

I. Cadre de l'étude

- Soient (X_i, Y_i) , $i = 1, \dots, n$ des copies indépendantes du couple aléatoire $(X, Y) \in \mathbb{R}^d \times \mathbb{R}$ avec Y une variable d'intérêt associée à une covariable X .
- Estimer pour tout $x \in \mathbb{R}^d$ et pour tout $\alpha_n \rightarrow 0$, les courbes de niveaux extrêmes définies comme les graphes de fonctions $x \in \mathbb{R}^d \mapsto q(\alpha_n|x) \in \mathbb{R}$ vérifiant

$$\bar{F}(q(\alpha_n|x)|x) \stackrel{\text{def}}{=} \mathbb{P}(Y > q(\alpha_n|x)|X = x) = \alpha_n,$$

lorsque la fonction de répartition conditionnelle de Y sachant $X = x$ est à **variations régulières** d'indice $-1/\gamma(x)$, i.e

$$q(\alpha_n|x) = \alpha_n^{-\gamma(x)} \ell(1/\alpha_n|x),$$

avec $\gamma(\cdot)$ une fonction positive et inconnue de la covariable appelée l'“**indice de queue conditionnel**” et $\ell(\cdot|x)$ une “**fonction à variations lentes**”, i.e pour tout $\lambda > 0$,

$$\lim_{y \rightarrow \infty} \ell(\lambda y|x)/\ell(y|x) = 1.$$

II. Estimateurs

$$\hat{q}_n(\alpha_n|x) = \hat{F}_n^{\leftarrow}(\alpha_n|x) = \inf \left\{ t, \hat{F}_n(t|x) \leq \alpha_n \right\}.$$

\hat{F}_n^{\leftarrow} est l'inverse généralisé de l'estimateur à noyau de la fonction de survie conditionnelle

$$\hat{F}_n(y|x) = \frac{\frac{1}{nh_n^d} \sum_{i=1}^n K\left(\frac{x - X_i}{h_n}\right) \mathbf{1}\{Y_i \geq y\}}{\frac{1}{nh_n^d} \sum_{i=1}^n K\left(\frac{x - X_i}{h_n}\right)} = \frac{\hat{\psi}_n(y, x)}{\hat{g}_n(x)},$$

- La fonction $K(\cdot)$ appelée noyau est positive, bornée, intégrable et à support compact.
- Le paramètre de lissage $h_n \rightarrow 0$ quand $n \rightarrow \infty$.
- La fonction $\hat{g}_n(\cdot)$ est l'estimateur à noyau classique de la densité $g(\cdot)$ de X .
- La fonction $\hat{\psi}_n(y, x)$ est un estimateur de $\psi(y, x) = \bar{F}(y|x)g(x)$.

III. Normalité asymptotique de $\hat{q}_n(\alpha_n|x)$

1. **Collomb (1976)** a étudié le comportement asymptotique de l'estimateur $\hat{g}_n(\cdot)$.
2. Si $\ell(\cdot|x)$ est normalisée et sous des conditions de régularité on établit le comportement asymptotique de l'estimateur $\hat{\psi}_n(y_n, x)$ et on en déduit la loi limite de l'estimateur $\hat{F}_n(y_n|x)$ quand la suite y_n converge lentement vers l'infini.
3. De ce qui précède, pour tout $x \in \mathbb{R}^d$ et pour $j = 1, \dots, J$ tel que $\alpha_{n,j} = \tau_j \alpha_n$, si $\alpha_n \rightarrow 0$ et $nh_n^d \alpha_n \rightarrow \infty$ quand $n \rightarrow \infty$, on déduit que

$$\left\{ \sqrt{nh_n^d \alpha_n} \left(\frac{\hat{q}_n(\alpha_{n,j}|x)}{q(\alpha_{n,j}|x)} - 1 \right) \right\}_{j=1, \dots, J} \xrightarrow{\mathcal{L}} \mathcal{N} \left(0_{\mathbb{R}^J}, \gamma^2(x) \frac{\|K\|_2^2}{g(x)} \Sigma \right),$$

où $\Sigma_{j,j'} = 1/\tau_j \wedge j'$ pour $(j, j') \in \{1, \dots, J\}^2$ avec (τ_j) une suite strictement positive et décroissante.

IV. Estimation de l'indice de queue conditionnel

- Des résultats précédents, on déduit deux estimateurs de l'indice de queue conditionnel :

$$\hat{\gamma}_n^P(x) = \frac{1}{\log 2} \log \left(\frac{\hat{q}_n(\alpha_n|x) - \hat{q}_n(2\alpha_n|x)}{\hat{q}_n(2\alpha_n|x) - \hat{q}_n(4\alpha_n|x)} \right) \quad \text{estimateur de type Pickands}$$

$$\hat{\gamma}_n^H(x) = \frac{\sum_{j=1}^J \log(\hat{q}_n(\alpha_{n,j}|x)/\hat{q}_n(\alpha_{n,1}|x))}{\sum_{j=1}^J \log(\tau_j/\tau_1)} \quad \text{estimateur de type Hill}$$

avec $J > 1$.

- **Condition du second ordre** : la valeur absolue de la fonction $\varepsilon(y|x) \stackrel{\text{def}}{=} y \frac{\ell'(y|x)}{\ell(y|x)}$ est asymptotiquement décroissante et tend vers 0 lorsque $y \rightarrow \infty$.
- Cette condition nous permet d'établir la loi limite des estimateurs $\hat{\gamma}_n^P(x)$ et $\hat{\gamma}_n^H(x)$.

V. Normalité asymptotique de $\hat{\gamma}_n^P(x)$ et $\hat{\gamma}_n^H(x)$

1. Si $\sqrt{nh_n^d \alpha_n} \varepsilon(q(2\alpha_n|x)|x) \rightarrow 0$ quand $n \rightarrow \infty$, alors

$$\sqrt{nh_n^d \alpha_n} (\hat{\gamma}_n^P(x) - \gamma(x)) \xrightarrow{\mathcal{L}} \mathcal{N} \left(0, \frac{\|K\|_2^2 \gamma^2(x) (2^{2\gamma(x)+1} + 1)^2}{g(x) 4(\log 2)^2 (2^{\gamma(x)} - 1)^2} \right),$$

2. Si $\sqrt{nh_n^d \alpha_n} \varepsilon(q(\alpha_{n,1}|x)|x) \rightarrow 0$ quand $n \rightarrow \infty$, alors

$$\sqrt{nh_n^d \alpha_n} \sum_{j=1}^J \log(\tau_j/\tau_1) (\hat{\gamma}_n^H(x) - \gamma(x)) \xrightarrow{\mathcal{L}} \mathcal{N} \left(0, \frac{C \|K\|_2^2 \gamma^2(x)}{g(x)} \right),$$

où $C = (2J + 1) \sum_{j=1}^J 1/\tau_j - 2 \sum_{j=1}^J j/\tau_j - J^2/\tau_1$.

VI. Illustration


- On génère un échantillon $\{(Y_i, x_i), i = 1, \dots, n\}$ de taille $n = 1000$ dont le quantile conditionnel est donné par

$$q(\alpha|x) = \{-\log(1 - \alpha)\}^{-\gamma(x)}, \quad (\text{loi de Fréchet})$$


et où la fonction indice de queue conditionnel est définie par

$$x \in [0, 1] \mapsto \gamma(x) = \frac{1}{2} \left(\frac{1}{10} + \sin(\pi x) \right) \left(\frac{11}{10} - \frac{1}{2} \exp(-64(x - 1/2)^2) \right).$$

- On choisit le paramètre de lissage par validation croisée (**critère de Yao (1999)**).
- On fixe $\alpha_n = 5 \log(n)/n$ et on représente l'estimateur de quantile $\hat{q}_n(\alpha_n|\cdot)$ correspondant.
- On pose $\tau_j = \tau_0/j$ puis on représente l'estimateur $\hat{\gamma}_n^H(\cdot)$ de **variance minimale** ($J = 9$).
- Le paramètre de lissage trouvé par le critère vaut $h_{cv} = 0.164$.



Le quantile extrême conditionnel théorique en noir et son estimateur $\hat{q}_n(\alpha_n|\cdot)$ en bleu.



La fonction indice de queue conditionnel en noir et son estimateur $\hat{\gamma}_n^H(\cdot)$ en bleu.

Références

- [1] A. Daouia, L. Gardes, S. Girard et A. Lekina. Kernel estimators of extreme level curves. <http://hal.inria.fr/inria-00393588/fr/>, 2009.
- [2] G. Collomb. *Estimation non paramétrique de la régression par la méthode du noyau*. PhD thesis, Université Paul Sabatier de Toulouse, 1976.
- [3] B.M. Hill. A simple general approach to inference about the tail of a distribution. *Annals of Statistics*, 3, 1163–1174, 1975.
- [4] J. Pickands. Statistical inference using extreme order statistics. *The Annals of Statistics*, 3 :119–131, 1975.
- [5] Q. Yao. Conditional predictive regions for stochastic processes. *Technical report*, University of Kent at Canterbury, 1999.

Contact : Alexandre.Lekina@inria.fr
<http://mistis.inrialpes.fr/people/lekina>