

Examen du 21 janvier 2003, 13h05-16h05

**SE 203: ESTIMATION ET INTRODUCTION AUX TESTS**  
ENSAE, Paul Doukhan

Les documents distribués en cours et les notes manuscrites ainsi que les calequettes sont autorisés. On traitera les exercices dans un ordre arbitraire, à la condition de le préciser clairement. On pose  $\Phi(x) = \int_{-\infty}^x e^{-x^2/2} \frac{dx}{\sqrt{2\pi}}$ , et  $\bar{\Phi}(x) = 1 - \Phi(x)$  est la fonction de queue gaussienne. **Barème indicatif:** 1 point par question, sauf les questions A-7 et D-5 qui en compteront 2.

**Exercice A** (Modèle exponentiel)

Soit  $X_1, X_2, \dots$ , une suite iid de loi exponentielle de paramètre  $\lambda$ . On rappelle que leur densité s'écrit  $\lambda e^{-\lambda x}$  pour  $x \geq 0$ .

1. Calculez la vraisemblance de l'échantillon  $X^{(n)} = (X_1, \dots, X_n)$ . En déduire une statistique  $S$  exhaustive; on prouvera que cette statistique est complète.
2. Déterminez l'estimateur du maximum de vraisemblance fondé sur cet échantillon,
3. l'information de Fischer correspondante.
4. Ce modèle est-il régulier, si  $\lambda \geq 0$ , si  $\lambda > 0$ ?
5. L'estimateur du maximum de vraisemblance précédent est-il efficace?
6. Asymptotiquement efficace?
7. Calculez la densité  $f_n$  de la loi de  $S = X_1 + \dots + X_n$ . Indiquez l'intérêt de ce calcul: en particulier, expliquez pourquoi et de quelle manière il pourrait permettre d'obtenir des estimateurs de  $\lambda$  de bonne qualité (on ne demande pas de calculer explicitement de tels estimateurs).

**Exercice B** (Paramètre de translation)

On s'intéresse au problème d'estimation du paramètre de translation  $\theta \in \mathbb{R}$  dans le modèle de densité (sur  $\mathbb{R}$ )  $f_\theta(x) = f_0(x - \theta)$  donné par une densité  $f_0$  (fixée, une fois pour toutes). On observe ainsi un  $n$ -échantillon iid  $X = (X_1, \dots, X_n)$  de loi  $f_\theta$ , où  $f_0(x) \neq 0$  p.s.,  $\int x f_0(x) dx = 0$  et  $\int x^2 f_0(x) dx = 1$ .

1. Déterminez la densité  $p_\theta$  et la vraisemblance  $V_\theta = p_\theta(X)$  du  $n$ -échantillon  $X = (X_1, \dots, X_n)$ .
2. Etablir des conditions sur  $f_0$  pour que ce modèle soit régulier. Ecrire l'information de Fisher de ce modèle.
3. Montrez que la borne de Cramer Rao s'écrit simplement à partir de l'inégalité de Cauchy Schwartz dans ce cas.
4. Prouvez que l'estimateur  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  est efficace si et seulement si  $f_0(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$  est la densité gaussienne standard.
5. Dans le cas général, prouvez que cet estimateur est sans biais et la normalité asymptotique de  $\sqrt{n}(\bar{X} - \theta)$  sous la loi  $P_\theta$ .

**Exercice C** (*Détection d'un signal*)

Une antenne est réglée pour recevoir des signaux à une fréquence donnée. A chaque instant, elle reçoit une onde  $S$  d'amplitude  $f(t)$ . Cette amplitude est générée, soit par le signal, soit pour le bruit électromagnétique ambiant, les données sont collectées aux temps  $T/N, 2T/N, \dots, N$ . Le modèle stochastique choisi est le suivant. Si  $S$  n'a pas émis de signal, on reçoit une amplitude  $X_i = \xi_i \sim \mathcal{N}(0, \sigma_\xi^2)$  au temps  $iT/N$ . Si  $S$  a émis un signal, l'amplitude de ce signal est modélisée par une variable aléatoire  $\eta_i \sim \mathcal{N}(0, \sigma_\eta^2)$ ; on reçoit alors un signal d'amplitude  $X_i = \xi_i + \eta_i$  au temps  $iT/N$ . Les suites  $\xi_i$  et  $\eta_i$  sont mutuellement indépendantes. On suppose que les paramètres  $\sigma_\xi^2$  et  $\sigma_\eta^2$  sont connus.

1. Définir un modèle statistique paramétré par  $\theta \in \{0,1\}$  rendant compte de ces observations; calculez sa vraisemblance.
2. Construire le test de Neyman-Pearson de niveau  $\alpha$  pour décider de l'hypothèse  $H_0$  (l'observation est un bruit blanc pur), contre  $H_1 = H_0^c$  (l'hypothèse contraire). Précisez sa puissance (on notera que ce test au niveau  $\alpha$  est donné par un quantile de loi du  $\chi_N^2$  à  $N$  degrés de liberté).
3. Lorsque  $N$  est grand, donnez l'approximation  $\tilde{\beta}$  de la puissance fondée sur le théorème de limite centrale.
4. Alors, comment choisir  $N$  pour que ce test soit asymptotiquement non biaisé? On pourra utiliser le comportement asymptotique d'une loi du  $\chi_N^2$  lorsque  $N \uparrow \infty$ .
5. Lorsque  $N$  est grand, montrez qu'il existe une constante  $C > 0$  telle que la différence d'un  $\alpha$ -quantile de loi du  $\chi_N^2$  et du quantile gaussien correspondant est de valeur absolue  $\leq CN^{-1/8}$  (uniformément par rapport à  $\alpha$ ).

**Exercice D** (*Une variante du modèle Tobit*)

Soit  $(\xi_n)_{n \in \mathbb{N}}$  une suite iid réelle de fonction de répartition  $F : \mathbb{R} \rightarrow ]0,1[$ . On suppose la fonction  $F$  bijective. On pose  $Y_n = \sigma \xi_n + m$  pour  $n \in \mathbb{N}$ . On considère le modèle statistique  $(P_\theta^{\otimes n})_{\theta \in \Theta}$ , loi du  $n$ -uplet  $(X_1, \dots, X_n)$  où  $X_i$  vaut 0 lorsque  $Y_i < 0$ , 1 si  $Y_i \in [0,1]$  et 2, sinon, de plus  $\Theta$  est l'ensemble des couples  $\theta = (m, \sigma) \in \mathbb{R} \times \mathbb{R}^{+*}$ .

1. Traduisez la propriété de  $F$  en termes de la loi de  $\xi_1$ .
2. Prouvez que le modèle est identifiable.  
Soient  $S = \{(p_A, p_B, p_C) \in (\mathbb{R}^+)^3 \mid p_A + p_B + p_C = 1\}$ , le simplexe de dimension 3 et sa tranche  $T = \{(p_A, p_C) \in (\mathbb{R}^+)^2 \mid p_A + p_C \leq 1\}$ . Alors  $S$  est en bijection avec  $T$  en vertu de la relation  $p_B = 1 - p_A - p_C$ . Posons  $p_A = \mathbb{P}(Z_1 < 0)$ ,  $p_B = \mathbb{P}(Z_1 \in [0,1])$  et  $p_C = \mathbb{P}(Z_1 > 1)$ . Pour prouver que le modèle est identifiable, on pourrait, par exemple, montrer que la fonction  $K : S \rightarrow \Theta$ , définie par  $(p_A, p_C) \mapsto \theta = K(p_A, p_C)$  est bijective.
3. Montrez que l'estimateur du maximum de vraisemblance  $\theta_n$  de  $\theta$  s'écrit  $\hat{\theta} = K(\hat{p}_A, \hat{p}_C)$  pour des estimations par maximum de vraisemblance  $\hat{p}_A, \hat{p}_C$  que l'on précisera.
4. Déterminez les propriétés asymptotiques de  $(\hat{p}_A, \hat{p}_C)$  lorsque  $n \rightarrow \infty$ .  
Comment en déduiriez-vous un test de l'hypothèse  $\theta = \theta_0$  contre  $\theta \neq \theta_0$ .
5. Que se passe-t-il lorsque la variable  $X_i$  prend 2 valeurs (0, ou 1) selon que  $Y_i < 0$  ou  $Y_i \geq 0$ ? Et lorsqu'elle prend 4 valeurs ( $X_i = 2$  si  $1 < Y_i \leq 2$  et  $X_i = 3$  pour  $Y_i > 2$ )? Ces modèles sont-ils identifiables, que dire de leur estimateur du maximum de vraisemblance?

## Corrigé de l'examen SE203, session 2002-2003

### Exercice A (*Modèle exponentiel*)

1.  $\log p_\lambda(x) = n \log \lambda - \lambda(x_1 + \dots + x_n)$ , donc  $S = X_1 + \dots + X_n$  est une statistique exhaustive, on voit facilement qu'elle est complète.
2. De plus,  $\dot{L}_\lambda(x) = n/\lambda - (x_1 + \dots + x_n)$ , s'annule lorsque  $\lambda = 1/\bar{x}$  et  $\hat{\lambda} = 1/\bar{X}$
3. Pour  $n = 1$ , on obtient  $I_1(\lambda) = \text{Var}_\lambda X_1 = 2/\lambda^2 - 1/\lambda^2 = 1/\lambda^2$ , donc  $I_n(\lambda) = \frac{n}{\lambda^2}$ .
4. Le modèle est régulier, si  $\lambda > 0$  mais pas si  $\lambda \geq 0$ .

5. L'estimateur du maximum de vraisemblance est biaisé dans ce cas: l'inégalité de Cauchy Schwartz implique en effet que  $\mathbb{E}_\lambda \hat{\lambda} \mathbb{E}_\lambda \bar{X} > 1$ , (car  $1 = \sqrt{\hat{\lambda}} \cdot \sqrt{\bar{X}}$ ), le fait que  $(\bar{X})^2$  n'est pas constant implique que l'inégalité est stricte. Par suite la borne de Cramer Rao ne s'applique pas ici, un calcul direct prouve qu'il n'est pas efficace (la totalité des points sera accordée avec l'une des ces deux réponses).

De fait, le calcul (qui utilise la loi déterminée en question 7) prouve que  $\text{Var}_\lambda \hat{\lambda} = \frac{n^2 \lambda^2}{(n-1)^2 (n-2)} > \frac{\lambda^2}{n} = I_n^{-1}(\lambda)$ . Notons enfin que  $\lim_n n \text{Var}_\lambda \hat{\lambda} = I_1^{-1}(\lambda)$  (bien que cette propriété ne soit pas l'efficacité asymptotique).

6. C'est un résultat du cours, mais pour le prouver, on peut écrire,

$$\sqrt{n} \left( \frac{1}{\bar{X}} - \lambda \right) = \sqrt{n} \left( \frac{\bar{X}}{(\bar{X})^2} - \frac{\lambda^2}{\lambda} \right)$$

le lemme de Slutsky permet de conclure avec la relation  $\mathbb{E}_\lambda X_1 = \frac{1}{\lambda}$ .

7. On calcule par récurrence  $f_n(x) = \frac{\lambda^n}{(n-1)!} x^n e^{-\lambda x}$  pour  $x \geq 0$  (on peut aussi noter que  $2\lambda X_1 \sim \gamma(1, 1/2)$  et utiliser l'additivité de ces lois). La statistique  $S$  est exhaustive (question 1) donc un bon estimateur de  $\lambda$  s'écrit sous la forme  $T = g(S)$ , pour obtenir un estimateur optimal, on pourrait minimiser  $R_\lambda(T) = \mathbb{E}_\lambda (g(S) - \lambda)^2$  ou son risque bayésien  $\int R_\lambda(T) d\nu(\lambda)$ . Dans le cas d'une mesure  $\nu$ , exponentielle, elle aussi, les calculs sont possibles lorsque l'on a des éléments de calcul des variations. De tels calculs n'ont d'intérêt que pour des estimateurs biaisés ou pas réguliers en vertu de la borne FDRC.

### Exercice B (*Paramètre de translation*)

1.  $V_\theta = p_\theta(X) = \prod_i f_0(X_i - \theta)$ .
2. Il suffit que  $f_0$  soit dérivable et  $I = \int f_0'^2 / f_0 < \infty$  (en réalité, l'absolue-continuité de  $f_0$  qui implique la dérivabilité p.s., et équivaut au fait que la dérivée définie p.s. soit intégrable, suffit avec cette condition). L'information de Fisher de ce modèle vaut  $nI$ .
3. Comme  $\int x f_0(x) dx = 0$ , on a

$$\text{Var}_\theta X_1 = \int x^2 f_\theta(x) dx = \int ((x + \theta)^2 - \theta^2) f_0(x) dx = \int x^2 f_0(x) dx$$

et, puisque  $\int x f_0'(x) dx = -\int f_0(x) dx = -1$  (intégration par parties), l'inégalité FDCR s'écrit ainsi

$$1 = \left( \int \left( \frac{f_0'(x)}{f_0(x)} \cdot x \right) f_0(x) dx \right)^2 \leq \int \left( \frac{f_0'(x)}{f_0(x)} \right)^2 f_0(x) dx \int x^2 f_0(x) dx$$

4. L'efficacité dans l'inégalité de Schwartz a lieu lorsque les fonctions  $\frac{f_0'}{f_0}$  et  $x \mapsto x$  sont proportionnelles.
5. C'est le TLC.

**Exercice C** (*Détection d'un signal*)

1. La densité du modèle s'écrit avec  $\theta = 0$  ou  $\theta = 1$  selon qu'on est dans l'hypothèse nulle  $H_0$  d'un bruit pur ou l'hypothèse  $H_1$  d'un signal bruité.

$$\log p_\theta(x) = -\frac{N}{2} \log(2\pi(\sigma_\xi^2 + \theta\sigma_\eta^2)) - \frac{1}{\sigma_\xi^2 + \theta\sigma_\eta^2} \sum_{i=1}^N X_i^2$$

2. Donc

$$\log \frac{p_1(x)}{p_0(x)} = -\frac{N}{2} \log \left( \frac{\sigma_\xi^2}{\sigma_\eta^2} + 1 \right) + \frac{\sigma_\eta^2}{\sigma_\xi^2(\sigma_\xi^2 + \sigma_\eta^2)} \sum_{i=1}^N X_i^2$$

ainsi le test rejette l'hypothèse nulle lorsque  $\sum_{i=1}^N X_i^2 > \sigma_\xi^2 \chi_{N,1-\alpha}^2$ . La puissance du test vaut  $\beta = \mathbb{P} \left( (\sigma_\xi^2 + \sigma_\eta^2) \chi_N^2 \geq \sigma_\xi^2 \chi_{N,1-\alpha}^2 \right)$

3. La fonction  $\Phi(x)$  est croissante et  $(\Phi(z) \geq \alpha \Leftrightarrow z \geq \varphi_\alpha)$ .

On utilise l'approximation  $\chi_{N,1-\alpha}^2 \simeq \tilde{\chi}_{N,1-\alpha}^2 = N + \sqrt{2N} \varphi_{1-\alpha}$  obtenue via le TLC; en effet les valeurs  $\mathbb{E} \chi_N^2 = 1, \text{Var} \chi_N^2 = 2$  s'obtiennent rapidement grâce à des intégrations par parties.

Ainsi, en posant  $\rho = \frac{\sigma_\xi^2}{\sigma_\xi^2 + \sigma_\eta^2}$ , on réécrit

$$\beta = \mathbb{P} \left( \chi_N^2 \geq \rho \chi_{N,1-\alpha}^2 \right) = \mathbb{P} \left( \frac{\chi_N^2 - N}{\sqrt{2N}} \geq \frac{\rho \chi_{N,1-\alpha}^2 - N}{\sqrt{2N}} \right)$$

et l'approximation de la puissance est donc

$$\tilde{\beta} = \bar{\Phi} \left( \frac{\rho \tilde{\chi}_{N,1-\alpha}^2 - N}{\sqrt{2N}} \right) = \bar{\Phi} \left( \frac{\sigma_\xi^2 \varphi_{1-\alpha} - \sigma_\eta^2 \sqrt{\frac{N}{2}}}{\sigma_\xi^2 + \sigma_\eta^2} \right)$$

4. Donc le test est asymptotiquement sans biais lorsque

$$\frac{\sigma_\xi^2 \varphi_{1-\alpha} - \sigma_\eta^2 \sqrt{\frac{N}{2}}}{\sigma_\xi^2 + \sigma_\eta^2} \leq \varphi_\alpha = -\varphi_{1-\alpha}$$

c'est-à-dire  $\sqrt{\frac{N}{2}} \geq \varphi_{1-\alpha} \left(1 + 2\frac{\sigma_\xi^2}{\sigma_\eta^2}\right)$ .

On obtient donc  $\tilde{\beta} \geq \alpha$  lorsque

$$N > 2 \left( \varphi_{1-\alpha} \left(1 + 2\frac{\sigma_\xi^2}{\sigma_\eta^2}\right) \right)^2,$$

5. est une variante du théorème 1.2 du cours polycopié, on y remplace les variables de Bernoulli par des carrés de gaussiennes indépendantes .

**Exercice D** (Une variante du modèle Tobit)

1. La fonction  $F : \mathbb{R} \rightarrow ]0,1[$  est alors continue et d'inverse continue. De plus, la loi de  $\xi_1$  est sans atome ( $\mathbb{P}(\xi_1 = x) = 0$  pour tout  $x \in \mathbb{R}$ ) et charge tout intervalle ( $\mathbb{P}(\xi_1 \in ]a,b]) > 0$  pour  $a < b$ ).

En termes de loi, ceci signifie (de manière peu parlante) que la loi de  $\xi_1$  est une mesure équivalente à la mesure de Lebesgue. Pour finir, rappelons que l'existence d'une densité n'est là que pour simplifier les conditions: il existe des loi continues et non absolument continues comme celle de Cantor

Seule l'hypothèse  $F$  bijective sera utilisée par la suite.

2. On a  $p_A = F(-m/\sigma)$ ,  $p_C = 1 - F((1-m)/\sigma)$ . La loi de  $(X_1, \dots, X_n)$  s'écrit

$$\mathbb{P}_\theta((X_1, \dots, X_n) = (x_1, \dots, x_n)) = P_\theta(x_1, \dots, x_n) = p_A^{n_A} p_B^{n_B} p_C^{n_C},$$

avec  $n_A = \sum_i \mathbb{1}_{(x_i=0)}$ ,  $n_B = \sum_i \mathbb{1}_{(x_i=1)}$  et  $n_C = \sum_i \mathbb{1}_{(x_i=2)}$ . Posons  $a = F^{-1}(p_A)$ ,  $c = F^{-1}(1 - p_C)$ , alors  $m + a\sigma = 0, m + c\sigma = 1$  donc  $\sigma = 1/(c-a)$ ,  $m = -a/(c-a)$ . L'application  $\theta \mapsto (p_A, p_C)$  est donc bijective et le modèle est identifiable.

3. On trouve  $\hat{p}_A = N_A/n$ ,  $\hat{p}_B = N_B/n$  et  $\hat{p}_C = N_C/n$  avec des notations évidentes donc

$$\hat{\sigma} = \frac{1}{F^{-1}\left(\frac{n-N_C}{n}\right) - F^{-1}\left(\frac{N_A}{n}\right)}, \hat{m} = \frac{-F^{-1}\left(\frac{N_A}{n}\right)}{F^{-1}\left(\frac{n-N_C}{n}\right) - F^{-1}\left(\frac{N_A}{n}\right)}$$

4. On a  $\sqrt{n}(\hat{p}_A - p_A, \hat{p}_C - p_C) \rightarrow \mathcal{N}_2(0, \Sigma)$  pour  $\Sigma$ , la matrice de covariance ( $2 \times 2$ ) du couple  $(\mathbb{1}_{(Z_1 < 0)}, \mathbb{1}_{(Z_1 > 1)})$ . Un test asymptotique de l'hypothèse  $\theta = \theta_0$  contre  $\theta \neq \theta_0$  suit du TLC  $\sqrt{n}(\hat{p}_A - p_A^0, \hat{p}_C - p_C^0) \rightarrow \mathcal{N}_2(0, \Sigma)$  obtenu lorsque  $(p_A^0, p_C^0) = K^{-1}(\theta_0)$ .

La normalité asymptotique de  $\sqrt{n}(\hat{\theta} - \theta)$  suit aussi du TLC précédent pour  $(\hat{p}_A, \hat{p}_C)$  et du lemme de Slutsky car  $K$  est différentiable; elle permet de déterminer un test analogue.

5. – Dans le premier cas, l'application  $\theta \mapsto p_A$  n'est plus injective lorsque l'on pose  $p_A = \mathbb{P}(Z_1 < 0)$ . De plus tous les couples tels que  $F\left(-\frac{m}{\sigma}\right) = \frac{N_A}{n}$  sont des estimateurs du maximum de vraisemblance, qui existe mais n'est pas unique. On peut même paramétrer l'ensemble  $EMV$  de ces estimateurs

$$EMV = \left\{ \left( -tF^{-1}\left(\frac{N_A}{n}\right), t \right) \mid t \in \mathbb{R} \right\}$$

- Dans le second cas, avec des notations analogues aux précédentes, l'application  $\theta \mapsto H(\theta) = (p_A, p_B, p_C, p_D)$  n'est plus surjective et l'estimateur du maximum de vraisemblance n'existe plus forcément: Il existe si et seulement si

$$\left( \frac{N_A}{n}, \frac{N_B}{n}, \frac{N_C}{n}, \frac{N_D}{n} \right) \in H(\Theta)$$

De plus, lorsque  $F$  est dérivable (la loi de  $\xi_1$  a une densité), l'image  $H(\Theta)$  est une sous-variété différentiable de dimension 2 dans  $\mathbb{R}^4$ , elle est donc d'intérieur vide dans le simplexe de dimension 4,  $S_4 = \{(p_A, p_B, p_C, p_D) \in (\mathbb{R}^+)^4 \mid p_A + p_B + p_C + p_D = 1\}$ , qui est une variété (à bords) de dimension 3 (car il est homéomorphe à sa tranche  $T_3 = \{(p_A, p_B, p_C) \in (\mathbb{R}^+)^3 \mid p_A + p_B + p_C \leq 1\}$  qui est d'intérieur non vide, en vertu de la relation  $p_D = 1 - (p_A + p_B + p_C)$ ).

Il est alors toujours unique: un tel estimateur est aussi estimateur du maximum de vraisemblance dans le modèle déjà étudié; en effet, en posant  $\tilde{X}_i = \min\{X_i, 2\}$ , on retombe précisément sur la suite envisagée dans les questions précédentes.

**Remarque.** Notez que les questions sont de difficulté essentiellement croissante; la dernière question trouve des réponses diverses dont on ne s'étonnera pas si elles manipulent des notions qui ne vous sont pas familières. Le barème autorise la note maximale sans la traiter.

#### Barème indicatif

**Exercice A** sur (9) points

chaque question est notée 1 point, sauf les questions 5 et 7.

**Exercice B** sur 5 points

chaque question est notée 1 point.

**Exercice C** sur 5 points

chaque question est notée 1 point.

**Exercice D** sur (5+1) points

chaque question est notée 1 point, sauf la dernière pour laquelle 1 point additionnel peut être envisagé.