

# NL-Means et Agrégation

Joseph Salmon    Dominique Picard    Erwan Le Pennec

LPMA  
Paris 7-Diderot

Modélisation Statistique des Images, 2008

# Sommaire

- 1 Non Local Means
  - Définition
  - Convergence
  - Noyaux et NL-Means
- 2 Agrégation d'Estimateurs
  - Définition
  - Exemples
- 3 Méthodes PAC/EAC-Bayésienne
  - Point de vue Bayésien
  - Théorème général
  - Résultat de type Oracle

# Introduction

- **Cadre: débruitage d'images numériques**
- Méthode étudiée: NL-Means
- Enjeu du travail: Pourquoi ça marche si bien?
- Résultats espérés: Inégalités Oracles  
(Non-asymptotiques)

# Introduction

- Cadre: débruitage d'images numériques
- Méthode étudiée: NL-Means
- Enjeu du travail: Pourquoi ça marche si bien?
- Résultats espérés: Inégalités Oracles  
(Non-asymptotiques)

# Introduction

- Cadre: débruitage d'images numériques
- Méthode étudiée: NL-Means
- Enjeu du travail: Pourquoi ça marche si bien?
- Résultats espérés: Inégalités Oracles  
(Non-asymptotiques)

# Introduction

- Cadre: débruitage d'images numériques
- Méthode étudiée: NL-Means
- Enjeu du travail: Pourquoi ça marche si bien?
- Résultats espérés: Inégalités Oracles  
(Non-asymptotiques)

# Plan de l'exposé

- 1 Non Local Means
  - Définition
  - Convergence
  - Noyaux et NL-Means
- 2 Agrégation d'Estimateurs
  - Définition
  - Exemples
- 3 Méthodes PAC/EAC-Bayésienne
  - Point de vue Bayésien
  - Théorème général
  - Résultat de type Oracle

# Modèle

## "Fixed Design"

$$\text{Pixel: } y_i = f(x_i) + \xi_i, \quad i = 1, \dots, n$$


- $y(i)$  observation,  $f(x_i)$  vraie valeur au pixel  $x_i$  (déterministes)
- $\xi_i$  i.i.d,  $\mathbb{E}(\xi_i) = 0$  et  $\mathbb{E}(\xi_i^2) = \sigma^2$  (ex:  $\xi_i \stackrel{i.i.d}{\sim} \mathcal{N}(0, \sigma^2)$ )
- Risque d'un estimateur  $\hat{f}_n$ :  $R(\hat{f}_n, f) = \mathbb{E}\|\hat{f}_n - f\|_n^2$

$$\text{Notations: } \quad Y = (y_1, \dots, y_n)^\top, \quad X = (x_1, \dots, x_n)^\top$$

$$\text{Distance: } \quad \|Y - f\|_n^2 = \frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2$$



# Intuition



Couleur du "Patch":

- Rose: à débruiter
- Rouge: très ressemblant
- Orange: peu ressemblant
- Bleu: inutiles

# Définition de la méthode selon [BCM05]

## NL-Means

Estimateur: 
$$NL[y]_n(i) = \sum_{j=1}^n \theta(i, j) y(j)$$

Poids BCM: 
$$\theta(i, j) = \frac{\exp\left(-\|y(\mathcal{N}_i) - y(\mathcal{N}_j)\|_{2,a}^2/h^2\right)}{\sum_{j=1}^n \exp\left(-\|y(\mathcal{N}_i) - y(\mathcal{N}_j)\|_{2,a}^2/h^2\right)}$$

$y(\mathcal{N}_i)$  vecteur du "Patch" centré en  $i$ ,  $a$  paramètre de lissage

Remarque:  $0 \leq \theta(i, j) \leq 1$  et  $\sum_{j=1}^n \theta(i, j) = 1$

# Définition de la méthode selon [KB06]

## NL-Means

Estimateur: 
$$NL[y]_n(i) = \sum_{j=1}^n \theta(i, j) y(j)$$

Poids KB: 
$$\theta(i, j) = \frac{L_a(y(\mathcal{N}_i) - y(\mathcal{N}_j)) K_h(d(x_i, x_j))}{\sum_{j \in I} L_a(y(\mathcal{N}_i) - y(\mathcal{N}_j)) K_h(d(x_i, x_j))}$$

$y(\mathcal{N}_i)$  vecteur du "Patch" centré en  $i$

$L, K$  noyaux réels et  $a, h$  fenêtres associées

Remarque:  $0 \leq \theta(i, j) \leq 1$  (si les noyaux sont positifs) et  $\sum_{j=1}^n \theta(i, j) = 1$

# Définition générale

## NL-Means

Estimateur:  $NL[y]_n(i) = \sum_{j \in I} \theta(i, j) y(j)$

Poids :  $\theta(i, j) = \underbrace{P(i, j | Y)}_{\text{fonction des patches}} \times \underbrace{\pi(x_i, x_j)}_{\text{a priori}}$

Problème:

- choix des types de patch
- choix distance entre patch
- choix de la forme des poids

# Plan de l'exposé

- 1 **Non Local Means**
  - Définition
  - **Convergence**
  - Noyaux et NL-Means
- 2 **Agrégation d'Estimateurs**
  - Définition
  - Exemples
- 3 **Méthodes PAC/EAC-Bayésienne**
  - Point de vue Bayésien
  - Théorème général
  - Résultat de type Oracle

# Consistance de la méthode

$Y(\mathcal{N}_i \setminus \{i\})$ : Patch privé du point central

## Théorème [BCM05]


Si  $(Y(i), Y(\mathcal{N}_i \setminus \{i\}))$  est un processus stationnaire mélangeant, alors pour tout  $j$  de l'image:

$$NL[y]_n(j) \xrightarrow{n \rightarrow \infty} \mathbb{E} [Y_i | Y(\mathcal{N}_j \setminus \{j\}) = y(\mathcal{N}_j \setminus \{j\})] \quad \text{p.s}$$

# Plan de l'exposé

- 1 Non Local Means
  - Définition
  - Convergence
  - Noyaux et NL-Means
- 2 Agrégation d'Estimateurs
  - Définition
  - Exemples
- 3 Méthodes PAC/EAC-Bayésienne
  - Point de vue Bayésien
  - Théorème général
  - Résultat de type Oracle

# Lissage et noyaux



Intensité des poids:

- Rouge: poids importants
- Intermediaire: poids faibles
- Bleu: poids nuls



# Méthode à noyaux

Estimateur à Noyau:  $\hat{f}_n(x) = \sum_{i=1}^n \theta_i(x, X) y_i$

Nadaraya-Watson:  $\theta_i(x, X) = \frac{K_h(x_i - x)}{\sum_{j=1}^n K_h(x_j - x)}$

Contrôle de l'erreur: minimisation biais/variance, connu

Limite: peu d'attache aux données et pb dépendance cas

NL-means

Oracle:  $\theta$  fonction de  $\|f(\mathcal{N}_i) - f(\mathcal{N}_j)\| \simeq \|f(x_i) - f(x_j)\|$  (si régularité)

# Pré-estimateurs et Oracle

Hypothèse: on a une deuxième image  $\tilde{Y}$  tel que  $\tilde{Y} \stackrel{\perp}{\sim} Y$

Soient  $\tilde{Y}_\theta(x_j) = \sum_{i=1}^n \theta(i, j) \tilde{Y}_i$  (exemple:  $\theta(y(\mathcal{N}_i), \tilde{y}(\mathcal{N}_j), x_j)$ ) et  $f_\theta(x_j) = \sum_{i=1}^n \theta(i, j) f_i$

But: trouver un  $\hat{\theta}$  tel que

$$\mathbb{E} \|f - \tilde{Y}_{\hat{\theta}}\|_n^2 \leq C \inf_{\theta} \|f - \tilde{Y}_\theta\|_n^2 + C_n$$

$$\tilde{\mathbb{E}} \mathbb{E} \|f - \tilde{Y}_{\hat{\theta}}\|_n^2 \leq C \inf_{\theta} \tilde{\mathbb{E}} \|f - \tilde{f}_\theta\|_n^2 + C_n$$

$$\tilde{\mathbb{E}} \mathbb{E} \|f - \tilde{Y}_{\hat{\theta}}\|_n^2 \leq C \inf_{\theta} \underbrace{\left( \|f - f_\theta\|_n^2 + \frac{\sigma^2}{n} \sum_{i=1}^n \theta_i^2 \right)}_{\text{Biais/Variance estimateur à noyau}} + C_n$$

Biais/Variance estimateur à noyau

# Plan de l'exposé

- 1 Non Local Means
  - Définition
  - Convergence
  - Noyaux et NL-Means
- 2 Agrégation d'Estimateurs
  - Définition
  - Exemples
- 3 Méthodes PAC/EAC-Bayésienne
  - Point de vue Bayésien
  - Théorème général
  - Résultat de type Oracle

# Définition de l'agrégation

But n°1: estimer  $f$

$M$  Pré-estimateurs de  $f$ :  $\tilde{f}_1, \dots, \tilde{f}_M$  (gelés)

Poids:  $\theta = (\theta_1, \dots, \theta_M)$

$$\text{Agrégat: } f_\theta \triangleq \sum_{i=1}^M \theta_i \tilde{f}_i = \sum_{i=1}^M \theta_i(X, Y) \tilde{f}_i$$

$$\text{But n°2: trouver } \theta \in \Theta = \begin{cases} \mathbb{R}^M & (L) \\ \{\theta \in \mathbb{R}^M, \|\theta\|_0 = s\} & (S) \\ \Lambda^M = \{\theta \in \mathbb{R}^M : \theta_j \geq 0, \sum_{j=1}^M \theta_j \leq 1\} & (C) \\ \{e_1, \dots, e_M\} & (MS) \end{cases}$$

où  $e_j = (0, \dots, 1, \dots, 0)$

$\|\theta\|_0 = \#\{j \mid 1 \leq j \leq M \text{ et } \theta_j \neq 0\}$

# Résultat de type Oracle

## Inégalité Oracle

Trouver un estimateur  $f_{\hat{\theta}}$  de  $f$  tel que:

$$\mathbb{E} \left( \|f - f_{\hat{\theta}}\|_n^2 \right) \leq C \inf_{\theta \in \Theta} \|f - f_{\theta}\|_n^2 + \psi_{n,M}^{\Theta}$$

$\psi_{n,M}^{\Theta}$  terme de reste, "prix de l'agrégation" (indépendant de  $f$ )

Contraintes:

- $C$  à trouver proche de 1
- $\psi_{n,M}^{\Theta}$  à prendre petit.

# Plan de l'exposé

- 1 Non Local Means
  - Définition
  - Convergence
  - Noyaux et NL-Means
- 2 Agrégation d'Estimateurs
  - Définition
  - Exemples
- 3 Méthodes PAC/EAC-Bayésienne
  - Point de vue Bayésien
  - Théorème général
  - Résultat de type Oracle

# Pénalité $L_1$ et LASSO

Exemple bien connu:

$$\hat{\theta}^{LASSO} = \arg \min_{\theta \in R^M} \left( \|Y - f_{\theta}\|_n^2 + \underbrace{2r\|\theta\|_1}_{\text{Pénalité sur } \theta} \right)$$

$$\hat{f}_n^{LASSO} = f_{\hat{\theta}_n}$$

où 
$$\|\theta\|_1 = \sum_{j=1}^M |\theta_j|$$

Inégalité oracle disponible [BTW07] (optimale au sens minimax)

## Pénalité entropique et poids exponentiels [Lec07]

$$\hat{\theta}^{EW} = \arg \min_{\theta \in \Lambda^M} \left( \sum_{j=1}^M \theta_j \|Y - \tilde{f}_j\|_n^2 + \underbrace{\frac{\beta}{n} \sum_{j=1}^M \theta_j \log \theta_j + \log M}_{\text{Pénalité sur } \theta} \right)$$

$$\hat{f}^{EW} = f_{\hat{\theta}^{EW}} = \sum_{j=1}^M \hat{\theta}_j^{EW} \tilde{f}_j$$

Solution: 
$$\hat{\theta}_j^{EW} = \frac{\exp\left(-n\|Y - \tilde{f}_j\|_n^2/\beta\right)}{\sum_{k=1}^M \exp\left(-n\|Y - \tilde{f}_k\|_n^2/\beta\right)}$$



# Pénalité entropique et poids exponentiels (suite)

- $\mathbb{E} \|Y - \tilde{f}_j\|_n^2 - \sigma^2 = \|f - \tilde{f}_j\|_n^2$ : poids inchangés par ajout de constante
- Optimisation fonction linéaire espace convexe:

$$\arg \min_{j=1, \dots, M} \|f - \tilde{f}_j\|_n^2 = \arg \min_{\theta \in \Lambda^M} \sum_{j=1}^M \theta_j \|f - \tilde{f}_j\|_n^2$$

ajouter une pénalité sinon sélection modèle

## Inégalité Oracle (Sélection de Modèle) [Lec07]

Soit  $\tilde{f}_1, \dots, \tilde{f}_M$  des fonctions bornées sur  $[0, 1]$ . Alors il existe une constante  $K$ , telle que pour tout  $\varepsilon$  on a:

$$\mathbb{E} \|\hat{f}^{EW} - f\|^2 \leq (1 + \varepsilon) \min_{j=1, \dots, M} \left( \|f - \tilde{f}_j\|^2 \right) + \frac{K \log M}{\varepsilon n}$$

# Plan de l'exposé

- 1 Non Local Means
  - Définition
  - Convergence
  - Noyaux et NL-Means
- 2 Agrégation d'Estimateurs
  - Définition
  - Exemples
- 3 Méthodes PAC/EAC-Bayésienne
  - Point de vue Bayésien
  - Théorème général
  - Résultat de type Oracle

# Mélange à poids exponentiels

Pour une mesure a priori  $\pi \in \mathcal{P}_\Theta$  (mesure sur  $\theta$ ) et  $\beta > 0$ ,  
 $f_\theta = \sum_{i=1}^M \theta_i \tilde{f}_i$  :

$$\hat{f}_n(x) \triangleq \int_{\Theta} \lambda_\theta(\mathbf{Y}) f_\theta(x) \pi(d\theta)$$

et

$$\lambda_\theta(\mathbf{Y}) \triangleq \frac{\exp(-n\|\mathbf{Y} - f_\theta\|_n^2/\beta)}{\int_{\Theta} \exp(-n\|\mathbf{Y} - f_\omega\|_n^2/\beta) \pi(d\omega)}$$

où  $\mathcal{P}_\Theta$  est l'ensemble des mesures de probabilité sur  $\Theta$   
 $\hat{f}_n(x)$ : espérance a posteriori de  $f_\theta$  dans le model fantôme

$$Y_i = f_\theta(x_i) + \xi'_i$$

avec  $\xi'_i$  i.i.d  $\mathcal{N}(0, \frac{\beta}{2})$

# Plan de l'exposé

- 1 Non Local Means
  - Définition
  - Convergence
  - Noyaux et NL-Means
- 2 Agrégation d'Estimateurs
  - Définition
  - Exemples
- 3 Méthodes PAC/EAC-Bayésienne
  - Point de vue Bayésien
  - Théorème général
  - Résultat de type Oracle

# Majoration du risque

## Théorème [DT07]

Supposons que  $\forall j \|\tilde{f}_j\| \leq c_0$ ,  $\xi_1 \sim \mathcal{N}(0, \sigma^2)$ ,  $\forall \pi \in \mathcal{P}_\Theta$ ,  $\beta \geq 4\sigma^2$  alors :

$$\mathbb{E}(\|\hat{f}_n - f\|_n^2) \leq \inf_{p \in \mathcal{P}_\Theta} \left( \int_{\Theta} \|f_\theta - f\|_n^2 p(d\theta) + \frac{\beta \mathcal{K}(p, \pi)}{n} \right)$$

$$\mathcal{K}(p, \pi) = \int_{\Theta} p(\lambda) \log \left( \frac{p(\lambda)}{\pi(\lambda)} \right) d\lambda$$

Remarque:

- Généralisable aux bruits non gaussiens (Méthode de Stein)
- $p = \delta_{j_0}$  : Inégalité Oracle de type Sélection de Modèle

# Plan de l'exposé

- 1 Non Local Means
  - Définition
  - Convergence
  - Noyaux et NL-Means
- 2 Agrégation d'Estimateurs
  - Définition
  - Exemples
- 3 Méthodes PAC/EAC-Bayésienne
  - Point de vue Bayésien
  - Théorème général
  - Résultat de type Oracle

# Combinaisons linéaires et SOI

Ici  $\Theta = \mathbb{R}^M$ ,  $\forall j \|f_j\|_\infty \leq 1$  et  $\pi(d\theta) = q(\theta)d\theta$ :

$$q_0(t) = \frac{3}{2(1+|t|)^4} \quad \forall t \in \mathbb{R}$$

$$q(\theta) = \prod_{j=1}^M \frac{1}{\tau} q_0\left(\frac{\theta_j}{\tau}\right) \quad \forall \theta \in \mathbb{R}^M$$

## Théorème [DT07]

Si  $\xi_1 \sim \mathcal{N}(0, \sigma^2)$ ,  $\tau = \frac{\sigma}{\sqrt{nM}}$  et  $\beta > 4\sigma^2$ , il existe une constante  $C$

$$\mathbb{E} \left( \|\hat{f}_n - f\|_n^2 \right) \leq \inf_{\theta \in \mathbb{R}^M} \left[ \|\theta - f\|_n^2 + \frac{C\|\theta\|_0}{n} \log \left( 1 + \frac{\|\theta\|_1 \sqrt{Mn}}{\sigma\|\theta\|_0} \right) \right]$$

## Perspectives et limites

- Cadre "facile": plusieurs images disponibles (videos, bases de données,...); pas de problème de dépendance
- Cadre recherché: une image seulement.
- $f_j = Y_j$  non gelés! non indépendants! possible pré-découpage (Splitting)
- autre(s) solution(s) ???
- Problème pratique: poids du point central dans le patch ?
- Quid du type de poids? exponentiel = optimal?



## Perspectives et limites

- Cadre "facile": plusieurs images disponibles (videos, bases de données, . . . ); pas de problème de dépendance
- Cadre recherché: une image seulement.
- $f_j = Y_j$  non gelés! non indépendants! possible pré-découpage (Splitting)
- autre(s) solution(s) ???
- Problème pratique: poids du point central dans le patch ?
- Quid du type de poids? exponentiel = optimal?

## Perspectives et limites

- Cadre "facile": plusieurs images disponibles (videos, bases de données, . . . ); pas de problème de dépendance
- Cadre recherché: une image seulement.
- $f_j = Y_j$  non gelés! non indépendants! possible pré-découpage (Splitting)
- autre(s) solution(s) ???
- Problème pratique: poids du point central dans le patch ?
- Quid du type de poids? exponentiel = optimal?

## Perspectives et limites

- Cadre "facile": plusieurs images disponibles (videos, bases de données, . . . ); pas de problème de dépendance
- Cadre recherché: une image seulement.
- $f_j = Y_j$  non gelés! non indépendants! possible pré-découpage (Splitting)
- autre(s) solution(s) ???
- Problème pratique: poids du point central dans le patch ?
- Quid du type de poids? exponentiel = optimal?

## Perspectives et limites

- Cadre "facile": plusieurs images disponibles (videos, bases de données, . . . ); pas de problème de dépendance
- Cadre recherché: une image seulement.
- $f_j = Y_j$  non gelés! non indépendants! possible pré-découpage (Splitting)
- autre(s) solution(s) ???
- Problème pratique: poids du point central dans le patch ?
- Quid du type de poids? exponentiel = optimal?

## Perspectives et limites

- Cadre "facile": plusieurs images disponibles (videos, bases de données, . . . ); pas de problème de dépendance
- Cadre recherché: une image seulement.
- $f_j = Y_j$  non gelés! non indépendants! possible pré-découpage (Splitting)
- autre(s) solution(s) ???
- Problème pratique: poids du point central dans le patch ?
- Quid du type de poids? exponentiel = optimal?

## Références bibliographiques I

- ▶ Antoni Buades, Bartomeu Coll, and Jean-Michel Morel.  
A review of image denoising algorithms, with a new one.  
*Multiscale Model. Simul.*, 4(2):490–530 (electronic), 2005.
- ▶ Florentina Bunea, Alexandre B. Tsybakov, and Marten H. Wegkamp.  
Aggregation for Gaussian regression.  
*Ann. Statist.*, 35(4):1674–1697, 2007.
- ▶ Arnak S. Dalalyan and Alexandre B. Tsybakov.  
Aggregation by exponential weighting, sharp oracle inequalities and sparsity.  
In *COLT*, pages 97–111, 2007.

## Références bibliographiques II

- ▶ Charles Kervrann and Jérôme Boulanger.  
Optimal spatial adaptation for patch-based image denoising.  
*IEEETIP*, 15(10):2866–2878, 2006.
- ▶ Guillaume Lécué.  
Optimal rates of aggregation in classification under low noise assumption.  
*Bernoulli*, 13(4):1000–1022, 2007.