

Induktivní statistika

Odhady

Odhady

- bodové odhady
 - intervalové odhady
 - konstrukce intervalu spolehlivosti pro průměr
 - odhady podílů (kategoriální proměnné)
-

Odhady

- v příkladech v předchozích přednáškách jsme znali hodnoty průměru a rozptylu populace
 - obvykle tomu ale bývá přesně naopak: **známe hodnoty (statistiky) výběru a neznáme hodnoty (parametry) populace**
 - ty chceme z výběru **odhadnout**
-

Odhady

- 2 typy odhadů: bodové a intervalové
 - **bodový odhad**: použijeme průměr vzorku a odhadneme, že se rovná průměru populace
-

Bodový odhad

- bodový odhad je problematický v tom, že dva různé výběry nám mohou dát dva různé odhady
 - bodový odhad **neobsahuje** žádnou **informaci** o jeho **přesnosti** či **spolehlivosti**
 - na čem závisí přesnost odhadu?
-

Bodový odhad

přesnost odhadu závisí na dvou charakteristikách

- **velikost výběru** (čím větší n , tím menší výběrová chyba)
 - **variabilita hodnot v populaci** (čím vyšší, tím vyšší i výběrová chyba)
-

Intervalový odhad

- poskytuje rozsah (interval) hodnot, který s určitou pravděpodobností obsahuje hledanou hodnotu parametru
-

Intervalový odhad

je založen na:

- bodovém odhadu
- velikosti výběru
- variabilitě znaku v populaci (známé nebo rovněž odhadované)

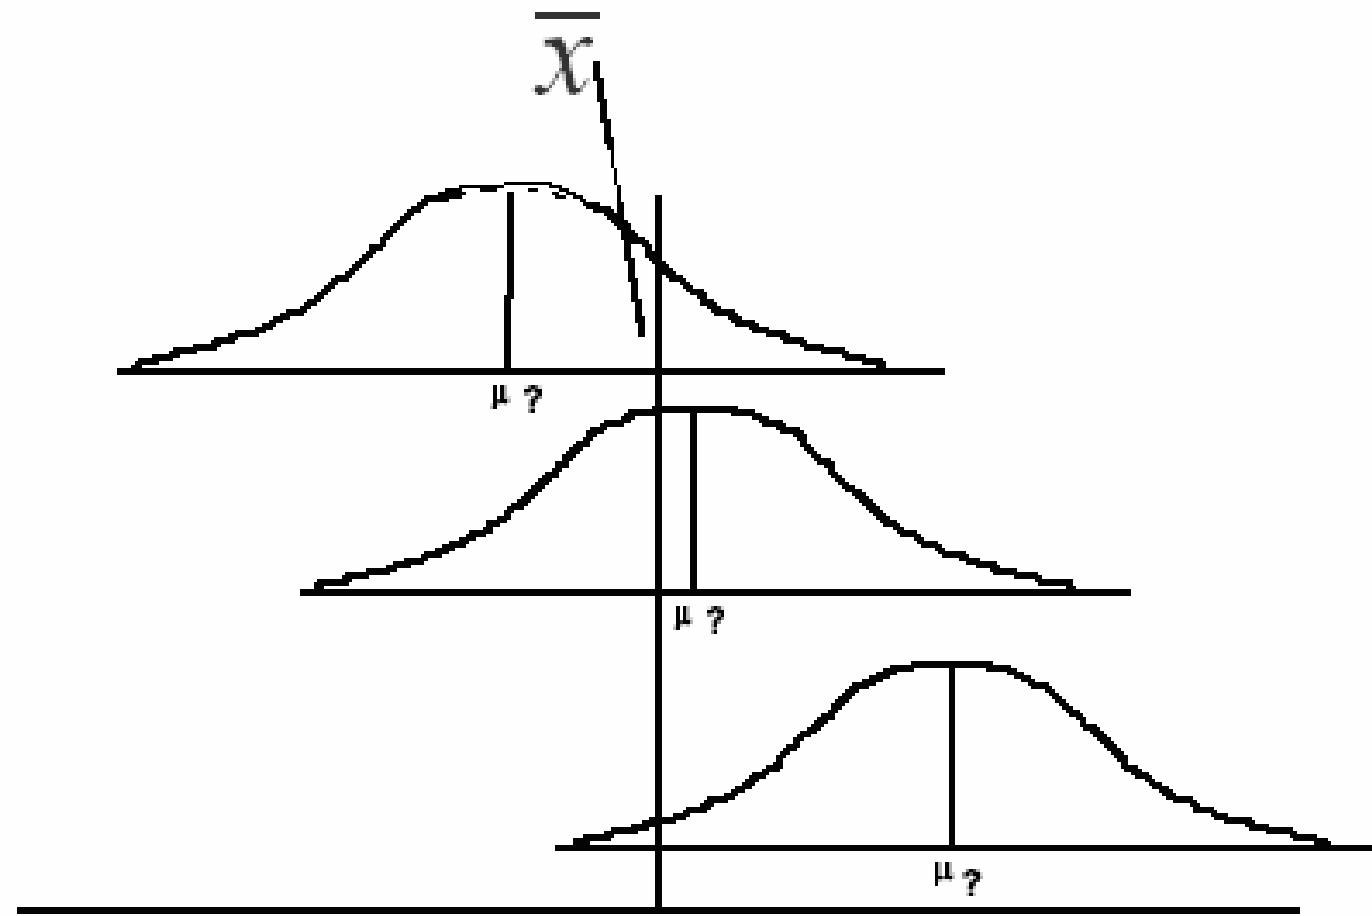
Intervalový odhad

ptáme se: jaká je hodnota μ ?

Intervalový odhad

- ptáme se: **jaká je hodnota μ ?**
 - výběrový průměr určité hodnoty může pocházet z populací o různých průměrech
 - proto **nemůžeme jednoznačně určit hodnotu μ**
-

Intervalový odhad



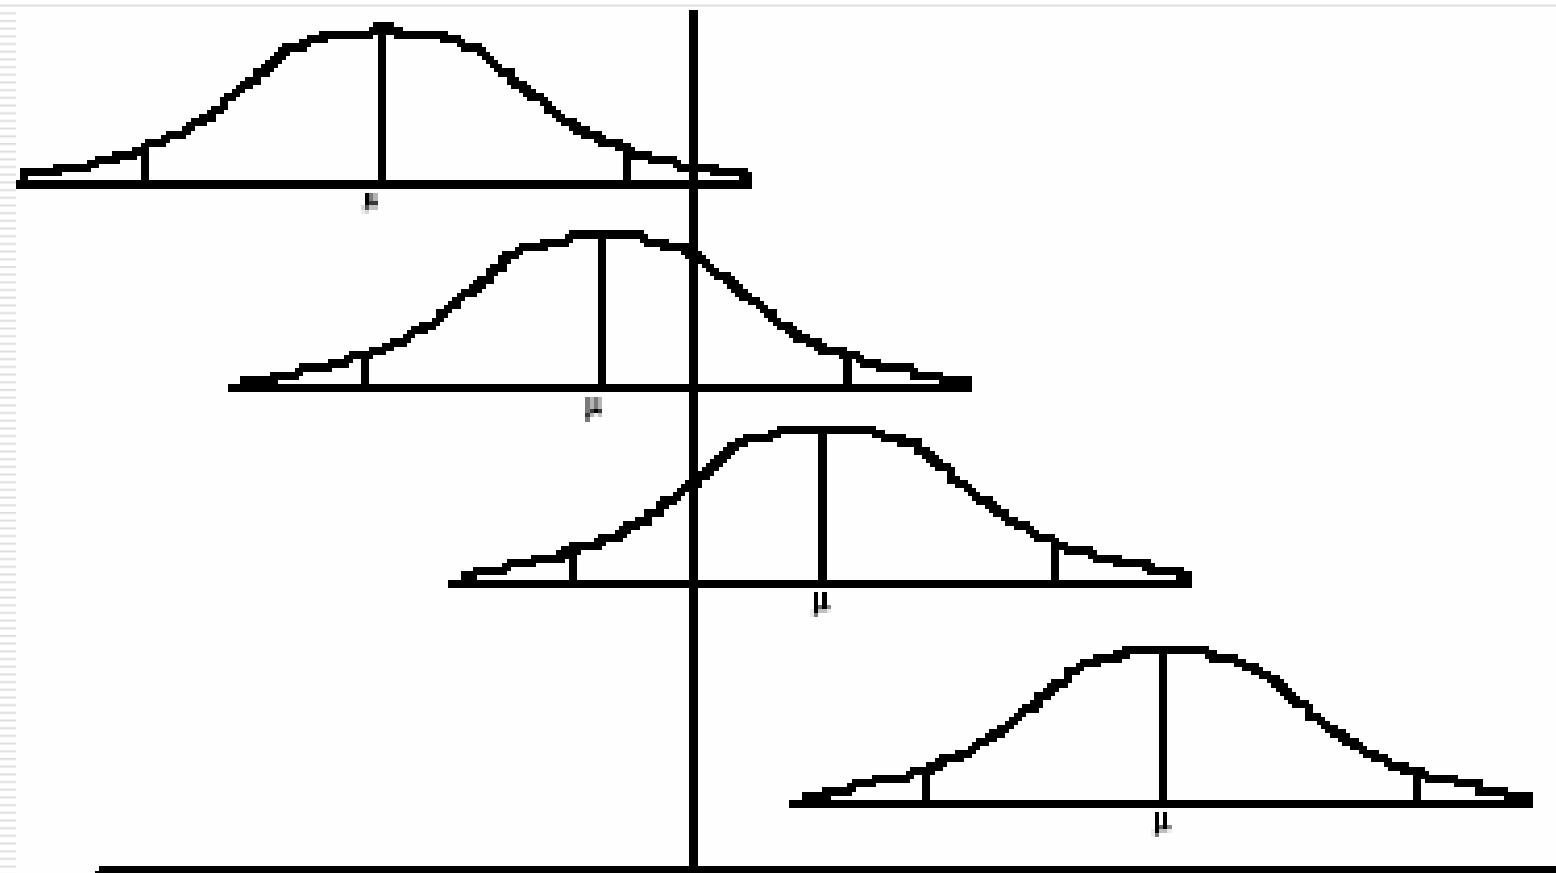
Intervalový odhad

- takže se místo toho snažíme určit, jaký je **možný rozsah hodnot μ**
 - jaké populace (tj. s jakou hodnotou průměru) by mohly být pravděpodobným zdrojem našeho vzorku?
-

Intervalové odhady

- ze které populace nejpravděpodobněji pochází výběr, jehož průměr je v následujícím grafu naznačen svislou čarou?

RVP pro populace I-IV



I
II
III
IV

Intervalové odhady

výběr pochází

- nejpravděpodobněji z populace II nebo III
 - méně pravděpodobně z populace I
 - a velmi málo pravděpodobně z populace IV
-

Intervalové odhady

- intervalový odhad spočívá v konstrukci tzv. **intervalu spolehlivosti** (confidence interval) = rozsahu hodnot, ve kterém s určitou pravděpodobností leží průměr populace
-

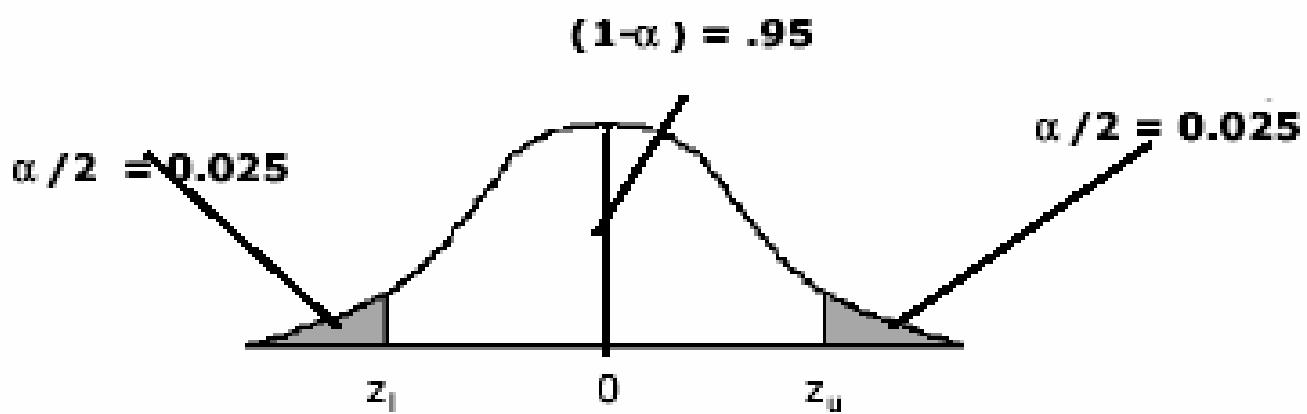
Interval spolehlivosti

- nejprve je třeba si **stanovit tuto pravděpodobnost** – tj. úroveň přesnosti(spolehlivosti);
 - obvyklá je např. **95%** - snažíme se najít interval hodnot, ve kterém s 95% pravděpodobností leží průměr populace
 - pak jde o tzv. **95% interval spolehlivosti**
-

Interval spolehlivosti

- poté najít hodnotu z pro tuto pravděpodobnost – tj. rozsah, ve kterém bude ležet středních 95% hodnot (výběrových průměrů)
 - 2,5% na každé straně rozdělení
-

Interval spolehlivosti



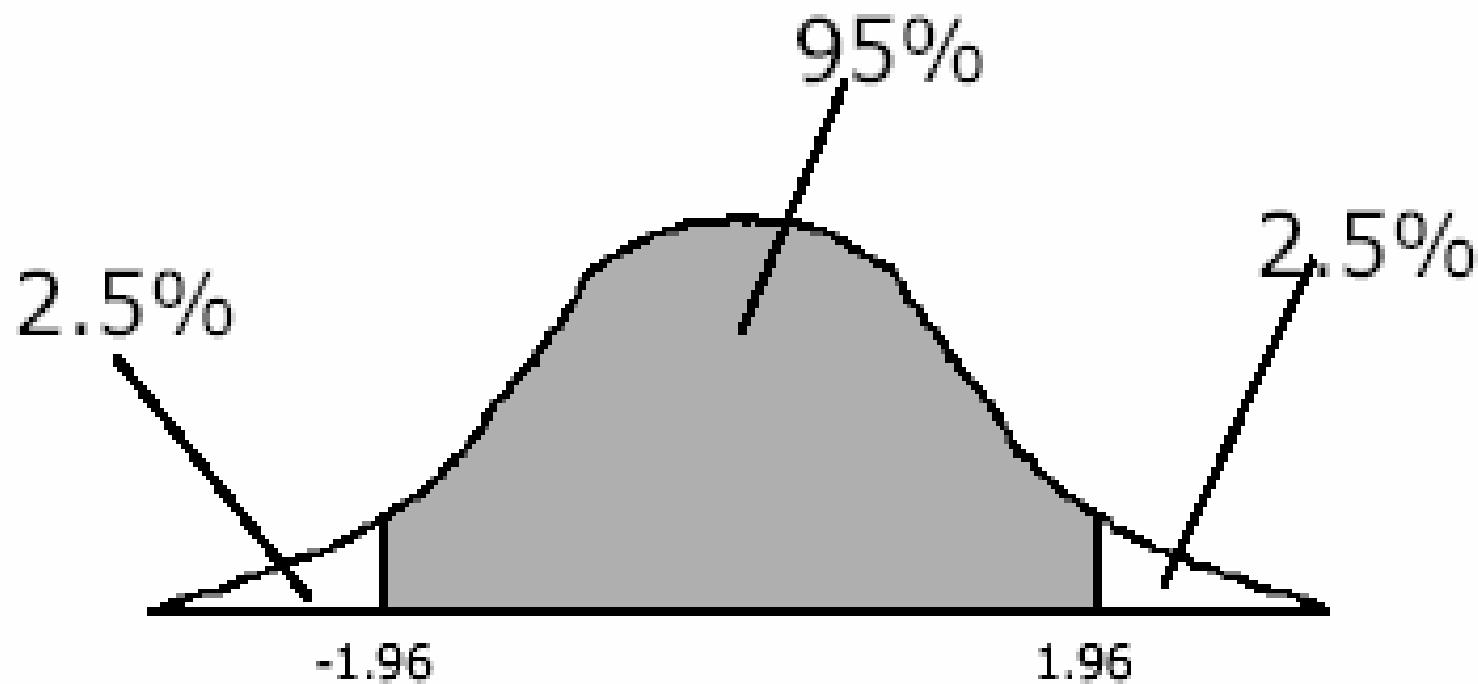
Interval spolehlivosti

tomu odpovídají hodnoty

$$z = -1,96$$

$$z = 1,96$$

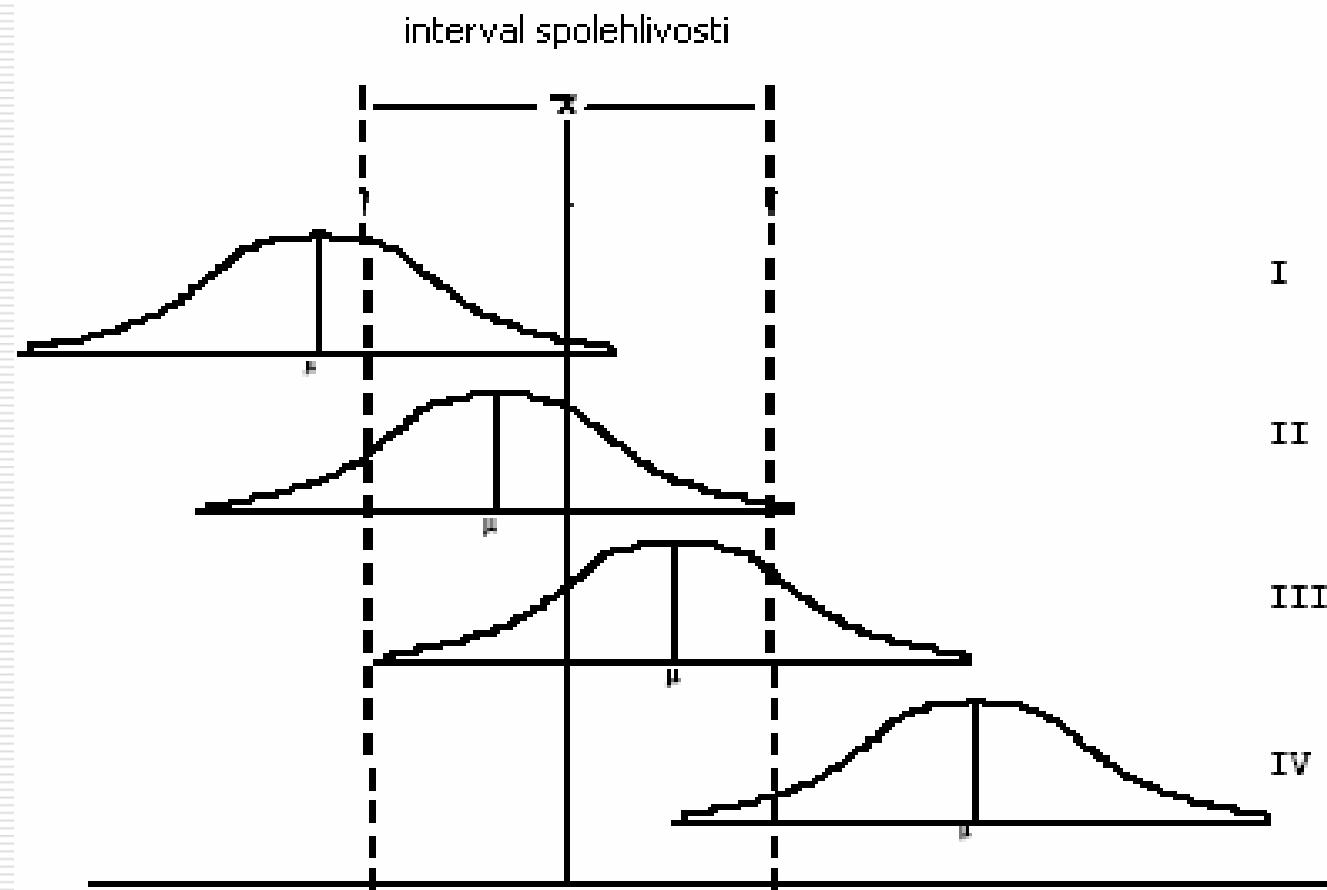
Interval spolehlivosti



Interval spolehlivosti - výpočet

$$\bar{x} \pm z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}$$

Interval spolehlivosti



Interval spolehlivosti

- interpretace intervalu spolehlivosti:
pokud bychom z populace vybrali 100
náhodných výběrů o velikosti n a pro
každý z nich sestrojili tento interval,
95 intervalů by obsahovalo průměr
populace a 5 nikoliv
 - opatrně můžeme říct : máme 95%
pravděpodobnost, že se v tomto
intervalu nachází průměr populace
-

Interval spolehlivosti

- oblíbený omyl:
 - v 95% intervalu spolehlivosti leží 95% hodnot populace (NEPLATÍ!)

 - kromě 95% intervalu spolehlivosti se používá také např. 99% a 90% pravděpodobnost
-

Příklad

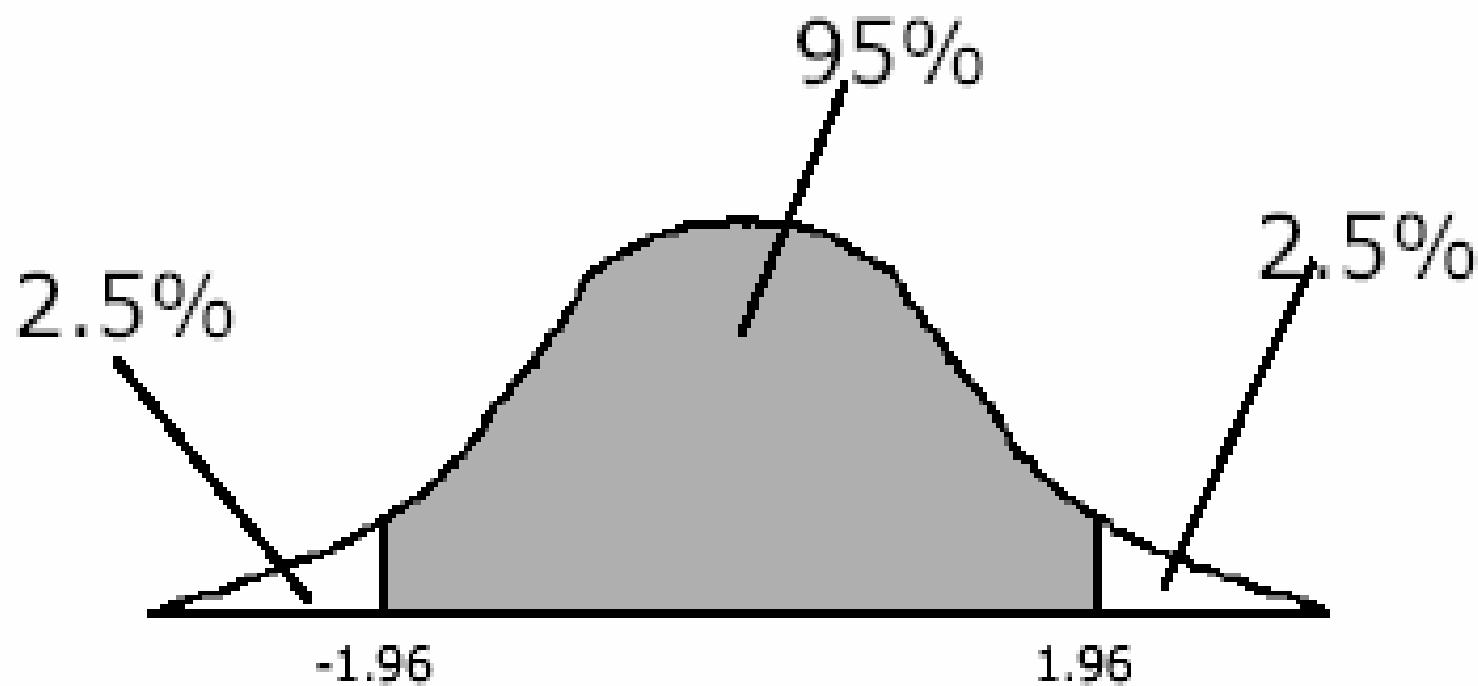
- náhodný výběr 36 dětí hospitalizovaných bez matky v raném věku (do 6 měsíců), průměrné IQ vzorku = 96
 - na základě tohoto zjištění odhadněte průměrné IQ populace dětí hospitalizovaných bez matky v raném věku (sestavte 95% interval spolehlivosti)
-

Příklad

□ Postup:

- bodový odhad: $\mu=96$
 - výpočet výběrové chyby (směrodatné odchyly RVP):
$$\sigma/\sqrt{n} = 15/\sqrt{36} = 15/6 = \mathbf{2,5}$$
 - stanovení úrovně spolehlivosti: 95%
 - najít hodnotu z pro 95% pravděpodobnost
-

Příklad



Příklad

- v tabulce normálního rozdělení najdeme hodnoty z
 - hodnoty z pro 99% : 1,96 a -1,96
-

Příklad

- k výběrovému průměru přičteme (pro horní hranici intervalu) a odečteme (pro spodní hranici) výběrovou chybu, vynásobenou hodnotou z
-

Příklad

$$\text{CI } (\mu) = \underline{x} + z \left(\sigma / \sqrt{n} \right)$$

$$\text{CI } (\mu) = 96 + 1,96 * 2,5 = 96 + 4,9 = 100,9$$

$$\text{CI } (\mu) = 96 - 1,96 * 2,5 = 96 - 4,9 = 91,10$$

95% interval spolehlivosti je 91,1 – 100,9

Interval spolehlivosti

□ **hodnoty z pro nejčastěji užívané pravděpodobnosti:**

- 90% (zbývá 5% + 5%) $z = +/- 1,645$
 - 95% (zbývá 2,5% + 2,5%) $z = +/- 1,96$
 - 99% (zbývá 0,5% + 0,5%) $z = +/- 2,57$
-

Příklad 2

- pro odhad průměru z předchozího příkladu sestrojte 99% interval spolehlivosti
-

Příklad 2

$$\text{CI} (\mu) = x \pm z (\sigma / \sqrt{n})$$

$$\text{CI} (\mu) = 96 + 2,57 * 2,5 = 96 + 6,4 = 102,4$$

$$\text{CI} (\mu) = 96 - 2,57 * 2,5 = 96 - 6,4 = 89,6$$

95% interval spolehlivosti je 89,6 – 102,4

Odhady podílů

- u kategoriálních proměnných nemůžeme počítat průměry
 - odhadujeme proto **podíly** jednotlivých kategorií proměnné
-

Odhady podílů

- např. podíl kuřáků v populaci českých adolescentů
 - podíl pacientů s rakovinou plic, kteří přežijí 5 let od diagnózy
 - podíl chlapců mezi dětmi s poruchou pozornosti
-

Odhady podílů

- pokud zkoumáme místo celé populace pouze výběr z ní, nezajímá nás totik, jaký je podíl kategorií proměnné ve výběru (četnost p)
 - ale spíše jaký je skutečný podíl v populaci – četnost π
-

Odhady podílů

- při dostatečně velkém n platí i pro rozdělení podílů centrální limitní věta
- rozdělení výběrových podílů je normální rozdělení, s **průměrnou četností π** a směrodatnou odchylkou (výběrovou chybou)

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

Příklad 4

- chceme zjistit, jaká je podpora zachování hlavního nádraží v Brně na stávajícím místě
 - náhodný výběr z populace brněnských voličů ($n=1000$ osob)
 - 585 osob se vyjádřilo pro ($p=0,585$)
 - odhadněte s 95% spolehlivostí podporu zachování nádraží v populaci brněnských voličů
-

Odhady podílů

- interval spolehlivosti pro podíly se spočítá podobně jako pro průměry:

$$p \pm z_{1-\frac{\alpha}{2}} \sigma_p$$

Odhady podílů

- nemůžeme však spočítat výběrovou chybu, protože neznáme π
 - v tomto případě je však možné dosadit místo toho p a přitom použít normální rozdělení (pokud je $n > 30$)
 - pokud je $n < 30$, pak dosadíme místo π hodnotu 0,5
-

Příklad 4

$p=0,585$

$z=1,96$

$SE(p)=\sqrt{[0,585(1-0,585)/1000]}$
 $=0,0156$

interval spolehlivosti

$$0.585 \pm 1.96(0.0156)$$

$$0.585 \pm 0,0305$$

--- přesnost odhadu je $\pm 3\%$

Příklad 4

- s 95% pravděpodobností je podíl osob souhlasících se zachováním hlavního nádraží na stávajícím místě **mezi 55.4% a 61.6%**
 - tj. máme 95% pravděpodobnost, že kdyby se v době průzkumu hlasovalo, bude většina pro
-

Odhady podílů

vztah mezi velikostí vzorku a přesností odhadu

- n=100 $\pm 10\%$
 - n=200 $\pm 7\%$
 - n=400 $\pm 5\%$
 - n=1000 $\pm 3\%$
 - n=2400 $\pm 2\%$
 - n=9600 $\pm 1\%$
-

Odhady podílů

- požadovaná velikost vzorku roste mnohem rychleji než spolehlivost odhadu (pro zdvojnásobení spolehlivosti je nutné asi čtyřnásobně zvětšit vzorek)
 - důležité při plánování výzkumu – jakou přesnost potřebujeme? jaké budou náklady?
 - podobný vztah platí pro odhad průměrů
-

Kontrolní otázky

- 2 typy odhadů
 - na čem závisí šířka intervalu spolehlivosti? (*není nutno znát zpaměti vzorce, ale je třeba chápav princip výpočtu*)
 - vztah velikosti výběru a spolehlivosti odhadu
-

Literatura

- Hendl: kapitoly 4 a 5
-