

PROCESE ALEATOARE DISCRETE ÎN TIMP

2.1 PROPRIETĂȚI GENERALE

2.1.1 Medii statistice. Clasificări

Un proces aleator discret poate fi definit ca o secvență de variabile aleatoare $x(n)$, indexată cu variabila temporală n . Evident, $x(n)$, privit ca o variabilă aleatoare, poate fi caracterizat prin funcția densitate de probabilitate, care va fi în general o funcție de timp, $w_{x(n)}(x)$. În consecință, valorile medii sunt și ele dependente și de variabila temporală n . De exemplu, valoarea medie va scrie

$$m_x(n) = E\{x(n)\} = \int_{-\infty}^{\infty} x w_{x(n)}(x) dx \quad (2.1)$$

iar funcțiile de corelație și covarianță vor depinde de două variabile temporale,

$$r_{xy}(k, l) = E\{x(k)y^*(l)\} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xy^* w_{x(k)y(l)}(x, y) dx dy \quad (2.2)$$

$$c_{xy}(k, l) = E\{x(k) - m_x(k)(y(l) - m_y(l))^*\} = r_{xy}(k, l) - m_x(k)m_y^*(l) \quad (2.3)$$

În cazul când $x(k)$ și $y(l)$ sunt două variabile aleatoare *statistic independente*, deci

$$w_{x(k)y(l)}(x, y) = w_{x(k)}(x)w_{y(l)}(y) \quad (2.4)$$

rezultă imediat că

$$r_{xy}(k, l) = m_x(k)m_y^*(l) \quad (2.5)$$

și în consecință

$$c_{xy}(k, l) = 0 \quad (2.6)$$

Dacă este îndeplinită ultima relație, se spune că $x(k)$ și $y(l)$ sunt *necorelate*. Se observă că dacă două semnale sunt statistic independente, ele sunt și necorelate. Reciproca nu este în

general adevărată. Ea are totuși loc în cazul proceselor gaussiene, unde cele două noțiuni sunt echivalente.

Se spune că $x(k)$ și $y(l)$ sunt *ortogonale*, dacă

$$r_{xy}(k, l) = E\{x(k)y^*(l)\} = 0 \quad (2.7)$$

În cazul particular $x=y$, se obțin funcțiile de autocorelație

$$r_{xx}(k, l) = E\{x(k)x^*(l)\} \quad (2.8)$$

și autocovarianță,

$$c_{xx}(k, l) = E\{(x(k) - m_x(k))(x(l) - m_x(l))^*\} = r_{xx}(k, l) - m_x(k)m_x^*(l) \quad (2.9)$$

Se poate ușor demonstra că:

- Dacă $x(k)$ și $y(l)$ sunt variabile aleatoare ortogonale, funcția de autocorelație a sumei este egală cu suma funcțiilor de autocorelație,

$$r_{x+y, x+y}(k, l) = r_{xx}(k, l) + r_{yy}(k, l) \quad (2.10)$$

- Dacă $x(k)$ și $y(l)$ sunt variabile aleatoare necorelate, autocovarianța sumei este egală cu suma autocovarianțelor,

$$c_{x+y, x+y}(k, l) = c_{xx}(k, l) + c_{yy}(k, l) \quad (2.11)$$

Proces aleator staționar

Dacă proprietățile statistice sunt independente de timp se zice că procesul este staționar.

De exemplu, dacă densitatea de probabilitate de ordinul 1, $w_{x(n)}(x) = w_x(x)$ nu depinde de n , rezultă că media $m_x(n) = m_x$ nu depinde de n . Se spune în acest caz că procesul este *staționar de ordinul 1* sau *staționar în medie*.

Dacă în plus, densitatea de probabilitate de ordinul 2, satisface condiția

$$w_{x(k)x(l)}(x_1, x_2) = w_{x(k+n)x(l+n)}(x_1, x_2) \quad (2.12)$$

pentru orice n întreg, se spune că procesul este *staționar de ordinul doi*. În acest caz funcția de autocorelație va fi

$$r_{xx}(k, l) = r_{xx}(k+n, l+n) \quad (\forall) n \in \mathbb{Z} \quad (2.13)$$

sau luând $n=-l$,

$$r_{xx}(k, l) = r_{xx}(k-l, 0) = r_{xx}(k-l) \quad (2.14)$$

deci funcția de autocorelație depinde numai de diferența momentelor de timp $k-l$.

În fine, dacă proprietatea de mai sus poate fi extinsă pentru densitățile de probabilitate de orice ordin, se spune că procesul este *staționar în sens strict*.

Deoarece frecvent interesează numai mediile de ordin 1 și 2, este utilă noțiunea de proces aleator *staționar în sens larg*, definit ca un proces pentru care:

- $m_x(n) = m_x$ constant;
- $r_{xx}(k, l) = r_{xx}(k-l)$ depinde numai de diferența momentelor de timp;
- $c_{xx}(0) < \infty$ (este finit).

Deoarece condițiile acestea se pun numai asupra momentelor, ele sunt mai slabe decât cele impuse asupra densităților de probabilitate.

Proprietăți ale funcțiilor de corelație pentru procese aleatoare staționare în sens larg

Pentru această categorie de procese aleatoare sunt evidente următoarele relații:

$$r_{xy}(k) = E\{x(n+k)y^*(n)\} = E\{x(n)y^*(n-k)\} \quad (2.15)$$

$$r_{xx}(k) = E\{x(n+k)x^*(n)\} = E\{x(n)x^*(n-k)\} \quad (2.16)$$

$$r_{yx}(k) = E\{y(n+k)x^*(n)\} = E\{x(n)y^*(n+k)\}^* = r_{xy}^*(-k) \quad (2.17)$$

În particular

$$r_{xx}(k) = r_{xx}^*(-k) \quad (2.18)$$

deci *secvența de autocorelație este conjugat simetrică*.

Având în vedere că

$$c_{xy}(k) = r_{xy}(k) - m_x m_y^* \quad (2.19)$$

rezultă de asemenea

$$c_{yx}(k) = c_{xy}^*(-k) \quad (2.20)$$

deci, în particular, și funcția de autocovarianță este conjugat simetrică, și

$$c_{xx}(k) = r_{xx}(k) - |m_x|^2 \quad (2.21)$$

În fine, valoarea din origine a funcției de autocorelație,

$$r_{xx}(0) = E\{|x(n)|^2\} \quad (2.22)$$

reprezintă *valoarea medie pătratică* a procesului aleator $x(n)$. Se poate demonstra că *modulul funcției de autocorelație își atinge maximul în origine*,

$$|r_{xx}(n)| < r_{xx}(0), \quad n \neq 0 \quad (2.23)$$

Valoarea în origine a funcției de autocovarianță este numită *varianță*

$$\text{var}\{x\} = c_{xx}(0) = \sigma_x^2 = r_{xx}(0) - |m_x|^2 \quad (2.24)$$

unde σ_x este *dispersia*.

2.1.2 Medii temporale. Ergodicitate

Valorile medii prezentate până aici sunt medii statistice, pe ansamblul tuturor realizărilor posibile. Deși sunt foarte utile pentru multe aplicații, frecvent ele nu sunt cunoscute. Se pune problema de a estima aceste valori medii pornind de la cunoașterea eșantioanelor succesive ale unei singure realizări particulare a procesului aleator.

Dacă se cunosc $2N+1$ eșantioane ale unei realizări particulare, se poate evalua media aritmetică a acestora,

$$\hat{m}_x(N) = \frac{1}{2N+1} \sum_{n=-N}^N x(n) \quad (2.25)$$

Se pune problema în ce măsură cantitatea de mai sus tinde către media statistică $E\{x(n)\}$, atunci când N crește. Evident problema are sens numai dacă procesul este staționar în medie (deci dacă media statistică este constantă).

Se spune că $m_x(N)$ tinde către m_x în medie pătratică dacă

$$\lim_{N \rightarrow \infty} E\{|\hat{m}_x(N) - m_x|^2\} = 0 \quad (2.26)$$

Un proces care satisface relația de mai sus se zice că este *ergodic în medie* și vom scrie că:

$$\lim_{N \rightarrow \infty} \hat{m}_x(N) = m_x = E\{x(n)\} \quad (2.27)$$

Se poate demonstra că o condiție necesară și suficientă pentru ca un proces staționar în sens larg să fie ergodic în medie este

$$\lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N c_{xx}(n) = 0 \quad (2.28)$$

Ideea de estimare temporală se poate extinde și asupra altor medii. Pentru funcția de autocorelație, putem porni de la secvența

$$y_k(n) = x(n+k)x^*(n) \quad (2.29)$$

Introducem estimatorul:

$$\hat{r}_{xx}(k, N) = \frac{1}{2N+1} \sum_{n=-N}^N y_k(n) = \frac{1}{2N+1} \sum_{n=-N}^N x(n+k)x^*(n) \quad (2.30)$$

Dacă acesta converge în medie pătratică spre $r_x(k)$,

$$\lim_{N \rightarrow \infty} E \left\{ \left| \hat{r}_{xx}(k, N) - r_{xx}(k) \right|^2 \right\} = 0 \quad (2.31)$$

se spune că procesul este *ergodic în autocorelație* și se scrie

$$\lim_{N \rightarrow \infty} \hat{r}_{xx}(k, N) = r_{xx}(k) \quad (2.32)$$

În particular, pentru un asemenea proces putem scrie:

$$r_{xx}(0) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N x^*(n)x(n) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N |x(n)|^2 \quad (2.33)$$

Această expresie reprezintă însă *puterea medie a semnalului*, deci rezultă valabilitatea afirmației:

Funcția de autocorelație evaluată în origine este egală cu puterea medie a semnalului.

Relația

$$r_{xx}(0) = \sigma_x^2 + |m_x|^2 \quad (2.34)$$

pune în evidență două componente ale acestei puteri; prima, dată de varianța semnalului, se referă la componentele variabile ale semnalului, în timp ce ultima, este datorată valorii medii.

Vom accepta în general faptul că

$$\lim_{n \rightarrow \infty} c_{xx}(n) = 0 \quad (2.35)$$

Aceasta corespunde ipotezei naturale că două eșantioane luate la momente de timp foarte depărtate devin practic necorelate. Se poate demonstra că această condiție are drept urmare faptul că procesul aleator este ergodic în medie.

2.1.3 Proprietăți spectrale

Vom introduce transformata Z a funcției de autocovarianță.

$$Z\{c_{xx}(n)\} = \sum_{n=-\infty}^{\infty} c_{xx}(n)z^{-n} \triangleq P_{xx}(z) \quad (2.36)$$

$$c_{xx}(n) = Z^{-1}\{P_{xx}(z)\}(n) = \frac{1}{2\pi j} \oint_C P_{xx}(z)z^{n-1} dz$$

unde C este un cerc inclus în domeniul de convergență al lui $P_{xx}(z)$.

S-a văzut că $c_{xx}(n) = c_{xx}^*(-n)$, astfel încât :

$$P_{xx}(z) = \sum_{n=-\infty}^{\infty} c_{xx}^*(-n)z^{-n} = \sum_{n=-\infty}^{\infty} c_{xx}^*(n)z^n = P_{xx}^*\left(\frac{1}{z^*}\right) \quad (2.37)$$

În particular, în cazul unui semnal real,

$$P_{xx}(z) = P_{xx}(z^{-1}). \quad (2.38)$$

În consecință, domeniul de convergență este de forma $R_- < |z| < R_+$, iar relația de mai sus conduce la $R_+ = 1/R_-$.

Aceasta înseamnă că dacă domeniul de convergență este nevid, $R_- < 1$, $R_+ > 1$, deci cercul $|z| = 1$ este inclus în domeniul de convergență. Trecând deci pe cercul $z = e^{j\omega}$, se obțin relațiile Wiener-Hincin:

$$c_{xx}(n) = \frac{1}{2\pi} \int_{-\pi}^{\pi} P_{xx}(e^{j\omega}) e^{jn\omega} d\omega = \text{TFTDI}\{P_{xx}(e^{j\omega})\}(n) \quad (2.39)$$

$$P_{xx}(e^{j\omega}) = \sum_{n=-\infty}^{\infty} c_{xx}(n) e^{-jn\omega} = \text{TFTD}\{c_{xx}(n)\}(\omega)$$

unde s-au notat cu TFTD și TFTDI transformatele Fourier în timp discret directă și inversă. Pentru $n=0$,

$$c_{xx}(0) = \frac{1}{2\pi} \int_{-\pi}^{\pi} P_{xx}(e^{j\omega}) d\omega \quad (2.40)$$

relație ce justifică numele de *densitate spectrală de putere* dat funcției $P_{xx}(e^{j\omega})$ pentru semnale cu valoare medie nulă, deoarece în acest caz

$$c_{xx}(0) = r_{xx}(0) = E\{|x(n)|^2\} \quad (2.41)$$

reprezintă puterea medie a semnalului.

În concluzie:

- Secvența de autocovarianță și funcția densitate spectrală de putere reprezintă o pereche de transformate Fourier.
- Această proprietate se extinde și asupra funcției de autocorelație pentru semnale cu valoare medie nulă. Acesta este și motivul pentru care în multe lucrări se întâlnește afirmația că funcția de autocorelație și densitatea spectrală de putere formează o pereche de transformate Fourier. Se remarcă însă că dacă valoarea medie nu este nulă, transformata Z a funcției de autocorelație are domeniul de convergență vid, iar transformata Fourier conține un impuls delta în origine.
- Funcția densitate spectrală de putere este o funcție reală de ω , după cum rezultă din relația (2.37). În plus, din (2.38) rezultă că densitatea spectrală de putere a unui semnal real este o funcție pară de ω .

- Puterea medie a unui semnal se poate evalua cu

$$E\{|x(n)|^2\} = \frac{1}{2\pi} \int_{-\pi}^{\pi} P_{xx}(e^{j\omega}) d\omega = \frac{1}{2\pi j} \oint_C P_{xx}(z) z^{-1} dz \quad (2.42)$$

$$C = \{z \in \mathbb{C} \mid |z| = 1\}$$

- Urmând un procedeu analog celui prezentat mai înainte, se poate introduce și o funcție *densitate de putere de interacțiune* a două procese, definită ca transformată Z a secvenței $c_{xy}(n)$.

Aplicația 1

Zgomotul alb se poate defini prin

$$r_{xx}(k) = \sigma_x^2 \delta(k) \quad (2.43)$$

Vom presupune în plus că valoarea medie este nulă, așa încât varianța

$$r_{xx}(0) = c_{xx}(0) = \sigma_x^2 \quad (2.44)$$

reprezintă puterea medie. Conform relațiilor de mai sus, zgomotul alb se caracterizează prin aceea că două eșantioane diferite sunt necorelate. Pe de altă parte, densitatea spectrală de putere este

$$P_{xx}(e^{j\omega}) = \sum_{n=-\infty}^{\infty} \sigma_x^2 \delta(n) e^{-jn\omega} = \sigma_x^2 \quad (2.45)$$

constantă, ceea ce justifică denumirea de zgomot alb și poate constitui o definiție echivalentă cu precedenta. Aparent, ar exista o contradicție între faptul că σ_x^2 reprezintă puterea și în același timp și densitatea de putere. Aceasta provine din faptul că se utilizează frecvențe normale, deci

$$P_{xx}(e^{j\omega}) = \sigma_x^2 \text{ pentru } \omega \in [0, 2\pi] \quad (2.46)$$

În frecvențe nenormate, densitatea spectrală de putere se exprimă prin

$$P_{xx}(e^{j\Omega}) = \frac{\sigma_x^2}{F_s} \text{ pentru } \Omega \in [0, 2\pi F_s] \quad (2.47)$$

Aplicația 2

Fie un proces aleator staționar discret caracterizat prin

$$E\{x(n)\} = 0, \quad r_{xx}(k) = \alpha^{|k|}, \quad 0 < \alpha < 1$$

Să evaluăm și să reprezentăm, ca funcție de ω , densitatea spectrală de putere.

$$P_{xx}(z) = Z\{r_{xx}(k)\} = \sum_{k=-\infty}^{\infty} \alpha^{|k|} z^{-k} = \sum_{k=-\infty}^{-1} (\alpha z)^{-k} + \sum_{k=0}^{\infty} (\alpha z^{-1})^k = \sum_{k=1}^{\infty} (\alpha z)^k + \sum_{k=0}^{\infty} (\alpha z^{-1})^k$$

Prima din cele două progresii geometrice este convergentă dacă:

$$|\alpha z| < 1 \Rightarrow |z| < \frac{1}{\alpha}$$

iar a doua, dacă

$$|\alpha z^{-1}| < 1 \Rightarrow |z| > \alpha$$

Rezultă domeniul comun de convergență,

$$\alpha < |z| < \frac{1}{\alpha}$$

nevid dacă $0 < \alpha < 1$, în care

$$P_{xx}(z) = \alpha z \frac{1}{1-\alpha z} + \frac{1}{1-\alpha z^{-1}} = \frac{1-\alpha^2}{(1-\alpha z)(1-\alpha z^{-1})}$$

Deoarece domeniul de convergență include cercul $|z|=1$, are sens

$$P_{xx}(e^{j\omega}) = \frac{1-\alpha^2}{(1-\alpha e^{j\omega})(1-\alpha e^{-j\omega})} = \frac{1-\alpha^2}{1+\alpha^2-2\alpha \cos \omega}$$

În figura 2.1 este reprezentată funcția de autocorelație pentru $\alpha=0,5$ (cu linie plină) și $\alpha=0,9$ (cu linie punctată). Evident, cu cât α este mai mic, $r_{xx}(k)$ scade mai repede (eșantioanele având un anumit decalaj în timp sunt mai slab corelate). În figura 2.2, sunt reprezentate densitățile spectrale de putere în cele două cazuri.




Fig. 2.1 Funcțiile de autocorelație pentru $\alpha = 0,5$ (linie plină) și $\alpha = 0,9$ (linie punctată)




Fig. 2.2 Densitățile spectrale de putere pentru $\alpha = 0,5$ (linie plină) și $\alpha = 0,9$ (linie punctată)

Se vede că la valori mai mici ale lui α , rezultă o mai mare "împrăștiere" a puterii în frecvență (semnalul se apropie mai mult de un zgomot alb, când $\alpha \rightarrow 0$). Exemplul considerat ilustrează de fapt o proprietate mai generală, conform căreia "durata" funcției de autocorelație și lărgimea de bandă a spectrului de putere al semnalului se află într-o dependență inversă.

2.1.4 Matricea de autocorelație a unui proces staționar

Fie seria temporală trunchiată, reprezentată prin vectorul

$$\mathbf{x}(n) = [x(n), x(n-1), \dots, x(n-N+1)]^T \quad (2.48)$$

unde x este un proces staționar în sens larg. Se definește matricea de autocorelație prin:

$$\mathbf{R} = E\{\mathbf{x}(n)\mathbf{x}^H(n)\} = \begin{bmatrix} r(0) & r(1) & \dots & r(N-1) \\ r(-1) & r(0) & \dots & r(N-2) \\ \vdots & \vdots & \ddots & \vdots \\ r(-N+1) & r(-N+2) & \dots & r(0) \end{bmatrix} \quad (2.49)$$

unde indicele H semnifică operațiile de conjugare și transpunere, iar

$$r(k) = E\{x^*(n)x(n+k)\} = E\{x^*(n-k)x(n)\} \quad (2.50)$$

este funcția de autocorelație a vectorului $\mathbf{x}(n)$. Altfel spus, elementul liniei i și coloanei j al matricei \mathbf{R} este $R_{ij} = r(j-i)$.

Având în vedere rolul foarte important pe care această matrice îl are în analiza statistică, vom prezenta în continuare o serie de proprietăți ale acesteia.

1) Matricea de autocorelație pentru un proces aleator staționar în sens larg este *hermitică*:

$$\mathbf{R}^H = \mathbf{R}$$

Acest lucru este evident din definiție (forma compactă) sau din forma dezvoltată, având în vedere că $r(-k) = r^*(k)$.

2) Matricea \mathbf{R} este o matrice *Toeplitz* (are toate elementele de pe diagonala principală egale, iar elementele de pe orice altă diagonală paralelă cu diagonala principală, de asemenea, egale între ele).

3) Matricea \mathbf{R} este *pozitiv semidefinită*. Pentru a demonstra această proprietate, vom arăta că pentru orice vector complex nenul \mathbf{u} de dimensiune $N \times 1$,

$$\mathbf{u}^H \mathbf{R} \mathbf{u} = \sum_{i=1}^N \sum_{j=1}^N r(j-i) \mathbf{u}_i^* \mathbf{u}_j \geq 0. \quad (2.51)$$

Într-adevăr,

$$\mathbf{u}^H \mathbf{R} \mathbf{u} = \mathbf{u}^H E\{\mathbf{x}(n)\mathbf{x}^H(n)\}\mathbf{u} = E\{\mathbf{u}^H \mathbf{x}(n)\mathbf{x}^H(n)\mathbf{u}\} = E\{|\mathbf{u}^H \mathbf{x}(n)|^2\} \geq 0. \quad (2.52)$$

4) Fie $\mathbf{x}^B(n)$ vectorul obținut inversând ordinea elementelor vectorului $\mathbf{x}(n)$:

$$\mathbf{x}^B(n) = [x(n-N+1), x(n-N+2), \dots, x(n)]^T \quad (2.53)$$

Matricea de autocorelație a acestui vector se obține prin transpunerea matricei \mathbf{R} inițiale:

$$E\{\mathbf{x}^B(n)\mathbf{x}^{BH}(n)\} = \mathbf{R}^T. \quad (2.54)$$

5) Matricea \mathbf{R} așa cum a fost definită, este de dimensiune $N \times N$. Putem pune în evidență acest lucru, adăugând un indice inferior (\mathbf{R}_N). Adăugând încă un element la vectorul $\mathbf{x}(n)$ va rezulta o *matrice de autocorelație extinsă* de dimensiune $(N+1) \times (N+1)$ pe care o notăm deci \mathbf{R}_{N+1} . Se poate ușor vedea că sunt posibile următoarele partiții:

$$\mathbf{R}_{N+1} = \begin{bmatrix} r(0) & \mathbf{r}^H \\ \mathbf{r} & \mathbf{R}_N \end{bmatrix} = \begin{bmatrix} \mathbf{R}_N & \mathbf{r}^{B*} \\ \mathbf{r}^{BT} & r(0) \end{bmatrix} \quad (2.55)$$

unde

$$\mathbf{r}^H = [r(1), r(2), \dots, r(N)] \quad (2.56)$$

$$\text{Fie } \lambda_i \text{ valorile proprii ale matricei } \mathbf{R}, \text{ deci rădăcinile ecuației caracteristice} \\ \det(\mathbf{R} - \lambda \mathbf{I}) = 0 \quad (2.57)$$

și \mathbf{q}_i vectorii proprii asociați,

$$\mathbf{R}\mathbf{q}_i = \lambda_i \mathbf{q}_i, \quad i = 1, \dots, N. \quad (2.58)$$

6) Valorile proprii ale matricei \mathbf{R}^k , unde k este întreg, sunt λ_i^k , $i=1, 2, \dots, N$.

7) Dacă valorile proprii λ_i , $i=1, \dots, N$ sunt distincte, atunci vectorii \mathbf{q}_i corespunzători sunt liniar independenți, și pot fi deci utilizați ca o bază pentru reprezentarea oricărui vector \mathbf{w} în spațiul respectiv.

8) Toate valorile proprii ale matricei de autocorelație sunt reale și pozitive. Este o consecință a proprietăților 1 și 3. Într-adevăr, înmulțind la stânga relația (2.58) cu \mathbf{q}_i^H se obține

$$\lambda_i = \frac{\mathbf{q}_i^H \mathbf{R} \mathbf{q}_i}{\mathbf{q}_i^H \mathbf{q}_i} \geq 0 \quad (2.59)$$

9) Vectorii proprii \mathbf{q}_i , \mathbf{q}_j , corespunzători unor valori proprii distincte, $\lambda_i \neq \lambda_j$, $i, j = 1, 2, \dots, N$, $i \neq j$, sunt ortogonali,

$$\mathbf{q}_j^H \mathbf{q}_i = 0 \quad (2.60)$$

Pentru demonstrație vom scrie, conform definiției:

$$\mathbf{R}\mathbf{q}_i = \lambda_i \mathbf{q}_i, \quad \mathbf{R}\mathbf{q}_j = \lambda_j \mathbf{q}_j \quad (2.61)$$

și vom înmulți prima relație cu \mathbf{q}_j^H ,

$$\mathbf{q}_j^H \mathbf{R} \mathbf{q}_i = \lambda_i \mathbf{q}_j^H \mathbf{q}_i \quad (2.62)$$

Celei de-a doua relații i se aplică o transpunere hermitică (transpunere și conjugare complexă), ținând seama și de proprietatea 1,

$$\mathbf{q}_j^H \mathbf{R}^H = \mathbf{q}_j^H \mathbf{R} = \lambda_j \mathbf{q}_j^H \quad (2.63)$$

după care se înmulțește cu \mathbf{q}_i la dreapta

$$\mathbf{q}_j^H \mathbf{R} \mathbf{q}_i = \lambda_j \mathbf{q}_j^H \mathbf{q}_i \quad (2.64)$$

și se scade din ecuația obținută mai înainte,

$$(\lambda_i - \lambda_j) \mathbf{q}_j^H \mathbf{q}_i = 0 \quad (2.65)$$

care demonstrează proprietatea enunțată. În particular, deoarece prin înmulțirea unui vector propriu cu o constantă se obține tot un vector propriu, se poate construi un set ortonormat de vectori proprii

$$\mathbf{q}_j^H \mathbf{q}_i = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases} \quad (2.66)$$

10) Matricea \mathbf{R} poate fi diagonalizată în cazul în care valorile proprii sunt distincte conform relației:

$$\mathbf{Q}^H \mathbf{R} \mathbf{Q} = \mathbf{\Lambda} \quad (2.67)$$

unde

$$\mathbf{Q} = [\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_N], \quad \mathbf{\Lambda} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_N) \quad (2.68)$$

iar \mathbf{q}_i reprezintă un set ortonormal de vectori proprii. Evident, matricea \mathbf{Q} este unitară, în sensul că:

$$\mathbf{Q}^H \mathbf{Q} = \mathbf{I}, \quad \text{sau} \quad \mathbf{Q}^{-1} = \mathbf{Q}^H. \quad (2.69)$$

Demonstrația proprietății este imediată, având în vedere că din relațiile (2.58) rezultă:

$$\mathbf{R} \mathbf{Q} = \mathbf{Q} \mathbf{\Lambda} \quad (2.70)$$

și înmulțind la stânga cu \mathbf{Q}^H se obține (2.67).

Înmulțind aceeași ecuație cu $\mathbf{Q}^{-1} = \mathbf{Q}^H$ rezultă *teorema lui Mercer* sau *teorema spectrală*:

$$\mathbf{R} = \mathbf{Q} \mathbf{\Lambda} \mathbf{Q}^H = \sum_{i=1}^N \lambda_i \mathbf{q}_i \mathbf{q}_i^H. \quad (2.71)$$

11) *Urma matricei \mathbf{R}* , adică suma elementelor de pe diagonala principală, este egală cu suma valorilor proprii

$$\text{tr}(\mathbf{R}) = \sum_{i=1}^N \lambda_i \quad (2.72)$$

Este o proprietate mai generală a matricelor pătrate, care în cazul de față conduce la

$$r(0) = \frac{1}{N} \sum_{i=1}^N \lambda_i. \quad (2.73)$$

12) Se definește *norma spectrală* a unei matrice \mathbf{A} prin

$$\|\mathbf{A}\|_s = \left(\text{valoarea proprie maxima a matricei } \mathbf{A}^H \mathbf{A} \right)^{\frac{1}{2}} \quad (2.74)$$

În cazul matricei \mathbf{R} , aceasta înseamnă, ținând seama de proprietățile 1 și 6,

$$\|\mathbf{R}\|_s = \lambda_{\max}. \quad (2.75)$$

Se definește *numărul condițional* al unei matrice, prin

$$\chi(\mathbf{A}) = \|\mathbf{A}\|_s \|\mathbf{A}^{-1}\|_s \quad (2.76)$$

În cazul matricei \mathbf{R} :

$$\|\mathbf{R}\|_s = \lambda_{\max}, \quad \|\mathbf{R}^{-1}\|_s = \frac{1}{\lambda_{\min}}, \quad \Rightarrow \quad \chi(\mathbf{R}) = \frac{\lambda_{\max}}{\lambda_{\min}} \quad (2.77)$$

unde λ_{\min} și λ_{\max} sunt respectiv valoarea proprie minimă și maximă ale matricei \mathbf{R} . Se spune că o matrice este “rău condiționată” când acest număr are valori mari, aceasta conducând la dificultăți în calculul numeric.

13) *Câțul Rayleigh* asociat unui vector \mathbf{u} nenul, de dimensiune $N \times 1$, definit prin

$$\frac{\mathbf{u}^H \mathbf{R} \mathbf{u}}{\mathbf{u}^H \mathbf{u}} \quad (2.78)$$

ia valori limitate inferior și superior conform:

$$\lambda_{\min} = \min \frac{\mathbf{u}^H \mathbf{R} \mathbf{u}}{\mathbf{u}^H \mathbf{u}}, \quad \lambda_{\max} = \max \frac{\mathbf{u}^H \mathbf{R} \mathbf{u}}{\mathbf{u}^H \mathbf{u}} \quad (2.79)$$

Acesta este o consecință a "teoremei minimax" din algebra liniară.

14) Valorile proprii ale matricei de autocorelație sunt mărginite superior și inferior de valorile maximă și respectiv, minimă ale densității spectrale de putere,

$$\min_{\omega} P_{xx}(e^{j\omega}) \leq \lambda_i \leq \max_{\omega} P_{xx}(e^{j\omega}) \quad (2.80)$$

Exemple:

1) Cazul unui zgomot alb:

$$r(k) = E\{x^*(n)x(n+k)\} = \begin{cases} \sigma^2, & k = 0 \\ 0, & k \neq 0 \end{cases}$$

deci

$$\mathbf{R} = \sigma^2 \mathbf{I}$$

2) Cazul unei sinusoidă complexe, $x(n) = A e^{jn\omega}$, $A = |A| e^{j\varphi}$ în care A și ω sunt niște constante, iar φ este o variabilă aleatoare.

$$r(k) = E\{A e^{-j\varphi} e^{-jn\omega} |A| e^{j\varphi} e^{j(n+k)\omega}\} = |A|^2 e^{jk\omega}$$

$$\mathbf{R} = |A|^2 \begin{bmatrix} 1 & e^{j\omega} & \dots & \dots & e^{j(N-1)\omega} \\ e^{-j\omega} & 1 & \dots & \dots & e^{j(N-2)\omega} \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ e^{-j(N-1)\omega} & e^{-j(N-2)\omega} & \dots & \dots & 1 \end{bmatrix} = |A|^2 \mathbf{e}(\omega) \mathbf{e}^H(\omega)$$

unde

$$\mathbf{e}(\omega) = [1, e^{-j\omega}, \dots, e^{-j(N-1)\omega}]^T$$

1) Sinusoidă complexă însumată cu zgomot alb, cu valoare medie nulă,

$$x(n) = A e^{jn\omega} + v(n)$$

$$r(k) = \begin{cases} |A|^2 + \sigma^2, & k = 0 \\ |A|^2 e^{jk\omega}, & k \neq 0 \end{cases}$$

$$\mathbf{R} = \begin{bmatrix} |A|^2 + \sigma^2 & |A|^2 e^{j\omega} & \dots & \dots & |A|^2 e^{j(N-1)\omega} \\ |A|^2 e^{-j\omega} & |A|^2 + \sigma^2 & \dots & \dots & |A|^2 e^{j(N-2)\omega} \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ |A|^2 e^{-j(N-1)\omega} & |A|^2 e^{-j(N-2)\omega} & \dots & \dots & |A|^2 + \sigma^2 \end{bmatrix}$$

2.2 RĂSPUNSUL SISTEMELOR DISCRETE ÎN TIMP LA PROCESE ALEATOARE

Fie $x(n)$ un proces aleator staționar în sens larg aplicat unui sistem liniar, invariant în timp, cu funcția de pondere $h(n)$. Semnalul de la ieșirea sistemului, $y(n)$, poate fi exprimat prin convoluția

$$y(n) = \sum_{k=-\infty}^{\infty} h(k)x(n-k) = x(n) * h(n) \quad (2.81)$$

- *Valoarea medie a semnalului la ieșire*

$$E\{y(n)\} = E\left\{\sum_{k=-\infty}^{\infty} h(k)x(n-k)\right\} = \sum_{k=-\infty}^{\infty} h(k)E\{x(n-k)\} = m_x \sum_{k=-\infty}^{\infty} h(k) = m_x H(e^{j0}) \quad (2.82)$$

- *Funcția de corelație între semnalele de la ieșire și intrare*

$$r_{yx}(k) = E\{y(n+k)x^*(n)\} = E\left\{\sum_{l=-\infty}^{\infty} h(l)x(n+k-l)x^*(n)\right\} = \sum_{l=-\infty}^{\infty} h(l)E\{x(n+k-l)x^*(n)\}$$

$$r_{yx}(k) = \sum_{l=-\infty}^{\infty} h(l)r_{xx}(k-l) = r_{xx}(k) * h(k) \quad (2.83)$$

- *Funcția de autocorelație a ieșirii*

$$\begin{aligned} r_{yy}(k) &= E\{y(n+k)y^*(n)\} = E\left\{y(n+k)\sum_{l=-\infty}^{\infty} x^*(l)h^*(n-l)\right\} = \sum_{l=-\infty}^{\infty} h^*(n-l)E\{y(n+k)x^*(l)\} = \\ &= \sum_{l=-\infty}^{\infty} h^*(-l)r_{yx}(k-l) = r_{yx}(k) * h^*(-k) \end{aligned} \quad (2.84)$$

Ținând seama de expresia obținută pentru funcția $r_{yx}(k)$ rezultă

$$r_{yy}(k) = r_{xx}(k) * h(k) * h^*(-k) \quad (2.85)$$

Rezultatele obținute pot fi reprezentate sintetic prin schema din figura 2.3.




Fig. 2.3 Schemă pentru calculul funcției de autocorelație la ieșirea sistemului

- *Densitatea spectrală de putere a semnalului de ieșire*

Vom presupune în cele ce urmează că semnalul de intrare are valoare medie nulă, deci

$$Z\{r_{xx}(k)\} = P_{xx}(z); \quad Z\{r_{yy}(k)\} = P_{yy}(z) \quad (2.86)$$

și vom nota funcția de transfer a sistemului

$$H(z) = Z\{h(n)\} \quad (2.87)$$

Rezultă imediat

$$Z\{h^*(-n)\} = H^*\left(\frac{1}{z^*}\right) \quad (2.88)$$

deci având în vedere expresia obținută mai înainte pentru r_{yy} și teorema convoluției,

$$P_{yy}(z) = P_{xx}(z)H(z)H^*\left(\frac{1}{z^*}\right) \quad (2.89)$$

sau, în frecvență:

$$P_{yy}(e^{j\omega}) = P_{xx}(e^{j\omega})|H(e^{j\omega})|^2 \quad (2.90)$$

- *Puterea medie a semnalului la ieșire.*

Presupunând în continuare valoarea medie a semnalului nulă,

$$r_{yy}(0) = c_{yy}(0) = \sigma_y^2 = \frac{1}{2\pi} \int_{-\pi}^{\pi} P_{yy}(e^{j\omega}) d\omega = \frac{1}{2\pi} \int_{-\pi}^{\pi} P_{xx}(e^{j\omega}) |H(e^{j\omega})|^2 d\omega \quad (2.91)$$

Utilizând transformate Z,

$$\sigma_y^2 = \frac{1}{2\pi j} \oint_C P_{yy}(z) z^{-1} dz = \frac{1}{2\pi j} \oint_C P_{xx}(z) H(z) H^*\left(\frac{1}{z^*}\right) z^{-1} dz, \quad C = \{z \in \mathbb{C} \mid |z| = 1\} \quad (2.92)$$

În cazul unui sistem cu funcție de pondere reală, rămâne:

$$\sigma_y^2 = \frac{1}{2\pi j} \oint_C P_{xx}(z) H(z) H(z^{-1}) z^{-1} dz, \quad C = \{z \in \mathbb{C} \mid |z| = 1\} \quad (2.93)$$

O exprimare temporală se obține pornind de la (2.84) care pentru $k=0$ conduce la

$$\sigma_y^2 = r_{yy}(0) = \sum_{l=-\infty}^{\infty} h^*(l) r_{yx}(l) = \sum_{l=-\infty}^{\infty} \sum_{m=-\infty}^{\infty} h^*(l) r_{xx}(l-m) h(m) \quad (2.94)$$

deci

$$\sigma_y^2 = E\{|y(n)|^2\} = \mathbf{h}^H \mathbf{R} \mathbf{h} \quad (2.95)$$

unde \mathbf{h} este vectorul coloană format cu elementele $h(n)$, iar \mathbf{R} este matricea de autocorelație. Această exprimare prezintă interes în special în cazul filtrelor cu răspuns finit la impuls, când dimensiunile lui \mathbf{h} și \mathbf{R} sunt finite.

- *Aplicație în cazul unui zgomot alb* cu valoare medie nulă $m_x=0$ și varianță (putere medie) σ_x^2 ;

$$r_{xx}(k) = \sigma_x^2 \delta(k), \quad P_{xx}(z) = \sigma_x^2$$

$$\sigma_y^2 = \frac{1}{2\pi j} \sigma_x^2 \oint_C H(z)H(z^{-1})z^{-1} dz = \frac{1}{2\pi} \sigma_x^2 \int_{-\pi}^{\pi} |H(e^{j\omega})|^2 d\omega$$

2.3 FACTORIZAREA SPECTRALĂ. TEOREMA LUI WOLD

2.3.1. Procese aleatoare regulate. Factorizarea spectrală.

Densitatea spectrală de putere, $P_{xx}(e^{j\omega})$, pentru un proces aleator discret, staționar în sens larg, este o funcție reală, pozitivă și periodică. Vom arăta în continuare că, dacă ea este o funcție continuă de ω , $P_{xx}(z)$ poate fi factorizat sub forma:

$$P_{xx}(z) = \sigma_0^2 Q(z) Q^* \left(\frac{1}{z^*} \right) \quad (2.96)$$

Relația de mai sus definește *factorizarea spectrală* a lui $P_{xx}(z)$.

Fie $x(n)$ un proces staționar în sens larg, cu valoare medie nulă și cu o densitate spectrală de putere $P_{xx}(e^{j\omega})$, continuă (ceea ce presupune absența componentelor periodice):

$$P_{xx}(z) = \sum_{n=-\infty}^{\infty} r_{xx}(n) z^{-n} \quad (2.97)$$

Să presupunem, în plus, că $\ln P_{xx}(z)$ este analitică într-o coroană circulară $R < |z| < \frac{1}{R}$, $R < 1$, conținând cercul unitate. Ca urmare, este posibilă o dezvoltare în serie Laurent:

$$\ln P_{xx}(z) = \sum_{n=-\infty}^{\infty} a(n) z^{-n} \quad (2.98)$$

sau pe cercul unitar

$$\ln P_{xx}(e^{j\omega}) = \sum_{n=-\infty}^{\infty} a(n) e^{-jn\omega} \quad (2.99)$$

Din ultima relație rezultă că $a(n)$ reprezintă coeficienții dezvoltării în serie Fourier ai funcției periodice $\ln P_{xx}(e^{j\omega})$. Deoarece aceasta e o funcție reală, rezultă că secvența $a(n)$ este conjugat simetrică,

$$a(n) = a^*(-n) \quad (2.100)$$

$$a(0) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \ln P_{xx}(e^{j\omega}) d\omega \quad (2.101)$$

Secvența $a(n)$ poartă numele de *cepstrum* al secvenței $r_{xx}(n)$. Mai departe

$$P_{xx}(z) = \exp\{a(0)\} \exp\left\{ \sum_{n=1}^{\infty} a(n) z^{-n} \right\} \exp\left\{ \sum_{n=-\infty}^{-1} a(n) z^{-n} \right\} \quad (2.102)$$

Vom defini:

$$Q(z) = \exp\left\{ \sum_{n=1}^{\infty} a(n) z^{-n} \right\}, \quad |z| > R \quad (2.103)$$

Deoarece $Q(z)$ și $\ln Q(z)$ sunt analitice în $|z| > R$, înseamnă că $Q(z)$ este o funcție de fază minimă (fără nuluri în exteriorul cercului de rază unitate). Ultimul termen din factorizarea lui $P(z)$ mai poate fi scris :

$$\exp\left\{\sum_{n=-\infty}^{-1} a(n)z^{-n}\right\} = \exp\left\{\sum_{n=1}^{\infty} a(-n)z^n\right\} = \exp\left\{\sum_{n=1}^{\infty} a(n)\left(\frac{1}{z}\right)^{-n}\right\}^* = Q^*\left(\frac{1}{z^*}\right) \quad (2.104)$$

așa încât

$$P_{xx}(z) = \sigma_0^2 Q(z) Q^*\left(\frac{1}{z^*}\right) \quad (2.105)$$

unde

$$\sigma_0^2 = \exp\left\{\frac{1}{2\pi} \int_{-\infty}^{\infty} \ln P(e^{j\omega}) d\omega\right\} \quad (2.106)$$

Un proces care îndeplinește condițiile precizate mai înainte și admite o asemenea factorizare spectrală se spune că este un *proces regulat*.

Proprietăți ale proceselor regulate.

- Un asemenea proces poate fi considerat ca ieșirea unui filtru stabil și cauzal, având la intrare zgomot alb cu varianța σ_0^2 (figura 2.4.a).




Fig. 2.4 Reprezentarea unui proces staționar în sens larg cu ajutorul inovațiilor

Această reprezentare a procesului aleator $x(n)$ este cunoscută în literatură sub denumirea de *reprezentare cu ajutorul inovațiilor*.

- Filtrul având funcția de transfer inversă, $1/Q(z)$, poate fi considerat un *filtru de albire* pentru procesul aleator cu densitatea spectrală de putere $P_{xx}(z)$.
- $Q(z)$ poate fi reprezentat printr-o serie de puteri:

$$Q(z) = q(0) + q(1)z^{-1} + q(2)z^{-2} + \dots \quad (2.107)$$

unde $q(0) = 1$, deoarece evident

$$\lim_{z \rightarrow \infty} Q(z) = q(0) = 1 \quad (2.108)$$

- Dacă $P_{xx}(z)$ este o funcție rațională, atunci

$$Q(z) = \frac{B(z)}{A(z)} \quad (2.109)$$

și factorizarea are forma:

$$P_{xx}(z) = \sigma_0^2 Q(z) Q^* \left(\frac{1}{z^*} \right) = \sigma_0^2 \frac{B(z) B^* \left(\frac{1}{z^*} \right)}{A(z) A^* \left(\frac{1}{z^*} \right)} \quad (2.110)$$

unde

$$\begin{aligned} A(z) &= 1 + a(1)z^{-1} + a(2)z^{-2} + \dots + a(N)z^{-N} \\ B(z) &= 1 + b(1)z^{-1} + b(2)z^{-2} + \dots + b(M)z^{-M} \end{aligned} \quad (2.111)$$

iar polinoamele $A(z)$, $B(z)$ au toate zerourile în interiorul cercului de rază unitate.

2.3.2 Teorema lui Wold

Forma reprezentare a semnalelor aleatoare, prezentată mai înainte, fiind după cum s-a văzut, supusă unor restricții, nu este cea mai generală.

Teorema lui Wold stabilește că un proces staționar în sens larg poate fi descompus în două părți:

-un proces regulat $x_r(n)$

-un proces predictibil $x_p(n)$

Se spune că un proces $x_p(n)$ este predictibil dacă există un set de coeficienți $a(n)$, așa încât:

$$x_p(n) = \sum_{k=1}^{\infty} a(k) x_p(n-k) \quad (2.112)$$

Altfel spus, orice eșantion poate fi determinat fără eroare, cunoscând eșantioanele precedente.

Se poate însă arăta că pentru un asemenea proces, densitatea spectrală de putere este de forma:

$$P_p(e^{j\omega}) = \sum_{k=1}^N \alpha_k \delta(\omega - \omega_k) \quad (2.113)$$

Rezultă că o formă generală a densității spectrale de putere este

$$P(e^{j\omega}) = P_r(e^{j\omega}) + \sum_{k=1}^N \alpha_k \delta(\omega - \omega_k) \quad (2.114)$$

unde $P_r(e^{j\omega})$, partea continuă a spectrului, corespunde unui proces regulat.

2.4 ELEMENTE DE TEORIA ESTIMĂRII

Noțiunea de estimare în prelucrarea semnalelor se referă la deducerea valorilor unor mărimi necunoscute sau aleatoare pornind de la un set de observații ce reprezintă variabile aleatoare.

Din afirmația de mai sus rezultă existența a două aspecte distincte.

a. *Estimarea parametrilor* - se referă la aflarea unor parametri determinați dar necunoscuți pornind de la setul de observații. Exemple: determinarea valorii medii, a funcției de autocorelație, a densității spectrale de putere pentru un proces aleator staționar.

b. *Estimarea unei variabile aleatoare.* De exemplu, determinarea eșantioanelor de la intrarea unui sistem cunoscând ieșirea acestuia, suprapusă peste un zgomot. Este evident o problemă mai complexă decât prima.

În cele ce urmează ne vom concentra atenția numai asupra primului aspect.

Să presupunem că se dorește estimarea unui parametru θ al densității de probabilitate $w_x(x;\theta)$ a unui proces aleator x pe baza observațiilor $\mathbf{x}^o = [x(0), x(1), \dots, x(N-1)]^T$. Vom nota cu

$$\hat{\theta} = \hat{\theta}(\mathbf{x}^o) \quad (2.115)$$

o estimare a lui θ , realizată pe baza setului de observații \mathbf{x}^o . Aceasta este evident o funcție de \mathbf{x}^o (vector aleator) și în consecință este de asemenea o variabilă aleatoare. Pentru aprecierea unui estimator se pot utiliza diverși indicatori.

- *Deplasarea* unui estimator se definește prin:

$$B(\theta) = E(\hat{\theta}) - \theta \quad (2.116)$$

Se spune că estimatorul e nedepășat dacă $B(\theta) = 0$. Dacă $B(\theta) \rightarrow 0$ când $N \rightarrow \infty$, estimatorul se numește *asimptotic nedepășat*.

- *Eroarea pătratică medie:*

$$\text{EPM} = E\left\{|\hat{\theta} - \theta|^2\right\} \quad (2.117)$$

- *Varianța și dispersia:*

$$\text{var}(\hat{\theta}) = \sigma_{\hat{\theta}}^2 = E\left\{|\hat{\theta} - E(\hat{\theta})|^2\right\} \quad (2.118)$$

- *Consistența* unui estimator. Un estimator e consistent dacă pentru orice $\varepsilon > 0$, oricât de mic,

$$\lim_{N \rightarrow \infty} \Pr\left\{|\hat{\theta} - \theta| > \varepsilon\right\} = 0 \quad (2.119)$$

- *Funcția de plauzibilitate* este definită prin densitatea de probabilitate

$$l(\theta) = w_x(x, \theta) \quad (2.120)$$

În unele cazuri este mai convenabil să se lucreze cu logaritmul acestei funcții,

$$L(\theta) = \ln(w_x(x, \theta)) \quad (2.121)$$

Dacă θ este un vector cu M componente, $L(\theta)$ este și el un vector

$$\mathbf{L}(\theta) = [L(\theta_1), L(\theta_2), \dots, L(\theta_M)]^T \quad (2.122)$$

- *Măsura informației unui parametru în sensul Fischer*

$$I(\theta) = -E\left\{\frac{\partial^2 L(\theta)}{\partial \theta^2}\right\} = -E\left\{\frac{\partial^2 \ln w_x(x, \theta)}{\partial \theta^2}\right\} \quad (2.123)$$

Se poate demonstra că este posibilă și următoarea exprimare echivalentă

$$I(\theta) = E\left\{\left(\frac{\partial L(\theta)}{\partial \theta}\right)^2\right\} = E\left\{\left(\frac{\partial \ln w_x(x, \theta)}{\partial \theta}\right)^2\right\} \quad (2.124)$$

Evident, o posibilitate de a găsi un estimator este de a maximiza după θ funcția de plauzibilitate,

$$\hat{\theta}(\mathbf{x}) = \arg \max_{\theta} \{w_x(\mathbf{x}, \theta)\} \quad (2.125)$$

Un asemenea estimator se numește *de plauzibilitate maximă*.

Dacă θ este un vector cu M componente, această măsură se exprimă printr-o matrice de dimensiuni $M \times M$, având drept elemente

$$I_{k,l} = -E \left\{ \frac{\partial^2 \ln w_x(x, \theta)}{\partial \theta_k \partial \theta_l} \right\} \quad (2.126)$$

sau, altfel scris,

$$\mathbf{I}(\theta) = -E \left\{ \nabla \mathbf{L}(\theta) (\nabla \mathbf{L}(\theta))^T \right\} \quad (2.127)$$

- *Marginea Cramér-Rao* reprezintă o valoare minimă pentru varianța unui estimator nedeplasat. În cazul unui estimator θ scalar, presupunând că derivata a doua a funcției $L(\theta)$ există și este absolut integrabilă,

$$\text{var}(\hat{\theta}) = \sigma_{\hat{\theta}}^2 \geq I^{-1}(\theta) \quad (2.128)$$

În relația de mai sus se obține egalitate dacă și numai dacă estimatorul satisface relația

$$\hat{\theta}(\mathbf{x}) - \theta = K(\theta) \frac{\partial L(\theta)}{\partial \theta} \quad (2.129)$$

în care $K(\theta)$ nu depinde de valoarea estimată.

Dacă această limită este atinsă, se spune că estimatorul este *de varianță minimă* sau că este *eficient*. În cazul unui estimator vectorial, inegalitatea de mai sus se transformă în afirmația că matricea

$$\mathbf{C}_{\hat{\theta}} - \mathbf{I}^{-1}(\theta) \quad (2.130)$$

unde $\mathbf{C}_{\hat{\theta}}$ este matricea de autocovarianță a estimatorului, este pozitiv semidefinită. În acest caz estimatorul de varianță minimă se obține dacă

$$\hat{\theta}(\mathbf{x}) - \theta = K(\theta) \nabla \{L(\theta)\} \quad (2.131)$$

Aplicații

1. Estimarea valorii medii.

Fie o variabilă aleatoare gaussiană, caracterizată prin:

$$w_x(x; m) = \frac{1}{\sqrt{2\pi\sigma_0^2}} e^{-\frac{(x-m)^2}{2\sigma_0^2}}$$

Să presupunem cunoscut setul de observații independente $\mathbf{x} = [x_0, x_1, \dots, x_{N-1}]^T$. Densitatea de probabilitate de ordinul N este deci

$$w_x(\mathbf{x}; m) = \prod_{i=1}^N w_x(x_i; m) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma_0^2}} e^{-\frac{(x_i-m)^2}{2\sigma_0^2}}$$

$$L(m) = -\frac{N}{2} \ln(2\pi\sigma_0^2) - \sum_{i=0}^{N-1} \frac{(x_i - m)^2}{2\sigma_0^2}$$

$$\frac{\partial L(m)}{\partial m} = \sum_{i=0}^{N-1} \frac{x_i - m}{\sigma_0^2}$$

Egalând cu 0 această cantitate se obține estimatorul de plauzibilitate maximă:

$$\hat{m} = \frac{1}{N} \sum_{i=0}^{N-1} x_i$$

Evident, estimatorul este nedeplasat, căci:

$$E\{\hat{m}\} = \frac{1}{N} E\left\{\sum_{i=0}^{N-1} x_i\right\} = m$$

Varianța estimatorului este

$$\text{var}\{\hat{m}\} = \frac{1}{N^2} \sum_{i=0}^{N-1} \text{var}\{x_i\} = \frac{\sigma_0^2}{N}$$

În fine,

$$I(m) = -E\left\{\frac{\partial^2 L(m)}{\partial m^2}\right\} = \frac{N}{\sigma_0^2}$$

deci

$$\text{var}(\hat{m}) = I^{-1}(m)$$

asa încât estimatorul este și de varianță minimă. Lucrul acesta era de așteptat având în vedere că

$$\hat{m}(\mathbf{x}) - m = \frac{1}{N} \sum_{i=0}^{N-1} x_i - m = \frac{\sigma_0^2}{N} \frac{\partial L(m)}{\partial m}$$

2. Estimarea dispersiei.

Pentru același caz al variabilei gaussiene,

$$\frac{\partial L(\sigma_0^2)}{\partial(\sigma_0^2)} = -\frac{N}{2\sigma_0^2} + \sum_{i=0}^{N-1} \frac{(x_i - m)^2}{\sigma_0^4}$$

Egalând cu zero se obține estimatorul varianței:

$$\hat{\sigma}_0^2 = \frac{1}{N} \sum_{i=0}^{N-1} (x_i - m)^2$$

Dacă m nu este cunoscut, se va utiliza pentru el estimatorul obținut mai înainte:

$$\hat{\sigma}_0^2 = \frac{1}{N} \sum_{i=0}^{N-1} (x_i - \hat{m})^2$$

Să calculăm valoarea medie a estimatorului:

$$\begin{aligned} E\{\hat{\sigma}_0^2\} &= \frac{1}{N} \sum_{i=0}^{N-1} \left(E\{x_i^2\} + E\{\hat{m}^2\} - 2E\{x_i \hat{m}\} \right) = \\ &= \frac{1}{N} \sum_{i=0}^{N-1} \left(E\{x_i^2\} + \frac{1}{N^2} \sum_{l=0}^{N-1} \sum_{j=0}^{N-1} E\{x_l x_j\} - \frac{2}{N} \sum_{j=0}^{N-1} E\{x_i x_j\} \right) \end{aligned}$$

Observațiile fiind presupuse independente:

$$E\{x_i x_j\} = \begin{cases} E\{x_i^2\} & i = j \\ E\{x_i\}E\{x_j\} = m^2, & i \neq j \end{cases}$$

așa încât, ținând seama și de staționaritate,

$$E\{\hat{\sigma}_0^2\} = \frac{1}{N} \sum_{i=0}^{N-1} \left(\frac{N-1}{N} (E\{x_i^2\} - m^2) \right) = \frac{N-1}{N} \sigma_0^2$$

Se constată că estimatorii de plauzibilitate maximă a varianței sau ai dispersiei sunt deplasați. Totuși,

$$\lim_{N \rightarrow \infty} E\{\hat{\sigma}_0^2\} = \sigma_0^2$$

deci ei sunt asimptotic nedeplasați. Uneori se preferă utilizarea estimatorului nedeplasat al dispersiei:

$$\hat{\sigma}_0^2 = \sqrt{\frac{1}{N-1} \sum_{i=0}^{N-1} (x_i - \hat{m})^2}$$

3. Estimatori pentru funcția de autocorelație

Vom considera un proces aleator staționar $x(n)$ de valoare medie nulă, deci:

$$r_{xx}(m) = c_{xx}(m) = E\{x^*(n)x(n+m)\}$$

Procesul fiind ergodic,

$$r_{xx}(m) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N x^*(n)x(n+m)$$

Ne propunem să găsim un estimator utilizând numai setul de observații $x(n)$, $n=0, \dots, N-1$, deci pornind de la:

$$x_N(n) = \begin{cases} x(n), & n \in [0, N-1] \\ 0 & n \notin [0, N-1] \end{cases}$$

Vom defini:

$$\hat{r}_{xx}(m) = \frac{1}{M} \sum_{n=-\infty}^{\infty} x_N^*(n)x_N(n+m)$$

unde M poate fi astfel ales încât să se obțină un estimator nedeplasat. Având în vedere suporturile finite,

$$\text{supp } x_N(n) = [0, N-1], \quad \text{supp } x_N^*(n+m) = [-m, N-1-m],$$

rezultă $\hat{r}_{xx}(m) = 0$ pentru $|m| > N-1$.

Pentru $m=0, \dots, N-1$, limitele de însumare vor fi 0 și $N-1-m$, așa încât în general vom putea scrie:

$$\hat{r}_{xx}(m) = \begin{cases} \frac{1}{M} \sum_{n=-\infty}^{\infty} x_N^*(n)x_N(n+m), & m \in [0, N-1] \\ \hat{r}_{xx}^*(-m), & m \in [-(N-1), -1] \end{cases}$$

Valoarea medie a estimatorului este:

$$\begin{aligned} E\{\hat{r}_{xx}(m)\} &= \frac{1}{M} \sum_{n=0}^{N-1-m} E\{x_N^*(n)x_N(n+m)\} = \\ &= \frac{1}{M} \sum_{n=0}^{N-1-m} r_{xx}(m) = \frac{N-m}{M} r_{xx}(m), \quad m = 0, 1, \dots, N-1 \end{aligned}$$

În mod asemănător, pentru $m = -(N-1), \dots, -1$ se obține:

$$E\{\hat{r}_{xx}(m)\} = \frac{N+m}{M} r_{xx}(m)$$

deci în general:

$$E\{\hat{r}_{xx}(m)\} = \frac{N-|m|}{M} r_{xx}(m)$$

și rezultă o deplasare a estimatorului:

$$B(\hat{r}_{xx}(m)) = E(\hat{r}_{xx}(m)) - r_{xx}(m) = \frac{N-|m|-M}{M} r_{xx}(m)$$

Pentru a obține un estimator nedeplasat se poate lua $M=N-|m|$ deci:

$$\hat{r}_{xx}(m) = \begin{cases} \frac{1}{N-m} \sum_{n=0}^{N-1-m} x_N^*(n)x_N(n+m), & m \in [0, N-1] \\ \hat{r}_{xx}^*(-m), & m \in [-(N-1), -1] \end{cases}$$

sau cu o exprimare unitară:

$$\hat{r}_{xx}(m) = \frac{1}{N-|m|} \sum_{n=0}^{N-1-|m|} x_N^*(n)x_N(n+m), \quad m \in [-(N-1), N-1]$$

Uneori se preferă să se ia $M=N$ și rezultă:

$$\hat{r}_{xx}(m) = \begin{cases} \frac{1}{N} \sum_{n=0}^{N-1-m} x_N^*(n)x_N(n+m), & m \in [0, N-1] \\ \hat{r}_{xx}^*(-m), & m \in [-(N-1), -1] \end{cases}$$

Acesta este evident un *estimator deplasat*, deoarece:

$$E(\hat{r}_{xx}(m)) = \frac{N-|m|}{N} r_{xx}(m)$$

Totuși când $N \rightarrow \infty$

$$\lim_{N \rightarrow \infty} E\{\hat{r}_{xx}(m)\} = r_{xx}(m)$$

și deci estimatorul acesta este *asimptotic nedeplasat*.

2.5 MODELAREA PROCESELOR ALEATOARE

2.5.1 Modele ARMA. Forme particulare

În multe cazuri întâlnite în practică, procesul aleator poate fi modelat ca ieșire $x(n)$ a unui sistem liniar, invariant în timp, caracterizat printr-o funcție de transfer rațională, $H(z)$,

$$H(z) = \frac{B(z)}{A(z)} = \frac{\sum_{k=0}^M b_k z^{-k}}{1 + \sum_{k=1}^N a_k z^{-k}} \quad (2.132)$$

căruia i se aplică la intrare un semnal $u(n)$. Frecvent, $u(n)$ este un zgomot alb, el fiind cel care imprimă caracterul aleator al lui $x(n)$. El reprezintă o parte intrinsecă a modelului. Vom putea exprima deci $x(n)$ cu ajutorul ecuației cu diferențe finite:

$$x(n) = \sum_{k=0}^M b_k u(n-k) - \sum_{k=1}^N a_k x(n-k) \quad (2.133)$$

Acest model este cunoscut în literatură sub denumirea de model "ARMA" (auto regressive-moving average), deci *autoregresiv cu mediere mobilă*.

$H(z)$ se presupune un filtru stabil și causal, așa încât nulosurile lui $A(z)$ se găsesc în interiorul cercului $|z|=1$.

Se știe că densitatea spectrală de putere a semnalului de la ieșire se poate calcula cu:

$$P_{xx}(e^{j\omega}) = |H(e^{j\omega})|^2 P_{uu}(e^{j\omega}) \quad (2.134)$$

În cazul când $u(n)$ este zgomot alb, cu $P_{uu}(e^{j\omega}) = \sigma^2$,

$$P_{xx}(e^{j\omega}) = \sigma^2 |H(e^{j\omega})|^2 \quad (2.135)$$

Fără a pierde din generalitate, vom considera că $a_0=b_0=1$, deoarece câștigul filtrului poate fi încorporat în σ^2 . Se utilizează frecvent notația ARMA (M,N), care pune în evidență gradele număratorului și numitorului.

Forme particulare

-Modelul *autoregresiv* (AR), notat $AR(N)=ARMA(0,N)$ se obține pentru $M=0$. Rămân ecuația cu diferențe finite :

$$x(n) = -\sum_{k=1}^N a_k x(n-k) + u(n) \quad (2.136)$$

și funcția de transfer:

$$H(z) = \frac{1}{A(z)} = \frac{1}{1 + \sum_{k=1}^N a_k z^{-k}} \quad (2.137)$$

-Modelul *mediere mobilă* (MA), notat $MA(M)=ARMA(M,0)$, rezultă particularizând $N=0$:

$$x(n) = \sum_{k=0}^M b_k u(n-k) \quad (2.138)$$

$$H(z) = B(z) = \sum_{k=0}^M b_k z^{-k} \quad (2.139)$$

Un proces ARMA(M, N), pentru M și N finiți, poate fi reprezentat printr-un proces AR(∞) sau printr-un proces MA(∞). Să ilustrăm această afirmație printr-un exemplu. Fie procesul ARMA(1,1), caracterizat prin funcția de transfer:

$$H(z) = \frac{1 + b_1 z^{-1}}{1 + a_1 z^{-1}}, \quad |a_1| < 1, \quad |b_1| < 1 \quad (2.140)$$

Pentru a-l exprima ca un model AR, $H(z)$ trebuie pus sub forma:

$$H(z) = \frac{1}{C(z)}, \quad C(z) = 1 + \sum_{k=1}^{\infty} c_k z^{-k} = \frac{z + a_1}{z + b_1} \quad (2.141)$$

Dar

$$c_k = Z^{-1} \left\{ \frac{z + a_1}{z + b_1} \right\} (k) \quad (2.142)$$

deci

$$c_k = (a_1 - b_1)(-b_1)^{k-1} \quad \text{pentru } k \geq 1 \quad (2.143)$$

Dacă se dorește aproximarea procesului ARMA(1,1) cu un proces AR(L), cu L finit, va fi necesar un ordin L cu atât mai mare cu cât nulul $z = -b_1$ este mai apropiat de cercul $|z|=1$.

Pentru a echivala procesul ARMA(1,1) cu un proces MA(∞) vom scrie:

$$H(z) = \frac{z + b_1}{z + a_1} = 1 + \sum_{k=1}^{\infty} d_k z^{-k} \quad (2.144)$$

din care

$$d_k = Z^{-1} \left\{ \frac{z + b_1}{z + a_1} \right\} (k) = (b_1 - a_1)(-a_1)^{k-1} \quad \text{pentru } k \geq 1 \quad (2.145)$$

Și în acest caz, dacă se dorește o aproximare a procesului ARMA(1,1) cu un proces MA(L) de ordin finit, L va fi cu atât mai mare cu cât polul $z = -a_1$ al procesului ARMA este situat mai aproape de cercul $|z|=1$.

2.5.2 Relații între parametrii modelului și funcția de autocorelație

Vom presupune că $u(n)$ este un zgomot alb cu valoare medie nulă și varianță σ^2 .

Atunci:

$$P_{xx}(z) = \frac{B(z)}{A(z)} \frac{B^* \left(\frac{1}{z^*} \right)}{A^* \left(\frac{1}{z^*} \right)} \sigma^2 \quad (2.146)$$

sau

$$P_{xx}(z)A(z) = H^* \left(\frac{1}{z^*} \right) B(z) \sigma^2 \quad (2.147)$$

Vom aplica transformata z inversă acestei relații și vom ține seama că:

$$Z^{-1} \{ P_{xx}(z) \} (k) = c_{xx}(k) = r_{xx}(k) \quad (2.148)$$

deoarece $x(n)$ va avea și el valoarea medie nulă, și

$$Z^{-1}\left\{H^*\left(\frac{1}{z^*}\right)\right\} = \sum_{n=0}^{\infty} h^*(-n)z^{-n} \quad (2.149)$$

Rezultă, folosind teorema convoluției și cauzalitatea secvenței $h(n)$:

$$\sum_{l=0}^N a_l r_{xx}(k-l) = \begin{cases} \sigma^2 \sum_{l=0}^M b_l h^*(l-k) = \sigma^2 \sum_{l=k}^M b_l h^*(l-k), & k = \overline{[0, M]} \\ 0, & k \geq M+1 \end{cases} \quad (2.150)$$

de unde:

$$r_{xx}(k) = \begin{cases} -\sum_{l=1}^N a_l r_{xx}(k-l) + \sigma^2 \sum_{l=k}^M b_l h^*(l-k), & k = \overline{[0, M]} \\ -\sum_{l=1}^N a_l r_{xx}(k-l), & k \geq M+1 \end{cases} \quad (2.151)$$

Acestea relații sunt cunoscute sub denumirea de *ecuațiile Yule-Walker*. În principiu, ele permit determinarea parametrilor modelului dacă se cunosc funcțiile de autocorelație. Cum în foarte multe cazuri acestea nu sunt cunoscute, ele pot fi eventual estimate, așa cum s-a văzut în paragraful precedent, pe baza cunoașterii unui număr de eșantioane (măsurări sau observații) ale unei realizări particulare a procesului aleator. Rezolvarea sistemului este simplă doar în cazul proceselor AR, când, deoarece $M=0$, dispăre practic a doua sumă, care imprimă un caracter neliniar ecuațiilor.

Pe de altă parte, ecuațiile Yule-Walker oferă o metodă recursivă de calcul a funcțiilor de autocorelație, dacă sunt cunoscuți parametrii modelului.

Alegerea unui model adecvat procesului studiat este esențială. Este util ca modelul ales să aibă un număr minim de parametri. În cazul în care procesul studiat se caracterizează printr-o densitate spectrală de putere cu maxime "ascuțite", este indicată alegerea unui model AR, știind că asemenea maxime se obțin datorită unor poli situați în apropierea cercului $|z|=1$. Dacă, din contră, ea se caracterizează prin minime pronunțate, eventual anulări, este indicată alegerea unui model MA cu zerouri situate în apropierea sau pe cercul $|z|=1$. Când intervin ambele tipuri de comportări ale densității spectrale de putere, se va alege un model ARMA. Un alt parametru ce trebuie avut în vedere este și panta caracteristicii densitate spectrală de putere - frecvență. O pantă mare (variație rapidă) va necesita pentru simulare un proces AR sau ARMA de ordin mare.

Bibliografie

- [B1] **Bellanger M.G.**, *Adaptive Digital Filters and Signal Analysis*, M. Dekker, New York, 1987.
- [Ci2] **Ciochină S.**, *Prelucrarea numerică a semnalelor*, partea II, UPB, 1986.
- [Ha1] **Haykin S.**, *Adaptive Filter Theory*, Prentice Hall, Englewood Cliffs, N.J., 1991.
- [Ka1] **Kay S.M.**, *Modern Spectrum Analysis*, Prentice Hall, Englewood Cliffs, New Jersey, 1987.
- [N1] **Negrescu C.**, *Bazele algoritmilor adaptivi de gradient. Metode de optimizare*, UPB, 1997.
- [Op1] **Oppenheim A.V., Schafer R.W.**, *Discrete-Time Signal Processing*, Prentice Hall, Englewood Cliffs, New Jersey, 1989.
- [Pa1] **Papoulis A.**, *Random Variables and Stochastic Processes*, Mc Graw-Hill, New York, 1991
- [Pr2] **Proakis J.G., Rader C.M., Ling F., Nikias C.L.**, *Advanced Digital Signal Processing Algorithms*, Macmillan Publishing Company, 1992.
- [St1] **Stanomir D.**, *Semnale și sisteme discrete*, Ed. Athena, 1997.
- [SM1] **Stoica P., Moses R.**, *Introduction to spectral analysis*, Prentice Hall, 1997.
- [Th1] **Therrien C. W.**, *Discrete Random Signals and Statistical Signal Processing*, Prentice Hall, Englewood Cliffs, New Jersey, 1992.

