

**Příklad 2.4. Rozdělení výběrového rozptylu a výběrové směrodatné odchylky**

Na základ simulacní studie ověrte, že pokud náhodná veličina  $X \sim N(\mu, \sigma^2)$ , potom pro výběrový rozptyl  $S_n^2$  a výběrovou směrodatnou odchylku  $S_n$  platí

- (a)  $S_n^2 \sim \Gamma\left(\frac{n}{2}, \frac{2\sigma^2}{n}\right)$  exaktně;
- (b)  $S_n^2 \sim N(\sigma^2, \frac{2\sigma^4}{n})$  asymptoticky;
- (c)  $S_n \sim \Gamma_G\left(\sqrt{\frac{2\sigma^2}{n}}, 2, \frac{n}{2}\right)$  exaktně;
- (d)  $S_n \sim N(\sigma, \frac{\sigma^2}{2n})$  asymptoticky.

Vygenerujte  $M = 1000$  náhodných výběrů z normálního rozdělení  $N(\mu, \sigma^2)$  o rozsahu  $n$ , kde  $\mu = 0$  a  $\sigma^2 = 4$ . Pro každý náhodný výběr vypočítejte výběrový rozptyl  $S_{n_i}^2$ ,  $i = 1, \dots, M$ . Rozptyly vykreslete pomocí histogramu a superponujte je křivkami hustoty exaktního i asymptotického rozdělení statistiky  $S_n^2$ . Dále pro každý náhodný výběr vypočítejte výběrovou směrodatnou odchylku  $S_{n_i}$ ,  $i = 1, \dots, M$ . Odchylky zaneste vykreslete do histogramu a superponujte je křivkami hustoty asymptotického a exaktního rozdělení statistiky  $S_n$ . Vytvořte animaci zobrazující konvergenci asymptotického rozdělení obou statistik k exaktnímu rozdělení při zvětšujícím se rozsahu náhodných výběrů  $n$ . Hodnoty rozsahu  $n$  volte 5, 10, 50, 100, 500, 1000.

Obrázek 4: Exaktní a asymptotické rozdělení (a) výběrového rozptylu  $S_n^2$ ; (b) výběrové směrodatné odchylky  $S_n$

**Teorie k příkladu 2.5**


- **nominální pravděpodobnost pokrytí** (spolehlivost) ... teoretická pravděpodobnost pokrytí (spolehlivost)  $1 - \alpha$  (jaká by teoreticky měla být)
- **aktuální pravděpodobnost pokrytí** (spolehlivost) ... skutečná pravděpodobnost pokrytí (spolehlivost)  $1 - \hat{\alpha}$  (jaká ve skutečnosti je)
- *Příklad:* Předokládáme, že nominální spolehlivost námi zvoleného intervalu spolehlivosti (IS) (např. o  $\mu$  když  $\sigma^2$  známe) je  $1 - \alpha = 0.95$ . Naměříme (nagenerujeme) data, a na základě nich vypočítáme aktuální spolehlivost  $1 - \hat{\alpha}$ . Pokud dodržíme předpoklady (naměřená (nagenerovaná) data budou pocházet z normálního rozdělení, všechny se stejným rozptylem  $\sigma^2$ ), bude aktuální spolehlivost  $1 - \hat{\alpha} \doteq 0.95$ . Nicméně, pokud předpoklady (ať už vědomě či nevědomě) porušíme, může se aktuální spolehlivost  $1 - \hat{\alpha}$  od nominální spolehlivosti  $1 - \alpha$  výrazně lišit.

**Příklad 2.5. Nezávislost  $\mu$  a  $\sigma^2$ ; pravděpodobnost pokrytí**

Nechť  $X \sim N(\mu, \sigma^2)$ , kde  $\mu = 150$  a  $\sigma^2 = 10^2$ . Pomocí simulační studie ověrte nezávislost výběrového průměru  $\bar{X}$  a výběrové směrodatné odchylky  $S = S_{n-1}$ .

Nakreslete rozptylový graf  $(\bar{x}_m, s_m)$ ,  $m = 1, 2, \dots, M$ , kde  $M = 2000$ . Barvu bodů zvolte šedou. Vypočítejte hodnotu Pearsonova korelačního koeficientu  $r_{\bar{X}, S}$ . Červenou barvou dále vyznačte v grafu takové body  $(\bar{x}_m, s_m)$ , pro které platí  $\mu \in IS_m = (dh_m; hh_m) = \left( \bar{x}_m - t_{n-1}(1 - \alpha/2) \frac{s}{\sqrt{n}}; \bar{x}_m - t_{n-1}(\alpha/2) \frac{s}{\sqrt{n}} \right)$ . Navíc vykreslete hranice definované body  $(\bar{x}_m, s_m)$ , jež splňují vztah  $dh_m = hh_m = \mu$ . Vypočítejte pravděpodobnost pokrytí 95 % DIS pro  $\mu$  jako podíl  $\frac{\sum_m I(\mu \in IS_m)}{M}$ . Zvolte (a)  $n = 5$ , (b)  $n = 50$  a (c)  $n = 100$ .

Simulaci proveděte také za předpokladu, že data pochází ze smíšeného rozdělení  $X \sim [pN(\mu, \sigma^2) + (1-p)N(\mu, \sigma_2^2)]$ , kde  $p = 0.9$ ,  $\mu = 150$ ,  $\sigma^2 = 10^2$  a  $\sigma_2^2 = 20^2$ .



Obrázek 5: Nezávislost výběrového průměru  $\bar{X}$  a výběrové směrodatné odchylky  $S_{n-1}$

### Teorie k příkladu 2.6


- **konzervativní IS** ... interval spolehlivosti, jehož aktuální (skutečná) pravděpodobnost pokrytí  $1 - \hat{\alpha}$  je větší než nominální pravděpodobnost pokrytí  $1 - \alpha$ , se nazývá *konzervativní IS* (IS obsahuje  $\theta$  s větší pravděpodobností, než bychom předpokládali).
- **liberální IS** ... interval spolehlivosti, jehož aktuální (skutečná) pravděpodobnost pokrytí  $1 - \hat{\alpha}$  je menší než nominální pravděpodobnost pokrytí  $1 - \alpha$ , se nazývá *liberální IS* (IS obsahuje  $\theta$  s menší pravděpodobností, než bychom předpokládali).

#### Příklad 2.6. Odhad koeficientu spolehlivosti $1 - \alpha$ Waldova empirického DIS pro parametr $\mu$ normálního rozdělení při známém rozptylu $\sigma^2$

Nechť  $X \sim N(5, 15)$ . Pomocí simulační studie ( $M = 100$ ) stanovte Monte Carlo (MC) odhad koeficientu spolehlivosti (pravděpodobnosti pokrytí) 95 % Waldova exaktního empirického DIS pro parametr  $\mu$  normálního rozdělení při známém rozptylu  $\sigma^2$ .


Vygenerujte  $M = 100$  náhodných výběrů z normálního rozdělení  $N(5, 10)$  a na základě každého náhodného výběru vypočítejte 95 % DIS pro parametr  $\mu$ . Všechny DIS vykreslete do jednoho grafu jako svislé šedé úsečky. Červenou barvou dále vyznačte v grafu ty DIS, které nepokrývají střední hodnotu  $\mu = 5$  a černou barvou vyznačte horizontální referenční čáru v bodě  $\mu$ . Dále vypočítejte aktuální pravděpodobnost pokrytí 95 % DIS pro  $\mu$  jako podíl  $\frac{\sum_m I(\mu \in IS_m)}{M}$  a porovnejte ji s nominální pravděpodobností pokrytí  $1 - \alpha$ . Rozsah náhodných výběrů volte (a)  $n = 50$ ; (b)  $n = 1000$ .

Simulaci proveďte také za předpokladu, že data pochází ze smíšeného rozdělení  $X \sim pN(5, 15) + (1 - p)N(5, 15^2)$ , kde  $p = 0.9$ , resp. ze smíšeného rozdělení  $X \sim pN(5, 15) + (1 - p)N(3, 15)$ , kde  $p = 0.9$ .




Obrázek 6: Pravděpodobnost pokrytí 95 % Waldových exaktních empirických DIS pro parametr  $\mu$  normálního rozdělení při známém rozptylu  $\sigma^2$

Zopakujeme-li několikrát simulační studii, vidíme, že pochází-li náhodné výběry z normálního rozdělení, pohybuje se aktuální pravděpodobnost pokrytí okolo nominální pravděpodobnosti pokrytí  $1 - \alpha$ . V případě, že náhodné výběry pochází ze směsi dvou normálních rozdělení, které se liší pouze v rozptylech, dochází s rostoucím rozdílem mezi oběma rozptyly k postupnému snížování aktuální pravděpodobnosti pokrytí, a tedy ke zvýšení aktuální hladiny významnosti. Aby se však tento trend projevil, museli bychom hodnotu rozptylu  $\sigma_2^2$  poznaménit opravdu výrazně (viz např.  $\sigma_1^2 = 15$  vs  $\sigma_2^2 = 15^2$ ). Podobná situace nastává v případě, že náhodné výběry pochází ze směsi dvou normálních rozdělení, které se liší střední hodnotou. Zde dochází k postupnému snížování aktuální pravděpodobnosti pokrytí, a tedy ke zvyšování aktuální hladiny významnosti s rostoucím rozsahem náhodných výběrů  $n$ .



Obrázek 7: Pravděpodobnost pokrytí 95 % Waldových exaktních empirických DIS pro parametr  $\mu$  normálního rozdělení při známém rozptylu  $\sigma^2$  za předpokladu, že náhodný výběr pochází ze smíšeného rozdělení  $pN(5, 15) + (1-p)N(5, 15^2)$ ,  $p = 0.9$



Obrázek 8: Pravděpodobnost pokrytí 95 % Waldových exaktních empirických DIS pro parametr  $\mu$  normálního rozdělení při známém rozptylu  $\sigma^2$  za předpokladu, že náhodný výběr pochází ze smíšeného rozdělení  $pN(5, 15) + (1-p)N(3, 15)$ ,  $p = 0.9$

Tabulka 1: Pravděpodobnost pokrytí 95 % Waldových empirických DIS pro parametr  $\mu$  normálního rozdělení při neznámém rozptylu  $\sigma^2$

	$1 - \alpha$	$1 - \hat{\alpha}$	$dh_{\alpha}$	$hh_{\alpha}$
normální r.: $n = 50$	0.9500	0.9900	0.9705	1.0095
normální r.: $n = 1000$	0.9500	0.9300	0.8800	0.9800
smíšené r. s rozdílnými $\sigma_1^2$ a $\sigma_2^2$ : $n = 50$	0.9500	0.7800	0.6988	0.8612
smíšené r. s rozdílnými $\sigma_1^2$ a $\sigma_2^2$ : $n = 1000$	0.9500	0.7600	0.6763	0.8437
smíšené r. s rozdílnými $\mu_1$ a $\mu_2$ : $n = 50$	0.9500	0.9300	0.8800	0.9800
smíšené r. s rozdílnými $\mu_1$ a $\mu_2$ : $n = 1000$	0.9500	0.7100	0.6211	0.7989