

**Exercice 1 : Fonction caractéristique empirique**

On cherche à estimer la fonction caractéristique  $\phi_X$  d'un échantillon  $(X_n)$  constitué de  $n$  variables aléatoires indépendantes et identiquement distribuées. La fonction caractéristique empirique  $\widehat{\phi}_X$  au point  $t \in \mathbb{R}$  est donné par

$$\widehat{\phi}_X(t) = \frac{1}{n} \sum_{i=1}^n e^{itX_i}.$$

- 1) Montrer que  $\widehat{\phi}_X(t)$  est un estimateur sans biais de  $\phi_X(t)$ .
- 2) Calculer la variance de  $\widehat{\phi}_X(t)$ .
- 3) En déduire l'ordre de grandeur de son risque quadratique ponctuel.

**Exercice 2 : Validation croisée pour l'histogramme**

Soit  $X_1 \dots X_n$  un échantillon i.i.d de densité  $f$  appartenant à  $L^2([0, 1])$ . L'estimateur par histogramme de  $f$  s'écrit pour tout  $x \in [0, 1]$  :

$$\widehat{f}_h(x) = \frac{1}{h} \sum_{j=1}^m \widehat{p}_j \mathbf{1}_{C_j}(x) \quad \text{où} \quad \widehat{p}_j = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{C_j}(X_i).$$

On note  $R(h)$  le risque quadratique intégré de  $\widehat{f}_h$  et  $J(h) = R(h) - \|f\|_2^2$ .

- 1) Calculer le biais et la variance de  $\widehat{f}_h(x)$ . Puis calculer  $J(h)$ .
- 2) Montrer que

$$\widehat{J}(h) = \frac{2}{(n-1)h} - \frac{n+1}{(n-1)h} \sum_{j=1}^m \widehat{p}_j^2$$

est un estimateur sans biais de  $J(h)$ .

**Exercice 3 : Vitesse de convergence pour l'histogramme**

Supposons que  $f$  est Hölderienne d'ordre  $\alpha$  : pour tous  $x, y$ ,

$$|f(x) - f(y)| \leq C_f |x - y|^\alpha$$

où  $C_f$  est une constante qui dépend uniquement de  $f$ .

- 1) Donner l'expression formelle dans la base d'histogrammes réguliers  $\{\varphi_1 \dots \varphi_D\}$  du projeté orthogonal  $f_D$  de  $f$ .
- 2) Montrer que le biais vérifie  $\|f - f_D\|^2 \leq C_f^2 D^{-2\alpha}$ .
- 3) En déduire un majorant du risque quadratique puis déterminer la valeur  $D_{\text{opt}}$  de  $D$  qui minimise cette borne.

**Exercice 4 :** *Estimateur par projection dans un modèle multiplicatif*

On considère le modèle

$$Y_i = \sigma(X_i)\varepsilon_i, \quad i = 1 \dots n$$

où les  $(X_i)$  sont iid de densité commune  $f$  et les  $(\varepsilon_i)$  sont iid centrées de variance 1 et indépendantes des  $(X_i)$ . On notera  $m_4 = \mathbb{E}[\varepsilon_i^4]$ . On observe les couples  $(X_i, Y_i)_i$ . On pose pour toute fonction  $t$  de  $L^2([0, 1])$

$$\gamma_n(t) = \|t\|_2^2 - \frac{2}{n} \sum_{i=1}^n Y_i^2 t(X_i).$$

- 1) Calculer  $\mathbb{E}[\gamma_n(t)]$  et en déduire comment estimer  $\psi := \sigma^2 f$ .
- 2) On note  $\widehat{\psi}_D = \arg \min_{t \in S_D} \gamma_n(t)$  où  $S_D$  est un sev de dimension  $D$  de  $L^2([0, 1])$  engendré par une base orthonormale  $\varphi_1, \dots, \varphi_D$ . Exprimer les coefficients de  $\widehat{\psi}_D$  dans cette base.
- 3) Donner l'expression de  $\psi_D$ , la projection de  $\psi$  sur  $S_D$ , et montrer que  $\mathbb{E}[\widehat{\psi}_D] = \psi_D$ .
- 4) Calculer puis majorer le risque quadratique intégré de  $\widehat{\psi}_D$ .
- 5) Donner un estimateur de  $\sigma^2$  déduit de  $\widehat{\psi}_D$ .

**Exercice 5 :** *Transformée de Fourier de la fonction caractéristique empirique*

On se place dans le cadre de l'exercice 1. On considère une pondération  $\psi$  telle que  $\psi(0) = 1$  et qui décroît ensuite vers 0. On note  $\psi_h(t) = \psi(h_n t)$ , pour tout  $t \in \mathbb{R}$ . La transformée de Fourier de l'estimateur de  $\phi_X$  associé à  $\psi_h$  est donnée, pour  $x \in \mathbb{R}$ , par

$$\widehat{f}_n(x) = \int_{\mathbb{R}} \widehat{\phi}_X(t) \psi(h_n t) e^{-itx} dt.$$

Montrer que  $\widehat{f}_n$  peut s'écrire comme un estimateur à noyau, que l'on précisera, de la densité  $f$ .

**Exercice 6 :** *Estimation par déformation dans un modèle multiplicatif*

On reprend le cadre de l'exercice 4. On suppose de plus que la fonction de répartition commune aux  $X_i$  est bijective. Soit  $K$  un noyau, on se propose d'estimer  $l := \sigma^2 \circ F^{-1}$  par

$$\widehat{l}_h(x) = \frac{1}{nh} \sum_{i=1}^n Y_i^2 K\left(\frac{F(X_i) - x}{h}\right).$$

- 1) Montrer que si  $\sigma^2$  est bornée par  $M$  et  $\|K\|_2^2 = N$  alors  $\text{Var}(\widehat{l}_h(x)) \leq \frac{M^2 N m_4}{nh}$ .
- 2) Exprimer  $\mathbb{E}[\widehat{l}_h(x)]$  en fonction de  $K$ ,  $h$ ,  $l$  et  $x$  uniquement.
- 3) On suppose  $l$  de classe  $\mathcal{C}^3$  et de dérivée troisième bornée, et  $K$  d'ordre 2 à support dans  $[-1, 1]$  tel que  $C_K := \int |u|^3 |K(u)| du < +\infty$ . Déterminer  $C$  et  $\beta$  tels que
$$\forall h \in ]0, 1/2[, \forall x \in [h, 1-h], |b_h(x)| \leq Ch^\beta$$
- 4) En déduire une majoration du risque ponctuel et déterminer  $h_{opt}$  qui la minimise.
- 5) En déduire un estimateur de  $\sigma^2$  si  $F$  est connue.
- 6) Quelle solution peut-on proposer quand  $F$  est inconnue ?