

---

## SÉRIE 13

---

**Exercice 1.** Pour le modèle statistique de régression linéaire  $Y = a + bX + \eta$ , quand on observe les points  $(x_i, y_i)$   $i = 1, 2, \dots, n$ , les réalisations des estimateurs de  $a$  et  $b$ ,  $\hat{a}$  et  $\hat{b}$ , peuvent s'écrire :

$$\hat{b} = \sum_{j=1}^n w_j y_j \text{ et } \hat{a} = \sum_{j=1}^n v_j y_j \text{ avec } w_j = \frac{x_j - \bar{x}}{\sum_{i=1}^n (x_i - \bar{x})^2} \text{ et } v_j = \frac{1}{n} - \bar{x} w_j.$$

Montrer les propriétés suivantes :

- a)  $\sum_{j=1}^n w_j = 0$  et  $\sum_{j=1}^n v_j = 1$ .
- b)  $\sum w_j^2 = \frac{1}{\sum_{i=1}^n (x_i - \bar{x})^2}$  et  $\sum v_j^2 = \frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$ .
- c)  $\sum w_j x_j = 1$  et  $\sum v_j x_j = 0$ .

**Exercice 2.** On cherche à calculer la relation entre la moyenne  $\bar{y}$  d'un examen et celle  $\bar{x}$  d'un test bonus. On sait que leur coefficient de corrélation empirique vaut  $\hat{r} = 0.6$ . En utilisant les données suivantes :

$$\bar{y} = 55, \quad \sum_{i=1}^n (y_i - \bar{y})^2 = 20, \quad \bar{x} = 70, \quad \sum_{i=1}^n (x_i - \bar{x})^2 = 10,$$

trouver l'équation de la droite de régression  $x \rightarrow \hat{a} + \hat{b}\bar{x}$  de la moyenne à l'examen en fonction de celle au test bonus.

**Exercice 3.** Au problème de la régression simple classique peut s'ajouter l'obligation de devoir passer par un point  $(x_0, y_0)$  spécifique. Ce type de régression est dite régression forcée. On considère un ensemble de points  $(x_i, y_i)$  pour  $i = 1, \dots, n$ , et le modèle  $y_i = \beta(x_i - x_0) + y_0 + \eta_i$  où les  $\eta_i$  sont des Gaussiennes indépendantes de moyenne 0 et de variance 1.

- a) Trouver la valeur  $\hat{\beta}$  de  $\beta$  qui minimise l'erreur de prédiction  $\sum_i \{y_i - y_0 - \beta(x_i - x_0)\}^2$ .  
On va utiliser cette valeur comme estimation (réalisation de l'estimateur) de  $\beta$ , la pente de la droite de régression forcée par un point  $(x_0, y_0)$ .
- b) Appliquer le résultat de la question a) au cas  $(x_0, y_0) = (\bar{x}, \bar{y})$  et comparer avec l'estimateur de la pente de la droite de régression simple classique.
- c) Déterminer le modèle de régression forcée par le point de coordonnées  $(3, 6)$  pour les données ci-dessous :

$x_i$	1	2	3	4	5	6	7
$y_i$	2.5	5.0	3.5	7	6.5	8.25	8

**Exercice 4.** Un échantillon aléatoire de 10 hommes âgés de 30 ans a été choisi. On a relevé les données de leur salaire annuel ( $Y$ ) et le nombre d'années d'école qu'ils ont suivies ( $X$ ). On a trouvé les valeurs suivantes :  $\Sigma x = 151$     $\Sigma y = 96.3$     $\Sigma xy = 1526.30$     $\Sigma x^2 = 2357$     $\Sigma y^2 = 1036.13$ .

En supposant que la moyenne de la loi des salaires est une fonction linéaire du nombre d'années d'école :

- Déterminer les estimations des paramètres  $a$  et  $b$  du modèle  $Y = a + bX + \eta$ , ainsi que l'estimation de  $\sigma^2$  (variance de  $\eta$ ).
- Tester l'hypothèse  $H_0 : b = 0$  contre l'alternative  $H_1 : b \neq 0$  au seuil de signification  $\alpha = 0.01$ .

**Exercice 5. Transformations des données.** Pour certains jeux de données, il peut être judicieux de calculer une transformation des données avant d'effectuer une régression linéaire.

Les données suivantes montrent les valeurs expérimentales de la pression  $P$  d'une masse donnée de gaz pour différentes valeurs du volume  $V$ .

Volume $V$ (cm <sup>3</sup> )	54.3	61.8	72.4	88.7	118.6	194.0
Pression $P$ (kg/cm <sup>2</sup> )	61.2	49.5	37.6	28.4	19.2	10.1

D'après les principes de la thermodynamique, on a la relation  $PV^\gamma = C$ , où  $\gamma$  et  $C$  sont des constantes dépendant des conditions d'expérience.

- Transformer  $PV^\gamma = C$  en modèle linéaire avec  $Y = \log(P)$ . Quels sont les paramètres dont on cherche la valeur ?
- En utilisant a), trouver les estimateurs de  $\gamma$  et  $\log(C)$ .
- Estimer  $P$  quand  $V = 100$  cm<sup>3</sup>.
- Calculer l'intervalle de confiance à 95% pour la pente de la droite du modèle de régression trouvé en a).