



Zadání příkladů – Statistická inference II – 2017



Příklad 12. nezávislost μ a σ^2 ; pravděpodobnost pokrytí Necht' $X \sim N(\mu, \sigma^2)$, 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 μ 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 proveďte 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
## aktualni pst.pokryti                0.952
## nominalni pst.pokryti (spolehlivost) 0.950
##                                     n
## aktualni pst.pokryti                0.958
## nominalni pst.pokryti (spolehlivost) 0.950
```



```
##                                     n
## aktualni pst.pokryti                0.958
## nominalni pst.pokryti (spolehlivost) 0.950
##                                     n
## aktualni pst.pokryti                0.9425
## nominalni pst.pokryti (spolehlivost) 0.9500
```



```
##                                     n
## aktualni pst.pokryti                0.946
## nominalni pst.pokryti (spolehlivost) 0.950
##                                     n
## aktualni pst.pokryti                0.942
## nominalni pst.pokryti (spolehlivost) 0.950
```



Příklad 13. konvergence ρ a ξ k normálnímu rozdělení

1. Proveďte simulaci pseudonáhodných čísel z $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, kde $\mu_1 = 0$, $\mu_2 = 0$, $\sigma_1 = 1$, $\sigma_2 = 1$, $M = 10\,000$, $\rho = 0.8$.

Pro každé $m = 1, 2, \dots, M$, vypočítejte realizaci výběrového korelačního koeficientu r_m a Fisherovy Z -proměnné $z_{R,m}$. Zobrazte histogramy simulovaných r_m a $z_{R,m}$ a superponujte je teoretickými hustotami příslušných normálních rozdělení. Vytvořte animaci zobrazující rozdělení výběrového korelačního koeficientu R a Fisherovy Z transformace pro různé rozsahy náhodného výběru $n \in \{5, 10, \dots, 70\}$.


2. Vytvořte animaci zobrazující rozdělení výběrového korelačního koeficientu $R \in \{0.1, 0.2, \dots, 0.9\}$ a Fisherovy Z transformace pro tyto různé korelační koeficienty. Animace vytvořte pro (a) $n = 5$, (b) $n = 10$, (c) $n = 100$.

Příklad 14. Test o korelačním koeficientu ρ : Mějme data `one-sample-correlation-skull-mf.txt` a proměnné největší výška mozkovny `skull.pH` a morfologická výška tváře `face.H` (obě v mm) starověké egyptské mužské populace, o kterých předpokládáme, že mají dvourozměrné normální rozdělení $N_2(\boldsymbol{\mu}, \boldsymbol{\Sigma})$.

- Otestujte hypotézu o tom, že korelační koeficient největší výšky mozkovny a morfologické výšky tváře je rovný 0.251.
- Vypočítejte $100 \times (1 - \alpha)\%$ empirický DIS pro korelační koeficient, kde koeficient spolehlivosti $1 - \alpha = 0.95$.

Použijte

- Waldovu testovací statistiku Z_W ;
- testovací statistiku poměrem věrohodnosti U_{LR} .



	test.statistika	W	kritický obor	p -hodnota
Waldův přístup	1.104799	$(-\infty, -1.959964) \cup (1.959964; \infty)$	(0.1868617, 0.4605561)	0.2692467
Věrohodnostní přístup	1.241757	$\langle 3.841459; \infty$	(0.1880626, 0.4590998)	0.2651328

Příklad 15. Rozdělení testovacích statistik F , U_W , U_S a U_{LR} jednovýběrového testu o rozptylu σ^2
Pomocí simulační studie ověřte, že

- statistika $F = \frac{nS_n^2}{\sigma_0^2} \sim \chi_n^2$
- statistika $U_w = \frac{n}{2} \left(\frac{n}{F_{obs}} - 1 \right)^2 \sim \chi^2(1)$
- statistika $U_S = \frac{n}{2} \left(\frac{F_{obs}}{n} - 1 \right)^2 \sim \chi^2(1)$
- statistika $U_{LR} = F_{obs} - n \left(1 + \ln \left(\frac{F_{obs}}{n} \right) \right) \sim \chi^2(1)$
- Vygenerujte $M = 1000$ pseudonáhodných výběrů o rozsahu $n = 5$. Pro každý náhodný výběr vypočítejte hodnoty realizací testovacích statistik F , U_W , U_S a U_{LR} . Vytvořte histogramy těchto testovacích statistik a superponujte je křivkami příslušného rozdělení.
- Vytvořte animaci, pomocí které bude zřejmé, jak se s rostoucím n rozdělení testovacích statistik F , U_W , U_S a U_{LR} asymptoticky blíží k příslušnému rozdělení. Animaci spravte pro měnící se $n \in \{3, 4, 5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 60, 70, 80, 90, 100, 200, 300, 400, 500, 600, 700, 800, 900, 1000\}$

Příklad 16. Pokračování příkladu 15

- Vygenerujte $M = 1000$ pseudonáhodných výběrů o rozsahu $n = 5$. Pro každý náhodný výběr stanovte hodnoty realizací testovacích statistik F , U_W , U_S a U_{LR} . Pomocí funkce `density()` vypočítejte jádrové odhady rozdělení testovacích statistik U_W , U_S a U_{LR} . Tyto jádrové odhady zobrazte do jednoho grafu a barevně je odlište. Do grafu dokreslete křivku hustoty χ^2 rozdělení o jednom stupni volnosti a vertikální referenční čaru v hodnotě 0.
- Vytvořte animaci, pomocí které bude zřejmé, jak se s rostoucím n rozdělení testovacích statistik U_W , U_S a U_{LR} asymptoticky blíží k $\chi^2(1)$ rozdělení. Animaci spravte pro měnící se $n \in \{3, 4, 5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 60, 70, 80, 90, 100, 200, 300, 400, 500, 600, 700, 800, 900, 1000\}$