



第一节 参数的点估计

- 点估计概念
- 求估计量的方法
- 课堂练习
- 小结






引言

上一讲，我们介绍了总体、样本、简单随机样本、统计量和抽样分布的概念，介绍了统计中常用的三大分布，给出了几个重要的抽样分布定理。它们是进一步学习统计推断的基础。





研究统计量的性质和评价一个统计推断的优良性，完全取决于其抽样分布的性质。





参数估计

现在我们来介绍一类重要的统计推断问题

参数估计问题是利用从总体抽样得到的信息来估计总体的某些参数或者参数的某些函数.

估计新生儿的体重





估计废品率



估计湖中鱼数

估计降雨量



在参数估计问题中，假定总体分布形式已知，未知的仅仅是一个或几个参数.

...
...





参数估计问题的一般提法

设有一个统计总体，总体的分布函数为 $F(x, \theta)$ ，其中 θ 为未知参数 (θ 可以是向量)。

现从该总体抽样，得样本

$$X_1, X_2, \dots, X_n$$

要依据该样本对参数 θ 作出估计，或估计 θ 的某个已知函数 $g(\theta)$ 。

这类问题称为参数估计。





参数估计 { 点估计
 { 区间估计





例如我们要估计某队男生的平均身高.

(假定身高服从正态分布 $N(\mu, 0.1^2)$)

现从该总体选取容量为5的样本, 我们的任务是要根据选出的样本 (5个数) 求出总体均值 μ 的估计. 而全部信息就由这5个数组成.

设这5个数是:

1.65 1.67 1.68 1.78 1.69

估计 μ 为1.68, 这是点估计.

估计 μ 在区间 [1.57, 1.84] 内, 这是区间估计.






一、点估计概念

例1 已知某地区新生婴儿的体重 $X \sim N(\mu, \sigma^2)$,

(μ, σ 未知)



...



随机抽查100个婴儿，得100个体重数据

10, 7, 6, 6.5, 5, 5.2, ...

而全部信息就由这100个数组成。

据此，我们应如何估计 μ 和 σ 呢？

2010年9月16日2时43分





为估计 μ :

我们需要构造出适当的样本的函数 $T(X_1, X_2, \dots, X_n)$, 每当有了样本, 就代入该函数中算出一个值, 用来作为 μ 的估计值 .

$T(X_1, X_2, \dots, X_n)$ 称为参数 μ 的点估计量,

把样本值代入 $T(X_1, X_2, \dots, X_n)$ 中, 得到 μ 的一个点估计值 .





我们知道, 若 $X \sim N(\mu, \sigma^2)$, 则 $E(X) = \mu$.

由大数定律,

样本体重的平均值

$$\lim_{n \rightarrow \infty} P\left\{\left|\frac{1}{n} \sum_{i=1}^n X_i - \mu\right| < \varepsilon\right\} = 1$$

自然想到把样本体重的平均值作为总体平均体重的一个估计.

用样本体重的均值 \bar{X} 估计 μ .

类似地, 用样本体重的方差 S^2 估计 σ^2 .

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





问题是：

使用什么样的统计量去估计 μ ?

可以用样本均值；

也可以用样本中位数；

还可以用别的统计量。





二、寻求估计量的方法


1. 矩估计法
2. 极大似然法
3. 最小二乘法
4. 贝叶斯方法

这里我们主要介绍前面两种方法。





概率论与数理统计



1. 矩估计法

矩估计法是英国统计学家K.皮尔逊最早提出来的. 由辛钦定理,

若总体 X 的数学期望 $E(X) = \mu$ 有限, 则有

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



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

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

其中 g 为连续函数.

2010年3月6日2时45分





这表明，当样本容量很大时，在统计上，可以用用样本矩去估计总体矩。这一事实导出矩估计法。

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：大数定律

矩估计法的具体做法如下

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

那么它的前 k 阶矩 $\mu_1, \mu_2, \dots, \mu_k$ ，一般

2010年3月6日2时45分





都是这 k 个参数的函数,记为:

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

从这 k 个方程中解出

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

那么用诸 μ_i 的估计量 A_i 分别代替上式中的诸 μ_i ,
即可得诸 θ_j 的矩估计量 :

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

矩估计量的观察值称为矩估计值 .





例2 设总体 X 在 $[a, b]$ 上服从均匀分布, a, b 未知. X_1, \dots, X_n 是来自 X 的样本, 试求 a, b 的矩估计量.

$$\text{解 } \mu_1 = E(X) = \frac{a+b}{2}$$

$$\mu_2 = E(X^2) = D(X) + [E(X)]^2$$

$$= \frac{(b-a)^2}{12} + \frac{(a+b)^2}{4}$$





即

$$\begin{cases} a + b = 2\mu_1 \\ b - a = \sqrt{12(\mu_2 - \mu_1^2)} \end{cases}$$

解得

$$\begin{aligned} a &= \mu_1 - \sqrt{3(\mu_2 - \mu_1^2)} \\ b &= \mu_1 + \sqrt{3(\mu_2 - \mu_1^2)} \end{aligned}$$

总体矩

于是 a, b 的矩估计量为

$$\hat{a} = \bar{X} - \sqrt{\frac{3}{n} \sum_{i=1}^n (X_i - \bar{X})^2}, \quad \hat{b} = \bar{X} + \sqrt{\frac{3}{n} \sum_{i=1}^n (X_i - \bar{X})^2}$$

样本矩

时45分





例3 设总体 X 的均值 μ 和方差 $\sigma^2 (> 0)$ 都存在, μ, σ^2 未知. X_1, \dots, X_n 是来自 X 的样本, 试求 μ, σ^2 的矩估计量.

解 $\mu_1 = E(X) = \mu$

$$\mu_2 = E(X^2) = D(X) + [E(X)]^2 = \sigma^2 + \mu^2$$





解得

$$\mu = \mu_1$$

$$\sigma^2 = \mu_2 - \mu_1^2$$

于是 μ, σ^2 的矩估计量为

$$\hat{\mu} = A_1 = \bar{X}$$

$$\hat{\sigma}^2 = A_2 - A_1^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

样本矩






矩法的优点是简单易行,并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。

其主要原因在于建立矩法方程时,选取那些总体矩用相应样本矩代替带有一定的随意性。





2010年3月

稍事休息





2. 最大似然法

它是在总体类型已知条件下使用的一种参数估计方法。

它首先是由德国数学家高斯在1821年提出的。然而,这个方法常归功于英国统计学家费歇。



费歇在1922年重新发现了这一方法，并首先研究了这种方法的一些性质。





最大似然法的基本思想

先看一个简单例子：

某位同学与一位猎人一起外出打猎。一只野兔从前方窜过。只听一声枪响，野兔应声倒下。如果要你推测，是谁打中的呢？你会如何想呢？



2010年3月





你就会想，只发一枪便打中，猎人命中的概率一般大于这位同学命中的概率。看来这一枪是猎人射中的。

这个例子所作的推断已经体现了极大似然法的基本思想。





最大似然估计原理:

设 X_1, X_2, \dots, X_n 是取自总体 X 的一个样本, 样本的联合密度(连续型) 或联合分布律 (离散型)为 $f(x_1, x_2, \dots, x_n; \theta)$.

当给定样本 X_1, X_2, \dots, X_n 时, 定义似然函数为:

$$L(\theta) = f(x_1, x_2, \dots, x_n; \theta)$$

这里 x_1, x_2, \dots, x_n 是样本的观察值 .





$$L(\theta) = f(x_1, x_2, \dots, x_n; \theta)$$

$L(\theta)$ 看作参数 θ 的函数，它可作为 θ 将以多大可能产生样本值 x_1, x_2, \dots, x_n 的一种度量。

最大似然估计法就是用使 $L(\theta)$ 达到最大值的 $\hat{\theta}$ 去估计 θ 。

$$L(\hat{\theta}) = \max_{\theta} L(\theta)$$

称 $\hat{\theta}$ 为 θ 的最大似然估计值。而相应的统计量

$\hat{\theta}(X_1, \dots, X_n)$ 称为 θ 的最大似然估计量。





两点说明:

1、求似然函数 $L(\theta)$ 的最大值点，可以应用微积分中的技巧。由于 $\ln(x)$ 是 x 的增函数， $\ln L(\theta)$ 与 $L(\theta)$ 在 θ 的同一值处达到它的最大值，假定 θ 是一实数，且 $\ln L(\theta)$ 是 θ 的一个可微函数。通过求解方程：

$$\frac{d \ln L(\theta)}{d \theta} = 0$$

可以得到 θ 的MLE。

若 θ 是向量，上述方程必须用方程组代替。

2、用上述求导方法求参数的MLE有时行不通。这时要用最大似然原则来求。





下面举例说明如何求最大似然估计

例5 设 X_1, X_2, \dots, X_n 是取自总体 $X \sim B(1, p)$ 的一个样本，求参数 p 的最大似然估计量。

解：似然函数为：

$$L(p) = f(x_1, x_2, \dots, x_n; p)$$

$$X_i \sim \begin{cases} 0 & 1-p \\ 1 & p \end{cases}$$

$$= \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i}$$





$$= p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i}$$

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

对数似然函数为：

$$\ln L(p) = \sum_{i=1}^n x_i \ln(p) + (n - \sum_{i=1}^n x_i) \ln(1-p)$$





对 p 求导并令其为0,

$$\frac{d \ln L(p)}{dp} = \frac{1}{p} \sum_{i=1}^n x_i - \frac{1}{1-p} (n - \sum_{i=1}^n x_i) = 0$$

得
$$\hat{p} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

即为 p 的最大似然估计值。

从而 p 的最大似然估计量为

$$\hat{p}(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$





求最大似然估计(MLE)的一般步骤是:

(1) 由总体分布导出样本的联合分布率(或联合密度);

(2) 把样本联合分布率 (或联合密度) 中自变量看成已知常数,而把参数 θ 看作自变量,得到似然函数 $L(\theta)$;

(3) 求似然函数 $L(\theta)$ 的最大值点(常常转化为求 $\ln L(\theta)$ 的最大值点), 即 θ 的MLE;

(4) 在最大值点的表达式中,用样本值代入就得参数的最大似然估计值.





例6 设总体 $X \sim N(\mu, \sigma^2)$, μ, σ^2 未知. x_1, \dots, x_n 是来自 X 的样本值, 试求 μ, σ^2 的最大似然估计量.

解 X 的概率密度为

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad -\infty < x < \infty$$

似然函数为

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





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

于是

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

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

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





解得

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

μ, σ^2 的最大似然估计量为

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





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 θ, μ 的最大似然估计.

解: 似然函数为

$$L(\theta, \mu) = \begin{cases} \prod_{i=1}^n \frac{1}{\theta} e^{-(x_i-\mu)/\theta}, & x_i \geq \mu \\ 0, & \text{其它} \end{cases} \quad i=1, 2, \dots, n$$

2010年3月6日2时45分





解：似然函数为

$$L(\theta, \mu) = \begin{cases} \prod_{i=1}^n \frac{1}{\theta} e^{-(x_i - \mu)/\theta}, & x_i \geq \mu \\ 0, & \text{其它} \end{cases} \quad i=1,2,\dots,n$$
$$= \begin{cases} \frac{1}{\theta^n} e^{-\frac{1}{\theta} \sum_{i=1}^n (x_i - \mu)}, & \min x_i \geq \mu \\ 0, & \text{其它} \end{cases}$$

对数似然函数为

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

2010年3月6日2时45分





对数似然

ln

用求导方法无法最终确定
用最大似然原则来求。

对 θ, μ 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 $\theta = \frac{1}{n} \sum_{i=1}^n x_i - \mu$

2010年3月6日2时45分





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

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

故使 $L(\theta, \mu)$ 达到最大的 μ , 即 μ 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 θ^*, μ^* 为 θ, μ 的MLE.





最后，我们用最大似然法估计湖中的鱼数

为了估计湖中的鱼数 N ，第一次捕上 r 条鱼，做上记号后放回。隔一段时间后，再捕出 S 条鱼，结果发现这 S 条鱼中有 k 条标有记号。根据这个信息，如何估计湖中的鱼数呢？

第二次捕出的有记号的鱼数 X 是 $r.v.$ ， X 具有超几何分布：

$$P\{X = k\} = \frac{\binom{r}{k} \binom{N-r}{S-k}}{\binom{N}{S}},$$

$$0 \leq k \leq \min(S, r)$$





$$P\{X = k\} = \frac{\binom{r}{k} \binom{N-r}{S-k}}{\binom{N}{S}}$$

把上式右端看作 N 的函数，记作 $L(N; k)$ 。

应取使 $L(N; k)$ 达到最大的 N ，作为 N 的极大似然估计。但用对 N 求导的方法相当困难，我们考虑比值：

$$\frac{P(X = k; N)}{P(X = k; N - 1)} = \frac{(N - S)(N - r)}{N(N - r - S + k)}$$

经过简单的计算知，这个比值大于或小于1，

由 $N < \frac{Sr}{k}$ 或 $N > \frac{Sr}{k}$ 而定。





$$\frac{P(X = k; N)}{P(X = k; N - 1)} = \frac{(N - S)(N - r)}{N(N - r - S + k)}$$

经过简单的计算知，这个比值大于或小于 1，

由 $N < \frac{Sr}{k}$ 或 $N > \frac{Sr}{k}$ 而定。

这就是说，当 N 增大时，序列 $P(X=k;N)$ 先是上升而后下降；当 N 为小于 $\frac{Sr}{k}$ 的最大整数时，达到最大值。故 N 的极大似然估计为 $\hat{N} = \left[\frac{Sr}{k} \right]$ 。





三、课堂练习

例1 设总体 X 的概率密度为

$$f(x) = \begin{cases} (\alpha + 1)x^\alpha, & 0 < x < 1 \\ 0, & \text{其它} \end{cases}$$

其中 $\alpha > 1$ 是未知参数, X_1, X_2, \dots, X_n 是取自 X 的样本, 求参数 α 的矩估计.





解 $\mu_1 = E(X) = \int_0^1 x(\alpha + 1)x^\alpha dx$

$$= (\alpha + 1) \int_0^1 x^{\alpha+1} dx = \frac{\alpha + 1}{\alpha + 2}$$

解得 $\alpha = \frac{2\mu_1 - 1}{1 - \mu_1}$ 总体矩

故 α 的矩估计量为 $\hat{\alpha} = \frac{2\bar{X} - 1}{1 - \bar{X}}$ 样本矩





例 2 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 θ, μ 的矩估计.

解 由密度函数知

$X - \mu$ 具有均值为 θ 的指数分布

故
$$\begin{cases} E(X - \mu) = \theta \\ D(X - \mu) = \theta^2 \end{cases} \quad \text{即} \quad \begin{cases} E(X) = \mu + \theta \\ D(X) = \theta^2 \end{cases}$$





也就是

$$E(X) = \mu + \theta$$

$$D(X) = \theta^2$$

解得

$$\theta = \sqrt{D(X)}$$

$$\mu = E(X) - \sqrt{D(X)}$$

于是 θ, μ 的矩估计量为

$$\left\{ \begin{array}{l} \hat{\theta} = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \\ \hat{\mu} = \bar{X} - \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \end{array} \right.$$





例3 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 θ 的最大似然估计值.

解 似然函数为

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

对数似然函数为

$$\ln L(\theta) = n \ln \theta + (\theta - 1) \sum_{i=1}^n \ln x_i$$





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

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

从中解得

$$\hat{\theta} = -n / \sum_{i=1}^n \ln x_i$$

即为 θ 的最大似然估计值。

2010年3月6日2时45分





四、小结

这一讲，我们介绍了参数点估计，给出了寻求估计量最常用的矩法和极大似然法。

参数点估计是用一个确定的值去估计未知的参数。看来似乎精确，实际上把握不大。





概率论与数理统计

理工学系

2010年3月6日2时45分

