

矩估计

在理解了外生性的概念之后，我们接下来讨论，如果外生性成立，我们该如何估计模型

$$y_i = x_i' \beta + u_i$$

需要注意的是，以下的估计方法都建立在独立同分布的假设条件下的：

假设（独立同分布）

假设 $\{(y_i, x_i, u_i), i = 1, 2, \dots, N\}$ 为独立同分布的样本。

矩估计

- 对于回归方程：

$$y_i = x_i' \beta + u_i$$

其中 x_i 为 K 维向量，代表解释变量； β 为解释变量的系数； u_i 为误差项。

- 如果外生性假设即

$$\mathbb{E}(u_i | x_i) = 0$$

那么根据条件期望的性质，必然有

$$\mathbb{E}(x_i u_i) = \mathbb{E}[\mathbb{E}(x_i u_i | x_i)] = \mathbb{E}[x_i \mathbb{E}(u_i | x_i)] = \mathbb{E}[x_i \cdot 0] = 0$$

矩估计：识别

- 注意到不可观测误差项 u_i 可以写为 $u_i = y_i - x_i'\beta$ 从而

$$\mathbb{E}[(y_i - x_i'\beta) x_i] = 0$$

- 注意由于 $u_i = y_i - x_i'\beta$ 为标量，而 x_i 为 $K \times 1$ 的向量，因而以上方程实际上包含着 K 个矩条件。对以上方程进行整理，得到：

$$\mathbb{E}(x_i x_i') \beta = \mathbb{E}(x_i y_i)$$

如果假设 $\mathbb{E}(x_i x_i')$ 可逆，那么

$$\beta = [\mathbb{E}(x_i x_i')]^{-1} \mathbb{E}(x_i y_i)$$

矩估计

如果以上识别条件成立，根据矩估计的思想，如果我们分别使用均值：

$$\frac{1}{N} \sum_{i=1}^N x_i x_i' \text{ 和 } \frac{1}{N} \sum_{i=1}^N x_i y_i$$

代替总体均值，那么就得到了以上问题的矩估计：

$$\hat{\beta} = \left[\frac{1}{N} \sum_{i=1}^N x_i x_i' \right]^{-1} \frac{1}{N} \sum_{i=1}^N x_i y_i = \left[\sum_{i=1}^N x_i x_i' \right]^{-1} \sum_{i=1}^N x_i y_i$$

注意以上估计实际上就是最小二乘估计： $\hat{\beta} = (X'X)^{-1} X'Y$ 。

极大似然估计方法

- 如果在外生性假设上更进一步，不仅假设 $E(u_i|x_i) = 0$ ，同时假设 $u_i|x_i$ 的分布，比如正态分布，我们还可以得到 β 的极大似然估计。
- 如果假设 $u_i|x_i \sim N(0, \sigma^2)$ ，那么 $y_i|x_i \sim N(x_i'\beta, \sigma^2)$ ，因而其条件极大似然函数为：

$$L(Y|X) = \sum_{i=1}^N \left[-\ln(2\pi) - \ln\sigma - \frac{(y_i - x_i'\beta)^2}{\sigma^2} \right]$$

- 最大化以上似然函数，实际上等价于最小化目标函数：

$$\sum_{i=1}^N (y_i - x_i'\beta)^2$$

即最小二乘的目标函数

- 因而在正态分布的假设下，使用条件极大似然方法得到的 β 的估计同样也是最小二乘估计量。

无偏性

无偏性意味着最小二乘估计量 $\hat{\beta}$ 估计真实参数 β 的平均（期望）误差为0。对于无偏性，由于：

$$\begin{aligned}\hat{\beta} &= (X'X)^{-1} X'Y \\ &= (X'X)^{-1} X'(X\beta + u) \\ &= \beta + (X'X)^{-1} X'u\end{aligned}$$

其中 $u = [u_1, \dots, u_N]'$ 为误差项向量。从而：

$$\begin{aligned}\mathbb{E}(\hat{\beta}|X) &= \beta + \mathbb{E}[(X'X)^{-1} X'u|X] \\ &= \beta + (X'X)^{-1} X'\mathbb{E}(u|X)\end{aligned}$$

在外生性假设下，有： $\mathbb{E}(\hat{\beta}|X) = \beta$ ，从而：

$$\mathbb{E}(\hat{\beta}) = \mathbb{E}[\mathbb{E}(\hat{\beta}|X)] = \beta$$

因而最小二乘估计是真实参数 β 的无偏估计。

$\hat{\beta}$ 的方差估计

此外我们还可以计算最小二乘估计 $\hat{\beta}$ 的方差。由于

$$\mathbb{V}(\hat{\beta}) = \mathbb{E}[\mathbb{V}(\hat{\beta}|X)] + \mathbb{V}[\mathbb{E}(\hat{\beta}|X)]$$

而其中 $\mathbb{E}(\hat{\beta}|X) = \beta$ 从而

$$\mathbb{V}[\mathbb{E}(\hat{\beta}|X)] = 0$$

因而我们接下来将主要经历放在 $\mathbb{V}(\hat{\beta}|X)$ 上。

$\hat{\beta}$ 的方差估计

注意到由于 $\hat{\beta} - \beta = (X'X)^{-1} X'u$ ，因而 $\hat{\beta}$ 的条件协方差矩阵为：

$$\begin{aligned}\mathbb{V}(\hat{\beta}|X) &= \mathbb{E} \left(\left[\hat{\beta} - \mathbb{E}(\hat{\beta}|X) \right] \left[\hat{\beta} - \mathbb{E}(\hat{\beta}|X) \right]' | X \right) \\ &= \mathbb{E} \left[\left(\hat{\beta} - \beta \right) \left(\hat{\beta} - \beta \right)' | X \right] \\ &= \mathbb{E} \left[\left(X'X \right)^{-1} X'uu'X \left(X'X \right)^{-1} | X \right] \\ &= \left(X'X \right)^{-1} X' \mathbb{E} [uu'|X] X \left(X'X \right)^{-1}\end{aligned}$$

了计算以上的方差，我们需要知道 $\mathbb{E}[uu'|X]$ 的结构。

同方差假设

- 根据独立同分布假设，易知 $\mathbb{E}(u_i u_j | X) = 0$ ，从而 $\mathbb{E}[u u' | X]$ 一定是一个对角矩阵。
- 此外，我们还需要对对角线元素，也就是 $\mathbb{V}(u_i | X) = \mathbb{V}(u_i | x_i)$ 的假设。

假设（同方差，homoscedasticity）

假设 $\mathbb{V}(u_i | x_i) = \sigma^2$ 。

同方差假设

在同方差假定下：

$$\begin{aligned} \mathbb{E}(uu'|X) &= \begin{bmatrix} \mathbb{V}(u_1|X) & \text{Cov}(u_1, u_2|X) & \cdots & \text{Cov}(u_1, u_N|X) \\ \text{Cov}(u_2, u_1|X) & \mathbb{V}(u_2|X) & \cdots & \text{Cov}(u_2, u_N|X) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(u_N, u_1|X) & \text{Cov}(u_N, u_2|X) & \cdots & \mathbb{V}(u_N|X) \end{bmatrix} \\ &= \begin{bmatrix} \sigma^2 & 0 & \cdots & 0 \\ 0 & \sigma^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma^2 \end{bmatrix}_{N \times N} = \sigma^2 I \end{aligned}$$

则上式可以化简为：

$$\begin{aligned} \mathbb{V}(\hat{\beta}|X) &= (X'X)^{-1} X' \mathbb{E}[uu'|X] X (X'X)^{-1} \\ &= (X'X)^{-1} X' \sigma^2 I X (X'X)^{-1} \\ &= \sigma^2 (X'X)^{-1} \end{aligned}$$

高斯-马尔可夫定理

- 可以证明，在 β 的所有线性无偏估计量中，最小二乘估计量是方差最小的估计量。
- 其中「线性性」意味着 β 的估计值是 Y 的一个线性函数，即可以写成 $\tilde{\beta} = CY$ 的形式， C 是一个不依赖于 Y （但是可以依赖于 X ）的矩阵。

高斯-马尔可夫定理, Gauss-Morkov theorem

在外生性假设、独立同分布假设、识别假设、同方差假设的条件下，最小二乘估计量 $\hat{\beta}$ 是 β 的无偏估计量，此外最小二乘估计量是所有 β 的线性无偏估计量中方差最小的估计量，因而我们也称最小二乘估计量为最优线性无偏估计量（Best linear unbiased estimator, BLUE）。

标准误的估计

- 以上我们计算了在同方差假定下，最小二乘估计量的条件方差：

$$\mathbb{V}(\hat{\beta}|X) = \sigma^2 (X'X)^{-1} \quad (1)$$

其中 $(X'X)^{-1}$ 是可观测的，但是 σ^2 不可观测，所以为了计算条件方差的估计： $\widehat{\mathbb{V}(\hat{\beta}|X)}$ ，我们还需要计算 σ^2 的估计。

- 由于 σ^2 是在同方差条件下误差项 u_i 的方差，一个很自然的想法是可以使用残差的方差：

$$\frac{1}{N-1} \sum_{i=1}^N \hat{u}_i^2 = \frac{\hat{u}'\hat{u}}{N-1}$$

对 σ^2 进行估计，然而该估计量不是无偏估计。

σ^2 的估计

- 可以证明：

$$\mathbb{E}\left(\frac{\hat{u}'\hat{u}}{N-K}\right) = \sigma^2$$

从而对于 σ^2 的无偏估计为

$$\hat{\sigma}^2 = s^2 = \frac{\hat{u}'\hat{u}}{N-K} = \frac{RSS}{N-K}$$

我们称之为均方误差（mean squared error, MSE），从而残差平方和除以 $N-K$ 得到了 σ^2 的无偏估计，所以残差平方和的自由度为 $N-K$ 。

- 而均方根误差（root mean squared error, RMSE）即均方误差的开平方：

$$RMSE = \sqrt{MSE} = \sqrt{\frac{RSS}{N-K}}$$

标准误的估计

- 将以上的无偏估计带入到式(1)中，就可以得到条件方差的估计：

$$\widehat{\mathbb{V}}(\hat{\beta}|X) = s^2 (X'X)^{-1} = \frac{RSS}{N-K} (X'X)^{-1}$$

- 从而 $\hat{\beta}_k$ 的标准误的估计为：

$$s.e.(\hat{\beta}_k) = \sqrt{s^2 (X'X)^{-1}_{kk}}$$

其中 $(X'X)^{-1}_{kk}$ 代表矩阵 $(X'X)^{-1}$ 的第 k 行第 k 列的元素值。

σ^2 的估计

- 进一步，在正态性假设下，有

$$\frac{(N - K) s^2}{\sigma^2} \sim \chi^2(N - K)$$

以上分布结论将是更进一步的假设检验结论的基础。

小样本分布

- 在正态性假设基础之上，由于 $\hat{\beta} - \beta = (X'X)^{-1} X'u$ ，因而：

$$\hat{\beta}|X \sim N\left(\beta, \sigma^2 (X'X)^{-1}\right)$$

- 进而，单独某一个系数的分布也是正态分布，即：

$$\hat{\beta}_k|X \sim N\left(\beta_k, \sigma^2 (X'X)^{-1}_{kk}\right)$$

小样本分布

- 对以上分布进行标准化，得到：

$$\frac{\hat{\beta}_k - \beta_k}{\sqrt{\sigma^2 (X'X)^{-1}_{kk}}} | X \sim N(0, 1)$$

- 注意以上的标准正态分布是不依赖于任何未知参数的，即给定任意的 X ，上式都服从标准正态分布，从而我们可以把给定 X 去掉，得到：

$$\frac{\hat{\beta}_k - \beta_k}{\sqrt{\sigma^2 (X'X)^{-1}_{kk}}} \sim N(0, 1)$$