

第6章 統計学の回帰分析への応用

6.1 確率的モデル：単回帰モデル

再び、話を簡単にするために単回帰モデルを考えることにしよう。すなわち、 $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$ のように n 組のデータがあり、 X_i と Y_i との間に線型関係を想定する。

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

最小二乗法を用いて、データに直線のあてはめを行った。その結果、 $\hat{\alpha}$, $\hat{\beta}$, \hat{Y}_i を求めるための公式は、

$$\hat{\beta} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})Y_i}{\sum_{i=1}^n (X_i - \bar{X})^2},$$

$$\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X},$$

であった。

$\hat{Y}_i = \hat{\alpha} + \hat{\beta}X_i$ とするとき、 Y_i , \hat{Y}_i , \hat{u}_i , $\hat{\alpha}$, $\hat{\beta}$ の関係は以下の通りである。

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

残差 \hat{u}_i が必ず含まれることから、回帰モデルを

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

として誤差項 (または、攪乱項) u_i を含め、それを確率変数として考える。 u_i は平均 0, 分散 σ^2 の正規分布が仮定されることが多い。ある確率密度分布 (ここでは正規分布) があって、その分布に従い、データ (ここでは Y_i) が生成されるモデルのことを確率的モデルと呼ぶ。

Y_i : 被説明変数, 従属変数

X_i : 説明変数, 独立変数

α, β : 未知母数 (未知パラメータ)

$\hat{\alpha}, \hat{\beta}$: 推定量 (特に, 最小二乗推定量), 時には, 推定値 (最小二乗推定値)

1. 残差 \hat{u}_i は u_i の実現値としてみなすことができる。
2. $\hat{\alpha}, \hat{\beta}$ の性質を統計学的に考察可能となる。

6.2 回帰モデルの仮定

回帰モデル

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

の仮定:

1. X_i は確率変数でないと仮定する (固定された値)。
2. すべての i について, $E(u_i) = 0$ とする。
3. すべての i について, $V(u_i) = \sigma^2$ とする。 ($V(u_i) = E(u_i^2) = \sigma^2$ に注意)
4. すべての $i \neq j$ について, $\text{Cov}(u_i, u_j) = 0$ とする。 ($\text{Cov}(u_i, u_j) = E(u_i u_j) = 0$ に注意)
5. すべての i について, $u_i \sim N(0, \sigma^2)$ とする。
6. $n \rightarrow \infty$ のとき, $\sum_{i=1}^n (X_i - \bar{X})^2 \rightarrow \infty$ とする。

攪乱項 u_1, u_2, \dots, u_n はそれぞれ独立に平均ゼロ, 分散 σ^2 の正規分布する。

再度, まとめて, 回帰モデル:

$$Y_i = \alpha + \beta X_i + u_i, \quad u_i \sim N(0, \sigma^2),$$

ただし,

Y_i : 被説明変数, 従属変数

X_i : 説明変数, 独立変数

α, β, σ^2 : 未知母数 (未知パラメータ)

$\hat{\alpha}, \hat{\beta}$: 推定量 (特に, 最小二乗推定量)

特に, 回帰直線は,

$$E(Y_i) = \alpha + \beta X_i$$

として解釈される。

6.2.1 誤差項 (攪乱項) の経済学的意味

1. 経済理論自身が不完全: X 以外にも他の説明変数が必要であるにもかかわらず, それを誤って除いている可能性がある。
2. モデルの定式化が不完全: Y と X との間の線形関係が誤りかもしれない。
3. 理論モデルとデータとの対応: 理論モデルで考えられる変数と実際に用いたデータが適当でないかもしれない。例: 所得のデータについては国民総生産, 国民所得, 可処分所得, 労働所得 ..., 金利では公定歩合, 国債利回り, 定期預金金利, 全国銀行平均約定金利 ...
4. 測定上の誤差: 経済データは一般的に推計されているため完全ではない。誤差を含む。

6.3 $\hat{\alpha}$, $\hat{\beta}$ の統計的性質

準備:

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

$$\bar{Y} = \alpha + \beta \bar{X} + \bar{u},$$

ただし,

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

とする。辺々を引いて,

$$Y_i - \bar{Y} = \beta(X_i - \bar{X}) + (u_i - \bar{u}),$$

を得る。

6.3.1 $\hat{\beta}$ について

β の最小二乗推定量 $\hat{\beta}$ に代入すると,

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

である。途中の計算で, $\sum_{i=1}^n (X_i - \bar{X})\bar{u} = 0$ に注意せよ。

よって, まとめると,

$$\hat{\beta} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} = \beta + \frac{\sum_{i=1}^n (X_i - \bar{X})u_i}{\sum_{i=1}^n (X_i - \bar{X})^2} = \beta + \sum_{i=1}^n \omega_i u_i,$$

となる。ただし, $\omega_i = \frac{(X_i - \bar{X})}{\sum_{i=1}^n (X_i - \bar{X})^2}$ とする。

6.3.2 $\hat{\alpha}$ について

α の最小二乗推定量 $\hat{\alpha}$ については,

$$\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X} = \alpha - (\hat{\beta} - \beta)\bar{X} + \bar{u}$$

ただし, $\bar{u} = \frac{1}{n} \sum_{i=1}^n u_i$ である。 $\bar{Y} = \alpha + \beta\bar{X} + \bar{u}$ を途中で使う。

6.3.3 $\hat{\alpha}$, $\hat{\beta}$ の平均

$\hat{\beta}$ は次のように書き換えられた。

$$\hat{\beta} = \beta + \sum_{i=1}^n \omega_i u_i,$$

の両辺に期待値をとると,

$$E(\hat{\beta}) = E\left(\beta + \sum_{i=1}^n \omega_i u_i\right) = \beta + \sum_{i=1}^n E(\omega_i u_i) = \beta + \sum_{i=1}^n \omega_i E(u_i) = \beta,$$

となり, $\hat{\beta}$ は β の不偏推定量であると言える。

$\hat{\alpha}$ については,

$$\hat{\alpha} = \alpha - (\hat{\beta} - \beta)\bar{X} + \bar{u}$$

を利用して, 辺々に期待値をとると,

$$E(\hat{\alpha}) = \alpha - E(\hat{\beta} - \beta)\bar{X} + E(\bar{u}) = \alpha$$

となる。 $E(\hat{\beta}) = \beta$ なので, $E(\hat{\beta} - \beta) = 0$ に注意。また, $E(\bar{u})$ の計算は以下のとおり。

$$E(\bar{u}) = E\left(\frac{1}{n} \sum_{i=1}^n u_i\right) = \frac{1}{n} \sum_{i=1}^n E(u_i) = 0$$

$\hat{\alpha}$ は α の不偏推定量であると言える。

 $\hat{\alpha}$, $\hat{\beta}$ の分散

$\hat{\beta}$ の分散について, $\hat{\beta} = \beta + \sum_{i=1}^n \omega_i u_i$ を用いると,

$$\begin{aligned} V(\hat{\beta}) &= V\left(\beta + \sum_{i=1}^n \omega_i u_i\right) = V\left(\sum_{i=1}^n \omega_i u_i\right) = \sum_{i=1}^n \omega_i^2 V(u_i^2) = \sigma^2 \sum_{i=1}^n \omega_i^2 \\ &= \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \end{aligned}$$

誤差項 (または, 攪乱項) の仮定より,

$$V(u_i) = \sigma^2,$$

を用いる。

最後の行は, $\omega_i = \frac{X_i - \bar{X}}{\sum_{j=1}^n (X_j - \bar{X})^2}$ に注意して,

$$\begin{aligned} \sum_{i=1}^n \omega_i^2 &= \sum_{i=1}^n \left(\frac{X_i - \bar{X}}{\sum_{j=1}^n (X_j - \bar{X})^2} \right)^2 = \sum_{i=1}^n \frac{(X_i - \bar{X})^2}{\left(\sum_{j=1}^n (X_j - \bar{X})^2 \right)^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\left(\sum_{j=1}^n (X_j - \bar{X})^2 \right)^2} \\ &= \frac{1}{\sum_{i=1}^n (X_i - \bar{X})^2} \end{aligned}$$

を用いる。 $\sum_{i=1}^n (X_i - \bar{X})^2 = \sum_{j=1}^n (X_j - \bar{X})^2$ に注意。

よって, $\hat{\beta}$ の平均は β , 分散は $\frac{\sigma^2}{\sum (X_i - \bar{X})^2}$ となることが示された。

$\hat{\alpha}$ の分散について, $\hat{\alpha} = \alpha - (\hat{\beta} - \beta)\bar{X} + \bar{u}$ を利用すると,

$$\begin{aligned} V(\hat{\alpha}) &= E(\hat{\alpha} - \alpha)^2 = E(-(\hat{\beta} - \beta)\bar{X} + \bar{u})^2 \\ &= \bar{X}^2 E(\hat{\beta} - \beta)^2 - 2\bar{X}E((\hat{\beta} - \beta)\bar{u}) + E(\bar{u}^2) \\ &= \sigma^2 \left(\frac{\bar{X}^2}{\sum_{i=1}^n (X_i - \bar{X})^2} + \frac{1}{n} \right) = \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2} \end{aligned}$$

途中で, 以下の計算が使われる。

$$\begin{aligned} E((\hat{\beta} - \beta)\bar{u}) &= E\left(\frac{\sum_{i=1}^n (X_i - \bar{X})u_i}{\sum_{i=1}^n (X_i - \bar{X})^2} \frac{1}{n} \sum_{i=1}^n u_i \right) \\ &= \frac{1}{n \sum_{i=1}^n (X_i - \bar{X})^2} E\left(\sum_{i=1}^n (X_i - \bar{X})u_i \sum_{j=1}^n u_j \right) \\ &= \frac{1}{n \sum_{i=1}^n (X_i - \bar{X})^2} \sum_{i=1}^n \sum_{j=1}^n (X_i - \bar{X})E(u_i u_j) \\ &= \frac{1}{n \sum_{i=1}^n (X_i - \bar{X})^2} \sigma^2 \sum_{i=1}^n (X_i - \bar{X}) = 0 \end{aligned}$$

$\sum_{i=1}^n (X_i - \bar{X}) = 0$ であることに注意。

$$\begin{aligned} E(\bar{u}^2) &= E\left(\frac{1}{n} \sum_{i=1}^n u_i\right)^2 = \frac{1}{n^2} E\left(\sum_{i=1}^n \sum_{j=1}^n u_i u_j\right) = \frac{1}{n^2} E\left(\sum_{i=1}^n u_i^2\right) \\ &= \frac{1}{n^2} \sum_{i=1}^n E(u_i^2) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 = \frac{\sigma^2}{n} \end{aligned}$$

よって、 $\hat{\alpha}$ の平均は α 、分散は $\frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}$ となることが示された。

$\hat{\alpha}$ と $\hat{\beta}$ の共分散について、 $\hat{\alpha} = \alpha - (\hat{\beta} - \beta)\bar{X} + \bar{u}$ を利用すると、

$$\begin{aligned} \text{Cov}(\hat{\alpha}, \hat{\beta}) &= E((\hat{\alpha} - \alpha)(\hat{\beta} - \beta)) = E((-(\hat{\beta} - \beta)\bar{X} + \bar{u})(\hat{\beta} - \beta)) \\ &= -E((\hat{\beta} - \beta)^2)\bar{X} + E(\bar{u}(\hat{\beta} - \beta)) = -E((\hat{\beta} - \beta)^2)\bar{X} \\ &= -\frac{\sigma^2 \bar{X}}{\sum_{i=1}^n (X_i - \bar{X})^2} \end{aligned}$$

となる。

数値例：

i	X_i	Y_i	X_i^2	$X_i Y_i$
1	5	4	25	20
2	1	1	1	1
3	3	1	9	3
4	2	3	4	6
5	4	4	16	16
合計	$\sum X_i$	$\sum Y_i$	$\sum X_i^2$	$\sum X_i Y_i$
	15	13	55	46
平均	\bar{X}	\bar{Y}		
	3	2.6		

$$V(\hat{\beta}) = \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2} = \frac{\sigma^2}{\sum_{i=1}^n X_i^2 - n\bar{X}^2} = \frac{\sigma^2}{55 - 5 \times 3^2} = \frac{\sigma^2}{10} = 0.1\sigma^2$$

$$V(\hat{\alpha}) = \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2} = \frac{\sigma^2 55}{5(55 - 5 \times 3^2)} = \frac{55\sigma^2}{50} = 1.1\sigma^2$$

$$\text{Cov}(\hat{\alpha}, \hat{\beta}) = -\frac{\sigma^2 \bar{X}}{\sum_{i=1}^n (X_i - \bar{X})^2} = -\frac{\sigma^2 \bar{X}}{\sum_{i=1}^n X_i^2 - n\bar{X}^2} = -\frac{3\sigma^2}{55 - 5 \times 3^2} = -0.3\sigma^2$$

注意： 最小二乗法を復習すると、まず、次のような関数 $S(\alpha, \beta)$ を定義する。

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

$S(\alpha, \beta)$ の最小化によって、

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

を満たす α, β が $\hat{\alpha}, \hat{\beta}$ となる。

すなわち、 $\hat{\alpha}, \hat{\beta}$ は、

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

を満たす。

さらに、

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

行列表示によって、

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

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

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

逆行列の部分と分散，共分散とは以下のような関係がある。

$$\begin{aligned} \begin{pmatrix} V(\hat{\alpha}) & \text{Cov}(\hat{\alpha}, \hat{\beta}) \\ \text{Cov}(\hat{\alpha}, \hat{\beta}) & V(\hat{\beta}) \end{pmatrix} &= \sigma^2 \begin{pmatrix} n & \sum_{i=1}^n X_i \\ \sum_{i=1}^n X_i & \sum_{i=1}^n X_i^2 \end{pmatrix}^{-1} \\ &= \frac{\sigma^2}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} \begin{pmatrix} \sum_{i=1}^n X_i^2 & -\sum_{i=1}^n X_i \\ -\sum_{i=1}^n X_i & n \end{pmatrix} \\ &= \begin{pmatrix} \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2} & -\frac{\sigma^2 \bar{X}}{\sum_{i=1}^n (X_i - \bar{X})^2} \\ -\frac{\sigma^2 \bar{X}}{\sum_{i=1}^n (X_i - \bar{X})^2} & \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \end{pmatrix} \end{aligned}$$

$\hat{\alpha}$, $\hat{\beta}$ の分布 (σ^2 が既知の場合)

1. $\hat{\beta} = \beta + \sum_{i=1}^n \omega_i u_i$
2. $E(\hat{\beta}) = \beta$
3. $V(\hat{\beta}) = \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}$

よって，

$$\hat{\beta} \sim N\left(\beta, \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}\right),$$

となる。

1. $\hat{\alpha} = \alpha - (\hat{\beta} - \beta)\bar{X} + \bar{u}$
2. $E(\hat{\alpha}) = \alpha$
3. $V(\hat{\alpha}) = \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2} = \sigma^2 \left(\frac{\bar{X}^2}{\sum_{i=1}^n (X_i - \bar{X})^2} + \frac{1}{n} \right)$

よって，

$$\hat{\alpha} \sim N\left(\alpha, \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}\right),$$

となる。

$\hat{\alpha}$, $\hat{\beta}$ の性質：最良線型不偏性と一致性

不偏性：既に証明したとおり， $E(\hat{\beta}) = \beta$, $E(\hat{\alpha}) = \alpha$ なので， $\hat{\alpha}$, $\hat{\beta}$ は β , α の不偏推定量である。

最良線型不偏性： $\hat{\beta}$ を変形すると以下の通りとなる。

$$\hat{\beta} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})Y_i}{\sum_{i=1}^n (X_i - \bar{X})^2} = \sum_{i=1}^n \omega_i Y_i$$

ただし， $\omega_i = \frac{(X_i - \bar{X})}{\sum_{i=1}^n (X_i - \bar{X})^2}$ とする。このように， $\hat{\beta}$ は線型不偏推定量であると言える。

別の線型不偏推定量を次のように考える。

$$\tilde{\beta} = \sum_{i=1}^n c_i Y_i$$

ただし， $c_i = \omega_i + d_i$ とする。 $\tilde{\beta}$ もまた β の不偏推定量と仮定したので，

$$\begin{aligned} \tilde{\beta} &= \sum_{i=1}^n c_i Y_i = \sum_{i=1}^n (\omega_i + d_i)(\alpha + \beta X_i + u_i) \\ &= \alpha \sum_{i=1}^n \omega_i + \beta \sum_{i=1}^n \omega_i X_i + \sum_{i=1}^n \omega_i u_i + \alpha \sum_{i=1}^n d_i + \beta \sum_{i=1}^n d_i X_i + \sum_{i=1}^n d_i u_i \\ &= \beta + \alpha \sum_{i=1}^n d_i + \beta \sum_{i=1}^n d_i X_i + \sum_{i=1}^n \omega_i u_i + \sum_{i=1}^n d_i u_i \end{aligned}$$

と変形される。 $\sum_{i=1}^n \omega_i = 0$, $\sum_{i=1}^n \omega_i X_i = 1$ に注意。

よって，期待値をとると，

$$\begin{aligned} E(\tilde{\beta}) &= \beta + \alpha \sum_{i=1}^n d_i + \beta \sum_{i=1}^n d_i X_i + \sum_{i=1}^n \omega_i E(u_i) + \sum_{i=1}^n d_i E(u_i) \\ &= \beta + \alpha \sum_{i=1}^n d_i + \beta \sum_{i=1}^n d_i X_i \end{aligned}$$

となる。 $\tilde{\beta}$ が不偏であるためには,

$$\sum_{i=1}^n d_i = 0, \quad \sum_{i=1}^n d_i X_i = 0,$$

の条件が必要となる。

この2つの条件が成り立っていると仮定すると,

$$\tilde{\beta} = \beta + \sum_{i=1}^n (\omega_i + d_i) u_i$$

を利用して,

$$\begin{aligned} V(\tilde{\beta}) &= E(\tilde{\beta} - \beta)^2 = E\left(\sum_{i=1}^n (\omega_i + d_i) u_i\right)^2 = \sum_{i=1}^n (\omega_i + d_i)^2 E(u_i^2) \\ &= \sigma^2 \left(\sum_{i=1}^n \omega_i^2 + 2 \sum_{i=1}^n \omega_i d_i + \sum_{i=1}^n d_i^2 \right) = \sigma^2 \left(\sum_{i=1}^n \omega_i^2 + \sum_{i=1}^n d_i^2 \right) \end{aligned}$$

$\tilde{\beta}$ の不偏性の条件 $\sum_{i=1}^n d_i = 0$, $\sum_{i=1}^n d_i X_i = 0$ を利用すると,

$$\sum_{i=1}^n \omega_i d_i = \frac{\sum_{i=1}^n (X_i - \bar{X}) d_i}{\sum_{i=1}^n (X_i - \bar{X})^2} = \frac{\sum_{i=1}^n X_i d_i - \bar{X} \sum_{i=1}^n d_i}{\sum_{i=1}^n (X_i - \bar{X})^2} = 0$$

を得る。

まとめると, $\tilde{\beta}$ の分散は,

$$V(\tilde{\beta}) = \sigma^2 \left(\sum_{i=1}^n \omega_i^2 + \sum_{i=1}^n d_i^2 \right)$$

となる。 $\hat{\beta}$ の分散は,

$$V(\hat{\beta}) = \sigma^2 \sum_{i=1}^n \omega_i^2$$

なので,

$$V(\tilde{\beta}) \geq V(\hat{\beta})$$

となる。等号が成り立つときは、 $\sum_{i=1}^n d_i^2 = 0$ 、すなわち、 $d_1 = d_2 = \cdots = d_n = 0$ のときとなり、これは $\hat{\beta}$ に一致する。

よって、 $\hat{\beta}$ は最小分散線型不偏推定量、または、最良線型不偏推定量であると言える。

⇒ ガウス=マルコフの定理

$\hat{\alpha}$ についても、同様に、 α の最小分散線型不偏推定量となる。

証明は、

$$\hat{\alpha} - \alpha = -(\hat{\beta} - \beta)\bar{X} + \bar{u}$$

を利用すればよい。

推定量の関係 ⇒

最小分散(最良)線型不偏推定量 ⊂ 線型不偏推定量 ⊂ 線型推定量 ⊂ 全推定量

一貫性： $E(\hat{\beta}) = \beta$ となることが分かった。

n が大きくなると、 $\hat{\beta}$ は β に近づくかどうかを調べる。

$$V(\hat{\beta}) = \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

$n \rightarrow \infty$ のとき、 $V(\hat{\beta}) \rightarrow 0$ となれば、 $\hat{\beta}$ は β の一致推定量となる。

最小二乗法の仮定の一つに、「 $n \rightarrow \infty$ のとき、 $\sum_{i=1}^n (X_i - \bar{X})^2 \rightarrow \infty$ 」というものがあった。この仮定は、「 $n \rightarrow \infty$ のとき、 $V(\hat{\beta}) \rightarrow 0$ 」を保証する。よって、 $\hat{\beta}$ は β の一致推定量である。

$\hat{\alpha}$ についても、同様に、 $E(\hat{\alpha}) = \alpha$ であることは分かっている。

$$V(\hat{\alpha}) = \sigma^2 \left(\frac{1}{n} + \frac{\bar{X}^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \right)$$

となり、「 $n \rightarrow \infty$ のとき、 $V(\hat{\alpha}) \rightarrow 0$ 」となるので、 $\hat{\alpha}$ も α の一致推定量であると言える。

6.3.4 誤差項 (または, 攪乱項) u_i の分散 σ^2 について

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

誤差項 (または, 攪乱項) の仮定 : $u_i \sim N(0, \sigma^2)$

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

u_i の分散 σ^2 の不偏推定量 :

$$\frac{\sum_{i=1}^n \hat{u}_i^2}{\text{自由度}}$$

$$\begin{aligned} \text{自由度} &= \text{標本数 } (n) - \text{推定すべき係数値の数 } (2) \\ &= n - 2 \end{aligned}$$

誤差項 (または, 攪乱項) の母分散 σ^2 の不偏推定量 s^2 は,

$$s^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{u}_i^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta} X_i)^2,$$

によって与えられる。

s^2 の不偏性の証明 : まず, 次のように書き直す。

$$u_i = Y_i - \alpha - \beta X_i = (\hat{\alpha} + \hat{\beta} X_i + \hat{u}_i) - \alpha - \beta X_i = (\hat{\alpha} - \alpha) + (\hat{\beta} - \beta) X_i + \hat{u}_i,$$

両辺を二乗する。

$$\begin{aligned} u_i^2 &= (\hat{\alpha} - \alpha)^2 + (\hat{\beta} - \beta)^2 X_i^2 + \hat{u}_i^2 + 2(\hat{\alpha} - \alpha)(\hat{\beta} - \beta) X_i \\ &\quad + 2(\hat{\alpha} - \alpha)\hat{u}_i + 2(\hat{\beta} - \beta) X_i \hat{u}_i \end{aligned}$$

総和をとる。

$$\begin{aligned} \sum_{i=1}^n u_i^2 &= n(\hat{\alpha} - \alpha)^2 + (\hat{\beta} - \beta)^2 \sum_{i=1}^n X_i^2 + \sum_{i=1}^n \hat{u}_i^2 + 2(\hat{\alpha} - \alpha)(\hat{\beta} - \beta) \sum_{i=1}^n X_i \\ &\quad + 2(\hat{\alpha} - \alpha) \sum_{i=1}^n \hat{u}_i + 2(\hat{\beta} - \beta) \sum_{i=1}^n X_i \hat{u}_i \\ &= n(\hat{\alpha} - \alpha)^2 + (\hat{\beta} - \beta)^2 \sum_{i=1}^n X_i^2 + \sum_{i=1}^n \hat{u}_i^2 + 2n(\hat{\alpha} - \alpha)(\hat{\beta} - \beta) \bar{X} \end{aligned}$$

期待値をとる。

$$\begin{aligned} E\left(\sum_{i=1}^n u_i^2\right) &= nE(\hat{\alpha} - \alpha)^2 + E(\hat{\beta} - \beta)^2 \sum_{i=1}^n X_i^2 + E\left(\sum_{i=1}^n \hat{u}_i^2\right) \\ &\quad + 2nE((\hat{\alpha} - \alpha)(\hat{\beta} - \beta))\bar{X} \\ n\sigma^2 &= \frac{\sigma^2 \sum_{i=1}^n X_i^2}{\sum_{i=1}^n (X_i - \bar{X})^2} + \frac{\sigma^2 \sum_{i=1}^n X_i^2}{\sum_{i=1}^n (X_i - \bar{X})^2} + E\left(\sum_{i=1}^n \hat{u}_i^2\right) - \frac{2n\sigma^2\bar{X}^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \\ &= 2\sigma^2 \left(\frac{\sum_{i=1}^n X_i^2 - n\bar{X}^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \right) + E\left(\sum_{i=1}^n \hat{u}_i^2\right) = 2\sigma^2 + E\left(\sum_{i=1}^n \hat{u}_i^2\right) \end{aligned}$$

途中の計算には以下が使われる。

$$\begin{aligned} E\left(\sum_{i=1}^n u_i^2\right) &= n\sigma^2, & E(\hat{\alpha} - \alpha)^2 &= \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}, \\ E(\hat{\beta} - \beta)^2 &= \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}, & E((\hat{\alpha} - \alpha)(\hat{\beta} - \beta)) &= -\frac{\sigma^2\bar{X}}{\sum_{i=1}^n (X_i - \bar{X})^2}, \end{aligned}$$

よって、

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

を得る。すなわち、 s^2 は σ^2 の不偏推定量である。

回帰分析に当てはめる。

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

α, β を推定値に置き換えると、

$$\frac{\sum_{i=1}^n \hat{u}_i^2}{\sigma^2} = \frac{\sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta} X_i)^2}{\sigma^2} \sim \chi^2(n-2),$$

となる。さらに、

$$s^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta} X_i)^2,$$

なので、

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

を得る。

s^2 の一致性の証明: s^2 は

$$s^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{u}_i^2 = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}X_i)^2,$$

と定義される。

$\frac{(n-2)s^2}{\sigma^2} \sim \chi^2(n-2)$ なので (証明略),

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

となる。さらに, 書き直すと,

$$\frac{(n-2)^2}{\sigma^4} V(s^2) = 2(n-2), \quad V(s^2) = \frac{2\sigma^4}{n-2},$$

を得る。「 $E(s^2) = \sigma^2$ で, しかも, $n \rightarrow \infty$ のとき $V(s^2) \rightarrow 0$ 」が言えるので, s^2 は σ^2 の一致推定量である。

標準誤差について: 標準誤差 = 不偏分散の平方根

誤差項 (または, 攪乱項) の標準誤差 s

$$s = \sqrt{\frac{\sum_{i=1}^n \hat{u}_i^2}{n-2}}$$

数値例: $\hat{\alpha} = 0.5, \hat{\beta} = 0.7$ なので, $\hat{Y}_i = 0.7 + 0.8X_i, \hat{u}_i = Y_i - 0.7 - 0.8X_i$ により, \hat{Y}_i, \hat{u}_i を計算する。

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	$\sum X_i$	$\sum Y_i$	$\sum X_i^2$	$\sum X_i Y_i$	$\sum \hat{Y}_i$	$\sum \hat{u}_i$
	15	13	55	46	13	0.0
平均	\bar{X}	\bar{Y}				
	3	2.6				

誤差項 (または, 攪乱項) の母分散 σ^2 の不偏推定量 s^2 は,

$$s^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{u}_i^2 = \frac{1}{5-2} (0.0^2 + (-0.2)^2 + (-1.6)^2 + 1.1^2 + 0.7^2) = 1.43333$$

によって与えられる。

s は「回帰の標準誤差 (Standard Error of Regression)」と呼ばれ, この例では, $s = \sqrt{1.43333} = 1.197$ となる。

$\hat{\alpha}$, $\hat{\beta}$ の分散の不偏推定量

$\hat{\alpha}$ と $\hat{\beta}$ の分散は,

$$V(\hat{\alpha}) = \sigma_{\hat{\alpha}}^2 = \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}, \quad V(\hat{\beta}) = \sigma_{\hat{\beta}}^2 = \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

によって, 与えられる。

σ^2 をその不偏分散 s^2 に置き換えることによって, $\hat{\alpha}$, $\hat{\beta}$ の分散の不偏推定量を次のように得ることができる。

$$s_{\hat{\alpha}}^2 = \frac{s^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}, \quad s_{\hat{\beta}}^2 = \frac{s^2}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

さらに, 平方根をとって, $\hat{\alpha}$, $\hat{\beta}$ の標準誤差はそれぞれ,

$$s_{\hat{\alpha}} = s \sqrt{\frac{\sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}}, \quad s_{\hat{\beta}} = \frac{s}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}}$$

として与えられる。

数値例: $s^2 = 1.43333$ なので,

$$s_{\hat{\beta}}^2 = \frac{s^2}{\sum_{i=1}^n (X_i - \bar{X})^2} = \frac{s^2}{\sum_{i=1}^n X_i^2 - n\bar{X}^2} = 1.433333 \times 0.1 = 0.1433333$$

$$s_{\hat{\alpha}}^2 = \frac{s^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2} = \frac{s^2 \sum_{i=1}^n X_i^2}{n(\sum_{i=1}^n X_i^2 - n\bar{X}^2)} = 1.433333 \times 1.1 = 1.5766667$$

$\hat{\alpha}$, $\hat{\beta}$ の標準誤差はそれぞれ、平方根をとって、

$$s_{\hat{\beta}} = \sqrt{0.1433333} = 0.3786, \quad s_{\hat{\alpha}} = \sqrt{1.5766667} = 1.25565$$

となる。

6.3.5 $\hat{\alpha}$, $\hat{\beta}$ の分布

$\hat{\beta}$ について：

$$\hat{\beta} = \beta + \frac{\sum_{i=1}^n (X_i - \bar{X})u_i}{\sum_{i=1}^n (X_i - \bar{X})^2} = \beta + \sum_{i=1}^n \omega_i u_i$$

$u_i \sim N(0, \sigma^2)$ で、かつ、それぞれ独立に分布する。また、 $\hat{\beta}$ の平均、分散はそれぞれ、

$$E(\hat{\beta}) = \beta, \quad V(\hat{\beta}) = \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2},$$

となるので、

$$\hat{\beta} \sim N\left(\beta, \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2}\right),$$

を得る。変形すると、

$$\frac{\hat{\beta} - \beta}{\sigma / \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}} \sim N(0, 1),$$

となる。

さらに、

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

となり (証明略), $\hat{\beta}$ とは独立なので (証明略),

$$\frac{\hat{\beta} - \beta}{\sigma / \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}} = \frac{\hat{\beta} - \beta}{s / \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}} \sim t(n-2)$$

結果的には, σ を s で置き換えることによって,

$$\frac{\hat{\beta} - \beta}{\sigma / \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}} \sim N(0, 1) \quad \Rightarrow \quad \frac{\hat{\beta} - \beta}{s / \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}} \sim t(n-2)$$

が得られる。

$\hat{\alpha}$ について :

また, $\hat{\alpha}$ の平均, 分散はそれぞれ,

$$E(\hat{\alpha}) = \alpha, \quad V(\hat{\alpha}) = \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2},$$

となるので,

$$\hat{\alpha} \sim N\left(\alpha, \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}\right),$$

を得る。変形すると,

$$\frac{\hat{\alpha} - \alpha}{\sigma \sqrt{\frac{\sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}}} \sim N(0, 1),$$

となる。

さらに,

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

となり (証明略), $\hat{\alpha}$ とは独立なので (証明略),

$$\frac{\hat{\alpha} - \alpha}{\sigma \sqrt{\frac{\sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}}} = \frac{\hat{\alpha} - \alpha}{s \sqrt{\frac{\sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}}} \sim t(n-2)$$

結果的に見ると, σ を s で置き換えると,

$$\frac{\hat{\alpha} - \alpha}{\sigma \sqrt{\frac{\sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}}} \sim N(0, 1) \quad \Rightarrow \quad \frac{\hat{\alpha} - \alpha}{s \sqrt{\frac{\sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}}} \sim t(n-2)$$

となる。

まとめ：

$$\frac{\hat{\beta} - \beta}{s_{\hat{\beta}}} \sim t(n-2), \quad \frac{\hat{\alpha} - \alpha}{s_{\hat{\alpha}}} \sim t(n-2)$$

ただし,

$$s_{\hat{\beta}} = \frac{s}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}}, \quad s_{\hat{\alpha}} = s \sqrt{\frac{\sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2}}$$

とする。 $s_{\hat{\beta}}$ は $\hat{\beta}$ の標準誤差, $s_{\hat{\alpha}}$ は $\hat{\alpha}$ の標準誤差とそれぞれ呼ばれる。

6.3.6 α , β の区間推定 (信頼区間)

$\hat{\alpha}$, $\hat{\beta}$ の分布は, 以下のように得られた。

$$\frac{\hat{\beta} - \beta}{s_{\hat{\beta}}} \sim t(n-2), \quad \frac{\hat{\alpha} - \alpha}{s_{\hat{\alpha}}} \sim t(n-2),$$

$t_{\alpha/2}(n-2)$, $t_{1-\alpha/2}(n-2)$ をそれぞれ自由度 $n-2$ の t 分布の上側から $100 \times \frac{\alpha}{2}$ %点, $100 \times (1 - \frac{\alpha}{2})$ %点の値とする。ただし, この α と切片の α は異なるものなので注意すること。このとき,

$$\text{Prob}\left(t_{1-\alpha/2}(n-2) < \frac{\hat{\beta} - \beta}{s_{\hat{\beta}}} < t_{\alpha/2}(n-2)\right) = 1 - \alpha,$$

すなわち, t 分布はゼロを中心として左右対称なので, $t_{1-\alpha/2}(n-2) = -t_{\alpha/2}(n-2)$ となり,

$$\text{Prob}\left(-t_{\alpha/2}(n-2) < \frac{\hat{\beta} - \beta}{s_{\hat{\beta}}} < t_{\alpha/2}(n-2)\right) = 1 - \alpha,$$

を得る。ただし, 自由度と α が決まれば, $t_{\alpha/2}(n-2)$ は t 分布表から得られる。書き直して,

$$\text{Prob}\left(\hat{\beta} - t_{\alpha/2}(n-2)s_{\hat{\beta}} < \beta < \hat{\beta} + t_{\alpha/2}(n-2)s_{\hat{\beta}}\right) = 1 - \alpha,$$

と表される。

したがって, $\hat{\beta}$, $s_{\hat{\beta}}$ を推定値で置き換えて, 信頼係数 $1 - \alpha$ の β の信頼区間は,

$$\left(\hat{\beta} - t_{\alpha/2}(n-2)s_{\hat{\beta}}, \hat{\beta} + t_{\alpha/2}(n-2)s_{\hat{\beta}}\right)$$

となる。

同様に, 信頼係数 $1 - \alpha$ (この α は確率) の α (この α は切片) の信頼区間は,

$$\left(\hat{\alpha} - t_{\alpha/2}(n-2)s_{\hat{\alpha}}, \hat{\alpha} + t_{\alpha/2}(n-2)s_{\hat{\alpha}}\right)$$

となる。

数値例: 今までと同様に, 以下の数値例をとりあげる。

i	X_i	Y_i
1	5	4
2	1	1
3	3	1
4	2	3
5	4	4

回帰モデル $Y_i = \alpha + \beta X_i + u_i$ を推定した結果、以下の推定値を得た。

$$\hat{\beta} = 0.7, \quad \hat{\alpha} = 0.5$$

$$s_{\hat{\beta}} = \sqrt{0.1433333} = 0.3786, \quad s_{\hat{\alpha}} = \sqrt{1.5766667} = 1.25565$$

$t_{0.025}(3) = 3.1824$ なので、信頼係数 0.95 の傾き β の信頼区間は、

$$(0.7 - 3.1824 \times 0.3786, 0.7 + 3.1824 \times 0.3786) = (-0.505, 1.905)$$

となり、信頼係数 0.95 の切片 α の信頼区間は、

$$(0.5 - 3.1824 \times 1.25565, 0.5 + 3.1824 \times 1.25565) = (-3.496, 4.496)$$

となる。

同様にして、 $t_{0.05}(3) = 2.3534$ なので、信頼係数 0.90 の傾き β の信頼区間は、

$$(0.7 - 2.3534 \times 0.3786, 0.7 + 2.3534 \times 0.3786) = (-0.191, 1.591)$$

となり、信頼係数 0.90 の切片 α の信頼区間は、

$$(0.5 - 2.3534 \times 1.25565, 0.5 + 2.3534 \times 1.25565) = (-2.455, 3.455)$$

となる。

6.3.7 α , β の仮説検定

「帰無仮説 $H_0 : \beta = \beta_0$, 対立仮説 $H_1 : \beta \neq \beta_0$ 」の検定を行う。帰無仮説：
 $H_0 : \beta = \beta_0$ が正しいとき、

$$\frac{\hat{\beta} - \beta_0}{s_{\hat{\beta}}} \sim t(n-2),$$

となる。

よって、検定の手順は、

1. 検定統計値 $\frac{\hat{\beta} - \beta_0}{s_{\hat{\beta}}}$ を計算する。ただし、

$$s_{\hat{\beta}}^2 = \frac{s^2}{\sum_{i=1}^n (X_i - \bar{X})^2}, \quad s^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{u}_i^2, \quad \hat{u}_i = Y_i - \hat{\alpha} - \hat{\beta}X_i,$$

$$\hat{\beta} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2}, \quad \hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X},$$

である。

2. 有意水準 α を決めて (この α は、回帰式の定数項の α とは異なることに注意), 自由度 $n-2$ の t 分布表から $100 \times \alpha \%$ 点の値を求める。通常, $\alpha = 0.01, 0.05$ とす場合が多い。
3. 自由度 $n-2$ の t 分布表から得られた $100 \times \alpha \%$ 点の値と検定統計値の大小を比較する。すなわち、

$$\left| \frac{\hat{\beta} - \beta_0}{s_{\hat{\beta}}} \right| > t_{\alpha/2}(n-2),$$

ならば、有意水準 α で帰無仮説 $H_0 : \beta = \beta_0$ を棄却する。帰無仮説 $H_0 : \beta = \beta_0$ を中心とした分布を考えると、データから得られた検定統計量は、分布の端にあり、確率的に起こりにくいと考える。

となる。

定数項の推定量 $\hat{\alpha}$ についても同様。

t 値について

特に、「帰無仮説 : $H_0 : \beta = 0$, 対立仮説 : $H_1 : \beta \neq 0$ 」の検定は特別の意味を持つ。

帰無仮説のもとでは (「帰無仮説が正しいとき」と同じ意味),

$$\frac{\hat{\beta}}{s_{\hat{\beta}}} \sim t(n-2)$$

の分布に従う。

このときの t 統計量の値 (すなわち, $\frac{\hat{\beta}}{s_{\hat{\beta}}}$) を t 値と呼ぶ。

$H_0: \beta = 0$ という帰無仮説は, 回帰式

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

において, 「 X_i が Y_i に何の影響も与えない」という仮説であることを意味する。

有意水準 α のもとで (この α は, 回帰式の定数項の α とは異なることに注意),

$$\left| \frac{\hat{\beta}}{s_{\hat{\beta}}} \right| > t_{\alpha/2}(n-2)$$

ならば, 有意水準 α で帰無仮説 $H_0: \beta = 0$ を棄却する。

1. 回帰モデル

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

において, 経済理論から $\beta > 0$ という符号条件が想定されたとする。

2. 有意水準 α を決める。(例えば, $\alpha = 0.05, 0.01$)

3. 実際のデータから, $\hat{\beta} > 0$ が得られた場合

(a) t 値が,

$$\frac{\hat{\beta}}{s_{\hat{\beta}}} > t_{\alpha/2}(n-2)$$

となった場合, 帰無仮説 $H_0: \beta = 0$ が棄却され, $\beta > 0$ が統計的にも証明され, 経済理論は現実経済をサポートする結果。

(b) t 値が,

$$\frac{\hat{\beta}}{s_{\hat{\beta}}} < t_{\alpha/2}(n-2)$$

となった場合, 帰無仮説 $H_0: \beta = 0$ を棄却できず, $\hat{\beta} > 0$ にもかかわらず, $\beta < 0$ の可能性もあるため, 経済理論が現実経済を積極的には支持しない。

4. 実際のデータから、 $\hat{\beta} < 0$ が得られた場合(a) t 値が,

$$-t_{\alpha/2}(n-2) < \frac{\hat{\beta}}{s_{\hat{\beta}}}$$

となった場合、帰無仮説 $H_0: \beta = 0$ を棄却できず、 $\hat{\beta} < 0$ にもかかわらず、 $\beta > 0$ の可能性もあるため、得られた推定結果と経済理論は完全に矛盾しているとは言えない。

(b) t 値が,

$$-t_{\alpha/2}(n-2) > \frac{\hat{\beta}}{s_{\hat{\beta}}}$$

となった場合、帰無仮説 $H_0: \beta = 0$ は棄却され、統計的には $\beta < 0$ となり、得られた推定結果と経済理論は完全に矛盾している。すなわち、この場合、経済理論の立て直しが必要。

数値例： 今までと同様に、以下の数値例を取りあげる。

i	X_i	Y_i
1	5	4
2	1	1
3	3	1
4	2	3
5	4	4

回帰モデル $Y_i = \alpha + \beta X_i + u_i$ を推定した結果、以下の推定値を得た。

$$\hat{\beta} = 0.7, \quad s_{\hat{\beta}} = \sqrt{0.1433333} = 0.3786,$$

帰無仮説 $H_0: \beta = 0$ 、対立仮説 $H_0: \beta \neq 0$ の検定を行う。 t 値は $0.7/0.3786 = 1.849$ 、有意水準 5% の $t_{\alpha/2}(n-2)$ の値は 3.1824 となり ($\alpha = 0.05, n = 5$),

$$\frac{\hat{\beta}}{s_{\hat{\beta}}} = \frac{0.7}{\sqrt{0.1433333}} = 1.849 < t_{\alpha/2}(n-2) = 3.1824$$

を得る。このように、有意水準 5% で帰無仮説 $H_0: \beta = 0$ は棄却されない。よって、 β の符号は統計学的に確定できない。

また、 α についても同様に、 t 値を計算できる。

$$\hat{\alpha} = 0.5, \quad s_{\hat{\alpha}} = \sqrt{1.5766667} = 1.25565,$$

なので、 t 値は、

$$\frac{\hat{\alpha}}{s_{\hat{\alpha}}} = \frac{0.5}{\sqrt{1.5766667}} = 0.398 < t_{\alpha/2}(n-2) = 3.1824,$$

となり、有意水準 5% で $H_0: \alpha = 0$ を棄却できない。

しかし、定数項については、経済学的意味が無い場合が多い。

推定結果の表記方法： 回帰モデル：

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

の推定の結果、 $\hat{\alpha} = 0.5$, $\hat{\beta} = 0.7$, $s_{\hat{\alpha}} = \sqrt{1.5766667} = 1.25565$, $s_{\hat{\beta}} = \sqrt{0.1433333} = 0.3786$, $\frac{\hat{\alpha}}{s_{\hat{\alpha}}} = 0.398$, $\frac{\hat{\beta}}{s_{\hat{\beta}}} = 1.849$, $s^2 = 1.433333$ (すなわち、 $s = 1.197$), $R^2 = 0.5326$, $\bar{R}^2 = 0.3768$, を得た。これらをまとめて、

$$Y_i = \underset{(0.398)}{0.5} + \underset{(1.849)}{0.7} X_i,$$

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

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。

または、

$$Y_i = \underset{(1.25565)}{0.5} + \underset{(0.3786)}{0.7} X_i,$$

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

ただし、係数の推定値の下の括弧内は標準誤差を表すものとする。

のように書く。

6.4 確率的モデル：重回帰モデル

n 組のデータ $(Y_i, X_{1i}, X_{2i}, \dots, X_{ki}), i = 1, 2, \dots, n$ を用いて、 k 変数の多重回帰モデルを考える。

$$Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i,$$

ただし、 X_{ji} は j 番目の説明変数の第 i 番目の観測値を表す。 u_i は誤差項（または、攪乱項）で、同じ仮定を用いる（すなわち、 u_1, u_2, \dots, u_n は互いに独立に、平均ゼロ、分散 σ^2 の正規分布に従う）。 $\beta_1, \beta_2, \dots, \beta_k$ は推定されるべきパラメータである。すべての i について、 $X_{1i} = 1$ とすれば、 β_1 は定数項として表される。

6.4.1 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、

$$E(\hat{\beta}_j) = \beta_j, \quad \text{plim } \hat{\beta}_j = \beta_j, \quad E(s^2) = \sigma^2, \quad \text{plim } s^2 = \sigma^2,$$

を証明することが出来る。（証明略）

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

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

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

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

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

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 の独立性から（証明略）、

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

となる。このように、通常の区間推定や仮説検定を行うことが出来る。

(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 をその推定値 \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、 $s^2 = \frac{1}{n-k} \sum_{i=1}^n \hat{u}_i^2$ 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値) を求めなければならない。 $n-k$ (= データ数 - パラメータ数) を自由度と呼ばれる。