

# ESTIMATION DE QUANTILES EXTRÊMES POUR DES OBSERVATIONS TRONQUÉES

Laurent Gardes <sup>1</sup> & Gilles Stupfler <sup>2</sup>

<sup>1</sup> *Université de Strasbourg & CNRS, IRMA, UMR 7501, 7 rue René Descartes, 67084 Strasbourg Cedex, France*

<sup>2</sup> *Aix Marseille Université, CERAM, EA 4225, 15-19 allée Claude Forbin, 13628 Aix-en-Provence Cedex 1, France*

**Résumé.** Dans ce travail, nous proposons une famille d'estimateurs non-paramétriques du quantile extrême ainsi que de l'indice des valeurs extrêmes pour des lois à queues lourdes et tronquées à droite. Nous montrons la consistance faible et établissons la normalité asymptotique des estimateurs. Nous terminons par une illustration sur des données simulées.

**Mots-clés.** Loi à queue lourde, indice des valeurs extrêmes, quantile extrêmes.

**Abstract.** The goal of this paper is to provide estimators of the tail index and extreme quantiles of a heavy-tailed random variable when the data is right-truncated. The weak consistency and asymptotic normality of the estimators are established and we illustrate the finite sample performance of our estimators on a simulation study.

**Keywords.** Heavy-tailed distribution, tail index, extreme quantile.

## 1 Présentation du modèle et définition des estimateurs

On considère  $n$  copies indépendantes  $(Y_1, T_1), \dots, (Y_n, T_n)$  d'un vecteur aléatoire  $(Y, T) \in [y_0, \infty) \times [t_0, \infty)$ , où  $y_0 \geq 0$  et  $y_0 \leq t_0$ . La variable  $T$  est une variable de troncature que l'on supposera indépendante de la variable d'intérêt  $Y$ . Nous supposons de plus que les fonctions de répartition marginales  $F$  et  $G$  des variables  $Y$  et  $T$  sont à queue lourde.

(M) Soient  $0 < \gamma_F < \gamma_G$ . Pour tout  $\lambda > 0$ , lorsque  $y \rightarrow \infty$ ,

$$\frac{1 - F(\lambda y)}{1 - F(y)} \rightarrow \lambda^{-1/\gamma_F} \text{ et } \frac{1 - G(\lambda y)}{1 - G(y)} \rightarrow \lambda^{-1/\gamma_G}.$$

L'objectif de ce travail est de proposer une famille d'estimateurs du quantile extrême d'ordre  $\alpha_n \in ]0, 1[$  défini par  $q(\alpha_n) := \inf\{y \geq y_0 \mid 1 - F(y) \leq \alpha_n\}$  avec  $\alpha_n \rightarrow 0$  lorsque

$n \rightarrow \infty$ . L'estimation de  $q(\alpha_n)$  passe par l'estimation de la fonction de répartition empirique. Cependant, la variable  $Y$  étant tronquée par  $T$ , nous disposons uniquement des observations  $(Y_i, T_i)$  pour lesquelles  $Y_i \leq T_i$ . Ainsi, l'estimateur non-paramétrique classique de la fonction de répartition ne peut pas être utilisé dans notre situation. Nous allons construire notre estimateur à l'aide du résultat suivant. Posons

$$F^*(y) = \mathbb{P}(Y \leq y | Y \leq T) \text{ et } G^*(t) = \mathbb{P}(T \leq t | Y \leq T),$$

les fonctions de répartition conditionnelles de  $Y$  et  $T$  sachant  $Y \leq T$ . On peut montrer que pour  $y > y_0$ ,

$$-\log F(y) = \int_y^\infty \frac{dF^*(z)}{F^*(z) - G^*(z)}.$$

Ainsi, pour estimer la fonction de répartition  $F$ , il suffit d'estimer les fonctions de répartition conditionnelles  $F^*$  et  $G^*$ . En posant

$$N := \sum_{i=1}^n \mathbb{I}_{\{Y_i \leq T_i\}},$$

et en notant  $(Y_i^*, T_i^*)$ ,  $1 \leq i \leq N$  les couples observés, les estimateurs classiques de  $F^*$  et  $G^*$  sont donnés par

$$\widehat{F}_N^*(y) = \frac{1}{N} \sum_{i=1}^N \mathbb{I}_{\{Y_i^* \leq y\}} \text{ et } \widehat{G}_N^*(t) = \frac{1}{N} \sum_{i=1}^N \mathbb{I}_{\{T_i^* \leq t\}}.$$

Remarquons que  $N$  suit une loi binomiale de paramètres  $n$  et  $p := \mathbb{P}(Y \leq T)$ . On en déduit facilement des estimateurs de la fonction de répartition et du quantile :

$$\widehat{F}_N(y) = \exp\left(-\frac{1}{N} \sum_{i=1}^N \frac{\mathbb{I}_{\{Y_i^* > y\}}}{\widehat{F}_N^*(Y_i^*) - \widehat{G}_N^*(Y_i^*)}\right) \text{ et } \widehat{q}_N(\alpha) = \inf\left\{y \geq y_0 \mid 1 - \widehat{F}_N(y) \leq \alpha\right\}$$

Comme on le verra dans le Théorème 1, l'estimateur  $\widehat{q}_N(\alpha_n)$  est consistant si  $\alpha_n$  ne converge pas trop rapidement vers zéro. Pour s'affranchir de cette limitation, on remarque que sous le modèle **(M)** et si  $\beta_n < \alpha_n$  sont deux suites positives qui convergent vers zéro et telles que  $\beta_n/\alpha_n \rightarrow 0$  alors  $q(\beta_n) \approx q(\alpha_n) (\alpha_n/\beta_n)^{\gamma_F}$ . Ainsi, pour estimer des quantiles d'ordre arbitrairement proche de zéro, on doit dans un premier temps estimer l'indice des valeurs extrêmes  $\gamma_F$ . On propose la famille d'estimateurs

$$\widehat{\gamma}_{N,F}(k_N, k'_N) = \frac{\widehat{\gamma}_{N,F^*}(k_N) \widehat{\gamma}_{N,G}(k'_N)}{\widehat{\gamma}_{N,G}(k'_N) - \widehat{\gamma}_{N,F^*}(k_N)} \quad (1)$$

où  $\widehat{\gamma}_{N,F^*}(k_N)$  et  $\widehat{\gamma}_{N,G}(k'_N)$  sont les estimateurs de Hill (voir Hill, 1975)

$$\widehat{\gamma}_{N,F^*}(k_N) = \frac{1}{k_N} \sum_{i=1}^{k_N} \log \frac{Y_{N-i+1,N}^*}{Y_{N-k_N,N}^*} \text{ et } \widehat{\gamma}_{N,G}(k'_N) = \frac{1}{k'_N} \sum_{i=1}^{k'_N} \log \frac{T_{N-i+1,N}^*}{T_{N-k'_N,N}^*}.$$

Les suites  $(k_n)$  and  $(k'_n)$  appartiennent à l'ensemble  $\{1, \dots, n-1\}$  et  $Y_{1,N}^* \leq \dots \leq Y_{N,N}^*$ ,  $T_{1,N}^* \leq \dots \leq T_{N,N}^*$  sont les statistiques d'ordre. On en déduit l'estimateur de type Weissman (voir Weissman, 1978) suivant

$$\widehat{q}_N^W(\beta_n | \alpha_n, k_N, k'_N) = \widehat{q}_N(\alpha_n) \left( \frac{\alpha_n}{\beta_n} \right)^{\widehat{\gamma}_{N,F}(k_N, k'_N)}. \quad (2)$$

## 2 Propriétés asymptotiques des estimateurs

Le résultat suivant établit la normalité asymptotique de l'estimateur  $\widehat{q}_N(\alpha_n)$  où  $\alpha_n \rightarrow 0$ .

**Théorème 1** *On suppose la fonction de répartition  $F$  dérivable, telle que  $yF'(y)/(1-F(y)) \rightarrow 1/\gamma_F$  et  $n\alpha_n(1-G(q(\alpha_n))) \rightarrow \infty$ . Sous le modèle **(M)***

$$\sqrt{n\alpha_n(1-G(q(\alpha_n)))} \left( \frac{\widehat{q}_N(\alpha_n)}{q(\alpha_n)} - 1 \right) \xrightarrow{d} \mathcal{N}(0, \gamma_F^2).$$

Pour établir la normalité asymptotique de l'estimateur de type Weissman, on introduit la condition du second ordre ci-dessous :

**(C)** Les fonctions de répartition  $F$  et  $G$  sont dérivables et telles que

$$F'(y) = \left[ \frac{1}{\gamma_F} - \Delta_F(y) \right] \frac{1-F(y)}{y} \quad \text{et} \quad G'(t) = \left[ \frac{1}{\gamma_G} - \Delta_G(t) \right] \frac{1-G(t)}{t},$$

où  $\Delta_F, \Delta_G$  sont des fonctions bornées asymptotiquement de signe constant, qui convergent vers zéro et telles que  $|\Delta_F|$  et  $|\Delta_G|$  sont asymptotiquement monotones et à variations régulières à l'infini d'indices respectifs  $\rho_F/\gamma_F \leq 0$  et  $\rho_G/\gamma_G \leq 0$ .

De plus, posons

$$R_{F^*}(y) = |\Delta_F(y)| \vee |\Delta_G(y)| \quad \text{et} \quad R_{G^*}(t) = |\overline{F}(t)| \vee |\Delta_G(t)|$$

où  $U_{F^*}, U_{G^*}$  sont les inverses généralisées des fonctions of  $1/(1-F^*)$  and  $1/(1-G^*)$ . On a le résultat suivant :

**Théorème 2** *Soient  $\alpha_n \rightarrow 0, \beta_n \rightarrow 0, k_n \wedge k'_n \rightarrow \infty$  et  $(k_n/n \vee k'_n/n) \rightarrow 0$ . Sous le modèle **(M)**, si  $\rho_F/\gamma_F \neq \rho_G/\gamma_G, (\rho_F/\gamma_F) \vee (\rho_G/\gamma_G) \neq -1/\gamma_F, \beta_n/\alpha_n \rightarrow 0, n\alpha_n(1-G(q(\alpha_n))) \rightarrow \infty, n\alpha_n(1-G(q(\alpha_n)))\Delta_F^2(q(\alpha_n)) \rightarrow 0, k_n R_{F^*}^2(U_{F^*}(n/k_n)) \vee k'_n R_{G^*}^2(U_{G^*}(n/k'_n)) \rightarrow 0$ , alors*

$$\frac{k_{[np]} \wedge k'_{[np]}}{n\alpha_n(1-G(q(\alpha_n)))} \rightarrow 1 \quad \text{et} \quad \sup_{q,r \in I_n} \left| \frac{k_q \wedge k'_q}{k_r \wedge k'_r} - 1 \right| \rightarrow 0.$$

Alors, si  $k_n/k'_n \rightarrow 0$  ou  $k'_n/k_n \rightarrow 0$ ,

$$\frac{\sqrt{n\alpha_n(1-G(q(\alpha_n)))}}{\log(\alpha_n/\beta_n)} \left( \frac{\widehat{q}_N^W(\beta_n | \alpha_n, k_N, k'_N)}{q(\beta_n)} - 1 \right) \xrightarrow{d} \mathcal{N}(0, \sigma_F^2),$$

avec  $\sigma_F^2 = p\gamma_F^2[1 + \gamma_F/\gamma_G]^3$  si  $k_n/k'_n \rightarrow 0$  et  $\sigma_F^2 = p\gamma_F^4/\gamma_G^2$  si  $k'_n/k_n \rightarrow 0$ .

### 3 Simulations

On s'intéresse ici au comportement à taille d'échantillon finie des estimateurs  $\widehat{q}_N$  et  $\widehat{q}_N^W$ . Pour ce faire, on considère le modèle :

$$\forall y, t > 0, \overline{F}(y) = (1 + y^{1/\delta})^{-\delta/\gamma_F} \text{ et } \overline{G}(t) = (1 + t^{1/\delta})^{-\delta/\gamma_G},$$

avec  $\delta > 0$  et  $0 < \gamma_F < \gamma_G$ . Dans ce cas, la probabilité de troncature est  $1 - p$ , avec  $p = \gamma_G/(\gamma_F + \gamma_G)$ . En pratique, pour calculer l'estimateur  $\widehat{q}_N$ , on utilise l'expression

$$\widehat{q}_N(\alpha) = \sum_{i=1}^{N-1} Y_{i,N}^* \mathbb{I}_{\{\alpha \in [\Theta_{i+1}, \Theta_i]\}} + Y_{N,N}^* \mathbb{I}_{\{\alpha < \Theta_N\}},$$

où pour tout  $i = 1, \dots, N$ ,

$$\Theta_i = 1 - \exp\left(-\frac{1}{N} \sum_{j=i}^N \frac{1}{\widehat{F}_N^*(Y_{j,n}^*) - \widehat{G}_N^*(Y_{j,n}^*)}\right).$$

L'estimateur  $\widehat{q}_N^W$  est défini pour  $\beta_n \rightarrow 0$  par

$$\widehat{q}_N^W(\beta_n | \alpha_n) = \widehat{q}_N(\alpha_n) \left(\frac{\alpha_n}{\beta_n}\right)^{\widehat{\gamma}_{n,F}(\alpha_n)},$$

où  $\widehat{\gamma}_{n,F}(\alpha_n)$  est l'estimateur de l'indice des valeurs extrêmes  $\gamma_F$  défini par (1) avec  $k_n = k'_n = \lfloor n\alpha_n \rfloor$ . Ainsi, l'estimateur  $\widehat{q}_N^W$  dépend uniquement du choix d'une suite  $\alpha_n$ .

Nous souhaitons ici comparer les estimateurs  $\widehat{q}_N$  et  $\widehat{q}_N^W$  et pour ce faire, on simule  $R = 1000$  échantillons de taille  $n = 200$  dans différentes situations :  $\gamma_F \in \{1/4, 1/2, 1\}$  et  $p \in \{0.7, 0.8, 0.9, 0.95\}$ . Dans chaque cas, pour une suite  $\alpha_n$  donnée, on obtient  $R$  observations des estimateurs  $\widehat{q}_N$  et  $\widehat{q}_N^W$  notées  $\widehat{q}_N^{(r)}$  et  $\widehat{q}_N^{W,(r)}(\cdot | \alpha_n)$ ,  $r = 1, \dots, R$ . La suite  $\alpha_n$  est choisie de la façon suivante :

$$\alpha_{opt}^{(r)} := \arg \min_{\alpha \in (0, 0.15]} \int_{0.07}^{0.15} \log^2 \left( \frac{\widehat{q}_N^{(r)}(\beta)}{\widehat{q}_N^{W,(r)}(\beta | \alpha)} \right) d\beta$$

Ce choix est basé sur l'idée simple que, pour des ordres de quantiles  $\beta$  pas trop petits, les estimateurs  $\widehat{q}_N^{(r)}$  et  $\widehat{q}_N^{W,(r)}(\cdot | \alpha_n)$  doivent être proches si la suite  $\alpha_n$  est bien choisie. On calcule ensuite les erreurs

$$E(\tilde{q}^{(r)}) := \int_0^{0.15} \log^2 \left( \frac{\tilde{q}^{(r)}(\beta)}{q(\beta)} \right) d\beta,$$

où  $\tilde{q}^{(r)}$  correspond soit à l'estimateur  $\widehat{q}_N^{(r)}$  soit à l'estimateur  $\widehat{q}_N^{W,(r)}(\cdot | \alpha_{opt}^{(r)})$ . Pour  $\theta = \{0.1, 0.5, 0.9\}$ , on note  $r(\theta)$  (resp.  $s(\theta)$ ) le numéro de la réplication ayant fourni le quantile

Estimateur $\hat{q}_N^{(r(\theta))}$												
$p$	0.7			0.8			0.9			0.95		
$\theta$	0.1	0.5	0.9	0.1	0.5	0.9	0.1	0.5	0.9	0.1	0.5	0.9
$\gamma_F = 1/4$	0.08	0.10	0.16	0.07	0.08	0.12	0.06	0.07	0.10	0.05	0.06	0.08
$\gamma_F = 1/2$	0.31	0.38	0.60	0.26	0.31	0.45	0.23	0.27	0.36	0.21	0.25	0.32
$\gamma_F = 1$	1.22	1.53	2.27	1.05	1.28	1.82	0.91	1.08	1.49	0.85	0.99	1.29

  

Estimateur $\hat{q}_N^{W,(s(\theta))}(. \alpha_{opt}^{(s(\theta))})$												
$p$	0.7			0.8			0.9			0.95		
$\theta$	0.1	0.5	0.9	0.1	0.5	0.9	0.1	0.5	0.9	0.1	0.5	0.9
$\gamma_F = 1/4$	0.004	0.03	0.22	0.003	0.02	0.10	0.002	0.01	0.06	0.002	0.01	0.04
$\gamma_F = 1/2$	0.01	0.10	0.50	0.007	0.05	0.27	0.004	0.03	0.16	0.004	0.03	0.12
$\gamma_F = 1$	0.04	0.39	1.71	0.03	0.25	1.15	0.02	0.13	0.61	0.01	0.09	0.39

Table 1: Erreurs associées aux estimateurs  $\hat{q}_N^{(r(\theta))}$  et  $\hat{q}_N^{W,(s(\theta))}(.|\alpha_{opt}^{(s(\theta))})$ .

d'ordre  $\theta$  de l'ensemble  $\{E(\hat{q}_N^{(r)}), r = 1, \dots, N\}$  (resp.  $\{E(\hat{q}_N^{W,(r)}), r = 1, \dots, N\}$ ). Le tableau 1 regroupe les valeurs  $E(\hat{q}_N^{(r(\theta))})$  et  $E(\hat{q}_N^{W,(s(\theta))}(.|\alpha_{opt}^{(s(\theta))}))$  dans chacune des situations. On remarque que l'estimateur  $\hat{q}_N^W$  fournit de meilleurs résultats que l'estimateur empirique  $\hat{q}_N$ . De plus, il apparaît que plus la probabilité  $p$  est faible, moins bonne est la qualité d'estimation.

## Bibliographie

- [1] Hill, B.M. (1975). A simple general approach to inference about the tail of a distribution, *Annals of Statistics* **3**: 1163–1174.
- [2] Weissman, I. (1978). Estimation of parameters and large quantiles based on the  $k$  largest observations, *Journal of the American Statistical Association* **73**: 812–815.