

## Zadání příkladů – Statistická inference II – 2017

**Příklad 1. Směs dvou normálních rozdělení** Nechť náhodná veličina  $X$  pochází ze směsi dvou normálních rozdělení  $X \sim [pN(\mu_1, \sigma_1^2) + (1-p)N(\mu_2, \sigma_2^2)]$ . Potom marginální hustota náhodné veličiny  $X$  má tvar

$$f(x_i, \theta) = \sum_{b_i \in \{0,1\}} f(x_i, b_i, \theta) = f(x_i, 1, \theta_1) + f(x_i, 0, \theta_2),$$

kde

$$f(x_i, 1, \theta_1) = \frac{p}{\sqrt{2\pi}\sigma_1} \exp\left(-\frac{(x_i - \mu_1)^2}{2\sigma_1^2}\right)$$

je sdružená hustota za podmínky, že data pochází z první skupiny a

$$f(x_i, 0, \theta_2) = \frac{1-p}{\sqrt{2\pi}\sigma_2} \exp\left(-\frac{(x_i - \mu_2)^2}{2\sigma_2^2}\right)$$

je sdružená hustota za podmínky, že data pochází z druhé skupiny.

Logaritmická věrohodnostní funkce náhodné veličiny  $X$  má tvar


$$L(\theta | \mathbf{x}) = \prod_{i=1}^n f(x_i, \theta).$$

### Příklad 2. Odhad parametrů směsi dvou normálních rozdělení

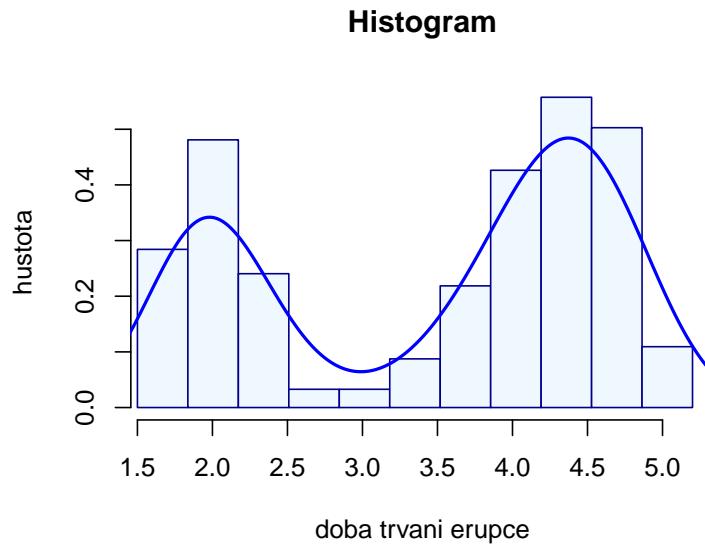
1. Načtěte datový soubor `faithful` obsahující údaje o době čekání na erupci (`waiting`) a o době trvání erupce (`eruption`), přičemž se zaměřte na proměnnou `waiting`.
2. Nakreslete histogram doby čekání na erupci a superponujte jej křivkou jádrového odhadu.
3. Pomocí funkce `optim()` odhadněte parametry  $p, \mu_1, \mu_2, \sigma_1^2, \sigma_2^2$  smíšeného rozdělení  $[pN(\mu_1, \sigma_1^2) + (1-p)N(\mu_2, \sigma_2^2)]$  náhodné proměnné `waiting`.
4. Pomocí funkce `optim()` nalezněte rozptyly odhadů parametrů  $\hat{p}, \hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2$ .

Body 1.–3. aplikujte také na proměnnou `eruption`.

```
a) ##          p      mu1 sigma1      mu2 sigma2
## MLE 0.3609 54.6145 5.8698 80.0908 5.8682
## Var  0.0010  0.4893 0.2884  0.2547 0.1608
```



```
b) ##          p      mu1 sigma1      mu2 sigma2
## MLE 0.3482 2.0183 0.2356 4.2733 0.4370
## Var 0.0009 0.0007 0.0005 0.0012 0.0007
```



**Příklad 3. Dvouozměrná Newton-Raphsonova metoda** Nechť náhodná veličina  $X$  pochází z normálního rozdělení se střední hodnotou  $\mu$  a rozptylem  $\sigma^2$ , tj.  $X \sim N(\mu, \sigma^2)$ . Hustota náhodné veličiny  $X$  má tvar

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right).$$

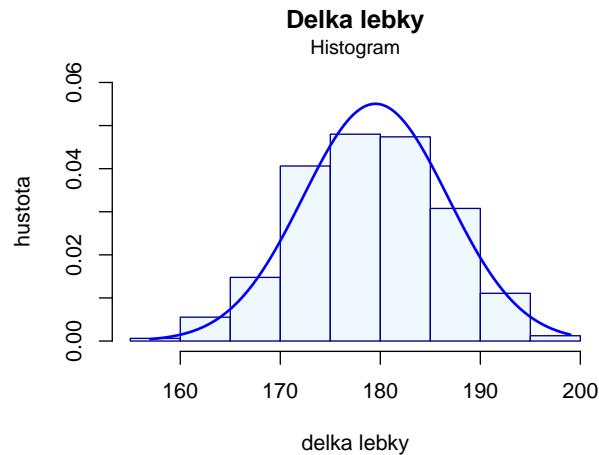
1. Odvod'te tvar věrohodnostní a logaritmické věrohodnostní funkce pro  $N(\mu, \sigma^2)$ .
2. Odvod'te tvar skóre funkce pro parametr  $\mu$  a pro parametr  $\sigma$  (ne  $\sigma^2$ !!!).
3. Odvod'te tvary druhých parciálních derivací logaritmické věrohodnostní funkce podle parametrů  $\mu$  a  $\sigma$  (celkem 4).
4. Naprogramujte v R dvouozměrnou Newton-Raphsonovu metodu pro normální rozdělení  $N(\mu, \sigma^2)$ . Funkci pojmenujte **NMnorm**.

Naprogramovanou funkci nyní vyzkoušíme na reálných datech.

5. Načtěte datový soubor *one-sample-mean-skull-mf.txt*.
6. Vykreslete histogram proměnné délka lebky (**skull.L**).
7. Pomocí naprogramované funkce **NMnorm** odhadněte parametr  $\mu$  a  $\sigma$  proměnné **skull.L**.
8. Odhadu získané pomocí funkce **NMnorm** porovnejte s bodovými odhady parametrů  $\mu$  a  $\sigma$ .
9. Body 6–8 aplikujte také na proměnnou šířka lebky (**skull.B**).

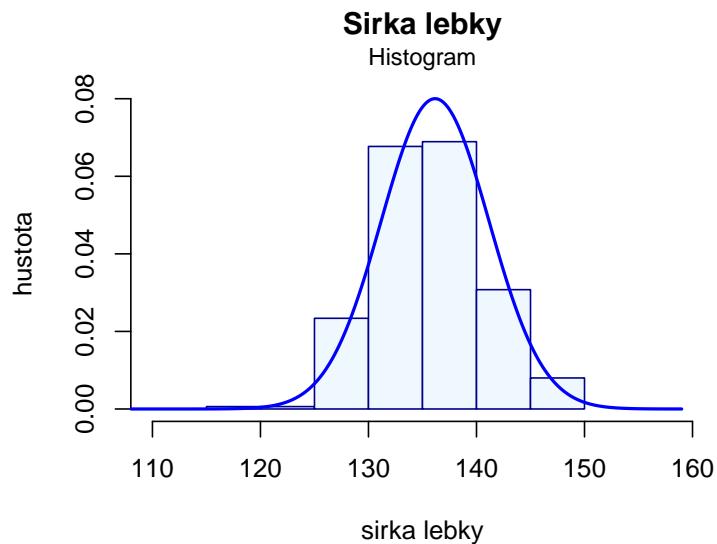
a) Délka lebky

```
##           mu   sigma
## Newtonova metoda 179.5169 7.1390
## exaktni vypocet  179.5169 7.2249
```



b) Šířka lebky

```
##           mu   sigma
## Newtonova metoda 136.1662 4.9247
## exaktni vypocet  136.1662 4.9708
```



#### Příklad 4. Broydenova metoda

1. Naprogramujte v R Broydenovu metodu (dvouozměrnou metodu sečen) pro normální rozdělení  $N(\mu, \sigma^2)$ . Funkci pojmenujte BrMnorm().
2. Načtěte datový soubor *one-sample-mean-skull-mf.txt*.
3. Pomocí funkce BrMnorm() získejte odhad parametrů  $\mu$  a  $\sigma$  délky lebky skull.L.
4. Pomocí funkce BrMnorm() získejte odhad parametrů  $\mu$  a  $\sigma$  šířky lebky skull.B.
3. Broydenova metoda aplikovaná na proměnnou skull.L

```
##                      mu  sigma
## Broydenova metoda 179.5174 7.2333
## exaktni vypocet   179.5169 7.2249
```

4. Broydenova metoda aplikovaná na proměnnou skull.B

```
##                      mu  sigma
## Broydenova metoda 136.1481 5.0360
## exaktni vypocet   136.1662 4.9708
```

### Příklad 5. MC experiment pro Waldovy empirické intervaly spolehlivosti 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) Vygenerujte  $M = 100$  náhodných výběrů s rozsahem  $n = 500$  a vypočítejte:


1. Waldovy exaktní empirické  $100(1 - \alpha)\%$  IS pro rozptyl  $\sigma^2$ , když  $\mu$  neznáme.
2. Waldovy asymptotické empirické  $100(1 - \alpha)\%$  IS pro rozptyl  $\sigma^2$ , když  $\mu$  neznáme.
3. Waldovy asymptotické empirické  $100(1 - \alpha)\%$  IS pro směrodatnou odchylku  $\sigma$ , když  $\mu$  neznáme.

Vždy spočítejte, kolik IS obsahuje rozptyl  $\sigma^2 = 1$  (resp. směrodatnou odchylku  $\sigma = 1$ ). Toto číslo podělené hodnotou  $M$  představuje simulovanou hladinu významnosti  $\alpha$ .

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


1. Waldovy exaktní empirické  $100(1 - \alpha)\%$  IS pro rozptyl  $\sigma^2$ , když  $\mu$  neznáme.

```
##          n
## simulovany pocet 48.0
## presny pocet     47.5
```




2. Waldovy asymptotické empirické  $100(1 - \alpha)\%$  IS pro rozptyl  $\sigma^2$ , když  $\mu$  neznáme.

```
##          n
## simulovany pocet 45.0
## presny pocet     47.5
```



3. Waldovy asymptotické empirické  $100(1 - \alpha)\%$  IS pro směrodatnou odchylku  $\sigma$ , když  $\mu$  neznáme.


```
##          n
## simulovaný počet 48.0
## presný počet     47.5
```



b)  $X \sim pN(0, 1) + (1 - p)N(0, 4)$


1. Waldovy exaktní empirické  $100(1 - \alpha)\%$  IS pro rozptyl  $\sigma^2$ , když  $\mu$  neznáme.

```
##          n
## simulovaný počet 42.0
## presný počet     47.5
```




2. Waldovy asymptotické empirické  $100(1 - \alpha)\%$  IS pro rozptyl  $\sigma^2$ , když  $\mu$  neznáme.

```
##          n
## simulovaný počet 45.0
## presný počet     47.5
```



3. Waldovy asymptotické empirické  $100(1 - \alpha)\%$  IS pro směrodatnou odchylku  $\sigma$ , když  $\mu$  neznáme.

```
##          n
## simulovaný počet 43.0
## presný počet     47.5
```



**Příklad 6. Simultánní oblasti spolehlivosti + elipsa spolehlivosti pro střední hodnotu a rozptyl (resp. směrodatnou odchylku)** Empirické  $100(1 - \alpha)\%$  asymptotické intervaly spolehlivosti Waldova typu pro  $\mu$ ,  $\sigma^2$  a  $\sigma$  jsou pro neznámé  $\sigma$  definovány následujícím způsobem:


$$\Pr\left(\bar{x} - u_{1-\alpha/2}\sqrt{\hat{\sigma}^2/n} < \mu < \bar{x} + u_{\alpha/2}\sqrt{\hat{\sigma}^2/n}\right) = 1 - \alpha$$

$$\Pr\left(\hat{\sigma}^2 - u_{1-\alpha/2}\sqrt{2\hat{\sigma}^4/n} < \sigma^2 < \hat{\sigma}^2 + u_{\alpha/2}\sqrt{2\hat{\sigma}^4/n}\right) = 1 - \alpha$$

$$\Pr\left(\hat{\sigma} - u_{1-\alpha/2}\sqrt{\hat{\sigma}^2/2n} < \sigma < \hat{\sigma} + u_{\alpha/2}\sqrt{\hat{\sigma}^2/2n}\right) = 1 - \alpha$$

1. (a) Nakreslete simultánní množinu spolehlivosti pro  $\theta = (\mu, \sigma^2)^T$  použitím exaktních intervalů spolehlivosti pro  $\mu$  a pro  $\sigma^2$ .
  - (b) Nakreslete simultánní množinu spolehlivosti pro  $\theta = (\mu, \sigma^2)^T$  použitím asymptotických intervalů spolehlivosti pro  $\mu$  a pro  $\sigma^2$ .
  - (c) Do obrázku dokreslete  $100(1-\alpha)\%$  elipsu spolehlivosti pro  $\theta = (\mu, \sigma^2)^T$  použitím asymptotických intervalů spolehlivosti pro  $\mu$  a pro  $\sigma^2$ .
2. (a) Nakreslete simultánní množinu spolehlivosti pro  $\theta = (\mu, \sigma)^T$  použitím exaktních intervalů spolehlivosti pro  $\mu$  a pro  $\sigma$ .
  - (b) Nakreslete simultánní množinu spolehlivosti pro  $\theta = (\mu, \sigma)^T$  použitím asymptotických intervalů spolehlivosti pro  $\mu$  a pro  $\sigma$ .
  - (c) Do obrázku dokreslete  $100(1-\alpha)\%$  elipsu spolehlivosti pro  $\theta = (\mu, \sigma)^T$  použitím asymptotických intervalů spolehlivosti pro  $\mu$  a pro  $\sigma$ .

Použijte (1)  $n = 10$ , (2)  $n = 100$ , (3)  $n = 10000$ . V (1), (2) a (3) zvolte  $\mu = 0$  a  $\sigma^2 = 1$  resp.  $\sigma^2 = 4$ . Koeficient spolehlivosti simultánní množiny zvolte  $1 - \alpha = 0.95$ .






**Příklad 7. Rozdělení výběrového rozptylu a výběrové směrodatné odchylky: simulační studie** Nechť  $X \sim N(\mu, \sigma^2)$ , potom

1. výběrový rozptyl  $S_n^2 \sim N(\sigma^2, \frac{2\sigma^4}{n})$ ;
2. výběrová směrodatná odchylka  $S_n \sim N(\sigma, \frac{\sigma^2}{2n})$ .
3. testovací statistika  $\frac{nS_n^2}{\sigma^2}$  pochází z  $\chi^2$  rozdělení o  $n$  stupních volnosti, tj.  $\frac{nS_n^2}{\sigma^2} \sim \chi_n^2$ .

Vygenerujte  $M = 1000$  náhodných výběrů z normálního rozdělení  $N(\mu, \sigma^2)$  o rozsahu  $n$ , kde  $\mu = 0$  a  $\sigma^2 = 4$ , resp.  $\sigma^2 = 1$ . Použijte (i)  $n = 10$ , (ii)  $n = 50$  a (iii)  $n = 500$ .

- (a) Pro každý náhodný výběr vypočítejte statistiku  $S_{n,i}^2$ ,  $i = 1, \dots, M$  a statistiky  $S_{n,i}$  zobrazte pomocí histogramu. Histogram superponujte křivkami hustoty asymptotického a exaktního rozdělení statistiky  $S_n^2$ .
- (b) Pro každý náhodný výběr vypočítejte statistiku  $S_{n,i}$ ,  $i = 1, \dots, M$  a statistiky  $S_{n,i}$  zobrazte pomocí histogramu. Histogram superponujte křivkami hustoty asymptotického a exaktního rozdělení statistiky  $S_n$ .






**Příklad 8.** P Předpokládejme, že  $X \sim N(\mu, \sigma^2)$ , kde  $\sigma^2$  známe. Nechť  $\theta = \mu$ . Testujeme všechny tři typy hypotéz

- a)  $H_{01} : \mu = \mu_0$  oproti  $H_{11} : \mu \neq \mu_0$  (oboustranná);
- b)  $H_{02} : \mu \leq \mu_0$  oproti  $H_{12} : \mu > \mu_0$  (pravostranná);
- c)  $H_{03} : \mu \geq \mu_0$  oproti  $H_{13} : \mu < \mu_0$  (levostranná).

1. Odvod'te tvary silofunkcí pro všechny tři typy hypotéz (a)–(c), t.j. tvary  $\beta_{11}^*(\mu)$ ,  $\beta_{12}^*(\mu)$  a  $\beta_{13}^*(\mu)$ .

2. Nakreslete silofunkce pro všechny tři typy hypotéz (a)–(c), kde  $\mu_0 = 0$ , a  $\sigma^2 = 1$ . Do jednoho obrázku zakreslete vždy tvary silofunkcí pro  $n = 10$ ,  $n = 30$ ,  $n = 50$  a  $n = 100$ . Hladinu významnosti  $\alpha$  zvolte 0.05. Hodnoty  $\mu$  volte rozumně, např. v intervalu  $(-1.5; 1.5)$ .





### Příklad 9. Rozdělení testovací statistiky pro test o střední hodnotě $\mu$ , když $\sigma^2$ neznáme

- Nechť náhodný výběr  $X$  pochází z normálního rozdělení, t.j.  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 600$  a  $\sigma^2 = 100^2$ . Rozsah náhodného výběru  $n = 20$ . Pomocí simulační studie v R porovnejte rozdělení testovací statistiky pro test 'nepřesně zvolené' nulové hypotézy  $H_0: \mu \leq 500$  (alternativní hypotéza  $H_1: \mu > 500$ ), když rozptyl  $\sigma^2$  neznáme, s rozdělením testovací statistiky nulové hypotézy  $H_0: \mu \leq 600$  (alternativní hypotéza  $H_1: \mu > 600$ ), opět když  $\sigma^2$  neznáme.


Nasimuluje M pseudonáhodných výběrů,  $M=1,\dots,10\,000$  a pro každý vypočítejte realizaci testovací statistiky  $t_{W,\lambda}^{(m)} = \frac{\bar{x}_m - \mu_0}{s_m} \sqrt{n}$  pro nulovou hypotézu  $H_0: \mu \leq 500$  oproti  $H_1: \mu > 500$ . Histogram superponujte jednak křivkou hustoty necentrálního  $t$ -rozdělení s  $n-1$  stupni volnosti a parametrem necentrality  $\lambda$  ( $\lambda = \frac{\mu_1 - \mu_0}{\sigma/\sqrt{n}}$ , kde  $\mu_1$  je vzatá z alternativní hypotézy) a jednak křivkou hustoty centrálního studentova rozdělení. Obě křivky potom vzájemně okometricky porovnejte.

- Nechť nyní  $X$  pochází ze směsi dvou normálních rozdělení, t.j.  $X \sim [pN(\mu, 100^2) + (1-p)N(\mu, 150^2)]$ , kde  $p = 0.9$  a  $\mu = 600$ . Proveďte simulační studii popsanou v bodě (1) pro tento náhodný výběr.





**Příklad 10. empirická a exaktní silofunkce testu; pokračování příkladu č.9**

- Nechť náhodný výběr  $X$  pochází z normálního rozdělení, t.j.  $X \sim N(\mu_1, \sigma^2)$ , kde  $\mu_1 = 470, 480, \dots, 590, 600$  a  $\sigma^2 = 100^2$ . Rozsah náhodného výběru  $n = 20$ . Použijte R na simulaci empirické silofunkce pro jednovýběrový Studentův  $t$ -test nulové hypotézy  $H_0: \mu \leq 500$  oproti  $H_1: \mu > 500$ . Vygenerujte  $M = 1\,000$  pseudonáhodných výběrů a pro každý stanovte hodnotu testovací statistiky  $t_m$ ,  $m = 1, \dots, 1\,000$ . Dále vypočítejte  $p$ -hodnotu korespondující s  $t_m$  a porovnejte ji s hladinou významnosti  $\alpha = 0.05$ . Tak získáte empirickou silofunkci  $1 - \widehat{\beta}(\mu_1)$  pro zvolenou alternativní hypotézu. Do grafu zakreslete  $1 - \widehat{\beta}(\mu_1)$  i její standardizované chyby  $SE[1 - \widehat{\beta}(\mu_1)] = \sqrt{\frac{(1 - \widehat{\beta}(\mu_1))\widehat{\beta}(\mu_1)}{M}}$  v podobě chybové úsečky  $1 - \widehat{\beta}(\mu_1) \pm SE[1 - \widehat{\beta}(\mu_1)]$ . Do grafu v kreslete také teoretickou silofunkci  $1 - \beta(\mu_1)$ ,  $\mu_1 \in \langle 470 ; 600 \rangle$  (na její výpočet použijte funkci power.t.test()).
- Nechť nyní  $X$  pochází ze směsi dvou normálních rozdělení, t.j.  $X \sim [pN(\mu_1, 100^2) + (1-p)N(\mu_1, 200^2)]$ , kde  $p = 0.9$  a  $\mu_1 = 470, \dots, 600$ . Proveďte simulační studii popsanou v bodě (1) pro tento náhodný výběr.



**Příklad 11. Přesná a přibližná silofunkce – Jednovýběrový Z-test o střední hodnotě** Uveďte tvary přesné silofunkce  $\hat{\beta}_{12}^*$  a přibližné silofunkce  $\tilde{\beta}_{12}^*$  pro test  $H_0 : \mu = \mu_0$  oproti  $H_1 : \mu \neq \mu_0$  když  $\sigma^2$  známe. Nakreslete křivky obou silofunkcí do jednoho grafu, kde na ose  $x$  budou různé hodnoty parametru  $\mu$  na ose  $y$  vynesená silofunkce, a porovnejte jejich tvary. Výsledek slovně okomentujte. Hodnotu  $n$  zvolte 20,  $\mu_0 = 0$  a  $\sigma^2 = 4$ . Rozsah osy  $x$  volte rozumně, pro globální pohled např.  $\langle -1.5; 1.5 \rangle$ , pro lokální zaměření rozdílů zvolte rozsah osy  $x$   $\langle -0.8; 0.8 \rangle$ .



**Příklad 12. MC experiment pro Waldovy empirické intervaly spolehlivosti** Nechť

(a)  $X \sim N(20, 100)$ ;


(b)  $X \sim pN(20, 100) + (1 - p)N(20, 400)$ , kde  $p = 0.9$ , tedy jde o směs dvou normálních rozdělení  $X \sim N(20, 100)$  a  $X \sim N(20, 400)$  v poměru 9 : 1.

Pro obě části (a) i (b) Vygenerujte  $M = 100$  náhodných výběrů s rozsahem  $n = 5$ , resp.  $n = 50$  a  $n = 100$  a vypočítejte Waldovy empirické  $100(1 - \alpha)\%$  IS pro střední hodnotu  $\mu$ , když  $\sigma^2$  neznáme. Vždy spočítejte, kolik IS obsahuje střední hodnotu  $\mu = 20$ . Toto číslo podělené hodnotou  $M$  představuje aktuální pravděpodobnost pokrytí (simulovanou spolehlivost  $1 - \alpha$ ). Porovnejte tuto hodnotu s nominální pravděpodobností pokrytí (spolehlivost  $1 - \alpha$ ).

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


$n = 5$

```
##                                     n
## aktualni pst.pokryti          0.95
## nominalni pst.pokryti (spolehlivost) 0.95
```



$n = 100$


```
##                                     n
## aktualni pst.pokryti          0.95
## nominalni pst.pokryti (spolehlivost) 0.95
```



b)  $X \sim pN(20, 100) + (1-p)N(20, 400)$


$n = 5$

```
##                                     n
## aktualni pst.pokryti          0.97
## nominalni pst.pokryti (spolehlivost) 0.95
```



$n = 100$


```
##                                     n
## aktualni pst.pokryti          0.94
## nominalni pst.pokryti (spolehlivost) 0.95
```



**Příklad 13. nezávislost  $\mu$  a  $\sigma^2$ ; pravděpodobnost pokrytí** Nechť  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 20$  a  $\sigma^2 = 100$ . Pomocí simulační studie vypočítejte Pearsonův korelační koeficient  $r_{\bar{X}, S}$ . Nakreslete šedou barvou rozptylový graf  $(\bar{x}_m, s_m)$ , kde  $m = 1, 2, \dots, M$ , přičemž  $M = 5000$ . Černou barvou vyznačte v grafu takové body  $(\bar{x}_m, s_m)$ , pro které platí  $t_{W,m} = \left| \frac{\bar{x}_m - \mu}{s_m} \sqrt{n} \right| < t_{n-1}(\alpha/2)$ . Dále vykreslete hranice, které jsou definovány body  $(\bar{x}_m, s_m)$ , jež splňují vztah  $t_{W,m} = t_{n-1}(\alpha/2)$ . Vypočítejte pravděpodobnost pokrytí 95 % DIS pro  $\mu$  jako podíl  $\sum_m I(t_{W,m} < t_{n-1}(\alpha/2))/M$ . Zvolte (a)  $n = 5$ , (b)  $n = 50$  a (c)  $n = 100$ .

Simulaci proveděte také za předpokladu, že data pochází ze smíšeného rozdělení  $X \sim [pN(\mu, \sigma_1^2) + (1-p)N(\mu, \sigma_2^2)]$ , kde  $p = 0.9$ ,  $\mu = 20$ ,  $\sigma_1^2 = 100$  a  $\sigma_2^2 = 400$ .

```
##                                     n
## aktuální pst.pokryti          0.952
## nominální pst.pokryti (spolehlivost) 0.950
##                                     n
## aktuální pst.pokryti          0.9435
## nominální pst.pokryti (spolehlivost) 0.9500
```



```
##                                     n
## aktuální pst.pokryti          0.948
## nominální pst.pokryti (spolehlivost) 0.950
##                                     n
## aktuální pst.pokryti          0.936
## nominální pst.pokryti (spolehlivost) 0.950
```

