

Partiel 2023/2024 – Durée 1h30

Vous serez évalués sur la démarche et la maîtrise des concepts utilisés. Par conséquent, peu d'importance sera accordée aux constantes numériques. Pour simplifier, **on supposera que tous les ratios de quantités qui nous arrangent sont des entiers** (si cela vous perturbe, libre à vous d'utiliser des parties entières quand nécessaire).

PRÉDICTION PAR HISTOGRAMMES

On se donne $D_n = ((X_1, Y_1), \dots, (X_n, Y_n))$ un échantillon i.i.d. de loi P , où $X_1 \in [0, 1]^2$ p.s. (carré unité de dimension 2) et $Y_1 \in \{0, 1\}$. On cherche à construire $\hat{f} : [0, 1]^2 \rightarrow \{0, 1\}$ en se basant sur D_n , de telle sorte que $\hat{f}(X)$ prédise au mieux Y .

1. De quel type de problème (classification/régression) s'agit-il? Quelle est la fonction de coût standard associée à ce problème?
2. Définir la fonction de risque associée, et rappeler la forme d'un classifieur de Bayes.

On se donne $M \in \mathbb{N}^*$, on découpe le carré $[0, 1]^2$ en $(A_j)_{j=1, \dots, M^2}$ sous-carrés de longueur $1/M$ (formant alors une partition du carré initial), et on définit le classifieur par histogrammes \hat{f}_M via

$$\hat{f}_M(x) = \sum_{j=1}^{M^2} \mathbb{1}_{A_j}(x) \mathbb{1}_{\sum_{i=1}^n (2Y_i - 1) \mathbb{1}_{A_j}(X_i) > 0},$$

pour $x \in [0, 1]^2$.

3. Montrer que \hat{f}_M est un classifieur de type plug-in, c'est à dire du type $\mathbb{1}_{\hat{\eta}_M(x) > (1/2)}$, où $\hat{\eta}_M$ est un estimateur de la fonction de régression $\eta(X) = \mathbb{E}(Y | X)$ que l'on précisera.
4. En notant R_P^* le risque de Bayes, montrer que

$$R_P(\hat{f}_M) - R_P^* \leq 2\sqrt{E_X((\hat{\eta}_M(X) - \eta(X))^2)}.$$

5. Pour $j \in [1, M^2]$, on note $p_j = \mathbb{P}(X \in A_j)$, $\bar{\eta}_j = \mathbb{E}(\eta(X) | X \in A_j)$ (en prenant pour convention $\bar{\eta}_j = 0$ si $p_j = 0$), et

$$\bar{\eta}_M(x) = \sum_{j=1}^{M^2} \bar{\eta}_j \mathbb{1}_{A_j}(x).$$

Montrer que

$$E_X((\hat{\eta}_M(X) - \eta(X))^2) = E_X((\eta(X) - \bar{\eta}_M(X))^2) + E_X((\bar{\eta}_M(X) - \hat{\eta}_M(X))^2).$$

6. **Attention question technique.** En notant $N_j = |\{i \mid X_i \in A_j\}|$, montrer que

$$E_{D_n} [E_X((\bar{\eta}_M(X) - \hat{\eta}_M(X))^2)] \leq \sum_{j=1}^{M^2} p_j \left(\mathbb{E} \left(\frac{1}{2N_j} \mathbb{1}_{N_j \geq 1} \right) + \mathbb{P}(N_j = 0) \right).$$

7. On admet pour le moment les deux inégalités suivantes : si $X \sim \mathcal{B}(n, p)$, alors $\mathbb{E}((X^{-1}) \mathbb{1}_{X>0}) \leq 2/(np)$, et, pour tout $u \in [0, 1]$, $u(1-u)^n \leq 1/n$. En déduire que

$$E_{D_n} [E_X((\bar{\eta}_M(X) - \hat{\eta}_M(X))^2)] \leq \frac{2M^2}{n}.$$

8. On suppose maintenant que η est L -Lipschitz pour la norme infinie. Montrer que

$$E_{D_n} \left(R_P(\hat{f}_M) - R_P^* \right) \leq \frac{2L}{M} + \frac{2\sqrt{2}M}{\sqrt{n}}.$$

9. En choisissant judicieusement M , montrer

$$\inf_{\hat{f}} \sup_{\eta \text{ } L\text{-Lip}} E_{D_n} \left(R_P(\hat{f}) - R_P^* \right) \leq c_0 \left(\frac{L}{\sqrt{n}} \right)^{\frac{1}{2}},$$

pour une constante absolue c_0 .

Point de vue ERM

Pour un M donné et avec les notations précédentes, on note, pour $\sigma \in \{0, 1\}^{M^2}$, f_σ le classifieur donné par

$$f_\sigma(x) = \sum_{j=1}^{M^2} \sigma_j \mathbb{1}_{A_j}(x),$$

et $\mathcal{F}_M = \{f_\sigma \mid \sigma \in \{0, 1\}^{M^2}\}$ l'ensemble des tels classifieurs.

10. Montrer que $\hat{f}_M \in \arg \min_{f \in \mathcal{F}_M} R_n(f)$, où R_n est le risque empirique. En notant $\bar{f}_M = \mathbb{1}_{\bar{\eta}_M > (1/2)}$, montrer que $\bar{f}_M \in \arg \min_{f \in \mathcal{F}_M} R_P(f)$.

11. Soit D la dimension de Vapnik de \mathcal{F}_M . Montrer que $D = M^2$.

12. En déduire un résultat similaire à la question 7 :

$$E_{D_n}(R_P(\hat{f}_M) - R_P(\bar{f}_M)) \leq 2c_0 \sqrt{\frac{M^2}{n}},$$

où c_0 est une constante absolue. **NB : Il n'est pas nécessaire de redémontrer les résultats de cours, préciser pourquoi ils s'appliquent suffira.**

Dans cette partie, le but est de choisir un M adapté au L que l'on ne connaît pas.

13. Pour un M donné, on note

$$Z_M = \sup_{f \in \mathcal{F}_M} |(R_n(f) - R(f))|.$$

Montrer que

$$\mathbb{P} \left(Z_M \geq c_0 \frac{M}{\sqrt{n}} + \sqrt{2vx} \right) \leq e^{-x},$$

avec $v = \frac{1}{4n}$.

14. Construire une famille $(M_j)_{j \in \mathbb{Z}}$ de "modèles" et mettre en oeuvre une stratégie de sélection de modèle pour que le prédicteur final, $\hat{f} = \hat{f}_{M_j}$ vérifie une inégalité de type

$$E_{D_n}(R_P(\hat{f}) - R_P^*) \leq c_0 \left(\frac{L}{\sqrt{n}} \right)^{\frac{1}{2}} + u_n,$$

avec $u_n = o(n^{-1/4})$. Bien évidemment le prédicteur final ne peut pas prendre en compte le L inconnu dans sa conception.

15. Prouver les résultats admis de la question 7-.

SOLUTION

1. Classification (encore que la suite montre que ce n'est pas si claire : dans la première partie on se base sur un problème de régression pour construire un classifieur).
Fonction de coût standard : pour $y, y' \in \{0, 1\}$, $c(y', y) = \mathbb{1}_{y \neq y'}$.
2. Fonction de risque : $R_P(f) = \mathbb{P}(f(X) \neq Y)$. Un classifieur de Bayes : $f^*(X) = \mathbb{1}_{\eta(X) > (1/2)}$, pour $\eta(X) = \mathbb{E}(Y | X)$. Par ailleurs un classifieur est de Bayes ssi il coïncide avec f^* sur $\{\eta(X) \neq (1/2)\}$ p.s..
3. On note $N_j = |\{i | X_i \in A_j\}|$. On remarque que, si $N_j \neq 0$,

$$\begin{aligned} \sum_{i=1}^n (2Y_i - 1) \mathbb{1}_{A_j}(X_i) > 0 &\Leftrightarrow 2 \frac{\sum_{i=1}^n Y_i \mathbb{1}_{X_i \in A_j}}{N_j} > 1 \\ &\Leftrightarrow \hat{\eta}_j > (1/2), \end{aligned}$$

avec $\hat{\eta}_j = \frac{\sum_{i=1}^n Y_i \mathbb{1}_{X_i \in A_j}}{N_j}$. En posant $\hat{\eta}_j = 0$ si $N_j = 0$, et

$$\hat{\eta}_M(x) = \sum_{j=1}^{M^2} \hat{\eta}_j \mathbb{1}_{A_j}(x),$$

on a bien $\hat{f}_M = \mathbb{1}_{\hat{\eta}_M > (1/2)}$.

4. On a

$$\begin{aligned} R_P(\hat{f}_M) - R_P(f^*) &= 2E_X \left(\left| \eta(X) - (1/2) \mathbb{1}_{\hat{f}_M(X) \neq f^*(X)} \right| \right) \\ &= 2E_X \left(\left| \eta(X) - (1/2) \mathbb{1}_{\mathbb{1}_{\hat{\eta}_M(X) > (1/2)} \neq \mathbb{1}_{\eta^*(X) > (1/2)}} \right| \right). \end{aligned}$$

Or, si $\mathbb{1}_{\hat{\eta}_M(X) > (1/2)} \neq \mathbb{1}_{\eta^*(X) > (1/2)}$, on a $|\eta(X) - (1/2)| \leq |\eta(X) - \hat{\eta}_M(X)|$ (il sont forcément de part et d'autre de 1/2). On en déduit

$$\begin{aligned} R_P(\hat{f}_M) - R_P(f^*) &\leq 2E_X (|\hat{\eta}_M(X) - \eta(X)|) \\ &\leq 2\sqrt{E_X((\hat{\eta}_M(X) - \eta(X))^2)} \quad (\text{Jensen}). \end{aligned}$$

5. Pour un j fixé, on a

$$\begin{aligned} E_X((\hat{\eta}_M(X) - \eta(X))^2 \mathbb{1}_{X \in A_j}) &= E_X((\hat{\eta}_j - \eta(X))^2 \mathbb{1}_{X \in A_j}) \\ &= E_X \mathbb{E} [((\hat{\eta}_j - \eta(X))^2 \mathbb{1}_{X \in A_j}) \mid X \in A_j] \\ &= E_X (\mathbb{E} [(\hat{\eta}_j - \bar{\eta}_j)^2 + (\eta(X) - \bar{\eta}_j)^2 \mid X \in A_j] \mathbb{1}_{X \in A_j}) \\ &= E_X((\hat{\eta}_M(X) - \bar{\eta}_M(X))^2 \mathbb{1}_{X \in A_j}) + E_X((\eta(X) - \bar{\eta}_M(X))^2 \mathbb{1}_{X \in A_j}). \end{aligned}$$

En sommant sur les j on obtient le résultat voulu.

6. On a

$$E_X((\bar{\eta}_M(X) - \hat{\eta}_M(X))^2) = \sum_{j|p_j \neq 0} p_j \left[\left(\bar{\eta}_j - \frac{\sum_{i=1}^n Y_i \mathbb{1}_{X_i \in A_j}}{N_j} \right)^2 \mathbb{1}_{N_j \geq 1} + \bar{\eta}_j^2 \mathbb{1}_{N_j = 0} \right]. \quad (1)$$

Travaillons maintenant à j fixé, et commençons par remarquer que

$$E_{D_n}(\bar{\eta}_j^2 \mathbb{1}_{N_j=0}) \leq \mathbb{P}(N_j = 0),$$

car $\bar{\eta}_j \in [0, 1]$. Ensuite, occupons nous du terme en $\mathbb{1}_{N_j \geq 1}$. Conditionnellement à X_1, \dots, X_n , les $Y_i \mathbb{1}_{X_i \in A_j}$ sont indépendantes de loi $\mathbb{1}_{X_i \in A_j} \mathcal{B}(\eta(X_i))$. On peut alors écrire

$$\begin{aligned} &E_{D_n} \left[\left(\bar{\eta}_j - \frac{\sum_{i=1}^n Y_i \mathbb{1}_{X_i \in A_j}}{N_j} \right)^2 \mathbb{1}_{N_j \geq 1} \mid X_1, \dots, X_n \right] \\ &= \left(\left(\bar{\eta}_j - \frac{\sum_{i=1}^n \eta(X_i) \mathbb{1}_{X_i \in A_j}}{N_j} \right)^2 + \frac{1}{N_j^2} \sum_{i=1}^n \eta(X_i)(1 - \eta(X_i)) \mathbb{1}_{X_i \in A_j} \right) \mathbb{1}_{N_j \geq 1} \\ &\leq \left[\left(\bar{\eta}_j - \frac{\sum_{i=1}^n \eta(X_i) \mathbb{1}_{X_i \in A_j}}{N_j} \right)^2 + \frac{1}{4N_j} \right] \mathbb{1}_{N_j \geq 1}, \end{aligned}$$

en utilisant $\eta(X_i)(1 - \eta(X_i)) \leq 1/4$. Notons maintenant $Z_n^j = (\mathbb{1}_{X_i \in A_j})_{i=1, \dots, n}$. Conditionnellement à Z_n^j , les $\eta(X_i)$ restent indépendantes, et on a $\mathbb{E}(\eta(X_i) \mathbb{1}_{X_i \in A_j} \mid Z_n^j) = \bar{\eta}_j \mathbb{1}_{X_i \in A_j}$. Comme $\eta(X_i) \in [0, 1]$, on a de plus $\text{Var}(\eta(X_i) \mid Z_n^j) \leq 1/4$. On en déduit alors

$$\begin{aligned} E_{D_n} \left[\left(\bar{\eta}_j - \frac{\sum_{i=1}^n \eta(X_i) \mathbb{1}_{X_i \in A_j}}{N_j} \right)^2 \mathbb{1}_{N_j \geq 1} \mid Z_n^j \right] &= \text{Var} \left(\frac{\sum_{i=1}^n \eta(X_i) \mathbb{1}_{X_i \in A_j}}{N_j} \mid Z_n^j \right) \mathbb{1}_{N_j \geq 1} \\ &= \frac{1}{N_j^2} \sum_{i=1}^n \text{Var}(\eta(X_i) \mid Z_n^j) \mathbb{1}_{X_i \in A_j} \mathbb{1}_{N_j \geq 1} \\ &\leq \frac{1}{4N_j} \mathbb{1}_{N_j \geq 1}. \end{aligned}$$

En recollant tous les morceaux de (1), on obtient le résultat voulu.

7. En remarquant que $N_j \sim \mathcal{B}(n, p_j)$, on obtient $\mathbb{E}(N_j^{-1} \mathbb{1}_{N_j \geq 1}) \leq 2/(np_j)$. Par ailleurs, on a, à j fixé,

$$p_j \mathbb{P}(N_j = 0) = p_j(1 - p_j)^n \leq \frac{1}{n}.$$

On en déduit alors

$$\begin{aligned} \sum_{j=1}^{M^2} p_j \left(E_{D_n} \left(\frac{1}{2N_j} \mathbb{1}_{N_j \geq 1} \right) + \mathbb{P}(N_j = 0) \right) &\leq \sum_{j=1}^{M^2} \left(\frac{1}{n} + \frac{1}{n} \right) \\ &\leq \frac{2M^2}{n}, \end{aligned}$$

ce dont on déduit l'inégalité voulue.

8. Si η est L -Lipschitz, on a, pour tout j tel que $p_j > 0$, et $x \in A_j$,

$$|\bar{\eta}_j - \eta(x)| \leq \frac{L}{M}.$$

On en déduit alors

$$\begin{aligned} E_X((\eta(X) - \bar{\eta}_M(X))^2) &\leq \sup_{j=1, \dots, M^2} p_j \frac{L^2}{M^2} \\ &\leq \frac{L^2}{M^2}. \end{aligned}$$

En utilisant le résultat de la question 4–, on déduit

$$E_{D_n} \left(R_P(\hat{f}_M) - R_P^* \right) \leq 2 \left[\frac{L}{M} + \frac{M\sqrt{2}}{\sqrt{n}} \right].$$

9. Optimiser la somme revient à choisir $M = \frac{\sqrt{Ln}^{1/4}}{2^{1/4}}$, ce qui donne

$$\inf_{\hat{f}} \sup_{\eta \text{ L-Lip}} E_{D_n} \left(R_P(\hat{f}) - R_P^* \right) \leq \sup_{\eta \text{ L-Lip}} E_{D_n} \left(R_P(\hat{f}_M) - R_P^* \right) \leq 4 \times 2^{1/4} \left(\frac{L}{\sqrt{n}} \right)^{\frac{1}{2}}.$$

C'est bien la vitesse optimale (en terme de n et L). Toutefois le prédicteur proposé prend en compte la constante L . On aimerait trouver un prédicteur qui s'adapte au L inconnue : on parle de procédure adaptative.

10. Pour $\sigma \in \{0, 1\}^{M^2}$, on peut écrire

$$R_n(f_\sigma) = \sum_{j=1}^{M^2} \sum_{i|X_i \in A_j} \mathbb{1}_{\sigma_j \neq Y_i}.$$

Or, à j fixé,

$$\sum_{i|X_i \in A_j} \mathbb{1}_{\sigma_j \neq Y_i} = \mathbb{1}_{\sigma_j=0} \sum_{i=1}^n Y_i \mathbb{1}_{X_i \in A_j} + \mathbb{1}_{\sigma_j=1} \sum_{i=1}^n (1 - Y_i) \mathbb{1}_{X_i \in A_j}$$

est minimal pour $\sigma_j = \mathbb{1}_{\sum_{i=1}^n (2Y_i - 1) \mathbb{1}_{A_j}(X_i) > 0}$, et donc pour $f_\sigma = \hat{f}_M$. Pareillement, on peut écrire

$$R_P(f_\sigma) = \sum_{j=1}^{M^2} p_j \mathbb{E}(Y \mathbb{1}_{A_j}(X) \neq \sigma_j),$$

et, à j fixé tel que $p_j \neq 0$ (ailleurs on peut mettre ce qu'on veut comme label),

$$\begin{aligned} \mathbb{E}(\mathbb{1}_{Y \neq \sigma_j} \mathbb{1}_{A_j}(X)) &= \mathbb{1}_{\sigma_j=0} E_X(\eta(X) \mathbb{1}_{A_j}(X)) + \mathbb{1}_{\sigma_j=1} E_X((1 - \eta(X)) \mathbb{1}_{A_j}(X)) \\ &= \mathbb{1}_{\sigma_j=0} E_X(\bar{\eta}_j \mathbb{1}_{A_j}(X)) + \mathbb{1}_{\sigma_j=1} E_X((1 - \bar{\eta}_j) \mathbb{1}_{A_j}(X)) \\ &= p_j (\mathbb{1}_{\sigma_j=0} \bar{\eta}_j + \mathbb{1}_{\sigma_j=1} (1 - \bar{\eta}_j)), \end{aligned}$$

qui est minimal pour $\sigma_j = \mathbb{1}_{\bar{\eta}_j > (1/2)}$, et donc pour $f_\sigma = \bar{f}_M$.

11. En notant $D_M = M^2$. Si on se donne (x_1, \dots, x_{D_M}) tel que pour tout j $x_j \in A_j$, alors, pour tout $\sigma \in \{0, 1\}^{D_M}$, on aura bien $f_\sigma(x_j) = \sigma_j$, et donc

$$|\{(f_\sigma(x_1), \dots, f_\sigma(x_{D_M})) \mid \sigma \in \{0, 1\}^{D_M}\}| = 2^{D_M},$$

ce dont on déduit $D \geq D_M$.

Dans l'autre sens, soit $(x_1, \dots, x_{D_M+1}) \in ([0, 1]^2)^{D_M+1}$. $(A_j)_{j=1, \dots, D_M}$ formant une partition de $[0, 1]^2$, il existe $j_1 \neq j_2 \leq D_M + 1$ et $j_0 \leq D_M$ tels que $x_{j_1}, x_{j_2} \in A_{j_0}$. Dans ce cas, si $\varepsilon \in \{0, 1\}^{D_M+1}$ est tel que $\varepsilon_{j_1} \neq \varepsilon_{j_2}$, il ne peut exister de $\sigma \in \{0, 1\}^{D_M}$ tel que $f_\sigma(x_{j_1}) = \varepsilon_{j_1}$ et $f_\sigma(x_{j_2}) = \varepsilon_{j_2}$ (rappelons que les f_σ sont constantes sur les A_j). On en déduit alors que

$$\forall (x_1, \dots, x_{D_M+1}) \quad |\{(f_\sigma(x_1), \dots, f_\sigma(x_{D_M+1})) \mid \sigma \in \{0, 1\}^{D_M}\}| < 2^{D_M+1},$$

et donc que $D < D_M + 1$.

12. En utilisant un résultat de cours sur les ERM (symétrisation puis inégalité entropique de Dudley), on a

$$\begin{aligned} E_{D_n}(R_P(\hat{f}_M) - R_P(\bar{f}_M)) &\leq \mathbb{E} \left(\sup_{f \in \mathcal{F}_M} |(R_n(f) - R_P(f))| \right) \\ &\leq 2E_{D_n} E_\varepsilon \left(\sup_{f \in \mathcal{F}_M} \frac{1}{n} \sum_{i=1}^n \varepsilon_i \mathbb{1}_{Y_i \neq f(X_i)} \right) \\ &\leq 2c_0 \frac{\sqrt{D}}{\sqrt{n}}, \end{aligned}$$

où les $\varepsilon_1, \dots, \varepsilon_n$ sont des variables de Rademacher i.i.d..

13. D'après la question précédente, on sait déjà que

$$\mathbb{E}(Z_M) \leq c_0 \frac{M}{\sqrt{n}}.$$

Par ailleurs, si on pose $Z_M = g(V_1, \dots, V_n)$, où $V_i = (X_i, Y_i)$, on a, pour tout $i \in \llbracket 1, n \rrbracket$,

$$|g(x_1, \dots, x_i, \dots, x_n) - g(x_1, \dots, x'_i, \dots, x_n)| \leq 1/n.$$

L'inégalité de Mac Diarmid donne alors

$$\mathbb{P} \left(Z_M \geq E(Z_M) + \sqrt{2 \frac{1}{4n} x} \right) \leq e^{-x},$$

correspondant à des queues sous-Gaussiennes de variance $v = \frac{1}{4n}$.

14. Posons $M_j = 2^j$, pour $j \in \mathbb{Z}$, et

$$\text{pen}(j) = c_0 \frac{M_j}{\sqrt{n}} + \sqrt{\frac{\log(2) + \log(\frac{\pi^2}{3}(j \vee 1)^2)}{2n}}.$$

On a alors

$$\mathbb{P} \left(\bigcup_{j \in \mathbb{Z}} Z_{M_j} \leq \text{pen}(j) + \sqrt{x/2} \right) \geq 1 - \left(\frac{1}{2} + \frac{1}{2} \sum_{j \in \mathbb{Z}^*} \frac{1}{j^2} \times \frac{3}{\pi^2} \right) e^{-x} \geq 1 - e^{-x}.$$

Dans la suite on se place sur cet évènement. On choisit alors

$$\hat{j} \in \arg \min_{j \in \mathbb{Z}} R_n(\hat{f}_{M_j}) + \text{pen}(j).$$

On peut alors écrire, pour un j quelconque

$$\begin{aligned}
R_P(\hat{f}_{\hat{j}}) - R_P^* &\leq R_n(\hat{f}_{\hat{j}}) + \text{pen}(\hat{j}) + \sqrt{x/(2n)} - R_P^* \\
&\leq R_n(\hat{f}_j) + \text{pen}(j) + \sqrt{x/(2n)} - R_P^* \\
&\leq R_n(\bar{f}_j) + \text{pen}(j) + \sqrt{x/(2n)} - R_P^* \\
&\leq R_P(\bar{f}_j) - R_P^* + 2\text{pen}(j) + \sqrt{2x/n}.
\end{aligned}$$

Essayons maintenant de déterminer $\inf_j R_P(\bar{f}_j) - R_P^* + 2\text{pen}(j)$. En utilisant les bornes obtenues en question 8 et 4, on a

$$R_P(\bar{f}_j) - R_P^* \leq \frac{2L}{M_j},$$

et donc

$$\begin{aligned}
R_P(\bar{f}_j) - R_P^* &\leq \frac{2L}{M_j} + 2\text{pen}(j) \\
&\leq 2^{1-j}L + c_0 \frac{2^{j+1}}{\sqrt{n}} + 2\sqrt{\frac{\log(2) + \log(\frac{\pi^2}{3}(j \vee 1)^2)}{2n}}.
\end{aligned}$$

Posons maintenant $j^* = \lfloor \frac{1}{2} \log_2 \left(\frac{\sqrt{n}L}{c_0} \right) \rfloor$, de sorte que

$$\frac{1}{2} \left(\frac{\sqrt{n}L}{c_0} \right)^{1/2} \leq 2^{j^*} \leq \left(\frac{\sqrt{n}L}{c_0} \right)^{1/2}.$$

On a d'une part

$$2^{1-j^*}L + c_0 \frac{2^{j^*+1}}{\sqrt{n}} \leq 6\sqrt{c_0} \left(\frac{L}{\sqrt{n}} \right)^{1/2},$$

et d'autre part

$$2\sqrt{\frac{\log(2) + \log(\frac{\pi^2}{3}(j^* \vee 1)^2)}{2n}} \leq \frac{\sqrt{2}}{\sqrt{n}} \sqrt{\log(2) + \log \left(\frac{\pi^2}{3} \left(\frac{1}{4} \log_2^2 \left(\frac{\sqrt{n}L}{c_0} \right) \vee 1 \right) \right)} := v_n,$$

avec $v_n \sim \log(n)/\sqrt{n} = o(n^{-1/4})$. On en déduit alors que, en posant $\hat{f} = \hat{f}_{\hat{j}}$

$$\mathbb{P} \left(R_P(\hat{f}) - R_P^* - 6\sqrt{c_0} \left(\frac{L}{\sqrt{n}} \right)^{1/2} - v_n \geq \sqrt{2x/n} \right) \leq e^{-x}.$$

En posant $\Delta_n = R_P(\hat{f}) - R_P^* - 6\sqrt{c_0} \left(\frac{L}{\sqrt{n}}\right)^{\frac{1}{2}} - v_n$, on déduit

$$\begin{aligned} E_{D_n} \Delta_n &\leq E_{D_n} \Delta_n^+ = \int_0^{+\infty} \mathbb{P}(\Delta_n > t) dt \\ &\leq \int_0^{+\infty} e^{-\frac{nt^2}{2}} \\ &\leq \frac{1}{2} \sqrt{\frac{2\pi}{n}}. \end{aligned}$$

En posant $u_n = v_n + \sqrt{\frac{\pi}{2n}} = o(n^{-1/4})$, on a bien

$$E_{D_n}(R_P(\hat{f}) - R_P^*) \leq 6\sqrt{c_0} \left(\frac{L}{\sqrt{n}}\right)^{\frac{1}{2}} + u_n,$$

on a donc construit une procédure optimale ne prenant pas en compte la constante de Lipschitz inconnue de la fonction de régression cible.

15. Posons $g(u) = u(1-u)^n$, pour $u \in [0, 1]$. On a $g'(u) = (1-u)^{n-1}((1-u) - nu)$. Le maximum est donc atteint en $u = 1/(n+1)$, et est inférieur à $1/(n+1)$ (donc à $1/n$). Maintenant soit $X \sim \mathcal{B}(n, p)$. On a

$$\mathbb{E}(X^{-1} \mathbb{1}_{X \geq 1}) = \sum_{k=1}^n \frac{1}{k} \binom{n}{k} p^k (1-p)^{n-k}.$$

Or, pour $k \geq 1$,

$$\frac{1}{k} \binom{n}{k} \leq \frac{2}{k+1} \binom{n}{k} \leq \frac{2}{n+1} \binom{n+1}{k+1}.$$

On en déduit

$$\mathbb{E}(X^{-1} \mathbb{1}_{X \geq 1}) \leq \frac{2}{(n+1)p} \sum_{k=1}^n \binom{n+1}{k+1} p^{k+1} (1-p)^{(n+1)-(k+1)} \leq \frac{2}{(n+1)p} \leq \frac{2}{np}.$$