

## T. D. n VI. Suite tests d'hypothèse

## Exercice n°1.

Une nouvelle technique de dosage de sels nutritifs vient d'être mise au point. Sept dosages, effectués à l'aide de cette nouvelle technique, à partir d'échantillons d'eau de mer de la même station, donnent les résultats suivants :

1.17, 1.16, 1.16, 1.19, 1.19, 1.21, 1.18 mg/l.

1. La technique utilisée jusque là était caractérisée par un écart-type de 0.05 mg/l. Peut-on dire que la nouvelle technique est plus précise que l'ancienne?
2. Déterminer un intervalle de confiance de la moyenne  $\mu$ .

## Exercice n°2.

On considère deux variables aléatoires réelles  $R$  et  $S$  de densités de probabilité données par :

$$f_R(r) = ae^{-ar}, r > 0, 0 \text{ sinon,}$$

et

$$f_S(s) = be^{-bs}, s > 0, 0 \text{ sinon.}$$

On veut construire des test concernant les paramètres  $a > 0$  et  $b > 0$  de ces deux distributions en construisant des variables aléatoires de densité connue.

1. Montrer que la variable aléatoire  $T = 2aR$  suit une loi du  $\chi_2^2$ . En déduire espérance et variance de  $R$ .
2. Soit un échantillon  $\{R_1, \dots, R_n\}$  *i.i.d.* de  $R$ . Soit la variable  $Z_n = 2a(R_1 + \dots + R_n)$ . Donner sa loi.
3. Soit un autre échantillon *i.i.d.*  $\{S_1, \dots, S_p\}$  de  $S$ . Soit la variable  $U(n, p) = \frac{pa(R_1 + \dots + R_n)}{nb(S_1 + \dots + S_p)}$ . Donner la loi de  $U(n, p)$ .
4. **Premier test.** Soit  $n = 12$ . On a observé :

0.1, 1.197, 0.152, 0.182, 0.418, 0.192, 0.029, 0.885, 0.161, 0.633, 0.278, 0.008.

Construire un test d'hypothèse  $H_0 : a = 3$  contre  $H_1 : a > 3$ . Donner le résultat du test.

5. **Second test.** Soit  $p = 10$ . On a observé :

0.361, 0.085, 0.293, 0.08, 0.077, 0.02, 0.036, 0.095, 0.197, 0.206.

Construire un test d'hypothèse  $H_0 : a = b$  contre  $H_1 : a \neq b$ . Donner le résultat du test.

6. **Estimation.** En cas de rejet de l'hypothèse  $a = b$ , déterminer un intervalle de confiance de  $b$  et donner une estimation de  $b$ .




Figure 1: Distribution du  $\chi_6^2$  et zone de rejet pour  $\alpha = 0.05$

## Corrections

### Correction Exercice n°1.

**Q1-** Dans cet exercice, il n'y a aucune indication sur la connaissance de paramètres populationnels. Nous travaillerons avec la réalisation d'un échantillon de  $n = 7$  variables aléatoires  $\{X_1, \dots, X_n\}$  que nous supposons *i.i.d.* et de même loi mère d'une variable  $X \rightsquigarrow \mathcal{N}(\mu, \sigma^2)$ . Nous allons donc commencer par estimer l'espérance et la variance de la population grâce aux estimateurs empiriques

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i,$$

$$S_{n-1}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2.$$

Les valeurs réalisées de ces estimateurs nous donne  $\bar{x}_{obs} = 1.18$  et  $6 \times s_6^2 = 0.002$ . Posons  $\sigma_0^2 = 0.05^2$ . On va maintenant construire un test pour confronter l'hypothèse nulle  $H_0 : \sigma^2 = \sigma_0^2$  contre l'alternative  $H_1 : \sigma^2 < \sigma_0^2$  (l'énoncé nous dit "plus précis"). Sous  $H_0$ , la variable

$$Z = \frac{(n-1) S_{n-1}^2}{\sigma_0^2} = \frac{6 S_6^2}{\sigma_0^2} \rightsquigarrow \chi_6^2$$

suit une loi du Chi2 à 6 degrés de liberté. Sous  $H_1$ , le protocole étant plus précis, les valeurs de l'échantillon devraient être peu dispersées :  $Z$  aura tendance à prendre des valeurs plus petites que sous  $H_0$ . Nous avons donc affaire à un test unilatéral avec zone de rejet à gauche (Fig. 1).

Fixons  $\alpha = 0.05$ , le risque de rejeter à tort l'hypothèse nulle, risque que l'on fixe petit. La valeur  $z_{n-1;\alpha} = z_{6;0.05} = 1.635$  représente le quantile d'ordre  $\alpha$  de la loi du  $\chi_6^2$ . La zone rouge de la figure 1 représente la zone de rejet de  $H_0$

$$RH_0 = [0; 1.635[$$

L'échantillon nous donne  $s_6^2 = \frac{0.002}{6}$  soit une valeur

$$z_{obs} = \frac{0.002}{0.0025} = 0.8$$

sous  $H_0$ . On observe que  $z_{obs} < 1.635$  et donc  $z_{obs} \in RH_0$ . On en déduit donc, qu'avec une probabilité de 0.95, le nouveau protocole expérimental est plus précis que celui d'avant. On peut également calculer la valeur  $\alpha_{obs} = P(Z \leq z_{obs}) = 0.008$ , (appelée *p-value*), très faible dans ce cas.

**Q2-** L'intervalle de confiance de l'espérance est la fois dépendant de l'estimation de la moyenne de la population mais également de celui de l'écart-type en utilisant un échantillon de faible effectif. On cumule donc deux sources de variabilité liées aux estimations des deux paramètres populationnels. On va s'intéresser à la variable

$$T = \frac{\bar{X} - \mu}{\sqrt{\frac{S_{n-1}^2}{n}}} = \frac{\bar{X} - \mu}{\sqrt{\frac{S_n^2}{n-1}}} = \frac{\bar{X} - \mu}{\sqrt{\frac{S_6^2}{7}}} \rightsquigarrow \mathcal{T}_6$$

qui suit une loi de Student à 6 degrés de liberté.

On connaît l' $IC_{1-\alpha}$  lorsque la moyenne et la variance populationnelle sont inconnus

$$IC_{1-\alpha} = \left[ \bar{X} - \sqrt{\frac{S_{n-1}^2}{n}} t_{n-1; 1-\alpha/2}; \bar{X} + \sqrt{\frac{S_{n-1}^2}{n}} t_{n-1; \alpha/2} \right].$$

Avec  $\alpha = 0.05$ , la valeur observée de  $\bar{X}$  et les quantiles de la loi de Student à  $n - 1 = 6$  degrés de liberté, on obtient

$$IC_{0.95} = \left[ 1.18 - \sqrt{\frac{0.002}{6 \times 7}} \times 2.447; 1.18 + \sqrt{\frac{0.002}{6 \times 7}} \times 2.447 \right] = [1.163; 1.197].$$

Avec une probabilité de 0.95, sachant l'écart-type de la population inconnu et estimé avec un échantillon de petite taille, la moyenne de la population se situe dans l'intervalle [1.163 1.197].

### Correction Exercice n°2.

**Q1-** Soit  $X$  une variable aléatoire suivant une loi du  $\chi_k^2$  à  $k$  degrés de liberté. Sa densité est donnée par

$$f_X(x) = \frac{1}{2^{\frac{k}{2}} \Gamma\left(\frac{k}{2}\right)} x^{\frac{k}{2}-1} \exp\left(-\frac{x}{2}\right), \quad x \geq 0,$$

où

$$\Gamma(z) = \int_0^{+\infty} t^{z-1} \exp(-t) dt$$

s'appelle la fonction Gamma. Soit  $T = 2aR$  une variable aléatoire. Pour trouver sa densité, on va d'abord chercher l'expression de sa fonction de répartition (FR)

$$\begin{aligned} F_T(t) &= P(T \leq t) \\ &= P(2aR \leq t) \\ &= P\left(R \leq \frac{t}{2a}\right) \\ &= F_R\left(\frac{t}{2a}\right). \end{aligned}$$

La FR de  $T$  est donc reliée à celle de  $R$ . La densité de  $T$  est donnée par la dérivée de sa FR

$$f_T(t) = \frac{dF_T}{dt}(t).$$

Or,  $R$  est une variable aléatoire qui suit une loi exponentielle de paramètre  $a$  (on notera  $R \rightsquigarrow \mathcal{E}(a)$ ), on connaît (ou on calcule aisément) sa FR que l'on peut évaluer en  $\frac{t}{2a}$  avec

$$F_R\left(\frac{t}{2a}\right) = 1 - \exp\left(-a \times \frac{t}{2a}\right), \quad t \geq 0.$$

La dérivée de cette fonction nous donne la densité de  $T$

$$f_T(t) = \frac{1}{2} \exp\left(-\frac{t}{2}\right), \quad t \geq 0.$$

On reconnaît ici une loi exponentielle de paramètre  $\frac{1}{2}$  donc  $T \rightsquigarrow \mathcal{E}\left(\frac{1}{2}\right)$ . Or, une variable  $X$  qui suit une loi du  $\chi_2^2$  à pour densité

$$f_X(x) = \frac{1}{2\Gamma(1)} \exp\left(-\frac{x}{2}\right), x \geq 0.$$

On peut montrer facilement que  $\Gamma(1) = 1$  avec

$$\Gamma(1) = \int_0^{+\infty} e^{-t} dt = [-e^{-t}]_0^{+\infty} = 1,$$

et on en déduit que la densité d'une loi du  $\chi_2^2$  est la même que celle d'une loi  $\mathcal{E}\left(\frac{1}{2}\right)$  donc

$$T = 2aR \rightsquigarrow \chi_2^2 = \mathcal{E}\left(\frac{1}{2}\right).$$

L'espérance et la variance d'une loi  $\chi_n^2$  sont données par

$$\begin{aligned} E(T) &= n \\ V(T) &= 2n. \end{aligned}$$

Dans notre cas,  $n = 2$ , donc

$$\begin{aligned} E(T) &= 2 \\ V(T) &= 4. \end{aligned}$$

On peut alors calculer l'espérance et la variance de  $R$  grâce au fait que

$$\begin{aligned} E(T) &= E(2aR) = 2 \\ V(T) &= V(2aR) = 4. \end{aligned}$$

Les propriétés de linéarité de l'espérance, les propriétés de la variance nous amène à

$$\begin{aligned} 2aE(R) &= 2 \\ 4a^2V(R) &= 4, \end{aligned}$$

on en déduit ainsi que

$$\begin{aligned} E(R) &= \frac{1}{a}, \\ V(R) &= \frac{1}{a^2}, \end{aligned}$$

résultats bien connus d'une variable qui suit une loi exponentielle de paramètre  $a$ .

**Q2-** Nous considérons maintenant la variable  $Z_n = 2a(R_1 + \dots + R_n)$ . On sait que les variables  $R_i$  sont indépendantes. On peut réécrire  $Z_n = T_1 + \dots + T_n$ , somme de  $n$  variables aléatoires indépendantes de même loi que la variable  $T$ . Or on sait qu'une variable aléatoire, somme de deux lois du  $\chi^2$  indépendantes, suit également une loi du  $\chi^2$  telle que

$$\chi_n^2 + \chi_p^2 \rightsquigarrow \chi_{n+p}^2.$$

La variable  $Z$  est une somme de  $n$  variables du  $\chi_2^2$ . On en déduit donc que

$$Z_n \rightsquigarrow \chi_{2n}^2.$$

**Q3-** On considère maintenant la variable

$$U(n, p) = \frac{pa(R_1 + \dots + R_n)}{nb(S_1 + \dots + S_p)}.$$




Figure 2: Distribution d'un  $\chi_{24}^2$  et test unilatéral.

On déduit des premières questions que

$$Y = 2bS \rightsquigarrow \chi_2^2$$

et que la variable  $W_p = 2b(S_1 + \dots + S_p)$  est telle que

$$W_p \rightsquigarrow \chi_{2p}^2.$$

La variable  $U(n, p)$  correspond donc à un rapport de deux variables aléatoires qui suivent une loi du  $\chi^2$  :

$$U(n, p) = \frac{2p \times 2a(R_1 + \dots + R_n)}{2n \times 2b(S_1 + \dots + S_p)} = \frac{2pZ_n}{2nW_p}.$$

La densité d'une telle variable aléatoire est connue sous le nom de loi de Fisher-Snedecor de paramètres  $(2n, 2p)$  et on note

$$U(n, p) \rightsquigarrow \mathcal{F}(2n, 2p).$$

**Q4-** On a observé  $n = 12$  valeurs de l'échantillon  $\{R_1, \dots, R_n\}$ . On souhaite savoir si cet échantillon provient d'une loi exponentielle de paramètre  $a_0 = 3$ . Pour cela, on construit un test statistique pour confronter l'hypothèse nulle  $H_0 : a = a_0$  à l'alternative  $H_1 : a > a_0$ . On s'intéresse naturellement à la statistique de test  $Z_{12} = 2a_0(R_1 + \dots + R_{12})$ . Sous  $H_0$ ,  $Z_{12} \rightsquigarrow \chi_{24}^2$ . Sous  $H_1$ , l'échantillon ne provient pas d'une loi exponentielle de paramètre  $a = a_0$  mais de paramètre, disons,  $a = a_1$ . La variable  $Z_{12}$  ne suit plus la même distribution mais on peut écrire

$$Z_{12} = \frac{a_0}{a_1} \times 2a_1(R_1 + \dots + R_{12}) = \frac{a_0}{a_1} Z'_{12}$$

où  $Z'_{12} \rightsquigarrow \chi_{24}^2$  d'après les résultats précédents. On voit que si  $a_1$  augmente,  $Z_{12}$  prendra probablement des valeurs inférieures à celles obtenues sous  $H_0$ . Le test est donc unilatéral avec zone de rejet à gauche (Fig. 2).

Fixons  $\alpha = 0.05$ , le risque de rejeter à tort l'hypothèse nulle, risque que l'on fixe petit. La zone de rejet de  $H_0$  est alors égale à :

$$RH_0 = [0; 13.85[$$

où la valeur  $z_{2n;\alpha} = z_{24;0.05} = 13.85$  représente le quantile d'ordre  $\alpha$  de la loi du  $\chi_{24}^2$ . Cette valeur correspond à une probabilité de 0.95 de trouver une valeur de  $Z$  dans la zone de non-rejet de  $H_0$  si l'échantillon provient d'une population sous  $H_0 : a = a_0$

$$P(Z_{12} \geq z_{24;\alpha}) = P(Z_{12} \in \overline{RH_0}/H_0) = 1 - \alpha.$$

L'échantillon nous donne  $r_1 + \dots + r_{12} = 4.235$  soit une valeur  $z_{obs} = 2 \times 3 \times 4.235 = 25.41$ , sous  $H_0$ . On observe que  $z_{obs} \in \overline{RH_0}$ . On peut également calculer la valeur  $\alpha_{obs} = P(Z_{12} \leq z_{obs}) = 0.616$ , ce qui est élevé. On en




Figure 3: Distribution de Fisher  $\mathcal{F}(24, 10)$  et test bilatéral.

déduit donc, qu'avec une probabilité de 0.95, l'échantillon provient de  $n = 12$  réalisations indépendantes d'une loi  $\mathcal{E}(a = 3)$ .

**Q5-** On dispose maintenant d'un échantillon  $\{R_1, R_2, \dots, R_{12}\}$  de taille  $n = 12$  et d'un échantillon  $\{S_1, S_2, \dots, S_{10}\}$  de taille  $p = 10$ , indépendant du précédent. On veut tester  $H_0 : a = b$  contre  $H_1 : a \neq b$ . Pour cela, on choisit la variable

$$U(12, 10) = \frac{10a(R_1 + R_2 + \dots + R_{12})}{12b(S_1 + S_2 + \dots + S_{10})}.$$

que l'on sait suivre une loi de Fisher  $\mathcal{F}(24, 20)$ .

Sous  $H_0 : 1 = \frac{a}{b}$ , la variable

$$U_0(12, 10) = \frac{10(R_1 + R_2 + \dots + R_{12})}{12(S_1 + S_2 + \dots + S_{10})} \rightsquigarrow \mathcal{F}(24, 20).$$

Sous  $H_1 : a \neq b$ , on peut écrire

$$U_0(12, 10) = \frac{b10a(R_1 + R_2 + \dots + R_{12})}{a12b(S_1 + S_2 + \dots + S_{10})} = \frac{b}{a}U(12, 10).$$

Cette expression nous permet de voir que si  $a > b$ , les valeur de  $U_0(12, 10)$  vont avoir tendance à baisser par rapport à  $H_0$  : la zone de rejet sera à gauche. Dans le cas  $a < b$ , la zone de rejet de  $H_0$  sera à droite. Nous avons affaire à un test bilatéral (Fig. 3).

Fixons  $\alpha = 0.05$ , le risque de rejeter à tort l'hypothèse nulle, risque que l'on fixe petit. La zone de non-rejet de  $H_0$  est alors égale à :

$$\overline{RH}_0 = [0.43; 2.407]$$

où la valeur  $u_{\alpha/2}(12, 10) = f_{0.025}(24, 20) = 0.43$  représente le quantile d'ordre  $\alpha/2$  de la loi de Fisher  $\mathcal{F}(24, 20)$  et  $u_{1-\alpha/2}(12, 10) = f_{0.975}(24, 20) = 2.407$  représente le quantile d'ordre  $1 - \alpha/2$ . L'échantillon nous donne

$$u_{obs} = \frac{10 \times 4.235}{12 \times 1.45} \simeq 2.434,$$

on voit immédiatement que  $u_{obs} \in RH_0$ . On en déduit donc, qu'avec une probabilité de 0.95, que les deux échantillons ne proviennent pas de la même loi exponentielle. Cependant, la valeur seuil

$$\alpha_{obs} = P(U(12, 10) \geq u_{obs}) = 0.0236$$

est très proche de 0.025 car  $u_{obs}$  est proche du seuil  $f_{0.975}(24, 20) = 2.407$ . Si le test est significatif, une petite modification de l'échantillon mènerait probablement à des résultats différents.

**Q6-** Pour construire un intervalle de confiance de  $b$ , nous allons considérer la variable aléatoire

$$W_{20} = 2b(S_1 + S_2 + \dots + S_{10}) = 20b\bar{S}$$

qui suit une loi du  $\chi_{20}^2$ , où  $\bar{S}$  est la moyenne empirique des  $S_i$ . On peut alors calculer la probabilité suivante

$$P(w_{20;\alpha/2} \leq W_{20} \leq w_{20;1-\alpha/2}) = 1 - \alpha$$

$$P\left(\frac{w_{20;\alpha/2}}{20\bar{S}} \leq b \leq \frac{w_{20;1-\alpha/2}}{20\bar{S}}\right) = 1 - \alpha.$$

On a observé  $\bar{s}_{obs} = 0.145$  et pour un coefficient de sécurité de 0.95, on a  $w_{20;0,025} = 9.59$  et  $w_{20;0,975} = 34.17$ . D'où, l'intervalle de confiance

$$3.307 \leq b \leq 11.78.$$

On sait que  $E(S) = \frac{1}{b}$ . Un bon estimateur de l'espérance de  $S$  est donné par  $\bar{S}$ . C'est un estimateur sans biais ( $E(\bar{S}) = E(S)$ ) et consistant : la limite lorsque  $p \rightarrow +\infty$  de  $V(\bar{S}) = \frac{1}{p}V(S)$  est nulle. On peut donc en déduire une estimation  $b_{obs}$  de  $b$  avec

$$b_{obs} = \frac{1}{\bar{s}_{obs}} = \frac{1}{0.145} = 6.89.$$