

Bandelettes, estimation géométrique des images et sélection de modèles

E. LE PENNEC,


Ch. DOSSAL, S. MALLAT

LPMA (Université Paris 7) – CMAP (École Polytechnique) – Let It Wave

Estimation géométrique des images

Estimation géométrique des images



Bruitée



Restaurée


Sans géométrie

Avec géométrie




Estimation géométrique des images

Bruitée




Restaurée

Sans géométrie




Avec géométrie



- Estimation par projection et sélection de modèles.

Estimation géométrique des images



Bruitée



Restaurée

Sans géométrie


Avec géométrie



- Estimation par projection et sélection de modèles.
- Représentation géométrique des images (bandelettes).


Estimation géométrique des images

Bruitée




Restaurée

Sans géométrie



Avec géométrie



- Estimation par projection et sélection de modèles.
- Représentation géométrique des images (bandelettes).
- Algorithmique.

Plan

Plan

- Modèle de bruit blanc et seuillage dans une base.

Plan

- Modèle de bruit blanc et seuillage dans une base.
- Lien avec l'approximation non linéaire.

Plan

- Modèle de bruit blanc et seuillage dans une base.
- Lien avec l'approximation non linéaire.
- Ondelettes 1D et 2D.

Plan

- Modèle de bruit blanc et seuillage dans une base.
- Lien avec l'approximation non linéaire.
- Ondelettes 1D et 2D.
- Représentations géométriques des images.

Plan

- Modèle de bruit blanc et seuillage dans une base.
- Lien avec l'approximation non linéaire.
- Ondelettes 1D et 2D.
- Représentations géométriques des images.
- Construction des bandelettes.

Plan

- Modèle de bruit blanc et seuillage dans une base.
- Lien avec l'approximation non linéaire.
- Ondelettes 1D et 2D.
- Représentations géométriques des images.
- Construction des bandelettes.
- Seuillage et sélection de modèles.

Plan

- Modèle de bruit blanc et seuillage dans une base.
- Lien avec l'approximation non linéaire.
- Ondelettes 1D et 2D.
- Représentations géométriques des images.
- Construction des bandelettes.
- Seuillage et sélection de modèles.
- Estimation géométrique des images.

Modèle de bruit blanc

Modèle de bruit blanc

- Modèle classique : $dY = f(t)dt + \epsilon dW(t)$.

Modèle de bruit blanc

- Modèle classique : $dY = f(t)dt + \epsilon dW(t)$.
- $f \in L^2$ fonction (image) à estimer et W processus de Wiener.

Modèle de bruit blanc

- Modèle classique : $dY = f(t)dt + \epsilon dW(t)$.
- $f \in L^2$ fonction (image) à estimer et W processus de Wiener.
- Observation corrompue par un bruit additif gaussien.

Modèle de bruit blanc

- Modèle classique : $dY = f(t)dt + \epsilon dW(t)$.
- $f \in L^2$ fonction (image) à estimer et W processus de Wiener.
- Observation corrompue par un bruit additif gaussien.
- Décomposition de dY dans une base orthonormée donne le modèle de bruit blanc pour les suites :

$$\langle dY, b_n \rangle = \langle f, b_n \rangle + \epsilon \langle dW, b_n \rangle \quad .$$

Modèle de bruit blanc

- Modèle classique : $dY = f(t)dt + \epsilon dW(t)$.
- $f \in L^2$ fonction (image) à estimer et W processus de Wiener.
- Observation corrompue par un bruit additif gaussien.
- Décomposition de dY dans une base orthonormée donne le modèle de bruit blanc pour les suites :

$$\langle dY, b_n \rangle = \langle f, b_n \rangle + \epsilon \langle dW, b_n \rangle \quad .$$

- En pratique, uniquement un nombre fini de composante (projection sur un sous espace de dimension fini).

Modèle de bruit blanc

- Modèle classique : $dY = f(t)dt + \epsilon dW(t)$.
- $f \in L^2$ fonction (image) à estimer et W processus de Wiener.
- Observation corrompue par un bruit additif gaussien.
- Décomposition de dY dans une base orthonormée donne le modèle de bruit blanc pour les suites :

$$\langle dY, b_n \rangle = \langle f, b_n \rangle + \epsilon \langle dW, b_n \rangle \quad .$$

- En pratique, uniquement un nombre fini de composante (projection sur un sous espace de dimension fini).
- Lien avec le modèle d'échantillonnage via $\epsilon = \frac{\sigma}{\sqrt{n}}$.

Seuillage dans une base

Seuillage dans une base

- Méthode simple d'estimation de f à partir de dY .

Seuillage dans une base

- Méthode simple d'estimation de f à partir de dY .
- Décomposition de dY dans une base orthonormée

$$dY = \sum_{b_n} \langle dY, b_n \rangle b_n(t) dt \quad .$$

Seuillage dans une base

- Méthode simple d'estimation de f à partir de dY .
- Décomposition de dY dans une base orthonormée

$$dY = \sum_{b_n} \langle dY, b_n \rangle b_n(t) dt \quad .$$

- Estimée F de f par seuillage avec un seuil T :

$$F = \sum_{\substack{b_n \\ |\langle dY, b_n \rangle| \geq T}} \langle dY, b_n \rangle b_n$$

Seuillage dans une base

- Méthode simple d'estimation de f à partir de dY .
- Décomposition de dY dans une base orthonormée

$$dY = \sum_{b_n} \langle dY, b_n \rangle b_n(t) dt \quad .$$

- Estimée F de f par seuillage avec un seuil T :

$$F = \sum_{\substack{b_n \\ |\langle dY, b_n \rangle| \geq T}} \langle dY, b_n \rangle b_n$$

- Performance ? : si $f \in \Theta$, convergence, vitesse, optimalité minimax ?

Estimateur par projection

Estimateur par projection

• $\{b_n\}_{n \leq N}$ base de dimension N .

Estimateur par projection

- $\{b_n\}_{n \leq N}$ base de dimension N .
- Estimateur par projection : $F_I = \sum_{n \in I} \langle dY, b_n \rangle b_n$.

Estimateur par projection

- $\{b_n\}_{n \leq N}$ base de dimension N .
- Estimateur par projection : $F_I = \sum_{n \in I} \langle dY, b_n \rangle b_n$.
- Comment choisir $I \subset 1, \dots, N$ pour minimiser le risque quadratique

$$E(\|F_I - f\|^2) = \sum_{n > N} |\langle f, b_n \rangle|^2 + \sum_{n \notin I} |\langle f, b_n \rangle|^2 + \sum_{n \in I} \epsilon^2$$

Estimateur par projection

- $\{b_n\}_{n \leq N}$ base de dimension N .
- Estimateur par projection : $F_I = \sum_{n \in I} \langle dY, b_n \rangle b_n$.
- Comment choisir $I \subset 1, \dots, N$ pour minimiser le risque quadratique

$$E(\|F_I - f\|^2) = \sum_{n \notin I} |\langle f, b_n \rangle|^2 + \sum_{n \in I} \epsilon^2$$

- Solution : $I = \{n \in \{1, \dots, N\}, |\langle f, b_n \rangle| \geq \epsilon\}$ donne F_O .

Estimateur par projection

- $\{b_n\}_{n \leq N}$ base de dimension N .
- Estimateur par projection : $F_I = \sum_{n \in I} \langle dY, b_n \rangle b_n$.
- Comment choisir $I \subset 1, \dots, N$ pour minimiser le risque quadratique

$$E(\|F_I - f\|^2) = \sum_{n \notin I} |\langle f, b_n \rangle|^2 + \sum_{n \in I} \epsilon^2$$

- Solution : $I = \{n \in \{1, \dots, N\}, |\langle f, b_n \rangle| \geq \epsilon\}$ donne F_O .
- Problème : nécessité d'un oracle (F_O dépend de f).

Estimateur par projection

- $\{b_n\}_{n \leq N}$ base de dimension N .
- Estimateur par projection : $F_I = \sum_{n \in I} \langle dY, b_n \rangle b_n$.
- Comment choisir $I \subset 1, \dots, N$ pour minimiser le risque quadratique

$$E(\|F_I - f\|^2) = \sum_{n > N} |\langle f, b_n \rangle|^2 + \sum_{n \notin I} |\langle f, b_n \rangle|^2 + \sum_{n \in I} \epsilon^2$$

- Solution : $I = \{n \in \{1, \dots, N\}, |\langle f, b_n \rangle| \geq \epsilon\}$ donne F_O .
- Problème : nécessité d'un oracle (F_O dépend de f).
- Lien avec le cadre déterministe de l'approximation non linéaire :

$$f_I = \sum_{n \in I} \langle f, b_n \rangle b_n$$

et minimisation à $|I| = M$ fixé de $\|f - f_I\|^2$ donne f_M .

Oracle et approximation non linéaire

Oracle et approximation non linéaire

● Risque :

$$E(\|F_I - f\|^2) = \sum_{n>N} |\langle f, b_n \rangle|^2 + \sum_{n \notin I} |\langle f, b_n \rangle|^2 + \sum_{n \in I} \epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_{\{1, \dots, N\}}\|^2 + \|f_{\{1, \dots, N\}} - f_I\|^2 + |I| \epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_I\|^2 + \epsilon^2 |I| \quad .$$

Oracle et approximation non linéaire

● Risque :

$$E(\|F_I - f\|^2) = \sum_{n > N} |\langle f, b_n \rangle|^2 + \sum_{n \notin I} |\langle f, b_n \rangle|^2 + \sum_{n \in I} \epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_{\{1, \dots, N\}}\|^2 + \|f_{\{1, \dots, N\}} - f_I\|^2 + |I| \epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_I\|^2 + \epsilon^2 |I| \quad .$$

● Formulation lagrangienne du problème d'approximation non linéaire ($f_I = f_M$ et $|I| = M$).

Oracle et approximation non linéaire

- Risque :

$$E(\|F_I - f\|^2) = \sum_{n>N} |\langle f, b_n \rangle|^2 + \sum_{n \notin I} |\langle f, b_n \rangle|^2 + \sum_{n \in I} \epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_{\{1, \dots, N\}}\|^2 + \|f_{\{1, \dots, N\}} - f_I\|^2 + |I| \epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_I\|^2 + \epsilon^2 |I| \quad .$$

- Formulation lagrangienne du problème d'approximation non linéaire ($f_I = f_M$ et $|I| = M$).
- Décroissance du risque en fonction de ϵ liée à la classe Θ (régularité) et à la base utilisée.

Oracle et approximation non linéaire

- Risque :

$$E(\|F_I - f\|^2) = \sum_{n>N} |\langle f, b_n \rangle|^2 + \sum_{n \notin I} |\langle f, b_n \rangle|^2 + \sum_{n \in I} \epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_{\{1, \dots, N\}}\|^2 + \|f_{\{1, \dots, N\}} - f_I\|^2 + |I| \epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_I\|^2 + \epsilon^2 |I| \quad .$$

- Formulation lagrangienne du problème d'approximation non linéaire ($f_I = f_M$ et $|I| = M$).
- Décroissance du risque en fonction de ϵ liée à la classe Θ (régularité) et à la base utilisée.
- Décroissance de l'erreur d'approximation $\|f - f_M\|^2$ en $M^{-\beta}$: convergence du risque quadratique oracle en $\epsilon^{2\beta/(\beta+1)}$.

Oracle et approximation non linéaire

- Risque :

$$E(\|F_I - f\|^2) = \sum_{n>N} |\langle f, b_n \rangle|^2 + \sum_{n \notin I} |\langle f, b_n \rangle|^2 + \sum_{n \in I} \epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_{\{1, \dots, N\}}\|^2 + \|f_{\{1, \dots, N\}} - f_I\|^2 + |I|\epsilon^2$$

$$E(\|F_I - f\|^2) = \|f - f_I\|^2 + \epsilon^2 |I| \quad .$$

- Formulation lagrangienne du problème d'approximation non linéaire ($f_I = f_M$ et $|I| = M$).
- Décroissance du risque en fonction de ϵ liée à la classe Θ (régularité) et à la base utilisée.
- Décroissance de l'erreur d'approximation $\|f - f_M\|^2$ en $M^{-\beta}$: convergence du risque quadratique oracle en $\epsilon^{2\beta/(\beta+1)}$.
- Optimisation : choix de la bonne base.

Oracle et seuillage

Oracle et seuillage

- Lien avec le seuillage : Donoho, Johnstone, Kerkycharian, Picard...

Oracle et seuillage

- Lien avec le seuillage : Donoho, Johnstone, Kerkycharian, Picard...
- Estimée F de f par seuillage avec un seuil T :

$$F = \sum_{\substack{b_n, n \leq N \\ |\langle dY, b_n \rangle| \geq T}} \langle dY, b_n \rangle b_n$$

Oracle et seuillage

- Lien avec le seuillage : Donoho, Johnstone, Kerkycharian, Picard...
- Estimée F de f par seuillage avec un seuil T :

$$F = \sum_{\substack{b_n, n \leq N \\ |\langle dY, b_n \rangle| \geq T}} \langle dY, b_n \rangle b_n$$

- **Théorème** : Pour $T = \lambda \sqrt{\log N} \epsilon$, avec λ suffisamment grand,

$$E(\|F - f\|^2) \leq C \log N (E(\|F_O - f\|^2) + \epsilon/N) \quad .$$

Oracle et seuillage

- Lien avec le seuillage : Donoho, Johnstone, Kerkycharian, Picard...
- Estimée F de f par seuillage avec un seuil T :

$$F = \sum_{\substack{b_n, n \leq N \\ |\langle dY, b_n \rangle| \geq T}} \langle dY, b_n \rangle b_n$$

- **Théorème** : Pour $T = \lambda \sqrt{\log N} \epsilon$, avec λ suffisamment grand,

$$E(\|F - f\|^2) \leq C \log N (E(\|F_O - f\|^2) + \epsilon/N) \quad .$$

- Estimateur par seuillage *aussi* efficace que l'estimateur oracle.

Oracle et seuillage

- Lien avec le seuillage : Donoho, Johnstone, Kerkycharian, Picard...
- Estimée F de f par seuillage avec un seuil T :

$$F = \sum_{\substack{b_n, n \leq N \\ |\langle dY, b_n \rangle| \geq T}} \langle dY, b_n \rangle b_n$$

- **Théorème** : Pour $T = \lambda \sqrt{\log N} \epsilon$, avec λ suffisamment grand,

$$E(\|F - f\|^2) \leq C \log N (E(\|F_O - f\|^2) + \epsilon/N) \quad .$$

- Estimateur par seuillage *aussi* efficace que l'estimateur oracle.
- Étude des performances de l'estimateur oracle.

Oracle et seuillage

- Lien avec le seuillage : Donoho, Johnstone, Kerkycharian, Picard...
- Estimée F de f par seuillage avec un seuil T :

$$F = \sum_{\substack{b_n, n \leq N \\ |\langle dY, b_n \rangle| \geq T}} \langle dY, b_n \rangle b_n$$

- **Théorème** : Pour $T = \lambda \sqrt{\log N} \epsilon$, avec λ suffisamment grand,


$$E(\|F - f\|^2) \leq C \log N (E(\|F_O - f\|^2) + \epsilon/N) \quad .$$

- Estimateur par seuillage *aussi* efficace que l'estimateur oracle.
- Étude des performances de l'estimateur oracle.
- Adaptivité automatique.

Régularité 1D


Régularité

Régularité 1D




• $f \in L^2([0, 1])$.

Régularité 1D




- $f \in L^2([0, 1])$.
- Classe des fonctions régulières (C^α , classe de Hölder d'ordre α).

Régularité 1D




- $f \in L^2([0, 1])$.
- Classe des fonctions régulières (C^α , classe de Hölder d'ordre α).
- Risque minimax $\propto \epsilon^{2\alpha/(\alpha+1/2)}$.

Régularité 1D




- $f \in L^2([0, 1])$.
- Classe des fonctions régulières (C^α , classe de Hölder d'ordre α).
- Risque minimax $\propto \epsilon^{2\alpha/(\alpha+1/2)}$.
- Classe des fonctions régulières par morceaux (C^α par morceaux).

Régularité 1D



- $f \in L^2([0, 1])$.
- Classe des fonctions régulières (C^α , classe de Hölder d'ordre α).
- Risque minimax $\propto \epsilon^{2\alpha/(\alpha+1/2)}$.
- Classe des fonctions régulières par morceaux (C^α par morceaux).
- Risque minimax : $\propto \epsilon^{2\alpha/(\alpha+1/2)}$.

Régularité 1D



- $f \in L^2([0, 1])$.
- Classe des fonctions régulières (C^α , classe de Hölder d'ordre α).
- Risque minimax $\propto \epsilon^{2\alpha/(\alpha+1/2)}$.
- Classe des fonctions régulières par morceaux (C^α par morceaux).
- Risque minimax : $\propto \epsilon^{2\alpha/(\alpha+1/2)}$.
- Peut-on atteindre cette borne ?

Base d'ondelettes 1D de $L^2[0, 1]$


Base d'ondelettes 1D de $L^2[0, 1]$

- Construite à partir d'une fonction d'échelle $\phi(x)$ et d'une ondelette mère $\psi(x)$



qui sont dilatées par 2^j et translatées de $2^j n$

$$\phi_{j,n}(x) = \frac{1}{\sqrt{2^j}} \phi\left(\frac{x - 2^j n}{2^j}\right) \quad , \quad \psi_{j,n}(x) = \frac{1}{\sqrt{2^j}} \psi\left(\frac{x - 2^j n}{2^j}\right) \quad .$$



Base d'ondelettes 1D de $L^2[0, 1]$


- Construite à partir d'une fonction d'échelle $\phi(x)$ et d'une ondelette mère $\psi(x)$



qui sont dilatées par 2^j et translatées de $2^j n$

$$\phi_{j,n}(x) = \frac{1}{\sqrt{2^j}} \phi\left(\frac{x - 2^j n}{2^j}\right) \quad , \quad \psi_{j,n}(x) = \frac{1}{\sqrt{2^j}} \psi\left(\frac{x - 2^j n}{2^j}\right) \quad .$$


- $\mathbf{B} = \left\{ \psi_{j,n} \right\}_{j \in \mathbb{N}, 2^j n \in [0,1)}$ est une base orthonormale de $L^2[0, 1]$.




Approximation non linéaire en ondelettes

Approximation non linéaire en ondelettes


f




$\langle f, \psi_{j,n} \rangle$



f_M



Approximation non linéaire en ondelettes



● Si f est C^α par morceaux et ψ a $p > \alpha$ moments nuls alors

$$\|f - f_M\|^2 \leq C M^{-2\alpha}.$$

Quasi optimalité

Quasi optimalité

Quasi optimalité

- Si f est $\mathbf{C}^\alpha$ par morceaux, $\|f - f_M\|^2 \leq C M^{-2\alpha}$.

Quasi optimalité

- Si f est $\mathbf{C}^\alpha$ par morceaux, $\|f - f_M\|^2 \leq C M^{-2\alpha}$.
- Risque oracle correspondant : $\propto \epsilon^{2\alpha/(\alpha+1/2)}$ (risque minimax).

Quasi optimalité

- Si f est $\mathbf{C}^\alpha$ par morceaux, $\|f - f_M\|^2 \leq C M^{-2\alpha}$.
- Risque oracle correspondant : $\propto \epsilon^{2\alpha/(\alpha+1/2)}$ (risque minimax).
- Risque de l'estimateur par seuillage : $\propto (\log \epsilon) \epsilon^{2\alpha/(\alpha+1/2)}$ si $N \leq \epsilon^{-1}$.

Quasi optimalité

- Si f est $\mathbf{C}^\alpha$ par morceaux, $\|f - f_M\|^2 \leq C M^{-2\alpha}$.
- Risque oracle correspondant : $\propto \epsilon^{2\alpha/(\alpha+1/2)}$ (risque minimax).
- Risque de l'estimateur par seuillage : $\propto (\log \epsilon) \epsilon^{2\alpha/(\alpha+1/2)}$ si $N \leq \epsilon^{-1}$.
- Condition non restrictive (théorie de l'approximation linéaire) :

$$\|f - f_{1\dots N}\|^2 \leq \|f - f_M\|^2 \quad .$$

Quasi optimalité

- Si f est $\mathbf{C}^\alpha$ par morceaux, $\|f - f_M\|^2 \leq C M^{-2\alpha}$.
- Risque oracle correspondant : $\propto \epsilon^{2\alpha/(\alpha+1/2)}$ (risque minimax).
- Risque de l'estimateur par seuillage : $\propto (\log \epsilon) \epsilon^{2\alpha/(\alpha+1/2)}$ si $N \leq \epsilon^{-1}$.
- Condition non restrictive (théorie de l'approximation linéaire) :

$$\|f - f_{1\dots N}\|^2 \leq \|f - f_M\|^2 \quad .$$

- Quasi optimalité de l'estimateur par seuillage en ondelettes pour les fonctions 1D.

Base d'ondelettes 2D séparables

Base d'ondelettes 2D séparables

● La famille


$$\left\{ \begin{array}{l} \phi_{j,n_1}(x_1) \psi_{j,n_2}(x_2) \quad , \quad \psi_{j,n_1}(x_1) \phi_{j,n_2}(x_2) \\ \quad \quad \quad , \quad \psi_{j,n_1}(x_1) \psi_{j,n_2}(x_2) \end{array} \right\}_{(j,n_1,n_2) \in \mathbb{Z}^3}$$

est une base orthonormée de $L^2[0, 1]^2$.


Base d'ondelettes 2D séparables

● La famille


$$\left\{ \begin{array}{l} \phi_{j,n_1}(x_1) \psi_{j,n_2}(x_2) \quad , \quad \psi_{j,n_1}(x_1) \phi_{j,n_2}(x_2) \\ \quad \quad \quad , \quad \psi_{j,n_1}(x_1) \psi_{j,n_2}(x_2) \end{array} \right\}_{(j,n_1,n_2) \in \mathbb{Z}^3}$$
 est une base orthonormée de $L^2[0, 1]^2$.




$\phi_{j,n_1}(x_1) \psi_{j,n_2}(x_2)$



$\psi_{j,n_1}(x_1) \phi_{j,n_2}(x_2)$



$\psi_{j,n_1}(x_1) \psi_{j,n_2}(x_2)$



Support
des ondelettes
isotropes

Seuillage en ondelettes 2D

Seuillage en ondelettes 2D

• $f \in L^2([0, 1]^2)$.

Seuillage en ondelettes 2D

- $f \in L^2([0, 1]^2)$.
- Modèle de bruit blanc : $dY = f(x)dx + \epsilon dW(x)$

Seuillage en ondelettes 2D

- $f \in L^2([0, 1]^2)$.
- Modèle de bruit blanc : $dY = f(x)dx + \epsilon dW(x)$
- Estimateur : $F = \sum_{\substack{j \geq j_0 \\ |\langle dY, \psi_{j,k} \rangle| \geq T}} \langle dY, \psi_{j,k} \rangle \psi_{j,k}$ avec $N = 2^{-j_0}$ et
 $T = \lambda \sqrt{\log N} \epsilon$.

Seuillage en ondelettes 2D

- $f \in L^2([0, 1]^2)$.
- Modèle de bruit blanc : $dY = f(x)dx + \epsilon dW(x)$
- Estimateur : $F = \sum_{\substack{j \geq j_0 \\ |\langle dY, \psi_{j,k} \rangle| \geq T}} \langle dY, \psi_{j,k} \rangle \psi_{j,k}$ avec $N = 2^{-j_0}$ et
 $T = \lambda \sqrt{\log N} \epsilon$.
- Quasi optimal pour les fonctions régulières C^α et autres espaces classiques.

Seuillage en ondelettes 2D

- $f \in L^2([0, 1]^2)$.
- Modèle de bruit blanc : $dY = f(x)dx + \epsilon dW(x)$
- Estimateur : $F = \sum_{\substack{j \geq j_0 \\ |\langle dY, \psi_{j,k} \rangle| \geq T}} \langle dY, \psi_{j,k} \rangle \psi_{j,k}$ avec $N = 2^{-j_0}$ et
 $T = \lambda \sqrt{\log N} \epsilon$.
- Quasi optimal pour les fonctions régulières $\mathbf{C}^\alpha$ et autres espaces classiques.
- Pour les images, modèle classique : $\mathbf{C}^\alpha - \mathbf{C}^\alpha$.

Seuillage en ondelettes 2D

- $f \in L^2([0, 1]^2)$.
- Modèle de bruit blanc : $dY = f(x)dx + \epsilon dW(x)$
- Estimateur : $F = \sum_{\substack{j \geq j_0 \\ |\langle dY, \psi_{j,k} \rangle| \geq T}} \langle dY, \psi_{j,k} \rangle \psi_{j,k}$ avec $N = 2^{-j_0}$ et
 $T = \lambda \sqrt{\log N} \epsilon$.
- Quasi optimal pour les fonctions régulières $\mathbf{C}^\alpha$ et autres espaces classiques.
- Pour les images, modèle classique : $\mathbf{C}^\alpha - \mathbf{C}^\alpha$.
- Ici, seul modèle possible : $f \in BV$ et $\|f - f_M\|^2 \leq C M^{-1}$.

Seuillage en ondelettes 2D


- $f \in L^2([0, 1]^2)$.
- Modèle de bruit blanc : $dY = f(x)dx + \epsilon dW(x)$
- Estimateur : $F = \sum_{\substack{j \geq j_0 \\ |\langle dY, \psi_{j,k} \rangle| \geq T}} \langle dY, \psi_{j,k} \rangle \psi_{j,k}$ avec $N = 2^{-j_0}$ et
 $T = \lambda \sqrt{\log N} \epsilon$.
- Quasi optimal pour les fonctions régulières $\mathbf{C}^\alpha$ et autres espaces classiques.
- Pour les images, modèle classique : $\mathbf{C}^\alpha - \mathbf{C}^\alpha$.
- Ici, seul modèle possible : $f \in BV$ et $\|f - f_M\|^2 \leq C M^{-1}$.
- Risque quadratique de l'ordre de ϵ^2 qui est sous optimal si $\alpha \geq 1$.

Seuillage en ondelettes 2D

- $f \in L^2([0, 1]^2)$.
- Modèle de bruit blanc : $dY = f(x)dx + \epsilon dW(x)$
- Estimateur : $F = \sum_{\substack{j \geq j_0 \\ |\langle dY, \psi_{j,k} \rangle| \geq T}} \langle dY, \psi_{j,k} \rangle \psi_{j,k}$ avec $N = 2^{-j_0}$ et $T = \lambda \sqrt{\log N} \epsilon$.
- Quasi optimal pour les fonctions régulières $\mathbf{C}^\alpha$ et autres espaces classiques.
- Pour les images, modèle classique : $\mathbf{C}^\alpha - \mathbf{C}^\alpha$.
- Ici, seul modèle possible : $f \in BV$ et $\|f - f_M\|^2 \leq C M^{-1}$.
- Risque quadratique de l'ordre de ϵ^2 qui est sous optimal si $\alpha \geq 1$.
- Problème d'approximation non linéaire.


Modèle de régularité géométrique

Modèle de régularité géométrique




- Fonctions régulières par morceaux avec des discontinuités le long de courbes régulières.

Modèle de régularité géométrique




- Fonctions régulières par morceaux avec des discontinuités le long de courbes régulières.
- Cf modèle horizon ou fonctions étoilées (*Tsybakov, Donoho*).

Modèle de régularité géométrique



- Fonctions régulières par morceaux avec des discontinuités le long de courbes régulières.
- Cf modèle horizon ou fonctions étoilées (*Tsybakov, Donoho*).
- Fonctions de régularité géométrique $\mathbf{C}^\alpha$:
 - $f = \tilde{f}$ ou $f = \tilde{f} \star h$,
 - $\tilde{f} : \mathbf{C}^\alpha(\Lambda)$ avec $\Lambda = [0, 1]^2 - \{\mathcal{C}_\gamma\}_{1 \leq \gamma \leq G}$,
 - $\mathcal{C}_\gamma : \mathbf{C}^\alpha$ + conditions géométriques de non tangence,
 - $h : \mathbf{C}^\alpha$ à support $\subset [-s, s]^2$ et $\|h\|_{\mathbf{C}^\alpha} \leq s^{-(2+\alpha)}$.

Modèle de régularité géométrique




- Fonctions régulières par morceaux avec des discontinuités le long de courbes régulières.
- Cf modèle horizon ou fonctions étoilées (*Tsybakov, Donoho*).
- Fonctions de régularité géométrique $\mathbf{C}^\alpha$:
 - $f = \tilde{f}$ ou $f = \tilde{f} \star h$,
 - $\tilde{f} : \mathbf{C}^\alpha(\Lambda)$ avec $\Lambda = [0, 1]^2 - \{\mathcal{C}_\gamma\}_{1 \leq \gamma \leq G}$,
 - $\mathcal{C}_\gamma : \mathbf{C}^\alpha$ + conditions géométriques de non tangence,
 - $h : \mathbf{C}^\alpha$ à support $\subset [-s, s]^2$ et $\|h\|_{\mathbf{C}^\alpha} \leq s^{-(2+\alpha)}$.
- Risque minimax : $\propto \epsilon^{2\alpha/(\alpha+1)}$.

Approximation en ondelettes des contours



Approximation en ondelettes des contours

- Approximation de f qui est C^α en dehors de contours C^α :



Approximation en ondelettes des contours



- Approximation de f qui est C^α en dehors de contours C^α :



- Avec M ondelettes : $\|f - f_M\|^2 \leq C M^{-1}$.

Approximation en ondelettes des contours

- Approximation de f qui est C^α en dehors de contours C^α :




- Avec M ondelettes : $\|f - f_M\|^2 \leq C M^{-1}$.
- Pour obtenir le risque minimax, besoin de $\|f - f_M\|^2 \leq C M^{-\alpha}$.

Éléments géométriques pour les contours



Éléments géométriques pour les contours

- Approximation de f qui est C^α en dehors de contours C^α :




Éléments géométriques pour les contours

- Approximation de f qui est C^α en dehors de contours C^α :





- Approximation linéaire par morceau sur M triangles adaptés :
si $\alpha \geq 2$ alors $\|f - f_M\|^2 \leq C M^{-2}$,




Éléments géométriques pour les contours


- Approximation de f qui est C^α en dehors de contours C^α :



- Approximation linéaire par morceau sur M triangles adaptés :
si $\alpha \geq 2$ alors $\|f - f_M\|^2 \leq C M^{-2}$,




- Approximation d'ordre élevé avec M "éléments" adaptés :
 $\|f - f_M\|^2 \leq C M^{-\alpha}$.




Éléments géométriques pour les contours


- Approximation de f qui est C^α en dehors de contours C^α :



- Approximation linéaire par morceau sur M triangles adaptés :
si $\alpha \geq 2$ alors $\|f - f_M\|^2 \leq C M^{-2}$,



- Approximation d'ordre élevé avec M "éléments" adaptés :
 $\|f - f_M\|^2 \leq C M^{-\alpha}$.




- Difficile de trouver une solution optimale mais bonnes solutions "gloutonnes" (*Dekel, Demaret, Dyn, Iske*).

Approximation en curvelets


Approximation en curvelets

- Les curvelets définissent un “tight frame” de $L^2[0, 1]^2$ avec des éléments allongés et orientés (*Candes, Donoho*) : $\{c_j(R_\theta x - \eta)\}_{j,\theta,\eta}$



Approximation en curvelets

- Les curvelets définissent un “tight frame” de $L^2[0, 1]^2$ avec des éléments allongés et orientés (*Candes, Donoho*) : $\{c_j(R_\theta x - \eta)\}_{j,\theta,\eta}$




- Si f est de régularité géométrique $\mathbf{C}^\alpha$ alors avec M curvelets :

$$\|f - f_M\|^2 \leq C (\log M)^3 M^{-2} \quad \text{si } \alpha \geq 2.$$

Approximation en curvelets

- Les curvelets définissent un “tight frame” de $L^2[0, 1]^2$ avec des éléments allongés et orientés (*Candes, Donoho*) : $\{c_j(R_\theta x - \eta)\}_{j,\theta,\eta}$




- Si f est de régularité géométrique $\mathbf{C}^\alpha$ alors avec M curvelets :

$$\|f - f_M\|^2 \leq C (\log M)^3 M^{-2} \quad \text{si } \alpha \geq 2.$$

- Quasi optimal pour $\alpha = 2$.

Approximation en curvelets

- Les curvelets définissent un “tight frame” de $L^2[0, 1]^2$ avec des éléments allongés et orientés (*Candes, Donoho*) : $\{c_j(R_\theta x - \eta)\}_{j,\theta,\eta}$




- Si f est de régularité géométrique $\mathbf{C}^\alpha$ alors avec M curvelets :

$$\|f - f_M\|^2 \leq C (\log M)^3 M^{-2} \quad \text{si } \alpha \geq 2.$$

- Quasi optimal pour $\alpha = 2$.
- Difficile d'obtenir des bases orthogonales ou des bases de Riesz : (*Vetterli & Minh Do*).


Bandelettes

Bandelettes




- Famille de base de bandelettes : bases adaptées à la géométrie des images.

Bandelettes




- Famille de base de bandelettes : bases adaptées à la géométrie des images.
- Introduites pour un problème de compression (frame) et modifiées pour obtenir des bases orthonormées.

Bandelettes



- Famille de base de bandelettes : bases adaptées à la géométrie des images.
- Introduites pour un problème de compression (frame) et modifiées pour obtenir des bases orthonormées.
- 3 ingrédients :
 - segmentation hiérarchique (structure d'arbre),
 - déformation géométrique locale,
 - ondelettes hyperboliques.

Bandelettes



- Famille de base de bandelettes : bases adaptées à la géométrie des images.
- Introduites pour un problème de compression (frame) et modifiées pour obtenir des bases orthonormées.
- 3 ingrédients :
 - segmentation hiérarchique (structure d'arbre),
 - déformation géométrique locale,
 - ondelettes hyperboliques.
- Représentation optimale et algorithme de recherche de la meilleure représentation.

Flot géométrique segmenté

Flot géométrique

Flot géométrique segmenté



- Spécification de la géométrie.

Flot géométrique segmenté

- Spécification de la géométrie.
- Flot géométrique : champ de vecteurs $\vec{\tau}(x_1, x_2)$ donnant des directions dans lesquelles l'image est localement régulière.



Flot géométrique segmenté

- Spécification de la géométrie.
- Flot géométrique : champ de vecteurs $\vec{\tau}(x_1, x_2)$ donnant des directions dans lesquelles l'image est localement régulière.
- Dans une région, le flot est constant horizontalement ou verticalement et induit par un polynôme.





Flot géométrique segmenté

- Spécification de la géométrie.
- Flot géométrique : champ de vecteurs $\vec{\tau}(x_1, x_2)$ donnant des directions dans lesquelles l'image est localement régulière.
- Dans une région, le flot est constant horizontalement ou verticalement et induit par un polynôme.



- Nécessité d'une segmentation de l'image.




Base d'ondelettes déformées

Base d'ondelettes déformées

- Supposons le flot constant verticalement :

$$\vec{\tau}(x_1, x_2) = (1, c'(x_1)) .$$




$$c(x_1) = \int_{x_{1,\min}}^{x_1} c'(u) \, du$$


Base d'ondelettes déformées

- Supposons le flot constant verticalement :

$$\vec{\tau}(x_1, x_2) = (1, c'(x_1)) .$$



$$c(x_1) = \int_{x_{1,\min}}^{x_1} c'(u) \, du$$




- À x_2 fixé, $f(x_1, x_2 + c(x_1))$ est une fonction régulière de x_1 .


Base d'ondelettes déformées

- Supposons le flot constant verticalement :

$$\vec{\tau}(x_1, x_2) = (1, c'(x_1)) .$$



$$c(x_1) = \int_{x_{1,\min}}^{x_1} c'(u) du$$




- À x_2 fixé, $f(x_1, x_2 + c(x_1))$ est une fonction régulière de x_1 .
- $\langle f(x_1, x_2 + c(x_1)), \Psi(x_1, x_2) \rangle = \langle f(x_1, x_2), \Psi(x_1, x_2 - c(x_1)) \rangle$.


Base d'ondelettes déformées

- Supposons le flot constant verticalement :

$$\vec{\tau}(x_1, x_2) = (1, c'(x_1)) .$$



$$c(x_1) = \int_{x_{1,\min}}^{x_1} c'(u) du$$



- À x_2 fixé, $f(x_1, x_2 + c(x_1))$ est une fonction régulière de x_1 .
- $\langle f(x_1, x_2 + c(x_1)), \Psi(x_1, x_2) \rangle = \langle f(x_1, x_2), \Psi(x_1, x_2 - c(x_1)) \rangle$.
- On décompose donc f dans une *base d'ondelettes déformées* de $L^2(\Omega)$:

$$\left\{ \begin{array}{l} \phi_{j,m_1}(x_1) \psi_{j,m_2}(x_2 - c(x_1)) \quad , \quad \psi_{j,m_1}(x_1) \phi_{j,m_2}(x_2 - c(x_1)) \\ \quad \quad \quad , \quad \psi_{j,m_1}(x_1) \psi_{j,m_2}(x_2 - c(x_1)) \end{array} \right\}_{j,m_1,m_2} .$$

Bandelettisation

Bandelettisation

- Les fonctions de la base doivent avoir des moments nuls selon x_1 (direction du flot).

Bandelettisation

- Les fonctions de la base doivent avoir des moments nuls selon x_1 (direction du flot).

- Base d'ondelettes déformées de $L^2(\Omega)$:

$$\left\{ \begin{array}{cc} \phi_{j,m_1}(x_1) \psi_{j,m_2}(x_2 - c(x_1)) & , \quad \psi_{j,m_1}(x_1) \phi_{j,m_2}(x_2 - c(x_1)) \\ \text{Isotrope} & , \quad \psi_{j,m_1}(x_1) \psi_{j,m_2}(x_2 - c(x_1)) \end{array} \right\}_{j, m_1, m_2} .$$

Bandelettisation

- Les fonctions de la base doivent avoir des moments nuls selon x_1 (direction du flot).
- Bandelettisation : remplace $\{\phi_{j,m_1}(x_1)\}_{m_1}$ par une famille d'ondelettes $\{\psi_{l,m_1}(x_1)\}_{l>j, m_1}$ qui génère le même espace.
- Base d'ondelettes déformées de $L^2(\Omega)$:


$$\left\{ \begin{array}{cc} \phi_{j,m_1}(x_1) \psi_{j,m_2}(x_2 - c(x_1)) & , \quad \psi_{j,m_1}(x_1) \phi_{j,m_2}(x_2 - c(x_1)) \\ & , \quad \psi_{j,m_1}(x_1) \psi_{j,m_2}(x_2 - c(x_1)) \end{array} \right\}_{m_1, m_2}^j.$$

Bandelettisation



- Les fonctions de la base doivent avoir des moments nuls selon x_1 (direction du flot).
- Bandelettisation : remplace $\{\phi_{j,m_1}(x_1)\}_{m_1}$ par une famille d'ondelettes $\{\psi_{l,m_1}(x_1)\}_{l>j, m_1}$ qui génère le même espace.
- Obtention d'une *base de bandelettes* de $L^2(\Omega)$:

$$\left\{ \begin{array}{ll} \psi_{l,m_1}(x_1) \psi_{j,m_2}(x_2 - c(x_1)) & , \quad \psi_{j,m_1}(x_1) \phi_{j,m_2}(x_2 - c(x_1)) \\ & , \quad \psi_{j,m_1}(x_1) \psi_{j,m_2}(x_2 - c(x_1)) \end{array} \right\}_{\substack{j,l>j \\ m_1,m_2}} .$$

Anisotrope



Isotrope



Base segmentée de bandelettes

Base segmentée de bandelettes

- Le support de l'image est segmenté en régions munies soit
 - d'une base de bandelettes à flot constant verticalement,
 - d'une base de bandelettes à flot constant horizontalement,
 - d'une base d'ondelettes sans flot (régularité isotrope).



Base segmentée de bandelettes

- Le support de l'image est segmenté en régions munies soit
 - d'une base de bandelettes à flot constant verticalement,
 - d'une base de bandelettes à flot constant horizontalement,
 - d'une base d'ondelettes sans flot (régularité isotrope).



- Transformée rapide en bandelettes ($O(N^2)$) :
 - rééchantillonnage, transformée en ondelettes déformées, bandelettisation.

Base segmentée de bandelettes

- Le support de l'image est segmenté en régions munies soit
 - d'une base de bandelettes à flot constant verticalement,
 - d'une base de bandelettes à flot constant horizontalement,
 - d'une base d'ondelettes sans flot (régularité isotrope).





- Transformée rapide en bandelettes ($O(N^2)$) :
 - rééchantillonnage, transformée en ondelettes déformées, bandelettisation.
- Pas de discontinuités aux frontières grâce à un schéma de lifting adapté.

Approximation M termes

Approximation M termes




- Une approximation en bandelettes est donnée par :
 - une segmentation en rectangle, représentée par les M_s nœuds intérieurs de l'arbre de la segmentation,
 - à l'intérieur de chaque carré Ω_i de la segmentation par :
 - $M_{g,i}$ coefficients du flot géométrique,
 - $M_{b,i}$ coefficients de bandelettes au dessus d'un seuil T .



Approximation M termes

- Une approximation en bandelettes est donnée par :
 - une segmentation en rectangle, représentée par les M_s nœuds intérieurs de l'arbre de la segmentation,
 - à l'intérieur de chaque carré Ω_i de la segmentation par :
 - $M_{g,i}$ coefficients du flot géométrique,
 - $M_{b,i}$ coefficients de bandelettes au dessus d'un seuil T .
- Nombre total de paramètres :

$$M = M_s + \sum_i \left(M_{g,i} + M_{b,i} \right) = \sum_i \left(M_{s,i} + M_{g,i} + M_{b,i} \right) .$$



Optimisation de l'approximation

Optimisation de l'approximation

- Minimiser $\|f - f_M\|^2$ pour un nombre fixé M de paramètres.

Optimisation de l'approximation

- Minimiser $\|f - f_M\|^2$ pour un nombre fixé M de paramètres.
- Approche lagrangienne : trouver le meilleur flot géométrique segmenté qui minimise

$$\|f - f_M\|^2 + T^2 M .$$

Optimisation de l'approximation

- Minimiser $\|f - f_M\|^2$ pour un nombre fixé M de paramètres.
- Approche lagrangienne : trouver le meilleur flot géométrique segmenté qui minimise

$$\|f - f_M\|^2 + T^2 M .$$

- Additivité du Lagrangien :

$$\|f - f_M\|^2 + T^2 M = \sum_i \|f - f_M\|_{\Omega_i}^2 + T^2 M_i \quad .$$

Optimisation de l'approximation


- Minimiser $\|f - f_M\|^2$ pour un nombre fixé M de paramètres.
- Approche lagrangienne : trouver le meilleur flot géométrique segmenté qui minimise

$$\|f - f_M\|^2 + T^2 M .$$

- Additivité du Lagrangien :

$$\|f - f_M\|^2 + T^2 M = \sum_i \|f - f_M\|_{\Omega_i}^2 + T^2 M_i .$$

- Algorithme rapide (CART) : programmation dynamique de bas en haut sur la segmentation en arbre.



Optimisation de l'approximation


- Minimiser $\|f - f_M\|^2$ pour un nombre fixé M de paramètres.
- Approche lagrangienne : trouver le meilleur flot géométrique segmenté qui minimise

$$\|f - f_M\|^2 + T^2 M .$$

- Additivité du Lagrangien :

$$\|f - f_M\|^2 + T^2 M = \sum_i \|f - f_M\|_{\Omega_i}^2 + T^2 M_i .$$


- Algorithme rapide (CART) : programmation dynamique de bas en haut sur la segmentation en arbre.
- Complexité polynomiale : nombre total de vecteurs de base et non pas le nombre total de bases




Fonction régulière par morceaux

Fonction régulière par morceaux

M=2650




PSNR = 45,97 dB





Bandelettes

PSNR = 40,17 dB



Ondelettes




Théorème d'approximation

Théorème d'approximation



Théorème : Si f est de régularité géométrique $\mathbf{C}^\alpha$ ($f = \tilde{f}$ ou $f = \tilde{f} \star h$ avec $\tilde{f} \in \mathbf{C}^\alpha$ en dehors de courbes $\mathbf{C}^\alpha$ par morceaux avec des conditions de non tangence) alors

$$\|f - f_M\|^2 \leq C (\log M)^{\alpha+1} M^{-\alpha} .$$




Théorème d'approximation

- **Théorème** : Si f est de régularité géométrique C^α ($f = \tilde{f}$ ou $f = \tilde{f} \star h$ avec $\tilde{f} \in C^\alpha$ en dehors de courbes C^α par morceaux avec des conditions de non tangence) alors

$$\|f - f_M\|^2 \leq C (\log M)^{\alpha+1} M^{-\alpha}.$$

- Adaptivité : degré de régularité α inconnu.




Théorème d'approximation

- **Théorème** : Si f est de régularité géométrique C^α ($f = \tilde{f}$ ou $f = \tilde{f} \star h$ avec $\tilde{f} C^\alpha$ en dehors de courbes C^α par morceaux avec des conditions de non tangence) alors

$$\|f - f_M\|^2 \leq C (\log M)^{\alpha+1} M^{-\alpha} .$$


- Adaptivité : degré de régularité α inconnu.
- Optimalité : exposant de décroissance α .



Théorème d'approximation

- **Théorème** : Si f est de régularité géométrique C^α ($f = \tilde{f}$ ou $f = \tilde{f} \star h$ avec $\tilde{f} C^\alpha$ en dehors de courbes C^α par morceaux avec des conditions de non tangence) alors

$$\|f - f_M\|^2 \leq C (\log M)^{\alpha+1} M^{-\alpha} .$$



- Adaptivité : degré de régularité α inconnu.
- Optimalité : exposant de décroissance α .
- Comparaison :
 - Ondelettes isotropes : $\|f - f_M\|^2 \leq C M^{-1}$.
 - Curvelets : $\|f - f_M\|^2 \leq C (\log M)^3 M^{-2}$.

Sélection de modèle

Sélection de modèle

- Approximation non linéaire : minimisation de $\|f - f_M\|^2 + T^2 M$.

Sélection de modèle

- Approximation non linéaire : minimisation de $\|f - f_M\|^2 + T^2 M$.
- Pour une base, équivalence avec du seuillage.

Sélection de modèle

- Approximation non linéaire : minimisation de $\|f - f_M\|^2 + T^2 M$.
- Pour une base, équivalence avec du seuillage.
- Algorithme de pénalisation pour la sélection de modèle :

$$F = \operatorname{argmin}_{\tilde{f}=P_{\mathcal{M}}Y} \|Y - \tilde{f}\|^2 + T^2 \dim(\mathcal{M})$$

où $\mathcal{M}$ parcourt les espace engendrés par des sous familles de bases orthonormées d'un sous espace de dimension N .

Sélection de modèle

- Approximation non linéaire : minimisation de $\|f - f_M\|^2 + T^2 M$.
- Pour une base, équivalence avec du seuillage.
- Algorithme de pénalisation pour la sélection de modèle :

$$F = \operatorname{argmin}_{\tilde{f}=P_{\mathcal{M}}Y} \|Y - \tilde{f}\|^2 + T^2 \dim(\mathcal{M})$$

où $\mathcal{M}$ parcourt les espace engendrés par des sous familles de bases orthonormées d'un sous espace de dimension N .

- **Théorème** (Donoho, Birge, Massart, Nowak,...) :
Si le nombre total de vecteurs dans les différentes bases est au plus polynomial en N alors, pour λ suffisamment grand et $T = \lambda\sqrt{\log N}\epsilon$,

$$E(\|F - f\|^2) \leq C \log N (E(\|F_O - f\|^2) + \epsilon/N)$$

Sélection de modèle

- Approximation non linéaire : minimisation de $\|f - f_M\|^2 + T^2 M$.
- Pour une base, équivalence avec du seuillage.
- Algorithme de pénalisation pour la sélection de modèle :

$$F = \operatorname{argmin}_{\tilde{f}=P_{\mathcal{M}}Y} \|Y - \tilde{f}\|^2 + T^2 \dim(\mathcal{M})$$

où $\mathcal{M}$ parcourt les espace engendrés par des sous familles de bases orthonormées d'un sous espace de dimension N .

- **Théorème** (Donoho, Birge, Massart, Nowak,...) :
Si le nombre total de vecteurs dans les différentes bases est au plus polynomial en N alors, pour λ suffisamment grand et $T = \lambda\sqrt{\log N}\epsilon$,

$$E(\|F - f\|^2) \leq C \log N (E(\|F_O - f\|^2) + \epsilon/N)$$

- Quasi optimalité de la méthode.

Sélection de modèle

- Approximation non linéaire : minimisation de $\|f - f_M\|^2 + T^2 M$.
- Pour une base, équivalence avec du seuillage.
- Algorithme de pénalisation pour la sélection de modèle :

$$F = \operatorname{argmin}_{\tilde{f}=P_{\mathcal{M}}Y} \|Y - \tilde{f}\|^2 + T^2 \dim(\mathcal{M})$$

où $\mathcal{M}$ parcourt les espace engendrés par des sous familles de bases orthonormées d'un sous espace de dimension N .

- **Théorème** (Donoho, Birge, Massart, Nowak,...) :
Si le nombre total de vecteurs dans les différentes bases est au plus polynomial en N alors, pour λ suffisamment grand et $T = \lambda\sqrt{\log N}\epsilon$,

$$E(\|F - f\|^2) \leq C \log N (E(\|F_O - f\|^2) + \epsilon/N)$$

- Quasi optimalité de la méthode.
- Possibilité pratique de faire la minimisation ?

Esquisse de démonstration

Esquisse de démonstration

Esquisse de démonstration

- Preuve d'une inégalité similaire en Probabilité.

Esquisse de démonstration

- Preuve d'une inégalité similaire en Probabilité.
- Inégalité de concentration pour les processus gaussiens (Borell, Cirel'son, Ibragimov, Sudakov).

Esquisse de démonstration

- Preuve d'une inégalité similaire en Probabilité.
- Inégalité de concentration pour les processus gaussiens (Borell, Cirel'son, Ibragimov, Sudakov).
- Tableau...

Quasi optimalité des Bandelettes

Quasi optimalité des Bandelettes

Quasi optimalité des Bandelettes

- Contrôle polynomial sur le nombre d'éléments.

Quasi optimalité des Bandelettes

- Contrôle polynomial sur le nombre d'éléments.
- Possibilité d'effectuer la minimisation par l'algorithme de programmation dynamique.

Quasi optimalité des Bandelettes

- Contrôle polynomial sur le nombre d'éléments.
- Possibilité d'effectuer la minimisation par l'algorithme de programmation dynamique.
- Quasi optimalité de la représentation pour l'approximation non linéaire.

Quasi optimalité des Bandelettes

- Contrôle polynomial sur le nombre d'éléments.
- Possibilité d'effectuer la minimisation par l'algorithme de programmation dynamique.
- Quasi optimalité de la représentation pour l'approximation non linéaire.
- **Théorème** : Pour $N \simeq \epsilon^{-1}$ et $T = \lambda \sqrt{\log N} \epsilon$,

$$E(\|F - f\|^2) \leq C |\log \epsilon|^{\alpha+2} \epsilon^{2\alpha/(\alpha+1)}$$


Quasi optimalité des Bandelettes

- Contrôle polynomial sur le nombre d'éléments.
- Possibilité d'effectuer la minimisation par l'algorithme de programmation dynamique.
- Quasi optimalité de la représentation pour l'approximation non linéaire.
- **Théorème** : Pour $N \simeq \epsilon^{-1}$ et $T = \lambda \sqrt{\log N} \epsilon$,



$$E(\|F - f\|^2) \leq C |\log \epsilon|^{\alpha+2} \epsilon^{2\alpha/(\alpha+1)}$$

- Adaptivité automatique.


Bruité (20,19 dB)



Bandelettes (30,29 dB)




Ondelettes (28,21 dB)



Bruité (20,19 dB)



Bandelettes (30,29 dB)




Ondelettes (28,21 dB)




Bruité




Bandelettes




Ondelettes



Bruité (20,19 dB)




Bandelettes (27,68 dB)



Ondelettes (25,79 dB)






Bruité



Bandelettes



Ondelettes



Conclusion

Conclusion

- Estimation à l'aide de la théorie de la sélection de modèle.

Conclusion

- Estimation à l'aide de la théorie de la sélection de modèle.
- Construction d'une représentation adaptée à la nature géométrique des images (bandelettes).

Conclusion

- Estimation à l'aide de la théorie de la sélection de modèle.
- Construction d'une représentation adaptée à la nature géométrique des images (bandelettes).
- Bonnes classes de fonctions ?

Conclusion

- Estimation à l'aide de la théorie de la sélection de modèle.
- Construction d'une représentation adaptée à la nature géométrique des images (bandelettes).
- Bonnes classes de fonctions ?
- Exemple de traitement d'image.

Conclusion

- Estimation à l'aide de la théorie de la sélection de modèle.
- Construction d'une représentation adaptée à la nature géométrique des images (bandelettes).
- Bonnes classes de fonctions ?
- Exemple de traitement d'image.
- Théorie de l'approximation et le principe de concision ont de nombreuses autres applications : compression, apprentissage,...

Preuve – 1

Preuve – 1

● $F = \operatorname{argmin} \|Y - \tilde{f}\|^2 + \lambda^2 \log \nu \sigma^2 M$ avec M_F coefficients.

Preuve – 1

- $F = \operatorname{argmin} \|Y - \tilde{f}\|^2 + \lambda^2 \log \nu \sigma^2 M$ avec M_F coefficients.
- $f_\lambda = \operatorname{argmin} \|f - \tilde{f}\|^2 + \lambda^2 \log \nu \sigma^2 M$ avec M_λ coefficients.

Preuve – 1

- $F = \operatorname{argmin} \|Y - \tilde{f}\|^2 + \lambda^2 \log \nu \sigma^2 M$ avec M_F coefficients.
- $f_\lambda = \operatorname{argmin} \|f - \tilde{f}\|^2 + \lambda^2 \log \nu \sigma^2 M$ avec M_λ coefficients.
- $\|Y - g\|^2 = \|Y - f\|^2 + 2\langle Y - f, f - g \rangle + \|f - g\|^2.$

Preuve – 1

- $F = \operatorname{argmin} \|Y - \tilde{f}\|^2 + \lambda^2 \log \nu \sigma^2 M$ avec M_F coefficients.
- $f_\lambda = \operatorname{argmin} \|f - \tilde{f}\|^2 + \lambda^2 \log \nu \sigma^2 M$ avec M_λ coefficients.
- $\|Y - g\|^2 = \|Y - f\|^2 + 2\langle Y - f, f - g \rangle + \|f - g\|^2.$
- En insérant ceci dans

$$\|Y - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F \leq \|Y - f_\lambda\|^2 + \lambda^2 \log \nu \sigma^2 M_\lambda$$

on obtient

$$\begin{aligned} \|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F &\leq \|f - f_\lambda\|^2 + \lambda^2 \log \nu \sigma^2 M_\lambda \\ &\quad + 2\langle Y - f, f_\lambda - F \rangle \quad . \end{aligned}$$

Preuve – 1

- $F = \operatorname{argmin} \|Y - \tilde{f}\|^2 + \lambda^2 \log \nu \sigma^2 M$ avec M_F coefficients.
- $f_\lambda = \operatorname{argmin} \|f - \tilde{f}\|^2 + \lambda^2 \log \nu \sigma^2 M$ avec M_λ coefficients.
- $\|Y - g\|^2 = \|Y - f\|^2 + 2\langle Y - f, f - g \rangle + \|f - g\|^2.$
- En insérant ceci dans

$$\|Y - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F \leq \|Y - f_\lambda\|^2 + \lambda^2 \log \nu \sigma^2 M_\lambda$$

on obtient

$$\begin{aligned} \|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F &\leq \|f - f_\lambda\|^2 + \lambda^2 \log \nu \sigma^2 M_\lambda \\ &\quad + 2\langle Y - f, f_\lambda - F \rangle \quad . \end{aligned}$$

- On conclut en prouvant qu'avec grande probabilité,

$$|\langle Y - f, f_\lambda - F \rangle| \leq (C/\lambda)(\|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F) \quad .$$

qui implique $C/\lambda < 1$.

Preuve – 2

Preuve – 2

• $|\langle Y - f, f_\lambda - F \rangle| \leq \|P_{\mathcal{M}_\lambda \cup \mathcal{M}_F} W\| \|f_\lambda - F\| \quad .$

Preuve – 2

- $|\langle Y - f, f_\lambda - F \rangle| \leq \|P_{\mathcal{M}_\lambda \cup \mathcal{M}_F} W\| \|f_\lambda - F\| \quad .$
- $\|f_\lambda - F\| \leq \|f_\lambda - f\| + \|f - F\|$
 $\|f_\lambda - F\| \leq 2(\|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F)^{1/2} \quad .$

Preuve – 2

- $|\langle Y - f, f_\lambda - F \rangle| \leq \|P_{\mathcal{M}_\lambda \cup \mathcal{M}_F} W\| \|f_\lambda - F\|$.
- $\|f_\lambda - F\| \leq \|f_\lambda - f\| + \|f - F\|$
 $\|f_\lambda - F\| \leq 2(\|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F)^{1/2}$.
- Inégalité de concentration :

$$P \left(\forall \mathcal{M}, \quad \|P_{\mathcal{M}} W\| \leq \sqrt{12 \log \nu \sigma^2 \dim(\mathcal{M})} \right) \geq 1 - e/\nu \quad .$$

Preuve – 2

- $|\langle Y - f, f_\lambda - F \rangle| \leq \|P_{\mathcal{M}_\lambda \cup \mathcal{M}_F} W\| \|f_\lambda - F\|$.
- $\|f_\lambda - F\| \leq \|f_\lambda - f\| + \|f - F\|$
 $\|f_\lambda - F\| \leq 2(\|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F)^{1/2}$.
- Inégalité de concentration :

$$P \left(\forall \mathcal{M}, \quad \|P_{\mathcal{M}} W\| \leq \sqrt{12 \log \nu \sigma^2 \dim(\mathcal{M})} \right) \geq 1 - e/\nu \quad .$$

- Avec $P \geq 1 - e/\nu$,

$$\|P_{\mathcal{M}_\lambda \cup \mathcal{M}_F} W\| \leq \sqrt{12 \log \nu \sigma^2 (M_\lambda + M_F)}$$

$$\|P_{\mathcal{M}_\lambda \cup \mathcal{M}_F} W\| \leq \sqrt{12/\lambda^2} (\|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F)^{1/2} \quad .$$

Preuve – 2

- $|\langle Y - f, f_\lambda - F \rangle| \leq \|P_{\mathcal{M}_\lambda \cup \mathcal{M}_F} W\| \|f_\lambda - F\|$.
- $\|f_\lambda - F\| \leq \|f_\lambda - f\| + \|f - F\|$
 $\|f_\lambda - F\| \leq 2(\|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F)^{1/2}$.
- Inégalité de concentration :

$$P \left(\forall \mathcal{M}, \quad \|P_{\mathcal{M}} W\| \leq \sqrt{12 \log \nu \sigma^2 \dim(\mathcal{M})} \right) \geq 1 - e/\nu$$

- Avec $P \geq 1 - e/\nu$,

$$\|P_{\mathcal{M}_\lambda \cup \mathcal{M}_F} W\| \leq \sqrt{12 \log \nu \sigma^2 (M_\lambda + M_F)}$$

$$\|P_{\mathcal{M}_\lambda \cup \mathcal{M}_F} W\| \leq \sqrt{12/\lambda^2} (\|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F)^{1/2}$$

- $|\langle Y - f, f_\lambda - F \rangle| \leq \sqrt{48/\lambda^2} (\|f - F\|^2 + \lambda^2 \log \nu \sigma^2 M_F)$.

Preuve – 3

Preuve – 3

● Pour chaque sous-espace $\mathcal{M} = \text{vect}\{b_{\gamma_n}\}$,

$$P(\|P_{\mathcal{M}}W\| \geq E\|P_{\mathcal{M}}W\| + t) \leq e^{-t^2/(2\sigma^2)}$$

Preuve – 3

- Pour chaque sous-espace $\mathcal{M} = \text{vect}\{b_{\gamma_n}\}$,

$$P(\|P_{\mathcal{M}}W\| \geq E\|P_{\mathcal{M}}W\| + t) \leq e^{-t^2/(2\sigma^2)}$$

- $E\|P_{\mathcal{M}}W\| \leq (E(\|P_{\mathcal{M}}W\|^2))^{1/2} \leq \sqrt{M\sigma^2}$ avec $M = \dim(\mathcal{M})$.

Preuve – 3

- Pour chaque sous-espace $\mathcal{M} = \text{vect}\{b_{\gamma_n}\}$,

$$P(\|P_{\mathcal{M}}W\| \geq E\|P_{\mathcal{M}}W\| + t) \leq e^{-t^2/(2\sigma^2)}$$

- $E\|P_{\mathcal{M}}W\| \leq (E(\|P_{\mathcal{M}}W\|^2))^{1/2} \leq \sqrt{M\sigma^2}$ avec $M = \dim(\mathcal{M})$.

- $t = \sqrt{6 \log \nu \sigma^2 M}$, $P\left(\|P_{\mathcal{M}}W\| \geq (1 + \sqrt{6})\sqrt{\log \nu \sigma^2 M}\right) \leq \nu^{-3M}$

Preuve – 3

- Pour chaque sous-espace $\mathcal{M} = \text{vect}\{b_{\gamma_n}\}$,

$$P(\|P_{\mathcal{M}}W\| \geq E\|P_{\mathcal{M}}W\| + t) \leq e^{-t^2/(2\sigma^2)}$$

- $E\|P_{\mathcal{M}}W\| \leq (E(\|P_{\mathcal{M}}W\|^2))^{1/2} \leq \sqrt{M\sigma^2}$ avec $M = \dim(\mathcal{M})$.

- $t = \sqrt{6 \log \nu \sigma^2 M}$, $P\left(\|P_{\mathcal{M}}W\| \geq (1 + \sqrt{6})\sqrt{\log \nu \sigma^2 M}\right) \leq \nu^{-3M}$

- Contrôle sur le nombre de sous-espaces possibles :

$$\begin{aligned} & P\left(\forall \mathcal{M}, \quad \|P_{\mathcal{M}}W\| \geq \sqrt{6 \log \nu \sigma^2 M}\right) \\ & \leq \sum_M \sum_{\mathcal{M}, \dim \mathcal{M} = M} P\left(\|P_{\mathcal{M}}W\| \geq \sqrt{12 \log \nu \sigma^2 M}\right) \\ & \leq \sum_M \binom{\nu}{M} \nu^{-3M} \leq \sum_M 1/(M!) \nu^{-2M} \leq e \nu^{-1} \end{aligned}$$