

Première Année Master M.A.E.F. 2012 – 2013

Statistiques II

Correction du contrôle continu n°2, avril 2013

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

1. (**Sur 18 (+4) points**) Soit $\varepsilon = (\varepsilon_t)_{t \in \mathbf{Z}}$ un bruit blanc fort centré de variance $\sigma_\varepsilon^2 > 0$, inconnue. On définit, lorsque cela est possible, le processus $X = (X_t)_{t \in \mathbf{Z}}$ tel que

$$X_t - 2aX_{t-1} + a^2X_{t-2} = \varepsilon_t \quad \text{pour } t \in \mathbf{Z}.$$

avec $a \in \mathbf{R}$.

- (a) Dire suivant les valeurs de a quel type de processus est X . On suppose désormais que $|a| < 1$.
- (b) Pour $t \in \mathbf{Z}$, déterminer l'expression de X_t en fonction de $(\varepsilon_{t-n})_{n \in \mathbf{N}}$ et de a .
- (c) Montrer que pour tout $x \in]-1, 1[$, $\sum_{k=0}^{\infty} kx^k = x(1-x)^{-2}$ et $\sum_{k=0}^{\infty} k^2x^k = x(1+x)(1-x)^{-3}$ (on pourra s'aider du développement en série entière de $(1-x)^{-1}$).
- (d) En déduire que $r_X(j) = \sigma_\varepsilon^2 a^{|j|} \left(\frac{(1+a^2) + (1-a^2)|j|}{(1-a^2)^3} \right)$ pour tout $j \in \mathbf{Z}$ où r_X est l'autocovariance de X . Quelle est la limite de $r_X(j)$ quand $|j| \rightarrow \infty$?
- (e) On observe finalement (Y_1, \dots, Y_n) où pour $t \in \mathbf{Z}$, $Y_t = \alpha + X_t + \xi_t$, avec $\alpha \in \mathbf{R}$ inconnu et $\xi = (\xi_t)_{t \in \mathbf{Z}}$ un bruit blanc fort centré de variance σ_ξ^2 , indépendant de ε . Montrer que $Y = (Y_t)_{t \in \mathbf{Z}}$ est stationnaire. Déterminer la densité spectrale de Y .
- (f) (**Facultatif: 4 points**) Montrer que cette densité spectrale est celle d'un processus ARMA dont on précisera l'ordre.
- (g) On définit $\bar{Y}_n = \frac{1}{n} \sum_{i=1}^n Y_i$. Montrer que \bar{Y}_n est un estimateur non biaisé de α . Montrer que \bar{Y}_n vérifie un théorème de la limite centrale que l'on précisera.

Proof. (a) Si $a = 0$, X est un bruit blanc fort (**0.5 pts**).

Si $a \neq 0$, comme $P(X) = 1 - 2aX + a^2X^2 = (1 - aX)^2$, P admet une unique racine $1/a$, double. On en déduit que si $|a| < 1$, X est un AR(2) stationnaire causal, si $|a| > 1$, X est un AR(2) stationnaire non causal, et si $|a| = 1$, X n'est pas stationnaire (**1.5 pt**).

(b) On a $(1-z)^{-2} = ((1-z)^{-1})' = (\sum_{k=0}^{\infty} z^k)' = \sum_{k=0}^{\infty} (k+1)z^k$. Donc $P(B)^{-1} = \sum_{k=0}^{\infty} (k+1)a^k B^k$. On en déduit que $X_t = \sum_{k=0}^{\infty} (k+1)a^k \varepsilon_{t-k}$ (**2 pts**).

(c) Comme pour $|x| < 1$, $(1-x)^{-1} = \sum_{k=0}^{\infty} x^k$, en dérivant, on obtient $(1-x)^{-2} = \sum_{k=1}^{\infty} kx^{k-1}$, donc $x \sum_{k=1}^{\infty} kx^{k-1} = \sum_{k=0}^{\infty} kx^k = x(1-x)^{-2}$ (**1 pt**).

En dérivant cette expression une fois, on obtient que $\sum_{k=0}^{\infty} k^2x^{k-1} = (x+1)(1-x)^{-3}$ puis en multipliant encore par x , on obtient bien $\sum_{k=0}^{\infty} k^2x^k = x(1+x)(1-x)^{-3}$ (**1 pt**).

(d) On a $r_X(j) = \mathbb{E}(X_0X_j) = \mathbb{E}\left[\sum_{k=0}^{\infty} \sum_{k'=0}^{\infty} (k+1)a^k \varepsilon_{-k}(k'+1)a^{k'} \varepsilon_{j-k'}\right]$. On peut intervertir espérance et séries (Lebesgue) et comme $\mathbb{E}[\varepsilon_i \varepsilon_j] = \sigma_\varepsilon^2 \delta_{ij}$, tous les termes de la double somme s'annule, sauf lorsque $-k = j - k'$, donc lorsque $k' = k + j$. En choisissant $j \in \mathbf{N}$, on aboutit à: $r_X(j) = \sigma_\varepsilon^2 \sum_{k=0}^{\infty} a^{2k+j} (k+1)(k+j+1) = \sigma_\varepsilon^2 a^j (\sum_{k=0}^{\infty} k^2 a^{2k} + (j+2) \sum_{k=0}^{\infty} k a^{2k} + (j+1) \sum_{k=0}^{\infty} a^{2k})$. En utilisant les formules précédentes, on obtient

$$r_X(j) = \frac{\sigma_\varepsilon^2 a^j}{(1-a^2)^3} (a^2(1+a^2) + (j+2)a^2(1-a^2) + (j+1)(1-a^2)^2) = \frac{\sigma_\varepsilon^2 a^j}{(1-a^2)^3} ((1+a^2) + j(1-a^2)). \quad (\mathbf{3 pts}).$$

En utilisant la parité de r_X on obtient la formule proposée (**0.5 pts**).

Il est clair que $r_X(j) \rightarrow 0$ quand $|j| \rightarrow \infty$ (**0.5 pts**).

(e) On sait que X est stationnaire et ξ également (comme bruit blanc fort). On doit donc montrer que la somme de 2 processus stationnaires indépendants est un processus stationnaire. On peut faire cela en utilisant la fonction caractéristique: si $n \in \mathbf{N}^*$, $(t_1, \dots, t_n) \in Z^n$, et $c \in \mathbf{Z}$,

$$\begin{aligned} \mathbb{E}\left[e^{i \sum_{k=1}^n u_k (X_{t_k} + \xi_{t_k})}\right] &= \mathbb{E}\left[e^{i \sum_{k=1}^n u_k X_{t_k}}\right] \mathbb{E}\left[e^{i \sum_{k=1}^n u_k \xi_{t_k}}\right] \\ &= \mathbb{E}\left[e^{i \sum_{k=1}^n u_k X_{t_k+c}}\right] \mathbb{E}\left[e^{i \sum_{k=1}^n u_k \xi_{t_k+c}}\right] = \mathbb{E}\left[e^{i \sum_{k=1}^n u_k (X_{t_k+c} + \xi_{t_k+c})}\right], \end{aligned}$$

en utilisant, l'indépendance, puis la stationnarité de X et de ξ , puis encore l'indépendance (**3 pts**).

Il est clair que comme les 2 processus sont indépendants, la densité spectrale de la somme est la somme des densités spectrales.

Donc $f_Y(\lambda) = \frac{\sigma_\xi^2}{2\pi} \frac{1}{|(1-ae^{i\lambda})^2|^2} + \frac{\sigma_\xi^2}{2\pi}$ (**2 pts**).

(f) On peut encore écrire $f_Y(\lambda) = \frac{1}{2\pi} \left(\frac{\sigma_\xi^2 + \sigma_\xi^2 |(1-ae^{i\lambda})^2|^2}{|(1-ae^{i\lambda})^2|^2} \right) = \frac{1}{2\pi} \left(\frac{\sigma_\xi^2 + \sigma_\xi^2 |(1-ae^{i\lambda})^2|^2}{|(1-ae^{i\lambda})^2|^2} \right) = \frac{1}{2\pi} \left(\frac{\sigma_\xi^2 + \sigma_\xi^2 (1+4a^2+a^4) - 4a(1+a^2) \cos(\lambda) + a^2 \cos(2\lambda)}{|(1-ae^{i\lambda})^2|^2} \right)$.

On voit ainsi apparaître un polynôme trigonométrique d'ordre 2 paire, donc Y est un ARMA(2,2) (**4 pts**).

(g) On a clairement $\mathbb{E}[\bar{Y}_n] = a$ donc l'estimateur est sans biais (**0.5 pts**).

On a $\bar{Y}_n = a + \bar{X}_n + \bar{\xi}_n$, où (\bar{X}_n) et $(\bar{\xi}_n)$ sont deux processus indépendants. Comme X est un AR(2), on sait que $(\bar{X}_n)_n$ vérifie:

$\sqrt{n}\bar{X}_n \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 2\pi f_X(0)) = \mathcal{N}(0, \frac{\sigma_\xi^2}{(1-a)^4})$. Comme ξ est un bruit blanc, on a $\sqrt{n}\bar{\xi}_n \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, \sigma_\xi^2)$. Ainsi, comme les 2 processus sont indépendants, la variance de la somme est la somme des variances et on obtient:

$$\sqrt{n}(\bar{Y}_n - a) \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}\left(0, \frac{\sigma_\xi^2}{(1-a)^4} + \sigma_\xi^2\right). \quad (\mathbf{2.5 pts}).$$

□

2. (Sur 9 points) Voici des simulations effectuées avec le logiciel R.

(a) On tape d'accord les commandes suivantes:


```
X=runif(120)
Y=1
p=0.4
for (i in c(1:119))
{Y[i+1]=Y[i]*(X[i]>p)-Y[i]*(X[i]<p)}
Y
Z=2+0.02*c(1:120)-5*sin(pi*c(1:120)/6)+4*(Y-p)
ts.plot(Z)
```

Voici les premières valeurs de Y obtenues:

> Y

```
[1] 1 -1 1 1 1 1 -1 1 1 1 1 1 1 1 -1 -1 1 1 -1 -1 1 1
[23] 1 1 1 -1 1 1 1 -1 -1 -1 -1 -1 1 1 -1 -1 1 -1 -1 1 1 1
[45] -1 1 1 -1 -1 -1 1 -1 -1 -1 -1 -1 1 1 1 1 -1 -1 -1 -1 -1 1
```

On obtient également le graphe suivant:



Questions: Quel est le processus simulé par le vecteur Y (préciser tous ses paramètres)? Pourquoi considère-t-on $Y - p$? Quelle sont les tendances et saisonnalités de Z ?

Proof. Y est tel que Y_n prend ses valeurs dans $\{-1, 1\}$ et quand $Y_{n-1} = 1$, alors $Y_n = 1$ avec une probabilité $(1-p)$ et $Y_n = -1$ avec une probabilité p , quand $Y_{n-1} = -1$ alors $Y_n = 1$ avec une probabilité p et $Y_n = -1$ avec une probabilité $1-p$, ceci pour tout $n > 1$. On en déduit que Y est une chaîne de Markov de matrice de transition $Q = \begin{pmatrix} 1-p & p \\ p & 1-p \end{pmatrix}$, où $p = 0.4$, et avec $Y_1 = 1$ (**2 pts**).

La mesure invariante associée à Y est telle que $(\mu_{-1}1 - \mu_{-1})Q = (\mu_{-1}1 - \mu_{-1})$, donc on trouve que la mesure invariante est $(1/2, 1/2)$. Donc asymptotiquement l'espérance de Y_n est 0. Il n'y a donc pas vraiment de raison de considérer $Y - p$. (**1 pt**)
La tendance de Z_t est $2 + 0.02t$, la saisonnalité $-5 \sin(\pi t/6)$ de période 12 (et on a bien $\sum_{k=1}^{12} -5 \sin(\pi k/6) = 0$) (**1 pt**). □

(b) Voici les commandes tapées ensuite:

```
Z1=c(1:120)
Z2=sin(pi*c(1:120)/6)
reg=lm(Z~Z1+Z2)
summary(reg)
```

Voici les résultats obtenus:

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	1.755147	0.732735	2.395	0.0182 *
Z1	-0.001297	0.010518	-0.123	0.9021
Z2	-5.243756	0.515256	-10.177	<2e-16 ***

Residual standard error: 3.98 on 117 degrees of freedom

Multiple R-squared: 0.4706, Adjusted R-squared: 0.4615

F-statistic: 52 on 2 and 117 DF, p-value: < 2.2e-16

Questions: Qu'a-t-on fait par ces commandes? Que représentent les valeurs 1.755147, -0.001297 et -5.243756? Pourquoi s'attendait-on approximativement à ces valeurs?

Proof. On effectue une régression linéaire de Z par rapport aux variables $Z1_t = t$ et $Z2_t = \sin(\pi t/6)$. Les valeurs obtenues sont ainsi des estimations de 2, -0.02 et -5. On sait que l'estimateur par moindres carrés ordinaires est sans biais et convergeant sous des conditions vérifiées ici (**2 pts**). \square

(c) On tape enfin les commandes suivantes:

```
X=runif(100)
epsilon=2*(X<0.5)-1
Y=0
for (i in c(1:99))
{Y[i+1]=epsilon[i]*sqrt(0.5+0.6*Y[i]^2)}
```

Voici les premières valeurs de Y obtenues:

```
> Y
 [1] 0.0000000 0.7071068 0.8944272 -0.9899495 1.0430724 -1.0736852
 [7] 1.0916410 1.1022740 -1.1086049 -1.1123861 1.1146487 -1.1160040
[13] -1.1168165 1.1173036 1.1175958 1.1177711 1.1178763 -1.1179394
[19] 1.1179772 1.1179999 1.1180136 -1.1180217 1.1180266 -1.1180296
[25] 1.1180313 1.1180324 1.1180330 -1.1180334 -1.1180336 -1.1180338
[31] -1.1180339 -1.1180339 -1.1180339 -1.1180340 1.1180340 1.1180340
[37] 1.1180340 1.1180340 -1.1180340 1.1180340 1.1180340 -1.1180340
```

Questions: Expliquez ce qui a été effectué avec ces commandes (en particulier, quelle est la loi de ϵ , quel processus est Y ?). Retrouvez par le calcul la valeur exacte correspondant à 1.1180340.

Proof. Le vecteur ϵ est composé de variables aléatoires indépendantes prenant pour valeurs 1 ou -1 avec une probabilité 1/2 (**0.5 pts**). C'est donc un bruit blanc fort. Y est donc un processus ARCH(1) tel que $Y_n = \epsilon_n \sqrt{0.5 + 0.6Y_{n-1}^2}$ (**0.5 pts**).

On a $Y_n^2 = 0.5 + 0.6Y_{n-1}^2$, donc Y_n^2 est une suite arithmo-géométrique qui converge (raison = 0.6 de module < 1) et sa limite ℓ est telle que $\ell = 0.5 + 0.6\ell$ soit $\ell = 5/4$. Donc à la limite Y_n prend pour valeur $\pm\sqrt{5/4} \simeq 1.1180340$ (**2 pts**). \square