



# 回帰分析

京都大学工学研究科

小山田研究室 TA

田中 哲平






# 回帰分析 Regression analysis


- 目的
  - XとYとの定量的な関係の構造(モデル)を求める
    - YとXとの関係を求める(相関分析)のではない
  - 従属変数の予測
  - 独立変数の影響

$$y = \beta_1 + \beta_2 x$$

↑  
従属変数

↑  
独立変数





# 回帰方程式

$$y = \beta_1 + \beta_2 x$$

- 線形回帰

- 非線形回帰であっても、関数変換等により線形モデルに変形または近似できるものも多い

- 例

- 弾性モデル

- $z = a\omega^b$


両辺の対数をとる

$$\log z = \log a + b \log \omega$$

- 指数回帰

- $z = ab^x$

$$\log z = \log a + x \log b$$

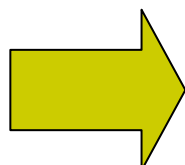



# 母回帰方程式

i番目の要素

$$Y_i = \beta_1 + \beta_2 X_i + \varepsilon_i$$

- $\beta_1, \beta_2$  : (偏)回帰係数
- $X_i$  : すでに確定した値 (確率変数ではない)
- $\varepsilon_i$  : 誤差項
  - $E(\varepsilon_i) = 0, \quad i = 1, 2, \dots, n$
  - $V(\varepsilon_i) = \sigma^2, \quad i = 1, 2, \dots, n$
  - 異なった誤差項は無相関



$$E(Y_i) = \beta_1 + \beta_2 X_i$$




# 回帰係数の推定

- **最小二乗法**
  - 予測誤差の2乗和を最小にする

$$\begin{aligned} S &= \sum (\varepsilon_i)^2 \\ &= \sum \{Y_i - (\beta_1 + \beta_2 X_i)\}^2 \end{aligned}$$



この式が最小となる  $\beta_1$ ,  $\beta_2$  を探す



# 最小二乗法の計算


- $S$  を回帰係数で偏微分してゼロとおく

$$\begin{cases} \frac{\partial S}{\partial \beta_1} = -2 \sum \{Y_i - (\beta_1 + \beta_2 X_i)\} = 0 \\ \frac{\partial S}{\partial \beta_2} = -2 \sum \{Y_i - (\beta_1 + \beta_2 X_i)\} X_i = 0 \end{cases}$$

- 正規方程式

- 偏微分により得られた連立方程式を解く

$$\begin{cases} n\beta_1 + (\sum X_i)\beta_2 = \sum Y_i \\ (\sum X_i)\beta_1 + (\sum X_i^2)\beta_2 = \sum X_i Y_i \end{cases}$$



# 標本(偏)回帰係数


- 正規方程式の解

$$\hat{\beta}_1 = \bar{Y} - \hat{\beta}_2 \bar{X}, \quad \hat{\beta}_2 = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sum (X_i - \bar{X})^2}$$

$\hat{\beta}_1, \hat{\beta}_2$  : 標本(偏)回帰係数

$\bar{X}$  :  $X_i$ を標本とする標本平均

$\bar{Y}$  :  $Y_i$ を標本とする標本平均



# 回帰値、回帰残差

- 回帰値

$$\hat{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 X_i$$

- 回帰残差

$$\begin{aligned}\hat{e}_i &= Y_i - \hat{Y}_i \\ &= Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_i\end{aligned}$$

誤差項の平均ゼロ

$$\sum \hat{e}_i = 0$$

分散は独立変数に依存せず一定

$$\sum \hat{e}_i X_i = 0$$





# 推定値の誤差標準

- 誤差項  $\varepsilon_i$  の分散  $\sigma^2$  は回帰方程式の当てはまりの良さを表す

$$s^2 = \frac{\sum (\hat{e}_i)^2}{n-2} \quad n: \text{サンプリング数}$$

**s** : 推定値の誤差標準

→ **小さいほど、よく適合している**

回帰残差の平方和を  $(n-2)$  で割るのは、先ほどの回帰残差の条件を満たすべきための制限が加わり、自由度が2失われているため



## 3つの平方和

- 偏差平方和  $S_{yy} = \sum (y_i - \bar{y})^2$
- 回帰平方和  $SS_R = \sum (\hat{y}_i - \bar{y})^2$
- 残差平方和  $SS_E = \sum (y_i - \hat{y}_i)^2$

3つの平方和の関係式

$$S_{yy} = S_R + S_e$$




## 決定係数(寄与率)

$$\begin{aligned} R^2 &= SS_R / S_{yy} \\ &= 1 - SS_E / S_{yy} \end{aligned}$$

$$0 < R \leq 1$$

Rの値が大きいほど、回帰モデルが良いことを表す？

変数を増やせば、残差は減少し値が大きくなるので、必ずしも**決定係数の値が大きいものが良い回帰モデルとは限らない**



# 自由度修正済み決定係数

$$R_{ad}^2 = 1 - \frac{SS_E / n - p - 1}{S_{yy} / n - 1}$$

n: サンプルング数

p: 説明変数の数