

# STATISTIQUE NON-ASYMPTOTIQUE - EXAMEN

14 décembre 2016, 9h-12h.

Les appareils électroniques et les documents ne sont pas autorisés. Le sujet comporte **deux** pages.

## Partie 1. Statistique paramétrique (S. Pergamenchtchikov)

### 1. Simple nonrandom regression (4 points)

1. Give the definition for the simple nonrandom regression model with unknown parameter  $\lambda$ .
2. Show that the least square estimator  $\widehat{\lambda}_n$  is optimal in the mean square accuracy sense in the class of all unbiased linear estimators, i.e. for any  $n \geq 1$

$$\mathbf{E}(\widehat{\lambda}_n - \lambda)^2 \leq \mathbf{E}(\widetilde{\lambda}_n - \lambda)^2,$$

where  $\widetilde{\lambda}_n$  is a linear estimator constructed on the  $n$  observations.

### 2. Sequential estimation (4 points)

Let us  $(y_j)_{j \geq 1}$  be the first order autoregressive process defined as

$$y_j = \lambda y_{j-1} + \xi_j, \quad y_0 = 0.$$

Here  $\lambda$  is an unknown constant parameter,  $(\xi_j)_{j \geq 1}$  is i.i.d. sequence of random variables with  $\mathbf{E} \xi_j = 0$  and  $\mathbf{E} \xi_j^2 = 1$ . We set  $\mathcal{F}_0 = \{\emptyset, \Omega\}$  and  $\mathcal{F}_j = \sigma\{y_1, \dots, y_j\}$  for any  $j \geq 1$ .

Let for some  $H > 0$

$$\tau_H = \inf\{n \geq 1 : \sum_{j=1}^n y_{j-1}^2 \geq H\}.$$

1. Show that  $\mathbf{P}(\tau_H < \infty) = 1$  for any  $H > 0$ .
2. Give the definition for the stopping times. Show that for any  $H > 0$  the moment  $\tau_H$  is the stopping time with respect to  $(\mathcal{F}_j)_{j \geq 0}$ .
3. Write the sequential estimator for the parameter  $\lambda$ .

### 3. Tests (2 points)

Let us  $(X_j)_{j \geq 1}$  be an i.i.d. sequence of random variables having a density.

1. Write the test problem in the sequential setting.
2. Write the Wald test.

## Partie 2. Statistique non-paramétrique (G. Chagny)

### Question de cours (1 point).

On observe  $(X_i)_{i=1, \dots, n}$  un échantillon de variables indépendantes identiquement distribuées de densité  $f$  inconnue appartenant à  $L^2(I)$ , pour  $I$  un intervalle de  $\mathbb{R}$ . Donner la définition de l'estimateur de  $f$  obtenu par la méthode de projection sur un sous espace vectoriel  $S_D \subset L^2(I)$  engendré par une base orthonormée  $\{\varphi_1, \dots, \varphi_D\}$ , (avec  $\varphi_j : I \rightarrow \mathbb{R}$ ).

### Exercice. Estimation d'une densité bivariée par noyaux (9 points).

On observe  $n$  couples de variables aléatoires réelles  $(X_1, Y_1), \dots, (X_n, Y_n)$  indépendants identiquement distribués de densité inconnue  $f : \mathbb{R}^2 \rightarrow \mathbb{R}$  par rapport à la mesure de Lebesgue sur  $\mathbb{R}^2$ .

Pour tout  $h = (h_1, h_2) \in (\mathbb{R}_+^*)^2$ , on considère l'estimateur  $\hat{f}_h$  de  $f$  défini, pour tout  $(x, y) \in \mathbb{R}^2$ , par

$$\hat{f}_h(x, y) = \frac{1}{nh_1h_2} \sum_{i=1}^n Q\left(\frac{x - X_i}{h_1}, \frac{y - Y_i}{h_2}\right),$$

où  $Q : \mathbb{R}^2 \rightarrow \mathbb{R}$  est un noyau *i.e.* une fonction intégrable telle que  $\iint_{\mathbb{R}^2} Q(u, v) dudv = 1$ . On supposera que

$$\|Q\|_2^2 := \iint_{\mathbb{R}^2} Q^2(u, v) dudv < \infty, \quad \iint_{\mathbb{R}^2} |Q(u, v)| |v| dudv < \infty, \quad \iint_{\mathbb{R}^2} Q(u, v) |u|^{1/2} dudv < \infty.$$

On considère le risque quadratique ponctuel en  $(x_0, y_0) \in \mathbb{R}^2$  de  $\hat{f}_h$ ,

$$R_{(x_0, y_0)}(\hat{f}_h, f) = \mathbb{E} \left[ \left( \hat{f}_h(x_0, y_0) - f(x_0, y_0) \right)^2 \right].$$

On note, pour tout  $(u, v) \in \mathbb{R}^2$ ,

$$Q_h(u, v) = \frac{1}{h_1h_2} Q\left(\frac{u}{h_1}, \frac{v}{h_2}\right).$$

Pour toutes fonctions  $f_1$  et  $f_2$  de deux variables, on note  $\star$  le produit de convolution entre  $f_1$  et  $f_2$ , dès que celui-ci a un sens,

$$(f_1 \star f_2)(x, y) = \iint_{\mathbb{R}^2} f_1(x - u, y - v) f_2(u, v) dudv, \quad (x, y) \in \mathbb{R}^2.$$

1. Justifier que si  $K : \mathbb{R} \rightarrow \mathbb{R}$  est un noyau sur  $\mathbb{R}$ , alors la fonction définie pour tout  $(u, v) \in \mathbb{R}^2$  par  $Q(u, v) = K(u)K(v)$  est bien un noyau sur  $\mathbb{R}^2$ .
2. Démontrer que  $R_{(x_0, y_0)}(\hat{f}_h, f) = \left( \mathbb{E} \left[ \hat{f}_h(x_0, y_0) \right] - f(x_0, y_0) \right)^2 + \text{Var}(\hat{f}_h(x_0, y_0))$ .
3. (a) Montrer que  $\mathbb{E} \left[ \hat{f}_h(x_0, y_0) \right] = Q_h \star f(x_0, y_0)$ .  
(b) Montrer que, si la fonction  $f$  est supposée bornée par  $M > 0$  sur  $\mathbb{R}^2$ ,

$$\text{Var}(\hat{f}_h(x_0, y_0)) \leq \frac{M \|Q\|_2^2}{nh_1h_2}.$$

4. On suppose de plus que la densité  $f$  vérifie la propriété suivante :

$$\forall ((u, v), (u', v')) \in (\mathbb{R}^2)^2, \quad |f(u, v) - f(u', v')| \leq |u - u'|^{1/2} + |v - v'|.$$

Montrer qu'alors,

$$\left( \mathbb{E} \left[ \hat{f}_h(x_0, y_0) \right] - f(x_0, y_0) \right)^2 \leq C(h_1 + h_2^2),$$

où  $C$  est une constante ne dépendant que du noyau  $Q$ .

5. (a) Soit la fonction  $g$  définie sur  $(\mathbb{R}_+^*)^2$  par  $g(u, v) = u + v^2 + 1/(nuv)$ ,  $(u, v) \in (\mathbb{R}_+^*)^2$ . Justifier que  $g$  admet sur  $(\mathbb{R}_+^*)^2$  un minimum global dont on calculera la valeur.  
(b) Dédurre des questions précédentes que la vitesse de l'estimateur  $\hat{f}_h$ , pour le risque quadratique ponctuel, est  $n^{-1/5}$ .
6. On note  $f_X$  la densité marginale de  $X_1$ .  
(a) Rappeler comment exprimer  $f_X$  en fonction de  $f$ .  
(b) Proposer alors un estimateur  $\hat{f}_X$  de  $f_X$  en fonction de l'estimateur  $\hat{f}_h$  précédent.  
(c) On suppose que  $Q$  s'écrit  $Q(u, v) = K(u)K(v)$ ,  $(u, v) \in \mathbb{R}^2$ , où  $K$  est un noyau sur  $\mathbb{R}$ . Quelle est alors l'expression de l'estimateur proposé  $\hat{f}_X$  ?