

计量经济学

第 6 讲：OLS 估计的小样本性质

授课人：刘 岩

中山大学商学院

2025 年 3 月 17 日

本讲内容

- ① 基本假设
- ② 模型拟合
- ③ 系数与方差的无偏估计

本节内容

- 1 基本假设
- 2 模型拟合
- 3 系数与方差的无偏估计

线性回归模型：小样本 vs 大样本

考虑线性回归模型

$$Y_i = \mathbf{X}_i^\top \boldsymbol{\beta} + \varepsilon_i, \quad i = 1, \dots, N$$

其中 \mathbf{X}_i 为 K 个解释变量的列向量

- 小样本 (small sample): 给定有限样本量, $N < \infty$, 且通常而言 $N \leq 100$
 - 重点在于样本量 N 有限且给定, 满足 $N > K$
 - 此时可以简单将 $\mathbf{X} = [\mathbf{X}_1^\top, \dots, \mathbf{X}_N^\top]^\top$ 视作给定的 $N \times K$ 矩阵
 - \mathbf{X}_i 的随机性不重要, DGP 随机性焦点在 $\{\varepsilon_i\}$, 不过为与大样本理论衔接, 依然假设 $\{\mathbf{X}_i\}$ 随机
- 大样本 (large sample): 样本量趋于无穷 $N \rightarrow \infty$
 - 这是一个理论假定 (theoretic postulate), 现实应用中样本量都是有限的, 但不妨碍考虑 $N \rightarrow \infty$ 的情况
 - 此时 \mathbf{X}_i 的随机性质就变得非常关键, 需要一系列额外假设

小样本回归的标准假设

考虑小样本线性回归模型

$$Y_i = \mathbf{X}_i^\top \boldsymbol{\beta} + \varepsilon_i, \quad i = 1, \dots, N < \infty$$

相应的标准假设如下：

- ① **外生性**： $\mathbb{E}[\varepsilon_i | \mathbf{X}] = \mathbb{E}[\varepsilon_i | \mathbf{X}_1, \dots, \mathbf{X}_N] = 0, i = 1, \dots, N$
 - $\mathbb{E}[W|Z]$ 表示 W 条件在 Z 上的期望，称为条件期望 (conditional expectation)
 - 外生性意味着 $\mathbb{E}\varepsilon_i = 0$ 以及 $\mathbb{E}[X_{ki}\varepsilon_i] = 0, k = 0, \dots, K - 1, i = 1, \dots, N$
- ② **无多重共线性**：矩阵 \mathbf{X} 列满秩，即 $\text{rank}(\mathbf{X}) = K < N$
 - 多重共线性 (multi-collinearity)： K 个变量之间线性相关，即某个线性组合为常数，方差为 0
 - 此时 $\mathbf{X}^\top \mathbf{X}$ 为可逆矩阵：注意到 $\text{rank}(\mathbf{X}) = K$ 时 $\mathbf{X}^\top \mathbf{X}$ 为正定矩阵，故可逆

小样本回归的标准假设

- ③ **球面误差**: 误差项方差为常数 $\mathbb{E}[\varepsilon_i^2|\mathbf{X}] = \sigma^2 > 0, i = 1, \dots, N$, 以及不同观测间误差项无相关性 $\mathbb{E}[\varepsilon_i \varepsilon_j|\mathbf{X}] = 0, i, j = 1, \dots, N, i \neq j$
 - 又称为同方差 (homoskedasticity) 假设, 其矩阵形式为 $\mathbb{E}[\varepsilon\varepsilon^\top|\mathbf{X}] = \sigma^2\mathbf{I}_N$
 - 上述假设弱于 $\{\varepsilon_i\}$ 为 iid 序列; 若 $\{\varepsilon_i\}$ iid, 且与 \mathbf{X} 独立, 则自动满足假设 1 和 3
- ④ **误差正态分布**: $\{\varepsilon_i\}_{i=1}^N \stackrel{\text{iid}}{\sim} \mathcal{N}(0, \sigma^2)$, 且 ε_i 与 \mathbf{X} 相互独立, $i = 1, \dots, N$
 - 该假设同时蕴含假设 1 和 3, 是线性回归模型经典 (classical) 理论的主要假设

注 对于线性回归模型小样本经典理论而言, \mathbf{X} 的随机性并不重要, 上述假设中 ε_i 关于 \mathbf{X} 的条件期望, 均可换为 ε_i 的无条件期望, 称为固定回归变量 (fixed regressor)

本节内容

- 1 基本假设
- 2 模型拟合
- 3 系数与方差的无偏估计

线性回归模型的拟合值

考虑给定样本 $\{Y_i, X_i\}_{i=1}^N$ 下的线性回归模型 $Y_i = X_i^\top \beta + \varepsilon_i, i = 1, \dots, N$

- 给定 OLS 估计 $\hat{\beta} = (X^\top X)^{-1} X^\top Y$, 则

$$\hat{Y}_i = X_i^\top \hat{\beta}, \quad i = 1, \dots, N$$

称为 Y_i 的 OLS 拟合值 (fitted value), 或 预测值 (prediction/predicted value)

- $e_i \equiv Y_i - \hat{Y}_i = Y_i - X_i^\top \hat{\beta}$ 称为 OLS 残差 (residual)
- 残差向量 $e = [e_1, \dots, e_N]^\top$ 满足

$$e = Y - X\hat{\beta}, \quad X^\top e = 0$$

后一等式表示残差向量 e 与 X 的所有列向量正交

残差平方和与方差分解

- 给定任意的拟合值 $\{\hat{Y}_i\}$ 及相应的残差 $\{e_i\}$, 可定义残差平方和 (sum of squared residuals) 为

$$SSR = \sum_{i=1}^N e_i^2 = \mathbf{e}^T \mathbf{e}$$

- 对于 OLS 拟合值及残差, 有 $Y_i = \hat{Y}_i + e_i$ 或 $\mathbf{Y} = \hat{\mathbf{Y}} + \mathbf{e}$, 且 $\hat{\mathbf{Y}}^T \mathbf{e} = \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{e} = \mathbf{0}$, 故因变量样本变动 (sample variation) 满足:

$$\sum_{i=1}^N Y_i^2 = \mathbf{Y}^T \mathbf{Y} = (\hat{\mathbf{Y}} + \mathbf{e})^T (\hat{\mathbf{Y}} + \mathbf{e}) = \hat{\mathbf{Y}}^T \hat{\mathbf{Y}} + \hat{\mathbf{e}}^T \hat{\mathbf{e}} = \sum_{i=1}^N \hat{Y}_i^2 + SSR_{OLS}$$

上述结果又称为因变量的方差分解 (variance decomposition)

线性回归模型的 R^2

- OLS 估计下, $\mathbf{Y}^T\mathbf{Y} = \hat{\mathbf{Y}}^T\hat{\mathbf{Y}} + \hat{\mathbf{e}}^T\hat{\mathbf{e}}$, 故可定义线性回归的 R^2 为

$$R^2 = \frac{\hat{\mathbf{Y}}^T\hat{\mathbf{Y}}}{\mathbf{Y}^T\mathbf{Y}} = 1 - \frac{\hat{\mathbf{e}}^T\hat{\mathbf{e}}}{\mathbf{Y}^T\mathbf{Y}} = 1 - \frac{SSR_{OLS}}{\mathbf{Y}^T\mathbf{Y}}$$


R^2 反映了线性回归模型对数据样本的整体拟合情况, 或模型的解释力 (explanatory power)

- 又由 $\hat{\mathbf{Y}}^T\hat{\mathbf{Y}}, \hat{\mathbf{e}}^T\hat{\mathbf{e}} \geq 0$, 可知 $R^2 \in [0, 1]$
- 对非 OLS 估计, 也可以类似定义 $R^2 = 1 - \frac{SSR}{\mathbf{Y}^T\mathbf{Y}}$, 但此时 R^2 可能为负值, 即 $SSR > \mathbf{Y}^T\mathbf{Y}$, 这在工具变量估计 (2SLS) 中很常见

线性回归与拟合值示例

DGP: $\varepsilon_i \stackrel{\text{iid}}{\sim} \mathcal{N}(0, 0.5^2)$, $X_i \stackrel{\text{iid}}{\sim} \mathcal{N}(0, 1)$, $Y_i = 0.2 + 0.8X_i + \varepsilon_i$, $N = 100$

样本散点图



回归模型 $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$ 估计值为 $\hat{\beta}_0 = 0.1248$, $\hat{\beta}_1 = 0.7696$, $R^2 = 0.7762$

本节内容

- ① 基本假设
- ② 模型拟合
- ③ 系数与方差的无偏估计

OLS 系数估计的无偏性

- 假设线性回归模型的数据生成过程 (DGP) 中, 回归系数的真实值为 β_0 , 即 $Y = X\beta_0 + \varepsilon$, 则回归系数的 OLS 估计满足

$$\hat{\beta} = (X^T X)^{-1} X^T Y = (X^T X)^{-1} X^T (X\beta_0 + \varepsilon) = \beta_0 + (X^T X)^{-1} X^T \varepsilon$$

- 上式两端取期望, 可得 $\mathbb{E}[\hat{\beta}] = \beta_0 + \mathbb{E}[(X^T X)^{-1} X^T \varepsilon]$
- 由全期望律 (law of total expectation), 即 $\mathbb{E}[W] = \mathbb{E}_Z\{\mathbb{E}[W|Z]\}$, 可知

$$\mathbb{E}[(X^T X)^{-1} X^T \varepsilon] = \mathbb{E}_X\{\mathbb{E}[(X^T X)^{-1} X^T \varepsilon|X]\}$$

- 在假设 1 下, 由条件期望的提出性 (pulling out), 即对任意函数 $f(\cdot)$ 有 $\mathbb{E}[f(Z)W|Z] = f(Z)\mathbb{E}[W|Z]$, 得

$$\mathbb{E}_X\{\mathbb{E}[(X^T X)^{-1} X^T \varepsilon|X]\} = \mathbb{E}_X\{(X^T X)^{-1} X^T \mathbb{E}[\varepsilon|X]\} = \mathbb{E}_X\{\mathbf{0}\} = \mathbf{0}$$

OLS 系数估计的无偏性

结论 在假设 1-2 下, 线性回归模型系数的 OLS 估计 $\hat{\beta}$ 是模型系数真实值 β_0 的无偏估计, 即

$$\mathbb{E}[\hat{\beta}] = \beta_0$$

证明 前页计算可知

$$\mathbb{E}[(X^T X)^{-1} X^T \varepsilon] = \mathbf{0}$$

$$\text{故 } \mathbb{E}[\hat{\beta}] = \beta_0 + \mathbb{E}[(X^T X)^{-1} X^T \varepsilon] = \beta_0$$

方差的无偏估计

在假设 1-3 下，可证明 OLS 估计得到的残差平方和 SSR_{OLS} 及相应的

$$s^2 \equiv \frac{SSR_{OLS}}{N - K}$$

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