

点估计

续本达

复习

统计推断

点估计

矩估计法

最大似然估计

最小二乘估计

# 点估计

续本达

清华大学 工程物理系

2023-11-15

点估计

续本达

复习

统计推断

点估计

矩估计法

最大似然估计

最小二乘估计

复习

样本  $(X_1, X_2, \dots, X_n)$  的不含有未知参数的连续函数  $g(X_1, X_2, \dots, X_n)$  称为 **统计量**。

- 样本均值、样本方差、样本标准差

## 抽样分布

正态总体  $X \sim N(\mu, \sigma^2)$  和  $X' \sim N(\mu', \sigma'^2)$

$$\chi^2 \text{ 分布 } \frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$$

$$F \text{ 分布 } \frac{S^2/S'^2}{\sigma^2/\sigma'^2} \sim F(n-1, n'-1)$$

$$t \text{ 分布 } \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$$

点估计

续本达

复习

统计推断

点估计

矩估计法

最大似然估计

最小二乘估计

# 统计推断

- 统计推断是数理统计理论的主要部分。
- 现行的统计推断理论，是建立在概率论的基础上的。
- 从总体中抽出的样本，去推断总体的性质（期望、方差、分布等）。

例

假定在教室里的学生中，身高服从正态分布  $N(\mu, \sigma^2)$ ，其中  $\mu, \sigma^2$  是未知参数，即为推断的对象。

统计推断的基本问题

参数估计问题

点估计

区间估计

假设检验问题

- **参数** 是刻画总体某方面概率特性的数量。
- 当此数量未知时，从总体抽出一个样本，用一定的方法对它进行**参数估计**。
  - ① 方法问题：如何利用样本估计未知参数
  - ② 评判标准：如何评价估计的好坏

## 参数估计类型

点估计 估计未知参数的值；

区间估计 估计未知参数的取值范围，并使此范围包含未知参数真值的概率为给定的值。

例

$X \sim N(\mu, \sigma^2)$ ，若  $\mu, \sigma^2$  未知，通过构造统计量，给出它们的 **估计值**（点估计）或 **取值范围**（区间估计）就是参数估计的内容。

- **参数** 是刻画总体某方面概率特性的数量。
- 当此数量未知时，从总体抽出一个样本，用一定的方法对它进行**参数估计**。
  - ① 方法问题：如何利用样本估计未知参数
  - ② 评判标准：如何评价估计的好坏

## 参数估计类型

**点估计** 估计未知参数的值；

**区间估计** 估计未知参数的取值范围，并使此范围包含未知参数真值的概率为给定的值。

例

$X \sim N(\mu, \sigma^2)$ ，若  $\mu, \sigma^2$  未知，通过构造统计量，给出它们的 **估计值**（点估计）或 **取值范围**（区间估计）就是参数估计的内容。

点估计

续本达

复习

统计推断

点估计

矩估计法

最大似然估计

最小二乘估计

# 点估计

例

设在炸药制造厂，一天中发生着火的次数  $X$  服从以  $\lambda$  为参数的泊松分布，参数未知，现有以下的样本值，试估计参数  $\lambda$ 。

着火次数 $k$	0	1	2	3	4	5	6	7	
发生 $k$ 次着火的天数 $n_k$	75	90	54	22	6	2	1	0	$\Sigma = 250$

由于  $X \sim \pi(\lambda)$ ，故有  $\lambda = E(X)$ ，用样本均值估计总体均值  $E(X)$ ，由数据计算得到

$$\bar{X} = 1.22$$

同样有  $\text{Var}(X) = \lambda$

```
library(Hmisc)
x <- data.frame(fire=c(0, 1, 2, 3, 4, 5, 6, 7),
                days=c(75, 90, 54, 22, 6, 2, 1, 0))
wtd.var(x$fire, weights=x$days)
```

1.27042570281125

$$s^2 = 1.27$$

该用哪个?

## 定义 (点估计)

用一个数值作为未知参数的估计值称为**点估计**。

- 设总体  $X$  的分布函数的形式已知,  $\theta$  是待估参数,  $X_1, X_2, \dots, X_n$  为总体的一个样本。
- 点估计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。

## 约定

尖帽符号  $\hat{\theta}$  表示估计量: 它是统计量。

## 定义 (点估计)

用一个数值作为未知参数的估计值称为**点估计**。

- 设总体  $X$  的分布函数的形式已知,  $\theta$  是待估参数,  $X_1, X_2, \dots, X_n$  为总体的一个样本。
- 点估计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。

## 约定

尖帽符号  $\hat{\theta}$  表示估计量: 它是统计量。

## 定义 (点估计)

用一个数值作为未知参数的估计值称为**点估计**。

- 设总体  $X$  的分布函数的形式已知,  $\theta$  是待估参数,  $X_1, X_2, \dots, X_n$  为总体的一个样本。
- 点估计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。

## 约定

尖帽符号  $\hat{\cdot}$  表示估计量: 它是统计量。

点估计

续本达

复习

统计推断

点估计

**矩估计法**

最大似然估计

最小二乘估计

# 矩估计法

## 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。

- 设随机变量  $X \sim f(x; \theta_1, \theta_2, \dots, \theta_k)$ ，其中  $\theta_1, \theta_2, \dots, \theta_k$  为待估参数。假设总体的前  $k$  阶矩存在：

$$E(X^r) = \mu_r(\theta_1, \theta_2, \dots, \theta_k), 1 \leq r \leq k$$

- 假设  $X_1, X_2, \dots, X_n$  为来自  $X$  的一个样本， $r$  阶样本矩  $A_r = \frac{1}{n} \sum_{i=1}^n X_i^r$ 。
- $A_r$  及其函数依概率收敛于相应的总体矩。因此可以
  - ① 用样本矩作为相应的总体矩的估计量；
  - ② 用样本矩的函数作为相应的总体矩函数的估计量。

## 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。

- 设随机变量  $X \sim f(x; \theta_1, \theta_2, \dots, \theta_k)$ ，其中  $\theta_1, \theta_2, \dots, \theta_k$  为待估参数。假设总体的前  $k$  阶矩存在：

$$E(X^r) = \mu_r(\theta_1, \theta_2, \dots, \theta_k), 1 \leq r \leq k$$

- 假设  $X_1, X_2, \dots, X_n$  为来自  $X$  的一个样本， $r$  阶样本矩  $A_r = \frac{1}{n} \sum_{i=1}^n X_i^r$ 。
- $A_r$  及其函数依概率收敛于相应的总体矩。因此可以
  - ① 用样本矩作为相应的总体矩的估计量；
  - ② 用样本矩的函数作为相应的总体矩函数的估计量。

## 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。

- 设随机变量  $X \sim f(x; \theta_1, \theta_2, \dots, \theta_k)$ ，其中  $\theta_1, \theta_2, \dots, \theta_k$  为待估参数。假设总体的前  $k$  阶矩存在：

$$E(X^r) = \mu_r(\theta_1, \theta_2, \dots, \theta_k), 1 \leq r \leq k$$

- 假设  $X_1, X_2, \dots, X_n$  为来自  $X$  的一个样本， $r$  阶样本矩  $A_r = \frac{1}{n} \sum_{i=1}^n X_i^r$ 。
- $A_r$  及其函数依概率收敛于相应的总体矩。因此可以
  - ① 用样本矩作为相应的总体矩的估计量；
  - ② 用样本矩的函数作为相应的总体矩函数的估计量。

## 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。

- 设随机变量  $X \sim f(x; \theta_1, \theta_2, \dots, \theta_k)$ ，其中  $\theta_1, \theta_2, \dots, \theta_k$  为待估参数。假设总体的前  $k$  阶矩存在：

$$E(X^r) = \mu_r(\theta_1, \theta_2, \dots, \theta_k), 1 \leq r \leq k$$

- 假设  $X_1, X_2, \dots, X_n$  为来自  $X$  的一个样本， $r$  阶样本矩  $A_r = \frac{1}{n} \sum_{i=1}^n X_i^r$ 。
- $A_r$  及其函数依概率收敛于相应的总体矩。因此可以
  - ① 用样本矩作为相应的总体矩的估计量；
  - ② 用样本矩的函数作为相应的总体矩函数的估计量。

总体的前  $k$  阶矩构成联立方程组，含  $k$  个未知参数。一般情况下可以解出这  $k$  个参数  $\theta_1, \theta_2, \dots, \theta_k$ ：

$$\begin{cases} \mu_1 = \mu_1(\theta_1, \theta_2, \dots, \theta_k), \\ \mu_2 = \mu_2(\theta_1, \theta_2, \dots, \theta_k), \\ \vdots \\ \mu_k = \mu_k(\theta_1, \theta_2, \dots, \theta_k), \end{cases} \Rightarrow \begin{cases} \theta_1 = \theta_1(\mu_1, \mu_2, \dots, \mu_k), \\ \theta_2 = \theta_2(\mu_1, \mu_2, \dots, \mu_k), \\ \vdots \\ \theta_k = \theta_k(\mu_1, \mu_2, \dots, \mu_k), \end{cases}$$

以样本矩  $A_r$  代替总体矩  $\mu_r (r = 1, 2, \dots, k)$  就得到待估参数的估计量，称为 **矩估计量**：

$$\hat{\theta}_i = \theta_i(A_1, A_2, \dots, A_k), i = 1, 2, \dots, k$$

矩估计量的观察值称为 **矩估计值**。

总体的前  $k$  阶矩构成联立方程组，含  $k$  个未知参数。一般情况下可以解出这  $k$  个参数  $\theta_1, \theta_2, \dots, \theta_k$ ：

$$\begin{cases} \mu_1 = \mu_1(\theta_1, \theta_2, \dots, \theta_k), \\ \mu_2 = \mu_2(\theta_1, \theta_2, \dots, \theta_k), \\ \vdots \\ \mu_k = \mu_k(\theta_1, \theta_2, \dots, \theta_k), \end{cases} \Rightarrow \begin{cases} \theta_1 = \theta_1(\mu_1, \mu_2, \dots, \mu_k), \\ \theta_2 = \theta_2(\mu_1, \mu_2, \dots, \mu_k), \\ \vdots \\ \theta_k = \theta_k(\mu_1, \mu_2, \dots, \mu_k), \end{cases}$$

以样本矩  $A_r$  代替总体矩  $\mu_r (r = 1, 2, \dots, k)$  就得到待估参数的估计量，称为 **矩估计量**：

$$\hat{\theta}_i = \theta_i(A_1, A_2, \dots, A_k), i = 1, 2, \dots, k$$

矩估计量的观察值称为 **矩估计值**。

- 随机变量  $X \sim f(x; \vec{\theta})$ ,  $\vec{\theta} \equiv (\theta_1, \dots, \theta_k)$  为待估参数。总体的前  $k$  阶矩构成向量  $\vec{\mu}(\vec{\theta})$ : 每个分量都是  $\vec{\theta}$  的函数,  $\mu_i = \mu_i(\vec{\theta})$ 。
- 一般情况下可反解出  $\vec{\theta}(\vec{\mu})$ 。
- 设  $\vec{X} = (X_1, \dots, X_n)$  是总体的一个样本, 样本的前  $k$  阶样本矩构成向量  $\vec{A} = (A_1, \dots, A_k)$ , 则待估函数的矩估计量为

$$\vec{\theta} = \vec{\theta}(\vec{\mu} = \vec{A})$$

- 随机变量  $X \sim f(x; \vec{\theta})$ ,  $\vec{\theta} \equiv (\theta_1, \dots, \theta_k)$  为待估参数。总体的前  $k$  阶矩构成矢量  $\vec{\mu}(\vec{\theta})$ : 每个分量都是  $\vec{\theta}$  的函数,  $\mu_i = \mu_i(\vec{\theta})$ 。
- 一般情况下可反解出  $\vec{\theta}(\vec{\mu})$ 。
- 设  $\vec{X} = (X_1, \dots, X_n)$  是总体的一个样本, 样本的前  $k$  阶样本矩构成矢量  $\vec{A} = (A_1, \dots, A_k)$ , 则待估函数的矩估计量为

$$\vec{\theta} = \vec{\theta}(\vec{\mu} = \vec{A})$$

例

设总体  $X \sim \text{Exp}(\lambda)$ ，即  $f(x) = \lambda e^{-\lambda x}$ 。  $X_1, \dots, X_n$  为总体的一个样本。  
求参数  $\lambda$  的矩法估计量。

$$\begin{aligned}\mu_1 &= E(X) = \frac{1}{\lambda} \\ \implies \lambda &= \frac{1}{\mu_1} \\ \implies \hat{\lambda} &= \frac{1}{A_1} = \frac{1}{\bar{X}}\end{aligned}$$

例

设总体  $X \sim \text{Exp}(\lambda)$ ，即  $f(x) = \lambda e^{-\lambda x}$ 。  $X_1, \dots, X_n$  为总体的一个样本。  
求参数  $\lambda$  的矩法估计量。

$$\mu_1 = E(X) = \frac{1}{\lambda}$$

$$\implies \lambda = \frac{1}{\mu_1}$$

$$\implies \hat{\lambda} = \frac{1}{A_1} = \frac{1}{\bar{X}}$$

例

如果总体的期望  $\mu$  与方差  $\sigma^2$  都存在（大部分常用分布满足该条件），则它们的矩估计量分别为

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

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

套用矩估计法

$$\mu_1 = E(X) = \mu$$

$$\mu_2 = E(X^2) = \text{Var}(X) + [E(X)]^2 = \sigma^2 + \mu^2$$

代入前两阶样本矩即可反解出。

例

如果总体的期望  $\mu$  与方差  $\sigma^2$  都存在（大部分常用分布满足该条件），则它们的矩估计量分别为

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

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

套用矩估计法

$$\mu_1 = E(X) = \mu$$

$$\mu_2 = E(X^2) = \text{Var}(X) + [E(X)]^2 = \sigma^2 + \mu^2$$

代入前两阶样本矩即可反解出。

例

设总体  $X \sim U(a, b)$ ,  $a, b$  未知, 求参数  $a, b$  的矩估计量.

一二阶矩为

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

$$\mu_2 = E(X^2) = \text{Var}(X) + [E(X)]^2 = \frac{(b-a)^2}{12} + \frac{(a+b)^2}{4}$$

解得  $a = \mu_1 - \sqrt{3(\mu_2 - \mu_1^2)}$ ,  $b = \mu_1 + \sqrt{3(\mu_2 - \mu_1^2)}$ , 代之以样本矩  $A_1$  和  $A_2$  即得到  $a$  和  $b$  的矩估计量

$$\hat{a} = A_1 - \sqrt{3(A_2 - A_1^2)} = A_1 - \sqrt{3B_2}$$

$$\hat{b} = A_1 + \sqrt{3(A_2 - A_1^2)} = A_1 + \sqrt{3B_2}$$

例

设总体  $X \sim U(a, b)$ ,  $a, b$  未知, 求参数  $a, b$  的矩估计量.

一二阶矩为

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

$$\mu_2 = E(X^2) = \text{Var}(X) + [E(X)]^2 = \frac{(b-a)^2}{12} + \frac{(a+b)^2}{4}$$

解得  $a = \mu_1 - \sqrt{3(\mu_2 - \mu_1^2)}$ ,  $b = \mu_1 + \sqrt{3(\mu_2 - \mu_1^2)}$ , 代之以样本矩  $A_1$  和  $A_2$  即得到  $a$  和  $b$  的矩估计量

$$\hat{a} = A_1 - \sqrt{3(A_2 - A_1^2)} = A_1 - \sqrt{3B_2}$$

$$\hat{b} = A_1 + \sqrt{3(A_2 - A_1^2)} = A_1 + \sqrt{3B_2}$$

例

设总体  $X \sim U(a, b)$ ,  $a, b$  未知, 求参数  $a, b$  的矩估计量.

一二阶矩为

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

$$\mu_2 = E(X^2) = \text{Var}(X) + [E(X)]^2 = \frac{(b-a)^2}{12} + \frac{(a+b)^2}{4}$$

解得  $a = \mu_1 - \sqrt{3(\mu_2 - \mu_1^2)}$ ,  $b = \mu_1 + \sqrt{3(\mu_2 - \mu_1^2)}$ , 代之以样本矩  $A_1$  和  $A_2$  即得到  $a$  和  $b$  的矩估计量

$$\hat{a} = A_1 - \sqrt{3(A_2 - A_1^2)} = A_1 - \sqrt{3B_2}$$

$$\hat{b} = A_1 + \sqrt{3(A_2 - A_1^2)} = A_1 + \sqrt{3B_2}$$

点估计

续本达

复习

统计推断

点估计

矩估计法

最大似然估计

最小二乘估计

# 最大似然估计

## 直觉

一次试验就出现的事件有较大的概率

## 例

有两外形相同的箱子, 各装 100 个球

一箱 99 个白球, 1 个红球

一箱 1 个白球, 99 个红球

现从两箱中任取一箱, 并从箱中任取一球, 结果所取得的球是白球。所取的球来自哪一箱?

## 直觉

一次试验就出现的事件有较大的概率

## 例

有两外形相同的箱子, 各装 100 个球

一箱 99 个白球, 1 个红球

一箱 1 个白球, 99 个红球

现从两箱中任取一箱, 并从箱中任取一球, 结果所取得的球是白球。所取的球来自哪一箱?

例

设总体  $X$  服从 0-1 分布, 且  $P(X = 1) = p$ , 用最大似然法求  $p$  的估计值.

总体  $X$  的概率分布为  $P(X = x) = p^x(1-p)^{1-x}$ ,  $x = 0, 1$ 。设  $x_1, x_2, \dots, x_n$  为总体的样本  $X_1, X_2, \dots, X_n$  的观测值, 则得到该样本值的概率为

$$P(X_1 = x_1, \dots, X_n = x_n) = \prod_{i=1}^n P(X_i = x_i) = p^{\sum_{i=1}^n x_i} (1-p)^{n - \sum_{i=1}^n x_i} \equiv L(p)$$

对于不同的  $p$ ,  $L(p)$  不同, 取  $p$  使这个事件发生的概率最大

$$\hat{p} = \arg \max L(p)$$

例

设总体  $X$  服从 0-1 分布, 且  $P(X = 1) = p$ , 用最大似然法求  $p$  的估计值.

总体  $X$  的概率分布为  $P(X = x) = p^x(1-p)^{1-x}$ ,  $x = 0, 1$ 。设  $x_1, x_2, \dots, x_n$  为总体的样本  $X_1, X_2, \dots, X_n$  的观测值, 则得到该样本值的概率为

$$P(X_1 = x_1, \dots, X_n = x_n) = \prod_{i=1}^n P(X_i = x_i) = p^{\sum_{i=1}^n x_i} (1-p)^{n - \sum_{i=1}^n x_i} \equiv L(p)$$

对于不同的  $p$ ,  $L(p)$  不同, 取  $p$  使这个事件发生的概率最大

$$\hat{p} = \arg \max L(p)$$

$\log$  是单调增函数

$$\hat{p} = \arg \max L(p) = \arg \max \log L(p)$$

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

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

所以,  $\hat{p} = \bar{x}$  是  $p$  的最大似然估计值。它恰好也是矩估计值。

- 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  $\theta$  的**最大似然估计量**。

未知参数可以不止一个, 如  $\vec{\theta}$ 。设  $X$  的概率密度为  $f(x, \vec{\theta})$ , 则定义似然函数

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

若对于某组给定的样本值  $\vec{x}$ , 参数  $\vec{\theta}$  使似然函数取得最大值, 即  $\hat{\vec{\theta}} = \arg \max L(\vec{x}, \vec{\theta})$ , 则称  $\hat{\theta}_r(\vec{x})$  为  $\theta_r (r = 1, 2, \dots, k)$  的最大似然估计值, 称统计量  $\hat{\theta}_r(\vec{X})$  为  $\theta_r$  的最大似然估计量。

## 似然方程组

若  $L(x_1, \dots, x_n; \theta_1, \dots, \theta_k)$  关于  $\vec{\theta}$  可微, 则称

$$\frac{\partial}{\partial \theta_r} L(x_1, \dots, x_n; \theta_1, \dots, \theta_k) = 0, r = 1, 2, \dots, k$$

为似然方程组。  $\frac{\partial}{\partial \theta_r} \log L = 0$  为对数似然方程组。

未知参数可以不止一个, 如  $\vec{\theta}$ 。设  $X$  的概率密度为  $f(x, \vec{\theta})$ , 则定义似然函数

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

若对于某组给定的样本值  $\vec{x}$ , 参数  $\vec{\theta}$  使似然函数取得最大值, 即  $\hat{\vec{\theta}} = \arg \max L(\vec{x}, \vec{\theta})$ , 则称  $\hat{\theta}_r(\vec{x})$  为  $\theta_r (r = 1, 2, \dots, k)$  的**最大似然估计值**, 称统计量  $\hat{\theta}_r(\vec{X})$  为  $\theta_r$  的**最大似然估计量**。

### 似然方程组

若  $L(x_1, \dots, x_n; \theta_1, \dots, \theta_k)$  关于  $\vec{\theta}$  可微, 则称

$$\frac{\partial}{\partial \theta_r} L(x_1, \dots, x_n; \theta_1, \dots, \theta_k) = 0, r = 1, 2, \dots, k$$

为**似然方程组**。  $\frac{\partial}{\partial \theta_r} \log L = 0$  为**对数似然方程组**。

未知参数可以不止一个, 如  $\vec{\theta}$ 。设  $X$  的概率密度为  $f(x, \vec{\theta})$ , 则定义似然函数

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

若对于某组给定的样本值  $\vec{x}$ , 参数  $\vec{\theta}$  使似然函数取得最大值, 即

$\hat{\vec{\theta}} = \arg \max L(\vec{x}, \vec{\theta})$ , 则称  $\hat{\theta}_r(\vec{x})$  为  $\theta_r (r = 1, 2, \dots, k)$  的**最大似然估计值**, 称统计量  $\hat{\theta}_r(\vec{X})$  为  $\theta_r$  的**最大似然估计量**。

## 似然方程组

若  $L(x_1, \dots, x_n; \theta_1, \dots, \theta_k)$  关于  $\vec{\theta}$  可微, 则称

$$\frac{\partial}{\partial \theta_r} L(x_1, \dots, x_n; \theta_1, \dots, \theta_k) = 0, r = 1, 2, \dots, k$$

为**似然方程组**。  $\frac{\partial}{\partial \theta_r} \log L = 0$  为**对数似然方程组**。

例

设总体  $X \sim N(\mu, \sigma^2)$ ,  $X_1, \dots, X_n$  是  $X$  的样本, 求  $\mu, \sigma^2$  的最大似然估计量.

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

$$\implies \log L = -\sum_{i=1}^n \frac{(x_i-\mu)^2}{2\sigma^2} - \frac{n}{2} \log \sigma^2 + C$$

$C$  是与  $\mu$  和  $\sigma^2$  无关的常数。

$$\begin{cases} \frac{\partial}{\partial \mu} \log L = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 \\ \frac{\partial}{\partial \sigma^2} \log L = \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{2(\sigma^2)} = 0 \end{cases} \implies \begin{cases} \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x} \\ \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \end{cases}$$

与矩估计法一致。

例

设总体  $X \sim N(\mu, \sigma^2)$ ,  $X_1, \dots, X_n$  是  $X$  的样本, 求  $\mu, \sigma^2$  的最大似然估计量.

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

$$\implies \log L = -\sum_{i=1}^n \frac{(x_i-\mu)^2}{2\sigma^2} - \frac{n}{2} \log \sigma^2 + C$$

$C$  是与  $\mu$  和  $\sigma^2$  无关的常数。

$$\begin{cases} \frac{\partial}{\partial \mu} \log L = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 \\ \frac{\partial}{\partial \sigma^2} \log L = \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{2(\sigma^2)} = 0 \end{cases} \implies \begin{cases} \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x} \\ \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \end{cases}$$

与矩估计法一致。

例

设总体  $X \sim N(\mu, \sigma^2)$ ,  $X_1, \dots, X_n$  是  $X$  的样本, 求  $\mu, \sigma^2$  的最大似然估计量.

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

$$\implies \log L = -\sum_{i=1}^n \frac{(x_i-\mu)^2}{2\sigma^2} - \frac{n}{2} \log \sigma^2 + C$$

$C$  是与  $\mu$  和  $\sigma^2$  无关的常数。

$$\begin{cases} \frac{\partial}{\partial \mu} \log L = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 \\ \frac{\partial}{\partial \sigma^2} \log L = \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{2(\sigma^2)} = 0 \end{cases} \implies \begin{cases} \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x} \\ \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \end{cases}$$

与矩估计法一致。

例

设总体  $X \sim N(\mu, \sigma^2)$ ,  $X_1, \dots, X_n$  是  $X$  的样本, 求  $\mu, \sigma^2$  的最大似然估计量.

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

$$\implies \log L = -\sum_{i=1}^n \frac{(x_i-\mu)^2}{2\sigma^2} - \frac{n}{2} \log \sigma^2 + C$$

$C$  是与  $\mu$  和  $\sigma^2$  无关的常数。

$$\begin{cases} \frac{\partial}{\partial \mu} \log L = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 \\ \frac{\partial}{\partial \sigma^2} \log L = \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{2(\sigma^2)} = 0 \end{cases} \implies \begin{cases} \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x} \\ \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \end{cases}$$

与矩估计法一致。

例

设总体  $X \sim N(\mu, \sigma^2)$ ,  $X_1, \dots, X_n$  是  $X$  的样本, 求  $\mu, \sigma^2$  的最大似然估计量.

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

$$\implies \log L = -\sum_{i=1}^n \frac{(x_i-\mu)^2}{2\sigma^2} - \frac{n}{2} \log \sigma^2 + C$$

$C$  是与  $\mu$  和  $\sigma^2$  无关的常数。

$$\begin{cases} \frac{\partial}{\partial \mu} \log L = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 \\ \frac{\partial}{\partial \sigma^2} \log L = \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 - \frac{n}{2(\sigma^2)} = 0 \end{cases} \implies \begin{cases} \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x} \\ \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \end{cases}$$

与矩估计法一致。

例

设  $X \sim U(a, b)$ ,  $X_1, X_2, \dots, X_n$  是  $X$  的一个样本, 求  $a, b$  的最大似然估计量。

似然函数为

$$L(a, b) = \begin{cases} \frac{1}{(b-a)^n}, & a < x_i < b \\ 0, & \text{其它} \end{cases} \implies \begin{cases} \frac{1}{(b-a)^n}, & a \leq \min x_i \leq \max x_i \leq b \\ 0, & \text{其它} \end{cases}$$

当  $a = \min x_i, b = \max x_i$  时,  $L(a, b)$  最大。所以

$$\hat{a} = \min X_i, \hat{b} = \max X_i$$

对比矩估计：两者不一致

$$\hat{a} = A_1 - \sqrt{3B_2}, \hat{b} = A_1 + \sqrt{3B_2}$$

例

设  $X \sim U(a, b)$ ,  $X_1, X_2, \dots, X_n$  是  $X$  的一个样本, 求  $a, b$  的最大似然估计量。

似然函数为

$$L(a, b) = \begin{cases} \frac{1}{(b-a)^n}, & a < x_i < b \\ 0, & \text{其它} \end{cases} \implies \begin{cases} \frac{1}{(b-a)^n}, & a \leq \min x_i \leq \max x_i \leq b \\ 0, & \text{其它} \end{cases}$$

当  $a = \min x_i, b = \max x_i$  时,  $L(a, b)$  最大。所以

$$\hat{a} = \min X_i, \hat{b} = \max X_i$$

对比矩估计：两者不一致

$$\hat{a} = A_1 - \sqrt{3B_2}, \hat{b} = A_1 + \sqrt{3B_2}$$

例

设  $X \sim U(a, b)$ ,  $X_1, X_2, \dots, X_n$  是  $X$  的一个样本, 求  $a, b$  的最大似然估计量。

似然函数为

$$L(a, b) = \begin{cases} \frac{1}{(b-a)^n}, & a < x_i < b \\ 0, & \text{其它} \end{cases} \implies \begin{cases} \frac{1}{(b-a)^n}, & a \leq \min x_i \leq \max x_i \leq b \\ 0, & \text{其它} \end{cases}$$

当  $a = \min x_i, b = \max x_i$  时,  $L(a, b)$  最大。所以

$$\hat{a} = \min X_i, \hat{b} = \max X_i$$

对比矩估计：两者不一致

$$\hat{a} = A_1 - \sqrt{3B_2}, \hat{b} = A_1 + \sqrt{3B_2}$$

点估计

续本达

复习

统计推断

点估计

矩估计法

最大似然估计

最小二乘估计

## 最小二乘估计

- 历史悠久；
- 计算高效；
- 估计量是样本的线性组合；
  - 线性组合是一类简单的函数形式，估计量的复杂性可控。
- 在线性回归中进一步讨论。