
NMFM301 – Statistika pro finanční matematiky

Metoda maximální věrohodnosti a momentová metoda.

Podrobné riešenie príkladov zo 4. cvičenia

A Příklady na cvičení

Nechť X_1, \dots, X_n je náhodný výběr z rozdělení s hustotou $f(x|\theta_X) \in \mathcal{F} = \{f(x|\theta), \theta \in \Theta\}$.

A1. [Procvičovací] Momentovou metodou najděte odhad $\tilde{\theta}_n$ parametru $\theta_X > 23$ v modelu \mathcal{F} , kde

$$f(x|\theta_X) = \frac{\theta_X}{x^{\theta_X+1}} \mathbb{I}_{(1,\infty)}(x), \quad (\text{Paretovo rozdělení}).$$

Určete asymptotické rozdělení $\tilde{\theta}_n$.

[Použijte vztahy $\mathbb{E} X_i = \frac{\theta_X}{\theta_X - 1}$, $\text{var } X_i = \frac{\theta_X}{(\theta_X - 1)^2(\theta_X - 2)}$.]

Řešení:

Momentová metóda odhadovania je založena na existencii konkrétneho vzťahu (vzťahoch) ktorý (é) existuje (ú) medzi neznámym parametrom (resp. neznámymi parametrami) a niektorým teoretickým momentom (prípadne viacerými momentami). Stredná hodnota náhodnej veličiny je prvým momentom a spolu s druhým centroványm momentom (t.j., rozptyl náhodnej veličiny) sa jedná o dva najčastejšie využívané momenty v momentovej metóde odhadovania (samozrejme nie jediné).

Využijeme nápovedu, že stredná hodnota a rozptyl náhodnej veličiny s Paretovým rozdelením s parametrom $\theta_X > 2$ (parametrizácia hustoty ako v zadání), sú určené vzťahmi

$$\mu_X = \mathbb{E} X_i = \frac{\theta_X}{\theta_X - 1} \quad \text{a} \quad \sigma_X^2 = \text{var } X_i = \frac{\theta_X}{(\theta_X - 1)^2(\theta_X - 2)}.$$

Z prvého vzťahu jednoduchými úpravami vyjadrieme neznámy parameter ako

$$\theta_X = \frac{\mu_X}{\mu_X - 1}$$

a preto príslušný odhad $\tilde{\theta}_n$ neznámeho parametru θ_X získame nahradením teoretickej strednej hodnoty μ_X jej empirickým protějškem – výberovou strednou hodnotou, resp. priemerom \bar{X}_n . Momentový odhad preto je

$$\tilde{\theta}_n = \frac{\bar{X}_n}{\bar{X}_n - 1}.$$

Pre určenie asymptotického rozdelenia tohto odhadu použijeme centrálnu limitnú vetu (CLV) a vhodnú transformáciu. Vieme, že z CLV platí, že

$$\sqrt{n}(\bar{X}_n - \mu_X) \xrightarrow{\mathcal{D}} N(0, \sigma_X^2), \quad \text{pre } n \rightarrow \infty.$$

Pripomeňme, že sa jedná o tzv. konvergenciu v distribúcii. Tento vzťah popisuje asymptotické rozdelenie výberového priemera \bar{X}_n , t.j., odhadu neznámeho parametru strednej hodnoty μ_X . Nás ale zaujíma iný parameter, parameter θ_X , ktorý ale lze jednoducho vyjadriť pomocou μ_X .

Pripomeňme vzťah $\theta_X = \mu_X / (\mu_X - 1)$. Príslušná transformácia, ktorá prevedie parameter μ_X na θ_X má tvar

$$h(x) = \frac{x}{x-1}, \text{ pričom pre deriváciu zároveň platí } h'(x) = -\frac{1}{(x-1)^2}.$$

Zároveň vieme, že pre transformovaný parameter, resp. jeho empirický odhad (v zmysle obecnej transformácie h) môžeme vyjadriť asymptotické rozdelenie odhadu transformovaného parametru pomocou vzťahu (t.j., aproximácia Taylorovým rozvojom, resp. tzv. delta metóda)

$$\sqrt{n}(h(\bar{X}_n) - h(\mu_X)) \xrightarrow{\mathcal{D}} N(0, \sigma_X^2 \cdot [h'(\mu_X)]^2), \quad \text{opäť pre } n \rightarrow \infty.$$

Jednoduchým dostadením dostaneme, že $h(\mu_X) = \theta_X$ a tiež

$$|h'(\mu_X)| = \frac{1}{(\mu_X - 1)^2} = (\theta_X - 1)^2.$$

Z nápovedy v zadaní zároveň vieme, že

$$\sigma_X^2 = \text{var } X_i = \frac{\theta_X}{(\theta_X - 1)^2(\theta_X - 2)}.$$

Dohromady dostaneme, že asymptotické rozdelenie momentového odhadu $\tilde{\theta}_n$ je

$$\sqrt{n}(\tilde{\theta}_n - \theta_X) \xrightarrow{\mathcal{D}} N\left(0, \underbrace{\frac{\theta_X(\theta_X - 1)^2}{\theta_X - 2}}_{\sigma_{MM}^2}\right), \quad \text{pre } n \rightarrow \infty.$$

- A2.** [Provičovací] Metodou maximální věrohodnosti najděte odhad $\hat{\theta}_n$ parametru θ_X v modelu z předchozího příkladu. Určete asymptotické rozdelení $\hat{\theta}_n$ a porovnejte asymptotický rozptyl maximálně věrohodného odhadu $\hat{\theta}_n$ a momentového odhadu $\tilde{\theta}_n$.

Řešení:

Opäť nás zaujíma odhad toho istého parametru $\theta_X > 2$, ale príslušný odhad chceme zostrojiť tentokrát pomocou metódy maximálnej viero hodnosti. Viero hodnostná funkcia pre Paretovo rozdelenie a náhodný výber X_1, \dots, X_n z tohto rozdelenia, je daná predpisom

$$L(\theta_X, \mathbf{X}) = \prod_{i=1}^n \frac{\theta_X}{X_i^{\theta_X+1}} \cdot \mathbb{I}_{\{(1, \infty)\}}(X_i) = \theta_X^n \left(\prod_{i=1}^n X_i \right)^{-(\theta_X+1)},$$

pričom sa jedná o funkciu neznámeho parametru θ_X , výslednú v náhodnom výbere $\mathbf{X} = (X_1, \dots, X_n)$. Príslušnú logaritmickú viero hodnosť získame logaritmovaním

$$l(\theta_X, \mathbf{X}) = \log(L(\theta_X, \mathbf{X})) = n \log \theta_X - (\theta_X + 1) \sum_{i=1}^n \log X_i$$

a skórovú funkciu získame derivovaním logaritmickej viero hodnosti podľa argumentu θ_X , teda

$$U(\theta_X, \mathbf{X}) = \frac{\partial}{\partial \theta_X} l(\theta_X, \mathbf{X}) = \frac{n}{\theta_X} - \sum_{i=1}^n \log X_i.$$

Odhad metódou maximálnej vierochnosti získame tak, že skórovú rovnicu položíme rovnú hodnote nula a hľadáme riešenie vzhľadom k $\theta > 2$. To znamená, že riešime rovnicu

$$\frac{n}{\theta_X} - \sum_{i=1}^n \log X_i = 0,$$

ktoľorj explicitné riešenie (a zároveň maximálne vierochný odhad) je v tvare

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

K overeniu, že sa naozaj jedná o maximum (a nie napr. lokálne minimum), je potrebné overiť, že v danom bode je funkcia konkávná. Zároveň potrebujeme spočítať asymptotické rozdelenie odhadu $\hat{\theta}_n$, ktoré je dané predpisom

$$\sqrt{n}(\hat{\theta}_n - \theta_X) \xrightarrow{\mathcal{D}} N(0, \mathbf{I}^{-1}(\theta_X)), \quad \text{pre } n \rightarrow \infty,$$

kde $\mathbf{I}(\theta_X)$ je Fisherova informácia o neznámom parametre θ_X obsažená v náhodnej veličine X_i . Fisherová informácia o parametru θ_X obsažená v celom náhodnom výbere X_1, \dots, X_n je definovaná výrazom

$$\mathbf{I}_n(\theta_X) = -E\left[\frac{\partial^2}{\partial \theta_X^2} l(\theta_X, \mathbf{X})\right] = -E\left[\frac{\partial}{\partial \theta_X} U(\theta_X, \mathbf{X})\right] = -E\left[\frac{-n}{\theta_X^2}\right] = \frac{n}{\theta_X^2}.$$

Zároveň vidíme, že druhá derivácia logaritmickej vierochnosti je záporná a teda naozaj sa jedná o maximum. Taktiež platí (protože náhodné veličiny X_1, \dots, X_n sú nezávislé), že

$$\mathbf{I}_n(\theta_X) = n \cdot \mathbf{I}(\theta_X).$$

Dosadením dostaneme, že asymptotické rozdelenie maximálne vierochného odhadu $\hat{\theta}_n$, neznámeho parametru $\theta_X > 1$ je

$$\sqrt{n}(\hat{\theta}_n - \theta_X) \xrightarrow{\mathcal{D}} N(0, \underbrace{\theta_X^2}_{\sigma_{ML}^2}), \quad \text{opäť pre } n \rightarrow \infty.$$

Nakoniec chceme porovnať asymptotické rozptyly oboch odhadov. Jednoduchou úpravou dostaneme, že

$$\sigma_{MM}^2 = \frac{\theta_X(\theta_X - 1)^2}{\theta_X - 2} = \theta_X^2 \cdot \frac{\theta_X^2 - 2\theta_X + 1}{\theta_X^2 - 2\theta_X} > \theta_X^2 = \sigma_{ML}^2.$$

A3. [Procvičovací] Metódou maximální vierochnosti najděte odhad $\hat{\theta}_n$ parametru θ v modelu \mathcal{F} , kde

$$f(x|\theta) = \frac{\theta}{1-\theta} x^{(2\theta-1)/(1-\theta)} \mathbb{I}_{(0,1)}(x), \quad \theta \in (0, 1).$$

Určete asymptotické rozdelení $\hat{\theta}_n$.

Řešení:

Vierochnostná funkcia je daná predpisom

$$L(\theta, \mathbf{X}) = \prod_{i=1}^n f(X_i|\theta) = \left(\frac{\theta}{1-\theta}\right)^n \cdot \left(\prod_{i=1}^n X_i\right)^{\frac{2\theta-1}{1-\theta}}.$$

Opäť sa jedná o funkciu argumentu $\theta \in (0, 1)$, vyhodnotenú v náhodnom výbere $\mathbf{X} = (X_1, \dots, X_n)$. Príslušná logaritmická vieročodnosť má tvar

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

Skórovú funkciu získame derivovaním logaritmickej vieročodnosti podľa argumentu θ , teda

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

Riešením skórovej rovnice (ktorú sme položili rovnú hodnote nula) je maximálne vieročodný odhad:

$$\begin{aligned} \frac{n}{\theta(1 - \theta)} + \frac{1}{(1 - \theta)^2} \sum_{i=1}^n \log X_i &= 0 \\ (1 - \theta) + \theta_X \frac{1}{n} \sum_{i=1}^n \log X_i &= 0 \\ \theta(1 - \frac{1}{n} \sum_{i=1}^n \log X_i) &= 1 \\ \hat{\theta}_n &= \frac{1}{1 - \frac{1}{n} \sum_{i=1}^n \log X_i}. \end{aligned}$$

Opäť je nutné overiť, že sa jedná o maximálne vieročodný odhad (maximum) – resp. že vieročodnostná funkcia je konkávna. Urobíme to vrámci výpočtu Fisherovej informácie nutnej k asymptotickému rozdeliu.

Pre Fisherovu informáciu $\mathbf{I}_n(\theta)$ o parametre θ obsaženou v náhodnom výbere X_1, \dots, X_n platí, že

$$\begin{aligned} \mathbf{I}_n(\theta) &= -E\left[\frac{\partial^2}{\partial \theta^2} l(\theta, \mathbf{X})\right] = -E\left[\frac{\partial}{\partial \theta} U(\theta, \mathbf{X})\right] = -E\left[\frac{-n}{\theta^2} + \frac{n}{(1 - \theta)^2} + \frac{2}{(1 - \theta)^3} \sum_{i=1}^n \log X_i\right] \\ &= \frac{n}{\theta^2} - \frac{n}{(1 - \theta)^2} - \frac{2}{(1 - \theta)^3} \sum_{i=1}^n E[\log X_i]. \end{aligned} \quad (1)$$

Zostáva spočítať strednú hodnotu $E[\log X_i]$, k čomu využijeme vhodnú transformáciu. Definujme náhodnú veličinu Z_i pomocou transformácie t , ako $Z_i = t(X_i) = -\log X_i$, pre $i = 1, \dots, n$. Inverzná transformácia t^{-1} je definovaná ako $X_i = t^{-1}(Z_i) = e^{-Z_i}$.

Ked'že pre hustotu transformovanej náhodnej veličiny platí, že

$$f_Z(z) = f_X(t^{-1}(z)) \cdot |(t^{-1})'(z)|,$$

kde f_Z a f_X sú hustoty náhodných veličín Z a X , tak po dostadení získame hustotu náhodnej veličiny $Z_i = -\log X_i$ v tvare

$$f_Z(z) = \frac{\theta}{1 - \theta} e^{-z \frac{2\theta - 1}{1 - \theta}} = \frac{\theta}{1 - \theta} e^{-z \frac{\theta}{1 - \theta}}, \quad \text{pre } \theta \in (0, 1),$$

čo je vlastne hustota náhodnej veličiny s exponenciálnym rozdelením s parametrom $\lambda = \frac{\theta}{1 - \theta} > 0$ (to znamená, že $EZ_i = \frac{1 - \theta}{\theta}$). Po dosadení do Fisherovej informácie $\mathbf{I}_n(\theta)$ v (1) dostaneme

$$\mathbf{I}_n(\theta) = \frac{1}{\theta^2(1 - \theta)^2}.$$

Asymptotické rozdelenie maximálne vieročodného odhadu je preto

$$\sqrt{n}(\hat{\theta}_n - \theta) \xrightarrow{\mathcal{D}} N(0, \underbrace{\theta^2(1 - \theta)^2}_{\sigma_{ML}^2}), \quad \text{pre } n \rightarrow \infty.$$

A4. [Procvičovaci] Momentovou metodou najdete odhad $\tilde{\theta}_n$ parametru θ_X v modelu z predchozího příkladu. Určete asymptotické rozdelení $\tilde{\theta}_n$ a porovnejte asymptotický rozptyl maximálně věrohodného odhadu $\hat{\theta}_n$ a momentového odhadu $\tilde{\theta}_n$.

Rešení:

Je dobré si uvedomiť, že v predchádzajúcim príklade sa jedná o hustotu Beta rozdelenia, ktoré má parametre $\alpha = \frac{2\theta-1}{1-\theta} + 1 = \frac{\theta}{1-\theta}$ a $\beta = 1$. Obecne totiž pre beta rozdelenie s parametrami $\alpha, \beta > 1$ platí, že hustota má tvar

$$f(x) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha+\beta)} x^{\alpha-1} (1-x)^{\beta-1}, \quad \text{pre } x \in (0, 1)$$

a stredná hodnota a rozptyl sú určené vzťahmi

$$EX_i = \frac{\alpha}{\alpha+\beta} \quad \text{a} \quad \text{var } X_i = \frac{\alpha\beta}{(\alpha+\beta)^2(\alpha+\beta+1)}.$$

Po dosadení dostaneme

$$EX_i = \frac{\frac{\theta}{1-\theta}}{\frac{\theta}{1-\theta} + 1} = \theta$$

a tiež

$$\text{var } X_i = \frac{\frac{\theta}{1-\theta}}{\left(\frac{1}{1-\theta}\right)^2 \left(\frac{1}{1-\theta} + 1\right)} = \frac{\theta(1-\theta)^2}{2-\theta}.$$

Na základe vzťahu pre strednú hodnotu je zrejmé, že momentový odhad pre parameter $\theta \in (0, 1)$ je samotný výberový priemer \bar{X}_n (t.j., $\tilde{\theta}_n = \bar{X}_n$). Na základe centrálnej limitnej vety získame hned asymptotické rozdelenie, ktoré je dané vzťahom

$$\sqrt{n}(\tilde{\theta}_n - \theta) \xrightarrow{\mathcal{D}} N\left(0, \underbrace{\frac{\theta(1-\theta)^2}{2-\theta}}_{\sigma_{MM}^2}\right).$$

Na záver chceme porovnať asymptotický rozptyl maximálne věrohodného odhadu $\hat{\theta}_n$ s asymptotickým rozptylom momentového odhadu $\tilde{\theta}_n$.

$$\sigma_{MM}^2 = \frac{\theta(1-\theta)^2}{2-\theta} = \theta^2(1-\theta)^2 \cdot \frac{1}{\theta(2-\theta)} > \theta^2(1-\theta)^2 = \sigma_{ML}^2,$$

protože funkcia $g(\theta) = \theta(2-\theta)$ je rastúca na intervale $(0, 1)$ (derivácia $g'(\theta) = 2 - 2\theta = 2(1-\theta)$ je kladná pre všetky $\theta \in (0, 1)$) a zároveň platí, že $g(0) = 0$ a $g(1) = 1$. Preto platí, že $\frac{1}{g(\theta)} > 1$ pre všetky $\theta \in (0, 1)$.

Pre malé hodnoty $\theta \in (0, 1)$ je momentový odhad dokonca hodne špatný (príliš veľká variabilita), protože $\frac{1}{g(\theta)} \rightarrow \infty$ pre $\theta \rightarrow_+ 0$.