

Introduction à l'estimation fonctionnelle par méthodes d'ondelettes

CHESNEAU Christophe, ATER Paris VI

06/02/07

Cadre statistique

Ondelettes

Estimation

Compléments

- **Partie I**
 - cadre statistique
- **Partie II**
 - ondelettes
- **Partie III**
 - estimation
- **Partie IV**
 - compléments

Cadre statistique



Cadre statistique

Problème

Illustration

Motivation

Obstacle

Boules de Besov

Bilan I

Ondelettes

Estimation

Compléments

■ Observations :

□ $(X_1, Y_1), \dots, (X_n, Y_n)$ i.i.d.,

$$Y_i = f(X_i) + z_i, \quad i = 1, \dots, n$$

- f fonction inconnue
- X_i de loi $\mathcal{U}([0, 1])$
- z_i de loi $\mathcal{N}(0, 1)$

■ Objectif :

□ reconstruire f à partir des observations

Cadre statistique

Problème

Illustration

Motivation

Obstacle

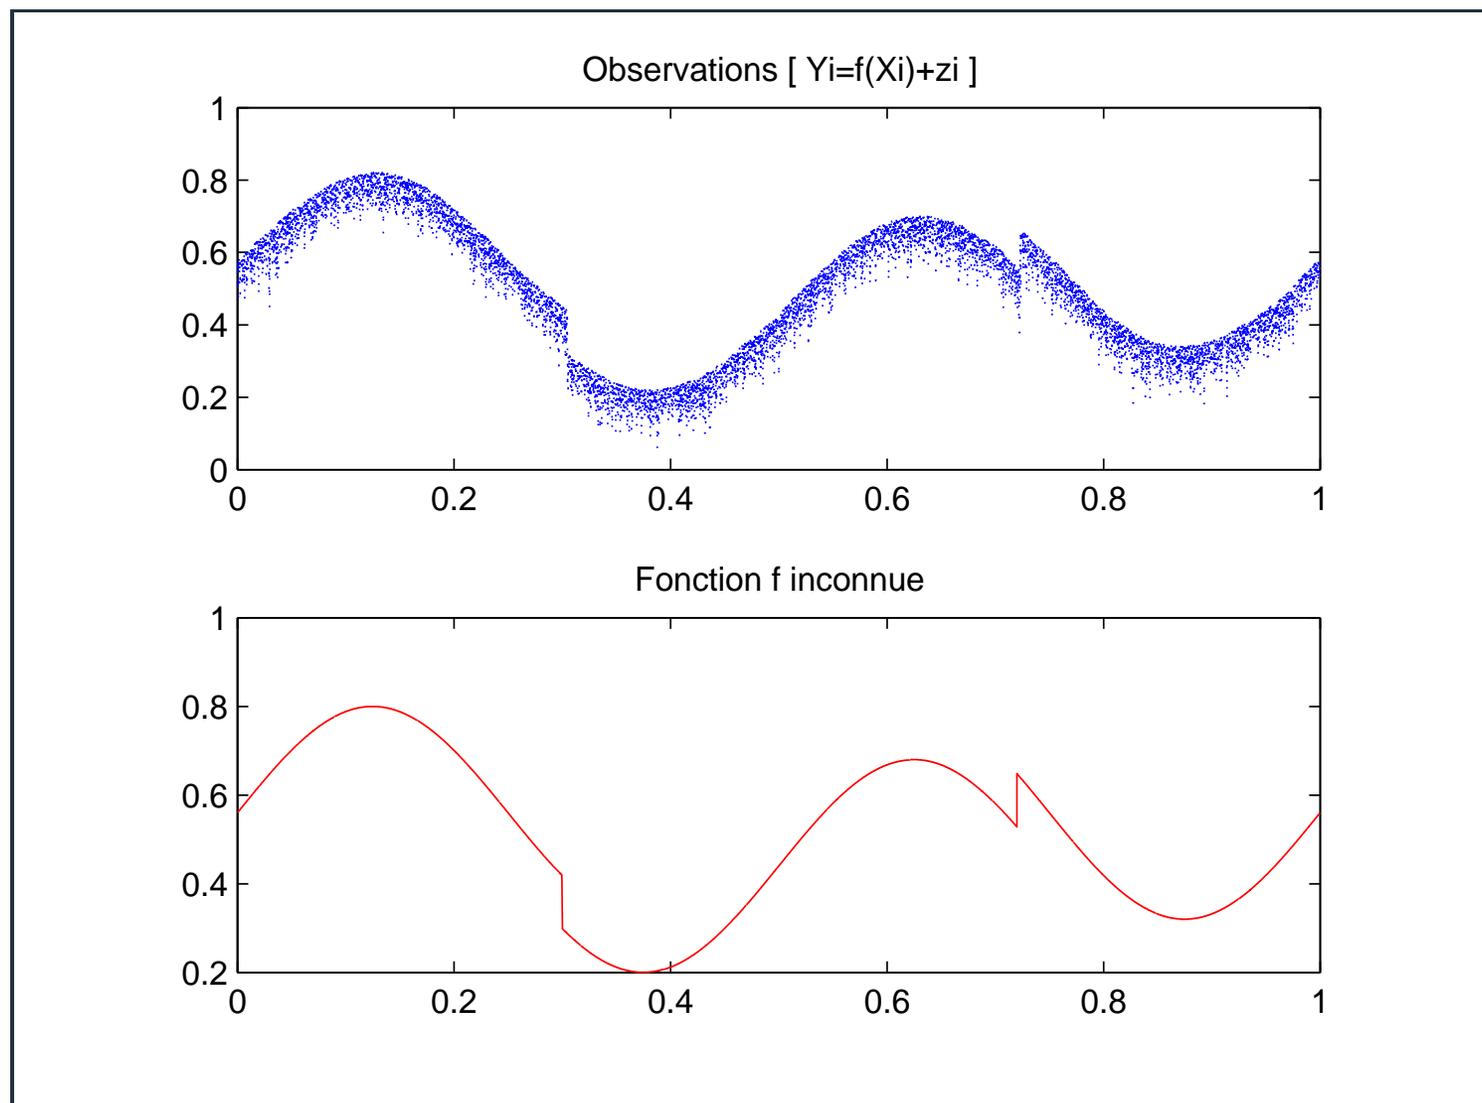
Boules de Besov

Bilan I

Ondelettes

Estimation

Compléments



Cadre statistique

Problème

Illustration

Motivation

Obstacle

Boules de Besov

Bilan I

Ondelettes

Estimation

Compléments

- Motivation :
 - construire des estimateurs \hat{f}_n performants
- Critère de qualité :
 - minimax
- Approche minimax :
 - \hat{f}_n est dit performant si le risque

$$\mathbb{E}_f^n(\|\hat{f}_n - f\|_p^p) = \mathbb{E}_f^n\left(\int_0^1 |\hat{f}_n(x) - f(x)|^p dx\right)$$

converge rapidement vers 0 quand $n \rightarrow +\infty$

Cadre statistique

Problème

Illustration

Motivation

Obstacle

Boules de Besov

Bilan I

Ondelettes

Estimation

Compléments

■ Contrainte :

pour tout \hat{f}_n , on a

$$\lim_{n \rightarrow \infty} \mathbb{E}_f^n(\|\hat{f}_n - f\|_p^p) = 0$$

ssi f appartient à un ensemble de fonctions \mathcal{A}^s

■ s caractérise la régularité

■ Question :

quel \mathcal{A}^s choisir ?

■ Réponse :

un ensemble de fonctions aussi large que possible

■ boules de Besov

Cadre statistique

Problème

Illustration

Motivation

Obstacle

Boules de Besov

Bilan I

Ondelettes

Estimation

Compléments

■ Préliminaires :

- $L, s \in]0, \infty[, \pi, r \in [1, \infty]$
- $\Delta_h(f)(x) = f(x+h) - f(x)$
- pour $u = \lfloor s \rfloor + 1,$

$$\rho^u(t, f, \pi) = \sup_{|h| \leq t} \|\Delta_h^u(f)\|_\pi$$

■ Boules de Besov :

- $f \in B_{\pi,r}^s(L)$ ssi

$$\|f\|_\pi + \left[\int_0^1 (t^{-s} \rho^u(t, f, \pi))^r t^{-1} dt \right]^{1/r} \leq L$$

Cadre statistique

Problème

Illustration

Motivation

Obstacle

Boules de Besov

Bilan I

Ondelettes

Estimation

Compléments

■ Au final :

- on veut construire des estimateurs \hat{f}_n tels que

$$\sup_{f \in B_{\pi,r}^s(L)} \mathbb{E}_f^n(\|\hat{f}_n - f\|_p^p)$$

converge rapidement vers 0 quand $n \rightarrow +\infty$

■ Méthode de construction pour \hat{f}_n :

- méthode d'ondelettes

Ondelettes



Cadre statistique

Ondelettes

Bases d'ondelettes

Décomposition en ondelettes

Intérêt des ondelettes I

Intérêt des ondelettes II

Intérêt des ondelettes III

Précisions

Bilan II

Estimation

Compléments

■ Bases d'ondelettes : Meyer, Daubechies,... (90-92)

□ fonctions de départ :

■ ϕ, ψ , support compact

□ fonctions translatées et dilatées :

■ $\phi_{j,k}(x) = 2^{j/2} \phi(2^j x - k)$

■ $\psi_{j,k}(x) = 2^{j/2} \psi(2^j x - k)$

□ base orthonormée de $\mathbb{L}^2([0, 1])$:

$$\{\phi_{l,k}(x); \psi_{j,k}(x)\}$$

■ $j \geq l, l$ entier grand

■ $k \in \{0, \dots, 2^j - 1\}$

Décomposition en ondelettes

Cadre statistique

Ondelettes

Bases d'ondelettes

Décomposition en ondelettes

Intérêt des ondelettes I

Intérêt des ondelettes II

Intérêt des ondelettes III

Précisions

Bilan II

Estimation

Compléments

■ Décomposition :

□ $f \in \mathbb{L}^2([0, 1]),$

$$f(x) = \sum_{k=0}^{2^l-1} \alpha_{l,k} \phi_{l,k}(x) + \sum_{j=l}^{\infty} \sum_{k=0}^{2^j-1} \beta_{j,k} \psi_{j,k}(x)$$

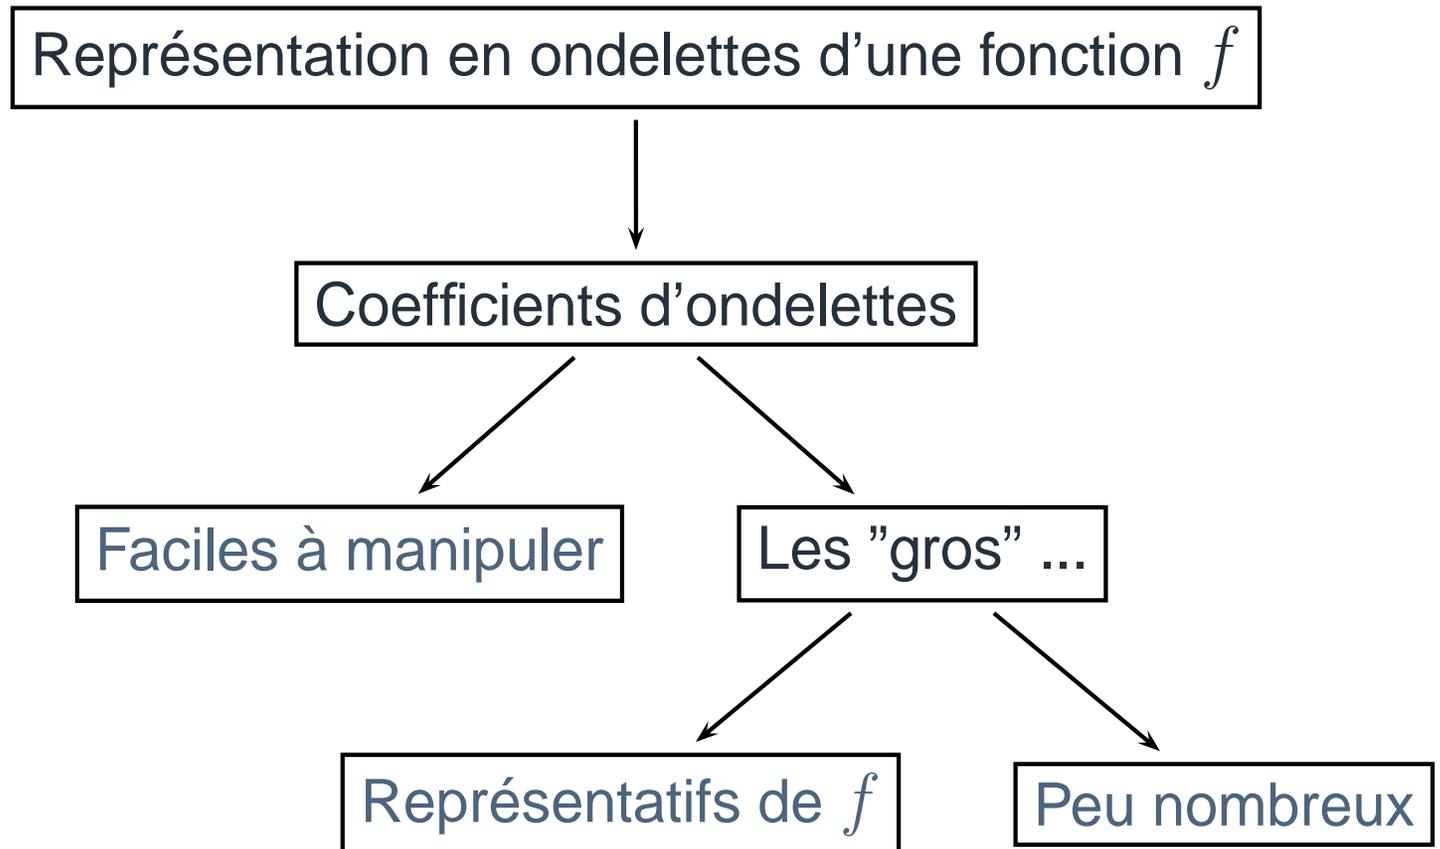
■ $\alpha_{j,k} = \int_0^1 f(x) \phi_{j,k}(x) dx$

■ $\beta_{j,k} = \int_0^1 f(x) \psi_{j,k}(x) dx$

■ Principe :

□ $f = \text{approximation} + \text{détail}$

■ Décomposition sparse :



Cadre statistique

Ondelettes

Bases d'ondelettes

Décomposition en ondelettes

Intérêt des ondelettes I

Intérêt des ondelettes II

Intérêt des ondelettes III

Précisions

Bilan II

Estimation

Compléments

■ Caractérisation des boules de Besov en ondelettes :

□ $f \in B_{\pi,r}^s(L),$

$$\left[\sum_{j=l-1}^{\infty} \left[2^{j(s+1/2)} (2^{-j} \sum_{k=0}^{2^j-1} |\beta_{j,k}|^{\pi})^{1/\pi} \right]^r \right]^{1/r} \leq L_*$$

■ $\beta_{j,k} = \int_0^1 f(x) \psi_{j,k}(x) dx$

■ $\beta_{l-1,k} = \alpha_{l,k}$

Cadre statistique

Ondelettes

Bases d'ondelettes

Décomposition en ondelettes

Intérêt des ondelettes I

Intérêt des ondelettes II

Intérêt des ondelettes III

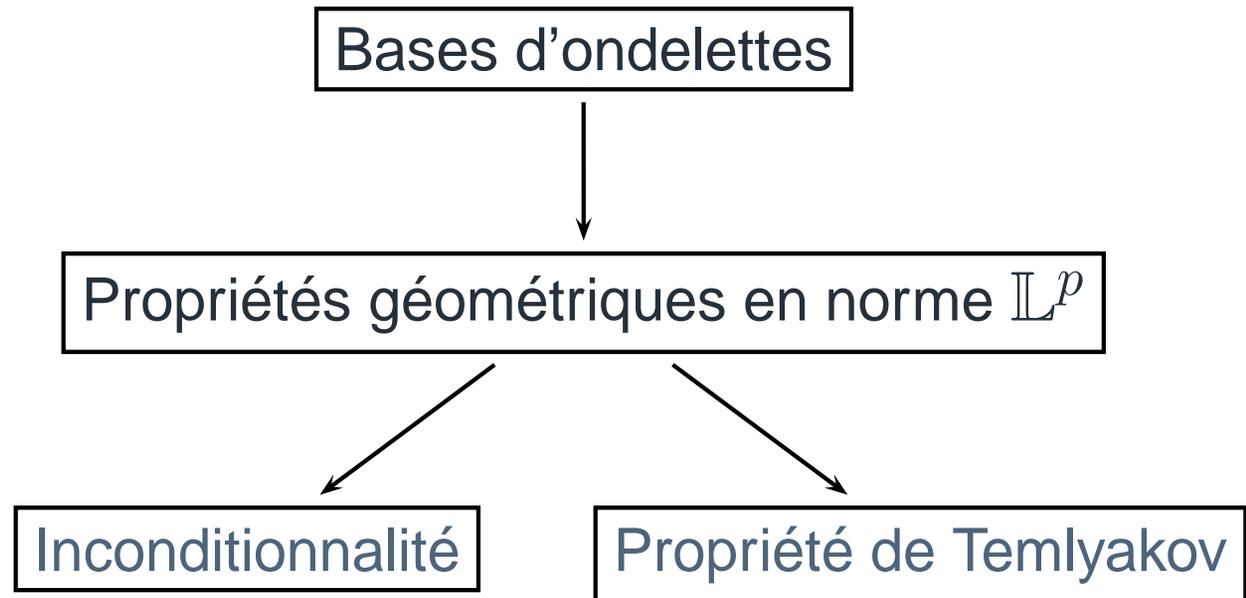
Précisions

Bilan II

Estimation

Compléments

■ Propriétés géométriques :



- Ces propriétés ne sont pas satisfaites par la base de Fourier

■ Propriété d'inconditionnalité :

□ pour tout $u = (u_{j,k})_{j,k}$,

$$\left\| \sum_{j=l}^{+\infty} \sum_{k=0}^{2^j-1} u_{j,k} \psi_{j,k} \right\|_p^p \asymp \left\| \left(\sum_{j=l}^{+\infty} \sum_{k=0}^{2^j-1} |u_{j,k} \psi_{j,k}|^2 \right)^{1/2} \right\|_p^p$$

■ Propriété de Temlyakov :

□ pour tout $\sigma \geq 0$, $A \subseteq \{l, \dots, \infty\}$ et $\mathcal{C} \subseteq \{0, \dots, 2^j - 1\}$,

$$\left\| \left(\sum_{j \in A} \sum_{k \in \mathcal{C}} |2^{\sigma j} \psi_{j,k}|^2 \right)^{1/2} \right\|_p^p \asymp \sum_{j \in A} \sum_{k \in \mathcal{C}} 2^{\sigma j p} \|\psi_{j,k}\|_p^p$$

Cadre statistique

Ondelettes

Bases d'ondelettes

Décomposition en ondelettes

Intérêt des ondelettes I

Intérêt des ondelettes II

Intérêt des ondelettes III

Précisions

Bilan II

Estimation

Compléments

- Au final :
 - les bases d'ondelettes
 - fournissent des décompositions *sparses*
 - caractérisent simplement les boules de Besov
 - possèdent des propriétés géométriques fortes
- À voir :
 - elles nous permettent de construire des estimateurs
 - performants
 - réalistes

Estimation



Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

■ Rappel :

- on observe $(X_1, Y_1), \dots, (X_n, Y_n)$ où

$$Y_i = f(X_i) + z_i, \quad i = 1, \dots, n$$

■ Estimateurs en ondelettes :

1. on décompose f sur la base d'ondelettes
2. on estime $\alpha_{j,k}$ et $\beta_{j,k}$ par $\hat{\alpha}_{j,k}$ et $\hat{\beta}_{j,k}$
3. on sélectionne les $\hat{\beta}_{j,k}$
4. on reconstruit le tout sur la base considérée

■ Méthode de sélection :

- seuillage

Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

- Estimateur de seuillage dur $\hat{f}_n^h(x)$: Donoho et al. (95)

$$\sum_{k=0}^{2^l-1} \hat{\alpha}_{l,k} \phi_{l,k}(x) + \sum_{j=l}^{j_1} \sum_{k=0}^{2^j-1} \hat{\beta}_{j,k} \mathbf{1}_{\left\{|\hat{\beta}_{j,k}| \geq \mu \sqrt{\frac{\log n}{n}}\right\}} \psi_{j,k}(x)$$

- estimateurs de $\alpha_{j,k}$ et $\beta_{j,k}$:

- $\hat{\alpha}_{j,k} = \frac{1}{n} \sum_{i=1}^n \phi_{j,k}(X_i) Y_i$
- $\hat{\beta}_{j,k} = \frac{1}{n} \sum_{i=1}^n \psi_{j,k}(X_i) Y_i$

- paramètres :

- μ réel positif
- $j_1 = \lfloor \log_2(n / \log n) \rfloor$

Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

■ Sans biais :

$$\mathbb{E}_f^n(\hat{\beta}_{j,k}) = \mathbb{E}_f^n(f(X_1)\psi_{j,k}(X_1)) = \beta_{j,k}$$

■ Inégalité de moments :

$$\mathbb{E}_f^n(|\hat{\beta}_{j,k} - \beta_{j,k}|^{2p}) \leq Cn^{-p}$$

■ Inégalité de grande déviation :

$$\mathbb{P}_f^n \left(|\hat{\beta}_{j,k} - \beta_{j,k}| \geq 2^{-1} \mu \sqrt{\frac{\log n}{n}} \right) \leq Cn^{-p}$$

Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

✓ THÉORÈME 1: Donoho et al. (96)

□ si $\pi \geq p$,

$$\sup_{f \in B_{\pi,r}^s(L)} \mathbb{E}_f^n (\| \hat{f}_n^h - f \|_p^p) \leq C \varphi_n,$$

$$\varphi_n = n^{-sp/(2s+1)} (\log n)^{sp/(2s+1)}$$

■ Question :

□ est-ce que la vitesse φ_n peut être améliorée ?

Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

✓ THÉORÈME 2

□ si $\pi \geq p$,

$$C\varphi_n \leq \sup_{f \in B_{\pi,r}^s(L)} \mathbb{E}_f^n(\|\hat{f}_n^h - f\|_p^p),$$

$$\varphi_n = n^{-sp/(2s+1)} (\log n)^{sp/(2s+1)}$$

■ Conclusion :

□ la vitesse φ_n ne peut pas être améliorée

■ Question :

□ existe-il des estimateurs plus performants que \hat{f}_n^h ?

- Estimateur de seuillage dur $\hat{f}_n^d(x)$: Delyon et al. (96)

$$\sum_{k=0}^{2^l-1} \hat{\alpha}_{l,k} \phi_{l,k}(x) + \sum_{j=l}^{j_1} \sum_{k=0}^{2^j-1} \hat{\beta}_{j,k} \mathbf{1}_{\left\{ |\hat{\beta}_{j,k}| \geq \mu \sqrt{\frac{(j-j_s)_+}{n}} \right\}} \psi_{j,k}(x)$$

- $j_s = \lfloor ((1/(1+2s)) \log_2(n)) \rfloor$

- Remarque :

- pour $j \leq j_1$,

$$\sqrt{\frac{\log n}{n}} \geq \sqrt{\frac{(j-j_s)_+}{n}}$$

Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

✓ THÉORÈME 3

□ si $\pi \geq p$,

$$\sup_{f \in B_{\pi,r}^s(L)} \mathbb{E}_f^n(\|\hat{f}_n^d - f\|_p^p) \leq C\varphi_n,$$

$$\varphi_n = n^{-sp/(2s+1)}$$

■ Problème :

□ \hat{f}^d dépend de s , la régularité de f

■ cela n'est pas réaliste car f est inconnue

■ Alternative :

□ seuillage par blocs

Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

- Estimateur BlockShrink $\hat{f}_n^b(x)$:

$$\sum_{k=0}^{2^l-1} \hat{\alpha}_{l,k} \phi_{l,k}(x) + \sum_{j=l}^{j_1} \sum_{k=0}^{2^j-1} \hat{\beta}_{j,k} 1_{\{\hat{b}_{j,k} \geq \mu n^{-1/2}\}} \psi_{j,k}(x)$$

- moyenne partielle des $(\hat{\beta}_{j,k})_k$:

$$\hat{b}_{j,k} = (|U_{j,k}|^{-1} \sum_{m \in U_{j,k}} |\hat{\beta}_{j,m}|^p)^{1/p}$$

- $U_{j,k}$ ensemble indépendant de s

- $|U_{j,k}| = \lfloor \log n \rfloor^{p/2}$

Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

✓ THÉORÈME 4

□ si $\pi \geq p$,

$$\sup_{f \in B_{\pi,r}^s(L)} \mathbb{E}_f^n(\|\hat{f}_n^b - f\|_p^p) \leq C\varphi_n,$$

$$\varphi_n = n^{-sp/(2s+1)}$$

■ Commentaire :

□ l'estimateur \hat{f}^b est :

- optimal au sens minimax
- réaliste

Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

■ Décomposition adéquate de

$$\mathbb{E}_f^n(\| \hat{f}_n^b - f \|_p^p)$$

- propriétés géométriques de la base d'ondelettes

■ Inégalité de concentration :

$$\mathbb{P}_f^n \left(\left[\sum_{k=0}^{\lfloor \log n \rfloor^{p/2}} |\hat{\beta}_{j,k} - \beta_{j,k}|^p \right]^{1/p} \geq 2^{-1} \mu \sqrt{\frac{\log n}{n}} \right) \leq C n^{-p}$$

- inégalité de Talagrand ($\times 2$)
- inégalité de Cirelson

Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

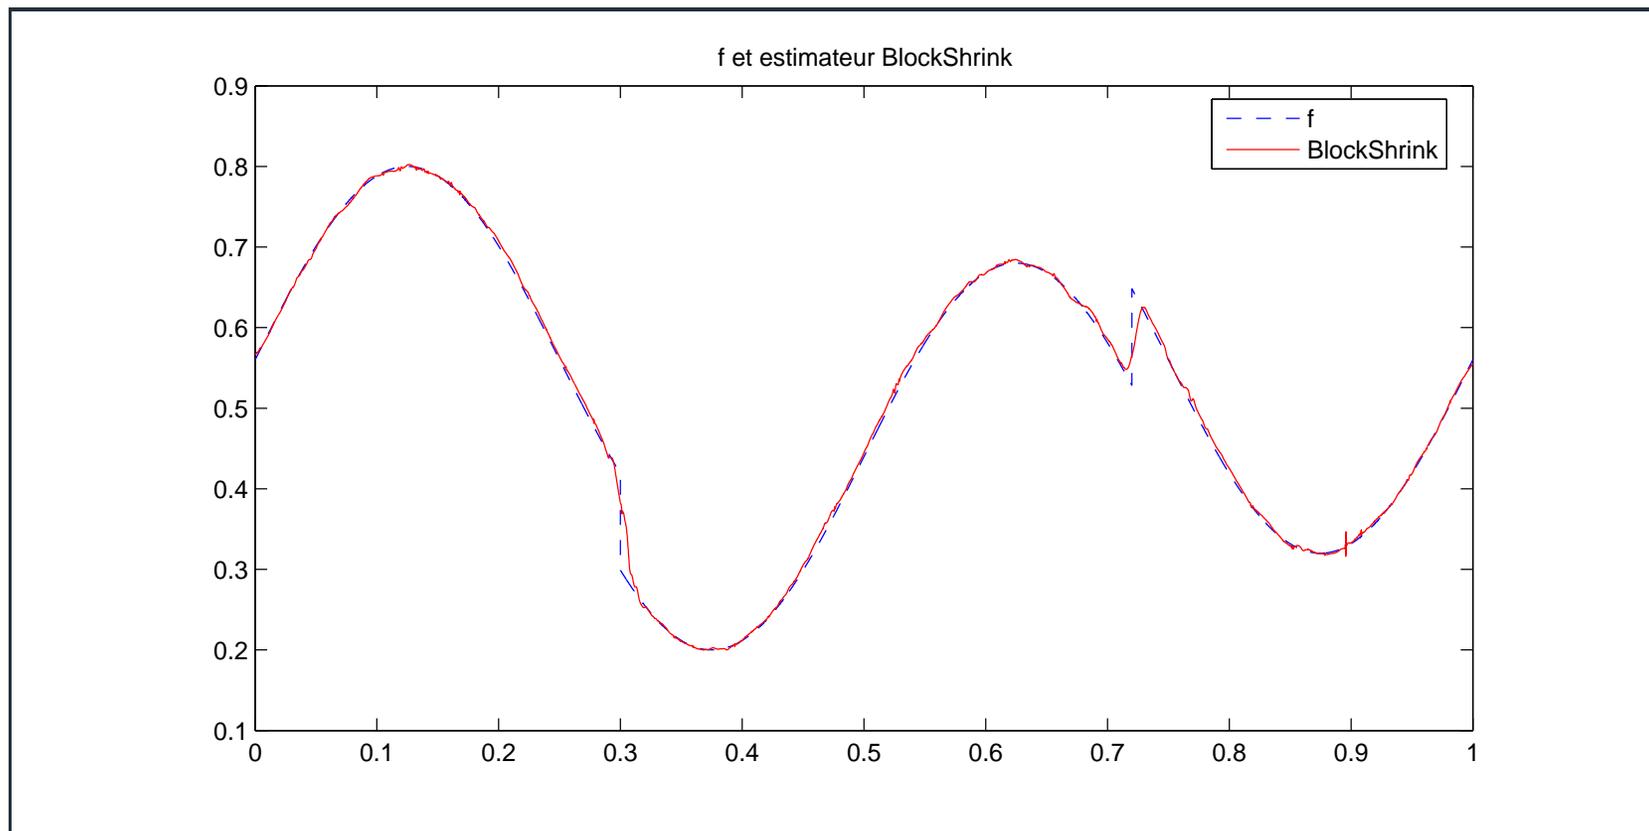
Bornes supérieures

Preuve

Simulation

Bilan III

Compléments



Cadre statistique

Ondelettes

Estimation

Constructions

Seuillage dur

Propriétés de $\hat{\beta}_{j,k}$

Bornes supérieures

Sous-optimalité

Seuillage dur 2

Bornes supérieures

Seuillage par blocs

Bornes supérieures

Preuve

Simulation

Bilan III

Compléments

- Au final :
 - l'estimateur de seuillage par blocs est
 - optimal au sens minimax
 - réaliste
 - performant en pratique

- Compléments :
 - introduction à l'approche maxiset
 - étude du modèle de convolution

Compléments



Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

- Limite de l'approche minimax :

- le choix de $B_{\pi,r}^s(L)$ est subjectif

- Questions :

1. quelles sont les vitesses atteintes par nos estimateurs si $f \notin B_{\pi,r}^s(L)$?
2. est-ce que $B_{\pi,r}^s(L)$ est bien adapté au problème ?

- Alternative :

- approche maxiset

Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

■ Maxiset : Cohen et al. (00), Autin (05)

□ on se fixe :

- une vitesse w_n
- un estimateur \hat{f}_n de f

□ on évalue :

$$\mathcal{M}(\hat{f}_n, w_n) = \left\{ f; \sup_{n>0} w_n^{-1} \mathbb{E}_f^n (\|\hat{f}_n - f\|_p^p) < \infty \right\}$$

■ Objectif :

- construire un estimateur \hat{f}_n tel que $\mathcal{M}(\hat{f}_n, w_n)$ soit le plus gros possible

Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

✓ THÉORÈME 5

□ vitesse :

■ $w_n \in \{n^{-\alpha p/2}, (\log n/n)^{\alpha p/2}\}$

□ $\alpha \in]0, 1[$

□ inclusion maxiset stricte :

$$\mathcal{M}(\hat{f}_n^h, w_n) \subset \mathcal{M}(\hat{f}_n^b, w_n)$$

■ Conclusion :

□ l'estimateur de seuillage par blocs est strictement meilleur au sens maxiset que l'estimateur de seuillage dur

Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du
problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

- Au final :
 - l'estimateur de seuillage par blocs est
 - optimal au sens minimax et maxiset
 - réaliste
 - performant en pratique

- À voir :
 - étude du modèle de convolution

Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

■ Observation :

$$dY(t) = (f \star g)(t)dt + n^{-1/2}dW(t)$$

- f fonction inconnue, 1-périodique
- g fonction connue, ...
- convolution :

$$(f \star g)(t) = \int_0^1 f(t - u)g(u)du$$

- $\{W(t), t \in [0, 1]\}$ Brownien

■ Objectif :

- reconstruire f à partir de $\{Y(t), t \in [0, 1]\}$

Reformulation du problème

Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

■ Remarque :

- le modèle de convolution est équivalent à

$$y_l = f_l \times g_l + n^{-1/2} b_l$$

- $y_l = \int_0^1 e^{-2\pi i l t} dY(t)$
- $f_l = \int_0^1 e^{-2\pi i l t} f(t) dt$
- $g_l = \int_0^1 e^{-2\pi i l t} g(t) dt$
- $b_l = \int_0^1 e^{-2\pi i l t} dB(t)$

■ Objectif :

- reconstruire f à partir de $\{y_l g_l^{-1}; l \in \mathbb{Z}\}$

Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du
problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

■ Hypothèse :

- pour tout $l \in \mathbb{Z}^*$,

$$g_l = \int_0^1 e^{-2\pi i l t} g(t) dt \asymp |l|^{-\delta}$$

■ Exemple simple:

$$g(x) = \sum_{m \in \mathbb{Z}} e^{-|x+m|}$$

- $g_l = 2(1 + 4\pi^2 l^2)^{-1} \asymp |l|^{-2}$

- g vérifie l'hypothèse avec $\delta = 2$

Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

- Estimateur BlockShrink $\hat{f}_n^b(x)$:

$$\sum_{k=0}^{2^l-1} \hat{\alpha}_{l,k} \phi_{l,k}(x) + \sum_{j=l}^{j_1} \sum_{k=0}^{2^j-1} \hat{\beta}_{j,k} 1_{\{\hat{b}_{j,k} \geq \mu 2^{\delta j} n^{-1/2}\}} \psi_{j,k}(x)$$

- ondelettes de Meyer
- estimateur de $\beta_{j,k}$:

$$\hat{\beta}_{j,k} = \sum_{l \in \mathbb{Z}} y_l g_l^{-1} \psi_{j,k,l}$$

- $\psi_{j,k,l} = \int_0^1 e^{-2\pi i l t} \psi_{j,k}(t) dt$
- $j_1 = \lfloor (1/(1+2\delta)) \log_2(n/\log n) \rfloor$

Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

✓ THÉORÈME 6

□ optimalité minimax :

■ si $\pi \geq p$,

$$\sup_{f \in B_{\pi, r}^s(L)} \mathbb{E}_f^n(\|\hat{f}_n^b - f\|_p^p) \leq C\varphi_n,$$

$$\varphi_n = n^{-sp/(2(s+\delta)+1)}$$

□ inclusion maxiset :

■ pour $w_n \in \{n^{-\alpha p/2}, (\log n/n)^{\alpha p/2}\}$, $\alpha \in]0, 1[$,

$$\mathcal{M}(\hat{f}_n^h, w_n) \subset \mathcal{M}(\hat{f}_n^b, w_n)$$

Cadre statistique

Ondelettes

Estimation

Compléments

Introduction

Approche maxiset

Résultat maxiset

Bilan IV

Convolution

Reformulation du problème

Hypothèse

Seuillage par blocs

Performances

Conclusion finale

■ Au final :

- l'estimateur de seuillage par blocs est
 - optimal au sens minimax et maxiset
 - réaliste
 - performant en pratique

■ Précision importante :

- cela est vrai pour de nombreux modèles statistiques sophistiqués
 - ex : régression à pas de loi uniforme
 - ex : modèle de convolution

Merci

