

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

 Efortul de calcul al **MCMMP** cu modelul **AR este susținut**, deoarece aît numărul datelor măsurate cît și numărul de parametri au valori mari (pentru a asigura o precizie suficientă).



Obiectiv

Reducerea efortului de calcul prin metode alternative de identificare.

Metoda Yule-Walker-Wiener

Algoritmul Levinson-Durbin

Algoritmul Levinson-Durbin (ALD)



Ideeua lui N. Levinson
(1947)

Estimarea parametrilor necunoscuți și a dispersiei zgomotului alb se poate realiza apelînd la **un algoritm recursiv**, pe baza proprietăților remarcabile ale matricilor de tip **Toeplitz simetrice**.

- Se pleacă tot de la **sistemul Yule-Walker-Wiener**, în care se folosesc următoarele **notații** (pentru a pune în evidență **indicele de recurență – ordinul modelului AR**):

$\{\hat{a}_{N,p,i}\}_{i \in \overline{1,n}}$ → Parametrii estimati din N date măsurate, pentru modelul **AR[p]**.

$p \in \overline{1,na}$

$\hat{\theta}_{N,p}$ → Vectorul parametrilor estimati din N date măsurate, pentru modelul **AR[p]**.

$\hat{\lambda}_{N,p}^2$ → Dispersia estimată a zgomotului alb din N date măsurate, pentru modelul **AR[p]**.

Pentru a rezolva sistemul Yule-Walker-Wiener de ordin na , se vor **reactualiza succesiv soluțiile sistemelor Yule-Walker-Wiener de ordine inferioare**, plecînd de la sistemul de ordin 1.

Matricile de tip Toeplitz simetrice joacă rolul principal în acest scenariu.

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Algoritmul Levinson-Durbin (continuare)

Propoziția 5 (proprietatea de invarianță la răsturnare a matricilor simetrice de tip Toeplitz)

Fie $A \in \mathbb{R}^{n \times n}$ o matrice simetrică de tip Toeplitz asociată operatorului liniar $\mathcal{A} : \mathbb{R}^n \rightarrow \mathbb{R}^n$.

Se notează prin $\mathcal{R} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ izomorfismul spațiului \mathbb{R}^n care realizează inversarea totală a ordinii elementelor oricărui vector din \mathbb{R}^n :

$$\mathcal{R}(\mathbf{x}) \stackrel{\text{def}}{=} \mathbf{x}^R = [x_n \ x_{n-1} \ \cdots \ x_1]^T, \quad \forall \mathbf{x} = [x_1 \ x_2 \ \cdots \ x_n]^T \in \mathbb{R}^n.$$

Atunci operatorii \mathcal{A} și \mathcal{R} comută. Mai precis:

$$\mathcal{A} \circ \mathcal{R} \equiv \mathcal{R} \circ \mathcal{A} \quad \Leftrightarrow \quad (\mathbf{Ax})^R = \mathbf{Ax}^R.$$

operația de răsturnare a vectorilor

Demonstrație

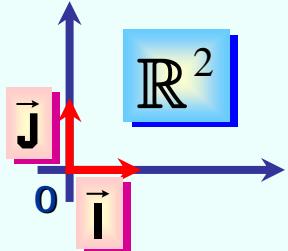
Exercițiu

Matricea caracteristică a operatorului de răsturnare

$$\mathbf{J} \stackrel{\text{def}}{=} \begin{bmatrix} 0 & \cdots & 0 & 1 \\ 0 & \cdots & 1 & 0 \\ \vdots & \ddots & \vdots & \vdots \\ 1 & \cdots & 0 & 0 \end{bmatrix} \in \mathbb{R}^{n \times n}$$

diagonala secundară

⇒ Analogie de notație cu cea din geometria plană.



Propoziția 5

$$\mathbf{AJ} = \mathbf{JA}$$

Exercițiu

Matricea de răsturnare coincide cu propria sa inversă.

$$\mathbf{JAJ} = \mathbf{A}$$

⇒ Aceeași proprietate ca a matricii unitare.

⇒ Diagonalele celor două matrici sunt geometric perpendicular.

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Algoritmul Levinson-Durbin (continuare)



Sistemul Yule-Walker-Wiener

$$a_1^* r_y[1] + \dots + a_{na}^* r_y[na] - \lambda^2 = -r_y[0]$$

$$\begin{bmatrix} r_y[0] & r_y[1] & \cdots & r_y[na-1] \\ r_y[1] & r_y[0] & \cdots & r_y[na-2] \\ \vdots & \vdots & \ddots & \vdots \\ r_y[na-1] & r_y[na-2] & \cdots & r_y[0] \end{bmatrix} \begin{bmatrix} a_1^* \\ a_2^* \\ \vdots \\ a_{na}^* \end{bmatrix} = -\begin{bmatrix} r_y[1] \\ r_y[2] \\ \vdots \\ r_y[na] \end{bmatrix}$$

exprimare matricială compactă



Proprietate remarcabilă de imbricare

$$\begin{bmatrix} r_y^N[0] & r_y^N[1] & \cdots & r_y^N[p] \\ r_y^N[1] & r_y^N[0] & \cdots & r_y^N[p-1] \\ \vdots & \vdots & \ddots & \vdots \\ r_y^N[p] & r_y^N[p-1] & \cdots & r_y^N[0] \end{bmatrix} \begin{bmatrix} 1 \\ \hat{a}_{N,p,1} \\ \vdots \\ \hat{a}_{N,p,p} \end{bmatrix} = \begin{bmatrix} \hat{\lambda}_{N,p}^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad \forall p \in \overline{1, na}$$

$\mathbf{R}_{N,p+1}$

$$\mathbf{R}_{N,p+1}$$

$$\hat{\theta}_{N,p}$$

vectorul parametrilor extins cu valoarea unită

$$\begin{bmatrix} r_y^N[0] & \cdots & r_y^N[p-1] \\ \vdots & \mathbf{R}_{N,p} & \vdots \\ r_y^N[p-1] & \cdots & r_y^N[0] \end{bmatrix} \begin{bmatrix} r_y^N[p] \\ r_y^N[1] \\ \vdots \\ r_y^N[0] \end{bmatrix} = \begin{bmatrix} 1 \\ \hat{a}_{N,p,1} \\ \vdots \\ \hat{a}_{N,p,p} \end{bmatrix} = \begin{bmatrix} \hat{\lambda}_{N,p}^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad \forall p \in \overline{1, na}$$

$\mathbf{R}_{N,p+1}$

Se va deduce o relație recurrentă de forma:

$$\hat{\theta}_{N,p} = \begin{bmatrix} \hat{\theta}_{N,p-1} \\ 0 \end{bmatrix} - \frac{\alpha_{N,p-1}}{\hat{\lambda}_{N,p-1}^2} \begin{bmatrix} \hat{\theta}_{N,p-1}^R \\ 1 \end{bmatrix} \quad \forall p \in \overline{2, na}$$

coeficient de adaptare

ce trebuie determinat



Această proprietate, împreună cu **Propoziția 5**, va permite exprimarea soluției curente în funcție de soluția precedentă.

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Algoritmul Levinson-Durbin (continuare)

$$\left[\begin{array}{ccc|c} r_y^N[0] & \cdots & r_y^N[p-1] & r_y^N[p] \\ \vdots & \ddots & \vdots & \vdots \\ r_y^N[p-1] & \cdots & r_y^N[0] & r_y^N[1] \\ \hline r_y^N[p] & \cdots & r_y^N[1] & r_y^N[0] \end{array} \right] \left[\begin{array}{c} \hat{a}_{N,p,1} \\ \vdots \\ \hat{a}_{N,p,p} \end{array} \right] = \left[\begin{array}{c} 1 \\ \vdots \\ 0 \\ \vdots \\ 0 \end{array} \right] \quad \forall p \in 1, na$$

$$\left[\begin{array}{ccc|c} r_y^N[0] & \cdots & r_y^N[p-1] & r_y^N[p] \\ \vdots & \ddots & \vdots & \vdots \\ r_y^N[p-1] & \cdots & r_y^N[0] & r_y^N[1] \\ \hline r_y^N[p] & \cdots & r_y^N[1] & r_y^N[0] \end{array} \right] \left[\begin{array}{c} \hat{a}_{N,p-1,1} \\ \vdots \\ \hat{\theta}_{N,p-1} \\ \vdots \\ \hat{a}_{N,p-1,p-1} \\ 0 \end{array} \right] = \left[\begin{array}{c} 1 \\ \vdots \\ 0 \\ \vdots \\ 0 \\ 0 \end{array} \right] \quad \forall p \in 2, na$$

Noul sistem moștenește **matricea sistemului curent**, dar operează cu **soluția sistemului precedent**.

¶ Noul sistem nu este echivalent cu sistemele curent sau precedent.

vectorul anterior al parametrilor, extins cu valoarea nulă

¶ Prin răsturnarea celor 2 vectori, matricea sistemului rămîne neschimbată.

Propoziția 5

$$\left[\begin{array}{ccc|c} r_y^N[0] & \cdots & r_y^N[p-1] & r_y^N[p] \\ \vdots & \ddots & \vdots & \vdots \\ r_y^N[p-1] & \cdots & r_y^N[0] & r_y^N[1] \\ \hline r_y^N[p] & \cdots & r_y^N[1] & r_y^N[0] \end{array} \right] \left[\begin{array}{c} \hat{a}_{N,p-1,p-1} \\ \vdots \\ \hat{\theta}_{N,p-1} \\ \vdots \\ \hat{a}_{N,p-1,1} \\ 1 \end{array} \right] = \left[\begin{array}{c} 0 \\ \vdots \\ 0 \\ \vdots \\ 0 \\ 1 \end{array} \right] \quad \forall p \in 2, na$$

Factor de corecție necesar pentru ca sistemul să fie compatibil.

$$\alpha_{N,p-1} \stackrel{\text{def}}{=} r_y^N[p] + \hat{a}_{N,p-1,1} r_y^N[p-1] + \cdots + \hat{a}_{N,p-1,p-1} r_y^N[1]$$

- Dacă $p=na+1$, această ecuație aproximează următoarea ecuație extrasă din sistemul Yule-Walker-Wiener:

$$r_y[p] + a_1^* r_y[p-1] + \cdots + a_{p-1}^* r_y[1] = 0$$

Factorul de corecție are amplitudini din ce în ce mai mici.

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Algoritmul Levinson-Durbin (continuare)

Așadar

Dispunem de două sisteme echivalente.

$$\left[\begin{array}{ccc|c} r_y^N[0] & \cdots & r_y^N[p-1] & r_y^N[p] \\ \vdots & & \vdots & \vdots \\ r_y^N[p-1] & \cdots & r_y^N[0] & r_y^N[1] \\ \hline r_y^N[p] & \cdots & r_y^N[1] & r_y^N[0] \end{array} \right] \left[\begin{array}{c} 1 \\ \hat{a}_{N,p-1,1} \\ \vdots \\ \hat{a}_{N,p-1,p-1} \\ 0 \end{array} \right] = \left[\begin{array}{c} \hat{\lambda}_{N,p-1}^2 \\ 0 \\ \vdots \\ 0 \\ \alpha_{N,p-1} \end{array} \right] \quad \forall p \in \overline{2,na}$$

$$\left[\begin{array}{ccc|c} r_y^N[0] & \cdots & r_y^N[p-1] & r_y^N[p] \\ \vdots & & \vdots & \vdots \\ r_y^N[p-1] & \cdots & r_y^N[0] & r_y^N[1] \\ \hline r_y^N[p] & \cdots & r_y^N[1] & r_y^N[0] \end{array} \right] \left[\begin{array}{c} 0 \\ \hat{a}_{N,p-1,p-1} \\ \vdots \\ \hat{a}_{N,p-1,1} \\ 1 \end{array} \right] = \left[\begin{array}{c} \alpha_{N,p-1} \\ 0 \\ \vdots \\ 0 \\ \hat{\lambda}_{N,p-1}^2 \end{array} \right] \quad \forall p \in \overline{2,na}$$



Factorul de corecție din primul sistem
poate fi anulat folosind al doilea sistem.

$$\left[\begin{array}{ccc|c} r_y^N[0] & \cdots & r_y^N[p-1] & r_y^N[p] \\ \vdots & & \vdots & \vdots \\ r_y^N[p-1] & \cdots & r_y^N[0] & r_y^N[1] \\ \hline r_y^N[p] & \cdots & r_y^N[1] & r_y^N[0] \end{array} \right] \left[\begin{array}{c} 1 \\ \hat{a}_{N,p-1,1} \\ \vdots \\ \hat{a}_{N,p-1,p-1} \\ 0 \end{array} \right] = \left[\begin{array}{c} \hat{\lambda}_{N,p-1}^2 \\ 0 \\ \vdots \\ 0 \\ \alpha_{N,p-1} \end{array} \right] \quad \forall p \in \overline{2,na}$$

$$-\frac{\alpha_{N,p-1}}{\hat{\lambda}_{N,p-1}^2}$$

$$\left[\begin{array}{ccc|c} r_y^N[0] & \cdots & r_y^N[p-1] & r_y^N[p] \\ \vdots & & \vdots & \vdots \\ r_y^N[p-1] & \cdots & r_y^N[0] & r_y^N[1] \\ \hline r_y^N[p] & \cdots & r_y^N[1] & r_y^N[0] \end{array} \right] \left[\begin{array}{c} 0 \\ \hat{a}_{N,p-1,p-1} \\ \vdots \\ \hat{a}_{N,p-1,1} \\ 1 \end{array} \right] = \left[\begin{array}{c} \alpha_{N,p-1} \\ 0 \\ \vdots \\ 0 \\ \hat{\lambda}_{N,p-1}^2 \end{array} \right] \quad \forall p \in \overline{2,na}$$

$$\left[\begin{array}{ccc|c} r_y^N[0] & \cdots & r_y^N[p-1] & r_y^N[p] \\ \vdots & \ddots & \vdots & \vdots \\ r_y^N[p-1] & \cdots & r_y^N[0] & r_y^N[1] \\ \hline r_y^N[p] & \cdots & r_y^N[1] & r_y^N[0] \end{array} \right] \left[\begin{array}{c} 1 \\ \hat{a}_{N,p-1,1} - \frac{\alpha_{N,p-1}}{\hat{\lambda}_{N,p-1}^2} \hat{a}_{N,p-1,p-1} \\ \vdots \\ \hat{a}_{N,p-1,p-1} - \frac{\alpha_{N,p-1}}{\hat{\lambda}_{N,p-1}^2} \hat{a}_{N,p-1,1} \\ -\frac{\alpha_{N,p-1}}{\hat{\lambda}_{N,p-1}^2} \end{array} \right] = \left[\begin{array}{c} \hat{\lambda}_{N,p-1}^2 - \frac{\alpha_{N,p-1}^2}{\hat{\lambda}_{N,p-1}^2} \\ 0 \\ \vdots \\ 0 \end{array} \right]$$

Matricea sistemului este
aceeași în ambele ecuații.

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Algoritmul Levinson-Durbin (continuare)

Rezultă

Soluția recurrentă a sistemului Yule-Walker-Wiener

$$\alpha_{N,p-1} = r_y^N[p] + \hat{a}_{N,p-1,1} r_y^N[p-1] + \cdots + \hat{a}_{N,p-1,p-1} r_y^N[1]$$

$$\begin{bmatrix} \hat{a}_{N,p,1} \\ \vdots \\ \hat{a}_{N,p,p-1} \\ \hat{a}_{N,p,p} \end{bmatrix} = \begin{bmatrix} \hat{a}_{N,p-1,1} - \frac{\alpha_{N,p-1}}{\hat{\lambda}_{N,p-1}^2} \hat{a}_{N,p-1,p-1} \\ \vdots \\ \hat{a}_{N,p-1,p-1} - \frac{\alpha_{N,p-1}}{\hat{\lambda}_{N,p-1}^2} \hat{a}_{N,p-1,1} \\ -\frac{\alpha_{N,p-1}}{\hat{\lambda}_{N,p-1}^2} \end{bmatrix}$$

$$\hat{\theta}_{N,p} = \begin{bmatrix} \hat{\theta}_{N,p-1} \\ 0 \end{bmatrix} - \frac{\alpha_{N,p-1}}{\hat{\lambda}_{N,p-1}^2} \begin{bmatrix} \hat{\theta}_{N,p-1}^R \\ 1 \end{bmatrix}$$

$\forall p \in \overline{2,na}$

Este dispersia corect estimată?



$$\hat{\lambda}_{N,p}^2 = \hat{\lambda}_{N,p-1}^2 - \frac{\alpha_{N,p-1}^2}{\hat{\lambda}_{N,p-1}^2}$$

Mai mult

$$0 \leq \hat{\lambda}_{N,p}^2 = \hat{\lambda}_{N,p-1}^2 \left[1 - \frac{\alpha_{N,p-1}^2}{\hat{\lambda}_{N,p-1}^4} \right] \leq \hat{\lambda}_{N,p-1}^2$$

$\forall p \in \overline{2,na}$

Propoziția 6 (corectitudinea soluției recurente)

În contextul definit de ecuațiile recurente ale lui Levinson, cantitatea:

$$\beta_{N,p} \stackrel{\text{def}}{=} \hat{\lambda}_{N,p-1}^2 - \frac{\alpha_{N,p-1}^2}{\hat{\lambda}_{N,p-1}^2}$$

este nenegativă.

¶ Cu cât modelul devine mai complex, cu atât el devine mai precis.

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Algoritmul Levinson-Durbin (ALD)



Date de intrare

$\mathcal{D}_N = \{y[n]\}_{n \in \overline{1, N}}$ (setul de date măsurate la ieșirea procesului auto-regresiv)
 na (ordinul modelului auto-regresiv)



Inițializare

① Se evaluatează valorile secvenței de auto-covarianță a datelor:

$$r_y^N[0], r_y^N[1], \dots, r_y^N[na]$$

$$\begin{aligned} \hat{a}_{1,1} &= -\frac{r_y^N[1]}{r_y^N[0]} \stackrel{\text{def}}{=} \hat{\theta}_1 \\ \hat{\lambda}_1^2 &= r_y^N[0] \left(1 - \hat{a}_{1,1}^2\right) \end{aligned}$$

Modelul este stabil.



Bucă iterativă

② Pentru $p \in \overline{2, na}$

① Se evaluatează cîștigul:

$$k_p = -\frac{1}{\hat{\lambda}_{p-1}^2} \left(r_y^N[p] + \hat{a}_{p-1,1} r_y^N[p-1] + \dots + \hat{a}_{p-1,p-1} r_y^N[1] \right)$$

Propoziția 6

$$|k_p| \leq 1$$

② Se reactualizează vectorul curent al parametrilor:

$$\hat{\theta}_p = \begin{bmatrix} \hat{\theta}_{p-1} \\ 0 \end{bmatrix} + k_p \begin{bmatrix} \hat{\theta}_{p-1}^R \\ 1 \end{bmatrix}$$

③ Se reactualizează dispersia zgromotului alb:

$$\hat{\lambda}_p^2 = \hat{\lambda}_{p-1}^2 \left[1 - k_p^2 \right]$$

↓ Coeficienții de reflexie
din cadrul Algoritmului Schür-Cohn.



Date de ieșire

$\hat{\theta}_{na}$ → Parametrii estimati ai modelului AR[na].
 $\hat{\lambda}_{na}^2$ → Dispersia estimată a zgromotului alb.

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Algoritmul Levinson-Durbin (continuare)

Performanțele ALD

◎ Algoritmul este **extrem de eficient**, deoarece se evită inversarea explicită a matricii sistemului.

Exercițiu

- Să se proiecteze un algoritm de inversare a matricilor simetrice de tip Toeplitz, folosind **ALD**.

Efortul de calcul

Calculul auto-covarianțelor

$$\begin{array}{c} \text{Înmulțiri} \\ \left[\frac{(na+1)(2N-na+2)}{2} \right]_x \end{array}$$

Adunări

$$\left[\frac{(na+1)(2N-na)}{2} \right]_+$$

Estimația inițială

$$[3]_x$$

$$[1]_+$$

Procesul iterativ

$$[(na-1)(na+4)]_x$$

$$\left[\frac{na(na-1)(3na-1)}{2} \right]_+$$

Total

$$O_{ALD} \sim \left[\frac{(na+1)(na+2N+10)}{2} \right]_x + \left[\frac{(na+1)(na+2N-2)}{2} \right]_+$$

Exemplul 1

$N = 1000$ $na = 30$ (off-line)

$$O_{MCMMMP} \sim [495625]_x + O_{MYWW} \sim [70515]_x + O_{ALD} \sim [31590]_x + \\ + [493795]_+ + [69120]_+$$

Exemplul 2

$N = 10$ $na = 10$ (on-line)

$$O_{MCMMMP} \sim [1625]_x + O_{MYWW} \sim [1605]_x + O_{ALD} \sim [210]_x + \\ + [1415]_+ + [1440]_+$$

◊ Efortul de calcul a scăzut sensibil, în special în cazul identificării adaptive, cînd ordinul modelului este comparabil cu dimensiunea orizontului de măsură.

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Aplicații

Predicția optimală a proceselor auto-regresive

Estimarea spectrală prin modelare auto-regresivă

Predicția optimală



Obiectiv

Estimarea valorilor ieșirii unui proces stocastic dincolo de orizontul de măsură, cu ajutorul unui model de identificare.

- Notății specifice:

$P \in \mathbb{N}^*$ → Margine de predicție: număr ales plecînd de la anumite caracteristici ale procesului stocastic.

$\overline{N+1, N+P}$ → Orizont de predicție (dincolo de orizontul de măsură).

\mathcal{M}_p → Predictor: model matematic determinat în scopul predicției cu deplasamentul p . $p \in \overline{1, P}$

Modelul de identificare determinat folosind datele măsurate poate fi de asemenea un predictor.

Convenție

$y_p[N+p | \mathcal{D}_N]$ → Valoarea predictată cu deplasamentul p (la momentul $N+p$), folosind datele achiziționate pe orizontul de măsură.

$$\mathcal{M}(\theta) = \mathcal{M}_0 \quad \text{def}$$

↓ Predictori eventual diferiți pentru deplasamente diferite.

$y_0[N+p | \mathcal{D}_N]$ → Valoarea predictată cu deplasamentul p (la momentul $N+p$), folosind modelul de identificare.

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Aplicații: predicția optimală (continuare)

Eroare de predicție cu p pași

⇒ În cazul general, pentru fiecare pas de predicție se va utiliza un predictor proiectat special.

$$\varepsilon[p] \stackrel{\text{def}}{=} y[N+p] - y_p[N+p | \mathcal{D}_N] \quad \forall p \in \overline{1, P}$$

ieșirea măsurată ieșirea predictată (prognozată)

Caz particular

$$\mathcal{M}(\theta) \stackrel{\text{def}}{=} \mathcal{M}_0$$

$$\varepsilon_0[p] \stackrel{\text{def}}{=} y[N+p] - y_0[N+p | \mathcal{D}_N] \quad \forall p \in \overline{1, P}$$



Erorile de predicție pot fi evaluate cu ajutorul unui singur predictor: cel dat de modelul de identificare.

Problema predicției optimale

Se cere determinarea unui set de predictori $\{\hat{\mathcal{M}}_p\}_{p \in \overline{1, P}}$ cu ieșirile $\{\hat{y}_p\}_{p \in \overline{1, P}}$, care să fie optimali în sensul minimizării dispersiei erorii de predicție:

$$E\left\{\left(y[N+p] - \hat{y}_p[N+p | \mathcal{D}_N]\right)^2\right\} \leq E\left\{\left(y[N+p] - y_p[N+p | \mathcal{D}_N]\right)^2\right\}, \quad \forall p \in \overline{1, P}$$

(față de alți predictori $\{\mathcal{M}_p\}_{p \in \overline{1, P}}$ cu ieșirile $\{y_p\}_{p \in \overline{1, P}}$);

$$E\left\{\left(y[N+p] - \hat{y}_p[N+p | \mathcal{D}_N]\right)^2\right\} \leq E\left\{\left(y[N+p] - y_0[N+p | \mathcal{D}_N]\right)^2\right\}, \quad \forall p \in \overline{1, P}$$

(față de predictorul de identificare).

Eroare optimală de predicție cu p pași

$$\hat{\varepsilon}[p] \stackrel{\text{def}}{=} y[N+p] - \hat{y}_p[N+p | \mathcal{D}_N] \quad \forall p \in \overline{1, P}$$

4 Metode de identificare și validare

4.8 Identificarea și predicția proceselor autoregresive

Aplicații: predicția optimală (continuare)

Cum poate fi rezolvată problema predicției optimale?



În forma originală, problemei nu i se poate construi o soluție, deoarece
nu se dispune de setul de date măsurate pe orizontul de predicție.

Problema trebuie **relaxată**, astfel încât să se poată construi o **soluție sub-optimală**.

- Folosind **inegalitatea triunghiului**, se poate obține o **condiție de sub-optimalitate** din condiția de optimalitate.

$$\begin{aligned} E\left\{\left(y[N+p] - \hat{y}_p[N+p | \mathcal{D}_N]\right)^2\right\} &= \text{se adună și se scade ieșirea predictată cu modelul de identificare} \\ &= E\left\{\left(y[N+p] - y_0[N+p | \mathcal{D}_N] + y_0[N+p | \mathcal{D}_N] - \hat{y}_p[N+p | \mathcal{D}_N]\right)^2\right\} \leq \text{inegalitatea triunghiului} \\ &\leq E\left\{\left(y[N+p] - y_0[N+p | \mathcal{D}_N]\right)^2\right\} + E\left\{\left(y_0[N+p | \mathcal{D}_N] - \hat{y}_p[N+p | \mathcal{D}_N]\right)^2\right\} \quad \forall p \in \overline{1, P} \end{aligned}$$

- În loc să fie minimizată dispersia erorii de predicție, va fi **minimizat termenul din dreapta inegalității**, exprimat ca o **sumă de două dispersii**.

Problema predicției sub-optimale

$$\min E\left\{\left(y[N+p] - y_0[N+p | \mathcal{D}_N]\right)^2\right\} + \min E\left\{\left(y_0[N+p | \mathcal{D}_N] - \hat{y}_p[N+p | \mathcal{D}_N]\right)^2\right\} \quad \forall p \in \overline{1, P}$$