

* 線形重回帰 (multiple linear regression : MLR)

• データセット $\mathcal{D} = \{(x_1, y_1), \dots, (x_N, y_N)\}$: given.

$$x_i = \begin{pmatrix} x_{i,1} \\ \vdots \\ x_{i,D} \end{pmatrix} \in \mathbb{R}^D, \quad y_i \in \mathbb{R} \quad (i=1, \dots, N) \text{ とする.}$$

(サンプル数 N は, 特徴量 D は.)

• 各特徴量について, "a := b" は "a と b と定義する" の意味.

$$\text{標本平均: } \bar{x}_j := \frac{1}{N} \sum_{i=1}^N x_{i,j} \quad (j=1, \dots, D)$$

$$\text{標本分散: } \sigma_j^2 := \frac{1}{N} \sum_{i=1}^N (x_{i,j} - \bar{x}_j)^2 \quad (j=1, \dots, D)$$

と, **標準化** (standardize)

$$x_{i,j} \leftarrow \frac{x_{i,j} - \bar{x}_j}{\sigma_j}$$

"a ← b" は "a に値 b を代入する" の意味.

を行うことで, データセットの各サンプルに対し平均 0, 分散 1

が成立しているとしても良い.

• 以下では, 扱うサンプルは全て標準化されているとする.

• **計画行列** (design matrix)

$$X := \begin{pmatrix} x_1^T \\ \vdots \\ x_N^T \end{pmatrix} = \begin{pmatrix} x_{1,1} & \dots & x_{1,D} \\ \vdots & \ddots & \vdots \\ x_{N,1} & \dots & x_{N,D} \end{pmatrix} \in M_{N,D}(\mathbb{R})$$

$N \times D$ 行列.
全体の集合

$$\boldsymbol{y} := \begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix} \in \mathbb{R}^N \text{ とする.}$$

・ 線形重回帰モデル: 各サンプル $(x_i, y_i) \in \mathcal{D}$ に対して.

$$y_i \simeq \sum_{j=1}^D b_j x_{ij} \quad (i=1, \dots, N)$$

と線形の近似かいてけると仮定するモデル.

$$\boldsymbol{b} := \begin{pmatrix} b_1 \\ \vdots \\ b_D \end{pmatrix} \in \mathbb{R}^D \text{ とすると, 上の近似式は}$$

$$y_i \simeq x_i^T \boldsymbol{b} \quad (i=1, \dots, N) \text{ とかける.}$$

全サンプルについてまとめて書くと, $\boldsymbol{y} \simeq X\boldsymbol{b}$ と表すことができる

やりたことは 近似 $\boldsymbol{y} \simeq X\boldsymbol{b}$ がなるべく「良くなる」ような
係数 $\hat{\boldsymbol{b}}$ を決定したい.

→ y の値が未知のデータ $x_* \in \mathbb{R}^D$ に対しても,

$$\hat{y} = x_*^T \hat{\boldsymbol{b}} \text{ により } y \text{ の値を推定できてほしい!}$$

Q. 近似が「良い」とはどういうこと?

A. $\boldsymbol{y} \simeq X\boldsymbol{b}$ の近似で表現できなかった誤差項

$\boldsymbol{\varepsilon} := \boldsymbol{y} - X\boldsymbol{b} \in \mathbb{R}^N$ (残差ベクトル) の大きさが小さいということ.

ある性質をみたしければ
どの方法でも良い。
詳しくは線形代数で。

ε の「大きさ」とは ε のノルムのこと。ここでは次のように定義する:

$$\|\varepsilon\| := \sqrt{\varepsilon^T \varepsilon} \quad (\text{内積から定まるノルム}).$$

先述の やり方 を数学的に書き直してみる:

(*) $\|y - Xb\|$ を最小化するような X の係数 \hat{b} を決定したい。

この問題(*)を

with respect to. (\sim に関して)

$$\min \|y - Xb\| \quad \text{w.r.t. } b$$

とか

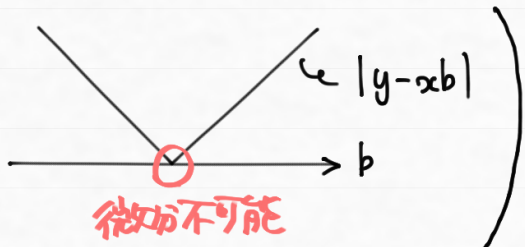
" $\operatorname{argmin}_x f(x)$ " は " $f(x)$ を最小にする x " を表す

$$\hat{b} = \operatorname{argmin}_b \|y - Xb\|$$

などと書く。

とすると、 $\|y - Xb\| = \sqrt{(y - Xb)^T (y - Xb)}$ の最小化はあんどろ。

（イメージ：右のような関数の最小化。
最小点で微分できないので
とてつらい。



$\hookrightarrow |y - xb|$

$\rightarrow \|y - Xb\| \geq 0$ となる。

全ての x で $f(x) \geq 0$ なら、どんな a, b_1 に対しても
 $f(a) \geq f(b) \Leftrightarrow f(a)^2 \geq f(b)^2$.

$$\operatorname{argmin}_b \|y - Xb\| = \operatorname{argmin}_b \|y - Xb\|^2$$

となっている！ 結局、残差のノルムの2乗を最小化すればよい。
(最小二乗法)


• $\hat{b} = \operatorname{argmin}_b \|y - Xb\|^2$ を考える.

最小化する関数 (目的関数) $\|y - Xb\|^2$ は,

b について 2次関数.

→ 唯一の極小値で最小となるような

とよむ最小化問題になっている.



↳ 専門用語では「凸最適化問題」というが
気にしないでいい

極小値を与える b をみつけたい!

→ $\frac{\partial}{\partial b} \|y - Xb\|^2 = 0$ をみたす b を求める \hat{b} .

Remark:

$$\frac{\partial}{\partial b} := \begin{pmatrix} \frac{\partial}{\partial b_1} \\ \vdots \\ \frac{\partial}{\partial b_n} \end{pmatrix} \text{ と定義される. } \frac{\partial}{\partial b} f(b) = \begin{pmatrix} \frac{\partial}{\partial b_1} f(b) \\ \vdots \\ \frac{\partial}{\partial b_n} f(b) \end{pmatrix}.$$

ベクトル微分の公式を使うと,

$$\frac{\partial}{\partial b} \|y - Xb\|^2 = -2X^T(y - Xb)$$

X^T は一般に正方行列でない.
↑ 仮定 $(X^T)^{-1}$ を使って $y - Xb = 0$
と解くのはよくない

となるので、 \hat{b} は

$$-2X^T(y - X\hat{b}) = 0 \Leftrightarrow X^T(y - X\hat{b}) = 0$$

をみたす.

$X^T(y - X\hat{b}) = 0$ の左辺を展開して整理すると.

$$X^T X \hat{b} = X^T y \quad (\text{正規方程式})$$

を得る.

• $X^T X$ は $D \times D$ 正定行列.

$X^T X$ に逆行列が存在するならば,

$$\hat{b} = (X^T X)^{-1} X^T y$$

と求める! 必ずしもいかな

rank $X = D$ ならば
rank $X^T X = D$ となり
 $(X^T X)^{-1}$ が存在.