
Corrigé du partiel du 08 décembre 2008

Exercice 1

1) \bar{X}_n est bien un estimateur sans biais de μ , puisque

$$\mathbb{E}[\bar{X}_n] = \mathbb{E}\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}[X_i] = \frac{n}{n} \mathbb{E}[X_i] = \mathbb{E}[X_i] = \mu$$

2)

$$\begin{aligned} \mathbb{E}[T_n] &= \mathbb{E}\left[\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2\right] \\ &= \frac{1}{n} \mathbb{E}\left[\sum_{i=1}^n (X_i - \bar{X}_n)^2\right] \\ &= \frac{1}{n} \mathbb{E}\left[\sum_{i=1}^n (X_i^2 - 2X_i\bar{X}_n + \bar{X}_n^2)\right] \\ &= \frac{1}{n} \mathbb{E}\left[\sum_{i=1}^n X_i^2 - 2\sum_{i=1}^n X_i\bar{X}_n + \sum_{i=1}^n \bar{X}_n^2\right] \\ &= \frac{1}{n} \mathbb{E}\left[\sum_{i=1}^n X_i^2 - 2\bar{X}_n \sum_{i=1}^n X_i + n\bar{X}_n^2\right] \\ &= \frac{1}{n} \mathbb{E}\left[\sum_{i=1}^n X_i^2 - 2n\bar{X}_n^2 + n\bar{X}_n^2\right] \\ &= \frac{1}{n} \mathbb{E}\left[\sum_{i=1}^n X_i^2 - n\bar{X}_n^2\right] \\ &= \frac{1}{n} \left(\mathbb{E}\left[\sum_{i=1}^n X_i^2\right] - n\mathbb{E}[\bar{X}_n^2]\right) \\ &= \frac{1}{n} \left(\sum_{i=1}^n \mathbb{E}[X_i^2] - n\mathbb{E}[\bar{X}_n^2]\right) \end{aligned}$$

Or, $\mathbb{E}[X_i^2] = \text{var}(X_i) + \mathbb{E}[X_i]^2 = \sigma^2 + \mu^2$ et $\mathbb{E}[\bar{X}_n^2] = \text{var}(\bar{X}_n) + \mathbb{E}[\bar{X}_n]^2 = \frac{\sigma^2}{n} + \mu^2$. Alors

$$\begin{aligned}\mathbb{E}[T_n] &= \frac{1}{n} \left(n(\sigma^2 + \mu^2) - n\left(\frac{\sigma^2}{n} + \mu^2\right) \right) \\ &= \frac{1}{n} (n\sigma^2 - \sigma^2) \\ &= \frac{n-1}{n} \sigma^2\end{aligned}$$

3) A partir de la réponse à la question précédente, un estimateur sans biais de σ^2 est donc

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

Exercice 2

Soit un n-échantillon (X_1, \dots, X_n) de loi de densité

$$f_\theta(x) = \frac{x^2}{2\theta^3} \exp\left(-\frac{x}{\theta}\right) \mathbf{1}_{[0, +\infty[}(x)$$

avec $\theta > 0$

1) Par hypothèse, $\mathbb{E}(X) = 3\theta$. On peut alors dire que $\theta = \mathbb{E}(X)/3$ et comme un estimateur sans biais de l'espérance est la moyenne empirique (c'est-à-dire \bar{X}_n), alors on propose $\bar{X}_n/3$ comme estimateur sans biais de θ .

2) Fonction de vraisemblance :

$$L_\theta(x_1, \dots, x_n) = \prod_{i=1}^n f_\theta(x_i)$$

avec $f_\theta(x_i) = \frac{x_i^2}{2\theta^3} \exp\left(-\frac{x_i}{\theta}\right) \mathbf{1}_{[0, +\infty[}(x_i)$

$$\begin{aligned}L_\theta(x_1, \dots, x_n) &= \prod_{i=1}^n \left(\frac{x_i^2}{2\theta^3} \exp\left(-\frac{x_i}{\theta}\right) \mathbf{1}_{[0, +\infty[}(x_i) \right) \\ &= \frac{\prod_{i=1}^n x_i^2}{2^n \theta^{3n}} \times \exp\left(-\frac{\sum_{i=1}^n x_i}{\theta}\right) \times \mathbf{1}_{[0, +\infty[}(x_1) \times \dots \times \mathbf{1}_{[0, +\infty[}(x_n) \\ &= \frac{\prod_{i=1}^n x_i^2}{2^n \theta^{3n}} \times \exp\left(-\frac{\sum_{i=1}^n x_i}{\theta}\right) \times \mathbf{1}_{\{\min_{1 \leq i \leq n} x_i \geq 0\}}\end{aligned}$$

3) Estimateur du maximum de vraisemblance : sur le domaine $\mathcal{D} = \{\min_{1 \leq i \leq n} x_i \geq 0\}$,

$$\ln L_\theta(x_1, \dots, x_n) = -n \ln 2 - 3n \ln \theta + 2 \sum_{i=1}^n \ln x_i - \frac{\sum_{i=1}^n x_i}{\theta}$$

$$\frac{\partial \ln L_\theta(x_1, \dots, x_n)}{\partial \theta} = -\frac{3n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n x_i$$

$$\begin{aligned} \frac{\partial \ln L_\theta(x_1, \dots, x_n)}{\partial \theta} = 0 &\iff -\frac{3n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n x_i = 0 \\ &\iff \frac{1}{\theta^2} \left(-3n\theta + \sum_{i=1}^n x_i \right) = 0 \\ &\iff -3n\theta + \sum_{i=1}^n x_i = 0 \end{aligned}$$

Le point $t_n = \frac{1}{3n} \sum_{i=1}^n x_i$ est donc stationnaire, vérifions maintenant que c'est bien un maximum.

$$\frac{\partial^2 \ln L_\theta(x_1, \dots, x_n)}{\partial \theta^2} = \frac{3n}{\theta^2} - \frac{2}{\theta^3} \sum_{i=1}^n x_i \quad \text{qui prend comme valeur en } t_n :$$

$$\frac{3n}{t_n^2} - \frac{2}{t_n^3} \sum_{i=1}^n x_i = \frac{1}{t_n^2} \left(3n - \frac{2}{t_n} \sum_{i=1}^n x_i \right) = \frac{1}{t_n^2} \left(3n - \frac{2}{\frac{1}{3n} \sum_{i=1}^n x_i} \sum_{i=1}^n x_i \right) = \frac{1}{t_n^2} (3n - 2 \times 3n) = -\frac{3n}{t_n^2} < 0$$

Le point t_n est bien un maximum. L'estimateur du maximum de vraisemblance est donc

$$T_n = \frac{1}{3n} \sum_{i=1}^n X_i$$

L'estimateur T_n est-il sans biais ?

$$\mathbb{E}(T_n) = \frac{1}{3n} \sum_{i=1}^n \mathbb{E}(X_i) = \frac{n}{3n} \mathbb{E}(X_i) = \frac{\mathbb{E}(X_i)}{3} = \frac{3\theta}{3} = \theta$$

Par conséquent, T_n est bien un estimateur sans biais de θ .

L'estimateur T_n est-il convergent ?

$$\text{var}(T_n) = \frac{1}{9n^2} \sum_{i=1}^n \text{var}(X_i) = \frac{n}{9n^2} \text{var}(X_i) = \frac{\text{var}(X_i)}{9n} = \frac{3\theta^2}{9n} = \frac{\theta^2}{3n}$$

Donc $\lim_{n \rightarrow +\infty} \text{var}(T_n) = 0$. Par conséquent, puisque l'estimateur T_n est un estimateur sans biais de θ et que $\lim_{n \rightarrow +\infty} \text{var}(T_n) = 0$, alors l'estimateur T_n est un estimateur convergent de θ .

L'estimateur T_n est-il efficace ?

$$\begin{aligned}
 I_n(\theta) &= -\mathbb{E} \left[\frac{\partial^2 \ln L_\theta(X_1, \dots, X_n)}{\partial \theta^2} \right] \\
 &= -\mathbb{E} \left[\frac{3n}{\theta^2} - \frac{2}{\theta^3} \sum_{i=1}^n X_i \right] \\
 &= -\frac{3n}{\theta^2} + \frac{2}{\theta^3} \mathbb{E} \left[\sum_{i=1}^n X_i \right] \\
 &= -\frac{3n}{\theta^2} + \frac{2}{\theta^3} \sum_{i=1}^n \mathbb{E}[X_i] \\
 &= -\frac{3n}{\theta^2} + \frac{2n}{\theta^3} \mathbb{E}[X_i] \\
 &= -\frac{3n}{\theta^2} + \frac{6n\theta}{\theta^3} \\
 &= -\frac{3n}{\theta^2} + \frac{6n}{\theta^2} \\
 &= \frac{3n}{\theta^2} \\
 &= \frac{1}{\text{var}(T_n)}
 \end{aligned}$$

Par conséquent, l'estimateur T_n est efficace.

4) Les réponses aux questions précédentes nous permettent de déterminer l'espérance et la variance de T_n : $\mathbb{E}(T_n) = \theta$ et $\text{var}(T_n) = \frac{\theta^2}{3n}$. D'après le TCL, on sait que

$$\frac{T_n - \theta}{\frac{\theta}{\sqrt{3n}}} \text{ a pour loi asymptotique la loi } \mathcal{N}(0, 1)$$

$$\text{Ainsi, } \frac{\sqrt{3n}(T_n - \theta)}{\theta} \text{ a pour loi asymptotique } \mathcal{N}(0, 1).$$

$$\text{Donc } \sqrt{3n}(T_n - \theta) \text{ a pour loi asymptotique } \mathcal{N}(0, \theta^2).$$

Exercice 3

On désire estimer la proportion de clients qui portent des lunettes.

1) Une estimation ponctuelle de la proportion p de personnes portant des lunettes est :

$$\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i = \frac{260}{780} = \frac{1}{3}$$

2) La construction d'un intervalle de confiance pour la proportion p au niveau de confiance 0,95 nécessite plusieurs étapes qui sont présentées ci-dessous.

Etape 1 : Il faut d'abord trouver un estimateur ayant les "bonnes" propriétés. On propose \bar{X}_n comme estimateur de p , avec $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$, avec X_i qui suit une loi de Bernoulli de paramètre p .

$$X_i = \begin{cases} 1 & \text{si le client porte des lunettes} \\ 0 & \text{sinon} \end{cases}$$

Il est nécessaire de vérifier que cet estimateur est un "bon" estimateur, autrement dit qu'il est un estimateur sans biais et convergent de p . $\mathbb{E}(\bar{X}_n) = \mathbb{E}(X_i) = p \Rightarrow \bar{X}_n$ est bien un estimateur sans biais de p . De plus, \bar{X}_n est un estimateur convergent de p , car $\lim_{n \rightarrow +\infty} \text{var}(\bar{X}_n) = 0$. En effet,

$$\text{var}(\bar{X}_n) = \frac{\text{var}(X_i)}{n} = \frac{p(1-p)}{n}$$

Etape 2 : Il faut ensuite introduire Z , une nouvelle variable aléatoire, dite pivotale, qui dépend de (X_1, \dots, X_n) et du paramètre p et de loi indépendante de p .

D'après le TCL, la variable aléatoire

$$Z = \frac{\bar{X}_n - p}{\sqrt{\frac{p(1-p)}{n}}}$$

converge vers une variable aléatoire de loi normale centrée réduite $\mathcal{N}(0,1)$, dès que $n > 30$, $np > 5$ et $n(1-p) > 5$. Puisqu'ici, n est suffisamment grand ($n > 30$), et que les variables aléatoires X_i sont indépendantes et de même loi de Bernoulli de paramètre p , les hypothèses du TCL sont satisfaites. On considère donc que Z suit asymptotiquement une loi $\mathcal{N}(0,1)$.

Etape 3 : On construit un intervalle de confiance pour la proportion p au niveau de confiance 0,95 à partir de la variable aléatoire Z .

On cherche a tel que $\mathbb{P}(-a \leq \bar{X}_n - p \leq a) = 0,95$ (*)

$$(*) \iff \mathbb{P}\left(\frac{-a}{\sqrt{\frac{p(1-p)}{n}}} \leq \frac{\bar{X}_n - p}{\sqrt{\frac{p(1-p)}{n}}} \leq \frac{a}{\sqrt{\frac{p(1-p)}{n}}}\right) = 0,95$$

$$(*) \iff \mathbb{P}\left(\frac{-a\sqrt{n}}{\sqrt{p(1-p)}} \leq Z \leq \frac{a\sqrt{n}}{\sqrt{p(1-p)}}\right) = 0,95$$

$$(*) \iff 2 \Phi\left(\frac{a\sqrt{n}}{\sqrt{p(1-p)}}\right) - 1 = 0,95$$

$$(*) \iff \Phi\left(\frac{a\sqrt{n}}{\sqrt{p(1-p)}}\right) = \frac{1,95}{2} = 0,975$$

$$(*) \iff \frac{a\sqrt{n}}{\sqrt{p(1-p)}} = \Phi^{-1}(0,975)$$

$$(*) \iff a = \sqrt{\frac{p(1-p)}{n}} \times \Phi^{-1}(0,975)$$

où Φ est la fonction de répartition d'une loi normale centrée réduite.

L'objectif est de déterminer a à partir de l'expression précédente. Mais on ne connaît pas p . On se propose alors d'approximer p par \bar{x}_n que l'on a calculé dans la première question de cet exercice. On sait également que 780 ménages ont été interrogés, autrement dit, $n = 780$.

$$a = \sqrt{\frac{\bar{x}_n(1-\bar{x}_n)}{n}} \times \Phi^{-1}(0,975)$$

$$a = \sqrt{\frac{1/3 \times 2/3}{780}} \times \Phi^{-1}(0,975)$$

$$a = \sqrt{\frac{2}{9} \times \frac{1}{780}} \times \Phi^{-1}(0,975)$$

$$a = \frac{\Phi^{-1}(0,975)}{\sqrt{9 \times 390}}$$

$$a = \frac{\Phi^{-1}(0,975)}{\sqrt{3510}}$$

$$a = \frac{1,96}{\sqrt{3510}}$$

$$a \simeq 0,03308$$

Pour déterminer $\Phi^{-1}(0,975)$, on a lu dans la table de la loi normale centrée réduite la valeur t telle que $\mathbb{P}(Z \leq t) = 0,975$, avec $Z \sim \mathcal{N}(0,1)$, ce qui donne $t = 1,96$. Par conséquent, $\Phi^{-1}(0,975) = 1,96$.

L'intervalle de confiance pour p est $IC = [\bar{X}_n - a; \bar{X}_n + a]$. L'intervalle de confiance observé est défini par $IC_{obs} = [\bar{x}_n - a; \bar{x}_n + a]$. Par conséquent, dans cet exercice, l'intervalle de confiance pour p , au niveau de confiance 0,95, est égal à $[0,30025; 0,36642]$.

3) On cherche les niveaux de confiance $(1 - \alpha)$ pour lesquels la longueur de l'intervalle

de confiance est inférieure ou égale à 0,05, ce qui s'écrit, connaissant la définition de a ,

$$\begin{aligned}
 \bar{x}_n + a - (\bar{x}_n - a) &\leq 0,05 \\
 2a &\leq 0,05 \\
 2 \Phi^{-1} \left(\frac{1 + (1 - \alpha)}{2} \right) \sqrt{\frac{\bar{x}_n(1 - \bar{x}_n)}{n}} &\leq 0,05 \\
 2 \Phi^{-1} \left(1 - \frac{\alpha}{2} \right) \sqrt{\frac{\bar{x}_n(1 - \bar{x}_n)}{n}} &\leq 0,05 \\
 \Phi^{-1} \left(1 - \frac{\alpha}{2} \right) &\leq \frac{0,05}{2} \sqrt{\frac{n}{\bar{x}_n(1 - \bar{x}_n)}} \\
 \Phi^{-1} \left(1 - \frac{\alpha}{2} \right) &\leq \frac{0,05}{2} \sqrt{\frac{780}{1/3 \times 2/3}} \\
 \Phi^{-1} \left(1 - \frac{\alpha}{2} \right) &\leq 1,48113
 \end{aligned}$$

Donc, d'après la lecture de la table de la loi normale centrée réduite,

$$\begin{aligned}
 1 - \frac{\alpha}{2} &\leq 0,9306 \\
 2 - \alpha &\leq 1,8612 \\
 1 - \alpha &\leq 0,8612
 \end{aligned}$$

En conclusion, pour que la longueur de l'intervalle de confiance soit inférieure ou égale à 0,05, le niveau de confiance doit être inférieur ou égal à 0,8612.

4) De même, on cherche n , la taille de l'échantillon, telle que

$$\begin{aligned}
 2a &\leq 0,05 \\
 2 \times 1,96 \sqrt{\frac{\bar{x}_n(1 - \bar{x}_n)}{n}} &\leq 0,05 \\
 \sqrt{n} &\geq \frac{2 \times 1,96}{0,05} \sqrt{(\bar{x}_n(1 - \bar{x}_n))} \\
 n &\geq \frac{2^2 \times 1,96^2}{0,05^2} (\bar{x}_n(1 - \bar{x}_n)) \\
 n &\geq \frac{2^2 \times 1,96^2}{0,05^2} \times \frac{1}{3} \times \frac{2}{3} \\
 n &\geq 1365,9022
 \end{aligned}$$

Donc, pour que la longueur de l'intervalle de confiance soit inférieure ou égale à 0,05, la taille de l'échantillon doit être au minimum de 1366.