

# データ解析 (第 12 回)

安藤 和敏

静岡大学システム工学科

# [復習] $y_i$ がしたがう分布

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma^2) \quad (i = 1, \dots, n)$$

のとき,

$y_i$  は期待値  $\beta_0 + \beta_1 x_i$ , 分散  $\sigma^2$  の正規分布にしたがう:

$$y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2) \quad (i = 1, \dots, n).$$

ここで,  $\beta_0, \beta_1, \sigma^2$  は未知のパラメータである.

# [復習] $\hat{\beta}_1$ がしたがう分布

$\hat{\beta}_1$  は正規分布にしたがう確率変数  $y_i$  の一次結合:

$$\hat{\beta}_1 = \frac{1}{S_{xx}} \sum_{i=1}^n (x_i - \bar{x}) y_i.$$

であるから,  $\hat{\beta}_1$  も正規分布にしたがう.  
その正規分布の期待値は  $\beta_1$ , 分散は  $\frac{\sigma^2}{S_{xx}}$  である.

$\hat{\beta}_1$  は期待値  $\beta_1$ , 分散  $\frac{\sigma^2}{S_{xx}}$  の正規分布にしたがう:

$$\hat{\beta}_1 \sim N \left( \beta_1, \frac{\sigma^2}{S_{xx}} \right). \quad (4.25)$$

ここで,  $\beta_1$  と  $\sigma^2$  は未知のパラメータである.

# 標準化

$\hat{\beta}_1$  を標準化 (式 (2.34)) すると,

$$u = \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\sigma^2 / S_{xx}}} \sim N(0, 1^2). \quad (4.26)$$

ここで,  $\beta_1$  と  $\sigma^2$  は未知のパラメータである.

# t-分布

$$u = \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\sigma^2/S_{xx}}} \sim N(0, 1^2). \quad (4.26)$$

の  $\sigma^2$  にその不偏推定量

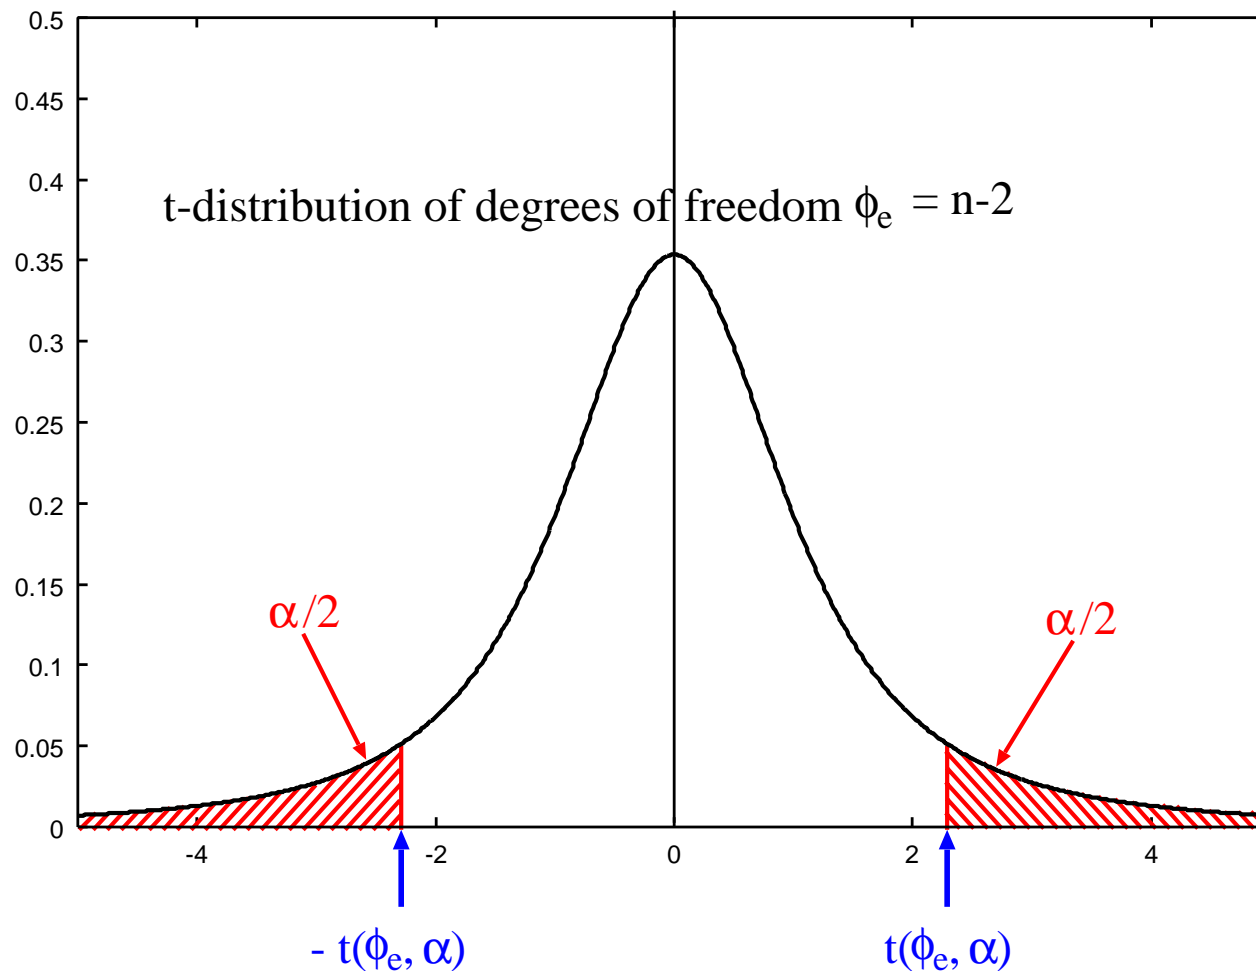
$$\hat{\sigma}^2 = V_e = \frac{S_e}{\phi_e} = \frac{S_e}{n-2} \quad (4.18)$$

を代入すると,

$$t = \frac{\hat{\beta}_1 - \beta_1}{\sqrt{V_e/S_{xx}}} \sim t(\phi_e). \quad (4.27)$$

ここで,  $\phi_e = n - 2$ .

# 自由度 $\phi_e$ の $t$ 分布の両側 $100\alpha\%$ 点: $t(\phi_e, \alpha)$



$$\alpha = \Pr(|t| \geq t(\phi_e, \alpha)) \quad (2.62)$$

# $\beta_1 = 0$ の検定

$x$  という変数が、説明変数として予測に役立つかどうか？を検定してみよう。有意水準 ( $\Rightarrow$  教科書 p. 25) を  $\alpha$  とする。

役立たない、つまり、 $\beta_1 = 0$  と仮定すると、

$$t_0 = \frac{\hat{\beta}_1 - 0}{\sqrt{V_e/S_{xx}}} \quad (4.29)$$

は、自由度  $n - 2$  の  $t$  分布にしたがう。



# $\beta_1 = 0$ の検定 (続き)

したがって,

$$|t_0| = \frac{|\hat{\beta}_1|}{\sqrt{V_e/S_{xx}}} \geq t(\phi_e, \alpha) \quad (*)$$

となる確率は,  $\alpha$  (=小さい数) である. これが成り立つのは起りそうもないこと ( $100\alpha\%$  の確率) であるから, 式 (\*) が成り立てば, この「 $x$  は予測に役立たない」という仮定は正しそうもないと判断し, 成り立たなければ, 正しそうだと判断する.


# $\beta_1 = 0$ の検定 (続き)

これを統計学の言葉でしゃべると,

式 (\*) が成り立てば, 危険率  $\alpha$  で仮説:  $\beta_1 = 0$  を棄却し, 成り立たなければ仮説:  $\beta_1 = 0$  を採択する.


になる.

# $\beta_1 = 0$ の信頼区間



$$\alpha = \Pr(|t| \geq t(\phi_e, \alpha)) \quad (2.62)$$

# $\beta_1 = 0$ の信頼区間 (続き)



$$1 - \alpha = \Pr(|t| \leq t(\phi_e, \alpha))$$

$$1 - \alpha = \Pr(|t| \leq t(\phi_e, \alpha))$$

で,

$$t = \frac{\hat{\beta}_1 - \beta_1}{\sqrt{V_e/S_{xx}}} \sim t(\phi_e). \quad (4.27)$$

なのだから,

$$\frac{|\hat{\beta}_1 - \beta_1|}{\sqrt{V_e/S_{xx}}} \leq t(\phi_e, \alpha)$$

が  $(1 - \alpha)100\%$  の確率で成り立つ.

書き直すと

$$\hat{\beta}_1 - t(\phi_e, \alpha) \sqrt{V_e / S_{xx}} \leq \beta_1 \leq \hat{\beta}_1 + t(\phi_e, \alpha) \sqrt{V_e / S_{xx}}$$

が  $(1 - \alpha)100\%$  の確率で成り立つ。

ゆえに、

$\beta_1$  の  $(1 - \alpha)100\%$  信頼区間は、

$$\hat{\beta}_1 \pm t(\phi_e, \alpha) \sqrt{V_e / S_{xx}}$$

である。

# $\hat{\beta}_0$ がしたがう分布

$\hat{\beta}_0$  は期待値  $\beta_0$ , 分散  $\left(\frac{1}{n} + \frac{\bar{x}^2}{S_{xx}}\right) \sigma^2$  の正規分布にしたがう:

$$\hat{\beta}_0 \sim N \left( \beta_0, \left( \frac{1}{n} + \frac{\bar{x}^2}{S_{xx}} \right) \sigma^2 \right).$$


ここで,  $\beta_0$  と  $\sigma^2$  は未知のパラメータである.

例題2 をやってみよう.




# (5) 得られた回帰式の利用 (p. 54–55)


# データ $(x_i, y_i)$




# 単回帰モデル $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$



# 直線の推定



# $x_0$ に対する母回帰 $\beta_0 + \beta_1 x_0$ の推定



$$\begin{aligned} E(\hat{\beta}_0 + \hat{\beta}_1 x_0) &= E(\hat{\beta}_0) + x_0 E(\hat{\beta}_1) \\ &= \beta_0 + \beta_1 x_0 \end{aligned}$$

だから,

$\hat{\beta}_0 + \hat{\beta}_1 x_0$  は,  $\beta_0 + \beta_1 x_0$  の不偏推定量である.


# $x_0$ に対する母回帰 $\beta_0 + \beta_1 x_0$ の区間推定

$x_0$  に対する母回帰  $\beta_0 + \beta_1 x_0$  の 95%信頼区間は,

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t(\phi_e, 0.05) \sqrt{\left\{ \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}} \right\} V_e} \quad (4.40)$$

である.

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t(\phi_e, 0.05) \sqrt{\left\{ \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}} \right\} V_e}$$






# $\beta_0 + \beta_1 x_0 + \epsilon$ の区間推定

$\beta_0 + \beta_1 x_0 + \epsilon$  の 95% 信頼区間は,

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t(\phi_e, 0.05) \sqrt{\left\{ 1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}} \right\} V_e} \quad (4.41)$$

で与えられる.

$$\hat{\beta}_0 + \hat{\beta}_1 x_0 \pm t(\phi_e, 0.05) \sqrt{\left\{ 1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}} \right\} V_e}$$



例題4 をやってみよう.