

# TRIEDA TRANSFORMOVANÝCH LAMBERT $W \times GAMA$ NÁHODNÝCH VELIČÍN A ICH APLIKÁCIE

Gejza Wimmer, Viktor Witkovský

ROBUST 2014, 19-24.1.2014, Jetřichovice

- Triedy náhodných veličín s Lambertovým  $W \times F$  rozdelením
- Testy založené na funkcii podielu vierohodností
- Trieda  $LW_{\mathcal{F}_\theta}^\theta$  transformovaných náhodných veličín s Lambertovým  $W \times F_{\text{Gama}}$  rozdelením
  - Distribúcia náhodnej veličiny  $Y \sim LW_{\mathcal{F}_\theta}^\theta$  ak  $X \sim \chi_\nu^2$
  - Distribúcia náhodnej veličiny  $Y \sim LW_{\mathcal{F}_{\chi_\nu^2}}^\theta$  ak  $\theta = (\nu(\ln \nu - 1), \nu, 1)$

## Triedy náhodných veličín s Lambertovým $W \times F$ rozdelením

Georg M. Goerg zaviedol vo veľmi zaujímavom článku [2] triedy zovšeobecnených rozdelení. Pomocou parametrickej nelineárnej transformácie sa zmení náhodná veličina  $X$  na tzv. Lambertovu náhodnú veličinu  $Y$ , ktorá umožňuje veľmi flexibilný prístup k modelovaniu zošikmených (skewed) rozdelení.

Iste ste sa všetci stretli so situáciami

- Dáta pochádzajú z rozdelenia "skoro" normálneho, ale zošikmeného doprava, alebo
- Návratnosť aktív má ťažké chvosty, ale údaje sú príliš zošikmené, aby malo zmysel uvažovať  $t$ -rozdelenie.

**Definícia.** Nech  $U$  je spojitá náhodná veličina s distribučnou funkciou  $F_U(u) = P\{U < u\}$ ,  $u \in \mathcal{R}$  a hustotou  $f_U(u)$ . Potom

$$Z = Ue^{\gamma U}, \quad \gamma \in \mathcal{R} \quad (1)$$

je náhodná veličina s Lambertovým  $W \times F_U$  rozdelením s parametrom šikmosti  $\gamma$ . Keď má náhodná veličina  $U$  dané rozdelenie pravdepodobnosti (napríklad  $Gama(a, b)$  rozdelenie), tak túto náhodnú veličinu budeme volať  $W \times Gama(a, b)$  náhodná veličina.

**Poznámka.** Mnohohodnotová funkcia  $W(z)$ , pre ktorú platí

$$W(z)e^{W(z)} = z, \quad z \in \mathcal{C}$$

sa nazýva Lambertova  $W$  funkcia.  
Detailnejšie pozri napr. v [1].

## Testy založené na funkcii podielu vierohodností

Majme parametrický štatistický model reprezentovaný triedou hustôt

$$\mathcal{M} = \{f(\mathbf{y}|\boldsymbol{\theta}) : \mathbf{y} \in \mathcal{Y}, \boldsymbol{\theta} \in \Theta\}, \quad (2)$$

kde  $\mathcal{Y}$  je výberový priestor (v našom prípade  $\mathcal{R}^n$ ),  $\Theta \subseteq \mathcal{R}^d$  je parametrický priestor,  $\mathbf{y}$  je realizácia observačného (náhodného) vektora  $\mathbf{Y}$  s hustotou  $f(\cdot|\boldsymbol{\theta})$ . Logaritmická vierohodnostná funkcia je

$$l(\boldsymbol{\theta}|\mathbf{y}) = \ln f(\mathbf{y}|\boldsymbol{\theta}).$$

Majme nulovú hypotézu  $H_0 : \boldsymbol{\theta} = (\boldsymbol{\theta}'_1, \boldsymbol{\theta}'_2)' \in \Theta_0$ , ( $\boldsymbol{\theta}_1 \in \mathcal{R}^t$ ,  $\boldsymbol{\theta}_2 \in \mathcal{R}^{d-t}$ ) a alternatívnu hypotézu  $H_a : \boldsymbol{\theta} = (\boldsymbol{\theta}'_1, \boldsymbol{\theta}'_2)' \in \Theta_a$ , pričom  $\Theta_0 \cup \Theta_a = \Theta$ . Testovať  $H_0 \times H_a$  môžeme testovacou štatistikou

$$-2 \left( \sup_{(\boldsymbol{\theta}'_1, \boldsymbol{\theta}'_2)' \in \Theta_0} l(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2|\mathbf{Y}) - \sup_{(\boldsymbol{\theta}'_1, \boldsymbol{\theta}'_2)' \in \Theta} l(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2|\mathbf{Y}) \right).$$

Nech  $l(\hat{\theta}_{1,0}, \hat{\theta}_{2,0} | \mathbf{y}) = \sup_{(\theta'_1, \theta'_2)' \in \Theta_0} l(\theta_1, \theta_2 | \mathbf{Y})$ .  $l(\hat{\theta}_{1,0}, \hat{\theta}_{2,0} | \mathbf{y})$  reprezentuje najlepšie vysvetlenie pre namerané údaje  $\mathbf{y}$  pre všetky  $(\theta'_1, \theta'_2)' \in \Theta_0$ . Podobne  $l(\hat{\theta}_1, \hat{\theta}_2 | \mathbf{y}) = \sup_{(\theta'_1, \theta'_2)' \in \Theta} l(\theta_1, \theta_2 | \mathbf{Y})$  reprezentuje najlepšie vysvetlenie pre namerané údaje  $\mathbf{y}$  pre všetky  $(\theta'_1, \theta'_2)' \in \Theta$ . Ak  $l(\hat{\theta}_{1,0}, \hat{\theta}_{2,0} | \mathbf{y}) = l(\hat{\theta}_1, \hat{\theta}_2 | \mathbf{y})$ , tak najlepšie vysvetlenie pre namerané údaje sa nachádza v  $\Theta_0$  a nezamietneme  $H_0$ . Ale ak  $l(\hat{\theta}_{1,0}, \hat{\theta}_{2,0} | \mathbf{y}) < l(\hat{\theta}_1, \hat{\theta}_2 | \mathbf{y})$ , tak najlepšie vysvetlenie pre namerané údaje sa nachádza v  $\Theta_a$  a musíme uvažovať zamietnutie  $H_0$  v prospech  $H_a$ . Pre štatistiku

$$\lambda(\theta_1, \theta_2 | \mathbf{Y}) = -2 \left( \sup_{(\theta'_1, \theta'_2)' \in \Theta_0} l(\theta_1, \theta_2 | \mathbf{Y}) - \sup_{(\theta'_1, \theta'_2)' \in \Theta} l(\theta_1, \theta_2 | \mathbf{Y}) \right) \quad (3)$$

platí  $0 \leq \lambda(\theta_1, \theta_2 | \mathbf{Y}) < \infty$ . Nulová hodnota  $\lambda(\theta_1, \theta_2 | \mathbf{y})$  indukuje, že  $H_0$  nezamietame (pri danej realizácii  $\mathbf{y}$ ). Veľká hodnota  $\lambda(\theta_1, \theta_2 | \mathbf{y})$  indukuje, že najlepšie vysvetlenie pre namerané údaje  $\mathbf{y}$  sa nachádza v  $\Theta_a$  a  $H_0$  zamietame v prospech  $H_a$ .

Ak tento test má mať hladinu významnosti  $\alpha$ , tak kritická oblasť je

$$U_\alpha = \{\mathbf{y} : \lambda(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2 | \mathbf{y}) > \kappa\},$$

príčom  $\kappa$  spočítame tak, aby za platnosti  $H_0$

$$P\{\lambda(\boldsymbol{\theta}_1, \boldsymbol{\theta}_2 | \mathbf{Y}) > \kappa\} = \alpha.$$

**Príklad 1.** Majme náhodný výber  $Y_1, Y_2, \dots, Y_n$ ,  $Y_i \sim N(\mu, \sigma^2)$ , pričom  $\mu$  poznáme,  $\sigma > 0$  nepoznáme. Testujeme hypotézu

$$H_0 : \sigma = \sigma_0 \quad \not\asymp \quad H_a : \sigma \neq \sigma_0$$

V tomto prípade

$$\Theta = \{(\mu, \sigma) : \sigma \in (0, \infty)\}, \quad \Theta_0 = \{(\mu, \sigma_0)\}, \\ \Theta_a = \{(\mu, \sigma) : \sigma \in (0, \infty), \sigma \neq \sigma_0\}$$

a

$$l(\mu, \sigma | \mathbf{Y}) = -\frac{n}{2} \ln 2\pi - n \ln \sigma - \frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - \mu)^2.$$

Z rovnice  $\frac{\partial l}{\partial \sigma} \Big|_{\sigma=\hat{\sigma}} = 0$  dostávame  $\frac{\partial l}{\partial \sigma} = -\frac{n}{\sigma} + \frac{1}{\sigma^3} \sum_{i=1}^n (Y_i - \mu)^2 = 0$ , čiže

$$\sup_{(\mu, \sigma) \in \Theta} l(\mu, \sigma | \mathbf{Y}) = -\frac{n}{2} \ln 2\pi - n \ln \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \mu)^2} - \frac{\sum_{i=1}^n (Y_i - \mu)^2}{2 \frac{1}{n} \sum_{i=1}^n (Y_i - \mu)^2} =$$

$$= -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \frac{1}{n} \sum_{i=1}^n (Y_i - \mu)^2 - \frac{n}{2},$$

$$\sup_{(\mu, \sigma) \in \Theta_0} l(\mu, \sigma | \mathbf{Y}) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma_0^2 - \frac{1}{2\sigma_0^2} \sum_{i=1}^n (Y_i - \mu)^2.$$

Za platnosti nulovej hypotézy dostávame exaktné rozdelenie  $\lambda(\mu, \sigma_0 | \mathbf{Y})$ :

$$\lambda(\mu, \sigma_0 | \mathbf{Y}) = -n \ln \frac{\sum_{i=1}^n (Y_i - \mu)^2}{n\sigma_0^2} - n + \frac{\sum_{i=1}^n (Y_i - \mu)^2}{\sigma_0^2} \sim Q_n - n - n \ln \frac{Q_n}{n},$$

kde  $Q_n \sim \chi_n^2$ .



**Príklad 2.** Majme náhodný výber  $Y_1, Y_2, \dots, Y_n$ ,  $Y_i \sim N(\mu, \sigma^2)$ , pričom  $\mu \in (-\infty, \infty)$  nepoznáme ani  $\sigma > 0$  nepoznáme. Testujeme hypotézu

$$H_0 : \mu = \mu_0, \sigma = \sigma_0 \quad \not\asymp \quad H_a : (\mu, \sigma) \neq (\mu_0, \sigma_0).$$

Teraz

$$\Theta = \{(\mu, \sigma) : -\infty < \mu < \infty, \sigma \in (0, \infty)\},$$

$$\Theta_0 = \{(\mu_0, \sigma_0)\}, \quad \Theta_a = \{(\mu, \sigma) : -\infty < \mu < \infty, \sigma \in (0, \infty), \mu \neq \mu_0, \sigma \neq \sigma_0\}$$

a

$$l(\mu, \sigma | \mathbf{Y}) = -\frac{n}{2} \ln 2\pi - n \ln \sigma - \frac{1}{2\sigma^2} \sum_{i=1}^n (Y_i - \mu)^2.$$

Z rovníc  $\left. \frac{\partial l}{\partial \mu} \right|_{\substack{\mu=\hat{\mu} \\ \sigma=\hat{\sigma}}} = 0$ ,  $\left. \frac{\partial l}{\partial \sigma} \right|_{\substack{\mu=\hat{\mu} \\ \sigma=\hat{\sigma}}} = 0$  dostávame  $\hat{\mu} = \bar{Y}$ ,  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2$

a teda

$$\sup_{(\mu, \sigma) \in \Theta} l(\mu, \sigma | \mathbf{Y}) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y})^2 - \frac{n}{2},$$

$$\sup_{(\mu, \sigma) \in \Theta_0} l(\mu, \sigma | \mathbf{Y}) = -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma_0^2 - \frac{1}{2\sigma_0^2} \sum_{i=1}^n (Y_i - \mu_0)^2.$$

Za platnosti nulovej hypotézy dostávame exaktné rozdelenie  $\lambda(\mu_0, \sigma_0 | \mathbf{Y})$ :

$$\begin{aligned} \lambda(\mu_0, \sigma_0 | \mathbf{Y}) &= \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{\sigma_0^2} - n - n \ln \frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n\sigma_0^2} + \frac{n(\bar{Y} - \mu_0)^2}{\sigma_0^2} \sim \\ &\sim Q_{n-1} - n - n \ln \frac{Q_{n-1}}{n} + Q_1, \end{aligned}$$

kde  $Q_{n-1} \sim \chi_{n-1}^2$ ,  $Q_1 \sim \chi_1^2$  a  $Q_{n-1}$ ,  $Q_1$  sú nezávislé.

**Príklad 3.** Majme lineárny regresný model  $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \sigma\boldsymbol{\varepsilon}$ ,  
 $\mathbf{Y} \sim N_n(\mathbf{X}_{n,k}\boldsymbol{\beta}, \sigma^2\mathbf{I})$ ,  $\boldsymbol{\beta} \in \mathcal{R}^k$ ,  $\sigma > 0$ ,  $h(\mathbf{X}) = k < n$ . Testujeme hypotézu

$$H_0 : (\boldsymbol{\beta}, \sigma) = (\boldsymbol{\beta}_0, \sigma_0) \quad \asymp \quad H_a : (\boldsymbol{\beta}, \sigma) \neq (\boldsymbol{\beta}_0, \sigma_0).$$

Za platnosti nulovej hypotézy možno odvodiť (pozri [3]) exaktné rozdelenie  $\lambda(\boldsymbol{\beta}_0, \sigma_0 | \mathbf{Y})$ :

$$\lambda(\boldsymbol{\beta}_0, \sigma_0 | \mathbf{Y}) \sim Q_{n-k} - n - n \ln \frac{Q_{n-k}}{n} + Q_k,$$

kde  $Q_{n-k} \sim \chi_{n-k}^2$ ,  $Q_k \sim \chi_k^2$  a  $Q_{n-k}$ ,  $Q_k$  sú nezávislé.

**Príklad 4.** Uvažujme lineárny zmiešaný model s dvomi variančnými komponentami

$$\mathbf{Y} = \mathbf{X}_{n,k}\boldsymbol{\beta} + \sigma_A \mathbf{U}_{n,q}\boldsymbol{\eta} + \sigma \boldsymbol{\varepsilon},$$

$\sigma_A^2 \geq 0$ ,  $\sigma^2 > 0$ ,  $\boldsymbol{\eta} \sim N_q(\mathbf{0}, \mathbf{A}_{q,q})$ ,  $\boldsymbol{\varepsilon} \sim N_n(\mathbf{0}, \mathbf{I})$ ,  $\mathbf{X}$ ,  $\mathbf{U}$  a  $\mathbf{A}$  sú známe matice,  $\boldsymbol{\eta}$ ,  $\boldsymbol{\varepsilon}$  sú nezávislé,  $h(\mathbf{X}) = \nu$ . Inferencia o  $(\sigma_A^2, \sigma^2)$  môže byť založená na vhodne transformovanom vektore  $\tilde{\mathbf{Y}} = \mathbf{B}_{\nu,n}\mathbf{Y}$ , pričom  $\tilde{\mathbf{Y}} \sim N(\mathbf{0}, \boldsymbol{\Sigma})$ ,

$\boldsymbol{\Sigma} = \sigma_A^2 \mathbf{BVB}' + \sigma^2 \mathbf{I}_\nu = \sum_{i=1}^r (\sigma_A^2 \varrho_i + \sigma^2) \mathbf{E}_i$ ,  $\mathbf{V} = \mathbf{UAU}'$ ,  $\mathbf{BVB}' = \sum_{i=1}^r \varrho_i \mathbf{E}_i$  je spektrálny rozklad matice  $\mathbf{BVB}'$  s vlastnými číslami  $\varrho_i$ , ( $\varrho_1 > \varrho_2 > \dots > \varrho_r \geq 0$ ) a ich násobky sú  $\nu_i$ ,  $\sum_{i=1}^r \nu_i = \nu$ . Označme kanonické parametre  $\theta_i = (\sigma_A^2 \varrho_i + \sigma^2) > 0$ ,  $i = 1, 2, \dots, r$ ,  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_r)'$ ,  $T_i = \tilde{\mathbf{Y}}' \mathbf{E}_i \tilde{\mathbf{Y}}$ ,  $i = 1, 2, \dots, r$ ,  $\mathbf{T} = (T_1, \dots, T_r)'$ . Testujeme hypotézu

$$H_0 : \boldsymbol{\theta} = \boldsymbol{\theta}_0 \quad \not\asymp \quad H_a : \boldsymbol{\theta} \neq \boldsymbol{\theta}_0.$$

Za platnosti nulovej hypotézy možno odvodiť (pozri [3]) exaktné rozdelenie  $\lambda(\boldsymbol{\theta}_0 | \mathbf{T})$ :

$$\lambda(\boldsymbol{\theta}_0, \sigma_0 | \mathbf{T}) \sim \sum_{i=1}^r \left( Q_{\nu_i} - \nu_i - \nu_i \ln \frac{Q_{\nu_i}}{\nu_i} \right),$$

kde  $Q_{\nu_i} \sim \chi_{\nu_i}^2$  sú navzájom nezávislé.

## Trieda transformovaných náhodných veličín s Lambertovým $W \times F_{Gama}$ rozdelením

V každom z predchádzajúcich príkladov sme sa stretli s náhodnou veličinou

$$Y = (Q_\nu - c) - c \ln \frac{Q_\nu}{c}, \quad (4)$$

kde  $Q_\nu \sim \chi_\nu^2$ ,  $c > 0$ . Po úprave

$$e^{-\frac{Y+c}{c}} = \frac{Q_\nu}{c} e^{-\frac{Q_\nu}{c}}.$$

Pri označení  $\frac{Q_\nu}{c} = U \sim Gama(\frac{\nu}{2}, \frac{1}{2c})$ ,  $\gamma = -1$  dostávame, že  $Z = e^{-\frac{Y+c}{c}} = Ue^{-U}$  patrí do triedy náhodných veličín s Lambertovým  $W \times F_{Gama}$  rozdelením a náhodná veličina

$$Y = -c - c \ln U + cU$$

je (vhodne) transformovaná náhodná veličina s Lambertovým  $W \times F_{Gama}$  rozdelením.

V ďalšom budeme skúmať triedu náhodných veličín

$$Y = \theta_1 - \theta_2 \ln X + \theta_3 X, \quad (5)$$

kde  $X$  je spojitá náhodná veličina, ktorá nadobúda nezáporné hodnoty a závisí od parametrov  $\vartheta$ ,  $\theta_1 \in \mathcal{R}$ ,  $\theta_2 > 0$ ,  $\theta_3 > 0$ . Jej distribučnú funkciu označme  $\mathcal{F}_\vartheta$ . Náhodná veličina  $Y$  nadobúda reálne hodnoty  $y \in \langle y_{min}, \infty \rangle$ , kde  $y_{min} = \theta_1 + \theta_2 - \theta_2 \ln \left( \frac{\theta_2}{\theta_3} \right)$  v bode  $x_{y_{min}} = \frac{\theta_2}{\theta_3}$ ,  $0 < x_{y_{min}} < \infty$ . Aplikáciou Lambertovej  $W$  funkcie dostaneme explicitnú inverznú transformáciu funkcie (5) a takto stanovíme exaktnú distribúciu náhodnej premennej  $Y$  ak máme distribúciu  $X$ . Distribúciu náhodnej veličiny  $Y$  označíme  $LW_{\mathcal{F}_\vartheta}^\theta$ ,  $Y \sim LW_{\mathcal{F}_\vartheta}^\theta$ . Ak  $x_L^\theta(y)$  a  $x_U^\theta(y)$  sú dve rôzne riešenia rovnice  $y = \theta_1 - \theta_2 \ln x + \theta_3 x$ , pričom  $x_L^\theta(y)$  je riešenie na intervale  $(0, x_{y_{min}})$  a  $x_U^\theta(y)$  je riešenie na intervale  $(x_{y_{min}}, \infty)$  tak distribučná funkcia  $Y$  označená ako  $F_{LW_{\mathcal{F}_\vartheta}^\theta}(\cdot)$  v bode  $y$  sa rovná

$$F_{LW_{\mathcal{F}_\vartheta}^\theta}(y) = F_{LW_{\mathcal{F}_\vartheta}^\theta}(x_U^\theta(y)) - F_{LW_{\mathcal{F}_\vartheta}^\theta}(x_L^\theta(y)). \quad (6)$$

Konkrétne

$$x_L^\theta(y) = -\frac{\theta_2}{\theta_3} W_0 \left( -\frac{\theta_3}{\theta_2} e^{-\frac{y-\theta_1}{\theta_2}} \right), \quad x_U^\theta(y) = -\frac{\theta_2}{\theta_3} W_{-1} \left( -\frac{\theta_3}{\theta_2} e^{-\frac{y-\theta_1}{\theta_2}} \right), \quad (7)$$

kde  $W_0(\cdot)$  a  $W_{-1}(\cdot)$  sú dve reálne vetvy multihodnotovej Lambertovej  $W$  funkcie ( $z = W(z)e^{W(z)}$ ) (viac pozri napr. [1]). Poznamenávame, že

$$\frac{d}{dy} x_L^\theta(y) = \frac{x_L^\theta(y)}{\theta_3 x_L^\theta(y) - \theta_2}, \quad \frac{d}{dy} x_U^\theta(y) = \frac{x_U^\theta(y)}{\theta_3 x_U^\theta(y) - \theta_2}. \quad (8)$$

Z (6) a (8) priamo dostávame hustotu náhodnej premennej  $Y \sim LW_{\mathcal{F}_\vartheta}^\theta$  :

$$f_{LW_{\mathcal{F}_\vartheta}^\theta}(y) = \frac{x_L^\theta(y)}{\theta_2 - \theta_3 x_L^\theta(y)x} f_{\mathcal{F}_\vartheta}(x_L^\theta(y)) + \frac{x_U^\theta(y)}{\theta_3 x_U^\theta(y)x - \theta_2} f_{\mathcal{F}_\vartheta}(x_U^\theta(y)), \quad (9)$$

kde  $f_{\mathcal{F}_\vartheta}(\cdot)$  je hustota náhodnej veličiny  $X$ . Ak  $y_{1-\alpha}$  je  $(1 - \alpha)$ -kvantil náhodnej veličiny  $Y$ , tak

$$y_{1-\alpha} = F_{LW_{\mathcal{F}_\vartheta}^\theta}^{-1}(1 - \alpha),$$

kde  $F_{LW_{\mathcal{F}_\vartheta}^\theta}^{-1}(\cdot)$  je kvantilová funkcia náhodnej premennej  $Y$ .



## Distribúcia náhodnej veličiny $Y \sim LW_{\mathcal{F}_\theta}^\theta$ ak $X \sim \chi_\nu^2$

Pretože distribučnú funkciu  $F_{\chi_\nu^2}(\cdot)$  náhodnej veličiny s  $X \sim \chi_\nu^2$  vieme vyjadriť pomocou neúplnej Gama funkcie  $\Gamma(n, a, b) = \int_a^b t^{n-1} e^{-t} dt$ , priamo zo vzťahu (6) dostávame

$$F_{LW_{\mathcal{F}_\theta}^\theta}(y) = F_{LW_{\mathcal{F}_{\chi_\nu^2}}^\theta}(y) = \frac{1}{\Gamma\left(\frac{\nu}{2}\right)} \Gamma\left(\frac{\nu}{2}, x_L^\theta(y), x_U^\theta(y)\right).$$

Pretože hustota  $f_{\chi_\nu^2}(\cdot)$  náhodnej veličiny  $X \sim \chi_\nu^2$  je

$$f_{\chi_\nu^2}(x) = \frac{1}{2^{\frac{\nu}{2}} \Gamma\left(\frac{\nu}{2}\right)} x^{\frac{\nu}{2}-1} e^{-\frac{x}{2}}, \quad x > 0, \quad f_{\chi_\nu^2}(x) = 0, \quad x \leq 0,$$

priamo z (9) dostávame

$$f_{LW_{\mathcal{F}_{\chi_\nu^2}}^\theta}(y) = \frac{1}{2^{\frac{\nu}{2}} \Gamma\left(\frac{\nu}{2}\right)} \left( \frac{(x_L^\theta(y))^{\frac{\nu}{2}} e^{-\frac{1}{2}x_L^\theta(y)}}{\theta_2 - \theta_3 x_L^\theta(y)} + \frac{(x_U^\theta(y))^{\frac{\nu}{2}} e^{-\frac{1}{2}x_U^\theta(y)}}{\theta_3 x_U^\theta(y) - \theta_2} \right).$$

Charakteristická funkcia  $chf_{LW_{\mathcal{F}}^{\theta} x_{\nu}^2}(\cdot)$  náhodnej veličiny  $Y \sim LW_{\mathcal{F}}^{\theta} x_{\nu}^2$  je

$$chf_{LW_{\mathcal{F}}^{\theta} x_{\nu}^2}(t) = \mathcal{E}(e^{itY}) = \frac{e^{it\theta_1} \Gamma\left(\frac{\nu}{2} - it\theta_2\right)}{2^{\frac{\nu}{2}} \Gamma\left(\frac{\nu}{2}\right) \left(\frac{1}{2} - it\theta_3\right)^{\frac{\nu}{2} - it\theta_2}}.$$

Momentová generujúca funkcia

$$mgf_{LW_{\mathcal{F}}^{\theta} x_{\nu}^2}(t) = chf_{LW_{\mathcal{F}}^{\theta} x_{\nu}^2}(it) \quad \text{pre } t < \frac{1}{2} \min\left(\frac{\nu}{\theta_2}, \frac{1}{\theta_3}\right).$$

Kumulanty  $\kappa_j$ ,  $j = 1, 2, \dots$  náhodnej veličiny  $Y \sim LW_{\mathcal{F}}^{\theta} x_{\nu}^2$  dostaneme rozvojom logaritmu momentovej vytvárajúcej funkcie:

$$\kappa_1 = \theta_1 - \theta_2 \ln 2 + \nu\theta_3 - \theta_2 \psi^{(0)}\left(\frac{\nu}{2}\right),$$

$$\kappa_j = 2^{j-1} \Gamma(j-1) \theta_3^{j-1} (-j\theta_2 + (j-1)\nu\theta_3) + (-1)^j \theta_2^j \psi^{(j-1)}\left(\frac{\nu}{2}\right), \quad j = 2, 3, \dots,$$

pričom  $\psi^{(m)}(\cdot)$  je polygamma funkcia  $m$ -tého rádu (t.j.  $(m+1)$ -vá derivácia logaritmu Gama funkcie).

Takto dostávame strednú hodnotu náhodnej premennej  $Y$

$$\mathcal{E}(Y) = \kappa_1 = \theta_1 - \theta_2 \ln 2 + \nu\theta_3 - \theta_2\psi^{(0)}\left(\frac{\nu}{2}\right),$$

rozptyl

$$\mathcal{D}(Y) = \kappa_2 = 2\theta_3(-2\theta_2 + \nu\theta_3) + \theta_2^2\psi^{(1)}\left(\frac{\nu}{2}\right),$$

koeficient šikmosti

$$\frac{\kappa_3}{\kappa_2^{\frac{3}{2}}} = \frac{4\theta_3^2(-3\theta_2 + 2\nu\theta_3) - \theta_2^3\psi^{(2)}\left(\frac{\nu}{2}\right)}{(2\theta_3(-2\theta_2 + \nu\theta_3) + \theta_2^2\psi^{(1)}\left(\frac{\nu}{2}\right))^{\frac{3}{2}}},$$

a koeficient špicatosti

$$\frac{\kappa_4}{\kappa_2^2} = \frac{16\theta_3^3(-4\theta_2 + 3\nu\theta_3) + \theta_2^4\psi^{(3)}\left(\frac{\nu}{2}\right)}{(2\theta_3(-2\theta_2 + \nu\theta_3) + \theta_2^2\psi^{(1)}\left(\frac{\nu}{2}\right))^2}.$$

Poznamenávame len, že pre náhodnú veličinu  $Y$  danú v (4), ak  $X \sim \chi_\nu^2$ , platí  $Y \sim LW_{\mathcal{F}_{\chi_\nu^2}}^\theta$ , kde  $\theta = (c(\ln c - 1), c, 1)'$ .

**Distribúcia náhodnej veličiny  $Y \sim LW_{\mathcal{F}_{x_\nu^2}}^\theta$  ak  $\theta = (\nu(\ln \nu - 1), \nu, 1)$**

Ústrednú roľu v štatistických inferenciách založených na pomere vierohodností pre normálne rozdelené dáta hrá rozdelenie náhodnej veličiny

$$Y = (Q_\nu - \nu) - \nu \ln \left( \frac{Q_\nu}{\nu} \right),$$

teda  $Y \sim LW_{\mathcal{F}_{x_\nu^2}}^\theta$ , kde  $\theta = (\nu(\ln \nu - 1), \nu, 1)$ .

Základné pravdepodobnostné charakteristiky náhodnej veličiny

$Y \sim LW_{\mathcal{F}_{x_\nu^2}}^\theta$ ,  $\theta = (\nu(\ln \nu - 1), \nu, 1)$ :

distribučná funkcia

$$F_{LW_{\mathcal{F}}^{\theta}}(y) = {}_{\nu}F(x) = \begin{cases} \frac{1}{\Gamma(\frac{\nu}{2})} \left[ \gamma\left(\frac{\nu}{2}, \frac{x_{2,y}}{2}\right) - \gamma\left(\frac{\nu}{2}, \frac{x_{1,y}}{2}\right) \right], & \text{ak } x > 0, \\ 0, & \text{ak } x \leq 0, \end{cases}$$

kde  $\Gamma(a, 0, x) = \int_0^x t^{a-1} e^{-t} dt$ ,  $a > 0$ ,  $x > 0$  (neúplná Gama funkcia),  $x_{1,y}$  je riešenie rovnice

$$y = -\nu \ln \frac{x}{\nu} + x - \nu \quad (10)$$

pre  $x \in (0, \nu)$  a  $x_{2,y}$  je riešenie rovnice (10) pre  $x \in (\nu, \infty)$ ,

*hustota*

$${}_{\nu}f(y) = \begin{cases} \left| \frac{x_{1,y}}{x_{1,y} - \nu} \right| f_{\chi^2_{\nu}}(x_{1,y}) + \left| \frac{x_{2,y}}{x_{2,y} - \nu} \right| f_{\chi^2_{\nu}}(x_{2,y}), & \text{ak } y > 0, \\ 0, & \text{ak } y \leq 0, \end{cases}$$

*charakteristická funkcia (chf)*

$${}_{\nu}chf(t) = \frac{\Gamma\left(\frac{\nu}{2} - \nu t\right)}{\Gamma\left(\frac{\nu}{2}\right)} \left(\frac{\nu}{2e}\right)^{\nu t} (1 - 2it)^{\nu t - \frac{\nu}{2}},$$

momentová generujúca funkcia (mgf)

$${}_{\nu} \text{mgf}(t) = \frac{\Gamma\left(\frac{\nu}{2} - \nu t\right)}{\Gamma\left(\frac{\nu}{2}\right)} \left(\frac{\nu}{2e}\right)^{\nu t} (1 - 2t)^{\nu t - \frac{\nu}{2}}, \quad 0 \leq t < \frac{1}{2}, \quad (11)$$

počiatočné momenty

$$\mu'_1 = \mu = -\nu \frac{\Gamma'\left(\frac{\nu}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right)} + \nu \ln \frac{\nu}{2},$$

$$\mu'_2 = \nu^2 \frac{\Gamma''\left(\frac{\nu}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right)} + \nu^2 (\ln \frac{\nu}{2})^2 - 2\nu - 2\nu^2 \frac{\Gamma'\left(\frac{\nu}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right)} \ln \frac{\nu}{2},$$

$$\begin{aligned} \mu'_3 = & \nu^3 \frac{\Gamma'''\left(\frac{\nu}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right)} + \nu^3 (\ln \frac{\nu}{2})^3 - 4\nu + 3\nu^3 \frac{\Gamma''\left(\frac{\nu}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right)} \ln \frac{\nu}{2} - 3\nu^3 \frac{\Gamma'\left(\frac{\nu}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right)} (\ln \frac{\nu}{2})^2 + \\ & + 6\nu^2 \frac{\Gamma'\left(\frac{\nu}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right)} - 6\nu^2 \ln \frac{\nu}{2}, \end{aligned}$$

## centrálne momenty

$$\mu_2 = -\nu \left( 2 - \nu \left\{ \frac{\Gamma'(z)}{\Gamma(z)} \right\}'_{z=\frac{\nu}{2}} \right),$$

$$\mu_3 = -\nu \left( 4 - \nu^2 \left\{ \frac{\Gamma'(z)}{\Gamma(z)} \right\}''_{z=\frac{\nu}{2}} \right),$$

## kumulanty

$$\kappa_2 = -2,$$

$$\kappa_k = -\nu \left( a_k + (-\nu)^{k-1} \psi^{(k-1)} \left( \frac{\nu}{2} \right) \right), \quad a_2 = 2, \quad a_k = 2a_{k-1}(k-1) \quad k = 3, 4, \dots$$



**Poznámka.** Po zdĺhavých výpočtoch sa dá ukázať, že momentová generujúca funkcia (11) konverguje pre  $\nu \rightarrow \infty$  k momentovej generujúcej funkcii  $\chi_1^2$  rozdelenia, t.j. k funkcii  $(1 - 2t)^{-1/2}$ . Náhodná veličina  $Y \sim LW_{\mathcal{F}_{\chi_1^2}}^\theta$ ,  $\theta = (\nu(\ln \nu - 1), \nu, 1)$  konverguje v distribúcii k náhodnej veličine s  $\chi_1^2$  rozdelením.

**Poznámka.** Invertovaním testu pomerom vierohodnosti priamo dostaneme realizáciu exaktnej simultánnej  $(1 - \alpha)$ -konfidenčnej oblasti pre parametre modelu (2), ktorá (oblasť) je založená na funkcii vierohodnosti.

**Pod'akovanie.** Výskum bol podporený grantami APVV/0096/10 a VEGA 2/0038/12.

## Literatúra



Corless, R. M., Gonnet, G. H., Hare, D. E. G., Jeffery, G. J., Knuth, D. E.:  
On the Lambert W function.  
*Advances in Computational Mathematics* 5 (1996), 329–359.



Goerg, G., M.:  
Lambert W Random Variables - a New Family of Generalized skewed  
Distributions with Applications to Risk Estimation.  
*The Annals of Applied Statistics* 5(3) (2011), 1–34.



Witkovský, V.:  
O niektorých exaktných simultánných konfidenčných oblastiach  
založených na funkcii vierohodnosti pre parametre normálneho LRM.  
*Sborník XIX. letní školy biometriky, Lednica 6.-10.9.2010.*

Ďakujeme za pozornosť