

Z_i は回帰式に含まれる説明変数でもよい。例えば, $Y_i = \alpha + \beta X_i + u_i$ について, u_i の平均はゼロ, 分散は $\sigma_*^2 X_i^2$ とする場合, 各変数を X_i で割って,

$$\begin{aligned}\frac{Y_i}{X_i} &= \alpha \frac{1}{X_i} + \beta + \frac{u_i}{X_i} \\ &= \alpha \frac{1}{X_i} + \beta + u_i^*\end{aligned}$$

を通常の最小二乗法で推定すればよい。 β は定数項として推定されるが, 意味は限界係数 (すなわち, 傾き) と同じなので注意すること。

不均一分散の例： 都道府県別『県民経済計算 2017 年版』

C_i = 家計最終消費支出 (1 兆円)

Y_i = 県民可処分所得 (1 兆円)


L_i = 人口 (千万人)

下記の消費関数を推定する。

$$C_i = \alpha + \beta Y_i + u_i, \quad i = 1, 2, \dots, n$$

$n = 47$ である。

C_i (兆円)



$$C_i = \mathbf{0.0063} + \mathbf{0.6219} Y_i, \quad R^2 = 0.9875, \quad \bar{R}^2 = 0.9872, \quad s = 0.8865$$

(0.1684) (0.0104)

各係数推定値の下の () 内は標準誤差を表す。

残差の二乗 \hat{u}_i^2 を人口の二乗 L_i に回帰させる。

$$\hat{u}_i^2 = - \begin{matrix} \mathbf{0.0838} \\ \mathbf{(0.1319)} \end{matrix} + \begin{matrix} \mathbf{5.6909} \\ \mathbf{(0.3720)} \end{matrix} L_i^2, \quad R^2 = 0.8387, \quad \overline{R}^2 = 0.8351, \quad s = 0.8233$$

各係数推定値の下の () 内は標準誤差を表す。

結果は、 L_i^2 の係数推定値の t 値は **15.3** ($= 5.6909/0.3720$) で、 L_i^2 の係数がゼロという仮説は棄却される。

よって、誤差項 u_i の分散 σ_i^2 は $\sigma_*^2 L_i^2$ と表される。

すなわち、 $u_i \sim N(0, \sigma_*^2 L_i^2)$ となる。


データを変換して，下記の式を推定し直す。

$$C_i^* = \alpha L_i^* + \beta Y_i^* + u_i^*$$

ただし， $C_i^* = \frac{C_i}{L_i}$ ， $L_i^* = \frac{1}{L_i}$ ， $Y_i^* = \frac{Y_i}{L_i}$ ， $u_i^* = \frac{u_i}{L_i}$ とする。

αL_i^* は一定ではないので， C_i^* と Y_i^* の関係は直線ではないことに注意。

C_i^* (兆円)



$$C_i^* = - \underset{(0.0647)}{0.1234} L_i^* + \underset{(0.0137)}{0.6206} Y_i^*, \quad R^2 = 0.9933, \quad \bar{R}^2 = 0.9709, \quad s = 1.8671$$

各係数推定値の下の () 内は標準誤差を表す。

7.3 誤差項：非正規分布のケース

(* 復習) 中心極限定理：

確率変数 X_1, X_2, \dots, X_n は互いに独立とする。 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ とする。

$n \rightarrow \infty$ のとき、 $\frac{\bar{X} - \mathbf{E}(\bar{X})}{\sqrt{\mathbf{V}(\bar{X})}} \rightarrow N(0, 1)$ となる。ただし、 $n\mathbf{V}(\bar{X}) < \infty$ とする。

(a) すべての i について $\mathbf{E}(X_i) = \mu$, $\mathbf{V}(X_i) = \sigma^2$ とする。

$n \rightarrow \infty$ のとき、 $\frac{\bar{X} - \mathbf{E}(\bar{X})}{\sqrt{\mathbf{V}(\bar{X})}} = \frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \rightarrow N(0, 1)$ となる。

$\mathbf{E}(\bar{X}) = \mu$, $\mathbf{V}(\bar{X}) = \frac{\sigma^2}{n}$ に注意。

(b) $\frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \rightarrow N(0, 1)$ は $\sqrt{n}(\bar{X} - \mu) \rightarrow N(0, \sigma^2)$ と同じ意味である

なぜなら, $\mathbf{V}(\sqrt{n}(\bar{X} - \mu)) = (\sqrt{n})^2 \mathbf{V}(\bar{X} - \mu) = n \mathbf{V}(\bar{X}) = \sigma^2$ となる。

(c) $\mathbf{E}(X_i) = \mu$, $\mathbf{V}(X_i) = \sigma_i^2$ (不均一分散), $\sigma^2 = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \sigma_i^2 < \infty$ のとき,

$\sqrt{n}(\bar{X} - \mu) \rightarrow N(0, \sigma^2)$ となる。

中心極限定理を回帰分析に当てはめる。

単回帰:

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

を考える。

• 誤差項 u_1, u_2, \dots, u_n は互いに独立で、それぞれ平均ゼロ・分散 σ^2 とする（正規分布を仮定しない）。

• $n \rightarrow \infty$ のとき、 $\frac{1}{n} \sum_i (X_i - \bar{X})^2 \rightarrow M < \infty$ （一定の値）とする。

この場合、最小二乗推定量はどうなるか？

β の最小二乗推定量 $\hat{\beta}$ は次のように書き換えられる。

$$\hat{\beta} = \frac{\sum_i (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_i (X_i - \bar{X})^2} = \beta + \sum_i \omega_i u_i$$

ただし、 $\omega_i = \frac{X_i - \bar{X}}{\sum_j (X_j - \bar{X})^2}$ とする。

$\hat{\beta}$ の分布を求めるために、まず $\hat{\beta} - \beta = \sum_i \omega_i u_i$ を利用して、 $\sum_i \omega_i u_i$ の分布を求める。

$\sum_i \omega_i u_i$ が「(* 復習) 中心極限定理」の $\bar{X} = \frac{1}{n} \sum_i X_i$ に対応する。

すなわち、 $n\omega_i u_i$ が「(* 復習) 中心極限定理」の X_i に対応する。

「(* 復習) 中心極限定理」の (c) に当てはめる。

$n\omega_i u_i$ の平均・分散は下記の通りとなる。

- $\mathbf{E}(n\omega_i u_i) = n\omega_i \mathbf{E}(u_i) = 0$
- $\mathbf{V}(n\omega_i u_i) = n^2 \omega_i^2 \mathbf{V}(u_i) = n^2 \omega_i^2 \sigma^2$

$n^2 \omega_i^2 \sigma^2$ は「(* 復習) 中心極限定理」(c) の σ_i^2 に対応する。

まずは、「(* 復習) 中心極限定理」(c) の $\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \sigma_i^2 < \infty$ が成り立つかどうかをチェックする。

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbf{V}(n\omega_i u_i) = \frac{1}{n} n^2 \sigma^2 \sum \omega_i^2 = \frac{\sigma^2}{\frac{1}{n} \sum (X_i - \bar{X})^2} \rightarrow \frac{\sigma^2}{M} < \infty$$

$$\sum_i \omega_i^2 = \frac{1}{\sum (X_i - \bar{X})^2} \text{ に注意。}$$

よって, $\sqrt{n} \sum_i \omega_i u_i \rightarrow N\left(0, \frac{\sigma^2}{M}\right)$ となる。

$\sqrt{n} \sum \omega_i u_i = \sqrt{n}(\hat{\beta} - \beta)$ なので,

$$\sqrt{n}(\hat{\beta} - \beta) \rightarrow N\left(0, \frac{\sigma^2}{M}\right)$$

となる。

さらに、 n が大きいとき、近似的に、

$$\hat{\beta} \sim N\left(\beta, \frac{\sigma^2}{\sum(X_i - \bar{X})^2}\right)$$

となる。

また、 σ^2 をその推定量 s^2 に置き換えても、 n が大きいとき、近似的に、

$$\hat{\beta} \sim N\left(\beta, \frac{s^2}{\sum(X_i - \bar{X})^2}\right)$$

となる（実践では、これが用いられる）。

結論： 誤差項 u_i の分布を仮定しなくても、データ数 n が大きければ、 $\hat{\beta}$ の分布は正規分布で近似できる。

重回帰 $Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \cdots + \beta_k X_{ki} + u_i$ でも同様に、 u_1, u_2, \dots, u_n の分布を仮定しなくても（ただし、互いに独立で、平均ゼロ・分散 σ^2 の仮定は必要）、 n が大きいとき、 $\hat{\beta}_j$ は近似的に下記のような正規分布を用いることができる。

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

$s\sqrt{a_{jj}}$ は $\hat{\beta}_j$ の標準誤差を表す。

a_{jj} については、11/10 講義ノート P.306 参照のこと。