



Facultatea de Inginerie Electrică, Energetică  
și Informatică Aplicată (IEEIA)



# Identificarea și Modelarea Sistemelor

C10

Prof.univ.dr.ing. Marian-Silviu Poboroniuc

**Reamintire:** Estimatorul celor mai mici pătrate se obține din ecuațiile :

$$\hat{\theta}_{CMMP} = \hat{\theta}_{LS}$$

$$V(\theta) = \frac{1}{N} \sum_{k=1}^N (y(k) - \varphi^T(k)\theta)^2$$

$$\nabla V(\theta) = \frac{\partial V(\theta)}{\partial \theta} = 2 \frac{1}{N} \sum_{k=1}^N (-\varphi(k))(y(k) - \varphi^T(k)\theta) = 0$$

$$\nabla^2 V(\theta) = \frac{\partial^2 V(\theta)}{\partial \theta^2} = 2 \frac{1}{N} \sum_{k=1}^N (\varphi(k))\varphi^T(k) > 0$$

și este dat de relația

$$\hat{\theta}_{LS} = \left( \frac{1}{N} \sum_{k=1}^N \varphi(k)\varphi^T(k) \right)^{-1} \left( \frac{1}{N} \sum_{k=1}^N \varphi(k)y(k) \right)$$

## Reamintire: lesirea era :

$$y(k) = \varphi^T(k)\theta + v(k)$$

de unde

$$\varphi(k)y(k) = \varphi(k)\varphi^T(k)\theta + \varphi(k)v(k)$$

$$\frac{1}{N} \sum_{k=1}^N \varphi(k)y(k) = \frac{1}{N} \sum_{k=1}^N \varphi(k)\varphi^T(k)\theta + \frac{1}{N} \sum_{k=1}^N \varphi(k)v(k)$$

De unde doar daca  $\varphi(k)$  si  $v(k)$  sunt necorelate, rezulta (pentru ca ultima suma sa fie egala cu zero):

$$\hat{\theta}_{LS} = \left( \frac{1}{N} \sum_{k=1}^N \varphi(k)\varphi^T(k) \right)^{-1} \left( \frac{1}{N} \sum_{k=1}^N \varphi(k)y(k) \right)$$

## 5.5. Metode de variabilă instrumentală

### 5.5.1. Principiul metodei de variabilă instrumentală

Estimatorul celor mai mici pătrate (CMMP) dedus în metoda anterioară:

$$\hat{\theta}_{LS} = \left[ \frac{1}{N} \sum_{k=1}^N \varphi(k) \varphi^T(k) \right]^{-1} \left[ \frac{1}{N} \sum_{k=1}^N \varphi(k) y(k) \right]$$

este consistent dacă sunt îndeplinite condițiile:

$$R = E[\varphi(k) \varphi^T(k)] > 0;$$
$$E[\varphi(k) v(k)] = 0$$

Prima condiție este asigurată, în general, prin ***persistența semnalului de intrare***. A doua condiție este îndeplinită numai dacă  $v(k)$  este zgomot alb, și constituie o limitare a metodei.

Variabilele instrumentale sunt introduse tocmai în idea de a obține un estimator similar celor mai mici pătrate care să fie consistent indiferent de natura perturbației. Metoda de variabilă instrumentală utilizează estimatorul:

$$\hat{\theta}_{VI} = \left[ \frac{1}{N} \sum_{k=1}^N z(k) \varphi^T(k) \right]^{-1} \left[ \frac{1}{N} \sum_{k=1}^N z(k) y(k) \right]$$

în care  $\varphi(k)$  are aceeași semnificație ca în cazul metodei CMMP ,

$$\varphi(k) = \left[ -y(k-1), -y(k-2), \dots, -y(k-na), u(k-1), \dots, u(k-nb) \right]^T$$

iar  $z(k)$ , de dimensiune  $\dim z(k) = na + nb$  este un vector oarecare ale cărui componente, numite **variabile instrumentale**, trebuie alese în așa fel încât estimatorul să fie consistent

Înlocuind  $y(k) = \varphi^T(k)\theta^* + v(k)$  în relația estimatorului, se obține

$$\begin{aligned}\hat{\theta}_{VI} &= \left[ \frac{1}{N} \sum_{k=1}^N z(k)\varphi^T(k) \right]^{-1} \frac{1}{N} \sum_{k=1}^N z(k)\varphi^T(k)\theta^* + \\ &+ \left[ \frac{1}{N} \sum_{k=1}^N z(k)\varphi^T(k) \right]^{-1} \frac{1}{N} \sum_{k=1}^N z(k)v(k) = \\ &= \theta^* + \left[ \frac{1}{N} \sum_{k=1}^N z(k)\varphi^T(k) \right]^{-1} \frac{1}{N} \sum_{k=1}^N z(k)v(k)\end{aligned}\tag{5.77}$$

Din (5.77) rezultă condițiile de consistență a estimatorului VI:

$$R = E[z(k)\varphi^T(k)] = \frac{1}{N} \sum_{k=1}^N z(k)\varphi^T(k) > 0\tag{5.78}$$

$$E[z(k)v(k)] = \frac{1}{N} \sum_{k=1}^N z(k)v(k) = 0\tag{5.79}$$

Variabilele instrumentale pot fi corelate cu intrările și ieșirile, dar nu sunt corelate cu perturbațiile. Pentru a satisface cerințele (5.78), (5.79) foarte **frecvent se alege ca variabile de stare eșantioanele întârziate ale intrării**. La întâzieri mai mari condițiile sunt mai bine satisfăcute .

Ca și estimatorul CMMP și estimatorul VI este insensibil la o transformare liniară. Această proprietate se poate utiliza la construirea vectorilor de variabilă instrumentală. Într-adevăr, dacă înlocuim  $z(k)$  cu  $Tz(k)$ , unde  $T$  este o matrice  $n\theta \times n\theta$  de transformare nesusingulară, estimatorul devine

$$\begin{aligned}
 T\hat{\theta}_{VI} &= \left[ \frac{1}{N} \sum_{k=1}^N Tz(k)\varphi^T(k) \right]^{-1} \frac{1}{N} \sum_{k=1}^N Tz(k)y(k) = \\
 &= \left[ \frac{1}{N} \sum_{k=1}^N z(k)\varphi^T(k) \right]^{-1} T^{-1} \cdot T \frac{1}{N} \sum_{k=1}^N z(k)y(k) = \\
 &= \left[ \frac{1}{N} \sum_{k=1}^N z(k)\varphi^T(k) \right]^{-1} \frac{1}{N} \sum_{k=1}^N z(k)y(k) = \hat{\theta}_{VI}
 \end{aligned}$$

### 5.5.2. Alegerea variabilelor instrumentale de bază

Se consideră o formă generală a vectorului de variabilă instrumentală

$$z(k) = K(q^{-1})[-\eta(k-1), \dots, -\eta(k-na), u(k-1), \dots, u(k-nb)]^T \quad (5.80)$$

unde  $\eta(k)$  este obținut prin filtrarea datelor de intrare:

$$\begin{aligned}\eta(k) &= \frac{C(q^{-1})}{D(q^{-1})} u(k) \\ C(q^{-1}) &= c_0 + c_1 q^{-1} + \dots + c_{nc} q^{-nc} \\ D(q^{-1}) &= 1 + d_1 q^{-1} + \dots + d_{nd} q^{-nd}\end{aligned}\tag{5.81}$$

$K(q^{-1})$  și  $K^{-1}(q^{-1})$  sunt filtre asimptotic stabile, iar polinoamele  $C(q^{-1})$  și  $D(q^{-1})$  au zerourile în afara cercului unitar și sunt prime între ele.

Există o mare varietate de variabile instrumentale pentru cazuri particulare de forme ale filtrului  $K(q^{-1})$  și polinoamelor  $C(q^{-1})$  și  $D(q^{-1})$ .

Pentru fiecare din aceste cazuri se determină parametrii astfel ca relațiile (5.78), (5.79) să fie îndeplinite. Dacă de exemplu  $nc=nd=na$  relația (5.80) devine:



$$z(k) = \frac{K(q^{-1})}{D(q^{-1})} [-C(q^{-1})u(k-1), \dots, -C(q^{-1})u(k-na), D(q^{-1})u(k-1) \dots \\ \dots D(q^{-1})u(k-nb)]^T = S(-C, D) \frac{K(q^{-1})}{D(q^{-1})} [u(k-1), u(k-2), \dots, u(k-na-nb)]^T \quad (5.82)$$

unde  $S(-C, D)$  este matricea Sylvester asociată polinoamelor  $-C$  și  $D$  :

$$S(-C, D) = \left[ \begin{array}{cccccccc} -c_0 & -c_1 \dots & -c_{na} & \overbrace{0 \quad 0 \quad \dots \quad 0 \quad 0}^{n_b} & & & & \\ 0 & -c_0 \dots & -c_{na-1} & -c_{na} & 0 \dots & 0 & 0 & \\ 0 & 0 \dots & -c_0 & -c_1 & & & -c_{na} & \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \\ 1 & d_1 \dots & d_{na} & 0 & & 0 & 0 & \\ 0 & 1 & d_1 \dots & d_{na-1} & d_{na} & \dots & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \\ 0 & 0 \dots & 1 & d_1 \dots & & & d_{na} & \end{array} \right] \left. \begin{array}{l} \dots \\ \dots \\ \dots \end{array} \right\} n_b \left. \begin{array}{l} \dots \\ \dots \\ \dots \end{array} \right\} n_a \left. \begin{array}{l} \dots \\ \dots \\ \dots \end{array} \right\} n_a + n_b$$

Dacă  $C(q^{-1})$  și  $D(q^{-1})$  sunt polinoame prime între ele rezultă că rangul matricei  $S(-C, D)$  este egal cu suma  $na + nb$ , deci matricea  $S$  este nesingulară.

## Estimarea parametrilor prin metoda variabilelor instrumentale

În MATLAB modelul este de forma unei ecuații cu diferențe:

$$A(q^{-1})y(k) = B(q^{-1})u(k - ni) + e(k)$$

Este necesar să se definească matricea de date intrare-ieșire  $z=[y, u]$  sau *data* și să se cunoască structura definită prin vectorul  $nn= [na \ nb \ ni ]$ , în care  $na$  și  $nb$  sunt gradele polinoamelor  $A$  și respectiv  $B$ , iar  $ni$  este întârzierea. Modelul  $m$  obținut este în forma polinomială IDPOLY pentru sistemele cu o singură ieșire sau în forma IDARX pentru sisteme cu mai multe ieșiri, sau sub forma THETA. Se utilizează **funcția `iv4()`** care este apelată (una dintre forme):

$$m = iv4(z, nn);$$

**Exemplu:** Se consideră sistemul monovariabil discret definit prin polinoamele  $A=[1 \ -1.2 \ 0.6]$ ;  $B=[0 \ 1 \ 0.5]$ ; pentru partea deterministă și  $C=[1 \ -0.8 \ 0.4]$  pentru caracterizarea perturbațiilor. Se asociază acestui sistem modelul  $m$

```
>> m=idpoly(A,B,C).
```

Discrete-time IDPOLY model:  $A(q)y(t) = B(q)u(t) + C(q)e(t)$  ; $t=k$

$$A(q) = 1 - 1.2 q^{-1} + 0.6 q^{-2}$$

$$B(q) = q^{-1} + 0.5 q^{-2}$$

$$C(q) = 1 - 0.8 q^{-1} + 0.4 q^{-2}$$

Se generează un semnal de intrare pseudoaleator binar  $u(k)$  și un semnal perturbator aleator  $e(k)$ :

```
>> u=sign(randn(500,1));
```

```
>> e=0.1*randn(500,1);
```

Se determină prin simulare numerică răspunsul sistemului  $y(k)$  pentru aceste semnale de intrare

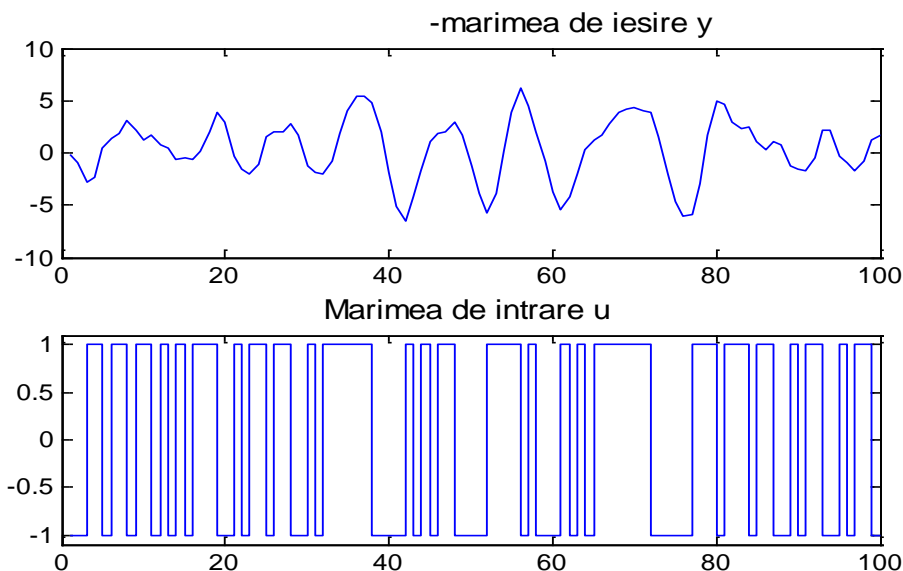
```
>> y=idsim([u,v],m);
```

Se consideră o matrice  $z$  cu vectori coloană conținând datele de ieșire și de intrare, eșantioanele cu numerele de la 1 la 300.

```
>>z=[y(1:300) u(1:300)];
```

- Se reprezintă grafic primele 100 de eșantioane de intrare-ieșire, prezentate în fig.5.3


```
- >>idplot(z, 1:100)
```



Prin metoda VI se caută un model cu doi poli,  $na=2$ , cu două zerouri,  $nb=2$  și întârzierea  $ni=1$ . Cu funcția *iv4* se obține modelul *thi*, care este afișat cu funcția *present*.

```
>>nn=[2 2 1]
```

```
>>thi=iv4(z,nn) ; >>present(thi)
```



$A(q) = 1 - 1.199 (+0.00315) q^{-1} + 0.5999 (+0.002534) q^{-2}$   
 $B(q) = 0.9942 (+0.005995) q^{-1} + 0.4983 (+0.00876) q^{-2}$   
 Estimated using IV4 from data set z  
 Loss function 0.0107966 and FPE 0.0110884

Sunt prezentate valorile coeficienților polinoamelor și abaterile lor standard. Cu funcția *resid* se determină reziduurile *ei* ale modelului și se reprezintă grafic în fig. 5.9.

```
>>ei=resid(z,thi);
```

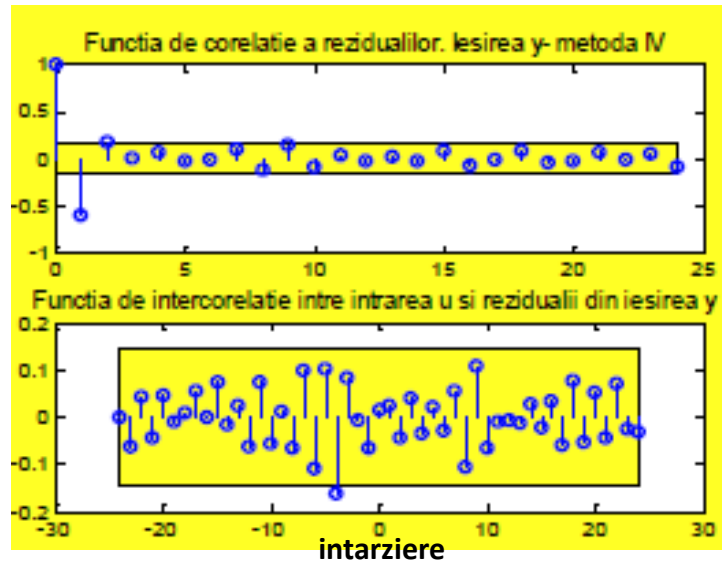


Fig. 5.9

Se reprezintă grafic răspunsul sistemului,  $y$  și a modelului IV4,  $y_m$ , pentru primele 50 de eșantioane, în fig.5.10

```
>>plot(t1,y(1:50),'b',t1,ym(1:50),'g');grid
>>title('Răspuns sistem y, răspuns model – ym. Metoda IV4')
```

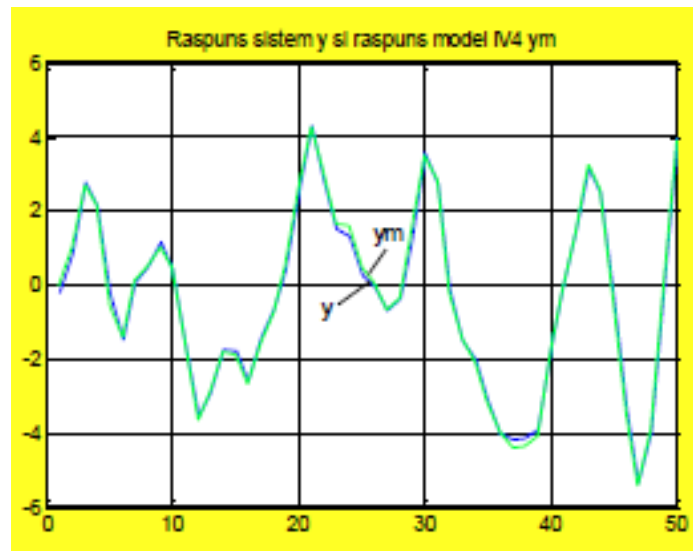


Fig. 5.10

# Metode recursive de identificare parametrică a sistemelor

- **Metodele de identificare** a parametrilor de tip **off-line** prezentate anterior prelucrează simultan întregul șir de măsurători intrare-ieșire.
- În cazul **metodelor de identificare recursive** sau **on-line** datele sunt prelucrate pe măsură ce ele devin disponibile prin măsurători.
- Procedurile **on-line** se impun în următoarele situații:
  - A-când se dorește continuarea experimentului de identificare până la obținerea unei precizii aprioric impuse;
  - B-când sistemul are parametri variabili în timp;
  - C-în cazul sistemelor de control adaptiv conform schemei bloc din fig. 5.11

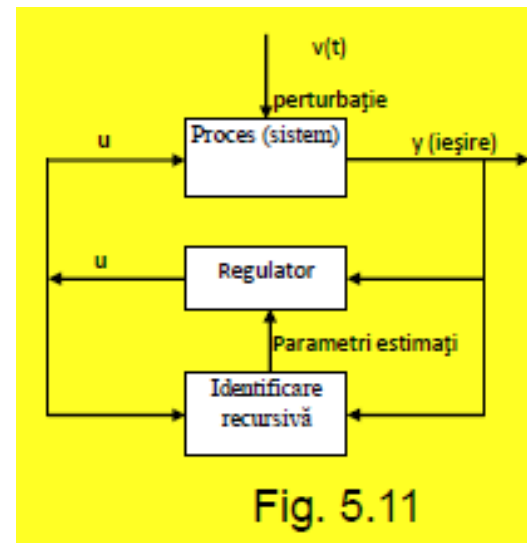


Fig. 5.11

# Metode recursive de identificare parametrică a sistemelor

- Procedurile **on-line** se impun în următoarele situații:
  - A-când se dorește continuarea experimentului de identificare până la obținerea unei precizii aprioric impuse;
  - B-când sistemul are parametri variabili în timp (*Parametrii procesului fiind variabili în timp, procesul nu poate fi reprezentat printr-un model valabil pentru orice moment de timp*);
  - C-în cazul sistemelor de control adaptiv conform schemei bloc din fig. 5.11 (*Se utilizează un model variabil în timp pentru a determina parametrii unui regulator, de asemenea, variabili în timp. În acest fel regulatorul va fi dependent de comportarea previzibilă a procesului*).




Fig. 5.11



# Metode recursive de identificare parametrică a sistemelor

- Algoritmii de estimare *on-line*, pot fi relativ simplu obținuți din cei off-line printr-o organizare corespunzătoare a calculelor, astfel ca estimația  $\theta(N+1)$  bazată pe  $N+1$  date, să poată fi calculată recursiv utilizând numai  $\theta(N)$ , măsurătorile la momentul  $N+1$  și alte câteva măsurători anterioare.
- Estimația recursivă este totuși o aproximare a estimației off-line și deci este mai puțin precisă.

# Metode recursive de identificare parametrică a sistemelor

- Metodele de identificare on-line cele mai utilizate sunt:
  1. Metoda recursivă a celor mai mici pătrate (**RCMMP**).
  2. Metoda recursivă a celor mai mici pătrate generalizate (**RCMMPG**)
  3. Metoda recursivă a variabilelor instrumentale (**RVI**)
  4. Metoda recursivă a verosimilității maxime (**RVM**)

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Se consideră un sistem real monovariabil (S/SO) descris de ecuațiile cu diferențe:

$$\begin{aligned}A^*(q^{-1})y(k) &= B^*(q^{-1})u(k) + v(k); v(k) = e(k) \\A^*(q^{-1}) &= 1 + a_1^*q^{-1} + \dots + a_{na}^*q^{-na} \\B^*(q^{-1}) &= b_1^*q^{-1} + \dots + b_{nb}^*q^{-nb} ; k = 1, 2, \dots\end{aligned}$$

Modelul este:

$$\begin{aligned}A(q^{-1})y_m(k) &= B(q^{-1})u(k) \\A(q^{-1}) &= 1 + a_1q^{-1} + \dots + a_{na}q^{-na} \\B(q^{-1}) &= b_1q^{-1} + b_2q^{-2} + \dots + b_{nb}q^{-nb} .\end{aligned}$$

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Pentru model:  $A(q^{-1})y_m(k) = B(q^{-1})u(k)$

$$A(q^{-1}) = 1 + a_1q^{-1} + \dots + a_{na}q^{-na}$$

$$B(q^{-1}) = b_1q^{-1} + b_2q^{-2} + \dots + b_{nb}q^{-nb} .$$

Se introduc notațiile:

$$\theta = [a_1, \dots, a_{na}, b_1, \dots, b_{nb}]^T$$

$$\varphi(k) = [-y(k-1), \dots, -y(k-n_a), u(k-1), \dots, u(k-n_b)]^T$$

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Pentru model:

$$A(q^{-1})y_m(k) = B(q^{-1})u(k)$$

$$A(q^{-1}) = 1 + a_1q^{-1} + \dots + a_{na}q^{-na}$$

$$B(q^{-1}) = b_1q^{-1} + b_2q^{-2} + \dots + b_{nb}q^{-nb} .$$

Se ajunge la forma:

$$y_m(k) = \varphi^T(k)\theta$$

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Pentru o funcție criteriu:

$$V(\theta) = \frac{1}{N} \sum_{k=1}^N A^2(q^{-1})(y(k) - y_m(k, \theta))^2 = \frac{1}{N} \sum_{k=1}^N A^2(q^{-1})e_m^2(k, \theta)$$

$$\begin{aligned} V(\theta) &= \frac{1}{N} \sum_{k=1}^N (A(q^{-1})y(k) - B(q^{-1})u(k))^2 = \\ &= \frac{1}{N} \sum_{k=1}^N (y(k) - \varphi^T(k)\theta)^2 \end{aligned}$$

se determină un estimator al celor mai mici pătrate pentru  $N$  măsurători.

$$\hat{\theta}(N) = \left( \sum_{k=1}^N \varphi(k)\varphi^T(k) \right)^{-1} \left( \sum_{k=1}^N \varphi(k)y(k) \right)$$

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Pentru o funcție criteriu generală:

$$\begin{aligned} V(\theta) &= \frac{1}{N} \sum_{k=1}^N \lambda^{N-k} (A(q^{-1})y(k) - B(q^{-1})u(k))^2 = \\ &= \frac{1}{N} \sum_{k=1}^N \lambda^{N-k} (y(k) - \varphi^T(k)\theta)^2 \end{aligned}$$

unde  $\lambda$  este un **coeficient de ponderare** a erorii pătratice, pentru  $N$  măsurători, se obține estimatorul.

$$\hat{\theta}(N) = \left( \sum_{k=1}^N \lambda^{N-k} \varphi(k) \varphi^T(k) \right)^{-1} \left( \sum_{k=1}^N \lambda^{N-k} \varphi(k) y(k) \right)$$

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Se introduce notatia:

$$P(N) = \left( \sum_{k=1}^N \lambda^{N-k} \varphi(k) \varphi^T(k) \right)^{-1}$$

Si estimatorul devine:

$$\hat{\theta}(N) = P(N) \left( \sum_{k=1}^N \lambda^{N-k} \varphi(k) y(k) \right)$$



# Metoda recursivă a celor mai mici pătrate (RCMMP).

Forma recursiva:

$$\begin{aligned} P(N+1) &= \left[ \sum_{k=1}^{N+1} \lambda^{N+1-k} \varphi(k) \varphi^T(k) \right]^{-1} = \\ &= \left[ \lambda \sum_{k=1}^N \lambda^{N-k} \varphi(k) \varphi^T(k) + \varphi(N+1) \varphi^T(N+1) \right]^{-1} = \\ &= \left[ \lambda P^{-1}(N) + \varphi(N+1) \varphi^T(N+1) \right]^{-1} \end{aligned}$$

Tine cont de identitatea de inversiune matriciala:

$$(A + bb^T)^{-1} = A^{-1} - A^{-1}b(1 + b^T A^{-1}b)^{-1}b^T A^{-1}$$

Utilizata cu  $A = \lambda * P^{-1}(N)$  si  $b = \varphi(N+1)$ .

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Se obține:

$$P(N+1) = \frac{P(N)}{\lambda} - \frac{P(N)}{\lambda} \varphi(N+1) \left[ 1 + \varphi^T(N+1) \frac{P(N)}{\lambda} \varphi(N+1) \right]^{-1} \cdot \varphi^T(N+1) \frac{P(N)}{\lambda} = \frac{1}{\lambda} \left[ P(N) - \frac{P(N) \varphi(N+1) \varphi^T(N+1) P(N)}{\lambda + \varphi^T(N+1) P(N) \varphi(N+1)} \right]$$

Si notatia:

$$K(N+1) = \frac{P(N) \varphi(N+1)}{\lambda + \varphi^T(N+1) P(N) \varphi(N+1)}$$

Rezulta

$$P(N+1) = \frac{1}{\lambda} [P(N) - K(N+1) \varphi^T(N+1) P(N)] = \frac{1}{\lambda} [I - K(N+1) \varphi^T(N+1)] P(N)$$

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Forma recursive pentru estimator:

$$\begin{aligned}\hat{\theta}(N+1) &= P(N+1) \sum_{k=1}^{N+1} \lambda^{N-k+1} \varphi(k) y(k) = \\ &= P(N+1) \left[ \lambda \sum_{k=1}^N \lambda^{N-k} \varphi(k) y(k) + \varphi(N+1) y(N+1) \right] = \\ &= P(N) \sum_{k=1}^N \lambda^{N-k} \varphi(k) y(k) - K(N+1) \varphi^T(N+1) P(N) \times \\ &\quad \times \sum_{k=1}^N \lambda^{N-k} \varphi(k) y(k) + \frac{P(N) \varphi(N+1) y(N+1)}{\lambda} - \\ &\quad - \frac{K(N+1) \varphi^T(N+1) P(N) \varphi(N+1) y(N+1)}{\lambda} = \\ &= \hat{\theta}(N) - K(N+1) \varphi^T(N+1) \hat{\theta}(N) + \\ &\quad + \frac{1}{\lambda} [P(N) \varphi(N+1) - K(N+1) \varphi^T(N+1) P(N) \varphi(N+1)] y(N+1) = \\ &= \hat{\theta}(N) - K(N+1) \varphi^T(N+1) \hat{\theta}(N) + \frac{\lambda K(N+1) y(N+1)}{\lambda} = \\ &= \hat{\theta}(N) + K(N+1) [y(N+1) - \varphi^T(N+1) \hat{\theta}(N)] = \\ &= \hat{\theta}(N) + K(N+1) \varepsilon(N+1)\end{aligned}$$

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Unde s-a tinut seama de:

$$P(N)\varphi(N+1) - K(N+1)\varphi^T(N+1)P(N)\varphi(N+1) = \lambda K(N+1)$$

Si s-a introdus notatia:

$$\varepsilon(N+1) = y(N+1) - \varphi^T(N+1)\hat{\theta}(N)$$

# Metoda recursivă a celor mai mici pătrate (RCMMP).

Implementarea relațiilor recurente este simplă. În esență următoarele operații trebuie efectuate pentru adaptarea informațiilor disponibile la momentul  $k$  :

a). Se adaptează  $\varphi(k) : \varphi(k) \rightarrow \varphi(k + 1)$

$$\varphi(k) = \begin{bmatrix} -y(k-1) \\ -y(k-2) \\ \vdots \\ -y(k-\hat{n}_a) \\ u(k-1) \\ u(k-2) \\ \vdots \\ u(k-\hat{n}_b) \end{bmatrix} \begin{array}{l} \leftarrow y(k) \text{ - noua măsurătoare a lui } y \\ \\ \\ \leftarrow \text{ se șterge} \\ \leftarrow u(k) \text{ noua măsurătoare a lui } u \\ \\ \\ \leftarrow \text{ se șterge} \end{array}$$

Se calculează :

b).  $x_a = P(k)\varphi(k+1)$

c).  $\sigma_a = \lambda + \varphi^T(k+1)x_a$

d).  $K(k+1) = \frac{x_a}{\sigma_a}$

e).  $\varepsilon(k+1) = y(k+1) - \varphi^T(k+1)\hat{\theta}(k)$

f).  $\hat{\theta}(k+1) = \hat{\theta}(k) + K(k+1)\varepsilon(k+1)$

g).  $P(k+1) = [P(k) - K(k+1)x_a^T] \frac{1}{\lambda}$

Metoda recursivă a celor mai mici pătrate (**RCMMP**).

În algoritmul recursiv RCMMP trebuie date valorile inițiale  $\hat{\theta}(0), P(0)$  și trebuie precizate valorile lui  $\lambda$ . Când nu se dispune de estimații inițiale ale parametrilor  $\hat{\theta}$  se alege de obicei  $\hat{\theta}(0) = 0$ . Pentru  $P(0)$  se alege frecvent

$$P(0) = \alpha I$$

## Metoda recursivă a celor mai mici pătrate (RCMMP).

$$P(0) = \alpha I$$

unde  $\alpha$  este un scalar cu valori de ordinul sutelor sau miilor, iar  $I$  este matricea unitate de același ordin cu  $P$ .

La valori mici ale lui  $\alpha$  convergența estimățiilor este lentă, iar la valori mari pot apărea oscilații de amplitudini mari pentru componentele vectorilor  $\hat{\theta}(\cdot)$

Pentru sisteme cu parametri variabili în timp  $\lambda$  se alege subunitar în domeniul 0,95 - 0,995.

Pentru sisteme invariante în timp  $\lambda$  se alege astfel:

$\lambda < 1$ , ( $\lambda = 0,95 - 0,995$ ) pentru primele câteva zeci de eșantioane  $k < N_1$ .  $\lambda = 1$ , pentru  $k > N_1$ .

În acest fel primele reziduuri care corespund unor estimății imprecise ale parametrilor sunt afectate de ponderi mici în criteriul CMMP.

## Estimarea recursivă a parametrilor modelelor discrete

Pentru estimarea recursivă a parametrilor modelelor discrete, în MATLAB, se utilizează funcțiile: ***rarx***, ***roe***, ***rarmax***, ***rpem***, ***rplr*** asociate diferitelor tipuri de modele ale sistemelor.

Astfel funcția ***rarx*** calculează estimațiile recursive pentru modele de tip ARX. Această funcție se apelează în forma

$$[thm, yhat] = rarx(z, nn, adm, adg) \quad (5.140)$$

unde:  $z$  este un obiect *iddata* sau o matrice de date intrare-ieșire  $\mathbf{z} = [\mathbf{y} \ \mathbf{u}]$ ; vectorul sau matricea (în cazul intrărilor multiple)  $\mathbf{nn} = [\mathbf{na} \ \mathbf{nb} \ \mathbf{ni}]$  definește structura modelului;  $\mathbf{adm}$  - definește mecanismul de adaptare;  $\mathbf{adg}$  – definește factorul de amplificare de adaptare



Algoritmii implementați se bazează pe unul din următoarele principii de adaptare:

- 1) **algoritmul bazat pe factorul de uitare** – măsurătorile vechi sunt deponderate exponențial pe baza **factorului de uitare  $\lambda$** ; în acest caz  $adm='ff'$ ,  $adg=\lambda$  ( $\lambda$  = factorul de uitare);
- 2) **algoritmul bazat pe filtrul Kalman** – se consideră că parametrii adevărați variază cu un pas aleator cu matricea de covarianță incrementală  $R_1$  ; în acest caz  $adm='kf'$ ,  $adg= R_1$ ;
- 3) **algoritmul bazat pe gradientul nenormalizat** – pasul parametrilor este luat ca un **pas de gradient de lungime  $\gamma$**  ( $\gamma = \text{gam}$  ( $th_{nou} = th_{vechi} + \gamma * \psi * \epsilon$ )); în acest caz  $adm='ng'$ ,  $adg=\text{gam}$ ; 4)
- 4) **algoritmul bazat pe gradientul normalizat** – se procedează ca în cazul 3 dar  $\gamma$  este înlocuit cu  $\gamma / (\psi * \psi)$ ;

***thm*** – conține estimațiile obținute;

linia  $k$  a matricei *thm* conține estimațiile în “ordine alfabetică” ce corespund datelor din linia  $k$  din matricea  $z$  și momentului de timp  $k$ ;

***yhat*** – conține valorile predictate ale ieșirii; linia  $k$  corespunde momentului de timp  $k$ .

Valorile inițiale ale parametrilor **th0** și a “**matricei  $P$** ”, ( $P(0)=P_0$ ) pot fi date prin apelarea următoare

$$[thm, yhat, P] = rarx(z, nn, adm, adg, th0, P_0)$$

Valorile inițiale și finale ale vectorului auxiliar *phi* sunt obținute prin apelarea

$$[thm, yhat, P, phi] = rarx(z, nn, adm, adg, th0, P_0, phi_0)$$

Cu funcția **roe** se calculează estimațiile recursive pentru modelul erorii de ieșire definit de ecuația cu diferențe

$$y(k) = \frac{B(q^{-1})}{F(q^{-1})} u(k - ni) + e(k)$$

Funcția *roe* se poate apela sub forme asemănătoare cu cele ale funcției *rarx*. Astfel se utilizează apelările:

$[thm, yhat] = roe(z, nn, adm, adg);$

$[thm, yhat, P] = roe(z, nn, adm, adg, th0, P_0);$

$[thm, yhat, P, phi, psi] = roe(z, nn, adm, adg, th0, P_0, phi_0, psi_0).$

Parametrii au aceleași semnificații ca pentru funcția *rarx*, cu excepțiile: vectorul  $nn = [nb\ nf\ ni]$  și un nou vector auxiliar *psi* cu valoarea inițială  $psi_0$ .

Funcția ***rarmax*** calculează recursiv estimațiile pentru parametrii unui model de tip ARMAX. Această funcție se poate apela sub formele

$[thm, yhat] = rar\ max(z, nn, adm, adg);$

$[thm, yhat, P] = rar\ max(z, nn, adm, adg, th0, P_0);$

$[thm, yhat, P, phi, psi] = rar\ max(z, nn, adm, adg, th0, P_0, phi_0, psi_0)$

Față de funcțiile *rarx* și *roe* diferă parametrul de structură  $nn$ :  $nn = [na\ nb\ nc\ ni]$ .

Cu funcția ***rpem*** sunt calculate estimațiile recursive pentru un model general descris de ecuația cu diferențe de forma

$$A(q^{-1})y(k) = \frac{B(q^{-1})}{F(q^{-1})}u(k - ni) + \frac{C(q^{-1})}{D(q^{-1})}e(k) \quad (5.146)$$

Funcția ***rpem*** se poate apela sub formele:

$$[thm, yhat] = rpem(z, nn, adm, adg); \quad (5.147)$$

$$[thm, yhat, P] = rpem(z, nn, adm, adg, th0, P_0);$$

$$[thm, yhat, P, phi, psi] = rpem(z, nn, adm, adg, th0, P_0, phi_0, psi_0)$$

în acest caz  $nn = [na \ nb \ nc \ nd \ nf \ ni]$ .

Cu funcția ***rplr*** se calculează estimațiile recursive pentru un model general (5.146) prin metoda regresiei pseudoliniare.

Funcția ***rplr*** se apelează sub formele

$$[thm, yhat] = rplr(z, nn, adm, adg); \quad (5.148)$$

$$[thm, yhat, P] = rplr(z, nn, adm, adg, th0, P_0);$$

$$[thm, yhat, P, phi] = rplr(z, nn, adm, adg, th0, P_0, phi_0)$$

**Exemplul 5.5.** Se consideră un sistem definit de polinoamele  $A, B, C$ . Să se determine estimațiile recursive ale parametrilor diferitelor modele asociate acestui sistem. Inițial se consideră pentru acest sistem un model *idpoly*

```
>>th=idpoly(A,B,C);
```

Discrete-time IDPOLY model:  $A(q)y(t) = B(q)u(t) + C(q)e(t)$

$$A(q) = 1 - 1.2 q^{-1} + 0.6 q^{-2}$$
$$B(q) = q^{-1} + 0.5 q^{-2}$$
$$C(q) = 1 - 0.8 q^{-1} + 0.4 q^{-2}$$

Se generează o matrice  $z$  de date intrare-ieșire, din care primele 50 de eșantioane se reprezintă în fig. 5.12

```
>>u=sign(randn(500,1));
```

```
>>e=0.1*randn(500,1);
```

```
>>y=idsim([u e],th);
```

```
>>z=[y(1:250),u(1:250)];
```

```
>>idplot(z,1:50),pause
```

Se consideră un model de ordinul 2,  $na=nb=2$ , cu o întârziere  $ni=1$ . Se estimează parametrii unui model *thm1* cu funcția *rarx*, aplicând algoritmul factorului de uitare ('ff') cu factorul de uitare  $lambda=0.96$ ).

```
>> thm1 = rarx(z,[2 2 1],'ff',0.96);
```

Se reprezintă grafic parametrii estimați ca funcții de timp în fig.5.13.

```
>> plot(thm1); axis([0 50 -2 2])
```

Se determină parametrii unui model de tip ARMAX, *thm3*, cu structura  $nn = [2 2 2 1]$ , cu algoritmul de adaptare cu filtru Kalman ('kf'), cu o varianță a parametrilor de 0.01.

```
>> thm3 = rarmax(z,[2 2 2 1],'kf',0.01*eye(6));
```

Parametrii estimați sunt reprezentați grafic în fig. 5.15.

```
>> plot(thm3); axis([0 50 -2 2]); pause
```

Se determină parametrii unui model general *thm4* cu structura  $nn=[2 2 2 2 1 1]$  cu funcția *rpem*, cu algoritmul factorului de uitare ('ff'), cu factorul  $lambda=0.96$

```
>>thm4=rpem(z,[2 2 2 2 1 1],'ff', 0.96);
```

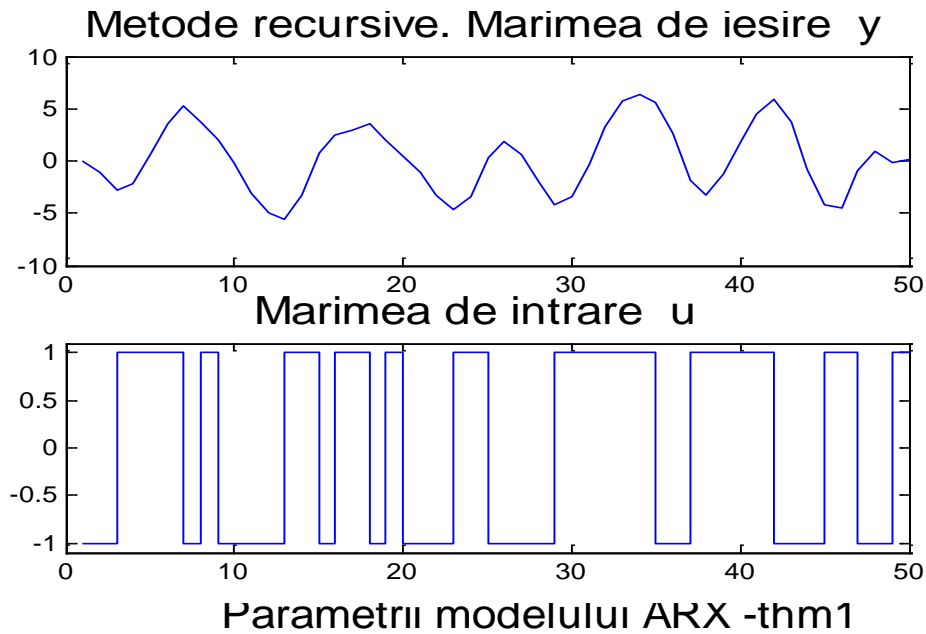


Fig. 5.12.

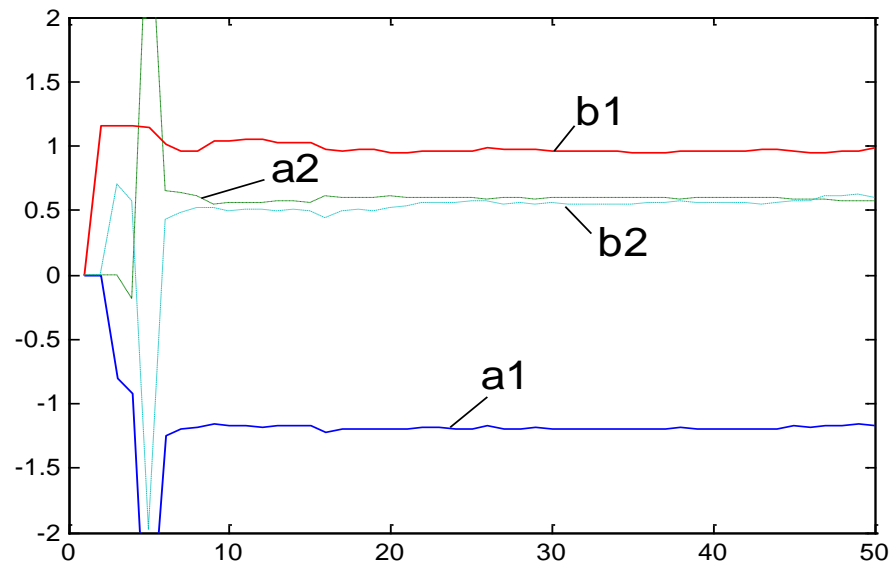


Fig. 5.13.



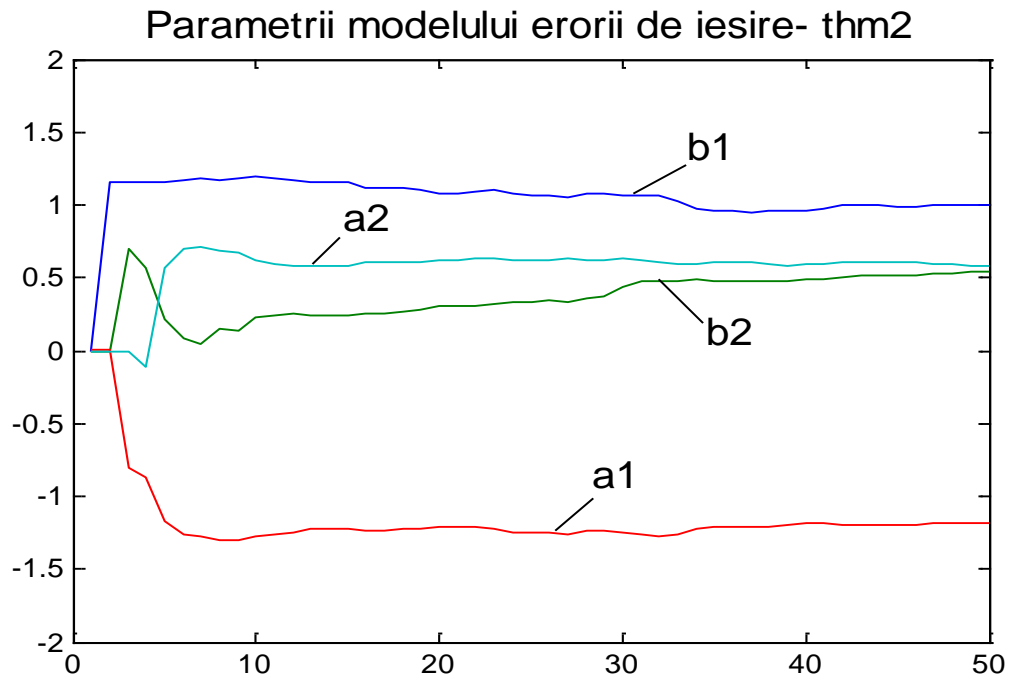


Fig. 5.14.

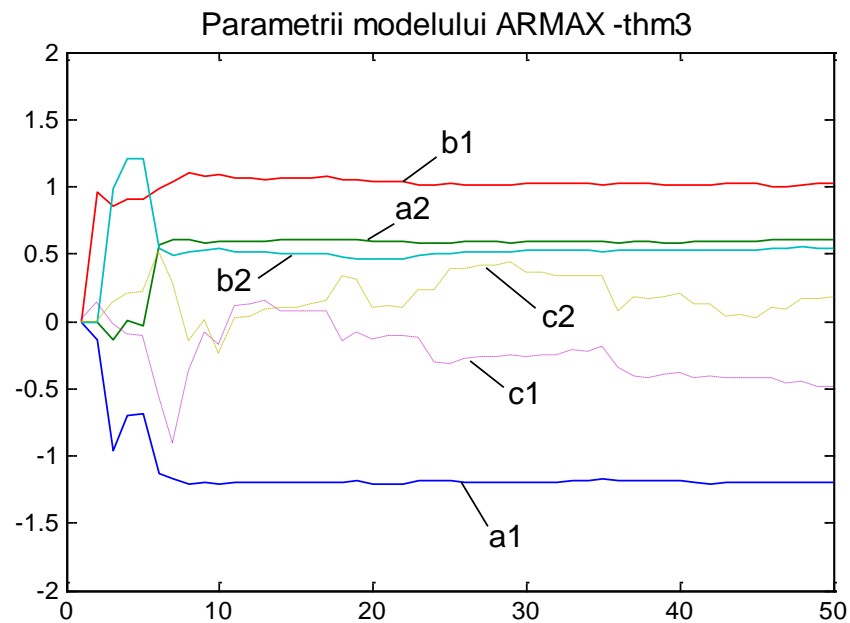


Fig. 5.15.