

データ解析

<http://coconut.sys.eng.shizuoka.ac.jp/data/06>

静岡大学工学部

安藤和敏

2006.10.23

前回までの復習

重回帰分析のデータ (説明変数が2個の場合)

個体番号	変数 x	変数 u	変数 y
1	x_1	u_1	y_1
2	x_2	u_2	y_2
⋮	⋮	⋮	⋮
i	x_i	u_i	y_i
⋮	⋮	⋮	⋮
n	x_n	u_n	y_n

残差平方和 Q

$$Q = \sum_{i=1}^n \varepsilon_i^2$$
$$= \sum_{i=1}^n \{y_i - (a + bx_i + cu_i)\}^2$$

Q を a, b, c を変数にもつ3変数関数として見て,
 $Q(a, b, c)$ を最小にする a, b, c が, データに「最もよくあてはまる」平面を与えると考える.

このようにして a, b, c を求める方法を**最小2乗法**と呼ぶ.

どのようにして $Q(a, b, c)$ を最小にする a, b, c をもとめるのかを見ていく.

$Q(a,b,c)$ を最小にする a,b,c

$$\begin{bmatrix} s_x^2 & s_{xu} \\ s_{xu} & s_u^2 \end{bmatrix} \begin{bmatrix} b \\ c \end{bmatrix} = \begin{bmatrix} s_{xy} \\ s_{uy} \end{bmatrix},$$

$$a = \bar{y} - b\bar{x} - c\bar{u}$$

説明変数が3個以上の場合

重回帰分析のデータ (説明変数が3個の場合)

号番体個	変数 x	変数 u	変数 v	変数 y
1	x_1	u_1	v_1	y_1
2	x_2	u_2	v_2	y_2
\vdots	\vdots	\vdots	\vdots	\vdots
i	x_i	u_i	v_i	y_i
\vdots	\vdots	\vdots	\vdots	\vdots
n	x_n	u_n	v_n	y_n

残差平方和 Q

$$Q = \sum_{i=1}^n \varepsilon_i^2$$
$$= \sum_{i=1}^n \{y_i - (a + bx_i + cu_i + dv_i)\}^2$$

Q を a, b, c, d を変数にもつ3変数関数として見て,
 $Q(a, b, c, d)$ を最小にする a, b, c, d が, データに「最もよくあてはまる」平面を与えると考える.

このようにして a, b, c, d を求める方法を**最小2乗法**と呼ぶ.

$Q(a,b,c,d)$ を最小にする a,b,c,d

$$\begin{bmatrix} S_x^2 & S_{xu} & S_{xv} \\ S_{xu} & S_u^2 & S_{uv} \\ S_{xv} & S_{uv} & S_v^2 \end{bmatrix} \begin{bmatrix} b \\ c \\ d \end{bmatrix} = \begin{bmatrix} S_{xy} \\ S_{uy} \\ S_{vy} \end{bmatrix},$$

$$a = \bar{y} - b\bar{x} - c\bar{u} - d\bar{v}$$

前々回やり残したこと

$$s_y^2 = s_\varepsilon^2 + bs_x^2 + cs_u^2 + 2bcs_{xu} \quad \dots\dots (3)$$

残差平方和の別表現(1)

$$\begin{aligned} Q &= \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n \{y_i - (a + bx_i + cu_i)\}^2 \\ &= \sum_{i=1}^n \{y_i - \bar{y} + \bar{y} - (a + bx_i + cu_i)\}^2 \\ &= \sum_{i=1}^n \{y_i - \bar{y} + a + b\bar{x} + c\bar{u} - (a + bx_i + cu_i)\}^2 \\ &= \sum_{i=1}^n \{(y_i - \bar{y}) - b(x_i - \bar{x}) - c(u_i - \bar{u})\}^2 \end{aligned}$$

残差平方和の別表現(2)

(つづき)

$$\begin{aligned} &= \sum_{i=1}^n (y_i - \bar{y})^2 + b^2 \sum_{i=1}^n (x_i - \bar{x})^2 + c^2 \sum_{i=1}^n (u_i - \bar{u})^2 \\ &\quad - 2b \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x}) - 2c \sum_{i=1}^n (y_i - \bar{y})(u_i - \bar{u}) \\ &\quad + 2bc \sum_{i=1}^n (x_i - \bar{x})(u_i - \bar{u}) \\ &= ns_y^2 + b^2 ns_x^2 + c^2 ns_u^2 - 2nbs_{xy} - 2ncs_{uy} + 2nbc s_{xu} \end{aligned}$$

残差平方和の別表現 (3)

(つづき)

$$= ns_y^2 + b^2 ns_x^2 + c^2 ns_u^2 - 2nbs_{xy} - 2ncs_{uy} + 2nbc s_{xu}$$

$$= ns_y^2 + n\{b(bs_x^2 + cs_{xu}) + c(cs_u^2 + bs_{xu})\}$$

$$- 2nbs_{xy} - 2ncs_{uy}$$

$$= ns_y^2 + n\{bs_{xy} + cs_{uy}\} - 2nbs_{xy} - 2ncs_{uy}$$

$$= ns_y^2 - n\{bs_{xy} + cs_{uy}\}$$

$$= ns_y^2 - n\{b(bs_x^2 + cs_{xu}) + c(cs_u^2 + bs_{xu})\}$$

$$= ns_y^2 - nb^2 s_x^2 - ncs_u^2 - 2nbc s_{xu}$$

残差平方和の別表現 (4)

$$\sum_{i=1}^n \varepsilon_i = \sum_{i=1}^n \{y_i - (a + bx_i + cu_i)\} = 0$$

だから,

$$\bar{\varepsilon} = \frac{1}{n} \sum_{i=1}^n \varepsilon_i = 0.$$

したがって,

$$Q = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (\varepsilon_i - \bar{\varepsilon})^2 = ns_{\varepsilon}^2.$$

$$s_y^2 = s_{\varepsilon}^2 + bs_x^2 + cs_u^2 + 2bcs_{xu} \dots\dots (3)$$

分散に関する公式

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

(証明)

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 &= \frac{1}{n} \sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2) \\ &= \frac{1}{n} \sum_{i=1}^n x_i^2 - 2\bar{x} \frac{1}{n} \sum_{i=1}^n x_i + \frac{1}{n} \sum_{i=1}^n \bar{x}^2 \\ &= \frac{1}{n} \sum_{i=1}^n x_i^2 - 2\bar{x}^2 + \bar{x}^2 \\ &= \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2 \end{aligned}$$

共分散に関する公式

$$s_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x}\bar{y}$$

(証明)
$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) &= \frac{1}{n} \sum_{i=1}^n (x_i y_i - x_i \bar{y} - y_i \bar{x} + \bar{x}\bar{y}) \\ &= \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \frac{1}{n} \sum_{i=1}^n y_i - \bar{y} \frac{1}{n} \sum_{i=1}^n x_i + \frac{1}{n} \sum_{i=1}^n \bar{x}\bar{y} \\ &= \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x}\bar{y} - \bar{x}\bar{y} + \bar{x}\bar{y} \\ &= \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x}\bar{y} \end{aligned}$$