

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



MCMMP-R – variante cu fereastră: MCMMP-R□ (continuare)

$$\hat{\theta}_k = \hat{\theta}_{k-1} - \mathbf{P}_k \varphi [k - M] \left(y[k - M] - \varphi^T [k - M] \hat{\theta}_{k-1} \right) + \mathbf{P}_k \varphi [k] \left(y[k] - \varphi^T [k] \hat{\theta}_{k-1} \right) \quad \forall k \geq M + 1$$

- De asemenea, erorile de predicție sunt ponderate de două câștiguri de sensibilitate:

$$\gamma_{b,k-M} \stackrel{\text{def}}{=} \mathbf{P}_k \varphi [k - M] \rightarrow \text{Câștig de sensibilitate a priori.}$$

$$\gamma_{f,k} \stackrel{\text{def}}{=} \mathbf{P}_k \varphi [k] \rightarrow \text{Câștig de sensibilitate a posteriori.}$$

$$\hat{\theta}_k = \hat{\theta}_{k-1} - \gamma_{b,k-M} \varepsilon_b [k - M] + \gamma_{f,k} \varepsilon_f [k] \quad \forall k \geq M + 1$$

Cum poate fi optimizată relația recursivă?

Prin aplicarea succesivă, de două ori, a lemei de inversare matricială.



$$\mathbf{P}_k^{-1} = \mathbf{P}_{k-1}^{-1} - \varphi [k - M] \varphi^T [k - M] + \varphi [k] \varphi^T [k] \quad \forall k \geq M + 1$$

$\mathbf{P}_{b,k-M}^{-1}$ (notație naturală)

✦ Același rezultat se obține plecînd de la:

$$\mathbf{P}_{f,k}^{-1} \stackrel{\text{def}}{=} \mathbf{P}_{k-1}^{-1} + \varphi [k] \varphi^T [k]$$

① Lema 1

$$\mathbf{P}_{b,k-M} \stackrel{\text{def}}{=} \left(\mathbf{P}_{k-1}^{-1} - \varphi [k - M] \varphi^T [k - M] \right)^{-1} = \mathbf{P}_{k-1} + \frac{\mathbf{P}_{k-1} \varphi [k - M] \varphi^T [k - M] \mathbf{P}_{k-1}}{1 - \varphi^T [k - M] \mathbf{P}_{k-1} \varphi [k - M]}$$

$\forall k \geq M + 1$

② Lema 1

$$\mathbf{P}_k = \left(\mathbf{P}_{b,k-M}^{-1} + \varphi [k] \varphi^T [k] \right)^{-1} = \mathbf{P}_{b,k-M} - \frac{\mathbf{P}_{b,k-M} \varphi [k] \varphi^T [k] \mathbf{P}_{b,k-M}}{1 + \varphi^T [k] \mathbf{P}_{b,k-M} \varphi [k]}$$

$\forall k \geq M + 1$

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



MCMMP-R – variante cu fereastră: MCMMP-R□ (continuare)

Mai mult

se aduce la același numitor

$$\overset{\text{def}}{\gamma_{f,k}} = \mathbf{P}_k \boldsymbol{\varphi}[k] = \mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k] - \frac{\mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k] \boldsymbol{\varphi}^T[k] \mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k]}{1 + \boldsymbol{\varphi}^T[k] \mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k]}$$

Lema 1

$$\mathbf{P}_k = \mathbf{P}_{b,k-M} - \frac{\mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k] \boldsymbol{\varphi}^T[k] \mathbf{P}_{b,k-M}}{1 + \boldsymbol{\varphi}^T[k] \mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k]}$$

$$= \frac{\mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k] + \cancel{\mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k] \boldsymbol{\varphi}^T[k] \mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k]} - \cancel{\mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k] \boldsymbol{\varphi}^T[k] \mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k]}}{1 + \boldsymbol{\varphi}^T[k] \mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k]} =$$

$$= \frac{\mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k]}{1 + \boldsymbol{\varphi}^T[k] \mathbf{P}_{b,k-M} \boldsymbol{\varphi}[k]}, \quad \forall k \geq M + 1.$$

☞ Pentru cel de-al doilea câștig, ar trebui evaluată:

$$\mathbf{P}_{f,k} \stackrel{\text{def}}{=} \left(\mathbf{P}_{k-1}^{-1} + \boldsymbol{\varphi}[k] \boldsymbol{\varphi}^T[k] \right)^{-1}$$

Algoritmul adaptiv al Celor Mai Mici Pătrate cu fereastră dreptunghiulară

Date de intrare

$M \geq 1$ (deschiderea ferestrei dreptunghiulare)

$\mathcal{D}_M = \{ \boldsymbol{\varphi}[n] \}_{n \in \overline{1, M}} \cup \{ y[n] \}_{n \in \overline{1, M}}$ (un set de date măsurate a priori pe durata ferestrei)

$n\theta$ (indicele structural al modelului de identificare)

Inițializare

MCMMP off-line

$$\hat{\boldsymbol{\theta}}_M = \left(\sum_{n=1}^M \boldsymbol{\varphi}[n] \boldsymbol{\varphi}^T[n] \right)^{-1} \left(\sum_{n=1}^M \boldsymbol{\varphi}[n] y[n] \right)$$

\mathbf{P}_M

$k = 0 \rightarrow$ indicele iterativ inițial

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



Algoritmul adaptiv al Celor Mai Mici Pătrate cu fereastră dreptunghiulară (continuare)

Bucă iterativă

↳ Pentru $k \geq M + 1$

① Se evaluează erorile de predicție curente:

$$\varepsilon_b[k - M] = y[k - M] - \varphi^T[k - M] \hat{\theta}_{k-1} \quad (\text{a priori})$$

$$\varepsilon_f[k] = y[k] - \varphi^T[k] \hat{\theta}_{k-1} \quad (\text{a posteriori})$$

② Se evaluează vectorul auxiliar: $\xi_k = \mathbf{P}_{k-1} \varphi[k - M]$

③ Se evaluează matricea: $\mathbf{P}_{b,k-M} = \mathbf{P}_{k-1} + \frac{\xi_k \xi_k^T}{1 - \varphi^T[k - M] \xi_k}$

④ Se reactualizează vectorul auxiliar: $\xi_k = \mathbf{P}_{b,k-M} \varphi[k]$

⑤ Se evaluează câștigul de senzitivitate a posteriori:

$$\gamma_{f,k} = \frac{\xi_k}{1 + \varphi^T[k] \xi_k}$$

⑥ Se reactualizează matricea de auto-covarianță a erorii de estimare:

$$\mathbf{P}_k = \mathbf{P}_{b,k-M} - \gamma_{f,k} \xi_k^T$$

⑦ Se evaluează câștigul de senzitivitate a priori:

$$\gamma_{b,k-M} = \mathbf{P}_k \varphi[k - M]$$

⑧ Se reactualizează vectorul parametrilor estimați:

$$\hat{\theta}_k = \hat{\theta}_{k-1} - \gamma_{b,k-M} \varepsilon_f[k - M] + \gamma_{f,k} \varepsilon_f[k]$$

⑨ Se incrementează indicele curent:

$$k \leftarrow k + 1$$

Exercițiu MVI-R□

(deducerea relațiilor recursive, algoritmul eficient, inițializare)

Date de ieșire

$$\{\hat{\theta}_k\}_{k \in \mathbb{N}}$$

Parametrii modelului reactualizați la fiecare pas de adaptare.

Complexitatea algoritmului este ridicată.

4 Metode de identificare și validare

4.9 Metode adaptive de identificare

MCMMMP-R bazată pe descompunerea QR (MCMMMPQR-R)

- Exploatarea MCMMMP în unele aplicații **necesită o mare stabilitate numerică**.

Ori

$$\mathbf{R} \stackrel{\text{def}}{=} \Phi^T \Phi = [\varphi[1] \mid \varphi[2] \mid \dots \mid \varphi[N]] \begin{bmatrix} \overline{\varphi^T[1]} \\ \overline{\varphi^T[2]} \\ \vdots \\ \overline{\varphi^T[N]} \end{bmatrix} = \sum_{n=1}^N \varphi[n] \varphi^T[n] \in \mathbb{R}^{n\theta \times n\theta}$$

☞ Care se inversează.

⊗ Este dezechilibrată numeric.

Dezechilibrată numeric?



Raportul dintre valorile singulare maximă și minimă **este prea mare**.

Numărul de condiționare numerică

$$\nu(\Phi) \stackrel{\text{def}}{=} \frac{\sigma_{\max}}{\sigma_{\min}}$$

Valorile singulare ale unei matrici **A**

Dezechilibrarea numerică a unei matrici inversabile conduce la **erori numerice importante ale inversei** (și chiar la **imposibilitatea evaluării acesteia pe un mijloc automat de calcul**).

Valorile proprii ale matricii **A^TA**.

Exemplu

Matricea modelului polinomial al datelor de ieșire

$$y[n] = a_0 + a_1 n + a_2 n^2 + \dots + a_p n^p + \varepsilon[n, a_0, \dots, a_p]$$

Exercițiu

$$\mathbf{R}_N = \begin{bmatrix} N & \frac{N(N+1)}{2} & \dots & \sum_{n=1}^N n^p \\ \frac{N(N+1)}{2} & \frac{N(N+1)(2N+1)}{6} & \dots & \sum_{n=1}^N n^{p+1} \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{n=1}^N n^p & \sum_{n=1}^N n^{p+1} & \dots & \sum_{n=1}^N n^{2p} \end{bmatrix}$$

☞ Valorile singulare ale matricii **Φ** sunt valorile proprii ale matricii **R**.

$$\sum_{n=1}^N n^{2p} \sim N^{2p+1} \gg N$$

4 Metode de identificare și validare

4.9 Metode adaptive de identificare

MCMMP-R bazată pe descompunerea QR (continuare)

Ce se poate face?



De regulă, matricile dezechilibrate numeric pot fi inversate după aplicarea unei **tehnici de balansare** (din domeniul **Metodelor Numerice**).

Exemplul precedent

Matricea modelului polinomial al datelor de ieșire

$$\mathbf{R}_N = \begin{bmatrix} N & \frac{N(N+1)}{2} & \dots & \sum_{n=1}^N n^p \\ \frac{N(N+1)}{2} & \frac{N(N+1)(2N+1)}{6} & \dots & \sum_{n=1}^N n^{p+1} \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{n=1}^N n^p & \sum_{n=1}^N n^{p+1} & \dots & \sum_{n=1}^N n^{2p} \end{bmatrix}$$

• În loc să se inverseze această matrice, se inversează matricea **balansată (echilibrată numeric)**:

$$\mathbf{B}_N \mathbf{R}_N \mathbf{B}_N$$

balancing matrix

$$\mathbf{B}_N \stackrel{\text{def}}{=} \begin{bmatrix} 1 & 0 & \dots & 0 \\ \frac{1}{\sqrt{N}} & 0 & \dots & 0 \\ 0 & \frac{1}{N\sqrt{N}} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{1}{N^p \sqrt{N}} \end{bmatrix}$$

Matrice diagonală.

Exercițiu de simulare

- Folosind mediul de simulare **MATLAB**, evaluați inversele celor două matrici din exemplu (nebalansată și balansată) pentru câteva valori ale gradului polinomului modelului, apoi verificați corectitudinea rezultatelor și evaluați numerele de condiționare numerică prin apelarea funcției de bibliotecă numită **cond**.

Prin echilibrare numerică, rezultatul final nu se modifică.

$$\mathbf{R}_N^{-1} = \mathbf{B}_N (\mathbf{B}_N \mathbf{R}_N \mathbf{B}_N)^{-1} \mathbf{B}_N$$

Matricea de balansare nu trebuie inversată.

4 Metode de identificare și validare

4.9 Metode adaptive de identificare

MCMMP-R bazată pe descompunerea QR (continuare)



Cele mai “bune” matrici pentru inversare au numărul de condiționare numerică **unitar**.

- Cu cât numărul de condiționare numerică este mai mare, cu atât matricea este mai dezechilibrată numeric, iar inversa este mai eronată, în absența unei tehnici de balansare.

⊗ În general, construcția unei matrici de balansare nu este simplă.


Și atunci?...



Pentru matricile simetrice (strict) pozitiv definite dezechilibrate numeric (cum este R_N), o tehnică de balansare se bazează pe **descompunerea QR a acestora**, cu ajutorul **matricilor de rotație** (care au numărul de condiționare numerică unitar).

Proprietăți remarcabile din Teoria Matricilor

→ Triangularizarea unei matrici monice



→ Invarianța normei euclidiene la transformări ortogonale

$$\|Qv\|^2 = v^T Q^T Q v = v^T v = \|v\|^2 \quad \forall v \in \mathbb{R}^m$$

- Existența matricii ortogonale din prima proprietate se poate demonstra cu ajutorul unui raționament constructiv, în care **matricile de rotație** joacă rolul principal.



Ideea de bază

Anularea succesivă a elementelor sub-diagonale ale matricii monice cu ajutorul **operatorilor Givens**.

Operator Givens

Matrice elementară de rotație.

Exemplu

$$G \stackrel{def}{=} \begin{bmatrix} \cos \alpha & \sin \alpha \\ -\sin \alpha & \cos \alpha \end{bmatrix}$$

← unghi de rotație

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



MCMMP-R bazată pe descompunerea QR (continuare)

Exemplu

Anularea elementului sub-diagonal al unei matrici de ordin 2

$$\mathbf{A} \stackrel{def}{=} \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$$

$$\begin{bmatrix} \cos \alpha_{21} & \sin \alpha_{21} \\ -\sin \alpha_{21} & \cos \alpha_{21} \end{bmatrix} \xrightarrow{\mathbf{G}_{21}} \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} = \begin{bmatrix} r_{11}^{21} & r_{12}^{21} \\ 0 & r_{22}^{21} \end{bmatrix} \iff \begin{cases} a_{11} \cos \alpha_{21} + a_{21} \sin \alpha_{21} = r_{11}^{21} \\ a_{12} \cos \alpha_{21} + a_{22} \sin \alpha_{21} = r_{12}^{21} \\ a_{21} \cos \alpha_{21} - a_{11} \sin \alpha_{21} = 0 \\ a_{22} \cos \alpha_{21} - a_{12} \sin \alpha_{21} = r_{22}^{21} \end{cases}$$

- Ecuația care conduce la determinarea unghiului de rotație aferent este a treia.
- Celelalte ecuații oferă valorile matricii triunghiulare rezultate.
- Calculul **se simplifică**, prin **determinarea directă** a elementelor operatorului Givens.

$$\alpha_{21} = \operatorname{atan2} \left(\frac{a_{21}}{a_{11}} \right)$$

$$\mathbf{G}_{21} \stackrel{def}{=} \begin{bmatrix} \cos \alpha_{21} & \sin \alpha_{21} \\ -\sin \alpha_{21} & \cos \alpha_{21} \end{bmatrix} = \begin{bmatrix} c_{21} & s_{21} \\ -s_{21} & c_{21} \end{bmatrix} = \frac{1}{\sqrt{a_{11}^2 + a_{21}^2}} \begin{bmatrix} a_{11} & a_{21} \\ -a_{21} & a_{11} \end{bmatrix}$$

Se evită utilizarea funcțiilor trigonometrice.

notație preluată din Robotică

$$s_{ij} \stackrel{def}{=} \sin \alpha_{ij} \quad c_{ij} \stackrel{def}{=} \cos \alpha_{ij}$$

- În cazul unei matrici monice oarecare, operatorul Givens care anulează primul element sub-diagonal se obține din \mathbf{G}_{21} prin **extinderea cu matricea unitate**, fără a recalcula elementele acestuia.

$$\mathbf{G}_2 \stackrel{def}{=} \begin{bmatrix} \mathbf{G}_{21} & \mathbf{0} \\ \mathbf{0} & \mathbf{I}_{m-2} \end{bmatrix}$$

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



MCMMP-R bazată pe descompunerea QR (continuare)

Așadar

$$G_2 A = \begin{bmatrix} \boxed{R_2} \\ \text{---} \\ \boxed{A_2} \end{bmatrix}$$

$$\begin{bmatrix} R_{21} & B_2 \end{bmatrix} \quad \text{! Epică.}$$

ultimele $m-2$ linii ale matricii A

Prin intermediul a 2 operatori Givens, a căror topologie este determinată de pozițiile celor 2 elemente.

Cum se pot anula primele 2 elemente ale lui A_2 ?



$$G_{31}^{def} = \begin{bmatrix} c_{31} & 0 & s_{31} \\ 0 & 1 & 0 \\ -s_{31} & 0 & c_{31} \end{bmatrix} = \frac{1}{\sqrt{(r_{11}^{21})^2 + a_{31}^2}} \begin{bmatrix} r_{11}^{21} & 0 & a_{31} \\ 0 & 1 & 0 \\ -a_{31} & 0 & r_{11}^{21} \end{bmatrix}$$

$$G_3^1 = \begin{bmatrix} G_{31} & 0 \\ \text{---} & \text{---} \\ 0 & I_{m-3} \end{bmatrix}$$

$$G_3^1 (G_2 A) = \begin{bmatrix} R_{31} \\ \text{---} \\ A_3 \end{bmatrix}$$

Acesta trebuie acum anulat.

$$r_{32}^{31}$$

! Elementul din poziția 32 nu este neapărat nul și nici egal cu a_{32} .

$$G_{32}^{def} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & c_{32} & s_{32} \\ 0 & -s_{32} & c_{32} \end{bmatrix} = \frac{1}{\sqrt{(r_{22}^{31})^2 + (r_{32}^{31})^2}} \begin{bmatrix} 1 & 0 & 0 \\ 0 & r_{22}^{31} & r_{32}^{31} \\ 0 & -r_{32}^{31} & r_{22}^{31} \end{bmatrix}$$

$$G_3 = G_3^2 G_3^1$$

$$G_3^2 = \begin{bmatrix} G_{32} & 0 \\ \text{---} & \text{---} \\ 0 & I_{m-3} \end{bmatrix}$$

$$G_3^2 (G_3^1 G_2 A) = \begin{bmatrix} \boxed{R_3} \\ \text{---} \\ \boxed{A_3} \end{bmatrix}$$

epică, superior triunghiulară

ultimele $m-3$ linii ale matricii A

Operatorul care anulează următoarele 2 elemente sub-diagonale ale matricii.

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



MCMMP-R bazată pe descompunerea QR (continuare)

În general

$$\mathbf{G}_i = \mathbf{G}_i^{i-1} \cdots \mathbf{G}_i^j \cdots \mathbf{G}_i^2 \mathbf{G}_i^1$$

Anulează elementele sub-diagonale ale matricii originale, de pe linia i .

Operator Givens compozit

$\forall i \in \{2, m\}$

Operatorul ortogonal de triangularizare

$$\mathbf{Q} = \mathbf{G}_m \mathbf{G}_{m-1} \cdots \mathbf{G}_3 \mathbf{G}_2$$

Ortogonal, deoarece este format dintr-un produs de matrici de rotație elementare.

$$\mathbf{G}_i^j = \begin{bmatrix} \mathbf{I}_{j-1} & \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & c_{ij} & \mathbf{0} & \cdots & \mathbf{0} & s_{ij} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & 1 & \cdots & \mathbf{0} & \mathbf{0} & \mathbf{0} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \cdots & 1 & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & -s_{ij} & \mathbf{0} & \cdots & \mathbf{0} & c_{ij} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} & \mathbf{0} & \mathbf{I}_{i-1} \end{bmatrix} \in \mathbb{R}^{m \times m}$$

← poziția j

← poziția i

$\forall j \in \overline{1, i-1}$

Exercițiu

- Să se determine numărul de operatori Givens elementari care formează operatorul ortogonal de triangularizare.

Mai mult

Acest operator Givens elementar modifică doar liniile i și j ale matricii originale.

$$\text{lin}_i(\mathbf{G}_i^j \mathbf{A}) = c_{ij} \text{lin}_i(\mathbf{A}) - s_{ij} \text{lin}_j(\mathbf{A})$$

$$\text{lin}_j(\mathbf{G}_i^j \mathbf{A}) = c_{ij} \text{lin}_j(\mathbf{A}) + s_{ij} \text{lin}_i(\mathbf{A})$$

Așadar

$$\mathbf{G}_m \mathbf{G}_{m-1} \cdots \mathbf{G}_3 \mathbf{G}_2 \mathbf{A} = \mathbf{R}$$

monică, superior triunghiulară

Elementele deja anulate rămân nule și după aplicarea oricărui operator Givens elementar.

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



MCMMP-R bazată pe descompunerea QR (continuare)

- Folosind **descompunerea QR a matricii regresorilor**, criteriul pătratic din contextul modelelor de regresie liniară poate fi minimizat printr-o tehnică specială, **stabilă din punct de vedere numeric**.

invarianța normei euclidiene la transformări ortogonale

$$\begin{matrix} N \\ \text{Q} \\ N \end{matrix} \times \begin{matrix} n\theta \\ \Phi \\ N \end{matrix} = \begin{matrix} n\theta \\ \mathbf{R} \\ N \end{matrix}$$

$Q = G_m G_{m-1} \dots G_3 G_2$

$$\mathcal{V}(\theta) \stackrel{\text{def}}{=} \|\varepsilon(\theta)\|^2 = \|\mathbf{Y} - \Phi\theta\|^2 = \|\mathbf{Q}(\mathbf{Y} - \Phi\theta)\|^2$$

Minimizarea constă în **anularea primului termen**.

$$\mathcal{V}(\theta) = \left\| \begin{bmatrix} \mathbf{r}^1 \\ \mathbf{r}^2 \end{bmatrix} - \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix} \theta \right\|^2 = \underbrace{\|\mathbf{r}^1 - \mathbf{R}\theta\|^2}_0 + \|\mathbf{r}^2\|^2$$

$$\mathcal{V}(\theta) = \left\| \begin{bmatrix} \mathbf{QY} \\ \mathbf{0} \end{bmatrix} - \begin{bmatrix} \mathbf{R} \\ \mathbf{0} \end{bmatrix} \theta \right\|^2$$

$$\mathbf{R}\theta = \mathbf{r}^1 \quad \gamma_N \hat{\lambda}^2$$

Sistem compatibil și determinat, care se poate rezolva prin procedeul substituției înapoi (sau al "exfolierii").

$$\mathbf{QY} = \begin{bmatrix} \mathbf{r}^1 \in \mathbb{R}^{n\theta} \\ \mathbf{r}^2 \in \mathbb{R}^{N-n\theta} \end{bmatrix}$$

Segmentare sugerată de forma operatorului aplicat lui θ .

$$\begin{bmatrix} r_{11} & \dots & r_{1(n\theta-1)} & r_{1n\theta} \\ \vdots & \ddots & \vdots & \vdots \\ 0 & \dots & r_{(n\theta-1)(n\theta-1)} & r_{(n\theta-1)n\theta} \\ 0 & \dots & 0 & r_{n\theta n\theta} \end{bmatrix} \begin{bmatrix} \hat{\theta}_1 \\ \vdots \\ \hat{\theta}_{n\theta-1} \\ \hat{\theta}_{n\theta} \end{bmatrix} = \begin{bmatrix} r_1^1 \\ \vdots \\ r_{n\theta-1}^1 \\ r_{n\theta}^1 \end{bmatrix}$$

$$\hat{\theta}_{n\theta} = \frac{r_{n\theta}^1}{r_{n\theta n\theta}}, \quad \hat{\theta}_{n\theta-1} = \frac{r_{n\theta-1}^1 - r_{(n\theta-1)n\theta} \hat{\theta}_{n\theta}}{r_{(n\theta-1)(n\theta-1)}}$$

$$\dots \hat{\theta}_1 = \frac{r_1^1 - r_{12} \hat{\theta}_2 - \dots - r_{1n\theta} \hat{\theta}_{n\theta}}{r_{11}}$$

$$\mathcal{O} \sim n\theta^2$$

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



MCMMP-R bazată pe descompunerea QR (continuare)

Dar în variantă adaptivă?

Se pleacă de la contextul curent definit pentru pasul $k-1 \geq n\theta$.



$$\Phi_{k-1} = \begin{matrix} \text{def} \\ \left[\begin{array}{c} \varphi^T[1] \\ \varphi^T[2] \\ \vdots \\ \varphi^T[k-1] \end{array} \right] \end{matrix} \in \mathbb{R}^{(k-1) \times n\theta}$$

→ Matricea curentă a regresorilor.

$$\mathbf{Y}_{k-1} \in \mathbb{R}^{k-1} \rightarrow \text{Vectorul curent al datelor de ieșire măsurate.}$$

$$\hat{\boldsymbol{\theta}}_{k-1} \in \mathbb{R}^{n\theta} \rightarrow \text{Vectorul curent al parametrilor estimați.}$$

$$\hat{\lambda}_{k-1}^2 \rightarrow \text{Dispersia curent estimată a zgomotului alb.}$$

$$\mathbf{Q}_{k-1} \Phi_{k-1} = \begin{bmatrix} \mathbf{R}_{k-1} \\ \mathbf{0} \end{bmatrix}$$

$\in \mathbb{R}^{n\theta \times n\theta}$

$\in \mathbb{R}^{(k-1) \times (k-1)}$

→ Descompunerea QR a matricii curente a regresorilor.

$$\mathbf{Q}_{k-1} \mathbf{Y}_{k-1} = \begin{bmatrix} \mathbf{r}_{k-1}^1 \\ \vdots \\ \mathbf{r}_{k-1}^2 \end{bmatrix}$$

$\in \mathbb{R}^{n\theta}$

$\in \mathbb{R}^{k-n\theta-1}$

→ Segmentarea curentă, în vederea minimizării.

• La pasul următor se adaugă datele: $y[k]$ $\varphi[k]$

$$\Phi_k = \begin{bmatrix} \Phi_{k-1} \\ \varphi^T[k] \end{bmatrix} \quad \mathbf{Y}_k = \begin{bmatrix} \mathbf{Y}_{k-1} \\ y[k] \end{bmatrix}$$



Relații recurente evidente.

Reactualizarea descompunerii QR, a vectorului parametrilor necunoscuți și a dispersiei zgomotului alb, prin conservarea efortului de calcul de la pasul curent.

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



MCMMP-R bazată pe descompunerea QR (continuare)

Reactualizarea descompunerii QR se bazează pe **matricea Q_{k-1} bordată.**

$$Q_k^{k-1} \stackrel{\text{def}}{=} \begin{bmatrix} Q_{k-1} & \mathbf{0} \\ \mathbf{0} & 1 \end{bmatrix} \in \mathbb{R}^{k \times k}$$

$$Q_k^{k-1} \Phi_k = \begin{bmatrix} Q_{k-1} & \mathbf{0} \\ \mathbf{0} & 1 \end{bmatrix} \begin{bmatrix} \Phi_{k-1} \\ \varphi^T[k] \end{bmatrix} = \begin{bmatrix} Q_{k-1} \Phi_{k-1} \\ \varphi^T[k] \end{bmatrix} = \begin{bmatrix} R_{k-1} \\ \mathbf{0} \\ \varphi^T[k] \end{bmatrix}$$

☝ O mare parte a efectului dorit fiind realizată, doar **ultima linie** mai trebuie anulată.

Colecție de $n\theta$ operatori Givens elementari.

$$G_k^j \stackrel{\text{def}}{=} \begin{bmatrix} \mathbf{I}_{j-1} & \mathbf{0} & \mathbf{0} & \dots & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & c_{kj} & 0 & \dots & 0 & s_{kj} \\ \mathbf{0} & 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \mathbf{0} & 0 & 0 & \dots & 1 & 0 \\ \mathbf{0} & -s_{kj} & 0 & \dots & 0 & c_{kj} \end{bmatrix} \in \mathbb{R}^{k \times k} \quad \forall j \in \overline{1, n\theta}$$

← poziția j (variabilă)

← poziția k (constantă)

$$s_{kj} = \frac{\varphi_j[k]}{\sqrt{(r_{jj}^{k-1})^2 + \varphi_j^2[k]}}$$

$$c_{kj} = \frac{r_{jj}^{k-1}}{\sqrt{(r_{jj}^{k-1})^2 + \varphi_j^2[k]}}$$

$\forall j \in \overline{1, n\theta}$

Rezultă

$$Q_k = G_k^1 G_k^2 \dots G_k^{n\theta-1} G_k^{n\theta} Q_k^{k-1} = \begin{bmatrix} R_k \\ \mathbf{0} \\ \mathbf{0} \end{bmatrix} = G_k^1 G_k^2 \dots G_k^{n\theta-1} G_k^{n\theta} \begin{bmatrix} R_{k-1} \\ \mathbf{0} \\ \varphi^T[k] \end{bmatrix}$$

☝ Descompunerea QR reactualizată.

4 Metode de identificare și validare

4.9 Metode adaptive de identificare

MCMMP-R bazată pe descompunerea QR (continuare)

Reactualizarea vectorilor liberi se bazează pe recurența din descompunerea QR.

$$\begin{bmatrix} \mathbf{r}_k^1 \\ \mathbf{r}_k^2 \end{bmatrix} = \mathbf{Q}_k \mathbf{Y}_k = \mathbf{G}_k^1 \mathbf{G}_k^2 \dots \mathbf{G}_k^{n\theta-1} \mathbf{G}_k^{n\theta} \begin{bmatrix} \mathbf{Q}_{k-1} & \mathbf{0} \\ \mathbf{0} & 1 \end{bmatrix} \begin{bmatrix} \mathbf{Y}_{k-1} \\ y[k] \end{bmatrix} = \mathbf{G}_k^1 \mathbf{G}_k^2 \dots \mathbf{G}_k^{n\theta-1} \mathbf{G}_k^{n\theta} \begin{bmatrix} \mathbf{r}_{k-1}^1 \\ \mathbf{r}_{k-1}^2 \\ y[k] \end{bmatrix}$$

☞ Uneori, nu este necesară determinarea vectorilor parametrilor la fiecare pas de reactualizare.

Altfel $\hat{\theta}_k = \mathbf{R}_k^{-1} \mathbf{r}_k^1$ ☞ **Nu prin inversare, ci prin exfoliere.**

Algoritmul adaptiv al Celor Mai Mici Pătrate cu descompunere QR

Date de intrare

$n\theta$ (indicele structural al modelului de identificare)

$\mathcal{D}_M = \{\varphi[n]\}_{n \in \overline{1, n\theta}} \cup \{y[n]\}_{n \in \overline{1, n\theta}}$ (un set de date măsurate a priori)

☞ Dimensiune egală cu indicele structural.

Inițializare

$\mathbf{Q}_{n\theta} \Phi_{n\theta} = \mathbf{R}_{n\theta} \in \mathbb{R}^{n\theta \times n\theta} \rightarrow$ descompunere QR off-line

$\mathbf{r}_{n\theta}^1 = \mathbf{Q}_{n\theta} \mathbf{Y}_{n\theta} \in \mathbb{R}^{n\theta}$ $\mathbf{r}_{n\theta}^2 = \mathbf{0} \in \mathbb{R}^0 \rightarrow$ vectorii liberi inițiali (al doilea – vid)

$\hat{\theta}_{n\theta} = \mathbf{R}_{n\theta}^{-1} \mathbf{r}_{n\theta}^1 \rightarrow$ vectorul inițial al parametrilor (prin exfoliere)

$\hat{\lambda}_{n\theta}^2 = 0 \rightarrow$ dispersia inițială a zgomotului

$k = n\theta \rightarrow$ indicele iterativ inițial

4 Metode de identificare și validare

4.9 Metode adaptive de identificare



MCMMP-R bazată pe descompunerea QR (continuare)

Algoritmul adaptiv al Celor Mai Mici Pătrate cu descompunere QR (continuare)

Bucă iterativă

☞ Pentru $k \geq n\theta + 1$

① Se evaluează operatorii Givens elementari:

$$G_k^j \stackrel{\text{def}}{=} \begin{bmatrix} \mathbf{I}_{j-1} & 0 & 0 & \dots & 0 & 0 \\ 0 & c_{kj} & 0 & \dots & 0 & s_{kj} \\ 0 & 0 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & 1 & 0 \\ 0 & -s_{kj} & 0 & \dots & 0 & c_{kj} \end{bmatrix} \in \mathbb{R}^{k \times k} \quad \forall j \in \overline{1, n\theta}$$

$$s_{kj} = \frac{\varphi_j[k]}{\sqrt{(r_{jj}^{k-1})^2 + \varphi_j^2[k]}}$$

$$c_{kj} = \frac{r_{jj}^{k-1}}{\sqrt{(r_{jj}^{k-1})^2 + \varphi_j^2[k]}}$$

② Se evaluează operatorul Givens global:

$$G_k = \prod_{j=1}^{n\theta} G_k^j$$

③ Se reactualizează operatorul ortogonal de triangularizare matricială:

$$Q_k = G_k \begin{bmatrix} Q_{k-1} & 0 \\ 0 & 1 \end{bmatrix}$$

④ Se reactualizează matricea triunghiulară și vectorii liberi:

$$\begin{bmatrix} R_k \\ 0 \\ 0 \end{bmatrix} = G_k \begin{bmatrix} R_{k-1} \\ 0 \\ \varphi^T[k] \end{bmatrix} \quad \begin{bmatrix} r_k^1 \\ r_k^2 \\ r_k^2 \end{bmatrix} = G_k \begin{bmatrix} r_{k-1}^1 \\ r_{k-1}^2 \\ y[k] \end{bmatrix}$$

☝ Algoritm extrem de stabil din punct de vedere numeric.

⑤ Se reactualizează vectorul parametrilor și dispersia zgomotului:

$$\hat{\theta}_k = R_k^{-1} r_k^1$$

$$\hat{\lambda}_k^2 = \frac{1}{\gamma_k} \|r_k^2\|^2$$

⑥ Se incrementează indicele curent: $k \leftarrow k + 1$



Date de ieșire

$$\{\hat{\theta}_k\}_{k \in \mathbb{N}}$$

Vectorii parametrilor modelului.

$$\{\hat{\lambda}_k^2\}_{k \in \mathbb{N}}$$

Dispersiile zgomotului.

$$\in \{N, N - n\theta\}$$