

Inference v lognormálním a Paretově rozdělení

Jiří Likeš

V řadě technických, ekonomických a jiných aplikací se často vyskytují asymetrická rozdělení známých tvarů. Dvě důležitá z nich jsou lognormální a Paretovo rozdělení. Tato práce se zabývá odhady a testy některých parametrických funkcí těchto dvou rozdělení.

1. Lognormální rozdělení

Uvažujme náhodnou veličinu, která má hustotu pravděpodobnosti

$$f(y) = \frac{1}{y\sqrt{2\pi}} \exp\left\{-(\ln y - \mu)^2/(2\sigma^2)\right\}, \quad y > 0 \quad (1.1)$$
$$= 0, \quad y \leq 0$$

s parametry $-\infty < \mu < \infty$, $\sigma^2 > 0$.

Má-li veličina Y lognormální rozdělení (1.1), má veličina $Z = \ln Y$ normální rozdělení $N(\mu, \sigma^2)$. Této transformace se využívá při hledání bodových a intervalových odhadů parametrů μ a σ^2 a pro testy hypotéz o těchto parametrech. Též transformace lze využít i pro intervalové odhady a testy hypotéz pro distribuční funkci

$$F(y) = \Phi\left(\frac{\ln y - \mu}{\sigma}\right), \quad y > 0$$

či pro kvantily

$$y_p = \exp(\mu + \sigma u_p), \quad 0 < p < 1,$$

lognormálního rozdělení. Zde $\Phi(u)$ značí distribuční funkci a u_p kvantil rozdělení $N(0,1)$. Těmito případy se zde nebudeme zabývat.

1.1. Parametrická funkce Θ

Budeme se zabývat odhady parametrické funkce

$$\Theta = \exp(b\mu + c\sigma^2), \quad (1.2)$$

kde b a c jsou daná reálná čísla. Příklady této parametrické funkce jsou:

(i) r-tý obecný moment

$$E(Y^r) = \exp(r\mu + \frac{r^2}{2}\sigma^2), \quad (1.3)$$

speciálně střední hodnota

$$E(Y) = \exp(\mu + \frac{1}{2}\sigma^2). \quad (1.4)$$

(ii) Medián rozdělení

$$Me(Y) = \exp(\mu) \quad (1.5)$$

(iii) Modus rozdělení

$$Mo(Y) = \exp(\mu - \sigma^2). \quad (1.6)$$

(iv) Parametrická funkce

$$\Theta = \exp(c\sigma^2), \quad (1.7)$$

např. podíl $E(Y)/Me(Y)$ nebo $E(Y)/Mo(Y)$ apod.

1.2. Náhodný výběr

Mějme náhodný výběr Y_1, \dots, Y_n rozsahu $n \geq 2$ z rozdělení (1.1). Pak $Z_i = \ln Y_i$, $i = 1, \dots, n$, je náhodný výběr z rozdělení $N(\mu, \sigma^2)$. Je známo, že

$$\hat{\mu}^* = \frac{1}{n} \sum_{i=1}^n Z_i = \frac{1}{n} \sum_{i=1}^n \ln Y_i, \quad W = \sum_{i=1}^n (\ln Y_i - \hat{\mu}^*)^2 \quad (1.8)$$

je úplná postačující statistika pro (μ, σ^2) . Přitom $\hat{\mu}^*$ a W jsou nezávislé náhodné veličiny, $\hat{\mu}^*$ má rozdělení $N(\mu, \sigma^2/n)$ a W/σ^2 má rozdělení $\chi^2(n-1)$.

1.3. Lognormální regrese

Uvažujme regresní model

$$Y = \exp(\mu + u) = \exp\left(\sum_{j=1}^p d_j x_j + u\right) \quad (1.9)$$

kde x_1, \dots, x_p jsou vysvětlující proměnné a d_1, \dots, d_p neznámé regresní parametry. Nechť x_1, \dots, x_p jsou nestochastické proměnné a nechť u je náhodná veličina mající rozdělení $N(0, \sigma^2)$.

Pro dané $\mathbf{x} = (x_1, \dots, x_p)'$ má veličina Y střední hodnotu

$$E(Y|\mathbf{x}) = \exp(\mu + \frac{1}{2} \sigma^2) \quad (1.10)$$

a medián

$$Me(Y|\mathbf{x}) = \exp(\mu). \quad (1.11)$$

Obě tyto funkce jsou parametrické funkce typu (1.2). Speciálním případem je parametrická funkce $\exp(d_1)$, je-li $x_1 = 1$ pro $x_2 = \dots = x_p = 0$ (tj. $\mu = d_1 + d_2 x_2 + \dots + d_p x_p$ a položíme $x_2 = \dots = x_p = 0$).

Mějme množinu $n > p$ nezávislých pozorování

$$y_i = \exp\left(\sum_{j=1}^p d_j x_{ij} + u_i\right), \quad i = 1, \dots, n$$

a označme

$$\mathbf{y} = (y_1, \dots, y_n)', \quad \mathbf{u} = (u_1, \dots, u_n)', \quad \mathbf{d} = (d_1, \dots, d_p)',$$

kde $y_i = \ln Y_i$, $i = 1, \dots, n$.

Pak platí

$$y = X\alpha + \tau, \quad (1.12)$$

kde $X = (x_{ij})$ je matici typu $n \times p$; předpokládejme, že hodnota X je rovna p .

Pomocí klasické metody nejmenších čtverců nalezneme odhad

$$\hat{\alpha}^* = (X'X)^{-1}X'y \quad (1.13)$$

vektoru $\hat{\alpha}$ a reziduální součet čtverců

$$W = (y - X\hat{\alpha})'(y - X\hat{\alpha}). \quad (1.14)$$

Je známo, že za uvedených předpokladů má $\hat{\alpha}^*$ p -rozměrné normální rozdělení, W/σ^2 má rozdělení $\chi^2(n-p)$, $\hat{\alpha}^*$ a W jsou nezávislé a jsou úplnou postačující statistikou pro (μ, σ^2) (viz např. [7]). Toho se opět využívá pro intervalové odhady parametrických funkcí $\sum_{j=1}^p h_j d_j$ (např. pro $\sum_{j=1}^p d_j x_j$ pro dané X) či pro testy hypotéz o takovýchto parametrických funkcích (např. pro testy o parametrech d_j).

Uvažujme nyní statistiku (pro dané X)

$$\mu^* = X'\hat{\alpha}^* = X'(X'X)^{-1}X'y. \quad (1.15)$$

Tato statistika má rozdělení $N(\mu, \lambda^2 \sigma^2)$, kde

$$\mu = X'\hat{\alpha}, \quad \lambda^2 = X'(X'X)^{-1}X. \quad (1.16)$$

1.4. Nejlepší nestranný odhad parametrické funkce Θ

Mějme statistiky μ^* a W , které:

jsou úplné postačující statistiky pro μ a σ^2 (nebo známými funkcemi úplné postačující statistiky: pro náhodný výběr je (1.8) úplnou postačující statistikou pro (μ, σ^2) ; pro lognormální regresi je (1.15) a (1.14) funkcií úplné postačující statistiky $(\hat{\alpha}^*, W)$);

μ^* má rozdělení $N(\mu, \lambda^2 \sigma^2)$ se známým kladným λ^2 ;

W/σ^2 má rozdělení $\chi^2(n)$;

μ^* a W jsou nezávislé.

Hledejme nyní nestranný odhad parametrické funkce (1.2). Střední hodnota

$$E(b\mu^*) = \exp(b\mu + \frac{b^2}{2} \lambda^2 \sigma^2),$$

takže je zapotřebí nalézt nestranný odhad parametrické funkce

$\exp\{(c - b^2 \lambda^2/2)\sigma^2\}$. Je známo ([8]), že statistika

$$\varphi_{[aw, v]} = 1 + \sum_{k=1}^{\infty} \frac{1}{k!} \frac{\Gamma(\frac{v}{2})}{\Gamma(\frac{v}{2}+k)} \left(\frac{aw}{4}\right)^k \quad (1.17)$$

je nestranným odhadem parametrické funkce $\exp(a\sigma^2/2)$ pro libovolné reálné a . Nestranným odhadem parametrické funkce (1.2) je tedy statistika

$$\theta^* = \exp(b\mu^*) \cdot \varphi_{[(2c - b^2 \lambda^2)w, v]} \quad (1.18)$$

Protože θ^* je funkcií pouze úplně postačující statistiky (μ^* a w v případě náhodného výběru, resp. μ^* a W v případě lognormální regrese), je θ^* nejlepším nestranným odhadem θ .

Tak např. pro $\theta = \exp(\mu + \sigma^2/2)$ je $\theta^* = \exp(\mu^*) \varphi_{[(1 - \lambda^2)w, v]}$ nebo pro $\theta = \exp(\mu)$ je $\theta^* = \exp(\mu^*) \varphi_{[-\lambda^2 w, v]}$, kde pro náhodný výběr je $\lambda^2 = 1/n$, $v = n-1$ a pro lognormální regresi je λ^2 výraz (1.16) a $v = n-p$.

D.J.Finney [3] uvažoval funkci

$$g_{[t, v]} = 1 + \sum_{k=1}^{\infty} \frac{1}{k!} \frac{v^k}{v(v+2)\dots(v+2k-2)} \left(\frac{v}{v+1}\right)^k t^k \quad (1.19)$$

Platí

$$\varphi_{[aw, v]} = g_{\left[\frac{v+1}{2v^2} aw, v\right]} \quad (1.20)$$

1.5. Rozptyl odhadu θ^*

Použijeme-li vztahu (viz [6])

$$E\{\varphi^2_{[aw, v]}\} = \exp(a\sigma^2) \varphi_{[a^2\sigma^4, v]}, \quad (1.21)$$

platí pro rozptyl $\text{var}(\theta^*)$ statistiky (1.18)

$$\text{var}(\theta^*) = \exp(2b\mu + 2b^2 \lambda^2 \sigma^2) \exp\{(2c - b^2 \lambda^2)\sigma^2\} \cdot$$

$$\cdot \varphi_{[(2c - b^2 \lambda^2)^2 \sigma^4, v]} - \theta^2 =$$

$$= \theta^2 \left\{ \exp(b^2 \lambda^2 \sigma^2) \varphi_{[(2c - b^2 \lambda^2)^2 \sigma^4, v]} - 1 \right\}. \quad (1.21)$$

Protože θ ani σ^2 neznáme, zajímá nás odhad rozptylu (1.21). Uvažujme $V(\theta^*) = \theta^{*2} - H(\theta^*)$, kde $H(\theta^*)$ je nestranný odhad parametrické funkce $\theta^2 = \exp(2b\mu + 2c\sigma^2)$. Použitím předchozího postupu dostaváme

$$V(\theta^*) = \theta^{*2} - \exp(2b\mu^*) \varphi_{[4(c - b^2 \lambda^2)w, v]} \quad (1.22)$$

Protože $V(\hat{\theta}^*)$ je funkcií pouze úplné postačující statistiky, je (1.22) nejlepší nestranný odhad $\text{var}(\hat{\theta}^*)$.

1.6. Parametrická funkce $\hat{\theta} = \sum_{i=1}^n h_i \theta_i$

Uvažujme nyní parametrickou funkci

$$\hat{\theta} = \sum_{i=1}^n h_i \theta_i = \sum_{i=1}^n h_i \exp(b_i \mu + c_i \sigma^2) \quad (1.23)$$

kde $h_i, b_i, c_i, i = 1, \dots, r$, jsou daná reálná čísla. Příklady $\hat{\theta}$:

$$(i) \text{ var}(Y) = \exp(2\mu + 2\sigma^2) - \exp(2\mu + \sigma^2),$$

$$(ii) E(Y) - \text{Me}(Y) = \exp(\mu + \sigma^2/2) - \exp(\mu)$$

pro lognormální rozdělení,

$$(iii) E(Y|\mathbf{x}) - \text{Me}(Y|\mathbf{x}) \quad (\text{pro dané } \mathbf{x}) \quad \text{či} \quad E(Y|\mathbf{x}_1) - E(Y|\mathbf{x}_2)$$

(pro dvě různá \mathbf{x}_1 a \mathbf{x}_2) pro lognormální regresi.

Nejlepším nestranným odhadem (1.23) je statistika

$$\hat{\theta}^* = \sum_{i=1}^n h_i \exp(b_i \mu^*) \varphi[(2c_i - b_i^2 \lambda^2)w, v]. \quad (1.24)$$

Její rozptyl

$$\text{var}(\hat{\theta}^*) = \sum_{i=1}^n \sum_{j=1}^n h_i h_j \text{cov}(\hat{\theta}_i^*, \hat{\theta}_j^*) \quad (1.25)$$

kde

$$\begin{aligned} \text{cov}(\hat{\theta}_i^*, \hat{\theta}_j^*) &= E\{\exp[(b_i + b_j)\mu^*]\} \cdot \\ &\quad \cdot E\{\varphi[a_i w, v] \varphi[a_j w, v]\} - \hat{\theta}_i^* \hat{\theta}_j^* \\ &= \hat{\theta}_i^* \hat{\theta}_j^* \{ \exp(b_i b_j \lambda^2 \sigma^2) \cdot \varphi[a_i a_j \sigma^2, v] - 1 \}, \end{aligned} \quad (1.26)$$

přičemž

$$a_i = 2c_i - b_i^2 \lambda^2, \quad i = 1, \dots, r. \quad (1.27)$$

Zde se použilo vztahu (viz [5])

$$E\{\varphi[a_1 w, v] \varphi[a_2 w, v]\} = \exp\{(a_1 + a_2)\sigma^2/2\} \varphi[a_1 a_2 \sigma^4, v]. \quad (1.28)$$

2. Paretovo rozdělení

Nechť náhodná veličina X má Paretovo rozdělení s parametry

$\gamma > 0$ a $\beta > 0$, takže její hustota pravděpodobnosti

$$\begin{aligned} f(x) &= \beta \gamma^\beta / x^{\beta+1}, \quad x > \gamma \\ &= 0, \quad x \leq \gamma. \end{aligned} \quad (2.1)$$

Toto rozdělení označíme $\text{Pa}(\gamma, \beta)$.

Má-li veličina X rozdělení $\text{Pa}(\gamma, \beta)$, má veličina $T = \ln X$ rozdělení $E(\ln \gamma, 1/\beta)$, kde $E(A, \theta)$ značí exponenciální rozdělení s hustotou pravděpodobnosti

$$g(t) = \frac{1}{\theta} \exp\left(-\frac{t - A}{\theta}\right), \quad t > A \quad (2.2)$$

$$= 0, \quad t \leq A.$$

Tohoto výsledku lze s výhodou využít pro inferenci v Paretově rozdělení, neboť pro exponenciální rozdělení je inference bohatě propracována.

2.1. γ známo

Nejprve uvažujme případ, kdy parametr γ je znám. Mějme náhodný výběr X_1, \dots, X_n z rozdělení $\text{Pa}(\gamma, \beta)$, tj. mějme náhodný výběr

$T_1 = \ln X_1, \dots, T_n = \ln X_n$ z rozdělení $E(\ln \gamma, 1/\beta)$. Je známo, že $\sum_{i=1}^n T_i = \sum_{i=1}^n \ln X_i$ je úplnou postačující statistikou pro parametr $\theta = 1/\beta$ a že veličina

$$\frac{2}{\theta} \sum_{i=1}^n (T_i - A) = 2\beta \sum_{i=1}^n (\ln X_i - \ln \gamma) \quad (2.3)$$

má rozdělení $\chi^2(2n)$.

2.1.1. Odhad a testy pro parametr β

Protože veličina (2.3) má rozdělení $\chi^2(2n)$, je statistika

$$\beta^* = \frac{n-1}{\sum_{i=1}^n (\ln X_i - \ln \gamma)}, \quad n \geq 2 \quad (2.4)$$

nestranným odhadem parametru β rozdělení $\text{Pa}(\gamma, \beta)$ pro γ známé. Protože β^* je funkcií úplné postačující statistiky $\sum_{i=1}^n \ln X_i$, je (2.4) nejlepší nestranný odhad β pro γ známé. Rozptyl

$$\text{var}(\beta^*) = \beta^2 / (n-2), \quad n \geq 3. \quad (2.5)$$

Maximálně věrohodný odhad parametru β je roven

$$\widehat{\beta} = \frac{n}{\sum_{i=1}^n (\ln X_i - \ln \gamma)} = \frac{n}{n-1} \beta^*; \quad (2.6)$$

$\widehat{\beta}$ tedy není nestranný odhad β , ale je asymptoticky nestranný.

Protože veličina (2.3) má rozdělení $\chi^2(2n)$, je interval

$$\frac{\chi^2_{d_1}(2n)}{2 \sum_{i=1}^n (\ln X_i - \ln \gamma)} < \beta < \frac{\chi^2_{1-d_2}(2n)}{2 \sum_{i=1}^n (\ln X_i - \ln \gamma)} \quad (2.7)$$

$100(1 - \alpha)$ procentní interval spolehlivosti pro β . Zde $0 \leq d_1 \leq d$, $0 \leq d_2 \leq d$, $d_1 + d_2 = d$ a $\chi^2_{\epsilon}(2n)$ je ϵ tý kvantil rozdělení $\chi^2(2n)$.

Pro test hypotézy $H_0: \beta = \beta_0$ se jako testového kritéria použije veličiny $2\beta_0 \sum_{i=1}^n (\ln X_i - \ln \gamma)$, která má za platnosti H_0 rozdělení $\chi^2(2n)$.

2.1.2. Odhad hodnoty distribuční funkce

Pro dané $b > \gamma$ chceme odhadnout hodnotu distribuční funkce

$$F(b) = 1 - (\gamma/b)^{\beta}, \quad b > \gamma. \quad (2.8)$$

Avšak

$$F(b) = P(X < b) = P(\ln X < \ln b) = P(T < \ln b) = P(Z < \ln \frac{b}{\gamma}),$$

kde $Z = T - \ln \gamma$ je náhodná veličina mající rozdělení $E(0, 1/\beta)$.

Z práce [9] vyplývá, že nejlepší nestranný odhad $F^*(b)$ hodnoty $F(b)$ je dán výrazy

$$F^*(b) = 1, \\ = 1 - \left(1 - \frac{\ln(b/\gamma)}{\sum_{i=1}^n \ln(X_i/\gamma)}\right)^{n-1}, \quad \begin{cases} \sum_{i=1}^n \ln(X_i/\gamma) \leq \ln(b/\gamma) \\ \sum_{i=1}^n \ln(X_i/\gamma) > \ln(b/\gamma) \end{cases} \quad (2.9)$$

Označme $\underline{\beta} < \beta < \bar{\beta}$ interval spolehlivosti (2.7) pro β . Pak

$$\underline{F} < F(b) < \bar{F}, \quad (2.10)$$

kde

$$\underline{F} = 1 - (\gamma/b)^{\underline{\beta}} \quad \text{pro } 0 \leq d_1 \leq d \\ \bar{F} = 1 - (\gamma/b)^{\bar{\beta}} \quad \text{pro } 0 \leq d_1 < d \\ \underline{d}_1 = d \quad (2.11)$$

je $100(1 - \alpha)$ procentní interval spolehlivosti pro $F(b)$.

2.1.3. Odhad kvantilu

Ptý kvantil rozdělení $P_a(\gamma, \beta)$ je roven

$$x_p = \gamma(1 - p)^{-1/\beta} = \gamma \exp(-\frac{1}{\beta} \ln(1 - p)), \quad 0 < p < 1. \quad (2.12)$$

Maximálně věrohodný odhad

$$\hat{x}_p = \gamma(1 - p)^{-1/\hat{\beta}} = \gamma \exp\left\{[-\ln(1 - p)] \frac{1}{n} \sum_{i=1}^n (\ln X_i - \ln \gamma)\right\} \quad (2.13)$$

Lze ukázat, že pro každé $0 < p < 1$ a konečné n je $E(\hat{x}_p) > x_p$, avšak $\lim_{n \rightarrow \infty} E(\hat{x}_p) = x_p$.

Označme opět $\underline{\beta} < \beta < \bar{\beta}$ interval spolehlivosti (2.7). Pak

$$\gamma_{\exp} \left\{ [-\ln(1 - P)] \frac{1}{\beta} \right\} < x_p < \gamma_{\exp} \left\{ [-\ln(1 - P)] \frac{1}{\bar{\beta}} \right\} \quad (2.14)$$

je $100(1 - d)$ procentní interval spolehlivosti pro x_p .

2.2. γ i β neznámy

Nyní uvažujme případ obou neznámých parametrů γ a β . Mějme uspořádaný výběr $X_{(1)} < \dots < X_{(n)}$, $n \geq 2$, z rozdělení $P_A(\gamma, \beta)$, tj. mějme uspořádaný výběr $T_{(1)} = \ln X_{(1)} < \dots < T_{(n)} \stackrel{(-\ln X_{(n)})}{\sim} \text{z rozdělení } E(\ln \gamma, 1/\beta)$.

Je známo [2], že

$$(T_{(1)} = \ln X_{(1)}, \sum_{i=2}^n (T_{(i)} - T_{(1)}) = \sum_{i=2}^n (\ln X_{(i)} - \ln X_{(1)}))$$

je úplná postačující statistika pro dvourozměrný parametr (A, θ) rozdělení $E(A, \theta)$ (v našem případě $A = \ln \gamma$ a $\theta = 1/\beta$). Přitom veličiny $T_{(1)}$ a $\sum_{i=2}^n (T_{(i)} - T_{(1)})$ jsou nezávislé, veličina $2n(T_{(1)} - A)/\theta$ má rozdělení $\chi^2(2)$ a veličina $2 \sum_{i=2}^n (T_{(i)} - T_{(1)})/\theta$ má rozdělení $\chi^2(2n-2)$.

2.2.1. Odhad a testy pro parametr β

Obdobným postupem jako v případě známého γ zjistíme, že v případě, kdy γ není známo, je

$$\beta^* = \frac{n-2}{\sum_{i=2}^n (\ln X_{(i)} - \ln X_{(1)})}, \quad n \geq 3 \quad (2.15)$$

nejlepším nestranným odhadem parametru β . Rozptyl tohoto odhadu

$$\text{var}(\beta^*) = \beta^2/(n-3), \quad n \geq 4. \quad (2.16)$$

Protože veličina $2\beta \sum_{i=2}^n (\ln X_{(i)} - \ln X_{(1)})$ má rozdělení $\chi^2(2n-2)$, je

$$\frac{\chi^2_{d_1}(2n-2)}{2 \sum_{i=2}^n (\ln X_{(i)} - \ln X_{(1)})} < \beta < \frac{\chi^2_{1-d_2}(2n-2)}{2 \sum_{i=2}^n (\ln X_{(i)} - \ln X_{(1)})} \quad (2.17)$$

$100(1 - d)$ procentní interval spolehlivosti pro β .

Pro test hypotézy $H_0: \beta = \beta_0$ se jako testového kritéria použije veličiny $2\beta_0 \sum_{i=2}^n (\ln X_{(i)} - \ln X_{(1)})$.

Maximálně věrohodným odhadem parametru β je statistika

$$\hat{\beta} = \frac{n}{n-2} \beta^* \quad (2.18)$$

2.2.2. Odhad a testy pro parametr γ

Nejlepším nestranným odhadem parametru γ je statistika (viz [4])

$$\hat{\gamma}^* = X_{(1)} \left[1 - \frac{1}{n(n-1)} \sum_{i=2}^n (\ln X_{(i)} - \ln X_{(1)}) \right], \quad n \geq 2, \quad n/\beta > 1. \quad (2.19)$$

Její rozptyl

$$\text{var}(\hat{\gamma}^*) = \gamma^2 / (\beta(n-1)(n/\beta - 2)), \quad n \geq 2, \quad n/\beta > 2. \quad (2.20)$$

$\hat{\gamma}$ Maximálně věrohodný odhad

$$\hat{\gamma} = X_{(1)}. \quad (2.21)$$

Veličina

$$F = \frac{n(n-1)(\ln X_{(1)} - \ln \hat{\gamma})}{\sum_{i=2}^n (\ln X_{(i)} - \ln X_{(1)})} \quad (2.22)$$

má rozdělení $F(2, 2n-2)$. Odtud vyplývá, že

$$X_{(1)} \exp \left\{ -\frac{F_{1-\alpha}}{n(n-1)} \sum_{i=2}^n (\ln X_{(i)} - \ln X_{(1)}) \right\} < \gamma < X_{(1)} \quad (2.23)$$

je $100(1-\alpha)$ procentní interval spolehlivosti pro γ . Zde $F_{1-\alpha}$ je $(1-\alpha)$ kvantil rozdělení $F(2, 2n-2)$.

Pro test hypotézy $H_0: \gamma = \gamma_0$ se jako testového kritéria použije veličiny (2.22) s $\gamma = \gamma_0$.

2.3. Některé jiné odhady parametrů β a γ

V práci [10] se uvažují některé jiné odhady parametrů β a γ .

Uvedeme zde dva z nich:

(i) Odhad z prvního momentu a z minimálního pozorování. Jelikož

$$E(\bar{X}) = \beta \gamma / (\beta - 1), \quad E(X_{(1)}) = n \beta \gamma / (n \beta - 1),$$

dostáváme odhady

$$\tilde{\beta} = (n\bar{X} - X_{(1)}) / (n(\bar{X} - X_{(1)})), \quad \tilde{\gamma} = (n\tilde{\beta} - 1)X_{(1)} / (n\tilde{\beta}) = (\tilde{\beta} - 1)\bar{X} / \tilde{\beta} \quad (2.24)$$

(ii) Odhad z kvantilů (pro velké výběry). Zvolí se P_1 a P_2 , $0 < P_1 < P_2 < 1$. Z výběru se naleznou odhadky kvantilů \tilde{x}_{P_1} a \tilde{x}_{P_2} (např. tak, že se položí $\tilde{x}_{P_i} = X_{(k_i)}$, kde $k_i = [(n+1)P_i]$; $[\cdot]$ značí celou část kladného čísla a). Pak

$$\tilde{x}_{P_i} = \gamma_{(1-P_i)^{-1}/\tilde{\beta}}, \quad i = 1, 2$$

a odtud

$$\tilde{\beta} = \ln \left\{ (1-P_1) / (1-P_2) \right\} / \ln (\tilde{x}_{P_2} / \tilde{x}_{P_1}), \quad \tilde{\gamma} = \tilde{x}_{P_i} (1-P_i)^{1/\tilde{\beta}} \quad (2.25)$$

pro $i=1$ nebo $i=2$.

V práci [10] je ukázáno, že odhady (2.24) i (2.25) jsou konsistentní.

Literatura

- [1] BRADU,D. and MUNDLAK,Y. (1970). Estimation in lognormal models. J. Amer. Stat. Assoc., 65, 198-211.
- [2] EPSTEIN,B. and SOBEL,M. (1954). Some theorems relevant to life testing from an exponential distribution. Ann. Math. Statist., 25, 373-381.
- [3] FINNEY,D.J. (1941). On the distribution of a variate whose logarithm is normally distributed. Suppl. to the J. Roy. Statist. Soc., 7, 155-161.
- [4] LIKEŠ,J.(1969).Minimum variance unbiased estimates of power-function and Pareto's distribution. Stat. Hefte, 10, 104-110.
- [5] LIKEŠ,J. (1980).Variance of the MVUE for lognormal variance. Technometrics, 22, 253-258.
- [6] MEHRAN,F. (1973). Variance of the MVUE for the lognormal mean. J. Amer. Stat. Assoc., 68, 726-727.
- [7] MOOD, A. M. and GRAYBILL,F.A. (1963). Introduction to the Theory of Statistics. New York: McGraw-Hill Book Co.
- [8] NEYMANN,J. and SCOTT,E.L. (1960). Correction for bias introduced by a transformation of variables. Ann. Math. Statist., 31, 643-655.
- [9] PUGH,E.L. (1963). The best estimate of reliability in the exponential case. Oper. Res., 11, 57-61.
- [10] QUANDT,R.E. (1966). Old and new methods of estimation and the Pareto distribution. Metrika, 10, 55-82.