

---

# NMFM301 – Statistika pro finanční matematiky

Opakování teoretické části

Teoretické cvičenie #5 | Zimní semestr 2024/2025

---

Posledné teoretické cvičenie pred prvou zápočtovou prácou je určené k opakovaniu teórie z prvých štyroch cvičení a k diskutovaniu správneho riešenia niektorých úloh zo série príkladov označených v zadaniach písmenom "B". Nižšie je uvedených niekoľko vybraných príkladov s podrobným riešením. Na záver je (bez explicitného riešenia) niekoľko vzorových príkladov z písomných zápočtových prác z minulých rokov. Tieto príklady slúžia k samostatnému precvičovaniu a tiež k ilustrácii konkrétnych problémov, ktoré lze očakávať na zápočtovej práci.

## Vybrané príklady zo série úloh B s riešením

### A1. [Séria 1, Príklad B3]

Pre nezávislé náhodné veličiny  $X, Y$  s exponenciálnym rozdelením  $Exp(\lambda)$  uvažujte náhodnú veličinu  $U$  definovanú nižšie a nájdite jej hustotu.

$$U = \frac{\min(X, Y)}{\max(X, Y)}$$

#### Riešenie:

Náhodné veličiny  $X, Y$  tvoria náhodný výber (keďže sú nezávislé a tiež rovnako rozdelené). Môžeme si tento náhodný výber označiť aj ako  $X_1, X_2$ , kde  $X_1 = X$  a  $X_2 = Y$ . Náhodné veličiny  $V = \min(X, Y)$  a  $W = \max(X, Y)$  tým pádom ale tvoria usporiadaný náhodný výber, t.j.  $(X_{(1)}, X_{(2)}) = (V, W) = (\min(X, Y), \max(X, Y))$ .

Veta 1.7 (Statistický větník na stránce kolegu Doc. Pešty) říká, že pre náhodný výber  $X_1, \dots, X_n$  z rozdelenia s hustotou  $f(x)$ , je združená hustota náhodného vektoru, ktorý je zároveň usporiadaným náhodným výberom, t.j. náhodného vektoru  $(X_{(1)}, \dots, X_{(n)})^\top$ , daná predpisom

$$f(x_1, \dots, x_n) = n!f(x_1) \dots f(x_n) \quad \text{pre } x_1 < \dots < x_n$$

a  $f(x_1, \dots, x_n) = 0$  jinak.

Pre náš konkrétny prípad to znamená, že náhodný vektor  $(V, W)^\top$  má hustotu

$$f(v, w) = 2!f(v)f(w) \quad \text{pre } 0 < v < w < \infty$$

a  $f(v, w) = 0$  inak. Prítom platí, že  $f(v) = \lambda \cdot e^{-\lambda v}$ , pre  $v > 0$  a analogicky aj pre  $f(w)$ . Hustota náhodného vektoru  $(V, W)^\top$  je teda

$$f_{(V,W)}(v, w) = 2\lambda^2 e^{-\lambda(v+w)}, \quad \text{pre } 0 < v < w < \infty.$$

Tým pádom je zároveň zrejmé, že náhodné veličiny  $V$  a  $W$  nie sú vzájomne nezávislé. Následne už len stačí definovať vhodnú transformáciu náhodného vektoru  $(V, W)^\top$  tak, aby sme dostali požadovanú náhodnú veličinu  $U = V/W$ . Použijeme nasledujúcu transformáciu:

$$t : \begin{pmatrix} V \\ W \end{pmatrix} \longrightarrow \begin{pmatrix} V/W \\ W \end{pmatrix} = \begin{pmatrix} U \\ W \end{pmatrix}.$$

Príslušné inverzné zobrazenie je

$$t^{-1} : \begin{pmatrix} U \\ W \end{pmatrix} \rightarrow \begin{pmatrix} U \cdot W \\ W \end{pmatrix} = \begin{pmatrix} V \\ W \end{pmatrix}.$$

Jakobián inverzného zobrazenia je

$$|J_{t^{-1}}| = \begin{vmatrix} w & u \\ 0 & 1 \end{vmatrix} = w,$$

tým pádom združená hustota náhodného vektoru  $(U, W)^\top$  je

$$f_{(U,W)}(u, w) = f_{(V,W)}(t_1^{-1}(u, w), t_2^{-1}(u, w)) \cdot |J_{t^{-1}}| = 2\lambda^2 e^{-\lambda u w} e^{-\lambda w} w,$$

pre  $u \in (0, 1)$  a  $w > 0$ . Zároveň sme využili značenie, kde  $t_1^{-1}$  predstavuje prvú zložku inverzného zobrazenia  $t^{-1}$  a analogicky aj  $t_2^{-1}$  označuje druhú zložku inverzného zobrazenia  $t^{-1}$ .

Požadovaná hustota náhodnej veličiny  $U$  sa získa preintegrovaním združenej hustoty  $f_{(U,W)}(u, w)$  vzhľadom k nadbytočnej premennej, t.j. premennej  $w$ . Platí teda

$$f_U(u) = \int_{\mathbb{R}} f_{(U,W)}(u, w) dw = \int_0^\infty 2\lambda^2 e^{-\lambda(u+1)w} w dw = \frac{2\lambda^2}{\lambda(u+1)} \int_0^\infty w \cdot \lambda(u+1) e^{-\lambda(u+1)w} dw,$$

pričom integrál nie je nič iné, ako stredná hodnota náhodnej veličiny s exponenciálnym rozdelením s parametrom  $\lambda \cdot (u+1)$  (kde  $u \in (0, 1)$ ). Hustota náhodnej veličiny  $U$  je preto

$$f_U(u) = \frac{2\lambda^2}{\lambda(u+1)} \cdot \frac{1}{\lambda(u+1)} = \frac{2}{(u+1)^2}, \quad \text{pre } u \in (0, 1)$$

a  $f_U(u) = 0$  inak.

## A2. [Séria 1, Príklad B10]

Pre náhodný výber  $X_1, \dots, X_n$  z rovnomerného rozdelenia na intervale  $(0, \theta)$  pre  $\theta > 0$  chceme ukázať, že náhodná veličina  $Z_n = n(1 - W_n/\theta)$  konverguje v distribúcii ku Gamma rozdeleniu, kde  $W_n = X_{(n)} - X_{(1)}$  je rozpätie náhodného výberu, teda maximum mínus minimum.

Náhodný výber pochádza zo spojitého rozdelenia. Označme príslušnú distribučnú funkciu ako  $F$  a hustotu ako  $f$ . Pre združené rozdelenie náhodného vektoru  $(X_{(1)}, W_n)^\top$  máme hustotu (bolo odvodené na prvom cvičení) v tvare

$$h_{(X_{(1)}, W_n)}(z, w) = n(n-1)f(z)f(z+w) \left[ F(z+w) - F(z) \right]^{n-2}, \quad \text{pro } z \in \mathbb{R} \text{ a } w > 0$$

a hustota je dodefinovaná nulou inak. Dosadením konkrétnej hustoty a distribučnej funkcie rovnomerného rozdelenia na intervale  $(0, \theta)$  získame združenú distribučnú funkciu náhodného vektoru  $(X_{(1)}, W_n)^\top$  v tvare

$$h_{(X_{(1)}, W_n)}(z, w) = n(n-1) \cdot \frac{1}{\theta} \mathbb{I}_{\{z \in (0, \theta)\}} \cdot \frac{1}{\theta} \mathbb{I}_{\{z+w \in (0, \theta)\}} \cdot \left[ \frac{z+w}{\theta} - \frac{z}{\theta} \right]^{n-2}, \quad \text{pro } z \in \mathbb{R} \text{ a } w > 0,$$

čo môžeme ešte upraviť do tvaru

$$h_{(X_{(1)}, W_n)}(z, w) = \frac{n(n-1)}{\theta^n} \cdot w^{n-2}, \quad \text{pro } z \in (0, \theta) \text{ a } w \in (0, \theta - z),$$

a hustota je nulová jinak (uvedomte si rolu jednotlivých indentifikátorov v zápise hustoty a následne obmedzenia na  $z$  a  $w$ ). Hustotu samotného rozpätia (t.j. náhodnej veličiny  $W_n$ ) získame preinte-grovaním, t.j.

$$\begin{aligned} f_{W_n}(w) &= \int_{\mathbb{R}} h_{(X_{(1)}, W_n)}(z, w) dz = \int_0^{\theta-w} \frac{n(n-1)}{\theta^n} w^{n-2} dz = \frac{n(n-1)}{\theta^n} w^{n-2} [z]_0^{\theta-w} \\ &= \frac{n(n-1)}{\theta^n} w^{n-2} \cdot (\theta - w), \quad \text{pre } w \in (0, \theta) \end{aligned}$$

příčemž hustota  $f_{W_n}(w)$  je definovaná nulou jinak. Máme teda vyjadrenú hustotu náhodnej veličiny  $W_n$  a pomoci vety o transformácii nájdeme hustotu pre náhodnú veličinu  $Z_n = n(1 - W_n/\theta)$ .

Príslušná transformácia (v značení pre prehľadnosť ponecháme závislosť na  $n \in \mathbb{N}$ ) má tvar

$$t_n : w \longrightarrow n \left(1 - \frac{w}{\theta}\right) =: z$$

a jedná sa o lineárnu transformáciu (prosté, klesajúce zobrazenie), ktorá zobrazuje interval  $(0, \theta)$  na interval  $(0, n)$ . Príslušné inverzné zobrazenie je

$$t_n^{-1} : z \longrightarrow \left(1 - \frac{z}{n}\right) \cdot \theta =: w$$

a tiež platí, že  $|(t_n^{-1})'(z)| = |-\theta/n| = \theta/n$ . Náhodná veličina  $Z_n$  má preto (z vety o transformácii) hustotu

$$\begin{aligned} f_{Z_n}(z) &= \frac{n(n-1)}{\theta^n} \left[\theta \left(1 - \frac{z}{n}\right)\right]^{n-2} \cdot \left(\theta - \theta \left(1 - \frac{z}{n}\right)\right) \cdot \frac{\theta}{n} \cdot \mathbb{I}_{\{z \in (0, n)\}} \\ &= \frac{n-1}{n} \left(1 - \frac{z}{n}\right)^{n-2} \cdot z \cdot \mathbb{I}_{\{z \in (0, n)\}}. \end{aligned}$$

Aby sme ukázali, že náhodná veličina  $Z_n$  konverguje pre  $n \rightarrow \infty$  v distribúcii k náhodnej veličine  $Y$ , ktorá má gamma rozdelenie, potrebujeme ukázať, že distribučná funkcia náhodnej veličiny  $Z_n$  konverguje v bodoch spojitosti k distribučnej funkcii náhodnej veličiny  $Y$ . Keďže v oboch prípadoch sa jedná o absolútne spojitú rozdelenie, môžeme ekvivalentne vyšetriť, či hustota  $f_{Z_n}$  bodovo konverguje k hustote gamma rozdelenia (označenie  $\Gamma(k, \alpha)$ ), ktorá je obecné definovaná predpisom

$$f_Y(y) = \frac{\alpha^k}{\Gamma(k)} y^{k-1} e^{-\alpha y}, \quad \text{pre } y > 0.$$

To bude následne implikovať aj konvergenciu distribučných funkcií (tzv. Scheffé-ho lemma). Limitným prechodom a postupným uvedením si nasledujúcich faktov:

- (a)  $\frac{n-1}{n} \xrightarrow{n \rightarrow \infty} 1$
- (b)  $(1 - z/n)^{n-2} \xrightarrow{n \rightarrow \infty} e^{-z}$
- (c)  $(0, n) \xrightarrow{n \rightarrow \infty} (0, \infty)$
- (d)  $\Gamma(2) = 1$

vpodstate dostaneme výsledok, že náhodná veličina  $Z_n$  konverguje v distribúcii pre  $n \rightarrow \infty$  k náhodnej veličine  $Y$  s gamma rozdelením  $\Gamma(2, 1)$ . Hustota  $f_{Z_n}$  bodovo konverguje k hustote  $f_Y(y) = \frac{1}{\Gamma(2)} y \cdot e^{-y} \cdot \mathbb{I}_{\{y > 0\}}$

**A3.** [Séria 3, Príklad B6]

Pre náhodný výber  $X_1, \dots, X_n$  z rovnomerného rozdelenia na intervale  $(0, \theta_X)$ , pre  $\theta_X > 0$ , je potrebné zostrojiť presný interval spoľahlivosti pre výberový medián, definovaný ako  $\hat{m}_X = X_{(k+1)}$ , pričom platí, že  $n = 2k + 1$ , pre  $n \in \mathbb{N}$ .

Riešenie:

V prvom rade je potrebné si uvedomiť, že teoretický medián v rovnomernom rozdelení na intervale  $(0, \theta_X)$  je  $m_X = \theta_X/2$ . Zároveň platí, že ak náhodné veličiny  $X_1, \dots, X_n$  majú rovnomerné rozdelenie na intervale  $(0, \theta_X)$ , tak potom náhodné veličiny  $X_1/\theta_X, \dots, X_n/\theta_X$  majú rovnomerné rozdelenie na intervale  $(0, 1)$  a teoretický medián je  $1/2$ . Ak je  $X_{(k+1)}$  teda  $(k+1)$ -vou pořadovou statistikou v usporiadanom náhodnom výbere  $X_{(1)}, \dots, X_{(n)}$ , tak potom  $X_{(k+1)}/\theta_X$  je  $(k+1)$ -vou pořadovou statistikou v usporiadanom náhodnom výbere  $X_{(1)}/\theta_X, \dots, X_{(n)}/\theta_X$ .

Obecne platí, že  $k$ -ta pořadová statistika v náhodnom výbere  $X_1, \dots, X_n$  zo spojitého rozdelenia s distribučnou funkciou  $F(x)$  a príslušnou hustotou  $f(x)$  má hustotu, ktorú lze vyjadriť ve tvaru

$$f_{(k)}(x) = n \binom{n-1}{k-1} f(x) [F(x)]^{k-1} [1-F(x)]^{n-k}, \quad \text{pre } x \in \mathbb{R}$$

a preto pre  $(k+1)$ -vú pořadovú statistiku (kde  $n = 2k + 1$ ) dostaneme

$$f_{(k+1)}(x) = n \binom{2k}{k} f(x) [F(x)]^k [1-F(x)]^k, \quad \text{pre } x \in \mathbb{R}.$$

Keďže náhodné veličiny  $X_1/\theta_X, \dots, X_n/\theta_X$  majú rovnomerné rozdelenie na intervale  $(0, 1)$  s distribučnou funkciou  $F(x) = x$  pre  $x \in (0, 1)$  (a  $F(x) = 0$  pre  $x < 0$  a  $F(x) = 1$ , pre  $x > 1$ ) a hustotou  $f(x) = \mathbb{1}_{\{x \in (0,1)\}}$ , tak  $(k+1)$ -vá pořadová statistika  $X_{(k+1)}/\theta_X$  má hustotu

$$f_{(k+1)}(x) = n \binom{2k}{k} x^k (1-x)^k \quad \text{for } x \in (0, 1) \text{ a } f_{(k+1)}(x) = 0 \text{ jinak.}$$

Náhodná veličina  $X_{(k+1)}/\theta_X$  má teda Beta rozdelenie s parametrami  $\alpha = k + 1$  a  $\beta = k + 1$ . Táto náhodná veličina je zároveň naším odhadom pre teoretický medián, teda hodnotu  $1/2$  (napr.  $\tilde{m}_X$ ).

Jedna z možností, ako zostrojiť presný interval spoľahlivosti pre medián, teda parameter  $m_X = \theta_X/2$  (ale táto možnosť nebola správna v zmysle požadovaného riešenia) by bolo využiť príslušné kvantily beta rozdelenia. Beta rozdelenie ale nepatrí k štandardným rozdeleniam v zmysle bežne tabulovaných kvantilov. Preto (v zmysle správneho riešenia) je nutné hľadať možnosť, ako využiť kvantily buď normálneho rozdelenia, studentovho  $t$  rozdelenia,  $\chi^2$  rozdelenia, alebo Fisherovho  $F$  rozdelenia (ktoré sú bežne tabulované v štatistických tabuľkách).

V tomto prípade použijeme to posledné—Fisherovo  $F$  rozdelenie. Obecně totiž platí, že pre náhodnú veličinu s beta rozdelením  $Z \sim \text{Beta}(\alpha/2, \beta/2)$  má transformovaná náhodná veličina  $\frac{\beta Z}{\alpha(1-Z)}$  Fisherovo  $F$  rozdelenie s  $\alpha$  a  $\beta$  stupňami voľnosti. V našom konkrétnom prípade teda dostávame, že ak

$$\frac{X_{(k+1)}}{\theta_X} \sim \text{Beta}(k+1, k+1) \implies \frac{2(k+1)X_{(k+1)}/\theta_X}{2(k+1)(1-X_{(k+1)}/\theta_X)} = \frac{X_{(k+1)}}{\theta_X - X_{(k+1)}} \sim F_{2(k+1), 2(k+1)}.$$

Pre príslušné kvantily (ktoré pre stručnosť označíme ako  $f_{\alpha/2}$  a  $f_{1-\alpha/2}$ ) z Fisherovho  $F$  rozdelenia s  $2k+2$  a  $2k+2$  stupňami voľnosti, môžeme písať

$$P \left[ f_{\alpha/2} \leq \frac{X_{(k+1)}}{\theta_X - X_{(k+1)}} \leq f_{1-\alpha/2} \right] = 1 - \alpha$$

a použitím ekvivalentných úprav tiež

$$P \left[ \frac{X_{(k+1)}}{f_{1-\alpha/2}} \leq \theta_X - X_{(k+1)} \leq \frac{X_{(k+1)}}{f_{\alpha/2}} \right] = P \left[ X_{(k+1)} + \frac{X_{(k+1)}}{f_{1-\alpha/2}} \leq \theta_X \leq X_{(k+1)} + \frac{X_{(k+1)}}{f_{\alpha/2}} \right] = 1 - \alpha.$$

Teď si už jenom stačí uvědomit, že máme konfidenční interval pro parameter  $\theta_X > 0$ , zatím co v zadání sme požadovali konfidenční interval pro parameter  $m_X = \theta_X/2$ . Stačí teda hornú a dolnú hranicu intervalu podelit hodnotou 1/2 a získame interval spoľehlivosti pro  $\theta_X/2$ , čo je vlastne parameter teoretického mediánu v rovnomernom rozdelení na intervale  $(0, \theta_X)$ .

**A4.** [Séria 3, Príklad B7]

Pre náhodný výber  $X_1, \dots, X_n$  z Poissonovho rozdelenia s parametrom  $\lambda > 0$  sestrojte pomoci CLV približný interval spoľehlivosti pro  $\lambda > 0$ . Pomoci CLV sestrojte také približný interval spoľehlivosti pro parameter  $\sqrt{\lambda}$  a tento interval využijte pro odvození približného intervalu spoľehlivosti pro  $\lambda > 0$ .

Riešenie:

Centrální limitní věta říká, že pro náhodný výběr  $X_1, \dots, X_n \sim Poiss(\lambda)$  (pre strednú hodnotu a rozptyl platí, že  $EX = \lambda$  a tiež  $VarX = \lambda$ ) máme

$$\sqrt{n}(\bar{X}_n - \lambda) \xrightarrow{\mathcal{D}} N(0, \lambda),$$

pre  $n \rightarrow \infty$ . Analogicky tiež

$$\sqrt{n} \frac{(\bar{X}_n - \lambda)}{\sqrt{\lambda}} \xrightarrow{\mathcal{D}} N(0, 1),$$

opäť pre  $n \rightarrow \infty$ . S využitím kvantilov normovaného normálneho rozdelenia dostávame

$$P \left[ u_{\alpha/2} \leq \sqrt{n} \frac{(\bar{X}_n - \lambda)}{\sqrt{\lambda}} \leq u_{1-\alpha/2} \right] \approx 1 - \alpha.$$

Problém ale nastane pri pokuse aplikovať ekvivalentné úpravy na výraz v zátvorke, aby sme osamostatnili uprostred neznámy parameter  $\lambda > 0$  a explicitne tak definovali dolnú a hornú medzu intervalu spoľahlivosti. Riešenie ponúka tzv. Cramér-Slutského veta, ktorá obecně říká, že ak

$$\left[ X_n \xrightarrow{\mathcal{D}} X \quad \text{a zároveň} \quad Y_n \xrightarrow{P} c \right] \implies X_n Y_n \xrightarrow{\mathcal{D}} cX.$$

Teda ak postupnosť náhodných veličín konverguje v distribúcií k nejakému limitnému rozdeleniu a postupnosť vynásobíme inou náhodnou veličinou, ktorá v pravdepodobnosti konverguje ku nenulovej konštante, tak potom súčin konverguje v distribúcií k povodnému limitnému rozdeleniu, ktoré je danou konštantou príslušne preškálované.

Pre potreby tohto príkladu využijeme Cramér-Slutského vetu následovne:

$$\underbrace{\sqrt{n} \frac{(\bar{X}_n - \lambda)}{\sqrt{\lambda}}}_{\rightarrow^{\mathcal{D}} N(0,1)} \cdot \underbrace{\frac{\sqrt{\lambda}}{\bar{X}_n}}_{\rightarrow^P 1} = \sqrt{n} \frac{(\bar{X}_n - \lambda)}{\sqrt{\bar{X}_n}} \xrightarrow{\mathcal{D}} N(0, 1).$$

Konvergenciu v distribúcií pre prvý výraz máme zaručenú centrálnou limitnou vetou. Druhý výraz konferguje k pravdepodobnosti k jednotke, čo plynie z vety o spojitaj transformácii, pretože  $\bar{X}_n$  (výberový priemer) je konzistentným odhadom parametru  $\lambda > 0$  (teoretickej strednej hodnoty). Inými slovami, neznámu sméodatnú chyby v jmenovateli zlomku jsme nahradili konzistentným odhadem. Konfidenční interval získame ekvivalentnými úpravami z následujúceho výrazu:

$$P \left[ u_{\alpha/2} \leq \sqrt{n} \frac{(\bar{X}_n - \lambda)}{\sqrt{\bar{X}_n}} \leq u_{1-\alpha/2} \right] \approx 1 - \alpha.$$

Pamätať na to, že sa jedná pouze o asymptoticky, resp. približný interval spoľahlivosti.

Pre druhú časť riešenia využijeme transformáciu  $g(x) = \sqrt{x}$ . Dostaneme teda

$$\sqrt{n}(g(\bar{X}_n) - g(\lambda)) \xrightarrow{\mathcal{D}} N(0, [g'(\lambda)]^2 \cdot \lambda).$$

Jedná sa o tzv. "rozptyl stabilizujúcu transformáciu", pretože  $g'(x) = \frac{1}{2\sqrt{x}}$  a  $[g'(\lambda)]^2 = \frac{1}{4\lambda}$  a je zrejmé, že neznámy parameter sa v asymptotickom rozptyle vykrátí. Asymptotický rozptyl teda nebude závisieť na neznámom parametri  $\lambda > 0$  a dostaneme

$$P \left[ u_{\alpha/2} \geq 2\sqrt{n}(\sqrt{\bar{X}_n} - \sqrt{\lambda}) \geq u_{1-\alpha/2} \right] \approx 1 - \alpha.$$

Aplikáciou ekvivalentných úprav získame požadovaný interval spoľahlivosti parameter  $\lambda > 0$ .

**A5.** [Séria 3, Príklad B10]

Pomocou náhodného výberu  $X_1, \dots, X_n$  z rozdelenia daného hustotou  $f(x, \theta) = \theta x^{\theta-1}$  pre  $x \in (0, 1)$  je potrebné zostrojiť presný interval spoľahlivosti a pomocou CLV aj približný interval spoľahlivosti pre  $\theta > 0$  (a nejaké vhodné  $\alpha \in (0, 1)$ ).

Riešenie:

Je dobré si uvedomiť, že sa jedná o Beta rozdelenie  $Beta(\theta, 1)$  so strednou hodnotou  $EX_1 = \frac{\theta}{\theta+1}$  a je prirodzené, že odhad parametru sa snažíme zostrojiť pomocou výberového priemeru  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$  (keďže je zrejma väzba medzi neznámym parametrom a strednou hodnotou). Potrebujeme ale poznať presné rozdelenie nejakej vhodnej pivotnej štatistiky – napr. náhodného súčtu  $\sum_{i=1}^n X_i$ , aby sme boli schopní zostrojiť presný interval spoľahlivosti. Využijeme k tomu transformáciu, ktorú ponúka zadanie, t.j.,  $t : Y_i = -\log X_i$ .

Hustota náhodnej veličiny  $Y_i$  je daná (z vety o transformácii) predpisom

$$f_Y(y) = f_X(t^{-1}(y)) \cdot |((t^{-1})'y)| = \theta(e^{-y})^{\theta-1} \cdot |-e^{-y}| = \theta e^{-\theta y},$$

pre  $y > 0$  a  $f_Y(y) = 0$  inak. Náhodné veličiny  $-\log X_1, \dots, -\log X_n$  majú teda exponenciálne rozdelenie s parametrom  $\theta > 0$  (tak, že stredná hodnota je  $E[-\log X_i] = 1/\theta$ ). Zároveň už poznáme vzťah medzi exponenciálnym rozdelením a Gamma rozdelením (prípadne  $\chi^2$  rozdelením). Exponenciálne rozdelenie s parametrom jedna polovina (t.j., stredná hodnota je 2) je to samé rozdelenie, ako  $Gamma(\lambda = \frac{1}{2}, n = 1)$ . Zároveň súčet  $n$  nezávislých náhodných veličín s exponenciálnym rozdelením s parametrom  $\lambda > 0$  má Erlangovo rozdelenie s parametrami  $n$  (velikosť součtu) a  $\lambda > 0$  – čo je vlastne  $Gamma(\lambda, n)$  rozdelenie. A nakoniec vieme, že  $Gamma(\frac{1}{2}, \frac{n}{2})$  je vlastne  $\chi^2$  rozdelenie s  $n$  stupňami voľnosti. Toto všetko potrebujeme využiť ku konštrukcii presného intervalu spoľahlivosti pre neznámy parameter  $\theta > 0$ .

Náhodný súčet  $-2\theta \sum_{i=1}^n \log X_i$  má Erlangovo rozdelenie  $Erlang(n, \frac{1}{2})$  (pretože stredná hodnota  $E[-2\theta \log X_i] = 2\theta E[-\log X_i] = 2$ , čo znamená, že náhodná veličina  $-2\theta \log X_i$  má exponenciálne rozdelenie s parametrom  $\lambda = \frac{1}{2}$ ).

Celkovo teda dostaneme, že

$$-2\theta \sum_{i=1}^n \log X_i \sim \Gamma\left(n, \frac{1}{2}\right) \equiv \chi_{2n}^2.$$

Pre presný interval spoľahlivosti nám stačí použiť kvantily  $\chi^2$  rozdelenia s  $2n$  stupňami voľnosti a dostaneme výraz

$$P \left[ \chi_{2n}^2(\alpha/2) \leq -2\theta \sum_{i=1}^n \log X_i \leq \chi_{2n}^2(1 - \alpha/2) \right] = 1 - \alpha.$$

Ekvivalentnými úpravami získame z predchádzajúceho výrazu potrebný (presný) interval spoľahlivosti pre neznámy parameter  $\theta > 0$ .

Pre približný interval spoľahlivosti použijeme Centrálnu limitnú vetu (CLV), vďaka ktorej vieme, že

$$\sqrt{n} \left( \frac{1}{n} \sum_{i=1}^n (-\log X_i) - \frac{1}{\theta} \right) \xrightarrow{\mathcal{D}} N \left( 0, \frac{1}{\theta^2} \right).$$

To zároveň znamená, že

$$\sqrt{n} \frac{\left( \frac{1}{n} \sum_{i=1}^n (-\log X_i) - \frac{1}{\theta} \right)}{\frac{1}{\theta}} \xrightarrow{\mathcal{D}} N(0, 1).$$

Použitím kvantilov štandardného normálneho rozdelenia získame výraz

$$P \left[ u_{\alpha/2} \leq \sqrt{n} \left( \frac{\theta}{n} \sum_{i=1}^n (-\log X_i) - 1 \right) \leq u_{1-\alpha/2} \right] \approx 1 - \alpha$$

a pomocou ekvivalentných úprav získame konečný výraz pre približný interval spoľahlivosti pre neznámy parameter  $\theta > 0$ .