

MAP553 Apprentissage Statistique

PC2 : Estimation d'une densité

Pour une fonction $g \in L^2(\mathbb{R})$, nous noterons $\mathcal{F}[g]$ sa transformée de Fourier. En particulier, si $g \in L^1(\mathbb{R}) \cap L^2(\mathbb{R})$,

$$\mathcal{F}[g](\omega) = \int_{-\infty}^{\infty} e^{it\omega} g(t) dt, \quad \omega \in \mathbb{R}.$$

Rappels transformée de Fourier

$$\begin{aligned} \int_{\mathbb{R}} g^2 &= \frac{1}{2\pi} \int_{\mathbb{R}} |\mathcal{F}[g]|^2 \\ \partial^k \mathcal{F}[g](\omega) &= \mathcal{F}[(ix)^k g(x)](\omega) \quad \text{si } \int_{\mathbb{R}} |x|^k |g(x)| dx < +\infty \\ \mathcal{F}[\partial^k g](\omega) &= (-i\omega)^k \mathcal{F}[g](\omega) \\ \mathcal{F}[g(z - \cdot)](\omega) &= e^{iz\omega} \mathcal{F}[g](-\omega) \\ \mathcal{F}[g(\cdot/h)](\omega) &= h \mathcal{F}[g](h\omega) \end{aligned}$$

1 Analyse Fourier du risque des estimateurs à noyau

Soient X_1, \dots, X_n des variables aléatoires i.i.d. de densité de probabilité p par rapport à la mesure de Lebesgue sur \mathbb{R} . Considérons l'estimateur à noyau de p défini par

$$\hat{p}_n(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{X_i - x}{h}\right).$$

Supposons que $K \in L^2(\mathbb{R})$ et que c'est une fonction paire (un *noyau symétrique*). Soit ϕ la fonction caractéristique associée à la densité p ,

$$\phi(\omega) = \int_{-\infty}^{\infty} e^{it\omega} p(t) dt, \quad \omega \in \mathbb{R}.$$

Définissons la fonction caractéristique empirique

$$\phi_n(\omega) = \frac{1}{n} \sum_{j=1}^n e^{iX_j\omega}, \quad \omega \in \mathbb{R}.$$

On écrira, pour abrégé,

$$\hat{K}(\omega) = \mathcal{F}[K](\omega).$$

1. Montrer que, pour tout noyau symétrique $K \in L^2(\mathbb{R})$,

$$\mathcal{F}[\hat{p}_n](\omega) = \phi_n(\omega)\hat{K}(h\omega).$$

2. Montrer que les premier et le deuxième moments de $\phi_n(\omega)$ valent :

$$\begin{aligned}\mathbb{E}[\phi_n(\omega)] &= \phi(\omega), \\ \mathbb{E}[|\phi_n(\omega)|^2] &= \left(1 - \frac{1}{n}\right) |\phi(\omega)|^2 + \frac{1}{n}\end{aligned}$$

et, par conséquent,

$$\mathbb{E}[|\phi_n(\omega) - \phi(\omega)|^2] = \frac{1}{n} (1 - |\phi(\omega)|^2).$$

3. Mesurons l'erreur de l'estimateur \hat{p}_n par son *risque quadratique intégré* :

$$\text{MISE} = \mathbb{E} \int (\hat{p}_n(x) - p(x))^2 dx.$$

Montrer que, pour toute densité de probabilité $p \in L^2(\mathbb{R})$ et tout noyau symétrique $K \in L^2(\mathbb{R})$,

$$\text{MISE} = \frac{1}{2\pi} \left[\int |1 - \hat{K}(h\omega)|^2 |\phi(\omega)|^2 d\omega + \frac{1}{n} \int |\hat{K}(h\omega)|^2 (1 - |\phi(\omega)|^2) d\omega \right]$$

2 Les noyaux d'ordre ℓ

Soit $\ell \geq 1$ un entier. On dit que $K : \mathbb{R} \rightarrow \mathbb{R}$ est un *noyau d'ordre ℓ* si les fonctions $u \mapsto u^j K(u)$, $j = 0, 1, \dots, \ell$, sont intégrables et vérifient

$$\int K(u) du = 1, \quad \int u^j K(u) du = 0, \quad j = 1, \dots, \ell.$$

1. Soit $\beta > 0$ et $K \in L^2(\mathbb{R})$ un noyau symétrique vérifiant $\hat{K} \in L^\infty(\mathbb{R})$. Montrer que la condition

$$\sup_{\omega \in \mathbb{R} \setminus \{0\}} \frac{|1 - \hat{K}(\omega)|}{|\omega|^\beta} \leq A \tag{1}$$

est équivalente à

$$\exists \omega_0, A_0 < \infty : \sup_{0 < |\omega| \leq \omega_0} \frac{|1 - \hat{K}(\omega)|}{|\omega|^\beta} \leq A_0.$$

2. Montrer que, pour un entier β la condition (1) est vérifiée si K est un noyau d'ordre $\beta - 1$ et

$$\int |u|^\beta |K(u)| du < \infty.$$

3. Pour quelles valeurs de β les noyaux suivants vérifient-ils la condition (1) :

$$\begin{aligned} K(u) &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{u^2}{2}\right) \quad (\text{le noyau gaussien}), \\ K(u) &= \frac{\sin u}{\pi u} \quad (\text{le noyau sinc}), \quad [\text{rappel : } \widehat{K}(\omega) = \mathbf{1}_{[-1,1]}(\omega)] \\ K(u) &= \frac{3}{4}(1 - u^2)I(|u| \leq 1) \quad (\text{le noyau parabolique ou d'Epanechnikov}). \end{aligned}$$

Même question pour les noyaux définis par leurs transformées de Fourier ($\alpha > 0$) :

$$\begin{aligned} \widehat{K}(\omega) &= \frac{1}{1 + |\omega|^\alpha} \quad (\text{le noyau "spline"}), \\ \widehat{K}(\omega) &= (1 - |\omega|^\alpha)_+ \quad (\text{le noyau de Pinsker}). \end{aligned}$$

4. Chercher l'ordre maximal du noyau de Silverman

$$K(u) = \frac{1}{2} \exp(-|u|/\sqrt{2}) \sin(|u|/\sqrt{2} + \pi/4).$$

Indication : on admettra que la transformée de Fourier de K est de la forme

$$\widehat{K}(\omega) = \frac{1}{1 + \omega^4}.$$

3 Vitesses de convergence sur les classes de Sobolev

Supposons que la densité p appartient à une *classe de Sobolev* définie par :

$$\mathcal{P}_S(\beta, L) = \left\{ p \mid p \geq 0, \int p(x)dx = 1 \text{ and } \int |\omega|^{2\beta} |\phi(\omega)|^2 d\omega \leq 2\pi L^2 \right\},$$

où $\beta > 0$ et $L > 0$ sont des constantes fixées et $\phi = \mathcal{F}[p]$ désigne la fonction caractéristique associée à p .

1. Soit $\beta \in \mathbb{N}$. Commenter sur le lien entre la condition $\int |\omega|^{2\beta} |\phi(\omega)|^2 d\omega \leq 2\pi L^2$ dans la définition de la classe de Sobolev et la condition sur la dérivée de p :

$$\int (p^{(\beta)}(u))^2 du \leq L^2.$$

La classe de Sobolev est ainsi une classe de densités suffisamment régulières.

2. Supposons que, pour un $\beta > 0$, la condition (1) est vérifiée et que $K \in L^2(\mathbb{R})$ est un noyau symétrique. Montrer que, si $p \in \mathcal{P}_S(\beta, L)$, alors

$$\mathbb{E} \int (\hat{p}_n(x) - p(x))^2 dx \leq C_1 h^{2\beta} + \frac{C_2}{nh}$$

avec les constantes $C_1 > 0$ et $C_2 > 0$ que l'on précisera.

3. Proposer un choix optimal de la fenêtre h et montrer qu'avec ce choix,

$$\sup_{p \in \mathcal{P}_S(\beta, L)} \mathbb{E} \int (\hat{p}_n(x) - p(x))^2 dx \leq C n^{-\frac{2\beta}{2\beta+1}}$$

où $C > 0$ est une constante ne dépendant que de L, A, β et du noyau K .