

République Algérienne Démocratique et Populaire  
Ministère de l'Enseignement Supérieur et de la Recherche  
Scientifique  
UNIVERSITÉ KASDI MERBAH OUARGLA  
FACULTÉ DE MATHÉMATIQUES ET SCIENCES DE LA  
MATIÈRE  
DÉPARTEMENT DE MATHÉMATIQUES



Mémoire présenté En Vue De L'obtention Du

**DIPLÔME DE MASTER**

EN MATHÉMATIQUES

**Option** : Probabilité et Statistique

Par

BENABED Rabah

Thème

Estimation de la moyenne d'une distribution  
à queue lourde en présence de censure

Membres du jury

BOUSAAD Abdelmalek	Maître assistant classe "A"	UKMO	Président
MANSOUL Brahim	Maître assistant classe "A"	UKMO	Examineur
ARBIA Hanane	Maître assistant classe "A"	UKMO	Rapporteur

novembre 2020

# Dédicace

Je dédie ce modeste travail

A ma tres chère mère et mon très cher père

A mes cheres soeurs et frères

A toute la famille BENABED

A mes chers amis

Je tiens à remercier tous les membres de ma promotion

Et tous mes professeurs

Enfinement à tous ceux qui m'ont aidée de proche ou de loin

## Remerciements

J'exprime d'abord mon profond remerciements à Dieu qui j'ai donné le courage et la volonté d'achever ce travail.

Je remercie particulièrement mes parents ; notre succès demeure de loin le fruit de leurs longues années de sacrifices et d'éducation.

Mon sentiments de reconnaissance et mon remerciements vont à ma Promotrice Dr.ARBIA H, pour ses conseils, ses encouragements, sa patience, sa compétence, ses qualités humaines et scientifiques resterons pour nous un exemple, qui nous en permis de bien mener ce travail. Le suivi et l'orientation dont nous avons pu bénéficier.

Mon remerciements vont au président de jury Pr. BOUSAAD Abdelmalek, merci de nous avoir fait l'honneur d'accepter de présider ce jury.

Mon vif remerciements s'adressent aussi au Pr. MANSOUL Brahim, qui a accepté d'examiner mon travail avec la bienveillance et je suis très honoré.

Un remerciement spécial à notre responsable de spécialité Pr. BEHDDI M, pour sa disponibilité et sa sympathie.

Mon remerciements les plus chaleureux s'adressent à ma soeur MOKHTAR .H, qui a contribué à la réalisation de ce modeste travail.

Merci à tout

# Table des matières

Dédicace	i
Remerciements	ii
Table des matières	iii
Table des figures	v
Notations et abreviations	vi
Introduction	1
<b>1 THÉORIE DES VALEURS EXTRÊMES</b>	<b>3</b>
1.1 Statistique d'Ordre . . . . .	3
1.1.1 Distribution d'une statistique d'ordre . . . . .	4
1.2 Définitions . . . . .	6
1.3 Comportement asymptotique des extrêmes . . . . .	8
1.3.1 Distribution des valeurs extrêmes . . . . .	8
1.4 Distributions GEV . . . . .	9
1.5 Domaines d'attraction . . . . .	11
1.5.1 Caractérisations des domaines d'attraction . . . . .	13
1.6 Distribution GPD . . . . .	16
1.7 Théorème de Balkema-de Haan-Pickands . . . . .	17
1.8 Estimateur de l'indice des valeurs extrêmes . . . . .	17
1.8.1 L'estimateur de Pickands . . . . .	17
1.8.2 Estimateur de Hill (1975) $\hat{\gamma}_{k_n}^H$ . . . . .	19
1.8.3 L'estimateur des moments de Dekkers-Einmahl De Haan	23

<b>2</b>	<b>Introduction à l'analyse de survie</b>	<b>25</b>
2.1	Définitions . . . . .	25
2.2	Données de censure . . . . .	26
2.2.1	Caractéristiques . . . . .	27
2.2.2	Types de censures . . . . .	27
2.3	Estimateur de Kaplan-Meier $\hat{S}(t)$ . . . . .	30
2.4	Estimation de l'indice des valeurs extrême avec censure . . . . .	31
<b>3</b>	<b>ESTIMATION DE LA MOYENNE AVEC CENSURE</b>	<b>35</b>
3.1	Simulation . . . . .	37
	<b>Conclusion</b>	<b>39</b>
	<b>Bibliographie</b>	<b>40</b>

# Table des figures

1.1	Fonction de distribution de Gumbel (en noire) et de Fréchet (en bleu) et de Weibull (en rouge). . . . .	11
1.2	Queue lourde. . . . .	12
1.3	Queue légère. . . . .	12
1.4	Queue finie. . . . .	13
1.5	Représentation des excès $Y$ issus des dépassements $Y$ au-delà d'un seuil $u$ . . . . .	16
1.6	Estimateur de Pickands avec un intervalle de confiance 95% de $\gamma$ basés sur 100 échantillons de taille 3000 pour la loi uniforme. . . . .	19
1.7	L'estimateur de Hill avec un intervalle de confiance 95% de $\gamma$ basés sur 100 échantillons de taille 3000 pour la loi de Pareto standard. . . . .	22
1.8	Estimateur des moments avec un intervalle de confiance 95% de $\gamma$ basés sur 100 échantillons de taille 3000 pour la loi de Gumbel standard. . . . .	24

## Notations et abriviations

$EVD$	:	Distribution des valeurs extrêmes
$EVI, \gamma$	:	Indice des valeurs extrêmes
$F$	:	Fonction de répartition ( $f dr$ )
$F_n$	:	Fonction de répartition empirique
$F^{\leftarrow}$	:	Iverse généralisé de $F$
$GEV$	:	Distribution des valeurs extrêmes généralisée
$GPD$	:	Distribution de pareto généralisée
$G_\gamma$	:	Famille de la loi de valeurs extrêmes généralisée
$iid$	:	Indépendantes et identiquement distribuées
$I_{\{A\}}$	:	Fonction indicatrices de l'ensemble $A$
$A$	:	loi de Gumbel

$\ell(x)$	:	Fonction à variation lente
$DA$	:	Domaine d'attraction de maximum
$M_n = X_{n:n}$	:	Maximum de $X_1, \dots, X_n$
$p.s$	:	Prèsque sûre
$\Phi$	:	Loi de Fréchet
$\Psi$	:	Loi de Weibull
$\Lambda$	:	Loi de Gumbel
$resp$	:	Respectivement
$S = \bar{F}$	:	$1 - F$ fonction de survie
$TEV$	:	Théorème des valeurs extrêmes
$X_{1:n}, \dots, X_{n:n}$	:	Statistique d'ordre associées à $X_1, \dots, X_n$
$X \wedge Y$	:	$\min(X, Y)$
$x_F$	:	Point terminal

$\hat{\gamma}^{(c,H)}$	:	Estimation de Hill avec les données censurées
$(\Omega, A, P)$	:	Espace probabilité
$N(0, 1)$	:	Loi normal standard
$\inf A$	:	Supremum de l'ensemble
$\xrightarrow{p.s}$	:	Converge presque sûre
$\xrightarrow{l}$	:	Converge en loi
$\xrightarrow{d}$	:	Converge en distribution
$\xrightarrow{p}$	:	Converge en probabilité
$Q$	:	Fonction de quantile
$Q_n$	:	Quantile empirique

# Introduction

La théorie des valeurs extrêmes a fourni un cadre dans lequel une estimation des forces anticipées pourrait être faite à l'aide de données historiques.

Apparue au cours des dernières années la modélisation du valeur extrêmes dans le cas censure. En 1997, et en 2007 il a été étudié par *Beirlant et al* [1]. L'étude a continué jusqu'en 2008, ou *Einmahl et al* [6], il a présenté l'indice est de diviser l'indicateur de *Hill* (1975) [10] sur  $\hat{p}$ .

Estimation de la moyenne d'un distribution à queue lourde en présence de censure ont un grand intérêt dans plusieurs domaines mathématiques. Notre sujet se divise en trois chapitres :

Dans le premier chapitre, on a présenté une introduction sur la théorie des valeurs extrêmes et on a défini les statistiques d'ordre, ainsi que les lois exactes des statistiques d'ordre et les lois asymptotiques des valeurs extrêmes. Ensuite, on a donné le résultat fondamental de la distribution *GEV*, ainsi que les caractéristiques des différents domaines d'attraction du maximum puis on a introduit la distribution *GPD* et le théorème de Belkema et de Haan, et on a donné les estimateurs classiques de l'indice de queue tels l'estimateur de Hill, de Pickands et des Moments.

Dans le deuxième chapitre, nous rappelons des préliminaires sur les modèles de survie. Nous introduisons les principales fonctions en analyse de survie : fonction de survie et les différentes formes du taux de risque...ect. Nous donnons aussi les différents types de censure (censure à droite, censure à gauche, censure par intervalle, ect....) et on a présenté les principaux estimateurs non-paramétriques qui sont l'estimateur de Kaplan-Meier de fonction de survie .Dans la dernière partie on présentera l'estimateur de l'indice des valeurs extrêmes avec censure.

Le troisième chapitre traite l'estimation des moyennes aléatoires. L'objectif principal de ce chapitre est de proposer une méthode pour estimer la moyenne de distribution à queue lourde en présence de censure.

# Chapitre 1

## THÉORIE DES VALEURS EXTRÊMES

La théorie des valeurs extrêmes (**TVE**) communément appelée «**Extrême Value Theory**» (**EVT**) en anglais, est une vaste théorie dont le but est d'étudier les événements rares c'est-à-dire les événements dont la probabilité d'apparition est faible. Autrement dit, elle essaie d'amener des éléments de réponses aux intempéries, aux catastrophes naturelles, aux problèmes financiers, ... etc. Les ouvrages de *Reiss et Thomas (2007)*[18], *Embrechts et al. (1997)*[7], *Beirlant et al. (2007)*[1], qui font le point sur les différentes techniques existantes.

### 1.1 Statistique d'Ordre

Les statistiques d'ordre fournissent des informations sur la distribution de queue, pour ça ils sont très importantes dans la théorie des valeurs extrêmes. en effet, de façon naturelle et depuis long-temps, dans les problèmes de données censurées ou tronquées.

Soit  $X_1, X_2, \dots, X_n$   $n$  variables aléatoires iid de distribution commune  $F$ . les va's  $X_{1,n}, X_{2,n}, \dots, X_{n,n}$  sont rangés par ordre croissante, soit :

$$X_{1,n} \leq X_{2,n} \leq \dots \leq X_{n,n}$$

sont appelées les statistiques d'ordre de l'échantillon  $X_1, X_2, \dots, X_n$ .

Deux statistiques d'ordre sont particulièrement intéressantes pour l'étude des événements extrêmes. Ce sont les statistiques d'ordre extrêmes qui sont données par la définition suivante :

$$X_{1,n} = \min(X_1, \dots, X_n) \text{ et } X_{n,n} = \max(X_1, \dots, X_n)$$

On note qu'il est très facile de passer de l'un à l'autre à l'aide de la relation :

$$\min(X_1, \dots, X_n) = -\max(-X_1, \dots, -X_n)$$

Dans la suite de ce mémoire, on se concentrera sur l'étude du maximum.

### 1.1.1 Distribution d'une statistique d'ordre

**Loi de  $X_{i,n}$ .**

$$F_{i,n} = P\{X_{i,n} \leq x\} = \sum_{r=i}^n C_r^n (F(x))^r (1 - F(x))^{n-r}.$$

Nous en déduisons que la fonction de densité est :

$$f_{i,n}(x) = \frac{n!}{(i-1)!(n-i)!} [F(x)]^{i-1} [1 - F(x)]^{n-i} f(x),$$

où  $f(x)$  est la densité de probabilité de  $X_i$  et  $F$  sa fonction de répartition associée.

**Loi de  $X_{1,n}$**

On a

$$\begin{aligned} \{X_{1,n} \geq x\} &\iff \{\min(X_1, \dots, X_n) \geq x\} \\ &\iff \bigcap_{i=1}^n \{X_i \geq x\} \end{aligned}$$

En utilisant la propriété d'indépendance des variables aléatoires  $X_1, \dots, X_n$  nous en déduisons que :

$$\begin{aligned} F_{1,n}(x) &= P\{X_{1,n} \leq x\} \\ &= 1 - P\{X_{1,n} \geq x\} \\ &= 1 - P\left\{\bigcap_{i=1}^n \{X_i \geq x\}\right\} \\ &= 1 - \prod_{i=1}^n P\{X_i \geq x\} \\ &= 1 - \prod_{i=1}^n [1 - P\{X_i \leq x\}] \\ &= 1 - [1 - F(x)]^n, \end{aligned}$$

d'où,

$$f_{1,n}(x) = nf(x)(1 - F(x))^{n-1}$$

**Loi de  $X_{n,n}$**

On a

$$\begin{aligned} \{X_{n,n} \leq x\} &\iff \{\max(X_1, \dots, X_n) \leq x\} \\ &\iff \bigcap_{i=1}^n \{X_i \leq x\} \end{aligned}$$

En utilisant la propriété d'indépendance des variables aléatoires  $X_1, \dots, X_n$ , nous en déduisons que :

$$\begin{aligned}
F_{n,n}(x) &= P\{X_{n,n} \leq x\} \\
&= P\{\cap_{i=1}^n \{X_i \leq x\}\} \\
&= \prod_{i=1}^n P\{X_i \leq x\} \\
&= [F(x)]^n,
\end{aligned}$$

d'où,

$$f_{n,n}(x) = nf(x)(F(x))^{n-1}$$

## 1.2 Définitions

**Définition 1.1 (La fonction de répartition empirique)** *La fonction de répartition empirique de l'échantillon  $(X_1, \dots, X_n)$  notée  $F_n$  est donnée par :*

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n 1_{]-\infty, x[}(X_i), \quad x \in \mathbb{R}.$$

Il existe une autre version de la définition de  $F_n$  :

$$F_n(x) = \begin{cases} 0 & \text{si, } x \leq X_{1,n} \\ \frac{i-1}{n} & \text{si, } X_{i-1,n} < x \leq X_{i,n} \quad 2 \leq i < n \\ 1 & \text{si, } x > X_{n,n} \end{cases}$$

**Définition 1.2 (Les fonctions de quantile et de quantile de queue)**

*On définit la fonction des quantiles  $Q$  par :*

$$Q(s) = F^{\leftarrow}(s) = \inf \{x \in \mathbb{R} : F(x) \geq s\}, \quad 0 < s < 1,$$

où  $F^{\leftarrow}$  est l'inverse généralisée de  $F$ . Dans la théorie des extrêmes une fonction, notée par  $U$  et (parfois) appelée la fonction quantile de queue, est utilisée assez souvent et elle est définie comme :

$$U(t) = Q(1 - 1/t) = (1/\bar{F})^{\leftarrow}(t), \quad 1 < t < \infty,$$

où

$$\bar{F}(t) = 1 - F(t)$$

**Définition 1.3 (La fonction de survie)** *La fonction de survie est pour  $t$  fixé, probabilité de survivre jusqu'à l'instant  $t$ , c'est-à-dire pour  $t \geq 0$*

$$\begin{aligned} S(t) &= 1 - F(x) \\ &= P(X > t) \end{aligned}$$

**Définition 1.4 (Fonctions empiriques de répartition et de survie)** *Soit  $X_1, \dots, X_n$  un échantillon de taille  $n \geq 1$  d'une v.a positive  $X$  de fonction de répartition  $F$  et de fonction de survie  $\bar{F}$ . Les fonctions empiriques de répartition et de survie,  $F_n$  et  $\bar{F}_n$  sont respectivement définies par :*

$$F_n(t) = \frac{1}{n} \sum_{i=1}^n 1\{X_i \leq t\}, \quad \forall t \geq 0$$

et

$$\begin{aligned} \bar{F}_n(t) &= 1 - F_n(t) \\ &= \frac{1}{n} \sum_{i=1}^n 1\{X_i > t\}, \quad \forall t \geq 0 \end{aligned}$$

où  $1\{A\}$  est la fonction indicatrice de l'ensemble  $A$ .

**Théorème 1.1 (Théorème Central Limite)** *Soit  $X_1, \dots, X_n$  une suite de variables aléatoires i.i.d de moyenne  $\mu$  et de variance  $\sigma^2$  finie, alors :*

$$\sqrt{n} \frac{X_i - \mu}{\sigma} \xrightarrow{d} N(0, 1) \quad \text{quand } n \longrightarrow \infty$$

## 1.3 Comportement asymptotique des extrêmes

Nous posons

$$M_n = \max(X_1, \dots, X_n).$$

Nous tirons la conclusion que le maximum  $M_n$  est une variable aléatoire dont la fonction de répartition est égale à  $(F_X)^n$ . La fonction de répartition de  $X$  étant souvent inconnue et généralement pas possible d'être déterminée. Notons  $x_F = \sup \{x \in \mathbb{R} : F_X(x) < 1\}$  le point terminal à droite de la fonction de répartition  $F_X$ . Ce point terminal peut être infini ou fini (*Embrechts et al. 1997*[7]). On s'intéresse ici à la distribution asymptotique du maximum, en faisant tendre  $n$  vers l'infini,

$$\lim_{n \rightarrow \infty} F_{M_n}(x) = \lim_{n \rightarrow \infty} [F_X(x)]^n = \begin{cases} 0 & \text{si } F(x) < 1 \\ 1 & \text{si } F(x) = 1 \end{cases}$$

On constate que la distribution asymptotique du maximum, donne une loi dégénérée, une masse de Dirac en  $x_F$ , puisque pour certaines valeurs de  $x$ , la probabilité peut être égale à 1 dans le cas où  $x_F$  est fini. Donc  $M_n$  tend vers  $x_F$  presque sûrement, Ce fait ne fournit pas assez d'informations. On s'intéresse par conséquent à une loi non dégénérée pour le maximum, la théorie des valeurs extrêmes permet de donner une réponse à cette problématique. Les premiers résultats sur la caractérisation du comportement asymptotique des maxima  $M_n$  convenablement normalisés et donnés par la suite :

### 1.3.1 Distribution des valeurs extrêmes

**Théorème 1.2 (Fisher et Tippett, 1928, Gnedenko, 1943)** [8], [9] *Soit  $X_1, \dots, X_n$  une suite de  $n$  variables aléatoires réelles i.i.d de loi continue  $P$  et  $M_n = \max(X_1, \dots, X_n)$ . S'il existe deux suites réelles  $(a_n)_{n \geq 1}$  et  $(b_n)_{n \geq 1}$ , avec  $b_n > 0$ , et une fonction de répartition non-dégénérée  $G_\gamma$  telle que,*

$$\begin{aligned} \lim_{n \rightarrow \infty} P \left[ \frac{M_n - b_n}{a_n} \leq x \right] &= \lim_{n \rightarrow \infty} [F(a_n x + b_n)]^n \\ &= G_\gamma(x), \quad \forall x \in \mathbb{R} \end{aligned}$$

Alors  $G_\gamma$  est du même type qu'une des trois lois suivantes :

loi de Gumbel :

$$\Lambda_\gamma(x) = \exp(-\exp(-x)) \quad -\infty < x < +\infty$$

loi de Fréchet :

$$\Phi_\gamma(x) = \begin{cases} 0 & x < 0 \\ \exp(-x^{-1/\gamma}) & x \geq 0, \gamma > 0, \end{cases}$$

loi de Weibull :

$$\Psi_\gamma(x) = \begin{cases} \exp(-(-x)^{-1/\gamma}) & x < 0, \gamma < 0, \\ 1 & x \geq 0, \end{cases}$$

avec,  $G_\gamma$  est la loi des valeurs extrêmes,  $\gamma$  est l'indice des valeurs extrêmes et  $a_n$  et  $b_n$  sont des paramètres de normalisation. Ce théorème donne la forme des lois limites de  $G_\gamma$ .

## 1.4 Distributions GEV

Il est difficile de travailler avec trois familles à la fois, *Jenkinson* en 1955 [11] montre que ces trois familles peuvent être regroupées sous une forme unique dite famille des lois des valeurs extrêmes généralisées (GEV, Generalized Extreme Value distribution).

**Définition 1.5 (Distribution GEV)** *La fonction de répartition de la famille  $G$  des valeurs extrêmes généralisées GEV, est pour  $\gamma \in \mathbb{R}$  et  $1 + \gamma x > 0$*

$$G_\gamma(x) = \begin{cases} \exp\left(- (1 + \gamma x)^{-1/\gamma}\right), & \forall x \in \mathbb{R}, \quad 1 + \gamma x > 0 \text{ si } \gamma \neq 0 \\ \exp(-\exp(-x)), & \forall x \in \mathbb{R}, \quad \text{si } \gamma = 0 \end{cases}$$

La forme la plus générale de la distribution des valeurs extrêmes est :

$$G_{\gamma,\mu,\sigma} = \exp\left(- \left(1 + \gamma \frac{x - \mu}{\sigma}\right)^{-\frac{1}{\gamma}}\right), \gamma \neq 0, 1 + \gamma \frac{x - \mu}{\sigma} > 0.$$

où  $G$  est une fonction de répartition non-dégénérée.  $\mu$  est un paramètre de localisation, il est directement lié à la valeur la plus probable de la loi, il indique donc approximativement où se trouve le coeur de la distribution.  $\sigma$  est un paramètre de dispersion, il indique l'étalement des extrêmes.  $\gamma$  est l'indice de queue.

**Remarque 1.1** - Les trois lois des extrêmes peuvent être représentés en fonction de  $G_\gamma$  par

$$G_\gamma = \begin{cases} \Lambda(x) & \gamma = 0 \\ \Phi_{\frac{1}{\gamma}}(x) & \gamma > 0 \\ \Psi_{-\frac{1}{\gamma}}(x) & \gamma < 0 \end{cases}$$

La densité correspondante à  $G_{\gamma,\mu,\sigma}$  est :

$$G_{\gamma,\mu,\sigma} = \begin{cases} \frac{1}{\sigma} \left(1 + \gamma \frac{x - \mu}{\sigma}\right)^{-\left(\frac{1+\gamma}{\gamma}\right)} \exp\left(- \left(1 + \gamma \frac{x - \mu}{\sigma}\right)^{-\frac{1}{\gamma}}\right), & \text{si } \gamma \neq 0, 1 + \gamma \frac{x - \mu}{\sigma} > 0 \\ \exp\left(- \left(\frac{x - \mu}{\sigma}\right) - \exp\left(-\frac{x - \mu}{\sigma}\right)\right), & \text{si } \gamma = 0, -\infty \leq x \leq \infty \end{cases}$$

Cette densité est présentée dans la figure suivante




FIG. 1.1 – Fonction de distribution de Gumbel (en noire) et de Fréchet (en bleu) et de Weibull (en rouge).

## 1.5 Domaines d'attraction

Le théorème précédant découle immédiatement que le comportement de la queue de distribution d'une fonction est complètement caractérisé par un unique paramètre noté  $\gamma$ , et appelé indice des valeurs extrêmes. Le signe de ce paramètre est un indicateur essentiel sur la forme de la queue de distribution. il faut donc distinguer les trois cas possibles :

- Si  $\gamma > 0$ ,  $F$  appartient au domaine d'attraction de Fréchet, et l'on note  $F \in D(\text{Fréchet})$ , Il contient toutes les lois dont la fonction de survie décroît comme une fonction puissance. Ce sont les lois à «queue lourde» ou lois de type Pareto, ces lois ont un point terminal  $x_F$  infini, ex : Burr, Pareto strict,...ect.
- Si  $\gamma = 0$ ,  $F$  appartient au domaine d'attraction de Gumbel, et l'on note  $F \in D(\text{Gumbel})$ , les queues des lois appartenant à ce domaine décroissent de manière exponentielle (i.e. les lois à queue légères) et le point terminal  $x_F$  peut être fini ou non, ex : Gamma, Logestic,...ect.
- Si  $\gamma < 0$ ,  $F$  appartient au domaine d'attraction de Weibull, et l'on note  $F \in D(\text{Weibull})$ , les lois de ce domaine d'attraction ont un point terminal  $x_F$  fini, ex : uniforme,...ect.




FIG. 1.2 – Queue lourde.




FIG. 1.3 – Queue légère.




FIG. 1.4 – Queue finie.

### 1.5.1 Caractérisations des domaines d'attraction

Nous donnons dans cette partie la caractérisation des trois domaines d'attraction, Fréchet, Weibull et Gumbel.

D'abord, nous donnons la définition d'une fonction variation régulière parce qu'elle est présente dans la caractérisation des domaines d'attraction.

**Définition 1.6 (Fonctions à variation régulière)** *Une fonction mesurable  $f : \mathbb{R}_+ \rightarrow \mathbb{R}_+$  est à variation régulière l'infini si et seulement si, il existe un réel  $\alpha$  tel que, pour tout  $x > 0$ ,*

$$\lim_{x \rightarrow \infty} \frac{f(tx)}{f(x)} = x^\alpha$$

Et on note  $f \in VR_\alpha$ ,  $\alpha$  est appelé indice de la fonction variation régulière.

**Proposition 1.1** *Soient  $\alpha \in \mathbb{R}$  et  $f \in VR_\alpha$  alors il existe une fonction à variation lente  $l$  à l'infini telle que :*

$$\forall x > 0; f(x) = x^\alpha l(x).$$

**Définition 1.7** Une fonction de répartition  $F$  sur  $\mathbb{R}$  appartient une classe à variation régulière  $VR$  s'il existe  $\alpha \geq 0$  tel que  $1 - F \in VR_{-\alpha}$  sur  $\mathbb{R}$ , ou d'une manière équivalente :

$$1 - F(x) \sim x^{-\alpha} l(x), \text{ quand } x \rightarrow \infty,$$

pour certaines  $l \in RV_0$ .

### Domaine d'attraction de Fréchet

**Théorème 1.3** Une fonction de répartition  $F$  appartient au domaine d'attraction de Fréchet avec un indice des valeurs extrêmes  $\gamma > 0$  si et seulement si

$$x_F = \sup\{x : F(x) < 1\} = +\infty$$

et sa fonction de survie  $\bar{F} \in RV_{-1/\gamma}$  :

$$1 - F(x) = x^{-1/\gamma} l(x)$$

Dans ce cas un choix possible des suites de normalisation  $a_n$  et  $b_n$  est :

$$a_n = \bar{F}\left(1 - \frac{1}{n}\right) = \bar{F}^{\leftarrow}\left(\frac{1}{n}\right) \text{ et } b_n = 0$$

### Domaine d'attraction de Gumbel

**Théorème 1.4** Une fonction de répartition  $F$  appartient au domaine d'attraction de Gumbel si et seulement si

$$x_F \leq \infty \text{ et } \bar{F}(x) = c(x) \exp\left\{-\int_y^x \frac{g(t)}{a(t)} dt\right\}, \quad y < x < x_F,$$

où  $c(x) \rightarrow c > 0$ ,  $g(x) \rightarrow 1$  et  $a'(x) \rightarrow 0$  si  $x \rightarrow x_F$ .

un choix possible pour la fonction  $a$  est la fonction moyenne des excès définie par :

$$a(x) = \frac{1}{F(x)} \int_x^{x_F} F(t) dt, \quad x < x_F.$$

Dans ce cas les suites  $a_n$  et  $b_n$  sont ainsi définies :

$$b_n = F^{\leftarrow}\left(1 - \frac{1}{n}\right) \text{ et } a_n = a(b_n).$$

### Domaine d'attraction de Weibull

**Théorème 1.5** Une fonction de répartition  $F$  appartient au domaine d'attraction de Weibull avec  $\gamma < 0$  si et seulement si  $x_F < +\infty$  et en plus  $1 - F^*$  est une fonction à variation régulière d'indice  $-1/\gamma$  c'est-à-dire

$$F^* = 1 - (x_F - x)^{-1/\gamma} l((x_F - x)^{-1})$$

avec

$$F^*(x) = \begin{cases} 0 & \text{si } x \leq 0, \\ F(x_F - x^{-1}) & \text{sinon.} \end{cases}$$

où  $l$  est une fonction à variation lente à l'infini ( $l \in RV_0$ ).

Dans ce domaine d'attraction les suites de normalisation sont déterminées comme suit :

$$a_n = x_F - F^{\leftarrow}\left(1 - \frac{1}{n}\right) \text{ et } b_n = x_F.$$

## 1.6 Distribution GPD

Pickands a introduit la méthode POT (**P**eaks-**o**ver-**T**hreshold) encore appelée méthode des excès au-delà d'un certain seuil réel  $u$  suffisamment grand, inférieur au point terminal ( $u < x_F$ ). Cette méthode consiste à utiliser les observations qui dépassent un certain seuil, plus particulièrement les différences entre ces observations et le seuil, appelées "excès".

Soient un échantillon de  $n$  v.a.s i.i.d  $X_1, \dots, X_n$  et  $u$  un seuil fixé tel que  $u < x_F$ . On note par  $N_u$  le nombre d'excédances  $X_1, \dots, X_{N_u}$  qui dépassent le seuil  $u$ . On appelle excès au-delà du seuil  $u$  les  $Y_j = X_i - u$ , pour  $j = 1, \dots, N_u$ .

Le principe de cette méthode est représenté dans la figure suivante




FIG. 1.5 – Représentation des excès  $Y$  issus des dépassements  $X$  au-delà d'un seuil  $u$ .

**Définition 1.8 (La fonction de distribution des excès)** Nous définissons la fonction de distribution des excès au-dessus du seuil  $u$  par :

$$\begin{aligned} F_u(y) &= P(Y \leq y \mid X > u) \\ &= P(X - u < y \mid X > u) \\ &= \frac{F(u + y) - F(u)}{1 - F(u)} \end{aligned}$$

Si  $F$  appartient à l'un des trois domaines d'attraction de la loi des valeurs extrêmes (Fréchet, Gumbel ou Weibull), alors il existe une fonction  $\sigma(u)$  strictement positive et un  $\gamma \in \mathbb{R}$  tels que :

$$G_{\gamma,\sigma}(y) = \begin{cases} 1 - (1 - \gamma \frac{y}{\sigma})^{-\frac{1}{\gamma}} & \text{si } \gamma \neq 0, \sigma > 0, \\ 1 - \exp(-\frac{y}{\sigma}) & \text{si } \gamma = 0, \sigma > 0, \end{cases}$$

## 1.7 Théorème de Balkema-de Haan-Pickands

Le théorème suivant fait le lien entre le comportement asymptotique de la distribution des excès et la loi de Pareto généralisé.

**Théorème 1.6 (de Balkema-de Haan-Pickands)** *Soit  $F_u$  la distribution des excès. Si  $F \in DA(H_\gamma)$ , la GPD est la distribution limite de la distribution des excès lorsque le seuil tend vers  $x_F$  :*

$$\lim_{u \rightarrow x_F} \sup_{0 \leq x \leq x_F - u} |F_u(x) - G_{\gamma,\beta(u)}(x)| = 0$$

où  $\beta(u)$  une fonction positive mesurable.

## 1.8 Estimateur de l'indice des valeurs extrêmes

### 1.8.1 L'estimateur de Pickands

Cet estimateur a été introduit par *Pickands (1975)*[17] pour  $\gamma \in \mathbb{R}$ . Il est le premier estimateur de  $\gamma$

**Définition 1.9** *L'estimateur de Pickands(1975) combine 4 statistique d'ordre. Il est calculé pour un ensemble de rang  $k$ . Sa formule est donnée par :*

$$\hat{\gamma}_{n,k}^{(p)} = \frac{1}{\log 2} \log \left( \frac{X_{(n-k+1,n)} - X_{(n-2k+1,n)}}{X_{(n-2k+1,n)} - X_{(n-4k+1,n)}} \right)$$

où  $X_1, \dots, X_n$  un échantillon de variables aléatoires i.i.d et  $n$  est la taille de l'échantillon observé.

*Pickands (1975)*[17] a démontré la consistance faible de son estimateur. La convergence forte ainsi que la normalité asymptotique ont été démontrées par *Dekkers et De Haan*. Des améliorations de cet estimateur ont été introduites notamment par *Drees et Segers*.

**Théorème 1.7** (*propriétés de  $\widehat{\gamma}_{(n,k)}^{(p)}$* )

Supposons que  $F \in DA(H_\gamma)$ ,  $\gamma \in \mathbb{R}$ ,  $k = k(n) \rightarrow \infty$  et  $k/n \rightarrow 0$  quand  $n \rightarrow \infty$

a . consistance faible :

$$\widehat{\gamma}_{n,k}^{(p)} \xrightarrow{p} \gamma \text{ quand } n \rightarrow \infty$$

b . consistance forte : Si  $k/\log \log n \rightarrow \infty$  quand  $n \rightarrow \infty$ , alors

$$\widehat{\gamma}_{n,k}^{(p)} \xrightarrow{p.s} \gamma \text{ quand } n \rightarrow \infty$$

c . Normalité asymptotique : Sous des conditions additionnelles sur la suite  $k(n)$  et la distribution  $F$

$$\sqrt{k} \left( \widehat{\gamma}_{n,k}^{(p)} - \gamma \right) \xrightarrow{\mathcal{L}} N \left( 0, \frac{\gamma^2 (2^{2\gamma+1} + 1)}{4 (\log 2)^2 (2^\gamma - 1)^2} \right) \text{ quand } n \rightarrow \infty$$




FIG. 1.6 – Estimateur de Pickands avec un intervalle de confiance 95% de  $\gamma$  basés sur 100 échantillons de taille 3000 pour la loi uniforme.

### 1.8.2 Estimateur de Hill (1975) $\hat{\gamma}_{k_n}^H$

L'estimateur de Hill de l'indice de queue (également connu sous le nom indice des valeurs extrêmes), uniquement défini pour les indices positifs  $\gamma > 0$ . La construction de l'estimateur de Hill est basée sur la méthode du Maximum de Vraisemblance où on se sert des statistiques d'ordre supérieur à un certain seuil  $u$ , pour ne garder que les observations les plus grandes, de façon à ce quelles suivent approximativement une distribution Pareto. Il est défini par la statistique suivante :

$$\begin{aligned} \hat{\gamma}_{n,k}^H &= \frac{1}{k} \sum_{i=1}^k \log X_{n-i+1,n} - \log X_{n-k,n} \\ &= \frac{1}{k} \sum_{i=1}^k i (\log X_{n-i+1,n} - \log X_{n-k,n}) \end{aligned}$$

Si on choisit  $k, n \rightarrow 0$  de sorte que  $\frac{k}{n} \rightarrow 0$  alors on peut montrer que

$$\lim_{k \rightarrow \infty} \hat{\gamma}_{n,k}^H = \gamma$$

et l'estimateur de Hill est de plus asymptotiquement normal :

$$\sqrt{k} \frac{\widehat{\gamma}_{n,k}^H - \gamma}{\gamma} \xrightarrow{d} N(0, 1)$$

Dans le cas général du domaine de Fréchet, la fonction de survie est de la forme  $1 - F(x) = x^{-1/\gamma} \ell(x)$  avec  $\ell$  une fonction à variation lente, Cela induit un biais important sur l'estimateur de Hill, qui est donc en pratique d'un maniement délicat. Dans le cas général, la fonction  $\ell$  apparaît comme un paramètre de nuisance de dimension infinie, qui complique l'estimation *BERTAIL*, (2002). Pour plus détails sur la consistance de  $\widehat{\gamma}^H$  *Beirlant et al.*(2007)[1]. Pour cela, nous allons commencer par les conditions du première et du seconds ordre :

**Proposition 1.2 (Condition du première ordre, de Haan et Ferreira (2006))**

[3] Les assertions suivantes sont équivalentes :

a.  $F$  est à queue lourde

$$F \in D(\text{Fréchet}), \gamma > 0$$

b.  $1 - F$  est une fonction variation régulière à l'infini d'indice  $-1/\gamma$

$$\lim_{t \rightarrow \infty} \frac{1 - F(tx)}{1 - F(t)} = x^{-1/\gamma}, \quad x > 0$$

c.  $Q(1 - s)$  est une fonction à variations régulières à zéro d'indice  $-\gamma$

$$\lim_{s \rightarrow \infty} \frac{Q(1 - sx)}{Q(1 - s)} = x^{-\gamma}, \quad x > 0$$

d.  $U$  est une fonction à variation régulière l'infini d'indice  $\gamma$

$$\lim_{s \rightarrow \infty} \frac{U(tx)}{Q(t)} = x^\gamma, \quad x > 0$$

**Proposition 1.3 (Condition du seconde ordre de Haan et Ferreira (2006))**

Une fonction de répartition  $F \in D(\text{Fréchet})$ ,  $\gamma > 0$ , admet une condition du seconde ordre à l'infini si elle satisfait l'une des assertions suivantes :

- a. Il existe un paramètre  $\rho \leq 0$ , et une fonction  $A_1(\cdot)$  qui tend vers 0 (ne change pas de signe à l'infini) définie par,  $\forall x > 0$

$$\lim_{t \rightarrow \infty} \frac{(1 - F(tx)) / (1 - F(t)) - x^{-1/\gamma}}{A_1(t)} = x^{-1/\gamma} \frac{x^\rho - 1}{\rho}.$$

- b. S'il existe un paramètre  $\rho \leq 0$  et une fonction  $A_2(\cdot)$  qui tend vers 0 (ne change pas de signe à zéro) définie par,  $\forall x > 0$

$$\lim_{t \rightarrow \infty} \frac{Q(1 - sx) / Q(1 - s) - x^{-\gamma}}{A_1(t)} = x^{-\gamma} \frac{x^\rho - 1}{\rho},$$

- c. S'il existe un paramètre  $\rho \leq 0$ , et une fonction  $A(\cdot)$  qui tend vers 0 (ne change pas de signe à l'infini) définie par,  $\forall x > 0$

$$\lim_{t \rightarrow 0} \frac{U(tx) / U(t) - x^\gamma}{A(t)} = x^\gamma \frac{x^\rho - 1}{\rho},$$

si  $\rho = 0$ , on remplace  $(x^\rho - 1)/\rho$  par  $\log x$ .

Les fonctions  $A(\cdot)$ ,  $A_1(\cdot)$ ,  $A_2(\cdot)$  sont à variations régulières l'infini d'indices respectifs  $\rho$ ,  $\rho/\gamma$ , et  $-\rho$ , avec  $A_1(t) = A(1/(1 - F(t)))$  et  $A_2(s) = A(1/s)$ .

Ces deux conditions ont permis de déterminer les propriétés asymptotiques de certains estimateurs de l'indice des valeurs extrêmes.

**Théorème 1.8 (Propriétés asymptotiques de l'estimateur de Hill)** Soit  $k_n, n \geq 1$  une suite d'entiers telle que  $1 \leq k_n \leq n, k_n \rightarrow \infty$  et  $k_n/n \rightarrow 0$  quand  $n \rightarrow \infty$ .

- a. Consistance faible :  $\hat{\gamma}_{k_n}^H$  converge en probabilité vers  $\gamma$
- b. Consistance forte : Si de plus  $k_n/\log n \log n \rightarrow \infty$  quant  $n \rightarrow \infty$ , alors  $\hat{\gamma}_{k_n}^H$  converge presque sûrement vers  $\gamma$ .
- c. Normalité asymptotique : Si la condition

$$\lim_{t \rightarrow \infty} \frac{U(tx)/U(t) - x^{-\gamma}}{A(t)} = x^\gamma \frac{x^\rho - 1}{\rho},$$

est satisfaite avec  $\sqrt{k_n}A(n/k_n) \rightarrow \lambda \in \mathbb{R}$  quand  $n \rightarrow \infty$ , alors

$$\sqrt{k_n} (\hat{\gamma}_{k_n}^H - \gamma) \xrightarrow{\mathcal{L}} N(\lambda/(1 - \rho), \gamma^2)$$




FIG. 1.7 – L'estimateur de Hill avec un intervalle de conance 95% de  $\gamma$  basés sur 100 échantillons de taille 3000 pour la loi de Pareto standard.

### 1.8.3 L'estimateur des moments de Dekkers-Einmahl De Haan

En 1989, *Dekkers-Einmahl-DeHaan*[4] ont proposé un estimateur de  $\gamma \in \mathbb{R}$  qui présente une extension de l'estimateur de Hill, appelé un estimateur de moment pour  $\gamma \in \mathbb{R}$ .

**Définition 1.10** *L'estimateur des moments est défini comme suit :*

$$\widehat{\gamma}_{n,k}^{(M)} = 1 + M_n^1 - \frac{1}{2} \left( \frac{(M_n^{(1)})}{(M_n^{(2)})} - 1 \right)^{-1}$$

$$M_n^{(r)} = M_n^{(r)}(k) = \frac{1}{k} \sum_{i=1}^{n-k} (\log X_{(n-i+1,n)} - \log X_{(n-k,n)})^r$$

Sous certaines conditions sur  $k$ , l'estimateur de *Dekkers-Einmahl-DeHaan* converge asymptotiquement vers la loi normale.

*Dekkers-Einmahl-DeHaan* ont démontré la consistance faible, la consistance forte et la normalité asymptotique de leur estimateur.

**Théorème 1.9 (Propriétés de  $\widehat{\gamma}_{n,k}^{(M)}$ )**

Supposons que  $F \in D(H_\gamma)$ ,  $\gamma \in \mathbb{R}$ ,  $k = k(n) \rightarrow \infty$  et  $k/n \rightarrow 0$  quand  $n \rightarrow \infty$

a . Consistance faible :

$$\widehat{\gamma}_{n,k}^{(M)} \xrightarrow{p} \gamma \text{ quand } n \rightarrow \infty$$

b . Consistance forte : Si  $k/\log \log n \rightarrow \infty$  quand  $n \rightarrow \infty$ , alors

$$\widehat{\gamma}_{n,k}^{(M)} \xrightarrow{p,s} \gamma \text{ quand } n \rightarrow \infty$$

c . Normalité asymptotique : Sous des conditions de régularité convenables

$$\sqrt{k} \left( \hat{\gamma}_{n,k}^{(M)} - \gamma \right) \xrightarrow{\mathcal{L}} N(0, \eta^2) \text{ quand } n \rightarrow \infty,$$

ou

$$\eta^2 = \begin{cases} 1 + \gamma^2 & \text{si } \gamma \geq 0 \\ (1 - \gamma)^2 (1 - 2\gamma) \left[ 4 - 8 \frac{1-2\gamma}{1-3\gamma} + \frac{(5-11\gamma)(1-2\gamma)}{(1-3\gamma)(1-4\gamma)} \right] & \text{si } \gamma < 0 \end{cases}$$




FIG. 1.8 – Estimateur des moments avec un intervalle de confiance 95% de  $\gamma$  basé sur 100 échantillons de taille 3000 pour la loi de Gumbel standard.

# Chapitre 2

## Introduction à l'analyse de survie

Une des caractéristiques des données de survie est l'existence d'observations incomplètes. En effet, les données sont souvent recueillies partiellement, notamment, à cause des processus de censure. Les données censurées proviennent du fait qu'on n'a pas accès à toute l'information : au lieu d'observer des réalisations indépendantes et identiquement distribuées (*i.i.d*) de durées  $X$ , on observe la réalisation de la variable  $X$  soumise à diverses perturbations, indépendantes ou non du phénomène étudié.

### 2.1 Définitions

**Définition 2.1 (Fonction de survie  $S$ )** Soit  $X$  une v.a. positive et continue dite "durée de vie". Pour  $t$  fixé, la fonction de survie est la probabilité de survivre jusqu'à l'instant  $t$ , c'est-à-dire

$$\begin{aligned} S(t) &= \bar{F}(t) \\ &= 1 - F(t) \\ &= 1 - P(X \leq t) \\ &= P(X > t) \end{aligned}$$

**Définition 2.2 (Risque instantané  $\lambda$ )** Le risque instantané (ou taux d'incidence), pour  $t$  fixé caractérise la probabilité de mourir dans un petit inter-

valle de temps après  $t$ , conditionnellement au fait d'avoir survécu jusqu'au temps  $t$  (c'est-à-dire le risque de mort instantané pour ceux qui ont survécu)

$$\lambda(t) = \lim_{h \rightarrow 0} \frac{P(t \leq X < t + h \mid X \geq t)}{h} = \frac{f(t)}{S(t)} = -\ln(S(t))'$$

**Définition 2.3 (Taux de hasard cumulé  $\Lambda$ )** *Le taux de hasard cumulé est l'intégrale du risque instantané  $\lambda$*

$$\Lambda(t) = \int_0^t \lambda(u) du = -\ln(S(t))$$

On peut déduire de cette équation une expression de la fonction de survie en fonction du taux de hasard cumulé :

$$S(t) = \exp(-\Lambda(t)) = \exp\left(-\int_0^t \lambda(u) du\right)$$

On en déduit que

$$f(t) = \lambda(t) \exp\left(-\int_0^t \lambda(u) du\right)$$

## 2.2 Données de censure

**Définition 2.4 (variable de censure)** *La variable de censure  $Y$  est définie par la non-observation de l'événement étudié. Si au lieu d'observer  $X$ , on observe  $Y$ , on a :*

1.  $X > Y$  est censure à droite.
2.  $X < Y$  est censure à gauche.
3.  $Y_1 < X < Y_2$  est censure par intervalle.

### 2.2.1 Caractéristiques

La censure est le phénomène le plus couramment rencontré lors du recueil de données en statistique.

Pour un individu donné  $j$ , on va considérer :

- Temps de survie  $X_j$ .
- Son temps de censure  $Y_j$ .
- La durée réellement observée  $Z_j$ .

### 2.2.2 Types de censures

Dans la littérature on distingue trois types de censure :

#### Censure à droite

La durée de vie est dite censurée à droite si l'individu n'a pas subi l'événement à sa dernière observation. En présence de censure à droite, les durées de vie ne sont pas toutes observées ; pour certaines d'entre elles, on sait seulement qu'elles sont supérieures à une certaine valeur connue.

#### Censure à gauche

Une durée de survie est dite censurée à gauche si l'individu a déjà subi l'événement d'intérêt avant l'entrée dans l'étude. Formellement, la durée de survie pour un individu est définie par le couple  $(Z, \delta)$  :

$$Z = X \vee Y = \max(X, Y) \text{ et } \delta = 1_{\{X \geq Y\}}$$

Notons  $X$  l'âge à laquelle une certaine maladie apparaît pour la première fois chez un individu. Après un examen médical on a reçu deux types de réponses :

1. l'individu a déjà été malade mais l'âge exact de la première apparition n'a pas été retenu :

Dans ce cas on n'a pas observé  $X$  mais on sait que  $X$  est inférieur à l'âge de l'individu lors de l'examen  $Y$ . Il s'agit d'une observation censurée à gauche.

2. l'individu n'a jamais eu de maladie : Dans ce cas on sait seulement que  $X$  est supérieur l'âge de l'individu, donc on a une observation censurée à droite.

**Remarque 2.1** *Si les variables de censures sont dégénérée (c'est-à-dire constantes), alors on dit que la censure est fixée.*

### Censure par intervalle

Dans ce cas, comme son nom l'indique, on observe la fois une borne inférieure et une borne supérieure de la variable d'intérêt. On retrouve ce modèle en général dans des études de suivi médical où les patients sont contrôlés périodiquement, si un patient ne se présente pas à un ou plusieurs contrôles et se présente ensuite après que l'évènement d'intérêt se soit produit. Nous avons aussi ce genre de données qui sont censurées à droite ou, plus rarement à gauche. Un avantage de ce type est qu'il permet de présenter les données censurées à droite ou à gauche par des intervalles du type  $[y, +\infty[$  et  $[0, y]$  respectivement.

Dans la littérature, il existe d'autres types de censure :

- **censure de type 1 : fixée**

Soit  $Y$  une valeur fixée, au lieu d'observer les variables  $X_1, \dots, X_n$  qui nous intéressent, on n'observe  $X_j$  uniquement lorsque  $X_j \leq Y$  si non on sait uniquement que  $X_j > Y$ . on utilise la notation suivante :

$$Z_j = X_j \wedge Y = \min(X_j, Y)$$

### Exemple 2.1

Dans l'apprentissage d'une langue par un groupe d'étudiants durant un stage de période fixée. On note  $X$  la durée d'apprentissage de cette langue. Pour certains étudiants nous allons observer leurs durées  $X_j$  d'apprentissage de la langue par contre pour d'autres leurs  $X_j$  ne seront pas observées car le stage est limité dans le temps.

- **Censure de type 2 : attente**

Elle présente quand on décide d'observer les durées de survie des  $n$  patients jusqu'à ce que  $k$  d'entre eux soient décédés et d'arrêter l'étude à ce moment là.

Soient  $X_{j,n}$  et  $Z_j$  les statistiques d'ordre des variables  $X_j$  et  $Z_j$ . La date de censure est donc  $X_{k:n}$  et on observe les variables suivantes :

$$\begin{aligned} Z_{1,n} &= X_{1,n} \\ &\vdots \\ Z_{k,n} &= X_{k,n} \\ Z_{k+1,n} &= X_{k,n} \\ &\vdots \\ Z_{n,n} &= X_{k,n} \end{aligned}$$

**- Censure de type 3 : aléatoire**

C'est typiquement ce modèle qui est utilisé pour les essais thérapeutiques. Dans ce type d'expérience, la date d'inclusion du patient dans l'étude est fixé, mais la date de fin d'observation est inconnue (celle-ci correspond, par exemple, la durée d'hospitalisation du patient). Ici, le nombre d'évènement observés et la durée totale de l'expérience sont aléatoires.

Soient  $Y_1, \dots, Y_n$  des variables aléatoires *i.i.d.* On observe les variables

$$Z_j = X_j \wedge Y_j.$$

L'information disponible peut être résumée par :

- 1- la durée réellement observée  $Z_j$ ,
- 2- un indicateur  $\delta_j = 1_{\{X_j \leq Y_j\}}$ 
  - (a)  $\delta_j = 1$  si l'évènement est observé (d'où  $Z_j = X_j$ ). On observe les "vraies" durées ou les durées complètes.
  - (b)  $\delta_j = 0$  si l'individu est censuré (d'où  $Z_j = Y_j$ ). On observe des durées incomplètes (censurées).

**Exemple 2.2** Lors d'un essai thérapeutique, on peut citer certaines causes entraînant la censure aléatoire :

1. *Perdu de vue* : le patient peut décider de se faire soigner ailleurs cause d'un déménagement et on le revoit plus.
2. *Arrêt du traitement* : suite à des effets secondaire le traitement est arrêté.
3. *Fin de l'étude* : l'étude se termine et certains patients soit toujours vivants (exclus-vivants).

## 2.3 Estimateur de Kaplan-Meier $\widehat{S}(t)$

L'estimateur de Kaplan-Meier découle de l'idée suivante : survivre après un temps  $t$  c'est être en vie juste avant  $t$  et ne pas mourir au temps  $t$ , c'est-à-dire, si  $t'' < t' < t$

$$\begin{aligned} P(X > t) &= P(X > t', X > t) \\ &= P(X > t \mid X > t') \\ &= P(X > t \mid X > t') \times P(X > t' \mid X > t'') \times P(X > t'') \end{aligned}$$

En considérant les temps d'événements (décès et censure) distincts  $Z_{(j)}$  ( $i = 1, \dots, n$ ) rangés par ordre croissant,  $Z_{(0)} = 0$  on obtient

$$P(X > Z_{(j)}) = \prod_{k=1}^j P(X > Z_{(k)} \mid X > Z_{(k-1)})$$

Considérons les notations suivantes :

$Y_j$  le nombre d'individus à risque de subir l'événement juste avant le temps  $Z_{(j)}$ ,  $d_j$  le nombre de décès en  $Z_{(j)}$ . Alors la probabilité  $p_j$  de mourir dans l'intervalle  $]Z_{(j-1)}, Z_{(j)}]$  sachant que l'on était vivant en  $Z_{(j-1)}$ , *i.e.*

$$p_j = P(X \leq Z_{(j)} \mid X > Z_{(j-1)}),$$

peut être estimée par  $p_j = \frac{d_j}{Y_j}$ . Comme les temps d'événements sont supposés distincts, on a

- $d_j = 0$  en cas de censure en  $Z_{(j)}$ , *i.e.* quand  $\delta_j = 0$ ,

-  $d_j = 1$  en cas de décès en  $Z_{(j)}$ , *i.e.* quand  $\delta_j = 1$ .

On obtient alors l'estimateur de Kaplan-Meier :

$$\begin{aligned}\widehat{S}_n(t) &= 1 - \widehat{F}_n(t) \\ &= \prod_{j=1:n, Z_{(j)} \leq t} \left(1 - \frac{\delta_j}{Y_j}\right) \\ &= \prod_{j:Z_j \leq t}^n \left(1 - \frac{\delta_j}{n - (j - 1)}\right) \\ &= \prod_{j=1}^n \left[\frac{n - 1}{n - j + 1}\right]^{\delta_j}\end{aligned}$$

L'estimateur  $\widehat{S}(t)$  est également appelé Produit Limite car il s'obtient comme la limite d'un produit. On montre que l'estimateur de Kaplan-Meier est un estimateur du maximum de vraisemblance.  $\widehat{S}(t)$  est une fonction en escalier décroissante, continue à droite. On peut également obtenir un estimateur de *Kaplan - Meier* [12] dans le cas de données tronquées mais pas dans le cas de données censurées par intervalles (car les temps de décès ne sont pas connus).

## 2.4 Estimation de l'indice des valeurs extrême avec censure

Nous travaillons dans l'espace de probabilité  $(\Omega, A, P)$  et soit l'échantillon  $(X_1, \dots, X_n)$  variable aléatoire définie sur  $(\Omega, A, P)$  sa fonction répartition  $F$  et sa queue de distribution :

$$1 - F \in RV(-1/\gamma_1)$$

Soit le deuxième échantillon  $(Y_1, \dots, Y_n)$ , des variables aléatoires *i.d.d.*, de fonction de répartition  $G$  et de queue de distribution :

$$1 - G \in RV(-1/\gamma_2)$$

Alors les variables  $Z_j$  définies par :

$$Z_j = X_j \wedge Y_j, \quad j = 1, \dots, n$$

avec,  $Z_j$  sont des variables indépendantes de loi  $H$  liées  $F$  et  $G$  par la relation :

$$1 - H(x) = (1 - F(x))(1 - G(x)).$$

Le points terminal de  $H$  est  $x_H = \sup \{x, H(x) < 1\}$ . On a  $F$  et  $G$  satisfaisant la condition de domaine d'attraction de Fêchet,  $F \in D(\Phi_{1/\gamma_1})$  et  $G \in D(\Phi_{1/\gamma_2})$ , telles que :

$$1 - F(x) = x^{-1/\gamma_1} l_1(x) \text{ et } 1 - G(x) = x^{-1/\gamma_2} l_2(x),$$

avec  $l_1(\cdot)$  et  $l_2(\cdot)$  sont des fonctions à variations lentes. Alors :

$$\begin{aligned} 1 - H(x) &= (1 - F(x))(1 - G(x)) \\ &= x^{-1/\gamma_1} l_1(x) x^{-1/\gamma_2} l_2(x) \\ &= x^{-(\gamma_1 + \gamma_2)/\gamma_1 \gamma_2} \tilde{l}(x) \\ &= x^{-1/\gamma} \tilde{l}(x), \end{aligned}$$

où  $\gamma = \frac{\gamma_1 \gamma_2}{\gamma_1 + \gamma_2}$ , avec  $\tilde{l}(x) = l_1(x) l_2(x)$ . Par conséquent,  $H$  appartenant au domaine d'attraction de Fréchet :

$$1 - H(x) \in RV(-1/\gamma)$$

Si  $F$  et  $G$  appartiennent au domaine d'attraction du maximum  $F \in D(G_{\gamma_1})$  et  $G \in (G_{\gamma_2})$  respectivement, pour certain  $\gamma_1, \gamma_2 \in \mathbb{R}$  avec points terminales  $x_F$  et  $x_G$ , où  $x_F = \sup \{x, F(x) < 1\}$ , alors cela signifie que  $H \in D(G_\gamma)$ . *Einmahl et al.(2008)[6]*, ont proposés les trois cas les plus intéressants suivants :

$$\left\{ \begin{array}{l} \text{cas 1 : } \gamma_1 > 0, \gamma_2 > 0, x_F = x_G = +\infty, \quad \gamma = \frac{\gamma_1 \gamma_2}{\gamma_1 + \gamma_2}, \\ \text{cas 2 : } \gamma_1 < 0, \gamma_2 < 0, x_F = x_G < \infty, \quad \gamma = \frac{\gamma_1 \gamma_2}{\gamma_1 + \gamma_2} \\ \text{cas 3 : } \gamma_1 = 0, \gamma_2 = 0, x_F = x_G = \infty, \quad \gamma = 0. \end{array} \right.$$

La méthode générale existante pour l'estimation de l'indice de queue en présence de censure à droite aléatoire, apparue d'abord dans *Beirlant et al.(2007)*[1] et développée dans *Einmahl et al.(2008)*[6], est considérer tout estimateur consistant  $\hat{\gamma}$  de l'EVI  $\gamma$  appliqué l'échantillon  $(Z_1, \dots, Z_n)$  et diviser par la proportion  $\hat{p}$  d'observation non censurées dans les plus grandes  $k$  valeurs de  $Z$  :

$$\hat{\gamma}_{Z,n,k}^{(c,\cdot)} = \frac{\hat{\gamma}_{Z,n,k}^{(\cdot)}}{\hat{p}},$$

où

$$\hat{p} = \frac{1}{k} \sum_{j=1}^k \delta_{[n-j+1,n]},$$

avec  $\delta_{[1,n]}, \dots, \delta_{[n,n]}$  les indicateurs de censure retenues correspondant à la statistique d'ordre  $(Z_{1,n}, \dots, Z_{n,n})$ , respectivement. Il sera suivre que  $\hat{p}$  estime  $p = \frac{\gamma_2}{\gamma_1 + \gamma_2}$ .

$\hat{\gamma}_{Z,n,k}^{(c,\cdot)}$  peut être n'importe quel estimateur non adapté la censure. En particulier, une adaptation de l'estimateur de Hill  $\hat{\gamma}_{Z,n,k}^{(H)}$  de l'indice  $\gamma_1$  dans le cas de censure est défini par :

$$\hat{\gamma}_{Z,n,k}^{(c,H)} = \frac{\hat{\gamma}_n^H}{\hat{p}}$$

où

$$\hat{\gamma}_n^H := \frac{1}{k} \sum_{j=1}^k \log(Z_{n-i+1,n}) - \log(Z_{n-k,n}), \quad 1 \leq k \leq n$$

Alors

$$\widehat{\gamma}_1^{(c,H)} = \frac{\sum_{j=1}^k \log(Z_{n-i+1,n}) - \log(Z_{n-k,n})}{\sum_{j=1}^k \delta_{[n-j+1,n]}}$$

# Chapitre 3

## ESTIMATION DE LA MOYENNE AVEC CENSURE

Soit  $X_1, \dots, X_n$ ,  $n \geq 1$  sont des des variable aléatoire positives, indépendantes et de fonction de répartition  $F$ , et indépendant des variables aléatoire  $Y_1, \dots, Y_n$ , les instants de censure associés, positives, de fonction de répartition  $G$ . On note  $\{(Z_1, \delta_1), \dots, (Z_n, \delta_n)\}$  l'échantillon réellement observé, où, pour  $1 \leq j \leq n$

$$Z_j = \min(X_j, Y_j) \text{ et } \delta_j = 1 \{X_j, Y_j\}$$

avec  $1 \{.\}$  indiquant la fonction de l'indicateur. Ce dernier indique s'il y a censure ou non. Si l'on note  $H$  le *cdf* des  $Z$  observés, par l'indépendance de  $X$  et  $Y$ , nous avons  $1 - H = (1 - F)(1 - G)$ . Dans ce chapitre, nous utiliserons la notation  $\bar{S}(x) = S(\infty) - S(x)$ , pour toute fonction  $S$  supposons en outre que  $F$  et  $G$  sont à queue lourde ou, en d'autres termes, que  $F$  et  $G$  varient régulièrement à l'infinité avec des indices négatifs  $-1/\gamma_1$  et  $-1/\gamma_2$  respectivement.

$$\lim_{x \rightarrow \infty} \frac{\bar{F}(xz)}{\bar{F}(z)} = x^{-1/\gamma_1} \text{ et } \lim_{x \rightarrow \infty} \frac{\bar{G}(xz)}{\bar{G}(z)} = x^{-1/\gamma_2}$$

pour tout  $x > 0$ . Par conséquent,  $H$  est aussi à queue lourde, avec un indice de queue  $\gamma = \frac{\gamma_1 \gamma_2}{\gamma_1 + \gamma_2}$ .

Il existe des constantes  $\rho_j < 0$  et des fonctions  $A_j$ ,  $j = 1, 2$  tendant vers zéro, ne changeant pas de signe près de l'infinité tel que pour tout  $x > 0$

$$\lim_{t \rightarrow \infty} \frac{\overline{F}(tx) / \overline{F}(t) - x^{-1/\gamma_1}}{A_1(t)} = x^{-1/\gamma_1} \frac{x^{\rho_1/\gamma_1 - 1}}{\gamma_1 \rho_1}$$

et

$$\lim_{t \rightarrow \infty} \frac{\overline{G}(tx) / \overline{G}(t) - x^{-1/\gamma_2}}{A_2(t)} = x^{-1/\gamma_2} \frac{x^{\rho_2/\gamma_2 - 1}}{\gamma_2 \rho_2}$$

L'estimateur du maximum de vraisemblance de cdf  $F$  est donné par *Kaplan et Meier* [12] :

$$\widehat{F}_n(x) = \begin{cases} 1 - \prod_{Z_{j:n} \leq x} \left( \frac{n-j}{n-(j-1)} \right)^{\delta_{[j:n]}} & \text{pour } x < Z_{n:n}, \\ 1 & \text{pour } x \geq Z_{n:n}, \end{cases}$$

$\widehat{F}_n$  est donné aussi par :

$$\widehat{F}_n(t) = \sum_{i=1}^n W_{i,n} 1\{Z_{i:n} \leq x\} \text{ où } W_{i,n} = \frac{\delta_{[i:n]}}{n-i+1} \prod_{j=1}^{i-1} \left[ \frac{n-j}{n-j+1} \right]^{\delta_{[j:n]}}$$

L'estimateur asymptotiquement normal pour la moyenne est  $\mu = E[X] = \int_0^{\infty} \overline{F}(x) dx$ , en substituant  $\widehat{F}_n$  à  $F$  dans l'équation précédente, *Stute* [22] a réduit la moyenne empirique des données censurées de

$$\widehat{\mu}_n := \sum_{i=1}^n \frac{\delta_{[i:n]}}{n-i+1} \prod_{j=1}^{i-1} \left[ \frac{n-j}{n-j+1} \right]^{\delta_{[j:n]}}$$

$\mu$  est un somme de deux termes :  $\mu = \int_0^h \overline{F}(x) dx + \int_h^{\infty} \overline{F}(x) dx = \mu_1 + \mu_2$ ,

$$\mu_1 = h\overline{F}(h) + \int_0^h xF(x) dx \text{ et } \mu_2 = h\overline{F}(h) \int_1^{\infty} \frac{\overline{F}(hx)}{\overline{F}(h)}.$$

L'estimation de  $\mu_1$  et  $\mu_2$  sont (remplaçant  $h$  et  $F(x)$  par  $Z_{n-kn}$  et  $\widehat{F}_n(x)$ ) [20] :

$$\widehat{\mu}_1 = \sum_{j=1}^{n-k} \left( \frac{n-j}{n-j+1} \right)^{\delta_{[j:n]}} Z_{n-k} + \sum_{j=1}^{n-k} \frac{\delta_{[i:n]}}{n-j+1} \prod_{j=1}^{i-1} \left( \frac{n-j}{n-j+1} \right)^{\delta_{[j:n]}} Z_{i:n}, \quad (3.1)$$

$$\mu_2 \sim \frac{\gamma_1}{1 - \gamma_1} h \bar{F}(h), \text{ comme } n \rightarrow \infty, 0 < \gamma_1 < 1. \quad (3.2)$$

Les quantités  $h$  et  $\bar{F}(h)$  sont, comme ci-dessus, naturellement estimées par  $Z_{n-k:n}$  et

$$\widehat{\bar{F}}_n(Z_{n-k}) = \prod_{j=1}^{i-k} \left( \frac{n-j}{n-j+1} \right)^{\delta_{[j:n]}}$$

pour dériver un estimateur de  $\mu_2$ , il faut estimer l'indice  $\gamma_1$ . La méthode générale existante, apparue pour la première fois dans *Beirlant et al*, puis développé dans *Einmahl et al*, cette méthode est basé sur l'évaluation  $Z$  et divisez-le par le proportion observées. Par exemple, *Einmahl et al*, adapté l'estimateur de Hill par un estimateur  $\widehat{\gamma}_1^{(H,c)} = \widehat{\gamma}^H / \widehat{p}$

$$\widehat{\gamma}^H = \frac{1}{k} \sum_{i=1}^k \log \frac{Z_{n-i+1:n}}{Z_{n-k}} \text{ et } \widehat{p} = \frac{1}{k} \sum_{i=1}^k \delta_{[n-i+1:n]},$$

En remplaçant, dans (3.2),  $F$  et  $\gamma_1$  par  $\widehat{F}_n$  et  $\widehat{\gamma}_1^{(H,c)}$

$$\widehat{\mu}_2 := \frac{\widehat{\gamma}_1^{(H,c)}}{1 - \widehat{\gamma}_1^{(H,c)}} Z_{n-k} \prod_{j=1}^{n-k} \left( \frac{n-j}{n-j+1} \right)^{\delta_{[j:n]}}, \widehat{\gamma}_1^{(H,c)} < 1 \quad (3.3)$$

Enfin, avec (3.1) et (3.3), l'estimateur  $\widehat{\mu}$  de la moyenne  $\mu$  est :

$$\widehat{\mu} = \frac{1}{k} \sum_{j=2}^{n-k} \frac{\delta_{[i:n]}}{n-i+1} \prod_{j=1}^{i-1} \left( \frac{n-j}{n-j+1} \right)^{\delta_{[j:n]}} Z_{i:n} + \prod_{j=1}^{n-k} \left( \frac{n-j}{n-j+1} \right)^{\delta_{[j:n]}} \frac{Z_{n-k}}{1 - \widehat{\gamma}_1^{(H,c)}}$$

### 3.1 Simulation

On a réalisé une étude de simulation basée sur 3000 échantillons de loi de Pareto de paramètre  $\gamma_1$  censurées par une autre variable de Pareto de paramètre  $\gamma_2$ .

$$F^{-1}(u) = (1 - u)^{-\gamma_1}, \quad G^{-1}(v) = (1 - v)^{-\gamma_2}.$$

$\{(Z_1, \delta_1), \dots, (Z_n, \delta_n)\}$  l'échantillon réellement observé, où, pour  $1 \leq j \leq n$

$$Z_j = \min(X_j, Y_j)$$

Le programme ci-dessous calcule l'estimateur  $\hat{\mu}$  de la moyenne  $\mu$  sous R :

```

gamma1<-1
gamma2<-0.5
u<-runif(n,0,1)
X<-(1-u)^gamma1
V<-runif(n,0,1)
Y<-(1-V)^gamma2
Z<-pmin(X,Y)
delta=as.numeric(X<=Y)
k<-100
for(i in 1 :k)
{
i<-seq(1,k)
gammah<-(1/k)*sum(log(Z[n-i+1]/Z[n-k]))
}
i<-seq(1,k)
p<-(1/k)*sum(delta[n-i+1])
gammach<-gammah/p
i<-seq(1,k)
for(i in 2 :n-k)
for(j in 1 :i-1)
{
S<-prod((n-j)/(n-j+1))^delta[j]
}
U1<-(1/k)*sum(delta[i]/n-i+1)*S*Z[i]
for(j in 1 :n-k)
{
U2<-(prod((n-j)/(n-j+1))^delta[j])*(Z[n-k]/(1-gammach))
}
U<-U1+U2

```

# Conclusion

Dans notre étude , nous avons abordé différents aspects de la théorie des valeurs extrêmes. Après avoir le premier chapitre la théorie des valeurs extrêmes en mentionnent les différentes caractéristiques et les notions de base qui sont très utile pour l'estimation des quantiles extrêmes et les données censurées et aussi nous nous sommes intéressés à la famille de lois à que de type Fréchet, on peut citer la loi de Pareto. On a présenté trois estimateurs (estimateur de Pickands, estimateur Hill (1975) et estimateur des moments), nous nous sommes intéressés dans le deuxième chapitre au certaines des notions clés en analyse de survie et quelques estimations (estimation de la fonction de survie et taux hasard ...ect) et les estimateurs de l'IVE avec censure. Dans le dernier chapitre, nous avons fait un rappel général sur l'estimation de la moyenne et de traiter une méthode pour estimer la moyenne d'un distribution à queue lourde en présence de censure.

# Bibliographie

- [1] Beirlant, J., Guillou, A., Dierckx, G. and Fils-Viletard, A., 2007. Estimation of the extreme value index and extreme quantiles under random censoring. *Extremes* 10 :3, 151-17
- [2] Brahimi, B., Meraghni, D. et Necir, A. (2015). Approximation gaussienne de l'estimateur de l'indice de valeur extrême d'une distribution à queue lourde sous censure aléatoire. *Math. Méthodes Statist.*, 24 (4), 266-279.
- [3] De Haan, L. et Ferreira, A. (2006). *Théorie des valeurs extrêmes : une introduction*. Springer-Verlag, New York.
- [4] Dekkers, A., Einmahl, J. H. J. et de Haan, L., (1989). Estimateur de moment pour l'indice d'une distribution de valeurs extrêmes. *Annals of Statistics*, 17 (4) : 1833 -1855.
- [5] Drees, H., (1996). Estimateur Renard-Pickands de l'indice des valeurs extrêmes. *Annals of Statistics*, 23 (6) : 2059-2080.
- [6] Einmahl, J. H ; Fils-Viletard, A et Guillon, A. (2008) *Statistiques des extrêmes sous censure aléatoire*, *Bernoulli*, 14(1) ; 207-227.
- [7] Embrechts, P., Klppelberg, C. et Mikosch, T. (1997). *Modélisation d'événements extrêmes pour l'assurance et la finance*, Springer-Verlag, Berlin.
- [8] Fisher, R., Tippett, L. (1928). La limitation forme la distribution de fréquence du membre le plus grand ou le plus petit d'un échantillon. *Actes de la Cambridge Philosophical Society*, 24 : 180-190.
- [9] Gnedenko, B. (1943). Sur la distribution limite du terme maximum d'une série aléatoire. *Ann. Math.*, 423- 453.
- [10] Hill, B.M. (1975) .Une approche générale simple à consulter sur le détail de la distribution, *Ann. Statist.*, 3, 1163-1174.

- [11] Jenkinson, A. F. (1955). La distribution de fréquence des valeurs annuelles maximales (ou minimales) des éléments météorologiques. Quarterly J.R. Methodol.Soc., 81 (348), 158-171
- [12] Kaplan, E. L et Meier, P. (1958). Estimation non paramétrique à partir d'observations incomplètes. J. Amer. Statist Assoc ; 53(282) ; 457-481.
- [13] Klein, J. P ; Moeschberger, M. L. (1997) Analyse de survie : techniques pour les données censurées et tronquées, Springer. Verlag Inc, Berlin, New York.
- [14] Lee, E.T ; et Wang, J. (2003) Méthodes statistiques pour l'analyse de données de survie. John. Wiley.
- [15] Mason, D. M. (1982). Lois des grands nombres pour des sommes de valeurs extrêmes. Ann. Probab., 754-764.
- [16] Ndao, P., Diop, A. et Dupuy, J. F. (2014). Estimation non paramétrique de l'indice de queue conditionnel et des quantiles extrêmes sous censure aléatoire. Comput. Statist. Data Anal., 79, 6379.
- [17] Pickands III, J. (1975). Inférence statistique à l'aide de statistiques d'ordre extrême. Statist., 119- 131.
- [18] Reiss,R.-D.,Thomas,M.S.,2007, Analyse statistique des valeurs extrêmes. De l'assurance, de la finance, de l'hydrologie et d'autres domaines. Birkhäuser Verlag, Basel., Boston, Berlin.
- [19] Segars. J., (2001). Estimateurs de résidus. Journal de StSmith, R. L., (1985). Estimation du maximum de vraisemblance dans une classe de cas non réguliers. Biometrika, 72 (1) : 6792
- [20] Soltane, Louiza, (2016). Analyse des valeurs extrêmes en présence de censure. Thèse de doctorat de université Mohamed khider, Biskra, Algérie.
- [21] Stuper, G. (2016). Estimation de l'indice conditionnel de valeur extrême sous censure aléatoire à droite. J. Multivariate Anal., 144, 1-24.
- [22] Stute, W. (1995). Le théorème de la limite centrale sous censure aléatoire. Ann. Statist., 422-439

## Résumé

Ce mémoire étudie l'estimation de la moyenne d'une distribution à queue lourde en présence de censure, d'un part est constitué de la théorie des valeurs extrêmes et d'autre part de l'analyse de survie, l'intérêt principal est de proposer une méthodologie d'estimation de la moyenne avec censure aléatoire à droite . Mots clés : Analyse de survie, Censure aléatoire, Estimateur de Hill, Estimateur de Kaplan-Meier, Estimation de la moyenne.

## Abstract

This is a study of the estimation of the mean of a heavy-tailed distribution in the presence of censorship, on the one hand is made up of the theory of extreme values and on the other hand of the survival analysis. The main thing is to propose a method of estimating the mean with random right-censoring. Key words: Survival analysis, Random censoring, Hill estimator; Kaplan-Meier estimator, Estimating the mean.

## ملخص

هذه الأطروحة عبارة عن دراسة لتقدير متوسط توزيع الذيل الثقيل في وجود الرقابة ، من ناحية تتكون من نظرية القيم المتطرفة ومن ناحية أخرى تحليل البقاء ، الهدف الرئيسي هو اقتراح منهجية لتقدير المتوسط مع وجود الرقابة  
الكلمات المفتاحية : تحليل البقاء ، الرقابة العشوائية ، مقدر هيل ، مقدر كابلان ماير ، تقدير المتوسط