

1 Privire de ansamblu

Problematica generală în IS



Plecînd de la un proces stocastic \mathcal{P} cu structură și comportament necunoscute, se urmărește construcția și determinarea unui model matematic \mathcal{M} , care să fie adecvat procesului într-un sens bine definit.

Obiectivul principal

Criterii empirice

- Se bazează pe unele noțiuni elementare de Statistică și sunt folosite mai mult pentru descrierea modelelor neparametrice.
- Modele neparametrice servesc la descrierea calitativă, de cele mai multe ori grosieră, imprecisă, a proceselor.
- Vor fi descrise câteva tehnici de identificare (numite analize) folosind modelele neparametrice și criteriile empirice pe baza cărora se poate evalua precizia acestora .

Categorii de criterii de adecvanță

Criterii de optimizare

Criterii de estimare

Caracteristice modelelor de identificare parametrice

- Modelul de identificare este descris de un anumit număr de parametri necunoscuți, care trebuie determinați.

👉 Nu numai valorile parametrilor nu se cunosc, ci și numărul lor.

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


Ipoteza fundamentală

Procesul funcționează ca un model matematic cu parametri adevărați, necunoscuți, cu valori deterministic (eventual variabile în timp), al căror vector este notat cu $\boldsymbol{\theta}^*$ și are dimensiunea $n\theta^*$.

1 Privire de ansamblu

Problematica generală în IS (continuare)

Formularea problemei din perspectiva Teoriei Optimizărilor (TO)



- Atât procesul cât și modelul sunt stimulate cu aceeași intrare, care constituie **colecția de date de intrare măsurate**.
- Procesul oferă **datele (de ieșire) măsurate**.
- Modelul matematic oferă **datele simulate**.
- Pentru același set de date măsurate la intrare și la ieșire, se poate obține o **colecție de vectori ai parametrilor necunoscuți** (atât ca valori, cât și ca dimensiuni), deci și de seturi de date simulate.
- Diferența dintre datele măsurate și cele simulate constituie **erorile dintre proces și model**.
- Ansamblul erorilor este folosit pentru a defini **criteriul de adecvanță** care trebuie **optimizat** în vederea determinării parametrilor necunoscuți.

$$\mathcal{U} = \{u[n]\}_{n=1,\overline{N}} \quad \begin{matrix} \text{dimensiunea} \\ \text{orizontului de măsură} \end{matrix}$$


$$\mathcal{Y} = \{y[n]\}_{n=1,\overline{N}}$$

$$\mathcal{Y}_M = \{y_M[n, \theta]\}_{n=1,\overline{N}} \quad \begin{matrix} \text{(depind de vectorul parametrilor} \\ \text{determinați din datele măsurate)} \end{matrix}$$

1 Privire de ansamblu

Problematica generală în IS (continuare)

Formularea problemei din perspectiva Teoriei Optimizărilor (continuare)



- Pentru rezolvarea acestei probleme se adoptă o **strategie iterativă**.

Numărul de parametri ai modelului **este mărit treptat**, începînd cu valorile minime, pînă la o valoare maximală prestabilită.

(acest mecanism va fi prezentat ulterior în detaliu)

- Eficiența și complexitatea **operației de optimizare** depinde sensibil de **maniera în care a fost definit criteriul de adecvanță**.
- Valoarea criteriului de adecvanță** evaluată pentru un anumit model de identificare este adesea interpretată ca un **indicator al preciziei modelului**.

$$\mathcal{V}(\theta)$$

Cum se poate alege
criteriul de adecvanță?



În acest context, **criteriul de adecvanță** este un **criteriu de optimizare** (parametrică).



Exemple

Criterii uzuale de optimizare parametrică, bazate pe eroarea totală dintre proces și model

→ Criteriul **robust**:

$$\mathcal{V}(\theta) \stackrel{\text{def}}{=} \sum_{n=1}^N |\varepsilon[n, \theta]|$$

→ Criteriul **pătratic**:

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

☺ Natural.

☹ Nederivabil peste tot.


☺ Derivabil, dacă eroarea este derivabilă.

☹ Mai puțin natural.

1 Privire de ansamblu

Problematica generală în IS (continuare)

Formularea problemei din perspectiva Teoriei Optimizărilor (continuare)



Formularea problemei în termeni matematici

$$\hat{\theta}_N = \underset{\theta \in \mathcal{S} \subseteq \mathbb{R}^{n\theta}}{\operatorname{argmin}} \mathcal{V}(\theta)$$

(Se citește: "argumentul care minimizează".)

$\hat{\theta}_N$ → valoarea optim(al)ă a vectorului parametrilor necunoscuți

\mathcal{S} → domeniul de stabilitate al modelului

→ Acest curs este focalizat în jurul problemei de identificare a sistemelor **stabile**.

- Identificarea sistemelor instabile este o **problemă deschisă**.

Tehnicile de optimizare sunt de regulă iterative, calitatea lor fiind analizată după 3 caracteristici:

- ① complexitate;
- ② convergență; → **cea mai importantă**
- ③ viteza de convergență.

- De regulă, rezolvarea acestei probleme trebuie să conducă la o **eroare globală minimă** (între proces și model).
- Pentru rezolvarea ei, se apelează frecvent la **metode de optimizare bazate pe tehnica gradientelor**.
- Tehnica de rezolvare depinde **esențialmente de maniera în care eroarea dintre proces și model depinde de vectorul parametrilor necunoscuți**.

→ Tehnici **neconvenționale** pot fi de asemenea utilizate.


- Tehnici de Inteligență Artificială (ascensiune montană, călire simulată, etc.).
- Strategii evoluționiste (**algoritmi genetici**).

1 Privire de ansamblu

Problematica generală în IS (continuare)

Formularea problemei din perspectiva Teoriei Estimării (TE)

- Deoarece datele furnizate de proces au un caracter **stochastic**, acesta se transferă și parametrilor determinați, care se mai numesc în acest context și **parametri estimări**.
- Metoda prin care se produc estimării ale parametrilor necunoscuți se mai numește și **estimator**.
- Problema de identificare este similară celei din perspectiva **TO**:




$P(\theta)$ → matricea de auto-covarianță a erorii de estimare

operatorul de mediare statistică
(speranța matematică)

$$P(\theta) \stackrel{\text{def}}{=} E\{(\theta - \theta^*)(\theta - \theta^*)^T\} \in \mathbb{R}^{n\theta \times n\theta}$$

Produsul interior = produsul scalar.




produsul exterior

1 Privire de ansamblu

Problematica generală în IS (continuare)

Formularea problemei din perspectiva Teoriei Estimației (continuare)



Formularea problemei în termeni matematici

$$\hat{\theta}_N = \underset{\theta \in S \subseteq \mathbb{R}^{n\theta}}{\operatorname{argmin}} P(\theta)$$

$\hat{\theta}_N$ → valoarea estimată a vectorului parametrilor necunoscuți

Minimizarea unei matrici?

- Deoarece criteriul matricial abordează direct parametrii adevărați (care sunt necunoscuți), aparent, el este **imposibil de evaluat**.
- Cu toate acestea, **pentru anumiți estimatori, criteriul matricial poate fi determinat**, chiar dacă parametrii adevărați nu sunt cunoscuți.
- Rezolvarea unei probleme de optimizare în cadrul **TE** este mai dificilă decât în cadrul **TO**.

Soluția problemei
TO

Ⓐ Adesea implementabilă
Ⓑ Fără proprietăți statistice.

Soluția problemei
TE

Ⓐ Cu proprietăți statistice.
Ⓑ Adesea neimplementabilă.


În sensul proprietății de pozitiv semi-definire.

$$P_1 \leq P_2 \Leftrightarrow P_2 - P_1 \geq 0$$



Calitatea unui estimator poate fi analizată în raport cu 3 caracteristici:

- ① complexitate; ⚡ **cea mai importantă**
- ② consistență (convergență statistică);
- ③ eficiență (viteză de convergență).




$$\lim_{N \rightarrow \infty} P(\hat{\theta}_N) = 0$$

1 Privire de ansamblu

Experiment de identificare

- Problema generală a identificării cutiei negre se rezolvă în cadrul unui **experiment de identificare**.



1 Privire de ansamblu

Experiment de identificare (continuare)



Pentru fiecare structură de model din ce în ce mai bogată ($m \in \{1, 2, \dots, M\}$):

- se determină parametrii modelului ales, θ_m ;
- se evaluatează precizia modelului ($\mathcal{V}(\theta_m)$ sau $P(\theta_m)$).

Alegerea modelului
adecvat datelor
achiziționate

$$\mathcal{M}(\theta_0)$$

NU

DA

Validarea
modelului


Model valid

$$\mathcal{M}(\theta_0)$$

1 Privire de ansamblu

Experiment de identificare (continuare)

- Informație preliminară despre proces
- Scopul identificării procesului



1 Privire de ansamblu

Experiment de identificare (continuare)

- Informație preliminară despre proces
- Scopul identificării procesului

♪ Prima operație:
precizarea procesului
care trebuie identificat.

→ Tipul de proces: puternic neliniar, neliniar, aproape liniar, liniar.


- Majoritatea proceselor sunt neliniare și puternic neliniare, dar **liniarizabile în jurul unor puncte nominale de funcționare**.
- Dacă se cunosc **ecuațiile de funcționare în timp continuu** (rezultate prin aplicarea legilor fizico-chimice), acestea pot fi **discretizate**, pentru a obține informații privind **structura modelului de identificare** ce ar trebui ales.
- Eventual, vor fi necesare **mai multe experimente de identificare succesive** pentru construcția unui **model adecvat și valid**.

→ Tipul de variație: lent (> 5s), mediu (1s...5s), rapid (< 1s).

- Informație care se referă la **durata de stabilizare a ieșirii** atunci când procesul este stimulat cu o **treaptă de o anumită amplitudine**, acceptată de proces (fără a produce instabilitate).
- Utilă în determinarea **perioadei de eșantionare** ce trebuie aleasă pentru **achiziția datelor numerice**.

→ Timpul mort intrinsec al procesului.

- Detectarea valorii acestuia în timp continuu și conversia sa (chiar imprecisă) în timp discret (exprimată ca un număr întreg de perioade de eșantionare) conduce la **simplificarea modelului de identificare ales** (prin reducerea numărului de parametri necesari).
- Determinarea timpului mort se poate efectua prin **stimularea preliminară a procesului** cu o **treaptă de o anumită amplitudine**, care nu îl conduce către instabilitate.



sampling period

1 Privire de ansamblu

Experiment de identificare (continuare)

➤ Informație preliminară despre proces

➤ Scopul identificării procesului

→ Variabilitatea în timp a procesului.


- Dacă parametrii sunt **aproximativ constanți**, este doar necesar ca la anumite intervale de timp **modelul matematic asociat să fie reevaluat**.
- Dacă parametrii **variază sesizabil în timp**, atunci **modelul trebuie adaptat mai des la dinamica procesului**.
- Această informație este utilă în **alegerea tipului de metodă de identificare adecvată: nerecursivă (off-line) sau recursivă (on-line)**.

→ Clasele de semnale de stimul acceptate de către proces .

- **Semnalele ideale** cu care procesul ar putea fi stimulat **pot produce instabilitate**.
- Modelul de identificare ar putea fi determinat prin stimularea procesului cu **semnalele folosite în exploatarea sa uzuală**.
- Utilizarea de **semnale cu amplitudini suficient de mici** poate conduce la modele matematice suficient de generale și precise.

→ Clasele de perturbații la care este expus procesul.

- Informație utilă în selectarea unui **model adecvat al zgomotelor** ce pot afecta măsurările la ieșirea procesului .
- În absența ei, experimentul de identificare **se poate repeta de cîteva ori**, pînă la stabilirea unui model adecvat de zgomot.



⌚ Modelul rezultat are generalitate redusă.

Simulare, reglare/comandă numerică, predicție, generare de date, etc.

- De exemplu, modelul perturbațiilor va fi mai precis în scopul predicției, decît în scopul reglării numerice.

1 Privire de ansamblu

Experiment de identificare (continuare)

Econometrie

Tehnica măsurării datelor.

Etapele unui experiment econometric



Obiectiv

→ Alegerea soluției de eșantionare.

- Pe de o parte, **tipul de variație** al procesului este determinant.



$$F_s = \frac{1}{T_s}$$

frecvență de eșantionare


- Pe de altă parte, **resursele financiare disponibile** induc restricții.
- În plus, soluția de eșantionare bazată pe utilizarea cîmpului electric are o limitare naturală, datorată **inertiei electronilor**.



Există o frecvență de eșantionare **maximă** produsă prin utilizarea **energiei electrice**.



Costul soluției de eșantionare crește **exponențial** de la un anumit nivel.



1 Privire de ansamblu

Experiment de identificare (continuare)

Etapele unui experiment econometric

→ Alegerea soluției de eșantionare.



Max Planck
(1858-1947)

★ Conform unui raționament bazat pe Fizica Cuantică, pentru viteze mari de comutație, electronii au inerție.

Principiul limitei cuantice (Planck)

Formula energiei a lui Einstein

$$\mathcal{E} = m \cdot c^2$$

Masa electronului

$$m = 9.11 \cdot 10^{-31} \text{ [kg]}$$

Viteza luminii în vid

$$c = 3 \times 10^8 \text{ [m/s]}$$



Albert Einstein
(1879-1955)

1905

Teoria relativității restrânse (Einstein)

2005

Anul internațional al Fizicii

Premiul Nobel pentru Teoria cuantică a fotonilor

Organizarea experimentului econometric

energia electronului

perioada proprie de oscilație a electronului

$$h = 6.626 \times 10^{-34} \text{ [J} \cdot \text{s]}$$

$$T_e \geq \frac{h}{\mathcal{E}} = \frac{h}{mc^2} \cong 8.0815 \cdot 10^{-21} \text{ [s]}$$

Energie × Frecvență de eșantionare \geq constantă

Frecvența de eșantionare maximă

$$F_s \leq 10^6 \text{ [GHz]}$$

- Nivelul tehnologic actual:

$$F_s \in [10, 100] \text{ [GHz]}$$

$$F_s \leq 10^{16} \text{ [GHz]}$$

