

# De l'utilisation des noyaux maxitifs en traitement de l'information

Kevin Loquin

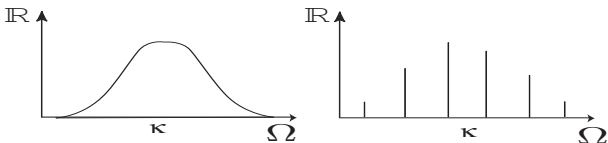
LIRMM

3 Novembre 2008

# Plan

- 1 Introduction
- 2 Extraction sommative d'informations
  - Principe et définition
  - Extraction sommative et théorie des probabilités
  - Applications
  - Discussion
- 3 Extraction maxitive d'informations
  - Principe et définition
  - Applications
- 4 Conclusion

# Noyau sommatif



## Définition

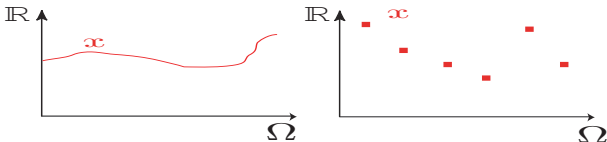
$$\sum_{i \in \Omega} \kappa_i = 1,$$

*dans le cas discret*

$$\int_{\Omega} \kappa(\omega) d\omega = 1,$$

*dans le cas continu*

# Extraction sommative d'informations

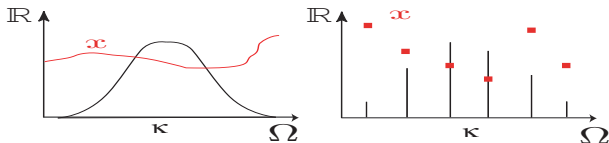


## Définition

$$y(\theta) = \sum_{i \in \Omega} x_i \kappa_i^\theta = \langle x, \kappa^\theta \rangle_{L_1(\Omega)}$$

$$y(\theta) = \int_{\Omega} x(\omega) \kappa^\theta(\omega) d\omega = \langle x, \kappa^\theta \rangle_{L_1(\Omega)}$$

# Extraction sommative d'informations

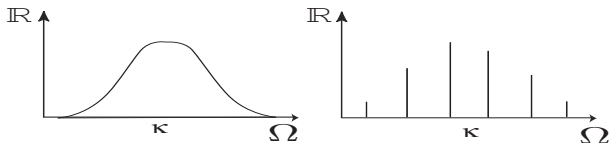


## Définition

$$y(\theta) = \sum_{i \in \Omega} x_i \kappa_i^\theta = \left\langle x, \kappa^\theta \right\rangle_{L_1(\Omega)}$$

$$y(\theta) = \int_{\Omega} x(\omega) \kappa^\theta(\omega) d\omega = \left\langle x, \kappa^\theta \right\rangle_{L_1(\Omega)}$$

## Noyau sommatif et distribution de probabilité

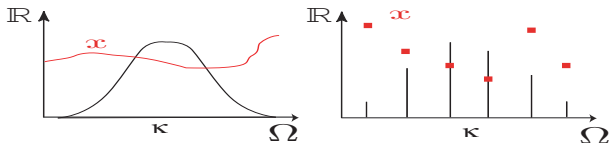


### Définition

$$P_{\kappa}(A) = \sum_{i \in A} \kappa_i, \quad \text{dans le cas discret}$$

$$P_{\kappa}(A) = \int_A \kappa(\omega) d\omega, \quad \text{dans le cas continu}$$

# Extraction sommative et espérance mathématique



## Définition

$$y(\theta) = \sum_{i \in \Omega} x_i \kappa_i^\theta = \langle x, \kappa^\theta \rangle_{\mathcal{H}(\Omega)} = \mathbb{E}_{\kappa^\theta}(x)$$

$$y(\theta) = \int_{\Omega} x(\omega) \kappa^\theta(\omega) d\omega = \langle x, \kappa^\theta \rangle_{\mathcal{H}(\Omega)} = \mathbb{E}_{\kappa^\theta}(x)$$

# Utilisation

- Statistiques :
  - Estimation de densité de probabilité par noyau de Parzen Rosenblatt, par histogramme binaire ou flou
  - Estimation de fonction de répartition par noyau de Parzen Rosenblatt, par histogramme binaire ou flou



# Utilisation

- Statistiques :
  - Estimation de densité de probabilité par noyau de Parzen Rosenblatt, par histogramme binaire ou flou
  - Estimation de fonction de répartition par noyau de Parzen Rosenblatt, par histogramme binaire ou flou
- Traitement du signal :
  - Modélisation de la mesure
  - Passages entre représentations continue et discrète d'un signal : interpolation et échantillonnage
  - Filtrage numérique ou analogique linéaire d'un signal
  - Dérivation d'un signal

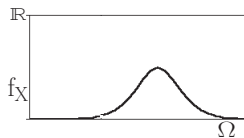
# Utilisation

- Statistiques :
  - Estimation de densité de probabilité par noyau de Parzen Rosenblatt, par histogramme binaire ou flou
  - Estimation de fonction de répartition par noyau de Parzen Rosenblatt, par histogramme binaire ou flou
- Traitement du signal :
  - Modélisation de la mesure
  - Passages entre représentations continue et discrète d'un signal : interpolation et échantillonnage
  - Filtrage numérique ou analogique linéaire d'un signal
  - Dérivation d'un signal
- Traitement d'image :
  - Transformation rigide d'une image
  - Modélisation de la projection tomographique

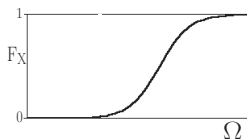
## Estimateurs de Parzen Rosenblatt

Soit  $X$  une variable aléatoire réelle de loi  $P$ .

- densité de probabilité  $f_X$ .



- fonction de répartition  $F_X$



# Estimateurs de Parzen Rosenblatt

Pour  $n$  observations  $(x_1, \dots, x_n)$ , les **estimateurs de Parzen Rosenblatt** de  $f_X$  et de  $F_X$  sont respectivement donnés par :

## Résultat

$$\hat{f}_{n\kappa}(x) = \frac{1}{n} \sum_{i=1}^n \kappa(x - x_i)$$

$$\hat{F}_{n\kappa}(x) = \int_{-\infty}^x \frac{1}{n} \sum_{i=1}^n \kappa(u - x_i) du$$

# Estimateurs de Parzen Rosenblatt

Pour  $n$  observations  $(x_1, \dots, x_n)$ , les **estimateurs de Parzen Rosenblatt** de  $f_X$  et de  $F_X$  sont respectivement donnés par :

## Résultat

$$\hat{f}_{n\kappa}(x) = \frac{1}{n} \sum_{i=1}^n \kappa(x - x_i) = \int_{\Omega} \frac{1}{n} \sum_{i=1}^n \delta_{x_i}(u) \kappa^x(u) du$$

$$\hat{F}_{n\kappa}(x) = \int_{-\infty}^x \frac{1}{n} \sum_{i=1}^n \kappa(u - x_i) du$$

$$\kappa^x(\omega) = \kappa(x - \omega),$$

# Estimateurs de Parzen Rosenblatt

Pour  $n$  observations  $(x_1, \dots, x_n)$ , les **estimateurs de Parzen Rosenblatt** de  $f_X$  et de  $F_X$  sont respectivement donnés par :

## Résultat

$$\hat{f}_{n\kappa}(x) = \frac{1}{n} \sum_{i=1}^n \kappa(x - x_i) = \int_{\Omega} \frac{1}{n} \sum_{i=1}^n \delta_{x_i}(u) \kappa^x(u) du$$

$$\hat{F}_{n\kappa}(x) = \int_{-\infty}^x \frac{1}{n} \sum_{i=1}^n \kappa(u - x_i) du$$

$$\kappa^x(\omega) = \kappa(x - \omega), \quad e_n = \frac{1}{n} \sum_{i=1}^n \delta_{x_i}$$

# Estimateurs de Parzen Rosenblatt

Pour  $n$  observations  $(x_1, \dots, x_n)$ , les **estimateurs de Parzen Rosenblatt** de  $f_X$  et de  $F_X$  sont respectivement donnés par :

## Résultat

$$\hat{f}_{n\kappa}(x) = \frac{1}{n} \sum_{i=1}^n \kappa(x - x_i) = \int_{\Omega} \frac{1}{n} \sum_{i=1}^n \delta_{x_i}(u) \kappa^x(u) du$$

$$\hat{F}_{n\kappa}(x) = \int_{-\infty}^x \frac{1}{n} \sum_{i=1}^n \kappa(u - x_i) du$$

$$\kappa^x(\omega) = \kappa(x - \omega), \quad e_n = \frac{1}{n} \sum_{i=1}^n \delta_{x_i}, \quad \mathbb{E}_{\kappa}(f) = \int_{\Omega} f(u) \kappa(u) du$$

# Estimateurs de Parzen Rosenblatt

Pour  $n$  observations  $(x_1, \dots, x_n)$ , les **estimateurs de Parzen Rosenblatt** de  $f_X$  et de  $F_X$  sont respectivement donnés par :

## Résultat

$$\hat{f}_{n\kappa}(x) = \frac{1}{n} \sum_{i=1}^n \kappa(x - x_i) = \int_{\Omega} \frac{1}{n} \sum_{i=1}^n \delta_{x_i}(u) \kappa^x(u) du = \mathbb{E}_{\kappa^x}(e_n)$$

$$\hat{F}_{n\kappa}(x) = \int_{-\infty}^x \frac{1}{n} \sum_{i=1}^n \kappa(u - x_i) du$$

$$\kappa^x(\omega) = \kappa(x - \omega), \quad e_n = \frac{1}{n} \sum_{i=1}^n \delta_{x_i}, \quad \mathbb{E}_{\kappa}(f) = \int_{\Omega} f(u) \kappa(u) du$$



# Estimateurs de Parzen Rosenblatt

Pour  $n$  observations  $(x_1, \dots, x_n)$ , les **estimateurs de Parzen Rosenblatt** de  $f_X$  et de  $F_X$  sont respectivement donnés par :

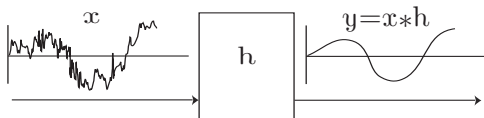
## Résultat

$$\hat{f}_{n\kappa}(x) = \frac{1}{n} \sum_{i=1}^n \kappa(x - x_i) = \int_{\Omega} \frac{1}{n} \sum_{i=1}^n \delta_{x_i}(u) \kappa^x(u) du = \mathbb{E}_{\kappa^x}(e_n)$$

$$\hat{F}_{n\kappa}(x) = \int_{-\infty}^x \frac{1}{n} \sum_{i=1}^n \kappa(u - x_i) du = \mathbb{E}_{\kappa^x}(E_n)$$

$$\kappa^x(\omega) = \kappa(x - \omega), \quad E_n(\omega) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{[x_i \leq \omega]}$$

# Filtrage linéaire d'un signal



## Définition

Filtrage analogique :  $y(\omega) = \int_{\Omega} x(v)h(\omega - v)dv = (x * h)(\omega)$

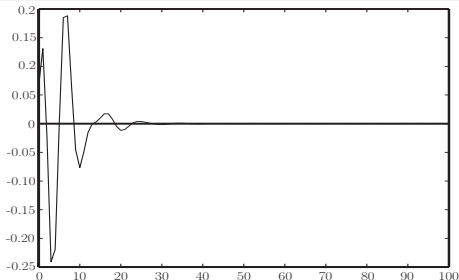
Filtrage numérique :  $y_k = \sum_{i \in \mathbb{Z}} x_i h_{k-i} = (x * h)_k$

# Filtrage linéaire d'un signal

## Théorème

*Tout noyau de convolution peut s'écrire comme la combinaison linéaire de deux noyaux sommatifs :*

$$h = a^+ \kappa^+ - a^- \kappa^-$$

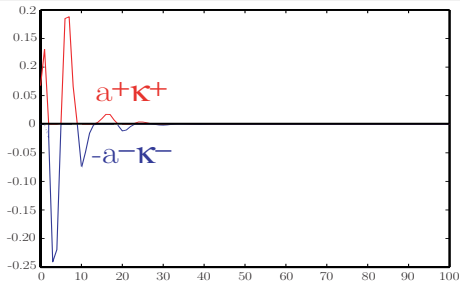


# Filtrage linéaire d'un signal

## Théorème

*Tout noyau de convolution peut s'écrire comme la combinaison linéaire de deux noyaux sommatifs :*

$$h = a^+ \kappa^+ - a^- \kappa^-$$



# Filtrage d'un signal et extraction sommative d'informations

## Résultat

**Filtrage analogique :**  $y(\omega) = a^+(x * \kappa^+)(\omega) - a^-(x * \kappa^-)(\omega)$

**Filtrage numérique :**  $y_k = a^+(x * \kappa^+)_k - a^-(x * \kappa^-)_k$

## Remarque

*L'opérateur de convolution est un opérateur d'espérance mathématique avec noyau translaté :*

$$(x * \kappa)(\omega) = \int_{\Omega} x(u)\kappa(\omega - u)du = \int_{\Omega} x(u)\kappa^{\omega}(u)du = \mathbb{E}_{\kappa^{\omega}}(x)$$

# Filtrage d'un signal et extraction sommative d'informations

## Résultat

**Filtrage analogique :**  $y(\omega) = a^+ \mathbb{E}_{\kappa^{\omega+}}(x) - a^- \mathbb{E}_{\kappa^{\omega-}}(x)$

**Filtrage numérique :**  $y_k = a^+ \mathbb{E}_{\kappa^{k+}}(x) - a^- \mathbb{E}_{\kappa^{k-}}(x)$

## Remarque


*L'opérateur de convolution est un opérateur d'espérance mathématique avec noyau translaté :*

$$(x * \kappa)(\omega) = \int_{\Omega} x(u) \kappa(\omega - u) du = \int_{\Omega} x(u) \kappa^{\omega}(u) du = \mathbb{E}_{\kappa^{\omega}}(x)$$

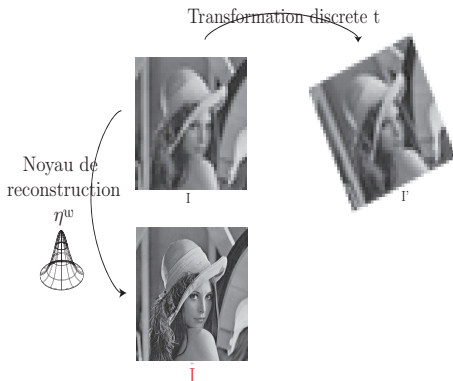
# Transformation rigide d'une image

$$I'_k = \sum_{i=1}^n I_i t_i^k$$

Transformation discrete t



# Transformation rigide d'une image





# Transformation rigide d'une image

## Résultat

Reconstruction :

$$\hat{l}(\omega) = \sum_{i=1}^n l_i \eta_i^\omega$$

$$\mathbb{E}_\kappa(f) = \sum_{i \in \Omega} f_i \kappa_i$$

# Transformation rigide d'une image

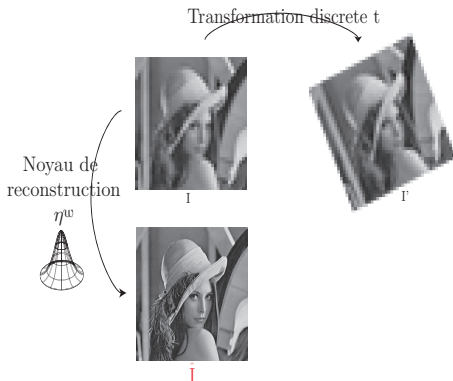
## Résultat

Reconstruction :

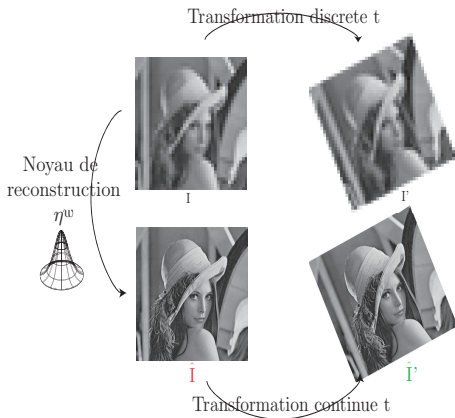
$$\hat{l}(\omega) = \sum_{i=1}^n l_i \eta_i^\omega = \mathbb{E}_{\eta^\omega}(l)$$

$$\mathbb{E}_\kappa(f) = \sum_{i \in \Omega} f_i \kappa_i$$

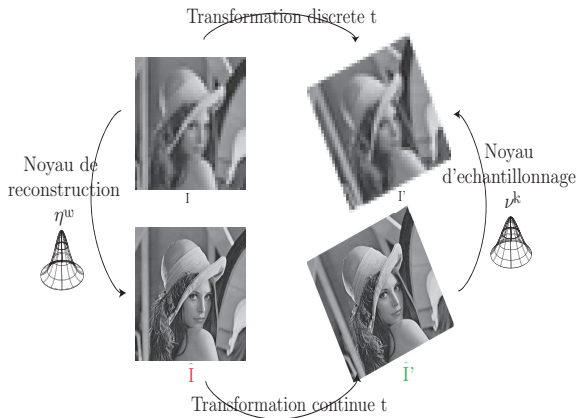
# Transformation rigide d'une image



# Transformation rigide d'une image



# Transformation rigide d'une image



# Transformation rigide d'une image

## Résultat

Échantillonnage :

$$I'_k = \int_{\Omega} \hat{I}'(v) \nu^k(v) dv$$

$$\mathbb{E}_{\kappa}(f) = \int_{\Omega} f(u) \kappa(u) du$$

# Transformation rigide d'une image

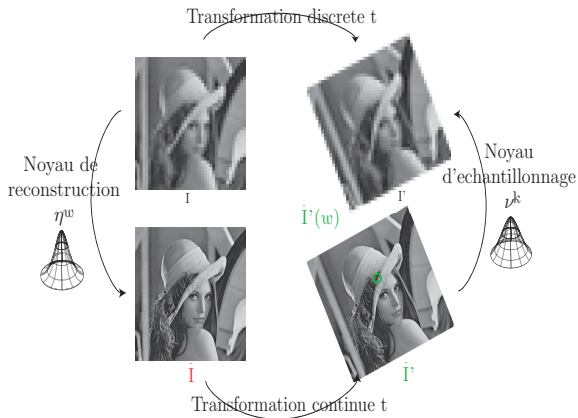
## Résultat

Échantillonnage :

$$I'_k = \int_{\Omega} \hat{I}'(v) \nu^k(v) dv = \mathbb{E}_{\nu^k}(\hat{I}')$$

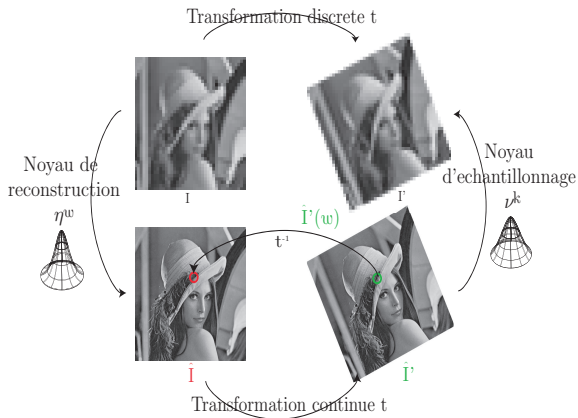
$$\mathbb{E}_{\kappa}(f) = \int_{\Omega} f(u) \kappa(u) du$$

# Transformation rigide d'une image

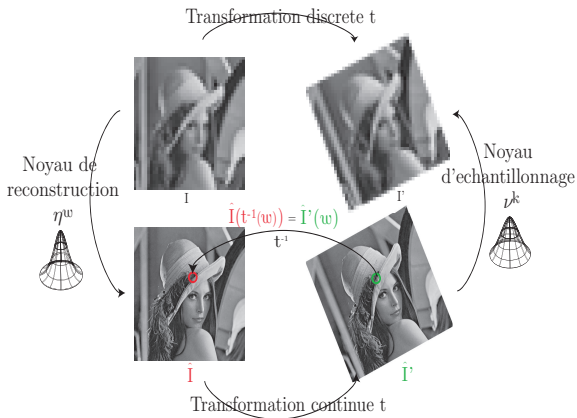




# Transformation rigide d'une image



# Transformation rigide d'une image



## Transformation rigide d'une image

### Résultat

$$l'_k = \sum_{i=1}^n l_i t_i^k$$

$$t_i^k = \int_{\Omega} \eta^{\omega}(\omega_i) t^{-1} \nu^k(\omega) d\omega$$

$$\mathbb{E}_{\kappa}(f) = \int_{\Omega} f(u) \kappa(u) du,$$

## Transformation rigide d'une image

### Résultat

$$l'_k = \sum_{i=1}^n l_i t_i^k$$

$$t_i^k = \int_{\Omega} \eta^\omega(\omega_i) t^{-1} \nu^k(\omega) d\omega = \mathbb{E}_{t^{-1} \nu^k}(\eta_i)$$

$$\mathbb{E}_{\kappa}(f) = \int_{\Omega} f(u) \kappa(u) du,$$

## Transformation rigide d'une image

### Résultat

$$l'_k = \sum_{i=1}^n l_i t_i^k$$

$$t_i^k = \int_{\Omega} \eta^{\omega}(\omega_i) t^{-1} \nu^k(\omega) d\omega = \mathbb{E}_{t^{-1} \nu^k}(\eta_i^{\bullet})$$

$$\mathbb{E}_{\kappa}(f) = \int_{\Omega} f(u) \kappa(u) du, \quad \mathbb{E}_{\kappa}(f) = \sum_{i \in \Omega} f_i \kappa_i$$

## Transformation rigide d'une image

### Résultat

$$l'_k = \sum_{i=1}^n l_i t_i^k = \mathbb{E}_{t^k}(l)$$

$$t_i^k = \int_{\Omega} \eta^{\omega}(\omega_i) t^{-1} \nu^k(\omega) d\omega = \mathbb{E}_{t^{-1} \nu^k}(\eta_i)$$

$$\mathbb{E}_{\kappa}(f) = \int_{\Omega} f(u) \kappa(u) du, \quad \mathbb{E}_{\kappa}(f) = \sum_{i \in \Omega} f_i \kappa_i$$

## Notre but

### Remarque

*Arbitraire dans le choix du noyau.*

## Notre but

### Remarque

*Arbitraire dans le choix du noyau.*

- 1 Modéliser la méconnaissance sur le bon noyau sommatif à utiliser



## Notre but

### Remarque

*Arbitraire dans le choix du noyau.*

- 1 Modéliser la méconnaissance sur le bon noyau sommatif à utiliser
- 2 prendre en compte cette méconnaissance dans les traitements

## Notre proposition

- 1 Passer d'un noyau unique à une famille de noyaux sommatifs :  
le noyau maxitif

## Notre proposition

- 1 Passer d'un noyau unique à une famille de noyaux sommatifs : le noyau maxitif
- 2 Développer une approche alternative à l'extraction sommative d'informations : l'extraction maxitive d'informations

# Notre proposition

Par quel moyen ?

## Proposition

*Utilisation de la **théorie des possibilités** à la place de la théorie des probabilités.*

## Notre proposition

Par quel moyen ?

### Proposition

Utilisation de la *théorie des possibilités* à la place de la *théorie des probabilités*.

- ① plus expressive que la théorie des probabilités

## Notre proposition

Par quel moyen ?

### Proposition

*Utilisation de la **théorie des possibilités** à la place de la théorie des probabilités.*

- 1 plus expressive que la théorie des probabilités
- 2 moins que les autres théories de probabilités imprécises (fonctions de croyance ou prévisions cohérentes...)

## Notre proposition

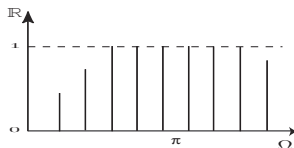
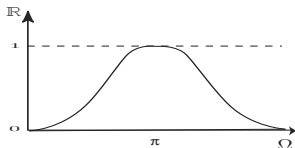
Par quel moyen ?

### Proposition

*Utilisation de la **théorie des possibilités** à la place de la théorie des probabilités.*

- 1 plus expressive que la théorie des probabilités
- 2 moins que les autres théories de probabilités imprécises (fonctions de croyance ou prévisions cohérentes...)
- 3 mais complexité algorithmique très simple

# Noyau maxitif



## Définition

$$\sup_{i \in \Omega} \pi_i = 1,$$

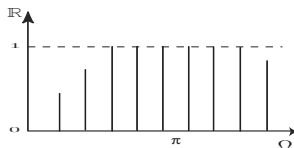
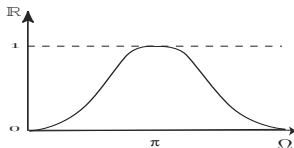
$$\sup_{\omega \in \Omega} \pi(\omega) = 1,$$

*dans le cas discret,*

*dans le cas continu.*



# Noyau maxitif et distribution de possibilité



## Définition

$$\Pi_{\pi}(A) = \sup_{i \in A} \pi_i,$$

*dans le cas discret,*

$$\Pi_{\pi}(A) = \sup_{\omega \in A} \pi(\omega),$$

*dans le cas continu,*

$$N_{\pi}(A) = 1 - \Pi_{\pi}(A^c)$$

# Extraction maxitive d'informations

**Rappel :** L'extraction sommative d'informations  $y$  à partir d'une fonction de données  $x$  pour un noyau sommatif  $\kappa$  en  $\theta$  s'écrit  $y(\theta) = \mathbb{E}_{\kappa\theta}(x)$ .

## Définition

*L'extraction maxitive d'informations à partir d'une fonction de données  $x$  pour un noyau maxitif  $\pi$  en  $\theta$  s'écrit :*

$$Y(\theta) = [\mathbb{C}_{\pi\theta}^c(x), \mathbb{C}_{\pi\theta}(x)].$$

où

$$\mathbb{C}_{\pi\theta}^c(x) = (C) \int_{\Omega} x dN_{\pi\theta}, \text{ et } \mathbb{C}_{\pi\theta}(x) = (C) \int_{\Omega} x d\Pi_{\pi\theta}.$$

## Pourquoi ces choix ?

### Propriété

*Un noyau maxitif est équivalent à une famille de noyaux sommatifs*

$$\mathcal{M}(\pi) = \{\kappa \mid \forall A \in \mathcal{B}(\Omega), N_\pi(A) \leq P_\kappa(A) \leq \Pi_\pi(A)\}.$$

# Pourquoi ces choix ?

## Théorème (Schmeidler/Denneberg)

Soit  $x$  une fonction de données. Soit  $\pi^\theta$  un noyau maxitif qui régit l'extraction maxitive d'informations en  $\theta$ , dont le résultat est noté  $Y(\theta)$ .

Pour tout noyau sommatif  $\kappa^\theta$  de  $\mathcal{M}(\pi^\theta)$ , le résultat de l'extraction sommative, noté  $y(\theta) = \mathbb{E}_{\kappa^\theta}(x)$ , est tel que :

$$y(\theta) \in Y(\theta) = [\mathbb{C}_{\pi^\theta}^c(x), \mathbb{C}_{\pi^\theta}(x)].$$

D. Schmeidler, **Integral representation without additivity**, Proceedings of the American Mathematical Society, Vol. 97, 255-261 (1986).

Proposition 3.

D. Denneberg, **Non-Additive Measure and Integral**, Kluwer Academic Publishers, Dordrecht, 1994. Proposition 10.3.

# Granularité

## Définition

La *granularité* d'un noyau maxitif  $\pi$  est définie par :

$$\Gamma(\pi) = \int_{\Omega} \pi(\omega) d\omega, \text{ dans le cas continu}$$

$$\Gamma(\pi) = \sum_{i \in \Omega} \pi_i, \text{ dans le cas discret}$$

Indice de la taille de la famille  $\mathcal{M}(\pi)$ .

# Granularité

## Définition

La *granularité* d'un noyau maxitif  $\pi$  est définie par :

$$\Gamma(\pi) = \int_{\Omega} \pi(\omega) d\omega, \text{ dans le cas continu}$$

$$\Gamma(\pi) = \sum_{i \in \Omega} \pi_i, \text{ dans le cas discret}$$

*Indice de la taille de la famille  $\mathcal{M}(\pi)$ .*

- indice de méconnaissance sur le bon noyau sommatif à utiliser

# Granularité

## Définition

La *granularité* d'un noyau maxitif  $\pi$  est définie par :

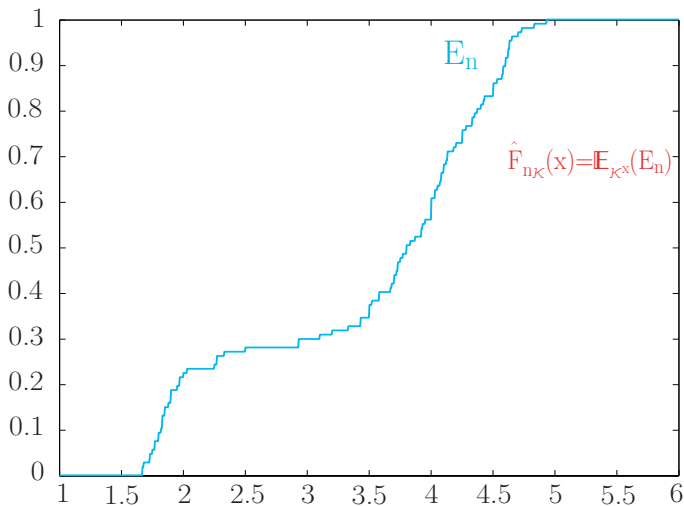
$$\Gamma(\pi) = \int_{\Omega} \pi(\omega) d\omega, \text{ dans le cas continu}$$

$$\Gamma(\pi) = \sum_{i \in \Omega} \pi_i, \text{ dans le cas discret}$$

*Indice de la taille de la famille  $\mathcal{M}(\pi)$ .*

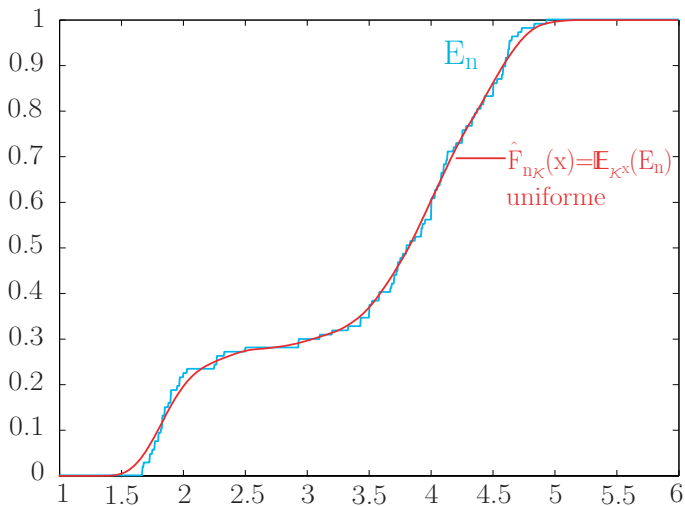
- indice de méconnaissance sur le bon noyau sommatif à utiliser
- indice d'imprécision du résultat (influence des variations des données)

# Estimateur maxitif de PR de fonction de répartition

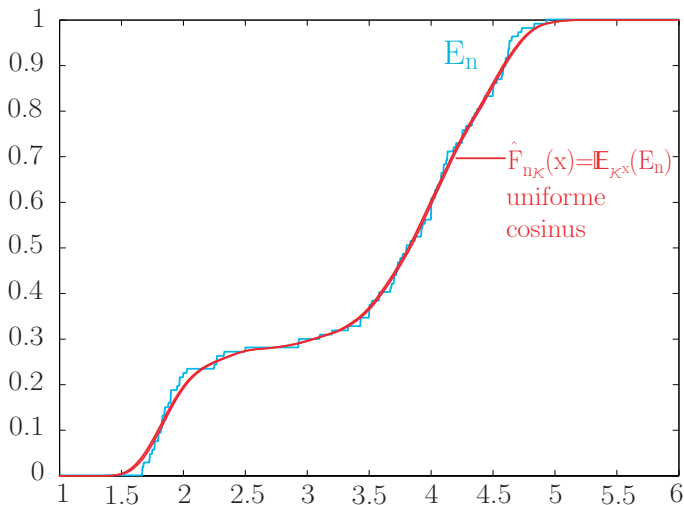




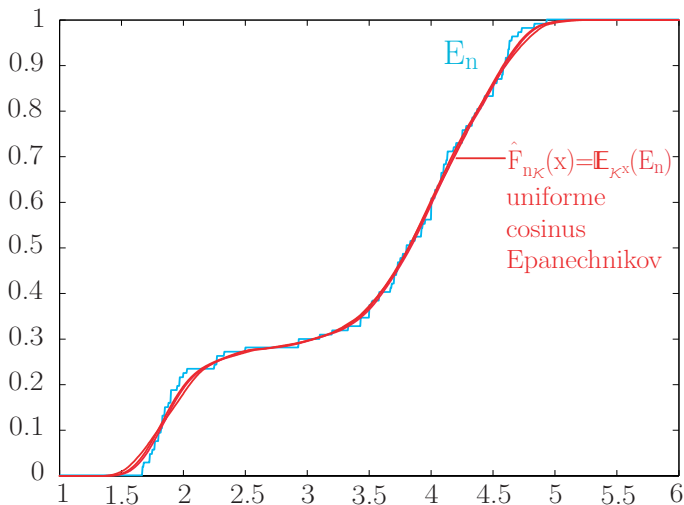
# Estimateur maxitif de PR de fonction de répartition



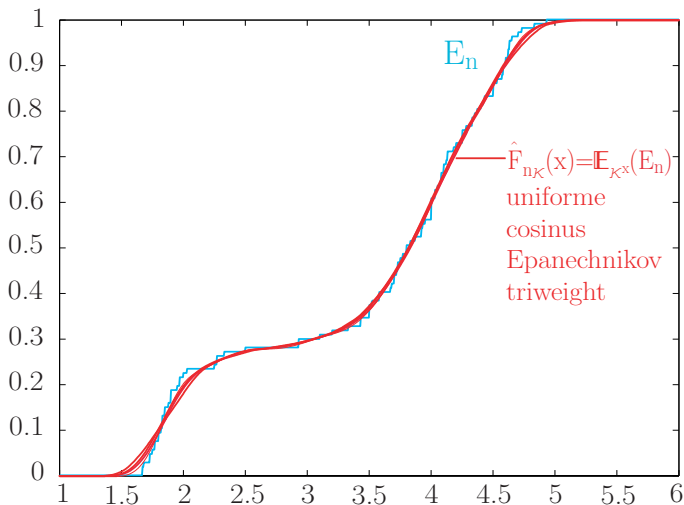
# Estimateur maxitif de PR de fonction de répartition



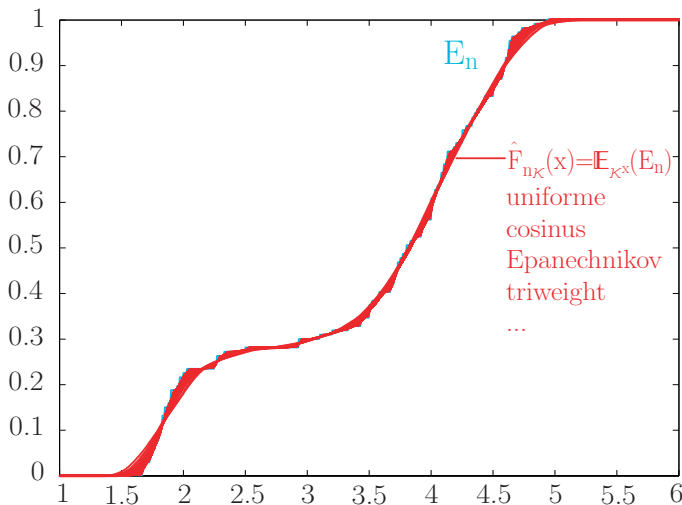
# Estimateur maxitif de PR de fonction de répartition



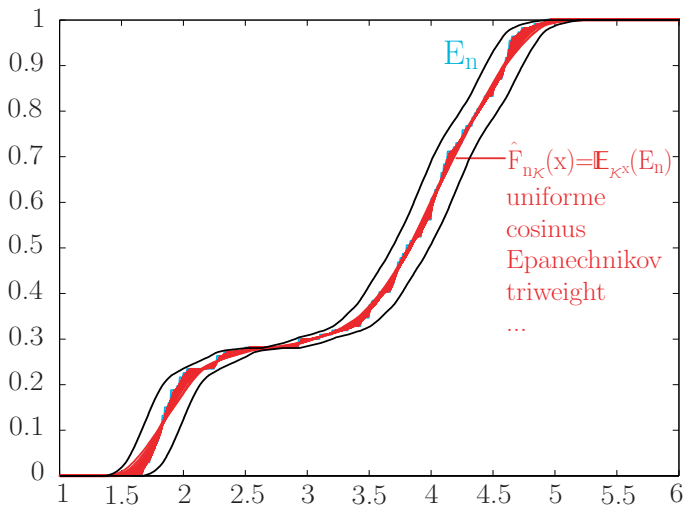
# Estimateur maxitif de PR de fonction de répartition



# Estimateur maxitif de PR de fonction de répartition



# Estimateur maxitif de PR de fonction de répartition



# Estimateur maxitif de PR de fonction de répartition

Rappel : Pour  $n$  observations  $(x_1, \dots, x_n)$ ,

$$\hat{F}_{n\kappa}(x) = \mathbb{E}_{\kappa^x}(E_n)$$

L'estimateur maxitif de Parzen Rosenblatt de  $F$  est donné par :

$$[\underline{F}_{n\pi}(x), \overline{F}_{n\pi}(x)] = [\mathbb{C}_{\pi^x}^c(E_n), \mathbb{C}_{\pi^x}(E_n)]$$

formules à faibles complexités algorithmiques :

$$\mathbb{C}_{\pi^x}^c(E_n) = \frac{1}{n} \sum_{i=1}^n \left( (1 - \pi^x(x_i)) \mathbb{1}_{[x \geq x_i]} \right),$$

$$\mathbb{C}_{\pi^x}(E_n) = \frac{1}{n} \sum_{i=1}^n \left( \pi^x(x_i) \mathbb{1}_{[x \leq x_i]} + \mathbb{1}_{[x > x_i]} \right).$$

# Estimateur maxitif de PR et granularité

$$\varepsilon_{\pi}(x) = \overline{F}_{n\pi}(x) - \underline{F}_{n\pi}(x) = \mathbb{C}_{\pi^x}(E_n) - \mathbb{C}_{\pi^x}^c(E_n),$$

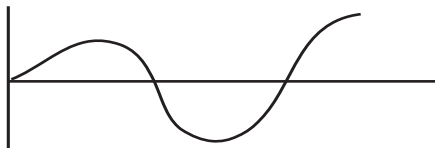
## Théorème

Pour tout noyau maxitif  $\pi$ ,

$$\Gamma(\pi) = \int_{\Omega} \varepsilon_{\pi}(\omega) d\omega$$



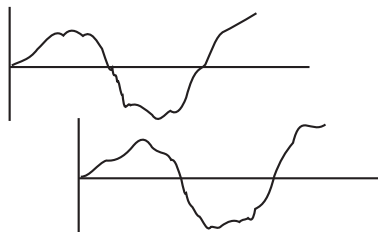
# Estimation du niveau de bruit d'un signal : le bruit



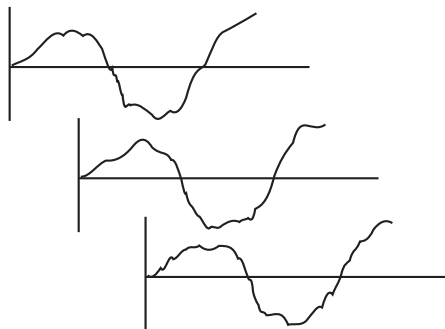
# Estimation du niveau de bruit d'un signal : le bruit



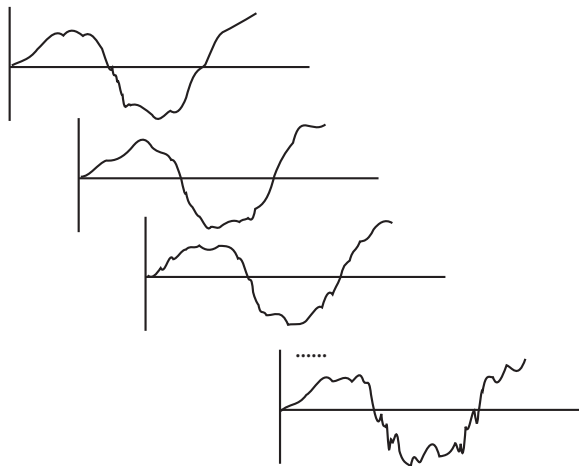
# Estimation du niveau de bruit d'un signal : le bruit



# Estimation du niveau de bruit d'un signal : le bruit



# Estimation du niveau de bruit d'un signal : le bruit



# Estimation du niveau de bruit d'un signal : le bruit

## 1 Bruit : Variations statistiques

# Estimation du niveau de bruit d'un signal : le bruit

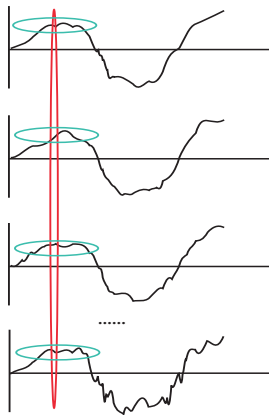
- 1 **Bruit** : Variations statistiques
- 2 **Quantification du bruit** : variance ou écart-type statistique

# Estimation du niveau de bruit d'un signal : le bruit

- 1 **Bruit** : Variations statistiques
- 2 **Quantification du bruit** : variance ou écart-type statistique
- 3 **Comment quantifier le bruit sur une seule occurrence du signal ?**



# Estimation du niveau de bruit d'un signal : notre approche



Les variations temporelles ou spatiales locales, c'est-à-dire définies sur des voisinages pondérés, sont égales aux variations statistiques.

# Estimation du niveau de bruit d'un signal : notre approche



$$[\underline{\bar{x}}(\omega), \bar{\bar{x}}(\omega)] = [C_{\pi\omega}^c(x), C_{\pi\omega}(x)],$$

Imprécision :

$$b^m(\omega) = \bar{\bar{x}}(\omega) - \underline{\bar{x}}(\omega)$$

# Estimation du niveau de bruit d'un signal : notre approche



$$[\underline{\bar{x}}(\omega), \bar{\bar{x}}(\omega)] = [C_{\pi\omega}^c(x), C_{\pi\omega}(x)],$$

Imprécision :

$$b^m(\omega) = \bar{\bar{x}}(\omega) - \underline{\bar{x}}(\omega)$$

Utilisation d'un filtre passe bas maxitif.

## Estimation du niveau de bruit d'un signal : notre approche


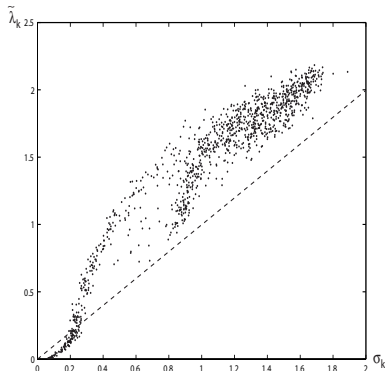


Fig.: Six images parmi 1000 acquisitions du fantôme de cerveau de Hoffman


# Estimation du niveau de bruit d'un signal : notre approche



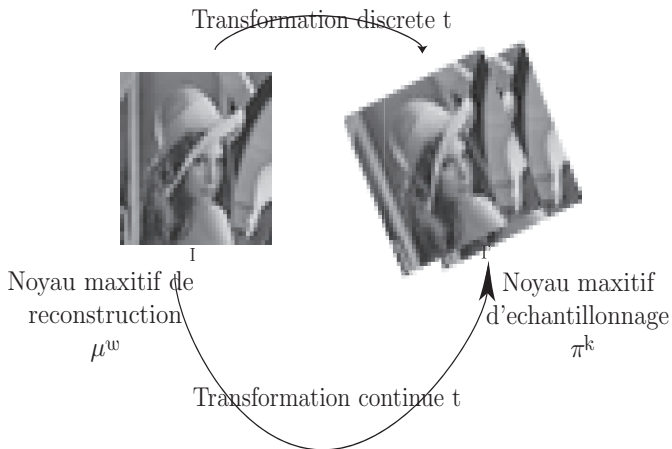
# Transformation rigide maxitive



# Transformation rigide maxitive



# Transformation rigide maxitive





# Applications

- Passages continu/discret en traitement du signal par extraction maxitive d'informations
- Transformation rigide maxitive d'une image
- Filtrage maxitif du signal
  
- Estimateurs maxitifs de fonction de répartition

# Applications

- Passages continu/discret en traitement du signal par extraction maxitive d'informations
- Transformation rigide maxitive d'une image
- Filtrage maxitif du signal
- Filtrage maxitif et morphologie sur une image
- Détection de contour sur une image
- Estimateurs maxitifs de fonction de répartition

# Applications

- Passages continu/discret en traitement du signal par extraction maxitive d'informations
- Transformation rigide maxitive d'une image
- Filtrage maxitif du signal
- Filtrage maxitif et morphologie sur une image
- Détection de contour sur une image
- Estimateurs maxitifs de fonction de répartition
- Estimateurs maxitifs de densité de probabilité

# Applications

- Passages continu/discret en traitement du signal par extraction maxitive d'informations
- Transformation rigide maxitive d'une image
- Filtrage maxitif du signal
- Filtrage maxitif et morphologie sur une image
- Détection de contour sur une image
- Estimateurs maxitifs de fonction de répartition
- Estimateurs maxitifs de densité de probabilité
- Modélisation maxitive de la mesure
- Modélisation maxitive de l'erreur de mesure

# Applications

- Passages continu/discret en traitement du signal par extraction maxitive d'informations
- Transformation rigide maxitive d'une image
- Filtrage maxitif du signal
- Filtrage maxitif et morphologie sur une image
- Détection de contour sur une image
- Estimateurs maxitifs de fonction de répartition
- Estimateurs maxitifs de densité de probabilité
- Modélisation maxitive de la mesure
- Modélisation maxitive de l'erreur de mesure
- Définition de la granularité d'un noyau sommatif

# Conclusion

Fin

Merci à tous de votre attention