

# Přednáška VI.

## Intervalové odhady

- ➔ Motivace
- ➔ Směrodatná odchylka a směrodatná chyba
- ➔ Centrální limitní věta
- ➔ Intervaly spolehlivosti



evropský  
sociální  
fond v ČR



EVROPSKÁ UNIE  
MINISTERSTVO ŠKOLSTVÍ,  
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

# Opakování – nestranné a MLE

- ➔ Jaký je princip nestranných odhadů?
- ➔ Jaký je princip odhadů metodou MLE?
- ➔ Jak vypadají nestranný a MLE odhad parametru  $\sigma^2$ ?

# Opakování – použití průměru a mediánu

- ➔ Jmenujte výhody a nevýhody průměru a mediánu jako statistik pro odhad střední hodnoty náhodné veličiny.
- ➔ Jmenujte příklad, kdy průměr je výhodnější než medián, a příklad, kdy medián je výhodnější než průměr.

# 1. Motivace

# Spolehlivost bodového odhadu

Výběr číslo 1




Výběr číslo 2



Celá cílová populace



Pracujeme-li s výběrem z cílové populace, je třeba na základě variability pozorovaných dat spočítat tzv. interval spolehlivosti pro bodový odhad.



Interval spolehlivosti na  
základě výběru číslo 1.

Tomáš Pavlík

Umíme-li „změřit“ celou cílovou populaci, nepotřebujeme interval spolehlivosti, protože jsme schopni odhadnout sledovaný parametr přesně – v praxi je tato situace nereálná.



# Intervalový odhad


- ➔ Bodový odhad je prvním krokem ve statistickém popisu dat.
- ➔ Co nám říká jedno číslo? Studie 1 může publikovat číslo  $x_1$ , studie 2 číslo  $x_2$ . Které je správnější, lepší, přesnější?
- ➔ Bodový odhad je sám o sobě nedostatečný pro popis parametru rozdělení pravděpodobnosti náhodné veličiny.
- ➔ Zajímá nás přesnost (spolehlivost) bodového odhadu.



## 2. Variabilita pozorování a variabilita výběrového průměru

# Populace a náhodná veličina

- ➔ **Cílová populace** – skupina subjektů, o které chceme zjistit nějakou informaci.
- ➔ Realizujeme-li náhodně výběr z cílové populace, dostaneme **výběrovou populaci** (experimentální vzorek).
- ➔ **Znak  $X$  = náhodná veličina  $X$**  – vlastnost, která nás zajímá.
- ➔ **Realizace náhodné veličiny** – reálné číslo, pozorovaná hodnota na vybraném subjektu.
- ➔ **Náhodný výběr** – množina  $n$  nezávislých náhodných veličin se stejným rozdělením:  $X_1, X_2, \dots, X_n$ .
- ➔ **Realizace náhodného výběru** – reálná čísla, hodnoty pozorované na výběrové populaci.



# Pravděpodobnostní chování náhodné veličiny

- ➔  $F(x)$ ,  $f(x)$  a  $p(x)$  – popisují chování náhodné veličiny úplně, ale složitě.
- ➔ Dvě charakteristiky odráží vlastnosti rozdělení jedním číslem: **střední hodnota** a **rozptyl**. Odmocnina z rozptylu je **směrodatná odchylka**.

$$E(X), D(X), SD(X)$$

- ➔ Platí následující:
  - ➔ Jednotlivé realizace náhodné veličiny vykazují variabilitu (dle  $SD(X)$ ).
  - ➔ Jakákoli statistika (např. průměr) je jako transformace náhodných veličin také náhodnou veličinou. Má tedy i rozdělení pravděpodobnosti.
  - ➔ Jednotlivé realizace statistiky nad různými náhodnými výběry také vykazují variabilitu (opět úměrnou  $SD(X)$ ).

# Co je zajímavé – výběrový průměr

- ➔ Rozdělení pravděpodobnosti výběrového průměru tím méně variabilní čím více pozorování je v průměru zahrnuto.
- ➔ Rozdělení pravděpodobnosti výběrového průměru se s rostoucím  $n$  přestává podobat rozdělení původních dat a začíná se podobat rozdělení normálnímu.
- ➔ Proč?

# Co je zajímavé – výběrový průměr

- ➔ Rozdělení pravděpodobnosti výběrového průměru tím méně variabilní čím více pozorování je v průměru zahrnuto → **plyne z vlastností rozptylu transformované náhodné veličiny.**
- ➔ Rozdělení pravděpodobnosti výběrového průměru se s rostoucím  $n$  přestává podobat rozdělení původních dat a začíná se podobat rozdělení normálnímu → **plyne z centrální limitní věty.**

# Charakteristiky výběrového průměru

- ➔ Máme posloupnost  $X_1, \dots, X_n$  nezávislých, stejně rozdělených náhodných veličin, které mají konečnou střední hodnotu  $\mu$  a rozptyl  $\sigma^2$ .

$$X_i \sim N(\mu, \sigma^2)$$

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

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


$$D(\bar{X}) = \frac{1}{n^2} \sum_{i=1}^n D(X_i) = \frac{\sigma^2}{n}$$

$$SD(\bar{X}) = \sqrt{D(\bar{X})} = \frac{\sigma}{\sqrt{n}}$$



Pro odhad, respektive statistiku, se tomuto výrazu říká **směrodatná chyba** nebo **standardní chyba** („standard error“) a značí se  $SE$ .

# Příklad – výběrový průměr



# Shrnutí

- ➔ Směrodatná odchylka ( $SD$ ) není směrodatná chyba popisné statistiky ( $SE$ )!
- ➔ Směrodatná odchylka ( $SD$ ) je odrazem variability náhodné veličiny ve sledované populaci.
- ➔ Směrodatná chyba ( $SE$ ) je odrazem přesnosti popisné statistiky jako odhadu střední hodnoty náhodné veličiny.
- ➔ Pozor na rozdíl mezi  $SD$  a  $SE$  v článcích a knihách – tabulkách a grafech!



# Příklad – výška člověka

- ➔ Náhodná veličina bude výška člověka:  $X \sim N(175, 15^2)$ , tedy uvažujme střední hodnotu 175 cm a směrodatnou odchylku 15 cm. Jak se chovají průměry pro náhodné výběry o velikosti  $n = 10$ ,  $n = 100$  a  $n = 1000$ ?
- ➔ Kód v R:

```
x <- rep(0, 100)                      # vytvořím si vektor pro ukládání průměrů

for (i in 1:100) {
  pom <- rnorm(10, 175, 15)
  x[i] <- mean(pom)}                  # cyklus pro výpočet výběrových průměrů pro n=10
hist(x, breaks=10, xlim=c(160,190)) # vykreslení histogramu pro výběrové průměry pro n=10


for (i in 1:100) {
  pom <- rnorm(100, 175, 15)
  x[i] <- mean(pom)}                 # cyklus pro výpočet výběrových průměrů pro n=100
hist(x, breaks=10, xlim=c(160,190)) # vykreslení histogramu pro výběrové průměry pro n=100

for (i in 1:100) {
  pom <- rnorm(1000, 175, 15)
  x[i] <- mean(pom)}                # cyklus pro výpočet výběrových průměrů pro n=1000
hist(x, breaks=10, xlim=c(160,190)) # vykreslení histogramu pro výběrové průměry pro n=1000
```


# Příklad – výška člověka

- ➔ Původní pozorování mají rozsah hodnot zhruba od 120 cm do 220 cm. Kde se pohybují jednotlivé průměry?


Výběrové průměry  
ze vzorku  $n = 10$



Výběrové průměry  
ze vzorku  $n = 100$




Výběrové průměry  
ze vzorku  $n = 1000$




# Příklad – výška člověka

➔ Původní pozorování mají rozsah hodnot zhruba od 120 cm do 220 cm. Kde se pohybují jednotlivé průměry?


Výběrové průměry  
ze vzorku  $n = 10$



Výběrové průměry  
ze vzorku  $n = 100$



Výběrové průměry  
ze vzorku  $n = 1000$



# 3. Centrální limitní věta

# Připomenutí: standardizace normálního rozdělení

- Standardizace je transformace náhodné veličiny s  $N(\mu, \sigma^2)$  na  $N(0,1)$ .
  - Důvod: řada statistických metod byla odvozena pro standardizované normální rozdělení,  $N(0,1)$ . Děláme to tedy opět kvůli lepší možnosti hodnocení dat.
- 
- Teoretická standardizace náhodné veličiny: 
$$U = \frac{X - \mu}{\sqrt{\sigma^2}}$$
  - Praktická standardizace naměřených hodnot: 
$$u_i = \frac{x_i - \bar{x}}{\sqrt{s^2}}$$

# Centrální limitní věta

- ➔ Klíčová věta umožňující sestrojení intervalových odhadů.
- ➔ Máme posloupnost  $X_1, \dots, X_n$  nezávislých, stejně rozdělených náhodných veličin, které mají konečnou střední hodnotu  $\mu$  a rozptyl  $\sigma^2$ .
- ➔ Pak platí, že pro  $n \rightarrow \infty$  má suma  $X_i = \sum_i X_i$  přibližně normální rozdělení pravděpodobnosti.

# Centrální limitní věta

- ➔ Máme posloupnost  $X_1, \dots, X_n$  nezávislých, stejně rozdělených náhodných veličin, které mají konečnou střední hodnotu  $\mu$  a rozptyl  $\sigma^2$ . Pak platí, že pro  $n \rightarrow \infty$  má výběrový průměr  $\bar{X} = \frac{1}{n} \sum_i X_i$  přibližně normální rozdělení se střední hodnotou  $\mu$  a rozptylem  $\sigma^2/n$ .
- ➔ Tedy  $(\bar{X} - \mu) / (\sigma / \sqrt{n})$  má přibližně standardizované normální rozdělení pravděpodobnosti:

$$\lim_{n \rightarrow \infty} P\left(\frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}} \leq x\right) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du$$

# CLV – zjednodušená interpretace


- ➔ Pokud je rozdělení pravděpodobnosti náhodné veličiny normální, pak je i rozdělení průměru pozorovaných hodnot normální (a to i pro  $n = 1$ ).
- ➔ Pokud rozdělení pravděpodobnosti náhodné veličiny není normální, pak je rozdělení průměru pozorovaných hodnot přibližně normální, když  $n$  je dostatečně velké ( $n \rightarrow \infty$  ).
- ➔ „Dostatečně velké“ znamená  $> 30$  pro rozdělení podobná normálnímu a  $> 100$  pro rozdělení nepodobná normálnímu.

# Co je super...

- ➔ Centrální limitní věta funguje i když rozdělení původní náhodné veličiny není normální rozdělení pravděpodobnosti. A dokonce i když není spojité!

# Příklad – binomické rozdělení

- ➔ Chceme sledovat s jakou přesností lze odhadnout podíl hypertoniků v dospělé populaci ČR.
- ➔ Předpokládejme, že skutečný podíl dospělých s hypertenzí je 0,2.
- ➔ Náhodná veličina  $X$ : osoba trpí / netrpí hypertenzí.
- ➔ Pravděpodobnostní funkce  $X$    
(alternativní rozdělení)



# Příklad – binomické rozdělení

- ➔ Náhodná veličina  $S$  bude součet  $X_i, i = 1, \dots, n$ .
- ➔ Náhodná veličina  $Y$  bude definována jako  $S/n$ .

$$E(S) = np$$

$$D(S) = np(1-p)$$

$$E(Y) = E(S)/n = p$$

$$D(Y) = D(S)/n^2 = (p(1-p))/n$$

- ➔ Jak se chová  $Y$  pro náhodné výběry o velikosti  $n = 10, n = 100$  a  $n = 1000$ ?

- ➔ Kód v R:


```
s <- rbinom(1000, 10, 0.2)          # vytvořím si 1000 realizací veličiny S při n=10 a p=0,2
y <- s / 10                          # S transformuji na 1000 realizací veličiny Y
hist(y, breaks=10, xlim=c(0,1))       # vykreslení histogramu pro výběrové průměry pro n=10

s <- rbinom(1000, 100, 0.2)          # vytvořím si 1000 realizací veličiny S při n=100 a p=0,2
y <- s / 100                         # S transformuji na 1000 realizací veličiny Y
hist(y, breaks=10, xlim=c(0,1))       # vykreslení histogramu pro výběrové průměry pro n=10


s <- rbinom(1000, 1000, 0.2)         # vytvořím si 1000 realizací veličiny S při n=1000 a p=0,2
y <- s / 1000                        # S transformuji na 1000 realizací veličiny Y
hist(y, breaks=10, xlim=c(0,1))       # vykreslení histogramu pro výběrové průměry pro n=1000
```

# Příklad – binomické rozdělení


1000 realizací veličiny  
 $Y$  při  $n = 10$




1000 realizací veličiny  
 $Y$  při  $n = 100$



1000 realizací veličiny  
 $Y$  při  $n = 1000$




# Příklad – Poissonovo rozdělení



# Co když ale $n$ nejde do nekonečna?

- ➔ Není-li velikost vzorku  $n$  dostatečně velká, nelze rozdělení výběrových průměrů považovat za normální.
- ➔ Aproximace Studentovým  $t$  rozdělením (viz přednáška o jednotlivých rozděleních pravděpodobnosti: Lze ho chápat jako aproximační normálního rozdělení pro malé vzorky, pro velké velikosti souborů konverguje k normálnímu rozdělení).



# 4. Intervalové odhady


# Co je super ... pokračování

- ➔ Centrální limitní věta mi říká, že rozdělení pravděpodobnosti výběrového průměru můžu při dostatečném  $n$  approximovat normálním rozdělením.
- ➔ Když provedu standardizaci, tak dokonce standardizovaným normálním rozdělením.

$$\lim_{n \rightarrow \infty} P\left(\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq x\right) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du \quad \rightarrow \quad \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim N(0,1)$$

# Interval spolehlivosti

- Princip vytvoření intervalového odhadu pro výběrový průměr, respektive konstrukce intervalu spolehlivosti pro výběrový průměr, je shodný s teoretickým pozadím pravidla  $\pm 3\sigma$ .




# Připomenutí – kvantilová funkce

→ Inverzní funkce k distribuční funkci, výsledkem není pravděpodobnost, ale číslo na reálné ose, které odpovídá určité pravděpodobnosti.


→ **Distribuční funkce**  $F(x) = P(X \leq x)$

→ **Kvantilová funkce**  $x_p = F^{-1}(P(X \leq x)) = F^{-1}(p)$

Spojitá náhodná  
veličina




# Kvantily standardizovaného normální rozdělení



# Kvantily standardizovaného normální rozdělení

➔ Oblast, kde se náhodná veličina se standardizovaným normálním rozdělením realizuje s pravděpodobností  $1 - \alpha$  lze vyjádřit pomocí následujícího vztahu:



$$P(z_{\alpha/2} \leq Z \leq z_{1-\alpha/2}) = F_{N(0,1)}(z_{1-\alpha/2}) - F_{N(0,1)}(z_{\alpha/2}) = 1 - \frac{\alpha}{2} - \frac{\alpha}{2} = 1 - \alpha$$

# 100(1–α)% interval spolehlivosti pro $\mu$

- Máme náhodný výběr  $X_1, X_2, \dots, X_n$  z normálního rozdělení.  $X_i \sim N(\mu, \sigma^2)$
- Budeme předpokládat, že  $\sigma$  známe!
- Z předchozího snímku víme, že platí:

$$P(z_{\alpha/2} \leq Z \leq z_{1-\alpha/2}) = F_{N(0,1)}(z_{1-\alpha/2}) - F_{N(0,1)}(z_{\alpha/2}) = 1 - \frac{\alpha}{2} - \frac{\alpha}{2} = 1 - \alpha$$

- Když si rozepíšeme a upravíme výraz na levé straně, dostaneme:

$$\begin{aligned} 1 - \alpha &= P(z_{\alpha/2} \leq Z \leq z_{1-\alpha/2}) = P(-z_{1-\alpha/2} \leq Z \leq z_{1-\alpha/2}) = P(-z_{1-\alpha/2} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq z_{1-\alpha/2}) \\ &= P(-\frac{\sigma}{\sqrt{n}} z_{1-\alpha/2} \leq \bar{X} - \mu \leq \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2}) = P(\bar{X} - \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2} \leq \mu \leq \bar{X} + \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2}) \end{aligned}$$

- 100(1–α)% IS pro  $\mu$  má tvar:  $(D, H) = (\bar{X} - \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2}; \bar{X} + \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2})$

# $100(1-\alpha)\%$ interval spolehlivosti pro $\mu$

➔ Co ten vzorec znamená?

$$(D, H) = (\bar{X} - \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2}; \bar{X} + \frac{\sigma}{\sqrt{n}} z_{1-\alpha/2})$$

$$\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$$

$$SE(\bar{X}) = \sqrt{\frac{\sigma^2}{n}} = \frac{\sigma}{\sqrt{n}}$$




➔ Tedy zjednodušeně:

$$100(1-\alpha)\% \text{ IS} = \bar{X} \pm z_{1-\alpha/2} SE(\bar{X})$$

# Interpretace intervalu spolehlivosti

- Poloha neznámého parametru je konstantní (jsme-li frekventisti)!
- 95% interval spolehlivosti má následující interpretaci:

Pokud bychom opakovaně vybírali skupiny subjektů o stejné velikosti ( $n$ ) a počítali výběrový průměr s 95% IS, pak 95 % těchto intervalů spolehlivosti neznámý parametr obsahuje a 5 % ho neobsahuje. Tedy 95% IS obsahuje neznámý parametr s rizikem  $\alpha$ .



# Co když neznáme $\sigma$ ?

- ➔ V předchozím případě jsme předpokládali, že známe přesnou hodnotu rozptylu / směrodatné odchylky. To je v praxi nereálné!
  - ➔ Musíme použít jinou statistiku s jiným rozdělením pravděpodobnosti.
- 
- ➔ Čím bychom mohli nahradit  $\sigma$ ?
  - ➔ K čemu to povede?

# Co když neznáme $\sigma$ ?

➔ Musíme použít jinou testovou statistiku s jiným rozdělením pravděpodobnosti.

➔ **Čím bychom mohli nahradit  $\sigma$ ?**

➔ Logické je použít výběrovou směrodatnou odchylku  $s$ .

➔ Náhrada ale není úplně jednoduchá – není to dosazení  $s$  za  $\sigma$ .

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

➔ **K čemu to bude?**

➔ Pomocí  $s^2$  vytvoříme statistiku s chí-kvadrát rozdělením ( $\chi^2$ ) – tu pak použijeme pro vytvoření statistiky se Studentovým  $t$  rozdělením (viz přednáška o jednotlivých rozděleních pravděpodobnosti):

$$X \sim N(0,1), Q \sim \chi^2(k) \rightarrow T = \frac{X}{\sqrt{Q/k}} \rightarrow T \sim t(k)$$

# Co když neznáme $\sigma$ ?

- ➔ Lze ukázat, že statistika  $K = \frac{n-1}{\sigma^2} s^2 \sim \chi^2(n-1)$
- ➔ Použijeme ještě standardizovanou normální veličinu  $Z = \frac{\bar{X}_n - \mu}{\sigma / \sqrt{n}} \sim N(0,1)$
- ➔ A obě dohromady použijeme pro vytvoření  $T$  statistiky:

$$T = \frac{Z}{\sqrt{K/(n-1)}} = \frac{\sqrt{n}(\bar{X}_n - \mu) / \sigma}{\sqrt{(n-1)s^2 / (n-1)\sigma^2}} = \frac{\bar{X}_n - \mu}{s / \sqrt{n}} \rightarrow T \sim t(n-1)$$

- ➔ Z toho plyne tvar  $100(1-\alpha)\%$  intervalu spolehlivosti pro  $\mu$  v případě, že neznáme hodnotu  $\sigma$ :

$$(D, H) = (\bar{X} - \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1); \bar{X} + \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1))$$

# Příklad – konstrukce intervalu spolehlivosti

- Chceme sestrojit 95% IS pro odhad střední hodnoty systolického tlaku studentů vysokých škol.

$$n = 100$$

$$\bar{X}_n = 123,4 \text{ mm Hg}$$

$$s = SD = 14,0 \text{ mm Hg}$$

$$SE = 14 / \sqrt{100} = 1,4 \text{ mm Hg}$$

$$t_{1-\alpha/2}(n-1) = 1,98$$

} naměřené hodnoty

→ z tabulek

$$95\% \text{ IS} = (D, H) = (\bar{X} - \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1); \bar{X} + \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1))$$

$$95\% \text{ IS} = (D, H) = (123,4 - \frac{14,0}{\sqrt{100}} t_{1-0,05/2}(99); 123,4 + \frac{14,0}{\sqrt{100}} t_{1-0,05/2}(99))$$

$$95\% \text{ IS} = (D, H) = (120,6; 126,2)$$

# Šířka intervalu spolehlivosti

→ Co ovlivňuje šířku intervalu spolehlivosti?

$$100(1-\alpha)\% \text{ IS pro } \mu = (D, H) = (\bar{X} - \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1); \bar{X} + \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1))$$

1. **Velikost vzorku** – s rostoucí velikostí vzorku je IS užší (máme více informace a odhad je přesnější), zároveň se kvantily  $t$  rozdělení blíží kvantilům standardizovaného normálního rozdělení.
2. Variabilita náhodné veličiny
3. Spolehlivost, kterou požadujeme

# Šířka intervalu spolehlivosti

→ Co ovlivňuje šířku intervalu spolehlivosti?

$$100(1-\alpha)\% \text{ IS pro } \mu = (D, H) = (\bar{X} - \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1); \bar{X} + \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1))$$

1. Velikost vzorku
2. **Variabilita náhodné veličiny** – čím náhodná veličina vykazuje větší variabilitu, tím je IS pro odhad střední hodnoty širší, tedy odhad je méně přesný.
3. Spolehlivost, kterou požadujeme

# Šířka intervalu spolehlivosti

→ Co ovlivňuje šířku intervalu spolehlivosti?

$$100(1-\alpha)\% \text{ IS pro } \mu = (D, H) = (\bar{X} - \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1); \bar{X} + \frac{s}{\sqrt{n}} t_{1-\alpha/2}(n-1))$$

1. Velikost vzorku
2. Variabilita náhodné veličiny
3. **Spolehlivost, kterou požadujeme** – chceme-li mít větší jistotu, že nás IS pokrývá neznámou střední hodnotu, IS musí být samozřejmě širší, stačí-li nám menší spolehlivost, bude užší. Standardně se používá 95% IS (ale také 90% anebo 99%)

# Poznámka 1

- ➔ Lze vytvořit i IS pro odhad parametru  $\sigma$ , který je založen na již zmíněné statistice  $K$ .

$$K = \frac{n-1}{\sigma^2} s^2 \sim \chi^2(n-1)$$

- ➔ Lze vytvořit i IS pro odhad podílu dvou parametrů  $\sigma_1$  a  $\sigma_2$  (pomocí  $F$  statistiky). Ten lze použít pro hodnocení homogeneity rozptylů dvou výběrů, která je jedním z předpokladů v testování hypotéz.

# Poznámka 2

➔ Velmi důležitý je i IS pro odhad střední hodnoty rozdílu dvou náhodných veličin.

$$\left. \begin{array}{l} X \sim N(\mu_1, \sigma_1^2) \\ Y \sim N(\mu_2, \sigma_2^2) \end{array} \right\} \begin{array}{l} \bar{X} \sim N(\mu_1, \frac{\sigma_1^2}{n_1}) \\ \bar{Y} \sim N(\mu_2, \frac{\sigma_2^2}{n_2}) \end{array} \right\} \bar{X} - \bar{Y} \sim N(\mu_1 - \mu_2, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2})$$

➔ Známe-li  $\sigma_1$  a  $\sigma_2$ , provedeme standardizaci a pak odvodíme  $100(1-\alpha)\%$  IS:

$$1 - \alpha = P(\bar{X} - \bar{Y} - z_{1-\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \leq \mu_1 - \mu_2 \leq \bar{X} - \bar{Y} + z_{1-\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}})$$

➔ Neznáme-li  $\sigma_1$  a  $\sigma_2$ , použijeme statistiky  $K_1$  a  $K_2$ , abychom se zbavili  $\sigma_1$  a  $\sigma_2$ , výsledná statistika má opět Studentovo  $t$  rozdělení.

$$1 - \alpha = P(\bar{X} - \bar{Y} - t_{1-\alpha/2}(n_1 + n_2 - 2) \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \leq \mu_1 - \mu_2 \leq \bar{X} - \bar{Y} + t_{1-\alpha/2}(n_1 + n_2 - 2) \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}})$$

# Příklad

➔ Radiofrekvenční ablace tkáně slinivky břišní u prasat. Sledujeme vliv typu chlazení okolních struktur (A – žádné, B – průplach vodou) na největší rozměr nekrózy. Zajímá nás rozdíl v efektu obou typů chlazení a jeho 95% IS.

$$\begin{array}{llll} n_A = 18 & \bar{x}_A = 25,1 \text{ mm} & SD_A = s_A = 0,8 & SE_A = 0,8 / \sqrt{18} = 0,19 \text{ mm} \\ n_B = 17 & \bar{x}_B = 21,8 \text{ mm} & SD_B = s_B = 2,4 & SE_B = 2,4 / \sqrt{17} = 0,58 \text{ mm} \end{array}$$

➔ Dosadíme do vzorce s použitím příslušného  $t$  kvantilu:  $t_{0,975}(18+17-2) = 2,03$

$$\begin{aligned} 1 - \alpha &= P(\bar{x}_A - \bar{x}_B - t_{1-\alpha/2}(n_A + n_B - 2) \sqrt{\frac{s_A^2}{n_A} + \frac{s_B^2}{n_B}} \leq \mu_A - \mu_B \leq \bar{x}_A - \bar{x}_B + t_{1-\alpha/2}(n_A + n_B - 2) \sqrt{\frac{s_A^2}{n_A} + \frac{s_B^2}{n_B}}) \\ &= P(3,3 - t_{0,975}(33) \sqrt{\frac{0,8^2}{18} + \frac{2,4^2}{17}} \leq \mu_A - \mu_B \leq 3,3 + t_{0,975}(33) \sqrt{\frac{0,8^2}{18} + \frac{2,4^2}{17}}) \\ &= P(2,1 \leq \mu_A - \mu_B \leq 4,5) \end{aligned}$$

# Poznámka 3

➔ Interval spolehlivosti počítá pouze s variabilitou danou náhodným výběrem, nepočítá se zdroji systematického zkreslení.

## ➔ Příklady:

- ➔ Měření krevního tlaku může být systematicky zkresleno starým měřidlem („technical bias“).
- ➔ Měření krevního tlaku může být systematicky zkresleno tím, že se do studie přihlásí pouze určitá skupina osob („selection bias“).

# Neparametrické metody pro konstrukci IS

- ➔ Variabilitu výběrového průměru lze odhadnout i pomocí neparametrických metod:
- ➔ **Bootstrap** – je založen na principu opakovaného vzorkování naměřených dat s vracením, kdy pro vytvoření nového vzorku dat může být každý prvek použit více než jednou, právě jednou anebo není použit vůbec (ovšem se zachováním celkové velikosti souboru  $n$  i velikosti jednotlivých skupin).
- ➔ **Jackknife** – opakovaný výpočet sledované charakteristiky je prováděn vždy s vynecháním právě jednoho pozorování. Tento postup nám stejně jako v případě metody bootstrap poskytuje představu o rozsahu hodnot, ve kterých se námi sledovaná charakteristika může pohybovat, budeme li považovat naměřená data za reprezentativní vzorek z cílové populace.


# Příklad

- ➔ Máme náhodný výběr o velikosti  $n = 100$  z  $N(0,1)$ . Vytvoříme 95% IS pro průměr pomocí směrodatné chyby a pomocí metody bootstrap (1000 bootstrap vzorků).

$$\bar{x} = 0,079$$

$$(d, h) = (-0,126; 0,284)$$

$$(d, h) = (-0,133; 0,264)$$



# Poděkování...

Rozvoj studijního oboru „Matematická biologie“ PřF MU Brno je finančně podporován prostředky projektu ESF č. CZ.1.07/2.2.00/07.0318 „Víceoborová inovace studia Matematické biologie“ a státním rozpočtem České republiky



evropský  
sociální  
fond v ČR



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,  
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání  
pro konkurenceschopnost



UNIVERSITAS  
MASARYKIANA BRUNENSIS

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Tomáš Pavlík



Biostatistika