

TP 3 : RÉGRESSION LINÉAIRE

1 Rappels de théorie (cf. poly)

On suppose que l'on dispose de données $x_1, \dots, x_n \in \mathbb{R}^p$ et $y_1, \dots, y_n \in \mathbb{R}$ liées par une relation de la forme

$$y_k = f(x_k) + \varepsilon_k,$$

où $f(x) = {}^t a x + b$ est une fonction affine $\mathbb{R}^p \rightarrow \mathbb{R}$ inconnue et $\varepsilon_1, \dots, \varepsilon_n$ sont des erreurs de mesures, inconnues elles aussi. L'objectif est de déterminer la fonction f à partir des données.

Sous forme matricielle, ceci s'écrit

$$Y = X\Theta + \varepsilon,$$

où

$$Y = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, \quad X = \begin{pmatrix} 1 & x_{1,1} & \cdots & x_{1,p} \\ 1 & x_{2,1} & \cdots & x_{2,p} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n,1} & \cdots & x_{n,p} \end{pmatrix}, \quad \Theta = \begin{pmatrix} b \\ a_1 \\ \vdots \\ a_p \end{pmatrix}, \quad \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}.$$

Pour que Θ soit défini de façon unique, il faut que X soit une matrice injective, donc de rang maximal $\text{rg}(X) = p + 1$. En particulier, il faut bien sûr $n \geq p + 1$.

On peut considérer ce modèle de façon probabiliste : ε est aléatoire, et par suite Y aussi, tandis que X et Θ sont fixés. Le modèle a notamment des propriétés intéressantes lorsque $\varepsilon_1, \dots, \varepsilon_n$ sont indépendantes et de même loi $\mathcal{N}(0, \sigma^2)$.

On cherche le vecteur $\hat{\Theta}$ qui minimise $\|Y - X\hat{\Theta}\|_2$, autrement dit la fonction affine \hat{f} qui minimise $\sum_k |y_k - \hat{f}(x_k)|^2$. C'est l'« estimateur des moindres carrés », ou « régression linéaire ».

Calcul de $\hat{\Theta}$. Par définition, $X\hat{\Theta}$ est la projection orthogonale de Y sur $E = \text{Im}(X)$. Autrement dit, $Y = X\hat{\Theta} + Z$ où $Z \perp E$. On a donc ${}^t X Z = 0$ d'où

$${}^t X Y = {}^t X X \hat{\Theta},$$

et l'hypothèse $\ker X = \{0\}$ implique que ${}^t X X$ est inversible (si ${}^t X X u = 0$, alors $0 = {}^t u {}^t X X u = \|X u\|^2$ d'où $X u = 0$ puis $u = 0$), donc

$$\hat{\Theta} = ({}^t X X)^{-1} ({}^t X) Y.$$

Le cas où les x_k sont réels ($p = 1$) admet une expression simple : alors $\hat{\Theta} = \begin{pmatrix} \hat{b} \\ \hat{a} \end{pmatrix}$ avec

$$\hat{a} = \frac{\text{Cov}(x, y)}{\text{Var}(x)} = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{x^2} - \bar{x}^2}$$

où $\bar{z} = \frac{1}{n} \sum_{k=1}^n z_k$ (avec $z_k = x_k y_k, x_k, \dots$), et \hat{b} se déduit de $\bar{y} = \hat{a}\bar{x} + \hat{b}$.

Cas gaussien. Si $\varepsilon \sim \mathcal{N}(0, \sigma^2 I_n)$, alors $Y \sim \mathcal{N}(X\Theta, \sigma^2 I_n)$. Ainsi, pour tout $y \in \mathbb{R}^n$, la densité de Y en y vaut $f_\Theta(y) = (2\pi\sigma^2)^{-n/2} e^{-\|y - X\Theta\|^2 / (2\sigma^2)}$ et est maximale (comme fonction de Θ) quand $\|y - X\Theta\|^2$ est minimale : l'estimateur des moindres carrés est aussi ici l'estimateur du maximum de vraisemblance.

On pose $\hat{Y} = X\hat{\Theta} = P_E(Y)$. On a $Y - \hat{Y} = P_{E^\perp}(Y)$, donc le théorème de Cochran montre que $Y - \hat{Y}$ est indépendant de \hat{Y} (et donc de $\hat{\Theta}$), et que $\|Y - \hat{Y}\|_2^2$ suit la loi $\chi_{n-(p+1)}^2$. En particulier, la variable aléatoire

$$\hat{\sigma}^2 = \frac{\|Y - \hat{Y}\|^2}{n - (p + 1)}$$

est un estimateur sans biais de σ^2 . On pourrait aussi déduire des régions de confiance pour Θ (voir poly).

2 Dans Scilab

Si X est une matrice de taille (p,n) dont les *colonnes* sont les différentes données x_k , et Y est un vecteur colonne de taille n , $[a,b]=\text{reglin}(X,Y)$ renvoie le vecteur ligne a et le réel b tels que $a*X+b$ est l'estimateur de Y au moindres carrés.

De plus, $[a,b,s]=\text{reglin}(x,y)$ permet d'obtenir également $\hat{\sigma}$.

NB. L'exposé précédent utilise la présentation usuelle en statistique $Y = X\Theta + \varepsilon$, tandis que Scilab considère le modèle équivalent $Y = aX + b + \varepsilon$, ce qui revient à transposer X , sans ajouter une série de 1, et à avoir $\Theta = \begin{pmatrix} b & a \end{pmatrix}$.

- 1) Pour $n = 50$ et $p = 1$: prendre $X=1:n$; $Y=2*X-7+\text{grand}(1,n,"nor",0,0.3)$, et retrouver les coefficients 2 et -7 par `reglin`, puis par les formules précédentes. Calculer $\hat{\sigma}$ et comparer avec la valeur fournie par `reglin`.
- 2) Pour $n = 50$ et $p = 2$: partir de $X=[(1:n);(1:n)^2]$; $Y=[2 \ -1]*X+5+\text{grand}(1,n,"nor",0,0.3)$, et adapter les questions précédentes.
- 3) Calculer les 100 premiers termes de la suite $(u_n)_{n \geq 0}$ définie par récurrence par $u_0 = 1$ puis $u_{n+1} = \sin(u_n)$. Représenter graphiquement $\log(u_n)$ en fonction de $\log n$; qu'est-ce que ceci suggère? Utiliser `reglin` pour deviner l'ordre de grandeur de u_n . Comparer graphiquement cette estimation avec la suite u_n .