

# Procese stochastice și teoria filtrării

## 1. Variabile aleatoare

### 1.1. Noțiunea de probabilitate

Fie  $E$  o mulțime nevidă și  $\mathcal{K}$  o familie nevidă de părți ale mulțimii  $E$ .

#### Definiția 1

de părți ale mulțimii  $E$

$\mathcal{K}$  se numește corp dacă:

- 1°  $\forall A \in \mathcal{K}$ , atunci  $C_A \in \mathcal{K}$  ( $C_A$  - complementara lui  $A$ );
- 2° dacă  $A, B \in \mathcal{K}$ , atunci  $A \cup B \in \mathcal{K}$ ;
- 3° dacă  $A, B \in \mathcal{K}$ , atunci  $A \cap B \in \mathcal{K}$ .

#### Definiția 2

de părți ale mulțimii  $E$

$\mathcal{K}$  se numește corp borelian dacă:

- 1°  $\forall A \in \mathcal{K}$ , atunci  $C_A \in \mathcal{K}$ ;
- 2°  $A_i \in \mathcal{K}$ ;  $i \in I$ , atunci  $\bigcup_{i \in I} A_i \in \mathcal{K}$ ;
- 3°  $A_i \in \mathcal{K}$ ;  $i \in I$ , atunci  $\bigcap_{i \in I} A_i \in \mathcal{K}$ ,

unde  $I$  este o familie numărabilă de indici.

#### Propoziția 1

$\mathcal{K}$  este corp (borelian) de părți ale mulțimii  $E$ , dacă satisface axioma 1° și una din axiomele 2°, 3° din definiția 1 (2). Demonstrația se face utilizând formulele lui Morgan.

#### Definiția 3

Dacă  $\mathcal{K}$  este un corp (borelian) de părți ale mulțimii  $E$ , cuplul  $(E, \mathcal{K})$  se numește câmp (borelian) de evenimente.

#### Definiția 4 (Kolmogorov)

Funcția  $P: \mathcal{K} \rightarrow \mathbb{R}$  se numește probabilitate pe corpul (borelian)  $\mathcal{K}$  dacă:

- 1°  $P(A) \geq 0$ ;
- 2°  $P(\bigcup_{i \in I} A_i) = \sum_{i \in I} P(A_i)$ , unde  $(A_i)_{i \in I} \in \mathcal{K}$ ,  $A_i \cap A_j = \emptyset$ , pentru  $i \neq j$ ,  $i, j \in I$ ;  $I$  - familie finită (numărabilă) de indici și  $\bigcup_{i \in I} A_i \in \mathcal{K}$ ;
- 3°  $P(E) = 1$ .

x.A  
164  
Multimile  $A, E, \emptyset$  in acest context se numesc eveniment, eveniment sigur, eveniment imposibil.

### Definitia 5

Dacă  $\mathcal{K}$  este corp (borelian) atunci tripletul  $(E, \mathcal{K}, P)$  se numeste câmp (borelian) de probabilitate.

### Propozitia 2

Dacă  $P$  este probabilitate pe corpul  $\mathcal{K}$ , atunci:

- $P(\emptyset) = 0$ ;
- $P(A) = 1 - P(CA)$ ;  $A \in \mathcal{K}$ ;
- $P(B \setminus A) = P(B) - P(A)$ ;  $A, B \in \mathcal{K}$ ,  $A \subset B$ ;
- $P(A) \leq P(B)$ , dacă  $A \subset B$ ;  $A, B \in \mathcal{K}$ ;
- $0 \leq P(A) \leq 1$ ,  $\forall A \in \mathcal{K}$ ;
- $P(A \cup B) + P(A \cap B) = P(A) + P(B)$ ,  $\forall A, B \in \mathcal{K}$ .

O demonstrație a acestei propozitii se găsește în [12].

### Definitia 6

Fie  $P$  o probabilitate pe  $\mathcal{K}$  și  $B \in \mathcal{K}$ , cu  $P(B) > 0$ .

Se numeste probabilitatea condiționată de  $B$  a evenimentului  $A$ , notată  $P_B(A)$  sau  $P(A|B)$ , raportul

$$(1) \quad P(A|B) = \frac{P(A \cap B)}{P(B)} \quad (\text{Bayes}). \quad P_B \neq \emptyset$$

Se poate arăta că  $P(A|B)$  este o probabilitate.

Dacă  $A$  este independent de  $B$ , atunci

$$P(A|B) = P(A)$$

și din relația (1) se obține:

$$(2) \quad P(A \cap B) = P(A) \cdot P(B).$$

Acest fapt conduce la următoarea definiție mai generală:

### Definitia 7

Evenimentele  $A_1, A_2, \dots, A_n$  sînt statistic independente în totalitatea lor, dacă pentru orice sir

$$1 \leq i_1 < i_2 < \dots < i_r \leq n,$$

avem:

$$(3) \quad P\left(\prod_{j=1}^r B_{i_j}\right) = \prod_{j=1}^r P(B_{i_j}),$$

unde:

$$B_k = A_k \quad \text{sau} \quad B_k = CA_k; \quad k = \overline{1, n}.$$

165

## 1.4 12. Definiția variabilei aleatoare

### Definiția 8

Funcția  $\xi: E \rightarrow X \subset \mathbb{R}$  notată  $x = \xi(e)$ ;  $e \in E, x \in X$ , se numește variabilă aleatoare discretă, dacă codomeniul  $X = \{x_1, x_2, \dots, x_n\}$  este finit sau numărabil ( $n$ -natural finit sau  $n \in \mathbb{N}$ ) și

$$(4) \quad \{e \mid e \in E, x = \xi(e) = x_i\} \in \mathcal{K}; \quad i = \overline{1, n}.$$

Aceasta înseamnă că fiecărei valori  $x_i \in X$  îi este asociat cel puțin un eveniment din corpul  $\mathcal{K}$ .

Cunoașterea valorilor  $x_i \in X$ , pe care le poate lua variabila aleatoare  $x$ , și a mulțimii evenimentelor  $E$  nu este suficientă pentru precizarea variabilei aleatoare  $x$  deoarece realizarea unui anumit eveniment  $A \in E$  are loc cu o anumită probabilitate  $P(A)$ . Ținând seama de definiția 8 putem afirma că fiecărei valori  $x_k \in X$  îi este asociată o anumită probabilitate

$$p_k = P(x = x_k).$$

Prin această notăție se înțelege probabilitatea evenimentului

$$x = x_k.$$

Pentru a vedea modul în care se precizează concret o variabilă aleatoare vom considera un câmp de probabilitate  $(E, \mathcal{K}, P)$ , cu  $A_i \in \mathcal{K}$ ;  $i = \overline{1, n}$ , disjuncte două câte două, și  $X = \{x_1, x_2, \dots, x_n\}$ . O variabilă aleatoare  $x: E \rightarrow X$  se dă prin tabloul de repartiție

$$\begin{pmatrix} x_1 & x_2 & \dots & x_k & \dots & x_n \\ p_1 & p_2 & \dots & p_k & \dots & p_n \end{pmatrix}, \quad \mathcal{K}_x$$

unde:

$$(5) \quad p_k = P(x = x_k); \quad i = \overline{1, n},$$

cu proprietatea:

$$(6) \quad \sum_{k=1}^n p_k = \sum_{k=1}^n P(x = x_k) = P\left(\bigcup_{k=1}^n (x = x_k)\right) = P(E) = 1.$$

### Definiția 9

O aplicație  $\xi: E \rightarrow \mathbb{R}$  notată  $x = \xi(e)$ ;  $e \in E, x \in \mathbb{R}$ , se numește variabilă aleatoare continuă dacă codomeniul  $\xi(E)$  este o mulțime neamărabilă și pentru orice  $u \in \mathbb{R}$  are loc deplinerea continuă

Propoz 4.

$$a) P(u_1 \leq x < u_2) = P_x(u_2) - P_x(u_1)$$

$$\begin{aligned} P(u_1 \leq x < u_2) &= P((u_1 \leq x) \cap (x < u_2)) = \\ &= P(u_1 \leq x) + P(x < u_2) - \underbrace{P((u_1 \leq x) \cup (x < u_2))}_{=1} = \\ &= P(u_1 \leq x) + P_x(u_2) - 1. \end{aligned}$$

$$P((x < u_1) \cup (u_1 \leq x)) = 1$$

$$P(x < u_1) + P(u_1 \leq x) = 1$$

$$P(u_1 \leq x) = 1 - P_x(u_1)$$

$$P(u_1 \leq x < u_2) = 1 - P_x(u_1) + P_x(u_2) - 1.$$

$$\begin{aligned} &P(u_1 \leq x) - P((u_1 \leq x) \cup (x < u_1)) = \\ &= P(u_1 \leq x) - P((u_1 \leq x) \cup (x < u_1)) = \\ &= P(u_1 \leq x) - P(u_1 \leq x) - P(x < u_1) = -\underline{P(x < u_1)} \end{aligned}$$

$$(7) \quad \{e \mid e \in E, x = \xi(e) < u\} \in \mathcal{X}. \quad 166$$

Ca și în cazul variabilei aleatoare discrete, se poate afirma că fiecărui interval  $[u, u+du)$  îi este asociată o anumită probabilitate  $p_x du$ . Prin aceasta se înțelege că  $p_x du$  este probabilitatea ca  $x \in [u, u+du)$ , pentru  $x, u \in \mathbb{R}$ .

### Definiția 10

Se numește funcție de repartiție a variabilei aleatoare  $x = \xi(e)$  o funcție de forma

$$(8) \quad F_x(u) = P(x < u); \quad x, u \in \mathbb{R}.$$

### Propoziția 3

Funcția de repartiție are proprietățile:

$$a) \quad \forall u_1, u_2 \in \mathbb{R}, \quad u_2 > u_1, \quad \text{atunci } F_x(u_2) > F_x(u_1);$$

$$b) \quad 0 \leq F_x(u) \leq 1;$$

$$c) \quad \lim_{u \rightarrow -\infty} F_x(u) = 0; \quad \lim_{u \rightarrow \infty} F_x(u) = 1.$$

Întrucât funcția de repartiție este de forma (8), proprietățile de mai sus rezultă din propoziția 2.

Funcția de repartiție este o funcție monoton crescătoare și mărginită, care are cel mult o mulțime numărabilă de puncte de discontinuitate de prima speță.

### Propoziția 4

Dacă variabila aleatoare  $x = \xi(e)$  are funcția de repartiție  $F_x(u)$ , atunci, oricare ar fi  $u_1 < u_2$ , avem

$$a) \quad P(u_1 \leq x < u_2) = F_x(u_2) - F_x(u_1);$$

$$b) \quad P(u_1 < x < u_2) = F_x(u_2) - F_x(u_1) - P(x = u_1);$$

$$c) \quad P(u_1 < x \leq u_2) = F_x(u_2) - F_x(u_1) - P(x = u_1) + P(x = u_2);$$

$$d) \quad P(u_1 \leq x \leq u_2) = F_x(u_2) - F_x(u_1) + P(x = u_2).$$

Demonstratia este imediată pe baza definiției 10.

### Propoziția 5

Dacă  $u = a$  este un punct de continuitate al funcției de repartiție a variabilei aleatoare  $x = \xi(e)$ , atunci

$$(9) \quad P(x = a) = 0.$$

D. Avem

$$P(x = a) = \lim_{n \rightarrow \infty} P(a \leq x < a + \frac{1}{n}) = \lim_{n \rightarrow \infty} [F_x(a + \frac{1}{n}) - F_x(a)] = 0. \quad \text{Q.E.D.}$$

Din această propoziție rezultă că  $P(x=a) > 0$  numai dacă  $u=a$  este un punct de discontinuitate al funcției de repartiție.

### Definiția 11

Dacă există o funcție reală  $f_x(u)$ , integrabilă pe  $\mathbb{R}$ , astfel încât

$$(10) \quad F_x(u) = \int_{-\infty}^u f_x(u) du,$$

atunci  $f_x(u)$  se numește densitate de repartiție a variabilei aleatoare  $x = \xi(\omega)$ .

În cazul în care  $x = \xi(\omega)$  este o variabilă aleatoare discretă integrala din (10) se înlocuiește cu o sumă.

Dacă  $f_x(u)$  este continuă, atunci

$$(11) \quad f_x(u) = \frac{d}{du} F_x(u).$$

Ținând seama de proprietățile funcției de repartiție, rezultă

$$(12) \quad f_x(u) \geq 0; \quad u \in \mathbb{R},$$

$$(13) \quad P(a \leq x < b) = \int_a^b f_x(u) du; \quad \int_{-\infty}^{+\infty} f_x(u) du = 1.$$

În aplicații apar frecvent situații când intervin mai multe variabile aleatoare între care există sau nu anumite relații. Vom introduce în cele ce urmează o serie de noțiuni în cazul unui sistem de două variabile aleatoare.

Fie un câmp de probabilitate  $(E, \mathcal{K}, P)$  și două variabile aleatoare  $\xi: E \rightarrow \mathbb{R}$  și  $\eta: E \rightarrow \mathbb{R}$ , notate  $x = \xi(\omega)$  și  $y = \eta(\omega)$ .

### Definiția 12

Se numește funcție de repartiție bidimensională a variabilelor aleatoare  $x = \xi(\omega)$ ,  $y = \eta(\omega)$  o funcție de probabilitate de forma:

$$(14) \quad P_{x,y}(u,v) = P(x < u \text{ și } y < v); \quad x, y, u, v \in \mathbb{R}.$$

### Propoziția 6

Funcția de repartiție bidimensională are proprietățile:

$$a) \quad \forall u_1, u_2 \in \mathbb{R}, \quad u_2 > u_1, \text{ atunci } P_{x,y}(u_2, v) > P_{x,y}(u_1, v);$$

$\forall v_1, v_2 \in \mathcal{R}, v_2 > v_1$  atunci  $P_{x,y}(u, v_2) > P_{x,y}(u, v_1)$   
 b)  $0 \leq P_{x,y}(u, v) \leq 1$ ;  
 c)  $\lim_{u \rightarrow -\infty} P_{x,y}(u, v) = 0, \lim_{v \rightarrow -\infty} P_{x,y}(u, v) = 0$ ;  
 $\lim_{u \rightarrow \infty} P_{x,y}(u, v) = F_y(v), \lim_{v \rightarrow \infty} P_{x,y}(u, v) = F_x(u)$ ;  
 $\lim_{u \rightarrow \infty} \lim_{v \rightarrow \infty} P_{x,y}(u, v) = 1$ .

Funcția de repartiție bidimensională (în spațiul tridimensional - o suprafață) este pentru orice  $u$  fixat, respectiv pentru orice  $v$  fixat, o funcție monoton crescătoare de  $v$ , respectiv de  $u$ , care are cel mult o mulțime numărabilă de puncte de discontinuitate de prima speță.

Ținând seama de definiția 12, propozițiile 4, 5 se pot extinde, mutatis mutandis, și pentru cazul funcției de repartiție bidimensionale.

### Definiția 13

Dacă există o funcție reală  $p_{x,y}(u, v)$ , integrabilă pe  $\mathcal{R}^2$ , astfel încât:

$$(15) \quad P_{x,y}(u, v) = \int_{-\infty}^u \int_{-\infty}^v p_{x,y}(u, v) du dv,$$

atunci  $p_{x,y}(u, v)$  se numește densitate de repartiție bidimensională a variabilelor aleatoare  $x = \xi(\omega), y = \eta(\omega)$ .

Dacă  $p_{x,y}(u, v)$  este continuă, atunci

$$(16) \quad p_{x,y}(u, v) = \frac{\partial^2}{\partial u \partial v} P_{x,y}(u, v).$$

De asemenea ținând seama de proprietățile funcției de repartiție, rezultă că:

$$(17) \quad p_{x,y}(u, v) \geq 0; \quad u, v \in \mathcal{R};$$

$$(18) \quad P(a \leq x < b \text{ și } c \leq y < d) = \int_a^b \int_c^d p_{x,y}(u, v) du dv;$$

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} p_{x,y}(u, v) du dv = 1;$$

$$(19) \quad \int_{-\infty}^{\infty} p_{x,y}(u, v) du = f_y(v) = \lim_{u \rightarrow \infty} \frac{\partial}{\partial v} P_{x,y}(u, v);$$

de  $f_x$       de  $f_y$

$$(20) \int_{-\infty}^{\infty} p_{x,y}(u,v) dv = p_x(u) = \lim_{v \rightarrow \infty} \frac{d}{du} P_x(u).$$

#### Definiția 14

Variabilele aleatoare  $x = \xi(\omega)$  și  $y = \eta(\omega)$  se numesc statistice independente dacă:

$$(21) P_{x,y}(u,v) = P_x(u) \cdot P_y(v), \quad \text{sau}$$

$$(22) p_{x,y}(u,v) = p_x(u) \cdot p_y(v).$$

Este evident că această definiție decurge din relația (2), respectiv definiția 7 de la 1.1.

Noțiunile de funcție de repartiție și densitate de repartiție se pot extinde și la vectori aleatori, considerați ca sisteme de  $n$  variabile aleatoare.

### 1.3. Valori medii pe mulțime

Pentru caracterizarea globală a unei variabile aleatoare și pentru evidențierea și a altor legături, în afară de funcția de repartiție, se utilizează valorile medii ale variabilelor aleatoare. Valorile medii, se știe, au origine intuitiv-concretă (de exemplu media aritmetică ponderată etc). În cele ce urmează vom da o definiție mai generală a valorii medii, pe care o vom particulariza după necesități.

#### Definiția 15

Fie o funcție  $f: R \rightarrow R$ . Numărul

$$(23) M(f(x)) = \int_{-\infty}^{\infty} f(u) p_x(u) du,$$

în ipoteza că integrala este convergentă, este valoarea medie (pe mulțime) a funcției  $f$  în raport cu variabila aleatoare  $x = \xi(\omega)$ ;  $\xi: E \rightarrow R$ .

Din această definiție rezultă imediat că valoarea medie pe mulțime se bucură de proprietatea de liniaritate pe mulțimea funcțiilor reale  $f$ .

Conform definiției 15  $M\{f(x)\}$  este o medie ponderată, motiv pentru care se mai numește și valoare așteptată a funcției  $f(x) = f[\xi(\omega)]$ .



1.1  
 În cazul în care  $x = \xi(\omega)$  este o variabilă aleatoare discretă  
 integrala din (23) se înlocuiește cu o sumă.

### Definiția 16

Pentru  $f(u) = u^n$ ,  $n$ -număr natural, valoarea medie  
 se numește moment de ordinul  $n$  al variabilei aleatoare  
 $\xi$ , și se notează

$$(24) \quad \overset{\sim}{x}^n = \mathcal{M}_0(x^n) = \int_{-\infty}^{+\infty} u^n p_x(u) du.$$

Numărul

$$(25) \quad m_{x^n} = \sqrt[n]{\overset{\sim}{x}^n}$$

se numește medie de ordinul  $n$  a variabilei aleatoare  $\xi$ .

Pentru  $n=1$  se obține media liniară

$$(26) \quad \overset{\sim}{x} = \mathcal{M}_0(x) = \int_{-\infty}^{+\infty} u p_x(u) du = m_x.$$

Pentru  $n=2$  se obține momentul de ordinul 2

$$(27) \quad \overset{\sim}{x}^2 = \mathcal{M}_0(x^2) = \int_{-\infty}^{+\infty} u^2 p_x(u) du$$

și valoarea medie pătratică

$$(28) \quad m_{x^2} = \sqrt{\overset{\sim}{x}^2}$$

### Definiția 17

Pentru  $f(u) = (u - m_x)^n$  valoarea medie se numește  
 moment centrat de ordinul  $n$  al variabilei aleatoare  $\xi$ ,  
 și se notează

$$(29) \quad \overset{\sim}{x}^n = \mathcal{M}_0[(x - m_x)^n] = \int_{-\infty}^{+\infty} (u - m_x)^n p_x(u) du.$$

Pentru  $n=1$  se obține  $\overset{\sim}{x} = 0$ .

Pentru  $n=2$  se obține varianța variabilei aleatoare  $\xi$

$$(30) \quad \text{Var}(x) = \overset{\sim}{x}^2 = \int_{-\infty}^{+\infty} (u - m_x)^2 p_x(u) du$$

(sau dispersia variabilei aleatoare  $\xi$ ) și abaterea medie pătratică

$$(31) \quad \sigma_x = \sqrt{\text{Var}(x)}.$$

Evident între varianța și momentul de ordinul 2 exis-  
 tă relația:

$$(32) \quad \text{Var}(x) = \overset{\sim}{x}^2 - m_x^2.$$

care se obține imediat efectuând calculele în (30).

### Definiția 18

Fie o funcție  $f: \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$ . Numărul

$$(33) \quad \mathcal{M}_0(f(x, y)) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(u, v) p_{x, y}(u, v) du dv,$$

în ipoteza că integrala este convergentă, este valoarea medie (pe mulțime) a funcției  $f$  în raport cu variabilele aleatoare  $x = \xi(\omega)$  și  $y = \eta(\omega)$ ;  $\xi: \mathcal{E} \rightarrow \mathbb{R}$  și  $\eta: \mathcal{E} \rightarrow \mathbb{R}$

### Definiția 19

Pentru  $f(u, v) = u^{n_1} v^{n_2}$  valoarea medie se numește moment mixt de ordinul  $n_1, n_2$  al variabilelor aleatoare  $\xi, \eta$  și se notează

$$(34) \quad \overbrace{x^{n_1} y^{n_2}} = \mathcal{M}_0(x^{n_1} y^{n_2}) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} u^{n_1} v^{n_2} p_{x, y}(u, v) du dv.$$

Pentru  $n_1 = 1, n_2 = 0$ , respectiv  $n_1 = 0, n_2 = 1$  se obțin mediile aritmetice  $m_x, m_y$ , iar pentru  $n_1 = 2, n_2 = 0$ , respectiv  $n_1 = 0, n_2 = 2$  momentele  $\overbrace{x^2}, \overbrace{y^2}$ .

Pentru  $n_1 = n_2 = 1$  se obține intercorelația variabilelor aleatoare  $\xi, \eta$  care se notează

$$(35) \quad \overbrace{xy} = \mathcal{M}_0(xy) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} u \cdot v p_{x, y}(u, v) du dv.$$

### Definiția 20

Pentru  $f(u, v) = (u - m_x)^{n_1} (v - m_y)^{n_2}$  valoarea medie se numește moment centrat mixt de ordinul  $n_1, n_2$  al variabilelor aleatoare  $\xi, \eta$  și se notează:

$$(36) \quad \overbrace{x^{n_1} y^{n_2}} = \mathcal{M}_0[(x - m_x)^{n_1} (y - m_y)^{n_2}] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (u - m_x)^{n_1} (v - m_y)^{n_2} p_{x, y}(u, v) du dv.$$

Pentru  $n_1 = 2, n_2 = 0$ , respectiv  $n_1 = 0, n_2 = 2$  se obțin  $\text{Var}(x)$  și  $\text{Var}(y)$ .

Pentru  $n_1 = n_2 = 1$  se obține covarianța variabilelor aleatoare  $\xi, \eta$  și se notează

$$(37) \quad c_{xy} = \text{Cov}(x, y) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (u - m_x)(v - m_y) p_{x, y}(u, v) du dv.$$

<sup>x.2</sup> Efectuind calculele în integrandul din (37) și ținând seama de definiția (35) rezultă imediat.

$$(38) \quad C_{x,y} = \psi_{x,y} - m_x m_y.$$

### Definiția 21

Variabile aleatoare  $x = \xi(\omega)$ ,  $y = \eta(\omega)$  se numesc necorelate dacă și numai dacă

$$(39) \quad C_{x,y} = 0.$$

Din (37), (38) urmează că pentru variabilele aleatoare necorelate se poate scrie

$$(40) \quad \psi_{x,y} = m_x \cdot m_y.$$

### Propoziția 7

Dacă variabilele aleatoare  $x = \xi(\omega)$ ,  $y = \eta(\omega)$  sînt statistice independente atunci sînt necorelate.

D. Într-adevăr ținînd seama de (22), relația (37) devine

$$\begin{aligned} C_{x,y} &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (u - m_x)(v - m_y) f_x(u) f_y(v) du dv = \\ &= \int_{-\infty}^{+\infty} (u - m_x) f_x(u) du \int_{-\infty}^{+\infty} (v - m_y) f_y(v) dv = 0. \quad \text{Q.e.d.} \end{aligned}$$

Reciproca nu are loc în general. Se spune că independența statistică este mai tare ca necorelarea.

## 2. Procese stochastice

### 2.1. Definiția procesului stochastic

#### Definiția 1

Prin proces stochastic (semnal stochastic, semnal aleator), vom înțelege o variabilă aleatoare dependentă de timp

$\xi: E \times T \rightarrow \mathcal{R}$ , unde  $T \subseteq \mathcal{R}$  este mulțimea de timp, și notația  $x_t = \xi(\omega, t)$ .

Pentru  $t$  fixat  $x_t = \xi(\omega, t)$  este o variabilă aleatoare numită esantion al procesului stochastic

Pentru  $\omega$  fixat  $x(t) = \xi(\omega, t)$  este o funcție de timp numită realizare a procesului stochastic.




fig.1. Exemplu de proces stochastic

### Exem. pl

Fie o infinitate de termocupluri de același tip, situate în condiții identice. Tensiunile electromotoare  $x_k$ ,  $k \in \mathbb{N}$ , sînt reprezentate grafic în fig.1. Pentru  $k$  fixat,  $x_k(t)$  este o realizare a procesului stochastic.

Mulțimea realizărilor constituie procesul stochastic.

Pentru  $t = t_1$  fixat, valorile  $x_k(t_1)$ ,  $k \in \mathbb{N}$ , reprezintă un esanțon.

Mulțimea esanționelor constituie procesul stochastic.

### Definiția 2

Pentru un  $t$  fixat se definește funcția de repartiție a procesului stochastic  $x_t = \xi(t, t)$ .

$$(1) \quad P_x(u, t) = P(x_t < u); \quad x_t, u \in \mathbb{R}; \quad t \in \mathbb{R}$$

Dacă există o funcție reală  $p_x(u, t)$ , integrabilă pentru  $u \in \mathbb{R}$ , astfel încît

$$(2) \quad P_x(u, t) = \int_{-\infty}^u p_x(u, t) du,$$

atunci  $p_x(u, t)$  se numește densitate de repartiție a procesului stochastic  $x_t$ .

### Definiția 3

Un proces stochastic se numește determinist dacă orice realizare a sa se produce cu probabilitate

$$(3) \quad P = 1$$

### Definiția 4

Un proces stochastic se numește stationar în sens restrîns dacă funcția de repartiție a procesului stochastic  $x_t = \xi(t, t)$

este identică cu cea a procesului stochastic  $x_{t+\tau} = \xi(e, t+\tau)$ ,  
 pentru orice  $t, \tau \in \mathbb{R}$ , adică dacă

$$(4) \quad P_x(u, t) = P_x(u, t+\tau); \quad \forall t, \tau \in \mathbb{R}; u \in \mathbb{R}$$

sau dacă

$$(5) \quad p_x(u, t) = p_x(u, t+\tau); \quad \forall t, \tau \in \mathbb{R}; u \in \mathbb{R}.$$

Propoziția 1

Dacă un proces stochastic este staționar în sens restrins atunci funcția de repartiție sau densitatea de repartiție sînt independente de timp.

D. Într-adevăr din (4), (5), pentru  $\tau = -t$ , se obțin

$$(6) \quad P_x(u, t) = P_x(u, 0) \equiv P_x(u); \quad \forall t \in \mathbb{R},$$

$$(7) \quad p_x(u, t) = p_x(u, 0) \equiv p_x(u); \quad \forall t \in \mathbb{R}. \quad \text{Q.e.d.}$$

Ca urmare orice valoare medie pe mulțime a unui proces stochastic staționar în sens restrins nu depinde de timp.

De exemplu pentru momentul de ordinul  $n$  rezultă:

$$(8) \quad \overline{x^n_t} = M(x^n(t)) = \int_{-\infty}^{\infty} u^n p_x(u) du = \text{constant}.$$

Pentru două momente oarecare  $t_1, t_2 \in \mathbb{R}$ , pentru variabilele aleatoare  $x_{t_1} = \xi(e, t_1)$ ,  $x_{t_2} = \xi(e, t_2)$  se poate introduce noțiunea de repartiție bidimensională a procesului stochastic  $x_t = \xi(e, t)$ .

Definiția 5 În cazul a două procese aleate

funcția de repartiție bidimensională a procesului stochastic  $x_t = \xi(e, t)$  este o funcție de probabilitate, de forma

$$(9) \quad P_{x,x}(u_1, u_2, t_1, t_2) = P(x_{t_1} < u_1 \text{ și } x_{t_2} < u_2).$$

Dacă există o funcție reală  $p_{x,x}(u_1, u_2, t_1, t_2)$  integrabilă pentru  $u_1, u_2 \in \mathbb{R}$ , astfel încît

$$(10) \quad P_{x,x}(u_1, u_2, t_1, t_2) = \int_{-\infty}^{u_1} \int_{-\infty}^{u_2} p_{x,x}(u_1, u_2, t_1, t_2) du_1 du_2,$$

atunci  $p_{x,x}(u_1, u_2, t_1, t_2)$  se numește densitate de repartiție bidimensională a procesului stochastic.

În aceeași manieră se pot introduce funcțiile de repartiție și densitățile de repartiție de ordin superior.

$$P_{x,y}(u, v, t_1, t_2) = P(x_{t_1} < u \text{ și } y_{t_2} < v)$$

$$p_{x,y}(u, v, t_1, t_2) = \int_{-\infty}^u \int_{-\infty}^v p_{x,y}(u, v, t_1, t_2) du dv$$

<sup>x.2</sup>  
Propoziția 2 din capitolul 2 din cursul proceselor - aleatoare <sup>175</sup>

Dacă procesul stochastic  $x_t = \xi(e, t)$  este staționar în sens restrins, atunci funcția de repartiție bidimensională, respectiv densitatea de repartiție bidimensională depind de  $t_1 - t_2 = \tau$ .

D. Conform definiției (4), care se extinde în mod corespunzător, pentru orice  $t, \theta \in \mathcal{R}$  se pot scrie relațiile

$$P_{x,x}(u_1, u_2, t_1, t_2) = P_{x,x}(u_1, u_2, t_1 + \theta, t_2 + \theta)$$

$$p_{x,x}(u_1, u_2, t_1, t_2) = p_{x,x}(u_1, u_2, t_1 + \theta, t_2 + \theta)$$

Pentru  $\theta = -t_2$  și  $\tau = t_1 - t_2$  rezultă

(1)  $P_{x,x}(u_1, u_2, t_1, t_2) = P_{x,x}(u_1, u_2, t_1 - t_2, 0) = P_{x,x}(u_1, u_2, \tau)$

(2)  $p_{x,x}(u_1, u_2, t_1, t_2) = p_{x,x}(u_1, u_2, t_1 - t_2, 0) = p_{x,x}(u_1, u_2, \tau)$

Q.e.d.

2.2. Valori medii pe mulțime și temporale

Valorile medii pe mulțime, în general funcții de timp, se introduc ca și în cazul variabilelor aleatoare.

În cele ce urmează ne vom opri numai la valorile medii care joacă un rol deosebit în descrierea transferului proceselor stochastice prin sistemele dinamice.

Definiția 6

Funcția de autocovarianță  $C_{x,x}(t_1, t_2)$  a procesului stochastic  $x_t = \xi(e, t)$  se definește ca valoarea medie pe mulțime, de forma

(13) 
$$C_{x,x}(t_1, t_2) = \dot{x}_{t_1} \dot{x}_{t_2} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (u_1 - \dot{x}_{t_1})(u_2 - \dot{x}_{t_2}) p_{x,x}(u_1, u_2, t_1, t_2) du_1 du_2$$

Definiția 7

Funcția de covarianță  $C_{x,y}(t_1, t_2)$  a proceselor stochastice  $x_t = \xi(e, t)$  și  $y_t = \eta(e, t)$  se definește ca valoarea medie pe mulțime de forma

(14) 
$$C_{x,y}(t_1, t_2) = \dot{x}_{t_1} \dot{y}_{t_2} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (u - \dot{x}_{t_1})(v - \dot{y}_{t_2}) p_{x,y}(u, v, t_1, t_2) du dv$$

Indep  
stat

Auto  
covarianță

Int  
covarianță

- Stabilitate în sens strict.

$$P_{x,x}(u_1, u_2, t_1, t_2) = P_{x,x}(u_1, u_2, t_1 + \theta, t_2 + \theta)$$

$$P_{x,y}(u, v, t_1, t_2) = P_{x,y}(u, v, t_1 + \theta, t_2 + \theta)$$

- Independența statistică

$$P_{x,x}(u_1, u_2, t_1, t_2) = P_x(u_1, t_1) P_x(u_2, t_2)$$

$$P_{x,y}(u, v, t_1, t_2) = P_x(u, t_1) P_y(v, t_2)$$

- Funcția de autocorelație

$$\varphi_{x,x}(t_1, t_2) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} u_1 u_2 p_{x,x}(u_1, u_2, t_1, t_2) du_1 du_2$$

- Funcția de intercorelație

$$\varphi_{x,y}(t_1, t_2) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} uv p_{x,y}(u, v, t_1, t_2) du dv$$

<sup>x-2</sup> Evident, ținând seama de (1.38) putem scrie și în aceste cazuri:

$$(15) \quad R_{x,x}(t_1, t_2) = \Psi_{x,x}(t_1, t_2) - \overset{\text{m.m.}}{x_{t_1}} \cdot \overset{\text{m.m.}}{x_{t_2}},$$

$$(16) \quad R_{x,y}(t_1, t_2) = \Psi_{x,y}(t_1, t_2) - \overset{\text{m.m.}}{x_{t_1}} \cdot \overset{\text{m.m.}}{y_{t_2}},$$

în care  $\Psi_{x,x}(t_1, t_2)$  și  $\Psi_{x,y}(t_1, t_2)$  sînt funcțiile de auto- și intercorelație ale proceselor  $x_t = \xi(e, t)$  și  $y_t = \eta(e, t)$ , v. (1.35).

### Propoziția 3

Dacă procesele stochastice  $x_t = \xi(e, t)$ ,  $y_t = \eta(e, t)$  sînt staționare în sens restrîns, atunci funcțiile de auto- și intercorelație depind de  $\tau = t_1 - t_2$ .

D. Într-adevăr, din (12), (13), (14) rezultă

$$(17) \quad \Psi_{x,x}(t_1, t_2) = \Psi_{x,x}(t_1 - t_2, 0) = \Psi_{x,x}(\tau),$$

$$(18) \quad \Psi_{x,y}(t_1, t_2) = \Psi_{x,y}(t_1 - t_2, 0) = \Psi_{x,y}(\tau). \quad \text{Q.e.d.}$$

### Definiția 8

Un proces stochastic  $x_t = \xi(e, t)$  se numește staționar în sens larg dacă

$$(19) \quad \overset{\text{m.m.}}{x_t} = \text{constant}$$

$$(20) \quad \Psi_{x,x}(t_1, t_2) = \Psi_{x,x}(\tau) \quad ; \quad \tau = t_1 - t_2.$$

### Propoziția 4

Dacă un proces stochastic  $x_t = \xi(t)$  este staționar în sens restrîns, atunci este staționar în sens larg.

D. Într-adevăr din (8), pentru  $n=1$  se obține (19), iar conform propoziției 3 relația (20) are loc. Q.e.d.

Reciproca acestei propoziții nu are loc în general. Se spune că staționaritatea în sens restrîns este mai tare ca staționaritatea în sens larg.

În afara valorilor medii pe mulțime, pentru caracterizarea oricărei realizări a unui proces stochastic se utilizează mediile temporale.

### Definiția 9

Media temporală de ordinul  $n$  a realizării

$x(t)$  se definește prin

$$(21) \quad \overline{x^n(t)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x^n(t) dt,$$

*Necesitate*



x.2 1ff

Definiția 10 (ipoteza ergodică)

Un proces stocastic staționar  $x_t = \xi(e, t)$  se numește ergodic dacă evenimentul

$$(22) \quad \overline{\lim}_n x_t^n = \overline{x^n(t)}$$

are loc cu probabilitate  $P=1$  (eveniment sigur).

În virtutea ipotezei ergodice rezultă că orice realizare  $x(t); t \in \mathbb{R}$ , a unui proces stocastic staționar și ergodic, poate fi utilizat pentru caracterizarea procesului în sine.

Ipoteza ergodică are o deosebită însemnătate practică deoarece cunoscând o singură realizare a unui proces stocastic pe o durată de timp suficient de mare se pot trage concluzii asupra procesului în întregime. Verificarea practică a ipotezei ergodice este dificilă deoarece atât la media pe mulțime cât și la media temporală, limitele de integrare, în condiții concrete nu pot fi decât finite.

*Aplic*

### 2.3. Procesul stocastic gaussian

Un proces stocastic gaussian, staționar în sens restrins are densitatea de repartiție de forma

$$p_x(u) = \frac{1}{\sqrt{2\pi} \sigma_x} \cdot e^{-\frac{(u-m_x)^2}{2\sigma_x^2}}; m_x, \sigma_x - \text{constante.}$$

Media liniară a procesului este

$$\overline{x(t)} = \frac{1}{\sqrt{2\pi} \sigma_x} \int_{-\infty}^{+\infty} u \cdot e^{-\frac{(u-m_x)^2}{2\sigma_x^2}} du = m_x.$$

Varianța procesului este

$$\overline{(x(t)-m_x)^2} = \frac{1}{\sqrt{2\pi} \sigma_x} \int_{-\infty}^{+\infty} (u-m_x)^2 \cdot e^{-\frac{(u-m_x)^2}{2\sigma_x^2}} du = \sigma_x^2$$

După cum se poate observa, un proces stocastic staționar normal este complet caracterizat de media liniară  $m_x$  și dispersia  $\sigma_x^2$ . Aceste două valori se pot determina relativ ușor și pe cale experimentală.

Un proces stocastic normal, dacă este staționar în

sens larg este staționar și în sens restrins. Verificarea acestei afirmații este imediată. Așadar în acest caz are loc reciproca propoziției 4

Densitatea de repartiție bidimensională a unui proces stocastic staționar normal, de medie aritmetică nulă, are expresia:

$$p_{x,x}(u_1, u_2, \tau) = \frac{1}{2\pi \sigma_x^2 \sqrt{1 - \rho^2(\tau)}} \cdot e^{-\frac{1}{2\sigma_x^2(1-\rho^2(\tau))} [u_1^2 - 2\rho(\tau)u_1u_2 + u_2^2]},$$

unde

$$\rho(\tau) = \frac{1}{\sigma_x^2} \text{Cov}[x(t), x(t+\tau)] = \frac{1}{\sigma_x^2} [\varphi_{x,x}(\tau) - m_x^2] = \frac{\varphi_{x,x}(\tau)}{\sigma_x^2}$$

este covarianța normată. În ipoteza că procesul este ergodic  $m_x, \sigma_x, \varphi_{x,x}(\tau)$ , respectiv  $\rho(\tau)$  se pot determina utilizând o singură realizare a procesului cu ajutorul mediilor temporale.

Foarte multe procese stochastice care se întâlnesc în aplicații se încadrează în categoria proceselor gaussiene.

### 3. Corelația temporală

#### 3.1. Funcția de autocorelație temporală

##### Definiția 1

Funcția de autocorelație temporală a unei realizări  $x(t)$  a unui proces stocastic se definește prin

$$(1) \quad \gamma_{x,x}(\tau) = \overline{x(t)x(t+\tau)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t)x(t+\tau) dt.$$

Această funcție pune în evidență dependența dintre  $x(t)$  și varianța ei decolată în timp  $x(t \pm \tau)$  - fig 2. - pentru orice  $t, \tau \in \mathcal{R}$ .

Funcția de autocorelație temporală este o noțiune deosebit de utilă, atât în studiul teoretic cât și în studiul experimental al proceselor stochastice, în special în cazul proceselor staționare ergodice. Totuși pentru funcția de autocorelație temporală a unei realizări oarecare  $x(t)$  nu se poate preciza o expresie analitică, deoarece  $x(t)$  nu este

x.3  
apriorie cunoscut.

119




fig 2 - Exemplu de realizare a unui proces stocastic și o varianță întârziată

După producerea realizării  $x(t)$  funcția de autocorelație temporală poate fi măsurată, utilizând corelatoare, a căror funcționare se bazează pe relația (1).

Însușirile

Spre deosebire de funcția de autocorelație temporală, funcția de autocorelație obținută ca medie pe mulțime se poate determina analitic, dacă se cunoaște densitatea de repartiție a procesului.

Dacă se admite ipoteza ergodică, atunci avem:

$$(2) \quad k_{x,x}(\tau) = \rho_{x,x}(\tau); \quad \tau \in \mathbb{R}.$$

Este evident că ipoteza ergodică aduce o serie de simplificări. Din punct de vedere teoretic există o singură funcție de autocorelație  $k_{x,x}(\tau)$  care poate fi definită în două moduri: ca medie pe mulțime și ca medie temporală; în funcție de necesități și de tratarea matematică se utilizează oricare din cele două definiții.

Din punct de vedere experimental, se poate investiga un proces stocastic prin analiza pe o durată suficient de mare de timp a unui număr redus de realizări ale procesului stocastic. Rezultatele obținute caracterizează întregul proces stocastic.

### Teorema 1

Funcția de autocorelație temporală are următoarele proprietăți

$$(3) \quad k_{x,x}(\tau) = k_{x,x}(-\tau); \quad \forall \tau \in \mathbb{R};$$

$$(4) \quad k_{x,x}(0) = \overline{x^2(t)};$$

$$(5) \quad \lim_{\tau \rightarrow \infty} h_{x,x}(\tau) = (\overline{x(t)})^2;$$

$$(6) \quad |h_{x,x}(\tau)| \leq h_{x,x}(0); \quad \forall \tau \in \mathbb{R}.$$

D. Proprietatea (3) rezultă imediat din (1) dacă se schimbă  $\tau$  cu  $-\tau$ . Proprietatea (4) se obține din (1) pentru  $\tau=0$ . Pentru a demonstra relația (5) vom ține seama de faptul că pentru  $\tau$  foarte mare  $x(t)$  și  $x(t+\tau)$  sînt statistic independente. În aceste condiții

$$p_{x,x}(u_1, u_2, t_1, t_2) = p_x(u_1, t_1) p_x(u_2, t_2); \quad t_1 - t_2 = \tau,$$

și deci

$$\begin{aligned} \lim_{\tau \rightarrow \infty} h_{x,x}(\tau) &= \lim_{\tau \rightarrow \infty} \varphi_{x,x}(\tau) = \lim_{\tau \rightarrow \infty} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} u_1 u_2 p_{x,x}(u_1, u_2, t_1, t_2) du_1 du_2 \\ &= \int_{-\infty}^{+\infty} u_1 p_x(u_1, t_1) du_1 \int_{-\infty}^{+\infty} u_2 p_x(u_2, t_2) du_2 = (\overline{x(t_1)})^2. \end{aligned}$$

Pentru a demonstra relația (6) se pornește de la inegalitatea evidentă

$$[x(t) - x(t \pm \tau)]^2 \geq 0.$$

Dezvoltînd și trecînd la medii temporale se scriu succesiv inegalitățile:

$$-x^2(t) - x^2(t \pm \tau) \leq 2x(t)x(t \pm \tau) \leq x^2(t) + x^2(t \pm \tau)$$

$$-\overline{x^2(t)} - \overline{x^2(t \pm \tau)} \leq 2\overline{x(t)x(t \pm \tau)} \leq \overline{x^2(t)} + \overline{x^2(t \pm \tau)}$$

$$-2\overline{x^2(t)} \leq 2h_{x,x}(\tau) \leq 2\overline{x^2(t)}.$$

Din ultima relație rezultă imediat inegalitatea (6). Q.e.d.




fig 3 - Exemplu de funcție de autocorelație.

Ca exemplu s-a considerat graficul unei funcții de autocorelație în fig 3.

Panta  $\left. \frac{dh_{x,x}(\tau)}{d\tau} \right|_{\tau=0}$  este o mărură a coerenței interne

181

$x$ -3  
 a procesului stochastic. Timpul  $\tau_0$  (subtangentă la  $\bar{c}=0$ ) - fig 3- se numește timp de coerență. Valori  $\tau_0$  mari indică dependențe între  $x(t)$  și  $x(t \pm \tau)$ , respectiv o tendință de conservare. Valori  $\tau_0$  mici indică o slabă coerență, respectiv o slabă dependență între  $x(t)$  și  $x(t \pm \tau)$ .

Din forma și valorile funcției de autocorelație nu se pot trage concluzii asupra desfășurării în timp a realizării  $x(t)$ , deoarece funcția de autocorelație este o medie pe multime sau medie temporală și ea are un caracter global.

### 3.2. Funcția de intercorelație temporală

#### Definiția 2

Funcția de intercorelație temporală a realizărilor  $x(t)$  și  $y(t)$  ale proceselor stochastice  $x(t) = \xi(e, t)$  și  $y(t) = \eta(e, t)$  se definește prin:

$$(7) \quad k_{x,y}(\tau) = \overline{x(t)y(t+\tau)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t)y(t+\tau) dt,$$

sau

$$(8) \quad k_{x,y}(\tau) = \overline{x(t-\tau)y(t)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t-\tau)y(t) dt,$$

respectiv

$$(9) \quad k_{y,x}(\tau) = \overline{y(t)x(t+\tau)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T y(t)x(t+\tau) dt,$$

sau

$$(10) \quad k_{y,x}(\tau) = \overline{y(t-\tau)x(t)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T y(t-\tau)x(t) dt.$$

Funcția de intercorelație temporală a realizărilor  $x(t)$  și  $y(t)$  este o măsură a dependenței statistice dintre acestea. Dacă se admite ipoteza ergodică atunci

$$(11) \quad k_{x,y}(\tau) = \psi_{x,y}(\tau); \quad \tau \in \mathbb{R}.$$

#### Teorema 2

Funcția de intercorelație temporală are următoarele proprietăți:

$$(12) \quad k_{x,y}(\tau) = k_{y,x}(-\tau); \quad \forall \tau \in \mathbb{R};$$

$$(13) \quad k_{x,y}(0) = \overline{x(t)y(t)};$$

$$(14) \quad \lim_{\tau \rightarrow \infty} r_{x,y}(\tau) = \overline{x(t)} \cdot \overline{y(t)} ;$$

$$(15) \quad |r_{x,y}(\tau)| \leq \frac{1}{2} (\overline{x^2(t)} + \overline{y^2(t)}) ; \quad \forall \tau \in \mathbb{R}.$$

Demonstrația relațiilor (12)-(15) se face ca la teorema 1.

### 3.3. Cazul semnalelor deterministe

Funcția de autocorelație sau de intercorelație se poate utiliza și în cazul semnalelor deterministe, a căror evoluție în timp este aprioric cunoscută.

Pentru un semnal  $x(t)$ , periodic, funcția de autocorelație se definește prin

$$(16) \quad r_{x,x}(\tau) = \frac{1}{2T_0} \int_{-T_0}^{T_0} x(t) x(t \pm \tau) dt ,$$

unde  $T_0$  este perioada semnalului.

Pentru un semnal sinusoidal

$$x(t) = X_m \sin(\omega_0 t - \varphi) , \quad \omega_0 = 2\pi / T_0 = \frac{2\pi}{T_0}$$

putem scrie

$$\begin{aligned} r_{x,x}(\tau) &= \frac{X_m^2}{2T_0} \int_{-T_0}^{T_0} \sin(\omega_0 t - \varphi) \sin(\omega_0 t \pm \omega_0 \tau - \varphi) dt = \\ &= \frac{X_m^2}{4\pi} \int_{-2\pi}^{2\pi} \sin(\omega_0 t - \varphi) \sin(\omega_0 t \pm \omega_0 \tau - \varphi) d(\omega_0 t) = \frac{1}{2} X_m^2 \cos \omega_0 \tau . \end{aligned}$$

Se remarcă faptul că funcția de autocorelație conține informații asupra amplitudinii și frecvenței semnalului  $x(t)$  prin faptul că  $r_{x,x}(\tau)$  este periodică de aceeași perioadă cu  $x(t)$ , dar nu conține informații privitoare la fază.

Funcția de intercorelație a două semnale de aceeași perioadă  $T_0$

$$x(t) = X_m \sin(\omega_0 t - \alpha) ,$$

$$y(t) = Y_m \sin(\omega_0 t - \beta)$$

este

$$\begin{aligned} r_{x,y}(\tau) &= \frac{X_m Y_m}{2T_0} \int_{-T_0}^{T_0} \sin(\omega_0 t - \alpha) \sin[\omega_0(t + \tau) - \beta] dt = \\ &= \frac{1}{2} X_m Y_m \cos(\omega_0 \tau - \varphi) ; \quad \varphi = \alpha - \beta . \end{aligned}$$

În acest caz funcția de intercorelație conține informații

asupra defazajului între semnalele  $x(t)$  și  $y(t)$ .

Faptul că periodicitatea semnalelor  $x(t)$  și  $y(t)$  se conservează în funcțiile de auto- și intercorelație ne permite să tragem următoarea concluzie foarte importantă: dacă procesele stochastice  $x_t$ ,  $y_t$  conțin și funcții periodice deterministe, atunci acest fenomen de periodicitate se regăsește și în funcțiile de auto- și intercorelație.

Pentru un semnal determinist aperiodic  $x(t)$ , funcția de autocorelație se definește prin

$$(17) \quad k_{x,x}(\tau) = \int_{-\infty}^{+\infty} x(t) x(t \pm \tau) dt,$$

cu condiția ca  $x(t)$  să fie absolut integrabilă.

Se remarcă faptul că în timp ce funcția de autocorelație a proceselor stochastice și a funcțiilor periodice, dimensional, reprezintă o „putere”, cea a funcțiilor deterministe aperiodice reprezintă o „energie”.

Pentru

$$x(t) = X_0 e^{-\alpha t} \delta(t),$$

avem

$$\begin{aligned} k_{x,x}(\tau) &= X_0^2 \int_{-\infty}^{+\infty} e^{-\alpha t} \delta(t) \cdot e^{-\alpha(t-\tau)} \delta(t-\tau) dt = \\ &= X_0^2 e^{\alpha \tau} \int_{\tau}^{+\infty} e^{-2\alpha t} dt = \frac{X_0^2}{2\alpha} e^{-\alpha \tau}; \quad \tau \geq 0. \end{aligned}$$

### 3.4. Relații „intrare-ieșire”

Ultima problemă pe care o vom examina în acest subcapitol este aceea a transferului proceselor stochastice staționare ergodice prin elemente ratiionale de transfer.

#### Teorema 3

Dacă pentru realizările  $x(t)$ ,  $y(t)$ ,  $z(t)$  avem

$$(18) \quad z(t) = x(t) \pm y(t),$$

atunci

$$(19) \quad \overline{z(t)} = \overline{x(t)} \pm \overline{y(t)},$$

$$(20) \quad k_{z,z}(\tau) = k_{x,x}(\tau) + k_{y,y}(\tau) \pm k_{x,y}(\tau) \pm k_{y,x}(\tau).$$

D. Relația (19) rezultă imediat în virtutea liniarității mediei pe mulțime sau temporale.

Pentru a demonstra relația (20) se scrie:

$$\begin{aligned} k_{z,z}(\tau) &= \overline{z(t)z(t+\tau)} = \overline{[x(t)+y(t)][x(t+\tau)+y(t+\tau)]} = \\ &= \overline{x(t)x(t+\tau)} + \overline{y(t)y(t+\tau)} + \overline{x(t)y(t+\tau)} + \overline{y(t)x(t+\tau)} = \\ &= k_{x,x}(\tau) + k_{y,y}(\tau) + k_{x,y}(\tau) + k_{y,x}(\tau). \quad \text{Q.e.d.} \end{aligned}$$

Dacă procesele stochastice  $x_t = \xi(e, t)$  și  $y_t = \eta(e, t)$  sînt statistic independente sau necorelate, atunci

$$(21) \quad \text{Cov}(x_t, y_t) = 0$$

și

$$(22) \quad k_{x,y}(\tau) = k_{y,x}(\tau) = \overline{x(t)} \cdot \overline{y(t)}.$$

În aceste condiții relația (20) devine

$$(23) \quad k_{z,z}(\tau) = k_{x,x}(\tau) + k_{y,y}(\tau) + 2\overline{x(t)} \cdot \overline{y(t)}.$$

Dacă cel puțin unul din procese are valoare medie nulă, adică

$$(24) \quad \overline{x(t)} = 0 \quad \text{sau} \quad \overline{y(t)} = 0,$$

atunci relația (23) devine

$$(25) \quad k_{z,z}(\tau) = k_{x,x}(\tau) + k_{y,y}(\tau).$$

În cazul unui amestec de semnale - unul determinist periodic de valoare medie nulă și celălalt stochastic, în ipoteza că sînt statistic independente, relația (25) rămîne valabilă.

Pentru

$$x(t) = X_m \sin(\omega_0 t - \varphi)$$

și  $y$  - stochastic, avem

$$k_{z,z}(\tau) = \frac{1}{2} X_m^2 \cos \omega_0 \tau + k_{y,y}(\tau).$$

Tinînd seama de proprietățile funcției de autocorelație  $k_{y,y}(\tau)$  și onume că pentru  $\tau \rightarrow \infty$ ,  $k_{y,y}(\tau) \rightarrow (\overline{y(t)})^2$ , rezultă că pentru  $\tau$  suficient de mare avem

$$k_{z,z}(\tau) \cong \frac{1}{2} X_m^2 \cos \omega_0 \tau + (\overline{y(t)})^2.$$

Se trage concluzia că dacă un semnal stochastic conține o componentă periodică deterministă, aceasta este scoasă în evidență de funcția sa de autocorelație.



Fie un R-element descris de produsul de convoluție

$$(26) \quad y(t) = \int_{-\infty}^{+\infty} g(\theta) u(t-\theta) d\theta = \int_{-\infty}^{+\infty} g(t-\theta) u(\theta) d\theta,$$

unde  $g(t)$  este răspunsul la impuls al R-elementului, considerat pentru generalitate necausal.

Vom presupune că  $u(t)$  este o realizare al unui proces stohastic. Se poate arăta că în acest caz și  $y(t)$  este o realizare a unui proces stohastic.

#### Teorema 4

Între realizările  $u(t)$  și  $y(t)$  de intrării și ieșirii unui R-element există următoarele relații

$$(27) \quad \overline{y(t)} = \overline{u(t)} \int_{-\infty}^{+\infty} g(\theta) d\theta,$$

$$(28) \quad k_{u,y}(\tau) = \int_{-\infty}^{+\infty} g(\tau-\theta) k_{u,u}(\theta) d\theta = \int_{-\infty}^{+\infty} g(\theta) k_{u,u}(\tau-\theta) d\theta,$$

$$(29) \quad k_{y,y}(\tau) = \int_{-\infty}^{+\infty} g(\theta) \int_{-\infty}^{+\infty} g(\eta) k_{u,u}(\tau+\theta-\eta) d\eta d\theta,$$

$$(30) \quad k_{y,y}(\tau) = \int_{-\infty}^{+\infty} g(\tau-\theta) k_{y,u}(\theta) d\theta = \int_{-\infty}^{+\infty} g(\theta) k_{y,u}(\tau-\theta) d\theta.$$

D. Pentru a demonstra relația (27) se scrie

$$\begin{aligned} \overline{y(t)} &= \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T y(t) dt = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T \int_{-\infty}^{+\infty} g(\theta) u(t-\theta) d\theta dt = \\ &= \int_{-\infty}^{+\infty} g(\theta) \left( \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T u(t-\theta) dt \right) d\theta = \overline{u(t)} \int_{-\infty}^{+\infty} g(\theta) d\theta. \end{aligned}$$

Vom demonstra acum relațiile (28), (29).

$$\begin{aligned} k_{u,y}(\tau) &= \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T u(t-\tau) y(t) dt = \\ &= \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T u(t-\tau) \int_{-\infty}^{+\infty} g(\theta') u(t-\theta') d\theta' dt = \\ &= \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T \int_{-\infty}^{+\infty} g(\tau-\theta) u(t-\tau) u(t-\tau+\theta) d\theta dt = \end{aligned}$$

$$\begin{aligned} (\tau-\theta'=\theta, \theta'=\tau-\theta, d\theta'=-d\theta, \theta'=-\infty, \theta'=\infty, \theta'=\infty, \theta'=-\infty) \\ = \int_{-\infty}^{+\infty} \left\{ g(\tau-\theta) \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T-\tau}^{\tau-\tau} u(t) u(t+\theta) dt \right\} d\theta = \end{aligned}$$

$$\begin{aligned}
 & \text{14.} \quad \text{186} \\
 & (t-z=t', \quad dt=dt', \quad t=-T, \quad t'=-T-z, \quad t=T, \quad t'=T-z) \\
 & = \int_{-\infty}^{+\infty} g(z-\theta) k_{u,u}(\theta) d\theta.
 \end{aligned}$$

$$\begin{aligned}
 k_{y,y}(z) &= \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T y(t-z) y(t) dt = \\
 &= \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T \left\{ \int_{-\infty}^{+\infty} g(\theta) u(t-z-\theta) d\theta \int_{-\infty}^{+\infty} g(\eta) u(t-\eta) d\eta \right\} dt = \\
 &= \int_{-\infty}^{+\infty} g(\theta) \int_{-\infty}^{+\infty} g(\eta) \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T u(t-z-\theta) u(t-\eta) dt d\eta d\theta = \\
 &= \int_{-\infty}^{+\infty} g(\theta) \int_{-\infty}^{+\infty} g(\eta) k_{u,u}(z+\theta-\eta) d\eta d\theta.
 \end{aligned}$$

Pentru a demonstra (30) vom pune relatie (28) sub forma

$$\begin{aligned}
 & k_{u,y}(z) = \int_{-\infty}^{+\infty} g(\eta) k_{u,u}(z-\eta) d\eta, \\
 & \text{sau} \\
 & k_{u,y}(z+\theta) = \int_{-\infty}^{+\infty} g(\eta) k_{u,u}(z+\theta-\eta) d\eta; \quad \forall \theta \in \mathcal{R}.
 \end{aligned}$$

Ținând seama de ultima ecuație, (29) devine

$$(31) \quad k_{y,y}(z) = \int_{-\infty}^{+\infty} g(\theta) k_{u,y}(z+\theta) d\theta.$$

Dar  $k_{u,y}(z) = k_{y,u}(-z)$  și  $k_{y,y}(z) = k_{y,y}(-z)$  astfel că din (31) rezultă imediat (30). G.e.d.

În cazul în care semnalele  $u(t)$  și  $y(t)$  sînt cauzale, iar  $\mathcal{R}$ -elementul realist, ecuațiile (27)-(30) rămîn valabile, cu modificările adecvate ale limitelor de integrare.

#### 4. Metoda frecvențială

Studiul proceselor stochastice în domeniul frecvențelor este practic o necesitate avînd în vedere larga utilizare a metodei frecvențiale în teoria sistemelor. La aplicarea metodei frecvențiale trebuie să se aibă în vedere faptul că nu se dispune de o expresie analitică pentru o realizare  $x(t)$  a unui proces stochastic. Ca urmare nu se poate determina densitatea spectrală  $X(f, \omega)$  sau densitatea de amplitudine  $|X(f, \omega)|$ , ca în cazul semnalelor deterministe. Se poate utiliza însă transformata Fourier o fun-

x4 187

cărei de autocorelație pentru caracterizarea spectrală a realizării  $x(t)$ . Este clar de la bun început că cu ajutorul acestei transformate nu se pot face aprecieri asupra spectrului de amplitudine a realizării  $x(t)$ , deoarece funcția de autocorelație are caracter global (este o valoare medie).

Pentru ca transformata Fourier a realizării  $x(t)$  să existe trebuie ca  $x(t)$  să fie absolut integrabil. Având în vedere faptul că în general  $\overline{x(t)} \neq 0$ , rezultă că  $x(t)$  nu admite o transformată Fourier. O posibilitate de abordare matematică a acestei probleme o constituie ipoteza lui Wiener că media pătratică temporală

$$(1) \quad \overline{x^2(t)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x^2(t) dt$$

există și este finită. Aceasta revine la ipoteza că  $x(t)$  este de pătrat integrabil. Aceasta ipoteză este mai slabă ca absoluta integrabilitate, iar transformata care se poate obține se numește transformată Fourier-Plancherel (vezi anexa C.6).

#### 4.1. Densitatea spectrală de putere

Pentru a introduce această noțiune vom considera o realizare  $x(t)$  a unui proces stohastic și funcția trunchiată temporal

$$(2) \quad x_T(t) = x(t)[\delta(t+T) - \delta(t-T)]; \quad T \in \mathbb{R}$$

unde  $\delta(t)$  este funcția treaptă unitară.

Transformata Fourier a funcției (2) este

$$(3) \quad X_T(j\omega) = \int_{-\infty}^{\infty} x_T(t) e^{-j\omega t} dt = \int_{-T}^T x(t) e^{-j\omega t} dt; \quad x_T(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X_T(j\omega) e^{j\omega t} d\omega$$

Pentru a calcula media pătratică temporală - relația (1), procedăm după cum urmează

$$(4) \quad \overline{x^2(t)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t) \left[ \frac{1}{2\pi} \int_{-\infty}^{\infty} X_T(j\omega) e^{j\omega t} d\omega \right] dt =$$

$$= \lim_{T \rightarrow \infty} \frac{1}{2T} \cdot \frac{1}{2\pi} \int_{-\infty}^{\infty} X_T(j\omega) \left[ \int_{-T}^T x(t) e^{j\omega t} dt \right] d\omega =$$

x4. 198

$$= \frac{1}{2\pi} \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-\infty}^{+\infty} X_T(j\omega) X_T(-j\omega) d\omega =$$

$$= \frac{1}{2\pi} \int_{-\infty}^{+\infty} \lim_{T \rightarrow \infty} \frac{X_T(j\omega) X_T(-j\omega)}{2T} d\omega = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \lim_{T \rightarrow \infty} \frac{|X_T(j\omega)|^2}{2T} d\omega.$$

### Definitia 1

Functia

$$(5) \quad S_{x,x}(j\omega) = \lim_{T \rightarrow \infty} \frac{|X_T(j\omega)|^2}{2T}$$

se numeste densitate spectrala de putere a procesului stochastic stationar si ergodic  $x_t = \xi(e,t)$ .

Denumirea este justificata prin faptul ca  $S_{x,x}(j\omega)$  depinde de densitatea spectrala  $X_T(j\omega)$  si din punct de vedere dimensional  $S_{x,x}(j\omega)$  este o „putere”.

### Teorema 1 (Wiener-Hincin)

Densitatea spectrala de putere  $S_{x,x}(j\omega)$  este transformata Fourier-Plancherel a functiei de autocorelatie  $k_{x,x}(\tau)$ .

D. Asadar trebuie demonstrat ca

$$(6) \quad S_{x,x}(j\omega) = \int_{-\infty}^{+\infty} k_{x,x}(\tau) \cdot e^{-j\omega\tau} d\tau$$

in ipoteza ca  $\overline{x^2(t)}$  exista si este finita.

In conformitate cu definitia (5) putem scrie

$$S_{x,x}(j\omega) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t_1) e^{-j\omega t_1} dt_1 \int_{-T}^T x(t_2) e^{j\omega t_2} dt_2 =$$

$$= \int_{-\infty}^{+\infty} \left\{ \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t_1) x(t_2) e^{-j\omega(t_1-t_2)} dt_2 \right\} dt_1 =$$

$$(t_1 - t_2 = \tau, dt_1 = d\tau)$$

$$= \int_{-\infty}^{+\infty} \left\{ \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t_2) x(t_2 + \tau) dt_2 \right\} e^{-j\omega\tau} d\tau =$$

$$= \int_{-\infty}^{+\infty} k_{x,x}(\tau) \cdot e^{-j\omega\tau} d\tau \quad \text{Q. e. d.}$$

### Teorema 2

Densitatea spectrala de putere are urmatoarele proprietati

- $S_{x,x}(j\omega)$  este functie reala de argument  $\omega^2$ ;
- $S_{x,x}(j\omega)$  este functie para si nenegativa;

199.

$$c) \quad k_{x,x}(0) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S_{x,x}(j\omega) d\omega.$$

D. Faptul că  $S_{x,x}(j\omega)$  este o funcție reală de argument  $\omega^2$  rezultă imediat din definiția (5). Într-adevăr, presupunând că  $X_T(j\omega)$  este o fracție rațională de forma

$$(7) \quad X_T(j\omega) = K \frac{\prod_{i=1}^m (j\omega - z_i)}{\prod_{k=1}^n (j\omega - p_k)}, \quad m, n \in \mathbb{N},$$

unde  $z_i$  și  $p_k$  sînt zerourile și poliile reali sau complex conjugate ai funcției  $X_T(j\omega)$ , putem scrie

$$(8) \quad X_T(j\omega) X_T(-j\omega) = K^2 \frac{\prod_{i=1}^m (j\omega - z_i)(-j\omega - z_i)}{\prod_{k=1}^n (j\omega - p_k)(-j\omega - p_k)} = K^2 \frac{\prod_{i=1}^m (\omega^2 + z_i^2)}{\prod_{k=1}^n (\omega^2 + p_k^2)}$$

Tot din definiția (5) rezultă că  $S_{x,x}(j\omega)$  este funcție pară. În conformitate cu teorema 1, are loc

$$(9) \quad k_{x,x}(\tau) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S_{x,x}(j\omega) e^{j\omega\tau} d\omega.$$

Pentru  $\tau = 0$  se obține proprietatea c). Q. e. d.

## 4.2: Densitatea interspectrală de putere

### Definiția 2

Funcția

$$(10) \quad S_{x,y}(j\omega) = \lim_{T \rightarrow \infty} \frac{X_T(j\omega) Y_T(-j\omega)}{2T}$$

se numește densitate interspectrală de putere a proceselor stochastice staționare și ergodice  $x_t = \xi(e,t)$ ,  $y_t = \eta(e,t)$ .

În această definiție

$$(11) \quad Y_T(j\omega) = \int_{-T}^T y(t) e^{-j\omega t} dt,$$

$$(12) \quad X_T(j\omega) = \int_{-T}^T x(t) e^{-j\omega t} dt.$$

### Teorema 3 (Wiener - Hincin)

Densitatea interspectrală de putere  $S_{x,y}(j\omega)$  este transformata Fourier-Plancherel a funcției de intercorelație  $k_{x,y}(\tau)$ .

Demonstratia este analogă cu cea de la teorema 1.

Asadar

$$(13) \quad S_{x,y}(j\omega) = \int_{-\infty}^{+\infty} k_{x,y}(\tau) e^{-j\omega\tau} d\tau$$

$$(14) \quad k_{x,y}(\tau) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S_{x,y}(j\omega) e^{j\omega\tau} d\omega$$

#### Teorema 4

Densitatea interspectrală de putere are următoarele propri-  
tati

a)  $S_{x,y}(j\omega)$  este o funcție complexă care satisface identitatea

$$(15) \quad S_{x,y}(j\omega) = S_{y,x}(-j\omega);$$

b)  $k_{x,y}(0) = \frac{1}{x(t)y(t)} = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S_{x,y}(j\omega) d\omega$ .

D. În general  $S_{x,y}(j\omega)$  este o funcție complexă. Acest lucru rezultă din definiția (10) și implică faptul că  $S_{x,y}(j\omega)$  conține informații despre defazajul dintre  $x(t)$  și  $y(t)$ . Identitatea (15) rezultă imediat din relațiile (3.12) și (13). În fine proprietatea b se obține pentru  $\tau=0$  din (14). Q.e.d.

### 4.3. Clasificarea semnalelor stochastice

După extinderea spectrului de frecvențe în densitatea spec-  
trală de putere, semnalele stochastice pot fi de următoarele  
tipuri:

a. zgomot alb. Aceste semnale conțin în mod uniform toate  
frecvențele spectrului - fig 4. Asadar

$$S_{x,x}(j\omega) = 1 \quad ; \quad k_{x,x}(\tau) = \delta(\tau).$$

Timpul de coerență a zgomotului alb este nul. Rezultă de  
aici că nu există nici o corelație între realizările  $x(t)$  și  
 $x(t \pm \tau)$  pentru orice  $\tau \neq 0$ . Din acest motiv zgomotul alb se  
mai numește proces stochastic pur.

b. zgomot de bandă largă (numit și zgomot alb de bandă  
limitată). Aceste semnale au un spectru de frecvențe apro-  
ximativ uniform într-un interval de frecvențe  $[-\omega_0, \omega_0]$ .

Ca exemplu, fig 5, se poate aminti

$$S_{x,x}(j\omega) = \frac{2K\omega_0}{\omega^2 + \omega_0^2} \quad ; \quad k_{x,x}(\tau) = K e^{-\omega_0|\tau|} \quad ; \quad \omega_0 > 0.$$

x.4.

191

Un astfel de semnal se poate obține filtrând un zgomot alb cu ajutorul unui filtru „trece-jos”.

c. Zgomot colorat. Aceste semnale au un spectru de frecvențe de bandă largă, limitat inferior și superior la un interval de frecvențe  $|\omega_1| \leq |\omega| \leq |\omega_2|$  - fig 6.

d. Zgomot de bandă îngustă. Aceste semnale au un spectru de frecvențe într-o bandă foarte îngustă - fig 7.




fig 4. Zgomot alb




fig 5. Zgomot alb de bandă limitată

#### 4.4. Exemple de calcul a densității spectrale de putere

a. Semnal determinist periodic. Pentru

$$x(t) = X_m \sin(\omega_0 t - \varphi)$$




fig 6. Zgomot colorat  
s-a obținut




fig 7. Zgomot de bandă îngustă

$$r_{x,x}(\tau) = \frac{1}{2} X_m^2 \cos \omega_0 \tau.$$

După cum se știe transformata Fourier-Plancherel a acestei funcții este (vezi anexa D.3.4)

$$S_{x,x}(j\omega) = \frac{1}{2} \pi X_m^2 [\delta(\omega + \omega_0) + \delta(\omega - \omega_0)],$$

ceea ce înseamnă că în spectru există numai frecvențele  $\pm \omega_0$ . Pentru

$$x(t) = X_m \sin(\omega_0 t - \alpha), \quad y(t) = Y_m \sin(\omega_0 t - \beta)$$

avem

$$k_{x,y}(\tau) = \frac{1}{2} X_m Y_m \cos(\omega_0 \tau - \varphi); \quad \varphi = \alpha - \beta$$

$$S_{x,y}(j\omega) = \frac{1}{2} \pi X_m Y_m [e^{j\varphi} \delta(\omega + \omega_0) + e^{-j\varphi} \delta(\omega - \omega_0)],$$

ceea ce înseamnă că  $S_{x,y}(j\omega)$  este o funcție complexă care conține informații asupra defazajului  $\varphi$  dintre  $x(t)$  și  $y(t)$ .

b. Proces stocastic de valoare medie nenulă

Fie o realizare  $x(t)$  a cărei valoare medie este  $\overline{x(t)}$ . Se poate defini semnalul centrat

$$y(t) = x(t) - \overline{x(t)} \quad \text{cu} \quad \overline{y(t)} = 0.$$

Funcția de autocorelație a semnalului  $x(t)$  este

$$k_{x,x}(\tau) = k_{y,y}(\tau) + (\overline{x(t)})^2,$$

iar densitatea spectrală de putere are expresia

$$S_{x,x}(j\omega) = S_{y,y}(j\omega) + 2\pi (\overline{x(t)})^2 \delta(\omega).$$

Se deduce din ultima relație că procesele stochastice de medie nenulă au în densitatea spectrală de putere un impuls Dirac de amplitudine  $2\pi (\overline{x(t)})^2$  la  $\omega = 0$ .

c. Semnal telegrafic. Un astfel de semnal este constant pe porțiuni, variind prin salt între două limite fixe a și -a (semnal binar) - fig 8.




fig. 8. Semnal telegrafic

Acest semnal este frecvent utilizat în studiul experimental al sistemelor dinamice deoarece poate fi relativ ușor generat sub formă numerică (pe calculator numeric) sau sub formă analogică utilizând registre de deplasare.



x.4:

193

Vom porni de la ipoteza că numărul de schimbări de semn a semnalului într-un interval  $(t_1, t_2)$  este aleator și independent de ceea ce se întâmplă în afara intervalului  $(t_1, t_2)$ . Fie  $A_n$  evenimentul producerii a exact  $n$  variații de semn pe durata  $\tau = t_2 - t_1$  și  $\lambda$  numărul mediu de variații de semn în unitatea de timp. Studiile experimentale au dat la iveală faptul că probabilitatea evenimentului  $A_n$  este dată de legea lui Poisson

$$P(A_n) = \frac{1}{n!} (\lambda |\tau|)^n e^{-\lambda |\tau|}.$$

Funcția de autocorelație a semnalului telegrafic, considerat staționar și ergodic, de valoare medie nulă, este dată de media pe mulțime

$$R_{x,x}(\tau) = \Psi_{x,x}(\tau) = \int_{-\infty}^{+\infty} \mu_1 \mu_2 p_{x,x}(\mu_1, \mu_2, \tau) d\mu_1 d\mu_2.$$

Pentru produsul  $\mu_1 \mu_2$  putem scrie

$$\mu_1 \mu_2 = \begin{cases} \alpha^2 & \text{pentru } n \text{ par,} \\ -\alpha^2 & \text{pentru } n \text{ impar.} \end{cases}$$

Probabilitatea totală a evenimentului care constă în producerea unui număr par de schimbări de semn este

$$P(A_0) + P(A_2) + P(A_4) + \dots = \sum_{n=0}^{\infty} P(A_{2n}).$$

Probabilitatea totală a evenimentului care constă în producerea unui număr impar de schimbări de semn este

$$P(A_1) + P(A_3) + P(A_5) + \dots = \sum_{n=0}^{\infty} P(A_{2n+1}).$$

În aceste condiții avem

$$R_{x,x}(\tau) = \alpha^2 \sum_{n=0}^{\infty} P(A_{2n}) - \alpha^2 \sum_{n=0}^{\infty} P(A_{2n+1}) =$$

$$= \alpha^2 \sum_{n=0}^{\infty} (-1)^n P(A_n) = \alpha^2 e^{-\lambda |\tau|} \sum_{n=0}^{\infty} \frac{1}{n!} (-\lambda |\tau|)^n = \alpha^2 e^{-2\lambda |\tau|}.$$

Densitatea spectrală de putere corespunzătoare este

$$S_{x,x}(j\omega) = \frac{4\alpha^2 \lambda}{\omega^2 + 4\lambda^2}.$$

Graficul acestei funcții este reprezentat în fig. 5 pentru

$k = a^2$  și  $\omega_0 = 2\lambda$ . Se remarcă <sup>194</sup> faptul că pentru  $\lambda$  suficient de ridicat, la limită  $\lambda \rightarrow \infty$ , semnalul telegrafic poate aproxima în condiții acceptabile zgomotul „alb”.

#### 4.5. Relații „intrare-ieșire”

În cele ce urmează ne vom ocupa de transferul proceselor stochastice staționare ergodice prin elemente ratiionale de transfer, sub aspect frecvențial.

##### Teorema 5

Dacă pentru realizările  $x(t), y(t), z(t)$  avem

$$(16) \quad z(t) = x(t) \pm y(t),$$

atunci

$$(17) \quad S_{z,z}(j\omega) = S_{x,x}(j\omega) + S_{y,y}(j\omega) \pm S_{x,y}(j\omega) \pm S_{y,x}(j\omega).$$

Această teoremă rezultă imediat din teorema 3 de la 3.4.

În cazul în care procesele stochastice  $x_t = \xi(e,t)$  și  $y_t = \eta(e,t)$  sînt statistic independente sau necorelate, atunci, ținînd seama de (3.22), avem

$$(18) \quad S_{x,y}(j\omega) = 2\pi \overline{x(t)} \cdot \overline{y(t)} \delta(\omega)$$

și relația (17) devine

$$(19) \quad S_{z,z}(j\omega) = S_{x,x}(j\omega) + S_{y,y}(j\omega) \pm 4\pi \overline{x(t)} \cdot \overline{y(t)} \delta(\omega).$$

Dacă cel puțin un proces este de valoare medie nulă, adică  $\overline{x(t)} = 0$  sau  $\overline{y(t)} = 0$ , atunci

$$(20) \quad S_{z,z}(j\omega) = S_{x,x}(j\omega) + S_{y,y}(j\omega).$$

În cazul unui amestec de semnale, unul determinat periodic de valoare medie nulă și celălalt stochastic staționar ergodic, în ipoteza că sînt statistic independente, relația (20) rămîne valabilă.

De exemplu pentru

$$x(t) = X_m \sin(\omega_0 t - \varphi)$$

relația (20) devine

$$S_{z,z}(j\omega) = \frac{1}{2} \pi X_m^2 [\delta(\omega + \omega_0) + \delta(\omega - \omega_0)] + S_{y,y}(j\omega).$$

Concluzia care se trage din acest rezultat este aceea că

dacă un semnal conține componente periodice, atunci acestea se vor manifesta sub formă de impulsuri Dirac în densitatea spectrală de putere.

Fie un R-element descris de produsul de convoluție (3.26).

### Teorema 6

Între <sup>relațiile</sup> semnalele  $u(t)$  și  $y(t)$  ale intrării și ieșirii unui

R-element există următoarele relații

$$(21) \quad S_{u,y}(j\omega) = G(j\omega) S_{u,u}(j\omega),$$

$$(22) \quad S_{y,y}(j\omega) = G(j\omega) S_{y,u}(j\omega),$$

$$(23) \quad S_{y,y}(j\omega) = |G(j\omega)|^2 S_{u,u}(j\omega),$$

unde  $G(j\omega) = \mathcal{F}\{g(t)\}$  este răspunsul la frecvență al R-elementului.

D. Relațiile (21), (22) se obțin imediat aplicând transformarea Fourier-Plancherel relațiilor (3.28), (3.30), ținând seama de teorema produsului de convoluție (vezi anexa C.6.1). Pentru a demonstra (23) se înlocuiește (21) în (22) ținând seama de faptul că  $S_{y,u}(j\omega) = S_{u,y}(-j\omega)$ . Q. e. d.

Relația (23) pune în evidență caracterul de filtrare al R-elementului. Utilizând un R-element adecvat și o sursă de zgomot „alb” se poate obține orice tip de zgomot. Într-adevăr, pentru  $S_{u,u}(j\omega) = 1$  din (23) se obține  $S_{y,y}(j\omega) = |G(j\omega)|^2$ . În acest caz R-elementul se numește filtru de formare.

## 4.6. Măsurarea semnalelor stochastice

### Corelatorul Temporal

Pentru măsurarea funcției de auto- sau intercorelație se folosesc corelatoarele. Pentru două semnale  $u(t)$  și  $y(t)$ , corelatorul trebuie să funcționeze conform relației

$$(24) \quad k_{u,y}(\tau) = \frac{1}{T} \int_0^T u(t-\tau) y(t) dt; \quad \tau \in [0, \infty).$$

În care  $T$  este o durată de timp suficient de mare. Schema bloc a unui astfel de dispozitiv este reprezentată în fig. 9. Pentru obținerea funcției  $k_{u,y}(\tau)$  se prelucrează semnalul  $x(t)$  conform schemei bloc, pe o durată  $T$  suficient

de mare, pentru diverse valori ale întârzierii  $\tau$  a elementului cu „timp mort”.

Pentru măsurarea funcției de autocorelație  $k_{u,u}(\tau)$  se înlocuiește  $y(t)$  cu  $u(t)$ .




fig.9. Schema bloc a unui corelator

Întrucât practic nu este posibil ca  $T \rightarrow \infty$ , rezultă că funcția de intercorelație măsurată depinde și de  $T$ . Se trage concluzia că funcția de intercorelație măsurată va fi afectată de erori de natură statistică. În legătura cu această problemă se pot consulta [2], [11].

### Spectrometrul de putere

Pentru realizarea unui dispozitiv pentru măsurarea densității spectrale de putere se pornește de la egalitatea

$$(25) \quad S_{x,x}(j\omega) = \lim_{\Delta\omega \rightarrow 0} \frac{\int_{\omega - \frac{\Delta\omega}{2}}^{\omega + \frac{\Delta\omega}{2}} S_{x,x}(j\omega) d\omega}{\Delta\omega}; \quad \omega \in [0, \infty).$$

*de f. adaptată în interval. [0, T]*

Ținând seama de definiția (5), reformulată pentru semnalul  $x(t)$  trunchiat temporal pe intervalul  $[0, T]$ , relația (25) devine

$$(26) \quad S_{x,x}(j\omega) = \lim_{\Delta\omega \rightarrow 0} \lim_{T \rightarrow \infty} \frac{1}{\Delta\omega} \int_{\omega - \frac{\Delta\omega}{2}}^{\omega + \frac{\Delta\omega}{2}} \frac{|X_T(j\omega)|^2}{T} d\omega.$$

În aceste condiții pentru  $\Delta\omega$  suficient de mic și  $T$  suficient de mare, expresia

$$(27) \quad \tilde{S}_{x,x}(j\omega) = \frac{1}{\Delta\omega T} \int_{\omega - \frac{\Delta\omega}{2}}^{\omega + \frac{\Delta\omega}{2}} |X_T(j\omega)|^2 d\omega$$

este o măsură a densității spectrale de putere a semnalului  $x(t)$ .  
Introducând funcția trunchiată frecvențial pe intervalul  
 $[\omega - \frac{\Delta\omega}{2}, \omega + \frac{\Delta\omega}{2}]$

$$(28) \quad X_{T,\Delta\omega}(j\omega) = X_T(j\omega) \left[ \delta(\omega + \frac{\Delta\omega}{2}) - \delta(\omega - \frac{\Delta\omega}{2}) \right],$$

în care  $\delta(\omega)$  este funcția treaptă unitară, și ținând seama de teorema lui Parseval (anexa C.6.1) relația (27) devine.

$$(29) \quad \tilde{S}_{x,x}(j\omega) = \frac{1}{\Delta\omega T} \int_{-\infty}^{+\infty} |X_{T,\Delta\omega}(j\omega)|^2 d\omega = \frac{2\pi}{\Delta\omega T} \int_{-\infty}^{+\infty} x_{T,\Delta\omega}^2(t) dt = \\ = \frac{2\pi}{\Delta\omega T} \int_0^T x^2(t) dt.$$

În această relație  $x_{T,\Delta\omega}(t)$  este un semnal care se obține din  $x(t)$  prin trunchiere temporală și trunchiere frecvențială. Concret aceasta înseamnă că semnalul  $x(t)$  este observat pe o durată finită  $T$  și este filtrat cu un filtru ideal „trece-banda”, cu caracteristica amplitudine-frecvență

$$M(\omega) = \delta(\omega + \frac{\Delta\omega}{2}) - \delta(\omega - \frac{\Delta\omega}{2}).$$

Schema bloc a unui spectrometru de putere este dată în fig. 10.




fig. 10. Spectrometrul de putere

Pentru obținerea funcției  $S_{x,x}(j\omega)$  se prelucrează semnalul  $x(t)$  conform schemei bloc pe o durată  $T$  suficient de mare, pentru diverse valori ale frecvenței medii  $\omega$  a filtrului de bandă  $\Delta\omega$ . Din relația (29) rezultă că densitatea spectrală de putere măsurată depinde și de  $T$  și de  $\Delta\omega$ . Ca atare și această funcție va fi afectată de erori de natură statistică, [2], [11].

Utilizând relațiile derivând din noțiunile de funcție de autocorelație și de densitate spectrală de putere se poate trage concluzia

falsă că se pot obține tot mai multe detalii analizând un număr tot mai mare de date și că teoretic nu există nici o limită a acuratetii măsurătorilor. Din fericire o astfel de limită există. În cazul analizei frecvențiale a semnalelor acest fapt se datorează dualității durată-frecvență. O determinare precisă a unei anumite frecvențe în spectrul unui semnal cere o durată de observație foarte mare. Aceste fapte sînt bine cunoscute din fizică (principiul incertitudinii) și pentru cazul analizei frecvențiale a semnalelor pot fi demonstrate și matematic, [2].

## 5. Filtre Wiener

### 5.1. Punerea problemei

Problema filtrării optimale a unui semnal stohastic staționar pornește de la necesitatea transformării unui semnal  $u(t)$  într-un semnal  $d(t)$  (dorit) prin aplicarea lui  $u(t)$  unui sistem causal și stabil. Întrucît în condiții reale mărimea de ieșire  $y(t)$  este diferită de  $d(t)$ , datorită faptului că  $g(t)$  este realist în timp ce  $g_i(t)$  poate fi ideal - fig 11, problema care se pune este de a găsi acea structură și acei parametri ai sistemului, care asigură ca eroarea

$$(1) \quad \varepsilon(t) = d(t) - y(t),$$

în medie pătratică, să fie minimă.  $g_i(t)$  este răspunsul la impuls al unui sistem ideal care transformă pe  $u(t)$  în  $d(t)$ .




fig. 11. Problema filtrării optimale

Asadar problema sintezei sistemului cu răspunsul la impuls  $g(t)$  este o problemă variațională. Indicele de calitate în acest caz este

$$(2) \quad \mathcal{J} = \overline{\varepsilon^2(t)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T \varepsilon^2(t) dt.$$

x-5

În ceea ce privește semnalul de ieșire dorit  $d(t)$ , acesta poate fi considerat, în general, de argument  $t+T_0$ , adică  $d(t+T_0)$ , unde  $T_0$  este o constantă reală. Eroarea în acest caz este

$$(3) \quad \varepsilon(t) = d(t+T_0) - y(t) \dots$$

În funcție de valoarea lui  $T_0$ , cu indicele de calitate (2) se poate sintetiza un sistem din următoarele 3 categorii:

- pentru  $T_0 = 0$  - filtru pur,
- pentru  $T_0 < 0$  - filtru de întârziere (netezire),
- pentru  $T_0 > 0$  - filtru de predicție.

### 5.2. Ecuația Wiener-Hopf

Ținând seama că sistemul  $g(t)$  este descris de produsul de convoluție

$$(4) \quad y(t) = \int_{-\infty}^{+\infty} g(\theta) u(t-\theta) d\theta,$$

eroarea definită prin (3) are expresia

$$(5) \quad \varepsilon(t) = d(t+T_0) - \int_{-\infty}^{+\infty} g(\theta) u(t-\theta) d\theta.$$

Problema de rezolvat este de a găsi  $g(t)$  astfel încât să fie satisfăcut indicele de calitate (2). Pentru evaluarea erorii pătratic medii se poate scrie

$$(6) \quad R_{\varepsilon, \varepsilon}(z) = \overline{d(t+T_0)d(t+T_0+z)} + \overline{y(t)y(t+z)} - \overline{d(t+T_0)y(t+z)} - \overline{y(t)d(t+T_0+z)}.$$

Pentru  $z=0$  din (6) se obține

$$(7) \quad \overline{\varepsilon^2(t)} = \overline{d^2(t+T_0)} + \overline{y^2(t)} - 2 \overline{d(t+T_0)y(t)}.$$

În ipoteza staționarității avem

$$(8) \quad \overline{d^2(t+T_0)} = \overline{d^2(t)} = R_{d,d}(0).$$

În conformitate cu relația (4) mai putem calcula

$$(9) \quad \overline{d(t+T_0)y(t)} = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T \overline{d(t+T_0) \int_{-\infty}^{+\infty} g(\theta) u(t-\theta) d\theta} dt =$$

$$= \int_{-\infty}^{+\infty} g(\theta) \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T \overline{u(t-\theta)d(t+T_0)} dt d\theta = \int_{-\infty}^{+\infty} g(\theta) R_{u,d}(\theta+T_0) d\theta;$$

$$(10) \quad \overline{y^2(t)} = R_{y,y}(0) = \int_{-\infty}^{+\infty} g(\theta) \int_{-\infty}^{+\infty} g(\eta) R_{u,u}(z+\theta-\eta) d\eta d\theta \Big|_{z=0} =$$

$$2.5. \quad = \int_{-\infty}^{\infty} g(\theta) \int_{-\infty}^{\infty} g(\eta) k_{u,u}(\theta-\eta) d\eta d\theta.$$

Cu aceste expresii (7) devine

$$(11) \quad \overline{\varepsilon^2(t)} = k_{d,d}(0) - 2 \int_{-\infty}^{\infty} g(\theta) k_{u,d}(\theta+\tau_0) d\theta + \int_{-\infty}^{\infty} g(\theta) \int_{-\infty}^{\infty} g(\eta) k_{u,u}(\theta-\eta) d\eta d\theta.$$

Se observă că indicele de calitate nu depinde de semnalele  $u(t)$ ,  $y(t)$ ,  $d(t)$ , ci de mediile temporale  $k_{u,u}(\tau)$ ,  $k_{u,d}(\tau)$ ,  $k_{d,d}(0)$ . Acest fapt prezintă o importanță deosebită deoarece o funcție de auto- sau intercorelație reprezintă o clasă largă de semnale și ca urmare filtrul  $g(t)$  va asigura eroarea medie minimă pentru acea clasă de semnale.

Dintre toate sistemele  $g(t)$  care minimizează funcționala (11), din punct de vedere practic prezintă un deosebit interes sistemele realizate și stabile IMEM, adică care satisfac condițiile:

$$(12) \quad g(t) \equiv 0 \text{ pentru } t < 0,$$

$$(13) \quad \int_0^{\infty} |g(t)| dt \leq K < +\infty.$$

Teorema 1 (Wiener - Hopf)

O condiție necesară ca  $g^*(t)$ , care satisface condiția (12), să fie o extremală a funcționalei (11) este ca

$$(14) \quad k_{u,d}(\theta+\tau_0) - \int_{-\infty}^{\infty} g^*(\eta) k_{u,u}(\theta-\eta) d\eta = 0, \quad \theta \geq 0.$$

D. Dacă  $g^*(t)$  este o extremală a funcționalei (11), atunci o funcție oarecare  $g(t)$  se poate scrie sub forma

$$(15) \quad g(t) = g^*(t) + \mathcal{L}g(t),$$

unde  $g(t)$  este o funcție arbitrară care satisface condiția (12) și  $\mathcal{L}$  un număr real, mic în valoare absolută.

În aceste condiții (11) devine

$$(16) \quad \overline{\varepsilon^2(t, \mathcal{L})} = k_{d,d}(0) - 2 \int_{-\infty}^{\infty} [g^*(\theta) + \mathcal{L}g(\theta)] k_{u,d}(\theta+\tau_0) d\theta + \int_{-\infty}^{\infty} [g^*(\theta) + \mathcal{L}g(\theta)] \int_{-\infty}^{\infty} [g^*(\eta) + \mathcal{L}g(\eta)] k_{u,u}(\theta-\eta) d\eta d\theta.$$

Condiția necesară de minimum, după cum se știe, (vezi 2.14),



este :

x.5

201

$$(17) \quad \frac{d}{dt} [\mathcal{E}^2(t, \mathcal{L})] \Big|_{t=0} = 0.$$

Conform acestei condiții, din (16) se obține

$$\begin{aligned} & -2 \int_{-\infty}^{\infty} g(\theta) k_{u,d}(\theta + T_0) d\theta + \int_{-\infty}^{\infty} g(\theta) \int_{-\infty}^{\infty} g^*(\eta) k_{u,u}(\theta - \eta) d\eta d\theta + \\ & + \int_{-\infty}^{\infty} g^*(\theta) \int_{-\infty}^{\infty} g(\eta) k_{u,u}(\theta - \eta) d\eta d\theta = 0, \end{aligned}$$

sau

$$(18) \quad \int_{-\infty}^{\infty} g(\theta) \left[ k_{u,d}(\theta + T_0) - \int_{-\infty}^{\infty} g^*(\eta) k_{u,u}(\theta - \eta) d\eta \right] d\theta = 0.$$

Notind

$$(19) \quad f(\theta) = k_{u,d}(\theta + T_0) - \int_{-\infty}^{\infty} g^*(\eta) k_{u,u}(\theta - \eta) d\eta,$$

ecuația (18) devine

$$(20) \quad \int_{-\infty}^{\infty} g(\theta) f(\theta) d\theta = 0.$$

Întrucît  $g(\theta) = 0$  pentru  $\theta < 0$ , rezultă că pentru  $\theta < 0$  ecuația (18) este satisfăcută. Pentru  $\theta \geq 0$ ,  $g(\theta) \neq 0$  și conform lemei fundamentale a calculului variational (vezi IX.1.4, teorema 3) rezultă că  $f(\theta) = 0$  pentru  $\theta \geq 0$ , de unde rezultă imediat relația (14). Q.e.d.

Soluția ecuației integrale (14), numită ecuația Wiener-Hopf este  $g^*(t)$ , adică structura și parametrii filtrului optimal realist căutat.

### 5.3. Soluția ecuației Wiener-Hopf.

Vom da în cele ce urmează o soluție  $g^*(t)$  care satisface condiția (13) (stabilită IMEM), a ecuației (14).

Întrucît densitatea spectrală de putere  $S_{u,u}(j\omega)$  este reală, nenegativă și pară, se poate scrie:

$$(21) \quad S_{u,u}(j\omega) = G_1(j\omega) G_1(-j\omega) = |G_1(j\omega)|^2,$$

în care  $G_1(j\omega)$  este o funcție cu poli și zerouri în  $\text{Re } s < 0$ .

În aceste condiții  $\frac{1}{G_1(s)}$  poate fi considerată funcția de transfer a unui sistem realist și stabil IMEM.

202

Se consideră că sistemul căutat  $G^*(s)$  este format din două subsisteme inseriate - fig 12, astfel că

$$(22) \quad G^*(s) = \frac{1}{G_1(s)} G_2(s),$$

unde  $G_2(s)$  urmează să se determine.

Pentru semnalul intermediar  $x(t)$  se poate scrie

$$(23) \quad S_{x,x}(j\omega) = \frac{1}{|G_1(j\omega)|^2} \cdot S_{u,u}(j\omega) = 1 \quad (k_{x,x}(\tau) = \delta(\tau)),$$

ceea ce înseamnă că  $x(t)$  este un zgomot alb.

Subsistemul  $G_2(s)$  trebuie să satisfacă ecuația Wiener-Hopf, adică

$$k_{x,d}(\theta + T_0) - \int_{-\infty}^{+\infty} g_2(\eta) k_{x,x}(\theta - \eta) d\eta = 0, \quad \theta \geq 0,$$

sau ținând seama de (23)

$$(24) \quad k_{x,d}(\theta + T_0) = g_2(\theta), \quad \theta \geq 0.$$

Din (24) rezultă imediat

$$(25) \quad g_2(\theta) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} S_{x,d}(j\omega) e^{j\omega T_0} e^{j\omega \theta} d\omega, \quad \theta \geq 0.$$

Pe de altă parte

$$(26) \quad S_{x,d}(j\omega) = \frac{1}{G_1(-j\omega)} \cdot S_{u,d}(j\omega) = \frac{G_i(j\omega)}{G_1(-j\omega)} S_{u,u}(j\omega),$$

astfel că (25) devine

$$(27) \quad g_2(\theta) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \frac{G_i(j\omega)}{G_1(-j\omega)} S_{u,u}(j\omega) e^{j\omega T_0} e^{j\omega \theta} d\omega, \quad \theta \geq 0.$$

Notînd

$$(28) \quad K(s) = \frac{G_i(j\omega)}{G_1(-s)} S_{u,u}(j\omega) e^{j\omega T_0},$$

în care  $s = j\omega$ , și presupunînd că are loc descompunerea

$$(29) \quad K(s) = K_+(s) + K_-(s),$$

în care  $K_+(s)$  este o funcție cu toți polii în  $\text{Re } s < 0$  și

$K_-(s)$  cu toți polii în  $\text{Re } s \geq 0$ , din (27) rezultă

$$(30) \quad g_2(\theta) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} K_+(j\omega) e^{j\omega \theta} d\omega,$$

adică

$$(31) \quad G_2(j\omega) = K_+(j\omega).$$

Cu această soluție căutată este

$$(32) \quad G^*(j\omega) = \frac{K_+(j\omega)}{G_1(j\omega)}$$





fig. 12. Soluția ecuației (14)

fig. 13. Considerarea perturbațiilor

Din expresia soluției (32) rezultă că filtrul optimal  $G^*(s)$  depinde direct de funcția de autocorelație a intrării  $u(t)$  și de funcția de intercorelație a semnalelor  $u(t)$  și  $d(t)$  și de timpul  $T_0$  care precizează tipul filtrului.

#### 5.4. Considerarea perturbațiilor

Problema filtrării poate fi formulată în aceiași termeni dacă se ține seama de existența unei perturbații stochastice  $v(t)$ , care se aplică la intrarea filtrului - fig. 13. Conform figurii avem

$$(33) \quad z(t) = u(t) + v(t),$$

în care  $u(t)$  este semnalul util.

În aceste condiții ecuația (14) devine

$$(34) \quad k_{z,d}(\theta + T_0) - \int_{-\infty}^{+\infty} g^*(\eta) k_{z,z}(\theta - \eta) d\eta = 0, \quad \theta \geq 0,$$

în care

$$(35) \quad k_{z,d}(\theta) = k_{u,d}(\theta) + k_{v,d}(\theta),$$

$$(36) \quad k_{z,z}(\theta) = k_{u,u}(\theta) + k_{v,v}(\theta) + k_{u,v}(\theta) + k_{v,u}(\theta).$$

Soluția ecuației (34) se determină ca în cazul ecuației (14).

#### 5.5. Aplicație

Fie un semnal util  $u(t)$ , de medie nulă, cu densitatea spectrală de putere

$$S_{u,u}(j\omega) = \frac{A^2}{\omega^2 + a^2}.$$

$$r_{x,d}(\theta + T_0) - \int_{-\infty}^{\infty} g_2^*(\gamma) r_{x,x}(\theta - \gamma) d\gamma = 0 \quad \theta \geq 0$$

$$g_2^*(\theta) = r_{x,d}(\theta + T_0) =$$

$$= \frac{1}{2\pi} \int_{-\infty}^{\infty} S_{x,d}(j\omega) e^{j\omega T_0} e^{j\omega \theta} d\omega$$

$$S_{x,d}(j\omega) = \frac{1}{G_1(-j\omega)} S_{z,d}(j\omega)$$

$$S_{z,d}(j\omega) = S_{u,d}(j\omega) + S_{v,d}(j\omega)$$

$$G_2(j\omega) = K_+(j\omega)$$

$$K_+(j\omega) = \left[ \frac{S_{z,d}(j\omega) e^{j\omega T_0}}{G_1(-j\omega)} \right]_+$$

x-5. 204  
 care este perturbat aditiv cu un zgomot "alb" de medie nulă

$$S_{v,r}(j\omega) = B^2,$$

necorelat cu  $u(t)$ .

Să se determine un filtru pur care să minimizeze, în medie pătratică eroarea  $\varepsilon(t) = u(t) - y(t)$ .

Conform datelor problemei avem:  $d(t) = u(t)$  și deci  $G_i(\lambda) = 1$ . Pentru  $z(t) = u(t) + v(t)$  și  $S_{u,v}(j\omega) = S_{v,u}(j\omega) = 0$  putem scrie

$$S_{z,z}(j\omega) = S_{u,u}(j\omega) + S_{v,v}(j\omega) = \frac{A^2}{\omega^2 + a^2} + B^2 = B^2 \frac{\omega^2 + b^2}{\omega^2 + a^2};$$

$$b^2 = a^2 + \frac{A^2}{B^2},$$

$$S_{z,u}(j\omega) = S_{u,u}(j\omega) = \frac{A^2}{\omega^2 + a^2}$$

$$G_1(j\omega) = \{S_{z,z}(j\omega)\}_+ = \left\{ B \frac{j\omega + b}{j\omega + a} \cdot B \frac{-j\omega + b}{-j\omega + a} \right\}_+ = B \frac{j\omega + b}{j\omega + a}$$

$$K_+(j\omega) = \left[ \frac{S_{z,u}(j\omega)}{G_1(-j\omega)} \right]_+ = \left[ \frac{A^2}{\omega^2 + a^2} \cdot \frac{1}{B} \cdot \frac{-j\omega + a}{-j\omega + b} \right]_+$$

$$= \left[ \frac{A^2}{B(j\omega + a)(-j\omega + b)} \right]_+ = \frac{A^2}{B} \left[ \frac{\alpha}{j\omega + a} + \frac{\beta}{-j\omega + b} \right]_+ = \frac{A^2}{B(a+b)(j\omega + a)}$$

În aceste relații  $\{F(j\omega)\}_+$  simbolizează operația prin care se reține din  $F(j\omega)$  numai factorul cu toți poli și zerourile în  $\text{Re } s < 0$ , iar  $[F(j\omega)]_+$  - operația prin care din  $F(j\omega)$  se rețin toate fracțiile simple cu poli în  $\text{Re } s < 0$ .

Răspunsul la frecvență al filtrului optimal este:

$$G^*(j\omega) = \frac{A^2}{B(a+b)(j\omega + a)} \cdot \frac{1}{B} \cdot \frac{j\omega + a}{j\omega + b} = \frac{A^2}{B^2(a+b)(j\omega + b)}$$

Acest filtru poate fi realizat cu un R-element PT, cu un factor de amplificare  $k = \frac{A^2}{B^2(a+b)b}$  și o constantă de timp  $T = \frac{1}{b}$ .

## 5.6. Problema estimării stării

Fie un sistem dinamic liniar constant

$$(37) \quad \dot{x} = Ax + bu, \quad x(0) = x_0,$$

$$(38) \quad y = Cx.$$

În condiții concrete problema estimării stării sistemului (37), (38) așa cum a fost introdusă la VI. 3.3, este mult mai complexă, datorită faptului că asupra sistemului (37), (38) acționează și alte mărimi de intrare, nemăsurabile, cu caracter perturbator, iar măsurarea însăși a mărimilor  $u$  și  $y$ , necesare pentru elaborarea stării estimate, poate fi afectată de perturbații.

Așadar, în general, din punctul de vedere al estimării stării, sistemul (1), (2) are forma

$$(39) \quad \dot{x} = Ax + bu + bv, \quad x(0) = x_0,$$

$$(40) \quad y = Cx + w,$$

în care  $v$  este o intrare perturbatoare, nemăsurabilă și  $w$  o perturbare de măsurare a ieșirii  $y$ . În general  $v$  și  $w$  sînt vectori cu componente procese stochastice.

Estimatorul corespunzător sistemului (3), (4) are forma cunoscută; adică

$$(41) \quad \dot{\hat{x}} = A\hat{x} + L(y - C\hat{x}) + bu, \quad \hat{x}(0) = 0.$$

Alegerea matricii  $L$  numai din condiția de stabilitate asimptotică a sistemului (41) nu mai este satisfăcătoare deoarece prezența perturbațiilor  $v$  și  $w$  face ca eroarea

$$(42) \quad \varepsilon = x - \hat{x}$$

să nu mai tindă la 0 atunci cînd  $t \rightarrow \infty$ .

Acest fapt orientează rezolvarea problemei estimării stării către determinarea matricii  $L$  dintr-o condiție de optimum și anume ca indicele de calitate

$$(43) \quad J = \int_0^{\infty} \varepsilon^T(t) \varepsilon(t) dt = \int_0^{\infty} \varepsilon^T(t) \varepsilon(t) dt$$

să fie minim.

În ipotezele

1° Vectorii  $v$  și  $w$  sînt vectori-procese stochastice

x.5. <sup>206</sup>  
 staționare ergodice, de tipul zgomotului alb, necorelate,  
 adică

$$(44) \quad \overbrace{v(t)v^T(t+\bar{z})} = \begin{bmatrix} \varphi_{v_1, v_1}(\bar{z}) & \varphi_{v_1, v_2}(\bar{z}) & \dots & \varphi_{v_1, v_m}(\bar{z}) \\ \varphi_{v_2, v_1}(\bar{z}) & \varphi_{v_2, v_2}(\bar{z}) & \dots & \varphi_{v_2, v_m}(\bar{z}) \\ \vdots & \vdots & \ddots & \vdots \\ \varphi_{v_m, v_1}(\bar{z}) & \varphi_{v_m, v_2}(\bar{z}) & \dots & \varphi_{v_m, v_m}(\bar{z}) \end{bmatrix} = Q \delta(\bar{z})$$

$$(45) \quad \overbrace{w(t)w^T(t+\bar{z})} = \begin{bmatrix} \varphi_{w_1, w_1}(\bar{z}) & \varphi_{w_1, w_2}(\bar{z}) & \dots & \varphi_{w_1, w_p}(\bar{z}) \\ \varphi_{w_2, w_1}(\bar{z}) & \varphi_{w_2, w_2}(\bar{z}) & \dots & \varphi_{w_2, w_p}(\bar{z}) \\ \vdots & \vdots & \ddots & \vdots \\ \varphi_{w_p, w_1}(\bar{z}) & \varphi_{w_p, w_2}(\bar{z}) & \dots & \varphi_{w_p, w_p}(\bar{z}) \end{bmatrix} = R \delta(\bar{z})$$

$$(46) \quad \overbrace{v(t)w^T(t+\bar{z})} = 0,$$

în care  $Q$  este o matrice constantă simetrică pozitivă semidefinită,  $R$  - matrice constantă simetrică, pozitivă definită și  $\delta(\bar{z})$  - impulsul Dirac;

2° componentele vectorilor  $v, w$  sînt de valori medii nule, adică

$$(47) \quad \overbrace{v(t)} = 0, \quad \overbrace{w(t)} = 0;$$

3° componentele vectorului  $x_0$  sînt variabile aleatoare gaussiene independente de  $v$  și  $w$ , de valori medii nule, adică

$$(48) \quad \overbrace{x_0} = 0,$$

se poate arăta, [6], că

$$(49) \quad L = k_0 C^T R^{-1},$$

unde matricea  $k_0$  este soluția ecuației algebrice Riccati (vezi 1X.4.2)

$$(50) \quad A k_0 + k_0 A^T - k_0 C^T R^{-1} C k_0 + B Q B^T = 0,$$

asociată problemei comenzii optime cu orizont infinit și stare finală fixată a sistemului dual

$$(51) \quad \dot{\tilde{x}}_x = A^T \tilde{x}_x + C^T u_x$$

cu indicele de calitate

$$(52) \quad J = \int_0^{\infty} [x_*^T (BQB^T)x_* + u_*^T R u_*] dt$$

Estimatorul determinat in acest fel este cunoscut sub numele de filtru Kalman-Bucy.

### 5.7. Aplicație

Fie sistemul de ordinul 1

$$\dot{x} = ax + bv$$

$$y = x + w$$

in care  $v$  și  $w$  sînt perturbații stochastice stationare, ergodice, cu proprietățile:

$$k_{v,v}(z) = g^2 \delta'(z), \quad \overline{v(t)} = 0,$$

$$k_{w,w}(z) = h^2 \delta'(z), \quad \overline{w(t)} = 0,$$

$$k_{v,w}(z) = k_{w,v}(z) = 0.$$

Condiția inițială  $x(0)$  este o variabilă aleatoare gaussiană independentă de  $v$  și  $w$ , de valoare medie nulă.

Se cere determinarea unui filtru Kalman-Bucy.

Ecuația estimatorului este

$$\dot{\hat{x}} = ax + l(y - \hat{x}), \quad \hat{x}(0) = 0,$$

in care

$$l = \frac{k_0}{h^2}$$

iar  $k_0$  este una din rădăcinile ecuației

$$k_0^2 - 2ah^2k_0 - b^2g^2h^2 = 0.$$

Alegînd rădăcina

$$k_0 = ah^2 + h \sqrt{a^2h^2 + b^2g^2}$$

se obține

$$l = a + \sqrt{a^2 + b^2 \frac{g^2}{h^2}},$$

care asigură realizarea unui estimator de stare

$$\dot{\hat{x}} = -\sqrt{a^2 + b^2 \frac{g^2}{h^2}} \hat{x} + \left( a + \sqrt{a^2 + b^2 \frac{g^2}{h^2}} \right) y$$

asimptotic stabil pentru orice  $a \neq 0$  și  $b \neq 0$ .