

## 1 Complexité de Rademacher

**Exercice 1. Inégalité de Ledoux** Le but de cet exercice est de prouver le théorème suivant :

*Theorème 1 (Inégalité de Ledoux).* Si  $\varphi$  est  $B$ -Lipshitz et  $\varepsilon_1^n = \{\varepsilon_i\}_{i=1}^n$  est une suite i.i.d. de variables Rad(1/2), nous avons

$$\mathbb{E} \left[ \sup_{\theta \in \Theta} \frac{1}{n} \sum_{i=1}^n \varepsilon_i \varphi(\theta^\top x_i) \right] \leq B \mathbb{E} \left[ \sup_{\theta \in \Theta} \frac{1}{n} \sum_{i=1}^n \varepsilon_i \theta^\top x_i \right].$$

Nous allons montrer par récurrence que pour tout  $k \in \{1, \dots, n\}$ , **toutes fonctions**  $b : \Theta \rightarrow \mathbb{R}$ ,  $a_i : \Theta \rightarrow \mathbb{R}$ ,  $i \in \{1, \dots, k\}$  et toutes fonctions 1-Lipshitz  $\varphi_i : \mathbb{R} \rightarrow \mathbb{R}$ ,  $i = 1, \dots, k$ ,

$$\mathbb{E} \left[ \sup_{\theta \in \Theta} b(\theta) + \sum_{i=1}^k \varepsilon_i \varphi_i(a_i(\theta)) \right] \leq \mathbb{E} \left[ \sup_{\theta \in \Theta} b(\theta) + \sum_{i=1}^k \varepsilon_i a_i(\theta) \right] \quad (1)$$

1. Pour toutes fonctions  $\varphi, \psi : \Theta \rightarrow \mathbb{R}$  et  $\varepsilon \sim \text{Rad}(1/2)$ , montrer que :

$$\begin{aligned} \mathbb{E} \left[ \sup_{\theta \in \Theta} \{\varphi(\theta) + \varepsilon \psi(\theta)\} \right] &= \frac{1}{2} \left[ \sup_{\theta, \theta' \in \Theta^2} \{\varphi(\theta) + \varphi(\theta') + \psi(\theta) - \psi(\theta')\} \right] \\ &= \frac{1}{2} \left[ \sup_{\theta, \theta' \in \Theta^2} \{\varphi(\theta) + \varphi(\theta') + |\psi(\theta) - \psi(\theta')|\} \right] \end{aligned} \quad (2)$$

2. Supposons que (1) est vérifiée pour  $k \in \mathbb{N}$ . Montrer que

$$\begin{aligned} &\mathbb{E} \left[ \sup_{\theta \in \Theta} b(\theta) + \sum_{i=1}^{k+1} \varepsilon_i \varphi_i(a_i(\theta)) \right] \\ &\leq \mathbb{E} \left[ \mathbb{E} \left[ \sup_{\theta, \theta' \in \Theta} \frac{b(\theta) + b(\theta')}{2} + \sum_{i=1}^k \varepsilon_i \frac{\varphi_i(a_i(\theta)) + \varphi_i(a_i(\theta'))}{2} + \frac{|a_{k+1}(\theta) - a_{k+1}(\theta')|}{2} \middle| \varepsilon_1^k \right] \right] \\ &= \mathbb{E} \left[ \mathbb{E} \left[ \sup_{\theta \in \Theta} b(\theta) + \sum_{i=1}^k \varepsilon_i \varphi_i(a_i(\theta)) + \varepsilon_{k+1} a_{k+1}(\theta) \middle| \varepsilon_1^k \right] \right] \\ &= \mathbb{E} \left[ \sup_{\theta \in \Theta} b(\theta) + \sum_{i=1}^{k+1} \varepsilon_i a_i(\theta) \right] \end{aligned}$$

3. Conclure.

**Exercice 2 (Dernière étape pour calculer la borne supérieure de la complexité de Rademacher).** Nous considérons  $X_1^n = \{X_i\}_{i=1}^n$  un  $n$ -échantillon de distribution  $\mathbb{P}$ . Nous supposons qu'il existe  $R > 0$ , tel que  $\mathbb{E}[\|X\|^2] \leq R^2$ . On considère  $\varepsilon_1^n = \{\varepsilon_i\}_{i=1}^n$  une suite de variables aléatoires indépendantes de Rademacher  $\mathcal{R}(1/2)$  indépendante de  $X_1^n$ . Montrer que :

$$\mathbb{E} \left[ \sup_{\|\theta\| \leq D} \frac{1}{n} \sum_{i=1}^n \varepsilon_i \theta^\top X_i \right] \leq \frac{RD}{\sqrt{n}}. \quad (3)$$

**Exercice 3 (Inégalité de McDiarmid).** Le but de cet exercice est de prouver l'inégalité de McDiarmid, énoncée ci-dessous :

*Dfinition 1 (Fonction de différence bornée).*  $g : Z^n \rightarrow \mathbb{R}$  est une fonction de différence bornée s'il existe des constantes  $\{c_i\}_{i=1}^n$  telles que, pour tout  $z_1^n = \{z_i\}_{i=1}^n$  et  $\tilde{z}_1^n = \{\tilde{z}_i\}_{i=1}^n$ ,

$$|g(z_1^n) - g(\tilde{z}_1^n)| \leq \sum_{i=1}^n c_i \mathbb{1}_{\{z_i \neq \tilde{z}_i\}}.$$

*Theorème 2 (Inégalité de McDiarmid).* Si  $g$  est une fonction de différence bornée et  $Z_i$  sont des variables aléatoires indépendantes alors

$$\begin{aligned} \mathbb{P}(g(Z_1, \dots, Z_n) - \mathbb{E}[g(Z_1, \dots, Z_n)] \geq \varepsilon) &\leq e^{-\frac{2\varepsilon^2}{\sum_{i=1}^n c_i^2}} \\ \mathbb{P}(\mathbb{E}[g(Z_1, \dots, Z_n)] - g(Z_1, \dots, Z_n) \geq \varepsilon) &\leq e^{-\frac{2\varepsilon^2}{\sum_{i=1}^n c_i^2}} \end{aligned}$$

Pour  $i \in \{1, \dots, n\}$  et  $z_1^i = (z_1, \dots, z_i) \in Z^i$ , nous posons  $g_i(z_1^i) = \mathbb{E}[g(z_1^i, Z_{i+1}^n)]$ . Par convention, nous posons  $g_0 = \mathbb{E}[g(Z_1^n)]$ . Notons que  $g_n(z_1^n) = g(z_1^n)$ , pour tout  $i \in \{1, \dots, n\}$ ,  $\mathbb{E}[g_i(Z_1^i)] = \mathbb{E}[g(Z_1^n)]$  et pour  $n \geq 1$

$$g(z_1^n) = g_n(z_1^n) = g_n(z_1^n) - g_{n-1}(z_1^{n-1}) + g_{n-1}(z_1^{n-1}) = \sum_{j=1}^n \{g_j(z_1^j) - g_{j-1}(z_1^{j-1})\},$$

avec la convention que  $g_0(z_1^0) = g_0$ .

1. Montrer que pour tout  $\lambda \in \mathbb{R}$ ,

$$\mathbb{E} \left[ e^{\lambda \{g_n(Z_1^n) - g_0\}} \right] = \mathbb{E} \left[ \mathbb{E} \left[ e^{\lambda \{g_n(Z_1^n) - g_{n-1}(Z_1^{n-1})\}} \mid Z_1^{n-1} \right] e^{\lambda \{g_{n-1}(Z_1^{n-1}) - g_0\}} \right]$$

2. Montrer que pour tout  $i \in \{1, \dots, n\}$ ,  $\inf_{z \in Z} g_i(z_1^{i-1}, z) \leq g_i(z_1^i) \leq \inf_{z \in Z} g_i(z_1^{i-1}, z) + c_i$  et que

$$g_{i-1}(Z_1^{i-1}) = \mathbb{E} \left[ g_i(Z_1^i) \mid Z_1^{i-1} \right], \quad \mathbb{P} - \text{p.s.}$$

3. En déduire que

$$\mathbb{E} \left[ e^{\lambda \{g_n(Z_1^n) - g_{n-1}(Z_1^{n-1})\}} \mid Z_1^{n-1} \right] \leq e^{\lambda^2 c_n^2 / 8}.$$

4. Montrer que :

$$\mathbb{E} \left[ e^{\lambda \{g(Z_1, \dots, Z_n) - \mathbb{E}[g(Z_1, \dots, Z_n)]\}} \right] \leq e^{\frac{\lambda^2 \sum_{i=1}^n c_i^2}{8}}.$$

5. Prouver le théorème

Nous considérons

$$\Delta_{n,01}(\mathcal{C}) = \sup_{f \in \mathcal{C}} R(f) - \widehat{R}_{n,01}(f) = \sup_{f \in \mathcal{C}} \left( \mathbb{E}[\ell_{01}(Y, f(X))] - \frac{1}{n} \sum_{i=1}^n \ell_{01}(Y_i, f(X_i)) \right).$$

6. Montrer que

$$\mathbb{P}(\Delta_n(\mathcal{C}) - \mathbb{E}[\Delta_n(\mathcal{C})] \leq \varepsilon) \geq 1 - e^{-2n\varepsilon^2}$$

## 2 Convexification du risque

**Exercice 4 (Lemme de Zhang, (cours)).** On considère le problème de classification binaire, où  $y \in \{\pm 1\}$ . Nous considérons également la règle de prédiction suivante : prédire  $y = 1$  si  $g(x) \geq 0$ , et prédire  $y = -1$  sinon. La perte 0-1 de classification de  $g(\cdot)$  en un point  $(x, y)$  est donnée par

$$\ell_{01}(g(x), y) = \begin{cases} 1, & \text{si } -g(x)y > 0, \\ 1, & \text{si } g(x) = 0 \text{ et } y = -1, \\ 0, & \text{sinon.} \end{cases}$$

Notre objectif est de trouver un prédicteur  $g(x)$  de sorte à minimiser le risque 0-1 :  $R_{01}(g) = \mathbb{E}[\ell_{01}(g(X), Y)]$ . Étant donné un ensemble de données d'apprentissage  $\mathcal{D}_n = \{(X_i, Y_i)\}_{i=1}^n$  i.i.d. la minimisation du risque empirique 0-1 consiste à trouver  $g$  dans une classe de fonctions  $\mathcal{C}$  qui minimise

$$\widehat{R}_{n,01}(g) = \frac{1}{n} \sum_{i=1}^n \ell_{01}(g(X_i), Y_i) \quad (4)$$

1. Pourquoi la minimisation du risque empirique  $\widehat{R}_{n,01}$  est elle problématique ?

Soit  $\phi : \mathbb{R} \rightarrow \mathbb{R}_+$  une fonction convexe. On considère la minimisation dans une classe de fonctions  $\mathcal{C}$  du risque empirique suivant

$$\widehat{R}_{n,\phi}(g) = \frac{1}{n} \sum_{i=1}^n \phi(-g(X_i) Y_i),$$

qui est une approximation stochastique du risque  $R_\phi(g) = \mathbb{E}[\phi(-g(X)Y)]$ .

2. Montrer que

$$R_\phi(g) = \mathbb{E}[\eta(X)\phi(-g(X)) + (1 - \eta(X))\phi(g(X))]$$

où  $\eta(X) = \mathbb{P}(Y = +1 | X)$ .

On rappelle les exemples suivants :

Nom de la perte	Perte $\phi$	Nom de la méthode
Moindres carrés	$\phi_2(v) = (1 + v)^2$	Moindres carrés.
Hinge	$\phi_H(v) = \max(1 + v, 0)$	SVM
Exponentielle	$\phi_E(v) = \exp(v)$	AdaBoost
Logistique	$\phi_L(v) = \log_2(1 + \exp(v))$	Régression Logistique

3. Quelles sont les propriétés cruciales de ces fonctions qui permettront de les optimiser ?

Montrer que pour tous les exemples ci dessus (sauf  $\phi_2$ ),

$$\phi \text{ est croissante, convexe, et } \phi(v) \geq \mathbb{1}_{\{v \geq 0\}}. \quad (\text{H1})$$

On s'intéresse dans la suite à une fonction  $\phi$  générique satisfaisant (H1). Au regard de la question 2, nous considérons la fonction  $H_\phi : [0, 1] \times \mathbb{R} \rightarrow \mathbb{R}$

$$H_\phi(\eta, p) = \eta\phi(-p) + (1 - \eta)\phi(p).$$

4. Montrer que  $p \mapsto H_\phi(\eta, p)$  est convexe.

5. Montrer que pour  $\eta \in ]0; 1[$ ,  $p \mapsto H_\phi(\eta, p)$  admet un minimum unique dans  $\mathbb{R}$ , pour  $\phi \in \{\phi_2, \phi_E, \phi_L\}$ . Qu'en est il pour  $\phi_H$ ? Qu'en est il pour  $\eta \in \{0; 1\}$ ?

Nous supposons dans la suite qu'il existe une fonction  $p_\phi^*(\eta) : [0, 1] \rightarrow \bar{\mathbb{R}}$  défini par <sup>1</sup>

$$p_\phi^*(\eta) = \arg \min_{p \in \mathbb{R}} H_\phi(\eta, p), \quad g_\phi^*(x) = p_\phi^* \circ \eta(x)$$

et nous notons

$$H_\phi^*(\eta) = \inf_{p \in \mathbb{R}} H_\phi(\eta, p) = H_\phi(\eta, p_\phi^*(\eta)),$$

$$\Delta H_\phi(\eta, p) = H_\phi(\eta, p) - H_\phi(\eta, p_\phi^*(\eta)) = H_\phi(\eta, p) - H_\phi^*(\eta).$$

Par symétrie, nous avons  $H_\phi(\eta, p) = H_\phi(1 - \eta, -p)$ . Lorsque que  $p_\phi^*(\eta)$  n'est pas déterminé de manière unique, on choisit un minimiseur quelconque mais on suppose dans la suite que  $p_\phi^*$  est choisi de telle sorte que  $p_\phi^*(1 - \eta) = -p_\phi^*(\eta)$ . En particulier, elle implique que  $p_\phi^*(1/2) = 0$ .

### Le prédicteur bayésien pour la perte $\phi$ est le prédicteur bayésien pour la perte 01

6. Montrer que :  $g_\phi^* \in \arg \min_{g \in \mathbb{R}^{\mathcal{X}}} R_\phi(g)$  et pour tout  $g$  :

$$\Delta R_\phi(g) = R_\phi(g) - R_\phi(g_\phi^*) = \mathbb{E}[\Delta H_\phi(\eta(X), g(X))]$$

7. Montrer que :

Nom de la perte	$p_\phi^*$	$H_\phi^*$
Moindres carrés	$p_\phi^*(\eta) = 2\eta - 1$	$H_\phi^*(\eta) = 4\eta(1 - \eta)$ .
Hinge	$p_\phi^*(\eta) = \text{sign}(2\eta - 1)$	$H_\phi^*(\eta) = 1 -  2\eta - 1 $ .
Logistique	$p_\phi^*(\eta) = \log_2 \frac{\eta}{1-\eta}$	$H_\phi^*(\eta) = -\eta \log_2 \eta - (1 - \eta) \log_2(1 - \eta)$ .

8. Montrer que pour  $\phi \in \{\phi_2, \phi_H, \phi_E, \phi_L\}$ , la règle de décision  $\text{signe}(g_\phi^*)$  est un classifieur de Bayes pour la perte 0 - 1.

9. Supposons que  $\phi$  est croissante, convexe et différentiable. Montrer que  $\text{signe}(g_\phi^*)$  est la règle de décision bayésienne pour la perte 0-1.

### Controle de l'excès de risque pour la perte 01 par l'excès de risque pour la perte $\phi$ .

Supposons que  $p_\phi^*(\eta) > 0$  lorsque  $\eta > 1/2$  et qu'il existe  $c > 0$  et  $s \geq 1$  tels que pour toute  $\eta \in [0, 1]$ ,

$$|1/2 - \eta|^s \leq c^s \Delta H_\phi(\eta, 0). \quad (\text{H2})$$

L'objectif de cet partie est d'établir que pour toute fonction mesurable  $g(x)$  .

$$R_{01}(g) - R_{01}^* \leq 2c \Delta R_\phi(g)^{1/s},$$

où  $R^*$  est l'erreur de Bayes optimale pour la perte 0 - 1.

1. Soit  $\bar{\mathbb{R}}$  la droite réelle étendue ( $\bar{\mathbb{R}} = \mathbb{R} \cup \{-\infty, +\infty\}$ ). Nous étendons une fonction convexe  $\psi : \bar{\mathbb{R}} \rightarrow \bar{\mathbb{R}}$  en définissant  $\psi(\infty) = \lim_{x \rightarrow \infty} \psi(x)$  et  $\psi(-\infty) = \lim_{x \rightarrow -\infty} \psi(x)$ . Elle garantit que le minimiseur optimal  $p_\phi^*(\eta)$  donné ci-dessous est bien défini à  $\eta = 0$  ou 1 pour certaines fonctions de perte.

10. Montrer que

$$R_{01}(g) - R_{01}^* \leq 2c \left( \mathbb{E}[\mathbb{1}_{\{(2\eta(X)-1)g(X) \leq 0\}} \Delta H_\phi(\eta(X), 0)] \right)^{1/s}.$$

11. Montrer que

$$(2\eta(x) - 1)g(x) < 0 \Rightarrow \Delta H_\phi(\eta(x), 0) \leq \Delta H_\phi(\eta(x), g(x))$$

12. Montrer que la condition (H2) est vérifiée avec  $c = \frac{1}{2}$ ,  $s = 2$ . pour le critère quadratique.

13. Montrer que la condition (H2) est vérifiée avec  $c = \frac{1}{2}$ ,  $s = 1$  pour la perte hinge.

14. Montrer que la condition (H2) est vérifiée avec  $c = \sqrt{\ln 2/2}$ ,  $s = 2$  pour la perte logistique.

### 3 Solutions

**Solution Exercice 1. :** 1. On remarque que

$$\begin{aligned}\mathbb{E} \left[ \sup_{\theta \in \Theta} \{\varphi(\theta) + \psi(\theta)\varepsilon_i\} \right] &= \frac{1}{2} \left( \sup_{\theta \in \Theta} \{\varphi(\theta) + \psi(\theta)\} + \sup_{\theta \in \Theta} \{\varphi(\theta) - \psi(\theta)\} \right) \\ &= \frac{1}{2} \left( \sup_{\theta, \theta' \in \Theta^2} \{\varphi(\theta) + \varphi(\theta') + \{\psi(\theta) - \psi(\theta')\}\} \right) \\ &= \frac{1}{2} \left( \sup_{\theta, \theta' \in \Theta^2} \{\varphi(\theta) + \varphi(\theta') + \{\psi(\theta) - \psi(\theta')\}\} \right)\end{aligned}$$

2. En utilisant la question précédente, nous obtenons

$$\begin{aligned}\mathbb{E} \left[ \sup_{\theta \in \Theta} b(\theta) + \sum_{i=1}^{k+1} \varepsilon_i \varphi_i(a_i(\theta)) \middle| \varepsilon_1^k \right] \\ &= \frac{1}{2} \mathbb{E} \left[ \sup_{\theta, \theta' \in \Theta} \{b(\theta) + b(\theta')\} + \sum_{i=1}^k \varepsilon_i \{\varphi_i(a_i(\theta)) + \varphi_i(a_i(\theta'))\} + |\varphi_{k+1}(a_{k+1}(\theta)) - \varphi_{k+1}(a_{k+1}(\theta'))| \middle| \varepsilon_1^k \right] \\ &\leq \frac{1}{2} \mathbb{E} \left[ \sup_{\theta, \theta' \in \Theta} \{b(\theta) + b(\theta')\} + \sum_{i=1}^k \varepsilon_i \{\varphi_i(a_i(\theta)) + \varphi_i(a_i(\theta'))\} + |a_{k+1}(\theta) - a_{k+1}(\theta')| \middle| \varepsilon_1^k \right] =: B_k\end{aligned}$$

En appliquant de nouveau (2) avec  $\psi_{k+1}(x) = x$ , nous en déduisons

$$B_k := \mathbb{E} \left[ \sup_{\theta \in \Theta} b(\theta) + \varepsilon_{k+1} a_{k+1}(\theta) + \sum_{i=1}^k \varepsilon_i \varphi_i(a_i(\theta)) \middle| \varepsilon_1^k \right]$$

Comme nous avons,

$$\mathbb{E}[B_k] = \mathbb{E} \left[ \mathbb{E} \left[ \sup_{\theta \in \Theta} b(\theta) + \varepsilon_{k+1} a_{k+1}(\theta) + \sum_{i=1}^k \varepsilon_i \varphi_i(a_i(\theta)) \middle| \varepsilon_{k+1} \right] \right]$$

nous pouvons utiliser l'hypothèse de récurrence (1) avec  $b \leftarrow b + \varepsilon_{k+1} a_{k+1}$ , ce qui montre

$$\mathbb{E}[B_k] \leq \mathbb{E} \left[ \sup_{\theta \in \Theta} b(\theta) + \sum_{i=1}^{k+1} \varepsilon_i \varphi_i(a_i(\theta)) \right]$$

Ce qui donne le résultat

**Solution Exercice 2. :** On a :

$$\begin{aligned}
\mathbb{E} \left[ \sup_{\|\theta\| \leq D} \frac{1}{n} \sum_{i=1}^n \varepsilon_i \theta^\top X_i \right] &= \mathbb{E} \left[ \sup_{\|\theta\| \leq D} \theta^\top \frac{1}{n} \sum_{i=1}^n \varepsilon_i X_i \right] \\
&\stackrel{CS}{\leq} \mathbb{E} \left[ \sup_{\|\theta\| \leq D} \|\theta\| \left\| \frac{1}{n} \sum_{i=1}^n \varepsilon_i X_i \right\| \right] \\
&\stackrel{\text{Jensen}}{\leq} D \left( \mathbb{E} \left[ \left\| \frac{1}{n} \sum_{i=1}^n \varepsilon_i X_i \right\|^2 \right] \right)^{1/2} \\
&\stackrel{\mathbb{E}[\varepsilon_i \varepsilon_j] = 0}{\leq} D \left( \mathbb{E} \left[ \frac{1}{n} \sum_{i=1}^n \varepsilon_i^2 \|X_i\|^2 \right] \right)^{1/2} \\
&\leq \frac{RD}{\sqrt{n}}.
\end{aligned}$$

**Solution Exercice 3. :** 1. Comme par construction  $g_n(z_1^n) - g_0 = g_n(z_1^n) - g_{n-1}(z_1^{n-1}) + g_{n-1}(z_1^{n-1}) - g_0$  nous avons

$$\begin{aligned}
\mathbb{E}[e^{\lambda(g_n(Z_1^n) - g_0)}] &= \mathbb{E}[e^{\lambda(g_n(Z_1^n) - g_{n-1}(Z_1^{n-1}))} e^{\lambda(g_{n-1}(Z_1^{n-1}) - g_0)}] \\
&= \mathbb{E}[\mathbb{E}[e^{\lambda(g_n(Z_1^n) - g_{n-1}(Z_1^{n-1}))} | Z_1^{n-1}] e^{\lambda(g_{n-1}(Z_1^{n-1}) - g_0)}]
\end{aligned}$$

où nous avons utilisé, pour tout variable  $Y \geq 0$  et toute tribu  $\mathcal{F}$ ,  $\mathbb{E}[Y] = \mathbb{E}[\mathbb{E}[Y | \mathcal{F}]]$  et pour tout  $Z \geq 0$   $\mathcal{F}$ -mesurable  $\mathbb{E}[YZ | \mathcal{F}] = \mathbb{E}[Y | \mathcal{F}] Z$ ,  $\mathbb{P}$ -p.s.

2. Nous avons  $\inf_{z \in Z} g_i(z_1^i, z) \leq g_i(z_1^i)$  (!) et

$$c_i \geq \sup_{z \in Z} g_i(z_1^i) - g_i(z_1^{i-1}, z) = g_i(z_1^i) - \inf_{z \in Z} g_i(z_1^{i-1}, z)$$

Pour établir la deuxième identité, nous utilisons que pour tout fonction mesurable positive,  $f : Z \times Z \rightarrow \mathbb{R}^+$ , toute tribu  $\mathcal{F}$ , toute variable aléatoire  $Y$   $\mathcal{F}$ -mesurable et toute variable aléatoire  $Z$  indépendante de  $\mathcal{F}$ ,

$$\mathbb{E}[f(Y, Z) | \mathcal{F}] = \phi(Y) \quad \mathbb{P} - \text{p.s.} \quad \text{avec} \quad \phi(y) = \mathbb{E}[f(y, Z)].$$

3. Découle directement du Lemme d'Hoeffding, Exercice 3, PC-9. appliqué à la variable aléatoire  $G_n = g_n(Z_1^n)$  et  $\mathbb{E} \leftarrow \mathbb{E}[\cdot | Z_1^{n-1}]$ .

4. En appliquant les résultats précédents, nous avons

$$\mathbb{E}[e^{\lambda(g_n(Z_1^n) - g_0)}] \leq e^{\lambda^2 c_n^2 / 8} \mathbb{E}[e^{\lambda(g_{n-1}(Z_1^{n-1}) - g_0)}]$$

et nous concluons par une récurrence immédiate.

5. On applique l'inégalité de Chernoff, Exercice 2, PC-9, comme dans la preuve de l'inégalité d'Hoeffding Exercice 3, PC-10.

**Solution Exercice 4. :** 1. en raison de la non-convexité de la fonction d'erreur de classification  $I$ , la minimisation de (4) est combinatoire.

2. Cf cours et PC8.

3. Les fonctions sont toutes croissantes (sauf  $\phi_2$ ), convexe, (continues).  $\theta \mapsto \widehat{R}_{\phi,n}(g_\theta : x \mapsto \theta^T x) =$  est donc une fonction convexe de  $\theta$ . La majoration  $\phi(v) \geq \mathbb{1}_{v \geq 0}$  est évidente.
4. Pour  $\phi \in \{\phi_2, \phi_E, \phi_L\}$ , la fonction  $\phi$  est strictement convexe, tend vers 0 en  $-\infty$  et  $+\infty$  en  $+\infty$ . Donc pour tout  $\eta \in ]0; 1[$ ,  $p \mapsto H_\phi(\eta, p)$  est strictement convexe, et tend vers l'infini aux infinis, donc admet un maximum unique. Geogebra.  
Pour  $\phi = \phi_H$ , la fonction  $\phi$  admet un minimum unique sauf pour  $\eta = 1/2$ .
5. Découle directement de :

$$\begin{aligned} R_\phi(g) &= \mathbb{E}[\eta(X)\phi(-g(X)) + (1 - \eta(X))\phi(g(X))] = \mathbb{E}[H_\phi(\eta(X), g(X))] \\ R_\phi(g_\phi^*) &= \mathbb{E}[H_\phi(\eta(X), g_\phi^*(X))] = \mathbb{E}[H_\phi(\eta(X), p_\phi^*(\eta(X)))] = \mathbb{E}[H_\phi^*(\eta(X))] \end{aligned}$$

et par différence

$$R_\phi(g) - R_\phi(g_\phi^*) = \mathbb{E}[H_\phi(\eta(X), g(X)) - H_\phi^*(\eta(X))]$$

6. Calculs élémentaires. Geogebra.
7. Nous observons que pour tous les exemples de fonctions  $\phi$  ci-dessus,  $p_\phi^*(\eta) > 0$  lorsque  $\eta > 1/2$ . Cela implique que si nous prenons  $g_\phi^*(x) = p_\phi^* \circ \eta(x)$ , alors la règle de décision  $\text{signe}(g_\phi^*)$  est un classifieur de Bayes pour la perte  $0 - 1$ .
8. Cf cours
9. Notons que  $R_{01}^* = R_{01}(2\eta - 1)$ . Par conséquent

$$\begin{aligned} R_{01}(g) - R_{01}(2\eta - 1) &= \mathbb{E}[\eta(X)\{\ell_{01}(g(X), 1) - \ell_{01}(2\eta(X) - 1, 1)\} + \{1 - \eta(X)\}\{\ell_{01}(g(X), 0) - \ell_{01}(2\eta(X) - 1, 0)\}] \\ &= \mathbb{E}[(2\eta(X) - 1)\{\ell_{01}(g(X), 1) - \ell_{01}(2\eta(X) - 1, 1)\}] \\ &\leq \mathbb{E}[\mathbb{1}_{\{(2\eta(X)-1)g(X) \leq 0\}} |2\eta(X) - 1|] \\ &\leq 2\{\mathbb{E}[\mathbb{1}_{\{(2\eta(X)-1)g(X) \leq 0\}} |\eta(X) - 1/2|^s]\}^{1/s}. \end{aligned}$$

et nous concluons en appliquant (H2).

10. Supposons tout d'abord que  $\eta(x) > 1/2$ . Par hypothèse,  $g_\phi^*(x) = p_\phi^* \circ \eta(x) > 0$  et  $g(x) < 0$ . Donc  $0 \in [g(x), g_\phi^*(x)]$  et comme la fonction  $p \mapsto H_\phi(\eta, p)$  est convexe

$$H_\phi(\eta(x), 0) \leq \max(H_\phi(\eta(x), g(x)), H_\phi(\eta(x), g_\phi^*(x))) = H_\phi(\eta(x), g(x)) .$$

Supposons maintenant que  $\eta(x) < 1/2$ . Par hypothèse,  $g_\phi^*(x) = g_\phi^* \circ \eta(x) = -g_\phi^*(1 - \eta(x)) < 0$  et  $g(x) > 0$ . Donc  $0 \in [g_\phi^*(x), g(x)]$  et nous concluons comme dans la question précédente.

11. Pour le risque quadratique nous avons  $\phi(p) = (1 - p)^2$ ,  $g_\phi^*(\eta) = 2\eta - 1$ ,  $H_\phi(0) = 1$  et  $H_\phi^*(\eta) = 4\eta(1 - \eta)$ . Par conséquent,

$$\Delta H_\phi(\eta, 0) = 1 - 4\eta(1 - \eta) = 2^2(\eta - 1/2)^2 .$$

Donc  $|\eta - 1/2|^2 \leq \frac{1}{2^2} \Delta H_\phi(\eta, 0)$ .



12. Dans ce cas  $\phi(v) = \max(0, 1 - v)$ ,  $p_\phi^*(\eta) = \text{signe}(2\eta - 1)$  et

$$\begin{aligned}\Delta H_\phi(\eta, p) &= \eta \left( \phi(p) - \phi \left( f_\phi^*(\eta) \right) \right) + (1 - \eta) \left( \phi(-p) - \phi \left( -p_\phi^*(\eta) \right) \right) \\ &= \eta \max(0, 1 - p) + (1 - \eta) \max(0, 1 + p) - 1 + |2\eta - 1|.\end{aligned}$$

ce qui implique que

$$\Delta H_\phi(\eta, 0) = \eta + (1 - \eta) - 1 + |2\eta - 1| = |2\eta - 1|.$$

13. On a  $H_\phi^*(\eta) = -\eta \log_2 \eta - (1 - \eta) \log_2(1 - \eta)$ , et  $H_\phi(\eta, 0) = 1$ , donc

$$\Delta H_\phi(\eta, 0) = 1 + \eta \log_2 \eta + (1 - \eta) \log_2(1 - \eta) =: h(\eta)$$

avec  $h(0) = h(1) = 1$ ,  $h(1/2) = 0$ ,  $h'(\eta) = \frac{1}{\ln(2)}(\ln(\eta) - \ln(1 - \eta))$  donc  $h'(\frac{1}{2}) = 0$ ,  
et finalement  $h''(\eta) = \frac{1}{\ln(2)} \left( \frac{1}{\eta} + \frac{1}{1-\eta} \right) = \frac{1}{\ln(2)} \frac{1}{\eta(1-\eta)} \geq \frac{4}{\ln(2)}$  pour tout  $\eta \in [0; 1]$ . Par  
intégration,  $h(\eta) \geq \frac{2}{\ln(2)} \left( \eta - \frac{1}{2} \right)^2$ , i.e.,

$$|\eta - 1/2|^2 \leq \frac{\ln(2)}{2} \Delta H_\phi(\eta, 0).$$