

## Corrigé type Examen

**Solution de l'Exercice 1** Les étapes qu'on doit suivre pour réaliser le test

$H_0 : \mu_1 = \mu_2 = \mu_3 = \mu$  contre  $H_1 : \exists i, j \in \{1, 2, 3\}$  tel que  $\mu_i \neq \mu_j$ ,

à l'aide de la technique ANOVA 1, sont les suivantes :

- Calculer les moyennes des différents échantillons :  $\bar{X}_1 = 24.73$ ,  $\bar{X}_2 = 21.53$  et  $\bar{X}_3 = 23.60$ .
- Calculer la moyenne globale de toutes les observations :  $\bar{X} = \frac{1}{n}(n_1\bar{X}_1 + n_2\bar{X}_2 + n_3\bar{X}_3) = 23.2889$ .
- Compléter le tableau de l'ANOVA à un seul facteur :

source de variation	Somme des carrés SC	Degrés de libertés ddl	Carré moyen CM	ratio $F_{obs}$	Ficher c
Inter-groupe	31.5911	2	15.7956	12.02	3.6823
Intra-groupe	19.7067	15	1.3138		
Total	51.2978	17			

• **Décision** : on constate que  $f_{obs} = 12.02 > f_\alpha = 3.6823$  (pour un risque de  $\alpha = 5\%$ ), donc les espaces moyens occupés par les informations sont significativement différents d'une bases de données à une autre. Cela signifie que le facteur bases de données influe sur l'espace mémoire occupé par les informations stockées.

**Solution de l'Exercice 2**

							Somme
X $\mu g/\mu l$	0	20	40	60	80	100	300
Y	0	0.205	0.331	0.515	0.584	0.671	2.3060
$X^2$	0	400	1600	3600	6400	10000	22000
$Y^2$	0	0.0420	0.1096	0.2652	0.3411	0.4502	1.2081
$X * Y$	0	4.10	13.24	30.90	46.72	67.10	162.06

Afin de modéliser ces données, nous avons proposé le modèle linéaire suivant :

$$Y = a x + b.$$

1. Calcul des estimateurs des paramètres  $a$  et  $b$ . On a :

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{6} 300 = 50.$$

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{1}{6} 3002.3060 = 0.3843.$$

$$Cov(x, y) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{X} \bar{Y} = \frac{1}{6} (162.06) - (50) (0.3843) = 7.7950$$

$$Var(x) = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{X}^2 = \frac{1}{6} (22000) - (50)^2 = 1166.6667$$



alors,

$$\hat{a} = \frac{Cov(x, y)}{Var(x)} = \frac{\frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{X} \bar{Y}}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{X}^2} = 0.0067.$$

$$\hat{b} = \bar{Y} - \hat{a} \bar{X} = 0.0503,$$

de ce fait la droite de régression de l'absorbance ( $Y$ ) en fonction de la concentration ( $x$ ) est donnée par :

$$\hat{Y} = 0.0067 x + 0.0503.$$

2. Quelle absorbance prévoyez-vous à une concentration  $40 \mu\text{g}/\mu\text{l}$ ? Que peut-on conclure?

$$\hat{Y} = 0.0067 (40) + 0.0503 = 0.3183.$$

On constate que la valeur de régression est très proche de la vraie valeur (0.331), donc à priori le modèle retenu est adéquate pour la représentation des données du tableau.

3. Calcul du coefficient de corrélation linéaire.

$$r = r(x, y) = \frac{Cov(x, y)}{\sigma_x \sigma_y} = 0.9851,$$

avec  $\sigma_y = \sqrt{var(Y)} = \sqrt{\frac{1}{n} \sum_{i=1}^n y_i^2 - \bar{Y}^2} = \sqrt{0.0536} = 0.2316$ ; La valeur du coefficient de corrélation est très proche de 1, i.e.  $X$  et  $Y$  sont fortement linéairement liés donc le modèle est efficace ce qui confirme les résultats de la question 3).

4. Pour un seuil de risque  $\alpha = 5\%$ , le modèle proposé est-il pertinent?

Pour répondre à cette question on utilise le test de validation du modèle (Fisher). On d'une part

$$f_c = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{Y})^2 / 1}{\sum_{i=1}^n (y_i - \hat{y}_i)^2 / (n - 2)} = \frac{0.3124 / 1}{0.0095 / (6 - 2)} = 131.5368,$$

et d'autre part

$$f_\alpha = f(1, n - 2, 1 - \alpha) = f(1, 4, 0.95) = 7.71.$$

On constate que  $f_c > f_\alpha$ , alors on accepte le modèle proposé, c'est-à-dire le modèle est valide (pertinent)