

## Statistická indukce a intervalové odhady

Je k výběru náhodného vzorku třeba, aby byly splněny následující podmínky (ano-ne)?

1. Aby byly skóry v populaci normálně rozložené.
2. Každý jedinec v populaci (jednotka zkoumání) musí mít stejnou pravděpodobnost, že bude vybrán do vzorku.
3. Výběr kteréhokoli jedince (jednotky zkoumání) musí být zcela nezávislý na výběru kohokoli jiného.

U Wechslerových inteligenčních škál jsou skóry normálně rozložené s  $\mu=100$  a  $\sigma=15$ . Představte si, že jsme otestovali náhodný vzorek 9 lidí, spočítali jejich průměrné skóre a celou proceduru zopakovali 1000krát.

15. Odhadněte směrodatnou odchylku těchto 1000 průměrů.
16. Zhruba jaká část (v %) těchto výběrových průměrů s  $n = 9$  by byla vyšší než 105? A než 110?
17. Zhruba jaká část (v %) těchto výběrových průměrů s  $n = 9$  by byla mezi 95 a 105? A mezi 90 a 110?
18. Budou tyto výběrové průměry normálně rozložené?
19. Jaký je rozptyl tohoto rozložení výběrových průměrů?
20. Kdyby  $n = 225$  (místo 9), jaká by byla hodnota směrodatné chyby?
21. Kdyby  $n = 225$ , jaká část (v %) výběrových průměrů by se pohybovala nejvýše jeden bod od 100, tj. mezi 99 a 101?
23. Bude rozložení výběrových průměrů přibližně normální i tehdy, kdyby rozložení skóre v populaci nebylo normální?
24. Který matematický teorém tvrdí, že výběrové rozložení průměrů se s rostoucím  $n$  blíží normálnímu, bez ohledu na tvar rozložení proměnné v populaci?
26. Známe-li  $\sigma$ , platí, že  $m \pm 1,96\sigma_m$  tvoří 95% interval spolehlivosti pro jakékoli  $n$ ?
27. Předpokládejme proměnnou s normálním rozložením a známou  $\sigma$ . Pokud vybereme náhodně 2 vzorky o  $n = 100$  a na obou spočítáme 68% interval spolehlivosti, budou tyto dva intervaly shodné?

Jsou následující páry ekvivalentními výrazy?

28. (1) směrodatná chyba  $\bar{X}$  a (2) směrodatná odchylka výběrového rozložení  $\bar{X}$ .
29. (1)  $\sigma^2/n$  a (2) směrodatná chyba  $\bar{X}$ .
30. (1)  $\sigma x^2$  a (2) rozptyl výběrového rozložení  $\bar{X}$ .
31. (1) populační rozptyl  $\sigma^2$  a (2)  $n$  krát  $\sigma x^2$ .
32. (1) průměr výběrového rozložení  $\bar{X}$  a (2)  $\sigma x^2$ .
34. (1)  $\mu$  a (2)  $(\sum X)/n$ .
35. (1)  $\bar{X}$  a (2)  $(\sum x)/n$ .
36. (1)  $s^2$  a (2)  $\sum x^2/(n-1)$ .

37. Pokud budeme provádět mnoho různých studií na různá témata a vždy v nich budeme k odhadovaným statistikám tvořit 95% intervaly spolehlivosti, kolik z těchto intervalů asi obsahuje odhadovaný parametr?

38. V kterém z následujících případů by nárůst velikost vzorku způsobil největší zúžení intervalu spolehlivosti?

- a) z 5 na 25
- b) z 10 na 30
- c) ze 40 na 60

39. Který typ odhadu lépe sděluje přesnost odhadu, bodový, nebo intervalový?

11.1 z se má k  $\sigma_m$  jako  $t$  se má k

- a)  $\sigma$
- b)  $\sigma^2$
- c)  $s$
- d)  $s_m$

11.4 Za jakých podmínek platí  $\sigma = \sigma_m$  ?

A. Provádíme výzkum toho, zda či jak dlouhodobá hospitalizace škodí dětem ve vývoji. Jednou z výzkumných otázek je, zda nedochází k zabřždění vývoje intelektu. Pro tento účel jsme 30 dlouhodobě hospitalizovaným dětem v mladším školním věku rozdali inteligenční test s následujícími výsledky:  $m_{IQ}=98$ ,  $s_{IQ}=11$ .

i) Stanovte 95% interval spolehlivosti pro průměrnou hodnotu inteligence v populaci dlouhodobě hospitalizovaných dětí v mladším školním věku ( $\mu_{IQ}$ ).

ii) Dále jsme zjistili, že délka hospitalizace (ve dnech) koreluje s IQ,  $r=-0,1$ . Stanovte 95% interval spolehlivosti pro korelaci mezi délkou hospitalizace a IQ ( $\rho$ ) (viz Hendl 252, pozor na chybu, výběrové rozložení Fischerova Z je normální, nikoli  $t$ )

*řešení na následující straně*

## Odpovědi

1. ne
2. ano
3. ano
15. 5
16.  $z=(105-100)/5=1$  ... 16%; pro 110 je to 2,3%
17. cca 68%; 95%
18. ano, přibližně ano
19. 25
20. 1
21. cca 68%
23. ano
24. centrální limitní teorém
26. ano, ale hodnota  $\sigma_m$  se pro různá  $n$  liší
27. ne, protože v obou případech budeme interval spolehlivosti konstruovat okolo jiného výběrového průměru.
28. ano
29. ne,  $\sigma^2/n = \sigma_{\bar{x}}^2$  a ne  $\sigma_{\bar{x}}$
30. ano
31. ano
32. ne
34. ne, (2) je  $m$ ,  $\bar{x}$
35. ne, suma odchylek od průměru je 0
36. ano
37. 95%
38. a)
39. intervalový

11.1 d)  
11.4  $n = 1$

A.  
I.

$m_{IQ}=98, s_{IQ}11, n=30$

Pokud bychom chtěli využít receptář Oseckých, pak budeme hledat sekci li (I výběr, intervalová proměnná) a v ní recept na proceduru I  $\mu$  S ( $\mu$ -průměr, interval Spolehlivosti)

Hledáme interval spolehlivosti se středem v  $m$  a takovou šířkou, aby s 95% pravděpodobností zahrnoval  $\mu$ .

1.  $\alpha=0,05$  ... 95% interval spolehlivosti

2. průměr má výběrové rozložení  $t$  s průměrem  $m$  a výběrovou chybou  $s_0=s/\text{odm}(n)$

$$s_0=11/5,5=2$$

interval tedy bude mít podobu  $[m-X.s_0 ; m+X.s_0]$ , kde  $X$  je hodnota  $t$ -rozložení odpovídající 2,5. a 97,5. percentilů (kvantil 0,025 a 0,975; tj.  $\alpha/2$  a  $1-\alpha/2$ ), mezi nimiž se nalézá 95% rozložení výběrových průměrů. Naše  $t$ -rozložení má  $\nu = n - 1 = 29$  stupňů volnosti.

Kvantily nalezneme nejnázne pomocí Excelu nebo v tabulkách  $t$ -rozložení

Protože  $t$ -rozložení je symetrické  $_{\alpha/2}t(\nu) = -_{1-\alpha/2}t(\nu)$ . Excel umí hledat jen  $_{\alpha/2}t(\nu)$ .

$$(X) = _{\alpha/2}t(\nu) = \text{TINV}(\alpha; \nu) = \text{TINV}(0,05;29) = 2,05 \quad (\text{ta } \alpha \text{ místo } \alpha/2 \text{ je ve vzorci proto, že excel si}$$

z nějakého důvodu dodanou hodnotu v tomto vzorci sám vydělí dvěma)

3. Zkonstruujeme interval spolehlivosti

$$[m-X.s_0 ; m+X.s_0] = [98-2.05*2; 98+2.05*2] = [93,9 ; 102,1]$$

II.

$$r = -0,1 ; n = 30$$

Pro tohle recept u Oseckých nenaleznete, ale zkuste to porovnat s receptem I p H na str. 19.

Postup je stejný jako v předchozím případě, pouze s jedním krokem navíc – z-transformací.

1.  $\alpha=0,05$  – 95% interval spolehlivosti

2. výběrové rozložení korelace neznáme (Hendl 252). Když se ale korelační koef. urč. způsobem přetransformuje, pak výběrové rozložení této transformované statistiky známe – jde o normální rozložení s  $s_0=1/\text{odm}(n-3)$ . Jde o Fisherovu z-transformaci:

$z = 0,5 \ln((1+r)/(1-r))$  (to je totéž, co funkce hyperbolický arkustangtens (arctgh), není nutné to počítat – v excelu to počítá funkce FISHER(r))

Takže v našem případě:

$z = \text{FISHER}(-0,1) = -0,10034$  (čím dále od nuly, tím více se bude  $z$  a  $r$  lišit, maximem  $z$  je nekonečno)

interval tedy bude mít podobu  $[z - X * s_0 ; z + X * s_0]$ , kde  $X$  je hodnota normálního rozložení odpovídající 2,5. a 97,5. percentilu (kvantil 0,025 a 0,975; tj.  $\alpha/2$  a  $1 - \alpha/2$ ), mezi nimiž se nalézá 95% rozložení výběrových z-transformovaných korelací.

$$s_0 = 1 / \sqrt{30 - 3} = 0,19$$

Kvantily nalezneme nejnázem pomocí excelu nebo v tabulkách normálního rozložení (nebo si vzpomeneme na 1,96 :-)

Protože normální rozložení je symetrické  $\alpha/2U = -1 - \alpha/2U$ .

$$(X) = \alpha/2U = \text{NORMSINV}(\alpha/2) = \text{NORMSINV}(0,025) = -1,96 \text{ (nás zajímá jen abs. hodnota)}$$

3. Zkonstruujeme interval spolehlivosti

$$[z - X * s_0 ; z + X * s_0] = [-0,10037 - 1,96 * 0,19 ; -0,10037 + 1,96 * 0,19] = [-0,47 ; 0,27]$$

Tohle je ale interval v z-transformovaných hodnotách, musíme tedy ještě jeho meze transformovat zpět na koeficient  $r$ . K tomu slouží v Excelu  $\text{FISHERINV}$  (neboli  $\text{TGH}$ )

$$[\text{fisherinv}(-0,47) ; \text{fisherinv}(0,27)] = \mathbf{[-0,51 ; 0,28]}$$