


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

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



$$Y_i = X_i - u, \text{ pro } X_i > u \dots \text{ výše překročení meze (práhu) } u \text{ (exces)}$$


pro $i = 1, 2, \dots, N_u$ $N_u = \text{počet } X_i \text{ které překročí hranici } u$

Hledáme distribuční funkci excesu Y_i . Označme ji $F_u(x) = P(Y_i \leq x) = P(X_i - u \leq x | X_i > u) = P(X_i \leq u + x | X_i > u) = \frac{P(u < X_i \leq u + x)}{P(X_i > u)} = \frac{F(u+x) - F(u)}{1 - F(u)}, x \geq 0.$

Rozdělení pro modelování excesu


1) Exponenciální rozdělení

$$W_0(x) = 1 - e^{-x}, x \geq 0$$




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

$$W_1(x) = 1 - x^{-d}, x \geq 1$$



3) Beta rozdělení s parametrem tvaru $d < 0$

$$W_2(x) = 1 - (-x)^{-d}, -1 \leq x \leq 0$$



Opět můžeme přidat parametr polohy μ a parametr měřítko σ :

$$W_{i,\mu,\sigma}(x) = W_i\left(\frac{x-\mu}{\sigma}\right), \text{ pro } i=0,1,2.$$

Účelem 3 distribuční funkce můžeme kapitol pomocí jednotného rozdělení:

Obecné Pareto rozdělení (GPD)

$$W_{\eta}(x) = 1 - (1 + \eta x)^{-\frac{1}{\eta}}, \quad \eta \in \mathbb{R} \text{ parametr}$$

Poznámka

pro $\eta = 0$ chápeme $W_{\eta}(x)$ jako $\lim_{\eta \rightarrow 0} W_{\eta}(x) = 1 - e^{-x}$, $x > 0$... exponenciální rozdělení

$\eta > 0$... Pareto rozdělení, $x \geq 0$.

$\eta < 0$... Beta rozdělení, $0 \leq x \leq -\frac{1}{\eta}$.

Úplnou třídu dostaneme přidáním parametru měřítko σ : $W_{\eta,\sigma}(x) = 1 - \left(1 + \frac{\eta}{\sigma} x\right)^{-\frac{1}{\eta}}$.

Poznámka

Obecné modely jsou všechny, které jsou nezáporné, parametr polohy $\mu = 0$.

Věta (Balkema, de Haan, Pickands)

Nechť X_1, \dots, X_n je náh. vektor s distribuční funkcí F . Necht existují posoupnosti konstant $a_n > 0$ a $b_n \in \mathbb{R}$ tak, že $F_{a_n}(a_n x + b_n) \xrightarrow{\mu_n \uparrow x_F} H(x)$ pro nějakou spojitou distribuční funkci H a $x_F = \sup \{x: F(x) < 1\}$ je pravý koncový bod množiny F , pak H je distribuční funkcí kolektivního Paretova rozdělení.

Poznámka

- podle předchozí věty je jediné možné limitní rozdělení excerní GPD rozdělení
- excerní $Y_n = X_n - \mu$ pro $X_n > a$ budeme modelovat pomocí GPD rozdělení s distribuční funkcí $W_{\gamma, \sigma}(x)$. Jeho parametry γ a σ odhadneme z dat.

Věta

Distribuční funkce $F \in \text{MDA}(G_\gamma) \Leftrightarrow$ existuje kladná funkce $\beta(u)$ tak, že $\lim_{\mu \uparrow x_F} \sup_{0 < x < x_F - \mu} |F_\mu(x) - W_{\gamma, \beta(u)}(x)| = 0$.

Poznámka

Rozdělení, která normovaná maxima konvergují k GEV rozdělení jsou stejná jako rozdělení, pro která rozdělení excerní konvergují k GPD rozdělení ($W_\gamma(x) = 1 + \log G_\gamma(x)$).

Namísto, parametry γ je v obou případech stejný (a nezávisí na μ).

Stabilita excerní GPD rozdělení

Nechť X_1, \dots, X_n je náh. vektor se kolektivního Paretova rozdělení s parametry γ a σ .

$$W_{\gamma, \sigma}(x) = 1 - \left(1 + \frac{\gamma}{\sigma} x\right)^{-\frac{1}{\gamma}}$$

distribuční funkce excen^o Y_i je $F_u(y) = \frac{F(u+y) - F(u)}{1 - F(u)} = \frac{\left(1 + \frac{y}{\sigma} u\right)^{-\frac{1}{\beta}} - \left(1 + \frac{y}{\sigma} u\right)^{-\frac{1}{\beta}}}{\left(1 + \frac{y}{\sigma} u\right)^{-\frac{1}{\beta}}} = 1 - \left[\frac{1 + \frac{y}{\sigma}(u+y)}{1 + \frac{y}{\sigma} u}\right]^{-\frac{1}{\beta}} = 1 - \left[\frac{\sigma + y(u+y)}{\sigma + y u}\right]^{-\frac{1}{\beta}} =$

$= 1 - \left(1 + \frac{y u}{\sigma + y u}\right)^{-\frac{1}{\beta}} = W_{\beta, \sigma + y u}(y)$... distribuční funkce zob. Pareto rozdělení s parametry β a $\sigma + y u$.

A dále, zobecnění Pareto rozdělení je jediné spojité rozdělení s touto vlastností.

Metoda POT při praktickém zpracování dat

X_1, \dots, X_n náh. vzty s distribuční funkcí F

Budeme předpokládat, že pro F jsou splněny předpoklady Balk. - de Skramosy - Lidkandrosy sítě

volíme hranici u a definujeme excen^o $Y_i = X_i - u$ pro $X_i > u$ pro $i = 1, 2, \dots, N_u$ (N_u je počet excen^o)

Y_1, \dots, Y_{N_u} poskládáme ka náh. vzty z GPD rozdělení s parametry β a σ . A ty budeme dále odhadovat.

metoda maximální věrohodnosti:

$W_{\beta, \sigma}(x) = 1 - \left(1 + \frac{\beta}{\sigma} x\right)^{-\frac{1}{\beta}}$

hustota je

$M_{\beta, \sigma}(x) = \frac{1}{\beta} \left(1 + \frac{\beta}{\sigma} x\right)^{-\frac{1}{\beta} - 1} \cdot \frac{\beta}{\sigma} = \frac{1}{\sigma} \left(1 + \frac{\beta}{\sigma} x\right)^{-(1 + \frac{1}{\beta})}$

$\log M_{\beta, \sigma}(x) = -\log \sigma - \left(1 + \frac{1}{\beta}\right) \log \left(1 + \frac{\beta}{\sigma} x\right)$

logaritmická věrohodnostní funkce: $l(\eta, \sigma) = \sum_{i=1}^{Nu} \log w_{\eta, \sigma}(Y_i) = -Nu \log \sigma - \left(1 + \frac{1}{\eta}\right) \sum_{i=1}^{Nu} \log \left(1 + \frac{Y_i}{\sigma}\right).$

Osobní

$l(\eta, \sigma)$ se maximalizuje přímo \Rightarrow maximální věrohodný odhad $(\hat{\eta}, \hat{\sigma})^T$.

pro $\eta > \frac{1}{2}$ je dokázáno jejich asymptotická nekorelace, konzistence a as. normalita.

metoda pravděpodobnostně vážených momentů (PWM)

připomeneme, že má-li n.v. X d.f. F definujeme $M_{P, r, D} = E[X^P [F(X)]^r [1-F(X)]^D]$ pro $P, r, D \in \mathbb{R}$ pravděpodobnostně vážené momenty.

speciální případ: $P=1, r=0$

$$d_D = M_{1,0,D} = E[X \cdot [1-F(X)]^D] \text{ pro } D=0,1$$

pro GPD je $d_D = \frac{\sigma}{(D-\eta+1)(D+1)}$.

odhad d_D je $\hat{d}_D = \frac{1}{Nu} \sum_{j=1}^{Nu} \left(\prod_{k=1}^D \frac{Nu-j-k+1}{Nu-k} \right) Y_{(j)}$ pro $D=0,1$.

Odhad $(\eta, \sigma)^T$ získáme řešením soustavy $d_D = \hat{d}_D$ pro $D=0,1$.

Úkol

1) Odhadnout $P(X_i > x)$ pro x velké

$$\text{pro } x \geq \mu \text{ platí } P(X_i > x | X_i > \mu) = \frac{P(X_i > x)}{P(X_i > \mu)} \Rightarrow$$

$$P(X_i > x) = P(X_i > \mu) \cdot P(X_i > x | X_i > \mu) = P(X_i > \mu) \cdot \underbrace{1 - P(X_i \leq x - \mu | X_i > \mu)}_{1 - F_{\mu, \sigma}(x - \mu)} = P(X_i > \mu) \cdot (1 - F_{\mu, \sigma}(x - \mu)) =$$

$$P(X_i > \mu) \cdot \left(1 + \frac{\gamma(x - \mu)}{\sigma}\right)^{-\frac{1}{\gamma}}$$

$$\widehat{P(X_i > x)} = \frac{N_{\mu}}{n} \cdot \left(1 + \frac{\hat{\gamma}(x - \mu)}{\hat{\sigma}}\right)^{-\frac{1}{\hat{\gamma}}} \quad \text{pro } x \geq \mu$$

2) Úloha náročná - extrémní jevy, který nastane v průměrně jednom ze k pozorování

hledáme $(1 - \frac{1}{k})$ -kvantil rozdělení n.v. X_i , označme jej $q = q_{1 - \frac{1}{k}}$

$$P(X_i > q) = \frac{1}{k}$$

$$P(X_i > \mu) \cdot \left(1 + \frac{\gamma(q - \mu)}{\sigma}\right)^{-\frac{1}{\gamma}} = \frac{1}{k} \quad \dots \quad \leadsto q = \mu + \frac{\sigma}{\gamma} \left[\left[k \cdot P(X_i > \mu) \right]^{\gamma} - 1 \right]$$

tedy odhad úrovně mávraku je $\hat{q}_j = \hat{q}_{1-\frac{1}{j}} = u + \frac{\hat{\sigma}}{j^k} \left[\left(\frac{k \cdot Nu}{m} \right)^{\frac{1}{j}} - 1 \right]$.

3) Doba mávraku

známe hodnotu $q_{1-\frac{1}{j}}$ a hledáme příslušný k

$$k = \frac{1}{P(X_i > u) \cdot \left(1 + \frac{j(q-u)}{\sigma}\right)^{-\frac{1}{j}}} = \frac{\left(1 + \frac{j(q-u)}{\sigma}\right)^{\frac{1}{j}}}{P(X_i > u)}$$

$$\text{odhad } \Rightarrow \hat{k} = \frac{m \left(1 + \frac{j(q-u)}{\sigma}\right)^{\frac{1}{j}}}{Nu}$$

jak volit velikost prahu u ?

- hodnota prahu u musí být dostatečně vysoká, aby „zapůsobila“ aproximací GPD rozdělením
- příliš vysoká hodnota prahu u však znamená nedostatečný počet pozorování Nu pro odhady parametrů GPD rozdělení

mean excess plot

definujeme střední hodnotu velikosti překročení prahu u (za podmínky, že k překročení došlo): mean excess: $e(u) = E(X_i - u | X_i > u)$.

Oceňování

Má-li m.v. Z skutečně Paretoovo rozdělení s parametry γ a σ , pak $EZ = \frac{\sigma}{1-\gamma}$.

γ -li X_1, \dots, X_m má náh. systém z GPD rozdělení s parametry γ a σ , pak $X_i - u | X_i > u$ má GPD rozdělení s parametry γ a $\sigma + \gamma \cdot u \Rightarrow e(u) = \frac{\sigma + \gamma u}{1-\gamma}$.

$\ell(u)$ je v tomto prípade lineárna funkcia v u . To je charakteristická vlastnosť GPD rozdelení.

Keď máme data, teda odhadneme funkciu $\ell(u)$. Použijeme empirický odhad $\widehat{\ell}(u) = \frac{\sum_{i=1}^{N_u} Y_i}{N_u}$, kde $Y_i = X_i - u$ pre $X_i > u$ $i = 1, \dots, N_u$.

prímer u ovni

Ma zároveň vykreslíme do grafu body $\{X_{(i)}, \widehat{\ell}(X_{(i)})\}$, $i = 2, 3, \dots, m$.

Podľa pozorovaní pochádzajúcich z GPD rozdelení, paž graf vykazuje lineárny trend.

Graf u máme teda jako bod z grafu, kde začínal "začína" byť lineárny.

Oceňovacia

V praxi číselne nepoužívateľné.

Graf u sa preto často volá jako graf empirického kvantilu väčších dát, napr. 96%.