

Korelacijska analiza

Korelacijska analiza – predpostavke

- X, Y – statistični spremenljivki.
- Podatki nastopajo v parih.
- Vzorec velikosti n : $(x_1, y_1), \dots, (x_n, y_n)$.
- Podatke prikažemo z razsevnim diagramom.

1. PRIMER: X meri telesno višino štorcklje.

Y meri telesno težo štorcklje.

Ugotovitve:

- Podatki so razpršeni v oblaku.
- Oblak je nagnjen – se dviguje.
- Intuitivno: višje štorcklje so težje.
- Pozitivna linearna povezanost oz. korelacija.

Pojem korelacije

- **Korelacijska analiza** proučuje soodvisnost (povezanost, usklajenost) med dvema (ali več) statističnima spremenljivkama.
- Soodvisnost med spremenljivkama lahko povzroča tudi kakšna tretja spremenljivka.

2. PRIMER: X meri prisotnost NaCl v zemlji.

Y meri oddaljenost zemlje od ceste.

Ugotovitve:

- Podatki so razpršeni v oblaku.
- Oblak je nagnjen – pada.
- Intuitivno: dlje od ceste, manj NaCl.
- Negativna linearna povezanost oz. korelacija.
- **Jakost linearne korelacije:** majhna, velika, močna.
- **Opomba:** Obstajajo tudi nelinearne korelacije.

Kovarianca

- Kovarianca – mera za medsebojno povezanost dveh spremenljivk. **Kovarianca spremenljivk X in Y :**

$$K(X, Y) = E((X - E(X))(Y - E(Y)))$$
- Cenilka za populacijsko kovarianco je **vzorčna kovarianca**:

$$S_{XY} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}); \bar{X} \text{ in } \bar{Y} \text{ sta vzorčni povprečji.}$$
 - Če je $K(X, Y) = 0$, sta X in Y **nekorelirani** (nepovezani).
 - $K(X, X) = D(X)$.
 - $K(X, Y) = K(Y, X)$.
 - Pomen pozitivne in negativne kovariance.
- Če sta X in Y neodvisni, potem sta tudi nekorelirani. Obrat v splošnem ne velja – velja ob določenih predpostavkah (npr., če sta X in Y normalno porazdeljeni).

Pearsonov korelacijski koeficient

- Jakost linearne povezave med sprem. X in Y merimo s Pearsonovim korelacijskim koeficientom: $\rho = \frac{K(X, Y)}{\sigma(X)\sigma(Y)}$.
- Uporaba Pearsonovega korelacijskega koeficienta kot mere za jakost linearne povezave, je utemeljena le za normalno porazdeljene spremenljivke.
- Cenilka za populacijski korelacijski koeficient je vzorčni korelacijski koeficient: $r = \frac{S_{XY}}{S_X S_Y}$, kjer sta

$$S_X^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \text{ in } S_Y^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2$$
vzorčni disperziji.

Lastnosti Pearsonovega korelacijskega koeficienta

- $\rho \in [-1, 1]$.
- Če je $\rho = 1$ ali $\rho = -1$, tedaj obstaja med X in Y linearna funkcijska zveza, $Y = a + bX$.
- Če je $\rho = 0$, sta X in Y nepovezani, nekorelirani. Če sta normalno porazdeljeni, sta tudi neodvisni.
- Če $\rho \neq -1, 0, 1$, potem med X in Y ni le linearne povezanosti.
 - $\rho < 0$: negativna povezava.
 - $\rho > 0$: pozitivna povezava.
 - 0 – 0,2: neznatna linearna povezanost.
 - 0,2 – 0,4: nizka linearna povezanost.
 - 0,4 – 0,7: zmerna linearna povezanost.
 - 0,7 – 0,9: visoka linearna povezanost.
 - 0,9 – 1: zelo visoka linearna povezanost.

Ocenjevanje in testiranje korelacijskega koeficienta ρ

- Točkovna cenilka: vzorčni korelacijski koeficient $r = \frac{S_{XY}}{S_X S_Y}$.
- Testiranje nekoreliranosti sprem. X in Y (oz. neodvisnosti pri normalno porazdeljenih spremenljivkah).
Na stopnji značilnosti α testiramo:
 $H_0(\rho = 0) : H_1(\rho \neq 0)$ (parametrični preizkus).
 H_0 : X in Y sta nekorelirani.
 H_1 : X in Y sta korelirani.
- Testna statistika: $T = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2} \sim S(n-2)$.
- Kritično območje dvostranskega testa:
 - Izberemo tak t_α , da velja $P(|T| < t_\alpha) = 1 - \alpha$ (tabela B).
 - Izračunamo vrednost testne statistike T na vzorcu: T_e .
 - Če je $|T_e| \geq t_\alpha$, hipotezo H_0 zavrnemo in potrdimo H_1 .
 - Če je $|T_e| < t_\alpha$, o hipotezi H_0 ne odločimo.
 - Če je $p \leq \alpha$, H_0 zavrnemo (p je signifikanca vzorca).

Ostali koeficienti

- Če X in Y ne zadoščata pogojem za uporabo Pearsonovega korelacijskega koeficienta ρ , lahko uporabimo (izbira je odvisna od vrste statističnih spremenljivk):
 - Spearmanov korelacijski koeficient.
 - Biseriální korelacijski koeficient.
 - Točkovni biseriální korelacijski koeficient.
 - Fi-koeficient.
 - Koeficient eta-kvadrat.

Spearmanov korelacijski koeficient

- Spearmanov korelacijski koeficient meri jakost monotone povezave med spremenljivkama X in Y .
- Uporabimo ga, če X in Y ne zadoščata pogojem za uporabo Pearsonovega korelacijskega koeficienta ρ .
- Naj bosta spremenljivki X in Y vsaj ordinalni.
- Vzorec velikosti n : $(x_1, y_1), \dots, (x_n, y_n)$.
Spearmanov korelacijski koeficient ρ_S je pravzaprav Pearsonov korelacijski koeficient, izračunan na podlagi rangov podatkov.
- Rangiramo podatke za X : $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n-1)} \leq x_{(n)}$.
- Rangiramo podatke za Y : $y_{(1)} \leq y_{(2)} \leq \dots \leq y_{(n-1)} \leq y_{(n)}$.
Pri tem po potrebi izračunamo povprečni rang.
- Označimo:
 - I_k = rang podatka x_k .
 - J_k = rang podatka y_k .
 - $D_k = I_k - J_k$ (razlika rangov).

Vzorčni Spearmanov koeficient korelacije

- Vzorčni Spearmanov koeficient korelacije je definiran kot:

$$r_S = 1 - \frac{6}{n^3 - n} \sum_{k=1}^n D_k^2.$$

Lastnosti:

- $r_S \in [-1, 1]$.
- Če je $r_S = 1$, velja $D_k = 0$ za vsak k , torej je vedno $I_k = J_k$.
 x_k ima isti rang kot y_k . Popolna pozitivna povezanost.
- Če je $r_S = -1$, sta ranžirni vrsti „narobe obrnjeni“: $(1, n), (2, n-1), \dots$ (popolna negativna povezanost).
- Če je $r_S = 0$, so rangi nekorelirani.
- Interpretacija r_S kot pri Pearsonovem koeficientu.

Neparametrično testiranje nekoreliranosti

- Naj bosta spremenljivki X in Y vsaj ordinalni.
- Vzorec velikosti n .
- Na stopnji značilnosti α testiramo:
 $H_0(\rho_S = 0) : H_1(\rho_S \neq 0)$.
 H_0 : X in Y sta nekorelirani.
 H_1 : X in Y sta korelirani.
- Izračunamo r_S .
- Za $n > 30$ je testna statistika $Z = r_S \sqrt{(n-1)} \sim N(0, 1)$.