

5.4.1 推定量の性質

$\beta_1, \beta_2, \dots, \beta_k$ の最小二乗推定量は $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$ とする。

誤差項 (または, 攪乱項) u_i の分散 σ^2 の推定量 s^2 は,

$$s^2 = \frac{1}{n-k} \sum_{i=1}^n \hat{u}_i^2 = \frac{1}{n-k} \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i} - \dots - \hat{\beta}_k X_{ki})^2$$

として表される。

このとき，

$$E(\hat{\beta}_j) = \beta_j \quad (\text{不偏推定量})$$

$$n \rightarrow \infty \text{ のとき, } \hat{\beta}_j \rightarrow \beta_j \quad (\text{一致推定量})$$

$$(*) \text{ plim } \hat{\beta}_j = \beta_j \text{ と書く。}$$

plim (「ピーリム」と読む) = 意味は「probability limit (確率極限)」

$$E(s^2) = \sigma^2 \quad (\text{不偏推定量})$$

$$n \rightarrow \infty \text{ のとき, } s^2 \rightarrow \sigma^2 \quad (\text{一致推定量})$$

$$(*) \text{ plim } s^2 = \sigma^2$$

を証明することが出来る。(証明略)

(*注) ベクトルの確率変数の期待値・分散について： $k \times 1$ ベクトルの確率変数 $X = \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_k \end{pmatrix}$

の平均・分散を考える。

$i = 1, 2, \dots, k$ について, $\mathbf{E}(X_i) = \mu_i$ とする。

$$\mathbf{E}(X) = \mathbf{E} \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_k \end{pmatrix} = \begin{pmatrix} \mathbf{E}(X_1) \\ \mathbf{E}(X_2) \\ \vdots \\ \mathbf{E}(X_k) \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_k \end{pmatrix} = \boldsymbol{\mu}$$

$$\begin{aligned}
\mathbf{V}(X) &= \mathbf{E}\left((X - \mu)(X - \mu)'\right) = \mathbf{E}\left(\begin{array}{c} X_1 - \mu_1 \\ X_2 - \mu_2 \\ \vdots \\ X_k - \mu_k \end{array} \begin{array}{cccc} (X_1 - \mu_1) & X_2 - \mu_2 & \cdots & X_k - \mu_k \end{array}\right) \\
&= \mathbf{E}\left(\begin{array}{cccc} (X_1 - \mu_1)^2 & (X_1 - \mu_1)(X_2 - \mu_2) & \cdots & (X_1 - \mu_1)(X_k - \mu_k) \\ (X_2 - \mu_2)(X_1 - \mu_1) & (X_2 - \mu_2)^2 & \cdots & (X_2 - \mu_2)(X_k - \mu_k) \\ \vdots & \vdots & \ddots & \vdots \\ (X_k - \mu_k)(X_1 - \mu_1) & (X_k - \mu_k)(X_2 - \mu_2) & \cdots & (X_k - \mu_k)^2 \end{array}\right) \\
&= \begin{pmatrix} \mathbf{E}\left((X_1 - \mu_1)^2\right) & \mathbf{E}\left((X_1 - \mu_1)(X_2 - \mu_2)\right) & \cdots & \mathbf{E}\left((X_1 - \mu_1)(X_k - \mu_k)\right) \\ \mathbf{E}\left((X_2 - \mu_2)(X_1 - \mu_1)\right) & \mathbf{E}\left((X_2 - \mu_2)^2\right) & \cdots & \mathbf{E}\left((X_2 - \mu_2)(X_k - \mu_k)\right) \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{E}\left((X_k - \mu_k)(X_1 - \mu_1)\right) & \mathbf{E}\left((X_k - \mu_k)(X_2 - \mu_2)\right) & \cdots & \mathbf{E}\left((X_k - \mu_k)^2\right) \end{pmatrix}
\end{aligned}$$

$$= \begin{pmatrix} \mathbf{V}(X_1) & \mathbf{Cov}(X_1, X_2) & \cdots & \mathbf{Cov}(X_1, X_k) \\ \mathbf{Cov}(X_2, X_1) & \mathbf{V}(X_2) & \cdots & \mathbf{Cov}(X_2, X_k) \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{Cov}(X_k, X_1) & \mathbf{Cov}(X_k, X_2) & \cdots & \mathbf{V}(X_k) \end{pmatrix} = \Sigma$$

このように $\mathbf{E}(X) = \mu$, $\mathbf{V}(X) = \Sigma$ の次元はそれぞれ $k \times 1$ ベクトル , $k \times k$ 行列となる。

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

$$\mathbf{V} \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \vdots \\ \hat{\beta}_k \end{pmatrix} = \begin{pmatrix} \mathbf{V}(\hat{\beta}_1) & \mathbf{Cov}(\hat{\beta}_1, \hat{\beta}_2) & \cdots & \mathbf{Cov}(\hat{\beta}_1, \hat{\beta}_k) \\ \mathbf{Cov}(\hat{\beta}_2, \hat{\beta}_1) & \mathbf{V}(\hat{\beta}_2) & \cdots & \mathbf{Cov}(\hat{\beta}_2, \hat{\beta}_k) \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{Cov}(\hat{\beta}_k, \hat{\beta}_1) & \mathbf{Cov}(\hat{\beta}_k, \hat{\beta}_2) & \cdots & \mathbf{V}(\hat{\beta}_k) \end{pmatrix}$$

$$= \sigma^2 \begin{pmatrix} \sum X_{1i}^2 & \sum X_{1i}X_{2i} & \cdots & \sum X_{1i}X_{ki} \\ \sum X_{1i}X_{2i} & \sum X_{2i}^2 & \cdots & \sum X_{2i}X_{ki} \\ \vdots & \vdots & \ddots & \vdots \\ \sum X_{1i}X_{ki} & \sum X_{2i}X_{ki} & \cdots & \sum X_{ki}^2 \end{pmatrix}^{-1} = \sigma^2 A$$

最後の等号の右辺の逆行列 A の i 行 j 列目の要素を a_{ij} としたとき， $\hat{\beta}_j$ の分散は，

$$\mathbf{V}(\hat{\beta}_j) = \sigma^2 a_{jj}$$

となる（証明略）。このとき，

$$\hat{\beta}_j \sim N(\beta_j, \sigma^2 a_{jj})$$

となり，標準化すると，

$$\frac{\hat{\beta}_j - \beta_j}{\sigma \sqrt{a_{jj}}} \sim N(0, 1)$$

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， $\hat{\beta}_j$ と s^2 の独立である（証明略），

さらに，

(* 復習) t 分布について (再掲):

$Z \sim N(0, 1)$, $U \sim \chi^2(k)$, Z と U は独立のとき ,

$$T = \frac{Z}{\sqrt{U/k}} \sim t(k) \text{ となる。}$$

を利用すると ,

$$\frac{\frac{\hat{\beta}_j - \beta_j}{\sigma \sqrt{a_{jj}}}}{\sqrt{\frac{(n-k)s^2}{\sigma^2} / (n-k)}} = \frac{\hat{\beta}_j - \beta_j}{s \sqrt{a_{jj}}} \sim t(n-k)$$

が得られる。

このように， $t(n-k)$ を用いることによって，通常の区間推定や仮説検定を行うことが出来る。

$s\sqrt{a_{jj}}$ は $\hat{\beta}_j$ の標準誤差である。

すなわち， $s\sqrt{a_{jj}}$ は，単回帰の場合の $s_{\hat{\alpha}}$ ， $s_{\hat{\beta}}$ に対応する。

$\hat{\beta}_j$ の区間推定： $\frac{\hat{\beta}_j - \beta_j}{s\sqrt{a_{jj}}} \sim t(n-k)$ なので，

$$\mathbf{Prob}\left(-t_{\alpha/2}(n-k) < \frac{\hat{\beta}_j - \beta_j}{s\sqrt{a_{jj}}} < t_{\alpha/2}(n-k)\right) = 1 - \alpha$$

ただし， $t_{\alpha/2}(n-k)$ は自由度 $n-k$ の t 分布の $100 \times \frac{\alpha}{2}$ % 点の値とする。

β_j について解くと,

$$\mathbf{Prob}\left(\hat{\beta}_j - t_{\alpha/2}(n-k) \times s \sqrt{a_{jj}} < \beta_j < \hat{\beta}_j + t_{\alpha/2}(n-k) \times s \sqrt{a_{jj}}\right) = 1 - \alpha$$

を得る。

$\hat{\beta}_j$, s を推定値で置き換えて, 信頼係数 $1 - \alpha$ の β_j の区間推定は,

$$\left(\hat{\beta}_j - t_{\alpha/2}(n-k) \times s \sqrt{a_{jj}}, \hat{\beta}_j + t_{\alpha/2}(n-k) \times s \sqrt{a_{jj}}\right)$$

となる。

$\hat{\beta}_j$ の仮説検定： 帰無仮説 $H_0: \beta_j = \beta_{*j}$ を検定することを考える (β_{*j} は分析者が設定する値とする)。

$$\frac{\hat{\beta}_j - \beta_j}{s \sqrt{a_{jj}}} \sim t(n-k) \text{ なので, 帰無仮説が正しいもとで (すなわち, } \beta_j = \beta_{*j} \text{),}$$

$$\frac{\hat{\beta}_j - \beta_{*j}}{s \sqrt{a_{jj}}} \sim t(n-k)$$

となる。

$\hat{\beta}_j, s$ を推定値で置き換えて,

$$\left| \frac{\hat{\beta}_j - \beta_{*j}}{s \sqrt{a_{jj}}} \right| > t_{\alpha/2}(n-k)$$

のとき, 有意水準 $100 \times \alpha\%$ で帰無仮説 $H_0: \beta_j = \beta_{*j}$ を棄却する (帰無仮説が起こる確率は

100 × α% 以下ということになるので)

(注) u_1, u_2, \dots, u_n は互いに独立で, $u_i \sim N(0, \sigma^2)$ のとき,

$$\sum_{i=1}^n \left(\frac{u_i}{\sigma}\right)^2 \sim \chi^2(n)$$

となる。 u_i をその推定量 \hat{u}_i で置き換えると,

$$\sum_{i=1}^n \left(\frac{\hat{u}_i}{\sigma}\right)^2 = \frac{(n-k)s^2}{\sigma^2} \sim \chi^2(n-k)$$

ただし, s^2 は σ^2 の推定量で, $s^2 = \frac{1}{n-k} \sum_{i=1}^n \hat{u}_i^2 = \frac{1}{n-k} \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i} - \dots - \hat{\beta}_k X_{ki})^2$ である。 \hat{u}_i を得るためには, $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$ (k 個のパラメータ推定量) を求めなければならない。 $n-k$ (= データ数 n - パラメータ数 k) を自由度と呼ばれる。

(注) s^2 が σ^2 の不偏推定量，一致推定量であることは，

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

を利用すれば簡単に証明できる。

(* 復習) カイ二乗分布の平均・分散について (再掲):

$U \sim \chi^2(k)$ のとき， $\mathbf{E}(U) = k$ ， $\mathbf{V}(U) = 2k$ となる。

この重回帰の場合は，

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

なので ,

$$\mathbf{E}\left(\frac{(n-k)s^2}{\sigma^2}\right) = n-k, \quad \mathbf{V}\left(\frac{(n-k)s^2}{\sigma^2}\right) = 2(n-k)$$

すなわち ,

$$\mathbf{E}\left(\frac{(n-k)s^2}{\sigma^2}\right) = \frac{n-k}{\sigma^2}\mathbf{E}(s^2) = n-k, \quad \mathbf{V}\left(\frac{(n-k)s^2}{\sigma^2}\right) = \left(\frac{n-k}{\sigma^2}\right)^2\mathbf{V}(s^2) = 2(n-k)$$

から

$$\mathbf{E}(s^2) = (n-k) \times \frac{\sigma^2}{n-k} = \sigma^2, \quad \mathbf{V}(s^2) = 2(n-k) \times \left(\frac{\sigma^2}{n-k}\right)^2 = \frac{2\sigma^4}{n-k}$$

となる。

$E(s^2) = \sigma^2$ で、かつ、 $n \rightarrow \infty$ のとき $V(s^2) \rightarrow 0$ となるので、 s^2 は不偏推定量かつ一致推定量である。

第6章 ダミー変数，関数形，その他

6.1 ダミー変数

6.1.1 異常値ダミー

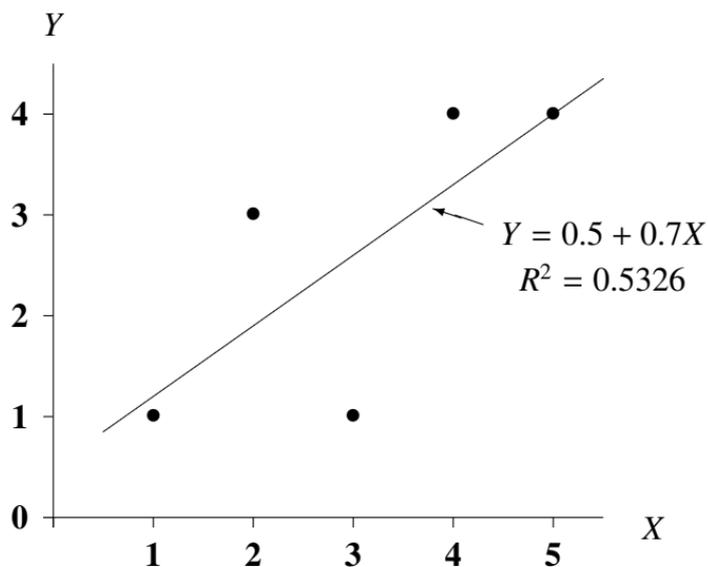
ダミー変数とは、0 と 1 から成る変数のことである。データに異常値が含まれている場合、ダミー変数を使う。

例えば、今までの数値例を使って説明する。

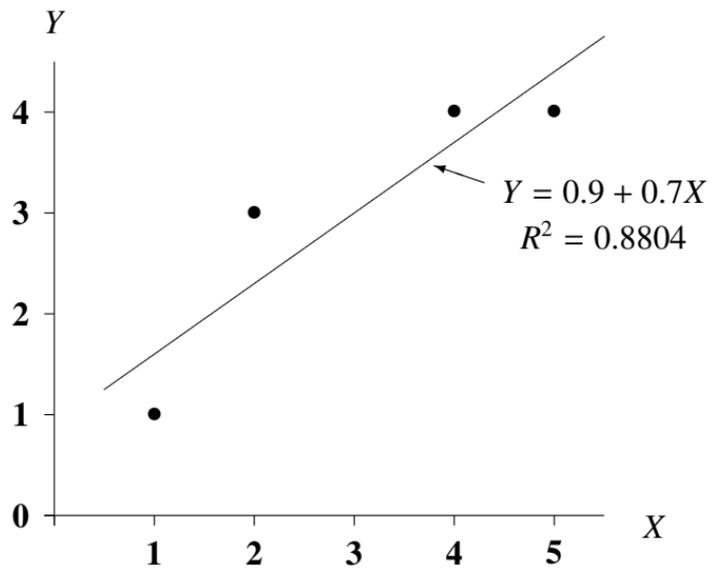
i	X_i	Y_i	X_i^2	$X_i Y_i$	\hat{Y}_i	\hat{u}_i
1	5	4	25	20	4.0	0.0
2	1	1	1	1	1.2	-0.2
3	3	1	9	3	2.6	-1.6
4	2	3	4	6	1.9	1.1
5	4	4	16	16	3.3	0.7
合計	ΣX_i	ΣY_i	ΣX_i^2	$\Sigma X_i Y_i$	$\Sigma \hat{Y}_i$	$\Sigma \hat{u}_i$
	15	13	55	46	13	0.0
平均	\bar{X}	\bar{Y}				
	3	2.6				

$i = 3$ のデータ $(X_3, Y_3) = (3, 1)$ について，直線 $Y = 0.5 + 0.7X$ との縦軸方向の垂直距離，す

なわち，残差 $\hat{u}_3 = -1.6$ が絶対値で最も大きくなっている。



$i = 3$ のデータを除いて， $n = 4$ 個のデータを用いて最小二乗法で推定してみる。



今まで見てきた通り , $i = 1, 2, 3, 4, 5$ の全部のデータを使って ,

$$Y_i = \mathbf{0.5} + \mathbf{0.7} X_i,$$

(0.398) (1.849)

$$R^2 = 0.5326, \quad \bar{R}^2 = 0.3768, \quad s^2 = 1.197^2$$

と推定される。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。

一方 , $i = 3$ を除いて , $i = 1, 2, 4, 5$ の 4 組のデータを使うと ,

$$Y_i = \mathbf{0.9} + \mathbf{0.7} X_i,$$

(1.132) (2.985)

$$R^2 = 0.8804, \quad \bar{R}^2 = 0.7609, \quad s^2 = 0.742^2$$

となる。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、定数項の結果変わる（傾きの値が変化しなかったのは、単なる偶然）。

3番目のデータが、回帰直線から離れている（すなわち、異常値）ものとして考えて、

$$D_i = \begin{cases} 0, & i = 1, 2, 4, 5 \text{ のとき} \\ 1, & i = 3 \text{ のとき} \end{cases}$$

というダミー変数を作り、

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

を推定する。 γ の推定値 $\hat{\gamma}$ の有意性を調べることによって、3番目のデータが異常値かどうかを検定することができる。

この回帰式の意味は，

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

となる。3番目のデータのときに定数項（切片）が γ だけシフトする。

推定結果は，

$$Y_i = \mathbf{0.9} + \mathbf{0.7} X_i - \mathbf{2.0} D_i,$$

(1.132) (2.985) (2.412)

$$R^2 = 0.8804, \quad \bar{R}^2 = 0.7609, \quad s^2 = 0.742^2$$

となる。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。

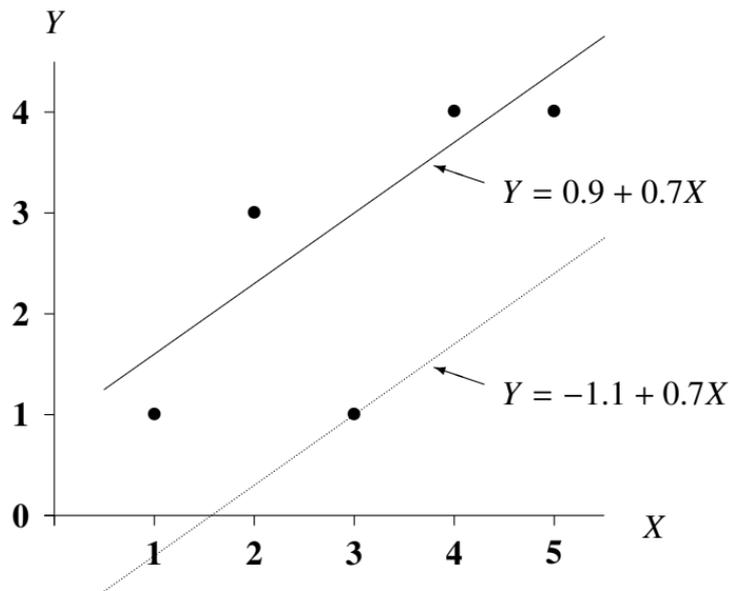
推定結果からみると, D_i の係数推定値の t 値は **2.412** で, この場合, 自由度 $n-k = 5-3 = 2$ の t 分布の **2.5 %** 点 $t_{0.025}(2) = 4.3027$ と比較することになる。

$2.412 < 4.3027$ なので, 有意水準 **5 %** で $H_0: \gamma = 0$ を棄却できない。

すなわち, $i = 3$ のデータは異常値とは認められない。

この場合, $\hat{Y}_3 = Y_3$, すなわち, $\hat{u}_3 = 0$ となることに注意。

グラフに描くと, $i = 3$ のデータを通る平行移動した直線が追加される。



6.1.2 構造変化ダミー

経済構造がある時期から変化した場合もダミー変数を使って、処理することができる。

この場合、添え字 i は時間を表す。

$n = 20$ として、例えば、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。

$$D_i = \begin{cases} 0, & i = 1, 2, \dots, 9 \text{ のとき} \\ 1, & i = 10, 11, \dots, 20 \text{ のとき} \end{cases}$$

という変数を作り、

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

$$= \begin{cases} \alpha + \beta X_i + u_i, & i = 1, 2, \dots, 9 \text{ のとき} \\ (\alpha + \delta) + \beta X_i + u_i, & i = 10, 11, \dots, 20 \text{ のとき} \end{cases}$$

を推定する（定数項だけが変化したと考えた場合）。または，

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

$$= \begin{cases} \alpha + \beta X_i + u_i, & i = 1, 2, \dots, 9 \text{ のとき} \\ (\alpha + \delta) + (\beta + \gamma) X_i + u_i, & i = 10, 11, \dots, 20 \text{ のとき} \end{cases}$$

を推定する（定数項も係数も変化）。

δ や γ 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
9	Y_9	X_9	0	0
10	Y_{10}	X_{10}	1	X_{10}
11	Y_{11}	X_{11}	1	X_{11}
\vdots	\vdots	\vdots	\vdots	\vdots
20	Y_{20}	X_{20}	1	X_{20}

となる。

数值例：

i	X_i	Y_i	D_i	$D_i X_i$
1	1	1	0	0
2	1	2	0	0
3	1	0	0	0
4	2	1	0	0
5	2	2	0	0
6	2	3	0	0
7	3	2	0	0
8	3	3	0	0
9	3	4	0	0
10	4	4	1	4
11	4	5	1	4
12	4	6	1	4
13	5	5	1	5
14	5	6	1	5
15	5	7	1	5
16	6	5	1	6
17	6	6	1	6
18	6	7	1	6
19	7	6	1	7
20	7	7	1	7

20 組全部のデータを用いて推定すると，推定結果は，ダミー変数を用いなければ，

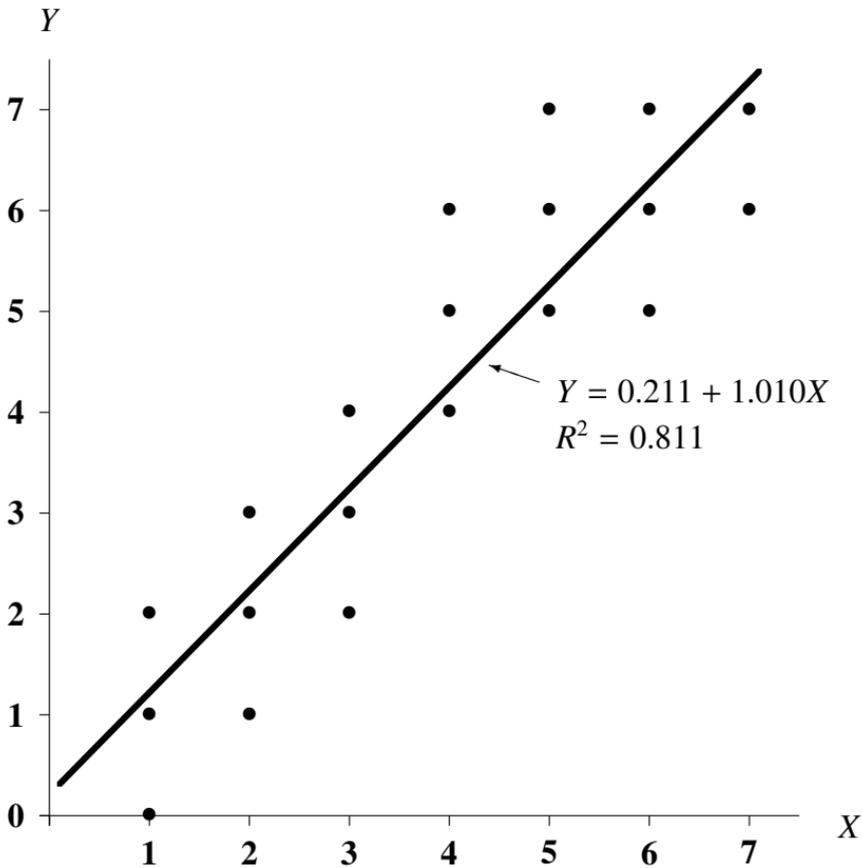
$$Y_i = \mathbf{0.211} + \mathbf{1.010} X_i$$

(0.427) (8.784)

$$R^2 = 0.8108, \quad \bar{R}^2 = 0.8003, \quad s^2 = 0.9928^2$$

となる（自由度は $n - k = 20 - 2 = 18$ ）。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。

散布図と回帰直線は次ページであるが，一見何の問題もないように見える。

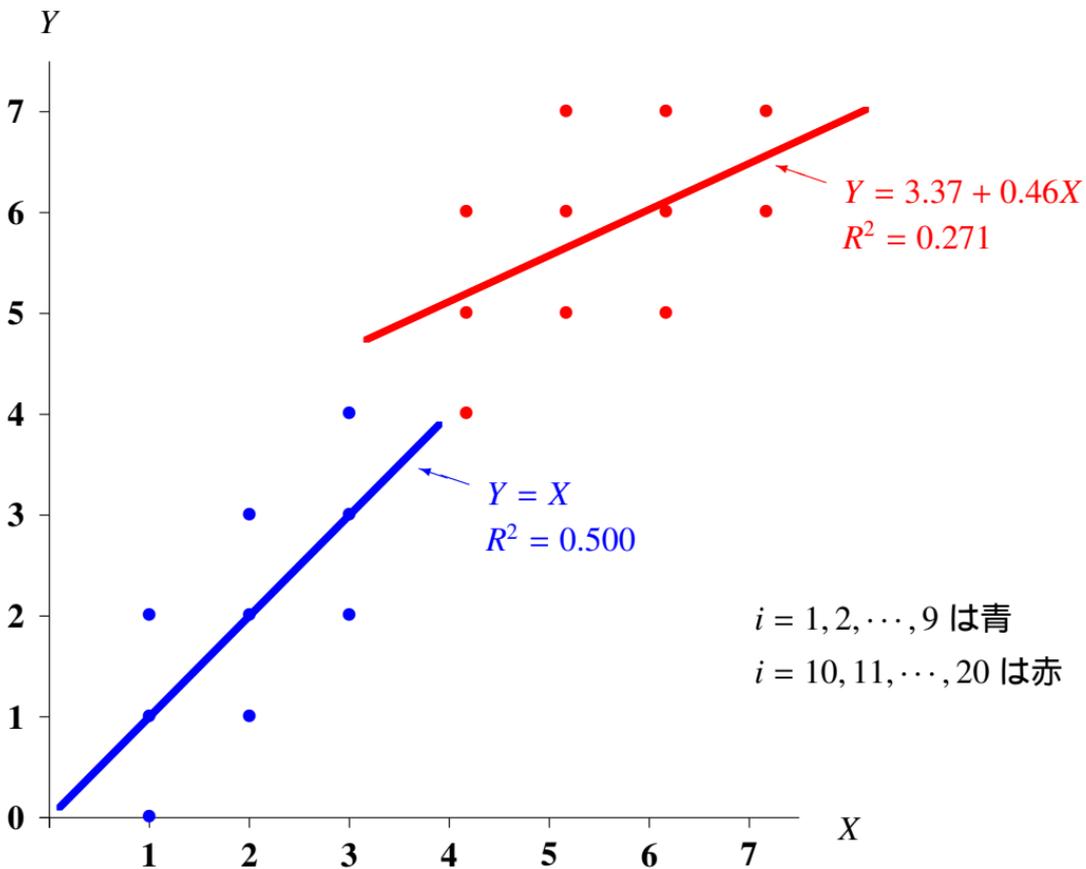


数値例の表によると，左下の方のデータは推定期間の前半のデータ ($i = 1, 2, \dots, 9$)，右上のデータは後半のデータ ($i = 10, 11, \dots, 20$) と想定している。

2つの部分の回帰式は同じになるかどうか？

2つの期に分けて，別々に推定する。 \implies 次ページ

この場合，前半部分の自由度は $n - k = 9 - 2 = 7$ ，後半部分は $n - k = 11 - 2 = 9$ となる。



推定結果は，ダミー変数を用いなければ，

$$Y_i = \mathbf{0.211} + \mathbf{1.010} X_i$$

$(\mathbf{0.427}) \quad (\mathbf{8.784})$

$$R^2 = 0.8108, \quad \bar{R}^2 = 0.8003, \quad s^2 = 0.9928^2$$

となる（自由度は $n - k = 20 - 2 = 18$ ）。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。

また，ダミー変数を用いて，切片と傾きの両方が変化したと考えて推定すると，

$$Y_i = \mathbf{0.000} + \mathbf{1.000} X_i + \mathbf{3.370} D_i - \mathbf{0.543} D_i X_i,$$

$(\mathbf{0.000}) \quad (\mathbf{2.715}) \quad (\mathbf{2.101}) \quad (\mathbf{1.214})$

$$R^2 = 0.8612, \quad \bar{R}^2 = 0.8351, \quad s^2 = 0.9021^2$$

となる（自由度は $n - k = 20 - 4 = 16$ ）。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。

教科書『計量経済学』の附表 (p.352) から， $t_{0.025}(16) = 2.120$ である。

$2.101 < 2.120$ ， $1.214 < 2.120$ なので， $H_0 : \delta = 0$ ， $H_0 : \gamma = 0$ の帰無仮説を共に有意水準 5% で棄却できない。

したがって，切片・傾き共に構造変化があったとは言えない。