

# 15. LINEARNA REGRESIJA

## PREDOLOČEN SISTEM LINEARNIH ENAČB

1/5

Tako dostopen objekt v ravnini  $x, y$  so opazovali s štirih različnih lokacij:

Pri opazovanju je izmeril, da objekt leži na premici  $a_{11}x + a_{12}y = b_1$ .

Drugi " " " "

$$a_{21}x + a_{22}y = b_2$$

Tretji " " " "

$$a_{31}x + a_{32}y = b_3$$


Četrta " " " "

$$a_{41}x + a_{42}y = b_4$$

Dobili smo sistem štirih enačb za neznanli  $x, y$ :

$$\begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \\ a_{31} & a_{32} \\ a_{41} & a_{42} \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \\ b_4 \end{bmatrix}$$

Primerjenju mestojajev manjše slučajne napake (šum ...), tako da se te štiri premice ne sečajo v isti točki (glej 1).



(OVERDETERMINED)

Sistem torej formalno ni rešljiv. Preverimo, da je PREDOLOČEN.

Nadalje je vsaka meritev nekaj vredna. Kako uporabiti vse štiri meritve za to, da dobimo dober objekt?

Oglejmo si splošno situacijo.

Imamo predložen sistem  $m$  linearnih enačb za  $n$  neznank:

$$\boxed{A\vec{x} = \vec{y}} \quad (A \in \mathbb{R}^{m \times n}, m > n);$$

z več enačbami, kot je neznank. Če se ne moremo najti  
tak  $\vec{x}$ , da bi bil  $A\vec{x} - \vec{y} = 0$ , se bomo zadovoljili s takim  $\vec{x}$ ,  
da bo

$$\boxed{\|A\vec{x} - \vec{y}\| \text{ minimalna.}}$$

Torej iščemo najbližjo aproksimacijo za  $\vec{y}$  v  $\text{im } A = A\mathbb{R}^n$ .

To pa je najbližja projekcija vektorja  $\vec{y}$  na  $\text{im } A$ . Zato je  
 $(A\vec{x} - \vec{y}) \perp \text{im } A$ , se pravi  $\langle A\vec{x} - \vec{y}, A\vec{z} \rangle = 0$  za vse  $\vec{z} \in \mathbb{R}^n$ .

Od tod je  $\langle A^T(A\vec{x} - \vec{y}), \vec{z} \rangle = 0$  za vse  $\vec{z} \in \mathbb{R}^n$ , torej

$(A^T A \vec{x} - A^T \vec{y}) \perp \mathbb{R}^n$  in od tod sledi  $A^T A \vec{x} - A^T \vec{y} = 0$ :


$$\boxed{A^T A \vec{x} = A^T \vec{y}.}$$

NORMALNA ENAČBA

Tu je  $A^T A$  kvadratna matrika velikosti  $n \times n$ .

\* [Če je  $\det A \neq 0$ , je  $A^T A$  nesingularna, zato ima obratni  
sistem matricno eno rešitev  $\vec{x}$ . (Res, če je  $A^T A \vec{z} = 0$ , je  
 $\langle A^T A \vec{z}, \vec{z} \rangle = \langle A \vec{z}, A \vec{z} \rangle = 0$ , zato  $A \vec{z} = 0$  in tako  $\vec{z} = 0$ . Torej je  
 $\det(A^T A) \neq 0$ .) ]

Imamo vrsto meritev skalarnih količin  $y$ . Včasih smo zanje izmerili vrednost  $y_i$  ( $i = 1, 2, \dots, m$ ). Najširše rezultate meritev v koordinatnem sistemu (slika 1).



Slika 1

Iz slike 1 vidimo, da ne moremo dobiti, da bi te točke ležale na premici. Pri meritvah nastajajo slučajne napake...

Kako najzadejemo premico, ki bi se najbolj približala tem podatkom, tako da bi maksimalno izkoristili rezultate meritev?

Če bi te točke ležale na premici z enačbo  $y = pt + q$ , bi veljalo

$$t_i p + q = y_i \quad (i = 1, 2, \dots, m).$$

Spet imamo predložen sistem enačb za  $p, q$ :

$$\begin{bmatrix} t_1 & 1 \\ t_2 & 1 \\ \vdots & \vdots \\ t_m & 1 \end{bmatrix} \begin{bmatrix} p \\ q \end{bmatrix} = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix} = \vec{y}$$

Če pišemo  $A = \begin{bmatrix} t_1 & 1 \\ t_2 & 1 \\ \vdots & \vdots \\ t_m & 1 \end{bmatrix}$ , je  $A \begin{bmatrix} p \\ q \end{bmatrix} = \vec{y}$ . Rešiti moramo


toje normalni sistem:

$$A^T A \begin{bmatrix} p \\ q \end{bmatrix} = \vec{y}.$$

Če je  $\begin{bmatrix} p \\ q \end{bmatrix}$  rešitev normalnega sistema, je premica  $t \mapsto pt + q$

Primer 1: Imamo tabelo

t	0	1	2
y	-3	0	2



Te tri točke ne leže na istoj premici (shizka 2).

Če bi ležale na premici  $y = pt + q$ , bi veljalo:


$$p \cdot 0 + q = -3$$

$$p \cdot 1 + q = 0$$

$$p \cdot 2 + q = 2$$

Imamo predložen sistem:

$$\underbrace{\begin{bmatrix} 0 & 1 \\ 1 & 1 \\ 2 & 1 \end{bmatrix}}_A \begin{bmatrix} p \\ q \end{bmatrix} = \begin{bmatrix} -3 \\ 0 \\ 2 \end{bmatrix}$$



Pomnožimo z  $A^T$  na obeh straneh, da dobimo normalni sistem:

$$\begin{bmatrix} 0 & 1 & 2 \\ 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} 0 & 1 \\ 1 & 1 \\ 2 & 1 \end{bmatrix} \begin{bmatrix} p \\ q \end{bmatrix} = \begin{bmatrix} 0 & 1 & 2 \\ 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} -3 \\ 0 \\ 2 \end{bmatrix}$$


ali

$$\begin{bmatrix} 5 & 3 \\ 3 & 3 \end{bmatrix} \begin{bmatrix} p \\ q \end{bmatrix} = \begin{bmatrix} 4 \\ -1 \end{bmatrix}$$


Od tod je  $p = \frac{5}{2}$ ,  $q = -\frac{17}{6}$ . Enača regresijske premice je (shizka 3)

$$\underline{\underline{y = \frac{5}{2}t - \frac{17}{6}}}$$

Včasih je očitno, da premoča mi dobra aproksimacija te mase podatke.



Slika 3



Slika 4

Na sliki 3 bi morala poskusiti z aproksimacijo  $y = p_0 + p_1 t + p_2 t^2$ ,  
na sliki 4 pa morda z  $y = p_1 + p_2 \ln t$ .

Denimo, da želimo naše podatke aproksimirati s funkcijo

$$f = p_1 f_1 + p_2 f_2 + \dots + p_m f_m,$$

kjer so  $f_1, \dots, f_m$  znane funkcije. Idejno bi bilo najti vektor

$$\vec{p} = \begin{bmatrix} p_1 \\ p_2 \\ \vdots \\ p_m \end{bmatrix}, \text{ da bi veljalo}$$

$$f(t_i) = f_1(t_i)p_1 + f_2(t_i)p_2 + \dots + f_m(t_i)p_m = y_i$$

za  $i = 1, \dots, m$  ali

$$A\vec{p} = \vec{y},$$

kjer je

$$A = \begin{bmatrix} f_1(t_1), f_2(t_1), \dots, f_m(t_1) \\ f_1(t_2), f_2(t_2), \dots, f_m(t_2) \\ \dots \\ f_1(t_m), f_2(t_m), \dots, f_m(t_m) \end{bmatrix}$$

ker to morda ne gre, iščemo torej  $\vec{p}$ , da bo

$$\|A\vec{p} - \vec{y}\| \text{ minimalna.}$$

Od tod sledi, da je najmanjša vrednost

$$A^T A \vec{p} = A^T \vec{y}. \quad (1)$$

Vemo, da bo potem  $\|A\vec{p} - \vec{y}\|^2$  minimalna, če prvi

$$\sum_{i=1}^m [f_1(t_i)p_1 + \dots + f_n(t_i)p_n - y_i]^2$$

je minimalna. Če je  $\vec{p}$  rešitev enačbe (1) in

$$f = \sum_{i=1}^m p_i f_i,$$

je torej  $\sum_{i=1}^m [f(t_i) - y_i]^2$  minimalna. Vsota kvadratov

odstopanj od REGRESIJSKE FUNKCIJE  $f$  je torej minimalna.

Zato naši metodi rečemo METODA NAJMANJŠIM KVADRATOM.

V letih 1800 - 1803 sta to metodo razvile francoski matematik LEGENDRE in nemški matematik GAUSS.

Obe sta proučevala orbite planetov in asteroidov, Gauss pa se je ukvarjal tudi z geodezijo, kjer je bilo treba pogosto ponovljati merjenja.

Primer 2. Iščeemo najboljšo aproksimacijo v obliki  $y = p_1 + p_2 \ln t$  za tabelo

t	1	2	3	4
y	2	3	3,5	4

Tu je  $f_1(t) = 1$  za vsak  $t$  in  $f_2(t) = \ln t$ . Pišemo  $\vec{p} = \begin{bmatrix} p_1 \\ p_2 \end{bmatrix}$ ,

$$A = \begin{bmatrix} 1 & 0 \\ 1 & \ln 2 \\ 1 & \ln 3 \\ 1 & \ln 4 \end{bmatrix}, \quad \vec{y} = \begin{bmatrix} 2 \\ 3 \\ 3,5 \\ 4 \end{bmatrix}$$

Potem je  $A^T A = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 0 & \ln 2 & \ln 3 & \ln 4 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 1 & \ln 2 \\ 1 & \ln 3 \\ 1 & \ln 4 \end{bmatrix} = \begin{bmatrix} 4 & \ln 24 \\ \ln 24 & c_{22} \end{bmatrix},$

gde je  $c_{22} = (\ln 2)^2 + (\ln 3)^2 + (\ln 4)^2 \approx 3,609.$

$$A^T y = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 0 & \ln 2 & \ln 3 & \ln 4 \end{bmatrix} \begin{bmatrix} 2 \\ 3 \\ 3,5 \\ 4 \end{bmatrix} = \begin{bmatrix} 12,5 \\ z_2 \end{bmatrix},$$

gde je  $z_2 = 3 \ln 2 + 3,5 \ln 3 + 4 \ln 4 \approx 11,467.$

Normalni sistem je :

$$\begin{aligned} 4p_1 + (\ln 24)p_2 &= 12,5 \\ (\ln 24)p_1 + c_{22}p_2 &= z_2 \end{aligned}$$

Od tad je  $p_1 \approx 1,998, p_2 \approx 1,419.$

za aproksimaciju namemo  $y = 1,998 + 1,419 \ln t.$

Izračunamo lakše:

$y(1) \approx 1,998$	$y(3) \approx 3,557$
$y(2) \approx 2,982$	$y(4) \approx 3,965,$

koje da je aproksimacija vrlo dobra.

Nelije.

# Linearna regresija & grafičnim računalom SHARP

Idemo v STATISTIČNI MENI.

Vnesemo podatke: Prva kartica:

$$(t_1) = x_1 = \dots$$

$$y_1 = \dots$$

Druge kartice ...

Nato gremo v meni za GRAFIČNE PRIKAZE V STATISTIKI:

Izberemo podmeni REG (regija).

Izberemo, v kateri množici funkcij bomo našli aproksimacijo.

Moje računalno ime za linearno regresijo naslednje možnosti:

$$a + bx$$

$$a + b \log x$$

$$a + b \ln x$$

$$a + \frac{b}{x}$$

Program nam izkazuje:

Prihvatimo tipko MENU, izberemo REG in določimo vrednosti za  $a, b$ .

# NALOGE

8/L

1. Poišči regresijsko premico za tabelo

t	-1	0	1	2
y	-7	-3	3	8

2. Za podatke iz primera 2 poišči najboljšo aproksimacijo v obliki  $y = p_1 + \frac{p_2}{x}$ .