

Teorie extrémních hodnot

1.1 Parametrické modely extrémních hodnot

Potřeba parametrického modelování vychází z toho, že se zajímáme o hodnoty, kterých je dosahováno s malými pravděpodobnostmi a které se v pozorovaných datech vyskytují zřídka.

Nejprve uvedeme dva základní způsoby, jakými mohou být pozorované hodnoty upraveny, aby na ně mohly být užity modely teorie extrémů:

1. **Bloková maxima:** Data X_1, X_2, \dots jsou rozdělena do m bloků o velikosti n , z nich jsou zjištěna bloková maxima M_{n1}, \dots, M_{nm} . Příkladem mohou být roční maxima průtoků vody získaná z denních měření nebo roční maximální ztráty v řadě denních změn ceny akcií.
2. **Překročení limitu:** Z dat jsou užita pouze pozorování překračující stanovenou vysokou mez (tato metoda je v současnosti preferována, neboť efektivněji využívá informace o extrémních hodnotách obsažené v datech).

1.1.1 Rozdělení extrémních hodnot

Parametrickými modely užívanými v analýze blokových maxim jsou *rozdělení extrémních hodnot*. Tato rozdělení jsou limitními rozděleními pro posloupnost vhodně normovaných maxim M_n z n nezávislých stejně rozdělených veličin (při $n \rightarrow \infty$). Hrají roli analogickou roli normálního rozdělení v konvergenci normovaných součtů nezávislých stejně rozdělených veličin.

Uvedeme distribuční funkce rozdělení extrémních hodnot:

$$\text{Gumbelovo rozdělení:} \quad G_0(x) = \exp(-e^{-x}), \quad x \in \mathbb{R}, \quad (1)$$

$$\text{Fréchetovo rozdělení:} \quad G_{1,\alpha}(x) = \exp(-x^{-\alpha}), \quad x \geq 0, \quad \alpha > 0, \quad (2)$$

$$\text{Weibullovo rozdělení:} \quad G_{2,\alpha}(x) = \exp(-(-x)^{-\alpha}), \quad x \leq 0, \quad \alpha < 0. \quad (3)$$

Úplné třídy těchto rozdělení dostaneme zavedením parametru polohy μ a parametru měřítka $\sigma > 0$:

$$G_{0,\mu,\sigma}(x) = \exp\left(-e^{-(x-\mu)/\sigma}\right), \quad (4)$$

$$G_{i,\alpha,\mu,\sigma}(x) = G_{i,\alpha}\left(\frac{x-\mu}{\sigma}\right), \quad i = 1, 2. \quad (5)$$

Poznamenejme, že parametr μ je levým koncovým bodem distribuční funkce Fréchetova rozdělení a pravým koncovým bodem distribuční funkce Weibullova rozdělení.

Výše uvedené modely je možné zavedením reparametrisace $\gamma = \frac{1}{\alpha}$ převést na jednotný model *zobecněného rozdělení extrémních hodnot* s distribuční funkcí

$$G_\gamma(x) = \exp(-(1 + \gamma x)^{-1/\gamma}), \quad \gamma \neq 0, \quad (6)$$

$$G_0(x) = \exp(-e^{-x}), \quad \gamma = 0, \quad (7)$$

kde $1 + \gamma x > 0$.

Parametry polohy a měřítka v původních třídách rozdělení byly zvoleny tak, aby platilo

$$\lim_{\gamma \rightarrow 0} G_\gamma(x) = G_0(x).$$

Pro $\gamma > 0$ dostáváme Fréchetovo rozdělení s levým koncovým bodem $-1/\gamma$. Pro $\gamma < 0$ dostáváme Weibulovo rozdělení s pravým koncovým bodem $1/|\gamma|$.

V modelu zobecněného rozdělení extrémních hodnot je γ parametrem určujícím tvar rozdělení, tříparametrickou rodinu opět dostaneme zavedením parametru polohy μ a parametru měřítka $\sigma > 0$:

$$G_{\gamma,\mu,\sigma}(x) = \exp\left(-\left(1 + \gamma \frac{x - \mu}{\sigma}\right)^{-1/\gamma}\right), \quad \gamma \neq 0, \quad (8)$$

$$G_{0,\mu,\sigma}(x) = \exp\left(-e^{\frac{x-\mu}{\sigma}}\right), \quad \gamma = 0, \quad (9)$$

kde $1 + \gamma \frac{x-\mu}{\sigma} > 0$.

1.1.2 Fisherova-Tippettova věta

Předpokládejme, že X_1, X_2, \dots je posloupnost nezávislých stejně rozdělených náhodných veličin s distribuční funkcí F . Potom

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

má distribuční funkci

$$P(M_n \leq x) = F^n(x).$$

Limitní chování normovaných maxim charakterizuje

Věta 1 (Fisher, Tippett). *Pokud existují posloupnosti konstant $c_n > 0$, $d_n \in \mathbb{R}$ tak, že*

$$\lim_{n \rightarrow \infty} P\left(\frac{M_n - d_n}{c_n} \leq x\right) = \lim_{n \rightarrow \infty} F^n(c_n x + d_n) = G(x) \quad (10)$$

pro nějakou nedegenerovanou distribuční funkci G , potom G je distribuční funkce zobecněného rozdělení extrémních hodnot.

Pokud je splněn předpoklad Fisherovy-Tippettovy věty, říkáme, že distribuční funkce F náleží do *sféry přitažlivosti* (*maximum domain of attraction*) rozdělení s distribuční funkcí G , značíme $F \in \text{MDA}(G)$.

Poznámka. Při konvergenci normovaných maxim je typ limitního rozdělení (specifikovaný parametrem γ) určen jednoznačně, parametr polohy a měřítka závisí na zvolených posloupnostech normujících konstant. Ty je vždy možno zvolutit tak, že limitou je standardní distribuční funkce $G_\gamma (= G_{\gamma,0,1})$.

Označme $\bar{F}(x) = 1 - F(x)$. Sféru přitažlivosti rozdělení extrémních hodnot charakterizuje následující tvrzení:

Věta 2. *Distribuční funkce F patří do sféry přitažlivosti rozdělení extrémních hodnot s distribuční funkcí G s normujícími konstantami $c_n > 0$, $d_n \in \mathbb{R}$, právě když*

$$\lim_{n \rightarrow \infty} n\bar{F}(c_n x + d_n) = -\ln G(x), \quad x \in \mathbb{R}. \quad (11)$$

(Pro $G(x) = 0$ interpretujeme limitu jako $+\infty$.)

Důkaz. Nechť platí

$$\lim_{n \rightarrow \infty} \text{P}(M_n \leq c_n x + d_n) = \lim_{n \rightarrow \infty} (1 - \bar{F}(c_n x + d_n))^n = G(x) \neq 0. \quad (12)$$

Potom je $\lim_{n \rightarrow \infty} \bar{F}(c_n x + d_n) = 0$ a tvrzení dostaneme z (12) užitím řádové rovnosti $-\log(1-x) \sim x$, $x \rightarrow 0$.

Nyní předpokládejme, že platí (11), kde $G(x) \neq 0$. Potom je

$$\text{P}(M_n \leq c_n x + d_n) = \left(1 + \frac{\log G(x)}{n} + o\left(\frac{1}{n}\right)\right)^n \rightarrow G(x), \quad n \rightarrow \infty.$$

V případě $G(x) = 0$ se z předpokladu, že $\lim_{n \rightarrow \infty} n\bar{F}(c_n x + d_n) = \infty$ dokáže platnost vztahu $\lim_{n \rightarrow \infty} \text{P}(M_n \leq c_n x + d_n) = 0$ sporem: pokud by posledně uvedená limita byla nenulová, mohli bychom vybrat posloupnost $\{n_k\}$ tak, že $\lim_{k \rightarrow \infty} n_k \bar{F}(c_{n_k} x + d_{n_k}) < \infty$. Obrácená implikace se dokáže podobně. \square

1.1.3 Fréchetovo rozdělení

U Fréchetova rozdělení s distribuční funkcí (2) má pravděpodobnost překročení hodnoty x vyjádření

$$\bar{G}_{1,\alpha}(x) = 1 - \exp(-x^{-\alpha}) \sim x^{-\alpha}, \quad x \rightarrow \infty.$$

Pro momenty Fréchetova rozdělení platí

$$\text{E } X^j = \int_0^\infty x^j d\bar{G}_{1,\alpha}(x) = \Gamma(1 - j/\alpha), \quad j < \alpha,$$

kde

$$\Gamma(z) = \int_0^\infty x^{z-1} e^{-x} dx.$$

Sféru přitažlivosti Fréchetova rozdělení lze charakterizovat pomocí chvostů příslušných rozdělení:

Věta 3.

$$F \in \text{MDA}(G_{1,\alpha}) \iff \bar{F}(x) = x^{-\alpha} L(x), \alpha > 0,$$

kde L je kladná lebesgueovský měřitelná funkce na $(0, \infty)$ splňující

$$\lim_{x \rightarrow \infty} \frac{L(tx)}{L(x)} = 1, \quad t > 0. \quad (\text{SV})$$

Podmínka (SV) definuje *pomalu se měnící funkci v nekonečnu*.

Podle výše uvedeného tvrzení jsou chvosty rozdělení ze sféry přitažlivosti Fréchetova rozdělení *pravidelně se měnící funkce v nekonečnu*. Rozdělení z $\text{MDA}(G_{1,\alpha})$ jsou rozdělení s „těžkými chvosty“. Lze například ukázat, že momenty $E X^j$ rozdělení nezáporné náhodné veličiny nalezející do $\text{MDA}(G_{1,\alpha})$ jsou nekonečné pro $j > \alpha$.

Příklad. Paretovo rozdělení s distribuční funkcí

$$F(x) = 1 - \left(\frac{\kappa}{\kappa + x} \right)^\alpha, \quad \alpha > 0, \quad \kappa > 0, \quad x \geq 0,$$

patří do sféry přitažlivosti Fréchetova rozdělení. Vedle výše uvedené charakterizace pomocí chvostů lze toto ověřit přímo volbou normujících posloupností v (10):

$$c_n = \kappa n^{1/\alpha} / \alpha, \quad d_n = \kappa n^{1/\alpha} - \kappa.$$

1.1.4 Gumbelovo rozdělení

Pro distribuční funkci Gumbelova rozdělení platí

$$\bar{G}_0(x) = 1 - \exp(-e^{-x}) \sim e^{-x}, \quad x \rightarrow \infty,$$

jeho střední hodnota je rovna Eulerově konstantě $\lambda = 0.577216\dots$

Sféra přitažlivosti Gumbelova rozdělení obsahuje distribuční funkce s omezeným i neomezeným nosičem. Kladné náhodné veličiny z $\text{MDA}(G_0)$ mají konečné momenty všech řádů.

Příklad. Pro exponenciální rozdělení s distribuční funkcí

$$F(x) = 1 - \exp(-\beta x), \quad \beta > 0, \quad x \geq 0,$$

lze ověřit podmítku (10) volbou

$$c_n = \frac{1}{\beta}, \quad d_n = \frac{\ln n}{\beta}.$$

Do sféry přitažlivosti Gumbelova rozdělení patří i další často používaná rozdělení, například rozdělení gama, normální či logaritmicko-normální.

1.1.5 Weibullovo rozdělení

Weibullovo rozdělení má zprava omezený nosič, není proto příliš významné pro modelování extrémních jevů. Pro momenty rozdělení s distribuční funkcí (3) dostaneme vyjádření

$$\mathbb{E} X^j = \int_{-\infty}^0 x^j dG_{2,\alpha}(x) = (-1)^j \Gamma(1 - j/\alpha).$$

Při označení

$$x_F = \sup\{x \in \mathbb{R} : F(x) < 1\}$$

lze podobně jako u Fréchetova rozdělení charakterizovat sféru přitažlivosti Weibullova rozdělení pomocí chvostů příslušných distribučních funkcí.

Věta 4.

$$F \in \text{MDA}(G_{2,\alpha}) \iff x_F < \infty \text{ a } \bar{F}(x_F - x^{-1}) = x^\alpha L(x), \alpha < 0,$$

kde L splňuje podmínu (SV).

Příkladem rozdělení z $\text{MDA}(G_{2,\alpha})$ je rozdělení beta definované na intervalu $(0,1)$.

1.1.6 Zobecněné Paretovo rozdělení

Při analýze dat podle překročení stanovené vysoké meze hrají významnou úlohu rozdělení s distribučními funkcemi

$$\text{exponenciální rozdělení:} \quad W_0(x) = 1 - e^{-x}, \quad x \geq 0 \quad (13)$$

$$\text{Paretovo rozdělení:} \quad W_{1,\alpha}(x) = 1 - x^{-\alpha}, \quad x \geq 1, \quad (14)$$

$$\text{beta rozdělení:} \quad W_{2,\alpha}(x) = 1 - (-x)^{-\alpha}, \quad -1 \leq x \leq 0. \quad (15)$$

Parametr α je pro Paretovo rozdělení kladný a pro rozdělení beta záporný.

Uvedeme vyjádření obecných momentů těchto rozdělení.

$$\begin{aligned} W_0 : \quad & \mathbb{E} X^j = j!, \\ W_{1,\alpha} : \quad & \mathbb{E} X^j = \frac{\alpha}{\alpha - j}, \quad j < \alpha, \\ & = +\infty, \quad j \geq \alpha, \\ W_{2,\alpha} : \quad & \mathbb{E} X^j = (-1)^j \frac{\alpha}{\alpha - j}. \end{aligned}$$

Podobně jako v případě rozdělení extrémních hodnot můžeme pro popis výše uvedených distribučních funkcí s vhodně zvolenými parametry polohy a měřítka zavést jednotný tvar v závislosti na parametru γ . Dostáváme pak distribuční funkci

$$W_\gamma(x) = 1 - (1 + \gamma x)^{-1/\gamma}, \quad (16)$$

kde Paretovu rozdělení odpovídá volba $\gamma > 0$ a nosič $x \geq 0$ a rozdělení beta odpovídá volba $\gamma < 0$ a nosič $0 \leq x \leq 1/|\gamma|$. Z (16) také vyplývá spojitost uvedeného vyjádření v parametru γ ve smyslu konvergence k distribuční funkci exponenciálního rozdělení při $\gamma \rightarrow 0$.

Obecný tvar distribuční funkce zobecněného Paretova rozdělení pak opět dostaneme zavedením parametru polohy a měřítka:

$$W_{\gamma,\mu,\sigma}(x) = W_\gamma \left(\frac{x - \mu}{\sigma} \right), \quad \mu \in \mathbb{R}, \quad \sigma > 0. \quad (17)$$

Parametr μ je vždy levým koncovým bodem distribuční funkce (17).

Zavedeme nyní označení pro distribuční funkci rozdělení hodnot, které v pozorování veličin s distribuční funkcí F překračují stanovenou mez u ,

$$F^{[u]}(x) = \text{P}(X \leq x | X > u) = \frac{F(x) - F(u)}{1 - F(u)}, \quad x \geq u,$$

a pro distribuční funkci rozdělení excesů nadmezí u (výší překročení meze),

$$F^{(u)}(x) = \text{P}(X - u \leq x | X > u) = \frac{F(x + u) - F(u)}{1 - F(u)}, \quad 0 \leq x \leq x_F - u. \quad (18)$$

1.1.7 POT-stabilita zobecněného Paretova rozdělení

Distribuční funkce zobecněných Paretových rozdělení jsou jediné spojité distribuční funkce takové, že pro určitou volbu konstant b_u a a_u platí

$$F^{[u]}(b_u + a_u x) = F(x). \quad (19)$$

Vlastnost (19) se nazývá *POT-stabilita* (z anglického označení pro metody založené na sledování hodnot překračujících stanovenou mez - *peaks over threshold*). Uvedeme nyní některé konkrétní příklady:

1. Exponenciální rozdělení s nulovým levým koncovým bodem:

$$W_{0,0,\sigma}^{[u]} = W_{0,u,\sigma}.$$

2. Paretovo rozdělení s parametrem měřítka $\sigma \leq u$:

$$W_{1,\alpha,0,\sigma}^{[u]} = W_{1,\alpha,0,u}.$$

3. Zobecněné Paretovo rozdělení v γ -parametrizaci s parametrem polohy $\mu < u$:

$$W_{\gamma,\mu,\sigma}^{[u]} = W_{\gamma,u,\sigma+\gamma(u-\mu)}.$$

1.1.8 Limitní věta pro rozdělení vysokých hodnot

Parametrické modelování distribuční funkce $F^{[u]}$ pro velké hodnoty u pomocí zobecněného Paretova rozdělení je založeno na následujícím tvrzení:

Věta 5 (Balkema, de Haan). *Pokud $F^{[u]}(b_u + a_u x)$ má spojitou limitní distribuční funkci pro $u \rightarrow x_F$, potom*

$$\lim_{u \rightarrow x_F} |F^{[u]}(x) - W_{\gamma, u, \sigma(u)}(x)| = 0, \quad (20)$$

kde $\sigma(u) > 0$.

1.1.9 Konvergence rozdělení excesů

Konvergence rozdělení excesů k zobecněnému Paretovu rozdělení lze užít k charakterizaci sféry přitažlivosti rozdělení extrémních hodnot. Uvažujme distribuční funkci zobecněného rozdělení extrémních hodnot (6).

Věta 6. *Distribuční funkce F patří do sféry přitažlivosti $MDA(G_\gamma)$ právě když existuje kladná funkce $\beta(u)$ tak, že*

$$\lim_{u \uparrow x_F} \sup_{0 < x < x_F - u} |F^{(u)}(x) - W_{\gamma, 0, \beta(u)}(x)| = 0.$$

Výše uvedené tvrzení říká, že rozdělení, pro která konvergují normovaná maxima k zobecněnému rozdělení extrémních hodnot tvoří množinu, pro kterou příslušná rozdělení excesů konvergují s rostoucí mezí k zobecněnému Paretovu rozdělení. Navíc parametr určující tvar limitního rozdělení excesů je stejný jako parametr limitního rozdělení maxim.

1.1.10 Maxima veličin se zobecněným Paretovým rozdělením

Budeme-li uvažovat distribuční funkce (13), (14), resp. (15), snadno nahlédneme, že zobecněné Paretovo rozdělení vždy náleží do sféry přitažlivosti rozdělení extrémních hodnot se shodným parametrem α , s distribuční funkcí (1), (2), resp. (3). Platí totiž

$$\lim_{n \rightarrow \infty} W_0^n(x + \ln n) = G_0(x), \quad (21)$$

$$\lim_{n \rightarrow \infty} W_{1,\alpha}^n(n^{1/\alpha} x) = G_{1,\alpha}(x), \quad (22)$$

$$\lim_{n \rightarrow \infty} W_{2,\alpha}^n(n^{1/\alpha} x) = G_{2,\alpha}(x). \quad (23)$$

1.2 Analýza dat v modelech extrémních hodnot

Dále se budeme zabývat vybranými postupy pro statistickou analýzu extrémních hodnot. Analyzovaná data mohou mít podobu blokových maxim nebo hodnot překračujících danou vysokou mez.

1.2.1 Metoda blokových maxim pro nezávislá pozorování

Předpokládejme vzájemně nezávislá pozorování pocházející z rozdělení s distribuční funkcí F . Nechť F patří do sféry přitažlivosti zobecněného rozdělení extrémních hodnot (8). Z hlediska modelování extrémních jevů má význam zejména Fréchetovo rozdělení, tedy případ, kdy $\gamma > 0$. Data mějme rozdělená do m bloků o velikosti n (může jít například o roční bloky měření prováděných denně). Z těchto bloků použijeme pro analýzu maxima M_{n1}, \dots, M_{nm} . Pro dostatečně velký rozsah bloků n může být rozdělení blokových maxim approximováno distribuční funkcí (8). K odhadu parametrů této distribuční funkce lze užít metodu maximální věrohodnosti. Příslušná logaritmická věrohodnostní funkce má tvar

$$\begin{aligned} l(\gamma, \mu, \sigma; M_{n1}, \dots, M_{nm}) &= \sum_{i=1}^m \ln g_{\gamma, \mu, \sigma}(M_{ni}) \\ &= -m \ln \sigma \\ &\quad - (1 + 1/\gamma) \sum_{i=1}^m \ln \left(1 + \gamma \frac{M_{ni} - \mu}{\sigma} \right) - \sum_{i=1}^m \left(1 + \gamma \frac{M_{ni} - \mu}{\sigma} \right)^{-1/\gamma}, \end{aligned} \quad (24)$$

kde $g_{\gamma, \mu, \sigma}(x)$ je hustota příslušná distribuční funkci (8). Logaritmická věrohodnostní funkce se maximalizuje za podmínek $\sigma > 0$, $1 + \gamma(M_{ni} - \mu)/\sigma > 0$ pro všechna i . Poznamenejme, že v tomto případě množina přípustných hodnot pro odhadované parametry závisí na pozorováních. Nejsou tedy splněny podmínky regularity obvykle užívané pro vyvození žadoucích vlastností odhadů. V literatuře se nicméně uvádí, že pro $\gamma > -1/2$ lze dokázat konsistenci a asymptotickou vydatnost odhadů $\hat{\gamma}, \hat{\mu}, \hat{\sigma}$ získaných maximalizací (24).

Všimněme si rozporu ve volbě optimálního počtu a rozsahu bloků. Velký počet m použitých bloků znamená více dat pro metodu maximální věrohodnosti a vede tak k odhadům s menším rozptylem. Oproti tomu velký rozsah n jednotlivých bloků znamená přesnejší přiblžení skutečného rozdělení blokových maxim pomocí zobecněného rozdělení extrémních hodnot a vede tak k menšímu vychýlení výsledných odhadů.

1.2.2 Analýza extrémních jevů v modelu blokových maxim

Předpokládejme, že jsme přiblížili rozdělení blokových maxim v datech pomocí distribuční funkce zobecněného rozdělení extrémních hodnot, s parametry odhadnutými například výše zmíněnou metodou maximální věrohodnosti. Odhadnutý model pak můžeme dále využít například pro

1. stanovení velikosti extrémního jevu, který bude v průměru nastávat se zvolenou frekvencí,
2. stanovení průměrné frekvence výskytu extrémního jevu dané úrovňě.

Nechť G označuje skutečnou distribuční funkci maxim z bloků o rozsahu n . Zaved'me označení

$$r_{n,k} = q_{1-1/k}(G)$$

pro $(1 - 1/k)$ -kvantil rozdělení s distribuční funkcí G , tj.

$$P(M_n > r_{n,k}) = \frac{1}{k}.$$

Hodnota $r_{n,k}$ je tedy definována jako úroveň, která je v průměru překročena maximem v jednom z k bloků. Nazýváme ji *úroveň návratu (return level)*. Pokud přiblížíme distribuční funkci G distribuční funkci (8) s odhadnutými parametry $\hat{\gamma}, \hat{\mu}, \hat{\sigma}$, odvodíme vyjádření odhadu úrovni návratu ve tvaru

$$\hat{r}_{n,k} = \hat{\mu} + \frac{\hat{\sigma}}{\hat{\gamma}} \left((-\ln(1 - 1/k))^{-\hat{\gamma}} - 1 \right).$$

Podobně můžeme pro dané u definovat pomocí distribuční funkce G hodnotu

$$k_{n,u} = \frac{1}{\bar{G}(u)} = \frac{1}{1 - G(u)},$$

tj.

$$P(M_n > u) = \frac{1}{k_{n,u}}.$$

Lze tedy říci, že v $k_{n,u}$ blocích o rozsahu n očekáváme výskyt jednoho bloku, v němž dojde k překročení úrovni u . Číslo $k_{n,u}$ nazýváme *doba návratu (return period)* a pro jeho odhad použijeme vztah

$$\hat{k}_{n,u} = \frac{1}{\bar{G}_{\hat{\gamma}, \hat{\mu}, \hat{\sigma}}(u)}.$$

1.2.3 Metody založené na překročení meze

Uvažujme distribuční funkci zobecněného Paretova rozdělení (17) s nulovým parametrem polohy:

$$\begin{aligned} W_{\gamma, \sigma}(x) &= 1 - (1 + \gamma x / \sigma)^{-1/\gamma}, \quad \gamma \neq 0 \\ W_{0, \sigma}(x) &= 1 - \exp(-x / \sigma), \end{aligned} \tag{25}$$

kde $\sigma > 0$. Rozdělení je definováno pro $x \geq 0$ v případě $\gamma \geq 0$ a pro $0 \leq x \leq -\sigma/\gamma$ pro $\gamma < 0$.

Zavedeme označení

$$e(u) = E(X - u | X > u) \tag{26}$$

pro střední hodnotu velikosti překročení meze u za podmínky, že k překročení meze dojde. Jde o střední hodnotu rozdělení s distribuční funkci (18). Z (17) a (18) lze snadno odvodit, že pro náhodnou veličinu se zobecněným Paretovým rozdělením (25) mají excesy nad danou mezí u opět rozdělení typu (18), se stejným parametrem γ a parametrem měřítka závislým na u :

$$F^{(u)}(x) = W_{\gamma, \sigma(u)}(x), \quad \sigma(u) = \sigma + \gamma u, \tag{27}$$

kde $0 \leq x < \infty$ v případě $\gamma \geq 0$ a $0 \leq x \leq -(\sigma/\gamma) - u$ v případě $\gamma < 0$. Zároveň lze z (25) odvodit vyjádření střední hodnoty zobecněného Paretova rozdělení

$$\mathbb{E} X = \frac{\sigma}{1 - \gamma}, \quad (28)$$

která je konečná pro $\gamma < 1$. Z (27) a (28) pak plyne

$$= e(u) \frac{\sigma + \gamma u}{1 - \gamma},$$

kde $0 \leq u < \infty$ v případě $0 \leq \gamma < 1$, $0 \leq u \leq -\beta/\gamma$ v případě $\gamma < 0$.

Linearita funkce $e(u)$ je vlastností užívanou k identifikaci zobecněného Paretova rozdělení. Z n pozorování můžeme pro danou mez u sestrojit empirický odhad střední hodnoty $e(u)$ ve tvaru

$$e_n(u) = \frac{\sum_{i=1}^n (X_i - u) \mathbf{I}_{[X_i > u]}}{\sum_{i=1}^n \mathbf{I}_{[X_i > u]}}. \quad (29)$$

Pak můžeme graficky znázornit body

$$\{(X_{i,n}, e_n(X_{i,n})), i = 2 \dots n\},$$

kde $X_{n,n} \leq \dots \leq X_{1,n}$ jsou pořadové statistiky z pozorování X_1, \dots, X_n . V případě, že pozorování pocházejí ze zobecněného Paretova rozdělení, měl by tento graf vykazovat lineární trend. Místo, kde začíná být průběh grafu přibližně lineární, může případně sloužit k volbě meze u pro účely modelování chvostů rozdělení pomocí zobecněného Paretova modelu. Rostoucí lineární trend bude ukazovat na model s $\gamma > 0$, směřování k horizontálnímu grafu na případ s $\gamma = 0$, klesající trend pak na $\gamma < 0$.

1.2.4 Modelování chvostů rozdělení

Mějme X_1, \dots, X_n pozorování nezávislých stejně rozdělených náhodných veličin. Označme N_u počet pozorování překračujících zvolenou mez u . Z hodnot $\tilde{X}_1, \dots, \tilde{X}_{N_u}$ překračujících mez u získáme velikosti excesů $Y_j = \tilde{X}_j - u$. Pro účel proložení rozdělení (25) pozorovanými excesy lze užít metodu maximální věrohodnosti. Logaritmická věrohodnostní funkce

$$l(\gamma, \sigma; Y_1, \dots, Y_{N_u}) = -N_u \ln \sigma - (1 + 1/\gamma) \sum_{j=1}^{N_u} \ln \left(1 + \gamma \frac{Y_j}{\sigma} \right) \quad (30)$$

se maximalizuje za podmínek $\sigma > 0$, $1 + \gamma Y_j / \sigma > 0$ pro všechna j .

Pokud pro danou distribuční funkci F budeme approximovat rozdělení excesů nadmezí u zobecněným Paretovým rozdělením (25), můžeme psát pro $x \geq u$

$$\bar{F}(x) = \bar{F}(u) \bar{F}^{(u)}(x - u) = \bar{F}(u) \left(1 + \gamma \frac{x - u}{\sigma} \right)^{-1/\gamma}. \quad (31)$$

Inverzí odtud dostaneme vyjádření kvantilu (označovaného také jako *hodnota v riziku* VaR_α) pro $\alpha \geq F(u)$:

$$q_\alpha(F) = u + \frac{\sigma}{\gamma} \left(\left(\frac{1-\alpha}{\bar{F}(u)} \right)^{-\gamma} - 1 \right). \quad (32)$$

Z (31) a (32) odvodíme pro $x \geq u$ odhad

$$\hat{\bar{F}}(x) = \frac{N_u}{n} \left(1 + \hat{\gamma} \frac{x-u}{\hat{\sigma}} \right)^{-1/\hat{\gamma}} \quad (33)$$

a pro $\alpha > 1 - N_u/n$ odhad

$$\hat{q}_\alpha(F) = u + \frac{\hat{\sigma}}{\hat{\gamma}} \left(\left(\frac{1-\alpha}{N_u/n} \right)^{-\hat{\gamma}} - 1 \right). \quad (34)$$

V (33) a (34) nahrazujeme parametry zobecněného Paretova rozdělení jejich odhadů získanými například maximalizací (30). Pravděpodobnost $\bar{F}(u)$ odhadujeme poměrem N_u/n . Předpokládáme, že počet pozorování přesahujících mez u je dostatečný pro spolehlivý odhad $\bar{F}(u)$. Oproti tomu při odhadu $\bar{F}(x)$ pro vysoká x využíváme extrapolace založené na zobecněném Paretově rozdělení.

1.2.5 Hillova metoda

Popíšeme přístup vhodný pro odhadování chvostů rozdělení náležejících do sféry přitažlivosti Fréchetova rozdělení (2). Jde o rozdělení charakteristická „těžkými chvosty“ (pomalou konvergencí $\bar{F}(x)$ k nule při $x \rightarrow \infty$). Sféru přitažlivosti Fréchetova rozdělení charakterizuje Věta 3. Parametr α se nazývá *index chvostu* rozdělení s distribuční funkcí $F \in \text{MDA}(G_{1,\alpha})$. *Hillův odhad* je odhadem indexu α na základě stejně rozdělených pozorování X_1, \dots, X_n . Naznačíme jedno z jeho možných odvození.

Označme

$$\begin{aligned} e^*(\ln u) &= E(\ln X - \ln u | \ln X > \ln u) \\ &= \frac{1}{\bar{F}(u)} \int_u^\infty (\ln x - \ln u) dF(x). \end{aligned}$$

Integrací per partes a dosazením dle Věty 3 dostaneme vyjádření

$$e^*(\ln u) = \frac{1}{\bar{F}(u)} \int_u^\infty \frac{\bar{F}(x)}{x} dx = \frac{1}{\bar{F}(u)} \int_u^\infty L(x) x^{-(\alpha+1)} dx. \quad (35)$$

Další zjednodušení (35) je založeno na *Karamatově větě* pro pomalu se měnící funkce v nekonečnu.

Věta 7 (Karamata). Nechť L je pomalu se měnící funkce, která je lokálně omezená v $[x_0, \infty)$ pro nějaké $x \geq 0$. Potom pro $\kappa < -1$ platí řádová rovnost

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

Aplikací na (35) dostáváme řádovou rovnost

$$e^*(\ln u) \sim \frac{L(u) u^{-\alpha} \alpha^{-1}}{\bar{F}(u)} = \alpha^{-1}, \quad u \rightarrow \infty. \quad (36)$$

Hillův odhad indexu α je převrácená hodnota odhadu $e_n^*(\ln X_{k,n})$, kde $X_{k,n}$ je k -tá největší hodnota v X_1, \dots, X_n .

$$\hat{\alpha}_{k,n}^{(H)} = \left(\frac{1}{k} \sum_{j=1}^k \ln X_{j,n} - \ln X_{k,n} \right)^{-1}. \quad (37)$$

Odhad (37) závisí na volbě k . Doporučuje se grafické znázornění bodů (*Hillův graf*)

$$\{(k, \hat{\alpha}_{k,n}^{(H)}), k = 2 \dots n\},$$

které slouží k nalezení oblasti, ve které vycházejí podobné hodnoty odhadu počítané z různých počtů pořadových statistik.

Nyní ukážeme, jak lze s pomocí (37) odhadovat pravděpodobnosti $\bar{F}(u)$ pro distribuční funkci ze sféry přitažlivosti Fréchetova rozdělení. Předpokládejme $\bar{F}(x) = C x^{-\alpha}$ pro $x \geq u > 0$, kde u je vysoká mez. (Pomalu se měnící funkci nahradíme pro dostatečně velké x konstantou.) Pak můžeme psát $C = u^\alpha \bar{F}(u)$, kde index α nahradíme odhadem (37) a u nahradíme pořadovou statistikou $X_{k,n}$. Potom $\bar{F}(u)$ je odhadnuto podílem k/n a dostáváme odhad

$$\hat{\bar{F}}(x) = \frac{k}{n} \left(\frac{x}{X_{k,n}} \right)^{-\hat{\alpha}_{k,n}^{(H)}}. \quad (38)$$

Pokud označíme $X_{k,n} = u$, $k = N_u$, $\hat{\gamma}^{(H)} = \left(\hat{\alpha}_{k,n}^{(H)} \right)^{-1}$, můžeme (38) přepsat ve tvaru

$$\hat{\bar{F}}(x) = \frac{N_u}{n} \left(1 + \hat{\gamma}^{(H)} \frac{x-u}{\hat{\gamma}^{(H)} u} \right)^{-1/\hat{\gamma}^{(H)}},$$

který umožňuje srovnání s odhadem (33) založeným na maximálně věrohodných odhadech parametrů zobecněného Paretova rozdělení (při pevně zvolené mezi u).

Literatura

- [1] P.Embrechts, C.Klüppelberg, T.Mikosh: Modelling Extremal Events. Springer, 1997.
- [2] A.J.McNeil, R.Frey, P.Embrechts: Quantitative Risk Management. Princeton University Press, 2005.
- [3] R.D.Reiss, M.Thomas: Statistical Analysis of Extreme Values. Birkhäuser, 1997.