

## Correction de la feuille de TD 3 : Théorème de Cochran et modèle linéaire

**Exercice :** Le principe de la régression linéaire est de modéliser une variable  $y$  à partir de variables explicatives  $\mathbf{x} = (x_1, \dots, x_p)^T$ , i.e de considérer

$$y = \beta_1 x_1 + \dots + \beta_p x_p,$$

où  $\beta = (\beta_1, \dots, \beta_p)$  est inconnu. En pratique, on dispose d'un échantillon  $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)$ , mais on obtient jamais réellement une droite (erreurs de mesures...). On va donc considérer le modèle linéaire

$$y = \beta_1 x_1 + \dots + \beta_p x_p + \epsilon$$

avec  $\epsilon \sim \mathcal{N}(0, \sigma^2)$ . On parle alors de modèle linéaire gaussien. On suppose maintenant que les données suivent le modèle suivant :

$$Y_i = \beta_1 x_{i,1} + \dots + \beta_p x_{i,p} + \epsilon_i,$$

avec

- $Y_i$  est une variable aléatoire et on observe les réalisations  $y_i$ .
- Les  $\mathbf{x}_i = (x_{i,1}, \dots, x_{i,p})^T$  sont déterministes.
- Le paramètre  $\beta = (\beta_1, \dots, \beta_p)^T$  est inconnu et déterministe.
- Les  $\epsilon_i$  sont i.i.d et  $\epsilon_1 \sim \mathcal{N}(0, \sigma^2)$ .

1. Ecrire le modèle de manière matricielle.

$$Y = X\beta + \epsilon,$$

avec  $Y = (Y_1, \dots, Y_n)^T$ ,  $\epsilon = (\epsilon_1, \dots, \epsilon_n)^T$  et

$$X = \begin{pmatrix} x_{1,1} & \dots & x_{1,p} \\ \vdots & \vdots & \vdots \\ x_{n,1} & \vdots & x_{n,p} \end{pmatrix}$$

Pour tout  $i$ , on a bien

$$Y[i] = (x_{i,1}, \dots, x_{i,p})^T \beta + \epsilon_i = x_{i,1}\beta_1 + \dots + x_{i,p}\beta_p + \epsilon_i = Y_i.$$

2. Donner la loi du vecteur  $Y$ . Quelle est la loi de  $Y_i$  ?

On a  $\epsilon \sim \mathcal{N}(0, \sigma^2 I_p)$  et donc

$$Y \sim \mathcal{N}(X\beta, \sigma^2 I_p)$$

et en particulier  $Y_i \sim \mathcal{N}((X\beta)[i], \sigma^2)$ .

On considère à partir de maintenant que  $\text{rang}(X) = p$ , et on note  $D = \text{Im}(X)$ . On s'intéresse à l'estimateur des moindres carrés défini par

$$\hat{\beta} = \arg \min_{h \in \mathbb{R}^p} \|Y - Xh\|^2$$

Montrer que la matrice  $X^T X$  est inversible et en déduire  $\hat{\beta}$ .

La matrice  $X^T X$  est clairement symétrique. De plus pour tout  $h$ ,

$$h^T X^T X h = \|Xh\|^2 \geq 0.$$

De plus, comme  $X$  est de taille  $n \times d$  et de rang  $p$ , elle est injective, donc

$$Xh = 0 \implies h = 0_{\mathbb{R}^p}.$$

On note  $G(h) = \|Y - Xh\|^2$ .

$$\nabla G(h) = -2X^T(Y - Xh) \quad \text{et} \quad \nabla^2 G(h) = X^T X.$$

Comme  $X^T X$  est positive, la fonction est fortement convexe et si le gradient admet un 0, c'est donc l'unique minimiseur. On résout donc

$$\nabla G(h) = 0 \Leftrightarrow X^T Y - X^T X h = 0 \Leftrightarrow h = (X^T X)^{-1} X^T Y$$

On obtient donc  $\hat{\beta} = (X^T X)^{-1} X^T Y$  qui est l'unique minimiseur des moindres carrés.

3. Montrer que  $P_D = X (X^T X)^{-1} X^T$  est le projecteur orthogonal sur  $D$  parallèlement à  $D^\perp$ .

$P_D$  est clairement symétrique et

$$P_D^2 = X (X^T X)^{-1} X^T X (X^T X)^{-1} X^T = X (X^T X)^{-1} (X^T X) (X^T X)^{-1} X^T = P_D.$$

De plus pour tout  $h' \in D$ , il existe  $h \in \mathbb{R}^p$  tel que  $h' = Xh$ . On a donc

$$P_D(h') = P_D(Xh) = X (X^T X)^{-1} X^T X h = X (X^T X)^{-1} (X^T X) h = Xh = h'$$

Pour tout  $h' \in D^\perp \Leftrightarrow \forall h \in \mathbb{R}^p, (Xh)^T h' = 0$ . De plus, pour tout  $h \in \mathbb{R}^p$  et  $h' \in D^\perp$ , on a

$$P_D(h')^T h = \underbrace{h'}_{\in D^\perp} \underbrace{P_D^T h}_{= P_D(h) \in D} = 0$$

et donc  $P_D(h') = 0$ .

4. Que pouvez vous en déduire sur  $X\hat{\beta}$ ?

On a

$$X\hat{\beta} = X \left( X^T X \right)^{-1} X^T Y = P_D Y$$

et  $X\hat{\beta}$  est donc la projection orthogonale de  $Y$  sur  $D$ .

5. Donner la loi de  $X\hat{\beta}$  et en déduire celle de  $\hat{\beta}$ .

Comme  $Y \sim \mathcal{N}(\beta, \sigma^2 I_p)$ , on obtient

$$X\hat{\beta} \sim \mathcal{N}\left(P_D X \beta, \sigma^2 P_D I_p P_D^T\right)$$

Comme  $X\beta \in D$  et  $P_D$  est une projection orthogonale, on obtient

$$X\hat{\beta} \sim \mathcal{N}(X\beta, \sigma^2 P_D)$$

En multipliant par  $X^T$ , on obtient

$$X^T X \hat{\beta} \sim \mathcal{N}\left(X^T X \beta, \sigma^2 X^T P_D X\right)$$

et comme  $X^T X$  est inversible, et en remarquant que  $(X^T X)^{-1} X^T P_D X = (X^T X)^{-1}$ ,

$$\hat{\beta} \sim \mathcal{N}\left(\beta, \sigma^2 \left(X^T X\right)^{-1}\right).$$

6. On suppose  $\sigma^2$  connu. Soit  $x_0 \in \mathbb{R}^p \setminus \{0\}$ , donner un intervalle de confiance de niveau au moins  $1 - \alpha$  de  $x_0^T \beta$ .

On a

$$x_0^T \hat{\beta} \sim \mathcal{N}\left(x_0^T \beta, \sigma^2 x_0^T \left(X^T X\right)^{-1} x_0\right).$$

En remarquant que  $x_0^T \left(X^T X\right)^{-1} x_0 \in \mathbb{R}_+^*$ , on obtient (en centrant et réduisant)

$$\frac{x_0^T \hat{\beta} - x_0^T \beta}{\sigma \sqrt{x_0^T \left(X^T X\right)^{-1} x_0}} \sim \mathcal{N}(0, 1).$$

On a donc

$$1 - \alpha = \mathbb{P} \left[ -q_{1-\alpha} \leq \frac{x_0^T \hat{\beta} - x_0^T \beta}{\sigma \sqrt{x_0^T (X^T X)^{-1} x_0}} \leq q_{1-\alpha} \right] = \mathbb{P} \left[ x_0^T \beta \in x_0^T \hat{\beta} \pm q_{1-\alpha} \sigma \sqrt{x_0^T (X^T X)^{-1} x_0} \right].$$

7. On suppose maintenant que  $\sigma^2$  est inconnu et on considère l'estimateur

$$\hat{\sigma}^2 = \frac{1}{n-p} \|Y - X\hat{\beta}\|^2$$

(a) Expliquer ce choix d'estimateur.

Comme  $\sigma^2$  est la variance des  $\epsilon_i$  (et en particulier le moment d'ordre 2), un estimateur naturel aurait été

$$\tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n \epsilon_i^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - X\beta)^2 = \frac{1}{n} \|Y - X\beta\|^2.$$

Pendant, comme  $\beta$  est inconnu, on le remplace par son estimateur. Le remplacement de  $n$  par  $n-p$  permet (a priori) d'obtenir un estimateur sans biais de  $\sigma^2$ .

(b) Exprimer  $\hat{\sigma}^2$  à l'aide de projections.

On a

$$\frac{1}{n-p} \hat{\sigma}^2 = \frac{1}{n-p} \|Y - X\hat{\beta}\|^2 = \frac{1}{n-p} \|Y - P_D Y\|^2 = \frac{1}{n-p} \|P_{D^\perp} Y\|^2$$

(c) Enoncer le théorème de Cochran dans ce cas. On a  $\mathbb{R}^p = D \oplus D^\perp$ . Ainsi,  $X\hat{\beta} = P_D(Y)$  et  $P_{D^\perp}(Y)$  sont indépendants et comme  $X\beta \in D$ ,

$$\frac{1}{\sigma^2} \|P_{D^\perp} Y - P_{D^\perp} X\beta\|^2 = \frac{n-p}{\sigma^2} \hat{\sigma}^2 \sim \chi_{n-p}^2$$

et en particulier,  $\hat{\beta}$  et  $\hat{\sigma}^2$  sont indépendants. De plus, on a

$$\frac{1}{\sigma^2} \|X\beta - X\hat{\beta}\|^2 \sim \chi_p^2$$

et est également indépendants de  $\hat{\sigma}^2$ .

(d) En déduire un intervalle de confiance pour  $x_0^T \beta$ .

Grâce à la question précédente, on a

$$\frac{x_0^T \hat{\beta} - x_0^T \beta}{\hat{\sigma} \sqrt{x_0^T (X^T X)^{-1} x_0}} \sim T_{n-p}.$$

On a donc

$$1 - \alpha = \mathbb{P} \left[ -t_{n-p, 1-\alpha} \leq \frac{x_0^T \hat{\beta} - x_0^T \beta}{\hat{\sigma} \sqrt{x_0^T (X^T X)^{-1} x_0}} \leq t_{n-p, 1-\alpha} \right] = \mathbb{P} \left[ x_0^T \beta \in x_0^T \hat{\beta} \pm t_{n-p, 1-\alpha} \hat{\sigma} \sqrt{x_0^T (X^T X)^{-1} x_0} \right]$$

(e) En déduire un test de niveau  $\alpha$  pour tout tester  $\beta_j = \beta_{j,0}$ .

En notant  $e_j = (0, \dots, 1, 0, \dots, 0)^T$ , on a  $\beta_j = e_j^T \beta$ . On a donc l'intervalle de confiance

$$IC_{1-\alpha}(\beta_j) = \left[ x_0^T \hat{\beta} \pm t_{n-p, 1-\alpha} \hat{\sigma} \left( X^T X \right)^{-1} [j, j] \right]$$

où  $(X^T X)^{-1} [j, j]$  est la  $j, j$ -ème coordonnée de  $(X^T X)^{-1}$ . On rejette donc le test si  $\beta_{j,0}$  n'est pas dans l'intervalle de confiance.

(f) Construire un intervalle de confiance pour  $\sigma$ .

Comme

$$\frac{n-p}{\sigma^2} \hat{\sigma}^2 \sim \chi_{n-p}^2$$

en notant  $k_{\alpha/2}$  et  $k_{1-\alpha/2}$  les quantiles d'ordre  $\alpha/2$  et  $1 - \alpha/2$ , on obtient l'intervalle

$$IC_{1-\alpha}(\sigma^2) = \left[ \frac{(n-p)\hat{\sigma}^2}{k_{1-\alpha/2}}; \frac{(n-p)\hat{\sigma}^2}{k_{\alpha/2}} \right]$$

(g) Construire un test di niveau  $\alpha$  pour tester  $\beta = \beta_0$ .

D'après la question c), on a

$$\frac{1}{\sigma^2} \|X\beta - X\hat{\beta}\|^2 \sim \chi_p^2 \quad \text{et} \quad \frac{n-p}{\sigma^2} \hat{\sigma}^2 \sim \chi_{n-p}^2$$

et ces deux variables sont indépendantes. On a donc

$$\frac{\|X\beta - X\hat{\beta}\|^2}{\hat{\sigma}^2} \sim \mathcal{F}(p, n-p).$$

On cherche donc  $c_\alpha$  tel que

$$\mathbb{P} \left[ \frac{\|X\beta - X\hat{\beta}\|^2}{\hat{\sigma}^2} \geq c_\alpha \right] = \alpha \Leftrightarrow \mathbb{P} [\mathcal{F}(p, n-p) \geq c_\alpha] \Leftrightarrow c_\alpha = f_{p, n-p, 1-\alpha}$$

où  $f_{p, n-p, 1-\alpha}$  est le quantile d'ordre  $1 - \alpha$  d'une loi de Fisher de paramètre  $p, n - p$ .

8. On considère maintenant une  $n + 1$ -ème donnée  $x_{n+1}$  et on souhaite prédire  $Y_{n+1}$ .

(a) Proposer un prédicteur  $\hat{Y}_{n+1}$ . On considère  $\hat{Y}_{n+1} = x_{n+1}^T \hat{\beta}$ .

(b) Donner sa loi.

On a

$$x_{n+1}^T \hat{\beta} \sim \mathcal{N} \left( x_{n+1}^T \beta, \sigma^2 x_{n+1}^T (X^T X)^{-1} x_{n+1} \right).$$

(c) Donner la loi de l'erreur de prédiction  $\hat{\epsilon}_{n+1} = Y_{n+1} - \hat{Y}_{n+1}$ .

On a

$$Y_{n+1} - \hat{Y}_{n+1} = x_{n+1}^T \beta - x_{n+1}^T \hat{\beta} + \epsilon_{n+1} \sim \mathcal{N} \left( 0, \sigma^2 x_{n+1}^T (X^T X)^{-1} x_{n+1} + \sigma^2 \right)$$

(d) En déduire un intervalle de prédiction.

D'après la question précédente, et comme  $\hat{\sigma}^2$  et  $\hat{\beta}$  sont indépendants, on a

$$\frac{Y_{n+1} - \hat{Y}_{n+1}}{\hat{\sigma} \sqrt{x_{n+1}^T (X^T X)^{-1} x_{n+1} + 1}} \sim T_{n-p}.$$

On obtient donc l'intervalle de prédiction

$$IP_{1-\alpha}(Y_{n+1}) = \left[ \hat{Y}_{n+1} \pm t_{n-p, 1-\alpha/2} \hat{\sigma} \sqrt{x_{n+1}^T (X^T X)^{-1} x_{n+1} + 1} \right]$$