

---

## 第六章：参数估计

6.1	点估计 . . . . .	2
6.1.1	矩估计方法 . . . . .	2
6.1.2	最大似然估计方法 . . . . .	7
6.1.3	点估计的优良准则 . . . . .	20

---

### 参数估计问题:

- 总体:  $X \sim f_{\theta}(x), f$  形式已知,  $\theta = (\theta_1, \dots, \theta_k)$  为未知参数
- 样本:  $X_1, \dots, X_n$

利用样本对参数  $\theta$  的作出估计或估计它们的某个已知函数  $g(\theta)$ .

- **点估计**: 用样本的一个函数  $T(X_1, \dots, X_n)$  去估计  $g(\theta)$
- **区间估计**: 用一个区间 (区域) 去估计  $g(\theta)$

---

## 6.1 点估计

根据样本  $X_1, \dots, X_n$  来估计参数  $\theta$ , 就是要构造适当的统计量  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ . 当有了样本  $X_1, \dots, X_n$  的值后, 就代入  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$  中算出一个值, 用来作为  $\theta$  的估计值. 为这样特定目的而构造的统计量  $\hat{\theta}$  叫做  $\theta$  的**估计量**. 由于参数  $\theta$  是数轴上的一个点, 用  $\hat{\theta}$  估计  $\theta$ , 等于用一个点去估计另一个点, 所以这样的估计叫做**点估计**.

求点估计的方法有多种, 下面介绍两种点估计方法:

### 6.1.1 矩估计方法

矩方法追溯到 19 世纪的**Karl Pearson**. 矩方法是基于一种简单的“替换”思想建立起来的一种估计方法. 其基本思想是用样本矩估计总体矩. 由大数律, 如果未知参数和总体的某个 (些) 矩有关系, 我们很自然的来构造未知参数的估计。

---

回忆一下以前关于矩的记法:

$$\text{样本 } k \text{ 阶矩: } a_k = \frac{1}{n} \sum_{i=1}^n X_i^k \quad m_k = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k$$

$$\text{总体 } k \text{ 阶矩: } \alpha_k = EX^k \quad \mu_k = E(X - EX)^k$$

因此在  $k$  阶矩存在的情况下, 根据大数律有

$$a_k \xrightarrow{P} \alpha_k, \quad m_k \xrightarrow{P} \mu_k$$

从而我们可以使用  $a_k, m_k$  分别估计  $\alpha_k, \mu_k$ , 进而得到  $\theta$  的估计. 介绍如下: 假设总体  $X$  包含  $k$  个未知参数  $\theta = (\theta_1, \dots, \theta_k)$ , 由方程组

$$\begin{cases} \alpha_1 = f_1(\theta_1, \dots, \theta_k) \\ \quad \quad \quad \vdots \\ \alpha_k = f_k(\theta_1, \dots, \theta_k) \end{cases}$$

---

反解得到

$$\begin{cases} \theta_1 = g_1(\alpha_1, \dots, \alpha_k) \\ \vdots \\ \theta_k = g_k(\alpha_1, \dots, \alpha_k) \end{cases}$$

将其中的总体矩用相应的样本矩代替，则我们可以得到参数  $\theta_1, \dots, \theta_k$  的一个估计：

$$\begin{cases} \hat{\theta}_1 = g_1(a_1, \dots, a_k) \\ \vdots \\ \hat{\theta}_k = g_k(a_1, \dots, a_k) \end{cases}$$

若要估计参数  $\theta_1, \dots, \theta_k$  的某函数  $g(\theta_1, \dots, \theta_k)$ ，则用  $g(\hat{\theta}_1, \dots, \hat{\theta}_k)$  去估计它。

这里我们用的都是原点矩  $\alpha_k$ ，当然也可以使用中心矩  $\mu_k$ ，或者两个都使用。在这种情况下，只需要把相应的总体矩换成样本矩。我们称这种估计方法为矩估计法，得到的估计量称为矩估计量。**矩估计方法应用的原则是：能用低阶矩处理的就不用高阶矩。**

---

矩估计法的优点是简单易行, 有些情况下不需要事先知道总体是什么分布. 缺点是, 当总体类型已知时, 没有充分利用分布提供的信息. 一般场合下, 矩估计量不具有唯一性.

投掷一枚硬币, 为了解正面出现的概率, 现独立重复的投掷  $n$  次, 用  $X_1, \dots, X_n$  表示投掷结果. 显然此时总体  $X$  的分布为  $B(1, p)$ ,  $p$  为感兴趣的量. 而  $X_1, \dots, X_n$  为样本, 则求参数  $p$  的矩估计量。

↑Example

↓Example

**解:** 由于  $EX = p$ , 而样本均值  $\bar{X}$  收敛到总体均值  $EX$ , 因此  $p$  的一个矩估计量为  $\hat{p} = \bar{X}$ .

---

为考察某种考试成绩分布情况, 使用正态分布  $N(a, \sigma^2)$  来作为总体  $X$  的分布. 现在从中随机调查  $n$  个人, 即样本为  $X_1, \dots, X_n$ . 试求参数  $a, \sigma^2$  的矩估计量。

↑Example

↓Example

---

## 6.1.2 最大似然估计方法

最大似然方法到目前为止应用最广的的点估计方法. 这种方法是基于如下的看法:

设样本  $X = (X_1, \dots, X_n)$  有概率函数

$$f(x; \theta) = f(x; \theta_1, \dots, \theta_k)$$

这里参数  $\theta = (\theta_1, \dots, \theta_k) \in \Theta$ ,  $x = (x_1, \dots, x_n)$  为样本  $X$  的观察值. 当固定  $x$  时把  $f(x; \theta)$  看成为  $\theta$  的函数, 称为似然函数, 常记为  $L(x; \theta)$  或  $L(\theta)$ .

Definition

当固定参数  $\theta$  时,  $f(x; \theta)$  可以看成是得到样本观察值  $x$  的可能性, 这样, 当把参数  $\theta$  看成变动时, 也就得到“在不同的  $\theta$  值下能观察到  $x$  的可能性大小, 即  $L(x; \theta)$ ”; 由于我们已经观察到了  $x$ , 所以



---

使得能观察到  $x$  的可能性  $L(x; \theta)$  最大的  $\theta$  值, 看起来应该最像未知的  $\theta$ 。这个  $\theta$  的值即称为  $\theta$  最大似然估计值(看上去最有可能的)。我们先看一个例子:

从鱼池里随机捕捞 500 条鱼, 做好记号后重新放入鱼池中, 待充分混合后再捕捞 1000 条鱼, 结果发现其中有 72 条带有记号. 试问鱼池中可能有多少条鱼.

↑Example

↓Example



---

现给出最大似然估计的一般性定义:

设  $X = (X_1, \dots, X_n)$  为从具有概率函数  $f_\theta(x)$  的总体中抽取的样本,  $\theta$  为未知参数或者参数向量.  $x = (x_1, \dots, x_n)$  为样本的观察值. 若在给定  $x$  时, 值  $\hat{\theta} = \hat{\theta}(x)$  满足下式

$$L(\hat{\theta}) = \max_{\theta \in \Theta} L(x; \theta)$$

Definition

则称  $\hat{\theta}$  为参数  $\theta$  的最大似然估计值, 而  $\hat{\theta}(X)$  称为参数  $\theta$  的最大似然估计量. 若待估参数为  $\theta$  的函数  $g(\theta)$ , 则  $g(\theta)$  的最大似然估计量为  $g(\hat{\theta})$ .

---

求最大似然估计值相当于求似然函数的最大值。在简单样本的情况下,

$$L(x; \theta) = \prod_{i=1}^n f_{\theta}(x_i)$$

而把似然函数的对数  $l(\theta) = \log L(\theta)$  称为对数似然函数 (这是由于在一些情况下, 处理对数似然函数更方便)

当似然函数对变量  $\theta$  单调时, 我们可以容易得到其最大值点. 反之当似然函数为非单调函数且对变量  $\theta$  可微分时, 我们可以求其驻点: 令

$$\frac{dl(\theta)}{d\theta} = 0 \quad (\text{或者} \frac{dL(\theta)}{d\theta} = 0)$$

当  $\theta$  为多维时, 比如  $\theta = (\theta_1, \dots, \theta_k)$  时令

$$\frac{\partial l(\theta)}{\partial \theta_i} = 0 \quad (\text{或者} \frac{\partial L(\theta)}{\partial \theta_i} = 0) \quad i = 1, \dots, k$$

然后判断此驻点是否是最大值点。

---

设  $X_1, \dots, X_n$  为从总体  $X \sim N(a, \sigma^2)$  中抽取的样本, 求参数  $a, \sigma^2$  的最大似然估计量。

↑Example

↓Example

解:

---

设总体  $X$  服从  $[a, b]$  上的均匀分布,  $a < b$ , 求参数  $a, b$  的最大似然估计.

↑Example

↓Example

解:

---

设  $X_1, \dots, X_n$  为从具有如下形式密度的总体中抽取的样本:

↑Example

$$f(x; a, b) = \begin{cases} \frac{1}{b} \exp\{-\frac{x-a}{b}\} & , x > a \\ 0 & , x \leq a \end{cases}$$

求参数  $a, b$  的最大似然估计量.

↓Example

解:

---

解是最大值点。从而得到  $a, b$  的最大似然估计量:

$$\begin{cases} \hat{a} = X_{(1)} \\ \hat{b} = \frac{1}{n} \sum_{i=1}^n (X_i - X_{(1)}). \end{cases}$$



---

设总体  $X_1, \dots, X_n$  服从 0-1 分布  $B(1, p)$ ,  $0 < p < 1$ , 求参数  $p$  的最大似然估计.

↑Example

↓Example

解:

---

设总体  $X_1, \dots, X_n$  服从柯西分布  $f(x) = \frac{1}{\pi} \frac{1}{1+(x-\theta)^2}$ ,  $x \in R, \theta \in R$ , 求参数  $\theta$  的最大似然估计.

↑Example

↓Example

解:

---

设  $X_1, \dots, X_n$  为从如下分布中抽取的简单样本, 求  $\theta$  的最大似然估计.

↑Example

$$f(x) = \frac{1}{x!(2-x)!} [\theta^x (1-\theta)^{2-x} + \theta^{2-x} (1-\theta)^x], \quad x = 0, 1, 2; \quad \theta \in (0, \frac{1}{2})$$

↓Example

解:

---

再记  $n_i = \#\{X_1, \dots, X_n \text{ 中等于 } i \text{ 的个数}\}$ ,  $i = 0, 1, 2$ , 则得到似然函数为

$$L(\eta) = \left(\frac{1}{2}(1-\eta)\right)^{n_0} \eta^{n_1} \left(\frac{1}{2}(1-\eta)\right)^{n_2} = \left(\frac{1}{2}(1-\eta)\right)^{n-n_1} \eta^{n_1}$$

求解并注意  $\eta$  的上界即得到  $\eta$  的最大似然估计为

$$\hat{\eta} = \min\left\{\frac{n_1}{n}, \frac{1}{2}\right\}$$

再由  $\theta = \frac{1-\sqrt{1-2\eta}}{2}$  得到  $\theta$  的最大似然估计为

$$\hat{\theta} = \frac{1 - \sqrt{1 - 2\hat{\eta}}}{2}$$

---

### 6.1.3 点估计的优良准则

我们看到对同一个参数，有多个不同的估计量，因此，评选不同估计量的优劣性是需要考虑的。

#### 1. 相合性

设总体分布依赖于参数  $\theta_1, \dots, \theta_k$ ,  $g(\theta_1, \dots, \theta_k)$  是待估参数函数。设  $X_1, \dots, X_n$  为自该总体中抽取的样本,  $T(X_1, \dots, X_n)$  为  $g(\theta_1, \dots, \theta_k)$  的一个估计量, 如果对任意的  $\epsilon > 0$  和  $\theta_1, \dots, \theta_k$  的一切可能值都有

$$\lim_{n \rightarrow \infty} P_{\theta_1, \dots, \theta_k} (|T(X_1, \dots, X_n) - g(\theta_1, \dots, \theta_k)| \geq \epsilon) = 0$$

我们则称  $T(X_1, \dots, X_n)$  为  $g(\theta_1, \dots, \theta_k)$  的一个 (弱)相合估计量 (Consistent Estimator)。

相合性是对一个估计量的最基本的要求, 如果一个估计量没有相合性, 那么无论样本大小多大, 我们也不能把未知参数估计到任意预定的精度。这种估计量显然是不可取的。

---

矩估计量是满足相合性的，最大似然估计量在很一般的条件下也是满足相合性的。

## 2. 无偏性

设  $\hat{g}(X_1, \dots, X_n)$  为待估参数函数  $g(\theta)$  的一个估计量，若

$$E\hat{g}(X_1, \dots, X_n) = g(\theta)$$

则称  $\hat{g}(X_1, \dots, X_n)$  为  $g(\theta)$  的**无偏估计量 (Unbiased Estimator)**。无偏性的实际意义就是无系统误差。因此在有多个估计量可供选择时，我们优先考虑无偏估计量。

很多时候我们得到的估计量是有偏，例如正态总体的方差  $\sigma^2$  的最大似然估计量  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$  是有偏的， $E\hat{\sigma}^2 = \frac{n-1}{n}\sigma^2$ 。若以  $\frac{n}{n-1}$  乘以  $\hat{\sigma}^2$ ，所得到的估计量就是无偏的。这种方法称为修正。

若某一参数存在多个无偏估计时，如何选择使用哪个估计量？人们又在无偏性的基础上增加了对方差的要求。

---

### 3. 有效性

设  $\hat{g}_1(X_1, \dots, X_n)$  和  $\hat{g}_2(X_1, \dots, X_n)$  为待估参数函数  $g(\theta)$  的两个不同的无偏估计量, 若对任意的  $\theta \in \Theta$ , 有

$$\text{Var}(\hat{g}_1(X_1, \dots, X_n)) \leq \text{Var}(\hat{g}_2(X_1, \dots, X_n))$$

而且至少对某个  $\theta_0 \in \Theta$  使得严格不等式成立。则称  $\hat{g}_1$  较  $\hat{g}_2$  有效。

---

设  $X_1, \dots, X_n$  为从如下分布中抽取的简单样本，试证明样本方差为总体方差的无偏估计.

↑Example

↓Example

证:



---

设总体  $X$  服从  $(0, \theta)$  上的均匀分布,  $0 < \theta$ , 求参数  $\theta$  的最大似然估计是否为无偏估计.

↑Example

↓Example

解:

设  $X_1, \dots, X_n$  来自均值为  $\mu$ , 方差为  $\sigma^2$  的总体分布的简单样本,  $\omega_1, \dots, \omega_n$  为已知的非负权值, 且满足  $\sum \omega_i = 1$ , 试比较  $\mu$  的两个估计估计  $\bar{X}$  和  $\sum_{i=1}^n \omega_i X_i$ .

↑Example

↓Example

$$E\bar{X} = E\frac{1}{n}\sum_k X_k = \frac{1}{n}\sum_k EX_k = \mu$$

解:  $E\sum \omega_i X_i = \sum \omega_i EX_i = \mu$

$$\left\{ \begin{aligned} \text{Var } \bar{X} &= \text{Var} &&= \frac{1}{n} \sigma^2 \\ &&&= \sigma^2 \sum_i \omega_i^2 \end{aligned} \right.$$

---

#### 4. 渐近正态性

估计量是样本  $X_1, \dots, X_n$  的函数，其确切的分布一般不是容易得到。但是，许多形式很复杂的统计量（未必是和），当  $n$  很大时，其分布都渐近于正态分布，这个性质称为统计量的“渐近正态性”。

无偏性和有效性都是对固定的样本大小  $n$  而言的，这种性质称为估计量的“小样本性质”，而相合性和渐近正态性都是考虑在样本大小趋于无穷时的性质，这种性质称为“大样本性质”。

$$\hat{\theta}_M = \frac{1-\bar{X}}{5} \quad \hat{\theta}_L = \frac{n-n_3}{3n}$$

设从总体

↑ Example

	$n_0$	$n_1$	$n_2$	$n_3$
X	0	1	2	3
P	$\theta/2$	$\theta$	$3\theta/2$	$1-3\theta$

$$E(\hat{\theta}_M) = \theta$$

$$E(\hat{\theta}_L) = \theta$$

抽取的一个简单样本  $X_1, \dots, X_{10}$  的观察值为  $(0, 3, 1, 1, 0, 2, 0, 0, 3, 0)$ ,

- (1) 求  $\theta$  的矩估计量  $\hat{\theta}_M$  和最大似然估计量  $\hat{\theta}_L$ , 并求出估计值。
- (2) 上述估计量是否为无偏的? 若不是, 请作修正。
- (3) 比较修正后的两个估计量, 指出那个更有效。

↓ Example

$$\text{Var}(X) = E(X^2) - E^2(X) = 10\theta - 25\theta^2$$

$$\text{Var}(\hat{\theta}_M) = \text{Var}\left(\frac{\bar{X}}{5}\right) = \frac{1}{25} \frac{\text{Var}(X)}{n} = \frac{20 - 50\theta^2}{5n} \quad \text{Var}(\hat{\theta}_L) = \frac{1}{9n^2} \text{Var}(n_3) = \frac{(1-3\theta)3\theta}{9n^2} \quad (\text{作差})$$

由有效性的定义, 我们自然会问在一切可能的无偏估计里, 能否找到具有最小方差的无偏估计量? 如果存在这样的估计量, 我们称其为最小方差无偏估计量, 详细地可以参考课本。