

最小二乗推定量の統計的性質

前提：

データの分布の仮定

(Data Generating Process: DGP)

$$y_i = \alpha + \beta x_i + \varepsilon_i$$

ε_i : 攪乱項 , 誤差項

注意：残差項： $\hat{u}_i = y_i - \hat{\alpha} - \hat{\beta}x_i$ と区別すること

α, β は真の値を示す

回帰式： $y_i = \hat{\alpha} + \hat{\beta}x_i + \hat{u}_i$ と形が一致している

特定化の誤りなし

攪乱項の仮定

$$E[\varepsilon_i] = 0 \quad \text{平均 0}$$

$$V[\varepsilon_i] = \sigma^2 \quad \text{分散一定, かつ, 有限}$$

$\varepsilon_i, \varepsilon_j$ は独立

不偏性：推定値の期待値が真の値になる

$$E[\hat{\alpha}] = \alpha$$

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

(説明)

$$\begin{aligned}
\hat{\beta} &= \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \\
&= \frac{\sum_{i=1}^n \{\alpha + \beta x_i + \varepsilon_i - (\alpha + \beta \bar{x} + \bar{\varepsilon})\}(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \\
&= \frac{\sum_{i=1}^n \{\beta(x_i - \bar{x}) + (\varepsilon_i - \bar{\varepsilon})\}(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \\
&= \beta + \frac{\sum_{i=1}^n (\varepsilon_i - \bar{\varepsilon})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \\
&= \beta + \frac{\sum_{i=1}^n \varepsilon_i (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}
\end{aligned}$$

よって,

$$E[\hat{\beta}] = E[\beta] + E\left[\frac{\sum_{i=1}^n \varepsilon_i (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}\right]$$

$$= \beta + E\left[\sum_{i=1}^n \frac{(x_i - \bar{x})}{\sum_{j=1}^n (x_j - \bar{x})^2} \varepsilon_i\right]$$

$$= \beta + \sum_{i=1}^n \frac{(x_i - \bar{x})}{\sum_{j=1}^n (x_j - \bar{x})^2} E[\varepsilon_i]$$

$$= \beta$$

$$E[\hat{\alpha}] = [\bar{y} - \hat{\beta}\bar{x}] = E[\alpha + \beta\bar{x} + \bar{\varepsilon} - \hat{\beta}\bar{x}]$$

$$= E[\alpha + (\beta - \hat{\beta})\bar{x} + \bar{\varepsilon}]$$

$$= E[\alpha] + E[(\beta - \hat{\beta})\bar{x}] + E[\bar{\varepsilon}]$$

$$= \alpha + \bar{x}E[\beta - \hat{\beta}] + E\left[(1/n)\sum_{i=1}^n \varepsilon_i\right]$$

$$= \alpha + \bar{x}E[\beta - \hat{\beta}] + \frac{1}{n}\sum_{i=1}^n E[\varepsilon_i]$$

$$= \alpha$$

一致性

$V(\hat{\alpha}), V(\hat{\beta})$ がデータの数が増えるに従って小さくなる
(説明)

$$\hat{\beta} = \beta + \frac{\sum_{i=1}^n (x_i - \bar{x})}{\sum_{j=1}^n (x_j - \bar{x})^2} \varepsilon_i \text{ と}$$

$$V[X + c] = V[X] \text{ (} c \text{ は定数),}$$

$$V[c_1 X + c_2 Y] = c_1^2 V[X] + c_2^2 V[Y]$$

(X, Y が独立なら)

そして, ε_i が各 i について独立,

$$\begin{aligned} V[\hat{\beta}] &= V \left[\frac{\sum_{i=1}^n (x_i - \bar{x})}{\sum_{j=1}^n (x_j - \bar{x})^2} \varepsilon_i \right] = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{\left\{ \sum_{j=1}^n (x_j - \bar{x})^2 \right\}^2} V[\varepsilon_i] \\ &= \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{\left\{ \sum_{j=1}^n (x_j - \bar{x})^2 \right\}^2} \sigma^2 = \frac{\sigma^2}{\left\{ \sum_{j=1}^n (x_j - \bar{x})^2 \right\}^2} \sum_{i=1}^n (x_i - \bar{x})^2 \\ &= \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \end{aligned}$$

n が大きくなると, $\sum_{i=1}^n (x_i - \bar{x})^2 \rightarrow \infty$ の場合には,

$V(\hat{\beta})$ は n が大きくなると如何様にも小さくなる.

注意: $\sum_{i=1}^n (x_i - \bar{x})^2 \rightarrow \infty$ でない場合は一致性を持たない. 例としては, 講義資料, 問題

2 - 5, 類題 2 - 6 を参照


中心極限定理 ~ 正規分布での近似

正規分布

平均 μ , 分散 σ^2 の正規分布: $N(\mu, \sigma)$

確率密度関数:

$$f(t) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(t-\mu)^2}{2\sigma^2}\right]$$



中心極限 $\mu-2\sigma$ $\mu-\sigma$ μ $\mu+\sigma$ $\mu+2\sigma$

X_1, \dots, X_n が独立, $V[X_i] = \sigma^2$ のとき,

$$\frac{X_1 + \dots + X_n}{\sqrt{n}} \xrightarrow{D} N(0, \sigma^2)$$

(説明)

$$\begin{aligned} V\left[\frac{X_1 + \dots + X_n}{\sqrt{n}}\right] &= \sum_{i=1}^n \left(\frac{1}{\sqrt{n}}\right)^2 V[X_i] = \frac{1}{n} \sum_{i=1}^n V[X_i] \\ &= V[X_i] = \sigma^2 \end{aligned}$$

$\frac{1}{n} \sum_{i=1}^{\infty} a_i^2 = a$ ならば,

$$\frac{a_1 X_1 + \dots + a_n X_n}{\sqrt{n}} \xrightarrow{D} N(0, \sigma^2 a)$$

(説明)

$$\begin{aligned}
V\left[\frac{a_1 X_1 + \cdots + a_n X_n}{\sqrt{n}}\right] &= \sum_{i=1}^n \left(\frac{a_i}{\sqrt{n}}\right)^2 V[X_i] \\
&= \sum_{i=1}^n \frac{a_i^2}{n} V[X_i] \\
&= \frac{\sigma^2}{n} \sum_{i=1}^n a_i^2 \\
&= \sigma^2 \mathbf{a}
\end{aligned}$$

最小二乗推定量の近似分布

$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ が存在するとする .

$$\hat{\beta} - \beta = \sum_{i=1}^n \frac{(x_i - \bar{x})}{\sum_{j=1}^n (x_j - \bar{x})^2} \varepsilon_i$$

$$\sqrt{n}(\hat{\beta} - \beta) = \frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{(x_i - \bar{x})}{\sum_{j=1}^n (x_j - \bar{x})^2 / n} \varepsilon_i$$

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n \frac{(x_i - \bar{x})}{\sum_{j=1}^n (x_j - \bar{x})^2 / n} \varepsilon_i$$

$$\xrightarrow{D} N \left(0, \sigma^2 \lim_{n \rightarrow \infty} \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}{\left\{ \frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})^2 \right\}^2} \right)$$

$$= N \left(0, \sigma^2 \left\{ \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})^2 \right\}^{-1} \right)$$

から ,

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{D} N\left(0, \sigma^2 \left\{ \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right\}^{-1}\right)$$

近似による $\hat{\beta}$ の分布

$$\frac{\sqrt{n}(\hat{\beta} - \beta)}{\sigma \left\{ \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right\}^{-1/2}} = \frac{\hat{\beta} - \beta}{\sigma \left\{ \sum_{i=1}^n (x_i - \bar{x})^2 \right\}^{-1/2}} \xrightarrow{D} N(0,1)$$

しかし, σ は不明.

σ^2 を $\frac{1}{n} \sum_{i=1}^n \hat{u}_i^2$ で代用してもよい.

$$\frac{\hat{\beta} - \beta}{\left\{ \frac{1}{n} \sum_{i=1}^n \hat{u}_i^2 \right\}^{1/2} \left\{ \sum_{i=1}^n (x_i - \bar{x})^2 \right\}^{-1/2}} \xrightarrow{D} N(0,1)$$

標本平均の分布

DGP: $y_i = \mu + \varepsilon_i$, $E[\varepsilon_i] = 0$, $V[\varepsilon_i] = \sigma^2$, ε_i は独立

回帰: $y_i = \hat{\mu} + \hat{u}_i$

$$\text{推定量: } \hat{\mu} = \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

$$\text{不偏性: } E[\hat{\mu}] = E\left[\frac{1}{n} \sum_{i=1}^n y_i\right] = \frac{1}{n} \sum_{i=1}^n E[y_i] = \frac{1}{n} \sum_{i=1}^n \mu = \mu$$

一致性:

$$V[\hat{\mu}] = V\left[\frac{1}{n} \sum_{i=1}^n y_i\right] = \frac{1}{n^2} \sum_{i=1}^n V[y_i] = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 = \frac{\sigma^2}{n}$$

n が大きくなると標本平均の分散は 0 に近づく.

近似分布:

$$\sqrt{n}(\hat{\mu} - \mu) \xrightarrow{D} N(0, \sigma^2)$$

σ^2 を $\frac{1}{n} \sum_{i=1}^n \hat{u}_i^2$ で代用するが, $\hat{u}_i = y_i - \hat{\mu} = y_i - \bar{y}$ なので,

$$\frac{\sqrt{n}(\bar{y} - \mu)}{\left\{ \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 \right\}^{1/2}} \xrightarrow{D} N(0,1)$$

3章 多変数回帰
回帰式

以後は回帰式と DGP が一致している (特定化の誤りがない) 場合は DGP で回帰式も表す .

$$y_i = \beta_1 x_{1i} + \beta_2 x_{2i} + \cdots + \beta_k x_{ki} + \varepsilon_i \quad (i = 1, \cdots, n)$$

$$E[\varepsilon_i] = 0, V[\varepsilon_i] = \sigma^2, \varepsilon_i \text{ は各 } i \text{ に対して独立}$$

$\hat{\beta}_1, \cdots, \hat{\beta}_k$ を求める .

正規方程式
最小二乗法

$$S = \sum_{i=1}^n \{y_i - (b_1 x_{1i} + b_2 x_{2i} + \cdots + b_k x_{ki})\}^2 \text{ を } b_1, \cdots, b_k \text{ を動かして最小化 . 最}$$

小化したときの $\hat{\beta}_1, \cdots, \hat{\beta}_k$ をとする .

一階条件

$$\begin{aligned} \frac{\partial S}{\partial b_j} &= \frac{\partial}{\partial b_j} \sum_{i=1}^n \{y_i - (b_1 x_{1i} + b_2 x_{2i} + \cdots + b_k x_{ki})\}^2 \\ &= \sum_{i=1}^n \frac{\partial \{y_i - (b_1 x_{1i} + b_2 x_{2i} + \cdots + b_k x_{ki})\}^2}{\partial b_j} \\ &= \sum_{i=1}^n \left[\frac{\partial \{y_i - (b_1 x_{1i} + b_2 x_{2i} + \cdots + b_k x_{ki})\}^2}{\partial \{y_i - (b_1 x_{1i} + b_2 x_{2i} + \cdots + b_k x_{ki})\}} \right. \\ &\quad \left. \times \frac{\partial \{y_i - (b_1 x_{1i} + b_2 x_{2i} + \cdots + b_k x_{ki})\}}{\partial b_j} \right] \\ &= \sum_{i=1}^n [2\{y_i - (b_1 x_{1i} + b_2 x_{2i} + \cdots + b_k x_{ki})\} \times (-x_{ji})] \\ &= -2 \sum_{i=1}^n \{y_i - (b_1 x_{1i} + b_2 x_{2i} + \cdots + b_k x_{ki})\} x_{ji} \\ &= 0 \end{aligned}$$

これを満

たす b_1, \dots, b_k が $\hat{\beta}_1, \dots, \hat{\beta}_k$ であるから,

$$\sum_{i=1}^n \{y_i - (\hat{\beta}_1 x_{1i} + \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki})\} x_{ji} = 0 \quad (j=1, \dots, k) \quad \text{が満たす}$$

べき方程式.

$$\hat{u}_i = y_i - (\hat{\beta}_1 x_{1i} + \hat{\beta}_2 x_{2i} + \dots + \hat{\beta}_k x_{ki})$$

に注意すると,

$$\sum_{i=1}^n \hat{u}_i x_{ji} = 0 \quad (j=1, \dots, k)$$

となり, 残差と説明変数の積和が 0 というのが正規方程式.

計算方法

連立方程式 (k本の)

偏回帰係数の計算

1) X_{ji} (j番目の説明変数) を残りの変数に回帰し,

最小二乗法を行う.

つまり,

$$X_{ji} = \hat{c}_1 x_{1i} + \dots + \hat{c}_{j-1} x_{j-1,i} + \hat{c}_{j+1} x_{j+1,i} + \dots + \hat{c}_k x_{ki} \\ + X_{ji}^*$$

回帰残差を X_{ji}^* とする.

2) y_i を X_{ji}^* に回帰し, 最小二乗法を行う. つまり,

$$y_i = \hat{\beta}_j^* X_{ji}^* + \hat{u}_i^*$$

$$\hat{\beta}_j^* = \frac{\sum_{i=1}^n y_i X_{ji}^*}{\sum_{i=1}^n (X_{ji}^*)^2} \quad (\text{偏回帰係数})$$

$$\text{実は, } \hat{\beta}_j^* = \hat{\beta}_j$$

(偏回帰係数は最小二乗法推定量と一致)

3) さらに, y_i を j 以外の変数に回帰し, 最小二乗法を行った残差を y_i^* とすれば, つまり,

$$y_i = \hat{a}_1 x_{1i} + \dots + \hat{a}_{j-1} x_{j-1,i} + \hat{a}_{j+1} x_{j+1,i} + \dots + \hat{a}_k x_{ki} \\ + y_i^*$$

としたなら,

$$y_i^* = \hat{\beta}_j^* X_{ji}^* + \hat{u}_i^*$$

となり、 $\hat{\beta}_j^* = \hat{\beta}_j$ で、しかも、 \hat{u}_i は元の回帰式の最小二乗法残差と一致。(部分回帰則3とする)

注意:

n変数に関しては上記の手順を繰り返す。つまり、

$$x_{ji} = \hat{c}_1 x_{1i} + \cdots + \hat{c}_{j-1} x_{j-1,i} + \hat{c}_{j+1} x_{j+1,i} + \cdots + \hat{c}_k x_{ki} + x_{ji}^*$$

で x_{ji}^* を計算する時に3)を適用する。

それを、一変数になるまで繰り返す。

モデル $y_i = \alpha + \beta x_i + \varepsilon_i$ の場合、まず、 X_i を1に回帰して、その残差は $x_i^* = x_i - \bar{x}$ となるから、 y を x_i^* に回帰して、

$$\hat{\beta} = \frac{\sum_{i=1}^n x_i^* y_i}{\sum_{i=1}^n (x_i^*)^2} = \frac{\sum_{i=1}^n x_i^* y_i - \bar{y} \sum_{i=1}^n x_i^*}{\sum_{i=1}^n (x_i^*)^2} = \frac{\sum_{i=1}^n x_i^* (y_i - \bar{y})}{\sum_{i=1}^n (x_i^*)^2}$$

(証明は教材プリント参照)

偏相関係数

$r_{xy|z_1, \dots, z_k}$: Z_1, \dots, Z_k の影響を x と y との取り除いた偏相関係数

まず、最小二乗法による回帰によって x と y の影響を取り除いた回帰残差を求める

$$x_i = \hat{c}_1 z_{1i} + \cdots + \hat{c}_k z_{ki} + x_i^*$$

$$y_i = \hat{d}_1 z_{1i} + \cdots + \hat{d}_k z_{ki} + y_i^*$$

その結果を利用して

$$r_{xy|z_1, \dots, z_k} = \frac{\sum_{i=1}^n x_i^* y_i^*}{\sqrt{\sum_{i=1}^n (x_i^*)^2} \sqrt{\sum_{i=1}^n (y_i^*)^2}} \text{ で定義}$$

注意:

$$r_{xy} = r_{xy|1} = r_{xy|\text{定数}} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

これに従って以下定数項を含む場合は、無視して $r_{xy} = r_{xy|1}$ と書こう。

$$x_i^* = x_i - (\bar{x} + \hat{c}_2 \bar{z}) - \hat{c}_2 z_i = x_i - \bar{x} - \hat{c}_2 (z_i - \bar{z})$$

$$= x_i - \bar{x} - \frac{\sum_{i=1}^n (x_i - \bar{x})(z_i - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2} (z_i - \bar{z})$$

同様に、

$$y_i^* = y_i - \bar{y} - \frac{\sum_{i=1}^n (y_i - \bar{y})(z_i - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2} (z_i - \bar{z})$$

従って,

$$\begin{aligned}
 & \sum_{i=1}^n x_i^* y_i^* \\
 &= \sum_{i=1}^n \left\{ y_i - \bar{y} - \frac{\sum_{i=1}^n (y_i - \bar{y})(z_i - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2} (z_i - \bar{z}) \right\} \left\{ x_i - \bar{x} - \frac{\sum_{i=1}^n (x_i - \bar{x})(z_i - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2} (z_i - \bar{z}) \right\} \\
 &= \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x}) - \frac{\sum_{i=1}^n (x_i - \bar{x})(z_i - \bar{z}) \sum_{i=1}^n (y_i - \bar{y})(z_i - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2} \\
 &= n(S_{xy} - S_{xz} S_{zz}^{-1} S_{zy})
 \end{aligned}$$

また,

$$\begin{aligned}
 & \sum_{i=1}^n (x_i^*)^2 \\
 &= \sum_{i=1}^n \left\{ x_i - \bar{x} - \frac{\sum_{i=1}^n (x_i - \bar{x})(z_i - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2} (z_i - \bar{z}) \right\}^2 \\
 &= \sum_{i=1}^n (x_i - \bar{x})^2 - \frac{\left\{ \sum_{i=1}^n (x_i - \bar{x})(z_i - \bar{z}) \right\}^2}{\sum_{i=1}^n (z_i - \bar{z})^2} \\
 &= n(S_{xx} - S_{xz}^2 S_{zz}^{-1})
 \end{aligned}$$

同様に,

$$\sum_{i=1}^n (y_i^*)^2 = n(S_{yy} - S_{yz}^2 S_{zz}^{-1})$$

よって,

$$\begin{aligned}
 r_{xy|z} &= r_{xy|z} = \frac{\sum_{i=1}^n x_i^* y_i^*}{\sqrt{\sum_{i=1}^n (x_i^*)^2} \sqrt{\sum_{i=1}^n (y_i^*)^2}} \\
 &= \frac{S_{xy} - S_{xz} S_{zz}^{-1} S_{zy}}{\sqrt{S_{xx} - S_{xz}^2 S_{zz}^{-1}} \sqrt{S_{yy} - S_{yz}^2 S_{zz}^{-1}}} \\
 &= \frac{S_{xy} / (\sqrt{S_{xx}} \sqrt{S_{yy}}) - S_{xz} / (\sqrt{S_{xx}} \sqrt{S_{zz}}) S_{zy} / (\sqrt{S_{yy}} \sqrt{S_{zz}})}{\sqrt{1 - S_{xz}^2 S_{zz}^{-1} S_{xx}^{-1}} \sqrt{S_{yy} - S_{yz}^2 S_{zz}^{-1}}} \\
 &= \frac{r_{xy} - r_{xz} r_{zy}}{\sqrt{(1 - r_{xz}^2)(1 - r_{yz}^2)}}
 \end{aligned}$$

多重共線性(マルチコリニアリティ)

- ・ ある説明変数が他の説明変数の線形和 = 一次式で表される場合を言う.
- ・ この場合, 係数は一意に確定しないので, 多くの回帰ソフトではエラーとなる.
- ・ 厳密にある説明変数が他の説明変数の線形和 = 一次式で表され無くても, 近似的に線形和で表せる場合には, 推定した係数値が不安定になる.

決定係数

単回帰と同様

3 最小二乗推定量の分布

係数の分散

$$\hat{\beta}_j = \frac{\sum_{i=1}^n y_i x_{ji}^*}{\sum_{i=1}^n (x_{ji}^*)^2} \text{ より,}$$

$$\hat{\beta}_j = \frac{\sum_{i=1}^n (\beta_1 x_{1i} + \dots + \beta_k x_{ki} + \varepsilon_i) x_{ji}^*}{\sum_{i=1}^n (x_{ji}^*)^2}$$

$$x_{ji} = \hat{c}_1 x_{1i} + \dots + \hat{c}_{j-1} x_{j-1,i} + \hat{c}_{j+1} x_{j+1,i} + \dots + \hat{c}_k x_{ki} \text{ より,}$$
$$+ x_{ji}^*$$

$$\sum_{i=1}^n x_{ji}^* x_{mi} = 0 \quad (m \neq j) \text{ であるから,}$$

$$\hat{\beta}_j = \frac{\sum_{i=1}^n (\beta_j x_{ji}^* + \varepsilon_i) x_{ji}^*}{\sum_{i=1}^n (x_{ji}^*)^2} = \beta_j + \frac{\sum_{i=1}^n x_{ji}^* \varepsilon_i}{\sum_{i=1}^n (x_{ji}^*)^2}$$

となり, 単回帰と同様な式(ただし単回帰では $x_i^* = x_i - \bar{x}$)となるので,

$$V(\hat{\beta}_j) = \frac{\sigma^2}{\sum_{i=1}^n (x_{ji}^*)^2}$$

t統計量

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{\frac{\sum_{i=1}^n \hat{u}_i^2}{n \sum_{i=1}^n (x_{ji}^*)^2}}} \text{ は近似的に } N(0,1) \text{ (平均 0 分散 1 正規分布)}$$

係数間の共分散と相関係数

$$\hat{\beta}_j - \beta_j = \frac{\sum_{i=1}^n x_{ji}^* \varepsilon_i}{\sum_{i=1}^n (x_{ji}^*)^2} \text{ より,}$$

$$\begin{aligned}
& E\left[(\hat{\beta}_j - \beta_j)(\hat{\beta}_m - \beta_m)\right] \\
&= E\left[\left(\frac{\sum_{i=1}^n x_{ji}^* \varepsilon_i}{\sum_{i=1}^n (x_{ji}^*)^2}\right)\left(\frac{\sum_{i=1}^n x_{mi}^* \varepsilon_i}{\sum_{i=1}^n (x_{mi}^*)^2}\right)\right] \\
&= E\left[\frac{\sum_{i=1}^n x_{ji}^* x_{mi}^* \varepsilon_i^2 + 2 \sum_{i=1}^n \sum_{p=i+1}^n x_{ji}^* x_{mp}^* \varepsilon_i \varepsilon_p}{\sum_{i=1}^n (x_{ji}^*)^2 \sum_{i=1}^n (x_{mi}^*)^2}\right] \\
&= \frac{\sum_{i=1}^n x_{ji}^* x_{mi}^* E[\varepsilon_i^2] + 2 \sum_{i=1}^n \sum_{p=i+1}^n x_{ji}^* x_{mp}^* E[\varepsilon_i \varepsilon_p]}{\sum_{i=1}^n (x_{ji}^*)^2 \sum_{i=1}^n (x_{mi}^*)^2}
\end{aligned}$$

$E[\varepsilon_i^2] = \sigma^2$, ε_i の独立性より $E[\varepsilon_i \varepsilon_p] = 0$ であるから,

$$\begin{aligned}
\text{Cov}(\hat{\beta}_j, \hat{\beta}_m) &= E\left[(\hat{\beta}_j - \beta_j)(\hat{\beta}_m - \beta_m)\right] \\
&= \frac{\sum_{i=1}^n x_{ji}^* x_{mi}^*}{\sum_{i=1}^n (x_{ji}^*)^2 \sum_{i=1}^n (x_{mi}^*)^2} \sigma^2
\end{aligned}$$

相関係数は,

$$\begin{aligned}
\text{Cor}(\hat{\beta}_j, \hat{\beta}_m) &= \frac{\text{Cov}(\hat{\beta}_j, \hat{\beta}_m)}{\sqrt{V(\hat{\beta}_j)V(\hat{\beta}_m)}} \\
&= \frac{\sum_{i=1}^n x_{ji}^* x_{mi}^* \sigma^2}{\sqrt{\sum_{i=1}^n (x_{ji}^*)^2 \sum_{i=1}^n (x_{mi}^*)^2}} \\
&= \frac{\sum_{i=1}^n x_{ji}^* x_{mi}^*}{\sqrt{\sum_{i=1}^n (x_{ji}^*)^2 \sum_{i=1}^n (x_{mi}^*)^2}}
\end{aligned}$$

4. 最小二乗推定量の諸性質

・ 回帰に変数を追加すると残差は減少し, R^2 も減少する.

(説明)

$$y_i = \beta_0 x_{0i} + \beta_1 x_{1i} + \cdots + \beta_{k-1} x_{k-1,i} + \beta_k + \varepsilon_i \quad (\text{A})$$

$$y_i = \beta_1 x_{1i} + \cdots + \beta_{k-1} x_{k-1,i} + \beta_k + \varepsilon_i \quad (\text{B})$$

とする. ただし, (A) の残差を \hat{u}_A , (B) の残差を \hat{u}_B とすると, $\hat{u}_B = y^*$. また, 最小二乗残差 x_{0i}^* を

$$x_{0i} = \hat{c}_1 x_{1i} + \cdots + \hat{c}_{k-1} x_{k-1,i} + \hat{c}_k + x_{0i}^*$$

とすると、部分回帰則3から、

$$\hat{u}_{Bi} = \hat{\beta}_0 x_{0i}^* + \hat{u}_{Ai}$$

となる。ここから、

$$\begin{aligned} \sum_{i=1}^n \hat{u}_{Bi}^2 &= \sum_{i=1}^n \hat{u}_{Ai}^2 + \sum_{i=1}^n \hat{\beta}_0^2 (x_{0i}^*)^2 \\ &= \sum_{i=1}^n \hat{u}_{Ai}^2 + \left(\frac{\sum_{i=1}^n x_{0i}^* y_i^0}{\sum_{i=1}^n (x_{0i}^*)^2} \right)^2 \sum_{i=1}^n (x_{0i}^*)^2 \\ &= \sum_{i=1}^n \hat{u}_{Ai}^2 + \frac{\left(\sum_{i=1}^n x_{0i}^* y_i^0 \right)^2}{\sum_{i=1}^n (x_{0i}^*)^2} \frac{\sum_{i=1}^n (\hat{u}_{Bi})^2}{\sum_{i=1}^n (y_{0i}^*)^2} \\ &= \sum_{i=1}^n \hat{u}_{Ai}^2 + r_{yx_0 | \text{他の説明変数}}^2 \sum_{i=1}^n (\hat{u}_{Bi})^2 \end{aligned}$$

従って、 $\sum_{i=1}^n \hat{u}_{Ai}^2 = (1 - r_{yx_0 | \text{他の説明変数}}^2) \sum_{i=1}^n (\hat{u}_{Bi})^2$ 。 $1 \geq 1 - r_{yx_0 | \text{他の説明変数}}^2 \geq 0$ より、 $\sum_{i=1}^n \hat{u}_{Ai}^2 \leq \sum_{i=1}^n (\hat{u}_{Bi})^2$

・ t統計量の再定義と偏相関係数との関係
[t統計量]

いままでは、 $t_{\beta_j} = \frac{(\hat{\beta}_j - \beta_j)}{\sqrt{\frac{\sum_{i=1}^n \hat{u}_i^2}{n} \frac{1}{\sum_{i=1}^n (x_i^*)^2}}}$ と定義してきたが、次章で説明する自由度の関係から、

$$t_{\beta_j} = \frac{(\hat{\beta}_j - \beta_j)}{\sqrt{\frac{\sum_{i=1}^n \hat{u}_i^2}{n - K} \frac{1}{\sum_{i=1}^n (x_i^*)^2}}}$$

と定義する。

[偏相関係数との関係]

$$t_{\beta_j}^2 = (n - K) \frac{r^2}{1 - r^2}$$

ただし、 $r = r_{yx_j | \text{他の説明変数}}$

(説明)

$$y_i = \beta_0 x_{0i} + \beta_1 x_{1i} + \cdots + \beta_{k-1} x_{k-1,i} + \beta_k + \varepsilon_i \quad (\text{A})$$

$$y_i = \beta_1 x_{1i} + \cdots + \beta_{k-1} x_{k-1,i} + \beta_k + \varepsilon_i \quad (\text{B})$$

とする。(A)の残差を \hat{u}_A 、(B)の残差を \hat{u}_B とすると、

$$\sum_{i=1}^n \hat{u}_{Ai}^2 = (1 - r_{yx_0 | \text{他の説明変数}}^2) \sum_{i=1}^n (\hat{u}_{Bi})^2$$

となるが、ここから、

$$r_{y_{x_0}^2 | \text{他の説明変数}} = \frac{\sum_{i=1}^n (\hat{u}_{Bi})^2 - \sum_{i=1}^n \hat{u}_{Ai}^2}{\sum_{i=1}^n (\hat{u}_{Bi})^2} \quad (\text{あ})$$

一方,

$$t_{\beta_0} = \frac{(\hat{\beta}_0 - \beta_0)}{\sqrt{\frac{\sum_{i=1}^n \hat{u}_{iA}^2}{n - K} \frac{1}{\sum_{i=1}^n (x_i^*)^2}}}$$

より,

$$t_{\beta_0}^2 = (n - K) \frac{(\hat{\beta}_0 - \beta_0)^2 \sum_{i=1}^n (x_i^*)^2}{\sum_{i=1}^n \hat{u}_{iA}^2}$$

また, $y_i = \beta_0 x_{0i} + \beta_1 x_{1i} + \dots + \beta_{k-1} x_{k-1,i} + \beta_k + \varepsilon_i$ を, 最小二乗残差 x_{0i}^* を

$$x_{0i} = \hat{c}_1 x_{1i} + \dots + \hat{c}_{k-1} x_{k-1,i} + \hat{c}_k + x_{0i}^*$$

として, 二段階目の回帰

$$\hat{u}_{Bi} = \hat{\beta}_0 x_{0i}^* + \hat{u}_{Ai}$$

でおこなうことを考えると, この式での

回帰変動 + 残差変動 = 総変動

の関係から,

$$\begin{aligned} \sum_{i=1}^n (\hat{\beta}_0 x_{0i}^* - \beta_0 x_{0i}^*)^2 + \sum_{i=1}^n u_{iA}^2 &= (\hat{\beta}_0 - \beta_0)^2 \sum_{i=1}^n (x_{0i}^*)^2 + \sum_{i=1}^n u_{iA}^2 \\ &= \sum_{i=1}^n y_i^* = \sum_{i=1}^n u_{iB}^2 \end{aligned}$$

となり,

$$(\hat{\beta}_0 - \beta_0)^2 \sum_{i=1}^n (x_{0i}^*)^2 = \sum_{i=1}^n u_{iB}^2 - \sum_{i=1}^n u_{iA}^2$$

よって,

$$t_{\beta_0}^2 = (n - K) \frac{\sum_{i=1}^n \hat{u}_{iB}^2 - \sum_{i=1}^n \hat{u}_{iA}^2}{\sum_{i=1}^n \hat{u}_{iA}^2} \quad (\text{い})$$

(あ)と(い)を組み合わせると結果を得る.