

Séminaire TEST

Andrés SÁNCHEZ PÉREZ

October 18th, 2013

1 Présentation du sujet

Le problème de régression non-paramétrique se pose de la façon suivante :

Supposons que l'on dispose de n couples indépendantes de v.a. $(X_1, Y_1), \dots, (X_T, Y_T)$ telles que :

$$Y_i = \theta(X_i) + \xi_i, \quad X_i \in [0, 1] ,$$

où $\mathbb{E}(\xi_i) = 0$ pour tout i et la fonction dite de régression $\theta : [0, 1] \rightarrow \mathbb{R}$ est inconnue. On cherche à estimer θ qui appartient à un ensemble non-paramétrique (infini-dimensionnel) Θ .

Ça fait partie d'une classe plus large de problèmes, celle de la estimation non paramétrique. On utilisera comme ensemble Θ la classe de Hölder $\Sigma(\beta, L)$.

Definition 1 (Classe de Hölder) Pour $I \subseteq \mathbb{R}$, soient $\beta > 0, L > 0$. La classe de Hölder sur I est l'ensemble de toutes les fonctions $f : I \rightarrow \mathbb{R}$ telles que la dérivée $f^{(\ell)}$, $\ell = \lfloor \beta \rfloor$ existe et vérifie

$$|f^{(\ell)}(x) - f^{(\ell)}(x')| \leq L|x - x'|^{\beta - \ell}, \quad \forall x, x' \in I .$$

Il y a trois éléments qui caractérisent un problème d'estimation non-paramétrique :

- Une classe non-paramétrique de fonctions Θ contenant la "vraie" fonction θ .
- Une famille $\{\mathbb{P}_\theta, \theta \in \Theta\}$ de mesures de probabilité sur un espace mesurable (X_T, \mathcal{A}_T) associé à un T -échantillon.
- Une semi-distance d sur Θ utilisée pour définir le risque.

La performance d'un estimateur $\hat{\theta}_T$ de θ est mesurée par son risque maximal sur θ :

$$r(\hat{\theta}_T) = \sup_{\theta \in \Theta} \mathbb{E}_\theta [d^2(\hat{\theta}_T, \theta)] .$$

Si pour certains estimateurs on a des inégalités du type :

$$\sup_{\theta \in \Theta} \mathbb{E}_\theta [d^2(\hat{\theta}_T, \theta)] \leq C\psi_T^2, \quad (1)$$

avec $\psi_T \rightarrow 0$ et $C < \infty$, on serait intéressés à obtenir des bornes inférieures correspondantes :

$$\forall \hat{\theta}_T, \sup_{\theta \in \Theta} \mathbb{E}_\theta [d^2(\hat{\theta}_T, \theta)] \geq c\psi_T^2. \quad (2)$$

Definition 2 (Risque minimax)

$$\mathcal{R}_T = \inf_{\hat{\theta}_T} \sup_{\theta \in \Theta} \mathbb{E}_\theta [d^2(\hat{\theta}_T, \theta)]$$

Definition 3 (Vitesse optimale de convergence) La suite $\{\psi_T\}_{T \geq 1}$ est dite vitesse optimale de convergence des estimateurs sur (Θ, d) si 1 et 2 sont vérifiées. Un estimateur θ_T^* qui vérifie :

$$\sup_{\theta \in \Theta} \mathbb{E}_\theta \left[d^2(\theta_T^*, \theta) \right] \leq C' \psi_T^2,$$

est dit estimateur optimal en vitesse de convergence sur (Θ, d) .

On peut considérer un cadre plus général où le risque maximal est défini par

$$r_w(\hat{\theta}_T) = \sup_{\theta \in \Theta} \mathbb{E}_\theta \left[w(\psi_T^{-1} d(\hat{\theta}_T, \theta)) \right],$$

avec une fonction perte $w : \mathbb{R}_+ \rightarrow \mathbb{R}_+$ monotone croissante, non identiquement nulle et telle que $w(0) = 0$. Exemple : $w(u) = u^p, p > 0$.

2 Rappels de théorie de la mesure

Definition 4 Soit ν une mesure positive sur (X, \mathcal{A}) et soit $\rho, \bar{\rho}$ des mesures positives (resp. réelles, resp. complexes) sur (X, \mathcal{A}) .

- On dit que ρ est absolument continue par rapport à ν , et l'on note $\rho \ll \nu$, si pour tout $A \in \mathcal{A}$ tel que $\nu(A) = 0$, on a également $\rho(A) = 0$. Si ν et ρ sont σ -finies $\rho \ll \nu \Leftrightarrow \rho(A) = \int_A \frac{d\rho}{d\nu} d\nu$. $\frac{d\rho}{d\nu}$ est la densité de ρ par rapport à ν , qui, dans ce cas est une fonction mesurable positive (resp. -intégrable réelle, resp. -intégrable complexe).
- On dit que ρ est concentrée sur $E \in \mathcal{A}$ si pour tout $A \in \mathcal{A}$ on a $\rho(A) = \rho(A \cap E)$, ou bien encore $\rho(A \setminus E) = 0$.
- On dit que ρ et $\bar{\rho}$ sont étrangères, et l'on note $\rho \perp \bar{\rho}$, s'il existe $E \in \mathcal{A}$ telle que ρ soit portée par E et $\bar{\rho}$ soit portée par E^c .

Theorem 2.1 (Radon-Nikodym-Lebesgue) Soient ν une mesure positive σ -finie sur (X, \mathcal{A}) et μ une mesure positive σ -finie (resp. réelle, resp. complexe) sur (X, \mathcal{A}) . Alors :

(i) Il existe un unique couple de mesures positives σ -finies (resp. réelles, resp. complexes) tel que :

- $\mu = \mu_1 + \mu_2$,
- $\mu_1 \ll \nu$,
- $\mu_2 \perp \nu$

Cette décomposition s'appelle la décomposition de Lebesgue de μ .

(ii) Il existe une unique (à égalité -presque partout près) fonction h, ν -intégrable mesurable positive (resp. réelle, resp. complexe), telle que pour tout $A \in \mathcal{A}$ on ait :

$$\mu_1(A) = \int_A h d\nu = \int_X \mathbb{1}_A h d\nu$$

Cette fonction s'appelle la dérivée de Radon-Nykodym de μ_1 par rapport à ν .

Supposons que ν est une mesure σ -finie sur (X, \mathcal{A}) telle que $P_0 \ll \nu, P_1 \ll \nu$, on définit $p_0 = \frac{dP_0}{d\nu}, p_1 = \frac{dP_1}{d\nu}$. ν existe toujours, par exemple, $\nu = P_0 + P_1$.

Definition 5 (Divergence de Kullback-Leibler) Entre P_0 et P_1 est définie par :

$$\mathcal{K}(P_0, P_1) = \begin{cases} \int \log \frac{dP_0}{dP_1} dP_0 & , \text{ si } P_0 \ll P_1 \\ +\infty & , \text{ sinon.} \end{cases}$$

Si $P_0 \ll P_1$, on a $\{p_1 > 0\} \supseteq \{p_0 > 0\}$, $\{p_0 p_1 > 0\} = \{p_0 > 0\}$. De plus, l'intégrale dans la définition 5 est calculée sur l'ensemble $\{p_0 > 0\}$. On en déduit que si $P_0 \ll P_1$:

$$\mathcal{K}(P_0, P_1) = \int_{p_0 p_1 > 0} p_0 \log \frac{p_0}{p_1} dv .$$

Lemma 1 (Inégalité de Le Cam, 1973)

$$\int \min(p_0, p_1) dv \geq \frac{1}{2} \left(\int \sqrt{p_0 p_1} dv \right)^2$$

Proof du Lemme 1

$$\begin{aligned} \left(\int \sqrt{p_0 p_1} dv \right)^2 &= \left(\int_{p_0 \geq p_1} \sqrt{p_0 p_1} dv + \int_{p_0 < p_1} \sqrt{p_0 p_1} dv \right)^2 \\ &\leq 2 \left[\left(\int_{p_0 \geq p_1} \sqrt{p_0 p_1} dv \right)^2 + \left(\int_{p_0 < p_1} \sqrt{p_0 p_1} dv \right)^2 \right] \\ &\leq 2 \left[\int_{p_0 \geq p_1} p_0 dv \int_{p_0 \geq p_1} p_1 dv + \int_{p_0 < p_1} p_1 dv \int_{p_0 < p_1} p_0 dv \right] \\ &= 2 \int \min(p_0, p_1) dv \end{aligned}$$

■

Lemma 2

$$\int \min(p_0, p_1) dv \geq \frac{1}{2} \exp(-2\mathcal{K}(P_0, P_1)) .$$

Proof du lemme 2

Grâce à l'inégalité de Jensen,

$$\begin{aligned} \left(\int \sqrt{p_0 p_1} dv \right)^2 &= \exp \left(2 \log \int_{p_0 p_1 > 0} \sqrt{p_0 p_1} dv \right) \\ &= \exp \left(2 \log \int_{p_0 p_1 > 0} p_0 \sqrt{\frac{p_1}{p_0}} dv \right) \\ &= \exp \left(2 \log \int_{p_0 p_1 > 0} \sqrt{\frac{dP_1}{dP_0}} dP_0 \right) \end{aligned}$$

$$\begin{aligned} &\geq \exp\left(2 \int_{p_0 p_1 > 0} \log \sqrt{\frac{dP_1}{dP_0}} dP_0\right) \\ &= \exp(-2\mathcal{K}(P_0, P_1)) \end{aligned}$$

On complète la preuve en utilisant l'Inégalité de Le Cam. ■

3 Schéma général de réduction

a) Réduction aux bornes en probabilité :

Soit A une constante telle que $w(A) > 0$, l'inégalité de Markov conduit à :

$$\inf_{\hat{\theta}_T} \sup_{\theta \in \Theta} \mathbb{E}_\theta \left[w(\psi_T^{-1} d(\hat{\theta}_T, \theta)) \right] \geq w(A) \inf_{\hat{\theta}_T} \sup_{\theta \in \Theta} \mathbb{P}_\theta (d(\hat{\theta}_T, \theta) \geq s)$$

avec $s = A\psi_T$.

b) Réduction au problème de test d'un nombre fini d'hypothèses :

$$\inf_{\hat{\theta}_T} \sup_{\theta \in \Theta} \mathbb{P}_\theta (d(\hat{\theta}_T, \theta) \geq s) \geq \inf_{\hat{\theta}_T} \max_{\theta \in \{\theta_0, \dots, \theta_M\}} \mathbb{P}_\theta (d(\hat{\theta}_T, \theta) \geq s) \quad (3)$$

where $\{\theta_0, \dots, \theta_M\} \subset \Theta$. Cet ensemble doit être convenablement choisi.

c) Choix des hypothèses séparées d'une distance d'au moins $2s$:

Si :

$$d(\theta_j, \theta_k) \geq 2s, \quad k \neq j,$$

soit $\psi^* = \arg \min_{0 \leq k \leq M} d(\hat{\theta}_T, \theta_k)$ le test du minimum de distance, alors

$$\psi^* \neq j \Rightarrow d(\theta_{\psi^*}, \hat{\theta}_T) + d(\hat{\theta}_T, \theta_j) \geq d(\theta_{\psi^*}, \theta_j) \geq 2s \Rightarrow d(\hat{\theta}_T, \theta_j) \geq s,$$

et donc $\mathbb{P}_{\theta_j} (d(\hat{\theta}_T, \theta_j) \geq s) \geq \mathbb{P}_{\theta_j} (\psi^* \neq j), \forall j = 0, \dots, M$.

$$\inf_{\hat{\theta}_T} \max_{\theta \in \{\theta_0, \dots, \theta_M\}} \mathbb{P}_\theta (d(\hat{\theta}_T, \theta) \geq s) \geq \inf_{\psi} \max_{0 \leq j \leq M} \mathbb{P}_{\theta_j} (\psi \neq j). \quad (4)$$

L'infimum dans le terme de droite est pris dans l'ensemble de tous les tests, i.e. fonctions (Y_1, \dots, Y_T) -mesurables ψ à valeurs dans $\{0, \dots, M\}$. On note :

$$p_{e,M} = \inf_{\psi} \max_{0 \leq j \leq M} \mathbb{P}_{\theta_j} (\psi \neq j).$$

L'objectif est d'obtenir une borne inférieure pour $p_{e,M}$ qui soit indépendante de T .

Dans la pratique 3 conditions sont cherchées afin de borner $p_{e,M}$:

1. Assurer 3 : $\theta_j \in \Theta, \forall j = 0, \dots, M$.
2. Assurer 4 : $d(\theta_j, \theta_k) \geq 2s > 0, \forall 0 \leq j < k \leq M$.
3. Assurer que $p_{e,M} \geq c > 0$:
 - **Theorem 3.1** Soient P_0, P_1 deux mesures de probabilité sur \mathcal{A} . Si $\mathcal{K}(P_0, P_1) \leq \alpha < \infty$, alors :

$$p_{e,1} \geq \frac{1}{2} \exp(-2\alpha)$$

- **Theorem 3.2** Supposons que Θ contient $M \geq 2$ éléments $\theta_0, \dots, \theta_M$ tels que :
- (i) $d(\theta_j, \theta_k) \geq 2s > 0, \forall 0 \leq j < k \leq M,$
 - (ii) $P_j \ll P_0, \forall 1 \leq j < k \leq M,$ et
 - (iii) $\frac{1}{M} \sum_{j=1}^M K(\mathbb{P}_{\theta_j}, \mathbb{P}_{\theta_0}) \leq \alpha \log M,$ avec $\alpha \in \left(0, \frac{1}{4}\right).$

Alors,

$$p_{e,M} \geq \frac{1}{2} \left(1 - \alpha - \sqrt{\frac{2\alpha}{\log M}} \right) > 0 .$$

Proof du Théorème 3.1

$$\begin{aligned} p_{e,1} &= \inf_{\psi} \max_{j=0,1} P_j(\psi \neq j) \\ &\geq \inf_{\psi} [P_0(\psi \neq 0) + P_1(\psi \neq 1)] \\ &= \inf_{A \in \mathcal{A}} \int [\mathbb{1}_A p_0 + \mathbb{1}_{A^c} p_1] d\nu \\ &= \int \min(p_0, p_1) d\nu \\ &= P_0(\psi^* \neq 0) + P_1(\psi^* \neq 1) \end{aligned}$$

L'ensemble A où l'infimum est atteint est $A^* = \{p_0 \leq p_1\}$ et en conséquence $\psi^* = \mathbb{1}_{A^*}$.
On utilise le lemme 2 et cela donne :

$$\begin{aligned} p_{e,1} &\geq \int \min(p_0, p_1) d\nu \\ &\geq \frac{1}{2} \exp(-2\mathcal{K}(P_0, P_1)) \\ &\geq \frac{1}{2} \exp(-2\alpha) . \end{aligned}$$

■

4 Borne inférieure pour la régression en un point

Exemple d'application des bornes basées sur deux hypothèses dans le modèle de régression vérifiant les conditions suivantes.

- Le modèle statistique est celui de régression non-paramétrique :

$$Y_i = f(X_i) + \xi_i, \quad , i = 1, \dots, T$$

où $f : [0, 1] \rightarrow \mathbb{R}$.

- Les variables aléatoires ξ_i sont i.i.d., de densité p_ξ par rapport à la mesure de Lebesgue sur \mathbb{R} , vérifiant :

$$\exists p_* > 0, v_0 > 0 : \int p_\xi(u) \log \frac{p_\xi(u)}{p_\xi(u+v)} du \leq p_* v^2 ,$$

pour tout $|v| \leq v_0$.

- Les $X_i \in [0, 1]$ sont déterministes.

– Il existe un $a_0 \in \mathbb{R}$ tel que, pour tout intervalle $A \subseteq [0, 1]$ et tout $T \geq 1$,

$$\frac{1}{T} \sum_{i=1}^T \mathbb{1}_{\{X_i \in A\}} \leq a_0 \max\left(\text{Leb}(A), \frac{1}{T}\right)$$

La deuxième condition est satisfaite si, par exemple, p_ξ est la densité de la loi normale $\mathcal{N}(0, \sigma^2)$, $\sigma > 0$.

Notre objectif est d'établir une borne inférieure pour le risque minimax sur (Θ, d) , où $\Theta = \Sigma(\beta, L)$ est une classe de Hölder et pour la semi-distance d , la distance en un point fixé $x \in [0, 1]$: $d(f, g) = |f(x_0) - g(x_0)|$. La vitesse qu'on veut obtenir est $\psi_T = T^{-\frac{\beta}{2\beta+1}}$, la même que dans les bornes supérieures des estimateurs par polynômes locaux par exemple (page 36).

Il nous suffira de prendre $M = 1$ (2 hypothèses) :

$$\theta_0(x) \equiv 0, \quad \theta_1(x) = Lh_T^\beta K\left(\frac{x-x_0}{h_T}\right), \quad x \in [0, 1],$$

où $h_T = c_0 T^{-\frac{1}{2\beta+1}}$, $c_0 > 0$, $L > 0$ et la fonction $K : \mathbb{R} \rightarrow [0, +\infty)$ vérifie :

$K \in \Sigma\left(\beta, \frac{1}{2}\right) \cap C^\infty(\mathbb{R})$, $K(u) > 0 \Leftrightarrow u \in \left(-\frac{1}{2}, \frac{1}{2}\right)$. Les fonctions K vérifiant cette condition existent. Par exemple, on peut prendre, avec un $a > 0$ suffisamment petit,

$$K(u) = aK_0(2u), \quad \text{où} \quad K_0(u) = \exp\left(-\frac{1}{1-u^2}\right) \mathbb{1}_{|u| \leq 1}.$$

Pour pouvoir utiliser le Théorème 3.1 on doit vérifier trois conditions :

– La condition $\theta_j \in \Sigma(\beta, L)$, $j = 0, 1$.

Pour $\ell = \lfloor \beta \rfloor$, la dérivée ℓ -ème de θ_1 vaut $\theta_1^{(\ell)}(x) = Lh_T^{\beta-\ell} K^{(\ell)}\left(\frac{x-x_0}{h_T}\right)$ et alors :

$$\begin{aligned} |\theta_1^{(\ell)}(x) - \theta_1^{(\ell)}(x')| &= Lh_T^{\beta-\ell} \left| K^{(\ell)}\left(\frac{x-x_0}{h_T}\right) - K^{(\ell)}\left(\frac{x'-x_0}{h_T}\right) \right| \\ &\leq \frac{Lh_T^{\beta-\ell}}{2} \left| \frac{x-x_0}{h_T} - \frac{x'-x_0}{h_T} \right|^{\beta-\ell} \\ &= \frac{L}{2} |x-x'|^{\beta-\ell} \end{aligned}$$

Donc $\theta_1 \in \Sigma\left(\beta, \frac{L}{2}\right) \subset \Sigma(\beta, L)$.

– La condition $d(\theta_0, \theta_1) \geq 2s$.

$$d(\theta_0, \theta_1) = |\theta_1(x_0)| = Lh_T^\beta K(0) = Lc_0^\beta K(0) n^{-\frac{\beta}{2\beta+1}}$$

Et la condition est satisfaite avec $A = \frac{1}{2} Lc_0^\beta K(0)$.

– La condition $\mathcal{K}(P_0, P_1) \leq \alpha$.

Notons que P_j (la loi de Y_1, \dots, Y_T pour θ_j) admet une densité par rapport à la mesure de Lebesgue sur \mathbb{R}^T de la forme

$$p_j(u_1, \dots, u_T) = \prod_{i=1}^T p_\xi(u_i - \theta_j(X_i)), \quad j = 0, 1$$

Il existe un entier T_0 tel que pour tout $T > T_0$ on a $Th_T \geq 1$ et $Lh_T^\beta K_{\max} \leq \nu_0$ où $K_{\max} = \max_u K(u)$ et T_0 ne dépend que de $c_0, L, \beta, K_{\max}, \nu_0$. Donc :

$$\begin{aligned}
 \mathcal{K}(P_0, P_1) &= \int \log \frac{dP_0}{dP_1} dP_0 \\
 &= \int \dots \int \log \prod_{i=1}^T \frac{p_\xi(u_i)}{p_\xi(u_i - \theta_1(X_i))} \prod_{i=1}^T [p_\xi(u_i) du_i] \\
 &= \sum_{i=1}^T \int \log \frac{p_\xi(y)}{p_\xi(y - \theta_1(X_i))} p_\xi(y) dy \\
 &\leq p_* \sum_{i=1}^T \theta_1^2(X_i) \\
 &= p_* L^2 h_T^{2\beta} \sum_{i=1}^T K^2 \left(\frac{X_i - x_0}{h_T} \right) \\
 &\leq p_* L^2 h_T^{2\beta} K_{\max}^2 \sum_{i=1}^T \mathbb{1} \left\{ \left| \frac{X_i - x_0}{h_T} \right| \leq \frac{1}{2} \right\} \\
 &\leq p_* a_0 L^2 K_{\max}^2 h_T^{2\beta} \max(Th_T, 1) \\
 &= p_* a_0 L^2 K_{\max}^2 Th_T^{2\beta+1} .
 \end{aligned}$$

Si on choisit $c_0 = \left(\frac{\alpha}{p_* a_0 L^2 K_{\max}^2} \right)^{\frac{1}{2\beta+1}}$, on obtient $\mathcal{K}(P_0, P_1) \leq \alpha$.