

Míry asociace

- obecná definice – síla a směr vztahu
 - míry asociace pro nominální data
 - míry asociace pro ordinální data
 - korelace
-

Míry asociace

- míry asociace vyjadřují **těsnotu vztahu proměnných** (a případně **směr** vztahu)
 - z chí-kvadrátu se dozvíme pouze, **zda nějaký vztah mezi proměnnými existuje** (tj. zda se liší četnosti pozorované a četnosti očekávané za předpokladu, že proměnné jsou nezávislé)
-

Míry asociace

- **těsnost (síla) vztahu** – vyjádřena absolutní hodnotou koeficientu
 - není shoda v tom, od jaké hodnoty je vztah považován za těsný (někdy uváděno >0.70 , jindy >0.30), středně těsný či slabý
-

Míry asociace

- **směr vztahu** – pouze u ordinálních a kardinálních proměnných
 - **pozitivní vztah** – čím vyšší hodnoty jedné proměnné, tím vyšší hodnoty druhé proměnné
 - **negativní vztah** - čím vyšší hodnoty jedné proměnné, tím nižší hodnoty druhé proměnné
-

Míry asociace pro nominální data

- míry asociace pro nominální data ukazují pouze sílu vztahu dvou proměnných, nikoli směr či jiné informace o povaze vztahu
-

Míry asociace pro nominální data

- rozsah koeficientů je obvykle mezi 0 a 1
 - čím vyšší hodnota, tím těsnější vztah
 - 0 – žádný vztah
 - 1 – absolutní vztah (z hodnot jedné proměnné můžeme předpovědět hodnoty druhé proměnné)
 - pro koeficienty je možno spočítat statistickou významnost
-

Míry založené na chí-kvadrátu

- velikost hodnoty chí-kvadrát je ovlivněna velikostí výběru a počtem kategorií (políček tabulky)
 - účelem koeficientů založených na chí-kvadrátu je eliminovat tyto vlivy
-

Míry založené na chí-kvadrátu

- mezi nejčastěji užívané míry asociace založené na chí-kvadrátu patří koeficienty
 - Fí (Phi)
 - Cramerovo V (Cramer's V)
-

Míry založené na chí-kvadrátu

- **Fí koeficient** - užívá se pro tabulky 2x2 (tj. pro dichotomické proměnné, např. pohlaví)
 - vypočte se tak, že se hodnota chí-kvadrátu vydělí počtem osob a výsledek se odmocní
-

Míry založené na chí-kvadrátu

- **Cramerovo V** – podobný výpočet jako F_i ; počet osob se navíc násobí (počtem řádků - 1)
 - (pokud je počet řádků menší než počet sloupců, jinak počtem sloupců - 1)
 - používá se pro tabulky větší než 2x2
-

Příklad

- příklad z přednášky o Chí-kvadrátu - jak souvisí model manželství s jeho vydařeností
 - Chí-kvadrát = 18.71
 - počet osob $N = 154$
 - $m = (\text{počet řádků} - 1) = 3 - 1 = 2$
-

Kontingenční tabulka

MODEL_M: model rodic. rodiny - muz	2-rozměrná tabulka: Pozorované četnosti (family)			
	RODICE_M vydarene	RODICE_M prumerne	RODICE_M nevydarene	Řádk. součty
matka dominance	22	29	18	69
Řádk. četn.	31,88%	42,03%	26,09%	
otec dominance	14	19	11	44
Řádk. četn.	31,82%	43,18%	25,00%	
kooperativnost	29	8	4	41
Řádk. četn.	70,73%	19,51%	9,76%	
Celk.	65	56	33	154

Příklad

□ tabulka 3x3 – použijeme Cramerovo V

$$\square V = \sqrt{\chi^2 / (N * m)}$$

$$\square V = \sqrt{18.71 / (154 * 2)}$$

$$\square \mathbf{V = 0,246}$$

Příklad

- **interpretace:** hodnota 0,246 je poměrně nízká – vztah mezi modelem manželství a jeho vydařeností není příliš těsný (i když statisticky významný – viz výstup ve Statistice)
-

Výstup ve Statistice

Statist.	Statist. : MODEL_M(3) x RODICE_M(3) (family)		
	Chí-kvadr.	sv	p
Pearsonův chí-kv.	18,71174	df=4	p=,00090
M-V chí-kvadr.	18,83684	df=4	p=,00085
Fí	,3485754		
Kontingenční koeficient	,3291517		
Cramér. V	,2464800		

Další míry asociace

- **Cohenova kappa** – koeficient shody
 - většinou používán pro měření shody mezi posuzovateli
-

Další testy

- ❑ **McNemarův test** – pro závislé výběry (opakovaná měření)
 - ❑ pro tabulky 2x2 – zachycuje míru změny (kolik osob z určité kategorie při prvním měření přejde při druhém měření do jiné kategorie)
 - ❑ obdobný test pro více než dvě měření – **Cochranův test**
-

Míry asociace pro ordinální data

- u ordinálních dat je výpočet založen na poměru tzv. souhlasných a nesouhlasných párů případů
 - **souhlasný** pár případů – hodnota obou proměnných je u jednoho člena páru vyšší (nebo nižší) než u druhého
 - **nesouhlasný** pár případů – hodnota jedné proměnné je u jednoho člena páru vyšší a hodnota druhé proměnné je nižší než u druhého člena páru
-

Příklad

- souvisí spokojenost v manželství
 - 3 velmi šťastné, 2 spíše šťastné, 1 ne příliš šťastné
 - s hodnocením života
 - jako 3 vzrušujícího, 2 stereotypního až 1 nudného?
-

Příklad

Případ	manželství	život
Osoba 1	2	3
Osoba 2	1	2
Osoba 3	2	1

Příklad

- PÁR 1: osoba 1 (2, 3) a osoba 2 (1, 2) - souhlasný
 - PÁR 2: osoba 1 (2, 3) a osoba 3 (2, 1) – nerozhodně (tzv. tie)
 - PÁR 3: osoba 2 (1, 2) a osoba 3 (2, 1) - nesouhlasný
-

Míry asociace pro ordinální data

- koeficient gamma = počet souhlasných minus počet nesouhlasných párů, tento rozdíl vzhledem k celkovému počtu párů (jen souhlasných a nesouhlasných)
 - nerozhodné páry nebere gamma v úvahu
-

Míry asociace pro ordinální data

$$\square \text{ gamma} = \frac{\text{souhlasné} - \text{nesouhlasné}}{\text{souhlasné} + \text{nesouhlasné}}$$

$$\square \text{ gamma} = (1-1)/2 = \mathbf{0}$$

Míry asociace pro ordinální data

- pokud je většina párů souhlasných, je hodnota gamma kladná – tj. **pozitivní vztah** (až +1)
 - pokud je většina párů nesouhlasných, je hodnota gamma záporná – tj. **negativní vztah** (až -1)
 - pokud je počet souhlasných a nesouhlasných párů vyrovnán – gamma kolem 0
-

Míry asociace pro ordinální data

- gamma je symetrická míra – nedělá rozdíly mezi závislou a nezávislou proměnnou
 - asymetrická varianta koeficientu gamma – **Sommerovo D**
 - **Kendallovu tau b** – stejný výpočet jako gamma, ale bere v úvahu i nerozhodné páry (tzv. ties); hodnoty v rozsahu -1 až +1 mohou být získány pouze pro čtvercové tabulky (tj. stejný počet kategorií obou proměnných)
 - **Kendallovu tau c** – kromě korekce pro ties obsahuje i korekci pro velikost tabulky
 - **Spearmanův koeficient korelace** (viz dále)
-

Shrnutí

- u nominálních dat hodnota míry asociace proměnných indikuje sílu vztahu – rozsah od 0 do 1
 - u ordinálních dat míry asociace indikují jak sílu vztahu (abs. hodnota koeficientu), tak směr vztahu
-

Pearsonův korelační koeficient

- u intervalových a poměrových dat můžeme jako míru asociace – vztahu mezi proměnnými použít **Pearsonův korelační koeficient**
 - **korelace**
 - ko = s, spolu, vzájemně
 - relace = vztah
 - korelace = vzájemný vztah proměnných
-

Pearsonův korelační koeficient

- absolutní hodnota koeficientu vyjadřuje **sílu (těsnot) vztahu**
 - znaménko (+ nebo -) **směr vztahu**
 - **rozsah -1 až +1**
 - označuje se **r**
-

Pearsonův korelační koeficient

- sám o sobě je deskriptivní statistikou, ale podobně jako u ostatních měř asociace je možno spočítat **statistickou významnost (=zda se se významně liší od nuly, tj. zda nějaký vztah mezi proměnnými vůbec existuje)**
 - závisí na velikosti výběru – čím vyšší, tím nižší koeficient vychází průkazný
-


Pearsonův korelační koeficient

- je mírou **pouze pro lineární vztahy**
 - před výpočtem je vhodné zobrazit vztah mezi proměnnými graficky – tzv. **scatter** (dvourozměrný bodový diagram)
-

Scatter

- **pozitivní vztah** (přímá úměra) – čím vyšší hodnoty proměnné X, tím vyšší hodnoty proměnné Y


- $r > 0$



Scatter


- **negativní vztah** (nepřímá úměra) – čím vyšší hodnoty proměnné X, tím nižší hodnoty proměnné Y

- $r < 0$



Scatter


- **žádný vztah** -
hodnoty
proměnné X
nesouvisí s
hodnotami
proměnné Y
- $r = 0$



Scatter

□ **nelineární
vztah**


□ $r = 0$



Příklad

- jak spolu souvisí pocit štěstí a míra extraverze?
 - 10 osob, 2 proměnné – skór z dotazníku štěstí a skór ze škály extraverze
-

Příklad



Příklad

šťěstí	15	8	7	18	4	12	10	10	6	9
extraverze	12	7	5	14	6	3	5	10	4	13

Příklad

□ výpočet r

□ $r_{xy} = s_{xy} / s_x s_y$

□ s_{xy} = kovariance

□ $s_{xy} = \frac{(\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}))}{(n-1)}$

□ s_x, s_y = směrodatné odchylky

Příklad

□ $\bar{x} = m_x = 9,90$

□ $s_x = 4,20$

□ $\bar{y} = m_y = 7,90$

□ $s_y = 4,01$

□ $n = 10$

Příklad

□ $s_{xy} = (\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})) / (n-1)$

□ $s_{xy} = (\sum_{i=1}^n (x_i - 9,9)(y_i - 7,9)) / (10-1)$

□ $s_{xy} = ((15-9,9)(12-7,9) + (8-9,9)(7-7,9) + (7-9,9)(5-7,9) + (18-9,9)(14-7,9) + (4-9,9)(6-7,9) + (12-9,9)(3-7,9) + (10-9,9)(5-7,9) + (10-9,9)(10-7,9) + (6-9,9)(4-7,9) + (9-9,9)(13-7,9)) / 9$

□ $s_{xy} = ((5,1*4,1) + (-1,9*-0,9) + (-2,9*-2,9) + (8,1*6,1) + (-5,9*-1,9) + (2,1*-4,9) + (0,1*-2,9) + (0,1*2,1) + (-3,9*-3,9) + (-0,9*5,1)) / 9$

□ $s_{xy} = (20,91 + 1,71 + 8,41 + 49,41 + 11,21 + (-10,29) + (-0,29) + 0,21 + 15,21 + (-4,59)) / 9$

□ $s_{xy} = 91,9 / 9$

□ $s_{xy} = \mathbf{10,21}$

Příklad

$$\square r_{xy} = s_{xy} / s_x s_y$$

$$\square r_{xy} = 10,21 / 4,20 * 4,01$$

$$\square r_{xy} = 10,21 / 16,84$$

$$\square r_{xy} = 0,606$$

Výstup ve Statistice

Proměnná	Korelace (data příklad přednáška 2) Označ. korelace jsou významné na hlad. $p < ,0500$ (N=10 (Celé případy vynechány u ChD))	
	šťěstí	extraverze
šťěstí	1,00	0,61
extraverze	0,61	1,00

Interpretace r

- není shoda v tom, jaká hodnota r je považována za těsný vztah
 - interpretace navržená Guilfordem:
 - <0.20 zanedbatelný vztah
 - $0.20-0.40$ nepříliš těsný vztah
 - $0.40-0.70$ středně těsný vztah
 - $0.70-0.90$ velmi těsný vztah
 - >0.90 extrémně těsný vztah
-

Interpretace r

- pro lepší interpretaci je možné převést koeficient korelace na **koeficient determinace (r^2)**
 - ukazuje, kolik rozptylu v jedné proměnné může být vysvětleno rozptylem ve druhé proměnné
-

Interpretace r

- v našem příkladu
 - $r = 0,606$
 - $r^2 = 0,367$
 - 36,7% rozdílů v míře štěstí můžeme vysvětlit rozdíly v míře extraverze
-

Interpretace r

□ korelace neznamená příčinný vztah mezi proměnnými

- ten můžeme ověřovat např. experimentem, kdy jsou všechny ostatní proměnné udržovány konstantní, proměnná X předchází Y v čase atd.
-

Faktory ovlivňující r


- omezený rozsah hodnot proměnné
 - použití extrémních skupin
 - nehomogenní soubor
 - extrémní hodnoty (outliers)
 - nelineární vztahy
 - reliabilita použitých nástrojů
-

Omezený rozsah hodnot


- omezený rozsah hodnot jedné nebo obou proměnných snižuje hodnotu r
 - stejně tak nízká variabilita (extrémní případ: pokud by všechny hodnoty 1 proměnné byly stejné, zákonitě $r=0$)
-

Použití extrémních skupin

- použití extrémních skupin (např. jen osob s vysokým IQ) vede k vyššímu r





(a)



(b)

Nehomogenní soubor

- může zkreslit r jak směrem nahoru, tak dolů





Extrémní hodnoty

- extrémní hodnoty v jedné nebo obou proměnných mohou r výrazně zkreslit (nejen hodnotu, ale i směr), zvláště když je počet osob v souboru nízký
-

Extrémní hodnoty

□ $r = 0,606$

□ $r = 0,766$



Neparametrický koeficient

- pro ordinální data je možno spočítat **Spearmanův koeficient pořadové korelace** (ρ)
 - počítá se tak, že
 - hodnoty obou proměnných se seřadí od nejnižší po nejvyšší a přidělí se jim pořadí
 - z pořadí se pak počítá Pearsonův koeficient korelace
-

Literatura

□ Hendl: kapitoly 8.3, 7.1 a 7.2
