1}^n (x_i - \mu)}, \quad \min x_i \geq \mu \end{aligned}$$

对数似然函数为  $\ln L(\theta, \mu) = -n \ln \theta - \frac{1}{\theta} \sum_{i=1}^n (x_i - \mu)$



对数似然

ln

用求导方法无法最终确定  $\theta$ 、 $\mu$ ，  
利用函数的单调性来求。

对  $\theta$ 、 $\mu$  分别求偏导并令其为0，

$$\frac{\partial \ln L(\theta, \mu)}{\partial \theta} = -\frac{n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n (x_i - \mu) = 0 \quad (1)$$

$$\frac{\partial \ln L(\theta, \mu)}{\partial \mu} = \frac{n}{\theta} > 0 \quad (2)$$

由(1)得 
$$\theta = \frac{1}{n} \sum_{i=1}^n x_i - \mu$$



$$L(\theta, \mu) = \begin{cases} \frac{1}{\theta^n} e^{-\frac{1}{\theta} \sum_{i=1}^n (x_i - \mu)} & , \quad \min x_i \geq \mu \\ 0, & \text{其它} \end{cases}$$

对  $\mu \leq \min x_i$ ,  $L(\theta, \mu) > 0$ , 且是  $\mu$  的增函数  
 $\mu$  取其它值时,  $L(\theta, \mu) = 0$ .

故使  $L(\theta, \mu)$  达到最大的  $\mu$ , 即  $\mu$  的MLE是

$$\mu^* = \min_{1 \leq i \leq n} x_i$$

于是

$$\theta^* = \frac{1}{n} \sum_{i=1}^n x_i - \mu^*$$

即  $\theta^*, \mu^*$  为  $\theta, \mu$  的MLE.



例8 设总体 $X$ 在 $[a, b]$ 上服从均匀分布,  $a, b$ 是未知参数,  $x_1, x_2, \dots, x_n$ 为样本值, 求 $a, b$ 的极大似然估计量。

解: 令  $x_{(1)} = \min \{x_1, x_2, \dots, x_n\}$

$$x_{(n)} = \max \{x_1, x_2, \dots, x_n\}$$

则似然函数为  $L(a, b) = \frac{1}{(b-a)^n} \quad a \leq x_{(1)}, b \geq x_{(n)}$

对于满足条件  $a \leq x_{(1)}, x_{(n)} \leq b$  的任意 $a, b$ 有

$$L(a, b) = \frac{1}{(b-a)^n} \leq \frac{1}{(x_{(n)} - x_{(1)})^n}$$



$$b - a \geq x_{(n)} - x_{(1)} > 0$$



即  $L(a, b)$  在  $a = x_{(1)}, b = x_{(n)}$  时达到最大值,

故  $\mathbf{a}, \mathbf{b}$  的极大似然估计值为

$$\hat{a} = x_{(1)} = \min_{1 \leq i \leq n} x_i, \quad \hat{b} = x_{(n)} = \max_{1 \leq i \leq n} x_i$$

$\mathbf{a}, \mathbf{b}$  的极大似然估计量为

$$\hat{a} = X_{(1)} = \min_{1 \leq i \leq n} X_i, \quad \hat{b} = X_{(n)} = \max_{1 \leq i \leq n} X_i$$



## § 7.2 估计量的评选标准

例 设总体  $X \sim U(a, b)$ ,  $a, b$  未知

$$\hat{a}_{\text{矩}} = \bar{X} - \sqrt{3B_2} \quad \hat{b}_{\text{矩}} = \bar{X} + \sqrt{3B_2}$$

$$\hat{a}_{\text{MLE}} = X_{(1)}, \quad \hat{b}_{\text{MLE}} = X_{(n)}$$

需要讨论以下几个问题：

- (1) 我们希望一个“好的”估计量具有什么特性？
- (2) 怎样决定一个估计量是否比另一个估计量“好”？
- (3) 如何求得合理的估计量？

常用的几条标准是：

1. 无偏性
2. 有效性
3. 均方误差
4. 相合性

# 一、无偏性

定义1. 设  $\hat{\theta}(X_1, \dots, X_n)$  是未知参数  $\theta$  的估计量, 若

$E(\hat{\theta}) = \theta$  则称  $\hat{\theta}$  为  $\theta$  的无偏估计.

例1 设总体  $X$  的  $k$  阶矩  $\mu_k = E(X^k)$  存在  
 $(X_1, X_2, \dots, X_n)$  是总体  $X$  的样本,

证明:  $A_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  是  $\mu_k$  的无偏估计.

证 由于  $E(X_i^k) = \mu_k \quad i = 1, 2, \dots, n$  因而

$$E(A_k) = E\left(\frac{1}{n} \sum_{i=1}^n X_i^k\right) = \frac{1}{n} \sum_{i=1}^n E(X_i^k) = \frac{1}{n} \cdot n \cdot \mu_k = \mu_k$$

## 特别地

(1) 样本均值  $\bar{X}$  是总体期望  $E(X)$  的无偏估计

(2) 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.

**例2** 设总体  $X$  的期望与方差存在,  $X$  的样本为

$(X_1, X_2, \dots, X_n)$  ( $n > 1$ ). 证明

(1)  $S_n^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$  不是  $D(X)$  的无偏估计;

(2)  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  是  $D(X)$  的无偏估计.

证 前已证  $\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2$

$$E(X_i) = E(X) = \mu, \quad D(X_i) = D(X) = \sigma^2$$

$$E(\bar{X}) = E(X) = \mu, \quad D(\bar{X}) = \frac{\sigma^2}{n}$$

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

$$= (\sigma^2 + \mu^2) - \left(\frac{\sigma^2}{n} + \mu^2\right) = \frac{n-1}{n} \sigma^2 \neq \sigma^2$$

故  $E\left(\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2\right) = \sigma^2$

**例3** 设总体  $X$  的密度函数为

$$f(x; \theta) = \begin{cases} \frac{1}{\theta} e^{-\frac{x}{\theta}} & x > 0, \\ 0 & x \leq 0 \end{cases} \quad \theta > 0 \text{ 为常数}$$

$(X_1, X_2, \dots, X_n)$  为  $X$  的一个样本

证明  $\bar{X}$  与  $n \min\{X_1, X_2, \dots, X_n\}$  都是  $\theta$  的无偏估计

**证**  $X \sim \text{Exp}\left(\frac{1}{\theta}\right) \quad E(X) = \theta$

故  $E(\bar{X}) = E(X) = \theta$

$\bar{X}$  是  $\theta$  的无偏估计量.

$$\text{令 } Z = \min\{X_1, X_2, \dots, X_n\}$$

$$\begin{aligned} F_Z(z) &= 1 - P(X_1 > z, X_2 > z, \dots, X_n > z) \\ &= 1 - P(X_1 > z)P(X_2 > z) \cdots P(X_n > z) \\ &= 1 - \prod_{i=1}^n (1 - P(X_i \leq z)) = \begin{cases} 0 & z < 0 \\ 1 - e^{-\frac{nz}{\theta}} & z \geq 0 \end{cases} \end{aligned}$$

$$f_Z(z) = \begin{cases} 0 & z < 0 \\ \frac{n}{\theta} e^{-\frac{nz}{\theta}} & z \geq 0 \end{cases}$$

$$\text{即 } Z \sim \text{Exp}\left(\frac{n}{\theta}\right) \quad E(Z) = \frac{\theta}{n} \quad E(nZ) = \theta$$

故  $nZ$  是  $\theta$  的无偏估计量.

**例4** 设总体  $X \sim U(0, \theta)$ , 其密度函数为

$$f(x; \theta) = \begin{cases} \frac{1}{\theta} & 0 < x < \theta, \\ 0 & \text{其他} \end{cases} \quad \theta > 0 \text{ 为常数}$$

$(X_1, X_2, \dots, X_n)$  为  $X$  的一个样本

$\theta$  的矩估计量为  $\hat{\theta}_1 = 2\bar{X}$

$\theta$  的极大似然估计量为  $\hat{\theta}_2 = X_{(n)} = \max\{X_1, X_2, \dots, X_n\}$

证明  $\hat{\theta}_1 = 2\bar{X}$  与  $\hat{\theta}_2 = \frac{n+1}{n} X_{(n)}$  都是  $\theta$  的无偏估计

证明:  $E(\hat{\theta}_1) = 2 E(\bar{X}) = 2 \times \frac{\theta}{2} = \theta$

$\therefore \hat{\theta}_1 = 2\bar{X}$  是  $\theta$  的无偏估计量.

$$\hat{\theta}_2 = X_{(n)} = \max\{X_1, X_2, \dots, X_n\} \quad F_{x_{(n)}}(\mathbf{x}) = [F(x)]^n$$

$$\therefore f_{x_{(n)}}(\mathbf{x}) = F'_{x_{(n)}}(\mathbf{x}) = nf(x)[F(x)]^{n-1} = \begin{cases} \frac{n}{\theta} \left(\frac{x}{\theta}\right)^{n-1} & 0 < x < \theta \\ 0 & \text{其他} \end{cases}$$

$$E\hat{\theta}_2 = EX_{(n)} = \int_{-\infty}^{\infty} xf_{x_{(n)}}(x)dx = \int_0^{\theta} n \left(\frac{x}{\theta}\right)^n dx = \frac{n}{n+1}\theta$$

$$\therefore E\hat{\theta} = \frac{n+1}{n} EX_{(n)} = \theta$$

$\therefore \hat{\theta} = \frac{n+1}{n} X_{(n)}$  是  $\theta$  的无偏估计量.

## 2、有效性

定义 设  $\hat{\theta}_1 = \theta_1(X_1, X_2, \dots, X_n)$

$$\hat{\theta}_2 = \theta_2(X_1, X_2, \dots, X_n)$$

都是总体参数  $\theta$  的无偏估计量, 且

$$D(\hat{\theta}_1) < D(\hat{\theta}_2)$$

则称  $\hat{\theta}_1$  比  $\hat{\theta}_2$  更有效.

**例5** 设总体  $X$  的密度函数为

$$f(x; \theta) = \begin{cases} \frac{1}{\theta} e^{-\frac{x}{\theta}} & x > 0, \\ 0 & x \leq 0 \end{cases} \quad \theta > 0 \text{ 为常数}$$

由例3可知,  $\bar{X}$  与  $n \min\{X_1, X_2, \dots, X_n\}$  都是  $\theta$  的无偏估计量, 问哪个估计量更有效?

**解**  $\text{Var}(\bar{X}) = \frac{\theta^2}{n}$ ,  $\text{Var}(n \min\{X_1, X_2, \dots, X_n\}) = \theta^2$

所以,  $\bar{X}$  比  $n \min\{X_1, X_2, \dots, X_n\}$  更有效.

**例6** 设总体  $X \sim U(0, \theta)$ , 其密度函数为

$$f(x; \theta) = \begin{cases} \frac{1}{\theta} & 0 < x < \theta, \\ 0 & \text{其他} \end{cases} \quad \theta > 0 \text{ 为常数}$$

$(X_1, X_2, \dots, X_n)$  为  $X$  的一个样本

$\hat{\theta}_1 = 2\bar{X}$  与  $\hat{\theta} = \frac{n+1}{n}X_{(n)}$  都是  $\theta$  的无偏估计

问哪一个更有效?

解:  $D(\hat{\theta}_1) = 4 D(\bar{X}) = 4 \times \frac{\theta^2}{12n} = \frac{\theta^2}{3n}$       当  $n > 2$  时  $D(\hat{\theta}) < D(\hat{\theta}_1)$

$$D(\hat{\theta}) = D\left(\frac{n+1}{n}X_{(n)}\right) = \frac{\theta^2}{n(n+2)} \quad \therefore \hat{\theta} \text{ 较 } \hat{\theta}_1 \text{ 有效。}$$

**例7** 设总体  $X$ , 且  $E(X)=\mu$ ,  $D(X)=\sigma^2$

$(X_1, X_2, \dots, X_n)$  为总体  $X$  的一个样本

(1) 设常数  $c_i \neq \frac{1}{n} \quad i=1, 2, \dots, n. \quad \sum_{i=1}^n c_i = 1.$

证明  $\hat{\mu}_1 = \sum_{i=1}^n c_i X_i$  是  $\mu$  的无偏估计

(2) 证明  $\hat{\mu} = \bar{X}$  比  $\hat{\mu}_1 = \sum_{i=1}^n c_i X_i$  更有效

**证** (1)  $E(\hat{\mu}_1) = \sum_{i=1}^n c_i E(X_i) = \sum_{i=1}^n c_i \mu = \mu$

$$(2) \quad D(\hat{\mu}_1) = \sum_{i=1}^n c_i^2 D(X_i) = \sigma^2 \sum_{i=1}^n c_i^2$$

$$\text{而} \quad 1 = \left( \sum_{i=1}^n c_i \right)^2 = \sum_{i=1}^n c_i^2 + 2 \sum_{1 \leq i < j \leq n} c_i c_j$$

$$< \sum_{i=1}^n c_i^2 + \sum_{1 \leq i < j \leq n} (c_i^2 + c_j^2) \leq n \sum_{i=1}^n c_i^2$$

$$\rightarrow \sum_{i=1}^n c_i^2 > \frac{1}{n} \rightarrow D(\hat{\mu}) = \frac{1}{n} \sigma^2 < D(\hat{\mu}_1)$$

**结论**

算术均值比加权均值更有效。

例如  $X \sim N(\mu, \sigma^2)$ ,  $(X_1, X_2)$  是一样本.

$$\hat{\mu}_1 = \frac{2}{3}X_1 + \frac{1}{3}X_2$$

$$\hat{\mu}_2 = \frac{1}{4}X_1 + \frac{3}{4}X_2$$

$$\hat{\mu}_3 = \frac{1}{2}X_1 + \frac{1}{2}X_2$$

都是  $\mu$  的无偏估计量

由例7(2) 知  $\hat{\mu}_3$  最有效.

### 3、均方误差

目的：对有偏估计进行评价

均方误差： $MSE(\hat{\theta}) = E(\hat{\theta} - \theta)^2$

$$\begin{aligned} MSE(\hat{\theta}) &= E[(\hat{\theta} - E\hat{\theta}) + (E\hat{\theta} - \theta)]^2 \\ &= E(\hat{\theta} - E\hat{\theta})^2 + (E\hat{\theta} - \theta)^2 \\ &\quad + 2E[(\hat{\theta} - E\hat{\theta})(E\hat{\theta} - \theta)] \\ &= Var(\hat{\theta}) + (E\hat{\theta} - \theta)^2. \end{aligned}$$

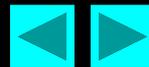
## 4、相合性

定义 设  $\hat{\theta}_n = \hat{\theta}_n(X_1, X_2, \dots, X_n)$  是总体参数  $\theta$  的估计量. 若对于任意的  $\theta \in \Theta$ , 当  $n \rightarrow \infty$  时,  $\hat{\theta}_n$  依概率收敛于  $\theta$ , 即  $\forall \varepsilon > 0$ ,

$$\lim_{n \rightarrow \infty} P(|\hat{\theta}_n - \theta| \geq \varepsilon) = 0$$

则称  $\hat{\theta}_n$  是总体参数  $\theta$  的一致(或相合)估计量.

相合估计量仅在样本容量  $n$  足够大时, 才显示其优越性.



## 由辛钦定理

若总体  $X$  的数学期望  $E(X) = \mu$  有限, 则有

$$A_k = \frac{1}{n} \sum_{i=1}^n X_i^k \xrightarrow{P} E(X^k) = \mu_k \quad (k = 1, 2, \dots)$$

$$g(A_1, A_2, \dots, A_k) \xrightarrow{P} g(\mu_1, \mu_2, \dots, \mu_k)$$

故

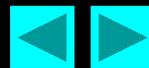
$A_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  为  $E(X^k) = \mu_k \quad (k = 1, 2, \dots)$  的相合估计量。

$g(A_1, A_2, \dots, A_k)$  为  $g(\mu_1, \mu_2, \dots, \mu_k)$  的相合估计量。

## 关于相合性的两个常用结论

1. 样本  $k$  阶原点矩是总体  $k$  阶原点矩的相合估计. } 由大数定律证明

2. 设  $\hat{\theta}_n$  是  $\theta$  的无偏估计量, 且  $\lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$  则  $\hat{\theta}_n$  是  $\theta$  的相合估计. } 用切比雪夫不等式证明



**例8**  $X \sim f(x; \theta) = \begin{cases} \frac{1}{\theta} e^{-\frac{x}{\theta}} & x > 0, \\ 0 & x \leq 0 \end{cases} \quad \theta > 0 \text{ 为常数}$

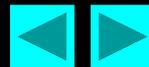
则  $\bar{X}$  是  $\theta$  的无偏、相合估计.

**证**  $E\bar{X} = \theta$

$$\lim_{n \rightarrow \infty} D(\bar{X}) = \lim_{n \rightarrow \infty} \frac{\theta^2}{n} = 0$$

$$\therefore \bar{X} \xrightarrow{P} \theta$$

所以  $\bar{X}$  是  $\theta$  的相合估计, 证毕.



设总体  $X \sim N(0, \sigma^2)$ , 它的概率密度函数为 ↵

$$f(x; \sigma^2) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{x^2}{2\sigma^2}\right), \text{ 其中 } \sigma^2 \text{ 为未知参数. } \leftarrow$$

设  $X_1, X_2, \dots, X_n$  是来自总体  $X$  的一个样本 ↵

(1) 求  $\sigma^2$  的极大似然估计量  $\hat{\sigma}_1^2$ ;      (2) 求  $\sigma^2$  的矩估计量  $\hat{\sigma}_2^2$ . ↵

(3) 证明  $\hat{\sigma}_1^2$  是  $\sigma^2$  的无偏、相合估计; ↵

(1) 求  $\sigma^2$  的极大似然估计量  $\hat{\sigma}_1^2$ ;

(2) 求  $\sigma^2$  的矩估计量  $\hat{\sigma}_2^2$ .

(3) 证明  $\hat{\sigma}_1^2$  是  $\sigma^2$  的无偏、相合估计;

$$\begin{aligned} \text{1) } L(\sigma^2) &= \prod_{i=1}^n f(x_i, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x_i^2}{2\sigma^2}} \\ &= \frac{1}{(2\pi)^{\frac{n}{2}} (\sigma^2)^{\frac{n}{2}}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2} \end{aligned}$$

$$\ln L(\sigma^2) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2$$

$$\frac{d \ln L(\sigma^2)}{d\sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n x_i^2 = 0$$

$$\therefore \hat{\sigma}_1^2 = \frac{1}{n} \sum_{i=1}^n x_i^2$$

$$\text{2) } E(\hat{\sigma}_1^2) = \frac{1}{n} \sum_{i=1}^n E(x_i^2) = \frac{1}{n} \sum_{i=1}^n \sigma^2 = \sigma^2$$

$\therefore \hat{\sigma}_1^2$  是  $\sigma^2$  的无偏估计

由辛钦大数定律  $\hat{\sigma}_1^2 = \hat{\sigma}_2 = \frac{1}{n} \sum_{i=1}^n x_i^2 \xrightarrow{P} E(x^2) = \sigma^2 \therefore \hat{\sigma}_1^2$  是  $\sigma^2$  的相合估计

$$\text{1) } E(X) = 0$$

$$E(X^2) = \int_{-\infty}^{+\infty} x^2 \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} dx$$

$$= \sigma^2 = \mu_2$$

$\therefore \sigma^2$  的矩估计量为

$$\hat{\sigma}_2^2 = A_2 = \frac{1}{n} \sum_{i=1}^n x_i^2$$