

# Estimation de densités par noyaux

Cuvelier F.

6 juin 2009

## Table des matières

<b>1</b>	<b>Rappels</b>	<b>1</b>
<b>2</b>	<b>Comparaison de différents noyaux</b>	<b>4</b>
2.1	Noyaux d'ordre 2 et $X \sim \mathcal{N}(0; 1)$	4
2.2	Noyaux d'ordre 2 et $X \sim \mathcal{N}(0; 0.2^2)$	6
2.3	Noyaux d'ordre 2 et $X \sim \frac{1}{2}\mathcal{N}(-0.4; 0.2^2) + \frac{1}{2}\mathcal{N}(0.3; 0.4^2)$	8
2.4	Noyaux d'ordre 2 et $X \sim 0.3\mathcal{N}(-0.45; 0.1^2) + 0.7\mathcal{N}(0.4; 0.2^2)$	10
2.5	Noyaux d'ordre 2 et $X \sim \frac{1}{2}\mathcal{N}(1; (4/7)^2) + \frac{1}{2}\mathcal{N}(1; (4/7)^2)$	12
2.6	Noyaux d'ordre 2 et $X \sim \mathcal{U}([0; 1])$	14
2.7	Noyaux d'ordre 2 et $X \sim \mathcal{U}([-1; 2])$	16
2.8	Noyaux d'ordre 2 et Densité discontinue (Density1.m)	18
2.9	Noyaux d'ordre 2 et Densité discontinue (Density2.m)	21

## 1 Rappels

Soit  $X = (X_1, \dots, X_N)$  un  $N$ -échantillon de variables aléatoires indépendantes et identiquement distribuées selon une loi  $\mu$  de densité  $f$  inconnue.

On veut illustrer les techniques d'estimation par noyaux introduites par Rosenblatt (1956) et Parzen (1962).

Les estimateurs  $\hat{f}_h(x)$  sont définis par

$$\hat{f}_{N,h}(x) = \frac{1}{N} \sum_{i=1}^N K_h(x - X_i) \quad (0.1)$$

où  $h$  est la largeur de fenêtre et  $K$  le noyau,  $K_h(u) = K(u/h)/h$ .

Habituellement, on impose les conditions suivantes sur  $K$  :

**Propriété 1.1.** On appelle noyau d'ordre  $k$ , l'application  $K$  de  $\mathbb{R}$  dans  $\mathbb{R}$  vérifiant

1.  $K$  est symétrique,  $K(u) = K(-u)$ ,
2.  $\int_{\mathbb{R}} K(u) du = 1$
3.  $\int_{\mathbb{R}} u^j K(u) du = 0, \forall j \in [1, k-1]$
4.  $\int_{\mathbb{R}} u^k K(u) du \neq 0$

Pour  $k = 2$ , on peut imposer à  $K$  d'être positif, i.e.  $K$  est alors une densité de probabilité. Pour  $k > 2$ , il est nécessaire que  $K$  puisse prendre des valeurs négatives (Berwin A. Turlach).

Voici quelques noyaux usuels d'ordre 2, où l'on note  $I(\bullet)$  la fonction indicatrice :




FIG. 1 – Mauvais choix du paramètre  $h$  : trop petit (gauche), trop grand (droite)

Noyau d'ordre 2	$K(u)$
Uniform	$\frac{1}{2}I( u  \leq 1)$
Triangle	$(1 -  u )I( u  \leq 1)$
Epanechnikov	$\frac{3}{4}(1 - u^2)I( u  \leq 1)$
Quartic	$\frac{15}{16}(1 - u^2)^2I( u  \leq 1)$
Triweight	$\frac{35}{32}(1 - u^2)^3I( u  \leq 1)$
Gaussian	$\frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2}u^2)$

Il ressort de Silverman (1986), le fait que le choix de  $h$  est plus important pour le comportement de  $\hat{f}_{N,h}$  que le choix du noyau  $K$ . De petites valeurs de  $h$  font que l'estimation est fortement <bruitée> et de grandes valeurs régularisent de trop l'estimation (voir figure 1).

Avec un paramètre  $h$  optimisé, on obtient la figure 1








FIG. 2 – choix du paramètre  $h$  optimisé :  $h_{opt} \approx 0.075$



## 2 Comparaison de différents noyaux

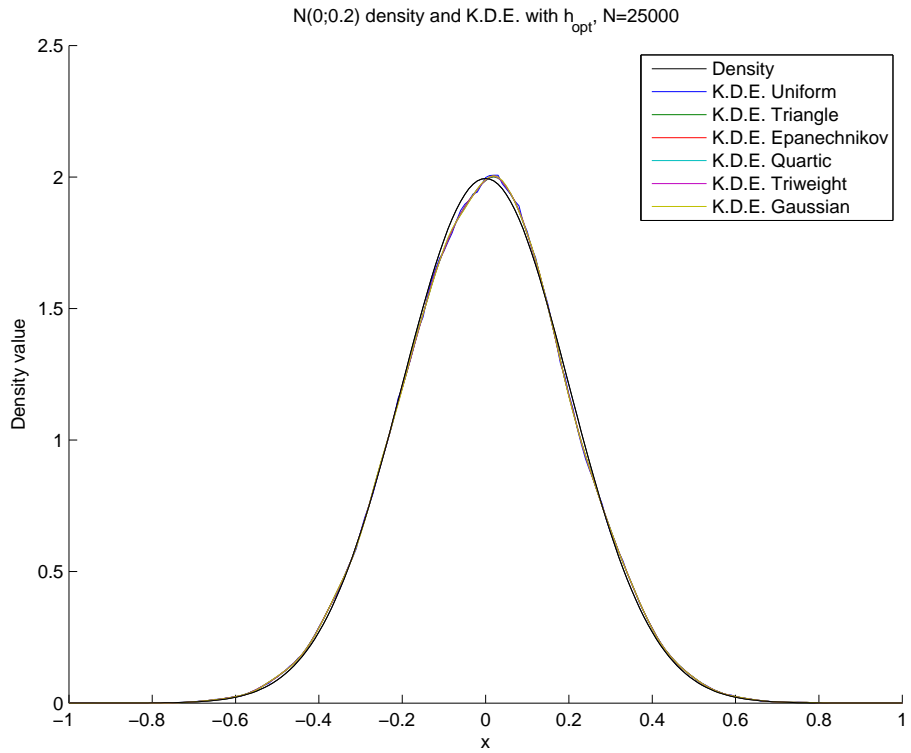
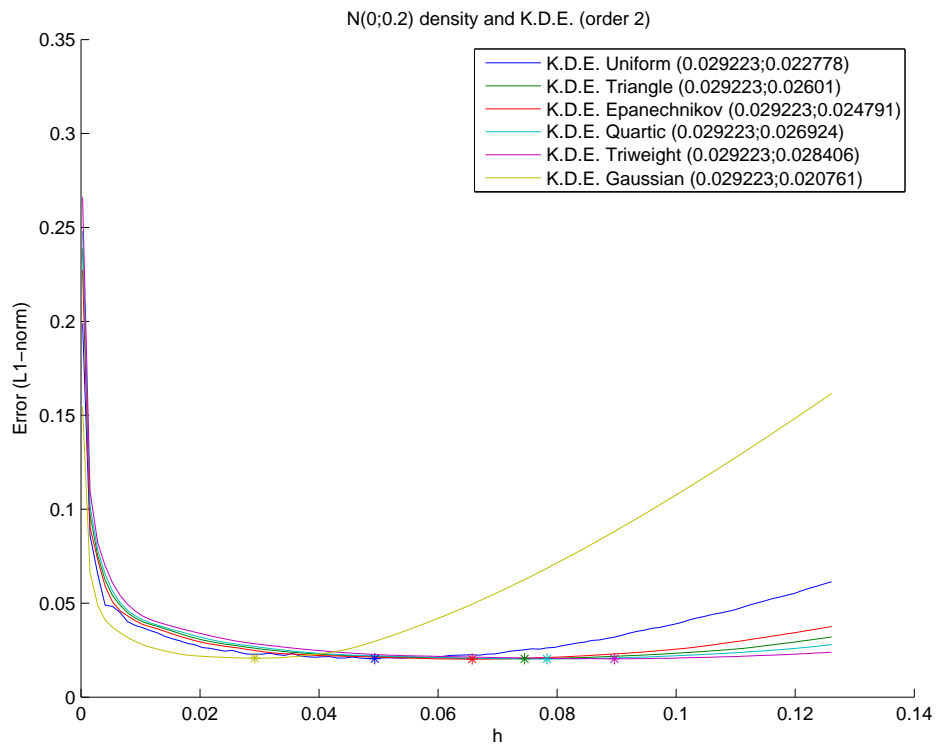
### 2.1 Noyaux d'ordre 2 et $X \sim \mathcal{N}(0; 1)$









## 2.2 Noyaux d'ordre 2 et $X \sim \mathcal{N}(0; 0.2^2)$









### 2.3 Noyaux d'ordre 2 et $X \sim \frac{1}{2}\mathcal{N}(-0.4; 0.2^2) + \frac{1}{2}\mathcal{N}(0.3; 0.4^2)$









## 2.4 Noyaux d'ordre 2 et $X \sim 0.3\mathcal{N}(-0.45; 0.1^2) + 0.7\mathcal{N}(0.4; 0.2^2)$









## 2.5 Noyaux d'ordre 2 et $X \sim \frac{1}{2}\mathcal{N}(1; (4/7)^2) + \frac{1}{2}\mathcal{N}(1; (4/7)^2)$









## 2.6 Noyaux d'ordre 2 et $X \sim \mathcal{U}([0; 1])$



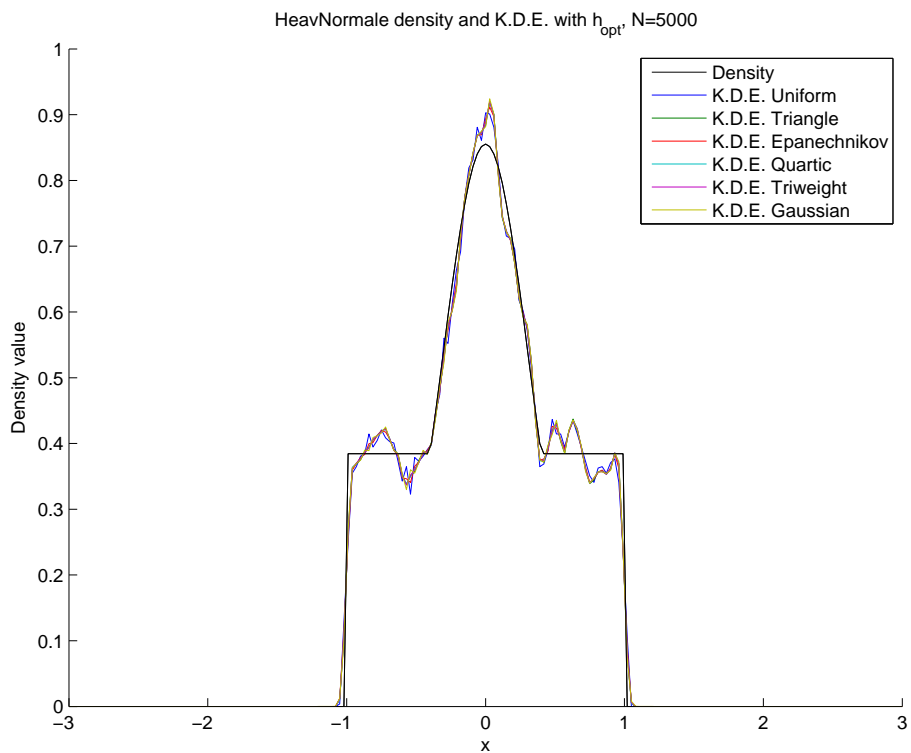
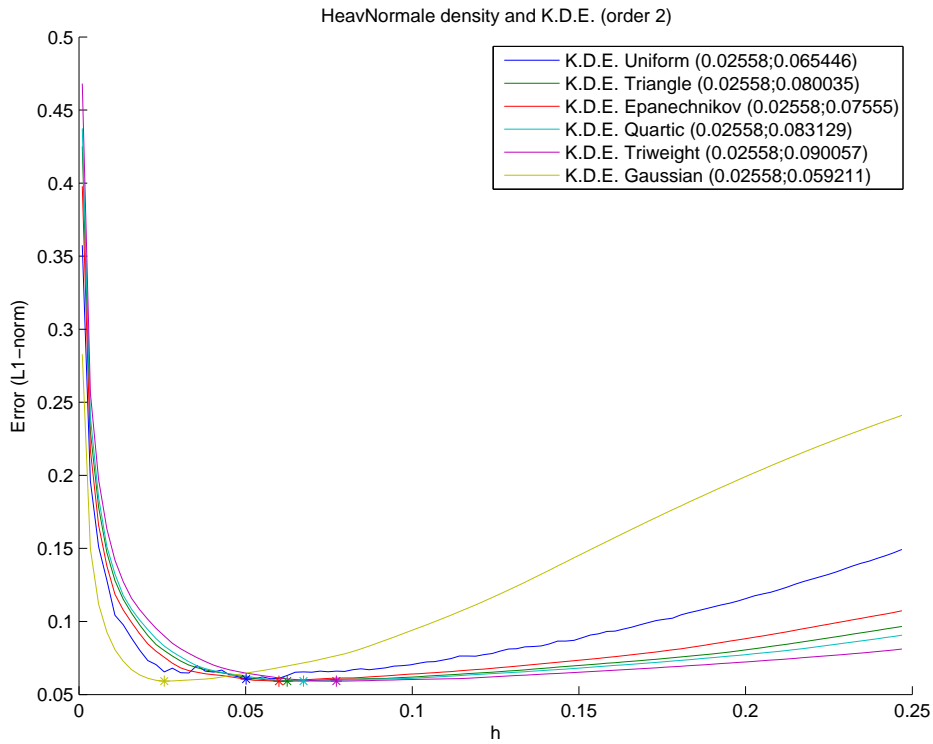


## 2.7 Noyaux d'ordre 2 et $X \sim \mathcal{U}([-1; 2])$







## 2.8 Noyaux d'ordre 2 et Densité discontinue (Density1.m)

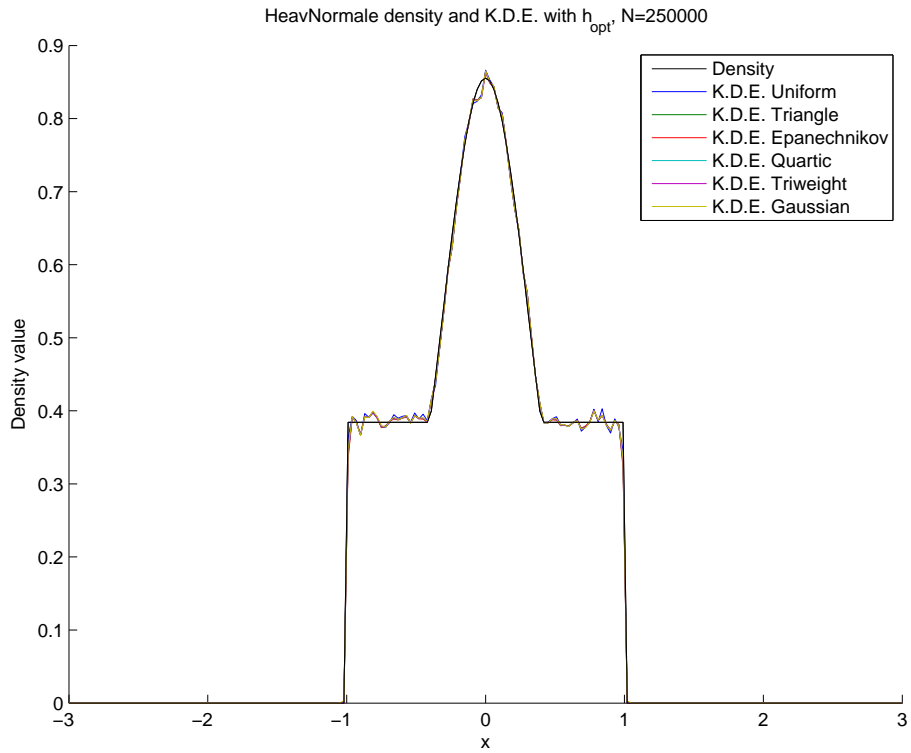



HeavNormale density and K.D.E. (order 2)

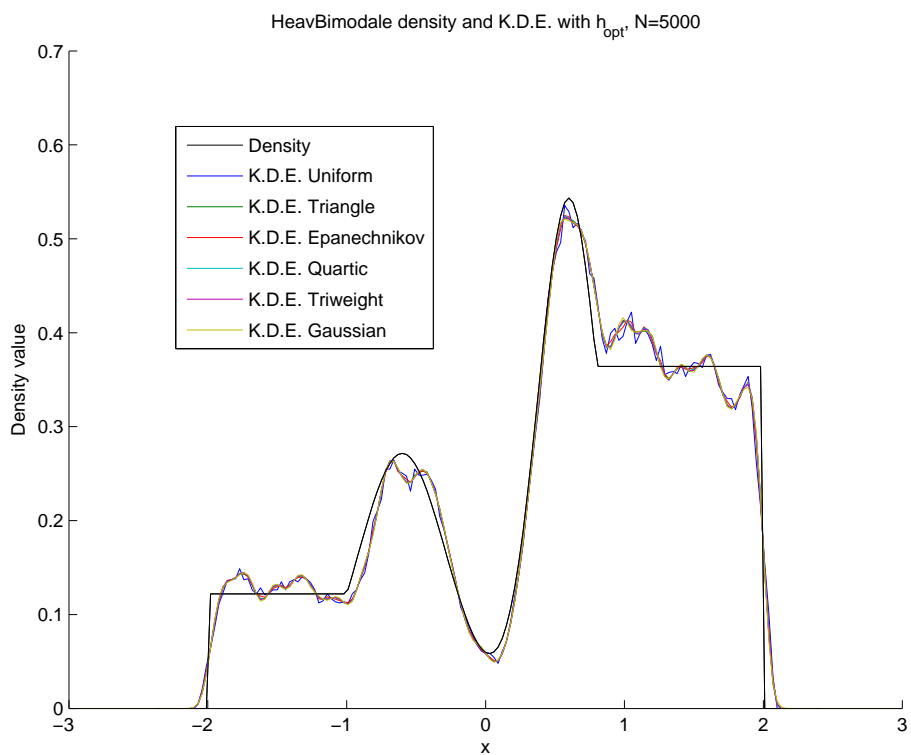



HeavNormale density and K.D.E. with  $h_{opt}$ , N=25000






## 2.9 Noyaux d'ordre 2 et Densité discontinue (Density2.m)



HeavBimodale density and K.D.E. (order 2)



HeavBimodale density and K.D.E. with  $h_{opt}$  N=25000

