

# Teória extrémnych hodnôt

# Motivácia

- Ako súvisia holandské protipovodňové hrádze s bankovou reguláciou?
- Pri snahe o odhad celého rozdelenia strát sa sústredíme na centrálnu časť rozdelenia, význam chvostov je podhodnotený
- V manažmente rizík nás zaujímajú práve udalosti na chvoste („low probability, large impact“)
  - Ťažké chvosty = Súčet náhodných premenných je na chvostoch úplne determinovaný jediným outlierom:
- Údajov na chvoste je málo, ale je možné využiť asymptotické vlastnosti chvostov (analógia centrálnej limitnej vety)
- Rozdelenie na chvostoch môže nadobúdať iba tri typy:
  - Žiadny chvost (distribučná funkcia je useknutá)
  - Exponenciálna funkcia
  - Mocninová funkcia

# Čo hovoria dáta

- Na prvej prednáške sme si ukázali, že výnos akciového indexu je lepšie modelovať Studentovým  $t$ -rozdelením s 3 stupňami voľnosti ako normálnym rozdelením

$$f(x) = \frac{\Gamma\left(\frac{a+1}{2}\right)}{\Gamma\left(\frac{a}{2}\right)} \frac{1}{\sqrt{a\pi}} \frac{1}{\left(1 + \frac{x^2}{a}\right)^{\frac{a+1}{2}}} \sim \text{const } x^{-a-1}$$


# Paretovo rozdelenie

- Taliansky ekonóm Vilfredo Pareto (1964)
- Definícia

$$\Pr(X \leq x) = \begin{cases} 1 - x^{-\alpha} & x \geq 1 \\ 0 & x < 1 \end{cases}$$

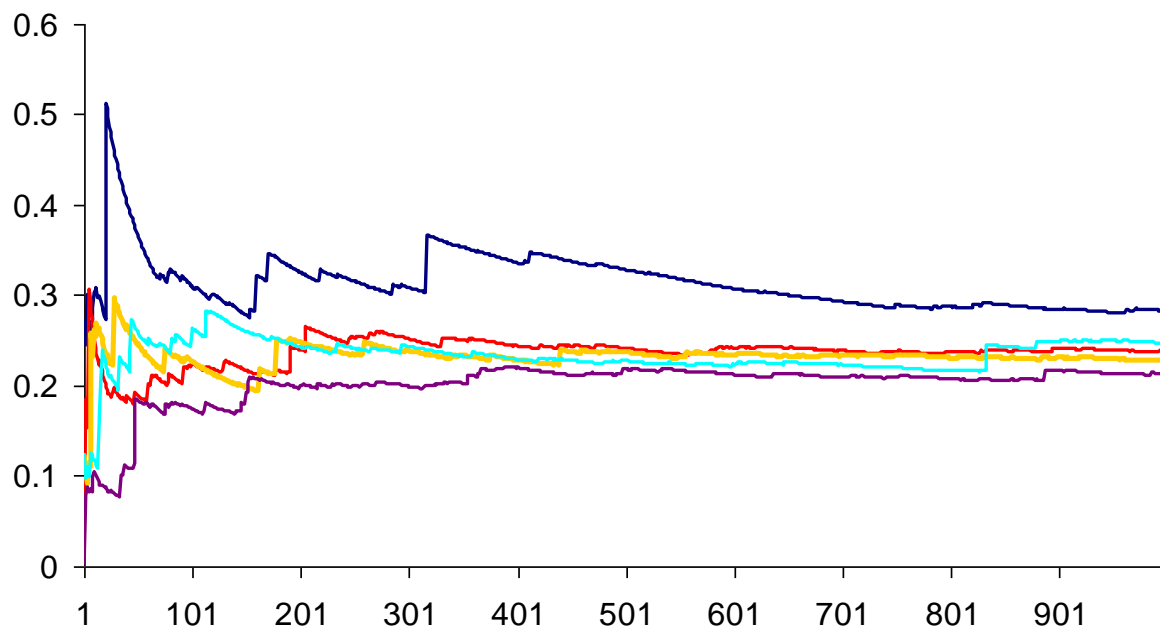
- Aplikácie
  - Veľkosť sídiel
  - Veľkosť meteoritov
  - Množstvo ropných zásob v ropných poliach
  - Najväčší jednodenný úhrn zrážok v roku
  - Počet postihnutých ha lesa pri požiari
  - ...
  - Jednodenné výnosy akcií
- Ak  $\alpha = 2$ , rozdelenie má nekonečnú varianciu. Čo to znamená v praxi?

Hustota Paretovho rozdelenia s parametrom  $k$



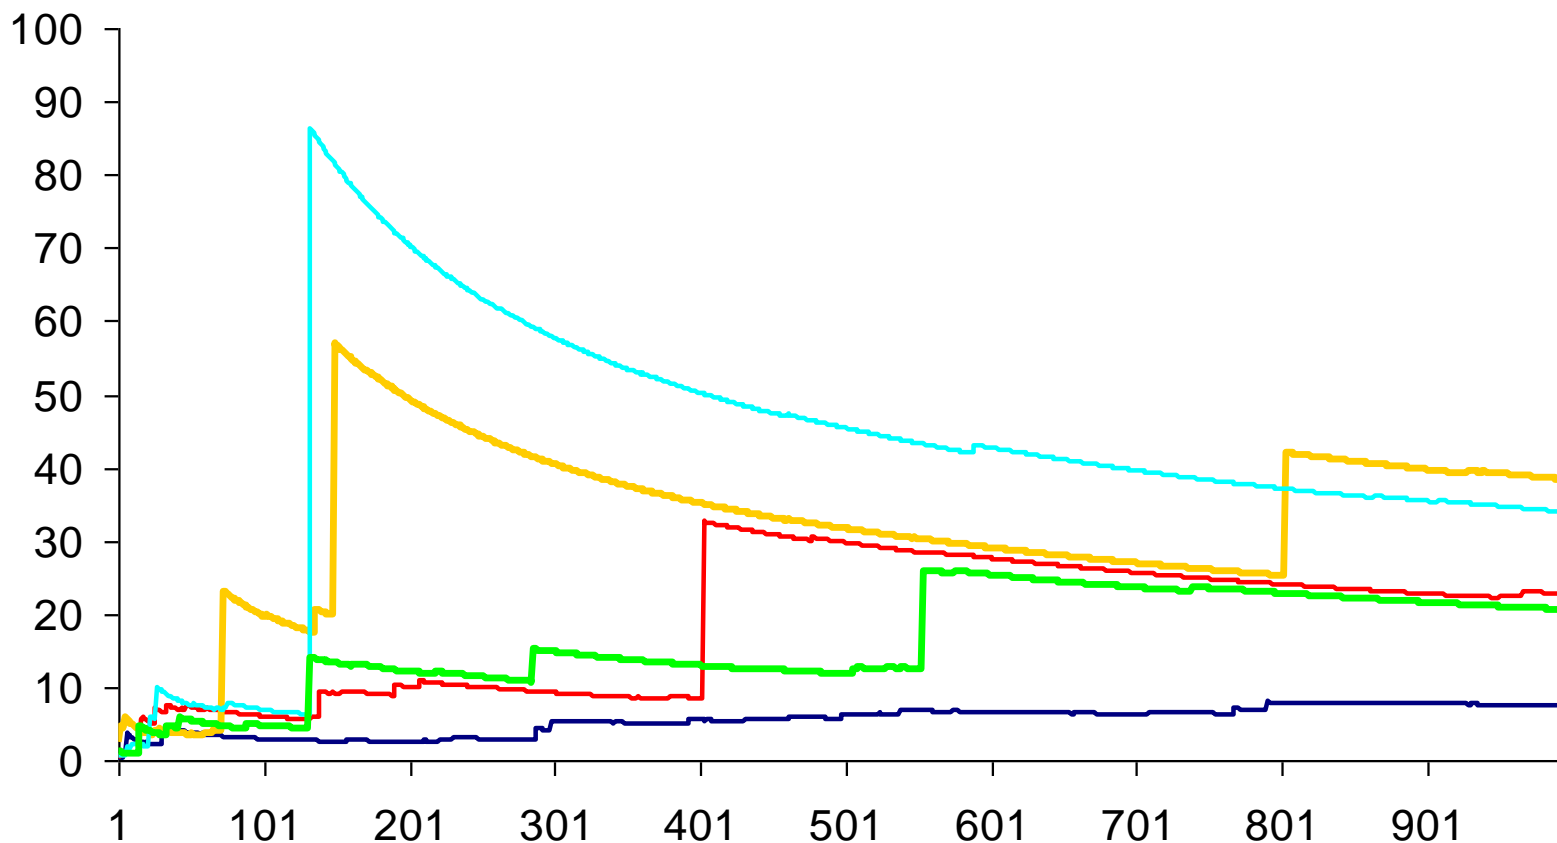
# Paretovo rozdelenie

- Vygenerujem dáta z Paretovho rozdelenia
- Vypočítam kumulatívnu volatilitu  $\sigma_k$  z údajov  $X_1, \dots, X_k$  pre  $k = 1, \dots, n$
- Graf  $\sigma_k$  pre  $k = 1, \dots, n$  s parametrom  $\alpha = 6$  (teoretická hodnota  $\sigma = 0.24$ )







# Paretoovo rozdelenie

- Rôzne priebehy kumulatívnej volatility pre parameter  $\alpha = 1.2$  (teoretická volatility neexistuje)



# Paretovo rozdelenie

- Ak druhý moment neexistuje, kumulatívna volatilita vykazuje fraktálne správanie
  - Ak vynecháme najväčšie pozorovanie, charakter grafu sa nezmení



# Zovšeobecnené Paretovo rozdelenie

- Distribučná funkcia Zovšeobecneného Paretovho rozdelenia (*Generalized Pareto Distribution* – GPD)


$$G_{\xi, \beta}(x) = \begin{cases} 1 - (1 + \xi x / \beta)^{-1/\xi} & \xi \neq 0, \\ 1 - \exp(-x / \beta) & \xi = 0, \end{cases}$$

- Parameter  $\xi = \textit{shape parameter}$ .
  - Pre  $\xi > 0$  je to rozdelenie s ťažkými chvostami (Paretovo s  $\alpha = 1/\xi$ )
  - $k$ -ty moment neexistuje pre  $k \geq 1/\xi$
  - Pre  $\xi = 0$  je to exponenciálne rozdelenie
  - Pre  $\xi < 0$  ide o rozdelenie na ohraničenom intervale  $[0, -\beta/\xi]$  (tzv. Pareto type II distribution)
- Parameter  $\alpha = 1/\xi$  sa nazýva *tail index*



# Zovšeobecnené Paretovo rozdelenie

- Hustota GPD



# Peaks over threshold

- GPD sa používa na modelovanie chvostov rozdelenia, t.j. pre dáta prekračujúce istú hranicu (*peaks over threshold*), pričom sa modeluje veľkosť tohto prekročenia
- Excess distribution ( $u = \text{threshold}$ ):

$$F_u(x) = P(X - u \leq x \mid X > u) = \frac{P(X - u \leq x \wedge X > u)}{P(X > u)} = \frac{F(x+u) - F(u)}{1 - F(u)}$$

(rozdelenie veľkostí prekročenia nad prahovou hodnotou  $u$  za predpokladu, že dôjde k jej prekročeniu)

# GDP je dobrá aproximácia

**Veta** [Balkema and de Haan, 1974, Pickands, 1975]:

Pre veľkú triedu rozdelení možno nájsť takú funkciu  $\beta(u)$ , že platí

$$\lim_{u \rightarrow x_F} \sup_{0 \leq x < x_F - u} |F_u(x) - G_{\xi, \beta(u)}(x)| = 0$$

Označenie:

- $x_F$  = pravý krajný bod rozdelenia
- $u$  = threshold
- $F_u$  = excess distribution function

Táto trieda rozdelení zahŕňa všetky štandardné rozdelenia (normálne, lognorm., chí-kvadrát, t, F, beta, gamma, exp., rovnomerné...)

Interpretácia: Podmienené rozdelenie veľkostí prekročenia nad prahovou hodnotou možno „asymptoticky“ modelovať pomocou GPD

# Peaks over threshold

- Otázky:
  - Ako tieto výsledky môžem využiť v praxi (napr. pri výpočte VaR)?
  - Ako zistiť, či je takýto model pre moje dáta dobrý?
  - Ako mám odhadnúť parametre  $(\xi, \beta)$ ?
  - Ako mám nastaviť threshold  $(u)$ ?

# Výpočet VaR pomocou GPD

- Predpokladajme, že poznáme hodnoty oboch parametrov ( $\xi, \beta$ ) aj prahovú hodnotu ( $u$ )
- Označme  $x$  veľkosť prekročenia nad prahovou hodnotou (pokiaľ k takémuto prekročeniu dôjde)
- Potom platí:

$$GPD(x) \approx F_u(x) = \frac{F(x+u) - F(u)}{1 - F(u)}, \quad \text{kde } F(u) = \frac{N - N_u}{N}, \quad N_u = \text{pocet prekroceni}$$

$$F(x+u) = (1 - F(u))GPD(x) + F(u) = \frac{N_u}{N}GPD(x) + \frac{N - N_u}{N}$$

$$\text{Ak položíme } F(x_\alpha + u) = \alpha \Rightarrow x_\alpha = GDP^{-1}\left(\left(\alpha - 1\right)\frac{N}{N_u} - 1\right) = \frac{\beta}{\xi} \left[ \left( (1 - \alpha) \frac{N}{N_u} \right)^{-\xi} - 1 \right]$$

- Preto 
$$VaR_\alpha = u + x_\alpha = u + \frac{\beta}{\xi} \left[ \left( (1 - \alpha) \frac{N}{N_u} \right)^{-\xi} - 1 \right]$$

# Mean excess function

- Mean excess function vyjadruje priemernú podmienenú veľkosť prekročenia nad prahovou hodnotou (za predpokladu, že k prekročeniu došlo):

$$e_u(x) = E(X - u \mid X > u)$$

- Túto funkciu možno využiť:
  - Na overenie správnosti modelu
  - Na odhad prahovej hodnoty

# Mean excess function

- Pre GPD je charakteristické, že  $e_u(x)$  je lineárna v  $u$ :

$$e_u^{GPD_{\xi, \beta}}(x) = E(X - u \mid X > u) = \frac{\beta + \xi u}{1 - \xi}$$

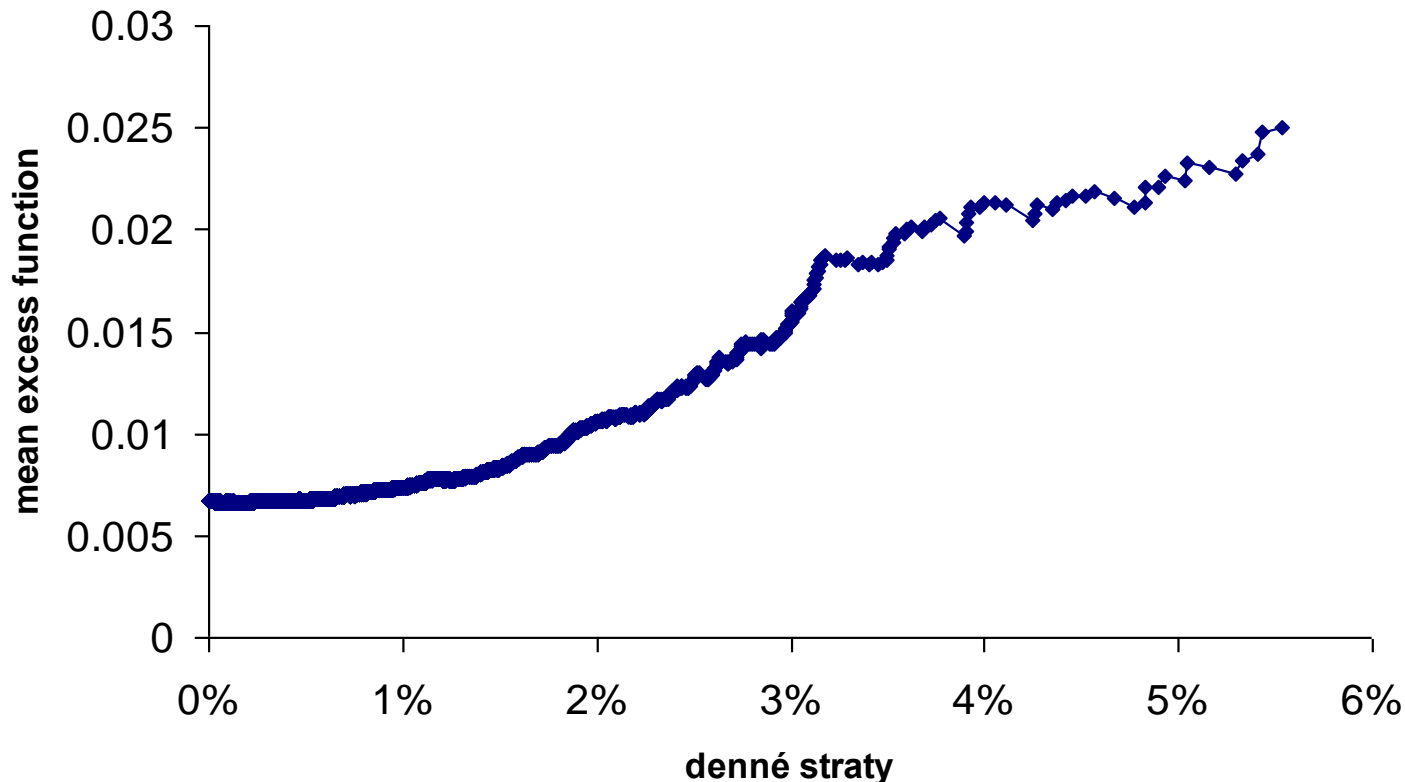
- Empirický výpočet:

$$e^{EMP}(u) = \frac{\sum_{i=1}^n \max(X_i - u, 0)}{\sum_{i=1}^n I_{\{X_i > u\}}}$$

- Overenie modelu: Pre dost' veľké  $u$  by mala byť táto funkcia približne lineárna (sklon závisí od shape parametra)
- Určenie prahovej hodnoty: Vykreslíme graf  $(X_i, e^{EMP}(X_i))$  a zvolíme  $u = X_j$ , od ktorého je graf približne lineárny (tzv. sample mean excess plot)

# Mean excess function

- Mean excess plot pre denné straty S&P 500, 1950-2011 (posledných 0.25% dát bolo vynechaných kvôli nestabilite odhadov)
- Ukazuje na prahovú hodnotu cca 3.2 % (= 99 %-ný kvantil)





# Metódy odhadu

- **Maximum likelihood**

- Odhad štandardnej odchýlky odhadov (intervaly spoľahlivosti)
- Možnosť štatistického testovania, či ide o rozdelenie s ťažkými chvostami
- Jednoduchá implementácia v Matlabe

```
q = quantile(losses,.95); % 95% quantile
y = losses(losses>q) - q; % exceedances

[parameters,confidence_interval]=gpfit(y);
xi=parameters(1) % shape parameter
alpha=1/xi % tail index
beta=parameters(2) % scale parameter
```

- **Hill estimator**



- Odhad iba parametra  $\alpha$ , nie parametra  $\beta$
- Na výpočet VaR to postačuje
- Výpočet je jednoduchý, implementovateľný v Exceli!

# Hill estimator

- Alternatívna metóda odhadu parametra  $\alpha$
- Vychádza z ML odhadu mocninového koeficientu hustoty Paretovho rozdelenia
- Distribučná funkcia Paretovho rozdelenia:  $F(x) = 1 - cx^{-\alpha}$
- Podmienená distribučná funkcia:  $F(x | x > u) = F(x)/(1 - F(u)) = (1 - cx^{-\alpha}) / (cu^{-\alpha})$
- Podmienená hustota:  $f(x | x > u) = \alpha x^{-\alpha-1} u^{\alpha} = \alpha (x/u)^{-\alpha} x^{-1}$
- ML odhad parametra  $\alpha$ : 
$$\frac{\partial \ln f}{\partial \alpha} = \frac{1}{\alpha} - \ln \frac{x}{u} \Rightarrow \frac{1}{\hat{\alpha}^{(k)}} = \frac{1}{k} \sum_{i=1}^k \ln \frac{X_{(i)}}{u}$$
- $(X_{(1)}, X_{(2)}, \dots)$  sú usporiadané hodnoty  $X_1, X_2, \dots$
- Prahovú hodnotu zvolíme tak, aby bol odhad  $\alpha(k)$  na nejakom intervale stabilný

# Hill estimator

- Odhad parametra  $\alpha$  pomocou Hillovho estimátora (S&P 500, 1950-2011)



# Pravidlá konvolúcie

- Konvolúcia:  $P(X + Y > t) = ?$

- Feller convolution theorem:

Ak  $X$  a  $Y$  majú Paretovo rozdelenie (i.i.d.), tak pre  $t$  dostatočne veľké platí

$$P(X + Y > t) \approx 2At^{-\alpha} = 2P(X > t)$$


- Náčrt dôkazu:

$$P(X + Y > t) \geq 1 - P(X \leq t, Y \leq t) = 1 - (1 - At^{-\alpha})^2 = 2At^{-\alpha} - A^2t^{-2\alpha}$$

- Interpretácia: Dôležité sú iba dáta popri osiach, priestor medzi nimi je „málo hustý“

# Pravidlá konvolúcie

- Scatter Plot pre realizácie dvoch nezávislých náhodných premenných so Studentovým t-rozdelením so 4 stupňami voľnosti (5000 realizácií)



# Pravidlá konvolúcie

- Aplikácia pre risk manažment:

Ak  $VaR(n)$  označíme ako VaR s holding period  $n$  pracovných dní, tak za predpokladu konštantnej úrovne pravdepodobnosti a v čase nezávislých strát platí

$$VaR(n) = n^{\frac{1}{\alpha}} VaR(1)$$

kde  $\alpha > 2$  je tail index.

- Dôkaz:  $P(X > VaR(1)) = AVaR(1)^{-\alpha} = p$   
 $P(nX > VaR(n)) = nAVaR(n)^{-\alpha} = p$   
 $\Rightarrow AVaR(1)^{-\alpha} = nAVaR(n)^{-\alpha}$   
 $\Rightarrow VaR(n) = n^{\frac{1}{\alpha}} VaR(1)$

- Dôsledok: Škálovací faktor je menší ako vyplýva z pravidla druhej odmocniny.

# Klasická EVT

- Klasická EVT študuje rozdelenie blokových maxím
- Maximum  $n$  pozorovaní:  $M_n := \max(X_1, \dots, X_n)$
- Otázka: Ako vypočítať  $P(M_n \leq x)$ , ak  $X_i$  sú i.i.d.?
- Platí:  $P(M_n \leq x) = P(X_1 \leq x, \dots, X_n \leq x) = F_n(x)$
- Existuje nejaké štandardné asymptotické rozdelenie pre maximá?
- Motivácia:
  - $F$  často nepoznáme
  - Pre sumu  $S_n := X_1 + \dots + X_n$  platí centrálna limitná veta:

$$\lim_{n \rightarrow \infty} P\left(\frac{S_n - a_n}{b_n} \leq x\right) = \Phi(x), \quad \text{kde } a_n = nE(X_1) \text{ a } b_n = \sqrt{\text{var}(X_1)}$$

# Klasická EVT

**VETA** (Fischer – Trippet, 1928): Ak vhodne normalizované maximá konvergujú v rozdelení k netriviálnemu limitnému rozdeleniu, potom musí ísť o tzv. generalized extreme value (GEV) distribution v tvare

$$H_{\xi}(x) = \begin{cases} \exp\left(-\left(1 + \xi x\right)^{-1/\xi}\right) & \xi \neq 0, \\ \exp\left(-e^{-x}\right) & \xi = 0, \end{cases}$$

Základné typy GEV rozdelení:

- Fréchetovo ( $\xi > 0$ ) [platí pre rozdelenia s ťažkými chvostami]
- Gumbelovo ( $\xi = 0$ ) [normálne, lognorm., exponenciálne, gamma, F,  $\chi^2$ ]
- Weibullovo ( $\xi < 0$ ) [rovnomerné]

Poznámky:

- Parameter  $\xi$  má tú istú hodnotu ako v GPD
- Distribučná funkcia GEV je spojitá v parametri  $\xi$
- V limitnej je vete stačí normované rozdelenie, pri aplikácii na dáta treba odhadnúť aj parameter strednej hodnoty a škálovania