


Teorie extrémních hodnot (EVT)

data:

extrémní (výše) hodnoty




klasická statistika

- průměrná data, výše plnění
- průměrný klient

- neparametrické metody - nejsou vhodné, protože máš řádový hodnoty, které se o datech objemů rozdílu nebo výšec
- parametrické metody - příliš citlivé na odchylky modelu


=> to není ve uplatnění jiný přístup

1) Metoda blokujících maxim



- porovnání rozdělíme na bloky
- v každém bloku najdeme maximální hodnotu
- modelujeme jen bloková maxima

2) Metoda POT (peaks-over-threshold) - překročení hranice



- zvolíme hranici μ
- najdeme ta pozorování, která překročí hranici μ
- modelujeme veličnosti překročení této hranice $X_i - \mu$ pro pozorování, která ji překročila

CL: odhadnout $P(X > x)$ pro x velké (pred. extrémní události)
 odhadnout $F^{-1}(z)$ pro z velké (výše kvantily)

- určit výši plnění, kterou máš jen málo procento klientů
- určit hranici, která bude překročena s průměrnou jednotou μ a x let

Chození maxima náh. systémů

X_1, \dots, X_n je náh. systém s distribuční funkcí F

označme $M_n = \max \{X_1, \dots, X_n\}$ maximum náh. systémů s rozsahem n .

Dozítelná je distribuční funkce: $G_n(x) = P(M_n \leq x) = P(\max \{X_1, \dots, X_n\} \leq x) = P(X_1 \leq x, \dots, X_n \leq x) = P(X_1 \leq x) \cdot \dots \cdot P(X_n \leq x) = [F(x)]^n, x \in \mathbb{R}$

Studujeme limitní rozdělení maxima M_n :

$$\lim_{n \rightarrow \infty} G_n(x) = \begin{cases} 0 & \dots x < X_F \\ 1 & \dots x \geq X_F \end{cases} \quad \text{, kde } X_F = \sup \{x \in \mathbb{R} : F(x) < 1\} \text{ je pravý koncový bod monotónní } F \text{ (může být } +\infty)$$

\Rightarrow limitní rozdělení M_n je degenerované v bodě X_F (případně $M_n \xrightarrow{P} \infty$ když $X_F = \infty$), $P(M = X_F) = 1$, $P(M = x) = 0$, jinak.

Centrální limitní věta (CLV)

X_1, \dots, X_n je náh. systém, označme $\mu = EX_i$ a $\sigma^2 = DX_i$

zkoumáme chození systémového průměru \bar{X} - jeho limitní rozdělení je degenerované v bodě μ ($\bar{X} \xrightarrow{P} \mu$).

$$\text{CLV: } \bar{X} \approx N\left(\mu, \frac{\sigma^2}{n}\right) \rightarrow \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \approx N(0, 1) \text{ tj. } P\left(\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq x\right) \xrightarrow{n \rightarrow \infty} \Phi(x), \forall x \in \mathbb{R}$$

\leftarrow distribuční funkce $N(0, 1)$

obecně: $P\left(\frac{\bar{X} - b_n}{a_n} \leq x\right) \xrightarrow{n \rightarrow \infty} \Phi(x)$, kde $\{b_n\}_{n=1}^{\infty}$ je posl. reálných čísel a $\{a_n\}_{n=1}^{\infty}$ posl. kladných čísel.

idea pro maxima:

Budeme hledat podobné normující konstanty $a_n > 0$ a $b_n \in \mathbb{R}$ tak, aby $\frac{M_n - b_n}{a_n}$ při $n \rightarrow \infty$ konvergovalo k nějakému nedegenerovanému rozdělení.
normované maximum

distribuční funkce normovaných maxim: $P\left(\frac{M_n - b_n}{a_n} \leq x\right) = P(M_n \leq a_n x + b_n) = G_n(a_n x + b_n) = [F(a_n x + b_n)]^n \xrightarrow[n \rightarrow \infty]{\text{chceme}} H(x), \forall x \in \mathbb{R}$
pro nějakou nedegenerovanou dist. fci H.

Průhled (maximum exponenciálního rozdělení)

X_1, \dots, X_n je máh. vztaž z $E_\lambda(1)$

$$f(x) = e^{-x}, x > 0$$

$$F(x) = 1 - e^{-x}, x > 0$$

$$a_n = 1$$

$$b_n = \log n$$

distr. fce normovaných maxim: $P\left(\frac{M_n - b_n}{a_n} \leq x\right) = [F(a_n x + b_n)]^n = \left[1 - e^{-(x + \log n)}\right]^n = \left[1 - e^{-x} \cdot e^{-\log n}\right]^n = \left(1 - \frac{e^{-x}}{n}\right)^n \xrightarrow{n \rightarrow \infty} e^{-x}, x \in \mathbb{R}$

*distribuční funkce
Gumbelova rozdělení*

Průhled (maximum Paretova rozdělení typu II - Lomax rozdělení)

X_1, \dots, X_n je máh. vztaž z Pareto (d, θ) , $d, \theta > 0$

$$f(x) = \frac{d}{\theta} \left(1 + \frac{x}{\theta}\right)^{-(d+1)}, x \geq 0$$

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

$$a_m = \frac{\sigma \cdot m^{\frac{1}{\alpha}}}{\alpha} \quad b_m = \sigma \cdot m^{\frac{1}{\alpha}} - \sigma$$


$$P\left(\frac{M_m - b_m}{a_m} \leq x\right) = [F(a_m x + b_m)]^m = \left[1 - \left(1 + \frac{\frac{\sigma \cdot m^{\frac{1}{\alpha}}}{\alpha} \cdot x + \sigma \cdot m^{\frac{1}{\alpha}} - \sigma}{\sigma}\right)^{-\alpha}\right]^m = \left[1 - \left(1 + m^{\frac{1}{\alpha}} \left(\frac{x}{\alpha} + 1\right)\right)^{-\alpha}\right]^m = \left[1 - \frac{1}{m} \left(1 + \frac{x}{\alpha}\right)^{-\alpha}\right]^m \xrightarrow{m \rightarrow \infty}$$

$e^{-\left(1 + \frac{x}{\alpha}\right)^{-\alpha}}$
 ℓ ... distribuční funkce Fréchetova rozdělení

Rozdělení extrémních hodnot

1) Gumbelovo rozdělení


$$G_0(x) = e^{-e^{-x}}, \quad x \in \mathbb{R}$$



$$g_0(x) = e^{-(x+e^{-x})}, \quad x \in \mathbb{R}$$

2) Fréchetovo rozdělení s parametrem tvaru $d > 0$

$$G_1(x) = e^{-x^{-d}}, \quad x \geq 0$$




$$g_1(x) = \frac{d}{x^{d+1}} \cdot e^{-x^{-d}}, \quad x > 0$$

3) Weibullovo rozdělení (extremální) s parametrem $d < 0$

$$G_2(x) = e^{-(-x)^{-d}}, \quad x \leq 0$$

$$g_2(x) = -d \cdot (-x)^{-d-1} \cdot e^{-(-x)^{-d}}, \quad x \leq 0$$



Předchozí 3 rozdělení jsou standardizovaná (mají parametr polohy rovnou 0 a parametr měřítky rovnou 1).

\Rightarrow přidání parametru polohy μ a parametru měřítky σ a dostaneme distribuční funkce:

$$G_{i,\mu,\sigma}(x) = G_i\left(\frac{x-\mu}{\sigma}\right) \quad \text{pro } i = 0, 1, 2$$

Poznámka

speciálně dostaneme: $G_{0,\mu,\sigma}(x) = e^{-\left(\frac{x-\mu}{\sigma}\right)^{-d}}$, $G_{1,\mu,\sigma}(x) = e^{-\left(\frac{x-\mu}{\sigma}\right)^{-d}}$, $G_{2,\mu,\sigma}(x) = e^{-\left(\frac{x-\mu}{\sigma}\right)^{-d}$.

Otázka: Nemohli bychom předchozí 3 distribuční funkce kapsat jedním vzorcem?

Obecnější rozdělení extrémních hodnot (GEV rozdělení)

ne standardizovaném tvaru: $G_\gamma(x) = \exp\left\{-\left(1+\gamma x\right)^{-\frac{1}{\gamma}}\right\}$, $1+\gamma x > 0$ ($\gamma \in \mathbb{R}$ parametr)

Poznámka

pro $\gamma = 0$ chápe se $G_\gamma(x)$ jako $\lim_{\gamma \rightarrow 0} G_\gamma(x) = e^{-x}$... Gumbelovo rozdělení

$\gamma > 0 \dots$ Fréchetovo rozdělení

$\gamma < 0 \dots$ Weibullovo rozdělení

úplnou třídu dostaneme opět přidáním parametrů μ a σ : $G_{\gamma, \mu, \sigma}(x) = \exp \left\{ - \left(1 + \frac{\gamma(x-\mu)}{\sigma} \right)^{-\frac{1}{\gamma}} \right\}$, $1 + \frac{\gamma(x-\mu)}{\sigma} > 0$.

Težka (Eisher - Sippell)

Necht X_1, \dots, X_n je náhodný vektor s distribuční funkcí F . Označme $M_n = \max \{X_1, \dots, X_n\}$. Necht existují posl. konstanty $a_n > 0$ a $b_n \in \mathbb{R}$ tak, že

$\lim_{n \rightarrow \infty} P \left(\frac{M_n - b_n}{a_n} \leq x \right) = H(x)$, $\forall x \in \mathbb{R}$ pro nějakou nedegenerovanou dist. fci H . Pak H je distribuční funkce GEV rozdělení.

Poznámky

- o podle předchozí věty je jediné možná limitní rozdělení GEV rozdělení \Rightarrow maxima budeme modelovat pomocí GEV rozdělení
- o jednoduše a_n, b_n ? Lze nalézt více postupností $\{a_n\}$ a $\{b_n\}$ tak, že $\frac{M_n - b_n}{a_n}$ konverguje. Výsledná limitní rozdělení se liší jen posunutím a měřítkem (parametry μ a σ).

Modelování: Necht ex. posl. a_n, b_n :

$$P \left(\frac{M_n - b_n}{a_n} \leq x \right) \rightarrow G_\gamma(x) \quad \rightsquigarrow \quad P(M_n \leq \underbrace{a_n x + b_n}_y) \xrightarrow{n \rightarrow \infty} G_\gamma(x)$$

pro n velké $P(M_n \leq y) \approx G_\gamma \left(\frac{y - b_n}{a_n} \right) = G_{\gamma, b_n, a_n}(y)$. \Rightarrow Maximum modelujeme pomocí GEV rozdělení se 3 parametry $\gamma, \mu, \sigma \Rightarrow$ by odhadneme 2 dal

Poznámky

γ -limitní předpokl. F-T. věty pro F , říká, že F patří do nějaké příslušné třídy dist. fci G_γ , přičemž $F \in \text{MDA}(G_\gamma)$ (maximum domain of attraction).

Podobně říká, že F patří do nějaké příslušné třídy Gumbelova, Fréchetova nebo Weibullova roz. (dají se odvodit pravidla, podle nichž zjistíme, které rozdělení to je).