

①

Leçon n° 4: EMMT Lien forte proba - espérance,

Complexité de Mademacher, application aux

modèles linéaires

Contexte: Contrôle de $\sup_{f \in F} (\hat{M}(f) - M(f))$

+ $\sup_{f \in F} (M(f) - \hat{M}(f))$ (Erreur d'estimation)

I. Lien forte Proba - Espérance.

$$\hat{M}(f) = \frac{1}{n} \sum_{i=1}^n P(y_i | x_i)$$

Hypothèse: $\forall f \in F, \forall (x, y) \in \text{Supp}(P_i \text{ des données}),$

$$0 \leq P(y_i, f(x_i)) \leq P_{\infty}$$

Remarque: En changeant un couple (x_i, y_i) par n'importe quel qui reste dans le support de la P_i des données, $\hat{M}(f)$ change au plus de $\frac{P_{\infty}}{n}$ (vrai $\forall f$).

Et donc, $\left(\sup_{f \in F} (\hat{M}(f) - M(f)) \right)$ change au plus de $\frac{P_{\infty}}{n}$.
(Idem pour l'autre sens)

②

Il est alors possible d'appliquer l'inégalité de McDiarmid à

$\sup_{f \in \mathcal{F}} (\hat{m}(f) - m(f))$, ce qui donne, avec probabilité $1 - \delta$,

(pour $\delta \in (0, 1)$),

$$\left| \sup_{f \in \mathcal{F}} (\hat{m}(f) - m(f)) - \mathbb{E} \left(\sup_{f \in \mathcal{F}} (\hat{m}(f) - m(f)) \right) \right| \leq \frac{P_{\infty}}{\sqrt{2n}} \sqrt{\log \frac{1}{\delta}}$$

Donc Pour obtenir des bornes avec forte proba, il suffit d'être capable de donner des bornes à l'espérance.

③

II Complexité de Mademacher

Idée Pour donner des bornes sur $\mathbb{E} \left(\sup_{f \in F} \left| \hat{M}(f) - M(f) \right| \right)$, il existe un outil générique appelé la complexité de Mademacher.

Reformulation On reparamétrise les fonctions f (et F) par des fonctions h (et H). Nous sommes alors intéressés par

$$\sup_{h \in H} \left\{ \mathbb{E} \left(\sup_{h \in H} h(z) - \frac{1}{n} \sum_{i=1}^n h(z_i) \right) \right\}$$

Definition: $M_n(H) \equiv \mathbb{E}_{\varepsilon, z} \left(\sup_{h \in H} \frac{1}{n} \sum_{i=1}^n \varepsilon_i h(z_i) \right)$

où $\varepsilon = (\varepsilon_1, \dots, \varepsilon_n)$ est une suite de variables de Mademacher indépendantes entre elles et de toutes les autres quantités.

$M_n(H)$ s'appelle la complexité de Mademacher de la classe H .

9

Théorème (Propriété de symétrisation).

Les deux inégalités suivantes sont vérifiées :

$$\bullet \mathbb{E} \left(\sup_{h \in H} \left(\frac{1}{n} \sum_{i=1}^n h(z_i) - \mathbb{E}(h(z)) \right) \right) \leq 2M_n(H)$$

~~$$\bullet \mathbb{E} \left(\sup_{h \in H} \left(\mathbb{E}(h(z)) - \frac{1}{n} \sum_{i=1}^n h(z_i) \right) \right) \leq 2M_n(H)$$~~

$$\bullet \mathbb{E} \left(\sup_{h \in H} \left(\mathbb{E}(h(z)) - \frac{1}{n} \sum_{i=1}^n h(z_i) \right) \right) \leq 2M_n(H)$$

preuve: L'idée est d'introduire des variables aléatoires z_1', \dots, z_n' qui sont indépendables entre elles et des autres quantités du problème.

$$\begin{aligned} \text{Alors } & \mathbb{E} \left(\sup_{h \in H} \left(\frac{1}{n} \sum_{i=1}^n h(z_i) - \mathbb{E}(h(z)) \right) \right) \\ &= \mathbb{E} \left(\sup_{h \in H} \left(\frac{1}{n} \sum_{i=1}^n h(z_i) - \frac{1}{n} \sum_{i=1}^n \mathbb{E} \left(h(z_i') \right) \right) \right) \\ &= \mathbb{E} \left(\sup_{h \in H} \left(\mathbb{E} \left(\frac{1}{n} \sum_{i=1}^n \left(h(z_i) - h(z_i') \right) \right) \right) \right) \\ &\leq \sup_{h \in H} \mathbb{E} \left(\sup_{\substack{z_1, \dots, z_n \\ z_1', \dots, z_n'}} \left(\frac{1}{n} \sum_{i=1}^n \left(h(z_i) - h(z_i') \right) \right) \right) \end{aligned}$$

- (5) De plus, z_i et z_i' ont des lois interchangeables (car $h(z_i) - h(z_i')$ est symétrique) et ε_i est symétrique.

dac

$$E \left(\sup_{h \in \mathcal{H}} \left| \frac{1}{n} \sum_{i=1}^n h(z_i) - E(h) \right| \right)$$

$$\leq E \left(\sup_{\substack{z_1, \dots, z_n \\ z_1', \dots, z_n' \\ \varepsilon_1, \dots, \varepsilon_n}} \left(\sup_{h \in \mathcal{H}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i (h(z_i) - h(z_i')) \right| \right) \right)$$

$$\leq E \left(\sup_{h \in \mathcal{H}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i h(z_i) \right| \right) + E \left(\sup_{h \in \mathcal{H}} \left| \frac{1}{n} \sum_{i=1}^n -\varepsilon_i h(z_i') \right| \right)$$

$$= 2M_n(\mathcal{H})$$

□

III Analyse des modèles linéaires contraints via la complexité de Rademacher

~~1) Calcul de la complexité de Rademacher~~
 → À présent après le calcul de complexité.

Lemme: Lorsque la fonction $f(y, \cdot)$ est G -lipschitz p.s., alors

$$E \left(\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(y_i, \cdot) \right| \right) \leq G \cdot E \left(\sup_{f \in \mathcal{F}} \left| \frac{1}{n} \sum_{i=1}^n \varepsilon_i f(x_i) \right| \right)$$

preuve: Admis, voir Bach 2024

□

⑥

Modèles linéaires contraints :

$$\mathcal{F} = \left\{ \theta \mid \theta = \Phi^T \varphi, \Omega(\theta) \leq 0 \right\}$$

Ω : norme sur \mathbb{R}^d

$$M_n(F) = \mathbb{E} \left[\sup_{\Omega(\theta) \leq 0} \left(\frac{1}{n} \sum_{i=1}^n \varepsilon_i \theta^T \varphi(x_i) \right) \right]$$

$$= \mathbb{E} \left[\sup_{\Omega(\theta) \leq 0} \frac{1}{n} \varepsilon^T \Phi \theta \right] \quad (\text{Notation léger 2})$$

$$= \frac{D}{n} \mathbb{E} \left(\Omega^* \left(\Phi^T \varepsilon \right) \right) \quad (\Omega^* : \text{norme duale de } \Omega)$$

Lorsque $\Omega(\cdot) = \|\cdot\|_2$:

$$M_n(F) = \frac{D}{n} \mathbb{E} \left(\|\Phi^T \varepsilon\|_2 \right)$$

$$\leq \frac{D}{n} \sqrt{\mathbb{E} \left(\|\Phi^T \varepsilon\|_2^2 \right)}$$

Jensen

$$= \frac{D}{n} \sqrt{\mathbb{E} \left(\varepsilon^T \Phi \Phi^T \varepsilon \right)}$$

$$= \frac{D}{n} \sqrt{\mathbb{E} \left(\text{tr} \left(\varepsilon^T \Phi \Phi^T \varepsilon \right) \right)}$$

$$= \frac{D}{n} \sqrt{\mathbb{E} \left(\text{tr} \left(\Phi^T \varepsilon \varepsilon^T \Phi \right) \right)}$$

⑦

$$= \frac{D}{n} \sqrt{\mathbb{E}(\text{tr}(\Phi^T \varepsilon \varepsilon^T \Phi) | \Phi)}$$

$$= \frac{D}{n} \sqrt{\mathbb{E}(\text{tr}(\Phi^T \underbrace{\mathbb{E}(\varepsilon \varepsilon^T | \Phi)}_{= I} \Phi))}$$

$$= \frac{D}{n} \sqrt{\mathbb{E}(\text{tr}(\Phi^T \Phi))} = \frac{D}{n} \sqrt{\sum_{i=1}^{\hat{}} \mathbb{E}(\Phi^T \Phi)_i}$$

$$= \frac{D}{n} \sqrt{\sum_{i=1}^{\hat{}} \mathbb{E}(\|\phi(x_i)\|_2^2)}$$

$$= \frac{D}{\sqrt{n}} \sqrt{\mathbb{E}(\|\phi(x)\|_2^2)}$$

donc
$$M_n(F) \leq \frac{D}{\sqrt{n}} \sqrt{\mathbb{E}(\|\phi(x)\|_2^2)}$$

Indep de la dimension.

Conclusion: lorsque $f(y, \cdot)$ est G -Lipschitz p.s.

Soit $\bigcup_{f \in F} \text{Supp}(x)$, alors

$$\mathbb{E}(M(P_{\hat{\sigma}^2})) \leq \inf_{\|x\|_2 \leq D} M(P_{\sigma^2}) + \frac{4GD \sqrt{\mathbb{E}(\|\phi(\cdot)\|_2^2)}}{\sqrt{n}}$$