


# 8. SEMINÁŘ

## **INDUKTIVNÍ STATISTIKA**

### **1. ODHADY PARAMETRŮ**

# STATISTICKÁ INDUKCE



- Vlastnosti a složení výběrového souboru je přesně známé.
- Vlastnosti a složení základního souboru odhadujeme s určitou mírou nejistoty.
- Metody induktivní statistiky nejistotu neodstraňují, ale dokáží určit míru této nejistoty.

# Pravděpodobnost náhodného jevu

- Pravděpodobnost je mírou „častosti“ výskytu tohoto jevu
- Pravděpodobnost je vlastnost náhodného jevu
- Pravděpodobnost NJ zjistíme opakováním pokusů, jejichž výsledkem může být daný jev a „měříme“ ji **relativní četností (p)** tohoto jevu v řadě opakovaných pokusů (  $p = k/n$ ).


# Pravděpodobnost náhodného jevu

- Klasická definice pravděpodobnosti –  $pst$  NJ je dána podílem příznivých a všech možných výsledků (v experimentu, jehož možné výsledky jsou stejně pravděpodobné).
- Pravděpodobnost jevů spojených s karetními hrami, (hod kostkou, mincí ..) – dle definice
- **Nelze** dle def. vypočítat pravděpodobnost jevů v medicíně, můžeme  $pst$  jen **odhadovat pomocí relativních četností**


# NÁHODNÁ VELIČINA (NV)

- Spojitá NV – její rozdělení je dáno hustotou pravděpodobnosti – **frekvenční křivka (funkce)**.
- Matematicky – rovnice frekvenční funkce
- Graficky - hladká, plynulá čára

# Prezentace kvantitativních dat



# Příklad frekvenční fce spojité NV



$P(a \leq x \leq b)$  - pravděpodobnost, že NV  $X$  nabývá hodnot z intervalu  $a,b$

- Celá plocha pod frekvenční křivkou = 1 (100%)
- $P = 0 \Leftrightarrow a = b$  / pravděpodobnost znázorněna úsečkou – obsah plochy = 0/
- Pst malá – pokud  $\langle a,b \rangle$  krátký

# Základní a výběrový soubor

## VÝBĚROVÝ SOUBOR

- reprezentativní náhodný výběr
- výběrové (empirické) rozdělení četnosti
- popis rozdělení:  
tabulka, graf
- stat. ukazatele = **výběrové charakteristiky**: **m, s, p** (ozn. latinkou)
- jsou to charakteristiky náhodných veličin a také se jako náhodné veličiny chovají, tzn. mění se výběr od výběru (nutno počítat s chybami)

## ZÁKLADNÍ SOUBOR

- soubor, který nás zajímá
- teoretické rozdělení četnosti (matematický model)
- popis rozdělení:  
pravděpodobnostní rozdělení
- stat. ukazatele = **parametry**:  **$\mu, \sigma, \pi$**  (ozn. řeckou abecedou)
- jsou to neměnné konstanty, zpravidla neznámé, pro **n → ∞** platí, že  **$m → \mu, s → \sigma, p → \pi$** .

# Empirické a pravděpodobnostní rozdělení

- Každá veličina je ovlivňována řadou nepatrných vlivů, což způsobuje její **variabilitu** – tzn. veličina nabývá u různých subjektů různých hodnot – **náhodná veličina** (proměnná).
- Měříme-li veličinu ve výběrovém souboru, pak rozložení hodnot této veličiny znázorňujeme na základě **empiricky** zjištěných četností (histogram) = **výběrové rozdělení**.
- Každá veličina má své **pravděpodobnostní (teoretické) rozdělení**.
  - V takovém rozložení jsou **na ose x** všechny **hodnoty**, kterých může veličina potenciálně nabývat, a **na ose y** jsou **pravděpodobnosti**, se kterými se dané hodnoty vyskytují.

# Empirické a pravděpodobnostní rozdělení

- **V empirickém rozdělení** (histogram, polygon četnosti) jsou popsány četnosti, se kterými se naměřené hodnoty vyskytovaly ve výběrovém souboru
  - X
- **Pravděpodobnostní rozdělení** (pravděpodobnostní křivka) vyjadřuje **očekávání, jak často** se budou jednotlivé hodnoty vyskytovat v nekonečně velkém souboru
- **Pravděpodobnostní rozdělení** náhodných veličin jsou teoretické (matematické) modely, jejichž pomocí popisujeme nejrůznější reálné situace. Navzdory různorodosti a mnohotvárnosti přírodních a společenských jevů vystačíme v praxi s malým počtem modelů(tj. typů rozdělení).

# Typy pravděpodobnostních rozdělení

## Diskrétní veličiny

- binomické rozdělení (jev – nejev)
- rovnoměrné rozdělení
- Poissonovo rozdělení (vzácné jevy)

## Spojité veličiny

- normální (**Gaussovo**) rozdělení
- Studentovo t-rozdělení
- Snedecorovo F-rozdělení
- Chí-kvadrát rozdělení

## Pozn.:


- S veličinou zacházíme jako s normálně rozdělenou, pokud nemáme dostatečné důvody pro vyvrácení této domněnky.
- Rozložení většiny veličin lze převést na normální rozdělení.

# **NORMÁLNÍ (GAUSSOV) ROZDĚLENÍ**

- nejdůležitější spojité rozdělení
- NV má normální rozdělení tehdy, je-li tvořena nahromaděním velkého počtu nepatrných nezávislých příčin nahodilé povahy.
- př.- tělesná výška

# NORMÁLNÍ ROZDĚLENÍ (GAUSSOVA KŘIVKA)

Matematický model rozdělení četnosti spojité náhodné veličiny




$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2} \left(\frac{x-\mu}{\sigma}\right)^2}$$

- Frekvenční křivka NR je jednoznačně určena dvěma parametry:  $\mu$  a  $\sigma$ .
  - $\mu$  - určuje polohu křivky na ose x (analogie m)
  - $\sigma$  - určuje tvar křivky (analogie s)
- Symetrické rozdělení četností, parametr  $\mu$  = průměr a zároveň nejčetnější hodnota, která půlí plochu pod křivkou na dvě stejně velké části


# NORMÁLNÍ ROZDĚLENÍ

- Frekvenční křivky normálního rozdělení se stejnými směrodatnými odchylkami a odlišnými průměry ( $\mu_1 \neq \mu_2; \sigma_1 = \sigma_2$ )




# NORMÁLNÍ ROZDĚLENÍ

- Frekvenční křivky normálního rozdělení se stejnými průměry a odlišnými směrodatnými odchylkami ( $\mu_1 = \mu_2; \sigma_1 \neq \sigma_2$ )




# VLASTNOSTI NORMÁLNÍHO ROZDĚLENÍ




- Frekvenční křivky normálního rozdělení mají různý tvar a polohu pro různé veličiny. Pro všechny však platí, že v intervalu:
  - $\mu \pm 1\sigma$  leží 68,2% hodnot, kterých může daná veličina nabývat
  - $\mu \pm 2\sigma$  leží 95,4% hodnot, kterých může daná veličina nabývat
  - $\mu \pm 3\sigma$  leží 99,7% hodnot, kterých může daná veličina nabývat

# VLASTNOSTI NORMÁLNÍHO ROZDĚLENÍ



- Častěji nás ale zajímá, v jakém intervalu leží 95% (99%) hodnot sledované veličiny
  - pak lze tvrdit, že s pravděpodobností 95% (99%) se hodnoty sledované veličiny nacházejí právě v tomto intervalu resp., že 95% hodnot, kterých sledovaná veličina nabývá, leží v tomto intervalu
  - tento interval je vymezen tzv. **kritickými hodnotami normálního rozdělení**
- $P(\mu - 1,96\sigma \leq x \leq \mu + 1,96\sigma) = 0,95$
- $P(\mu - 2,58\sigma \leq x \leq \mu + 2,58\sigma) = 0,99$

# KRITICKÉ HODNOTY NORMÁLNÍHO ROZDĚLENÍ



- Kritické hodnoty normálního rozložení:  $1,96\sigma$  a  $2,58\sigma$
- V intervalu  $(\mu - 1,96\sigma; \mu + 1,96\sigma)$  se nachází 95 % všech možných hodnot sledované veličiny
- V intervalu  $(\mu - 2,58\sigma; \mu + 2,58\sigma)$  se nachází 99% všech možných hodnot sledované veličiny

# Tabulky normálního rozdělení

- Pro nematematiky
- Pro zvolené hranice intervalu  $a, b$  lze najít odpovídající pravděpodobnost a obráceně
- Tabelace je možná proto, že
  - 1/ normální rozdělení je symetrické
  - 2/ hranice  $a, b$  lze vyjádřit jako **odchylky od  $\mu$  v násobcích směrodatné odchylky  $\sigma$**   
(zásada: plocha = pravděpodobnost!)

**pravděpodobnost**

0,99  
0,95  
0,90  
0,80  
0,75  
0,50

**násobky  
směrodatné odchylky**

2,58  
1,96  
1,64  
1,28  
1,15  
0,65

**násobky  
směrodatné odchylky**

0,50  
1,00  
1,50  
2,00  
2,50  
3,00

**pravděpodobnost**

0,3828  
0,6827  
0,8664  
0,9545  
0,9876  
0,9973

# ODHADY PARAMETRŮ

- **Bodové odhady**
- **Intervalové odhady**

# BODOVÉ ODHADY

- Neznámý parametr odhadujeme jedním číslem tj. **bodem**.
- Např. výběrový aritmetický průměr  $m$  je bodovým odhadem parametru  $\mu$   
 $(\mu \approx m, \sigma \approx s, \pi \approx p)$
- Bodové odhady se „nestrefí“ přesně do odhadovaného parametru

# INTERVALOVÉ ODHADY

- Neznámý parametr odhadujeme intervalom vytvořeným kolem tzv. nejlepšího nestranného bodového odhadu.
- **Interval spolehlivosti** (konfidenční interval)
- **Spolehlivost** určujeme sami, obvykle 95% nebo 99%
  - jde o **pravděpodobnost**, že odhadovaný parametr se nachází v daném intervalu.
- **Hraniční hodnoty:**  
Platí (**dolní hranice < odhadovaný parametr < horní hranice**)
- zápis:  
**95% CI (dolní hranice ; horní hranice)**  
**99% CI (dolní hranice ; horní hranice)**

# INTERVALOVÉ ODHADY

Doplněk spolehlivosti do jedné (do 100%) vyjadřuje **riziko odhadu (riziko induktivního úsudku)** – tj. pravděpodobnost, že odhadovaný parametr leží mimo interval:

- při spolehlivosti 95% je riziko odhadu 5%,
- při spolehlivosti 99% je riziko odhadu 1%.

# INTERVALOVÉ ODHADY

- a) **Dvoustranné** – určujeme horní i dolní mez intervalu  
(např. u cholesterolu)

$$P(4,37 < \mu < 4,77) = 0,95$$

- b) **Jednostranné**

– levostranné: pouze dolní hranice intervalu

$$P(\mu > 4,37) = 0,975$$



– pravostranné: pouze horní hranice intervalu

$$P(\mu < 4,77) = 0,975$$

U jednostranných odhadů jsou odpovídající kritické hodnoty pro spolehlivost:

a) 95%	$\pm 1,645$
b) 99%	$\pm 2,326$

# Změna kritických hodnot u jednostranného odhadu pro spolehlivost 0,95



# ODHAD PRŮMĚRU ZÁKLADNÍHO SOUBORU (PARAMETRU $\mu$ )

1. Nejlepší bodový odhad parametru  $\mu$  je výběrový průměr  $m$ .
2. V souborech, kde  $n \geq 30$ , se výběrový průměr chová jako náhodná veličina, která má **normální rozdělení**, a to i v případě, že veličina, ze které je průměr vypočítán, normální rozdělení nemá.
3. Výběrový průměr se jako náhodná veličina **vyznačuje variabilitou**. Variabilita výběrových průměrů je menší než variabilita veličiny, z níž jsou průměry počítány. Díky variabilitě je každý výběrový průměr zatížen chybou – jde o tzv. **standardní chybu průměru  $SE_m$** , kterou odhadujeme ze vztahu:

$$SE_m = \frac{s}{\sqrt{n-1}}$$

Závěr:  $95\% \text{ CI} \quad m \pm 1,96 \cdot \frac{s}{\sqrt{n-1}}$

$99\% \text{ CI} \quad m \pm 2,58 \cdot \frac{s}{\sqrt{n-1}}$

- \* V souborech, kde  $n < 30$ , používáme model **Studentova rozdělení** (konstanty 1,96, příp. 2,58 se nahrazují jinými – viz. skripta, str. 25).

# ODHAD PRŮMĚRU ZÁKLADNÍHO SOUBORU (PARAMETRU $\mu$ )

Z vlastností normálního rozdělení vyplývá:


- $P(\mu - 1,96 \sigma_m \leq m \leq \mu + 1,96 \sigma_m) = 0,95$
- $P(\mu - 2,58 \sigma_m \leq m \leq \mu + 2,58 \sigma_m) = 0,99$

úprava nerovnosti uvnitř závorky →

**hranice pro 95 % CI a 99% CI pro  $\mu$**

dolní hranice:  $m - 1,96 \sigma_m$        $m - 2,58 \sigma_m$

horní hranice:  $m + 1,96 \sigma_m$        $m + 2,58 \sigma_m$



Když má náhodná veličina (např. VKP) normální rozložení s průměrem  $\mu$  a odchylkou  $\sigma$  (tj. s rozptylem  $\sigma^2$ ), pak má výběrový průměr  $m$  normální rozložení s průměrem  $\mu$  a odchylkou  $\sigma = \frac{\sigma}{\sqrt{n-1}}$  (tj. s rozptylem  $\frac{\sigma^2}{n-1}$ ).

Protože hodnotu  $\sigma$  neznáme, dosazujeme za ni nejlepší bodový odhad, tj. s.

- Když provedeme náhodný výběr o rozsahu  $n > 30$  a vypočítáme výběrový průměr  $m$ , pak jeho hodnota padne s pravděpodobností 0,95 do vzdálenosti menší než  $1,96 \cdot \frac{s}{\sqrt{n-1}}$  od parametru  $\mu$ .

**JINAK ŘEČENO:**

- Provedeme-li výběr o rozsahu  $n > 30$  a vypočítáme  $m$ , pak parametr  $\mu$  s pravděpodobností 0,95 leží ve vzdálenosti menší než  $1,96 \cdot \frac{s}{\sqrt{n-1}}$  od  $m$ .

**TO ZNAMENÁ, ŽE:**

- Interval s krajními body  $m \pm 1,96 \cdot \frac{s}{\sqrt{n-1}}$  pokrývá hodnotu parametru  $\mu$  s pravděpodobností 0,95. Tento interval se nazývá **Interval spolehlivosti** pro průměr.

# Odhad průměru ZS ( $\mu$ ) - příklad

- Odhadněte průměrnou vitální kapacitu plic mužů ve věku 40-50 let na podkladě výběrového šetření 200 mužů s výsledky:

$$m = 4,83$$

$$s = 0,66$$

$$n = 200$$

# Řešení

$$m \pm \boxed{1,96 \cdot \frac{s}{\sqrt{n-1}}}$$

$$SE = 0,66 / \sqrt{200-1} = 0,66 / 14,107 = \underline{0,04678}$$

Pro spolehlivost 0,95

$$a = m - 1,96 \cdot SE \quad a = 4,83 - (1,96 \cdot 0,04678) = 4,74$$

$$b = m + 1,96 \cdot SE \quad b = 4,83 + (1,96 \cdot 0,04678) = 4,92$$

$$\text{Přesnost} = 1,96 \cdot SE = 1,96 \cdot 0,04678 = 0,09$$

3 formy zápisu: 1/  $\mu = 4,83 \pm 0,09$

2/  $P(4,74 \leq \mu \leq 4,92) = 0,95$

3/ **95% CI (4,74 ; 4,92)**

# Interpretace

- Průměrná vitální kapacita plic v ZS mužů věkové kategorie 40 - 50 let se pohybuje s pravděpodobností 0,95 v rozmezí  $4,83 \pm 0,09$ , tj. od 4,74 do 4,92 litrů.

Proveďte odhad se spolehlivostí 0,99.

# VLASTNOSTI INTERVALOVÉHO ODHADU

## 1) SPOLEHLIVOST

- volí se předem, jde o stanovení pravděpodobnosti, obvykle 0,95 nebo 0,99

## 2) PŘESNOST

- je dána délkou intervalu
- čím kratší je interval, tím je vyšší přesnost odhadu

$$m \pm 1,96 \cdot \frac{s}{\sqrt{n-1}}$$

  
přesnost

- OBĚ VLASTNOSTI SPOLU SOUVISEJÍ
- PŘESNOST ODHADU LZE OVLIVNIT:
  - a) snížením či zvýšením  $P$  (spolehlivosti)
  - b) snížením či zvýšením  $n$  (velikost souboru)
  - c) snížením či zvýšením  $s$  (homogenita souboru)

# Vlastnosti odhadu

- 95%CI (4,74 ; 4,92)    přesnost  $\pm 0,09$
- 99%CI (4,71; 4,95)    přesnost  $\pm 0,12$
- Porovnejme spolehlivost, délku a přesnost intervalů

Příklad: Kolik musíme / nejméně / vyšetřit osob, abychom odhadli průměrnou vitální kapacitu plic s přesností na  $\pm 0,1$  litru při 99% spolehlivosti ?

Řešení: 
$$\frac{\text{přesnost} (0,1)}{s} = \frac{2,58 \cdot SE_m}{0,66} =$$
$$= 2,58 \cdot \frac{1}{\sqrt{n-1}} = 2,58 \cdot \frac{1}{\sqrt{n-1}}$$
$$n - 1 = 2,58^2 \cdot \frac{0,66^2}{0,1^2} = 289,9$$

**n = 291**

Interpretace: Musíme vyšetřit nejméně 291 osob, abychom odhadli průměrnou vitální plic s přesností  $\pm 0,1$  při 99% spolehlivosti.

# ODHAD NEZNÁMÉ PRAVDĚPODOBNOSTI NÁHODNÉHO JEVU (PARAMETRU $\pi$ )

1. Nejlepší bodový odhad pravděpodobnosti je relativní četnost

$$p = \frac{k}{n} \rightarrow \pi$$

$n$  = počet pozorování

$k$  = počet pozorování, u nichž nastal sledovaný jev

2. Pro pravděpodobnosti sice platí binomické rozdělení, ale pokud platí  $n \cdot p \cdot (1 - p) > 9$ , můžeme vycházet z normálního rozdělení.
3. Standardní chybu SE odhadujeme ze vztahu:

$$SE = \sqrt{\frac{p(1-p)}{n}} \quad \text{nebo} \quad SE = \sqrt{\frac{p(100-p)}{n}} \text{ v \%}$$

Závěr: 95% CI  $p \pm 1,96 \cdot \sqrt{\frac{p(1-p)}{n}}$

99% CI  $p \pm 2,58 \cdot \sqrt{\frac{p(1-p)}{n}}$

## Příklad:

Odhadněte pravděpodobnost výskytu zrakové vady u studentů LF na základě výběrového šetření u 200 studentů.

$$n = 200 \quad k = 80 \quad p = 0,40 \text{ (40\%)}$$

- ✿ Než začnete počítat hranice konfidenčního intervalu pomocí kritických hodnot normálního rozložení, nezapomeňte ověřit splnění podmínky, tj. platnost nerovnosti  $n \cdot p \cdot (1 - p) > 9$ .

1) Platnost podmínky

$$n \cdot p \cdot (1-p) > 9$$

$$200 \cdot 0,4 \cdot (1-0,4) > 9$$

$$\underline{\underline{48 > 9}}$$

$$200 \cdot 0,4 \cdot 0,6 > 9$$

$$2) SE = \sqrt{\frac{0,4 \cdot (1-0,4)}{200}} = 0,03464 \doteq 0,035$$

$$0,035 \times 1,96 = 0,0686 \doteq 0,069$$

$$CI \ 95\% (0,33; 0,47)$$

$$p = 0,4 \pm 0,069$$

s 95% pravdepodobností bude znak. rada tříjet (33-47%)

## Příklad:

Ve výběru 100 šestiměsíčních zdravých dětí náhodně vybraných z brněnské populace byl sledován hemoglobin v g%.

$$n = 100 \quad m = 13,10 \quad s = 1,9$$

1. Určete interval, ve kterém se pohybuje hemoglobin u 95% vyšetřených dětí.
2. Odhadněte průměrné množství hemoglobinu v základním souboru se spolehlivostí 0,95. Jaká je přesnost tohoto odhadu?
3. U kolika dětí musíme provést šetření, aby přesnost odhadu průměru byla při spolehlivosti 0,95 nejméně  $\pm 0,2$ .

## Řešení:

1. Určete interval, ve kterém se pohybuje hemoglobin u 95% vyšetřených dětí.

$$m \pm 2s$$

$$\underline{9,3 - 16,9}$$

$$13,10 \pm 2 \cdot 1,9 \dots 13,10 \pm 3,8$$

2. Odhadněte průměrné množství hemoglobinu v základním souboru se spolehlivostí 0,95. Jaká je přesnost tohoto odhadu?

$$m \pm 1,96SE$$

$$SE = \frac{1,9}{\sqrt{99}} = 0,19$$

$$\underline{95\% \text{ CI} (12,73; 13,47)}$$

$$\underline{\text{PŘESNOST}} = \pm 1,96 SE_m = \pm 1,96 \cdot 0,19 = \pm 0,37$$

3. U kolika dětí musíme provést šetření, aby přesnost odhadu průměru byla při spolehlivosti 0,95 nejméně  $\pm 0,2$ .

$$1,96SE = 0,2$$

$$1,96 \cdot \frac{s}{\sqrt{n-1}} = 0,2$$

$$1,96 \cdot \frac{1,90}{\sqrt{n-1}} = 0,2$$

$$m-1 = 1,96^2 \cdot \frac{1,9^2 \cdot 1}{0,2^2}$$

$$m-1 = 346,7$$

$$m \doteq 346,7 + 1$$

$$\underline{m \doteq 348} \quad (\text{cca } 350)$$

# ODHADY PARAMETRŮ - SHRNUTÍ

- **Parametry jsou charakteristiky základního souboru, odhadují se z výběrových charakteristik.**
- **Výběrové charakteristiky se chovají jako náhodné veličiny, výběr od výběru se liší.**
- Pomocí výpočtu standardní chyby (SE) výběrové charakteristiky určujeme interval, ve kterém se hodnota odhadovaného parametru bude s určitou pravděpodobností pohybovat

$$\mu: \quad 95\% \text{ CI } (m - 1,96SE ; m + 1,96SE)$$

$$99\% \text{ CI } (m - 2,58SE ; m + 2,58SE)$$

$$SE_m = \frac{s}{\sqrt{n-1}}$$

- **1,96 a 2,58 jsou konstanty normálního rozložení a vymezují plochu pod frekvenční křivkou, která představuje 95%, resp. 99% pravděpodobnost, že odhadovaný parametr bude spadat do výše uvedených intervalů**

$$\pi: \quad 95\% \text{ CI } (p - 1,96SE ; p + 1,96SE)$$

$$99\% \text{ CI } (p - 2,58SE ; p + 2,58SE)$$

$$SE = \sqrt{\frac{p(1-p)}{n}}$$

# Děkuji za pozornost

---



---