

## ESTIMATEUR DE LA DENSITÉ (C5, H)

(27 / 08 / 2020, © Monfort, Dicostat2005, 2005-2020)

Une **densité de probabilité** est un **paramètre** particulier, à caractère « fonctionnel ». Son **estimation** peut s'effectuer dans un **contexte** paramétrique ou non.

On considère un **échantillon**  $X = (X_1, \dots, X_N)$  constitué de **copies** issues d'une **va** réelle (scalaire ou vectorielle)  $\xi$ , dont la **loi**  $P^\xi$  admet une **densité**  $f$  pr à une **mesure** donnée  $\mu$ . L'objectif est l'estimation de  $f$ .

(i) Divers **estimateurs** de  $f$  ont été définis, soit à l'aide d'une méthode **paramétrique**, soit par une **méthode non paramétrique**. Les plus classiques sont les suivants :

(a) estimateur par le **noyau** : méthode de PARZEN, méthode de ROSENBLATT (cf **méthode du noyau**) ;

(b) **estimateur du maximum de vraisemblance** (avec **pénalisation** éventuelle), notamment lorsque  $f$  dépend d'un **paramètre**  $\theta$  ;

(c) **estimateur par tamisage** (cf **méthode des tamis**) ;

(d) **estimateur par les fonctions orthogonales**, basé sur un développement de la densité  $pr$  à une base de **fonctions orthogonales** (ou de fonctions orthonormales) (cf **méthode des fonctions orthogonales**) ;

(e) estimateur par **fonction spline** : **estimateur spline de la densité**, ou « **histo-spline** » ;

(f) estimateur par les **moments** (cf **méthode des moments**) ;

(g) estimateur par développement en série (tronqué) : cf eg **série de CHARLIER**, **développement de CHARLIER-GRAM** ;

(h) estimateur par une **méthode des moindres carrés** ou, plus généralement, par moindre **distance** ou par une **méthode de moindre norme** (cf **estimateur à distance minimale**, **estimateur à distance minimum**).

Ainsi, lorsque  $f$  dépend d'un paramètre  $\theta \in \mathbf{R}^Q$ , on en construit un **histogramme**  $h$  en  $K$  classes, puis l'on estime  $\theta$  par **régression** des **fréquences relatives** (empiriques)  $f_k$  (avec  $k = 1, \dots, K$ ) sur des points  $x_k \in I_k$  (eg les centres des classes  $I_k$ ) (cf **fréquence empirique**).

Par suite (en supposant que  $Q < K$ ), le **modèle de régression** (non linéaire) :

$$(1) \quad f_k = f(x_k, \theta) + u_k, \quad \forall k = 1, \dots, K,$$

conduit à un estimateur non strict (cf **estimateur strict**) ;

(i) estimateur par **dérivation** : on estime la **fonction de répartition**  $F$  de  $\xi$  à l'aide d'une fonction  $F_N \sim$ , supposée dérivable, puis on estime  $f$  par la dérivée  $(F_N \sim)'$  de  $F_N \sim$ .

(ii) Lorsque la densité  $f$  est paramétrable par  $\theta \in \Theta$ , avec  $\Theta \subset \mathbf{R}^Q$ , les méthodes généralement utilisées sont la **méthode du mv** et la **méthode des moments**.

On peut parfois estimer une **caractéristique** donnée de  $P^\xi$  (ou de  $f$ ) (eg le **mode**, un **p-quantile** ou un **moment**) de façon indirecte : on définit l'estimateur à partir de la caractéristique analogue de l'estimateur  $f_N \sim$  de  $f$  (ie celle de l'estimateur de  $P^\xi$  qui s'en déduit implicitement).