

Identificarea sistemelor

Ingineria sistemelor, anul 3
Universitatea Tehnică din Cluj-Napoca

Lucian Buşoniu



Partea V

Metoda ARX

Clasificare

Reamintim taxonomia modelelor din Partea I:

După numărul de parametri:

- 1 **Modele parametrice**: au formă fixă (formulă matematică), număr cunoscut și de obicei mic de parametri
- 2 Modele neparametrice: nu pot fi descrise cu un număr fix, mic de parametri
Adesea reprezentate prin grafice sau tabele

După cunoștințele disponibile în avans (“culoare”):

- 1 Modele din principii de bază, cutie albă: complet cunoscute în avans
- 2 **Modele cutie neagră**: complet necunoscute în avans
- 3 Modele cutie gri: parțial cunoscute

Metoda ARX produce modele *parametrice*, de tip polinomial.

De ce ARX?

- Metodă pentru orice ordin, implementabilă programatic, cu garanții – ca și analiza de corelație
- Spre deosebire de analiza de corelație, furnizează un model *compact*, numărul de parametri fiind proporțional cu ordinul sistemului

Conținut

- 1 Modelul ARX
- 2 Identificarea ARX
- 3 Exemplu Matlab
- 4 Garanție de performanță
- 5 ARX neliniar

Vom rămâne în cazul cu intrări și ieșiri scalare, cu excepția anexei opționale. ARX neliniar este pentru proiect, nu va fi necesar pentru laboratoare.

Conținut

- 1 Modelul ARX
- 2 Identificarea ARX
- 3 Exemplu Matlab
- 4 Garanție de performanță
- 5 ARX neliniar

Reamintim: Timp discret

Rămânem în cazul de timp discret:



Structura modelului ARX

În structura **ARX**, ieșirea $y(k)$ la pasul curent este calculată din intrările și ieșirile la pași precedenți:

$$\begin{aligned}y(k) + a_1 y(k-1) + a_2 y(k-2) + \dots + a_{na} y(k-na) \\ = b_1 u(k-1) + b_2 u(k-2) + \dots + b_{nb} u(k-nb) + e(k)\end{aligned}$$

echivalent cu

$$\begin{aligned}y(k) = -a_1 y(k-1) - a_2 y(k-2) - \dots - a_{na} y(k-na) \\ b_1 u(k-1) + b_2 u(k-2) + \dots + b_{nb} u(k-nb) + e(k)\end{aligned}$$


$e(k)$ este zgomotul la pasul k .

Parametrii modelului: a_1, a_2, \dots, a_{na} și b_1, b_2, \dots, b_{nb} .

Nume: Model **AutoRegresiv** ($y(k)$ depinde de valorile y precedente)
cu intrare eXogenă (dependență de u)

Forma grafică

$$y(k) = -a_1y(k-1) - a_2y(k-2) - \dots - a_nay(k-na) + b_1u(k-1) + b_2u(k-2) + \dots + b_nbu(k-nb) + e(k)$$



unde **operatorul de deplasare** q^{-1} întârzie cu un pas orice semnal $z(k)$ în timp discret:

$$q^{-1}z(k) = z(k-1)$$

Forma polinomială

Folosind q^{-1} , avem:

$$\begin{aligned}y(k) + a_1y(k-1) + a_2y(k-2) + \dots + a_nay(k-na) \\ = (1 + a_1q^{-1} + a_2q^{-2} + \dots + a_naq^{-na})y(k) =: A(q^{-1})y(k)\end{aligned}$$

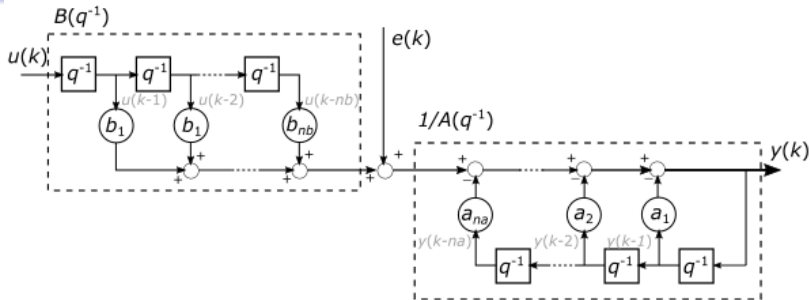
și:

$$\begin{aligned}b_1u(k-1) + b_2u(k-2) + \dots + b_nbu(k-nb) \\ = (b_1q^{-1} + b_2q^{-2} + \dots + b_nbq^{-nb})u(k) =: B(q^{-1})u(k)\end{aligned}$$


Ca urmare, modelul ARX se poate scrie compact:

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

Forma grafică compactă



Zoom out:



legat și de faptul că:

$$y(k) = \frac{1}{A(q^{-1})} [B(q^{-1})u(k) + e(k)]$$

Observații

- 1 Modelul ARX este general, poate descrie orice relație liniară între intrări și ieșiri. Zgomotul participă însă în model într-o manieră restrictivă, și mai târziu vom descrie modele care generalizează acest element.
- 2 Fără zgomot, am avea o funcție standard de transfer în timp discret.

Model în forma de regresie liniară

Revenind la reprezentarea explicită recursivă:

$$\begin{aligned}y(k) &= -a_1y(k-1) - a_2y(k-2) - \dots - a_nay(k-na) \\ &\quad b_1u(k-1) + b_2u(k-2) + \dots + b_nbu(k-nb) + e(k) \\ &= [-y(k-1), \dots, -y(k-na), u(k-1), \dots, u(k-nb)] \\ &\quad \cdot [a_1, \dots, a_na, b_1, \dots, b_nb]^\top + e(k) \\ &=: \varphi^\top(k)\theta + e(k)\end{aligned}$$

ARX se supune așadar formei standard de model din regresia liniară!

Vector de regresori și parametri

Vector de regresori: $\varphi(k) \in \mathbb{R}^{na+nb}$, ieșirile și intrările precedente.

Vector de parametri: $\theta \in \mathbb{R}^{na+nb}$, coeficienții polinoamelor.

$$\varphi(k) = \begin{bmatrix} -y(k-1) \\ \vdots \\ -y(k-na) \\ u(k-1) \\ \vdots \\ u(k-nb) \end{bmatrix} \quad \theta = \begin{bmatrix} a_1 \\ \vdots \\ a_{na} \\ b_1 \\ \vdots \\ b_{nb} \end{bmatrix}$$

Conținut

- 1 Modelul ARX
- 2 Identificarea ARX**
- 3 Exemplu Matlab
- 4 Garanție de performanță
- 5 ARX neliniar

Problema de identificare

Considerăm un set de date $u(k), y(k), k = 0, \dots, N$, din care trebuie aflați parametrii θ ai modelului.

Pentru $k = 1, \dots, N$:

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

unde $\varepsilon(k)$ este interpretat acum ca o eroare în ecuație (de unde și notația schimbată).

Obiectiv: minimizarea erorii medii pătratice:

$$V(\theta) = \frac{1}{N} \sum_{k=1}^N \varepsilon(k)^2$$

Observație: Când $k \leq na, nb$, valori ale u și y la momente de timp negative sunt necesare pentru construirea φ . Aceste valori pot fi luate 0 (presupunând condiții inițiale nule).

Sistem liniar de ecuații

$$y(1) = [-y(0) \quad \cdots \quad -y(1-na) \quad u(0) \quad \cdots \quad u(1-nb)] \theta$$

$$y(2) = [-y(1) \quad \cdots \quad -y(2-na) \quad u(1) \quad \cdots \quad u(2-nb)] \theta$$

...

$$y(N) = [-y(N-1) \quad \cdots \quad -y(N-na) \quad u(N-1) \quad \cdots \quad u(N-nb)] \theta$$

Forma matriceală:

$$\begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(N) \end{bmatrix} = \begin{bmatrix} -y(0) & \cdots & -y(1-na) & u(0) & \cdots & u(1-nb) \\ -y(1) & \cdots & -y(2-na) & u(1) & \cdots & u(2-nb) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ -y(N-1) & \cdots & -y(N-na) & u(N-1) & \cdots & u(N-nb) \end{bmatrix} \cdot \theta$$

$$Y = \Phi \theta$$

cu notațiile $Y \in \mathbb{R}^N$ și $\Phi \in \mathbb{R}^{N \times (na+nb)}$.

Soluția ARX

Din regresia liniară, parametrii care minimizează $\frac{1}{2} \sum_{k=1}^N \varepsilon(k)^2$ sunt:

$$\hat{\theta} = (\Phi^T \Phi)^{-1} \Phi^T Y$$

Cum noua funcție obiectiv $V(\theta) = \frac{1}{N} \sum_{k=1}^N \varepsilon(k)^2$ este proporțională cu criteriul de mai sus, aceeași soluție minimizează și $V(\theta)$.

Soluția pentru seturi mari de date

În cazul în care numărul N de date este foarte mare, forma de mai sus este impractică pentru identificare. O formă mai bună este cea alternativă menționată în partea de regresie liniară:

$$\Phi^T \Phi = \sum_{k=1}^N \varphi(k) \varphi^T(k), \quad \Phi^T Y = \sum_{k=1}^N \varphi(k) y(k)$$
$$\Rightarrow \hat{\theta} = \left[\sum_{k=1}^N \varphi(k) \varphi^T(k) \right]^{-1} \left[\sum_{k=1}^N \varphi(k) y(k) \right]$$

Soluția pentru seturi mari de date (continuare)

O problemă rămasă: suma celor N termeni poate fi mare, ducând la probleme numerice: (matrice de numere foarte mari) $^{-1}$ · vector de numere foarte mari.

Soluție: Normalizarea valorilor prin împărțirea fiecărui element cu N . În ecuații, N se simplifică deci nu are nici un efect asupra dezvoltării analitice, dar în practică această împărțire menține numerele la valori rezonabile.

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

Cum rămâne cu împărțirea sumei la N ? Se poate efectua recursiv, fără a implica niciodată numere mari - detalii mai târziu.

Utilizarea modelului

Predicție cu un pas înainte \hat{y} : Secvența de ieșiri reale este cunoscută, deci toate valorile precedente sunt disponibile și pot fi înlocuite în formulă, pe lângă coeficienții extrași din θ :

$$\hat{y}(k) = -a_1y(k-1) - a_2y(k-2) - \dots - a_nay(k-na) \\ + b_1u(k-1) + b_2u(k-2) + \dots + b_nbu(k-nb)$$

Semnalele la momente negative de timp pot fi luate 0.

Exemplu: În ziua $k-1$, predicția meteo pentru ziua k .

Simulare $\tilde{y}(k)$: Ieșirile reale $y(k-i)$ sunt necunoscute și trebuie să fie înlocuite cu ieșirile simulate $\tilde{y}(k-i)$ la iterații anterioare:

$$\tilde{y}(k) = -a_1\tilde{y}(k-1) - a_2\tilde{y}(k-2) - \dots - a_n\tilde{y}(k-na) \\ + b_1u(k-1) + b_2u(k-2) + \dots + b_nbu(k-nb)$$

(ieșirile simulate la pași negativi și zero pot fi și ele luate 0.)

Exemplu: Simularea răspunsului unui avion la comenzi ale pilotului într-o situație de urgență, care ar fi periculoasă pentru sistemul real.

Notă despre utilizarea modelelor

Mai multe tipuri de modele se pot utiliza în **predicție** sau **simulare**, nu doar ARX.


FIR este un caz particular de ARX

Alegând $A = 1$ ($na = 0$) în ARX, obținem:

$$y(k) = B(q^{-1})u(k) + e(k) = \sum_{j=1}^{nb} b_j u(k-j) + e(k)$$
$$= \sum_{j=0}^{M-1} h(j)u(k-j) + e(k)$$

modelul FIR din analiza de corelație!

Mai detaliat, luăm $nb = M - 1$ și $b_j = h(j)$. De notat că $h(0)$, răspunsul la impuls la momentul 0, se presupune egal cu 0 – adică sistemul nu răspunde instantaneu la schimbări ale intrării.



Diferența fundamentală între ARX și FIR

$$\text{ARX: } A(q^{-1})y(k) = B(q^{-1})u(k) + e(k)$$

$$\text{FIR: } y(k) = B(q^{-1})u(k) + e(k)$$

Cum ARX include o relație recursivă între ieșirea curentă și cele precedente, este suficient să luăm ordinele na și nb egale cu ordinul sistemului dinamic.

Modelul FIR are nevoie de un ordin nb (lungime M) suficient de mare pentru a modela întregul regim tranzitoriu al răspunsului la impuls (în mod ideal recuperăm modelul corect doar dacă $M \rightarrow \infty$).

⇒ mai mulți parametri ⇒ mai multe date necesare pentru identificare.





Conținut

- 1 Modelul ARX
- 2 Identificarea ARX
- 3 Exemplu Matlab**
- 4 Garanție de performanță
- 5 ARX neliniar

Date experimentale

Se dau două seturi de date, unul pentru identificare, celălalt pentru validare.

```
plot(id); și plot(val);
```



Observații: Intrarea de identificare: *semnal pseudo-aleator binar*.
Intrarea de validare: o secvență de semnale treaptă.

Identificarea unui model ARX

```
model = arx(id, [na, nb, nk]);
```

Argumente funcție:

- 1 Datele de identificare.
- 2 Vector conținând ordinele A și B , și întârzierea nk .

Structura diferită de cea teoretică: include o întârziere minimă nk între intrări și ieșiri, utilă pentru a modela sistemele cu timp mort.

$$y(k) + a_1y(k-1) + a_2y(k-2) + \dots + a_nay(k-na) \\ = b_1u(k-nk) + b_2u(k-nk-1) + \dots + b_nbu(k-nk-nb+1) + e(k)$$

$$A(q^{-1})y(k) = B(q^{-1})u(k-nk) + e(k), \text{ unde:}$$

$$A(q^{-1}) = (1 + a_1q^{-1} + a_2q^{-2} + \dots + a_naq^{-na})$$

$$B(q^{-1}) = (b_1 + b_2q^{-1} + b_nbq^{-nb+1})$$


Structura teoretică se obține luând $nk = 1$. Pentru $nk > 1$, noua structură se poate transforma în cea teoretică alegând un polinom B de ordinul $nk + nb - 1$, cu primii $nk - 1$ coeficienți nuli:

$$B_{\text{theor}}(q^{-1}) = 0q^{-1} + \dots + 0q^{-nk+1} + b_1q^{-nk} + \dots + b_nbq^{-nk-nb+1}$$

Validarea modelului

Presupunând că sistemul este de ordinul 2, în forma ARX, și fără întârzieri, alegem $na = 2$, $nb = 2$, $nk = 1$. Validare:

```
compare(model, val);
```



Rezultatele nu sunt bune.

Selecția structurii

Alternativă: încercăm mai multe structuri diferite și o alegem pe cea mai bună.

```
Na = 1:15;  
Nb = 1:15;  
Nk = 1:5;  
NN = struc(Na, Nb, Nk);  
V = arxstruc(id, val, NN);
```

- `struc` generează toate combinațiile de ordine în `Na`, `Nb`, `Nk`.
- `arxstruc` identifică pentru fiecare combinație un model ARX (pe datele din primul argument), îl simulează (pe datele din al doilea argument), și returnează toate valorile MSE pe prima linie din `V` (vezi `help arxstruc` pentru formatul variabilei `V`).


Selecția structurii (continuare)

Pentru a alege structura cu valoarea MSE minimă:

```
N = selstruc(V, 0);
```

Pentru datele noastre, $N = [8, 7, 1]$.


Alternativ, selecție grafică: `N = selstruc(V, 'plot');` Click pe bara corespunzătoare modelului optim (roșu), apoi "Select", "Close".



(Mai târziu vom discuta selecția între modele alternative cu alte criterii decât MSE.)

Validarea celui mai bun model ARX

```
model = arx(id, N); compare(model, val);
```



Rezultatele sunt mai bune. Sistemele de ordinul 8 sunt însă destul de rare în practică, probabil se întâmplă ceva mai complicat... vom relua ideea în cursurile următoare.

Conținut

- 1 Modelul ARX
- 2 Identificarea ARX
- 3 Exemplu Matlab
- 4 Garanție de performanță**
- 5 ARX neliniar

Rezultat

Ipoteze

- 1 Există un vector corect de parametri θ_0 pentru care:

$$y(k) = \varphi^\top(k)\theta_0 + v(k)$$

unde $v(k)$ este un proces stohastic staționar independent de $u(k)$.

- 2 $E \{ \varphi(k)\varphi^\top(k) \}$ este o matrice inversabilă.
- 3 $E \{ \varphi(k)v(k) \} = 0$.

Teoremă

Identificarea ARX este **consistentă**: parametrii estimați $\hat{\theta}$ converg la cei corecți θ_0 , la limită când numărul de date crește la infinit $N \rightarrow \infty$.

Discuție ipoteze

- 1 Ipoteza 1 este echivalentă cu existența unor polinoame corecte $A_0(q^{-1})$, $B_0(q^{-1})$ pentru care:

$$A_0(q^{-1})y(k) = B_0(q^{-1})u(k) + v(k)$$

Pentru a motiva Ipoteza 2, reamintim

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

Când $N \rightarrow \infty$, $\frac{1}{N} \sum_{k=1}^N \varphi(k)\varphi^T(k) \rightarrow E \{ \varphi(k)\varphi^T(k) \}$.

- 2 $E \{ \varphi(k)\varphi^T(k) \}$ este inversabilă dacă datele sunt “suficient de informative” (de ex. $u(k)$ nu trebuie să fie un feedback simplu de la $y(k)$; vezi Söderström & Stoica pentru discuții adiționale).
- 3 $E \{ \varphi(k)v(k) \} = 0$ de ex. dacă $v(k)$ este zgomot alb. Mai târziu, vom rediscuta Ipoteza 3 și rolul condiției $E \{ \varphi(k)v(k) \} = 0$.

Rezumat

- Structura de model ARX și reprezentarea cu polinoame în q^{-1}
 - Forma de regresie liniară cu regresori φ și parametri θ
 - Soluția problemei de regresie liniară. Rescriere pentru seturi mari de date
 - Utilizarea modelului pentru predicție și simulare
 - Relația cu FIR
-
- Exemplu Matlab.
 - Garanție de acuratețe simplificată.

Conținut

- 1 Modelul ARX
- 2 Identificarea ARX
- 3 Exemplu Matlab
- 4 Garanție de performanță
- 5 ARX neliniar**

Structura ARX neliniară

Reamintim ARX standard:

$$y(k) = -a_1 y(k-1) - a_2 y(k-2) - \dots - a_{na} y(k-na) \\ b_1 u(k-1) + b_2 u(k-2) + \dots + b_{nb} u(k-nb) + e(k)$$

Dependență liniară de ieșirile precedente $y(k-1), \dots, y(k-na)$ și intrările precedente $u(k-1), \dots, u(k-nb)$.

ARX neliniar (NARX) generalizează la orice dependență neliniară:

$$y(k) = g(y(k-1), y(k-2), \dots, y(k-na), \\ u(k-1), u(k-2), \dots, u(k-nb); \theta) + e(k)$$

Funcția g este parametrizată de $\theta \in \mathbb{R}^n$, și acești parametri pot fi aleși pentru a recupera datele de identificare, identificând astfel un sistem dinamic neliniar.

NARX polinomial

În cazul nostru particular, g este un **polinom de gradul m în ieșirile și intrările precedente**:

$$\begin{aligned}y(k) &= p(y(k-1), \dots, y(k-na), u(k-1), \dots, u(k-nb)) + e(k) \\ &=: p(d(k)) + e(k)\end{aligned}$$

unde $d(k) = [y(k-1), \dots, y(k-na), u(k-1), \dots, u(k-nb)]^T$ este vectorul de semnale precedente.

De ex., pentru ordinele $na = nb = 1$ (de unde $d(k) = [y(k-1), u(k-1)]^T$) și gradul $m = 1$, modelul este:

$$y(k) = ay(k-1) + bu(k-1) + c + e(k)$$

și dacă impunem în plus $c = 0$, recuperăm modelul ARX liniar

NARX polinomial (continuare)

Pentru aceleași $na = nb = 1$ și gradul $m = 2$:

$$y(k) = ay(k-1) + bu(k-1) + cy(k-1)^2 \\ + du(k-1)^2 + wu(k-1)y(k-1) + z + e(k)$$

Observații:

- A nu se confunda cu forma polinomială liniară
 $A(q^{-1})y(k) = B(q^{-1})u(k) + e(k)$
- Parametrii sunt acum coeficienții tuturor polinoamelor, de ex.
 $\theta = [a, b, c, d, w, z]^T$
- Regresia liniară funcționează ca de obicei, găsind parametrii care minimizează valoarea MSE-ului!
- y și u la momente zero și negative pot fi luate 0, presupunând că sistemul este în condiții inițiale nule

Reamintim predicție versus simulare

Predicție cu un pas înainte \hat{y} : ieșirea reală a sistemului este cunoscută, deci vectorul de semnale întârziate $d(k)$ este disponibil:

$$d(k) = [y(k-1), \dots, y(k-na), u(k-1), \dots, u(k-nb)]^T$$

$$\hat{y}(k) = g(d(k); \hat{\theta})$$

Simulare \tilde{y} : ieșirea reală este necunoscută, folosim ieșirile simulate anterior pentru a construi o *aproximare* $\tilde{d}(k)$ a lui $d(k)$:

$$\tilde{d}(k) = [\tilde{y}(k-1), \dots, \tilde{y}(k-na), u(k-1), \dots, u(k-nb)]^T$$

$$\tilde{y}(k) = g(\tilde{d}(k); \hat{\theta})$$

Anexă: Intrări și ieșiri multiple

Sistem MIMO

Până acum am considerat $y(k) \in \mathbb{R}$, $u(k) \in \mathbb{R}$,
sisteme *Single-Input, Single-Output (SISO)*

Multe sisteme sunt *Multiple-Input, Multiple-Output (MIMO)*.
De ex., avion. Intrări: putere motoare, eleron, elevator, cârmă.
Ieșiri: viteză, deviații unghiulare în jurul celor trei axe.



ARX MIMO

Mai departe considerăm $y(k)$, $e(k) \in \mathbb{R}^{ny}$, $u(k) \in \mathbb{R}^{nu}$.

Model ARX MIMO:

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

$$A(q^{-1}) = I + A_1q^{-1} + \dots + A_{na}q^{-na}$$

$$B(q^{-1}) = B_1q^{-1} + \dots + B_{nb}q^{-nb}$$

unde I este matricea identitate $ny \times ny$, $A_1, \dots, A_{na} \in \mathbb{R}^{ny \times ny}$,
 $B_1, \dots, B_{nb} \in \mathbb{R}^{ny \times nu}$.

Exemplu concret

Luăm $na = 1$, $nb = 2$, $ny = 2$, $nu = 3$. Atunci:

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

$$A(q^{-1}) = I + A_1 q^{-1}$$

$$= I + \begin{bmatrix} a_1^{11} & a_1^{12} \\ a_1^{21} & a_1^{22} \end{bmatrix} q^{-1}$$

$$B(q^{-1}) = B_1 q^{-1} + B_2 q^{-2}$$

$$= \begin{bmatrix} b_1^{11} & b_1^{12} & b_1^{13} \\ b_1^{21} & b_1^{22} & b_1^{23} \end{bmatrix} q^{-1} + \begin{bmatrix} b_2^{11} & b_2^{12} & b_2^{13} \\ b_2^{21} & b_2^{22} & b_2^{23} \end{bmatrix} q^{-2}$$

Exemplu concret (continuare)


$$\begin{aligned} & \left(\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} + \begin{bmatrix} a_1^{11} & a_1^{12} \\ a_1^{21} & a_1^{22} \end{bmatrix} q^{-1} \right) \begin{bmatrix} y_1(k) \\ y_2(k) \end{bmatrix} \\ &= \left(\begin{bmatrix} b_1^{11} & b_1^{12} & b_1^{13} \\ b_1^{21} & b_1^{22} & b_1^{23} \end{bmatrix} q^{-1} + \begin{bmatrix} b_2^{11} & b_2^{12} & b_2^{13} \\ b_2^{21} & b_2^{22} & b_2^{23} \end{bmatrix} q^{-2} \right) \begin{bmatrix} u_1(k) \\ u_2(k) \\ u_3(k) \end{bmatrix} + \begin{bmatrix} e_1(k) \\ e_2(k) \end{bmatrix} \end{aligned}$$

Relație explicită:

$$\begin{aligned} y_1(k) &+ a_1^{11} y_1(k-1) + a_1^{12} y_2(k-1) \\ &= b_1^{11} u_1(k-1) + b_1^{12} u_2(k-1) + b_1^{13} u_3(k-1) \\ &+ b_2^{11} u_1(k-2) + b_2^{12} u_2(k-2) + b_2^{13} u_3(k-2) + e_1(k) \\ y_2(k) &+ a_1^{21} y_1(k-1) + a_1^{22} y_2(k-1) \\ &= b_1^{21} u_1(k-1) + b_1^{22} u_2(k-1) + b_1^{23} u_3(k-1) \\ &+ b_2^{21} u_1(k-2) + b_2^{22} u_2(k-2) + b_2^{23} u_3(k-2) + e_2(k) \end{aligned}$$

Exemplu Matlab

Considerăm un reactor de tip *continuous stirred-tank reactor*, CSTR:



Credit imagine: mathworks.com



Intrare: debit Q al agentului de răcire

Ieșiri:

- Concentrația C_A a substanței A în amestec
- Temperatura T a amestecului

Matlab: Date experimentale

Stânga: identificare, Dreapta: validare



Matlab: ARX MIMO, diferit de teorie

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

$$A(q^{-1}) = \begin{bmatrix} a^{11}(q^{-1}) & a^{12}(q^{-1}) & \dots & a^{1ny}(q^{-1}) \\ a^{21}(q^{-1}) & a^{22}(q^{-1}) & \dots & a^{2ny}(q^{-1}) \\ \vdots & \vdots & \ddots & \vdots \\ a^{ny1}(q^{-1}) & a^{ny2}(q^{-1}) & \dots & a^{nyny}(q^{-1}) \end{bmatrix}$$

$$a^{ij}(q^{-1}) = \begin{cases} 1 & \text{dacă } i = j \\ 0 & \text{altfel} \end{cases} + a_1^{ij}q^{-1} + \dots + a_{na_{ij}}^{ij}q^{-na_{ij}}$$

$$B = \begin{bmatrix} b^{11}(q^{-1}) & b^{12}(q^{-1}) & \dots & b^{1nu}(q^{-1}) \\ b^{21}(q^{-1}) & b^{22}(q^{-1}) & \dots & b^{2nu}(q^{-1}) \\ \vdots & \vdots & \ddots & \vdots \\ b^{ny1}(q^{-1}) & b^{ny2}(q^{-1}) & \dots & b^{nynu}(q^{-1}) \end{bmatrix}$$

$$b^{ij}(q^{-1}) = b_1^{ij}q^{-nk_{ij}} + \dots + b_{nb_{ij}}^{ij}q^{-nk_{ij} - nb_{ij} + 1}$$

Matlab: Identificarea modelului

```
m = arx(id, [Na, Nb, Nk]);
```

Argumente funcție:

- 1 Datele de identificare.
- 2 Matrici cu ordinele polinoamelor din A , B , și întârzieri nk :

$$Na = \begin{bmatrix} na_{11} & \dots & na_{1ny} \\ \dots & & \\ na_{ny1} & \dots & na_{nyny} \end{bmatrix}$$

$$Nb = \begin{bmatrix} nb_{11} & \dots & nb_{1nu} \\ \dots & & \\ nb_{ny1} & \dots & nb_{nynu} \end{bmatrix}$$

$$Nk = \begin{bmatrix} nk_{11} & \dots & nk_{1nu} \\ \dots & & \\ nk_{ny1} & \dots & nk_{nynu} \end{bmatrix}$$

Matlab: Rezultate

Luăm $na = 2$, $nb = 2$, și $nk = 1$ peste tot in elementele matricilor:

```
Na = [2 2; 2 2]; Nb = [2; 2]; Nk = [1; 1];
```

```
m = arx(id, [Na Nb Nk]);
```

```
compare(m, val);
```

