

Exercices : Estimations

Exercice 1:

Soit X de loi $\mathcal{U}([0; a])$ et (X_1, \dots, X_n) un n -échantillon de X . On cherche à estimer a . On note \overline{X}_n la moyenne empirique de X .

1. Soit $T_n = 2\overline{X}_n$. Montrer que T_n est un estimateur sans biais de a et calculer son risque quadratique.
2. Soit $T'_n = \max(X_1, \dots, X_n)$.
Donner la fonction de répartition de X , puis déterminer celle de T'_n .
En déduire une densité de T'_n puis son biais et son risque quadratique.
3. Soit $T''_n = \frac{n+1}{n}T'_n$. Déterminer son biais et son risque quadratique.
4. Pour de grandes valeurs de n , quelle est le meilleur estimateur de a ?

Exercice 2:

Soit X ayant une espérance m et une variance v , et soit (X_1, \dots, X_n) un n -échantillon de X . On appelle variance empirique de X la variable $W_n = \frac{1}{n} \sum_{i=1}^n X_i^2 - \overline{X}_n^2$, où \overline{X}_n est la moyenne empirique de X .

1. Soit Y ayant une espérance et une variance. Exprimer $E(Y^2)$ en fonction de $V(Y)$ et $E(Y)$.
2. Calculer $E(\overline{X}_n)$ et $V(\overline{X}_n)$ et en déduire $E(\overline{X}_n^2)$.
3. Calculer alors $E(W_n)$ et en déduire un estimateur sans biais de v .

Exercice 3:

Un sériciculteur a pesé 100 cocons provenant de son élevage de vers à soie. Il a obtenu les résultats suivants :

Poids en g	0,64	0,65	0,66	0,67	0,68	0,69	0,70	0,71
Effectif	3	5	2	6	6	10	12	10

Poids en g	0,72	0,73	0,74	0,75	0,76	0,77	0,78	0,79
Effectif	9	8	8	6	5	4	3	3

On appelle m la moyenne des poids de tous les cocons de l'élevage et on suppose que le poids X d'un cocon suit une loi normale de variance $0,0016g^2$.

1. Préciser les paramètres de cette loi normale.
2. On choisit au hasard un échantillon de 100 cocons. On appelle X_i le poids du i -ème cocon de cet échantillon. On suppose que X_1, \dots, X_{100} sont mutuellement indépendantes, de même loi que X . On pose $T = \frac{1}{100} \sum_{i=1}^{100} X_i$ et on admet que T suit une loi normale.

Préciser les paramètres de cette loi normale et déterminer la variable centrée réduite T^* associée à T .

3. Déterminer un réel t tel que $P(-t \leq T^* \leq t) \geq 0,95$.
4. Montrer que $P(T - 0,00784 \leq m \leq T + 0,00784) \geq 0,95$.
5. En déduire un intervalle de confiance pour m au niveau de confiance 0,95 et donner une estimation de cet intervalle.

Exercice 4:

Lors d'un sondage sur 100 personnes interrogées, 60 pensent voter pour A.

On modélise le choix par un échantillon (X_1, \dots, X_{100}) de variables indépendantes de même loi de Bernoulli de paramètre p .

On cherche à déterminer un intervalle de confiance pour p au niveau de confiance 99 %.

1. Déterminer l'espérance et la variance de la moyenne empirique $F = \frac{1}{100} \sum_{i=1}^{100} X_i$.

2. On note F^* la variable centrée réduite associée à F .

Par quelle loi peut-on approcher celle de F^* ? On suppose désormais que F^* suit la loi $\mathcal{N}(0, 1)$.

3. Déterminer t tel que $P(-t \leq F^* \leq t) \geq 0,99$ et en déduire que

$$P\left(F - t \frac{\sqrt{p(1-p)}}{10} \leq p \leq F + t \frac{\sqrt{p(1-p)}}{10}\right) \geq 0,99$$

4. Montrer que pour tout $p \in [0; 1]$, $p(1-p) \leq \frac{1}{4}$ et en déduire un intervalle de confiance pour p au niveau de confiance 0,99 puis en donner une estimation.

Correction

Exercice 1:

1. T_n s'exprime en fonction des X_i donc c'est un estimateur de a . On cherche le biais de T_n donc il nous faut calculer son espérance.

$$E(T_n) = E(2\overline{X_n}) = 2 \times \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{2}{n} \sum_{i=1}^n \frac{a}{2} = a$$

On a donc $b(T_n) = E(T_n) - a = 0$ et ainsi T_n est un estimateur sans biais de a .

Comme T_n est un estimateur sans biais de a , son risque quadratique est égal à sa variance. Or comme les X_i sont indépendantes on a :

$$V(T_n) = V\left(\frac{2}{n} \sum_{i=1}^n X_i\right) = \frac{4}{n^2} \sum_{i=1}^n V(X_i) = \frac{4}{n^2} \sum_{i=1}^n \frac{a^2}{12} = \frac{a^2}{3n}$$

2. • D'après le cours la fonction de répartition de X est définie par $F(x) = \begin{cases} 0 & \text{si } x < 0 \\ \frac{x}{a} & \text{si } 0 \leq x \leq a \\ 1 & \text{si } x > a \end{cases}$.
- Notons G_n la fonction de répartition de T'_n . Par définition $G_n(x) = P(T'_n \leq x)$. Or $[T_n \leq x] = [X_1 \leq x] \cap \dots \cap [X_n \leq x]$. Donc comme les X_i sont indépendantes :

$$G_n(x) = P(X_1 \leq x) \times \dots \times P(X_n \leq x) = (F(x))^n$$

On a donc $G_n(x) = \begin{cases} 0 & \text{si } x < 0 \\ \left(\frac{x}{a}\right)^n & \text{si } 0 \leq x \leq a \\ 1 & \text{si } x > a \end{cases}$.

- Une densité de T'_n s'obtient en dérivant G_n là où elle est dérivable et en complétant les points manquants :

$$g_n(t) = \begin{cases} 0 & \text{si } t < 0 \text{ ou } t > a \\ \frac{n}{a} \left(\frac{t}{a}\right)^{n-1} & \text{si } 0 \leq t \leq a \end{cases}$$

- Pour calculer le biais de T'_n il nous faut calculer son espérance. Comme la densité de T'_n est nulle en dehors de $[0; a]$ et que $t \rightarrow tg_n(t)$ est continue sur $[0; a]$, T'_n admet une espérance et :

$$E(T'_n) = \int_0^a t \times \frac{n}{a} \left(\frac{t}{a}\right)^{n-1} dt = \frac{n}{a^n} \int_0^a t^n dt = \frac{n}{a^n} \left[\frac{t^{n+1}}{n+1}\right]_0^a = \frac{na}{n+1}$$

Donc $b(T'_n) = \frac{na}{n+1} - a = \frac{-a}{n+1}$

- Pour les mêmes raisons que pour l'espérance, T'_n admet une variance et :

$$\begin{aligned} V(T'_n) &= \int_0^a t^2 \times \frac{n}{a} \left(\frac{t}{a}\right)^{n-1} dt - E(T'_n)^2 = \frac{n}{a^n} \int_0^a t^{n+1} dt - \frac{n^2 a^2}{(n+1)^2} \\ &= \frac{n}{a^n} \left[\frac{t^{n+2}}{n+2}\right]_0^a - \frac{n^2 a^2}{(n+1)^2} = \frac{na^2}{n+2} - \frac{n^2 a^2}{(n+1)^2} \\ &= \frac{n}{(n+2)(n+1)^2} a^2 \end{aligned}$$

On a donc :

$$\begin{aligned} r(T'_n) &= V(T'_n) + b(T'_n)^2 = \frac{n}{(n+2)(n+1)^2}a^2 + \frac{a^2}{(n+1)^2} \\ &= \frac{(2n+2)a^2}{(n+2)(n+1)^2} = \frac{2a^2}{(n+2)(n+1)} \end{aligned}$$

3. On a vu que $E(T'_n) = \frac{na}{n+1}$ donc $E(T''_n) = a$ et ainsi T''_n est un estimateur sans biais de a .

De plus comme $V(T'_n) = \frac{n}{(n+2)(n+1)^2}a^2$ on a $V(T''_n) = \frac{a^2}{n(n+2)}$ et donc $r(T''_n) = \frac{a^2}{n(n+2)}$.

4. T_n et T''_n sont meilleurs que T'_n car ils sont des estimateurs sans biais. De plus lorsque n tend vers $+\infty$ on a :

$$r(T_n) \underset{n \rightarrow +\infty}{\sim} \frac{a^2}{3} \times \frac{1}{n} \quad \text{et} \quad r(T''_n) \underset{n \rightarrow +\infty}{\sim} a^2 \times \frac{1}{n^2}$$

Donc le meilleur estimateur est T''_n .

Exercice 2:

- On sait que $V(Y) = E(Y^2) - E(Y)^2$ donc on a $E(Y^2) = V(Y) + E(Y)^2$.
- On a :

$$E(\overline{X}_n) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \sum_{i=1}^n m = m$$

et comme les variables X_i sont indépendantes :

$$V(\overline{X}_n) = V\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n V(X_i) = \frac{1}{n^2} \sum_{i=1}^n v = \frac{v}{n}$$

Grâce à la question précédente on a donc $E(\overline{X}_n^2) = \frac{v}{n} + m^2$.

3. On a donc :

$$\begin{aligned} E(W_n) &= E\left(\frac{1}{n} \sum_{i=1}^n X_i^2 - \overline{X}_n^2\right) = \frac{1}{n} \sum_{i=1}^n E(X_i^2) - E(\overline{X}_n^2) \\ &= \frac{1}{n} \sum_{i=1}^n (v + m^2) - \left(\frac{v}{n} + m^2\right) \\ &= v + m^2 - \frac{v}{n} - m^2 = \frac{n-1}{n}v \end{aligned}$$

Si on pose $W'_n = \frac{n}{n-1}W_n$ alors on a bien que W'_n est un estimateur de v et de plus $E(W'_n) = \frac{n-1}{n}E(W_n) = v$ donc c'est bien un estimateur sans biais.

Exercice 3:

- Les paramètres d'une loi normale sont son espérance et sa variance. $X \hookrightarrow \mathcal{N}(m; 0,0016)$
- $E(T) = m$ et $V(T) = \frac{0,0016}{100}$ donc $T \hookrightarrow \mathcal{N}\left(m; \frac{0,0016}{100}\right)$.

On a par définition :

$$T^* = \frac{T - E(T)}{\sqrt{V(T)}} = \frac{T - m}{\sqrt{0,0016/100}} = \frac{T - m}{0,004}$$

3. On sait donc que $T^* \hookrightarrow \mathcal{N}(0, 1)$. Donc $P(-t \leq T^* \leq t) = \Phi(t) - \Phi(-t) = 2\Phi(t) - 1$.
On a donc

$$P(-t \leq T^* \leq t) \geq 0,95 \Leftrightarrow 2\Phi(t) - 1 \geq 0,95 \Leftrightarrow \Phi(t) \geq 0,975 \Leftrightarrow t \geq 1,96$$

On peut donc choisir $t = 1,96$.

4. D'après la question précédente :

$$\begin{aligned} P(-1,96 \leq T^* \leq 1,96) &\geq 0,95 \Leftrightarrow P\left(-1,96 \leq \frac{T-m}{0,004} \leq 1,96\right) \geq 0,95 \\ &\Leftrightarrow P(-0,004 \times 1,96 \leq T-m \leq 0,004 \times 1,96) \geq 0,95 \\ &\Leftrightarrow P(T-0,00784 \leq m \leq T+0,00784) \geq 0,95 \end{aligned}$$

5. D'après la question précédente $[T-0,00784; T+0,00784]$ est un intervalle de confiance pour m au niveau de confiance 0,95.

Le tableau de valeurs nous permet de calculer une réalisation de T : 0,7132

Un intervalle de confiance réalisé est donc $[0,70536; 0,72104]$.

Exercice 4:

1. $E(F) = \frac{1}{100} \sum_{i=1}^{100} E(X_i) = p$ et, comme les X_i sont indépendantes,

$$V(F) = \frac{1}{10000} \sum_{i=1}^{100} V(X_i) = \frac{p(1-p)}{100}.$$

2. D'après le théorème de la limite centrée, comme $100 > 30$, que les X_i sont indépendantes, suivent toutes la même loi et ont une variance non nulle, F^* suit approximativement la loi normale centrée réduite.
3. • On a $P(-t \leq F^* \leq t) = \Phi(t) - \Phi(-t) = 2\Phi(t) - 1$ donc

$$P(-t \leq F^* \leq t) \geq 0,99 \Leftrightarrow 2\Phi(t) - 1 \geq 0,99 \Leftrightarrow \Phi(t) \geq 0,995 \Leftrightarrow t \geq 2,58$$

On choisit $t = 2,58$.

- De plus comme $F^* = \frac{F-p}{\sqrt{p(1-p)}/10}$, on a

$$P(-t \leq F^* \leq t) = P\left(F - t \frac{\sqrt{p(1-p)}}{10} \leq p \leq F + t \frac{\sqrt{p(1-p)}}{10}\right)$$

On a donc bien $P\left(F - t \frac{\sqrt{p(1-p)}}{10} \leq p \leq F + t \frac{\sqrt{p(1-p)}}{10}\right) \geq 0,99$

4. Il suffit ici d'étudier la fonction $f : x \rightarrow x(1-x)$ sur $[0; 1]$ et de remarquer qu'elle atteint son maximum en $x = \frac{1}{2}$ et que ce maximum vaut $\frac{1}{4}$.

On a donc $\left[F - t \frac{\sqrt{p(1-p)}}{10} \leq p \leq F + t \frac{\sqrt{p(1-p)}}{10}\right] \subset \left[F - t \frac{1}{20} \leq p \leq F + t \frac{1}{20}\right]$ donc :

$$P\left(F - t \frac{1}{20} \leq p \leq F + t \frac{1}{20}\right) \geq P\left(F - t \frac{\sqrt{p(1-p)}}{10} \leq p \leq F + t \frac{\sqrt{p(1-p)}}{10}\right) \geq 0,99$$

Donc $[F - 0,129 \leq p \leq F + 0,129]$ est un intervalle de confiance de p au niveau de confiance 0,99.

De plus une réalisation de F est d'après l'énoncé : 0,6 donc une estimation de cet intervalle est $[0,471; 0,729]$.