

On utilise le lemme suivant:

(5)

Si X variable positive:

$$E[X] = \int_0^{+\infty} \mathbb{P}(X \geq t) dt \quad (\text{Fubini-Tonelli})$$

On a donc:

$$E \left[\max_{g \in \mathcal{G}} |\hat{R}(g) - R(g)| \right] \\ = \int_0^{+\infty} \mathbb{P} \left(\max_{g \in \mathcal{G}} |\hat{R}(g) - R(g)| \geq t \right) dt$$

On va contrôler: $\mathbb{P} \left(\max_{g \in \mathcal{G}} |\hat{R}(g) - R(g)| \geq t \right)$
 $\forall t \geq 0$.

C'est à dire, que l'on cherche à contrôler les déviations du processus empirique

$$\max_{g \in \mathcal{G}} |\hat{R}(g) - R(g)|$$

On a: $\left\{ \max_{g \in \mathcal{G}} |\hat{R}(g) - R(g)| \geq t \right\}$

$$= \left\{ \exists g \in \mathcal{G}, |\hat{R}(g) - R(g)| \geq t \right\}$$

$$= \bigcup_{g \in \mathcal{G}} \left\{ |\hat{R}(g) - R(g)| \geq t \right\}$$

$$\Rightarrow \mathbb{P}(\max_{g \in \mathcal{Y}} |\hat{R}(g) - R(g)| \geq t) \quad (6)$$

$$= \mathbb{P}\left(\bigcup_{g \in \mathcal{Y}} |\hat{R}(g) - R(g)| \geq t\right)$$

$$\leq \sum_{g \in \mathcal{Y}} \mathbb{P}(|\hat{R}(g) - R(g)| \geq t)$$

$$\Rightarrow \mathbb{E}\left[\mathcal{E}(\hat{g}(D_m))\right] \leq 2 \sum_{g \in \mathcal{Y}} \int_0^{+\infty} \mathbb{P}(|\hat{R}(g) - R(g)| \geq t) dt$$

Etape 3 Application de l'inégalité de Hoeffding

pour $t \geq 0$, on va commencer à l'aide de l'inégalité de Hoeffding :

$$\mathbb{P}(|\hat{R}(g) - R(g)| \geq t) \quad \text{pour } g \in \mathcal{Y}.$$

L'inégalité de Hoeffding peut être vue comme un raffinement de l'inégalité de Markov (ou Bienaymé-Tchebychev)

D'après Bienaymé-Tchebychev, on

$$\mathbb{P}\left(|\hat{R}(g) - R(g)| \geq t\right) \leq \frac{\text{Var}(\hat{R}(g))}{t^2}$$

$\mathbb{E}[\hat{R}(g)] = R(g)$

σ : $\text{Var}(\hat{R}(g))$

\downarrow x_i, y_i iid

$$= \text{Var}\left(\frac{1}{m} \sum_{i=1}^m \mathbb{1}_{\{g(x_i) \neq y_i\}}\right)$$

$$= \frac{1}{m^2} \sum_{i=1}^m \text{Var}(\mathbb{1}_{\{g(x_i) \neq y_i\}})$$

$$= \frac{\text{Var}(\mathbb{1}_{\{g(x) \neq y\}})}{m}$$

σ : $\mathbb{1}_{\{g(x) \neq y\}} \sim \text{Ber}(R(g))$

Car: $\mathbb{P}(\mathbb{1}_{\{g(x) \neq y\}} = 1) = \mathbb{P}(g(x) \neq y) = R(g)$

$\Rightarrow \text{Var}(\hat{R}(g)) = \frac{R(g)(1-R(g))}{m}$

$\Rightarrow \forall t > 0$

$$\mathbb{P}(|\hat{R}(g) - R(g)| \geq t) \leq \frac{R(g)(1-R(g))}{m t^2}$$

$$\leq \frac{1}{4 m t^2}$$

Inégalité de Hoeffding: Soit (z_1, \dots, z_m)

m variables indépendantes et centrées.

tg $\forall i a_i \leq z_i \leq b_i$ ales $\forall t > 0$

$$\mathbb{P}\left(\sum_{i=1}^m z_i \geq t\right) \leq \exp\left(-\frac{2t^2}{\sum_{i=1}^m (b_i - a_i)^2}\right)$$

et $\mathbb{P}\left(|\sum_{i=1}^m z_i| \geq t\right) \leq 2 \exp\left(-\frac{2t^2}{\sum_{i=1}^m (b_i - a_i)^2}\right) \leftarrow$

On va appliquer Hoeffding à

$$|\hat{R}(g) - R(g)|$$

$$= \left| \frac{1}{m} \sum_{i=1}^m \mathbb{1}_{\{g(x_i) \neq y_i\}} - \underbrace{\mathbb{E}[\mathbb{1}_{\{g(x) \neq y\}}]}_{R(g)} \right|$$

$$= \left| \frac{1}{m} \sum_{i=1}^m \left(\mathbb{1}_{\{g(x_i) \neq y_i\}} - \mathbb{E}[\mathbb{1}_{\{g(x) \neq y\}}] \right) \right|$$

$$= \frac{1}{m} \left| \sum_{i=1}^m Z_i \right| \quad \left[R(g) = \frac{1}{m} \sum_{i=1}^m R(g) \right]$$

On Z_i centrée $\forall i$ et indépendantes.

$$\text{De plus: } -R(g) \leq Z_i \leq 1 - R(g)$$

$$(0 \leq \mathbb{1}_{\{g(x_i) \neq y_i\}} \leq 1)$$

$$\Rightarrow \forall i \quad a_i = -R(g) \text{ et } b_i = 1 - R(g)$$

$$\text{et } b_i - a_i = 1$$

$$\Rightarrow \sum_{i=1}^m (b_i - a_i)^2 = m.$$

par Hoeffding :

$$\mathbb{P} \left(\frac{1}{m} \left| \sum_{i=1}^m Z_i \right| \geq t \right) = \mathbb{P} \left(\left| \sum_{i=1}^m Z_i \right| \geq mt \right) \leq 2 \exp \left(- \frac{2 m^2 t^2}{m} \right)$$

(9)

Finalement: On a $\forall t > 0$

$$\mathbb{P}(|\hat{R}(g) - R(g)| \geq t) \leq 2 \exp(-2mt^2)$$

$$\Rightarrow \mathbb{P}\left(\max_{g \in \mathcal{G}} |\hat{R}(g) - R(g)| \geq t\right)$$

$$\leq \sum_{g \in \mathcal{G}} 2 \exp(-2mt^2) = 2 \text{Card}(\mathcal{G}) \exp(-2mt^2)$$

$$\Rightarrow \mathbb{P}\left(\max_{g \in \mathcal{G}} |\hat{R}(g) - R(g)| \geq t\right)$$

$$\leq \min(1, 2 \text{Card}(\mathcal{G}) \exp(-2mt^2))$$

$$\leq \min(1, \exp(-(2mt^2 - \log(2 \text{Card}(\mathcal{G}))))))$$

$$= \exp(-(2mt^2 - \log(2 \text{Card}(\mathcal{G})))_+)$$

$$= \exp(-(2mt^2 - (K+1) \log(2))_+)$$

$$\Rightarrow \mathbb{E}\left[\mathcal{E}(\hat{g}(D_m))\right] \leq \int_0^{+\infty} \exp(-(2mt^2 - (K+1) \log(2))_+) dt$$

Etape 4: Conclusion.

Majoration de $\int_0^{+\infty} \exp(-(2mt^2 - (K+1) \log(2))_+) dt$.

On note: $f(t) = \exp(-(2mt^2 - (k+1)\log(2))_+)$ (10)

on a $f(t) = 1$

Si $2mt^2 - (k+1)\log(2) \leq 0$

Rappel: $(x)_+ = x$ si $x > 0$
 $= 0$ sinon.

$\Rightarrow t \leq \sqrt{\frac{(k+1)\log(2)}{2m}}$

$$\int_0^{+\infty} f(t) dt = \int_0^{\sqrt{\frac{(k+1)\log(2)}{2m}}} dt + \int_{\sqrt{\frac{(k+1)\log(2)}{2m}}}^{+\infty} \exp(-(2mt^2 - (k+1)\log(2))) dt$$

$$= \sqrt{\frac{(k+1)\log(2)}{2m}} + \int_{\sqrt{\frac{(k+1)\log(2)}{2m}}}^{+\infty} \exp(-(2mt^2 - (k+1)\log(2))) dt$$

on a: $(2mt^2 - (k+1)\log(2))$

$$= 2m \left(t^2 - \frac{(k+1)\log(2)}{2m} \right)$$

or: $a^2 - b^2 \geq (a-b)^2$ pour $a \geq b \geq 0$

$\Rightarrow (2mt^2 - (k+1)\log(2))$

$$\geq 2m \left(t - \sqrt{\frac{(k+1)\log(2)}{2m}} \right)^2$$

$$\int_{\frac{\sqrt{(k+1)\log(z)}}{2m}}^{+\infty} \text{escp}(-2mt^2 - (k+1)\log(z)) dt$$

$$\leq \int_{\frac{\sqrt{(k+1)\log(z)}}{2m}}^{+\infty} \text{escp}(-2m(t - \frac{\sqrt{(k+1)\log(z)}}{2m})^2) dt$$

chgt de variable

$$\int_0^{+\infty} \text{escp}(-2m u^2) du$$

change de variable

$$\frac{1}{\sqrt{2m}} \int_0^{+\infty} \text{escp}(-x^2) dx = \frac{\sqrt{\pi}}{2\sqrt{2m}}$$

$$\Rightarrow \int_0^{+\infty} f(v) dt \leq \sqrt{\frac{(k+1)\log(z)}{2m}} + \frac{\sqrt{\pi}}{2\sqrt{2m}}$$

$$\Rightarrow E[R(\hat{g}(D_m))] - R(g^*) \leq 2 \left(\sqrt{\frac{(k+1)\log(z)}{2m}} + \frac{\sqrt{\pi}}{2\sqrt{2m}} \right)$$

$$\leq C \sqrt{\frac{k}{m}} \leq C \sqrt{\frac{\text{Card}(Z)}{m}}$$

où C est une constante.
Dès que $k \geq 4$

5.3 Conclusion et remarques

(12)

On a vu dans le cas où \mathcal{X} est de cardinal fini égal à $k \geq 4$ en classification binaire le minimum du risque empirique satisfait :

$\forall P$ la distribution de (X, Y)

$$E[R(\hat{g}(D_n)) - R(g^*)] \leq C \sqrt{\frac{k}{n}}.$$

On a donc montré que le minimum du risque empirique est universellement consistant. En fait, on a montré mieux :

la vitesse de convergence est uniforme en la loi de (X, Y) :

$$\lim_{n \rightarrow +\infty} \sup_{P \sim (X, Y)} E[R(\hat{g}(D_n)) - R(g^*)] = 0.$$

\Rightarrow On dit que \hat{g} est uniformément universellement consistant.