

# 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

		2-rozměrná tabulka: Pozorované četnosti (family)			
		RODICE_M vydarene	RODICE_M prumerne	RODICE_M nevydarene	Řádk. součty
MODEL_M: model rodic. rodiny - muz					
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 měr 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

---

<b>šťestí</b>	<b>15</b>	<b>8</b>	<b>7</b>	<b>18</b>	<b>4</b>	<b>12</b>	<b>10</b>	<b>10</b>	<b>6</b>	<b>9</b>
<b>extraverze</b>	<b>12</b>	<b>7</b>	<b>5</b>	<b>14</b>	<b>6</b>	<b>3</b>	<b>5</b>	<b>10</b>	<b>4</b>	<b>13</b>

---

# Příklad

---

□ výpočet  $r$

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

□  $s_{xy}$  = kovariance

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

□  $s_x, s_y$  = směrodatné odchylky

---

# Příklad

---

$$\square \bar{x} = m_x = 9,90$$

$$\square s_x = 4,20$$

$$\square \bar{y} = m_y = 7,90$$

$$\square s_y = 4,01$$

$$\square n = 10$$

---

# Příklad

---

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

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

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

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

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

$$\square s_{xy} = 91,9 / 9$$

$$\square s_{xy} = \mathbf{10,21}$$

---



# 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  $r=0$ )
-

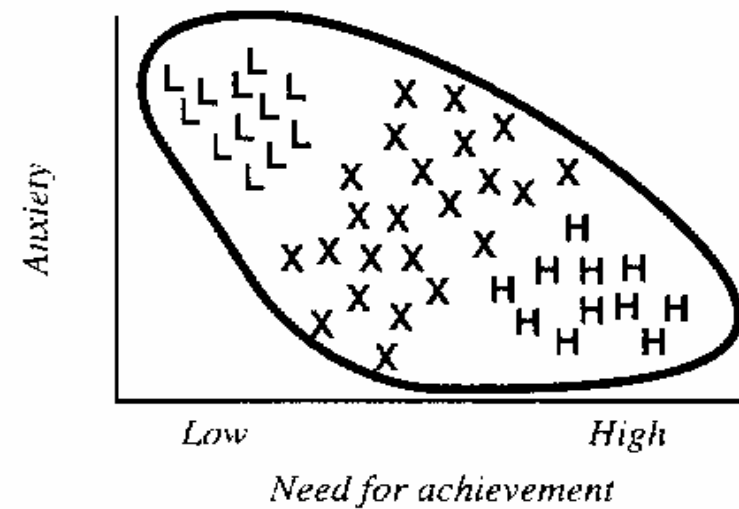


# Použití extrémních skupin

- 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** ( $\rho$ )
  - 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**

---