

Exercices de statistiques descriptives

Série 2: Exercices avec indications

P. Floquet, J. Gergaud

Exercice 1. Le tableau suivant donne les revenus imposables des Français en 1970.

Classes	Fréquences relatives
$[2500;5000[$	0.0067
$[5000;10000[$	0.3018
$[10000;15000[$	0.2750
$[15000;20000[$	0.1709
$[20000;30000[$	0.1445
$[30000;50000[$	0.0701
$[50000;70000[$	0.0166
$[70000;100000[$	0.0081
$[100000;200000[$	0.0051
$[200000;400000[$	0.0010

1. tracer l'histogramme de ces données pour les revenus allant de 0 à 7000.

Indications Attention les intervalles de classes ne sont pas constants.

Exercice 2. On désire tester n produits. On fait appel à 2 goûteurs et on leur demande de classer ces n produits. Nous avons donc à notre disposition une série statistique double:

$$\begin{aligned}x_1, x_2, \dots, x_n \\ y_1, y_2, \dots, y_n\end{aligned}$$

avec:

$$\{x_1, x_2, \dots, x_n\} = \{y_1, y_2, \dots, y_n\} = \{1, 2, \dots, n\}$$

On appelle coefficient de Spearman le coefficient de corrélation linéaire:

$$r_s = \frac{\text{cov}(x, y)}{s_x s_y}$$

1. Montrer que

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}$$

où $d_i = x_i - y_i$.

2. Que signifie $r_s = 1, r_s = -1, r_s = 0$?

Indication

1. On rappelle que la somme des n premiers entiers est égale à $n(n+1)/2$ et que la somme des carrés des n premiers entiers est égale à $n(n+1)(2n+1)/6$.

On calculera SCE_x en fonction de n

Exercice 3. Dans une solution aqueuse contenant un polluant, on plonge un solide adsorbant (charbon actif sous forme de tissu) qui "capture" une partie des molécules de la substance polluante. Au bout d'un certain temps, le système est à l'équilibre: Chaque point d'équilibre est caractérisé par la concentration à l'équilibre C_e et la quantité de polluant adsorbé par unité de masse de charbon actif, q_e . A une température donnée, on peut mesurer différents points sur une courbe (C_e, q_e) dite isotherme d'adsorption. Le tableau suivant fournit l'isotherme d'adsorption de l'aniline à 25 °C (Faur-Brasquet, 1998).

C_e (mg/l)	72	57,7	38,5	21,3	13,1	6,9	3,9	1,2
q_e (mg/g)	232,5	211	192	163,4	136,7	116,3	96,2	61,9

Etudier la liaison entre q_e et C_e en supposant que les incertitudes expérimentales sur C_e sont négligeables devant celles sur q_e . On fera le graphique en "nuage de points" des valeurs de q_e en fonction des valeurs de C_e . On étudiera ensuite les deux modèles suivants :

Modèle de Langmuir $q_e = \frac{q_m b C_e}{1 + b C_e}$

Modèle de Freundlich $q_e = K C_e^{1/n}$

Pour chacun des deux modèles, on estimera les paramètres du modèle (q_m et b , K et n) par régression linéaire simple sur des variables "modifiées".

Conclure sur "l'adéquation" des 2 modèles proposés.

Indications

On prendra pour le modèle de Langmuir les variables $x_L = 1/C_e$ et $y_L = 1/q_e$ et pour le modèle de Freundlich les variables $x_F = \ln C_e$ et $y_F = \ln q_e$. On donne

$$\sum_i x_{Li} = 1.4151 \quad \sum_i y_{Li} = 0,0628 \quad \sum_i x_{Li}^2 = 0.7904 \quad \sum_i x_{Li} y_{Li} = 0,0185$$

$$\sum_i x_{Fi} = 21,0887 \quad \sum_i y_{Fi} = 39,5204 \quad \sum_i x_{Fi}^2 = 69,6526 \quad \sum_i x_{Fi} y_{Fi} = 108,5925$$