

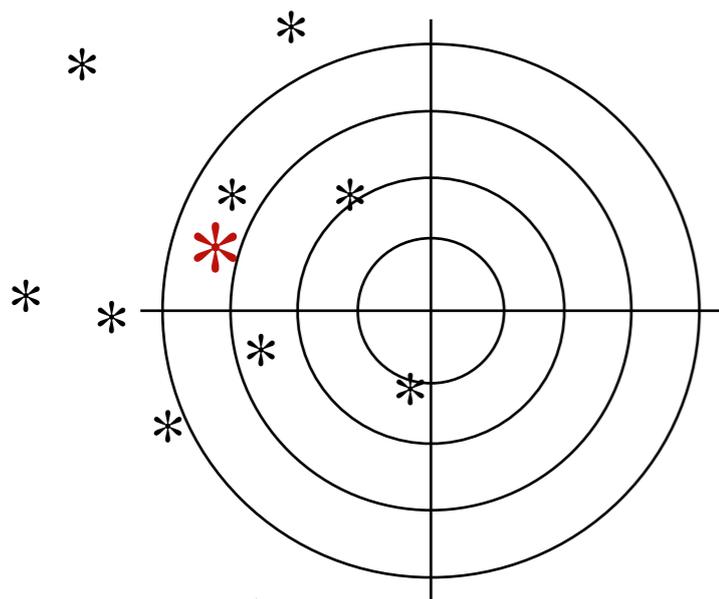
# Základy pravděpodobnosti a matematické statistiky

## 9. Odhady statistických charakteristik

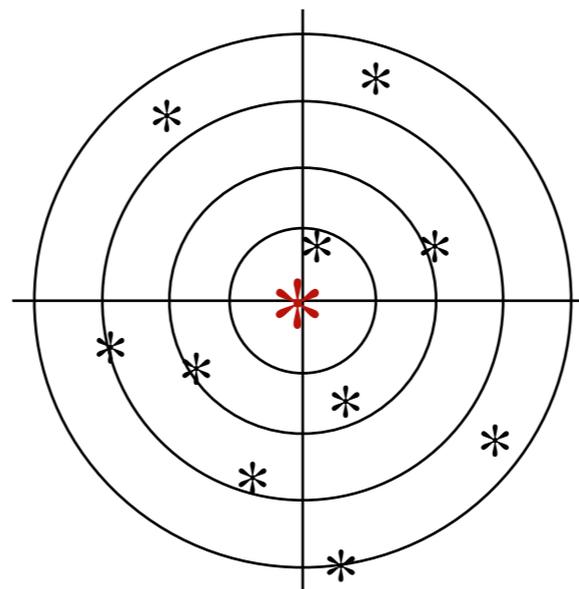


# 9. Odhady statistických charakteristik

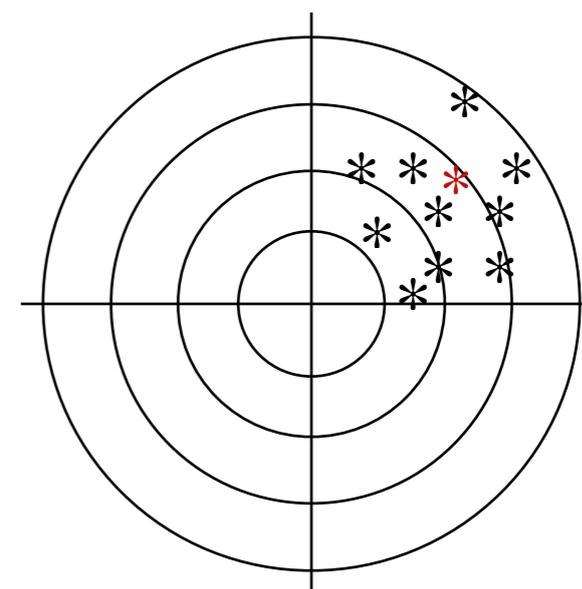
# Bodové odhady



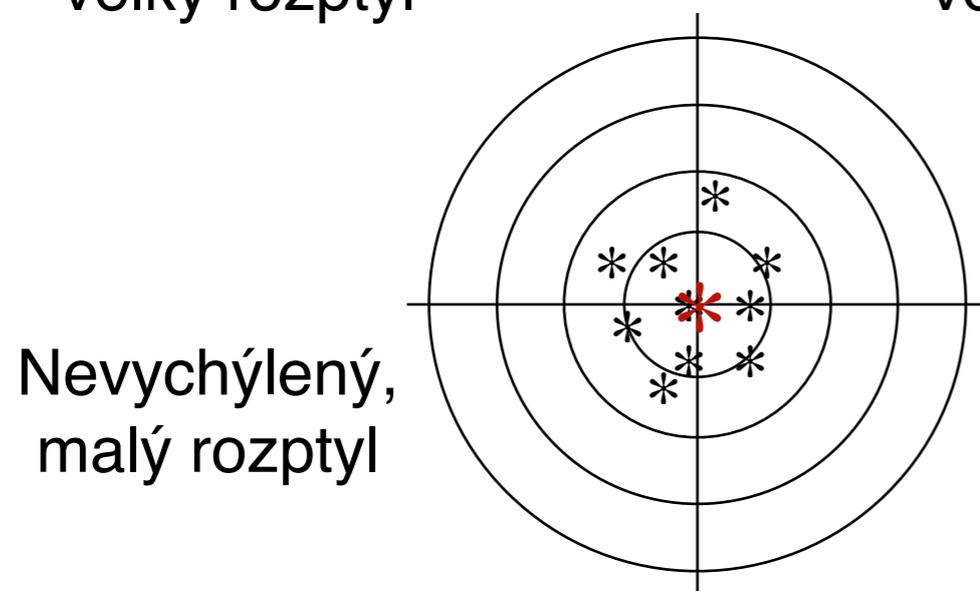
\* Vychýlený,  
velký rozptyl



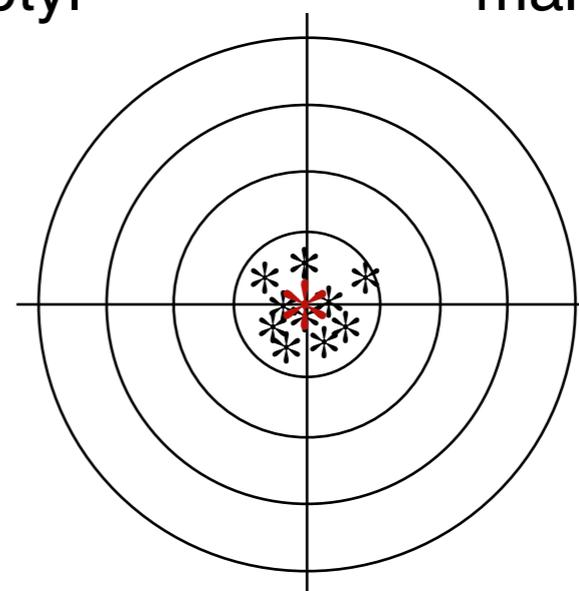
Nevychýlený,  
velký rozptyl



Vychýlený,  
malý rozptyl



Nevychýlený,  
malý rozptyl



Nejlepší  
neustranný

Jiří Likeš, Josef Machek: Matematická statistika, Kapitola II

[https://sms.nipax.cz/\\_media/teorie\\_pravdepodobnosti.pdf](https://sms.nipax.cz/_media/teorie_pravdepodobnosti.pdf)

<https://meloun.upce.cz/docs/lecture/chemometrics/slidy/32is.pdf>



## Bodové odhady

Statistické charakteristiky: jsou spočteny na základě pozorování  $x_1, x_2, \dots, x_n$   
i.i.d. výběru  $X_1, X_2, \dots, X_n$ .

Odhad střední hodnoty:  $\hat{\mu} = \bar{X}_n$  - je nevychýlený (nestranný, unbiased)

$$E(\bar{X}_n) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} E\left(\sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \sum_{i=1}^n \mu = \mu$$

$$\text{Var}(\bar{X}_n) = E(\bar{X}_n - \mu)^2 = E\left(\frac{\sum_{i=1}^n X_i - n\mu}{n}\right)^2 = \frac{1}{n^2} E\left(\sum_{i=1}^n (X_i - \mu)\right)^2 =$$

$$\frac{1}{n^2} \left( \sum_{i=1}^n E(X_i - \mu)^2 + 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n E(X_i - \mu)(X_j - \mu) \right) = \frac{\sum_{i=1}^n \text{Var}(X_i)}{n^2}$$

$$= \frac{\sigma^2}{n} \quad \text{- rozptyl konverguje k 0 pro } n \rightarrow \infty \quad \Rightarrow \quad \text{je konzistentní}$$



## Bodové odhady

Statistické charakteristiky: jsou spočteny na základě pozorování  $x_1, x_2, \dots, x_n$   
i.i.d. výběru  $X_1, X_2, \dots, X_n$ .

Odhad rozptylu:  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$  - je vychýlený (biased)

$$\begin{aligned} E(\hat{\sigma}) &= E\left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2\right) = \frac{1}{n} E\left(\sum_{i=1}^n (X_i - \bar{X}_n)^2\right) = \\ &= \frac{1}{n} \left(E\left(\sum_{i=1}^n X_i^2\right) - nE(\bar{X}_n^2)\right) = \frac{n(\sigma^2 + \mu^2) - \sigma^2 - n\mu^2}{n} = \sigma^2\left(1 - \frac{1}{n}\right) \end{aligned}$$

$$\sigma^2 = E(X_i^2) - (E(X_i))^2 = E(X_i^2) - \mu^2 \Rightarrow E(X_i^2) = \sigma^2 + \mu^2$$

$$\frac{1}{n}\sigma^2 = E(\bar{X}_n^2) - \mu^2 \Rightarrow E(\bar{X}_n^2) = \frac{\sigma^2}{n} + \mu^2$$



## Bodové odhady

Statistické charakteristiky: jsou spočteny na základě pozorování  $x_1, x_2, \dots, x_n$   
i.i.d. výběru  $X_1, X_2, \dots, X_n$ .

$$E(\hat{\sigma}^2) = \frac{n-1}{n} \sigma^2 \quad s^2 = \frac{n}{n-1} \hat{\sigma}^2 \quad \Rightarrow \quad E(s^2) = \sigma^2$$

Tedy výběrový rozptyl  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$  je nestranným odhadem rozptylu  $\sigma^2$

Jak je to s rozptylem těchto odhadů?

$$\text{Var}(s^2) = \text{Var}\left(\frac{n}{n-1} \hat{\sigma}^2\right) = \left(\frac{n}{n-1}\right)^2 \text{Var}(\hat{\sigma}^2) \geq \text{Var}(\hat{\sigma}^2)$$

Tedy:

rozptyl základního souboru  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2$  je vychýlený,  
ale má menší rozptyl

výběrový rozptyl  $s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$  je nevychýlený,  
ale má větší rozptyl



## Bodové odhady

Odhadujeme neznámý parametr  $\theta$ . Najdeme odhadovou statistiku  $\hat{\theta}(X_1, X_2, \dots, X_n)$  tak, aby splňovala některou (nejlépe všechny) z následujících vlastností:

- Nestrannost:  $E(\hat{\theta}(X_1, X_2, \dots, X_n)) = \theta$
- Vydatnost:  $\text{Var}(\hat{\theta}(X_1, X_2, \dots, X_n))$  je minimální
- Konzistence:  $\lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}(X_1, X_2, \dots, X_n)) = 0$

Jak se hledá odhadová statistika?

- Metoda maximální věrohodnosti (maximalizuje věrohodnostní funkci)
- Momentová metoda (srovnává teoretické a výběrové momenty)
- Metoda nejmenších čtverců (minimalizuje čtvercovou odchylku)



## Metoda maximální věrohodnosti (Maximum likelihood)

- pozorováním i.i.d. výběru  $X_1, X_2, \dots, X_n$  dostaneme pozorování  $x_1, x_2, \dots, x_n$
- uvažujme sdruženou hustotu náhodného vektoru  $(X_1, X_2, \dots, X_n)$ , která závisí na neznámém parametru  $f(x_1, x_2, \dots, x_n; \theta)$
- s touto funkcí budeme nadále zacházet jako s funkcí neznámé  $\theta$  a budeme ji nazývat věrohodnostní funkcí:  $l(\theta; x_1, x_2, \dots, x_n)$
- hledáme  $\hat{\theta} = \arg \max_{\theta} l(\theta; x_1, \dots, x_n)$  a nazveme je maximálně věrohodným odhadem parametru  $\theta$ .

Často namísto funkce  $l(\theta; x_1, x_2, \dots, x_n)$  maximalizujeme logaritmickou věrohodnostní funkci  $L(\theta; x_1, x_2, \dots, x_n) = \ln(l(\theta; x_1, x_2, \dots, x_n))$ .

Výsledkem je tzv. ML odhad (MLE)



# Metoda maximální věrohodnosti (Maximum likelihood)

**Příklad 1:** Odhad parametru Poissonova rozdělení  $p(k) = \frac{\lambda^k}{k!} e^{-\lambda}$

Máme pozorování  $k_1, k_2, \dots, k_n$  a vytvoříme věrohodnostní funkci

$$l(\lambda; k_1, \dots, k_n) = \prod_{i=1}^n \frac{\lambda^{k_i}}{k_i!} e^{-\lambda} = e^{-n\lambda} \lambda^{\sum_{i=1}^n k_i} \prod_{i=1}^n \frac{1}{k_i!}$$

Vytvoříme logaritmickou věrohodnostní funkci:

$$L(\lambda; k_1, \dots, k_n) = -n\lambda + \ln(\lambda) \sum_{i=1}^n k_i + \ln\left(\prod_{i=1}^n \frac{1}{k_i!}\right)$$

a hledáme maximum:

$$\frac{dL(\lambda; k_1, \dots, k_n)}{d\lambda} = -n + \frac{1}{\lambda} \sum_{i=1}^n k_i$$

$$-n + \frac{1}{\hat{\lambda}} \sum_{i=1}^n k_i = 0 \Rightarrow \hat{\lambda} = \frac{\sum_{i=1}^n k_i}{n} = \text{ML odhad } \lambda \quad (\text{MLE } \lambda)$$



## Momentová metoda

- pozorováním i.i.d. výběru  $X_1, X_2, \dots, X_n$  z nějakého rozdělení s d.f.  $F(x;\theta)$ , kde  $\theta = (\theta_1, \dots, \theta_k)$  je  $k$  neznámých parametrů
- Spočteme  $k$  teoretických momentů  $\mu_1, \dots, \mu_k$  a  $k$  výběrových momentů  $m_1, \dots, m_k$
- porovnáním těchto momentů dostaneme  $k$  rovnic, z nichž vyjádříme  $k$  odhadů neznámých parametrů.

**Příklad 2:** Odhad parametrů normálního rozdělení  $N(\mu, \sigma^2)$  momentovou metodou.

$$\mu_1 = E(X) = \mu, \quad m_1 = \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad \text{odtud:} \quad \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i$$
$$\mu_2 = E(X^2) = \sigma^2 + \mu^2 \quad m_2 = \frac{1}{n} \sum_{i=1}^n x_i^2 \quad \text{tedy:} \quad \hat{\sigma}^2 + \hat{\mu}^2 = \frac{1}{n} \sum_{i=1}^n x_i^2$$
$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \left( \frac{1}{n} \sum_{i=1}^n x_i \right)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$



## Intervalové odhady - Intervaly spolehlivosti

Intervalový odhad je interval  $(\hat{\Theta}_L(X), \hat{\Theta}_H(X))$  takový, že

$$P(\Theta \in (\hat{\Theta}_L(X), \hat{\Theta}_H(X))) = 1 - \alpha$$

$\alpha$  - hladina významnosti

$1-\alpha$  - koeficient spolehlivosti

**Příklad 3:** konstrukce intervalového odhadu střední hodnoty při výběru z normálního rozdělení.

$$\hat{\mu} = \bar{X}_n \quad \bar{X}_n \sim N(\mu, \sigma^2/n) \quad Z = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$$

Protože  $\mu$  ani  $\sigma^2$ , musíme použít t-rozdělení:

$$T = \frac{\bar{X} - \mu}{s} \sqrt{n} \sim t(n - 1)$$

$$\begin{aligned} P(\hat{\mu}_L \leq \mu \leq \hat{\mu}_H) &= P(-\hat{\mu}_L \geq -\mu \geq -\hat{\mu}_H) = P(\bar{X} - \hat{\mu}_L \geq \bar{X} - \mu \geq \bar{X} - \hat{\mu}_H) \\ &= P\left(\frac{\bar{X} - \hat{\mu}_L}{s} \sqrt{n} \geq \frac{\bar{X} - \mu}{s} \sqrt{n} \geq \frac{\bar{X} - \hat{\mu}_H}{s} \sqrt{n}\right) \\ &= P\left(\frac{\bar{X} - \hat{\mu}_L}{s} \sqrt{n} \geq T \geq \frac{\bar{X} - \hat{\mu}_H}{s} \sqrt{n}\right) = 1 - \alpha = P(t_{1-\alpha/2}(n-1) \geq T \geq t_{\alpha/2}(n-1)) \end{aligned}$$

odtud:  $\frac{\bar{X} - \hat{\mu}_L}{s} \sqrt{n} = t_{1-\alpha/2}(n-1)$   $\frac{\bar{X} - \hat{\mu}_H}{s} \sqrt{n} = t_{\alpha/2}(n-1)$



## Intervalové odhady - Intervaly spolehlivosti

**Příklad 3:** konstrukce intervalového odhadu střední hodnoty při výběru z normálního rozdělení.

$$\frac{\bar{X} - \hat{\mu}_L}{s} \sqrt{n} = t_{1-\alpha/2}(n-1)$$

$$\frac{\bar{X} - \hat{\mu}_H}{s} \sqrt{n} = t_{\alpha/2}(n-1)$$

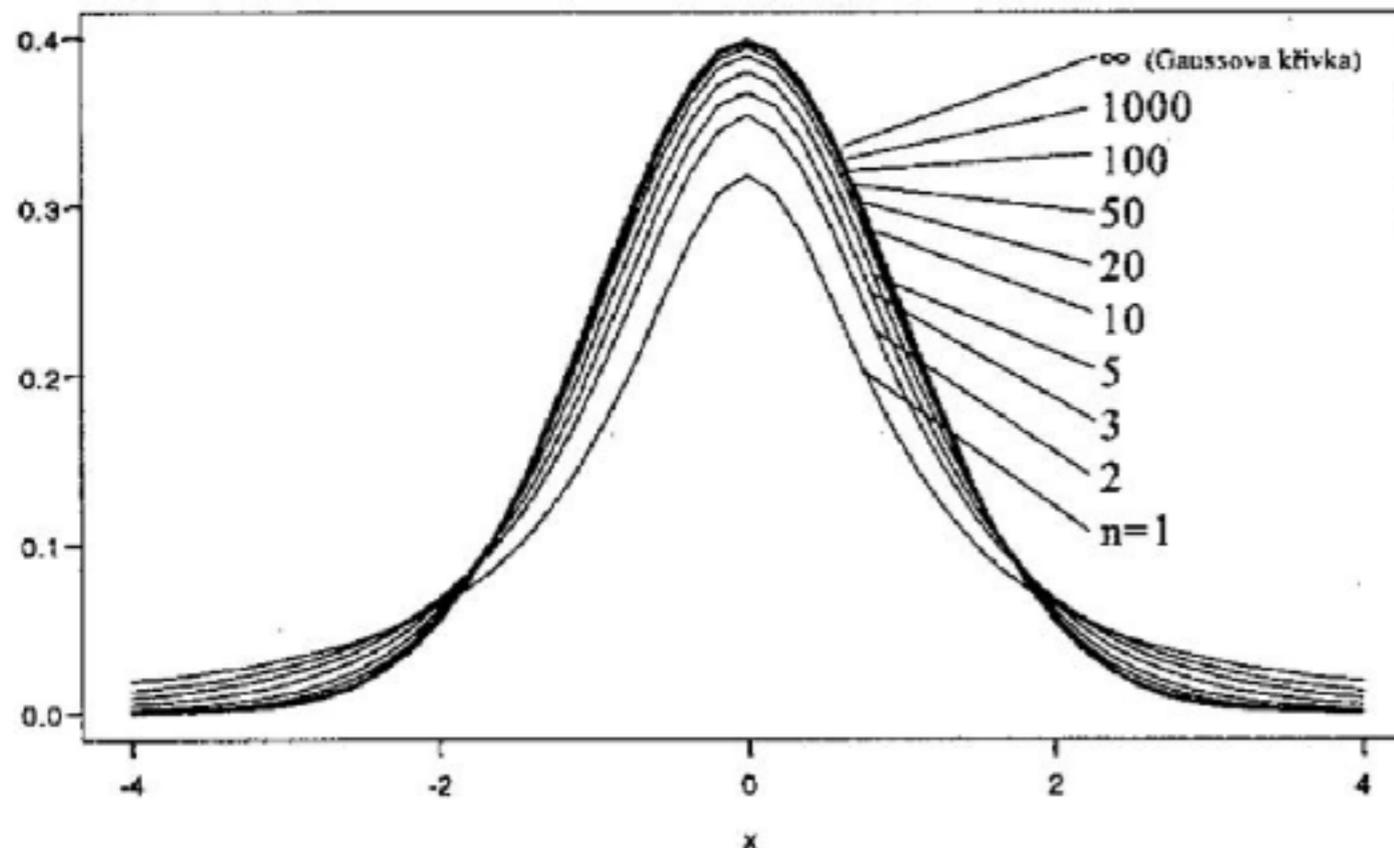
a tedy: 
$$\hat{\mu}_L = \bar{X} - \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1)$$

$$\hat{\mu}_H = \bar{X} - \frac{s}{\sqrt{n}} t_{\alpha/2}(n-1)$$

ze symetrie t-rozdělení víme, že  $t_{\alpha/2}(n-1) = -t_{1-\alpha/2}(n-1)$ , a tedy

$$\hat{\mu}_H = \bar{X} + \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1)$$

Hustota pravděpodobnosti Studentova rozdělení  $t(n)$



## Intervalové odhady - Intervaly spolehlivosti

**Příklad 3:** konstrukce intervalového odhadu střední hodnoty při výběru z normálního rozdělení.

$$\frac{\bar{X} - \hat{\mu}_L}{s} \sqrt{n} = t_{1-\alpha/2}(n-1) \qquad \frac{\bar{X} - \hat{\mu}_H}{s} \sqrt{n} = t_{\alpha/2}(n-1)$$

a tedy: 
$$\hat{\mu}_L = \bar{X} - \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1) \qquad \hat{\mu}_H = \bar{X} - \frac{s}{\sqrt{n}} t_{\alpha/2}(n-1)$$

ze symetrie t-rozdělení víme, že  $t_{\alpha/2}(n-1) = -t_{1-\alpha/2}(n-1)$ , a tedy

$$\hat{\mu}_H = \bar{X} + \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1)$$

Označíme-li  $\frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1) = SE$ , potom lze intervalový odhad psát ve tvaru

$$(\hat{\mu}_L, \hat{\mu}_U) = (\bar{X} - SE, \bar{X} + SE)$$

**SE = standardní  
chyba**

$$P(\bar{X} - SE \leq \mu \leq \bar{X} + SE) = 1 - \alpha$$

**Poznámka:** Pokud rozptyl  $\sigma^2$  známe, potom můžeme použít kvantily standardního normálního rozdělení a standardní chyba bude mít tvar  $SE = \frac{\sigma}{\sqrt{n}} u_{1-\alpha/2}$ .



## Intervalové odhady - Intervaly spolehlivosti

### Příklad 4: Test spotřeby automobilu

Deklarovaná průměrná spotřeba je 13,5 l/100 km

Otázka: **Odpovídá deklarovaná průměrná spotřeba naměřeným datům?**

$$\bar{X} = \frac{1}{14} \sum_{i=1}^{14} x_i = \frac{194,8}{14} = 13,914$$

$$s^2 = \frac{1}{13} \left[ \sum_{i=1}^{14} x_i^2 - 14 \cdot \bar{x}^2 \right] = \frac{4,017}{13} = 0,309$$

Zvolíme  $\alpha=0,05 \Rightarrow t_{0,975}(13) = 2,16036866$

$$SE = \sqrt{\frac{0,309}{14}} t_{0,95}(13) = 0,15216 = 0,32$$

**Tedy intervalový odhad je (13,59; 14,23).**

Protože  $13,5 \notin (13,59; 14,23)$ , můžeme tvrdit, že naměřená spotřeba se od deklarované *statisticky významně liší*. ???

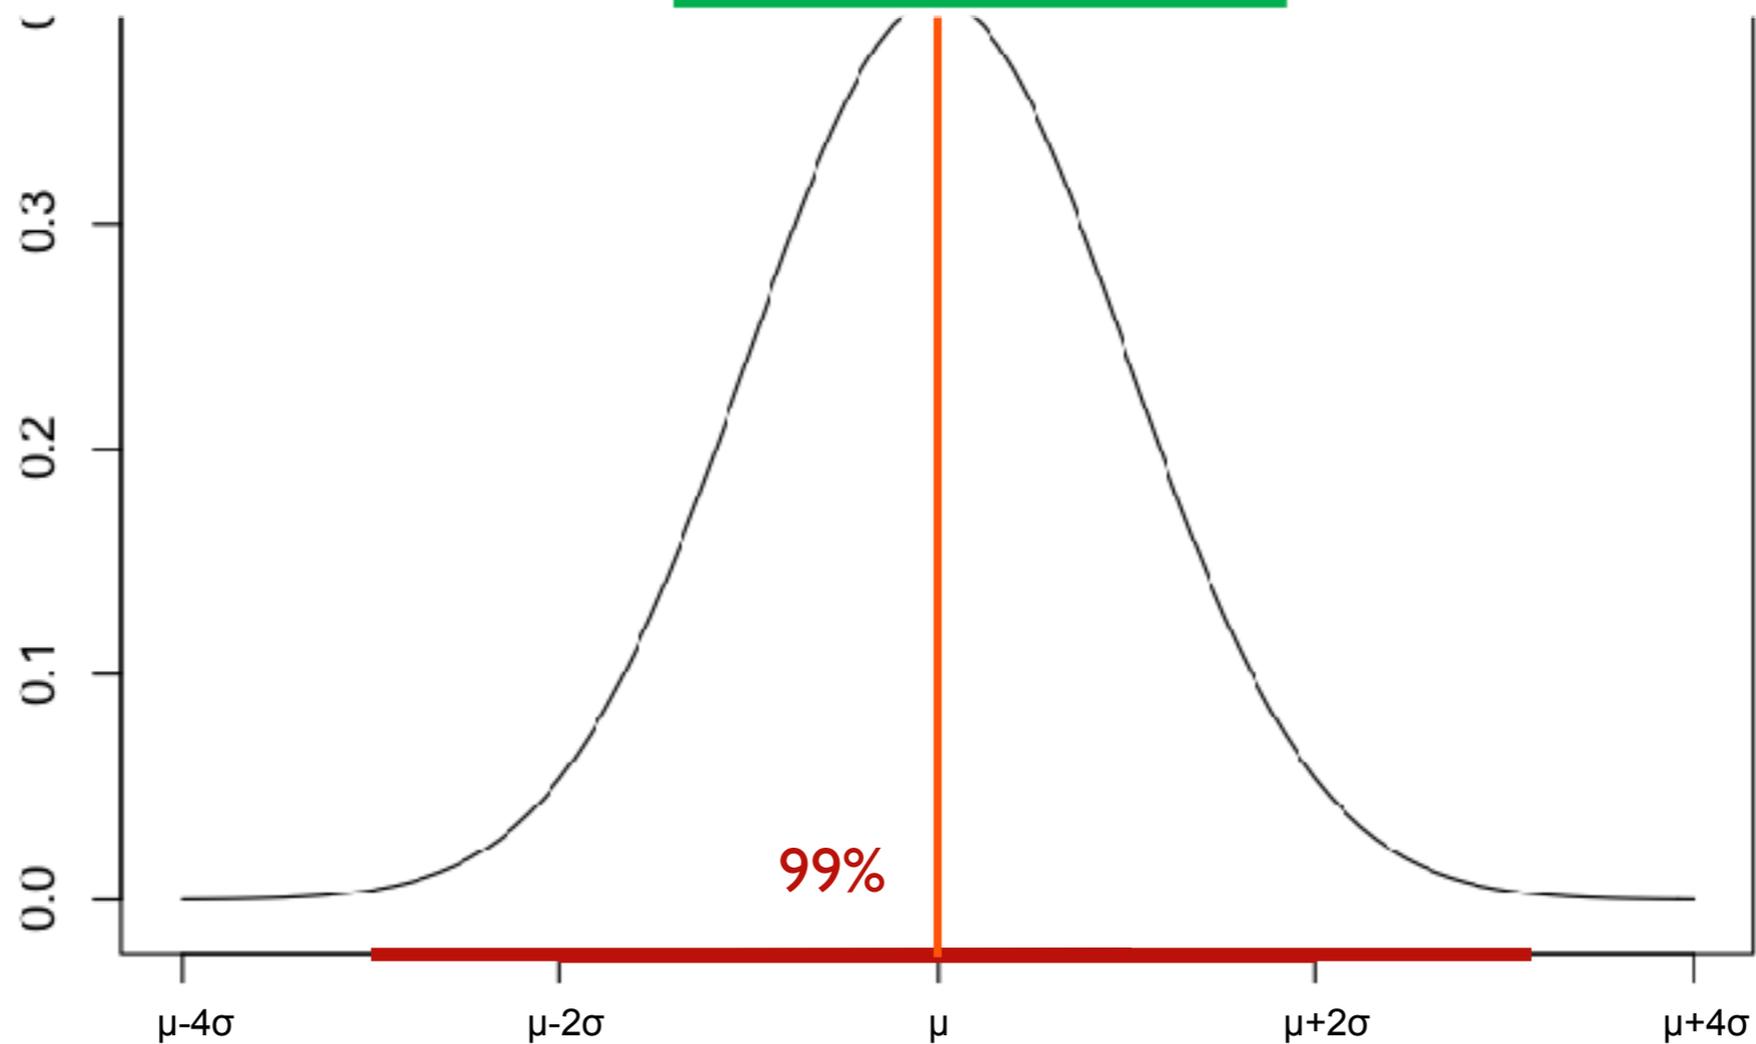
$n$	spotřeba (l/100)
1	12,8
2	13,5
3	14,2
4	13,6
5	14,1
6	14,5
7	13,6
8	13,9
9	14,3
10	15,1
11	13,7
12	13,4
13	13,9
14	14,2

$$T.INV(0,975;13) = 2,16036866$$



# Intervalové odhady - Intervaly spolehlivosti

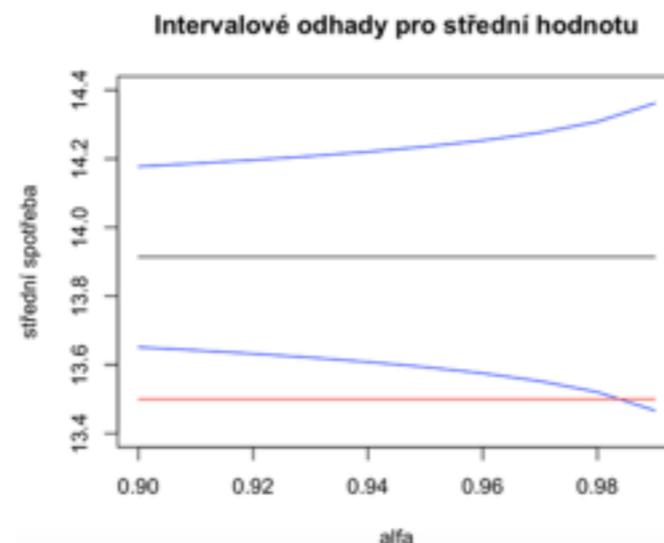
Proměnná	Průměr	Sm.odch.	N	Sm.chyba	Int. spolehl. -90,000%	Int. spolehl. +90,000%	Referenční konstanta	t	SV	p
spotřeba l/100	13,91429	0,555888	14	0,148567	13,65118	14,17739	12,50000	9,519502	13	0,000000
Proměnná	Průměr	Sm.odch.	N	Sm.chyba	Int. spolehl. -95,000%	Int. spolehl. +95,000%	Referenční konstanta	t	SV	p
spotřeba l/100	13,91429	0,555888	14	0,148567	13,59333	14,23525	12,50000	9,519502	13	0,000000
Proměnná	Průměr	Sm.odch.	N	Sm.chyba	Int. spolehl. -99,000%	Int. spolehl. +99,000%	Referenční konstanta	t	SV	p
spotřeba l/100	13,91429	0,555888	14	0,148567	13,46676	14,36181	12,50000	9,519502	13	0,000000



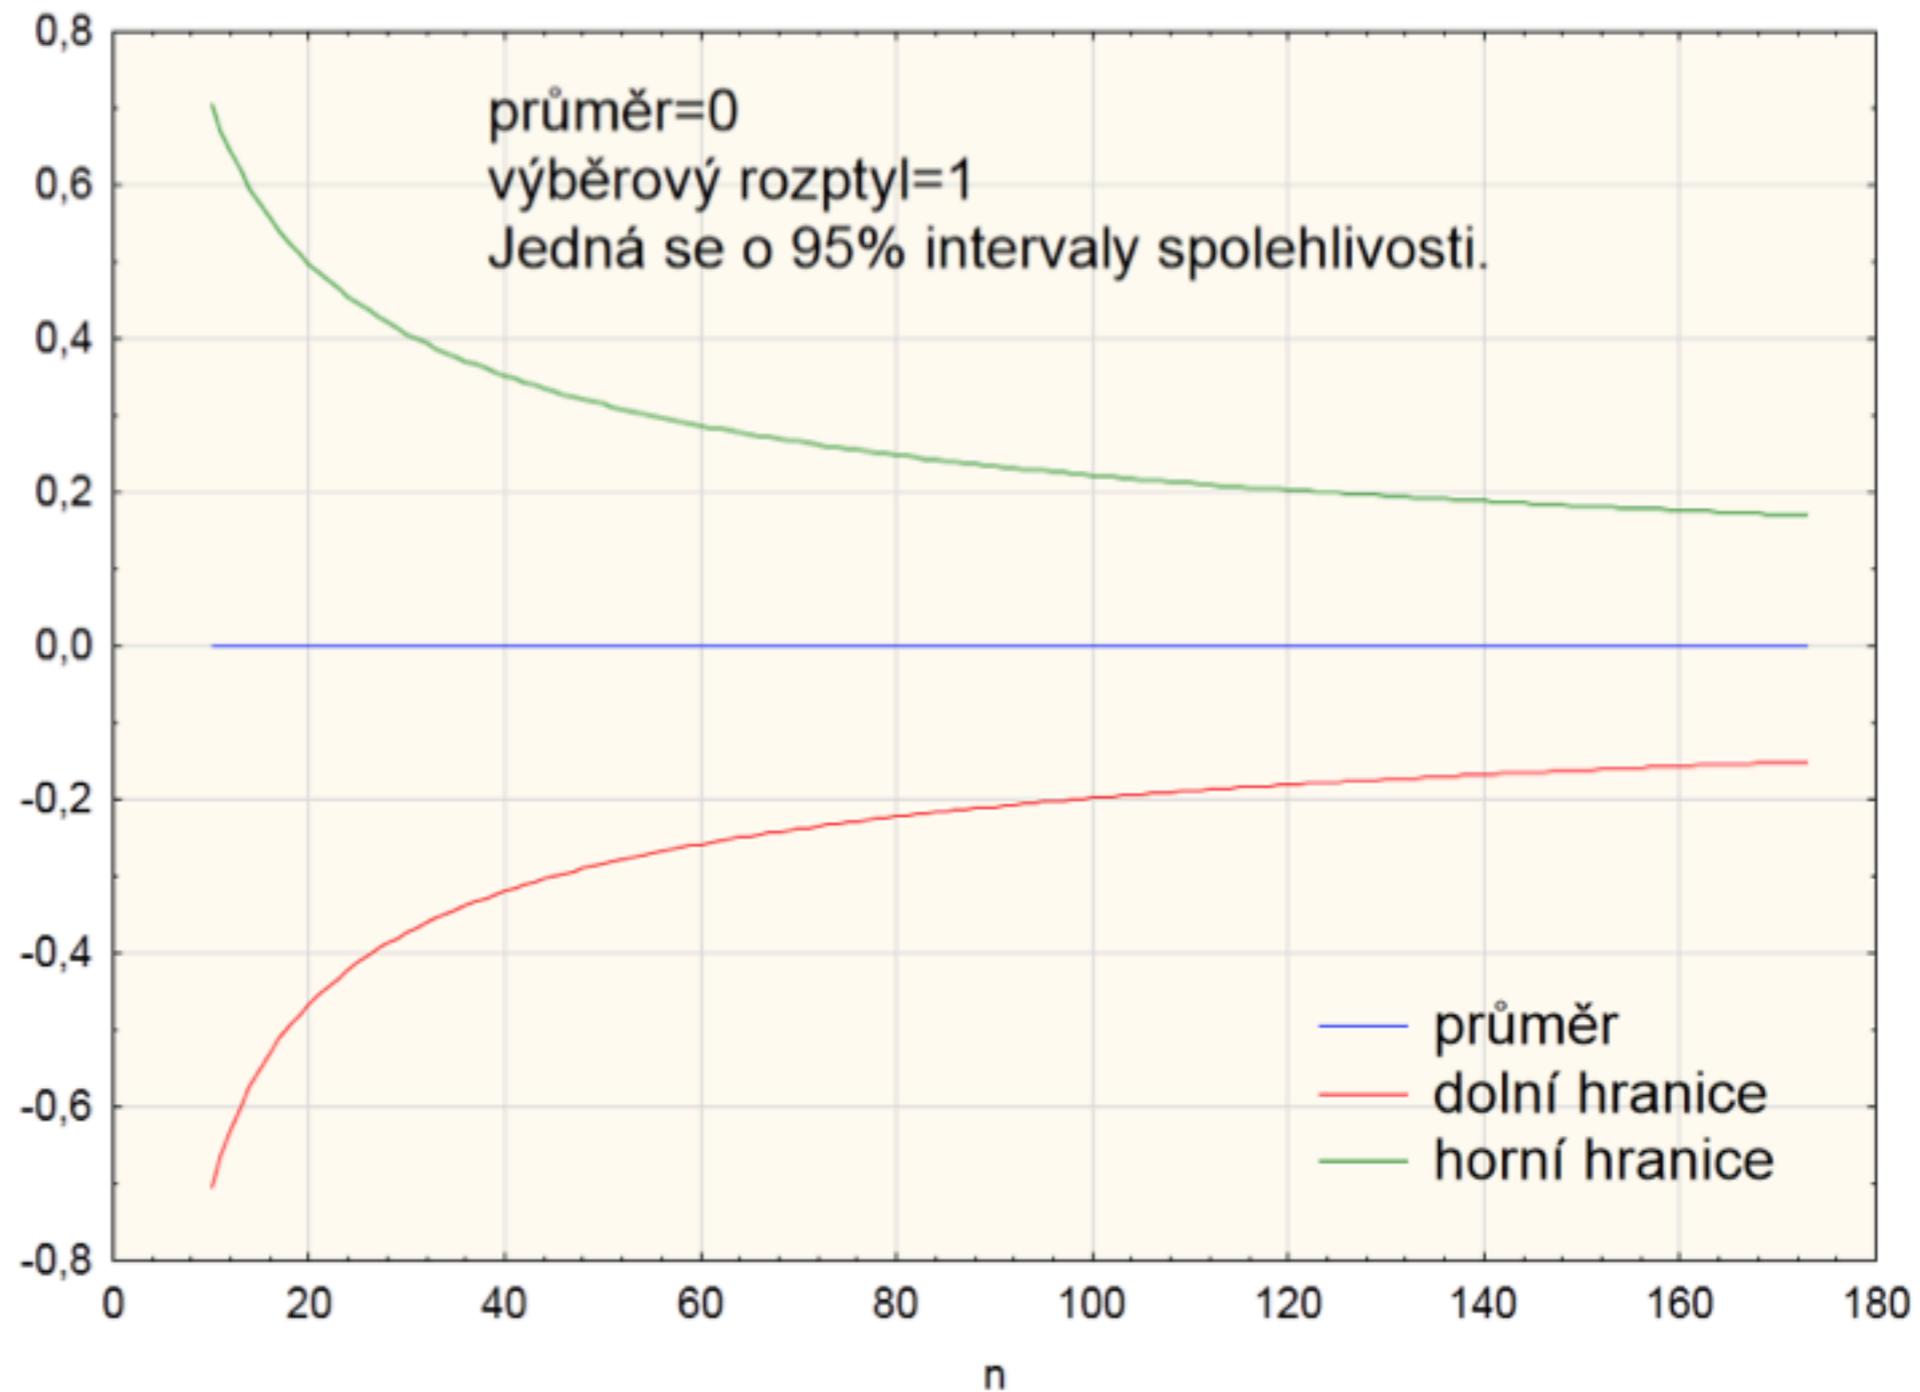
# Intervalové odhady - Intervaly spolehlivosti



```
spotreba <- data.matrix(read.table(„spotreba.txt“)) #načteme data
for (i in 1:10) a[i]=1-i/100 #hladina významnosti  $\alpha$ 
clm=matrix(0, nrow=10, ncol=2) # sem uložíme meze int. spolehlivosti
for(i in 1:10) {
  a[i]=1-i/100 #měníme hladinu významnosti od 0,99 do 0,9
  t=t.test(spotreba, conf.level=a[i]) #funkce t.test spočte intervalové odhady,
  clm[i,]=c(t$conf.int) #které ukládáme do matice clm
}
plot(a,clm[,1], ylim=c(13.4, 14.4), type="l", # vykreslíme graf s dolní mezí
      main="Intervalové odhady pro střední hodnotu",
      xlab="alfa", ylab="střední spotřeba", col="blue")
lines(a,clm[,2], col=„blue“) # doplníme horní mez
for (i in 1:10) d[i]=13.5 # deklarovaná spotřeba, kterou
lines(a,d, col=„red“) # zde vykreslíme jako červenou linku
for (i in 1:10) m[i]=mean(spotreba) # průměrnou naměřenou spotřebu
lines(a,m) # zde vykreslíme jako černou linku
```

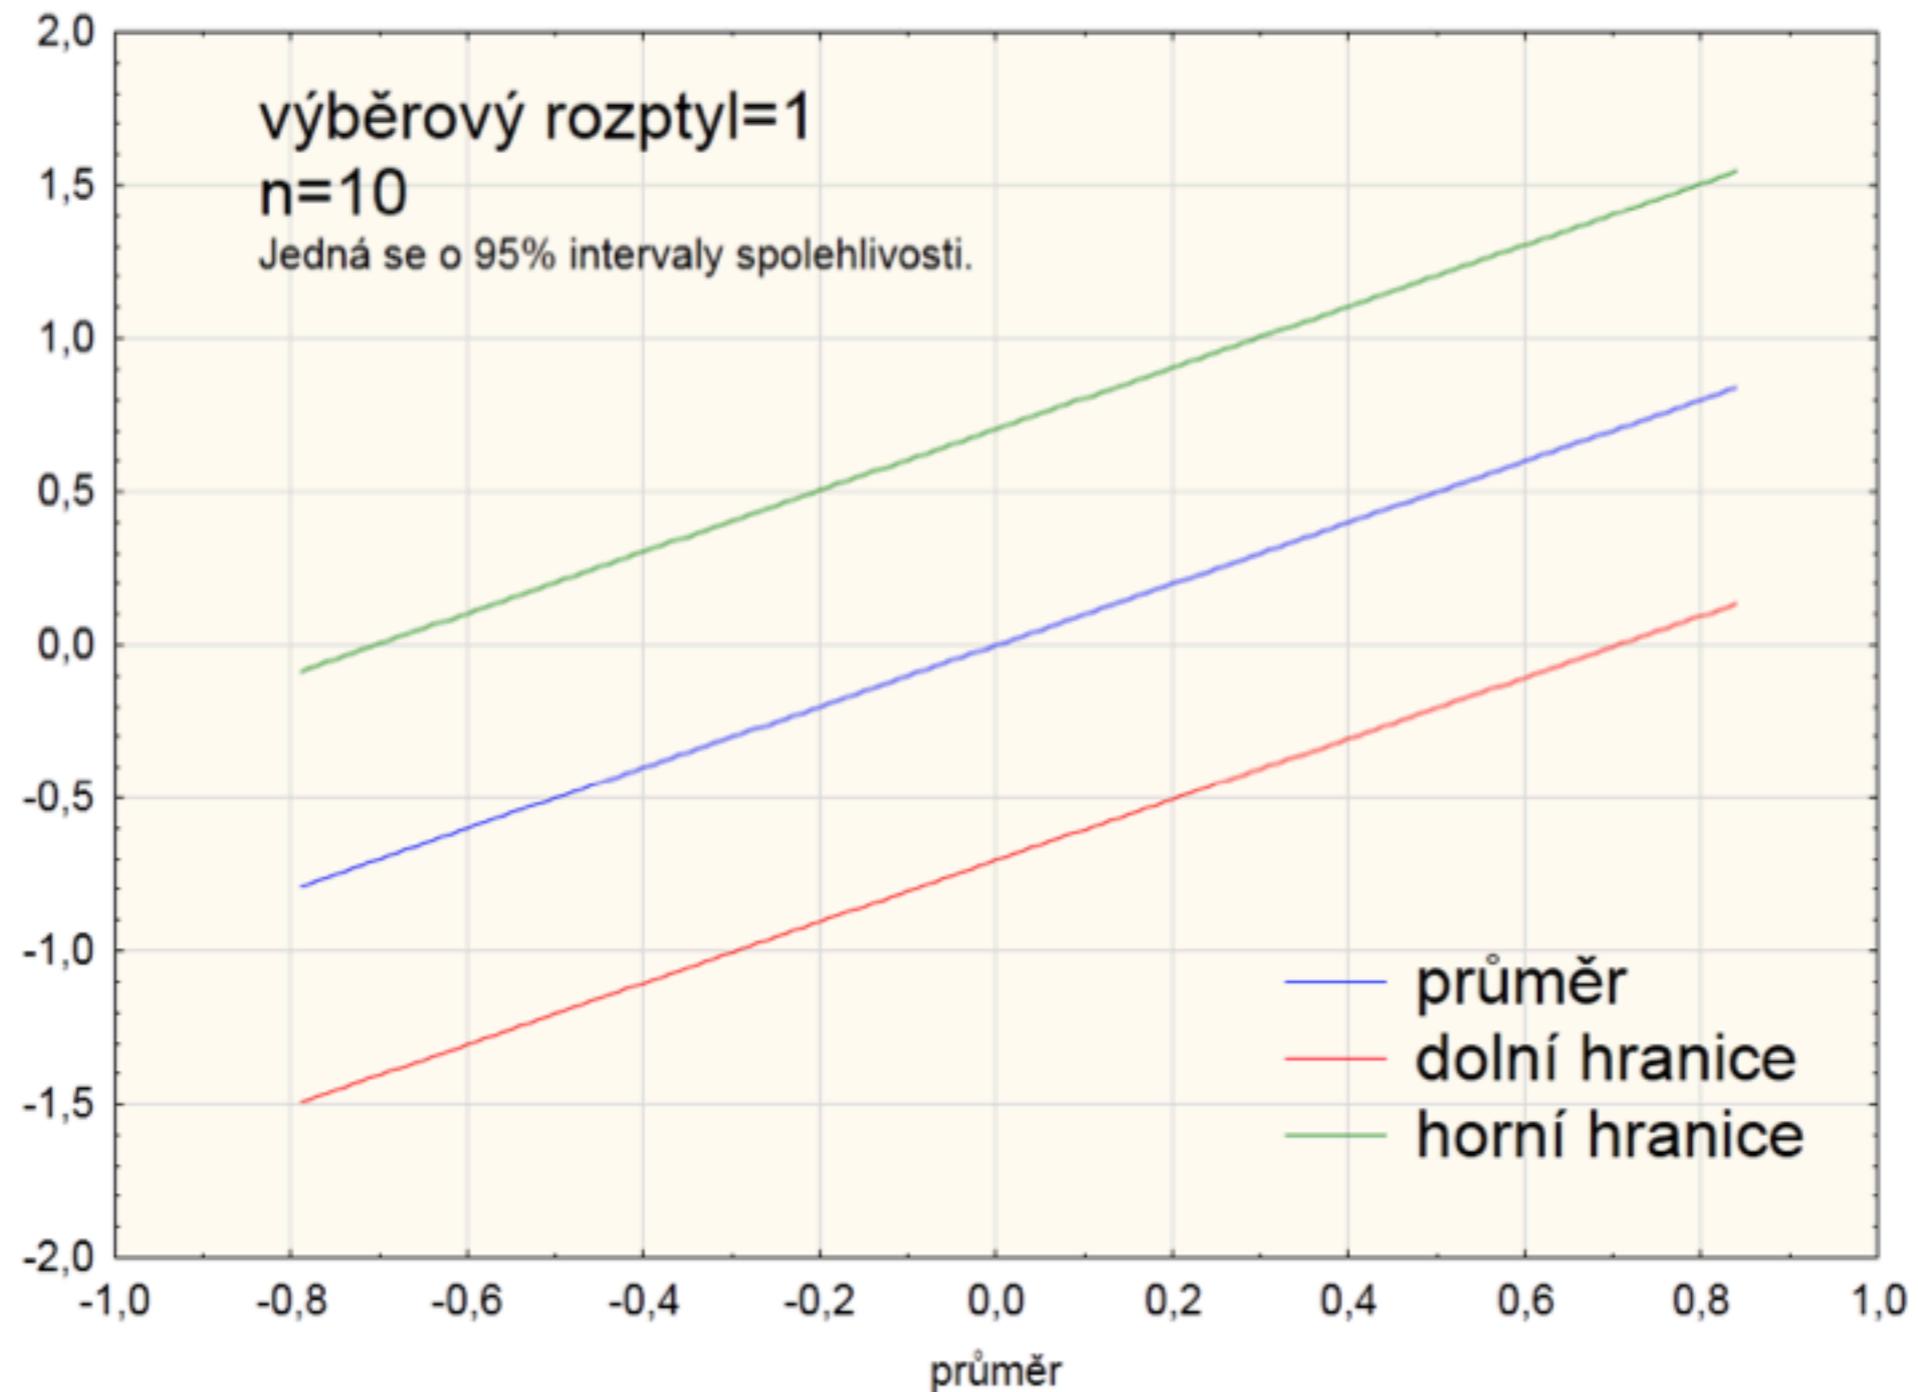


# Intervalové odhady - Intervaly spolehlivosti



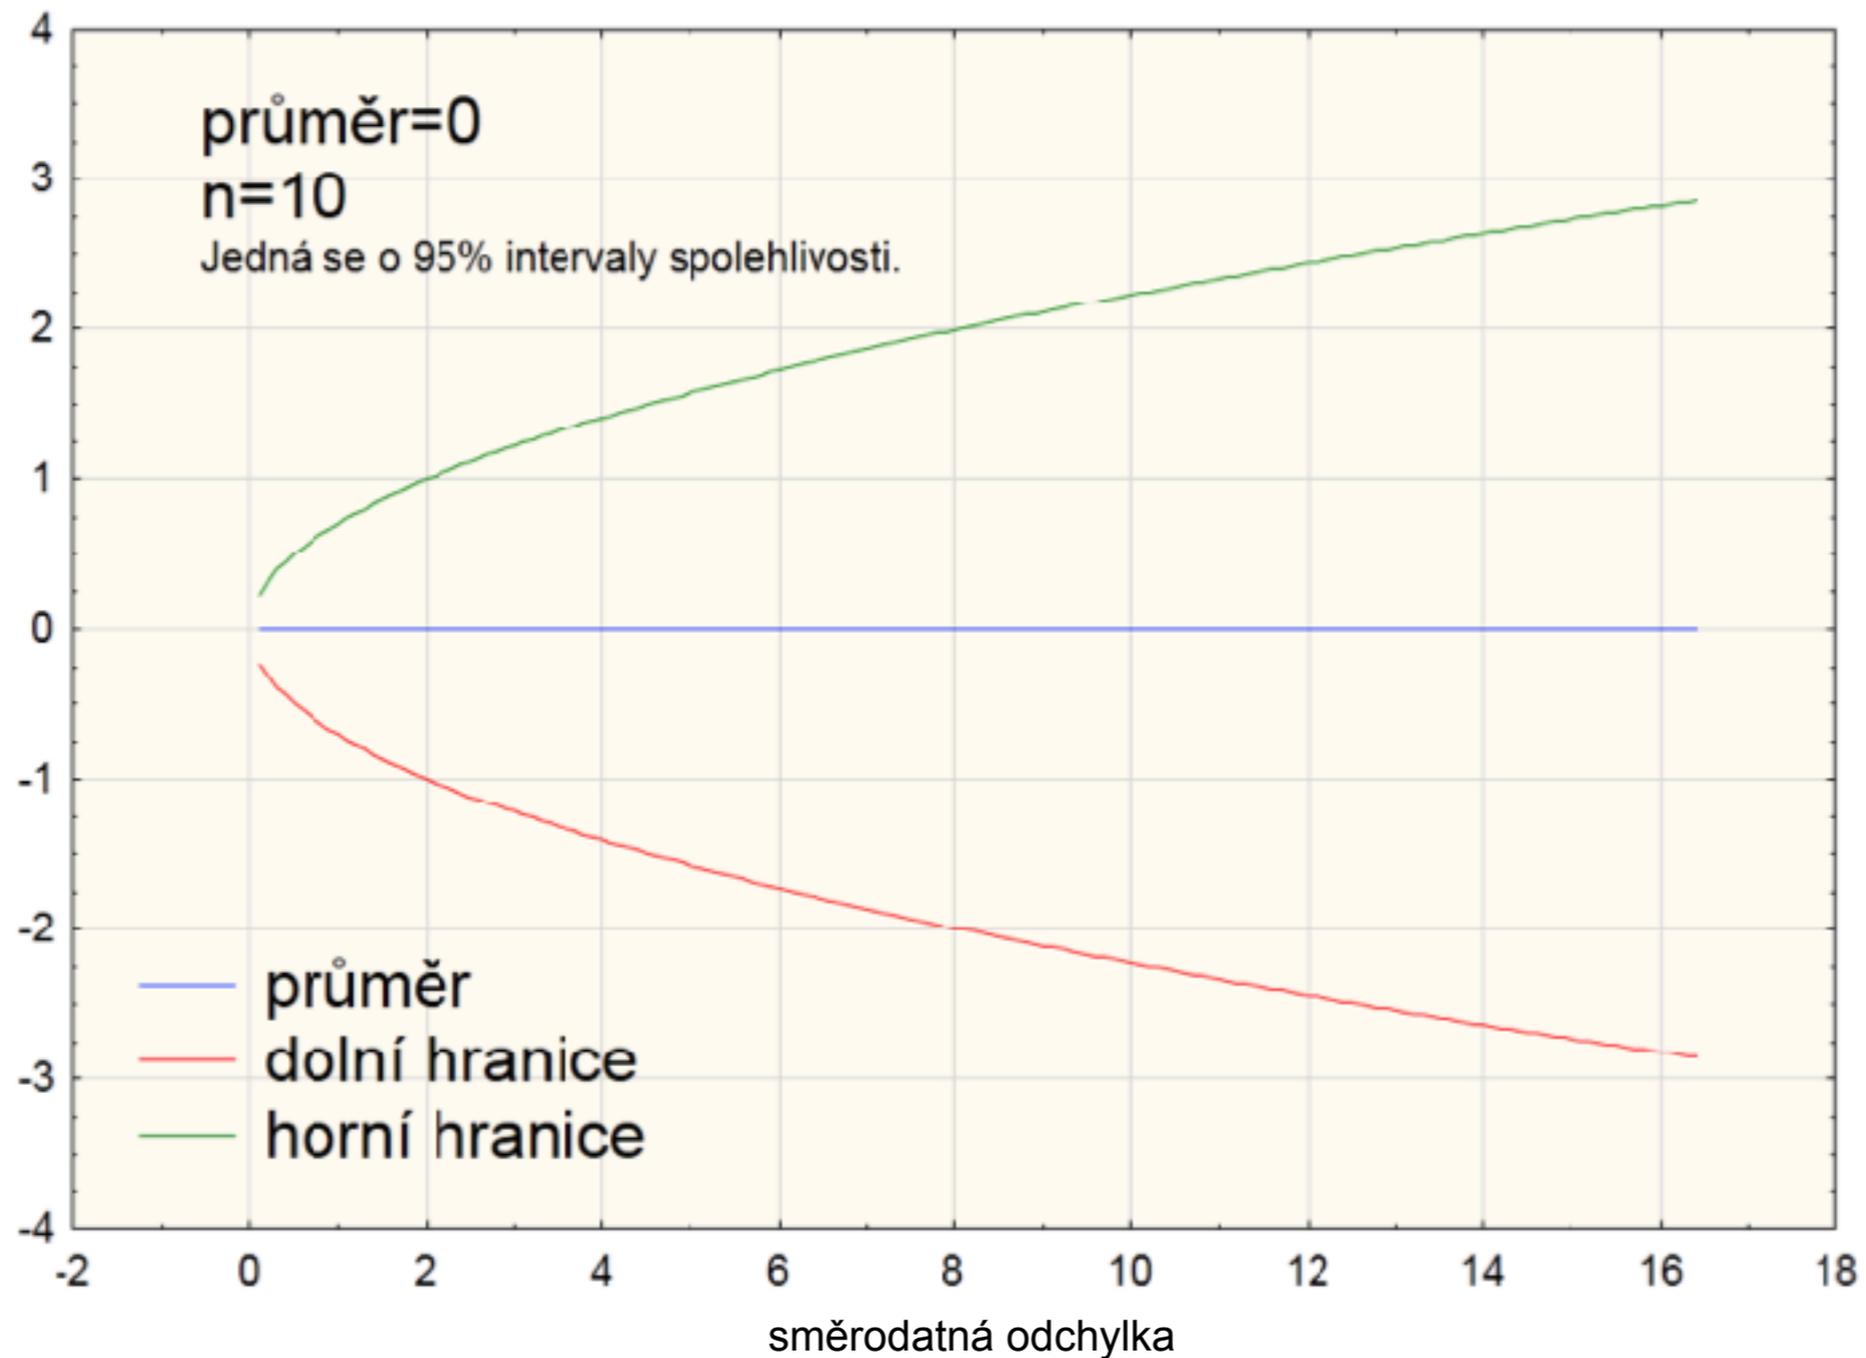
## Intervalové odhady - Intervaly spolehlivosti

Vliv změny odhadovaného parametru na šířku intervalu spolehlivosti



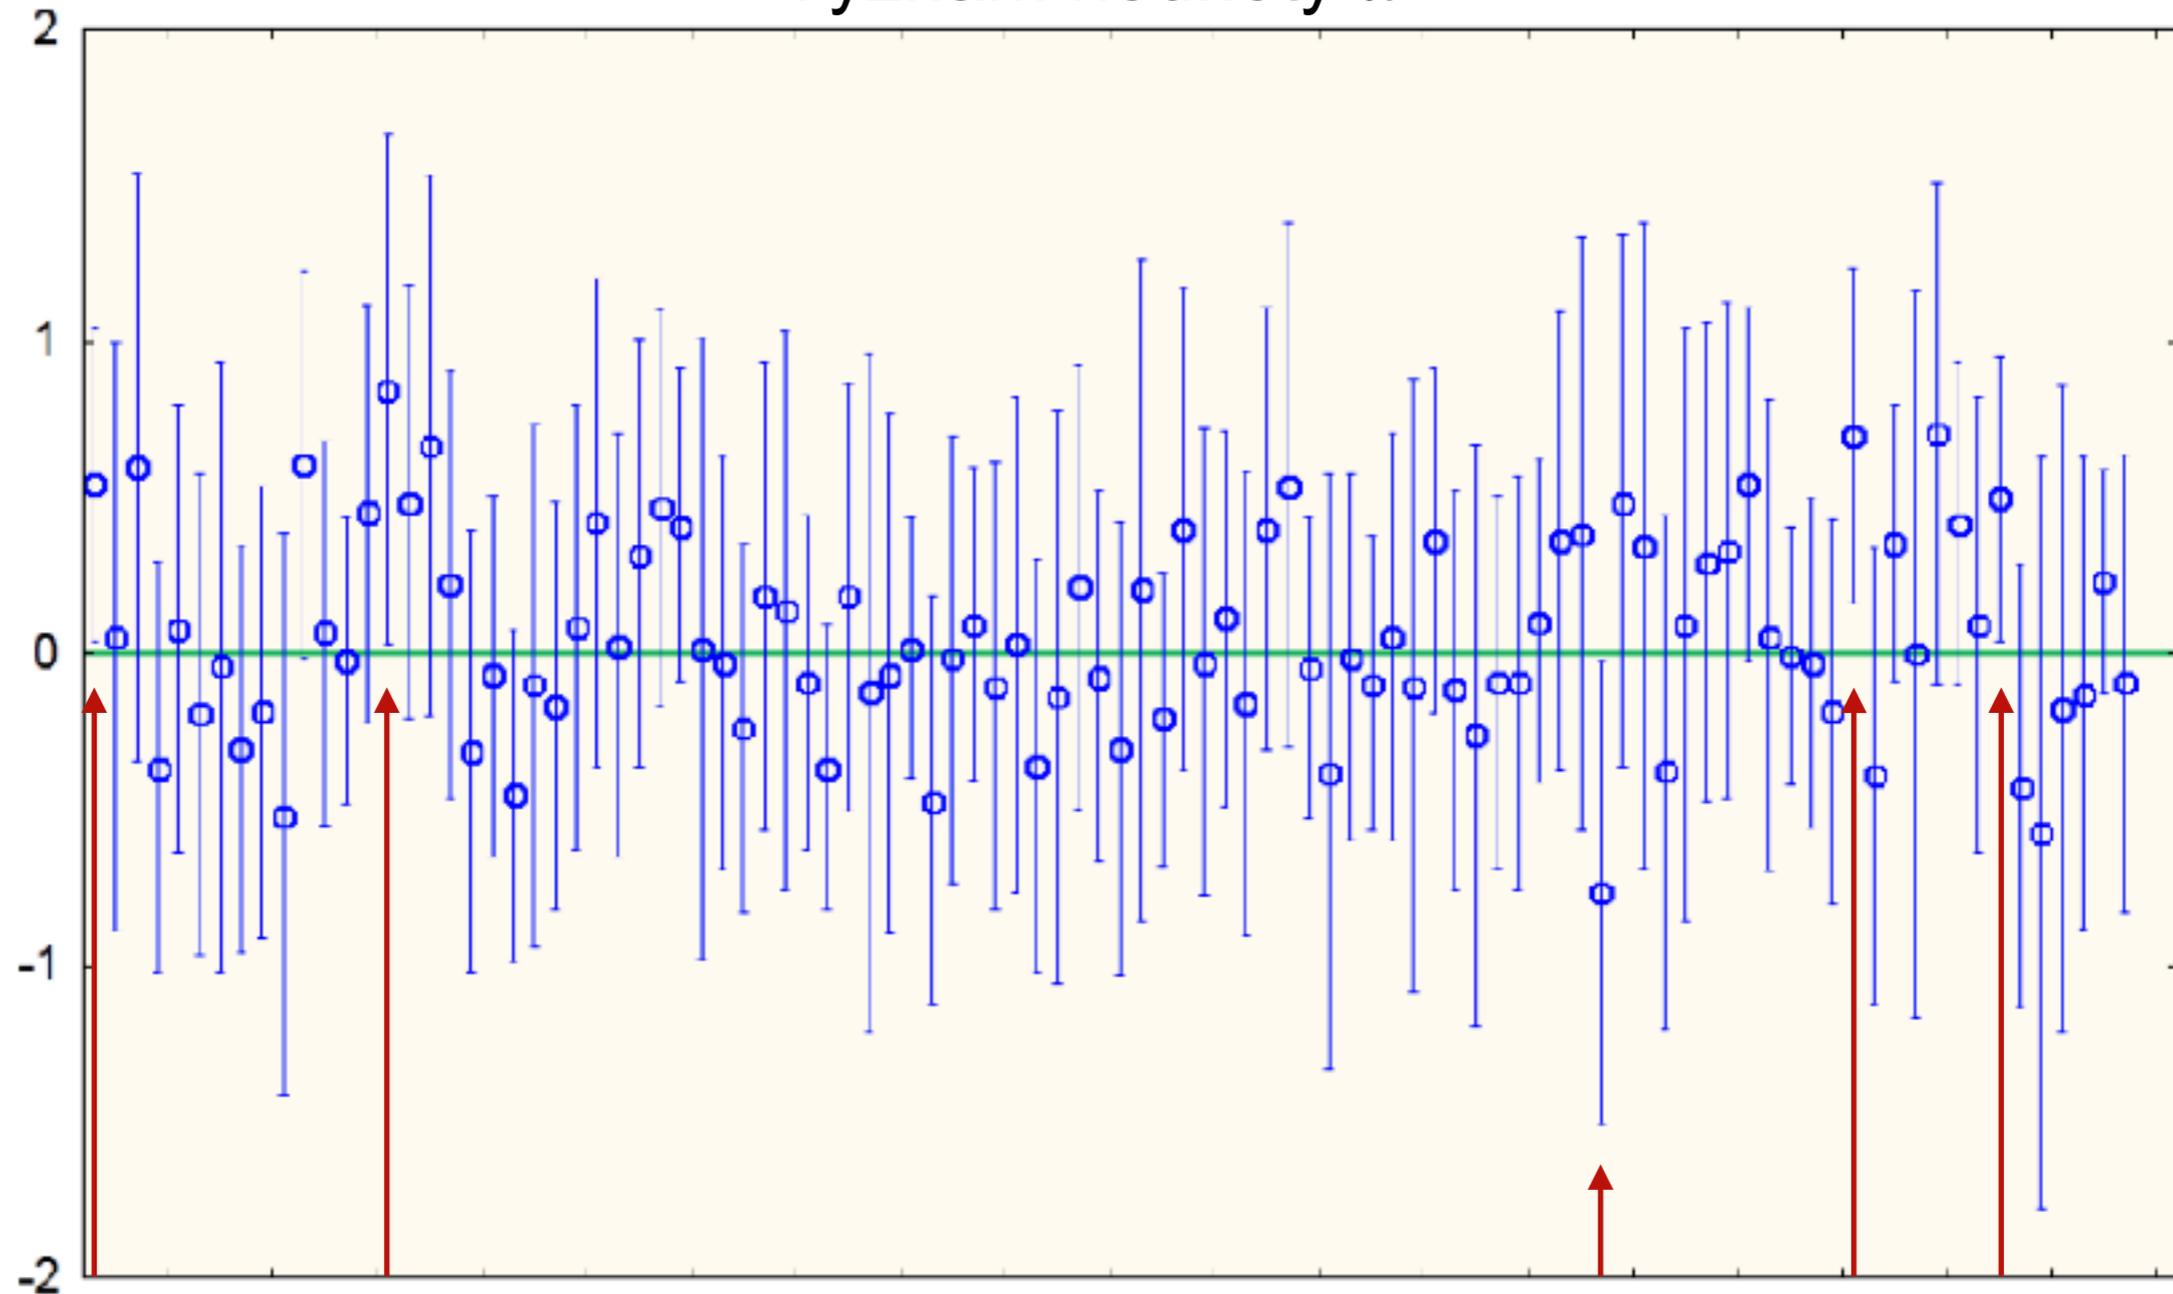
# Intervalové odhady - Intervaly spolehlivosti

Vliv změny směrodatné odchylky na šířku intervalu spolehlivosti



# Intervalové odhady - Intervaly spolehlivosti

Význam hodnoty  $\alpha$

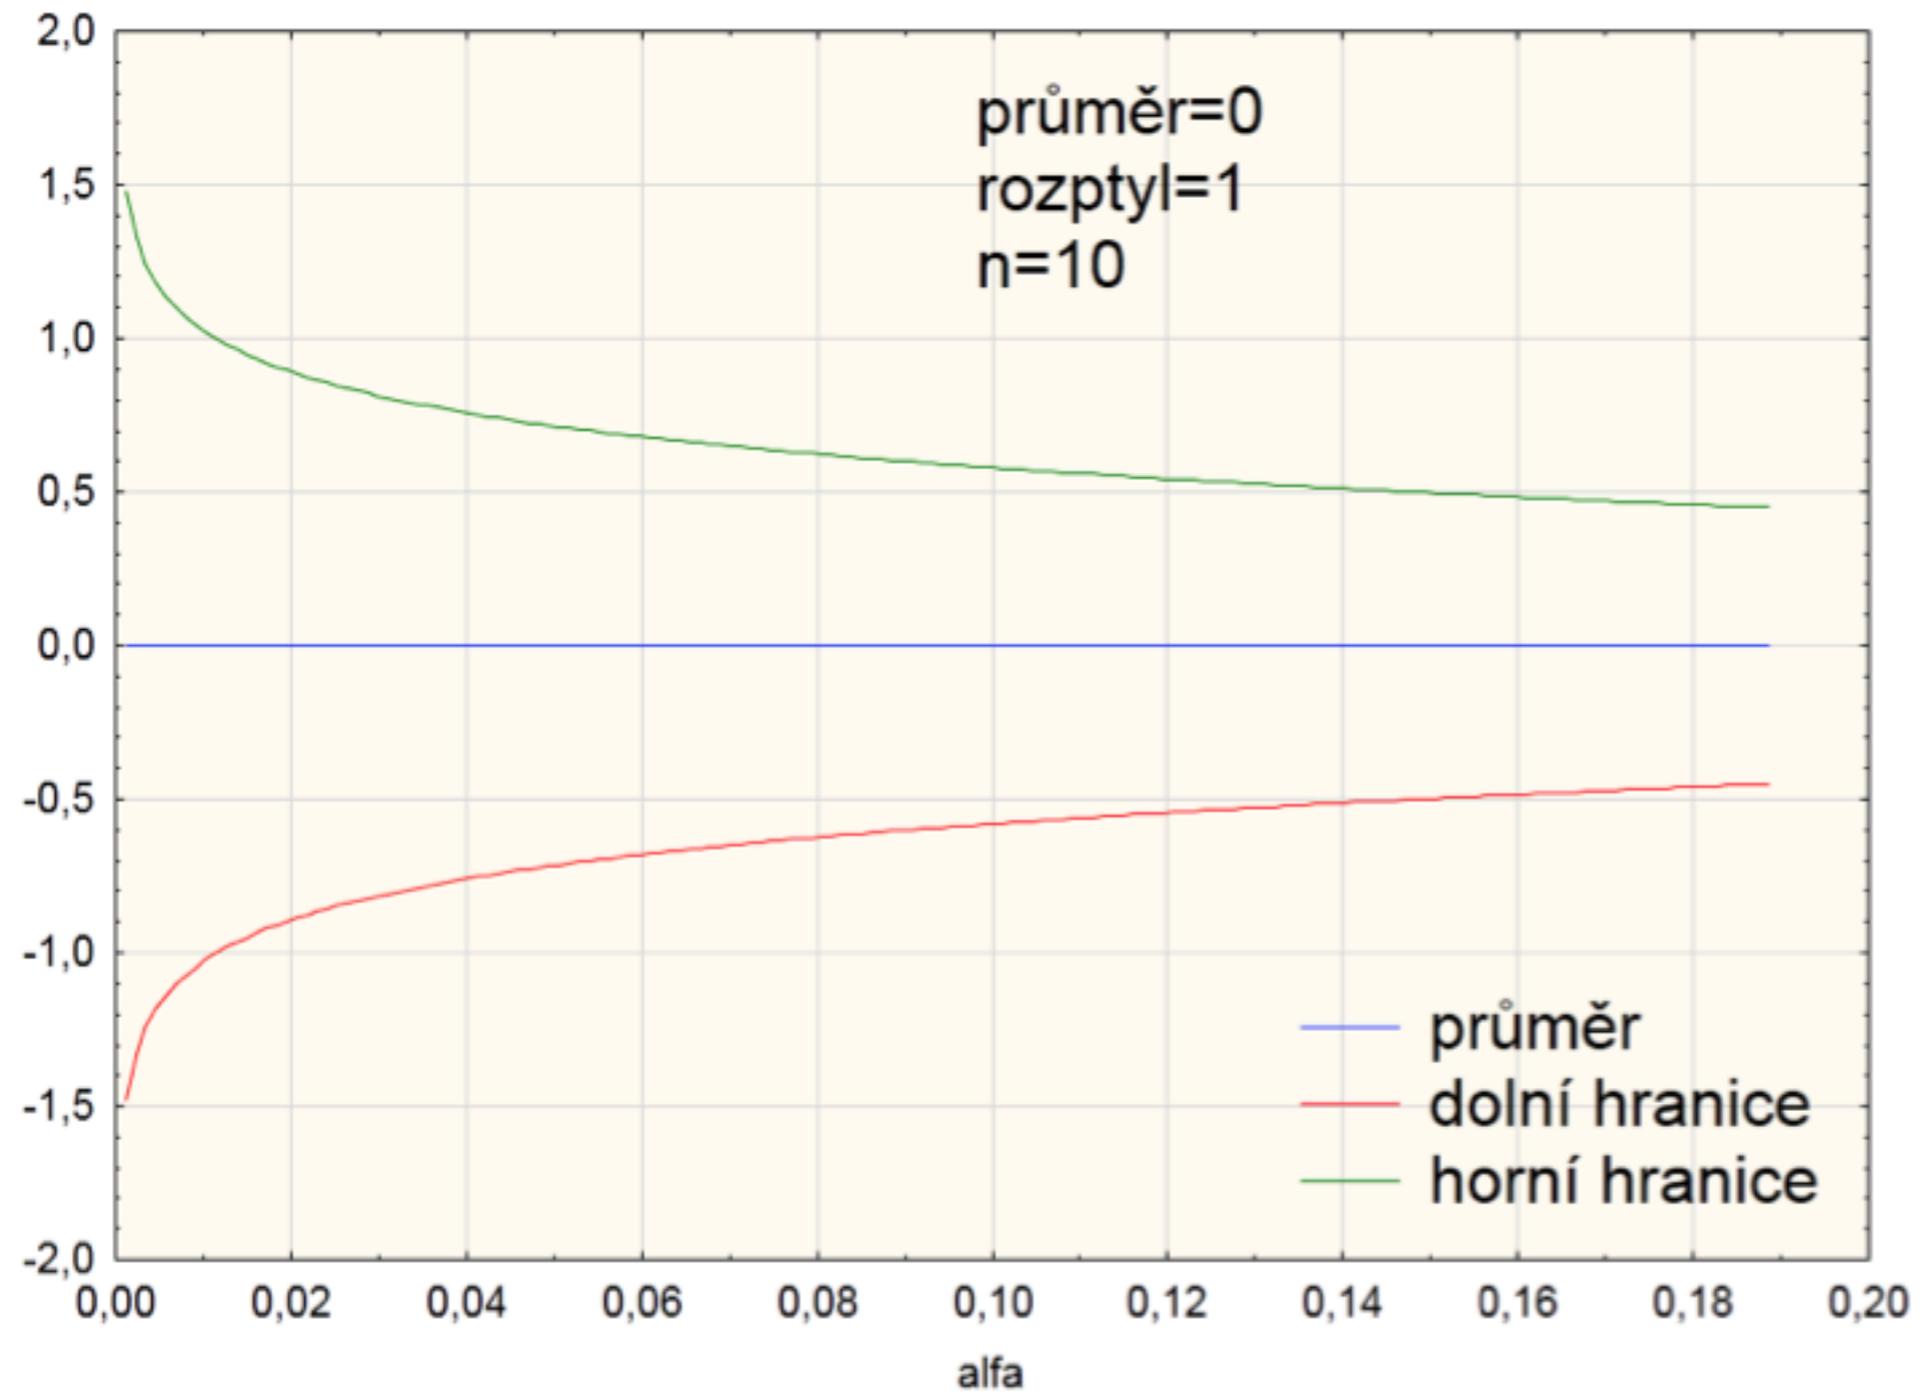


Simulační příklad:  $N=100$ ,  $\mu=0$ ,  $\alpha=0,05$ , (5 intervalů mimo)



# Intervalové odhady - Intervaly spolehlivosti

Vliv změny hodnoty  $\alpha$  na šířku intervalu spolehlivosti



## Intervalové odhady - Intervaly spolehlivosti

**Příklad 5:** konstrukce intervalového odhadu rozptylu při výběru z normálního rozdělení.

Zde využijeme znalost toho, že  $\frac{(n-1)s^2}{\sigma^2} \sim \chi^2(n-1)$

Podobnými úpravami jako v případě střední hodnoty se dostaneme k intervalovému odhadu ve tvaru

$$\frac{(n-1)s^2}{\chi_{1-\alpha/2}^2(n-1)} \leq \sigma^2 \leq \frac{(n-1)s^2}{\chi_{\alpha/2}^2(n-1)}$$



## Intervalové odhady - Intervaly spolehlivosti

**Příklad 6:** Odhad pravděpodobnosti  $p$ .

- při šetření jsme zjistili, že ze 100 dotázaných respondentů 43 se chystá volit stranu mírného pokroku v mezích zákona
- má tato strana šanci vyhrát ve volbách?

$X_i$  :  $i$ -tý dotázaný bude volit SMPvMZ = 1, nebude volit SMPvMZ = 0,

$Y$  = počet těch, kteří budou volit SMPvMZ =  $\sum_{i=1}^{100} X_i \sim Bin(100, p)$

$Y$  lze aproximovat rozdělením  $N(np, np(1-p))$

$\bar{X}$  má potom také přibližně normální rozdělení  $N\left(p, \frac{p(1-p)}{n}\right)$

Odhad pravděpodobnosti  $p$  lze tedy chápat jako odhad střední hodnoty  $\bar{X}$ .

Bodový odhad pravděpodobnosti  $p$  je  $\bar{X} = 0,43$ . Intervalový odhad je potom

$$\bar{X} - \sqrt{\frac{p(1-p)}{n}} u_{1-\alpha/2} \leq p \leq \bar{X} + \sqrt{\frac{p(1-p)}{n}} u_{1-\alpha/2}$$

$u_{0,975} = 1,96$  Tedy intervalový odhad je  $(0,33; 0,53) \Rightarrow$  SMPvMZ má statisticky významnou šanci na hladině významnosti 5 % získat nadpoloviční většinu.

