

Aproximarea funcțiilor prin metoda celor mai mici pătrate

Prof.dr.ing. Gabriela Ciuprina


Universitatea "Politehnica" București, Facultatea de Inginerie Electrică

Suport didactic pentru disciplina *Algoritmi Numerici*, 2016-2017


Cuprins

- 1 **Introducere**
 - Formularea problemei
 - Ideea metodei CMMP
- 2 **CMMP prin rezolvarea sistemului normal**
 - Funcții de bază
 - Algoritm
 - Și asta nu e tot...
- 3 **CMMP prin factorizarea QR**
 - Ideea QR
 - Algoritm
- 4 **CMMP prin descompunerea SVD**
 - Ideea SVD
 - Algoritm
 - Concluzii

Interpolare vs. aproximare



Interpolare



Aproximare

Se dă un set de date (x_k, y_k) , $k = 0, \dots, m$, unde $y_k = f(x_k)$.

Se caută o aproximare notată $g(x)$, unde $g(x_k) \approx y_k$.

Ideea metodei

Funcția de aproximare se caută a.î:

$$\|g(x) - f(x)\| \quad \text{minimă}$$

Deoarece f este cunoscută într-un număr discret de puncte \Rightarrow norma discretă (de exemplu norma Euclidiană discretă).

Metoda celor mai mici pătrate (CMMP) caută g a.î:


$$E = \sum_{k=0}^m (f(x_k) - g(x_k))^2 \quad \text{minimă} \quad (1)$$

Regresia liniară

$$g(x) = c_0 + c_1 x \quad c_0 = ?, c_1 = ?.$$

Exemplu: $m = 3$: (1,3), (2,1), (4,4).


$$\begin{aligned} E(c_0, c_1) &= (y_0 - c_0 - c_1 x_0)^2 + \\ &+ (y_1 - c_0 - c_1 x_1)^2 + \\ &+ (y_2 - c_0 - c_1 x_2)^2 = \\ &= (3 - c_0 - c_1)^2 + \\ &+ (1 - c_0 - 2c_1)^2 + \\ &+ (4 - c_0 - 4c_1)^2. \end{aligned}$$



Regresia liniară

$$\begin{aligned}
 E(c_0, c_1) &= (y_0 - c_0 - c_1 x_0)^2 + (y_1 - c_0 - c_1 x_1)^2 + (y_2 - c_0 - c_1 x_2)^2 = \\
 &= (3 - c_0 - c_1)^2 + (1 - c_0 - 2c_1)^2 + (4 - c_0 - 4c_1)^2.
 \end{aligned} \tag{2}$$

$$\left\{ \begin{array}{l} \frac{\partial E}{\partial c_0} = 0, \\ \frac{\partial E}{\partial c_1} = 0. \end{array} \right. \Rightarrow \left\{ \begin{array}{l} 3c_0 + 7c_1 = 8, \\ 7c_0 + 21c_1 = 21 \end{array} \right. \Rightarrow c_0 = 1.5, \quad c_1 = 0.5. \tag{3}$$




$$g(1) = 2, \quad g(2) = 2.5, \quad g(3) = 3.5;$$

$$\min E = (3 - 2)^2 + (1 - 2.5)^2 + (4 - 3.5)^2$$

Regresia liniară

$$\begin{aligned}
 E(c_0, c_1) &= (y_0 - c_0 - c_1 x_0)^2 + (y_1 - c_0 - c_1 x_1)^2 + (y_2 - c_0 - c_1 x_2)^2 = \\
 &= (3 - c_0 - c_1)^2 + (1 - c_0 - 2c_1)^2 + (4 - c_0 - 4c_1)^2.
 \end{aligned} \tag{2}$$

$$\left\{ \begin{array}{l} \frac{\partial E}{\partial c_0} = 0, \\ \frac{\partial E}{\partial c_1} = 0. \end{array} \right. \Rightarrow \left\{ \begin{array}{l} 3c_0 + 7c_1 = 8, \\ 7c_0 + 21c_1 = 21 \end{array} \right. \Rightarrow c_0 = 1.5, \quad c_1 = 0.5. \tag{3}$$



$$g(1) = 2, \quad g(2) = 2.5, \quad g(3) = 3.5;$$

$$\min E = (3 - 2)^2 + (1 - 2.5)^2 + (4 - 3.5)^2$$

Regresia liniară

Set oarecare de date:

$$E(c_0, c_1) = \sum_{k=0}^m (y_k - c_0 - c_1 x_k)^2, \quad (4)$$

$$\begin{cases} \frac{\partial E}{\partial c_0} = 0, \\ \frac{\partial E}{\partial c_1} = 0. \end{cases} \Rightarrow \begin{cases} \sum_{k=0}^m -2(y_k - c_0 - c_1 x_k) = 0, \\ \sum_{k=0}^m -2x_k(y_k - c_0 - c_1 x_k) = 0. \end{cases} \quad (5)$$

\Rightarrow

$$\begin{cases} c_0(m+1) + c_1 \sum_{k=0}^m x_k = \sum_{k=0}^m y_k, \\ c_0 \sum_{k=0}^m x_k + c_1 \sum_{k=0}^m x_k^2 = \sum_{k=0}^m x_k y_k. \end{cases} \quad (6)$$

Sistem normal

Regresia liniară

Soluția se poate calcula explicit:

$$c_0 = \frac{d_0}{d}, \quad c_1 = \frac{d_1}{d}, \quad (7)$$

unde

$$d = (m+1) \sum_{k=0}^m x_k^2 - \left(\sum_{k=0}^m x_k \right)^2, \quad (8)$$

$$d_0 = \left(\sum_{k=0}^m x_k^2 \right) \left(\sum_{k=0}^m y_k \right) - \left(\sum_{k=0}^m x_k \right) \left(\sum_{k=0}^m x_k y_k \right), \quad (9)$$

$$d_1 = (m+1) \sum_{k=0}^m x_k y_k - \left(\sum_{k=0}^m x_k \right) \left(\sum_{k=0}^m y_k \right). \quad (10)$$

Regresia liniară - alt raționament

Condițiile de interpolare pentru datele din tabel și

$$g(x) = c_0 + c_1 x:$$

$$c_0 + c_1 x_k = y_k, \quad k = 1, \dots, m, \quad (11)$$

⇒ sistem supradeterminat de ecuații. Dacă notăm

$$\mathbf{A} = \begin{bmatrix} 1 & x_0 \\ 1 & x_1 \\ \vdots & \vdots \\ 1 & x_m \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_m \end{bmatrix}, \quad (12)$$

atunci (11) se scriu compact

$$\mathbf{A}\mathbf{c} = \mathbf{y}, \quad (13)$$

unde $\mathbf{c} = [c_0 \ c_1]^T$, iar sistemul normal este

$$\mathbf{A}^T \mathbf{A} \mathbf{c} = \mathbf{A}^T \mathbf{y}. \quad (14)$$

Regresia liniară - alt raționament

Reluăm exemplul simplu: $m = 3$: $(1,3)$, $(2,1)$, $(4,4)$.

$$\mathbf{A} = \begin{bmatrix} 1 & 1 \\ 1 & 2 \\ 1 & 4 \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} 1 & 3 \\ 1 & 1 \\ 1 & 4 \end{bmatrix}, \quad (15)$$

$$\mathbf{A}^T \mathbf{A} = \begin{bmatrix} 3 & 7 \\ 7 & 21 \end{bmatrix}, \quad \mathbf{A}^T \mathbf{y} = \begin{bmatrix} 8 \\ 21 \end{bmatrix}. \quad (16)$$

$$\begin{cases} 3c_0 + 7c_1 = 8, \\ 7c_0 + 21c_1 = 21 \end{cases} \Rightarrow c_0 = 1.5, \quad c_1 = 0.5. \quad (17)$$

Cazul general

Metoda celor mai mici pătrate nu este limitată la polinoame de gradul întâi.

Exemplu:

$$g(x) = c_0 \ln(x) + c_1 \sin(x) + c_2 \sqrt{x}.$$

- 1 Se minimizează funcția definită de $E = \sum_{k=0}^m (f(x_k) - g(x_k))^2$;
- 2 Se impun condițiile de minimizare;
- 3 Se rezolvă un sistem algebric liniar de dimensiune 3.

Cazul general

În general, se caută o aproximare de forma unui polinom generalizat

$$g(\mathbf{x}) = \sum_{j=0}^n c_j \varphi_j(\mathbf{x}), \quad (18)$$

unde $\varphi_j(\mathbf{x})$ se numesc *funcții de bază*.

OBS: $n + 1 < m + 1$

$$E(c_0, c_1, \dots, c_n) = \sum_{k=0}^m (g(\mathbf{x}_k) - f(\mathbf{x}_k))^2 = \sum_{k=0}^m \left(\sum_{j=0}^n c_j \varphi_j(\mathbf{x}_k) - y_k \right)^2. \quad (19)$$

Cazul general

$$E(c_0, c_1, \dots, c_n) = \sum_{k=0}^m (g(x_k) - f(x_k))^2 = \sum_{k=0}^m \left(\sum_{j=0}^n c_j \varphi_j(x_k) - y_k \right)^2. \quad (20)$$

Punctul de minim al acestei funcții este un punct critic:

$$\frac{\partial E}{\partial c_i} = 0, \quad i = 0, \dots, n. \quad (21)$$

Înlocuind expresia (20) în (21) rezultă

$$\sum_{j=0}^n \left(\sum_{k=0}^m \varphi_i(x_k) \varphi_j(x_k) \right) c_j = \sum_{k=0}^m y_k \varphi_i(x_k), \quad i = 0, \dots, n. \quad (22)$$

Sistem normal dificil de rezolvat dacă φ_k nu sunt alese
potrivit

Cazul general - alt raționament

Condițiile de interpolare pentru datele din tabel și $g(x)$

$$g(x_k) = y_k, \quad k = 1, \dots, m, \quad (23)$$

⇒ sistem supradeterminat de ecuații. Notăm

$$\mathbf{A} = \begin{bmatrix} \varphi_0(x_0) & \varphi_1(x_0) & \cdots & \varphi_n(x_0) \\ \varphi_0(x_1) & \varphi_1(x_1) & \cdots & \varphi_n(x_1) \\ \vdots & \vdots & & \vdots \\ \varphi_0(x_m) & \varphi_1(x_m) & \cdots & \varphi_n(x_m) \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} y_0 \\ y_1 \\ \vdots \\ y_m \end{bmatrix}, \quad (24)$$

atunci (23) se scriu compact

$$\mathbf{A}\mathbf{c} = \mathbf{y}, \quad (25)$$

unde $\mathbf{c} = [c_0, c_1 \dots c_{n+1}]^T$. Sistemul normal:

$$\mathbf{A}^T \mathbf{A} \mathbf{c} = \mathbf{A}^T \mathbf{y}. \quad (26)$$

Funcții de bază clasice

Sistemul normal de rezolvat

$$\mathbf{Nc} = \mathbf{t} \quad (27)$$

are, în cazul *regresiei liniare* forma

$$\mathbf{N} = \begin{bmatrix} m+1 & \sum_{k=0}^m x_k \\ \sum_{k=0}^m x_k & \sum_{k=0}^m x_k^2 \end{bmatrix}, \quad \mathbf{t} = \begin{bmatrix} \sum_{k=0}^m y_k \\ \sum_{k=0}^m x_k y_k \end{bmatrix}. \quad (28)$$

Funcții de bază clasice

Sistemul normal de rezolvat

$$\mathbf{Nc} = \mathbf{t} \quad (29)$$

are, în cazul *regresiei parabolice* $g(x) = c_0 + c_1x + c_2x^2$,
 forma:

$$\mathbf{N} = \begin{bmatrix} m+1 & \sum_{k=0}^m x_k & \sum_{k=0}^m x_k^2 \\ \sum_{k=0}^m x_k & \sum_{k=0}^m x_k^2 & \sum_{k=0}^m x_k^3 \\ \sum_{k=0}^m x_k^2 & \sum_{k=0}^m x_k^3 & \sum_{k=0}^m x_k^4 \end{bmatrix}, \quad \mathbf{t} = \begin{bmatrix} \sum_{k=0}^m y_k \\ \sum_{k=0}^m x_k y_k \\ \sum_{k=0}^m x_k^2 y_k \end{bmatrix}. \quad (30)$$

OBS:

Generalizarea este ușoară pentru $n > 2$, dar sistemul este slab condiționat. :(

Funcții de bază clasice

Sistemul normal de rezolvat

$$\mathbf{Nc} = \mathbf{t} \quad (29)$$

are, în cazul *regresiei parabolice* $g(x) = c_0 + c_1x + c_2x^2$,
 forma:

$$\mathbf{N} = \begin{bmatrix} m+1 & \sum_{k=0}^m x_k & \sum_{k=0}^m x_k^2 \\ \sum_{k=0}^m x_k & \sum_{k=0}^m x_k^2 & \sum_{k=0}^m x_k^3 \\ \sum_{k=0}^m x_k^2 & \sum_{k=0}^m x_k^3 & \sum_{k=0}^m x_k^4 \end{bmatrix}, \quad \mathbf{t} = \begin{bmatrix} \sum_{k=0}^m y_k \\ \sum_{k=0}^m x_k y_k \\ \sum_{k=0}^m x_k^2 y_k \end{bmatrix}. \quad (30)$$

OBS:

Generalizarea este ușoară pentru $n > 2$, dar sistemul este slab condiționat. :(**Remedii ?**

Funcții de bază clasice

Remedii:

- 1 Folosirea unor alte funcții de bază;
- 2 O altă strategie pentru CMMP, care nu rezolvă sistemul normal.

Funcții de bază - polinoame Chebyshev

În cazul în care se caută polinoamelor algebrice, atunci folosirea **polinoamelor Chebyshev**, definite recursiv ca:

$$T_0(x) = 1, \quad (31)$$

$$T_1(x) = x, \quad (32)$$

$$T_j(x) = 2xT_{j-1}(x) - T_{j-2}(x), \quad (33)$$

generează un sistem de ecuații mult mai bine condiționat.

OBS: Există un algoritm mai eficient de evaluare a aproximării $g(x)$ cu polinoame Chebyshev, decât rezolvarea sistemului normal [Cheney07].

Funcții de bază ortonormale

Ideal (din p.d.v. al condiționării) - varianta în care matricea coeficienților este matricea unitate, adică dacă

$$\sum_{k=0}^m \varphi_i(\mathbf{x}_k) \varphi_j(\mathbf{x}_k) = \delta_{ij}, \quad \text{unde } \delta_{ij} = \begin{cases} 1 & \text{dacă } i = j \\ 0 & \text{dacă } i \neq j \end{cases}, \quad (34)$$

ceea ce înseamnă că **funcțiile de bază sunt ortonormale**.

$$\mathbf{c}_j = \sum_{k=0}^m y_k \varphi_j(\mathbf{x}_k), \quad j = 0, \dots, n. \quad (35)$$

Funcții de bază ortonormale

Dacă notăm cu \mathcal{G} spațiul vectorial al funcțiilor generat de funcții de bază $\varphi_j(\mathbf{x})$

$$\mathcal{G} = \left\{ g : \exists c_0, c_1, \dots, c_n, \text{ astfel încât } g(\mathbf{x}) = \sum_{j=0}^n c_j \varphi_j(\mathbf{x}) \right\}, \quad (36)$$

atunci o bază ortonormală se poate construi de exemplu printr-o procedură Gram-Schmidt.

Algoritm - pași principali

Date:

- tabelul de valori;
- valorile în care se dorește evaluarea polinomului de aproximare.

Se alege:

- funcțiile de bază (în consecință și gradul polinomului de aproximare).

Se calculează:

- valorile polinomului de aproximare în punctele dorite.

Algoritm - pași principali

CMMP_SystemNormal

1. Asamblează \mathbf{A} și \mathbf{y}
2. Calculează $\mathbf{N} = \mathbf{A}^T \mathbf{A}$ și $\mathbf{t} = \mathbf{A}^T \mathbf{y}$
3. Rezolvă sistemul pătrat $\mathbf{Nc} = \mathbf{t} \Rightarrow \mathbf{c}$
4. Evaluează polinomul de aproximare $g(x)$ în punctul dorit

Algoritm - pași principali

Obs:

- În cazuri particulare, se poate evita calculul explicit al coeficienților \mathbf{c} .
- Se poate ca tabelul de valori să includă numere complexe.
În acest caz:

$$\mathbf{N} = \mathbf{A}^H \mathbf{A}, \quad \mathbf{t} = \mathbf{A}^H \mathbf{y}$$

unde \mathbf{A}^H (notată uneori și cu \mathbf{A}^*) este *transpusa hermitiană* adică $(a^H)_{ij} = \overline{a_{ji}}$.

- Sistemul normal $\mathbf{A}^H \mathbf{A} \mathbf{c} = \mathbf{A}^H \mathbf{y}$ este nesingular dacă și numai dacă \mathbf{A} este de rang complet [Trefethen97].

1. Netezirea datelor

- **Q:** În cazul unor date experimentale, ce grad să aibă polinomul de aproximare ?
- **A:** Am putea crește gradul polinomului până când avem o aproximare suficient de netedă a datelor.
- **Q:** Cum să stabilim cantitativ gradul de netezire?
- **A:** Folosind criteriile din statistică.

1. Netezirea datelor

- **Q:** În cazul unor date experimentale, ce grad să aibă polinomul de aproximare ?
- **A:** Am putea crește gradul polinomului până când avem o aproximare suficient de netedă a datelor.
- **Q:** Cum să stabilim cantitativ gradul de netezire?
- **A:** Folosind criteriile din statistică.

1. Netezirea datelor

- **Q:** În cazul unor date experimentale, ce grad să aibă polinomul de aproximare ?
- **A:** Am putea crește gradul polinomului până când avem o aproximare suficient de netedă a datelor.
- **Q:** Cum să stabilim cantitativ gradul de netezire?
- **A:** Folosind criterii din statistică.

1. Netezirea datelor

- **Q:** În cazul unor date experimentale, ce grad să aibă polinomul de aproximare ?
- **A:** Am putea crește gradul polinomului până când avem o aproximare suficient de netedă a datelor.
- **Q:** Cum să stabilim cantitativ gradul de netezire?
- **A:** Folosind criteriile din statistică.

1. Netezirea datelor

Forsythe [1957]:

- Se construiesc funcții de bază ortogonale adaptate setului de date;
- Se pp. că valorile din tabel sunt afectate de erori

$$y_i = p_N(x_i) + \varepsilon_i, \quad i = 0, \dots, m$$

unde ε_i sunt presupune variabile aleatoare independente distribuite normal.

- Pentru fiecare aproximare de grad n determinată se calculează varianța

$$\sigma_n^2 = \frac{1}{m-n} \sum_{i=0}^m [y_i - p_n(x_i)]^2$$

1. Netezirea datelor

Teoria statistică:

Dacă tendința datelor din tabel e într-adevăr polinom de gradul N atunci are loc

$$\sigma_0^2 > \sigma_1^2 > \dots > \sigma_N^2 = \sigma_{N+1}^2 = \dots = \sigma_m^2$$

Algoritmul va calcula aproximări de ordin crescător până când varianța nu se mai modifică. Pentru detalii ale acestui algoritm, consultați [Cheney07, subcapitolul 12.2].

2. Cazul unei funcții date prin cod

Dacă $f : [a, b] \rightarrow \mathbb{R}$ e dată prin cod, atunci mărimea de minimizat folosește o normă continuă

$$E(c_0, c_1, \dots, c_n) = \int_a^b [g(x) - f(x)]^2 dx. \quad (37)$$

În anumite aplicații e de dorit că aproximarea să se potrivească mai bine pe anumite intervale, caz în care se folosesc funcții pondere $w(x)$:

$$E(c_0, c_1, \dots, c_n) = \int_a^b [g(x) - f(x)]^2 w(x) dx. \quad (38)$$

2. Cazul unei funcții date prin cod

Sistemul normal de ecuații devine

$$\sum_{j=0}^n [\varphi_i(\mathbf{x})\varphi_j(\mathbf{x})w(\mathbf{x}) \, d\mathbf{x}] \, c_j = \int_a^b f(\mathbf{x})\varphi_i(\mathbf{x})w(\mathbf{x}) \, d\mathbf{x}, \quad i = 0, \dots, n. \quad (39)$$

Au fost propuse mai multe seturi de astfel de funcții ortogonale și ponderi potrivite.

3. Probleme de CMMP neliniare

Până acum polinoamele de interpolare = combinații liniare de coeficienți necunoscuți.

Dar dacă:

Pentru setul de date (x_k, y_k) , $k = 0, m$ se caută $g(x) = e^{cx}$?
Metoda CMMP minimizează funcția

$$E(c) = \sum_{k=0}^m (e^{cx_k} - y_k)^2 \quad (40)$$

Minimul are loc pentru $E'(c) = 0$, deci

$$2 \sum_{k=0}^m (e^{cx_k} - y_k) e^{cx_k} x_k = 0, \quad (41)$$

3. Probleme de CMMP neliniare

Pentru setul de date (x_k, y_k) , $k = 0, m$ se caută $g(x) = e^{cx}$.
CMMP duce la

$$\sum_{k=0}^m (e^{cx_k} - y_k) e^{cx_k} x_k = 0, \quad (42)$$

ecuație neliniară în $c \Rightarrow$

- rezolvare de ecuații neliniare;
- metode de minimizare.

3. Probleme de CMMP neliniare

Pentru setul de date (x_k, y_k) , $k = 0, m$ se caută $g(x) = e^{cx}$.
Acestea sunt **probleme de CMMP neliniare**.

OBS:

Reformulare ca o problemă de CMMP liniară:

Pentru setul de date $(x_k, \ln(y_k))$, $k = 0, m$ se caută $h(x) = cx$.
Valoarea c din problema reformulată nu este soluția ecuației neliniare (42), dar aproximarea $e^{h(x)}$ s-ar putea să fie satisfăcătoare.

Recapitularea ideilor de până acum

- Se caută aproximarea unor date dintr-un tabel de valori;
- CMMP găsește o funcție a.î. distanța dintre ea și tabelul de date să fie minimă (în normă Euclidiană);
- Aceasta problemă este echivalentă cu rezolvarea unui sistem de ecuații supradimensionat $\mathbf{Ac} = \mathbf{y}$;
- Acesta se poate aduce la un sistem de ecuații normal, cu matricea coeficienților pătrată;
- Condiționarea sistemului normal depinde de alegerea funcțiilor de bază;

Recapitularea ideilor de până acum

- Polinoamele algebrice clasice se pot folosi pentru regresii liniare sau parabolice;
- Pentru ordine mai mari e mai bine să se folosească polinoame Chebyshev;
- O procedură eficientă poate folosi polinoame ortogonale adaptate setului de date;
- Găsirea ordinului optim se poate facând o analiză statistică.

Recapitularea ideilor de până acum

CMMP poate fi privită ca o metodă de rezolvare a unui sistem supradeterminat, care a fost notat

$$\mathbf{Ac} = \mathbf{y}.$$

Minimizarea normei Euclidiene discrete este echivalentă cu minimizarea normei reziduului

$$\mathbf{r} = \mathbf{Ac} - \mathbf{y}.$$

În cele ce urmează, vom prezenta alți algoritmi CMMP, care nu assemblează sistemul normal.

Recapitularea ideilor de până acum

Problema formulată va fi aceea a rezolvării unui sistem supradeterminat de ecuații, pe care îl vom formula cu **notația standard**:

$$\mathbf{Ax} = \mathbf{b},$$

A - matrice dreptunghiulară de dimensiuni $(m + 1) \times (n + 1)$

b - vector coloană de dimensiune $(n + 1)$

x - soluția care se caută în sensul CMMP.

Recapitularea ideilor de până acum

$$\mathbf{Ax} = \mathbf{b}$$

\mathbf{x} reprezintă punctul pentru care se atinge minimul expresiei

$$E(x_0, x_1, \dots, x_n) = \sum_{k=0}^m \sum_{j=0}^n (a_{kj}x_j - b_k)^2$$

Dacă notăm reziduul (care depinde de \mathbf{x})

$$\mathbf{r} = \mathbf{b} - \mathbf{Ax}$$

atunci

$$\|\mathbf{r}\|_2^2 = E(x_0, x_1, \dots, x_n)$$

Un altă interpretare algebrică

$$\mathbf{Ax} = \mathbf{b}$$

$$\mathbf{r} = \mathbf{b} - \mathbf{Ax}$$

Rezolvarea unui sistem supradeterminat în sensul CMMP este echivalentă cu minimizarea normei Euclidiene a reziduuului.

⇔

Rezolvarea unui sistem supradeterminat în sensul CMMP este echivalentă cu găsirea unei soluții pentru care reziduuul este ortogonal pe imaginea transformării liniare \mathbf{Ax}


$$\mathbf{r} \perp \text{range}(\mathbf{A})$$

Un altă interpretare algebrică

Cazul $m = 1, n = 0$ (2 ec., 1 nec., pp. numere reale):

$$\begin{aligned} a_1 x &= b_1 \\ a_2 x &= b_2 \end{aligned} \quad (43)$$

$$\text{range}(\mathbf{A}) = \left\{ \mathbf{y} \in \mathbb{R}^2 : \exists x \in \mathbb{R}, y_1 = a_1 x, y_2 = a_2 x \right\}$$



Factorizarea QR

Factorizare QR redusă

$$\mathbf{A} = \hat{\mathbf{Q}}\hat{\mathbf{R}}$$

\mathbf{A} - matrice dreptunghiulară $(m + 1) \times (n + 1)$

$\hat{\mathbf{Q}}$ - matrice dreptunghiulară $(m + 1) \times (n + 1)$, **cu coloane ortonormale**

$\hat{\mathbf{R}}$ - matrice pătrată $(n + 1) \times (n + 1)$, **superior triunghiulară**

$$\hat{\mathbf{Q}}^H \hat{\mathbf{Q}} = \mathbf{I}_{n+1}$$

$r_{ij} > 0$, $r_{ij} = 0$ pentru $j < i$.

Factorizarea QR

Factorizare QR completă

$$A = QR$$

A - matrice dreptunghiulară $(m + 1) \times (n + 1)$

\hat{Q} - matrice pătrată $(m + 1) \times (m + 1)$, **unitară**

\hat{R} - matrice dreptunghiulară $(m + 1) \times (n + 1)$, **superior
triunghiulară**

$$\hat{Q}^H \hat{Q} = I_{m+1}$$

$r_{ij} > 0$, $r_{ij} = 0$ pentru $j < i$.

Factorizarea QR

$$A = \hat{Q} \hat{R}$$

$$A = Q R$$

Ideea QR

$$\mathbf{A} = \hat{\mathbf{Q}}\hat{\mathbf{R}}$$

$$\mathbf{Ax} = \mathbf{b}$$

$$\hat{\mathbf{Q}}\hat{\mathbf{R}}\mathbf{x} = \mathbf{b}$$

$$\hat{\mathbf{Q}}^H\hat{\mathbf{Q}}\hat{\mathbf{R}}\mathbf{x} = \hat{\mathbf{Q}}^H\mathbf{b}$$

Deoarece

$$\hat{\mathbf{Q}}^H\hat{\mathbf{Q}} = \mathbf{I}$$

rezulta

$$\hat{\mathbf{R}}\mathbf{x} = \hat{\mathbf{Q}}^H\mathbf{b}$$

Algoritm - pași principali

$$\mathbf{Ax} = \mathbf{b}$$

Date:

- matrice dreptunghiulară, cu coeficienți complecși \mathbf{A} ;
- vectorul termenilor liberi \mathbf{b}

Se calculează:

- soluția sistemului supradeterminat \mathbf{x} în sensul CMMP.

Algoritm - pași principali

CMMP_QR

1. Calculează factorizarea QR redusă a matricei \mathbf{A} : $\mathbf{A} = \hat{\mathbf{Q}}\hat{\mathbf{R}}$
2. Calculează vectorul $\mathbf{t} = \hat{\mathbf{Q}}^H\mathbf{b}$
3. Rezolvă sistemul pătrat, superior triunghiular $\hat{\mathbf{R}}\mathbf{x} = \mathbf{t} \Rightarrow \mathbf{x}$

Algoritm - calculul factorizării

Procedură de **ortogonalizare Gram-Schmidt** aplicată coloanelor matricei **A**

$$\mathbf{A} = \mathbf{R}_1 \mathbf{R}_2 \cdots \mathbf{R}_{n+1} = \hat{\mathbf{Q}}$$

apoi

$$\hat{\mathbf{R}} = \mathbf{R}_{n+1}^{-1} \mathbf{R}_n^{-1} \cdots \mathbf{R}_1^{-1}$$

Sau, mai eficient \Rightarrow

Algoritm - calculul factorizării

Procedură **Householder**

$$\mathbf{Q}_{n+1}\mathbf{Q}_n \cdots \mathbf{Q}_1 \mathbf{A} = \mathbf{R}$$


apoi

$$\mathbf{Q} = \mathbf{Q}_1^H \mathbf{Q}_2^H \cdots \mathbf{Q}_{n+1}^H$$

Obs

- \mathbf{Q}_k - matrice elementare unitare, urmăresc eliminarea elementelor ca la Gauss;
- Se obține factorizarea QR completă;

Algoritm - calculul factorizării



Trecerea la factorizarea QR redusă se obține prin ultimelor coloane din Q și a ultimelor linii din R .

Factorizarea SVD

SVD = *singular value decomposition* (desc. în valori singulare)

Factorizare SVD redusă

$$\mathbf{A} = \hat{\mathbf{U}}\hat{\mathbf{S}}\hat{\mathbf{V}}^H$$

\mathbf{A} - matrice dreptunghiulară $(m + 1) \times (n + 1)$ (presupusă de rang complet)

$\hat{\mathbf{U}}$ - matrice dreptunghiulară $(m + 1) \times (n + 1)$, **cu coloane ortonormale**

$\hat{\mathbf{S}}$ - matrice pătrată $(n + 1) \times (n + 1)$, **diagonală**

$\hat{\mathbf{V}}$ - matrice pătrată $(n + 1) \times (n + 1)$, **unitară**

$$\hat{\mathbf{V}}^H\hat{\mathbf{V}} = \mathbf{I}_{n+1}$$

$s_{ii} > 0$, $s_{ij} = 0$ pentru $i \neq j$.

Factorizarea SVD

SVD = *singular value decomposition* (desc. în valori singulare)

Factorizare SVD completă

$$\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^H$$

A - matrice dreptunghiulară $(m + 1) \times (n + 1)$ (presupusă de rang complet)

U - matrice pătrată $(m + 1) \times (m + 1)$, **unitară**



S - matrice dreptunghiulară $(m + 1) \times (n + 1)$, **diagonală**

V - matrice pătrată $(n + 1) \times (n + 1)$, **unitară**

$$\hat{\mathbf{V}}^H \hat{\mathbf{V}} = \mathbf{I}_{n+1}; \quad \hat{\mathbf{U}}^H \hat{\mathbf{U}} = \mathbf{I}_{m+1}$$

$$s_{ii} > 0, \quad s_{ij} = 0 \text{ pentru } i \neq j.$$

Factorizarea SVD



Ideea SVD

$$\mathbf{A} = \hat{\mathbf{U}}\hat{\mathbf{S}}\mathbf{V}^H$$

$$\mathbf{A}\mathbf{x} = \mathbf{b}$$

$$\hat{\mathbf{U}}\hat{\mathbf{S}}\mathbf{V}^H\mathbf{x} = \mathbf{b}$$

$$\hat{\mathbf{U}}\hat{\mathbf{S}}\mathbf{V}^H\mathbf{x} = \hat{\mathbf{U}}\hat{\mathbf{U}}^H\mathbf{b}$$

$$\hat{\mathbf{S}}\mathbf{V}^H\mathbf{x} = \hat{\mathbf{U}}^H\mathbf{b}$$

$$\hat{\mathbf{S}}(\mathbf{V}^H\mathbf{x}) = \hat{\mathbf{U}}^H\mathbf{b}$$

$$\hat{\mathbf{S}}\mathbf{w} = \hat{\mathbf{U}}^H\mathbf{b}$$

unde am notat

$$\mathbf{V}^H\mathbf{x} = \mathbf{w}$$

$$\mathbf{V}^H\mathbf{x} = \mathbf{V}^H\mathbf{V}\mathbf{w}$$

$$\mathbf{x} = \mathbf{V}\mathbf{w}$$

Algoritm - pași principali

$$\mathbf{Ax} = \mathbf{b}$$

Date:

- matrice dreptunghiulară, cu coeficienți complecși \mathbf{A} ;
- vectorul termenilor liberi \mathbf{b}

Se calculează:

- soluția sistemului supradeterminat \mathbf{x} în sensul CMMP.

Algoritm - pași principali

CMMP_SVD

1. Calculează descompunerea redusă în valori singulare a matricei \mathbf{A} : $\mathbf{A} = \hat{\mathbf{U}}\hat{\mathbf{S}}\mathbf{V}^H$
2. Calculează vectorul $\mathbf{t} = \mathbf{U}^H\mathbf{b}$
3. Rezolvă sistemul diagonal $\hat{\mathbf{S}}\mathbf{w} = \mathbf{t} \Rightarrow \mathbf{w}$
4. Calculează $\mathbf{x} = \mathbf{V}\mathbf{w}$.

Pentru detalii, consultați [Trefethen97],[Dumitrescu98].

Pseudoinversa unei matrice dreptunghiulare

$$\mathbf{Ax} = \mathbf{b} \Rightarrow \mathbf{x} = \mathbf{A}^+ \mathbf{b}$$

Pseudoinversa unei matrice diagonale este tot o matrice diagonală având pe diagonală inversele:

$$\mathbf{D} = \begin{bmatrix} d_1 & 0 & 0 \\ 0 & d_2 & 0 \end{bmatrix} \Rightarrow \mathbf{D}^+ = \begin{bmatrix} 1/d_1 & 0 \\ 0 & 1/d_2 \\ 0 & 0 \end{bmatrix} \quad (44)$$

Pseudoinversa unei matrice dreptunghiulare

$$\mathbf{Ax} = \mathbf{b} \Rightarrow \mathbf{x} = \mathbf{A}^+\mathbf{b}$$

$$\hat{\mathbf{U}}\hat{\mathbf{S}}\mathbf{V}^H\mathbf{x} = \mathbf{b}$$

$$\hat{\mathbf{S}}\mathbf{V}^H\mathbf{x} = \hat{\mathbf{U}}^H\mathbf{b}$$

$$\mathbf{V}^H\mathbf{x} = \hat{\mathbf{S}}^+\hat{\mathbf{U}}^H\mathbf{b}$$

$$\mathbf{x} = \mathbf{V}\hat{\mathbf{S}}^+\hat{\mathbf{U}}^H\mathbf{b}$$

Rezultă că

$$\mathbf{A}^+ = \mathbf{V}\hat{\mathbf{S}}^+\hat{\mathbf{U}}^H$$

Pseudoinversa unei matrice dreptunghiulare

Important:

- Pseudoinversa este unică dacă descompunerea în valori singulare se face astfel încât acestea să fie ordonate în S : $\sigma_1 \geq \sigma_2 \geq \dots$ [Cheney]
- În rezolvarea în sens CMMP a problemei $\mathbf{Ax} = \mathbf{b}$ prin descompunere SVD, este util să se analizeze valorile singulare ale matricei.

Este bine ca valorile singulare mai mici decât o anumită toleranță să fie anulate.

O astfel de abordare face ca metoda să fie cea mai stabilă din toate variantele.

Pseudoinversa unei matrice dreptunghiulare

Proprietăți ale pseudoinversei (proprietăți **Penrose**):

$$1 \quad \mathbf{A} = \mathbf{A}\mathbf{A}^+\mathbf{A}$$

$$2 \quad \mathbf{A}^+ = \mathbf{A}^+\mathbf{A}\mathbf{A}^+$$

$$3 \quad \mathbf{A}\mathbf{A}^+ = (\mathbf{A}\mathbf{A}^+)^T$$

$$4 \quad \mathbf{A}^+\mathbf{A} = (\mathbf{A}^+\mathbf{A})^T$$

Comparații între algoritmi

- 1 Din punct de vedere al timpului de calcul:
 - CMMP prin rezolvarea sistemului normal: $O(mn^2 + n^3/3)$;
 - CMMP prin QR: $O(2mn^2 + 2n^3/3)$;
 - CMMP prin SVD: $O(2mn^2 + 11n^3)$;
- 2 Din punct de vedere al stabilității:
 - CMMP prin rezolvarea sistemului normal - de folosit doar pentru regresii liniare sau parabolice;
 - CMMP prin QR - stabil dacă $\text{rang}(\mathbf{A}) = n+1$;
 - CMMP prin SVD - trebuie folosit dacă \mathbf{A} are deficiența de rang.

Matlab: `qr`, `svd`, `pinv`.

Referințe

Minimal:

[AN] Gabriela Ciuprina,

Algoritmi numerici pentru calcule științifice în ingineria electrică

Editura MatrixROM, 2013, pag. 143-168.

[Ioan98] D. Ioan et al., *Metode numerice in ingineria electrica*, Ed.

Matrix Rom, Bucuresti, 1998. (Capitolul 13)

Alte recomandări:

[Cheney] Ward Cheney and David Kincaid, *Numerical Mathematics and Computing*, Brooks/Cole publishing Company, 2000.

[Trefethen97] Lloyd N. Trefethen, David Bau III, *Numerical Linear Algebra*, SIAM 1997.

[Dumitrescu98] Bogdan Dumitrescu, Corneliu Popeea, Boris Jora, *Metode de calcul numeric matriceal. Algoritmi fundamentali*, Editura All, 1998.

Tema 8 (din categoria "examen")

- 1 Pregătiți date sintetice astfel: alegeți un polinom de grad 10 și perturbați-l cu valori aleatoare distribuite normal. Generați un tabel de date cu 50 de puncte;
- 2 Implementați și testați procedura de aproximare cu determinarea optimă a gradului polinomului de aproximare.

Notă: puteți folosi orice fel de funcții `matlab` doriți.

Scrieți un scurt raport care să reflecte rezolvarea temei. Este obligatoriu ca raportul să aibă: o pagină de titlu, un cuprins generat automat, o lista de referințe. Dați o structură coerentă raportului.