

Contrôle continu. Cours de M2 "Statistique non paramétrique."

F. Comte.

3 Octobre 2007, à rendre pour dans deux semaines.

On considère le modèle de régression : $Y_i = m(X_i) + \varepsilon_i, i = 1, \dots, n$. Les $(\varepsilon_i)_{1 \leq i \leq n}$ sont i.i.d. centrés de variance commune s_ε^2 et les $(X_i)_{1 \leq i \leq n}$ sont i.i.d. de densité commune f . De plus, les $(X_i)_{1 \leq i \leq n}$ et les $(\varepsilon_i)_{1 \leq i \leq n}$ sont indépendantes. On dispose d'un échantillon d'observations $(X_i, Y_i)_{1 \leq i \leq n}$. On se propose d'estimer la fonction $\ell = m \cdot f$ au moyen de l'estimateur

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

où K est un noyau.

- 1) a) Donner deux exemples de noyaux.
- b) Choisissez une fonction m et une loi f , des ε_i gaussiens, $s_\varepsilon^2 = 0.25, n = 1000$. Donner un programme de simulation du modèle. *certifié*
- c) Choisissez K, h . Donner un programme de calcul de l'estimateur et une représentation graphique superposant la vraie et l'estimée.

2) Montrer que l'erreur quadratique ponctuelle $\mathbb{E}[(\hat{\ell}_n(x) - \ell(x))^2] = MSE(x)$ se décompose en une somme de deux termes : un terme de variance $\text{Var}(\hat{\ell}_n(x)) = \sigma^2(x)$ plus un terme de biais au carré $[\mathbb{E}(\hat{\ell}_n(x)) - \ell(x)]^2 = b^2(x)$.

3) Calculer $\mathbb{E}(\hat{\ell}_n(x))$ en fonction de K, h, ℓ .

4) Montrer que si f est bornée par $M_f, |m|$ est bornée par M, K est un noyau tel que $\int K(u)du = 1$ et $\int K^2(u)du < +\infty$, alors $\sigma^2(x) \leq M_f(M^2 + s_\varepsilon^2) \int K^2(u)du / (nh)$.

5) On note $[\beta]$ le plus grand entier strictement inférieur à β . On définit la classe de Hölder $\Sigma(\beta, L)$ sur un intervalle I comme l'ensemble des fonctions $h : I \rightarrow \mathbb{R}$ telles que la dérivée d'ordre $p, h^{(p)}$ existe, où $p = [\beta]$, et vérifie :

$$|h^{(p)}(x) - h^{(p)}(y)| \leq L|x - y|^{\beta-p}, \forall x, y \in I.$$

Montrer que si ℓ appartient à une classe $\Sigma(\beta, L)$, si K est un noyau d'ordre $p = [\beta]$ (i.e. $\int K(u)du = 1$ et $\int u^k K(u)du = 0$, pour $u = 1, \dots, p$) et si $\int |u|^\beta |K(u)|du < +\infty$, alors,

$$\forall x \in \mathbb{R}, \forall h > 0, \forall n \geq 1, |b(x)| \leq C_2 h^\beta, \text{ où } C_2 = \frac{L}{p!} \int |u|^\beta |K(u)|du.$$

6) En déduire une majoration de $MSE(x)$. Montrer que, si $\beta > 1/2$, cette quantité majorante est minimale pour une valeur h_n^* de h que l'on calculera.