

# 専門セミナー（計量経済学の基礎）

## （2017年度 春～夏学期 講義ノート）

平成 29 年 4 月 27 日（木）版

参考書『基本統計学（第3版）』

（豊田・大谷・小川・長谷川・谷崎著，東洋経済新報社，2010年）

谷崎 久志  
大阪大学・経済学部

目次		4 行列について	6
1 度数分布 (P.3)	1	5 回帰分析	9
1.1 変数 (P.4)	1	5.1 重要な公式	9
1.2 度数分布 (P.4)	1	5.2 データについて	9
2 代表値 (P.15)	2	6 最小二乗法について：単回帰モデル	9
2.1 平均値 (P.16)	2	6.1 最小二乗法と回帰直線	9
2.2 分散，標準偏差 (P.20)	2	6.2 切片 $\alpha$ と傾き $\beta$ の求め方	9
2.3 範囲，四分位点，メディアン，モード (P.18)	3	6.3 残差 $\hat{u}_i$ の性質について	11
2.4 相関係数 (P.23)	4	6.4 決定係数 $R^2$ について	12
3 計量経済学について	4	6.5 決定係数の比較	13
3.1 例 1：マクロの消費関数	5	6.6 まとめ	14
3.2 例 2：日本酒の需要関数	5	7 最小二乗法について：重回帰モデル	14

7.1	重回帰モデルにおける回帰係数の意味 . . .	15
7.2	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 . . . . .	16

- この講義ノートは,  
<http://www2.econ.osaka-u.ac.jp/~tanizaki/class/2017>  
からダウンロード可。
- この講義ノートの文中のページは教科書『基本統計学  
(第3版)』のページに対応。

# 序説 (P.1)

## 1. 統計的記述 :

資料の収集と整理 (平均値・分散・メディアン等の計算) ⇒ 第 1, 2 章

## 2. 統計的推測 :

標本から母集団の特徴をつかむこと

- (a) 標本 : データを標本と考える
- (b) 母集団 : 標本を含む全体
- (c) 母集団の特徴 : 母集団の特性を表すパラメータ (母数という)
- (d) パラメータ (母数) : 平均, 分散

⇒ 母数 (パラメータ) の推定と仮説検定が主な内容

# 1 度数分布 (P.3)

## 1.1 変数 (P.4)

変数の種類 (P.4)

1. 連続型変数 : ある区間内の任意の実数値をとりうる変数 (身長, 体重, 温度, ...)
2. 離散型変数 : 不連続な値しかとらない変数 (サイコロの出た目, 家族数, ...)  
ただし, 離散型変数を連続型変数とみなす場合も多い (例 : 金額は離散型変数, 2009 年の GDP は  $470936.7 \times 10$  億円で, 1 円に対して, GNP の値はあまりにも大きい)

データの種類 (P.9,10)

1. 時系列データ : 時間に依存するデータ (P.6 の表 1.1, 表 1.2, P.9 の表 1.4)
2. クロスセクション・データ (横断面データ) : 家計, 企業等の一時点でのデータの系列 (P.10 の表 1.6)

## 1.2 度数分布 (P.4)

表 1.3 (P.7) のデータ (20 個の物体の重さ):

4.3 5.2 7.2 6.4 3.5 5.6 6.7 6.1 4.1 6.8  
5.0 5.6 3.8 4.6 5.8 5.1 6.2 5.3 7.4 5.9

このデータを整理する。

⇒ 表 1.4 (P.8)

階級値	階級境界値	度数
3.45	2.95~3.95	2
4.45	3.95~4.95	3
5.45	4.95~5.95	8
6.45	5.95~6.95	5
7.45	6.95~7.95	2
合計		20

をもとにして,

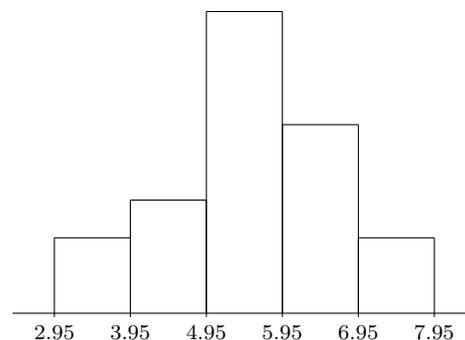
表 1.4 20 個の物体の重さの度数分布表

階級値	階級境界値	度数	相対度数	累積 度数	累積 相対度数
3.45	2.95~3.95	2	0.10	2	0.10
4.45	3.95~4.95	3	0.15	5	0.25
5.45	4.95~5.95	8	0.40	13	0.65
6.45	5.95~6.95	5	0.25	18	0.90
7.45	6.95~7.95	2	0.10	20	1.00
合計		20	1.000		

を得る。小数第 2 位の 0.05 の単位で区間を分けている理由  
→ 四捨五入の関係

小数第 1 位の 0.1 の単位で区間を分けた場合, 境界値がどの階級に属するか区別できなくなる。(例えば, 5.0 は 4.95 以上から 5.05 未満の間の数値)

図 1.1 20 個の物体の重さのグラフ (P.11)



グラフの形

- 右の裾野が広い  $\implies$  右に歪んでいる
- 左の裾野が広い  $\implies$  左に歪んでいる

### グラフの作り方

1. 階級境界値：階級の境界を定める値
2. 階級値：階級境界値の中点
3. 度数：ある階級に属するデータの数
4. 度数分布表：各階級とその度数を表に表したもの
5. ヒストグラム：度数分布をグラフに表す
6. 相対度数：各階級の度数をデータの総数で割ったもの、すなわち、各階級に属するデータの割合
7. 累積度数：ある階級以下の度数を合計したもの
8. 累積相対度数：ある階級以下の相対度数を合計したもの

## 2 代表値 (P.15)

度数分布表、ヒストグラム：統計データを整理し、母集団に関する情報を得る一つの方法。

分布の状態を数値で表したい。

代表値：データを代表する値  $\implies$  平均値，分散，標準偏差，中央値（メディアン），最頻値（モード），…

### 2.1 平均値 (P.16)

$n$  個のデータ：  $x_1, x_2, \dots, x_n$

算術平均 (P.16)：

$$\bar{x} = \frac{1}{n}(x_1 + x_2 + \dots + x_n) = \frac{1}{n} \sum_{i=1}^n x_i$$

表 1.3 (P.7) のデータから

$$\bar{x} = \frac{1}{20}(4.3 + 5.2 + \dots + 5.9) = 5.53$$

となる。

加重平均 (P.16)：

階級値	階級境界値		度数
	(以上)	(未満)	
$m_1$	$a_0 \sim a_1$		$f_1$
$m_2$	$a_1 \sim a_2$		$f_2$
$\vdots$	$\vdots$		$\vdots$
$m_k$	$a_{k-1} \sim a_k$		$f_k$
	合計		$n$

ただし、  $m_1 = \frac{a_0 + a_1}{2}$ ,  $m_2 = \frac{a_1 + a_2}{2}$ ,  $\dots$ ,  
 $m_k = \frac{a_{k-1} + a_k}{2}$  とする。

上のような度数分布表が利用可能なとき、

$$\bar{x} = \frac{1}{n}(f_1 m_1 + f_2 m_2 + \dots + f_k m_k) = \frac{1}{n} \sum_{i=1}^k f_i m_i$$

として、平均値を計算することが出来る。  $\implies$  加重平均 (各階級値を度数でウェイトづけして平均したもの)

$$\bar{x} = \sum_{i=1}^k \frac{f_i}{n} m_i$$

$\frac{f_i}{n}$  は相対度数である。

$\frac{f_i}{n}$  の表のデータの平均を求めると、

$$\begin{aligned} \bar{x} &= \frac{1}{20} (2 \times 3.45 + 3 \times 4.45 \\ &\quad + 8 \times 5.45 + 5 \times 6.45 + 2 \times 7.45) \\ &= 5.55 \end{aligned}$$

階級の幅の選び方によって、多少、値は異なる。

### 2.2 分散，標準偏差 (P.20)

分散，標準偏差：データの散らばり具合を表す

分散，標準偏差が大きければ、データの存在する範囲が広い  
 標準偏差 = 分散の平方根

分散 ( $s^2$  で表す) の定義：

$$\begin{aligned} s^2 &= \frac{1}{n} ((x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2) \\ &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \end{aligned}$$

ただし、  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  とする。

標準偏差：  $s$

分散の実際の計算には、

$$s^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2$$

を用いる。  
なぜなら、

$$\begin{aligned}
s^2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \\
&= \frac{1}{n} \sum_{i=1}^n (x_i^2 - 2\bar{x}x_i + \bar{x}^2) \\
&= \frac{1}{n} \left( \sum_{i=1}^n x_i^2 - 2\bar{x} \sum_{i=1}^n x_i + \sum_{i=1}^n \bar{x}^2 \right) \\
&= \frac{1}{n} \left( \sum_{i=1}^n x_i^2 - 2n\bar{x}^2 + n\bar{x}^2 \right) \\
&= \frac{1}{n} \left( \sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) \\
&= \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2
\end{aligned}$$

となる。

表 1.3 (P.7) のデータの分散を求めると、

$$\begin{aligned}
s^2 &= \frac{1}{20} \left( (4.3 - 5.53)^2 + (5.2 - 5.53)^2 + \dots \right. \\
&\quad \left. + (5.9 - 5.53)^2 \right) \\
&= 1.1591
\end{aligned}$$

または、

$$\begin{aligned}
s^2 &= \frac{1}{20} (4.3^2 + 5.2^2 + \dots + 5.9^2) - 5.53^2 \\
&= 1.1591
\end{aligned}$$

$s = 1.0766$  ===> 標準偏差

表 2.1 (P.17) の度数分布表からの計算では、

$$s^2 = \frac{1}{n} \sum_{i=1}^k f_i (m_i - \bar{x})^2$$

となる。ただし、 $\bar{x} = \frac{1}{n} \sum_{i=1}^k f_i m_i$  とする。

実際の計算には、

$$s^2 = \frac{1}{n} \sum_{i=1}^k f_i m_i^2 - \bar{x}^2$$

を使う。

なぜなら、

$$\begin{aligned}
s^2 &= \frac{1}{n} \sum_{i=1}^k f_i (m_i - \bar{x})^2 \\
&= \frac{1}{n} \sum_{i=1}^k f_i (m_i^2 - 2\bar{x}m_i + \bar{x}^2) \\
&= \frac{1}{n} \left( \sum_{i=1}^k f_i m_i^2 - 2\bar{x} \sum_{i=1}^k f_i m_i + \bar{x}^2 \sum_{i=1}^k f_i \right) \\
&= \frac{1}{n} \left( \sum_{i=1}^k f_i m_i^2 - 2n\bar{x}^2 + n\bar{x}^2 \right) \\
&= \frac{1}{n} \left( \sum_{i=1}^k f_i m_i^2 - n\bar{x}^2 \right) \\
&= \frac{1}{n} \sum_{i=1}^k f_i m_i^2 - \bar{x}^2
\end{aligned}$$

となる。

上の表のデータの分散を求めると、

$$\begin{aligned}
s^2 &= \frac{1}{20} \left( 2(3.45 - 5.55)^2 + 3(4.45 - 5.55)^2 \right. \\
&\quad \left. + 8(5.45 - 5.55)^2 + 5(6.45 - 5.55)^2 \right. \\
&\quad \left. + 2(7.45 - 5.55)^2 \right) \\
&= 1.19
\end{aligned}$$

または、

$$\begin{aligned}
s^2 &= \frac{1}{20} (2 \times 3.45^2 + 3 \times 4.45^2 \\
&\quad + 8 \times 5.45^2 + 5 \times 6.45^2 + 2 \times 7.45^2) - 5.55^2 \\
&= 1.19
\end{aligned}$$

すなわち、 $s = 1.0909$ 、

### 2.3 範囲，四分位点，メディアン，モード (P.18)

- 範囲： 最大値－最小値
- 四分位点：  
25 %点 (第1四分位点)，50 %点 (第2四分位点)，75 %点 (第3四分位点) のこと
- 四分位範囲： 第3四分位点－第1四分位点

- メディアン (中央値):  
大きい順に並べて, 真ん中の値 (第2四分位点) → 表 1.3 (P.7) のデータでは, 大きい順に並べて 10 番目と 11 番目のデータの平均で,  $(5.6 + 5.6)/2 = 5.6$
- モード (最頻値):  
最も多い度数の階級値 → 表 1.3 (P.7) のデータでは 5.45, 階級の幅によって変わる

## 2.4 相関係数 (P.23)

2変数データの組に関する代表値 ⇒ 共分散, 相関係数

例: 100 人の家計からの消費と所得, 身長と体重

$n$  組のデータ  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$

共分散  $s_{xy}$

$$\begin{aligned} s_{xy} &= \frac{1}{n} \left( (x_1 - \bar{x})(y_1 - \bar{y}) + (x_2 - \bar{x})(y_2 - \bar{y}) \right. \\ &\quad \left. + \dots + (x_n - \bar{x})(y_n - \bar{y}) \right) \\ &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \\ &= \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x}\bar{y} \end{aligned}$$

$s_{xy} > 0$ : 正の相関 ( $x$  と  $y$  との関係はプラスの傾き)

$s_{xy} < 0$ : 負の相関 ( $x$  と  $y$  との関係はマイナスの傾き)

$s_{xy} = 0$ : 相関なし ( $x$  と  $y$  との関係は正負の傾きを決定できず)

相関 ⇒ 互いにかかわりを持つこと。相互に関係しあっていること。(『国語大辞典(新装版)』小学館, 1988)

相関の強弱を表す指標 ⇒ 相関係数  $r$

$$r = \frac{s_{xy}}{s_x s_y}$$

ただし,

$$s_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2, \quad s_y^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2,$$

とし,  $s_x, s_y$  は  $x$  の標準偏差,  $y$  の標準偏差である。

$r > 0$ : 正の相関 ( $x$  と  $y$  との関係はプラスの傾き)

$r < 0$ : 負の相関 ( $x$  と  $y$  との関係はマイナスの傾き)

$r = 0$ : 相関なし ( $x$  と  $y$  との関係は正負の傾きを決定できず)

$r$  は,

$$-1 \leq r \leq 1$$

となる。

証明:

次のような  $t$  に関する式を考える。

$$f(t) = \frac{1}{n} \sum_{i=1}^n \left( (x_i - \bar{x})t - (y_i - \bar{y}) \right)^2,$$

平方和なので, 必ずゼロ以上となる。よって, すべての  $t$  について,  $f(t) \geq 0$  となるための条件を求めればよい。 $t$  に関する 2 次方程式の判別式がゼロ以下となる条件を求める。

$$\begin{aligned} f(t) &= t^2 \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \\ &\quad + 2t \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \\ &\quad + \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 \\ &= s_x^2 t^2 + 2s_{xy}t + s_y^2 \geq 0 \end{aligned}$$

判別式

$$\frac{D}{4} = s_{xy}^2 - s_x^2 s_y^2 \leq 0$$

$$\frac{s_{xy}^2}{s_x^2 s_y^2} \leq 1,$$

$$-1 \leq \frac{s_{xy}}{s_x s_y} \leq 1,$$

を得る。

$r$  が 1 に近いほど, 正の相関が強くなる ( $x$  と  $y$  のプロットが正の傾きで一直線上に近づく)。

$r$  が  $-1$  に近いほど, 負の相関が強くなる ( $x$  と  $y$  のプロットが負の傾きで一直線上に近づく)。

$r = -1, 1$  のとき,  $x$  と  $y$  は一直線上に並ぶ ( $r = 1$  は正の傾き,  $r = -1$  は負の傾き)。

## 3 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  $\implies$  経済理論が現実にな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。

### 3.1 例 1: マクロの消費関数

$$C = f(Y)$$

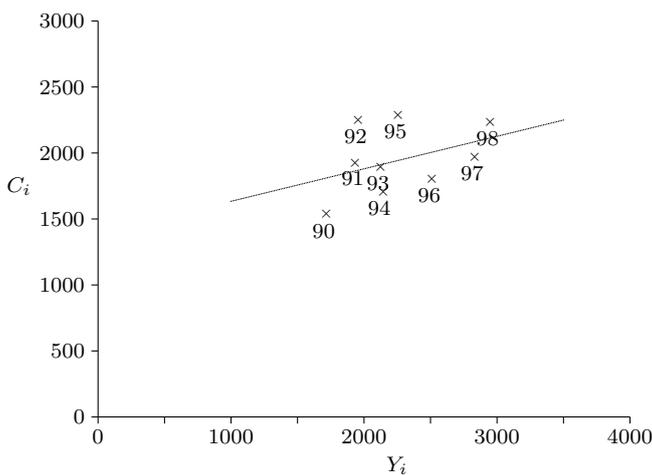
ただし,  $C$  は消費,  $Y$  は所得。

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.  $(Y_i, C_i) \implies t$  期のデータ, i.e.,  $i = 1, 2, \dots, 9$

3.  $i = 1 \implies 1990$  年,  
 $i = 2 \implies 1991$  年,  
...,  
 $i = 9 \implies 1998$  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。

### 3.2 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.  $Y \nearrow \implies Q \nearrow$ ,  
 $P_1 \nearrow \implies Q \searrow$ ,  
 $P_2 \nearrow \implies Q \nearrow$
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)

$$Q = a + b_1Y + b_2P_1 + b_3P_2$$

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)

$$Q = a + b_1Y + b_2\frac{P_1}{P_2}$$

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。

## 4 行列について

$A$  を  $2 \times 2$  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  $2 \times 1$  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  $1 \times 2$  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。

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

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 ( $1 \times 1$  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。

$$AB = \begin{pmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nk} \end{pmatrix} \begin{pmatrix} b_{11} & \cdots & b_{1n} \\ \vdots & \ddots & \vdots \\ b_{k1} & \cdots & b_{kn} \end{pmatrix}$$

$$= \begin{pmatrix} \sum_{m=1}^k a_{1m}b_{m1} & \cdots & \sum_{m=1}^k a_{1m}b_{mn} \\ \vdots & \ddots & \vdots \\ \sum_{m=1}^k a_{nm}b_{m1} & \cdots & \sum_{m=1}^k a_{nm}b_{mn} \end{pmatrix}$$

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。

$$BA = \begin{pmatrix} b_{11} & \cdots & b_{1n} \\ \vdots & \ddots & \vdots \\ b_{k1} & \cdots & b_{kn} \end{pmatrix} \begin{pmatrix} a_{11} & \cdots & a_{1k} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nk} \end{pmatrix}$$

$$= \begin{pmatrix} \sum_{m=1}^n b_{1m}a_{m1} & \cdots & \sum_{m=1}^n b_{1m}a_{mk} \\ \vdots & \ddots & \vdots \\ \sum_{m=1}^n b_{km}a_{m1} & \cdots & \sum_{m=1}^n b_{km}a_{mk} \end{pmatrix}$$

すなわち、 $BA$  は  $k \times k$  行列で、 $BA$  の  $ij$  要素は、 $b_{i1}a_{1j} + b_{i2}a_{2j} + \cdots + b_{ik}a_{kj} = \sum_{m=1}^k a_{im}b_{mj}$  となる。  
このように、 $AB$  と  $BA$  の次元は異なる。

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

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

$$= \begin{pmatrix} 1 \times 5 + 2 \times 7 & 1 \times 6 + 2 \times 8 \\ 3 \times 5 + 4 \times 7 & 3 \times 6 + 4 \times 8 \end{pmatrix}$$

$$= \begin{pmatrix} 19 & 22 \\ 43 & 50 \end{pmatrix}$$

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

$$= \begin{pmatrix} 5 \times 1 + 6 \times 3 & 5 \times 2 + 6 \times 4 \\ 7 \times 1 + 8 \times 3 & 7 \times 2 + 8 \times 4 \end{pmatrix}$$

$$= \begin{pmatrix} 23 & 34 \\ 31 & 46 \end{pmatrix}$$

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。

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

$I$  が  $n \times n$  行列のとき、 $I_n$  と書くことも多い。

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

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

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

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

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

$$\begin{pmatrix} 1 & & 0 \\ & \ddots & \\ 0 & & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$$

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,

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

となる。また,

$$I_n x = x$$

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  ${}^tA$ ) 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。

$$(A')' = A$$

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

## 5 回帰分析

### 5.1 重要な公式

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

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

$$3. \sum_{i=1}^n (X_i - \bar{X})^2 = \sum_{i=1}^n X_i^2 - n\bar{X}^2$$

$$4. \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) = \sum_{i=1}^n X_i Y_i - n\bar{X}\bar{Y} = \sum_{i=1}^n (X_i - \bar{X})Y_i = \sum_{i=1}^n (Y_i - \bar{Y})X_i$$

$$5. 2 \times 2 \text{ 行列の逆行列の公式: } \begin{pmatrix} a & b \\ c & d \end{pmatrix}^{-1} = \frac{1}{ad - bc} \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$$

## 5.2 データについて

1. タイム・シリーズ (時系列)・データ：添え字  $i$  が時間を表す (第  $i$  期)。  $t$  を添え字に使う場合も多い。
2. クロス・セクション (横断面)・データ：添え字  $i$  が個人や企業を表す (第  $i$  番目の家計, 第  $i$  番目の企業)。

## 6 最小二乗法について：単回帰モデル

最小二乗法とは、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である。

### 6.1 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、 $\alpha, \beta$  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。切片  $\alpha$  と傾き  $\beta$  をデータ  $\{(X_i, Y_i), i = 1, 2, \dots, n\}$  から推定することを考える。

ある基準の下で、 $\alpha$  と  $\beta$  の推定値が求められたとしよう。それぞれ、 $\hat{\alpha}$  と  $\hat{\beta}$  とする。データ  $\{(X_i, Y_i), i = 1, 2, \dots, n\}$  と直線との関係は、

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

となる。すなわち、実際のデータ  $Y_i$  と直線上の値  $\hat{\alpha} + \hat{\beta} X_i$  との間には、誤差  $\hat{u}_i$  (残差と呼ばれる) が生じる。

### 6.2 切片 $\alpha$ と傾き $\beta$ の求め方

$\alpha, \beta$  のある推定値を  $\hat{\alpha}, \hat{\beta}$  としよう。次のような関数  $S(\hat{\alpha}, \hat{\beta})$  を定義する。

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

これは残差平方和と呼ばれる。

このとき、

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

となるような  $\hat{\alpha}, \hat{\beta}$  を求める (最小自乗法)。最小化のためには,

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

を満たす  $\hat{\alpha}, \hat{\beta}$  を求める。

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

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

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

を満たす。

さらに,

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

$$\sum_{i=1}^n X_i Y_i = \hat{\alpha} \sum_{i=1}^n X_i + \hat{\beta} \sum_{i=1}^n X_i^2 \quad (4)$$

(3) 式の辺々を  $n$  で割って,

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

すなわち,

$$\bar{Y} = \hat{\alpha} + \hat{\beta}\bar{X} \quad (5)$$

を得る。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。

さらに,  $\sum_{i=1}^n X_i = n\bar{X}$  と (5) 式を利用して,  $\hat{\alpha}$  を消去すると,

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

$\hat{\beta}$  で整理して,

$$\begin{aligned} \hat{\beta} &= \frac{\sum_{i=1}^n X_i Y_i - n\bar{X}\bar{Y}}{\sum_{i=1}^n X_i^2 - n\bar{X}^2} \\ &= \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} = \frac{S_{XY}}{S_X^2} \end{aligned} \quad (6)$$

が得られ,  $\hat{\alpha}$  は (5) 式から,

$$\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X} \quad (7)$$

となる。ただし,

$$S_{XY} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$$

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

とする。

または, 行列を用いて解くこともできる。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,

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

さらに,  $\hat{\beta}$  について解くと,

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

$\hat{\alpha}$  については,

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

となる。

回帰直線は,

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

として与えられる。 $\hat{Y}_i$  は,  $X_i$  を与えたときの  $Y_i$  の予測値と解釈される。

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

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

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

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

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。

$i$	$X_i$	$Y_i$	$X_i^2$	$X_i Y_i$
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		

表中では， $\sum_{i=1}^n$  を  $\sum$  と省略して表記している。

よって，

$$\hat{\beta} = \frac{46 - 5 \times 3 \times 2.6}{55 - 5 \times 3^2} = \frac{7}{10} = 0.7$$

$$\hat{\alpha} = 2.6 - 0.7 \times 3 = 0.5,$$

となる。

注意事項：

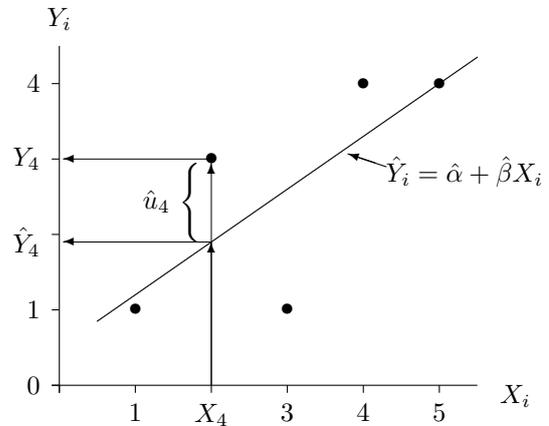
1.  $\alpha, \beta$  は真の値で未知である。
2.  $\hat{\alpha}, \hat{\beta}$  は  $\alpha, \beta$  の推定値でデータから計算される。

回帰直線は， $\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i$  であり，上の数値例では，

$$\hat{Y}_i = 0.5 + 0.7 X_i,$$

となる。 $\hat{Y}_1, \hat{Y}_2, \dots, \hat{Y}_5$  として，次の表のように計算される。 $Y_i, X_i, \hat{Y}_i, \hat{u}_i$  の関係が図 1 に描かれている。

図 1:  $Y_i, X_i, \hat{Y}_i, \hat{u}_i$  の関係



$i$	$X_i$	$Y_i$	$X_i^2$	$X_i Y_i$	$\hat{Y}_i$
1	5	4	25	20	4.0
2	1	1	1	1	1.2
3	3	1	9	3	2.6
4	2	3	4	6	1.9
5	4	4	16	16	3.3
合計	$\sum X_i$	$\sum Y_i$	$\sum X_i^2$	$\sum X_i Y_i$	$\sum \hat{Y}_i$
	15	13	55	46	13
平均	$\bar{X}$	$\bar{Y}$			
	3	2.6			

$\hat{Y}_i$  を実績値  $Y_i$  の予測値または理論値と呼ぶ。

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

$\hat{u}_i$  を残差と呼ぶ。 $Y_i, \hat{Y}_i, \hat{u}_i$  の関係， $\hat{Y}_i, X_i, \hat{\alpha}, \hat{\beta}$  の関係は，

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

の式でまとめられる。

### 6.3 残差 $\hat{u}_i$ の性質について

$\hat{u}_i = Y_i - \hat{\alpha} - \hat{\beta} X_i$  に注意すると，(1) 式，(2) 式から，

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

を得る。また， $\hat{Y}_i = \hat{\alpha} + \hat{\beta} X_i$  から，

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

が得られる。なぜなら、

$$\sum_{i=1}^n \hat{Y}_i \hat{u}_i = \sum_{i=1}^n (\hat{\alpha} + \hat{\beta} X_i) \hat{u}_i = \hat{\alpha} \sum_{i=1}^n \hat{u}_i + \hat{\beta} \sum_{i=1}^n X_i \hat{u}_i = 0$$

となるからである。

数値例で確認してみよう。

$i$	$X_i$	$Y_i$	$\hat{Y}_i$	$\hat{u}_i$	$X_i \hat{u}_i$	$\hat{Y}_i \hat{u}_i$
1	5	4	4.0	0.0	0.0	0.00
2	1	1	1.2	-0.2	-0.2	-0.24
3	3	1	2.6	-1.6	-4.8	-4.16
4	2	3	1.9	1.1	2.2	2.09
5	4	4	3.3	0.7	2.8	2.31
合計	$\sum X_i$	$\sum Y_i$	$\sum \hat{Y}_i$	$\sum \hat{u}_i$	$\sum X_i \hat{u}_i$	$\sum \hat{Y}_i \hat{u}_i$
	15	13	13	0.0	0.0	0.0
平均	$\bar{X}$	$\bar{Y}$				
	3	2.6				

## 6.4 決定係数 $R^2$ について

$Y_i, \hat{Y}_i, \hat{u}_i$  の関係は、

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

であった。 $\bar{Y}$  を両辺から引くと、

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

が得られる。さらに、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。二つ目の等式の右辺第二項では、 $\sum_{i=1}^n \hat{Y}_i \hat{u}_i = \bar{Y} \sum_{i=1}^n \hat{u}_i = 0$  が使われている。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、両辺を左辺で割ると、

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

が得られる。それぞれの項は、

1.  $\sum_{i=1}^n (Y_i - \bar{Y})^2 \rightarrow Y_i$  の全変動
2.  $\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 \rightarrow \hat{Y}_i$  (回帰直線) で説明される部分
3.  $\sum_{i=1}^n \hat{u}_i^2 \rightarrow \hat{Y}_i$  (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  $R^2$  が、

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}, \quad (8)$$

のように定義される。 $R^2$  は  $Y_i$  のうち  $\hat{Y}_i$  (または、 $X_i$ ) で説明できる比率を意味する。または、

$$R^2 = 1 - \frac{\sum_{i=1}^n \hat{u}_i^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}, \quad (9)$$

として書き換えることもできる。

**$R^2$  の取り得る範囲:** さらに、 $R^2$  の取り得る範囲を求める。(8) 式の右辺の分子と分母は共に正なので、 $R^2 \geq 0$  となる。(9) 式の右辺では 1 から第二項の正の値 (分子分母共に正) を差し引いているので、 $R^2 \leq 1$  となることが分かる。すなわち、 $R^2$  の取り得る範囲は、

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

となる。

$R^2 = 1$  となる場合はすべての  $i$  について  $\hat{u}_i = 0$  となり、観測されたデータ  $(X_i, Y_i)$  は一直線上に並んでいる状態となる。

$R^2 = 0$  となる場合は二通りが考えられる。一つは、 $Y_i$  が  $X_i$  に影響されないときで、 $\hat{\beta} = 0$  の状態、すなわち、データが横軸に平行に一直線上に並んでいる状態となる。もう一つは、データが円状に散布していて、どこにも直線が引けない状態である (ちなみに、データが楕円上に散布している場合は、直線が引ける状態である)。

実際のデータを用いた場合は  $R^2 = 0$  や  $R^2 = 1$  という状況はあり得ない。 $R^2$  が 1 に近づけば回帰式の当てはまりは良い、 $R^2$  が 0 に近づけば回帰式の当てはまりは悪いと言える。しかし、「どの値よりも大きくなるべき」といった基準はない。慣習的には、メドとして 0.9 以上が当てはまりが良いと判断する。

データと  $R^2$  との関係は、後述の 6.5 節で、数値例を挙げながら解説する。

**$R^2$  の別の解釈:**  $R^2$  のもう一つの解釈をするために、 $R^2$  の右辺の分子を、

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

と書き換える。最初の等式では、括弧二乗の一つに  $\hat{Y}_i = Y_i - \hat{u}_i$  が用いられている。 $R^2$  は、

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

と書き換えられる。この式では、 $R^2$  が  $Y_i$  と  $\hat{Y}_i$  の相関係数の二乗と解釈されることを意味する。なお、二つ目の等号の右式では、分子と分母に  $\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$  を掛けていることに注意せよ。

特に、単回帰の場合、 $\hat{Y}_i = \hat{\alpha} + \hat{\beta}X_i$  と  $\bar{Y} = \hat{\alpha} + \hat{\beta}\bar{X}$  を用いて、

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

を利用すると、

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

$$\begin{aligned} &= \frac{\hat{\beta}^2 \sum_{i=1}^n (X_i - \bar{X})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \\ &= \left(\frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2} \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}}\right)^2 \\ &= \frac{S_{XY}^2}{S_X^2 S_Y^2}, \end{aligned}$$

としても書き換えられる。すなわち、単回帰の場合、決定係数は説明変数  $X_i$  と被説明変数  $Y_i$  との相関係数の二乗となる。

数値例： 決定係数の計算には以下の公式を用いる。

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

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

$i$	$X_i$	$Y_i$	$\hat{Y}_i$	$\hat{u}_i$	$\hat{u}_i^2$	$Y_i^2$
1	5	4	4.0	0.0	0.00	16
2	1	1	1.2	-0.2	0.04	1
3	3	1	2.6	-1.6	2.56	1
4	2	3	1.9	1.1	1.21	9
5	4	4	3.3	0.7	0.49	16
合計	$\sum X_i$ 15	$\sum Y_i$ 13	$\sum \hat{Y}_i$ 13	$\sum \hat{u}_i$ 0.0	$\sum \hat{u}_i^2$ 4.3	$\sum Y_i^2$ 43
平均	$\bar{X}$ 3	$\bar{Y}$ 2.6				

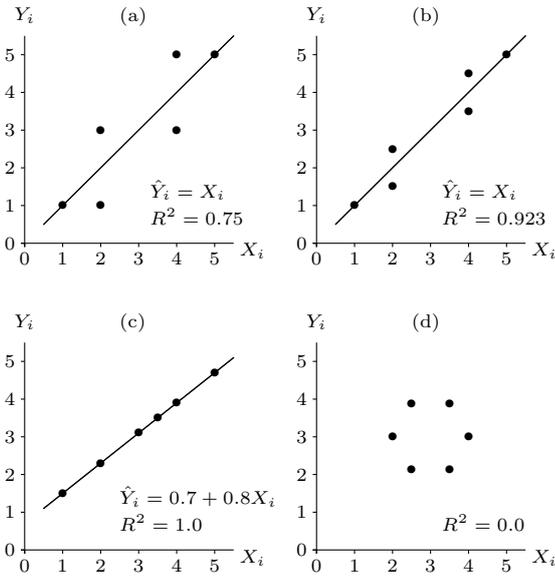
$\bar{Y} = 2.6$ 、 $\sum_{i=1}^n \hat{u}_i^2 = 4.3$ 、 $\sum_{i=1}^n Y_i^2 = 43$  なので、

$$R^2 = 1 - \frac{4.3}{43 - 5 \times 2.6^2} = \frac{4.9}{9.2} = 0.5326$$

## 6.5 決定係数の比較

次の数値例を用いて、決定係数の比較を行おう。 $X$  と  $Y$  のプロットしたものが図 2(a)~(d) である。

図 2: 決定係数の比較



	(a)		(b)		(c)		(d)	
$i$	$X_i$	$Y_i$	$X_i$	$Y_i$	$X_i$	$Y_i$	$X_i$	$Y_i$
1	1	1	1	1	1	1.5	1	3
2	2	1	2	1.5	2	2.3	2.5	2.134
3	2	3	2	2.5	3	3.1	2.5	3.866
4	4	3	4	3.5	3.5	3.5	3.5	2.134
5	4	5	4	4.5	4	3.9	3.5	3.866
6	5	5	5	5	5	4.7	4	3

(a) と (b) のどちらの場合も、切片・傾きの値は  $\hat{\alpha} = 0$ ,  $\hat{\beta} = 1$  として計算されるが、決定係数について、(a) は 0.75, (b) は 0.923 となる（読者はチェックすること）。データのプロットと回帰直線は図 2 の (a) と (b) に描かれている。 $X_i$  はどちらも同じ数値とした。横軸  $X$  が 2, 4 のケースについて、(b) が (a) より直線に近くなるように、 $Y$  の値を変えてみた。(b) のデータの方が (a) より直線に近いために、決定係数が 0.923 と 1 に近い値となっているのが分かる。

(c) はデータが一直線上に並んでいる場合で、決定係数が 1 となる。決定係数がゼロとなるのは (d) の場合で、 $X$  と  $Y$  との関係を表す直線が描けない場合である。(d) の数値例では、 $X$  と  $Y$  との関係が円としているが、満遍なく散布している状態と考えてもらえば良い。

## 6.6 まとめ

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

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

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

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。

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

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

## 7 最小二乗法について：重回帰モデル

$k$  変数の多重回帰モデルを考える。

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

$X_{ji}$  は  $j$  番目の説明変数の第  $i$  番目の観測値を表す。 $\beta_1, \beta_2, \dots, \beta_k$  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、 $\beta_1$  は定数項として表される。 $n$  組のデータ  $(Y_i, X_{1i}, X_{2i}, \dots, X_{ki})$ ,  $i = 1, 2, \dots, n$  を用いて、 $\beta_1, \beta_2, \dots, \beta_k$  を求める。

ある基準の下で、 $\beta_1, \beta_2, \dots, \beta_k$  の解を  $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$  としよう。データ  $\{(X_i, Y_i), i = 1, 2, \dots, n\}$  と直線との関係は、

$$Y_i = \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \cdots + \hat{\beta}_k X_{ki} + \hat{u}_i = \hat{Y}_i + \hat{u}_i,$$

となる。すなわち、すべての  $i$  について、実際のデータ  $Y_i$  と直線上の値  $\hat{Y}_i = \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \cdots + \hat{\beta}_k X_{ki}$  が一致することはあり得ないので、残差  $\hat{u}_i$  の二乗和を考える。

次のような関数  $S(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)$  を定義する。

$$S(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k) = \sum_{i=1}^n \hat{u}_i^2$$

$$= \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i} - \cdots - \hat{\beta}_k X_{ki})^2$$

このとき、

$$\min_{\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k} S(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)$$

となるような  $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$  を求める。  $\implies$  最小自乗法  
最小化のためには、

$$\begin{aligned} \frac{\partial S(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)}{\partial \hat{\beta}_1} &= 0 \\ \frac{\partial S(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)}{\partial \hat{\beta}_2} &= 0 \\ &\vdots \\ \frac{\partial S(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)}{\partial \hat{\beta}_k} &= 0 \end{aligned}$$

を満たす  $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$  となる。

すなわち、 $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$  は、

$$\begin{aligned} \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i} - \dots - \hat{\beta}_k X_{ki}) X_{1i} &= 0, \\ \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i} - \dots - \hat{\beta}_k X_{ki}) X_{2i} &= 0, \\ &\vdots \\ \sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i} - \dots - \hat{\beta}_k X_{ki}) X_{ki} &= 0, \end{aligned}$$

を満たす。

さらに、

$$\begin{aligned} \sum_{i=1}^n X_{1i} Y_i &= \hat{\beta}_1 \sum_{i=1}^n X_{1i}^2 + \hat{\beta}_2 \sum_{i=1}^n X_{1i} X_{2i} + \dots + \hat{\beta}_k \sum_{i=1}^n X_{1i} X_{ki} \\ \sum_{i=1}^n X_{2i} Y_i &= \hat{\beta}_1 \sum_{i=1}^n X_{1i} X_{2i} + \hat{\beta}_2 \sum_{i=1}^n X_{2i}^2 + \dots + \hat{\beta}_k \sum_{i=1}^n X_{2i} X_{ki} \\ &\vdots \\ \sum_{i=1}^n X_{ki} Y_i &= \hat{\beta}_1 \sum_{i=1}^n X_{1i} X_{ki} + \hat{\beta}_2 \sum_{i=1}^n X_{2i} X_{ki} + \dots + \hat{\beta}_k \sum_{i=1}^n X_{ki}^2 \end{aligned}$$

行列表示によって、

$$\begin{pmatrix} \sum X_{1i} Y_i \\ \sum X_{2i} Y_i \\ \vdots \\ \sum X_{ki} Y_i \end{pmatrix} = \begin{pmatrix} \sum X_{1i}^2 & \sum X_{1i} X_{2i} & \dots & \sum X_{1i} X_{ki} \\ \sum X_{1i} X_{2i} & \sum X_{2i}^2 & \dots & \sum X_{2i} X_{ki} \\ \vdots & \vdots & \ddots & \vdots \\ \sum X_{1i} X_{ki} & \sum X_{2i} X_{ki} & \dots & \sum X_{ki}^2 \end{pmatrix} \begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \vdots \\ \hat{\beta}_k \end{pmatrix}$$

が得られる。

$\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$  についてまとめると、

$$\begin{pmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \\ \vdots \\ \hat{\beta}_k \end{pmatrix} = \begin{pmatrix} \sum X_{1i}^2 & \sum X_{1i} X_{2i} & \dots & \sum X_{1i} X_{ki} \\ \sum X_{1i} X_{2i} & \sum X_{2i}^2 & \dots & \sum X_{2i} X_{ki} \\ \vdots & \vdots & \ddots & \vdots \\ \sum X_{1i} X_{ki} & \sum X_{2i} X_{ki} & \dots & \sum X_{ki}^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum X_{1i} Y_i \\ \sum X_{2i} Y_i \\ \vdots \\ \sum X_{ki} Y_i \end{pmatrix}$$

を解くことになる。  $\implies$  コンピュータによって計算

$\sum_{i=1}^n X_{ji} X_{li}$ ,  $\sum_{i=1}^n X_{ji} Y_i$  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。

## 7.1 重回帰モデルにおける回帰係数の意味

結論： 他の変数の影響を取り除いての被説明変数への影響を表す。

$k = 2$  の単純なモデル：

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

$\beta_1, \beta_2$  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。

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

一方、次の2つの回帰式を考える。

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

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

$\alpha_1, \alpha_2$  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。

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

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

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

「 $Y_i$  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  $\hat{\beta}_1$  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  $\beta_j$  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。

## 7.2 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,  $\hat{Y}_i = \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \cdots + \hat{\beta}_k X_{ki}$ ,  $Y_i = \hat{Y}_i + \hat{u}_i$  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  $\sigma^2$  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。(  $k = 1$  のときのみに, 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。

$i$	$X_i$	$Y_i$	$\hat{Y}_i$	$\hat{u}_i$	$\hat{u}_i^2$	$Y_i^2$
1	5	4	4.0	0.0	0.00	16
2	1	1	1.2	-0.2	0.04	1
3	3	1	2.6	-1.6	2.56	1
4	2	3	1.9	1.1	1.21	9
5	4	4	3.3	0.7	0.49	16
合計	$\sum X_i$ 15	$\sum Y_i$ 13	$\sum \hat{Y}_i$ 13	$\sum \hat{u}_i$ 0.0	$\sum \hat{u}_i^2$ 4.3	$\sum Y_i^2$ 43
平均	$\bar{X}$ 3	$\bar{Y}$ 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,

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

となり,  $\bar{R}^2$  は,

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

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