

# Statistiques avec SAS : Sujet du TD N°6

Jean-Sébastien Roy (js@jeannot.org)

## 1 Estimation non paramétrique d'une densité

Créer une table, que l'on appellera `deuxn`, contenant quelques centaines de tirages d'observations `xi` suivant une loi  $N(0,1)$  pour 50% d'entre eux, et  $N(4,1.5)$  pour les 50% restants.

Créer une table, que l'on appellera `grid`, contenant une seule variable `x`, et dont les valeurs parcourent l'intervalle  $[-4,9]$  avec un pas tel que la table contienne une centaine de valeurs.

Calculer dans une table que l'on appellera `exact`, la valeur exacte de la densité pour l'ensemble des valeurs de la table `grid`.

Créer une table, que l'on appellera `stats`, contenant le nombre d'observations  $n$ , l'écart type  $\hat{\sigma}$ , et l'intervalle inter-quartiles  $Q_{range}$  de la variable `xi` de la table `deuxn`.

Soit :

$$SNR = \hat{\sigma} \left( \frac{4}{3n} \right)^{\frac{1}{5}}$$

Créer une table, que l'on appellera `h`, contenant une dizaine de valeur de  $h = SNR \cdot e^f$  où  $f$  varie dans l'intervalle  $[\ln(0.05), \ln(3)]$ . La valeur  $h$  est appelée fenêtre.

Créer une table, que l'on appellera `kesti`, contenant pour l'ensemble des valeurs de `h` (dans la table `h`) et de `x` (dans la table `grid`) la variable `y` définie ainsi :

Soit le noyau gaussien :

$$K(d) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}d^2}$$

Alors on appelle estimateur de Rozenblatt-Parzen la fonction :

$$y_h(x) = \frac{\sum_i K\left(\frac{x-x_i}{h}\right)}{nh}$$

Tracer une un même graphe les fonctions  $y_h$  et la densité précédemment calculée.

Comparer en fonction de  $h$  la moyenne des carrées des écarts sur les points de la grille, entre  $y_h$  et la densité précédemment calculée.

Recalculer et tracer  $y_h$  pour les valeurs de  $h$  suivantes :

$$h = SNR$$

$$h = SROT = 0.9 \cdot \min\left(\hat{\sigma}, \frac{Q_{range}}{1.34}\right) \cdot n^{-\frac{1}{5}}$$

$$h = OS = 3\hat{\sigma} \left( \frac{1}{70\sqrt{\pi n}} \right)^{\frac{1}{5}}$$

Ainsi que pour la valeur de  $h$  obtenue en réalisant une estimation non paramétrique de la densité avec SAS/Insight.

## 2 Estimation fonctionnelle non paramétrique

Créer une table `points`, contenant pour une centaine de valeurs de  $x_i$  suivant une loi uniforme sur  $[0, 1]$ , la valeur  $y_i = f(x_i)$  de la fonction  $f$  définie par :  $f(x) = \frac{1}{2} - 2x$  si  $x < \frac{1}{5}$ , et  $f(x) = x - \frac{1}{10}$  sinon ; fonction que l'on perturbera par l'ajout d'un bruit suivant une loi normale d'écart type  $\frac{1}{10}$ .

Calculer de manière similaire à la question précédente les tables `exact`, `stats`, `h` et `grid`.

Calculer de même les valeurs de l'estimateur de Nadaraya-Watson (1964) :

$$y_h(x) = \frac{\sum_i K\left(\frac{x-x_i}{h}\right) y_i}{\sum_i K\left(\frac{x-x_i}{h}\right)}$$

Tracer les courbes simultanément et les comparer avec la courbe exacte. On calculera de même la moyenne des carrés des écarts en fonction de  $h$ .

Calculer et tracer en fonction de  $h$  la validation croisée (Clark, 1975) qui correspond la moyenne des carrés des écarts entre  $y_i$  et la valeur  $y_h(x)$  calculée sans prendre en compte le point  $i$ , ce qui correspond à la valeur du PRESS en régression linéaire.