
NMFM301 – Statistika pro finanční matematiky

1. Zápočtová písemná práce | 03. 11. 2021 | Varianta A

(Celkově 20 bodů | Čas: 90 minut)

1. (12 bodů) Uvažujte náhodný výběr X_1, \dots, X_n s hustotou danou předpisem

$$f_\theta(x) = \frac{x}{\theta^2} \exp\left\{-\frac{x^2}{2\theta^2}\right\} \cdot \mathbb{I}_{\{x>0\}}, \quad \text{pro } \theta \in (0, \infty).$$

(a) Najděte odhad $\tilde{\theta}_n$ parametru θ metodou maximální věrohodnosti. [2]

Vierohodnostná funkcia má tvar

$$L(\mathbb{X}, \theta) = \prod_{i=1}^n \left[\frac{X_i}{\theta^2} \exp\left\{-\frac{X_i^2}{2\theta^2}\right\} \right] = \theta^{-2n} \left(\prod_{i=1}^n X_i \right) \exp\left\{-\frac{\sum_{i=1}^n X_i^2}{2\theta^2}\right\}$$

a logaritmická vierohodnostná funkcia je

$$l(\mathbb{X}, \theta) = (-2n) \log \theta + \sum_{i=1}^n \log X_i - \frac{\sum_{i=1}^n X_i^2}{2\theta^2}.$$

Maximálne vierohodný odhad získame riešením skórovej rovnice

$$\frac{\partial}{\partial \theta} l(\mathbb{X}, \theta) = \frac{-2n}{\theta} + \frac{\sum_{i=1}^n X_i^2}{\theta^3} := 0.$$

Jednoduchými úpravami získame maximálne vierohodný odhad neznámeho parametru $\theta > 0$ ve tvaru

$$\tilde{\theta}_n = \sqrt{\frac{\sum_{i=1}^n X_i^2}{2n}},$$

a keďže je zadaná hustota exponenciálneho typu (t.j., splnené sú podmienky regularity), tak sa jedná naozaj o globálne maximum vierohodnostnej funkcie. ■

(b) Spočítajte asymptotické rozdelení odhadu $\tilde{\theta}_n$ a sestrojte približný interval spoľahlivosti pro $\alpha = 0.05$ (využite fakt, že $\mathbb{E}X_i^2 = 2\theta^2$). [2]

Maximálne vierohodné odhady sú za platnosti podmienky regularity asymptoticky normálne a špeciálne platí, že

$$\sqrt{n}(\tilde{\theta}_n - \theta) \xrightarrow[n \rightarrow \infty]{\mathcal{D}} N(0, I^{-1}(\theta)),$$

kde $I(\theta) = I_n(\theta)/n$ a $I_n(\theta)$ je Fisherova informacia o parametru $\theta > 0$ obsiahnutá v náhodnom výbere o rozsahu $n \in \mathbb{N}$. Zároveň platí, že

$$\begin{aligned} I_n(\theta) &= -E \left[\frac{\partial^2}{\partial \theta^2} l(\mathbb{X}, \theta) \right] = -E \left[\frac{\partial}{\partial \theta} \left(\frac{-2n}{\theta} + \frac{\sum_{i=1}^n X_i^2}{\theta^3} \right) \right] \\ &= -E \left[\frac{2n}{\theta^2} - \frac{3 \sum_{i=1}^n X_i^2}{\theta^4} \right] = -\frac{2n}{\theta^2} + \frac{3n(2\theta^2)}{\theta^4} = \frac{4n}{\theta^2}, \end{aligned}$$

prícom sme v predposlednom kroku (namiesto počítania strednej hodnoty $\mathbb{E}X_i^2$ z definície pomocou integrálu) využili ponúkaný "hint", že $\mathbb{E}X_i^2 = 2\theta^2$.

Asymptotické rozdelenie maximálne vierohodného odhadu $\tilde{\theta}_n$ je teda

$$\sqrt{n}(\tilde{\theta}_n - \theta) \xrightarrow[n \rightarrow \infty]{\mathcal{D}} N(0, \theta^2/4)$$

a pre konkrétne $\alpha \in (0, 1)$ dostaneme (približný) interval spoľahlivosti v tvare

$$P \left[\theta \in (\tilde{\theta}_n \pm u_{1-\alpha/2} \theta / 2\sqrt{n}) \right] \approx 1 - \alpha.$$

■

(c) Najdte odhad $\hat{\theta}_n$ parametru θ pomoci momentové metody. [2]

Tu sa síce ponúka možnosť spočítať strednú hodnotu (t.j. integrovať pomocou per-partes), ale najjednoduchšie je opäť využiť ponúkaný "hint", že $EX_i^2 = 2\theta^2$. Neznámy parameter teda dávame do vzťahu s druhým momentom a získame

$$\theta = \sqrt{\frac{EX_i^2}{2}}.$$

Hustota je nenulová na kladnej poloose, pre neznámy parameter platí, že $\theta > 0$, teda všetko je správne definované. Druhý moment konzistentne odhadneme výberovým priemerom

$$\widehat{EX_i^2} = \frac{1}{n} \sum_{i=1}^n X_i^2$$

a dosadíme do predchádzajúceho výrazu. Momentový odhad neznámeho parametru $\theta > 0$ je definovaný predpisom

$$\hat{\theta}_n = \sqrt{\frac{1}{2n} \sum_{i=1}^n X_i^2}.$$

Odhad získaný momentovou metódou je teda totožný s odhadom získaným metódou maximálnej vierohodnosti. ■

(d) Pomoci centálnej limitnej vety a transformácie $g(\theta) = \sqrt{\theta/2}$ nájdte asymptotické rozdelenie momentového odhadu $\hat{\theta}_n$. [2]

V prvom rade je dobré si uvedomiť, že ponúkaná transformácia je presne tou transformáciou, ktorá dáva do súvislosti výberový priemer náhodných veličín X_1^2, \dots, X_n^2 (teda empirický odhad druhého momentu $\widehat{EX_i^2}$) a neznámy parameter $\theta > 0$. Použijeme preto CLV pre nezávislé a rovnako rozdelené náhodné veličiny X_1^2, \dots, X_n^2 a následne ponúkanú transformáciu. Z CLV dostaneme, že

$$\sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n X_i^2 - EX_i^2 \right) \xrightarrow[n \rightarrow \infty]{\mathcal{D}} N(0, Var X_i^2),$$

pričom platí, že $EX_i^2 = 2\theta^2$ ("hint") a $Var(X_i^2) = EX_i^4 - (EX_i^2)^2$. Stačí teda spočítať štvrtý moment

$$EX_i^4 = \int_0^\infty \frac{x^5}{\theta^2} \exp \left\{ -\frac{x^2}{2\theta^2} \right\} dx = \left| \begin{array}{l} \text{subst.} \\ x^2 = y \\ 2xdx = dy \end{array} \right| = \int_0^\infty \frac{y^2}{2\theta^2} \exp \left\{ -\frac{y}{2\theta^2} \right\} dy.$$

V tomto momente je výhodné si uvedomiť, že posledný integrál je vlastne druhý moment nejakej náhodnej veličiny, ktorá ma exponenciálne rozdelenie s parametrom $\lambda = 1/2\theta^2$ (a strednou hodnotou $2\theta^2$ a rozptylom $4\theta^4$ a teda druhým momentom $4\theta^4 + (2\theta)^2$, keďže všeobecne platí, že $Var X = EX^2 - (EX)^2$). Preto stačí využiť znalosť strednej hodnoty a rozptylu v exponenciálnom rozdelení a integrál nie je nutné manuálne počítať. Preto dostaneme, že $EX_i^4 = 4\theta^2 + (2\theta)^2 = 8\theta^4$ a $Var X_i^2 = 8\theta^4 - (2\theta^2)^2 = 4\theta^4$.

Máme teda asymptotické rozdelenie (vďaka CLV) v tvare

$$\sqrt{n} \left(\frac{1}{n} \sum_{i=1}^n X_i^2 - EX_i^2 \right) \xrightarrow[n \rightarrow \infty]{\mathcal{D}} N(0, 4\theta^4)$$

a transformácia v zadaní presne transformuje parameter strednej hodnoty na neznámy parameter $\theta > 0$, resp. výberový priemer $\frac{1}{n} \sum_{i=1}^n X_i^2$ na momentový odhad neznámeho parametru, teda

$$g \left(\frac{1}{n} \sum_{i=1}^n X_i^2 \right) = \sqrt{\frac{1}{2n} \sum_{i=1}^n X_i^2} = \hat{\theta}_n.$$

Použitím transformácie všeobecne dostaneme

$$\sqrt{n} \left[g \left(\frac{1}{n} \sum_{i=1}^n X_i^2 \right) - g(EX_i^2) \right] \xrightarrow[n \rightarrow \infty]{\mathcal{D}} N(0, [g'(EX_i^2)]^2 \cdot Var X_i^2)$$

a špecificky, pre konkrétny tvar transformačnej funkcie

$$\sqrt{n} [\hat{\theta}_n - \theta] \xrightarrow[n \rightarrow \infty]{\mathcal{D}} N(0, [g'(EX_i^2)]^2 \cdot Var X_i^2).$$

Keďže $[g'(\theta)]^2 = [1/4 \cdot \sqrt{2/\theta}]^2 = 1/8\theta$, tak $[g'(EX_i^2)]^2 = 1/16\theta^2$ a celkovo teda

$$\sqrt{n} [\hat{\theta}_n - \theta] \xrightarrow[n \rightarrow \infty]{\mathcal{D}} N(0, \theta^2/4).$$

■

- (e) Porovnejte asymptotický rozptyl odhadov $\tilde{\theta}_n$ a $\hat{\theta}_n$. [2]

Rozptyl odhadu metódou maximálnej vierohodnosti a rozptyl odhadu momentovou metódou sú rovnaké. ■

- (f) Použite transformáciu $Y_i = X_i^2$ a pro $\alpha = 0.05$ sestrojte presný interval spoľahlivosti pro neznámy parameter $\theta > 0$. [2]

Cheme použiť transformáciu $t : x \rightarrow x^2 =: y$. Príslušná inverzná transformácia je $t^{-1} : y \rightarrow \sqrt{y} =: x$. Keďže hustota je nenulová pouze na kladnej časti reálnej osi, tak je transformácia prostá. Hustota náhodnej veličiny $Y_i = X_i^2$ je teda definovaná predpisom

$$f_Y(y) = f_\theta(t^{-1}(y)) \cdot |(t^{-1})'(y)| = \frac{\sqrt{y}}{2\theta^2} \exp \left\{ -\frac{(\sqrt{y})^2}{2\theta^2} \right\} \cdot \left| \frac{1}{2\sqrt{y}} \right| = \frac{1}{2\theta^2} \exp \left\{ -\frac{y}{2\theta^2} \right\},$$

pre $y > 0$ a hustota je definovaná nulou inak. Jedna sa o hustotu exponenciálneho rozdelenia s parametrom $\lambda = 1/2\theta^2$ (stredná hodnota je $2\theta^2$). Platí teda, že náhodné veličiny $Y_1/\theta^2, \dots, Y_n/\theta^2$ majú exponenciálne rozdelenie s parametrom $\lambda = 1/2$ (t.j.,

stredná hodnota 2). Súčet $n \in \mathbb{N}$ takýchto nezávislých náhodných veličín má tzv. Erlangovo rozdelenie s parametrami n a $1/2$ (čo je vlastne Gamma rozdelenie s rovnakými parametrami) a zo vzťahu medzi Gamma rozdelením a χ^2 rozdelením dostaneme, že

$$\frac{1}{\theta^2} \sum_{i=1}^n Y_i \sim \chi_{2n}^2.$$

Použitím kvantilov χ^2 rozdelenia s $2n$ stupňami voľnosti (pre stručnosť ich označme ako $q_{\alpha/2}$ a $q_{1-\alpha/2}$) dostaneme

$$P \left[q_{\alpha/2} \leq \frac{1}{\theta^2} \sum_{i=1}^n Y_i \leq q_{1-\alpha/2} \right] = 1 - \alpha$$

a ekvivalentnými úpravami získame (presný) interval spoľahlivosti pre neznámy parameter $\theta > 0$. ■

2. (8 bodů) Uvažujte náhodný výber X_1, \dots, X_{2n} z rozdelení s hustotou

$$f(x; \theta) = \theta x^{\theta-1} \mathbb{I}_{\{x \in (0,1)\}}, \quad x \in \mathbb{R};$$

kde $\theta > 0$ je neznámy parameter. Uvažujte transformáciu $W_i = -\log X_i$.

(a) Určete rozdění

$$Y = \sum_{i=1}^n W_i.$$

[2]

Uvažovaná transformácia je $t: x \rightarrow -\log x =: w$ a príslušná inverzná transformácia je $t^{-1}: w \rightarrow e^{-w} =: x$. Náhodná veličina W_i má teda rozdění dané hustotou

$$f_W(w) = f(t^{-1}(w); \theta) \cdot |(t^{-1})'(w)| = \theta(e^{-w})^{\theta-1} \cdot |-e^{-w}| = \theta e^{-\theta w},$$

pre $w > 0$ a hustota je definovaná nulou inak. Jedná sa teda o exponenciálne rozdění s parametrom $\lambda = \theta > 0$ (stredná hodnota je $1/\theta$). Náhodná veličina Y (čo je vlastne súčet nezávislých náhodných veličín s exponenciálnym rozdienením) má preto Erlangovo rozdění s parametrami $\lambda = \theta$ a $n \in \mathbb{N}$. Hustota náhodnej veličiny Y je daná predpisom

$$f_Y(y) = \frac{\theta^k y^{k-1} e^{-\theta y}}{(k-1)!},$$

pre $y > 0$ a nula inak. To je tiež gamma rozdění s parametrami $\theta > 0$ a $n \in \mathbb{N}$ (t.j., $Y \sim \Gamma(\theta, n)$). ■

(b) Určete rozdění

$$Z = \min_{i=n+1, \dots, 2n} W_i.$$

[2]

Už vieme, že náhodné veličiny W_i majú exponenciálne rozdění s parametrom $\theta > 0$ (stredná hodnota $1/\theta$) a sú vzájomne nezávislé. Príslušná distribučná funkcia (náhodnej

veličiny W_i) je $F_W(w) = 1 - e^{-\theta w}$ pre $w \geq 0$ a $F_W(w) = 0$ pre $w < 0$. Prvá pořadová statistika—t.j., minimum $Z = \min_{i=n+1, \dots, 2n} W_i$ —má distribučnú funkciu

$$F_Z(z) = 1 - [1 - F_W(z)]^n = 1 - [e^{-\theta z}]^n = 1 - e^{-n\theta z},$$

pre $z \geq 0$ a $F_Z(z) = 0$ pre $z < 0$. Jedná sa vlastne o exponenciálne rozdelenie s parametrom $\lambda = n\theta$ (stredná hodnota je $1/n\theta$). ■

(c) **Odvoďte rozdelení**

$$\frac{nZ}{Y + nZ}.$$

[2]

Náhodné veličiny Y a Z sú nezávislé, pretože pôvodné veličiny X_1, \dots, X_{2n} tvorili náhodný výber (t.j., nezávislé a rovnako rozdelené náhodné veličiny) a náhodná veličina Y je definovaná pomocou prvej poloviny pozorovaní, t.j., náhodných veličín X_1, \dots, X_n , zatiaľ čo náhodná veličina Z je definovaná pouze pomocou druhej poloviny pozorovaní, t.j., pozorovaní X_{n+1}, \dots, X_{2n} . Navyše, keďže $Z \sim \text{Exp}(n\theta)$ (stredná hodnota je $1/n\theta$), tak potom $nZ \sim \text{Exp}(\theta)$ (t.j., stredná hodnota je $\frac{1}{\theta}$).

Združené rozdelenie náhodného vektoru $(nZ, Y)^\top$ je preto definované ako súčin marginálnych rozdelení Y a nZ , to znamená, že

$$(nZ, Y)^\top \sim f_{(nZ, Y)}(z, y) = f_{nZ}(z)f_Y(y) = \theta e^{-\theta z} \cdot \frac{\theta^k y^{k-1} e^{-\theta y}}{(k-1)!},$$

pre $z > 0$ a $y > 0$ a hustota je definovaná nulou inak.

Využijeme transformáciu

$$t : \begin{pmatrix} nZ \\ Y \end{pmatrix} \rightarrow \begin{pmatrix} nZ \\ \frac{nZ}{Y+nZ} \end{pmatrix} =: \begin{pmatrix} U \\ V \end{pmatrix}$$

s príslušnou inverznou transformáciou

$$t^{-1} : \begin{pmatrix} U \\ V \end{pmatrix} \rightarrow \begin{pmatrix} U \\ \frac{U(1-V)}{V} \end{pmatrix} =: \begin{pmatrix} Z \\ Y \end{pmatrix}$$

Jakobián inverzného zobrazenia je

$$|J_{t^{-1}}| = \begin{vmatrix} 1 & 0 \\ \frac{(1-V)}{V} & -\frac{U}{V^2} \end{vmatrix} = \frac{U}{V^2}.$$

Združená hustota náhodného vektoru $(U, V)^\top$ je teda

$$\begin{aligned} f_{(U, V)}(u, v) &= f_{nZ}(t_1^{-1}(u, v))f_Y(t_2^{-1}(u, v)) \cdot |J_{t^{-1}}| \\ &= \theta e^{-\theta u} \cdot \frac{\theta^k (u(1-v)/v)^{(k-1)} e^{-\theta(u(1-v)/v)}}{(k-1)!}. \end{aligned}$$

Požadované rozdelenie náhodnej veličiny $\frac{nZ}{Y+nZ}$ by sa získalo integrovaním združenej hustoty, teda

$$f_V(u) = \int_{\mathbb{R}} f_{(U, V)}(u, v) dv.$$

Pre účely správneho riešenia bolo postačujúce vyjadriť vhodnú transformáciu združeného vektoru a uviesť, že požadované rozdelenie získame vhodným preintegrovaním. ■

(d) Pomoci CLV spočítete přibližně pravděpodobnost

$$P[Y \leq \sqrt{n}]$$

[2]

Náhodná veličina Y je definovaná ako súčet $n \in \mathbb{N}$ nezávislých a rovnako rozdelených náhodných veličín W_1, \dots, W_n s exponenciálnym rozdelením s parametrom $\lambda = \theta$ (t.j., so strednou hodnotou $1/\theta$ a rozptylom $1/\theta^2$).

S využitím CLV preto postupnými ekvivalentnými úpravami dostaneme

$$\begin{aligned} P[Y \leq \sqrt{n}] &= P\left[\frac{1}{n} \sum_{i=1}^n W_i \leq \frac{\sqrt{n}}{n}\right] = P\left[\bar{W}_n - EW_1 \leq \frac{1}{\sqrt{n}} - EW_1\right] \\ &= P\left[\sqrt{n}(\bar{W}_n - EW_1) \leq (1 - \sqrt{n}/\theta)\right] = P\left[\sqrt{n} \frac{(\bar{W}_n - EW_1)}{\sqrt{\text{Var}W_1}} \leq (\theta - \sqrt{n})\right], \end{aligned}$$

pričom náhodná veličina na ľavej strane v poslednej pravdepodobnosti má z CLV asymptoticky normálne rozdelenie s nulovou strednou hodnotou a jednotkovým rozptylom. Označme distribučnú funkciu štandardizovaného normálneho rozdelenia (klasické značenie) ako $\Phi(x) = P[X \leq x]$, kde $X \sim N(0, 1)$.

Teda platí (asymptoticky, alebo približne), že

$$P[Y \leq \sqrt{n}] \approx \Phi(\theta - \sqrt{n}).$$

■

1. $X_1, \dots, X_n \sim f_{\theta}(x) = \frac{x}{\theta^2} e^{-\frac{x}{\theta^2}} \mathbb{1}_{\{x>0\}}, \theta \in (0, \infty)$

(a) odhad $\hat{\theta}_n$ parametru θ max. virohodnostou

$$L_n(\theta) = \prod_{i=1}^n \frac{x_i}{\theta^2} e^{-\frac{x_i}{\theta^2}} = \theta^{-2n} \prod_{i=1}^n x_i e^{-\frac{x_i}{\theta^2}} = \theta^{-2n} \prod_{i=1}^n x_i e^{-\frac{\sum x_i}{\theta^2}}$$

$$l_n(\theta) = \log[L_n(\theta)] = \log\left[\theta^{-2n} \prod_{i=1}^n x_i e^{-\frac{\sum x_i}{\theta^2}}\right] = -2n \log \theta + \sum_{i=1}^n \log x_i - \frac{\sum x_i}{\theta^2}$$

$$U_n(\theta) = \frac{\partial}{\partial \theta} [l_n(\theta)] = \frac{\partial}{\partial \theta} \left[-2n \log \theta + \sum_{i=1}^n \log x_i - \frac{\sum x_i}{\theta^2}\right] = -\frac{2n}{\theta} + \frac{\sum x_i}{\theta^3}$$

$$-\frac{2n}{\theta} + \frac{\sum x_i}{\theta^3} = 0$$

$$\frac{\sum x_i}{\theta^3} = \frac{2n}{\theta}$$

$$\theta \sum x_i = 2n\theta^3$$

$$\sum x_i = 2n\theta^2$$

$$\theta^2 = \frac{\sum x_i}{2n}$$

$$\theta = \sqrt{\frac{\sum x_i}{2n}}$$

(b) asymptotické rozdělení odhadu $\hat{\theta}_n$ + přibližný interval spolehlivosti pro $\alpha = 0,05$

(využít $EX_i^2 = 2\theta^2$)

$$I_n(\theta) = -E\left[\frac{\partial}{\partial \theta} \left(-\frac{2n}{\theta} + \frac{\sum x_i}{\theta^3}\right)\right] = -E\left[\frac{2n}{\theta^2} - \frac{3}{\theta^4} \sum_{i=1}^n x_i^2\right] = \frac{-2n}{\theta^2} + \frac{3}{\theta^4} E\left[\sum_{i=1}^n x_i^2\right] = \frac{-2n}{\theta^2} + \frac{6n}{\theta^2} = \frac{4n}{\theta^2}$$

$$I(\theta) = \frac{1}{n} \frac{4n}{\theta^2} = \frac{4}{\theta^2}; \quad I^{-1}(\theta) = \frac{\theta^2}{4}$$

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{D} N\left(0, \frac{\theta^2}{4}\right) \rightsquigarrow P\left[\theta \in \left(\hat{\theta}_n \pm u_{1-\frac{\alpha}{2}} \frac{\theta}{2\sqrt{n}}\right)\right] \approx 1 - \alpha$$

(c) odhad $\hat{\theta}_n$ parametru θ momentovou metodou

$$EX^2 = 2\theta^2$$

$$\theta^2 = \frac{EX^2}{2}$$

$$\theta = \sqrt{\frac{EX^2}{2}}; \quad \hat{EX}^2 = \frac{1}{n} \sum_{i=1}^n x_i^2$$

$$\Rightarrow \hat{\theta}_n = \sqrt{\frac{\frac{1}{n} \sum_{i=1}^n x_i^2}{2}} = \sqrt{\frac{1}{2n} \sum_{i=1}^n x_i^2}$$

(d) pomocí CLV a transformace $g(\theta) = \sqrt{\frac{\theta}{2}}$ do rozl. momentového odhadu

CLV: $\sqrt{n}(\bar{X}_n^2 - EX^2) \xrightarrow{D} N\left(0, \frac{\theta^2}{4}\right)$

$$\sqrt{n}(\bar{X}_n^2 - EX^2) \xrightarrow{D} N\left(0, \text{Var} X_i^2\right)$$

$$= 2\theta^2$$

$$\text{Var} X_i^2 = EX_i^4 - (EX_i^2)^2 = 8\theta^4 - 4\theta^4 = 4\theta^4$$

$$\sqrt{n}(\bar{X}_n^2 - EX^2) \xrightarrow{D} N\left(0, 4\theta^4\right)$$

$$= \int_0^{\infty} x^4 \frac{x}{\theta^2} e^{-\frac{x}{\theta^2}} dx = \int_0^{\infty} \frac{x^5}{\theta^2} e^{-\frac{x}{\theta^2}} dx \stackrel{y=x/\theta^2}{=} \int_0^{\infty} \frac{y^5}{2\theta^2} e^{-y} dy = \int_0^{\infty} \frac{1}{2\theta^2} e^{-y} dy \cdot \int_0^{\infty} y^5 e^{-y} dy = \frac{1}{2\theta^2} \cdot 4! = \frac{24}{2\theta^2} = \frac{12}{\theta^2}$$

$$\hookrightarrow EY^2 = \text{Var} Y + (EY)^2 = 4\theta^4 + 4\theta^4 = 8\theta^4$$

$$\rightarrow \Delta \cdot g(\epsilon) = \sqrt{\frac{\epsilon}{2}}$$

$$g'(\epsilon) = \frac{1}{\sqrt{2}} \cdot \frac{1}{2\sqrt{\epsilon}} = \frac{1}{2\sqrt{2\epsilon}} \quad ; \quad (g'(\epsilon))^2 = \frac{1}{8\epsilon}$$

$$\sqrt{n} (g(\bar{X}_n^2) - g(EX^2)) \xrightarrow{D} N(0, g'(EX^2) \text{Var} X_i^2 g'(EX^2))$$

$$\sqrt{n} (\sqrt{\frac{1}{2n} \sum X_i^2} - \theta) \xrightarrow{D} N(0, 4\theta^4 \frac{1}{16\theta^2})$$

$$\sqrt{n} (\hat{\theta}_n - \theta) \xrightarrow{D} N(0, \frac{\theta^2}{4})$$

(e) porovnať as. rozptyl odhadov $\tilde{\theta}_n$ a $\hat{\theta}_n$

$$\tilde{\theta}_n : \frac{\theta^2}{4} = \frac{\theta^2}{4} : \hat{\theta}_n \quad \Rightarrow \text{ sú rovnaké }$$

(f) použiť transformáciu $Y_i = X_i^2$ a pro $\alpha = 0,05$ zostrojiť presný interval spoľahlivosti pro $\theta > 0$

$$X_i \xrightarrow{t} X_i^2 = Y_i \xrightarrow{\hat{c}} \sqrt{Y_i} = X_i$$

$$\begin{aligned} x^2 &= y & \hat{c}(y) &= \sqrt{y} \\ x &= \sqrt{y} & |\hat{c}'| &= \frac{1}{2\sqrt{y}} \end{aligned}$$

$$f_X(x) = \frac{x}{\theta^2} e^{-\frac{x^2}{2\theta^2}} \mathbb{1}\{x>0\}, \theta \in (0, \infty)$$

$$f_Y(y) = \frac{\sqrt{y}}{\theta^2} \exp\left\{-\frac{\sqrt{y}}{2\theta^2}\right\} \frac{1}{2\sqrt{y}} \mathbb{1}\{y \in (0, \infty)\} = \frac{1}{2\theta^2} \exp\left\{-\frac{\sqrt{y}}{2\theta^2}\right\} \mathbb{1}\{y>0\} \sim \text{Exp}\left(\frac{1}{2\theta^2}\right)$$

$$Y_i \sim \text{Exp}\left(\frac{1}{2\theta^2}\right) \rightarrow Y_1/\theta^2, \dots, Y_n/\theta^2 \sim \text{Exp}\left(\frac{1}{2}\right) \rightarrow \sum_{i=1}^n \frac{Y_i}{\theta^2} \sim \Gamma\left(\frac{1}{2}, n\right) \equiv \chi_{2n}^2$$

$\frac{r}{2} = n \Rightarrow r = 2n$

$$P\left[q_{\frac{\alpha}{2}} < \frac{1}{\theta^2} \sum_{i=1}^n Y_i < q_{1-\frac{\alpha}{2}} \right] = 1 - \alpha \quad ; \quad \alpha = 0,05$$

.. atď. ekv. úpravy ale už mám dost (zamostatník θ)

2. $X_1, \dots, X_{2n} \sim f(x, \theta) = \theta x^{\theta-1} \mathbb{1}\{x \in (0, 1)\}, \theta > 0;$

transformace $W_i = -\log X_i$

(a) určit rozdělení $Y = \sum_{i=1}^n W_i$

$$X_i \xrightarrow{t} -\log X_i = W_i \xrightarrow{\hat{c}} e^{-W_i} = X_i$$

$$\begin{aligned} \log x^{-1} &= w & \tau(w) &= e^{-w} \\ e^w &= x^{-1} = \frac{1}{x} & |\tau'| &= e^{-w} \end{aligned}$$

$$x = e^{-w}$$

$$f_W(w) = \theta e^{-w(\theta-1)} e^{-w} \mathbb{1}\{w>0\} = \theta e^{-w\theta} \mathbb{1}\{w>0\} \sim \text{Exp}(\theta)$$

$$W_i \sim \text{Exp}(\theta) \rightarrow \Gamma(\theta, n) \Rightarrow f_Y(y) = \frac{\theta^n}{\Gamma(n)} y^{n-1} e^{-\theta y} \mathbb{1}\{y \in (0, \infty)\}$$

(b) určit rozdělení $Z = \min_{i=1, \dots, n} W_i$

$$Z = W_{(1)} \sim F_{(1)}(z) = 1 - (1 - \underbrace{F_W(x)}_{W_i \sim \text{Exp}(\theta)})^n = 1 - e^{-\theta x n} \sim \text{Exp}(n\theta)$$

$$F_W = 1 - e^{-\theta x}$$

(c) odvodit rozdělení $\frac{nZ}{4+nZ}$

$$\left. \begin{array}{l} Z \sim \text{Exp}(n\theta) \rightarrow nZ \sim \text{Exp}(\theta) \sim \Gamma(\theta, 1) \\ Y \sim \Gamma(\theta, n) \end{array} \right\} Y + nZ \sim \Gamma(\theta, n+1)$$

$$Y \perp\!\!\!\perp Z \Rightarrow Y \perp\!\!\!\perp nZ$$

$$(nZ, Y)^T \sim f_{(nZ, Y)}(z, y) = f_{nZ}(z) f_Y(y) = \theta e^{-\theta z} \frac{\theta^n}{\Gamma(n)} y^{n-1} e^{-\theta y} \mathbb{1}_{\{(z, y) \in (0, \infty)^2\}} = \frac{\theta^{n+1}}{\Gamma(n)} y^{n-1} e^{-\theta(z+y)} \mathbb{1}_{\{(z, y) \in (0, \infty)^2\}}$$

$$\begin{pmatrix} nZ \\ Y \end{pmatrix} \xrightarrow{t} \begin{pmatrix} nZ \\ \frac{nZ}{Y+nZ} \end{pmatrix} = \begin{pmatrix} U \\ V \end{pmatrix} \xrightarrow{c} \begin{pmatrix} U \\ \frac{U}{V} - U \end{pmatrix} = \begin{pmatrix} nZ \\ Y \end{pmatrix}$$

$$\frac{nZ}{Y+nZ} = v \rightarrow \frac{\mu}{y+\mu} = v$$

$$\begin{aligned} \mathcal{E}_1(\mu, v) &= \mu \\ \mathcal{E}_2(\mu, v) &= \frac{\mu}{v} - \mu \end{aligned}$$

$$\mu = vy + v\mu$$

$$\mu = v(y + \mu)$$

$$\frac{\mu}{v} = y + \mu$$

$$\frac{\mu}{v} - \mu = y$$

$$|J_{\mathcal{E}}| = \begin{vmatrix} 1 & 0 \\ \frac{1}{v} - 1 & -\frac{\mu}{v^2} \end{vmatrix} = \frac{\mu}{v^2}$$

$$f_{U, V}(\mu, v) = f_{nZ, Y}(\mathcal{E}(\mu, v)) |J_{\mathcal{E}(\mu, v)}| \mathbb{1}_{\{(\mu, v) \in (0, 1) \times (0, \infty)\}}$$

potom $f_V(\mu) = \int_{\mathcal{R}} f_{U, V}(\mu, v) d\mu$

(d) pomocou CLV spočítat približne pravdepodobnosť $\mathcal{P}[Y \leq \sqrt{n}]$

$$Y = \sum_{i=1}^n W_i \sim \Gamma(\theta, n)$$

$$W_i \sim \text{Exp}(\theta)$$

$$\mathcal{P}[Y \leq \sqrt{n}] = \mathcal{P}\left[\sum_{i=1}^n W_i \leq \sqrt{n}\right] = \mathcal{P}\left[\frac{1}{n} \sum W_i \leq \frac{\sqrt{n}}{n}\right] = \mathcal{P}\left[\bar{W}_n \leq \frac{\sqrt{n}}{n}\right] = \mathcal{P}\left[\bar{W}_n - EW \leq \frac{1}{\sqrt{n}} - EW\right] =$$

$$= \mathcal{P}\left[\sqrt{n}(\bar{W}_n - EW) \leq \sqrt{n}(1 - \sqrt{n}EW)\right] = \mathcal{P}\left[\sqrt{n} \frac{\bar{W}_n - EW}{\sqrt{\text{Var}W}} \leq \sqrt{n}\left(1 - \frac{\sqrt{n}}{\theta}\right)\right] =$$

$$= \mathcal{P}\left[\sqrt{n} \frac{\bar{W}_n - EW}{\sqrt{\text{Var}W}} \leq \right]$$

