

Grandes déviations pour des L -statistiques

H.Boistard

<http://www.eio.uva.es/~helene>

Definition des L -statistiques

Définition 1.

$$A_n = \sum_{i=1}^n a_{n,i} X_{(i)},$$

où $(X_i)_{i=1}^n$ i.i.d. $\sim F$, $(X_{(i)})_{i=1}^n$ la statistique d'ordre, $a_{n,i}$ des coefficients dans \mathbb{R}^k .

Souvent : $a_{n,i} \simeq \frac{1}{n} a\left(\frac{i}{n}\right)$ où $a : [0, 1] \rightarrow \mathbb{R}^k$.

Pour nous : $a_{n,i} = \frac{1}{n} \int_{\frac{i-1}{n}}^{\frac{i}{n}} a(t) dt$. Dans ce cas :

$$A_n = \int_0^1 a(t) F_n^{-1}(t) dt.$$

Exemples de L -statistiques

- α -moyenne recoupée : $\frac{1}{n-2[\alpha n]} \sum_{i=[\alpha n]+1}^{n-[\alpha n]} X_{(i)}$.
- Différence moyenne de Gini : estimateur du paramètre de dispersion $\theta = E(|X_1 - X_2|)$.

$$T_n = \frac{1}{C_n^2} \sum_{i < j} |X_i - X_j| = \frac{1}{C_n^2} \sum_{i=1}^n (-n + 2i - 1) X_{(i)}.$$

- Test d'ajustement de D'Agostino :

$$D = \frac{\sum_{i=1}^n (i - (n+1)2^{-1}) X_{(i)}}{n^2 S_n},$$

avec S_n^2 la variance empirique.

Lois limites

- LGN : via un raffinement du théorème de Glivenko-Cantelli (Wellner (1977, 1978), van Zwet (1980)).
- TCL : via méthode des projections de Hájek (Stigler (1974)), approximation par des U -statistiques (Helmers (1981)), ou processus empiriques (Mason et Shorack (1992)).
- Références complètes : Shorack et Wellner (1986) pour les lois limites, van der Vaart (1998) pour le TCL.

Rappels de grandes déviations

\mathcal{X} un espace de Hausdorff, $\mathcal{B}(\mathcal{X})$ sa tribu de Borel.

Définition 2. $I : \mathcal{X} \rightarrow \mathbb{R}_+ \cup \{+\infty\}$ est appelée fonction de taux (f.t.) si elle est s.c.i. Elle est dite bonne (b.f.t.) si $\forall \alpha$, l'ensemble de niveau

$$\{x : I(x) \leq \alpha\}$$

est compact.

Définition 3. Une suite (R_n) de mesures de probabilité sur $(\mathcal{X}, \mathcal{B}(\mathcal{X}))$ satisfait un PGD de f.t. I si $\forall A \in \mathcal{B}(\mathcal{X})$,

$$-\inf_{x \in \overset{\circ}{A}} I(x) \leq \liminf_{n \rightarrow \infty} \frac{1}{n} \log R_n(A) \leq \limsup_{n \rightarrow \infty} \frac{1}{n} \log R_n(A) \leq -\inf_{x \in \text{clo}(A)} I(x).$$

Outils importants

Proposition 1. (Principe de contraction) \mathcal{X} et \mathcal{Y} deux espaces de Hausdorff, $f : \mathcal{X} \rightarrow \mathcal{Y}$ une fonction continue. (R_n) satisfait un PGD sur \mathcal{X} de b.f.t. I . Alors $(R_n \circ f^{-1})$ satisfait un PGD sur \mathcal{Y} de b.f.t. I' définie pour $y \in \mathcal{Y}$ par :

$$I'(y) = \inf\{I(x) : x \in \mathcal{X}, f(x) = y\}.$$

Proposition 2. (Equivalence exponentielle)

(\mathcal{X}, d) espace métrique. ζ_n et ξ_n deux v.a. à valeurs dans \mathcal{X} . Elles sont exponentiellement équivalentes si $\forall \delta > 0$,

$$\limsup_{n \rightarrow \infty} \frac{1}{n} \log P(d(\zeta_n, \xi_n) > \delta) = -\infty.$$

Dans ce cas (ζ_n) satisfait un PGD de b.f.t. $\Rightarrow (\xi_n)$ satisfait le même PGD.

Théorème fonctionnel sous hypothèse forte de moment exponentiel

$\mathcal{M}_2(\mathbb{R})$ l'espace des fonctions quantile G^{-1} de lois P_G sur \mathbb{R} telles que

$$\int x^2 dP_G = \int_0^1 (G^{-1}(t))^2 dt < \infty.$$

Topologie : héritée de $L_2(0, 1)$. Correspond à la topologie de la distance de Wasserstein sur les mesures de probabilités avec second moment fini :

$$\begin{aligned} \mathcal{W}^2(P_G, P_H) &= \inf \left\{ E(X - Y)^2 : \mathcal{L}(X) = P_G, \mathcal{L}(Y) = P_H \right\} \\ &= \int_0^1 (G^{-1}(t) - H^{-1}(t))^2 dt. \end{aligned}$$

Condition forte de moment exponentiel : $\exists \varphi : \mathbb{R} \rightarrow \mathbb{R}, \varphi(x) \rightarrow +\infty, |x| \rightarrow \infty$, et $t > 0$ tq

$$E \left(e^{tX_1^2 \varphi(X_1)} \right) < +\infty. \quad (1)$$

Théorème 1. *Sous (1), F_n^{-1} satisfait un PGD dans $\mathcal{M}_2(\mathbb{R})$ de bonne fonction de taux*

$$I_1(G^{-1}) = K(G, F).$$

K est la distance de Kullback.

Conséquence : PGD pour $A_n = \int_0^1 a(t) F_n^{-1}(t) dt$ lorsque $a \in L_2(0, 1)$, de b.f.t. :

$$I_2(C) = \inf_{G \text{ f.r.}, \int a G^{-1} = C} K(G, F).$$

Plan de la preuve

- Hypothèse (1) \Rightarrow tension exponentielle de F_n^{-1} .
- Identification de la fonction de taux par théorème de Sanov. (PGD pour la mesure empirique $\nu_n = \frac{1}{n} \sum_{i=1}^n \delta_{X_i \cdot}$)

Application au cas uniforme

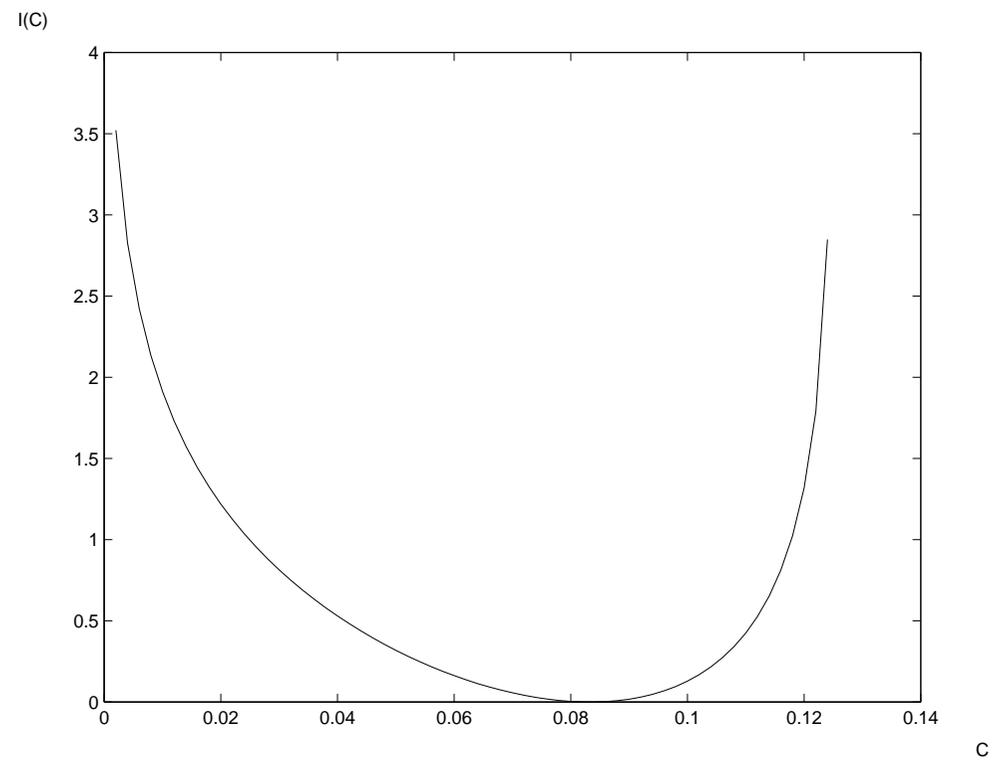
F la loi uniforme sur $[0, 1]$, $a \in L_2(0, 1)$ telle que $E(a(X_1)) = 0$.

PGD pour $\int_0^1 a(t)F_n^{-1}(t)dt$, fonction de taux exprimée grâce à outils de dualité.

Exemple : $a(t) = t - \frac{1}{2}$.

$$I(C) = \sup_{x,y \in \mathbb{R}} 1 + x + Cy + \int_0^1 \log \left(-x - \frac{y}{2}t(1-t) \right) dt.$$

Fonction de taux pour $a(t) = t - \frac{1}{2}$



PGD sous hypothèse de moment plus faible

Condition de moment plus faible :

$$E(e^{sX_1^2}) < \infty, \quad \forall s \in \mathbb{R}. \quad (2)$$

Théorème 2. *Sous (2), F_n^{-1} satisfait un PGD, de b.f.t. :*

$$I_3(G^{-1}) = \sup_{\delta > 0} \liminf_{T \rightarrow \infty} \inf_{\|H^{-1} - G^{-1}\|_2 < \delta} K(H, F^T).$$

Preuve : argument de troncature.

$$X_i^T = -T1_{X_i < -T} + X_i 1_{|X_i| \leq T} + T1_{X_i > T} \text{ satisfait (1).}$$

PGD pour des L -statistiques normalisées

Sous (1),

$$F_n^{-1,N} = \sum_{i=1}^n \mathbf{1}_{\left(\frac{i-1}{n}, \frac{i}{n}\right]} \frac{X_{(i)} - \bar{X}}{\sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}}$$

satisfait un PGD de b.f.t.

$$I_5(G^{-1}) = \begin{cases} \inf_{\mu \in \mathbb{R}, \sigma > 0} K\left(G\left(\frac{\cdot - \mu}{\sigma}\right), F\right) & \text{quand } G \text{ est } (0, 1), \\ +\infty & \text{sinon.} \end{cases}$$

Preuve : la même que Théorème 1, avec la normalisation en plus.

Exemple : statistique D de D'Agostino.

PGD pour la loi exponentielle

PGD fonctionnel pour la mesure

$$\nu_n = \frac{1}{n} \sum_{i=1}^n X_{(i)} \delta_{i/n}.$$

Espace $\mathcal{P}([0, 1])$ des mesures régulières bornées sur $[0, 1]$, muni de la convergence en loi, dual de $\mathcal{C}([0, 1])$.

$$\frac{1}{n} \log E(\exp[\nu_n(na)]) \rightarrow \Lambda(a), \forall a \in \mathcal{C}([0, 1])$$

où

$$\Lambda(a) = \begin{cases} - \int_0^1 \log \left[1 - \frac{\int_{1-t}^1 a(u) du}{t} \right] dt & \text{lorsque l'intégrale est définie} \\ +\infty & \text{sinon.} \end{cases}$$

Application du théorème de Gärtner-Ellis : ν_n satisfait un PGD de bonne fonction de taux

$$\Lambda^*(\mu) = \sup_{a \in C([0,1])} \left[\int_0^1 a(t) d\mu(t) - \Lambda(a) \right].$$

Expression de $\Lambda^*(\mu)$ par dualité : si μ s'écrit $\mu = l\lambda + \mu(\{1\})\delta_1$, où $l(u) = \int_0^u dm(s)$, m a pour décomposition de Lebesgue $m = \alpha\lambda + \chi$ et la mesure singulière $-td\chi(1-t) + \mu(\{1\})\delta_0$ est positive, alors

$$\Lambda^*(\mu) = \int_0^1 (t\alpha(1-t) - \log \alpha(1-t)) dt - \int_0^1 td\chi(1-t) + \mu(\{1\}).$$

Sinon, $\Lambda^*(\mu) = +\infty$.