

Korelace

POLb 1139

Peter Spáč

Korelace - základy


- Vzájemná souvislost mezi proměnnými
- Nárůst hodnot jedné proměnné je spojený s nárůstem (anebo poklesem) hodnot druhé proměnné
- Korelace neimplikuje kauzalitu

Divorce rate in Maine

correlates with

Per capita consumption of margarine

Correlation: 99.26% ($r=0.992558$)



Korelace - druhy

- Bivariační – souvislost mezi dvěma proměnnými
- Parciální (partial) – souvislost mezi dvěma proměnnými za určité kontroly vlivu jiných proměnných
- JASP umožňuje pouze bivariační korelaci
- Pro kontrolu vlivu třetích proměnných typicky využíváme pokročilejší techniky (regrese)

Korelace a proměnné

- Podoba analýzy závisí na typu proměnných
- Kontingenční tabulky (crosstabs):
 - Dvě kategorické proměnné – nominální, ordinální
 - Nižší počet kategorií v proměnných (podmínka jsou minimálně dvě)
- Korelace (correlation):
 - Dvě kardinální proměnné, kardinální a ordinální, dvě ordinální
 - Specifický případ – kardinální a dichotomická proměnná

Bivariační korelace

- Posuzuje souvislost mezi dvěma proměnnými bez dalšího
- Tři základní postupy:
 - Pearsonův korelační koeficient
 - Spearmanovo rho
 - Kendallovo tau
- Odlišné podmínky a předpoklady

Pearsonův korelační koeficient

- Parametrický postup
- Předpoklady:
 - Kardinální data (možná výjimka – kardinální a binární proměnná)
 - Pokud zjišťujeme i statistickou signifikanci, tak i normální rozložení (nebo dostatečná velikost vzorku)
- Citlivost na odlehlé případy (outliers)

Pearsonův korelační koeficient


- Vychází z výpočtu rozptylu, pro srovnatelnost se standardizuje
- Hodnoty koeficientu:
 - Rozsah od -1 po 1
 - +1 = perfektní kladná souvislost
 - -1 = perfektní záporná souvislost
 - 0 = žádná souvislost
- Čím více je hodnota vzdálena od nuly, tím je souvislost silnější

Pearsonův korelační koeficient

- Vychází z výpočtu rozptylu, pro srovnatelnost se standardizuje
- Síla vztahu:
 - $\pm 0,1$ – slabý
 - $\pm 0,3$ – střední
 - $\pm 0,5$ – silný
- Spíše orientační, podstatnější je věcný význam zjištění

Postup

- 1. Zhodnocení a kontrola dat
 - Podmínky pro jednotlivé koeficienty
 - Vizualizace dat
- 2. Výběr vhodného korelačního koeficientu
- 3. Spočítání výsledků a jejich (především věcná) interpretace
 - Existence vztahu, směr, síla
 - Možnost zobecnění na populaci



Pearson's Correlations

Variable		sales	airplay
1. sales	Pearson's r	—	
	p-value	—	
2. airplay	Pearson's r	0.599	—
	p-value	< .001	—

Pearson's Correlations

		Pearson	
		r	p
sales	-	airplay 0.599***	< .001

* p < 0.5, ** p < 0.01, *** p < 0.001

Pearsonův korelační koeficient

- Po umocnění r získáváme tzv. Index determinace (R^2)
- R^2 vymezuje, jaký podíl variability jedné proměnné je sdílený s druhou proměnnou
- Pro názornost se R^2 násobí číslem 100 a vyjadřuje v procentech
- Nadále však daná hodnota neříká nic o kauzalitě

Spearmanovo rho a Kendallovo tau

- Neparametrické postupy
- Např. nominální a ordinální proměnná, dvě ordinální proměnné
- Data nejdřív seřadí a následně toto pořadí využívá pro výpočet korelačního koeficientu
- Výsledky a interpretace stejné jako u Pearsonova korelačního koeficientu
- Kendallovo tau:
 - Vhodnější při menším počtu dat a opakujících se hodnotách
 - Výsledné hodnoty o něco nižší než u Spearmanova rho

Sample Correlation Coefficient

- Pearson's r
- Spearman's rho
- Kendall's tau-b

Additional Options

- Display pairwise
- Report significance
- Flag significant correlations
- Confidence intervals
Interval %
- Vovk-Sellke maximum p-ratio
- Sample size

Alt. Hypothesis

- Correlated
- Correlated positively
- Correlated negatively

Plots

- Scatter plots
- Densities for variables
- Statistics
- Heatmap

Sample Correlation Coefficient

- Pearson's r
- Spearman's rho
- Kendall's tau-b

Additional Options


- Display pairwise
- Report significance
- Flag significant correlations
- Confidence intervals
Interval %
- Vovk-Sellke maximum p-ratio
- Sample size

Alt. Hypothesis

- Correlated
- Correlated positively
- Correlated negatively

Plots

- Scatter plots
- Densities for variables
- Statistics
- Heatmap



Spearman's Correlations

Variable		Vel_kat	Ucast
1. Vel_kat	Spearman's rho	—	
	p-value	—	
2. Ucast	Spearman's rho	-0.445	—
	p-value	< .001	—



Spearman's Correlations

		Spearman	
		rho	p
Vel_kat	-	-0.445***	< .001

* p < 0.5, ** p < 0.01, *** p < 0.001



Limity

- Základní pravidlo – **korelace \neq kauzalita**
- Korelace vyjadřuje pouze souvislost mezi proměnnými, ne příčinu a následek
 - Vliv třetích proměnných
 - Korelace neuvádí směr působení proměnných
- Nemožnost konstatovat kauzalitu trvá i pokud se příčinný vztah jeví jako „logický“
- Statistické zjištění nemá automaticky věcný význam
- Uživatelský limit – pozor na kódování kategorických proměnných