

第2章 最小2乗法と決定係数

『入門 実践する計量経済学』

PPT

- **回帰モデル**
- **データの整理**
- **最小2乗法**
- **回帰直線と予測**
- **残差の性質**
- **決定係数**

回帰モデル

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_K X_K$$

--- Y は被説明変数

--- X_1, X_2, \dots, X_K は、 K 個の説明変数

--- 関心はパラメータ($\alpha, \beta_1, \beta_2, \dots, \beta_K$)の推定にある

--- α : 数学的切片、もしくは $X = 0$ のときの Y の値

--- $\beta_1, \beta_2, \dots, \beta_K$: 回帰係数

--- 回帰係数 β_1

X_1 以外の説明変数を一定として、 X_1 を1単位増やしたとき、 Y が何単位変化するか

[証明] $Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_K X_K$ から、
 X_1 を1単位増やすと

$$Y' = \alpha + \beta_1(X_1 + 1) + \beta_2 X_2 + \dots + \beta_K X_K$$

このとき、 Y の変化分は β_1 となる

$$\begin{aligned} Y' - Y &= [\alpha + \beta_1(X_1 + 1) + \beta_2 X_2 + \dots + \beta_K X_K] \\ &\quad - [\alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_K X_K] = \beta_1 \end{aligned} \quad \text{[終]}$$

--- 説明変数が1個なら単回帰モデル($K=1$)、
2個以上なら重回帰モデルと呼ばれる($2 \leq K$)

--- 本章では単回帰モデルを扱う

$$Y_i = \alpha + \beta X_i \quad (i = 1, 2, \dots, n)$$

データの整理

・ データ

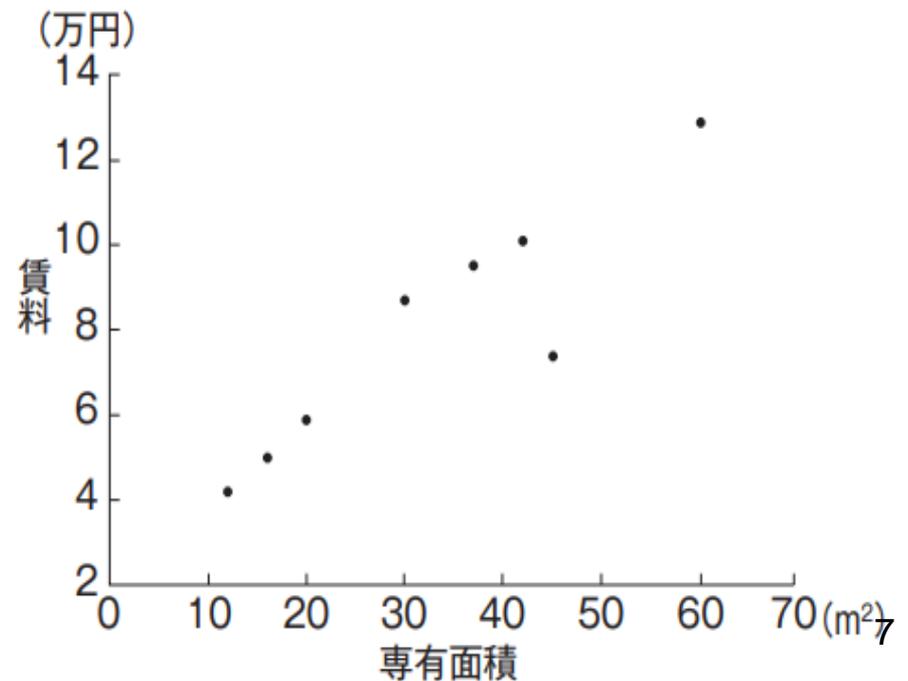
(Y_1, X_1) 、 (Y_2, X_2) 、 \dots 、 (Y_n, X_n)

--- サンプルサイズは n 個

・ 表 2 - 2 賃料と専有面積

i	賃料(万円) Y	面積(m^2) X
1	4.2	12
2	5.0	16
3	5.9	20
4	7.4	45
5	8.7	30
6	9.5	37
7	10.1	42
8	12.9	60

・ 図 2 - 1 賃料と専有面積の関係を表す散布図



特性値の復習

- 標本平均

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

--- データの中心を測る代表的指標

- 標本分散

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

--- データのばらつきを測る指標

- 標本標準偏差

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

--- データのばらつきを測る指標

- 標本共分散

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

--- $s_{XY} > 0$ なら正の相関、 $s_{XY} < 0$ なら負の相関

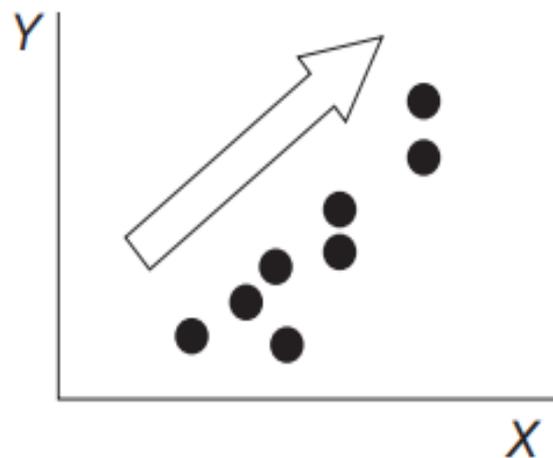
- 標本相関係数

$$r_{XY} = \frac{s_{XY}}{\sqrt{s_X^2 s_Y^2}} = \frac{s_{XY}}{s_X s_Y}$$

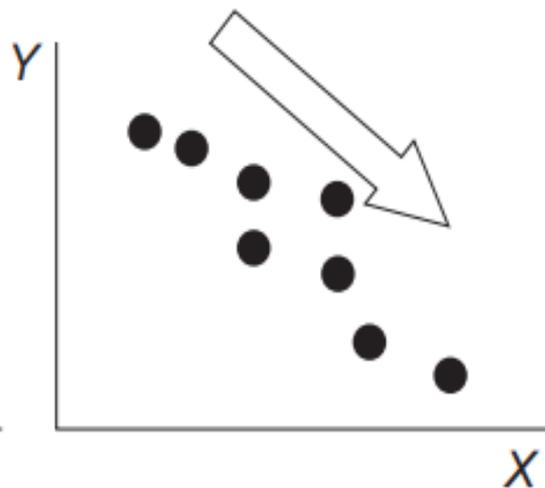
--- -1 から $+1$ の間で定義される

図 2 - 2 相関関係のイメージ

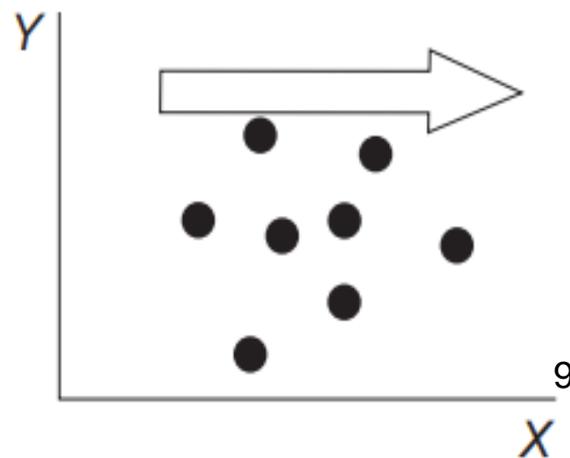
(a) 正の相関



(b) 負の相関



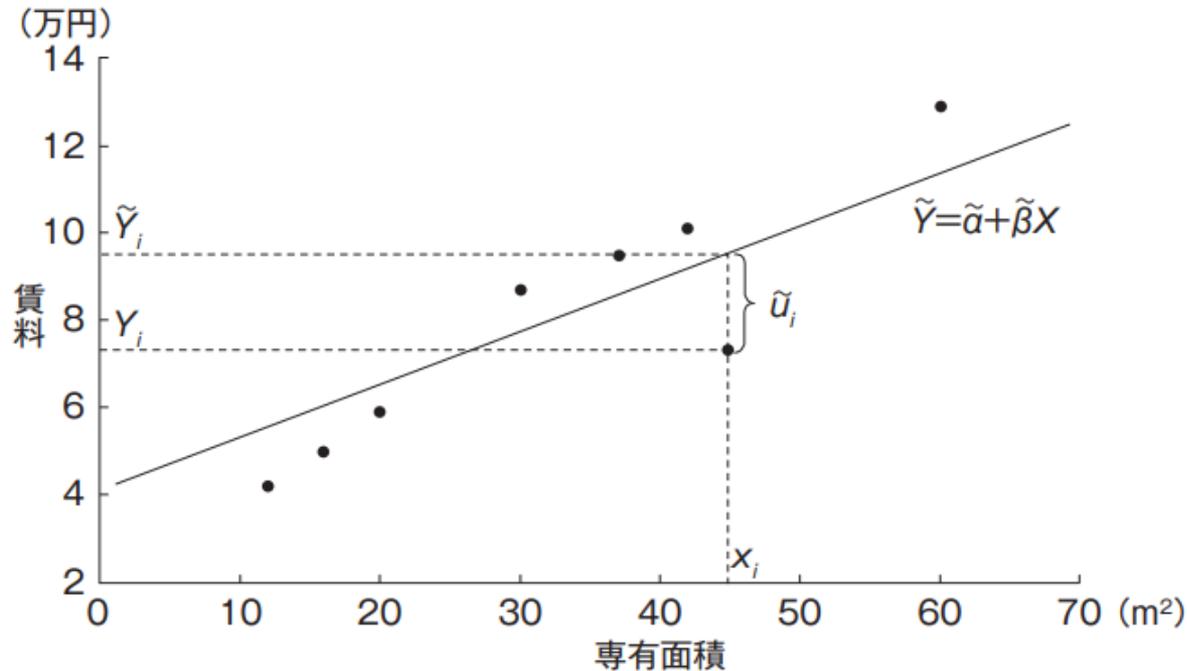
(c) 相関なし



最小2乘法

当てはまりの良い線をどうやって引いたらよいか？

図 2 - 4 線形関係と残差



- データは $(X_1, Y_1)(X_2, Y_2) \dots (X_n, Y_n)$
- 残差 \tilde{u}_i が「小さい」ほど、当てはまりが良い

$$\tilde{u}_i = Y_i - \tilde{Y}_i = Y_i - (\tilde{\alpha} + \tilde{\beta}X_i)$$

残差を小さくするように線を引けばよい！

・ 残差の総和

$$\sum_{i=1}^n \tilde{u}_i = \sum_{i=1}^n (Y_i - \tilde{\alpha} - \tilde{\beta} X_i)$$

--- プラスとマイナスで打ち消し合ってしまう

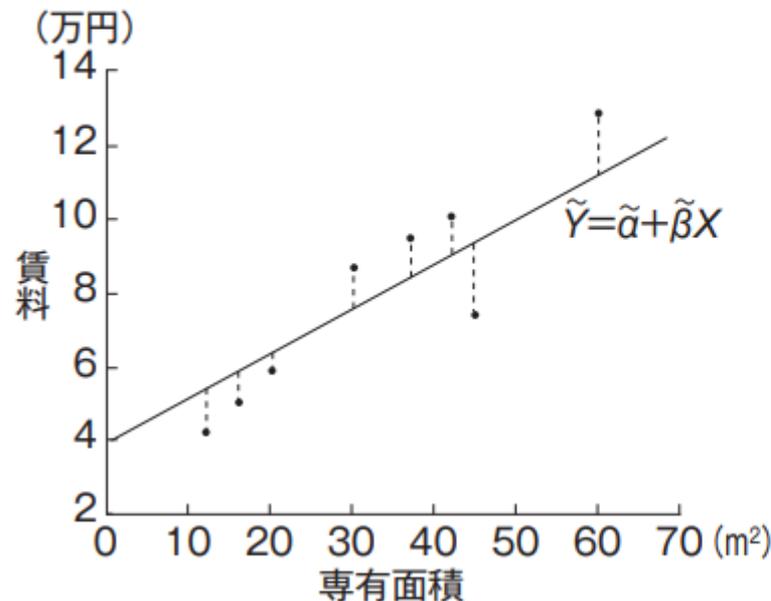
・ 残差2乗和

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

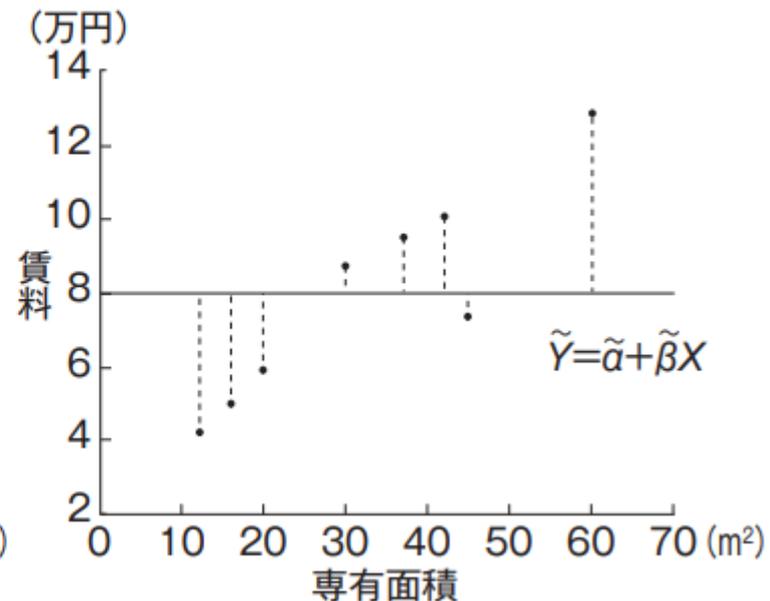
--- 全てプラスになるため打ち消し合わない

図 2-5 全物件の残差

(a) $\tilde{\beta} > 0$ とした場合



(b) $\tilde{\beta} = 0$ とした場合



- ・ 最小2乗推定量 (OLS推定量)

$\tilde{\alpha}, \tilde{\beta}$ を残差2乗和を最小に選ぶ ($\hat{\alpha}$ と $\hat{\beta}$ と表記)

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

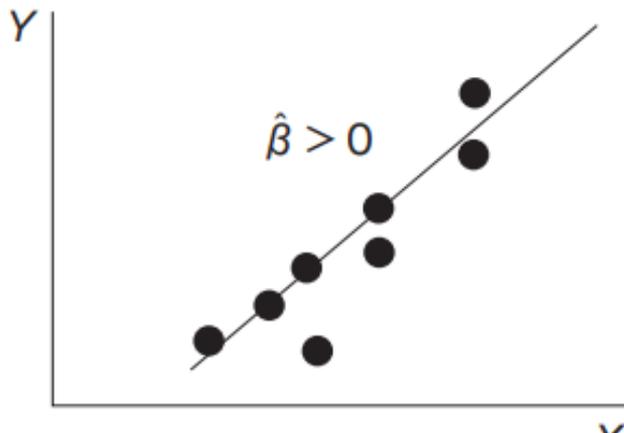
$\hat{\beta}$ の意味を考える

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

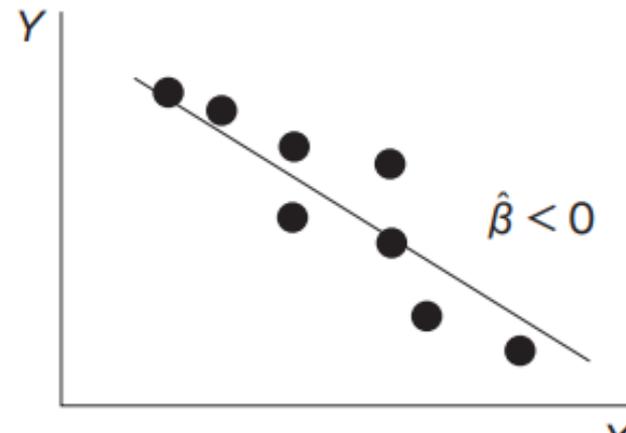
- 分子は X と Y の標本共分散、分母は X の標本分散、
⇒傾きの符号条件は標本共分散にだけ依存する
- 標本共分散が正(負)なら、傾きは正(負)

図 2 - 6 係数と標本共分散の符号

(a) 標本共分散がプラスの場合



(b) 標本共分散がマイナスの場合

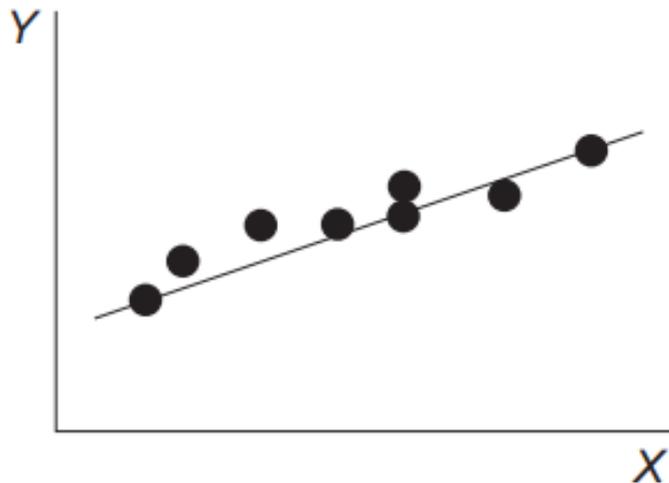


$$\hat{\beta} = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(X_i - \bar{X}) / (n - 1)}{\sum_{i=1}^n (X_i - \bar{X})^2 / (n - 1)}$$

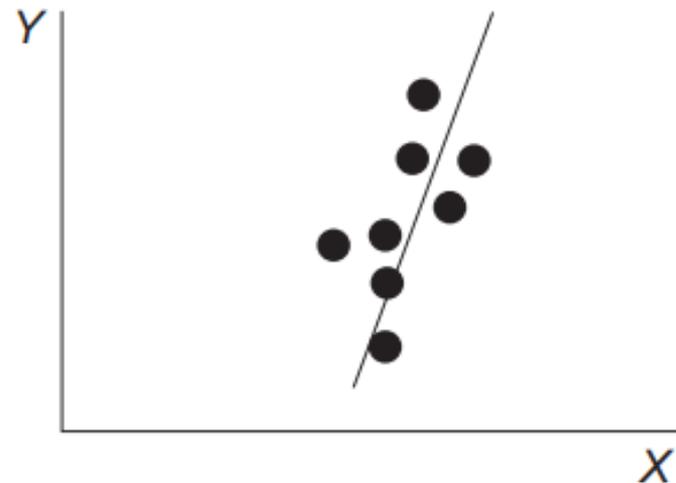
--- X の分散が大きい(小さい)ほど傾きはゆるい(きつい)

図 2 - 7 X の標本分散と傾きの関係

(a) X の標本分散が大きい場合



(b) X の標本分散が小さい場合



$\hat{\alpha}$ の意味を考える

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

- α は、次の n 個の方法でも推定できる

$$Y_1 - \hat{\beta}X_1, Y_2 - \hat{\beta}X_2, \dots, Y_n - \hat{\beta}X_n$$

[証明] $Y_i = \alpha + \beta X_i$

$$\Rightarrow \alpha = Y_i - \beta X_i \quad [\text{終}]$$

- これら n 個の平均をとったものが $\hat{\alpha}$ となる

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

回帰直線と予測

重要な概念

- ・回帰直線：残差2乗和を最小にする直線

$$\hat{Y} = \hat{\alpha} + \hat{\beta}X$$

- ・予測値(理論値)： X に具体的値 X_i を代入して求めた回帰直線上の値

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

- ・残差：観測値 Y_i と予測値 \hat{Y}_i との差

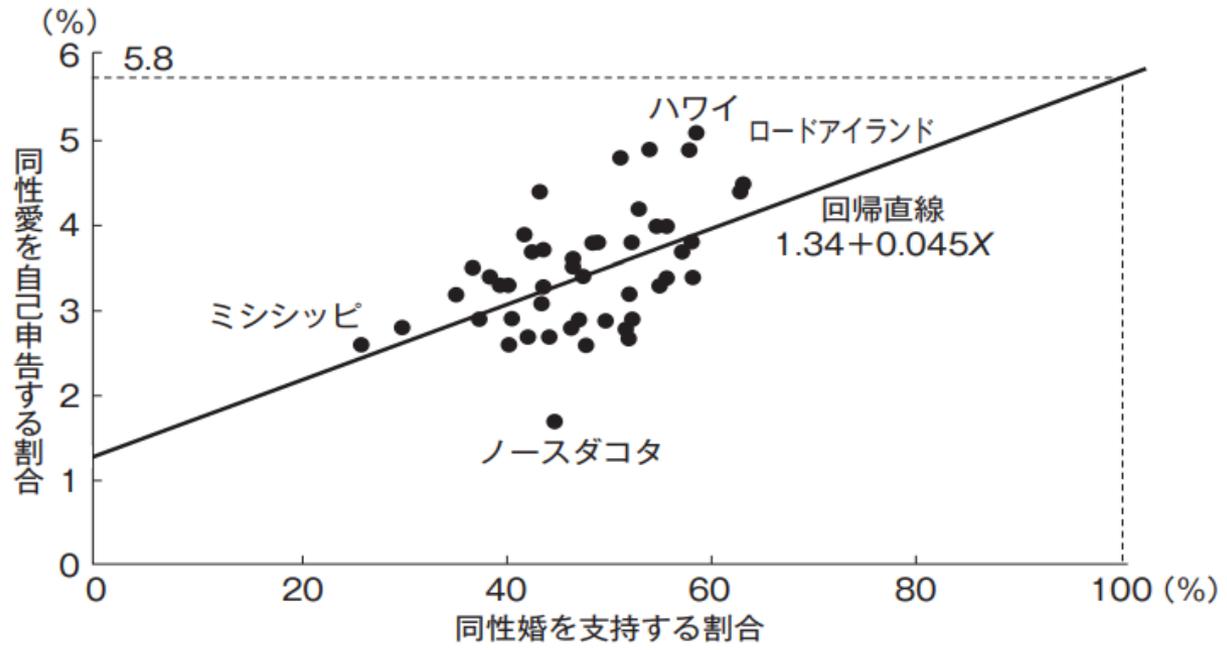
$$\hat{u}_i = Y_i - \hat{Y}_i = Y_i - (\hat{\alpha} + \hat{\beta}X_i)$$

- ・実現値の分解： $Y_i = \hat{Y}_i + \hat{u}_i = \underbrace{\hat{\alpha} + \hat{\beta}X_i}_{\text{モデルで説明できた部分}} + \underbrace{\hat{u}_i}_{\text{モデルで説明できなかった部分}}$

モデルで説明できた部分

モデルで説明できなかった部分

例) 同性愛者の割合(米国州別データ)



$$\hat{Y}_i = 1.34 + 0.045X_i$$

- X_i : 同性婚を支持する割合、 Y_i : 同性愛を自己申告する割合
- $\hat{\beta} = 0.045$: 支持割合が1%ポイント上がると、
自己申告が0.045%ポイント増える
- $\hat{\alpha} = 1.34$ は、支持割合が0%のとき、自己申告は1.34%しかない
- 支持が100%なら、自己申告の予測値は、
 $1.34 + 0.045 \times 100 = 5.8\%$

最小2乗推定量の導出

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

- 残差2乗和を最小化する $\tilde{\alpha}$ と $\tilde{\beta}$ を求める

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

- $\tilde{\alpha}$ と $\tilde{\beta}$ でそれぞれ偏微分して0と置く

$$\frac{\partial \sum \tilde{u}_i^2}{\partial \tilde{\alpha}} = \sum \frac{\partial \tilde{u}_i^2}{\partial \tilde{\alpha}} = \sum \frac{\partial \tilde{u}_i^2}{\partial \tilde{u}_i} \frac{\partial \tilde{u}_i}{\partial \tilde{\alpha}} \quad \text{合成関数の微分の公式}$$

$$= \sum 2\tilde{u}_i(-1) = \underline{-2 \sum (Y_i - \hat{\alpha} - \hat{\beta}X_i) = 0}$$

$$\frac{\partial}{\partial \tilde{\beta}} \sum \tilde{u}_i^2 = \sum \frac{\partial \tilde{u}_i^2}{\partial \tilde{\beta}} = \sum \frac{\partial \tilde{u}_i^2}{\partial \tilde{u}_i} \frac{\partial \tilde{u}_i}{\partial \tilde{\beta}}$$

$$= \sum 2\tilde{u}_i(-X_i) = \underline{-2 \sum (Y_i - \hat{\alpha} - \hat{\beta}X_i)X_i = 0}$$

- 正規方程式

$$\textcircled{1} \quad \sum (Y_i - \hat{\alpha} - \hat{\beta}X_i) = 0$$

$$\textcircled{2} \quad \sum (Y_i - \hat{\alpha} - \hat{\beta}X_i)X_i = 0$$

- $\hat{u}_i = Y_i - \hat{\alpha} - \hat{\beta}X_i$ から、以下の残差の性質が得られる

$$\textcircled{1}' \quad \sum \hat{u}_i = 0 \quad (\text{残差の和は0})$$

$$\textcircled{2}' \quad \sum \hat{u}_i X_i = 0 \quad (\text{残差と説明変数の積和は0})$$

・ 正規方程式①から

$$\sum(Y_i - \hat{\alpha} - \hat{\beta}X_i) = \sum Y_i - n\hat{\alpha} - \hat{\beta} \sum X_i = 0$$

両辺を n で割ると

$$\frac{\sum Y_i}{n} - \hat{\alpha} - \hat{\beta} \frac{\sum X_i}{n} = 0$$

となり、これを $\hat{\alpha}$ について解くと $\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X}$ となる。

・ 正規方程式②に、 $\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{X}$ を代入すると

$$\begin{aligned}\sum(Y_i - \hat{\alpha} - \hat{\beta}X_i)X_i &= \sum(Y_i - (\bar{Y} - \hat{\beta}\bar{X}) - \hat{\beta}X_i)X_i \\ &= \sum(Y_i - \bar{Y} - \hat{\beta}(X_i - \bar{X}))X_i \\ &= \sum(Y_i - \bar{Y})X_i - \hat{\beta} \sum (X_i - \bar{X})X_i = 0\end{aligned}$$

よって、

$$\hat{\beta} = \frac{\sum(Y_i - \bar{Y})X_i}{\sum(X_i - \bar{X})X_i} = \frac{\sum(Y_i - \bar{Y})(X_i - \bar{X})}{\sum(X_i - \bar{X})^2}$$

偏差の和は0

$$\begin{aligned}\sum(Y_i - \bar{Y})(X_i - \bar{X}) &= \sum(Y_i - \bar{Y})X_i - \bar{X} \sum(Y_i - \bar{Y}) = \sum(Y_i - \bar{Y})X_i \\ \sum(X_i - \bar{X})(X_i - \bar{X}) &= \sum(X_i - \bar{X})X_i - \bar{X} \sum(X_i - \bar{X}) = \sum(X_i - \bar{X})^2\end{aligned}$$

- ・ 偏差の和は0

$$\begin{aligned}\sum_{i=1}^n (Y_i - \bar{Y}) &= \sum_{i=1}^n Y_i - n\bar{Y} \\ &= \sum_{i=1}^n Y_i - n \frac{\sum_{i=1}^n Y_i}{n} \\ &= \sum_{i=1}^n Y_i - \sum_{i=1}^n Y_i = 0\end{aligned}$$

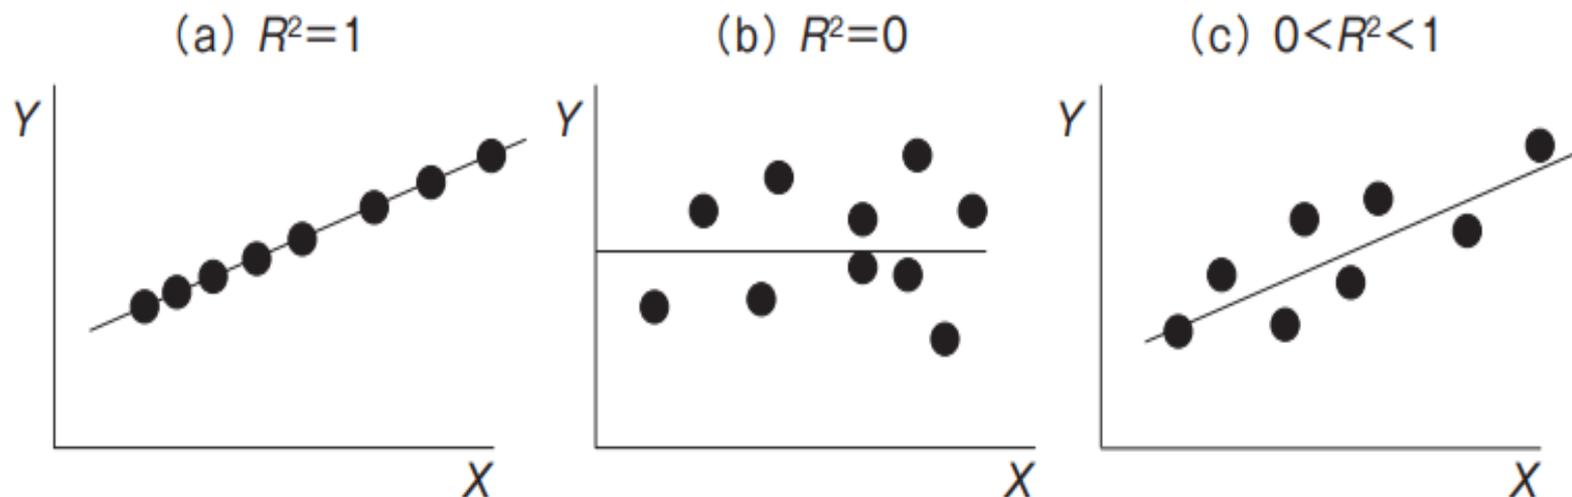
--- 数式展開で用いられる性質

決定係数

決定係数： 当てはまりの良さを測る指標

--- 0~1で定義、1に近いほど当てはまり良い

図 2-10 決定係数



--- Y の変動をどれぐらい予測値の変動で説明できるか

--- 実現値の分解

$$Y_i = \hat{Y}_i + \hat{u}_i = \underbrace{\hat{\alpha} + \hat{\beta}X_i}_{\text{モデルで説明できた部分}} + \underbrace{\hat{u}_i}_{\text{モデルで説明できなかった部分}}$$

モデルで説明できた部分 モデルで説明できなかった部分

- Yの全変動を分解する

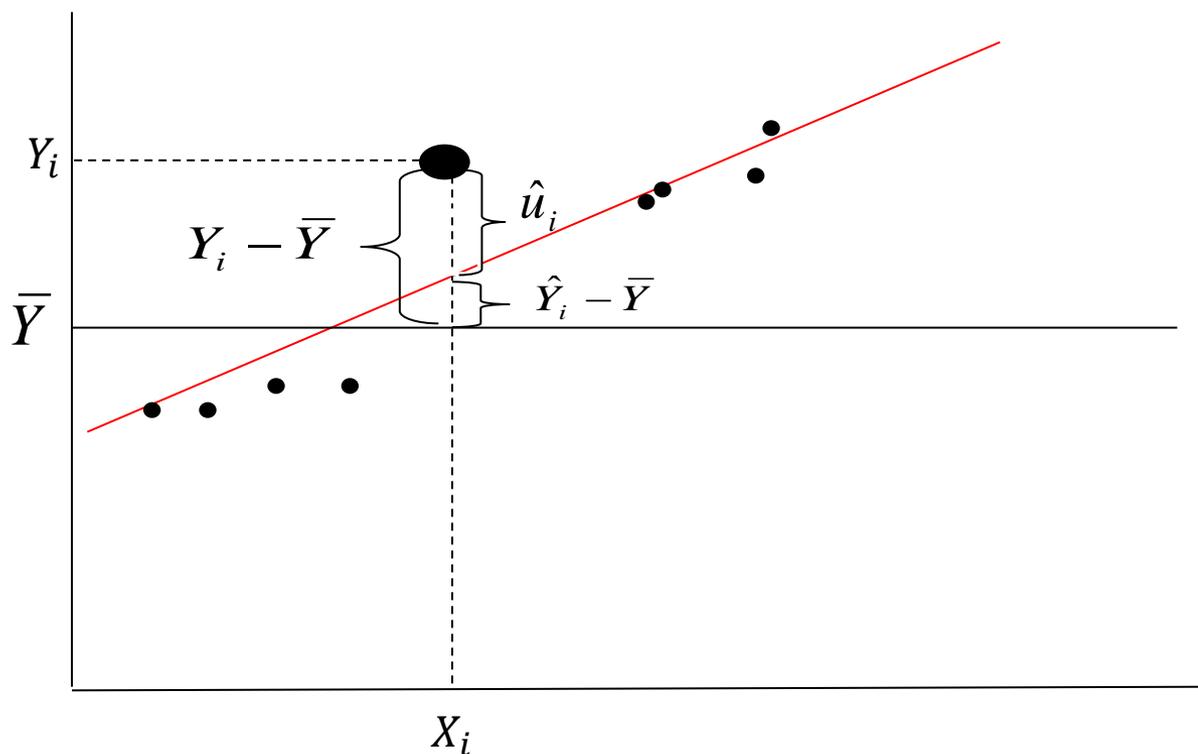
$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \underbrace{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}_{\text{モデルで説明された Y の変動}} + \underbrace{\sum_{i=1}^n \hat{u}_i^2}_{\text{モデルで説明されなかった Y の変動}}$$

Yの全変動

モデルで説明された
Yの変動

モデルで説明されなかった
Yの変動

図 2 - 9 偏差の分解



[証明]

・ここで $Y_i = \hat{Y}_i + \hat{u}_i$ から、 Y_i の全変動は

$$\begin{aligned}\sum_{i=1}^n (Y_i - \bar{Y})^2 &= \sum_{i=1}^n (\hat{Y}_i + \hat{u}_i - \bar{Y})^2 \\ &= \sum_{i=1}^n ((\hat{Y}_i - \bar{Y}) + \hat{u}_i)^2 \\ &= \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n \hat{u}_i^2 + 2 \underbrace{\sum_{i=1}^n (\hat{Y}_i - \bar{Y}) \hat{u}_i}_{=0}\end{aligned}$$

[第3項目が0の証明]

残差の性質は、

- ① $\sum \hat{u}_i = 0$ (残差の和は0)
- ② $\sum \hat{u}_i X_i = 0$ (残差と説明変数の積和は0)

①②を用いると、

$$\sum_{i=1}^n (\hat{Y}_i - \bar{Y}) \hat{u}_i = \sum_{i=1}^n \hat{Y}_i \hat{u}_i - \bar{Y} \sum_{i=1}^n \hat{u}_i = 0$$

なお、

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

決定係数：モデルで説明された変動 ÷ Yの全変動

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

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

式展開

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

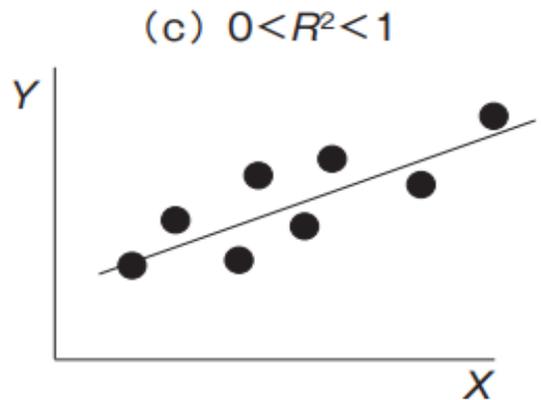
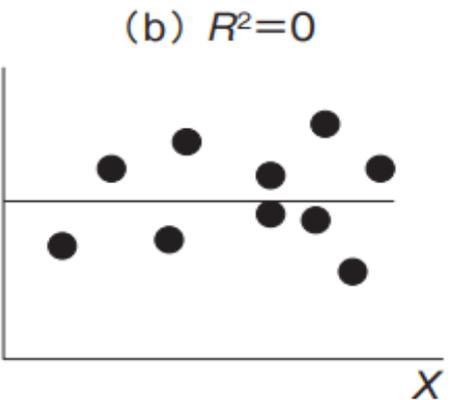
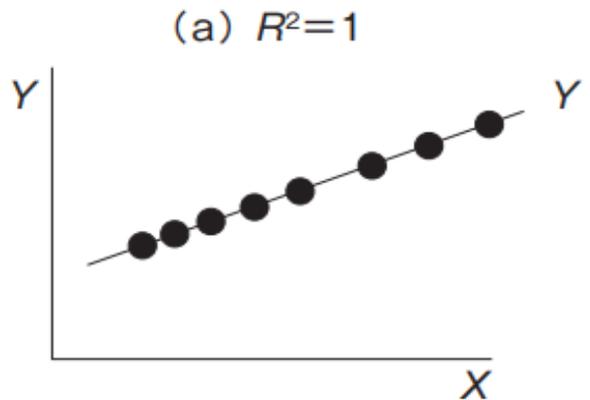
$$\Rightarrow \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = \sum_{i=1}^n (Y_i - \bar{Y})^2 - \sum_{i=1}^n \hat{u}_i^2$$

よって、

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

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

図 2-10 決定係数

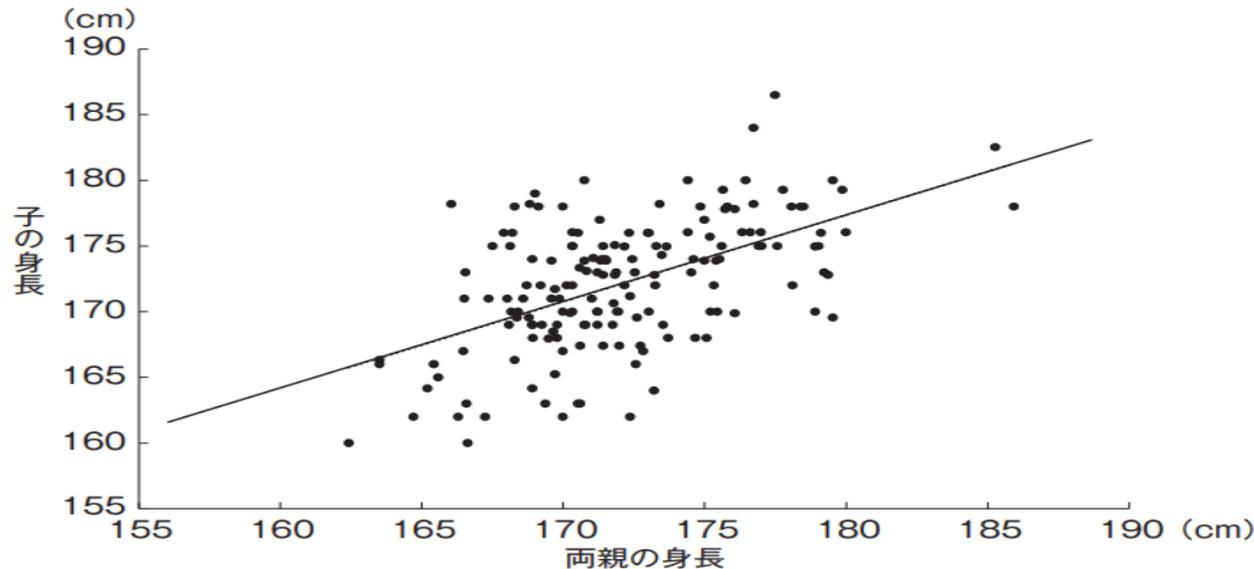


- (a) 残差は0なので R^2 は1となる
- (b) 残差が大きいため R^2 は0に近い値となる
- (c) 通常、 R^2 は0より大きく、1より小さい

例) 両親と子供の身長

- 両親の平均身長 = (父親の身長 + 1.08 × 母親の身長) / 2
- 子供の身長、ただし、娘の身長は1.08 × 娘の本当の身長

図 2-11 親子の身長の関係



$$\widehat{\text{子供の身長}}_i = 58.41 + 0.661 \text{両親の身長}_i$$

- $\beta = 0.661$: 両親が1cm高いと子供の身長も0.661cm高くなる
- $\alpha = 58.41$ は数学的切片と解釈する
- 決定係数は0.295 (子供の身長の変動のうち29.5%が親の身長から説明できる)

- ・ 両親の平均身長190cmなら、子供は

$$58.41 + 0.661 \times 190 = 184cm$$

両親の平均身長160cmなら、子供は

$$58.41 + 0.661 \times 160 = 164cm$$

ゴールトンの「平均への回帰」

親の身長が高いと子供の身長も高くなるが、
親の身長ほど高くはない

まとめ

- **回帰モデル**

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_K X_K$$

- **最小2乗法**

- 当てはまりの良い線を引く

- **予測**

- 推定された回帰直線に基づいた予測

- **決定係数**

- 当てはまりの尺度(0~1で定義される)