

T. D. n° 7

Régression linéaire multiple

L'exercice 1 est issu du livre « Probabilités, Statistique et technique de régression » de Gérald Baillargeon, Les éditions SMG et l'exercice 2 est issu du livre « Analyse de régression appliquée » de Yadolah Dodge, Édition Dunod.

Exercice 1. L'entreprise CITRON fabrique un matériau en matière plastique qui est utilisé dans la fabrication de jouets. Le département de contrôle de qualité de l'entreprise a effectué une étude qui a pour but d'établir dans quelle mesure la résistance à la rupture (en kg/cm^2) de cette matière plastique pouvait être affectée par l'épaisseur du matériau ainsi que la densité de ce matériau. Une étude réalisée au préalable a montré que la résistance du jouet suit une loi normale. Douze essais ont été effectués et les résultats sont présentés dans le tableau ci-dessous.

| Essai numéro | Résistance à la rupture Y_i | Épaisseur du matériau X_{i_1} | Densité X_{i_2} |
|--------------|-------------------------------|---------------------------------|-------------------|
| 1 | 37,8 | 4 | 4,0 |
| 2 | 22,5 | 4 | 3,6 |
| 3 | 17,1 | 3 | 3,1 |
| 4 | 10,8 | 2 | 3,2 |
| 5 | 7,2 | 1 | 3,0 |
| 6 | 42,3 | 6 | 3,8 |
| 7 | 30,2 | 4 | 3,8 |
| 8 | 19,4 | 4 | 2,9 |
| 9 | 14,8 | 1 | 3,8 |
| 10 | 9,5 | 1 | 2,8 |
| 11 | 32,4 | 3 | 3,4 |
| 12 | 21,6 | 4 | 2,8 |

Diverses analyses ont été effectuées sur ordinateur et nous les résumons dans les trois tableaux suivants :

Régression de la résistance à la rupture Y en fonction de l'épaisseur X_1

| Coefficients $\hat{\beta}_j$ | Erreurs-types $s(\hat{\beta}_j)$ | Source de variation | Somme des carrés | ddl |
|------------------------------|----------------------------------|---------------------|------------------|-------|
| $\hat{\beta}_0 = 3,523$ | $s(\hat{\beta}_1) = 1,279$ | Régression X_1 | 980,63 | 1 |
| $\hat{\beta}_1 = 6,036$ | | Erreur | 440,03 | 10 |

Régression de la résistance à la rupture Y en fonction de la densité X_2

| Coefficients $\hat{\beta}_j$ | Erreurs-types $s(\hat{\beta}_j)$ | Source de variation | Somme des carrés | ddl |
|------------------------------|----------------------------------|---------------------|------------------|-------|
| $\hat{\beta}_0 = -36,373$ | $s(\hat{\beta}_2) = 6,069$ | Régression X_2 | 643,57 | 1 |
| $\hat{\beta}_2 = +17,464$ | | Erreur | 777,10 | 10 |

Régression de la résistance à la rupture Y en fonction de l'épaisseur X_1 et de la densité X_2

| Coefficients $\hat{\beta}_j$ | Erreurs-types $s(\hat{\beta}_j)$ |
|---------------------------------|-------------------------------------|
| $\hat{\beta}_0 = -30,081$ | |
| $\hat{\beta}_1 = +04,905$ | $s(\hat{\beta}_1) = 1,014$ |
| $\hat{\beta}_2 = +11,072$ | $s(\hat{\beta}_2) = 3,621$ |

| Source de variation | Somme des carrés | ddl |
|---------------------------|------------------|-----|
| Régression (X_1, X_2) | 1204,86 | 2 |
| Erreur | 215,81 | 9 |

1. Quel pourcentage de variation dans la résistance à la rupture est expliquée par chacune des régressions ?
2. Pour chaque régression linéaire, compléter le tableau suivant :

| | Carré moyen des résidus | Écart-type des résidus |
|---------------------------------|-------------------------|------------------------|
| Régression due à X_1 | | |
| Régression due à X_2 | | |
| Régression due à (X_1, X_2) | | |

3. Compléter le tableau d'analyse de la variance suivant pour la régression comportant les deux variables explicatives.

| Source de variation | Somme des carrés | Degrés de liberté | Carrés moyens | F_{obs} |
|---------------------------------|------------------|-------------------|---------------|-----------|
| Régression due à (X_1, X_2) | | | | |
| Résiduelle | | | | |
| Totale | | | | |

4. Tester au seuil de signification $\alpha = 5\%$, l'hypothèse nulle

$$\mathcal{H}_0 : \beta_1 = \beta_2 = 0$$

contre l'hypothèse alternative

$$\mathcal{H}_1 : \text{au moins un des } \beta \neq 0.$$

Quelle est votre conclusion ?

5. Quel est l'apport marginal de la variable « densité du matériau » notée X_2 lorsqu'elle est introduite à la suite de la variable « épaisseur du matériau » notée X_1 ?
6. Est-ce que l'apport marginal de la variable « densité du matériau » notée X_2 , lorsqu'elle est introduite à la suite de la variable « épaisseur du matériau » notée X_1 , est significative au seuil de signification $\alpha = 5\%$? Pour répondre à cette question, utiliser le test de Student ou le test de Fisher partiel.
7. Nous voulons obtenir diverses estimations de la résistance à la rupture. Quelle est, en moyenne, la résistance à la rupture de jouets dont l'épaisseur du matériau utilisé et la densité du matériau sont celles indiquées dans le

tableau suivant ?

| Épaisseur X_1 | Densité X_2 | Estimation de la résistance moyenne | Écart-type de l'estimation |
|--------------------|------------------|--|-------------------------------|
| 4 | 3,8 | | 2,10 |
| 3 | 3,4 | | 1,43 |
| 4 | 2,9 | | 2,57 |

8. Entre quelles valeurs peut se situer la résistance moyenne à la rupture, pour des jouets dont l'épaisseur du matériau est $X_1 = 4$ et la densité du matériau est $X_2 = 3,8$, si l'entreprise utilise un niveau de confiance de 95% ?
9. Quelle est la marge d'erreur dans l'estimation effectuée à la question 8. ?
10. Nous désirons un intervalle de prédiction de la résistance à la rupture pour un jouet ayant comme épaisseur du matériau $X_1 = 4$ et densité du matériau égale à $X_2 = 3,9$. Quel est cet intervalle au niveau de confiance de 95% ?

Exercice 2. Les données proposées dans cet exercice présentent le taux de décès par crise cardiaque chez les hommes de 55 à 59 ans dans différents pays.

Les variables sont les suivantes :

- Y : $100 [\log(\text{nombre de décès par crise cardiaque pour 100 000 hommes de 55 à 59 ans}) - 2]$;
- X_1 : téléphones par millier d'habitants ;
- X_2 : calories grasses en pourcentage du total des calories ;
- X_3 : calories provenant de protéines animales en pourcentage du total des calories.

Une étude réalisée au préalable a montré que le taux de décès par crise cardiaque chez les hommes de 55 à 59 suit une loi normale.

1. Régresser Y sur X_1 et tester la signification de cette régression linéaire simple.
2. Trouver l'équation de la régression linéaire multiple de Y sur X_1 et X_2 .
3. Effectuer un test conjoint d'hypothèse nulle $\mathcal{H}_0 : \beta_1 = \beta_2 = 0$.
4. Tester si l'adjonction de la variable X_2 à l'équation trouvée à la question 1. a significativement amélioré l'estimation.
5. Construire la régression linéaire multiple de Y sur X_1 , X_2 et X_3 .
6. Donner les limites de l'intervalle de confiance à 95% pour β_3 dans cette équation.
7. Donner les limites de l'intervalle de confiance à 95% pour \hat{Y} au point $X_1 = 221$, $X_2 = 39$ et $X_3 = 7$.
8. Tester si X_2 et X_3 ensemble apportent quelque chose à la régression linéaire simple de Y sur X_1 .
9. Régresser X_1 sur X_2 et X_3 .
10. Donner les limites de l'intervalle de confiance à 95% pour les coefficients de la régression linéaire de X_1 sur X_3 .

| Observation i | Pays | X_1 x_{1i} | X_2 x_{2i} | X_3 x_{3i} | Y x_{4i} |
|------------------|------------------|-------------------|-------------------|-------------------|-----------------|
| 1 | Australie | 124 | 33 | 8 | 81 |
| 2 | Autriche | 49 | 31 | 6 | 55 |
| 3 | Canada | 181 | 38 | 8 | 80 |
| 4 | Ceylan | 4 | 17 | 2 | 24 |
| 5 | Chili | 22 | 20 | 4 | 78 |
| 6 | Danemark | 152 | 39 | 6 | 52 |
| 7 | Finlande | 75 | 30 | 7 | 88 |
| 8 | France | 54 | 29 | 7 | 45 |
| 9 | Allemagne | 43 | 35 | 6 | 50 |
| 10 | Irlande | 41 | 31 | 5 | 69 |
| 11 | Israël | 17 | 23 | 4 | 66 |
| 12 | Italie | 22 | 21 | 3 | 45 |
| 13 | Japon | 16 | 8 | 3 | 24 |
| 14 | Mexique | 10 | 23 | 3 | 43 |
| 15 | Pays-Bas | 63 | 37 | 6 | 38 |
| 16 | Nouvelle-Zélande | 170 | 40 | 8 | 72 |
| 17 | Norvège | 125 | 38 | 6 | 41 |
| 18 | Portugal | 12 | 25 | 4 | 38 |
| 19 | Suède | 221 | 39 | 7 | 52 |
| 20 | Suisse | 171 | 33 | 7 | 52 |
| 21 | Grande-Bretagne | 97 | 38 | 6 | 66 |
| 22 | États-Unis | 254 | 39 | 8 | 89 |