

1 R-Sweave

2 Kvantily a bodové odhadы parametrů

- Příklad 2.1 ... $x > \log(1 + x) > \frac{x}{1+x}$
- Příklad 2.2 ... Pro $n \rightarrow \infty$ konverguje Studentovo rozdělení o n stupních volnosti ke standardizovanému normálnímu rozdělení (uspokojivá shoda nastává cca pro $n \geq 50$)
- Příklad 2.3 ... Uvedené rovnosti platí, tj. $\chi_1^2(1 - \alpha) = u_{1-\alpha/2}^2$; $F_{1,n-1}(1 - \alpha) = t_{n-1}^2(1 - \alpha/2)$; $\chi_n^2(1 - \alpha) = \Gamma_{\frac{n}{2},2}(1 - \alpha)$, a to pro libovolné n i α
- Příklad 2.4 ... $S_n^2 \sim \Gamma(\frac{n}{2}, \frac{2\sigma^2}{n})$ exaktně; $S_n^2 \sim N(\sigma^2, \frac{2\sigma^4}{n})$ asymptoticky (uspokojivá shoda nastává při zadaných parametrech cca pro $n \geq 500$); $S_n \sim \Gamma_G(\sqrt{\frac{2\sigma^2}{n}}, 2, \frac{n}{2})$ exaktně; $S_n \sim N(\sigma, \frac{\sigma^2}{2n})$ asymptoticky (uspokojivá shoda nastává při zadaných parametrech cca pro $n \geq 100$).
- Příklad 2.5
 - (a) Pro $X \sim N(\mu, \sigma^2)$, $\mu = 150$, $\sigma = 10^2$, pro $n = 5$, $n = 50$ i $n = 100$ je aktuální spolehlivost (pst pokrytí) $1 - \hat{\alpha}$ blízká nominální spolehlivosti $1 - \alpha$;
 - (b) Pro $X \sim [pN(\mu, \sigma^2) + (1 - p)N(\mu, \sigma_2^2)]$, $p = 0.9$, $\sigma_2^2 = 20^2$, pro $n = 5$, $n = 50$ i $n = 100$ je aktuální spolehlivost (pst pokrytí) $1 - \hat{\alpha}$ blízká nominální spolehlivosti $1 - \alpha$; tj. 10% příměs lišící se pouze v rozptylu aktuální spolehlivost $1 - \hat{\alpha}$ 95% DIS pro μ , když σ^2 neznáme, nijak závažným způsobem neovlivňuje.
- Příklad 2.6
 - (a) $X \sim N(5, 15)$, $n = 50$, ... Po opakováném spuštění MC studie vidíme, že aktuální pravděpodobnost pokrytí $1 - \hat{\alpha}$ nabývá rovnoměrně častokrát vyšší i nižší hodnoty než je nominální pravděpodobnost pokrytí $1 - \alpha = 0.95$. 95% DIS pro μ , když σ^2 známe, není v tomto případě konzervativní ani liberální. Aktuální spolehlivost je celkem výrazně vyšší / nižší než 0.95, což je způsobeno nízkým rozsahem náhodných výběrů.
 - (b) $X \sim N(5, 15)$, $n = 1000$... Po opakováném spuštění MC studie vidíme, že aktuální pravděpodobnost pokrytí $1 - \hat{\alpha}$ nabývá rovnoměrně častokrát vyšší i nižší hodnoty než je nominální pravděpodobnost pokrytí $1 - \alpha = 0.95$. DIS není ani konzervativní ani liberální.
 - (c) smíšené rozdělení s rozdílnými rozptyly, $n = 50$; $n = 1000$... Aktuální pravděpodobnost pokrytí DIS je systematicky podhodnocována (systematicky je aktuální pst pokrytí menší než nominální pst pokrytí), tj. v tomto případě je DIS liberální.
 - (d) smíšené rozdělení s rozdílnými středními hodnotami, $n = 50$... Aktuální pravděpodobnost pokrytí 95% DIS je systematicky podhodnocována (systematicky je aktuální pst pokrytí menší než nominální pst pokrytí), tj. v tomto případě je DIS liberální. Efekt liberálnosti zde není tak zřejmý jako v situaci (e), díky nižšímu rozsahu náhodných výběrů.
 - (e) smíšené rozdělení s rozdílnými středními hodnotami, $n = 1000$... Aktuální pravděpodobnost pokrytí 95% DIS je systematicky podhodnocována, tj. v tomto případě je DIS liberální. Efekt liberálnosti je velmi výrazný kvůli vysokým rozsahům náhodných výběrů.

3 Postačující statistika, monotónní poměr věrohodnosti a rovnoměrně nejsilnější test

- Příklad 3.3 ... Z animace vidíme, že poměr věrohodnosti pro parametr p je skutečně monotónní funkcí statistiky $X = \sum_{i=1}^N X_i$.
- Příklad 3.4 ...
 - Pro H_{02} rovnoměrně nejsilnější test existuje. Je jím například Waldův, či skóre test o pravděpodobnosti, neboť testovací statistika obou testů je založena na postačující statistice $X = \sum_{i=1}^N X_i$, která je pouze přičítána/odečítána/násobena/dělena konstantami p_0 a N .
 - Pro H_{03} rovnoměrně nejsilnější test existuje. Je jím například Waldův, či skóre test o pravděpodobnosti, neboť testovací statistika obou testů je založena na postačující statistice $X = \sum_{i=1}^N X_i$, která je pouze přičítána/odečítána/násobena/dělena konstantami p_0 a N .
 - Pro H_{01} rovnoměrně nejsilnější test neexistuje. Z přednášky z SI II víme, že rovnoměrně nejsilnější test neexistuje pro oboustrannou alternativu.
- Z animace vidíme, že poměr věrohodnosti pro parametr μ normálního rozdělení je skutečně monotónní funkci statistiky $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$.
 - Pro H_{02} rovnoměrně nejsilnější test existuje. Je jím například Waldův test o parametru μ při známém rozptylu σ^2 , neboť testovací statistika tohoto testu Z_W je založena na postačující statistice \bar{X} , která je pouze přičítána/odečítána/násobena/dělena konstantami μ_0 , \sqrt{n} a σ .
 - Pro H_{03} rovnoměrně nejsilnější test existuje. Je jím například Waldův test o parametru μ při známém rozptylu σ^2 , neboť testovací statistika tohoto testu Z_W je založena na postačující statistice \bar{X} , která je pouze přičítána/odečítána/násobena/dělena konstantami μ_0 , \sqrt{n} a σ .
 - Pro H_{01} rovnoměrně nejsilnější test neexistuje. Z přednášky z SI II víme, že rovnoměrně nejsilnější test neexistuje pro oboustrannou alternativu.

4 Test o střední hodnotě při známém rozptylu

- Příklad 4.1

- (a) $X \sim N(20, 100)$, $n = 5$, či $n = 100$... Po opakovaném spuštění MC studie vidíme, že aktuální pravděpodobnost pokrytí $1 - \hat{\alpha}$ nabývá rovnoměrně častokrát vyšší i nižší hodnoty než je nominální pravděpodobnost pokrytí $1 - \alpha$. DIS pro μ , když σ^2 známe, není v tomto případě konzervativní ani liberální, stejně jako test založený na testovací statistice Z_W .
- (b) $X \sim pN(20, 100) + (1-p)N(28, 100)$, $n = 5$, či $n = 100$... Po opakovaném spuštění MC studie vidíme, že aktuální pravděpodobnost pokrytí $1 - \hat{\alpha}$ je soustavně nižší než nominální pravděpodobnost pokrytí $1 - \alpha$. DIS pro μ , když σ^2 známe, je v tomto případě liberální, stejně jako test založený na testovací statistice Z_W . Pro $n = 5$ není efekt liberálnosti tak zřejmý jako při $n = 100$, díky nižšímu rozsahu náhodných výběrů.

- Příklad 4.2

- (a) $\mu = 146$... Centrální rozdělení přísluší parametru $\mu_0 = 150$, proto se červená křivka centrálního rozdělení realizuje okolo hodnoty 0. Naproti tomu rozdělení testovací statistiky Z_W přísluší hodnotě $\mu = 146$ (modrý histogram superponovaný modrou křivkou). Hodnota $\mu = 146 < \mu_0 = 150$, proto parametr necentrality λ nabývá záporné hodnoty a histogram i s modrou křivkou necentrálního rozdělení se realizuje nad zápornou hodnotou (cca okolo hodnoty -3) nalevo od červené křivky centrálního rozdělení. Modrá křivka superponuje histogram přesně, protože náhodný výběr pochází z předpokládaného rozdělení $N(146, 10^2)$.
- (b) $\mu = 155$... Centrální rozdělení přísluší parametru $\mu_0 = 150$, proto se červená křivka centrálního rozdělení realizuje okolo hodnoty 0. Naproti tomu rozdělení testovací statistiky Z_W přísluší hodnotě $\mu = 155$ (modrý histogram superponovaný modrou křivkou). Hodnota $\mu = 155 > \mu_0 = 150$, proto parametr necentrality λ nabývá kladné hodnoty a histogram i s modrou křivkou necentrálního rozdělení se realizuje nad kladnou hodnotou (cca okolo hodnoty 3) napravo od červené křivky centrálního rozdělení. Modrá křivka superponuje histogram přesně, protože náhodný výběr pochází z předpokládaného rozdělení $N(155, 10^2)$.
- (c) směs, $\mu = 146$... Analogicky jako (a). Modrá křivka nesuperponuje histogram přesně, protože náhodný výběr, na jehož základě byly vypočítány testovací statistiky Z_W reprezentované histogramem, pochází ze směsi, zatímco my předpokládáme, že pochází z "nekontaminovaného" rozdělení $N(146, 10^2)$, kterému přísluší rozdělení testovací statistiky Z_W reprezentované modrou křivkou.
- (d) směs, $\mu = 155$... Analogicky jako (b). Modrá křivka nesuperponuje histogram přesně, protože náhodný výběr, na jehož základě byly vypočítány testovací statistiky Z_W reprezentované histogramem, pochází ze směsi, zatímco my předpokládáme, že pochází z "nekontaminovaného" rozdělení $N(155, 10^2)$, kterému přísluší rozdělení testovací statistiky Z_W reprezentované modrou křivkou.

- Příklad 4.3

- (a) oboustranná alternativa: síla testu klesá s hodnotou $\mu \rightarrow \mu_0 = 150$ z obou stran. V hodnotě μ_0 je síla rovná hladině významnosti, tj. $1 - \beta = \alpha = 0.05$. Pro $n \rightarrow 0$ je pokles síly pozvolnější.
- (b) pravostranná alternativa: síla testu klesá s $\mu \rightarrow \mu_0 = 150$ zprava. V hodnotě μ_0 je síla rovná hladině významnosti, tj. $1 - \beta = \alpha = 0.05$. Pro $n \rightarrow 0$ je pokles síly pozvolnější.
- (c) levostranná alternativa: síla testu klesá s hodnotou $\mu \rightarrow \mu_0 = 150$ zleva. V hodnotě μ_0 je síla rovná hladině významnosti, tj. $1 - \beta = \alpha = 0.05$. Pro $n \rightarrow 0$ je pokles síly pozvolnější.

- Příklad 4.4 ... Exaktní a empirická silufunkce jsou si tvarově velmi blízké všude s výjimkou intervalu cca (149.2; 150.8). Exaktní sílu tedy můžeme approximovat v případě, že μ je dostatečně vzdálená od μ_0 , tj. cca pro $\mu \in (-\infty; 149.2) \cup (150.8; \infty)$.

- Příklad 4.5

- (a) $X \sim N(\mu, 10^2)$... V tomto případě je empirická silufunkce velmi blízká exaktní silufunkci, protože náhodný výběr pochází z předpokládaného rozdělení $N(\mu, \sigma^2)$.

- (b) $X \sim [pN(\mu, 10^2) + (1-p)N(\mu, 30^2)]$, kde $p = 0.9 \dots$ V tomto případě má empirická silofunkce mnohem pozvolnější pokles než silofunkce exaktní. Lokální minimum empirické silofunkce je větší než lokální minimum exaktní silofunkce a neodpovídá hodnotě α . Ze studie je tedy krásně patrné, jak moc může náhodný výběr pocházející ze směsi silofunkci poškodit.
- Příklad 4.6 ... Z uvedené animace krásně vidíme propojení polohy necentrálního rozdělení a hodnoty silofunkce. Pokud se s hodnotou μ blížíme k hodnotě μ_0 zleva, vidíme, že necentrální rozdělení se čím dál blíže posouvá k centrálnímu rozdělení a hodnota silofunkce klesá. V hodnotě $\mu = \mu_0 = 150$ centrální a necentrální rozdělení splývají a silofunkce dosahuje svého minima, které je rovné hladině významnosti $\alpha = 0.05$. Následně se s hodnotou μ vzdalujeme od hodnoty μ_0 směrem doprava, a vidíme, že necentrální rozdělení se čím dál více vzdaluje od centrálního rozdělení, zatímco hodnota silofunkce začíná růst k jedné.
- Příklad 4.7 ... Z grafů a souhrnné tabulky vidíme, že pro oboustrannou alternativu jsou rozsahy náhodných výběrů (pro pevně zvolené μ_0 a μ) vyšší než pro jednostranné alternativy. Pro pravostrannou alternativu ($H_{12}: \mu > \mu_0$) nemá smysl počítat rozsahy náhodných výběrů za předpokladu, že $\mu \leq \mu_0$. Pro levostrannou alternativu ($H_{13}: \mu < \mu_0$) nemá naopak smysl počítat rozsahy náhodných výběrů za předpokladu, že $\mu \geq \mu_0$. Dále, v případě, že by $\mu = \mu_0$, by minimální rozsah náhodného výběru musel být nekonečně velký (uvažujeme pouze teoreticky), a to pro všechny tři typy alternativní hypotézy.

5 Test o střední hodnotě při neznámém rozptylu

- Příklad 5.1

- * (a) $X \sim N(20, 100)$, $n = 5$ i $n = 100$... Po opakovaném spuštění MC studie vidíme, že aktuální pravděpodobnost pokrytí $1 - \hat{\alpha}$ nabývá rovnoměrně častokrát vyšší i nižší hodnoty než je nominální pravděpodobnost pokrytí $1 - \alpha$. DIS pro μ , když σ^2 neznáme, není v tomto případě konzervativní ani liberální, stejně jako test založený na testovací statistice T_W .
- * (b) $X \sim pN(20, 100) + (1-p)N(28, 100)$, kde $p = 0.9$, $n = 5$... Jelikož v tomto případě je náhodný výběr tvořen směsí dvou rozdělení s různými středními hodnotami, měli bychom být na pozoru. Po opakovaném spuštění MC studie vidíme, že aktuální pravděpodobnost pokrytí $1 - \hat{\alpha}$ bývá spíše nižší než nominální pravděpodobnost pokrytí $1 - \alpha$, není to však pravidlem (bývá i vyšší). DIS pro μ , když σ^2 neznáme, je liberální, stejně jako test založený na testovací statistice T_W , nicméně díky nízkému rozsahu náhodného výběru ($n = 5$) není efekt liberálnosti ze simulace příliš zřejmý, DIS se chová, jako by nebyl ani konzervativní, ani liberální, a v praxi by efekt liberálnosti neměl příliš výrazný vliv. Z grafu však vidíme, že křivka Studentova rozdělení je oproti histogramu posunutá mírně doleva.
- * (c) $X \sim pN(20, 100) + (1-p)N(28, 100)$, kde $p = 0.9$, $n = 100$... Po opakovaném spuštění MC studie vidíme, že aktuální pravděpodobnost pokrytí $1 - \hat{\alpha}$ je soustavně nižší než nominální pravděpodobnost pokrytí $1 - \alpha$. DIS pro μ , když σ^2 neznáme, je v tomto případě liberální, stejně jako test založený na testovací statistice T_W . Z grafu je zřejmé výrazné posunutí křivky Studentova rozdělení oproti histogramu směrem doleva.

- Příklad 5.2 ... Z animací vidíme, že oba vztahy platí, tj. $T_W \sim t_{n-1}$ a $T_W^2 \sim F_{1,n-1}$, a to asymptoticky. Příklad má spojitost s příkladem 2.3 a v něm uvedeným vztahem $F_{1,n-1}(1 - \alpha) = t_{n-1}^2(1 - \alpha/2)$. Z tohoto vztahu totiž vyplývá, že $t_{n-1}^2 = F_{1,n-1}$ a proto pokud $T_W \sim t_{n-1}$, potom $T_W^2 \sim t_{n-1}^2 = F_{1,n-1}$.
- Příklad 5.3 ... Z animací vidíme, že všechny tři uvedené vztahy platí, tj. $U_W \sim \chi_1^2$, $U_S \sim \chi_1^2$, $U_{LR} \sim \chi_1^2$ asymptoticky.
- Příklad 5.4 ... Z uvedené animace je zřejmé, že pro $n \rightarrow \infty$ se testovací statistiky U_W , U_S a U_{LR} vzájemně čím dál více blíží (uspokojivá shoda nastává cca od $n = 50$). Dále vidíme, že pro velmi nízké rozsahy náhodného výběru (cca $n \leq 8$) testovací statistika U_W selhává, a tedy není na testování H_0 o μ , když σ^2 neznáme, vůbec vhodná. Z obrázku 5 je potom patrné, že platí nerovnost $U_W > U_{LR} > U_S$. Tato nerovnost vyplývá z nerovnosti $x > \log(1 + x) > \frac{x}{1+x}$, kterou jsme si ověřili v příkladu 2.1.
- Příklad 5.5 ... V tomto příkladě si vzájemně porovnáváme tvar centrálního Studentova rozdělení s tvarem necentrálních rozdělení s parametrem necentrality λ . Z grafů zobrazujících tvary hustot i distribučních funkcí je patrné, že s měnící se hodnotou parametru necentrality λ se mění nejen střední hodnota, ale i rozptyl Studentova necentrálního rozdělení. Čím je parametr necentrality λ (v absolutní hodnotě) větší, tím více se necentrální a centrální rozložení liší v (a) poloze; (b) v rozptylu, a to ve smyslu: čím vyšší λ , tím vyšší rozptyl.
- Příklad 5.6 ... Příklad je analogický příkladu 4.2.
 - * (a) $\mu = 130$... Centrální rozdělení přísluší parametru $\mu_0 = 150$, proto se modrá křivka centrálního rozdělení realizuje okolo hodnoty 0. Naproti tomu rozdělení testovací statistiky T_W přísluší hodnotě $\mu = 130$ (červený histogram superponovaný červenou křivkou). Hodnota $\mu = 130 < \mu_0 = 150$, proto parametr necentrality λ nabývá záporné hodnoty a histogram i s červenou křivkou necentrálního rozdělení se realizuje nad zápornou hodnotou (cca okolo hodnoty -5) nalevo od modré křivky centrálního rozdělení. Červená křivka superponuje histogram přesně, protože náhodný výběr pochází z předpokládaného rozdělení $N(130, 30^2)$.
 - * (b) $\mu = 170$... Centrální rozdělení přísluší parametru $\mu_0 = 150$, proto se modrá křivka centrálního rozdělení realizuje okolo hodnoty 0. Naproti tomu rozdělení testovací statistiky T_W přísluší hodnotě $\mu = 170$ (červený histogram superponovaný červenou křivkou). Hodnota $\mu = 170 > \mu_0 = 150$, proto parametr necentrality λ nabývá kladné hodnoty a histogram i s červenou křivkou necentrálního rozdělení se realizuje nad kladnou hodnotou (cca okolo hodnoty 5) napravo od modré křivky centrálního rozdělení. Červená křivka superponuje histogram přesně, protože náhodný výběr pochází z předpokládaného rozdělení $N(170, 30^2)$.

- * (c) směs, $\mu = 130 \dots$ Analogicky jako (a). Červená křivka nesuperponuje histogram přesně, protože náhodný výběr, na jehož základě byly vypočítány testovací statistiky Z_W reprezentované histogramem, pochází ze směsi, zatímco my předpokládáme, že pochází z "nekontaminovaného" rozdělení $N(130, 30^2)$, kterému přísluší rozdělení testovací statistiky Z_W reprezentované červenou křivkou.
- * (d) směs, $\mu = 170 \dots$ Analogicky jako (b). Červená křivka nesuperponuje histogram přesně, protože náhodný výběr, na jehož základě byly vypočítány testovací statistiky Z_W reprezentované histogramem, pochází ze směsi, zatímco my předpokládáme, že pochází z "nekontaminovaného" rozdělení $N(170, 30^2)$, kterému přísluší rozdělení testovací statistiky Z_W reprezentované červenou křivkou.
- Příklad 5.7 ... Příklad je analogický příkladu 4.6
 - * Z uvedené animace krásně vidíme propojení polohy necentrálního rozdělení a hodnoty silofunkce. Pokud se s hodnotou μ blížíme k hodnotě μ_0 zleva, vidíme, že necentrální rozdělení se čím dál blíže posouvá k centrálnímu rozdělení a hodnota silofunkce klesá. V hodnotě $\mu = \mu_0 = 150$ centrální a necentrální rozdělení splývají a silofunkce dosahuje svého minima, které je rovné hladině významnosti $\alpha = 0.05$. Následně se s hodnotou μ vzdalujeme od hodnoty μ_0 směrem doprava, a vidíme, že necentrální rozdělení se čím dál více vzdaluje od centrálního rozdělení, zatímco hodnota silofunkce začíná růst k jedné.
- Příklad 5.8
 - * Test normality: $n = 107 > 100 \rightarrow$ Lillieforsův test; p -hodnota $= 0.0989 > \alpha = 0.05 \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$. Naměřené hodnoty basion-bregmatické výšky lebky žen starověké egyptské populace pochází z normálního rozdělení.
 - * Test o μ , když σ^2 neznáme:
 - Pomocí testovací statistiky T_W : $t_W = -2.8004$, $W = (-\infty; -1.9826) \cup (1.9826; \infty)$, $t_W \in W \rightarrow H_0$ zamítáme; $\mu_0 = 126.942$, $IS = (124.7904; 126.5741)$, $\mu_0 \notin IS \rightarrow H_0$ zamítáme; p -hodnota $= 0.0061$, $\alpha = 0.05$, p -hodnota $< \alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
 - Pomocí testovací statistiky U_W : $u_W = 7.9163$, $W = (3.8415; \infty)$, $u_W \in W \rightarrow H_0$ zamítáme; $\mu_0 = 126.942$, $IS = (124.8078; 126.5596)$, $\mu_0 \notin IS \rightarrow H_0$ zamítáme; p -hodnota $= 0.0049$, $\alpha = 0.05$, p -hodnota $< \alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
 - Pomocí testovací statistiky U_S : $u_S = 7.3710$, $W = (3.8415; \infty)$, $u_S \in W \rightarrow H_0$ zamítáme; $\mu_0 = 126.942$, $IS = (124.7932; 126.5742)$, $\mu_0 \notin IS \rightarrow H_0$ zamítáme; p -hodnota $= 0.0066$, $\alpha = 0.05$, p -hodnota $< \alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
 - Pomocí testovací statistiky U_{LR} : $u_{LR} = 7.6371$, $W = (3.8415; \infty)$, $u_{LR} \in W \rightarrow H_0$ zamítáme; $\mu_0 = 126.942$, $IS = (124.7981; 126.5645)$, $\mu_0 \notin IS \rightarrow H_0$ zamítáme; p -hodnota $= 0.0057$, $\alpha = 0.05$, p -hodnota $< \alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
 - Interpretace: Mezi basion–bregmatickou výškou lebky žen starověké a novověké egyptské populace existuje statisticky významný rozdíl ($|\mu - \mu_0| = 1.2598$ mm).

6 Test o rozptylu

- Příklad 6.1
 - * (a) $X \sim N(0, 1)$... předpoklad asymptotického χ^2_{n-1} rozdělení testovací statistiky F_W v tomto případě platí.
 - * (b) $X \sim pN(0, 1) + (1-p)N(0, 4)$, $p = 0.9$... předpoklad asymptotického χ^2_{n-1} rozdělení testovací statistiky F_W v tomto případě neplatí.
 - * (c) $X \sim \text{Exp}(1)$, ... předpoklad asymptotického χ^2_{n-1} rozdělení testovací statistiky F_W v tomto případě neplatí.
- Příklad 6.2 ... Vztah $F_{W,n-1} \sim \chi^2_{n-1}$ platí exaktně, vztah $F_{W,n} \sim \chi^2_n$ platí pouze asymptoticky (pro $n \rightarrow \infty$). Je to jednak proto, že $F_{W,n-1} = F_{W,n}$, a jednak proto, že pro $n \rightarrow \infty$ se rozdělení χ^2_{n-1} a χ^2_n k sobě vzájemně blíží (viz následující příklad 6.3). Z rovnosti $F_{W,n-1} = F_{W,n}$ potom dále vyplývá, že $F_{W,n-1} \sim \chi^2_n$ asymptoticky a $F_{W,n} \sim \chi^2_{n-1}$ exaktně.
- Příklad 6.3 ... Z animace je zřejmé, že skutečně pro $n \rightarrow \infty$ se rozdělení χ^2_{n-1} a χ^2_n k sobě vzájemně blíží (uspokojivá shoda nastává cca pro $n \geq 100$).
- Příklad 6.4
 - * $T_W \dots T_W \sim N(0, 1)$ asymptoticky (uspokojivá shoda nastává pro cca $n \geq 25$)
 - * $U_W \dots U_W \sim \chi^2_1$ asymptoticky (uspokojivá shoda nastává pro cca $n \geq 20$)
 - * $U_S \dots U_S \sim \chi^2_1$ asymptoticky (uspokojivá shoda nastává pro cca $n \geq 10$)
 - * $U_{LR} \dots U_{LR} \sim \chi^2_1$ asymptoticky (uspokojivá shoda nastává pro cca $n \geq 5$)
- Příklad 6.5 ... Z animace je zřejmé, že testovací statistiky U_W , U_S i U_{LR} konvergují pro $n \rightarrow \infty$ k χ^2_1 rozdělení. Nejrychleji konverguje testovací statistika U_{LR} (dobré výsledky již pro $n \geq 5$), následně U_S (cca pro $n \geq 10$) a nakonec U_W (cca pro $n \geq 30$). Naprostě nevhodná pro test nulové hypotézy o rozptylu při rozsahu náhodného výběru $n \leq 5$ je statistika U_W . Z obrázku 6 zobrazujícího průměrné hodnoty testovacích statistik U_W , U_S a U_{LR} je potom patrné, že pro test o rozptylu nerovnost $U_W > U_{LR} > U_S$ neplatí.
- Příklad 6.6
 - * Test normality: $n = 107 > 100 \rightarrow$ Lillieforsův test; p -hodnota = 0.0989 > $\alpha = 0.05 \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$. Naměřené hodnoty basion-bregmatické výšky lebky žen starověké egyptské populace pochází z normálního rozdělení. (viz příklad 5.8)
 - * Test o rozptylu σ^2 , když μ neznáme:
 - Pomocí testovací statistiky $F_{W,n-1}$: $f_{W,n-1} = 116.9533$, $W = (-\infty; 79.4013) \cup (136.3822; \infty)$, $f_{W,n-1} \notin W \rightarrow H_0$ nezamítáme; $\sigma_0^2 = 19.6249$, $IS = (16.8292; 28.9063)$, $\sigma_0^2 \in IS \rightarrow H_0$ nezamítáme; p -hodnota = 0.4394, $\alpha = 0.05$, p -hodnota > $\alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
 - Pomocí testovací statistiky U_W : $u_W = 0.3875$, $W = (3.8415; \infty)$, $u_W \notin W \rightarrow H_0$ nezamítáme; $\sigma_0^2 = 19.6249$, $IS = (15.7030; 27.1973)$, $\sigma_0^2 \in IS \rightarrow H_0$ nezamítáme; p -hodnota = 0.5336, $\alpha = 0.05$, p -hodnota > $\alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
 - Pomocí testovací statistiky U_S : $u_S = 0.4629$, $W = (3.8415; \infty)$, $u_S \notin W \rightarrow H_0$ nezamítáme; $\sigma_0^2 = 19.6249$, $IS = (16.9176; 29.3017)$, $\sigma_0^2 \in IS \rightarrow H_0$ nezamítáme; p -hodnota = 0.4963, $\alpha = 0.05$, p -hodnota > $\alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
 - Pomocí testovací statistiky U_{LR} : $u_{LR} = 0.4361$, $W = (3.8415; \infty)$, $u_{LR} \notin W \rightarrow H_0$ nezamítáme; $\sigma_0^2 = 19.6249$, $IS = (16.5975; 28.3950)$, $\sigma_0^2 \in IS \rightarrow H_0$ nezamítáme; p -hodnota = 0.5090, $\alpha = 0.05$, p -hodnota > $\alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
 - Interpretace: Mezi rozptylem basion-bregmatické výšky lebky žen starověké a novověké egyptské populace neexistuje statisticky významný rozdíl ($|\sigma^2 - \sigma_0^2| = 2.0279 \text{ mm}^2$).

7 Test o korelačním koeficientu

- Příklad 7.1 ... Z uvedené animace vidíme, že Fisherova Z -transformace Z_R konverguje k normálnímu rozdělení $N\left(\frac{1}{2} \ln \frac{1+\rho}{1-\rho}, \frac{1}{n-3}\right)$ rychleji (uspokojivá shoda pro situaci, kdy $\rho = 0.8$, je cca $n \geq 5$) než výběrový korelační koeficient R k rozdělení $N\left(\rho, \frac{(1-\rho^2)^2}{n-1}\right)$ (uspokojivá shoda pro situaci, kdy $\rho = 0.8$, je cca $n \geq 35$).
- Příklad 7.2
 - * pro $n = 5 \dots$ Z uvedené animace vidíme, že Fisherova Z -transformace Z_R konverguje k normálnímu rozdělení $N\left(\frac{1}{2} \ln \frac{1+\rho}{1-\rho}, \frac{1}{n-3}\right)$ nejlépe pro ρ blízké nule. S $\rho \rightarrow 1$ se kvalita shody rozdělení Z_R a normálního rozdělení zhoršuje (situace se začíná zhoršovat cca od $\rho > 0.5$ a neuspokojivá začíná být cca od $\rho > 0.8$). V případě výběrového korelačního koeficientu R je situace neuspokojivá pro libovolné ρ .
 - * pro $n = 50 \dots$ Z uvedené animace vidíme, že pro $n = 50$ je kvalita konvergence Fisherovy Z -transformace Z_R i výběrového korelačního koeficientu R k příslušnému rozdělení uspokojivá pro libovolnou hodnotu korelačního koeficientu ρ .
- Příklad 7.3
 - * Test dvourozměrné normality: Mardiův test: (a) Test o nulovém koeficientu šiknosti: p -hodnota $= 0.3853 > \alpha = 0.05 \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$. (b) Test o nulovém koeficientu špičatosti: p -hodnota $= 0.1998 > \alpha = 0.05 \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$. Naměřené hodnoty největší výšky mozkovny a morfologické výšky tváře mužů starověké egyptské populace nevykazují statisticky významné zešikmení ani zešpičatění, z čehož vyplývá, že naměřené hodnoty největší výšky mozkovny a morfologické výšky tváře mužů starověké egyptské populace pochází z dvourozměrného normálního rozdělení.
 - * Test o korelačním koeficientu ρ :
 - $H_0 : \rho = 0.251; H_1 : \rho \neq 0.251$
 - Pomocí testovací statistiky Z_W : $z_W = 1.1048$, $W = (-\infty; -1.9600) \cup (1.9600; \infty)$, $z_W \notin W \rightarrow H_0$ nezamítáme; $\rho_0 = 0.251$, $IS = (0.1869; 0.4606)$, $\rho_0 \in IS \rightarrow H_0$ nezamítáme; p -hodnota $= 0.2692$, $\alpha = 0.05$, p -hodnota $> \alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
 - Pomocí testovací statistiky U_{LR} : $u_{LR} = 1.2418$, $W = (3.8415; \infty)$, $u_{LR} \notin W \rightarrow H_0$ nezamítáme; $\rho_0 = 0.251$, $IS = (0.1880; 0.4596)$, $\rho_0 \in IS \rightarrow H_0$ nezamítáme; p -hodnota $= 0.2651$, $\alpha = 0.05$, p -hodnota $> \alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
 - Interpretace: Mezi korelačním koeficientem největší výšky mozkovny a morfologické výšky tváře mužů starověké a novověké egyptské populace neexistuje statisticky významný rozdíl. Mezi největší výškou mozkovny a morfologickou výškou tváře mužů starověké egyptské populace existuje mírný stupeň přímé lineární závislosti ($\rho = 0.3306$). Mezi největší výškou mozkovny a morfologickou výškou tváře mužů novověké egyptské populace existuje nízký stupeň přímé lineární závislosti ($\rho = 0.251$).
- Příklad 7.4 ... příklad je analogický příkladu 4.7.
 - * Z grafů je patrné, že pro oboustrannou alternativu jsou rozsahy náhodných výběrů (pro pevně zvolené ρ_0 a ρ) vyšší než pro jednostranné alternativy. Pro pravostrannou alternativu ($H_{12}: \rho > \rho_0$) nemá smysl počítat rozsahy náhodných výběrů za předpokladu, že $\rho \leq \rho_0$. Pro levostrannou alternativu ($H_{13}: \rho < \rho_0$) nemá naopak smysl počítat rozsahy náhodných výběrů za předpokladu, že $\rho \geq \rho_0$. Dále, v případě, že by $\rho = \rho_0$, by minimální rozsah náhodného výběru musel být nekonečně velký (uvažujeme pouze teoreticky), a to pro všechny tři typy alternativní hypotézy.
 - * (a) Chyba v zadání. V situaci (a) raději uvažujme, že $H_0 : \rho \geq \rho_0$, a tedy $H_1 : \rho < \rho_0$. Za předpokladu hodnot parametrů uvedených v zadání je minálmí rozsah náhodného výběru $n_{\min} = 20$. Poznámka: Minimální rozsah náhodného výběru lze spočítat i pro stávající zadání, kde $H_0 : \rho \leq \rho_0$, nicméně z praktického hlediska toto zadání nedává smysl.
 - * (b) Za předpokladu hodnot parametrů uvedených v zadání je pro $H_0 : \rho = \rho_0$ minálmí rozsah náhodného výběru $n_{\min} = 438$.

- * (c) Chyba v zadání. V situaci (c) raději uvažujme, že $H_0 : \rho \leq \rho_0$, a tedy $H_1 : \rho > \rho_0$. Za předpokladu hodnot parametrů uvedených v zadání je minálmí rozsah náhodného výběru $n_{\min} = 84$. Poznámka: Minimální rozsah náhodného výběru lze spočítat i pro původní zadání, kde $H_0 : \rho \geq \rho_0$, nicméně z praktického hlediska toto zadání nedává smysl.

8 Test o pravděpodobnosti

- Příklad 8.1 ... *Poznámka:* Uspokojivá shoda rozdělení testovací statistiky Z_W se standardizovaným normálním rozdělením $N(0, 1)$ je více patrná, pokud v histogramu zvolíme hrubší dělení realizací z_W do třídicích intervalů, a to s ekvidistantní šírkou $d = 1$, namísto $d = 0.5$, jak je uvedeno v materiálech. Před pročtením komentářů si proto, prosím, toto třídění ve svých kódech opravte.
 - (a) $p = 0.1, p = 0.9 \dots$ Z animace vidíme, že Haldova podmínka je dobrým ukazatelem situací, kdy je možné rozdělení testovací statistiky Z_W approximovat normálním rozdělením $N(0, 1)$. Podle této podmínky je pro dobrou approximaci (a tedy spolehlivé testování) při volbě $p = 0.1$, resp. $p = 0.9$ potřebné mít náhodný výběr o rozsahu $N > 100$. Z animace vidíme, že pro nižší rozsahy není approximace upokojivá. Dále vidíme, že minimální rozsahy náhodných výběrů jsou symetrické pro hodnoty parametru p okolo hodnoty $p = 0.5$ (vysvětlení, proč pro $p = 0.1$ i pro $p = 0.9$ je minimální rozsah náhodného výběru N stejný). Můžete si ověřit, že toto platí pro libovolnou dvojici p a $1 - p$.
 - (b) $p = 0.5 \dots$ Z animace vidíme, že Haldova podmínka je dobrým ukazatelem situací, kdy je možné rozdělení testovací statistiky Z_W approximovat normálním rozdělením $N(0, 1)$. Podle této podmínky je pro dobrou approximaci (a tedy spolehlivé testování) při volbě $p = 0.5$ potřebné mít náhodný výběr o rozsahu $N > 36$ (nutno z Haldovy podmínky dopočítat). Pro nižší rozsahy není approximace dostatečně kvalitní, jak je vidět z animace. Pro $p = 0.5$, potřebujeme nejmenší minimální rozsah náhodného výběru. Čím více se s p blížíme do 0, či 1, tím vyšší minimální rozsah náhodného výběru potřebujeme, aby byla Haldova podmínka dobré approximace splněna a approximace rozdělení testovací statistiky Z_W normálním rozdělením byla dostatečně kvalitní.
- Příklad 8.2 ... Příklady 8.2, 8.3 a 8.4 ukazují jediný správný výpočet aktuální pravděpodobnosti pokrytí pro $(1 - \alpha)\%$ empirický IS pro parametr p . Konkrétně příklad 8.2 nám ukazuje úskalí aktuální pravděpodobnosti pokrytí 95% Waldova empirického DIS. Pokud náhodná veličina $X \sim \text{Bin}(30, 0.8)$ a při experimentu dojde k zaznamenání 24 úspěchů ze 30, je vše v pořádku a aktuální pravděpodobnost pokrytí $(1 - \hat{\alpha}) = 0.9463 \doteq 0.95$. Nicméně, pokud náhodná veličina $X \sim \text{Bin}(30, 0.79)$ a při experimentu dojde k zaznamenání 24 úspěchů ze 30 (což by reálně s vysokou pravděpodobností skutečně nastalo), klesne aktuální pravděpodobnost pokrytí $(1 - \hat{\alpha})$ na hodnotu $0.8876 \doteq 0.89$, tj. aktuální pravděpodobnost pokrytí je o 0.06 nižší než nominální pravděpodobnost pokrytí, což v pořádku není.
- Příklad 8.3 ... v tomto příkladu si vytváříme náhled na aktuální pravděpodobnost pokrytí 95% Waldova, skóre a věrohodnostního empirického DIS pro parametr p a pro různé rozsahy náhodného výběru N . Díky tomuto náhledu můžeme snadno zhodnotit, které DIS jsou pro určitá p a N naprostě nevhodná, jelikož jejich aktuální pravděpodobnost prokrytí se od nominální pravděpodobnosti pokrytí propastně liší.
 - Waldův 95% DIS ... pro $N = 5$ DIS ve většině případů z hlediska pravděpodobnosti pokrytí naprostě selhává, aktuální pst pokrytí je nižší než nominální pst pokrytí a DIS je silně liberální. Pro rostoucí N se situace lepsí, DIS nicméně povětšinou zůstává liberální, navíc výrazně selhává při nízkých hodnotách parametru p , zejména pro $p < 0.1$ nebo $p > 0.9$.
 - Skóre 95% DIS ... pro $N = 5$ dává DIS dobré výsledky (není ani konzervativní ani liberální) pro $p \in (0.2; 0.8)$. Pro cca $p < 0.2$ a $p > 0.8$ je liberální. S rostoucím N však jeho kvalita velmi rychle roste, pro $N = 100$ funguje skvěle pro cca $p \in (0.05; 0.95)$, pro $N = 500$ funguje skvěle de facto na celém intervalu $(0; 1)$. Ze všech DIS je z hlediska pravděpodobnosti pokrytí suverénně nejlepší.
 - Věrohodnostní 95% DIS ... pro $N = 5$ dává DIS dobré výsledky (není ani konzervativní ani liberální) pro cca $p \in (0.2; 0.8)$. Pro $p < 0.2$ a $p > 0.8$ je liberální. S rostoucím N však jeho kvalita velmi rychle roste, pro $N = 100$ funguje skvěle pro cca $p \in (0.1; 0.9)$, pro $N = 500$ funguje skvěle pro cca $p \in (0.02; 0.98)$.
- Příklad 8.4 ... v tomto příkladu si vytváříme náhled na aktuální pravděpodobnost pokrytí zpětně transformovaných 95% empirických DIS pro parametr p a pro různé rozsahy náhodného výběru N .
 - 95% zpětně transformovaný DIS s transformací $p/(1 - p)$... pro $N = 5$ DIS nevychází vůbec dobře, na celém intervalu $(0; 1)$ je liberální a od hodnoty $p > 0.8$ naprostě selhává; pro $N = 100$ se situace lepší, nicméně DIS je stále liberální a selhává pro $p > 0.9$. S rostoucím N se jeho vlastnosti zlepšují, nicméně v porovnání s následujícími alternativami i s alternativami z příkladu 8.3 vychází suveréně nejhůře.

- 95% zpětně transformovaný DIS s transformací $\ln(p/(1-p))$ … pro $N = 5$ DIS vychází dobře (není ani konzervativní ani liberální); pro $p \in (0.2; 0.8)$. Pro $p < 0.2$ nebo $p > 0.8$ je liberální, pro $p < 0.1$, či $p > 0.9$ selhává. S rostoucím N se však jeho kvalita rapidně zlepšuje a s výjimkou intervalu cca $(0; 0.05)$ a $(0.95; 1)$ není ani konzervativní ani liberální. V úzkém okolí hodnot 0 a 1 je liberální, v intervalech $(0; 0.05)$, $(0.95; 1)$ je spíše konzervativní.
- 95% zpětně transformovaný DIS s transformací $\arcsin(\sqrt{p})$ … pro $N = 5$ vychází dobře (není ani konzervativní ani liberální) pro $p \in (0.15; 0.85)$. Pro cca $p < 0.15$ nebo $p > 0.85$ je liberální a následně selhává. Stejně vlastnosti si drží i pro větší rozsahy náhodných výběrů; pro $N = 100$ je liberální pro cca $p < 0.1$ a $p > 0.9$; pro $N = 500$ je liberální pro cca $p < 0.05$ a $p > 0.95$, atd. Jeho nespornou výhodou navíc je, že rozptyl transformace je pevný (neměnný), a tedy není závislý na odhadu parametru p .
- Seřazení 95% empirických DIS pro parametr p podle kvality (z hlediska pravděpodobnosti pokrytí) od nejlepšího po nejhorší: (1) skóre, (2–3) věrohodnostní, (2–3) transformace $\arcsin(\sqrt{p})$, (4) transformace $\ln\left(\frac{p}{1-p}\right)$, (5) Waldův, (6) transformace $\frac{p}{1-p}$. Nejhodnější je na analýzy zvolit skóre DIS a tedy také skóre test.

9 Test o rozdílu středních hodnot

- Příklad 9.1

- (a) $X_1 \sim N(4, 2^2)$, $X_2 \sim N(2.5, 2^2)$... Centrální rozdělení přísluší parametru $\mu_0 = 0$, proto se červená křivka centrálního rozdělení realizuje okolo hodnoty 0. Naproti tomu rozdělení testovací statistiky T_W (zelený histogram superponovaný zelenou křivkou) přísluší hodnotě rozdílu $\mu_1 - \mu_2$, který pro $\mu_1 = 4$ a $\mu_2 > 4$ nabývá záporných hodnot, pro $\mu_2 = 4$ nabývá nuly a pro $\mu_2 < 4$ nabývá kladných hodnot. Zelený histogram i se zelenou křivkou necentrálního rozdělení se tedy nejprve realizuje nad zápornými hodnotami a s klesající hodnotou parametru μ_2 se postupně posouvá přes nulu do kladných čísel. Zelená křivka superponuje histogram přesně, protože oba náhodné výběry X_1 , resp. X_2 pochází z předpokládaných rozdělení $N(4, 2^2)$, resp. $N(2.5, 2^2)$.
- (b) $X_1 \sim$ směs, $X_2 \sim N(2.5, 2^2)$... Analogicky jako (a). Zelená křivka nesuperponuje histogram přesně, protože náhodný výběr X_1 pochází ze směsi, a tedy testovací statistiky T_W reprezentované histogramem jsou touto směsí kontaminovány. Rozdělení testovací statistiky T_W reprezentované zelenou křivkou nicméně odpovídá předpokladu, že X_1 , resp. X_2 pochází z "nekontaminovaného" normálního rozdělení $N(4, 2^2)$, resp. $N(2.5, 2^2)$.

- Příklad 9.2

- (1-a, b, c, d) $n = 5, n = 50, n = 100$... ani konzervativní ani liberální
- (2-a, b, c, d) $n = 5$... konzervativní
- (2-a, b, c, d) $n = 50, n = 100$... ani konzervativní ani liberální
- (3-a, b, c, d), (4-a, b, c, d), $n = 5$... liberální
- (3-a, b, c, d), (4-a, b, c, d), $n = 50$... mírně liberální
- (3-a, b, c, d), (4-a, b, c, d), $n = 100$... ani konzervativní, ani liberální
- Z hlediska pravděpodobnosti pokrytí vychází pro všechny čtyři situace (a)–(d) nejlépe Waldovy DIS pro shodné rozptyly obou náhodných výběrů. Tyto DIS nejsou konzervativní ani liberální již pro nízké rozsahy ($n \geq 5$) náhodných výběrů. Pro vyšší rozsahy ($n \geq 50$) vychází dobře také Waldovy DIS pro různé rozptyly, které jsou pro nižší rozsahy $n < 50$ konzervativní. Vérohodnostní DIS vychází z hlediska pravděpodobnosti pokrytí dobře pro náhodné výběry s rozsahy $n \geq 100$. Pro $n \leq 100$ jsou vérohodnostní DIS mírně liberální, pro nízké rozsahy ($n \leq 5$) jsou nevhodné, jelikož jsou velmi liberální. Všimněme si, že z hlediska pravděpodobnosti pokrytí není příliš výrazný rozdíl mezi intervaly spolehlivosti sestřjenými za předpokladu shodných rozptylů a za předpokladu různých rozptylů. Závěrem poznamenejme, že pravděpodobnost prokrytí je pouze jednou z vlastností intervalu spolehlivosti, kterou bychom před jeho použitím v praxi měli znát. Finální volba intervalu spolehlivosti by však měla záviset i na dalších aspektech (například, pokud DIS používáme k testování, záleží také na síle testu, který DIS reprezentuje :)).

- Příklad 9.3

- Test normality muži: $n = 50 \rightarrow$ Andersonův-Darlingův test; p -hodnota = 0.4316 > $\alpha = 0.05 \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$. Naměřené hodnoty délky klíční kosti z pravé strany u mužů pochází z normálního rozdělení.
- Test normality ženy: $n = 50 \rightarrow$ Andersonův-Darlingův test; p -hodnota = 0.0191 < $\alpha = 0.05 \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$. Naměřené hodnoty největší výšky mozkovny žen starověké egyptské populace nepochází z normálního rozdělení. → Nesprávně zvolená data na tento typ příkladu z mé strany. Správný postup by nyní byl použít na ověření zadáné hypotézy neparametrický test. Pro účely procvičení se však pro tentokrát tvařme, že normalita náhodného výběru pro ženy je též v pořádku.
- Test o shodě rozptylů σ_1^2/σ_2^2 :
 - * Jelikož různé testy o podílu rozptylů probíráme až v následující sekci, otestujeme hypotézu o shodě rozptylů pouze pomocí testu, který známe z bakalářského studia, tj. pomocí F -testu, který provedeme příkazem `var.test()`, a to pouze na základě p -hodnoty: p -hodnota = 0.0981 > $\alpha = 0.05$, tj. H_0 nezamítáme na hladině významnosti $\alpha = 0.05$. Mezi rozptylem délky klíční kosti z pravé strany u mužů a žen neexistuje statisticky významný rozdíl (předpokládáme, že rozptyly jsou shodné).

– Test o rozdílu středních hodnot:

- * Pomocí testovací statistiky T_W : $t_W = 7.1019$, $W = (-\infty; -1.9845) \cup (1.9845; \infty)$, $t_W \in W \rightarrow H_0$ zamítáme; $\mu_0 = 0$, $IS = (10.1313; 17.9887)$, $\mu_0 \notin IS \rightarrow H_0$ zamítáme; p -hodnota < 0.0001, $\alpha = 0.05$, p -hodnota < $\alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
- * Pomocí testovací statistiky T_W s Welchovou aprox. st. volnosti: $t_W = 7.1019$, $W = (-\infty; -1.9858) \cup (1.9858; \infty)$, $t_W \notin W \rightarrow H_0$ zamítáme; $\mu_0 = 0$, $IS = (10.1286; 17.9914)$, $\mu_0 \notin IS \rightarrow H_0$ zamítáme; p -hodnota < 0.0001, $\alpha = 0.05$, p -hodnota < $\alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
- * Pomocí testovací statistiky U_{LR} , $\sigma_1^2 = \sigma_2^2$: $u_{LR} = 41.5196$, $W = (3.8415; \infty)$, $u_{LR} \in W \rightarrow H_0$ zamítáme; $\mu_0 = 0$, $IS = (10.1816; 17.9384)$, $\mu_0 \notin IS \rightarrow H_0$ zamítáme; p -hodnota < 0.0001, $\alpha = 0.05$, p -hodnota < $\alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
- * Pomocí testovací statistiky U_{LR} , $\sigma_1^2 \neq \sigma_2^2$: $u_{LR} = 51.4667$, $W = (3.8415; \infty)$, $u_{LR} \in W \rightarrow H_0$ zamítáme; $\mu_0 = 0$, $IS = (10.2188; 17.9012)$, $\mu_0 \notin IS \rightarrow H_0$ zamítáme; p -hodnota < 0.0001, $\alpha = 0.05$, p -hodnota < $\alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
- * Interpretace: Mezi délku klíční kosti z pravé strany u mužů a žen existuje statisticky významný rozdíl. ($|\mu_1 - \mu_2| = |151.74 - 137.68| = 14.06$ mm).
- * *Poznámka:* Vzhledem k výsledku testu o podílu rozptylů bychom v praxi pro otestování H_0 o rozdílu středních hodnot použili buď (a) klasický t -test, nebo (c) věrohodnostní test, když $\sigma_1^2 = \sigma_2^2$.

10 Test o podílu rozptylů

- Příklad 10.1 (a) ... Podíl rozptylů největší výšky mozkovny mužů a žen
 - * Test normality muži: $n = 164 > 100 \rightarrow$ Lillieforsův test; p -hodnota = 0.0710 > $\alpha = 0.05 \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$. Naměřené hodnoty největší výšky mozkovny mužů starověké egyptské populace pochází z normálního rozdělení.
 - * Test normality ženy: $n = 78; 50 < n < 100 \rightarrow$ Andersonův-Darlingův test; p -hodnota = 0.4501 > $\alpha = 0.05 \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$. Naměřené hodnoty největší výšky mozkovny žen starověké egyptské populace pochází z normálního rozdělení.
 - * Test o podílu rozptylů σ_1^2/σ_2^2 :
 - Pomocí testovací statistiky F_W : $f_W = 0.9005, W = (-\infty; 0.6893) \cup (1.4904; \infty), f_W \notin W \rightarrow H_0$ nezamítáme; $\sigma_0^2 = 1, IS = (0.6042; 1.3065), \sigma_0^2 \in IS \rightarrow H_0$ nezamítáme; p -hodnota = 0.5747, $\alpha = 0.05, p$ -hodnota > $\alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
 - Pomocí testovací statistiky U_{LR} : $u_{LR} = 0.2936, W = (3.8415; \infty), u_{LR} \notin W \rightarrow H_0$ nezamítáme; $\sigma_0^2 = 1, IS = (0.6091; 1.3087), \sigma_0^2 \in IS \rightarrow H_0$ nezamítáme; p -hodnota = 0.5879, $\alpha = 0.05, p$ -hodnota > $\alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
 - Interpretace: Mezi rozptylem největší výšky mozkovny mužů a žen starověké egyptské populace neexistuje statisticky významný rozdíl. ($|\sigma_1^2 - \sigma_2^2| = |21.1387 - 23.4734| = 2.3347 \text{ mm}^2$).

Poznámka: Graf zobrazený na obrázku 1 vlevo ukazuje, že hodnota parametru $\sigma_0^2 = 1$ skutečně náleží do 95% věrohodnostního empirického intervalu spolehlivosti.
- Příklad 10.1 (b) ... Podíl rozptylů morfologické výšky tváře mužů a žen
 - * Test normality muži: $n = 164 > 100 \rightarrow$ Lillieforsův test; p -hodnota = 0.0450 < $\alpha = 0.05 \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$. Při pohledu na p -hodnotu však vidíme, že k zamítnutí H_0 o normalitě došlo na hladině významnosti $\alpha = 0.05$ hraničně. Pokud bychom chtěli být naprostě korektní, museli bychom H_0 o normalitě zamítout, udělat závěr, že data nepochází z normálního rozdělení a H_0 o podílu rozptylů otestovat vhodným neparametrickým testem. Nicméně víme, že parametrické testy jsou mnohem silnější, než testy neparametrické, proto v praxi při hraničním zamítnutí H_0 přivíráme oči a i přes hraniční zamítnutí H_0 o normalitě považujeme naměřené hodnoty za normálně rozložené. Tak tomu bude i v tomto příkladu. V reálné situaci by však záleželo pouze na vás, zda byste se striktně řídili výsledkem testu normality, či zda byste také přivřeli oči :). *Poznámka:* Na rozdíl od příkladu 9.3 zde byla data s hraniční normalitou použita záměrně, abyste si vyzkoušeli řešení při sporné a hraniční situaci.
 - * Test normality ženy: $n = 78; 50 < n < 100 \rightarrow$ Andersonův-Darlingův test; p -hodnota = 0.4053 > $\alpha = 0.05 \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$. Naměřené hodnoty morfologické výšky tváře žen starověké egyptské populace pochází z normálního rozdělení.
 - * Test o podílu rozptylů σ_1^2/σ_2^2 :
 - Pomocí testovací statistiky F_W : $f_W = 1.5207, W = (-\infty; 0.6893) \cup (1.4904; \infty), f_W \in W \rightarrow H_0$ zamítáme; $\sigma_0^2 = 1, IS = (1.0203; 2.2063), \sigma_0^2 \notin IS \rightarrow H_0$ zamítáme; p -hodnota = 0.0397, $\alpha = 0.05, p$ -hodnota < $\alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
 - Pomocí testovací statistiky U_{LR} : $u_{LR} = 4.3956, W = (3.8415; \infty), u_{LR} \in W \rightarrow H_0$ zamítáme; $\sigma_0^2 = 1, IS = (1.0285; 2.2100), \sigma_0^2 \notin IS \rightarrow H_0$ zamítáme; p -hodnota = 0.0360, $\alpha = 0.05, p$ -hodnota < $\alpha \rightarrow H_0$ zamítáme na hladině významnosti $\alpha = 0.05$.
 - Interpretace: Mezi rozptylem morfologické výšky tváře mužů a žen starověké egyptské populace existuje statisticky významný rozdíl. ($|\sigma_1^2 - \sigma_2^2| = |51.4368 - 33.8242| = 17.6126 \text{ mm}^2$).

Poznámka: Jelikož v tomto případě došlo k zamítnutí H_0 o podílu rozptylů opět více méně hraničně, bylo by vhodné provést také neparametrický test o shodě rozptylů obou náhodných výběrů a prověřit, zda by závěrem neparametrického testu bylo rovněž zamítnutí H_0 o shodě rozptylů.
- Graf zobrazený na obrázku 1 vpravo ukazuje, že hodnota parametru $\sigma_0^2 = 1$ skutečně nenáleží do 95% věrohodnostního empirického intervalu spolehlivosti.

11 Test o parametru λ Poissonova rozdělení

– Příklad 11.1

- * Pomocí testovací statistiky Z_W : $z_W = 0.1811, W = (-\infty; -1.9600) \cup (1.9600; \infty), z_W \notin W \rightarrow H_0$ nezamítáme; $\lambda_0 = 0.6, IS = (0.5018; 0.7182)$, $\lambda_0 \in IS \rightarrow H_0$ nezamítáme; p -hodnota = 0.8563, $\alpha = 0.05$, p -hodnota $> \alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
- * Pomocí testovací statistiky U_S : $u_S = 0.0333, W = (3.8415; \infty), u_S \notin W \rightarrow H_0$ nezamítáme; $\lambda_0 = 0.6, IS = (0.5109; 0.7283)$, $\lambda_0 \in IS \rightarrow H_0$ nezamítáme; p -hodnota = 0.8551, $\alpha = 0.05$, p -hodnota $> \alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
- * Pomocí testovací statistiky U_{LR} : $u_{LR} = 0.0331, W = (3.8415; \infty), u_{LR} \notin W \rightarrow H_0$ nezamítáme; $\lambda_0 = 0.6, IS = (0.5081; 0.7247)$, $\lambda_0 \in IS \rightarrow H_0$ nezamítáme; p -hodnota = 0.8555, $\alpha = 0.05$, p -hodnota $> \alpha \rightarrow H_0$ nezamítáme na hladině významnosti $\alpha = 0.05$.
- * Interpretace: Střední počet úmrtí v důsledku kopnutí koněm v Pruských armádních jednotkách během jednoho roku není statisticky významně odlišný od hodnoty 0.6. (Náhodná veličina X popisující počet úmrtí v důsledku kopnutí koněm v Pruských armádních jednotkách pochází z Poissonova rozdělení (viz Statistická inference I) s parametrem λ , který není statisticky významně odlišný od hodnoty 0.6.)