

Míry asociace

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

Míry asociace

- míry asociace vyjadřují **těsnot** **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)
 - koeficient kontingence (Contingency Coefficient)
-

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

- (Pearsonův) koeficient kontingence – užívá se někdy místo F pro tabulky větší než 2×2
 - bohužel jeho max. hodnota je nižší než 1 (závisí na počtu políček tabulky)
 - neužívá se proto příliš často
-

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**
 - **Kendalovo 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)
 - **Kendalovo 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 (těsnotu) 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 spočít **statistickou významnost**
 - 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

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

Příklad

□ výpočet r

$$r = \frac{SP_{XY}}{\sqrt{SS_X \cdot SS_Y}}$$

Příklad

$$\square \mathbf{SP}_{XY} = \Sigma(X - \bar{X})(Y - \bar{Y}) = \Sigma XY - (\Sigma X)(\Sigma Y)/N$$

$$\mathbf{SS}_X = \Sigma(X - \bar{X})^2 = \Sigma X^2 - (\Sigma X)^2/N$$

$$\mathbf{SS}_Y = \Sigma(Y - \bar{Y})^2 = \Sigma Y^2 - (\Sigma Y)^2/N$$

Příklad

$$\square SP_{xy} = 91,9$$

$$SS_x = 158,9$$

$$SS_y = 144,9$$

$$r = 91,9 / (\sqrt{158,9 * 144,9})$$

$$r = \mathbf{0,606}$$

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

Parciální korelace

- parciální korelace je taková korelace mezi dvěma proměnnými, kdy kontrolujeme vliv třetí proměnné na obě z nich
 - např. chceme zjistit, jaký je vztah mezi prospěchem na SŠ a prospěchem na VŠ; obě proměnné jsou nejspíš ovlivněny IQ
-

Kontrolní otázky

- k čemu slouží míry asociace proměnných?
 - nejužívanější míry pro nominální data
 - nejužívanější míry pro ordinální data
-

Kontrolní otázky

- co vyjadřuje absolutní hodnota Pearsonova koeficientu korelace? a co jeho znaménko (+ nebo -)?
 - co je to koeficient determinace?
 - čím může být zkreslen korelační koeficient?
-

Literatura

□ **Hendl: kapitoly 8.3, 7.1 a 7.2**
