

## Lucrarea 13

### Metode parametrice de analiză spectrală

Metodele neparametrice expuse anterior foloseau transformata Fourier în estimarea densității spectrale de putere a unui semnal. Constrângerile impuse de calculul transformatei Fourier determină limitări severe în rezoluția frecvențială, limitări ce devin inacceptabile dacă este necesar să se analizeze semnale de scurtă durată. Mai mult, aceste metode suferă de un fenomen numit *scurgere spectrală* (*spectral leakage*) ca efect al convoluției dintre spectrul unei ferestre cu spectrul semnalului care determină o lărgire a spectrului. Acest lucru poate conduce la mascarea unor componente spectrale de amplitudine mică. Cu ajutorul metodelor parametrice o parte din dezavantajele metodelor clasice sunt înlăturate.

Una din principalele limitări ale metodelor neparametrice era aceea că estimatul funcției de autocorelației  $r_{xx}[m]$  era zero pentru  $m \geq N$ . Metodele moderne pornesc de la stabilirea unui model al procesului ce a generat eşantioanele de date, bazat pe existența unor informații apriori sau a unor ipoteze. Vor trebui parcurse următoarele etape:

- selectarea modelului corespunzător seriei temporale respective;
- estimarea (identificarea) parametrilor modelului respectiv pornind de la datele (observațiile) de care se dispune;
- calculul estimatorului spectral prin înlocuirea parametrilor estimați în formula densității spectrale de putere specifice modelului.

#### 1. Modele pentru procese aleatoare

Modelele parametrice se bazează pe considerația că secvența de date  $x[n]$  este ieșirea unui sistem liniar caracterizat de o funcție de transfer rațională de forma:

$$H(z) = \frac{\sum_{k=0}^q b_k z^{-k}}{1 + \sum_{k=1}^p a_k z^{-k}} \quad (1)$$

Ecuția cu diferențe corespunzătoare este:

$$x[n] = -\sum_{k=1}^p a_k x[n-k] + \sum_{k=0}^q b_k w[n-k] \quad (2)$$

unde  $w[n]$  este secvența de date din intrarea sistemului. Cu observația că dacă semnalul de intrare este un proces staționar atunci și ieșirea sistemului este un proces staționar, se poate scrie că densitatea spectrală de putere a lui  $x[n]$  este:

$$P_{xx}(f) = |H(f)|^2 P_w(f) \quad (3)$$

Cu presupunerea că semnalul  $w[n]$  este un proces de tip zgomot alb cu dispersia  $\sigma_w^2$  și cu medie nulă densitatea spectrală de putere (d.s.p.) devine:

$$P_{xx}(f) = \sigma_w^2 |H(f)|^2 \text{ sau în domeniul } Z \quad P_{xx}(z) = \sigma_w^2 H(z)H(z^{-1}) \quad (4)$$

Se pot identifica astfel trei modele corespunzătoare celor trei forme sub care se poate prezenta funcția de sistem  $H(z)$  :

- modelul **ARMA** (*autoregresiv cu medie alunecătoare*) denumit și *poli-zerouri* cu:

$$H(z) = \frac{b_0 + b_1 z^{-1} + \dots + b_q z^{-q}}{1 + a_1 z^{-1} + \dots + a_p z^{-p}} \quad (5)$$

$H(z)$  are  $q$  zerouri și  $p$  poli.

- modelul **MA** (*medie alunecătoare*) denumit și *numai-zerouri* cu

$$H(z) = b_0 + b_1 z^{-1} + \dots + b_q z^{-q} \quad (6)$$

- modelul **AR** (*autoregresiv*) denumit și *numai-poli* cu :

$$H(z) = \frac{1}{1 + a_1 z^{-1} + \dots + a_p z^{-p}} \quad (7)$$

Dintre cele trei modele liniare cel mai folosit este pe departe modelul AR. Avantajele acestuia sunt:

- spectrul dedus cu un model AR de ordin mic are o rezoluție satisfăcătoare;
- parametrii modelului se calculează relativ ușor în raport cu parametrii modelului ARMA. Pe de altă parte, calculul densității spectrale de putere cu ajutorul modelului MA este într-un fel asemănător periodogramei, de aceea modelul MA nu este folosit în metodele parametrice.

În lucrarea de față se va trata modelul AR și calculul d.s.p. cu ajutorul acestui model.

## 2. Estimarea spectrului de putere pentru semnale modelate AR

Relațiile dintre funcția de autocorelație și parametrii modelului sunt:

$$\gamma_{xx}[m] = \begin{cases} -\sum_{k=1}^p a_k \gamma_{xx}[m-k] & m > q \\ -\sum_{k=1}^p a_k \gamma_{xx}[m-k] + \sigma_w^2 \sum_{k=0}^{q-m} h[k] b_{k+m} & 0 \leq m \leq q \\ \gamma_{xx}^*[-m] & m < 0 \end{cases} \quad (8)$$

Dacă se adoptă un model  $AR(p)$  pentru datele observate, relația dintre parametrii modelului și secvența de autocorelație se obține din (8), pentru  $q=0$ , adică:

$$\gamma_{xx}[m] = \begin{cases} -\sum_{k=1}^p a_k \gamma_{xx}[m-k] & m > 0 \\ -\sum_{k=1}^p a_k \gamma_{xx}[m-k] + \sigma_w^2 & m = 0 \\ \gamma_{xx}^*[-m] & m < 0 \end{cases} \quad (9)$$

În acest caz parametrii  $\{a_k\}$  se obțin din soluția sistemului de ecuații

$$\begin{bmatrix} \gamma_{xx}[0] & \gamma_{xx}[-1] & \dots & \gamma_{xx}[-p+1] \\ \gamma_{xx}[1] & \gamma_{xx}[0] & \dots & \gamma_{xx}[-p+2] \\ \dots & \dots & \dots & \dots \\ \gamma_{xx}[p-1] & \gamma_{xx}[p-2] & \dots & \gamma_{xx}[0] \end{bmatrix} \cdot \begin{bmatrix} a_1 \\ a_2 \\ \dots \\ a_p \end{bmatrix} = - \begin{bmatrix} \gamma_{xx}[1] \\ \gamma_{xx}[2] \\ \dots \\ \gamma_{xx}[p] \end{bmatrix} \quad (10)$$

care reprezintă ecuațiile Yule-Walker sau normale.

Dispersia  $\sigma_w^2$  poate fi obținută din ecuația:

$$\sigma_w^2 = \gamma_{xx}[0] + \sum_{k=1}^p a_k \gamma_{xx}[-k] \quad (11)$$

Ecuațiile (10) și (11) sunt de obicei combinate în una singură, de forma

$$\begin{bmatrix} \gamma_{xx}[0] & \gamma_{xx}[-1] & \dots & \gamma_{xx}[-p] \\ \gamma_{xx}[1] & \gamma_{xx}[0] & \dots & \gamma_{xx}[-p+1] \\ \dots & \dots & \dots & \dots \\ \gamma_{xx}[p] & \gamma_{xx}[p-1] & \dots & \gamma_{xx}[0] \end{bmatrix} \cdot \begin{bmatrix} 1 \\ a_1 \\ \dots \\ a_p \end{bmatrix} = \begin{bmatrix} \sigma_w^2 \\ 0 \\ \dots \\ 0 \end{bmatrix} \quad (12)$$

sau

$$\begin{bmatrix} \gamma \\ \mathbf{a} \end{bmatrix} = \begin{bmatrix} \sigma_w^2 \\ \mathbf{0} \end{bmatrix} \quad (13)$$

Realizând inversa matricei  $[\gamma]$  se pot calcula parametrii modelului AR. Pentru un ordin  $p$  al modelului AR, trebuie calculate  $p+1$  valori ale funcției de autocorelației  $\gamma_{xx}$ . O soluție recursivă eficientă în mod particular pentru această problemă se poate obține cu ajutorul algoritmului *Levinson-Durbin*.

În afara eficacității, sale acest algoritm permite determinarea ordinului adecvat pentru un model AR, ceea ce este deosebit de util, deoarece nu este cunoscut apriori. Algoritmul Levinson-Durbin pune în evidență faptul că eroarea de predicție este o funcție necrescătoare cu ordinul modelului, nu are un minim absolut și nu permite să alegem un ordin care să fie asociat cu cea mai mică eroare din toate modelele posibile. Există mai multe criterii folosite în alegerea ordinului modelului.

Două din cele mai bune criterii pentru selectarea ordinului modelului au fost propuse de Akaike:

1. *Criteriul erorii de predicție finale FPE (Final Prediction Error)* în care ordinul este selectat astfel încât să se minimizeze indicele de performanță

$$FPE(p) = \sigma_p^2 \left( \frac{N+p+1}{N-p-1} \right) \quad (14)$$

unde  $\sigma_p^2$  este dispersia estimată a erorii de predicție liniară.

2. *Criteriul informației Akaike AIC(p), (Akaike Information Criterion)* se bazează pe alegerea ordinului care minimizează cantitatea

$$AIC(p) = \ln \sigma_p^2 + 2p/N \quad (15)$$

Ordinul  $p$  al modelul se alege astfel încât să minimizeze cantitatea din (14) sau (15).

Pentru a calcula parametrii modelului trebuie cunoscute valorile funcției de autocorelație. Acestea nu sunt cunoscute a priori, ci trebuie estimate din secvența de date avută la dispoziție, ceea ce presupune un număr de observații mult mai mare decât ordinul modelului AR.

Pentru metoda Yule-Walker există funcțiile Matlab 'aryule' respectiv 'pyulear'.  
**a=aryule(x,ordin)** – returnează parametrii  $a_k$  ai modelului AR. Argumentele de intrare sunt: **x** - vectorul ce conține eșantioanele semnalului al cărui spectru trebuie estimat; **ordin** - ordinul modelului AR ales.  
**Pxx=pyulear(x,ordin)** - returnează direct estimatul spectrului semnalului.

### 3. Metoda Burg

Metoda elaborată de Burg se bazează tot pe algoritmul Levinson-Durbin pentru a determina estimății parametrilor modelului  $[\hat{a}_p]$ , singura diferență fiind aceea că parametrii modelului AR sunt determinați direct din datele  $x[n]$  evitând astfel estimarea autocorelației segmentului de date.

Avantajul major este acela că metoda dă rezultate bune și pentru lungimi reduse ale vectorului de date spre deosebire de metoda Yule-Walker unde, după cum se va vedea rezultatele nu sunt satisfăcătoare. Apar însă și dezavantaje, precum apariția a două linii spectrale în locul uneia singure efect denumit *line splitting* sau apariția unor componente spectrale (vârfuri) false la ordine prea mari.

Programul Matlab permite deducerea parametrilor modelului AR cu ajutorul acestei metode folosind funcția `arburg`. De asemenea se poate calcula direct densitatea spectrală de putere cu metoda Burg folosind funcția `pburg`. Acestea au sintaxa identică cu `aryule` și `pyulear`.

### 4. Aplicații rezolvate

**Exemplul 1.** Se generează o secvență de tip un zgomot alb, gaussian, cu medie nulă și dispersie 0.25 care va fi în intrarea unui filtru cu funcția de sistem:

$$H(z) = \frac{1}{1 + 0.5z^{-1} + 0.75z^{-2}}$$

Obiectul acestei aplicații este acela de a identifica procesul de tip AR și de a determina parametrii  $(\sigma^2, a_1, a_2)$  care corespund datelor. Se va utiliza funcția Matlab `zplane` pentru a reprezenta polii și zerourile filtrului. Se va arăta că spectrul semnalului filtrat este proporțional cu răspunsul în frecvență a filtrului.

%funcția de calcul a coeficientilor cu ajutorul modelului AR

```
function [coef, sigma2]=param_AR(semnal,ordin);
```

```

N=length(semnal);
r=xcorr(semnal,'unbiased');
[max1,pos]=max(r);
autocor_semnal=r(pos:pos+ordin);
matr_toeplitz=toeplitz(autocor_semnal);
parametri=inv(matr_toeplitz)*[1 ;zeros(ordin,1)];
coef=parametri/parametri(1);
sigma2=1/parametri(1);
zplane(1,coef');

%P13_1
noise=randn(1,2048)*0.5;
b=1 ;a=[1 0.5 0.75];
y=filter(b,a,noise);
y=y';
[coef,sigma2]=param_AR(y,2);
zplane(1,coef') ;
title('Polii unui proces AR deordin 2') ;

```

Se calculează apoi densitatea spectrală de putere a semnalului filtrat, completând programul P13\_1 cu următoarele linii:

```

%Reprezentarea spectrului
figure(2);
[H,w]=freqz(sigma2,coef);
plot(w/pi,abs(H));
title('Răspunsul în frecvență al filtrului');
xlabel('Frecvență normalizată');
ylabel('Amplitudine');

```

**Observație:** Se observă cu ușurință că răspunsul în frecvență al filtrului cu doi poli (complex-conjugați) corespunde unui Filtru Trece Bandă.

**Exemplul 2.** Se generează 512 de eșantioane dintr-un semnal sinusoidal (pur) cu frecvența de 50 Hz eșantionat cu 200 Hz și e reprezentă densitatea sa spectrală de putere considerând acest semnal ca un proces AR, pentru care se va determina ordinul optim conform criteriului FPE a lui Akaike (relația (14)).

În cadrul acestei aplicații se va folosi funcția **aryule**, funcție ce determină coeficienții modelului AR precum și eroarea pătratică folosind algoritmul Levinson-Durbin.

Sintaxa funcției **aryule**

```
[coef,sigma2]=aryule(semnal,ordin);
```

- semnal** - secvența pentru care se dorește determinarea spectrului;
- ordin** - ordinul  $p$  pentru care se face estimarea coeficienților;
- coef** - coeficienții returnați;
- sigma2** - eroarea pătratică medie.

Se generează o funcția **dsp\_ar** ce calculează d.s.p. cunoscând parametrii modelului AR și eroarea pătratică medie de estimare.

```

function [dsp,frecv]=dsp_ar(coef,sigma2,Ndsp);
[H,w]=freqz(1,coef,Ndsp);
plot(w/pi,abs(H));

```

```

dsp=sigma2*abs(H);
frecv=w/2/pi;

%P13_2
lung=512;
n=0:lung-1;
F1=50; Fs=200;
y=sin(2*pi*F1/Fs*n);
y=y' ;
FPE=0;
for ord=1:10;
    [coef,sigma2]=aryule(y,ord);
    FPE(ord)=((lung+ord+1)/(lung-ord-1))*sigma2;
    coef;
end;
[minim,ordinoptim]=min(FPE);
[coef,sigma2]=aryule(y,ordinoptim);
[dsp,f]=dsp_ar(coef,sigma2,lung);
plot(f,dsp);title('DSP al semnalului');
xlabel('Frecventa normalizata');
ylabel('Amplitudine');
ordinoptim
coef

```

**Exemplul 3.** Se generează un semnal compus din două sinusoidale ale căror frecvențe sunt:

**Prima sinusoidă**  
*frecvența* = 25 Hz  
*amplitudine* = 1

**A doua sinusoidă**  
*frecvența* = 50 Hz  
*amplitudine* = 0.1

peste care se suprapune un zgomot alb, gaussian, centrat de dispersie 0.031. Frecvența de eșantionare este de 200Hz.

Se va determina ordinul optim pentru un model AR și densitatea spectrală de putere a semnalului. De asemenea se va reprezenta eroarea finală de predicție pe un interval cuprins în jurul ordinului optim.

```

function [ordin,FPE]=akaike_fpe(y,start_ord,end_ord);
lung=length(y);
for ord=start_ord:end_ord;
    [coef,sigma2]=aryule(y,ord);
    FPE(ord)=((lung+ord)/(lung-ord))*sigma2;
end;
[min1,poz]=min(FPE);
ordin=start_ord+poz-1;

%P13_3
lung=512;
n=0:lung-1;
F1=25; F2=50; Fs=200;

maxord=100;
y=sin(2*pi*F1/Fs*n)+0.1*sin(2*pi*F2/Fs*n)+randn(1,lung)*0.031 ;
[ordin,FPE]=akaike_fpe(y,1,maxord) ;
[coef,sigma2]=aryule(y,ordin) ;
[dsp,f]=dsp_ar(coef,sigma2,1024) ;

```

```
subplot(2,1,1);plot(f,10*log10(dsp));
title('DSP');xlabel('Frecventa normalizata');ylabel('Amplitudine');
subplot(2,1,2);plot(FPE);axis([1 maxord 0 0.009]);
title('FPE');xlabel('Ordinul modelului AR');ylabel('Valoare FPE');
```

Comparați rezultatele cu cele obținute la metodele clasice.

Se va repeta exemplul de mai sus dar în acest caz se vor determina parametrii AR cu ajutorul metodei Burg. Se va substitui funcția 'aryule' cu funcția 'arburg' atât în scriptul pentru exemplul 3 (P13\_3) cât și în funcția 'akaike\_fpe'.

Repetăți aceleași operațiuni și pentru lungimea vectorului de date de 30. În acest caz maxord=15.

**Exemplul 4.** Se generează un semnal definit pe 20 eșantioane compus din două sinusoides de frecvență 23Hz, respectiv 36Hz și de amplitudine 1 și un zgomot alb, gaussian. Frecvența de eșantionare este 100Hz iar raportul semnal zgomot este de 20dB. Folosind un model AR(4) se va reprezenta densitatea spectrală de putere a semnalului cu ajutorul celor două metode Yule-Walker și Burg.

**Observație:** În Matlab sunt implementate funcțiile **pyulear** și **pburg**, funcții ce au sintaxa: **Pxx=pyulear(x,ordin)**; sau **Pxx=pburg(x,ordin)**; unde:

- x** - segmentul de date;
- ordin** – ordinul  $p$  al modelului AR;
- Pxx** - d.s.p. estimată a semnalului  $x$ .

```
%P13_4
lung=20;
n=0:lung-1;
F1=23; F2=36; Fs=100;
x=sin(2*pi*F1/Fs*n)+sin(2*pi*F2/Fs*n)+randn(1,lung)*sqrt(0.01) ;
X1=pyulear(x,4);
X2=pburg(x,4);
frecv=(0:length(X1)-1)/(2*length(X1));
plot(frecv,10*log10(X1),frecv,10*log10(X2),'r');
title('D.s.p. estimat cu metoda Y-W si Burg');
xlabel('Frecventa normalizata');
ylabel('Magnitudine (dB)');
legend('metoda Y-W','metoda Burg',-1); grid
```

Se observă că metoda Yule-Walker dă un estimat al spectrului extrem de neted în timp, în timp ce la metoda Burg se observă o mai bună estimare, însă cu apariția unei deplasări. Concluzia este că metoda Burg este superioară metodei Yule-Walker pentru lungimi de date reduse. Ca exercițiu se poate mări lungimea segmentului de date cu un ordin de mărime (de exemplu 256) și se poate constata că cele două metode dau rezultate asemănătoare.

**Exemplul 5.** Pentru a pune în evidență influența alegerii ordinului modelului asupra estimatului d.s.p. se va calcula d.s.p. pentru diverse ordine  $p$ . Folosind semnalul generat anterior se va estima d.s.p. a acestuia cu metoda Burg pentru mai multe ordine ale modelului AR: AR(2), AR(4), AR(16). Comentați rezultatele.

```
%P13_5
lung=100;
n=0:lung-1;
```

```

F1=23; F2=36; Fs=100;
x=sin(2*pi*F1/Fs*n)+sin(2*pi*F2/Fs*n)+rand(1,lung)*sqrt(0.01);

Pxx1=pburg(x,2);
Pxx2=pburg(x,4);
Pxx3=pburg(x,16);
frecv=(0:length(Pxx1)-1)/(2*length(Pxx1));
plot(frecv,10*log10(Pxx1));hold on;
plot(frecv,10*log10(Pxx2),'r');hold on;
plot(frecv,10*log10(Pxx3),'g');
legend('AR(2)', 'AR(4)', 'AR(16)',-1);
xlabel('Frecventa normalizata');
ylabel('Magnitudine (dB)');
title('D.S.P. cu metoda Burg'); grid

```

## 5. Aplicații propuse

1. Să se determine efectul fazei inițiale asupra estimatului cu metoda lui Burg. În aceste se vor genera șase semnale pe 20 de eșantioane de forma:

$$x_i[n] = \sin(2\pi f_1 n + \varphi_{1i}) + \cos(2\pi f_2 n + \varphi_{2i}) + w[n]$$

unde  $f_1 = 0.23$ ,  $f_2 = 0.36$ ,  $\varphi_{1i} = \varphi_{2i} = 2\pi \frac{(i-1)}{6}$ ;  $i = 1, \dots, 6$ ,  $w[n]$  o secvență de tip zgomot alb cu dispersia 0.03. Se va calcula densitatea spectrală de putere cu metoda Burg pentru fiecare dintre cele șase semnale. Rezultatele se vor reprezenta pe același grafic.

2. Mărind ordinul modelului peste cel al ordinului optim, ce se observă în cazul unui semnal de tip sinus afectat de zgomot?

3. Să se proiecteze un filtru trece jos FIR, prin metoda ferestrelor, de ordinul 32, cu frecvența discretă de tăiere de 0.2 ( $f \in (0, 0.5)$ ). Fie un semnal de tip zgomot alb  $w[n]$  de medie nulă și dispersie 0.1 în intrarea filtrului proiectat anterior. Să se determine parametrii modelului AR(2), AR(4), AR(16) prin metoda Yule-Walker și Burg și să se reprezinte densitatea spectrală de putere a semnalului din ieșirea filtrului.