

Première Année Master M.A.E.F. 2016 – 2017

Statistiques II

Contrôle continu n°2, avril 2017

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

1. **(7 points + 2 points)** On suppose que  $M = (M_k)_{k \in \mathbf{Z}}$  est un processus centré stationnaire du second ordre tel qu'il existe  $\alpha > 0$  et  $\beta \in \mathbf{R}$  vérifiant pour tout  $k \in \mathbf{Z}$ :

$$\mathbb{E}(M_k^2) = \alpha, \quad \mathbb{E}(M_k M_{k+1}) = \beta \quad \text{et} \quad \mathbb{E}(M_k M_{k+i}) = 0 \quad \text{pour} \quad i \geq 2. \quad (1)$$

- (a) Montrer que l'on a nécessairement  $|\beta| \leq \alpha$  **(1pt)**.  
 (b) Rappeler l'expression de la densité spectrale de  $M$ . En déduire que nécessairement  $2|\beta| \leq \alpha$  **(1.5pts)**.  
 (c) Soit  $(\xi_k)_{k \in \mathbf{Z}}$  une suite de v.a.i.i.d. centrées et de variance  $\sigma^2 > 0$  et soit  $(N_k)_{k \in \mathbf{Z}}$  un processus tel que pour tout  $k \in \mathbf{Z}$ ,  $N_k = \xi_k + c\xi_{k-1}$  avec  $c \in \mathbf{R}$ . Quel type de processus est  $(N_k)$  **(0.5pts)**? Déterminer l'autocovariance de  $(N_k)$  **(1pt)**. En déduire que  $(N_k)_{k \in \mathbf{Z}}$  vérifie (1) en précisant  $c$  et  $\sigma^2$  en fonction de  $\alpha$  et  $\beta$  **(1pt)**.  
 (d) Si  $M$  est un processus gaussien vérifiant (1), montrer que  $M$  est nécessairement un processus MA(1) et donner son écriture à l'aide d'un bruit blanc gaussien  $\varepsilon = (\varepsilon_k)_{k \in \mathbf{Z}}$  dont vous préciserez la variance **(2pts)**.  
 (e) **(Question facultative sur 2 points)** Montrer que si  $M$  est la somme d'un processus MA(1) et d'un processus ARCH( $p$ ) stationnaire d'ordre 2, indépendant de ce MA(1), alors  $M$  vérifie également la relation (1). Y-a-t-il une contradiction avec la propriété précédente?

*Proof.* (a) On utilise l'inégalité de Cauchy-Schwarz.

- (b) On sait que si  $\sum_k |r(k)| < \infty$ , où  $r$  est la covariance de  $M$ , alors  $M$  admet une densité spectrale continue. Ceci est clairement le cas puisque  $r(0) = \alpha$ ,  $r(1) = \beta$  et  $r(k) = 0$  pour  $|k| \geq 2$ . On a ainsi  $f(\lambda) = \alpha + 2\beta \cos(\lambda)$  pour tout  $\lambda \in [-\pi, \pi]$ . Mais on sait qu'une densité spectrale est nécessairement positive. Ceci implique donc que  $\alpha \pm 2\beta \geq 0$  (pour  $\lambda = \pi$  ou 0) donc  $2|\beta| \leq \alpha$ .  
 (c) On sait que  $(N_k)$  est un processus MA(1) centré et stationnaire. De plus  $\mathbb{E}N_k^2 = \mathbb{E}((\xi_k + c\xi_{k-1})^2) = \sigma^2(1 + c^2)$  car  $\xi_k$  et  $\xi_{k+1}$  sont indépendantes et centrées et  $\mathbb{E}N_k N_{k+1} = \mathbb{E}((\xi_k + c\xi_{k-1})(\xi_{k+1} + c\xi_k)) = c\sigma^2$ . Ainsi  $(N_k)$  vérifie (1) lorsque  $\alpha = \sigma^2(1 + c^2)$  et  $\beta = c\sigma^2$ . Donc  $\alpha = \sigma^2 + \frac{\beta^2}{\sigma^2}$ , soit  $\sigma^4 - \alpha\sigma^2 + \beta^2 = 0$ ; on trouve ainsi que  $\sigma^2 = \frac{1}{2}(\alpha + \sqrt{\alpha^2 - 4\beta^2})$  (on retrouve ici également la condition  $2|\beta| \leq \alpha$ ) et  $c = 0$  si  $\beta = 0$ ,  $c = \frac{1}{2\beta}(\alpha - \sqrt{\alpha^2 - 4\beta^2})$  si  $\beta \neq 0$ .  
 (d) La loi d'un processus gaussien est entièrement donnée par ses moments d'ordre 1 et 2. Or si  $M$  est un processus gaussien centré qui vérifie (1) alors  $M$  a la même loi que  $N$  le processus MA(1) de la question précédente, quand  $(\xi_k)$  est gaussien. Donc  $M$  est un bien un processus MA(1) qui s'écrit  $M_k = \varepsilon_k + c\varepsilon_{k-1}$  avec  $c$  donné dans la question précédente, où  $(\varepsilon_k)$  est un bruit blanc gaussien de variance  $\sigma^2$  donné dans la question précédente.  
 (e) Il est clair que comme la covariance d'un ARCH( $p$ ) est nulle, alors si on note  $\gamma^2$  la variance du processus ARCH( $p$ ) on obtient pour nouvelles équations:  $\alpha = (1 + c^2)\sigma^2 + \gamma^2$  et  $\beta = c\sigma^2$ . Ceci permet de trouver tout un ensemble de solutions possibles. Ainsi  $M$  n'est pas seulement un MA(1). Cela n'est pas en contradiction avec la question précédente (qui imposait que  $M$  soit seulement un MA(1)) car on sait qu'un ARCH( $p$ ) ne peut pas être un processus gaussien.

□

2. **(7 points)** On considère deux processus stationnaires indépendants  $X = (X_k)_{k \in \mathbf{Z}}$  et  $Y = (Y_k)_{k \in \mathbf{Z}}$  tels que pour tout  $k \in \mathbf{Z}$ ,

$$X_k = \rho_1 X_{k-1} + u_k, \quad \text{avec} \quad 0 < |\rho_1| < 1, \quad (2)$$

$$Y_k = \rho_2 Y_{k-1} + v_k, \quad \text{avec} \quad 0 < |\rho_2| < 1, \quad (3)$$

où  $u = (u_k)_{k \in \mathbf{Z}}$  et  $v = (v_k)_{k \in \mathbf{Z}}$  sont deux bruits blancs gaussiens indépendants de variances respectives  $\sigma_u^2$  et  $\sigma_v^2$ . Soit enfin  $Z = (Z_k)_{k \in \mathbf{Z}}$  tel que

$$Z_k = X_k + Y_k \quad \text{pour tout} \quad k \in \mathbf{Z}.$$

- (a) Si  $\rho_1 = \rho_2$ , quel type de processus est  $Z$  (**1pt**)?
- (b) Si  $\rho_1 \neq \rho_2$ , montrer que  $Z$  est un processus ARMA(2, 1) dont vous donnerez l'écriture (on pourra considérer  $Z_k - (\rho_1 + \rho_2)Z_{k-1} + \rho_1\rho_2Z_{k-2}$ , puis s'aider de la question 1.(d)) (**4pts**).
- (c) Quelle relation doivent satisfaire  $\rho_1, \rho_2, \sigma_u^2$  et  $\sigma_v^2$  pour que  $Z$  soit un AR(2) (**2pts**)?

*Proof.* (a) Si  $\rho_1 = \rho_2$  alors  $(X_k + Y_k) = \rho_1(X_{k-1} + Y_{k-1}) + (u_k + v_k)$  pour tout  $k \in \mathbf{Z}$ . Donc si on pose  $\varepsilon_k = u_k + v_k$  pour tout  $k \in \mathbf{Z}$ , alors  $(\varepsilon_k)_k$  est un bruit blanc gaussien de variance  $\sigma_u^2 + \sigma_v^2$  et  $Z_k = \rho_1 Z_{k-1} + \varepsilon_k$  pour tout  $k \in \mathbf{Z}$ :  $(Z_k)_k$  est un processus AR(1) gaussien stationnaire.

- (b) On peut écrire que  $Z_k = (\rho_1 + \rho_2)Z_{k-1} - \rho_1\rho_2Z_{k-2} + u_k + v_k - \rho_2u_{k-1} - \rho_1v_{k-1}$ . Posons  $M_k = u_k + v_k - \rho_2u_{k-1} - \rho_1v_{k-1}$ . Alors  $(M_k)_k$  est un processus gaussien (filtre linéaire d'un processus gaussien)  $\mathbb{E}M_k^2 = \sigma_u^2(1 + \rho_2^2) + \sigma_v^2(1 + \rho_1^2)$  et  $\mathbb{E}M_k M_{k-1} = -\rho_2\sigma_u^2 - \rho_1\sigma_v^2$  et  $\mathbb{E}M_k M_{k-j} = 0$  dès que  $|j| \geq 2$ . Donc d'après la question 1. (c),  $(M_k)_k$  est un processus AR(1) gaussien et peut s'écrire sous la forme  $M_k = \varepsilon_k + c\varepsilon_{k-1}$  avec (après calculs):

$$\mathbb{E}M_k^2 = \frac{1}{2} \left( \sigma_u^2(1 + \rho_2^2) + \sigma_v^2(1 + \rho_1^2) + \sqrt{(\sigma_u^2(1 - \rho_2^2) + \sigma_v^2(1 - \rho_1^2))^2 + 4\sigma_u^2\sigma_v^2(\rho_1 + \rho_2)^2} \right)$$

$$\text{et } c = -\frac{1}{2(\rho_2\sigma_u^2 + \rho_1\sigma_v^2)} \left( \sigma_u^2(1 + \rho_2^2) + \sigma_v^2(1 + \rho_1^2) - \sqrt{(\sigma_u^2(1 - \rho_2^2) + \sigma_v^2(1 - \rho_1^2))^2 + 4\sigma_u^2\sigma_v^2(\rho_1 + \rho_2)^2} \right).$$

Donc  $Z_k - (\rho_1 + \rho_2)Z_{k-1} + \rho_1\rho_2Z_{k-2} = M_k - cM_{k-1}$  où  $(M_k)_k$  est un bruit blanc gaussien de variance  $\mathbb{E}M_k^2$ :  $(Z)$  est bien un processus ARMA(2, 1).

- (c)  $(Z_k)_k$  est un processus AR(2) si  $\mathbb{E}M_k M_{k-1} = -\rho_2\sigma_u^2 - \rho_1\sigma_v^2 = 0$ , donc si  $\rho_2\sigma_u^2 = -\rho_1\sigma_v^2$  (on remarque que ceci n'est pas possible si  $\rho_1 = \rho_2 \neq 0$ , cas qui correspondait à un AR(1)).


□

### 3. (9 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) (**0.5pts**)? Quelles sont les tendances et saisonnalités de  $Y$  (**1pt**)? Quelle est sa variance (théorique) (**2pts**)?

*Proof.*  $X$  est un ARMA(1, 1) d'équation  $X_n + 0.7X_{n-1} = \text{epsilon}_n - 2\text{epsilon}_{n-1}$ .

La tendance de  $Y$  est  $a(t) = 15 + 4\ln(t)$  et sa saisonnalité est  $7 * \cos(\pi * (t - 2)/6)$  avec une période de 12. La variance théorique de  $Y$  est celle de  $X$ . On montre facilement que  $X = (\sum_{n=0}^{\infty} (-0.7)^n B^n)(I - 2B)\text{epsilon}$  donc  $X_n = \text{epsilon}_n - 2.7 \sum_{k=1}^{\infty} (-0.7)^k \text{epsilon}_{n-k}$ . En conséquence,  $\text{var}(X_0) = 9(1 + (2.7)^2 \sum_{k=1}^{\infty} 0.49^{k-1}) = 9(1 + (2.7)^2/0.51) = 9 * 260/17 \simeq 137$ . □

- (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 (0.5pts)? Que représentent les valeurs 10.6447975, 0.593669 et 1.5746636 (1.5pts)? Que conclure à la lecture de ces résultats (0.5pts)?*

*Proof.* On estime la tendance et la stationarité de  $Y$  par régression. On régresse  $Y$  par rapport à des variables diverses pour la tendance ( $Z1$  à  $Z3$ ) et par rapport à  $Z4$  et  $Z5$  qui modélisent la saisonnalité.

10.6447975 est l'estimation de l'intercept (15 dans le modèle simulé), 0.593669 est la  $p$ -value de la variable  $Z2$  (testant si le coefficient devant  $Z2$  est nul) et 1.5746636 est la valeur de l'écart-type estimé de l'estimateur du coefficient devant la variable  $Z5$ .

Il apparaît que le modèle n'est pas satisfaisant (en particulier les variables  $Z1$ ,  $Z2$  et  $Z3$  ne semble pas forcément explicatives). □

(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 (0.5pts)? Est-on satisfait du modèle obtenu (0.5pts)? Pouvait-on s'attendre aux valeurs numériques 3.4173 et 5.9084 (0.5pts)? Expliquez ce que représente le graphe (0.5pts). La valeur numérique décrite par la seconde barre est approximativement de  $-0.85$ . Expliquez ce que l'on pouvait espérer comme valeur théorique (1pt).*

*Proof.* On élimine la variable ayant la plus forte  $p$ -value lorsque celle-ci est supérieure à 0.05 et on obtient au final un modèle avec  $Z_3$  (pour la tendance),  $Z_4$  et  $Z_5$  (pour la saisonnalité). On peut aussi avoir choisi le critère du  $R^2$ -ajusté que l'on maximise pour choisir le meilleur modèle possible.

On est satisfait a priori du modèle choisi, car toutes les  $p$ -values des tests de student sont inférieures à 0.05.

3.4173 et 5.9084 sont les estimations des paramètres apparaissant devant  $Z_4$  et  $Z_5$ . Dans le modèle simulé, la saisonnalité est  $7 * \cos(\pi * (t - 2)/6) = 7(\frac{1}{2}\cos(\pi * t/6) + \frac{\sqrt{3}}{2}\cos(\pi * t/6)) \simeq 3.5 Z_4 + 5.5 Z_5$ . On voit que les estimations sont bonnes.

Le graphe représente les autocorrélations empiriques des résidus de la régression, qui sont des estimations des  $\epsilon_i$ .

La valeur numérique décrite par la seconde barre est approximativement de  $-0.85$  est une approximation de la corrélation d'ordre 1 des  $\epsilon_i$ . Or comme  $\mathbb{E}(X_n + 0.7X_{n-1})^2 = \mathbb{E}(\epsilon_n - 2*\epsilon_{n-1})^2 = 45$ , donc  $1.49r(0) + 1.4r(1) = 45$ . On trouve ainsi  $r(1) \simeq (45 - 1.49*137)/1.4 \simeq -114$ . Par suite la corrélation théorique vaut  $\rho(1) = r(1)/r(0) \simeq -114/137 \simeq -0.83$ . L'estimation est donc très proche!  $\square$