

**Préparation du contrôle du second semestre - exercices corrigés.**

On donne: si  $Z$  suit  $\mathcal{N}(0, 1)$ , alors  $P[Z > 1.6449] = 0.05$ ,  $P[Z > 2.3263] = 0.01$ .  
 $P[|Z| > 1.96] = 0.05$  et  $P[|Z| > 2.5758] = 0.01$ .

**Exercice 1.** Soit  $X$  une variable aléatoire réelle continue ayant pour densité de probabilité

$$f(x) = \begin{cases} \lambda x & \text{si } 0 \leq x \leq 1 \\ 0 & \text{ailleurs} \end{cases}.$$

- (1) Calculez  $\lambda$ .
- (2) Calculez la moyenne de  $X$ .
- (3) Calculez  $\mathbb{P}(X \in [0, 1/2])$ .

**Exercice 2.** La durée d'attente à une caisse de supermarché est assimilée à une loi exponentielle. La variable aléatoire égale au délai d'attente suit une loi exponentielle de paramètre  $\lambda = 0,04 \text{ min}^{-1}$ .

- (1) Quelle est la probabilité qu'un client attende moins de cinq minutes ?
- (2) Quelle est la probabilité qu'il attende plus de 15 minutes ?
- (3) Quel est le temps d'attente moyen ?

**Exercice 3.** Le staff médical d'une grande entreprise fait des statistiques sur le taux de cholestérol de ses employés ; les observations sur 100 employés tirés au sort sont les suivantes:

Taux de cholestérol (en cg)	120	160	200	240	280	320
effectif	9	22	25	21	16	7

- (1) Estimez la moyenne et l'écart-type empiriques de l'échantillon.
- (2) Donnez les intervalles de confiance à 95% et 99% pour la moyenne.

**Exercice 4.** On souhaite vérifier si la prise de poids d'un jeune mouton en un an (variable  $Y$  en kilogrammes) dépend de son poids initial (variable  $X$  également en kilogrammes). Sur 100 moutons, on donne les résultats suivants :

$$\sum x_i = 3560; \sum y_i = 4230; \sum x_i^2 = 127200; \sum y_i^2 = 180100; \sum x_i y_i = 151320.$$

- (1) Calculez la moyenne et l'écart type empiriques de  $X$  et  $Y$ .
- (2) Calculer le coefficient de corrélation linéaire.
- (3) Estimer les paramètres  $a$ ,  $b$  pour la régression linéaire de  $Y$  sur  $X$ .
- (4) Selon ce modèle combien un mouton de poids initial 37 kg devrait-il prendre de poids ?

**Exercice 5.** Chez un individu adulte, le logarithme du dosage en d-dimères, variable que nous noterons  $X$ , est modélisé par une loi normale d'espérance  $\mu$  et de variance  $\sigma^2$ . La variable  $X$  est un indicateur de risque cardio-vasculaire: on considère que chez les individus sains,  $\mu = 1$ , alors que chez les individus à risque,  $\mu = 0$ . Dans les deux cas, la valeur de  $\sigma^2$  est la même :  $\sigma^2 = 0.09$ .

Le Dr. House ne souhaite pas alarmer inutilement ses patients. Quelles hypothèses  $H_0$  et  $H_1$  choisira-t-il de tester ? Donner la règle de décision pour son test, au seuil de 1%, et au seuil de 5%.

**Solution de l'exercice 1.** 1) Il faut  $f \geq 0$  donc  $\lambda \geq 0$  et  $\int_{\mathbb{R}} f(x) dx = 1$  soit

$$1 = \int_0^1 \lambda x dx = \left[ \frac{\lambda x^2}{2} \right]_0^1 = \frac{\lambda}{2}$$

d'où  $\lambda = 2$ .

$$2) \mathbb{E}[X] = \int_{\mathbb{R}} x f(x) dx = \int_0^1 2x^2 dx = \left[ \frac{2x^3}{3} \right]_0^1 = \frac{2}{3}$$

$$3) \mathbb{P}(X \in [0, 1/2]) = \int_0^{1/2} 2x dx = [x^2]_0^{1/2} = \frac{1}{4}.$$

**Solution de l'exercice 2.** Rappelons que la loi exponentielle de paramètre  $\lambda$  est donnée par la densité

$$f(x) = \begin{cases} \lambda e^{-\lambda x} & \text{si } x \geq 0 \\ 0 & \text{sinon} \end{cases}.$$

$$1) P(X \leq 5) = \int_0^5 0.04 e^{-0.04t} dt = [-e^{-0.04t}]_0^5 = -e^{-0.2} + 1 = 0.18$$

$$2) P(X \geq 15) = 1 - P(X \leq 15) = 1 - \int_0^{15} 0.04 e^{-0.04t} dt = 1 - [-e^{-0.04t}]_0^{15} = 1 + e^{-0.6} - 1 = 0.55$$

$$3) E[X] = \int_0^{+\infty} 0.04t e^{-0.04t} dt = [-te^{-0.04t}]_0^{+\infty} + \int_0^{+\infty} e^{-0.04t} dt = -0 + 0 + \left[ -\frac{1}{0.04} e^{-0.04t} \right]_0^{+\infty} = \frac{1}{0.04} = 25 \text{ min}$$

**Solution de l'exercice 3.** 1)  $\tilde{\mu} = \frac{120 \times 9 + 160 \times 22 + \dots + 320 \times 7}{100} = 214 \text{ cg}$

$$\sigma^2 = \frac{120^2 \times 9 + 160^2 \times 22 + \dots + 320^2 \times 7}{100} - 214^2 \text{ donc } \sigma = 55,8.$$

2) Les intervalles de confiance sont de la forme  $[\tilde{\mu} - u_\alpha \frac{\sigma}{\sqrt{n}}, \tilde{\mu} + u_\alpha \frac{\sigma}{\sqrt{n}}]$  où  $u_\alpha = 1.96$  pour 95% et  $u_\alpha = 2.5758$  pour 99%.

En effet, les données sont une réalisation de la variable aléatoire  $(X_1, \dots, X_{100})$  où  $X_1, \dots, X_{100}$  sont 100 copies indépendantes de la variable aléatoire  $X$ : taux de cholestérol chez un employé.

La moyenne empirique est une réalisation de la variable aléatoire  $Y = \frac{X_1 + \dots + X_{100}}{100}$ .

Soit  $Z = \frac{X_1 - \mu + \dots + X_{100} - \mu}{\sigma \sqrt{100}}$ . D'après le théorème central limite,  $Z$  suit (à

peu près) la loi normale  $\mathcal{N}(0, 1)$ . De plus  $\frac{\sigma Z}{\sqrt{n}} = Y - \mu$  et comme  $\tilde{\mu}$  est une réalisation de  $Y$ ,

$$P(|\mu - \tilde{\mu}| \geq \lambda) = P\left(\left|\frac{\sigma Z}{\sqrt{n}}\right| \geq \lambda\right) = P\left(|Z| \geq \lambda \frac{\sqrt{n}}{\sigma}\right)$$

Comme  $Z$  suit  $\mathcal{N}(0, 1)$  on sait déterminer  $u_\alpha$  pour que  $P(|Z| \geq u_\alpha) = \alpha$  et on prend  $\lambda$  pour que  $\lambda \frac{\sqrt{n}}{\sigma} = u_\alpha$  soit  $\lambda = u_\alpha \frac{\sigma}{\sqrt{n}}$ .

**Solution de l'exercice 4.** 1) Les moyennes sont  $\mu_X = \frac{1}{100} \sum x_i = \frac{3560}{100} = 35.6$  et  $\mu_Y = \frac{1}{100} \sum y_i = \frac{423}{100} = 42.3$ .

Les écarts-types sont  $\sigma_X^2 = \frac{1}{100} \sum x_i^2 - \mu_X^2 = 4.64$  d'où  $\sigma_X = 2.15$  et  $\sigma_Y^2 = \frac{1}{100} \sum y_i^2 - \mu_Y^2 = \sum y_i^2 = 11.71$  d'où  $\sigma_Y = 3.42$ .

2)  $\sigma_{XY} = \frac{1}{100} \sum x_i y_i - \mu_X \mu_Y = 7.32$  d'où  $\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} = 0.99$  ce qui indique une très forte corrélation.

3)  $a = \frac{\sigma_{XY}}{\sigma_X^2} = 1.58$  et  $b = \mu_Y - \mu_X \frac{\sigma_{XY}}{\sigma_X^2} = -13.86$ .

4) La droite de régression est  $y = ax + b$ , selon ce modèle, si  $x = 37$ ,  $y = 1.58 \times 37 - 13.86 = 44.6 \text{ kg}$ . La prise de poids est donc de  $44.6 - 37 = 7.6 \text{ kg}$ .

**Solution de l'exercice 5.** Si Dr. House ne veut pas alarmer inutilement un patient, l'hypothèse qu'il considère comme dangereux de rejeter à tort est: *le patient n'est pas à risque*, donc que sa variable  $X$  (la statistique de test) a pour espérance 1. Son hypothèse  $H_0$  est donc  $\mu = 1$  (le patient ne présente pas de risque), qu'il teste contre  $H_1: \mu = 0$  (le patient présente un risque). Il choisira de rejeter des valeurs trop élevées de  $X$ . La règle de décision sera donc

$$\text{Rejet de } H_0 \Leftrightarrow X > \ell,$$

où  $P_{H_0}[X > \ell] = \alpha$ .

Sous l'hypothèse  $H_0$ , la statistique de test  $X$  suit la loi  $\mathcal{N}(1, 0.09)$ , donc  $\frac{X(1)}{\sqrt{0.09}}$  suit la loi  $\mathcal{N}(0, 1)$ . Une règle de décision équivalente est :

$$\text{Rejet de } H_0 \Leftrightarrow \frac{X(1)}{\sqrt{0.09}} > \frac{\ell(1)}{\sqrt{0.09}}.$$

Donc  $\frac{\ell(1)}{\sqrt{0.09}}$  est la valeur qui a probabilité  $\alpha$  d'être dépassée pour une variable aléatoire  $Z$  de loi  $\mathcal{N}(0, 1)$  :  $P[Z > 1.6449] = 0.05$ ,  $P[Z > 2.3263] = 0.01$ . Au seuil 0.05% la règle de décision du test est:

$$\text{Rejet de } H_0 \Leftrightarrow \frac{X(1)}{\sqrt{0.09}} > 1.6449 \Leftrightarrow X > 1.6449\sqrt{0.09} - 1 = 0.5065.$$

On déclare que le patient présente un risque cardio-vasculaire quand son dosage en d-dimères est supérieur à 0.5065.

Au seuil 0.01 la règle de décision du test est :

$$\text{Rejet de } H_0 \Leftrightarrow \frac{X(1)}{\sqrt{0.09}} > 2.3263 \Leftrightarrow X > 2.3263\sqrt{0.09} - 1 = 0.3021.$$

Plus le seuil est faible, moins la règle de décision rejette d'individus à risque. Ce qui doit se produire pour rejeter  $\mu = 1$  au seuil 0.01 est plus extraordinaire qu'au seuil 0.05.