

エコノメトリックス

(2016年度前期 講義ノート)

April 19, 2016 (火) 版

教科書『計量経済学』
(山本拓著, 新世社, 1995年)

谷崎 久志
大阪大学・経済学部

Contents

1 計量経済学について	1
1.1 例1：マクロの消費関数	1
1.2 例2：日本酒の需要関数	4
2 行列について	6
3 最小二乗法について	20

3.1	最小二乗法と回帰直線	20
3.2	切片 α と傾き β の推定	21
3.3	残差 \widehat{u}_i の性質について	29
3.4	決定係数 R^2 について	31
3.5	まとめ	36
4	統計学の回帰分析への応用	38
4.1	回帰モデルの仮定	42
4.2	誤差項(攪乱項)の経済学的意味	44
4.3	$\widehat{\alpha}$, $\widehat{\beta}$ の統計的性質	45
4.3.1	$\widehat{\beta}$ について	46
4.3.2	$\widehat{\alpha}$ について	47
4.3.3	$\widehat{\alpha}$, $\widehat{\beta}$ の平均	48
4.3.4	$\widehat{\alpha}$, $\widehat{\beta}$ の分散	50
4.3.5	$\widehat{\alpha}$, $\widehat{\beta}$ の分布 (σ^2 が既知の場合)	61
4.3.6	$\widehat{\alpha}$, $\widehat{\beta}$ の性質: 最良線型不偏性と一致性	64
4.4	誤差項(または, 攪乱項) u_i の分散 σ^2 について	74
4.4.1	$\widehat{\alpha}$, $\widehat{\beta}$ の分散の不偏推定量	84
4.5	$\widehat{\alpha}$, $\widehat{\beta}$ の分布	88
4.5.1	統計学の復習 (t 分布)	88

4.5.2	$\widehat{\beta}$ について：	91
4.5.3	$\widehat{\alpha}$ について：	93
4.5.4	まとめ：	94
4.6	α, β の区間推定(信頼区間)	94	
4.6.1	統計学の復習：区間推定(信頼区間)	94
4.6.2	α, β の区間推定(信頼区間)	97	
4.7	α, β の仮説検定	100	
4.7.1	統計学の復習：仮説検定	100	
4.7.2	α, β の仮説検定	103	
4.7.3	t 値について	105	
5	多重回帰		111
5.1	重回帰モデルにおける回帰係数の意味	116	
5.2	推定量の性質	119	
5.3	ダミー変数について	126	
5.3.1	異常値	126	
5.3.2	構造変化	130	
6	関数型について		132

7 系列相関：<i>DW</i>について	137
7.1 <i>DW</i> について	137
7.2 最小二乗推定量の分散について	147
7.3 系列相関のもとで回帰式の推定	149
8 不均一分散(不等分散)	152
8.1 不均一分散(不等分散)の意味と推定方法	152
8.2 最小二乗推定量の分散について	155
9 多重共線性について	157
10 <i>F</i>検定について	162
10.1 いくつかの例	163
10.2 統計学の復習	164
10.3 検定の方法	165
11 応用例	168
11.1 マクロの消費関数	168
11.2 ミクロの消費関数(需要関数)	181
11.3 株価, 金利, 為替レート	196

12 推定量の求め方	201
12.1 最小二乗法	201
12.2 最尤法	203
12.2.1 変数変換	224
12.2.2 回帰分析への応用	226
12.2.3 誤差項に系列相関がある場合	234
12.3 尤度比検定	238
13 時系列分析と季節調整	251
13.1 季節変動	253
13.2 トレンド	255
13.3 循環変動	256
14 時系列分析と定常性	256
14.1 時系列モデルの特定化	260
14.1.1 自己回帰(AR)モデル	260
14.1.2 移動平均(MA)モデル	261
14.1.3 より複雑なモデル	261
14.2 時系列モデルの作成手順と予測	263
14.3 非定常時系列	263

14.3.1	単位根	263
14.3.2	見せかけ回帰	270
14.3.3	共和分	271

- この講義ノートは,
<http://www2.econ.osaka-u.ac.jp/~tanizaki/class/2014>
からダウンロード可。

教科書

『計量経済学』(山本拓著, 1995, 新世社)

『基本統計学(第3版)』(豊田他著, 東洋経済新報社, 2010年)

1 計量経済学について

- 経済理論(ミクロ, マクロ, 財政, 金融, 国際経済, …)
- データ(GNP, 消費, 投資, 金利, 為替レート, …)

計量経済学 \Rightarrow 経済理論が現実に成り立つものかどうかを, データを用いて, 統計的に検証する。

1.1 例1：マクロの消費関数

$$C = f(Y)$$

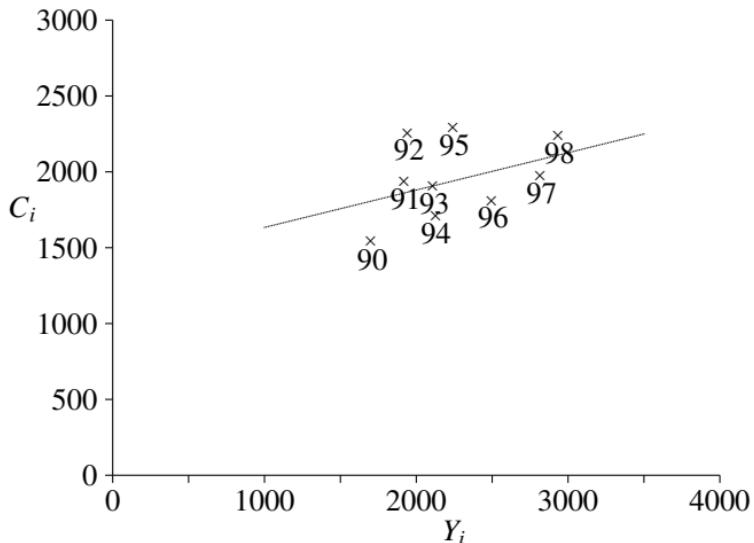
ただし, C は消費, Y は所得。

1. $Y \nearrow \implies C \nearrow$
2. $\frac{dC}{dY}$ = 限界消費性向 = 所得 1 円増加で消費が何円増加するか
3. すなわち, $\frac{dC}{dY} > 0$

モデルの定式化

1. $C = a + bY$
2. $b = \frac{dC}{dY}$ = 限界消費性向
3. a = 基礎消費 ($Y = 0$ のときに必要な消費)
4. 符号条件 : $a > 0, b > 0$ (しかも, $1 > b$)

図 1：消費(C_i)と所得(Y_i)



1. $\times \rightarrow$ 実際のデータ
2. $(Y_i, C_i) \Rightarrow t$ 期のデータ, i.e., $i = 1, 2, \dots, 9$
3. $i = 1 \Rightarrow 1990$ 年,
 $i = 2 \Rightarrow 1991$ 年,

$\dots,$

$i = 9 \Rightarrow 1998$ 年,

1. 実際のデータを用いて, a, b を求める。
2. a, b を求める \equiv 現実の経済構造を求める
3. その結果, もし $a > 0, 1 > b > 0$ なら, 経済理論は現実経済を説明していると言える。

1.2 例2：日本酒の需要関数

$$Q = f(Y, P_1, P_2)$$

ただし, Q は日本酒の需要量, Y は所得, P_1 は日本酒の価格, P_2 は洋酒の価格。

1. $Y \nearrow \Rightarrow Q \nearrow,$

$P_1 \nearrow \Rightarrow Q \searrow,$

$P_2 \nearrow \Rightarrow Q \nearrow$

2. $\frac{\partial Q}{\partial Y} > 0, \frac{\partial Q}{\partial P_1} < 0, \frac{\partial Q}{\partial P_2} > 0$

3. 日本酒と洋酒は代替財

4. モデルの定式化 (A)

$$Q = a + b_1 Y + b_2 P_1 + b_3 P_2$$

5. Q, Y, P_1, P_2 を用いて, a, b_1, b_2, b_3 を求める (日本酒の需要構造を求める)。

6. 符号条件 : $b_1 > 0, b_2 < 0, b_3 > 0, a ?$

7. t 期のデータ $(Q_i, Y_i, P_{1i}, P_{2i})$

8. n 組のデータ, i.e., $i = 1, 2, \dots, n$

9. モデルの定式化 (B)

$$Q = a + b_1 Y + b_2 \frac{P_1}{P_2}$$

符号条件 : $b_1 > 0, b_2 < 0$

10. モデルの定式化 (C)

$$\log(Q) = a + b_1 \log(Y) + b_2 \log\left(\frac{P_1}{P_2}\right)$$

符号条件 : $b_1 > 0, b_2 < 0$

11. モデル (A), (B), (C) のどれが最も現実的かを得られた結果から判断する。

2 行列について

A を 2×2 行列とすると,

$$A = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix}$$

と表される。

$a_{ij} = A$ の第 i 行, 第 j 列の要素

a を 2×1 行列 (縦ベクトル) とすると,

$$a = \begin{pmatrix} a_1 \\ a_2 \end{pmatrix}$$

と表される。

$a_i = a$ の第 i 要素

a を 1×2 行列 (横ベクトル) とすると,

$$a = (a_1 \quad a_2)$$

と表される。

$a_i = a$ の第 i 要素

A を $n \times k$ 行列とすると,

$$A = \begin{pmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nk} \end{pmatrix}$$

と表される。

$a_{ij} = A$ の第 i 行, 第 j 列の要素 (ij 要素)

a を $n \times 1$ 行列 (縦ベクトル) とすると,

$$a = \begin{pmatrix} a_1 \\ \vdots \\ a_n \end{pmatrix}$$

と表される。

$a_i = a$ の第 i 要素

a を $1 \times k$ 行列 (横ベクトル) とすると,

$$a = (a_1 \quad \cdots \quad a_k)$$

と表される。

$a_i = a$ の第 i 要素

行列の等号: A, B を $n \times k$ 行列とする。 $A = B$ は、すべての $i = 1, \dots, n$, $j = 1, \dots, k$ について、 $a_{ij} = b_{ij}$ を意味する。ただし、 a_{ij}, b_{ij} は、それぞれ、 A, B の ij 要素とする。

$x = 3, y = 2$ の 2 つの等式を行列で表す。

$$\begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 3 \\ 2 \end{pmatrix} \quad \text{または} \quad (x \quad y) = (3 \quad 2)$$

行列の和と差: A, B を $n \times k$ 行列とする。

$$A + B = \begin{pmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nk} \end{pmatrix} + \begin{pmatrix} b_{11} & \cdots & b_{1k} \\ \vdots & \ddots & \vdots \\ b_{n1} & \cdots & b_{nk} \end{pmatrix}$$

$$= \begin{pmatrix} a_{11} + b_{11} & \cdots & a_{1k} + b_{1k} \\ \vdots & \ddots & \vdots \\ a_{n1} + b_{n1} & \cdots & a_{nk} + b_{nk} \end{pmatrix}$$

すなわち、 $A + B$ の ij 要素は、 $a_{ij} + b_{ij}$ となる。

$$A = \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix} \quad B = \begin{pmatrix} 5 & 6 \\ 7 & 8 \end{pmatrix}$$

$$A + B = \begin{pmatrix} 1+5 & 2+6 \\ 3+7 & 4+8 \end{pmatrix} = \begin{pmatrix} 6 & 8 \\ 10 & 12 \end{pmatrix}$$

$$A - B = \begin{pmatrix} 1-5 & 2-6 \\ 3-7 & 4-8 \end{pmatrix} = \begin{pmatrix} -4 & -4 \\ -4 & -4 \end{pmatrix}$$

要素と行列の積： A を $n \times k$ 行列とする。 c をスカラー (1×1 行列のこと) とする。

$$cA = c \begin{pmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nk} \end{pmatrix} = \begin{pmatrix} ca_{11} & \cdots & ca_{1k} \\ \vdots & \ddots & \vdots \\ ca_{n1} & \cdots & ca_{nk} \end{pmatrix}$$

$$A = \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix} \quad c = 5 \quad \text{のとき}$$

$$cA = 5 \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix} = \begin{pmatrix} 5 \times 1 & 5 \times 2 \\ 5 \times 3 & 5 \times 4 \end{pmatrix} = \begin{pmatrix} 5 & 10 \\ 15 & 20 \end{pmatrix}$$

行列と行列の積： A, B を $n \times k, k \times n$ 行列とする。

$$\begin{aligned} AB &= \begin{pmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nk} \end{pmatrix} \begin{pmatrix} b_{11} & \cdots & b_{1n} \\ \vdots & \ddots & \vdots \\ b_{k1} & \cdots & b_{kn} \end{pmatrix} \\ &= \begin{pmatrix} \sum_{m=1}^k a_{1m}b_{m1} & \cdots & \sum_{m=1}^k a_{1m}b_{mn} \\ \vdots & \ddots & \vdots \\ \sum_{m=1}^k a_{nm}b_{m1} & \cdots & \sum_{m=1}^k a_{1m}b_{mn} \end{pmatrix} \end{aligned}$$

すなわち， AB は $n \times n$ 行列で， AB の ij 要素は， $a_{i1}b_{1j} + a_{i2}b_{2j} + \cdots + a_{ik}b_{kj} = \sum_{m=1}^k a_{im}b_{mj}$ となる。

$$\begin{aligned}
BA &= \begin{pmatrix} b_{11} & \cdots & b_{1n} \\ \vdots & \ddots & \vdots \\ b_{k1} & \cdots & b_{kn} \end{pmatrix} \begin{pmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nk} \end{pmatrix} \\
&= \begin{pmatrix} \sum_{m=1}^n b_{1m}a_{m1} & \cdots & \sum_{m=1}^n b_{1m}a_{mk} \\ \vdots & \ddots & \vdots \\ \sum_{m=1}^n b_{km}a_{m1} & \cdots & \sum_{m=1}^n b_{1m}a_{mk} \end{pmatrix}
\end{aligned}$$

すなわち、 BA は $k \times k$ 行列で、 BA の ij 要素は、 $b_{i1}a_{1j} + b_{i2}a_{2j} + \cdots + b_{ik}a_{kj} = \sum_{m=1}^k a_{ik}b_{kj}$ となる。

このように、 AB と BA の次元は異なる。

$$A = \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix} \quad B = \begin{pmatrix} 5 & 6 \\ 7 & 8 \end{pmatrix}$$

$$\begin{aligned}
AB &= \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix} \begin{pmatrix} 5 & 6 \\ 7 & 8 \end{pmatrix} \\
&= \begin{pmatrix} 1 \times 5 + 2 \times 7 & 1 \times 6 + 2 \times 8 \\ 3 \times 5 + 4 \times 7 & 3 \times 6 + 4 \times 8 \end{pmatrix} \\
&= \begin{pmatrix} 19 & 22 \\ 43 & 50 \end{pmatrix}
\end{aligned}$$

$$\begin{aligned}
 BA &= \begin{pmatrix} 5 & 6 \\ 7 & 8 \end{pmatrix} \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix} \\
 &= \begin{pmatrix} 5 \times 1 + 6 \times 3 & 5 \times 2 + 6 \times 4 \\ 7 \times 1 + 8 \times 3 & 7 \times 2 + 8 \times 4 \end{pmatrix} \\
 &= \begin{pmatrix} 23 & 34 \\ 31 & 46 \end{pmatrix}
 \end{aligned}$$

一般的に， $AB \neq BA$ となる。

c をスカラーとする。

$$cAB = AcB = (Ac)B = A(cB) = ABC$$

c をどこで掛けても値は変わらない。

連立方程式：

$$\begin{cases} x + 2y = 3 \\ 4x + 5y = 6 \end{cases}$$

行列表示すると，

$$\begin{pmatrix} 1 & 2 \\ 4 & 5 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 3 \\ 6 \end{pmatrix}$$

となる。

また,

$$\begin{cases} x + 2y + 3z = 4 \\ 5x + 6y + 7z = 8 \\ 9x + 10y + 11z = 12 \end{cases}$$

行列表示すると,

$$\begin{pmatrix} 1 & 2 & 3 \\ 5 & 6 & 7 \\ 9 & 10 & 11 \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \begin{pmatrix} 4 \\ 8 \\ 12 \end{pmatrix}$$

となる。

単位行列: 単位行列とは, 対角要素 1, その他 0 となる行列であり, I で表す。

$$I = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & & \\ \vdots & & \ddots & \vdots \\ 0 & & \cdots & 1 & 0 \\ & & & 0 & 1 \end{pmatrix}$$

I が $n \times n$ 行列のとき, I_n と書くことが多い。

A を $n \times n$ 行列, x を $n \times 1$ 行列(ベクトル)とする。

$$I_n A = A I_n = A \quad I_n x = x$$

$$\begin{aligned} & \begin{pmatrix} 1 & & 0 \\ & \ddots & \\ 0 & & 1 \end{pmatrix} \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nn} \end{pmatrix} \\ &= \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nn} \end{pmatrix} \begin{pmatrix} 1 & & 0 \\ & \ddots & \\ 0 & & 1 \end{pmatrix} \\ &= \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nn} \end{pmatrix} \\ & \begin{pmatrix} 1 & & 0 \\ & \ddots & \\ 0 & & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \end{aligned}$$

逆行列： A を $n \times n$ とする。 A の逆行列とは、 $AB = I_n$ または $BA = I_n$ となる B を指す。 A も B も次元は同じ。

B を A^{-1} と表す。

すなわち、 A の逆行列は A^{-1} であり、 A^{-1} の逆行列は A である。

$$A = \begin{pmatrix} a & b \\ c & d \end{pmatrix}$$

のとき、

$$A^{-1} = \frac{1}{ad - bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

となる。

$$\begin{aligned} A^{-1}A &= \frac{1}{ad - bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix} \begin{pmatrix} a & b \\ c & d \end{pmatrix} \\ &= \frac{1}{ad - bc} \begin{pmatrix} da - bc & db - bd \\ -ca + ac & -bc + ad \end{pmatrix} \\ &= \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = I_2 \end{aligned}$$

$$\begin{aligned}
AA^{-1} &= \begin{pmatrix} a & b \\ c & d \end{pmatrix} \times \frac{1}{ad - bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix} \\
&= \frac{1}{ad - bc} \begin{pmatrix} ad - bc & -ab + ba \\ cd - dc & -cb + da \end{pmatrix} \\
&= \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = I_2
\end{aligned}$$

連立方程式の解： A を $n \times n$ 行列， x と b を $n \times 1$ 行列（ベクトル）とする。

$$Ax = b$$

両辺に A^{-1} を左から掛ける。

$$A^{-1}Ax = A^{-1}b$$

$A^{-1}A = I_n$ なので，

$$I_nx = A^{-1}b$$

となる。また，

$$I_nx = x$$

なので、 x を A, b で表すと、

$$x = A^{-1}b$$

となる。

例

$$\begin{cases} x + 2y = 3 \\ 4x + 5y = 6 \end{cases}$$

の行列表示は、

$$\begin{pmatrix} 1 & 2 \\ 4 & 5 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 3 \\ 6 \end{pmatrix}$$

となる。

x, y の解は、

$$\begin{pmatrix} 1 & 2 \\ 4 & 5 \end{pmatrix}^{-1} \begin{pmatrix} 1 & 2 \\ 4 & 5 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 1 & 2 \\ 4 & 5 \end{pmatrix}^{-1} \begin{pmatrix} 3 \\ 6 \end{pmatrix}$$

なので、

$$\begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 1 & 2 \\ 4 & 5 \end{pmatrix}^{-1} \begin{pmatrix} 3 \\ 6 \end{pmatrix}$$

すなわち,

$$\begin{aligned}\begin{pmatrix} x \\ y \end{pmatrix} &= \begin{pmatrix} 1 & 2 \\ 4 & 5 \end{pmatrix}^{-1} \begin{pmatrix} 3 \\ 6 \end{pmatrix} \\ &= \frac{1}{1 \times 5 - 2 \times 4} \begin{pmatrix} 5 & -2 \\ -4 & 1 \end{pmatrix} \begin{pmatrix} 3 \\ 6 \end{pmatrix} \\ &= -\frac{1}{1 \times 3} \begin{pmatrix} 5 \times 3 - 2 \times 6 \\ -4 \times 3 + 1 \times 6 \end{pmatrix} = \begin{pmatrix} -1 \\ 2 \end{pmatrix}\end{aligned}$$

例

$$\begin{cases} x + 2y + 3z = 4 \\ 5x + 6y + 7z = 8 \\ 9x + 10y + 11z = 12 \end{cases}$$

の行列表示は,

$$\begin{pmatrix} 1 & 2 & 3 \\ 5 & 6 & 7 \\ 9 & 10 & 11 \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \begin{pmatrix} 4 \\ 8 \\ 12 \end{pmatrix}$$

となる。 x, y, z の解は,

$$\begin{pmatrix} x \\ y \\ z \end{pmatrix} = \begin{pmatrix} 1 & 2 & 3 \\ 5 & 6 & 7 \\ 9 & 10 & 11 \end{pmatrix}^{-1} \begin{pmatrix} 4 \\ 8 \\ 12 \end{pmatrix}$$

となる。

転置行列： A を $n \times k$ 行列とする。

A の ij 要素を a_{ij} とする。

A の転置行列 (A' または $'A$) の ij 要素は, a_{ji} となる。

$$A = \begin{pmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nk} \end{pmatrix}$$

$$A' = \begin{pmatrix} a_{11} & \cdots & a_{n1} \\ \vdots & \ddots & \vdots \\ a_{1k} & \cdots & a_{nk} \end{pmatrix}$$

A' は $k \times n$ となる。

$$(A')' = A$$

$$x = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} \quad x' = (x_1 \quad x_2 \quad \cdots \quad x_n)$$

3 最小二乗法について

経済理論に基づいた線型モデルの係数の値をデータから求める時に用いられる手法 \Rightarrow 最小二乗法

3.1 最小二乗法と回帰直線

$(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$ のように n 組のデータがあり、 X_i と Y_i との間に以下の線型関係を想定する。

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

X_i は説明変数、 Y_i は被説明変数、 α, β はパラメータとそれぞれ呼ばれる。

上の式は回帰モデル(または、回帰式)と呼ばれる。目的は、切片 α と傾き β をデータ $\{(X_i, Y_i), i = 1, 2, \dots, n\}$ から推定すること、

データについて：

1. タイム・シリーズ(時系列)・データ： i が時間を表す(第 i 期)。
2. クロス・セクション(横断面)・データ： i が個人や企業を表す(第 i 番目の家計、第 i 番目の企業)。

3.2 切片 α と傾き β の推定

次のような関数 $S(\alpha, \beta)$ を定義する。

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

このとき、

$$\min_{\alpha, \beta} S(\alpha, \beta)$$

となるような α, β を求める(最小自乗法)。このときの解を $\widehat{\alpha}, \widehat{\beta}$ とする。

最小化のためには,

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

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

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

すなわち, $\widehat{\alpha}, \widehat{\beta}$ は,

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

$$\sum_{i=1}^n X_i(Y_i - \widehat{\alpha} - \widehat{\beta}X_i) = 0, \quad (2)$$

を満たす。

さらに,

$$\sum_{i=1}^n Y_i = n\widehat{\alpha} + \widehat{\beta} \sum_{i=1}^n X_i, \quad (3)$$

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

行列表示によって、

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

逆行列の公式：

$$\begin{pmatrix} a & b \\ c & d \end{pmatrix}^{-1} = \frac{1}{ad - bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

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

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

さらに、 $\widehat{\beta}$ について解くと、

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

連立方程式の(3)式から、

$$\widehat{\alpha} = \bar{Y} - \widehat{\beta} \bar{X}$$

となる。ただし、

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

とする。

数値例：以下の数値例を使って、回帰式 $Y_i = \alpha + \beta X_i$ の α , β の推定値 $\widehat{\alpha}$, $\widehat{\beta}$ を求める。

i	Y_i	X_i
1	6	10
2	9	12
3	10	14
4	10	16

$\hat{\alpha}$, $\hat{\beta}$ を求めるための公式は

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

なので、必要なものは \bar{X} , \bar{Y} , $\sum_{i=1}^n X_i^2$, $\sum_{i=1}^n X_i Y_i$ である。

i	Y_i	X_i	$X_i Y_i$	X_i^2
1	6	10	60	100
2	9	12	108	144
3	10	14	140	196
4	10	16	160	256
合計	$\sum Y_i$ 35	$\sum X_i$ 52	$\sum X_i Y_i$ 468	$\sum X_i^2$ 696
平均	\bar{Y} 8.75	\bar{X} 13		

よって、

$$\hat{\beta} = \frac{468 - 4 \times 13 \times 8.75}{696 - 4 \times 13^2} = \frac{13}{20} = 0.65$$

$$\hat{\alpha} = 8.75 - 0.65 \times 13 = 0.3$$

となる。

注意事項：

1. α, β は真の値で未知

2. $\widehat{\alpha}, \widehat{\beta}$ は α, β の推定値でデータから計算される

回帰直線は

$$\widehat{Y}_i = \widehat{\alpha} + \widehat{\beta}X_i,$$

として与えられる。

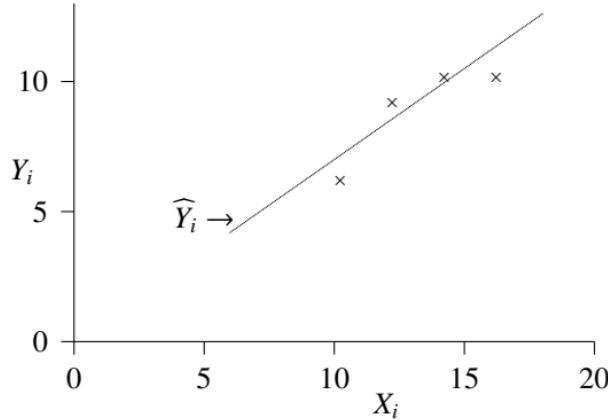
上の数値例では、

$$\widehat{Y}_i = 0.3 + 0.65X_i$$

となる。

i	Y_i	X_i	$X_i Y_i$	X_i^2	\widehat{Y}_i
1	6	10	60	100	6.8
2	9	12	108	144	8.1
3	10	14	140	196	9.4
4	10	16	160	256	10.7
合計	$\sum Y_i$ 35	$\sum X_i$ 52	$\sum X_i Y_i$ 468	$\sum X_i^2$ 696	$\sum \widehat{Y}_i$ 35.0
平均	\bar{Y} 8.75	\bar{X} 13			

図 2 : Y_i , X_i , \widehat{Y}_i



\widehat{Y}_i を実績値 Y_i の予測値または理論値と呼ぶ。

$$\widehat{u}_i = Y_i - \widehat{Y}_i,$$

\widehat{u}_i を残差と呼ぶ。

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

さらに、 \bar{Y} を両辺から引いて、

$$(Y_i - \bar{Y}) = (\widehat{Y}_i - \bar{Y}) + \widehat{u}_i,$$

3.3 残差 \widehat{u}_i の性質について

$\widehat{u}_i = Y_i - \widehat{\alpha} - \widehat{\beta}X_i$ に注意して、(1)式から、

$$\sum_{i=1}^n \widehat{u}_i = 0,$$

を得る。

(2)式から、

$$\sum_{i=1}^n X_i \widehat{u}_i = 0,$$

を得る。

$\widehat{Y}_i = \widehat{\alpha} + \widehat{\beta}X_i$ から、

$$\sum_{i=1}^n \widehat{Y}_i \widehat{u}_i = 0,$$

を得る。なぜなら、

$$\begin{aligned}\sum_{i=1}^n \widehat{Y}_i \widehat{u}_i &= \sum_{i=1}^n (\widehat{\alpha} + \widehat{\beta} X_i) \widehat{u}_i \\&= \widehat{\alpha} \sum_{i=1}^n \widehat{u}_i + \widehat{\beta} \sum_{i=1}^n X_i \widehat{u}_i \\&= 0\end{aligned}$$

である。

i	Y_i	X_i	\widehat{Y}_i	\widehat{u}_i	$X_i \widehat{u}_i$	$\widehat{Y}_i \widehat{u}_i$
1	6	10	6.8	-0.8	-8.0	-5.44
2	9	12	8.1	0.9	10.8	7.29
3	10	14	9.4	0.6	8.4	5.64
4	10	16	10.7	-0.7	-11.2	-7.49
合計	$\sum Y_i$ 35	$\sum X_i$ 52	$\sum \widehat{Y}_i$ 35.0	$\sum \widehat{u}_i$ 0.0	$\sum X_i \widehat{u}_i$ 0.0	$\sum \widehat{Y}_i \widehat{u}_i$ 0.00

3.4 決定係数 R^2 について

次の式

$$(Y_i - \bar{Y}) = (\hat{Y}_i - \bar{Y}) + \hat{u}_i,$$

の両辺を二乗して、総和すると、

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

となる。まとめると、

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

を得る。さらに、

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

それぞれの項は、

1. $\sum_{i=1}^n (Y_i - \bar{Y})^2 \Rightarrow y$ の全変動
2. $\sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2 \Rightarrow \widehat{Y}_i$ (回帰直線) で説明される部分
3. $\sum_{i=1}^n \widehat{u}_i^2 \Rightarrow \widehat{Y}_i$ (回帰直線) で説明されない部分

となる。

回帰式の当てはまりの良さを示す指標として、決定係数 R^2 を以下の通りに定義する。

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

または,

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

として書き換えられる。

または, $Y_i = \widehat{Y}_i + \widehat{u}_i$ と

$$\begin{aligned}& \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2 \\&= \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})(Y_i - \bar{Y} - \widehat{u}_i) \\&= \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})(Y_i - \bar{Y}) - \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})\widehat{u}_i \\&= \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})(Y_i - \bar{Y})\end{aligned}$$

を用いて,

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

$$\begin{aligned}
&= \frac{\left(\sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2\right)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2} \\
&= \left(\frac{\sum_{i=1}^n (\widehat{Y}_i - \bar{Y})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2}} \right)^2
\end{aligned}$$

と書き換えられる。すなわち、 R^2 は Y_i と \widehat{Y}_i の相関係数の二乗と解釈される。

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\widehat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n \widehat{u}_i^2 \text{ から, 明らかに,}$$

$$0 \leq R^2 \leq 1,$$

となる。 R^2 が 1 に近づけば回帰式の当てはまりは良いと言える。しかし、 t 分布のような数表は存在しない。したがって、「どの値よりも大きくなるべき」というような基準はない。

慣習的には、メドとして 0.9 以上を判断基準にする。

数値例： 決定係数の計算には以下の公式を用いる。

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

計算に必要なものは、 $\widehat{u}_i = Y_i - (\widehat{\alpha} + \widehat{\beta}X_i)$, \bar{Y} , $\sum_{i=1}^n Y_i^2$ である。

i	Y_i	X_i	\widehat{Y}_i	\widehat{u}_i	\widehat{u}_i	Y_i^2
1	6	10	6.8	-0.8	0.64	36
2	9	12	8.1	0.9	0.81	81
3	10	14	9.4	0.6	0.36	100
4	10	16	10.7	-0.7	0.49	100
合計	$\sum Y_i$	$\sum X_i$	$\sum \widehat{Y}_i$	$\sum \widehat{u}_i$	$\sum \widehat{u}_i^2$	$\sum Y_i^2$
	35	52	35.0	0.0	2.30	317

$\sum \widehat{u}_i^2 = 2.30$, $\bar{X} = 13$, $\bar{Y} = 8.75$, $\sum_{i=1}^n Y_i^2 = 317$ なので,

$$R^2 = 1 - \frac{2.30}{317 - 4 \times 8.75^2} = 1 - \frac{2.30}{10.75} = 0.786$$

3.5 まとめ

$\hat{\alpha}$, $\hat{\beta}$ を求めるための公式は

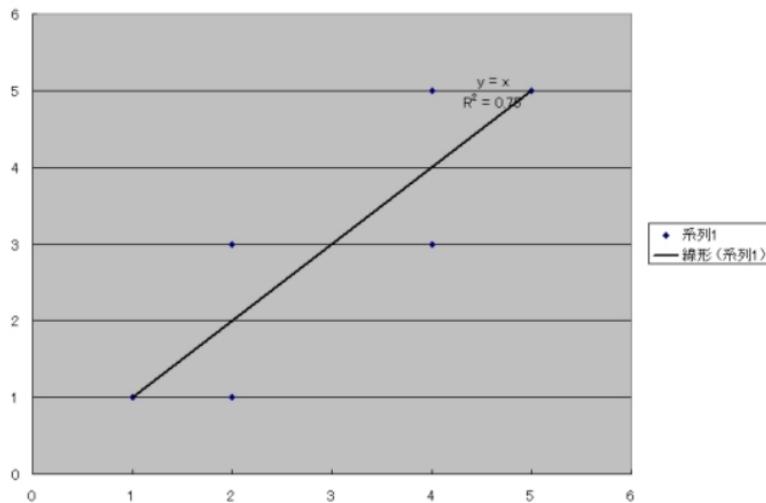
$$\begin{aligned}\hat{\beta} &= \frac{\sum_{i=1}^n X_i Y_i - n \bar{X} \bar{Y}}{\sum_{i=1}^n X_i^2 - n \bar{X}^2} \\ \hat{\alpha} &= \bar{Y} - \hat{\beta} \bar{X}\end{aligned}$$

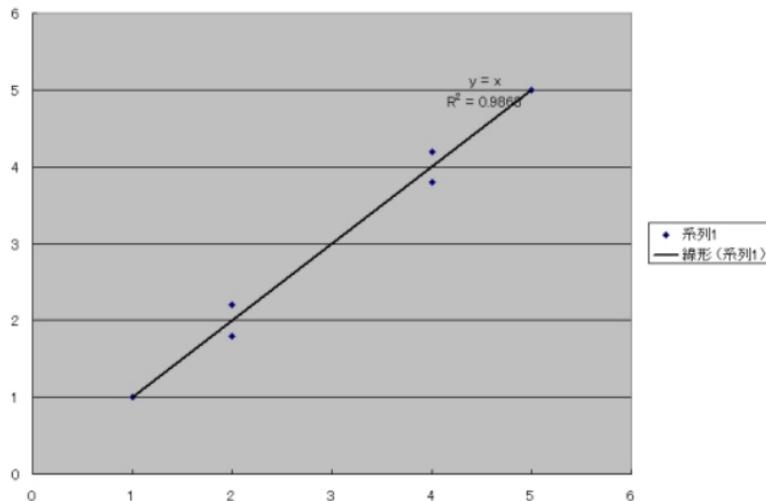
なので、必要なものは \bar{X} , \bar{Y} , $\sum_{i=1}^n X_i^2$, $\sum_{i=1}^n X_i Y_i$ である。

決定係数の計算には以下の公式を用いる。

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

計算に必要なものは、 $\sum \hat{u}_i^2$, \bar{Y} , $\sum_{i=1}^n Y_i^2$ である。





4 統計学の回帰分析への応用

$(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$ 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。
 $\hat{\alpha}$, $\hat{\beta}$, \hat{Y}_i を求めるための公式は

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

である。

Y_i , \hat{Y}_i , \hat{u}_i , $\hat{\alpha}$, $\hat{\beta}$ の関係は以下の通りである。

$$\begin{aligned}Y_i &= \hat{Y}_i + \hat{u}_i \\ &= \hat{\alpha} + \hat{\beta}X_i + \hat{u}_i\end{aligned}$$

残差 \hat{u}_i が必ず含まれることから、

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

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。
⇒ 確率的モデル

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)

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

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

統計学の復習(統計量、推定量、推定値について)

1. 理論標本、理論観測値

⇒ X_1, X_2, \dots, X_n

⇒ 確率変数

2. 実現された標本, 実現された観測値, 実現値

$\implies x_1, x_2, \dots, x_n$

\implies 数値

1. 理論観測値 X_1, X_2, \dots, X_n の関数 \implies 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 $\implies \mu$ の推定量

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

(b) $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ は σ^2 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 \implies 推定値

(a) $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ は μ 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。
6. α, β は母数。
7. $\widehat{\alpha}, \widehat{\beta}$ は α, β の推定量である。

4.1 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。($\text{Cov}(u_i, u_j) = \text{E}(u_i u_j) = 0$ 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。

4.2 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ません。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。

4.3 $\widehat{\alpha}$, $\widehat{\beta}$ 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,

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i,$$

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i,$$

$$\bar{u} = \frac{1}{n} \sum_{i=1}^n u_i,$$

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。

4.3.1 $\widehat{\beta}$ について

β の最小二乗推定量 $\widehat{\beta}$ に代入すると,

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

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、

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

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。

4.3.2 $\widehat{\alpha}$ について

α の最小二乗推定量 $\widehat{\alpha}$ については、

$$\begin{aligned}\widehat{\alpha} &= \bar{Y} - \widehat{\beta}\bar{X} \\ &= \alpha - (\widehat{\beta} - \beta)\bar{X} + \bar{u}\end{aligned}$$

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。

4.3.3 $\hat{\alpha}, \hat{\beta}$ の平均

統計学の復習 (期待値の公式) :

1. X を確率変数とする。

$$E(a + bX) = a + bE(X),$$

となる。ただし, a, b は定数とする。

2. X_1, X_2, \dots, X_n の n 個の確率変数を考える。このとき,

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

となる。ただし, c_1, c_2, \dots, c_n は定数とする。

$\widehat{\alpha}$, $\widehat{\beta}$ の平均 : $\widehat{\beta}$ は次のように書き換えられた。

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

の両辺に期待値をとると,

$$\begin{aligned}\text{E}(\widehat{\beta}) &= \text{E}(\beta + \sum_{i=1}^n \omega_i u_i) \\ &= \beta + \sum_{i=1}^n \text{E}(\omega_i u_i) \\ &= \beta + \sum_{i=1}^n \omega_i \text{E}(u_i) \\ &= \beta,\end{aligned}$$

となり, $\widehat{\beta}$ は β の不偏推定量であると言える。

$\widehat{\alpha}$ については,

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

を利用して、辺々に期待値をとると、

$$\begin{aligned} E(\widehat{\alpha}) &= \alpha - E(\widehat{\beta} - \beta)\bar{X} + E(\bar{u}) \\ &= \alpha \end{aligned}$$

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

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

$\widehat{\alpha}$ は α の不偏推定量であると言える。

4.3.4 $\widehat{\alpha}, \widehat{\beta}$ の分散

統計学の復習(分散の公式)：

1. X を確率変数とする。

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

となる。ただし, $\mu = E(X)$ とする。

2. X を確率変数とする。

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

となる。ただし, a, b は定数とする。

3. X_1, X_2, \dots, X_n の n 個の確率変数は互いに独立とする。このとき,

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

となる。ただし, c_1, c_2, \dots, c_n は定数とする。

$\hat{\alpha}, \hat{\beta}$ 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,

$$\begin{aligned} V(\hat{\beta}) &= V(\beta + \sum_{i=1}^n \omega_i u_i) \\ &= V\left(\sum_{i=1}^n \omega_i u_i\right) \end{aligned}$$

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

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、 $\omega_i = \frac{X_i - \bar{X}}{\sum_{i=1}^n (X_i - \bar{X})^2}$ に注意して、

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

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

を用いる。

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。

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

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

$$\text{E}(\bar{u}^2) = \text{E}\left(\frac{1}{n} \sum_{i=1}^n u_i\right)^2$$

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

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、

$$\begin{aligned}
\text{Cov}(\hat{\alpha}, \hat{\beta}) &= E((\hat{\alpha} - \alpha)(\hat{\beta} - \beta)) \\
&= E((- (\hat{\beta} - \beta)\bar{X} + \bar{u})(\hat{\beta} - \beta))
\end{aligned}$$

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

となる。

数値例：

i	Y_i	X_i	$X_i Y_i$	X_i^2
1	6	10	60	100
2	9	12	108	144
3	10	14	140	196
4	10	16	160	256
合計	$\sum Y_i$ 35	$\sum X_i$ 52	$\sum X_i Y_i$ 468	$\sum X_i^2$ 696
平均	\bar{Y} 8.75	\bar{X} 13		

$$\begin{aligned}
V(\hat{\beta}) &= \frac{\sigma^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \\
&= \frac{\sigma^2}{\sum_{i=1}^n X_i^2 - n\bar{X}^2} \\
&= \frac{\sigma^2}{696 - 4 \times 13^2} \\
&= \frac{\sigma^2}{20} \\
&= 0.05\sigma^2
\end{aligned}$$

$$\begin{aligned}
V(\hat{\alpha}) &= \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum_{i=1}^n (X_i - \bar{X})^2} \\
&= \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n(\sum_{i=1}^n X_i^2 - n\bar{X}^2)} \\
&= \frac{\sigma^2 696}{4(696 - 4 \times 13^2)}
\end{aligned}$$

$$= \frac{696\sigma^2}{80} \\ = 8.7\sigma^2$$

$$\begin{aligned}\text{Cov}(\widehat{\alpha}, \widehat{\beta}) &= -\frac{\sigma^2 \bar{X}}{\sum_{i=1}^n (X_i - \bar{X})^2} \\ &= -\frac{\sigma^2 \bar{X}}{\sum_{i=1}^n X_i^2 - n \bar{X}^2} \\ &= -\frac{13\sigma^2}{696 - 4 \times 13^2} \\ &= -0.65\sigma^2\end{aligned}$$

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,

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

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

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

すなわち, $\widehat{\alpha}, \widehat{\beta}$ は,

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

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

を満たす。

さらに,

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

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

行列表示によって、

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

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

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

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。

$$\begin{pmatrix} V(\widehat{\alpha}) & Cov(\widehat{\alpha}, \widehat{\beta}) \\ Cov(\widehat{\alpha}, \widehat{\beta}) & V(\widehat{\beta}) \end{pmatrix}$$

$$\begin{aligned}
&= \sigma^2 \left(\frac{n}{\sum_{i=1}^n X_i} \frac{\sum_{i=1}^n X_i}{\sum_{i=1}^n X_i^2} \right)^{-1} \\
&= \frac{\sigma^2}{n \sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} \\
&\quad \times \begin{pmatrix} \sum_{i=1}^n X_i^2 & -\sum_{i=1}^n X_i \\ -\sum_{i=1}^n X_i & n \end{pmatrix} \\
&= \begin{pmatrix} \frac{\sigma^2 \sum_{i=1}^n X_i^2}{n \sum(X_i - \bar{X})^2} & -\frac{\sigma^2 \bar{X}}{\sum(X_i - \bar{X})^2} \\ -\frac{\sigma^2 \bar{X}}{\sum(X_i - \bar{X})^2} & \frac{\sigma^2}{\sum(X_i - \bar{X})^2} \end{pmatrix}
\end{aligned}$$

4.3.5 $\hat{\alpha}, \hat{\beta}$ の分布 (σ^2 が既知の場合)

統計学の復習 (正規分布について):

1. n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の分布に従うものとする。このとき,

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

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

となる。

2. n 個の独立な確率変数 X_1, X_2, \dots, X_n が同一の正規分布に従うものとする。
このとき,

$$\sum_{i=1}^n c_i X_i \sim N\left(\text{E}\left(\sum_{i=1}^n c_i X_i\right), \text{V}\left(\sum_{i=1}^n c_i X_i\right)\right)$$

となる。すなわち,

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

3. 特に, $X_i \sim N(\mu, \sigma^2)$, 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。)

$\widehat{\alpha}$, $\widehat{\beta}$ の分布:

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

よって,

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

となる。

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

よって、

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

となる。

4.3.6 $\widehat{\alpha}, \widehat{\beta}$ の性質：最良線型不偏性と一致性

統計学の復習 (推定量の望ましい性質) : $\widehat{\alpha}, \widehat{\beta}$ の性質を求めるために

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 $\widehat{\theta}$ を考える。

このとき、

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

となるとき、 $\widehat{\theta}$ は θ の不偏推定量であると言う。

$\widehat{\theta}$ は不偏性を持つと言う。

$E(\widehat{\theta}) - \theta$ は偏りと定義される。

(a) 標本平均 \bar{X} は μ の不偏推定量である。

証明 :

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

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。

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, $\widehat{\theta}$ を最小分散不偏推定量, または, 最良不偏推定量と言う。

(a) 推定量 $\sum_{i=1}^n c_i X_i$ の中で, $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ が最も小さな分散を持つ推定量となる。

⇒ 最良線型不偏推定量

3. 一致性:

ある母数 θ について推定量 $\widehat{\theta}$ を考える。 n 個の標本から構成された推定量を $\widehat{\theta}^{(n)}$ と定義する。

数列 $\widehat{\theta}^{(1)}, \widehat{\theta}^{(2)}, \dots, \widehat{\theta}^{(n)}, \dots$ を考える。

十分大きな n について, $\widehat{\theta}^{(n)}$ が θ に確率的に収束するとき, $\widehat{\theta}$ は θ の一致推定量であると言う。

$$\operatorname{plim}_{n \rightarrow \infty} \widehat{\theta} = \theta$$

と表現する。

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

(b) 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,

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

となるので、 \bar{X} は μ の一致推定量であると言える。

$\hat{\alpha}, \hat{\beta}$ の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： $\widehat{\beta}$ を変形すると以下の通りとなる。

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

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， $\widehat{\beta}$ 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。

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

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,

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

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、

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

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 つの条件が成り立つと仮定すると、

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

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,

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

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, $d_1 = d_2 = \dots = d_n = 0$ 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, 同様で, α の最小分散線型不偏推定量となる。

証明は,

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

を利用すればよい。

推定量の関係 \Rightarrow

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

一致性: $E(\widehat{\beta}) = \beta$ となることが分かった。

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

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

$n \rightarrow \infty$ のとき, $V(\widehat{\beta}) \rightarrow 0$ となれば, $\widehat{\beta}$ 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, $\sum_{i=1}^n (X_i - \bar{X})^2 \rightarrow \infty$ 」というものがなかった。この仮定は, 「 $n \rightarrow \infty$ のとき, $V(\widehat{\beta}) \rightarrow 0$ 」を保証する。よって, $\widehat{\beta}$ は β の一致推定量である。

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

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

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

4.4 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： $u_i \sim N(0, \sigma^2)$

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

u_i の分散 σ^2 の不偏推定量：

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