

# **Testy o střední hodnotě při známém rozptylu**

Mgr. Zdeňka Geršlová

# **Teorie**

Prezentace [Statistical inference I and II](#), kapitola 7.

# Příklady

## Příklad 1

Vzájemné porovnání testovacích statistik  $U_W, U_S, U_{LR}$

Vzájemně porovnejte tvary křivek  $y = \frac{x}{1+x}$ ,  $y = \log(1 + x)$  a  $y = x$  a stanovte, která křivka dosahuje na intervalu  $(0, 5)$  (a) nejvyšších hodnot (b) nejnižších hodnot. Výsledek porovnání lze využít při porovnávání testovacích statistik.

Postup: Vytvoříme sekvenci bodů na zadaném intervalu, definujeme jednotlivé křivky a vykreslíme je do grafu pomocí funkce [lines](#).

## Výsledek




Figure 1: Porovnání křivek (globální a lokální pohled)

## Příklad 2

**Aktuální vs. nominální hladina významnosti  $\alpha$ , konzervativní vs. liberální test**

Nechť

- a.  $X \sim N(20, 100)$
- b.  $X \sim pN(20, 100) + (1 - p)N(28, 100)$ , kde  $p = 0.9$ , tedy jde o směs dvou normálních rozdělení  $X \sim N(20, 100)$  a  $X \sim N(28, 100)$  v poměru 9 : 1.

Pro obě části (a) i (b) vygenerujte  $M = 500$  náhodných výběrů s rozsahem  $n = 5$ , resp.  $n = 100$  a vypočítejte hodnotu testovací statistiky  $Z_W$  pro Waldův test nulové hypotézy  $H_0 : \mu = \mu_0 = 20$  oproti  $H_1 : \mu \neq 20$ , když  $\sigma^2$  známe ( $\sigma^2 = 10^2$ ) na hladině významnosti  $\alpha = 0.05$ . Hodnoty testovacích statistik  $Z_W$  zaneste do histogramu. Vždy spočítejte, kolik testovacích statistik  $Z_W$  spadá do kritického oboru  $W$ . Podíl tohoto čísla a  $M$  představuje aktuální hladinu významnosti  $\hat{\alpha}$ . Porovnejte ji s nominální hladinou významnosti  $\alpha$  a v každé ze čtyř situací určete, zda je test konzervativní či liberální.

*Pozn.: Test samozřejmě nemusí být ani konzervativní ani liberální, což je ten nejlepší případ.*

*Konzervativnost nebo liberálnost testu chápeme jako (negativní) vlastnost testu, kterou, je-li přítomná, musíme mít na zřeteli.*


## Postup

Pro univerzální použití vytvoříme funkci `HistWald`, která bude připravena pro libovolnou směs normálních rozdělení s volitelnými parametry jednotlivých rozdělení, počtu a rozsahu náh. výběrů.

```
HistWald <- function(mu0, n, M = 500,
                      mu1 = 20, mu2 = mu1,
                      sigma1 = 10, sigma2 = sigma1,
                      p = 0.9, alpha = 0.05, main) {
  X <- matrix(NA, M, n)
  for (i in 1:M) {
    bin <- rbinom(n, 1, p)
    X[i, ][bin == 1] <- rnorm(sum(bin), mu1, sigma1)
    X[i, ][bin == 0] <- rnorm(n - sum(bin), mu2, sigma2)
  } # generovani smesi rozdeleni
  m <- apply(X, 1, mean)
  zW <- ... # vzorec pro Zw statistiku
  d <- hist(zW, plot = F)$dens
  xfit <- seq(min(zW) - 10, max(zW) + 10, length = 512) # sekvence pro vykresleni Zw
  yfit <- ... # hustota N(0,1)
  alpha_aktual <- sum(abs(zW) > qnorm(1 - alpha / 2)) / M # aktualni hl. vyzn.
  d <- hist(zW, plot = F)$dens # vyska sloupca histogramu
  hist(..., ylim = c(0, max(yfit, d)), ...)
  mtext(expression(z[W]), side = 1, line = 2.2)
  mtext(bquote(paste(alpha == .(alpha), "; ", widehat(alpha) == .(alpha_aktual))), side = 1,
        line = 3.3)
  mtext(main, side = 1, line = 4.5)
  lines(...) # krivka hustoty
}
```

## Výsledek pro normální rozdělení


```
1 source("M8986-source.R")
2 set.seed(10)
3 par(mar = c(6, 4, 1, 1), mfrow = c(1,2))
4 HistWald(mu0 = 20, n = 5, main = expression(paste('X ~ N(20, 100); n = 5')))
5 HistWald(mu0 = 20, n = 100, main = expression(paste('X ~ N(20, 100); n = 100')))
```



Rozdělení Waldovy testovací statistiky pro test o střední hodnotě při známém rozptylu

## Směs normálních rozdělení

```
1 par(mar = c(6, 4, 1, 1), mfrow = c(1,2))
2 HistWald(mu0 = 20, mu2 = 28, n = 5,
3           main = expression(paste('X ~ 0.9 N(20, 100) + 0.1 N(28, 100); n = 5'))))
4
5 HistWald(mu0 = 20, n = 100, mu2 = 28,
6           main = expression(paste('X ~ 0.9 N(20, 100) + 0.1 N(28, 100); n = 100')))
```



Rozdělení Waldovy testovací statistiky pro test o střední hodnotě při známém rozptylu (směs rozdělení)

## Závěr

Při opakovaném spuštění MC studie vidíme, že v případě (a) aktuální hladina významnosti  $\hat{\alpha}$  nabývá rovnoměrně častokrát vyšší i nižší hodnoty než je nominální hladina významnosti  $\alpha$  (navíc rozdíly nejsou příliš velké). DIS pro  $\mu$ , když  $\sigma^2$  známe, není v tomto případě konzervativní ani liberální, stejně jako test založený na testovací statistice  $Z_W$ .

Oproti tomu v případě (b) je aktuální hladina významnosti  $\hat{\alpha}$  vyšší než nominální hladina významnosti  $\alpha$ , tj. aktuální pravděpodobnost pokrytí je nižší než nominální pravděpodobnost pokrytí a DIS pro  $\mu$ , když  $\sigma^2$  známe, je v tomto případě liberální, stejně jako test založený na testovací statistice  $Z_W$ . Efekt se více projeví pro vyšší rozsah náhodných výběrů.

### Příklad 3

#### Rozdělení testovací statistiky pro test o střední hodnotě se známým rozptylem

Nechť náhodný výběr  $X$  pochází z normálního rozdělení, t.j.  $X \sim N(\mu, \sigma^2)$ . Pomocí simulační studie porovnejte rozdělení testovací statistiky  $Z_W$  pro test nulové hypotézy  $H_0: \mu = 150$  (alternativní hypotéza  $H_1: \mu \neq 150$ ), když rozptyl  $\sigma^2$  známe, s rozdělením testovací statistiky stanovené na základě náhodného výběru se střední hodnotou  $\mu$ . Parametry zvolte

- (a)  $\mu = 146, \sigma^2 = 10^2, n = 50$ ;
- (b)  $\mu = 155, \sigma^2 = 10^2, n = 50$ .

Nechť dále  $X$  pochází ze směsi dvou normálních rozdělení, t.j.  $X \sim [pN(\mu, 10^2) + (1 - p)N(\mu, 30^2)]$ , kde  $p = 0.9$  a

- (c)  $\mu = 146$ ;
- (d)  $\mu = 155$ .

Provedte simulační studii popsanou výše také pro tento náhodný výběr.


## Postup


1. Nasimulujte  $M$  pseudonáhodných výběrů,  $M = 1, \dots, 2\,000$  a pro každý vypočítejte realizaci testovací statistiky  $z_{W,\lambda}^{(m)} = \frac{\bar{x}_m - \mu_0}{\sigma} \sqrt{n}$  pro nulovou hypotézu  $H_0: \mu = 150$  oproti  $H_1: \mu \neq 150$ .
2. Vykreslete histogram testovacích statistik  $Z_W$  a superponujte jej jednak křivkou hustoty normálního rozdělení  $N(\lambda, 1)$  s parametrem necentrality  $\lambda$  ( $\lambda = \frac{\mu - \mu_0}{\sigma} \sqrt{n}$ , kde  $\mu$  je skutečná střední hodnota (relevantní za platnosti  $H_1$ )) a jednak křivkou hustoty standardizovaného normálního rozdělení  $N(0, 1)$ .  
Obě křivky nakonec vzájemně porovnejte.

*Pozn.: U směsi křivka hustoty necentrálního rozdělení nesuperponuje histogram statistik  $z_W$  dostatečně. Zamyslete se nad tím, proč.*

## Výsledné grafy

```
1 par(mar = c(6, 4, 1, 1), mfrow = c(2,2))
2 RozdeleniNecentr(mu = 146, main = 'X ~ N(146, 100)')
3 RozdeleniNecentr(mu = 155, main = 'X ~ N(155, 100)', pozice = 'topright')
4 RozdeleniNecentr(mu = 146, sigma2 = 30, main = 'X ~ 0.9 N(146, 100) + 0.1 N(146, 900)')
5 RozdeleniNecentr(mu = 155, sigma2 = 30, main = 'X ~ 0.9 N(155, 100) + 0.1 N(155, 900)',
6                 pozice = 'topright')
```





V [source](#) vytvoříme funkci **RozdeleniNecentr**, která bude pro směs rozdělení vykreslovat histogramy superponované křivkami hustoty (normálního rozdělení s parametrem ncentrality a standardizovaného norm. rozdělení).

```
RozdeleniNecentr <- function(mu, mu0 = 150, sigma = 10,
                                sigma2 = sigma, M = 2000, n = 50,
                                p = 0.9, main = "", pozice = "topleft"){

X <- ... # matice nah. vyberu - analogicky predchozimu pr.
m <- apply(X, 1, mean)
zW <- ... # test. statistika z_w
lambda <- ... # parametr ncentrality

xfit <- ... # sekvence pro vykresleni hustoty
yfit <- ... # hustota norm. rozd.
zfit <- ... # hustota ncentralniho norm. rozd.

hist(...)
lines(...) # cervene N(0,1), modre ncentralni
legend(pozice, ...)
}
```

## Komentář

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  $\mu = 146$  (resp.  $\mu = 155$ ), v grafu znázorněno jako modrý histogram superponovaný modrou křivkou, proto parametr necentrality  $\lambda$  nabývá záporné (resp. kladné) hodnoty a histogram i s modrou křivkou necentrálního rozdělení se realizuje nalevo (resp. napravo) od červené křivky centrálního rozdělení. Modrá křivka superponuje histogram přesně, protože náhodný výběr pochází z předpokládaného rozdělení  $N(146, 10^2)$ .

V případě směsi rozdělení je situace podobná, ovšem modrá křivka nyní nesuperponuje histogram přesně, což má důvod právě v přítomnosti "příměsi" v námi předpokládaném rozdělení.

## Příklad 4

### Silofunkce pro jednovýběrový Z-test o střední hodnotě

Předpokládejme, že  $X \sim N(\mu, \sigma^2)$ , kde  $\sigma^2$  známe. Nechť  $\theta = \mu$ . Na hladině významnosti  $\alpha = 0.05$  testujeme všechny tři typy hypotéz

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

Odvodte tvary silofunkcí pro všechny tři typy hypotéz (a)–(c), t.j. tvary  $\beta_{11}^*(\mu)$ ,  $\beta_{12}^*(\mu)$  a  $\beta_{13}^*(\mu)$  (viz Aplikovaná štatistická inferencia I - př. 155, str. 122 a dále)

Dále nakreslete silofunkce pro všechny tři typy hypotéz (a)–(c), kde  $\mu_0 = 150$ , a  $\sigma^2 = 10^2$ . Do jednoho obrázku zakreslete vždy tvary silofunkcí pro  $n = 10$ ,  $n = 20$ ,  $n = 50$  a  $n = 100$ . Hodnoty  $\mu$  volte rozumně, např. v intervalu (132; 168).

## Postup

Vytvoříme funkci [SilaExakt](#) pro výpočet exaktní silofunkce


```
SilaExakt <- function(mu0 = 0, mu, sigma = 1,
                      n, alpha = 0.05, alternative = "two.sided") {
  if (alternative == "two.sided") {
    sila <- pnorm(qnorm(alpha / 2) - (mu - mu0) / sigma * sqrt(n)) +
      pnorm(qnorm(alpha / 2) + (mu - mu0) / sigma * sqrt(n))
  }
  if (alternative == "greater") { ... # pravostranna alternativa
  }
  if (alternative == "less") { ... # levostranna alternativa
  }
  return(sila)
}
```

A dále funkci [PlotSila](#), která bude pracovat s výstupem této funkce a vykreslí silofunkce pro zadaná  $n$ .

```
PlotSila <- function(mu0 = 150, mu, sigma = 10,
                      n, alpha = 0.05, alternative = "two.sided") {
  barva <- ... # zde muzeme definovat posloupnost barev
  plot(mu, SilaExakt(...), type = "n", ylim = c(0, 1), ...)

  for (i in 1:length(n)) {
    sila <- SilaExakt(..., n = n[i],...)
    lines(mu, sila, col = barva[i])
  }
  legend(..., col = barva, legend = paste("n =", n), ... ) # legenda
  abline(...) # pridani linie v alpha
}
mu <- seq(..., length = 512) # sekvence pro mu
n <- c(...) # vektor n
```

## Výsledek



Silofunkce testu o střední hodnotě se známým rozptylem (oboustranná, pravostranná a levostranná alternativa)

## Komentář

Hladina významnosti  $\alpha$  (z definice) udává riziko chyby, že  $H_0$  nesprávně zamítáme, přestože platí. Ve všech třech případech (a), (b) i (c) se tedy pro  $\mu = \mu_0 = 150$  hodnota síly rovná přímo hodnotě hladiny významnosti  $\alpha = 0.05$ .

- (a) Z grafu pozorujeme, jak s rostoucí vzdáleností  $\mu$  od  $\mu_0 = 150$  roste pravděpodobnost, že  $H_0$  zamítáme (tj. roste síla testu). Platí tedy, že síla testu klesá s hodnotou  $\mu \rightarrow \mu_0 = 150$  z obou stran.
- (b) U pravostranné alternativy síla testu klesá s  $\mu \rightarrow \mu_0 = 150$  zprava.
- (c) U levostranné alternativy síla testu klesá s hodnotou  $\mu \rightarrow \mu_0 = 150$  zleva.

## Příklad 5

### Porovnání exaktní a approximativické silofunkce


Uveďte tvary přesné silofunkce  $\beta_{11}^*$  a přibližné silofunkce  $\tilde{\beta}_{11}^*$  pro test  $H_{01} : \mu = \mu_0$  oproti  $H_{11} : \mu \neq \mu_0$  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 komentujte. Hodnotu  $n$  zvolte 100,  $\mu_0 = 150$  a  $\sigma^2 = 10^2$ . Rozsah osy  $x$  volte rozumně, pro globální pohled např.  $\langle 145; 155 \rangle$ , pro lokální zaměření rozdílů zvolte rozsah osy  $x$   $\langle 148; 152 \rangle$ .

*Pozn.: Aproximativickou sílu můžeme spočítat pouze pro oboustrannou alternativu, neboť její myšlenka spočívá ve společném vyjádření obou částí síly (dvou distribučních funkcí) prostřednictvím jedné distribuční funkce s absolutní hodnotou. U jednostranných alternativ je síla tvořena pouze jednou distribuční funkcí, proto zde myšlenka fungující u oboustranné alternativy postrádá smysl.*

Vytvoříme funkci pro výpočet approximativické síly [SilaAprox](#) a pro vykreslení použijeme [plot\(\)](#) a [lines\(\)](#)

```
SilaAprox <- function(...){  
    sila <- pnorm(qnorm(alpha / 2) + abs(mu0 - mu) / sigma * sqrt(n))  
}  
  
# nastavení pro lokalní pohled  
plot(..., xlim = c(148, 152), ylim = c(-0.1, 0.4), asp = F, las = 1)
```

## Výsledné grafy



Exaktní vs. approximatická silofunkce testu o střední hodnotě při známém rozptylu

## Závěr

Exaktní a empirická silofunkce jsou si tvarově velmi blízké všude s výjimkou intervalu cca (149.2; 150.8).

Exaktní sílu tedy můžeme approximovat v případě, že  $\mu$  je dostatečně vzdálená od  $\mu_0$ .

Důvod: Aproximatická síla je založena na zanedbání jedné ze dvou distribučních funkcí, které tvoří exaktní sílu. V okolí  $\mu = \mu_0 = 150$  je vzdálenost  $\mu$  od  $\mu_0$  malá a do výsledné hodnoty exaktní síly přispívají velkým dílem obě distribuční funkce. Pokud tedy jednu z těchto distribučních funkcí zanedbáváme, přicházíme v approximatické síle o její příspěvek (aproximatická síla je v okolí  $\mu = \mu_0$  výrazněji menší než exaktní síla).

## Příklad 6

### Minimální rozsah náhodného výběru

Předpokládejme, že  $X \sim N(\mu, \sigma^2)$ , kde  $\sigma^2 = 10^2$ . Nechť  $\theta = \mu$ . Testujeme všechny tři typy hypotéz:

$H_{01} : \mu = \mu_0$  oproti  $H_{11} : \mu \neq \mu_0$  (oboustranná),

$H_{02} : \mu \leq \mu_0$  oproti  $H_{12} : \mu > \mu_0$  (pravostranná),

$H_{03} : \mu \geq \mu_0$  oproti  $H_{13} : \mu < \mu_0$  (levostanná),

kde  $\mu_0 = 150$ . Vypočítejte minimální rozsah náhodného výběru pro test nulové hypotézy při  $\alpha = 0.05$  a

$1 - \beta = 0.8$ , pro

$\mu \in \{145, 145.5, \dots, 154.5, 155\}$  (ad (1));  $\mu \in \{150.25, 150.5, 150.75, \dots, 153.5, 153.75, 154\}$  (ad (2));

$\mu \in \{146, 146.25, 146.5, \dots, 149.5, 149.75\}$  (ad (3)).

- Závislost minimálního rozsahu náhodného výběru na hodnotě  $\mu$  zakreslete do grafu pomocí bodů (na osu  $x$  vyneste parametr  $\mu$ , na osu  $y$  minimální rozsah náhodného výběru).
- Sestavte tabulku minimálních rozsahů náhodného výběru pro test nulové hypotézy  $H_0 : \mu = \mu_0$ , kde  $\mu_0 = 150$  oproti alternativním hypotézám  $H_{11}$ ,  $H_{12}$  a  $H_{13}$  při předem stanovené síle  $\beta^* = 0.8$  a hladině významnosti  $\alpha = 0.05$ , předpokládáme-li, že výběrová střední hodnota  $\mu$  bude nabývat hodnot  $\mu \in \{145, 146, 147, 148, 149, 149.5, 150.5, 151, \$152, 153, 155\}$ .

## Postup v R

Sestavíme funkci **MinZTest**, která bude pro zadané parametry rozdělení a stanovenou sílu a hladinu významnosti počítat minimální rozsah pro jednotlivé alternativy (nezapomeňte výstup zaokrouhlit na nejbližší vyšší celé číslo).

```
MinZTest <- function(mu, mu0 = 150, sigma = 10,
                      alpha = 0.05, sila = 0.8, alternative = "two.sided") {
  if (alternative == "two.sided") {
    n <- (qnorm(sila) - qnorm(alpha / 2))^2 / abs(mu - mu0)^2 * sigma^2
  }
  ... # jednostranne alternativy
  return(ceiling(n)) # zaokrouhleni
}
```

Lze použít i funkci **power.z.test** z knihovny **asbio**.

```
library(asbio)
result <- power.z.test(sigma = 10, power = 0.8, alpha = 0.05,
                        test = "two.tail", effect = c(0.5, 1, 2))
ceiling(result$n)
```


```
[1] 3140 785 197
```

Potom sestavíme sekvenci  $\mu$  dle zadání pro příslušnou alternativu a vykreslíme bodový graf, kde na ose  $x$  jsou jednotlivé hodnoty  $\mu$  a na ose  $y$  příslušný minimální rozsah.

Pozn.: K vykreslení čárkované čáry v místě, kde nemá smysl uvažovat min. rozsah (případ jednostranné alternativy), lze použít funkci **segments**.

```
segments(145, 0, 150, 0, lty = 2, col = 'grey40')
```

## Grafy



Minimální rozsahy náh. výběru pro Z test o střední hodnotě při známém rozptylu

## Tabulka

```
```{r}
#| code-line-numbers: false
#| tbl-cap: Rozsahy náh. výběru pro jednotlivé alternativy Z testu pro zvolená $\mu$ 
#| options: knitr.kable.NA = '.'
library(knitr)
mu_vyber <- c(145:149, 149.5, 150.5, 151:155)
n11 <- MinZTest(mu_vyber, alternative = 'two.sided')
n12 <- MinZTest(mu_vyber, alternative = 'greater')
n13 <- MinZTest(mu_vyber, alternative = 'less')
n12 <- c(rep(NA, 6), n12[7:12])
n13 <- c(n13[1:6], rep(NA, 6))

tab <- data.frame(t(data.frame(mu = mu_vyber, n11 = n11, n12 = n12, n13 = n13)),
                   row.names = c('$\mu$', '$H_{11}: \mu = \mu_0$', 
                                 '$H_{12}: \mu > \mu_0$', '$H_{13}: \mu < \mu_0$'))
kable(tab, col.names = NULL)
```

```

Rozsahy náh. výběru pro jednotlivé alternativy Z testu pro zvolená  $\mu$

| $\mu$                  | 145 | 146 | 147 | 148 | 149 | 149.5  | 150.5  | 151 | 152 | 153 | 154 | 155 |
|------------------------|-----|-----|-----|-----|-----|--------|--------|-----|-----|-----|-----|-----|
| $H_{11} : \mu = \mu_0$ | 32  | 50  | 88  | 197 | 785 | 3140.0 | 3140.0 | 785 | 197 | 88  | 50  | 32  |
| $H_{12} : \mu > \mu_0$ | NA  | NA  | NA  | NA  | NA  | NA     | 2474.0 | 619 | 155 | 69  | 39  | 25  |
| $H_{13} : \mu < \mu_0$ | 25  | 39  | 69  | 155 | 619 | 2474.0 | NA     | NA  | NA  | NA  | NA  | NA  |

Pozn.: Pro oboustrannou alternativu jsou rozsahy náhodných výběrů (pro pevně zvolené  $\mu_0$  a  $\mu$ ) vyšší než pro jednostranné alternativy.

## Příklad 7

### Silofunkce testu o střední hodnotě $\mu$ když $\sigma^2$ známe

Předpokládejme, že  $X \sim N(\mu, \sigma^2)$ , kde  $\sigma^2 = 10^2$ ,  $n = 100$ . Nechť  $\theta = \mu$ . Na hladině významnosti  $\alpha = 0.05$  testujeme hypotézu  $H_{01} : \mu = \mu_0$  oproti  $H_{11} : \mu \neq \mu_0$  (oboustranná), kde  $\mu_0 = 150$ .

Vytvořte animaci zobrazující


- změnu polohy necentrálního rozdělení vzhledem k hodnotě centrálního rozdělení testovací statistiky testu o  $\mu$  když  $\sigma^2$  známe, spolu s barevně odlišenou oblastí kritického oboru a exaktní síly;
- změnu hodnoty exaktní silofunkce; při měnící se střední hodnotě náhodného výběru  $\mu = 140, 141, \dots, 146, 146.5, \dots, 153.5, 154, 155, \dots, 160$ .

Pozn: V prvním grafu budeme mít červené křivku hustoty centrálního rozdělení s vyznačeným kritickým oborem, modré křivky hustoty necentrálního rozdělení s parametrem necentrality lambda a vyznačenou exaktní silou testu (síla - pravděpodobnost - obsah pod křivkou vymezený kvantilem).

## Animace

```
```{r}
#| fig-show: animate
#| animation-hook: gifski
#| fig-cap: Průběh síly testu pro střední hodnotu při známém rozptylu,
#| obooustranná alternativa
#| code-line-numbers: false
mu <- c(140:145, seq(146, 153.5, by = 0.5), 154:160)
for (i in 1:length(mu)) {
  SilaAnimace(150, mu = mu[i], sigma = 10, n = 100,
              alternative = 'two.sided')
}
```

```



Průběh síly testu pro střední hodnotu při známém rozptylu, obooustranná alternativa

## Funkce SilaAnimace

Vytvoříme funkci [SilaAnimace](#), která bude zobrazovat oba grafy.

Nejprve vypočítáme parametr necentrality lambda, určíme dostatečně hustou posloupnost x, ve které vykreslujeme hustotu, a vypočítáme hustotu centrálního a necentrálního rozdělení.

```
SilaAnimace <- function(mu0, mu, sigma, n,
                           alpha = 0.05,
                           alternative = 'two.sided') {
  lambda <- (mu - mu0) / sigma * sqrt(n)
  x <- ... # posloupnost na intervalu (-10,10)
  y <- ... # hustota centralniho rozdeleni
  l <- ...(..., mean = lambda) # hustota necentralniho rozd.

  ## kod pro vykresleni grafu
}
```

## Vykreslení hustoty


Pro vykreslení hustoty použijeme nejprve `plot` s argumentem `type = 'n'` pro nastavení grafického okna a potom postupně vykreslíme křivky hustot pomocí `lines` a oblast kritického oboru pomocí funkce `polygon` (na vstupu je nejprve vektor x-ových souřadnic a potom y-ových souřadnic, níže je postup pro křivku hustoty centrálního rozdělení, necentrální zobrazíme analogicky, jen použijeme hustotu necentrálního rozdělení a zobrazíme modrou barvou).

```
par(mfrow = c(1, 2), mar = c(5, 4, 1, 1))
plot(..., type = 'n', las = 1)

q1 <- qnorm(alpha / 2)
q2 <- qnorm(1 - alpha / 2)

polygon(x = c(min(x), max(x[x <= q1]),
              max(x[x <= q1]), rev(x[x <= q1])),
        y = c(0, 0, y[x == max(x[x <= q1])]),
        rev(y[x %in% x[x <= q1]])),
        col = 'red', density = 40)
polygon(c(min(x[x >= q2]), max(x),
          rev(x[x >= q2]), min(x[x >= q2])),
        c(0, 0, rev(y[x %in% x[x >= q2]])),
        y[x == min(x[x >= q2])]),
        col = 'red', density = 40)
lines(x, y, col = 'red')
```

# Polygon



## Vykreslení síly

Ve druhém grafu vykreslíme křivku exaktní síly (pomocí funkce `SilaExakt`, kterou jsme vytvořili v předchozím příkladu) pro rozumnou sekvenci středních hodnot a přidáme vždy výrazný bod v místě aktuální hodnoty  $\mu$ . Vodorovnou čarou zvýrazníme hodnotu hladiny významnosti  $\alpha$ .

```
mu1 <- seq(mu0 - 20, mu0 + 20, length = 512)

sila_ex <- SilaExakt(mu0 = mu0, mu = mu1, sigma = sigma,
                      n = n, alternative = 'two.sided')
plot(mu1, sila_ex, ... )

sila_akt <- SilaExakt(mu0 = mu0, mu = mu, sigma = sigma,
                      n = n, alternative = 'two.sided')
points(...)
```

## Závěr

V hodnotě  $\mu = \mu_0 = 150$  necentrální rozdělení splývá s centrálním a silofunkce dosahuje svého minima, které je rovno hladině významnosti  $\alpha = 0.05$ .

Při vzdalování  $\mu$  od  $\mu_0$  se necentrální rozdělení vzdaluje od centrálního a hodnota silofunkce roste.