

KORELACIJA

STATISTIČKI PRAKTIKUM 2

2

Problem

Zanima nas razina *statističke povezanosti* dvije pojave/obilježja - možemo li, i koliko dobro, predvidjeti ponašanje jednog obilježja pomoću drugog.

Pitanja:

- ▶ jesu li obilježja statistički povezana?
- ▶ ako jesu, koliko je ta veza snažna?
- ▶ ako jesu, u kojem smjeru se kreće ta veza?
- ▶ možemo li matematički modelirati tu vezu?
- ▶ postoji li zavisnost među tim obilježjima, u smislu da kretanje jednog obilježja određuje kretanje drugog, ili se kreću zajedno?
 - ▶ korelacija vs kauzalnost!
- ▶ što ako imamo više od dva obilježja čiju međusobnu povezanost želimo ispitati?

Statističku povezanost mjerimo *kvantitativno* funkcijom koja ovisi o *tipu varijabli* s kojima radimo.

Nakon procjene povezanosti slijedi analiza kvalitete modela (tj. procjene), eng. *goodness of fit*.

Tipovi varijabli

- ▶ **kvalitativne varijable** (kategorijske)
 - ▶ poprimaju konačno mnogo vrijednosti (označene slovima ili brojevima) koje predstavljaju moguća stanja/kategorije koje varijabla može poprimiti
 - ▶ među kategorijama ne mora postojati uređaj
- ▶ **kvantitativne varijable** (numeričke, neprekidne)
 - ▶ vrijednosti su brojevi na nekom intervalu ili jako velikom skupu (npr. $[0, 1]$, $\mathbb{R}$, $\mathbb{N}$)
 - ▶ među vrijednostima postoji uređaj
 - ▶ skup vrijednosti može biti i konačan i beskonačan, ali u pravilu je velik (u suprotnom varijable u pravilu smatramo kategorijskima)

Kako mjerimo povezanost?

	kvalitativna	kvantitativna
kvalitativna	χ^2 -test; Cramerov V koeficijent	ANOVA; Kruskal-Wallisov test; logistička regresija
kvantitativna	ANOVA; Kruskal-Wallisov test; logistička regresija	Pearsonov koeficijent; Spearmanov koeficijent; linearna regresija

Cramerov V koeficijent

- ▶ jačina veze između dvije kvalitativne varijable
- ▶ poprima vrijednost u intervalu $[0, 1]$ (0 - nema povezanosti, 1 - savršena povezanost)
- ▶ primjenjiv na kontingencijskim tablicama raznih dimenzija (može se koristiti za uspoređivanje raznih χ^2 statistika)
- ▶ veličina uzorka ne utječe na rezultat (korisno kada sumnjamo da je povezanost posljedica velikog uzorka)

$$V = \sqrt{\frac{\chi^2}{n(q-1)}},$$

- ▶ $\chi^2 = \sum_{i,j} \frac{\left(n_{ij} - \frac{n_{i.} \cdot n_{.j}}{n}\right)^2}{\frac{n_{i.} \cdot n_{.j}}{n}}$
- ▶ $q = \min\{r, c\}$ (manji od broja redova i broja stupaca kontingencijske tablice; tj. broja kategorija svake varijable)
- ▶ n = ukupna veličina uzorka

Cramerov V koeficijent

Interpretacija:

- ▶ $V \in [0, 0.1] \Rightarrow$ nema povezanosti
- ▶ $V \in \langle 0.1, 0.3] \Rightarrow$ slaba povezanost
- ▶ $V \in \langle 0.3, 0.5] \Rightarrow$ srednja razina povezanosti
- ▶ $V \in \langle 0.5, 1] \Rightarrow$ jaka povezanost

Simetrična mjera (nije bitan redoslijed varijabli).

```
> library(rcompanion)
> cramerV()
```

Pearson vs. Spearman

Pearsonov koeficijent korelacije

- ▶ $\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}} \in [-1, 1]$
- ▶ stupanj linearne povezanosti $Y = aX$
- ▶ povećanje jedne varijable dovodi do linearnog povećanja/smanjenja ($a > 0/a < 0$) druge varijable
- ▶ nezavisnost $\implies$ nekoreliranost, ali obrat ne vrijedi!





Pearson vs. Spearman

Spearmanov koeficijent monotone povezanosti

- ▶ stupanj *monotone povezanosti* dvije varijable (povećanje jedne varijable dovodi do povećanja ili smanjenja druge varijable, ali ne nužno proporcionalno)
- ▶ varijable mogu biti povezane i nekom drugom funkcijom (kretanje jedne varijable utječe na kretanje druge varijable)
- ▶ vrijednosti su u intervalu $[-1, 1]$
- ▶ Spearmanov koeficijent korelacije = Pearsonov koeficijent korelacije rangova tih varijabli
- ▶ ako u uzorcima nema ponavljajućih vrijednosti, vrijednosti ± 1 predstavljaju situaciju kada je jedna varijabla jednaka savršenoj monotonnoj funkciji druge varijable

Primjeri

- ▶ $x = (0, 10, 101, 102)$, $y = (1, 100, 500, 2000)$
- ▶ zanimljiv primjer s Wikipedije



Zadatak

Učitajte podatke iz tablice `podaci1.csv`.

- (a) Odredite tipove varijabli.
- (b) Jesu li spol, stručna sprema i regija statistički povezane varijable? Koja od preostale dvije varijable više utječe na stručnu spremu osobe?
- (c) Ovisi li plaća osobe o njenom spolu ili stručnoj spremi?
- (d) Na razini značajnosti od 5%, jesu li dob i plaća osobe korelirane?