

Exercices - Série 3

Régression linéaire simple

Exercice 1 - Densité européenne

Dans le fichier *Europe.xlsx* disponible sur le site web du cours, vous trouverez la population et la superficie de 27 pays d'Europe.

- a) Tracer le nuage de points de la population en fonction de la superficie. En examinant ce graphique, êtes-vous portés à dire que les postulats du modèle de régression linéaire sont respectés? Quelle est la conséquence de votre réponse?
- b) Pour estimer la densité de population moyenne en Europe, on propose 3 approches :
 - i) en calculant la densité de chaque pays, puis en faisant la moyenne de ces 27 densités.
 - ii) en calculant la population totale des 27 pays, et en la divisant par la superficie totale des 27 pays.
 - iii) en estimant la pente de la droite de régression aux moindres carrés

Exprimer les 3 quantités ci-dessus en nombre d'habitants par km^2 , et commenter chacune d'elles. Laquelle des approches vous apparaît la meilleure?

Exercice 2 - Drill, baby, drill! (Comme disait Sarah Palin)

- a) Montrer que la somme des produits croisés $S_{XY} = \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$ peut aussi s'écrire $S_{XY} = \sum_{i=1}^n X_i Y_i - n\bar{X}\bar{Y}$.
- b) Montrer que la somme des produits croisés $S_{XY} = \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$ peut aussi s'écrire $S_{XY} = \sum_{i=1}^n (X_i - \bar{X})Y_i$.
- c) Retrouver les estimateurs des moindres carrés de la pente et de l'ordonnée à l'origine en annulant les dérivées partielles par rapport à β_0 et β_1 de la somme des carrés des erreurs :

$$S = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_i)^2$$

- d) On peut déduire des résultats précédents que $\hat{\beta}_1$ est une combinaison linéaire des Y_i (lorsqu'on considère les X_i fixés). Quelle est la principale conséquence de cet état de fait?

Exercice 3 - Dans le ventre de sa maman...

Téléchargez sur le site du cours le jeu de données *gestation_longévité.xlsx*. À l'aide de la commande *Régression linéaire* de l'*Utilitaire d'analyse*, ajustez un modèle de régression linéaire simple sur les variables suivantes : (Demandez de faire calculer les résidus.)

Modèle 1 :	Longévité	en fonction de	Gestation
Modèle 2 :	Longévité	en fonction de	$\ln(\text{Gestation})$
Modèle 3 :	$\ln(\text{Longévité})$	en fonction de	Gestation
Modèle 4 :	$\ln(\text{Longévité})$	en fonction de	$\ln(\text{Gestation})$

- En étudiant les quatre nuages de points, lequel des modèles proposés est préférable pour mettre en lien ces deux variables ? Pourquoi ?
- Dans les résultats de son analyse, Excel fournit trois coefficients permettant d'évaluer la qualité de l'ajustement. Pouvez-vous les identifier, et préciser la formule utilisée pour calculer chacun d'eux ?
- En vous basant sur le R^2 , lequel des quatre modèles proposés fournit le meilleur ajustement ?
- Pour le modèle que vous avez choisi en a), quelle est l'estimation de la variance des observations autour de la droite ?
- Pour le modèle que vous avez choisi en a), calculez la moyenne et l'écart-type des résidus. Auriez-vous pu trouver ces valeurs sans les faire calculer par Excel à partir de la liste des résidus ?

Exercice 4 - Jouons avec les Y

Considérons les données suivantes :


Variable X	Variable Y ₁	Variable Y ₂	Variable Y ₃
0	1	11,0	1,5
10	1,5	10,4	2,6
19	2,6	8,3	5,1
27	2,7	7,9	7,9
29	5,0	7,2	7,2
32	5,1	5,1	10,4
34	7,2	5,0	2,7
43	7,9	2,7	11,0
50	8,3	2,6	8,3
51	10,4	1,5	5,0
55	11,0	1,0	1,0

- a) Estimer les paramètres du modèle de régression linéaire de Y_1 en fonction de X :
- i) par la méthode de Mayer ;
 - ii) par la méthode médiane-médiane ;
- b) Si on inverse l'ordre des Y_i (et donc qu'on travaille avec la variable Y_2), qu'advient-il des paramètres avec les deux méthodes ? Pouvez-vous répondre sans faire de calcul ?
- c) Si on change complètement l'ordre des Y_i (et donc qu'on travaille avec la variable Y_3), devez-vous réordonner les Y_i avant de calculer les points moyens et médians ?

Exercice 5 - Un air de déjà vu...

Un scientifique désire étudier l'influence d'un antibiotique sur une culture bactérienne. Il répartit dans 10 tubes des volumes égaux de culture additionnée d'une quantité X d'antibiotique, et il mesure (après incubation) la densité optique Y . Il a noté que $\bar{x} = 0,6$ et que $\bar{y} = 4,15$.

Les résultats sont illustrés par le graphique suivant :



$X = \text{antibiotique}$	0.2	0.2	0.4	0.4	0.6
$Y = \text{densité}$	2.9	3.0	3.5	3.6	4.0

$X = \text{antibiotique}$	0.6	0.8	0.8	1.0	1.0
$Y = \text{densité}$	4.2	4.7	4.9	5.3	5.4

- a) D'après les résultats de l'expérience, lorsqu'il n'y a pas d'antibiotique, la densité optique est estimée à 2,335. Trouver l'équation de la droite de régression. Ajouter la droite de régression à votre graphique.
- b) Sachant que la variance échantillonnale des x_i est 0,0889, que celle des y_i est 0,8206, et que la somme des carrés des erreurs du modèle est de 0,0645, donner une estimation de l'erreur-type associée à $\hat{\beta}_0$ et de l'erreur-type associée à $\hat{\beta}_1$.

- c) Peut-on dire que la pente de la droite est supérieure à 3 au seuil $\alpha = 5\%$?
- d) Quelle est la proportion de variation de la densité optique expliquée par la quantité d'antibiotique ?
- e) Un onzième tube est additionné d'une quantité d'antibiotique égale à 0,9. Donner un intervalle de valeurs permettant de prédire la densité optique de ce tube qu'on mesurera après incubation. Utiliser $\alpha = 0,05$.
- f) Toutes choses étant égales par ailleurs, l'intervalle que vous avez calculé au numéro précédent aurait-il été plus long ou plus court...
- i) si on avait choisi une quantité d'antibiotique égale à 0,7 ?
 - ii) si on avait choisi $\alpha = 0,01$?
 - iii) si on avait utilisé une taille d'échantillon de 20 unités ?
 - iv) si on avait construit l'intervalle pour estimer la densité optique moyenne de tous les tubes ayant reçu une quantité d'antibiotique égale à 0,9 ?
- g) Considérons un tube dont la quantité d'antibiotique additionnée est située à 1,5 écart-type sous la moyenne.
- i) Combien d'unités d'antibiotique ce tube a-t-il reçu ?
 - ii) Quelle est la valeur de densité optique prédite par le modèle pour ce tube ?
 - iii) À combien d'écarts-types de la densité optique moyenne cette valeur se situe-t-elle ? Est-ce à 1,5 écart-type sous la densité moyenne ?
 - iv) Pouvez-vous déduire de vos calculs au numéro précédent la valeur du coefficient de corrélation ?
- h) Un autre analyste propose de calculer la moyenne de tous les y_i ayant une même valeur de X avant d'ajuster un modèle de régression. On utiliserait donc les cinq points suivants :

$X = \text{antibiotique}$	0.2	0.4	0.6	0.8	1.0
$Y = \text{densité}$	2.95	3.55	4.1	4.8	5.35

Pouvez-vous déterminer quel sera l'impact de cette approche sur ...

- i) la moyenne des x_i et des y_i ?
- ii) l'équation de la droite de régression ?
- iii) l'estimation de la variance autour de la droite et la précision des prédictions ?

L'une des deux analyses est-elle préférable à l'autre ?

Exercice 6 - Ma cabane au Canada

On veut modéliser le prix moyen des maisons au Canada en fonction du temps et on obtient les données suivantes (malheureusement incomplètes...) :

Année (X)	1980	1981	...	2010
Prix moyen des maisons (\$) (Y)	74 721	76 236	...	249 017

Une analyse de ces données montre qu'un modèle linéaire pourrait éventuellement s'appliquer pour expliquer le prix des maisons à partir de l'année. On calcule la covariance et la corrélation échantillonnales, et on obtient les quantités suivantes :

$$\begin{aligned} Cov(X, Y) &= 374\,225 \\ r &= 0,77 \end{aligned}$$

- On décide d'exprimer le prix des maisons en milliers de dollars plutôt qu'en dollars. Que deviennent la covariance et la corrélation ?
- Conservons les prix initiaux (en dollars). On veut maintenant exprimer le temps en nombre d'années écoulées depuis 1980. Qu'advient-il de la covariance et de la corrélation ?