

- ◆ § 3.1 多元回归分析：估计问题
- ◆ § 3.2 多元回归分析：推断问题
- ◆ § 3.3 线性回归模型的矩阵表达

## § 3.1 多元回归分析: 估计问题

- 3.1.1 三变量模型: 符号与假定
- 3.1.2 对多元回归方程的解释
- 3.1.3 偏回归系数的含义
- 3.1.4 偏回归系数的OLS 与ML 估计
- 3.1.5 多元判定系数 $R^2$  与多元相关系数 $R$
- 3.1.6 一个说明性例子
- 3.1.7 从多元回归的角度看简单回归: 设定偏误初探
- 3.1.8  $R^2$ 及调整 $R^2$
- 3.1.9 柯布-道格拉斯生产函数: 函数形式再议
- 3.1.10 多项式回归模型
- 3.1.11 偏相关系数

- 三变量的PRF为：

(式7.1.1)

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$$

- $\beta_1$  : 截距项
- $u_i$  表示所有未包含到模型中来的变量对Y的平均影响。
- $\beta_2$  和  $\beta_3$  : 偏回归系数 (partial regression coefficients)
- $i$  : 指第*i*次观测，当数据为时间序列时用*t*表示；

(式7.1.2)

- **假设1：线性回归模型**
  - 模型中参数必须线性，变量可以不是线性；
- **假设2：X是固定的或独立于误差项**
  - 每个 $u_i$ 和每个X之间协方差为0

(式7.1.3)

$$\text{cov}(X_{2i}, \mu_i) = \text{cov}(X_{3i}, \mu_i) = 0, i = 1, 2, \dots, n$$

- **假设3：干扰项 $u_i$ 的均值为零，即：**

(式7.1.4)

$$E(u_i | X_{2i}, X_{3i}) = 0$$

- **假设4：同方差性或 $\mu_i$ 的方差相等**

(式7.1.5)

$$\text{var}(u_i) = \sigma^2$$

- 假设5：干扰项 $u_i$ 无序列相关

(式7.1.4)

$$\text{COV}(u_i, u_j) = 0 \quad i \neq j$$

(式7.1.5)

- 假设6：观测次数 $n$ 必须大于参数个数（3）

(式7.1.6)

- 假设7：X变量值必须存在变异

(式7.1.7)

- 假设8：X变量间不存在完全共线性：

(式7.1.8)

- 假设9：模型无设定偏误

(式7.1.1)

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$$

(式7.2.1)

$$E(Y_i | X_{2i}, X_{3i}) = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i}$$

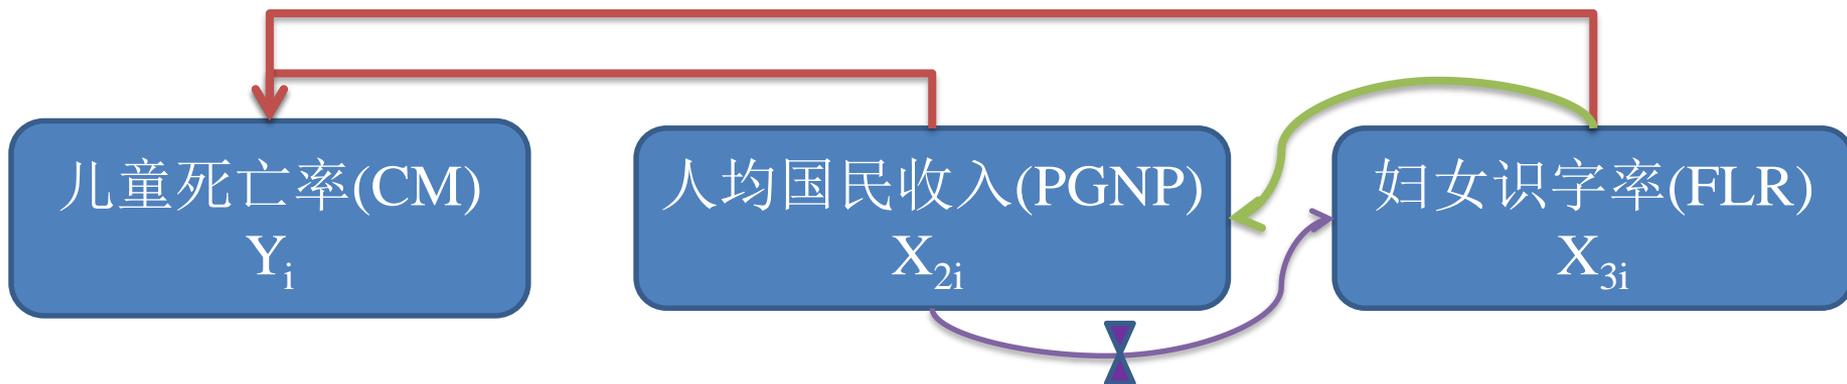
- 多元回归分析是以多个解释变量的固定值为条件的回归分析。
- 我们所获得的，是各个自变量X值固定时，Y的平均值或Y的平均响应（mean response）。

(式7.1.1)

(式7.2.1)

- 偏回归系数的含义：
  - $\beta_2$  度量着在保持 $X_3$ 不变的情况下， $X_2$ 每变化1个单位时， $Y$ 的均值  $E(Y)$  的变化。换句话说， $\beta_2$  给出 $X_2$ 的单位变化对 $Y$ 均值的“直接”或“净”影响（净在不染有 $X_3$ 的影响）。
  - $\beta_3$  则给出了 $X_3$ 的单位变化对 $Y$ 均值  $E(Y)$ 的“直接”或“净”影响，净在不沾有 $X_2$ 的影响。

➤ (一) 多元回归模型的理解



$$CM_i = 263.6416 - 0.0056PGNP_i - 2.231FLR_i$$

$$s.e. \quad (11.5932) \quad (0.0019) \quad (0.2099)$$

$$R^2 = 0.7077$$

$$\bar{R}^2 = 0.6981$$

# 理解偏回归系数——儿童死亡率案例

## ——如何分离出PNGP对CM的“真实”或净影响呢？

### ➤ (二) 一元回归模型的理解

#### ● (1) 死亡率对妇女识字率的回归

$$CM_i = 263.8635 - 2.3905FLR_i + e_{1i}$$

*s.e.*    (12.2249)    (0.2133)

$r^2 = 0.6695$

(式7.1.1)

$$e_{1i} = CM_i - 263.8635 + 2.3905FLR_i$$

(式7.2.1)

#### ● (2) 人均国民收入对妇女识字率的回归

$$PNGP_i = -39.3033 + 28.1427FLR_i + e_{2i}$$

*s.e.*    (734.9526)    (12.8211)

$r^2 = 0.0721$

$$e_{2i} = PNGP_i + 39.3033 - 28.1427FLR_i$$

- 如何分离出 $X_2$ 对 $Y$ 的“真实”或净影响呢？
- (3) 死亡率对人均国民收入的“净”回归
    - A. 剔除FLR影响后的“净”CM

(式7.1.1)

$$e_{1i} = CM_i - 263.8635 + 2.3905FLR_i$$

- B. 剔除FLR影响后的“净”PNGP

(式7.2.1)

$$e_{2i} = PNGP_i + 39.3033 - 28.1427FLR_i$$

- C. CM对PNGP的“净”回归——剔除了FLR影响

$$\hat{e}_{1i} = -0.0056e_{2i}$$

$$s.e. \quad (0.0019)$$

$$r^2 = 0.1152$$

➤ 样本回归函数 (SRF)

(式7.4.1)  
(SRF)

$$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i}$$

(式7.4.1)  
(SRF\_s)

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + e_i$$

$$\hat{y}_i = \hat{\beta}_2 x_{2i} + \hat{\beta}_3 x_{3i}$$

(式7.1.1)  
(PRF)

$$E(Y_i | (X_{2i}, X_{3i})) = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i}$$

(式7.1.1)  
(PRF\_s)

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i$$

(式7.4.2)

$$\min \sum e_i^2 = \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})^2$$

(式7.4.3)

$$\left\{ \begin{array}{l} \frac{\partial \sum e_i^2}{\partial \hat{\beta}_1} = 2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})(-1) = 0 \end{array} \right.$$

(式7.4.4)

$$\left\{ \begin{array}{l} \frac{\partial \sum e_i^2}{\partial \hat{\beta}_2} = 2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})(-X_{2i}) = 0 \end{array} \right.$$

(式7.4.5)

$$\left\{ \begin{array}{l} \frac{\partial \sum e_i^2}{\partial \hat{\beta}_3} = 2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})(-X_{3i}) = 0 \end{array} \right.$$

(式7.4.6)

$$\left\{ \begin{array}{l} \bar{Y} = \hat{\beta}_1 + \hat{\beta}_2 \bar{X}_2 + \hat{\beta}_3 \bar{X}_3 \end{array} \right.$$

(式7.4.7)

$$\left\{ \begin{array}{l} \sum Y_i X_{2i} = \hat{\beta}_1 \sum X_{2i} + \hat{\beta}_2 \sum X_{2i}^2 + \hat{\beta}_3 \sum X_{2i} X_{3i} \end{array} \right.$$

(式7.4.8)

$$\left\{ \begin{array}{l} \sum Y_i X_{3i} = \hat{\beta}_1 \sum X_{3i} + \hat{\beta}_2 \sum X_{2i} X_{3i} + \hat{\beta}_3 \sum X_{3i}^2 \end{array} \right.$$

正规方程组

(式7.4.9)

$$\hat{\beta}_1 = \bar{Y} - \hat{\beta}_2 \bar{X} - \hat{\beta}_3 \bar{X}_3$$

(式7.4.10)

$$\hat{\beta}_2 = \frac{(\sum y_i x_{2i})(\sum x_{3i}^2) - (\sum y_i x_{3i})(\sum x_{2i} x_{3i})}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i} x_{3i})^2}$$

(式7.4.11)

$$\hat{\beta}_3 = \frac{(\sum y_i x_{3i})(\sum x_{2i}^2) - (\sum y_i x_{2i})(\sum x_{2i} x_{3i})}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i} x_{3i})^2}$$

OLS估计量 $\hat{\beta}_i$ 的特点:

- ①可以从方程 (7.4.7) 和 (7.4.8) 中的一个通过 $x_2$ 和 $x_3$ 的对调而得到另一个, 所以, 它们本质上是对称的。
- ②两个方程的分母完全相同。
- ③三变量情形是双变量情形的自然而然的推广。

$(\hat{\beta}_1$  真实方差)

$$\sigma_{\hat{\beta}_1}^2 = \text{var}(\hat{\beta}_1) = \left[ \frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2\bar{X}_3 \sum x_{2i}x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - (\sum x_{2i}x_{3i})^2} \right] \cdot \sigma^2$$

 $(\hat{\beta}_1$  真实标准差)

$$\sigma_{\hat{\beta}_1} = \sqrt{\left[ \frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2\bar{X}_3 \sum x_{2i}x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - (\sum x_{2i}x_{3i})^2} \right] \cdot \sigma^2}$$

 $(\hat{\beta}_1$  样本方差)

$$S_{\hat{\beta}_1}^2 = \left[ \frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2\bar{X}_3 \sum x_{2i}x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - (\sum x_{2i}x_{3i})^2} \right] \cdot \hat{\sigma}^2$$

 $(\hat{\beta}_1$  样本标准差)

$$S_{\hat{\beta}_1} = \sqrt{\left[ \frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2\bar{X}_3 \sum x_{2i}x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - (\sum x_{2i}x_{3i})^2} \right] \cdot \hat{\sigma}^2}$$

### § 3.1.4

## 偏回归系数的 OLS估计

# 偏回归系数的OLS估计

——OLS估计量 $\hat{\beta}_2$ 的方差和标准误

( $\hat{\beta}_2$  真实方差)

$$\sigma_{\hat{\beta}_2}^2 = \text{var}(\hat{\beta}_2) = \frac{\sum x_{3i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \sigma^2 = \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)}$$

( $\hat{\beta}_2$  真实标准差)

$$\sigma_{\hat{\beta}_2} = \sqrt{\text{var}(\hat{\beta}_2)} = \sqrt{\frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)}}$$

$$r_{23}^2 = \frac{(\sum x_{2i}x_{3i})^2}{\sum x_{2i}^2 \sum x_{3i}^2}$$

( $\hat{\beta}_2$  样本方差)

$$S_{\hat{\beta}_2}^2 = \frac{\sum x_{3i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \hat{\sigma}^2 = \frac{\hat{\sigma}^2}{\sum x_{2i}^2 (1 - r_{23}^2)}$$

( $\hat{\beta}_2$  样本标准差)

$$S_{\hat{\beta}_2} = \sqrt{\frac{\hat{\sigma}^2}{\sum x_{2i}^2 (1 - r_{23}^2)}}$$

$(\hat{\beta}_3$  真实方差)

$$\sigma_{\hat{\beta}_2}^2 = \text{var}(\hat{\beta}_3) = \frac{\sum x_{2i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \sigma^2 = \frac{\sigma^2}{\sum x_{3i}^2 (1 - r_{23}^2)}$$

 $(\hat{\beta}_3$  真实标准差)

$$\sigma_{\hat{\beta}_3} = \sqrt{\text{var}(\hat{\beta}_2)} = \sqrt{\frac{\sigma^2}{\sum x_{3i}^2 (1 - r_{23}^2)}}$$

$$r_{23}^2 = \frac{(\sum x_{2i}x_{3i})^2}{\sum x_{2i}^2 \sum x_{3i}^2}$$

 $(\hat{\beta}_3$  样本方差)

$$S_{\hat{\beta}_3}^2 = \frac{\sum x_{2i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \hat{\sigma}^2 = \frac{\hat{\sigma}^2}{\sum x_{3i}^2 (1 - r_{23}^2)}$$

 $(\hat{\beta}_3$  样本标准差)

$$S_{\hat{\beta}_3} = \sqrt{\frac{\hat{\sigma}^2}{\sum x_{3i}^2 (1 - r_{23}^2)}}$$

- 可以证明 $\hat{\sigma}^2$ 是 $\sigma^2$ 的无偏估计量:

(式7.4.9)

$$(n-3) \frac{\hat{\sigma}^2}{\sigma^2} \sim \chi^2(n-3) \longrightarrow E(\hat{\sigma}^2) = E(\sigma^2)$$

(式7.4.10)

其中:  $\hat{\sigma}^2 = \frac{\sum e_i^2}{n-3}$

**残差方差:** 因为在估计 $\sum e_i^2$ 之前, 必须先估计 $\hat{\beta}_1, \hat{\beta}_2$ 和 $\hat{\beta}_3$ , 损失3个自由度(f.d.=n-3)。四变量中(f.d.=n-3)

(式7.4.19)

$$\begin{aligned} \sum e_i^2 &= \sum (e_i e_i) \\ &= \sum e_i (y_i - \hat{\beta}_2 x_{2i} - \hat{\beta}_3 x_{3i}) \\ &= \sum e_i y_i \\ &= \sum y_i (y_i - \hat{\beta}_2 x_{2i} - \hat{\beta}_3 x_{3i}) \\ &= \sum y_i^2 - \hat{\beta}_2 \sum y_i x_{2i} - \hat{\beta}_3 \sum y_i x_{3i} \end{aligned}$$

$$\sum e_i x_{2i} = \sum e_i x_{3i} = 0$$

## 偏回归系数的OLS估计

——*OLS*估计量的性质：偏回归系数 $\hat{\beta}_{ki}$ 是一个BLUE

- 偏回归系数的OLS估计量是**最佳线性无偏估计 (BLUE)**
  - 如同双变量模型，它们也满足高斯-马尔可夫定理()

偏回归系数的OLS估计  
——OLS估计量的性质

- 1. 三变量回归面通过均值点 $(\bar{Y}, \bar{X}_2, \bar{X}_3)$ ：

$$\bar{Y} = \hat{\beta}_1 + \hat{\beta}_2 \bar{X}_2 + \hat{\beta}_3 \bar{X}_3$$

三变量模型情况

$$\bar{Y} = \hat{\beta}_1 + \hat{\beta}_2 \bar{X}_2 + \hat{\beta}_3 \bar{X}_3 + \cdots + \hat{\beta}_K \bar{X}_K$$

k变量模型情况

- 2. 估计的 $\hat{Y}_i$ 的均值（即 $\bar{\hat{Y}}$ ）等于真实 $Y_i$ 的均值（即 $\bar{Y}$ ）：

$$\begin{aligned} \hat{Y}_i &= \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} \\ &= (\bar{Y} - \hat{\beta}_2 \bar{X}_2 - \hat{\beta}_3 \bar{X}_3) + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} \\ &= \bar{Y} + \hat{\beta}_2 (X_{2i} - \bar{X}_2) + \hat{\beta}_3 (X_{3i} - \bar{X}_3) \\ &= \bar{Y} + \hat{\beta}_2 x_{2i} + \hat{\beta}_3 x_{3i} \end{aligned}$$

$$\bar{Y} = \hat{\beta}_1 + \hat{\beta}_2 \bar{X}_2 + \hat{\beta}_3 \bar{X}_3$$

(式7.4.22)

$$1/n \sum \hat{Y}_i = 1/n \sum (\bar{Y} + \hat{\beta}_2 x_{2i} + \hat{\beta}_3 x_{3i})$$

$$\bar{\hat{Y}} = \bar{Y}$$

$$\sum x_{2i} = 0, \sum x_{3i} = 0$$

偏回归系数的OLS估计  
——OLS估计量的性质

- 3. 残差和等于0:  $\sum e_i = \bar{e}_i = 0$

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}_1} = 2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})(-1) = 0$$

正规方程之一

- 4. 残差 $e_i$ 与 $X_{2i}$ 和 $X_{3i}$ 都不相关:  $\sum e_i X_{2i} = \sum e_i X_{3i} = 0$

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}_2} = 2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})(-X_{2i}) = 0$$

正规方程之二

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}_3} = 2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \hat{\beta}_3 X_{3i})(-X_{3i}) = 0$$

正规方程之三

➤ 5. 残差 $e_i$ 与 $\hat{Y}_i$ 不相关:  $\sum e_i \hat{Y}_i = 0$

$$\sum e_i \hat{Y}_i = \sum e_i (\hat{y}_i + \bar{Y}) = \sum e_i \hat{y}_i + \bar{Y} \sum e_i = 0$$

$$\begin{aligned} \sum \hat{y}_i e_i &= \hat{\beta}_2 \sum x_{2i} e_i + \hat{\beta}_3 \sum x_{3i} e_i \\ &= \hat{\beta}_2 \sum (X_{2i} - \bar{X}_2) e_i + \hat{\beta}_3 \sum (X_{3i} - \bar{X}_3) e_i \\ &= \hat{\beta}_2 \sum X_{2i} e_i - \hat{\beta}_2 \bar{X}_2 \sum e_i + \hat{\beta}_3 \sum X_{3i} e_i - \hat{\beta}_3 \bar{X}_3 \sum e_i \\ &= 0 \end{aligned}$$

(式7.4.22)

$$\hat{y}_i = \hat{\beta}_2 x_{2i} + \hat{\beta}_3 x_{3i}$$

已证明

➤ 6.  $var(\hat{\beta}_2)$ 和 $var(\hat{\beta}_3)$  的关系:

$$var(\hat{\beta}_2) = \sigma_{\hat{\beta}_2}^2 = \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)}$$

$$var(\hat{\beta}_3) = \sigma_{\hat{\beta}_3}^2 = \frac{\sigma^2}{\sum x_{3i}^2 (1 - r_{23}^2)}$$

a. 给定 $\sum x_{ki}^2$ 和 $\sigma^2$ :

$r_{23} \rightarrow 1, var(\hat{\beta}_2) \rightarrow \infty; var(\hat{\beta}_3) \rightarrow \infty$

真值 $\beta_i$ 的估计将变得很困难!

b. 给定 $\sum x_{ki}^2$ 和 $r_{23}^2$ :

$var(\hat{\beta}_i)$ 与总体方差呈正比!

c. 给定 $\sigma^2$ 和 $r_{23}^2$ :

$var(\hat{\beta}_i)$ 与 $\sum x_{ki}^2$ 呈反比! 表明 $X_{ki}$ 样本值变化越大, 真值 $\beta_i$ 的估计精度越高!

# 多元判定系数 $R^2$ 与多元相关系数R

## ——平方和分解

- 多元判定系数：在三变量（或者更多变量）的模型中，衡量Y的变异由变量 $X_{1i}$ 、 $X_{2i}$ 等联合解释的比重，记作 $R^2$ ：

(式7.5.1)

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + e_i$$

$$Y_i = \hat{Y}_i + \hat{u}_i$$

$$\bar{Y} = \hat{\beta}_1 + \hat{\beta}_2 \bar{X}_2 + \hat{\beta}_3 \bar{X}_3$$

$$\begin{aligned} y_i &= \hat{\beta}_2 x_{2i} + \hat{\beta}_3 x_{3i} + e_i \\ &= \hat{y}_i + e_i \end{aligned}$$

(式7.5.3)

$$\sum y_i^2 = \sum \hat{y}_i^2 + \sum e_i^2 + 2 \sum \hat{y}_i e_i$$

$$= \sum \hat{y}_i^2 + \sum e_i^2$$

$$\sum e_i^2 = \sum y_i^2 - \hat{\beta}_2 \sum y_i x_{2i} - \hat{\beta}_3 \sum y_i x_{3i}$$

TSS

=

ESS

+

RSS

总离差平方和

=

回归平方和

+

残差平方和

# 多元判定系数 $R^2$ 与多元相关系数R

## —— $R^2$ 计算公式

- 容易得到 $R^2$ 计算公式如下：

$$\sum y_i^2 = \sum \hat{y}_i^2 + \left( \sum y_i^2 - \hat{\beta}_2 \sum y_i x_{2i} - \hat{\beta}_3 \sum y_i x_{3i} \right)$$

(式7.5.4)

$$ESS = \sum \hat{y}_i^2 = \hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i}$$

$$TSS = \sum y_i^2$$

(式7.5.5)

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} = 1 - \frac{\sum e_i^2}{\sum y_i^2} = \frac{\hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i}}{\sum y_i^2}$$

- $R^2$ 越接近于1，我们说模型“拟合”优度越高。

$$\left( \text{比较：一元回归：} r^2 = \frac{ESS}{TSS} = \frac{\hat{\beta}_2^2 \sum x_i^2}{\sum y_i^2} = \hat{\beta}_2^2 \left( \frac{\sum x_i^2}{\sum y_i^2} \right) \right)$$

(讨论)

讨论：在一元回归中， $r$ 可正可负；但是，在多元回归中， $R$ 永远取正值。实际上， $R$ 没有太大的意义，用途不大。？有意义的是 $R^2$

# 标准化变量回归的优势

## ——儿童死亡率与GNP和妇女识字率的关系

(式7.6.1)

$$\widehat{CM}_i = 263.6416 - 0.0056 PGNP_i - 2.231 FLR_i$$

$$se = (11.5932) (0.0019) \quad (0.2099) \quad R^2 = 0.7077$$

(式7.6.2)

$$R^2 = 0.6981 \text{ ①}$$

提问1: 怎么陈述结论? 大白话说出来!

提问2: 如果PGNP提高1美元, FLR同时也提高1%, CM怎么变化?

(式7.6.3)

$$\widehat{CM}^* = -0.2026 PGNP_i^* - 0.7639 FLR_i^*$$

$$se = (0.0713) \quad (0.0713) \quad r^2 = 0.7077$$

(讨论)

提问1: 怎么陈述结论? 大白话说出来!

提问2: 标准化变量后的回归结果与没有标准化的回归结果一致么?

## 设定偏误初探

——例说：儿童死亡率与GNP和妇女识字率的关系

➤ 错误拟合一个模型会导致严重后果：

$$Y_t = \beta_1 + \beta_2 X_{2t} + \beta_3 X_{3t} + u_t$$

$$Y_t = b_1 + b_{12} X_{2t} + u_{1t}$$

(式7.7.1)

$$\widehat{CM}_i = 263.6416 - 0.0056 PGNP_i - 2.231 FLR_i$$

$$se = (11.5932) (0.0019) \quad (0.2099)$$

“真实”多元回归

$$R^2 = 0.7077$$

$$\bar{R}^2 = 0.6981 \textcircled{1}$$

(式7.7.2)

$$\widehat{CM}_i = 157.4244 - 0.0114 PGNP_i$$

$$se = (9.8455) (0.0032) \quad r^2 = 0.1662$$

“误设”一元回归1

(式7.7.3)

$$\widehat{CM}_i = 263.8635 - 2.3905 FLP_i$$

$$se = (21.2249) (0.2133) \quad r^2 = 0.6696$$

“误设”一元回归2

(讨论)

如果你认定某个特殊的回归模型是“正确”模型，就不要从中略去一个或多个变量，而把它加以修改。

如果你忽视这条原则，你就会得到有偏误的参数估计。不仅如此，你还可能低估了真实的方差 $\sigma^2$ 并因而低估了回归系数的估计标准误。

§ 3.1.8  
R<sup>2</sup>与调整R<sup>2</sup>

R<sup>2</sup>与调整R<sup>2</sup> ( $\bar{R}^2$ )

——更高的R<sup>2</sup>：请谨慎看待！

➤ R<sup>2</sup>与变量X<sub>ki</sub>的数量(k-1)有关：

(式7.8.1)

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} = 1 - \frac{\sum e_i^2}{\sum y_i^2} = \frac{\hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i}}{\sum y_i^2}$$

(分母部分)

$$X_{ki} \xrightarrow{\text{变量数无关}} \sum y_i^2 = \sum (Y_i - \bar{Y})^2$$

(分子部分)

$$X_{ki} \xrightarrow{\text{变量数有关}} \sum e_i^2 = \sum y_i^2 - \hat{\beta}_2 \sum y_i x_{2i} - \hat{\beta}_3 \sum y_i x_{3i}$$

(R<sup>2</sup>变化)

$$X_{ki} \uparrow \xrightarrow{\text{变量数有关}} \sum e_i^2 \downarrow; \sum y_i^2 \text{不变} \xrightarrow{\text{使得}} R^2 \uparrow$$

启示：模型选择时，较高的R<sup>2</sup>可能来自解释变量个数的增加，并不能说明模型就一定更好。

➤ 调整R<sup>2</sup>为校正 (adjusted R<sup>2</sup>) : 利用相应的自由度对平方和进行校正。

(式7.8.2)

$$\bar{R}^2 = 1 - \frac{\sum e_i^2 / (n - k)}{\sum y_i^2 / (n - 1)}$$

• k: 三变量回归 (二元回归) 为3;

(式7.8.3)

$$\bar{R}^2 = 1 - \frac{\hat{\sigma}^2}{S_Y^2}$$

$$\hat{\sigma}^2 = \frac{\sum e_i^2}{n - k}$$

残差方差

$$S_Y^2 = \frac{\sum (Y - \bar{Y})^2}{n - 1}$$

Y样本方差

(式7.8.4)

$$\bar{R}^2 = 1 - (1 - R^2) \frac{n - 1}{n - k}$$

(讨论)

(1)如果k=1,则R<sup>2</sup>= $\bar{R}^2$ ; (2)如果k>1,则R<sup>2</sup>> $\bar{R}^2$ 。表明随着变量数的增多, $\bar{R}^2$ 相对要增大慢一些; (3)R<sup>2</sup> ≥ 0, 但 $\bar{R}^2$ 可以小于0, 此时可以处理为 $\bar{R}^2 = 0$ ; (4)不能单凭最高的 $\bar{R}^2$ 之值来选择模型, 可参考的标准还可以有AIC、APC等。

§ 3.1.8  
R<sup>2</sup>与调整R<sup>2</sup>

R<sup>2</sup>与调整R<sup>2</sup> ( $\bar{R}^2$ )

——模型选择标准的比较案例1：美国咖啡消费量与价格

表 7—1 1970—1980 年美国咖啡消费 (Y) 与平均真实零售价格 (X)\* 的关系

年份	Y (人均日消费杯数)	X (美元/磅)
1970	2.57	0.77
1971	2.50	0.74
1972	2.35	0.72
1973	2.30	0.73
1974	2.25	0.76
1975	2.20	0.75
1976	2.11	1.08
1977	1.94	1.81
1978	1.97	1.39
1979	2.06	1.20
1980	2.02	1.17

(式7.8.8)

$$\hat{Y}_i = 2.6911 - 0.4795X_i$$

线性模型：

$$se = (0.1216) (0.1140) \quad RSS = 0.1491 \quad r^2 = 0.6628$$

(式7.8.9)

$$\widehat{\ln Y}_i = 0.7774 - 0.2530 \ln X_i$$

$$se = (0.0152) (0.0494) \quad RSS = 0.0226 \quad r^2 = 0.7448$$

(讨论)

讨论1：两个模型可以进行拟合优度比较的基础或前提是什么？

Y和n必须一样

(二元回归)

$$\widehat{CM}_i = 263.6416 - 0.0056 PGNP_i - 2.231 FLR_i$$

$$se = (11.5932) (0.0019) \quad (0.2099) \quad R^2 = 0.7077$$

$$R^2 = 0.6981 \text{ ①}$$

(一元回归)

$$\widehat{CM}_i = 263.8635 - 2.3905 FLR_i$$

$$se = (12.2249) (0.2133) \quad r^2 = 0.6695$$

(讨论)

讨论2:  $R^2$ 可以在不同回归元之间进行分配吗?

不可以。

# 函数形式再议

## ——柯布-道格拉斯生产函数

(式7.9.1)

$$Y_i = \beta_1 X_{2i}^{\beta_2} X_{3i}^{\beta_3} e^{u_i}$$

其中Y=产出；

$X_2$  = 劳动投入；

$X_3$  = 资本投入；

$u$  = 随机干扰项；

$e$  = 自然对数的底。

(式7.9.2)

$$\begin{aligned} \ln Y_i &= \ln \beta_1 + \beta_2 \ln X_{2i} + \beta_3 \ln X_{3i} + u_i \\ &= \beta_0 + \beta_2 \ln X_{2i} + \beta_3 \ln X_{3i} + u_i \quad \beta_0 = \ln \beta_1 \end{aligned}$$

$$\widehat{\ln Y_i} = 3.8876 + 0.4683 \ln X_{2i} + 0.5213 \ln X_{3i}$$

$$(0.3962) \quad (0.0989) \quad (0.0969)$$

$$t = (9.8115) \quad (4.7342) \quad (5.3803)$$

展示数据表7-3

(讨论)

$$R^2 = 0.9642 \quad df = 48$$

$$\bar{R}^2 = 0.9627$$

- 多项式回归模型 (polynomial regression models)

(式7.10.1)

$$Y = \beta_1 + \beta_2 X + \beta_3 X^2$$

(式7.10.2)

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 X_i^2 + u_i$$

(式7.10.3)

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 X_i^2 + \dots + \beta_k X_i^k + u_i$$

$$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i}$$

(讨论)

思考1：上述模型是线性回归模型吗？

思考2：X与X的诸多幂函数之间是高度相关的吗？有没有违背自变量无多重共线性的CLRM假设？

思考1：是线性回归

思考2：不相关；

没有违背无多重共线性的假设

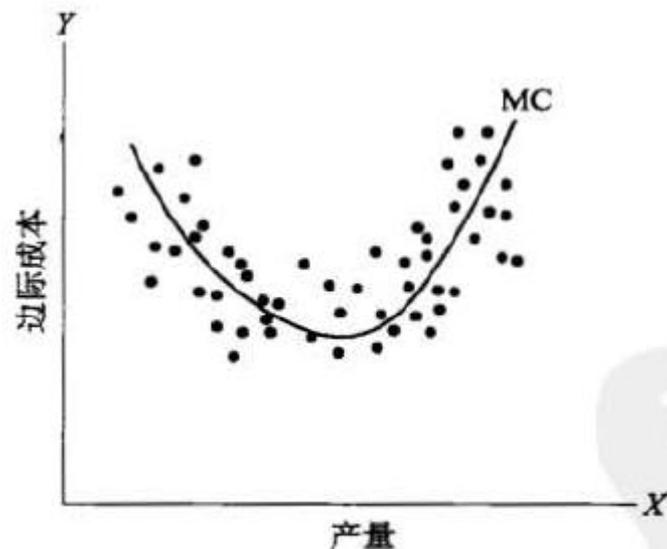


图 7—1 U型边际成本曲线

§ 3.1.10  
多项式回归  
模型

# 多项式回归模型

——一个说明案例：估计总成本函数

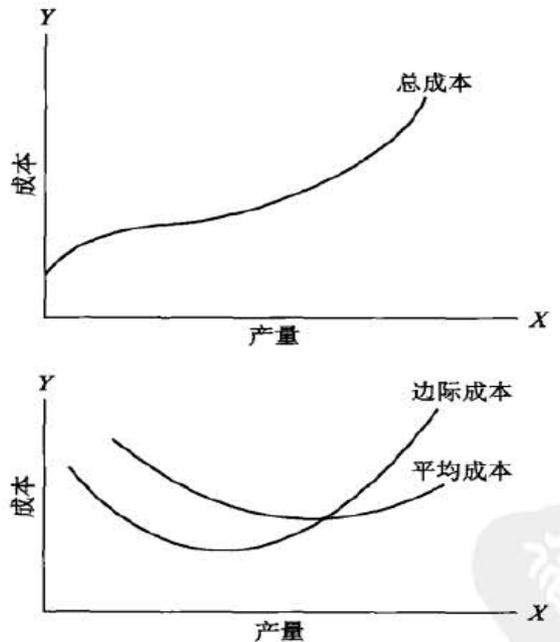


图 7—3 短期成本函数

表 7—4 总成本 (Y) 与产出 (X)

产出	总成本 (美元)
1	193
2	226
3	240
4	244
5	257
6	260
7	274
8	297
9	350
10	420

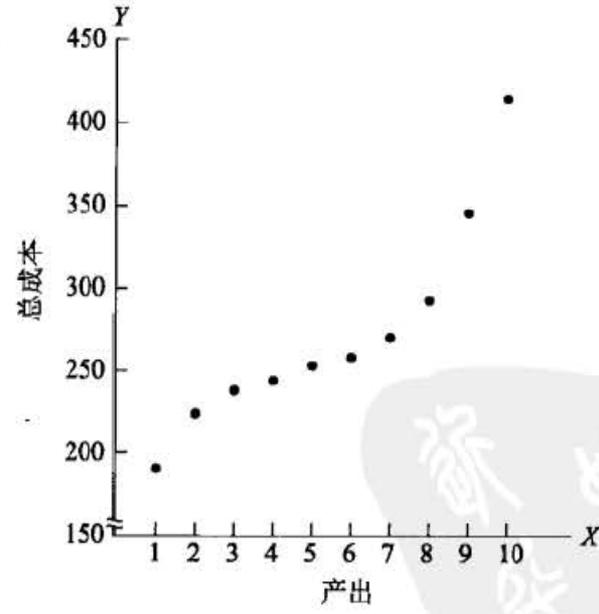


图 7—2 总成本曲线

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 X_i^2 + \beta_4 X_i^3 + u_i$$

$$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + \hat{\beta}_4 X_{4i}$$

$$Y_i = 141.7667 + 63.4776 X_i - 12.9615 X_i^2 + 0.9396 X_i^3$$

(6.3753) (4.7786) (0.9857) (0.0591)  $R^2 = 0.9983$

(SRF)

$$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i}$$

➤ 偏相关系数 (partial correlation coefficient) :

若变量1为Y, 变量2为 $X_{2i}$ , 变量3为 $X_{3i}$ , 则偏相关系数的含义如下:

- 保持 $X_{3i}$  不变, Y与 $X_{2i}$  之间的相关系数:

$$r_{12.3} = \frac{r_{12} - r_{13}r_{23}}{\sqrt{(1 - r_{13}^2)(1 - r_{23}^2)}}$$

- 保持 $X_{2i}$  不变, Y与 $X_{3i}$  之间的相关系数:

$$r_{13.2} = \frac{r_{13} - r_{12}r_{23}}{\sqrt{(1 - r_{12}^2)(1 - r_{23}^2)}}$$

- 保持Y不变,  $X_{2i}$ 与 $X_{3i}$  之间的相关系数:

$$r_{23.1} = \frac{r_{23} - r_{12}r_{13}}{\sqrt{(1 - r_{12}^2)(1 - r_{13}^2)}}$$

(式7.11.1)

(式7.11.2)

(式7.11.3)

(SRF)

$$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i}$$

➤ 简单相关系数(simple correlation coefficients)

● Y与 $X_{2i}$ 之间的相关系数:

$$r_{12} = \frac{\sum y_i x_{2i}}{\sqrt{\sum y_i^2} \sqrt{\sum x_{2i}^2}}$$

● Y与 $X_{3i}$ 之间的相关系数:

$$r_{13} = \frac{\sum y_i x_{3i}}{\sqrt{\sum y_i^2} \sqrt{\sum x_{3i}^2}}$$

●  $X_{2i}$ 与 $X_{3i}$ 之间的相关系数:

$$r_{23} = \frac{\sum x_{2i} x_{3i}}{\sqrt{\sum x_{2i}^2} \sqrt{\sum x_{3i}^2}}$$

1.  $r_{12} = 0$ ,  $r_{12.3}$ 不一定为零。
2.  $r_{12} = 0$ , 如果 $r_{13}$ 和 $r_{23}$ 均不为零且符号相同, 则 $r_{12.3}$ 为负; 如果 $r_{13}$ 和 $r_{23}$ 异号, 则 $r_{12.3}$ 为正。
3.  $r_{12.3}$ 和 $r_{12}$ 不一定同号。
4. 在双变情形中,  $r^2$ 落在0和1之间。偏相关系数的平方也有同样的性质。
5.  $r_{13} = r_{23} = 0$ 并不意味着 $r_{12} = 0$ 。也就是说,  $Y$ 与 $X_3$ 不相关, 同时 $X_2$ 与 $X_3$ 不相关, 但并不意味着 $Y$ 与 $X_2$ 不相关。

## § 3.2 多元回归分析: 推断问题

- 3.2.1 再议正态性假定
- 3.2.2 多元回归中的假设检验: 总评
- 3.2.3 检验关于个别偏回归系数的假设
- 3.2.4 检验样本回归的总显著性
- 3.2.5 检验两个回归系数是否相等\*
- 3.2.6 受约束的最小二乘法: 检验线性等式约束条件
- 3.2.7 检验回归模型的结构或参数稳定性\*
- 3.2.8 用多元回归做预测\*

(SRF)

$$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i}$$

- 如果回归分析的目的仅在于对回归模型的参数作点估计，则OLS法就足够了，并不需要对干扰项  $\mu_i$  的概率分布作任何假定。(OLS估计量是BLUE)
- 如果我们的目的还在于区间估计和统计推断，那么，我们还需要假定  $\mu_i$  遵循某个概率分布。

- 假设：

$$u_i \sim N(0, \sigma^2)$$

$$\hat{\beta}_1 \sim N(\beta_1, \sigma_{\hat{\beta}_1}^2)$$

- 那么：

$$\hat{\beta}_2 \sim N(\beta_2, \sigma_{\hat{\beta}_2}^2)$$

$$\hat{\beta}_3 \sim N(\beta_3, \sigma_{\hat{\beta}_3}^2)$$

——回顾：方差、样本方差、样本标准误

(式7.4.9)

$$\sigma_{\hat{\beta}_1}^2 = \text{var}(\hat{\beta}_1) = \left[ \frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2\bar{X}_3 \sum x_{2i}x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - (\sum x_{2i}x_{3i})^2} \right] \cdot \sigma^2$$

$$se(\hat{\beta}_1) = +\sqrt{\widetilde{\text{var}}(\hat{\beta}_1)} = \sqrt{\hat{\sigma}_{\hat{\beta}_1}^2(\hat{\beta}_1)}$$

(式7.4.10)

$$\sigma_{\hat{\beta}_2}^2 = \text{var}(\hat{\beta}_2) = \frac{\sum x_{3i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \sigma^2 = \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)}$$

$$se(\hat{\beta}_2) = +\sqrt{\widetilde{\text{var}}(\hat{\beta}_2)} = \sqrt{\hat{\sigma}_{\hat{\beta}_2}^2(\hat{\beta}_2)}$$

简单相关系数:  $r_{23}^2 = \frac{(\sum x_{2i}x_{3i})^2}{\sum x_{2i}^2 \sum x_{3i}^2}$

(式7.4.11)

$$\sigma_{\hat{\beta}_3}^2 = \text{var}(\hat{\beta}_3) = \frac{\sum x_{2i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \sigma^2 = \frac{\sigma^2}{\sum x_{3i}^2 (1 - r_{23}^2)}$$

$$se(\hat{\beta}_3) = +\sqrt{\widetilde{\text{var}}(\hat{\beta}_3)} = \sqrt{\hat{\sigma}_{\hat{\beta}_3}^2(\hat{\beta}_3)}$$

——回顾： $\hat{\beta}_1$ 的方差、样本方差、样本标准差 $(\hat{\beta}_1$  真实方差)

$$\sigma_{\hat{\beta}_1}^2 = \text{var}(\hat{\beta}_1) = \left[ \frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2\bar{X}_3 \sum x_{2i}x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - (\sum x_{2i}x_{3i})^2} \right] \cdot \sigma^2$$

 $(\hat{\beta}_1$  真实标准差)

$$\sigma_{\hat{\beta}_1} = \sqrt{\left[ \frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2\bar{X}_3 \sum x_{2i}x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - (\sum x_{2i}x_{3i})^2} \right] \cdot \sigma^2}$$

 $(\hat{\beta}_1$  样本方差)

$$S_{\hat{\beta}_1}^2 = \left[ \frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2\bar{X}_3 \sum x_{2i}x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - (\sum x_{2i}x_{3i})^2} \right] \cdot \hat{\sigma}^2$$

 $(\hat{\beta}_1$  样本标准差)

$$S_{\hat{\beta}_1} = \sqrt{\left[ \frac{1}{n} + \frac{\bar{X}_2^2 \sum x_{3i}^2 + \bar{X}_3^2 \sum x_{2i}^2 - 2\bar{X}_2\bar{X}_3 \sum x_{2i}x_{3i}}{\sum x_{2i}^2 \sum x_{3i}^2 - (\sum x_{2i}x_{3i})^2} \right] \cdot \hat{\sigma}^2}$$

——回顾： $\hat{\beta}_2$ 的方差、样本方差、样本标准差 $(\hat{\beta}_2$  真实方差)

$$\sigma_{\hat{\beta}_2}^2 = \text{var}(\hat{\beta}_2) = \frac{\sum x_{3i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \sigma^2 = \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)}$$

 $(\hat{\beta}_2$  真实标准差)

$$\sigma_{\hat{\beta}_2} = \sqrt{\text{var}(\hat{\beta}_2)} = \sqrt{\frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)}}$$

$$r_{23}^2 = \frac{(\sum x_{2i}x_{3i})^2}{\sum x_{2i}^2 \sum x_{3i}^2}$$

 $(\hat{\beta}_2$  样本方差)

$$S_{\hat{\beta}_2}^2 = \frac{\sum x_{3i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \hat{\sigma}^2 = \frac{\hat{\sigma}^2}{\sum x_{2i}^2 (1 - r_{23}^2)}$$

 $(\hat{\beta}_2$  样本标准差)

$$S_{\hat{\beta}_2} = \sqrt{\frac{\hat{\sigma}^2}{\sum x_{2i}^2 (1 - r_{23}^2)}}$$

——回顾： $\hat{\beta}_3$ 的方差、样本方差、样本标准差 $(\hat{\beta}_3$  真实方差)

$$\sigma_{\hat{\beta}_3}^2 = \text{var}(\hat{\beta}_3) = \frac{\sum x_{2i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \sigma^2 = \frac{\sigma^2}{\sum x_{3i}^2 (1 - r_{23}^2)}$$

 $(\hat{\beta}_3$  真实标准差)

$$\sigma_{\hat{\beta}_3} = \sqrt{\text{var}(\hat{\beta}_3)} = \sqrt{\frac{\sigma^2}{\sum x_{3i}^2 (1 - r_{23}^2)}}$$

$$r_{23}^2 = \frac{(\sum x_{2i}x_{3i})^2}{\sum x_{2i}^2 \sum x_{3i}^2}$$

 $(\hat{\beta}_3$  样本方差)

$$S_{\hat{\beta}_3}^2 = \frac{\sum x_{2i}^2}{(\sum x_{2i}^2)(\sum x_{3i}^2) - (\sum x_{2i}x_{3i})^2} \hat{\sigma}^2 = \frac{\hat{\sigma}^2}{\sum x_{3i}^2 (1 - r_{23}^2)}$$

 $(\hat{\beta}_3$  样本标准差)

$$S_{\hat{\beta}_3} = \sqrt{\frac{\hat{\sigma}^2}{\sum x_{3i}^2 (1 - r_{23}^2)}}$$

- $\hat{\sigma}^2$  是  $\sigma^2$  的无偏估计量：

$$(n-3) \frac{\hat{\sigma}^2}{\sigma^2} \sim \chi^2(n-3) \longrightarrow E(\hat{\sigma}^2) = E(\sigma^2)$$

$$\hat{\sigma}^2 = \frac{\sum e_i^2}{n-3} = \frac{1}{n-3} \left( \sum y_i^2 - \hat{\beta}_2 \sum y_i x_{2i} - \hat{\beta}_3 \sum y_i x_{3i} \right)$$

- 那么，我们可以根据如下t分布，进行区间估计和假设检验：

$$t_1 = \frac{\hat{\beta}_1 - \beta_1}{se(\hat{\beta}_1)} \sim t(n-3)$$

$$t_2 = \frac{\hat{\beta}_2 - \beta_2}{se(\hat{\beta}_2)} \sim t(n-3)$$

$$t_3 = \frac{\hat{\beta}_3 - \beta_3}{se(\hat{\beta}_3)} \sim t(n-3)$$

# 正态性假设目的

——示例：儿童死亡率与GNP和妇女识字率

(式8.1.4)

$$\widehat{CM}_i = 263.6416 - 0.0056 \text{PGNP}_i - 2.2316 \text{FLR}_i$$

se =	(11.5932)	(0.0019)	(0.2099)
t =	(22.7411)	(-2.8187)	(-10.6293)
p 值 =	(0.0000)*	(0.0065)	(0.0000)*

$R^2 = 0.7077$        $\bar{R}^2 = 0.6981$

(思考)

- 所观察到这些结论的统计显著性如何？
  - 比如：考虑PGNP 的系数- 0.0056。这个系数是统计显著的么？即它统计显著地异于零么？
  - 类似地，FLR 的系数-2.2316 是统计显著的么？这个系数都是统计显著的么？

$$E(Y | X_2, X_3) = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i}$$

- 检验关于个别偏回归系数的假设( § 3.2.3 )
- 检验所估计的多元回归模型的总体显著性, 也就是要判别是否全部偏斜率系数同时为零( § 3.2.4 )
- ~~● 检验两个或多个系数是否相等( § 3.2.5 )~~
- 检验偏回归系数是否满足某种约束条件( § 3.2.6 )
- ~~● 检验所估计的回归模型在时间上或在不同横截面单元上的稳定性( § 3.2.7 )。~~
- 检验回归模型的函数形式( § 3.2.8 )

## 检验关于个别偏回归系数的假设

——单个 $\beta_i$ 的t假设检验

➤ 以 $\beta_2$ 的t假设检验为例：

- 构造原假设和备择假设： $H_0 : \beta_2 = 0$ ;  $H_1 : \beta_2 \neq 0$

- 计算 $(1 - \alpha)100\%$ ：

$$\hat{\beta}_2 - t_{\alpha/2} se(\hat{\beta}_2) \leq \beta_2 \leq \hat{\beta}_2 + t_{\alpha/2} se(\hat{\beta}_2)$$

- 进行显著性检验：

- 如果计算的 $t_2$ 值超过选定显著性水平的临界t值就可以拒绝 $H_0$ ；否则就不拒绝它。

➤ 示例说明：儿童死亡率与GNP和妇女识字率 $\beta_2$ 的t假设检验

$$\widehat{CM}_i = 263.6416 - 0.0056 PGNP_i - 2.2316 FLR_i$$

$$se = (11.5932) \quad (0.0019) \quad (0.2099)$$

$$t = (22.7411) \quad (-2.8187) \quad (-10.6293)$$

- 双尾： $|t_{\alpha/2}^{(n-k)}| = |t_{0.05/2}^{(61)}| = 2.0$

- 单尾： $|t_{1-\alpha}^{(n-k)}| = |t_{0.95}^{(61)}| = 1.671$

$$t_2^* = \frac{\hat{\beta}_2 - \beta_2}{se(\hat{\beta}_2)} = \frac{-0.0056}{0.002} = -2.8187$$

## 检验样本回归的总体显著性 ——假设的提出（联合假设）

### ➤ 估计回归线的总显著性(overall significance)检验：

- 含义：检验Y是否与  $X_{1i}$  和  $X_{2i}$  两者有线性关系。
- 假设的提出：

$$H_0 : \beta_2 = \beta_3 = 0; \quad H_1 : \beta_2, \beta_3 \text{不全为零}$$

- 虚拟假设是关于  $\beta_1$  和  $\beta_2$  联合地或同时地等于零的一个 **联合假设 (joint hypothesis)**
- 注意区别于单个偏相关系数的t检验：
  - 单个偏回归系数t检验时，我们暗含地假定，每一个显著性检验都是根据一个不同的（独立的）样本进行的。
  - 也就是说，我们暗含地假定，在假设  $H_0: \beta_2 = 0$  下检验显著性的样本，不同于在假设  $H_0: \beta_3 = 0$  下检验显著性的样本。

# 检验样本回归的总体显著性

——理论根源：方差分析(ANOVA)

(式7.5.3)

$$\begin{aligned} \sum y_i^2 &= \sum \hat{y}_i^2 + \sum e_i^2 + 2\sum \hat{y}_i e_i \\ &= \sum \hat{y}_i^2 + \sum e_i^2 \end{aligned}$$

$$\sum e_i^2 = \sum y_i^2 - \hat{\beta}_2 \sum y_i x_{2i} - \hat{\beta}_3 \sum y_i x_{3i}$$

**TSS** = **ESS** + **RSS**

总离差平方和 = 总离差平方和 + 总离差平方和

(Table 8-2)  
(ANOVA)

变异来源	SS	df	MSS
来自回归 (ESS)	$\hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i}$	2	$\frac{\hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i}}{2}$
来自残差 (RSS)	$\sum e_i^2$	n-3	$\hat{\sigma}^2 = \frac{\sum e_i^2}{n-3}$
总计 (TSS)	$\sum y_i^2$	n-1	

# 检验样本回归的总体显著性

——原理：构建适合检验的F统计量

- 可以证明，在原假设 $H_0$ 下，可得如下F统计量：

(式8.4.3)

$$F^* = \frac{MSS_{ESS}}{MSS_{RSS}} = \frac{ESS/df_{ESS}}{RSS/df_{RSS}} = \frac{(\hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i})/2}{\sum e_i^2 / (n-3)} \sim F(2, n-3)$$

- 又因为：

(式8.4.4)

$$E \frac{\sum e_i^2}{n-3} = E(\hat{\sigma}^2) = \sigma^2$$

$$\leftarrow u_i \sim N(0, \sigma^2)$$

(式8.4.5)

$$\frac{E(\hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i})}{2} = \sigma^2$$

$$\leftarrow \begin{matrix} u_i \sim N(0, \sigma^2) \\ H_0: \beta_2 = \beta_3 = 0 \end{matrix}$$

**原理：**如果原假设 $H_0$ 是真实的，(8.4.4)和(8.4.5)都将对真实 $\sigma^2$ 给出同样的估计。即， $X_{1i}$ 和 $X_{2i}$ 对Y的联合影响和随机影响毫无区别。如果虚拟假设谬误，即 $X_{1i}$ 和 $X_{2i}$ 确实影响Y，则不能在(8.4.4)和(8.4.5)之间划等号。这时，在适当考虑自由度之后，**ESS要相对大于RSS。**

(式8.4.3)

$$F^* = \frac{MSS_{ESS}}{MSS_{RSS}} = \frac{ESS/df_{ESS}}{RSS/df_{RSS}} = \frac{(\hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i})/2}{\sum e_i^2 / (n-3)} \sim F(2, n-3)$$

- (8.4.3) 的 $F^*$ 值对真实斜率系数同时为零的这一虚拟假设，提供了一种检验。
- 在显著水平 $\alpha$ 下，如果 $F^* > F_\alpha$ ，则拒绝 $H_0$ ；否则就不能拒绝 $H_0$ 。

➤ 示例：

表 8—3 儿童死亡率一例的 ANOVA 表

变异来源	SS	df	MSS
来自回归	257 362.4	2	128 681.2
来自残差	106 315.6	61	1 742.88
总计	363 678	63	

$$F_\alpha(k-1, n-k) = F_{0.95}(2, 60) = 3.15$$

$$F_2^*(2, 60) = \frac{MSS_{ESS}}{MSS_{RSS}} = \frac{128681.2}{1742.88} = 73.8325$$

(Table 8-3)

# 检验样本回归的总体显著性

——多元扩展：k变量回归模型的F检验

- 给定k变量回归模型：

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + \cdots + \beta_k X_{ki} + u_i$$

- 设计研究假设为：

(式8.4.9)

$$H_0 : \beta_2 = \beta_3 = \cdots = \beta_k = 0; \quad H_1 : \beta_2, \beta_3, \dots, \beta_k \text{不全为零}$$

- 样本数据的F统计量为：

(式8.4.7)

$$F = \frac{ESS/df}{RSS/df} = \frac{ESS/(k-1)}{RSS/(n-k)} = \frac{MSS_{ESS}}{MSS_{RSS}} \sim F(k-1, n-k)$$

- 假设检验的判断：

如果， $F > F_\alpha(k-1, n-k)$ ，则拒绝 $H_0$

(式8.4.3)

$$\begin{aligned} F &= \frac{(n-k)ESS}{(k-1)RSS} \\ &= \frac{n-k}{k-1} \cdot \frac{ESS}{TSS-ESS} = \frac{n-k}{k-1} \cdot \frac{ESS/TSS}{1-(ESS/TSS)} \\ &= \frac{n-k}{k-1} \cdot \frac{R^2}{1-R^2} \\ &= \frac{R^2/(k-1)}{(1-R^2)/(n-k)} \end{aligned}$$

$R^2 = 0, F = 0$  ;  $R^2 \uparrow$  则  $F \uparrow$ ;  $R^2 = 1, F = \infty$

- 由此可见，F检验既是所估计回归的总显著性的一个度量，也是R<sup>2</sup>的一个显著性检验。换句话说，检验虚拟假设（式8.4.9）等价于检验总体R<sup>2</sup> = 0 的虚拟假设。

# 检验样本回归的总体显著性

——多元扩展：F与R<sup>2</sup>的联系 (R<sup>2</sup>表示的ANOVA)

表8.4 由R<sup>2</sup>表示的ANOVA表

变异来源	SS	df	MSS
来自回归 (ESS)	$R^2 (\sum y_i^2)$	k-1	$R^2 (\sum y_i^2) / (k-1)$
来自残差 (RSS)	$(1-R^2) (\sum y_i^2)$	n-k	$(1-R^2) (\sum y_i^2) / (n-k)$
总计 (TSS)	$\sum y_i^2$	n-1	

(Table 8-4)

- F的计算将只需要R<sup>2</sup>和自由度！

(讨论F检验)

案例：儿童死亡率

$$\widehat{CM}_i = 263.6416 - 0.0056 PGNP_i - 2.2316 FLR_i$$

$$R^2 = 0.7077$$

$$\bar{R}^2 = 0.6981$$

# 检验样本回归的总体显著性

——多元扩展：何时增加或减少一个解释变量？理论

(知识回顾)

讨论2:  $R^2$ 可以在不同回归元之间进行分配吗?

案例2: 儿童死亡率案例

$$\widehat{CM}_i = 157.4244 - 0.0114 PGNP_i$$

se = (9.8455) (0.0032)       $r^2 = 0.1662$       调整 $r^2 = 0.1528$

$$\widehat{CM}_i = 263.6416 - 0.0056 PGNP_i - 2.231 FLR_i$$

se = (11.5932) (0.0019)      (0.2099)       $R^2 = 0.7077$   
 $R^2 = 0.6981$  ①

思考:  
那么我们能不能知道引入一个新变量对于模型的“边际贡献”呢?

一个思路:

- ①先单独分析PGNP(X2)对CM的影响。
- ②再进一步引入新的解释变量FLR(X3)。
- ③观察ANOVA, 进行增量贡献分析。

# 检验样本回归的总体显著性

——多元扩展：何时增加或减少一个解释变量？理论

表 8—6 用于评价变量增量贡献的 ANOVA 表

变异来源	SS	df	MSS
仅由于 $X_2$ 的 ESS	$Q_1 = \hat{\beta}_{12}^2 \sum x_{2i}^2$	1	$\frac{Q_1}{1}$
仅由于增加的 $X_3$ 的 ESS	$Q_2 = Q_3 - Q_1$	1	$\frac{Q_2}{1}$
$X_2$ 和 $X_3$ 共同的 ESS	$Q_3 = \hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i}$	2	$\frac{Q_3}{2}$
RSS	$Q_4 = Q_5 - Q_3$	$n - 3$	$\frac{Q_4}{n - 3}$
总计	$Q_5 = \sum y_i^2$	$n - 1$	

$$F = \frac{Q_2 / df}{Q_4 / df} = \frac{(\text{ESS}_{\text{new}} - \text{ESS}_{\text{old}}) / \text{新增回归元个数}}{\text{RSS}_{\text{new}} / (n - \text{新模型中的参数个数})}$$

$$F = \frac{(R_{\text{new}}^2 - R_{\text{old}}^2) / \text{新增回归元个数}}{(1 - R_{\text{new}}^2) / (n - \text{新模型中的参数个数})}$$

§ 3.2.4  
检验样本回归  
的总显著性

# 检验样本回归的总体显著性

——多元扩展：何时增加或减少一个解释变量？案例

old模型

$$\widehat{CM}_i = 157.4244 - 0.0114 PGNP_i$$

$$se = (9.8455) \quad (0.0032) \quad r^2 = 0.1662$$

$$F_{old}^* = \frac{60449.5}{4890.78} = 12.3598$$

表 8—5 回归方程 (8.4.14) 的 ANOVA 表

变异来源	SS	df	MSS
ESS (来自 PGNP)	60 449.5	1	60 449.5
RSS	303 228.5	62	4 890.782 2
总计	363 678	63	

new模型

$$\widehat{CM}_i = 263.6416 - 0.0056 PGNP_i - 2.231 FLR_i$$

$$se = (11.5932) \quad (0.0019) \quad (0.2099) \quad R^2 = 0.7077$$

$$F_{new}^* = \frac{128681.2}{1742.88} = 73.8325$$

表 8—3 儿童死亡率一例的 ANOVA 表

变异来源	SS	df	MSS
来自回归	257 362.4	2	128 681.2
来自残差	106 315.6	61	1 742.88
总计	363 678	63	

# 检验样本回归的总体显著性

——多元扩展：何时增加或减少一个解释变量？案例

表 8—7 说明性例子的 ANOVA 表：增量分析

变异来源	SS	df	MSS
old模型 仅由于 PGNP 的 ESS	60 449.5	1	60 449.5
仅由于增加的 FLR 的 ESS	196 912.9	1	196 912.9
new模型 PGNP 和 FLR 共同的 ESS	257 362.4	2	128 681.2
new模型 RSS	106 315.6	61	1 742.878 6
总计	363 678	63	

$$F = \frac{196\,912.9}{1\,742.878\,6} = 112.981\,4$$

启示——引入新变量的指导准则：  
 1.模型的比较与选择应该是基于“因变量相同，而解释变量不同”。  
 2.如果新增变量的系数的t值的绝对值大于1，则调整R<sup>2</sup>会增大。

自学：本课程不要求掌握！

# 受约束的最小二乘法: 检验线性等式约束条件 ——什么是线性等式约束条件?

## ➤ 线性等式约束条件:

- 根据已有的经济理论, 某一回归模型中的系数需满足一些线性等式约束条件。
- 柯布道格拉斯生产函数 (the Cobb-Douglas production function):

(式8.6.1)

$$Y_i = \beta_1 X_{2i}^{\beta_2} X_{3i}^{\beta_3} e^{u_i}$$

— 其中:  $Y$ —产出,  $X_{2i}$ —劳动投入,  $X_{3i}$ —资本投入。

- 其对数线性模型为:

(式8.6.2)

$$\ln Y_i = \beta_0 + \beta_2 \ln X_{2i} + \beta_3 \ln X_{3i} + u_i$$

— 其中:  $\beta_0 = \ln \beta_1$

- 假设所描述的生产是规模报酬不变, 由经济理论可知:

(式8.6.3)

$$\beta_2 + \beta_3 = 1$$

——线性等式约束条件

# 受约束的最小二乘法: 检验线性等式约束条件

——线性等式约束的检验: t检验

- 如何检验生产是规模报酬不变? 也即如何检验:

$$\beta_2 + \beta_3 = 1$$

➤ **方法一: t检验** (静观后效法, post mortem examination)

- 先做无约束的或无限制的回归 (unrestricted or unconstrained regression):

$$\ln Y_i = \hat{\beta}_0 + \hat{\beta}_2 \ln X_{2i} + \hat{\beta}_3 \ln X_{3i} + e_i$$

- 构建t统计量: 
$$t = \frac{(\hat{\beta}_2 + \hat{\beta}_3) - (\beta_2 + \beta_3)}{se(\hat{\beta}_2 + \hat{\beta}_3)} \sim t(n-k)$$

- 在虚拟假设  $H_0: \beta_2 + \beta_3 = 1$  下, 有:

$$t^* = \frac{\hat{\beta}_2 + \hat{\beta}_3 - 1}{se(\hat{\beta}_2 + \hat{\beta}_3)} = \frac{\hat{\beta}_2 + \hat{\beta}_3 - 1}{\sqrt{\text{var}(\hat{\beta}_2) + \text{var}(\hat{\beta}_3) + 2\text{cov}(\hat{\beta}_2, \hat{\beta}_3)}}$$

(式8.6.4)

如果  $t^* > t_\alpha(n-k)$ , 拒绝  $H_0$ , 即规模报酬可变;  
如果  $t^* < t_\alpha(n-k)$ , 则不拒绝  $H_0$  (即规模报酬不变)。

➤ 方法二: F检验

(式8.6.2)

$$\ln Y_i = \beta_0 + \beta_2 \ln X_{2i} + \beta_3 \ln X_{3i} + u_i$$

(式8.6.3)

$$\beta_2 + \beta_3 = 1$$

——线性等式约束条件

● 受约束的最小二乘法 (restricted least squares, RLS)

- A. 直接带入约束条件:

(式8.6.5)

$$\beta_2 = 1 - \beta_3$$

(式8.6.6)

$$\text{或: } \beta_3 = 1 - \beta_2$$

- B. 得到转换后的柯布道格拉斯生产函数:

$$\ln Y_i = \beta_0 + (1 - \beta_3) \ln X_{2i} + \beta_3 \ln X_{3i} + u_i$$

$$= \beta_0 + \ln X_{2i} + \beta_3 (\ln X_{3i} - \ln X_{2i}) + u_i$$

(式8.6.7)

$$(\ln Y_i - \ln X_{2i}) = \beta_0 + \beta_3 (\ln X_{3i} - \ln X_{2i}) + u_i$$

(式8.6.8)

$$\text{或: } \ln(Y_i / X_{2i}) = \beta_0 + \beta_3 \ln(X_{3i} / X_{2i}) + u_i$$

# 受约束的最小二乘法: 检验线性等式约束条件

## ——线性等式约束的检验: F检验 (2/3)

- 如何检验生产是规模报酬不变? 也即如何检验:

$$\beta_2 + \beta_3 = 1$$

- RLS下F检验步骤如下:

(Unrestricted model)

$$\ln Y_i = \hat{\beta}_0 + \hat{\beta}_2 \ln X_{2i} + \hat{\beta}_3 \ln X_{3i} + e_i$$

无约束条件

(Restricted model)

$$(\ln Y_i - \ln X_{2i}) = \hat{\beta}_0 + \hat{\beta}_3 (\ln X_{3i} - \ln X_{2i}) + e_i$$

约束条件:  $\beta_2 = 1 - \beta_3$

- 得到:

(式8.6.9)

$$F^* = \frac{(RSS_R - RSS_{UR})/m}{RSS_{UR}/(n-k)} = \frac{(\sum e_R^2 - \sum e_{UR}^2)/m}{\sum e_{UR}^2/(n-k)} \sim F(m, n-k)$$

$\sum e_{UR}^2$  = 无约束回归的RSS  
 $\sum e_R^2$  = 受约束回归的RSS

m—线性约束个数 (本例中是1)  
 k—无约束回归中的参数个数  
 n—观测次数

如果  $F^* > F_\alpha(m, n-k)$ , 拒绝  $H_0$ , 即规模报酬可变;  
 如果  $F^* < F_\alpha(m, n-k)$ , 则不拒绝  $H_0$  (即规模报酬不变)。

# 受约束的最小二乘法: 检验线性等式约束条件

——线性等式约束的检验: F检验 (3/3)

- F统计量公式也可用 $R^2$ 表示:

(式8.6.10)

$$F = \frac{(R_{UR}^2 - R_R^2)/m}{(1 - R_{UR}^2)/(n - k)}$$

$R_{UR}^2$  = 无约束回归的RSS

$R_R^2$  = 约束回归的RSS

m—线性约束个数 (本例中是1)

k—无约束回归中的参数个数

n—观测次数

# 受约束的最小二乘法: 检验线性等式约束条件

——实例说明: 墨西哥经济的柯布道格拉斯生产函数

(式8.6.10)

$$\widehat{\ln GDP}_t = -1.6524 + 0.3397 \ln Labor_t + 0.8460 \ln Capital_t$$

$$t = (-2.7259) \quad (1.8295) \quad (9.0625)$$

$$p \text{ 值} = (0.0144) \quad (0.0849) \quad (0.0000)$$

$$R^2 = 0.9951$$

$$RSS_{UR} = 0.0136$$

$$\widehat{\ln (GDP/Labor)}_t = -0.4947 + 1.0153 \ln (Capital/Labor)_t$$

$$t = (-4.0612) \quad (28.1056)$$

$$p \text{ 值} = (0.0007) \quad (0.0000)$$

$$R_R^2 = 0.9777 \quad RSS_R = 0.0166$$

$$F = \frac{(RSS_R - RSS_{UR})/m}{RSS_{UR}/(n-k)}$$

$$= \frac{(0.0166 - 0.0136)/1}{(0.0136)/(20-3)}$$

$$= 3.75$$

$$F_\alpha(m, n-k)$$

$$= F_{0.05}(1, 17) = 4.451322$$

**自学：本课程不要求掌握！**

自学：本课程不要求掌握！

## § 3.3 线性回归模型的矩阵表达

- 3.3.1 k变量线性回归模型
- 3.3.2 经典线性回归模型假定的矩阵表述
- 3.3.3 OLS 估计
- 3.3.4 用矩阵表示的判定系数 $R^2$
- 3.3.5 相关矩阵
- 3.3.6 对单个回归系数进行假设检验的矩阵表述
- 3.3.7 检验回归的总显著性:方差分析的矩阵表述
- 3.3.8 检验线性约束:用矩阵表示的一般F检验法\*
- 3.3.9 用多元回归做预测:矩阵表述
- 3.3.10 矩阵方法总结: 一个说明性例子



# k变量线性回归模型 ——矩阵表达

- k变量总体回归模型矩阵表达为：

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{21} & X_{31} & \cdots & X_{k1} \\ 1 & X_{22} & X_{32} & \cdots & X_{k2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{2n} & X_{3n} & \cdots & X_{kn} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix}$$

$$\begin{matrix} \mathbf{y} & = & \mathbf{X} & & \boldsymbol{\beta} & + & \mathbf{u} \\ n \times 1 & & n \times k & & k \times 1 & & n \times 1 \end{matrix}$$

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$$

我们将用小写粗体字母表示**向量**，用大写粗体字母表示**矩阵**

- 根据表2-4，一元回归分析中：

$$\begin{bmatrix} 70 \\ 65 \\ 90 \\ 95 \\ 110 \\ 115 \\ 120 \\ 140 \\ 155 \\ 150 \end{bmatrix} = \begin{bmatrix} 1 & 80 \\ 1 & 100 \\ 1 & 120 \\ 1 & 140 \\ 1 & 160 \\ 1 & 180 \\ 1 & 200 \\ 1 & 220 \\ 1 & 240 \\ 1 & 260 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \\ u_5 \\ u_6 \\ u_7 \\ u_8 \\ u_9 \\ u_{10} \end{bmatrix}$$

$$\begin{matrix} \mathbf{y} & = & \mathbf{X} & \boldsymbol{\beta} & + & \mathbf{u} \\ 10 \times 1 & & 10 \times 2 & 2 \times 1 & & 10 \times 1 \end{matrix}$$

(式C. 1. 6)

表C-1 关于经典回归模型的假定

标量符号		矩阵符号
假设1: 对每个 <i>i</i> , $E(u_i) = 0$	(3.2.1)	$E(\mathbf{u}) = \mathbf{0}$ 其中 <u>u</u> 和0都是n×1列向量 且0是零向量
假设2: $E(u_i u_j) = \begin{cases} 0, & i \neq j \\ \sigma^2, & i = j \end{cases}$	(3.2.5) (3.2.2)	$E(\mathbf{u}\mathbf{u}') = \sigma^2 \mathbf{I}$ 其中I是n×n单位矩阵
假设3: $X_2, X_3, \dots, X_k$ 是非随机的或固定的		n×k矩阵X是非随机的,即它由固定数的一个集合构成
假设4: X诸变量之间无完全的线性关系,即无多重共线性	(7.1.7)	$R(\mathbf{X}) = R(\mathbf{X}'\mathbf{X}) = k$ 其中k是X中的列数,且k小于观测次数n
假设5: $u_i \sim N(0, \sigma^2)$	(4.2.4)	$\mathbf{u} \sim N(\mathbf{0}, \sigma^2 \mathbf{I})$

- 假设1：干扰项的期望等于零

$$E(\mathbf{u}) = \mathbf{0} \xrightarrow{\text{表达式代表}} E \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} = \begin{bmatrix} E(u_1) \\ E(u_2) \\ \vdots \\ E(u_n) \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

- 干扰项的方差-协方差矩阵(variance covariance matrix)

$$\begin{aligned}
 E(\mathbf{uu}') &= E \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} [u_1 \quad u_2 \quad \cdots \quad u_n] = E \begin{bmatrix} u_1^2 & u_1u_2 & \cdots & u_1u_n \\ u_2u_1 & u_2^2 & \cdots & u_2u_n \\ \cdots & \cdots & \cdots & \cdots \\ u_nu_1 & u_nu_2 & \cdots & u_n^2 \end{bmatrix} \\
 &= \begin{bmatrix} E(u_1^2) & E(u_1u_2) & \cdots & E(u_1u_n) \\ E(u_2u_1) & E(u_2^2) & \cdots & E(u_2u_n) \\ \cdots & \cdots & \cdots & \cdots \\ E(u_nu_1) & E(u_nu_2) & \cdots & E(u_n^2) \end{bmatrix}
 \end{aligned}$$



➤ **假设4：X诸变量之间无完全线性关系，即无多重共线性**

$$R(\mathbf{X}) = R(\mathbf{X}'\mathbf{X}) = k$$

- 其中R表示矩阵的秩
- 该矩阵表达式说明：X矩阵是列满秩(full column rank)的，也即其秩等于矩阵的列数。
- 表明：X矩阵的列是线性独立的，即在X变量之间无完全的线性关系即无多重共线性。

(式C. 3. 1)

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + \cdots + \hat{\beta}_k X_{ki} + e_i$$

(式C. 3. 3)

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{21} & X_{31} & \cdots & X_{k1} \\ 1 & X_{22} & X_{32} & \cdots & X_{k2} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ 1 & X_{2n} & X_{3n} & \cdots & X_{kn} \end{bmatrix} \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \vdots \\ \hat{\beta}_k \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}$$

$$\begin{matrix} \mathbf{y} & = & \mathbf{X} & \hat{\boldsymbol{\beta}} & + & \mathbf{e} \\ n \times 1 & & n \times k & k \times 1 & & n \times 1 \end{matrix}$$

(式C. 3. 2)

$$\mathbf{y} = \mathbf{X}\hat{\boldsymbol{\beta}} + \mathbf{e}$$

(式C. 3. 1)

$$\sum e_i^2 = \sum \left( Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \dots - \hat{\beta}_k X_{ki} \right)^2$$

(式C. 3. 3)

$$= e_1^2 + e_2^2 + \dots + e_n^2 = [e_1 \ e_2 \ \dots \ e_n] \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}$$

$$= \mathbf{e}'\mathbf{e} = (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})' (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})$$

$$= \mathbf{y}'\mathbf{y} - 2\hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} + \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}$$

$$\mathbf{y} = \mathbf{X}\hat{\boldsymbol{\beta}} + \mathbf{e}$$

$$\mathbf{e} = \mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}$$

(式C. 3. 2)

$$(\hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y})' = \mathbf{y}'\mathbf{X}\hat{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}$$

标量的转置还是自身!

$$(1*k) \cdot (k*n) \cdot (n*1) = (1*1)$$

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}_1} = 2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \dots - \hat{\beta}_k X_{ki}) (-1) = 0$$

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}_2} = 2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{2i} - \dots - \hat{\beta}_k X_{ki}) (-X_{2i}) = 0$$

.....

$$\frac{\partial \sum e_i^2}{\partial \hat{\beta}_k} = 2 \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_{ki} - \dots - \hat{\beta}_k X_{ki}) (-X_{ki}) = 0$$



$$\begin{bmatrix}
 n & \sum X_{2i} & \sum X_{3i} & \dots & \sum X_{ki} \\
 \sum X_{2i} & \sum X_{2i}^2 & \sum X_{2i}X_{3i} & \dots & \sum X_{2i}X_{ki} \\
 \sum X_{3i} & \sum X_{3i}X_{2i} & \sum X_{3i}^2 & \dots & \sum X_{3i}X_{ki} \\
 \dots & \dots & \dots & \dots & \dots \\
 \sum X_{ki} & \sum X_{ki}X_{2i} & \sum X_{ki}X_{3i} & \dots & \sum X_{ki}^2
 \end{bmatrix}
 \begin{bmatrix}
 \hat{\beta}_1 \\
 \hat{\beta}_2 \\
 \hat{\beta}_3 \\
 \dots \\
 \hat{\beta}_k
 \end{bmatrix}
 =
 \begin{bmatrix}
 1 & 1 & 1 & \dots & 1 \\
 X_{21} & X_{22} & X_{23} & \dots & X_{2n} \\
 X_{31} & X_{32} & X_{33} & \dots & X_{3n} \\
 \dots & \dots & \dots & \dots & \dots \\
 X_{k1} & X_{k2} & X_{kn} & \dots & X_{kn}
 \end{bmatrix}
 \begin{bmatrix}
 Y_1 \\
 Y_2 \\
 Y_3 \\
 \dots \\
 Y_n
 \end{bmatrix}$$

$(\mathbf{X}'\mathbf{X}) \quad \hat{\boldsymbol{\beta}} \quad \mathbf{X}' \quad \mathbf{y}$

$$(\mathbf{X}'\mathbf{X})\hat{\boldsymbol{\beta}} = \mathbf{X}'\mathbf{y}$$

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} 1 & 1 & 1 & \cdots & 1 \\ X_{21} & X_{22} & X_{32} & \cdots & X_{2n} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ X_{k1} & X_{k2} & X_{k3} & \cdots & X_{kn} \end{bmatrix} \begin{bmatrix} 1 & X_{21} & X_{31} & \cdots & X_{k1} \\ 1 & X_{22} & X_{32} & \cdots & X_{k2} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ 1 & X_{2n} & X_{3n} & \cdots & X_{kn} \end{bmatrix} = \begin{bmatrix} n & \sum X_{2i} & \sum X_{3i} & \cdots & \sum X_{ki} \\ \sum X_{2i} & \sum X_{2i}^2 & \sum X_{2i}X_{3i} & \cdots & \sum X_{2i}X_{ki} \\ \sum X_{3i} & \sum X_{3i}X_{2i} & \sum X_{3i}^2 & \cdots & \sum X_{3i}X_{ki} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \sum X_{ki} & \sum X_{ki}X_{2i} & \sum X_{ki}X_{3i} & \cdots & \sum X_{ki}^2 \end{bmatrix}$$

● 特点：

- (1) 它给出X 变量的原始平方和与交叉乘积和， 变量之一是每次观测都取值1 的截距项, 主对角线上的元素是原始平方和. 而主对角线以外的元素则是原始交叉乘积和。（“原始” 是指以原有度量单位计算的）。
- (2) 它是对称的；
- (3) 它的阶数是 $(k \times k)$ , 也就是k行与k列

$$(\mathbf{X}'\mathbf{X})\hat{\boldsymbol{\beta}} = \mathbf{X}'\mathbf{y}$$

if  $\exists (\mathbf{X}'\mathbf{X})^{-1}$

$$(\mathbf{X}'\mathbf{X})^{-1} (\mathbf{X}'\mathbf{X})\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$

$$(k \times 1) \quad (k \times k) \quad (k \times n) \quad (n \times 1)$$

(式C.3.11)

$$\frac{\partial \mathbf{e}'\mathbf{e}}{\partial \hat{\boldsymbol{\beta}}} = \frac{\partial}{\partial \hat{\boldsymbol{\beta}}} (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})' (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}) = 0$$

$$\frac{\partial}{\partial \hat{\boldsymbol{\beta}}} (\mathbf{y}'\mathbf{y} - 2\mathbf{y}'\mathbf{X}\hat{\boldsymbol{\beta}} + \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}) = 0$$

$$-2\mathbf{X}'\mathbf{y} + (\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} + \mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}) = \mathbf{0}$$

$$-\mathbf{X}'\mathbf{y} + \mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{0}$$

$$\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}'\mathbf{y}$$

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$

若  $\mathbf{F} = \mathbf{AZ}$ , 则  $\frac{\partial \mathbf{F}}{\partial \mathbf{Z}} = \mathbf{A}'$ ;

若  $\mathbf{F} = \mathbf{ZA}$ , 则  $\frac{\partial \mathbf{F}}{\partial \mathbf{Z}} = \mathbf{A}$ ;

若  $\mathbf{F} = \mathbf{Z}'\mathbf{A}$ , 则  $\frac{\partial \mathbf{F}}{\partial \mathbf{Z}} = \mathbf{A}$ ;

若  $\mathbf{F} = \mathbf{A}'\mathbf{ZB}$ , 则  $\frac{\partial \mathbf{F}}{\partial \mathbf{Z}} = \mathbf{AB}'$ ;

若  $\mathbf{F} = \mathbf{A}'\mathbf{Z}'\mathbf{B}$ , 则  $\frac{\partial \mathbf{F}}{\partial \mathbf{Z}} = \mathbf{BA}'$

若  $\mathbf{F} = \mathbf{Z}'\mathbf{AZ}$ , 则  $\frac{\partial \mathbf{F}}{\partial \mathbf{Z}} = \mathbf{AZ} + \mathbf{A}'\mathbf{Z}$ ;

if  $\exists (\mathbf{X}'\mathbf{X})^{-1}$



$$\begin{bmatrix} 70 \\ 65 \\ 90 \\ 95 \\ 110 \\ 115 \\ 120 \\ 140 \\ 155 \\ 150 \end{bmatrix} = \begin{bmatrix} 1 & 80 \\ 1 & 100 \\ 1 & 120 \\ 1 & 140 \\ 1 & 160 \\ 1 & 180 \\ 1 & 200 \\ 1 & 220 \\ 1 & 240 \\ 1 & 260 \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} + \begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \\ u_5 \\ u_6 \\ u_7 \\ u_8 \\ u_9 \\ u_{10} \end{bmatrix}$$

$$\begin{matrix} \mathbf{y} & = & \mathbf{X} & \boldsymbol{\beta} & + & \mathbf{u} \\ 10 \times 1 & & 10 \times 2 & 2 \times 1 & & 10 \times 1 \end{matrix}$$

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ X_1 & X_2 & X_3 & \dots & X_n \end{bmatrix} \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ 1 & X_3 \\ \dots \\ 1 & X_N \end{bmatrix} = \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix}$$

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} 10 & 1\ 700 \\ 1\ 700 & 322\ 000 \end{bmatrix}$$

$$(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} 0.975\ 76 & -0.005\ 152 \\ -0.005\ 152 & 0.000\ 030\ 3 \end{bmatrix}$$

$$\mathbf{X}'\mathbf{y} = \begin{bmatrix} 1 & 1 & 1 & \dots & 1 \\ X_1 & X_2 & X_3 & \dots & X_n \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix}$$

$$\mathbf{X}'\mathbf{y} = \begin{bmatrix} 1\ 110 \\ 205\ 500 \end{bmatrix}$$

$$\boldsymbol{\beta} = \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} 0.975\ 76 & -0.005\ 152 \\ -0.005\ 152 & 0.000\ 030\ 3 \end{bmatrix} \begin{bmatrix} 1\ 110 \\ 205\ 500 \end{bmatrix} = \begin{bmatrix} 24.454\ 5 \\ 0.507\ 9 \end{bmatrix}$$

$$\begin{aligned} \text{var-cov}(\hat{\beta}) &= E \left\{ \left[ \hat{\beta} - E(\hat{\beta}) \right] \left[ \hat{\beta} - E(\hat{\beta}) \right]' \right\} \\ &= \begin{bmatrix} \text{var}(\hat{\beta}_1) & \text{cov}(\hat{\beta}_1, \hat{\beta}_2) & \text{cov}(\hat{\beta}_1, \hat{\beta}_k) \\ \text{cov}(\hat{\beta}_2, \hat{\beta}_1) & \text{var}(\hat{\beta}_2) & \text{cov}(\hat{\beta}_2, \hat{\beta}_k) \\ \text{L} & \text{L} & \text{L} \\ \text{cov}(\hat{\beta}_k, \hat{\beta}_1) & \text{cov}(\hat{\beta}_k, \hat{\beta}_2) & \text{L} & \text{var}(\hat{\beta}_k) \end{bmatrix} \\ &= \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \end{aligned}$$

$$\begin{aligned} & \text{var-cov}(\hat{\beta}) \\ &= E\left[(\hat{\beta} - \beta)(\hat{\beta} - \beta)'\right] \\ &= E\left\{\left[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}\right]\left[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}\right]'\right\} \\ &= E\left[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}\mathbf{u}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\right] \\ &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E(\mathbf{u}\mathbf{u}')\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \\ &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\sigma^2\mathbf{I}\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \\ &= \sigma^2(\mathbf{X}'\mathbf{X})^{-1} \end{aligned}$$

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

$$\begin{aligned} (AB)' &= B'A' \\ [(\mathbf{X}'\mathbf{X})^{-1}]' &= [(\mathbf{X}'\mathbf{X})']^{-1} \\ &= (\mathbf{X}'\mathbf{X})^{-1} \end{aligned}$$

$\mathbf{X}$ 取固定值；且 $E(\mu\mu') = \sigma^2\mathbf{I}$

- 可以证明 $\sigma^2$ 的无偏估计量是(证明略)：

$$E(\hat{\sigma}^2) = \sigma^2$$

- 其中，残差方差：
$$\hat{\sigma}^2 = \frac{\sum e_i^2}{n-k} = \frac{\mathbf{e}'\mathbf{e}}{n-k}$$

$$RSS = \sum e_i^2 = \mathbf{e}'\mathbf{e}$$

$$\mathbf{e}'\mathbf{e} = (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})' (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})$$

$$= (\mathbf{y}' - \hat{\boldsymbol{\beta}}'\mathbf{X}') (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})$$

$$= \mathbf{y}'\mathbf{y} - \mathbf{y}'\mathbf{X}\hat{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} + \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}$$

$$= \mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} - (\mathbf{y}' - \hat{\boldsymbol{\beta}}'\mathbf{X}') \mathbf{X}\hat{\boldsymbol{\beta}}$$

$$= \mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} - \mathbf{e}'\mathbf{X}\hat{\boldsymbol{\beta}}$$

$$= \mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} - (\mathbf{X}'\mathbf{e})' \hat{\boldsymbol{\beta}}$$

$$= \mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}$$

$$\mathbf{y} = \mathbf{X}\hat{\boldsymbol{\beta}} + \mathbf{e}$$

$$\mathbf{y}' = \hat{\boldsymbol{\beta}}'\mathbf{X}' + \mathbf{e}'$$

$$\mathbf{y}' - \hat{\boldsymbol{\beta}}'\mathbf{X}' = \mathbf{e}'$$

$$\mathbf{y} = \mathbf{X}\hat{\boldsymbol{\beta}} + \mathbf{e}$$

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$

$$\mathbf{X}'\mathbf{y} = \mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} + \mathbf{X}'\mathbf{e}$$

$$\begin{aligned} \mathbf{X}'\mathbf{y} &= \mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} + \mathbf{X}'\mathbf{e} \\ &= \mathbf{X}'\mathbf{y} + \mathbf{X}'\mathbf{e} \end{aligned}$$

$$\mathbf{X}'\mathbf{e} = \mathbf{0}$$

$$\text{TSS} = \mathbf{y}'\mathbf{y} - n\bar{Y}^2$$

$$\text{RSS} = \mathbf{e}'\mathbf{e} = \mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}$$

$$\text{ESS} = \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} - n\bar{Y}^2$$

$n\bar{Y}^2$ 被称为  
均值修正值

$$\begin{aligned} \text{ESS} &= \text{TSS} - \text{RSS} \\ &= \mathbf{y}'\mathbf{y} - n\bar{Y}^2 - (\mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}) \\ &= \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} - n\bar{Y}^2 \end{aligned}$$

$$\begin{aligned} \text{ESS} &= \sum y_i^2 - \left( \sum y_i^2 - \hat{\beta}_2 \sum y_i x_{2i} - \hat{\beta}_3 \sum y_i x_{3i} - \dots - \hat{\beta}_k \sum y_i x_{ki} \right) \\ &= \hat{\beta}_2 \sum y_i x_{2i} + \dots + \hat{\beta}_k \sum y_i x_{ki} \end{aligned}$$

$$\begin{aligned} \text{TSS} &= \sum y_i^2 \\ &= \sum (Y_i - \bar{Y})^2 \\ &= \sum (Y_i^2 - 2Y_i\bar{Y} + \bar{Y}^2) \\ &= \sum Y_i^2 - 2\bar{Y} \sum Y_i + n\bar{Y}^2 \\ &= \sum Y_i^2 - 2\bar{Y}n\bar{Y} + n\bar{Y}^2 \\ &= \sum Y_i^2 - n\bar{Y}^2 \\ &= \mathbf{y}'\mathbf{y} - n\bar{Y}^2 \end{aligned}$$

- 线性性:  $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$

- 无偏性:

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

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$$

$$E(\hat{\boldsymbol{\beta}}) = E(\boldsymbol{\beta}) + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'E(\mathbf{u}) = \boldsymbol{\beta}$$

- 最小方差性：
  - 令  $\beta^*$  为  $\beta$  的任意其他线性估计量，则：

$$\begin{aligned}\beta^* &= \left[ (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' + \mathbf{C} \right] \mathbf{y} \\ &= \left[ (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' + \mathbf{C} \right] (\mathbf{X}\beta + \mathbf{u}) \\ &= \beta + \mathbf{C}\mathbf{X}\beta + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{u} + \mathbf{C}\mathbf{u} \\ \beta^* - \beta &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{u} + \mathbf{C}\mathbf{u}\end{aligned}$$

若要求  $\beta^*$  为  $\beta$  的一个无偏估计量，  
则： $\mathbf{C}\mathbf{X} = \mathbf{0}$

- 根据方差定义，有：

$$\begin{aligned}\mathbf{var} - \mathbf{cov}(\boldsymbol{\beta}^*) &= \mathbf{E}(\boldsymbol{\beta}^* - \boldsymbol{\beta})(\boldsymbol{\beta}^* - \boldsymbol{\beta})' \\ &= \mathbf{E} \left\{ \left[ (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{u} + \mathbf{C}\mathbf{u} \right] \left[ (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{u} + \mathbf{C}\mathbf{u} \right]' \right\} \\ &= \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} + \sigma^2 \mathbf{C}\mathbf{C}' \\ &= \mathbf{var} - \mathbf{cov}(\hat{\boldsymbol{\beta}}) + \sigma^2 \mathbf{C}\mathbf{C}'\end{aligned}$$

∴  $\sigma^2 \mathbf{C}\mathbf{C}'$  是半正定矩阵，主对角线元素  $\geq 0$ ，

∴  $\mathbf{var} - \mathbf{cov}(\boldsymbol{\beta}^*) \geq \mathbf{var} - \mathbf{cov}(\hat{\boldsymbol{\beta}})$ ，即最小方差性成立。

$$\text{TSS} = \mathbf{y}'\mathbf{y} - n\bar{Y}^2$$

$$\text{RSS} = \mathbf{e}'\mathbf{e} = \mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}$$

$$\text{ESS} = \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} - n\bar{Y}^2$$

$$\begin{aligned} R^2 &= \frac{\text{ESS}}{\text{TSS}} \\ &= \frac{\hat{\beta}_2 \sum y_i x_{2i} + \hat{\beta}_3 \sum y_i x_{3i} + \cdots + \hat{\beta}_k \sum y_i x_{ki}}{\sum y_i^2} \\ &= \frac{\hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y} - n\bar{Y}^2}{\mathbf{y}'\mathbf{y} - n\bar{Y}^2} \end{aligned}$$

➤ 相关系数矩阵:

- k变量回归模型共有 $\frac{k(k+1)}{2}$ 个相关系数:

$$R = \begin{bmatrix} r_{11} & r_{12} & r_{13} & \cdots & r_{1k} \\ r_{21} & r_{22} & r_{23} & \cdots & r_{2k} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ r_{k1} & r_{k2} & r_{k3} & \cdots & r_{kk} \end{bmatrix} = \begin{bmatrix} 1 & r_{12} & r_{13} & \cdots & r_{1k} \\ r_{21} & 1 & r_{23} & \cdots & r_{2k} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ r_{k1} & r_{k2} & r_{k3} & \cdots & 1 \end{bmatrix}$$

### § 3.3.6

对单个回归系数进行  
假设检验的矩阵表达

## 对单个回归系数进行假设检验的矩阵表达 ——t检验：原理及矩阵形式

$$\mathbf{u} \sim N(\mathbf{0}, \sigma^2 \mathbf{I})$$

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

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$

$$\text{var-cov}(\hat{\boldsymbol{\beta}}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

$$t = \frac{\hat{\beta}_i - \beta_i}{S_{\hat{\beta}_i}} \sim t(n-k)$$

$$\hat{\sigma}^2 = \frac{\sum e_i^2}{n-k} = \frac{\mathbf{e}'\mathbf{e}}{n-k} = \frac{RSS}{n-k} = \frac{\mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}}{n-k}$$

$$t = \frac{\hat{\beta}_j - \beta_j}{S_{\hat{\beta}_j}} = \frac{\hat{\beta}_j - \beta_j}{\sqrt{c_{ij} \frac{\mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}}{n-k}}}$$

以  $c_{ij}$  表示矩阵  
 $(\mathbf{X}'\mathbf{X})^{-1}$  主对角线  
上的第  $j$  个元素

### § 3.3.7

检验回归的总显著性:  
方差分析的矩阵表达

## 检验回归的总显著性: 方差分析的矩阵表达 ——判定系数 $R^2$ 的矩阵形式

变异来源	平方和(SS)	自由度	均方和MSS
来自回归(即来自 $X_2, X_3 \dots X_k$ )	$\hat{\beta}'\mathbf{X}'\mathbf{y} - n\bar{Y}^2$	$k-1$	$\frac{\hat{\beta}'\mathbf{X}'\mathbf{y} - n\bar{Y}^2}{k-1}$
来自残差	$\mathbf{y}'\mathbf{y} - \hat{\beta}'\mathbf{X}'\mathbf{y}$	$n-k$	$\frac{\mathbf{y}'\mathbf{y} - \hat{\beta}'\mathbf{X}'\mathbf{y}}{n-k}$
总计	$\mathbf{y}'\mathbf{y} - n\bar{Y}^2$	$n-1$	

$$R^2 = \frac{ESS}{TSS} = \frac{(\hat{\beta}'\mathbf{X}'\mathbf{y} - n\bar{Y}^2)}{\mathbf{y}'\mathbf{y} - n\bar{Y}^2}$$

$$\bar{R}^2 = \frac{ESS/f_{ESS}}{TSS/f_{TSS}} = \frac{MSS_{ESS}}{MSS_{TSS}} = \frac{(\hat{\beta}'\mathbf{X}'\mathbf{y} - n\bar{Y}^2)/k-1}{(\mathbf{y}'\mathbf{y} - n\bar{Y}^2)/n-1}$$

### § 3.3.7

检验回归的总显著性:  
方差分析的矩阵表达

## 检验回归的总显著性: 方差分析的矩阵表达 ——F检验: k 变量线性回归的ANOVA矩阵形式

变异来源	平方和(SS)	自由度	均方和MSS
来自回归(即来自 $X_2, X_3 \dots X_k$ )	$\hat{\beta}'X'y - n\bar{Y}^2$	k-1	$\frac{\hat{\beta}'X'y - n\bar{Y}^2}{k-1}$
来自残差	$y'y - \hat{\beta}'X'y$	n-k	$\frac{y'y - \hat{\beta}'X'y}{n-k}$
总计	$y'y - n\bar{Y}^2$	n-1	

$$F^* = \frac{ESS / f_{ESS}}{RSS / f_{RSS}} = \frac{MSS_{ESS}}{MSS_{RSS}} = \frac{(\hat{\beta}'X'y - n\bar{Y}^2) / (k-1)}{(y'y - \hat{\beta}'X'y) / (n-k)}$$

### § 3.3.7

检验回归的总显著性:  
方差分析的矩阵表达

## 检验回归的总显著性: 方差分析的矩阵表达 ——F检验: 由 $R^2$ 表示的k变量ANOVA矩阵形式

变异来源	平方和	自由度	均方和
来自回归(即来自 $X_2, X_3, \dots, X_k$ )	$R^2(y'y - n\bar{Y}^2)$	$k-1$	$\frac{R^2(y'y - n\bar{Y}^2)}{k-1}$
来自残差	$(1-R^2)(y'y - n\bar{Y}^2)$	$n-k$	$\frac{(1-R^2)(y'y - n\bar{Y}^2)}{n-k}$
总计	$y'y - n\bar{Y}^2$	$n-1$	

$$F = \frac{R^2 / (k-1)}{1-R^2 / n-k}$$

自学: 本课程不要求掌握

对于模型 $\hat{Y} = X\hat{\beta}$ , 给定 $X_0 = (1, X_{01}, X_{02}, \dots, X_{0k})$

$$E(\hat{Y}_0) = E(\mathbf{X}_0\hat{\beta}) = \mathbf{X}_0 E(\hat{\beta}) = \mathbf{X}_0\beta = E(Y_0)$$

方差定义

$$\text{Var}(\hat{Y}_0) = E(\mathbf{X}_0\hat{\beta} - \mathbf{X}_0\beta)^2 = E(\mathbf{X}_0(\hat{\beta} - \beta)\mathbf{X}_0(\hat{\beta} - \beta))$$

 $X_0(\hat{\beta}-\beta)$ 为标量

$$\text{Var}(\hat{Y}_0) = E(\mathbf{X}_0(\hat{\beta} - \beta)(\hat{\beta} - \beta)'\mathbf{X}_0')$$

标量的转置为其自身

$$= \mathbf{X}_0 E(\hat{\beta} - \beta)(\hat{\beta} - \beta)'\mathbf{X}_0'$$

 $E(\hat{\beta}-\beta)(\hat{\beta}-\beta)'$ 即 $\text{Var}(\hat{\beta})$ 

$$= \sigma^2 \mathbf{X}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}_0'$$

 $\text{Var}(\hat{\beta}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$ 

$$\hat{Y}_0 \sim N(\mathbf{X}_0\beta, \sigma^2 \mathbf{X}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}_0')$$

取随机扰动项的样本估计量 $\hat{\sigma}^2$ ，构造如下t统计量

$$\frac{\hat{Y}_0 - E(Y_0)}{S_{\hat{Y}_0}} = \frac{\hat{Y}_0 - E(Y_0)}{\sqrt{\hat{\sigma}^2 \mathbf{x}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0}} \sim t(n-k)$$

$$\hat{\sigma}^2 = \frac{\sum e_i^2}{n-k} = \frac{\mathbf{e}'\mathbf{e}}{n-k} = \frac{\mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}}{n-k}$$

于是，得到 $(1-\alpha)$ 的置信水平下 $E(Y_0)$ 的**置信区间**：

$$\hat{Y}_0 - t_{\frac{\alpha}{2}} \times \hat{\sigma} \sqrt{\mathbf{x}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0} < E(Y_0) < \hat{Y}_0 + t_{\frac{\alpha}{2}} \times \hat{\sigma} \sqrt{\mathbf{x}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0}$$

其中， $t_{\alpha/2}$ 为 $(1-\alpha)$ 的置信水平下的**临界值**。

$$e_0 = Y_0 - \hat{Y}_0$$

$$\begin{aligned} E(e_0) &= E(\mathbf{X}_0 \boldsymbol{\beta} + \mu_0 - \mathbf{X}_0 \hat{\boldsymbol{\beta}}) \\ &= E(\mu_0 - \mathbf{X}_0 (\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})) \\ &= E(\mu_0 - \mathbf{X}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\boldsymbol{\mu}) \\ &= 0 \end{aligned}$$

$$\begin{aligned} \text{Var}(e_0) &= E(e_0^2) \\ &= E(\mu_0 - \mathbf{X}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\boldsymbol{\mu})^2 \\ &= \sigma^2 (1 + \mathbf{X}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'_0) \end{aligned}$$

PRF和SRF的定义

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

扰动项期望为0假设

方差定义，且  $E(e_0)=0$

同上面的推导

用到标量转置性质

思考：有没有更简单的思路得出  $\text{Var}(e_0)$ ???

$$e_0 \sim N(0, \sigma^2 (1 + \mathbf{X}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}_0'))$$

$$S_{e_0}^2 = \hat{\sigma}^2 [1 + \mathbf{x}_0' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0]$$

$$S_{e_0} = \sqrt{\hat{\sigma}^2 [1 + \mathbf{x}_0' (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0]}$$

$$t = \frac{\hat{Y}_0 - Y_0}{S_{e_0}} = \frac{\hat{Y}_0 - Y_0}{\sqrt{\hat{\sigma}^2 (1 + \mathbf{x}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_0)}} \quad \square \quad t(n-k)$$

$$\hat{Y}_0 - t_{\frac{\alpha}{2}} \times \hat{\sigma} \sqrt{1 + \mathbf{X}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}_0'} < Y_0 < \hat{Y}_0 + t_{\frac{\alpha}{2}} \times \hat{\sigma} \sqrt{1 + \mathbf{X}_0 (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}_0'}$$

### § 3.3.10

矩阵方法总结:  
一个说明性例子

## 人均私人消费支出与(人均可支配收入和时间)的关系 ——数据表与基础计算

PPCE, $Y$	PPDI, $X_2$	时间, $X_3$	PPCE, $Y$	PPDI, $X_2$	时间, $X_3$
1 673	1 839	1 (=1956)	1 948	2 126	9
1 688	1 844	2	2 048	2 239	10
1 666	1 831	3	2 128	2 336	11
1 735	1 881	4	2 165	2 404	12
1 749	1 883	5	2 257	2 487	13
1 756	1 910	6	2 316	2 535	14
1 815	1 969	7	2 324	2 595	15 (=1970)
1 867	2 016	8			

$$Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_{2i} + \hat{\beta}_3 X_{3i} + a_i$$

$$\begin{matrix} \mathbf{y} & = & \mathbf{X} & \boldsymbol{\beta} & + & \mathbf{a} \\ 15 \times 1 & & 15 \times 3 & 3 \times 1 & & 15 \times 1 \end{matrix}$$

$$\bar{Y} = 1\,942.333 \quad \bar{X}_2 = 2\,126.333 \quad \bar{X}_3 = 8.0$$

$$\sum (Y_i - \bar{Y})^2 = 830\,121.333$$

$$\sum (X_{2i} - \bar{X}_2)^2 = 1\,103\,111.333 \quad \sum (X_{3i} - \bar{X}_3)^2 = 280.0$$

§ 3.3.10

矩阵方法总结:  
一个说明性例子

人均私人消费支出与(人均可支配收入和时间)的关系  
——求出回归系数矩阵

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} 1 & 1 & 1 & \cdots & 1 \\ X_{21} & X_{22} & X_{23} & \cdots & X_{2n} \\ X_{31} & X_{32} & X_{33} & \cdots & X_{3n} \end{bmatrix} \begin{bmatrix} 1 & X_{21} & X_{31} \\ 1 & X_{22} & X_{32} \\ 1 & X_{23} & X_{33} \\ \vdots & \vdots & \vdots \\ 1 & X_{2n} & X_{3n} \end{bmatrix}$$

$$= \begin{bmatrix} n & \sum X_{2i} & \sum X_{3i} \\ \sum X_{2i} & \sum X_{2i}^2 & \sum X_{2i}X_{3i} \\ \sum X_{3i} & \sum X_{2i}X_{3i} & \sum X_{3i}^2 \end{bmatrix}$$

$$= \begin{bmatrix} 15 & 31\ 895 & 120 \\ 31\ 895 & 68\ 922.513 & 272\ 144 \\ 120 & 272\ 144 & 1\ 240 \end{bmatrix}$$

$$(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} 37.232\ 491 & -0.022\ 508\ 2 & 1.336\ 707 \\ -0.022\ 508\ 2 & 0.000\ 013\ 7 & -0.000\ 831\ 9 \\ 1.336\ 707 & -0.000\ 831\ 9 & 0.054\ 034 \end{bmatrix}$$

$$\mathbf{X}'\mathbf{y} = \begin{bmatrix} 29\ 135 \\ 62\ 905\ 821 \\ 247\ 934 \end{bmatrix}$$

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} = \begin{bmatrix} 300.286\ 25 \\ 0.741\ 98 \\ 8.043\ 56 \end{bmatrix}$$

$$\sum e_i^2 = \mathbf{e}'\mathbf{e} = \mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}$$

$$= 57\ 420\ 003 - [300.286\ 25\ 0.741\ 98\ 8.043\ 56] \begin{bmatrix} 29\ 135 \\ 62\ 905\ 821 \\ 247\ 934 \end{bmatrix}$$

$$= 1\ 976.855\ 74$$

$$\hat{\sigma}^2 = \frac{\sum e_i^2}{n-k} = \frac{\mathbf{e}'\mathbf{e}}{12} = 164.73797$$

$$var-cov(\hat{\boldsymbol{\beta}}) = \hat{\sigma}^2 (\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} 6\ 133.650 & -3.707\ 94 & 220.206\ 34 \\ -3.707\ 94 & 0.002\ 26 & -0.137\ 05 \\ 220.206\ 34 & -0.137\ 05 & 8.901\ 55 \end{bmatrix}$$

$$ESS: \hat{\beta}'X'y - n\bar{Y}^2 = 828\,144.477\,86$$

$$TSS: y'y - n\bar{Y}^2 = 830\,121.333$$

$$\begin{aligned} R^2 &= \frac{\hat{\beta}'X'y - n\bar{Y}^2}{y'y - n\bar{Y}^2} \\ &= \frac{828\,144.477\,86}{830\,121.333} \\ &= 0.997\,61 \end{aligned}$$

$$t_{0.05/2}(12) = 2.178813$$

$$\begin{aligned} Y_i &= 300.286\,25 + 0.741\,98 X_{2i} + 8.043\,56 X_{3i} \\ &\quad (78.317\,63) \quad (0.047\,53) \quad (2.983\,54) \\ t &= (3.834\,21) \quad (15.609\,56) \quad (2.695\,98) \\ R^2 &= 0.997\,61 \quad R^2 = 0.997\,22 \quad df = 12 \end{aligned}$$

表 C—5

表 C—4 中数据的 ANOVA 表

变异来源	平方和	自由度	均方和
来自 $X_2, X_3$	828 144. 477 86	2	414 072. 389 3
来自残差	<u>1 976. 855 74</u>	<u>12</u>	164. 737 97
总计	830 121. 333 60	14	

$$F = \frac{414\ 072.389\ 3}{164.737\ 97} = 2\ 513.52$$

$$F_{0.05} (2, 12) = 3.885294$$

$$\begin{aligned}
 (\text{PPCE}_{1971} \mid \text{PPDI}_{1971}, X_3 = 16) &= \mathbf{x}'_{1971} \boldsymbol{\beta} \\
 &= [1 \quad 2610 \quad 16] \begin{bmatrix} 300.28625 \\ 0.74198 \\ 8.04356 \end{bmatrix} = 2365.55
 \end{aligned}$$

$$\begin{aligned}
 \text{var}(\hat{Y}_{1971} \mid \mathbf{x}'_{1971}) &= \sigma^2 [\mathbf{x}'_{1971} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_{1971}] \\
 &= 164.73797 [1 \quad 2610 \quad 16] (\mathbf{X}'\mathbf{X})^{-1} \begin{bmatrix} 1 \\ 2610 \\ 16 \end{bmatrix} = 48.6426
 \end{aligned}$$

$$\text{se}(\hat{Y}_{1971} \mid \mathbf{x}'_{1971}) = 6.9744$$

$$\text{var}(Y_{1971} \mid \mathbf{x}'_{1971}) = 213.3806$$

$$\text{se}(Y_{1971} \mid \mathbf{x}'_{1971}) = 14.6076$$