

# 計量モデル分析I

## グローバル計量モデル分析

### Thr., 8:50-10:20

### Room # 4 (法経講義棟)

- The prerequisite of this class is **Basic Statistics** (統計基礎) (by Prof. Oya, Tue., 16:20-17:50, this semester) and **Econometrics** (エコノメトリックス) (undergraduate level, next semester, 『計量経済学』 山本 拓 著, 新世社).
- The class of **Introductory Econometrics** (計量経済学基礎) (by Prof. Takeuchi, Mon., 16:20-17:50, this semester) should be registered.

代表的テキスト：

- J.D. Hamilton (1994) *Time Series Analysis*
- 沖本・井上訳 (2006) 『時系列解析(上・下)』
- A.C. Harvey (1981) *Time Series Models*
- 国友・山本訳 (1985) 『時系列モデル入門』
- 沖本竜義 (2010) 『経済・ファイナンスデータの計量時系列分析』

# **Statistics Test (統計検定) on June 22 (Sun.)**

- **Exams :** Level 2 (2 級) – Level 4 (4 級)

Note that Level 4 is Junior high school level,

Level 3 is High school level, and

Level 2 is the 1st or 2nd year statistics in undergraduate school.

See <http://www.toukei-kentei.jp/index.html> in more detail.

- **Qualification for Exam (受験資格) :**

Undergraduate and Graduate Students in Osaka University

- **Application Period (受験申込期間) :** April 14 (Mon.) — May 14 (Wed.)

- **Application Fee (受験料) :** Free

受験料は、平成24年度に採択された文部科学省の大学間連携共同推進事業「データに基づく課題解決型人材育成に資する統計教育質保証」から支払われる。

連携校： 東京大学、大阪大学、総合研究大学院大学、青山学院大学（代表校）、多摩大学、立教大学、早稲田大学、同志社大学

ちなみに、連携大学以外の人の受験料は、

統計検定2級 10:30～12:00 5,000円

統計検定3級 13:30～14:30 4,000円

統計検定4級 10:30～11:30 3,000円

となる。

- **Exam Date (試験日) :** June 22 (Sun.)
- **Exam Place (場所) :** 法経講義棟 #1, 2, 4

# 1 最小二乗法について

経済理論に基づいた線型モデルの係数の値をデータから求める時に用いられる手法  $\Rightarrow$  最小二乗法

## 1.1 最小二乗法と回帰直線

$(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$  のように  $n$  組のデータがあり、 $X_i$  と  $Y_i$  との間に以下の線型関係を想定する。

$$Y_i = \alpha + \beta X_i,$$

$X_i$  は説明変数、 $Y_i$  は被説明変数、 $\alpha, \beta$  はパラメータとそれぞれ呼ばれる。

上の式は回帰モデル(または、回帰式)と呼ばれる。目的は、切片  $\alpha$  と傾き  $\beta$  をデータ  $\{(X_i, Y_i), i = 1, 2, \dots, n\}$  から推定すること、

データについて：

1. タイム・シリーズ(時系列)・データ： $i$  が時間を表す(第  $i$  期)。
2. クロス・セクション(横断面)・データ： $i$  が個人や企業を表す(第  $i$  番目の家計，第  $i$  番目の企業)。

## 1.2 切片 $\alpha$ と傾き $\beta$ の推定

次のような関数  $S(\alpha, \beta)$  を定義する。

$$S(\alpha, \beta) = \sum_{i=1}^n u_i^2 = \sum_{i=1}^n (Y_i - \alpha - \beta X_i)^2$$

このとき，

$$\min_{\alpha, \beta} S(\alpha, \beta)$$

となるような  $\alpha, \beta$  を求める(最小自乗法)。このときの解を  $\widehat{\alpha}, \widehat{\beta}$  とする。

最小化のためには,

$$\frac{\partial S(\alpha, \beta)}{\partial \alpha} = 0$$

$$\frac{\partial S(\alpha, \beta)}{\partial \beta} = 0$$

を満たす  $\alpha, \beta$  が  $\widehat{\alpha}, \widehat{\beta}$  となる。 すなわち,  $\widehat{\alpha}, \widehat{\beta}$  は,

$$\sum_{i=1}^n (Y_i - \widehat{\alpha} - \widehat{\beta}X_i) = 0, \quad (1)$$

$$\sum_{i=1}^n X_i(Y_i - \widehat{\alpha} - \widehat{\beta}X_i) = 0, \quad (2)$$

を満たす。 さらに,

$$\sum_{i=1}^n Y_i = n\widehat{\alpha} + \widehat{\beta} \sum_{i=1}^n X_i, \quad (3)$$

$$\sum_{i=1}^n X_i Y_i = \widehat{\alpha} \sum_{i=1}^n X_i + \widehat{\beta} \sum_{i=1}^n X_i^2,$$

行列表示によって,

$$\begin{pmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n X_i Y_i \end{pmatrix} = \begin{pmatrix} n & \sum_{i=1}^n X_i \\ \sum_{i=1}^n X_i & \sum_{i=1}^n X_i^2 \end{pmatrix} \begin{pmatrix} \widehat{\alpha} \\ \widehat{\beta} \end{pmatrix},$$

逆行列の公式 :

$$\begin{pmatrix} a & b \\ c & d \end{pmatrix}^{-1} = \frac{1}{ad - bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

$\widehat{\alpha}, \widehat{\beta}$ について, まとめて,

$$\begin{aligned} \begin{pmatrix} \widehat{\alpha} \\ \widehat{\beta} \end{pmatrix} &= \begin{pmatrix} n & \sum_{i=1}^n X_i \\ \sum_{i=1}^n X_i & \sum_{i=1}^n X_i^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n X_i Y_i \end{pmatrix} \\ &= \frac{1}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} \begin{pmatrix} \sum_{i=1}^n X_i^2 & -\sum_{i=1}^n X_i \\ -\sum_{i=1}^n X_i & n \end{pmatrix} \begin{pmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n X_i Y_i \end{pmatrix} \end{aligned}$$

さらに,  $\widehat{\beta}$ について解くと,

$$\widehat{\beta} = \frac{n \sum_{i=1}^n X_i Y_i - (\sum_{i=1}^n X_i)(\sum_{i=1}^n Y_i)}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2}$$

$$= \frac{\sum_{i=1}^n X_i Y_i - n \overline{X} \overline{Y}}{\sum_{i=1}^n X_i^2 - n \overline{X}^2} = \frac{\sum_{i=1}^n (X_i - \overline{X})(Y_i - \overline{Y})}{\sum_{i=1}^n (X_i - \overline{X})^2}$$

連立方程式の(3)式から、

$$\hat{\alpha} = \overline{Y} - \hat{\beta} \overline{X}$$

となる。ただし、

$$\overline{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad \overline{Y} = \frac{1}{n} \sum_{i=1}^n Y_i,$$

とする。

**数値例：** 以下の数値例を使って、回帰式  $Y_i = \alpha + \beta X_i$  の  $\alpha$ ,  $\beta$  の推定値  $\hat{\alpha}$ ,  $\hat{\beta}$  を求める。

| $i$ | $Y_i$ | $X_i$ |
|-----|-------|-------|
| 1   | 6     | 10    |
| 2   | 9     | 12    |
| 3   | 10    | 14    |
| 4   | 10    | 16    |

$\hat{\alpha}$ ,  $\hat{\beta}$  を求めるための公式は

$$\hat{\beta} = \frac{\sum_{i=1}^n X_i Y_i - n \overline{X} \overline{Y}}{\sum_{i=1}^n X_i^2 - n \overline{X}^2}$$

$$\hat{\alpha} = \overline{Y} - \hat{\beta} \overline{X}$$

なので、必要なものは  $\overline{X}$ ,  $\overline{Y}$ ,  $\sum_{i=1}^n X_i^2$ ,  $\sum_{i=1}^n X_i Y_i$  である。

| $i$ | $Y_i$      | $X_i$      | $X_i Y_i$      | $X_i^2$      |
|-----|------------|------------|----------------|--------------|
| 1   | 6          | 10         | 60             | 100          |
| 2   | 9          | 12         | 108            | 144          |
| 3   | 10         | 14         | 140            | 196          |
| 4   | 10         | 16         | 160            | 256          |
| 合計  | $\sum Y_i$ | $\sum X_i$ | $\sum X_i Y_i$ | $\sum X_i^2$ |
|     | 35         | 52         | 468            | 696          |
| 平均  | $\bar{Y}$  | $\bar{X}$  |                |              |
|     | 8.75       | 13         |                |              |

よって、

$$\hat{\beta} = \frac{468 - 4 \times 13 \times 8.75}{696 - 4 \times 13^2} = \frac{13}{20} = 0.65$$

$$\hat{\alpha} = 8.75 - 0.65 \times 13 = 0.3$$

となる。

## 注意事項：

1.  $\alpha, \beta$  は真の値で未知
2.  $\widehat{\alpha}, \widehat{\beta}$  は  $\alpha, \beta$  の推定値でデータから計算される

回帰直線は

$$\widehat{Y}_i = \widehat{\alpha} + \widehat{\beta}X_i,$$

として与えられる。

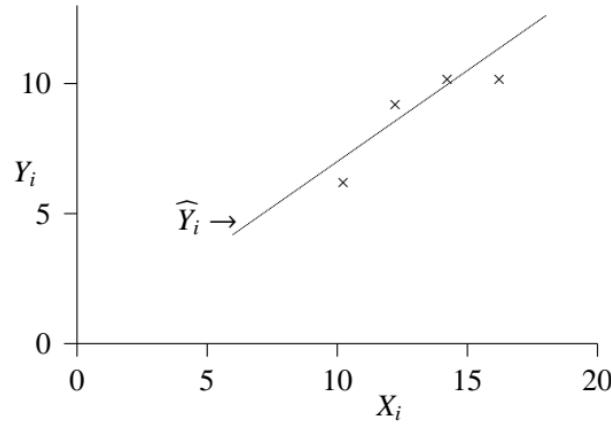
上の数値例では、

$$\widehat{Y}_i = 0.3 + 0.65X_i$$

となる。

| $i$ | $Y_i$      | $X_i$      | $X_i Y_i$      | $X_i^2$      | $\widehat{Y}_i$      |
|-----|------------|------------|----------------|--------------|----------------------|
| 1   | 6          | 10         | 60             | 100          | 6.8                  |
| 2   | 9          | 12         | 108            | 144          | 8.1                  |
| 3   | 10         | 14         | 140            | 196          | 9.4                  |
| 4   | 10         | 16         | 160            | 256          | 10.7                 |
| 合計  | $\sum Y_i$ | $\sum X_i$ | $\sum X_i Y_i$ | $\sum X_i^2$ | $\sum \widehat{Y}_i$ |
|     | 35         | 52         | 468            | 696          | 35.0                 |
| 平均  | $\bar{Y}$  | $\bar{X}$  |                |              |                      |
|     | 8.75       | 13         |                |              |                      |

図 2 :  $Y_i$ ,  $X_i$ ,  $\widehat{Y}_i$



$\widehat{Y}_i$  を実績値  $Y_i$  の予測値または理論値と呼ぶ。

$$\widehat{u}_i = Y_i - \widehat{Y}_i,$$

$\widehat{u}_i$  を残差と呼ぶ。

$$Y_i = \widehat{Y}_i + \widehat{u}_i = \widehat{\alpha} + \widehat{\beta}X_i + \widehat{u}_i,$$

さらに、 $\overline{Y}$  を両辺から引いて、

$$(Y_i - \overline{Y}) = (\widehat{Y}_i - \overline{Y}) + \widehat{u}_i,$$

### 1.3 残差 $\widehat{u}_i$ の性質について

$\widehat{u}_i = Y_i - \widehat{\alpha} - \widehat{\beta}X_i$  に注意して、(1) 式から、

$$\sum_{i=1}^n \widehat{u}_i = 0,$$

を得る。 (2) 式から、

$$\sum_{i=1}^n X_i \widehat{u}_i = 0,$$

を得る。  $\widehat{Y}_i = \widehat{\alpha} + \widehat{\beta}X_i$  から,

$$\sum_{i=1}^n \widehat{Y}_i \widehat{u}_i = 0,$$

を得る。なぜなら,

$$\begin{aligned}\sum_{i=1}^n \widehat{Y}_i \widehat{u}_i &= \sum_{i=1}^n (\widehat{\alpha} + \widehat{\beta}X_i) \widehat{u}_i \\ &= \widehat{\alpha} \sum_{i=1}^n \widehat{u}_i + \widehat{\beta} \sum_{i=1}^n X_i \widehat{u}_i \\ &= 0\end{aligned}$$

である。

| $i$ | $Y_i$      | $X_i$      | $\widehat{Y}_i$      | $\widehat{u}_i$      | $X_i \widehat{u}_i$      | $\widehat{Y}_i \widehat{u}_i$      |
|-----|------------|------------|----------------------|----------------------|--------------------------|------------------------------------|
| 1   | 6          | 10         | 6.8                  | -0.8                 | -8.0                     | -5.44                              |
| 2   | 9          | 12         | 8.1                  | 0.9                  | 10.8                     | 7.29                               |
| 3   | 10         | 14         | 9.4                  | 0.6                  | 8.4                      | 5.64                               |
| 4   | 10         | 16         | 10.7                 | -0.7                 | -11.2                    | -7.49                              |
| 合計  | $\sum Y_i$ | $\sum X_i$ | $\sum \widehat{Y}_i$ | $\sum \widehat{u}_i$ | $\sum X_i \widehat{u}_i$ | $\sum \widehat{Y}_i \widehat{u}_i$ |
|     | 35         | 52         | 35.0                 | 0.0                  | 0.0                      | 0.00                               |

## 1.4 決定係数 $R^2$ について

次の式

$$(Y_i - \bar{Y}) = (\widehat{Y}_i - \bar{Y}) + \widehat{u}_i,$$

の両辺を二乗して、総和すると、

$$\begin{aligned}\sum_{i=1}^n (Y_i - \bar{Y})^2 &= \sum_{i=1}^n ((\widehat{Y}_i - \bar{Y}) + \widehat{u}_i)^2 \\&= \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2 + 2 \sum_{i=1}^n (\widehat{Y}_i - \bar{Y}) \widehat{u}_i + \sum_{i=1}^n \widehat{u}_i^2 \\&= \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n \widehat{u}_i^2\end{aligned}$$

となる。まとめると、

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n \widehat{u}_i^2$$

を得る。さらに、

$$1 = \frac{\sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} + \frac{\sum_{i=1}^n \widehat{u}_i^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$$

それぞれの項は、

1.  $\sum_{i=1}^n (Y_i - \bar{Y})^2 \Rightarrow y$  の全変動
2.  $\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \Rightarrow \hat{Y}_i$  (回帰直線) で説明される部分
3.  $\sum_{i=1}^n \hat{u}_i^2 \Rightarrow \hat{Y}_i$  (回帰直線) で説明されない部分

となる。

回帰式の当てはまりの良さを示す指標として、決定係数  $R^2$  を以下の通りに定義する。

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}$$

または、

$$R^2 = 1 - \frac{\sum_{i=1}^n \hat{u}_i^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2},$$

として書き換えられる。

または、 $Y_i = \widehat{Y}_i + \widehat{u}_i$  と

$$\begin{aligned}\sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2 &= \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})(Y_i - \bar{Y} - \widehat{u}_i) \\&= \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})(Y_i - \bar{Y}) - \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})\widehat{u}_i \\&= \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})(Y_i - \bar{Y})\end{aligned}$$

を用いて、

$$\begin{aligned}R^2 &= \frac{\sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \\&= \frac{\left(\sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2\right)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2} \\&= \left( \frac{\sum_{i=1}^n (\widehat{Y}_i - \bar{Y})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2}} \right)^2\end{aligned}$$

と書き換えられる。 すなわち,  $R^2$  は  $Y_i$  と  $\widehat{Y}_i$  の相関係数の二乗と解釈される。

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n \widehat{u}_i^2 \text{ から, 明らかに,}$$

$$0 \leq R^2 \leq 1,$$

となる。 $R^2$  が 1 に近づけば回帰式の当てはまりは良いと言える。しかし,  $t$  分布のような数表は存在しない。したがって, 「どの値よりも大きくなるべき」というような基準はない。

慣習的には, メドとして 0.9 以上を判断基準にする。

数値例 : 決定係数の計算には以下の公式を用いる。

$$R^2 = 1 - \frac{\sum_{i=1}^n \widehat{u}_i^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} = 1 - \frac{\sum_{i=1}^n \widehat{u}_i^2}{\sum_{i=1}^n Y_i^2 - n\bar{Y}^2}$$

計算に必要なものは、 $\widehat{u}_i = Y_i - (\widehat{\alpha} + \widehat{\beta}X_i)$ ,  $\overline{Y}$ ,  $\sum_{i=1}^n Y_i^2$  である。

| $i$ | $Y_i$      | $X_i$      | $\widehat{Y}_i$      | $\widehat{u}_i$      | $\widehat{u}_i$        | $Y_i^2$      |
|-----|------------|------------|----------------------|----------------------|------------------------|--------------|
| 1   | 6          | 10         | 6.8                  | -0.8                 | 0.64                   | 36           |
| 2   | 9          | 12         | 8.1                  | 0.9                  | 0.81                   | 81           |
| 3   | 10         | 14         | 9.4                  | 0.6                  | 0.36                   | 100          |
| 4   | 10         | 16         | 10.7                 | -0.7                 | 0.49                   | 100          |
| 合計  | $\sum Y_i$ | $\sum X_i$ | $\sum \widehat{Y}_i$ | $\sum \widehat{u}_i$ | $\sum \widehat{u}_i^2$ | $\sum Y_i^2$ |
|     | 35         | 52         | 35.0                 | 0.0                  | 2.30                   | 317          |

$\sum \widehat{u}_i^2 = 2.30$ ,  $\overline{X} = 13$ ,  $\overline{Y} = 8.75$ ,  $\sum_{i=1}^n Y_i^2 = 317$  なので,

$$R^2 = 1 - \frac{2.30}{317 - 4 \times 8.75^2} = 1 - \frac{2.30}{10.75} = 0.786$$

## 1.5 まとめ

$\hat{\alpha}$ ,  $\hat{\beta}$  を求めるための公式は

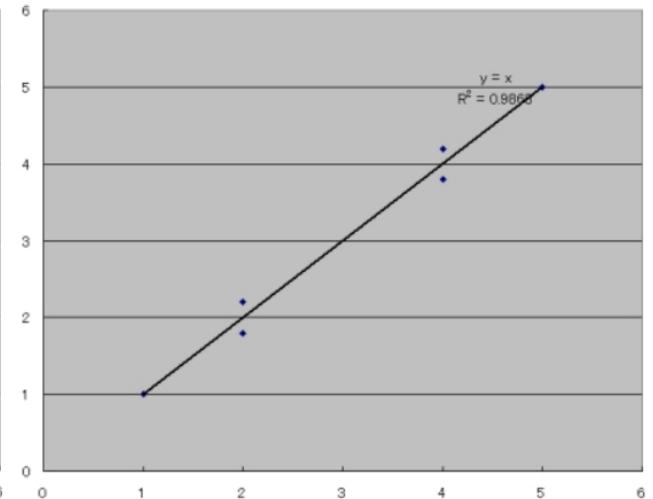
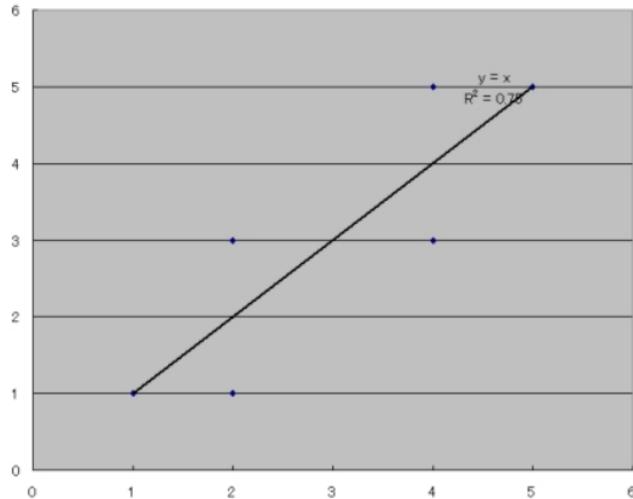
$$\begin{aligned}\hat{\beta} &= \frac{\sum_{i=1}^n X_i Y_i - n \bar{X} \bar{Y}}{\sum_{i=1}^n X_i^2 - n \bar{X}^2} \\ \hat{\alpha} &= \bar{Y} - \hat{\beta} \bar{X}\end{aligned}$$

なので、必要なものは  $\bar{X}$ ,  $\bar{Y}$ ,  $\sum_{i=1}^n X_i^2$ ,  $\sum_{i=1}^n X_i Y_i$  である。

決定係数の計算には以下の公式を用いる。

$$R^2 = 1 - \frac{\sum_{i=1}^n \hat{u}_i^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} = 1 - \frac{\sum_{i=1}^n \hat{u}_i^2}{\sum_{i=1}^n Y_i^2 - n \bar{Y}^2}$$

計算に必要なものは、 $\sum \hat{u}_i^2$ ,  $\bar{Y}$ ,  $\sum_{i=1}^n Y_i^2$  である。



## 2 Regression Analysis (回帰分析)

### 2.1 Setup of the Model

When  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  are available, suppose that there is a linear relationship between  $y$  and  $x$ , i.e.,

$$y_i = \beta_1 + \beta_2 x_i + u_i, \quad (4)$$

for  $i = 1, 2, \dots, n$ .  $x_i$  and  $y_i$  denote the  $i$ th observations.

→ Single (or simple) regression model (単回帰モデル)

$y_i$  is called the **dependent variable** (従属変数) or the **explained variable** (被説明変数), while  $x_i$  is known as the **independent variable** (独立変数) or the **explanatory (or explaining) variable** (説明変数).

$$\beta_1 = \text{Intercept} \text{ (切片)}, \quad \beta_2 = \text{Slope} \text{ (傾き)}$$

$\beta_1$  and  $\beta_2$  are unknown **parameters** (パラメータ, 母数) to be estimated.

$\beta_1$  and  $\beta_2$  are called the **regression coefficients** (回帰係数).

$u_i$  is the unobserved **error term** (誤差項) assumed to be a random variable with mean zero and variance  $\sigma^2$ .

$\sigma^2$  is also a parameter to be estimated.

$x_i$  is assumed to be **nonstochastic** (非確率的), but  $y_i$  is **stochastic** (確率的) because  $y_i$  depends on the error  $u_i$ .

The error terms  $u_1, u_2, \dots, u_n$  are assumed to be mutually independently and identically distributed, which is called *iid*.

It is assumed that  $u_i$  has a distribution with mean zero, i.e.,  $E(u_i) = 0$  is assumed.

Taking the expectation on both sides of (4), the expectation of  $y_i$  is represented as:

$$\begin{aligned} E(y_i) &= E(\beta_1 + \beta_2 x_i + u_i) = \beta_1 + \beta_2 x_i + E(u_i) \\ &= \beta_1 + \beta_2 x_i, \end{aligned} \tag{5}$$

for  $i = 1, 2, \dots, n$ .

Using  $E(y_i)$  we can rewrite (4) as  $y_i = E(y_i) + u_i$ .

(5) represents the true regression line.

Let  $\hat{\beta}_1$  and  $\hat{\beta}_2$  be estimates of  $\beta_1$  and  $\beta_2$ .

Replacing  $\beta_1$  and  $\beta_2$  by  $\hat{\beta}_1$  and  $\hat{\beta}_2$ , (4) turns out to be:

$$y_i = \hat{\beta}_1 + \hat{\beta}_2 x_i + e_i, \tag{6}$$

for  $i = 1, 2, \dots, n$ , where  $e_i$  is called the **residual** (残差).

The residual  $e_i$  is taken as the experimental value (or realization) of  $u_i$ .

We define  $\hat{y}_i$  as follows:

$$\hat{y}_i = \hat{\beta}_1 + \hat{\beta}_2 x_i, \quad (7)$$

for  $i = 1, 2, \dots, n$ , which is interpreted as the **predicted value** (予測値) of  $y_i$ .

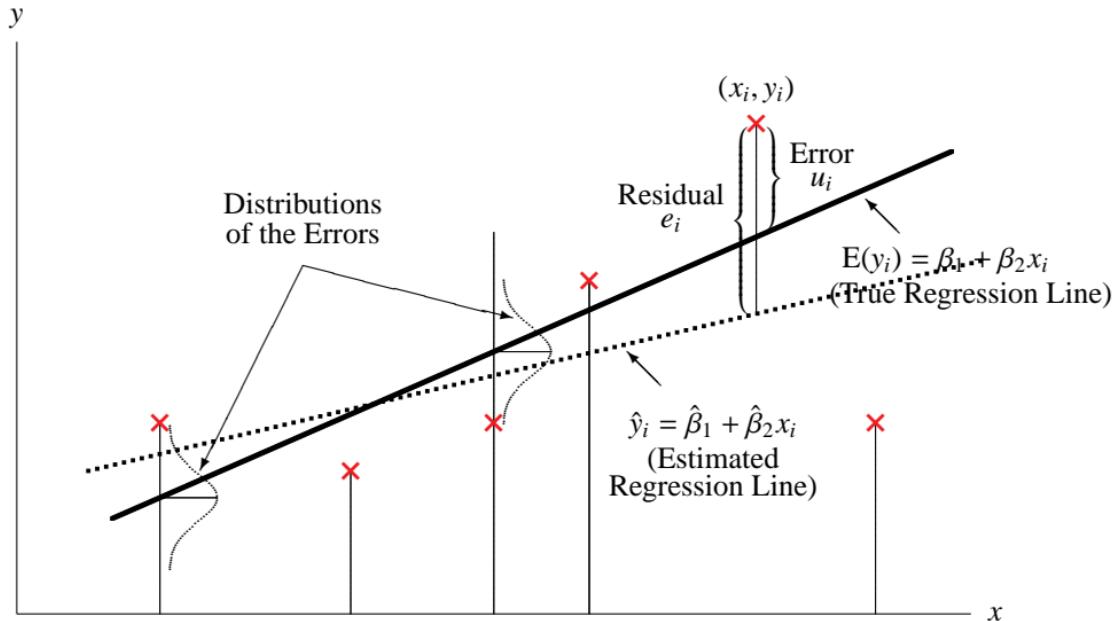
(7) indicates the estimated regression line, which is different from (5).

Moreover, using  $\hat{y}_i$  we can rewrite (6) as  $y_i = \hat{y}_i + e_i$ .

(5) and (7) are displayed in Figure 1.

Consider the case of  $n = 6$  for simplicity.  $\times$  indicates the observed data series.

**Figure 1. True and Estimated Regression Lines (回帰直線)**



The true regression line (5) is represented by the solid line, while the estimated regression line (7) is drawn with the dotted line.

Based on the observed data,  $\beta_1$  and  $\beta_2$  are estimated as:  $\hat{\beta}_1$  and  $\hat{\beta}_2$ .

In the next section, we consider how to obtain the estimates of  $\beta_1$  and  $\beta_2$ , i.e.,  $\hat{\beta}_1$  and  $\hat{\beta}_2$ .

## 2.2 Ordinary Least Squares Estimation

Suppose that  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  are available.

For the regression model (4), we consider estimating  $\beta_1$  and  $\beta_2$ .

Replacing  $\beta_1$  and  $\beta_2$  by their estimates  $\hat{\beta}_1$  and  $\hat{\beta}_2$ , remember that the residual  $e_i$  is given by:

$$e_i = y_i - \hat{y}_i = y_i - \hat{\beta}_1 - \hat{\beta}_2 x_i.$$

The sum of squared residuals is defined as follows:

$$S(\hat{\beta}_1, \hat{\beta}_2) = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{\beta}_1 - \hat{\beta}_2 x_i)^2.$$

It might be plausible to choose the  $\hat{\beta}_1$  and  $\hat{\beta}_2$  which minimize the sum of squared residuals, i.e.,  $S(\hat{\beta}_1, \hat{\beta}_2)$ .

This method is called the **ordinary least squares estimation** (最小二乘法, **OLS**).

To minimize  $S(\hat{\beta}_1, \hat{\beta}_2)$  with respect to  $\hat{\beta}_1$  and  $\hat{\beta}_2$ , we set the partial derivatives equal to zero:

$$\frac{\partial S(\hat{\beta}_1, \hat{\beta}_2)}{\partial \hat{\beta}_1} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_1 - \hat{\beta}_2 x_i) = 0,$$

$$\frac{\partial S(\hat{\beta}_1, \hat{\beta}_2)}{\partial \hat{\beta}_2} = -2 \sum_{i=1}^n x_i(y_i - \hat{\beta}_1 - \hat{\beta}_2 x_i) = 0.$$

The second order condition for minimization is:

$$\begin{pmatrix} \frac{\partial^2 S(\hat{\beta}_1, \hat{\beta}_2)}{\partial \hat{\beta}_1^2} & \frac{\partial^2 S(\hat{\beta}_1, \hat{\beta}_2)}{\partial \hat{\beta}_1 \partial \hat{\beta}_2} \\ \frac{\partial^2 S(\hat{\beta}_1, \hat{\beta}_2)}{\partial \hat{\beta}_2 \partial \hat{\beta}_1} & \frac{\partial^2 S(\hat{\beta}_1, \hat{\beta}_2)}{\partial \hat{\beta}_2^2} \end{pmatrix} = \begin{pmatrix} 2n & 2 \sum_{i=1}^n x_i \\ 2 \sum_{i=1}^n x_i & 2 \sum_{i=1}^n x_i^2 \end{pmatrix}$$

should be a positive definite matrix.

The diagonal elements  $2n$  and  $2 \sum_{i=1}^n x_i^2$  are positive.

The determinant:

$$\begin{vmatrix} 2n & 2 \sum_{i=1}^n x_i \\ 2 \sum_{i=1}^n x_i & 2 \sum_{i=1}^n x_i^2 \end{vmatrix} = 4n \sum_{i=1}^n x_i^2 - 4 \left( \sum_{i=1}^n x_i \right)^2 = 4n \sum_{i=1}^n (x_i - \bar{x})^2$$

is positive.  $\implies$  The second-order condition is satisfied.

The first two equations yield the following two equations:

$$\bar{y} = \hat{\beta}_1 + \hat{\beta}_2 \bar{x}, \tag{8}$$

$$\sum_{i=1}^n x_i y_i = n \bar{x} \hat{\beta}_1 + \hat{\beta}_2 \sum_{i=1}^n x_i^2, \tag{9}$$

where  $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$  and  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ .

Multiplying (8) by  $n\bar{x}$  and subtracting (9), we can derive  $\hat{\beta}_2$  as follows:

$$\hat{\beta}_2 = \frac{\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}}{\sum_{i=1}^n x_i^2 - n\bar{x}^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}. \quad (10)$$

From (8),  $\hat{\beta}_1$  is directly obtained as follows:

$$\hat{\beta}_1 = \bar{y} - \hat{\beta}_2 \bar{x}. \quad (11)$$

When the observed values are taken for  $y_i$  and  $x_i$  for  $i = 1, 2, \dots, n$ , we say that  $\hat{\beta}_1$  and  $\hat{\beta}_2$  are called the **ordinary least squares estimates** (or simply the **least squares estimates**, 最小二乘推定值) of  $\beta_1$  and  $\beta_2$ .

When  $y_i$  for  $i = 1, 2, \dots, n$  are regarded as the random sample, we say that  $\hat{\beta}_1$  and  $\hat{\beta}_2$  are called the **ordinary least squares estimators** (or the **least squares estimators**, 最小二乘推定量) of  $\beta_1$  and  $\beta_2$ .