

计量经济学

第7讲：OLS估计的小样本推断

授课人：刘 岩

中山大学商学院

2025年3月24日

本讲内容

- ① OLS 估计方差无偏性证明
- ② 多元正态分布的基本性质
- ③ 小样本 OLS 估计的分布

本节内容

- 1 OLS 估计方差无偏性证明
- 2 多元正态分布的基本性质
- 3 小样本 OLS 估计的分布

方差估计无偏性的证明

结论 在线性回归基本假设 1-3 下，给定模型 OLS 估计所得残差向量 $\mathbf{e} = \mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}$ ，则

$$s^2 = \frac{SSR_{OLS}}{N - K} = \frac{\mathbf{e}^\top \mathbf{e}}{N - K}$$

为模型误差项方差 σ^2 的无偏估计量，即 $\mathbb{E}[s^2] = \sigma^2$

证明 将证明 $\mathbb{E}[s^2|\mathbf{X}] = \sigma^2$ ，进而得到 $\mathbb{E}[s^2] = \sigma^2$ 。首先，首先注意到

$\mathbf{e} = \mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{Y} - \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} = (\mathbf{I}_N - \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top) \mathbf{Y}$ ；定义矩阵

$\mathbf{M} \equiv \mathbf{I}_N - \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top$ ，则有 $\mathbf{M}\mathbf{X} = \mathbf{0}$ ，故 $\mathbf{e} = \mathbf{M}\mathbf{Y} = \mathbf{M}(\mathbf{X}\boldsymbol{\beta}_0 + \boldsymbol{\varepsilon}) = \mathbf{M}\boldsymbol{\varepsilon}$ ；同

时，易验证 $\mathbf{M}^2 = \mathbf{M}$ ，由此知 $\mathbf{e}^\top \mathbf{e} = \boldsymbol{\varepsilon}^\top \mathbf{M}\boldsymbol{\varepsilon}$ ，故 $\mathbb{E}[\mathbf{e}^\top \mathbf{e}|\mathbf{X}] = \mathbb{E}[\boldsymbol{\varepsilon}^\top \mathbf{M}\boldsymbol{\varepsilon}|\mathbf{X}]$ 。

方差估计无偏性的证明

继续 其次, 令 m_{ij} 为 M 的第 i 行、第 j 列元素, 则有 $\boldsymbol{\varepsilon}^\top \mathbf{M} \boldsymbol{\varepsilon} = \sum_{i=1}^N \sum_{j=1}^N \varepsilon_i \varepsilon_j m_{ij}$, 取期望可得

$$\mathbb{E}[\boldsymbol{\varepsilon}^\top \mathbf{M} \boldsymbol{\varepsilon} | \mathbf{X}] = \sum_{i=1}^N \sum_{j=1}^N \mathbb{E}[\varepsilon_i \varepsilon_j m_{ij} | \mathbf{X}] = \sum_{i=1}^N \sum_{j=1}^N m_{ij} \mathbb{E}[\varepsilon_i \varepsilon_j | \mathbf{X}] = \sum_{i=1}^N \sigma^2 m_{ii} = \sigma^2 \text{tr}(\mathbf{M})$$

最后, 由矩阵求迹 $\text{tr}(\cdot)$ 的性质可知

$$\begin{aligned} \text{tr}(\mathbf{M}) &= \text{tr}(\mathbf{I}_N - \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top) = \text{tr}(\mathbf{I}_N) - \text{tr}(\mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top) \\ &= N - \text{tr}((\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{X}) = N - \text{tr}(\mathbf{I}_K) = N - K \end{aligned}$$

$$\text{故 } \mathbb{E}[s^2 | \mathbf{X}] = \frac{(N-K)\sigma^2}{N-K} = \sigma^2。$$

本节内容

- 1 OLS 估计方差无偏性证明
- 2 多元正态分布的基本性质**
- 3 小样本 OLS 估计的分布

协方差矩阵：矩阵表示

- 给定随机向量 $\mathbf{X} = [X_1, \dots, X_n]^\top$ ，其协方差矩阵 $\text{var}(\mathbf{X})$ 定义为

$$\text{var}(\mathbf{X}) = \boldsymbol{\Sigma}_{\mathbf{X}} \equiv \begin{bmatrix} \text{cov}(X_1, X_1) & \cdots & \text{cov}(X_1, X_n) \\ \vdots & \ddots & \vdots \\ \text{cov}(X_n, X_1) & \cdots & \text{cov}(X_n, X_n) \end{bmatrix}$$

- \mathbf{X} 的期望记为 $\boldsymbol{\mu}_{\mathbf{X}}$ ，则

$$\boldsymbol{\Sigma}_{\mathbf{X}} = \mathbb{E}[(\mathbf{X} - \boldsymbol{\mu}_{\mathbf{X}})(\mathbf{X} - \boldsymbol{\mu}_{\mathbf{X}})^\top] = \mathbb{E}[\mathbf{X}\mathbf{X}^\top] - \boldsymbol{\mu}_{\mathbf{X}}\boldsymbol{\mu}_{\mathbf{X}}^\top$$

随机向量的仿射变换

给定 n -维随机向量 $\mathbf{X} = [X_1, \dots, X_n]^\top$, 假设有 $m \times n$ 常数变换矩阵 \mathbf{A} , 以及 $m \times 1$ 常数平移向量 (translation vector) \mathbf{c}

- $\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{c}$ 是一个 m -维随机向量, 称为 \mathbf{X} 的仿射变换 (affine transformation)
 - 当 $\mathbf{c} = \mathbf{0}$ 时, 仿射变换退化为线性变换
- 期望的仿射变换: $\boldsymbol{\mu}_Y = \mathbb{E}\mathbf{Y} = \mathbb{E}\mathbf{A}\mathbf{X} + \mathbf{c} = \mathbf{A}\mathbb{E}\mathbf{X} + \mathbf{c} = \mathbf{A}\boldsymbol{\mu}_X + \mathbf{c}$
- \mathbf{Y} 的协方差矩阵 $\boldsymbol{\Sigma}_Y$ 可写为

$$\begin{aligned}\boldsymbol{\Sigma}_Y &= \mathbb{E}[\mathbf{Y}\mathbf{Y}^\top] - \boldsymbol{\mu}_Y\boldsymbol{\mu}_Y^\top \\ &= \mathbb{E}[(\mathbf{A}\mathbf{X} + \mathbf{c})(\mathbf{X}^\top\mathbf{A}^\top + \mathbf{c}^\top)] - (\mathbf{A}\boldsymbol{\mu}_X + \mathbf{c})(\boldsymbol{\mu}_X^\top\mathbf{A}^\top + \mathbf{c}^\top) \\ &= \mathbf{A}\left(\mathbb{E}[\mathbf{X}\mathbf{X}^\top] - \boldsymbol{\mu}_X\boldsymbol{\mu}_X^\top\right)\mathbf{A}^\top \\ &= \mathbf{A}\boldsymbol{\Sigma}_X\mathbf{A}^\top\end{aligned}$$

多元正态分布的仿射变换

- n 维正态分布: $\mathbf{X} = [X_1, \dots, X_n] \sim \mathcal{N}(\boldsymbol{\mu}_X, \boldsymbol{\Sigma}_X)$, 令 $\mathbf{x} = [x_1, \dots, x_n]^\top$, 其密度函数为

$$f(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^n \det \boldsymbol{\Sigma}_X}} \exp \left\{ -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_X)^\top \boldsymbol{\Sigma}_X^{-1}(\mathbf{x} - \boldsymbol{\mu}_X) \right\}$$

- 考虑仿射变换 $\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{c}$, \mathbf{A} 为 $m \times n$ 常数变换矩阵, \mathbf{c} 为 $m \times 1$ 常数向量, 则 \mathbf{Y} 服从 m 元正态分布, 即 $\mathbf{Y} \sim \mathcal{N}(\boldsymbol{\mu}_Y, \boldsymbol{\Sigma}_Y) = \mathcal{N}(\mathbf{A}\boldsymbol{\mu}_X + \mathbf{c}, \boldsymbol{\Sigma}_X)$

结论 若 \mathbf{X} 服从多维正态分布, 且对某两个 X_i, X_j 有 $\text{cov}(X_i, X_j) = 0$, 则 X_i, X_j 相互独立

例 考虑 2 维标准正态 $\mathbf{X} \sim \mathcal{N}(\mathbf{0}, \mathbf{I}_2)$, 则 $Y_1 = X_1 + X_2, Y_2 = X_1 - X_2$ 相互独立

本节内容

- 1 OLS 估计方差无偏性证明
- 2 多元正态分布的基本性质
- 3 小样本 OLS 估计的分布**

OLS 估计系数的分布

- 假设 DGP 中系数向量真实值为 β_0 , OLS 估计为 $\hat{\beta} = \beta_0 + (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \varepsilon$, 则在假设 1-3 之下 $\mathbb{E}[\hat{\beta} - \beta_0 | \mathbf{X}] = \mathbf{0}$ 且

$$\begin{aligned} \text{var}(\hat{\beta} | \mathbf{X}) &= \text{var}(\hat{\beta} - \beta_0 | \mathbf{X}) = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \underbrace{\mathbb{E}[\varepsilon \varepsilon^\top | \mathbf{X}]}_{=\sigma^2 \mathbf{I}} \mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{I} \mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1} = \sigma^2 (\mathbf{X}^\top \mathbf{X})^{-1} \end{aligned}$$

- 进一步引入假设 4, 则条件在 \mathbf{X} 上时, $\hat{\beta}$ 的随机性完全来自 $\varepsilon \sim \mathcal{N}(0, \sigma^2 \mathbf{I})$, 且为 ε 的仿射变换, 故同样服从多元正态分布, 即

$$\hat{\beta} - \beta_0 | \mathbf{X} \sim \mathcal{N}(\mathbf{0}, \sigma^2 (\mathbf{X}^\top \mathbf{X})^{-1})$$

OLS 估计系数的假设检验：单系数情形

- 给定 $\hat{\beta} - \beta_0 | \mathbf{X} \sim \mathcal{N}(\mathbf{0}, \sigma^2(\mathbf{X}^\top \mathbf{X})^{-1})$ ，似乎可以对任意 $\beta_k, k = 0, \dots, K - 1$ 进行假设检验
 - 如果 σ^2 确实是已知参数，则 $\hat{\beta}_k - \beta_{k,0} \sim \mathcal{N}(0, \sigma^2[(\mathbf{X}^\top \mathbf{X})^{-1}]_{k+1,k+1})$ ，其中 $[(\mathbf{X}^\top \mathbf{X})^{-1}]_{k+1,k+1}$ 表示矩阵 $(\mathbf{X}^\top \mathbf{X})^{-1}$ 对角线上第 $k + 1$ 个元素，此时

$$z_k \equiv \frac{\hat{\beta}_k - \beta_{k,0}}{\sqrt{\sigma^2[(\mathbf{X}^\top \mathbf{X})^{-1}]_{k+1,k+1}}} \sim \mathcal{N}(0, 1)$$

是一个直接可用的检验统计量：给定原假设下 $\beta_{k,0}$ 的取值，由样本 $\{Y_i, \mathbf{X}_i\}_{i=1}^N$ 可直接计算分子和分母取值，并且知晓该统计量服从标准正态分布

- 问题在于， σ^2 也是模型未知参数
- 简单的想法：用样本统计量 $s^2 = \mathbf{e}^\top \mathbf{e} / (N - K)$ 代替 σ^2


单系数检验的 t -统计量

- 对回归系数 β_k , 构造如下 t -统计量

$$t_k \equiv \frac{\hat{\beta}_k - \beta_{k,0}}{\sqrt{s^2[(\mathbf{X}^T \mathbf{X})^{-1}]_{k+1,k+1}}}, \quad k = 0, \dots, K-1$$

结论 假设 1-4 成立时, 给定样本 \mathbf{X} 的条件下, 统计量 $t_k | \mathbf{X}$ 服从自由度为 $N-K$ 的 t -分布

- t -分布的密度函数可以直接写出, 但没有必要掌握 (记住)
- 给定两个相互独立的随机变量 W, Z , 其中 $W \sim \mathcal{N}(0, 1)$ 而 $Z \sim \chi^2(N-K)$, 即 Z 服从自由度为 $N-K$ 的 χ^2 分布, 则 $U = \frac{W}{\sqrt{Z/(N-K)}}$ 服从自由度为 $N-K$ 的 student t -分布, 记作 $t(N-K)$ 分布
- 自由度为 L 的 χ^2 分布, 念卡方分布, 记作 $\chi^2(L)$ 分布, 定义为 L 个相互独立的标准正态分布随机变量的平方和

Student t -分布密度函数：自由度 $\nu = 1, 2, 5$ 

当 $\nu \rightarrow \infty$ 时， t -分布密度函数趋近于标准正态分布，即 t 分布当自由度趋近于无穷时，分布函数收敛到标准正态分布

单系数检验的 t -统计量：证明

证明 t_k 可写为

$$t_k \equiv \frac{\hat{\beta}_k - \beta_{k,0}}{\sqrt{\sigma^2[(\mathbf{X}^\top \mathbf{X})^{-1}]_{k+1,k+1}} \cdot \sqrt{\frac{s^2}{\sigma^2}}} = \frac{z_k}{\sqrt{\frac{\mathbf{e}^\top \mathbf{e}/(N-K)}{\sigma^2}}}$$

注意到条件在 \mathbf{X} 下时，分子 $z_k \sim \mathcal{N}(0, 1)$ ，故只需证明分母与分子独立且为 $\chi^2(N-K)$ 分布。

为此，注意到 $z_k | \mathbf{X}$ 通过 $\hat{\beta}_k$ 是 $\boldsymbol{\varepsilon}$ 的线性变换，而 $\mathbf{e} = \mathbf{M}\boldsymbol{\varepsilon}$ 也是 $\boldsymbol{\varepsilon}$ 的线性变换，故 $(\hat{\boldsymbol{\beta}}, \mathbf{e}) | \mathbf{X}$ 为联合正态分布，于是由 $\text{cov}(\hat{\boldsymbol{\beta}}, \mathbf{e} | \mathbf{X}) = \mathbf{0}_{K,N}$ （最后证明）说明二者无相关性，进而相互独立。这进一步意味着 z_k 与 $\mathbf{e}^\top \mathbf{e}$ 独立，故分子与分母独立。而 $\frac{1}{\sigma^2} \mathbf{e}^\top \mathbf{e} = \frac{1}{\sigma^2} \boldsymbol{\varepsilon}^\top \mathbf{M} \boldsymbol{\varepsilon}$ 可证明服从 $\chi^2(N-K)$ 分布（不做要求）。

单系数检验的 t -统计量：证明

继续 最后验证 $\text{cov}(\hat{\beta}, e|X) = \mathbf{0}_{K,N}$ 。事实上，该条件协方差定义为 $\mathbb{E}[(\hat{\beta} - \beta_0)e^\top|X]$ ，而 $\hat{\beta} - \beta_0 = (X^\top X)^{-1}X^\top \varepsilon$ ， $e^\top = \varepsilon^\top M$ ，故

$$\begin{aligned}\mathbb{E}[(\hat{\beta} - \beta_0)e^\top|X] &= (X^\top X)^{-1}X^\top \mathbb{E}[\varepsilon \varepsilon^\top|X]M = (X^\top X)^{-1}X^\top(\sigma^2 I)M \\ &= \sigma^2(X^\top X)^{-1}X^\top(I - X(X^\top X)^{-1}X^\top) = \mathbf{0}_{K,N}\end{aligned}$$