


數值計算（7）

最小二乘法

主成分分析

最小二乗法



回帰分析では従属変数と
独立変数の関係を推定

データを直線で近似 (回帰直線)

一次回帰曲線

$$y = ax + b$$

データ (x_i, y_i) に対する残差

$$y_i - (ax_i + b)$$

残差平方和 → 最小

$$S = \sum_{i=1}^N \{ y_i - (ax_i + b) \}^2$$

2乗和を最小 \Rightarrow 偏微分 = 0

$$\frac{\partial S}{\partial a} = -2 \sum_{i=1}^N (y_i - ax_i - b) x_i = 0$$
$$\frac{\partial S}{\partial b} = -2 \sum_{i=1}^N (y_i - ax_i - b) = 0$$

$\left\{ \begin{array}{l} \left(\sum_{i=1}^N x_i \right) a + \left(\sum_{i=1}^N 1 \right) b = \sum_{i=1}^N y_i \\ \left(\sum_{i=1}^N x_i^2 \right) a + \left(\sum_{i=1}^N x_i \right) b = \sum_{i=1}^N x_i y_i \end{array} \right.$

數值計算

x	0.0	1.0	2.0	3.0	4.0	5.0
y	10.2	12.0	15.7	17.0	20.5	22.4

$$\left(\sum_{i=1}^6 x_i \right) = 15 \quad \left(\sum_{i=1}^6 x_i^2 \right) = 55 \quad \left(\sum_{i=1}^6 y_i \right) = 97.8 \quad \left(\sum_{i=1}^6 x_i y_i \right) = 288.4$$

$$\begin{cases} 15a + 6b = 97.8 \\ 55a + 15b = 288.4 \end{cases} \quad \begin{cases} a = 2.51 \\ b = 10.03 \end{cases}$$

$$y = 2.51x + 10.03$$

多項式近似（回帰曲線）

$$y = P_n(x) = a_0 + a_1x + a_2x^2 + \cdots + a_nx^n$$

残差 $y_i - P_n(x_i)$

残差平方和 $S = \sum_{i=1}^N \{y_i - P_n(x_i)\}^2$

a_j で偏微分 = 0

$$\frac{\partial S}{\partial a_j} = -2 \sum_{i=1}^N (y_i - P_n(x_i)) x_i^j = 0, \quad \sum_{i=1}^N P_n(x_i) x_i^j = \sum_{i=1}^N x_i^j y_i$$

$$j = 0 \quad \left(\sum_{i=1}^N 1 \right) a_0 + \left(\sum_{i=1}^N x_i \right) a_1 + \cdots + \left(\sum_{i=1}^N x_i^n \right) a_n = \sum_{i=1}^N y_i$$

$$j = 1 \quad \left(\sum_{i=1}^N x_i \right) a_0 + \left(\sum_{i=1}^N x_i^2 \right) a_1 + \cdots + \left(\sum_{i=1}^N x_i^{n+1} \right) a_n = \sum_{i=1}^N x_i y_i$$

⋮

$$j = n \quad \left(\sum_{i=1}^N x_i^n \right) a_0 + \left(\sum_{i=1}^N x_i^{n+1} \right) a_1 + \cdots + \left(\sum_{i=1}^N x_i^{2n} \right) a_n = \sum_{i=1}^N x_i^n y_i$$

⋮

數值計算 $y = P_3(x) = a_0 + a_1x + a_2x^2 + a_3x^3$

x	0.0	1.0	2.0	3.0	4.0	5.0
y	10.2	14.0	15.7	16.0	18.5	22.4

$$\left(\sum_{i=1}^6 1 \right) = 6, \quad \left(\sum_{i=1}^6 x_i \right) = 15, \quad \left(\sum_{i=1}^6 x_i^2 \right) = 55, \quad \left(\sum_{i=1}^6 x_i^3 \right) = 255,$$

$$\left(\sum_{i=1}^6 x_i^4 \right) = 979, \quad \left(\sum_{i=1}^6 x_i^5 \right) = 4425, \quad \left(\sum_{i=1}^6 x_i^6 \right) = 20515,$$

$$\sum_{i=1}^6 y_i = 96.8, \quad \sum_{i=1}^6 x_i y_i = 279.4, \quad \sum_{i=1}^6 x_i^2 y_i = 1076.8, \quad \sum_{i=1}^6 x_i^3 y_i = 4555.6$$

$$\begin{cases} 6a_0 + 15a_1 + 55a_2 + 255a_3 = 96.8 \\ 15a_0 + 55a_1 + 255a_2 + 979a_3 = 279.4 \\ 55a_0 + 255a_1 + 979a_2 + 4425a_3 = 1076.8 \\ 255a_0 + 979a_1 + 4425a_2 + 20515a_3 = 4555.6 \end{cases}$$

多項式近似 行列版

$$\begin{pmatrix} \sum_{i=1}^N 1 & \sum_{i=1}^N x_i & \cdots & \sum_{i=1}^N x_i^n \\ \sum_{i=1}^N x_i & \sum_{i=1}^N x_i^2 & \cdots & \sum_{i=1}^N x_i^{n+1} \\ \vdots & \vdots & & \vdots \\ \sum_{i=1}^N x_i^n & \sum_{i=1}^N x_i^{n+1} & \cdots & \sum_{i=1}^N x_i^{2n} \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_n \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N x_i y_i \\ \vdots \\ \sum_{i=1}^N x_i^n y_i \end{pmatrix}$$

ここで、

$$A = \begin{pmatrix} 1 & x_1 & x_1^2 & \cdots & x_1^n \\ 1 & x_2 & x_2^2 & \cdots & x_2^n \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_N & x_N^2 & \cdots & x_N^n \end{pmatrix} \quad \text{とすると,} \quad A^t A a = A^t y$$

線形最小二乗法

$$y = a_1 f_1(x) + a_2 f_2(x) + \cdots + a_n f_n(x) = \sum_{k=1}^n a_k f_k(x)$$

残差平方和 $S = \sum_{i=1}^N \left(y_i - \sum_{k=1}^n a_k f_k(x_i) \right)^2$

$$\frac{\partial S}{\partial a_j} = -2 \sum_{i=1}^N \left(y_i - \sum_{k=1}^n a_k f_k(x_i) \right) f_j(x_i) = 0, \quad \sum_{k=1}^n \sum_{i=1}^N f_j(x_i) f_k(x_i) a_k = \sum_{i=1}^N f_j(x_i) y_i$$

ここで、

$$A = \begin{pmatrix} f_1(x_1) & f_2(x_1) & \cdots & f_n(x_1) \\ f_1(x_2) & f_2(x_2) & \cdots & f_n(x_2) \\ \vdots & \vdots & & \vdots \\ f_1(x_N) & f_2(x_N) & \cdots & f_n(x_N) \end{pmatrix} \text{とすると, } A^t A \mathbf{a} = A^t \mathbf{y}$$

数値計算 $f_1(x) = 1, f_2(x) = x, f_3(x) = \sin(\frac{2\pi}{5}x)$

x	0.0	1.0	2.0	3.0	4.0	5.0
y	10.2	14.0	15.7	16.0	18.5	22.4

$$A = \begin{pmatrix} 1 & 0 & 0.00 \\ 1 & 1 & 0.95 \\ 1 & 2 & 0.58 \\ 1 & 3 & -0.58 \\ 1 & 4 & -0.95 \\ 1 & 5 & 0.00 \end{pmatrix} \quad y = \begin{pmatrix} 10.2 \\ 14.0 \\ 15.7 \\ 16.0 \\ 18.5 \\ 22.4 \end{pmatrix}$$

$$A^t A a = A^t y \quad \text{を解くと,}$$

よって,

$$\begin{cases} a_0 = 10.01 \\ a_1 = 2.45 \\ a_2 = 1.59 \end{cases}$$

$$y = 10.01 + 2.45x + 1.59\sin(\frac{2\pi}{5}x)$$

多次元の場合

独立変数 x_1, x_2, \dots, x_n と従属変数 y

j 番目のデータを $(x_{j1}, x_{j2}, \dots, x_{jn}, y_j)$ と表すと $(1 \leq j \leq N)$



$x_1 = f_1(\xi), x_2 = f_2(\xi), \dots, x_n = f_n(\xi)$ と考える

$$y = a_1 x_1 + a_2 x_2 + \dots + a_n x_n = \sum_{k=1}^n a_k x_k$$

$f_k(\xi)$? 計算に必要なのは、データ $f_k(\xi_j) = x_{jk}$

$$\mathbf{A} = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & & \vdots \\ x_{N1} & x_{N2} & \dots & x_{Nn} \end{pmatrix} \quad \mathbf{A}^t \mathbf{A} \mathbf{a} = \mathbf{A}^t \mathbf{y}$$

主成分分析



生データ (x^*_i, y^*_i)

データの平均 (\bar{x}^*, \bar{y}^*)

$$x_i = x^*_i - \bar{x}^* \quad \mathbf{x}_i = \begin{pmatrix} x_i \\ y_i \end{pmatrix}$$
$$y_i = y^*_i - \bar{y}^*$$

データを最も良く表す直線

$$y = \frac{b}{a} x$$

データ (x_i, y_i) に対する距離最小

↓

\mathbf{x}_i の直線に対する射影長最大

$$\mathbf{u} = \begin{pmatrix} a \\ b \end{pmatrix} \quad (a^2 + b^2 = 1)$$

射影長は $\mathbf{x}_i^t \mathbf{u}$

$$\text{射影長の平方和} = \sum_{i=1}^N (\mathbf{x}_i^t \mathbf{u})^2$$

先ほどと同様に

$$A = \begin{pmatrix} x_1 & y_1 \\ x_2 & y_2 \\ \vdots & \vdots \\ x_N & y_N \end{pmatrix} \quad \text{とおくと,} \quad A\mathbf{u} = \begin{pmatrix} \mathbf{x}_1^t \mathbf{u} \\ \mathbf{x}_2^t \mathbf{u} \\ \vdots \\ \mathbf{x}_N^t \mathbf{u} \end{pmatrix}$$

$$(A\mathbf{u})^t A\mathbf{u} = (\mathbf{x}_1^t \mathbf{u} \ \mathbf{x}_2^t \mathbf{u} \ \cdots \ \mathbf{x}_N^t \mathbf{u}) \begin{pmatrix} \mathbf{x}_1^t \mathbf{u} \\ \mathbf{x}_2^t \mathbf{u} \\ \vdots \\ \mathbf{x}_N^t \mathbf{u} \end{pmatrix} = \sum_{i=1}^N (\mathbf{x}_i^t \mathbf{u})^2$$

||

$\mathbf{u}^t A^t A\mathbf{u} \leftarrow$ これを最大にすれば良い

$\mathbf{u}^t (A^t A\mathbf{u})$ は, \mathbf{u} と $A^t A\mathbf{u}$ の内積

$A^t A$ により向きが変わらないベクトル（固有ベクトル）で,
変換倍率（固有値）が最大のものを選べば良いのでは？

$A^t A$ は分散共分散行列であり, 固有値はすべて非負である

数値計算

x	0.0	1.0	2.0	3.0	4.0	5.0
y	10.2	12.0	15.7	17.0	20.5	22.4

$$\begin{aligned}\bar{x} &= 2.5 \\ \bar{y} &= 16.3\end{aligned}$$

$\mathbf{A}^t \mathbf{A}$ 固有値, 固有ベクトルは,

$$\det(\mathbf{A}^t \mathbf{A} - \lambda \mathbf{E}) = 0$$

$$\mathbf{A} = \begin{pmatrix} -2.5 & -6.1 \\ -1.5 & -4.3 \\ -0.5 & -0.6 \\ 0.5 & 0.7 \\ 1.5 & 4.2 \\ 2.5 & 6.1 \end{pmatrix} \quad (17.5 - \lambda)(111.4 - \lambda) - 43.9^2 = 0 \text{ を解いて} \\ \lambda_1 = 128.73 \quad \lambda_2 = 0.17 \\ \mathbf{u}_1 = \begin{pmatrix} 0.37 \\ 0.93 \end{pmatrix} \quad \mathbf{u}_2 = \begin{pmatrix} -0.93 \\ 0.37 \end{pmatrix}$$

$$\mathbf{A}^t \mathbf{A} = \begin{pmatrix} 17.5 & 43.9 \\ 43.9 & 111.4 \end{pmatrix} \quad y = \frac{0.93}{0.37} (x - 2.5) + 16.3$$

$$y = 2.51x + 9.67$$

多次元のとき $\leftarrow n \text{ 次元 } \rightarrow$

$$A = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{Nn} \end{pmatrix} \quad \begin{matrix} \uparrow \\ N \text{ データ} \\ \downarrow \end{matrix}$$

$A^t A$ の最大の固有値に対応する固有ベクトル u_1

主成分 z_1 固有ベクトル u_1

$$z_1 = A u_1 \quad \begin{pmatrix} z_{11} \\ z_{21} \\ \vdots \\ z_{N1} \end{pmatrix} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{Nn} \end{pmatrix} \begin{pmatrix} u_{11} \\ u_{21} \\ \vdots \\ u_{n1} \end{pmatrix}$$

n 次元 \rightarrow 1 次元

$\mathbf{A}^t \mathbf{A}$ の大きい方から1~ k 番目の固有値に対応する固有ベクトル

$$\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_k$$

$$\mathbf{Z}_k = \mathbf{A} \mathbf{U}_k$$

第1主成分 \mathbf{z}_1	第 k 主成分 \mathbf{z}_k	\mathbf{u}_1	\mathbf{u}_k
\downarrow	\downarrow	\downarrow	\downarrow
$\begin{pmatrix} z_{11} & z_{12} & \dots & z_{1k} \\ z_{21} & z_{22} & \dots & z_{2k} \\ \vdots & \vdots & & \vdots \\ z_{N1} & z_{N2} & \dots & z_{Nk} \end{pmatrix}$	$=$	$\begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & & \vdots \\ x_{N1} & x_{N2} & \dots & x_{Nn} \end{pmatrix}$	$\begin{pmatrix} u_{11} & u_{12} & \dots & u_{1k} \\ u_{21} & u_{22} & \dots & u_{2k} \\ \vdots & \vdots & & \vdots \\ u_{n1} & u_{n2} & \dots & u_{nk} \end{pmatrix}$

n 次元 $\rightarrow k$ 次元 (次元削減, 次元圧縮)

$$\text{寄与率} = \frac{\lambda_k}{\sum_{i=1}^n \lambda_i}$$

$$\text{累積寄与率} = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^n \lambda_i}$$