

第二讲 普通最小二乘估计量

一、基本概念：估计量与估计值

对总体参数的一种估计法则就是估计量。例如，为了估计总体均值为 μ ，我们可以抽取一个容量为 N 的样本，令 Y_i 为第 i 次观测值，则 μ 的一个很自然的

估计量就是 $\hat{\mu} = \bar{Y} = \frac{\sum Y_i}{N}$ 。A、B 两同学都利用了这种

估计方法，但手中所掌握的样本分别是 $(y_1^A, y_2^A, \dots, y_N^A)$ 与 $(y_1^B, y_2^B, \dots, y_N^B)$ 。A、B 两同学分别计算出估计值

$\hat{\mu}^A = \frac{\sum y_i^A}{N}$ 与 $\hat{\mu}^B = \frac{\sum y_i^B}{N}$ 。因此，在上例中，估计量 $\hat{\mu}$

是随机的，而 $\hat{\mu}^A, \hat{\mu}^B$ 是该随机变量可能的取值。估计量所服从的分布称为抽样分布。

如果真实模型是： $y = \beta_0 + \beta_1 x + \varepsilon$ ，其中 β_0, β_1 是待估计的参数，而相应的 OLS 估计量就是：

$$\hat{\beta}_1 = \frac{\sum (x_i - \bar{x}) y_i}{\sum (x_i - \bar{x})^2}; \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

我们现在的任务就是，基于一些重要的假定，来考察上述 OLS 估计量所具有的一些性质。

二、高斯-马尔科夫假定

●假定一：真实模型是： $y = \beta_0 + \beta_1 x + \varepsilon$ 。有三种情况属于对该假定的违背：（1）遗漏了相关的解释变量或者增加了无关的解释变量；（2） y 与 x 间的关系是非线性的；（3） β_0, β_1 并不是常数。

●假定二：在重复抽样中， (x_1, x_2, \dots, x_N) 被预先固定下来，即 (x_1, x_2, \dots, x_N) 是非随机的（进一步的阐释见附录），显然，如果解释变量含有随机的测量误差，那么该假定被违背。还存其他的违背该假定的情况。

笔记：

(x_1, x_2, \dots, x_N) 是随机的情况更一般化，此时，高斯-马尔科夫假定二被更改为：对任意 i, j , x_i 与 ε_j 不相关，此即所谓的解释变量具有严格外生性。显然，当 (x_1, x_2, \dots, x_N) 非随机时， x_i 与 ε_j 必定不相关，这是因为 ε_j 是随机的。

●假定三：误差项期望值为 0，即 $E(\varepsilon_i) = 0, i = 1, 2, \dots, N$ 。

笔记：

1、当 (x_1, x_2, \dots, x_N) 随机时，标准假定是：

$$E(\varepsilon_i | x_1, x_2, \dots, x_N) = 0, i = 1, 2, \dots, N$$

根据迭代期望定律有： $E[E(\varepsilon_i | x_1, x_2, \dots, x_N)] = E(\varepsilon_i)$ ，因此，如果 $E(\varepsilon_i | x_1, x_2, \dots, x_N) = 0$ 成立，必定有： $E(\varepsilon_i) = 0$ 。

另外，根据迭代期望定律也有：

$$E[E(\boldsymbol{\varepsilon}_i x_j | x_1, x_2, \dots, x_N)] = E(\boldsymbol{\varepsilon}_i x_j)$$

而 $E(\boldsymbol{\varepsilon}_i x_j | x_1, x_2, \dots, x_N) = x_j E(\boldsymbol{\varepsilon}_i | x_1, x_2, \dots, x_N)$ 。故有：

$$E(\boldsymbol{\varepsilon}_i | x_1, x_2, \dots, x_N) = 0 \Rightarrow \begin{cases} E(\boldsymbol{\varepsilon}_i) = 0 \\ E(\boldsymbol{\varepsilon}_i x_j) = 0 \end{cases}$$

$$\rightarrow \text{Cov}(\boldsymbol{\varepsilon}_i, x_j) = E(\boldsymbol{\varepsilon}_i x_j) - E(\boldsymbol{\varepsilon}_i)E(x_j) = 0$$

因此，在 (x_1, x_2, \dots, x_N) 是随机的情况下，假定二、三可以修正为一个假定： $E(\boldsymbol{\varepsilon}_i | x_1, x_2, \dots, x_N) = 0$ 。

2、所谓迭代期望定律是指：如果信息集 $\Theta \leq \Omega$ ，则有 $E[E(X|\rho)|\theta] = E(X|\theta)$ 。为了理解上述等式，考虑一个极端情况： Ω 包含了全部的信息，此时 X 丧失了随机性，故 $E(X|\rho) = X$ ，因此必有 $E[E(X|\rho)|\theta] = E(X|\theta)$ 。无条件期望所对应的信息集是空集，因此 $E[E(X|\rho)] = E(X)$ 。

3、回忆第一讲，对模型 $y = \beta_0 + \beta_1 x + \boldsymbol{\varepsilon}$ ，在 OLS 法下我们一定能保证：(1) 残差均值为零；(2) 残差与 x 样本不相关。残差是对误差的近似，如果假定二、三不成立，即误差项与解释变量相关，误差项期望值不为零，显然此时残差并不是对误差项的有效近似，换句话说，此时 OLS 估计量是有严重问题的。因此，假定二、三非常重要。

●假定四： $\delta_{\boldsymbol{\varepsilon}_i}^2 = \delta^2$ ，即所谓的同方差假定。

笔记:

在 (x_1, x_2, \dots, x_N) 是随机的情况下，该假定修订为：

$$\text{Var}(\varepsilon_i | x_1, x_2, \dots, x_N) = \delta^2$$

●假定五： $\text{Cov}(\varepsilon_i, \varepsilon_j) = 0, i \neq j$ ，即所谓的序列不相关假定。

笔记：

在 (x_1, x_2, \dots, x_N) 是随机的情况下，该假定修订为：

$$\text{Cov}(\varepsilon_i, \varepsilon_j | x_1, x_2, \dots, x_N) = 0, i \neq j$$

●假定六： $\sum(x_i - \bar{x})^2 \neq 0$ ，在多元回归中，该假定演变为 XX' 的逆存在，即各解释变量不完全共线。

三、高斯-马尔科夫定理

当高斯-马尔科夫假定成立时，在所有线性无偏估计量中，OLS估计量方差最小。或者说，OLS估计量是最优线性无偏估计量（best linear unbiased estimator, BLUE）。这被称为高斯-马尔科夫定理。

（一）OLS估计量是线性估计量

所谓OLS估计量是线性估计量，是指它能够被表示为 y_i 的线性函数。例如：

$$\hat{\beta}_1 = \sum \left[\frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2} \right] y_i = \sum k_i y_i$$

注意，在假定二下， k_i 是非随机的。

练习：把 $\hat{\beta}_0$ 表示成 y_i 的线性函数。

笔记：

线性意味着简单，简单意味着普通。因此有称谓“普通最小二乘法”。二乘即为平方，故 OLS 即为“简单的最小二乘法”。

(二) OLS 估计量具有无偏性： $E(\hat{\beta}_1) = \beta_1$ ； $E(\hat{\beta}_0) = \beta_0$ 证明 $E(\hat{\beta}_1) = \beta_1$ ：

$$\hat{\beta}_1 = \sum \left[\frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2} \right] y_i = \sum k_i y_i = \sum k_i (\beta_0 + \beta_1 x_i + \varepsilon_i)$$

$$\Rightarrow E(\hat{\beta}_1) = \beta_0 \sum k_i + \beta_1 \sum k_i x_i + \sum k_i E(\varepsilon_i)$$

而 $\sum k_i = 0$ ； $\sum k_i x_i = 1$ 。因此在重要假定三： $E(\varepsilon_i) = 0$

下，有： $E(\hat{\beta}_1) = \beta_1$ 。

笔记：

在 (x_1, x_2, \dots, x_N) 是随机的情况下，我们需证：

$$E(\hat{\beta}_1 | x_1, x_2, \dots, x_N) = \beta_1$$

练习：证明 $E(\hat{\beta}_0) = \beta_0$

(三) 在所有线性无偏估计量中，OLS 估计量方差最

小

1、关于方差

$$\delta_{\beta} = \text{Var}[\sum k_i(\beta_0 + \beta_1 x_i + \varepsilon_i)] = \text{Var}(\sum k_i \varepsilon_i)$$

在重要假定五： $\text{Cov}(\varepsilon_i, \varepsilon_j) = 0, i \neq j$ 及其重要假定

四： $\delta_{\varepsilon} = \delta^2$ 下，有：

i

$$\delta_{\hat{\beta}_1}^2 = \delta^2 \sum k_i^2$$

注意到 $\sum k_i^2 = \sum \left(\frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2} \right)^2 = \frac{1}{\sum (x_i - \bar{x})^2}$

因此有：

$$\delta_{\hat{\beta}_1}^2 = \frac{\delta^2}{\sum (x_i - \bar{x})^2}$$

笔记：

$$\delta_{\hat{\beta}_1}^2 = \frac{\delta^2}{\sum (x_i - \bar{x})^2} = \frac{\frac{1}{N} \delta^2}{\frac{1}{N} \sum (x_i - \bar{x})^2}, \text{ 当 } N \text{ 趋于无穷大}$$

时，样本方差 $\frac{1}{N} \sum (x_i - \bar{x})^2$ 收敛于总体方差，故当 N 趋于无

穷大时， $\delta_{\hat{\beta}_1}^2$ 趋于 0。由于 $E(\hat{\beta}_1) = \beta_1$ ，因此，当 N 趋于无

穷

大时， $\hat{\beta}_1$ 在概率上收敛于 β_1 ，即 $\hat{\beta}_1$ 是 β_1 的一致估计量

。你能表明 $\hat{\beta}_0$ 是 β_0 的一致估计量吗？应该注意到，一致性是估计

量应该满足的最低要求。想一想，如果把总体都告诉你，但你的估计或者猜测却与真实参数不一致，你是不是应该检讨一下你的估计方法？

练习:

(1) 证明在高斯-马尔科夫假定下:

$$\delta_{\hat{\beta}_0}^2 = \left(\frac{1}{N} + \frac{\bar{x}^2}{\sum (x_i - \bar{x})^2} \right) \delta^2 = \delta^2 \frac{\sum x_i^2}{N \sum (x_i - \bar{x})^2}$$

(2) 证明在高斯-马尔科夫假定下:

$$E(\varepsilon_i - \bar{\varepsilon})^2 = \delta^2 \left(1 - \frac{1}{N} \right)$$

(3) 证明在高斯-马尔科夫假定下:

$$\text{Cov}(\varepsilon, \hat{\beta}_1) = 0$$

(4) 证明在高斯-马尔科夫假定下:

$$\text{Cov}(\hat{\beta}_0, \hat{\beta}_1) = -\frac{\bar{x} \delta^2}{\sum (x_i - \bar{x})^2}$$

2、证明方差最小

把任意一种线性估计量表示为 $\sum w_i y_i$ ，当 $w_i = k_i = \frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2}$ 时，该估计量即为 β_1 的 OLS 估计量。现在我们将证明：在所有无偏的 β_1 的线性估计量中，OLS 估计量具有最小的方差。

“在所有无偏的 β_1 的线性估计量中”是一个前提条件。我们的任务是，在给定前提下（约束条件），证明 OLS 估计量所对应的权数使方差（目标函数）取最小值。

首先分析前提条件：线性估计量的表达是

$$\hat{\beta}_1 = \sum w_i y_i = \sum w_i (\beta_0 + \beta_1 x_i + \varepsilon_i)$$

为了保证 $\hat{\beta}_1$ 的无偏性，那么应该保证：

$$E(\hat{\beta}_1) = \beta_0 \sum w_i + \beta_1 \sum w_i x_i + \sum w_i E(\varepsilon_i) = \beta_0 \sum w_i + \beta_1 \sum w_i x_i = \beta_1$$

因此， $\sum w_i = 0$ ； $\sum w_i x_i = 1$

其次分析方差表示：

$\delta_{\hat{\beta}_1}^2 = \text{Var}(\sum w_i y_i) = \text{Var}[\sum w_i (\beta_0 + \beta_1 x_i + \varepsilon_i)] = \text{Var}(\sum w_i \varepsilon_i)$ ，在假定四、五下，有： $\delta_{\hat{\beta}_1}^2 = \text{Var}(\sum w_i \varepsilon_i) = \sigma^2 \sum w_i^2$ 。

最后，形成数学问题：

$$\begin{aligned} \text{Min} \quad & \delta^2 \sum_{i=1}^N w_i^2 \\ \text{s.t.} \quad & \sum w_i = 0 \quad (1) \\ & \sum w_i x_i = 1 \quad (2) \end{aligned}$$

常数 δ^2 对于该最优化问题并不重要，因此上述问题简化为：

$$\begin{aligned} \text{Min} \quad & \sum_{i=1}^N w_i^2 \\ \text{s.t.} \quad & \sum w_i = 0 \quad (1) \\ & \sum w_i x_i = 1 \quad (2) \end{aligned}$$

对上述极值问题，其拉格朗日函数是：

$$L = \sum w_i^2 - \lambda_1 \sum w_i + \lambda_2 (1 - \sum w_i x_i)$$

相应的一阶条件是：

$$\frac{\partial l}{\partial w_1} = 2w_1 - \lambda_1 - \lambda_2 x_1 = 0$$

$$\frac{\partial l}{\partial w_i} = 2w_i - \lambda_1 - \lambda_2 x_i = 0$$

M

$$\frac{\partial l}{\partial w_N} = 2w_N - \lambda_1 - \lambda_2 x_N = 0 \quad (3group)$$

$$\frac{\partial l}{\partial \lambda_1} = -\sum w_i = 0$$

$$\frac{\partial l}{\partial \lambda_2} = 1 - \sum w_i x_i = 0$$

(4)

(5)

应该注意到，把（3group）中各式相加并利用（4）有： $N\lambda_1 + \lambda_2 \sum x_i = 0$ ，即 $\lambda_1 = -\lambda_2 \bar{x}$ ；把（3group）中第*i*式两边同乘以 x_i 并各式相加，然后利用（5），有：

$$2 - \lambda_1 \sum x_i - \lambda_2 \sum x_i^2 = 0, \quad \text{即} \quad 2 + \lambda_2 \bar{x} \sum x_i - \lambda_2 \sum x_i^2 = 0$$

$$\text{因此, } \lambda_2 = \frac{2}{\sum x_i(x_i - \bar{x})}; \quad \lambda_1 = -\frac{2\bar{x}}{\sum x_i(x_i - \bar{x})}$$

因此,

$$\begin{aligned} w_i &= \frac{\lambda_1 + \lambda_2 x_i}{2} = \frac{-\frac{2\bar{x}}{\sum x_i(x_i - \bar{x})} + \frac{2x_i}{\sum x_i(x_i - \bar{x})}}{2} = \frac{x_i - \bar{x}}{\sum x_i(x_i - \bar{x})} \\ &= \frac{x_i - \bar{x}}{\sum (x_i - \bar{x})^2} \end{aligned}$$

而在前面我们已知道这个权数正是 β_1 的 OLS 估计量所对应的权数！

练习：证明 OLS 估计量 $\hat{\beta}_0$ 在所有 β_0 的线性无偏估计量中方差是最小的。

以上内容仅为本文档的试下载部分，为可阅读页数的一半内容。
如要下载或阅读全文，请访问：

<https://d.book118.com/317144004104010014>