

## Première Année Master M.A.E.F. 2010 – 2011

## Statistiques II

Contrôle continu n°2, avril 2011

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

1. (**Sur 15 points**) On considère une suite  $(\varepsilon_i)_{i \in \mathbf{N}}$  de variables aléatoires indépendantes identiquement distribuées (vaid) centrées et de variance commune  $\sigma^2$  et de moment d'ordre 4,  $\mu_4 = \mathbb{E}\varepsilon_0^4 < \infty$ . On définit pour tout  $i \in \mathbf{Z}$  la suite  $(X_i)_{i \in \mathbf{Z}}$  telle qu'avec  $a \in ]-1, 1[$ :

$$X_{i+2} = aX_i + \varepsilon_{i+2} \quad \text{pour tout } i \in \mathbf{Z}.$$

- (a) Rappeler, en justifiant, quel processus est  $(X_i)_{i \in \mathbf{Z}}$  (**0.5pts**). Est-il stationnaire (**0.5pts**)? Causal (**0.5pts**)?
- (b) Déterminer l'expression de  $X_i$  en fonction de  $(\varepsilon_{i-k})_{k \in \mathbf{N}}$  (**1pt**).
- (c) Déterminer l'expression (sans nombre complexe) de la densité spectrale de  $(X_i)$  (**1pt**).
- (d) Montrer que  $r(k)$ , l'autocovariance de  $(X_i)_{i \in \mathbf{Z}}$  vérifie  $r(2n) = \mu a^n$  et  $r(2n+1) = 0$  pour  $n \in \mathbf{N}$ , où  $\mu$  est un réel que l'on pourra exprimer en fonction de  $\sigma^2$  et  $a$  (**2.5pts**).
- (e) On suppose que  $(X_1, \dots, X_N)$  est observé, avec  $N$  "grand", les  $\varepsilon_i$ ,  $a$  et  $\sigma^2$  étant inconnus. On désire estimer  $a$  et  $\sigma^2$ . On définit  $\hat{a}_N = \text{Argmin}_{\{\alpha, 0 \leq \alpha < 1\}} Q_N(\alpha)$  où  $Q_N(\alpha) = \frac{1}{N-2} \sum_{k=3}^N (X_k - \alpha X_{k-2})^2$ . Montrer que  $\hat{a}_N$  est unique et déterminer son expression exacte en fonction de  $(X_1, \dots, X_N)$  (**2pts**).
- (f) Montrer que  $Q_N(a)$  vérifie une loi forte des grands nombres et un théorème central limite (**1pt**).
- (g) Plus généralement, on peut montrer (ne pas le faire) que pour tout  $|\alpha| < 1$ ,  $Q_N(\alpha) \xrightarrow[n \rightarrow +\infty]{p.s.} Q(\alpha)$  avec  $Q(\alpha) = \lim_{N \rightarrow \infty} \mathbb{E}Q_N(\alpha)$ . Calculer  $Q(\alpha)$  (**1pt**) et montrer pour tout  $\alpha \neq a$ ,  $Q(\alpha) > Q(a)$  (**1pt**). En déduire que  $\hat{a}_N \xrightarrow[N \rightarrow +\infty]{p.s.} a$  (**3pts**).
- (h) Montrer alors que  $\hat{\sigma}_N^2 = Q_N(\hat{a}_N)$  est un estimateur convergeant presque sûrement vers  $\sigma^2$  (**1pt**).

*Proof.* (a)  $X$  est un AR[2] stationnaire causal...

(b) Il est clair que  $X_n = \sum_{i=0}^{\infty} a^i \varepsilon_{n-2i}$ .

(c) On a  $f(\lambda) = \frac{\sigma^2}{2\pi} |1 - ae^{2i\lambda}|^{-2} = \frac{\sigma^2}{2\pi} |1 + a^2 - 2a \cos(2\lambda)|^{-1}$ .

(d) On a clairement  $r(k+2) = ar(k)$  pour tout  $k \geq 0$ . De ceci on déduit bien que  $r(2n) = \mu a^n$ , où  $\mu$  est un réel. De plus, de par l'expression précédente de  $X_n$  en fonction des  $\varepsilon_i$ , il est clair que  $\mathbb{E}X_0 X_{2n+1} = 0$  donc  $r(2n+1) = 0$ . Il reste à déterminer  $r(0)$  et  $r(1)$ . Mais  $r(0)(1+a^2) - 2ar(1) = \sigma^2$  (avec  $\mathbb{E}(X_{n+2} - aX_n)^2 = \mathbb{E}\varepsilon_{n+2}^2$ ) et avec  $r(1) = 0$  on a  $r(0) = \frac{\sigma^2}{1-a^2}$  d'où  $r(2n) = a^n r(0)$  et  $r(2n+1) = 0$  pour tout  $n \in \mathbf{N}$ .

(e) Soit  $Y^N = (X_3, X_4, \dots, X_N)$  et  $Z^N = (X_1, X_2, \dots, X_{N-2})$ , qui sont deux vecteurs de  $\mathbf{R}^{N-2}$ . On a clairement  $(N-2)Q_N(\alpha)$  qui est la norme au carré pour le produit scalaire classique sur  $\mathbf{R}^{N-2}$  entre  $Y^N$  et  $aZ^N$  donc comme on est en dimension finie le minimum de la distance représente la distance entre  $Y^N$  et le sev de dim engendré par  $Z^N$ : ce minimum existe bien et est unique.

On obtient donc  $\hat{a}_N = ({}^t Z^N Z^N)^{-1} {}^t Z^N Y^N = \left( \sum_{i=1}^{N-2} X_{i+2} X_i \right) \left( \sum_{i=1}^{N-2} X_i^2 \right)^{-1}$ .

(f) On a  $Q_N(a) = \frac{1}{n-2} \sum_{k=3}^n \varepsilon_k^2$ . Comme les  $(\varepsilon_k^2)$  sont des vaid d'espérance finie valant  $\sigma^2$ , d'après la loi forte des grands nombres,  $Q_N(a) \xrightarrow[n \rightarrow +\infty]{p.s.} \sigma^2$ . Comme les  $(\varepsilon_k^2)$  sont également des vaid de variance finie valant  $\mu^4 - \sigma^4$ , d'après le théorème central limite,

on obtient  $\sqrt{N-2}(Q_N(a) - \sigma^2) \xrightarrow[N \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, \mu^4 - \sigma^4)$ . (g) Du fait de la stationarité de  $X$ , on a

$$\begin{aligned} \mathbb{E}Q_N(\alpha) &= \mathbb{E}(X_2 - \alpha X_0)^2 = (1 + \alpha^2)r(0) - 2\alpha r(2) \\ &= \frac{(1 + \alpha^2) - 2\alpha a}{1 - a^2} \sigma^2 = \frac{(\alpha - a)^2 + 1 - a^2}{1 - a^2} \sigma^2. \end{aligned}$$

On voit donc bien que  $Q(\alpha)$  est minimum quand  $\alpha = a$  et donc  $Q(\alpha) > Q(a)$  pour  $\alpha \neq a$ .

Le minimum de la fonction de  $Q$  est donc  $a$ . Or  $Q_N(\alpha)$  tend presque sûrement vers  $Q(\alpha)$  donc le minimum de  $Q_N(\alpha)$ , soit  $Q_N(\hat{a}_N)$  tend presque sûrement vers le minimum des  $Q(\alpha)$  (donc vers  $Q(a)$ ). Or la fonction  $\alpha \mapsto Q_N(\alpha)$  est continue presque sûrement, donc

si  $Q_N(\hat{a}_N) \xrightarrow[N \rightarrow +\infty]{p.s.} Q(a)$  on a bien  $\hat{a}_N \xrightarrow[N \rightarrow +\infty]{p.s.} a$ .

(h) D'après ce qui précède  $Q_N(\hat{a}_N) \xrightarrow[N \rightarrow +\infty]{p.s.} Q(a)$ , donc  $Q_N(\hat{a}_N) \xrightarrow[N \rightarrow +\infty]{p.s.} \sigma^2$ . □

2. **(Sur 14 points)** Soit une chaîne de Markov  $X = (X_t)_{t \in \mathbf{N}}$  homogène prenant les valeurs 1 ou  $-1$  et telle que  $\mathbb{P}(X_1 = 1 \mid X_0 = 1) = p$  et  $\mathbb{P}(X_1 = -1 \mid X_0 = -1) = q$  où  $p$  et  $q$  sont des réels de  $[0, 1]$ . On suppose également que  $X_0$  suit une loi quelconque inconnue.

- (a) Déterminer la matrice de transition de  $X$  **(0.5pts)**. A quelles conditions sur  $p$  et  $q$  cette chaîne est-elle irréductible **(0.5pts)**? On se placera désormais sous ces conditions.
- (b) Déterminer la mesure invariante  $\mu$  de  $X$  **(1pt)**. On suppose désormais que  $X_0$  suit la loi  $\mu$ .
- (c) Montrer que  $\mathbb{E}X_n = \frac{p-q}{2-p-q}$  **(0.5pts)** et calculer  $\text{var}X_n$  pour  $n \in \mathbf{N}$  **(0.5pts)**.
- (d) Montrer que  $\text{cov}(X_0, X_1) = 4 \frac{(1-q)(1-p)(p+q-1)}{(2-p-q)^2}$  **(3pts)**. A quelle condition sur  $p$  et  $q$   $X$  est-il un bruit blanc **(1pt)**?
- (e) On considère le processus  $Y = (Y_n)_{n \in \mathbf{N}}$  modélisant par exemple défini par  $Y_n = aX_n + b + \varepsilon_n$  pour  $n \in \mathbf{N}$ , où  $\varepsilon_i$  est un bruit blanc fort gaussien indépendant de  $(X_n)$  et  $a, b$  deux réels inconnus. Déterminer la tendance, la saisonnalité et la partie bruit  $u = (u_n)_{n \in \mathbf{N}}$  de  $Y$  **(0.5pts)**. Ce bruit est-il stationnaire **(1pt)**? Un bruit blanc **(1pt)**?
- (f) On suppose que l'on observe  $(X_1, \dots, X_N)$  et  $(Y_1, \dots, Y_N)$  et l'on désire estimer  $a$  et  $b$  par régression linéaire. Donner l'expression d'un estimateur  $(\hat{a}_N, \hat{b}_N)$  de  $(a, b)$  (on pourra utiliser les notations  $\bar{X}_N = \frac{1}{N} \sum_{i=1}^N X_i$ ,  $\bar{Y}_N = \frac{1}{N} \sum_{i=1}^N Y_i$ ,  $\bar{\sigma}_X^2 = \frac{1}{N} \sum_{i=1}^N X_i^2 - \bar{X}_N^2$  et  $\bar{\sigma}_{XY} = \frac{1}{N} \sum_{i=1}^N X_i Y_i - \bar{X}_N \bar{Y}_N$ ) **(2pts)**. Montrer que cet estimateur converge **(2.5pts)**.

*Proof.* (a) La matrice de transition de  $X$  est  $P = \begin{pmatrix} q & 1-q \\ 1-p & p \end{pmatrix}$ . La chaîne de Markov est irréductible si tous les états peuvent être visités donc si  $0 \leq p, q < 1$ .

(b) La mesure invariante  $\mu = (\mu_{-1}, \mu_1)$  est telle que  $\mu P = \mu$  soit  $\mu_{-1}(q-1) + (1-p)\mu_1 = 0$  et  $\mu_{-1} + \mu_1 = 1$ . On trouve donc que  $\mu_{-1} = \frac{1-p}{2-p-q}$  et  $\mu_1 = \frac{1-q}{2-p-q}$ .

(c) Comme  $X_0$  a pour loi  $\mu$ ,  $X_n$  a pour loi  $\mu$  pour tout  $n \in \mathbf{N}$ . D'où pour tout  $n \in \mathbf{N}$ , on obtient que  $\mathbb{E}X_n = \frac{p-q}{2-p-q}$  et

$$\text{var}X_n = 1 - (\mathbb{E}X_n)^2 = \frac{(2-p-q)^2 - (p-q)^2}{(2-p-q)^2} = 4 \frac{(1-p)(1-q)}{(2-p-q)^2}.$$

(d)  $\mathbb{E}X_0 X_1 = (P(X_0 = 1 \cap X_1 = 1) + P(X_0 = -1 \cap X_1 = -1) - (P(X_0 = 1 \cap X_1 = -1) + P(X_0 = -1 \cap X_1 = 1))$ , soit  $\mathbb{E}X_0 X_1 = P(X_0 = 1)(2p-1) + P(X_0 = -1)(2q-1) = \frac{(1-q)(2p-1) + (1-p)(2q-1)}{2-p-q} = \frac{3(p+q) - 4pq - 2}{2-p-q}$ . Ainsi on en déduit

$$\text{cov}(X_0, X_1) = \frac{(3(p+q) - 4pq - 2)(2-p-q) - (p-q)^2}{(2-p-q)^2} = 4 \frac{(1-q)(1-p)(p+q-1)}{(2-p-q)^2}.$$

Ainsi  $\text{cov}(X_0, X_1) = 0$  si et seulement si  $p+q=1$ . Mais si  $p+q=1$ , on a également  $P(X_1 = \pm 1 \mid X_0 = \pm 1) = P(X_1 = \pm 1)$  donc  $X_1$  est indépendant de  $X_0$ . Comme  $X_2$  ne dépend en loi que de  $X_1$  on en déduit que  $X_2$  est aussi indépendant de  $X_0$  et par itération les  $X_i$  sont tous indépendants:  $X$  est alors un bruit blanc fort lorsque  $\mathbb{E}X_0 = 0$  soit  $p=q=1/2$ .

(e) On a  $\mathbb{E}Y_n = a \frac{p-q}{2-p-q} + b$  donc  $Y$  admet pour tendance  $a \frac{p-q}{2-p-q} + b$  et pas de saisonnalité. Le bruit  $u$  vérifie  $u_n = a(X_n - \mathbb{E}X_n) + \varepsilon_n$  donc comme  $X$  et  $\varepsilon$  sont indépendants, comme  $X - \mathbb{E}X_0$  et  $\varepsilon$  sont stationnaires, on en déduit que  $u$  est stationnaire. En revanche,  $u$  est un bruit blanc si et seulement si  $p+q=1$ .

(f) Après de simples calculs, on obtient  $\begin{pmatrix} \hat{a}_N \\ \hat{b}_N \end{pmatrix} = \begin{pmatrix} \bar{\sigma}_{XY} / \bar{\sigma}_X^2 \\ \bar{Y}_N - \bar{X}_N \bar{\sigma}_{XY} / \bar{\sigma}_X^2 \end{pmatrix}$ .

On a  $\bar{X}_N \xrightarrow[N \rightarrow +\infty]{p.s.} \mathbb{E}X_0$  d'après le Théorème ergodique,  $\bar{Y}_N = a\bar{X}_N + b + \bar{\varepsilon}_N \xrightarrow[N \rightarrow +\infty]{p.s.} a\mathbb{E}X_0 + b$  d'après le Théorème ergodique et la LFGN pour  $(\varepsilon_i)$ ,  $\bar{\sigma}_X^2 \xrightarrow[N \rightarrow +\infty]{p.s.} \text{var}(X_0)$  d'après le Théorème ergodique et enfin  $\bar{\sigma}_{XY} = a\bar{\sigma}_X^2 + \bar{X}_N \bar{\varepsilon}_N \xrightarrow[N \rightarrow +\infty]{p.s.} \text{var}(X_0)$  d'après le Théorème ergodique et la LFGN. Donc  $\hat{a}_N \xrightarrow[N \rightarrow +\infty]{p.s.} a$  et  $\hat{b}_N \xrightarrow[N \rightarrow +\infty]{p.s.} b$ .  $\square$