

ESTIMATION NON-PARAMETRIQUE DES QUANTILES EXTREMES CONDITIONNELS

Alexandre LEKINA

Doctorant, Equipe Mistis, INRIA Grenoble-Rhône-Alpes & LJK.
<http://mistis.inrialpes.fr/people/lekina>

En collaboration avec Laurent GARDES & Stéphane GIRARD

26 mai 2009

- 1 Motivation
- 2 Cadre d'étude statistique
- 3 Méthode d'estimation
- 4 Estimateurs et lois asymptotiques
- 5 Illustration par simulation

Hydrologie

En fonction de la localisation géographique x , les précipitations sont modélisées par une variable aléatoire Y . On dispose de Y_1, \dots, Y_n hauteurs de précipitations annuelles respectivement en n lieux x_1, \dots, x_n déterministes.

Hydrologie

En fonction de la localisation géographique x , les précipitations sont modélisées par une variable aléatoire Y . On dispose de Y_1, \dots, Y_n hauteurs de précipitations annuelles respectivement en n lieux x_1, \dots, x_n déterministes.

Problème :

- Calculer pour une probabilité $p < 1/n$, une hauteur de précipitation h extrême en un lieu x vérifiant $\mathbb{P}(Y > h|x) = p$.

Hydrologie

En fonction de la localisation géographique x , les précipitations sont modélisées par une variable aléatoire Y . On dispose de Y_1, \dots, Y_n hauteurs de précipitations annuelles respectivement en n lieux x_1, \dots, x_n déterministes.

Problème :

- Calculer pour une probabilité $p < 1/n$, une hauteur de précipitation h extrême en un lieu x vérifiant $\mathbb{P}(Y > h|x) = p$.

Difficultés :

- La fonction de survie conditionnelle $\mathbb{P}(Y > h|x)$ est inconnue et difficile à estimer au-delà de l'observation maximale.
- La hauteur de précipitation h est une fonction de x .

Modèle à plan fixe (design fixe)

- $Y \in \mathbb{R}$ est une v.a associée à une covariable non-aléatoire $x \in E$.
- E désigne un espace métrique muni d'une distance d .
- E peut être **de dimension infinie**.

Modèle à plan fixe (design fixe)

- $Y \in \mathbb{R}$ est une v.a associée à une covariable non-aléatoire $x \in E$.
- E désigne un espace métrique muni d'une distance d .
- E peut être **de dimension infinie**.

But

Estimer pour tout $x \in E$ et tout $\alpha \rightarrow 0$ le réel $q(\alpha, x)$ défini par

$$\mathbb{P}(Y > q(\alpha, x) | x) = \alpha,$$


lorsque la fonction de répartition conditionnelle est dite à **queue lourde**, i.e pour tout $\lambda > 0$, (se référer à Bingham, Goldie et Teugels (1987))

$$\lim_{\alpha \rightarrow 0} \frac{q(\lambda\alpha, x)}{q(\alpha, x)} = \lambda^{-\gamma(x)}, \quad (1)$$

- $\gamma(x) > 0$ est une fonction inconnue de la covariable x appelée "**indice des valeurs extrêmes conditionnel**" (Gardes et Girard (2008)).
- $q(\alpha, x)$: "**quantile extrême conditionnel**" d'ordre $1 - \alpha$.


Méthode

- On dispose d'un échantillon $\{(Y_i, x_i), i = 1, \dots, n\}$ d'observations indépendantes.
- On veut construire en un point $x \in E$ un estimateur du quantile conditionnel $q(\alpha, x)$ lorsque $\alpha \rightarrow 0$.
- Comme l'illustre ce graphique, en ordonnée on a la variable d'intérêt et en abscisse la covariable. Ici $E = [0, 1]$ et $x = 0.37$ (en trait interrompu).



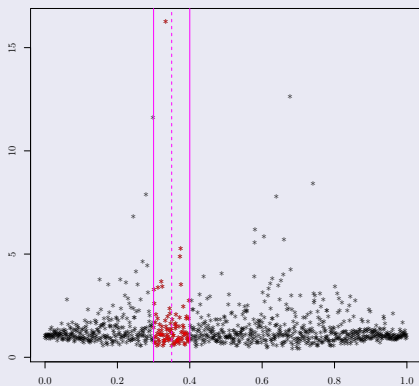
Méthode

- On utilise une méthode de fenêtres mobiles.
- $B(x, r_{n,x})$: le rayon de la boule est choisi tel que $r_{n,x} \rightarrow 0$ quand $n \rightarrow \infty$.



Méthode

- On ne sélectionne que les observations Y_i pour lesquelles $x_i \in B(x, r_{n,x})$.
- On note par $\{Z_i(x), i = 1, \dots, m_{n,x}\}$ ces observations et $Z_{1,m_{n,x}}(x) \leq \dots \leq Z_{m_{n,x},m_{n,x}}(x)$ les statistiques ordonnées correspondantes.




- Trois situations en fonction de la vitesse de convergence de $\alpha_{m_n, x}$ vers 0.

Situation (S.1)

Convergence "lente" de $\alpha_{m_{n,x}}$ vers 0, i.e $\alpha_{m_{n,x}} \rightarrow 0$ et $m_{n,x}\alpha_{m_{n,x}} \rightarrow \infty$.

Quantile théorique d'ordre $\alpha = 10/100 = 0.1$



Situation (S.1) Convergence "lente" : $\alpha_{m_{n,x}} \rightarrow 0$ et $m_{n,x}\alpha_{m_{n,x}} \rightarrow \infty$.

Estimateur

$$\hat{q}_1(\alpha_{m_{n,x}}, x) = Z_{m_{n,x} - \lfloor m_{n,x}\alpha_{m_{n,x}} \rfloor + 1, m_{n,x}}(x). \quad (2)$$

Loi asymptotique (Gardes, Girard & Lekina (2008))

Sous l'hypothèse que $q(\cdot, x)$ soit à variations régulières d'indice $-\gamma(x)$ (cf. équation (1)) et sous des conditions de régularités (du quantile conditionnel)

$$(m_{n,x}\alpha_{m_{n,x}})^{1/2} \left(\frac{\hat{q}_1(\alpha_{m_{n,x}}, x)}{q(\alpha_{m_{n,x}}, x)} - 1 \right) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \gamma^2(x)).$$

Situation (S.1) Convergence "lente" : $\alpha_{m_{n,x}} \rightarrow 0$ et $m_{n,x}\alpha_{m_{n,x}} \rightarrow \infty$.

Estimateur

$$\hat{q}_1(\alpha_{m_{n,x}}, x) = Z_{m_{n,x} - \lfloor m_{n,x}\alpha_{m_{n,x}} \rfloor + 1, m_{n,x}}(x). \quad (2)$$

Loi asymptotique (Gardes, Girard & Lekina (2008))

Sous l'hypothèse que $q(\cdot, x)$ soit à variations régulières d'indice $-\gamma(x)$ (cf. équation (1)) et sous des conditions de régularités (du quantile conditionnel)

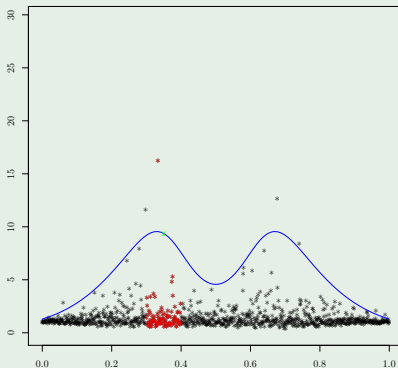
$$(m_{n,x}\alpha_{m_{n,x}})^{1/2} \left(\frac{\hat{q}_1(\alpha_{m_{n,x}}, x)}{q(\alpha_{m_{n,x}}, x)} - 1 \right) \xrightarrow{\mathcal{L}} \mathcal{N}(0, \gamma^2(x)).$$

- La variance asymptotique est inversement proportionnelle à $\alpha_{m_{n,x}}$.
- La variance asymptotique croît avec l'indice de queue $\gamma(x)$.

Situation (S.2)

Convergence "rapide" de $\alpha_{m_{n,x}}$ vers 0, i.e $\alpha_{m_{n,x}} \rightarrow 0$ et $m_{n,x}\alpha_{m_{n,x}} \rightarrow c \geq 1$.

Quantile théorique d'ordre $\alpha = 1/100 = 0.01$



Situation (S.2) Convergence "rapide" : $\alpha_{m_{n,x}} \rightarrow 0$ et $m_{n,x}\alpha_{m_{n,x}} \rightarrow c \geq 1$.

Estimateur

$$\hat{q}_1(\alpha_{m_{n,x}}, x) = Z_{m_{n,x} - \lfloor m_{n,x}\alpha_{m_{n,x}} \rfloor + 1, m_{n,x}}(x).$$

Loi asymptotique (Gardes, Girard & Lekina (2008))

Sous l'hypothèse que $q(\cdot, x)$ soit à variations régulières d'indice $-\gamma(x)$ et sous des conditions de régularités (du quantile conditionnel)

$$\left(\frac{\hat{q}_1(\alpha_{m_{n,x}}, x)}{q(\alpha_{m_{n,x}}, x)} - 1 \right) \xrightarrow{\mathcal{L}} \mathcal{E}(c, \gamma(x))$$

où $\mathcal{E}(c, \gamma(x))$ est une loi non dégénérée et **non gaussienne**.

Situation (S.2) Convergence "rapide" : $\alpha_{m_{n,x}} \rightarrow 0$ et $m_{n,x}\alpha_{m_{n,x}} \rightarrow c \geq 1$.

Estimateur

$$\hat{q}_1(\alpha_{m_{n,x}}, x) = Z_{m_{n,x} - \lfloor m_{n,x}\alpha_{m_{n,x}} \rfloor + 1, m_{n,x}}(x).$$

Loi asymptotique (Gardes, Girard & Lekina (2008))

Sous l'hypothèse que $q(\cdot, x)$ soit à variations régulières d'indice $-\gamma(x)$ et sous des conditions de régularités (du quantile conditionnel)

$$\left(\frac{\hat{q}_1(\alpha_{m_{n,x}}, x)}{q(\alpha_{m_{n,x}}, x)} - 1 \right) \xrightarrow{\mathcal{L}} \mathcal{E}(c, \gamma(x))$$

où $\mathcal{E}(c, \gamma(x))$ est une loi non dégénérée et **non gaussienne**.

- L'estimateur $\hat{q}_1(\alpha_{m_{n,x}}, x)$ n'est pas **constant en un certain sens** i.e

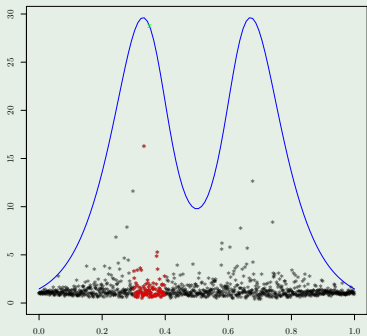
$\frac{\hat{q}_1(\alpha_{m_{n,x}}, x)}{q(\alpha_{m_{n,x}}, x)}$ **ne converge pas en probabilité vers 1** [consistance faible].

Situation (S.3)

Convergence "très rapide" de $\alpha_{m_n, x}$ vers 0, i.e

$$\alpha_{m_n, x} \rightarrow 0 \text{ et } m_{n, x} \alpha_{m_n, x} \rightarrow c \in [0, 1].$$

Quantile théorique d'ordre $\alpha = 0.1/100 = 0.001$



Situation **(S.3)** Convergence “très rapide” de $\alpha_{m_n, x}$ vers 0 :

$$\alpha_{m_n, x} \rightarrow 0 \text{ et } m_{n, x} \alpha_{m_n, x} \rightarrow c \in [0, 1[.$$

Estimateur (Weissman (1978))

$$\hat{q}_2(\alpha_{m_n, x}, x) = \hat{q}_1(\beta_{m_n, x}, x) \left(\frac{\beta_{m_n, x}}{\alpha_{m_n, x}} \right)^{\hat{\gamma}_n(x)}, \quad (3)$$

- $\beta_{m_n, x}$ satisfait **(S.1)**.
- $\hat{\gamma}_n(x)$ est un estimateur de l'indice des valeurs extrêmes conditionnel, (Beirlant et Goegebeur (2002) & Gardes et Girard (2008)).

Situation **(S.3)** Convergence "très rapide" de $\alpha_{m_n, x}$ vers 0 :

$$\alpha_{m_n, x} \rightarrow 0 \text{ et } m_n, x \alpha_{m_n, x} \rightarrow c \in [0, 1].$$

Estimateur (Weissman (1978))

$$\hat{q}_2(\alpha_{m_n, x}, x) = \hat{q}_1(\beta_{m_n, x}, x) \left(\frac{\beta_{m_n, x}}{\alpha_{m_n, x}} \right)^{\hat{\gamma}_n(x)}, \quad (3)$$

- $\beta_{m_n, x}$ satisfait **(S.1)**.
- $\hat{\gamma}_n(x)$ est un estimateur de l'indice des valeurs extrêmes conditionnel, (Beirlant et Goegebeur (2002) & Gardes et Girard (2008)).
- L'estimateur $\hat{q}_2(\cdot, x)$ dépend non seulement de la statistique d'ordre $\hat{q}_1(\cdot, x)$ mais aussi de l'estimateur d'indice de queue $\hat{\gamma}_n(x)$.

Situation **(S.3)** Convergence "très rapide" de $\alpha_{m_n, x}$ vers 0 :

$$\alpha_{m_n, x} \rightarrow 0 \text{ et } m_{n, x} \alpha_{m_n, x} \rightarrow c \in [0, 1[.$$

Loi asymptotique (Gardes, Girard & Lekina (2008))

Si la suite $\beta_{m_n, x}$ satisfait **(S.1)** et s'il existe une suite positive $v_n(x)$ et une loi \mathcal{D} telle que

$$v_n(x) (\hat{\gamma}_n(x) - \gamma(x)) \xrightarrow{\mathcal{L}} \mathcal{D},$$

alors, deux situations se présentent :

(i) Soit la loi asymptotique découle de $\hat{q}_1(\beta_{m_n, x}, x)$ et nous avons

$$(m_{n, x} \alpha_{m_n, x})^{1/2} \left(\frac{\hat{q}_2(\alpha_{m_n, x}, x)}{q(\alpha_{m_n, x}, x)} - 1 \right) \xrightarrow{\mathcal{L}} \mathcal{N} \left(0, \gamma^2(x) \right).$$

(ii) Sinon, elle provient de $\hat{\gamma}_n(x)$ et nous avons

$$\frac{v_n(x)}{\log(\beta_{m_n, x} / \alpha_{m_n, x})} \left(\frac{\hat{q}_2(\alpha_{m_n, x}, x)}{q(\alpha_{m_n, x}, x)} - 1 \right) \xrightarrow{\mathcal{L}} \mathcal{D}.$$

Simulations

- La famille d'estimateurs proposée par Gardes et Girard (2008)

$$\hat{\gamma}_n(x, W) = \sum_{i=1}^{k_{n,x}} i \log \left(\frac{Z_{m_{n,x}-i+1, m_{n,x}}}{Z_{m_{n,x}-i, m_{n,x}}} \right) W(i/k_{n,x}, x) \Big/ \sum_{i=1}^{k_{n,x}} W(i/k_{n,x}, x),$$

- $W(\cdot, x)$ est une fonction de poids définie sur $]0, 1[$ dont l'intégrale vaut 1.
- $k_{n,x} = m_{n,x} \beta_{m_{n,x}}$.

Simulations

- La famille d'estimateurs proposée par Gardes et Girard (2008)

$$\hat{\gamma}_n(x, W) = \sum_{i=1}^{k_{n,x}} i \log \left(\frac{Z_{m_{n,x}-i+1, m_{n,x}}}{Z_{m_{n,x}-i, m_{n,x}}} \right) W(i/k_{n,x}, x) \Big/ \sum_{i=1}^{k_{n,x}} W(i/k_{n,x}, x),$$

- $W(\cdot, x)$ est une fonction de poids définie sur $]0, 1[$ dont l'intégrale vaut 1.
- $k_{n,x} = m_{n,x} \beta_{m_{n,x}}$.

Remarques

- Le choix des paramètres $r_{n,x}$ et $\beta_{m_{n,x}}$ est un problème délicat.

Simulations

- La famille d'estimateurs proposée par Gardes et Girard (2008)

$$\hat{\gamma}_n(x, W) = \frac{\sum_{i=1}^{k_{n,x}} i \log \left(\frac{Z_{m_{n,x}-i+1, m_{n,x}}}{Z_{m_{n,x}-i, m_{n,x}}} \right) W(i/k_{n,x}, x)}{\sum_{i=1}^{k_{n,x}} W(i/k_{n,x}, x)},$$

- $W(\cdot, x)$ est une fonction de poids définie sur $]0, 1[$ dont l'intégrale vaut 1.
- $k_{n,x} = m_{n,x} \beta_{m_{n,x}}$.

Remarques

- Le choix des paramètres $r_{n,x}$ et $\beta_{m_{n,x}}$ est un problème délicat.
- Si $W(\cdot, x) = 1$, alors

$$\hat{\gamma}_n(x) := \hat{\gamma}_n(x, 1) = \frac{1}{k_{n,x}} \sum_{i=1}^{k_{n,x}} i \log \left(Z_{m_{n,x}-i+1, m_{n,x}} / Z_{m_{n,x}-i, m_{n,x}} \right),$$

c'est l'estimateur de Hill (1975) adapté au cas conditionnel.

Simulations

- La famille d'estimateurs proposée par Gardes et Girard (2008)

$$\hat{\gamma}_n(x, W) = \frac{\sum_{i=1}^{k_{n,x}} i \log \left(\frac{Z_{m_{n,x}-i+1, m_{n,x}}}{Z_{m_{n,x}-i, m_{n,x}}} \right) W(i/k_{n,x}, x)}{\sum_{i=1}^{k_{n,x}} W(i/k_{n,x}, x)},$$

- $W(\cdot, x)$ est une fonction de poids définie sur $]0, 1[$ dont l'intégrale vaut 1.
- $k_{n,x} = m_{n,x} \beta_{m_{n,x}}$.

Remarques

- Le choix des paramètres $r_{n,x}$ et $\beta_{m_{n,x}}$ est un problème délicat.
- Si $W(\cdot, x) = 1$, alors

$$\hat{\gamma}_n(x) := \hat{\gamma}_n(x, 1) = \frac{1}{k_{n,x}} \sum_{i=1}^{k_{n,x}} i \log \left(Z_{m_{n,x}-i+1, m_{n,x}} / Z_{m_{n,x}-i, m_{n,x}} \right),$$

c'est l'estimateur de Hill (1975) adapté au cas conditionnel.


- En posant $W(s, x) = -\log(s)$, on retrouve l'estimateur de Zipf (Schultze et Steinebach (1996) & Kratz et Resnick (1996)) adapté au cas conditionnel.

Simulations

- Soit $E = [0, 1]$, on définit la fonction

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

Allure de la fonction $\gamma(x)$



Simulations

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

$$q(\alpha, x) = \left\{ \log \left(\frac{1}{1 - \alpha} \right) \right\}^{-\gamma(x)} \quad (\text{Loi de Fréchet}).$$

Simulations

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

$$q(\alpha, x) = \left\{ \log \left(\frac{1}{1 - \alpha} \right) \right\}^{-\gamma(x)} \quad (\text{Loi de Fréchet}).$$

- On choisit arbitrairement les paramètres $\beta_{m_{n,x}}$ et $r_{n,x}$:

$$\beta_{m_{n,x}} = 0.25 \text{ et } r_{n,x} = 0.1.$$

Simulations

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

$$q(\alpha, x) = \left\{ \log \left(\frac{1}{1 - \alpha} \right) \right\}^{-\gamma(x)} \quad (\text{Loi de Fréchet}).$$

- On choisit arbitrairement les paramètres $\beta_{m_{n,x}}$ et $r_{n,x}$:

$$\beta_{m_{n,x}} = 0.25 \text{ et } r_{n,x} = 0.1.$$

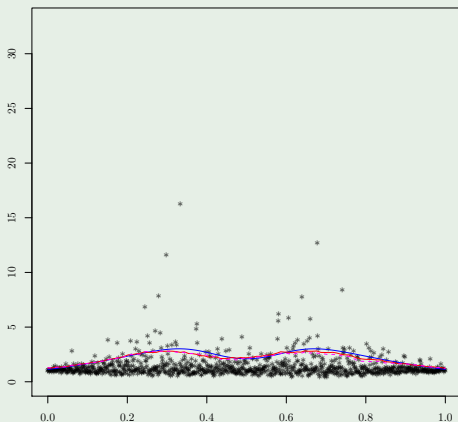
- On utilise l'estimateur

$$\hat{q}_2(\alpha_{m_{n,x}}, x) = \hat{q}_1(\beta_{m_{n,x}}, x) \left(\frac{\beta_{m_{n,x}}}{\alpha_{m_{n,x}}} \right)^{\hat{\gamma}_n(x)}.$$

- $W(s, x) = -\log(s)$ (en magenta) et $W(s, x) = 1$ (en rouge).

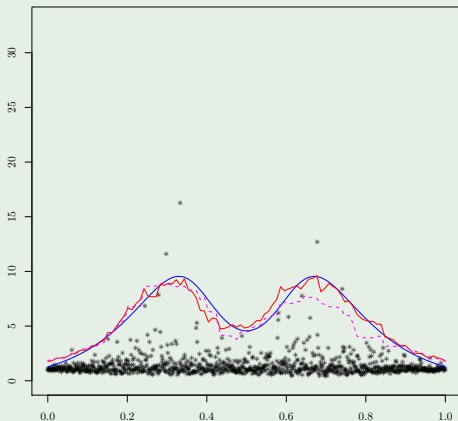
(S.1) Estimation du quantile théorique d'ordre $\alpha = 10/100 = 0.1$ avec $\hat{q}_2(\alpha, x)$

— $\hat{q}_2(\alpha, \cdot)$ avec $W(s, x) = -\log(s)$ et — $\hat{q}_2(\alpha, \cdot)$ avec $W(s, x) = 1$.




(S.2) Estimation du quantile théorique d'ordre $\alpha = 1/100 = 0.01$ avec $\hat{q}_2(\alpha, x)$

— $\hat{q}_2(\alpha, \cdot)$ avec $W(s, x) = -\log(s)$ et — $\hat{q}_2(\alpha, \cdot)$ avec $W(s, x) = 1$.



(S.3) Estimation du quantile théorique d'ordre $\alpha = 0.001$ avec $\hat{q}_2(\alpha, x)$

— $\hat{q}_2(\alpha, \cdot)$ avec $W(s, x) = -\log(s)$ et — $\hat{q}_2(\alpha, \cdot)$ avec $W(s, x) = 1$.



Bibliographie

- [1] Beirlant, J. et Goegebeur, Y. (2004) Local polynomial maximum likelihood estimation for Pareto-type distributions, *Journal of Multivariate Analysis*, 89, 97–118.
- [2] Bingham, N.H., Goldie, C.M. et Teugels, J.L. (1987) *Regular variation*, Encyclopedia of Mathematics and its Applications, 27, Cambridge University Press.
- [3] Gardes, L. et Girard, S. (2008) A moving window approach for nonparametric estimation of the conditional tail index, *Journal of Multivariate Analysis*, 99, 2368–2388.
- [4] Gardes, L., Girard, S. et Lekina, A. (2008) Functional nonparametric estimation of conditional extreme quantiles, <http://hal.archives-ouvertes.fr/hal-00289996/fr/>.
- [5] Hill, B. M. (1975) A simple general approach to inference about the tail of a distribution. *Annals of Statistics*, 3, 1163–1174.
- [6] Kratz, M. et Resnick, S. (1996) The QQ-estimator and heavy tails. *Stochastic Models*, 12, 699–724.
- [7] Schultze, J. et Steinebach, J. (1996) On least squares estimates of an exponential tail coefficient. *Statistics and Decisions*, 14, 353–372.
- [8] Weissman, I. (1978) Estimation of parameters and large quantiles based on the k -largest observations, *Journal of the American Statistical Association*, 73, 812–815.

♣ QUESTIONS ...