


Linearna regresija


Deterministički povezane varijable:

Vrijeme i put u slobodnom padu:




Nedeterministički povezane varijable:

Početa brzina i domet topovske granate:



Snaga automobila i potrošnja goriva



Linearan odnos

Deterministički: $y = ax + b$

Npr.: poznata opruga: $l = \frac{g}{K}m + l_0$

Nedeterministički:

Nezavisna varijabla X , vrijednosti x_i

Za određeni x_i , zavisna varijabla Y_i je slučajna varijabla.

Poprima vrijednost y_i

Npr.: opruge iz iste serije


x_1, x_2, \dots, x_n - vrijednosti nezavisne varijable

Y_i slučajna varijabla pridružena x_i -u.

y_i opažena vrijednost pridružena x_i -u.

n opaženih parova $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$.

→ graf



linearno?

$a=?$

$b=?$

tražimo najvjerojatnije!

Određivanje koeficijenata metodom najmanjih kvadrata


Pretpostavka:

Postoje parametri a i b takvi da za svaku vrijednost x_i nezavisne varijable X , zavisnu varijablu Y_i možemo pisati:


$$Y_i = ax_i + b + \hat{\varepsilon}$$

gdje je $\hat{\varepsilon}$ normalna slučajna varijabla s očekivanjem $E(\hat{\varepsilon}) = 0$ i varijancom $V(\hat{\varepsilon}) = \sigma^2$.

σ^2 je jednaka za sve vrijednosti x .



Za izmjerene (opažene) parove vrijedi:



$$y_i = ax_i + b + \varepsilon_i$$

Princip najmanjih kvadrata:

Od svih pravaca $y = ax + b$, najvjerojatniji pravac regresije jest onaj za koji je suma kvadrata odstupanja

$$f(a, b) = \sum_{i=1}^n [y_i - (ax_i + b)]^2 = \sum_{i=1}^n \varepsilon_i^2$$

minimalna.

normalne jednadžbe

Suma kvadrata odstupanja je minimalna kada istodobno vrijedi:

$$\frac{\partial f(a, b)}{\partial a} = 0 \quad \text{i} \quad \frac{\partial f(a, b)}{\partial b} = 0$$

$$\sum_{i=1}^n y_i x_i - a \sum_{i=1}^n x_i^2 - b \sum_{i=1}^n x_i = 0$$

$$\sum_{i=1}^n y_i - a \sum_{i=1}^n x_i - nb = 0$$

rješenje:

$$a = \frac{\sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \quad b = \frac{\sum_{i=1}^n x_i^2 \sum_{i=1}^n y_i - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2}$$

$$N_z = n \sum_{i=1}^n (x_i - \bar{x})^2 \quad a = \frac{\sum_{i=1}^n (x_i - \bar{x}) y_i}{N_z} \quad b = \bar{y} - a \bar{x}$$

Napomene:

- Prije računanja pravca regresije treba u grafu provjeriti ima li smisla linearna regresija i jesu li podaci podjednako raspoređeni.
- Rezultate sumiranja ne smije se zaokruživati jer pogreška zaokruživanja bitno utječe na razliku velikih sličnih brojeva.

Tražimo nepouzdanosti parametara a i b

$$V(\hat{a}) = \frac{n^2}{N_z^2} \sum_{i=1}^n (x_i - \bar{x})^2 V(Y_i)$$

$$\sigma_a^2 = \frac{n^2}{N_z^2} \sum_{i=1}^n (x_i - \bar{x})^2 \sigma^2 = n \frac{\sigma^2}{N_z}$$

Nepistrani procjenitelj za σ^2 dan je izrazom:

$$s^2 = \hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - y_i^*)^2}{n-2} = \frac{\sum_{i=1}^n [y_i - (ax_i + b)]^2}{n-2}$$

Konačni rezultati:

$$a = \frac{\sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \quad b = \frac{\sum_{i=1}^n x_i^2 \sum_{i=1}^n y_i - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2}$$

$$M_a = \sqrt{\frac{1}{(n-2)} \left[\frac{n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i \right)^2}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} - a^2 \right]} \quad M_b = M_a \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}}$$

Regresija s transformiranim varijablama


nelinearnu ovisnost prikazati u linearnom obliku:

- Mogu se primijeniti jednadžbe za linearnu regresiju.
- Takav grafički prikaz zorno potvrđuje (ili odbacuje) ispravnost primijenjene teorije.


Primjer s prošlog predavanja (napredni praktikum 2):

Modul elastičnosti

$$\lambda = \frac{1}{4E} \frac{L^3}{ab^3} F$$



$$x = L^3$$



Logaritamski grafovi

$$Y = X^\alpha \quad \alpha \text{ ne znamo ili želimo provjeriti}$$



Isti primjer: Modul elastičnosti čelika.

Savijenost šipke je:

$$\lambda = \frac{1}{4E} \frac{F}{ab^3} L^\alpha = K \cdot L^\alpha$$

$$\log \lambda = \log K + \alpha \log L$$

$$x = \log L \quad y = \log \lambda$$



Nelinearne regresije

Zavisna varijabla nelinearno ovisi o nezavisnoj

Npr.: tjerani prigušeni harmonički oscilator (napredni praktikum 1)

$$y = \frac{A}{\sqrt{(\omega_0^2 - \omega^2)^2 + (\omega/\tau)^2}} \quad \text{parametri } A, \omega_0 \text{ i } \tau$$


Suma kvadrata odstupanja minimalna:

$$f(A, \omega_0, \tau) = \sum_i \left(y_i - \frac{A}{\sqrt{(\omega_0^2 - \omega_i^2)^2 + (\omega_i/\tau)^2}} \right)^2$$

Tri jednadžbe:

$$\frac{\partial f(A, \omega_0, \tau)}{\partial A} = 0 \quad ; \quad \frac{\partial f(A, \omega_0, \tau)}{\partial \omega_0} = 0 \quad ; \quad \frac{\partial f(A, \omega_0, \tau)}{\partial \tau} = 0$$

⇒ računalom!



$$y = \frac{A}{\sqrt{(\omega_0^2 - \omega^2)^2 + (\omega/\tau)^2}}$$