

Séance du 21/02

Notations: $f: \mathbb{R}^d \rightarrow \mathbb{R}$ fonction "cible".

$$\hat{y}^{(N)}(x; \theta) = \frac{1}{N} \sum_{i=1}^N \sigma_{\#}(x; \theta_i)$$

$$R_N(\theta) = \mathbb{E} \left[\left(f(x) - \hat{y}^{(N)}(x; \theta) \right)^2 \right] = \text{risque quadratique moyen.}$$

$$= \mathbb{E} \left[f(x)^2 \right] + \frac{2}{N} \sum_i V(\theta_i) + \frac{1}{N^2} \sum_{i,j} U(\theta_i, \theta_j)$$

$$V(\theta) = \mathbb{E} \left[-f(x) \sigma_{\#}(x; \theta) \right]$$

$$U(\theta_1, \theta_2) = \mathbb{E} \left[\sigma_{\#}(x; \theta_1) \sigma_{\#}(x; \theta_2) \right]$$

$$\Psi(\theta; \rho) = V(\theta) + \int U(\theta, \theta') d\rho(\theta')$$

$$\begin{aligned} G(\theta; \rho) &= -\nabla_{\theta} \Psi = \mathbb{E} \left[f(x) \nabla_{\theta} \sigma_{\#}(x; \theta) \right] \\ &\quad - \int \mathbb{E} \left[\nabla_{\theta} \sigma_{\#}(x; \theta) \sigma_{\#}(x; \theta') \right] d\rho(\theta') \\ &= \mathbb{E} \left[\left(y - \int \sigma_{\#}(x; \theta) d\rho(\theta) \right) \nabla_{\theta} \sigma_{\#}(x; \theta) \right] \end{aligned}$$

Remarque : on définit

$$R(\rho) = \mathbb{E}[\ell(x)] + 2 \int V(\theta) d\rho(\theta) + \int U(\theta, \theta') d\rho(\theta) d\rho(\theta')$$

le risque pour une distribution ρ des paramètres.

Alors $\left| \inf_{\theta} R_N(\theta) - \inf_{\rho} R(\rho) \right| \leq \frac{C}{N}$

Et $\inf_{\theta} R_N(\theta)$ approche le risque minimum à $O(\frac{1}{N})$ près (théor. de Barron). Donc si on trouve un jeu de paramètres tels que $R_N(\theta)$ est proche de $\inf_{\rho} R(\rho)$, on a gagné.

Dynamique : SGD

$$\theta_i^{k+1} = \theta_i^k + \underbrace{2\mathbb{E}(y - \hat{y}(x_k; \theta^k)) \cdot \nabla_{\theta} \sigma_i(x_k; \theta_i^k)}_{F[\theta](x_k; \theta_i^k)}$$

Equation pour $\rho_t(\theta)$:

$$\partial_t \rho = 2 \nabla_{\theta} (\nabla_{\theta} \Psi(\theta; t) \rho_t)$$

On introduit la dynamique:

$$\bar{\theta}_i^t = \theta_i(0) - 2 \int_0^t \nabla_{\theta} \Psi(\bar{\theta}_i^s, \rho_s) ds$$

alors $p_s = \text{loi de } \bar{\Theta}_i(s)$, et les $\bar{\Theta}_i(s)$ sont i.i.d.

But: démontrer que $\hat{p}_k^{(N)} = \frac{1}{N} \sum_i \delta(\theta - \theta_i^k)$

est proche de $p_{k\epsilon}$.

On va démontrer que $|\theta_i^k - \bar{\Theta}_i(k\epsilon)|$ petit
 \uparrow
 $\bar{\Theta}_i^k$

Hypothèses: On suppose toute la régularité
qu'on veut sur σ_x , sur P_x .

On admet toutes les propriétés souhaitées
sur p_t (en particulier: lipschitz en t).

On appellera C toutes les constantes.

Théo: t fixé $k = t/\epsilon$
 $\max_i E[|\theta_i^k - \bar{\Theta}_i^k|] \leq e^{Ct} \times (\dots)$

petit quand $N \rightarrow \infty, \epsilon \rightarrow 0$

$$\begin{aligned} \frac{1}{2} (\theta_i^k - \bar{\theta}_i^k) &= \varepsilon \sum_{\ell=0}^{k-1} F[\theta^\ell](x_\ell; \theta_i^\ell) - \int_0^{k\varepsilon} G(\bar{\theta}_i(s), \rho_s) ds \\ &= \varepsilon \sum_{\ell=0}^{k-1} F[\theta^\ell](x_\ell; \theta_i^\ell) - \sum_{\ell=0}^{k-1} \int_{\ell\varepsilon}^{(\ell+1)\varepsilon} G(\bar{\theta}_i(s), \rho_s) ds \end{aligned}$$

$$G(\bar{\theta}_i^\ell; \rho_{\ell\varepsilon}) + C\varepsilon$$

$\bar{\theta}_i(s), \rho_s$ lipch. en s .

$$\begin{aligned} \frac{1}{2} |\theta_i^k - \bar{\theta}_i^k| &\leq \varepsilon \left| \sum_{\ell=0}^{k-1} F[\theta^\ell](x_\ell; \theta_i^\ell) - G(\bar{\theta}_i^\ell; \rho_{\ell\varepsilon}) \right| \\ &\quad + C\varepsilon^2 k \end{aligned}$$

$\mathcal{F}_\ell =$ tribu engendrée par $\bigvee_{i=1}^n \theta_i(s)$ et x_0, \dots, x_ℓ .

$$\text{Alors } \mathbb{E}[F[\theta^\ell](x_\ell; \theta_i^\ell) | \mathcal{F}_{\ell-1}] = G(\theta_i^\ell, \hat{\rho}_\ell^{(n)})$$

même empirique des θ_i^ℓ

on introduit

$$Z_i^\ell = F[\theta^\ell](x_\ell; \theta_i^\ell) - G(\theta_i^\ell; \hat{\rho}_\ell^{(n)})$$

Alors $\sum_{\ell=0}^{k-1} Z_i^\ell = M_i^{k-1}$: martingale.

Termes à estimer : $\varepsilon \Pi_i^{k-1}$ et $\underbrace{G(\Theta_i^l, \hat{\rho}_l^{(N)}) - G(\bar{\Theta}_i^l, \rho_{l\varepsilon})}_E$

$$|E| \leq \left| G(\Theta_i^l, \hat{\rho}_l^{(N)}) - G(\bar{\Theta}_i^l, \hat{\rho}_l^{(N)}) \right| \leq C |\Theta_i^l - \bar{\Theta}_i^l| \\ + \left| G(\bar{\Theta}_i^l, \hat{\rho}_l^{(N)}) - G(\bar{\Theta}_i^l, \hat{\rho}_l^{(N)}) \right| \leq C \frac{1}{N} \sum_j |\Theta_j^l - \bar{\Theta}_j^l| \\ + \left| G(\bar{\Theta}_i^l, \hat{\rho}_l^{(N)}) - G(\bar{\Theta}_i^l, \rho_{l\varepsilon}) \right| = Y_i^l$$

$$\mathbb{E}(|Y_i^l|) \leq \frac{C}{\sqrt{N}}$$

$$\mathbb{E}(|\Theta_i^k - \bar{\Theta}_i^k|) \leq C \varepsilon \sum_{l=0}^{k-1} \mathbb{E}(|\Theta_i^l - \bar{\Theta}_i^l|) + C \varepsilon \sum_{l=0}^{k-1} \frac{1}{N} \sum_j |\Theta_j^l - \bar{\Theta}_j^l| \\ + L \varepsilon^2 k + \frac{C \varepsilon k}{\sqrt{N}} + \varepsilon C \sqrt{k}$$

$$\Delta_k = \max_i \left(|\Theta_i^k - \bar{\Theta}_i^k| \right) \quad \leftarrow k\varepsilon = t \text{ fixé petit quand } \begin{cases} N \rightarrow \infty \\ \varepsilon \rightarrow 0 \end{cases}$$

$$\Delta_k \leq C \varepsilon \sum_{l=0}^{k-1} \Delta_l + \alpha_k$$

Gronwall discret pour terminer.

$$\text{Si } u_R \leq C \sum_{l=0}^{R-1} u_l + \varepsilon_R$$

also $u_R \leq \varepsilon_R + C(1+C) \sum_{l=0}^{R-1} \varepsilon_l (1+C)^{-l}$

$$\Rightarrow \Delta_R \leq \varepsilon_R + C(1+C)^R \varepsilon_R$$

$$\leq C_1 e^{Ct} \varepsilon_R$$

$$\varepsilon_R \leq L \varepsilon t + \frac{Ct}{\sqrt{N}} + C\sqrt{\varepsilon t}$$