

Käyrän sovitus PNS - menetelmällä

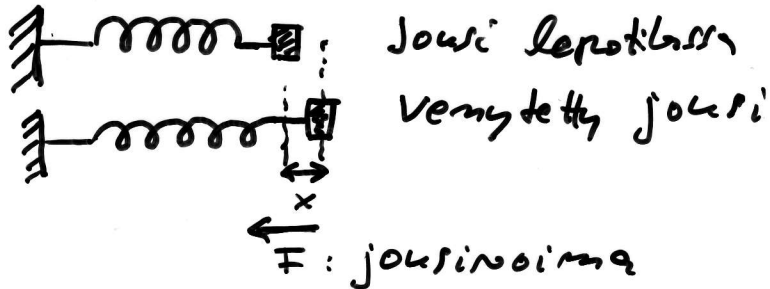
« PNS: Pienimmän neliösumman ...
« LSA: Least Squares

Lähteitä: Lay: 6.6: Application to Linear Models
KRE: 20.5: Least Squares Method
[Esitystapa poikkeaa tiyisiä luentotyylistä ja on kovasti rajoitettua]

Leon: Linear Algebra with applications, Pearson, 2006, ch 5. [Hyvä ohjelukemistökirja]

Johdandoesina: Jousivoima

Hooken laki: Jousivoima on verrannollinen venymään.
 $F = kx$



Teekkarit T_1 ja T_2 yhdessä laboratoriossa. Jousivoima?

Mittaukset:

F / N	x / cm
3	4
5	7
8	11

$$\begin{cases} 4k = 3 \Rightarrow k = \frac{3}{4} \\ 7k = 5 \Rightarrow k = \frac{5}{7} \\ 11k = 8 \Rightarrow k = \frac{8}{11} \end{cases}$$

Ristiriitaiset yhtälöt.

Mikä neuvoisi?

Teekkarit T_i ($i = 1$ tai 2)

Mikäis se oikeaan se PNS?

$$\begin{bmatrix} 4 \\ 7 \\ 11 \end{bmatrix} k = \begin{bmatrix} 3 \\ 5 \\ 8 \end{bmatrix}$$

(Harvoimaisen laike
kertoimatriisi!)

$$[4 \ 7 \ 11] \begin{bmatrix} 4 \\ 7 \\ 11 \end{bmatrix} k = [4 \ 7 \ 11] \begin{bmatrix} 3 \\ 5 \\ 8 \end{bmatrix}$$

$$\Leftrightarrow 186k = 135 \Rightarrow k \approx 0.726$$

Teekkari T₂-iti: "Eivät, jos oltaisiin laskettu
keskiarvot" Tällöin $k \approx 0.731$

T_i: "Ainakin edellisessä oli tyyli."

Jos lukua k pidetään vakiofunktiona,
tämä voidaan ajatella 0-asteisen
käyrän (polynomien) sovituksena


PNS - suora

Olkoon annettu mittauspisteet

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$$

Teoreettisesti (fysiikalaisesta, ..., psykologisesta,
silminmääräisestä) syystä voidaan otaksua,
että taustalla olevaa ilmiötä voidaan
mallintaa suoralla:

$$F(x) = c_0 + c_1 x$$



Neliösumma:

$$S(c_0, c_1) = \sum_{i=1}^n (y_i - F(x_i))^2$$

Tehtävä : Määrittämät kertoimet c_0 ja c_1 ,

s.e. $S(c_0, c_1) = \min.$

DATA		MALLIN ENNUSTE
x_1	y_1	$F(x_1) = c_0 + c_1 x_1$
x_2	y_2	$F(x_2) = c_0 + c_1 x_2$
\vdots	\vdots	\vdots
x_n	y_n	$F(x_n) = c_0 + c_1 x_n$

$$\begin{cases} c_0 + c_1 x_1 = y_1 \\ c_0 + c_1 x_2 = y_2 \\ \vdots \\ c_0 + c_1 x_n = y_n \end{cases} \quad \underbrace{\begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix}}_A \underbrace{\begin{bmatrix} c_0 \\ c_1 \end{bmatrix}}_{\vec{c}} = \underbrace{\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}}_{\vec{y}}$$

Yhtälöryhmän $A\vec{c} = \vec{y}$ PNS -ratkaisu
 merkitse sitä, että etsitään $\text{col } A : n$
 vektoria $c_0 [1, 1, \dots, 1]^T + c_1 [x_1, x_2, \dots, x_n]^T$
 jonka etäisyys vektorista $\vec{y} = [y_1, \dots, y_n]^T$
 on mahdollisimman pieni.

Tämä etäisyys on juuri

$$(c_0 + c_1 x_1 - y_1)^2 + (c_0 + c_1 x_2 - y_2)^2 + \dots + (c_0 + c_1 x_n - y_n)^2$$

$$= S(c_0, c_1).$$

Ratkaisu normaaliyhtälöillä :

$$A^T A \vec{c} = A^T \vec{y}$$

[PNS - suoran tapauksessa normaaliyhtälö-
 ratkaisu on riittävän ok, sillä $A^T A$ on 2×2
numeerisestikin]

Esim. Määritä PNS - suora, kun

$$xdata : 2 \ 5 \ 7 \ 8$$

$$ydata : 1 \ 2 \ 3 \ 3$$


$$\bar{X} = \begin{bmatrix} 1 & 2 \\ 1 & 5 \\ 1 & 7 \\ 1 & 8 \end{bmatrix}, \quad \bar{y} = \begin{bmatrix} 1 \\ 2 \\ 3 \\ 3 \end{bmatrix}$$

(Merh. vakioteeksi \bar{X})

NORMAALI-
YHT. : $\bar{X}^T \bar{X} \begin{bmatrix} c_0 \\ c_1 \end{bmatrix} = \bar{X}^T \bar{y} \iff \begin{bmatrix} 4 & 22 \\ 22 & 142 \end{bmatrix} \begin{bmatrix} c_0 \\ c_1 \end{bmatrix} = \begin{bmatrix} 9 \\ 57 \end{bmatrix}$

$$\left(\begin{array}{l} \begin{bmatrix} 1 & 1 & 1 & 1 \\ 2 & 5 & 7 & 8 \end{bmatrix} \begin{bmatrix} 1 \\ 2 \\ 3 \\ 3 \end{bmatrix} = \begin{bmatrix} 4 & 22 \\ 22 & 142 \end{bmatrix} \\ \text{--- " ---} \begin{bmatrix} 1 & 2 & 3 & 3 \end{bmatrix}^T = \begin{bmatrix} 9 & 57 \end{bmatrix}^T \end{array} \right)$$

$$\Rightarrow \bar{c} = \begin{bmatrix} \frac{2}{7} \\ \frac{5}{14} \end{bmatrix}^T, \quad y = \frac{2}{7} + \frac{5}{14}x$$



Matlab :

$$\gg xd = [2 \ 5 \ 7 \ 8]; \quad yd = [1 \ 2 \ 3 \ 3];$$

$$\gg m = \text{length}(xd) \% \text{ yleensä dataa paljon}$$

$$\gg \bar{X} = [\text{ones}(m, 1) \ xd]$$

$$\gg \bar{X}\bar{X} = \bar{X}' * \bar{X}; \quad \bar{X}\bar{y} = \bar{X}' * yd';$$

$$\gg c = \bar{X}\bar{X} \setminus \bar{X}\bar{y}$$

$$\gg x = [0 \ 9]; \quad y = c(1) + c(2) * x;$$

$$\gg \text{plot}(x, y, 'r'); \text{hold on}; \text{plot}(xd, yd, 'o'); \text{grid}$$

Yleinen lineaarinen malli.

Edellinen on helppo yleistää polynomimallille. Jos haluttaisiin sovittaa dataan

2. asteen polynomii, niin edellä oleva

funktionmalli saisi muodon $F(x) = c_0 + c_1x + c_2x^2$

Tämä johtaisi PNS - tekniikan:

$$\underbrace{\begin{bmatrix} 1 & x_0 & x_0^2 \\ 1 & x_1 & x_1^2 \\ \vdots & \vdots & \vdots \\ 1 & x_n & x_n^2 \end{bmatrix}}_{\underline{X}} \begin{bmatrix} c_0 \\ c_1 \\ c_2 \end{bmatrix} = \underbrace{\begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_n \end{bmatrix}}_{\underline{y}}$$

(Vaihdettiin data-indeksiä alkaen 0:sta \rightarrow $n+1$ datapist.)

Tätä voidaan jatkua n -asteiseen polynomiiin ($n+1$ kerrointa) saakka.

Tällöin ollaankin matriisissa J interpolointitekniikassa, jolla on aina 1-kärsiväisyys, kun x_i -pisteet erilliset.

Voimme osoittaa esim. Lagrangen menetelmällä.

(Kts. vaikka Luento1-36.html:n "Solmu"-linkkiä.)

Mallia ei ole yleensä järkevästi pakottaa kulkemaan tarkasti datapisteiden kautta. Korkeasteinen polynomii heilhtelee voimakkaasti.

Ainiesimerkkinä voisi olla suora mallintava data, jossa on hiukan virhettä. Tällöin esim. 10 datapisteen kautta kulkeva 9 asteen polynomii johtaisi toteutisesti harhaan.

Kts. L/PNSsuorajointipol.html

Gleisesdi: Dataa kuvaava lineaarinen funktiomalli voidaan muodostaa annettujen "kantafunktioiden" lineaarikon - lineaariksi:

$$y = F(x) = c_0 \phi_0(x) + c_1 \phi_1(x) + \dots + c_n \phi_n(x)$$

Polynomimallissa siis $\phi_j(x) = x^j$.

Annettu data: x_0, \dots, x_n
 y_0, \dots, y_n

$$F(x_i) = c_0 \phi_0(x_i) + c_1 \phi_1(x_i) + \dots + c_n \phi_n(x_i)$$

Aivan samoin kuin edellä, RMS - tekniik-

min $\sum_{i=0}^n (y_i - F(x_i))^2$ johtaa ylimääräis-

tyyseen yhtälöryhmään $\Sigma \vec{c} = \vec{y}$,

missä

$$\Sigma = \begin{bmatrix} \phi_0(x_0) & \phi_1(x_0) & \dots & \phi_n(x_0) \\ \phi_0(x_1) & \phi_1(x_1) & \dots & \phi_n(x_1) \\ \vdots & \vdots & \ddots & \vdots \\ \phi_0(x_n) & \phi_1(x_n) & \dots & \phi_n(x_n) \end{bmatrix}$$

Esim. Jos data on jaksoilista, voidaan ottaa kantafunktioiksi esim.

$$\phi_0 \equiv 1, \phi_1(x) = \sin x, \phi_2(x) = \cos x, \\ \phi_3(x) = \sin 2x, \phi_4(x) = \cos 2x \\ \dots$$

HUOM! "Lineaarinen" tarkoittaa lineaarisuutta parametrien c_0, c_1, \dots suhteen. Mallintava funktio $F(x)$ voi olla vaikka kuinka "kihara".

Muita keinoja PNS - laskentaan

Normaalilyhtälöt : $A^T A \vec{x} = A^T \vec{b}$.

Numeerisesti raskas, jos matriisin A on paljon sarakkeita (ja jos dataa paljon).

Miten neuvoksi? 1) QR - hajotelma

Lause 12 (Lay 6.4 s. 405)

$A (m \times n)$, LRT sarakkeet. Tällöin A voidaan esittää muodossa $A = QR$, missä

$Q (m \times m)$, ON sarakkeet

$R (n \times n)$, yläkolmionmatriisi, diag. alkio $\neq 0$.

Tod. Juoni: Gram-Schmidt - ortogonalisointi $\Rightarrow Q$:n sarakkeet.

Menetelmä antaa kolmiomaisen matriisin kertoimia r_{ij} , niistä rakentuu R. \square

Tästä voidaan pitää lähinnä olemassaolo - todistuksena.

Oikeasti hajotelma muodostetaan ns. Householder'n muunnoksilla vähän samaan tyyliin kuin LU-hajotelma rakennettiin alkeismatriiseilla kertomalla.

Kts. KRE⁹ 20.9: Tridiagonalization and QR-Fact.

KRE - kirjassa QR - hajotelma esitetään menetelmänä ominuusanvojen ja vektorien laskentaan.

PNS - reth. $A^T A \vec{x} = A^T \vec{b}$

$A = QR, Q^T Q = I$

$(QR)^T QR \vec{x} = (QR)^T \vec{b}$

R kääntynyt yläkolmion.

$R^T Q^T I$

$\Leftrightarrow R^T R \vec{x} = R^T Q^T \vec{b}$ | korr. vas $(R^T)^{-1}$:llä

$\Leftrightarrow R \vec{x} = Q^T \vec{b}$

RATKAISU TAKAISINSIJOTUKSELLA