

Partie I

$$1 \quad R(g_n) - R^* \geq 0$$

$$2 \quad P(g_n(X) \neq Y \mid (X_i, Y_i), X)$$

$$= 1 - P(g_n(X) \neq Y, Y=1 \mid (X_i, Y_i), X) - P(g_n(X) \neq Y, Y=0 \mid (X_i, Y_i), X)$$

$$= 1 - \eta(X) \mathbb{1}_{\{g_n(X)=1\}} - (1-\eta(X)) \mathbb{1}_{\{g_n(X)=0\}}$$

3 La même égalité est vraie pour  $g^*$ . Donc

$$P(g_n(X) \neq Y \mid (X_i, Y_i), X) - P(g^*(X) \neq Y \mid X)$$

$$= -\eta(X) \left[ \mathbb{1}_{\{g_n(X)=1\}} - \mathbb{1}_{\{g^*(X)=1\}} \right] - (1-\eta(X)) \left[ \mathbb{1}_{\{g_n(X)=0\}} - \mathbb{1}_{\{g^*(X)=0\}} \right]$$

$$| | = \begin{cases} 1 & \text{si } g_n(X) \neq g^*(X) \\ 0 & \text{sinon} \end{cases}$$

$$| | = \begin{cases} 1 & \text{si } g_n(X) \neq g^*(X) \\ 0 & \text{sinon} \end{cases}$$

$$\leq |2\eta(X) - 1| \mathbb{1}_{\{g_n(X) \neq g^*(X)\}}$$

4 On passe à l'espérance sur  $X$  :

$$R(g_n) - R^* \leq E \left[ |2\eta(X) - 1| \mathbb{1}_{\{g_n(X) \neq g^*(X)\}} \mid (X_i, Y_i) \right]$$

$$\text{On, si } \mathbb{1}_{\{g_n(X) \neq g^*(X)\}} = 1, \left| \eta(X) - \frac{1}{2} \right| \leq |\eta(X) - \eta_n(X)|$$

$$\text{Donc } R(g_n) - R^* \leq 2 \int_{\mathbb{R}^d} |\eta_n(x) - \eta(x)| \mu(dx)$$

## Partie II


- 5  $\omega_{m,i}(x) = \nu_{m,j}$  où  $j$  est l'indice tel que  $Y_i = Y_j$
- 6  $\mu$  est à densité donc  $\mu(B(x, \cdot)) = \frac{k_m}{n}$  admet une unique solution notée  $\rho_m(x)$

## Partie III

- 7  $\omega_{m,i}(x) = 0$  pour  $i > k_m$
- Or, par déf. de  $H_{k_m}$ ,  $\mathbb{1}_{B(x, H_{k_m})}(X_i) = 0$  ssi  $i > k_m$
- Ajouter cette indicatrice ne change donc pas la somme.
- 8  $\eta_m^{\rho}(x) - \eta_m(x) = \sum_{i=1}^n \omega_{m,i}(x) Y_i \left[ \mathbb{1}_{B(x, \rho_m)}(X_i) - \mathbb{1}_{B(x, H_{k_m})}(X_i) \right]$

Or  $\omega_{m,i}(x) \leq \frac{\alpha}{k_m}$  et  $Y_i \leq 1$  donc

$$\begin{aligned} \left| \eta_m^{\rho}(x) - \eta_m(x) \right| &\leq \frac{\alpha}{k_m} \underbrace{\sum_{i=1}^n \left| \mathbb{1}_{B(x, \rho_m)}(X_i) - \mathbb{1}_{B(x, H_{k_m})}(X_i) \right|}_{= \left| n \mu_m(B(x, \rho_m)) - k_m \right| \text{ par définition de la loi empirique et de } H_{k_m}} \\ &= \left| n \mu_m(B(x, \rho_m)) - k_m \right| \end{aligned}$$



Or, par 6,  $\frac{k_m}{n} = \mu(B(x, \rho_m))$ . Donc

$$\left| \eta_m^{\rho}(x) - \eta_m(x) \right| \leq \frac{\alpha n}{k_m} \left| \mu_m(B(x, \rho_m)) - \mu(B(x, \rho_m)) \right|$$

9  $\mu_n(B(x, \rho_n)) \times n \sim \text{Binom.}(\mu(B(x, \rho_n)), n)$   
 donc  $E[Z_n(x)^2] = \frac{\sigma^2}{h_n^2} n \underbrace{\mu(B(x, \rho_n))}_{\frac{h_n}{n}} \underbrace{[1 - \mu(B(x, \rho_n))]}_{\leq 1}$

$$E[Z_n(x)]^2 \leq E[Z_n(x)^2] \leq \frac{\sigma^2}{h_n} \quad \text{donc} \quad E[Z_n(x)] \leq \frac{\sigma}{\sqrt{h_n}}$$

#### Partie IV

10  $|\eta_n^*(x) - \eta(x)| \leq |\eta_n^*(x) - \eta_n(x)| + |\eta_n(x) - \eta(x)|$

On  $E|\eta_n(x) - \eta(x)| \xrightarrow[n \rightarrow \infty]{} 0$  (par l'énoncé)

et  $E|\eta_n^*(x) - \eta_n(x)| \leq E[Z_n(x)] \leq \frac{\sigma}{\sqrt{h_n}} \xrightarrow[n \rightarrow \infty]{} 0$

Donc, pour  $n$  assez grand,  $E|\eta_n^*(x) - \eta(x)| \leq \frac{\epsilon}{20}$

11  $|\eta_n(x) - \eta(x)| \leq \underbrace{|\eta_n(x) - \eta_n^*(x)|}_{(A)} + \underbrace{|\eta_n^*(x) - \eta(x)|}_{(B)}$

$$\begin{aligned} (A) \int |\eta_n(x) - \eta_n^*(x)| \mu(dx) &\leq \int Z_n(x) \mu(dx) \\ &\leq \left| \int Z_n(x) \mu(dx) - E \int Z_n(x) \mu(dx) \right| \\ &\quad + E \int Z_n(x) \mu(dx) \end{aligned}$$

Or  $\mathbb{E} \int Z_m(x) \mu(dx) \leq \frac{\sigma}{\sqrt{k_m}} \leq \frac{\varepsilon}{20}$  pour  $n$  assez grand

$$(B) \int |\eta_m^p(x) - \eta(x)| \mu(dx)$$

$$\leq \left| \int |\eta_m^p(x) - \eta(x)| \mu(dx) - \mathbb{E} \int |\eta_m^p(x) - \eta(x)| \mu(dx) \right|$$

$$+ \underbrace{\mathbb{E} \int |\eta_m^p(x) - \eta(x)| \mu(dx)}$$

$$= \mathbb{E} |\eta_m^p(X) - \eta(X)| \leq \frac{\varepsilon}{20} \text{ pour } n \text{ assez grand.}$$

Bilan:  $\int |\eta_m(x) - \eta(x)| \mu(dx)$

$$\leq \left| \int Z_m(x) \mu(dx) - \mathbb{E} \int Z_m(x) \mu(dx) \right|$$

$$+ \left| \int |\eta_m^p(x) - \eta(x)| \mu(dx) - \mathbb{E} \int |\eta_m^p(x) - \eta(x)| \mu(dx) \right| + \frac{\varepsilon}{10}$$

On conclut avec  $\frac{\varepsilon}{2} - \frac{\varepsilon}{10} = \frac{2\varepsilon}{5}$ .

Parce V

$$12 \quad | \dots | \leq \underbrace{\left| y_i \mathbb{1}_{B(x, \rho_m)}(x_i) - y'_i \mathbb{1}_{B(x, \rho_m)}(x'_i) \right|}_{\leq 1} \underbrace{\omega_{m,i}(x)}_{\leq \frac{\sigma}{k_m}}$$

13 Si  $| \dots | > 0$

dors  $| y_i \mathbb{1}_{B(x, \rho_n)}(x_i) - y'_i \mathbb{1}_{B(x, \rho_n)}(x'_i) | > 0$

Donc l'une des deux indicatrices (au moins) est non-nulle, ie  $x_i \in B(x, \rho_n)$  ou  $x'_i \in B(x, \rho_n)$

14 Si  $x_i \in B(x, \rho_n)$ ,  $\|x_i - x\| \leq \rho_n$

donc  $\mu(B(x, \|x_i - x\|)) \leq \mu(B(x, \rho_n)) = \frac{k_n}{n}$

Réciproquement, comme  $B(x, \|x_i - x\|)$  et  $B(x, \rho_n)$  partagent le même centre, et comme  $\mu(B(x, \rho_n)) = \frac{k_n}{n}$ ,  
 $\mu(B(x, \|x_i - x\|)) \leq \frac{k_n}{n} \Rightarrow B(x, \|x_i - x\|) \subset B(x, \rho_n)$

et donc  $\|x_i - x\| \leq \rho_n$  ie  $x_i \in B(x, \rho_n)$

15  $\int | \dots | \mu(dx) \leq \frac{\alpha}{k_n} \int [ \mathbb{1}_{B(x, \rho_n(x))}(x_i) + \mathbb{1}_{B(x, \rho_n(x))}(x'_i) ] \mu(dx)$

par 12 et 13. Alors, par 14,

$$\int | \dots | \mu(dx) \leq \frac{\alpha}{k_n} \left[ \int_{\{x: \mu(B(x, \|x_i - x\|)) \leq \frac{k_n}{n}\}} \mu(dx) + \int_{\{x: \mu(B(x, \|x'_i - x\|)) \leq \frac{k_n}{n}\}} \mu(dx) \right]$$

Par le rés. admis de 15,

$$\int |\dots| \mu(dx) \leq \frac{\alpha}{h_m} \times 2 \delta_d \frac{h_m}{m} = \frac{2 \alpha \delta_d}{m}$$

## Partie VI

16 On peut appliquer l'in. de Hoeffding par les rés. de la partie V. On a alors

$$P\left(|\dots| \geq \frac{\varepsilon}{5}\right) \leq 2 \exp\left(-\frac{2 \left(\frac{\varepsilon}{5}\right)^2}{m \frac{4 \alpha^2 \delta_d^2}{m^2}}\right)$$

$$\leq 2 \exp\left(-\frac{1}{50} \times \frac{m \varepsilon^2}{\alpha^2 \delta_d^2}\right)$$

$$17 \quad P(R(g_m) - R^* \geq \varepsilon) \leq P\left(\int_{\mathbb{R}^d} |\eta_m(x) - \eta(x)| \mu(dx) \geq \frac{\varepsilon}{2}\right)$$

par 4. Alors, par 11, 16 et l'hypothèse de 17,

$$P(R(g_m) - R^* \geq \varepsilon) \leq 4 \exp\left(-\frac{m \varepsilon^2}{50 \alpha^2 \delta_d^2}\right)$$

Bonus: seulement dans la question 6

Fin

Sujet fortement inspiré de Lectures on the Nearest Neighbor Method. Biau and Devroye (2015).