

Solution de l'exercice 1 de la série N°3

Exercice 1 Une étude de sociologie porte sur le temps passé par des enfants, âgés de 8 à 16 ans, sur des jeux électroniques. La question est de savoir si le temps moyen par jour est de 7 heures. On a demandé à 15 enfants leurs nombres d'heures de jeu par jour et les réponses sont les suivantes:

5 9 5 8 7 6 7 9 7 9 6 9 10 9 8

1. En supposant que ce temps est normalement distribué, avec une variance égale à 3, que conclut-on au niveau de signification 5% ?
2. Répondre à la même question si la variance était inconnue.

Solution. 1) Le cas variance connue $\sigma^2 = 3$. Il s'agit d'un test bilatéral:

$$\begin{cases} H_0 : \mu = 7 \\ H_1 : \mu \neq 7 \end{cases}$$

D'après le cours la région critique est de la forme

$$W := \{(x_1, \dots, x_{15}) \in \mathbb{R}^+ : |\bar{x} - 7| \geq k\},$$

avec $\mathbf{P}_{\mu=7}(|\bar{X} - 7| \geq k) = \alpha = 0.05$. En d'autres termes

$$\mathbf{P}_{\mu=7} \left(\left| \frac{\bar{X} - 7}{\sqrt{3/15}} \right| \geq \frac{k}{\sqrt{3/15}} \right) = 0.05,$$

ce qui est équivalent à $\mathbf{P}(|Z| \geq \sqrt{5}k) = 0.05$. Ceci implique que

$$\sqrt{5}k = \Phi^{-1}(1 - 0.05/2) = 1.96,$$

ainsi $k = 1.96/\sqrt{5} = 0.876$. La fonction test statistique est donc

$$\delta = \begin{cases} 1 & \text{si } |\bar{x} - 7| \geq 0.876 \\ 0 & \text{si } |\bar{x} - 7| < 0.876 \end{cases}.$$

Application: nous avons

$$\bar{x} = \frac{1}{15} (5 + 9 + 5 + 8 + 7 + 6 + 7 + 9 + 7 + 9 + 6 + 9 + 10 + 9 + 8) = 7.6.$$

Comme $|7.6 - 7| = 0.6 < 0.876$, alors en garde H_0 , c'est à dire le temps passé par des enfants, âgés de 8 à 16 ans, sur des jeux électroniques est en effet de 7 heures.

2. **Le cas variance inconnue.** D'après le cours, la région critique est de la forme

$$W := \left\{ (x_1, \dots, x_{15}) \in \mathbb{R}^+ : \left| \frac{\bar{x} - 7}{\tilde{s}/\sqrt{15-1}} \right| \geq t_{1-0.05/2} \right\},$$

où $\tilde{s} = \sqrt{\frac{1}{15} \sum_{i=1}^{15} (x_i - \bar{x})^2}$ (la variance empirique observée) et $t_{1-0.05/2}$ est le quantile d'ordre $1 - 0.05/2 = 0.975$ de loi de student à $15 - 1 = 14$ degré de liberté. De la table statistique on tire $t_{1-0.05/2} = 2.144$. La fonction test statistique est donc

$$\delta = \begin{cases} 1 & \text{si } \left| \frac{\bar{x}-7}{\tilde{s}/\sqrt{15-1}} \right| \geq 2.144 \\ 0 & \text{si } \left| \frac{\bar{x}-7}{\tilde{s}/\sqrt{15-1}} \right| < 2.144 \end{cases}.$$

Application: nous avons $\tilde{s}^2 = \frac{1}{15} \sum_{i=1}^{15} (x_i - 7.6)^2 = 2.722$ qui donne $\tilde{s} = 1.65$. Comme $\left| \frac{7.6-7}{1.65/\sqrt{15-1}} \right| = 1.3606 < 2.144$, alors on garde encore une fois l'hypothèse nulle H_0 .

Solution de l'exercice 2 de la Série N°3

Exercice 2.

On suppose que le poids (en grammes) d'un paquet de café est une variable aléatoire normale de moyenne μ et de variance σ^2 (toutes les deux inconnues). Pour faire des tests, au niveau de signification 10%, sur ces deux paramètres, on dispose de l'échantillon suivant :

480 502 484 500 504 503 495 500 501 481

Que décidez-vous pour chacun des problèmes suivants :

$$\begin{cases} H_0 : \mu = 500 \\ H_1 : \mu \neq 500 \end{cases} \text{ et } \begin{cases} H_0 : \sigma^2 = 25 \\ H_1 : \sigma^2 > 25 \end{cases}$$

Solution. Considérons tout d'abord le test bilatérale de la moyenne

$$\begin{cases} H_0 : \mu = 500 \\ H_1 : \mu \neq 500 \end{cases},$$

avec $n = 10$, $\alpha = 0.1$ et σ^2 est inconnue. D'après le cours, la région critique de ce test est donnée par

$$W = \left\{ (x_1, \dots, x_{10}) \in \mathbb{R}_+^{10} \mid \frac{|\bar{x} - 500|}{\tilde{s}/\sqrt{10-1}} \geq k \right\},$$

où k est la solution de l'équation $\mathbf{P}(|T_{(10-1)}| \geq k) = \alpha = 0.1$, avec $T_{(10-1)} = T_9$ est la variable aléatoire de Student à 9 degré de liberté. On rappelle que $\bar{x} = \frac{1}{10} \sum_{i=1}^{10} x_i$ et $\tilde{s}^2 = \frac{1}{10} \sum_{i=1}^{10} (x_i - \bar{x})^2$ désignent la moyenne et la variance empiriques respectivement. De la table statistique de la loi de Student on obtient $k = 1.8331$, ainsi

$$W = \left\{ (x_1, \dots, x_{10}) \in \mathbb{R}_+^{10} \mid \frac{|\bar{x} - 500|}{\tilde{s}/3} \geq 1.8331 \right\}.$$

Le fonction statistique test correspondante est

$$\delta(x_1, \dots, x_{10}) = \begin{cases} 1 & \text{si } \frac{|\bar{x} - 500|}{\tilde{s}/3} \geq 1.8331 \\ 0 & \text{si } \frac{|\bar{x} - 500|}{\tilde{s}/3} < 1.8331 \end{cases}.$$

La moyenne et l'écart-type des données observées sont $\bar{x}_{obs} = 495$ et $\tilde{s}_{obs} \simeq 9$ respectivement, ainsi

$$\frac{|\bar{x}_{obs} - 500|}{\tilde{s}_{obs}/3} = \frac{|495 - 500|}{9/3} = 1.6667 < 1.8331.$$

Donc on accepte l'hypothèse H_0 disant que le poids des paquets de café est de 500 grammes.

Traitons maintenant le test de la variance

$$\begin{cases} H_0 : \sigma^2 = 25 \\ H_1 : \sigma^2 > 25 \end{cases},$$

avec la moyenne μ inconnue. Nous avons aussi annoncé au cours la région critique de ce test est donnée par

$$W = \left\{ (x_1, \dots, x_{10}) \in \mathbb{R}_+^{10} \mid \frac{10v^2}{25} \geq k \right\},$$

où $v^2 = \tilde{s}^2 = \frac{1}{10} \sum_{i=1}^{10} (x_i - \bar{x})^2$, et k est la solution de l'équation $\mathbf{P}(\chi_9^2 \geq k) = 0.1$, où χ_9^2 désigne la variable de Chi-deux (ou de Pearson) à 9 degrés de liberté. De la table statistique on obtient $k = 14.683$, ainsi

$$\begin{aligned} W &= \left\{ (x_1, \dots, x_{10}) \in \mathbb{R}_+^{10} \mid \frac{10v^2}{25} \geq 14.683 \right\} \\ &= \left\{ (x_1, \dots, x_{10}) \in \mathbb{R}_+^{10} \mid v^2 \geq 36.709 \right\}. \end{aligned}$$

La fonction statistique test correspondante est

$$\delta(x_1, \dots, x_{10}) = \begin{cases} 1 & \text{si } v^2 \geq 36.709 \\ 0 & \text{si } v^2 < 36.709 \end{cases}.$$

Comme $v_{obs}^2 = \tilde{s}_{obs}^2 \simeq 9^2 = 81 > 36.709$, alors on rejette H_0 ; c'est à dire $\sigma^2 > 25$.

Solution de l'exercice 3 de la Série N°3

Exercice 3. Le coiffeur du village affirme **qu'au moins 90%** de ses clients sont satisfaits de ses services. Les gens du village croient **qu'il exagère**. Alors ils décident de faire un test au niveau de signification 0.05. Sur 150 clients, 132 se disent satisfaits. Conclure.

Solution. On note $X = 1$ (resp. $X = 0$) pour un client satisfait (resp. non satisfait) du service du client. Il donc s'agit d'une v.a. de Bernoulli de paramètre p :

$$\mathbf{P}(X = 1) = p \text{ et } \mathbf{P}(X = 0) = 1 - p.$$

Ceci peut être aussi réécrit sous la forme suivante

$$\mathbf{P}(X = x) = p^x (1 - p)^{1-x}, \quad x = 0, 1.$$

Les gens du village veulent alors tester

$$\begin{cases} H_0 : & p \geq p_0 = 90\% \\ H_1 & p < 90\% \end{cases}$$

au niveau de signification 0.05, à partir d'un échantillon de taille $n = 150$. Pour cela nous allons utiliser le principe du rapport des vraisemblances monotone: pour $0 < p_1, p_2 < 1$, telles que $p_1 > p_2$, on écrit

$$\frac{L_1}{L_2} = \frac{\prod_{i=1}^n p_1^{x_i} (1 - p_1)^{1-x_i}}{\prod_{i=1}^n p_2^{x_i} (1 - p_2)^{1-x_i}} = \frac{p_1^t (1 - p_1)^{n-t}}{p_2^t (1 - p_2)^{n-t}}, \quad t = \sum_{i=1}^n x_i.$$

En d'autres termes

$$\frac{L_1}{L_2} = \left(\frac{1 - p_1}{1 - p_2} \right)^n \left(\frac{p_1 (1 - p_2)}{p_2 (1 - p_1)} \right)^t.$$

Il est clair que $a := \frac{1-p_1}{1-p_2} > 0$, $b := \frac{p_1(1-p_2)}{p_2(1-p_1)} > 1$, donc la fonction $t \rightarrow a^n \times b^t$ est une fonction croissante en t . Donc la distribution de X , possède un rapport de vraisemblance croissant par rapport à t . est la statistique de test correspondante est $T_n = \sum_{i=1}^n X_i$. D'après le théorème central limite on a

$$Z = \frac{T_n - \mathbf{E}[T_n]}{\sqrt{\mathbf{Var}[T_n]}} \xrightarrow{\mathcal{D}} \mathcal{N}(0, 1), \text{ quand } n \rightarrow \infty.$$

Nous avons $\mathbf{E}[T_n] = n\mathbf{E}[X] = np$ et $\mathbf{Var}[T_n] = np(1 - p)$. En d'autres termes

$$T_n \rightsquigarrow \mathcal{N}(np, np(1 - p)), \text{ pour } n \text{ grand.}$$

Pour avoir une bonne approximation, on doit s'assurer que $n \geq 30$, $np \geq 5$ et $n(1 - p) \geq 5$. Nous avons $n = 150 > 30$, et pour $p = 0.9$, on a $150 \times 0.9 = 135 \geq 5$ et $150 \times (1 - 0.9) = 15 \geq 5$. Donc pour $p = 0.9$, on peut appliquer l'approximation gaussienne ci-dessus. Ainsi, notre région critique est

$$W = \left\{ (x_1, \dots, x_{150}) \in \{0, 1\}^{150} \mid T_n = \sum_{i=1}^{150} X_i \leq c \right\},$$

ou

$$\mathbf{P}_{p=0.9} \left(\sum_{i=1}^{150} X_i \leq c \right) = 0.05.$$

Ce qui équivalent à

$$\mathbf{P}_{p=0.9} \left(\frac{T_{150} - 150 \times 0.9}{\sqrt{150 \times 0.9 (1 - 0.9)}} \leq \frac{c - 150 \times 0.9}{\sqrt{150 \times 0.9 (1 - 0.9)}} \right) = \mathbf{P}(Z \leq k) = 0.05.$$

De la table statistique, nous avons $k = -1.644854$, ainsi

$$\frac{c - 150 \times 0.9}{\sqrt{150 \times 0.9(1 - 0.9)}} = -1.644854,$$

ce qui donne $c = 128.96$. Alors

$$W = \left\{ (x_1, \dots, x_{150}) \in \{0, 1\}^{150} \mid \sum_{i=1}^{150} X_i \leq 128.96 \right\}.$$

Nous avons $T_{obs} = 132 > 128.96$, donc on ne rejette pas l'hypothèse H_0 . En conclusion le coiffeur a raison d'affirmer qu'au moins 90% de ses clients sont satisfaits de ses services.

Solution de l'exercice 4 de la Série N°3

Exercice 4. L'étude de l'exercice 1 était faite en 1999. La même étude est faite en 2009, avec l'échantillon suivant:

4 5 7 7 5 7 5 6 5 6 7 8 5 7 8 7

En supposant des distributions Gaussiennes de même variance, comparer les temps de jeu moyens par jour pour les deux années, au niveau signification 5%. Etudier le problème en supposant que les variances pas nécessairement égales.

Solution. Il s'agit ici d' test de comparaison entre deux moyennes:

$$\begin{cases} H_0 : \mu_1 = \mu_2 \\ H_0 : \mu_1 \neq \mu_2 \end{cases}$$

Nous avons $\alpha = 0.05$, $n_1 = 15$, $n_2 = 16$, $\bar{x}_{1,obs} = 7.6$, $\bar{x}_{2,obs} = 6.18$, $\tilde{s}_{1,obs}^2 = 2.37$, $\tilde{s}_{2,obs}^2 = 1.40$. En supposant que les variances sont égales, la statistique de test est

$$\frac{\bar{X}_1 - \bar{X}_2}{\tilde{S}\sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \rightsquigarrow t(n_1 + n_2 - 2),$$

où

$$\tilde{S} = \sqrt{\frac{n_1\tilde{S}_1^2 + n_2\tilde{S}_2^2}{n_1 + n_2 - 2}},$$

et $t(n_1 + n_2 - 2)$ est la loi de Student à $n_1 + n_2 - 2$ degré de liberté. La région critique associée est

$$W = \left\{ \left(x_1^{(1)}, \dots, x_1^{(15)}; x_2^{(1)}, \dots, x_2^{(16)} \right) \in \mathbb{R}_+^{31} \mid \frac{|\bar{x}_1 - \bar{x}_2|}{\tilde{s}\sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \geq t_{1-\alpha/2} \right\},$$

où

$$\tilde{s} := \sqrt{\frac{n_1\tilde{s}_1^2 + n_2\tilde{s}_2^2}{n_1 + n_2 - 2}},$$

et $t_{1-\alpha/2}$ (la valeur critique) est le quantile d'ordre $1 - \alpha/2$ de $t(n_1 + n_2 - 2)$. En utilisons la table statistique de la loi de Student à $15 + 16 - 2 = 29$ degré de liberté on obtient $t_{1-0.05/2} = t_{0.975} = 2.04$. En outre nous avons

$$\tilde{s}_{obs} = \sqrt{\frac{15 \times 2.37 + 16 \times 1.40}{15 + 16 - 2}} = 1.41,$$

et

$$\frac{|\bar{x}_{1,obs} - \bar{x}_{2,obs}|}{\tilde{s}_{obs}\sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} = \frac{|7.6 - 6.18|}{1.4\sqrt{\frac{1}{15} + \frac{1}{16}}} = 2.82.$$

Comme $2.82 > 2.04$, alors on rejette l'hypothèse de l'égalité des moyennes de deux populations.

Supposons maintenant que les variances pas nécessairement égales, ce qui est une hypothèse réaliste. Dans ce cas on utilise **la statistique de Welch**:

$$\frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\tilde{S}_1^2/n_1 + \tilde{S}_2^2/n_2}} \simeq t(\nu),$$

où $t(\nu)$ est une v.a de Student à ν degré de liberté définit par

$$\nu := \frac{(\tilde{s}_1^2/n_1 + \tilde{s}_2^2/n_2)^2}{\tilde{s}_1^4/(n_1^2(n_1 - 1)) + \tilde{s}_2^4/(n_2^2(n_2 - 1))}.$$

Pour notre cas:

$$\nu = \frac{(2.37/15 + 1.40/16)^2}{(2.37)^2 / ((15)^2 (15 - 1)) + (1.40)^2 / ((16)^2 (16 - 1))} = 26.27.$$

Le degré de liberté est un nombre naturel non nulle, donc on doit effectuer une interpolation linéaire afin de calculer la valeur critique associée $t_{0.975}(\nu)$. En utilisant les deux quantiles les plus proches, $t_{0.975}(26)$ et $t_{0.975}(27)$, on obtient

$$\begin{aligned} t_{0.975}(26.27) &\simeq t_{0.975}(\lfloor 26.27 \rfloor) + (26.27 - \lfloor 26.27 \rfloor) \frac{t_{0.975}(\lceil 26.27 \rceil) - t_{0.975}(\lfloor 26.27 \rfloor)}{\lceil 26.27 \rceil - \lfloor 26.27 \rfloor}, \\ &= t_{0.975}(26) + (26.27 - 26) \frac{t_{0.975}(27) - t_{1-\alpha/2}(26)}{27 - 26} \\ &= 2.056 + 0.27(2.052 - 2.056) \\ &\simeq 2.054. \end{aligned}$$

La région critique associée est donc

$$W = \left\{ \left(x_1^{(1)}, \dots, x_1^{(15)}; x_2^{(1)}, \dots, x_2^{(16)} \right) \in \mathbb{R}_+^{31} \mid \frac{|\bar{x}_1 - \bar{x}_2|}{\sqrt{\hat{s}_1^2/n_1 + \hat{s}_2^2/n_2}} \geq 2.054 \right\}.$$

La valeur observée (en valeur absolue) de la statistique du test est

$$\left| \frac{\bar{x}_{1,obs} - \bar{x}_{2,obs}}{\sqrt{\hat{s}_{1,obs}^2/n_1 + \hat{s}_{2,obs}^2/n_2}} \right| = \left| \frac{7.6 - 6.18}{\sqrt{2.37/15 + 1.4/16}} \right| = 2.86.$$

Nous avons $2.86 > 2.054$, encore une fois on rejette H_0 . Passons maintenant au raisonnement par le biais de la p-value:

$$\begin{aligned} p - value &= \mathbf{P}(|T_{26.27}| \geq 2.948) = 2\mathbf{P}(T_{26.27} \geq 2.86) \\ &= 2(1 - \mathbf{P}(T_{26.27} \leq 2.86)). \end{aligned}$$

On pose $\mathbf{p}_\nu := \mathbf{P}(T_\nu \leq 2.86)$. En utilisant l'interpolation linéaire, on écrit:

$$\mathbf{p}_{26.27} \simeq 0.27(\mathbf{p}_{27} - \mathbf{p}_{26}) + \mathbf{p}_{26}$$

:En utilisant le logiciel R, on trouve $\mathbf{p}_{27} = 0.9959$ et $\mathbf{p}_{26} = 0.9958$, ainsi

$$\mathbf{p}_{26.27} \simeq 0.27(0.9959 - 0.9958) + 0.9958 = 0.9958$$

Finalement

$$\begin{aligned} p - value &= 2(1 - \mathbf{p}_{26.27}) \\ &= 2(1 - 0.9958) = 0.0084 < 0.05. \end{aligned}$$

Encore une fois on rejette H_0 .

Remarque: Le tableau statistique de loi de Student (comme d'autres lois de probabilités) offre uniquement les quantiles, tandis que les valeurs de probabilités on les calcule numériquement à l'aide des langages Softwar, à savoir le R ou le Matlab. En utilisant un de ces deux derniers on obtient $\mathbf{p}_{27} = 0.9959$ et $\mathbf{p}_{26} = 0.9958$. Bien sur en examen on vous donne quelques valeurs de probabilités et l'étudiant choisi celle qui convient au problème.

Solution de l'exercice 5 de la Série N°3

Exercice 5. On veut tester l'égalité des variances de deux populations $X_1 \sim \mathcal{N}(\mu_1, \sigma_1^2)$ et $X_2 \sim \mathcal{N}(\mu_2, \sigma_2^2)$ au niveau de signification $\alpha = 0.05$. Un échantillon de taille 16 de X_1 donne une variance empirique $\tilde{s}_{1,obs}^2 = 7.62$ et un échantillon de taille 12 de X_2 donne une variance empirique $\tilde{s}_{2,obs}^2 = 3.96$. Conclure.

Solution. Il s'agit ici d'un test (bilatéral) de comparaison entre deux variances:

$$\begin{cases} H_0 : \sigma_1^2 = \sigma_2^2 \\ H_0 : \sigma_1^2 \neq \sigma_2^2 \end{cases}$$

Nous avons $\alpha = 0.05$, $n_1 = 16$, $n_2 = 12$, $\tilde{s}_{1,obs}^2 = 7.62$, $\tilde{s}_{2,obs}^2 = 3.96$. La statistique de test (variable de décision) à utiliser est:

$$\frac{\frac{16\tilde{S}_1^2/\sigma_1^2}{15}}{\frac{12\tilde{S}_2^2/\sigma_2^2}{11}} \rightsquigarrow F(15, 11), \quad (\text{sous } H_0 : \sigma_1^2 = \sigma_2^2), \quad (1)$$

où $F(15, 11)$ désigne la loi de Fisher à (15, 11) degrés de liberté. A un seuil de signification $\alpha = 5\%$, la région critique associée est

$$W = \left\{ \left(x_1^{(1)}, \dots, x_1^{(16)}; x_2^{(1)}, \dots, x_2^{(12)} \right) \in \mathbb{R}^{28} \mid \frac{\tilde{s}_1^2}{\tilde{s}_2^2} \geq \frac{12 \times 15}{16 \times 11} c_1 \text{ ou } \frac{\tilde{s}_1^2}{\tilde{s}_2^2} \leq \frac{12 \times 15}{16 \times 11} c_2 \right\},$$

où c_1 et c_2 sont deux constantes telles que

$$\mathbf{P}(F(15, 11) \geq c_1) = \mathbf{P}(F(15, 11) \leq c_2) = \alpha/2 = 0.025.$$

Donc c_1 est le quantile d'ordre $1 - 0.025 = 0.975$ et c_2 est le quantile d'ordre 0.025 de la loi Fisher à (15, 11) degrés de liberté. De la table statistique de Fisher on obtient $c_1 = 3.40$. Pour trouver la valeur de c_2 , on utilise la formule suivante:

$$F(\nu_1, \nu_2) \rightsquigarrow \frac{1}{F(\nu_2, \nu_1)}.$$

Donc

$$\mathbf{P}(F(15, 11) \leq c_2) = 0.025 \iff \mathbf{P}(F(11, 15) \geq 1/c_2) = 0.025.$$

De la table statistique on obtient $1/c_2$ qui donne $c_2 = 0.33$. La région critique est donc

$$W = \left\{ \left(x_1^{(1)}, \dots, x_1^{(16)}; x_2^{(1)}, \dots, x_2^{(12)} \right) \in \mathbb{R}^{28} \mid \frac{\tilde{s}_1^2}{\tilde{s}_2^2} \geq 3.40 \text{ ou } \frac{\tilde{s}_1^2}{\tilde{s}_2^2} \leq 0.33 \right\},$$

Nous avons

$$\frac{\tilde{s}_{1,obs}^2}{\tilde{s}_{2,obs}^2} = \frac{7.62}{3.96} = 1.92.$$

Cette valeur est ni ≥ 3.40 ni ≤ 0.33 , donc on accepte l'égalité des deux variances. La p-value dans notre cas est égale à

$$\begin{aligned} p - value &= 2 \min \left\{ \mathbf{P} \left(\frac{\tilde{S}_1^2}{\tilde{S}_2^2} \geq 1.92 \right), \mathbf{P} \left(\frac{\tilde{S}_1^2}{\tilde{S}_2^2} \leq 1.92 \right) \right\} \\ &= 2 \min \left\{ \mathbf{P} \left(\frac{\frac{16\tilde{S}_1^2/\sigma_1^2}{15}}{\frac{12\tilde{S}_2^2/\sigma_2^2}{11}} \geq \frac{16/\sigma_1^2}{12/\sigma_2^2} 1.92 \right), \mathbf{P} \left(\frac{\frac{16\tilde{S}_1^2/\sigma_1^2}{15}}{\frac{12\tilde{S}_2^2/\sigma_2^2}{11}} \leq \frac{16/\sigma_1^2}{12/\sigma_2^2} 1.92 \right) \right\} \\ &= 2 \min \left\{ \mathbf{P} \left(F(15, 11) \geq \frac{16}{12} 1.92 \right), \mathbf{P} \left(F(15, 11) \leq \frac{16}{12} 1.92 \right) \right\}, \end{aligned}$$

car sous H_0 on a $\sigma_1^2 = \sigma_2^2$. Donc

$$p - value = 2 \min \{ \mathbf{P}(F(15, 11) \geq 1.87), \mathbf{P}(F(15, 11) \leq 1.87) \}.$$

En utilisant le langage R on obtient $\mathbf{P}(F(15, 11) \leq 1.87) = 0.85$, ainsi

$$p - value = 2 \min \{ 1 - 0.85, 0.85 \} = 0.3 > 0.05,$$

donc, effet l'égalité des deux variances est encore une fois confirmée.

Solution de l'exercice 6 de la Série N°3

Exercice 6. Selon un institut de sondage A, 510 sur 980 personnes interrogées sont favorables à une certaine mesure gouvernementale. Un autre institut de sondage B donne 505 personnes favorables (à la même mesure) sur 1030. Tester, au niveau de signification 5%, l'égalité des proportions de gens favorables proposées par les deux instituts.

Solution. Il s'agit ici d' test de comparaison entre deux proportions:

$$\begin{cases} H_0 : p_1 = p_2 \\ H_1 : p_1 \neq p_2 \end{cases}$$

Nous avons $\alpha = 0.05$, $n_1 = 980$, $n_2 = 1030$, $p_{1,obs} = 510/980$, $p_{2,obs} = 505/1030$. Sous l'hypothèse " $p_1 = p_2$ ", la statistique de test est

$$\frac{\hat{p}_1 - \hat{p}_2}{\sqrt{\hat{p}(1-\hat{p})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \rightsquigarrow \mathcal{N}(0,1),$$

où

$$\hat{p} := \frac{n_1\hat{p}_1 + n_2\hat{p}_2}{n_1 + n_2},$$

et l'estimateur commun de p_1 et p_2 , à condition que

$$n_1 + n_2 > 30, n_i p_i \geq 5 \text{ et } n_i(1 - p_i) \geq 5, \text{ pour } i = 1, 2.$$

Pour notre problème nous avons:

$$n_1 + n_2 = 2010 > 30; n_1 p_1 = 510 > 5; n_2 p_2 = 505 > 5.$$

La région critique associée est :

$$W = \left\{ \left(x_1^{(1)}, \dots, x_1^{(980)}; x_2^{(1)}, \dots, x_2^{(1030)} \right) \in \mathbb{R}_+^{2010} \mid \frac{|\hat{p}_1 - \hat{p}_2|}{\sqrt{\hat{p}(1-\hat{p})\left(\frac{1}{980} + \frac{1}{1030}\right)}} \geq z_{1-0.05/2} \right\},$$

où $z_{1-0.05/2}$ (la valeur critique) est le quantile d'ordre $1 - \alpha/2$ de $\mathcal{N}(0,1)$. De la table statistique de la loi normale centré réduite on obtient $z_{1-0.05/2} = z_{0.975} \simeq 1,88$, ainsi

$$W = \left\{ \left(x_1^{(1)}, \dots, x_1^{(980)}; x_2^{(1)}, \dots, x_2^{(1030)} \right) \in \mathbb{R}_+^{2010} \mid \frac{|\hat{p}_1 - \hat{p}_2|}{\sqrt{\hat{p}(1-\hat{p})\left(\frac{1}{980} + \frac{1}{1030}\right)}} \geq 1.88 \right\}$$

La valeur observée de \hat{p} donne:

$$p_{obs} = \frac{n_1 p_{1,obs} + n_2 p_{2,obs}}{n_1 + n_2} = \frac{510 + 505}{980 + 1030} = 0.50498.$$

Ainsi la valeur observée de la statistique de test est

$$\begin{aligned} & \frac{|p_{1,obs} - p_{2,obs}|}{\sqrt{p_{obs}(1-p_{obs})\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \\ &= \frac{|510/980 - 505/1030|}{\sqrt{0.50498(1-0.50498)\left(\frac{1}{980} + \frac{1}{1030}\right)}} \simeq 1.35. \end{aligned}$$

Comme $1.35 < 1.88$, alors on accepte l'hypothèse d'égalité de deux proportions.