

# データ解析演習問題

2006.10.19

提出期限: 2006年10月23日(月) 12:00  
提出場所: システム棟5F レポート提出BOX

学籍番号: \_\_\_\_\_

氏名: \_\_\_\_\_

## A.

以下の表 A.1 のように, 3 変数  $x, u, y$  に関する  $n$  個のデータ与えられている. データ

表 A.1: 変数  $x, u, y$  のデータ

	$x$	$u$	$y$
1	$x_1$	$u_1$	$y_1$
2	$x_2$	$u_2$	$y_2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$i$	$x_i$	$u_i$	$y_i$
$\vdots$	$\vdots$	$\vdots$	$\vdots$
$n$	$x_n$	$u_n$	$y_n$

$(x_i, u_i, y_i)$  ( $i = 1, \dots, n$ ) が与えられているときに, 平面  $y = a + bx + cu$  に対する残差平方和  $Q$  は,

$$Q = \sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n \{y_i - (a + bx_i + cu_i)\}^2 \quad (\text{A.1})$$

で定義される.  $Q(a, b, c)$  を最小にする  $a, b, c$  は, 次の連立方程式の解であることを前回 (2006年10月16日) 見た.

$$\sum_{i=1}^n \{y_i - (a + bx_i + cu_i)\} = 0, \quad (\text{A.2})$$

$$\sum_{i=1}^n x_i \{y_i - (a + bx_i + cu_i)\} = 0, \quad (\text{A.3})$$

$$\sum_{i=1}^n u_i \{y_i - (a + bx_i + cu_i)\} = 0. \quad (\text{A.4})$$

式 (A.2) によって,  $\sum_{i=1}^n \epsilon_i = 0$  であるから, 両辺を  $n$  で割って,  $\bar{\epsilon} = 0$  を得る. したがって,

$$s_\epsilon^2 = \frac{1}{n} \sum_{i=1}^n (\epsilon_i - \bar{\epsilon})^2 = \frac{1}{n} \sum_{i=1}^n \epsilon_i^2 = Q/n \quad (\text{A.5})$$

である.

以下の小問に答えよ. 式の証明では, どの式をどこで用いたのかを記入すること.

A.1. 式 (A.2) を用いて, 以下の式を証明せよ.

$$\hat{\bar{y}} = \bar{y}. \quad (\text{A.6})$$

$$\begin{aligned} \hat{\bar{y}} &= \frac{1}{n} \sum_{i=1}^n \hat{y}_i \\ &= \frac{1}{n} \sum_{i=1}^n \{a + bx_i + cu_i\} \\ &= \frac{1}{n} \sum_{i=1}^n y_i \quad ((\text{A.2}) \text{ を用いた.}) \\ &= \bar{y}. \end{aligned}$$

A.2. 式 (A.2)~式 (A.4) を用いて, 以下の式を証明せよ.

$$\sum_{i=1}^n \epsilon_i \{(a + bx_i + cu_i) - \bar{y}\} = 0. \quad (\text{A.7})$$

$$\begin{aligned} \sum_{i=1}^n \epsilon_i \{(a + bx_i + cu_i) - \bar{y}\} &= \sum_{i=1}^n \{\epsilon_i(a - \bar{y}) + b\epsilon_i x_i + c\epsilon_i u_i\} \\ &= (a - \bar{y}) \sum_{i=1}^n \epsilon_i + b \sum_{i=1}^n \epsilon_i x_i + c \sum_{i=1}^n \epsilon_i u_i \\ &= (a - \bar{y}) \cdot 0 + b \cdot 0 + c \cdot 0 \quad ((\text{A.2}), (\text{A.3}), (\text{A.4}) \text{ を用いた.}) \\ &= 0. \end{aligned}$$

A.3. 式(A.5), 式(A.6), 及び, 式(A.7)を用いて, 以下の式を証明せよ.

$$s_y^2 = s_\epsilon^2 + s_{\hat{y}}^2. \quad (\text{A.8})$$

$$\begin{aligned} \sum_{i=1}^n (y_i - \bar{y})^2 &= \sum_{i=1}^n \{(y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})\}^2 \\ &= \sum_{i=1}^n \{\epsilon_i + (\hat{y}_i - \bar{y})\}^2 \\ &= \sum_{i=1}^n \{\epsilon_i^2 + 2\epsilon_i(\hat{y}_i - \bar{y}) + (\hat{y}_i - \bar{y})^2\} \\ &= \sum_{i=1}^n \epsilon_i^2 + 2 \sum_{i=1}^n \epsilon_i(\hat{y}_i - \bar{y}) + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \\ &= \sum_{i=1}^n \epsilon_i^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad ((\text{A.7}) \text{を用いた.}) \\ &= \sum_{i=1}^n \epsilon_i^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad ((\text{A.6}) \text{を用いた.}). \end{aligned}$$

ゆえに,  $\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n \epsilon_i^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$ . この式の両辺を  $n$  で割って,

$$\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n} \sum_{i=1}^n \epsilon_i^2 + \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad (\text{A.9})$$

であるが, 式(A.5)より(A.8)を得る.

## B.

表 B.1 に示すように, 3変数  $x, u, y$  についての  $n = 10$  個のデータが得られているとする. 前回(2006年10月16日)の演習問題で, 回帰方程式  $y = a + bx + cu$  の切片  $a$  及び偏回帰係数  $b, c$  が以下のように求まった. (小数点以下4桁で四捨五入した.)

$$a = 5.853, b = -1.660, c = 3.246.$$

以下の文章中の空欄  ~  の中に適切な 数値 を,  の中に適切な文を, 記入せよ.

$y$  の分散  $s_y^2$ , 残差  $\epsilon$  の分散  $s_\epsilon^2$ , 予測値の分散  $s_{\hat{y}}^2$  を求めよ. (小数点以下第3桁を四捨五入して, 小数点以下第2桁まで記入せよ.)

$$s_y^2 = \text{ア } 1624.84, \quad s_\epsilon^2 = \text{イ } 15.54, \quad s_{\hat{y}}^2 = \text{ウ } 1609.30$$

寄与率  $R^2$ , 及び, 自由度調整済み寄与率  $R^{*2}$  は, 以下ようになる. (小数点以下第5桁を四捨五入して, 小数点以下第4桁まで記入せよ.)

表 B.1:  $x, u, y$  に関するデータ

No.	$x$	$u$	$y$
1	94	58	38
2	57	43	44
3	78	47	32
4	61	45	56
5	66	43	32
6	93	32	-42
7	71	36	2
8	53	53	95
9	88	30	-42
10	88	57	41

$$R^2 = \boxed{\text{エ } 0.9904}, R^{*2} = \boxed{\text{オ } 0.9877}$$

したがって、 $\boxed{\text{カ}}$  回帰方程式はデータを良く表現できていると言える。

C.

本講義「データ解析」についての感想、要望、質問等があれば記せ。