

3.) Kopuly extrémních hodnot

Příklad (motivace)

Nechť $(X_1, Y_1)^T, \dots, (X_m, Y_m)^T$ je máh. vzájemně nezávislého rozdělení se sdruženou distribuční funkcí $F(x, y)$ a marginálními dist. funkcemi $F_1(x)$ a $F_2(y)$.

$$\text{označíme } M_n^x = \max \{X_1, \dots, X_m\} \dots F_1^{\wedge n}(x)$$

$$M_n^y = \max \{Y_1, \dots, Y_m\} \dots F_2^{\wedge n}(y)$$

$$\text{Gelar} \rightarrow F(x, y) = C(F_1(x), F_2(y))$$

jak vypadá sdružená distribuční funkce $(M_n^x, M_n^y)^T$?

$$F^{\wedge n}(x, y) = P(M_n^x \leq x, M_n^y \leq y) = P(X_1 \leq x, \dots, X_m \leq x, Y_1 \leq y, \dots, Y_m \leq y) = P((X_1, Y_1)^T \leq (x, y)^T, \dots, (X_m, Y_m)^T \leq (x, y)^T) = P((X_i, Y_i)^T \leq (x, y)^T)^m = F^{\wedge n}(x, y)$$

$$\tilde{C}(F_1^{\wedge n}(x), F_2^{\wedge n}(y))$$

$$C^{\wedge n}(F_1(x), F_2(y))$$

$$\tilde{C}(F_1^{\wedge n}(x), F_2^{\wedge n}(y)) = C^{\wedge n}(F_1(x), F_2(y)) = C^{\wedge n}((F_1(x))^{\hat{\wedge}}, (F_2(y))^{\hat{\wedge}})$$

$$\tilde{C}(u, v) = C(u^{\hat{\wedge}}, v^{\hat{\wedge}})$$

$$\underline{\tilde{C}(u^{\wedge}, v^{\wedge}) = C(u, v)}$$

Kopula extrémních hodnot je taková kopula, pro kterou platí $C(u^{\wedge}, v^{\wedge}) = C(u, v)$, $\forall u \in [0, 1], v \in [0, 1]$ a $\forall m = 1, 2, \dots$ (max-stabilita).

Boenimla

Üe d hoi vlatnol riika, ee kopula püinlunio $(M_m^x, M_m^y)^T$ jü lejivä jato $u (X_i, Y_i)^T$.

a) Gumbelova kopula

$$C(u, v) = \exp \left\{ - \left[(-\log u)^\sigma + (-\log v)^\sigma \right]^{\frac{1}{\sigma}} \right\}, \text{ kedo } \sigma \geq 1 \text{ jü parametru.}$$

$$\begin{aligned} C(u^m, v^m) &= \exp \left\{ - \left[\overbrace{(-\log u^m)^\sigma}^{-m \log u} + \overbrace{(-\log v^m)^\sigma}^{-m \log v} \right]^{\frac{1}{\sigma}} \right\} = \exp \left\{ - \left[m^\sigma (-\log u)^\sigma + m^\sigma (-\log v)^\sigma \right]^{\frac{1}{\sigma}} \right\} \\ &= \exp \left\{ - m \left[(-\log u)^\sigma + (-\log v)^\sigma \right]^{\frac{1}{\sigma}} \right\} = \exp \left\{ - \left[(-\log u)^\sigma + (-\log v)^\sigma \right]^{\frac{1}{\sigma}} \right\} \\ &= C^m(u, v). \end{aligned}$$

b) Galambrova kopula

$$C(u, v) = u \cdot v \cdot \exp \left\{ \left[(-\log u)^{-\sigma} + (-\log v)^{-\sigma} \right]^{\frac{1}{\sigma}} \right\}, \quad \sigma > 0 \text{ parametru.}$$

c) Taurnova kopula

$$C(u, v) = u^{1-d} \cdot v^{1-\beta} \cdot \exp \left\{ - \left[(-d \log u)^\sigma + (-\beta \log v)^\sigma \right]^{\frac{1}{\sigma}} \right\}, \quad \sigma \geq 1, 0 \leq d \leq 1, 0 \leq \beta \leq 1 \text{ jion parametru.}$$

Jak generovat náhodné veličiny (jejich realizace) z daného rozdělení?

• 1D případ

předpokládáme, že umíme generovat z $Rs(0,1)$.

- zaměňovací metoda

- metoda inverzní transformace - chceme generovat realizaci n.v. X s distribuční funkcí F

platí: $U \sim Rs(0,1)$, pak $F^{-1}(U) \sim$ rozdělení s distribuční funkcí F

nejprve generujeme realizaci n.v. z $Rs(0,1)$, označíme ji u , pak $F^{-1}(u)$ je realizace n.v. X .

• 2D případ

mezi náh. velič. $(U, V)^T$ má kopulu $C(u, v)$, $U \sim Rs(0,1)$ a $V \sim Rs(0,1)$. Pokud C je absolutně spojitá

$c(u, v) = \frac{\partial^2 C(u, v)}{\partial u \partial v}$ je hustota kopuly.

Hustota n.v. $U|V=v$ je $c(u|v) = \frac{c(u, v)}{\underbrace{c(v)}_{=1}} = c(u, v)$, tj. funkce $c(\cdot, v)$, neboli $u \mapsto c(u, v)$. A podobně

Hustota n.v. $V|U=u$ je $c(v|u) = \frac{c(u, v)}{\underbrace{c(u)}_{=1}} = c(u, v)$, tj. funkce $c(u, \cdot)$, neboli $v \mapsto c(u, v)$.

distribuční funkce n.o. $V|U=\mu$ je $\sigma \mapsto \frac{\partial C(\mu, \sigma)}{\partial \mu}$.

distribuční funkce n.o. $V|U=\mu$

$$\frac{\partial C(\mu, \sigma)}{\partial \mu} = \frac{\partial}{\partial \mu} \int_0^\sigma \left(\int_0^\mu c(s, t) dt \right) ds = \int_0^\sigma \left(\frac{\partial}{\partial \mu} \int_0^\mu c(s, t) ds \right) dt = \int_0^\sigma c(\mu, t) dt = P(V \leq \sigma | U = \mu) = F_{V|U=\mu}(\sigma) \dots \text{distribuční funkce n.o. } V|U=\mu.$$

podobně distribuční funkce n.o. $U|V=\sigma$ je $\mu \mapsto \frac{\partial C(\mu, \sigma)}{\partial \sigma}$.

Máme chem generoval realizaci náh. vektoru $(X, Y)^T$ s distribuční funkcí $F(x, y)$, označ mey. dsh. je $F_1(x)$ a $F_2(y)$

Uplat $F(x, y) = C(F_1^{-1}(x), F_2^{-1}(y))$, ozn. $F_1(x) = \mu, F_2(y) = \sigma$

$$C(\mu, \sigma) = F(F_1^{-1}(\mu), F_2^{-1}(\sigma))$$

(i) generujeme realizaci n.o. $U \in \mathcal{R}_s(0, 1)$, označme ji μ .

(ii) generujeme realizaci n.o. $V \in$ podmíněného rozdělení $V|U=\mu$ s distribuční funkcí $\frac{\partial C(\mu, \sigma)}{\partial \mu}$, označme ji σ .

Tedy (μ, σ) je realizace kopuly C

(iii) hledáme realizaci (x, y) dotaneme aplikací kvantilových funkcí: $(x, y)^T = (F_1^{-1}(\mu), F_2^{-1}(\sigma))^T$.

Modelování dvourozměrných dat

$(X_1, Y_1)^T, \dots, (X_m, Y_m)^T$ je náh. vzorek z dvourozměrného rozložení nezávislých dim. $f_1(x, y)$ a marginální $F_1(x)$ a $F_2(y)$.

Model: $F(x, y) = C(F_1(x), F_2(y))$

parametrický přístup

- modelujeme marginální distrib. $F_1(x)$ a $F_2(y)$ \rightarrow přidáme měrné parametry $\rightarrow F_1(x, \theta_1), F_2(y, \theta_2)$, θ_1 a θ_2 jsou měrné parametry

- zvolíme vhodnou kopulu C , upravíme její parametry jako $\theta_3 \rightarrow C_{\theta_3}(u, v)$.

$$F(x, y) = C_{\theta_3}(F_1(x, \theta_1), F_2(y, \theta_2)), \text{ kde } \theta = (\theta_1^T, \theta_2^T, \theta_3^T)^T \text{ je vektor měrných parametrů.}$$

$$f(x, y) = \frac{\partial^2 F(x, y)}{\partial x \partial y} = c_{\theta_3}(F_1(x, \theta_1), F_2(y, \theta_2)) \cdot f_1(x, \theta_1) \cdot f_2(y, \theta_2)$$

kde $f_1(x, \theta_1)$ a $f_2(y, \theta_2)$ jsou marginální hustoty a $c(u, v) = \frac{\partial^2 C(u, v)}{\partial u \partial v}$ je hustota kopuly.

$$\text{logaritmičtá věhodnostní funkce: } l(\theta) = \sum_{i=1}^m \log f(X_i, Y_i) = \underbrace{\sum_{i=1}^m \log f_1(X_i, \theta_1)}_{l_1(\theta_1)} + \underbrace{\sum_{i=1}^m \log f_2(Y_i, \theta_2)}_{l_2(\theta_2)} + \underbrace{\sum_{i=1}^m \log c_{\theta_3}(F_1(X_i, \theta_1), F_2(Y_i, \theta_2))}_{l_3(\theta_1, \theta_2, \theta_3)}$$

maximální věrohodný odhad parametrů Θ je $\hat{\Theta} = \underset{\Theta}{\operatorname{argmax}} l(\Theta)$.

Předpoklady

podmínky regularity \rightarrow as. nekorelovanost, konzistence a as. normalita $\hat{\Theta}$.

výpočet náročný a nestabilní (dimenze Θ může být velká) \rightarrow modifikace metody.

pseudo-maximální věrohodný odhad (IFM = inference pro marginální rozdělení)

• nejprve odhadneme parametry marg. rozdělení: $\hat{\Theta}_1 = \underset{\Theta_1}{\operatorname{argmax}} l_1(\Theta_1)$ a $\hat{\Theta}_2 = \underset{\Theta_2}{\operatorname{argmax}} l_2(\Theta_2)$.

• Co by bylo prové hodnoty $\hat{\Theta}_1$ a $\hat{\Theta}_2$ maximalizujeme $l_3(\hat{\Theta}_1, \hat{\Theta}_2, \Theta_3)$: $\hat{\Theta}_3 = \underset{\Theta_3}{\operatorname{argmax}} l_3(\hat{\Theta}_1, \hat{\Theta}_2, \Theta_3)$.

• Výsledný odhad parametrů Θ je: $\hat{\Theta} = (\hat{\Theta}_1^T, \hat{\Theta}_2^T, \hat{\Theta}_3^T)^T$.

semiparametrický přístup

- semiparametrický odhad pomocí marginálního rozdělení pomocí empirické distribuční funkce: $\hat{F}_1(x) = \frac{1}{m+1} \sum_{i=1}^m \mathbb{1}\{X_i \leq x\}$, $\hat{F}_2(y) = \frac{1}{m+1} \sum_{i=1}^m \mathbb{1}\{Y_i \leq y\}$

- kopula C modelujeme parametricky $C(u, v) = C_{\Theta_3}(u, v)$. Parametry Θ_3 odhadneme pomocí metody max. věrohodnosti:

$$\hat{\Theta}_3 = \underset{\Theta_3}{\operatorname{argmax}} \sum_{i=1}^m \log C_{\Theta_3}(\hat{F}_1(x_i), \hat{F}_2(y_i))$$

transformace $(X_1, Y_1)^T, \dots, (X_m, Y_m)^T \rightsquigarrow (U_1, V_1)^T, \dots, (U_m, V_m)^T$

$U_i = \frac{R_i}{m+1}$ (R_i je pořadí X_i mezi X₁, ..., X_m.)

$V_i = \frac{S_i}{m+1}$ (S_i je pořadí Y_i mezi Y₁, ..., Y_m.)

Poznámka

Řešící metoda bývá označována CML - kanonická metoda maximální věrohodnosti

Pro Θ_3 jednorozměrný parametr lze pro jeho odhad použít následující postup založený na odhadu Kendallova τ .

Mínus jím odvodili, že pro některé kopule umíme vyjádřit $\tau = f(\Theta_3)$ jako nějakou funkci neznámého parametru.

$$\text{Z dal odhadneme Kendallova } \tau \text{ jako } \hat{\tau} = \frac{\sum_{i \neq j} \text{sign}(X_i - X_j) \cdot \text{sign}(Y_i - Y_j)}{n(n-1)} = \frac{2(a-b)}{n(n-1)}$$

a... počet koncordantních párů $(x_i, y_i), (x_j, y_j)$
b... počet diskordantních párů $(x_i, y_i), (x_j, y_j)$

$\hat{\Theta}_3$ jako odhad Θ_3 řeší rovnici $\hat{\tau} = f(\hat{\Theta}_3)$.

Příklad

Gumbelova kopule s parametrem $\Theta \geq 1$

$$\tau = 1 - \frac{1}{\Theta} \Rightarrow \Theta = \frac{1}{1-\tau} \rightarrow \hat{\Theta} = \frac{1}{1-\hat{\tau}} \quad (\text{pro } \hat{\tau} \geq 0)$$

Poznámka

Podobně můžeme definovat p -rozměrnou kopuli pro p -rozměrné náh. vektory.

Jak zvlášť vhodnou kopuli? Maximální věrohodnosti, jiný penalizační kritéria.