

Fiche 3 Intervalles de confiance

Exercice 1 :

On s'intéresse à la taille du lobe frontal des crabes (*Leptograpsus variegatus*). On prend 200 valeurs de la variable la taille du lobe frontal "FL" du fichier "crabs" de la librairie "MASS" comme population. On note μ et σ^2 la moyenne théorique et la variance théorique de la variable FL. Après une étude statistique préalable (test de la normalité), on suppose raisonnablement que la population admet une loi normale $\mathcal{N}(\mu, \sigma^2)$ avec les deux paramètres inconnus.

a) `install.packages("MASS"); library(MASS)`

b) Sauvegarder ces 200 valeurs de "FL" du fichier "crabs" (sans "e") dans une variable nommée **Population**.

c) Générer une réalisation de l'échantillon $(X_1 \dots X_n)$ avec $n=28$, puis construire l'intervalle de confiance de μ de niveau de confiance $1-\alpha = 95\%$. Contient-il la valeur de $\mu = \text{mean}(\text{Population})$?

d) Générer 100 réalisations de l'échantillon $(X_1 \dots X_n)$ avec $n=28$, puis construire 100 réalisations de l'intervalle de confiance de μ de niveau de confiance $1-\alpha = 95\%$. Quel est le pourcentage des réalisations qui ne contiennent pas le paramètre $\mu = 15.583$?

e) Générer une réalisation de l'échantillon $(X_1 \dots X_n)$ avec $n=15$, puis construire l'intervalle de confiance de σ^2 de niveau de confiance $1-\alpha = 90\%$. Contient-il la valeur de $\sigma^2 = \text{var}(\text{Population})$?

f) Générer 100 réalisations de l'échantillon $(X_1 \dots X_n)$ avec $n=15$, puis construire l'intervalle de confiance de σ^2 de niveau de confiance $1-\alpha = 90\%$. Quel est le pourcentage des réalisations qui ne contiennent pas le paramètre $\sigma^2 = 12.2173$?

g) Comparer les résultats avec ceux des autres étudiants.

Exercice 1' pour les économistes :

On s'intéresse aux rendements journaliers de bourse de l'indice Standard and Poors 500 de 1990 à 1999. On prend 2780 valeurs du fichier "SP500" de la librairie "MASS" comme population. On note μ et σ^2 la moyenne théorique et la variance théorique du rendement. Après une étude statistique préalable (test de la normalité), on suppose raisonnablement que la population admet une loi normale $\mathcal{N}(\mu, \sigma^2)$ avec les deux paramètres inconnus.

a) `install.packages("MASS"); library(MASS)`

b) Sauvegarder ces $N = 2780$ valeurs du rendement du fichier "SP500" dans une variable nommée **Population**.

c) Générer une réalisation de l'échantillon $(X_1 \dots X_n)$ avec $n=28$, puis construire l'intervalle de confiance de μ de niveau de confiance $1-\alpha = 95\%$. Contient-il la valeur de $\mu = \text{mean}(\text{Population})$?

d) Générer 100 réalisations de l'échantillon $(X_1 \dots X_n)$ avec $n=28$, puis construire 100 réalisations de l'intervalle de confiance de μ de niveau de confiance $1-\alpha = 95\%$. Quel est le pourcentage des réalisations qui ne contiennent pas le paramètre $\mu = 0.04575267$?

e) Générer une réalisation de l'échantillon $(X_1 \dots X_n)$ avec $n=15$, puis construire l'intervalle de confiance de σ^2 de niveau de confiance $1-\alpha = 90\%$. Contient-il la valeur de $\sigma^2 = \text{var}(\text{Population})$?

f) Générer 100 réalisations de l'échantillon $(X_1 \dots X_n)$ avec $n=15$, puis construire l'intervalle de confiance de σ^2 de niveau de confiance $1-\alpha = 90\%$. Quel est le pourcentage des réalisations qui ne contiennent pas le paramètre $\sigma^2 = 0.8982233$?

g) Comparer les résultats avec ceux des autres étudiants.

Exercice 2 :

On simule $M = 100$ réalisations d'un échantillon (X_1, \dots, X_{20}) ($n=20$) de la loi $\mathcal{N}(-10, 1.5^2)$. On n'est pas censé de connaître les deux paramètres $\mu = -10$ et $\sigma^2 = 1.5^2$. On sauvegarde 100 réalisations de la statistique \bar{X} ainsi que celles de S_c^2 .

a) Déterminer 100 réalisations de l'intervalle de confiance de μ au niveau de confiance de **90%**, basée sur ces 100 réalisations. Quel est le pourcentage des réalisations qui ne contiennent pas le paramètre $\mu = -10$? Commenter vos résultats.

b) Comment utiliser R pour représenter ces 100 réalisations de l'intervalle de confiance sur un même graphe ?

c) Déterminer 100 réalisations de l'intervalle de confiance de σ^2 au niveau de confiance de 95%, basée sur ces 100 réalisations. Quel est le pourcentage des réalisations qui ne contiennent pas le paramètre $\sigma^2 = 1.5^2$?

d) Ayant un niveau de confiance 95% ($\alpha = 0.05$), les deux quantiles suivants

$$\mathbb{P}\left(\frac{(n-1)S_c^2}{\sigma^2} < C_1\right) = \mathbb{P}\left(\frac{(n-1)S_c^2}{\sigma^2} > C_2\right) = \frac{\alpha}{2}.$$

fournissent un choix simple à calculer, et proche du choix optimal. Quelles sont les longueurs des réalisations des IC en c) ?

e) Pour le même niveau de confiance 95%, on définit dans cette question

$$\begin{aligned} \mathbb{P}\left(\frac{(n-1)S_c^2}{\sigma^2} < C_1\right) &= 0.0445 \\ \mathbb{P}\left(\frac{(n-1)S_c^2}{\sigma^2} > C_2\right) &= 0.00539. \end{aligned}$$

On sait qu'ils sont biaisés. Montrer qu'ils ont systématiquement des longueurs plus courtes.

Exercice 3 : Intervalle de confiance pour π (la proportion de largeur d'anneaux $\leq 0,89$)

On s'intéresse à la largeur des anneaux de croissance des arbres. On prend le fichier "treering" avec 7980 comme étant le cardinal de la population. On note π la proportion de largeurs qui sont inférieures ou égales à 0,89 (unité) et on souhaite construire un intervalle de confiance de π de niveau de confiance de 95%.

a) Convertir ensuite les valeurs des "treering" en 1 ou 0 selon que les valeurs des largeurs $\leq 0,89$ (unité) ou non. Sauvegarder ces 7980 valeurs converties dans un vecteur nommé **Population**.

b) Générer une réalisation de l'échantillon (X_1, \dots, X_n) de taille $n = 65$.

c) Appliquer Théorème Central Limite pour construire un intervalle de confiance de niveau 95% du paramètre π . Contient-il le paramètre π ?

```
install.packages("BioStatR"); library(BioStatR)
```

d) Comparer avec le résultat par la méthode exacte :

```
binom.ci(k,n=n1, conf.level=0.95,method="exact")
```

e) Comparer avec le résultat par la méthode de Wilson :

```
binom.ci(k,n=n1, conf.level=0.95,method="Wilson")
```

f) Comparer avec le résultat par la méthode de Wald :

```
binom.ci(k,n=n1, conf.level=0.95,method="wald")
```

g) Mêmes questions avec $M = 100$ réalisations.

Exercice 4 :

On simule $M = 100$ réalisations d'un échantillon (X_1, \dots, X_{15}) ($n=15$) de la loi de Bernoulli $\mathcal{B}(1, 0.3)$. On n'est pas censé de connaître le paramètre $p = 0.3$. On sauvegarde 100 réalisations de la statistique \bar{X} .

a) Déterminer, par la méthode exacte, 100 réalisation de l'intervalle de confiance de p au niveau de confiance de 95%, basée sur ces 100 réalisations. Quel est le pourcentage des réalisations qui ne contiennent pas le paramètre $p = 0.3$? Commenter vos résultats.

b) Comment utiliser R pour représenter ces 100 réalisations de l'intervalle de confiance sur un même graphe ?

c) Déterminer, par la méthode de Wilson, 100 réalisation de l'intervalle de confiance de p au niveau de confiance de 95%, basée sur ces 100 réalisations. Quel est le pourcentage des réalisations qui ne contiennent pas le paramètre p ?

d) Comment utiliser R pour représenter ces 100 réalisations de l'intervalle de confiance sur un même graphe ?

e) Peut-on utiliser la méthode de Wald ? Pourquoi ?