

Sélection de modèles et sélection d'estimateurs pour l'Apprentissage statistique

Sylvain Arlot

¹CNRS

²École Normale Supérieure (Paris), LIENS, Équipe SIERRA

Cours Peccot, Collège de France, 24/01/2011

- ① Lundi 10 : Apprentissage statistique et sélection d'estimateurs
- ② Lundi 17 : Calibration de pénalités et pénalités minimales
- ③ **Aujourd'hui : Rééchantillonnage et pénalisation**
- ④ Lundi 31, 15h30–17h30 : Validation croisée et pénalités reliées

Plan du cours

- 1 Régressogrammes en régression hétéroscédastique
- 2 Nécessité d'estimer la forme de la pénalité
- 3 Rééchantillonnage
- 4 Garanties théoriques pour les régressogrammes
- 5 Estimation de densité par moindres carrés
- 6 Conclusion

Plan

- 1 Régressogrammes en régression hétéroscédastique
- 2 Nécessité d'estimer la forme de la pénalité
- 3 Rééchantillonnage
- 4 Garanties théoriques pour les régressogrammes
- 5 Estimation de densité par moindres carrés
- 6 Conclusion

Cadre de la régression hétéroscédastique

- Plan d'expérience **aléatoire** : $(X_1, Y_1), \dots, (X_n, Y_n)$ **i.i.d.**

$$Y_i = \eta(X_i) + \varepsilon_i$$

$$\mathbb{E}[\varepsilon_i | X_i] = 0 \quad \text{et} \quad \mathbb{E}[\varepsilon_i^2 | X_i] = \sigma^2(X_i)$$

Cadre de la régression hétéroscédastique

- Plan d'expérience aléatoire : $(X_1, Y_1), \dots, (X_n, Y_n)$ i.i.d.

$$Y_i = \eta(X_i) + \varepsilon_i$$

$$\mathbb{E}[\varepsilon_i | X_i] = 0 \quad \text{et} \quad \mathbb{E}[\varepsilon_i^2 | X_i] = \sigma^2(X_i)$$

- Perte quadratique :

$$P\gamma(t) = \mathbb{E}_{(X,Y) \sim P} [\gamma(t; (X, Y))] = \mathbb{E}_{(X,Y) \sim P} [(t(X) - Y)^2]$$

- Perte relative : $\eta = s^*$ et

$$\ell(s^*, t) = P\gamma(t) - P\gamma(s^*) = \mathbb{E}_{(X,Y) \sim P} [(s^*(X) - t(X))^2]$$

Régressogrammes

Pour toute partition finie m de \mathcal{X}

$$S_m := \left\{ \sum_{\lambda \in m} \alpha_\lambda \mathbf{1}_\lambda \text{ t.q. } \alpha \in \mathbb{R}^m \right\}$$

⇒ estimateur des moindres carrés sur S_m (régressogramme) :

$$\hat{s}_m \in \arg \min_{t \in S_m} \{ P_n \gamma(t) \} = \arg \min_{t \in S_m} \left\{ \frac{1}{n} \sum_{i=1}^n (Y_i - t(X_i))^2 \right\}$$

Régressogrammes

Pour toute partition finie m de \mathcal{X}

$$S_m := \left\{ \sum_{\lambda \in m} \alpha_\lambda \mathbb{1}_\lambda \text{ t.q. } \alpha \in \mathbb{R}^m \right\}$$

⇒ estimateur des moindres carrés sur S_m (régressogramme) :

$$\hat{s}_m \in \arg \min_{t \in S_m} \{ P_n \gamma(t) \} = \arg \min_{t \in S_m} \left\{ \frac{1}{n} \sum_{i=1}^n (Y_i - t(X_i))^2 \right\}$$

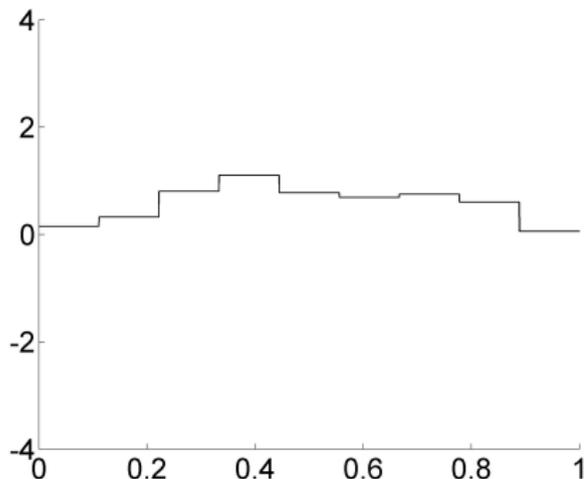
Si pour tout $\lambda \in m$

$$\hat{p}_\lambda = \hat{p}_\lambda(D_n) = \frac{1}{n} \text{Card} \{ i \text{ t.q. } X_i \in \lambda \} > 0$$

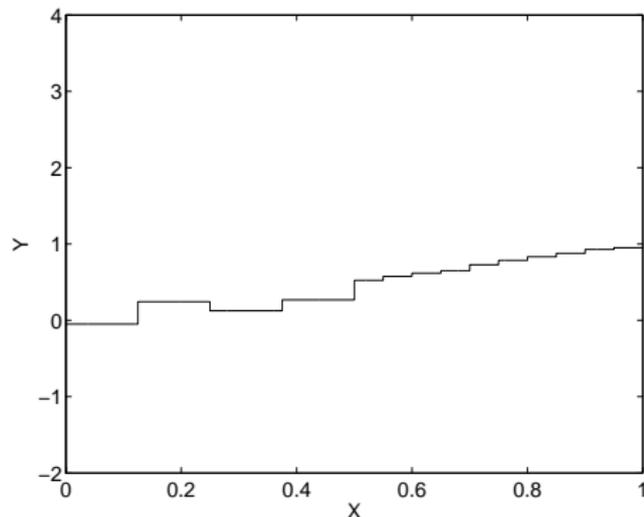
$$\hat{s}_m = \sum_{\lambda \in m} \hat{\beta}_\lambda \mathbb{1}_\lambda \quad \hat{\beta}_\lambda := \frac{1}{n \hat{p}_\lambda} \sum_{i \text{ t.q. } X_i \in \lambda} Y_i$$

Régressogrammes : exemples ($\mathcal{X} = [0, 1]$)

$\mathcal{M}_n^{(\text{reg})}$ (partitions régulières)



$\mathcal{M}_n^{(\text{reg}, 1/2)}$ (partitions régulières sur $[0, 1/2]$ et sur $[1/2, 1]$)



Régressogrammes : biais, pénalité idéale

Régressogrammes : biais, pénalité idéale

$$s_m^* = \sum_{\lambda \in m} \beta_\lambda \mathbb{1}_\lambda \quad \beta_\lambda := \mathbb{E}_{(X,Y) \sim P} [Y \mid X \in \lambda]$$

$$\ell(s^*, s_m^*) = \sum_{\lambda \in m} p_\lambda \left(\sigma_\lambda^{(d)} \right)^2 \quad \left(\sigma_\lambda^{(d)} \right)^2 := \mathbb{E} \left[(\beta_\lambda - s^*(X))^2 \mid X \in \lambda \right]$$

Régressogrammes : biais, pénalité idéale

$$s_m^* = \sum_{\lambda \in m} \beta_\lambda \mathbb{1}_\lambda \quad \beta_\lambda := \mathbb{E}_{(X,Y) \sim P} [Y \mid X \in \lambda]$$

$$\ell(s^*, s_m^*) = \sum_{\lambda \in m} p_\lambda \left(\sigma_\lambda^{(d)} \right)^2 \quad \left(\sigma_\lambda^{(d)} \right)^2 := \mathbb{E} \left[(\beta_\lambda - s^*(X))^2 \mid X \in \lambda \right]$$

$$\text{pen}_{\text{id}}(m) = p_1(m) + p_2(m) - \delta(m)$$

$$p_1(m) = P(\gamma(\widehat{s}_m) - \gamma(s_m^*)) = \sum_{\lambda \in m} p_\lambda \left(\widehat{\beta}_\lambda - \beta_\lambda \right)^2$$

$$p_2(m) = P_n(\gamma(s_m^*) - \gamma(\widehat{s}_m)) = \sum_{\lambda \in m} \widehat{p}_\lambda \left(\widehat{\beta}_\lambda - \beta_\lambda \right)^2$$

$$\delta(m) = (P_n - P)\gamma(s_m^*)$$

Régressogrammes : espérances conditionnelles

$$\mathcal{P}_m := (\mathbb{1}_{X_i \in \lambda})_{1 \leq i \leq n, \lambda \in m}$$

$$\mathbb{E}[p_1(m) \mid \mathcal{P}_m] = \frac{1}{n} \sum_{\lambda \in m} \frac{p_\lambda}{\hat{p}_\lambda} \sigma_\lambda^2$$

$$\mathbb{E}[p_2(m) \mid \mathcal{P}_m] = \frac{1}{n} \sum_{\lambda \in m} \sigma_\lambda^2$$

$$\sigma_\lambda^2 := \mathbb{E}_{(X,Y) \sim P} \left[(Y - \beta_\lambda)^2 \mid X \in \lambda \right] = \left(\sigma_\lambda^{(d)} \right)^2 + \left(\sigma_\lambda^{(a)} \right)^2$$

$$\left(\sigma_\lambda^{(a)} \right)^2 := \mathbb{E}_{(X,Y) \sim P} \left[(\sigma(X))^2 \mid X \in \lambda \right]$$

Régressogrammes : espérances

$$\mathbb{E} [p_1(m)] = \frac{1}{n} \sum_{\lambda \in m} \sigma_\lambda^2 (1 + \delta_{n,p_\lambda})$$

$$\mathbb{E} [p_2(m)] = \frac{1}{n} \sum_{\lambda \in m} \sigma_\lambda^2$$

$$\delta_{n,p_\lambda} := \mathbb{E} \left[\frac{p_\lambda}{\hat{p}_\lambda} \mid \hat{p}_\lambda > 0 \right] - 1$$

$$-\exp(-np) \leq \delta_{n,p} \leq \min \left\{ 1 + \frac{\kappa_1}{(np)^{1/4}}, \kappa_2 \right\}$$

Régressogrammes : risque, espérance de la pénalité idéale

$$\mathbb{E}[\ell(s^*, \hat{s}_m)] = \sum_{\lambda \in m} p_\lambda \left(\sigma_\lambda^{(d)} \right)^2 + \frac{1}{n} \sum_{\lambda \in m} (1 + \delta_{n,p_\lambda}) \sigma_\lambda^2$$

$$\mathbb{E}[\text{pen}_{\text{id}}(m)] = \frac{1}{n} \sum_{\lambda \in m} (2 + \delta_{n,p_\lambda}) \sigma_\lambda^2$$

Plan

- 1 Régressogrammes en régression hétéroscédastique
- 2 Nécessité d'estimer la forme de la pénalité
- 3 Rééchantillonnage
- 4 Garanties théoriques pour les régressogrammes
- 5 Estimation de densité par moindres carrés
- 6 Conclusion

Limitations de $\text{pen} = \text{pen}(D_m)$

$$Y = s^*(X) + \varepsilon \quad \text{avec} \quad X \sim \mathcal{U}([0, 1])$$

$$\mathbb{E}[\varepsilon^2 \mid X] = \sigma(X) \quad \text{et} \quad \int_0^{1/2} (\sigma(x))^2 dx \neq \int_{1/2}^1 (\sigma(x))^2 dx$$

$$m \in \mathcal{M}_n^{(\text{reg}, 1/2)} : \begin{array}{l} D_{m,1} \text{ morceaux sur } [0, \frac{1}{2}] \\ D_{m,2} \text{ morceaux sur } [\frac{1}{2}, 1] \end{array}$$

Limitations de $\text{pen} = \text{pen}(D_m)$

$$Y = s^*(X) + \varepsilon \quad \text{avec} \quad X \sim \mathcal{U}([0, 1])$$

$$\mathbb{E}[\varepsilon^2 \mid X] = \sigma(X) \quad \text{et} \quad \int_0^{1/2} (\sigma(x))^2 dx \neq \int_{1/2}^1 (\sigma(x))^2 dx$$

$$m \in \mathcal{M}_n^{(\text{reg}, 1/2)} : D_{m,1} \text{ morceaux sur } [0, \frac{1}{2}]$$

$$D_{m,2} \text{ morceaux sur } [\frac{1}{2}, 1]$$

$$\mathbb{E}[\text{pen}_{\text{id}}(m)] \approx \frac{4}{n} \left[D_{m,1} \int_0^{1/2} (\sigma(x))^2 dx + D_{m,2} \int_{1/2}^1 (\sigma(x))^2 dx \right]$$

Limitations de $\text{pen} = \text{pen}(D_m)$: un exemple

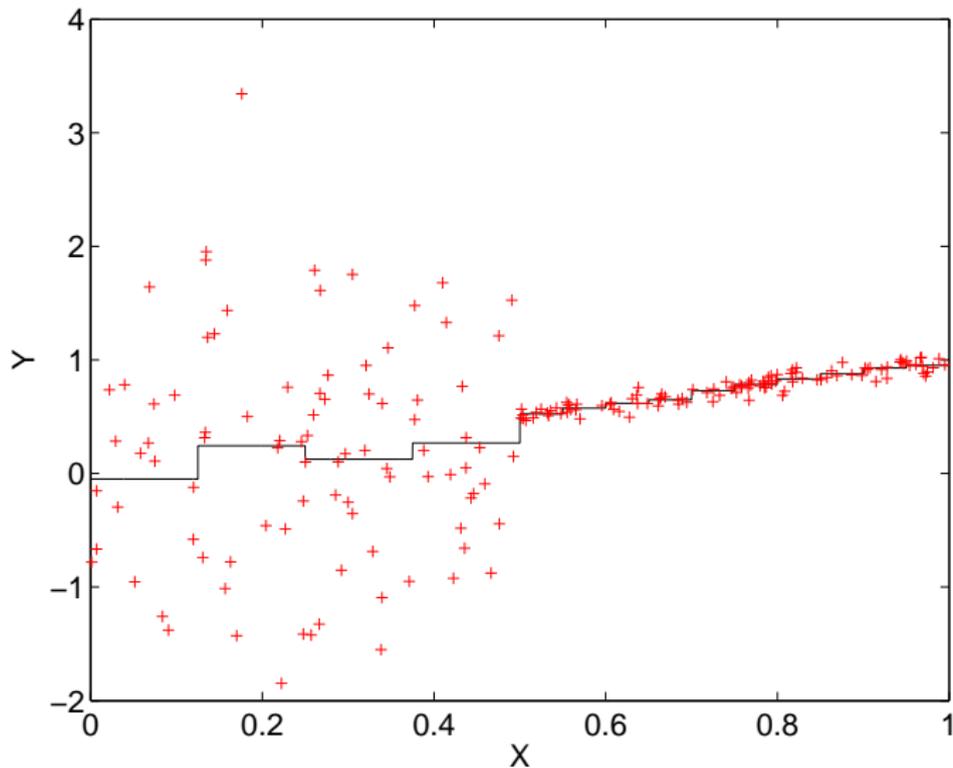
$$Y = s^*(X) + \varepsilon \quad \text{avec} \quad X \sim \mathcal{U}([0, 1])$$

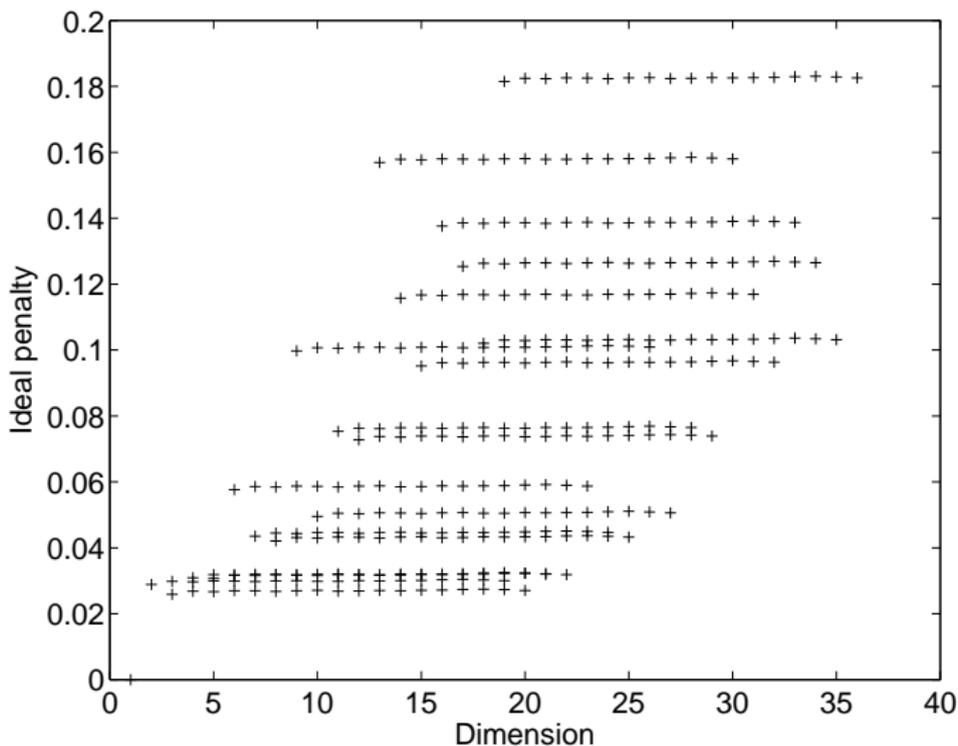
$$\mathcal{L}(\varepsilon | X) = \mathcal{N}(0, \sigma(X)^2)$$

$$s^*(X) = X \quad \sigma(X) = \mathbb{1}_{X \leq \frac{1}{2}} + \frac{1}{20} \mathbb{1}_{X > \frac{1}{2}}$$

$$\mathbb{E}[\text{pen}_{\text{id}}(m)] \approx \frac{2}{n} \left[D_{m,1} + \frac{D_{m,2}}{400} \right]$$

Exemple : données et oracle ($n = 200$)



Exemple : $\text{pen}_{\text{id}}(m)$ en fonction de D_m 

Pénalités fonction de la dimension

Lemme

Pour tout $D \in \mathcal{D}_n = \{D_m \text{ t.q. } m \in \mathcal{M}_n\}$

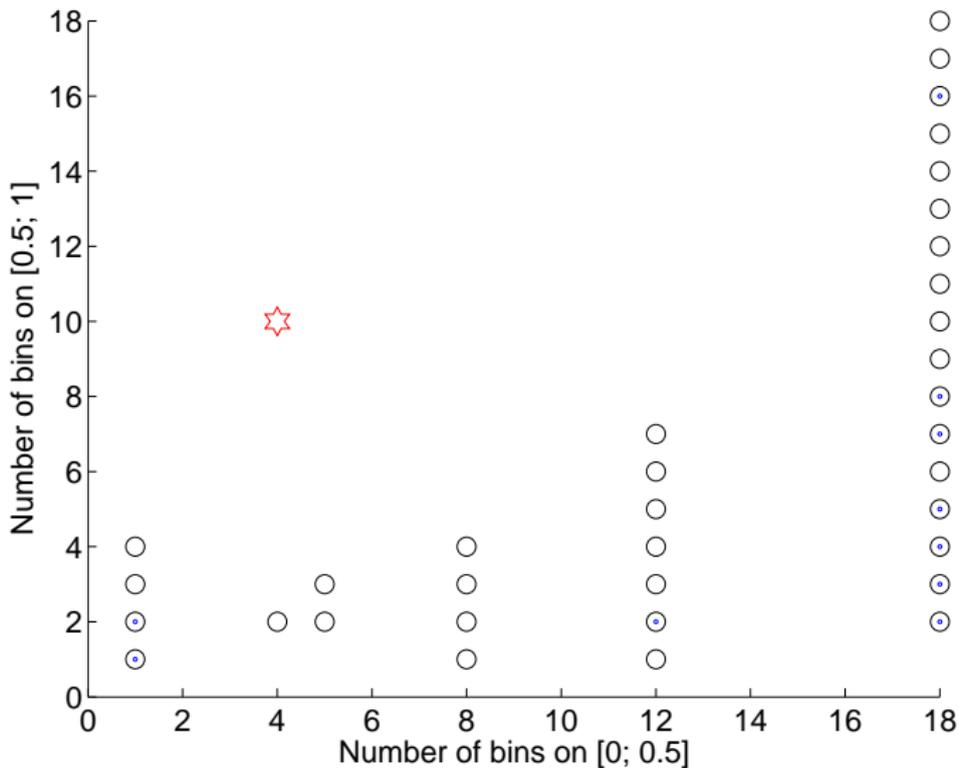
$$\mathcal{M}_{\dim}(D) := \operatorname{argmin}_{m \in \mathcal{M}_n \text{ t.q. } D_m = D} \{P_n \gamma(\hat{s}_m)\}$$

$$\mathcal{M}_{\dim} := \bigcup_{D \in \mathcal{D}_n} \mathcal{M}_{\dim}(D)$$

Alors, $\forall F : \mathcal{M}_n \mapsto \mathbb{R} \forall (X_i, Y_i)_{1 \leq i \leq n}$

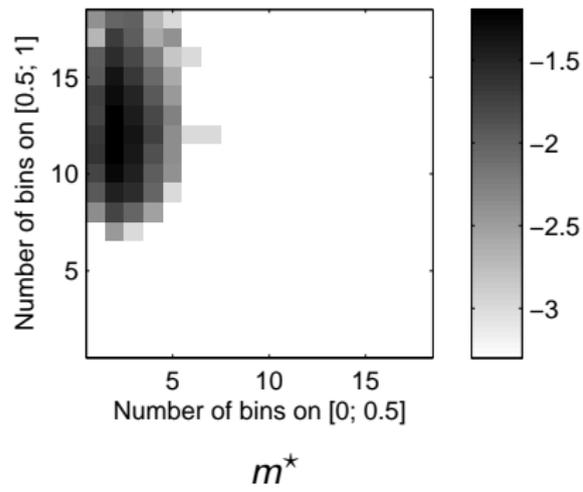
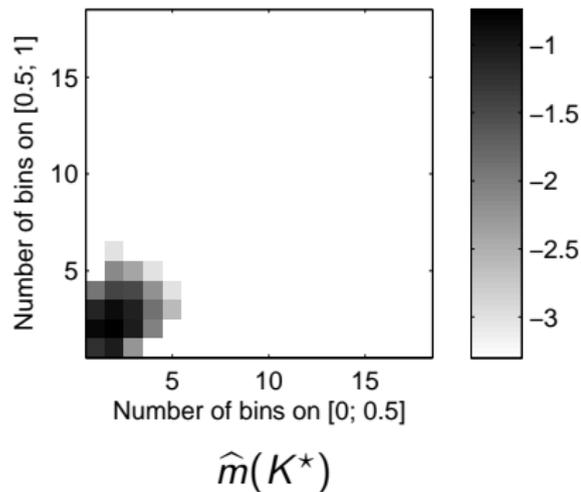
$$\operatorname{argmin}_{m \in \mathcal{M}_n} \{P_n \gamma(\hat{s}_m) + F(D_m)\} \subset \mathcal{M}_{\dim}$$

Modèles sélectionnables avec $\text{pen}(D_m)$



Limitations de $\text{pen} = \text{pen}(D_m) : \hat{m}(D^*) \neq m^*$

Densités de $(D_{\hat{m}(D^*),1}, D_{\hat{m}(D^*),2})$ et $(D_{m^*,1}, D_{m^*,2})$ sur $N = 1000$ échantillons



Vers une preuve : concentration de $p_{n,i}$

Hypothèses : $\|Y\|_\infty \leq A < \infty$ et $\sigma(\cdot) \geq \sigma_{\min} > 0$

- Concentration de p_1 et p_2 :
si $\min_{\lambda \in m} \{np_\lambda\} \geq \diamond \ln(n)$, avec probabilité au moins $1 - Ln^{-\gamma}$, pour $i = 1, 2$

$$|p_i(m) - \mathbb{E}[p_i(m)]| \leq \frac{L_{A, \sigma_{\min}, \gamma} (\ln(n))^2}{\sqrt{D_m}} \mathbb{E}[p_2(m)]$$

- Inégalité de Bernstein : avec probabilité $1 - 2e^{-x}$,

$$\forall \theta \in]0, 1] \quad |(P_n - P)(\gamma(s_m^*) - \gamma(s^*))| \leq \theta \ell(s^*, s_m^*) + \frac{6A^2 x}{\theta n}$$

Heuristique de preuve : espérances

$$\mathbb{E}[p_1(m)] \approx \mathbb{E}[p_2(m)] \approx \frac{\beta_1 D_{m,1}}{n} + \frac{\beta_2 D_{m,1}}{n}$$

$$\beta_1 = 2 \int_0^{1/2} \sigma^2 \quad \beta_2 = 2 \int_{1/2}^1 \sigma^2$$

$$\ell(s^*, s_m^*) \approx \frac{\alpha_1}{D_{m,1}^2} + \frac{\alpha_2}{D_{m,2}^2}$$

$$\alpha_1 = \frac{1}{48} \int_0^{1/2} (s^{*'})^2 \quad \alpha_2 = \frac{1}{48} \int_{1/2}^1 (s^{*'})^2$$

Heuristique de preuve : espérances

$$\beta_1 = 2 \int_0^{1/2} \sigma^2 \quad \beta_2 = 2 \int_{1/2}^1 \sigma^2$$

$$\alpha_1 = \frac{1}{48} \int_0^{1/2} (s^{*'})^2 \quad \alpha_2 = \frac{1}{48} \int_{1/2}^1 (s^{*'})^2$$

$$P_n \gamma(\hat{s}_m) - P \gamma(s^*) \approx \frac{\alpha_1}{D_{m,1}^2} + \frac{\alpha_2}{D_{m,2}^2} - \frac{\beta_1 D_{m,1}}{n} - \frac{\beta_2 D_{m,1}}{n}$$

$$\ell(s^*, \hat{s}_m) \approx \frac{\alpha_1}{D_{m,1}^2} + \frac{\alpha_2}{D_{m,2}^2} + \frac{\beta_1 D_{m,1}}{n} + \frac{\beta_2 D_{m,1}}{n}$$

Heuristique de preuve : espérances

$$\beta_1 = 2 \int_0^{1/2} \sigma^2 > \beta_2 = 2 \int_{1/2}^1 \sigma^2$$

$$\alpha_1 = \frac{1}{48} \int_0^{1/2} (s^{*'})^2 \quad \alpha_2 = \frac{1}{48} \int_{1/2}^1 (s^{*'})^2$$

$$P_n \gamma(\hat{s}_m) - P \gamma(s^*) \approx \frac{\alpha_1}{D_{m,1}^2} + \frac{\alpha_2}{D_{m,2}^2} - \frac{\beta_1 D_{m,1}}{n} - \frac{\beta_2 D_{m,1}}{n}$$

$$\ell(s^*, \hat{s}_m) \approx \frac{\alpha_1}{D_{m,1}^2} + \frac{\alpha_2}{D_{m,2}^2} + \frac{\beta_1 D_{m,1}}{n} + \frac{\beta_2 D_{m,1}}{n}$$

$$m^* \approx \left(\left(\frac{2\alpha_1 n}{\beta_1} \right)^{1/3}, \left(\frac{2\alpha_2 n}{\beta_2} \right)^{1/3} \right)$$

Limitations de $\text{pen} = \text{pen}(D_m)$: théorie

$$Y = s^*(X) + \varepsilon \quad \text{avec} \quad X \sim \mathcal{U}([0, 1]) \quad , \quad \mathbb{E}[\varepsilon^2 \mid X] = \sigma(X)$$

$$\text{et} \quad \sigma_a^2 = \int_0^{1/2} (\sigma(x))^2 dx \neq \int_{1/2}^1 (\sigma(x))^2 dx = \sigma_b^2$$

Théorème (A. 2008)

Si $\mathcal{M} = \mathcal{M}_n^{(\text{reg}, 1/2)}$, sous des hypothèses “raisonnables” sur $(s^*, \varepsilon, \sigma)$, il existe $\eta(\sigma_a^2/\sigma_b^2) > 0$ telle qu’avec probabilité au moins $1 - C(\|\varepsilon\|_\infty, \sigma_a^2, \sigma_b^2, \|s^{*'}\|_\infty, \|s^{*''}\|_\infty)n^{-2}$

$$\forall F \quad , \quad \forall \hat{m}_F \in \arg \min_{m \in \mathcal{M}_n} \{P_n \gamma(\hat{s}_m) + F(D_m)\} \quad ,$$

$$\ell(s^*, \hat{s}_{\hat{m}_F}) \geq \left(1 + \eta\left(\frac{\sigma_a^2}{\sigma_b^2}\right)\right) \inf_{m \in \mathcal{M}_n} \{\ell(s^*, \hat{s}_m)\}$$

Quelles motivations pour estimer la forme de la pénalité ?

- $\text{pen}(D) = F(D) \Rightarrow$ perte d'un **facteur $(1 + \eta) > 1$**

Quelles motivations pour estimer la forme de la pénalité ?

- $\text{pen}(D) = F(D) \Rightarrow$ perte d'un **facteur $(1 + \eta) > 1$**
- $\text{pen}(m) = 2\mathbb{E} [\sigma(X)^2] D_m/n \Rightarrow$ **explosion du risque** possible

Quelles motivations pour estimer la forme de la pénalité ?

- $\text{pen}(D) = F(D) \Rightarrow$ perte d'un **facteur** $(1 + \eta) > 1$
- $\text{pen}(m) = 2\mathbb{E} [\sigma(X)^2] D_m/n \Rightarrow$ **explosion du risque** possible
- $\text{pen}(m) = 2 \|\sigma\|_\infty^2 D_m/n \Rightarrow$ inégalité-oracle avec **constante**
 $\mathcal{O}(\max \sigma^2 / \min \sigma^2)$

Quelles motivations pour estimer la forme de la pénalité ?

- $\text{pen}(D) = F(D) \Rightarrow$ perte d'un **facteur $(1 + \eta) > 1$**
 - $\text{pen}(m) = 2\mathbb{E} [\sigma(X)^2] D_m/n \Rightarrow$ **explosion du risque** possible
 - $\text{pen}(m) = 2 \|\sigma\|_{\infty}^2 D_m/n \Rightarrow$ inégalité-oracle avec **constante $\mathcal{O}(\max \sigma^2 / \min \sigma^2)$**
- \Rightarrow nécessaire d'estimer $\mathbb{E}[\text{pen}_{\text{id}}(m)]$ pour avoir un oracle avec **constante $(1 + o(1))$** et éviter le risque de sur-apprentissage

Plan

- 1 Régressogrammes en régression hétéroscédastique
- 2 Nécessité d'estimer la forme de la pénalité
- 3 Rééchantillonnage**
- 4 Garanties théoriques pour les régressogrammes
- 5 Estimation de densité par moindres carrés
- 6 Conclusion

Heuristique de rééchantillonnage (bootstrap, Efron 1979)

Monde réel : $P \xrightarrow{\text{échantillonnage}} P_n \Longrightarrow \hat{s}_m$

$$\text{pen}_{\text{id}}(m) = (P - P_n)\gamma(\hat{s}_m) = F(P, P_n)$$

Heuristique de rééchantillonnage (bootstrap, Efron 1979)

Monde réel : $P \xrightarrow{\text{échantillonnage}} P_n \Longrightarrow \hat{s}_m$



Monde bootstrap : P_n

$$\text{pen}_{\text{id}}(m) = (P - P_n)\gamma(\hat{s}_m) = F(P, P_n)$$

Heuristique de rééchantillonnage (bootstrap, Efron 1979)

Monde réel :

$$P \xrightarrow{\text{échantillonnage}} P_n \xRightarrow{\quad\quad\quad} \widehat{S}_m$$



Monde bootstrap :

$$P_n \xrightarrow{\text{rééchantillonnage}} P_n^W \xRightarrow{\quad\quad\quad} \widehat{S}_m^W$$

$$(P - P_n)\gamma(\widehat{S}_m) = F(P, P_n) \rightsquigarrow F(P_n, P_n^W) = (P_n - P_n^W)\gamma(\widehat{S}_m^W)$$

Rééchantillonnage à poids échangeables

$$P_n^W := \frac{1}{n} \sum_{i=1}^n W_i \delta_{\xi_i}$$

- **Bootstrap** :

$$W \sim \mathcal{M} \left(n; \frac{1}{n}, \dots, \frac{1}{n} \right)$$

Rééchantillonnage à poids échangeables

$$P_n^W := \frac{1}{n} \sum_{i=1}^n W_i \delta_{\xi_i}$$

- Efron(m) ou Bootstrap “ m out of n ” :

$$\frac{m}{n} W \sim \mathcal{M} \left(m; \frac{1}{n}, \dots, \frac{1}{n} \right)$$

Rééchantillonnage à poids échangeables

$$P_n^W := \frac{1}{n} \sum_{i=1}^n W_i \delta_{\xi_i} \quad \text{ou} \quad \frac{1}{\sum_k W_k} \sum_{i=1}^n W_i \delta_{\xi_i} = \frac{1}{n} \sum_{i=1}^n \frac{W_i}{\overline{W}} \delta_{\xi_i}$$

- **Efron**(m) ou Bootstrap “ m out of n ” :

$$\frac{m}{n} W \sim \mathcal{M} \left(m; \frac{1}{n}, \dots, \frac{1}{n} \right)$$

- Sous-échantillonnage :
 - **Random-hold out**(q) ou validation aléatoire, $q \in \{1, \dots, n-1\}$:

$$W_i = \frac{n}{q} \mathbb{1}_{i \in I} \quad \text{avec} \quad I \sim \mathcal{U}(\mathfrak{P}_q(\{1, \dots, n\}))$$

- **Rademacher**(p) ou Bernoulli :

$$pW_1, \dots, pW_n \text{ i.i.d. } \sim \mathcal{B}(p)$$

Justification théorique asymptotique

Théorème (van der Vaart & Wellner, 1996)

Soit $(W_{n,1}, \dots, W_{n,n}) \in \mathbb{R}^n$ un vecteur aléatoire positif, échangeable, indépendant de $\xi_{1\dots n}$, **borné** et tel que

$$n^{-1} \sum_{i=1}^n (W_{n,i} - \overline{W}_n)^2 \xrightarrow{(P)} c^2 > 0 .$$

Alors, lorsque n tend vers l'infini,

$$\sup_{h \in BL_1} \left| \mathbb{E}_W \left[h \left(\sqrt{n} \left(P_n^W - \overline{W}_n P_n \right) \right) \right] - \mathbb{E} [h(c\mathbb{G})] \right| \xrightarrow{(P)} 0$$

où \mathbb{G} est le processus Gaussien **limite de $\sqrt{n}(P_n - P)$** , de moyenne nulle et de fonction de covariance $\text{cov}(f, g) = P(fg) - P(f)P(g)$.

Utilisations classiques du rééchantillonnage

- estimation de la **variance**, du **risque quadratique**
- estimation et/ou **correction du biais**
- **intervalles de confiance**, p -valeurs
- estimation de l'**erreur de prédiction**, sélection de modèles
- **stabilisation** (bagging, forêts aléatoires)
- ...

Estimateur de la variance par rééchantillonnage

Cadre :

$$\xi_1, \dots, \xi_n \text{ i.i.d. } \sim P \quad \mathbb{E}[\xi_i] = \mu \quad \mathbb{E}[(\xi_i - \mu)^2] = \sigma^2$$

$$\begin{aligned} \sigma^2 &= n\mathbb{E} \left[\left(\frac{1}{n} \sum_{i=1}^n \xi_i - \mu \right)^2 \right] = n\mathbb{E} \left[(\mathbb{E}_{\xi \sim P_n} \xi - \mathbb{E}_{\xi \sim P} \xi)^2 \right] \\ &= n\mathbb{E} [F(P, P_n)] \end{aligned}$$

⇒ estimateur par rééchantillonnage

$$\widehat{\sigma}_W^2 = n\mathbb{E}_W [F(P_n, P_n^W)]$$

Estimateur de la variance par rééchantillonnage

$$\widehat{\sigma}_W^2 = n \mathbb{E}_W \left[F(P_n, P_n^W) \right]$$

$$\widehat{\sigma}_W^2 = \frac{R_V^{(W)}}{n} \left[\sum_{i=1}^n (\xi_i - \mu)^2 - \frac{1}{n-1} \sum_{i \neq j} (\xi_i - \mu) (\xi_j - \mu) \right]$$

$$R_V^{(W)} := \mathbb{E}_W \left[\left(\frac{nW_i}{\sum_{k=1}^n W_k} - 1 \right)^2 \right]$$

Comparaison avec l'estimateur classique

Estimateur classique de la variance :

$$\widehat{\sigma^2} = \frac{1}{n-1} \sum_{i=1}^n \left(\xi_i - \frac{1}{n} \sum_{k=1}^n \xi_k \right)^2$$

Comparaison avec l'estimateur classique

Estimateur classique de la variance :

$$\widehat{\sigma^2} = \frac{1}{n-1} \sum_{i=1}^n \left(\xi_i - \frac{1}{n} \sum_{k=1}^n \xi_k \right)^2$$

$$\widehat{\sigma_W^2} = R_V^{(W)} \widehat{\sigma^2}$$

$$\Rightarrow \mathbb{E} \left[\widehat{\sigma_W^2} \right] = R_V^{(W)} \sigma^2$$

Rééchantillonnage et structure

- Propriétés de $F(P, P_n) = (\mathbb{E}_{\xi \sim P_n} \xi - \mathbb{E}_{\xi \sim P} \xi)^2$:
 - échangeabilité
 - invariance par translation
 - homogénéité
 - polynôme en les ξ_i et en $\mathbb{E}_{\xi \sim P} \xi$

$\Rightarrow \mathbb{E}_W[F(P_n, P_n^W)]$ possède les mêmes propriétés

Rééchantillonnage et structure

- Propriétés de $F(P, P_n) = (\mathbb{E}_{\xi \sim P_n} \xi - \mathbb{E}_{\xi \sim P} \xi)^2$:
 - échangeabilité
 - invariance par translation
 - homogénéité
 - polynôme en les ξ_i et en $\mathbb{E}_{\xi \sim P} \xi$

$\Rightarrow \mathbb{E}_W[F(P_n, P_n^W)]$ possède les mêmes propriétés

$$\Rightarrow \mathbb{E}_W \left[F(P_n, P_n^W) \right] \propto \widehat{\sigma}^2$$

Rééchantillonnage et concentration

Sur-concentration de l'estimateur par rééchantillonnage :

$$\text{var} \left(n \left(\frac{1}{n} \sum_{i=1}^n \xi_i - \mu \right)^2 \right) = 2\sigma^4 + \frac{\mathbb{E} \left[(\xi_1 - \mu)^4 \right] - 3\sigma^4}{n}$$
$$\text{var} \left(\frac{1}{R_V^{(W)}} \widehat{\sigma_W^2} \right) = \frac{1}{n} \left(\mathbb{E} \left[(\xi_1 - \mu)^4 \right] - \sigma^4 \right) + \frac{2}{n(n-1)} \sigma^4$$

Calcul de la constante multiplicative

$$R_V^{(W)} := \mathbb{E}_W \left[\left(\frac{nW_i}{\sum_{k=1}^n W_k} - 1 \right)^2 \right]$$

Calcul de la constante multiplicative

$$R_V^{(W)} := \mathbb{E}_W \left[\left(\frac{nW_i}{\sum_{k=1}^n W_k} - 1 \right)^2 \right]$$

Efron(m) :

$$R_V^{(W)} = \frac{n-1}{m}$$

Rademacher(p) :

$$R_V^{(W)} = \frac{1 + \delta_{n,p}}{p} - 1 \approx \frac{1}{p} - 1$$

Random hold-out(q) :

$$R_V^{(W)} = \frac{n}{q} - 1$$

Leave-one-out = Rho($n-1$) :

$$R_V^{(W)} = \frac{1}{n-1}$$

Estimation par rééchantillonnage de $\text{pen}_{\text{id}}(m)$

- Pénalité idéale :

$$(P - P_n)(\gamma(\hat{s}_m)) = F(P, P_n)$$

- Estimateur de $\mathbb{E}[F(P, P_n)]$ par rééchantillonnage :

$$\text{pen}(m) = C_W \mathbb{E} \left[(P_n - P_n^W)(\gamma(\hat{s}_m^W)) \mid (X_i, Y_i)_{1 \leq i \leq n} \right]$$

- bootstrap (Efron, 1983 ; Shibata, 1997), bootstrap “ m out of n ” pour l’identification (Shao, 1996), poids échangeables généraux (A. 2009)
- **Constante C_W** : pourquoi ? comment l’estimer ?

Pénalités de Rademacher

- Pénalités globales :

$$\text{pen}_{\text{id}}(m) \leq \text{pen}_{\text{id}}^{\text{glo}}(m) = \sup_{t \in S_m} (P - P_n)\gamma(t)$$

Pénalités de Rademacher

- Pénalités globales :

$$\text{pen}_{\text{id}}(m) \leq \text{pen}_{\text{id}}^{\text{glo}}(m) = \sup_{t \in S_m} (P - P_n)\gamma(t)$$

- **Pénalités de Rademacher globales** en classification (Koltchinskii, Panchenko 2001 ; Bartlett, Boucheron, Lugosi 2002), poids échangeables (Fromont 2004)

$$\mathbb{E} \left[\sup_{t \in S_m} \left\{ \frac{1}{n} \sum_{i=1}^n \varepsilon_i \gamma(t; \xi_i) \right\} \middle| P_n \right]$$

avec $\varepsilon_1, \dots, \varepsilon_n$ i.i.d. $\sim \mathcal{U}(\{-1, +1\})$

- **complexités de Rademacher locales** (Bartlett, Bousquet and Mendelson, 2004 ; Koltchinskii, 2006)

Plan

- 1 Régressogrammes en régression hétéroscédastique
- 2 Nécessité d'estimer la forme de la pénalité
- 3 Rééchantillonnage
- 4 Garanties théoriques pour les régressogrammes**
- 5 Estimation de densité par moindres carrés
- 6 Conclusion

Rappels

$$\hat{s}_m = \sum_{\lambda \in m} \hat{\beta}_\lambda \mathbf{1}_\lambda \quad \text{avec} \quad \hat{\beta}_\lambda := \frac{1}{n\hat{p}_\lambda} \sum_{i \text{ t.q. } X_i \in \lambda} Y_i$$

$$\hat{p}_\lambda = \hat{p}_\lambda(D_n) = \frac{1}{n} \text{Card} \{ i \text{ t.q. } X_i \in \lambda \}$$

$$\text{pen}_{\text{id}}(m) = p_1(m) + p_2(m) - \delta(m)$$

$$p_1(m) = P(\gamma(\hat{s}_m) - \gamma(s_m^*)) = \sum_{\lambda \in m} \left[p_\lambda (\hat{\beta}_\lambda - \beta_\lambda)^2 \right]$$

$$p_2(m) = P_n(\gamma(s_m^*) - \gamma(\hat{s}_m)) = \sum_{\lambda \in m} \left[\hat{p}_\lambda (\hat{\beta}_\lambda - \beta_\lambda)^2 \right]$$

$$\delta(m) = (P_n - P)\gamma(s_m^*)$$

Pénalité par rééchantillonnage

$$\text{pen}_W(m) = \frac{C_W}{n} \sum_{\lambda \in m} \frac{R_{1,W} + R_{2,W}}{n\hat{p}_\lambda - 1} \left(S_{\lambda,2} - \frac{1}{n\hat{p}_\lambda} S_{\lambda,1}^2 \right) \mathbb{1}_{n\hat{p}_\lambda \geq 2}$$

$$\text{avec } S_{\lambda,1} := \sum_{X_i \in \lambda} (Y_i - \beta_\lambda) \quad S_{\lambda,2} := \sum_{X_i \in \lambda} (Y_i - \beta_\lambda)^2$$

$$R_{1,W}(n, \hat{p}_\lambda) := \mathbb{E} \left[\frac{(W_1 - \widehat{W}_\lambda)^2}{\widehat{W}_\lambda^2} \middle| X_1 \in \lambda, \widehat{W}_\lambda > 0 \right]$$

$$\text{et } R_{2,W}(n, \hat{p}_\lambda) := \mathbb{E} \left[\frac{(W_1 - \widehat{W}_\lambda)^2}{\widehat{W}_\lambda} \middle| X_1 \in \lambda \right]$$

Valeurs pour R_1 et R_2 : exemples

$R_{1,W}(n, \hat{p}_\lambda) \sim R_{2,W}(n, \hat{p}_\lambda)$ lorsque $n\hat{p}_\lambda \rightarrow \infty$

$$C_{W,\infty}(n) := \lim_{n\hat{p}_\lambda \rightarrow \infty} \frac{1}{R_{2,W}(n, \hat{p}_\lambda)}$$

Efron(m) :	$R_{2,W}(n, \hat{p}_\lambda) = \frac{n}{m} \left(1 - \frac{1}{n\hat{p}_\lambda} \right)$	$C_{W,\infty} = \frac{m}{n}$
Rademacher(p) :	$R_{2,W}(n, \hat{p}_\lambda) = \frac{1}{p} - 1$	$C_{W,\infty} = \frac{p}{1-p}$
Random hold-out(q) :	$R_{2,W}(n, \hat{p}_\lambda) = \frac{n}{q} - 1$	$C_{W,\infty} = \frac{q}{n-q}$
Leave-one-out :	$R_{2,W}(n, \hat{p}_\lambda) = \frac{1}{n-1}$	$C_{W,\infty} = n-1$

Espérances

$$\mathbb{E}[Y_i - \beta_\lambda \mid X_i \in \lambda] = 0 \quad \text{et} \quad \mathbb{E}\left[(Y_i - \beta_\lambda)^2 \mid X_i \in \lambda\right] = \sigma_\lambda^2$$

$$\mathbb{E}[\text{pen}_W(m) \mid \mathcal{P}_m] = \frac{C_W}{n} \sum_{\lambda \in m} (R_{1,W} + R_{2,W}) \sigma_\lambda^2 \mathbb{1}_{n\hat{p}_\lambda \geq 2}$$

$$\mathbb{E}[\text{pen}_W(m)] = \frac{C_W}{C_{W,\infty}} \frac{1}{n} \sum_{\lambda \in m} \left(2 + \bar{\delta}_{n,p_\lambda}^{(\text{pen}W)}\right) \sigma_\lambda^2$$

avec $\bar{\delta}_{n,p_\lambda}^{(\text{pen}W)} \rightarrow 0$ quand $np_\lambda \rightarrow +\infty$

⇒ adaptation à l'hétéroscédasticité

Concentration

Proposition (A. 2009)

- *Données bornées* : $\|Y_i\|_\infty \leq A < \infty$
- *Bruit minoré* : $\sigma(X_i) \geq \sigma_{\min} > 0$
- $\mathcal{L}(W)$ parmi Efr(n), Rad($1/2$), Rho($n/2$), Loo

Pour tout $A_n \geq 2$, avec probabilité au moins $1 - L_1 n^{-\gamma}$,

$$\begin{aligned} & |\text{pen}_W(m) - \mathbb{E}[\text{pen}_W(m) \mid \mathcal{P}_m]| \mathbf{1}_{\min_{\lambda \in m} \{n\hat{p}_\lambda\} \geq A_n} \\ & \leq \frac{C_W}{C_{W,\infty}} \frac{L_2(A/\sigma_{\min}, \gamma) \ln(n)}{\sqrt{A_n D_m}} \mathbb{E}[p_2(m)] \end{aligned}$$

Inégalité-oracle “trajectorielle” non-asymptotique

- $\mathcal{L}(W)$ parmi $\text{Efr}(n)$, $\text{Rad}(1/2)$, $\text{Rho}(n/2)$, Loo
- $C_W \approx C_{W,\infty}$

Inégalité-oracle “trajectorielle” non-asymptotique

- $\mathcal{L}(W)$ parmi Efr(n), Rad(1/2), Rho($n/2$), Loo
- $C_W \approx C_{W,\infty}$
- $\text{Card}(\mathcal{M}_n) \leq C_{\mathcal{M}} n^{\alpha_{\mathcal{M}}}$
- **Données bornées** : $\|Y_i\|_{\infty} \leq A < \infty$
- **Bruit minoré** : $\sigma(X_i) \geq \sigma_{\min} > 0$

Inégalité-oracle “trajectorielle” non-asymptotique

- $\mathcal{L}(W)$ parmi Efr(n), Rad(1/2), Rho($n/2$), Loo
- $C_W \approx C_{W,\infty}$
- $\text{Card}(\mathcal{M}_n) \leq C_{\mathcal{M}} n^{\alpha_{\mathcal{M}}}$
- **Données bornées** : $\|Y_i\|_{\infty} \leq A < \infty$
- **Bruit minoré** : $\sigma(X_i) \geq \sigma_{\min} > 0$
- $s^* \in \mathcal{H}(\alpha, R)$ non-constante
- **Présélection** de modèles : $\forall m \in \mathcal{M} , \min_{\lambda \in m} n\hat{p}_{\lambda} \geq 3$

Inégalité-oracle "trajectorielle" non-asymptotique

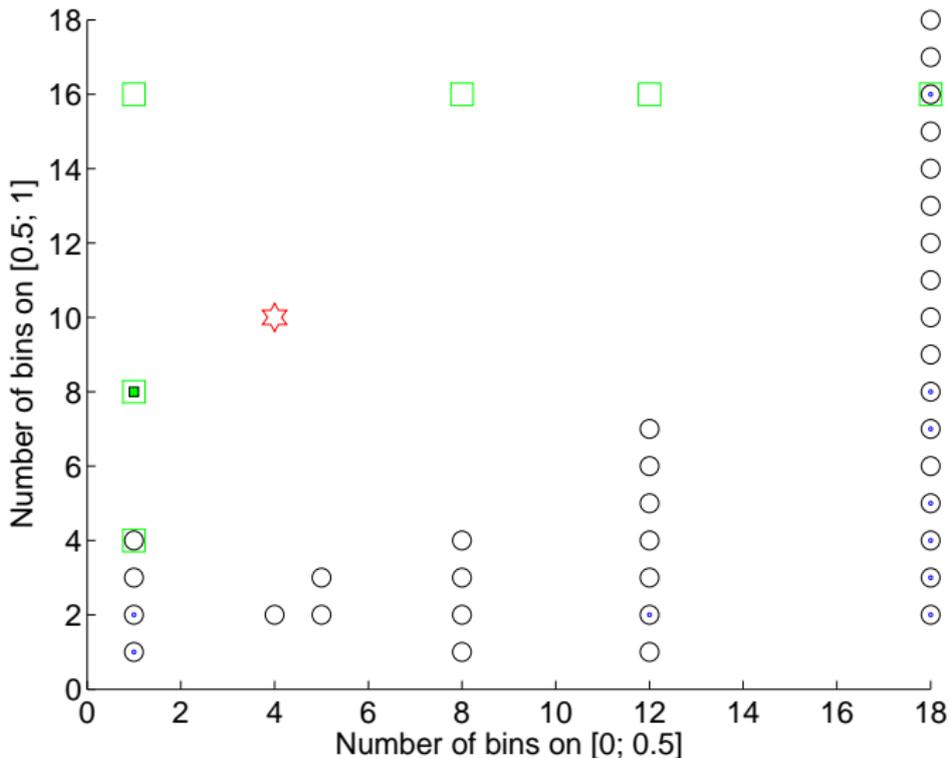
- $\mathcal{L}(W)$ parmi Efr(n), Rad(1/2), Rho($n/2$), Loo
- $C_W \approx C_{W,\infty}$
- $\text{Card}(\mathcal{M}_n) \leq C_{\mathcal{M}} n^{\alpha_{\mathcal{M}}}$
- **Données bornées** : $\|Y_i\|_{\infty} \leq A < \infty$
- **Bruit minoré** : $\sigma(X_i) \geq \sigma_{\min} > 0$
- $s^* \in \mathcal{H}(\alpha, R)$ non-constante
- **Présélection** de modèles : $\forall m \in \mathcal{M}, \min_{\lambda \in m} n\hat{p}_{\lambda} \geq 3$

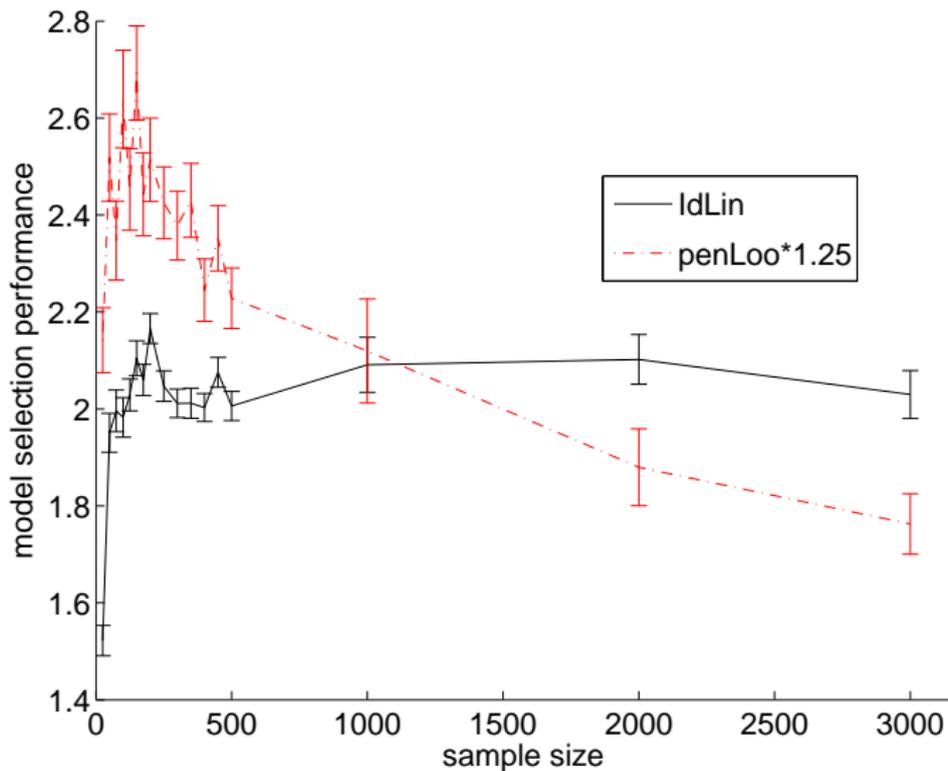
Théorème (A. 2009)

Avec probabilité au moins $1 - \diamond n^{-2}$,

$$l(s^*, \hat{s}_{\hat{m}}) \leq \left(1 + (\ln(n))^{-1/5}\right) \inf_{m \in \mathcal{M}} \{l(s^*, \hat{s}_m)\}$$

Modèles sélectionnables : penLoo mieux que pen(D_m)



Simulations : $1.25 \times \text{pen}_{\text{Loo}}(m)$ vs. K^*D_m 

Adaptation

$$\tilde{s} := \widehat{s}_{\widehat{m}} \quad \text{avec} \quad \widehat{m} \in \underset{\substack{m \in \mathcal{M}_n^{(\text{reg})} \\ \min_{\lambda \in m} \{ n\widehat{p}_\lambda \} \geq 3}}{\text{argmin}} \{ P_n \gamma(\widehat{s}_m) + \text{pen}_W(m) \}$$

Hypothèses :

- **Données bornées** : $\|Y_i\|_\infty \leq A < \infty$
- **Bruit minoré** : $\sigma(X_i) \geq \sigma_{\min} > 0$
- **Densité de X minorée** : $\forall I \subset \mathcal{X}, \mathbb{P}(X \in I) \geq c_X^{\min} \text{Leb}(I)$
- $s^* = \eta \in \mathcal{H}(\alpha, R)$ avec $\alpha \in]0, 1]$:

$$\forall x_1, x_2 \in \mathcal{X}, |s^*(x_1) - s^*(x_2)| \leq R \|x_1 - x_2\|_\infty^\alpha$$

Adaptation

$$\tilde{s} := \hat{s}_{\hat{m}} \quad \text{avec} \quad \hat{m} \in \underset{\substack{m \in \mathcal{M}_n^{(\text{reg})} \\ \min_{\lambda \in m} \{ n\hat{p}_\lambda \} \geq 3}}{\text{argmin}} \{ P_n \gamma(\hat{s}_m) + \text{pen}_W(m) \}$$

$$\mathbb{E}[\ell(s^*, \tilde{s})] \leq K_2 R^{\frac{2d}{2\alpha+d}} n^{\frac{-2\alpha}{2\alpha+d}} \|\sigma\|_\infty^{\frac{4\alpha}{2\alpha+d}} + \frac{K_3 A^2}{n^2}$$

Adaptation

$$\tilde{s} := \hat{s}_{\hat{m}} \quad \text{avec} \quad \hat{m} \in \underset{\substack{m \in \mathcal{M}_n^{(\text{reg})} \\ \min_{\lambda \in m} \{ n\hat{p}_\lambda \} \geq 3}}{\text{argmin}} \{ P_n \gamma(\hat{s}_m) + \text{pen}_W(m) \}$$

$$\mathbb{E}[\ell(s^*, \tilde{s})] \leq K_2 R^{\frac{2d}{2\alpha+d}} n^{\frac{-2\alpha}{2\alpha+d}} \|\sigma\|_\infty^{\frac{4\alpha}{2\alpha+d}} + \frac{K_3 A^2}{n^2}$$

- et si $\sigma(\cdot)$ est K_σ -Lipschitz plus un maximum de J_σ sauts :

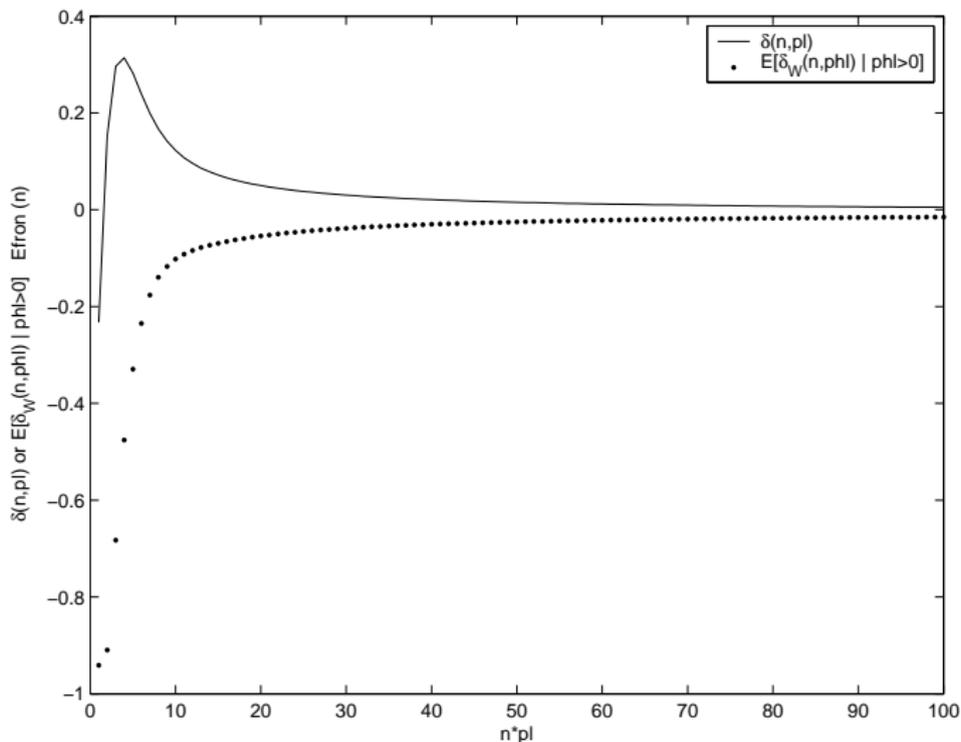
$$\mathbb{E}[\ell(s^*, \tilde{s})] \leq K_2 R^{\frac{2d}{2\alpha+d}} n^{\frac{-2\alpha}{2\alpha+d}} \|\sigma\|_{L^2(\text{Leb})}^{\frac{4\alpha}{2\alpha+d}} + \frac{K_4 A^2}{n^2}$$

Comparaison théorique des poids : rappels

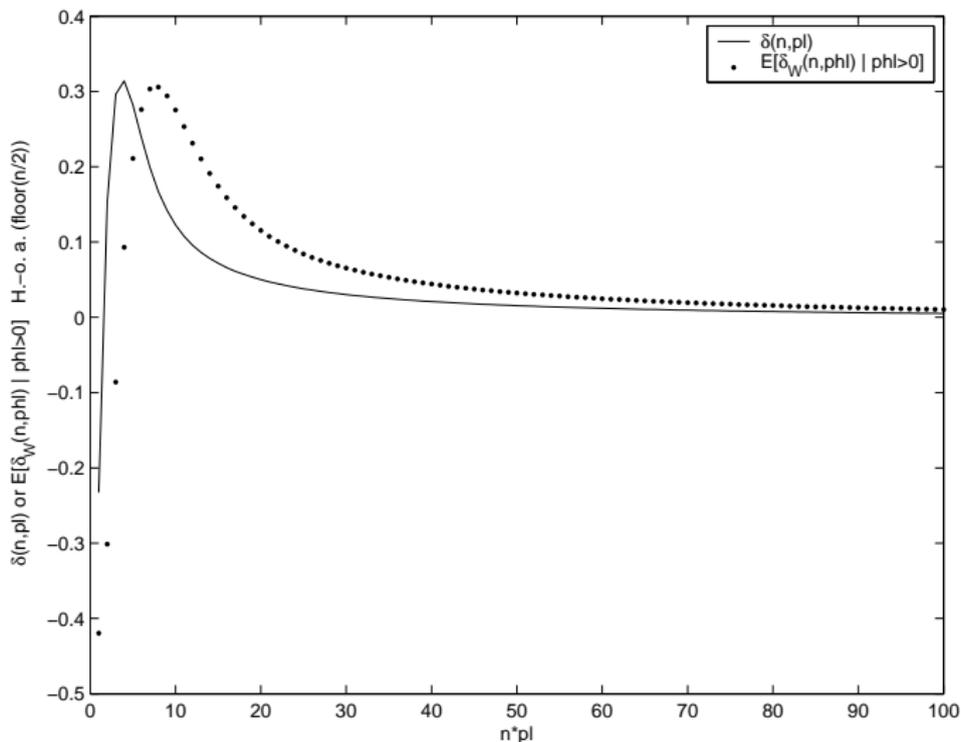
$$\mathbb{E}[\text{pen}_{\text{id}}(m)] = \frac{1}{n} \sum_{\lambda \in m} (2 + \delta_{n, p_\lambda}) \sigma_\lambda^2$$

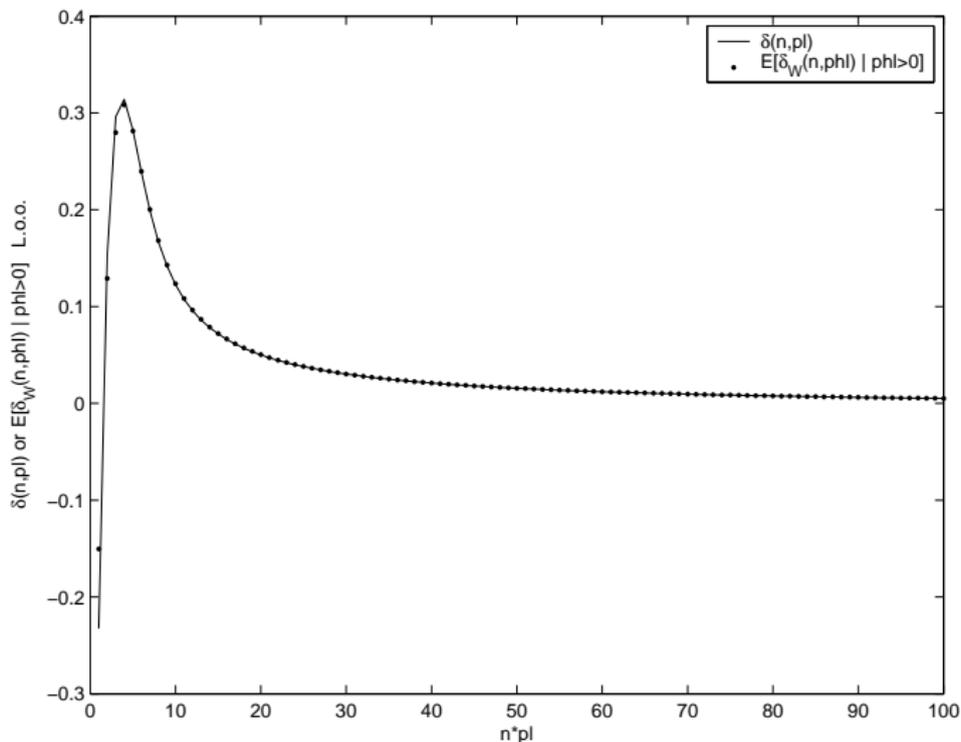
et
$$\mathbb{E}[\text{pen}_W(m)] = \frac{1}{n} \sum_{\lambda \in m} \left(2 + \overline{\delta}_{n, \hat{p}_\lambda}^{(\text{pen}W)} \right) \sigma_\lambda^2$$

$\overline{\delta}_{n, \hat{p}_\lambda}^{\text{penW}}$ vs. δ_{n, p_λ} : Efron(n) \approx Poisson(1)

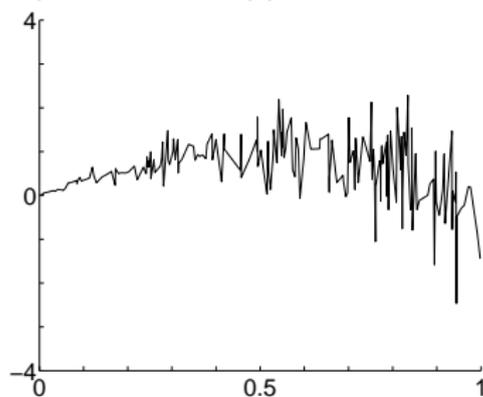
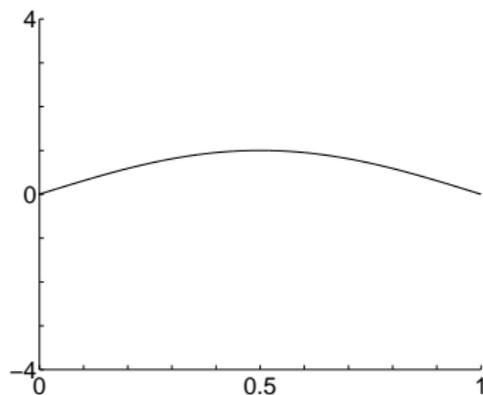


$\overline{\delta}_{n, \hat{p}_\lambda}^{\text{penW}}$ vs. δ_{n, p_λ} : $\text{Rho}(n/2) \approx \text{Rad}(1/2)$



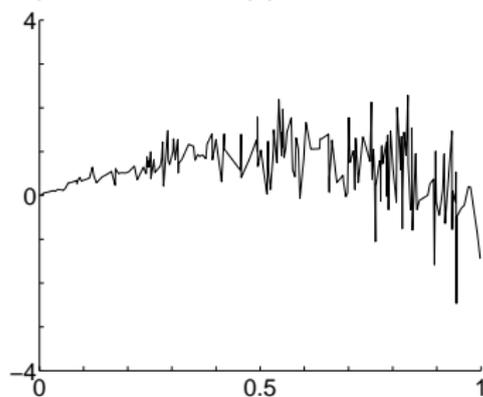
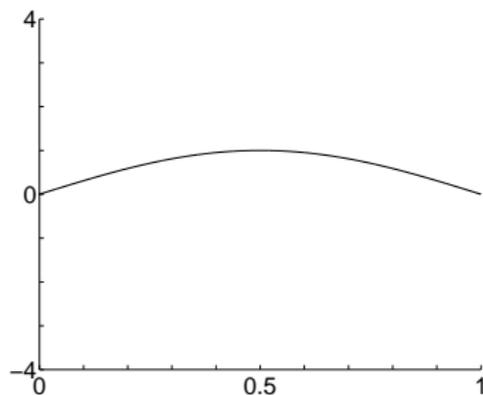
$\overline{\delta}_{n, \hat{p}_\lambda}^{\text{(penW)}}$ vs. δ_{n, p_λ} : Leave-one-out

$$s^*(x) = \sin(2\pi x) \quad n = 200 \quad \sigma(x) = x \quad \mathcal{M} = \mathcal{M}^{(\text{reg}, 1/2)}$$



Mallows	3.69 ± 0.07
$\mathbb{E}[\text{pen}_{\text{id}}]$	2.30 ± 0.05
pen Efr	3.15 ± 0.07
pen Loo	2.59 ± 0.06
pen Rho	2.50 ± 0.06
pen Rad	2.49 ± 0.06

$$s^*(x) = \sin(2\pi x) \quad n = 200 \quad \sigma(x) = x \quad \mathcal{M} = \mathcal{M}^{(\text{reg}, 1/2)}$$



Mallows	3.69 ± 0.07
$\mathbb{E}[\text{pen}_{\text{id}}]$	2.30 ± 0.05
pen Efr	3.15 ± 0.07
pen Loo	2.59 ± 0.06
pen Rho	2.50 ± 0.06
pen Rad	2.49 ± 0.06
Mallows $\times 1.25$	3.17 ± 0.07
$\mathbb{E}[\text{pen}_{\text{id}}] \times 1.25$	2.03 ± 0.04
pen Efr $\times 1.25$	2.60 ± 0.06
pen Loo $\times 1.25$	2.22 ± 0.05
pen Rho $\times 1.25$	2.14 ± 0.05
pen Rad $\times 1.25$	2.14 ± 0.05

Plan

- 1 Régressogrammes en régression hétéroscédastique
- 2 Nécessité d'estimer la forme de la pénalité
- 3 Rééchantillonnage
- 4 Garanties théoriques pour les régressogrammes
- 5 Estimation de densité par moindres carrés
- 6 Conclusion

Estimation de densité par moindres carrés

- μ mesure de référence sur Ξ
- $f = dP/d\mu \in \mathbb{S} = L^2(\mu)$

Estimation de densité par moindres carrés

- μ mesure de référence sur Ξ
- $f = dP/d\mu \in \mathbb{S} = L^2(\mu)$
- $\gamma(t; \xi) = \|t\|_{L^2(\mu)}^2 - 2t(\xi)$
 - $\Rightarrow P\gamma(t) = \|t\|_{L^2(\mu)}^2 - 2\langle t, f \rangle_{L^2(\mu)}$
 - $\Rightarrow s^* = f$ et $\ell(s^*, t) = \|t - s^*\|_{L^2(\mu)}^2$

Estimation de densité par moindres carrés

- μ mesure de référence sur Ξ
- $f = dP/d\mu \in \mathbb{S} = L^2(\mu)$
- $\gamma(t; \xi) = \|t\|_{L^2(\mu)}^2 - 2t(\xi)$
 $\Rightarrow P\gamma(t) = \|t\|_{L^2(\mu)}^2 - 2\langle t, f \rangle_{L^2(\mu)}$
 $\Rightarrow s^* = f$ et $\ell(s^*, t) = \|t - s^*\|_{L^2(\mu)}^2$
- $(\psi_\lambda)_{\lambda \in m}$ b.o.n. de S_m
 $\Rightarrow s_m^* = \sum_{\lambda \in m} (P\psi_\lambda)\psi_\lambda$ et $\hat{s}_m = \sum_{\lambda \in m} (P_n\psi_\lambda)\psi_\lambda$

Estimation de densité par moindres carrés

- μ mesure de référence sur Ξ
- $f = dP/d\mu \in \mathbb{S} = L^2(\mu)$
- $\gamma(t; \xi) = \|t\|_{L^2(\mu)}^2 - 2t(\xi)$
 - $\Rightarrow P\gamma(t) = \|t\|_{L^2(\mu)}^2 - 2\langle t, f \rangle_{L^2(\mu)}$
 - $\Rightarrow s^* = f$ et $\ell(s^*, t) = \|t - s^*\|_{L^2(\mu)}^2$
- $(\psi_\lambda)_{\lambda \in m}$ b.o.n. de S_m
 - $\Rightarrow s_m^* = \sum_{\lambda \in m} (P\psi_\lambda)\psi_\lambda$ et $\hat{s}_m = \sum_{\lambda \in m} (P_n\psi_\lambda)\psi_\lambda$

$$\begin{aligned} \text{pen}_{\text{id}}(m) &= (P - P_n)\gamma(\hat{s}_m) = 2(P_n - P)(\hat{s}_m) \\ &= 2\|s_m^* - \hat{s}_m\|_{L^2(\mu)}^2 + 2(P_n - P)(s_m^*) \end{aligned}$$

Cas i.i.d. (Lerasle 2009)

$$\text{pen}_{\text{id}}(m) = 2(P_n - P)(\hat{s}_m)$$

$$\text{pen}_W(m) = C_W \mathbb{E}_W \left[2(P_n^W - \overline{W}P_n)(\hat{s}_m^W) \right]$$

Cas i.i.d. (Lerasle 2009)

$$\text{pen}_W(m) = C_W \mathbb{E}_W \left[2(P_n^W - \overline{W}P_n)(\hat{s}_m^W) \right]$$

⇒ $\text{pen}_W(m)$ ne dépend de W que par une **constante multiplicative**

Cas i.i.d. (Lerasle 2009)

$$\text{pen}_W(m) = C_W \mathbb{E}_W \left[2(P_n^W - \overline{W}P_n)(\hat{s}_m^W) \right]$$

⇒ $\text{pen}_W(m)$ ne dépend de W que par une constante multiplicative

$$\Rightarrow \mathbb{E} [\text{pen}_W(m)] = C_W \text{var} (W_1 - \overline{W}) \mathbb{E} [\text{pen}_{\text{id}}(m)]$$

+ **concentration** de $\text{pen}_W(m)$ autour de son espérance (plus rapide que $\text{pen}_{\text{id}}(m)$)

Cas i.i.d. (Lerasle 2009)

$$\text{pen}_W(m) = C_W \mathbb{E}_W \left[2(P_n^W - \overline{W}P_n)(\hat{s}_m^W) \right]$$

- ⇒ $\text{pen}_W(m)$ ne dépend de W que par une constante multiplicative
- ⇒ $\mathbb{E}[\text{pen}_W(m)] = C_W \text{var}(W_1 - \overline{W}) \mathbb{E}[\text{pen}_{\text{id}}(m)]$
 - + concentration de $\text{pen}_W(m)$ autour de son espérance (plus rapide que $\text{pen}_{\text{id}}(m)$)
- ⇒ **inégalité-oracle avec constante $1 + o(1)$** sous de bonnes hypothèses sur P et \mathcal{M}_n

Cas dépendant (Lerasle 2010)

- Hypothèses de **mélange** (β ou τ)
 - Découpage des données en **blocs** \Rightarrow on garde un bloc sur deux
 - On **rééchantillonne les blocs** (qui sont quasi-indépendants entre eux)
- \Rightarrow Inégalité-oracle (avec un oracle n'utilisant pas toutes les données de départ)

Plan

- 1 Régressogrammes en régression hétéroscédastique
- 2 Nécessité d'estimer la forme de la pénalité
- 3 Rééchantillonnage
- 4 Garanties théoriques pour les régressogrammes
- 5 Estimation de densité par moindres carrés
- 6 Conclusion

Limites

- Temps de calcul

⇒ alternative : poids non-échangeables (e.g., V-fold)

- Résultats non-asymptotiques : possible sans calculs explicites ?

La semaine prochaine

- Lundi 31, 15h30–17h30 : Validation croisée et pénalités reliées

Lundi 31, 13h30–14h40 :

Deux approches nouvelles en sparsité (I) : Les liens de la régularisation L1 avec la sélection de modèles parmi des boules L1
par Caroline Meynet (Université Paris-Sud).

Salle W, ENS, 45 rue d'Ulm

http://www.math.ens.fr/-Seminaires-?id_seance=178