

6. OPTIMIZARE PE BAZA METODEI CELOR MAI MICI PATRATE


6.1 Metoda standard a celor mai mici pătrate (LS)

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.1. Funcția cost

O funcție cost fără medii statistice:

$$J = \sum_{n=i_1}^{i_2} |e(n)|^2$$



6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.1. Funcția cost

$$e(n) = d(n) - y(n) = d(n) - \sum_{k=0}^{N-1} w_k^*(n) x(n-k) = d(n) - \mathbf{w}^H(n) \mathbf{x}(n)$$

$$\mathbf{x}(n) = [x(n), x(n-1), \dots, x(n-N+1)]^T$$

Vom presupune că dispunem de setul de eșantioane:

$$x(1), x(2), \dots, x(M), \quad M > N.$$

În expresia lui J intervin eșantioane de la i_1-N+1 până la i_2 , $\Rightarrow i_1=N, i_2=M$, așa încât în expresia lui J intervin numai eșantioanele cunoscute ale observației. Vor trebui deci determinați coeficienții filtrului, w_k , pentru care:

$$J = \sum_{n=N}^M |e(n)|^2$$

este minim.

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.1. Funcția cost

Vom exprima eroarea pentru $n = N, N + 1, \dots, M$ sub forma:

$$\begin{aligned}e^*(N) &= d^*(N) - \mathbf{x}^H(N)\mathbf{w} \\e^*(N+1) &= d^*(N+1) - \mathbf{x}^H(N+1)\mathbf{w} \\&\vdots \\&\vdots \\&\vdots \\e^*(M) &= d^*(M) - \mathbf{x}^H(M)\mathbf{w}\end{aligned}$$

Vom introduce vectorii:

$$\begin{aligned}\mathbf{e}^H &= [e(N), e(N+1), \dots, e(M)]; \\ \mathbf{d}^H &= [d(N), d(N+1), \dots, d(M)]\end{aligned}$$

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.1. Funcția cost

și matricea de dimensiuni $N \times P$, $P = M - N + 1$:

$$\mathbf{A}^H = [\mathbf{x}(N), \mathbf{x}(N+1), \dots, \mathbf{x}(M)] = \begin{bmatrix} x(N) & x(N+1) & \cdot & \cdot & \cdot & x(M) \\ x(N-1) & x(N) & \cdot & \cdot & \cdot & x(M-1) \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ x(1) & x(2) & \cdot & \cdot & \cdot & x(M-N+1) \end{bmatrix}$$

Ecuțiile de mai sus pot fi exprimate compact sub forma

$$\mathbf{e} = \mathbf{d} - \mathbf{A}\mathbf{w}$$

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.1. Funcția cost

Rezultă funcția cost:

$$J = \|\mathbf{e}\|^2 = \|\mathbf{d} - \mathbf{A}\mathbf{w}\|^2 = \mathbf{e}^H \mathbf{e}.$$
$$J = \mathbf{d}^H \mathbf{d} - \mathbf{w}^H \mathbf{A}^H \mathbf{d} - \mathbf{d}^H \mathbf{A}\mathbf{w} + \mathbf{w}^H \mathbf{A}^H \mathbf{A}\mathbf{w}$$

Metoda de optimizare ce pornește de la minimizarea acestei funcții cost este cunoscută sub denumirea de *metoda celor mai mici pătrate*. Este consacrată prescurtarea “LS” provenind din limba engleză (**L**east **S**quares).

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.1. Funcția cost

Vom introduce matricea:

$$\mathbf{\Phi} = \mathbf{A}^H \mathbf{A} = \begin{bmatrix} \Phi(0,0) & \Phi(1,0) & \cdot & \cdot & \cdot & \Phi(N-1,0) \\ \Phi(0,1) & \Phi(1,1) & \cdot & \cdot & \cdot & \Phi(N-1,1) \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \Phi(0,N-1) & \Phi(1,N-1) & \cdot & \cdot & \Phi(N-1,N-1) \end{bmatrix}$$

sau

$$\mathbf{\Phi} = \sum_{i=0}^{M-1} \mathbf{x}(i) \mathbf{x}^H(i)$$

în care:

$$\Phi(p,r) = \sum_{k=0}^{M-1} x^*(k-p)x(k-r)$$

reprezintă un *estimator temporal al funcției de autocorelație*, deci se poate considera că matricea introdusă reprezintă de fapt un *estimator al matricei de autocorelație*. Este o matrice hermitică, pozitiv semidefinită, cu valori proprii reale și pozitive, dar nu mai e Toeplitz.

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.1. Funcția cost

Notăm

$$\boldsymbol{\theta} = [\theta(0), \theta(-1), \dots, \theta(-N+1)]^T = \mathbf{A}^H \mathbf{d}$$

unde

$$\theta(-p) = \sum_{n=N}^M d^*(n)x(n-p)$$

reprezintă un *estimator temporal al funcției de corelație între semnalul dorit și secvența de intrare.*

$$J = \mathbf{d}^H \mathbf{d} - \mathbf{w}^H \mathbf{A}^H \mathbf{d} - \mathbf{d}^H \mathbf{A} \mathbf{w} + \mathbf{w}^H \mathbf{A}^H \mathbf{A} \mathbf{w}$$

$$J = \mathbf{d}^H \mathbf{d} - \mathbf{w}^H \boldsymbol{\theta} - \boldsymbol{\theta}^H \mathbf{w} + \mathbf{w}^H \boldsymbol{\Phi} \mathbf{w}$$

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.2. Ecuația normală. Principiul ortogonalității

Pentru minimizarea funcției cost în raport cu coeficienții w_k , va trebui egalat cu zero gradientul complex al acesteia:

$$\nabla J = -\mathbf{A}^H \mathbf{d} + \mathbf{A}^H \mathbf{A} \mathbf{w} = \mathbf{0}$$

Sau

$$\nabla J = -\boldsymbol{\theta} + \boldsymbol{\Phi} \mathbf{w} = \mathbf{0}$$

Ecuația normală

$$\boldsymbol{\Phi} \mathbf{w} = \boldsymbol{\theta}$$

$$\sum_{p=0}^{N-1} w_p \Phi(p, r) = \theta(-r), \quad r = 0, \dots, N-1$$

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.2. Ecuația normală. Principiul ortogonalității

Dacă matricea de mai sus este nesară, sistemul se poate rezolva, conducând la setul de coeficienți optimi,

$$\mathbf{w}_o = \Phi^{-1}\boldsymbol{\theta}.$$

Sau

$$\mathbf{w}_o = (\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H \mathbf{d} = \mathbf{A}^+ \mathbf{d}$$

unde \mathbf{A}^+ este *pseudoinversa* matricei \mathbf{A} .

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.2. Ecuația normală. Principiul ortogonalității

Principiul ortogonalității

$$\mathbf{A}^H \mathbf{d} - \mathbf{A}^H \mathbf{A} \mathbf{w}_o = \mathbf{A}^H (\mathbf{d} - \mathbf{A} \mathbf{w}_o) = \mathbf{A}^H \mathbf{e}_{\min} = \mathbf{0}$$

$$\sum_{i=N}^M x(i-k) e_{\min}^*(i) = 0, \quad k = 0, \dots, N-1$$

Punând matricea \mathbf{A} sub forma

$$\mathbf{A} = \begin{bmatrix} \mathbf{a}(N) & \mathbf{a}(N-1) & \dots & \mathbf{a}(1) \end{bmatrix}$$

$$\mathbf{A}^H \mathbf{e}_{\min} = \begin{bmatrix} \mathbf{a}^H(N) \\ \mathbf{a}^H(N-1) \\ \vdots \\ \mathbf{a}^H(1) \end{bmatrix} \mathbf{e}_{\min} = \mathbf{0}$$

sau

$$\mathbf{a}^H(n) \mathbf{e}_{\min} = \mathbf{0}, \quad n = 1, \dots, N$$

Vectorul erorilor este ortogonal pe vectorii având drept componente cele $M-N+1$ eșantioane corespunzătoare oricăruia dintre semnalele din linia de întârziere a filtrului, în cazul când coeficienții au valorile optime.

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.2. Ecuația normală. Principiul ortogonalității

Definind vectorul ieșirilor filtrului,

$$\mathbf{y}^H = [y(N), y(N+1), \dots, y(M)],$$

$$\mathbf{y}_o = \mathbf{A}\mathbf{w}_o; \quad \mathbf{y}_o^H \mathbf{e}_{\min} = \mathbf{w}_o^H \mathbf{A}^H \mathbf{e}_{\min} = 0$$

sau

$$\sum_{i=N}^M y_o(i) e_{\min}^*(i) = 0.$$

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.2. Ecuația normală. Principiul ortogonalității

Interpretare geometrică. Fie $\{\mathbf{A}\}$ spațiul definit de vectorii coloană ai matricei \mathbf{A} :

$$\mathbf{a}^H(n) = [x(n), x(n+1), \dots, x(n+M-N)]$$


Evident, deoarece

$$\mathbf{y}_o = \mathbf{A}\mathbf{w}_o = \mathbf{a}(N)w_{o,0} + \mathbf{a}(N-1)w_{o,1} + \dots + \mathbf{a}(1)w_{o,N-1}$$

vectorul \mathbf{y}_o aparține spațiului $\{\mathbf{A}\}$. \mathbf{e}_{\min} este un vector ortogonal pe spațiul $\{\mathbf{A}\}$, iar \mathbf{y}_o este ortogonal pe \mathbf{e}_{\min} . În triunghiul format de \mathbf{y}_o , \mathbf{e}_{\min} și \mathbf{d} ,

$$\mathbf{e}_{\min} = \mathbf{d} - \mathbf{y}_o, \quad \mathbf{e}_{\min} \perp \mathbf{y}_o, \quad \mathbf{e}_{\min} \perp \{\mathbf{A}\}$$

deci de fapt \mathbf{y}_o reprezintă proiecția vectorului \mathbf{d} pe spațiul definit de \mathbf{A}



6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.2. Ecuația normală. Principiul ortogonalității

$$\mathbf{y}_o = \mathbf{A}\Phi^{-1}\boldsymbol{\theta} = \mathbf{A}(\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H \mathbf{d}$$

Având în vedere interpretarea geometrică de mai înainte vom numi

$$\mathbf{P}_A = \mathbf{A}(\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H$$

matricea de proiecție a spațiului $\{\mathbf{A}\}$, deci

$$\mathbf{y}_o = \mathbf{P}_A \mathbf{d}$$

Vom introduce de asemenea matricea *complement ortogonal al matricei de proiecție a spațiului $\{\mathbf{A}\}$* :

$$\mathbf{P}_A^\perp = \mathbf{I} - \mathbf{A}(\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H$$

6.1 Metoda standard a celor mai mici pătrate (LS)

6.1.2. Ecuația normală. Principiul ortogonalității

Din relațiile de ortogonalitate decurge evident următoarea relație între energii:

$$E_d = E_y + E_{\min}$$

în care E_d, E_y, E_{\min} reprezintă energia semnalului dorit, a semnalului la ieșire și respectiv, a semnalului eroare, în cazul coeficienților optimi:

$$E_d = \sum_{i=N}^M |d(i)|^2; \quad E_y = \sum_{i=N}^M |y_o(i)|^2; \quad E_{\min} = J_{\min} = \sum_{i=N}^M |e_{\min}(i)|^2;$$

În fine, energia erorii în cazul coeficienților optimi este:

$$\begin{aligned} E_{\min} = J_{\min} &= E_d - E_y = E_d - \mathbf{y}_o^H \mathbf{y}_o = E_d - \mathbf{w}_o^H \mathbf{A}^H \mathbf{A} \mathbf{w}_o = \\ &= E_d - \mathbf{w}_o^H \mathbf{\Phi} \mathbf{w}_o = E_d - \mathbf{w}_o^H \boldsymbol{\theta} = E_d - \boldsymbol{\theta}^H \mathbf{\Phi}^{-1} \boldsymbol{\theta} \end{aligned}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

Coeficienții optimi sunt rădăcinile ecuației:

$$\Phi \mathbf{w} = \boldsymbol{\theta}, \quad \Phi = \mathbf{A}^H \mathbf{A}, \quad \boldsymbol{\theta} = \mathbf{A}^H \mathbf{d}$$

Matricea Φ nu mai este o matrice Toeplitz \rightarrow algoritmul Levinson-Durbin nu mai poate fi aplicat pentru rezolvarea sistemului.

Rezolvarea sistemului presupune inversarea matricei Φ .

Numărul condițional al matricei Φ este pătratul numărului condițional al matricei \mathbf{A} \rightarrow erori importante în calculul inversei.

În plus, gama dinamică a elementelor matricei Φ este mare ca urmare a efectuării produsului.

De aceea este mai indicat să se caute alte metode de rezolvare a sistemului fără a apela la calculul inversei matricei Φ .

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

Scriind sistemul sub forma:

$$\mathbf{A}^H \mathbf{A} \mathbf{w} = \mathbf{A}^H \mathbf{d}$$

se constată că el este satisfăcut dacă

$$\mathbf{A} \mathbf{w} = \mathbf{d}$$

Condiția aceasta este suficientă, dar nu și necesară; ea presupune de fapt anularea erorilor și sistemul respectiv nu este compatibil decât în cazuri cu totul particulare (este un sistem de $P=M-N+1$ ecuații cu N necunoscute).

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.1 Factorizarea Cholesky

Pornește de la ideea descompunerii matricei Φ într-un produs de două matrice pătrate, una inferior triunghiulară și alta superior triunghiulară:

$$\Phi = \mathbf{L}\mathbf{L}^H, \quad \mathbf{L} = [l_{ij}]_{i,j=1,\dots,N}$$
$$l_{ij} = 0, \quad j = i + 1, \dots, N$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.1 Factorizarea Cholesky

Realizarea descompunerii.

Să vedem cum poate fi realizată această factorizare printr-un procedeu recursiv.

Vom nota $\varphi_{i,j}$ elementele matricei Φ . Evident:

$$\varphi_{ij} = \sum_{k=1}^{\min\{i,j\}} l_{ik} l_{jk}^*$$

$$\varphi_{11} = l_{11}^2 \Rightarrow l_{11} = \sqrt{\varphi_{11}}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.1 Factorizarea Cholesky

$$\varphi_{i,1} = l_{i1}l_{11} \Rightarrow l_{i1} = \frac{\varphi_{i1}}{\sqrt{\varphi_{11}}} \quad i = 2, \dots, N$$

$$\varphi_{jj} = \sum_{k=1}^j |l_{jk}|^2 = l_{jj}^2 + \sum_{k=1}^{j-1} |l_{jk}|^2$$

$$l_{jj} = \sqrt{\varphi_{jj} - \sum_{k=1}^{j-1} |l_{jk}|^2}$$

Cu aceste relații se poate calcula elementul de pe diagonală și coloana j , cunoscând elementele de pe coloanele $1, \dots, j-1$.

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.1 Factorizarea Cholesky

În general, se poate scrie pentru $i > j$:

$$\varphi_{ij} = l_{ij}l_{jj} + \sum_{k=1}^{j-1} l_{ik}l_{jk}^*$$

de unde

$$l_{ij} = \frac{1}{l_{jj}} \left(\varphi_{ij} - \sum_{k=1}^{j-1} l_{ik}l_{jk}^* \right), \quad i = j+1, \dots, N$$

care permite calculul celorlalte elemente ale coloanei j .

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.1 Factorizarea Cholesky

```

$$l_{11} = \sqrt{\varphi_{11}}$$


for  $i=2:N$


$$l_{i1} = \frac{\varphi_{i1}}{\sqrt{\varphi_{11}}} \quad i=2,\dots,N$$


end  $i$



for  $j=2:N$


$$l_{jj} = \sqrt{\varphi_{jj} - \sum_{k=1}^{j-1} |l_{jk}|^2}$$


for  $i=j+1:N$


$$l_{ij} = \frac{1}{l_{jj}} \left( \varphi_{ij} - \sum_{k=1}^{j-1} l_{ik} l_{jk}^* \right)$$


end  $i$



end  $j$


```

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.1 Factorizarea Cholesky

Rezolvarea sistemului

$$\mathbf{L}\mathbf{L}^H \mathbf{w} = \boldsymbol{\theta}$$

Primă etapă: vom rezolva sistemul

$$\mathbf{L}\mathbf{u} = \boldsymbol{\theta} \quad \text{unde} \quad \mathbf{u} = \mathbf{L}^H \mathbf{w}$$

Datorită caracterului triunghiular al matricei \mathbf{L} sistemul se rezolvă simplu prin substituții succesive, începând cu:

$$u_1 = \frac{\theta_1}{l_{11}}$$

și continuând apoi conform relației:

$$u_i = \frac{1}{l_{ii}} \left(\theta_i - \sum_{j=1}^{i-1} l_{ij} u_j \right), \quad i = 2, \dots, N$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.1 Factorizarea Cholesky

A doua etapă: se va rezolva sistemul:

$$\mathbf{L}^H \mathbf{w} = \mathbf{u}$$

avându-se în vedere că de această dată matricea sistemului este superior triunghiulară:

$$w_N = \frac{u_N}{l_{NN}}$$
$$w_i = \frac{1}{l_{ii}} \left(u_i - \sum_{j=i+1}^N w_j l_{ji}^* \right), \quad i=N-1, N-2, \dots, 1$$

În mediul MATLAB, instrucțiunea $\mathbf{R}=\mathbf{CHOL}(\mathbf{X})$, unde \mathbf{X} este o matrice hermitică pozitiv semidefinită, generează o matrice superior triunghiulară \mathbf{R} , astfel încât:

$$\mathbf{R}^H \mathbf{R} = \mathbf{X}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.2 Factorizarea LDU

Ne propunem să realizăm o descompunere a matricei Φ sub forma:

$$\Phi = \mathbf{L}\mathbf{D}\mathbf{U}, \quad \mathbf{U} = \mathbf{L}^H$$

unde \mathbf{L} este o matrice inferior triunghiulară, având $l_{ii}=1, i=1,\dots,N$, iar \mathbf{D} este o matrice diagonală, cu elementele notate cu d_i .

Realizarea factorizării

$$\varphi_{ij} = \sum_{k=1}^j l_{ik} d_k l_{jk}^*, \quad j = 1, 2, \dots, i$$

Coeficienții l_{ik} și d_k vor putea fi calculați recursiv:

$$d_1 = \varphi_{11}$$

$$l_{i1} = \frac{\varphi_{i1}}{d_1}, \quad i = 2, \dots, N$$

$$d_i = \varphi_{ii} - \sum_{k=1}^{i-1} |l_{ik}|^2 d_k \quad i = 2, \dots, N$$

$$l_{ij} = \frac{1}{d_j} \left(\varphi_{ij} - \sum_{k=1}^{j-1} l_{ik} d_k l_{jk}^* \right) \quad i = 2, \dots, N, \quad j = 2, \dots, i-1$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.2 Factorizarea LDU

Rezolvarea sistemului

Prima etapă: se rezolvă sistemul:

$$\mathbf{L}\mathbf{u} = \boldsymbol{\theta}, \quad \text{unde} \quad \mathbf{u} = \mathbf{D}\mathbf{L}^H \mathbf{w}$$

Având în vedere structura matricei \mathbf{L} , sistemul se rezolvă simplu, prin substituții:

$$u_1 = \theta_1$$
$$u_i = \theta_i - \sum_{j=1}^{i-1} l_{ij} u_j, \quad i = 2, \dots, N$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.2 Factorizarea LDU

A doua etapă: se rezolvă sistemul:

$$\mathbf{DL}^H \mathbf{w} = \mathbf{u} \quad \text{sau}$$

$$\mathbf{L}^H \mathbf{w} = \mathbf{D}^{-1} \mathbf{u}$$

În mod asemănător

$$w_N = \frac{u_N}{d_N}$$

$$w_i = \frac{u_i}{d_i} - \sum_{j=i+1}^N l_{ji}^* w_j, \quad i = N-1, N-2, \dots, 1$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

Factorizarea matricei \mathbf{A} sub forma:

$$\mathbf{QA} = \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix}$$

\mathbf{A} este de forma $P \times N$, $P = M - N + 1$;

\mathbf{R} este o matrice superior triunghiulară, $N \times N$

\mathbf{Q} matrice unitară, $P \times P$.

Presupunem $P \geq N \Rightarrow$ sistemul $\mathbf{Aw} = \mathbf{d}$ este supradeterminat.

$$\mathbf{A} = \mathbf{Q}^H \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

Ecuția normală devine:

$$\mathbf{A}^H \mathbf{A} \mathbf{w} = \mathbf{A}^H \mathbf{d} \Rightarrow \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix}^H \mathbf{Q} \mathbf{Q}^H \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix} \mathbf{w} = \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix}^H \mathbf{Q} \mathbf{d}$$

Vom face o partiție a vectorului \mathbf{Qd} de dimensiune $P \times 1$ sub forma:

$$\mathbf{Qd} = \begin{bmatrix} \mathbf{d}_N \\ \mathbf{c}_{P-N} \end{bmatrix}$$

$$\mathbf{R}^H \mathbf{R} \mathbf{w} = \mathbf{R}^H \mathbf{d}_N$$

$$\mathbf{R} \mathbf{w} = \mathbf{d}_N$$

Cum \mathbf{R} este o matrice triunghiulară, sistemul se rezolvă simplu prin substituții.

$$\mathbf{\Phi} = \mathbf{A}^H \mathbf{A} = \mathbf{R}^H \mathbf{R}$$

deci \mathbf{R}^H este factorul Cholesky al matricei $\mathbf{\Phi}$.

Numărul condițional al matricei \mathbf{R} este egal cu cel al matricei \mathbf{A} , deci este mai mic (rădăcină pătrată) față de cel al matricei $\mathbf{\Phi}$.

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.1 Ortogonalizarea Gram-Schmidt

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.2 Metoda rotațiilor Givens

Rotirea unui vector real:

$$\mathbf{v} = [v_1, v_2]^T = [r \cos \alpha, r \sin \alpha]^T$$

$$r = \sqrt{v_1^2 + v_2^2}, \quad \operatorname{tg} \alpha = \frac{v_2}{v_1}$$

Fie o matrice unitară

$$\mathbf{T} = \begin{bmatrix} \cos \beta & \sin \beta \\ -\sin \beta & \cos \beta \end{bmatrix}$$

Produsul:

$$\mathbf{v}' = \mathbf{T}\mathbf{v} = \begin{bmatrix} r \cos(\alpha - \beta) \\ r \sin(\alpha - \beta) \end{bmatrix}$$

reprezintă un vector rotit față de \mathbf{v} cu unghiul β .

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.2 Metoda rotațiilor Givens

Produsul:

$$\mathbf{v}' = \mathbf{T}\mathbf{v} = \begin{bmatrix} r \cos(\alpha - \beta) \\ r \sin(\alpha - \beta) \end{bmatrix}$$

reprezintă un vector rotit față de \mathbf{v} cu unghiul β .

În particular, se poate alege β astfel încât:

$$v'_2 = -v_1 \sin \beta + v_2 \cos \beta = 0 \quad \Rightarrow \quad \operatorname{tg} \beta = \frac{v_2}{v_1}$$

$$\mathbf{T} = \begin{bmatrix} c & s \\ -s & c \end{bmatrix}, \quad c = \cos \beta = \frac{v_1}{\sqrt{v_1^2 + v_2^2}}, \quad s = \sin \beta = \frac{v_2}{\sqrt{v_1^2 + v_2^2}}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.2 Metoda rotațiilor Givens

Rotația unui vector \mathbf{v} complex.

Vom accepta totuși fără a reduce generalitatea că v_1 este real și pozitiv.

Pentru a obține:

$$\mathbf{T}\mathbf{v} = \begin{bmatrix} r \\ 0 \end{bmatrix} \Rightarrow$$
$$\mathbf{T} = \begin{bmatrix} c & s^* \\ -s & c \end{bmatrix}, \quad r = \sqrt{|v_1|^2 + |v_2|^2}, \quad c = \frac{v_1}{r}, \quad s = \frac{v_2}{r}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.2 Metoda rotațiilor Givens

Rotația unui vector N - dimensional

Să presupunem că vectorul N - dimensional \mathbf{v} cu componentele v_j și v_k nenule, v_j real și pozitiv și dorim să anulăm componenta k . Se constituie matricea \mathbf{T}_{jk} :

$$\mathbf{T}_{jk} = \begin{bmatrix} 1 & . & . & . & 0 & . & . & . & 0 & . & . & . & 0 \\ . & . & . & . & . & . & . & . & . & . & . & . & . \\ . & . & . & . & . & . & . & . & . & . & . & . & . \\ 0 & . & . & . & c & . & . & . & s^* & . & . & . & 0 \\ . & . & . & . & . & . & . & . & . & . & . & . & . \\ . & . & . & . & . & . & . & . & . & . & . & . & . \\ 0 & . & . & . & -s & . & . & . & c & . & . & . & 0 \\ . & . & . & . & . & . & . & . & . & . & . & . & . \\ . & . & . & . & . & . & . & . & . & . & . & . & . \\ 0 & . & . & . & 0 & . & . & . & 0 & . & . & . & 1 \end{bmatrix}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.2 Metoda rotațiilor Givens

$$t_{jj} = t_{kk} = c = \frac{v_j}{\sqrt{|v_j|^2 + |v_k|^2}}, \quad t_{jk} = s^*, \quad t_{kj} = -s, \quad s = \frac{v_k}{\sqrt{|v_j|^2 + |v_k|^2}}$$

iar toate celelalte elemente corespund unei matrice unitate.

$$\mathbf{v}' = \mathbf{T}_{jk} \mathbf{v}$$

$$v'_i = v_i, \quad i \neq j, k$$

$$v'_j = \sqrt{|v_j|^2 + |v_k|^2}; \quad v'_k = 0$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.2 Metoda rotațiilor Givens

Rotația aplicată unei matrice

În fine, să considerăm cazul când \mathbf{T}_{jk} acționează asupra unei matrice \mathbf{A} de dimensiune $P \times N$:

$$\mathbf{A}' = \mathbf{T}_{jk} \mathbf{A}$$

Presupunând că \mathbf{T} are structura prezentată mai înainte, rezultă că va acționa numai asupra liniilor j și k , celelalte elemente rămânând nemodificate. Mai precis,

$$a'_{ji} = ca_{ji} + s^* a_{ki}; \quad a'_{ki} = -sa_{ji} + ca_{ki};$$

Ne propunem să anulăm elementul a'_{kj} . Presupunând a_{jj} real și pozitiv și alegând:

$$c = \frac{a_{jj}}{\sqrt{|a_{jj}|^2 + |a_{kj}|^2}}, \quad s = \frac{a_{kj}}{\sqrt{|a_{jj}|^2 + |a_{kj}|^2}}$$

se obțin:

$$a'_{jj} = \sqrt{|a_{jj}|^2 + |a_{kj}|^2}, \quad a'_{kj} = 0$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.2 Metoda rotațiilor Givens

Procedeul poate fi aplicat succesiv pentru triangularizarea matricei \mathbf{A} .

Se începe cu anularea elementelor de pe prima coloană și liniile $2, 3, \dots, P$. Pentru aceasta se vor lua succesiv pentru j, k perechile $(1, 2)$, $(1, 3)$, \dots , $(1, P)$. Prin $P-1$ asemenea operații se anulează $a_{k,1}$, $k=2, \dots, P$.

Se trece apoi la coloana a doua, urmărind să se anuleze $a_{k,2}$, $k=3, \dots, P$ și așa mai departe, până la ultima coloană.

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.3 Realizarea rotațiilor Givens cu ajutorul algoritmului CORDIC

CORDIC (COordinate Rotation DIgital Computation)

$$\begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} \begin{bmatrix} 0 \cdots 0 & a_{jj} & a_{j,j+1} & \cdots & a_{jN} \\ 0 \cdots 0 & a_{kj} & a_{k,j+1} & \cdots & a_{kN} \end{bmatrix} = \begin{bmatrix} 0 \cdots 0 & a'_{jj} & a'_{j,j+1} & \cdots & a'_{jN} \\ 0 \cdots 0 & a'_{kj} & a'_{k,j+1} & \cdots & a'_{kN} \end{bmatrix}$$

Argumentul θ se alege așa încât $a'_{kj} = 0$, deci vectorul $\begin{bmatrix} a_{jj} \\ a_{kj} \end{bmatrix}$, de forma $\begin{bmatrix} x \\ y \end{bmatrix}$, pe care

îl vom numi *vector director*, trebuie astfel rotit încât să devină colinar cu axa Ox;

apoi toți vectorii următori $\begin{bmatrix} a_{ji} \\ a_{ki} \end{bmatrix}$, $i > j$ vor fi roțiți cu același unghi

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.3 Realizarea rotațiilor Givens cu ajutorul algoritmului CORDIC

$$\begin{bmatrix} a'_j \\ a'_k \end{bmatrix} = \begin{bmatrix} a_j \cos \theta + a_k \sin \theta \\ -a_j \sin \theta + a_k \cos \theta \end{bmatrix} = \cos \theta \begin{bmatrix} a_j + a_k \operatorname{tg} \theta \\ a_k - a_j \operatorname{tg} \theta \end{bmatrix}$$

Dacă

$$\operatorname{tg} \theta = 2^{-i}, \quad i \in \mathbf{N}$$

$$\begin{bmatrix} a'_j \\ a'_k \end{bmatrix} = \cos \theta \begin{bmatrix} a_j + a_k 2^{-i} \\ a_k - a_j 2^{-i} \end{bmatrix}$$

θ poate fi exprimat

$$\theta = \sum_{i=0}^{\infty} \rho_i \theta_i, \quad \rho_i = \pm 1, \quad \theta_i = \operatorname{arctg} 2^{-i}$$

$$K = \prod_{i=0}^{\infty} \cos \theta_i$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.3 Realizarea rotațiilor Givens cu ajutorul algoritmului CORDIC

așa încât o rotație se reduce la efectuarea succesiunii de operații:

$$\begin{aligned} & \left[a_j^{(0)}, a_k^{(0)} \right] = K \left[a_j, a_k \right] \\ \left[a_j^{(1)}, a_k^{(1)} \right] &= \left[a_j^{(0)} + \rho_0 2^0 a_k^{(0)}, a_k^{(0)} - \rho_0 2^0 a_j^{(0)} \right] \\ \left[a_j^{(2)}, a_k^{(2)} \right] &= \left[a_j^{(1)} + \rho_1 2^{-1} a_k^{(1)}, a_k^{(1)} - \rho_1 2^{-1} a_j^{(1)} \right] \\ & \vdots \\ \left[a_j^{(i+1)}, a_k^{(i+1)} \right] &= \left[a_j^{(i)} + \rho_i 2^{-i} a_k^{(i)}, a_k^{(i)} - \rho_i 2^{-i} a_j^{(i)} \right] \\ & \vdots \end{aligned}$$


Problema determinării unghiului θ , deci de fapt a parametrilor binari $\rho_i = \pm 1$

$$\rho_i = \operatorname{sgn}(a_{jj}^{(i)}) \operatorname{sgn}(a_{kj}^{(i)}) = \operatorname{sgn}(a_{kj}^{(i)})$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.3 Realizarea rotațiilor Givens cu ajutorul algoritmului CORDIC



6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.4 Transformarea (reflexia) Hauseholder

$$\mathbf{H} = \mathbf{I} - 2\mathbf{u}\mathbf{u}^H$$

unde \mathbf{u} este un vector de normă unitară

$$\mathbf{u}^H \mathbf{u} = 1$$

Matricea \mathbf{H} a transformării este *hermitică unitară*:

$$\mathbf{H} = \mathbf{H}^H$$
$$\mathbf{H}^H \mathbf{H} = \mathbf{H}\mathbf{H} = (\mathbf{I} - 2\mathbf{u}\mathbf{u}^H)(\mathbf{I} - 2\mathbf{u}\mathbf{u}^H) = \mathbf{I} - 4\mathbf{u}\mathbf{u}^H + 4\mathbf{u}\mathbf{u}^H\mathbf{u}\mathbf{u}^H = \mathbf{I}$$

Se verifică ușor că dacă se alege

$$\mathbf{u} = \frac{\mathbf{x}}{\|\mathbf{x}\|} \Rightarrow \mathbf{H}\mathbf{x} = -\mathbf{x}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.4 Transformarea (reflexia) Huseholder


Interpretare geometrică

$$P_u(\mathbf{x}) = (\mathbf{u}^H \mathbf{x}) \mathbf{u}$$

reprezintă proiecția vectorului \mathbf{x} pe vectorul \mathbf{u} și

$$H\mathbf{x} = \mathbf{x} - 2\mathbf{u}\mathbf{u}^H \mathbf{x} = \mathbf{x} - 2(\mathbf{u}^H \mathbf{x}) \mathbf{u} = \mathbf{x} - 2P_u(\mathbf{x})$$

$H\mathbf{x}$ reprezintă imaginea oglindită (reflexia) lui \mathbf{x} în raport cu hiperplanul ortogonal pe vectorul \mathbf{u} .



6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.4 Transformarea (reflexia) Hauseholder

Fie un vector \mathbf{e}_i având toate elementele nule, cu excepția elementului i care are valoarea 1. Să considerăm transformarea definită prin vectorul:

$$\mathbf{u} = \frac{\mathbf{x} - \|\mathbf{x}\|\mathbf{e}_i}{\|\mathbf{x} - \|\mathbf{x}\|\mathbf{e}_i\|}$$

Se găsesc :

$$\mathbf{u}^H \mathbf{x} = \frac{(\mathbf{x}^H - \|\mathbf{x}\|\mathbf{e}_i^H)\mathbf{x}}{\|\mathbf{x} - \|\mathbf{x}\|\mathbf{e}_i\|} = \frac{\|\mathbf{x}\|(\|\mathbf{x}\| - x_i)}{\|\mathbf{x} - \|\mathbf{x}\|\mathbf{e}_i\|}$$

$$\mathbf{H}\mathbf{x} = \mathbf{x} - 2(\mathbf{u}^H \mathbf{x})\mathbf{u} = \mathbf{x} - 2 \frac{\|\mathbf{x}\|(\|\mathbf{x}\| - x_i)(\mathbf{x} - \|\mathbf{x}\|\mathbf{e}_i)}{(\mathbf{x}^H - \|\mathbf{x}\|\mathbf{e}_i^H)(\mathbf{x} - \|\mathbf{x}\|\mathbf{e}_i)} = \mathbf{x} - 2 \frac{\|\mathbf{x}\|(\|\mathbf{x}\| - x_i)(\mathbf{x} - \|\mathbf{x}\|\mathbf{e}_i)}{2\|\mathbf{x}\|(\|\mathbf{x}\| - x_i)}$$

$$\mathbf{H}\mathbf{x} = \|\mathbf{x}\|\mathbf{e}_i$$

Deoarece:

$$\|\mathbf{x} - \|\mathbf{x}\|\mathbf{e}_i\|^2 = (\mathbf{x}^H - \|\mathbf{x}\|\mathbf{e}_i^H)(\mathbf{x} - \|\mathbf{x}\|\mathbf{e}_i) = 2\|\mathbf{x}\|(\|\mathbf{x}\| - x_i) > 0$$

rezultă că x_i trebuie să fie real și

$$\|\mathbf{x}\| - x_i > 0$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.4 Transformarea (reflexia) Huseholder

Această proprietate face transformarea Householder utilă pentru triunghiularizarea unei matrice și deci și pentru rezolvarea ecuației normale prin descompunere QR.

Matricea \mathbf{A} poate fi scrisă:

$$\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_N], \quad \mathbf{a}_i = [a_{1i}, a_{2i}, \dots, a_{Pi}]^T$$

O primă transformare urmărește eliminarea elementelor coloanei 1, mai puțin a_{11} .

$$\mathbf{u}_1 = \frac{\mathbf{a}_1 - \|\mathbf{a}_1\| \mathbf{e}_1}{\|\mathbf{a}_1 - \|\mathbf{a}_1\| \mathbf{e}_1\|}$$

$$\mathbf{H}_1 = \mathbf{I} - 2\mathbf{u}_1\mathbf{u}_1^H$$

$$\mathbf{H}_1\mathbf{A} = \begin{bmatrix} a_{11}^{(1)} & a_{12}^{(1)} & \cdot & \cdot & \cdot & a_{1N}^{(1)} \\ 0 & a_{22}^{(1)} & \cdot & \cdot & \cdot & a_{2N}^{(1)} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & a_{P2}^{(1)} & \cdot & \cdot & \cdot & a_{PN}^{(1)} \end{bmatrix}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.4 Transformarea (reflexia) Huseholder

Următoarea etapă va consta în anularea termenilor coloanei a doua, situați sub diagonala principală, luând

$$\mathbf{u}_2 = \frac{\mathbf{a}'_2 - \|\mathbf{a}'_2\| \mathbf{e}_2}{\|\mathbf{a}'_2 - \|\mathbf{a}'_2\| \mathbf{e}_2\|}$$
$$\mathbf{a}'_2 = \left[0, a_{22}^{(1)}, \dots, a_{P2}^{(1)} \right]^T$$

Elementele primei linii și ale primei coloane nu sunt modificate de transformare.

$$\mathbf{H}_2 \mathbf{H}_1 \mathbf{A} = \begin{bmatrix} a_{11}^{(1)} & a_{12}^{(1)} & \cdot & \cdot & \cdot & a_{1N}^{(1)} \\ 0 & a_{22}^{(2)} & \cdot & \cdot & \cdot & a_{2N}^{(2)} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & \cdot & \cdot & \cdot & a_{PN}^{(2)} \end{bmatrix}$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.3 Factorizarea QR

6.2.3.4 Transformarea (reflexia) Huseholder

Presupunând $P > N$, după N asemenea operații se obține:

$$\mathbf{H}_N \mathbf{H}_{N-1} \dots \mathbf{H}_1 \mathbf{A} = \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix}$$

$$\mathbf{Q} = \mathbf{H}_{N-1} \mathbf{H}_{N-2} \dots \mathbf{H}_1$$

și sistemul se rezolvă după cum s-a arătat în paragrafele precedente.

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.4 Descompunerea matricei \mathbf{A} după valorile singulare

6.2.4.1 Teorema descompunerii după valorile singulare. Pseudoinversa unei matrice dreptunghiulare.

Există două matrice unitare \mathbf{V} și \mathbf{U} , așa încât:

$$\mathbf{U}^H \mathbf{A} \mathbf{V} = \begin{bmatrix} \mathbf{\Sigma} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}, \quad \text{unde} \quad \mathbf{\Sigma} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$$

σ_i se numesc *valorile singulare* ale matricei \mathbf{A} , iar pătratele lor coincid cu valorile proprii ale matricei $\mathbf{\Phi}$. Ele sunt reale și pozitive și le vom presupune ordonate $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$, iar r este rangul matricei \mathbf{A} . \mathbf{U} este o matrice de dimensiuni $P \times P$,

$$\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_P],$$

iar vectorii coloană \mathbf{u}_i se numesc *vectori singulari la stânga* ai matricei \mathbf{A} . \mathbf{V} este o matrice de dimensiuni $N \times N$,

$$\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_N]$$

iar vectorii coloană \mathbf{v}_i se numesc *vectori singulari la dreapta*.

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.4 Descompunerea matricei A după valorile singulare

6.2.4.1 Teorema descompunerii după valorile singulare. Pseudoinversa unei matrice dreptunghiulare.

Se definește *pseudoinversa* matricei \mathbf{A}

$$\mathbf{A}^+ = \mathbf{V} \begin{bmatrix} \boldsymbol{\Sigma}^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \mathbf{U}^H$$

Pseudoinversa poate fi exprimată și direct în funcție de matricea \mathbf{A} , dacă aceasta este de rang maxim,

$$r = \min\{P, N\},$$

prin

$$\mathbf{A}^+ = \left(\mathbf{A}^H \mathbf{A}\right)^{-1} \mathbf{A}^H$$

în cazul $P > N$, sau prin

$$\mathbf{A}^+ = \mathbf{A}^H \left(\mathbf{A} \mathbf{A}^H\right)^{-1}$$

dacă $P < N$.

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.4 Descompunerea matricei A după valorile singulare

6.2.4.1 Teorema descompunerii după valorile singulare. Pseudoinversa unei matrice dreptunghiulare.

în cazul $P > N$

$$\mathbf{A}^+ = \left(\mathbf{A}^H \mathbf{A} \right)^{-1} \mathbf{A}^H$$

În acest caz

$$\mathbf{A}^+ \mathbf{A} = \mathbf{I}_N$$

și deoarece $r=N$

$$\mathbf{U}^H \mathbf{A} \mathbf{V} = \begin{bmatrix} \boldsymbol{\Sigma} \\ \mathbf{0} \end{bmatrix}$$

și

$$\mathbf{A}^+ = \mathbf{V} \begin{bmatrix} \boldsymbol{\Sigma}^{-1} & \mathbf{0} \end{bmatrix} \mathbf{U}^H$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.4 Descompunerea matricei A după valorile singulare

6.2.4.1 Teorema descompunerii după valorile singulare. Pseudoinversa unei matrice dreptunghiulare.

în cazul $P < N$.

$$\mathbf{A}^+ = \mathbf{A}^H (\mathbf{A} \mathbf{A}^H)^{-1}$$
$$\mathbf{A} \mathbf{A}^+ = \mathbf{I}_P$$

și deoarece $r = P$

$$\mathbf{U}^H \mathbf{A} \mathbf{V} = [\mathbf{\Sigma} \quad \mathbf{0}]$$

și

$$\mathbf{A}^+ = \mathbf{V} \begin{bmatrix} \mathbf{\Sigma}^{-1} \\ \mathbf{0} \end{bmatrix} \mathbf{U}^H$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.4 Descompunerea matricei A după valorile singulare

6.2.4.1 Teorema descompunerii după valorile singulare. Pseudoinversa unei matrice dreptunghiulare.

Consecințe

Deoarece \mathbf{U} este o matrice unitară,

$$\mathbf{AV} = \mathbf{U} \begin{bmatrix} \boldsymbol{\Sigma} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}$$

de unde

$$\mathbf{Av}_i = \begin{cases} \sigma_i \mathbf{u}_i, & i = 1, \dots, r \\ \mathbf{0}, & i = r+1, \dots, P \end{cases}$$

Exprimarea matricei de date în funcție de valorile singulare și vectorii singulari

$$\mathbf{A} = \mathbf{U} \begin{bmatrix} \boldsymbol{\Sigma} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \mathbf{V}^H \quad \text{sau} \quad \mathbf{A} = \sum_{i=1}^r \sigma_i \mathbf{u}_i \mathbf{v}_i^H$$

Exprimarea pseudoinversei în funcție de valorile singulare și vectorii singulari

$$\mathbf{A}^+ = \sum_{i=1}^r \frac{1}{\sigma_i} \mathbf{v}_i \mathbf{u}_i^H$$

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.4 Descompunerea matricei \mathbf{A} după valorile singulare

6.2.4.2 Soluția de normă minimă a problemei celor mai mici pătrate

Fie sistemul:

$$\mathbf{A}\mathbf{w} = \mathbf{d}$$

având în general P ecuații și N necunoscute cu o matrice \mathbf{A} de rangul r . Sistemul are o soluție unică dacă $r=P=N$, și aceasta este:

$$\mathbf{w} = \mathbf{A}^{-1}\mathbf{d}$$

Dacă $r \leq N < P$, sistemul este incompatibil (supradeterminat) deci nu admite nici o soluție, cu excepția situației particulare când $N=r=\text{rang}[\mathbf{A},\mathbf{d}]$. Dacă $r \leq P < N$ sistemul este nedeterminat (subdeterminat), deci admite o infinitate de soluții.

Vom arăta în continuare că:

$$\mathbf{w} = \mathbf{A}^+\mathbf{d}$$

reprezintă soluția unică a sistemului în sensul celor mai mici pătrate, adică cea soluție ce minimizează norma erorii

$$\|\mathbf{A}\mathbf{w} - \mathbf{d}\|^2$$

și are totodată norma euclidiană $\|\mathbf{w}\|$ minimă.

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.4 Descompunerea matricei A după valorile singulare

6.2.4.2 Soluția de normă minimă a problemei celor mai mici pătrate

Demonstrație

$$\begin{aligned}\|\mathbf{Aw} - \mathbf{d}\|^2 &= (\mathbf{d}^H - \mathbf{w}^H \mathbf{A}^H)(\mathbf{d} - \mathbf{Aw}) = (\mathbf{d}^H - \mathbf{w}^H \mathbf{A}^H) \mathbf{U} \mathbf{U}^H (\mathbf{d} - \mathbf{Aw}) = \\ &= (\mathbf{d}^H \mathbf{U} - \mathbf{w}^H \mathbf{A}^H \mathbf{U}) (\mathbf{U}^H \mathbf{d} - \mathbf{U}^H \mathbf{Aw}) = (\mathbf{d}^H \mathbf{U} - \mathbf{w}^H \mathbf{V} \mathbf{V}^H \mathbf{A}^H \mathbf{U}) (\mathbf{U}^H \mathbf{d} - \mathbf{U}^H \mathbf{A} \mathbf{V} \mathbf{V}^H \mathbf{w})\end{aligned}$$

$$\mathbf{V}^H \mathbf{w} = \mathbf{z} = \begin{bmatrix} \mathbf{z}_1 \\ \mathbf{z}_2 \end{bmatrix}, \quad \mathbf{U}^H \mathbf{d} = \mathbf{c} = \begin{bmatrix} \mathbf{c}_1 \\ \mathbf{c}_2 \end{bmatrix}$$

$$\begin{aligned}\|\mathbf{Aw} - \mathbf{d}\|^2 &= \left(\mathbf{c}^H - \mathbf{z}^H \begin{bmatrix} \mathbf{\Sigma} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \right) \left(\mathbf{c} - \begin{bmatrix} \mathbf{\Sigma} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \mathbf{z} \right) = \left(\mathbf{c}_1^H, \mathbf{c}_2^H \right) - \left[\mathbf{z}_1^H \mathbf{\Sigma}, \mathbf{0} \right] \left(\begin{bmatrix} \mathbf{c}_1 \\ \mathbf{c}_2 \end{bmatrix} - \begin{bmatrix} \mathbf{\Sigma} \mathbf{z}_1 \\ \mathbf{0} \end{bmatrix} \right) = \\ &= \left[\mathbf{c}_1^H - \mathbf{z}_1^H \mathbf{\Sigma}, \mathbf{c}_2^H \right] \begin{bmatrix} \mathbf{c}_1 - \mathbf{\Sigma} \mathbf{z}_1 \\ \mathbf{c}_2 \end{bmatrix} = \|\mathbf{c}_1 - \mathbf{\Sigma} \mathbf{z}_1\|^2 + \|\mathbf{c}_2\|^2\end{aligned}$$

Aceasta poate fi minimizată luând

$$\mathbf{z}_1 = \mathbf{\Sigma}^{-1} \mathbf{c}_1$$

și nu depinde de \mathbf{z}_2 .

6.2 METODE EFICIENTE DE REZOLVARE A PROBLEMEI CELOR MAI MICI PĂTRATE

6.2.4 Descompunerea matricei A după valorile singulare

6.2.4.2 Soluția de normă minimă a problemei celor mai mici pătrate

Pe de altă parte:

$$\|\mathbf{w}\|^2 = \mathbf{w}^H \mathbf{w} = \mathbf{w}^H \mathbf{V} \mathbf{V}^H \mathbf{w} = \mathbf{z}^H \mathbf{z} = \|\mathbf{z}_1\|^2 + \|\mathbf{z}_2\|^2$$

care poate fi minimizat luând

$$\mathbf{z}_2 = \mathbf{0}$$

Rezultă deci

$$\mathbf{w} = \mathbf{V} \mathbf{z} = \mathbf{V} \begin{bmatrix} \boldsymbol{\Sigma}^{-1} \mathbf{c}_1 \\ \mathbf{0} \end{bmatrix} = \mathbf{V} \begin{bmatrix} \boldsymbol{\Sigma}^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{c}_1 \\ \mathbf{c}_2 \end{bmatrix} = \mathbf{V} \begin{bmatrix} \boldsymbol{\Sigma}^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \mathbf{U}^H \mathbf{d} = \mathbf{A}^+ \mathbf{d}$$