

Estimation de la fonction régression par la méthode du noyau. Propriétés statistiques

K. LAGHA

Laboratory of Modelisation and Optimisation of Systems
University of Bejaia, 06000 Bejaia, Algéria
email : karima_lagha@yahoo.com

Résumé Dans ce travail, nous considérons le problème d'estimation non paramétrique par la méthode du noyau de la fonction de régression. Nous étudions la consistance de l'estimateur de Nadaraya-Watson à travers les propriétés statistiques et asymptotiques de l'estimateur, à savoir le biais, la variance, l'erreur quadratique moyenne, asymptotique et intégrée, la normalité asymptotique ainsi que les lois uniformes du logarithme pour la fonction de régression.

Mots clés : Fonction de régression, estimation non paramétrique, Lois uniformes du logarithme, paramètre de lissage.

12.1 Introduction

On considère le modèle de régression suivant :

Soit un n -échantillon

$$(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$$

On suppose qu'il existe une fonction $m(\cdot)$ telle que pour $i, \quad 1 \leq i \leq n$

$$Y_i = m(X_i) + \epsilon_i, \quad \epsilon_i \curvearrowright \mathcal{N}(\mu, \sigma^2)$$

et les ϵ_i sont II des X_i

Si (X, Y) a une fonction densité conjointe $f_{X,Y}$ et $E|Y| < \infty$ alors $m(\cdot)$ est définie par :

$$m(x) = E(Y \mid X = x) = \frac{\int y f(x, y) dy}{\int f(x, y) dy} = \frac{r(x)}{f(x)}$$

Estimation non paramétrique de $m(\cdot)$

Soit $m(\cdot)$ une fonction dans une classe de fonction \mathcal{F} (exp : classe de fonctions continues sur $[0, 1]$). On considère l'estimateur ayant la forme suivante (estimateur linéaire par rapport à Y_i) :

$$\hat{m}_n(x) = \sum_{i=1}^n Y_i W_{ni}(x)$$

Où $W_{ni}(\cdot)$ est II des obs Y_i .

12.1.1 Estimateur de Nadaraya-Watson NW

En utilisant l'estimateur à noyau de la fonction densité (proposé par Parzen-Rozenblatt), défini par :

$$\hat{f}_n(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right), x \in R$$

tel que :

1. $h = h_n \rightarrow 0$ qd $n \rightarrow \infty$
2. $K : R \rightarrow R$ fct mesurable vérifiant :
 - (K.1) K est bornée : $\sup_{u \in R} |K(u)| < \infty$
 - (K.2) $\lim_{|u| \rightarrow \infty} |u|K(u) = 0$
 - (K.3) $K(\cdot) \in L_1(R) : \int_R |K(u)| < \infty$
 - (K.4) $\int_R K(u) = 1$

L'estimateur de NW est se présente alors :

$$\hat{m}_n(x) = \begin{cases} \frac{\sum_{i=1}^n Y_i K\left(\frac{x - X_i}{h}\right)}{\sum_{i=1}^n K\left(\frac{x - X_i}{h}\right)} & \text{si } \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right) \neq 0 \\ \frac{1}{n} \sum_{i=1}^n Y_i & \text{sinon} \end{cases}$$

Le noyau K détermine la forme du voisinage autour de x et la fenêtre h contrôle la taille de ce voisinage.

Ou encore, $\hat{m}_n(x) = \frac{\hat{r}_n(x)}{\hat{f}_n(x)}$ avec

$$\hat{r}_n(x) = \frac{1}{nh} \sum_{i=1}^n Y_i K\left(\frac{x - X_i}{h}\right) = \int y \hat{f}(x, y) dy$$

- Phénomène de sous lissage : Variance est trop grande
- Phénomène de sur lissage : Biais (erreur déterministe) est trop grande

Les propriétés statistiques de NW dépendent de h (à choisir de sorte à équilibrer le biais et la variance).

12.1.2 Consistance de l'estimateur

La décomposition biais-variance donne :

$$E \left[\{\hat{m}_n(x) - m(x)\}^2 \right] = Var [\hat{m}_n(x)] + \{E[\hat{m}_n(x)] - m(x)\}^2$$

Lorsque cette espérance tend vers 0, on a

$$\hat{m}_n(x) \xrightarrow{L^2} m(x), \quad \text{d'où, } \hat{m}_n(x) \xrightarrow{P} m(x)$$

Calcul de la variance

On a

$$Var(\hat{f}_n(x)) = \frac{1}{nh} f(x) \int K^2(z) dz (1 + o(h)), \quad h \rightarrow 0.$$

$$Var(\hat{r}_n(x)) = \frac{1}{nh} s(x) \int K^2(z) dz (1 + o(h)), \quad h \rightarrow 0$$

où $s(x) = \int y^2 f(x, y) dy$ et

$$\begin{aligned} Cov(\hat{f}_n(x), \hat{r}_n(x)) &= E[\hat{f}_n(x)\hat{r}_n(x)] - E\hat{f}_n(x)E\hat{r}_n(x) = E\left[\{\hat{f}_n(x) - E\hat{f}_n(x)\}\{\hat{r}_n(x) - E\hat{r}_n(x)\}\right] \\ &= \frac{1}{nh} r(x) \int K^2(z) dz (1 + o(h)), \quad r(x) = \int y f(x, y) dy. \end{aligned}$$

En utilisant la matrice variance-covariance on obtient

$$Var(\hat{m}_n(x)) = \frac{\sigma^2(x)}{nhf(x)} \int K^2(u) du (1 + o(h))$$

Calcul du biais

On définit $\tilde{E}(\hat{m}_n(x)) = \frac{E(\hat{r}_n(x))}{E(\hat{f}_n(x))}$. D'où,

$$E(\hat{m}_n(x)) = \tilde{E}(\hat{m}_n(x)) + \frac{a_n(x) + b_n(x)}{(E\hat{f}_n(x))^2}$$

avec,

$$\begin{cases} a_n(x) = -Cov(\hat{f}_n(x), \hat{r}_n(x)) = o\left(\frac{1}{nh}\right), \\ b_n(x) = E\left[\hat{m}_n(x) \left(\hat{f}_n(x) - E\hat{f}_n(x)\right)^2\right], \end{cases}$$

On a deux cas :

1 cas Y est bornée : $\exists M$ tel que $|Y| \leq M$ alors $|\hat{m}_n(x)| \leq M$ d'où, $b_n(x) \leq o\left(\frac{1}{nh}\right)$.

$$E(\hat{m}_n(x)) = \tilde{E}(\hat{m}_n(x)) + o\left(\frac{1}{nh}\right)$$

2 cas $EY^2 < \infty$ et $nh^2 \rightarrow \infty$ alors $|\hat{m}_n(x)| \leq \sum_j |Y_j|$, d'où $b_n(x) \leq o\left(\frac{1}{n^{1/2}h}\right)$.

$$E(\hat{m}_n(x)) = \tilde{E}(\hat{m}_n(x)) + o\left(\frac{1}{n^{1/2}h}\right)$$

De plus,

$$\tilde{E}(\hat{m}_n(x)) - m(x) = \frac{h}{2} \left\{ m''(x) + 2m'(x) \frac{f'(x)}{f(x)} \right\} \int u^2 K(u) du$$

12.1.3 Optimalité et Normalité asymptotique

Les C.N.S. sur h_n pour obtenir la consistance de $\hat{m}_n(x)$ sont $h_n \rightarrow 0$ et $nh_n \rightarrow \infty$ qd $n \rightarrow \infty$.

- L'erreur quadratique moyenne (MSE)

$$MSE(\hat{m}_n(x)) = E [\{\hat{m}_n(x) - m(x)\}^2] = \frac{h^{2q}}{(q!)^2} \left\{ m^{(q)}(x) + qm^{(q-1)}(x) \frac{f'(x)}{f(x)} \right\}^2 \times \\ \left(\int u^q K(u) du \right)^2 (1 + o(h)) + \frac{1}{nh} \left\{ \frac{\sigma^2(x)}{f(x)} \right\} \int k^2(u) du (1 + o(h))$$

- L'erreur quadratique moyenne Asymptotique (AMSE)

$$AMSE(\hat{m}_n(x)) = \frac{h^{2q}}{(q!)^2} \left\{ m^{(q)}(x) + qm^{(q-1)}(x) \frac{f'(x)}{f(x)} \right\}^2 \times \left(\int u^q K(u) du \right)^2 + \frac{1}{nh} \left\{ \frac{\sigma^2(x)}{f(x)} \right\} \int k^2(u) du$$

(Minimiser suivant h la qtte ci-dessus).

- L'erreur quadratique intégrée moyenne (MISE)

$$MISE(\hat{m}_n(x)) = E \left[\int \{\hat{m}_n(x) - m(x)\}^2 dx \right] = \int MSE(\hat{m}_n(x)) dx \\ = \frac{h^{2q}}{(q!)^2} \left\{ \int m^{(q)}(x) dx + q \int m^{(q-1)}(x) \frac{f'(x)}{f(x)} dx \right\}^2 \times \\ \left(\int u^q K(u) du \right)^2 + \frac{1}{nh} \int \frac{\sigma^2(x)}{f(x)} dx \int k^2(u) du (1 + o(h)).$$

Normalité asymptotique (Schuster 1972)

Sous les conditions : K noyau borné, à support compact et d'ordre 2 et h_n égale à $cn^{-1/5}$, on a le théorème suivant :

Théorème Hardle 1990

Y bornée (ou de moment d'ordre > 2), $f(\cdot)$ et $m(\cdot)$ sont de classe $C^2(R)$, $\forall x$ tel que $\sigma^2(x)$ est continue, $f(x) > 0$,

$$(nh)^{1/2} \{\hat{m}_n(x) - m(x)\} \xrightarrow{\mathcal{L}} \mathcal{N}(B(x), v^2(x)) \\ \left\{ \begin{array}{l} B(x) = \left\{ m''(x) + 2m'(x) \frac{f'(x)}{f(x)} \int u^2 K(u) du \right\}, \\ v^2(x) = \frac{\sigma^2(x)}{f(x)} \int K^2(u) du. \end{array} \right.$$

12.2 Lois Uniformes du logarithme pour la fonction régression

On utilise le principe d'invariance : approximation du processus empirique uniforme par une suite de ponts Browniens et obtention de lois uniforme du logarithme. Soit :

$$m_\psi(x) = E(\psi(Y) \mid X = x) = \frac{\int \psi(y)f(x,y)dy}{\int f(x,y)dy} = \frac{r_\psi(x)}{f(x)}$$

$\psi(\cdot)$ est une fct réelle mesurable et bornée sur des compacts.

• Hypothèses sur f :

(F.1) $f_{X,Y}(\cdot, \cdot)$ est continue sur $I \times R$, $I = [a, b]$

(F.2) $f_X(\cdot)$ est continue > 0 sur I

(F.3) $Y \mathbb{1}_{\{X \in I\}}$ est bornée

• Hypothèses sur K :

(K.1) $K(\cdot)$ est à variation bornée et continue sur R :

$$\int |dK(u)| = |K|_v < \infty$$

(K.2) $K(u) = 0$ si $u \notin [-\epsilon/2, \epsilon/2]$, $0 < \epsilon < \infty$.

(K.3) $\int K(u)du = 1$.

• Hypothèses sur h :

(H.1) $h_n \rightarrow 0$ qd $n \rightarrow \infty$

(H.2) $nh_n / \log n \rightarrow \infty$ qd $n \rightarrow \infty$

(C.N.S pour la cvgence uniforme en proba de la déviation associée aux estimateurs).

(H.3) $h_n \searrow 0$ et $nh_n \nearrow \infty$ qd $n \rightarrow \infty$.

(H.4) $|\log h_n| / \log \log n \rightarrow \infty$ qd $n \rightarrow \infty$.

(C. reliées à la cvgence p.s.)

On considère le processus :

$$W_n(x, \psi) = \sum_{i=1}^n \psi(Y_i)K\left(\frac{x - X_i}{h}\right) - nE\left\{\psi(Y)K\left(\frac{x - X_i}{h}\right)\right\}$$

Sous les conditions :

(F.1-3), (H.1-2) et (K.1-4) qd $n \rightarrow \infty$ on a :

$$\left| \sup_{x \in I} \frac{\{\pm W_n(x, \psi)\}}{\{2nh \log 1/h\}^{1/2}} - \sigma_W(I) \right| \xrightarrow{p} 0$$

Sous les conditions :

(F.1-3), (H.2-4) et (K.1-4) qd $n \rightarrow \infty$ on a :

$$\left| \sup_{x \in I} \frac{\{\pm W_n(x, \psi)\}}{\{2nh \log 1/h\}^{1/2}} - \sigma_W(I) \right| \xrightarrow{p.s.} 0$$

où

$$\sigma_W^2(I) = \sup_{x \in I} E [\psi^2(Y) \mid X = x] f(x) \left(\int K(t) dt \right)^2$$

Il s'agit de montrer que $\forall \epsilon > 0$,

$$P \left\{ \sup_{x \in I} \frac{|W_n(x, \psi)|}{\{2nh \log 1/h\}^{1/2}} > (1 + \epsilon) \sigma_W(I) \right\} \xrightarrow{p(oup.s.)} 0$$

et

$$P \left\{ \sup_{x \in I} \frac{|W_n(x, \psi)|}{\{2nh \log 1/h\}^{1/2}} < (1 - \epsilon) \sigma_W(I) \right\} \xrightarrow{p(oup.s.)} 0$$

Discrétisation

Examiner le processus empirique fonctionnel $W_n(\cdot, \psi)$ pour un nombre fini de points de I .

$$\begin{aligned} W_n(x, \psi) &= \sum_{i=1}^n \left[\psi(Y_i) K \left(\frac{x - X_i}{h} \right) - E \left(\psi(Y_i) K \left(\frac{x - X_i}{h} \right) \right) \right] \\ &= n^{1/2} \left[\frac{1}{\sqrt{n}} \sum_{i=1}^n (g(X_i, Y_i) - E g(X_i, Y_i)) \right] = n^{1/2} \alpha_n(g_{n,x}) \end{aligned}$$

où $g_{n,x}(u, v) = \psi(v) K \left(\frac{x-u}{h} \right)$. On considère pour $0 < \delta < 1$, $I = [a, b]$

$$z_{n,i} = a + i\delta h_n, \quad 0 \leq i \leq l_n = \lceil (b-a)/\delta h_n \rceil.$$

D'où l'étude du processus empirique indéré par la classe $G_n \{g_{n,i}, 0 \leq i \leq l_n\}$ et

$$P \left\{ \max_{0 \leq i \leq l_n} \frac{|\alpha_n(g_{n,i})|}{\{2nh \log 1/h\}^{1/2}} > (1 + \epsilon) \sigma_W(I) \right\} \xrightarrow{p(oup.s.)} 0$$

Proposition

Z_j sont des v.a. centrées de variance $\sigma^2 < \infty$, $\forall j$ et $\exists M > 0$, $|Z_j| < M \forall j$ alors $\forall t > 0$,

$$P \left\{ \sum_{j=1}^n Z_j > t\sqrt{n} \right\} \leq \exp \left(\frac{-t^2}{2\sigma^2 + \frac{2}{3} M n^{-1/2} t} \right)$$

Dans notre cas, on pose : $Z_j = g_{n,i}(X_j, Y_j) - E g_{n,i}(X_j, Y_j)$.

Z_j sont centrées et bornées par $2\|\psi\| \cdot \|K\| = M$ (K étant à variation bornée donc $\|K\| < \infty$).

D'après la proposition

$$P \left(\sum_j Z_j > t\sqrt{n} \right) = P(\alpha_n(g_{n,i}) > t)$$

On prend $t = \sigma_W(I)(1 + \epsilon)\sqrt{2h_n \log 1/h_n}$, d'où

$$P\left(\frac{|\alpha_n(g_{n,i})|}{\sqrt{2h_n \log 1/h_n}} > \sigma_W(I)(1 + \epsilon)\right) \leq 2(l_n + 1)\exp(-(1 + \epsilon)^2 \log 1/h_n) = o(h_n^{(1+\epsilon)^2-1}).$$

Le résultat s'ensuit en utilisant le lemme suivant :

Lemme de Cantelli

Soit (\sum, \mathcal{A}, P) un espace de probabilité quelconque, $\forall\{A_n, n \geq 1\} \subset \mathcal{A}$ (evts mesurables)

$$\sum_{n \geq 1} P(A_n) < \infty \implies P(\limsup_n A_n) = 0$$

(quand $\sum A_n$ est Convergente A_n^C est vrai p.s).

12.3 Application Statistique

Fenêtre adaptive et Intervalle de confiance

- Pour construire un intervalle de confiance on utilise souvent la normalité asymptotique et les lois qui en découlent.
- Du point de vue statistique, la convergence en probabilité est une notion suffisante. La convergence p.s. nous oblige souvent à supposer des conditions plus fortes sur le paramètre de lissage.
- On considère les lois limites uniformes du logarithme pour le mode de convergence en proba afin de déterminer l'intervalle de confiance (car ça nécessite des hypothèses moins restrictives sur la fenêtre).

Corollaire

Sous les hyp (F.1-3), (H.1-3) et (K.1-3), qd $n \rightarrow \infty$ (Déviation maximale par rapport à l'espérance)

$$\left\{ \frac{nh_n}{2 \log 1/h_n} \right\}^{1/2} \sup_{x \in I} \pm \left\{ \frac{\hat{f}_n(x)}{\hat{\sigma}_n^2(x)} \right\}^{1/2} \{\hat{m}_n(x) - \tilde{E}[\hat{m}_n(x)]\} \xrightarrow{P} \int K^2(u)du$$

(le biais est négligeable qd h_n est d'ordre $n^{-\delta}$, $(2l + 1)^{-1} \leq \delta \leq 1$.)

$$\sup_{x \in I} \left\{ \tilde{E}[\hat{m}_n(x)] - m(x) \right\} = O(h_n^l), l > 1$$

Si $h_n = n^{-1/(2l+1)}$, $n \rightarrow \infty$

$$\left\{ \frac{nh_n}{2 \log 1/h_n} \right\}^{1/2} \sup_{x \in I} \pm \left\{ \frac{\hat{f}_n(x)}{\hat{\sigma}_n^2(x)} \right\}^{1/2} \{\hat{m}_n(x) - m_n(x)\} \xrightarrow{P} \int K^2(u)du$$

Où,

$$\hat{\sigma}_n^2(x) = \frac{\sum_{i=1}^n \{\psi(Y_i) - \hat{m}_n(x)\}^2 K\left(\frac{x-X_i}{h_n}\right)}{\sum_{i=1}^n K\left(\frac{x-X_i}{h_n}\right)}$$

Si $\sum_{i=1}^n K\left(\frac{x-X_i}{h_n}\right) \neq 0$. D'où, Pour tout $\epsilon \in]0, 1[$ qd $n \rightarrow \infty$

$$P\{m(x) \in [\hat{m}_n(x) - (1 + \epsilon)L_n(x), \hat{m}_n(x) + (1 + \epsilon)L_n(x)], \forall x \in I\} \rightarrow 1 \text{ et}$$

$$P\{m(x) \in [\hat{m}_n(x) - (1 - \epsilon)L_n(x), \hat{m}_n(x) + (1 - \epsilon)L_n(x)], \forall x \in I\} \rightarrow 0$$

avec

$$L_n(x) = \left\{ \frac{2 \log 1/h_n}{nh_n} \times \frac{\hat{\sigma}_n^2(x)}{\hat{f}_n(x)} \right\}^{1/2} \left[\int K^2(u) du \right]^{1/2}$$

D'où, L'intervalle de confiance asymptotiquement optimale pour $\hat{m}_n(x)$, $x \in I$ est

$$[\hat{m}_n(x) - L_n(x), \hat{m}_n(x) + L_n(x)]$$