

V-3-4. 最適化と疑似逆行列

重回帰分析では、被説明変数を説明変数で説明するために、データを使って最適な係数を求めます。ここで、被説明変数を \mathbf{y} として説明変数を \mathbf{x} とすると、データセットは以下のようになります。

$$\begin{aligned} & y_1, x_{11}, x_{21} \cdots x_{p1} \\ & y_2, x_{12}, x_{22} \cdots x_{p2} \\ & y_3, x_{13}, x_{23} \cdots x_{p3} \\ & \vdots \\ & y_m, x_{1m}, x_{2m} \cdots x_{pm} \end{aligned}$$

私たちは次のように被説明変数を説明変数で表したいと考えているのです。

$$\begin{aligned} y_1 &= a_1 x_{11} + a_2 x_{21} + \cdots + a_p x_{p1} \\ y_2 &= a_1 x_{12} + a_2 x_{22} + \cdots + a_p x_{p2} \\ y_3 &= a_1 x_{13} + a_2 x_{23} + \cdots + a_p x_{p3} \\ & \vdots \\ y_m &= a_1 x_{1m} + a_2 x_{2m} + \cdots + a_p x_{pm} \end{aligned}$$

しかし、被説明変数は未知の変動要因を含んでいますから、一般的には次のように誤差項を加えて、式を完成します

$$\begin{aligned} y_1 &= a_1 x_{11} + a_2 x_{21} + \cdots + a_p x_{p1} + e_1 \\ y_2 &= a_1 x_{12} + a_2 x_{22} + \cdots + a_p x_{p2} + e_2 \\ y_3 &= a_1 x_{13} + a_2 x_{23} + \cdots + a_p x_{p3} + e_3 \\ & \vdots \\ y_m &= a_1 x_{1m} + a_2 x_{2m} + \cdots + a_p x_{pm} + e_m \end{aligned}$$

重回帰分析はこの誤差項の最適化・最小化です。最適化にはさまざまな方法が考えられます。最小二乗法も誤差項の最小化の一つの方法です。

これを行列で表すと、誤差項のベクトルは次のようになります。

$$\mathbf{E} = \mathbf{Y} - \mathbf{X}\mathbf{A}$$

$$\mathbf{E} = \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_m \end{pmatrix}, \mathbf{Y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{pmatrix}, \mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mp} \end{pmatrix}, \mathbf{A} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{pmatrix}$$

誤差項のベクトルの大きさを最小にすることを考えます。この場合、ベクトルの大きさは、誤差項の総和ではありません。ベクトルや行列の大きさとはノームです。 q 次のノーム L^q の定義底は以下の通りです。

$$\mathbf{X} = (x_1, x_2, \cdots, x_n), 1 \leq q \leq \infty$$

$$L^q = \sqrt[q]{|x_1|^q + |x_2|^q + \cdots + |x_n|^q}$$

L^q を $\|\mathbf{X}\|_q$ と表すこともあります。これを使うと

$$\|\mathbf{X}\|_1 = |x_1| + |x_2| + \dots + |x_n|$$

$$\|\mathbf{X}\|_2 = \sqrt{|x_1|^2 + |x_2|^2 + \dots + |x_n|^2}$$

となりますが、 L^2 はユークリッド距離です。最小二乗法は L^2 を最小化する方法です。

$$\|\mathbf{E}\|_2 = \sqrt{|e_1|^2 + |e_2|^2 + \dots + |e_m|^2}$$

$$= \sqrt{e_1^2 + e_2^2 + \dots + e_m^2}$$

$$\|\mathbf{E}\|_2^2 = e_1^2 + e_2^2 + \dots + e_m^2$$

$$= (e_1, e_2, \dots, e_m) \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_m \end{pmatrix}$$

$$\mathbf{E}^T = (e_1, e_2, \dots, e_m)$$

。

$$\mathbf{E} = \mathbf{Y} - \mathbf{X}\mathbf{A}$$

$$\mathbf{E}^T = (\mathbf{Y} - \mathbf{X}\mathbf{A})^T$$

$$\|\mathbf{E}\|_2^2 = (\mathbf{Y} - \mathbf{X}\mathbf{A})^T (\mathbf{Y} - \mathbf{X}\mathbf{A})$$

$$= \mathbf{Y}^T \mathbf{Y} - \mathbf{A}^T \mathbf{X}^T \mathbf{Y} - \mathbf{Y}^T \mathbf{X}\mathbf{A} + \mathbf{X}^T \mathbf{A}^T \mathbf{X}\mathbf{A}$$

$$= \mathbf{Y}^T \mathbf{Y} - 2\mathbf{Y}^T \mathbf{X}\mathbf{A} + \mathbf{X}^T \mathbf{A}^T \mathbf{X}\mathbf{A}$$

$\|\mathbf{E}\|_2^2$ は正定値なので、以下の偏微分によって最小値を求めることができます。

$$\frac{\partial \|\mathbf{E}\|_2^2}{\partial \mathbf{A}} = 0$$

$$\frac{\partial \|\mathbf{E}\|_2^2}{\partial \mathbf{A}} = \frac{\partial (\mathbf{Y}^T \mathbf{Y} - 2\mathbf{Y}^T \mathbf{X}\mathbf{A} + \mathbf{X}^T \mathbf{A}^T \mathbf{X}\mathbf{A})}{\partial \mathbf{A}}$$

$$= \frac{\partial (\mathbf{Y}^T \mathbf{Y})}{\partial \mathbf{A}} - 2 \frac{\partial (\mathbf{Y}^T \mathbf{X}\mathbf{A})}{\partial \mathbf{A}} + \frac{\partial (\mathbf{X}^T \mathbf{A}^T \mathbf{X}\mathbf{A})}{\partial \mathbf{A}} = \mathbf{0}$$

$$\frac{\partial (\mathbf{Y}^T \mathbf{Y})}{\partial \mathbf{A}} = 0$$

$$\frac{\partial (\mathbf{Y}^T \mathbf{X}\mathbf{A})}{\partial \mathbf{A}} = \mathbf{Y}^T \mathbf{X}$$

$$\frac{\partial (\mathbf{X}^T \mathbf{A}^T \mathbf{X}\mathbf{A})}{\partial \mathbf{A}} = 2\mathbf{X}^T \mathbf{X}\mathbf{A}$$

$$\frac{\partial \|\mathbf{E}\|_2^2}{\partial \mathbf{A}} = -2\mathbf{Y}^T \mathbf{X} + 2\mathbf{X}^T \mathbf{X}\mathbf{A} = \mathbf{0}$$

$$\mathbf{Y}^T \mathbf{X} = \mathbf{X}^T \mathbf{X}\mathbf{A}$$

$$\mathbf{A} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{Y}^T \mathbf{X}$$

$$\mathbf{A} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$$

ここで、 $(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$ を次のように一つの行列だと考えます。

$$(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T = \mathbf{X}^\#$$

$\mathbf{Y} = \mathbf{X}\mathbf{A}$ と表せるときに（これを行列が正則だと言います。）、次のように、 $\mathbf{m}\mathbf{Y}$ に逆行列 \mathbf{X}^{-1} を左から掛けて、 \mathbf{A} を求めます。

$$\mathbf{X}^{-1}\mathbf{Y} = \mathbf{X}^{-1}\mathbf{X}\mathbf{A} = \mathbf{A}$$

同じように、正則でない場合にも、最適解 \mathbf{A} を $\mathbf{X}^\#$ を左から掛けて求めることができます。

$$\mathbf{X}^\#\mathbf{Y} = \mathbf{A}$$

$$\mathbf{X}^\# = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$$

式 71

$$\mathbf{X}^\#\mathbf{X} = (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \mathbf{X}) = \mathbf{I}$$

唯一解ではなくて最適解が求まるのですが、 $\mathbf{X}^\#$ には逆行列と似たような機能があります。そこで、この行列を疑似逆行列と呼びます。逆に言えば、 \mathbf{X} が正則であれば、 $\mathbf{X}^\# = \mathbf{X}^{-1}$ であり、疑似逆行列 $\mathbf{X}^\#$ は連立方程式の解を与えます。

練習のために、この方法で単回帰分析の式を作ってみます。

$$y = ax + b$$

$$\mathbf{Y} = \mathbf{X}\mathbf{A}$$

$$\mathbf{Y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \mathbf{X} = \begin{pmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{pmatrix}, \mathbf{A} = \begin{pmatrix} a \\ b \end{pmatrix}$$

$$\mathbf{X}^T = \begin{pmatrix} x_1 & x_2 & \cdots & x_n \\ 1 & 1 & \cdots & 1 \end{pmatrix}$$

$$\mathbf{X}^T \mathbf{X} = \begin{pmatrix} x_1 & x_2 & \cdots & x_n \\ 1 & 1 & \cdots & 1 \end{pmatrix} \begin{pmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & n \end{pmatrix}$$

$$(\mathbf{X}^T \mathbf{X})^{-1} = \begin{pmatrix} \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & n \end{pmatrix}^{-1} = \frac{1}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \begin{pmatrix} n & -\sum_{i=1}^n x_i \\ -\sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix}$$

$$\mathbf{X}^\# = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T = \frac{1}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \begin{pmatrix} n & -\sum_{i=1}^n x_i \\ -\sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix} \begin{pmatrix} x_1 & x_2 & \cdots & x_n \\ 1 & 1 & \cdots & 1 \end{pmatrix}$$

$$\begin{aligned}
&= \frac{1}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \begin{pmatrix} nx_1 - \sum_{i=1}^n x_i & nx_2 - \sum_{i=1}^n x_i & \cdots & nx_n - \sum_{i=1}^n x_i \\ -x_1 \sum_{i=1}^n x_i + \sum_{i=1}^n x_i^2 & -x_2 \sum_{i=1}^n x_i + \sum_{i=1}^n x_i^2 & \cdots & x_n \sum_{i=1}^n x_i + \sum_{i=1}^n x_i^2 \end{pmatrix} \\
X^{\#}Y &= \frac{1}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \begin{pmatrix} nx_1 - \sum_{i=1}^n x_i & nx_2 - \sum_{i=1}^n x_i & \cdots & nx_n - \sum_{i=1}^n x_i \\ -x_1 \sum_{i=1}^n x_i + \sum_{i=1}^n x_i^2 & -x_2 \sum_{i=1}^n x_i + \sum_{i=1}^n x_i^2 & \cdots & x_n \sum_{i=1}^n x_i + \sum_{i=1}^n x_i^2 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} \\
&= \frac{1}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \begin{pmatrix} n \sum_{i=1}^n x_i y_i + \sum_{i=1}^n x_i \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_i y_i \sum_{i=1}^n x_i + \sum_{i=1}^n y_i \sum_{i=1}^n x_i^2 \end{pmatrix} = \begin{pmatrix} a \\ b \end{pmatrix} \\
a &= \frac{n \sum_{i=1}^n x_i y_i + \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \\
b &= \frac{\sum_{i=1}^n x_i y_i \sum_{i=1}^n x_i + \sum_{i=1}^n y_i \sum_{i=1}^n x_i^2}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}
\end{aligned}$$

a が回帰係数になっていることを確かめてください。

ここで言いたかったことは、重回帰の解法を線形代数的に説明すると、疑似逆行列を掛けることになるということです。