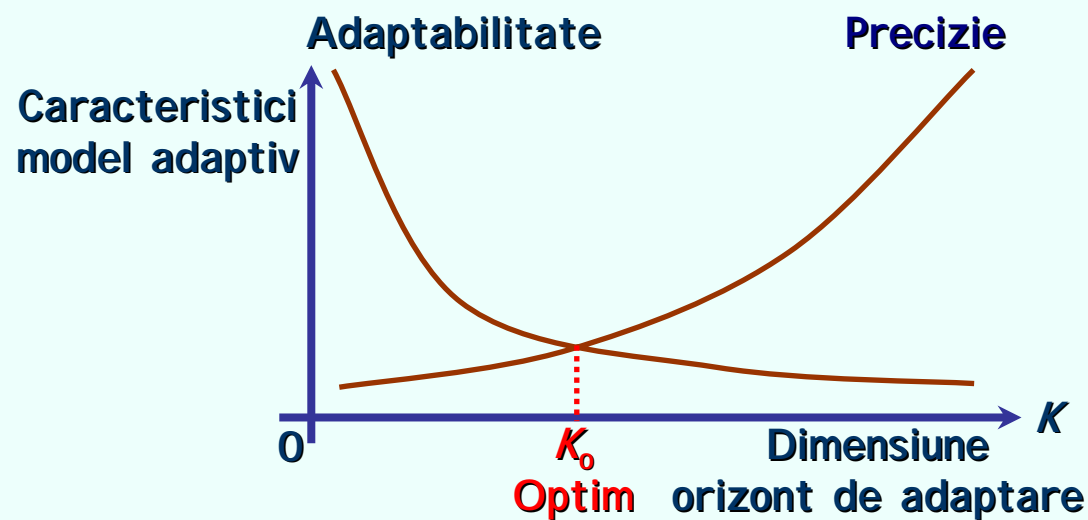


# 4 Metode de identificare și validare



## 4.9 Metode adaptive de identificare

- 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 **identificarea adaptivă**, se urmărește **asigurarea unui compromis între două caracteristici opuse** ale estimației parametrilor necunoscuți (variabili pe orizontul de măsură):



### Principiul metodelor adaptive

Estimația vectorului parametrilor necunoscuți se reactualizează folosind datele măsurate pe orizontul de adaptare.

$$\hat{\theta}_{K\left[\frac{k}{K}\right]} = \hat{\theta}_{K\left[\frac{k-1}{K}\right]} + \Delta_{K\left[\frac{k}{K}\right]} \quad \forall k \in \mathbb{N}^*$$

Corecție

Adaptabilitatea **scade**, în timp ce precizia **crește** odată cu dimensiunea orizontului de adaptare.

Cu cât se achiziționează **mai multe date** între momentele de reactualizare, cu atât **adaptarea se efectuează mai rar**, modelul fiind incapabil să surprindă variațiile caracteristicilor procesului între aceste momente.

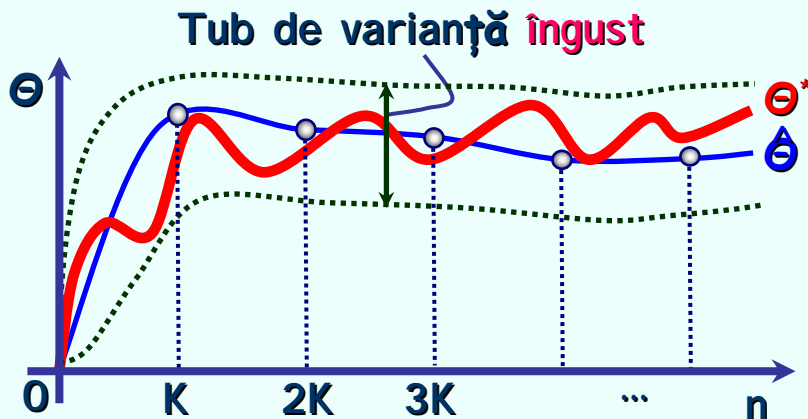
În schimb, **precizia modelului crește**, deoarece parametrii săi sunt determinați cu ajutorul unui set mai bogat de date.

# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare


⊗ 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.

$K = 1$

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

# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare

### Metodele abordate în acest curs

Metoda Celor Mai Mici Pătrate  
Recursivă (MCMMP-R)

MCMMP-R cu fereastră  
exponențială (MCMMP-R $\lambda$ )

MCMMP-R cu fereastră  
dreptunghiulară (MCMMP-R $\square$ )

MCMMP-R bazată pe descompunerea QR  
(MCMMPQR-R)

Metoda Variabilelor Instrumentale  
Recursivă (MVI-R)

MVI-R cu fereastră exponențială  
(MVI-R $\lambda$ )

MVI-R cu fereastră  
dreptunghiulară (MVI-R $\square$ )

### Alte metode adaptive (de precizie și complexitate ridicate)

Metode de Gradient  
Recursive (M $\nabla$ -R)

MCMMPE Recursivă  
(MCMMPE-R)

MMEP Recursivă  
(MMEP-R)

MRPL Recursivă  
(MRPL-R)

Metoda Kalman-Bucy  
(MKB)

♣ Va fi descrisă în  
finalul cursului de IS.

Strategia  
generală

Expresia generală a corecției pentru metoda recursivă (on-line) va fi dedusă plecând de la expresia finală a estimației din metoda nerecursivă (off-line).

# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare

De ce corecția aplicată vectorului curent al parametrilor estimați este aditivă?



Acest rezultat remarcabil se datorează în realitate IE, care permite aproximarea mediei statistice cu o medie temporală exprimată prin intermediul unei sume.



$$\hat{\theta}_k = \hat{\theta}_{k-1} + \Delta_k$$

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

### De asemenea

Eficiența crescută a algoritmilor adaptivi de identificare se datorează unui rezultat din **Teoria Matricilor**.

### Lema 1 (Inversarea matricilor modificate aditiv de un produs exterior)

Fie  $A \in \mathbb{R}^{n \times n}$  o matrice inversabilă și  $b \in \mathbb{R}^n$ ,  $c \in \mathbb{R}^n$  doi vectori cu dimensiunile egale (compatibili dimensional cu matricea  $A$ ), avînd proprietatea:  $c^T A^{-1} b \neq -1$ . Atunci matricea  $A + bc^T$  este inversabilă, inversa acesteia avînd exprimarea:

$$(A + bc^T)^{-1} = A^{-1} - \frac{A^{-1}bc^T A^{-1}}{1 + c^T A^{-1}b}$$

### Demonstrație

Exercițiu

(prin verificare directă)

Caz particular

$$b = c$$

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

Dacă inversa unei matrici este deja evaluată, prin adăugarea unui produs exterior la matricea originală, rezultă o nouă matrice a cărei inversă poate fi evaluată **fără a efectua inversarea explicită a acesteia** (se efectuează **doar inversarea unui scalar**).

# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare

### MCMMP-R – varianta de bază

#### MCMMP nerecursivă (off-line)

☞ Pentru orice model de regresie liniară.

$$\hat{\theta}_k = \left( \sum_{n=1}^k \varphi[n] \varphi^T[n] \right)^{-1} \left( \sum_{n=1}^k \varphi[n] y[n] \right) \quad \forall k \in \mathbb{N}^*$$

$$P(\hat{\theta}_N) = \lambda^2 \left( \sum_{n=1}^N \varphi[n] \varphi^T[n] \right)^{-1}$$

matricea de auto-covarianță a erorii de estimare

$P_k$  ← Notăție sugerată de **Teorema fundamentală a MCMMP**.

- Inversele matricilor  $P_k$  verifică o relație recurentă evidentă:

$$P_k^{-1} \stackrel{\text{def}}{=} \sum_{n=1}^k \varphi[n] \varphi^T[n] = \sum_{n=1}^{k-1} \varphi[n] \varphi^T[n] + \varphi[k] \varphi^T[k] = P_{k-1}^{-1} + \varphi[k] \varphi^T[k], \quad \forall k \in \mathbb{N}^*.$$

$$P_{k-1}^{-1}$$

$$P_0 \in \mathbb{R}^{n\theta \times n\theta}$$

→ Matrice inițială care trebuie să verifice proprietățile tuturor matricilor succesive: **inversabilitate, simetrie, pozitiv (semi-definire)**.

- Folosind același artificiu, estimația off-line se poate de asemenea exprima recursiv:

$$\begin{aligned} \hat{\theta}_k &= P_k \left( \sum_{n=1}^k \varphi[n] y[n] \right) = P_k \left( \underbrace{\sum_{n=1}^{k-1} \varphi[n] y[n]}_{P_{k-1}^{-1} \hat{\theta}_{k-1}} + \varphi[k] y[k] \right) = P_k \left( P_{k-1}^{-1} \hat{\theta}_{k-1} + \varphi[k] y[k] \right) \\ &= P_k \left[ \left( P_k^{-1} - \varphi[k] \varphi^T[k] \right) \hat{\theta}_{k-1} + \varphi[k] y[k] \right] = \hat{\theta}_{k-1} + P_k \varphi[k] \left( y[k] - \varphi^T[k] \hat{\theta}_{k-1} \right), \quad \forall k \in \mathbb{N}^*. \end{aligned}$$

$$\theta_0 \in \mathbb{R}^{n\theta}$$

inițializare prestabilită



# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare

### MCMMP-R – varianta de bază (continuare)

**Așadar**  $\hat{\theta}_k = \hat{\theta}_{k-1} + \mathbf{P}_k \varphi[k] \left( y[k] - \varphi^T[k] \hat{\theta}_{k-1} \right)$  **O primă relație recursivă.**

$\Delta_k$

**Corecție**

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

⊗ Ineficientă, deoarece la fiecare pas trebuie inversată o matrice.

- Corecția este formată din 2 factori:

$\varepsilon[k] \stackrel{\text{def}}{=} y[k] - \varphi^T[k] \hat{\theta}_{k-1}$  → Eroarea de predicție cu un pas.

$\gamma_k \stackrel{\text{def}}{=} \mathbf{P}_k \varphi[k]$  → Cîștig (de sensibilitate), cu rolul de a pondera eroarea de predicție pentru fiecare componentă a vectorului parametrilor estimați.

$$\hat{\theta}_k = \hat{\theta}_{k-1} + \gamma_k \varepsilon[k]$$

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

⚡ Nu toți parametrii sunt la fel de sensibili la reactualizare.

Cum poate fi mărită eficiența metodei?

Metoda ar fi mult mai eficientă dacă inversarea matricilor s-ar putea efectua **tot de o manieră recursivă.**

**Lema 1**

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

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

Efortul de calcul efectuat inițial pentru inversare este **conservat** de-a lungul procesului recursiv, adaptarea inverselor necesitînd **numai împărțirea la un scalar.**

# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare



### MCMMP-R – varianta de bază (continuare)



Mai mult, eficiența metodei poate crește și printr-o **organizare judicioasă a memoriei**.

- Folosind lema de inversare matricială se poate evalua și **cîștigul de sensibilitate**:

$$\begin{aligned} \overset{\text{def}}{\gamma_k} = \mathbf{P}_k \boldsymbol{\varphi}[k] &= \mathbf{P}_{k-1} \boldsymbol{\varphi}[k] - \frac{\mathbf{P}_{k-1} \boldsymbol{\varphi}[k] \boldsymbol{\varphi}^T[k] \mathbf{P}_{k-1} \boldsymbol{\varphi}[k]}{1 + \boldsymbol{\varphi}^T[k] \mathbf{P}_{k-1} \boldsymbol{\varphi}[k]} \quad \underline{\underline{\text{se aduce la același numitor}}} \\ \text{Lema 1} & \\ &= \frac{\mathbf{P}_{k-1} \boldsymbol{\varphi}[k] + \cancel{\mathbf{P}_{k-1} \boldsymbol{\varphi}[k] \boldsymbol{\varphi}^T[k] \mathbf{P}_{k-1} \boldsymbol{\varphi}[k]} - \cancel{\mathbf{P}_{k-1} \boldsymbol{\varphi}[k] \boldsymbol{\varphi}^T[k] \mathbf{P}_{k-1} \boldsymbol{\varphi}[k]}}{1 + \boldsymbol{\varphi}^T[k] \mathbf{P}_{k-1} \boldsymbol{\varphi}[k]} = \frac{\mathbf{P}_{k-1} \boldsymbol{\varphi}[k]}{1 + \boldsymbol{\varphi}^T[k] \mathbf{P}_{k-1} \boldsymbol{\varphi}[k]}, \quad \forall k \in \mathbb{N}^*. \end{aligned}$$

### Sumarul relațiilor MCMMP-R (on line)

Eroarea de predicție	$\varepsilon[k] = y[k] - \boldsymbol{\varphi}^T[k] \hat{\boldsymbol{\theta}}_{k-1}$
Cîștigul de sensibilitate	$\gamma_k = \frac{\mathbf{P}_{k-1} \boldsymbol{\varphi}[k]}{1 + \boldsymbol{\varphi}^T[k] \mathbf{P}_{k-1} \boldsymbol{\varphi}[k]}$
Matricea de auto-covarianță a erorii de estimare	$\mathbf{P}_k = \mathbf{P}_{k-1} - \gamma_k \boldsymbol{\varphi}^T[k] \mathbf{P}_{k-1}$
Vectorul parametrilor estimați	$\hat{\boldsymbol{\theta}}_k = \hat{\boldsymbol{\theta}}_{k-1} + \gamma_k \varepsilon[k]$

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

**Inițializare?**

➔ Informații preliminare **absente**:

$$\boldsymbol{\theta}_0 \in \mathbb{R}^{n\theta} \quad \mathbf{P}_0 = \alpha \mathbf{I}_{n\theta} > 0$$

arbitrar (eventual nul)

➔ Informații preliminare **disponibile** sub forma unui **set redus de date**:

$$\hat{\boldsymbol{\theta}}_0 = \left( \sum_{n=1}^{N_0} \boldsymbol{\varphi}[n] \boldsymbol{\varphi}^T[n] \right)^{-1} \left( \sum_{n=1}^{N_0} \boldsymbol{\varphi}[n] y[n] \right)$$

# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare

### Algoritmul adaptiv al Celor Mai Mici Pătrate

**Date de intrare**  $\left\{ \begin{array}{l} \mathcal{D}_{N_0} = \{\varphi[n]\}_{n \in \overline{1, N_0}} \cup \{y[n]\}_{n \in \overline{1, N_0}} \text{ (un set redus de date măsurate, dacă este posibil)} \\ n\theta \text{ (indicele structural al modelului de identificare)} \end{array} \right.$

**Inițializare**  $\left\{ \begin{array}{l} \mathbf{P}_0 \in \mathbb{R}^{n\theta \times n\theta} \quad \boldsymbol{\theta}_0 \in \mathbb{R}^{n\theta} \rightarrow \text{neutră sau personalizată, după caz} \\ k = 0 \rightarrow \text{indicele iterativ inițial} \end{array} \right.$

#### Bucă iterativă

↳ Pentru  $k \geq 1$

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

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

③ Se evaluează câștigul de senzitivitate:  $\gamma_k = \frac{\boldsymbol{\xi}_k}{1 + \boldsymbol{\varphi}^T[k] \boldsymbol{\xi}_k}$

④ Se reactualizează matricea de auto-covarianță a erorii de estimare:  $\mathbf{P}_k = \mathbf{P}_{k-1} - \gamma_k \boldsymbol{\xi}_k^T$

⑤ Se reactualizează vectorul parametrilor estimați:  $\hat{\boldsymbol{\theta}}_k = \hat{\boldsymbol{\theta}}_{k-1} + \gamma_k \varepsilon[k]$

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

**Date de ieșire**

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

Parametrii modelului reactualizați la fiecare pas de adaptare.



# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare

### MCMMP-R – varianta de bază (continuare)

Cum poate fi caracterizată precizia estimăției adaptive?



Tot prin intermediul **conceptului de consistență**, dar adaptat la anumite procese cu parametri variabili.

**Ipoteză**

$$\theta_{\infty}^* \stackrel{\text{def}}{=} \lim_{n \rightarrow \infty} \left[ E \left\{ \varphi[n] \varphi^T[n] \right\} \right]^{-1} \left[ E \left\{ \varphi[n] y[n] \right\} \right]$$

Parametrii adevărați se stabilizează la valori constante.

- Se va arăta că parametrii estimați folosind **MCMMP-R** tind, la rîndul lor, la valorile constante, **indiferent de inițializarea utilizată**.
- Se pleacă de la următoarea identitate evidentă:
- Apoi, se deduc relații recurente pentru fiecare din cei **2 factori**.

$$\hat{\theta}_k = \hat{\theta}_k \iff \hat{\theta}_k = (k\mathbf{P}_k) \left( \frac{1}{k} \mathbf{P}_k^{-1} \hat{\theta}_k \right) \quad \forall k \in \mathbb{N}^*$$

$$k\mathbf{P}_k = \left( \frac{1}{k} \mathbf{P}_k^{-1} \right)^{-1} = \left[ \frac{1}{k} \left( \mathbf{P}_{k-1}^{-1} + \varphi[k] \varphi^T[k] \right) \right]^{-1} = \dots = \left[ \frac{1}{k} \left( \mathbf{P}_0^{-1} + \sum_{n=1}^k \varphi[n] \varphi^T[n] \right) \right]^{-1}, \quad \forall k \in \mathbb{N}^*.$$

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

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

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

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

$$= \dots = \frac{1}{k} \left( \mathbf{P}_0^{-1} \hat{\theta}_0 + \sum_{n=1}^k \varphi[n] y[n] \right), \quad \forall k \in \mathbb{N}^*.$$

# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare

### MCMMP-R – varianta de bază (continuare)

Așadar

$$\hat{\theta}_k = \left[ \frac{1}{k} \left( \mathbf{P}_0^{-1} + \sum_{n=1}^k \varphi[n] \varphi^T[n] \right) \right]^{-1} \left[ \frac{1}{k} \left( \mathbf{P}_0^{-1} \hat{\theta}_0 + \sum_{n=1}^k \varphi[n] y[n] \right) \right]$$

☞ Contribuția inițializării se atenuază după o lege hiperbolică.

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

Algoritmul recursiv de bază **funcționează și în cazul unei inițializări necorespunzătoare** (de exemplu, dacă matricea  $\mathbf{P}_0$  nu este pozitiv definită), **dar viteza de convergență scade.**

Rezultă

$$\begin{aligned} \lim_{k \rightarrow \infty} \hat{\theta}_k &= \left\{ \lim_{k \rightarrow \infty} \left[ \frac{1}{k} \left( \mathbf{P}_0^{-1} + \sum_{n=1}^k \varphi[n] \varphi^T[n] \right) \right]^{-1} \right\} \left\{ \lim_{k \rightarrow \infty} \frac{1}{k} \left( \mathbf{P}_0^{-1} \hat{\theta}_0 + \sum_{n=1}^k \varphi[n] y[n] \right) \right\} = \\ &= \underbrace{\lim_{k \rightarrow \infty} \frac{\mathbf{P}_0^{-1}}{k}}_0 + \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{n=1}^k \varphi[n] \varphi^T[n] \left[ \underbrace{\lim_{k \rightarrow \infty} \frac{\mathbf{P}_0^{-1} \hat{\theta}_0}{k}}_0 + \lim_{k \rightarrow \infty} \frac{1}{k} \sum_{n=1}^k \varphi[n] y[n] \right] \stackrel{\text{IE}}{=} \\ &= \lim_{n \rightarrow \infty} \left[ E \{ \varphi[n] \varphi^T[n] \} \right]^{-1} \left[ E \{ \varphi[n] y[n] \} \right] = \theta_\infty^* . \end{aligned}$$

☞ În general, însă, sunt dificil de cuantificat atât precizia, cât și mai ales adaptabilitatea (capacitatea de urmărire a) estimației parametrilor necunoscuți.

Exercițiu

- Să se refacă raționamentele anterioare pentru a proiecta și analiza **Algoritmul recursiv al Variabilelor Instrumentale.**

# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare


### MCMMP-R – variante cu fereastră

- Există situații (în special în cazul proceselor rapid variabile) în care contribuția datelor anterioare momentului curent de reactualizare **trebuie atenuată cu rapiditate controlată**.
- Istoria comportamentului procesului poate distorsiona rezultatul operației de adaptare curentă **dacă** datele achiziționate **devin rapid învechite** și **tind să nu mai corespundă comportamentului actual al procesului**.

Cum poate fi controlată atenuarea istoriei datelor?



Prin intermediul **ferestrelor culisante** fie de-a lungul setului de date, fie de-a lungul erorilor de predicție.



$w_N$  → Fereastră cu deschiderea determinată de dimensiunea orizontului de măsură.  
**w**indow

De regulă, nenegativă.

- În acest curs, va fi abordată problema estimării recursive a parametrilor prin **minimizarea** unui **criteriu pătratic** în care **pătratul erorii de predicție curente este ponderat de o fereastră culisantă nenegativă**.

- Selecția datelor are loc prin înmulțirea valorilor ferestrei (**ponderilor**) cu valorile omoloage ale datelor.

În cazul modelelor de regresie liniară, datele sunt ponderate de **radicalul ferestrei**.

$$\mathcal{V}(\theta) = \sum_{n=1}^N w_N[n] \varepsilon^2[n, \theta]$$

# 4 Metode de identificare și validare

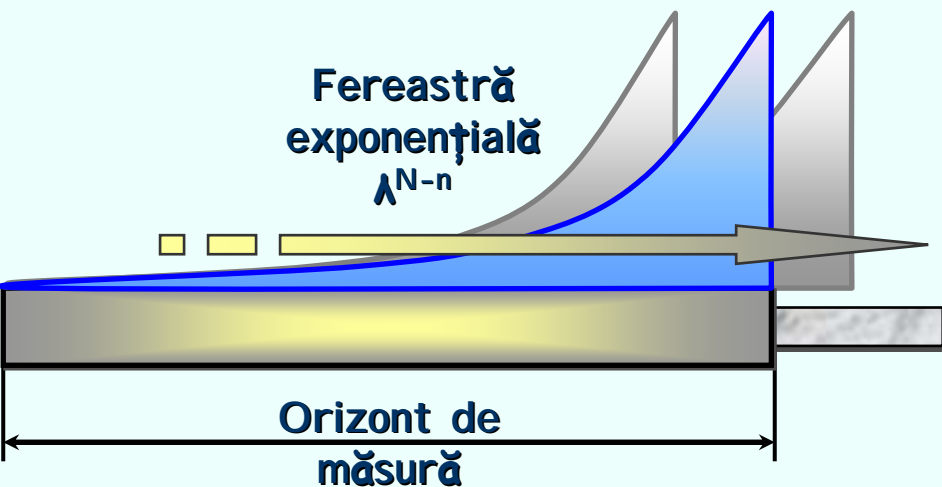
## 4.9 Metode adaptive de identificare

### MCMMP-R – variante cu fereastră (continuare)

- Deponderarea **prea drastică** a datelor implică **deteriorarea sensibilă** a preciziei modelului de identificare, astfel că **fereastra trebuie aleasă cu atenție**.
- Aplicarea ferestrelor de ponderare asupra datelor este o **operație frecvent întâlnită** în aplicațiile de PS.
- Spre deosebire de ferestrele din aplicațiile de PS (care, de regulă, sunt **simetrice pe orizontul de măsură**), ferestrele utilizate în aplicațiile de IS pot fi **asimetrice**.

### Ferestre de culisare frecvent utilizate în aplicațiile de IS

#### Exponențială




$$w_N[n] = \lambda^{N-n} \quad \forall k \in \mathbb{N}$$

Factor de uitare

De regulă

$$\lambda \in [0.95, 1]$$

#### Dreptunghiulară



$$w_{M,N}[n] = \begin{cases} 1 & , n \in \overline{N-M+1, N} \\ 0 & , n \in \overline{1, N-M} \quad \forall k \in \mathbb{N} \end{cases}$$

# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare

### MCMMP-R – variante cu fereastră (continuare)

Exerciții

MCMMP-R $\lambda$

MVI-R $\lambda$

(deducerea relațiilor recursive, algoritmul eficient, inițializare, consistență)

### MCMMP-R cu fereastră dreptunghiulară (MCMMP-R $\square$ )

- Dacă apare **problema înlăturării complete a datelor învechite**, mai utilă este **fereastra dreptunghiulară**, care permite aplicarea unui **factor de uitare totală** asupra datelor situate în afara deschiderii sale.



$$w_{M,N}[n] = \begin{cases} 1 & , n \in \overline{N-M+1, N} \\ 0 & , n \in \overline{1, N-M} \end{cases} \quad \forall k \in \mathbb{N}$$

$$\mathcal{V}(\theta) = \sum_{n=1}^N w_N[n] \varepsilon^2[n, \theta] = \sum_{n=N-M+1}^N \varepsilon^2[n, \theta]$$

MCMMP  
off-line

- Pentru a deduce expresia corecției, se adoptă aceeași strategie ca în cazul MCMMP-R.

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

- Relația recurentă a inverselor matricilor  $\mathbf{P}_k$ :

$\mathbf{P}_k$  ← Simetrică și strict pozitiv definită.

$$\mathbf{P}_k^{-1} = \sum_{n=k-M+1}^k \varphi[n] \varphi^T[n] = \sum_{n=k-M}^{k-1} \varphi[n] \varphi^T[n] - \varphi[k-M] \varphi^T[k-M] + \varphi[k] \varphi^T[k] =$$

$\mathbf{P}_{k-1}^{-1}$

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



# 4 Metode de identificare și validare

## 4.9 Metode adaptive de identificare

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

- Urmează deducerea expresiei corecției:

$$\begin{aligned} \hat{\theta}_k &= \mathbf{P}_k \left( \sum_{n=k-M+1}^k \varphi[n]y[n] \right) = \mathbf{P}_k \left( \underbrace{\sum_{n=k-M}^{k-1} \varphi[n]y[n]}_{\mathbf{P}_{k-1}^{-1} \hat{\theta}_{k-1}} - \varphi[k-M]y[k-M] + \varphi[k]y[k] \right) = \\ &= \mathbf{P}_k \left( \mathbf{P}_{k-1}^{-1} \hat{\theta}_{k-1} - \varphi[k-M]y[k-M] + \varphi[k]y[k] \right) \stackrel{\mathbf{P}_{k-1}^{-1} = \mathbf{P}_k^{-1} + \varphi[k-M]\varphi^T[k-M] - \varphi[k]\varphi^T[k]}{=} \\ &= \mathbf{P}_k \left[ \left( \mathbf{P}_k^{-1} + \varphi[k-M]\varphi^T[k-M] - \varphi[k]\varphi^T[k] \right) \hat{\theta}_{k-1} - \varphi[k-M]y[k-M] + \varphi[k]y[k] \right] = \\ &= \hat{\theta}_{k-1} - \mathbf{P}_k \varphi[k-M] \left( y[k-M] - \varphi^T[k-M] \hat{\theta}_{k-1} \right) + \mathbf{P}_k \varphi[k] \left( y[k] - \varphi^T[k] \hat{\theta}_{k-1} \right), \quad \forall k \geq M+1. \end{aligned}$$

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

☞ Corecția este formată din 2 termeni.

$\Delta_{b,k}$

Corecție  
a priori

Corecție  
a posteriori

$\Delta_{f,k}$

- Pentru a putea determina corecțiile, trebuie evaluate:

$$\varepsilon_b[k-M] \stackrel{\text{def}}{=} y[k-M] - \varphi^T[k-M] \hat{\theta}_{k-1}$$

→ Eroarea de predicție a priori  
(prognoză în trecut).

$$\varepsilon_f[k] \stackrel{\text{def}}{=} y[k] - \varphi^T[k] \hat{\theta}_{k-1}$$

→ Eroarea de predicție a posteriori  
(prognoză în viitor).

☞ Folosind numai datele delimitate de fereastra dreptunghiulară.