



Corrigé de l'examen du 15 juin 2006.
Première partie : exercices 1–3

Ex 1. *Vitesse moyenne (3 points)*

On a enregistré à l'aide d'un radar les vitesses $X_1(\omega) = x_1, \dots, X_{400}(\omega) = x_{400}$ de 400 automobiles dans des conditions permettant de supposer que X_1, \dots, X_{400} sont indépendantes et de même loi. On a obtenu les statistiques suivantes :

$$\sum_{i=1}^{400} x_i = 35\,200 \text{ km/h}, \quad \sum_{i=1}^{400} x_i^2 = 3\,107\,600 \text{ (km/h)}^2.$$

On se propose d'estimer $\mathbf{E}X_1$ par un intervalle de confiance au niveau 98%.

Ici la loi des v.a. X_i est inconnue. Il est clair pour des raisons physiques que les X_i sont des v.a. bornées, donc *a fortiori* de carré intégrable. Un estimateur naturel de $\mathbf{E}X_1$ est la moyenne empirique \bar{X} en raison de la loi forte des grands nombres. On va chercher pour $\mathbf{E}X_1$ un intervalle de confiance centré sur $\bar{X}(\omega) = 35\,200/400 = 88 \text{ km/h}$.

Pour construire cet intervalle de confiance, on ne peut pas utiliser ici le théorème limite central classique car l'écart-type σ des x_i est inconnu. On va utiliser le TLC avec autonormalisation où l'on remplace σ par S , la racine carrée de la variance empirique

$$S^2 := \frac{1}{n} \sum_{i=1}^n (X_i - \mathbf{E}X_i)^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X})^2.$$

Les X_i étant de carré intégrable, le TLC avec autonormalisation nous dit que

$$\sqrt{n} \frac{\bar{X} - \mathbf{E}X_1}{S} \xrightarrow[n \rightarrow +\infty]{\text{loi}} Z, \quad Z \sim \mathfrak{N}(0, 1). \quad (1)$$

Cette convergence légitime pour n grand, l'approximation

$$P\left(\left|\sqrt{n} \frac{\bar{X} - \mathbf{E}X_1}{S}\right| \leq t\right) \simeq P(|Z| \leq t) = 2\Phi(t) - 1,$$

où Φ est la f.d.r. de la loi $\mathfrak{N}(0, 1)$. La résolution d'inégalité :

$$\left|\sqrt{n} \frac{\bar{X} - \mathbf{E}X_1}{S}\right| \leq t \quad \Leftrightarrow \quad \bar{X} - \frac{tS}{\sqrt{n}} \leq \mathbf{E}X_1 \leq \bar{X} + \frac{tS}{\sqrt{n}},$$

nous donne alors un intervalle de confiance pour $\mathbf{E}X_1$ au niveau $2\Phi(t) - 1$. Il s'agit bien d'un intervalle de confiance puisque les bornes $\bar{X} \pm tSn^{-1/2}$ sont calculables à partir des observations sans connaissance de la loi des X_i .

Pour terminer les calculs, on détermine t en résolvant $2\Phi(t) - 1 = 0,98$, ce qui équivaut à $\Phi(t) = 0,99$, d'où $t = 2,33$ (approximativement). On calcule ensuite $\bar{X}(\omega)$ et $S(\omega)$:

$$\bar{X}(\omega) = \bar{x} = \frac{1}{400} \sum_{i=1}^{400} x_i = \frac{35\,200}{400} = 88 \text{ km/h.}$$

$$S^2(\omega) = s^2 = \frac{1}{400} \sum_{i=1}^{400} x_i^2 - (\bar{x})^2 = \frac{3\,107\,600}{400} - 88^2 = 7\,769 - 7\,744 = 25 \text{ km/h}^2,$$

d'où $S(\omega) = s = 5 \text{ km/h}$. Un intervalle de confiance I au niveau 98% pour $\mathbf{E}X_1$ en km/h est donc

$$I = \left[88 - \frac{2,33 \times 5}{20}; 88 + \frac{2,33 \times 5}{20} \right] = [87,41; 88,59].$$

N.B. On a arrondi la borne gauche par défaut et la borne droite par excès.

Ex 2. *Estimation par maximum de vraisemblance (3 points)*

On note X_1, \dots, X_n un échantillon associé au modèle statistique $(\Omega, \mathcal{F}, (P_\theta)_{\theta \in]0, +\infty[})$, les X_i étant des v.a. à valeurs dans $]0, 1[$ ayant pour densité sous P_θ la fonction :

$$t \mapsto f(t, \theta) := \theta t^{\theta-1} \mathbf{1}_{]0,1[}(t).$$

On se propose d'estimer θ par maximum de vraisemblance.

1) La fonction de vraisemblance s'écrit ici

$$L(x_1, \dots, x_n, \theta) = \prod_{i=1}^n f(x_i, \theta) = \theta^n (x_1 \cdots x_n)^{\theta-1} \mathbf{1}_{]0,1[}(x_1) \cdots \mathbf{1}_{]0,1[}(x_n).$$

Comme les X_i sont à valeurs dans $]0, 1[$, toutes les observations x_i sont forcément dans cet intervalle, donc toutes les indicatrices ci-dessus valent 1, d'où

$$L(x_1, \dots, x_n, \theta) = \theta^n (x_1 \cdots x_n)^{\theta-1}.$$

Il est commode ici de considérer la log-vraisemblance (de même sens de variation que L) :

$$\ln L(x_1, \dots, x_n, \theta) = n \ln \theta + (\theta - 1) \ln(x_1 \cdots x_n).$$

La dérivée par rapport à θ est

$$\frac{\partial}{\partial \theta} \ln L(x_1, \dots, x_n, \theta) = \frac{n}{\theta} + \ln(x_1 \cdots x_n).$$

En notant que le réel $x_1 \cdots x_n$ appartient à $]0, 1[$ et a donc un logarithme *négalif*, on voit que cette dérivée est strictement positive pour $0 < \theta < -n / \ln(x_1 \cdots x_n)$ et strictement

négative pour $\theta > -n/\ln(x_1 \cdots x_n)$. La log-vraisemblance et la vraisemblance ont donc un unique maximum absolu atteint au point

$$\hat{\theta} = \frac{-n}{\ln(x_1 \cdots x_n)}.$$

On en déduit que l'estimateur T_n de θ par maximum de vraisemblance est la statistique

$$T_n := \frac{-n}{\ln(X_1 \cdots X_n)} = \frac{-n}{\ln X_1 + \cdots + \ln X_n}. \quad (2)$$

2) Pour justifier l'existence de $\mathbf{E}_\theta(\ln X_1)$ il nous faut montrer que $\mathbf{E}_\theta|\ln X_1| < +\infty$. Or X_1 ayant sous chaque P_θ une loi à densité $f(t, \theta)$, cette espérance s'écrit

$$\mathbf{E}_\theta|\ln X_1| = \int_{-\infty}^{+\infty} |\ln t|f(t, \theta) dt = \int_{-\infty}^{+\infty} |\ln t|\theta t^{\theta-1} \mathbf{1}_{]0,1[}(t) = \int_0^1 |\ln t|\theta t^{\theta-1} dt.$$

Pour $\theta > 1$, la fonction $g :]0, 1] \rightarrow \mathbb{R}$, $t \mapsto |\ln t|\theta t^{\theta-1}$ se prolonge par continuité en 0 en posant $g(0) := 0$ et l'intégrale ci-dessus se réduit à une intégrale de Riemann ordinaire d'une fonction continue sur un intervalle fermé borné. Elle est donc finie. Par contre si $0 < \theta \leq 1$, g tend vers $+\infty$ à droite en 0 et on a une vraie intégrale généralisée. Pour montrer sa convergence, le plus simple est de la calculer en intégrant par parties, ce calcul valable pour tout $\theta > 0$, pouvant être recyclé dans le calcul de $\mathbf{E}_\theta(\ln X_1)$. Considérons donc pour tout $\varepsilon \in]0, 1[$, l'intégrale

$$\int_\varepsilon^1 |\ln t|\theta t^{\theta-1} dt = \int_\varepsilon^1 (-\ln t)\theta t^{\theta-1} dt,$$

en notant que $\ln t$ est négatif pour tout $t \in]0, 1[$. L'intégration par parties permet de faire disparaître le logarithme par dérivation. On pose donc ici

$$\begin{aligned} u(t) &= -\ln t & v'(t) &= \theta t^{\theta-1} \\ u'(t) &= \frac{-1}{t} & v(t) &= t^\theta. \end{aligned}$$

Il vient alors

$$\int_\varepsilon^1 (-\ln t)\theta t^{\theta-1} dt = [(-\ln t)t^\theta]_\varepsilon^1 - \int_\varepsilon^1 \frac{-1}{t} t^\theta dt = \varepsilon^\theta \ln \varepsilon + \left(\frac{1^\theta}{\theta} - \frac{\varepsilon^\theta}{\theta} \right).$$

En faisant tendre ε vers 0 et en rappelant que θ est strictement positif, on voit que ceci converge vers $1/\theta$. On a donc montré la finitude de $\mathbf{E}_\theta|\ln X_1|$. L'existence de $\mathbf{E}_\theta(\ln X_1)$ est ainsi justifiée. Pour calculer cette dernière espérance, on remarque simplement que, puisque $X_1(\omega) \in]0, 1[$ pour tout $\omega \in \Omega$, $\ln X_1 = -|\ln X_1|$ et on déduit immédiatement du calcul ci-dessus que

$$\mathbf{E}_\theta(\ln X_1) = \frac{-1}{\theta}.$$

Il n'est pas surprenant de trouver une valeur négative puisque $\ln X_1$ ne prend que des valeurs négatives.

3) En revenant à (2), on voit que T_n peut aussi s'écrire

$$T_n = \frac{-1}{\frac{1}{n}(\ln X_1 + \dots + \ln X_n)},$$

ce qui suggère d'appliquer la loi forte des grands nombres à la suite des v.a. $Y_i := \ln X_i$. La suite $(Y_i)_{i \geq 1}$ hérite de l'indépendance et de l'équidistribution de $(X_i)_{i \geq 1}$. D'après la question 2, $\mathbf{E}_\theta |Y_1| < +\infty$. Les hypothèses de la loi forte des grands nombres sont donc bien vérifiées par $(Y_i)_{i \geq 1}$, d'où pour tout $\theta \in]0, +\infty[$,

$$\frac{1}{n}(Y_1 + \dots + Y_n) = \frac{1}{n}(\ln X_1 + \dots + \ln X_n) \xrightarrow[n \rightarrow +\infty]{P_\theta\text{-p.s.}} \mathbf{E}_\theta(\ln X_1) = \frac{-1}{\theta}.$$

La fonction $h : t \mapsto -1/t$ étant continue sur \mathbb{R}^* , donc en particulier au point $-1/\theta$, on en déduit que $T_n = h(n^{-1}(Y_1 + \dots + Y_n))$ converge P_θ -p.s. vers $h(-1/\theta) = \theta$. Ainsi T_n est un estimateur fortement consistant de θ .

Ex 3. *Convergence en loi (4 points)*

Soit $(X_i)_{i \geq 1}$ une suite de variables aléatoires définies sur le même espace probabilisé (Ω, \mathcal{F}, P) , indépendantes et de même loi telle que $\mathbf{E}X_1^2 = 1$ et $\mathbf{E}X_1 = 0$. On suppose de plus que pour tout i , $X_i(\omega)$ n'est jamais nul. On définit alors sur (Ω, \mathcal{F}, P) les suites de variables aléatoires $(Y_n)_{n \geq 1}$ et $(Z_n)_{n \geq 1}$ par

$$Y_n := \sqrt{n} \frac{X_1 + \dots + X_n}{X_1^2 + \dots + X_n^2}, \quad Z_n := \frac{X_1 + \dots + X_n}{(X_1^2 + \dots + X_n^2)^{1/2}}.$$

Montrons que $(Y_n)_{n \geq 1}$ et $(Z_n)_{n \geq 1}$ convergent en loi quand n tend vers l'infini vers une v.a. gaussienne de loi $\mathfrak{N}(0, 1)$.

La méthode pour prouver ces convergences en loi de $(Y_n)_{n \geq 1}$ et $(Z_n)_{n \geq 1}$ est la même que celle vue en cours pour établir le théorème limite central avec autonormalisation. On met en facteur S_n^* , la somme centrée réduite du TLC classique et on montre que l'autre facteur converge en probabilité vers une constante. Ceci permet de conclure *via* le lemme de Slutsky.

Commençons par calculer $S_n^* = (\text{Var } S_n)^{-1/2}(S_n - \mathbf{E}S_n)$, où $S_n := X_1 + \dots + X_n$. Comme les X_i ont une espérance nulle, $\mathbf{E}S_n = \sum_{i=1}^n \mathbf{E}X_i = 0$. De plus par indépendance des v.a. de carré intégrable X_i ,

$$\text{Var } S_n = \sum_{i=1}^n \text{Var } X_i = n \text{Var } X_1 = n\mathbf{E}(X_1^2) = n,$$

où la deuxième égalité repose sur l'équidistribution des X_i et la troisième égalité utilise la nullité de $\mathbf{E}X_1$. Par conséquent,

$$S_n^* = \frac{X_1 + \dots + X_n}{\sqrt{n}}. \quad (3)$$

Les X_i étant i.i.d. et de carré intégrable, le théorème limite central nous donne la convergence en loi :

$$\frac{X_1 + \cdots + X_n}{\sqrt{n}} \xrightarrow[n \rightarrow +\infty]{\text{loi}} Z, \quad Z \sim \mathfrak{N}(0, 1). \quad (4)$$

Au vu de (3), la factorisation de Y_n par S_n^* s'écrit :

$$Y_n = S_n^* \frac{n}{X_1^2 + \cdots + X_n^2} = S_n^* \left(\frac{X_1^2 + \cdots + X_n^2}{n} \right)^{-1}. \quad (5)$$

Les v.a. X_i^2 sont i.i.d. et intégrables puisque les X_i sont i.i.d. de carré intégrable. La loi forte des grands nombres appliquée aux X_i^2 nous donne donc

$$\frac{X_1^2 + \cdots + X_n^2}{n} \xrightarrow[n \rightarrow +\infty]{\text{p.s.}} \mathbf{E}X_1^2 = 1.$$

L'application $g : x \mapsto 1/x$ étant continue sur \mathbb{R}^* , donc en particulier au point 1, on en déduit que

$$V_n := \left(\frac{X_1^2 + \cdots + X_n^2}{n} \right)^{-1} = g \left(\frac{X_1^2 + \cdots + X_n^2}{n} \right) \xrightarrow[n \rightarrow +\infty]{\text{p.s.}} 1.$$

La convergence p.s. implique la convergence en probabilité, d'où

$$\left(\frac{X_1^2 + \cdots + X_n^2}{n} \right)^{-1} \xrightarrow[n \rightarrow +\infty]{\text{Pr}} 1. \quad (6)$$

La factorisation (5) nous a donc permis de représenter Y_n comme le produit de $S_n^* V_n$ où S_n^* converge en loi vers Z et V_n converge en probabilité vers 1. Par le lemme de Slutsky, le vecteur aléatoire (S_n^*, V_n) converge en loi vers $(Z, 1)$. En prenant son image par la fonction continue $h : \mathbb{R}^2 \rightarrow \mathbb{R}$, $(x, y) \mapsto xy$, on en déduit la convergence en loi de $Y_n = h(S_n^*, V_n)$ vers $g(Z, 1) = Z$.

Pour établir la convergence en loi de Z_n vers Z , on remplace (5) par la factorisation

$$Z_n = S_n^* \left(\frac{n}{X_1^2 + \cdots + X_n^2} \right)^{1/2} = S_n^* \left(\frac{X_1^2 + \cdots + X_n^2}{n} \right)^{-1/2}. \quad (7)$$

Ensuite on utilise le même raisonnement que ci-dessus en prenant pour g l'application $x \mapsto x^{-1/2}$.