

Stabilita maxim GEV rozdělení

X_1, \dots, X_n je náh. systém z Gumbelova rozdělení s parametry μ a σ .

$$F(x) = e^{-e^{-\frac{x-\mu}{\sigma}}}, \quad x \in \mathbb{R}$$

označíme $M_n = \max\{X_1, \dots, X_n\}$. Hledáme jeho distribuční funkci:

$$G_n(x) = [F(x)]^n = \left[e^{-e^{-\frac{x-\mu}{\sigma}}} \right]^n = e^{-n e^{-\frac{x-\mu}{\sigma}}} = e^{-e^{\log n} \cdot e^{-\frac{x-\mu}{\sigma}}} = e^{-e^{\log n - \frac{x-\mu}{\sigma}}} = e^{-e^{-\frac{x - (\mu + \log n)}{\sigma}}}, \quad x \in \mathbb{R}$$

distribuční funkce Gumbelova rozdělení s parametry $\mu^* = \mu + \log n$ a $\sigma^* = \sigma$.

Podobná vlastnost platí pro náh. systém z Fréchetova a Weibullova rozdělení, a tedy i pro GEV rozdělení. } max-stabilita

A oběcenně, toto jsou jediná rozdělení, pro která tato vlastnost platí

Metoda blokových maxim při praktickém zpracování dat

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

Předpokládáme, že F patří do sféry příslušnosti GEV rozdělení (tj. jsou splněny předpoklady Fisherova-Tippettovy věty).

Data rozdělíme do m bloků o velikosti n ($N = m \cdot n$) a v každém bloku určíme příslušné blokové maximum $M_i = M_n^{(i)}$.

Tedy místo původního náh. systému X_1, \dots, X_N uvažujeme m blokových maxim M_1, \dots, M_m (nezávislé, stejné rozdělení) a ty budeme modelovat.

Pro další účely nelze dělat bloky n můžeme rozdělení blokových maxim modelovat pomocí GEV rozdělení.

$\Rightarrow M_1, \dots, M_m$ poradiáno na náh. sŕetí z GEV rozdelemí s parametroy γ, μ a σ . A by budeme ďale odhadovat.

Overánka

Jež volit delku bloku?

- jean-li data se ľavé částeí řády, pak se hlody volí "přirozené" (měříc, rok, apod.)
- delka bloku m musí bý dostatečnĕ velká, aby "zafungovala" Eisteon-Tippellon věta
- počet bloku m musí bý také velká, abychom měli dostateč dat k odhadum parametrů GEV rozdelemí

metoda maximálnĕ věřehodnoty:

model: M_1, \dots, M_m náh. sŕetí z GEV rozdelemí s distribučnĕ funkčĕ $G_{\gamma, \mu, \sigma}(x) = \exp \left\{ - \left(1 + \frac{x - \mu}{\sigma} \right)^{\frac{1}{\gamma}} \right\}$, pro $1 + \frac{x - \mu}{\sigma} > 0$.

hustota g

$$g_{\gamma, \mu, \sigma}(x) = \exp \left\{ - \left(1 + \frac{x - \mu}{\sigma} \right)^{\frac{1}{\gamma}} \right\} \cdot (-1) \cdot \left(-\frac{1}{\gamma} \right) \cdot \left(1 + \frac{x - \mu}{\sigma} \right)^{\frac{1}{\gamma} - 1} \cdot \frac{1}{\sigma} = \exp \left\{ - \left(1 + \frac{x - \mu}{\sigma} \right)^{\frac{1}{\gamma}} \right\} \cdot \frac{1}{\sigma} \cdot \left(1 + \frac{x - \mu}{\sigma} \right)^{\frac{1}{\gamma} - 1}, \text{ pro } 1 + \frac{x - \mu}{\sigma} > 0.$$

$$\log g_{\gamma, \mu, \sigma}(x) = -\log \sigma - \left(1 + \frac{1}{\gamma} \right) \cdot \log \left(1 + \frac{x - \mu}{\sigma} \right) - \left(1 + \frac{x - \mu}{\sigma} \right)^{\frac{1}{\gamma} - 1}.$$

logaritmická věřehodnotnĕ funkce. $l(\gamma, \mu, \sigma) = \sum_{i=1}^m \log g_{\gamma, \mu, \sigma}(M_i) = -m \cdot \log \sigma - \left(1 + \frac{1}{\gamma} \right) \sum_{i=1}^m \log \left(1 + \frac{M_i - \mu}{\sigma} \right) - \sum_{i=1}^m \left(1 + \frac{M_i - \mu}{\sigma} \right)^{\frac{1}{\gamma} - 1}$

pro $1 + \frac{\gamma(M_i - \mu)}{\sigma} > 0 \quad \forall i=1, \dots, m$.

Logaritmickou věrohodnostní funkci maximalizujeme přes všechny hodnoty $\sigma > 0, \mu$ a σ takové, že $1 + \frac{\gamma(M_1 - \mu)}{\sigma} > 0, \dots, 1 + \frac{\gamma(M_m - \mu)}{\sigma} > 0$.

$l(\gamma, \mu, \sigma)$ má diferenciální, tedy je třeba provést maximalizaci přímo \Rightarrow maximálně věrohodný odhad $(\hat{\gamma}, \hat{\mu}, \hat{\sigma})^T$.

Navic, nejsou splněny podmínky regularity pro odvození asymptotických vlastností.

Poznámka

U libovolné γ pro $\gamma > -\frac{1}{2}$ dokázáno, že $\hat{\Theta} = (\hat{\gamma}, \hat{\mu}, \hat{\sigma})^T$ je asymptoticky normální, konzistentní odhad parametru $\Theta = (\gamma, \mu, \sigma)^T$.

Navic $\hat{\Theta} \approx N_3(\Theta, \frac{1}{m} \cdot \bar{J}^{-1}(\Theta)) \dots \Rightarrow$ můžeme konstruovat IS pro γ, μ a σ .

γ -li - $1 < \gamma \leq -0,5$, pač maximálně věrohodné odhady existují, ale nemají „hezké“ vlastnosti.

Pro $\gamma \leq -1$ MLE obvykle neexistují.

metoda pravděpodobnostně vážených momentů (PWM)

Definice

Necht X je náh. veličina s distribuční funkcí F . Pak čísla $M_{P,R,D} = E[X^P [F(X)]^R \cdot [1-F(X)]^D]$ pro $P, R, D \in \mathbb{R}$.

jsou pravděpodobnostně vážené momenty.

speciální případ: $p=1, \sigma=0$

$$\beta_r = M_{1,r,0} = E[X \cdot [F(X)]^r] \quad \text{pro } r=0, 1, 2.$$

$$\text{pro GEV rozdělení platí: } \beta_r = \frac{1}{r+1} \left\{ \mu - \frac{\sigma}{\gamma^r} [1 - (r+1)^{\gamma^r} \Gamma(1-\gamma^r)] \right\} \quad \text{pro } \gamma^r < 1, \gamma^r \neq 0.$$

$$\text{odhad } \beta_r \text{ } \hat{\beta}_r = \frac{1}{m} \sum_{j=1}^m \binom{r}{l=1}^{j-l} \cdot M_{l,j} \quad \text{pro } r=1, 2 \quad \text{a } \hat{\beta}_0 = \frac{1}{m} \sum_{j=1}^m M_{j,j}.$$

Odhady $(\gamma, \mu, \sigma)^T$ získáme jako řešení soustavy $\beta_r = \hat{\beta}_r$ pro $r=0, 1, 2$.

Úlohy

1.) Odhadnout $P(X_i > x)$ pro x velké

$$M_1 = \max \{X_1, \dots, X_m\}$$

$$P(M_1 \leq x) = [P(X_i \leq x)]^m = [1 - P(X_i > x)]^m \quad \left\{ \Rightarrow P(X_i > x) = 1 - [G_{\gamma, \mu, \sigma}(x)]^{\frac{1}{m}} \right.$$

$G_{\gamma, \mu, \sigma}(x)$

$$\widehat{P}(X_i > x) = 1 - \left[G_{\hat{\mu}, \hat{\sigma}}(x) \right]^{\frac{1}{n}} = 1 - \left[\exp \left\{ - \left(1 + \frac{\hat{\mu}(x - \hat{\mu})}{\hat{\sigma}} \right)^{-\frac{1}{\hat{\beta}}} \right\} \right]^{\frac{1}{n}} = 1 - \exp \left\{ - \frac{1}{n} \left(1 + \frac{\hat{\mu}(x - \hat{\mu})}{\hat{\sigma}} \right)^{-\frac{1}{\hat{\beta}}} \right\}$$

uvážeme-li aproximační $z = 1 + z$ (pač $\widehat{P}(X_i > x) = \frac{1}{n} \left(1 + \frac{\hat{\mu}(x - \hat{\mu})}{\hat{\sigma}} \right)^{-\frac{1}{\hat{\beta}}}$).

2) Odhad extrémních kvantilů

chápeme-li data jako časovou řadu, pak chceme odhadnout velikost extrémního jevu, který bude nastat v průměru se zvolenou frekvencí (úroveň návratu), tj. 1x za k časových

skamienku, tedy hledáme $(1 - \frac{1}{k})$ -kvantil příslušného GEV rozdělení, označme jej $q_{1-\frac{1}{k}}$.

$$\text{Tedy platí } P(M_1 \leq q_{1-\frac{1}{k}}) = 1 - \frac{1}{k} \Leftrightarrow P(M_1 > \underline{q_{1-\frac{1}{k}}}) = \frac{1}{k}$$

hledání úrovně návratu

pro přehlednost označme $q := q_{1-\frac{1}{k}}$.

$$1 - G_{\hat{\mu}, \hat{\sigma}}(q) = \frac{1}{k}$$

$$1 - \exp \left\{ - \left(1 + \frac{\hat{\mu}(q - \hat{\mu})}{\hat{\sigma}} \right)^{-\frac{1}{\hat{\beta}}} \right\} = \frac{1}{k}$$

$$- \left(1 + \frac{\hat{\mu}(q - \hat{\mu})}{\hat{\sigma}} \right)^{-\frac{1}{\hat{\beta}}} = \log \left(1 - \frac{1}{k} \right)$$

$$1 + \frac{y(q-\mu)}{\sigma} = \left[-\log\left(1 - \frac{1}{z}\right) \right]^{-y}$$

$$q = \frac{\sigma}{y} \left\{ \left[-\log\left(1 - \frac{1}{z}\right) \right]^{-y} - 1 \right\} + \mu$$

odhad úrovně nárazu získáme dosazením odhadů parametrů: $\hat{q} = \hat{q}_{1-\frac{1}{z}} = \frac{\hat{\sigma}}{\hat{y}} \left\{ \left[-\log\left(1 - \frac{1}{z}\right) \right]^{-\hat{y}} - 1 \right\} + \hat{\mu}$.

3) Stanovit průměrnou frekvenci výskytu extrémního jevu dané úrovně (dobu nárazu)

- známá úroveň $q_{1-\frac{1}{z}}$ a hledáme příslušné k .

$$P(M_1 > q_{1-\frac{1}{z}}) = \frac{1}{z} \Rightarrow k = \frac{1}{1 - G_{y, \mu, \sigma}(q_{1-\frac{1}{z}})}$$

„

$$1 - G_{y, \mu, \sigma}(q_{1-\frac{1}{z}})$$

odhad doby nárazu získáme opět dosazením odhadů: $\hat{k} = \frac{1}{1 - G_{\hat{y}, \hat{\mu}, \hat{\sigma}}(q_{1-\frac{1}{z}})} = \frac{1}{1 - \exp \left\{ - \left(1 + \frac{\hat{\sigma}(q_{1-\frac{1}{z}} - \hat{\mu})}{\hat{\sigma}} \right)^{-\frac{1}{\hat{y}}} \right\}}$.