

# Estimation de densité par pénalisation $\ell_1$ minimale

Erwan LE PENNEC

SELECT, INRIA Saclay - Univ. Paris Sud  
en collaboration avec

Karine BERTIN (Univ. de Valparaiso, Chili)  
et

Vincent RIVOIRARD (Univ. Paris Dauphine)

50 ans du LPMA - 07 décembre 2010

# Estimation de densité par pénalisation $\ell_1$ minimale

Erwan LE PENNEC

ex LPMA – Université Paris Diderot

en collaboration avec

Karine BERTIN (ex LPMA – Université Pierre et Marie Curie)

et

Vincent RIVOIRARD (ex LPMA – Université Paris Diderot)

50 ans du LPMA - 07 décembre 2010



# LPMA



# LPMA



# LPMA



# LPMA



# Cadre

## Estimation de densité

- $X_1, \dots, X_n$  i.i.d de loi  $f_0(x)dx$ .
- Hyp :  $f_0 \in L^2$ .
- Pas d'hypothèse  $f_0 \in L^\infty$  et surtout pas  $\|f_0\|_\infty$  connue.

## Approche dictionnaire

- Dictionnaire arbitraire  $\mathcal{D} = \{\phi_k\}_{1 \leq k \leq p}$ .
- Hyp :  $\phi_k \in L^2 \cap L^\infty$  et  $\|\phi_k\|_\infty$  connue.
- Notation :  $f_\lambda = \sum_{k=1}^p \lambda_k \phi_k$ .

## Objectifs

- Estimation de  $f_0$  par une combinaison linéaire  $f_\lambda$  du dictionnaire  $\mathcal{D}$ .
- Mesure de l'erreur en norme  $L^2$ .
- Oracle  $\ell_0$  :  $\|\hat{f} - f_0\|^2 \leq (1 + c) \left( \inf_{\lambda \in \mathbb{R}^p} \|f_\lambda - f_0\|^2 + C|\lambda|_0 \right)$  ?
- Cas  $p \gg n$  possible...

# Estimateur de Dantzig

## Produits scalaires

- Produits scalaires et espérances :  $\beta_k = \langle f_0, \phi_k \rangle = \mathbb{E}(\phi_k(X))$ .
- Produits scalaires empiriques :  $\hat{\beta}_k = \frac{1}{n} \sum_{i=1}^n \phi_k(X_i) \simeq \beta_k$ .
- Pour  $f_\lambda = \sum_{k=1}^p \lambda_k \phi_k$ ,  $\langle f_\lambda, \phi_k \rangle = (G\lambda)_k$  où  $G$  : matrice de Gram du dictionnaire  $\mathcal{D}$  ( $G_{k,k'} = \langle \phi_k, \phi_{k'} \rangle$ ).

## Contraintes et régularisation

- Recherche de  $\lambda$  tel que  $G\lambda \simeq \hat{\beta} \simeq \beta$ .
- Moindres carrés :  $\hat{\lambda}^{MC} = \operatorname{argmin} \|G\lambda - \hat{\beta}\|^2$ . (Pb si  $p \gg n$ !).
- Contraintes de Dantzig :  $\forall k \in \{1, \dots, p\}, |(G\lambda)_k - \hat{\beta}_k| \leq \eta_k$ .
- + Régularisation par la norme  $\ell_1$  de  $\lambda$ .
- Estimateur de Dantzig :  
$$\hat{\lambda}^D = \operatorname{argmin} \|\lambda\|_{\ell_1} \quad \text{sous} \quad \forall k \in \{1, \dots, p\}, |(G\lambda)_k - \hat{\beta}_k| \leq \eta_k.$$

# Estimateur Lasso / SPADES

## Norme quadratique

- Erreur  $L^2$  :  $\|f - f_0\|_2^2 = \|f\|_2^2 - 2\mathbb{E}(f(X)) + \|f_0\|_2^2$ .
- Contraste  $L^2$  :  $\gamma(f) = -2\frac{1}{n} \sum_{i=1}^n f(X_i) + \|f\|_2^2 \simeq \|f - f_0\|_2^2 - \|f_0\|_2^2$ .
- Pour  $f_\lambda = \sum_{k=1}^p \lambda_k \phi_k$ ,  $\gamma(f_\lambda) = -2\lambda^* \hat{\beta} + \lambda^* G \lambda$ .

## Contraste et pénalisation

- Minimisation du contraste empirique pénalisé par  $2 \sum_k \eta_k |\lambda_k|$ .
- SPADES / Estimateur Lasso :  
$$\hat{\lambda}^L = \operatorname{argmin} \frac{1}{2} \left( -2\lambda^* \hat{\beta} + \lambda^* G \lambda \right) + \sum_{k=1}^p \eta_k |\lambda_k|$$

## Lien Dantzig / Lasso

- Condition d'optimalité de premier ordre du Lasso  
= Contraintes de Dantzig,  $\forall k \in \{1, \dots, p\}, |(G\lambda)_k - \hat{\beta}_k| \leq \eta_k$
- Lien fort entre les deux estimateurs...

# Bibliographie parcimonieuse

## Pénalisation $\ell_1$ en statistique

- Frank et Friedman (91–93) Bridge.
- Tibshirani et al. (94–96) Lasso.
- Donoho et al. (95–01) Basis Pursuit.

## Parcimonie et système sous déterminé

- Donoho (2004) Parcimonie et matrice gaussienne.
- Candes, Tao et Romberg (2004) Parcimonie et matrice de Fourier.

## Parcimonie et $\ell_1$ en statistique

- Candes et Tao (2007) Dantzig.
- Lasso/Dantzig, SPADES : Tsybakov, Bickel, Ritov, Bunea, Wegkamp
- Énorme littérature : Plan, Temlyakov, Lounici, van de Geer,...

# Inégalités de concentration

## Choix de $\eta_k$

- Comment choisir  $\eta_k$  pour que  $\mathbb{P}(|\beta_k - \hat{\beta}_k| > \eta_k) \leq 2e^{-u^2/2}$  ?
- Concentration d'un processus empirique simple autour de sa moyenne.

## Hoeffding

- $\eta_k = u \frac{\|\phi_k\|_\infty}{\sqrt{n}} \implies \mathbb{P}(|\beta_k - \hat{\beta}_k| > \eta_k) \leq 2e^{-u^2/2}$ .
- Souvent utilisé mais majoration grossière n'utilisant pas  $f_0$  et limitation sur la norme des  $\phi_k$ .

## Bernstein

- Utilisation de la variance :  $\sigma_k^2 = \text{Var}(\phi_k(X))$ .
- $\eta_k = u \frac{\sigma_k}{\sqrt{n}} + \frac{u^2}{3} \frac{\|\phi_k\|_\infty}{n} \implies \mathbb{P}(|\beta_k - \hat{\beta}_k| > \eta_k) \leq 2e^{-u^2/2}$ .
- Prise en compte fine de  $f_0$  et limitation beaucoup moins forte sur la norme de  $\phi_k$ .

# Inégalités de concentration

## Bernstein (suite)

- Pb : Comme  $f_0$ , la variance est inconnue...
- Majoration possible mais perte du caractère fin :
  - $\sigma_k \leq \|\phi_k\|_\infty$  ( $\simeq$  Hoeffding)
  - $\sigma_k \leq \|f\|_\infty^{1/2} \|\phi_k\|_2$  (Pb hypothèse sur  $\|f\|_\infty$ )

## Adaptation/Auto renormalisation

- Variance empirique :  $\hat{\sigma}_k^2 = \frac{1}{n-1} \sum_{i=1}^n (\phi_k(X_i) - \hat{\beta}_k)^2$
- $\eta_k = \tilde{u} \frac{\hat{\sigma}_k}{\sqrt{n}} + \frac{7}{2} \frac{\tilde{u}^2}{3} \frac{\|\phi_k\|_\infty}{n-1} \implies \mathbb{P}(|\beta_k - \hat{\beta}_k| > \eta_k) \leq 2e^{-u^2/2}$  avec  
 $\tilde{u} = u \sqrt{1 + \frac{2 \log 2}{u^2}}$  et  $\|\phi_k\|_\infty = \sup \phi_k - \inf \phi_k \leq 2\|\phi_k\|_\infty$ .
- Prise en compte adaptative de la variabilité de  $f_0$ .
- De plus,  $\mathbb{P}\left(|\hat{\sigma}_k - \sigma_k| > u \frac{\|\phi_k\|_\infty}{\sqrt{n-1}}\right) \leq 2e^{-u^2/2}$ .

# Contrôle sur les coefficients avec grande probabilité

## Contrôle sur les coefficients

- Borne d'union avec  $u = \sqrt{2\gamma \log p}$ .
- $\eta_k^\gamma = \sqrt{2\gamma c_{\gamma,p} \log p} \frac{\hat{\sigma}_k}{\sqrt{n-1}} + \frac{7}{3} \gamma c_{\gamma,p} \log p \frac{\|\phi_k\|_\infty}{n-1}$  avec  $c_{\gamma,p} = 1 + \frac{\log 2}{\gamma \log p}$ .

## L'évènement $\Omega_{\gamma_1}$

- Pour tout  $\gamma_1 > 0$ , évènement  $\Omega_{\gamma_1}$  de proba  $\geq 1 - 2 \left(\frac{1}{p}\right)^{\gamma_1 - 1}$  :

$$\Omega_{\gamma_1} = \{\forall k \in \{1, \dots, p\}, |\hat{\beta}_k - \beta_k| \leq \eta_k^{\gamma_1}\}$$

- De plus sous  $\Omega_{\gamma_1}$  :  $\forall k \in \{1, \dots, p\}, |\hat{\sigma}_k - \sigma_k| \leq \sqrt{2\gamma_1 \log p} \frac{\|\phi_k\|_\infty}{\sqrt{n-1}}$

$$\begin{aligned} \sup_k \eta_k^\gamma &= \|\eta^\gamma\|_\infty \leq \sqrt{2\gamma c_{\gamma,p} \log p} \frac{\sigma_k}{\sqrt{n}} \\ &\quad + (2\sqrt{\gamma c_{\gamma,p} \gamma_1} + \frac{7}{3} \gamma c_{\gamma,p}) \log p \frac{\|\phi_k\|_\infty}{n-1} \end{aligned}$$

# Estimateurs

## Contrainte de Dantzig

- Pour  $\gamma_0 > 0$ ,  $\forall k \in \{1, \dots, p\}$

$$|(G\lambda)_k - \hat{\beta}_k| \leq \eta_k^{\gamma_0} = \sqrt{2\gamma_0 c_{\gamma_0, p} \log p} \frac{\hat{\sigma}_k}{\sqrt{n-1}} + \frac{7}{3} \gamma_0 c_{\gamma_0, p} \log p \frac{\|\phi_k\|_\infty}{n-1}.$$

## Estimateurs pénalisés adaptatifs

- Dantzig :

$$\hat{\lambda}^{D, \gamma_0} = \operatorname{argmin} \|\lambda\|_{\ell_1} \text{ sous } \forall k \in \{1, \dots, p\}, |(G\lambda)_k - \hat{\beta}_k| \leq \eta_k^{\gamma_0}.$$

- Lasso :  $\hat{\lambda}^{L, \gamma_0} = \operatorname{argmin} \frac{1}{2} \left( -2\lambda^* \hat{\beta} + \lambda^* G\lambda \right) + \sum_{k=1}^p \eta_k^{\gamma_0} |\lambda_k|.$


## Variantes

- Estimateurs non adaptatifs en remplaçant  $\eta_k^{\gamma_0}$  par  $\tilde{\eta}_k^{\gamma_0}$  :


$$\tilde{\eta}_k^{\gamma_0} = \min \left( \sqrt{2\gamma_0 \log p} \frac{\|\phi_k\|_\infty}{\sqrt{n}}, \sqrt{2\gamma_0 \log p} \frac{\|f_0\|_\infty^{1/2} \|\phi_k\|_2}{\sqrt{n}} + \frac{2}{3} \gamma_0 \log p \frac{\|\phi_k\|_\infty}{n} \right)$$

- Amélioration possible avec une seconde étape de type moindre carré sur le support de  $\hat{\lambda}$  (à la Gauss-Dantzig).


# Fourier




# Boxes




# Haar




# Mix = Fourier + Boxes



# Mix2 = Fourier + Boxes + Haar





# Dantzig et Dantzig+LS





# Dantzig / Lasso $f_1/f_2$

$f_1$



$f_2$




$n = 500$


$n = 2000$

# Dantzig / Lasso $f_3/f_4$



$f_3$



$f_4$







$n = 500$





$n = 2000$

# Dantzig / Non adaptive D. $f_1/f_2$



 $f_1$  $f_2$  $n = 500$  $n = 2000$

# Dantzig / Non adaptive D. $f_3/f_4$

$f_3$







$f_4$



$n = 500$



$n = 2000$

# Dantzig / Dantzig+LS $f_1/f_2$



 $f_1$  $f_2$  $n = 500$  $n = 2000$

# Dantzig / Dantzig+LS $f_3/f_4$

$f_3$



$f_4$



$n = 500$

$n = 2000$

# Hypothèses sur le dictionnaire

## Hypothèses de structure sur le dictionnaire

- Indispensable pour obtenir des résultats de type  $\ell_0$ .
- Variante autour des bases orthonormées...

## Hypothèse locale

- Hypothèse « minimale » pour obtenir un résultat.
- Soit  $J_0$  un support, l'hypothèse locale  $HL(J_0, \kappa_{J_0}, \mu_{J_0})$  est :

$$\|f_\lambda\|_2 \geq \frac{\kappa_{J_0} \|\lambda_{J_0}\|_{\ell_1} - \mu_{J_0} (\|\lambda_{J_0^c}\|_{\ell_1} - \|\lambda_{J_0}\|_{\ell_1})_+}{\sqrt{|J_0|}}$$

est vérifiée pour tout  $\lambda$  avec  $\kappa_{J_0} > 0$  et  $\mu_{J_0} \geq 0$ .

- Pour un dictionnaire  $\mathcal{D}$  orthonormé,  $\kappa_{J_0} = 1$  and  $\mu_{J_0} = 0$  convient :

$$\|f_\lambda\|_2 = \|\lambda\|_{\ell_2} \geq \|\lambda_{J_0}\|_{\ell_2} \geq \frac{\|\lambda_{J_0}\|_{\ell_1}}{\sqrt{|J_0|}}$$

- RIP, RE et leurs variantes  $\implies HL(J_0, \kappa_{J_0}, \mu_{J_0})$  dès que  $|J_0| < c \frac{n}{\log n}$  avec  $\kappa_{J_0}$  et  $\mu_{J_0}$  ne dépendant que de la taille du support.

# Théorème Dantzig

## Théorème

- Sous  $\Omega_{\gamma_1}$ , événement de proba  $\geq 1 - 2 \left(\frac{1}{p}\right)^{\gamma_1 - 1}$ , si l'hypothèse locale  $HL(J_0, \kappa_{J_0}, \mu_{J_0})$  est satisfaite alors pour tout  $\lambda \in \mathbb{R}^p$

$$\begin{aligned} \|\hat{f}^{D, \gamma_0} - f_0\|_2^2 &\leq \|f_\lambda - f_0\|_2^2 + 2 \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{\|\lambda_{J_0^c}\|_{\ell_1}^2}{|J_0|} \\ &\quad + \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{(\|\hat{\lambda}^{D, \gamma_0}\|_{\ell_1} - \|\lambda\|_{\ell_1})_+^2}{|J_0|} \\ &\quad + 4 \left(1 + \frac{1}{\kappa_{J_0}^2}\right) |J_0| (\|\eta^{\gamma_0}\|_{\ell_\infty} + \|\eta^{\gamma_1}\|_{\ell_\infty})^2. \end{aligned}$$

## Interprétation

- Biais ( Approx. par  $f_\lambda$  + Approx. en dehors de  $J_0$  ) / Variance
- “Faisabilité” de la contrainte de Dantzig

# Théorème Dantzig

## Théorème

- Sous  $\Omega_{\gamma_1}$ , événement de proba  $\geq 1 - 2 \left(\frac{1}{p}\right)^{\gamma_1 - 1}$ , si l'hypothèse locale  $HL(J_0, \kappa_{J_0}, \mu_{J_0})$  est satisfaite alors pour tout  $\lambda \in \mathbb{R}^p$

$$\begin{aligned} \|\hat{f}^{D, \gamma_0} - f_0\|_2^2 &\leq \|f_\lambda - f_0\|_2^2 + 2 \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{\|\lambda_{J_0^c}\|_{\ell_1}^2}{|J_0|} \\ &\quad + \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{(\|\hat{\lambda}^{D, \gamma_0}\|_{\ell_1} - \|\lambda\|_{\ell_1})_+^2}{|J_0|} \\ &\quad + 4 \left(1 + \frac{1}{\kappa_{J_0}^2}\right) |J_0| (\|\eta^{\gamma_0}\|_{\ell_\infty} + \|\eta^{\gamma_1}\|_{\ell_\infty})^2. \end{aligned}$$

## Interprétation

- Biais (  $\text{Approx. par } f_\lambda$  +  $\text{Approx. en dehors de } J_0$  ) / Variance
- “Faisabilité” de la contrainte de Dantzig

# Théorème Dantzig

## Théorème

- Sous  $\Omega_{\gamma_1}$ , événement de proba  $\geq 1 - 2 \left(\frac{1}{p}\right)^{\gamma_1 - 1}$ , si l'hypothèse locale  $HL(J_0, \kappa_{J_0}, \mu_{J_0})$  est satisfaite alors pour tout  $\lambda \in \mathbb{R}^p$

$$\begin{aligned} \|\hat{f}^{D, \gamma_0} - f_0\|_2^2 &\leq \|f_\lambda - f_0\|_2^2 + 2 \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{\|\lambda_{J_0^c}\|_{\ell_1}^2}{|J_0|} \\ &\quad + \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{(\|\hat{\lambda}^{D, \gamma_0}\|_{\ell_1} - \|\lambda\|_{\ell_1})_+^2}{|J_0|} \\ &\quad + 4 \left(1 + \frac{1}{\kappa_{J_0}^2}\right) |J_0| (\|\eta^{\gamma_0}\|_{\ell_\infty} + \|\eta^{\gamma_1}\|_{\ell_\infty})^2. \end{aligned}$$

## Interprétation

- Biais (  $\text{Approx. par } f_\lambda$  +  $\text{Approx. en dehors de } J_0$  ) / Variance
- “Faisabilité” de la contrainte de Dantzig

# Théorème Dantzig

## Théorème

- Sous  $\Omega_{\gamma_1}$ , événement de proba  $\geq 1 - 2 \left(\frac{1}{p}\right)^{\gamma_1 - 1}$ , si l'hypothèse locale  $HL(J_0, \kappa_{J_0}, \mu_{J_0})$  est satisfaite alors pour tout  $\lambda \in \mathbb{R}^p$

$$\begin{aligned} \|\hat{f}^{D, \gamma_0} - f_0\|_2^2 &\leq \|f_\lambda - f_0\|_2^2 + 2 \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{\|\lambda_{J_0^c}\|_{\ell_1}^2}{|J_0|} \\ &\quad + \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{(\|\hat{\lambda}^{D, \gamma_0}\|_{\ell_1} - \|\lambda\|_{\ell_1})_+^2}{|J_0|} \\ &\quad + 4 \left(1 + \frac{1}{\kappa_{J_0}^2}\right) |J_0| (\|\eta^{\gamma_0}\|_{\ell_\infty} + \|\eta^{\gamma_1}\|_{\ell_\infty})^2. \end{aligned}$$

## Interprétation

- Biais (  $\text{Approx. par } f_\lambda$  +  $\text{Approx. en dehors de } J_0$  ) / Variance
- “Faisabilité” de la contrainte de Dantzig

# Théorème Dantzig

## Théorème

- Sous  $\Omega_{\gamma_1}$ , événement de proba  $\geq 1 - 2 \left(\frac{1}{p}\right)^{\gamma_1 - 1}$ , si l'hypothèse locale  $HL(J_0, \kappa_{J_0}, \mu_{J_0})$  est satisfaite alors pour tout  $\lambda \in \mathbb{R}^p$

$$\begin{aligned} \|\hat{f}^{D, \gamma_0} - f_0\|_2^2 &\leq \|f_\lambda - f_0\|_2^2 + 2 \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{\|\lambda_{J_0^c}\|_{\ell_1}^2}{|J_0|} \\ &\quad + \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{(\|\hat{\lambda}^{D, \gamma_0}\|_{\ell_1} - \|\lambda\|_{\ell_1})_+^2}{|J_0|} \\ &\quad + 4 \left(1 + \frac{1}{\kappa_{J_0}^2}\right) |J_0| (\|\eta^{\gamma_0}\|_{\ell_\infty} + \|\eta^{\gamma_1}\|_{\ell_\infty})^2. \end{aligned}$$

## Interprétation

- Biais ( Approx. par  $f_\lambda$  + Approx. en dehors de  $J_0$  ) / Variance
- “Faisabilité” de la contrainte de Dantzig

# Variance

## Terme de variance

• Dans le théorème :  $4 \left(1 + \frac{1}{\kappa_{J_0}^2}\right) |J_0| (\|\eta^{\gamma_0}\|_{\ell_\infty} + \|\eta^{\gamma_1}\|_{\ell_\infty})^2$

• Sous  $\Omega_{\gamma_1}$ ,

$$\begin{aligned} (\|\eta^{\gamma_0}\|_{\ell_\infty} + \|\eta^{\gamma_1}\|_{\ell_\infty})^2 &\leq 8(\gamma_0 c_{\gamma_0, p} + \gamma_1 c_{\gamma_1, p}) \log p \frac{\sup_k \sigma_k^2}{n-1} \\ &\quad + 2 \left( 2 \left( \sqrt{\gamma_0 c_{\gamma_0, p} \gamma_1} + \sqrt{c_{\gamma_1, p} \gamma_1} \right) \right. \\ &\quad \left. + \frac{7}{3} (\gamma_0 c_{\gamma_0, p} + \gamma_1 c_{\gamma_1, p}) \right)^2 \\ &\quad \times \log^2 p \frac{\sup_k \|\phi_k\|_\infty^2}{(n-1)^2}. \end{aligned}$$

• Simplification dans le théorème !

# Théorème Dantzig simplifié

## Théorème

- Sous  $\Omega_{\gamma_1}$ , événement de proba  $\geq 1 - 2 \left(\frac{1}{p}\right)^{\gamma_1 - 1}$ , si l'hypothèse locale  $HL(J_0, \kappa_{J_0}, \mu_{J_0})$  est satisfaite alors pour tout  $\lambda \in \mathbb{R}^p$

$$\begin{aligned} \|\hat{f}^{D, \gamma_0} - f_0\|_2^2 &\lesssim \|f_\lambda - f_0\|_2^2 + 2 \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{\|\lambda_{J_0^c}\|_{\ell_1}^2}{|J_0|} \\ &+ \left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{(\|\hat{\lambda}^{D, \gamma_0}\|_{\ell_1} - \|\lambda\|_{\ell_1})_+^2}{|J_0|} \\ &+ 32(\gamma_0 c_{\gamma_0, p} + \gamma_1 c_{\gamma_1, p}) \left(1 + \frac{1}{\kappa_{J_0}^2}\right) |J_0| \log p \frac{\sup_k \sigma_k^2}{n} \end{aligned}$$

## Interprétation

- Biais (  $\text{Approx. par } f_\lambda$  +  $\text{Approx. en dehors de } J_0$  ) / Variance
- “Faisabilité” de la contrainte de Dantzig

# Contrainte de Dantzig

## "Faisabilité" de la contrainte de Dantzig

- Dans le théorème :  $\left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{(\|\hat{\lambda}^{D,\gamma_0}\|_{\ell_1} - \|\lambda\|_{\ell_1})_+^2}{|J_0|}$
- Contrôle difficile : pas de lien a priori entre  $\lambda$  et  $\hat{\lambda}^{D,\gamma_0}$ ...
- Disparition si  $\|\lambda\|_{\ell_1} \geq \|\hat{\lambda}^{D,\gamma_0}\|_{\ell_1}$ .
- Disparition si  $\lambda$  satisfait la contrainte de Dantzig.

## Corollaire

- Si  $\gamma_1 \leq \gamma_0$ , sous  $\Omega_{\gamma_1}$ , événement de proba  $\geq 1 - 2\left(\frac{1}{p}\right)^{\gamma_1-1}$ , si l'hypothèse locale  $HL(J_0, \kappa_{J_0}, \mu_{J_0})$  est satisfaite et si  $f_{\lambda_0} = P_{\mathcal{D}} f_0$  alors

$$\begin{aligned} \|\hat{f}^{D,\gamma_0} - f_0\|_2^2 &\lesssim \|P_{\mathcal{D}} f_0 - f_0\|_2^2 + 2\left(1 + \frac{2\mu_{J_0}}{\kappa_{J_0}}\right)^2 \frac{\|\lambda_{0J_0^c}\|_{\ell_1}^2}{|J_0|} \\ &+ 32(\gamma_0 c_{\gamma_0,p} + \gamma_1 c_{\gamma_1,p}) \left(1 + \frac{1}{\kappa_{J_0}^2}\right) |J_0| \log p \frac{\sup_k \sigma_k^2}{n} \end{aligned}$$

# Théorème Dantzig/Lasso

## Dantzig/Lasso

- Proximité des estimateurs  $\implies$  proximité des solutions ?
- Proximité déjà prouvée dans un sens car  $\hat{f}^{L,\gamma_0}$  est faisable...
- Contrôle plus fin possible.

## Théorème (sans le terme de Dantzig)

- Sous  $\Omega_{\gamma_1}$ , événement de proba  $\geq 1 - 2 \left(\frac{1}{p}\right)^{\gamma_1 - 1}$ , si l'hypothèse locale  $HL(J_0, \kappa_{J_0}, \mu_{J_0})$  est satisfaite alors

$$\begin{aligned} & \left| \|\hat{f}^{D,\gamma_0} - f_0\|_2^2 - \|\hat{f}^{L,\gamma_0} - f_0\|_2^2 \right| \\ & \leq 2 \left( 1 + \frac{2\mu_{J_0}}{\kappa_{J_0}} \right)^2 \frac{\|\hat{\lambda}_{J_0^c}^{L,\gamma_0}\|_{\ell_1}^2}{|J_0|} \\ & + 32(\gamma_0 c_{\gamma_0,p} + \gamma_1 c_{\gamma_1,p}) \left( 1 + \frac{1}{\kappa_{J_0}^2} \right) |J_0| \log p \frac{\sup_k \sigma_k^2}{n} \end{aligned}$$

# Pénalité minimale


## Choix de $\gamma_0$

- Comment choisir  $\gamma_0$  ?
- Paramètre de pénalisation :
  - $\gamma_0$  grand : surlissage (grand biais),
  - $\gamma_0$  petit : instabilité (grande variance).
- Inégalité oracle pour tout  $\gamma_0$  :
  - $\gamma_0$  grand : surpénalisation de la variance dans l'inégalité oracle,
  - $\gamma_0$  petit : présence du terme Dantzig en  $(\|\lambda^{S, \gamma_0}\|_{\ell_1} - \|\lambda\|_{\ell_1})_+$  difficile à contrôler.

## Pénalité minimale

- Bon calibrage :  $\gamma_0 = 1$  !
- Résultat théorique :
  - Si  $\gamma_0 > 1$  : avec proba  $\geq 1 - 2 \left(\frac{1}{\rho}\right)^{\gamma_0 - 1}$ , inégalité oracle sans le terme Dantzig pour tout  $\lambda$  tel que  $f_\lambda = P_{\mathcal{D}} f_0$ .
  - Si  $\gamma_0 < 1$  : théorème montrant que l'estimateur est mauvais (sur un cas simple d'estimation de la densité uniforme sur  $[0, 1]$  dans la base de Haar).

# Pénalité minimale



# Conclusion

## Estimation de densité par Dantzig adaptatif

- Nouvelle méthode d'estimation de densité par pénalisation  $\ell_1$  adaptative.
- Utilisation d'inégalités de concentration fine pour obtenir cette pénalisation adaptative.
- Inégalité oracle en probabilité sur l'estimateur.
- Calibration de la pénalité : pénalité minimale.
- Hypothèses assez faibles sur la structure du dictionnaire.
- Lien théorique avec le Lasso adaptatif.

## Perspectives

- Performance de la méthode en deux étapes.
- Passage à des résultats en espérance.
- Relaxation des hypothèses sur la structure par passage à des résultats en proba sur les signaux (modélisation probabiliste des signaux).