

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!



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


Korelacije

Razni stupnjevi rasipanja:




Korelacije

Razni stupnjevi rasipanja:




Korelacije

Razni stupnjevi rasipanja:



Korelacije

Razni stupnjevi rasipanja:




Proučavamo srednju sliku:

ovisnost Y o X:

$$y = ax + b$$

$$a = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{x^2} - \bar{x}^2}$$

$$b = \frac{\overline{x^2}\bar{y} - \bar{x}\overline{xy}}{\overline{x^2} - \bar{x}^2}$$



$$a = \frac{m_{11} - m_{10}m_{01}}{m_{20} - m_{10}^2} = \frac{M_{11}}{M_{20}} = \frac{\sigma_{XY}}{\sigma_X^2}$$

kovarijanca :

$$M_{11} = \sigma_{XY} = \frac{1}{n} \sum_i (x_i - \bar{x})(y_i - \bar{y})$$


$$M_{11} = \frac{1}{n} \sum_i x_i y_i - \bar{x}\bar{y} = \frac{1}{n} \sum_i x_i y_i - \frac{1}{n^2} \sum_i x_i \sum_i y_i$$

Ovisnost X o Y:


$$x = cy + d$$

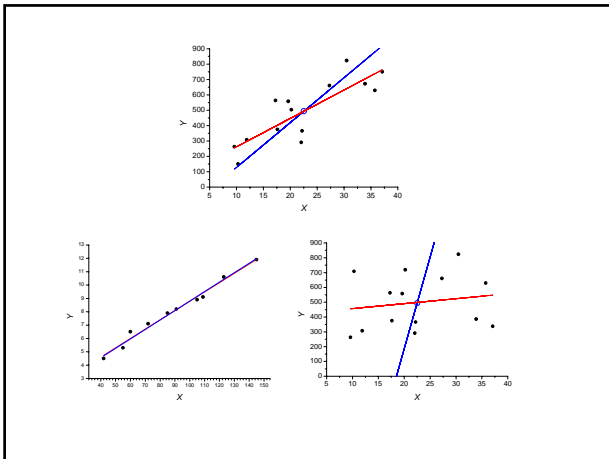
$$c = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{y^2} - \bar{y}^2}$$

$$d = \frac{\overline{y^2}\bar{x} - \bar{y}\overline{xy}}{\overline{y^2} - \bar{y}^2}$$



$$c = \frac{m_{11} - m_{10}m_{01}}{m_{02} - m_{01}^2} = \frac{M_{11}}{M_{02}} = \frac{\sigma_{XY}}{\sigma_Y^2}$$





Jednadžbe pravaca regresije pomoću kovarijance

Ovisnost Y o X:
 jednadžba pravca: $(y - \bar{y}) = \frac{\sigma_{XY}}{\sigma_X^2} (x - \bar{x})$

Ovisnost X o Y:
 jednadžba pravca: $(x - \bar{x}) = \frac{\sigma_{XY}}{\sigma_Y^2} (y - \bar{y})$

standardizirane jednadžbe pravca:


$$\frac{(y - \bar{y})}{\sigma_Y} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} \frac{(x - \bar{x})}{\sigma_X}$$

$$\frac{(x - \bar{x})}{\sigma_X} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} \frac{(y - \bar{y})}{\sigma_Y}$$

bezdimezionalne varijable: $\xi = \frac{(x - \bar{x})}{\sigma_X}$ i $\psi = \frac{(y - \bar{y})}{\sigma_Y}$

novi pravci regresije: $\psi = \rho \xi$ $\xi = \rho \psi$

Def.: **koeficijent korelacije:** $\rho = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$ bezdimezionalno
ne ovisi o jedinicama



Značenje koeficijenta korelacije

poprima vrijednosti: $-1 \leq \rho \leq 1$

$$\rho = \text{tg } \theta$$

$$\gamma = \frac{\pi}{2} - 2\theta$$

$$\text{tg } \gamma = \frac{1 - \rho^2}{2\rho}$$

X i Y nezavisni $\Rightarrow \gamma = \frac{\pi}{2}$, $\rho = 0$

X i Y linearno deterministički vezani $\Rightarrow \gamma = 0$, $\rho = -1$ ili $\rho = 1$

Dogovor: dobra korelacija $\rightarrow |\rho| > 0,5$

Napomena:
 Kad su X i Y nezavisne varijable, koeficijent korelacije težiti će nuli ($\rho \approx 0$). Međutim, činjenica da je $\rho = 0$ ne znači nužno da su varijable nezavisne.

Primjer:

Provjeravanje (testiranje) hipoteza

Provjera hipoteze vrlo je bitan dio statističkog zaključivanja.

Da bi se takva provjera formulirala, potrebno je postaviti neku teoriju koja se želi dokazati.

Npr.:

- Novi lijek bolji je za liječenje određenih simptoma od starog.
- Igrača kocka ima pomaknuto težište
- U svijetu se rađa više muškaraca nego žena

U svakom takvom problemu postavljamo dvije tvrdnje (hipoteze) od kojih je točno jedna istinita:

H_0 = nul-hipoteza

H_1 = alternativna hipoteza

One se **ne** tretiraju **ravnopravno**:

U sudskom procesu: H_0 : optuženi je nevin

H_1 : optuženi je kriv

Hipoteza H_0 smatra se ispravnom dok se ne dokaže H_1 .

Za H_0 obično se uzima stara, postojeća teorija:

Npr., za lijek: H_0 = stari lijek jednako je dobar kao i novi

za kocku: H_0 = kocka je poštena

Ako ne odbacimo H_0 , to ne znači da je ona ispravna, nego samo da nemamo dovoljno dokaza da ju odbacimo.


Primjer: ispitujemo simetričnost Galtonove daske sa 16 redova.

1. Postavljanje problema, izricanje hipoteza

H_0 : daska je simetrična, tj. $X \sim \text{Bin}(16, 1/2)$

H_1 : daska je nagnuta udesno

Raspodjela dana nul-hipotezom:




2. Postavljanje problema, kritično područje

Prije uzimanja uzorka podijelimo skup mogućih ishoda u dva područja:

A = područje prihvatanja H_0

B = područje odbacivanja H_0 = **kritično područje**



Odlučimo se: A = {0, 1, 2, ..., 11} B = {12, 13, ..., 16}

Vrste pogrešaka

		odluka	
		odbaci H_0	prihvati H_0
istina	H_0	pogreška I. vrste	ispravan zaključak
	H_1	ispravan zaključak	pogreška II. vrste

Smatra se da je pogreška I. vrste mnogo ozbiljnija od pogreške II. vrste.

Vjerojatnost pogreške I. vrste:


α = vjerojatnost odbacivanja H_0 kada je istinita = $P(B/H_0)$

Vjerojatnost pogreške II. vrste:

β = vjerojatnost prihvatanja H_0 kada nije istinita = $P(A/H_1)$

U našem primjeru je $\alpha = 0,038 \approx 4\%$.

Međutim, čak i da je daska toliko nagnuta da je $p = 2/3$, raspodjela varijable X bi bila



pa bi vjerojatnost pogreške II. vrste uz naš odabir kritičnog područja bila $\beta = 0,6488$.

Veliki β se događa kada je uzorak premalen ($n = 16$).

Signifikantnost testa (važnost, značajnost)

Def:

Za postupak provjere kažemo da ima **razinu signifikantnosti** (važnosti) α ako je

$$P(\text{pogreška I. vrste}) \leq \alpha.$$

Kažemo da je to **test razine α** .

Naš primjer je test razine 0,04.

Tradicionalno se kao razine signifikantnosti uzimaju vrijednosti 0,01; 0,05 ili 0,10.

Za $\alpha = 0,05$ kažemo da je test **signifikantan**, a za $\alpha = 0,01$ kažemo da je test **vrlo signifikantan**.

Moć testa

Moć statističkog testa mjeri sposobnost testa da odbaci nul-hipotezu kad je uistinu pogrešna, tj. da učini ispravnu odluku.

$$P = 1 - \beta$$

U našem primjeru je $P = 0,34$. Idealno je $P = 1$. Za snažniji test morali bismo imati veći uzorak.

Opća pravila odabira testa

Prije uzimanja uzorka:

- 1) Izreci nul-hipotezu i alternativnu hipotezu.
- 2) Razmotri odgovarajuću raspodjelu danu nul-hipotezom.
- 3) Odluči o razini signifikantnosti testa.
- 4) Odredi kritično područje (odluči o kriteriju odbacivanja nul-hipoteze)

Sada uzmi uzorak!

- 5) Očitaj rezultat testa (izračunaj vrijednost statistike testa)
- 6) Učini odluku:
 - Ako je vrijednost statistike testa u kritičnom području, odbaci H_0 !
 - Ako vrijednost statistike testa nije u kritičnom području, nemoj odbaciti H_0 !