

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 ϵ_i sont i.i.d et $\epsilon_1 \sim \mathcal{N}(0, \sigma^2)$.

1. Ecrire le modèle de manière matricielle.
2. Donner la loi du vecteur Y . Quelle est la loi de Y_i ?
3. 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 $\hat{\beta}$.

4. Montrer que $P_D = X (X^T X)^{-1} X^T$ est le projecteur orthogonale sur D parallèlement à D^\perp .
5. Que pouvez vous en déduire sur $X\hat{\beta}$?
6. Donner la loi de $X\hat{\beta}$ et en déduire celle de $\hat{\beta}$.

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

8. On suppose maintenant que σ^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.
 - (b) Exprimer $\hat{\sigma}^2$ à l'aide de projections.
 - (c) Énoncer le théorème de Cochran dans ce cas.
 - (d) En déduire un intervalle de confiance pour $x_0^T \beta$.
 - (e) En déduire un test de niveau α pour tout tester $\beta_j = \beta_{j,0}$.
 - (f) Construire un intervalle de confiance pour σ .
 - (g) Construire un test de niveau α pour tester $\beta = \beta_0$.
9. 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} .
 - (b) Donner la loi de l'erreur de prédiction $\hat{\epsilon}_{n+1} = Y_{n+1} - \hat{Y}_{n+1}$.
 - (c) En déduire un intervalle de prédiction.