

$k = 2$ の単純なモデル：

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

β_1, β_2 の最小二乗推定量は，

$$\min_{\beta_1, \beta_2} \sum_{i=1}^n (Y_i - \beta_1 X_{1i} - \beta_2 X_{2i})^2$$

を解いて， $\hat{\beta}_1$ ， $\hat{\beta}_2$ が次のように得られる。

$$\begin{aligned} \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} &= \begin{pmatrix} \sum X_{1i}^2 & \sum X_{1i}X_{2i} \\ \sum X_{1i}X_{2i} & \sum X_{2i}^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum X_{1i}Y_i \\ \sum X_{2i}Y_i \end{pmatrix} \\ &= \frac{1}{(\sum X_{1i}^2)(\sum X_{2i}^2) - (\sum X_{1i}X_{2i})^2} \begin{pmatrix} \sum X_{2i}^2 & -\sum X_{1i}X_{2i} \\ -\sum X_{1i}X_{2i} & \sum X_{1i}^2 \end{pmatrix} \begin{pmatrix} \sum X_{1i}Y_i \\ \sum X_{2i}Y_i \end{pmatrix} \\ &= \begin{pmatrix} \frac{(\sum X_{2i}^2)(\sum X_{1i}Y_i) - (\sum X_{1i}X_{2i})(\sum X_{2i}Y_i)}{(\sum X_{1i}^2)(\sum X_{2i}^2) - (\sum X_{1i}X_{2i})^2} \\ \frac{-\sum X_{1i}X_{2i}(\sum X_{1i}Y_i) + (\sum X_{1i}^2)(\sum X_{2i}Y_i)}{(\sum X_{1i}^2)(\sum X_{2i}^2) - (\sum X_{1i}X_{2i})^2} \end{pmatrix} \end{aligned}$$

$\sum_{i=1}^n X_{ji}X_{li}$, $\sum_{i=1}^n X_{ji}Y_i$ をそれぞれ $\sum X_{ji}X_{li}$, $\sum X_{ji}Y_i$ と表記する。

ただし, $j = 1, 2$, $l = 1, 2$ とする。

一方, 次の2つの回帰式を考える。

$$Y_i = \alpha_1 X_{2i} + v_i$$

$$X_{1i} = \alpha_2 X_{2i} + w_i$$

α_1 , α_2 のそれぞれの最小二乗推定量を求めると,

$$\hat{\alpha}_1 = \frac{\sum X_{2i}Y_i}{\sum X_{2i}^2}, \quad \hat{\alpha}_2 = \frac{\sum X_{2i}X_{1i}}{\sum X_{2i}^2}$$

となる。

$\hat{\alpha}_1$, $\hat{\alpha}_2$ を用いて, 残差 \hat{v}_i , \hat{w}_i を下記のようにそれぞれ求める。

$$\hat{v}_i = Y_i - \hat{\alpha}_1 X_{2i}, \quad \hat{w}_i = X_{1i} - \hat{\alpha}_2 X_{2i}$$

\hat{v}_i , \hat{w}_i は Y_i , X_{1i} から X_{2i} の影響を取り除いたものと解釈できる。

更に, 次の回帰式を考える。

$$\hat{v}_i = \gamma \hat{w}_i + \epsilon_i$$

γ の最小二乗推定量 $\hat{\gamma}$ は $\hat{\beta}_1$ に一致することを示す。

$$\begin{aligned} \hat{\gamma} &= \frac{\sum \hat{w}_i \hat{v}_i}{\sum \hat{w}_i^2} = \frac{\sum (X_{1i} - \hat{\alpha}_2 X_{2i})(Y_i - \hat{\alpha}_1 X_{2i})}{\sum (X_{1i} - \hat{\alpha}_2 X_{2i})^2} \\ &= \frac{\sum X_{1i} Y_i - \hat{\alpha}_1 \sum X_{1i} X_{2i} - \hat{\alpha}_2 \sum X_{2i} Y_i + \hat{\alpha}_1 \hat{\alpha}_2 \sum X_{2i}^2}{\sum X_{1i}^2 - 2\hat{\alpha}_2 \sum X_{1i} X_{2i} + \hat{\alpha}_2^2 \sum X_{2i}^2} \\ &= \frac{\sum X_{1i} Y_i - \frac{(\sum X_{2i} Y_i)(\sum X_{1i} X_{2i})}{\sum X_{2i}^2}}{\sum X_{1i}^2 - \frac{(\sum X_{1i} X_{2i})^2}{\sum X_{2i}^2}} \\ &= \frac{(\sum X_{2i}^2)(\sum X_{1i} Y_i) - (\sum X_{1i} X_{2i})(\sum X_{2i} Y_i)}{(\sum X_{1i}^2)(\sum X_{2i}^2) - (\sum X_{1i} X_{2i})^2} = \hat{\beta}_1, \end{aligned}$$

「 Y_i から X_{2i} の影響を取り除いた変数」を被説明変数、「 X_{1i} から X_{2i} の影響を取り除いた変数」を説明変数とした回帰係数が β_1 に等しい。

一般化： 次の回帰モデルを考える。

$$Y_i = \beta_1 X_{1i} + \beta_2 X_{2i} + \cdots + \beta_k X_{ki}$$

j 番目の回帰係数 β_j の意味は、「 Y_i から $X_{1i}, \dots, X_{j-1,i}, X_{j+1,i}, \dots, X_{ki}$ (すなわち, X_{ji} 以外の説明変数) の影響を取り除いた変数」を被説明変数、「 X_{ji} から $X_{1i}, \dots, X_{j-1,i}, X_{j+1,i}, \dots, X_{ki}$ (すなわち, X_{ji} 以外の説明変数) の影響を取り除いた変数」を説明変数とした回帰係数となる。

4.3.2 決定係数 R^2 と自由度修正済み決定係数 \bar{R}^2 について

また, 決定係数 R^2 についても同様に表される。

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

ただし, $\hat{Y}_i = \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \dots + \hat{\beta}_k X_{ki}$, $Y_i = \hat{Y}_i + \hat{u}_i$ 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, $\sum_{i=1}^n \hat{u}_i^2$ 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。

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

$\sum_{i=1}^n \hat{u}_i^2 / (n - k)$ は u_i の分散 σ^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。分散や不偏推定量の意味は，統計学の知識を必要とし，後述する。

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	X_i	Y_i	X_i^2	$X_i Y_i$	\hat{Y}_i	\hat{u}_i	$X_i \hat{u}_i$	$\hat{Y}_i \hat{u}_i$	\hat{u}_i^2	Y_i^2
1	5	4	25	20	4.0	0.0	0.0	0.00	0.00	16
2	1	1	1	1	1.2	-0.2	-0.2	-0.24	0.04	1
3	3	1	9	3	2.6	-1.6	-4.8	-4.16	2.56	1
4	2	3	4	6	1.9	1.1	2.2	2.09	1.21	9
5	4	4	16	16	3.3	0.7	2.8	2.31	0.49	16
合計	$\sum X_i$	$\sum Y_i$	$\sum X_i^2$	$\sum X_i Y_i$	$\sum \hat{Y}_i$	$\sum \hat{u}_i$	$\sum X_i \hat{u}_i$	$\sum \hat{Y}_i \hat{u}_i$	$\sum \hat{u}_i^2$	$\sum Y_i^2$
	15	13	55	46	13	0.0	0.0	0.0	4.3	43
平均	\bar{X}	\bar{Y}								
	3	2.6								

$\bar{Y} = 2.6$, $\sum_{i=1}^n \hat{u}_i^2 = 4.3$, $\sum_{i=1}^n Y_i^2 = 43$ なので ,

$$R^2 = 1 - \frac{\sum \hat{u}_i^2}{\sum Y_i^2 - n\bar{Y}^2} = 1 - \frac{4.3}{43 - 5 \times 2.6^2} = 1 - \frac{4.3}{9.2} = 0.5326$$

となり、 \bar{R}^2 は、

$$\bar{R}^2 = 1 - \frac{\sum \hat{u}_i^2 / (n - k)}{(\sum Y_i^2 - n\bar{Y}^2) / (n - 1)} = 1 - \frac{4.3 / (5 - 2)}{9.2 / (5 - 1)} = 0.3768$$

となる。

自由度について：分子について、残差 \hat{u}_i を求めるためには、 $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$ の k 個の推定値を得なければならない。データ数 n から推定値の数 k を差し引いたものを自由度 (degree of freedom) と呼ぶ。

一方、分母については、 X_{1i} が定数項だとして、 Y_i が定数項を除く $X_{2i}, X_{3i}, \dots, X_{ki}$ に依存しない場合を考える。この場合、 $\beta_2 = \beta_3 = \dots = \beta_k = 0$ とするので、 $\hat{u}_i = Y_i - \hat{\beta}_1$ となる。 \hat{u}_i を得るためには $\hat{\beta}_1$ だけを求めればよい。最小二乗法の考え方に沿って求めれば、 $\hat{\beta}_1 = \bar{Y}$ となる（読者は確認すること）。すなわち、自由度は「データ数 - 推定値の数 = $n - 1$ 」ということになる。

このように、決定係数の第二項目の分子・分母をそれぞれの自由度で割ることによって、自由度修正済み決定係数が得られる。

注意： R^2 や \bar{R}^2 を比較する場合，被説明変数が同じであることが重要である。被説明変数が対数かまたはそのままの値であれば，決定係数・自由度修正済み決定係数の大小比較は意味をなさない。ただし，被説明変数が異なる場合であっても，被説明変数を上昇率とするかそのままの値を用いるかの比較では，決定係数・自由度修正済み決定係数の大小比較はできないが，誤差項 u_i の標準誤差での比較は可能である（標準誤差の小さいモデルを採用する）。⇒ 関数型の選択

第5章 統計学の基礎：復習

5.1 確率変数，確率分布について

確率変数は，通常，大文字のアルファベット（例えば， X ）で表すのに対して，実際に起こった値（すなわち，実現値）を小文字（例えば， x ）で表す。

確率変数には離散型確率変数と連続型確率変数がある。まず，離散型確率変数 X を考える。 X の取り得る値は分かっている。例えば， $X = x_1, x_2, \dots, x_n$ の n 通りの値を取るものとする。それぞれの値には確率が割り当てられる。すなわち， $\text{Prob}(X = x_i) = p_i$ と表記し，「確率変数 X が x_i を取る確率は p_i である」と読む。 p_i は確率であり，しかも， X は x_1, x_2, \dots, x_n のいずれかの値を取るのので， $\sum_{i=1}^n p_i = 1$ となる。また， p_i は x_i の関数であり， $f(x_i)$ と表すことができ

る。 $f(x_i)$ を確率関数と呼ぶ。 $f(x_i)$ は、(i) $f(x_i) \geq 0$ 、(ii) $\sum_{i=1}^n f(x_i) = 1$ を満たす関数でなければならない。

X をサイコロを投げて出た目としよう。このとき、 X の取る値は $1, 2, 3, 4, 5, 6$ で、それぞれの目が出る確率は $\frac{1}{6}$ となる。したがって、 $x_i = i, p_i = \frac{1}{6}, i = 1, 2, 3, 4, 5, 6$ となる。

X が連続型確率変数の場合は、ある値 a から別の値 b までの区間に入る確率 $\text{Prob}(a < X < b)$ という意味になる（ただし、 $a < b$ ）。この場合、 $f(x), x = a, x = b, x$ 軸で囲まれた面積が確率を表すことになる。すなわち、

$$\text{Prob}(a < X < b) = \int_a^b f(x)dx,$$

となり、 $f(x)$ を確率密度関数、または、密度関数と呼ぶ。 $f(x)$ は、(i) $f(x) \geq 0$ 、(ii) $\int_{-\infty}^{\infty} f(x)dx = 1$ を満たす連続関数でなければならない。

離散型の $f(\cdot)$ と連続型の $f(\cdot)$ の違いは、前者は $f(\cdot)$ そのものが確率を表すのに対して、後者の $f(\cdot)$ は面積が確率を表す（すなわち、連続型の $f(\cdot)$ の高さは確率を表さない）。

分布関数（累積分布関数）： 分布関数（累積分布関数） $F(x)$ は，

$$F(x) = \text{Prob}(X \leq x) = \begin{cases} \sum_{i=1}^r f(x_i) & X \text{ が離散型確率変数のとき} \\ \int_{-\infty}^x f(t) dt & X \text{ が連続型確率変数のとき} \end{cases}$$

ただし，離散型の場合， r は $x_r \leq x < x_{r+1}$ となる r である。すなわち，離散型の場合， $F(x)$ は 0 と 1 の間の階段状（階段関数）となる。

同時確率分布： 2つの確率変数 X, Y を考える。離散型の場合， X の取る値を x_1, x_2, \dots, x_n とし， Y の取る値を y_1, y_2, \dots, y_m としたとき， X が x_i を取り，かつ， Y が y_j を取る確率を同時確率分布と呼び，下記のように表す。

$$\text{Prob}(X = x_i, Y = y_j) = p_{ij}$$

p_{ij} は x_i, y_j の関数となり， $p_{ij} = f(x_i, y_j)$ と表す。 $f(x_i, y_j)$ を同時確率関数と呼ぶ。

連続型の場合は， X が c と d の間の値（ただし， $a < b$ ）を取り，かつ， Y が c と d の間の値（ただし， $c < d$ ）を取る確率は，下記のように表される。

$$\text{Prob}(a < X < b, c < Y < d) = \int_a^b \int_c^d f(x, y) dy dx$$

$f(x, y)$ を同時確率密度関数（または，同時密度関数）と呼ぶ。

5.2 期待値・分散・共分散の定義・定理

5.2.1 期待値の定義

定義（期待値，1変数）： 確率変数 X ，ある関数 $g(\cdot)$ とするとき， $g(X)$ の期待値は次のように定義される。

$$E(g(X)) = \begin{cases} \sum_{i=1}^n g(x_i) f(x_i), & X \text{ が離散型確率変数のとき} \\ \int_{-\infty}^{\infty} g(x) f(x) dx, & X \text{ が連続型確率変数のとき} \end{cases} \quad (5.1)$$

ただし, $f(\cdot)$ は確率関数 (離散型するとき), または, 密度関数 (連続型するとき) を表す。

定義 (期待値, 2変数): 確率変数 X, Y , ある関数 $g(\cdot, \cdot)$ とするとき, $g(X, Y)$ の期待値は次のように定義される。

$$E(g(X, Y)) = \begin{cases} \sum_{i=1}^n \sum_{j=1}^m g(x_i, y_j) f(x_i, y_j), & X, Y \text{ が離散型確率変数のとき} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f(x, y) dy dx, & X, Y \text{ が連続型確率変数のとき} \end{cases} \quad (5.2)$$

ただし, $f(\cdot, \cdot)$ は確率関数 (離散型するとき), または, 密度関数 (連続型するとき) を表す。

2変数 (X, Y) を n 変数 (X_1, X_2, \dots, X_n) に拡張することも出来る。

5.2.2 期待値の定理

定理 (1 変数) : X を確率変数とする。 $a + bX$ の期待値は ,

$$E(a + bX) = a + bE(X), \quad (5.3)$$

となる。ただし , a, b は定数とする。 $g(X) = a + bX$ に対応する。

定理 (2 変数) : X, Y を確率変数とする。 $X + Y$ の期待値は ,

$$E(X + Y) = E(X) + E(Y), \quad (5.4)$$

となる。 $g(X, Y) = X + Y$ に対応する。

定理 (多変数) : n 個の確率変数 X_1, X_2, \dots, X_n を考える。このとき , $\sum_{i=1}^n c_i X_i$ の平均は ,

$$E\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i E(X_i), \quad (5.5)$$

となる。

5.2.3 分散・共分散の定義・定理

定義 (1 変数): X を確率変数とする。 X の分散 $\sigma^2 = V(X)$ は,

$$\sigma^2 = V(X) = E((X - \mu)^2), \quad (5.6)$$

である。ただし, $\mu = E(X)$ とする。 $g(X) = (X - \mu)^2$ に対応する。

定義 (1 変数): X を確率変数とする。 X の標準偏差 σ は,

$$\sigma = \sqrt{V(X)} \quad (5.7)$$

である。

定理 (1 変数): X を確率変数とする。 X の分散は,

$$V(X) = E(X^2) - \mu^2, \quad (5.8)$$

と書き換えられる。ただし, $\mu = E(X)$ とする。

定理 (1 変数)： X を確率変数とする。 $a + bX$ の分散は，

$$V(a + bX) = V(bX) = b^2 V(X), \quad (5.9)$$

となる。ただし， a, b は定数とする。

定理 (1 変数)： X を平均 μ ，分散 σ^2 の確率変数とする。 $Z = \frac{X - \mu}{\sigma}$ について，

$$E(Z) = 0, \quad V(Z) = 1, \quad (5.10)$$

となる。この変換を標準化，または，基準化と呼ぶ。

定義 (2 変数)： X, Y を確率変数とする。 X と Y の共分散 $\sigma_{XY} = \text{Cov}(X, Y)$ は，

$$\sigma_{XY} = \text{Cov}(X, Y) = E((X - \mu_X)(Y - \mu_Y)), \quad (5.11)$$

となる。 $\text{Cov}(X, Y)$ について， $g(X, Y) = (X - \mu_X)(Y - \mu_Y)$ に対応する。

定義 (2 変数): X, Y を確率変数とする。 X と Y の相関係数 ρ_{XY} は,

$$\rho_{XY} = \frac{\text{Cov}(X, Y)}{\sqrt{V(X)} \sqrt{V(Y)}} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}, \quad (5.12)$$

となる。ただし, $\sigma_X^2 = V(X)$, $\sigma_Y^2 = V(Y)$ とする。

定理 (2 変数): X, Y を確率変数とする。 X と Y の共分散は,

$$\text{Cov}(X, Y) = E(XY) - \mu_X \mu_Y, \quad (5.13)$$

と書き換えられる。 $E(XY)$ について, $g(X, Y) = XY$ に対応する。

定理 (2 変数): X, Y を確率変数とする。 $X + Y$ の分散は,

$$V(X + Y) = V(X) + 2\text{Cov}(X, Y) + V(Y), \quad (5.14)$$

となる。

定理 (2 変数)： X, Y を確率変数とする。 X と Y が独立のとき， X と Y の共分散は，

$$\text{Cov}(X, Y) = 0, \quad (5.15)$$

となる。

定理 (2 変数)： X, Y を確率変数とする。 X と Y が独立のとき， $X + Y$ の分散は，

$$V(X + Y) = V(X) + V(Y), \quad (5.16)$$

となる。

定理 (多変数)： n 個の独立な確率変数 X_1, X_2, \dots, X_n を考える。このとき， $\sum_{i=1}^n c_i X_i$ の分散は，

$$V\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i^2 V(X_i), \quad (5.17)$$

となる。

5.3 正規分布について

確率変数 X の密度関数 $f(x)$ が,

$$f(x) = (2\pi\sigma^2)^{-1/2} \exp\left(-\frac{1}{2\sigma^2}(x - \mu)^2\right),$$

となるとき, $f(x)$ を正規分布と呼ぶ。ただし, $\exp(x) = e^x$ である。 e は自然対数の底と呼ばれ, $e = \lim_{n \rightarrow \infty} \left(1 + \frac{1}{n}\right)^n = 2.7182818284590452353602874713\dots$ と定義される。

上記の正規分布は,

$$E(X) = \mu, \quad V(X) = \sigma^2,$$

となる (期待値の定義通りに計算すればよい)。

確率変数 X が上記の密度関数 $f(x)$ となるとき, $X \sim N(\mu, \sigma^2)$ と表す。 $X \sim N(\mu, \sigma^2)$ とは, 「 X は平均 μ , 分散 σ^2 の正規分布に従う」という意味である。すなわち, N は正規分布 (Normal distribution) のアルファベットの頭文字で, \sim は「に従う」と読む。

定理（標準化，基準化）： (5.10) のように X を基準化する。

$$X \sim N(\mu, \sigma^2) \quad \text{のとき,} \quad Z = \frac{X - \mu}{\sigma} \sim N(0, 1) \quad (5.18)$$

基準化によって， X がどの分布に従う確率変数であっても，平均 0，分散 1 に変換することができるということを (5.10) の定理は示している。(5.18) では，さらに進んで， X が正規分布であれば， Z も正規分布となるということを言っている。この証明は，変数変換（置換積分）を利用して証明することになる（本書では証明略）。平均 0，分散 1 の正規分布 $N(0, 1)$ は，標準正規分布と呼ばれる。

標準正規分布の確率分布表があれば，一般の正規分布の確率を得ることが出来る。すなわち， μ と σ^2 が既知とするとき， Z が z より大きい確率 $\text{Prob}(Z > z)$ について， $\text{Prob}(Z > z) = \text{Prob}(X > \mu + z\sigma)$ となる。同様に， X が x より大きい確率 $\text{Prob}(X > x)$ について， $\text{Prob}(X > x) = \text{Prob}\left(Z > \frac{x - \mu}{\sigma}\right)$ となる。320 ページの付表 1 を用いると，標準正規分布の確率，すなわち， $\text{Prob}(Z > z)$ を求めることができる。

(5.5) 式と (5.16) 式によって， n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の

分布（平均，分散が同じ分布）に従うとき， $\sum_{i=1}^n c_i X_i$ の平均，分散は，

$$E\left(\sum_{i=1}^n c_i X_i\right) = \mu \sum_{i=1}^n c_i, \quad V\left(\sum_{i=1}^n c_i X_i\right) = \sigma^2 \sum_{i=1}^n c_i^2$$

となる。ただし，すべての i について $\mu = E(X_i)$, $\sigma^2 = V(X_i)$ とする。

n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の正規分布に従うものとする。すなわち，すべての i について $X_i \sim N(\mu, \sigma^2)$ とする。このとき，

$$\sum_{i=1}^n c_i X_i \sim N\left(\mu \sum_{i=1}^n c_i, \sigma^2 \sum_{i=1}^n c_i^2\right)$$

となる。すなわち，正規分布に従う確率変数の加重和もまた正規分布となる。この証明はそれほど簡単ではなく，積率母関数を利用して証明することになる（本書では証明略）。

特に，標本平均 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ を考えると，

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

となる（すべての i について， $c_i = \frac{1}{n}$ の場合を考えればよい）。

5.4 統計値・統計量，推定値・推定量について

1. 理論標本，理論観測値 $\Rightarrow X_1, X_2, \dots, X_n \Rightarrow$ 確率変数
2. 実現された標本，実現された観測値，実現値，観測値 $\Rightarrow x_1, x_2, \dots, x_n$
 \Rightarrow 観測データ
1. 理論観測値 X_1, X_2, \dots, X_n の関数 \Rightarrow 統計量
2. すべての i について， $\mu = E(X_i)$ と仮定する。
3. 母平均 μ の推定に使われる統計量 $\Rightarrow \mu$ の推定量

(a) $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ は μ の推定量

$$(b) S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \text{ は } \sigma^2 \text{ の推定量}$$

4. 実現された標本を用いて実際に計算された推定量の値 \Rightarrow 推定値

$$(a) \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \text{ は } \mu \text{ の推定値}$$

$$(b) s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \text{ は } \sigma^2 \text{ の推定値}$$

5. μ や σ^2 の推定量の候補は無数に考えられる。

5.5 大数の法則と中心極限定理

5.5.1 大数の法則

大数の法則：その1 n 個の確率変数 X_1, X_2, \dots, X_n は互いに独立ですべて同じ分布にしたがい、すべての $i = 1, 2, \dots, n$ について $E(X_i) = \mu$ とする。 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$

(すなわち、標本平均) とする。

$n \rightarrow \infty$ のとき、

$$\bar{X} \rightarrow \mu$$

となる。

大数の法則：その2 n 個の確率変数 X_1, X_2, \dots, X_n を考える (互いに独立である必要はなく、同じ分布である必要もない)。

$$\mu = \lim_{n \rightarrow \infty} \frac{1}{n} E\left(\sum_{i=1}^n X_i\right) < \infty, \quad \sigma^2 = \lim_{n \rightarrow \infty} \frac{1}{n} V\left(\sum_{i=1}^n X_i\right) < \infty$$

とする。

$n \rightarrow \infty$ のとき ,

$$\bar{X} \rightarrow \mu$$

となる。

5.5.2 中心極限定理

中心極限定理：その n 個の確率変数 X_1, X_2, \dots, X_n は互いに独立ですべて同じ分布にしたがい , すべての $i = 1, 2, \dots, n$ について $E(X_i) = \mu$, $V(X_i) = \sigma^2$ とす

る。 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ とする。

$n \rightarrow \infty$ のとき ,

$$\frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \rightarrow N(0, 1)$$

となる。 $E(\bar{X}) = \mu$, $V(\bar{X}) = \sigma^2/n$ に注意せよ。

中心極限定理：その2 n 個の確率変数 X_1, X_2, \dots, X_n を考える（互いに独立である必要はなく，同じ分布である必要もない）。

$$\mu = \lim_{n \rightarrow \infty} \frac{1}{n} E\left(\sum_{i=1}^n X_i\right) < \infty, \quad \sigma^2 = \lim_{n \rightarrow \infty} \frac{1}{n} V\left(\sum_{i=1}^n X_i\right) < \infty$$

とする。

$n \rightarrow \infty$ のとき，

$$\frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \rightarrow N(0, 1)$$

となる。

5.6 推定量の望ましい性質

$\hat{\alpha}, \hat{\beta}$ の性質を求めるために

5.6.1 不偏性

ある母集団のある母数 θ に対して, θ の推定量として $\hat{\theta}$ を考える。このとき,

$$E(\hat{\theta}) = \theta$$

となるとき, $\hat{\theta}$ は θ の不偏推定量であると言う。 $\hat{\theta}$ は不偏性を持つと言う。 $E(\hat{\theta}) - \theta$ は偏りと定義される。

n 個の確率変数 X_1, X_2, \dots, X_n に関して, すべての $i = 1, 2, \dots, n$ について $E(X_i) = \mu$ とするとき, 標本平均 \bar{X} は μ の不偏推定量である。

証明:

$$E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \sum_{i=1}^n \mu = \mu$$

このように, $E(\bar{X}) = \mu$ なので, 標本平均 \bar{X} は μ の不偏推定量となる。

5.6.2 有効性 (最小分散性)

ある母数 θ に対して, $\hat{\theta}_1$ と $\hat{\theta}_2$ の 2 つの不偏推定量を考える。このとき, $V(\hat{\theta}_1) \leq V(\hat{\theta}_2)$ が成り立つとき, $\hat{\theta}_1$ は $\hat{\theta}_2$ より有効であると言う。

ある母数 θ に対して、可能なすべての不偏推定量を考え、 $\hat{\theta}$ が最も小さな分散を持つ不偏推定量であるとする。このとき、 $\hat{\theta}$ を最小分散不偏推定量、または、最良不偏推定量と言う。

一般に、有効推定量が存在するとは限らない。代わりに、推定量 $\sum_{i=1}^n c_i X_i$ (すなわち、線形推定量) の中で最も小さい分散を持つ推定量を求めることを考える。この推定量を最良線形不偏推定量と呼ぶ。

標本平均 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ は不偏推定量の中で最も小さな分散を持つ推定量である。

証明：

期待値を取ると、

$$E\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n c_i E(X_i) = \mu \sum_{i=1}^n c_i$$

となる。 $\sum_{i=1}^n c_i X_i$ が不偏推定量になるためには $\sum_{i=1}^n c_i = 1$ が必要となる。分散は、

$$V\left(\sum_{i=1}^n c_i X_i\right) = \sum_{i=1}^n V(c_i X_i) = \sum_{i=1}^n c_i^2 V(X_i) = \sigma^2 \sum_{i=1}^n c_i^2$$

となる。

したがって、最良線形不偏推定量を得るためには、 $\sum_{i=1}^n c_i = 1$ の条件のもとで、 $\sum_{i=1}^n c_i^2$ を最小にする c_1, c_2, \dots, c_n を求めればよい。ラグランジェ未定乗数法を用いれば、 $c_i = \frac{1}{n}$ が得られる。

5.6.3 一致性

ある母数 θ について推定量 $\hat{\theta}$ を考える。 n 個の標本から構成された推定量を $\hat{\theta}^{(n)}$ と定義する。数列 $\hat{\theta}^{(1)}, \hat{\theta}^{(2)}, \dots, \hat{\theta}^{(n)}, \dots$ を考える。十分大きな n について、

$\hat{\theta}^{(n)}$ が θ に確率的に収束するとき、 $\hat{\theta}$ は θ の一致推定量であると言う。

$$\hat{\theta} \rightarrow \theta, \quad \text{または,} \quad \text{plim } \hat{\theta} = \theta,$$

と表現する。plim とは probability limit の略である。

$E(\hat{\theta}) = \theta$ とする。 $n \rightarrow \infty$ のとき $V(\hat{\theta}) \rightarrow 0$ が成り立てば、 $\hat{\theta}$ は θ の一致推定量である。

μ の推定量 \bar{X} を調べる。

$$E(\bar{X}) = \mu$$

である。

$$V(\bar{X}) = \frac{\sigma^2}{n}$$

となる。 $n \rightarrow \infty$ のとき、

$$V(\bar{X}) = \frac{\sigma^2}{n} \rightarrow 0$$

となるので、 \bar{X} は μ の一致推定量であると言える。

5.7 χ^2 分布

m 個の確率変数 Z_1, Z_2, \dots, Z_m は, 互いに独立な標準正規分布に従うものとする。このとき, $Y = \sum_{i=1}^m Z_i^2$ は, 自由度 m の χ^2 分布に従う。

$Y \sim \chi^2(m)$, または, $Y \sim \chi_m^2$ と表記する。

χ^2 (カイ二乗) 分布表から確率を求める。

$Y \sim \chi^2(m)$ のとき, $E(Y) = m$, $V(Y) = 2m$ となる。(証明略)

1. 2つの独立な χ^2 分布からの確率変数 X, Y を考える。 $X \sim \chi^2(n)$, $Y \sim \chi^2(m)$ とする。このとき, $Z = X + Y \sim \chi^2(n + m)$ となる。(証明略)
2. n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の正規分布 $N(\mu, \sigma^2)$ に従うものとする。
3. $\frac{X_i - \mu}{\sigma} \sim N(0, 1)$ なので, $\left(\frac{X_i - \mu}{\sigma}\right)^2 \sim \chi^2(1)$ となる。

$\frac{X_1 - \mu}{\sigma}, \frac{X_2 - \mu}{\sigma}, \dots, \frac{X_n - \mu}{\sigma}$ はそれぞれ独立なので,

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

となる。

4. μ を \bar{X} に置き換えると,

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

となる。(証明は後述)

さらに,

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

を定義すると,

$$\frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$$

となる。 S^2 は σ^2 の不偏推定量である (後述)。

5. すなわち,

$$E\left(\frac{(n-1)S^2}{\sigma^2}\right) = n-1 \quad V\left(\frac{(n-1)S^2}{\sigma^2}\right) = 2(n-1),$$

となる。

5.8 t 分布

正規分布の重要な定理: n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の正規分布 $N(\mu, \sigma^2)$ に従うものとする。このとき,

$$\sum_{i=1}^n c_i X_i \sim N\left(\mu \sum_{i=1}^n c_i, \sigma^2 \sum_{i=1}^n c_i^2\right)$$

となる。ただし, c_1, c_2, \dots, c_n は定数とする。

t 分布: Z を標準正規分布, Y を自由度 m の χ^2 分布に従い, 両者は独立な確率変数とする。このとき, $U = \frac{Z}{\sqrt{Y/m}}$ は, 自由度 m の t 分布に従う。

$U \sim t(m)$, または, $U \sim t_m$ と表記する。

$U \sim t(m)$ のとき, $m > 1$ について $E(U) = 0$, $m > 2$ について $V(U) = \frac{m}{m-2}$ となる。(証明略)

t 分布表から確率を求める。(表 10.1.3 を見よ)

1. ゼロを中心に左右対称。($E(U) = 0$)
2. t 分布は, 標準正規分布より裾野の広い分布(なぜなら, $V(U) = \frac{m}{m-2} > 1$)
3. $m \rightarrow \infty$ のとき, $t(m) \rightarrow N(0, 1)$ となる。(期待値は $m > 1$ について $E(U) = 0$, 分散は $V(U) = \frac{m}{m-2} \rightarrow 1$)

5.9 標本平均 \bar{X} の分布

X_1, X_2, \dots, X_n の n 個の確率変数は, 互いに独立で, 平均 μ , 分散 σ^2 の正規分布に従うものとする。

1. $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ なので, $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$ となる。
2. $\frac{(n-1)S^2}{\sigma^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} \sim \chi^2(n-1)$ である。(証明は略)
3. $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$ と $\frac{(n-1)S^2}{\sigma^2}$ は独立。(証明は略)
すなわち, \bar{X} と S^2 は独立。

4. したがって，

$$\frac{\frac{\bar{X} - \mu}{\sigma / \sqrt{n}}}{\sqrt{\frac{(n-1)S^2}{\sigma^2} / n - 1}} = \frac{\bar{X} - \mu}{S / \sqrt{n}} \sim t(n-1)$$

を得る。

重要な結果は，

$$\frac{\bar{X} - \mu}{S / \sqrt{n}} \sim t(n-1)$$

ただし， $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ ， $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ である。

σ^2 を S^2 に置き換えると，正規分布から t 分布になる。

$$\frac{\bar{X} - \mu}{\sigma / \sqrt{n}} \sim N(0, 1) \quad \Rightarrow \quad \frac{\bar{X} - \mu}{S / \sqrt{n}} \sim t(n-1)$$

5.10 区間推定 (信頼区間)

\bar{X} の分布を利用して, μ の信頼区間を求める。

1. \bar{X} の分布は以下の通り。

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t(n-1)$$

となる。

2. $t_{\alpha/2}(n-1)$, $t_{1-\alpha/2}(n-1)$ を自由度 $n-1$ の t 分布の上から $100 \times \frac{\alpha}{2}$ % 点, $100 \times (1 - \frac{\alpha}{2})$ % 点の値とする。このとき,

$$\text{Prob}\left(t_{1-\alpha/2}(n-1) < \frac{\bar{X} - \mu}{S/\sqrt{n}} < t_{\alpha/2}(n-1)\right) = 1 - \alpha$$

となる。ただし, 自由度と α が決まれば, $t_{\alpha/2}(n-1)$, $t_{1-\alpha/2}(n-1)$ は t 分布表から得られる。

3. t 分布は左右対称なので ,

$$t_{1-\alpha/2}(n-1) = -t_{\alpha/2}(n-1) \quad t_{\alpha/2}(n-1) = |t_{1-\alpha/2}(n-1)|$$

$$t_{1-\alpha/2}(n-1) = -|t_{\alpha/2}(n-1)|$$

となる。

4. 書き直して ,

$$\text{Prob}\left(\bar{X} - t_{\alpha/2}(n-1)\frac{S}{\sqrt{n}} < \mu < \bar{X} + t_{\alpha/2}(n-1)\frac{S}{\sqrt{n}}\right) = 1 - \alpha$$

となる。

5. μ が区間 $(\bar{X} - t_{\alpha/2}(n-1)\frac{S}{\sqrt{n}}, \bar{X} + t_{\alpha/2}(n-1)\frac{S}{\sqrt{n}})$ にある確率は $1 - \alpha$ である。

6. 推定量 \bar{X} , S^2 をその推定値 \bar{x} , s^2 で置き換える。ただし , $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$,

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \text{ とする。}$$

7. 区間 $(\bar{x} - t_{\alpha/2}(n-1)\frac{s}{\sqrt{n}}, \bar{x} + t_{\alpha/2}(n-1)\frac{s}{\sqrt{n}})$ を信頼係数 $1 - \alpha$ の信頼区間と
いい、 $\bar{x} - t_{\alpha/2}(n-1)\frac{s}{\sqrt{n}}$ を信頼下限、 $\bar{x} + t_{\alpha/2}(n-1)\frac{s}{\sqrt{n}}$ を信頼上限と呼ぶ。

5.11 仮説検定

\bar{X} の分布を利用して、 μ の仮説検定を行う。

1. 帰無仮説 $H_0: \mu = \mu_0$ 対立仮説 $H_1: \mu \neq \mu_0$
2. 帰無仮説 $H_0: \mu = \mu_0$ が正しいもとでの分布は、

$$\frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t(n-1)$$

となる。

3. $\text{Prob}(t_{1-\alpha/2}(n-1) < \frac{\bar{X} - \mu_0}{S/\sqrt{n}} < t_{\alpha/2}(n-1)) = 1 - \alpha$

$t_{\alpha/2}(n-1)$, $t_{1-\alpha/2}(n-1)$ をそれぞれ自由度 $n-1$ の t 分布の上から $100 \times \frac{\alpha}{2}$ % 点, $100 \times \frac{1-\alpha}{2}$ % 点の値とする。

自由度と α が決まれば, $t_{\alpha/2}(n-1)$, $t_{1-\alpha/2}(n-1)$ は t 分布表から得られる。

4. α を有意水準と呼ぶ。慣習的に $\alpha = 0.01, 0.05$ が使われる。

5. $-t_{\alpha/2}(n-1) > \frac{\bar{X} - \mu_0}{S/\sqrt{n}}$, または, $\frac{\bar{X} - \mu_0}{S/\sqrt{n}} > t_{\alpha/2}(n-1)$ ならば, 帰無仮説 $H_0: \mu = \mu_0$ は, 分布の端にあり, 起こりにくいと考える。

⇒ 有意水準 α で帰無仮説 $H_0: \mu = \mu_0$ を棄却する。

6. 実際の検定手続：

(a) \bar{X}, S^2 を実績値で置き換えて,

$$\frac{\bar{x} - \mu_0}{s/\sqrt{n}}$$

を得る。ただし, $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$, $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$ とする。

(b) $-t_{\alpha/2}(n-1) > \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$, または , $\frac{\bar{x} - \mu_0}{s/\sqrt{n}} > t_{\alpha/2}(n-1)$ ならば , 有意水準 α で帰無仮説 $H_0 : \mu = \mu_0$ を棄却する。

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 (u_i は正規分布を仮定する)。
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。

- 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…
- 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： $\omega_i = \frac{(X_i - \bar{X})}{\sum_{j=1}^n (X_j - \bar{X})^2}$ とする。

このとき，

$$\sum_{i=1}^n \omega_i = 0$$

となる ($\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ から $\sum_{i=1}^n (X_i - \bar{X}) = 0$ となるので， $\sum_{i=1}^n \omega_i = 0$ が得られる)。

また,

$$\sum_{i=1}^n \omega_i X_i = 1$$

となる ($\sum_{i=1}^n \omega_i X_i = \sum_{i=1}^n \omega_i X_i - \sum_{i=1}^n \omega_i \bar{X} = \sum_{i=1}^n \omega_i (X_i - \bar{X}) = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sum_{j=1}^n (X_j - \bar{X})^2} = 1$ となるので)。

6.3.1 $\hat{\beta}$ について

β の最小二乗推定量 $\hat{\beta}$ は,

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

となる。ただし、 $\omega_i = \frac{(X_i - \bar{X})}{\sum_{j=1}^n (X_j - \bar{X})^2}$ である。二つ目の等式について、添え字を変更しても等式は成り立つので、分母の添え字を j に変更している。最後の等式では、 $\sum_{i=1}^n \omega_i = 0$ を利用している。

さらに、

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

となる。

最後の等式では、 $\sum_{i=1}^n \omega_i = 0$ 、 $\sum_{i=1}^n \omega_i X_i = 1$ を利用している。

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、

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