

$$= \frac{1}{n-k} \sum_{i=1}^n (Y_i - \widehat{\beta}_1 X_{1i} - \widehat{\beta}_2 X_{2i} - \cdots - \widehat{\beta}_k X_{ki})^2$$

として表される。

このとき、

$$E(\widehat{\beta}_j) = \beta_j,$$

$$\text{plim} \widehat{\beta}_j = \beta_j,$$

$$E(s^2) = \sigma^2,$$

$$\text{plim} s^2 = \sigma^2,$$

を証明することが出来る。(証明略)

分布について： $\widehat{\beta}_1, \widehat{\beta}_2, \dots, \widehat{\beta}_k$  の分散は以下のように表される。

$$V \begin{pmatrix} \widehat{\beta}_1 \\ \widehat{\beta}_2 \\ \vdots \\ \widehat{\beta}_k \end{pmatrix}$$

$$\begin{aligned}
&= \begin{pmatrix} V(\widehat{\beta}_1) & \text{Cov}(\widehat{\beta}_1, \widehat{\beta}_2) & \cdots & \text{Cov}(\widehat{\beta}_1, \widehat{\beta}_k) \\ \text{Cov}(\widehat{\beta}_2, \widehat{\beta}_1) & V(\widehat{\beta}_2) & \cdots & \text{Cov}(\widehat{\beta}_2, \widehat{\beta}_k) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(\widehat{\beta}_k, \widehat{\beta}_1) & \text{Cov}(\widehat{\beta}_k, \widehat{\beta}_2) & \cdots & V(\widehat{\beta}_k) \end{pmatrix} \\
&= \sigma^2 \begin{pmatrix} \sum X_{1i}^2 & \sum X_{1i}X_{2i} & \cdots & \sum X_{1i}X_{ki} \\ \sum X_{1i}X_{2i} & \sum X_{2i}^2 & \cdots & \sum X_{2i}X_{ki} \\ \vdots & \vdots & \ddots & \vdots \\ \sum X_{1i}X_{ki} & \sum X_{2i}X_{ki} & \cdots & \sum X_{ki}^2 \end{pmatrix}^{-1}
\end{aligned}$$

$\widehat{\beta}_j$  の分散 (すなわち, 上の逆行列の  $j$  番目の対角要素) を,

$$V(\widehat{\beta}_j) = \sigma_{\widehat{\beta}_j}^2,$$

として, その推定量を  $s_{\widehat{\beta}_j}^2$  とする。

このとき,

$$\widehat{\beta}_j \sim N(\beta_j, \sigma_{\widehat{\beta}_j}^2),$$

となり, 標準化すると,

$$\frac{\widehat{\beta}_j - \beta_j}{\sigma_{\widehat{\beta}_j}} \sim N(0, 1),$$

が得られる。さらに,

$$\frac{(n-k)s^2}{\sigma^2} \sim \chi^2(n-k),$$

となり (証明略), しかも,  $\widehat{\beta}_j$  と  $s^2$  の独立性から (証明略),

$$\frac{\widehat{\beta}_j - \beta_j}{s_{\widehat{\beta}_j}} \sim t(n-k)$$

となる。

よって, 通常の区間推定や仮説検定を行うことが出来る。

決定係数について: また, 決定係数  $R^2$  についても同様に表される。

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

ただし,  $\widehat{Y}_i = \widehat{\beta}_1 X_{1i} + \widehat{\beta}_2 X_{2i} + \cdots + \widehat{\beta}_k X_{ki}$ ,  $Y_i = \widehat{Y}_i + \widehat{u}_i$  である。

$R^2$  は、説明変数を増やすことによって、必ず大きくなる。なぜなら、説明変数が増えることによって、 $\sum_{i=1}^n \widehat{u}_i^2$  が必ず減少するからである。

$R^2$  を基準にすると、被説明変数にとって意味のない変数でも、説明変数が多いほど、よりよいモデルということになる。この点を改善するために、自由度修正済み決定係数  $\bar{R}^2$  を用いる。

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

$\sum_{i=1}^n \widehat{u}_i^2 / (n - k)$  は  $u_i$  の分散  $\sigma^2$  の不偏推定量であり、 $\sum_{i=1}^n (Y_i - \bar{Y})^2 / (n - 1)$  は  $Y_i$  の分散の不偏推定量である。

$R^2$  と  $\bar{R}^2$  との関係は、

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

となる。さらに、

$$\frac{1 - \bar{R}^2}{1 - R^2} = \frac{n - 1}{n - k} \geq 1,$$

という関係から、 $\bar{R}^2 \leq R^2$  という結果を得る。(  $k = 1$  のときのみ、等号が成り立つ。 )

数値例： 今までと同じ数値例で、 $\bar{R}^2$  を計算する。

$i$	$Y_i$	$X_i$	$X_i Y_i$	$X_i^2$	$\widehat{Y}_i$	$\widehat{u}_i$
1	6	10	60	100	6.8	-0.8
2	9	12	108	144	8.1	0.9
3	10	14	140	196	9.4	0.6
4	10	16	160	256	10.7	-0.7
合計	$\sum Y_i$ 35	$\sum X_i$ 52	$\sum X_i Y_i$ 468	$\sum X_i^2$ 696	$\sum \widehat{Y}_i$ 35	$\sum \widehat{u}_i$ 0
平均	$\bar{Y}$ 8.75	$\bar{X}$ 13				

まず  $R^2$  は、

$$\begin{aligned}
 R^2 &= 1 - \frac{\sum \widehat{u}_i^2}{\sum Y_i^2 - n\bar{Y}^2} \\
 &= 1 - \frac{(-0.8)^2 + 0.9^2 + 0.6^2 + (-0.7)^2}{35 - 4 \times 8.75^2} \\
 &= 1 - \frac{2.30}{10.75} \\
 &= 0.786
 \end{aligned}$$

となり、 $\bar{R}^2$  は、

$$\begin{aligned}\bar{R}^2 &= 1 - \frac{\sum \widehat{u}_i^2 / (n - k)}{(\sum Y_i^2 - n\bar{Y}^2) / (n - 1)} \\ &= 1 - \frac{2.30 / (4 - 2)}{10.75 / (4 - 1)} \\ &= 0.679\end{aligned}$$

となる。

**注意：**  $R^2$  や  $\bar{R}^2$  を比較する場合、被説明変数が同じことが必要である。被説明変数が異なる場合 (例えば、被説明変数を上昇率とするかそのままの値を用いるかによって、被説明変数が異なる)、誤差項  $u_i$  の標準誤差で比較すべきである (標準誤差の小さいモデルを採用する)。

⇒ 関数型の選択

## 5.3 ダミー変数について

### 5.3.1 異常値

データに異常値が含まれている場合、経済構造がある時期から変化した場合、ダミー変数を使う。

ダミー変数とは、0と1から成る変数のことである。

例えば、データが20期間あるとして、9期目のデータが、回帰直線から離れている場合(異常値の場合)を考える。

$$D_i = \begin{cases} 0, & i \neq 9 \text{ のとき} \\ 1, & i = 9 \text{ のとき} \end{cases}$$

という変数を作り、

$$Y_i = \alpha + \delta D_i + \beta X_i + u_i$$

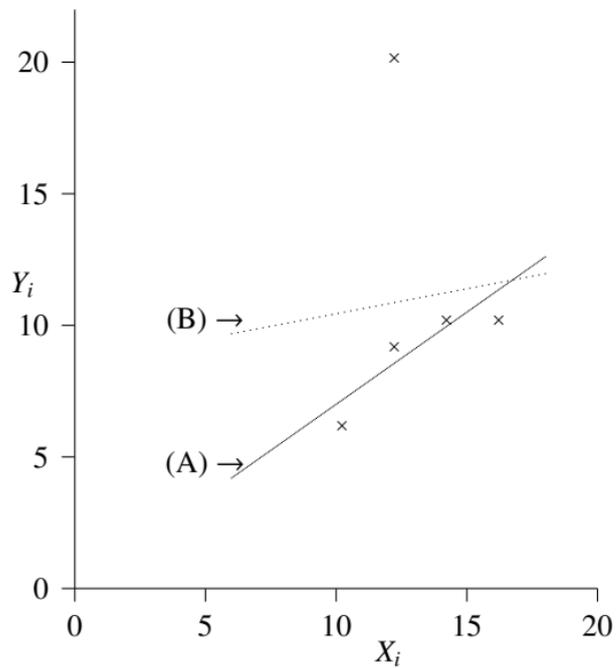
を推定する。 $\delta$ の推定値 $\hat{\delta}$ の有意性を調べることによって、異常値かどうかの検定ができる。

数値例： 今までと同様に、以下の数値例をとりあげる。

$i$	$Y_i$	$X_i$	$D_i$
1	6	10	0
2	9	12	0
3	10	14	0
4	10	16	0
5	20	12	1

第 5 期目が異常値である。

图 3：異常値



(A) は  $i = 1, 2, 3, 4$  のデータを使って，推定した回帰直線である。(B) は  $i = 1, 2, 3, 4, 5$  のデータを使って，推定した回帰直線である。(A), (B) の推定結果は以下のとおりである。

$$(A): Y_i = \frac{0.3}{(0.095)} + \frac{0.65}{(2.708)} X_i,$$
$$R^2 = 0.786, \quad s^2 = 1.072^2,$$

$$(B): Y_i = \frac{8.54}{(0.49)} + \frac{0.19}{(0.14)} X_i,$$
$$R^2 = 0.007, \quad s^2 = 6.09^2,$$

ただし，係数の推定値の下の括弧内は  $t$  値を表すものとする。

このように，結果が大幅に変わる。第5期は異常値なので，ダミー変数を用いて，

$$Y_i = \alpha + \beta X_i + \gamma D_i + u_i,$$

として推定を行う。 $i = 1, 2, 3, 4$  について， $D_i = 0$  とし， $i = 5$  について， $D_i = 1$  とする変数である。この回帰式の意味は，

$$Y_i = \begin{cases} \alpha + \beta X_i + u_i, & i = 1, 2, 3, 4 \text{ のとき,} \\ (\alpha + \gamma) + \beta X_i + u_i, & i = 5 \text{ のとき,} \end{cases}$$

となる。推定結果は、

$$Y_i = \frac{0.3}{(0.095)} + \frac{0.65}{(2.708)} X_i + \frac{11.9}{(9.73)} D_i,$$
$$R^2 = 0.979, \quad s^2 = 1.072^2,$$

となる。この場合、 $\widehat{Y}_5 = Y_5$ ，すなわち、 $\widehat{u}_5 = 0$  となることに注意。

### 5.3.2 構造変化

次に、9期目以前と以降とで、経済構造が変化している場合を考える。

$$D_i = \begin{cases} 0, & i = 1, 2, \dots, 8 \text{ のとき} \\ 1, & i = 9, 10, \dots, 20 \text{ のとき} \end{cases}$$

という変数を作り、

$$Y_i = \alpha + \delta D_i + \beta X_i + u_i$$

を推定する (定数項だけが変化したと考えた場合)。または、

$$Y_i = \alpha + \delta D_i + \beta X_i + \gamma D_i X_i + u_i$$

を推定する (定数項も係数も変化)。

$\delta$  や  $\gamma$  の推定値の有意性を調べることによって、構造変化の検定を行うことができる。

上の例でデータを示すと、

$i$	$Y_i$	$X_i$	$D_i$	$D_i X_i$
1	$Y_1$	$X_1$	0	0
2	$Y_2$	$X_2$	0	0
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
8	$Y_8$	$X_8$	0	0
9	$Y_9$	$X_9$	1	$X_9$
10	$Y_{10}$	$X_{10}$	1	$X_{10}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
20	$Y_{20}$	$X_{20}$	1	$X_{20}$

となる。