

PSY117/454

Statistická analýza dat v psychologii

Přednáška 5

Vlastnosti a využití korelace

Pořadová korelace a nezávislost

Robustnost a resistance statistik

Statistics are like bikinis. What they reveal is suggestive, but what they conceal is vital.

Aaron Levenstein



Vlastnosti Pearsonova korelačního koeficientu

- Jde o **momentový** koeficient korelace, a tedy je nutná intervalová a vyšší úroveň měření
- Je vhodný pro popis normálně rozložených proměnných (nebo alespoň **stejně rozložených**)
- Vyjadřuje **sílu(těsnost) lineárního** vztahu, tj. jak moc připomíná tvar scatteru štíhlou elipsu, čáru

Co když tyto podmínky nejsou splněny?

Pořadová korelace

- Řeší mnohá omezení Pearsonovy r
- Čím víc, tím víc/míň nahrazuje ideou shody **pořadí**

Vysoká pozitivní (negativní) korelace pak znamená:

Má-li jeden člověk v jedné proměnné vyšší hodnotu než druhý člověk (tj. nižší pořadí), pak by i v druhé proměnné měl mít ten první vyšší (nižší) hodnotu než druhý.

Kendallův koeficient pořadové korelace tau

známka a M	obvod hlavy	pořadí v M	pořadí v obv. h.	pořadí v M	pořadí v obv. h.	K+, D-
3	48	3	3	1	5	----
2	43	2	2	2	2	++-
1	50	1	5	3	3	+-
4	49	4	4	4	4	-
5	40	5	1	5	1	

$$\tau = (K-D) / [N(N-1)/2] = (3-7)/(5 \cdot 4/2) = -4/10 = -0,4$$

Kendallův koeficient pořadové korelace tau

- τ = přeškálovaná pravděpodobnost, že dva náhodní lidé budou podle obou proměnných shodně (opačně) seřazeni
- $\tau \in \langle -1; 1 \rangle$
- τ zachycuje i monotonní nelineární vztah
- τ díky pořadovému základu není ovlivněno outliery
- τ kromě pořadové úrovně měření nepředpokládá nic

Modifikace τ_b a τ_c řeší problém shody pořadí (ties).
Podobné: (Goodmanova a Kruskalova) γ a Sommerovo d

Spearmanův koeficient pořadové korelace r_s

známka a M	obvod hlavy	pořadí v M	pořadí v obv. h.
3	48	3	3
2	43	2	2
1	50	1	5
4	49	4	4
5	40	5	1

r_s = Pearsonova r spočítaná na transformovaných proměnných = -0,6

Spearmanovo r_s (ρ , ρ , rho)

r_s – tak na půl cesty mezi r a τ

- Je pořadový a nepředpokládá striktně lineární vztah, ale zohledňuje **velikost odchylek** od ideálního pořadí
- Počítá se jako Pearsonova korelace, ale na pořadích
- Používá se obvykle jako rezistentnější varianta Pearsonovy r , která zachytí i monotónní nelineární vztahy.
 - Je-li $r_s > r$, je možné, že vztah není lineární
- Lze interpretovat r_s^2
- *Vychází obvykle numericky vyšší než tau, ovšem to by nikdy nemělo hrát roli ve vašem rozhodování. V obou případech jde o jiný typ vztahu.*

Vztahy na nominální úrovni

- Korelační koeficienty založené na hodnotě χ^2 počítané nad kontingenční tabulkou.
 - χ^2 je sumou rozdílů mezi získanými četnostmi v kontingenční tabulce a četnostmi, jaké bychom očekávali, kdyby mezi proměnnými nebyl žádný vztah
- Kvůli neexistenci směru mají koeficienty rozsah od 0 (žádný vztah) do 1 (maximálně těsný vztah)
- Větší množství koeficientů se specializovaným užitím
 - Pearsonův kontingenční koeficient
 - Cramerovo V
 - r_ϕ – koeficient ϕ (phi)


Těmto vztahům se budeme věnovat později.

Konstrukce psychologických škál

Lateralita = součet 5 položek

- psaní, házení, kopání, odraz, zapalování

	<i>M</i>	<i>SD</i>
psaní	1,82	0,39
házení	1,93	0,25
kopání	1,89	0,32
odraz	1,53	0,50
sírka	1,82	0,39
(c) Lateralita	1,80	0,25



Využití korelací v konstrukci psychologických testů

- ❑ Položky lze sčítat, pokud spolu korelují.
- ❑ Položky korelují, existuje-li společný důvod pro určitý způsob odpovídání na ně – měřená charakteristika.

Jak moc spolu musí korelovat?

$$r_{tt} = \frac{kr_M}{1 + (k-1)r_M} \qquad r_{tt} = \frac{k}{k-1} \left(1 - \frac{\sum_{i=1}^k \sigma_i^2}{\sigma_t^2} \right)$$

r_{tt} je vnitřní konzistence, r_M je průměrná korelace mezi položkami, k je počet položek

- ❑ při 10 položkách stačí průměrná korelace 0,2

Vnitřní konzistence – **Cronbachovo α** – horní mez reliability

- ❑ minimálně 0,7 pro výzkum, 0,9 pro diagnostiku
-

zpět k *lateralitě*

	psaní	házení	kopání	odraz	sirka
psaní	1,00	0,57	0,57	0,02	0,92
házení	0,57	1,00	0,61	-0,08	0,57
kopání	0,57	0,61	1,00	0,09	0,48
odraz	0,02	-0,08	0,09	1,00	0,02
sirka	0,92	0,57	0,48	0,02	1,00

$$r_M = 0,379$$

$$r_{tt} = 0,69$$

$$r_{tt}(\text{bez odrazu}) = 0,87$$

Jaké statistiky už známe

Četnosti

Popisné statistiky jedné proměnné

- momentové: M , SD , s^2
- pořadové: min , max , Md , Q_1 , Q_3 , IQR , percentily
- kategorické: Mo

Ukazatele vztahu mezi dvěma proměnnými

- momentové: Pearsonova r , b
- pořadové: Kendalovo τ , Spearmanova r_s
- kategorické: r_ϕ , Cramerovo V

S jakými předpoklady je spojeno použití těchto statistik?

Co se stane, když nejsou tyto předpoklady splněny?

Předpoklady statistik

Jejich splnění podmiňuje

- matematickou **smysluplnost** výpočtu
 - typicky úroveň měření
- **přesnost**, výpovědní schopnost vypočítané hodnoty
 - typicky tvar rozložení

Při splnění všech předpokladů nese vypočítaná statistika tu informaci, kterou od nich v souladu se statistickou teorií očekáváme.

Statistiky, které nejsou porušením předpokladů příliš ovlivněné, jsou **ROBUSTNÍ**.

- používáme i pro statistiky s minimálními či žádnými předpoklady.

Co ještě omezuje výpovědní schopnost statistik?

□ Odlehlé, extrémní hodnoty

- Není-li statistika příliš ovlivněna výskytem extrémních hodnot, je **REZISTENTNÍ**
- Resistenci momentových statistik někdy zvyšujeme ořezáváním extrémů, např. trimmed mean

□ Efekt podlahy a stropu

- snižuje ukazatele variability
 - posunuje ukazatele centrální tendence
 - snižuje korelaci
 - ... a nic moc s tím nenaděláme, to je věc metodologie
-