

Z teorie víme, že pokud $X \sim N(\mu, \sigma^2)$, potom pro test. statistiku F_W testu o rozptylu σ^2 při neznámé střední hodnotě μ platí:

$$F_W = \frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

Tento fakt si ověříme pomocí simulační studie (a). Navíc se podíváme, jak to se vztahem $F_W \sim \chi_{n-1}^2$ vypadá, když:

b) $X \sim pN(\mu, \sigma^2) + (1-p)N(\mu, \sigma_2^2)$

c) $X \sim Exp(\lambda)$.

$\mu=0, \sigma^2=1, \sigma_2^2=4, p=0.9, \lambda=1$.

1. Vypočítáme funkci simulace.F(), která podle vybrané volby rozdělení ('normal', 'mix', 'exp') při zadaných parametrech μ, σ ($+\sigma_2, p$), resp. λ , vykreslí příslušný graf.

```
simulace.F <- function(n, mu=0, sigma=..., sigma2=..., M=..., p=..., type=...) {
  if(type == 'normal') {
    Fw <- replicate(M, (n-1)*sd(rnorm(n, mu, sigma))^2 / sigma^2)
    main <- paste('x ~ N(mu, sigma^2)', sep=' ')
  }
  if(type == 'mix') {
    X <- matrix(NA, M, n)
    for(...) {
      ... } =>  $\otimes \sum$  matice M=1000 měř. výběru o rozsahu n. Znaménko závorky 04 a 05.
    S <- apply( ) ... vektor 1000 sm. odchylek (délka = 1000)
    Fw <-  $\frac{(n-1)S^2}{\sigma^2}$  ... vektor 1000 sest. statistik Fw (délka = 1000)
    main <- paste('x ~ pN(mu, sigma^2) + (1-p)N(mu, sigma_2^2)', sep=' ')
  }
  if(type == 'exp') {
    Fw <- replicate(M, ... rexp(n, lambda)...)
    main <- paste(...) ... automaticky měni se popis X ~ Exp(lambda) podle hodnot mu, sigma^2, p, sigma_2^2.
  }
  xfit <- seq(..., ..., max(Fw)+2) & délce minimálně 500.
  yfit <- dchisq(xfit, n-1) hustota  $\chi^2$  rozdělení o n-1 s.d. rovná mod posl. xfit
  d <- hist(Fw, plot=F, breaks=15, dens) ... výběr sloupců histogramu (využijeme v histogramu při nastavení rozsahu y)
  hist(Fw, prob=..., breaks=15, ylim=c(0, max(ylim, d)),
        border='darkorange2', col='darkorange', ...)
  box() □
  lines(xfit, yfit, ...) křivka hustoty  $\chi_{n-1}^2$ 
  mtext(expression(...), ...) popisek Fw
  mtext(paste('n = ', n, ';', main, sep=' '), ...) popisek pod popiskem Fw (mění se podle argumentu type)
}
```

2. Vypočítáme animaci ukazující změnu histogramu a křivky χ_{n-1}^2 pro situaci (a).

$n <- c(3, 4, 5, 10, \dots, 250, 500)$... posl. n určená v rozsahu souboru

(...) úvodní nastavení animace

saveLatex(for(i in 1:length(n)) {

simulace.F(n=n[i], type='normal', ...) }) cyklos vykreslující jednotlivé kroky animace.

} ...)

3. Analogicky vypočítáme animaci pro (b) a (c). ! Jednou větou rázem komentujte vývoj v animaci pro n>10

$$X \sim N(150, 30^2)$$

$$H_0: \sigma^2 = 60^2 \quad H_1: \sigma^2 \neq 60^2$$

$$H_0: \sigma^2 = 30^2 \quad H_1: \sigma^2 \neq 30^2$$

H_0 testujeme testem σ^2 když μ nevímme.

$$1. \text{ Testovací statistika } F_{W,n-1} = \frac{(n-1)S^2}{\sigma_0^2} \sim \chi^2_{n-1}$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$2. \text{ Testovací statistika } F_{W,n} = \frac{n S_n^2}{\sigma_0^2} \sim \chi^2_n$$

$$S_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$3. \text{ Testovací statistika } T_W = \sqrt{\frac{n}{2}} \left(1 - \frac{n}{F_{W,n}} \right) \sim N(0,1)$$

$$4. \text{ Testovací statistika } U_W = \frac{n}{2} \left(1 - \frac{n}{F_{W,n}} \right)^2 \sim \chi^2_1$$

$$5. \text{ Testovací statistika } U_S = \frac{n}{2} \left(\frac{F_{W,n}}{n} - 1 \right)^2 \sim \chi^2_1$$

$$6. \text{ Testovací statistika } U_{LR} = F_{W,n} - n \left(1 + \ln \left(\frac{F_{W,n}}{n} \right) \right) \sim \chi^2_1$$

Příklady 6.2 a 6.4 vyřešíme společně myšlením funkce `F.stat()`, která v závislosti na zadáném typu test. statistiky vykreslí odpovídající obrázek. Tuto funkci pak použijeme k vykreslení animaci v obou příkladech.

`F.stat <- function (sigma0, mu, sigma, mu2=mu, sigma2=sigma, n=..., M=..., p=..., type=...) {`

Generování dat

$X \leftarrow \text{matrix}(NA, M, n)$	n	$(...) rnorm(\text{sum}(bin == 1), mu, sigma)$
$\text{for}(\dots) \{$	\otimes	$(...) rnorm(\text{sum}(bin == 0), mu_1, sigma_2)$
$\dots \}$	Σ	kód si nachystáme i pro směs, až jí v tomto příkladě nemáme zadáno. Se změnou parametrů $\mu_1, \mu_2, \sigma_1^2, \sigma_2^2$ a p pak můžete kdykoliv libovolně experimentovat. =)

statistik

`S <- apply()`
`S_n <- sqrt(apply(X, 1, var)*(n-1)/n)`

testovacích

`F_w <- $\frac{(n-1)S^2}{\sigma_0^2}$`
`F_wn <- $\frac{n S_n^2}{\sigma_0^2}$`
`t_w <- $\sqrt{\frac{n}{2}} \left(1 - \frac{n}{F_{W,n}} \right)$`
`u_w <- $\frac{n}{2} \left(1 - \frac{n}{F_{W,n}} \right)^2 = b_w^2$`
`u_s <- $\frac{n}{2} \left(\frac{F_{W,n}}{n} - 1 \right)^2$`
`u_lr <- $F_{W,n} - n \left(1 + \ln \left(\frac{F_{W,n}}{n} \right) \right)$`

Príprava statistických

`if (type == 'Fw') {`
`X <- Fw`
`xx <- seq(..) posl. od 0 do max(Fw) + 1 o délce minimálně 500`
`yy <- dchisq(..) hustota χ^2_{n-1} rozdělení nad posl. xx`
`main <- expression (F['W, n-1']) ... popisek $F_{W,n-1}$`
`}`
`if (type == 'Fwn') {`
`x <- ..`
`xx <- ..`
`yy <- ..`
`main <- ..`

ne-testovací statistické

analogicky jako u F_w

Specifikace vybraných proměnných podle zvole

```

if(type == 'tW'){
  x <- tW
  xx <- seq(..) pos. od min(tW)-1 do max(tW)+2 o minimální délce 500
  yy <- dnorm(..) hustota  $N(0,1)$  nad posloupností xx
  main <- expression(..) ... popis tW
}

if(type == 'uW'){
  x <- uW
  xx <- seq(..) pos. od 0 do max(uW)+1 o minimální délce 500
  yy <- dchisq(..) hustota  $\chi^2$  rozdělení nad posloupností xx
  main <- expression(..) popis uW
}

if(type == 'uS'){
  analogicky jako uW
}

if(type == 'ULR'){
  analogicky jako uW
}

d <- max(hist(x, plot=F, breaks=15)$dens) ... výška nejvyššího sloupu v histogramu (využijeme při stanovení
hist(X, prob=T, breaks=15, ylim=c(0, d+d/15), ...)      rozsahu osy y v malém pásmu)
box(...) □
mtext(main, ...) popis ... může mít několik desívacích statistik
mtext(paste('n = ', n), ...) popis n = ... (n je automaticky menší než počet hodnot na rozdílu na rozdílném rozsahu měření)
lines(xx, yy, ...) hranice pětičlánkového rozdělení desívacích statistik
}

```

Vykreslení grafu

6.2: Animace rozdělení desívacích statistik $F_{w,n-1}$ a $F_{w,n}$.

```

n <- c(3,4,5,...,250,500) ... posl. n nadání posle rozdělení přibližně
par(mfrow=c(1,2), mar=c(5,5,1,1)) ... mfrow: □□ ; mar: 5 1/5 1 okraje
... úvodní nastavení animace
saveLatex(for(i in 1:length(n)){
  F.stat(sigma0=30, mu=150, sigma=30, n=n[i], type='Fw')
  F.stat(-||- -||-, type='Fwn')
})

```

6.4: Animace rozdělení desívacích statistik T_w , U_w , U_s a $U_{LR} \rightarrow$ viz. obr. 5 řádku pí. 6.4.

$$F_{W,n-1} = \frac{(n-1)S^2}{60} = \frac{(n-1)}{60} \cdot \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{60} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$F_{W,n} = \frac{n S_n^2}{60} = \frac{n}{60} \cdot \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{60} \sum_{i=1}^n (x_i - \bar{x})^2$$

$\Rightarrow F_{W,n-1} = F_{W,n}$

Současné výše, že $F_{W,n-1} \sim \chi^2_{n-1}$ je vzhledem (tj. $F_{W,n} \sim \chi^2_{n-1}$, takže vzhledem, ale to máš až když mnohem).

V tomto příkladu myní ověříme, že pro $n \rightarrow \infty$ χ^2_{n-1} rozdílení a χ^2_n rozdílení konverguje.

Z konvergence potom vyplývá, že $F_{W,n} \sim \chi^2_n$.

V rámci tohoto příkladu si ukážeme názornou konvergenci rozdílení χ^2_n a rozdílení χ^2_{n-1} .

1. Vyhodíme funkci konvergence.chi(), která pro zadání n vykreslí graf s křivkami hustot χ^2_n a χ^2_{n-1} .
Doporučení: Příklad je krátký, jednoduchý, můžeš si jej dletoho neplatit napsat programovat samostatně.
ber dívání na následující pseudokód. \Rightarrow Post. xfit násobek od 0 do $n + \frac{n}{2}$ o délce min. 500.

`konvergence.chi <- function(n) {`

`xfit <- seq(0, n + n/2, length.out = 500)`

`yfit <- dchisq(xfit, n)` hustota χ^2_n rozdílení nad post. xfit

`zfit <- dchisq(xfit, n - 1)` hustota χ^2_{n-1} rozdílení nad post. xfit

`plot(xfit, yfit, type = 'l')` křivka hustoty χ^2_{n-1}

`lines(xfit, zfit)` křivka hustoty χ^2_n popisek n legenda χ^2_{n-1} analogicky

`legend('topright', c(expression(chi[n-1]^2), expression(...)), ...)` ... legenda

`mtext(bquote(n == .), 1)` ... popisek $n = \text{CP}$, kde CP se automaticky mění podle rozsahu měř. vyberi m.

}

2. Vyhodíme animaci:

`n <- c(2, 3, ..., 500, 1000)` zadání post. rozsahu měř. vyberi n.

... úvodní nastavení animace

`saveLatex(for(...){`

`konvergence.chi(n[i])`

`}, ...)`

Tip: V komentářích mi můžeš napsat, když ještě příklad vyřešili ber pseudokód nebo a pseudokódem a jak to říká. \Rightarrow

Animace rozdílení diskovacích statistik T_W a U_W :

$n \leftarrow c(3, 4, 5, 10, \dots, 250, 500)$

par(mfrow = c(1, 2), mar = c(5, 5, 1, 1)), mfrow: $\boxed{\quad} \boxed{\quad}$; mar: $5 \frac{1}{5} \times 1$ okraj
... išvodní nastavení animace

```
saveLatex(for(i in 1:length(n)){
  F.stat(sigma0=30, mu=150, sigma=30, n=n[i], type='tW')
  F.stat(-||- -||- -||- type = 'uW')
},...)
```

Animace rozdílení diskovacích statistik U_S a U_{LR} :

par(...) $\boxed{\quad} \boxed{\quad}$; $5 \frac{1}{5} \times 1$
... išvodní nastavení animace

```
saveLatex(for(...){
  F.stat(...)
  F.stat(...)
},...)
```

* Tip: Vyříjděte se, že funkce **F.stat()** umí generovat grafy i pro směšná rozdílení a podívejte se, jak vypadá situace máme-li směs A:

- ričními μ a μ_2 , ale stejnými rozptyly σ^2 .
- stejnými μ , ale různými rozptyly σ^2 a σ_2^2 .
- ričními μ a μ_2 i různými σ^2 a σ_2^2 .

Komentáře situace (a) - (c) v komentářích nemusíte, ale poučte se z toho. =)

Příklad je analogický k příkladu 5.4. Pokud chceš, můžeš si jej naprogramovat samostatně a pseudokód povídají jen pro kontrolu. =)

$$H_0: \sigma^2 = \sigma_0^2$$

$$H_1: \sigma^2 \neq \sigma_0^2$$

$$U_S = \frac{n}{2} \left(\frac{F_{w,n}}{n} - 1 \right)^2 \sim \chi_1^2$$

$$U_{LR} = F_{w,n} - n \left(1 + \ln \left(\frac{F_{w,n}}{n} \right) \right) \sim \chi_1^2$$

$$U_W = \frac{n}{2} \left(1 - \frac{n}{F_{w,n}} \right)^2 \sim \chi_1^2$$

$$F_{w,n} = \frac{n S_n^2}{\sigma_0^2}, \quad S_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

1. Vyrobíme fci porovnani.var(), která pro zadání n, μ, σ, σ_0 a M vykreslí 1 obrátek a vypočítá průměrnou hodnotu z M klasických testovacích statistik U_W, U_S a U_{LR} .

`porovnani.var <- function(n, M=..., mu=..., sigma=..., sigma0=..., M=..., plot=...) {`

`X <- t(replicate(...))` ... matice $M=1000$ měs. výběrů z $N(\mu, \sigma^2)$ o rozsahu n $\begin{matrix} X \\ \Sigma \\ \vdots \\ n \end{matrix}$
`m <- apply(...)` vektor výb. průměrů (délka = 1000)
`s <- apply(...)` vektor výb. sm. odchylek $S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$ (1000)
`S.n <- sqrt((n-1)*S^2/n)` ... uprava S na s_n ; $s_n = \sqrt{\frac{(n-1) \cdot S^2}{n}}$ (1000)
`Fwn <- F_w,n` vektor $M=1000$ test. statistik $F_{w,n}$ (délka = 1000)
`uW <- UW` (1000)
`uS <- US` (1000)
`uLR <- ULR` (1000)

`prumery <- c(mean(uW), mean(uS), mean(uLR))` ... vektor 3 průměrů test. statistik (délka = 3)

`xfit <- seq(...)` posl. od 0 do 30 o délce minimálně 500

`yfit <- dchisq(...)` ... hustota χ_1^2 rozdělení nad posloupcemi `xfit`

`if (plot == T) {`

`plot(uW, type='n', xlim=c(0,6), ylim=c(0,1), ...)` ... připrava prázdného grafu

`mtext(...)` ... popisek 'x'

`mtext(bquote(paste(n == .(n), mu == .(mu), sigma^2 == .(sigma^2))), ...)` ... popisek $n=n, \mu=\mu, \sigma^2=\sigma^2$.

`lines(density(uW, from=0, to=10), ...)` ... křivka jádrovýho odhadu hustoty test. statistiky U_W sestaveného

`lines(density(...), ...)` ... křivka jádrovýho odhadu hustoty test. statistiky U_W . Zadr. odhad je

`lines(density(...), ...)` ... křivka jádrovýho odhadu pro U_{LR} sestaveného nad posl. čísel od 0 do 10.

`lines(xfit, yfit, ...)` ... křivka hustoty χ_1^2 rozdělení

`abline(...)` ... vertikální referenční křivka $y=0$.

`legend(..., lty=c(1,1,1,2,2), lwd=c(1,1,1,2,2), ...)` ... legenda

}

`return(prumery)` ... výsledek funkce bude vektor průměrů test. statistik (1) U_W , (2) U_S a (3) U_{LR} .

}

2. Vyrobíme animaci:

`n <- c(...)` ... posloupnost rozsahu měs. výběrů (viz zadání příkladu)

... úvodní nastavení animace

`saveLatex(for(...){`

`porovnani.var(n = n[i])`
`}, ...)`

3. Graf průměrů test. statistik U_W , U_S a U_{LR} :

7

`m50 <- porovnani.var(n=50,...)` ... průměrné hodnoty $H=1000$ test. statistik U_W , U_S a U_{LR} (délka = 3) pro různé množství n = 50.

`m100 <- ...` ... n = 100.

`m500 <- ...` ... n = 500.

`m1000 <- ...` ... n = 1000.

`m <- cbind(m50, m100, m500, m1000)`

`m.uW <- m[1,]` ... vektor prům. hodnot test. statistik U_W pro n = 50, n = 100, n = 500 a n = 1000.

`m.uS <- ...` ... U_S ...

`m.ulR <- ...` ... U_{LR} ...

`plot(1:4, m.uW, type='o', ylim=c(min(m.uS)-0.1, max(m.uW)+0.1),`

axes=F,...) ... body prům. hodnot test. statistiky U_W pro n = 50, n = 100, n = 500 a n = 1000 spojene čarami

`box(...)` □

`axis(1, at=..., labels=...)` ... sítové mřížko o y x. Čísla 1-4 přiřadíme popisky 50, 100, 500 a 1000.

`axis(2,...)` ... mřížko o y

`lines(1:4, m.uS, type='...', ...)` ... body průměrných hodnot U_S pro n = 50, n = 100, n = 500 a n = 1000 spojene čarami

`lines(...)` ... U_{LR} ...

`legend(...)` legenda

V rámci tohoto příkladu si vyzkoušme aplikaci testovacích statistik $F_{W,n-1}$, U_W , U_S a U_{LR} na reálná data. Nejprve ověříme předpoklad normality. Následně otestujeme H_0 ze zadání, a to němi třemi různými způsoby (krit. oborem, IS i p-hodnotou) pro každou test. s statistiku $F_{W,n-1}$, U_W , U_S i U_{LR} . Nerapovememe významný rozdíl mezi H_0 a mohouc interpretaci návěřu testování. Nakonec vykreslime hranice a oblasti Waldova, skóre a výrohodnostního 95% empirického IS.

Příprava dat

```
data <- read.delim(...) ... načtení dat. souboru 11-two-samples-means-skull.txt
skull.F <- data[data$sex == 'f', 'skull.H'] ... výběr v datovém souboru hodnoty biomass - bregm. výšky pro ženy
skull.F <- na.omit(skull.F) ... odstranění NA hodnot
```

H_0 :

H_1 :

`nortest::lillie.test(...)`

Závěr: Protože ..., H_0 ... na hl. významnosti $\alpha = 0.05$.

Interpretace:

Poznámka: Test normality pro stejná data jsme provádili v rámci příkladu 5.8. Proto, pokud jde příklad 5.8 nepracovali, nemí mít, aby byly nově vykreslovati kontingenční histogram a Q-Q diagram. Grafy si všichni vykresleli, pokud jde příklad 5.8 nepracovali.

Test o σ^2 , když μ neznáme

Do komentářů uvedět názvy H_0 a H_1 :

H_0 :

H_1 :

Příprava hodnot

```
Sigma0 <- ... 60
n <- ... n
S <- ...  $S = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$ 
Sn <- ...  $s_n = \sqrt{s^2/n}$ 
alpha <- ... 2
```

Testování kritickým oborem:

$F_W <- ... F_{W,n-1}$

$F_{Wn} <- ... F_{W,n}$

$u_W <- ... U_W$

$u_S <- ... U_S$

$u_{LR} <- ... U_{LR}$

$q_1 <- ... \chi^2_{n-1}(\alpha/2)$

$q_2 <- ... \chi^2_{n-1}(1-\alpha/2)$

$q_f <- ... \chi^2_1(1-\alpha)$

Příprava krit. oboru Testovací statistiky

+

Pro kritický test uvedět polovičný návěř o H_0 :

Protože $F_W = \dots$ malé / menší do krit. oboru $W = \dots$, $H_0 \dots$ má hl. významnosti $\alpha = 0.05$.
(analogicky pro U_W , U_S a U_{LR}).

Testování IS:

$$dh.Fw \leftarrow \frac{s^2(n-1)}{\chi^2_{n-1}(1-\alpha/2)}$$

$$hh.Fw \leftarrow \frac{s^2(n-1)}{\chi^2_{n-1}(\alpha/2)}$$

`sigma.i <- seq(...)` ... posl. σ od 2.5 do 6 se rozdíleními mezi body 0.0001 (by = 0.0001)

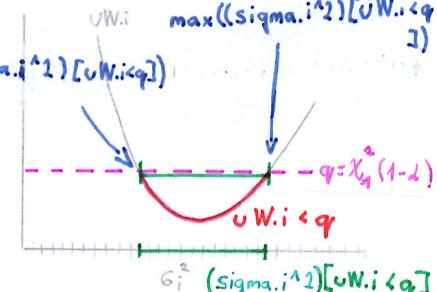
$$Fwn.i \leftarrow n * s_n^2 / sigma.i^2 \quad \text{vektor } Fwn.i = \frac{n s_n^2}{\sigma_i^2}$$

`uW.i` ← vektor 35001 test. statistik $u_{W,i}$ pro posl. σ_i (`sigma.i`)

`dh.uW` ← $\min((\sigma_i^2)[uW.i < q])$... dolní hranice Waldova 95% emp. IS

`hh.uW` ← $\max((\sigma_i^2)[uW.i < q])$... horní hranice Waldova 95% emp. IS
(vyhání z uW)

čím více bodů, tím přesnější
hranice IS
(délka = 35001)



`US.i` ← ... vektor 35001 test. statistik $u_{S,i}$ pro posl. σ_i (`sigma.i`)

`dh.uS` ← ... analogicky jako u `dh.uW` ... dolní hr. skóre 95% emp. IS (vyhání z uS)

`hh.uS` ← ... analogicky jako u `hh.uW` ... horní hr. -II-

`ULR.i` ← ... vektor 35001 test. statistik $u_{LR,i}$ pro posl. σ_i (`sigma.i`)

`dh.uS` ← ... analogicky jako u `dh.uW` ... dolní hr. výrodnostního 95% emp. IS (vyhání z u_{LR})

`hh.uS` ← ... analogicky jako u `hh.uW` ... horní hr. -II-

Pro každý test uveděte racionální rávér o H_0 :

Protože ... málí σ / méná σ do IS = ..., H_0 ... má hl. významnosti $\alpha = 0.05$.

Testování p-hodnotou

`p.Fw` ← $2 \min(pchisq(Fw, n-1), 1-pchisq(Fw, n-1))$

`p.uW` ← $1 - pchisq(uW, 1)$

`p.uS` ← ...

`p.uLR` ← ...

Pro každý test uveděte racionální rávér o H_0 :

Protože p-hodnota = ... $</> \alpha$, H_0 ... má hl. významnosti ...

Interpretace výsledků testování: Uveděte antropologický rávér (interpretaci výsledků testování). Co pme se dorovnění
 σ s výsledky různých libkry žen?

`tab` ← `data.frame`($s2 = rep(s^2, 4)$, vektor výhledu $\hat{\sigma}^2 = s^2$)

`stat` = `c(Fwn, uW, uS, uLR)`; vektor test. statistik

`w.th` = `c(q1, NA, NA, NA)`; vektor horních hranic krit. oboru } dolní hranice } (-∞; hh) ∪ (dh; ∞)

`w.dh` = `c(q2, q1, q1, q)`; vektor dolních hranic krit. oboru }

`IS.dh` = `c(dh.Fw, ...)`; vektor dolních hranic IS

`IS.hh` = `c(hh.Fw, ...)`; vektor horních hranic IS

`p` = `c(p.Fw, ...)`; vektor p-hodnot

`row.names` = `c('Fw', ...)`; vektor název řádků tabulek

`round(tab, 4)` ... vypíše tabulku zdrobněnou na 4 des. místa

`plot(sigma.i^2, UW.i, xlim=c(0,40), ylim=c(0,30), ...)` ... křivka UW... ✓
`lines((sigma.i^2)[UW.i < q], UW.i[UW.i < q], ...)` ... barevně vyznačená oblast UW v IS. ✓
`abline(h=q, ...)` ... vodorovná říďka přesrovná referenční čísla v hodnotě kvantily $\chi^2_{\alpha}(1-d)$ -----
`mtext(bquote(sigma^2), ...)` ... popisek σ^2
`mtext(...)` ... popisek IS=(..., ...), analogicky napsat jako ≈ 5.8

`plot(sigma.i^2, US.i, ...)` ✓

`lines(...)` ... ✓

`abline(...)` -----

`mtext(...)` popisek σ^2

`mtext(...)` popisek IS=(..., ...)

`plot(...)` ... ✓

`lines(...)` ... ✓

`abline(...)` ... -----

`mtext(...)` ... popisek σ^2

`mtext(...)` ... popisek IS=(..., ...)

Test o σ když μ neznáme

Zde sladí si pouze určitom, že $H_0: \sigma = \sigma_0 = 4.430$ přivedeme na $H_0: \sigma^2 = \sigma_0^2 = 4.430^2$. Analogicky $H_1: \sigma \neq \sigma_0$ přivedeme na $H_1: \sigma^2 \neq \sigma_0^2$.

Test o směrodatné odchylce σ přivedeme tedy na test o rozptylu σ^2 a testujeme stejně jako je uvedeno výše. Závěry platící pro rozptyl σ^2 platí i pro sm. odchylku σ . Probíhá se tentokráte naměřujeme na H_0 sm. odchylce, upravíme akorát tabulkou nízledru:

```
tab2 <- data.frame (s = rep(s,4),
                      stat = ... , )
                      w.hh = ... , } barevné
                      w.dh = ... , } barevné
                      IS.dh = sqrt(c(dh.Fw, dh.uW, ...)), odhadnice z hranic IS pro  $\sigma^2$ 
                      IS.hh = sqrt(c(hh.Fw, hh.uW, ...)), odhadnice z hranic IS pro  $\sigma^2$ 
                      p= ... , } barevné
                      row.names = )
```

`round(tab2, 4)` ... napsí tabulku tab2 načleněnou na 4 des. místa.

Analogicky bydlem mohli vykreslit grafy Waldova, shore a výrohodnosního IS pro σ .

```
plot(sigma.i, UW.i, ...)
lines(sigma.i[UW.i < q], UW.i[UW.i < q], ...)
abline(...)
mtext(...)
mtext(...)
```

Vyširování tabulky tab2 a vykreslení grafu Waldova, shore a výrohodnosního 95% empirického IS mechanickám nicméně jako dobravolný ikol pro nájimec. Pokud mechanické tabulky a grafy vykresloval, uveděte pouze komendy:

H_0 (resp. H_1) o sm. odchylce přivedu na H_0 (resp. H_1) o rozptylu a testuji testem o rozptylu. =