

MINISTERUL ÎNȘIȘĂRII ȘI ÎNȘIȘĂRII ÎNȘIȘĂRII
INȘIȘĂRII ȘI ÎNȘIȘĂRII "TRAIU VULPI" TIMIȘARA
INȘIȘĂRII DE INȘIȘĂRII ȘI ÎNȘIȘĂRII

ing. Liviu Toma

CONTRIBUȘIILE ÎNȘIȘĂRII ÎNȘIȘĂRII ȘI ÎNȘIȘĂRII

Teză de doctorat

BIBLIOTECA CENTRALĂ
UNIVERSITATEA "POLITEHNICA"
TIMIȘARA

Conducător științific
Prof. dr. ing. Eugen Pop

Timișoara 1984

BIBLIOTECA CENTRALĂ
UNIVERSITATEA "POLITEHNICA"
TIMIȘARA
486.068
Vol. 351 4
După

1. INTRODUCERE

Prelucrarea numerică a semnalelor a devenit o disciplină majoră odată cu apariția și dezvoltarea calculatoarelor de mare viteză, reprezentând un domeniu de mare interes, prin aplicațiile tot mai numeroase în ramuri dintre cele mai diverse ale științei și tehnicii. Evoluția rapidă a tehnicilor de prelucrare numerică a semnalelor este determinată de avantajele pe care le oferă față de prelucrarea analogică. Aceste avantaje se referă în principal la performanță, flexibilitate, reproductibilitate, gabarit și preț de cost. Progresele realizate de tehnologie, integrarea pe scară largă, mărirea vitezei de lucru a circuitelor numerice, apariția, perfecționarea, diversificarea și creșterea complexității microprocesoarelor, apariția sistemelor bit-slice și microprogramarea au contribuit la evoluția rapidă a tehnicilor de prelucrare numerică a semnalelor /65/.

Prelucrarea numerică a semnalelor cuprinde reprezentarea semnalelor prin secvențe de numere și prelucrarea acestor secvențe. Scopul acestei prelucrări este de a extrage anumite informații despre semnale, sau despre sistemele care le-au generat. Tehnicile de prelucrare urmăresc în general transformarea unui semnal în alt semnal care este mai convenabil dintr-un anumit punct de vedere. O astfel de transformare, utilizată în analiza semnalelor, este transformarea spectrală. Prin calculul spectrului se obține distribuția amplitudinii, fazei, puterii sau energiei unui semnal în funcție de frecvență. Analiza spectrală a semnalelor este utilizată în inginerie, economie, medicină, geofizică, acustică, comunicații, navigație, radiotelegrafie, /15/, /18/, /20/, /24/, /31/, /36/, /37/, /71/.

De exemplu, prin analiza spectrală a datelor privind repetarea în timp unor evenimente seismice se pot determina

periodicității. Acestea pot fi corelate cu perioadele unor fenomene astronomice. De asemenea, prin analiză spectrală se determină adâncimea de la suprafața pământului la care s-a declanșat un eveniment seismic /31/. Un alt exemplu se referă la determinarea unor componente periodice ale evoluției cliimei, prin analiza spectrală a datelor rezultate din studiul parametrilor biologici și chimici ai sedimentelor depuse pe fundul oceanelor /31/. Dispunerea în adâncime a acestor sedimente este calibrată în timp geologic. În radiolocație, analiza spectrală este utilizată la detectarea țintelor /71/.

În cele ce urmează se prezintă succint metodele tradiționale și optimizate de analiză spectrală. Pentru reprezentarea matematică a unui semnal discret $\{x_n\}$ de energie infinită, acesta se consideră ca fiind o realizare a unui proces aleatoriu compus din variabile aleatoare x_n , $-\infty < n < \infty$ și de funcțiile de probabilitate asociate variabilelor aleatoare /6/. Un semnal discret de energie infinită este dat, în general, sub formă unei secvențe de numere cu lungime finită $\{x_n\}$, $n=0,1,\dots,N-1$. Dacă se cunosc funcțiile de probabilitate ale procesului aleatoriu, pentru $-\infty < n < \infty$, nu înseamnă că se pot determina valorile semnalului discret în afara intervalului de observare $n=0,1,\dots,N-1$. În schimb pot fi prevăzute mediile procesului aleatoriu care servesc pentru caracterizarea incompletă a semnalului discret de energie infinită, considerat o realizare a procesului aleatoriu. Dintre aceste medii se reține că secvența de autocorelație. Densitatea spectrală de putere $P_x(f)$ a unui proces aleatoriu staționar în sens larg este definită /24/, /59/, /27/ ca transformată Fourier a secvenței de autocorelație. În cazurile practice procesul aleatoriu nu este determinat statistic, adică nu se cunosc toate funcțiile de probabilitate /49/. Informația principală despre procesul aleatoriu o reprezintă secvența de date $\{x_n\}$ de lungime finită $n=0,1,\dots,N-1$. Rezultă deci posibilitatea de a determina doar estimății /3/, /57/ ale secvenței de autocorelație și ale densității spectrale de putere.

Metodele tradiționale de estimare spectrală utilizează operatorul de transformare Fourier aplicat secvenței de autocorelație sau secvenței de date. Estimarea Blackman-Tukey a

densității spectrale de putere este dată de relația /24/, /67/.

$$\hat{P}_{BT}(f) = \frac{1}{NT} \sum_{m=-L}^L \hat{R}_{XX}(m) \exp(-j2\pi f m T), \quad -\frac{1}{2T} \leq f \leq \frac{1}{2T} \quad (1.1)$$

unde $\{\hat{R}_{XX}(m)\}$ reprezintă o estimare de lungime L a secvenței de autocorelație obținută pe baza secvenței de date de lungime finită. Estimarea densității spectrale de putere în funcție de secvența de date este exprimată prin relația /24/, /67/.

$$\hat{P}_{PBK}(f) = \frac{1}{NT} \left| \sum_{n=0}^{N-1} x_n \exp(-j2\pi f n T) \right|^2, \quad -\frac{1}{2T} \leq f \leq \frac{1}{2T} \quad (1.2)$$

Estimatorul $\hat{P}_{PBK}(f)$ este cunoscut în literatură sub denumirea de periodogramă. Utilizarea transformatei Fourier rapide /6/, /13/ permite evaluarea estimării $\hat{P}_{PBK}(f)$ pentru frecvențele $f_m = m \Delta f$, $m=0, 1, \dots, N-1$ și $\Delta f = 1/NT$, /24/

$$\hat{P}_m = \hat{P}_{PBK}(f_m) \cdot \Delta f = \left| \frac{1}{N} \sum_{n=0}^{N-1} x_n \exp(-j2\pi m n / N) \right|^2 \quad (1.3)$$

Estimarea \hat{P}_m se numește periodogramă discretă și permite obținerea spectrului sub formă de linii.

Principala cauză care conduce la erori în estimarea spectrală cu metodele tradiționale constă în prelucrarea unei secvențe de date de lungime finită. Astfel se presupune implicit că secvența de date este nulă în afara intervalului de observare, în locul secvenței reale de lungime infinită se prelucerează produsul acesteia cu o funcție fereastră dreptunghiulară, ceea ce în domeniul frecvență reprezintă convoluția celor două transformate. Dacă puterea unui semnal este concentrată într-o bandă îngustă de frecvențe,

această convoluție va produce o scurgere de putere spre regiunile de frecvență adiacente sub forma unor lobi laterali. Fenomenul de scurgere a puterii are implicații nedorite și asupra procesului de detectare și estimare a puterii unor componente sinusoidale. Astfel, lobi laterali corespunzători unei componente sinusoidale de putere mare pot masca lobul principal al unei componente de putere mai mică. Utilizarea ferestrelor diferite de cea dreptunghiulară pot conduce la reducerea fenomenului de scurgere, dar întotdeauna prin lărgirea lobului principal al transformatei ferestrei, deci cu prețul reducerii rezoluției /4/, /19/, /45/, /70/.

Metodele optimizate de analiză spectrală se bazează pe faptul că de multe ori în cazurile practice se cunosc, în afara secvenței de date și alte informații despre procesul care generează această secvență, sau se pot face anumite presupuneri plauzibile. În funcție de aceste informații sau presupuneri se poate alege un model exact sau aproximativ al procesului care generează secvența de date. Având modelul, se procedează la identificarea parametrilor modelului pe baza secvenței de date. Analiza spectrală, bazată pe tehnica modelării și identificarea parametrilor, se face prin determinarea optimizării spectrale în funcție de parametrii modelului. Rezoluția și fidelitatea estimării spectrale este funcție de abilitatea cu care se face corelarea modelului și a parametrilor lui cu secvențe de date și cu informațiile apriori pe care le deținem asupra procesului care generează secvența de date. Deoarece tehnica modelării implică extrapolarea secvenței de date în afara intervalului de observare /3/, rezultă posibilitatea obținerii unor estimări spectrale îmbunătățite față de cele obținute prin metodele tradiționale, în special în cazul secvențelor scurte /24/. Principalele modele utilizate la estimarea spectrală sînt : modelul autoregresiv, modelul de mediere, modelul ARMA, modelul Prony de estimare a densității spectrale de energie și modelul Prony de estimare a liniilor spectrale /24/, /51/.

În lucrarea de față, analiza spectrală se bazează pe modelul Prony de estimare a liniilor spectrale. Procesul este

modelat ca o sumă de sinusoides pentru care nu se impune corelarea armonică. Astfel, estimarea vizează numărul de sinusoides, frecvențele, amplitudinile și fazele lor.

În capitolul 2 se arată că un proces format din sinusoides este un proces autoregresiv cu coeficienții de autoregresie simetrici. Estimarea coeficienților de autoregresie permite calculul amplitudinilor, amplitudinilor și fazelor sinusoidelor. Contribuțiile lucrării în acest capitol constau în definirea matricii de date sumă și estimarea numărului de sinusoides și a coeficienților de autoregresie prin utilizarea descompunerii valorilor singulare a matricii de date sumă.

În capitolul 3 se prezintă o metodă optimizată de estimare a liniilor spectrale, care este contribuția a lucrării de față. Metoda se bazează pe mărirea simulată a pasului de eșantionare și permite reducerea erorilor de estimare a frecvențelor sinusoidelor, simultan cu reducerea volumului de calcul necesar estimării. În condiția menținerii constante a erorilor de estimare, metoda permite reducerea intervalului de timp de observare a procesului.

Capitolul 4 prezintă partea experimentală prin care se susțin contribuțiile lucrării. Experimentele se bazează pe simularea unor procese compuse din sinusoides în zgomot.

În capitolul 5 se prezintă concluziile rezultate din contribuțiile lucrării.

x x
x

Autorul este mulțumiri prof.dr.doc.ing.Edmond Nicolau, de la Institutul Politehnic București, dr.ing.Aurel Millea, de la Institutul Național de Metrologie București și conf.dr.ing.Iosif Hoffmann, de la Institutul Politehnic Timișoara, pentru discuțiile, sugesturile și recomandările primite în perioada de elaborare a tezei.

Lucrarea de față își datorează existența climatului moral și îndrumarea științifică de care a beneficiat autorul din partea prof.dr.in. Eugen Pop.

2. ESTIMAREA LINIILOR SPECTRALE

Prin estimarea liniilor spectrale se înțelege reprezentarea unui semnal în domeniul frecvență, ca o sumă de sinusoides. Se consideră secvența de numere x_0, x_1, \dots, x_{N-1} obținută prin esantionarea cu pasul T , a unui semnal analog $x(t)$. Semnalul $x(t)$ se modelează ca o sumă de N sinusoides complexe de frecvențe alese arbitrar f_0, f_1, \dots, f_{N-1} . Rezultă secvența $\{\hat{x}_n\}$, care modelează semnalul discret $\{x_n\}$, conform relației

$$\hat{x}_n = \sum_{m=0}^{N-1} a_m \exp(j2\pi f_m nT), \quad n=0, 1, \dots, N-1. \quad (2.1)$$

Relația (2.1) se scrie sub formă matriceală

$$\hat{\mathbf{x}} = \mathbf{F} \mathbf{a}, \quad (2.2)$$

unde

$$\hat{\mathbf{x}} = [\hat{x}_0, \hat{x}_1, \dots, \hat{x}_{N-1}]^T,$$

$$\mathbf{a} = [a_0, a_1, \dots, a_{N-1}]^T,$$

$$\mathbf{F} = \begin{bmatrix} 1 & 1 & \dots & 1 \\ \exp(\lambda_0) & \exp(\lambda_1) & \dots & \exp(\lambda_{N-1}) \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ \exp(\lambda_0 [N-1]) & \exp(\lambda_1 [N-1]) & \dots & \exp(\lambda_{N-1} [N-1]) \end{bmatrix}$$

și

$$\lambda_m = j2\pi f_m T. \quad (2.3)$$

Se pune problema de a determina coeficienții a_m , astfel încât secvența $\{\hat{x}_n\}$ să modeleze cât mai bine semnalul discret $\{x_n\}$, în cazul în care frecvențele f_m și numărul lor N sînt impare. Pentru aceasta se minimizează eroarea patrată

$$\sum_{n=0}^{N-1} |x_n - \hat{x}_n|^2, \quad (2.4)$$

adică se rezolvă sistemul (2.2) în sensul celor mai mici pătrate. Se obține relația /33/

$$a = (F^H F)^{-1} b, \quad (2.5)$$

unde

$$x = [x_0, x_1, \dots, x_{N-1}]^T$$

și F^H reprezintă matricea transpusă complex conjugată a matricei F .

Se consideră modelul seriei Fourier /48/ pentru care frecvențele sinusoidelor sînt

$$f_m = m \Delta f, \quad (2.6)$$

unde

$$\Delta f = \frac{1}{NT}. \quad (2.7)$$

Din relația (2.3), se obține

$$\lambda_m = j \frac{2\pi}{T} m, \quad m = 0, 1, \dots, N-1. \quad (2.8)$$

În acest caz coloanele matricei F sînt vectori ortonormali /61/.

Rezultă

$$F^H F = \frac{1}{N} I, \quad (2.9)$$

unde I este matricea unitate. Se obține soluția sistemului (2.2)

$$a = \frac{1}{N} F^H x,$$

adică

$$a_m = \frac{1}{N} \sum_{n=0}^{N-1} x_n \exp(-j2\pi mn/N),$$

pentru $m = 0, 1, \dots, N-1$. Remarță că puterea unei sinusoidे complexe de frecvență impusă este

$$|a_m|^2 = \left| \frac{1}{N} \sum_{n=0}^{N-1} x_n \exp(-j2\pi mn/N) \right|^2. \quad (2.10)$$

Relația (2.10) reprezintă expresia de calcul a periodogramei discrete (1.3). Rezultă că metoda periodogramei discrete de estimare a liniilor spectrale corespunde unui model compus dintr-un număr dat de sinusoidे complexe cu frecvențe armonice [24], [2]. Cu acest model se consideră semnalul discret ca repetându-se periodic în afara intervalului de observare NT . Deoarece numărul și frecvențele sinusoidelor se impun, rezultă că este necesară doar estimarea puterii sinusoidelor, ceea ce se realizează cu relația (2.10) de definire a periodogramei discrete.

În lucrarea de față se tratează metodele de estimare a liniilor spectrale utilizând modelul Prony. Acest model este nearmonic și necesită estimarea numărului, frecvențelor, amplitudinilor și fazelor sinusoidelor. Pentru estimarea frecvențelor sinusoidelor se consideră secvența de date cu parametrii unui model autoregresiv. Rezultă să, spre deosebire de periodograma discretă care presupune desfășurarea periodică a semnalului în afara intervalului de observare, modelul Prony presupune desfășurarea semnalului în afara intervalului de observare conform unui proces autoregresiv. Această presupunere, mult mai realistă, poate conduce la obținerea unor es-

timații spectrale mult îmbunătățite sub aspectul rezoluției și fidelității, în special pentru semnale disponibile pe un interval de timp scurt.

2.1. Modelarea autoregresivă a secvențelor de date corespunzătoare semnalelor sinusoidale

Se consideră secvența de date $\{x_n\}$, $n=1,2,\dots,N$ obținută prin eșantionarea unui proces format din L sinusoidale de amplitudini A_k , frecvențe f_k și faze φ_k , $k=1,2,\dots,L$. Un eșantion x_n aparținând secvenței de date are expresia

$$x_n = \sum_{k=1}^L A_k \sin(2\pi f_k nT + \varphi_k), \quad n=1,2,\dots,N \quad (2.11)$$

unde T reprezintă pasul de eșantionare.

Relația (2.11) poate fi exprimată ca sumă de exponențiale complexe

$$x_n = \sum_{k=1}^L (a_k e^{s_k n} + a_k^* e^{s_k^* n}), \quad n=1,2,\dots,N \quad (2.12)$$

unde a_k și s_k sînt numere complexe. Prin identificarea relațiilor (2.11) și (2.12) se obține

$$a_k = \frac{A_k}{2j} e^{j\varphi_k}, \quad k=1,2,\dots,L \quad (2.13)$$

$$s_k = j2\pi f_k T, \quad k=1,2,\dots,L \quad (2.14)$$

În cazul general în care numerele complexe s_k au partea reală diferită de zero, secvența de date corespunde unui

proces format din sinusoida atenuate exponențial.

2.1.1. Modelul autoregresiv

În acest paragraf se demonstrează că un proces format din M sinusoida atenuate exponențial este un proces autoregresiv de ordinul $2M$.

Pentru aceasta se definește matricile de date. Astfel, matricea de date directe este definită /29/ prin relația

$$A_d = \begin{bmatrix} x_{L+1} & x_L & \dots & x_1 \\ x_{L+2} & x_{L+1} & \dots & x_2 \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ x_N & x_{N-1} & \dots & x_{N-L} \end{bmatrix} \quad (2.15)$$

cu $2M \leq L \leq N-2M$. Matricea de date directe cu dimensiunea $(N-L) \times (L+1)$ este de tip Toeplitz /1/. Elementele matricii A_d situate pe orice linie paralelă cu diagonala principală sînt egale.

Se definește matricea de date inverso /29/

$$A_i = \begin{bmatrix} x_1 & x_2 & \dots & x_{L+1} \\ x_2 & x_3 & \dots & x_{L+2} \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ x_{N-L} & x_{N-L+1} & \dots & x_N \end{bmatrix} \quad (2.16)$$

cu $2M \leq L \leq N-2M$. Matricea de date inverso cu dimensiunea $(L+1, L+1)$ este de tip Hankel /1/. Elementele matricii A_i situate pe orice linie perpendiculară pe diagonala principală sînt egale.

Se definește matricea de date directe-inverse

$$A_{di} = \begin{bmatrix} A_d \\ A_i \end{bmatrix} = \begin{bmatrix} x_{L+1} & x_L & \dots & x_1 \\ x_{L+1} & x_{L+1} & \dots & x_2 \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ x_{N-L} & x_{N-1} & \dots & x_{N-L} \\ x_1 & x_2 & \dots & x_{L+1} \\ x_2 & x_3 & \dots & x_{L+2} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ x_{N-L} & x_{N-L+1} & \dots & x_N \end{bmatrix} \quad (2.17)$$

de dimensiunea $2(N-L) \times (L+1)$.

Se pune problema de a determina rangurile matricilor de date definite mai sus, în funcție de numărul L de sinusoidale atenuate exponențial ce compun procesul din care s-a prelevat secvența de date $\{x_n\}$, $n = 1, 2, \dots, N$. În acest scop se consideră vectorii dați prin relațiile :

$$v_{1k} = \begin{bmatrix} e^{s_k(L+1)} & e^{s_k L} & \dots & e^{s_k 2} & e^{s_k} \end{bmatrix}^T, \quad k = 1, 2, \dots, L \quad (2.18)$$

$$v_{2k} = \begin{bmatrix} e^{s_k^*(L+1)} & e^{s_k^* L} & \dots & e^{s_k^* 2} & e^{s_k^*} \end{bmatrix}^T, \quad k = 1, 2, \dots, L \quad (2.19)$$

$$v_{3k} = \begin{bmatrix} e^{s_k} & e^{s_k 2} & \dots & e^{s_k L} & e^{s_k(L+1)} \end{bmatrix}^T, \quad k = 1, 2, \dots, L \quad (2.20)$$

$$v_{4k} = \left[e^{s_k^*}, e^{s_k^* 2}, \dots, e^{s_k^* L}, e^{s_k^* (L+1)} \right]^T, \\ k = 1, 2, \dots, L. \quad (2.21)$$

În cazul general în care numerele complexe s_k au partea reală diferită de zero, ceea ce corespunde unui proces format din sinusoidă atenuată exponențial, toți vectorii $v_{1k}, v_{2k}, v_{3k}, v_{4k}, k=1, 2, \dots, L$ sînt liniar independenți. Din relația (2.12) se deduce că orice linie a matricii de date directe A_d se obține din combinația liniară a $2L$ vectori liniar independenți $v_{1k}, v_{2k}, k=1, 2, \dots, L$. Similar, orice linie a matricii de date inverse A_i se obține din combinația liniară a $2L$ vectori independenți $v_{3k}, v_{4k}, k=1, 2, \dots, L$. Rezultă că, dacă numărul de linii ale matricilor A_d și A_i este mai mare sau egal cu $2L$, adică $N-L \geq 2L$, rangul acestor matrici este egal cu $2L$. Din modul de definire al matricii de date directe-inverse A_{di} rezultă că aceasta este de rang $4L$.

Deoarece rangul matricii de date directe (inverse) este $2L$ rezultă că orice coloană a acestei matrici se obține prin combinații liniare ale altor $2L$ coloane ale aceleiași matrici. Se obține

$$x_n = - \sum_{m=1}^{2L} b_m x_{n-m}, \quad (2.22)$$

unde $n = 2L+1, 2L+2, \dots, N$. Relația (2.22) exprimă faptul că un proces format din L sinusoidă atenuată exponențial este un proces autoregresiv de ordinul $2L$ cu coeficienții de autoregresie b_m reali [24].

2.1.2. Modelul autoregresiv simetric. Matricea de date sumă

În cele ce urmează se demonstrează că un proces format din L sinusoidă nestenueată este un proces autoregresiv de ordinul $2L$ cu coeficienții de autoregresie reali și simetrice. Problemele tratate în această lucrare se referă la sinusoidă

neatenuate și nu se va mai specifica acest fapt. Deoarece, în acest caz, numerele s_k , $k=1,2,\dots,M$ sînt pur imaginare, conform relației 2.14, rezultă

$$e^{s_k^*} = e^{-s_k}, \quad k=1,2,\dots,M. \quad (2.23)$$

Avînd în vedere modul de definire a vectorilor v_{1k} , v_{2k} , v_{3k} , v_{4k} , se obține

$$e^{-s_k(L+2)} v_{1k} = v_{4k}, \quad k=1,2,\dots,M, \quad (2.24)$$

$$e^{-s_k(L+2)} v_{3k} = v_{2k}, \quad k=1,2,\dots,M.$$

Relațiile (2.24) exprimă faptul că vectorii v_{1k} și v_{4k} , respectiv v_{2k} și v_{3k} , $k=1,2,\dots,M$ devin liniar dependenți doi cîte doi. Rezultă că, în cazul unui proces format din M sinusoidale, rangul matricii de date A_{di} este $2M$.

Deoarece rangul matricii de date direct-inverse A_{di} este $2M$ rezultă că orice coloană a acestei matrici se obține prin combinații liniare ale altor $2M$ coloane. Rezultă relațiile


$$x_n = - \sum_{m=1}^{2M} b_m x_{n-m}, \quad (2.25)$$

$$x_{n-2L} = - \sum_{m=1}^{2L} b_m x_{n-2L+m}, \quad (2.26)$$

unde $n=2M+1, 2M+2, \dots, N$. Din compatibilitatea relațiilor (2.25) și (2.26) se obține

$$b_{2L} = 1, \quad (2.27)$$

$$b_m = b_{2L-m}.$$



Rezultă că un proces format din L sinusoidă este un proces autoregresiv de ordinul $2L$ cu coeficienții de autoregresie b_m reali și simetrici /7/, /24/, /39/.

Având în vedere simetria coeficienților de autoregresie, rezultă că devine utilă definirea matricii de date, cu formă /2/

$$A' = \begin{bmatrix} x_{L+1}+x_1 & x_L+x_2 & \dots & 2x_{L/2+1} \\ x_{L+2}+x_2 & x_{L+1}+x_3 & \dots & 2x_{L/2+2} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ x_N+x_{N-L} & x_{N-1}+x_{N-L+1} & \dots & 2x_{N-L/2} \end{bmatrix} \quad (2.28)$$

cu $2L \leq L \leq N-L$ și L un număr par. Matricea A' are o structură Toeplitz plus Kankel și implică un vector al coeficienților de autoregresie de formă /25/

$$b = [b_0, b_1, \dots, b_{L/2-1}, b_{L/2/2}]^T.$$

În lucrarea de față se definește matricea de date sub forma

$$A_B = \begin{bmatrix} x_{L+1}+x_1 & x_L+x_2 & \dots & x_{L/2+1} \\ x_{L+2}+x_2 & x_{L+1}+x_3 & \dots & x_{L/2+2} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ x_N+x_{N-L} & x_{N-1}+x_{N-L+1} & \dots & x_{N-L/2} \end{bmatrix} \quad (2.29)$$

cu $2L \leq L \leq N-L$ și L un număr par. Matricea A_B implică un vector al coeficienților de autoregresie de forma

$$b = [b_0, b_1, \dots, b_{L/2-1}, b_{L/2}]^T.$$

Matricea de date sumă are dimensiunea $(N-L) \times (L/2+1)$.

Pentru a determina rangul matricei de date sumă A_g în funcție de numărul de sinusoid ce compun procesul din care s-a prelevat secvența de date $\{x_n\}$, $n=1,2,\dots,L$, se definesc vectorii

$$v_{5k} = \begin{bmatrix} e^{-s_k(L+1)} & e^{-s_k L} & e^{-s_k^2} & \dots & e^{-s_k(L/2+1)} & e^{-s_k L/2} & e^{-s_k(L+2)/2} \\ +e^{-s_k} & +e^{-s_k} & +e^{-s_k} & \dots & +e^{-s_k} & +e^{-s_k} & +e^{-s_k} \end{bmatrix}$$

$$k=1,2,\dots,L$$

$$v_{6k} = \begin{bmatrix} e^{-s_k^*(L+1)} & e^{-s_k^* L} & e^{-s_k^{*2}} & \dots & e^{-s_k^*(L/2+2)} & e^{-s_k^* L/2} & e^{-s_k^*(L/2+1)} \\ +e^{-s_k^*} & +e^{-s_k^*} & +e^{-s_k^*} & \dots & +e^{-s_k^*} & +e^{-s_k^*} & +e^{-s_k^*} \end{bmatrix}$$

$$k=1,2,\dots,L. \quad (2.30)$$

Avînd în vedere relația (2.23) se deduce

$$e^{-s_k(L+1)} v_{5k} = v_{6k} \cdot k=1,2,\dots,L. \quad (2.31)$$

Relația (2.31) exprimă faptul că vectorii v_{5k} și v_{6k} , $k=1,2,\dots,L$ sînt liniar dependenți doi cîte doi. Se menționează că vectorii v_{5k} , $k=1,2,\dots,L$ sînt liniar independenți, ca și vectorii v_{6k} , $k=1,2,\dots,L$. Din relația (2.31) se deduce că orice linie a matricei de date sumă A_g se obține din combinația liniară a 2L vectori v_{5k} , v_{6k} , $k=1,2,\dots,L$ dintre care L sînt liniar independenți. Rezultă că rangul matricei de date sumă A_g este L, e adică cu numărul de sinusoid ce compun procesul.

Demonstrația privind rangul matricei de date sumă în funcție de numărul de sinusoid ce compun procesul din care s-a prelevat secvența de date $\{x_n\}$ este o contribuție a prezentei lucrări.

2.2. Determinarea frecvențelor, amplitudinilor și fazelor sinusoidelor

În paragraful precedent s-a demonstrat că un proces format din L sinusoid este un proces autoregresiv de ordi-

nul $2L$ cu coeficienții de autoregresie reali și simetrici, ceea ce este exprimat prin relațiile (2.25) și (2.27). Se pune problema de a determina frecvențele sinusoidelor în funcție de coeficienții de autoregresie. Pentru aceasta se formează cu coeficienții de autoregresie polinomul caracteristic definit prin relația

$$P(z) = \sum_{l=0}^{2L} b_l z^{2l-1}, \quad (2.32)$$

în care $b_0=1$. Deoarece coeficienții de autoregresie sînt reali rezultă că polinomul $P(z)$ are rădăcini complexe conjugate, fapt exprimat prin relația

$$P(z) = \prod_{k=1}^L (z - z_k)(z - z_k^*). \quad (2.33)$$

Se scrie relația (2.25) sub forma

$$\sum_{m=0}^{2L} b_m x_{n-m} = 0, \quad (2.34)$$

unde $b_0=1$. Din relațiile (2.12) și (2.34) se obține

$$\sum_{m=0}^{2L} b_m \sum_{k=1}^L \left[s_k e^{s_k(n-m)} + s_k^* e^{s_k^*(n-m)} \right] = 0. \quad (2.35)$$

În relația (2.25) se fac substituțiile

$$e^{s_k(n-m)} = e^{s_k(n-2L)} e^{s_k(2L-m)},$$

$$e^{s_k^*(n-m)} = e^{s_k^*(n-2L)} e^{s_k^*(2L-m)}.$$

Se obține

$$\sum_{k=1}^M a_k e^{s_k(n-2L)} \sum_{m=0}^{2M} b_m e^{s_k(2L-m)} + \sum_{k=1}^M a_k^* e^{s_k^*(n-2L)} \sum_{m=0}^{2M} b_m e^{s_k^*(2L-m)} = 0 \quad (2.36)$$

Relația (2.36), la fel ca și (2.34), se menține pentru orice n . Astfel, se obține din relația (2.36) un sistem de ecuații care admite soluția

$$\sum_{m=0}^{2M} b_m e^{s_k(2L-m)} = 0, \quad k=1, 2, \dots, L \quad (2.37)$$

$$\sum_{m=0}^{2M} b_m e^{s_k^*(2L-m)} = 0, \quad k=1, 2, \dots, L$$

Rezultă că rădăcinile polinomului caracteristic $P(z)$ definit prin relația (2.32) sînt

$$z_k = e^{s_k}, \quad k=1, 2, \dots, L \quad (2.38)$$

$$z_k^* = e^{s_k^*}, \quad k=1, 2, \dots, L$$

Înlocuind în (2.38) coeficienții a_k dați prin relația (2.14), se obține

$$z_k = e^{j2\pi k}, \quad k=1, 2, \dots, L \quad (2.39)$$

$$z_k^* = e^{-j2\pi k}, \quad k=1, 2, \dots, L \quad (2.40)$$

486068
35741

Rezultă că, pentru un proces format din sinusoidale, coeficienții de autoregresie sînt funcții de frecvențele sinusoidelor și nu depind de amplitudinile și fazele lor. Pentru determinarea frecvențelor sinusoidelor în funcție de coeficienții de autoregresie se calculează rădăcinile polinomului caracteristic (2.32) și apoi se folosește relația

$$f_k = \frac{1}{2\pi T} [\arg(z_k) + 2\pi r], \quad k=1,2,\dots,M. \quad (2.41)$$

Erorile alias /55/ se manifestă prin nedeterminarea numărului întreg r . Dacă secvența de date este obținută prin eșantionare cu pasul T , astfel încît să se respecte teorema eșantionării $1/T > 2f_k$, $k=1,2,\dots,M$, coeficientul r din relația (2.41) este egal cu zero.

În cele ce urmează se pune problema determinării amplitudinilor și fazelor sinusoidelor în funcție de secvența de date și de frecvențele sinusoidelor. În acest scop se scrie relația (2.11) sub formă

$$x_n = \sum_{k=1}^M [\alpha_k \sin(2\pi f_k nT) + \beta_k \cos(2\pi f_k nT)], \quad n=1,2,\dots,N \quad (2.42)$$

unde

$$A_k = \sqrt{\alpha_k^2 + \beta_k^2}, \quad k=1,2,\dots,M \quad (2.43)$$

$$\varphi_k = \arctg \frac{\beta_k}{\alpha_k}, \quad k=1,2,\dots,M. \quad (2.44)$$

Dacă se dă secvența de date $\{x_n\}$, $n=1,2,\dots,N$ și se cunosc frecvențele sinusoidelor f_k , $k=1,2,\dots,M$, relația (2.42) reprezintă un sistem de ecuații liniare cu $2M$ necunoscute α_k, β_k , $k=1,2,\dots,M$. Rezolvînd sistemul de ecuații liniare se obțin coeficienții α_k și β_k . Cu relațiile (2.43) și

(2.44) se obțin amplitudinile și respectiv fazele sinusoidelor.

În cazul $L > 2L$, numărul de ecuații ale sistemului (2.42) este mai mare decât numărul de necunoscute, și sistemul devine supradeterminat. Dacă pentru determinarea amplitudinilor și fazelor se dispune de estimății ale frecvențelor f_k , $k = 1, 2, \dots, L$, sistemul de ecuații liniare supradeterminat se rezolvă în sensul celor mai mici pătrate.

Din cele prezentate rezultă că determinarea frecvențelor, amplitudinilor și fazelor sinusoidelor, în funcție de coeficienții de autoregresie și de secvența de date, se face în două etape. În prima, se determină frecvențele sinusoidelor, ca rădăcini ale polinomului caracteristic construit cu coeficienții de autoregresie. În a doua etapă se determină amplitudinile și fazele sinusoidelor în funcție de coeficienții de autoregresie și de secvența de date, prin rezolvarea sistemului de ecuații liniare (2.42).

2.3. Estimarea numărului de sinusoid

În paragraful 2.1 s-a demonstrat că, pentru un proces format din L sinusoid, rangul matricilor de date directe A_d , inverse A_i și directe-inverse A_{di} este $2L$, iar rangul matricii de date sumă A_g este L . Rezultă că numărul de sinusoid poate fi determinat ca rang al matricilor de date. În acest paragraf se pune problema estimării numărului de sinusoid în situația în care secvența de date este afectată de zgomot. Această estimare se face prin calculul numeric al rangului matricilor de date. Dificultățile reale privind soluționarea acestei probleme rezultă din faptul că rangul unei matrice este o funcție discontinuă de elementele matricii [12]. Astfel, perturbații mici ale elementelor unei matrice A cu dimensiunea $m \times n$ ($m > n$), de rang $r < n$, conduc la o matrice de rang $r = n$ [58]. Se afirmă [5], [25], [26] că utilizarea decompunerii valorilor singulare (DVS) constituie singurul mijloc sigur de determinare a rangului unei matrice de formă generală.

Teorema referitoare la descompunerea valorilor singulare /5/, /25/ afirmă că pentru orice matrice reală A de dimensiune $m \times n$ și rang r , există matricile ortogonale U , $m \times m$ și V , $n \times n$, astfel încât

$$A = U \Sigma V^T, \quad (2.45)$$

unde Σ se numește formă canonică pseudodiagonală a matricii A .

$$\Sigma = \begin{bmatrix} S & O \\ O & O \end{bmatrix}; \quad (2.46)$$

și S este o matrice diagonală

$$S = \text{diag} (\sigma_1, \sigma_2, \dots, \sigma_r), \quad (2.47)$$

cu

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0. \quad (2.48)$$

În relația (2.45) este notat cu V^T transpusă matricii V .

Numerele $\sigma_1, \sigma_2, \dots, \sigma_r$ împreună cu $\sigma_{r+1} = 0, \sigma_{r+2} = 0, \dots, \sigma_n = 0$ se numesc valorile singulare ale matricii A și sînt rădăcinile pozitive ale valorilor proprii ale matricii $A^T A$. Coloanele matricii U se numesc vectori singulari la stînga ai matricii A și sînt vectorii proprii ortonormali ai matricii AA^T . Coloanele matricii V se numesc vectori singulari la dreapta ai matricii A și sînt vectorii proprii ortonormali ai matricii $A^T A$.

Din cele prezentate pînă aici sus rezultă că rangul unei matrice este dat de numărul valorilor singulare diferite de zero obținute prin DVS.

Fiind dată o matrice reală A de dimensiune $m \times n$ și rang r , toate matricile B , $m \times n$, care satisfac relația

$$\|B - A\|_2 < \sigma_r \quad (2.49)$$

sînt de rang mai mare decît r . În relația (2.49) prin $\| \cdot \|_2$ s-a notat norma spectrală a unei matrice, definită ca normă

matriceală indusă de norma vectorială euclidiană /30/, prin relația

$$\|A\|_2 = \sup_{\|x\|_2=1} \|Ax\|_2, \quad (2.50)$$

unde vectorul $x \in \mathbb{R}^n$. Se arată /30/, /64/ că

$$\|A\|_2 = \max\{\sigma_1, \sigma_2, \dots, \sigma_r\} = \sigma_1, \quad (2.51)$$

unde σ_1 reprezintă valoarea singulară maximă a matricii A.
Matricea

$$B = U \hat{\Sigma} V^T, \quad (2.52)$$

unde

$$\hat{\Sigma} = \begin{bmatrix} \hat{S} & O \\ O & O \end{bmatrix},$$
$$\hat{S} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_{r-1}),$$

are rangul $r-1$ și

$$\|B - A\|_2 = \sigma_r. \quad (2.53)$$

Rezultă că valoarea singulară minimă σ_r a matricii A exprimă cât de departe, în sensul norme spectrale, este matricea A față de matricile de rang mai mic decât r. Pentru exprimarea relației acestei depărțări se folosește raportul

$$\frac{\sigma_r}{\|A\|_2} = \frac{\sigma_r}{\sigma_1}.$$

Pentru toate matricile B care satisfac relația (2.49) se definește rangul efectiv egal cu r /12/. Rangul efectiv al unei matrice, fiind o funcție întreagă, este discontinuă de elementele matricii, dar numărul de discontinuități este mult mai mic decât cel al funcției definite de rangul unei matrice.

In prezenta lucrare numărul de sinusoidे dintr-un proces compus din sinusoidे în zgomot se estimează ca rang efectiv al matricii de date sumă A_g . Rangul efectiv se obține prin analiza valorilor singulare rezultate din DVS a matricii A_g . Dacă intervalul de timp pe care sînt prelevate eșantioanele unei linii a matricii de date este foarte scurt relativ la perioadele frecvențelor mici, aportul acestor frecvențe în eșantioanele liniei respective este aproximativ constant. În consecință valorile singulare indică numai prezența frecvențelor mici. Această concluzie este susținută prin rezultatele experimentului 2.1 (Capitolul 4) în care se consideră un proces format din cinci sinusoidे în zgomot aditiv: $f_1 = 2$ Hz; $f_2 = 6$ Hz; $f_3 = 20$ Hz; $f_4 = 25$ Hz și $f_5 = 30$ Hz. Pasul de eșantionare este $T = 1/256$ s. Intervalul de timp pe care sînt prelevate eșantioanele unei linii a matricii de date A_g , cu $L = 2L = 10$, este $1/25,6$ s, mult mai mic relativ la perioadele frecvențelor f_1 și f_2 . Astfel, în experimentul 2.1 se obțin valorile singulare $\sigma_1 = 45,1$; $\sigma_2 = 24,5$; $\sigma_3 = 3,2$; $\sigma_4 = 0,06$; $\sigma_5 = 0,028$; $\sigma_6 = 0,015$. Deoarece $\sigma_4 \ll \sigma_3$, rangul efectiv al matricii A_g se id egal cu trei. Rezultă că valorile singulare indică numai prezența sinusoidelor cu frecvențele mai mari f_3 , f_4 și f_5 .

Pentru a obține estimări corecte, pentru numărul de sinusoidे este necesară utilizarea matricilor de date sumă cu mărire simulată a pasului de eșantionare A_{gK} , $K = 2, 3, \dots$, definite prin prezenta lucrare (relație 3.22 Capitolul 3). Intervalul de timp corespunzător unei linii a matricii de date A_{gK} este de K ori mai mare decît intervalul de timp corespunzător unei linii a matricii A_g . În acest fel se impune prezența frecvențelor mici, ceea ce se confirmă prin experimentele 2.2, 2.3 și 2.4, în care se utilizează matricea de date sumă A_{g4} , cu $K = 4$. Astfel, în experimentul 2.1, se obțin valorile singulare ale matricii A_{g4} , cu $L = 2L = 10$: $\sigma_1 = 19,9$; $\sigma_2 = 17,6$; $\sigma_3 = 8,23$; $\sigma_4 = 5,1$; $\sigma_5 = 3,59$; $\sigma_6 = 0,025$. Deoarece $\sigma_6 \ll \sigma_5$, rangul efectiv al matricii A_{g4} este cinci. Rezultă că valorile singulare indică prezența celor cinci sinusoidे.

Dintr-un punct de vedere mai general valorile singulare indică posibilitatea constrinși modelului cu neovența de date. În această lucrare modelul este format dintr-o sumă de sinusoidे. O valoare singulară σ a matricii A_g exprimă cît de depar-

te, în sensul normei spectrale, este matricea A_g față de matricile de rang mai mic decît r . Exprimarea relativă a acestei depărtări se face prin raportul σ_r/σ_1 . Rezultă că raportul σ_r/σ_1 este o măsură a corelării unui model format din $(r-1)$ sinusoidale cu secvența de date. Cu cît acest raport este mai mic corelarea este mai bună.

În cazul unui proces format din $(r-1)$ sinusoidale în zgomot, raportul σ_r/σ_1 este cu atît mai mic cu cît raportul semnal-zgomot este mai mare. Aceasta în condiția ca intervalul de timp corespunzător unei linii a matricei de date să nu fie mult mai mic relativ la perioadele frecvențelor mici conținute în proces.

Estimarea numărului de sinusoidale prin utilizarea DVS a matricilor de date sună și observația că estimăția mai bună se obține prin utilizarea matricilor de date sună cu mîrire simulată a pasului de eșantionare, reprezintă contribuții ale prezentei lucrări.

2.4. Estimarea coeficienților de autoregresie

În paragraful 2.1 s-a demonstrat că un proces format din k sinusoidale este un proces autoregresiv de ordinul $2k$ cu coeficienții de autoregresie reali și simetrici. Se pune problema estimării coeficienților de autoregresie în cazul în care procesul format din sinusoidale este afectat de zgomot aditiv. Dacă se notează cu $\{y_n\}$, $n=1,2,\dots,N$ secvența obținută prin eșantionarea unui proces format din k sinusoidale în zgomot, cu $\{x_n\}$, $n=1,2,\dots,n$ secvența corespunzătoare aceluiași proces în absența zgomotului și cu $\{w_n\}$, $n=1,2,\dots,N$ secvența de zgomot, se obține

$$y_n = x_n + w_n, \quad n=1,2,\dots,N. \quad (2.54)$$

Avînd în vedere relația (2.29) rezultă

$$y_n = \sum_{i=1}^{2k} a_i x_{n-i} + w_n. \quad (2.55)$$

Inlocuind $x_{n+m} = y_{n-m} - w_{n-m}$ în relația (2.55) se obține

$$y_n = - \sum_{m=1}^{2M} b_m y_{n-m} + \sum_{m=1}^{2M} b_m w_{n-m} + w_n \quad (2.56)$$

Din relația (2.56) rezultă că un proces format din 1. este un proces ARMA de ordinul 2M, cu coeficienții de autoregresie egali cu cei de mediere /24/, /67/, /69/. Această proprietate a procesului impune metode de estimare a parametrilor procesului diferite față de metodele generale utilizate în cazul modelului ARMA.

2.4.1. Estimarea coeficienților de autoregresie în funcție de secvența de autocorelație

Metoda descompunerii armonice Pisarenko permite estimarea coeficienților de autoregresie b_m în cazul în care se cunoaște secvența de autocorelație $\{R_{yy}(k)\}$, $k=0,1,\dots,2M$, iar zgomotul aditiv este alb cu media zero și dispersia σ_w^2 /24/, /67/, /53/.

Se scrie relația (2.56) sub formă matriceală

$$y^T b = w^T b \quad (2.57)$$

unde

$$y^T = [y_n, y_{n-1}, \dots, y_{n-2M}] \quad (2.58)$$

$$w^T = [w_n, w_{n-1}, \dots, w_{n-2M}]$$

iar b reprezintă vectorul coeficienților de autoregresie

$$b^T = [1, b_1, \dots, b_{2M}] \quad (2.59)$$

Se înmulțesc la stânga cei doi termeni din relația (2.57) cu vectorul y și se aplică operatorul de mediere pe

ansamblu. Se obține

$$E \left[yy^T \right] b = E \left[yw^T \right] b . \quad (2.60)$$

Matricea

$$E \left[yy^T \right] = R_{yy} = \begin{bmatrix} R_{yy}(0) & \dots & R_{yy}(-2L) \\ \vdots & & \vdots \\ R_{yy}(2L) & \dots & R_{yy}(0) \end{bmatrix} \quad (2.61)$$

este matricea autocorelație a procesului și este de tip Toeplitz.

Dacă se face notația

$$x^T = [x_n, x_{n-1}, \dots, x_{n-2L}] ,$$

se obține

$$E \left[yw^T \right] = E \left[(xw)^T w^T \right] = E \left[xw^T \right] = \sigma_w^2 I , \quad (2.62)$$

unde I este matricea unitate.

În relație (2.62) s-a avut în vedere că $E \left[xw^T \right] = 0$ deoarece sinusoidelii nu sînt corelate cu zgomotul.

Din relațiile (2.50), (2.61) și (2.62) rezultă

$$R_{yy} b = \sigma_w^2 b \quad (2.63)$$

Se observă că dispersia zgomotului este o valoare proprie a matricei de autocorelație, iar vectorul coeficienților de autoregresie este vectorul propriu asociat valorii proprii σ_w^2 și ales astfel încît primul element să fie egal cu unu.

Relația (2.63) permite estimarea coeficienților de autoregresie $b_k, k = 1, 2, \dots, 2L$. Dacă secvența de autocorelație $\{R_{yy}(k)\}, k = 0, 1, \dots, 2L$ se cunoaște exact este posibi-

lă determinarea exactă a coeficienților de autoregresie și implicit a celor M frecvențe. Amplitudinile A_k ale sinusoidelor și dispersia σ_w^2 rezultă din relațiile

$$R_{yy}(0) = \sigma_w^2 + \sum_{i=1}^M \frac{A_i^2}{2},$$

$$R_{yy}(k) = \sum_{i=1}^M \frac{A_i^2}{2} \cos(2\pi f_k nT), \text{ pentru } k \neq 0, \quad (2.64)$$

unde T reprezintă pasul de eșantionare. Deoarece s-a presupus că se cunoaște numai secvența de autocorelație, informațiile privind fazele sinusoidelor nu există.

În cazul în care nu se cunoaște numărul de sinusoides, dar se cunoaște exact secvența de autocorelație se rezolvă (2.63) pentru ordine M crescătoare pînă cînd dispersia σ_w^2 atinge valoarea minimă și rămîne constantă, ceea ce indică valoarea corectă a lui M . În cazurile practice se cunosc doar estimații ale secvenței de autocorelație, astfel încît ordinal M se alege corespunzător variației minime a mărîmii σ_w^2 , rezultată prin rezolvarea ecuației (2.63) pentru ordine M succesive.

În cele ce urmează se prezintă un algoritm care reduce calculele necesare rezolvării ecuației (2.63) și care utilizează structura Toeplitz a matricii de autocorelație R_{yy} . Pentru aceasta se precizează că dispersia σ_w^2 este o valoare proprie a matricii R_{yy} , iar b este un vector propriu asociat valorii proprii σ_w^2 . Se arată /33/ că pentru un proces format din M sinusoides în zgomot alb, σ_w^2 corespunde valorii proprii minime a matricii de autocorelație R_{yy} , cînd dimensiunea minimă a acesteia este $(2M+1) \times (2M+1)$. Valoarea proprie minimă a matricii R_{yy} și vectorul propriu corespunzător pot fi determinate prin metoda puterii /35/ în care secvența de vectori

$$b(k+1) = R_{yy}^{-1} b(1), \quad k = 0, 1, \dots \quad (2.65)$$

converge la limită spre vectorul propriu corespunzător valorii proprii minime, pentru $b(0)$ ales inițial.

Relația (2.65), scrisă sub forma

$$R_{yy} b(k+1) = b(k), \quad (2.66)$$

se rezolvă obținând vectorul $b(k+1)$ în funcție de vectorul $b(k)$. Rezolvarea sistemului (2.66) prin metoda eliminării Gauss necesită un număr de operații elementare de ordinul M^3 . Dacă se utilizează algoritmi de rezolvare a sistemului (2.66) care valorifică structura Toeplitz a matricii R_{yy} /11/, numărul de operații elementare este de ordinul M^2 . Se recomandă /24/ alegerea inițială

$$b^T(0) = [1, \dots, 1].$$

Vectorul $b(\infty)$ se obține în general după câteva iterații. Dacă vectorul coeficienților de autoregresie b este determinat, se poate obține dispersia σ_w^2 ca valoare proprie minimă a matricii R_{yy}

$$\sigma_w^2 = \frac{b^T R_{yy} b}{b^T b} \quad (2.67)$$

Determinarea coeficienților de autoregresie b permite determinarea frecvențelor sinusoidelor, prin intermediul rădăcinilor polinomului caracteristic (2.32) și a relației (2.41).

Având în vedere relația (2.64), determinarea amplitudinilor sinusoidelor se face cu sistemul de ecuații

$$Fp = r, \quad (2.68)$$

unde

$$F = \begin{bmatrix} \cos(2\pi f_1 T) & \dots & \cos(2\pi f_L T) \\ \vdots & & \vdots \\ \cos(2\pi f_1 T) & \dots & \cos(2\pi f_L T) \end{bmatrix}$$

$$p^T = \left[\frac{A_1^2}{2}, \dots, \frac{A_L^2}{2} \right],$$

$$r^T = [R_{yy}(1), \dots, R_{yy}(L)].$$

Dispersia zgomotului se determină din relația

$$\sigma_w^2 = R_{yy}(0) - \sum_{l=1}^L \frac{A_l^2}{2} \quad (2.69)$$

Din cele prezentate rezultă că în cadrul metodei decompunerii armonice Pisarenko, estimarea numărului de sinusoid se face prin rezolvarea succesivă a ecuației (2.63) pentru ordine L crescătoare și analiza dispersiilor σ_w^2 rezultate. Această metodă necesită un volum mare de calcul și, deoarece, în practică sînt utilizate estimări ale secvenței de autocorelație, se pot obține estimări greșite ale numărului de sinusoid. Dacă numărul de sinusoid estimat este prea mare apar componente sinusoidale false. Dacă numărul de sinusoid estimat este prea mic se obțin erori mari la estimarea frecvențelor sinusoidelor. deoarece procesul compus din sinusoid în zgomot este dat prin secvența de date $\{y_n\}$, $n=1,2,\dots,N$, se pot calcula estimările pentru secvența de autocorelație /23/

$$\hat{R}_{yy}(k) = \frac{1}{N - |k|} \sum_{n=0}^{N-|k|-1} y_{n+k} y_n, \text{ pentru } |k| < N \quad (2.70)$$

$$\hat{R}_{yy}^*(k) = \frac{1}{N} \sum_{n=0}^{N-|k|-1} y_{n+k} y_n, \text{ pentru } |k| < N. \quad (2.71)$$

Estimatorul $\hat{R}_{yy}(k)$ este nedebelat, iar estimatorul \hat{R}_{yy}^* este debelat /24/, /25/. Aplicînd operatorul de medii

estimatorului deplasat se obține

$$E[\hat{R}'_{yy}(k)] = \frac{1-k}{N} R_{yy}(k) . \quad (2.72)$$

Rezultă că media secvenței de autocorelație $\hat{R}'_{yy}(k)$ corespunde secvenței de autocorelație adevărată $R_{yy}(k)$ ponderată cu fereastra triunghiulară /14/. Dacă în cadrul metodei descompunerii armonice Pisarenko se utilizează estimatorul nedepășat al secvenței de autocorelație $\hat{R}_{yy}(k)$, matricea de autocorelație nu rezultă în mod necesar pozitiv definită, ceea ce poate conduce la valori proprii negative și la estimări în sens pentru frecvențe. În cazul utilizării estimatorului deplasat \hat{R}'_{yy} , matricea de autocorelație rezultă pozitiv definită, dar ponderarea secvenței de autocorelație cu fereastra triunghiulară conduce la estimări eronate ale frecvenței și la introducerea unor componente de frecvență false /24/.

2.4.2. Estimarea coeficienților de autoregresie în funcție de secvența de date

Se consideră un proces format din N sinusoidă în zgomot aditiv din care s-a prelevat secvența de date

$$y_n = x_n + w_n, \quad n = 1, 2, \dots, N. \quad (2.73)$$

Secvența $\{x_n\}$, $n = 1, 2, \dots, N$ corespunde aceluiași proces în absența zgomotului, iar w_n reprezintă un egantion al secvenței de zgomot.

Se pune problema estimării coeficienților de autoregresie

$$b = [b_0, b_1, b_2, \dots, b_{21}]^T, \quad b_0 = 1 \quad (2.74)$$

în funcție de secvența de date $\{y_n\}$, $n = 1, 2, \dots, N$ unde a ne-

cesita estimarea secvenței de autocorelație, ca în cazul metodei descompunerii amantice Pisarenko.

În paragraful 4.2 se demonstrează că rădăcinile polinomului caracteristic

$$P(z) = \sum_{m=0}^{2L} b_m z^{2L-m}, \quad (2.75)$$

permite determinarea frecvențelor sinusoidelor. Rădăcinile polinomului $P(z)$ se numesc rădăcini adevărate.

Relația (2.25) poate fi scrisă sub formă

$$\sum_{m=0}^{2L} b_m x_{n-m} = 0, \quad b_0 = 1 \quad (2.76)$$

de unde rezultă că vectorul coeficienților de autoregresie este ortogonal pe orice vector x format din $2L+1$ eșantioane consecutive ale secvenței $\{x_n\}$, $n = 1, 2, \dots, L$.

Se definește $(2L+1)$ -tricea

$$G_L = \begin{bmatrix} b_0 & b_1 & \dots & b_{2L} & 0 & 0 & \dots & 0 \\ 0 & b_0 & \dots & b_{2L-1} & b_{2L} & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & b_0 & \dots & \dots & \dots & b_{2L} \end{bmatrix}^T \quad (2.77)$$

de dimensiunea $(L+1) \times (L+1 - 2L)$. Deoarece coloanele matricii G_L sînt linear independente, rezultă că rangul ei este egal cu $L+1-2L$. Se demonstrează [1] că orice vector

$$c_t = [c_0, c_L, \dots, c_L]^T, \quad (2.78)$$

care aparține spațiului liniar generat de liniile matricii G_L^T , verifică

$$c_t = G_L^T b, \quad (2.79)$$

cu

$$s = [s_0, s_1, \dots, s_{L-2L}]^T$$

un vector oarecare, conduce la polinomul caracteristic

$$P_L(z) = \sum_{m=0}^L c_m z^{L-m}, \quad (2.30)$$

care are rădăcinile adevărate ale polinomului $P(z)$, precum și $L-2L$ rădăcini suplimentare. Aceste rădăcini suplimentare sînt date de polinomul

$$P_{L-2L}(z) = \sum_{m=0}^{L-2L} d_m z^{L-2L-m} \quad (2.31)$$


Deoarece elementele vectorului s sînt reale rezultă că și rădăcinile suplimentare sînt perechi complex conjugate.

Se deduce /12/ că spațiul liniar generat de liniile matricii G_L^T este ortogonal pe orice vector format din $L+1$ eșantioane consecutive ale secvenței $\{x_n\}$, $n=1,2,\dots,M$. Considerînd vectorul c_t ca aparținînd acestui spațiu liniar și definit prin relațiile (2.78), (2.79) rezultă

$$\sum_{m=0}^L c_m x_{L-m} = 0 \quad (2.82)$$

În cazul în care $L=2L$, relația (2.82) devine identică cu relația (2.79). În particular, în relația (2.82) vectorul c_t poate fi luat ca oricare din liniile matricii G_L^T . Dacă se consideră matricea de date directe

$$A_d = \begin{bmatrix} x_{L+1} & x_L & \dots & x_1 \\ x_{L+1} & x_{L+1} & \dots & x_2 \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ \vdots & x_{L-1} & & x_{L-1} \end{bmatrix}, \quad (2.83)$$



din relația (2.82) se obține

$$A_d G_L = 0 \quad (2.84)$$

Rezultă că spațiul liniar generat de liniile matricii G_L^T este identic cu spațiul nul al matricii A_d sau $A_d^T A_d$. Spațiul nul al matricii A_1 este definit /30/ ca mulțimea tuturor vectorilor c_t care satisfac relația

$$A_d c_t = 0 \quad (2.85)$$

Deci, orice soluție a sistemului de ecuații liniare (2.85) conduce la un polinom caracteristic $P_L(z)$ definit prin relația (2.80), care are rădăcinile adăugate ale polinomului $P(z)$ dat prin relația (2.75), precum și un număr de $L-2L$ rădăcini suplimentare.

Având în vedere simetria coeficienților de autoregresie b în cazul unui proces format din sinusoida, se deduce că spațiul nul al matricii de date inverse

$$A_1 = \begin{bmatrix} x_1 & x_2 & \dots & x_{L+1} \\ x_2 & x_3 & \dots & x_{L+2} \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ x_{N-L} & x_{N-L+1} & \dots & x_N \end{bmatrix} \quad (2.86)$$

este identic cu spațiul nul al matricii de date directe A_d . Rezultă că și spațiul nul al matricii de date directe-inverse

$$A_{d1} = \begin{bmatrix} A_1 \\ A_d \end{bmatrix} \quad (2.87)$$

este identic cu spațiul nul al matricii de date directe A_d . Cu

alte cuvinte, în cazul unui proces format din sinusoidă, sistemul de ecuații liniare (2.85) este echivalent /34/ cu sistemele

$$A_1 c_t = 0, \quad (2.88)$$

$$A_{d1} c_t = 0, \quad (2.89)$$

adică au aceleași soluții.

Se consideră din spațiul nul al matricii A_0 vectorii c_t simetrici, adică

$$c_t = [c_0, c_1, \dots, c_L]^T, \quad c_m = c_{L-m} \quad (2.90)$$

pentru $m = 0, 1, \dots, L/2$. Dacă se face notația

$$c = [c_0, c_1, \dots, c_{L/2}]^T, \quad (2.91)$$

sistemul de ecuații liniare (2.85) devine

$$A_B c = 0, \quad (2.92)$$

unde A_B este matricea de date sumă

$$A_B = \begin{bmatrix} x_{1+1} & x_{1+x_2} & \dots & x_{L/2+1} \\ x_{1+2} & x_{1+1+x_3} & \dots & x_{L/2+2} \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ x_{N-1} & x_{N-1+x_{N-1+1}} & \dots & x_{N-1/2} \end{bmatrix}. \quad (2.93)$$

În cazul în care $L=2M$ și vectorul c_t este simetric, relația (2.82) devine identică cu relația (2.76), cu coeficienții b_m simetrici. Aceasta corespunde unui proces format din sinusoidă. Dacă ace vectorii c_t simetrici reprezintă un

subspațiu al spațiului nul al matricei A_d , rezultă că orice soluție a sistemului de ecuații liniare (2.92) va conduce la un polinom caracteristic $\chi_d(z)$ cu $2L$ rădăcini adevărate și $L-2L$ rădăcini suplimentare. Rădăcinile adevărate permit calculul frecvențelor celor L sinusoidale. Rezultă că determinarea coeficienților polinomului se poate face prin rezolvarea sistemelor de ecuații liniare (2.84), (2.83), (2.89) sau (2.92). Se observă că sistemul (2.92) este de dimensiuni mai mici decât celelalte, ceea ce conduce la reducerea calculului necesar soluționării.

Prezența zgomotului aditiv în procesul format din sinusoidale conduce la obținerea prin egalitate a secvenței $\{y_n\}$, $n=1,2,\dots,N$ legată de secvența $\{x_n\}$ prin relația (2.73). Astfel, matricile de date se vor construi conform relațiilor (2.83), (2.86), (2.87) și (2.93), în care ecuațiile x_n sînt înlocuite cu ecuațiile y_n . În acest caz soluționarea sistemelor (2.84), (2.83), (2.89) și (2.92) reprezintă probleme de rezolvare a sistemelor de ecuații liniare supra-determinate /5/.

Din cele prezentate mai sus, rezultă că, dacă $L > 2L$, polinomul caracteristic va avea cele $2L$ rădăcini adevărate și $L-2L$ rădăcini suplimentare, se afirmă /21/, /23/, /32/ că în prezența zgomotului, rădăcinile suplimentare au un efect de absorbție a acestuia acoperind rădăcinile adevărate. Astfel, introducerea rădăcinilor suplimentare prin estimarea unui vector al coeficienților autoregresie c_t de dimensiune $(L-1)$ mai mare decât dimensiunea $(2L+1)$ a vectorului b (2.74), este o practică comună care conduce la estimări mai bune pentru frecvențe. Se recomandă /32/ ca alegerea numărului L să se facă conform relației

$$\frac{N}{3} \leq L \leq \frac{N}{2}, \quad (2.94)$$

pentru a obține estimările cele mai bune pentru frecvențe. În relația (2.94) numărul N reprezintă lungimea secvenței de date $\{y_n\}$. Separarea rădăcinilor adevărate de cele suplimentare se

poate face pe baza unor informații suplimentare despre proces, în afara secvenței de date $\{y_n\}$, sau prin determinarea a două soluții pentru sistemele de ecuații supradeterminate și identificarea rădăcinilor adică verificate ca rădăcini comune corespunzătoare celor două soluții. Pentru un proces format din L sinusoidale în zgomot se propune, în prezenta lucrare, utilizarea algoritmului de reducere. Acesta constă în determinarea spațiului nul al matricilor A_d , A_1 sau A_{d1} și identificarea acestuia cu subspațiul generat de liniile matricii G_L^T . Spațiul nul al matricilor A_d , A_1 sau A_{d1} este determinat dacă se cunosc $(L+1-2l)$ vectori liniar independenți aparținând spațiului. Cu acești vectori se construiește o matrice G^T avînd ca linii acești vectori. Matricea G^T este de aceeași dimensiune cu matricea G_L^T definită prin relație (2.77). Pentru a determina coeficienții de autoregresie b , care permit rădăcinilor adevărate ale polinomului caracteristic, se urmărește transformarea matricii G^T la forma matricii G_L^T , prin algoritmul de reducere. În acest scop se aduce matricea G^T la forma trapezoidală superioară, producînd un triunghi de zerouri în colțul din stînga jos, prin eliminare Gauss directă cu pivotare parțială /5/, /63/. În matricea obținută se produce un triunghi de zerouri în colțul din dreapta sus prin eliminare Gauss inversă fără permutarea liniilor matricii. Se obține o matrice de forma matricii G_L^T cu liniile multiplicată cu niște constante. Se aliniează liniile matricii G^T eliminînd zerourile. Matricea rezultată Q de dimensiune $(L+1-2l) \times (L+1)$ este de rang unu, în absența perturbațiilor. Liniile matricii Q sînt colineare și oricare poate fi luată ca b^T pentru calculul rădăcinilor adevărate ale polinomului caracteristic. În prezența perturbațiilor se alege b ca vectorul propriu corespunzător valorii proprii maxime a matricii Q , ceea ce echivalează cu apăsîndu-se matricii Q cu o matrice de rang unu. Calculul vectorului propriu se poate face cu metoda puterii /5/, /63/, sau prin utilizarea descompunerii valorilor singulare a matricii Q .

În cele ce urmează se vor analiza metodele de rezolvare a unui sistem de ecuații liniare supradeterminat

$$Ax = 0, \quad (2.95)$$

unde A este o matrice cu dimensiunea $[xJ]$, de rang R și x este un vector cu dimensiunea J . Pentru ca sistemul de ecuații liniare (2.95) să fie supradeterminat se impune

$$I > J > R. \quad (2.96)$$

O primă metodă de rezolvare a sistemului de ecuații liniare supradeterminat (2.95) începe prin înlăturarea unui număr de $I-R$ linii ale matricii A obținând astfel o matrice B cu dimensiunea $R \times J$. S-a nulțurat numărul maxim de linii astfel încât rangul matricii B să fie egal cu R . Se obține sistemul

$$Bx = 0. \quad (2.97)$$

Se trec în partea dreaptă a sistemului (2.97) un număr de $J-R$ coloane ale matricii B . Se obține sistemul

$$B_s x_s = -B_d x_d, \quad (2.98)$$

unde :

- B_s este o matrice pătrată nesingulară cu dimensiunea $R \times R$, formată din R coloane ale matricii B ,

- B_d este o matrice cu dimensiunea $R \times (J-R)$, formată din $J-R$ coloane ale matricii B ,

- x_s este un vector cu dimensiunea R , format din elementele vectorului x ce corespund cu coloanele matricii B_s ,

- x_d este un vector cu dimensiunea $J-R$, format din elementele vectorului x ce corespund cu coloanele matricii B_d .

Rezolvarea sistemului (2.98) constă în alegerea arbitrară a vectorului x_d și determinarea vectorului x_s cu relația

$$x_s = -B_s^{-1} B_d x_d. \quad (2.99)$$

Soluția x a sistemului (2.95) se obține din vectorii x_s și x_d . Alegerea arbitrară a vectorului x_d indică faptul că soluția x este oricare dintre-un spațiu liniar cu dimensiunea $J-R$.

Această metodă este bună numai în cazul în care elementele matricii A nu sînt afectate de perturbații și calculele efectuate sînt exacte. În cazul în care apar perturbații este nejustificată înlăturarea unui număr de I-R linii ale matricii A , ceea ce înseamnă utilizarea incompletă a datelor conținute în matricea A .

O a doua metodă de rezolvare a sistemului de ecuații liniare supradeterminat (2.95) pornește de la faptul că spațiul nul al matricii A este același cu spațiul nul al matricii $A^T A$. Matricea $A^T A$ este pătrată cu dimensiunea $J \times J$. Rezultă că soluția sistemului (2.95) coincide cu soluția sistemului

$$A^T A x = 0 \quad (2.100)$$

Din matricea $A^T A$ se înlătură $J-k$ linii obținându-se o matrice B cu care se operează la fel ca și în prima metodă prezentată. Această a doua metodă este o procedură de rezolvare a sistemului de ecuații liniare supradeterminat în sensul celor mai mici pătrate.

Din relația (2.96) rezultă că rezolvarea sistemului (2.100) necesită înlăturarea unui număr mai mic de linii ale matricii decât în cazul rezolvării sistemului (2.95). De asemenea, rezolvarea sistemului (2.100) presupune utilizarea integrală a datelor. Totuși, datele nu sînt tratate uniform în sensul că liniile matricii $A^T A$ care se înlătură, precum și coloanele matricii rezultante care se transferă în dreapta sistemului, sînt alese arbitrar. Aceasta înseamnă că datele conținute în matricea A nu au contribuții egale în stabilirea soluției. În situația în care datele sînt afectate de perturbații există posibilitatea obținerii unei soluții deplasate din punct de vedere statistic.

În cele ce urmează se tratează această metodă pentru cazul în care

$$J = k+1 \quad (2.101)$$

Soluția sistemului (2.100) este de forma

$$x = \lambda x_0,$$

unde λ este un număr arbitrar, iar x_0 este un vector. Matricea B_d din relația (2.98) este un vector care se notează cu b_d , iar vectorul x_d este un scalar. Dacă se alege acest scalar ca ultim element al vectorului x , matricea B din (2.97) se separă conform relației

$$B = [B_S ; b_d]. \quad (2.101)$$

Soluția sistemului este

$$x^T = [x_S^T ; x_d].$$

Din relația (2.101) obține

$$x^T = [(-B_S b_d)^T ; 1] x_d, \quad (2.102)$$

unde x_d este un scalar arbitrar.

Se separă matricea A conform relației

$$A = [A_S ; a],$$

unde a este un vector format din ultima coloană a matricei A . Deoarece la formarea matricei B se elimină numai ultima linie a matricei $A^T A$, în condiția (2.101), se obține

$$B_S = A_S^T A_S,$$

$$b_S = A_S^T a.$$

Soluția finală a sistemului de ecuații liniare supra-determinat $Ax = 0$, cu $x_d = 1$, este

$$x^T = \left\{ \left[-(A_S^T A_S)^{-1} A_S^T a \right]^T ; 1 \right\} x_d, \quad (2.104)$$

pe care x_d un scalar arbitrar. Acest procedeu de rezolvare a sistemului în sensul celor trei mici pătrate, pentru cazul particular precizat, se numește metoda covarianței [21/, /36/.

O a treia metodă de rezolvare a sistemului de ecuații liniare supradeterminat (2.95) constă în utilizarea descompunerii valorilor singulare DVS. Teorema referitoare la DVS a fost prezentată în paragraful 2.3. Astfel, matricea A de rang k , cu dimensiunea $I \times J$, poate fi scrisă sub formă

$$A = U \Sigma V^T \quad (2.105)$$

Matricea Σ cu dimensiunea $I \times J$ este diagonală, având elementele de pe diagonala principală

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_k > \sigma_{k+1} = \sigma_{k+2} = \dots = 0,$$

numite valori singulare. Matricile U și V , cu dimensiunile $I \times I$ și respectiv $J \times J$, sînt ortogonale, adică $U^T = U^{-1}$ și $V^T = V^{-1}$.

Dacă în sistemul (2.95) se utilizează descompunerea valorilor singulare pentru matricea A se obține

$$U \Sigma V^T x = c \quad (2.106)$$

Prin multiplicarea la stînga a relației (2.106) cu matricea U^T rezultă

$$\Sigma \alpha = c, \quad (2.107)$$

unde s-a notat

$$\alpha = V^T x \quad (2.108)$$

Avînd în vedere forma diagonală a matricei Σ , se obține

$$\alpha^T = [c_1, \dots, c_k, d^T], \quad (2.109)$$

unde d este un vector arbitrar cu dimensiunea $J-k$.

Din relațiile (2.108) și (2.109) se obține soluția sistemului de ecuații supradeterminat

$$x = V \alpha = V [c_1, \dots, c_k, d^T]^T, \quad (2.110)$$

unde matricea V_d este constituită din ultimele $J-R$ coloane ale matricei V . Rezultă că soluția sistemului $Ax = 0$ este compusă din spațiul liniar generat de ultimele $J-R$ coloane ale matricei V .

Dacă datele conținute în matricea A sînt afectate de perturbații, rangul matricei A crește peste valoarea R . Astfel, numărul valorilor singulare diferite de zero, rezultate din SVD a matricei A , este mai mare decît k . Se definește pentru matricea A afectată de perturbații aproximația de rang R prin relația

$$A_R = U \Sigma_R V^T \quad (2.112)$$

unde matricea Σ_R se obține din matricea Σ prin anulara tuturor valorilor singulare cu excepția primelor k valori, cele mai mari. Matricea A_R este cea mai apropiată matrice cu rangul R de matricea A , apropiere măsurată în sensul normei spectrale sau Frobenius [6]. Norma spectrală a unei matrice este definită în paragraful 2.3, iar norma matriceală Frobenius este definită prin relația

$$\|A\|_F = \left(\sum_{i=1}^I \sum_{j=1}^J |a_{ij}|^2 \right)^{1/2}. \quad (2.113)$$

Rezultă că este logic să se estimeze spațiul nul al matricei A cu spațiul nul al matricei A_R , care este generat de ultimele $J-R$ coloane ale matricei V .

Utilizarea descompunerii valorilor singulare la soluționarea sistemelor de ecuații liniare supradeterminate este avantajoasă în condițiile erorilor de zgomotului și a erorilor de calcul [21]. Astfel, se presupune în lucrarea de față estimarea coeficienților de autoresonanță pentru un proces compus din sinusoidale în zgomot, prin spațiul liniar generat de ultimele coloane ale matricei V . Obținând soluția sistemului sub formă de spațiu liniar, rezultă și posibilitatea aplicării algoritmului de reducere pentru obținerea numai a frecvențelor odevi-

Pentru aplicarea metodelor de rezolvare a sistemului de ecuații liniare supradeterminat $As=0$, metode prezentate mai sus, la rezolvarea sistemelor (2.85), (2.88), (2.89) și (2.92), se prezintă în tabelul 2.1 corespondența între dimensiunile și dimensiunile matricilor, în absența perturbațiilor.

Matrice	Nr.linii	Nr.coloane	rang
A	1	J	1
A_d	$N-L$	$L+1$	$2L$
A_1	$N-L$	$L+1$	$2L$
A_{di}	$2(N-L)$	$L+1$	2
A_s	$N-L$	$L/2+1$	1

Tabelul 2.1

Din cele prezentate rezultă că problema estimării coeficienților de regresie în funcție de secvența de date, corespunzătoare unui proces format din sinusoidă, se reduce la rezolvarea unui sistem de ecuații liniare supradeterminat. Soluția unui astfel de sistem nu este unică, ci este constituită dintr-un nul al matricii de date. Dacă matricile de date sînt construite cu $L=2M$, soluția sistemului se obține ca produs al unui vector și o constantă arbitrară. O soluție unică se obține dacă se ia ca valoare unuia dintre coeficienții de regresie. Construirea matricilor de date cu $L > 2M$ conduce la obținerea unor estimări mai bune pentru rădăcinile rădăcinate ale polinomului caracteristic, deci implicit pentru frecvențele sinusoidelor. În acest caz, soluția sistemului de ecuații liniare supradeterminat $A_d c_t = 0$, $A_1 c_t = 0$ și $A_s c_t = 0$ este un spațiu liniar de dimensiune

$(L+1-2h)$, iar soluția sistemului $A_g c = 0$ este un spațiu liniar de dimensiune $(L/2+1-h)$. Identificarea rădăcinilor adevărate se poate face pe baza unor informații suplimentare, sau prin determinarea a doi vectori soluție și identificarea rădăcinilor comune ale polinoamelor caracteristice corespunzătoare celor doi vectori. Pentru sistemele cu matricile A_d, A_i, A_{di} se poate utiliza algoritmul de reducere, care conduce la obținerea unui vector soluție de dimensiunea $2n+1$. Rădăcinile adevărate se obțin din polinomul caracteristic construit cu acest vector.

Soluționarea sistemelor de ecuații liniare supradeterminate se face, în sensul celor mai mici pătrate, prin metoda covarianței sau prin utilizarea descompunerii valorilor singulare. Se prezintă în /39/, /40/, un algoritm eficient care corespunde soluționării sistemului

$$A' c' = 0, \quad (2.113)$$

în sensul celor mai mici pătrate. În relația (2.113) matricea A' este

$$A' = \begin{bmatrix} y_1 + y_{L+1} & y_2 + y_L & \dots & 2y_{L/2+1} \\ y_2 + y_{L+2} & y_3 + y_{L+1} & \dots & 2y_{L/2+2} \\ \vdots & \vdots & \ddots & \vdots \\ y_{N-L} + y_N & y_{-L+1} + y_{N-1} & \dots & 2y_{N-L/2} \end{bmatrix} \quad (2.114)$$

Rezultă vectorul c' sub forma

$$c' = [c_0, c_1, \dots, c_{L/2-1}, c_{L/2}]^T. \quad (2.115)$$

Algoritmul utilizează structura Toeplitz plus Hankel a matricei A' . O soluție unică se obține impunând $c_{L/2} = 1$. Numărul de operații elementare necesare aplicării algoritmului

este de ordinul $(n/2)^2$. Algoritmul permite obținerea simultană a soluțiilor pentru toate ordinele 1, 2, ... , L/2. Prin urmărirea erorii pătratice rezultate pentru ordine succesive, se poate selecta ordinul de la care eroarea pătratică scade nesemnificativ. Astfel se poate estima numărul de sinusoidă ce compun procesul /39/.

Utilizarea descompunerii valorilor singulare la soluționarea sistemelor de ecuații liniare supradeterminate este avantajoasă în condițiile existenței zgomotului și a erorilor de calcul /21/. Prezența acestor perturbații este indicată prin apariția valorilor singulare mici. Din analiza valorilor singulare este posibilă determinarea rangului matricii de date, deci implicit numărului de sinusoidă ce compun procesul. Algoritmul de calcul al descompunerii valorilor singulare este extrem de eficient și stabil. /5/, /12/, /15/.

3. METODA CANTONAREA DE ESTIMARE A LINIILOR SPECTRALE

În acest capitol se prezintă o metodă originală care permite îmbunătățirea estimărilor pentru frecvențele sinusoidelor. Se consideră un proces format din L sinusoidale în zgomot aditiv și disponibil pentru eșantionare pe intervalul de timp Δt . Alegerea numărului de eșantioane n care se prelevează pe intervalul de timp Δt , se face astfel încât, pentru estimarea coeficienților de regresie, să se obțină un sistem de ecuații liniare supra-determinat. În cele ce urmează se arată că această alegere conduce la obținerea unui pas de eșantionare mic față de limita inferioară a teoremei eșantionării, în cazul în care intervalul de timp Δt este scurt.

Se consideră matricea de date A_S , utilizată în lucrarea de față la estimarea coeficienților de autoregresie corespunzător unui proces format din sinusoidale în zgomot aditiv. Pentru a obține un sistem de ecuații liniare supra-determinat cu matricea A_S , de dimensiune $(N-L) \times (L/2+1)$, se impune

$$N-L > \frac{L}{2} + 1. \quad (3.1)$$

Rezultă că numărul de eșantioane n , care se prelevează, trebuie să satisfacă condiția

$$N > \frac{3}{2} L + 1. \quad (3.2)$$

Din teorema eșantionării se obține/44/

$$T \leq \frac{1}{2 f_{\text{max}}}, \quad (3.3)$$

unde T reprezintă pasul de eșantionare, iar f_{max} reprezintă

frecvența maximă conținută de procesul considerat. Avînd în vedere că procesul este disponibil pentru eșantionare pe intervalul Δt , se obține

$$T = \frac{\Delta t}{N-1} . \quad (3.4)$$

Din relațiile (3.3) și (3.4) rezultă

$$N \geq 2 \Delta t f_{\max} + 1 . \quad (3.5)$$

Relația (3.5) reprezintă condiția impusă numărului de eșantioane de teorema eșantionării. Dacă intervalul de timp Δt este scurt, limita impusă pentru N prin relația (3.5) este mai mică decât limita impusă de condiția de supradeterminare (3.2). Astfel, alegînd numărul de eșantioane N_1 , conform condiției (3.2), rezultă

$$N_1 \gg 2 \Delta t f_{\max} + 1 . \quad (3.6)$$

Dacă se ține seama de T_1 pasul de eșantionare rezultat, se obține

$$T_1 = \frac{\Delta t}{N_1 - 1} . \quad (3.7)$$

Din relațiile (3.6) și (3.7) se obține

$$T_1 \ll \frac{1}{2 f_{\max}} . \quad (3.8)$$

Rezultă, din cele prezentate mai sus, că alegerea numărului de eșantioane din condiția de supradeterminare conduce la un pas de eșantionare mic față de valoarea limită impusă de teorema eșantionării, într-un proces disponibil pe un interval de timp scurt.

3.1. Erori de estimare a frecvențelor sinusoidelor

În cele ce urmează se analizează erorile ce apar la estimarea frecvențelor sinusoidelor ca rădăcini ale polinoamelor caracteristice

$$P(z) = \prod_{k=1}^M (z - z_k)(z - z_k^*) \quad (3.9)$$

Conform demonstrației din paragraful 2.2, relațiile (2.39) și (2.40), polinoamelor caracteristice are rădăcinile

$$z_k = e^{j2\pi f_k T}, \quad k = 1, 2, \dots, M \quad (3.10)$$

$$z_k^* = e^{-j2\pi f_k T}, \quad k = 1, 2, \dots, M \quad (3.11)$$

Astfel, relația (3.9) poate fi scrisă sub forma

$$P(z) = \prod_{k=1}^M (z^2 + a_k z + 1), \quad (3.12)$$

unde

$$a_k = -(e^{j2\pi f_k T} + e^{-j2\pi f_k T})$$

Rezultă

$$a_k = -2 \cos 2\pi f_k T, \quad k = 1, 2, \dots, M. \quad (3.13)$$

Relația (3.13) permite calculul frecvențelor sinusoidelor în funcție de coeficienții a_k . Se pune problema de a determina eroarea de determinare a frecvenței f_k în funcție de eroarea de estimare a coeficientului corespunzător a_k . Din (3.13) se obține

$$\Delta a_k = \frac{\partial(-2\cos 2\pi f_k T)}{\partial f_k} \Delta f_k \quad (3.14)$$

Rezultă succesiv

$$\Delta a_k = 4\pi T(\sin 2\pi f_k T) \Delta f_k$$

$$\Delta f_k = \frac{1}{4\pi T \sin 2\pi f_k T} \Delta a_k \quad (3.15)$$

Reprezentarea grafică a relației (3.15), pentru Δa_k constant și T constant, este dată în fig.3.1.




Fig.3.1

S-a considerat, pentru f_k , domeniul de frecvență delimitat de teoria eșantionării /55/

$$f_k \leq \frac{1}{2T} \quad (3.16)$$

Se observă, în figura 3.1, că eroarea Δa_k de estimare a coeficientului a_k este multiplicată cu atât mai mult

cu cât frecvența f_k este mai apropiată de limitele intervalului delimitat de teorema eșantionării. Rezultă că, pentru erori de estimare a coeficienților de autoregresie constante, estimațiile pentru frecvențele mici și mari din intervalul specificat rezultă cu erori mari.

Considerînd procesul format din L sinusoidale în zgomot se constată că pe durata Δt a prelevării secvenței de date $\{y_n\}$, $n=1,2,\dots,N$, frecvențele mari sînt eșantionate pe mai multe perioade decît frecvențele mici. Pentru un interval de timp Δt scurt, frecvențele mici sînt eșantionate pe mai puțin de o perioadă. Aceasta conduce la obținerea unor estimații mai bune pentru coeficienții a_k corespunzători frecvențelor mari în comparație cu estimațiile pentru coeficienții a_k corespunzători frecvențelor mici.

Din cele prezentate rezultă că, la estimarea frecvențelor sinusoidelor în funcție de secvența de date prin utilizarea modelului autoregresiv, erori de estimare mari se obțin pentru frecvențele mult mai mici în comparație cu frecvențele de eșantionare (fig.3.1)

$$f_k < \frac{1}{12T} = \frac{f_e}{12} \quad (3.10)$$

Această concluzie este susținută prin rezultatele experimentului 2 (capitolul 4), în care se consideră un proces format din cinci sinusoidale în zgomot. În tabelul (3.1) se prezintă valorile reale ale sinusoidelor, precum și erorile relative procentuale de estimare a frecvențelor pentru trei algoritme. Erorile relative de estimare sînt calculate ca raport între abaterile standard și frecvențele reale corespunzătoare. Abaterile standard sînt obținute prin repetarea experimentelor pentru 20 secvențe de zgomot diferite, dar pentru același raport semnal-zgomot.

Din tabelul (3.1) rezultă, în mod evident, că erorile de estimare sînt cu atât mai mari cu cât frecvența estimată este mai mică. Supradetectorul este sistemului de ecuații linia-

re pentru estimarea coeficienților de autoregresie este mai mică în experimentul 2.3 decât în experimentul 2.2. Rezultă

Frecvențe reale	Hz	2	6	20	25	30
Erori.Bibliografice /lc/ %		10	1,0	0,6	0,36	0
Erori.Experimentul 2.2 %		0,67	0,103	0,057	0,046	0,012
Erori.Experimentul 2.3 %		2,52	0,47	0,20	0,047	0,082

Tabelul 3.1

erori mai mari de estimare a coeficienților de autoregresie în cazul experimentului 2.3. În același experiment frecvența de 30 Hz apare plasată foarte aproape de extremitatea dreaptă a curbei din fig.3.1. Rezultă erori mari la determinarea acestei frecvențe în funcție de coeficienții de autoregresie. Astfel se explică creșterea erorii la frecvența de 30 Hz față de cea de 25 Hz, în experimentul 2.3. Se remarcă erorile mult mai mari corespunzătoare frecvenței de 2 Hz plasată aproape de extremitatea stângă a curbei din fig.3.1, simetric față de frecvența de 30 Hz.

Având în vedere că erori mari de estimare apar pentru frecvențele mult mai mici decât frecvența de eșantionare, relația (3.16), se impune mărirea pasului de eșantionare astfel încât (fig.3.1).

$$f_{kmin} > \frac{1}{12T} = \frac{f_e}{12}$$

unde f_{kmin} este frecvența minimă conținută de procesul considerat. Rezultă

$$T > \frac{1}{12 f_{kmin}} \quad (3.17)$$

Mărirea pasului de eşantionare este limitată de teorema eşantionării

$$T \leq \frac{1}{2 f_{k \max}}, \quad (3.13)$$

unde $f_{k \max}$ este frecvența maximă conținută de proces. În condiția (3.13) se evită egalitatea și apropierea exagerată a pasului de eşantionare de limita impusă de teorema eşantionării. În caz contrar, apar erori mari la calculul frecvenței $f_{k \max}$ în funcție de coeficienții de autoregresie (fig. 3.1). Dacă inecuațiile (3.17) și (3.13) nu au soluție, se utilizează numai condiția (3.11) cu precizările indicate mai sus.

Mărirea efectivă a pasului de eşantionare, pentru un număr de eşantioane dat, înseamnă de fapt mărirea intervalului de timp pe care este cunoscut procesul, ceea ce evident conduce la îmbunătățirea estimațiilor pentru frecvențe.

3.2. Reducerea erorilor de estimare a frecvențelor sinusoidelor prin mărirea simulată a pasului de eşantionare și reducerea supradeterminării sistemului cu care se estimează coeficienții de autoregresie

Se pune problema să, pentru o secvență de date $\{y_n\}$, $n=1,2,\dots,N$, obținută prin eşantionare cu pasul T , să se simuleze mărirea pasului de eşantionare T prin algoritmul de estimare a coeficienților de autoregresie. În cele ce urmează se prezintă algoritmul de estimare a frecvențelor sinusoidelor și care oferă ca mărirea pasului de eşantionare.

Pentru aceasta să luăm în vedere, prin lucrarea de față, matricile de date

$$A_{dK} = \begin{bmatrix} y_{1(L+1)} & y_{K(L-1)+1} & \dots & y_1 \\ y_{1(L+2)} & y_{K(L-1)+2} & \dots & y_2 \\ \vdots & \vdots & & \vdots \\ y_{N-K} & & \dots & y_{N-KL} \end{bmatrix} \quad (3.19)$$

$$A_{iK} = \begin{bmatrix} y_{K+1} & \dots & y_{KL+1} \\ y_{K+2} & \dots & y_{KL+2} \\ \vdots & & \vdots \\ y_{N-K(L-1)} & \dots & y_N \end{bmatrix} \quad (3.20)$$

$$A_{d1K} = \begin{bmatrix} 1 \\ \vdots \\ 0 \end{bmatrix} \quad (3.21)$$

$$A_{eK} = \begin{bmatrix} y_{KL+1} + y_1 & y_{(L-1)+1} + y_{K+1} & \dots & y_{K(L/2+1)} \\ y_{KL+2} + y_2 & y_{(L-1)+2} + y_{K+2} & \dots & y_{K(L/2+1)+1} \\ \vdots & \vdots & & \vdots \\ y_N + y_{N-KL} & y_{N-K(L-1)} & \dots & y_{N-K(L/2-1)-1} \end{bmatrix} \quad (3.22)$$

unde K este un număr întreg. Dimensionile matricilor de date sînt $A_{dK}(N-KL) \times (L+1)$, $A_{iK}(N-KL) \times (L+1)$, $A_{d1K}(2L-L) \times (L+1)$ și $A_{eK}(N-KL) \times (L+1)$.

Matricile definite mai sus sînt construite cu același egalitate și pe același principii cu matricile A_d , A_1 , A_{d1} și A_g definite în paragraful 2.1, cu diferența că în liniile matricilor A_{dK} , A_{1K} , A_{d1K} și A_{gK} egalitățile nu sînt luate unul după celălalt ci sînt luate în K . Relațiile (3.19), (3.20), (3.21) și (3.22) reprezintă un mod general de definire a matricilor de date. În particular, pentru $K=1$, se obțin matricile de date definite în paragraful 2.1. Pentru estimarea numărului de sinusoidelor și coeficienților de autoregresie se operează cu matricile A_{dK} , A_{1K} , A_{d1K} și A_{gK} la fel ca și cu matricile A_d , A_1 , A_{d1} și A_g . Determinarea frecvențelor sinusoidelor în funcție de rădăcinile polinomului caracteristic se face cu relația

$$f_k = \frac{1}{2\pi K T} \arg(\lambda_k), \quad k=1,2,\dots,n. \quad (3.23)$$

Faptul că în liniile matricilor de date egalitățile sînt luate din K în K echivalează, din punct de vedere al estimării frecvențelor, cu mărirea pasului de eșantionare de K ori. Se definește pasul simulat de eșantionare

$$T_{sK} = K T, \quad (3.24)$$

unde T reprezintă pasul de eșantionare s-a prelevat secvența de date $\{y_n\}$. Factorul de multiplicare K se alege astfel încît să se respecte teorema eșantionării

$$K < \frac{1}{2T f_{kmax}}, \quad (3.25)$$

unde f_{kmax} este frecvența maximă conținută în procesul considerat.

Mărirea simulată a pasului de eșantionare, în condiția unei secvențe de date de lungime constantă N prelevată pe un interval de timp constant Δt , conduce la reducerea supradeterminării sistemelor de ecuații construite cu matricile de date. Supradeterminarea este proporțională cu numărul de ecuații ale sistemului, deci cu numărul de linii ale matricii de date.

Numărul de linii ale matricilor de date A_{dK} , A_{iK} , A_{dL} este $(N-KL)$, iar numărul de linii ale matricii A_{dIK} este $(2(N-KL))$. Rezultă o reducere a supradeterminării sistemelor cu atât mai mare cu cât K este mai mare. Reducerea supra-determinării sistemelor conduce, în principiu, la obținerea unor estimări mai puțin bune pentru coeficienții de autoregresie. Pe de altă parte, reducerea numărului de linii ale matricilor de date conduce la reducerea volumului și deci a timpului de calcul necesar rezolvării sistemului de ecuații supradeterminat.

Din cele prezentate rezultă că, fiind dată o secvență de date de lungime constantă N prelevată prin egantionarea unui proces format din sinusoidă în zgomot aditiv pe un interval de timp constant Δt , utilizarea matricilor de date cu $K > 1$ are mai multe consecințe. Astfel se obține mărirea simulată a pasului de egantionare, ceea ce conduce la estimări mai bune pentru frecvențe. Reducerea supra-determinării este o altă consecință și are un efect contrar cu cel obținut prin mărirea simulată a pasului de egantionare. Ultima consecință constă în reducerea timpului de calcul afectat estimării frecvențelor sinusoidelor.

În cele ce urmează se va analiza corelarea dintre consecințele expuse mai sus pentru cazul matricii de date sumă. Utilizarea matricii A_{EK} pentru estimarea frecvențelor sinusoidelor se justifică prin aceea că numărul de coeficienți de autoregresie estimați este redus la jumătate față de cazul utilizării matricilor A_{dK} , A_{iK} sau A_{dIK} .

Se definește factorul de mărire relativă a pasului de egantionare

$$\eta_K = \frac{T_E}{T_{dL}} \quad (3.26)$$

Având în vedere relația (3.24) se obține

$$\eta_K = K \quad (3.27)$$

Se definește factorul de supra-determinare raportat între numărul de linii și numărul de coloane ale matricii

de date sumă

$$\varepsilon_K = \frac{N-KL}{\frac{L}{2} + 1} \quad (3.21)$$

Pentru a analiza consecințele utilizării matricilor A_{gk} , cu $K > 1$ se interpretează rezultatele experimentelor 1 și (capitolul 4). În experimentul 1 se consideră un proces format din o sinusoidă în zgomot activ. Estimarea frecvenței sinusoidale în experimentul 1.1 se face cu matricea $A_{g1} = A_{g1}$, de dimensiune 7×2 , rezultând un sistem de ecuații cu factorul de supradeterminare 3,5. Utilizarea matricii de date A_{g2} ($K=2$), de dimensiune 5×2 și a set-ului de supradeterminare 2,5, în experimentul 1.3, conduce la reducerea abaterii standard a estimărilor pentru frecvență de aproape jumătate din cea obținută în experimentul 1.2. Abaterile standard sînt obținute prin repetarea experimentului pentru 200 de probe de zgomot diferite, dar pentru același proces semnal-zgomot. Rezultă că reducerea supradeterminării de la 3,5 la 2, are un efect mult mai mic decît dublarea numărului de ecuații de ecantionare. În experimentul 1.4 se utilizează matricea de date A_{g3} ($K=3$) de dimensiune 3×2 , rezultând un sistem cu factor de supradeterminare 1,5. Se obține aproximativ aceeași abatere standard a estimărilor pentru frecvență ca și în experimentul 1.3. Rezultă că, din punctul de vedere al estimărilor pentru frecvență, efectul măririi numărului de ecantionare de la 21 la 31 s-a compensat cu efectul reducerii supradeterminării de la 2,5 la 1,5. Totuși, prin experimentul 1.4, s-a obținut o reducere a dimensiunii sistemului de ecuații, deci implicit ecuațiilor necesare pentru estimare. În aprecierile prezentate nu s-au implicat valorile medii ale estimărilor pentru frecvență deoarece variațiile lor sînt mult mai mici decît valorile abaterilor standard.

În experimentul 2 (capitolul 4) se consideră un proces format din cinci sinusoidale în zgomot. Utilizarea matricii de date $A_g = A_{g1}$ în experimentul 1.1, de dimensiune 61×6 , conduce la obținerea unor erori sistematice grosolane. Valorile singulare ale matricii A_{g1} au rangul trei pentru matricea A_g .

Rezultă că este evidentă doar prezența celor trei sinusoidale cu frecvențe mari. Aceasta se explică prin aceea că o durată corespunzătoare unei linii a matricii A_g nivelul frecvențelor mici se schimbă puțin. Altfel spus, raportul frecvențelor mici în ecantioanele corespunzătoare unei linii a matricii A_g este aproximativ constant. În experimentul 2.2 se utilizează matricea de date A_{g4} ($k=4$), de dimensiune 31×6 , rezultând un sistem cu factor de supradeterminare 5,16. Valorile singulare ale matricii A_{g4} indică clar prezența celor cinci sinusoidale. Pentru a putea aprecia estimațiile obținute pentru frecvențe se face comparația cu rezultatele obținute în /10/ pentru același proces și aceleași date. În /10/ estimarea frecvențelor se face prin r-un algoritmul ce corespunde utilizării matricii de date A_{di} , de dimensiune 70×26 . Se constată prezența rădăcinilor suplimentare ale polinomului caracteristic al sistemului cu coeficienții de autoregresie. În tabelul 3.1 se prezintă erorile relative de estimare pentru frecvențe, obținute în /10/ și în experimentul 2.2. Erorile relative sînt exprimate ca raport între abaterile standard și frecvențele reale corespunzătoare. Abaterile standard sînt obținute prin simularea procesului experimental pentru 20 frecvențe de zgomot diferit, și pentru același raport semnal-zgomot. Din rezultatele prezente în tabelul 3.2 rezultă că multiplicarea simulată cu patru numărul de ecantioane, în experimentul 2.2, conduce la o îmbunătățirea substanțială a estimațiilor pentru frecvențe și la o reducere a erorilor publicate în /10/. Reducerea erorii relative de estimare este cu atât mai pronunțată cu cît frecvența sinusoidalei este mai mică. În experimentul 2.3 se utilizează doar primele 15 ecantioane din cele 71 utilizate în experimentul 2.2. Rezultă o matrice A_{g4} de dimensiune 13×6 , care conduce la un sistem cu factor de supradeterminare 2,16. În tabelul (3.1) se observă că și în acest caz se obțin estimații mai bune decît cele publicate în /10/.


În celelalte două cazuri se evidențiază posibilitatea reducerii numărului de ecantioane și menținerea constantă sau re-

ducerea erorilor de estimare, prin mărirea simulată a pasului de eşantionare şi reducerea supradeterminării. În acest caz apare şi o mărire efectivă a pasului de eşantionare deoarece se prelevează mai puţine eşantioane pe un interval de timp dat. Pe de altă parte, reducerea numărului de eşantioane măsoară valoarea maximă a factorului de multiplicare K ce poate fi utilizat, astfel încât sistemul de ecuaţii liniare să fie supradeterminat.

Astfel, în experimentul 1.5 se prelevează pe intervalul de timp $\Delta t = 0,4$ s un număr $n = 7$ eşantioane, faţă de nouă eşantioane prelevate în experimentul 1.2. Valoarea maximă a factorului de multiplicare utilizabil este $K = 2$, pentru care rezultă matricea A_{92} , de dimensiune 3×2 . Factorul de supra-determinare este $\xi = 1,5$. Astfel ce obţine, în experimentul 1.5, o reducere a abaterii standard a estimărilor pentru frecvenţă cu peste 40% mai mică decât cea obţinută în experimentul 1.2, unde se utilizează matricea $A_9 = A_{92}$. Acest rezultat susţine posibilitatea reducerii numărului de eşantioane prelevate pe un interval de timp dat şi menţinerea constantă, sau reducerea erorilor de estimare, prin mărirea simulată a pasului de eşantionare şi reducerea supradeterminării.

Pe baza consideraţiilor teoretice şi a rezultatelor experimentale prezentate rezultă că mărirea simulată a pasului de eşantionare conduce la îmbunătăţirea estimărilor pentru frecvenţe în cazul reducerii supradeterminării sistemului de ecuaţii liniare în care se estimează coeficienţii de autoregresie. La factori de supra-determinare mici, apropiati de unu, efectul reducerii supradeterminării poate compensa efectul mării simulete a pasului de eşantionare. În acest caz rămâne avantajul privind reducerea volumului şi deci a timpului de calcul necesar estimării frecvenţelor sinusoidelor.

În plus, mărirea simulată a pasului de eşantionare permite reducerea numărului de eşantioane prelevate pe un interval de timp dat şi menţinerea constantă sau reducerea erorilor de estimare a frecvenţelor sinusoidelor, în urma reducerii supradeterminării sistemului de ecuaţii liniare cu care se estimează coeficienţii de autoregresie.



Mărirea similitudinii a pasului de eșantionare conduce la mărirea intervalului de timp pe care sînt prelevate eșantioanele unei linii a matricii de date ca și în cazul introducerii rădăcinilor suplimentare. Rezultă ca, prin utilizarea matricilor de date cu $K > 1$, se elimină necesitatea introducerii rădăcinilor suplimentare. Se obține o simplificare a algoritmului deoarece nu mai este necesară operația de identificare a frecvențelor adevărate și în plus se elimină posibilitatea apariției efectului de mascare a liniilor spectrale (experimentul 2.4).

3.3. Reducerea erorilor de estimare a frecvențelor sinusoidelor prin mărirea simulată a pasului de eșantionare și mărirea numărului de eșantioane

Se consideră procesul format din M sinusoides în zgomot aditiv și disponibil pentru eșantionare pe intervalul de timp Δt . Din cele prezentate anterior s-a rezultat că, pentru un număr de eșantioane M impus, utilizarea matricilor de date A_{gK} , $K > 1$, conduce la reducerea factorului de supradeterminare al sistemului cu care se estimează coeficientii de autoregrare. În cele ce urmează se impune ca la utilizarea matricilor de date A_{gK} , $K > 1$, factorul de supradeterminare al sistemului rezultant să fie același ca și în cazul utilizării matricii de date A_{g1} . Aceasta se poate realiza numai prin mărirea numărului de eșantioane prelevate pe intervalul de timp Δt . Mărirea unui factor de supradeterminare constant garantată, din punct de vedere statistic, erori constante de calcul la rezolvarea sistemului de ecuații liniare supradeterminate. Mărirea numărului de eșantioane presupune, pentru Δt constant, micșorarea pasului efectiv de eșantionare. Totuși, prin utilizarea matricilor de date A_{gK} , $K > 1$, se obține mărirea simulată a pasului de eșantionare față de cazul utilizării matricii de date A_{g1} . Rezultă estimări mai bune pentru frecvențele sinusoidelor.

Se afirmă că un pas de eșantionare mic nu este util deoarece el este compus din eșantioane consecutive

tinde să devină egal cu vectorul constant $(1,1,\dots,1)^T$. Este cazul liniilor matricii de date A_{g1} construite prin combinația unor eșantioane consecutive. Deoarece la formarea liniilor matricilor A_{gK} , $K > 1$, eșantioanele sînt luate din K E_{11} , acest dezavantaj este eliminat. În prezenta lucrare se afirmă și se demonstrează că prelevarea pe durată Δt a unui număr cît mai mare de eșantioane, deci utilizarea unui pas de eșantionare cît mai mic, conduce la obținerea unor estimări mai bune pentru frecvența, prin mîzire simulată a pasului de eșantionare. Acest fapt devine posibil numai prin utilizarea matricilor de date A_{gK} , $K > 1$. Se precizează că aceasta se realizează fără a mări valoarea de calcul necesară estimării frecvențelor sinusoidale.

În cele ce urmează se demonstrează posibilitatea mîzirii simulate a pasului de eșantionare prin mărirea numărului de eșantioane prelevate pe intervalul de timp constant Δt , în condiția menținerii supra-determinării constante a sistemului de ecuații.

Dacă se notează cu N_K și h_K , pasul de eșantionare și respectiv numărul de eșantioane prelevate pe intervalul Δt , în cazul utilizării matricilor de date A_{gK} , $K=1,2,\dots$, se obține

$$\frac{\Delta t}{T_K} = N_K - 1 \quad (3.29)$$

Pasul simulat de eșantionare este dat de relația

$$T_{gK} = K T_K \quad (3.30)$$

Factorul de supra-determinare este

$$\xi = \frac{N_K - K + 1}{\frac{L}{2} + 1} \quad (3.31)$$

Prin notație fără indice a factorului de supra-determinare se precizează că acesta este funcție de K . Din relația

ția (3.31) se cedează numărul de ecuații necesare construirii matricii $A_{ek}, k=1,2,\dots$ în funcție de factorul de supra-determinare μ_k

$$n_k = KL + \xi\left(\frac{L}{K} + 1\right) \quad (3.32)$$

se obține valoarea relativă a numărului de ecuații

$$\frac{n_k}{n_1} = \frac{KL + \xi\left(\frac{L}{K} + 1\right)}{L + \xi\left(\frac{L}{1} + 1\right)} \quad (3.33)$$

Relația (3.33) arată de câte ori trebuie mărit numărul de ecuații preluate pe intervalul de timp Δt , la utilizarea matricii $A_{ek}, k=1,2,\dots$, față de cazul utilizării matricii $A_{e1}=A_1$, astfel încât supra-determinarea sistemelor de ecuații rezultate să fie aceeași.

Rezultă valoarea a frecvenței de ecuaționare

$$\frac{f_{ek}}{f_{e1}} = \frac{T_1}{T_k} \cdot \frac{-1}{-1} \quad (3.34)$$

Având în vedere relația (3.32) se obține mărimea relativă a frecvenței de ecuaționare

$$\frac{f_{ek}}{f_{e1}} = \frac{KL + \xi\left(\frac{L}{K} + 1\right) - 1}{L + \xi\left(\frac{L}{1} + 1\right) - 1} \quad (3.35)$$

Factorul de mărime relativă a numărului de ecuaționare este

$$\eta_k = \frac{T_1}{T_k} \quad (3.36)$$

Din relațiile (3.30) și (3.36) se obține

$$\eta_K = K \frac{T_K}{T_1} = K \frac{f_{ei}}{f_e} \quad (3.37)$$

Rezultă

$$\eta_K = K \frac{L + \left(\frac{L}{2} + 1\right) \varepsilon - 1}{KL + \left(\frac{L}{2} + 1\right) \varepsilon - 1} \quad (3.38)$$

Deoarece $\varepsilon > 1$ și $L \geq 2$, atunci

$$\eta_K > 1, \quad (3.39)$$

pentru $K = 2, 3, \dots$. Relația (3.39) indică posibilitatea mării simulete a pasului de calcul mare prin mărirea numărului de eşantioane preluate pe intervalul de timp constant Δt , în condiția obținerii unei soluții determinări constante a sistemului de ecuații. Relația (3.39) arată de câte ori se mărește pasul simulat de eşantionare în cazul utilizării matricii A_{2K} , $K = 1, 2, \dots$ față de cazul utilizării matricii $A_{21} = A_2$. Această mărire este limitată de valoarea

$$\eta_\infty = \frac{L + \varepsilon\left(\frac{L}{2} + 1\right) - 1}{L} \quad (3.40)$$

Pentru cazul în care se introduce rădăcini suplimentare, adică

$$L = 2M,$$

relațiile (3.38), (3.39) și (3.40) devin

$$\frac{N_K}{N_1} = \frac{2KL + \varepsilon(L+1)}{2L + \varepsilon(L+1)}, \quad (3.41)$$

$$\frac{f_{eK}}{f_{e1}} = \frac{2K + \varepsilon(l+1) - 1}{2K + \varepsilon(l+1) - 1}, \quad (3.42)$$

$$\eta_K = K \frac{2K + \varepsilon(l+1) - 1}{2K + \varepsilon(l+1) - 1}. \quad (3.43)$$




Pe baza datelor dinor deduse mai sus se analizează procesul prezentat în experimentul 1 (Capitolul 4). Scopul analizei constă în a stabili criteriile de alegere a factorului de multiplicare K . Procesul menționat constă din o sinusoidă cu frecvența de 1 Hz generat aditiv și este disponibil pentru eșantionare pe un interval de timp $\Delta t = 0,4$ s. În experimentul 1.2 numărul de eșantioane este $N_1 = 9$ și avînd în vedere că $l = 2k = 2$, se obține o matrice A_9 de dimensiune 7×2 . Rezultă factorul de supradeterminare $\varepsilon = 3,5$. În aceste condiții relațiile (3.41), (3.42) și (3.43) devin

$$\frac{N_K}{N_1} = \frac{2K + 3}{9}, \quad (3.44)$$

$$\frac{f_{eK}}{f_{e1}} = \frac{K + 3}{K + 3}, \quad (3.45)$$

$$\eta_K = \frac{4K}{K + 3}. \quad (3.46)$$

Reprezentarea grafică a relațiilor de mai sus, pentru $K = 1, 2, \dots, 10$, este prezentată în figura 3.2. Se constată că în timp ce numărul de eșantioane și frecvența de eșantionare cresc cu o pantă constantă în funcție de K , factorul de mărire relativă a pasului de eșantionare crește cu o pantă ce scade odată cu creșterea lui K . Rezultă că la mărirea exagerată a factorului de multiplicare, câștigul în mărirea relativă a pasului de eșantionare este mic, în timp ce frecvența de eșantionare și numărul de eșantioane cresc mult.



3.2

Imbunătățirea este realizată pentru frecvențe, prin mărirea numărului de ogonici, realizate pe intervalul de timp Δt utilizarea matricilor de transfer $A_{gk}, k=1$, este susținută prin

compararea rezultatelor experimentului 1.2 ($K=1$; $N_1=9$; $T_1=0,05s$; $\xi=3,5$) cu rezultatele experimentului 1.5 ($K=7$; $N_7=21$; $T_7=0,05s$; $\xi=3,5$; $\eta_7=2,3$). Astfel prin experimentul 1.6 se realizează micșorarea abaterii standard a estimațiilor pentru frecvența de 2,3 ori față de abaterea standard corespunzătoare experimentului 1.2. Abaterile standard sînt obținute prin repetarea fiecărui experiment pentru 200 secvențe de zgomot diferite, dar pentru același raport semnal-zgomot. Reducerea abaterii standard de 2,3 ori, în condițiile măririi numărului de eșantioane de la 9 la 21 și a măririi frecvenței de eșantionare de 2,5 ori, este posibilă prin mărirea simplității pasului de eșantionare de 2,3 ori cu matricea de date A_{SK} . Volumul și timpul de calcul necesar estimării amplitudinii sinusoidale este același în ambele experimente.

Din condițiile teoretice și rezultatele experimentale prezente rezultă că, în condiția obținerii unui sistem de ecuații cu același factor de supradeterminare, este posibilă mărirea simplității pasului de eșantionare prin mărirea numărului de eșantioane prelevate pe intervalul de timp Δt constant. Rezultă o îmbunătățire a estimațiilor pentru frecvențe, fapt ce devine posibil numai prin utilizarea matricilor de date A_{SK} , $K > 1$. Deoarece factorul de supradeterminare este constant rezultă un același volum de calcul și deci de timp de calcul necesar pentru estimarea frecvențelor sinusoidale.

3.4. Necesitatea intervalului de timp pe care se prelevează eșantioanele și menținerea constantă a erorilor de estimare a frecvențelor sinusoidale prin mărirea simplității pasului de eșantionare și mărirea numărului de eșantioane

Se consideră procesul format din n sinusoidale în zgomot aditiv. Se vede că la utilizarea matricilor de date A_{SK} , $K > 1$, factorul de supradeterminare al sistemelor rezul-

tante să fie același ca și în cazul utilizării matricii A_{s1} . Având în vedere că eșantioanele sînt prelevate pe un interval de timp mai scurt și că suprafața de determinare este constantă rezultă creșterea erorilor de estimare a coeficienților de auto-regresie. În cazul în care frecvențele sinusoidelor conținute în proces sînt mult mai mici decît frecvența de eșantionare este posibilă compensarea creșterii erorilor de estimare a coeficienților de auto-regresie prin reducerea erorilor la determinarea frecvențelor în funcție de acești coeficienți. În acest scop se procedează la mărirea simuleții a pasului de eșantionare, astfel încît

$$T_{sK} > T_1 = T, \quad (3.47)$$

unde T_{sK} reprezintă pasul simulat de eșantionare. Rezultă că factorul de mărire relativă a pasului de eșantionare trebuie să fie supraunitar

$$\eta_K = \frac{T_{sK}}{T_1} > 1.$$

În cele ce urmează se demonstrează că utilizarea matricilor de date A_{sK} , $K \geq 2$, în condițiile precizate mai sus, conduce la reducerea intervalului de timp pe care se prelevează eșantioanele, dacă se menține numărul de eșantioane și implicit frecvența de eșantionare.

Dacă se notează cu Δt_K intervalul de timp pe care se prelevează eșantioanele în cazul utilizării matricilor A_{sK} , $K = 1, 2, \dots$ se obține

$$\frac{\Delta t_K}{T_K} = N_K - 1. \quad (3.48)$$

Pasul simulat de eșantionare este

$$T_{sK} = K \Delta t_K. \quad (3.49)$$

Rezultă mărimea relativă a frecvenței de egantionare

$$\frac{f_{eK}}{f_{e1}} = \frac{T_1}{T_K} = \frac{T_1}{T_{BK}} \quad (3.50)$$

Din relația de definiție a factorului de supraestimar-
minare pentru măsurările de date sumă

$$\xi = \frac{\frac{N_K - n_0}{K} - 1}{\frac{L}{2} + 1}, \quad (3.51)$$

se obține

$$N_K = n_0 + \xi \left(\frac{L}{2} + 1 \right), \quad (3.52)$$

unde $K = 1, 2, \dots$ este mărimea relativă a numărului de
egantioane

$$\frac{N_K}{N_1} = \frac{n_0 + \xi \left(\frac{L}{2} + 1 \right)}{L + \xi \left(\frac{L}{2} + 1 \right)}. \quad (3.53)$$

Se definește reducerea relativă a intervalului de
timp pe care se înregistrează egantioanele prin raportul

$\Delta t_K / \Delta t_1$. Din (3.53) se obține

$$\frac{\Delta t_K}{\Delta t_1} = \frac{T_K (N_1 - 1)}{T_1 (N_K - 1)}. \quad (3.54)$$

Inlocuind relațiile (3.50) și (3.52) în (3.54), re-
zultă

$$\frac{\Delta t_K}{\Delta t_1} = \frac{1}{K} \cdot \frac{\left[n_0 + \xi \left(\frac{L}{2} + 1 \right) - 1 \right]}{\left[L + \xi \left(\frac{L}{2} + 1 \right) - 1 \right]} \cdot \frac{T_{BK}}{T_1}. \quad (3.55)$$

Avînd în vedere relația (3.47), se obține

$$\frac{\Delta t_K}{\Delta t_1} > \frac{1}{K} \cdot \frac{KL + \xi \left(\frac{L}{K} + 1 \right) - 1}{L + \xi \left(\frac{L}{K} + 1 \right) - 1} \quad (3.56)$$

Deoarece $\xi > 1$ și $K > 1$, termenul din dreapta al relației (3.56) este subunitar, pentru $K = 2, 3, \dots$, rezultă deci posibilitatea ca raportul $\Delta t_K / \Delta t_1$ să fie subunitar ceea ce corespunde reducerii intervalului de timp pe care se prelevează eșantioanele.

Pentru cazul în care se introduce rezistență suplimentară, adică

$$L = 2L,$$

relațiile (3.53) și (3.54) devin

$$\frac{N_K}{N_1} = \frac{2KL + \xi(L+1)}{2L + \xi(L+1)}, \quad (3.57)$$

$$\frac{\Delta t_K}{\Delta t_1} = \frac{1}{K} \cdot \frac{2KL + \xi(L+1) - 1}{2L + \xi(L+1) - 1} \cdot \frac{T_{BK}}{T_1} \quad (3.58)$$

Pe baza relațiilor prezentate mai sus se analizează procesul prezentat în experimentul (Capitolul 4). Procesul menționat constă din o sinusoidă de frecvență de 1 Hz în zgomot aditiv și este disponibil pentru măsurare pe un interval de timp $\Delta t_1 = 0,4s$. În experimentul menționat numărul de eșantioane este $N_1 = 9$ și, avînd în vedere relația (3.57) pentru $K=2$, se obține o matrice A_2 de dimensiune 7×2 . Întrucît $N_2 > N_1$ există un factor de supradeterminare $\xi = 3,5$. În cele ce urmează se presupune o anumită reducere a intervalului de timp pe care se prelevează eșantioanele și se analizează posibilitatea de a realiza simularea a posului de eșantionare, mărire destinată să compenseze reducerea intervalu-

lui de timp din punctul de vedere al erorilor de estimare
 ă frecvențelor. Astfel se impune o reducere cu 25% a inter-
 valului de timp în care se prelevează eșantioanele, adică

$$\frac{\Delta t_K}{\Delta t_1} = 0,75$$

pentru a se preciza mai sus, relațiile (3.57) și
 (3.58) devin.

$$\frac{n_K}{n_1} = \frac{2K+1}{3} \quad (3.59)$$

$$\eta_K = \frac{T_{01}}{T_{0K}} \quad (3.60)$$

Din relațiile (3.59) și (3.60) rezultă

$$\frac{f_{eK}}{f_{e1}} = \frac{K+1}{3} \quad (3.61)$$

Reprezentarea grafică a relațiilor (3.59), (3.60) și
 (3.61), pentru $K=1, 2, \dots, 10$ este prezentată în figura 3.3.

Se constată că numărul de eșantioane și frecvența de
 eșantionare cresc cu o pantă constantă în funcție de K , în
 timp ce panta de creștere a factorului de mărire relativă a
 pasului de eșantionare scade odată cu creșterea lui K . Re-
 zultă că la mărire exagerată a factorului de multiplicare,
 câștigul în măsurare relativă a pasului de eșantionare este
 mic, în timp ce frecvența de eșantionare și numărul de eșan-
 tioane cresc mult.

Posibilitatea reducerii intervalului de timp în care
 se prelevează eșantioanele și menținerea constantă a erori-
 lor de estimare este susținută experimental. Astfel în ex-
 perimentul 1.7 ($\omega = 100$; $n_0 = 19$; $T_0 = 0,0157s$; $\varepsilon = 3,5$; $\Delta t_0 = 0,3s$),
 erorile de estimare la frecvenței sînt cu puțin mai mici decît

cele obținute în experimentul 1.2 ($K=1$ $N_1=9$; $T_1=0,05$; $\varepsilon=3,5$; $\Delta t_1=0,4s$). Se evidențiază faptul că în experimentul 1.7 in-






Fig. 3.3

Intervalul de timp pe care procesul trebuie să fie disponibil pentru eșantionare este redus cu 25% față de cel necesar în experimentul 1.2. Aceasta în condițiile mării numărului de

egantioane de la 9 la 19 și a măririi frecvenței de egantionare de trei ori. Obținerea unor erori comperabile în cele două experimente este posibilă numai prin mărirea simulată a pasului de egantionare care compensează reducerea intervalului de timp pe care se prelevează egantioanele. Volumul de calcul necesar estimării frecvenței sinusoidale este același în ambele experimente și rezultă din condiția de supradeterminare constantă.

Din considerațiile teoretice și din rezultatele experimentale prezente se rezultă că este posibilă reducerea intervalului de timp pe care se prelevează egantioanele cu menținerea constantă a erorilor de estimare. Erori de estimare constante se pot obține prin impunerea unei supradeterminări constante prin compensarea efectului reducerii intervalului de timp cu efectul măririi simulată a pasului de egantionare. Pentru aceasta este necesară mărirea numărului de egantioane și a frecvenței de egantionare. Dacă factorul de supradeterminare este constant rezultă menținerea constantă a volumului și deci a timpului de calcul necesar estimării evenimentelor sinusoidalelor.

4. DATE EXPERIMENTALE

Partea experimentală a lucrării are scopul de a verifica principalele contribuții teoretice ale lucrării și se bazează pe simularea unor procese aleatoare compuse din sinusoidă și din zgomot aditiv. Acest procedeu de experimentare este utilizat frecvent în literatură de specialitate /9/, /10/, /22/, /24/, /39/, /57/.

Considerând un proces format din L sinusoidă de amplitudini A_k , frecvențe f_k și faze φ_k , $k=1,2,\dots,L$, se calculează esantioanele x_n conform relației

$$x_n = \sum_{k=1}^L A_k \sin(\pi f_k n T + \varphi_k), \quad n=1,2,\dots,N \quad (4.1)$$

unde T reprezintă pasul de eșantionare, iar N reprezintă lungimea secvenței de date. Pentru a simula zgomotul se generează o secvență, $\{w_n\}$, $n=1,2,\dots,N$, de numere aleatoare Gaussiene de medie nulă și dispersie unitară ca funcție de raportul semnal-zgomot impus. Secvența de date s-a generat pe baza subrutinei GAUS, din /53/, care aplică teorema limitei centrale la generarea a unui esantion al secvenței aleatoare Gaussiene din 12 numere aleatoare uniform distribuite.

Secvența de date corespunzătoare procesului format din sinusoidă în zgomot aditiv se obține prin relația

$$y_n = x_n + w_n, \quad n=1,2,\dots,N. \quad (4.2)$$

Pentru interpretarea statistică a rezultatelor, fiecare experiment este repetat cu secvențe diferite de zgomot.

dar cu același nivel de semnal-zgomot. Se calculează, astfel, valori medii și erori standard pentru mărimile estimate, frecvențe, amplitudini și faze.

Pentru decompunerea valorilor singulare a matricilor de date se utilizează subrutina `MSVD`, din /58/. Subrutina se bazează pe un algoritm stabil și eficient /17/.

Algoritmul constă în reducerea matricii la forma bidiagonală prin două succese de transformări Householder la stînga și la dreapta, urmînd diagonalizarea ca o variantă a procedurii din /58/.

Pentru calculul rădăcinilor polinomului caracteristic se utilizează subrutina `KPRAD1`, din /53/, bazată pe procedeul iterativ Levenberg-Marquardt. Pentru determinarea amplitudinilor și fazelor sinusoidelor, în funcție de secvența de date și de estimările pentru frecvențe, se utilizează subrutinele `KPRF` și `KPRFI` din /53/ de rezolvare a sistemelor de ecuații liniare supraderminate.

Programele sînt în FORTRAN.

Alegerea experimentelor corespunde contribuțiilor originale ale lucrării. Astfel, pentru estimarea numărului de sinusoidale se utilizează matricile de date A_g sau A_{gk} . Numărul de sinusoidale se estimează ca rang efectiv al acestei matrici, prin analiza valorilor singulare rezultate din DVS. Rezolvarea sistemelor de ecuații liniare supraderminate pentru estimarea coeficienților de autoregresie se face prin utilizarea de compuneri valorilor singulare. Soluția unui sistem este dată de spațiul liniar generat de ultimele coloane ale matricii V rezultată din DVS. În cazul introducerii rădăcinilor suplimentare pentru polinomul caracteristic, se utilizează algoritmul de reducere pentru determinarea rădăcinilor adevărate. Se certifică experimental că erorile mari de estimare se obțin pentru frecvențele mult mai mici decât pasul de eșantionare. Pentru mărirea simulată a numărului de eșantionare se utilizează matricile A_{gk} , $k=1,2,\dots$. Se evidențiază reducerea erorilor de estimare a fazelor sinusoidelor prin mărirea simulată a pasului de eșantionare și reducerea supraderminată

rii, pentru un număr de eșantioane dat. Mărirea simulată a pasului de eșantionare conduce la mărirea intervalului de timp pe care sînt preluate eșantioanele unei linii a matricii de date, ca și în cazul introducerii rădăcinilor suplimentare. Rezultă că prin utilizarea matricilor de date A_{kq} , $k=2,3,\dots$, se elimină necesitatea introducerii rădăcinilor suplimentare. În acest caz soluția sistemului de ecuații liniare supradeterminat este cea ultimă coloană a matricii V rezultată din DVS a matricii de date. Se obține o simplificare a algoritmului deoarece nu mai este necesară operația de identificare a frecvențelor săvârșite și în plus se elimină posibilitatea apariției aspectului de despiciere a liniilor spectrale. Se dovedește experimental reducerea erorilor de estimare a frecvențelor, chiar în cazul reducerii numărului de eșantioane prelevate pe un interval de timp dat. Această rezultă prin mărirea similitudinii pasului de eșantionare și reducerea supradeterminării. Se evidențiază reducerea erorilor de estimare a frecvențelor sinusoidelor prin mărirea simulată a pasului de eșantionare și mărirea numărului de eșantioane prelevate pe un interval de timp dat. În acest caz supradeterminarea se menține constantă. Se dovedește experimental posibilitatea reducerii intervalului de timp pe care se prelevează eșantioanele în condiția menținerii constante a erorilor de estimare a frecvențelor sinusoidelor. Aceasta se obține prin mărirea similitudinii pasului de eșantionare, mărirea numărului de eșantioane și menținerea unei supradeterminări constante.

Experimentul 1

În cadrul primului experiment se simulează un proces format din o sinusoidă unisonot aditiv. Sinusoida are frecvența, $f=1$ Hz, amplitudina, $A=1$ și faza, $\varphi=0^\circ$. Intervalul de timp pe care se consideră procesul ca fiind disponibil este $\Delta t=0,4$ s, mai mic decît valoarea perioadei sinusoidale. Numărul semnal-zgomot, ρ , este dat prin relația

$$SNR = 10 \lg \frac{\sum_{n=0}^{N-1} A \sin(2\pi n T + \varphi)^2}{N \sigma^2}, \quad (4.3)$$

este de 10 dB. În relația (4.3), N reprezintă numărul de eșantioane preluate pe intervalul de timp Δt , iar σ^2 reprezintă dispersia zgomotului de zgomot.

Experimentul 4.1

Prin acest experiment se evidențiază utilitatea descompunerii valorilor singulare la estimarea coeficienților de autoregresie. Modelul sistemului de ecuații liniare supradeterminat este de spațiu liniar generat de alți sinele coloane ale matricii V rezultat din DVS a matricii de date. De asemenea, prin acest experiment, se evidențiază utilizarea algoritmului de reducere pentru determinarea coeficienților de autoregresie corespunzători sinusoidelor adevărate.

Pe intervalul de timp $\Delta t = 0,4$ s se prelevează un număr de eșantioane $N = 100$. Rezultă un pachet de eșantioane $t = 0,05$ s. Pentru estimarea coeficienților de autoregresie se utilizează matricea de date A_{d1} , cu $L = 4$, ceea ce implică prezența unei sinusoidale adevărate. Dimensiunea matricii A_{d1} este 10×5 . Sistemul de ecuații liniare supradeterminat, prin care se estimează coeficienții de autoregresie, se rezolvă prin utilizarea metodei de reducere. Soluția sistemului rezultă ca spațiu liniar generat de alți sinele trei coloane ale matricii V , obținută din DVS a matricii A_{d1} . Pentru determinarea coeficienților de autoregresie corespunzători sinusoidelor adevărate se aplică algoritmul de reducere. În tabelul 4.1 se prezintă rezultatele experimentului 4.1, adică valorile medii și abaterile standard ale estimărilor calculate prin repetarea experimentului pe 100 secvențe diferite de zgomot.

	Valoare reală	Valoare medie	Abateri standard
f	1	1,0021	0,0635
A	1	1,0033	0,0342
φ	0°	-1,0310 $^\circ$	3,6903 $^\circ$

tabelul 4.1

Experimentul 1.1.

Prin acest experiment se evidențiază utilizarea matricii de date A_g pentru estimarea coeficienților de autoregresie, cu consecința reducerii volumului și timpului de calcul necesari față de experimentul 1.1.

Pe intervalul de timp $\Delta t = 0,4s$ se prelevează un număr de eșantioane $n=9$. Rata de eșantionare $f=0,05s$. Pentru estimarea coeficienților de autoregresie se utilizează matricea de date A_g , care, ceea ce indică că nu se introduc sinusoida suplimentară. Dimensiunea matricii A_g este 7×11 , rezultând un factor de condiționare $\xi = 3,9$. Sistemul de ecuații liniare supracondiționat se rezolvă prin utilizarea DVS. Coeficienții de autoregresie rezultă ca ultimă coloană a matricii V obținută din inversa matricii A_g . În tabelul 4.2 se prezintă rezultatele experimentului 1.2, adică valorile medii și abaterile standard ale estimărilor calculate prin repetarea experimentului pentru frecvențe diferite de zgomot.

	Valoare reală	Valoare medie	Abateri standard
f	1	1,0052	0,0697
A	1	1,0051	0,0362
φ	0°	-1,2030	3,9125 $^\circ$

tbl 4.2

Se constată că erorile de estimare sînt cu puțin mai mari decît cele obținute în experimentul 1.1. Avînd în vedere că diferențele valorilor medii sînt mici în comparație cu abaterile standard, rezultă că pentru compararea estimațiilor trebuie să se aibă în vedere abaterile standard care sînt foarte apropiate în cele două experimente. Se remarcă faptul că în experimentul 1.2 dimensiunea matricii de date A_{g2} este 7×2 , mult mai mică decît dimensiunea matricii A_{g1} , utilizată în experimentul 1.1. De asemenea în experimentul 1.1 este necesară aplicarea algoritmului de reducere. Rezultă, în experimentul 1.2, o simplificare a algoritmului și o reducere a timpului de calcul necesar estimării frecvenței sinusoidale, în condițiile menținerii unor erori de estimare comparabile cu cele obținute în experimentul 1.1.

Experimentul 1.3

Prin acest experiment se evidențiază posibilitatea utilizării matricii de date A_{g2} pentru estimarea coeficienților de autoregresie, cu consecințe măririi simulei la pasului de eșantionare. Se demonstrează reducerea erorilor de estimare a frecvenței sinusoidale prin mărirea simulei la pasului de eșantionare și reducerea factorului de supradeterminare. De asemenea se demonstrează reducerea volumului și deci a timpului de calcul.

Pe intervalul de timp $t = 0,48$ se prelevează un număr de eșantioane $n=9$, cu pasul de eșantionare $\Delta t = 0,05s$. Pentru estimarea coeficienților de autoregresie se utilizează matricii de date A_{g2} , cu $L=2$. Dimensiunea matricii A_{g2} este 5×2 , avînd un factor de supradeterminare $\xi_2 = 2,5$. Prin înălțarea matricii de date A_{g2} , $n=9$, se obține un factor de mărire relativă a pasului de eșantionare $\eta_2 = 2$. Sistemul de ecuații liniare supradeterminat se rezolvă prin metoda celor DVS . Coeficienții de autoregresie se obțin ca elemente ale coloanei s matricii V , obținută din DVS a matricii A_{g2} . În tabelul 4.5 se prezintă rezultatele experimentului 1.3, alături de valorile medii și abaterile stan-

dard ale estimațiilor calculate prin repetarea experimentului pentru 200 secvențe diferite de zgomot.

	Valoare reală	Valoare medie	Abatere standard
f	1	1,0100	0,0369
A	1	1,0063	0,0278
φ	0°	-1,3784°	2,4279°

Modelul 4.3

În comparație cu rezultatele experimentului 1.2, se constată că valoarea medie a estimațiilor pentru frecvență este mai deplasată în acest experiment cu 0,0038. Pe de altă parte se constată, în experimentul 1.3, o reducere cu 0,0121 a abaterii standard față de cea obținută în experimentul 1.2. Avînd în vedere că abaterea standard se reduce de aproape două ori și că este mult mai mare decît deplasarea valorii medii, rezultă că erorile de estimare se reduc considerabil. Aceasta este consecința măririi simulate, de două ori, a pasului de eșantionare, cu toate că factorul de supradeterminare s-a redus de la 3,5 la 2,5. Se remarcă faptul că în acest experiment dimensiunea matricii de date este 5×2 , mai mică decît dimensiunea matricii A_0 , 7×2 , utilizată în experimentul 1.2. Rezultă o reducere a volumului și deci a timpului de calcul necesar estimării frecvenței sinusoidale.

Experimentul 1.4

În acest experiment se evidențiază posibilitatea utilizării matricii de date A_3 pentru estimarea coeficienților de autoregresie. Se constată că efectul măririi simulate a pasului de eșantionare poate compensa cu efectul reduce-

rii supradeterminării, pentru factori de supradeterminare mici. În acest caz, rămâne avantajul privind reducerea volumului și deci a timpului de calcul necesar estimării frecvenței sinusoidale.

Pe intervalul de timp $\Delta t=0,4s$ se prelevează un număr de eșantioane $n=9$, cu pasul de eșantionare $T=0,05s$. Pentru estimarea coeficienților de autoregresie se utilizează matricea de date A_{93} , cu $m=2$. Dimensiunea matricii A_{93} este 3×9 , rezultând un factor de supradeterminare $\xi_3=1,5$. Prin utilizarea matricii de date A_{93} , $K=3$, se obține un factor de micșorare relativă a pasului de eșantionare $\eta_3=3$. Sistemul de ecuații liniare supradeterminat se rezolvă prin utilizarea DVS. Coeficienții de autoregresie rezultă ca ultimă coloană a matricii V , obținută din DVS a matricii A_{93} . În tabelul 4.4 se prezintă rezultatele experimentului 1.4, adică valorile medii și abaterile standard ale estimărilor calculate prin repetarea experimentului pentru 200 secvențe diferite de zgomot.

	Valoarea exactă	Valoare medie	Abateri standard
f	1	1,0112	0,0398
A	1	1,0068	0,0285
φ	0°	-1,4456 $^\circ$	2,4927

Tabelul 4.4

Se constată că erorile de estimare sînt comparabile cu cele obținute în experimentul 1.3 și, în consecință, sînt mult mai mici decît cele obținute în experimentul 1.2. Rezultă că mărirea simplității a pasului de eșantionare de la $\eta_2=1$, în experimentul 1.3, la $\eta_3=3$, în experimentul 1.4, și rezultă în corespunzătoare a supradeterminării

de la $\xi_2=2,5$, la $\xi_3=1,5$, cu efecte ce se compensează. Deoarece, în acest experiment, dimensiunea matricii A_{03} este 3×2 , mai mică decât dimensiunea matricii A_{02} , 5×2 , utilizată în experimentul 1.3, rezultă o reducere a volumului și deci a timpului de calcul necesar estimării frecvenței sinusoidale.

Experimentul 1.5

Prin acest experiment se evidențiază posibilitatea reducerii numărului de eșantioane prelevate pe un interval de timp constant și obținerea unor estimări comparabile, sau mai bune, prin mărirea efectivă și simuleții a pasului de eșantionare și reducerea supradeterminării.

Pe intervalul de timp $\Delta t=0,40$ se prelevează un număr de eșantioane $N=7$, cu pasul de eșantionare $\tau=0,0660$. Pentru estimarea coeficienților de autoregresie se utilizează matricea de date A_{02} , ca în 1.3. În acest caz, dimensiunea matricii A_{02} este 3×2 , rezultând un factor de supradeterminare $\xi=1,5$. Prin utilizarea matricii A_{02} se obține un pas de eșantionare simulat $\tau_s=0,132$. Sistemul de ecuații liniare supradeterminat se rezolvă prin utilizarea DVS. Coeficienții de autoregresie rezultă ca ultimă coloană a matricii V , obținută din inversa matricii de date A_{02} . În tabelul 4.5 se prezintă rezultatele experimentului 1.5, adică valorile medii și abaterile standard ale estimărilor calculate în repetarea experimentului pentru 200 secvențe de zgomot diferite.

	Valoare reală	Valoare medie	Abateri standard
f	1	1,0103	0,0399
A	1	1,0073	0,0299
φ	0°	$-1,6433^\circ$	$2,551^\circ$

Tabelul 4.5

Se constată că erorile de estimare sînt comparabile cu cele obținute în experimentele 1.3, 1.4 și sînt mult mai mici decît cele obținute în experimentul 1.2. Rezultă că mărirea numărului de pașii de eșantionare conduce la estimări mai bune, de toate că pe intervalul de timp $\Delta t = 0,4s$ se prelevează un număr de șapte eșantioane, față de nouă în experimentul 1.1, și factorul de supradeterminare scade la 1,5, de la 2,5. În plus, se obține o reducere a volumului și timpului de calcul necesar estimării frecvenței sinusoidale.

Experimentul 1.6

Prin acest experiment se evidențiază posibilitatea reducerii erorilor de estimare a frecvenței sinusoidale, prin mărirea numărului de pașii de eșantionare și mărirea numărului de eșantioane prelevate pe un interval de timp dat, fără a mai avea volumul de calcul necesar estimării coeficienților de autoregresie.

Pe intervalul de timp $\Delta t = 0,4s$ se prelevează un număr de eșantioane egal, cu pasul de eșantionare $t = 0,02s$. Pentru estimarea coeficienților de autoregresie se utilizează matricea de date A_{87} , cu $L=2$. Dimensiunea matricii A_{87} este 7×8 , rezultînd un factor de supradeterminare $\xi = 3,5$. Prin utilizarea matricii A_{87} se obține un pas de eșantionare sinusoidal de $0,14s$. Sistemul de ecuații liniare supradeterminat se rezolvă prin DVS. Coeficienții de autoregresie rezultă din ultimă coloană a matricii V , obținută din DVS a matricii de date A_{87} . În tabelul 4.6 se prezintă rezultatele experimentului 1.6, adică valorile medii și abaterea standard ale estimațiilor calculate prin repetarea experimentului pentru 200 secvențe diferite de zgomot.

	Valoare medie	Valoare medie	Abatere standard
f	1	1,0017	0,0307
A	1	0,9996	0,0194
φ	0	-0,4312°	1,716°

Tabelul 4.6

Se constată că în acest experiment se obțin cele
bune estimări pentru incertanță, atât sub aspectul valorii
medii cât și al abaterii standard, în comparație cu estimările
obținute în experimentele 1.1, ..., 1.5. Estimările per-
tru amplitudine și fază, fiind obținute în funcție de esti-
mările pentru frecvență, rezultă și ele cele mai bune.
Prin referire la experimentul 1.2, rezultă că reducerea er-
rorilor de estimare se obține prin mărirea simulată a pâr-
sului de eșantionare de 2,8 ori ($\eta_7=2,8$), menținerea constan-
tă a supradeterminării, $\xi=3,5$ și mărirea numărului de eșan-
tioane prelevate pe intervalul $\Delta t=0,4$ de la 9 la 21. Se
precizează că volumul de lucru și timpul de calcul necesar es-
timării coeficienților de autoregresie este același ca și
în experimentul 1.2 deoarece matricile de date au aceeași
dimensiune 7×2 ($\xi=3,5$).

Experimentul 1.7

Prin acest experiment se evidențiază posibilitatea re-
ducerii intervalului de timp pe care se prelevează eșantio-
nele, în condiția menținerii constante a erorilor de estima-
re. Această posibilitate rezultă din mărirea simulată a pâr-
sului de eșantionare și din mărirea numărului de eșan-
tioane fără a mări timpul de calcul necesar estimării coe-
ficienților de autoregresie.

Pe intervalul de timp $\Delta t=0,3s$ se prelevează un număr
de eșantioane $N=19$, cu pârslă de eșantionare $\lambda=0,0166$. Pentru
estimarea coeficienților de autoregresie se utilizează matri-
cea de date A_{35} , cu dimensiunea matricii A_{35} este 7×2
rezultând un factor de supradeterminare $\xi=3,5$. Prin utiliza-
rea matricii A_{35} se obține un pas de eșantionare simulat de
 $0,1s$. Sistemul de ecuații liniare supradeterminat se rezolvă
prin DVS. Coeficienții de autoregresie rezultă ca ultimă co-
loană a matricii V , obținută din DVS a matricii de date A_{35} .
În tabelul 4.7 se prezintă rezultatele experimentului 1.7,
adică valorile medii și abaterile standard ale estimărilor
calculate prin repetarea experimentului pentru 200 secvențe
diferite de zgomot.

Valoare reală		Valoare medie	Abatere standard
f	1	0,9966	0,0658
A	1	1,004	0,0208
φ	0°	-0,4766 $^\circ$	1,9671 $^\circ$

Tabelul 4.7

Se constată că erorile de estimare sînt cu puțin mai mici decît cele obținute în experimentul 1.2. Astfel, efectul reducerii intervalului de timp la 0,3s, de la 0,4s în experimentul 1.2, se compensează cu efectul măririi simulate a numărului de eșantionare. În acest experiment pasul de eșantionare simulat este 0,1s, de două ori mai mare decît pasul care a fost utilizat la construcția matricii de date în experimentul 1.2. Pentru a fi posibilă această mărire simulată a numărului de eșantionare, se prelevează 19 eșantioane pe intervalul de timp $\Delta t = 0,3s$, față de 7 eșantioane pe intervalul de timp $\Delta t = 0,4s$, în experimentul 1.2. Se precizează că timpul de calcul necesar estimării coeficienților de amplitudine și fază este același ca și în experimentul 1.2 deoarece matricile de date au aceeași dimensiune 7×2 (8 și 7).

Experimentul 4.4

În acest experiment se simulează un proces format din cinci sinusuri cu amplitudine aditiv /10/. Valorile reale ale frecvențelor, amplitudinilor și fazelor sinusoidelor sînt prezentate în tabelul 4.3. Se prelevează un număr de 71 eșantioane, cu un pas de eșantionare $\tau = 1/256s$. Intervalul de timp pe care sînt prelevate eșantioanele este $\Delta t = 0,27s$, puțin mai mare decît jumătate din perioada corespunzătoare sinusoidelor cu frecvențe cele mai mici.

	Valoare reală	Valoare medie	Abatere standard
f_1	2,00	1,92	0,20
f_2	6,00	5,91	0,06
f_3	20,00	19,99	0,12
f_4	25,00	24,99	0,09
f_5	30,00	29,99	0,08
A_1	1,50	1,44	0,08
A_2	1,25	1,24	0,04
A_3	0,375	0,38	0,01
A_4	0,625	0,62	0,01
A_5	1,25	1,25	0,01
A_1	90°	93°	9°
2	120°	120°	3°
3	150°	151°	7°
4	90°	93°	5°
5	135°	139°	1°

Tabelul 4.8

Raportul semnal-zgomot,

$$J_{hh} = 10 \log_{10} \frac{\sum_{n=0}^{N-1} \left\{ \sum_{k=1}^5 A_k \sin(2\pi f_k n T + \varphi_k) \right\}^2}{N \sigma^2}, \quad (4.4)$$

este de 31 db. Dacă σ^2 reprezintă dispersia secvenței de zgomot.

Acest proces este tratat în /10/ printr-un algoritm ce corespunde înmulțirii matricii de date A_{di} , cu dimensiunea 70×30 . Se constată introducerea unui număr mare de sinusoides suplimentare. Rezultatele publicate în /10/ sînt prezentate în tabelul 4.8. Valorile medii și abaterile standard ale amplitudinilor pentru frecvențe, amplitudini și faze sînt obținute prin repetarea experimentului pentru 20 secvențe de zgomot diferite. Se constată că erorile cele mai mari apar pentru frecvențele mici.

Experimentul 2.1

Prin acest experiment se evidențiază necesitatea măririi simulei numărului de eșantionare la estimarea numărului și frecvențelor sinusoidelor.

Se utilizează o matrice de date A_g , cu $h=21=10$, ceea ce indică că trebuie introduse sinusoides suplimentare. Dimensiunea matricii de date este 61×6 , rezultînd un factor de supradeterminare $\xi=10,16$. Se procedează la descompunerea valorilor proprii ale matricii A_g . Corespunzător unei secvențe de zgomot se obțin valorile singulare: $\sigma_1=45,1$; $\sigma_2=24,5$; $\sigma_3=3,0$; $\sigma_4=0,067$; $\sigma_5=0,023$; $\sigma_6=0,015$. Analiza valorilor singulare indică rangul trei pentru matricea de date A_g . Rezultatele sînt evidențiate doar prezența a trei sinusoides cu frecvențe ale căror valori sînt mai mari dintre cele cinci conținute de proces. Acest lucru se explică prin faptul că pe datele corespunzătoare unei linii a matricii A_g nivelul frecvențelor mici se schimbă în mod regulat. Altfel spus, raportul frecvențelor mici în eșantionare este corespunzător unei linii a matricii

A_B este aproximativ constant. In consecință estimățile pentru frecvențe rezultă cu erori foarte mari.

Din cele de mai sus rezultă necesitatea utilizării matricilor de date A_{SK} , $K > 1$, deci a măririi simulate a pasului de eșantionare. Astfel, intervalul de timp corespunzător unei linii va crește, ceea ce va determina evidențierea, prin valorile singulare, a celor cinci sinusoides și obținerea unor estimății bune pentru frecvențe.

Experimentul 2.2

Prin acest experiment se evidențiază posibilitatea estimării numărului de sinusoides, ca rang al matricii de date sumă și posibilitatea reducerii erorilor de estimare a frecvențelor sinusoidelor prin măriria simulată a pasului de eșantionare. Se remarcă că adăugarea sinusoidelor suplimentare și reducerea volumului de calcul necesar estimării frecvențelor sinusoidelor.

Pentru estimarea coeficienților de autoregresie se utilizează matricea de date A_{B4} , cu $L=10$. Dimensiunea matricii A_{B4} este 31×6 , rezultând un factor de supradeterminare $\xi=5,16$. Se procedează la descompunerea valorilor singulare a matricii A_{B4} . Pentru o evență de zgomot se obțin valorile singulare : $\sigma_1=19,1$; $\sigma_2=17,5$; $\sigma_3=8,23$; $\sigma_4=7,51$; $\sigma_5=3,5$; $\sigma_6=0,025$. Deoarece $\sigma_6 \ll \sigma_5$, rezultă că matricea A_{B4} este foarte aproape, în sens al unei spectrale sau Frobenius, de o matrice de rang egal cu al ei. Astfel, se evidențiază probabilitatea celor cinci sinusoides conținute de proces și se confirmă posibilitatea estimării numărului de sinusoides ca rang al matricii de date sumă. Coeficienții de autoregresie rezultă ca ultimă coloană a matricii obținută din DVS a matricii de date A_{B4} . In tabelul 4.3 se prezintă rezultatele experimentului 2.2, adică valorile coeficienților și abaterile standard ale estimățiilor calculate la repetarea experimentului pentru 20 secvențe diferite de zgomot.

Se constată, față de rezultatele din tabelul 4.3 și publicate în /10/, o îmbunătățire substanțială a estimății-

	Valoare reală	Valoare medie	Amplitudine standard
f_1	2,00	1,997	0,0135
f_2	6,00	6,001	0,0062
f_3	20,00	19,997	0,0115
f_4	25,00	25,001	0,0117
f_5	30,00	29,999	0,0036
A_1	1,50	1,500	0,0031
A_2	1,25	1,349	0,0024
A_3	0,375	0,375	0,0005
A_4	0,625	0,624	0,0003
A_5	1,25	1,249	0,0006
1	90°	$90,09^\circ$	$0,60^\circ$
2	120°	$119,95^\circ$	$0,22^\circ$
3	150°	$150,12^\circ$	$0,62^\circ$
4	90°	$89,92^\circ$	$0,58^\circ$
5	135°	$135,04^\circ$	$0,19^\circ$

Tabloul 4.9

lor pentru frecvențe, amplitudini și faze, atât ca valori
medii cât și ca amplitudine standard. Amplitudinile standard

estimațiilor se reduc cu și mult de un ordin, în special la frecvențele mici. Aceasta este consecința mării simulate pasului de eșantionare de patru ori. Se remarcă faptul că în experimentul 2.2, dimensiunea matricii de date A_{S4} este 35×6 , mult mai mică decât dimensiunea matricii A_{d1} (70×35), utilizată în /10/. De asemenea în acest experiment nu se introduc sinusoid suplimentare, astfel încât nu se pune problema utilizării unui algoritm de colectare a sinusoidelor odevitate. Rezultă, în experimentul 2.2, o simplificare a algoritmului și o reducere semnificativă a volumului de calcul necesar estimării frecvențelor sinusoidelor în comparație cu experimentul realizat în /10/.

Experimental

Prin acest experiment se evidențiază posibilitatea reducerii erorilor de estimare a frecvențelor sinusoidelor prin mărirea simulei pasului de eșantionare.

Pentru estimarea coeficienților de autoregresie se utilizează numai primele 71 de eșantioane din cele 71 utilizate în /10/ și în experimentul 2.2. Aceasta înseamnă o reducere a intervalului de timp Δt , pe care procedul se consideră disponibil, cu o construcție a matricii de date A_{S4} , cu $L=10$. Dimensiunea matricii de date este 13×6 , rezultând un factor de supraîncălzire $\xi=1,16$. Pentru o secvență de zgomot se obțin valorile singulare : $\sigma_1=13,7$; $\sigma_2=9,02$; $\sigma_3=4,16$; $\sigma_4=2,75$; $\sigma_5=0,0035$; $\sigma_6=0,0035$. Deoarece $\sigma_6 \ll \sigma_5$ rezultă că rangul efectiv al matricii A_{S4} este șase. Astfel valoarea celor șase sinusoidelor este determinată și rezolvă prin metoda celor șase coloane a matricii de date A_{S4} . În tabelul 4.10 se prezintă valorile medii și abaterile standard prin repetarea experimentului pentru 20 de valori diferite de zgomot.

Față de rezultatul obținut în /10/, tabelul 4.3, se constată o îmbunătățire semnificativă a estimațiilor pentru

	Valoare reală	Valoare medie	Abatere standard
f_1	2,00	1,993	0,0505
f_2	6,00	6,004	0,0234
f_3	20,00	19,991	0,0402
f_4	25,00	25,001	0,0113
f_5	20,00	30,005	0,0257
A_1	1,1	1,499	0,0070
A_2	1,1	1,247	0,0134
A_3	0,3	0,374	0,0042
A_4	0,6	0,623	0,0058
A_5	1,1	1,249	0,0019
1	90°	90,25°	2,09°
2	120°	119,81°	1,03°
3	150°	150,33°	1,52°
4	90°	89,80°	0,89°
5	135°	134,79°	0,97°

Tabloul 4.10

frecvențele mici. Aceasta este consecința mărimii simulate a pasului de calculare de patru ori, cu toate că procesul este considerat disponibil pentru eantionare și un

interval de timp Δt redus cu 25% și se prelucerează un număr de eşantioane redus, de asemenea, cu 25%. Estimările obținute în acest experiment sînt mai puțin bune decît cele obținute în experimentul 2.2, tabelul 4.9. Aceasta se explică prin reducerea intervalului de timp Δt și prin reducerea factorului de supradeterminare al sistemului de ecuații liniare cu care se estimează coeficienții de autoregresie, de la 5,16 la 2,16. Volumul de calcul necesar estimării frecvențelor sinusoidelor în acest experiment este foarte redus. Se au în vedere dimensiunile matricilor de date utilizate la estimarea frecvențelor: A_{14} de dimensiune 70×36 în /lo., A_{14} de dimensiune 31×8 în experimentul 2.2 și A_{14} de dimensiune 13×6 în experimentul 2.3.

Experimentul 2.4.

Prin acest experiment se evidențiază posibilitatea estimării numărului de sinusoides ca rang efectiv al matricii de date sumă prin utilizarea DVS. De asemenea se evidențiază fenomenul de despicare a rădănilor speciale în cazul utilizării sinusoidelor suplimentare.

Se utilizează matricea de date A_{14} , cu $p=14$, ceea ce indică prezența a două sinusoides suplimentare. Pentru secvența de date compusă din 14 eşantioane rezultă matricea A_{14} de dimensiune 19×8 , cu factorul de supradeterminare $\xi=1,17$. Corespunzător unei secvențe de zgomot se obțin valorile singulare: $\xi_1=15,4$; $\xi_2=13,4$; $\xi_3=1,10$; $\xi_4=2,60$; $\xi_5=1,00$; $\xi_6=0,016$; $\xi_7=0,097$; $\xi_8=0,035$. Deoarece $\xi_6 \ll \xi_5$, rezultă că valorile singulare indică prezența a cinci sinusoides și deci se susține experimental posibilitatea estimării numărului de sinusoides ca rang efectiv al matricii de date sumă prin utilizarea DVS. Coeficienții de autoregresie se iau ca ultimă coloană a matricii V rezultată din DVS a matricii de date. Experimentul se repetă pentru secvențe diferite de zgomot. În tabelul 4.11 se prezintă frecvențele obținute pentru două realizări semnificative ale experimentului.

Se constată că în realizarea 1^o a experimentului se obțin estimări foarte bune pentru frecvențele sinusoidelor

	f_1	f_2	f_3	f_4	f_5	f_6	f_7
1°	1,9971	6,0003	12,232	14,072	20,002	25,0002	30,0003
2°	2,0451	5,2829	10,2829	17,765	20,002	25,004	30,0005

tabelul 4.11

adevărate, care pot fi identificate ușor în tabelul 4.11. În realizarea 2°, se constată prezența fenomenului de despărțire a liniilor spectrale. Astfel puterea sinusoidalei cu frecvență 6,0003 este împărțită între componentele cu frecvențele 5,2829 și 6,2829. Oricare dintre acestea reprezintă o estimare de precizie mare a frecvenței sinusoidalei.

În cele ce urmează se va prezenta aportul experimentelor prezentate în susținerea contribuțiilor originale ale lucrării. Astfel, estimarea numărului de sinusoidale de rang efectiv al matricii de date sunt rezultate din analiza valorilor singulare, este evidentă și prin experimentele 2.2, 2.3 și 2.4. Intervalul de timp corespunzător unei linii a matricii de date este foarte scurt în raport cu perioada frecvenței mici, aportul acestora în ecantioanele unei linii a matricii este aproximativ constant. În consecință valorile mici ale indicelui nu indică prezența frecvențelor mari, ceea ce este constatat în experimentul 2.1. În acest caz este necesară utilizarea matricilor de date cu o rezoluție simulată a pasului de eșantionare, rezultând o creștere a intervalului de timp corespunzător unei linii a matricii de date. Astfel, se obțin estimări corecte pentru numărul de sinusoidale, ceea ce este confirmat prin experimentele 2.2, 2.3 și 2.4.

Estimarea coeficienților de autoregresie ca spațiu liniar generat prin metodele coloane ale matricii V , rezultată din DVS a fost realizată pe baza de date directe-inverse, ceea ce evi-

dentiată prin experimentul 1.1. Deoarece în acest experiment este introdusă o sinusoidă suplimentară, se utilizează algoritmul de reducere care permite separarea sinusoidelor adevărate.

Utilizarea matricelor de date sumă și a DVS, pentru estimarea coeficienților de autoregresie este susținută prin experimentul 1.2. Astfel, se obțin erori de estimare comparabile cu cele din experimentul 1.1, bazat pe matricea de date directe-inverse, cu avantajul reducerii considerabile a volumului de calcul.

Concluzia, rezultată din analiza teoretică a erorilor de estimare a frecvențelor sinusoidelor, conform căreia erorile de estimare sînt cu atât mai mari cu cît frecvențele sinusoidelor sînt mai mici în raport cu frecvența de eșantionare, este susținută prin rezultatele publicate în /10/ (tabelul 4.8), precum și prin experimentele 2.2 (tabelul 4.9) și 2.3 (tabelul 4.10).

Utilizarea matricelor de date sumă cu mărire simulată a pasului de eșantionare pentru estimarea coeficienților de autoregresie este susținută prin experimentele 1.3, ..., 1.7, 2.1, 2.3 și 2.4.

Reducerea erorii de estimare a frecvențelor sinusoidelor și a volumului de calcul prin mărirea simulată a pasului de eșantionare și evitarea supradeterminării este susținută prin experimentele 1.3, 1.4, 2.2 și 2.3. Aceasta se obține în condiția menținerii constante a numărului de eșantioane prelevate pe un interval de timp dat, pe care procesul se consideră disponibil. Astfel, prin utilizarea matricelor de date A_{B2} și A_{B3} , în experimentul 1.3 și respectiv 1.4, se obține o reducere a abaterii standard a estimărilor pentru frecvență de aproape două ori față de experimentul 1.2, în care se utilizează matricea A_{B1} . Reducerea volumului și deci a timpului de calcul necesar estimării coeficienților de autoregresie este datorată reducerii dimensiunilor matricilor de date: A_{B1} (7×2), A_{B2} (5×2) și A_{B3} (3×2). Prin utilizarea matricelor A_{B2} , în experimentul 2.2 cu un

proces format din cinci sinusoides, se obține o îmbunătățire substanțială a estimațiilor pentru frecvențe față de rezultatele publicate în /10/. Abaterile standard se reduc cu mai mult de un ordin, în special la frecvențele mici. Pentru a sublinia importanța mărimii simulate a pasului de eșantionare se consideră experimentul 2.3 în care se furnează matricea A_{g4} num 1 cu primele 75% din eșantioanele utilizate în experimentul 2.2 și în /10/. Și în aceste condiții se obține o scădere substanțială a erorilor de estimare față de rezultatele publicate în /10/, în special pentru frecvențele mici. Reducerea volumului de calcul necesar estimării coeficienților de autoregresie este dată de dimensiunile matricii de date A_{d1} (70 x 36) în /10/, A_{g4} (31 x 6) în experimentul 2.2 și A_{g4} (13 x 6) în experimentul 2.3.

Eliminarea necesității introducerii sinusoidelor suplimentare este susținută prin rezultatele experimentelor 2.2 și 2.3 în comparație cu rezultatele publicate în /10/. Lărirea simulate a pasului de eșantionare conduce la mărirea intervalului de timp corespunzător eșantioanelor ce compun o linie a matricii de date, efect ce se constată și în cazul introducerii sinusoidelor suplimentare. Astfel, în experimentele ... 2.3 nu se introduc sinusoides suplimentare și se obțin estimații mult mai bune față de cele publicate în /10/, unde se introduce un număr mare de sinusoides suplimentare. Eliminarea sinusoidelor suplimentare conduce la o simplificare a algoritmului de calcul deoarece nu mai este necesară selecția sinusoidelor adevărate. În plus se elimină posibilitatea apariției efectului de despicare a liniilor de date, efect evidențiat în experimentul 2.4.

Posibilitatea reducerii numărului de eșantioane și menținerea constantă sau reducerea erorilor de estimare, prin mărirea simulată a pasului de eșantionare și reducerea supradeterminării, este susținută prin experimentul 2.5. Eșantioanele în număr redus sînt preluate pe aceeași inter-

val de timp pe care procesul se consideră disponibil. În experimentul 1.5 se utilizează un număr de șapte eșantioane și matricea de date A_{S2} , obținându-se o reducere a abaterii standard a estimațiilor pentru frecvență cu peste 40% mai mică decât cea obținută în experimentul 1.2, unde se utilizează un număr de 9 eșantioane și matricea $A_S = A_{S1}$. În plus se obține o reducere a volumului de calcul ceea ce constată din dimensiunile matricilor de date A_{S2} (3×2) în experimentul 1.5 respectiv A_{S1} (7×2) în experimentul 1.2.

Reducerea erorii de estimare a frecvențelor sinusoidelor prin mărirea similitudinii pasului de eșantionare, mărirea numărului de eșantioane și menținerea constantă a supradeterminării, este susținută prin experimentul 1.6. Eșantioanele în număr mărit sînt preluate pe același interval de timp pe care procesul se consideră disponibil. Astfel prin prelevarea unui număr de 21 eșantioane și utilizarea matricei de date A_{S7} se obțin cele mai bune estimații pentru sinusoida considerată în experimentul 1, atât ca valoare medie cît și ca abatere standard (tabelul 4.6). Se precizează că volumul de calcul necesar estimării coeficienților de autoregresie este același ca și în experimentul 1.2 și rezultă din menținerea constantă a supradeterminării.

Posibilitatea reducerii intervalului de timp pe care se prelevează eșantioanele în condiția menținerii constante a erorilor de estimare, prin mărirea similitudinii pasului de eșantionare, mărirea numărului de eșantioane și menținerea constantă a supradeterminării, este susținută prin experimentul 1.7. Astfel, prin utilizarea matricei de date A_{S6} construită cu un număr de 19 eșantioane preluate pe un interval de timp redus cu 25% față de cel corespunzător experimentului 1.2, în care se utilizează matricea $A_S = A_{S1}$ construită cu 9 eșantioane, se obțin erori de estimare cu puțin mai mici decât cele obținute în experimentul 1.2. Se precizează că volumul de calcul necesar estimării coeficienților de autoregresie este același ca și în experimentul 1.2 și rezultă din menținerea constantă a supradeterminării.

5. C O N C L U Z I I

Problema prezentată în lucrarea de față se referă la metoda de analiză spectrală a semnalelor bazată pe modelul Prony de estimare a liniilor spectrale. Conform acestui model, un semnal reprezintă în domeniul frecvențelor o sumă de sinusoidale care nu se impune corelarea canonică. Astfel, pentru un semnal dat printr-o secvență de date $\{y_n\}$, $n=1,2,\dots,N$, se pune problema estimării numărului de sinusoidale, a frecvențelor, amplitudinilor și fazelor acestora. Estimarea frecvențelor sinusoidelor se face printr-o procedură în două etape, care se bazează pe faptul că un proces format din sinusoidale este un proces autoregresiv cu coeficienți de autoregresie simetrici ale căror valori depind de frecvențele sinusoidelor și nu depind de amplitudinile și fazele lor. Astfel, în prima etapă, se estimează coeficienții de autoregresie prin corelarea modelului autoregresiv cu secvența de date. În a doua etapă se determină frecvențele sinusoidelor în funcție de coeficienții de autoregresie. Estimarea amplitudinilor și fazelor se face în funcție de frecvențele sinusoidelor și de secvența de date.

Contribuția lucrării de față se referă la estimarea numărului și a frecvențelor sinusoidelor. În cele ce urmează se prezintă conținutul lucrării și concluziile rezultate din ele.

1. Avînd în vedere că un proces format din sinusoidale este un proces autoregresiv cu coeficienți de autoregresie simetrici, se construiește matricea de date sumă. Se face această matrice în funcție de un număr de coeficienți de autoregresie reținuți în funcție de matrișă și datele date, în-

verse sau direct-inverse, se creează premise reducerii volumului de calcul necesar estimării numărului și frecvențelor sinusoidelor.

2. Se demonstrează în lucrarea de față, că rangul matricii de date sumă, corespunzătoare unui proces format din sinusoidă, este egal cu numărul de sinusoidă. Astfel, numărul de sinusoidă cu care se modelază un proces, se estimează cu rang efectiv al matricii de date sumă. Rangul efectiv se obține din analiza valorilor singulare rezultate din DVS a matricii de date sumă, singulare fiind o metodă generală de încredere pentru determinarea numerică a rangului unei matrici în prezența perturbărilor și a erorilor de calcul. Se arată, în lucrarea de față, că valorile singulare indică și posibilitatea corelării de un procesul analizat.

3. Pentru estimarea coeficienților de autoregresie se utilizează matricea de date sumă care permite reducerea volumului de calcul necesar pentru estimare, prin reducerea la jumătate a numărului de coeficienți de autoregresie, față de cazul utilizării matricilor de date directe, inverse sau direct-inverse.

4. Rezolvarea sistemului de ecuații liniare supradeterminat pentru estimarea coeficienților de autoregresie se face prin utilizarea de la determinarea valorilor singulare. Se propune, în lucrarea de față, estimarea coeficienților de autoregresie, pentru procesul analizat ca o sumă de sinusoidă, ca spațiu liniar nul generat de ultimele coloane ale matricii V , rezultată din DVS a matricii de date. Se apreciază /21/ că utilizarea DVS la soluționarea sistemelor de ecuații liniare supradeterminate este avantajosă în condițiile existenței perturbărilor și a erorilor de calcul.

5. În cazul utilizării sinusoidelor suplimentare se propune utilizarea algoritmului de reducere pentru identificarea sinusoidelor adevărate. Algoritmul este aplicabil în cazul utilizării matricilor de date directe, inverse, sau direct-inverse.

6. În lucrarea de față s-a analizat erorile de estimare a frecvențelor sinusoidelor corespunzătoare celor două etape de calcul. Din analiza teoretică rezultă că erori de estimare mari apar pentru frecvențele mult mai mici decât frecvențele de eșantionare, fapt constatat experimental în bibliografie precum și în experimentele efectuate în prezenta lucrare. Se obține, astfel, concluzia privind necesitatea măririi pasului de eșantionare.

7. Se definește, prin prezenta lucrare, matricile de date cu mărire simulată a pasului de eșantionare. Aceste matrici se construiesc pe baza aceleiași secvențe de date ca și matricile de date precizate anterior. Mărirea simulată a pasului de eșantionare rezultă din aranjarea eșantionelor în liniile matricii, nu în ordine consecutivă, ci din K în K , unde $K=2,3,\dots$. Această definiție a matricilor de date este o definiție generală, deoarece pentru $K=1$ se obțin matricile de date precizate anterior.

8. Utilizarea matricilor de date cu mărirea simulată a pasului de eșantionare conduce la mărirea intervalului de timp corespunzător eșantionelor ce intervin într-o linie a matricii de date. Se constată, în această lucrare, că mărirea acestui interval de timp se obține și în cazul introducerii sinusoidelor suplimentare, dar cu prețul măririi volumului de calcul, deoarece se estimează un număr mai mare de coeficienți de dezvoltare și cu prețul complicării algoritmului de calcul, deoarece este necesară identificarea sinusoidelor adevărate. Mărirea intervalului de timp corespunzător unei linii a matricii de date conduce la reducerea substanțială a erorii de estimare a numărului și a frecvențelor sinusoidelor.

9. Utilizarea eșantionelor secvenței de date în matricile cu mărire simulată a pasului de eșantionare este mai uniformă, în sensul că se tinde ca, la mărirea lui K , fiecare eșantion să fie totuși o singură dată în matrice. Acest fapt conduce la simplificarea și optimizarea algoritmului de calcul și la obținerea rezultatelor prin utilizarea matricilor de date cu mărirea pasului de eșantionare.

10. Se arată, în lucrarea de față, că utilizarea matricilor de date sumă cu abstracția simulată a pasului de egantionare conduce la reducerea erorilor de estimare a numărului de sinusoidale conținute de un proces. Numărul de sinusoidale se estimează ca rang efectiv al acestor matrici de date. Rangul efectiv rezultă din analiza valorilor singulare.

11. Având în vedere că mărirea simulată a pasului de egantionare și introducerea sinusoidelor suplimentare au același efect de mărire a intervalului de timp corespunzător unei linii a matricii de date, se afirmă și se demonstrează experimental eliminarea necesității introducerii sinusoidelor suplimentare. Se obține, astfel, reducerea volumului de calcul, simplificarea algoritmului de estimare a frecvențelor sinusoidelor și eliminarea posibilității de apariție a fenomenului de despăcare a liniilor spectrale.

12. Se analizează teoretic și se demonstrează experimental reducerea erorilor de estimare a frecvențelor sinusoidelor și a volumului de calcul prin mărirea simulată a pasului de egantionare și reducerea supradeterminării sistemului de ecuații liniare. Acestea se obține în condiția menținerii constante a numărului de ecuații prelevate pe un interval de timp dat, pe care procesul îl consideră disponibil. Pentru factori de supradeterminare mici, efectul reducerii supradeterminării poate compensa efectul mării simulată a pasului de egantionare. În acest caz, rămâne avantajul privind reducerea volumului și deci a timpului de calcul necesar estimării frecvențelor sinusoidelor.

Astfel, în experimentul referitor la un proces corelat pozitiv, prin mărirea simulată a pasului de egantionare, se obține o reducere a erorilor de estimare a frecvențelor sinusoidelor de un ordin de mărire de cel puțin două ori mai mare decât în cazul acelui experiment în /10/. Dimensiunile matricilor de date care generează sistemele de ecuații liniare supradeterminate sunt 31×6 în experimentul /11/ și 70×36 în /10/.

13. Se afirmă și se demonstrează experimental posibilitatea reducerii numărului de ecuații prelevate și menținerea constantă

tă sau reducerea erorilor de estimare, prin mărirea simulată a pasului de eșantionare și reducerea supradeterminării. În acest caz, apare și o mărire efectivă a pasului de eșantionare deoarece se prelevează mai puține eșantioane pe un interval de timp dat.

14. Se demonstrează că, în condiția obținerii unui sistem de ecuații liniare cu factori de supradeterminare dat, este posibilă mărirea simulată a pasului de eșantionare, prin mărirea numărului de eșantioane prelevate pe un interval de timp dat. Se arată în [1] că un pas de eșantionare mic nu este util deoarece este compus din eșantioane consecutive tinde să devină egal cu vectorul constant $(1, 1, \dots, 1)^T$. Deoarece la formarea listelor de matricilor cu mărirea simulată a pasului de eșantionare, eșantioanele nu sînt luate unul după celălalt ci din K în K , întrucît acest dezavantaj este eliminat. În prezenta lucrare se afirmă și se demonstrează că, prelevarea unui număr mai mare de eșantioane pe un interval de timp dat, deci mărirea unui pas de eșantionare cît mai mic, poate conduce la obținerea unor estimări mai bune pentru frecvențele sinusoidelor, numai prin mărirea simulată a pasului de eșantionare. Deoarece supradeterminarea este constantă rezultă dintr-o alegere voluntară de calcul necesar estimării frecvențelor sinusoidelor.

15. Din considerații teoretice și din rezultate experimentale se arată, în lucrarea de față, că este posibilă reducerea intervalului de timp pe care se prelevează eșantioanele cu menținerea constantă a erorilor de estimare. Erori de estimare constante se obțin prin impunerea unei supradeterminări constante și prin compensarea efectului reducerii intervalului de timp cu efectul mării simulată a pasului de eșantionare. Pentru aceasta este necesară mărirea numărului de eșantioane. Deoarece supradeterminarea este constantă rezultă dintr-o alegere voluntară de calcul necesar estimării frecvențelor sinusoidelor. Astfel, în experimentul 1.7 referitor la un proces generat din o sinusoidă în zgomot aditiv, prin mărirea simulată a pasului de eșantionare, se obține o

reducere cu 25% a intervalului de timp pe care se prelevează eşantioanele, în condiția menținerii constante a erorilor de estimare a frecvenței sinusoidale.

Toate contribuțiile lucrării sînt susținute prin rezultate experimentale prezentate în capitolul 4.

Contribuția centrală a lucrării constă în definierea și în reducerea matricilor de date cu mărire simulată a pasului de eşantionare. Prin aceasta se mărește intervalul de timp corespunzător eşantionării și compun o linie a matricii de date. Se constată, prin analiza lucrării, că mărirea acestui interval de timp se obține și prin introducerea rădăcinilor suplimentare în polinomul caracteristic cu care se estimează coeficienții de autoregresie. Mărirea simulată a pasului de eşantionare, ca și introducerea rădăcinilor suplimentare se face cu prețul reducerii supradeterminării sistemului de ecuații liniare, cu care se estimează coeficienții de autoregresie. În cazul introducerii rădăcinilor suplimentare rezultă, în plus, o mărire a volumului de calcul necesar estimării, deoarece numărul coeficienților de autoregresie este mai mare și o complicare a algoritmului, deoarece este necesară separarea rădăcinilor adevărate ale polinomului caracteristic. Se afirmă în literatură [21/, [22/, [68/, [69/, [94/, [62/, [41/, pe baza experimentală, că introducerea rădăcinilor suplimentare conduce la reducerea erorilor de estimare a coeficienților de autoregresie. Rezultă deci o posibilă reducere a erorilor de estimare este de așteptat în cazul utilizării matricilor de date cu mărire simulată a pasului de eşantionare. Se remarcă, de asemenea, că distribuția evenimentelor de apariție a eşantionelor în matricile de date cu mărirea simulată a pasului de eşantionare tinde să se uniformizeze. Astfel, pentru K coeficient de mare fiecare ecuație este utilizată o singură dată în matrice. Acest fapt conduce la o uniformizare a ponderii eşantionelor de compunerea de date în estimațiile pentru coeficienții de autoregresie.

Considerentele prezentate mai sus se referă la utilizarea matricilor de date cu mărirea simulată a pasului de eşan-

tionare în cazul general al estimării coeficienților de autoregresie.


Utilizarea, în lucrarea de față, a matricii de date sumă cu mărire simulată a pasului de eșantionare la estimarea liniilor spectrale conduce la reducerea considerabilă a erorilor de estimare a frecvențelor sinusoidelor simultan cu reducerea volumului de calcul și simplificarea algoritmului.

Rezultă că, în cercetări viitoare pot evidenția utilitatea matricilor de date cu mărire simulată a pasului de eșantionare la reducerea erorilor de estimare și a volumului de calcul, în cazul general al estimării coeficienților de autoregresie și în particular la estimarea parametrilor modelului format din sinusoidă atenuate exponențial. Acest model este utilizat în metoda de estimare a densității spectrale de energie.

BIBLIOGRAFIE

1. R. Bellman, Introducere în analiza matriceală. Editura Tehnică, București, 1967.
2. P. Bloomfield, Fourier Analysis of Time Series : An Introduction. New York, Wiley, 1976.
3. G.E.P.Box and G.M.Jenkins, Time Series Analysis. Forecasting and Control. San Francisco, CA: Holden-Day, 1970.
4. D.R.Brillinger, The effects of tapering in spectrum estimation, Trans.Acoust., Speech, Signal Processing, vol.ASSP-29, pp.1077-1081, Oct.1981.
5. C.L.Bucur, C.A.Popescu, Gh.Șinjon, Matematici speciale. Calculul numeric. Editura didactică și pedagogică, București, 1983.
6. Gh.Cartianu, Analiza și sinteza circuitelor electrice, Editura didactică și științifică, București, 1971.
7. Y.T.Chen, J.H.L.Love, and J.B.Plant, A parameter estimation approach to the estimation of frequencies of sinusoids, IEEE Trans. Acoust., Speech, Signal Processing, vol.ASSP-29, pp.214-219, Apr.1981.
8. G.Ciucu, U.Craiu, Tehnica estimăției și verificarea ipotezelor statistice, Editura didactică și pedagogică, 1968.
9. T.van Eck, Periodicities in short-time series : frequency, amplitude and initial phase determinations, Report nr.3-10, Seismological Section, Cornell University, Ithaca, 1930.
10. T. van Eck, Quantitative determination of periodicities from short time series, Trans.Acoust., Speech, Signal Processing, vol.ASSP-29, pp.329-331, Apr.1981.

11. D.C.Farden, Solution of a Toeplitz set of linear equation, *IEEE Trans. Antennas Propagat.*, vol.AP-24, pp.906-908, Nov.1976.
12. G.E.Forsythe, A.L.Malcolm, and C.B.Moler, *Computer Methods for Mathematical Computations*. Englewood Cliffs, N.J.: Prentice-Hall, 1977.
13. St.Gârleşu, *Prelegerarea în timp real a semnalelor fizice*, *Scrişul Românesc*, Craiova, 1978.
14. S.Gârleşu, C.Fogg, S.Ionel, *Introducere în analiză spectrală şi de corelaţie*. Edit.Facla, Timişoara, 1981.
15. W.Gersch and J.Yonemoto, Automatic classification of EEG's: A parametric model new features for classification approach, in *Proc. 1977 Joint Automatic Control Conf.*, pp.762-769, June 1977.
16. B.Gold and C.M.Rader, *Digital Processing of Signals*, McGraw Hill, New York, 1969.
17. G.H.Golub and C.Reinsch, Singular value decomposition and least squares solution, *Numer.Math.*, vol.14, pp.403-420, 1970.
18. L.J.Griffiths and R.Prieto-Diaz, Spectral analysis of natural seismic events using autoregressive techniques, *IEEE Trans. Science Electronics*, vol.GE-15, pp:13-25, Jan.1977.
19. F.J.Harris, On the use of windows for harmonic analysis with the discrete Fourier transform, *Proc.IEEE*, vol.66, pp.51-83, Jan.1973.
20. S.S.Haykin, ed., *Nonlinear Methods of Spectral Analysis*, New York, Springer-Verlag, 1979.
21. T.L.Henderson, Geometric methods for determining system poles from transient response, *IEEE Trans.Acoust., Speech, Signal Processing*, vol.ASSP-29, pp.982-983, Oct.1981.
22. B.K.Hung and H.Merring, Simulation experiments to compare the signal detection properties of DFT and ML spectra", *IEEE Trans.Acoust., Speech, Signal Processing*, vol.ASSP-29, pp.1034-1039, Oct.1981.



23. G.M.Jenkins and D.G.Watts, Spectral Analysis and Its Applications. San Francisco, CA: Holden-Day, 1968.
24. S.M.Key, S.L.Larple, Jr., Spectrum analysis - a modern perspective, Proceedings of the IEEE, vol.69, pp.1380-1419, Nov.1981.
25. V.C.Klemm and A.J.Mann, The singular value decomposition: Its computation and some applications, IEEE Trans. Automat.Contr., vol.AC-29, pp.164-176, Apr.1980.
26. K.Konstantinides and S.Luo, Applications of singular value decomposition to system modeling in signal processing, IEEE Int.Conf.Acoustics, Speech and Signal Processing, 1983.
27. L.H.Koopmans, The Spectral Analysis of Time Series. Academic Press, New York and London, 1974.
28. R.Kumaresan and D.B.Tufts, Estimating the parameters of exponentially damped sinusoids and pole-zero modeling in noise, IEEE Trans.Acoust., Speech, Signal Processing, vol.ASSP-30, pp.833-848, Dec.1982.
29. R.Kumaresan, On the zeros of the linear prediction-error filter for deterministic signals, IEEE Trans.Acoust., Speech, Signal Processing, vol.ASSP 31, pp.217-220, Feb. 1983,
30. P.Lancaster, Theory of Matrices. Academic, 1969.
31. T.E.Landers and K.L.Dobson, Some geophysical application of autoregressive spectral estimates, IEEE Trans.Geoscience Electronics, vol.GE-15, pp.26-32, Jan.1977.
32. J.W.Lang and J.H. McClellan, Frequency estimation with maximum entropy spectral estimators, IEEE Trans.Acoust., Speech, Signal Processing, vol.ASSP-28, pp.716-724, Dec. 1980.
33. C.L.Lawson and R.J.Hanson, Solving Least-Squares Problems. Englewood Cliffs, NJ: Prentice-Hall, 1974.
34. A.Leonte, C.Vrasiu, Elemente de calcul matriceal cu aplicații. Editura Tehnică, București, 1975.

35. S.Levy, C.Walker, I.J.Ulrych and P.K.Fullager,
A linear programming approach to the estimation of
the power spectra of harmonic processes, Trans.Acoust.,
Speech, Signal Processing, vol. ASSP-30, pp.675-679,
Aug.1982.
36. J.Lakhoul, Linear prediction: A tutorial review, Proc.
IEEE, vol.63, pp.561-580, 1975.
37. J.Lakhoul, Spectral Linear Prediction: Properties and
Applications, IEEE Trans. on Acoust., Speech, Signal
Processing, vol. ASSP-23, pp. 283-296, June 1975.
38. S.L.Marple, Jr., Conventional Fourier, autoregressive,
and special linear methods, of spectrum analysis, Engi-
neer's Dissertation, Stanford Univ., Stanford, CA,
Dep.elec.Eng., Dec.1976.
39. S.L.Marple, Jr., Spectral line analysis via a fast
Prony algorithm, 1982, IEEE.
40. S.L.Marple, Jr., Fast algorithms for linear prediction
and system identification filters with linear phase,
IEEE Trans.Acoust., Speech, Signal Processing, vol.
ASSP-30, pp.942-953, Dec.1982.
41. S.L.Marple, Jr., A fast algorithm for and performance
of the Kung-Huang-Prony method of spectrum analysis,
IEEE Int.Conv.Acoustics, Speech and Signal Processing,
1983.
42. Gh.Lihoc, G.Grigu, Tratat de statistica matematica, Se-
lectie si aplicatii. Vol.1, Edit.Academiei R.S.R., Bu-
curesti, 1974.
43. Gh.Lihoc, G.Grigu, Tratat de statistica matematica.
Vol.IV. Correlatie si regresie liniara. Editura Academiei
RSR, 1981.
44. Ed.Nicolean, M.Popovici, Introducere in cibernetica sis-
temelor hibride. Editura tehnica, Bucuresti 1985.

45. A.H.Nuttall, Some windows with very good sidelobe behavior, *IEEE Trans.Acoust., Speech, Signal Process.*, vol.ASSP-29, pp.84-89, Feb.1981.
46. A.V.Oppenheim and A.W.Schafer, *Signal Processing*. Englewood Cliffs, NJ: Prentice-Hall, 1975.
47. R.K.Otnes and L.Ebenezer, *Digital Time Series Analysis*. New York: Wiley, 1972.
48. A.Papoulis, *The Fourier Integral and its Applications*, McGraw-Hill Book Company, 1962.
49. A.Papoulis, *Probability, Random Variables, and Stochastic Processes*. New York: McGraw-Hill, 1965.
50. A.Papoulis, *Signal Analysis*. New York, McGraw-Hill, 1977.
51. A.Papoulis, Maximum entropy and spectral estimation: A Review, *Trans.Acoust., Speech, Signal Processing*, vol. ASSP-29, pp.1176-1181, Dec.1981.
52. Gh.Pic, *Algebră superioară*. Editura didactică și pedagogică, București, 1966.
53. V.F.Pisarenko, The retrieval of harmonics from a covariance function, *Geophysical J.Royal Astronomical Soc.*, vol.33, pp.247-266, 1972.
54. A.J.Poggio, M.L.Vannelli, B.K.Miller, and K.Littre, Evaluation of a procedure technique for transient data, *IEEE Trans.Antennas Propagat.*, vol.AP-26, pp.165-173, 1978.
55. B.Pop, V.Stoica, *Principii și metode de măsurare numerică*, Editura Facultății, 1977.
56. Rabiner L.R. and B.Gold, *Theory and Application of Digital Signal Processing*, Prentice Hall Inc., Englewood Cliffs, New Jersey, 1975.
57. A.P.Sage and J.L.Melsa, *Estimation Theory with Application to Communication and control*. New York, McGraw-Hill, 1972.

58. x x x , SIFAC. Sistem de programe pentru identificarea și proiectarea asistată de calculator a sistemelor automate. Manual de prezentare și utilizare. Institutul Central pentru Conducere și Informatică. Direcția de cercetare. Laboratorul calculatoare de proces. 1980.
59. A.I.Spătaru, Teoria transmisiunii informației, cartura didactică și pedagogică, București, 1983.
60. D.Stanoliș, G.Stanșilă, Metoda matematică în teoria semnalelor, cartura tehnică, București, 1980.
61. S.D.Stearns, Digital Signal Analysis. Hayden Book Company, Inc., New Jersey, 1971.
62. K.Steiglitz, On the simultaneous estimation of poles and zeros in speech analysis, IEEE Trans.Acoust., Speech, Signal Processing, vol.ASSP-25, pp.229-234, 1977.
63. G.W.Stewart, Introduction to Matrix Computations. New York: Academic, 1973.
64. G.W.Stewart, On the perturbation of pseudoinverses, projections and linear least squares problems, SIAM Rev., vol.19, no.4, pp.634-662, 1977.
65. G.Stolojan, V. Odaru, F.Cetină, Prelucrarea numerică a semnalelor audio, Editura Militară, București, 1984.
66. V.Tiponut, Studii privind aplicarea egantionării la aparatele de sunet. Teză de doctorat. 1981.
67. L.Toma, Metode optimizate de analiză spectrală. Referat 1983.
68. D.W.Tufts and P.Nussli, Singular value decomposition and improved frequency estimation using linear prediction, IEEE Trans.Acoust., Speech, Signal Processing, vol.ASSP-30, pp.671-675, Aug.1982.
69. T.J.Ulrych and R.W.Clayton, Time series modelling and maximum entropy, Phys.Learth and Planetary Interiors, vol.12, pp.131-140, Aug.1976.

70. C.Van, Schooneveld and D.J.Frijling, Spectral Analysis: On the usefulness of tapering for leakage suppression, Trans.Acoust., Speech, Signal Processing, vol.ASSP-29, pp.323-329, Apr.1981.
71. J.L.Zolesio, J.L.Besonnec, Transformee de Fourier Discrète en Radar Doppler, Laboratoire Central de Télécommunications, Velizy-Villacoublay, novembre, 1979.

CONTINUT

	pag.
1. INTRODUCERE	1
2. ESTIMAREA PARAMETRILOR OPTIMALE	6
2.1. Modelarea autoregresivă a secvențelor de date corespunzătoare semnalelor sinusoidale	9
2.1.1. Modelul autoregresiv	10
2.1.2. Modelul autoregresiv simetric. Matricea de date de	12
2.2. Determinarea frecvenței, amplitudinilor și fazelor sinusoidelor	15
2.3. Estimarea numărului de sinusoidale	19
2.4. Estimarea coeficienților de autoregresie	23
2.4.1. Estimarea coeficienților de autoregresie în funcție de secvența de autocorelație	24
2.4.2. Estimarea coeficienților de autoregresie în funcție de secvența de date	29
3. METODA OPTIMIZĂRII ÎN ESTIMAREA PARAMETRILOR SPECTRALE	44
3.1. Erorile de estimare a frecvențelor sinusoidelor	46
3.2. Reducerea erorilor de estimare a frecvențelor sinusoidelor prin mărirea simulată a pasului de eșantionare și reducerea supra-determinării sistemului pe care se estimează coeficienții de autoregresie	50
3.3. Reducerea erorilor de estimare a frecvențelor sinusoidelor prin mărirea simulată a pasului de eșantionare și mărirea numărului de eșantioane	57
3.4. Reducerea erorilor de estimare a frecvențelor sinusoidelor prin mărirea simulată a pasului de eșantionare și mărirea numărului de eșan- tioane	63
4. REZULTATE NUMERICE	70
5. CONCLUZII	93
BIBLIOGRAFIE	100