

Identificarea sistemelor

Ingineria sistemelor, anul 3
Universitatea Tehnică din Cluj-Napoca

Lucian Buşoniu



Partea VII

Metoda minimizării erorii de predicție

Conținut

- 1 Structuri de model
- 2 Metoda generală a minimizării erorii de predicție
- 3 Rezolvarea problemei de optimizare
- 4 Garanții de performanță

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

Ca și ARX, metoda generală a minimizării erorii de predicție (MEP) produce modele *cutie neagră*, *parametrice* (polinomiale).

Conținut

- 1 Structuri de model
- 2 Metoda generală a minimizării erorii de predicție
- 3 Rezolvarea problemei de optimizare
- 4 Garanții de performanță

Motivație

MEP poate fi văzută ca o extensie a metodei ARX la structuri de model mult mai generale, fiind așadar capabilă să identifice mult mai multe clase de sisteme.

Pentru claritate, vom prezenta întâi structura generală de model căreia i se aplică MEP.

Structura generală de model

$$y(k) = G(q^{-1})u(k) + H(q^{-1})e(k)$$

unde G și H sunt *funcții de transfer* în timp discret – fracții de polinoame. Semnalul $e(t)$ este zgomot alb de medie zero.

Prin gruparea factorilor comuni ai numitoarelor din G și H în $A(q^{-1})$, obținem forma mai detaliată:

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

unde A, B, C, D, F sunt toate polinoame, de ordin na, nb, nc, nd, nf :

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

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


$$F(q^{-1}) = 1 + f_1q^{-1} + \dots + f_{nf}q^{-nf}$$

$$C(q^{-1}) = 1 + c_1q^{-1} + \dots + c_{nc}q^{-nc}$$

$$D(q^{-1}) = 1 + d_1q^{-1} + \dots + d_{nd}q^{-nd}$$

Structura generală de model (continuare)

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

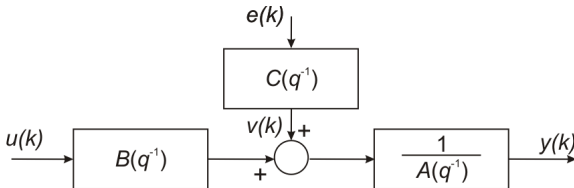


Această formă este foarte generală. Nu se va folosi în practică, ci pentru descrierea algoritmilor într-un mod generic care funcționează pentru orice formă particulară. În practică, vom folosi una dintre aceste forme particulare, exemplificate în cele ce urmează.

Structura ARMAX

Impunând $F = D = 1$ (adică ordinele $nf = nd = 0$), obținem:

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



Nume: **AutoRegresiv** (dependența de ieșirile anterioare), **cu Medie Alunecătoare** (se referă la modelul perturbației) **cu intrare eXogenă** (dependența de u)

ARMAX: formă explicită

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

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

$$B(q^{-1}) = b_1q^{-1} + \dots + b_n bq^{-nb}$$

$$C(q^{-1}) = 1 + c_1q^{-1} + \dots + c_n c q^{-nc}$$

$$\begin{aligned} y(k) + a_1y(k-1) + \dots + a_n ay(k-na) \\ = b_1u(k-1) + \dots + b_n bu(k-nb) \\ + e(k) + c_1e(k-1) + \dots + c_n ce(k-nc) \end{aligned}$$

cu vectorul de parametri:

$$\theta = [a_1, \dots, a_n a, b_1, \dots, b_n b, c_1, \dots, c_n c]^T \in \mathbb{R}^{na+nb+nc}$$

Exemplu recurent: ARMAX de ordinul 1

Alegem $na = nb = nc = 1$, obținând un model ARMAX de ordinul întâi:

$$(1 + aq^{-1})y(k) = bq^{-1}u(k) + (1 + cq^{-1})e(k)$$
$$y(k) = -ay(k-1) + bu(k-1) + ce(k-1) + e(k)$$

unde am omis indecșii pentru a, b, c fiindcă există un singur parametru în fiecare polinom.

Vom reveni la acest exemplu de-a lungul părții curente pentru a ilustra toate etapele MEP.

Caz special de ARMAX: ARX

Impunând $C = 1$ în ARMAX ($nc = 0$), obținem:

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

exact modelul ARX pe care l-am studiat deja.

În comparație cu ARX, ARMAX poate modela perturbații mai complicate $(C(q^{-1})e(k))$ în loc de $e(k)$, care de obicei se presupune că este zgomot alb de medie zero).

Reamintim: FIR este un caz particular al ARX

Impunând mai departe $A = 1$ ($na = 0$) în ARX, obținem:

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

modelul FIR.

Relația globală

Forma generală \supset ARMAX \supset ARX \supset FIR


- ARMAX la ARX: Mai puțină flexibilitate în modelarea perturbației.
- ARX la FIR: Mai mulți parametri.

Structura de tip eroare de ieșire

Alte forme de model sunt posibile, care nu sunt cazuri particulare ale ARMAX, de ex. **eroarea de ieșire, OE** (en. *Output Error*):

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

obținută pentru $na = nc = nd = 0$, adică $A = C = D = 1$.



Structura corespunde unui zgomot simplu, aditiv la ieșire (de unde reiese și numele).

Exercițiu: Care este forma explicită a modelului OE?

Conținut

- 1 Structuri de model
- 2 **Metoda generală a minimizării erorii de predicție**
 - Pas preliminar: ARX revizitat
 - Cazul general
 - Cazuri speciale: ARMAX ordinul 1, ARX
 - Exemplu Matlab
- 3 Rezolvarea problemei de optimizare
- 4 Garanții de performanță

ARX reinterpretat ca MEP

- 1 Dat fiind vectorul de parametri θ , calculăm predicțiile la fiecare pas, $\hat{y}(k) = \varphi^\top(k)\theta$.
- 2 Calculăm erorile de predicție la fiecare pas, $\varepsilon(k) = y(k) - \hat{y}(k)$.
- 3 Găsim vectorul de parametri θ care minimizează media erorilor pătratice $V(\theta) = \frac{1}{N} \sum_{k=1}^N \varepsilon^2(k)$.

Procedura de mai sus este doar o reinterpretare, echivalentă cu algoritmul deja studiat la cursul de ARX.

MEP se obține extinzând procedura la structura generală de model.

ARX reinterpretat ca MEP (continuare)

Observații:

- Pentru ARX, știm deja cum să minimizăm MSE (cu regresia liniară); pentru modele mai generale vom prezenta metode noi de minimizare.
- Predictorul ARX $\hat{y}(k)$ este ales pentru a obține eroarea $\varepsilon(k) = e(k)$, egală cu zgomotul. Acesta va fi și scopul MEP generale, intuitiv fiindcă nu putem spera la mai mult. De notat semnificațiile diferite ale $\varepsilon(k)$ (eroare de predicție) și $e(k)$ (zgomot)
- Eroarea de predicție este doar o rearanjare a ecuației $y(k) = \varphi^\top(k)\theta + \varepsilon(k) = \hat{y}(k) + \varepsilon(k)$.

Checklist

Pentru fiecare structură de model, va trebui să trecem prin acești trei pași: predictor, eroare de predicție, și minimizarea MSEului.

Vom menține o listă de verificare (pe scurt, checklist):

	ARX
predicție $\hat{y}(k)$	✓
eroare de predicție $\varepsilon(k)$	✓
minimizare $V(\theta)$	✓

Conținut

- 1 Structuri de model
- 2 **Metoda generală a minimizării erorii de predicție**
 - Pas preliminar: ARX revizitat
 - **Cazul general**
 - Cazuri speciale: ARMAX ordinul 1, ARX
 - Exemplu Matlab
- 3 Rezolvarea problemei de optimizare
- 4 Garanții de performanță

Reamintim: Structura generală de model

$$y(k) = G(q^{-1})u(k) + H(q^{-1})e(k)$$

unde G și H sunt funcții de transfer în timp discret:

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

În cele ce urmează, vom omite argumentul q^{-1} pentru a mări lizibilitatea ecuațiilor, și vom înțelege explicit că literele mari se referă la funcții de transfer sau polinoame în variabila q^{-1} .

Eroarea de predicție

Începem prin calculul zgomotului $e(k)$.

$$y(k) = Gu(k) + He(k)$$

$$\Rightarrow e(k) = H^{-1}(y(k) - Gu(k))$$

unde $H^{-1} = \frac{AD}{C}$ este inversa fracției de polinoame H .

Predictorul va fi derivat în așa fel încât eroarea de predicție să fie egală cu zgomotul, $\varepsilon(k) = y(k) - \hat{y}(k) = e(k)$. Așadar, aceeași formulă ca și mai sus se poate folosi pentru a calcula $\varepsilon(k)$:

$$\varepsilon(k) = H^{-1}(y(k) - Gu(k))$$

Acesta este un **sistem dinamic** care poate fi simulat pentru a obține semnalul $\varepsilon(k)$.

Predictor

Pentru a obține eroarea $e(k)$, dinamica predictorului trebuie să fie:

$$\begin{aligned}
 \hat{y}(k) &= y(k) - e(k) = Gu(k) + He(k) - e(k) = Gu(k) + (H - 1)e(k) \\
 &= Gu(k) + (H - 1)H^{-1}(y(k) - Gu(k)) \\
 &= Gu(k) + (1 - H^{-1})(y(k) - Gu(k)) \\
 &= Gu(k) + (1 - H^{-1})y(k) - Gu(k) + H^{-1}Gu(k) \\
 &= \boxed{(1 - H^{-1})y(k) + H^{-1}Gu(k)}
 \end{aligned}$$

Observație: Pentru a avea un predictor *causal*, care depinde doar de valorile anterioare ale ieșirii și intrării, impunem $G(0) = 0$ și $H(0) = 1$.

Găsirea parametrilor și folosirea modelului

Odată ce o procedură pentru calculul erorilor este disponibilă, parametrii θ sunt găsiți prin minimizarea funcției obiectiv $V(\theta) = \frac{1}{N} \sum_{k=1}^N \varepsilon^2(k)$. Această minimizare poate necesita evaluări multiple ale semnalului de eroare, pentru mai multe valori ale lui θ .

Nu discutăm încă metodele prin care rezolvăm problema de minimizare. Le vom studia în detaliu în secțiunea următoare.

În final, odată ce o estimare $\hat{\theta}$ a optimului este găsită, formula de predicție poate fi aplicată pentru calculul ieșirii modelului $\hat{y}(k)$.

Checklist

	ARX	MEP generală
predictor $\hat{y}(k)$	✓	✓
eroare de predicție $\varepsilon(k)$	✓	✓
minimizare $V(\theta)$	✓	?

Table of contents

- 1 Structuri de model
- 2 **Metoda generală a minimizării erorii de predicție**
 - Pas preliminar: ARX revizitat
 - Cazul general
 - **Cazuri speciale: ARMAX ordinul 1, ARX**
 - Exemplu Matlab
- 3 Rezolvarea problemei de optimizare
- 4 Garanții de performanță

Exemplu recurent: ARMAX ordinul 1

Reamintim ARMAX:

$$Ay(k) = Bu(k) + Ce(k)$$

Prin plasare în forma standard, obținem:

$$\begin{aligned} y(k) &= \frac{B}{A}u(k) + \frac{C}{A}e(k) \\ &= Gu(k) + He(k) \end{aligned}$$

Așadar, $G = \frac{B}{A}$, $H = \frac{C}{A}$

Pentru ordinul 1: $A = 1 + aq^{-1}$, $B = bq^{-1}$, $C = 1 + cq^{-1}$.

ARMAX ordinul 1: Predictor

Reamintim formula generală a predictorului:

$$\hat{y}(k) = (1 - H^{-1})y(k) + H^{-1}Gu(k)$$

În cazul nostru, fiindcă $G = \frac{B}{A}$, $H = \frac{C}{A}$:

$$\hat{y}(k) = \left(1 - \frac{A}{C}\right)y(k) + \frac{A}{C}\frac{B}{A}u(k)$$

$$C\hat{y}(k) = (C - A)y(k) + Bu(k)$$

$$(1 + cq^{-1})\hat{y}(k) = (\lambda + cq^{-1} - \lambda - aq^{-1})y(k) + bq^{-1}u(k)$$

$$\hat{y}(k) + c\hat{y}(k-1) = (c - a)y(k-1) + bu(k-1)$$

$$\hat{y}(k) = -c\hat{y}(k-1) + (c - a)y(k-1) + bu(k-1)$$

Formula predictorului este una *dinamică*, recursivă ce trebuie simulată! Necesită inițializare pentru $\hat{y}(0)$; această valoare inițială se ia de obicei 0.

ARMAX ordinul 1: Eroare de predicție

Reamintim formula generală a erorii de predicție:

$$\varepsilon(k) = H^{-1}(y(k) - Gu(k))$$

În cazul nostru, fiindcă $G = \frac{B}{A}$, $H = \frac{C}{A}$:

$$\varepsilon(k) = \frac{A}{C} \left(y(k) - \frac{B}{A} u(k) \right)$$

$$C\varepsilon(k) = Ay(k) - Bu(k)$$

$$(1 + cq^{-1})\varepsilon(k) = (1 + aq^{-1})y(k) - bq^{-1}u(k)$$

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

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

Din nou, o formulă *dinamică*, recursivă. Necesită inițializare pentru $\varepsilon(0)$, de obicei luată 0.

Checklist

	ARX	MEP generală	ARMAX ordinul 1
predictor $\hat{y}(k)$	✓	✓	✓
eroare de predicție $\varepsilon(k)$	✓	✓	✓
minimizare $V(\theta)$	✓	?	?

Specializarea metodei la cazul ARX

Este util să vedem cum se simplifică formulele în cazul ARX.
Rescriem modelul ARX în forma generală:

$$y(k) = Gu(k) + He(k) = \frac{B}{A}u(k) + \frac{1}{A}e(k)$$

Avem:

$$H^{-1} = A \Rightarrow 1 - H^{-1} = 1 - A, \quad H^{-1}G = B$$

$$\hat{y}(k) = (1 - A)y(k) + Bu(k)$$

$$= (-a_1q^{-1} - \dots - a_naq^{-na})y(k) + (b_1q^{-1} + \dots b_{nb} + q^{-nb})u(k)$$

$$= \varphi(k)\theta$$

$$\varepsilon(k) = H^{-1}(y(k) - Gu(k)) = Ay(k) - Bu(k)$$

$$= y(k) - (1 - A)y(k) - Bu(k) = y(k) - \hat{y}(k)$$

care este așadar echivalent cu formularea ARX.





Conținut

- 1 Structuri de model
- 2 **Metoda generală a minimizării erorii de predicție**
 - Pas preliminar: ARX revizitat
 - Cazul general
 - Cazuri speciale: ARMAX ordinul 1, ARX
 - **Exemplu Matlab**
- 3 Rezolvarea problemei de optimizare
- 4 Garanții de performanță

Date experimentale


Folosim din nou datele experimentale pe care am identificat modelul ARX mai demult.

```
plot(id); și plot(val);
```



Reamintim: rezultat ARX

Presupunând că sistemul este de ordinul 2 fără timp mort, alegem $na = 2, nb = 2, nk = 1$.



Rezultatele sunt destul de proaste.

Identificarea unui model ARMAX

```
mARMAX = armax(id, [na, nb, nc, nk]);
```

Argumente:

- 1 Setul de date de identificare.
- 2 Vector conținând ordinele polinoamelor A , B , C și întârzierea nk .

Ca și pentru ARX, structura include explicit întârzierea minimă nk între intrări și ieșiri.

$$\begin{aligned}y(k) + a_1 y(k-1) + a_2 y(k-2) + \dots + a_{na} y(k-na) \\= b_1 u(k-nk) + b_2 u(k-nk-1) + \dots + b_{nb} u(k-nk-nb+1) \\+ e(k) + c_1 e(k-1) + c_2 e(k-2) + \dots + c_{nc} e(k-nc)\end{aligned}$$

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

$$A(q^{-1}) = (1 + a_1 q^{-1} + a_2 q^{-2} + \dots + a_{na} q^{-na})$$


$$B(q^{-1}) = (b_1 + b_2 q^{-1} + b_{nb} q^{-nb+1})$$

$$C(q^{-1}) = (1 + c_1 q^{-1} + c_2 q^{-2} + \dots + c_{nc} q^{-nc})$$

Observație: Ca pentru ARX, structura teoretică se obține alegând $nk = 1$ (și pentru a reprezenta $nk > 1$ în structura teoretică, adăugăm coeficienți inițiali zero în B).

Model ARMAX

Considerând că sistemul este de ordinul 2 fără timp mort, alegem $na = nb = nc = 2$, $nk = 1$. Validare: `compare(val, mARMAX)`;




Spre deosebire de ARX, rezultatele sunt bune. Modelul mai flexibil al perturbației își arată utilitatea.

Identificarea unui model OE

Reamintim structura OE:

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



Identificarea unui model OE (continuare)

$$mOE = oe(id, [nb, nf, nk]);$$

Argumente:

- 1 Setul de date de identificare.
- 2 Vector conținând ordinele polinoamelor B , F , și întârzierea nk .

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

$$B(q^{-1}) = (b_1 + b_2 q^{-1} + b_{nb} q^{-nb+1})$$

$$F(q^{-1}) = (1 + f_1 q^{-1} + f_2 q^{-2} + \dots + f_{nf} q^{-nf})$$


Formula explicită:

$$\begin{aligned} & y(k) + f_1 y(k-1) + f_2 y(k-2) + \dots + f_{nf} y(k-nf) \\ & = b_1 u(k-nk) + b_2 u(k-nk-1) + \dots + b_{nb} u(k-nk-nb+1) \\ & \quad + e(k) + f_1 e(k-1) + f_2 e(k-2) + \dots + f_{nf} e(k-nf) \end{aligned}$$

Observație: Ca și înainte, structura teoretică se obține alegând $nk = 1$ (sau schimbând B dacă $nk > 1$).

Model OE

Considerând că sistemul este de ordinul 2 fără timp mort, alegem $nb = 2, nf = 2, nk = 1$. Validare: `compare(val, mOE)` ;



Rezultatele sunt la fel de bune ca și ARMAX. Sistemul satisface deci ambele structuri de model. **Întrebare:** Care este structura reală?

Conținut

- 1 Structuri de model
- 2 Metoda generală a minimizării erorii de predicție
- 3 Rezolvarea problemei de optimizare**
- 4 Garanții de performanță

Checklist

	ARX	MEP generală	ARMAX ordinul 1
predictor $\hat{y}(k)$	✓	✓	✓
eroare de predicție $\varepsilon(k)$	✓	✓	✓
minimizare $V(\theta)$	✓	?	?

Problema de optimizare

Obiectivul procedurii de identificare: Minimizarea erorii medii pătratice

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

unde $\varepsilon(k)$ sunt erorile de predicție. În cazul general:

$$\varepsilon(k) = H^{-1}(q^{-1})(y(k) - G(q^{-1})u(k))$$

Soluția: $\hat{\theta} = \arg \min_{\theta} V(\theta)$

Până acum am presupus că această soluție a fost deja obținută, și i-am investigat proprietățile. Pe când în ARX puteam obține soluția folosind regresia liniară, în general această metodă nu va funcționa. Principala problemă care apare în implementare este:

Cum se rezolvă problema de optimizare?


Minimizare folosind zeroul derivatei

Considerăm întâi cazul scalar, $\theta \in \mathbb{R}$.


Idee: în orice minim, derivata $f(\theta) = \frac{dV}{d\theta}$ este zero. Așadar, căutăm un zero al funcției $f(\theta)$.

Observații:

- Trebuie avut grijă ca metoda să găsească un minim și nu un maxim sau punct de inflexiune. Acest lucru se poate verifica folosind derivata a doua, $\frac{d^2V}{d\theta^2} = \frac{df}{d\theta} > 0$.
- Este posibil ca metoda să găsească și un punct de minim local, în care funcția are valoare mai mare decât în minimul global.



Metoda lui Newton pentru rezolvarea ecuației $f(\theta) = 0$



- Pornim dintr-un punct inițial θ_0 .
- La iterația ℓ , următorul punct $\theta_{\ell+1}$ este intersecția între abscisă și **tangenta** la f în punctul curent θ_ℓ . Geometric:

$$\theta_{\ell+1} = \theta_\ell - \frac{f(\theta_\ell)}{\frac{df(\theta_\ell)}{d\theta}}$$

Observații:

- Notația $\frac{df(\theta_\ell)}{d\theta}$ înseamnă valoarea derivatei $\frac{df}{d\theta}$ în punctul θ_ℓ .
- Panta tangentei este $\frac{df(\theta_\ell)}{d\theta}$.
- $\theta_{\ell+1}$ este cea mai bună estimare a soluției dată fiind informația din punctul curent θ_ℓ .

Metoda lui Newton pentru optimizare

Înlocuim $f(\theta)$ cu $\frac{dV}{d\theta}$ pentru a ne întoarce la problema de optimizare:

$$\theta_{\ell+1} = \theta_{\ell} - \frac{\frac{dV(\theta_{\ell})}{d\theta}}{\frac{d^2V(\theta_{\ell})}{d\theta^2}}$$

Gradientul și Hessianul

Pentru a generaliza de la cazul scalar la $\theta \in \mathbb{R}^n$, avem nevoie de derivatele de ordinul 1 și 2 ale lui $V(\theta)$, ținând cont că $V : \mathbb{R}^n \rightarrow \mathbb{R}$.
Atunci:

$$\frac{dV}{d\theta} = \begin{bmatrix} \frac{\partial V}{\partial \theta_1} \\ \frac{\partial V}{\partial \theta_2} \\ \vdots \\ \frac{\partial V}{\partial \theta_n} \end{bmatrix}, \quad \frac{d^2V}{d\theta^2} = \begin{bmatrix} \frac{\partial^2 V}{\partial \theta_1^2} & \frac{\partial^2 V}{\partial \theta_1 \partial \theta_2} & \cdots & \frac{\partial^2 V}{\partial \theta_1 \partial \theta_n} \\ \frac{\partial^2 V}{\partial \theta_2 \partial \theta_1} & \frac{\partial^2 V}{\partial \theta_2^2} & \cdots & \frac{\partial^2 V}{\partial \theta_2 \partial \theta_n} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial^2 V}{\partial \theta_n \partial \theta_1} & \frac{\partial^2 V}{\partial \theta_n \partial \theta_2} & \cdots & \frac{\partial^2 V}{\partial \theta_n^2} \end{bmatrix}$$

Gradientul $\frac{dV}{d\theta}$ este un vector de lungimea n , și **Hessianul** $\frac{d^2V}{d\theta^2}$ este o matrice de dimensiunea $n \times n$.

Metoda lui Newton pentru optimizare

Pornim de la formula din cazul scalar:

$$\theta_{\ell+1} = \theta_{\ell} - \frac{\frac{dV(\theta_{\ell})}{d\theta}}{\frac{d^2V(\theta_{\ell})}{d\theta^2}}$$

și generalizăm folosind vectorul de gradient și matricea cu Hessianul:

$$\theta_{\ell+1} = \theta_{\ell} - \left[\frac{d^2V(\theta_{\ell})}{d\theta^2} \right]^{-1} \frac{dV(\theta_{\ell})}{d\theta}$$

Adăugăm un **pas** $\alpha_{\ell} > 0$. Forma finală:

$$\theta_{\ell+1} = \theta_{\ell} - \alpha_{\ell} \left[\frac{d^2V(\theta_{\ell})}{d\theta^2} \right]^{-1} \frac{dV(\theta_{\ell})}{d\theta}$$

Observație: Pasul ajută la convergența metodei, de ex. când funcția V este afectată de zgomot.

Criteriu de oprire

Algoritmul poate fi oprit:

- Când diferența între doi vectori consecutivi de parametri este mică, de ex. $\max_{i=1}^n |\theta_{i,\ell+1} - \theta_{i,\ell}|$ este mai mic decât un prag prestabilit.

sau

- Când numărul de iterații ℓ depășește un maxim prestabilit.

Observație: Până acum, nimic din metoda lui Newton nu e specific identificării sistemelor! Metoda funcționează în general, pentru orice problemă de optimizare. În cele ce urmează, revenim la problema de identificare din MEP.

Calculul derivatelor

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

Ținând cont că $\varepsilon(k)$ depinde de θ , avem:

$$\frac{dV}{d\theta} = \frac{2}{N} \sum_{k=1}^N \varepsilon(k) \frac{d\varepsilon(k)}{d\theta}$$
$$\frac{d^2 V}{d\theta^2} = \frac{2}{N} \sum_{k=1}^N \frac{d\varepsilon(k)}{d\theta} \left[\frac{d\varepsilon(k)}{d\theta} \right]^T + \frac{2}{N} \sum_{k=1}^N \varepsilon(k) \frac{d^2 \varepsilon(k)}{d\theta^2}$$

unde:

- $\frac{d\varepsilon(k)}{d\theta}$ este derivata vectorială și $\frac{d^2 \varepsilon(k)}{d\theta^2}$ este Hessianul lui $\varepsilon(k)$.
- $\frac{d\varepsilon(k)}{d\theta} \left[\frac{d\varepsilon(k)}{d\theta} \right]^T$ este o matrice $n \times n$.

Gauss-Newton

Ignorăm cel de-al doilea termen în Hessianul lui V și îl folosim doar pe primul:

$$\mathcal{H} = \frac{2}{N} \sum_{k=1}^N \frac{d\varepsilon(k)}{d\theta} \left[\frac{d\varepsilon(k)}{d\theta} \right]^\top$$

Obținem metoda **Gauss-Newton**:

$$\theta_{\ell+1} = \theta_\ell - \alpha_\ell \mathcal{H}^{-1} \frac{dV(\theta_\ell)}{d\theta}$$

Motivare:

- Forma pătratică a lui \mathcal{H} duce la un comportament mai bun al algoritmului.
- Calculele sunt mai simple.

Calculul detaliat al derivatei $\frac{d\varepsilon(k)}{d\theta}$ depinde de structura aleasă pentru model.

Checklist

	ARX	MEP generală	ARMAX ordinul 1
predictor $\hat{y}(k)$	✓	✓	✓
eroare de predicție $\varepsilon(k)$	✓	✓	✓
minimizare $V(\theta)$	✓	✓	?

Exemplu: ARMAX de ordinul 1

Reamintim modelul ARMAX de ordinul 1 și eroarea sa de predicție:

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

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

Avem nevoie de $\frac{d\varepsilon(k)}{d\theta} = \left[\frac{\partial\varepsilon(k)}{\partial a}, \frac{\partial\varepsilon(k)}{\partial b}, \frac{\partial\varepsilon(k)}{\partial c} \right]^T$. Derivând a doua ecuație:

$$\frac{\partial\varepsilon(k)}{\partial a} = -c \frac{\partial\varepsilon(k-1)}{\partial a} + y(k-1)$$

$$\frac{\partial\varepsilon(k)}{\partial b} = -c \frac{\partial\varepsilon(k-1)}{\partial b} - u(k-1)$$

$$\frac{\partial\varepsilon(k)}{\partial c} = -c \frac{\partial\varepsilon(k-1)}{\partial c} - \varepsilon(k-1)$$

$\frac{\partial\varepsilon(k)}{\partial a}$, $\frac{\partial\varepsilon(k)}{\partial b}$, $\frac{\partial\varepsilon(k)}{\partial c}$ sunt **semnale dinamice**! Ele pot fi calculate folosind formulele recursive de mai sus, pornind de ex. de la valori inițiale 0.

Exemplu: ARMAX de ordinul 1 (continuare)

În final, algoritmul complet poate fi implementat după cum urmează:

inițializează θ_0 , indexul de iterație $\ell = 0$

repeat

dat fiind vectorul curent de parametri θ_ℓ ,

calculează cu formulele recursive $\frac{d\varepsilon(k)}{d\theta}$, $k = 1, \dots, n$

înlocuiește $\frac{d\varepsilon(k)}{d\theta}$ în formulele $\frac{dV}{d\theta}$, $\frac{d^2V}{d\theta^2}$

găsește $\theta_{\ell+1}$ cu actualizarea Newton (sau Gauss-Newton)

incrementează indexul: $\ell = \ell + 1$

until $\theta_{\ell+1} - \theta_\ell$ este destul de mic, sau numărul maxim de iterații este atins

Checklist

	ARX	MEP generală	ARMAX ordinul 1
predictor $\hat{y}(k)$	✓	✓	✓
eroare de predicție $\varepsilon(k)$	✓	✓	✓
minimizare $V(\theta)$	✓	✓	✓

Conținut


- 1 Structuri de model
- 2 Metoda generală a minimizării erorii de predicție
- 3 Rezolvarea problemei de optimizare
- 4 Garanții de performanță**

Ipoteze

Ipoteze (simplificate)

- 1 Semnalele $u(k)$ și $y(k)$ sunt procese stohastice staționare.
- 2 Semnalul de intrare $u(k)$ are un ordin de PE suficient de mare.
- 3 Hessianul $\frac{d^2V}{d\theta^2}$ este inversabil în punctele de minim ale funcției MSE V .


Reamintim funcția de MSE $V(\theta) = \frac{1}{N} \sum_{k=1}^N \varepsilon^2(k)$. Ipoteza 3 garantează că V nu este “plat” în jurul minimelor.



Garanție

Teorema 1

Definim limita $V_\infty(\theta) = \lim_{N \rightarrow \infty} V(\theta)$. Date fiind Ipotezele 1–3, soluția de identificare $\hat{\theta} = \arg \min_{\theta} V(\theta)$ converge la un punct de minim θ^* al $V_\infty(\theta)$ când numărul de date $N \rightarrow \infty$.



Observație: Rezultatul este unul de **consistență**, în limita unui număr infinit de date.

Ipoteze adiționale

Ipoteze (simplificate)

- 1 Sistemul adevărat satisface structura de model aleasă. Anume, există cel puțin un vector corect θ_0 astfel încât pentru orice intrare $u(k)$ și ieșirea corespunzătoare $y(k)$ a sistemului adevărat, avem:

$$y(k) = G(q^{-1}; \theta_0)u(k) + H(q^{-1}; \theta_0)e(k)$$

unde $e(k)$ este *zgomot alb*.

- 2 Intrarea $u(k)$ este independentă de zgomotul $e(k)$ (experimentul este efectuat în buclă deschisă).

Garanție adițională

Teorema 2

Date fiind Ipotezele 1-5, $\hat{\theta}$ converge la vectorul corect de parametri θ_0 când $N \rightarrow \infty$.

Observație: Și această garanție este una de consistență. Pe când Teorema 1 garantează o soluție de eroare minimă, Teorema 2 ne spune că această soluție corespunde sistemului adevărat, *în condițiile în care* sistemul satisface structura aleasă pentru model.