

Theorem 11 ($MDA(\Psi_\alpha)$, Gnedenko 1943)

$F \in MDA(\Psi_\alpha)$ ($\alpha > 0$) $\iff x_F := \sup\{x \in \mathbb{R}: F(x) < 1\} < \infty$ und $\bar{F}(x_F - x^{-1}) \in RV_{-\alpha}$ ($\alpha > 0$).

Wenn $F \in MDA(\Psi_\alpha)$, dann $\lim_{n \rightarrow \infty} a_n^{-1}(M_n - x_F) = \Psi_\alpha$ mit $a_n = x_F - F^{\leftarrow}(1 - n^{-1})$.

Beispiel 23 Sei $X \sim U(0, 1)$. Es gilt $X \in MDA(\Psi_1)$ mit $a_n = 1/n$, $n \in \mathbb{N}$.

Theorem 12 ($MDA(\Lambda)$)

Sei F eine Verteilungsfunktion mit rechtem Endpunkt $x_F \leq \infty$. $F \in MDA(\Lambda)$ dann und nur dann wenn es ein $z < x_F$ existiert, sodass für F folgende Darstellung gilt:

$$\bar{F}(x) = c(x) \exp\left\{-\int_z^x \frac{g(t)}{a(t)} dt\right\}, \forall x, z < x \leq x_F.$$

Für die Funktionen $c(x)$ und $g(x)$ gilt $\lim_{x \uparrow x_F} c(x) = c > 0$ und $\lim_{t \uparrow x_F} g(t) = 1$, und $a(t)$ ist eine positive absolut stetige Funktion, sodass $\lim_{t \uparrow x_F} a'(t) = 0$.

Theorem 13 ($MDA(\Lambda)$, alternative Charakterisierung)

Eine Verteilungsfunktion F gehört zu $MDA(\Lambda)$ dann und nur dann wenn es eine positive Funktion \tilde{a} existiert, sodass

$$\lim_{x \uparrow x_F} \frac{\bar{F}(x + u\tilde{a}(x))}{\bar{F}(x)} = e^{-u}, \forall u \in \mathbb{R}$$

Eine mögliche Wahl für \tilde{a} ist $\tilde{a}(x) = a(x)$

$$a(x) = \int_x^{x_F} \frac{\bar{F}(t)}{\bar{F}(x)} dt$$

Die Funktion $a(x)$ heißt durchschnittliche Überschufunktion (mean excess function):

$$a(x) = E(X - x | X > x), \forall x \leq x_F$$

Einige Verteilungen, die dem $MDA(\Lambda)$ gehören:

- Normal: $F(x) = (2\pi)^{-1/2} \exp\{-x^2/2\}$, $x \in \mathbb{R}$.
- Exponential: $f(x) = \lambda^{-1} \exp\{-\lambda x\}$, $x > 0$, $\lambda > 0$.
- Lognormal: $f(x) = (2\pi x^2)^{-1/2} \exp\{-(\ln x)^2/2\}$, $x > 0$.
- Gamma: $f(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} \exp\{-\beta x\}$, $x > 0$, $\alpha, \beta > 0$.

Graphische Methoden zur Untersuchung des Verteilungsrandes

- Histogramm
- Quantil-Quantil Plots

X_1, X_2, \dots, X_n sind i.i.d. ZV mit einer unbekanntem Verteilung \tilde{F} . Es wird vermutet, dass \tilde{F} am Rand von einer bekannten Verteilung F approximiert wird. Wie kann man diese Vermutung testen?

Sei $X_{n,n} \leq X_{n-1,n} \leq \dots \leq X_{1,n}$ eine sortierte Stichprobe aus X_1, X_2, \dots, X_n .

qq-plot: $\{(X_{k,n}, F^{\leftarrow}(\frac{n-k+1}{n+1})) : k = 1, 2, \dots, n\}$.

Bei einer plausiblen Vermutung stellt der qq-plot eine einigermaßen lineare Abhängigkeit dar. Diese Eigenschaft bleibt auch dann erhalten wenn die echte Verteilung und die Referenz-Verteilung nicht übereinstimmen, sondern vom selben Typus sind.

Faustregel: Je größer das Quantil um so mehr “heavy tailed” ist die Verteilung!

Der Hill Schätzer

Seien X_1, X_2, \dots, X_n i.i.d. mit Verteilungsfunktion F , sodass $\bar{F} \in RV_{-\alpha}$, $\alpha > 0$, d.h. $\bar{F}(x) = x^{-\alpha}L(x)$ mit $L \in RV_0$.

Ziel: Schätzung von α !

Theorem 14 (Satz von Karamata)

Sei L eine langsam variierende und lokal beschränkte Funktion auf $[x_0, +\infty)$ für ein $x_0 \in \mathbb{R}$. Dann gilt:

(a) Für $\kappa > -1$:

$$\int_{x_0}^x t^\kappa L(t) dt \sim \frac{1}{\kappa + 1} x^{\kappa+1} L(x) \text{ für } x \rightarrow \infty$$

(b) Für $\kappa < -1$:

$$\int_x^{+\infty} t^\kappa L(t) dt \sim -\frac{1}{\kappa + 1} x^{\kappa+1} L(x) \text{ für } x \rightarrow \infty$$

Beweis in Bingham et al. 1987.

Annahme: L ist lokal beschränkt in $[u, +\infty)$.

Aus dem Satz von Karamata folgt:

$$E(\ln(X) - \ln(u) | \ln(X) > \ln(u)) = \lim_{u \rightarrow \infty} \frac{1}{\bar{F}(u)} \int_u^\infty (\ln x - \ln u) dF(x) = \alpha^{-1}. \quad (8)$$

Für die empirische Verteilung $F_n(x) = \frac{1}{n} \sum_{k=1}^n I_{[x_k, \infty)}(x)$ und eine hohe stichprobenabhängige Schwelle $x_{k,n}$, erhält man:

$$E(\ln(X) - \ln(x_{k,n}) | \ln(X) > \ln(x_{k,n})) \approx \frac{1}{\bar{F}_n(x_{k,n})} \int_{x_{k,n}}^\infty (\ln x - \ln x_{k,n}) dF_n(x) = \frac{1}{k-1} \sum_{j=1}^{k-1} (\ln x_{j,n} - \ln x_{k,n}).$$

Wenn $k = k(n) \rightarrow \infty$ und $k/n \rightarrow 0$, dann $x_{k,n} \rightarrow \infty$ für $n \rightarrow \infty$, und dann folgt aus (8):

$$\lim_{n \rightarrow \infty} \frac{1}{k-1} \sum_{j=1}^{k-1} (\ln x_{j,n} - \ln x_{k,n}) \stackrel{d}{=} \alpha^{-1}$$

Der untenstehende Hill-Schätzer ist also konsistent:

$$\hat{\alpha}_{k,n}^{(H)} = \left(\frac{1}{k} \sum_{j=1}^k (\ln x_{j,n} - \ln x_{k,n}) \right)^{-1}$$

Wie wird ein passendes k für eine gegebene Stichprobengröße n gewählt?

k zu klein: hohe Varianz des Schätzers!

k zu gross: Schätzer basiert auf zentrale Werte der Verteilung \implies
Der Schätzer ist verzerrt!

Grafische Inspektion des Hill Plots: $\left\{ \left(k, \hat{\alpha}_{k,n}^{(H)} \right) : k = 2, \dots, n \right\}$

Für einen gegebenen Schätzer $\hat{\alpha}_{k,n}^{(H)}$ von α erhält man folgenden Schätzer für die Randverteilung \hat{F} :

$$\hat{F}(x) = \frac{k}{n} \left(\frac{x}{x_{k,n}} \right)^{-\hat{\alpha}_{k,n}^{(H)}}.$$

und folgenden Quantil-Schätzer:

$$\hat{q}_p = \hat{F}^{\leftarrow}(p) = \left(\frac{n}{k}(1-p) \right)^{-1/\hat{\alpha}_{k,n}^{(H)}} x_{k,n}.$$