

Agrégation d'estimateurs affines pour la régression

Joseph Salmon

(en collaboration avec **Arnak Dalalyan**)

Séminaire de probabilités et statistiques

Angers

Janvier 2011



Plan

Introduction et motivations

L'agrégation d'estimateurs et les poids exponentiels (EWA)

- Modèle de regression

- L'agrégation d'estimateurs

- L'agrégation à poids exponentiels (EWA)

Résultats

- Inégalité oracle principale

- Corollaires

- Expériences numériques

Conclusion

Introduction

Motivations

- ▶ Théorique : inégalités d'oracles (grande dimension, sparsité), adaptation
- ▶ Applications variées : **traitement d'images**, génétique, problèmes inverses (estimation de dérivée, déconvolution avec un noyau connu, tomographie, etc.)

Heuristique sous-jacente

- ▶ L'agrégation/mélange d'estimateurs est plus stable que la sélection d'un seul estimateur

Motivation principale : débruitage d'images

Modèle du bruit additif



Image observée

Motivation principale : débruitage d'images

Modèle du bruit additif




Image observée

=



Image idéale

Motivation principale : débruitage d'images

Modèle du bruit additif




Image observée

=



Image idéale

+



Bruit

Notation :

$$Y = f + \varepsilon$$

Méthodes à patches et redondance

Introduction aux Non-Local Means (NLM)

Introduction des patches pour le débruitage Buades Coll et Morel (2005)

État de l'art : Dabov et al. (2007), Mairal et al. (2009)

- ▶ Patch à débruiter
- ▶ Patches similaires : poids importants
- ▶ Patches peu similaires : poids faibles
- ▶ Patches très différents : poids quasi nuls

Méthodes à patches et redondance

Introduction aux Non-Local Means (NLM)

Introduction des patches pour le débruitage Buades Coll et Morel (2005)

État de l'art : Dabov et al. (2007), Mairal et al. (2009)

- ▶ Patch à débruiter
- ▶ Patches similaires : poids importants
- ▶ Patches peu similaires : poids faibles
- ▶ Patches très différents : poids quasi nuls

Mélanger lissage classique et NL-Means

- ▶ Y est le vecteur contenant les intensités des pixels d'un patch bruité.
- ▶ L'approche par filtrage estime le vrai patch f par AY , A est une matrice de convolution.
 - ▶ Inégalité oracle exacte pour l'agrégation d'estimateur AY pour des matrices de projections [Leung et Barron \(2006\)](#)
- ▶ L'approche NL-Means estime f en combinant des patches voisins b qui sont essentiellement indépendants de Y .
 - ▶ Inégalité oracle exacte pour l'agrégation d'estimateur construit sur un échantillon indépendant [Dalalyan et Tsybakov \(2007,2008\)](#)
- ▶ On veut étendre ces résultats à l'agrégation d'éléments de la forme $AY + b$ avec A et b indépendants de Y

Notations et modèle

Modèle hétéroscédastique gaussien

$$Y_i = f_i + \sigma_i \varepsilon_i, \quad i = 1, \dots, n \quad (\star)$$

$$\varepsilon_i \text{ i.i.d } \mathcal{N}(0, 1) \quad \text{et} \quad \Sigma = \text{diag}(\sigma_1^2, \dots, \sigma_n^2) \quad (\Sigma \text{ connue})$$

- Rem 1 : grille d'observation fixe (pixels) $f_i = f(x_i), (x_i)_{i=1, \dots, n}$
- Rem 2 : $\Sigma = \sigma^2 Id$, modèle homoscedastique

But : estimer f par \hat{f} , avec un faible risque

$$r = \mathbb{E} \left(\|f - \hat{f}_n\|_n^2 \right) = \mathbb{E} \left(\frac{1}{n} \sum_{i=1}^n (f_i - \hat{f}_i)^2 \right)$$

Lien problème inverse/hétéroscédasticité

T : opérateur **connu** sur un Hilbert $(\mathcal{H}, \langle \cdot | \cdot \rangle_{\mathcal{H}})$

Y : processus aléatoire , pour un $h \in \mathcal{H}$

$$Y = Th + \varepsilon \xi \quad \Longleftrightarrow \quad Y(g) = \langle Th | g \rangle_{\mathcal{H}} + \varepsilon \xi(g), \quad \forall g \in \mathcal{H},$$

T^* : l'adjoint de T ; si $T^* T$ est compact, par SVD

$$T\phi_k = b_k\psi_k, \quad T^*\psi_k = b_k\phi_k, \quad k \in \mathbb{N},$$

b_k : valeurs singulières, $\{\phi_k\}$: base orthonormale de \mathcal{H} , $\{\psi_k\}$: base orthonormale de $\text{Im}(T) \subset \mathcal{H}$. Le modèle se ré-écrit

$$Y(\psi_k) = \langle h | \phi_k \rangle_{\mathcal{H}} b_k + \varepsilon \xi(\psi_k), \quad k \in \mathbb{N}.$$

Si $b_k \neq 0$ le modèle est équivalent à (\star) , avec $f_i = \langle h | \phi_i \rangle_{\mathcal{H}}$ et $\sigma_i = \varepsilon b_i^{-1}$

Cadre de l'agrégation et inégalité d'oracle

On dispose d'une famille de « pré-estimateur » :

$$\mathcal{F}_\Lambda = \{\hat{f}_\lambda \in \mathbb{R}^n, \lambda \in \Lambda\} \text{ avec } \Lambda \subset \mathbb{R}^M$$

But : fournir une inégalité d'oracle pour un estimateur \hat{f}_{agr}

Inégalité d'oracle Nermirovski (2000)

$$\mathbb{E}\|\hat{f}_{agr} - f\|_n^2 \leq C_n \inf_{\lambda \in \Lambda} \mathbb{E}\|\hat{f}_\lambda - f\|_n^2 + R_{n,\Lambda}$$

- ▶ l'**oracle** est l'élément \hat{f}^{λ^*} qui minimise $\mathbb{E}\|\hat{f}_\lambda - f\|_n^2$ sur \mathcal{F}_Λ
- ▶ $C_n \geq 1$. Si $C_n = 1$: on parle d'inégalité d'oracle **exacte**
- ▶ $R_{n,\Lambda} \xrightarrow{n \rightarrow \infty} 0$: prix à payer car on ne connaît pas l'oracle, dépend de la complexité de Λ , du bruit, ...

Rem 1 : on n'a pas besoin d'évaluer le terme d'approximation

Rem 2 : optimalité (borne inférieure) pour certain Λ

Estimation Non-Paramétrique contre Agrégation

	Disponible	Non Disponible	Cible
Estimation NP	\mathbf{Y}	f	trouver le meilleur estimateur
Agrégation	$\mathbf{Y}, \mathcal{F}_\Lambda$	f	trouver un estimateur (presque) aussi bon que le meilleur d'une certaine famille

Avantage : pas besoin d'évaluer le terme d'erreur d'approximation

Méthode par pénalisation

Famille de « pré-estimateurs » : $\mathcal{F}_\Lambda = (\hat{f}_\lambda)_{\lambda \in \Lambda} \in \mathbb{R}^n$ avec $\Lambda \subset \mathbb{R}^M$.

\hat{r}_λ : estimateur sans biais du risque, $\mathbb{E}(\hat{r}_\lambda) = \mathbb{E}(\|f - \hat{f}_\lambda\|_n^2) = r_\lambda$

On suppose que $\hat{f}_\lambda = f_\lambda = \sum_{j=1}^M \lambda_j \varphi_j$

Méthode par pénalisation

$$\hat{f}^{\text{Pen}} = f_{\hat{\lambda}}, \quad \text{où} \quad \hat{\lambda} = \arg \min_{\lambda \in \Lambda} \left(\underbrace{\hat{r}_\lambda}_{\text{adéquation}} + \underbrace{\text{Pen}(\lambda)}_{\text{régularisation}} \right)$$

- $\text{Pen}(\lambda) = \beta \|\lambda\|_2^2$: Ridge **Tikhonov** [43]
- $\text{Pen}(\lambda) = \beta \|\lambda\|_0$: AIC, BIC **Akaike** [74], **Schwarz** [78]
- $\text{Pen}(\lambda) = \beta \|\lambda\|_1$: LASSO **Tibshirani** [96]

Rem 1 : pour les deux derniers des inégalités d'oracles existent

Rem 2 : β paramètre de lissage

Versions par blocs possibles...

Agrégation à poids exponentiels (EWA)

- Extension : élargir l'espace de recherche, changer de pénalité
- Espace de recherche :

$$\mathcal{P}_\Lambda = \{p : \text{probabilité sur } \Lambda \text{ tel que } \mathbb{E} \int_\Lambda \|\hat{f}_\lambda\|_n^2 p(d\lambda) < \infty\}$$

- Pénalisation étendue : $\hat{f}^{\text{Pen}} = \int_\Lambda \hat{f}_\lambda \hat{\pi}^{\text{Pen}}(d\lambda)$ avec

$$\hat{\pi}^{\text{Pen}} = \arg \min_{p \in \mathcal{P}_\Lambda} \left(\int_\Lambda \hat{r}_\lambda p(d\lambda) + \int_\Lambda \text{Pen}(\lambda) p(d\lambda) \right)$$

- Pénalisation KL : π *a priori* sur Λ , l'EWA est

$$\hat{\pi}^{\text{EWA}} = \arg \min_{p \in \mathcal{P}_\Lambda} \left(\int_\Lambda \hat{r}_\lambda p(d\lambda) + \frac{\beta}{n} \mathcal{K}(p, \pi) \right)$$

$$\hat{f}^{\text{EWA}} = \int_\Lambda \hat{f}_\lambda \hat{\pi}^{\text{EWA}}(d\lambda)$$

avec $\mathcal{K}(p, \pi)$ la divergence de Kullback-Leibler entre deux mesures de probabilité $p, \pi \in \mathcal{P}_\Lambda$.

$$\mathcal{K}(p, \pi) = \begin{cases} \int_\Lambda \log \left(\frac{dp}{d\pi}(\lambda) \right) p(d\lambda) & \text{si } p \ll \pi, \\ +\infty & \text{sinon.} \end{cases}$$

Agrégation à poids exponentiels (EWA)

- Extension : élargir l'espace de recherche, changer de pénalité
- Espace de recherche :

$$\mathcal{P}_\Lambda = \{p : \text{probabilité sur } \Lambda \text{ tel que } \mathbb{E} \int_\Lambda \|\hat{f}_\lambda\|_n^2 p(d\lambda) < \infty\}$$

- Pénalisation étendue : $\hat{f}^{\text{Pen}} = \int_\Lambda \hat{f}_\lambda \hat{\pi}^{\text{Pen}}(d\lambda)$ avec

$$\hat{\pi}^{\text{Pen}} = \arg \min_{p \in \mathcal{P}_\Lambda} \left(\int_\Lambda \hat{r}_\lambda p(d\lambda) + \int_\Lambda \text{Pen}(\lambda) p(d\lambda) \right)$$

- Pénalisation KL : π *a priori* sur Λ , l'EWA est

$$\hat{\pi}^{\text{EWA}} = \arg \min_{p \in \mathcal{P}_\Lambda} \left(\int_\Lambda \hat{r}_\lambda p(d\lambda) + \frac{\beta}{n} \mathcal{K}(p, \pi) \right)$$

$$\hat{f}^{\text{EWA}} = \int_\Lambda \hat{f}_\lambda \hat{\pi}^{\text{EWA}}(d\lambda)$$

avec $\mathcal{K}(p, \pi)$ la divergence de Kullback-Leibler entre deux mesures de probabilité $p, \pi \in \mathcal{P}_\Lambda$.

$$\mathcal{K}(p, \pi) = \begin{cases} \int_\Lambda \log \left(\frac{dp}{d\pi}(\lambda) \right) p(d\lambda) & \text{si } p \ll \pi, \\ +\infty & \text{sinon.} \end{cases}$$

Agrégation à poids exponentiels (EWA)

On choisit un *a priori* $\pi \in \mathcal{P}_\Lambda$ (mesure de probabilité sur Λ)

L'agrégat à poids exponentiels (EWA)

Mesure de Gibbs : mesure *a posteriori* sur Λ

$$\hat{\pi}^{\text{EWA}}(d\lambda) \propto \exp(-n\hat{r}_\lambda/\beta)\pi(d\lambda)$$

- ▶ β : un paramètre de lissage (température)
- ▶ \hat{r}_λ : estimateur sans biais du risque $\mathbb{E}\|\hat{f}_\lambda - f\|_n^2$

L'agrégat à poids exponentiel est l'espérance *a posteriori* :

$$\hat{f}^{\text{EWA}} = \int_{\Lambda} \hat{f}_\lambda \hat{\pi}^{\text{EWA}}(d\lambda)$$

Rem : Si $\beta \rightarrow 0$, $\hat{f}^{\text{EWA}} \rightarrow \hat{f}_{\lambda^*}$ avec $\lambda^* = \arg \min_{\lambda} \hat{r}_\lambda$

Si $\beta \rightarrow \infty$, $\hat{f}^{\text{EWA}} \rightarrow \int_{\Lambda} \hat{f}_\lambda \pi(d\lambda)$

Agrégation d'estimateurs affines

Cadre de l'agrégation

- ▶ Point de départ : famille de « pré-estimateurs » :
 $\mathcal{F}_\Lambda = (\hat{f}_\lambda)_{\lambda \in \Lambda} \in \mathbb{R}^n$ avec $\Lambda \subset \mathbb{R}^M$
- ▶ Objectif : approcher f aussi bien que le ferait le meilleur élément de cette famille.

Rem : les pré-estimateurs doivent dépendre des données (!)

Pré-estimateurs affines

$$\hat{f}_\lambda = A_\lambda \mathbf{Y} + b_\lambda$$

- ▶ A_λ est une matrice déterministe $n \times n$
- ▶ b_λ est un vecteur déterministe de \mathbb{R}^n
- ▶ A_λ et b_λ sont indépendants de \mathbf{Y}

Agrégation d'estimateurs affines

Cadre de l'agrégation

- ▶ Point de départ : famille de « pré-estimateurs » :
 $\mathcal{F}_\Lambda = (\hat{f}_\lambda)_{\lambda \in \Lambda} \in \mathbb{R}^n$ avec $\Lambda \subset \mathbb{R}^M$
- ▶ Objectif : approcher f aussi bien que le ferait le meilleur élément de cette famille.

Rem : les pré-estimateurs doivent dépendre des données (!)

Pré-estimateurs affines

$$\hat{f}_\lambda = A_\lambda \mathbf{Y} + b_\lambda$$

- ▶ A_λ est une matrice déterministe $n \times n$
- ▶ b_λ est un vecteur déterministe de \mathbb{R}^n
- ▶ A_λ et b_λ sont indépendants de \mathbf{Y}

Cas constant : $A_\lambda = 0$

Pré-estimateurs déterministes : $\hat{f}_\lambda = f_\lambda (= b_\lambda)$

Exemples de familles de pré-estimateurs

- ▶ $\mathcal{F}_\Lambda = \{\varphi_1, \dots, \varphi_M\}$ est un « dictionnaire » fixé et fini
- ▶ $\mathcal{F}_\Lambda = \text{conv}(\varphi_1, \dots, \varphi_M)$ combinaisons convexes d'éléments d'un « dictionnaire » : $f_\lambda = \sum_{j=1}^M \lambda_j \varphi_j$, où les φ_j sont fixées
- ▶ $\mathcal{F}_\Lambda = \text{vect}(\varphi_1, \dots, \varphi_M)$ combinaisons linéaires d'éléments d'un « dictionnaire » : $f_\lambda = \sum_{j=1}^M \lambda_j \varphi_j$, où les φ_j sont fixées
- ▶ $\mathcal{F}_\Lambda = \text{vect}_S(\varphi_1, \dots, \varphi_M)$ combinaisons “creuses” (sparse) d'éléments d'un « dictionnaire » :
 $f_\lambda = \sum_{j=1}^M \lambda_j \varphi_j$, avec au plus S coefficients λ_j non nuls

Bornes inférieures disponibles : Tsybakov (2003), Bunea Tsybakov Wegkamp (2007)

Cas linéaire : $\hat{f}_\lambda = A_\lambda \mathbf{Y}$ ($b_\lambda = 0$)

Moindres carrés ordinaires

$\{\mathcal{S}_\lambda : \lambda \in \Lambda\}$ ensemble de sous-espaces de \mathbb{R}^n

A_λ : projecteurs orthogonaux sur \mathcal{S}_λ Leung et Barron [06], Alquier et Lounici [à paraître], Rigollet et Tsybakov [à paraître]

Cas des matrices diagonales

$$A_\lambda = \text{diag}(a_1, \dots, a_n)$$

- ▶ Projections ordonnées : $a_k = \mathbb{1}_{(k \leq \lambda)}$ pour λ entier, ie. $\Lambda = \{1, \dots, n\}$
- ▶ Filtre de Pinsker : $a_k = (1 - \frac{k^\alpha}{w})_+$, où $x_+ = \max(x, 0)$ et $w, \alpha > 0$, i.e., $\Lambda = (\mathbb{R}_+^*)^2$

Autres cas possibles : Kernel ridge regression, traitement par blocs, etc.

Cas linéaire : $\hat{f}_\lambda = A_\lambda \mathbf{Y}$ ($b_\lambda = 0$)

Moindres carrés ordinaires

$\{\mathcal{S}_\lambda : \lambda \in \Lambda\}$ ensemble de sous-espaces de \mathbb{R}^n

A_λ : projecteurs orthogonaux sur \mathcal{S}_λ Leung et Barron [06], Alquier et Lounici [à paraître], Rigollet et Tsybakov [à paraître]

Cas des matrices diagonales

$$A_\lambda = \text{diag}(a_1, \dots, a_n)$$

- Projections ordonnées : $a_k = \mathbb{1}_{(k \leq \lambda)}$ pour λ entier, ie.
 $\Lambda = \{1, \dots, n\}$
- Filtre de Pinsker : $a_k = (1 - \frac{k^\alpha}{w})_+$, où $x_+ = \max(x, 0)$ et $w, \alpha > 0$, i.e., $\Lambda = (\mathbb{R}_+^*)^2$

Autres cas possibles : Kernel ridge regression, traitement par blocs, etc.

Pré-estimateurs affines et estimation du risque

Formule de Stein [81]

Si \hat{f} est un estimateur différentiable presque partout en Y et que $\partial_{Y_i} \hat{f}_i$ est intégrable alors

$$\hat{r} = \|Y - \hat{f}\|_n^2 + \frac{2}{n} \sum_{i=1}^n \partial_{Y_i} \hat{f}_i \sigma_i^2 - \frac{1}{n} \sum_{i=1}^n \sigma_i^2$$

est un estimateur sans biais du risque $\mathbb{E}(\hat{r}_n) = r$

Cas affine : $\hat{f}_\lambda = A_\lambda Y + b_\lambda$

Conclusion :

$$\hat{r}_\lambda = \|Y - \hat{f}_\lambda\|_n^2 + \frac{2}{n} \text{Tr}(\Sigma A_\lambda) - \frac{1}{n} \text{Tr}(\Sigma)$$

est un estimateur sans biais du risque r_λ

Conditions du théorème principal

Condition C_1

- ▶ Matrices A_λ : projections orthogonales ($A_\lambda^2 = A_\lambda^\top = A_\lambda$)
- ▶ Vecteurs b_λ : $A_\lambda b_\lambda = 0$

Exemple : A_λ projections sur des sous espaces de \mathbb{R}^n Leung et Barron [06]

Condition C_2

- ▶ Matrices A_λ : symétriques, semi-définies positives
- ▶ $A_\lambda A_{\lambda'} = A_{\lambda'} A_\lambda, \forall \lambda, \lambda' \in \Lambda$
- ▶ Vecteurs b_λ : $A_{\lambda'} b_\lambda = 0, \forall \lambda, \lambda' \in \Lambda$

Exemple : les A_λ sont des estimateurs par seuillage de type James-Stein en deux blocs Leung [04]

Conditions du théorème principal

Condition C_1

- ▶ Matrices A_λ : projections orthogonales ($A_\lambda^2 = A_\lambda^\top = A_\lambda$)
- ▶ Vecteurs b_λ : $A_\lambda b_\lambda = 0$

Exemple : A_λ projections sur des sous espaces de \mathbb{R}^n Leung et Barron [06]

Condition C_2

- ▶ Matrices A_λ : symétriques, semi-définies positives
- ▶ $A_\lambda A_{\lambda'} = A_{\lambda'} A_\lambda, \forall \lambda, \lambda' \in \Lambda$
- ▶ Vecteurs b_λ : $A_{\lambda'} b_\lambda = 0, \forall \lambda, \lambda' \in \Lambda$

Exemple : les A_λ sont des estimateurs par seuillage de type James-Stein en deux blocs Leung [04]

Énoncé du théorème principal

Borne PAC-bayésienne Dalalyan et S. [Soumis]

Si \mathbf{C}_1 ou \mathbf{C}_2 est vérifiée, alors \hat{f}^{EWA} vérifie pour tout *a priori* π :

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

où $\mathcal{K}(p, \pi)$ est la divergence de Kullback-Leibler entre p et π , et $\beta \geq 4 \max_{i=1, \dots, n} \sigma_i^2$ sous \mathbf{C}_1 et $\beta \geq 8 \max_{i=1, \dots, n} \sigma_i^2$ sous \mathbf{C}_2 , avec $\mathcal{K}(p, \pi)$ la divergence de Kullback-Leibler entre deux mesures de probabilité $p, \pi \in \mathcal{P}_\Lambda$.

$$\mathcal{K}(p, \pi) = \begin{cases} \int_\Lambda \log \left(\frac{dp}{d\pi}(\lambda) \right) p(d\lambda) & \text{si } p \ll \pi, \\ +\infty & \text{sinon.} \end{cases}$$

Corollaire : cas discret

Inégalité Oracle : $\Lambda = \llbracket 1, M \rrbracket$, π uniforme

Si \mathbf{C}_1 ou \mathbf{C}_2 est vérifiée, et si π est uniforme sur $\llbracket 1, M \rrbracket$, alors

$$\mathbb{E}(\|\hat{f}^{\text{EWA}} - f\|_n^2) \leq \inf_{\lambda \in \llbracket 1, M \rrbracket} \left(\mathbb{E}\|\hat{f}_\lambda - f\|_n^2 + \frac{\beta \log(M)}{n} \right)$$

pour $\beta \geq \alpha \max_{i=1, \dots, n} \sigma_i^2$. $\alpha = 4$ sous \mathbf{C}_1 et $\alpha = 8$ sous \mathbf{C}_2 .

- Pour $b_\lambda = 0$, résultat de [Leung et Barron \(2006\)](#)
- Pour $A_\lambda = 0$, et si pour tout i , $\sigma_i = \sigma$: l'inégalité est optimale [Tsybakov \(2003\)](#)

Inégalité Oracle Sparse

Scénario sparse : il existe un vecteur sparse $\lambda^* \in \Lambda = \mathbb{R}^M$ tel que $\hat{f}_{\lambda^*} \approx f$. Choix d'un *a priori* favorisant la sparsité

$$\pi(d\lambda) \propto \prod_{j=1}^M \frac{1}{(1 + |\lambda_j/\tau|^2)^2} \mathbb{1}_{\Lambda}(\lambda),$$

$\tau > 0$: paramètre de concentration.

Inégalité Oracle

Prenons π définit ci-dessus, supposons que $\lambda \mapsto r_{\lambda}$ est \mathcal{C}^1 , et qu'il existe une matrice \mathcal{M} de taille $M \times M$ telle que :

$$r_{\lambda} - r_{\lambda'} - \nabla r_{\lambda'}^{\top}(\lambda - \lambda') \leq (\lambda - \lambda')^{\top} \mathcal{M}(\lambda - \lambda'), \quad \forall \lambda, \lambda' \in \Lambda.$$

Si \mathbf{C}_1 ou \mathbf{C}_2 est vérifiée

$$\mathbb{E}(\|\hat{f}^{\text{EWA}} - f\|_n^2) \leq \inf_{\lambda \in \mathbb{R}^M} \left\{ \mathbb{E} \|\hat{f}_{\lambda} - f\|_n^2 + \frac{4\beta}{n} \sum_{j=1}^M \log \left(1 + \frac{|\lambda_j|}{\tau} \right) \right\} + \text{Tr}(\mathcal{M}) \tau^2$$

pour $\beta \geq \alpha \max_{i=1, \dots, n} \sigma_i^2$. $\alpha = 4$ sous \mathbf{C}_1 et $\alpha = 8$ sous \mathbf{C}_2 .

Point de vue minimax : cas homoscédastique, $\Sigma = \sigma^2 Id$

$\theta_k(f) = \langle f | \varphi_k \rangle_n$: coefficients de la transformée (orthogonale) de Fourier discrète de f , notée $\mathcal{D}f$

Ellipsoïde de Sobolev : $\mathcal{F}(\alpha, R) = \{f \in \mathbb{R}^n : \sum_{k=1}^n k^{2\alpha} \theta_k(f)^2 \leq R\}$

Théorème de Pinsker

$$\begin{aligned} \inf_{\hat{f}} \sup_{f \in \mathcal{F}(\alpha, R)} \mathbb{E}(\|\hat{f} - f\|_n^2) &\sim \inf_A \sup_{f \in \mathcal{F}(\alpha, R)} \mathbb{E}(\|A \mathbf{Y} - f\|_n^2) \\ &\sim \inf_{w > 0} \sup_{f \in \mathcal{F}(\alpha, R)} \mathbb{E}(\|A_{\alpha, w} \mathbf{Y} - f\|_n^2) \end{aligned}$$

\inf est sur tous les estimateurs \hat{f} possibles et

$A_{\alpha, w} = \mathcal{D}^\top \text{diag}((1 - k^\alpha/w)_+; k = 1, \dots, n) \mathcal{D}$: Filtre de Pinsker

Morale : Estimateurs linéaires minimax sur les ellipsoïdes

EWA, adaptation et simulations

EWA sur des filtres de Pinsker : $\hat{f}_{\alpha,w} = \mathcal{D}^\top A_{\alpha,w} \mathcal{D} Y$ (\mathcal{D} : DCT),
avec $A_{\alpha,w} = \text{diag}((1 - \frac{k^\alpha}{w})_+, k = 1, \dots, n)$

Choix *a priori* π :


- ▶ Tirer α selon une lois exponentielle de paramètre 1
- ▶ Sachant α , tirer w selon $\frac{2n_\sigma^{-\alpha/(2\alpha+1)}}{(1+n_\sigma^{-\alpha/(2\alpha+1)})^w}$ avec $n_\sigma = n/\sigma^2$

Performance


- ▶ Théorique : adaptatif au sens minimax exacte sur les ellipsoïdes $\{\mathcal{F}(\alpha, R) : \alpha > 0, R > 0\}$
- ▶ Pratique : performances au moins aussi bonnes que celle d'autres estimateurs adaptatifs classiques (Sure-Shrink Donoho et Johnstone [95] , James-Stein par blocs Cai [99] , minimiseur du risque empirique Cavalier et al. [02])

Application à des signaux 1D


Signal Length: $n=512$




Noisy function : $\sigma=0.1$ and $MSE=0.0093593$



Denosed by EWA — $MSE=0.0021633$




Denosed by other methods




Application à des signaux 1D


Signal Length: $n=512$




Noisy function : $\sigma=0.33$ and $\text{MSE}=0.10477$



Denoised by EWA — $\text{MSE}=0.0074036$




Denoised by other methods




Application à des signaux 1D


Signal Length: $n=512$




Noisy function : $\sigma=1$ and $\text{MSE}=0.89902$



Denoised by EWA — $\text{MSE}=0.021491$



Denoised by other methods



Conclusion

Contributions

- ▶ Inégalité d'oracle exacte pour certains estimateurs affines
- ▶ Résultat sur l'adaptation en fonction de la régularité des signaux

Ouvertures possibles et travaux en cours

- ▶ Liens avec les travaux sur l'apprentissage pour le traitement par patches
- ▶ Autres modèles de bruits : modèle de Poisson notamment

<http://people.math.jussieu.fr/~salmon/>

Conclusion

Contributions

- ▶ Inégalité d'oracle exacte pour certains estimateurs affines
- ▶ Résultat sur l'adaptation en fonction de la régularité des signaux

Ouvertures possibles et travaux en cours

- ▶ Liens avec les travaux sur l'apprentissage pour le traitement par patches
- ▶ Autres modèles de bruits : modèle de Poisson notamment

<http://people.math.jussieu.fr/~salmon/>

Références I

► H. Akaike.

A new look at the statistical model identification.

IEEE Trans. Automatic Control, AC-19 :716–723, 1974.

System identification and time-series analysis.

► P. Alquier and K. Lounici.

Pac-bayesian bounds for sparse regression estimation with exponential weights.

hal-00465801, submitted, 2010.

► A. Buades, B. Coll, and J-M. Morel.

A review of image denoising algorithms, with a new one.

Multiscale Model. Simul., 4(2) :490–530, 2005.

► F. Bunea, A. B. Tsybakov, and M. H. Wegkamp.

Aggregation for Gaussian regression.

Ann. Statist., 35(4) :1674–1697, 2007.

Références II

- ▶ T. T. Cai.
Adaptive wavelet estimation : a block thresholding and oracle inequality approach.
Ann. Statist., 27(3) :898–924, 1999.
- ▶ L. Cavalier, G. K. Golubev, D. Picard, and A. B. Tsybakov.
Oracle inequalities for inverse problems.
Ann. Statist., 30(3) :843–874, 2002.
- ▶ K. Dabov, A. Foi, V. Katkovnik, and K. O. Egiazarian.
Image denoising by sparse 3-D transform-domain collaborative filtering.
IEEE Trans. Image Process., 16(8) :2080–2095, 2007.
- ▶ D. L. Donoho and I. M. Johnstone.
Adapting to unknown smoothness via wavelet shrinkage.
J. Amer. Statist. Assoc., 90(432) :1200–1224, 1995.
- ▶ A. S. Dalalyan and A. B. Tsybakov.
Aggregation by exponential weighting, sharp oracle inequalities and sparsity.
In *COLT*, pages 97–111, 2007.

Références III

- ▶ A. S. Dalalyan and A. B. Tsybakov.
Aggregation by exponential weighting, sharp pac-bayesian bounds and sparsity.
Mach. Learn., 72(1-2) :39–61, 2008.
- ▶ A. S. Dalalyan and A. B. Tsybakov.
Sparse regression learning by aggregation and Langevin Monte-Carlo.
In *COLT*, 2009.
- ▶ G. Leung and A. R. Barron.
Information theory and mixing least-squares regressions.
IEEE Trans. Inf. Theory, 52(8) :3396–3410, 2006.
- ▶ G. Leung.
Information Theory and Mixing Least Squares Regression.
PhD thesis, Yale University, 2004.
- ▶ J. Mairal, F. Bach, J. Ponce, G. Sapiro, and A. Zisserman.
Non-local sparse models for image restoration.
ICCV, 2009.

Références IV

- ▶ A. S. Nemirovski.
Topics in non-parametric statistics, volume 1738 of *Lecture Notes in Math.*
Springer, Berlin, 2000.
- ▶ Ph. Rigollet and A. B. Tsybakov.
Exponential screening and optimal rates of sparse estimation.
arXiv :1003.2654, submitted, 2010.
- ▶ G. Schwarz.
Estimating the dimension of a model.
Ann. Statist., 6(2) :461–464, 1978.
- ▶ C. M. Stein.
Estimation of the mean of a multivariate normal distribution.
Ann. Statist., 9(6) :1135–1151, 1981.
- ▶ R. Tibshirani.
Regression shrinkage and selection via the lasso.
J. Roy. Statist. Soc. Ser. B, 58(1) :267–288, 1996.

Références V

- ▶ A. N. Tikhonov.

On the stability of inverse problems.

C. R. (Doklady) Acad. Sci. URSS (N.S.), 39 :176–179, 1943.

- ▶ A. B. Tsybakov.

Optimal rates of aggregation.

In *COLT*, pages 303–313, 2003.