

統計解析論 第2回


最小二乗法による係数推定

1. 最小二乗法による線形回帰

- 線形回帰
 - データに**最も**フィットする直線を決める
 - 最もフィット? 基準は?
- 最小二乗法
 - 基準の一つ
 - 回帰直線からのデータの隔たりの2乗の合計を最小にするという基準
 - 他の基準
 - はずれの絶対値の合計を最小化するなどさまざまな基準があるが、最小二乗法はもっともポピュラー

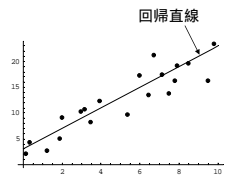
1.1 最小二乗基準

- 問題
 - 与えられたデータの組にもっとも当てはまる直線を求めよ
- 最小二乗基準
 - 「もっとも当てはまる」の意味?
 - その一つの答え
 - 誤差の二乗の合計が最小
 - 誤差とは右図の縦線の長さ



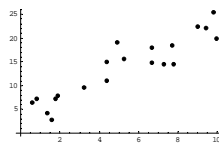
2. 用語(1)

- 回帰直線
- 回帰式
 - 回帰直線を式で表したもの
 - 一般的には $Y = \alpha + \beta X$ と表すことができる
 - 誤差を含めると $Y = \alpha + \beta X + \text{誤差項}$
- 説明変数 X
 - $Y = \alpha + \beta X = \alpha \times 1 + \beta \times X$ と解釈すると X と 1 が説明変数とも理解できる.
- 被説明変数 Y
 - X, Y は例えば所得, 消費などの変数を表す



2. 用語(2)

- 前のスライドは説明変数, 被説明変数間の関係を扱った
- データの値を表す
 - データの値は小文字で表す
 - 何番目のデータかはその添え字で表す $(x_1, y_1), (x_2, y_2), \dots$
 - $y_i = \alpha + \beta x_i + \text{誤差項}$
- データ数 = 標本数 n



i	x_i	X	Y	y_i
1	x_1	7.27	14.50	y_1
2	x_2	6.66	17.95	y_2
3	x_3	4.36	11.00	y_3
20	x_{20}	1.86	7.89	y_{20}

3. 最小二乗法

- 最小二乗法
 - 最小二乗基準に従ってデータに最もフィットする回帰直線を求める.
- 問題の変形
 - 最小二乗基準 誤差の二乗の合計の最小化
 - 変化させるパラメータ = 係数 $Y = \alpha + \beta X + \text{誤差項}$ の
 - 誤差の二乗の和を $\sum (y_i - (\alpha + \beta x_i))^2$ の式で表す
 - 誤差 = $y_i - (\alpha + \beta x_i)$

3.1 最小二乗法の解

- 変形された問題
 - $\sum_{i=1}^n \text{誤差}_i^2 = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$ を最小化する α, β を求める.
 - このような α, β をデータの値だけの式で表す.
- 解答のための方針
 - 最小化の二つの方向
 - 微分
 - 二次関数化

7

3. 最小二乗法の解 (2)

- 標本平均
 - 例
 - Xのデータの標本平均 $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$
 - Yのデータの値の二乗の標本平均 $\bar{y^2} = \frac{1}{n} \sum_{i=1}^n y_i^2$
 - 性質
 - $\sum_{i=1}^n (x_i - \bar{x}) = \sum_{i=1}^n x_i - \sum_{i=1}^n \bar{x} = \sum_{i=1}^n x_i - \bar{x} \sum_{i=1}^n 1 = \sum_{i=1}^n x_i - n\bar{x}$
 - $= n \left(\frac{1}{n} \sum_{i=1}^n x_i - \bar{x} \right) = 0$
 - $\sum_{i=1}^n \text{定数}(x_i - \bar{x}) = \text{定数} \sum_{i=1}^n (x_i - \bar{x}) = 0$

8

3.2 最小二乗法による係数推定

- 最小二乗法による係数値の決定法
 - 理論的に最小値を探す = 微分
 - 結果
 - 推定した回帰直線(式)

$$y = \hat{\alpha} + \hat{\beta}x$$
 - $\hat{\alpha}, \hat{\beta}$ で誤差の2乗の合計が最小になったとする

$$\hat{\beta} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad \hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}$$

9

3.3 残差とその性質

- 残差
 - 回帰直線からのデータの隔たり

$$\hat{u}_i = y_i - (\hat{\alpha} + \hat{\beta} x_i)$$
- 残差の性質
 - 説明変数と残差の積の合計は0 $\sum_{i=1}^n \hat{u}_i x_i = 0$
 - 残差の和は0 $\sum_{i=1}^n \hat{u}_i = 0$

10

3.4 分散分析(1)

- RSS (Sum of Squared Residuals) <残差変動>

$$RSS = \sum_{i=1}^n \hat{u}_i^2$$
- TSS (Total Sum of Squared Deviation) <全変動>

$$TSS = \sum_{i=1}^n (y_i - \bar{y})^2$$
- ESS (Explained Sum of Squared Deviation) <回帰変動>

$$ESS = \sum_{i=1}^n \{(\hat{\alpha} + \hat{\beta} x_i) - (\hat{\alpha} + \hat{\beta} \bar{x})\}^2$$

$$= \sum_{i=1}^n \hat{\beta}^2 (x_i - \bar{x})^2$$

11

3.5 分散分析と決定係数

- 分散分析

$$TSS = RSS + ESS$$
- 重決定係数
 - ESSのTSSに対する割合
 - yの変動のうちどれだけ回帰変動で説明できるか
 - 回帰式の説明力の指標

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} \quad (R^2 \leq 1)$$

12

3.6 (重)相関係数と重決定係数

- (重)相関係数(復習)

$$r = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (-1 \leq r \leq 1)$$

- 重決定係数との関係

$$R^2 = r^2$$

- 相関係数の絶対値は線形関係の当てはまりの強さを示す

13

4. 変数変換と回帰係数

- 変数変換

$$y_i = \alpha + \beta x_i + \text{誤差項}$$

$$z_i = cy_i + hx_i + o$$

$$w_i = px_i + q$$

$$z_i = \gamma + \delta w_i + \text{誤差項}$$

- 係数推定値

$$\hat{\gamma} = \frac{c\hat{\beta} + h}{p}$$

$$\hat{\gamma} = c\hat{\alpha} + o - \frac{c\hat{\beta} + h}{p}q$$

14

係数の変換

- 係数の一次式を係数に持つ新たな回帰式をつくる

- $Y = \alpha + \beta X$ を変形して X の係数が $3\alpha + 5\beta + 1$ となる回帰式を作る。

- 方針

- 左辺を変形 (X が残るように変形)

$$\alpha + \beta X = \alpha + (3\alpha + 5\beta + 1)(X/5) + (-3/5\alpha - 1/5)X$$

- のこりの係数が がある部分だけまとめる。

$$= \alpha - 3/5\alpha X + (3\alpha + 5\beta + 1)(X/5) - 1/5X$$

- , に関わらない変数を左辺 = 被説明変数に移行

$$Y + 1/5X = \alpha(1 - 3/5X) + (3\alpha + 5\beta + 1)(X/5)$$

15

説明変数の変換

- 回帰式 $Y = \alpha + \beta X$ から説明変数が $5X + 3$ である回帰式を求める。つまり, 回帰式

$$Y = c + () (5X + 3)$$

- の $5X + 3$ の係数を求める。

- やりかた

$$Y = \alpha + \beta X = \alpha + (\beta/5)(5X + 3) - (3/5)\beta$$

$$= (\alpha - 3/5\beta) + (\beta/5)(5X + 3)$$

16

説明変数の単位変換

- 説明変数の単位変換

- 100億円のデータを10兆円に換える

- データの桁数が大きいので3桁分へらす
- 説明変数を $1/1000$ 倍する

- 数式で表現

- $Y = \alpha + \beta X$ において $X \rightarrow cX$

$$Y = \alpha + (\beta/c)(cX)$$

なので c 倍された変数の回帰係数は $1/c$ 倍

- 3桁減らすとその回帰係数のみ3桁増える

17

被説明変数の変換

- 回帰式 $Y = \alpha + \beta X$ から被説明変数が $-2Y + 5X + 3$ である回帰式を求める。つまり, 回帰式

$$-2Y + 5X + 3 = () + () X$$

- の $()$ 内の係数を求める

- やりかた

$$Y = \alpha + \beta X$$

$$-2Y = (-2\alpha) + (-2\beta)X$$

$$-2Y + 5X = (-2\alpha) + (-2\beta)X + 5X = (-2\alpha) + (-2\beta + 5)X$$

$$-2Y + 5X + 3 = (-2\alpha) + 3 + (-2\beta + 5)X = (-2\alpha + 3) + (-2\beta + 5)X$$

18

被説明変数の単位変換

- 被説明変数の単位変換
 - 100億円単位のデータを10兆円に換える
 - データの桁数が大きいので3桁分へらす
 - 被説明変数を1/1000倍する
- 数式で表現
 - $Y = \alpha + \beta X + \text{誤差}$ において $Y \rightarrow cY$
 $cY = c\alpha + (c\beta)X$
なので回帰係数はc倍される
- 3桁減らすと回帰係数は全て3桁減る

19

説明変数, 被説明変数の変換の組み合わせ

- まず説明変数を変換し, 被説明変数を変換する。

20

被説明, 説明変数の単位変換

- 被説明変数と説明変数の両方をc倍したら?
 - 例
 - 両方を3桁減らす
 - $C = 1/1000$
- 式変形
 - $cY = c\alpha + (c\beta)X$
 - $cY = c\alpha + (c\beta/c)(cX)$
- 定数項はc倍, 傾きは同じになる
 - 定数項は3桁減る, 傾きはそのまま

21

5. 相関係数再訪

- YをXに回帰する
 - $Y = \alpha + \beta X$
- Y/S_Y を X/S_X に回帰する
 - $Y = \alpha + \beta X = \alpha + (\beta S_X)(X/S_X)$
 - $Y/S_Y = (\alpha/S_Y) + (\beta S_X/S_Y)(X/S_X)$
- 回帰係数を最小二乗法で推定すると相関係数が求まる
 - $\hat{\beta} = S_{XY}/S_X^2$
 - $\hat{\beta} S_X/S_Y = (S_{XY}/S_X^2) \cdot (S_X/S_Y) = S_{XY}/(S_X S_Y) = r$

22