

## ESTIMATION DE DENSITÉS

Soit  $X$  une variable aléatoire réelle continue de densité de probabilité  $f$  inconnue. On suppose que  $f$  est dérivable à dérivée continue bornée. On peut estimer la densité  $f$  par l'estimateur de Parzen-Rosenblatt défini, pour tout  $x \in \mathbb{R}$ , par

$$f_n(x) = \frac{1}{nh_n} \sum_{k=1}^n K\left(\frac{x - X_k}{h_n}\right)$$

où  $(X_1, \dots, X_n)$  est un  $n$ -échantillon de même loi que  $X$  et  $K$  est une fonction positive bornée, appelée noyau, telle que

$$\int_{\mathbb{R}} K(x)dx = 1, \quad \int_{\mathbb{R}} xK(x)dx = 0, \quad \int_{\mathbb{R}} (K(x))^2 dx = \xi^2.$$

La fenêtre  $(h_n)$  est une suite déterministe, strictement positive et décroissante vers zéro, telle que  $nh_n$  tend vers l'infini. On utilisera dans toute la suite  $h_n = 1/n^\alpha$  avec  $\alpha \in ]0, 1[$ . La détermination du noyau n'est pas un point crucial. On peut utiliser le noyau gaussien

$$K(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{x^2}{2\sigma^2}\right)$$

avec  $\sigma > 0$ . On peut aussi utiliser des noyaux à support compact, en particulier les noyaux Uniforme, d'Epanechnikov, ou Quadratique, donnés pour  $a > 0$ ,  $b > 0$  et  $c > 0$ , par

$$K(x) = \frac{1}{2a} \mathbb{I}_{|x| \leq a}, \quad K(x) = \frac{3}{4b} \left(1 - \frac{x^2}{b^2}\right) \mathbb{I}_{|x| \leq b}, \quad K(x) = \frac{15}{16c} \left(1 - \frac{x^2}{c^2}\right)^2 \mathbb{I}_{|x| \leq c}.$$

On peut montrer la convergence presque sûre

$$\lim_{n \rightarrow \infty} f_n(x) = f(x) \quad \text{p.s.}$$

ainsi que la normalité asymptotique pour  $1/5 < \alpha < 1$ ,

$$\sqrt{nh_n} \left( f_n(x) - f(x) \right) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \xi^2 f(x)).$$

Une autre stratégie pour estimer la densité  $f$  consiste à utiliser des estimateurs récursifs comme les estimateurs de Wolverton-Wagner-Yamato ou de Wegman-Davies, respectivement définis, pour tout  $x \in \mathbb{R}$ , par

$$\hat{f}_n(x) = \frac{1}{n} \sum_{k=1}^n \frac{1}{h_k} K\left(\frac{x - X_k}{h_k}\right), \quad \tilde{f}_n(x) = \frac{1}{nh_n^{1/2}} \sum_{k=1}^n \frac{1}{h_k^{1/2}} K\left(\frac{x - X_k}{h_k}\right).$$

L'estimateur de Wegman-Davies partage les mêmes propriétés asymptotiques que celui de Parzen-Rosenblatt. Par contre, pour l'estimateur de Wolverton-Wagner-Yamato, on a la convergence p.s. ainsi que la normalité asymptotique pour  $1/5 < \alpha < 1$ ,

$$\sqrt{nh_n} \left( \hat{f}_n - f(x) \right) \xrightarrow{\mathcal{L}} \mathcal{N}\left(0, \frac{\xi^2}{1 + \alpha} f(x)\right).$$

Créer un code Scilab permettant de visualiser les convergences presque sûres et les normalités asymptotiques de ces trois estimateurs de  $f$ . Utiliser les commandes `tic`, `toc` et `timer` afin de comparer les vitesses d'exécution et le temps CPU consommé de ces trois procédures d'estimation de  $f$ . Choisir plusieurs valeurs de la fenêtre  $\alpha$  et préciser la procédure d'estimation qui vous semble la plus efficace.