

Inferenční statistika - úvod

- z-skóry
- normální rozdělení
- pravděpodobnost
- rozdělení výběrových průměrů

Pravděpodobnost

- postupy induktivní statistiky vycházejí z teorie pravděpodobnosti
- **pravděpodobnost**, že nastane určitý výsledek, **definujeme** jako podíl
počet pokusů, kdy nastal jev A

delěno

celkový počet jevů

- pravděpodobnost bývá uváděna nejčastěji jako **podíl** (0,33), **zlomek** (1/3) nebo **procento** (33,3%)
- pravděpodobnost určitého jevu nebo třídy jevů můžeme odhadnout z rozdělení hodnot (četností)

Pravděpodobnost - příklady

- představme si, že máme krabici se 40 očíslovanými žetony s čísly 1 – 5
- v tabulce jsou uvedeny absolutní i relativní četnosti jednotlivých čísel žetonů

- hodnoty jsou v pořadí: číslo žetonu, absolutní četnost, relativní četnost

Tabulka:

□ 1 4 0,10

□ 2 8 0,20

□ 3 16 0,40

□ 4 10 0,25

□ 5 2 0,05

- vaším úkolem je vytáhnout 1 žeton

- **jaká je pravděpodobnost, že vytáhnete žeton s číslem 3?**

- **$p(3) = f/N = 16/40 = 0,40$**
nebo 2/5 či 40%

- Jaká je pravděpodobnost, že vytáhnete žeton s číslem vyšším než 2?**

$$p(X > 2) = ?$$

$$0,05 + 0,25 + 0,40 = \mathbf{0,70}$$

tj. 70%

- Jaká je pravděpodobnost, že vytáhnete žeton s číslem nižším než 5?**

$$p(X < 5) = ?$$

$$0,10 + 0,20 + 0,40 + 0,25 = \mathbf{0,95}$$

tj. 95%

- Jaká je pravděpodobnost, že vytáhnete žeton s číslem nižším než 4 a vyšším než 1?**

$$p(4 > X > 1) = ?$$

$$0,20 + 0,40 = \mathbf{0,60}$$

tj. 60%

Pravděpodobnost

- pravděpodobnost odpovídá hustotě **oblasti pod křivkou** pro daný interval

Z-skóry

- transformace hodnot proměnné
- umožňují najít a popsat **pozici každé hodnoty** v rámci rozdělení hodnot
- a také **srovnávání hodnot** pocházejících z měření **na rozdílných stupnicích**
- hrubé skóry jsou převedeny na **standardizovanou stupnici** (jednotkou je směrodatná odchylka)

Z-skóry - příklad

- např. skóry ze dvou testů – biologie a psychologie
- v testu z biologie byl průměr celého ročníku $m=18$ ($sd=6$)
- v testu z psychologie byl průměr celého ročníku $m=500$ ($sd=100$)
- student získal 26 bodů z biologie a 620 z psychologie. Ve kterém předmětu byl lepší?
- přímé porovnání není snadné – skóry z obou testů mají rozdílné průměry i směrodatné odchylky
- z skór = odchylka skóru od průměru vzhledem k velikosti směrodatné odchylky
- $z = \text{odch. od průměru} / \text{směr. odch.}$
- skór z biologie: $(26-18)/6 = 1,33$
- skór psychologie: $(620-500)/100=1,2$
- v biologii byl student lepší: 1,33 směrodatné odchylky nad průměrem

Z-skóry

- z-skór přesně udává pozici každé hodnoty vzhledem k ostatním hodnotám
- znaménko (+ nebo -) ukazuje, zda je hodnota nad nebo pod průměrem rozdělení
- hodnota z-skóru upřesňuje, kolik směrodatných odchylek byla hodnota od průměru vzdálena
- průměr rozdělení z-skóru je vždy 0

- směrodatná odchylka je 1

Z-skóry

vzorec pro výpočet z-skóru hodnoty X

- u populace: $z = (X_i - \mu) / \sigma$

- u vzorku: $z = (X_i - m) / s$

Z-skóry

- podobně můžeme i z-skór převést na hrubý skór, známe-li průměr a směrodatnou odchylku
- např. u stupnice IQ
- $\mu = 100, \sigma = 15$
- pro osobu se $z = -3$ (3 směrodatné odchylky pod průměrem) bude IQ ?

$$X = Z * \sigma + \mu$$

$$X = -3 * 15 + 100$$

$$X = 55$$

Rozdělení z-skórů

- tvár** rozdělení z-skórů je **stejný** jako tvar původního rozdělení hrubých skórů
- průměr je 0, směrodatná odchylka 1
- transformace změní jen označení hodnot na ose X

Normální rozdělení

- normální rozdělení je symetrické, unimodální, zvonovitého tvaru
- označuje se i jako Gaussova křivka

- 34.13% skóreů spadá mezi průměr a 1 směr. odchylku
- 13.59% hodnot spadá mezi 1. a 2. směr. odchylku
- 2.28% hodnot spadá mezi 2. a 3. směr. odchylku

Normální rozdělení

- tabulka normálního rozdělení (z rozdělení)
- důležitý nástroj, obvykle jako appendix v učebnicích statistiky (spolu s dalšími tabulkami)
- umožňuje zjistit hustotu oblasti pod křivkou (tj. pravděpodobnost) pro jednotlivé z-skóre

Normální rozdělení - příklady

- postup při zjišťování **pravděpodobnosti** z tabulky:
 - načrtnout si normální rozdělení, s hodnotou průměru a směr. odch.
 - zakreslit hledanou hodnotu (v přibližné vzdálenosti od průměru), vystínovat hledanou oblast
 - převést hodnotu X na z-skór
 - najít v tabulce pravděpodobnost

Normální rozdělení - příklady

- Kolik procent osob z populace má IQ 130 nebo vyšší? ($\mu = 100$, $\sigma = 15$)

otázku je možno formulovat i jako:

- Jaká je pravděpodobnost, že náhodně vybraná osoba z populace bude mít IQ 130 nebo vyšší? ($\mu = 100$, $\sigma = 15$)
- $z = (130 - 100)/15$
- $z = 2$**

z tabulky z-rozdělení plyne, že $p = 0.0228$ tj. **2,3%**

Normální rozdělení - příklady

Jaká je pravděpodobnost, že náhodně vybraná osoba z populace bude mít IQ 85 nebo nižší?

$$z = (100-85)/15$$

$$z = -1$$

$p = 0.5 - 0.3413 = \mathbf{0.1587}$

tj. **15,9%**

Normální rozdělení - příklady

postup při zjišťování **z-skóru** z tabulky:

- načrtnout si normální rozdělení
- vystínovat oblast odpovídající zadané pravděpodobnosti
- v tabulce vyhledat příslušný z-skór
- vypočítat z něj hrubý skór

Normální rozdělení - příklady

Jakou minimální hodnotu IQ musí člověk mít, aby patřil mezi 5% osob s nejvyššími hodnotami IQ?

$p = 0.05$

Normální rozdělení

z tabulky: **$z = 1.645$**

$X = (1.645) \cdot (15) + 100 = \mathbf{124.675}$

musí mít IQ 124 bodů

Normální rozdělení - příklady

pomocí tabulky normálního rozdělení je možno nalézt také hodnotu percentilu

příklad: kolik procent osob má nižší hodnoty IQ než člověk s IQ 130?

$z = 2$

z tabulky: pro $z = 2$

$p = 0.4772$ (+ 50% pod průměrem)

97.72% osob má nižší skór než IQ 130

Rozdělení výběrových průměrů

- cílem induktivní statistiky je odhadnout parametry populace z charakteristik vzorku (výběrového souboru)
- např. odhadem průměru populace bude průměr vzorku
- odhad je vždy zatížen určitou **výběrovou chybou**

Rozdělení výběrových průměrů

- předpokládejme, že z jedné populace vybereme 3 různé vzorky
- budou se nejspíš navzájem lišit ve tvaru rozdělení hodnot, průměru i variabilitě
- jak se rozhodneme, který z nich zvolit pro odhad průměru populace ??

Rozdělení výběrových průměrů

- pokud bychom spočítali průměry ze všech možných výběrů o určité velikosti n , budou tvořit tzv. **rozdělení výběrových průměrů** (sampling distribution)

Rozdělení výběrových průměrů

- příklad**: populace hodnot 2, 4, 6, 8
- průměr $\mu = 5$
- předpokládejme, že průměr neznáme a pokoušíme se ho odhadnout ze vzorku $n=2$
- v tabulce jsou uvedeny všechny možné výběrové soubory (v pořadí výběr, první skór, druhý skór, průměr vzorku)

Tabulka:

1	2	2	2
2	2	4	3
3	2	6	4
4	2	8	5
5	4	2	3
6	4	4	4
7	4	6	5
8	4	8	6
9	6	2	4

10	6	4	5
11	6	6	6
12	6	8	7
13	8	2	5
14	8	4	6
15	8	6	7
16	8	8	8

- jaká je pravděpodobnost, že z této populace vybereme vzorek s průměrem vyšším než 7?
- v rozdělení výběrových průměrů je takový vzorek jen 1 ze 16 – tj. pravděpodobnost takového vzorku je $1/16 = 0.0625$, tj. 6%
- jaká je pravděpodobnost, že náhodně vybraný vzorek 2 čísel z této populace bude mít průměr roven průměru populace, tj. 5?
- tato pravděpodobnost je $4/16$, tj. 25%

Rozdělení výběrových průměrů

- většina populací i vzorků je mnohem větší
- ale existují určité základní vlastnosti rozdělení výběrových průměrů (RVP)
- tvar** – RVP se při dostatečně velkém vzorku (30 a více) blíží **normálnímu rozdělení**
- průměr** tohoto rozdělení (=průměr průměrů všech teoretických výběrů) je roven **průměru populace**
- označuje se také jako očekávaná hodnota průměru vzorku
- variabilita** – směrodatná odchylka RVP se označuje jako výběrová nebo standardní chyba průměru (standard error)
- jde o směrodatnou odchylku výběrových průměrů od průměru populace
- ukazuje, jak spolehlivý je odhad populačního průměru z průměru vzorku – tj. jak velkou chybou je odhad zatížen
- velikost výběrové chyby je dána dvěma charakteristikami: variabilitou v populaci a velikostí výběru
- variabilita znaku v populaci**: čím je vyšší, tím je vyšší i

variabilita výběrových průměrů

- velikost výběru – čím větší výběr (n), tím méně průměrů výběrů se odchyluje od průměru populace (= výběrová chyba je menší)
- vzorec pro výpočet směrodatné chyby:

$$\sigma_x = \sigma/\sqrt{n}$$

tj. směrodatná odchylka populace dělena odmocninou z velikosti vzorku

Rozdělení výběrových průměrů

- platí zjednodušení **tzv. centrálního limitního teorému** – pro každou populaci o průměru μ a směrodatné odchylce σ se bude rozdělení výběrových průměrů výběrů (pro rozsah výběru jdoucí do nekonečna) blížit normálnímu rozdělení s průměrem μ a směrodatnou odchylkou $\sigma_x = \sigma/\sqrt{n}$

Rozdělení výběrových průměrů

- **příklad:** když vybereme z populace náhodně vzorek 9 osob, jaká je pravděpodobnost, že jejich průměrné IQ bude větší nebo rovno 112?
- ptáme se vlastně: jaká je pravděpodobnost, že vzorek 9 osob z populace o průměru 100 bude mít průměr 112 nebo vyšší? Kolik % je takových vzorků ze všech možných vzorků o této velikosti?
- musíme zjistit charakteristiku rozdělení výběrových průměrů pro tuto velikost vzorku ($N=9$) u populace s $\mu = 100$, $\sigma = 15$
- průměr RVP = 100
- směrodatná odchylka = standardní chyba:
 $\sigma_x = \sigma/\sqrt{n} = 15/3 = 5$
- známe průměr a směrodatnou odchylku rozdělení, převedeme tedy skór 112 na z-skór
- $\mu = 100$, $\sigma_x = 5$

- $z = (112-100) / \sigma_x = 12/5 = \mathbf{2.4}$
- pak najdeme v tabulce z-rozdělení pravděpodobnost pro $z=2.4$
- z tabulky $P(Z \geq 2.4) = \mathbf{0.4918}$
- odečteme od 50% (celá jedna strana z-rozdělení) a vyjde nám pravděpodobnost:
- $p = 0.5000 - 0.4918 = \mathbf{0.0082}$

Kontrolní otázky

- výpočet a především interpretace z-skóru
- normální rozdělení – charakteristiky
- rozdělení výběrových průměrů
- výpočet směrodatné chyby

Literatura

- Hendl: kapitoly 4 a 5