




Teorija pogrešaka

Linearna Regresija



Procjena pogrešaka

Pretpostavka: mjerimo neku veličinu relativno nepreciznim instrumentom, te uvijek dobivamo istu vrijednost $\bar{x} = x_1 = x_2 = \dots = x_n$.

Znači li to da nema pogreške?

Odgovor: nikako!

To samo znači da instrument nije dovoljno osjetljiv.


U tom slučaju **procijenjujemo pogrešku** i pišemo:

$$X = \bar{x} \pm \Delta x, \quad R = \frac{\Delta x}{\bar{x}} \cdot 100(\%)$$



Procjena pogrešaka

Kako procijeniti Δx ?



Δx je najmanji razmak u kojem na određenom instrumentu možemo uočiti promjenu

Δx ima značenje *maksimalne pogreške*, koju možemo definirati i na skupu mjerenih rezultata x_1, x_2, \dots, x_n

$$\Delta x = |\bar{x} - x_i|_{\max}$$



Pogreška ovisnih veličina

Pretpostavimo da je fizička veličina F funkcija neposredno mjerenih veličina y_1, y_2, \dots, y_n

Primjeri:

1. mjerimo duljinu, širinu i visinu kvadra, a zanima nas njegov obujam ($V = a \cdot b \cdot c$)
2. mjerimo mase tri predmeta, m_1, m_2 i m_3 , a zanima nas ukupna masa ($m = m_1 + m_2 + m_3$)
3. mjerimo vrijeme t padanja kuglice s vrha nebodera, a želimo odrediti visinu nebodera ($h = gt^2/2$)

Najvjerojatnija vrijednost veličine \bar{F} je:

$$\bar{F} = F(\bar{y}_1, \bar{y}_2, \dots, \bar{y}_n)$$



Pogreška ovisnih veličina

Primjer I. $\bar{a} = 2.31 \text{ cm}$, $\bar{b} = 1.43 \text{ cm}$, $\bar{c} = 4.11 \text{ cm}$

$$\bar{V} = \bar{a} \cdot \bar{b} \cdot \bar{c} = 13.58 \text{ cm}^3$$

No, što s pogreškom? Znamo pogreške osnovnih veličina, ali u kakvoj su one vezi s pogreškom ovisne veličine?

Iz zakona rasprostranjenja pogreške znamo da je uz $F = y_1 + y_2 + \dots + y_k$:

$$m^2(F) = m^2(y_1) + m^2(y_2) + \dots + m^2(y_k)$$

Što možemo pisati i kao:

$$m^2(F) = \left[\frac{\partial F}{\partial y_1} m(y_1) \right]^2 + \left[\frac{\partial F}{\partial y_2} m(y_2) \right]^2 + \dots + \left[\frac{\partial F}{\partial y_k} m(y_k) \right]^2 = \sum_{i=1}^k \left[\frac{\partial F}{\partial y_i} m(y_i) \right]^2$$



Pogreška ovisnih veličina

Pokazuje se da se ovaj pristup može poopćiti i na nelinearne funkcije $F(y_1, y_2, \dots, y_k)$, te da vrijedi:

$$m^2(F) = \sum_{j=1}^k \left[\frac{\partial F}{\partial y_j} \right]^2 m^2(y_j) \quad \text{srednja pogreška}$$

$$\sigma^2(F) = \sum_{j=1}^k \left[\frac{\partial F}{\partial y_j} \right]^2 \sigma^2(y_j) \quad \text{standardna devijacija}$$

$$M^2(F) = \sum_{j=1}^k \left[\frac{\partial F}{\partial y_j} \right]^2 M^2(y_j) \quad \text{nepouzdanost}$$



Pogreška ovisnih veličina

Primjer: $F = a \cdot b + c = F(a, b, c)$

$$M^2(F) = \left\{ \left(\frac{\partial F}{\partial a} M_a \right)^2 + \left(\frac{\partial F}{\partial b} M_b \right)^2 + \left(\frac{\partial F}{\partial c} M_c \right)^2 \right\}_{\substack{a=\bar{a} \\ b=\bar{b} \\ c=\bar{c}}} =$$
$$= (\bar{b} \cdot M_a)^2 + (\bar{a} \cdot M_b)^2 + (1 \cdot M_c)^2$$



Pogreška ovisnih veličina

Primjer iz praktikuma (vježba 8):

Modul elastičnosti čelika određuje se mjeranjem dimenzija čelične šipke, savijenosti čelične šipke po jedinici sile i udaljenosti potpornja. Teorijska formula za savijenost šipke je:

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

gdje je E modul elastičnosti čelika, L je udaljenost potporanja, a je širina šipke, b je debljina šipke, a F je sila teže utega.

Izmjerene su sljedeće veličine:

$$A = \frac{\lambda}{F} = (0,76 \pm 0,01) \frac{\text{mm}}{\text{N}} = (7,6 \pm 0,1) \cdot 10^{-4} \frac{\text{m}}{\text{N}} = \bar{A} \pm M_A$$

$$a = (10,26 \pm 0,05) \text{ mm} = (1,026 \pm 0,005) \cdot 10^{-2} \text{ m} = \bar{a} \pm M_a$$

$$b = (1,53 \pm 0,03) \text{ mm} = (1,53 \pm 0,03) \cdot 10^{-3} \text{ m} = \bar{b} \pm M_b$$

$$L = (29,0 \pm 0,1) \text{ cm} = (2,90 \pm 0,01) \cdot 10^{-1} \text{ m} = \bar{L} \pm M_L$$

Najvjerojatnija vrijednost za modul elastičnosti čelika je:

$$\bar{E} = \frac{1}{4} \frac{\bar{L}^3}{\bar{a}\bar{b}^3} \frac{1}{\bar{A}} = 2,183226 \text{ N/m}^2$$

Varijanca modula elastičnosti je:

$$M_E^2 = \left(\frac{\partial E}{\partial A} \right)^2 M_A^2 + \left(\frac{\partial E}{\partial a} \right)^2 M_a^2 + \left(\frac{\partial E}{\partial b} \right)^2 M_b^2 + \left(\frac{\partial E}{\partial L} \right)^2 M_L^2 =$$



Pogreška ovisnih veličina

$$\begin{aligned} &= \left(\frac{\bar{L}^3}{4\bar{a}\bar{b}^3\bar{A}^2} \right)^2 M_A^2 + \left(\frac{\bar{L}^3}{4\bar{a}^2\bar{b}^3\bar{A}} \right)^2 M_a^2 + \left(\frac{3\bar{L}^3}{4\bar{a}\bar{b}^4\bar{A}} \right)^2 M_b^2 + \left(\frac{3\bar{L}^2}{4\bar{a}\bar{b}^3\bar{A}} \right)^2 M_L^2 = \\ &= \bar{E}^2 \left[\left(\frac{M_A}{\bar{A}} \right)^2 + \left(\frac{M_a}{\bar{a}} \right)^2 + \left(3 \frac{M_b}{\bar{b}} \right)^2 + \left(3 \frac{M_L}{\bar{L}} \right)^2 \right] = \\ &= \bar{E}^2 \left[1,73 \cdot 10^{-4} + 2,37 \cdot 10^{-5} + 3,46 \cdot 10^{-3} + 1,07 \cdot 10^{-4} \right] \end{aligned}$$

Standardna pogreška je:

$$M_E = \bar{E} \sqrt{3,76 \cdot 10^{-3}} = 0,13 \cdot 10^{11} \text{ N/m}^2$$

Rezultat za modul elastičnosti pišemo:

$$E = (2,2 \pm 0,1) \cdot 10^{11} \text{ N/m}^2$$



Pogreška ovisnih veličina

Što ako imamo samo procijenjene pogreške Δy_i ?

Tada ne možemo govoriti o rasprostranjenju pogreške, što je zakon definiran na statističkom skupu.

Umjesto toga razvijamo F u red oko \bar{F} i računamo *maksimalnu pogrešku*.

$$F = F(\bar{y}_1, \bar{y}_2, \dots, \bar{y}_k) \pm \sum_{j=1}^k \left(\frac{\partial F}{\partial y_j} \right)_{y_j=\bar{y}_j} \times \Delta y_j = \bar{F} \pm \Delta F$$

Budući da je $\Delta F \geq 0$, uzimamo absolutne vrijednosti derivacija, pa je:

$$\Delta F = \sum_{j=1}^k \left| \frac{\partial F}{\partial y_j} \right|_{y_j=\bar{y}_j} \times \Delta y_j$$



Pogreška ovisnih veličina

Primjer:

$$F = a \cdot b + c$$

$$\Delta F = \left\{ \left| \frac{\partial F}{\partial a} \right| \Delta a + \left| \frac{\partial F}{\partial b} \right| \Delta b + \left| \frac{\partial F}{\partial c} \right| \Delta c \right\}_{\substack{a=\bar{a} \\ b=\bar{b} \\ c=\bar{c}}} = \bar{b} \Delta a + \bar{a} \Delta b + \Delta c$$



Mjerenja s različitim statističkim težinama

Pretpostavimo da je u više različitih laboratorijskih neovisno mjerena ista veličina X . Ostvareni su rezultati:

$$X_1 = \bar{x}_1 \pm M_1, X_2 = \bar{x}_2 \pm M_2, \dots, X_l = \bar{x}_l \pm M_l$$

Kako će netko tko dobije samo listu rezultata, a ne zna ništa o pojedinostima eksperimenta, izraziti rezultat ovih mjerenja u obliku:

$$X = \bar{\bar{x}} + \bar{M}$$

gdje je $\bar{\bar{x}}$ opća aritmetička sredina, a \bar{M} opća nepouzdanost.

Mjerenja se obično izvode na različite načine i s različitim pouzdanostima pa ih ne smijemo tretirati ravnopravno. Kažemo da mjerenja imaju različite statističke težine.



Mjerenja s različitim statističkim težinama


Pretpostavimo da svakom rezultatu pridijelimo *statističku težinu w_j* , tako da je:

$$\bar{x} = \sum_{j=1}^l w_j \bar{x}_j; \quad \sum_{j=1}^l w_j$$

Dakle, w_j ima slično značenje kao i relativna frekvencija pojavljivanja događaja, a \bar{x}_j kao pojedinačno mjerjenje.

U praksi se najčešće uzima (veća težina za manji M_j):

$$w_j = \frac{1}{M_j} \cdot \frac{1}{\sum_{k=1}^l M_k}$$



zadovoljava $\sum_{j=1}^l w_j = 1$



Mjerenja s različitim statističkim težinama

Prema tome, opća aritmetička sredina je:

$$\bar{\bar{x}} = \frac{\sum_{j=1}^l \bar{x}_j}{\sum_{j=1}^l M_j^2}$$



Mjerenja s različitim statističkim težinama

Koliki je M ?

Zamislimo jedno mjerjenje koje ima statističku težinu $w = 1$ i nepouzdanost \bar{M} , a u potpunosti zamjenjuje l rezultata.


Znamo otprije:

$$\frac{w_i}{w_j} = \frac{M_j^2}{M_i^2}$$

i stavimo

$$w_i = 1$$
$$M_i = \bar{M}$$

$$\frac{1}{w_j} = \frac{M_j^2}{\bar{M}^2}$$



$$\bar{M}^2 = w_j M_j^2 = \frac{1}{\sum_{k=1}^l \frac{1}{M_k^2}}$$



Mjerenja s različitim statističkim težinama

Prema tome, opća nepouzdanost je:

$$\bar{M} = \sqrt{\frac{1}{\sum_{j=1}^l \frac{1}{M_j^2}}}$$



Mjerenja s različitim statističkim težinama

Kako računati?

(i) $\bar{x}_i \approx \bar{x}_j$ i $M_i \approx M_j, \forall i, j$

koristiti gornje formule za $\bar{\bar{x}}$ i \bar{M}

(ii) $M_k \ll M_i$, za neki k , tj. rezultat $X_k = \bar{x}_k \pm M_k$ puno je precizniji od svih ostalih.
 $w_k \gg w_i$ za sve i , pa uzimamo $w_k = 1$:

$$\bar{\bar{x}} = \bar{x}_k; \quad \bar{M} = M_k$$

(iii) $M_i \approx M_j$ za sve i, j , ali \bar{x}_i i \bar{x}_j se znatno razlikuju za sve i, j

zanemarujemo M_i , te smatramo \bar{x}_i neposredno mjerenim veličinama:

$$\bar{\bar{x}} = \frac{1}{l} \sum_{j=1}^l \bar{x}_j; \quad \bar{M} = \sqrt{\frac{\sum_{j=1}^l (\bar{\bar{x}} - \bar{x}_j)^2}{l(l-1)}}$$



Korelacija u linearnoj regresiji

Zamislimo neki događaj na kojem su definirana dva obilježja x i y .

Svako promatranje tog događaja daje par brojeva (x, y) .

Npr. elastična sila, obilježja: masa utega i duljina opruge
slobodni pad, obilježja: vrijeme i prijeđeni put
studenti, obilježja: uspjeh na prijemnom i uspjeh na studiju

Pitamo se: jesu li obilježja x i y na bilo koji način povezana, tj. **korelirana?**

Drugim riječima, postoji li funkcionalna veza $y(x)$ koja može dobro opisati parove (x, y) ?

Mi ćemo se zadržati na najjednostavnijem slučaju, tj. istraživanjem postoji li zadovoljavajući opis u okvirima **linearne regresije**.


$$y = ax + b$$



Korelacija u linearnoj regresiji

Prva ocjena može se donijeti crtanjem grafa, tj. točaka u x-y ravnini:

Primjer:



- možemo “od oka” povući pravac;
korelacija vjerojatno postoji:
1. koja je jednadžba pravca?
2. koja je kvantitativna ocjena
postojanja korelacije

- ne možemo “od oka” povući pravac;
korelacija vjerojatno ne postoji:
I. koja je kuantitativna ocjena
nepostojanja korelacije



Korelacija u linearnoj regresiji

Događaj možemo tretirati kao 2D slučajnu varijablu, pri čemu frekvencija pojavljivanja nekog događaja ima značenje (nenormirane) vjerojatnosti:

$$P(x_i, y_j) \Leftrightarrow \frac{f_{i,j}}{N}, \quad N = \sum_{i=1}^n \sum_{j=1}^m f_{i,j}$$

$$f_i = \sum_{j=1}^m f_{ij}; \quad f_j = \sum_{i=1}^n f_{ij}$$

Npr. $\{(1,1), (1,1), (1,2), (2,2), (2,2), (2,2)\}$

$$f_{11} = 2, f_{12} = 1, f_{22} = 2; \quad N = 2 + 1 + 2 = 5$$



Korelacija u linearnoj regresiji

Također vrijedi:

$$\bar{x} = \frac{1}{N} \sum_{i,j} f_{i,j} x_i = \frac{1}{N} \sum_{i=1}^n f_i x_i$$

$$\bar{y} = \frac{1}{N} \sum_{i,j} f_{i,j} y_j = \frac{1}{N} \sum_{j=1}^m f_j y_j$$

$$\sigma_x^2 = \frac{1}{N} \sum_{i,j} f_{i,j} (x_i - \bar{x})^2 = \frac{1}{N} \sum_{i=1}^n f_i (x_i - \bar{x})^2$$

$$\sigma_y^2 = \frac{1}{N} \sum_{i,j} f_{i,j} (y_j - \bar{y})^2 = \frac{1}{N} \sum_{j=1}^m f_j (y_j - \bar{y})^2$$

$$\sigma_{xy} = \frac{1}{N} \sum_{i,j} f_{i,j} (x_i - \bar{x})(y_j - \bar{y}) = \frac{1}{N} \sum_{i,j} f_{i,j} x_i y_j - \bar{x} \cdot \bar{y}$$



Korelacija u linearnoj regresiji

Sjetimo se da je za nezavisna svojstva x i y , $\sigma_{xy} = 0$

Definiramo *koeficijent korelacijs* r :

$$r = \frac{\sigma_{xy}}{\sigma_x \sigma_y}$$

$\sigma_{xy} \rightarrow 0$; r je mali, korelacija je slaba

Najčešći kriterij dobrote korelacijs:

- korelacija je dobra ukoliko je $|r| \geq 0.5$


U praksi je kriterij često stroži, npr $|r| \geq 0.7$

Dakle, r je *kvantitativni* pokazatelj prisustva ili odsustva korelacijs veličina x i y



Korelacija u linearnoj regresiji

No, kako povući najbolji pravac $y(x)$ ili $x(y)$?



Od oka?
Previše proizvoljno



Korelacija u linearnoj regresiji


Pretpostavimo da postoji funkcionalna veza $y(x) = ax + b$, gdje su a i b koeficijenti koji nabolje opisuju eksperimentalne rezultate

Preuredimo malo notaciju:

$$(x_i, y_j) \leftrightarrow (x_i, y_{ij})$$

npr. zaokruženu točku
možemo pisati


$$(x_2, y_4) \text{ ili } (x_2, y_{24})$$



Primjetimo da vrijedi: $\sum_{i,j} f_{ij} x_i y_j = \sum_{i,j} f_{ij} x_i y_{ij}$



Korelacija u linearnoj regresiji



Uvodimo sume kvadrata odstupanja:


$$S^2 = \frac{1}{N} \sum_{i,j} f_{ij} (y_{ij} - y(x_i))^2$$

Moramo kvadrirati razlike, jer dobar opis $y(x) = ax+b$ postiže se samo ako je podjednako pozitivnih i negativnih razlika, pa je:

$$\sum_{i,j} f_{ij} (y_{ij} - y(x_i)) \approx 0$$



Korelacija u linearnoj regresiji

$S^2 = \frac{1}{N} \sum_{i,j} f_{ij} (y_{ij} - ax_i - b)^2$  za najbolji odabir, ovaj izraz je minimalan

$$\frac{\partial S^2}{\partial a} = 0; \quad \frac{\partial S^2}{\partial b} = 0$$

$$\frac{\partial S^2}{\partial a} = -\frac{2}{N} \sum_{i,j} f_{ij} x_i (y_{ij} - ax_i - b) = 0$$

$$\frac{\partial S^2}{\partial b} = -\frac{2}{N} \sum_{i,j} f_{ij} (y_{ij} - ax_i - b) = 0$$



Korelacija u linearnoj regresiji

To nam daje sustav jednadžbi za a i b :

$$(1) \quad \sum_{i,j} f_{ij} y_{ij} = a \sum_{i,j} f_{ij} x_i + b \sum_{i,j} f_{ij}$$

$$(2) \quad \sum_{i,j} f_{ij} y_{ij} x_i = a \sum_{i,j} f_{ij} x_i^2 + b \sum_{i,j} f_{ij} x_i$$

Prepoznajmo sljedeće:

$$\sum_{i,j} f_{ij} y_{ij} = \sum_j f_j y_j = N\bar{y}; \quad \sum_{i,j} f_{ij} x_i = N\bar{x}$$

$$\sum_{i,j} f_{ij} y_{ij} x_i = N(\sigma_{xy} + \bar{x} \cdot \bar{y}); \quad \sum_{i,j} f_{ij} = N$$

$$\sum_{i,j} f_{ij} x_i^2 = \sum_i f_i x_i^2 = N\bar{x}^2$$



Korelacija u linearnoj regresiji

(1) $N\bar{y} = aN\bar{x} + bN \Rightarrow \bar{y} = a\bar{x} + b$ pravac ide kroz točku (\bar{x}, \bar{y})

$$(2) N(\sigma_{xy} + \bar{xy}) = (\bar{ax}^2 + b\bar{x})N$$

$$\sigma_{xy} + \bar{xy} = \bar{ax}^2 + b\bar{x}$$


To sve skupa daje:

$$a = \frac{\sigma_{xy}}{\bar{x}^2 - \bar{x}^2} = \frac{\sigma_{xy}}{\sigma_x^2}, \quad b = \bar{y} - \frac{\sigma_{xy}}{\sigma_x^2} \bar{x}$$



Korelacija u linearnoj regresiji

Pravac $y(x)=ax+b$ zovemo 'pravac y s obzirom na x', i on pokazuje kako aritmetičke sredine točaka y_{ij} ovise o x



- zaokružena točka je \bar{y}_2 , tj. aritmetička sredina svih točaka y_{2j}



Korelacija u linearnoj regresiji

Ekvivalentno, možemo promatrati kako \bar{x}_j ovisi o y , i tad dobivamo pravac 'x s obzirom na y'

$$x = Ay + B; \quad A = \frac{\sigma_{xy}}{\sigma_y^2} \quad B = \bar{x} - \frac{\sigma_{xy}}{\sigma_y^2} \bar{y}$$



Korelacija u linearnoj regresiji

Pogledajmo još kolika je suma kvadrata odstupanja za $y(x)$:

$$\begin{aligned} S^2 &= \frac{1}{N} \sum_{i,j} f_{ij} (y_{ij} - ax_i - b)^2 = \frac{1}{N} \sum_{i,j} f_{ij} \left(y_{ij} - \frac{\sigma_{xy}}{\sigma_x^2} x_i - \bar{y} + \frac{\sigma_{xy}}{\sigma_x^2} \bar{x} \right)^2 = \\ &= \frac{1}{N} \sum_{i,j} f_{ij} \left((y_{ij} - \bar{y}) - \frac{\sigma_{xy}}{\sigma_x^2} (x_i - \bar{x}) \right)^2 = \\ &= \frac{1}{N} \sum_{i,j} f_{ij} (y_{ij} - \bar{y})^2 + \frac{\sigma_{xy}^2}{\sigma_x^4} \frac{1}{N} \sum_{i,j} f_{ij} (x_i - \bar{x})^2 - 2 \sum_{i,j} f_{ij} (y_{ij} - \bar{y})(x_i - \bar{x}) \frac{\sigma_{xy}}{\sigma_x^2} = \\ &= \sigma_y^2 + \frac{\sigma_{xy}^2}{\sigma_x^4} \sigma_x^2 - 2 \frac{\sigma_{xy}}{\sigma_x^2} \sigma_{xy} = \sigma_y^2 - \frac{\sigma_{xy}^2}{\sigma_x^2} = \sigma_y^2 \left(1 - \frac{\sigma_{xy}^2}{\sigma_x^2 \sigma_y^2} \right) = \sigma_y^2 (1 - r^2) \end{aligned}$$

$$S^2 = \sigma_y^2 (1 - r^2)$$



Korelacija u linearnoj regresiji

Očito je sljedeće:

- (1) $S^2 > 0$, jer $|r| \leq 1$
- (2) Za $r = 1$, $S^2 = 0$, tj. korelacija je potpuna i sve točke leže na pravcu $y = ax + b$