

## Examen du 27 Janvier 2011 de 9h30 à 12h30

*Les notes de cours sont autorisées. Les calculatrices sont autorisées.*

### 1 Choix de Modèles

Pour  $n \geq 2$ , on considère le modèle linéaire gaussien de dimension  $2n \times 3$ ,  $Y = X\theta^* + \varepsilon$  où  $\varepsilon \sim \mathcal{N}_{2n}(0, \sigma_*^2)$ ,

$$X := \begin{pmatrix} 1 & -1 & 1 \\ 1 & 1 & 1 \\ \vdots & \vdots & \vdots \\ 1 & (-1)^n & 1 \\ 1 & (-1)^{n+1} & -1 \\ 1 & (-1)^{n+2} & -1 \\ \vdots & \vdots & \vdots \\ 1 & (-1)^{2n} & -1 \end{pmatrix} \quad \text{et } \theta^* := \begin{pmatrix} \theta_1^* \\ \theta_2^* \\ \theta_3^* \end{pmatrix}.$$

Dans tout l'exercice on suppose que l'on a  $\theta_1^* = \theta_3^* = 0$ . Evidemment l'observateur des résultats du modèle, le dénomé Jack Istique ne le sait pas et va chercher à le découvrir par différents moyens.

1. Montrer que le modèle précédent rentre dans le cadre du modèle linéaire gaussien régulier. Calculer les estimateurs du maximum de vraisemblance  $\widehat{\theta}_n$  et  $\widehat{\sigma}_n^2$  de  $\theta^*$  et  $\sigma_*^2$ .
2. Montrer que  $\widehat{\theta}_n$  converge presque sûrement, quand  $n$  tend vers l'infini, vers  $\theta^*$ .
3. Quelle est la loi jointe de  $(\sqrt{2n}(\widehat{\theta}_n - \theta^*), 2n\frac{\widehat{\sigma}_n^2}{\sigma_*^2})$ ? Décrire les régions de confiance pour  $\theta^*$  et  $\sigma_*^2$ .
4. Pour  $J \subset \{1, 2, 3\}$ , on pose  $\theta_J^* := (\theta_j^*)_{j \in J}$ . Pour  $J \subset \{1, 2, 3\}$  et  $J \neq \emptyset$ , décrire précisément la procédure de test de  $H_0 \quad \theta_J^* = 0$  contre  $H_1 \quad \theta_J^* \neq 0$ .
5. On se propose de comparer les stratégies de choix de modèles du  $C_p$  de Mallows avec BIC. Rappelons tout d'abord les fonctions d'objectifs associées. Pour  $J \subset \{1, 2, 3\}$ ,  $|J|$  désigne le nombre d'éléments de  $J$  et  $\widehat{\sigma}_{n,J}^2$  la variance estimée par maximum de vraisemblance dans le modèle à  $|J|$  paramètres où le paramètre intervenant dans la moyenne des observations est  $\theta_J$ . On a alors

$$C_p(J) := \frac{\widehat{\sigma}_{n,J}^2}{\widehat{\sigma}_n^2} + \frac{|J|}{n},$$

$$BIC(J) := \log(\widehat{\sigma}_{n,J}^2) + \frac{\log 2 + \log n}{2n} |J|.$$

Rappelons que l'on se place dans le cas où  $J^* = \{2\}$ . Les questions qui suivent seront traitées pour le BIC et  $C_p$  de Mallows

- Calculer la probabilité de sous-ajustement ainsi que sa limite quand  $n$  tend vers l'infini.
- Pour chacun des 3 sous-ensembles  $J$  de  $\{1, 2, 3\}$  qui sur-ajustent  $J^*$  calculer les probabilités de se tromper de modèle en sélectionnant le modèle  $J$ . Calculer les limites, quand  $n$  tend vers l'infini, de ces probabilités.
- On rappelle que si  $A$  et  $B$  sont des ensembles mesurables on a  $\mathbb{P}(A \cup B) \leq \mathbb{P}(A) + \mathbb{P}(B)$ . Donner un majorant de la probabilité de sur-ajustement et déterminer la limite, quand  $n$  tend vers l'infini, de cette borne.
- Que pensez-vous des critères BIC et  $C_p$  de Mallows pour le modèle étudié ici ?

## 2 Loi des Extrêmes

Soit  $X_1, \dots, X_n$  des variables i.i.d. de loi de Cauchy. On rappelle que la loi de Cauchy a pour densité par rapport à la mesure de Lebesgue sur  $\mathbb{R}$  :

$$f(x) = \frac{1}{\pi(1+x^2)}, \quad (x \in \mathbb{R}).$$

1. Calculer la fonction de répartition de  $X_1$  notée  $F$ .
2. La fonction caractéristique de  $X_1$  vaut pour  $t \in \mathbb{R}$ ,  $\exp(-|t|)$ . Quelle est la loi de la moyenne empirique de  $X_1, \dots, X_n$  ? Quelle est la loi de l'inverse de la moyenne empirique de  $X_1, \dots, X_n$  ?

3. On considère la fonction

$$\psi(x) := \tan(x) + \tan\left(\frac{1}{x}\right),$$

définie sur  $\mathbb{R}_*$ . Calculer la dérivée de  $\psi$  sur  $\mathbb{R}_*$  et en déduire que cette fonction ne prend que 2 valeurs distinctes. Soit  $x \in \mathbb{R}$  et un entier naturel  $n > x$ , on pose  $u_n(x) := (1 + \frac{x}{n})^n$ . Calculer la limite, quand  $n$  tend vers l'infini, de  $u_n(x)$ .

4. On pose maintenant, pour  $n \geq 1$ ,  $X_{(n)} := \max_{i=1 \dots n} X_i$ . Pour  $t \in \mathbb{R}$ , calculer la fonction de répartition de  $X_{(n)}$ . On note  $F_{X_{(n)}}$  cette fonction de répartition. En utilisant la question précédente montrer que

$$\begin{aligned} \lim_{n \rightarrow \infty} F_{X_{(n)}}(nu) &= \exp\left(-\frac{1}{\pi u}\right), \quad (u > 0), \\ \lim_{n \rightarrow \infty} F_{X_{(n)}}(nu) &= 0, \quad (u \leq 0). \end{aligned}$$

En déduire que  $n^{-1}X_{(n)}$  converge en loi vers une loi  $G$  à préciser.

5. Soit  $Y_1, \dots, Y_n$  des variables i.i.d. de loi exponentielle de paramètre 1. Montrer que  $Y_{(n)} - \log n$  converge en loi vers une loi  $H$  à préciser.

## 3 Séries chronologiques

Soit  $(\varepsilon_n)_{n \in \mathbb{Z}}$  une suite de variables i.i.d. de loi normale standard. Soit  $a \in \mathbb{R}$ , on considère le processus  $(X_n)_{n \in \mathbb{Z}}$  défini par l'équation de récurrence :

$$X_{n+1} := \varepsilon_n + a\varepsilon_{n+1}, \quad (n \in \mathbb{N}).$$

1. Calculer pour  $n, h \in \mathbb{Z}$   $\text{cov}(X_n, X_{n+h})$ . Montrer que  $(X_n)_{n \in \mathbb{Z}}$  est un processus gaussien stationnaire.
2. Quelle est la densité spectrale de ce processus.
3. Soit  $N$  un entier naturel non nul. Exprimer  $(X_1, \dots, X_N)$  en fonction de  $(\varepsilon_0, \dots, \varepsilon_N)$  puis  $(\varepsilon_0, \dots, \varepsilon_N)$  en fonction de  $(\varepsilon_0, X_1, \dots, X_N)$ . Déterminer la densité du vecteur aléatoire  $(\varepsilon_n)_{n=0, \dots, N}$ . En déduire la densité du vecteur aléatoire  $(\varepsilon_0, (X_n)_{n=1, \dots, N})$  puis celle de  $(X_n)_{n=1, \dots, N}$ .
4. Soit  $\Gamma_n$  la matrice de variance covariance du vecteur  $(X_n)_{n=1, \dots, N}$ . En utilisant la question précédente, déterminer  $\Gamma_n^{-1}$ .
5. On observe  $(X_n)_{n=1, \dots, N}$ , déterminer très précisément la loi conditionnelle de  $X_{N+1}$  sachant cette observation. On désire estimer le paramètre  $a$ . Utiliser la covariance empirique  $\hat{r}_N(1) := (N-1)^{-1} \sum_{j=1}^{N-1} X_j X_{j-1}$  pour bâtir un estimateur empirique  $\hat{a}_N$  de  $a$ . Ecrire la vraisemblance associée aux observations  $(X_n)_{n=1, \dots, N}$ . L'estimateur du maximum de vraisemblance est-il calculable ?
6. Montrer que  $\hat{a}_N$  est un estimateur sans biais et qu'il converge en probabilité vers  $a$ .