

Première Année Master M.A.E.F. 2011 – 2012

Statistiques II

Correction du contrôle continu n°1, mars 2012

Examen de 1h30. Tout document ou calculatrice est interdit.

1. (Sur 15 points + 7 points facultatifs) Soit $X = (X_t)_{t \in \mathbf{Z}}$ le processus défini par:

$$X_t = \sum_{i=0}^{\infty} \frac{1}{i+1} \varepsilon_{t-i} \quad \text{pour } t \in \mathbf{Z},$$

où $(\varepsilon_t)_{t \in \mathbf{Z}}$ est un bruit blanc gaussien de variance σ^2 .

- (a) Soit $N \in \mathbf{N}$ et soit $(X_t^{(N)})_{t \in \mathbf{Z}}$ le processus tel que pour $t \in \mathbf{Z}$, $X_t^{(N)} = \sum_{i=0}^N \frac{1}{i+1} \varepsilon_{t-i}$. Montrer que $(X_t^{(N)})_{t \in \mathbf{Z}}$ est un processus stationnaire.
- (b) Montrer que pour tout $t \in \mathbf{Z}$, la suite $(X_t^{(N)})_N$ converge absolument dans \mathbb{L}^2 . En déduire que (X_t) existe dans \mathbb{L}^2 et est un processus stationnaire gaussien.
- (c) Déterminer $\mathbb{E}X_t$ et $\text{var}(X_t)$ (on rappelle que $\sum_{n=1}^{\infty} \frac{1}{n^2} = \frac{\pi^2}{6}$). En déduire la loi de X_t pour $t \in \mathbf{Z}$.
- (d) Calculer (sous forme de série) l'autocovariance r_X de (X_t) . Le processus (X_t) est-il un bruit blanc?
- (e) On utilisant la décomposition $\frac{1}{i(i+k)} = \frac{1}{k} \left(\frac{1}{i} - \frac{1}{k+i} \right)$, montrer que $r_X(k) \simeq \sigma^2 \frac{\ln k}{k}$ pour $k \rightarrow \infty$.
- (f) En déduire que la densité spectrale f_X de (X_t) existe sur $[-\pi, 0[\cup]0, \pi[$, mais $\lim_{x \rightarrow 0} f_X(x) = \infty$.
- (g) (**Question facultative = 7 points**) Soit $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$. Montrer que pour tout $n \in \mathbf{N}^*$,

$$\text{var}(\bar{X}_n) = \frac{1}{n} \text{var}(X_0) + \frac{2}{n^2} \sum_{k=1}^{n-1} (n-k) r_X(k), \text{ puis que } \text{var}(\bar{X}_n) \simeq \sigma^2 \frac{\log^2 n}{n} \text{ pour } n \rightarrow \infty.$$

En déduire que $\bar{X}_n \xrightarrow[n \rightarrow +\infty]{\mathcal{P}} 0$ puis que $\frac{\sqrt{n}}{\log n} \bar{X}_n \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, \sigma^2)$.

Proof. (a) Pour $n \in \mathbf{N}^*$, $(t_1, \dots, t_n) \in \mathbf{Z}^n$, (ε_t) est un processus stationnaire donc $(\varepsilon_{t_1}, \varepsilon_{t_1-1}, \dots, \varepsilon_{t_1-N}, \varepsilon_{t_2}, \varepsilon_{t_2-1}, \dots, \varepsilon_{t_n}, \varepsilon_{t_n-1}, \dots, \varepsilon_{t_n-N})$ a la même loi que $(\varepsilon_{t_1+c}, \varepsilon_{t_1-1+c}, \dots, \varepsilon_{t_n+c}, \varepsilon_{t_n-1+c}, \dots, \varepsilon_{t_n-N+c})$ pour tout $c \in \mathbf{Z}$. On applique alors la fonction $g : (x_1, \dots, x_{n(N+1)}) \mapsto$

$(\sum_{i=0}^N \frac{1}{i+1} x_{i+1}, \dots, \sum_{i=0}^N \frac{1}{i+1} x_{(n-1)(N+1)+i+1})$ qui est continue donc mesurable et ainsi $(X_{t_1}^{(N)}, \dots, X_{t_n}^{(N)})$ a la même loi que $(X_{t_1+c}^{(N)}, \dots, X_{t_n+c}^{(N)})$ (**2 pts**).

(b) On a facilement $\mathbb{E}(X_t^{(N)})^2 = \sigma^2 \sum_{i=1}^{N-1} \frac{1}{i^2}$ donc $\mathbb{E}(X_t^{(N)})^2 < \infty$ pour tout $N \in \mathbf{N}^*$. D'où la convergence dans \mathbb{L}^2 (**1 pt**).

La convergence dans \mathbb{L}^2 est aussi valable pour tout vecteur $(X_{t_1}^{(N)}, \dots, X_{t_n}^{(N)})$ (on passe par une combinaison linéaire quelconque) donc (X_t) existe dans \mathbb{L}^2 et la propriété de stationnarité est conservée par passage à la limite (**1.5 pts**).

Enfin, comme chaque $(X_{t_1}^{(N)}, \dots, X_{t_n}^{(N)})$ est un vecteur gaussien car défini comme une application linéaire (g) d'un vecteur de v.a. indépendantes gaussiennes $(\varepsilon_{t_1}, \varepsilon_{t_1-1}, \dots, \varepsilon_{t_1-N}, \varepsilon_{t_2}, \varepsilon_{t_2-1}, \dots, \varepsilon_{t_n}, \varepsilon_{t_n-1}, \dots, \varepsilon_{t_n-N})$, $(X_t^{(N)})$ est un processus gaussien pour tout $N \in \mathbf{N}^*$. Par passage à la limite de tout vecteur $(X_{t_1}^{(N)}, \dots, X_{t_n}^{(N)})$, comme cette limite existe, elle est gaussienne (**1.5 pts**).

(c) On a facilement $\mathbb{E}X_t = 0$ (**0.5 pts**) et $\text{var}(X_t) = \frac{\pi^2}{6} \sigma^2$ (**0.5 pts**). Donc X_t a pour loi $\mathcal{N}(0, \frac{\pi^2}{6} \sigma^2)$ (**0.5 pts**).

(d) On a facilement $r_X(k) = \sigma^2 \sum_{i=1}^{\infty} \frac{1}{i(i+k)}$ (**1 pt**). (X_t) n'est donc pas un bruit blanc car par exemple $r_X(1) = \sigma^2 \neq 0$ (**0.5 pts**).

(e) On a donc $r_X(k) = \lim_{N \rightarrow \infty} \frac{1}{k} \sum_{i=1}^N \frac{1}{k} \left(\frac{1}{i} - \frac{1}{k+i} \right) = \lim_{N \rightarrow \infty} \frac{1}{k} \left(\sum_{i=1}^k \frac{1}{i} - \sum_{i=1}^k \frac{1}{N+i} \right)$. Or $\lim_{N \rightarrow \infty} \sum_{i=1}^k \frac{1}{N+i} = 0$ et $\sum_{i=1}^k \frac{1}{i} \simeq \log k$ pour $k \rightarrow \infty$. D'où le résultat (**2.5 pts**).

(f) Pour $x \neq 0$, $f_X(x) = \frac{1}{2\pi} \sum_{k \in \mathbf{Z}} r_X(k) e^{-ikx}$ qui existe (d'après Abel-Dirichlet) et pour $x \rightarrow 0$, $f_X(x) \rightarrow \frac{1}{2\pi} \sum_{k \in \mathbf{Z}} r_X(k)$ qui diverge d'après le comportement asymptotique de r_X (série de Bertrand) (**1.5 pts**).

(g) On a $\text{var}(\bar{X}_n) = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n r_X(j-i) = \frac{1}{n} \sum_{i=1}^n r_X(0) + \frac{2}{n^2} \sum_{1 \leq i < j \leq n} r_X(j-i)$. Dans cette dernière somme, on a $n-1$ fois le terme $r_X(1)$ qui apparaît, $(n-2)$ fois le terme $r_X(2)$, ..., d'où le résultat (**1.5 pts**).

On a $\sum_{k=1}^n r_X(k)$ qui a le même comportement asymptotique que $\int_1^n \frac{\log x}{x} dx$. Par une IPP, on montre que $\int_1^n \frac{\log x}{x} dx = \frac{1}{2} \log^2 n$.

Par ailleurs, $\sum_{k=1}^n k r_X(k)$ a le même comportement asymptotique que $\int_1^n \log x dx \simeq n \log n$. En rassemblant le tout on a bien $\text{var}(\bar{X}_n) \simeq \sigma^2 \frac{\log^2 n}{n}$ (**3 pts**).

On utilise alors l'inégalité de Bienaymé-Tchebychev pour montrer la convergence en probabilité (**1 pt**) et le Lemme de Slutski pour montrer le théorème de la limite centrale (**1.5 pt**). □

2. (**Sur 9 points**) On suppose maintenant que l'on observe (Y_1, \dots, Y_{3n}) issu du processus $Y = (Y_t)_{t \in \mathbf{N}}$ tel que

$$Y_t = a g(t) + X_t \quad \text{pour tout } t \in \mathbf{N}.$$

où $a \in \mathbf{R}^*$ est inconnu, et $g(3i) = 1$, $g(3i+1) = 3$ et $g(3i+2) = -1$ pour tout $i \in \mathbf{N}$.

- Le processus $(Y_t)_{t \in \mathbf{N}}$ est-il stationnaire? Gaussien?
- Déterminer la tendance, la saisonnalité de Y et sa période.
- On désire estimer a et σ^2 . A l'aide d'une estimation par moindres carrés ordinaires, montrer que

$$\hat{a}_n = \frac{1}{11n} \sum_{i=0}^{n-1} (3Y_{3i+1} - Y_{3i+2} + Y_{3i+3}).$$

En déduire un estimateur non biaisé de σ^2 .

- Montrer que \hat{a}_n est un estimateur sans biais. Montrer que si deux suites de variables aléatoires $(U_n)_n$ et $(V_n)_n$ sont telles que $U_n \xrightarrow[n \rightarrow +\infty]{\mathbb{L}^2} 0$ et $V_n \xrightarrow[n \rightarrow +\infty]{\mathbb{L}^2} 0$, alors $U_n + V_n \xrightarrow[n \rightarrow +\infty]{\mathbb{L}^2} 0$. En déduire que $\hat{a}_n \xrightarrow[n \rightarrow +\infty]{\mathbb{L}^2} a$ (on utilisera les mêmes raisonnements qu'en 1.(g) sans faire de calculs).
- En déduire un estimateur convergeant de la tendance et de la saisonnalité de Y .

Proof. (a) Si $a \neq 0$, $\mathbb{E}Y_1 = 3a$ et $\mathbb{E}Y_2 = -a$, donc l'espérance dépend du temps: le processus (Y_t) n'est donc pas stationnaire (**1 pt**). Il est en revanche gaussien car (X_t) est gaussien (**0.5 pts**).

(b) On peut écrire que $a(t) = a$ (tendance) et $s(t) = 2a(\mathbb{1}_{t=1[3]} - \mathbb{1}_{t=2[3]})$ (saisonnalité) de période 3 (**1.5 pts**).

(c) On pose $Z = {}^t(3, -1, 1, 3, -1, 1, 3, \dots, 1)$ et alors $Y = aZ + \varepsilon$ (écriture vectorielle du modèle). Alors $\hat{a}_n = ({}^t Z Z)^{-1} {}^t Z Y$ d'où l'expression proposée de \hat{a}_n (**1.5 pts**).

Classiquement on en déduit l'estimateur $\hat{\sigma}_n^2 = \frac{1}{n-1} \sum_{i=1}^{3n} (Y_i - \hat{a}_n g(i))^2$ (**0.5 pts**).

(d) Il est clair que $\hat{a}_n = a + \frac{1}{11n} \sum_{i=0}^{n-1} (3X_{3i+1} - X_{3i+2} + X_{3i+3})$ donc \hat{a}_n est un estimateur non biaisé de a (**1 pt**).

On a $\mathbb{E}(U_n + V_n)^2 \leq 2(\mathbb{E}U_n^2 + \mathbb{E}V_n^2) \xrightarrow[n \rightarrow \infty]{} 0$, donc $U_n + V_n \xrightarrow[n \rightarrow +\infty]{\mathbb{L}^2} 0$ (**1 pt**).

Comme en 1.(g), on montre $\text{var}\left(\frac{1}{n} \sum_{i=0}^{n-1} X_{3i+1}\right) \xrightarrow[n \rightarrow \infty]{} 0$, $\text{var}\left(\frac{1}{n} \sum_{i=0}^{n-1} X_{3i+2}\right) \xrightarrow[n \rightarrow \infty]{} 0$ et $\text{var}\left(\frac{1}{n} \sum_{i=0}^{n-1} X_{3i+3}\right) \xrightarrow[n \rightarrow \infty]{} 0$, donc

$\frac{1}{11n} \sum_{i=0}^{n-1} (3X_{3i+1} - X_{3i+2} + X_{3i+3}) \xrightarrow[n \rightarrow +\infty]{\mathbb{L}^2} 0$, donc $\hat{a}_n \xrightarrow[n \rightarrow +\infty]{\mathbb{L}^2} a$ (**1.5 pts**).

(e) Comme la tendance est a , alors \hat{a}_n est un estimateur convergeant de la tendance, comme la saisonnalité est $2a(\mathbb{1}_{t=1[3]} - \mathbb{1}_{t=2[3]})$, alors $2\hat{a}_n(\mathbb{1}_{t=1[3]} - \mathbb{1}_{t=2[3]})$ est un estimateur convergeant de la saisonnalité (**0.5 pts**). □