

ODHADY NÁVRATOVÝCH HODNOT KLIMATOLOGICKÝCH DAT

Jan Pícek

Katedra aplikované matematiky

Fakulta přírodovědně-humanitní a pedagogická

Technická univerzita v Liberci

Robust 2018

Velká pozornost v analýze extrémních dat (např. záplavy) je věnována odhadům T -leté úrovně (návrátová hodnota, T -letá voda).

Představa: úroveň opakující se v průměru jednou za T let.

Velká pozornost v analýze extrémních dat (např. záplavy) je věnována odhadům T -leté úrovně (návrátová hodnota, T -letá voda).

Představa: úroveň opakující se v průměru jednou za T let.

Z pohledu statistiky: vysoký kvantil rozdělení náhodné veličiny (průtoky).

$$u(T) = F^{-1} \left(1 - \frac{1}{T} \right)$$

$$P(X > u(T)) = 1 - F(u(T)) = \frac{1}{T}$$

Příklad: Roční maxima teploty vzduchu za období 1961-2007

Stanice Liberec

Návratová hodnota (roky)	10	20	100	1000
GEV rozdělení				
metoda max. věrohodnosti	34.1	34.9	36.3	37.9

Maximální dosažená hodnota za sledované období 36.2.

Nechť X_1, X_2, \dots jsou nezávislé stejně rozdělené náhodné veličiny s distribuční funkcí F .

Nechť $M_n = \max(X_1, \dots, X_n)$.

Předpokládejme, že existuje posloupnost reálných čísel $a_n > 0$ a b_n tak, že posloupnost $(M_n - b_n)/a_n$ konverguje v distribuci, t.j.

$$P((M_n - b_n)/a_n \leq x) = F^n(a_n x + b_n) \rightarrow G(x), \quad n \rightarrow \infty,$$

pro nějakou nedegenerovanou d.f. $G(x)$

Jestliže podmínka platí, říkáme, že F je ve **sféře přitažlivosti** G (maximum domain of attraction), $F \in \text{MDA}(G)$.

FISHEROVA-TIPPETTOVA VĚTA (1928)

Jestliže $F \in \text{MDA}(G)$ potom G je typu jedné z následujících tří d.f.

$$\text{Fréchet} \quad \Phi_{1/\gamma}(x) = \begin{cases} 0, & x \leq 0 \\ \exp(-x^{-1/\gamma}), & x > 0 \end{cases} \quad \gamma > 0$$

$$\text{Weibull} \quad \Psi_{1/\gamma}(x) = \begin{cases} \exp\{-(-x)^{1/\gamma}\}, & x \leq 0 \\ 1 & x > 0 \end{cases} \quad \gamma > 0$$

$$\text{Gumbel} \quad \Lambda(x) = \exp(-e^{-x}), \quad x \in \mathbb{R}.$$

FISHEROVA-TIPPETTOVA VĚTA (1928)

Jestliže $F \in \text{MDA}(G)$ potom G je typu jedné z následujících tří d.f.

$$\text{Fréchet} \quad \Phi_{1/\gamma}(x) = \begin{cases} 0, & x \leq 0 \\ \exp(-x^{-1/\gamma}), & x > 0 \end{cases} \quad \gamma > 0$$

$$\text{Weibull} \quad \Psi_{1/\gamma}(x) = \begin{cases} \exp\{-(-x)^{1/\gamma}\}, & x \leq 0 \\ 1 & x > 0 \end{cases} \quad \gamma > 0$$

$$\text{Gumbel} \quad \Lambda(x) = \exp(-e^{-x}), \quad x \in \mathbb{R}.$$

GNĚDĚNKO (1943)

Limitní rozdělení je zobecněné rozdělení extrémních hodnot.

$$G(x) = G_\gamma(x) = \begin{cases} \exp(-(1 + \gamma x)^{-1/\gamma}) & \gamma \neq 0 \\ \exp(-e^{-x}) & \gamma = 0 \end{cases},$$

kde $1 + \gamma x > 0$

G je určena jednoznačně až na parametr polohy a měřítka.

Předpokládáme, že data rozdělíme do bloků obsahující n (velké) hodnot, bereme maximum v každém bloku a využijeme limitní výsledek, t.j. GEV rozdělení.

Užití limitního rozdělení:

$$P\left(\frac{M_n - b_n}{a_n} \leq x\right) \approx G_\gamma(x).$$

$$y = a_n x + b_n \Rightarrow P(M_n \leq y) \approx G_\gamma\left(\frac{y - b_n}{a_n}\right) = G_{\gamma, b_n, a_n}(y).$$

Parametry odhadneme, např. metodou maximální věrohodnosti

$$L(b, a, \gamma) = -m \log a - (1 + 1/\gamma) \sum_{i=1}^m \log \left(1 + \gamma \left(\frac{z_i - b}{a} \right) \right) \\ - \sum_{i=1}^m \left[1 + \gamma \left(\frac{z_i - b}{a} \right) \right]^{-1/\gamma}$$

pro $\gamma = 0$

$$L(b, a) = -m \log a - \sum_{i=1}^m \left(\frac{z_i - b}{a} \right) - \sum_{i=1}^m \exp \left\{ \left(\frac{z_i - b}{a} \right) \right\}.$$

Neexistuje analytické řešení.

Příklad: Roční maxima teploty vzduchu za období 1961-2007

Stanice Liberec

Návratová hodnota (roky)	10	20	100	1000
GEV rozdělení				
metoda max. věrohodnosti	34.1	34.9	36.3	37.9

Maximální dosažená hodnota za sledované období 36.2.

Příklad: Roční maxima teploty vzduchu za období 1961-2007

Stanice Liberec

Návratová hodnota (roky)	10	20	100	1000
GEV rozdělení				
metoda max. věrohodnosti	34.1	34.9	36.3	37.9
Gumbelovo rozdělení				
metoda max. věrohodnosti	34.4	35.3	38.4	42.2

Maximální dosažená hodnota za sledované období 36.2.

Pro malé a střední rozsahy výběrů odhady lepší vlastnosti než metoda maximální věrohodnosti *např. simulační studie (Hosking, Wallis, Wood) ukazuje, že pro všechna k GEV z intervalu $(-0.5, 0.5)$ a rozsah výběru do 100 mají odhady menší či srovnatelnou střední kvadratickou chybu ve srovnání s odhady maximální věrohodnosti*

Nechť X_1, X_2, \dots, X_n je náhodný výběr s distribuční funkcí $F(x)$ a kvantilovou funkcí $Q(u)$ a necht' $X_{1:n} \leq X_{2:n} \leq X_{n:n}$ jsou pořádkové statistiky.

L-momenty:

$$\lambda_r = \frac{1}{r} \sum_{k=0}^{r-1} (-1)^k \binom{r-1}{k} EX_{r-k:r}, \quad r = 1, 2, \dots$$

$$EX_{j:r} = \frac{r!}{(j-1)!(r-j)!} \int x (F(x))^{j-1} (1-F(x))^{r-j} dF(x)$$

$$\lambda_1 = EX = \int_0^1 Q(u) du$$

$$\lambda_2 = \frac{1}{2} E(X_{2:2} - X_{1:2}) = \int_0^1 Q(u)(2u-1) du$$

$$\lambda_3 = \frac{1}{3} E(X_{3:3} - 2X_{2:3} + X_{1:3}) = \int_0^1 Q(u)(6u^2 - 6u + 1) du$$

Příklady L -momentů některých rozdělení:

Rovnoměrné na (a, b) $\lambda_1 = \frac{1}{2}(a + b), \lambda_2 = \frac{1}{6}(b - a), \tau_3 = 0, \tau_4 = 0$

Normální $\mathcal{N}(\mu, \sigma^2)$ $\lambda_1 = \mu, \lambda_2 = \frac{\sigma}{\pi}, \tau_3 = 0, \tau_4 = 0.1226$

Gumbelovo rozdělení $F(x) = \exp[-\exp(-(x - \xi)/\alpha)]$

$\lambda_1 = \xi + \alpha\gamma, \lambda_2 = \alpha \log 2, \tau_3 = 0.1699,$
 $\tau_4 = 0.1504, \gamma = 0.5772... \text{ konst.}$

Zobecněné rozdělení
extrémních hodnot
(GEV)

$F(x) = \exp[-(1 - k(x - \xi)/\alpha)^{\frac{1}{k}}]$
 $\lambda_1 = \xi + \alpha(1 - \Gamma(1 + k))/k,$
 $\lambda_2 = \alpha(1 - 2^{-k})\Gamma(1 + k)/k,$
 $\tau_3 = 2(1 - 3^{-k})/(1 - 2^{-k}) - 3, \tau_4 = \dots$
 $k > -1, \Gamma(.)$ označuje gamma funkci

Odhady: Výběrový L -moment:

$$l_r = \binom{n}{r}^{-1} \sum_{1 \leq i_1 < i_2 < \dots < i_r \leq n} \sum_{k=0}^{r-1} (-1)^k \binom{r-1}{k} X_{i_{r-k}:n},$$

$r = 1, 2, \dots, n.$

Speciálně:

$$l_1 = \frac{1}{n} \sum_{i=1}^n X_i, \quad l_2 = \frac{1}{2} \binom{n}{2}^{-1} \sum_{i>j} (X_{i:n} - X_{j:n})$$

$$l_3 = \frac{1}{3} \binom{n}{3}^{-1} \sum_{i>j>k} (X_{i:n} - 2X_{j:n} + X_{k:n})$$

$$l_4 = \frac{1}{4} \binom{n}{4}^{-1} \sum_{i>j>k>l} (X_{i:n} - 3X_{j:n} + 3X_{k:n} - X_{l:n})$$

Odhady paramterů – L-momentová metoda

Rovnoměrné na (a, b) $\hat{a} = l_1 - 3l_2, \hat{a} = l_1 + 3l_2$

Normální $\mathcal{N}(\mu, \sigma^2)$ $\hat{\mu} = l_1, \hat{\sigma} = \pi^{1/2}l_2$

Gumbelovo rozdělení $F(x) = \exp[-\exp(-(x - \xi)/\alpha)]$

$$\begin{aligned}\hat{\xi} &= l_1 - \hat{\alpha}\gamma, \hat{\alpha} = l_2 / \log 2 \\ \gamma &= 0.5772... \text{ konst.}\end{aligned}$$

Zobecněné rozdělení
extrémních hodnot
(GEV)

$$\begin{aligned}F(x) &= \exp[-(1 - k(x - \xi)/\alpha)^{\frac{1}{k}}] \\ z &= 2/(3 + t_3) - \log 2 / \log 3, \\ \hat{k} &= 7.8590z + 2.9554z^2, \\ \hat{\alpha} &= l_2 \hat{k} / [(1 - 2^{-\hat{k}})\Gamma(1 + \hat{k})], \\ \hat{\xi} &= l_1 + \hat{\alpha}[\Gamma(1 + \hat{k}) - 1] / \hat{k}\end{aligned}$$

Příklad: Roční maxima teploty vzduchu za období 1961-2007

Stanice Liberec

Návratová hodnota (roky)	10	20	100	1000
GEV rozdělení				
metoda max. věrohodnosti	34.1	34.9	36.3	37.9
L-momentová metoda	34.2	35.0	36.7	38.6

Maximální dosažená hodnota za sledované období 36.2.

Příklad: Roční maxima teploty vzduchu za období 1961-2007

Stanice Liberec

Návratová hodnota (roky)	10	20	100	1000
GEV rozdělení				
metoda max. věrohodnosti	34.1	34.9	36.3	37.9
L-momentová metoda	34.2	35.0	36.7	38.6
Gumbelovo rozdělení				
metoda max. věrohodnosti	34.4	35.3	38.4	42.2
L-momentová metoda	34.2	35.0	37.8	41.4

Maximální dosažená hodnota za sledované období 36.2.

Nechť X_1, X_2, \dots jsou nezávislé stejně rozdělené náhodné veličiny s ditr. funkcí F . Je "rozumné" zahrnovat všechny hodnoty překračující daný vysoký práh (threshold) u . Chování extrémních událostí je dáno podmíněnou pravděpodobností $P(X_i > y | X_i > u)$ a

$$P(X_i < y | X_i > u) \rightarrow H(y), \quad u \rightarrow u_{end},$$

zobecněné Paretovo rozdělení

$$H(x) = \begin{cases} 1 - (1 + \gamma (\frac{x-\mu}{\sigma}))^{-1/\gamma} & \gamma \neq 0 \\ 1 - e^{-(\frac{x-\mu}{\sigma})} & \gamma = 0 \end{cases},$$

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

Uvažujeme hodnoty větší než dostatečně vysoký práh (threshold) a předpokládáme, že asymptotický výsledek je přibližně pravdivý, tj. užijeme zobecněné Paretovo rozdělení jako vhodný model.

Metoda je známa jako 'peaks-over-threshold' (POT).

Příklad: Roční maxima teploty vzduchu za období 1961-2007

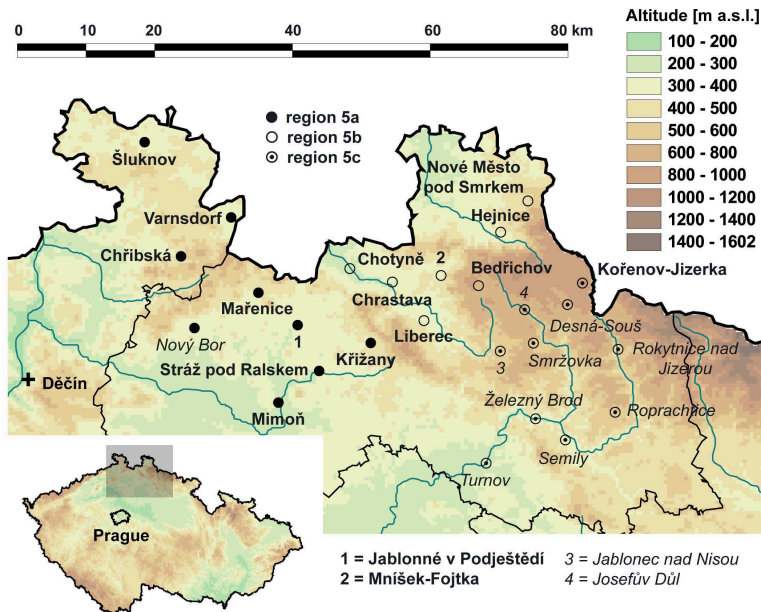
Stanice Liberec

Návratová hodnota (roky)	10	20	100	1000
GEV rozdělení				
metoda max. věrohodnosti	34.1	34.9	36.3	37.9
L-momentová metoda	34.2	35.0	36.7	38.6
POT				
treshold 26.50	34.1	34.6	35.5	36.7
treshold 29.37	34.3	34.9	36.1	37.5

Maximální dosažená hodnota za sledované období 36.2.

Kyselý, Jan ; Gaál, L. ; Pícek, J. ; Schindler, M., 2013: Return periods of the August 2010 heavy precipitation in northern Bohemia (Czech Republic) in the present climate and under climate change, Journal of Water and Climate Change, 4, pp. 265-286

SRÁŽKY - LIBERECKO



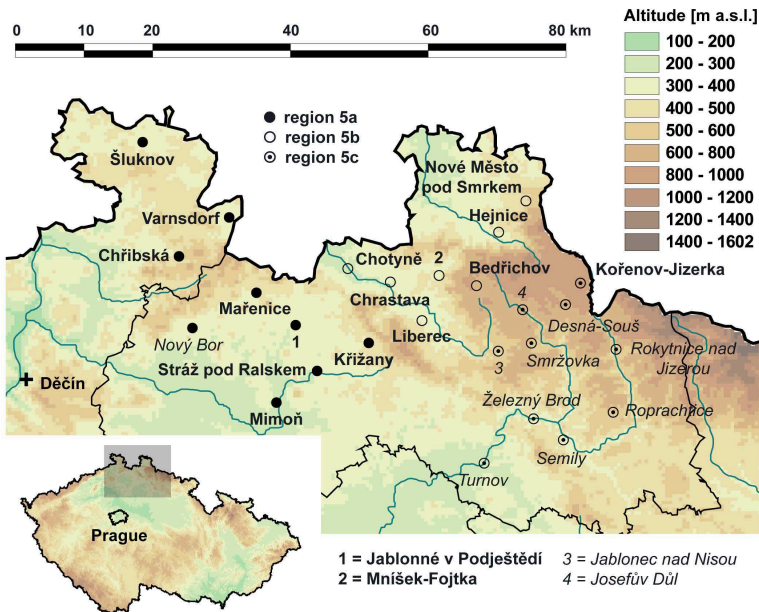
SRÁŽKY - LIBERECKO



Stanice	srpen 2010	roky (bez)	roky (s)
Hejnice	179.0	156.9	78.2
Mníšek	160.0	305.4	89.9
Chrastava	135.5	1337.9	66.1
Mařenice	124.2	1250.8	153.0
Bedřichov	112.0	17.3	15.9
Liberec	98.9	45.0	35.2

SRÁŽKY - LIBERECKO

Stanice	srpen 2010	roky (bez)	roky (s)
Hejnice	179.0	156.9 (53.4 - 24 809)	78.2 (36.8 - 2 612.5)
Mníšek	160.0	305.4 (67.8 - 95 119)	89.9 (38.2 - 8 117.3)
Chrastava	135.5	1337.9 (87.1 - 1.848x10 ⁶)	66.1 (28.9 - 4 427.8)
Mařenice	124.2	1250.8 (140.6 - 1.608x10 ⁶)	153.0 (54.6 - 23 530)
Bedřichov	112.0	17.3 (13.1 - 42.7)	15.9 (12.3 - 36.2)
Liberec	98.9	45.0 (24.8 - 535.1)	35.2 (21.4 - 200.6)

SRÁŽKY - LIBERECKO





?

Děkuji za pozornost.