



## 2 Statistická inference II - cvičení 16-03-01

### Řešení příkladů z domácí úlohy - SI I

#### Příklad č.4 (kvadratická approximace profilové funkce věrohodnosti)

- (a) Nakreslete škálovaný logaritmus profilové funkce věrohodnosti normálního rozdělení pro  $\mu$ . Na ose  $x$  bude  $\mu$  a na ose  $y$   $\ln \mathcal{L}_P(\mu|\mathbf{x}) = l_P(\mu|\mathbf{x}) - l_P(\hat{\mu}|\mathbf{x})$ . Porovnejte  $\ln \mathcal{L}_P(\mu|\mathbf{x})$  s kvadratickou approximací vypočítanou pomocí Taylorova rozvoje  $\ln \mathcal{L}_P(\mu|\mathbf{x}) = \ln\left(\frac{L_P(\mu|\mathbf{x})}{L_P(\hat{\mu}|\mathbf{x})}\right) \approx -\frac{1}{2}\mathcal{I}(\hat{\mu})(\mu - \hat{\mu})^2$ .
- (b) Nechť skóre funkce  $S(\mu) = \frac{\partial}{\partial \mu} \ln L_P(\mu|\mathbf{x})$ . Vezmeme-li derivaci kvadratické approximace uvedené výše, dostaneme  $S(\mu) \approx -\mathcal{I}(\hat{\mu})(\mu - \hat{\mu})$  nebo  $-\mathcal{I}^{-1/2}(\hat{\mu})S(\mu) \approx \mathcal{I}^{1/2}(\hat{\mu})(\mu - \hat{\mu})$ . Potom zobrazením pravé strany na ose  $x$  a levé strany na ose  $y$  dostaneme asymptoticky lineární funkci s jednotkovým sklonem. Asymptoticky také platí  $\mathcal{I}^{1/2}(\bar{X})(\mu - \bar{X}) \xrightarrow{D} N(0, 1)$ . Je postačující mít rozsah osy  $x$  rovný  $(-2, 2)$ , protože funkce je asymptoticky (lokálně) lineární na tomto intervalu. Rozumně škálujte osu  $y$ . Zobrazte pro (a)  $n = 10$ , (b)  $n = 100$  a (c)  $n = 1000$ . Použijte (1)  $X \sim N(0, 1)$  a (2)  $X \sim (1-p)N(0, 1) + pN(0, 2)$ , kde  $p = 0.05$ . Okomentujte rozdíly mezi (a), (b) a (c), stejně jako rozdíly mezi (1) a (2).






## Statistická inference II – příklady

### Příklad č.1 (Generování pseudonáhodných čísel)

1. Nechť  $Y \sim pN(\mu_1, \sigma_1^2) + (1-p)N(\mu_2, \sigma_2^2)$ , kde  $\mu_1 = 2$ ,  $\mu_2 = 3$ ,  $\sigma_1^2 = 0.5^2$  a  $\sigma_2 = 0.8^2$ . Vygenerujte  $n = 1000$  pseudonáhodných čísel z tohoto smíšeného rozdělení.




2. Nechť  $X_1 \sim N(\mu_1, \sigma_1^2)$  a  $X_2 \sim N(\mu_2, \sigma_2^2)$ . Potom náhodný vektor  $(X_1, X_2)^T$  pochází z dvourozměrného normálního rozdělení s vektorem středních hodnot  $\boldsymbol{\mu} = (\mu_1, \mu_2)^T$  a variační maticí  $\Sigma$

$$\Sigma \begin{pmatrix} \sigma_1^2 & \rho \\ \rho & \sigma_2^2 \end{pmatrix} \quad (1)$$

Vygenerujte  $n = 500$  pseudonáhodných čísel z dvourozměrného normálního rozdělení, pokud  $\mu_1 = 2$ ,  $\mu_2 = 3$ ,  $\sigma_1^2 = 0.5^2$ ,  $\sigma_2^2 = 1$ ,  $\rho = 0.3$ . K vygenerování použijte

- (a) funkci `mvrnorm()` z knihovny MASS;
- (b) funkci `rmvtnorm()` z knihovny mvtnorm.



## Příklad č.2 (MC experiment pro IS)



Nechť

(a)  $X \sim N(0, 1)$ ;



(b)  $X \sim pN(0, 1) + (1-p)N(0, 4)$ , kde  $p = 0.9$ , tedy jde o směs dvou normálních rozdělení  $X \sim N(0, 1)$  a  $X \sim N(0, 4)$  v poměru 9 : 1.

Pro obě části (a) i (b):

1. Vygenerujte  $M = 100$  náhodných výběrů s rozsahem  $n = 500$  a vypočítejte Waldovy  $100(1-\alpha)\%$  empirické IS pro střední hodnotu  $\mu$ , když  $\sigma^2$  známe. Spočítejte, kolik IS obsahuje střední hodnotu  $\mu = 0$ . Toto číslo podělené hodnotou  $M$  představuje simulovanou hladinu významnosti  $\alpha$ .



2. Vygenerujte  $M = 100$  náhodných výběrů s rozsahem  $n = 500$  a vypočítejte Waldovy  $100(1-\alpha)\%$  empirické IS pro střední hodnotu  $\mu$ , když  $\sigma^2$  známe. Spočítejte, kolik IS obsahuje střední hodnotu  $\mu = 0$ . Toto číslo podělené hodnotou  $M$  představuje simulovanou hladinu významnosti  $\alpha$ .



3. Postupy (1) a (2) zopakujte  $N = 100 \times$  a zjistěte, jaká je průměrná simulovaná hladina významnosti  $\alpha$  v těchto stech pokusech.