

特殊講義（計量經濟分析1）

水曜 1時間目（AM8:50 – 10:20）

法經講義棟 4番講義室

2025年4月16日

第1章 回帰分析

1.1 準備

1.1.1 重要な公式

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

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

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

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

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

1.1.2 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)。

1.2 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。

1.2.1 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。切片 α と傾き β をデータ $\{(X_i, Y_i), i = 1, 2, \dots, n\}$ から求める（推定する）ことを考える。

ある基準の下で、 α と β 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、差 $\hat{u}_i$ (残差と呼ばれる) が生じる。

1.2.2 切片 α と傾き β の求め方

α, β 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。

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

この $S(\hat{\alpha}, \hat{\beta})$ 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,

$$\sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}X_i) = 0, \quad (1.1)$$

$$\sum_{i=1}^n X_i(Y_i - \hat{\alpha} - \hat{\beta}X_i) = 0, \quad (1.2)$$

を満たす。

さらに,

$$\sum_{i=1}^n Y_i = n\hat{\alpha} + \hat{\beta} \sum_{i=1}^n X_i \quad (1.3)$$

$$\sum_{i=1}^n X_i Y_i = \hat{\alpha} \sum_{i=1}^n X_i + \hat{\beta} \sum_{i=1}^n X_i^2 \quad (1.4)$$

(1.3) 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,

$$\bar{Y} = \hat{\alpha} + \hat{\beta}\bar{X} \quad (1.5)$$

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 (1.5) 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,

$$\hat{\beta} = \frac{\sum_{i=1}^n X_i Y_i - n\bar{X}\bar{Y}}{\sum_{i=1}^n X_i^2 - n\bar{X}^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} = \frac{S_{XY}}{S_X^2} \quad (1.6)$$

が得られ, $\hat{\alpha}$ は (1.5) 式から,

$$\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X} \quad (1.7)$$

となる。ただし,

$$S_{XY} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}), \quad S_X^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

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,

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

さらに, $\hat{\beta}$ について解くと,

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

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

$\hat{\alpha}$ 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 α , β 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 Σ と省略して表記している。

よって,

$$\hat{\beta} = \frac{46 - 5 \times 3 \times 2.6}{55 - 5 \times 3^2} = \frac{7}{10} = 0.7, \quad \hat{\alpha} = 2.6 - 0.7 \times 3 = 0.5,$$

となる。

注意事項：

1. α, β は真の値で未知である。
2. $\hat{\alpha}, \hat{\beta}$ は α, β 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、

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

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 1.1 に描かれている。

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。

図 1.1: Y_i , X_i , $\hat{Y}_i$, $\hat{u}_i$ の関係

1.2.3 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, (1.1) 式, (1.2) 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	X_i^2	$X_i Y_i$	$\hat{Y}_i$	$\hat{u}_i$	$X_i \hat{u}_i$	$\hat{Y}_i \hat{u}_i$
1	5	4	25	20	4.0	0.0	0.0	0.00
2	1	1	1	1	1.2	-0.2	-0.2	-0.24
3	3	1	9	3	2.6	-1.6	-4.8	-4.16
4	2	3	4	6	1.9	1.1	2.2	2.09
5	4	4	16	16	3.3	0.7	2.8	2.31
合計	$\sum X_i$	$\sum Y_i$	$\sum X_i^2$	$\sum X_i Y_i$	$\sum \hat{Y}_i$	$\sum \hat{u}_i$	$\sum X_i \hat{u}_i$	$\sum \hat{Y}_i \hat{u}_i$
	15	13	55	46	13	0.0	0.0	0.0
平均	$\bar{X}$	$\bar{Y}$						
	3	2.6						

1.2.4 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,

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}, \quad (1.8)$$

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,

$$R^2 = 1 - \frac{\sum_{i=1}^n \hat{u}_i^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}, \quad (1.9)$$

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。(1.8) 式の右辺の分子と分母は共に正なので、 $R^2 \geq 0$ となる。(1.9) 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 1.2.5 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、

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

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、

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

を利用すると、

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

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	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	$\sum X_i$ 15	$\sum Y_i$ 13	$\sum X_i^2$ 55	$\sum X_i Y_i$ 46	$\sum \hat{Y}_i$ 13	$\sum \hat{u}_i$ 0.0	$\sum X_i \hat{u}_i$ 0.0	$\sum \hat{Y}_i \hat{u}_i$ 0.0	$\sum \hat{u}_i^2$ 4.3	$\sum Y_i^2$ 43
平均	$\bar{X}$ 3	$\bar{Y}$ 2.6								

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

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

1.2.5 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1.2(a)~(d)である。

	(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 1.2 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。

1.2.6 まとめ

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

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

図 1.2: 決定係数の比較



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。

1.3 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、 β_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。

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

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。 $\Rightarrow$ 最小自乗法
最小化のためには,

$$\frac{\partial S(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)}{\partial \hat{\beta}_1} = 0, \quad \frac{\partial S(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)}{\partial \hat{\beta}_2} = 0, \quad \dots, \quad \frac{\partial S(\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k)}{\partial \hat{\beta}_k} = 0$$

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,

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

$$\sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i} - \cdots - \hat{\beta}_k X_{ki}) X_{2i} = 0,$$

$$\vdots$$

$$\sum_{i=1}^n (Y_i - \hat{\beta}_1 X_{1i} - \hat{\beta}_2 X_{2i} - \cdots - \hat{\beta}_k X_{ki}) X_{ki} = 0,$$

を満たす。

さらに,

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

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

$$\vdots$$

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

行列表示によって,

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

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

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

を解くことになる。⇒ コンピュータによって計算

1.3.1 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：

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

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。

1.3.2 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	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	$\sum X_i$ 15	$\sum Y_i$ 13	$\sum X_i^2$ 55	$\sum X_i Y_i$ 46	$\sum \hat{Y}_i$ 13	$\sum \hat{u}_i$ 0.0	$\sum X_i \hat{u}_i$ 0.0	$\sum \hat{Y}_i \hat{u}_i$ 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,

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

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