

Corrigé du devoir surveillé du 3 décembre 2009

Exercice 1 (4 points). On s'intéresse au diamètre de pièces circulaires fabriquées par une machine. Du fait des imperfections de la machine, le diamètre correspond à la réalisation d'une variable aléatoire de moyenne $m = 60$ et de variance $\sigma^2 = 100$. Le fabricant souhaite vérifier que le diamètre de ces pièces est bien de taille 60. Il réalise alors un n -échantillon (X_1, X_2, \dots, X_n) . On s'intéresse à la moyenne empirique \bar{X}_n .

1. (2 points) Calculer l'espérance et la variance de \bar{X}_n .

Corrigé $\mathbf{E}[\bar{X}_n] = m = 60$; $\text{var}(\bar{X}_n) = \sigma^2/n = 100/n$.

2. (1 point) Déterminer suivant la taille de l'échantillon la loi de \bar{X}_n .

Corrigé Pour des petites valeurs de n , on ne connaît pas la loi de \bar{X}_n . Pour n grand ($n \geq 30$), on peut approcher la loi de \bar{X}_n par la loi normale $\mathbf{N}(60, 100/n)$.

3. (1 point) Calculer la probabilité en tirant au hasard un échantillon de taille 100, d'observer une moyenne d'échantillon inférieure à 58.2 ?

Corrigé Pour $n = 100$, on peut donc approcher la loi de \bar{X}_n par la loi $\mathbf{N}(60, 1)$ et donc la loi de $\bar{X}_n - 60$ par la loi $\mathbf{N}(0, 1)$. La probabilité cherchée est donc $\Phi(-1.8)$, où Φ est la fonction de répartition de la loi normale. Par symétrie, $\Phi(-1.8) = 1 - \Phi(1.8)$. On lit sur la table $\Phi(1.8) = 0.9641$, d'où $\Phi(-1.8) = 0.0359$.

Exercice 2 (9.5 points). Considérons un n -échantillon (X_1, X_2, \dots, X_n) i.i.d de loi de densité de paramètre α , $\alpha > 0$:

$$f(x) = \frac{1}{\alpha} x^{-\frac{1}{\alpha}-1} \quad \text{si } x \geq 1 \quad \text{et } 0 \text{ sinon}$$

1. (1 point) Vérifier que f est une densité de probabilité.

Corrigé On vérifie que $\alpha^{-1} \int_1^\infty x^{-1/\alpha-1} dx = 1$.

2. (1 point) Donner la fonction de vraisemblance de l'échantillon.

Corrigé La vraisemblance est le produit des vraisemblances marginales car les variables sont indépendantes, soit

$$V(\alpha, x_1, \dots, x_n) = \alpha^{-n} \left(\prod_{i=1}^n x_i \right)^{-1/\alpha-1}.$$

3. (2.5 points) Déterminer l'estimateur du maximum de vraisemblance de α .

Corrigé Il est équivalent de maximiser la log-vraisemblance donnée par

$$L(\alpha, x_1, \dots, x_n) = -n \log(\alpha) - \left(\frac{1}{\alpha} + 1 \right) \sum_{i=1}^n \log(x_i).$$

La dérivée par rapport à α est

$$\frac{\partial L}{\partial \alpha}(\alpha, x_1, \dots, x_n) = -\frac{n}{\alpha} + \frac{1}{\alpha^2} \sum_{i=1}^n \log(x_i).$$

Elle s'annule en la valeur

$$\frac{1}{n} \sum_{i=1}^n \log(x_i).$$

Cette valeur est bien un maximum car c'est l'unique zéro de la dérivée et la log-vraisemblance vaut $-\infty$ en 0 et $+\infty$. L'estimateur du maximum de α est donc

$$\hat{\alpha} = \frac{1}{n} \sum_{i=1}^n \log(X_i).$$

4. (2 points) On considère la variable aléatoire $Y = \log(X)$, avec X qui suit une loi de densité $f(x)$. Calculer la fonction de répartition de Y et en déduire qu'elle est de loi exponentielle.

Corrigé Y est une variable aléatoire positive. Soit $y \geq 0$.

$$\mathbf{P}(Y \leq y) = \mathbf{P}(\log(X) \leq y) = \mathbf{P}(X \leq e^y) = 1 - (e^y)^{-1/\alpha} = 1 - e^{-1/\alpha y}.$$

Y suit donc la loi exponentielle de paramètre $1/\alpha$.

5. (1.5 point) En utilisant les résultats de la question précédente dire si l'estimateur obtenu est sans biais? convergent?

Corrigé L'estimateur du maximum de vraisemblance est donc la moyenne empirique d'un échantillon de la loi exponentielle de paramètre $1/\alpha$. On a donc

$$\mathbf{E}[\hat{\alpha}] = \mathbf{E}[\bar{Y}_n] = \mathbf{E}[Y] = \alpha.$$

L'estimateur $\hat{\alpha}$ est donc sans biais. Il est aussi convergent par la loi des grands nombres.

6. (1 point) Calculer l'information relative à α contenue dans l'échantillon.

Corrigé L'information relative à α contenue dans l'échantillon est

$$I(\alpha) = -\mathbf{E} \left[\frac{\partial^2 L}{\partial \alpha^2} \right] = -\frac{n}{\alpha^2} - \frac{2n}{\alpha^3} \mathbf{E}[\bar{Y}_n] = -\frac{n}{\alpha^2} - \frac{2n}{\alpha^2} = \frac{n}{\alpha^2}.$$

7. (0.5 point) En déduire si l'estimateur précédent est efficace?

Corrigé On a $\text{var}(\hat{\alpha}) = \text{var}(\bar{Y}_n) = \alpha^2/n = I^{-1}(\alpha)$, donc $\hat{\alpha}$ est efficace.

Exercice 3. [7.5 points] Un état souhaite connaître la proportion p de ses électeurs en accord avec un nouveau texte de loi. Pour cela, il décide d'organiser un sondage sur un n -échantillon (X_1, X_2, \dots, X_n) et sur 100 personnes interrogées, 80 pensent voter oui.

1. (2 point) Quelle est la loi des variables X_i ? Sont-elles indépendantes? Donner leur espérance et leur variance.

Corrigé Les variables X_i sont des variables de Bernoulli de même paramètre p que l'on peut considérer comme indépendantes car on a interrogé un nombre d'individus n très petit devant la population totale. On a $\mathbf{E}[X_i] = p$ et $\text{var}(X_i) = p(1-p)$.

2. (1 point) Proposer un estimateur sans biais de p .

Corrigé La moyenne empirique \bar{X}_n , définie par $\bar{X}_n = (X_1 + \dots + X_n)/n$, est un estimateur sans biais de p car $\mathbf{E}[\bar{X}_n] = p$.

3. (2.5 points) On décide maintenant de prendre comme estimateur de p la moyenne empirique \bar{X}_n . Par quelle loi peut-on approximer celle de \bar{X}_n ? En déduire un intervalle de confiance pour p au niveau de confiance 95%.

Corrigé Pour n grand, on peut approcher la loi de \bar{X}_n par la loi normale. Plus précisément, $\sqrt{n}(\bar{X}_n - p)$ suit approximativement la loi $\mathbf{N}(0, p(1-p))$. On peut de plus remplacer $p(1-p)$ par l'estimateur empirique de la variance qui a l'expression $\bar{X}_n(1 - \bar{X}_n)$ pour la loi de Bernoulli. Un intervalle de confiance de niveau 95% est donc

$$I_1 = \left[\bar{X}_n - 1.96 \frac{\sqrt{\bar{X}_n(1 - \bar{X}_n)}}{\sqrt{n}}, \bar{X}_n + 1.96 \frac{\sqrt{\bar{X}_n(1 - \bar{X}_n)}}{\sqrt{n}} \right].$$

Application numérique. La demi-longueur de l'intervalle de confiance est $1.96\sqrt{.8 * .2}/10 = 0.0784$, d'où

$$I_1 = [0.7216, 0.8784].$$

4. (2 points) Montrer que pour $p \in [0, 1]$ on a $p(1-p) \leq \frac{1}{4}$ en déduire un nouvel intervalle de confiance pour p au niveau de confiance 95%.

Corrigé La fonction $p \rightarrow p(1-p)$ est maximale pour $p = 1/2$ (par symétrie) et donc $p(1-p) \leq 1/4$ pour tout $p \in [0, 1]$. On en déduit donc un nouvel intervalle de niveau au moins 95% :

$$\left[\bar{X}_n - \frac{1.96}{2\sqrt{n}}, \bar{X}_n + \frac{1.96}{2\sqrt{n}} \right].$$

Application numérique. La demi-longueur de l'intervalle de confiance est maintenant $1.96/(2 * 10) = 0.098$, d'où

$$I_2 = [0.702, 0.898].$$

Le second intervalle est plus large que le premier mais il est en fait de niveau supérieur à 95%.