


## ② Modele de identificare

### ②.① Scurtă clasificare



# 2 Modele de identificare

## 2.1 Scurtă clasificare



- Mai **precise**.

$$M(\theta)$$

- Mai **puțin precise**.
- Oferă mai mult **descrieri calitative** ale procesului de interes, dar pot fi utilizate pentru a stabili anumite **caracteristici** ale **experimentului de identificare** parametrică desfășurat ulterior (întârziere intrinsecă, **frecvență de eșantionare**, numărul maxim de parametri, etc.).



**Single Input Single Output**



**Multi(ple) Input(s) Multi(ple) Output(s)**




**Single Input Multi(ple) Output(s)**



**Multi(ple) Input(s) Single Output**

# ② Modele de identificare

## ②.① Scurtă clasificare



# 2 Modele de identificare

## 2.2 Noțiuni de Statistică și Prelucrare de Semnal

☞ Colecțiile de date măsurate sunt semnale avînd un caracter nedeterminist (stocastic).

Modelele de identificare construite plecînd de la astfel de date **au natură statistică**.

- Pentru a putea caracteriza proprietățile modelelor de identificare sunt necesare cîteva concepte elementare de **Statistică** și de **Prelucrare de Semnal (PS)**.

### Densitate de probabilitate (distribuție de probabilitate)

- Distribuții de probabilitate uzuale:

Gaussiană

Student

Laplaciană

Pearson

Probabilitate

$$\mathcal{P}(x \in S) \stackrel{\text{def}}{=} \int \rho(x) dx$$

probabilitatea ca  $x$  să aparțină submulțimii  $S$  din domeniul de variație

Apartenența unei variabile aleatoare la domeniul său de variație este un **eveniment sigur**.

$$\rho : \mathcal{D}(x) \rightarrow [0, 1]$$

domeniul de variație al variabilei aleatoare  $x$

$$\int_{\mathcal{D}(x)} \rho(x) dx = 1$$

$\mathcal{D}(x)$  cel mult numărabil

$\rho$  frecvență de apariție


$\mathcal{D}(x)$  finit

$h$  histogramă

$\rho \equiv \frac{h}{\#\mathcal{D}(x)}$  frecvență de apariție

cardinalul domeniului de variație (numărul de valori)

☞ Frecvența de apariție este adesea considerată o aproximare a densității de probabilitate.



# 2 Modele de identificare

## 2.2 Noțiuni de Statistică și Prelucrare de Semnal



### Tipuri de densități de probabilitate utilizate în IS

#### Densitatea simplă de probabilitate

$$\stackrel{\text{def}}{p}(u[n], n) = p(u[n]) \in [0, 1]$$

$$\stackrel{\text{def}}{p}(y[n], n) = p(y[n]) \in [0, 1]$$

Probabilitatea ca valoarea intrării, respectiv ieșirii să aparțină setului de date măsurate la momentul  $n \in \mathbb{N}^*$ .

#### Densitatea de probabilitate încrucișată (intrare-ieșire)

$$p(u[m], y[n], m, n)$$

$$\stackrel{\text{def}}{=} p(u[m], y[n]) \in [0, 1]$$

Probabilitatea ca intrarea  $u[m]$  să producă ieșirea  $y[n]$  în datele măsurate, la momentele  $m \in \mathbb{N}^*$  și  $n \in \mathbb{N}^*$ .

#### Densitatea de probabilitate a aceleiași realizări

$$p(y[m], y[n], m, n)$$

$$\stackrel{\text{def}}{=} p(y[m], y[n]) \in [0, 1]$$

Probabilitatea ca valorile  $y[m]$  și  $y[n]$  ale ieșirii procesului să aparțină aceleiași realizări, la momentele  $m \in \mathbb{N}^*$  și  $n \in \mathbb{N}^*$ .

! Cunoașterea preliminară a acestor densități de probabilitate este dificilă (dacă nu imposibilă).

☞ Convenție: distribuțiile de probabilitate ale proceselor vor fi implicit considerate **de tip Gaussian**, dacă nu se specifică altfel.

**TLC**

# 2 Modele de identificare

## 2.2 Noțiuni de Statistică și Prelucrare de Semnal

### Medie statistică

(valoarea cea mai așteptată, speranța matematică)

$$E\{y[n]\} \stackrel{\text{def}}{=} \int_{\mathcal{D}(y[n])} \underbrace{p(y[n]) \cdot y[n]}_{\forall n \in \mathbb{N}^*} dy[n]$$

Operator de mediere statistică

**E**

**Expected**

Speranță matematică?

produsul dintre valoarea densității de probabilitate și valoarea corespunzătoare a variabilei aleatoare

Folosind media statistică a unui set de date aleatoare (cu o anumită distribuție de probabilitate), se poate obține o **predicție** (de regulă grosieră) a valorii care s-ar adăuga datelor disponibile la momentul următor de achiziție.

⚡ Timpul joacă un rol secundar în definiția operatorului **E**, deoarece integrarea se efectuează peste mulțimea valorilor variabilei aleatoare și nu de-a lungul axei timpului.

Direcția de integrare în definiția operatorului de mediere statistică


Proprietăți elementare ale operatorului de mediere statistică

➔ Invarianța **variabilelor deterministe**

$$E\{a[n]\} = a[n] \quad \forall n \in \mathbb{N}^*$$

➔ Liniaritate

$$E\{a_1[n]y_1[n] + a_2[n]y_2[n]\} = a_1[n]E\{y_1[n]\} + a_2[n]E\{y_2[n]\} \quad \forall n \in \mathbb{N}^*$$



Realizări ale procesului

$E\{y[n]\}$

Variabilă în timp, dar **deterministă**.

# 2 Modele de identificare

## 2.2 Noțiuni de Statistică și Prelucrare de Semnal



### Exemplu

Revenim la răspunsul indicial al unui sistem linear de ordin I



Parametrii procesului pot fi determinați cu o anumită precizie folosind **curba medie statistică** a tuturor realizărilor acestuia.

- Inconveniențele utilizării directe a definiției operatorului de mediere statistică în aplicații practice:

⊗ De cele mai multe ori, **nu se cunoaște** densitatea de probabilitate a datelor măsurate.



Ar putea fi estimată prin inițierea unui mare număr de experimente econometrice și trasarea histogramelor valorilor măsurate la fiecare moment de timp.

⊗ Pentru evaluarea cu precizie a mediei statistice, este necesară o **colecție infinită** de realizări ale procesului.



Un mare număr de experimente econometrice ar putea conduce la valori suficient de precise ale mediei statistice.



complicat



costisitor

# 2 Modele de identificare

## 2.2 Noțiuni de Statistică și Prelucrare de Semnal



Cum se poate utiliza operatorul de mediere statistică în cazul în care doar o singură realizare a procesului este disponibilă?



Folosind o ipoteză celebră din Fizică.

**Ipoteza Ergodică (IE) (de medie)**

Media statistică pe ansamblul realizărilor unui proces se poate evalua calculând **mediile temporale** succesive **ale oricărei realizări**, în jurul fiecărui moment de timp.  
 Precizia evaluării crește odată cu numărul datelor care reprezintă acea realizare.

$$E\{y[n]\} \cong \frac{1}{n} \sum_{i=1}^n y[i] \quad \leftarrow \text{medie temporală}$$

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

Direcția de sumare/integrare în definiția mediei temporale


**Caz particular**

numărul de termeni ai sumei

**Proces staționar (în medie)**

$$E\{y[n]\} \stackrel{\text{def}}{=} \bar{y} = \text{constant} \quad \forall n \in \mathbb{N}^*$$

**Teorema de medie**



**IE**

$$E\{y[n]\} = \bar{y} = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n y[i] \quad \leftarrow \text{cauzală}$$

$$E\{y[n]\} = \bar{y} = \lim_{N \rightarrow \infty} \frac{1}{2N} \sum_{i=-N+1}^{n+N} y[i] \quad \leftarrow \text{necauzală}$$

$$E\{y[n]\} \cong \frac{1}{n} \sum_{i=1}^n y[i] \quad \forall n \in \mathbb{N}^*$$

⚡ Timpul joacă rolul principal.

# 2 Modele de identificare

## 2.2 Noțiuni de Statistică și Prelucrare de Semnal



### Așadar

Folosirea **IE** conduce la posibilitatea de a aproxima operatorul de mediere statistică în aplicații practice **fără a cunoaște densitatea de probabilitate** a datelor și **fără a efectua mai mult de un experiment econometric**.

Cît de precisă este această aproximație?



Precizia aproximației crește odată cu numărul de date achiziționate.

deterministă

nedeterministă

$$E\{y\} = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n y[i] \quad \forall n \in \mathbb{N}^*$$

$$E\{y[n]\} \cong \frac{1}{n} \sum_{i=1}^n y[i] \quad \forall n \in \mathbb{N}^*$$

Totuși, pentru un număr constant de date achiziționate, precizia aproximației poate fi testată cu ajutorul **dispersiei datelor în jurul mediei**.

### Dispersie

$$\sigma_y^2[n] \stackrel{\text{def}}{=} E\{y^2[n]\} = \int_{\mathcal{D}(y^2[n])} p(y^2[n]) y^2[n] dy^2[n] \quad (\text{media pătratelor valorilor}) \quad \forall n \in \mathbb{N}^*$$

### Date staționarizate

$$\tilde{y}[n] = y[n] - E\{y[n]\} \quad (\text{centrate pe medie}) \quad \forall n \in \mathbb{N}^* \quad E\{\tilde{y}[n]\} = 0 \quad (\text{vezi proprietățile operatorului } E) \quad \forall n \in \mathbb{N}^*$$

### Varianță

$$\sigma_{\tilde{y}}^2[n] \stackrel{\text{def}}{=} E\{\tilde{y}^2[n]\} \quad (\text{dispersia datelor în jurul mediei}) \quad \forall n \in \mathbb{N}^*$$

$$\text{IE} \Rightarrow \sigma_y^2[n] \cong \frac{1}{n} \sum_{i=1}^n y^2[i] \quad \forall n \in \mathbb{N}^*$$

### Deviație standard

$$\sigma_{\tilde{y}}[n] \stackrel{\text{def}}{=} \sqrt{E\{\tilde{y}^2[n]\}} \quad \forall n \in \mathbb{N}^*$$

• Altă variantă:

$$\sigma_y^2[n] \cong \frac{1}{n-1} \sum_{i=1}^n y^2[i] \quad \forall n \in \mathbb{N}^* \setminus \{1\}$$



proprietăți statistice superioare

# 2 Modele de identificare

## 2.2 Noțiuni de Statistică și Prelucrare de Semnal



Gradul de grupare a datelor în jurul mediei este cuantificat de deviația standard, cu ajutorul **tubului de deviație standard**.



factor de proporționalitate care depinde de interpretarea pe care o are tubul

Cu cât tubul este mai îngust, cu atât precizia curbei medii este mai mare.

Exemplu

Cazul procesului normal distribuit

$\alpha = 3$

Altă interpretare

Precizia de predicție a procesului

Tubul de deviație standard este definit în orice moment de intervalul  $3\sigma$ .

Valoarea măsurată la momentul următor celui curent ( $n$ ) se va situa în **intervalul de încredere**:

♣ Mai mult de 95% din realizările procesului trec prin acest tub.

$$\left[ E\{y[n]\} - \alpha\sigma_{\tilde{y}}[n], E\{y[n]\} + \alpha\sigma_{\tilde{y}}[n] \right]$$

cu o anumită probabilitate, **numită nivel de încredere**.

♣ De regulă, nivelul de încredere **scade odată cu îngustarea intervalului de încredere**.

Exemplu

Nivelul de încredere pentru predicția procesului normal distribuit este **0.95**.