

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

Statistiques II

Examen final, avril 2013

Examen de 3h00. Tout document ou calculatrice est interdit.

1. (8 points) Soit $(\varepsilon_n)_{n \in \mathbf{Z}}$ un bruit blanc gaussien de variance σ_ε^2 , où $\sigma_\varepsilon^2 > 0$ est inconnu et soit $X = (X_n)_{n \in \mathbf{Z}}$ le processus défini par

$$X_n = \alpha X_{n-1} + \varepsilon_n \quad \text{pour } n \in \mathbf{Z},$$

avec $|\alpha| < 1$ un réel inconnu.

- (a) Quel processus est X ? Est-il centré? stationnaire? gaussien? (justifier)
 (b) Pour $n \in \mathbf{Z}$, déterminer $\mathbb{E}(X_n | X_{n-1})$ et $\mathbb{E}(X_n^2 | X_{n-1})$. En déduire que $\text{var}(X_n | X_{n-1}) = \sigma_\varepsilon^2$ (on rappelle que $\text{var}(X_n | X_{n-1}) = \mathbb{E}(X_n^2 | X_{n-1}) - (\mathbb{E}(X_n | X_{n-1}))^2$) et la loi de X_n sachant X_{n-1} .
 (c) On observe une trajectoire (X_1, \dots, X_N) de X . Montrer que la log-vraisemblance de (X_2, \dots, X_N) sachant X_1 vaut:

$$LV_{\alpha, \sigma_\varepsilon^2}(X_2, \dots, X_N) = -\frac{(N-1)}{2} (\log(2\pi) + \log(\sigma_\varepsilon^2)) - \frac{1}{2\sigma_\varepsilon^2} \sum_{n=2}^N (X_n - \alpha X_{n-1})^2.$$

En déduire les estimateurs $\hat{\alpha}_N$ et $\hat{\sigma}_N^2$ de α et σ_ε^2 maximisant cette log-vraisemblance (on montrera que $\hat{\alpha}_N = \frac{\sum_{n=2}^N X_n X_{n-1}}{\sum_{n=2}^N X_{n-1}^2}$).

- (d) On rappelle que pour un processus ARMA stationnaire causal, $\sqrt{N}(\hat{r}_N(k) - r(k))_{0 \leq k \leq m} \xrightarrow[N \rightarrow \infty]{\mathcal{L}} \mathcal{N}_{m+1}(0, \Sigma)$, où $\Sigma = (4\pi \int_{-\pi}^{\pi} f^2(\lambda) \cos(i\lambda) \cos(j\lambda) d\lambda)_{1 \leq i, j \leq m}$, avec r et f l'autocovariance et la densité spectrale du processus et $\hat{r}_N(k) = \frac{1}{N} \sum_{n=1}^N X_n X_{n+k}$. En déduire un théorème de la limite centrale vérifiée par $\hat{\alpha}_N$.

2. (8 points) On considère maintenant $(\xi_n)_{n \in \mathbf{Z}}$ un bruit blanc gaussien de variance 1 admettant un moment d'ordre 4 et soit $Y = (Y_n)_{n \in \mathbf{Z}}$ le processus défini par

$$Y_n = \xi_n \sqrt{a_0 + a_1 Y_{n-1}^2} \quad \text{pour } n \in \mathbf{Z},$$

où a_0 et a_1 sont deux réels strictement positifs inconnus.


- (a) Quel processus est Y ? Rappeler la condition portant sur a_1 permettant à Y d'être stationnaire d'ordre 2 et causal.
 (b) On se place désormais sous cette condition. Calculer alors $\mathbb{E}(Y_0)$ et $\text{cov}(Y_0, Y_k)$ pour tout $k \in \mathbf{Z}$.
 (c) Pour $n \in \mathbf{Z}$, déterminer $\mathbb{E}(Y_n | Y_{n-1})$ et $\mathbb{E}(Y_n^2 | Y_{n-1})$. En déduire la loi de Y_n sachant Y_{n-1} . Que vaut $\text{cov}(Y_n, Y_{n+k} | Y_{n+k-1})$ pour $k \in \mathbf{N}$?
 (d) Soit le processus $Z = (Z_n)_{n \in \mathbf{Z}}$ tel que $Z_n = Y_n^2 - a_0(1 - a_1)^{-1}$ pour $n \in \mathbf{Z}$. Montrer que Z vérifie $Z_n = a_1 Z_{n-1} + u_n$, où $u_n = (\xi_n^2 - 1)(a_0 + a_1(Z_{n-1} + a_0(1 - a_1)^{-1}))$ pour $n \in \mathbf{Z}$. Montrer que (u_n) est un bruit blanc faible.
 (e) On observe une trajectoire (Y_1, \dots, Y_N) de Y . En utilisant 1.(c) et (d), proposer un estimateur de a_1 fonction de (Y_1, \dots, Y_N) et dont on donnera un théorème de la limite centrale (on admettra que le Théorème obtenu en 1.(d) est valide pour (Z_n)), puis en utilisant la valeur de $\text{var}(Y_0)$ proposer un estimateur convergeant de a_0 .

3. (8 points) Voici des simulations effectuées avec le logiciel R.

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

```
epsilon=3*rnorm(144)
X=0
for (j in c(1:143))
  {X[j+1]=-0.7*X[j]+epsilon[j+1]-2*epsilon[j]}
t=c(1:144)
Y=15+4*log(t)+7*cos(pi*(t-2)/6)+X
ts.plot(Y)
```

Voici le graphe obtenu:



Questions: Quel est le processus simulé par le vecteur X (préciser tous ses paramètres)? Quelles sont les tendances et saisonnalités de Y ? Quelle est sa variance (théorique)?

(b) Voici les commandes tapées ensuite:

```
Z1=t
Z2=t^2
Z3=sqrt(t)
Z4=cos(pi*t/6)
Z5=sin(pi*t/6)
reg=lm(Y~Z1+Z2+Z3+Z4+Z5)
summary(reg)
```

Voici les résultats obtenus:

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) 10.6447975 11.1173261  0.957 0.339991
Z1           -0.4077850  0.5735870 -0.711 0.478322
Z2            0.0009389  0.0017558  0.535 0.593669
Z3            5.3872548  5.0063068  1.076 0.283763
Z4            3.4346042  1.5587953  2.203 0.029227 *
Z5            6.0576026  1.5746636  3.847 0.000182 ***
```

```
Residual standard error: 13.22 on 138 degrees of freedom
Multiple R-squared: 0.1789, Adjusted R-squared: 0.1492
```

Questions: Qu'a-t-on fait par ces commandes? Que représentent les valeurs 10.6447975, 0.593669 et 0.1492? Que conclure à la lecture de ces résultats?

(c) On tape enfin les commandes suivantes:

```
reg=lm(Y~Z1+Z3+Z4+Z5)
summary(reg)
reg=lm(Y~Z3+Z4+Z5)
summary(reg)
acf(reg$res)
```

Voici les résultats obtenus ainsi que le graphe tracé:

```
lm(formula = Y ~ Z1 + Z3 + Z4 + Z5)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	15.2777	6.9492	2.198	0.0296	*
Z1	-0.1099	0.1367	-0.804	0.4225	
Z3	2.9408	2.0282	1.450	0.1493	
Z4	3.4318	1.5548	2.207	0.0289	*
Z5	5.9595	1.5599	3.820	0.0002	***


Residual standard error: 13.19 on 139 degrees of freedom
Multiple R-squared: 0.1772, Adjusted R-squared: 0.1536

```
lm(formula = Y ~ Z3 + Z4 + Z5)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	20.1762	3.3436	6.034	1.35e-08	***
Z3	1.3403	0.3928	3.412	0.000843	***
Z4	3.4173	1.5527	2.201	0.029384	*
Z5	5.9084	1.5567	3.796	0.000219	***

Residual standard error: 13.17 on 140 degrees of freedom
Multiple R-squared: 0.1734, Adjusted R-squared: 0.1557



Questions: Expliquez pourquoi on a répété deux fois la commande `lm` et quel(s) critère(s) guide(nt) cette répétition? Est-on satisfait du modèle obtenu? Pouvait-on s'attendre aux valeurs numériques 3.4173 et 5.9084? Expliquez ce que représente le graphe. La valeur numérique décrite par la seconde barre est approximativement de -0.85 . Expliquez ce que l'on pouvait espérer comme valeur théorique.