

# M7988 Modely ztrát v neživotním pojištění

# Parametrický model a úlohy matematické statistiky

**Model:**  $X_1, \dots, X_n$  je náhodný výběr z rozdělení s distribuční funkcí  $F(x, \theta)$ . Tuto distribuční funkci známe až na neznámý parametr  $\theta \in \Theta \subset \mathbb{R}^P$ .

Úlohy matematické statistiky:

- Bodový odhad parametru  $\theta$ .
- Intervalový odhad parametru  $\theta$ .
- Testy hypotéz o parametru  $\theta$ .

Někdy nás místo samotného parametru  $\theta$  zajímá nějaká jeho funkce, tzv. *parametrická funkce*  $\gamma(\theta)$ , kde  $\gamma : \Theta \rightarrow \Theta^* \subset \mathbb{R}$  je reálná funkce.

Dále budeme uvažovat jednorozměrný parametr  $\theta \in \Theta \subset \mathbb{R}$ .

# Bodové odhady

Řekneme, že  $T : \mathbb{R}^n \rightarrow \mathbb{R}$  je bodový odhad parametru  $\theta \in \Theta \subset \mathbb{R}$ , jestliže  $T$  je měřitelnou funkcí náhodného výběru  $X_1, \dots, X_n$ . Tedy  $T = T(X_1, \dots, X_n)$  je náhodná veličina.

Vlastnosti bodových odhadů:

- $T$  je nestranný odhad parametru  $\theta$ , jestliže  $\mathbb{E} T = \theta$  pro všechna  $\theta \in \Theta$ .
- $T$  je asymptoticky nestranný odhad parametru  $\theta$ , jestliže  $\lim_{n \rightarrow \infty} \mathbb{E} T = \theta$  pro všechna  $\theta \in \Theta$ .
- $T$  je konzistentní odhad parametru  $\theta$ , jestliže  $T = T(X_1, \dots, X_n) \rightarrow \theta$  v pravděpodobnosti pro  $n \rightarrow \infty$  pro všechna  $\theta \in \Theta$ .

# Který odhad je nejlepší?

- Nechť  $T_1, T_2$  jsou dva nestranné odhady parametru  $\theta$ . Řekneme, že  $T_1$  je více eficientní (*lepsi*) než  $T_2$ , jestliže  $D T_1 \leq D T_2$  pro všechna  $\theta \in \Theta$ .
- Nechť  $T$  je nestranný odhad parametru  $\theta$ . Řekneme, že  $T$  je nejlepší nestranný odhad parametru  $\theta$ , jestliže  $D T \leq D T^*$  pro všechna  $\theta \in \Theta$  a pro všechny nestranné odhady  $T^*$ .
- Nechť  $T$  je odhad parametru  $\theta$ . Střední čtvercovou (kvadratickou) chybu odhadu definujeme jako  $MSE(T) = \mathbb{E}(T - \theta)^2$ .
- Je-li  $T$  je nestranný odhad parametru  $\theta$ , pak  $MSE(T) = D T$ .
- Nechť  $T_1, T_2$  jsou dva odhady parametru  $\theta$ . Řekneme, že  $T_1$  je více eficientní (*lepsi*) než  $T_2$ , jestliže  $MSE(T_1) \leq MSE(T_2)$  pro všechna  $\theta \in \Theta$ .
- (Stejnoměrně) nejlepší odhad parametru  $\theta$  neexistuje.

# Metoda momentů

- Dále předpokládejme, že neznámý parametr  $\theta$  je  $p$ -rozměrný ( $\Theta \subset \mathbb{R}^p$ ).
- Nechť existují obecné momenty  $\mu'_k = \mu'_k(\theta) = \mathbb{E}X_1^k$  pro  $k = 1, \dots, p$ .
- Označme jejich výběrové protějšky  $M'_k = \frac{1}{n} \sum_{i=1}^n X_i^k$  pro  $k = 1, 2, \dots$ .
- Řekneme, že  $\tilde{\theta}$  je odhad parametru  $\theta$  metodou momentů, jestliže  $\mu'_k(\tilde{\theta}) = M'_k$  pro  $k = 1, \dots, p$ .
- Je-li řešení předchozí soustavy nejednoznačné (rovnice jsou lineárně závislé), přidáme další rovnici pro  $k = p + 1$ , pokud ovšem existuje příslušný moment.

# Metoda maximální věrohodnosti

- Označme sdruženou hustotu náhodného vektoru  $(X_1, \dots, X_n)'$  jako

$$L(\theta) = \prod_{i=1}^n f(x_i, \theta).$$

- $f(x, \theta)$  je hustota (pravděpodobnostní hustota, pravděpodobnostní funkce) náhodné veličiny  $X_i$ .
- $L(\theta) = L(\theta, x_1, \dots, x_n)$  se nazývá věrohodnostní funkce.
- $\hat{\theta}$  se nazývá maximálně věrohodným odhadem parametru  $\theta$ , jestliže  $L(\hat{\theta}) \geq L(\theta), \forall \theta \in \Theta$ .
- $\hat{\theta} = \arg \max\{L(\theta); \theta \in \Theta\}$ .
- $I(\theta) = \log L(\theta) = \sum_{i=1}^n \log f(x_i, \theta)$  se nazývá logaritmická věrohodnostní funkce.
- $\hat{\theta} = \arg \max\{I(\theta); \theta \in \Theta\}$ .

# Regulární systém hustot

Řekneme, že systém hustot  $\{f(x, \theta), \theta \in \Theta\}$  je regulární, jestliže

- ①  $\Theta \subset \mathbb{R}^p$  je otevřená borelovská množina.
- ② Množina  $M = \{x \in \mathbb{R} : f(x, \theta) > 0\}$  nezávisí na hodnotě parametru  $\theta$ .
- ③ Pro všechna  $x \in M$  existuje konečná parciální derivace

$$f'_i(x, \theta) = \frac{\partial f(x, \theta)}{\partial \theta}, \quad i = 1, \dots, p.$$

- ④ Pro všechna  $\theta \in \Theta$  a všechna  $i = 1, \dots, p$  platí

$$\int_M f'_i(x, \theta) dx = 0.$$

- ⑤ Pro všechna  $\theta \in \Theta$  a pro každou dvojici  $(i, j)$  existuje konečný integrál

$$J_{i,j}(\theta) = \int_M \frac{f'_i(x, \theta) f'_j(x, \theta)}{f_i^2(x, \theta)} f_i(x, \theta) dx$$

- ⑥ Matice  $J(\theta) = (J_{i,j}(\theta))_{i,j=1}^p$  je pozitivně definitní pro všechna  $\theta \in \Theta$ .

# Vlastnosti maximálně věrohodných odhadů

- Nechť systém hustot  $\{f(x, \theta), \theta \in \Theta\}$  je regulární, pak maximálně věrohodný odhad parametru  $\theta$  je asymptoticky nestranný, konzistentní a má asymptoticky normální rozdělení.
- $\sqrt{n}(\hat{\theta} - \theta)$  má asymptoticky rozdělení  $\mathcal{N}_p(\mathbf{0}, \mathbf{J}^{-1}(\theta))$ .
- $$\mathbf{J}(\theta) = \left( \mathbb{E} \frac{\partial \log f(X_1, \theta)}{\partial \theta_i} \frac{\partial \log f(X_1, \theta)}{\partial \theta_j} \right)_{i,j=1}^p$$
je Fisherova informační matice o parametru  $\theta$  příslušná  $X_1$ .
- $$\mathbf{J}(\theta) = -\mathbb{E} \left( \frac{\partial^2 \log f(X_1, \theta)}{\partial \theta_i \partial \theta_j} \right)_{i,j=1}^p.$$
- $\hat{\theta} \approx \mathcal{N}_p(\theta, \frac{1}{n} \mathbf{J}^{-1}(\theta))$ .

# Maximálně věrohodné odhady pro parametrickou funkci $\gamma$

- Nechť  $\gamma : \Theta \rightarrow \Theta^*$  je parametrická funkce.
- Funkci  $\tilde{L}(\theta^*) = \sup\{L(\theta); \theta \in \Theta : \gamma(\theta) = \theta^*\}$  pro  $\theta^* \in \Theta^*$  nazveme věrohodnostní funkcí indukovanou parametrickou funkci  $\gamma$ .
- $\hat{\theta}^*$  je maximálně věrohodný odhad parametrické funkce  $\gamma(\theta) = \theta^*$ , jestliže  $\tilde{L}(\hat{\theta}^*) \geq \tilde{L}(\theta^*)$  pro všechna  $\theta^* \in \Theta^*$ .
- Zehnaova věta (princip invariance MLE): Je-li  $\hat{\theta}$  maximálně věrohodný odhad parametru  $\theta$ , pak  $\gamma(\hat{\theta})$  je maximálně věrohodný odhad parametrické funkce  $\gamma(\theta)$ .

# Delta metoda

## Theorem

Nechť  $\{\mathbf{X}_n\}_{n=1}^{\infty}$  je posloupnost  $p$ -rozměrných náhodných vektorů takových, že  $\sqrt{n}(\mathbf{X}_n - \boldsymbol{\theta})$  má asymptoticky normální rozdělení  $\mathcal{N}_p(\mathbf{0}, \boldsymbol{\Sigma})$ . Dále bud'  $\gamma : \mathbb{R}^p \rightarrow \mathbb{R}$  měřitelná funkce, která má totální diferenciál v bodě  $\boldsymbol{\theta}$ . Pak platí:  $\sqrt{n}(\gamma(\mathbf{X}_n) - \gamma(\boldsymbol{\theta}))$  má asymptoticky normální rozdělení  $\mathcal{N}(0, \sigma^2)$ , kde  $\sigma^2 = \nabla \gamma'(\boldsymbol{\theta}) \boldsymbol{\Sigma} \nabla \gamma(\boldsymbol{\theta})$ , kde

$$\nabla \gamma(\boldsymbol{\theta}) = \left( \frac{\partial \gamma(\boldsymbol{\theta})}{\partial \theta_1}, \dots, \frac{\partial \gamma(\boldsymbol{\theta})}{\partial \theta_p} \right)'$$

je gradient funkce  $\gamma$  v bodě  $\boldsymbol{\theta}$ .

# Aplikace na MLE

- Již víme, že je-li systém hustot  $\{f(x, \theta), \theta \in \Theta\}$  regulární, pak:  
 $\sqrt{n}(\hat{\theta} - \theta)$  má asymptoticky rozdělení  $\mathcal{N}_p(\mathbf{0}, \mathbf{J}^{-1}(\theta))$ .
- Aplikací delta metody dostaneme, že za splnění podmínek regularity platí:

$$\sqrt{n}(\gamma(\hat{\theta}) - \gamma(\theta)) \text{ má asymptoticky } \mathcal{N}(0, \nabla\gamma'(\theta)\mathbf{J}^{-1}(\theta)\nabla\gamma(\theta)).$$

- $\gamma(\hat{\theta}) \approx \mathcal{N}(\gamma(\theta), \frac{1}{n}\nabla\gamma'(\theta)\mathbf{J}^{-1}(\theta)\nabla\gamma(\theta))$ .
- Je-li  $\theta$  jednorozměrný parametr, pak  $\gamma(\hat{\theta}) \approx \mathcal{N}\left(\gamma(\theta), \frac{[\gamma'(\theta)]^2}{nJ(\theta)}\right)$ .

# Intervalová data

- Nepozorujeme přímo hodnoty náhodného výběru  $X_1, \dots, X_n$ .
- O každém pozorování víme jen to, do kterého intervalu patří.
- Obor hodnot náhodného výběru je rozdělen na intervale
- $(c_0, c_1], (c_1, c_2], \dots, (c_{k-1}, c_k]$ .
- $c_0$  může být i  $-\infty$  a  $c_k$  může být i  $\infty$ .
- Označme  $n_j$  počet pozorování, která leží v intervalu  $(c_{j-1}, c_j]$ .
- $n = n_1 + \dots + n_k$ .

# Empirická distribuční funkce pro intervalová data

- Standardně pro hodnoty náhodného výběru  $X_1, \dots, X_n$  definujme empirickou distribuční funkci

$$\widehat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{I}_{\{X_i \leq x\}}.$$

- Podle předchozí definice můžeme určit její přesné hodnoty v bodech  $c_0, c_1, \dots, c_k$ :

$$\widehat{F}_n(c_0) = 0, \quad \widehat{F}_n(c_j) = \frac{n_1 + \dots + n_j}{n}, \quad \widehat{F}_n(c_k) = 1.$$

- Mezi těmito body empirickou distribuční funkci spojitě dodefinujeme, například lomennou čarou (ogive).

•

$$\widehat{F}_n(x) = \begin{cases} 0, & x \leq c_0, \\ \frac{c_j - x}{c_j - c_{j-1}} \widehat{F}_n(c_{j-1}) + \frac{x - c_{j-1}}{c_j - c_{j-1}} \widehat{F}_n(c_j), & c_{j-1} < x < c_j, \\ 1, & x \geq c_k. \end{cases}$$

# Histogram pro intervalová data

- Histogram je po částech konstantní odhad hustoty původních veličin  $X_1, \dots, X_n$ .
- $f_n(x) = \hat{F}'_n(x)$  pro všechna  $x \neq c_0, \dots, c_k$ .
- 

$$f_n(x) = \frac{n_j}{n} \cdot \frac{1}{c_j - c_{j-1}}, \quad c_{j-1} < x < c_j.$$

- V bodech  $c_0, \dots, c_k$  můžeme definovat libovolně.
- Hodnota histogramu v intervalu  $(c_{j-1}, c_j]$  je rovna relativní četnosti pozorování v daném intervalu dělená délkou tohoto intervalu.

# Empirická kvantilová funkce pro intervalová data

- Můžeme ji určit jako inverzní funkci k empirické distribuční funkci (ogive), tj.  $\widehat{Q}_n(\alpha) = \widehat{F}_n^{-1}(\alpha)$  pro  $0 < \alpha < 1$ .
- Nebo opět určit přesné hodnoty v bodech  $0, \frac{n_1}{n}, \frac{n_1+n_2}{n}, \dots, 1$ :

$$\widehat{Q}_n(0) = c_0, \quad \widehat{Q}_n(\alpha_j) = c_j, \quad \widehat{Q}_n(1) = c_k,$$

kde  $\alpha_j = \frac{n_1+\dots+n_j}{n}$ .

- Mezi těmito body empirickou kvantilovou funkci opět spojite dodefinujeme, například lomennou čarou.
- 

$$\widehat{Q}_n(\alpha) = \frac{\alpha_j - \alpha}{\alpha_j - \alpha_{j-1}} \widehat{Q}_n(\alpha_{j-1}) + \frac{\alpha - \alpha_{j-1}}{\alpha_j - \alpha_{j-1}} \widehat{Q}_n(\alpha_j), \quad \alpha_{j-1} < \alpha < \alpha_j.$$

# Metoda maximální věrohodnosti pro intervalová data

- Nechť každá z nepozorovaných náhodných veličin  $X_1, \dots, X_n$  má distribuční funkci  $F(x, \theta)$ , kde  $\theta \in \Theta$  je neznámý parametr.
- Pravděpodobnost, že dané pozorování  $X_i$  leží v intervalu  $(c_{j-1}, c_j]$  je

$$P(X_i \in (c_{j-1}, c_j]) = F(c_j, \theta) - F(c_{j-1}, \theta).$$

- Věrohodnostní funkce pro naše data je:  
$$L(\theta) = \prod_{i=1}^n P(X_i \in (c_{j-1}, c_j]) = [F(c_1, \theta) - F(c_0, \theta)]^{n_1} \cdot [F(c_2, \theta) - F(c_1, \theta)]^{n_2} \cdots [F(c_{k-1}, \theta) - F(c_k, \theta)]^{n_k} = \prod_{j=1}^k [F(c_j, \theta) - F(c_{j-1}, \theta)]^{n_j}.$$
- $I(\theta) = \log L(\theta) = \sum_{j=1}^k n_j \log[F(c_j, \theta) - F(c_{j-1}, \theta)]$  je logaritmická věrohodnostní funkce pro naše data.
- $\hat{\theta} = \arg \max\{I(\theta); \theta \in \Theta\}$ .

# Metoda minimálního $\chi^2$

- Označme  $p_j(\theta)$  teoretickou pravděpodobnost, že náhodná veličina  $X_i$  nabude hodnoty z intervalu  $(c_{j-1}, c_j]$ , tedy

$$p_j(\theta) = P(X_i \in (c_{j-1}, c_j]) = F(c_j, \theta) - F(c_{j-1}, \theta).$$

- Dohromady máme celkem  $n$  pozorování. V intervalu  $(c_{j-1}, c_j]$  by tedy mělo být  $np_j(\theta)$  pozorování.
- Porovnejme očekávaný a skutečný (pozorovaný) počet pozorování v jednotlivých intervalech  $(c_{j-1}, c_j]$  pomocí Pearsonovy  $\chi^2$  statistiky testu dobré shody:

$$\chi^2(\theta) = \sum_{j=1}^k \left( \frac{n_j - np_j(\theta)}{\sqrt{np_j(\theta)}} \right)^2.$$

- 

$$\chi^2(\theta) = \sum_{j=1}^k \frac{n_j^2}{np_j(\theta)} - n.$$

- Odhad parametru  $\theta$  metodou minimálního  $\chi^2$  minimalizuje  $\chi^2(\theta)$  přes všechny hodnoty  $\theta \in \Theta$ , tj.  $\tilde{\theta} = \arg \min \{\chi^2(\theta), \theta \in \Theta\}$ .

# Metoda minimálního $\chi^2$ pro klasická data

- Obor hodnot náhodné veličiny  $X_i$  musíme na  $k$  po dvou disjunktních intervalů rozdělit sami, stejně tak spočítat  $n_j$  počet pozorování v intervalu  $(c_{j-1}, c_j]$ .
- Na tato umělá intervalová data aplikujeme předchozí postup.
- Intervaly  $(c_{j-1}, c_j]$  by se měly volit stejně pravděpodobné, tj.  
 $p_j(\tilde{\theta}) = \frac{1}{k}$  pro  $j = 1, \dots, k$ .
- Volba počtu tříd  $k$  - heuristická pravidla, např.  $k \doteq 15 \left( \frac{n}{100} \right)^{2/5}$ , nebo  $k \doteq 2n^{2/5}$ .

# Bayesovské odhady (Bayesovská statistika)

- Kombinuje informaci obsaženou v datech (parametrický model) s apriorní informací o neznámém parametru  $\theta$  (zkušenosti, domněnky, dřívější pozorování).
- Závěry (odhadů) vyvozuje až z aposteriorního rozdělení.
- Idea: Naše informace o hodnotě neznámého parametru může být vyjádřena pomocí pravděpodobnostního rozdělení, tj. neznámý parametr  $\theta$  považujeme za náhodný vektor.

# Matematický model

- $X_1, \dots, X_n$  je náhodný výběr z rozdělení s hustotou  $f(x, \theta)$ , kde  $\theta \in \Theta$ .
- $\theta$  je nyní náhodný vektor s hustotou  $q(\theta)$ .
- Označme podmíněnou hustotu náhodného vektoru  $(X_1, \dots, X_n)'$  při dané hodnotě parametru  $\theta$  jako  $r(\mathbf{x}|\theta) = \prod_{i=1}^n f(x_i, \theta)$ , kde  $\mathbf{x} = (x_1, \dots, x_n)'$ .

## Theorem (Bayesova věta)

Pro podmíněnou hustotu náhodného vektoru  $\theta$  při daných hodnotách  $\mathbf{X} = \mathbf{x}$  platí:

$$\pi(\theta|\mathbf{x}) = \begin{cases} \frac{r(\mathbf{x}|\theta)q(\theta)}{\int_{\Theta} r(\mathbf{x}|\theta)q(\theta)d\theta}, & \text{pokud } \int_{\Theta} r(\mathbf{x}|\theta)q(\theta)d\theta \neq 0, \\ 0, & \text{jinak.} \end{cases}$$

# Poznámky

- $q(\theta)$  se nazývá apriorní hustota - vyjadřuje informaci o parametru  $\theta$  ještě před realizací náhodného výběru  $\mathbf{X}$ .
- $\pi(\theta|\mathbf{x})$  se nazývá aposteriorní hustota - vyjadřuje informaci o parametru  $\theta$  až po realizaci náhodného výběru  $\mathbf{X}$ .
- Při Bayesovském přístupu používáme kromě dat (realizace náhodného výběru) ještě informaci o parametru  $\theta$  nezávisle na našich datech.
- Tato informace může mít objektivní i subjektivní charakter.

# Volba apriorního rozdělení

- Pokud máme informace (výsledky) z minulosti
  - přesná znalost rozdělení
  - jádrové odhady hustoty
  - parametrický model
- Pokud nemáme informace (výsledky) z minulosti
  - neinformativní (rovnoramenné) rozdělení  $q(\theta) \propto 1$
  - Jeffreysovo apriorní rozdělení  $q(\theta) \propto \sqrt{|\mathbf{J}(\theta)|}$
  - konjugované apriorní rozdělení

# Bodové odhady

- Definujme ztrátovou funkci  $L(\theta, \hat{\theta})$  - ztráta, kterou utrpíme, když odhadneme parametr  $\theta$  pomocí odhadu  $\hat{\theta}$ .
- Dále definujme bayesovské riziko (průměrná aposteriorní ztráta):

$$r(\theta) = \int_{\Theta} L(\theta, \hat{\theta}) \pi(\theta | \mathbf{x}) d\theta.$$

- Hledáme odhad, který minimalizuje bayesovské riziko. Nechť dále  $\theta$  je jednorozměrný parametr.
- Pro kvadratickou ztrátovou funkci  $L(\theta, \hat{\theta}) = (\theta - \hat{\theta})^2$  je bayesovským odhadem aposteriorní střední hodnota, tj.  $\hat{\theta} = \mathbb{E}(\theta | X_1, \dots, X_n)$ .
- Pro absolutní ztrátovou funkci  $L(\theta, \hat{\theta}) = |\theta - \hat{\theta}|$  je bayesovským odhadem aposteriorní medián, tj.  $\hat{\theta} = \text{med}(\theta | X_1, \dots, X_n)$ .
- Pro 0-1 ztrátovou funkci  $L(\theta, \hat{\theta}) = \mathbb{I}\{\theta \neq \hat{\theta}\}$  je bayesovským odhadem aposteriorní modus, tj.  $\hat{\theta} = \arg \max \pi(\theta | X_1, \dots, X_n)$ .

# Intervalové odhady

## Definition

100(1 -  $\alpha$ )% věrohodnostní interval pro parametr  $\theta$  je takový interval  $[a, b] = [a(X_1, \dots, X_n), b(X_1, \dots, X_n)]$ , pro který

$$P(a \leq \theta \leq b | \mathbf{X}) = 1 - \alpha.$$

- Equal tail - je takový interval  $[a, b]$ , kde  $a$  je  $\alpha/2$ -kvantil aposteriorního rozdělení  $\theta | \mathbf{X}$  a  $b$  je  $1 - \alpha/2$ -kvantil aposteriorního rozdělení  $\theta | \mathbf{X}$ .
- HPD (interval o největší aposteriorní hustotě) je takový interval  $[a, b]$  takový, že  $\pi(\theta | \mathbf{x}) \geq c$  pro všechna  $\theta \in [a, b]$  a  $c > 0$  je nejmenší číslo takové, že  $P(\pi(\theta | \mathbf{x}) \geq c) = 1 - \alpha$ .

## Theorem

Je-li  $\pi(\theta | \mathbf{x})$  spojitá a unimodální, pak HPD interval je nejkratší mezi všemi věrohodnostními intervaly.

# Predikce budoucího pozorování

- Nechť se budoucí pozorování  $X_{n+1}$  řídí stejným modelem jako  $X_1, \dots, X_n$  - tedy má hustotu  $f(x, \theta)$ .
- Chceme predikovat(předpovídat) jeho budoucí hodnotu.
- S pomocí Bayesovy věty můžeme odvodit aposteriorní prediktivní hustotu

$$f(x_{n+1}|\mathbf{x}) = \int_{\Theta} f(x_{n+1}, \theta) \pi(\theta|\mathbf{x}) d\theta.$$

# Model selection (výběr modelu)

- ① Je náš model vhodný? Popisuje dobře naše data?
- ② Máme-li více modelů, který z nich je nejlepší? Který máme použít?

# Grafické metody pro posouzení vhodnosti modelu

- Jsou založené na porovnání teoretického a empirického rozdělení.
- Porovnání teoretické distribuční funkce  $F(x, \hat{\theta})$  a empirické distribuční funkce  $\hat{F}_n(x)$  v jednom grafu.
- Porovnání teoretické a empirické distribuční funkce pomocí funkce  $D(x) = \hat{F}_n(x) - F(x, \hat{\theta})$ .
- Porovnání teoretické hustoty  $f(x, \hat{\theta})$  a empirické hustoty (histogram, jádrový odhad) v jednom grafu.
- Q-Q plot
- P-P plot

# Q-Q plot

- Porovnává teoretické a empirické kvantily.
- Uspořádnané hodnoty náhodného výběru označme

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}.$$

- Podle upravené definice  $x_{(i)}$  je  $p_i = \frac{i-\beta}{n+1-2\beta}$ -tý výběrový kvantil, kde  $0 \leq \beta < 1$  je korekční faktor.
- Q-Q plot je graf  $\left[ F^{-1}(p_i, \hat{\theta}), x_{(i)} \right]$  pro  $i = 1, \dots, n$ .
- Je-li náš model správný, pak by se body Q-Q plotu měly náhodně vyskytovat kolem osy prvního kvadrantu.

# P-P plot

- porovnává hodnoty teoretické a empirické distribuční funkce.
- P-P plot je graf  $\left[ F(x_{(i)}, \hat{\theta}), \frac{i}{n+1} \right]$  pro  $i = 1, \dots, n$ .
- Je-li náš model správný, pak by se body P-P plotu měly náhodně vyskytovat kolem osy prvního kvadrantu.

# Statistické testy

- Potřebujeme obecnější model:  $X_1, \dots, X_n$  je náhodný výběr z rozdělení s distribuční funkcí  $F$  (libovolná).
- Formálně testujeme nulovou hypotézu  $H_0: F = F(x, \theta)$  pro nějaké  $\theta \in \Theta$  proti alternativě, že  $H_0$  neplatí.
- Testujeme tedy, že námi specifikovaný model je vhodný pro naše data.
- Testy založené na porovnání distribučních funkcí (Kolmogorovův - Smirnovův test, Andersonův - von Darlingův test, Cramérův - von Misesův test), testy dobré shody (Pearsonův  $\chi^2$  test) a další.
- Pro odvození testů budeme ještě potřebovat pomocnou nulovou hypotézu  $H_0^*: F = F(x, \theta^*)$ , kde  $\theta^*$  je známá hodnota.

# Kolmogorovův - Smirnovův test

- Nulová hypotéza  $H_0^*$ :  $F = F(x, \theta^*)$ , kde  $\theta^*$  je známá hodnota.

- Testová statistika

$$D_n = \max_{x \in \mathbb{R}} \{|\hat{F}_n(x) - F(x, \theta^*)|\} = \max_{i=1, \dots, n} \left\{ \left| \frac{i}{n} - F(x_{(i)}, \theta^*) \right| \right\}.$$

- Za platnosti  $H_0^*$  má  $\sqrt{n}D_n$  asymptotické rozdělení stejné jako  $\sup_{t \in [0,1]} |B(t)|$ , kde  $B(t)$  je Brownův most v  $\mathcal{C}(0, 1)$ .

- To má distribuční funkci  $1 - 2 \sum_{j=0}^{\infty} (-1)^{j+1} e^{-2j^2y^2}$ , pro  $y > 0$ .

- A approximativní kvantilovou funkci  $\sqrt{\frac{1}{2} \log \frac{2}{1-\alpha}}$ , pro  $0 < \alpha < 1$ .

- Test se dá použít jen, když  $\theta^*$  je známá. Pokud jsou k jejímu odhadu použita data, test nefunguje - je příliš konzervativní.

# Kolmogorovův - Smirnovův test (modifikace)

- Uvažujme původní hypotézu  $H_0: F = F(x, \theta)$  pro nějaké  $\theta \in \Theta$ .
- Neznámý parametr  $\theta$  nejprve odhadneme z dat.
- Testová statistika  
$$D_n = \max_{x \in \mathbb{R}} \{|\hat{F}_n(x) - F(x, \hat{\theta})|\} = \max_{i=1, \dots, n} \{|\frac{i}{n} - F(x_{(i)}, \hat{\theta})|\}.$$
- Rozdělení testové statistiky  $D_n$  za platnosti  $H_0$  závisí na daném rozdělení, ze kterého data pocházejí (a v některých situacích i na jeho parametrech).
- Pro testování normality bylo toto rozdělení odvozeno - Lillieforsův test.
- Pro ostatní rozdělení lze použít simulace - spočítat příslušnou  $p$ -hodnotu testu pomocí parametrického bootstrapu.

## Kolmogorovův - Smirnovův test (parametrický bootstrap)

- ① Spočítáme hodnotu testové statistiky  $D_n$  pro naše data s odhadnutým parametrem  $\hat{\theta}$ , označme ji  $t$ .
- ② Nagenerujeme si nový náhodný výběr o rozsahu  $n$  z rozdělení s distribuční funkcí  $F(x, \hat{\theta})$ , realizaci označme  $x_1^*, \dots, x_n^*$ .
- ③ Odhadneme neznámý parametr  $\theta$ , označme jej  $\tilde{\theta}$ .
- ④ Pro tuto realizaci spočítáme hodnotu testové statistiky
$$D_n = \max_{x \in \mathbb{R}} \{|\hat{F}_n^*(x) - F(x, \tilde{\theta})|\} = \max_{i=1, \dots, n} \left\{ \left| \frac{i}{n} - F(x_{(i)}^*, \tilde{\theta}) \right| \right\}.$$
- ⑤ Body (2) – (4) několikrát opakujeme.
- ⑥  $p$ -hodnotu testu poté odhadneme jako relativní četnost případů, kdy  $D_n \geq t$ .

# Andersonův - Darlingův test

- Patří do třídy testů s testovou statistikou

$$n \int_{-\infty}^{\infty} \left( \hat{F}_n(x) - F(x, \hat{\theta}) \right)^2 w(F(x, \hat{\theta})) f(x, \hat{\theta}) dx$$

pro nějakou váhovou funkci  $w$ .

- Andersonův - Darlingův test používá váhovou funkci  $w(y) = \frac{1}{y(1-y)}$  pro  $0 < y < 1$ .
- Testová statistika se dá zjednodušit do tvaru

$$A^2 = -n - \frac{1}{n} \sum_{i=1}^n (2i-1) \left[ \log(F(x_{(i)}, \hat{\theta})) + \log(1 - F(x_{(n+1-i)}, \hat{\theta})) \right].$$

- Rozdělení testové statistiky  $A^2$  i pro  $\theta$  známé závisí na testovaném rozdělení.
- Příslušnou  $p$ -hodnotu testu musíme získat pomocí simulací, například pomocí parametrického bootstrapu.

# Cramerův - von Misesův test

- Patří do třídy testů s testovou statistikou

$$n \int_{-\infty}^{\infty} \left( \widehat{F}_n(x) - F(x, \widehat{\theta}) \right)^2 w(F(x, \widehat{\theta})) f(x, \widehat{\theta}) dx$$

pro nějakou váhovou funkci  $w$ .

- Cramerův - von Misesův test používá váhovou funkci  $w(y) = 1$  pro  $0 < y < 1$ .
- Testová statistika se dá zjednodušit do tvaru

$$T = \frac{1}{12n} + \sum_{i=1}^n \left[ \frac{2i-1}{2n} - F(x_{(i)}, \widehat{\theta}) \right]^2.$$

- Rozdělení testové statistiky  $T$  i pro  $\theta$  známé závisí na testovaném rozdělení.
- Příslušnou  $p$ -hodnotu testu musíme získat pomocí simulací, například pomocí parametrického bootstrapu.

# Pearsonův $\chi^2$ test dobré shody

- Začněme opět nejprve s nulovou hypotézou  $H_0^*$ :  $F = F(x, \theta^*)$ , kde  $\theta^*$  je známá hodnota.
- Definujme si intervaly  $(c_{j-1}, c_j]$ ,  $j = 1, \dots, k$ .
- Označme  $n_j$  počet pozorování, které padnou do intervalu  $(c_{j-1}, c_j]$  pro  $j = 1, \dots, k$ .
- Určíme očekávaný počet pozorování (za platnosti  $H_0^*$ ), které by měly padnout do intervalu  $(c_{j-1}, c_j]$ :

$$e_j = np_j(\theta^*) = nP(X_1 \in (c_{j-1}, c_j]) = n(F(c_j, \theta^*) - F(c_{j-1}, \theta^*)).$$

- Testová statistika

$$\chi^2 = \sum_{j=1}^k \frac{(n_j - e_j)^2}{e_j}.$$

- $\chi^2$  má za platnosti nulové hypotézy  $H_0^*$  asymptoticky  $\chi^2$  rozdělení s  $k - 1$  stupni volnosti.

# Modifikace Pearsonova $\chi^2$ testu dobré shody

- Vratíme se k původní hypotéze  $H_0: F = F(x, \theta)$  pro nějaké  $\theta \in \Theta$ .
- Nejprve z dat odhadneme neznámý  $p$ -rozměrný parametr  $\theta$ , označme jej  $\hat{\theta}$ , a postupujeme stejně jako v předchozím.
- Testová statistika

$$\chi^2 = \sum_{j=1}^k \frac{(n_j - e_j)^2}{e_j},$$

kde  $e_j = n(F(c_j, \hat{\theta}) - F(c_{j-1}, \hat{\theta}))$ .

- Upravená testová statistika  $\chi^2$  má za platnosti nulové hypotézy  $H_0$  asymptoticky  $\chi^2$  rozdělení s  $k - 1 - p$  stupni volnosti.

Volba tříd:

- $e_j = \frac{n}{k}$  pro  $j = 1, \dots, k$ .
- Heuristická pravidla pro počet tříd –  $k \doteq 2n^{2/5}$ , nebo  $k \doteq 15(n/100)^{2/5}$ .

# Výběr modelu z několika kandidátů

Princip Occamovy břitvy - vybíráme co nejjednodušší vhodný model.

## ① Judgement-based přístup - založený na subjektivním úsudku analytika

- rozhodnutí založené na různých grafech či tabulkách (tail vs. mod fit)
- rozhodnutí založené na předchozí zkušenosti (Paretovo rozdělení pro výši příjmů, Benfordovo pro četnost prvních číslic)
- model je plně určen situací, kterou má popisovat (házení mincí - alternativní rozdělení)

## ② Score-based přístup - založený na číselných charakteristikách

- nejnižší hodnota statistiky nějakého statistického testu
- nejvyšší  $p$ -hodnota nějakého statistického testu
- nejvyšší hodnota věrohodnosti
- nejvyšší hodnota nějaké penalizované funkce, např. AIC, BIC:
  - $AIC = -2I(\hat{\theta}) + 2p.$
  - $BIC = -2I(\hat{\theta}) + p \log n.$

# Teorie extrémních hodnot

Cíl:

- odhadnout  $P(X > x)$  pro  $x$  velké.
- odhadnout  $F^{-1}(\alpha)$  pro  $\alpha$  blízké 1.
- určit výši plnění, kterou nárokuje jen malé procento klientů s nevyšším plněním.
- určit, jak často budou klienti nárokovat vysoké pojistné plnění.

Metody:

- Metoda blokových maxim.
- Metoda založená na překročení meze (peaks-over-threshold; POT).

# Chování maxima náhodného výběru

- Nechť  $X_1, \dots, X_n$  je náhodný výběr z rozdělení s distribuční funkcí  $F(x)$ . Označme  $M_n = \max\{X_1, \dots, X_n\}$  maximum  $X_1, \dots, X_n$ . Počítejme jeho distribuční funkci:

$$\begin{aligned}G_n(x) &= P(M_n \leq x) = P(\max\{X_1, \dots, X_n\} \leq x) \\&= P(X_1 \leq x, \dots, X_n \leq x) = P(X_1 \leq x) \cdots P(X_n \leq x) = F(x)^n.\end{aligned}$$

- Hledejme jeho asymptotické rozdělení

$$\lim_{n \rightarrow \infty} G_n(x) = \begin{cases} 0, & \text{pokud } x < x_F \\ 1, & \text{pokud } x \geq x_F, \end{cases}$$

kde  $x_F = \sup\{x \in \mathbb{R} : F(x) < 1\}$  je pravý koncový bod nosiče  $F$ .

- Limitní rozdělení  $M_n$  je degenerované v bodě  $x_F$ , nebo "utíká" do nekonečna.
- Budeme hledat posloupnosti konstant  $\{a_n\}$  a  $\{b_n\}$  tak, aby  $\frac{M_n - b_n}{a_n}$  (normovaná maxima) konvergovala k nějakému nedegenerovanému rozdělení.

# Rozdělení extrémních hodnot

## 1 Gumbelovo rozdělení



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



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

## 2 Fréchetovo rozdělení s parametrem tvaru $\alpha > 0$



$$G_1(x) = e^{-x^{-\alpha}}, \quad x > 0.$$



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

## 3 Weibullovo (extremální) rozdělení s parametrem tvaru $\alpha < 0$



$$G_2(x) = e^{-(-x)^{-\alpha}}, \quad x < 0.$$



$$g_2(x) = -\alpha(-x)^{-\alpha-1} e^{-(-x)^{-\alpha}}, \quad x < 0.$$

# Rozdělení extrémních hodnot s parametry polohy a měřítka

- Předchozí tři rozdělení jsou standardizované.
- Přidáme parametr polohy  $\mu$  a parametr měřítka  $\sigma > 0$ .
- $G_{i,\mu,\sigma}(x) = G_i\left(\frac{x-\mu}{\sigma}\right)$ .

## ① Gumbelovo rozdělení

$$G_{0,\mu,\sigma}(x) = e^{-e^{-\frac{x-\mu}{\sigma}}}, \quad x \in \mathbb{R}.$$

## ② Fréchetovo rozdělení s parametrem tvaru $\alpha > 0$

$$G_{1,\mu,\sigma}(x) = e^{-\left(\frac{x-\mu}{\sigma}\right)^{-\alpha}}, \quad x > \mu.$$

## ③ Weibullovo (extremální) rozdělení s parametrem tvaru $\alpha < 0$

$$G_{2,\mu,\sigma}(x) = e^{-\left(-\frac{x-\mu}{\sigma}\right)^{-\alpha}}, \quad x < \mu.$$

Předchozí tři distribuce můžeme zapsat jedním vzorcem.

# Zobecněné rozdělení extrémních hodnot (GEV rozdělení)

- GEV rozdělení s parametrem  $\gamma \in \mathbb{R}$  ve standardizovaném tvaru

$$G_\gamma(x) = e^{-(1+\gamma x)^{-\frac{1}{\gamma}}}, \quad 1 + \gamma x > 0.$$

- Pro  $\gamma = 0$  dostaneme Gumbelovo rozdělení.
- Pro  $\gamma > 0$  dostaneme Fréchetovo rozdělení.
- Pro  $\gamma < 0$  dostaneme Weibullovo rozdělení.
- Opět budeme potřebovat přidat parametr polohy  $\mu$  a parametr měřítka  $\sigma > 0$ .
- GEV rozdělení s parametrem polohy  $\mu \in \mathbb{R}$ , parametrem měřítka  $\sigma > 0$  a parametrem tvaru  $\gamma \in \mathbb{R}$

$$G_{\gamma,\mu,\sigma}(x) = e^{-\left(1 + \frac{\gamma(x-\mu)}{\sigma}\right)^{-\frac{1}{\gamma}}}, \quad 1 + \frac{\gamma(x-\mu)}{\sigma} > 0.$$

# Modelování maxim

## Theorem (Fisherova - Tippettova věta)

Nechť  $X_1, \dots, X_n$  je náhodný výběr z rozdělení s distribuční funkcí  $F(x)$ .

Nechť existují posloupnosti konstant  $\{a_n\}$  a  $\{b_n\}$  tak, že

$P\left(\frac{X_n - b_n}{a_n} \leq x\right) \rightarrow H(x)$  pro  $n \rightarrow \infty$  pro nějakou nedegenerovanou distribuční funkci  $H(x)$ . Pak  $H(x)$  je distribuční funkce GEV rozdělení.

- Předchozí věta říká, že GEV je jediné možné limitní rozdělení maxim.
- Maxima náhodného výběru budeme modelovat pomocí GEV rozdělení s parametry  $\mu$ ,  $\sigma$  a  $\gamma$ .

# Aplikace metody blokových maxim

- Nechť  $X_1, \dots, X_N$  je náhodný výběr z rozdělení s distribuční funkcí  $F(x)$ . Pozor, nyní počet pozorování značíme  $N$ .
- Data rozdělíme do  $m$  bloků o velikosti  $n$  ( $N = m \cdot n$ ).
- V každém bloku najdeme maximum, maximum v  $i$ -tému bloku označme  $M_i = M_i^{(n)}$ .
- Dále budeme modelovat veličiny  $M_1, \dots, M_m$  (jsou nezávislé a stejně rozdělené).
- Ty budeme modelovat pomocí GEV rozdělení s parametry  $\mu, \sigma$  a  $\gamma$ .
- Délka bloku  $n$  musí být dostatečně velká, aby "fungovala" approximace pomocí GEV rozdělení.
- Počet bloků  $m$  musí být taky dostatečně velký, aby odhady parametrů byly "přesné".

# Metoda maximální věrohodnosti pro GEV rozdělení

- Model:  $M_1, \dots, M_m$  je náhodný výběr z GEV rozdělení s parametry  $\mu, \sigma$  a  $\gamma$ .
- Logaritmická věrohodnostní funkce je

$$\begin{aligned} l(\gamma, \mu, \sigma) &= -m \log \sigma - \left(1 + \frac{1}{\gamma}\right) \sum_{i=1}^m \log \left(1 + \frac{\gamma(M_i - \mu)}{\sigma}\right) \\ &\quad - \sum_{i=1}^m \left(1 + \frac{\gamma(M_i - \mu)}{\sigma}\right)^{-\frac{1}{\gamma}}, \end{aligned}$$

pro  $1 + \frac{\gamma(M_1 - \mu)}{\sigma} > 0, \dots, 1 + \frac{\gamma(M_m - \mu)}{\sigma} > 0$ .

- Tu maximalizujeme přes všechny hodnoty  $\gamma, \mu$  a  $\sigma > 0$  takové, že  $1 + \frac{\gamma(M_1 - \mu)}{\sigma} > 0, \dots, 1 + \frac{\gamma(M_m - \mu)}{\sigma} > 0$ .
- Funkce  $l(\gamma, \mu, \sigma)$  není diferencovatelná, proto ji musíme maximalizovat numericky.
- Pro  $\gamma > -\frac{1}{2}$ , maximálně věrohodný odhad je asymptoticky nestranný, konzistentní a asymptoticky normální.

# Metoda pravděpodobnostně vážených momentů pro GEV rozdělení

## Definition

Nechť  $X$  je náhodná veličina s distribuční funkcí  $F(x)$ , pak čísla  $M_{p,r,s} = \mathbb{E}[X^p F(X)^r (1 - F(X))^s]$  pro  $p, r, s \in \mathbb{R}$  nazveme pravděpodobnostně vážené momenty.

- Speciálně položme  $p = 1$  a  $s = 0$  a označme  $\beta_r = M_{1,r,0} = \mathbb{E}[X \cdot F(X)^r]$  pro  $r = 0, 1, 2$ .
- Pro GEV rozdělení je  $\beta_r = \frac{1}{r+1} \left\{ \mu - \frac{\sigma}{\gamma} [1 - (r+1)^\gamma \Gamma(1-\gamma)] \right\}$  pro  $\gamma < 1$ ,  $\gamma \neq 0$ .
- Jeho odhad je  $\widehat{\beta}_0 = \frac{1}{m} \sum_{i=1}^m M_i$  a  $\widehat{\beta}_r = \frac{1}{m} \sum_{i=1}^m \left( \prod_{j=1}^r \frac{i-j}{m-j} M_{(i)} \right)$  pro  $r = 1, 2$ .
- Odhad parametrů metodou pravděpodobnostně vážených momentů získáme jako řešení soustavy  $\beta_r = \widehat{\beta}_r$ , pro  $r = 0, 1, 2$ .

# Odhad pravděpodobnosti překročení vysoké hranice



$$P(M_1 \leq x) = P(X_i \leq x)^n = [1 - P(X_i > x)]^n.$$



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

- Pro  $x$  velké můžeme odhadnout

$$\widehat{P(X_i > x)} = 1 - [G_{\widehat{\gamma}, \widehat{\mu}, \widehat{\sigma}}(x)]^{\frac{1}{n}} = 1 - e^{-\frac{1}{n}(1 + \frac{\widehat{\gamma}(x - \widehat{\mu})}{\widehat{\sigma}})^{-\frac{1}{\widehat{\gamma}}}}.$$

# Odhad vysokého kvantilu

- $q_\alpha$  je  $\alpha$ -kvantil veličiny  $X_i$ , jestliže  $P(X_i \leq q_\alpha) = \alpha$ .
- 

$$1 - \alpha = P(X_i > q_\alpha) = 1 - P(M_1 \leq q_\alpha)^{\frac{1}{n}} = 1 - [G_{\gamma, \mu, \sigma}(q_\alpha)]^{\frac{1}{n}}.$$

- 
- $q_\alpha = G_{\gamma, \mu, \sigma}^{-1}(\alpha^n) = \mu + \frac{\sigma}{\gamma} \left( (-\log(\alpha^n))^{-\gamma} - 1 \right).$
- Tedy  $\alpha$ -kvantil náhodné veličiny  $X_i$  je roven  $\alpha^n$ -kvantilu GEV rozdělení.
- Pro  $\alpha$  blízké 1 můžeme odhadnout

$$\hat{q}_\alpha = G_{\hat{\gamma}, \hat{\mu}, \hat{\sigma}}^{-1}(\alpha^n) = \hat{\mu} + \frac{\hat{\sigma}}{\hat{\gamma}} \left( (-\log(\alpha^n))^{-\hat{\gamma}} - 1 \right).$$

# Odhad doby návratu

- Cílem je stanovit průměrnou frekvenci výskytu extrémního jevu, tj. jak často je překračována nějaká vysoká hranice.
- Frekventistická definice pravděpodobnosti: je-li  $P(X_i > x) = p$ , pak  $X_i$  překročí hranici  $x$  v průměru jednou za  $\frac{1}{p}$  časových okamžiků.
- Předpokládejme, že máme danou hranici  $x$ .
- Označme  $k$  průměrnou frekvenci, tj.  $k = \frac{1}{p}$  a hledejme jej tak, že platí

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

- Tedy

$$k = \frac{1}{P(X_i > x)} = \frac{1}{1 - [G_{\gamma, \mu, \sigma}(x)]^{\frac{1}{n}}}.$$

- Tedy odhad doby návratu je

$$\hat{k} = \frac{1}{1 - e^{-\frac{1}{n} \left(1 + \frac{\hat{\gamma}(x - \hat{\mu})}{\hat{\sigma}}\right)^{-\frac{1}{\hat{\gamma}}}}}.$$

# Odhad úrovně návratu

- Cílem je stanovit hranici  $x$ , která je překračována v průměru jednou za  $k$  časových okamžiků.
- Opět začneme s frekventistickou definicí pravděpodobnosti:

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

- Potom  $x$  je  $(1 - \frac{1}{k})$ -kvantil  $X_i$ , tj.

$$x = G_{\gamma, \mu, \sigma}^{-1} \left( \left( 1 - \frac{1}{k} \right)^n \right).$$

- Tedy odhad úrovně návratu je

$$\hat{x} = \hat{\mu} + \frac{\hat{\sigma}}{\hat{\gamma}} \left( \left( -\log \left( \left( 1 - \frac{1}{k} \right)^n \right) \right)^{-\hat{\gamma}} - 1 \right).$$

## Odhad doby a úrovně návratu II

- V praxi často doba a úroveň návratu chápe časové okamžiky jako počty bloků.
- Označme  $k^*$  průměrnou frekvenci (v počtech bloků), pak

$$P(M_i > x) = \frac{1}{k^*} = 1 - G_{\gamma, \mu, \sigma}(x).$$

- Tedy odhad doby návratu (v počtech bloků) je

$$\widehat{k^*} = \frac{1}{1 - G_{\widehat{\gamma}, \widehat{\mu}, \widehat{\sigma}}(x)} = \frac{1}{1 - e^{-\left(1 + \frac{\widehat{\gamma}(x - \widehat{\mu})}{\widehat{\sigma}}\right)^{-\frac{1}{\widehat{\gamma}}}}}.$$

- A odhad úrovně návratu

$$\widehat{x} = G_{\widehat{\gamma}, \widehat{\mu}, \widehat{\sigma}}^{-1} \left(1 - \frac{1}{\widehat{k^*}}\right) = \widehat{\mu} + \frac{\widehat{\sigma}}{\widehat{\gamma}} \left(\left(-\log \left(1 - \frac{1}{\widehat{k^*}}\right)\right)^{-\widehat{\gamma}} - 1\right).$$

# Chování excesů náhodného výběru

- Nechť  $X_1, \dots, X_n$  je náhodný výběr z rozdělení s distribuční funkcí  $F(x)$ . Zvolme nějakou hranici (práh, threshold)  $u$  a definujme  $Y_i^{(u)} = X_i - u$  pro  $X_i > u$  výši jeho překročení (exces) pro pozorování, která tuto hranici překročila.
- Označme  $N_u$  počet pozorávní, která překročila hranici  $u$ .
- Hledejme distribuční funkci  $Y_i^{(u)}$ , označme ji  $F_u(x)$ :

$$\begin{aligned} F_u(x) &= P(Y_i^{(u)} \leq x) = P(X_i - u \leq x | X_i > u) \\ &= \frac{P(u < X_i \leq u + x)}{P(X_i > u)} = \frac{F(u+x) - F(u)}{1 - F(u)}, \quad x \geq 0. \end{aligned}$$

- Hledejme jeho asymptotické rozdělení pro  $u \nearrow x_F$ .
- To bude degenerované v bodě 0.
- Budeme hledat posloupnosti konstant  $\{a_n\}$  a  $\{b_n\}$  tak, aby  $\frac{Y_n^{(u)} - b_n}{a_n}$  (normované excesy) konvergovaly k nějakému nedegenerovanému rozdělení.

# Rozdělení pro modelování excesů

## ① Exponenciální rozdělení

•

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

•

$$w_0(x) = e^{-x}, \quad x \geq 0.$$

## ② Paretovo rozdělení s parametrem tvaru $\alpha > 0$

•

$$W_1(x) = 1 - x^{-\alpha}, \quad x \geq 1.$$

•

$$w_1(x) = \frac{\alpha}{x^{\alpha+1}}, \quad x \geq 1.$$

## ③ Beta rozdělení s parametrem tvaru $\alpha < 0$

•

$$W_2(x) = 1 - (-x)^{-\alpha}, \quad -1 \leq x \leq 0.$$

•

$$w_2(x) = -\alpha(-x)^{-\alpha-1}, \quad -1 \leq x \leq 0.$$

# Rozdělení pro modelování excesů s parametry polohy a měřítka

- Předchozí tři rozdělení jsou standardizované.
- Přidáme parametr polohy  $\mu$  a parametr měřítka  $\sigma > 0$ .
- $W_{i,\mu,\sigma}(x) = W_i\left(\frac{x-\mu}{\sigma}\right)$ .

## ① Exponenciální rozdělení

$$W_{0,\mu,\sigma}(x) = 1 - e^{-\frac{x-\mu}{\sigma}}, \quad x \geq \mu.$$

## ② Paretovo rozdělení s parametrem tvaru $\alpha > 0$

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

## ③ Beta rozdělení s parametrem tvaru $\alpha < 0$

$$W_{2,\mu,\sigma}(x) = 1 - \left(-\frac{x-\mu}{\sigma}\right)^{-\alpha}, \quad \mu - \sigma \leq x \leq \mu.$$

Předchozí tři distribuce můžeme zapsat jedním vzorcem.

# Zobecněné Paretovo rozdělení (GPD rozdělení)

- GPD rozdělení s parametrem  $\gamma \in \mathbb{R}$  ve standardizovaném tvaru

$$W_\gamma(x) = 1 - (1 + \gamma x)^{-\frac{1}{\gamma}}.$$

- Pro  $\gamma = 0$  dostaneme exponenciální rozdělení ( $x \geq 0$ ).
- Pro  $\gamma > 0$  dostaneme Paretovo rozdělení ( $x \geq 0$ ).
- Pro  $\gamma < 0$  dostaneme beta rozdělení ( $0 \leq x \leq -\frac{1}{\gamma}$ ).
- Nyní budeme potřebovat přidat pouze parametr měřítka  $\sigma > 0$ .
- GPD rozdělení s parametrem měřítka  $\sigma > 0$  a parametrem tvaru  $\gamma \in \mathbb{R}$

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

# Modelování excesů

Theorem (Balkemova - de Haanova - Pickandsova věta)

Nechť  $X_1, \dots, X_n$  je náhodný výběr z rozdělení s distribuční funkcí  $F(x)$ .

Nechť existují posloupnosti konstant  $\{a_n\}$  a  $\{b_n\}$  tak, že

$P\left(\frac{Y_n^{(u_n)} - b_n}{a_n} \leq x\right) \rightarrow H(x)$  pro  $u_n \nearrow x_F$  pro nějakou nedegenerovanou spojitou distribuční funkci  $H(x)$ . Pak  $H(x)$  je distribuční funkce GPD rozdělení.

- Předchozí věta říká, že GPD rozdělení je jediné možné limitní rozdělení excesů.
- Excesy náhodného výběru budeme modelovat pomocí GPD rozdělení s parametry  $\sigma$  a  $\gamma$ .

# Aplikace POT metody

- Nechť  $X_1, \dots, X_N$  je náhodný výběr z rozdělení s distribuční funkcí  $F(x)$ . Pozor, počet pozorování opět značíme  $N$ .
- Zvolíme dostatečně vysokou hranici  $u$ .
- A definujeme excesy  $Y_i = X_i - u$ , pokud  $X_i > u$ , pro  $i = 1, \dots, N_u$  ( $N_u$  je počet excesů).
- Dále budeme modelovat veličiny  $Y_1, \dots, Y_{N_u}$  (jsou nezávislé a stejně rozdělené).
- Ty budeme modelovat pomocí GPD rozdělení s parametry  $\sigma$  a  $\gamma$ .
- Velikost prahu  $u$  musí být dostatečně velká, aby "fungovala" approximace pomocí GPD rozdělení.
- Počet excesů  $N_u$  musí být taky dostatečně velký, aby odhady parametrů byly "přesné".

# Metoda maximální věrohodnosti pro GPD rozdělení

- Model:  $Y_1, \dots, Y_{N_u}$  je náhodný výběr z GPD rozdělení s parametry  $\sigma$  a  $\gamma$ .
- Logaritmická věrohodnostní funkce je

$$l(\gamma, \sigma) = -N_u \log \sigma - \left(1 + \frac{1}{\gamma}\right) \sum_{i=1}^{N_u} \log \left(1 + \frac{\gamma}{\sigma} Y_i\right)$$

pro  $1 + \frac{\gamma}{\sigma} Y_1 > 0, \dots, 1 + \frac{\gamma}{\sigma} Y_{N_u} > 0$ .

- Tu maximalizujeme přes všechny hodnoty  $\gamma$  a  $\sigma > 0$  takové, že  $1 + \frac{\gamma}{\sigma} Y_1 > 0, \dots, 1 + \frac{\gamma}{\sigma} Y_{N_u} > 0$ .
- Funkce  $l(\gamma, \sigma)$  není diferencovatelná, proto ji musíme maximalizovat numericky.
- Pro  $\gamma > -\frac{1}{2}$ , maximálně věrohodný odhad je asymptoticky nestranný, konzistentní a asymptoticky normální.

# Metoda pravděpodobnostně vážených momentů pro GPD rozdělení

Připomeňme definici pravděpodobnostně vážených momentů:

## Definition

Nechť  $X$  je náhodná veličina s distribuční funkcí  $F(x)$ , pak čísla  $M_{p,r,s} = \mathbb{E}[X^p F(X)^r (1 - F(X))^s]$  pro  $p, r, s \in \mathbb{R}$  nazveme pravděpodobnostně vážené momenty.

- Speciálně položme  $p = 1$  a  $r = 0$  a označme  $\alpha_s = M_{1,0,s} = \mathbb{E}[X \cdot (1 - F(X))^s]$  pro  $s = 0, 1$ .
- Pro GPD rozdělení je  $\alpha_s = \frac{\sigma}{(s-\gamma+1)(s+1)}$  pro  $\gamma < 1$ .
- Jeho odhad je  $\hat{\alpha}_0 = \frac{1}{N_u} \sum_{i=1}^{N_u} Y_i$  a  $\hat{\alpha}_1 = \frac{1}{N_u} \sum_{i=1}^{N_u} \frac{N_u - i}{N_u - 1} Y_{(i)}$ .
- Odhad parametrů metodou pravděpodobnostně vážených momentů získáme jako řešení soustavy  $\alpha_s = \hat{\alpha}_s$ , pro  $s = 0, 1$ .

# Odhad pravděpodobnosti překročení vysoké hranice



$$P(X_i > x | X_i > u) = \frac{P(X_i > x)}{P(X_i > u)}, \text{ pro } x \geq u.$$



$$\begin{aligned} P(X_i > x) &= P(X_i > u)P(X_i > x | X_i > u) \\ &= P(X_i > u)[1 - P(Y_i \leq x - u | X_i > u)] \\ &= P(X_i > u)[1 - F_u(x - u)] \\ &= P(X_i > u)(1 - W_{\gamma, \sigma}(x - u)) \\ &= P(X_i > u) \left(1 + \frac{\gamma(x - u)}{\sigma}\right)^{-\frac{1}{\gamma}}. \end{aligned}$$

- Pro  $x$  velké můžeme odhadnout

$$P(\widehat{X_i > x}) = \frac{N_u}{N} \left(1 + \frac{\widehat{\gamma}(x - u)}{\widehat{\sigma}}\right)^{-\frac{1}{\widehat{\gamma}}}.$$

# Odhad vysokého kvantilu

- $q_\alpha$  je  $\alpha$ -kvantil veličiny  $X_i$ , jestliže  $P(X_i \leq q_\alpha) = \alpha$ .
- $1 - \alpha = P(X_i > q_\alpha) = P(X_i > u)(1 - W_{\gamma, \sigma}(q_\alpha - u))$ .
- 

$$q_\alpha = u + W_{\gamma, \sigma}^{-1} \left( 1 - \frac{1 - \alpha}{P(X_i > u)} \right) = u + \frac{\sigma}{\gamma} \left[ \left( \frac{P(X_i > u)}{1 - \alpha} \right)^\gamma - 1 \right].$$

- Tedy  $\alpha$ -kvantil náhodné veličiny  $X_i$  je roven  $\left(1 - \frac{1-\alpha}{P(X_i > u)}\right)$ -kvantilu GPD rozdělení plus  $u$ .
- Pro  $\alpha$  blízké 1 můžeme odhadnout

$$\hat{q}_\alpha = u + W_{\hat{\gamma}, \hat{\sigma}}^{-1} \left( 1 - \frac{1 - \alpha}{\widehat{P(X_i > u)}} \right) = u + \frac{\hat{\sigma}}{\hat{\gamma}} \left[ \left( \frac{N_u}{N(1 - \alpha)} \right)^{\hat{\gamma}} - 1 \right].$$

# Odhad doby návratu

- Cílem je stanovit průměrnou frekvenci výskytu extrémního jevu, tj. jak často je překračována nějaká vysoká hranice.
- Frekventistická definice pravděpodobnosti: je-li  $P(X_i > x) = p$ , pak  $X_i$  překročí hranici  $x$  v průměru jednou za  $\frac{1}{p}$  časových okamžiků.
- Předpokládejme, že máme danou hranici  $x$ .
- Označme  $k$  průměrnou frekvenci, tj.  $k = \frac{1}{p}$  a hledejme jej tak, že platí

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

- Tedy

$$k = \frac{1}{P(X_i > x)} = \frac{1}{P(X_i > u)(1 - W_{\gamma, \sigma}(x - u))} = \frac{\left(1 + \frac{\gamma(x-u)}{\sigma}\right)^{\frac{1}{\gamma}}}{P(X_i > u)}.$$

- Tedy odhad doby návratu je

$$\hat{k} = \frac{N}{N_u (1 - W_{\hat{\gamma}, \hat{\sigma}}(x - u))} = \frac{N \left(1 + \frac{\hat{\gamma}(x-u)}{\hat{\sigma}}\right)^{\frac{1}{\hat{\gamma}}}}{N_u}.$$

# Odhad úrovně návratu

- Cílem je stanovit hranici  $x$ , která je překračována v průměru jednou za  $k$  časových okamžiků.
- Opět začneme s frekventistickou definicí pravděpodobnosti:

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

- Potom  $x$  je  $(1 - \frac{1}{k})$ -kvantil  $X_i$ , tj.

$$x = u + W_{\gamma, \sigma}^{-1} \left( 1 - \frac{1}{kP(X_i > u)} \right).$$

- Tedy odhad úrovně návratu je

$$\hat{x} = u + W_{\hat{\gamma}, \hat{\sigma}}^{-1} \left( 1 - \frac{N}{kN_u} \right) = u + \frac{\hat{\sigma}}{\hat{\gamma}} \left[ \left( \frac{kN_u}{N} \right)^{\hat{\gamma}} - 1 \right].$$

# Volba prahu $u$

## Definition

Střední hodnotu překročení prahu  $u$  za podmínky, že k překročení došlo (mean excess) definujeme jako  $e(u) = \mathbb{E}(X_i - u | X_i > u)$ .

- Má-li náhodná veličina  $X_i$  GPD rozdělení s parametry  $\sigma$  a  $\gamma$ , pak  $\mathbb{E}X_i = \frac{\sigma}{1-\gamma}$ .
- Má-li náhodná veličina  $X_i$  GPD rozdělení s parametry  $\sigma$  a  $\gamma$ , pak náhodná veličina  $X_i - u | X_i > u$  má GPD s parametry  $\sigma + \gamma u$  a  $\sigma$ .
- Má-li náhodná veličina  $X_i$  GPD rozdělení s parametry  $\sigma$  a  $\gamma$ , pak  $e(u) = \frac{\sigma + \gamma u}{1-\gamma}$ .
- Tedy  $e(u)$  je lineární funkcií v  $u$  (charakteristická vlastnost GPD rozdělení).

# Volba prahu $u$ II

- Pro naše data můžeme spočítat odhad:  $\hat{e}(u) = \frac{\sum_{i=1}^{N_u} Y_i}{N_u}$ , kde  $Y_i = X_i - u$  pro  $X_i > u$ ,  $i = 1, \dots, N_u$ .
- Vykreslíme graf  $[x_{(i)}, \hat{e}(x_{(i)})]$  pro  $i = 1, \dots, N$ .
- Ten se v praxi nazývá mean excess plot.
- Pokud data pochází z GPD rozdělení, pak by graf měl být lineární.
- Hranici  $u$  určíme jako bod z grafu, odkud křivka vykazuje lineární závislost.

# Modelování dvourozměrných dat

- Sdružené rozdělení náhodného vektoru  $(X, Y)'$  jednoznačně určuje marginální rozdělení náhodných veličin  $X$  a  $Y$ .
- Opačně to ale neplatí.
- Cíl: Popsat, jak vypadají všechna sdružená rozdělení s předem danými marginálními rozděleními.

## Definition

Funkce  $C : [0, 1] \times [0, 1] \rightarrow [0, 1]$  se nazývá kopula, jestliže

- ①  $C(u, 0) = C(0, u) = 0, \forall u \in [0, 1].$
- ②  $C(u, 1) = C(1, u) = u, \forall u \in [0, 1].$
- ③  $C(u_1, v_1) - C(u_1, v_2) - C(u_2, v_1) + C(u_2, v_2) \geq 0,$   
 $\forall 0 \leq u_1 \leq u_2 \leq 1, 0 \leq v_1 \leq v_2 \leq 1.$

# Modelování dvourozměrných dat

## Definition (Alternativní definice kopuly)

Funkce  $C : [0, 1] \times [0, 1] \rightarrow [0, 1]$  se nazývá kopula, jestliže existuje pravděpodobnostní prostor  $(\Omega, \mathcal{A}, P)$  a na něm definovaný náhodný vektor  $(U, V)'$  takový, že

- ①  $U \sim \mathcal{R}(0, 1)$ .
- ②  $V \sim \mathcal{R}(0, 1)$ .
- ③  $C(u, v) = P(U \leq u, V \leq v)$  je sdružená distribuční funkce  $(U, V)'$ .

Příklady:

- ①  $C(u, v) = \Pi(u, v) = u \cdot v$  (součinová kopula;  $U$  a  $V$  jsou nezávislé).
- ②  $C(u, v) = M(u, v) = \min\{u, v\}$  (horní kopula;  $V = U$ ).
- ③  $C(u, v) = W(u, v) = \max\{u + v - 1, 0\}$  (dolní kopula;  $V = 1 - U$ ).

# Modelování dvourozměrných dat

Theorem (Fréchetovy - Höffdingovy meze)

Pro každou kopulu  $C$  platí:

$$W(u, v) \leq C(u, v) \leq H(u, v), \quad \forall u, v \in [0, 1].$$

Theorem (Sklarova věta)

Nechť náhodný vektor  $(X, Y)'$  má distribuční funkci  $F$  a marginální distribuční funkce  $F_1$  a  $F_2$ . Pak existuje taková kopula  $C$ , že

$$F(x, y) = C(F_1(x), F_2(y)), \quad \forall x, y \in \mathbb{R}.$$

Je-li  $F$  spojitá, pak  $C$  je určená jednoznačně.

- Předchozí věta nám dává návod, jak modelovat dvourozměrná rozdělení.
- Předepřejeme si marginální rozdělení a zvolíme vhodnou kopulu, která popisuje závislost složek (nezávisle na marginálních rozděleních).

# Vztah kopul a korelačních koeficientů

- Pearsonův korelační koeficient

$$\rho = \rho(X, Y) = \frac{C(X, Y)}{\sqrt{D(X)D(Y)}}.$$

- Jeho hodnota závisí na marginálních rozděleních  $X$  a  $Y$ .
- Spearmanův korelační koeficient

$$\rho_S = \rho_S(X, Y) = \rho(F_1(X), F_2(Y)) = 12 \int_0^1 \int_0^1 C(u, v) dudv - 3.$$

- Kendallovo  $\tau$

$$\begin{aligned}\tau &= \tau(X, Y) = P((X_1 - X_2)(Y_1 - Y_2) > 0) \\ &\quad - P((X_1 - X_2)(Y_1 - Y_2) < 0) = 4 \int_0^1 \int_0^1 C(u, v) c(u, v) dudv - 1,\end{aligned}$$

kde  $(X_1, Y_1)'$  a  $(X_2, Y_2)'$  jsou dvě nezávislé kopie  $(X, Y)'$  a  
 $c(u, v) = \frac{\partial^2 C(u, v)}{\partial u \partial v}$  je hustota kopuly  $C$ .

# Příklady kopul

## ① Archimédovské kopuly

- Gumbelova kopula
- Joeova kopula
- Claytonova kopula
- Frankova kopula

## ② Eliptické kopuly

- Normální (gaussovská) kopula
- Studentova  $t$  kopula

## ③ Kopuly extrémních hodnot

- Gumbelova kopula
- Galambosova kopula
- Tawnova kopula

# Archimédovské kopuly

- Dají se většinou vyjádřit v uzavřeném tvaru.
- Většinou obsahují jeden parametr.
- 

$$C(u, v) = \phi^{-1}(\phi(u) + \phi(v)),$$

kde  $\phi : [0, 1] \rightarrow [0, \infty]$  je spojitá, klesající a konvexní funkce s  $\phi(1) = 0$ .

- Funkce  $\phi$  se nazývá generátor.
- Pro hodnotu Kendallova  $\tau$  platí:

$$\tau = 1 + 4 \int_0^1 \frac{\phi(u)}{\phi'(u)} du.$$

# Součinová (nezávislá) kopula

- Je Archimédovská kopula s generátorem  $\phi(u) = -\log u$ .
- $C(u, v) = u \cdot v$ .
- Pro hodnotu Kendallova  $\tau$  platí:  $\tau = 0$ .

# Gumbelova (Gumbelova - Hougaardova) kopula

- Je Archimédovská kopula s generátorem  $\phi(u) = (-\log u)^\theta$ .
- $\theta \geq 1$  je parametr.
- 

$$C(u, v) = \exp \left\{ - [(-\log u)^\theta + (-\log v)^\theta]^{\frac{1}{\theta}} \right\}.$$

- Pro hodnotu Kendallova  $\tau$  platí:  $\tau = 1 - \frac{1}{\theta}$ .
- Pro  $\theta = 1$  je Gumbelova kopula rovna součinové.
- Pro  $\theta \rightarrow \infty$  se Gumbelova kopula blíží horní kopule.

# Joeova kopula

- Je Archimédovská kopula s generátorem  $\phi(u) = -\log[1 - (1 - u)^\theta]$ .
- $\theta \geq 1$  je parametr.
- 

$$C(u, v) = 1 - [(1 - u)^\theta + (1 - v)^\theta - (1 - u)^\theta \cdot (1 - v)^\theta]^{\frac{1}{\theta}}.$$

- Pro  $\theta = 1$  je Joeova kopula rovna součinové.
- Pro  $\theta \rightarrow \infty$  se Joeova kopula blíží horní kopule.

# Claytonova kopula

- Je Archimédovská kopula s generátorem  $\phi(u) = \frac{1}{\theta} (u^{-\theta} - 1)$ .
- $\theta \in [-1, \infty) \setminus \{0\}$  je parametr.
- 

$$C(u, v) = \max\{(u^{-\theta} + v^{-\theta} - 1)^{-\frac{1}{\theta}}, 0\}.$$

- Pro hodnotu Kendallova  $\tau$  platí:  $\tau = \frac{\theta}{\theta+2}$ .
- Pro  $\theta = -1$  je Claytonova kopula rovna dolní kopule.
- Pro  $\theta \rightarrow 0$  se Claytonova kopula blíží součinové kopule.
- Pro  $\theta \rightarrow \infty$  se Claytonova kopula blíží horní kopule.

# Frankova kopula

- Je Archimédovská kopula s generátorem

$$\phi(u) = -\log \left( \frac{e^{-\theta u} - 1}{e^{-\theta} - 1} \right).$$

- $\theta \in \mathbb{R} \setminus \{0\}$  je parametr.

- 

$$C(u, v) = -\frac{1}{\theta} \log \left( 1 + \frac{(e^{-\theta u} - 1)(e^{-\theta v} - 1)}{e^{-\theta} - 1} \right).$$

- Pro  $\theta \rightarrow -\infty$  se Frankova kopula blíží dolní kopule.
- Pro  $\theta \rightarrow 0$  se Frankova kopula blíží součinové kopule.
- Pro  $\theta \rightarrow \infty$  se Frankova kopula blíží horní kopule.

# Normální (gaussovská) kopula

- Patří mezi eliptické kopuly.

- 

$$C(u, v) = \Phi_\rho(\Phi^{-1}(u), \Phi^{-1}(v)).$$

- $\Phi^{-1}$  je kvantilová funkce standardizovaného normálního rozdělení  $\mathcal{N}(0, 1)$ .
- $\Phi_\rho$  je distribuční funkce dvourozměrného normálního rozdělení  $\mathcal{N}_2(\mathbf{0}, \boldsymbol{\Sigma})$ , kde  $\boldsymbol{\Sigma} = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$  je jeho varianční matice.
- $\rho \in [-1, 1]$  je parametr.
- Pro hodnotu Kendallova  $\tau$  platí:  $\tau = \frac{2}{\pi} \arcsin \rho$ .
- Pro  $\rho = -1$  je normální kopula rovna dolní kopule.
- Pro  $\rho = 0$  je normální kopula rovna součinové kopule.
- Pro  $\rho = 1$  je normální kopula rovna horní kopule.

# Studentova $t$ kopula

- Patří mezi eliptické kopuly.
- $$C(u, v) = t_{\nu, \rho}(t_{\nu}^{-1}(u), t_{\nu}^{-1}(v)).$$
- $t_{\nu}^{-1}$  je kvantilová funkce  $t$  rozdělení s  $\nu$  stupni volnosti.
- $t_{\nu, \rho}$  je distribuční funkce dvourozměrného  $t$  rozdělení s  $\nu$  stupni volnosti a varianční maticí  $\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$ .
- $\rho \in [-1, 1]$  a  $\nu \in [1, \infty)$  jsou parametry.
- Pro hodnotu Kendallova  $\tau$  platí:  $\tau = \frac{2}{\pi} \arcsin \rho$ .
- Pro  $\rho = -1$  je Studentova kopula rovna dolní kopule.
- Pro  $\rho = 0$  je Studentova kopula rovna součinové kopule.
- Pro  $\rho = 1$  je Studentova kopula rovna horní kopule.

# Kopuly extrémních hodnot

Jsou takové kopuly, pro které platí:

$$C(u^n, v^n) = C^n(u, v), \quad 0 \leq u, v \leq 1, \forall n = 1, 2, \dots$$

## ① Gumbelova kopula

$$C(u, v) = \exp \left\{ - [(-\log u)^\theta + (-\log v)^\theta]^{\frac{1}{\theta}} \right\}, \quad \theta \geq 1 \text{ je parametr.}$$

## ② Galambosova kopula

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

## ③ Tawnova kopula

$$C(u, v) = u^{1-\alpha} \cdot v^{1-\beta} \cdot \exp \left\{ - [(-\alpha \log u)^\theta + (-\beta \log v)^\theta]^{\frac{1}{\theta}} \right\},$$

$$\theta \geq 1, 0 \leq \alpha \leq 1, 0 \leq \beta \leq 1 \text{ jsou parametry.}$$

# Generování dvourozměrných náhodných vektorů

- Naším úkolem je získat realizaci spojitého náhodného vektoru  $(X, Y)'$  se sdruženou distribuční funkcí  $F(x, y)$ .
- Sklarova věta:  $F(x, y) = C(F_1(x), F_2(y))$ .
- Označme  $c(u, v) = \frac{\partial^2 C(u, v)}{\partial u \partial v}$  hustotu kopuly  $C(u, v)$ .
- Hustota náhodné veličiny  $U|V = v$  je rovna  $c(u|v) = c(u, v)$ .
- Distribuční funkce náhodné veličiny  $U|V = v$  je rovna  $\frac{\partial C(u, v)}{\partial v}$ .

# Generování dvourozměrných náhodných vektorů

- ① Generujeme realizaci náhodné veličiny  $V$  z  $\mathcal{R}(0, 1)$ , označme ji  $v$ .
- ② Generujeme realizaci náhodné veličiny  $U$  z podmíněného rozdělení  $U|V = v$  s distribuční funkcí  $\frac{\partial C(u, v)}{\partial v}$ , označme ji  $u$ .
- ③ Tedy  $(u, v)'$  je realizace kopuly  $C$ .
- ④ Hledanou realizaci  $(x, y)'$  dostaneme jako  $(x, y)' = (F_1^{-1}(u), F_2^{-1}(v))'$ .

# Modelování dvourozměrných dat

- **Model:**  $(X_1, Y_1)', \dots, (X_n, Y_n)'$  je náhodný výběr z dvourozměrného rozdělení s distribuční funkcí  $F(x, y)$ .
- Naším cílem je odhadnout distribuční funkci  $F(x, y)$ .
- Sklarova věta:  $F(x, y) = C(F_1(x), F_2(y))$ , kde  $F_1(x)$  je marginální distribuční funkce náhodných veličin  $X_i$  a  $F_2(y)$  je marginální distribuční funkce náhodných veličin  $Y_i$ .
- **Parametrický přístup:** Zvolíme marginální rozdělení  $F_1$  a  $F_2$  a kopulu  $C$  a přidáme parametry.
- 

$$F_{\theta}(x, y) = C_{\theta_3}(F_1(x, \theta_1), F_2(y, \theta_2)),$$

kde  $\theta = (\theta'_1, \theta'_2, \theta'_3)'$  je vektor neznámých parametrů.

## Modelování dvourozměrných dat - MLE

- 

$$f_{\boldsymbol{\theta}}(x, y) = f_1(x, \boldsymbol{\theta}_1)f_2(y, \boldsymbol{\theta}_2)c_{\boldsymbol{\theta}_3}(F_1(x, \boldsymbol{\theta}_1), F_2(y, \boldsymbol{\theta}_2)),$$

kde  $f_1(x, \boldsymbol{\theta}_1)$  je marginální hustota  $X_i$ ,  $f_2(y, \boldsymbol{\theta}_2)$  je marginální hustota  $Y_i$  a  $c_{\boldsymbol{\theta}_3}(u, v)$  je hustota kopuly  $C$ .

- 

$$\begin{aligned} l(\boldsymbol{\theta}) &= \sum_{i=1}^n \log f_{\boldsymbol{\theta}}(X_i, Y_i) = \sum_{i=1}^n \log f_1(X_i, \boldsymbol{\theta}_1) + \sum_{i=1}^n \log f_2(Y_i, \boldsymbol{\theta}_2) + \\ &+ \sum_{i=1}^n \log c_{\boldsymbol{\theta}_3}(F_1(X_i, \boldsymbol{\theta}_1), F_2(Y_i, \boldsymbol{\theta}_2)) = l_1(\boldsymbol{\theta}_1) + l_2(\boldsymbol{\theta}_2) + l_3(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \boldsymbol{\theta}_3). \end{aligned}$$

- $\hat{\boldsymbol{\theta}} = \arg \max \{l(\boldsymbol{\theta}); \boldsymbol{\theta} \in \Theta\}$  je odhad parametru  $\boldsymbol{\theta}$  metodou maximální věrohodnosti.

# Modelování dvourozměrných dat - pseudoMLE

- Předchozí odhad je výpočetně náročný a nestabilní (dimenze  $\theta$  je velká).
- Modifikace metody - pseudomaximálně věrohodný odhad (IFM; inference for marginal distributions).
- Nejprve odhadneme marginální rozdělení, tj. získáme maximálně věrohodné odhady parametrů  $\theta_1$  a  $\theta_2$ :

$$\hat{\theta}_1 = \arg \max l_1(\theta_1), \quad \hat{\theta}_2 = \arg \max l_2(\theta_2).$$

- Pro tyto pevné hodnoty  $\hat{\theta}_1$  a  $\hat{\theta}_2$  maximalizujeme  $l_3(\theta_1, \theta_2, \theta_3)$ :

$$\hat{\theta}_3 = \arg \max \{l_3(\hat{\theta}_1, \hat{\theta}_2, \theta_3); \theta_3\}.$$

- Potom  $\hat{\theta} = (\hat{\theta}'_1, \hat{\theta}'_2, \hat{\theta}'_3)'$  je odhad parametru  $\theta$  metodou pseudomaximální věrohodnosti.

# Modelování dvourozměrných dat - CML

- Pro modelování můžeme využít i semiparametrický přístup (marginální rozdělení modelujeme neparametricky a kopulu parametricky).
- Marginální distribuční funkce odhadneme pomocí modifikovaných empirických distribučních funkcí  $\widehat{F}_1(x) = \frac{1}{n+1} \sum_{i=1}^n \mathbb{I}_{\{X_i \leq x\}}$  a  $\widehat{F}_2(y) = \frac{1}{n+1} \sum_{i=1}^n \mathbb{I}_{\{Y_i \leq y\}}$ .
- Odhad parametru  $\theta_3$  příslušný kopule  $C$  metodou kanonické maximální věrohodnosti je

$$\begin{aligned}\widehat{\theta}_3 &= \arg \max \sum_{i=1}^n \log c_{\theta_3}(\widehat{F}_1(X_i), \widehat{F}_2(Y_i)) \\ &= \arg \max \sum_{i=1}^n \log c_{\theta_3} \left( \frac{R_i}{n+1}, \frac{S_i}{n+1} \right),\end{aligned}$$

kde  $R_i$  je pořadí  $X_i$  mezi  $X_1, \dots, X_n$  a  $S_i$  je pořadí  $Y_i$  mezi  $Y_1, \dots, Y_n$ .

# Modelování dvourozměrných dat - metoda inverze Kendallova $\tau$

- Jedná se o semiparametrický přístup (marginální rozdělení modelujeme neparametricky a kopulu parametricky).
- Lze použít v případě, kdy kopula  $C$  závisí na jednorozměrném parametru  $\theta$  a hodnotu Kendallova  $\tau$  jsme schopni vyjádřit jako funkci  $\theta$ , tj.  $\tau = f(\theta)$ .
- Marginální distribuční funkce odhadneme pomocí modifikovaných empirických distribučních funkcí  $\hat{F}_1(x) = \frac{1}{n+1} \sum_{i=1}^n \mathbb{I}_{\{X_i \leq x\}}$  a  $\hat{F}_2(y) = \frac{1}{n+1} \sum_{i=1}^n \mathbb{I}_{\{Y_i \leq y\}}$ .
- Odhadneme hodnotu Kendallova  $\tau$  z dat:

$$\hat{\tau} = \frac{\sum \sum_{i \neq j} \text{sign}(X_i - X_j) \text{sign}(Y_i - Y_j)}{n(n-1)} = \frac{2(a-b)}{n(n-1)},$$

kde  $a$  je počet konkordančních párů a  $b$  je počet diskordančních párů.

- Odhad parametru  $\theta$  dostaneme jako řešení rovnice  $f(\theta) = \hat{\tau}$ .