

# Lec5: 点估计(二)

张伟平

September 29, 2009

## §1 极大似然估计

### 一、引言及定义

极大似然法是在参数分布族场合下常用的参数估计方法. 设有一参数分布族 $\mathcal{F} = \{F_\theta, \theta \in \Theta\}$ , 此处 $\Theta$ 为参数空间. 令 $\mathbf{X} = (X_1, \dots, X_n)$ 为从 $\mathcal{F}$ 中抽取的简单随机样本,  $f(\mathbf{x}, \theta) = f(x_1, \dots, x_n, \theta)$ 为样本 $\mathbf{X}$ 的概率函数. 即当总体分布为连续型时,  $f(\mathbf{x}, \theta)$ 表示样本 $\mathbf{X}$ 的密度函数; 当总体分布为离散形时,  $f(\mathbf{x}, \theta)$ 为样本 $\mathbf{X}$ 的概率分布, 即 $f(\mathbf{x}, \theta) = P_\theta(X_1 = x_1, \dots, X_n = x_n)$ . 首先引入似然函数的概念.

**定义 1.** 设 $f(\mathbf{x}, \theta) = f(x_1, \dots, x_n, \theta)$ 为样本 $\mathbf{X} = (X_1, \dots, X_n)$ 的概率函数. 当 $\mathbf{x}$ 固定时, 把 $f(\mathbf{x}, \theta)$ 看成 $\theta$ 的函数, 称为似然函数(*Likelihood function*), 记为

$$L(\theta, \mathbf{x}) = f(\mathbf{x}, \theta), \quad \theta \in \Theta, \quad \mathbf{x} \in \mathcal{X} \quad (1.1)$$

此处 $\Theta$ 为参数空间,  $\mathcal{X}$ 为样本空间. 称 $\log L(\theta, \mathbf{x})$ 为对数似然函数, 记为 $l(\theta, \mathbf{x})$ .

**注1.** 似然函数和概率函数是同一表达式(1.1), 但表示两种不同含意. 当把 $\theta$ 固定, 将其看成定义在样本空间 $\mathcal{X}$ 上的函数时, 称为概率函数; 当把 $\mathbf{x}$ 固定, 将其看成定义在参数空间 $\Theta$ 上的函数时, 称为似然函数. 这是两个不同的概念.

为解释极大似然原理, 考虑下列一个简单的实例.

**例1.** 设罐子里有许多黑球和红球. 假定已知它们的比例是 $1:3$ , 但不知道是黑球多还是红球多. 也就是说抽出一个黑球的概率或者是 $1/4$ 或者是 $3/4$ . 如果有放回地从罐子中抽 $n$ 个球, 要根据抽样数据, 说明抽到黑球的概率是 $1/4$ , 还是 $3/4$ .

**解** 将此问题用统计模型来表述. 令 $X_i$ 表示第*i*次抽球的结果, 即

$$X_i = \begin{cases} 1 & \text{抽出为黑球} \\ 0 & \text{否则.} \end{cases}$$

记每次抽样中抽到黑球的概率为 $\theta$ , 此处 $\theta$ 只取可能的两个值 $\theta_1 = 1/4, \theta_2 = 3/4$ 之一. 记 $X = \sum_{i=1}^n X_i$ , 则 $X \sim b(n, \theta)$ . 亦即样本分布族 $\mathcal{F} = \{F_{\theta_1}, F_{\theta_2}\}$ , 其中 $F_{\theta_1}$ 为 $b(n, \theta_1)$ ,  $F_{\theta_2}$ 为 $b(n, \theta_2)$ . 要根据抽样结果对 $\theta$ 作出估计, 即 $\theta$ 取值为 $1/4$ 还是 $3/4$ ? 或曰样本来自总体 $F_{\theta_1}$ 还是 $F_{\theta_2}$ ?

显然, 当样本 $X$ 给定时, 似然函数为

$$L(\theta, x) = \binom{n}{x} \theta^x (1-\theta)^{n-x}, \quad x = 0, 1, 2, \dots, n.$$

为简单计, 取 $n = 3$ . 当 $x = 0, 1, 2, 3$ 时似然函数取值如下表:

$x$	0	1	2	3
$L(\theta_1, x)$	27/64	27/64	9/64	1/64
$L(\theta_2, x)$	1/64	9/64	27/64	27/64

可见

当 $x = 0, 1$ 时,  $L(\theta_1, x) > L(\theta_2, x)$ ,

当 $x = 2, 3$ 时,  $L(\theta_2, x) > L(\theta_1, x)$ .

因此我们得出结论: 当样本观察值 $x = \sum_{i=1}^3 x_i$  取值为0, 1 时认为样本来自总体 $F_{\theta_1}$ , 即取参数 $\theta$ 的估计值为 $\hat{\theta}_1 = 1/4$ ; 当 $x = 2, 3$ 时认为样本来自总体 $F_{\theta_2}$ , 即取 $\theta$ 的估计值为 $\hat{\theta}_2 = 3/4$ .

将此例模型化如下: 若样本 $\mathbf{X} = (X_1, \dots, X_n)$ 为从总体 $\mathcal{F} = \{F_\theta, \theta \in \Theta\}$ 中抽取的简单随机样本, 其中 $\Theta = \{\theta_1, \theta_2\}$ . 此即等价地说分布族 $\mathcal{F}$ 中只有两个总体 $F_{\theta_1}, F_{\theta_2}$ . 一旦获得了样本 $\mathbf{x}$ , 如何用极大似然方法求出真参数 $\theta$ 的估计值呢? 上例表明若

$$L(\theta_1, \mathbf{x}) > L(\theta_2, \mathbf{x}),$$

则我们倾向于认为样本 $\mathbf{X}$ 来自总体 $F_{\theta_1}$  (即真参数 $\theta$ 为 $\theta_1$ ) 的理由比认为样本 $\mathbf{X}$ 来自总体 $F_{\theta_2}$  (即真参数 $\theta$ 为 $\theta_2$ ) 的理由更充分些. 或者说, 真参数 $\theta$ 为 $\theta_1$ 的“似然性”更大些. 这样, 我们自然把“似然性”最大(即看起来最像)的那个值作为真参数 $\theta$ 的估计值. 这正是“极大似然”一词的由来.

更一般, 若样本 $\mathbf{X}$ 的分布族 $\mathcal{F} = \{F_\theta, \theta \in \Theta\}$ , 参数空间 $\Theta$ 为 $R_1$ 的有限子集或无限子集. 当样本 $\mathbf{x}$ 给定时, 若 $\hat{\theta}^*$ 使似然函数 $L(\hat{\theta}^*, \mathbf{x})$  为似然函数的集合 $\{L(\theta, \mathbf{x}), \text{一切 } \theta \in \Theta\}$ 中最大者, 即参数 $\theta$ 的真值为 $\hat{\theta}^*$ 的“似然性”比 $\theta$ 取 $\Theta$ 中其它值的“似然性”更大, 则取“似然性”最大的 $\hat{\theta}^*$ 作为 $\theta$ 的估计值, 这一方法得到参数 $\theta$ 的估计, 称为“极大似然估计”. 将这一直观想法用数学语言来描述, 得到如下定义:

**定义 2.** 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从参数分布族 $\mathcal{F} = \{F_\theta, \theta \in \Theta\}$ 中抽取的简单随机样本,  $L(\theta, \mathbf{x})$ 是似然函数, 若存在统计量 $\hat{\theta}^*(\mathbf{X}) = \hat{\theta}^*(X_1, \dots, X_n)$ , 满足条件

$$L(\hat{\theta}^*(\mathbf{x}), \mathbf{x}) = \sup_{\theta \in \Theta} L(\theta, \mathbf{x}), \quad x \in \mathcal{X}, \tag{1.2}$$

或等价地使得

$$l(\hat{\theta}^*(\mathbf{x}), \mathbf{x}) = \sup_{\theta \in \Theta} l(\theta, \mathbf{x}), \quad x \in \mathcal{X}, \tag{1.3}$$

则称 $\hat{\theta}^*(\mathbf{X})$ 为 $\theta$ 的极大似然估计 (*Maximum Likelihood Estimation*, 简记为 *MLE*). 若待估函数是 $g(\theta)$ , 则定义 $g(\hat{\theta}^*(\mathbf{x}))$ 为 $g(\theta)$ 的 *MLE*.

极大似然估计是R.A. Fisher在1912年的一项工作中提出来的. 在正态分布这个特殊情况下, 这方法可追溯到Gauss在19世纪初关于最小二乘法的工作. Fisher后来在1922年工作中, 尤其1925年发表的《Theory of Statistical Estimation》一文中对这一估计作了许多研究. 因此这个方法应归功于R.A. Fisher.

## 二、极大似然估计的求法及例

获得参数 $\theta$ 的极大似然估计有下列两种方法:

### 1. 用微积分中求极值的方法

若似然函数 $L(\theta, \mathbf{x})$ 是 $\theta$ 的连续可微函数, 则我们可用微积分中求极值点的方法去求 $\theta$ 的MLE. 找使 $L(\theta, \mathbf{x})$ 达到最大时 $\theta$ 的值. 由于 $L(\theta, \mathbf{x})$ 和 $\log L(\theta, \mathbf{x}) = l(\theta, \mathbf{x})$ 具有相同的极值点, 我们可用 $l(\theta, \mathbf{x})$ 来代替 $L(\theta, \mathbf{x})$ . 因为 $L(\theta, \mathbf{x})$ 一般是若干个函数的乘积,  $l(\theta, \mathbf{x})$ 为若干个函数之和而较易于处理.

设 $\theta = (\theta_1, \dots, \theta_k)$ 为参数向量(特别当 $k = 1$ ,  $\theta$ 为参数). 若 $l(\theta, \mathbf{x})$ 的极大值在参数空间 $\Theta$ 的内点处(而非边界点)达到, 则此点必为似然方程组

$$\frac{\partial l(\theta, \mathbf{x})}{\partial \theta_i} = 0, \quad i = 1, 2, \dots, k$$

的解.

因此求极大似然估计首先求似然方程的解 $\hat{\theta}$ . 但此解是否一定是 $\theta$ 的MLE呢?  $\hat{\theta}$ 满足似然方程, 只是MLE的必要条件, 而非充分条件. 一般只有满足下列条件: (i) 似然函数的极大值在参数空间 $\Theta$ 内部达到, (ii) 似然方程只有唯一解, 则似然方程之解 $\hat{\theta}$ 必为 $\theta$ 的MLE.

因此我们求出似然方程(或方程组)的解后, 要验证它为 $\theta$ 的MLE, 有时并非易事. 但对样本分布族是指数族的场合, 有非常满意的结果, 叙述如下:

设 $\mathbf{X} = (X_1, \dots, X_n)$ 为从某总体中抽取的简单随机样本,  $X_1$ 的分布为指数族, 即

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

此处 $\Theta$ 为自然参数空间,  $\Theta_0$ 为 $\Theta$ 之内点集, 这时 $\mathbf{X}$ 的联合密度为

$$L(\theta, \mathbf{x}) = C^n(\theta) \exp \left\{ \sum_{i=1}^k \theta_i \sum_{j=1}^n T_i(x_j) \right\} h(\mathbf{x}),$$

其中 $h(\mathbf{x}) = \prod_{i=1}^n h(x_i)$ . 对上式取对数得

$$l(\theta, \mathbf{x}) = \log L(\theta, \mathbf{x}) = n \log C(\theta) + \sum_{i=1}^k \theta_i \sum_{j=1}^n T_i(x_j)$$

**定理 1.** 若对任何样本 $\mathbf{X} = (X_1, \dots, X_n)$ , 方程组

$$\frac{n}{C(\theta)} \frac{\partial C(\theta)}{\partial \theta_i} = - \sum_{j=1}^n T_i(X_j), \quad i = 1, 2, \dots, k$$

在 $\Theta_0$ 内有解, 则解必唯一, 且为 $\theta$ 的MLE.

**证明思路** 由于自然参数空间为一凸集, 若方程组有两个不同的解,  $\theta_0$ 和 $\theta_1$ , 则构造函数

$$H(t) = l(t\theta_0 + (1-t)\theta_1), 0 \leq t \leq 1.$$

由于 $\theta_0$ 和 $\theta_1$ 都是方程 $\partial l(\theta)/\partial\theta = 0$ 的解, 因此 $H'(0) = H'(1) = 0$ , 所以存在 $0 < t_0 < 1$ , 使得 $H''(t_0) = 0$ . 记

$$\tilde{\theta} = t_0\theta_0 + (1 - t_0)\theta_1$$

则

$$H''(t_0) = (\theta_0 - \theta_1)'Q(t_0)(\theta_0 - \theta_1) = 0$$

其中 $Q(\theta) = \frac{\partial^2 \log C(\theta)}{\partial \theta \partial \theta^T} = -Var(T_1(X), \dots, T_k(X)) < 0$ , 对任意的 $\Theta$ 内点 $\theta$ , 上式与此特性矛盾. 因此 $\theta_0 = \theta_1$ .

另一方面, 若 $\theta_0$ 为一个解, 而用 $\theta_1$ 表示 $\Theta$ 中任意一点, 则前面构造的函数 $H(t)$ 满足 $H'(1) = 0, H''(t) < 0$ . 因此 $H'(t) > 0, 0 \leq t < 1$ . 所以 $H(1) > H(0)$ , 即 $l(\theta_0) > l(\theta_1)$ ,  $\theta_0$ 为 $l$ 的极大点.

因此若样本分布为指数族, 只要似然方程解属于自然参数空间的内点集(这点很容易验证), 则其解必为 $\theta$ 的MLE. 常见的分布族, 如二项分布族、Poisson分布族、正态分布族、Gamma分布族等都是指数族, 定理3.3.1的条件皆成立. 因此似然方程的解, 就是有关参数的MLE.

## 2. 从定义出发

若似然函数 $L(\theta, \mathbf{x})$ 不是 $\theta$ 的可微函数, 特别当似然函数 $L(\theta, \mathbf{x})$ 不是 $\theta$ 的连续函数时, 我们不能采用上述方法, 必须直接从定义3.3.2出发去求参数 $\theta$ 的极大似然估计.

下面我们分别用上述两种方法考察一些例子.

**例2.** 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从两点分布族 $\{b(1, p) : 0 < p < 1\}$ 中抽取的简单样本, 求 $p$ 和 $g(p) = p(1 - p)$ 的MLE.

解 似然函数为

$$L(p, \mathbf{x}) = p^{\sum_{i=1}^n x_i} (1 - p)^{n - \sum_{i=1}^n x_i},$$

故有

$$l(p, \mathbf{x}) = \log L(p, \mathbf{x}) = \left( \sum_{i=1}^n x_i \right) \log p + \left( n - \sum_{i=1}^n x_i \right) \log(1 - p)$$

对数似然方程为

$$\frac{\partial l(p, \mathbf{x})}{\partial p} = \frac{1}{p} \sum_{i=1}^n x_i - \frac{1}{1-p} \left( n - \sum_{i=1}^n x_i \right) = 0,$$

解得

$$\hat{p}^* = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}.$$

由于两点分布族为指数族, 故 $\hat{p}^* = \bar{X}$ 为 $p$ 的MLE. 它与例3.2.2中给得出的 $p$ 的矩估计量相同. 按定义可知 $g(p) = p(1 - p)$ 的MLE为

$$\hat{g}^*(\mathbf{X}) = \hat{p}^*(1 - \hat{p}^*) = \bar{X}(1 - \bar{X}).$$

**例3.** 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从Poisson分布族 $\{P(\lambda) : \lambda > 0\}$ 中抽取的简单样本, 求 $\lambda$ 和 $g(\lambda) = e^{-\lambda}$ 的MLE.

解 似然函数,即样本  $\mathbf{X} = (X_1, \dots, X_n)$  的分布为

$$L(\lambda, \mathbf{x}) = P(X_1 = x_1, \dots, X_n = x_n) = \frac{\lambda^{\sum_{i=1}^n x_i} e^{-n\lambda}}{x_1! \cdots x_n!}, \quad \lambda > 0.$$

故对数似然函数为

$$l(\lambda, \mathbf{x}) = \left( \sum_{i=1}^n x_i \right) \log \lambda - n\lambda - \sum_{i=1}^n \log x_i! .$$

由对数似然方程

$$\frac{\partial l(\lambda, \mathbf{x})}{\partial \lambda} = \frac{1}{\lambda} \sum_{i=1}^n x_i - n = 0,$$

解得

$$\hat{\lambda}^* = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i .$$

由于Poisson分布族是指数族, 故  $\hat{\lambda}^* = \bar{X}$  为  $\lambda$  的MLE, 它与  $\lambda$  的矩估计量相同.

又由定义可知  $g(\lambda) = e^{-\lambda}$  的MLE为

$$\hat{g}^*(\mathbf{X}) = e^{-\bar{X}}.$$

**例4.** 设  $\mathbf{X} = (X_1, \dots, X_n)$  是从正态分布族  $\{N(a, \sigma^2) : \sigma^2 > 0, -\infty < \mu < \infty\}$  中抽取的简单样本, 求  $a, \sigma^2$  和  $g(\theta) = a/\sigma^2$  的MLE, 此处  $\theta = (a, \sigma^2)$ .

解 样本  $\mathbf{X} = (X_1, \dots, X_n)$  的分布为

$$f(\mathbf{x}, \theta) = \left( \frac{1}{\sqrt{2\pi}\sigma} \right)^n \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - a)^2 \right\} .$$

对数似然函数为

$$l(\theta, \mathbf{x}) = \log f(\mathbf{x}, \theta) = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - a)^2.$$

由对数似然方程组

$$\begin{aligned} \frac{\partial l(\theta, \mathbf{x})}{\partial a} &= \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - a) = 0, \\ \frac{\partial l(\theta, \mathbf{x})}{\partial \sigma^2} &= -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (X_i - a)^2 = 0, \end{aligned}$$

解得

$$\hat{a}^* = \bar{X}, \quad \hat{\sigma}_*^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = S_n^2 .$$

由于正态分布族为指数族, 故  $\hat{a}^* = \bar{X}$  和  $\hat{\sigma}_*^2 = S_n^2$  分别是  $a$  和  $\sigma^2$  的MLE, 它们也分别是  $a$  和  $\sigma^2$  的矩估计量. 前者是  $a$  的无偏估计, 后者不是  $\sigma^2$  的无偏估计. 可见极大似然估计不一定具有无偏性.

又由定义可知  $g(\theta) = a/\sigma^2$  的MLE为

$$\hat{g}^*(\mathbf{X}) = \bar{X}/S_n^2.$$

**例5.** 设元件的寿命服从下列指数分布  $EP(\lambda)$ , 其密度函数为

$$f(x, \lambda) = \begin{cases} \lambda e^{-\lambda x} & \text{当 } x > 0 \\ 0 & \text{当 } x \leq 0. \end{cases}$$

设  $X_1, \dots, X_n$  分别表示接受试验的  $n$  个元件寿命. 由于时间的限制, 试验实际上只进行到有  $r$  ( $r \leq n$ ) 个元件失效时就停止了, 以  $X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(r)}$  记这  $r$  个元件的寿命. 即, 我们只观察到了样本  $X_1, \dots, X_n$  前  $r$  个次序统计量  $X_{(1)}, X_{(2)}, \dots, X_{(r)}$ . 基于这前  $r$  个次序统计量, 求  $\lambda$  和  $g(\lambda) = 1/\lambda$  的 MLE.

解 为叙述方便, 记  $t_i = x_{(i)}$ ,  $i = 1, 2, \dots, r$ , 则有  $t_1 \leq t_2 \leq \dots \leq t_r$ . 为确定似然函数, 我们要知道上述观察结果的概率. 一个产品在  $[t_i, t_i + \Delta t_i]$  内失效的概率为  $f(t_i)\Delta t_i$ ,  $i = 1, 2, \dots, r$ . 其余  $n - r$  个产品寿命超过  $t_r$  的概率为  $[e^{-\lambda t_r}]^{n-r}$ , 所以上述结果出现的概率近似为

$$k(\lambda e^{-\lambda t_1} \Delta t_1)(\lambda e^{-\lambda t_2} \Delta t_2) \cdots (\lambda e^{-\lambda t_r} \Delta t_r)[e^{-\lambda t_r}]^{n-r},$$

其中  $k$  为某一常数. 忽略一个常数因子对求 MLE 无影响. 故取似然函数为

$$L(\lambda, x_{(1)}, \dots, x_{(r)}) = k\lambda^r \exp \left\{ -\lambda \left( \sum_{i=1}^r x_{(i)} + (n-r)x_{(r)} \right) \right\},$$

其对数似然函数为

$$l(\lambda, x_{(1)}, \dots, x_{(r)}) = r \log \lambda - \lambda \left( \sum_{i=1}^r x_{(i)} + (n-r)x_{(r)} \right).$$

对  $\lambda$  求导, 得似然方程为

$$\frac{\partial l}{\partial \lambda} = \frac{r}{\lambda} - \left( \sum_{i=1}^r x_{(i)} + (n-r)x_{(r)} \right) = 0,$$

解得

$$\hat{\lambda}^* = r / \left( \sum_{i=1}^r x_{(i)} + (n-r)x_{(r)} \right).$$

由于似然函数  $L(\lambda, x_{(1)}, \dots, x_{(r)})$  是指数族的形式, 故  $\hat{\lambda}^*$  为  $\lambda$  的 MLE. 由定义可知  $g(\lambda) = 1/\lambda$  的 MLE 为

$$\hat{g}^*(X_{(1)}, \dots, X_{(r)}) = \left( \sum_{i=1}^r X_{(i)} + (n-r)X_{(r)} \right) / r.$$

本例中所述产品寿命试验进行到第  $r$  个产品失效时就终止, 这种试验叫 定数截尾试验. 另一种方式是, 先定下一个时间  $T > 0$ , 当试验进行  $T$  时试验就终止, 这种试验叫做定时截尾试验.

**例6.** 设  $\mathbf{X} = (X_1, \dots, X_n)$  是从均匀分布族  $\{U(0, \theta) : \theta > 0\}$  中抽取的简单样本. (1) 求  $\theta$  的 MLE  $\hat{\theta}^*$ ; (2) 说明  $\hat{\theta}^*$  是否为  $\theta$  的无偏估计. 若不然, 作适当修正获得  $\theta$  的无偏估计  $\hat{\theta}_1^*$ ; (3) 试将  $\hat{\theta}_1^*$  与  $\theta$  的矩估计进行比较, 看哪一个有效? (4) 证明  $\theta$  的极大似然估计  $\hat{\theta}^* = X_{(n)}$  是  $\theta$  的弱相合估计.

解 (1) 样本  $\mathbf{X} = (X_1, \dots, X_n)$  的分布为

$$f(\mathbf{x}, \theta) = \begin{cases} \frac{1}{\theta^n} & \text{当 } 0 < x_1, \dots, x_n < \theta \\ 0 & \text{其他.} \end{cases} \quad (1.4)$$

因为均匀分布 $U(0, \theta)$ 的支撑集依赖于 $\theta$ ,似然函数 $L(\theta, \mathbf{x}) = f(\mathbf{x}, \theta)$ 作为 $\theta$ 的函数不是连续函数,因此不能用对然函数求微商的办法去求 $\theta$ 的MLE. 只能从MLE的定义出发来讨论.

为使 $L(\theta, \mathbf{x})$ 达到极大, 由(1.4)式可见, 应使分母上的 $\theta$ 尽可能地小, 但 $\theta$ 又不能太小, 太小了使似然函数变为0了. 这个界限就取在

$$\hat{\theta}^* = \max(X_1, \dots, X_n) = X_{(n)}.$$

因此 $\hat{\theta}^* = X_{(n)}$  就是 $\theta$ 的MLE.

(2) 为求 $E(X_{(n)})$ , 就要算出 $T = X_{(n)}$ 的密度函数, 易求 $T$  的密度函数

$$g(t, \theta) = \begin{cases} \frac{nt^{n-1}}{\theta^n} & \text{当 } 0 \leq t \leq \theta \\ 0 & \text{其 它,} \end{cases} \quad (1.5)$$

故有

$$E(\hat{\theta}^*) = E(T) = \int_0^\theta \frac{nt^n}{\theta^n} dt = \frac{n}{n+1}\theta,$$

故 $\hat{\theta}^* = X_{(n)}$ 不是 $\theta$ 的无偏估计. 显见

$$\hat{\theta}_1^* = \frac{n+1}{n}X_{(n)}$$

为 $\theta$ 的无偏估计.

(3)  $\theta$ 的矩估计 $\hat{\theta}_1 = 2\bar{X}$ 是 $\theta$ 的无偏估计. 由于

$$D(\hat{\theta}_1^*) = \theta^2 / [n(n+2)], \quad D(\hat{\theta}_1) = \theta^2 / 3n,$$

所以在 $n \geq 2$ 时 $\hat{\theta}_1^*$ 比 $\hat{\theta}_1$ 有效. 在 $n = 1$ 时 $\hat{\theta}_1^* = \hat{\theta}_1$ , 即这两个估计是相同的.

(4) 已知 $T$ 的密度函数由(1.5)给出, 故有

$$\begin{aligned} P(|\hat{\theta}^* - \theta| \geq \varepsilon) &= 1 - P(|\hat{\theta}^* - \theta| < \varepsilon) = 1 - P(\theta - \varepsilon < T < \theta + \varepsilon) \\ &= 1 - \int_{\theta-\varepsilon}^{\theta} \frac{nt^{n-1}}{\theta^n} dt = 1 - \frac{1}{\theta^n} [\theta^n - (\theta - \varepsilon)^n] = \left(1 - \frac{\varepsilon}{\theta}\right)^n. \end{aligned}$$

因此有

$$\lim_{n \rightarrow \infty} P(|\hat{\theta}^* - \theta| \geq \varepsilon) = \lim_{n \rightarrow \infty} \left(1 - \frac{\varepsilon}{\theta}\right)^n = 0,$$

故知 $\hat{\theta}^* = X_{(n)}$ 为 $\theta$ 的弱相合估计.

**例7.** 设 $\mathbf{X} = (X_1, \dots, X_n)$ 是从均匀分布族 $\{U(\theta, \theta + 1) : -\infty < \theta < +\infty\}$ 中抽取的简单样本,求 $\theta$ 的MLE.

解 给定样本 $\mathbf{x}$ 时,  $\theta$ 的似然函数为

$$L(\theta, \mathbf{x}) = \begin{cases} 1 & \theta \leq x_{(1)} \leq x_{(n)} \leq \theta + 1 \\ 0 & \text{其它,} \end{cases}$$

这时, 似然函数只取1和0两个值, 只要 $\theta \leq x_{(1)}$ 和 $\theta + 1 \geq x_{(n)}$ 都可使 $L$ 达到极大. 故 $\theta$ 的MLE不止一个, 如

$$\hat{\theta}_1^*(\mathbf{X}) = X_{(1)}, \quad \hat{\theta}_2^*(\mathbf{X}) = X_{(n)} - 1$$

都是 $\theta$ 的MLE. 事实上对任给的 $0 < \lambda < 1$ ,

$$\hat{\theta}^*(\mathbf{X}) = \lambda \hat{\theta}_1^*(\mathbf{X}) + (1 - \lambda) \hat{\theta}_2^*(\mathbf{X}) = \lambda X_{(1)} + (1 - \lambda) (X_{(n)} - 1)$$

都是 $\theta$ 的MLE, 故知 $\theta$ 的MLE有无穷多个.

**例8.** 设 $k$ 个事件 $A_1, A_2, \dots, A_k$ 构成完备事件群, 事件 $A_i$ 发生的概率为 $p_i$ ,  $i = 1, \dots, k$ 且 $\sum_{i=1}^k p_i = 1$ .

将试验独立重复 $n$ 次, 以 $X_i$ 记 $A_i$ 发生的次数,  $i = 1, 2, \dots, k$ , 则 $\mathbf{X} = (X_1, \dots, X_k)$ 服从多项分布 $M(n, p_1, \dots, p_k)$ . 求 $p_1, \dots, p_k$ 的MLE.

解 记 $\mathbf{p} = (p_1, \dots, p_k)$ . 给定样本 $\mathbf{x}$ 时,  $\mathbf{p}$ 的似然函数为

$$L(\mathbf{p}, \mathbf{x}) = \frac{n!}{x_1! \cdots x_k!} p_1^{x_1} \cdots p_k^{x_k} = \frac{n!}{x_1! \cdots x_k!} p_1^{x_1} \cdots p_{k-1}^{x_{k-1}} \left(1 - \sum_{i=1}^{k-1} p_i\right)^{x_k}.$$

对数似然函数为

$$l(\mathbf{p}, \mathbf{x}) = \log n! - \sum_{i=1}^k \log x_i! + \sum_{i=1}^{k-1} x_i \log p_i + x_k \log \left(1 - \sum_{i=1}^{k-1} p_i\right). \quad (1.6)$$

对 $p_i$ 求偏导数, 得似然方程组

$$\frac{\partial l(\mathbf{p}, \mathbf{x})}{\partial p_i} = \frac{x_i}{p_i} - \frac{x_k}{p_k} = 0, \quad i = 1, 2, \dots, k-1.$$

若令

$$\frac{x_1}{p_1} = \frac{x_2}{p_2} = \cdots = \frac{x_k}{p_k} = \lambda,$$

则有

$$x_i = \lambda p_i, \quad i = 1, 2, \dots, k. \quad (1.7)$$

将这 $k$ 个等式两边分别相加得

$$n = \sum_{i=1}^k x_i = \lambda \sum_{i=1}^k p_i = \lambda.$$

因此由(1.7)可知 $p_i$ 的MLE如下:

$$\hat{p}_i^* = X_i/n, \quad i = 1, 2, \dots, k.$$

**例9.** 设 $X_1, \dots, X_n$ 为从如下分布中抽取的简单样本, 求 $\theta$ 的MLE.

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

解: 由题设知 $f(x)$ 为离散型, 其分布律为

X	0	1	2
P	$\frac{1}{2}[(1-\theta)^2 + \theta^2]$	$2\theta(1-\theta)$	$\frac{1}{2}[(1-\theta)^2 + \theta^2]$

若直接从此分布出发, 则不能得到 $\theta$ 的显式表达. 为此, 我们重新参数化, 记 $\eta = 2\theta(1-\theta)$ . 则由题设知 $0 < \eta < 1/2$ . 则

X	0	1	2
P	$\frac{1}{2}(1-\eta)$	$\eta$	$\frac{1}{2}(1-\eta)$

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 $\eta$ 的下界即得到 $\eta$ 的MLE为

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

再由 $\theta = \frac{1-\sqrt{1-2\eta}}{2}$ 得到 $\theta$ 的MLE为

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

□

**例10.** 设从总体

X	0	1	2	3
P	$\theta/2$	$\theta$	$3\theta/2$	$1 - 3\theta$

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 $\hat{\theta}_M$ 和极大似然估计量 $\hat{\theta}_L$ , 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.

在有些问题中,  $p_1, \dots, p_k$ 都是另一些参数 $\theta_1, \dots, \theta_r$  ( $r \leq k$ )的函数, 这时去掉(1.6)中与 $\theta_1, \dots, \theta_r$ 无关的部分后, 得对数似然函数为

$$l(\theta_1, \dots, \theta_r; \mathbf{x}) = \sum_{i=1}^k x_i \log p_i(\theta_1, \dots, \theta_r)$$

对 $\theta_i$ 求偏导数得似然方程组

$$\frac{\partial l}{\partial \theta_i} = 0, \quad i = 1, 2, \dots, r. \quad (1.8)$$

若似然方程之解 $\hat{\theta}_1^*, \dots, \hat{\theta}_r^*$  为 $\theta_1, \dots, \theta_r$ 的MLE, 则 $p_1, \dots, p_k$ 的MLE分别是 $\hat{p}_1(\hat{\theta}_1^*, \dots, \hat{\theta}_r^*) \dots, \hat{p}_k(\hat{\theta}_1^*, \dots, \hat{\theta}_r^*)$ . 但有时似然方程组(1.8)无显式解, 就只能用数值方法.

### 三、极大似然估计的性质\*

前面例子中已指出极大似然估计不一定是无偏的. 至于相合性问题, 远没有矩估计那么简单. 极大似然估计的相合性问题, 引起许多统计学者的兴趣, 直到现在都不能说已彻底解决了. 1946年Cramer在一些条件下, 证明了似然方程有一根是参数 $\theta$ 的弱相合估计. 由于似然方程的根不一定是极大似然估计, 这个结果还是没有解决似然估计的相合性问题. 直到1949年, Wald才首次证明了极大似然估计的强相合性, 但所要求的条件很复杂. 此后有一些学者继续进行研究, 希望在较少的条件下证明相合性. 这些结果, 不便在此一一细述.

存在反例, 说明极大似然估计可以不相合, 有兴趣的读者可查看参考文献[2] P<sub>81</sub>的反例.

下面来介绍极大似然估计的几条性质:

#### 1. 极大似然估计与充分统计量

设 $\mathbf{X} = (X_1, \dots, X_n)$ 为自总体 $\{f(x, \theta), \theta \in \Theta\}$ 中抽出的简单随机样本,  $T = T(X_1, \dots, X_n)$ 是参数 $\theta$ 的充分统计量, 如果 $\theta$ 的极大似然估计存在, 则它必为 $T$ 的函数.

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

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

因此使  $\sup_{\theta} L(\theta, x)$  达到上确界之点  $\hat{\theta}^*$ , 即为使  $\sup_{\theta} g(T(\mathbf{x}), \theta)$  达到上确界之点, 它必为  $T(\mathbf{x})$  的函数.

此性质说明  $\theta$  的极大似然估计  $\hat{\theta}^* = \hat{\theta}^*(X_1, \dots, X_n)$  可表为  $T(\mathbf{X})$  的函数即  $\hat{\theta}^* = \hat{\theta}^*(T(X_1, \dots, X_n))$ . 如例3.3.2—例3.3.8中的极大似然估计皆为充分统计量的函数.

## 2. 极大似然估计与有效估计

设  $\mathbf{X} = (X_1, \dots, X_n)$  为自分布族  $\{f(x, \theta), \theta \in \Theta\}$  抽取的简单随机样本, 若  $g(\theta)$  的有效估计  $\hat{g}(\mathbf{X}) = \hat{g}(X_1, \dots, X_n)$  存在, 则  $g(\theta)$  的MLE  $\hat{g}^*(\mathbf{X}) = \hat{g}^*(X_1, \dots, X_n)$  必与  $\hat{g}(\mathbf{X})$  重合, 即  $g^*(\mathbf{X}) = \hat{g}(\mathbf{X})$ .

这一性质的证明放在§3.5, 即介绍了有效估计的概念之后, 其证明将由例3.5.11给出.

## 3. 相合渐近正态性

我们只考虑参数  $\theta$  为一维的情形. 设  $\mathcal{F} = \{f_\theta(x), \theta \in \Theta\}$  为一概率函数族,  $\Theta = (a, b)$  为  $R_1$  上开区间. 设  $f(x, \theta)$  满足下列条件:

(1) 对一切  $\theta \in \Theta$ , 偏导数

$$\frac{\partial \log f_\theta(x)}{\partial \theta}, \quad \frac{\partial^2 \log f_\theta(x)}{\partial \theta^2}, \quad \frac{\partial^3 \log f_\theta(x)}{\partial \theta^3}$$

存在.

(2) 存在定义于实轴上的函数  $F_1(x)$ 、 $F_2(x)$  和  $H(x)$ , 使对一切  $\theta \in \Theta$  和  $x \in R_1$  有

$$\left| \frac{\partial f_\theta(x)}{\partial \theta} \right| < F_1(x), \quad \left| \frac{\partial^2 f_\theta(x)}{\partial \theta^2} \right| < F_2(x), \quad \left| \frac{\partial^3 f_\theta(x)}{\partial \theta^3} \right| \leq H(x),$$

其中

$$\int_{-\infty}^{\infty} F_i(x) dx < \infty, \quad i = 1, 2; \quad \int_{-\infty}^{\infty} H(x) f_\theta(x) dx < M, \quad \theta \in \Theta,$$

这里  $M$  与  $\theta$  无关.

(3) 对一切  $\theta \in \Theta$  有

$$0 < I(\theta) = E \left[ \left( \frac{\partial \log f_\theta(x)}{\partial \theta} \right)^2 \right] = \int_{-\infty}^{\infty} \left( \frac{\partial \log f_\theta(x)}{\partial \theta} \right)^2 f_\theta(x) dx < \infty.$$

关于极大似然估计的相合渐近正态(CAN)性, 有下列结果:

**定理 2.** 设  $\mathbf{X} = (X_1, \dots, X_n)$  为自满足上述条件(1)-(3)的总体中抽取的简单随机样本, 且设对数似然方程

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

有唯一根  $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ ,  $\theta_0$  为真值, 则  $\hat{\theta}$  为  $\theta_0$  的CAN估计. 即

$$\sqrt{n}(\hat{\theta} - \theta_0) \xrightarrow{\mathcal{L}} N\left(0, \frac{1}{I(\theta_0)}\right),$$

且  $\hat{\theta}$  为  $\theta_0$  的弱相合估计.

**证明思路** 我们先不管条件, 记  $L_n(\theta) = \frac{1}{n} \sum_{i=1}^n \log f_\theta(x_i), \theta \in \Theta$ , 由大数律知

$$L_n(\theta) = \frac{1}{n} \sum_{i=1}^n \log f_\theta(x_i) \longrightarrow E_{\theta_0} \log f_\theta(X) = L(\theta), n \rightarrow \infty.$$

其中  $L(\theta) = E_{\theta_0} \log f_\theta(X) = \int \log f_\theta(x) f_{\theta_0}(x) dx$ . 显然  $L(\theta)$  与样本无关, 且易知  $\theta_0$  为其最大值点. 这是由于

$$L(\theta) \leq L(\theta_0), \forall \theta \in \Theta.$$

且等号成立当且仅当  $P(f_\theta(X) = f_{\theta_0}(X)) = 1$ . 事实上, 由于对任意的  $t > 0$  都有  $\log t \leq t - 1$ , 因此

$$\begin{aligned} L(\theta) - L(\theta_0) &= E_{\theta_0} \log f_\theta(X) - E_{\theta_0} \log f_{\theta_0}(X) = E_{\theta_0} \log \frac{f_\theta(X)}{f_{\theta_0}(X)} \\ &\leq E_{\theta_0} \left[ \frac{f_\theta(X)}{f_{\theta_0}(X)} - 1 \right] = 0. \end{aligned}$$

因此, 由于  $\hat{\theta}$  为  $L_n(\theta)$  的最大值点, 而  $L_n(\theta)$  收敛到  $L(\theta)$ ,  $\theta_0$  为  $L(\theta)$  的最大值点, 因此  $\hat{\theta}$  收敛到  $\theta_0$ , 即  $\hat{\theta}$  是  $\theta_0$  的相合估计.

对渐近正态性, 记  $l(\theta) = \frac{\partial L_n(\theta)}{\partial \theta}$ , 由 Taylor 展开式

$$0 = l(\hat{\theta}) = l(\theta_0) + (\hat{\theta} - \theta_0) l'(\tilde{\theta})$$

其中  $\tilde{\theta} \in [\hat{\theta}, \theta_0]$ . 所以

$$\sqrt{n}(\hat{\theta} - \theta_0) = \frac{-\sqrt{n}l(\theta_0)}{l'(\tilde{\theta})}.$$

注意到由中心极限定理有

$$-\sqrt{n}l(\theta_0) = -\frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{\partial \log f_\theta(X_i)}{\partial \theta} \Big|_{\theta=\theta_0} \xrightarrow{\mathcal{L}} N(0, \frac{1}{I(\theta_0)})$$

其中  $I(\theta) = E[\frac{\partial \log f_\theta(X)}{\partial \theta}]^2$ .

另外, 由大数律知对所有的  $\theta \in \Theta$  有

$$l'(\theta) = \frac{1}{n} \sum_{i=1}^n \frac{\partial^2 \log f_\theta(X_i)}{\partial \theta^2} \longrightarrow E \frac{\partial^2 \log f_\theta(X_i)}{\partial \theta^2} = -I(\theta)$$

右边等式是因为

$$\frac{\partial^2 \log f_\theta(X_i)}{\partial \theta^2} = \frac{f''}{f} - \left[ \frac{f'}{f} \right]^2$$

以及  $E f'' = 0$ .

因此, 结合  $\hat{\theta} \rightarrow \theta_0$  以及  $\tilde{\theta} \in [\hat{\theta}, \theta_0]$  知道

$$l'(\tilde{\theta}) \longrightarrow -I(\theta_0).$$

从而由 Slutsky 定理得证.

**例11.** 设  $X_1, \dots, X_n$  是取自正态总体  $N(\mu, \sigma^2)$  的样本. 证明例 3.3.4 给出的  $a$  和  $\sigma^2$  的 MLE 分别具有渐近正态性.

证 (1) 显然正态分布满足定理3.3.2的条件(1)-(3). 因此由例3.3.4已知 $\mu$  的MLE是 $\hat{\mu} = \bar{X}$ . 由于

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

故有

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

所以

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

从而由定理3.3.2可知

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

即 $\hat{\mu}$ 近似服从 $N(\mu, \sigma^2/n)$ .

(2) 由例3.3.4可知 $\sigma^2$ 的MLE是 $\hat{\sigma}^2 = S_n^2$ . 由于

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

故由定理3.3.2可知

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

即 $\hat{\sigma}^2$ 近似服从正态分布 $N(\sigma^2, 2\sigma^4/n)$ .