

# Bornes inférieures minimax

Eddie Amari  
13/01/16

(4)

- Références :
- Bin Yu - Assouad, Fano, LeCam - 1997
  - A. Tsybakov - Introduction to Nonparametric Estimation - 2009
  - I. Johnstone - Gaussian Estimation: Sequence & Wavelet models - (draft)
  - L. Gibbs, F. Su - On Choosing & Bounding Probability Metrics - 2002

But: Donner des techniques classiques pour minorer des risques minimax du type,

$$\inf_{\hat{\theta}} \sup_{P \in \mathcal{P}} E_P l(\hat{\theta}, \theta) \geq \dots > 0.$$

- Plan:
- 1/ Risque minimax, optimalité
  - 2/ Risques minimax fréquentiste et bayésien
  - 3/ Théorèmes usuels de bornes inférieures
    - a) Lemme de LeCam
    - a') Proximités stochastiques
    - b) Comparaison de plusieurs hypothèses
    - c) Lemme d'Assouad
    - d) Autres méthodes

4/ Exemples: regression sur les classes de Hölder

- a) Perte ponctuelle
- b) Perte quadratique
- c) Perte uniforme

# 1/ Risque minimax, optimalité

Soit  $\mathcal{P}$  un modèle. Pour tout  $P \in \mathcal{P}$ , le paramètre d'intérêt est  $\theta(P) \in \Theta$ . On s'intéresse à l'estimation de  $\theta$  uniformément sur  $\mathcal{P}$  pour la perte  $l(\cdot, \cdot) : \Theta \times \Theta \rightarrow \mathbb{R}$ . L'uniformité est à prendre au sens du risque minimax. Soit  $\left| \pi(\hat{\theta}, \theta(P)) = \mathbb{E}_{\sigma(P)} l(\hat{\theta}, \sigma) \right|$  est le risque de l'estimateur  $\hat{\theta}$  en  $P$  (ou par abus, en  $\sigma = \theta(P)$ ), le risque minimax s'écrit

$$R(\mathcal{P}) = \inf_{\hat{\theta} \text{ estimateur}} \sup_{P \in \mathcal{P}} \pi(\hat{\theta}, \theta(P))$$

$R(\hat{\theta})$

C'est le meilleur risque en pire cas sur  $\mathcal{P}$ .

$\hat{\theta}$  est dit minimax optimal si  $R(\hat{\theta}) = R(\mathcal{P})$ . Les cas où  $R(\mathcal{P})$  est calculable sont rares, et sa valeur exacte ne présente pas un grand intérêt, mais son comportement est important. On se contente de l'encadrer :

• Pour majorer  $R(\mathcal{P})$  : on étudie un estimateur  $\hat{\theta}$  bien choisi et on borne  $\pi(\hat{\theta}, \theta(P))$  uniformément en  $P \in \mathcal{P}$

• Pour minorer  $R(\mathcal{P})$  : les méthodes classiques reposent sur des approches bayésiennes.

Remarque : Dans la suite, on pourra noter indifféremment  $P, \theta(P)$  ou  $\theta$ , et désigner le modèle par  $\Theta$  au lieu de  $\mathcal{P}$ .

Observation initiale : Pour toute loi de probabilité  $\pi$  sur  $(\mathcal{H})$  et tout estimateur  $\hat{\theta}$ , (3)

$$\sup_{\theta \in \Theta} r(\hat{\theta}, \theta) \geq \int_{\Theta} r(\hat{\theta}, \theta) \pi(d\theta) =: \mathcal{B}(\hat{\theta}, \pi)$$

donc  $R(\Theta) = \inf_{\hat{\theta}} \sup_{\theta \in \Theta} r(\hat{\theta}, \theta) \geq \inf_{\hat{\theta}} \mathcal{B}(\hat{\theta}, \pi) =: \mathcal{B}(\pi)$

- Toutes les bornes présentées dans la suite sont basées là dessus.
- Souvent,  $\pi$  est composée uniquement de Diracs.
- Le choix de  $\pi$  est primordial et se fait au cas par cas. On peut aussi optimiser sur une famille de priors  $\Pi$  pour obtenir :

$$R(\Theta) \geq \sup_{\pi \in \Pi} \mathcal{B}(\pi) =: \mathcal{B}(\Pi) \quad (*)$$

Bien que la définition du risque minimax soit purement fréquentiste, son étude est fortement dépendante de considérations bayésiennes. Dans certains cas, on peut donner un lien rigoureux entre les deux.

## 2/ Risques minimax fréquentiste et bayésien (Johnstone, Chapitre 4) <sup>(4)</sup>

On considère le problème de l'estimation de  $\theta = (\theta_i)_{i \in \mathbb{N}}$  dans le modèle gaussien hétéroscédastique

$$Y_i = \theta_i + \varepsilon_i p_i Z_i, \quad i \in \mathbb{N}$$

avec  $Z_i \stackrel{\text{iid}}{\sim} N(0,1)$  et  $\varepsilon_i, p_i > 0$  connus. L'espace des paramètres est  $\Theta = \ell_{2,p} = \left\{ \theta : \sum_{i=0}^{\infty} \left( \frac{\theta_i}{p_i} \right)^2 < \infty \right\}$ .

Th: (Théorème minimax)

Supposons que pour tout  $\theta \in \overline{\mathbb{R}^{\mathbb{N}}}$ ,  $a \mapsto l(a, \theta)$  est convexe et semi-continue inférieurement ( $l(a, \theta) \leq \liminf_{b \rightarrow a} l(b, \theta) \forall \theta$ ).

Soit  $\Pi$  un ensemble convexe de mesures de probabilité sur  $\ell_{2,p}$ .

Alors

$$\inf_{\hat{\theta}} \sup_{\pi \in \Pi} B(\hat{\theta}, \pi) = \sup_{\pi \in \Pi} \inf_{\hat{\theta}} B(\hat{\theta}, \pi) = B(\Pi)$$

Dém: cf Johnstone. C'est une application du théorème minimax de Von Neumann, en remarquant notamment que  $\pi \mapsto B(\hat{\theta}, \pi)$  est linéaire et donc concave.

Application: On note que  $\kappa(\hat{\theta}, \sigma) = B(\hat{\theta}, \delta_\sigma) = \int_{\mathcal{H}} \kappa(\hat{\theta}, \sigma') \delta_\sigma(d\sigma')$  (5)

Ainsi, si  $\Pi \supset \{\delta_\sigma, \sigma \in \mathcal{H}\}$  on obtient

$$\sup_{\sigma \in \mathcal{H}} \kappa(\hat{\theta}, \sigma) \leq \sup_{\pi \in \Pi} B(\hat{\theta}, \pi)$$

Et donc  $R(\mathcal{H}) = \inf_{\hat{\theta}} \sup_{\sigma \in \mathcal{H}} \kappa(\hat{\theta}, \sigma)$

$$\leq \inf_{\hat{\theta}} \sup_{\pi \in \Pi} B(\hat{\theta}, \pi)$$

$$= \sup_{\pi \in \Pi} \inf_{\hat{\theta}} B(\hat{\theta}, \pi) \quad \text{par théorème minimax si } \Pi \text{ est convexe}$$

$$= B(\Pi)$$

D'autre part on a vu que  $R(\mathcal{H}) \geq B(\Pi)$ , donc

$$\underline{R(\mathcal{H}) = B(\Pi)}$$

En prenant par exemple  $\Pi = \text{Conv}(\{\delta_\sigma, \sigma \in \mathcal{H}\})$  on a montré que l'on peut trouver une famille de lois a priori  $\Pi$  sur  $\mathcal{H}$  réalisant l'égalité dans (\*). En particulier, dans ce contexte on ne perd rien à considérer le risque bayésien dans la minoration (\*).

Remarque: On peut faire plus précis: le Lemme 4.18 ("least favorable priors are discrete") suggère que les lois  $\pi$  maximisant  $B(\Pi) = \inf_{\hat{\theta}} B(\hat{\theta}, \pi)$  sont discrètes et sans points d'accumulation. Les méthodes où  $\pi$  est une somme finie de Dirac (Assouad, Fan, LeCam) sont donc potentiellement de bons choix

### 3/ Théorèmes usuels de bornes inférieures

(6)

#### a) Lemme de Lecam

Dans ce qui suit, la perte  $l(\cdot, \cdot)$  est une (semi)-distance. On peut généraliser à des pertes composites ou à des fonctionnelles satisfaisant l'inégalité triangulaire faible  $l(x, y) + l(y, z) \geq A l(x, z)$ ,  $A < 1$  facilement.

cf Tsybakov et Lu.

#### Th: (Lemme de Lecam)

Soient  $\Theta_1, \Theta_2 \subset \Theta$   $2\delta$ -séparés, au sens où  $l(\theta_1, \theta_2) \geq 2\delta$  pour tout  $\theta_1 \in \Theta_1, \theta_2 \in \Theta_2$ . On suppose que  $\mathcal{P}_1, \mathcal{P}_2 \subset \mathcal{P}$  sont tels que  $\theta(P_i) \in \Theta_i$  pour  $P_i \in \mathcal{P}_i, i=1,2$ . Alors

$$R(\mathcal{P}) = \inf_{\hat{\theta}} \sup_{P \in \mathcal{P}} E_P l(\hat{\theta}, \theta(P)) \geq \delta \cdot \sup_{P_i \in \text{Conv}(\mathcal{P}_i)} \|P_1 \wedge P_2\|,$$


où  $\|P_1 \wedge P_2\| = \int dP_1 dP_2$  et  $\text{Conv}(\mathcal{P}_i)$  est l'enveloppe convexe de  $\mathcal{P}_i$ .

Dem: Soit  $\hat{\theta}$  un estimateur. Pour  $P_i \in \mathcal{P}_i$ ,

$$\begin{aligned} M &= 2 \sup_{P \in \mathcal{P}} E_P l(\hat{\theta}, \theta(P)) \geq E_{P_1} l(\hat{\theta}, \theta(P_1)) + E_{P_2} l(\hat{\theta}, \theta(P_2)) \\ &\geq E_{P_1} l(\hat{\theta}, \Theta_1) + E_{P_2} l(\hat{\theta}, \Theta_2) \end{aligned}$$

Par combinaisons convexes,  $\forall P_i \in \text{Conv}(\mathcal{P}_i)$ ,

$$M \geq E_{P_1} l(\hat{\theta}, \Theta_1) + E_{P_2} l(\hat{\theta}, \Theta_2).$$



Comme  $l(\hat{\sigma}, \oplus_1) + l(\hat{\sigma}, \oplus_2) \geq l(\oplus_1, \oplus_2) \geq 2\delta$ , pour tout  $P_i \in \text{Conv}(\mathcal{P})$

$$M \geq 2\delta \cdot \inf_{\substack{f_i \geq 0 \\ f_1 + f_2 = 1}} \{E_{P_1} f_1 + E_{P_2} f_2\}$$

le terme de droite est clairement minoré par

$$2\delta \inf_{\substack{f_i \geq 0 \\ f_1 + f_2 = 1}} \int f_1 dP_1 + f_2 dP_2 \geq 2\delta \inf_{\substack{f_i \geq 0 \\ f_1 + f_2 = 1}} \int (f_1 + f_2) dP_1 dP_2 = 2\delta \|P_1 \perp P_2\| \square$$

### a') Proximités stochastiques

Th: (théorème de Scheffé)

$$TV(P, Q) = \sup_{A \in \mathcal{A}} |P(A) - Q(A)| = \frac{1}{2} \int |dP - dQ| = 1 - \|P \perp Q\|$$

Dem: (Seulement l'égalité de droite)  $|p - q| = p + q - 2p \wedge q$  + intégration

\* distance de Hellinger  $H(P, Q)^2 = \int (\sqrt{dP} - \sqrt{dQ})^2$

\* divergence de Kullback  $K(P, Q) = \begin{cases} \int \log \frac{dP}{dQ} dP & \text{si } P \ll Q \\ +\infty & \text{sinon} \end{cases}$

Prop: (Inégalité de LeCam)

$$\frac{1}{2} H^2(P, Q) \leq TV(P, Q) \leq H(P, Q) \sqrt{1 - \frac{H^2(P, Q)}{4}}$$

Prop: ( Pinsker )

$$TV(P, Q) \leq \sqrt{\frac{K(P, Q)}{2}}$$

Prop:  $H^2(P, Q) \leq K(P, Q)$

$$TV(P, Q) \leq 1 - \frac{1}{2} \exp(-K(P, Q))$$

Corollaire (Version Variation Totale de LeCam)

$$\left\{ \begin{array}{l} l(\Theta_1, \Theta_2) \geq 2\delta \\ \inf_{P_i \in \text{Conv}(\mathcal{P}_i)} TV(P_1, P_2) \leq \alpha \end{array} \right. , \text{ alors } R(\Theta) \geq \delta \cdot \frac{1-\alpha}{2}$$

Corollaire (Version Hellinger)

$$\left\{ \begin{array}{l} l(\Theta_1, \Theta_2) \geq 2\delta \\ \inf_{P_i \in \text{Conv}(\mathcal{P}_i)} H^2(P_1, P_2) \leq \alpha < 2 \end{array} \right. , \text{ alors } R(\Theta) \geq \frac{\delta}{2} (1 - \sqrt{\alpha(1 - \frac{\alpha}{2})})$$

Corollaire (Version Kullback)

$$\left\{ \begin{array}{l} l(\Theta_1, \Theta_2) \geq 2\delta \\ \inf_{P_i \in \text{Conv}(\mathcal{P}_i)} K(P_1, P_2) \leq \alpha < \infty \end{array} \right. , \text{ alors } R(\Theta) \geq \delta \cdot \text{Max} \left\{ \frac{1}{4} \exp(-\alpha), \frac{1 - \sqrt{\alpha}}{2} \right\}$$



Rq: Pour des exemples montrant la nécessité de considérer les enveloppes convexes dans certains cas :

- Tisu Kim "Minimax dimension estimation", 2016
- Kim & Zhou "Tight minimax rates for Manifold Estimation", 2013

On a ici comparé deux "hypothèses" entre elles. Ça n'est parfois pas suffisant, et introduire plus d'alternatives peut être nécessaire pour obtenir des bornes optimales

b) Comparaison de plusieurs hypothèses

Prop: (Comparaison de plusieurs hypothèses, Version Kullback)

Soit  $N \geq 2$  et  $\theta_0, \theta_1, \dots, \theta_N \in \Theta$  tels que :

$$\theta_0(P_0) \quad \theta_1(P_1) \quad \dots \quad \theta_N(P_N)$$

$$d(\theta_j, \theta_k) \geq 2\delta \quad \forall j \neq k$$

$$P_j \ll P_0 \quad \text{et} \quad \frac{1}{M} \sum_{j=1}^M K(P_j, P_0) \leq \alpha \log M$$

avec  $\alpha < \frac{1}{8}$ .

Alors 
$$\inf_{\hat{\theta}} \sup_{P \in \mathcal{P}} E_P d(\hat{\theta}, \theta(P)) \geq \delta \cdot \frac{\sqrt{M}}{1 + \sqrt{M}} \left( 1 - 2\alpha - \sqrt{\frac{2\alpha}{\log M}} \right)$$

Rq: Ici, seule importe la proximité stochastique entre  $P_0$  et les autres  $P_j$ , mais pas les  $(P_j)_{j \neq 0}$  entre elles.

# c) Lemme d'Assouad

10

Th: (Lemme d'Assouad)

Soit  $m \geq 1$ . On suppose que  $\mathcal{P} \subset \{P_\tau, \tau \in \{-1, 1\}^m\}$  contient  $2^m$  lois.  
 Notons  $\tau \sim \tau'$  si  $\tau$  et  $\tau'$  ne diffèrent que d'une coordonnée (exactement), et  $\tau \sim_j \tau'$  si celle-ci est la coordonnée  $j$ . Supposons que la perte se décompose sous la forme  $l(x, y) = \sum_{j=1}^m l_j(x, y)$ .

On suppose que si  $\tau \sim_j \tau'$ , alors  $l_j(\theta(P_\tau), \theta(P_{\tau'})) \geq 2\delta$ .

Alors  $\inf_{\hat{\theta}} \max_{\tau \in \{-1, 1\}^m} E_{\tau} l(\hat{\theta}, \theta(P_\tau)) \geq m \cdot \delta \cdot \min_{\tau \sim \tau'} \|P_\tau \wedge P_{\tau'}\|$

Dem:

$$\begin{aligned} \max_{\tau} E_{\tau} l(\hat{\theta}, \theta(P_\tau)) &= \max_{\tau} \sum_{j=1}^m E_{\tau} l_j(\hat{\theta}, \theta(P_\tau)) \\ &\geq \frac{1}{2^m} \sum_{\tau} \sum_{j=1}^m E_{\tau} l_j(\hat{\theta}, \theta(P_\tau)) \\ &= \sum_{j=1}^m \frac{1}{2^m} \sum_{\tau} E_{\tau} l_j(\hat{\theta}, \theta(P_\tau)) \\ &= \sum_{j=1}^m \frac{1}{2^{m+1}} \sum_{\tau} E_{\tau} l_j(\hat{\theta}, \theta(P_\tau)) + E_{\tau'} l_j(\hat{\theta}, \theta(P_{\tau'})) \\ &\quad \text{où } \tau' = (\tau_1, \dots, \tau_{j-1}, -\tau_j, \tau_{j+1}, \dots, \tau_m) \end{aligned}$$

Comme  $l_j(\hat{\theta}, \theta(P_\tau)) + l_j(\hat{\theta}, \theta(P_{\tau'})) \geq 2\delta$ , le même argument que précédemment donne le résultat.  $\square$

## d) Autres méthodes

(11)

- Fano : Une "généralisation" d'Assouad (on peut déduire le second du premier) spécifique à Kullback
- Inégalité de Van Tree : prior paramétrique (segment  $c\mathbb{R}$ ). Uniquement pour la perte quadratique dans  $\mathbb{R}$
- Hypothèses floues : comparaison de deux posteriors dont les priors sont stochastiquement éloignés. Écrit pour  $\mathbb{C}\mathbb{R}$  dans Tsybakov, mais facilement généralisable à une perte métrique générale.
- Théorème de convolution : résultat asymptotique en loi adapté à un cadre paramétrique. Cf Hajek, van der Vaart, ( $\approx$  Borne de Cramer-Rao asymptotique locale)

### 4/ Exemples : regression sur les classes de Hölder

La classe de Hölder  $\mathcal{C}^\beta(L)$  est l'ensemble des fonctions  $f: [0, 1] \rightarrow \mathbb{R}$   $L\beta$  fois dérivables et telles que  $\forall x, y \in [0, 1]$ ,

$$|f^{(L\beta)}(x) - f^{(L\beta)}(y)| \leq L|x-y|^{\beta-L\beta}$$


On considère le modèle  $Y_i = f(X_i) + \epsilon_i, \quad 1 \leq i \leq n$   
 avec  $\begin{cases} \epsilon_i \stackrel{iid}{\sim} N(0, \sigma^2) \\ X_i \text{ déterministes} \end{cases}$  et  $f \in \mathcal{C}^\beta(L)$

pour les pertes  $l_{x_0}(f, g) = |f(x_0) - g(x_0)|$  ponctuelle  
 $l_2(f, g) = \|f - g\|_{L^2}$   $L^2$  (quadratique)  
 $l_\infty(f, g) = \|f - g\|_{L^\infty}$   $L^\infty$  (uniforme)

Soit  $K: \mathbb{R} \rightarrow \mathbb{R}_+$  tel que  $\begin{cases} K \in \mathcal{C}^\infty(\mathbb{R}) \cap \mathcal{C}^\beta(\frac{1}{2}) \\ K(x) > 0 \iff -\frac{1}{2} < x < \frac{1}{2} \end{cases}$

a) Perte ponctuelle : On utilise lecam, avec Kullback :

$$f_0(x) = 0 \quad ; \quad f_1(x) = L h_n^\beta K\left(\frac{x - x_0}{h_n}\right)$$



On a :

$$f_0, f_1 \in \mathcal{L}^\beta(L)$$

$$l(f_0, f_1) = |f_1(x_0)| = L K(0) h_n^\beta$$

$$"K(P_0, P_1) \leq \alpha"$$

Sous  $P_j$ ,  $(Y_1, \dots, Y_n)$  admet pour densité

$$P_j(u_1, \dots, u_n) = \prod_{i=1}^n P_j(u_i - f_j(X_i)) \quad , \quad j=0,1$$

$$K(P_0, P_1) = \int \log \frac{dP_0}{dP_1}$$

$$= \int \dots \int \log \frac{\prod_i P_0(u_i)}{\prod_i P_1(u_i - f_1(X_i))} \cdot \prod_i P_1(u_i) du_i$$

$$= \sum_i \int \log \frac{P_0(y)}{P_1(y - f_1(X_i))} P_1(y) dy$$

(Admis)

$$\leq P_* \sum_{i=1}^n f_1^2(X_i)$$

$$= P_* L^2 h_n^{2\beta} \sum_i K^2\left(\frac{X_i - x_0}{h_n}\right)$$

$$\begin{aligned}
K(P_0, P_1) &\leq P_\alpha L^2 h_n^{2\beta} \|K\|_\infty^2 \sum_i \mathbb{1}_{\left\{ \left| \frac{x_i - x_0}{h_n} \right| \leq \frac{1}{2} \right\}} \\
&\leq P_\alpha L^2 h_n^{2\beta} \|K\|_\infty (m h_n) \forall 1 \\
&= \underbrace{P_\alpha L^2 \|K\|_\infty m h_n^{2\beta+1}}_{= c m h_n^{2\beta+1} = \alpha} \quad \text{dès que } m h_n \geq 1
\end{aligned}$$

On obtient donc par lecam :

$$\inf_{\hat{T}_n} \sup_{f \in \mathcal{C}^\beta(L)} E_f \left| f(x_0) - \hat{T}_n \right| \geq c' h_n^\beta \cdot \text{Max} \left( \frac{1}{4} \exp(-\alpha), \frac{1 - \sqrt{\alpha/2}}{2} \right)$$

En prenant  $h_n = \left( \frac{1}{m} \right)^{\frac{1}{2\beta+1}}$  on obtient  $\left. \begin{array}{l} \text{ce terme devient} \\ \text{constant.} \end{array} \right\}$

$$R_{h_n}(C^\beta(L)) \geq c \left( \frac{1}{m} \right)^{\frac{\beta}{2\beta+1}}$$

Rq: Vitesse atteignable avec un estimateur à noyau avec  $h = \left( \frac{1}{m} \right)^{\frac{1}{2\beta+1}}$  :  
vitesse optimale

b) Perte quadratique

Avec les mêmes deux hypothèses que précédemment on a, pour  $x_0 = \frac{1}{2}$

$$\|f_0 - f_1\|_L^2 = \left( L h_n^\beta \sqrt{\int_0^1 \left|k\left(\frac{x - \frac{1}{2}}{h_n}\right)\right|^2 dx} \right)^2$$

$$= L^2 h_n^{2\beta+1} \|k\|_L^2$$

En appliquant le cam on obtient

$$R_{f_2}^2(e^\beta(L)) \geq c h_n^{2\beta+1} \text{Max}\left(\frac{1}{4} \exp(-\alpha), \frac{1 - \sqrt{\alpha/2}}{2}\right),$$

et pour  $h_n = \left(\frac{1}{n}\right)^{\frac{1}{2\beta+1}}$  cela donne la vitesse  $\approx \left(\frac{1}{n}\right)^{\frac{\beta+1/2}{2\beta+1}} = \frac{1}{\sqrt{n}}$  où  $\alpha \propto n h_n^{2\beta+1}$

→ Vitesse paramétrique!  
↳ Peut mieux faire.

Utilisation d'Assouad : on note  $[0, 1] = \bigcup_{j=1}^m S_j$  la partition uniforme de  $[0, 1]$  de pas  $\frac{1}{m}$ .

$$d_2(f, g) = \|f - g\|_{L^2(0,1)} = \sum_j \|f - g\|_{L^2(S_j)}$$

On paramétrise le cube par  $[0, 1]^m$  au lieu de  $\{-1, 1\}^m$

$$\forall \tau \in \{0, 1\}^m, f_\tau(x) = \sum_{j=1}^m \tau_j f_j(x)$$

où  $f_j(x) = L h_n^\beta k\left(\frac{x - \alpha_j}{h_n}\right)$  avec  $h_n = \frac{1}{m}$



On a :

$$f_z \in \mathcal{C}^{\beta}(L)$$

$$l_2^2(f_z, f_{z'}) = L m h_n^{2\beta+1} \quad \text{si } z \sim z'$$

" $K(P_z, P_{z'}) \leq \alpha$ " : pareil que plus haut :

$$\text{Si } z \sim z', K(P_z, P_{z'}) \leq C m h_n^{2\beta+1} =: \alpha$$

Par ailleurs :

$$R_{l_2}(\mathcal{C}^{\beta}(L)) \geq C \underbrace{h_n^{2\beta+1}}_{= h_m^{2\beta}} \cdot m \cdot \text{Max} \left\{ \frac{1}{4} \exp(-d); \frac{1 - \sqrt{\alpha/2}}{2} \right\}$$

$$h_m = \left(\frac{1}{n}\right)^{\frac{1}{2\beta+1}} \rightarrow \boxed{\text{Vitesse en } \left(\frac{1}{n}\right)^{\frac{\beta}{2\beta+1}}}$$

c'est la vitesse optimale, car atteignable par un estimateur à noyau.

$$\boxed{\liminf_{\frac{1}{n}} \sup_{f \in \mathcal{C}^{\beta}(L)} \sqrt{\mathbb{E}_f \left\| \hat{T}_n - f \right\|_{L^2}^2} \geq C \left(\frac{1}{n}\right)^{\frac{\beta}{2\beta+1}}}$$



### c) Perte uniforme

Pq: les bornes supérieures pour les estimateurs à moyen donnent une vitesse  $(\frac{\log n}{n})^{\frac{\beta}{2\beta+1}}$ . Leam conclurait seulement  $(\frac{1}{n})^{\frac{\beta}{2\beta+1}}$

On utilise la version Kullback de la comparaison de  $M$  hypothèses pour aller chercher le log supplémentaire.

Comme précédemment, 
$$\begin{cases} f_0(x) = 0 \\ f_j(x) = L h_n^\beta \mathbb{1}_{\left(\frac{x - x_j}{h_n}\right)} \end{cases}, h_n = \frac{1}{M}$$
 pour  $j=1, \dots, M$

•  $f_j \in \mathcal{L}^\beta(L)$

•  $\rho(f_j, f_k) = \|f_j - f_k\|_\infty \geq L h_n^\beta K(0) \quad (= \varepsilon \delta)$

• 
$$\begin{aligned} \frac{1}{M} \sum_{j=1}^M K(P_j, P_0) &\leq \frac{1}{M} \sum_{j=1}^M P_* \sum_{i=1}^n f_j^2(X_i) \\ &\leq P_* L^2 \|K\|_\infty^2 h_n^{2\beta} \cdot \frac{1}{M} \sum_{j=1}^M |\{i \mid X_i \in \text{Supp}(f_j)\}| \\ &= P_* L^2 \|K\|_\infty^2 h_n^{2\beta} \cdot \frac{n}{M} \end{aligned}$$

Pour  $h_n = \frac{1}{M}$  et  $M = \left\lceil c_0 \left(\frac{n}{\log n}\right)^{\frac{1}{2\beta+1}} \right\rceil$  on arrive à

---  $\leq C \cdot \log n$ .

(18)

Or,  $\log M \geq \log \left( c_0 \left( \frac{m}{\log m} \right)^{\frac{1}{2\beta+1}} \right) \geq \frac{1}{2} \frac{\log m}{2\beta+1}$  pour  $m$  assez grand.

Ainsi,  $\frac{1}{M} \sum_{j=1}^M K(P_j, P_0) \leq \alpha \log M$  où  $\left\{ \begin{array}{l} \alpha = \frac{\|L\|_{\infty}^2}{c_0^{2\beta+1}} \\ M = \left( \frac{m}{\log m} \right)^{\frac{1}{2\beta+1}} \end{array} \right.$

En appliquant la version Kullback de la comparaison de  $M$  hypothèses,

$$\inf_{\hat{T}_n} \sup_{\{f \in \mathcal{L}^{\beta}\}} \mathbb{E}_f \|\hat{T}_n - f\|_{\infty} \geq c \left( \frac{\log m}{m} \right)^{\frac{\beta}{2\beta+1}}$$

pour  $m$  assez grand.