



Sumar

- ✓ Bibliografie
- ✓ ① Organizarea temelor de laborator
- ✓ ① Caracterizări în timp și frecvență ale proceselor stocastice
- ✓ ② Identificarea modelelor neparametrice
- ✓ ③ Identificare parametrică prin Metoda Celor Mai Mici Pătrate (MCMMP)
- ✓ ④ Identificare parametrică prin Metoda Variabilelor Instrumentale (MVI)
- ✓ ⑤ Identificare parametrică prin Metoda Minimizării Erorii de Predicție (MMEP)
- ☞ ⑥ Identificare recursivă

⑥ Identificare recursivă

☞ Contextul de lucru

- Majoritatea proceselor furnizoare de date **sunt neliniare** și/sau **posedă parametri variabili în timp**.
- Identificarea proceselor cu parametri variabili în timp se realizează cu ajutorul **modelelor și metodelor adaptive (recursive)**.
- Prin identificare recursivă, se urmărește **asigurarea unui compromis între două caracteristici opuse** ale estimației parametrilor necunoscuți (variabili pe orizontul de măsură):

05 0 Tc 0001 rg.02 16 Dimensiune 4996.02 0 202.499160 2BC 0 gBT3
orizont de adaptare


⑥ Identificare recursivă

☞ Contextul de lucru

⊗ Asigurarea compromisului precizie-adaptabilitate este dificilă.

Exemplu


Cazul parametrului scalar, variabil în timp.



Orizont de adaptare larg

☺ Valorile estimate ale parametrului sunt relativ apropiate de cele adevărate și tubul de varianță este relativ îngust.

⊗ Graficul parametrului estimat este neted, deci modelul sesizează mai puțin variațiile locale ale parametrului adevărat.



Orizont de adaptare îngust

⊗ Valorile estimate ale parametrului sunt relativ depărtate de cele adevărate și tubul de varianță este relativ larg.

☺ Graficul parametrului estimat urmărește variațiile locale ale parametrului adevărat, cu o anumită acuratețe.

$K = ?$



Se sacrifică precizia în favoarea adaptabilității.

$K = 1$

$$\hat{\theta}_k = \hat{\theta}_{k-1} + \Delta_k \quad \forall k \in \mathbb{N}^*$$

6 Identificare recursivă

Contextul de lucru

Algoritmul recursiv de bază în IS

➤ Date de intrare:

a. ordinele modelului de identificare: n_a , n_b , n_c , n_d și n_f ;

b. o colecție redusă de date intrare-ieșire măsurate (dacă este posibil):

$$\mathcal{D}_{N_0} = \{u[n]\}_{n \in \overline{1, N_0}} \cup \{y[n]\}_{n \in \overline{1, N_0}} \text{ (cu } N_0 \text{ de ordinul zecilor cel mult);}$$

c. un semnal instrumental extern: $\{f[n]\}_{n \geq 1}$ (eventual).

1. Dacă nu a fost specificat nici un semnal instrumental, vectorul variabilelor instrumentale, ζ , este identic cu vectorul regresorilor ϕ . Altfel, ζ este definit ca în cazul MVI, dar folosind în general semnalul instrumental extern f în locul intrării u (în particular, este posibil ca $f \equiv u$).

2. Inițializare. Fie se setează arbitrar vectorul parametrilor $\hat{\theta}_0$ și matricea $P_0 = \alpha I_{n_\theta}$ (cu $\alpha \in \mathbb{R}_+^*$) (în cazul în care nu se dispune de setul de date redus $\mathcal{D}_{N_0}$), fie se estimează valoarea inițială a parametrilor ($\hat{\theta}_0$) folosind o metodă off-line adecvată modelului particular utilizat (din clasa MCMMP-MVI) și se egalează matricea P_0 cu inversa matricii de covarianță R_0 folosită în calculul lui $\hat{\theta}_0$ (în cazul în care setul de date redus $\mathcal{D}_{N_0}$ este disponibil).

3. Pentru $k \geq 1$:

3.1. Se evaluează eroarea de predicție curentă: $\varepsilon[k] = y[k] - \phi^T[k] \hat{\theta}_{k-1}$.

3.2. Se evaluează vectorul auxiliar: $\xi_k = P_{k-1} \zeta[k]$.

3.3. Se evaluează câștigul de senzitivitate: $\gamma_k = \frac{\xi_k}{1 + \phi^T[k] \xi_k}$.

3.4. Se reactualizează inversa matricii R_k , adică: $P_k = P_{k-1} - \gamma_k \phi^T[k] P_{k-1}$ (cu evitarea inversării explicite a matricilor).

3.5. Se reactualizează vectorul parametrilor: $\hat{\theta}_k = \hat{\theta}_{k-1} + \gamma_k \varepsilon[k]$.

➤ Date de ieșire: parametrii $\hat{\theta}_k$ ai modelului de identificare la fiecare pas de reactualizare $k \geq 0$.

⑥ Identificare recursivă

☞ Contextul de lucru

Algoritmul recursiv cu fereastră dreptunghiulară

➤ Date de intrare:

a. ordinele modelului de identificare: n_a , n_b , n_c , n_d și n_f ;

b. lungimea ferestrei dreptunghiulare: M ;

c. o colecție redusă de date intrare-ieșire măsurate:

$$\mathcal{D}_M = \{u[n]\}_{n \in \overline{1, M}} \cup \{y[n]\}_{n \in \overline{1, M}} ;$$

d. un semnal instrumental extern: $\{f[n]\}_{n \geq 1}$ (eventual).

1. Dacă nu a fost specificat nici un semnal instrumental, vectorul variabilelor instrumentale, ζ , este identic cu vectorul regresorilor ϕ . Altfel, ζ este definit ca în cazul MVI, dar folosind în general semnalul instrumental extern f în locul intrării u (în particular, este posibil ca $f \equiv u$).

2. Inițializare. Se estimează valoarea inițială a parametrilor ($\hat{\theta}_0$) folosind o metodă off-line adecvată modelului particular utilizat (din clasa MCMMP-MVI, cu datele $\mathcal{D}_M$) și se egalează matricea P_0 cu inversa matricii de covarianță R_0 folosită în calculul lui $\hat{\theta}_0$.

3. Pentru $k \geq 1$:

3.1. Se evaluează eroarea de predicție la dreapta: $\varepsilon_d[k] = y[k] - \phi^T[k] \hat{\theta}_{k-1}$.

3.2. Se evaluează eroarea de predicție la stînga:

$$\varepsilon_s[k-M] = y[k-M] - \phi^T[k-M] \hat{\theta}_{k-1} .$$

3.3. Se reactualizează matricea P_k în 2 pași:

$$\bullet \xi_k = P_{k-1} \zeta[k] \text{ și } P_{k-1} \leftarrow P_{k-1} - \frac{\xi_k \phi^T[k] P_{k-1}}{1 + \phi^T[k] \xi_k} ;$$

$$\bullet \xi_k = P_{k-1} \zeta[k-M] \text{ și } P_{k-1} \leftarrow P_{k-1} + \frac{\xi_k \phi^T[k-M] P_{k-1}}{1 - \phi^T[k-M] \xi_k} .$$

3.4. Se reactualizează vectorul parametrilor:

$$\hat{\theta}_k = \hat{\theta}_{k-1} + P_k (\zeta[k] \varepsilon_d[k] - \zeta[k-M] \varepsilon_s[k-M]) .$$

➤ Date de ieșire: parametrii $\hat{\theta}_k$ ai modelului de identificare la fiecare pas de reactualizare $k \geq 0$.

⑥ Identificare recursivă

☞ Contextul de lucru

Algoritmul recursiv cu fereastră exponențială

➤ Date de intrare:

- ordinele modelului de identificare: n_a , n_b , n_c , n_d și n_f ;
- factorul de uitare: $\lambda \in [0, 1]$ (de regulă, $\lambda \in [0.95, 0.995]$);
- o colecție redusă de date intrare-ieșire măsurate (dacă este posibil):
 $\mathcal{D}_{N_0} = \{u[n]\}_{n \in \overline{1, N_0}} \cup \{y[n]\}_{n \in \overline{1, N_0}}$ (cu N_0 de ordinul zecilor, cel mult);
- un semnal instrumental extern: $\{f[n]\}_{n \geq 1}$ (eventual).

1. Dacă nu a fost specificat nici un semnal instrumental, vectorul variabilelor instrumentale, ζ , este identic cu vectorul regresorilor ϕ . Altfel, ζ este definit ca în cazul MVI, dar folosind în general semnalul instrumental extern f în locul intrării u (în particular, este posibil ca $f \equiv u$).

2. Inițializare. Fie se setează arbitrar vectorul parametrilor $\hat{\theta}_0$ și matricea $P_0 = \alpha I_{n_\theta}$ (cu $\alpha \in \mathbb{R}_+^*$) (în cazul în care nu se dispune de setul de date redus $\mathcal{D}_{N_0}$), fie se estimează valoarea inițială a parametrilor ($\hat{\theta}_0$) folosind o metodă off-line adecvată modelului particular utilizat (din clasa MCMMP-MVI) și se egalează matricea P_0 cu inversa matricii de covarianță R_0 folosită în calculul lui $\hat{\theta}_0$ (în cazul în care setul de date redus $\mathcal{D}_{N_0}$ este disponibil).

3. Pentru $k \geq 1$:

3.1. Se evaluează eroarea de predicție: $\varepsilon[k] = y[k] - \phi^T[k] \hat{\theta}_{k-1}$.

3.2. Se vectorul auxiliar: $\xi_k = P_{k-1} \zeta[k]$.

3.3. Se evaluează câștigul de senzitivitate: $\gamma_k = \frac{\xi_k}{\lambda + \phi^T[k] \xi_k}$.

3.4. Se reactualizează inversa matricii R_k , adică: $P_k = \frac{1}{\lambda} (P_{k-1} - \gamma_k \phi^T[k] P_{k-1})$ (cu evitarea inversării explicite a matricilor).

3.5. Se reactualizează vectorul parametrilor: $\hat{\theta}_k = \hat{\theta}_{k-1} + \gamma_k \varepsilon[k]$.

➤ Date de ieșire: parametrii $\hat{\theta}_k$ ai modelului de identificare la fiecare pas de reactualizare $k \geq 0$.

⑥ Identificare recursivă

☞ Contextul de lucru

Algoritmul recursiv de tip gradient

➤ Date de intrare:

- ordinele modelului de identificare: n_a , n_b , n_c , n_d și n_f ;*
- cîştigul de gradient: $\gamma \in \mathbb{R}_+^*$;*
- o colecție redusă de date intrare-ieșire măsurate (dacă este posibil):*
 $\mathcal{D}_{N_0} = \{u[n]\}_{n \in \overline{1, N_0}} \cup \{y[n]\}_{n \in \overline{1, N_0}}$ (cu N_0 de ordinul zecilor, cel mult);
- un semnal instrumental extern: $\{f[n]\}_{n \geq 1}$ (eventual).*

1. Dacă nu a fost specificat nici un semnal instrumental, vectorul variabilelor instrumentale, ζ , este identic cu vectorul regresorilor φ . Altfel, ζ este definit ca în cazul MVI, dar folosind în general semnalul instrumental extern f în locul intrării u (în particular, este posibil ca $f \equiv u$).

2. Inițializare. Fie se setează arbitrar vectorul parametrilor $\hat{\theta}_0$ (în cazul în care nu se dispune de setul de date redus $\mathcal{D}_{N_0}$), fie se estimează valoarea inițială a parametrilor ($\hat{\theta}_0$) folosind o metodă off-line adecvată modelului particular utilizat (din clasa MCMMP-MVI) (în cazul în care setul de date redus $\mathcal{D}_{N_0}$ este disponibil). Se setează $P_0 = \gamma I_{n_\theta}$.

3. Pentru $k \geq 1$:

3.1. Se evaluează eroarea de predicție: $\varepsilon[k] = y[k] - \varphi^T[k] \hat{\theta}_{k-1}$.

3.2. Se reactualizează matricea P_k astfel: $P_k = P_0$ (gradient ne-normalizat) sau
 $P_k = P_0 / \|\varphi[k]\|^2$ (gradient normalizat).

3.3. Se reactualizează vectorul parametrilor: $\hat{\theta}_k = \hat{\theta}_{k-1} + P_k \varphi[k] \varepsilon[k]$.

➤ Date de ieșire: parametrii $\hat{\theta}_k$ ai modelului de identificare la fiecare pas de reactualizare $k \geq 0$.

⑥ Identificare recursivă

☞ Contextul de lucru

Algoritmul recursiv cu filtrare Kalman

➤ Date de intrare:

- ordinele modelului de identificare: n_a , n_b , n_c , n_d și n_f ;
- matricea de răspîndire: $R_v > 0$;
- dispersia estimată a zgomotului alb de proces: λ^2 ;
- o colecție redusă de date intrare-ieșire măsurate (dacă este posibil):
 $\mathcal{D}_{N_0} = \{u[n]\}_{n \in \overline{1, N_0}} \cup \{y[n]\}_{n \in \overline{1, N_0}}$ (cu N_0 de ordinul zecilor, cel mult);
- un semnal instrumental extern: $\{f[n]\}_{n \geq 1}$ (eventual).

1. Dacă nu a fost specificat nici un semnal instrumental, vectorul variabilelor instrumentale, ζ , este identic cu vectorul regresorilor ϕ . Altfel, ζ este definit ca în cazul MVI, dar folosind în general semnalul instrumental extern f în locul intrării u (în particular, este posibil ca $f \equiv u$).

2. Inițializare. Fie se setează arbitrar vectorul parametrilor $\hat{\theta}_0$ și matricea $P_0 = \alpha I_{n_\theta}$ (cu $\alpha \in \mathbb{R}_+^*$) (în cazul în care nu se dispune de setul de date redus $\mathcal{D}_{N_0}$), fie se estimează valoarea inițială a parametrilor ($\hat{\theta}_0$) folosind o metodă off-line adecvată modelului particular utilizat (din clasa MCMMP-MVI) și se egalează matricea P_0 cu inversa matricii de covarianță R_0 folosită în calculul lui $\hat{\theta}_0$ (în cazul în care setul de date redus $\mathcal{D}_{N_0}$ este disponibil).

3. Pentru $k \geq 1$:

3.1. Se evaluează eroarea de predicție: $\varepsilon[k] = y[k] - \phi^T[k] \hat{\theta}_{k-1}$.

3.2. Se evaluează vectorul auxiliar: $\xi_k = P_{k-1} \zeta[k]$.

3.3. Se evaluează câștigul de senzitivitate: $\gamma_k = \frac{\xi_k}{\lambda^2 + \phi^T[k] \xi_k}$.

3.4. Se reactualizează matricea P_k , adică: $P_k = P_{k-1} + R_v - \gamma_k \phi^T[k] P_{k-1}$ (cu evitarea inversării explicite a matricilor).

3.5. Se reactualizează vectorul parametrilor: $\hat{\theta}_k = \hat{\theta}_{k-1} + \gamma_k \varepsilon[k]$.

➤ Date de ieșire: parametrii $\hat{\theta}_k$ ai modelului de identificare la fiecare pas de reactualizare $k \geq 0$.

⑥ Identificare recursivă

☞ Contextul de lucru

Procese generatoare de date

$$\text{ARMAX}[1,1,1] \quad (1 + a_1[n]q^{-1})y[n] = b_1[n]q^{-1}u[n] + (1 + c_1[n]q^{-1})e[n] \quad \forall n \in \mathbb{N}^*$$

Parametri constanți

$$a_1[n] = a_{10} = -0.7$$

$$b_1[n] = b_{10} = 0.6$$

$$c_1[n] = c_{10} = -0.9$$

$$\forall n \in \mathbb{N}^*$$

Parametri variabili

$$a_1[n] \stackrel{\text{def}}{=} a_{10} \cos\left(\frac{10\pi n}{N}\right) \quad b_1[n] \stackrel{\text{def}}{=} b_{10} \operatorname{sgn}\left[\cos\left(\frac{4\pi n}{N}\right)\right]$$

$$c_1[n] \stackrel{\text{def}}{=} c_{10} \operatorname{Sc}\left(\frac{18\pi n}{N}\right)$$

$$\forall n \in \mathbb{N}^*$$

e → SPAB Gaussian sau bipolar de medie nulă și dispersie unitară

Date generate $\mathcal{D} = \{u[n]\}_{n=1, \overline{N}} \cup \{y[n]\}_{n=1, \overline{N}}$

ales liber de către utilizator → $N \geq 200$

☞ Pe un orizont mare de timp, modelul ARMAX tinde să devină un model ARX.

Indici structurali sunt cunoscuți $na = nb = nc = 1$

Test de stop → Epuizarea datelor de pe orizontul de măsură.

Obiectiv

- Compararea performanțelor metodelor recursive de identificare în cazul modelelor din clasa ARMAX.



⑥ Identificare recursivă

👉 Probleme de simulare

Contextul de lucru

5p

Rutine preliminare

```
[theta,ypred] = rnume(D,si,ma,pa) ;
```

Rutine de bibliotecă MATLAB-IS

rarmax

ARMAX

MMEP-R

rarx

ARX

MCMMP-R

rbj

BJ

MMEP-R

rpem

RSISO

MMEP-R

rplr

ARMAX

MRPL-R

roe

OE

MMEP-R

👉 Argumentele de intrare al acestor funcții pot fi completate cu variabile care să indice explicit o anumită inițializare a procesului recursiv.

Metoda de Regresie Pseudo-Liniară

MMEP în care s-a înlocuit MGN cu o metodă de optimizare mai precisă:
Metoda Newton-Raphson (MNR)

```
[theta,ypred,P,phi] = rnume(D,si,ma,pa,theta0,P0,phi0) ;
```

D este obiectul de tip **IDDATA** corespunzător datelor generate (intrarea se regăsește în **D.u**, iar ieșirea în **D.y**);

si este vectorul indicilor structurali și al întârzierii modelului (ca în cazul rutinei **pem**):

si = [na nb nc nd nf nk];

⑥ Identificare recursivă

👉 Probleme de simulare

Contextul de lucru

Rutine preliminare

```
[theta,ypred,P,phi] = rnume(D,si,ma,pa,theta0,P0,phi0) ;
```

ma este un argument care indică metoda de adaptare a algoritmului off-line la algoritmul on-line (șir de 2 caractere):

- 'ff' se va opera cu criteriu pătratic afectat de fereastră exponențială (i.e. cu factor de uitare; 'ff' = *forgetting factor*);
- 'ug' se va utiliza o metodă de gradient (Newton-Raphson) ne-normalizată ('ug' = *unnormalized gradient*);
- 'ng' se va utiliza o metodă de gradient (Newton-Raphson) normalizată ('ng' = *normalized gradient*);
- 'kf' se va utiliza reprezentarea pe stare și filtrarea Kalman (aici: 'kf' = *Kalman filtering*);

pa este un parametru de adaptare corespunzător metodei de adaptare a algoritmului off-line la algoritmul on-line, adică argumentului **ma** (scalar sau matrice):

- λ factorul de uitare (scalar) pentru fereastra exponențială (când argumentul **ma** este setat cu 'ff');
- γ câștigul dorit (scalar) în cazul utilizării algoritmilor de gradient (când argumentul **ma** este setat cu 'ug' sau 'ng');
- R_v matricea de răspîndire în cazul utilizării algoritmului bazat pe filtrare Kalman (când argumentul **ma** este setat cu 'kf'); în acest caz, parametrul λ^2 (dispersia zgomotului alb) este considerat implicit egal cu 1; dacă, în realitate, λ^2 nu este unitară, se poate demonstra că estimația parametrilor nu este afectată dacă se scalează matricile R_v și P_0 cu valoarea estimată a sa (urmînd să se lucreze tot cu $\lambda^2 = 1$, ca în cazul implicit).

⑥ Identificare recursivă

👉 Probleme de simulare

Contextul de lucru

Rutine preliminare

[theta, ypred, P, phi] = rnume(D, si, ma, pa, theta0, P0, phi0) ;

theta este matricea parametrilor estimați variabili în timp; fiecare linie a matricii memorează valoarea parametrilor la un anumit moment de timp; numărul de linii este egal cu lungimea orizontului de măsură (adică a vectorilor **D.u** și **D.y**); pe fiecare linie, parametrii sunt precizați în ordinea alfabetică a numelor polinoamelor pe care le reprezintă (*A*, *B*, *C*, *D*, *F*);

ypred este vectorul ieșirii predictate a procesului la fiecare moment de timp, folosind modelul matematic reactualizat; lungimea sa este egală cu lungimea orizontului de măsură.

theta0 este vectorul inițial al parametrilor;

P0 este matricea inițială P_0 ;

phi0 este vectorul inițial al regresorilor $\phi[0]$;

P este matricea finală P_N ;

phi este vectorul final al regresorilor $\phi[N]$.

⑥ Identificare recursivă

👉 Probleme de simulare

Contextul de lucru

📌 Inexistentă în biblioteca
MATLAB-IS. Disponibilă pe CD.

Rutine preliminare

[theta,ypred,P,phi,z] = riv(D,si,f,lambda,theta0,P0,phi0,z0) ;

MVI-R

f este semnalul instrumental (implicit: **f=D.u**);
lambda este factorul de uitare ($\lambda \in (0,1]$) (implicit: **lambda=1**);
z0 este vectorul inițial al instrumentelor $\zeta[0]$;
z este vectorul final al instrumentelor $\zeta[N]$.

Restul argumentelor funcției au fost explicitate mai înainte, iar indicii structurali **si** conțin **numai ordinele modelului ARX**.

Cu toate acestea, algoritmul este implementat **numai în varianta cu fereastră exponențială** (de aceea argumentul **ma** lipsește).

[D,V,P] = gdata_vp(cv,N,sigma,lambda,bin) ; (generează date)

cv este un comutator care arată tipul de proces: cu parametri constanți (**cv=0**) sau cu parametri variabili (**cv~0**); (implicit: **cv=0**);
N este orizontul de măsură (implicit: **N=250**);
sigma este deviația standard a intrării SPA (implicit: **sigma=1**);

⑥ Identificare recursivă

➡ Probleme de simulare

Contextul de lucru

Rutine preliminare

[D,V,P] = gdata_vp(cv,N,sigma,lambda,bin) ; (generează date)

lambda este deviația standard a zgomotului alb Gaussian (implicit: **lambda=1**);

bin este un parametru care arată tipul de intrări dorit: **bin=0** (intrare SPAB Gaussiană); **bin~=-0** (implicit, intrare SPAB Gaussiană bipolară);

D este obiectul de tip **IDDATA** corespunzător datelor generate (intrarea se regăsește în **D.u**, iar ieșirea în **D.y**);

V este obiectul de tip **IDDATA** corespunzător zgomotelor generate (zgomotul alb se regăsește în **V.u**, iar zgomotul colorat (adică MA-filtrat) în **V.y**);

P este obiectul de tip **IDMODEL** corespunzător modelului de proces furnizor de date; în cazul parametrilor constanți: **P.a=[1 a0]**, **P.b=[0 b0]**, **P.c=[1 c0]**; în cazul parametrilor variabili: **P.a=[1 a]**, **P.b=[0 b]**, **P.c=[1 c]** (unde **a**, **b** și **c** sunt vectorii de variație).

☞ Se vor genera 2 seturi de date: unul provenit de la procesul cu parametri constanți și altul – de la procesul cu parametri variabili.

⑥ Identificare recursivă

👉 Probleme de simulare

Problema 6.1 (Identificare recursivă comparativă cu algoritmul de bază)

1p

Mini-simulatorul **ISLAB_6A** efectuează o comparație între cele 4 metode de identificare recursive menționate, adică: MCMMP-R, MVI-R, MMEP-R și MRPL-R, folosind setul de date $\mathcal{D}_c$ (generate de procesul cu parametri constanți). Primele două metode operează cu modelul ARX[1,1] (extras din modelul ARMAX prin anularea componentei MA), în timp ce ultimele două – cu modelul ARMAX[1,1,1]. Pentru aprecierea performanțelor lor, sunt afișate 4 ferestre grafice care includ variațiile parametrilor reali (aici constanți) suprapuse peste variațiile parametrilor estimați și variația ieșirii simulate suprapuse peste ieșirea reală (măsurată) a procesului.

0.3 p Să se comenteze rezultatele obținute cu ajutorul mini-simulatorului **ISLAB_6A**. Care ar fi explicațiile performanțelor mai slabe ale MCMMP-R în estimarea parametrului părții AR?

0.7 p Să se proiecteze mini-simulatorul **ISLAB_6B**, similar ca structură cu **ISLAB_6A**, dar care operează cu datele $\mathcal{D}_v$ (generate de procesul cu parametri variabili). Comentați rezultatele obținute.

Program
existent pe CD


ISLAB_6A

Program ce
trebuie proiectat

ISLAB_6B

⑥ Identificare recursivă

Ce afișează mini-simulatorul **ISLAB_6A**




Performanțele MCMMP-R în cazul modelului ARX

⑥ Identificare recursivă

Ce afișează mini-simulatorul **ISLAB_6A**


Performances of Recursive Instrumental Variables



Performanțele MVI-R în cazul modelului ARX

⑥ Identificare recursivă

Ce afișează mini-simulatorul **ISLAB_6A**




☞ Eficiență superioară.

Performanțele MMEP-R în cazul modelului ARMAX

⑥ Identificare recursivă

Ce afișează mini-simulatorul **ISLAB_6A**

Performances of Recursive Pseudo-Linear Regression



Performanțele MPRL-R în cazul modelului ARMAX

⑥ Identificare recursivă

👉 Probleme de simulare

Problema 6.2 (Identificare recursivă cu diferite inițializări) 2p

Să se proiecteze mini-simulatorul **ISLAB_6C**, care să afișeze performanțele MCMMP-R (sau MVI-R) pentru inițializările $P_0 = \alpha I$, cu $\alpha \in \{0.01, 0.1, 1, 10, 100\}$.

Program ce
trebuie proiectat

ISLAB_6C

Problema 6.3 (Identificare recursivă cu fereastră exponențială) 2p

Rutinele recursive folosite în mini-simulatoarele din **Problema 6.1** au posibilitatea de a opera cu fereastra exponențială aplicată erorii de predicție. Să se proiecteze mini-simulatorul **ISLAB_6D**, care să afișeze performanțele MCMMP-R (sau MVI-R) pentru următoarele valori ale factorului de uitare: $\lambda \in \{0.95, 0.96, 0.97, 0.98, 0.99\}$. Comentați rezultatele obținute în ultimele 2 probleme.

Program ce
trebuie proiectat

ISLAB_6D