

REVUE DE STATISTIQUE APPLIQUÉE

G. BANON

Sur un estimateur non paramétrique de la densité de probabilité

Revue de statistique appliquée, tome 24, n° 4 (1976), p. 61-73

http://www.numdam.org/item?id=RSA_1976__24_4_61_0

© Société française de statistique, 1976, tous droits réservés.

L'accès aux archives de la revue « *Revue de statistique appliquée* » (<http://www.sfds.asso.fr/publicat/rsa.htm>) implique l'accord avec les conditions générales d'utilisation (<http://www.numdam.org/conditions>). Toute utilisation commerciale ou impression systématique est constitutive d'une infraction pénale. Toute copie ou impression de ce fichier doit contenir la présente mention de copyright.

NUMDAM

Article numérisé dans le cadre du programme
Numérisation de documents anciens mathématiques
<http://www.numdam.org/>

SUR UN ESTIMATEUR NON PARAMÉTRIQUE DE LA DENSITÉ DE PROBABILITÉ

G. BANON

Laboratoire d'Automatique et d'Analyse
des Systèmes, Toulouse

Résumé

On rappelle dans cette note les estimateurs connus de la densité de probabilité, ceux de Rosenblatt-Parzen, Yamato et Deheuvels, ainsi que les conditions respectives de convergence en moyenne quadratique.

On introduit un critère de comparaison fondé sur le comportement asymptotique de la variance lorsque le nombre d'observations devient infini. Moyennant l'adjonction d'hypothèses supplémentaires on montre que le critère choisi permet d'ordonner les trois estimateurs.

Enfin on introduit un nouvel estimateur récurrent de la densité pour lequel on étudie le comportement du biais, on démontre la convergence en moyenne quadratique et on montre que sur la base du critère choisi ce dernier estimateur est meilleur que les précédents.

1 — NATURE DU PROBLEME

Soient $X_1, X_2, \dots, X_n$ des variables aléatoires réelles, indépendantes et identiquement distribuées suivant une fonction de répartition $F(x)$ possédant une densité de probabilité $f(x)$ bornée et continue sur R :

$$F(x) = \int_{-\infty}^x f(y) dy. \quad (1-1)$$

Le problème auquel on s'intéresse ici est l'étude d'estimateurs $f_n(x)$ de la densité de probabilité $f(x)$, fonction des variables aléatoires $X_1, X_2, \dots, X_n$, qui convergent en moyenne quadratique :

$$E(f_n(x) - f(x))^2 \xrightarrow{n \rightarrow \infty} 0, \quad (1-2)$$

ou encore, puisque :

$$E(f_n(x) - f(x))^2 = \text{Var } f_n(x) + (E f_n(x) - f(x))^2, \quad (1-3)$$

(1) Article remis en Novembre 1975, révisé en Juillet 1976.

Mots-clés : Estimation, non paramétrique, récurrente, densité de probabilité.

d'estimateurs tels que l'on ait simultanément :

$$E f_n(x) \xrightarrow{n \rightarrow \infty} f(x) \quad (1-4)$$

et

$$\text{Var } f_n(x) \xrightarrow{n \rightarrow \infty} 0. \quad (1-5)$$

Les estimateurs vérifiant la propriété (1-4) sont dits asymptotiquement sans biais.

Dans cette note, on se limitera à l'étude de la convergence en moyenne quadratique.

2 – RAPPEL HISTORIQUE

Plusieurs estimateurs de la densité de probabilité ont été proposés par le passé. Chronologiquement on peut rappeler les travaux de M. Rosenblatt [8], puis ceux de E. Parzen [7] sur l'étude d'un estimateur de la forme :

$$f_{1,n}(x) = \frac{1}{nh_n} \sum_{j=1}^n K\left(\frac{x - x_j}{h_n}\right), \quad (2-1)$$

où $K(y)$ est une fonction mesurable sur $\mathbb{R}$, éventuellement non négative (condition nécessaire si l'on désire que $f_n(x)$ soit une densité), bornée et vérifiant :

$$\int_{-\infty}^{\infty} K(y) dy = 1, \quad (2-2)$$

et où h est le terme général d'une suite numérique $\{h_n\}$ positive telle que :

$$h_n \xrightarrow{n \rightarrow \infty} 0 \quad (2-3)$$

et

$$nh_n \xrightarrow{n \rightarrow \infty} \infty \quad (2-4)$$

Sous ces conditions, on montre en particulier (voir par exemple [9] p. 1816) que $f_{1,n}(x)$ converge en moyenne quadratique vers $f(x)$, et que (voir [9] p. 1818) :

$$\text{Var } f_{1,n}(x) \underset{n \rightarrow \infty}{\sim} \frac{1}{nh_n} f(x) \int_{-\infty}^{\infty} K^2(y) dy. \quad (2-5)$$

On notera par C_1 l'ensemble des couples $(K(y), \{h_n\})$ tels que $K(y)$ soit une fonction mesurable non négative, bornée et satisfaisant (2-2), et tels que $\{h_n\}$ soit une suite numérique positive vérifiant (2-3) et (2-4).

En ce qui concerne le comportement asymptotique du biais $E f_{1,n}(x) - f(x)$, on démontre (voir par exemple [9] p. 1818) que si $K(y)$ est de plus une fonction paire telle que :

$$\int_{-\infty}^{\infty} y^2 K(y) dy < \infty, \quad (2-6)$$

et si $f'(x)$ et $f''(x)$ sont continues et bornées ($f''(x) \neq 0$) alors :

$$E f_{1,n}(x) - f(x) \underset{n \rightarrow \infty}{\sim} \frac{1}{2} h^2 f''(x) \int_{-\infty}^{\infty} y^2 K(y) dy. \quad (2-7)$$

Des propriétés asymptotiques de la variance et du biais on peut déduire, sous les conditions qui ont conduit à (2-5) et (2-7), le comportement asymptotique de l'erreur quadratique moyenne de l'estimateur de Rosenblatt-Parzen pour $n \rightarrow \infty$:

$$\begin{aligned} E (f_{1,n}(x) - f(x))^2 &= \frac{1}{nh_n} f(x) \int_{-\infty}^{\infty} K^2(y) dy \\ &+ \frac{1}{4} h_n^4 f''^2(x) \left(\int_{-\infty}^{\infty} y^2 K(y) dy \right)^2 + o \left(\frac{1}{nh_n} + h_n^4 \right). \end{aligned} \quad (2-8)$$

Remarque 2-1

Si l'on prend $h_n = n^{-s}$ avec $s \in]0,1[$, on déduit de (2-7) que le biais converge vers zéro comme n^{-2s} , et de (2-8) on conclut que la vitesse de convergence vers zéro de l'erreur quadratique moyenne est maximum pour $s = 1/5$. A partir de (2-8) on constate aussi que pour $s > 1/5$ le biais converge vers zéro plus rapidement que la variance et que par conséquent l'erreur quadratique moyenne se comporte alors asymptotiquement comme la variance.

On peut rappeler aussi les travaux de H. Yamato [10] qui a introduit un estimateur récurrent de la densité satisfaisant l'équation :

$$f_n(x) = \frac{n-1}{n} f_{n-1}(x) + \frac{1}{nh_n} K \left(\frac{x - X_n}{h_n} \right), \quad (2-9)$$

pour $n = 1, 2, \dots$

L'estimateur de Yamato solution de (2-9) s'écrit :

$$f_{2,n}(x) = \frac{1}{n} \sum_{j=1}^n \frac{1}{h_j} K \left(\frac{x - X_j}{h_j} \right). \quad (2-10)$$

On démontre en particulier (voir [10] théorème 2 p. 4) que pour tout couple $(K(y), \{h_n\})$ appartenant à C_2 sous ensemble de C_1 pour lequel les suites $\{h_n\}$ sont décroissantes, $f_{2,n}(x)$ converge en moyenne quadratique vers $f(x)$.

Remarque 2-2

L'hypothèse de suite décroissante pour $\{h_n\}$ n'est pas en général une condition nécessaire pour assurer les propriétés de convergence, mais puisque c'est une hypothèse simplificatrice dans les démonstrations et que ce n'est pas une limitation très forte en pratique, on la conservera dans toute la suite de cette note.

Si de plus $(K(y), \{h_n\})$ appartient à C'_2 sous ensemble de C_2 pour lequel les suites $\{h_n\}$ vérifient :

$$\frac{h_n}{n} \sum_{j=1}^n \frac{1}{h_j} \xrightarrow{n \rightarrow \infty} \alpha \quad (2-11)$$

avec $\alpha \in]0,1[$, alors on montre (voir [10] théorème 3 p. 6) que :

$$\lim_{n \rightarrow \infty} n h_n \text{Var } f_{2,n}(x) = \alpha f(x) \int_{-\infty}^{\infty} K^2(y) dy . \quad (2-12)$$

Enfin, P. Deheuvels [3] a proposé un autre estimateur récurrent de la densité de la forme :

$$f_{3,n}(x) = \frac{1}{b_n} \sum_{j=1}^n K\left(x, \frac{x - X_j}{h_j}\right) \quad (2-13)$$

avec

$$b_n = \sum_{j=1}^n h_j ,$$

où $K(x,y)$ est une fonction non négative, bornée, mesurable sur $\mathbb{R}^2$ et vérifiant :

$$\int_{-\infty}^{\infty} K(x,y) dy = 1 \quad \forall x \in \mathbb{R} \quad (2-14)$$

et

$$\sup_{x \in \mathbb{R}} \int_{|y| > t} |y| K(x,y) dy \xrightarrow{t \rightarrow \infty} 0 , \quad (2-15)$$

et où h_j est le terme général d'une suite numérique $\{h_j\}$ positive, décroissante vers zéro et vérifiant :

$$b_n \xrightarrow{n \rightarrow \infty} \infty . \quad (2-16)$$

Parmi de nombreux autres résultats P. Deheuvels a démontré que sous les conditions précédentes $f_{3,n}(x)$ converge en moyenne quadratique vers $f(x)$, et qu'en particulier (voir [3] théorème 1 p. 1119) :

$$\text{Var } f_{3,n}(x) \underset{n \rightarrow \infty}{\sim} \frac{1}{b_n} f(x) \int_{-\infty}^{\infty} K^2(x,y) dy . \quad (2-17)$$

Remarque 2-3

Puisque l'on se limite ici au cas de la convergence en moyenne quadratique, on se restreindra dans la suite de ce travail au cas où la fonction $K(x,y)$ ne dépend que de y . D'autre part, on pourrait vérifier qu'alors la condition (2-15) est superflue pour démontrer (2-17).

Comme dans le cas de l'estimateur de Rosenblatt-Parzen avec $h_n = n^{-s}$, on pourrait vérifier aussi (voir les résultats sur la convergence des espérances

mathématiques p. 29 th. 6 dans [5]) que pour $s > 1/5$ les biais des estimateurs de Yamato et de Deheuvels convergent vers zéro plus rapidement que leurs variances.

3 – DEFINITION D'UN NOUVEL ESTIMATEUR

Afin de dégager l'intérêt relatif des estimateurs de la densité présentés au paragraphe précédent on introduit maintenant un critère de comparaison fondé sur le comportement asymptotique de la variance.

Bien d'autres critères pourraient être choisis (convergence de l'erreur quadratique moyenne ou de son intégrale sur R, convergence presque sûre par exemple), les remarques 2-1 et 2-3 (deuxième paragraphe) font cependant le lien (et sont ainsi un motif de justification) entre la convergence de la variance et celle de l'erreur quadratique moyenne dans le cas pratique important où $h_n = n^{-s}$ et où s doit être pris supérieur à $1/5$.

Définition 3-1 (critère de comparaison)

C désignant un sous ensemble produit de fonction $K(y)$ mesurable sur R et de suite numérique $\{h_n\}$, on dira que relativement à C l'estimateur f est meilleur que l'estimateur g au sens de la variance et on notera $f \prec g$ si et seulement si à tout couple $(K(y), \{h_n\})$ de C égal il existe un réel non négatif a inférieur à l'unité tel que pour tout ϵ positif il existe un entier positif $N(\epsilon)$ tel que $n > N$ implique $\frac{\text{Var } f_n(x)}{\text{Var } g_n(x)} < a + \epsilon$, en résumé, relativement à C

$f \prec g \Leftrightarrow \exists a \in]0, 1[; \forall \epsilon > 0, \exists N(\epsilon);$

$$n > N \Rightarrow \frac{\text{Var } f_n(x)}{\text{Var } g_n(x)} < a + \epsilon. \quad (3-1)$$

Sur la base de la définition 3-1 on établit les deux lemmes suivants :

Lemme 3-1 (transitivité)

Si relativement à C $f \prec g$ et relativement à C' $g \prec h$ alors relativement à $C \cap C'$ $f \prec h$.

Lemme 3-2 (condition suffisante)

Si pour tout $(K(y), \{h_n\})$ appartenant à C , $\frac{\text{Var } f_n(x)}{\text{Var } g_n(x)} \leq u_n$ et $\lim_{n \rightarrow \infty} u_n = b$ avec $b \in [0, 1[$ alors relativement à C $f \prec g$.

Remarque 3-1

Avec la définition 3-1, pour comparer deux estimateurs, il n'est pas nécessaire que la limite de $\frac{\text{Var } f_n(x)}{\text{Var } g_n(x)}$ existe, il suffit par exemple que le lemme

3-2 soit vérifié. Dans ce cas on vérifie que $\lim_{n \rightarrow \infty} u_n$ est inférieure à l'unité plutôt que u_n inférieur à l'unité (ce qui conduirait à une autre définition du critère de comparaison ; en effet on peut se trouver parfois dans la situation où $u_n < 1$ et $\lim_{n \rightarrow \infty} u_n = 1$ comme le montre l'exemple suivant :

$$u_n = \frac{1}{n \log n} \sum_{j=2}^n \text{Log } j \quad \text{pour } n \quad \text{pour } n = 2, 3, \dots \quad (\text{Voir [10] p. 9})$$

En appliquant le critère de comparaison défini plus haut aux trois estimateurs déjà rencontrés on obtient le résultat suivant :

Proposition 3-1

f_1 , f_2 et f_3 désignant respectivement les estimateurs de Rosenblatt-Parzen, Yamato et Deheuvels et C'_3 étant le sous ensemble de C'_2 pour lequel $\{h_n\}$ vérifie :

$$\frac{nh_n}{b_n} \xrightarrow{n \rightarrow \infty} \beta \text{ avec } \beta \in [0, \alpha[, \text{ alors} \quad (3-2)$$

$$\text{relativement à } C'_2 \text{ on a } f_2 \rightsquigarrow f_2, \quad (3-3)$$

$$\begin{aligned} \text{relativement à } C'_3 \text{ on a } f_3 \rightsquigarrow f_2, \\ \text{et } f_3 \rightsquigarrow f_1. \end{aligned} \quad (3-5)$$

Démonstration

De (2-5) et (2-12) on déduit que pour tout élément de $C'_2 \lim_{n \rightarrow \infty} \frac{\text{Var } f_{2,n}(x)}{\text{Var } f_{1,n}(x)} = \alpha$, en appliquant le lemme 3-2 avec $b = \alpha$ on obtient (3-3). En rapprochant (2-12) et (2-17) on obtient que pour tout élément de $C'_3 \lim_{n \rightarrow \infty} \frac{\text{Var } f_{3,n}(x)}{\text{Var } f_{2,n}(x)} = \frac{\beta}{\alpha}$, or $\frac{\beta}{\alpha} < 1$ aussi en appliquant le lemme 3-2 avec $b = \frac{\beta}{\alpha}$ on obtient (3-4). (3-5) découle du lemme 3-1 puisque $C'_3 \subset C'_2$.

La question que l'on se pose maintenant est de savoir s'il existe au moins un estimateur meilleur que l'estimateur de Deheuvels au sens de la définition 3-1 pour au moins un ensemble non vide de couples $(K(y), \{h_n\})$.

Au prix d'une complexité accrue, la réponse est affirmative, on est dans cette situation dans le cas suivant :

$$f_{4,n}(x) = \frac{1}{b_n} \sum_{j=1}^n \frac{h_j}{b_j} \sum_{k=1}^j K\left(\frac{x - X_j}{h_k}\right), \quad (3-6)$$

avec $b_n = \sum_{j=1}^n h_j$ comme pour l'estimateur $f_{3,n}(x)$.

On constate que l'estimateur donné par l'expression (3-6) est récurrent et vérifie l'équation :

$$f_n(x) = \frac{b_{n-1}}{b_n} f_{n-1}(x) + \frac{h_n}{b_n^2} \sum_{k=1}^n K\left(\frac{x - X_n}{h_k}\right), \quad (3-7)$$

pour $n = 1, 2, \dots$, avec $b_0 = 0$ par convention.

Remarque 3-2

Dans le cas du noyau unité ($K(y) = \frac{1}{2} 1_{[-1,1]}(y)$), où 1_A est la fonction indicatrice de l'ensemble A) et de la suite $\{h_n\}$ de terme général $h_n = 1/\sqrt{n}$, la contribution (additive) de la 8^{ième} variable aléatoire X_8 dans l'expression (2-13) se calcule à partir de la fonction représentée sur la *figure 3-1*, cette contribution dans l'expression (3-6) se calcule, par contre, à partir de la fonction représentée sur la *figure 3-2*.




Figure 3-1




Figure 3-2

4 – PROPRIETES DE L'ESTIMATEUR $f_{4,n}(x)$

Dans la suite de ce travail on va définir des conditions suffisantes sur la fonction $K(y)$ et la suite $\{h_n\}$ pour que $f_{4,n}(x)$ converge en moyenne quadratique vers $f(x)$ et ait la propriété énoncée ci-dessus. On vérifiera que ces conditions sont satisfaites pour au moins une classe importante de cas pratiques. En outre on étudiera le comportement asymptotique du biais.

Théorème 4-1 (convergence asymptotique sans biais).

Si $(K(y), \{h_n\}) \in C_2$ alors

$$E f_{4,n}(x) \xrightarrow{n \rightarrow \infty} f(x). \quad (4-1)$$

Démonstration

D'après la définition de $f_{4,n}(x)$ on a :

$$E f_{4,n}(x) = \frac{1}{b_n} \sum_{j=1}^n \frac{h_j}{b_j} \sum_{k=1}^j E K \left(\frac{x - X_1}{h_k} \right). \quad (4-2)$$

D'autre part en remarquant que $\frac{1}{h_n} E K \left(\frac{x - X_1}{h_n} \right) = E f_{1,n}(x)$ on peut appliquer un résultat partiel établi par M. Rosenblatt (voir [9] p. 1816 expression (7)) et obtenir que pour tout élément de C_2 :

$$\frac{1}{h_n} E K \left(\frac{x - X_1}{h_n} \right) \xrightarrow{n \rightarrow \infty} f(x). \quad (4-3)$$

En utilisant (4-3) et en appliquant deux fois le lemme de Toeplitz rappelé ci-dessous on trouve que la limite de l'expression (4-2) est bien $f(x)$.

Lemme 4-1 (lemme de Toeplitz – énoncé partiel)

Si $b_n = \sum_{k=1}^n a_k \xrightarrow{n \rightarrow \infty} \infty$, alors $x_n \xrightarrow{n \rightarrow \infty} x$ implique que $\frac{1}{b_n} \sum_{k=1}^n a_k x_k \xrightarrow{n \rightarrow \infty} x$.

(Pour l'énoncé complet et la démonstration du lemme voir [6] p. 238).

A propos du comportement asymptotique du biais on peut établir le résultat particulier suivant :

Théorème 4-2

Si $(K(y), \{h_n\}) \in C_2$, si de plus $K(y)$ est une fonction paire satisfaisant (2-6) et si $f'(x)$ et $f''(x)$ sont continues et bornées ($f''(x) \neq 0$) alors :

$$E f_{4,n}(x) - f(x) \underset{n \rightarrow \infty}{\sim} \frac{1}{2} f''(x) \int_{-\infty}^{\infty} y^2 K(y) dy \left(\frac{1}{b_n} \sum_{j=1}^n \frac{h_j}{b_j} \sum_{k=1}^j h_k^3 \right) \quad (4-4)$$

Démonstration

Sous les conditions du théorème 4-2, en développant $f(x)$ au voisinage de x on obtient pour $n \rightarrow \infty$.

$$EK \left(\frac{x - X_1}{h_n} \right) = h_n f(x) + \frac{1}{2} h_n^3 f''(x) \int_{-\infty}^{\infty} y^2 K(y) dy + o(h_n^3), \quad (4-5)$$

en rapprochant (4-5) et (4-2) on établit alors (4-4).

Remarque 4-1

Si on prend $h_n = n^{-s}$ avec $s \in]0, 1[$ et si on utilise la propriété :

$$\sum_{j=1}^n j^{-s} \sim \frac{n^{1-s}}{1-s} \quad \forall s < 1, \quad (4-6)$$

on constate que comme dans le cas de l'estimateur de Rosenblatt-Parzen le biais converge vers zéro comme n^{-2s} (voir remarque 2-1).

Avant d'étudier la convergence en moyenne quadratique, on va démontrer le lemme suivant :

Lemme 4-2 (majoration de la variance)

Si $(K(y), \{h_n\}) \in C_4$ sous ensemble de C_2 tel que $K(y)$ soit monotone sur les intervalles y positif et y négatif, alors :

$$\text{Var } f_{4,n}(x) \leq \frac{1}{b_n^2} \sum_{j=1}^n \frac{h_j^2}{b_j^2} \sum_{k=1}^j (2j - 2k + 1) EK^2 \left(\frac{x - X_1}{h_k} \right). \quad (4-7)$$

Démonstration

D'après la définition de $f_{4,n}(x)$ et à cause de l'indépendance des X_j on a :

$$\text{Var } f_{4,n}(x) \leq \frac{1}{b_n^2} \sum_{j=1}^n \frac{h_j^2}{b_j^2} \sum_{k,\ell=1}^j EK \left(\frac{x - X_1}{h_k} \right) K \left(\frac{x - X_1}{h_\ell} \right) \quad (4-8)$$

La monotonie de $K(y)$ et $\{h_n\}$ implique l'inégalité :

$$EK \left(\frac{x - X_1}{h_k} \right) K \left(\frac{x - X_1}{h_\ell} \right) \leq EK^2 \left(\frac{x - X_1}{h_{\min(k,\ell)}} \right). \quad (4-9)$$

En considérant (4-8) et (4-9) simultanément on obtient :

$$\text{Var } f_{4,n}(x) \leq \frac{1}{b_n^2} \sum_{j=1}^n \frac{h_j^2}{b_j^2} \sum_{k,\ell=1}^j EK^2 \left(\frac{x - X_1}{h_{\min(k,\ell)}} \right), \quad (4-10)$$

ce qui implique (4-7).

Théorème 4-3 (convergence en moyenne quadratique)

Si $(K(y), \{h_n\}) \in C_4$ alors :

$$E(f_{4,n}(x) - f(x))^2 \xrightarrow{n \rightarrow \infty} 0. \quad (4-11)$$

Démonstration

Puisque d'après le théorème 4-1 le biais converge vers zéro relativement à $C_1 \supset C_4$, il suffit de démontrer maintenant que la variance converge vers zéro. A partir de l'expression (4-7) du lemme précédent on obtient les majorants suivants pour la variance :

$$\text{Var } f_{4,n}(x) \leq \frac{2}{b_n^2} \sum_{j=1}^n \frac{j h_j^2}{b_j^2} \sum_{k=1}^j E K^2 \left(\frac{x - X_1}{h_k} \right). \quad (4-12)$$

$$\leq \frac{2}{b_n^2} \sum_{j=1}^n \frac{h_j}{b_j} \sum_{k=1}^j E K^2 \left(\frac{x - X_1}{h_k} \right). \quad (4-13)$$

(4-13) découlant de la monotonie de $\{h_n\}$. Enfin, soit M tel que $\sup_{x \in \mathbb{R}} f(x) \leq M$, on a alors :

$$E K^2 \left(\frac{x - X_1}{h_k} \right) \leq h_k M \int_{-\infty}^{\infty} K^2(y) dy. \quad (4-14)$$

Finalement en rapprochant (4-13) et (4-14) on trouve :

$$\text{Var } f_{4,n}(x) \leq \frac{2M}{b_n} \int_{-\infty}^{\infty} K^2(y) dy, \quad (4-15)$$

ce qui implique la convergence vers zéro de la variance lorsque n devient infini.

Afin de comparer $f_{4,n}(x)$ avec les estimateurs présentés au paragraphe 2, on va démontrer le lemme suivant :

Lemme 4-3

Si $(K(y), \{h_n\}) \in C'_3$ et si la suite $\{h_n\}$ vérifie :

$$\frac{h_n}{b_n^2} \sum_{j=1}^n j h_j \xrightarrow{n \rightarrow \infty} \gamma, \text{ alors :} \quad (4-16)$$

$$\begin{aligned} \lim_{n \rightarrow \infty} \frac{1}{b_n} \sum_{j=1}^n \frac{h_j^2}{b_j^2} \sum_{k=1}^j (2j - 2k + 1) E K^2 \left(\frac{x - X_1}{h_k} \right) = \\ = 2(\beta - \gamma) f(x) \int_{-\infty}^{\infty} K^2(y) dy. \end{aligned} \quad (4-17)$$

Démonstration

On écrit le terme de gauche de l'expression (4-17) sous la forme :

$$u_n = \frac{1}{b_n} \sum_{j=1}^n h_j v_j \quad (4-18)$$

avec :

$$v_j = \frac{h_j}{b_j^2} \sum_{k=1}^j (2j - 2k + 1) E K^2 \left(\frac{x - X_1}{h_k} \right). \quad (4-19)$$

En remarquant que (4-3) peut s'étendre au cas des moments supérieurs à l'unité, on a en particulier :

$$\frac{1}{h_n} EK^2 \left(\frac{x - X_1}{h_n} \right) \xrightarrow{n \rightarrow \infty} f(x) \int_{-\infty}^{\infty} K^2(y) dy \quad (4-20)$$

et en appliquant trois fois le lemme de Toeplitz dans l'expression (4-19) on établit que :

$$v_j \underset{j \rightarrow \infty}{\sim} 2 \left(\frac{j h_j}{b_j} - \frac{h_j}{b_j^2} \sum_{k=1}^j k h_k \right) f(x) \int_{-\infty}^{\infty} K^2(y) dy . \quad (4-21)$$

En tenant compte de (3-2) et (4-16) on déduit de (4-21) que :

$$\lim_{j \rightarrow \infty} v_j = 2(\beta - \gamma) f(x) \int_{-\infty}^{\infty} K^2(y) dy . \quad (4-22)$$

Enfin en rapprochant (4-18) et (4-22) et en appliquant une dernière fois le lemme de Toeplitz on trouve (4-17).

Proposition 4-1

f_4 désignant l'estimateur donné par (3-6) et C'_4 étant le sous ensemble de $C'_3 \cap C_4$ pour lequel $\{h_n\}$ vérifie (4-16) avec $\gamma \in]\beta - \frac{1}{2}, \beta]$, alors relativement à C'_4 on a :

$$f_4 \rightsquigarrow f_3 , \quad (4-23)$$

$$f_4 \rightsquigarrow f_2 , \quad (4-24)$$

et

$$f_4 \rightsquigarrow f_1 . \quad (4-25)$$

Démonstration

Le lemme 4-2 permet d'établir que :

$$\frac{\text{Var } f_{4,n}(x)}{\text{Var } f_{3,n}(x)} \leq u_n$$

$$\text{avec } u_n = \frac{1}{\text{Var } f_{3,n}(x)} \frac{1}{b_n^2} \sum_{j=1}^n \frac{h_j^2}{b_j^2} \sum_{k=1}^j (2j - 2k + 1) EK^2 \left(\frac{x - X_1}{h_k} \right) . \quad (4-26)$$

Le lemme 4-3 et (2-17) permettent de conclure que :

$$\lim_{n \rightarrow \infty} u_n = 2(\beta - \gamma) . \quad (4-27)$$

Avec l'hypothèse sur γ on a $2(\beta - \gamma) \in [0, 1[$, aussi en appliquant le lemme 3-2 avec $b = 2(\beta - \gamma)$ on obtient (4-23), (4-24) et (4-25) découlent du lemme 3-1 sur la transitivité.

A l'aide d'exemples on vérifie maintenant que C'_4 n'est pas l'ensemble vide.

Les conditions de monotonie sur $K(y)$ sont vérifiées pour une classe importante de fonction densité. Une telle classe contient par exemple les fonctions densité correspondant au cas des distributions uniforme, triangulaire, gaussienne, exponentielle et de Cauchy.

Quant aux conditions sur $\{h_n\}$, elles sont vérifiées par exemple dans le cas pratique important où $h_n = n^{-s}$ avec $s \in]0, 1[$. En effet, en utilisant une fois de plus la propriété :

$$\frac{1}{n^{1-s}} \sum_{j=1}^n j^{-s} \xrightarrow{n \rightarrow \infty} \frac{1}{1-s} \quad \forall s < 1 \quad (4-28)$$

on trouve que :

$$\alpha = \frac{1}{s+1}, \quad (4-29)$$

$$\beta = 1-s, \quad (4-30)$$

et

$$\gamma = \frac{(1-s)^2}{2-s}. \quad (4-31)$$

On peut vérifier, que pour tout $s \in]0, 1[$, α , β et γ appartiennent bien aux intervalles $]0, 1[$, $]0, \alpha[$ et $]\beta - \frac{1}{2}, \beta[$ respectivement.

Remarque 4-2

A partir de (4-30) et (4-31) on trouve que $2(\beta - \gamma) = 2 \frac{1-s}{2-s}$, ce qui permet d'apprécier quantitativement le gain obtenu en utilisant $f_{4,n}(x)$ au lieu de $f_{3,n}(x)$ pour les suites $\{h_n\}$ du type $h_n = n^{-s}$ (Voir 4-27)).

On doit bien noter qu'on obtient (à cause de l'inégalité (4-9)) une évaluation pessimiste de ce gain.

Dans le cas où $K(y)$ correspond à la "fenêtre rectangulaire" (noyau unité) ou à la "fenêtre triangulaire" on peut faire le calcul exact de la limite de $\frac{\text{Var } f_{4,n}(x)}{\text{Var } f_{3,n}(x)}$

Tout calcul fait on aboutit aux résultats suivants :

$$\text{pour } K(y) = \frac{1}{2} 1_{]-1,1]}(y) \quad \lim_{n \rightarrow \infty} \frac{\text{Var } f_{4,n}(x)}{\text{Var } f_{3,n}(x)} = 2 \frac{(1-s)^2}{2-s}, \quad (4-32)$$

$$\text{pour } k(y) = (1 - |y|) 1_{]-1,1]}(y) \quad \lim_{n \rightarrow \infty} \frac{\text{Var } f_{4,n}(x)}{\text{Var } f_{3,n}(x)} = \frac{(1-s)^2 (3s+2)}{(2-s)(1+s)} \quad (4-33)$$

Si on choisit $s = 1/2$, la limite apparaissant dans l'expression (4-32) vaut $1/3$, celle apparaissant dans (4-33) vaut $7/18$.

REFERENCES

- [1] DEHEUVELS P. — Sur une application de la théorie des processus de renouvellement à l'estimation de la densité d'une variable aléatoire. *C.R. Acad. Sc. Paris*, (26 Mars 1973), t. 276, série A, p. 943-946.
- [2] DEHEUVELS P. — Sur une famille d'estimateurs de la densité d'une variable aléatoire. *C.R. Acad. Sc. Paris*, (2 Avril 1973), t. 276, série A, p. 1013-1015.
- [3] DEHEUVELS P. — Sur l'estimation séquentielle de la densité. *C.R. Acad. Sc. Paris*, (16 Avril 1973), t. 276, série A, p. 1119-1121.
- [4] DEHEUVELS P. — Conditions nécessaires et suffisantes de convergence ponctuelle presque sûre et uniforme presque sûre des estimateurs de la densité. *C.R. Acad. Sc. Paris*, (29 Avril 1974), t. 278, série A, p. 1217-1220.
- [5] DEHEUVELS P. — Estimation séquentielle de la densité. Thèse présentée à l'Université de Paris VI, 1974, p. 1-121.
- [6] LOEVE M. — Probability Theory. Third Edition, Van Nostrand Reinhold, 1963, p. 238.
- [7] PARZEN E. — On the estimation of a probability density function and the mode. *Ann. Math. Statist.*, 1962, vol. 33, p. 1065-1076.
- [8] ROSENBLATT M. — Remarks on some non parametric estimates of a density function. *Ann. Math. Statist.*, 1956, vol. 27, p. 832-837.
- [9] ROSENBLATT M. — Curve Estimates. *Ann. Math. Statist.*, 1971, vol. 42, p. 1815-1842.
- [10] YAMATO H. — Sequential estimation of a continuous probability density function and mode. *Bull. Math. Statist. Jap.*, 1972, vol. 14, p. 1-12.

REMERCIEMENTS

L'auteur tient ici à remercier Monsieur Chevalier pour ses remarques très précieuses qui ont permis d'améliorer substantiellement la première version de cette note.

Ce travail a été terminé à l'Université de Californie (Berkeley) grâce à une bourse (No. 01P75-04371) de la NSF (National Science Foundation) dans le cadre d'un programme d'échange entre l'Electronic Research Laboratory et le Laboratoire d'Automatique et d'Analyse des Systèmes du CNRS.