



(12)

## CERERE DE BREVET DE INVENTIE

(21) Nr. cerere: **a 2017 00416**

(22) Data de depozit: **23/06/2017**

(41) Data publicării cererii:  
**28/12/2018** BOPI nr. **12/2018**

(71) Solicitant:

- INSTITUTUL NATIONAL DE CERCETARE-DEZVOLTARE PENTRU MECATRONICĂ ȘI TEHNICA MĂSURĂRII - INCMDTM BUCUREȘTI, ȘOS.PANTELIMON NR.6-8, SECTOR 2, BUCUREȘTI, B, RO;
- INSTITUTUL NAȚIONAL DE CERCETARE-DEZVOLTARE ÎN INFORMATICĂ, BD.MAREȘAL AVERESCU NR.8-10, SECTOR 1, BUCUREȘTI, B, RO

(72) Inventatori:

- POPESCU THEODOR DAN, ȘOS.COLENTINA NR.55, BL.83, SC.1, ET.6, AP.29, SECTOR 2, BUCUREȘTI, B, RO;

• MANOLESCU MARIANE VEORONICA, ȘOS.COLENTINA NR.24, BL.10, SC.1, ET. 9, AP.64, SECTOR 2, BUCUREȘTI, B, RO;

• CIOBOATA DANIELA DOINA, ȘOS. ȘTEFAN CEL MARE NR.35, BL.31, SC.3, ET.2, AP.85, SECTOR 2, BUCUREȘTI, B, RO;

• STANCIU DĂNUȚ IULIAN, ȘOS. FUNDENI NR. 237, BL. 112, SC. C, ET. 7, AP. 117, SECTOR 2, BUCUREȘTI, B, RO

Această publicație include și modificările descrierii, revendicărilor și desenelor depuse conform art. 35 alin. (20) din HG nr. 547/2008.

### (54) PROCEDURĂ PENTRU MONITORIZAREA MAȘINILOR ROTATIVE UTILIZÂND SEPARAREA "OARBĂ" A SURSELOR DE VIBRAȚIE ȘI SEGMENTAREA ENTROPIEI RENYI

(57) Rezumat:

Invenția se referă la o procedură de detecție a schimbărilor în semnalele de vibrație, cu aplicabilitate în monitorizarea mașinilor rotative, bazată pe separarea "oarbă" a surselor de vibrație (BSS) și prelucrarea informației din reprezentarea timp-frecvență. Analiza se realizează pentru principalele surse independente de vibrație ale mașinii și face uz de entropia Renyi pe termen scurt, estimată din distribuția timp-frecvență (TFD) a surselor independente, și de un algoritm de segmentare a acesteia, bazat pe estimatorul de probabilitate maximă *a posteriori* (MAP), ce operează pe entropia Renyi, ca un nou spațiu de decizie de dimensiune redusă. Se asigură astfel detecția mai robustă a schimbărilor în semnalele de vibrație, la acțiunea factorilor perturbatori, decât în cazul aplicării procedurii de segmentare pe semnalele originale.

Revendicări initiale: 5

Revendicări amendate: 1

Figuri: 11

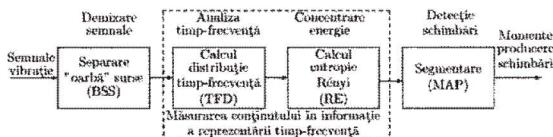
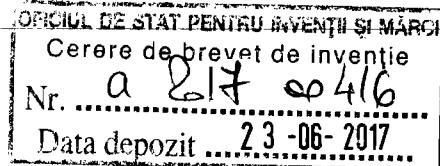


Fig. 1

Cu începere de la data publicării cererii de brevet, cererea asigură, în mod provizoriu, solicitantului, protecția conferită potrivit dispozițiilor art.32 din Legea nr.64/1991, cu excepția cazurilor în care cererea de brevet de inventie a fost respinsă, retrasă sau considerată ca fiind retrasă. Întinderea protecției conferite de cererea de brevet de inventie este determinată de revendicările conținute în cererea publicată în conformitate cu art.23 alin.(1) - (3).





# PROCEDURĂ PENTRU MONITORIZAREA MAȘINILOR ROTATIVE UTILIZÂND SEPARAREA ”OARBĂ” A SURSELOR DE VIBRAȚIE ȘI SEGMENTAREA ENTROPIEI RÉNYI

## DESCRIEREA INVENȚIEI

### **Titlul inventiei**

Procedură pentru monitorizarea mașinilor rotative utilizând separarea ”oarbă” a surselor de vibrație și segmentarea entropiei Rényi

### **Domeniul tehnic la care se referă inventia**

Invenția se referă la o procedură de detecție a schimbărilor în semnalele de vibrație, cu aplicabilitate în monitorizarea stării de funcționare a mașinilor rotative, bazată pe separarea ”oarbă” a surselor de vibrație și prelucrarea informației din planul timp-frecvență.

### **Stadiul tehnicii în domeniu**

Pe plan mondial se manifestă o cerință crescută în ceea ce privește înlocuirea procedurilor de întreținere sistematică, clasică, a mașinilor și utilajelor industriale prin strategii de întreținere conditională, bazate pe supravegherea continuă sau prin sondaj a comportării acestora, cu scopul de a preveni funcționarea anormală și a evita producerea unor catastrofe de natură economică sau ecologică. În acest context, apare ca soluție necesară, posibilă și eficientă, detecția din timp a funcționării anormale a mașinilor și utilajelor industriale, în raport cu o caracterizare a acestora în modul de lucru normal: fără excitare artificială, schimbare a regimului de lucru sau oprire.

Problema detecției și diagnozei schimbărilor produse în mașinile și utilajele industriale, în scopul monitorizării și întreținerii conditionale a acestora, s-a bucurat de o atenție deosebită în ultimele două decenii, atât în cadrul cercetărilor, cât și al aplicațiilor în diferite domenii, [1], [2], [3], [4], [5], etc. Din punct de vedere statistic, detecția schimbărilor caută să identifice schimbările în distribuția de probabilitate a unui proces stochastic.

O soluție clasică de rezolvare a acestei probleme constă în detecția incipientă a deviațiilor mici ale unor semnale de vibrație măsurate, în raport cu datele furnizate de o descriere parametrică a unui model, în condiții normale de lucru ale mașinii. Dacă pot fi detectate astfel de schimbări în fază incipientă, în raport cu schimbările în condițiile normale de operare, se poate spera prevenirea apariției unor variații mari ale unor mărimi, ca rezultat al producerii unor defectiuni sau avarii, sau a stării de oboseală, înaintea producerii funcționării anormale a mașinii, și - în consecință - să crească disponibilitatea acesteia.

Multe soluții fac uz de teorii bazate pe statistică matematică, [6], care furnizează instrumente de rezolvare a problemei detecției incipiente. Un algoritm pentru detecție implică în mod obișnuit două etape: generarea reziduurilor și luarea unei decizii. Reziduurile sunt valori analitice reprezentând diferența dintre comportarea observată, rezultată din măsurători, și comportarea așteptată a mașinii. Instrumentele clasice utilizate pentru generarea reziduurilor sunt filtrele și estimatoarele. În etapa de luare a deciziei, reziduurile sunt analizate și prelucrate utilizând reguli de decizie, pentru a determina starea mașinii sau utilajului, adică prezența sau absența unei schimbări în comportamentul acestora. Procesul de luare a deciziei poate consta într-un simplu "test de prag" sau poate implica utilizarea unui test statistic sistematic.

Există două abordări de bază în rezolvarea problemei detecției, care pot fi succint descrise ca fiind bazate pe modele cantitative, utilizând redundanță analitică, și pe modele calitative. Aceste două abordări pot fi combinate în mod convenabil pentru a crește robustețea generării reziduurilor cantitative. În cazul în care nu se dispune de modele analitice exacte, se poate face uz de modele bazate pe cunoștințe, modele fuzzy sau modele neuronale, în general modele rezultate din instruire. În ceea ce privește metodele de detecție bazate pe modele cantitative, pot fi menționate trei abordări principale, bazate pe identificare (estimarea parametrilor), observare (estimarea stării) și pe spațiul de paritate, [5].

Un element esențial al problemei de detecție se referă la caracterizarea mașinii, sau a unei componente a acesteia, supusă monitorizării, pe perioade scurte de timp, în timpul regimului de funcționare normal. Această caracterizare poate fi obținută, fie prin modelarea mașinii, sau a unei componente a acesteia, fie prin modelarea semnalelor de vibrație măsurate în timpul funcționării mașinii. Variații mari în aceste semnale sunt interpretate ca posibile semne ale unei funcționări anormale a mașinii, datorate producării unor defecțiuni ale acesteia. În esență, se pune problema găsirii unei descrieri adecvate a dinamicii mașinii, sau a unei componente a acesteia, care să poată fi apoi utilizată pentru detecție. În acest scop se va determina o "semnătură" sau "amprentă" ce va caracteriza mașina, sau o componentă a acesteia, operând în condiții normale de funcționare, prin intermediul modelării parametrice sau neparametrice.

Determinarea "semnăturii" se realizează în urma procesării semnalelor măsurate sau estimate. Dispunând de astfel de "semnături" și de un set nou de măsurători, se pune problema de a decide dacă măsurările sunt descrise adecvat de "semnătură", sau dacă s-a produs o schimbare în comportamentul mașinii, situație în care noile măsurători nu mai pot fi caracterizate de "semnătură". Există două soluții bazate pe evaluarea prin comparare a celor două "semnături", utilizând o funcție "distanță" convenabilă sau prin comparația directă a "semnăturii" disponibile cu noile măsurători. Soluția asigură construcția unor indicatori care permit măsurarea adecvanței unor "semnături" specifice cu noile măsurători, furnizând astfel și elemente pentru diagnoză.

În prezent în literatură sunt raportate abordări ce folosesc diferite măsuri de tip "distanță", inteligență artificială, logica fuzzy, recunoașterea formelor, etc. Unele caracteristici, cum ar fi nivelurile de amplitudine în domeniul timp, sunt extrase și clasificate ușor, dar sunt susceptibile la efectul zgromotului. Altele, cum ar fi concentrația de energie în domeniul timp-frecvență, [7], chiar dacă implică mai mult efort, pot conduce în final la o detecție mai robustă în schimbările produse, [8]. Algoritmii de prelucrare a semnalelor, ce fac uz de modele parametrice, pot fi utilizati pentru detecția schimbărilor, dacă se dispune de un model destul de precis al semnalului, în spațiul de reprezentare selectat. În ceea ce privește modelarea semnalelor nestaționare, aceasta este mai dificil de realizat, și nu se dispune de modele parametrice consistente, decât în puține cazuri. Cele mai multe din semnalele întâlnite în practică nu satisfac condițiile de staționaritate, ceea ce explică interesul crescut ce se manifestă în dezvoltarea unor tehnici specifice de prelucrare a acestora. Analiza timp-frecvență (TFA), [9], comparată cea clasica, formulată în general în domeniul timp, furnizează, în mod obișnuit, o înțelegere și interpretare mai simplă a comportării semnalelor nestaționare. Informația din planul timp-frecvență poate fi

prelucrată utilizând diferite tehnici, în scopul detecției schimbărilor în semnalele ce fac obiectul analizei, [10].

## Problema tehnică rezolvată de invenție

Problema tehnică rezolvată în cadrul invenției se referă la detecția schimbărilor în semnalele de vibrație, bazată pe separarea "oarbă" a surselor independente și analiza conținutului informației în planul timp-frecvență, cu aplicații în monitorizarea mașinilor rotative.

Procedura ce face obiectul invenției combină în premieră 3 tehnici de procesare a semnalelor de vibrație, ce se prezintă în Figura 1:

- Separarea "oarbă" a surselor de vibrație independente
- Măsurarea conținutului în informație a reprezentării timp-frecevență, prin estimarea entropiei Rényi
- Detecția schimbărilor în entropia Rényi și segmentarea acesteia

Totodată aceasta realizează și fuziunea informației rezultate în cele etape de prelucrare menționate anterior, în scopul realizării monitorizării eficiente a mașinii. Lucrul pe sursele independente, într-un nou spațiu, în locul celui generat de semnalele de vibrație originale, simplifică problema de detecție, în acest caz numărul semnalelor ce fac obiectul analizei fiind mai mic, și mai mult, analiza se va realiza pe semnale monodimensionale. Procedura propriu-zisă de detecție se va aplica în final pe un semnal monodimensional, entropia Rényi, rezultată prin aplicarea unei transformate pe reprezentarea în planul timp-frecvență a semnalului analizat. Utilizarea unui test în acest nou spațiu de decizie, ca urmarea a aplicării procedurii de detecție, va permite o înțelegere și interpretare mai simplă a comportării semnalelor nestaționare, și va conduce la detecția mai robustă a schimbărilor produse în dinamica semnalelor de vibrație, cu efecte asupra monitorizării mașinii sau a unor componente ale acesteia.

Procedura propusă realizează și o pre-procesare a datelor de măsură, semnalele de vibrație, prin separarea "oarbă" a surselor de vibrație independente, în scopul evidențierii schimbărilor produse în funcționarea mașinii, dar și o post-procesare a rezultatelor detecției, prin calculul implicit al entropiei Rényi, și detecția schimbărilor în parametrii modelului și în dispersia zgromotului.

## Expunerea invenției

Principalele etape ale procedurii ce face obiectul invenției, sunt reprezentate în Figura 1, și se prezintă în cele ce urmează.

### Borderou figuri

Figura 1 Principalele etape în procedura de monitorizare a mașinilor rotative ce utilizează separarea "oarbă" a surselor de vibrație și segmentarea entropiei Rényi

Figura 2 Mixarea și separarea semnalelor

Figura 3 Schema de măsurare multicanal: E = electromotor, MC = carcăsa mașină, T = tachometru, V = vană alimentare, S1-S7 = poziție senzori 1,7

Figura 4 Accelerăriile măsurate cu senzorii S1-S7

Figura 5 Sursele de vibrație independente rezultate în urma aplicării algoritmului SOBI pentru măsurătorile efectuate pe cele 7 canale

Figura 6 Distribuția timp-frecvență RID pentru sursa S1, în condițiile de funcționare normală și cu producerea unei defecțiuni a mașinii

Figura 7 Distribuția timp-frecvență RID pentru sursa S2, în condițiile de funcționare normală și cu producerea unei defecțiuni a mașinii

Figura 8 Entropia Rényi pe termen scurt pentru sursa S1

Figura 9 Entropia Rényi pe termen scurt pentru sursa S2

Figura 10 Segmentarea MAP a entropiei Renyi pentru sursa S1

Figura 11 Segmentarea MAP a entropiei Renyi pentru sursa S2

### Separarea "oarbă" a surselor de vibrație

Separarea "oarbă" a surselor (BSS) constă în estimarea surselor de vibrație independente care generează semnalele măsurate pe carcasa mașinii, utilizând Analiza Componentelor Independente (ICA), [11]. Problema este de mare actualitate în ingineria mecanică, unde prezintă interes estimarea surselor endogene, necunoscute, din măsurătorile exogene și oferă noi soluții în analiza vibrațiilor și a zgomotului, [12].

Modelul presupus pentru BSS presupune existența a  $n$  semnale independente  $s_1(t), \dots, s_n(t)$  și măsurarea mixărilor liniare și instantanee ale acestora:  $x_1(t), \dots, x_n(t)$ :

$$x_i(t) = \sum_{j=1}^n a_{ij} s_j(t) + n_i(t) \quad (1)$$

pentru fiecare  $i = 1, n$ . Modelul poate fi reprezentat compact prin următoarea ecuație de mixare:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) \quad (2)$$

unde  $\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T$  este un vector coloană,  $n \times 1$ , ce conține semnalele sursă, în timp ce vectorul  $\mathbf{x}(t)$  conține  $n$  semnale observate, iar "matricea de mixare"  $\mathbf{A}$ ,  $n \times n$ , conține coeficienții de mixare.

BSS constă în estimarea vectorului sursă  $\mathbf{s}(t)$  folosind numai datele observate  $\mathbf{x}(t)$ , ipoteza de independentă a componentelor vectorului  $\mathbf{s}(t)$  și, posibil, unele informații a priori privind distribuția de probabilitate a intrărilor,  $\mathbf{s}(t)$ . Aceasta poate fi formulată ca estimarea unei "matrici de separare"  $\mathbf{W}$ ,  $n \times n$ , ale cărei ieșiri, vectorul  $\hat{\mathbf{s}}(t)$ , reprezintă o estimare a vectorului semnalelor sursă, în cazul unei mixări instantanee, având forma (vezi Figura 2):

$$\hat{\mathbf{s}}(t) = \mathbf{W}\mathbf{x}(t) \quad (3)$$

Elementul cheie în succesul aplicării unei metode de separare, constă în alegerea criteriului statistic în raport cu care se realizează separarea. Astfel, dacă semnalele sunt temporal coerente, este posibil să rezolve problema BSS folosind numai statistici de ordinul doi. În acest caz rezultă un algoritm, SOBI (Second Order Blind Identification), care estimează sursele originale, pe baza autocorelațiilor pentru mai multe valori ale întârzierii și diagonalizarea aproxiinativă asociată acestora, [13]. Această metodă prezintă avantajul că este ușor de implementat și conduce, în multe cazuri, la soluții liniare care necesită un efort de calcul redus, și folosește tehnici numerice standard.

Numărul surselor independente rezultă în urma descompunerii după valori proprii a matricei de covarianță eșantion,  $\hat{\mathbf{R}}_x(0) = \frac{1}{N} \sum_{t=1}^N \mathbf{x}(t)\mathbf{x}(t)^T$ , a vectorului măsurătorilor  $\mathbf{x}(t)$ .

$$\hat{\mathbf{R}}_x(0) = \mathbf{H}\Delta\mathbf{H}^T \quad (4)$$

unde

$$\mathbf{H} = [\mathbf{h}_1, \dots, \mathbf{h}_m]$$

și

$$\Delta = diag[\lambda_1, \dots, \lambda_m]$$

cu  $\lambda_i \geq \lambda_j$  for  $i < j$ . Numărul surselor independente poate fi estimat pe baza spectrului rezultat  $\Delta$ , [13], [14], [15].

### Măsurarea conținutului în informație a reprezentării timp-frecvență folosind entropia Rényi

#### Analiza timp-frecvență

Obiectivul de bază al analizei timp-frecvență (TFA) este de a dezvolta o funcție care să permită descrierea modului în care densitatea de energie a semnalului este distribuită în domeniul timp,  $t$ , și frecvență,  $\omega$ . O astfel de funcție transformă semnalul din domeniul monodimensional timp într-o reprezentare bidimensională a energiei în raport cu timpul și frecvența.

Reprezentările timp-frecvență (TFR) pot fi clasificate în raport cu abordările de analiză utilizate, [16]. Într-o primă categorie, semnalul este reprezentat prin funcții timp-frecvență (TF) rezultate în urma translatării, modulării și scalării unei funcții de bază având o localizare definită în timp și frecvență. Pentru un semnal,  $x(t)$ , reprezentarea TFR este dată de relația:

$$TF_x(t, \omega) = \int_{-\infty}^{+\infty} x(\tau) \phi_{t,\omega}^*(\tau) d\tau = \langle x, \phi_{t,\omega} \rangle, \quad (5)$$

unde  $\phi_{t,\omega}$  reprezintă funcțiile de bază (numite de asemenea atomi TF), iar  $*$  reprezintă complex conjugatul. Funcțiile de bază se presupun a fi pătrat integrabile,  $\phi_{t,\omega} \in L^2(\mathbb{R})$ , adică au energie finită, [17].

A doua categorie de distribuții timp-frecvență (TFD), cunoscute ca distribuții de clasă Cohen, invariantă la deplasare, se bazează pe distribuția energiei în domeniul timp-frecvență. Acestea sunt caracterizate printr-o funcție nucleu. Proprietățile reprezentării sunt reflectate prin simple restricții asupra nucleului care produc TFR cu proprietăți dorite, prescrise, [9], [18]. O descriere matematică a acestor TFR poate fi dată de

$$TFD_x(t, \omega) = \frac{1}{4\pi^2} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x(u + \frac{1}{2}\tau) \times \\ x^*(u - \frac{1}{2}\tau) \phi(\theta, \tau) \exp^{-j\theta t - j\tau\omega + j\theta u} du d\tau d\theta \quad (6)$$

unde  $\phi(\theta, \tau)$  este o funcție nucleu bidimensională, determinând reprezentarea specifică în această categorie, și prin urmare, proprietățile reprezentării. Distribuția de bază în cadrul acestei abordări este distribuția Wigner (WD), [9].

$$WD_x(t, \omega) = \int_{-\infty}^{+\infty} x(t + \frac{1}{2}\tau) x^*(t - \frac{1}{2}\tau) \exp^{-j\tau\omega} d\tau. \quad (7)$$

Nucleul acestuia este  $\phi(\theta, \tau) = 1$ . De asemenea, spectrograma (SP), distribuția Choi-Williams (CWD) și distribuția binomială (BD) sunt câteva dintre metodele utilizate pentru obținerea TFD, [9]. Distribuția Choi-Williams (CWD) [19] și distribuția binomială (BD) [20] suprimă în mare măsură interferența cross-termenilor, dar cu prețul unei pierderi a rezoluției timp-frecvență. Aceste distribuții aparțin așa-numitelor distribuții cu interferență redusă (RID). Ele

aparțin, de asemenea, clasei Cohen, [9],[18], [21]. Fiecare membru al clasei generale Cohen poate fi interpretat ca fiind ca o distribuție WD, filtrată bidimensional.

### Entropia Rényi a reprezentării timp-frecvență

Așa cum s-a menționat anterior, una din cele mai simple proceduri de caracterizare a unui semnal, în TFA, se poate realiza prin intermediul concentrării energiei acestuia. Ideea constă în analiza concentrației energiei semnalului la anumite momente de timp sau benzi de frecvență, sau mai general, în anumite regiuni de timp și frecvență. O astfel de analiză este capabilă să furnizeze mai multă informație în legătură cu un fenomen particular. O analiză a reprezentării timp-frecvență, folosind concentrarea energiei, face obiectul lucrării [16], iar în [7] se prezintă mai multe măsuri pentru energie și se face o comparație a acestora, fiind utilizate norme cu distribuții la puteri egale sau mai mici decât unitatea. Toate aceste măsuri furnizează o măsură bună a concentrației auto-termenilor în distribuția timp-frecvență. Apariția cross-termenilor afectează comportarea acestor norme față de modul de lucru dorit. Au fost propuse și utilizate diferite modificări eficiente ale acestor măsuri pentru a lua în considerare apariția oscilațiilor nedorite ale distribuțiilor. Astfel în [22], norma distribuției este împărțită printr-o normă de ordin redus, și au fost impuse unele restricții asupra formelor nucleelor. Cu toate acestea, chiar formele normalizate ale măsurilor bazate pe normă nu sunt suficient de adecvate în cazurile în care există două sau mai multe componente (sau regiuni în planul timp-frecvență al unei componente) de energii aproximativ egale ale căror concentrații sunt foarte diferite. Măsurile bazate pe norme, ca urmare a ridicării valorilor distribuției la o putere ridicată (3 sau 4) vor favoriza distribuțiile cu un anumit tip de componentă ("peaky"). Aceasta înseamnă că dacă o componentă (regiune) este extrem de concentrată, și toate celelalte componente sunt slab concentrate, atunci nu se va realiza un compromis, ca în cazul în care toate componentele sunt suficient de bine concentrate. Există mai multe măsuri bazate pe entropia Rényi, capabile de a realiza analiza cantitativă în descrierea cantității de informație conținută în distribuția timp-frecvență, care să fie utilizate la detecția schimbărilor în semnalele de vibrație.

Odată ce a fost obținut conținutul în frecvență local, utilizând una din distribuțiile timp-frecvență prezentate anterior, poate fi evaluată o nouă măsură a entropiei, pentru o valoare dată a timpului,  $t = n$ .

Clasa măsurilor entropiei Rényi a fost introdusă în analiza timp-frecvență de Sang și Williams, [22], cu contribuții semnificative datorate lui Flandrin s. a., [23], care au stabilit proprietățile acestei măsuri. Entropiile generalizate Rényi au inspirat noi măsuri pentru estimarea informației conținută în semnal și complexitatea acestuia în planul timp-frecvență. Proprietățile locale ale entropiilor Rényi au fost studiate de Sucic s. a., [24]. Aceste măsuri posedă mai multe proprietăți utile și interesante, cum ar fi luarea în considerare a cross-termenilor și a invariantilor transformării, ceea ce le face de interes pentru măsurarea conținutului în informație a reprezentării timp-frecvență.

Pentru o distribuție timp-frecvență generică,  $P_x(n, k)$ , măsura entropiei Rényi are forma următoare:

$$RE_\alpha = \frac{1}{1-\alpha} \log_2 \left( \sum_n \sum_k P_x^\alpha(n, k) \right) \quad (8)$$

unde  $n$  este variabila discretă temporală, iar  $k$  variabila discretă frecvență, cu  $\alpha \geq 2$  valori recomandate pentru măsuri ale distribuției timp-frecvență, [23]. Pentru cazul  $\alpha = 2$  (energia distribuției) termenii cross vor crește energia, conducând la concluzia falsă privind îmbunătățirea concentrației, Cazul  $\alpha = 3$  eșuează în a detecta existența cross-termenilor diferenți de zero oscilatorii (care nu se suprapun peste auto-termeni), deoarece pentru valori impare  $\alpha$  aceștia nu contribuie la valoarea acestei măsuri. Acestea au fost motivele introducerii măsurilor

entropiei Rényi normalize, care vor fi trecute în revistă în continuare. Normalizarea poate fi făcută în diferite moduri, conducând la o varietate de măsuri posibile, [7], [23].

Eisberg și Resnik, [25], asimilează distribuțiile timp-frecvență la un moment de timp dat,  $t = n$ , cu o funcție de undă și în cazul general (8), pentru  $\alpha = 3$ , rezultă

$$RE_3 = -\frac{1}{2} \log_2 \left( \sum_n \sum_k P_x^3(n, k) \right) \quad (9)$$

Etapa de normalizare afectează exclusiv indexul  $k$ , când operația este restricționată la o singură poziție  $n$ , pentru a satisface condiția  $\sum_k P_x(n, k) = 1$  într-o astfel de poziție.

Măsura (9) poate fi rescrisă pentru un  $n$  dat astfel:

$$RE_3(n) = -\frac{1}{2} \log_2 \left( \sum_k P_x^3(n, k) \right) \quad (10)$$

Empiric, normalizarea propusă în [25] s-a dovedit a fi cea mai potrivită pentru aplicații în analiza semnalelor. Valorile lui  $RE_3(n)$  depind de dimensiunea  $N$  a ferestrei de date în (9) și se poate arăta că acestea se situează în intervalul  $0 \leq RE_3(n) \leq \log_2 N$ . Prin urmare, măsura poate fi normalizată aplicând relația:  $\hat{RE}_3(n) = RE_3(n) / \log_2 N$ .

### Segmentarea entropiei Rényi utilizând estimatorul MAP

#### Formularea problemei

Segmentarea entropiei Rényi pe termen scurt se va realiza utilizând modele de regresie liniară cu parametrii constanți pe porțiuni. Aceasta rezultă în urma detecției momentelor producerii unor schimbări în entropia Rényi. Problema constă în a găsi o secvență de indici de timp,  $k^n = k_1, k_2, \dots, k_n$ , unde atât numărul  $n$  cât și locațiile  $k_i$  sunt necunoscute, astfel încât un model de regresie liniară cu parametrii constanți pe porțiuni,

$$y_t = \phi_t^T \theta(i) + e_t, \quad E(e_t^2) = \lambda(i) \quad (11)$$

unde  $k_{i-1} < t \leq k_i$ , să realizeze o bună aproximare a entropiei Rényi,  $y_t$ , presupusă a avea  $N$  eșantioane;  $\theta(i)$  este vectorul parametrilor modelului, de dimensiune  $d$ , pentru segmentul  $i$ ,  $\phi_t$  este vectorul regresorilor ce conține valorile entropiei Rényi la momente anterioare, iar  $k_i$  reprezintă momentele producerii schimbării. Zgomotul  $e_t$  se presupune a fi Gaussian, de dispersie  $\lambda(i)$ , depinzând de segment. Atât  $\theta(i)$ , cât și  $\lambda(i)$  sunt necunoscuți.

O cale de garantare a faptului că a fost găsită cea mai bună soluție posibilă constă în a considera toate segmentările posibile,  $k^n$ , de a estima câte un model de regresie liniară în fiecare segment, și de a alege în final segmentarea particulară  $k^n$  care minimizează criteriile de optimalitate:

$$\widehat{k^n} = \arg \min_{n \geq 1, 0 < k_1 < \dots < k_n = N} V(k^n) \quad (12)$$

Pentru măsurătorile din segmentul  $i$ , adică  $y_{k_{i-1}+1}, \dots, y_{k_i} = y_{k_{i-1}+1}^{k_i}$ , vectorul estimărilor parametrilor modelului cu metoda celor mai mici pătrate (LS) și matricea sa de covarianță sunt date de:

$$\hat{\theta}(i) = P(i) \sum_{t=k_{i-1}+1}^{k_i} \phi_t y_t, \quad (13)$$

$$P(i) = \left( \sum_{t=k_{i-1}+1}^{k_i} \phi_t \phi_t^T \right)^{-1}. \quad (14)$$

Mărimile  $V =$  suma pătratelor reziduurilor, ,  $D = -\log \det$  al matricei de covariță  $P$  și  $N =$  numărul de date din fiecare segment sunt date de

$$V(i) = \sum_{t=k_{i-1}+1}^{k_i} (y_t - \phi_t^T \hat{\theta}(i))^2 \quad (15)$$

$$D(i) = -\log \det P(i) \quad (16)$$

$$N(i) = k_i - k_{i-1} \quad (17)$$

și reprezintă statistici suficiente în fiecare segment. Datele și statisticile utilizate în procedura de segmentare sunt prezentate în Tabelul 1.

Table 1: Datele și statisticile utilizate în procedura de segmentare

Date	$y_1, y_2, \dots, y_{k_1}$	...	$y_{k_{n-1}+1}, \dots, y_{k_n}$
Segment	Segment 1	...	Segment n
Estimație LS	$\hat{\theta}(1), P(1)$	...	$\hat{\theta}(n), P(n)$
Statistică	$V(1), D(1), N(1)$	...	$V(n), D(n), N(n)$

Se poate observa că segmentarea  $k^n$  are  $n - 1$  grade de libertate. În literatură au fost propuse două tipuri de criterii de optimalitate pentru rezolvarea problemei: criterii statistiche (verosimilitate maximă (ML) sau probabilitate maxima a posteriori (MAP)) și criterii bazate de informație. Problema principală în segmentare este cea a dimensionalității. Numărul de posibile segmentări  $k^n$  este  $2^N$  (se poate produce sau nu o schimbare la fiecare moment de timp).

### Estimatorul de probabilitate maximă a posteriori (MAP)

Descrierea conceptuală a estimatorului de probabilitate maximă a posteriori (MAP), [26], pentru datele și mărimile date în Tabelul 1 include următoarele etape de calcul:

**Etapa 1.** Se examinează separat fiecare segmentare posibilă, parametrizată prin numărul de schimbări,  $n$ , și momentele de producere a acestora,  $k^n$ .

**Etapa 2.** Pentru fiecare segmentare, se calculează cele mai bune modele în fiecare din segmente, sub forma estimării celor mai mici pătrate a parametrilor,  $\hat{\theta}(i)$ , și a matricei de covariță a acestora,  $P(i)$ .

**Etapa 3.** Se calculează în fiecare segment suma pătratelor erorilor de predicție,  $V(i)$  și  $D(i) = -\log \det P(i)$ .

**Etapa 4.** Estimația MAP a structurii modelui pentru trei ipoteze privind scalarea zgromotului: (i)  $\lambda(i) = \lambda_0$  cunoscut, (ii)  $\lambda(i) = \lambda$  necunoscut, dar constant, (iii)  $\lambda(i)$  necunoscut și variabil, este dată de următoarele ecuații, [26]:

$$\widehat{k^n} = \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + V(i)) + 2n \log \frac{1-q}{q} \quad (18)$$

$$\widehat{k^n} = \arg \min_{k^n, n} \sum_{i=1}^n D(i) + (N - nd - 2) \log \sum_{i=1}^n \frac{V(i)}{N - nd - 4} + 2n \log \frac{1-q}{q} \quad (19)$$

$$\widehat{k^n} = \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + (N(i) - d - 2) \log \frac{V(i)}{N(i) - d - 4}) + 2n \log \frac{1-q}{q} \quad (20)$$

unde  $q$  este probabilitatea producerii unei schimbări la fiecare moment de timp ( $0 < q < 1$ ). Pentru  $q = 0.5$ , estimatorul MAP devine estimatorul de verisimilitate maximă (ML).

Urmează să se va evalua una din ecuațiile (18)-(20), în funcție de ipoteza care se face privind scalarea zgomotului (a se vedea **Etapa 4.**).

Ultimele două probabilități (19) și (20) reprezintă valori aproximative. Evaluările ecuațiilor (18), (19) și (20) implica statisticile (15), (16) și (17). În toate cazurile prezentate au fost omise constantele din probabilitățile a posteriori. Diferențele în cele trei cazuri constau în modul în care este tratată suma pătratelor erorilor de predicție. O probabilitate a priori  $q$  produce un termen de penalizare care crește liniar cu  $n$  pentru  $q < 0.5$ . Obținerea ecuațiilor (18), (19) și (20) este valabilă numai dacă toți termenii sunt bine definiți. Condiția este ca  $P(i)$  să fie de rang complet pentru toate valorile  $i$ , și ca  $N - nd - 4 > 0$  și  $N(i) - d - 4 > 0$ , în (19) și respectiv (20). Prin urmare, segmentele sunt forțate să fie suficient de lungi.

Calculul verosimilității exacte este greu de efectuat din cauza complexității exponențiale. În această situație se utilizează algoritmi ce implementează tehnici recursive de căutare locale sau tehnici numerice de căutare bazate pe programarea dinamică sau tehnici de tip lanțuri Markov Monte Carlo (MCMC), [2].

## Avantaje invenție în raport cu stadiul tehnicii

Avantajele pe care soluția propusă le prezintă, comparativ cu soluțiile cunoscute în prezent, sunt:

- Lucrul pe sursele independente încruntării nou spațiu de dimensiune redusă, față de cel al semnalelor de vibrație originale, simplifică problema de detecție. În acest caz numărul semnalelor ce fac obiectul analizei este mai mic, și mai mult, analiza se va realiza pe semnale monodimensionale.
- Aplicarea procedurii propriu-zise de detecție/segmentare se va aplica în final pe un semnal monodimensional, entropia Rényi, rezultată prin aplicarea unei transformate pe reprezentarea bidimensională din planul timp-frecvență. Utilizarea unui test statistic în cadrul procedurii de detecție/segmentare, în acest nou spațiu de decizie, va permite o înțelegere și interpretare mai simplă a comportării semnalelor nestaționare, și va conduce la detecția mai robustă a schimbărilor produse în dinamica semnalelor de vibrație, cu efecte asupra monitorizării mașinii sau a unor componente ale acesteia.
- Procedura ce face obiectul invenției va permite realizarea unei fuziuni a informației rezultate în cele 3 etape de prelucrare menționate anterior, în scopul unei monitorizări eficiente a mașinii, cu evitarea unor alarme false privind necesitatea efectuării unei revizii, și va furniza informații suplimentare în scop de diagnoză.
- Procedura propusă realizează și o pre-procesare a datelor de măsură, prin separarea "oară" a surselor de vibrație independente, în scopul evidențierii schimbărilor produse în funcționarea mașinii (acestea apar mult mai vizibile în sursele de vibrație independente, dacă în semnalele originale), dar și o post-procesare a rezultatelor detecției, prin calculul implicit al entropiei Rényi, și detecția schimbărilor în parametrii modelului și în dispersia zgomotului.

## Modul de realizare și aplicare a invenției

Realizarea și aplicarea invenției constă în prelucrarea datelor de măsură, semnale de vibrație măsurate pe mașină sau utilajul tehnologic, conform procedurii descrise în Secțiunea 5, și pentru care a fost dezvoltat suportul software necesar. Realizarea și aplicarea invenției sunt exemplificate printr-un studiu de caz, pentru o mașină rotativă, o pompă industrială de mare capacitate.

### Datele de măsură

O schemă a pompei industriale, cu componente sale și poziția senzorilor este dată în Figura 3. Semnalele de vibrație, accelerăriile pe 7 canale, sunt măsurate pe carcasa mașinii. Măsurătorile au fost repetate pe două mașini identice, prima aflată în regim de funcționare normal, iar pentru cea de a doua s-a procedat la inducerea unei defecțiuni la cutia de viteze. Măsurătorile, efectuate în regim de încărcare minimă și maximă, la joasă și înaltă frecvență au fost obținute în cadrul proiectului "Machine diagnostics by neural networks project", realizat de TecluioFysica, The Netherlands, [27].

În cadrul analizei au fost selectate măsurătorile efectuate la înaltă frecvență, eșantionate cu 12800 Hz, și un segment de date de 4096 valori, 2048 de la pompa aflată în regim de funcționare normal, și 2048 de la pompa la care a fost inducătoare la cutia de viteze, ambele la încărcare minimă. Date au fost filtrate trece jos la 5000 Hz. Accelerăriile măsurate de senzorii S1-S7 sunt reprezentate în Figura 4.

Din cauza mixării principalelor surse de vibrație, din datele măsurate pe carcasa mașinii este dificil de stabilit momentul producerii unei defecțiuni la mașina ce face obiectul monitorizării. Din acest motiv, s-a procedat, într-o primă etapă, la transferul problemei de monitorizare din spațiul original al măsurătorilor, în spațiul surselor independente de vibrație. Aceasta a permis efectuarea analizei într-un spațiu de dimensiune redusă, iar aplicarea metodei de detecție/segmentare s-a va face pe semnale monodimensionale, ceea ce a condus la simplificarea în mare măsură a analizei.

### Separarea "oară" a surselor

Măsurătorile accelerărilor efectuate pe cele 7 canale conținând 4098 valori, de la cele două mașini, una aflată în regim de funcționare normal, iar cealaltă având indusă o defecțiune, au reprezentat datele de intrare pentru algoritmul SOBI de estimarea a surselor independente de vibrație, în cazul modelului de mixare instantaneu; aplicarea procedurii de estimare a numărului surselor independente, prezentată în Secțiunea 2 a condus la 2 surse independente. Sursele rezultante sunt reprezentate în Figura 5.

### Analiza timp-frecvență și calculul entropiei Rényi

Figura 6 prezintă distribuția timp-frecvență RID pentru sursa S1, cu utilizarea unei fereastre Hanning. Aceasta a fost calculată pentru un număr de puncte de frecvență,  $N_f = 4096$ , identic cu momentele de timp utilizate, o fereastră de netezire în timp,  $g(u)$ , de dimensiune  $L_g = 204$ , o fereastră de netezire în frecvență,  $h(\tau)$ , de dimensiune  $L_h = 512$ , și un prag de 5%. În Figura 6, reprezentată la scală liniară, se poate observa producerea unci schimbări în conținutul spectral al sursei S1, în cea de a doua parte a semnalului.

Resultatele analizei timp-frecvență pentru sursa S2 sunt prezentate în Figura 7, pentru același tip de distribuție, RID, utilizând o fereastră Hanning și aceiași parametrii, ca în cazul analizei sursei S1. În cazul de față se poate constata o schimbare mai redusă a conținutului spectral al sursei S2, în cea de a doua parte a semnalului, în comparație cu schimbarea de conținut spectral produsă în sursa S1.

O primă concluzie în această etapă a analizei, ar fi că sursa de vibrație S1 a fost indusă de producerea unei defecțiuni în funcționarea mașinii, ținând seama și de valoarea schimbării

în conținutul spectral al acesteia. Deoarece separarea surselor nu este realizată perfect, există posibilitatea ca o schimbare reală produsă într-una din surse să poată fi indușă și în alte surse, în cazul nostru în sursa S2, dar schimbarea în conținutul spectral al acestei surse este de valoare redusă în raport cu sursa S1.

Pentru a evalua rezultatele analizei timp-frecvență pentru sursa S1, prezentăm în Figura 8 entropia Rényi pe termen scurt, ca măsură a concentrației distribuției timp-frecvență, calculată cu RID; s-a utilizat o fereastră alunecătoare de dimensiune  $N = 64$  și o constantă de deviere, adăugată la valoarea semnalului egală cu 1. Entropia Rényi pe termen scurt pentru sursa S2, utilizând aceleași valori pentru fereastra alunecătoare și constantă de deviere, este reprezentată în Figura 9.

### Segmentarea MAP a entropiei Rényi

Analiza vizuală a entropiei Rényi pentru ambele surse, scoate în evidență faptul există un moment de timp în care se produce o schimbare în conținutul de energie și de frecvență. Pe baza experienței anterioare în analiza unor semnale similare, un model cu parametri constanți pe portiuni poate conduce la un compromis satisfăcător între complexitatea și eficiența algoritmilor de estimare off-line a momentelor producerii unor schimbări în dinamica semnalului. Procedura de detecție a schimbărilor în cazul celor două entropii Rényi s-a realizat cu estimatorul MAP, în cazul unui zgromot constant necunoscut, cu următoarele valori ale parametrilor de proiectare:  $q = 0.3$ ,  $M = 10$ ,  $ll = 8$  și  $mseg = 700$ , [26].

Procedura de segmentare a fost realizată pentru un model autoregresiv AR(1) de forma:

$$y_t = -\phi_1 * y_{t-1} + e_t \quad (21)$$

Estimările parametrilor modelului și ale dispersiei zgromotului rezultate în urma aplicării algoritmului bazat pe estimatorul MAP, pentru entropiile Rényi ale celor două surse sunt prezentate în Figura 10 și respectiv în Figura 11.

Valorile dispersiei zgromotului modelului cu parametrii constanți pe portiuni, în cazul ambelor surse, prezintă salturi semnificative în cea de a doua parte a semnalului, ceea ce denotă un fenomen de ruptură, datorat inducerii defecțiunii în funcționarea mașinii.

### Aplicarea în mediul industrial a invenției

În ceea ce privește aplicarea în mediul industrial a invenției, considerăm ca posibile următoarele moduri de utilizare:

- Dispunând de o înregistrare de date, semnale de vibrație, acestea pot fi analizate utilizând cele 3 etape incluse în procedura ce face obiectul invenției. Rezultatele obținute oferă o imagine de ansamblu asupra proceselor vibratorii specifice mașinii rotative, sau componentelor acesteia, ce fac obiectul monitorizării.
- În cazul în care se dispune de o înregistrare de probă a semnalelor de vibrație din funcționarea normală a mașinii rotative, sau a componentelor acesteia, (înregistrare "martor"), aceasta poate fi concatenată cu o înregistrare curentă din funcționarea mașinii rotative, sau a componentelor acesteia, semnalul rezultat urmând să fie analizat cu prelucrările menționate în cele 3 etape ale procedurii ce face obiectul invenției, în urma analizei rezultând dacă datele celor două înregistrări sunt consistente, sau dacă s-a produs o schimbare în funcționarea mașinii, sau a componentelor acesteia, situație în care pe baza acestor rezultate și a unor informații ce țin de experiența utilizatorului se poate trece la diagnoză și localizarea posibilei defecțiuni.

De menționat faptul că invenția poate fi aplicată nu numai în domeniul monitorizării stării de bună funcționare a mașinilor rotative și a componentelor acestora, ci și în alte domenii cum ar fi: industria energetică (turbine, generatoare, etc.), ingineria civilă (clădiri mari supuse acțiunii vântului și miscările seismice, poduri, baraje, platforme marine), aeronomică (structuri și componente supuse solicitărilor), automobile și sisteme de transport, etc.

## Bibliografie

- [1] M. Basseville, I. V. Nikiforov (1993), Detection of Abrupt Changes: Theory and Applications, Information and System Science Series, Prentice Hall, Englewood Cliffs, NJ.
- [2] F. Gustafsson (2001), Adaptive Filtering and Change Detection, Wiley, NJ.
- [3] J. Gertler (1998), Fault Detection and Diagnosis in Engineering Systems, Marcel Dekker.
- [4] M. Lipsett, C. K. Mechefske (2008), Fault detection using transient machine signals, Mechanical Systems and Signal Processing, 1724-1749.
- [5] R. Isermann (1997). Supervision, fault-detection and fault-diagnosis methods - An introduction, *Control Engineering Practice*, vol. 5, no. 5, 639-652.
- [6] M. Basseville (1997). Statistical approaches to industrial monitoring problems - Fault detection and isolation, *Proc. of the 11th IFAC/IFORS Symposium on Identification and System Parameter Estimation - SYSID'97*, Kitakyushu, Japan, July 8-11, 1997.
- [7] L. Stankovic (2001) A measure of some time-frequency distributions concentration, *Signal Processing*, 621-631.
- [8] J. Chen, R. J. Patton (1999), Robust Model-Based Fault Diagnosis for Dynamic Systems, Kluwer Academic Publishers.
- [9] L. Cohen (1995), Time-Frequency Distribution, Prentice Hall, New York.
- [10] S. Aviyente (2004), Information processing on the time-frequency plane, *Proc. IEEE International Conference Acoustics, Speech, and Signal Processing (ICASSP '04)*, 617-620.
- [11] A. Hyvärinen, J. Karhunen, E. Oja (2001), Independent Component Analysis, John Wiley.
- [12] J. Antoni (2005), Blind separation of vibration components: Principles and demonstrations, *Mechanical Systems and Signal Processing*, 1166-1180.
- [13] A. Belouchrani, K. Abed Meraim, J. F. Cardoso, E. Moulines (1997), A blind source separation technique using second - order statistics, *IEEE Trans. Signal Processing* 45, 434-444.
- [14] M. Wax, T. Kailath (1983), Determining the number of signals by information theoretic criteria, *Workshop on Spectral Estimation II*, Florida, USA, 192-196.
- [15] Y. Yin, P. Krishnaiah (1987), Methods for detection of the number of signals, *IEEE Trans. on ASSP* 35, 1533-1538.
- [16] E. Sejdić, I. Djurović, J. Jiang (2009), Time-frequency feature representation using energy concentration: An overview of recent advances, *Digital Signal Processing*, 153-183.
- [17] S. G. Mallat (1999), *A Wavelet Tour of Signal Processing*, Second Ed., Academic Press.
- [18] B. Boashash (2003), *Time frequency signal analysis and processing: A compressive reference*, Elsevier.

- [19] F. Hlawatsch, G. F. Boudreux-Bartels (1992), Linear and quadratic time-frequency signal representations, IEEE Signal Processing Magazine, 21-67.
- [20] M. Hussain, B. Bouashash (2000), Multi-component IF estimation, Proc. of the 10th IEEE Workshop on statistical signal and array processing - SSAP, 559-563.
- [21] J. Jeong, W. J. Williams (1992), Kernel design for reduced interference distributions, IEEE Transactions on Signal Processing, 402-4012.
- [22] T. H. Sang, W. J. Williams (1995), Rényi information and signal dependent optimal kernel design, Proc. of the ICASSP, 997-1000.
- [23] P. Flandrin, R. G. Baraniuk, O. Michel (1994), Time-frequency complexity and information, Proc. of the ICASSP, 329-332.
- [24] V. Sucic, N. Saulig, B. Bouashash (2014), Analysis of Local Time-Frequency Entropy Features for Nonstationary Signal Components Time Supports Detection, Digital Signal Processing, 56-66.
- [25] R. Eisberg, R. Resnick (1994), Quantum Physics, Wiley.
- [26] Th. D. Popescu (2004), Signal segmentation using changing regression models with application in seismic engineering, Digital Signal Processing, 14-26.
- [27] A. Ypma (2001), Learning Methods for Machine Vibration Analysis and Health Monitoring, PhD Thesis, TU Delft.

# PROCEDURĂ PENTRU MONITORIZAREA MAȘINILOR ROTATIVE UTILIZÂND SEPARAREA ”OARBĂ” A SURSELOR DE VIBRAȚIE ȘI SEGMENTAREA ENTROPIEI RÉNYI

## REVENDICĂRI

1. Procedură pentru detecția schimbărilor în semnalele de vibrație, cu aplicabilitate în monitorizarea mașinilor rotative, bazată pe separarea ”oarbă” a surselor de vibrație și prelucrarea informației din planul timp-frecvență, **caracterizată prin aceea că** analiza se realizează pe sursele de vibrație independente, într-un nou spațiu de dimensiune redusă, față de cel al semnalelor de vibrație originale, ceea ce simplifică problema de detecție, situație în care numărul semnalelor ce fac obiectul analizei este mai mic, față de cel al semnalelor de vibrație originale, iar analiza se realizează pe semnale monodimensionale.
2. Procedură pentru detecția schimbărilor în semnalele de vibrație, conform revendicării 1, **caracterizată prin aceea că** aplicarea procedurii propriu-zise de detecție/segmentare se realizează pe entropia Rényi a surselor de vibrație independente, ceea ce permite o înțelegere și interpretare mai simplă a comportării semnalelor nestaționare, și conduce la detecția mai robustă a schimbărilor produse în dinamica acestora.
3. Procedură pentru detecția schimbărilor în semnalele de vibrație, conform revendicărilor 1 și 2, **caracterizată prin aceea că** utilizează o metodă de detecție/segmentare a entropiei Rényi, ca un nou spațiu de decizie, bazată pe estimatorul de probabilitate maximă a posteriori (MAP).
4. Procedură pentru detecția schimbărilor în semnalele de vibrație, conform revendicărilor 1, 2 și 3, **caracterizată prin aceea că** realizează și o pre-procesare a datelor de măsură, prin separarea ”oarbă” a surselor de vibrație independente, în scopul evidențierii schimbărilor produse în funcționarea mașinii (acestea sunt mult mai vizibile în sursele de vibrație independente, dacă în semnalele originale), dar și o post-procesare a rezultatelor detecției, prin calculul implicit al entropiei Rényi, și detecția schimbărilor în acest nou spațiu de decizie.
5. Procedură pentru detecția schimbărilor în semnalele de vibrație, conform revendicărilor 1, 2 și 3, **caracterizată prin aceea că** dezvoltă și implementează algoritmi și proceduri de calcul, pentru separarea ”oarbă” a surselor de vibrație independente utilizând algoritmul SOBI, calculul entropiei Rényi pe termen scurt și detecția schimbărilor/segmentare în entropia Rényi, utilizând estimatorul de probabilitate maximă a posteriori (MAP), ce face uz de o tehnică numerică de căutare bazată pe lanțuri Markov Monte Carlo (MCMC).

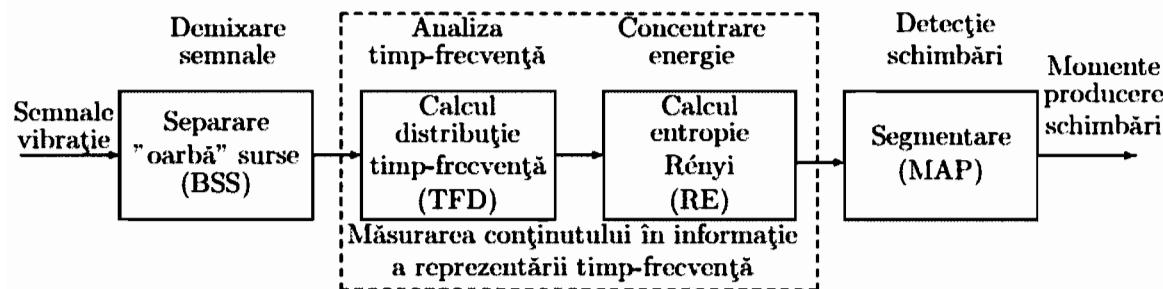


Figura 1

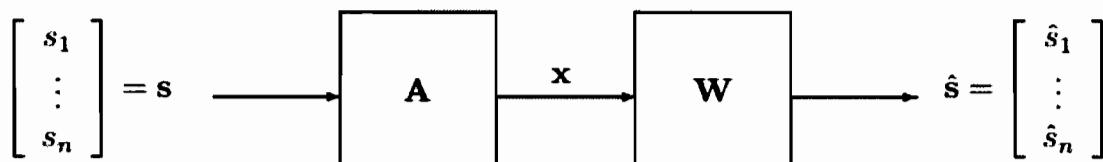


Figura 2

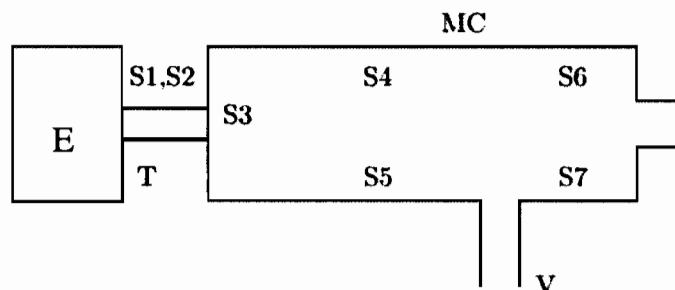


Figura 3

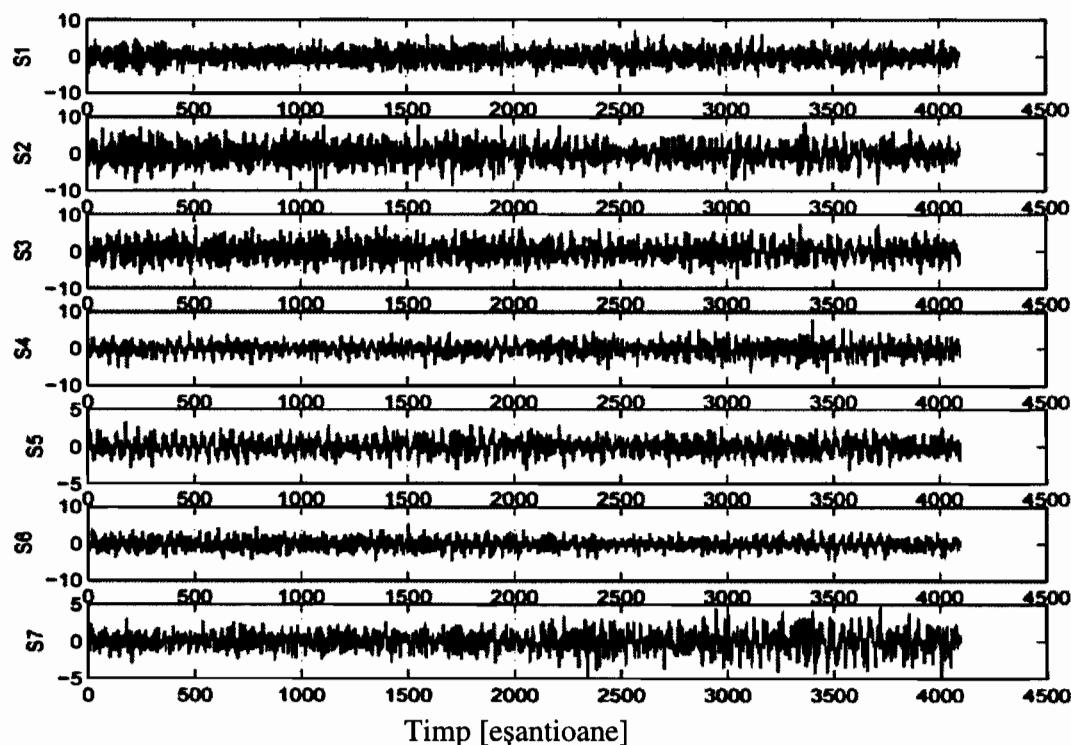
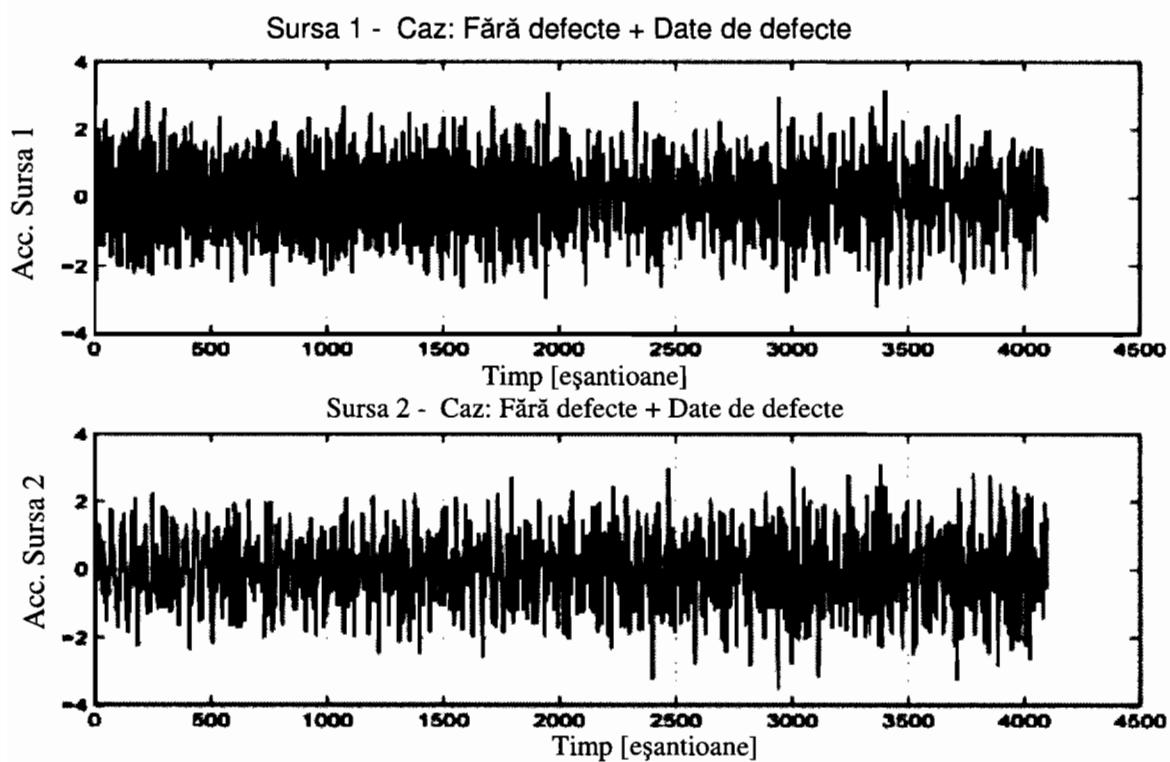
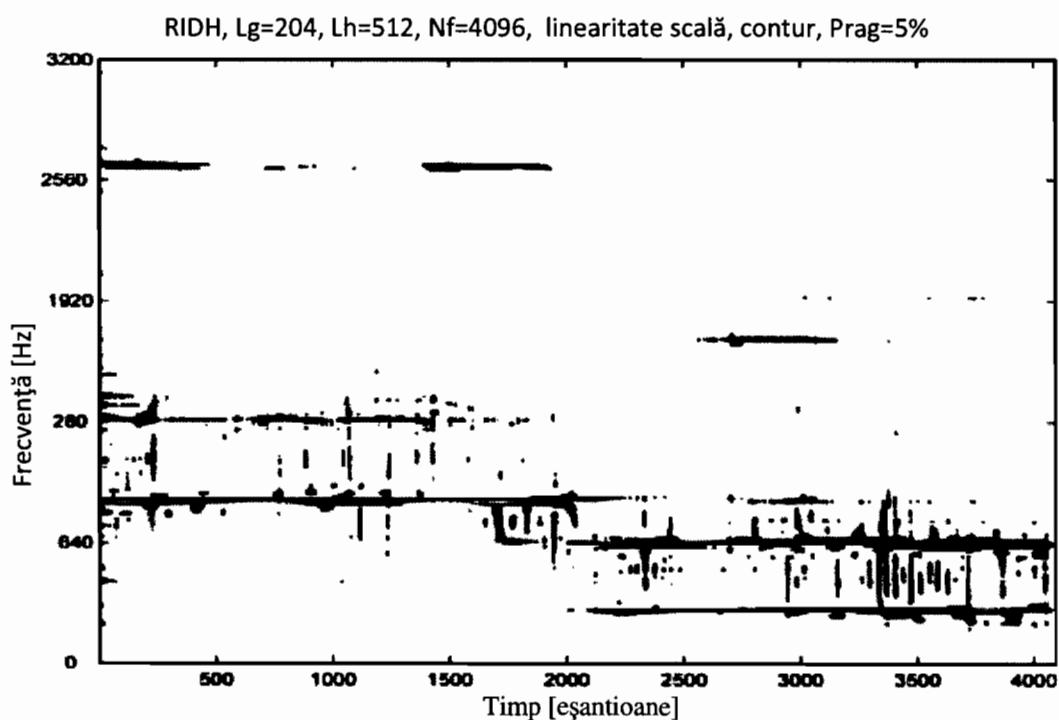
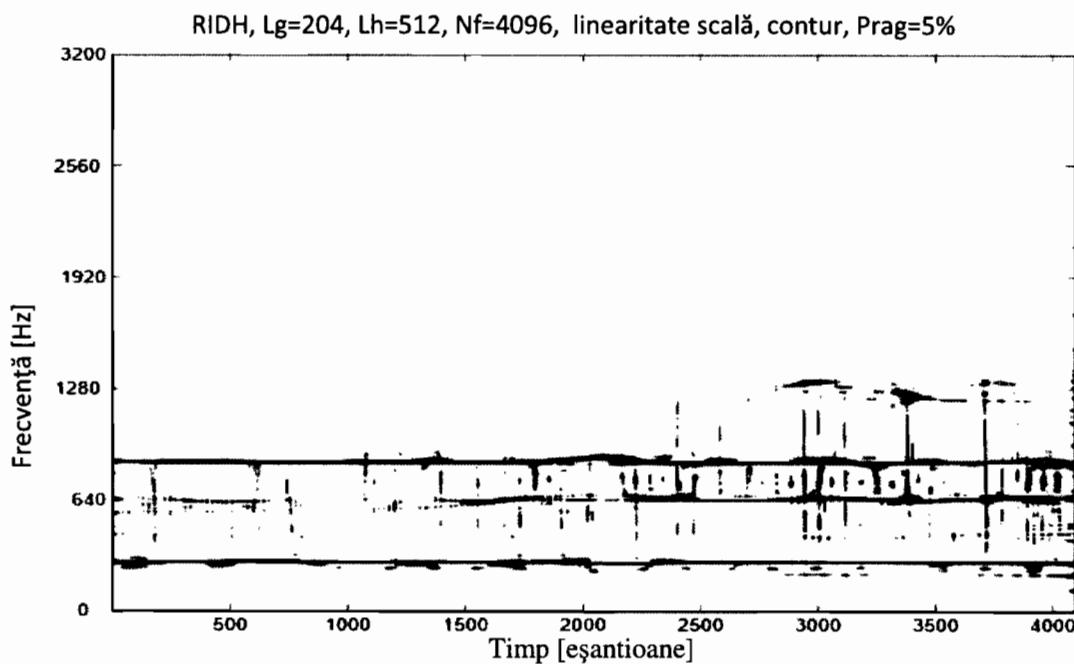
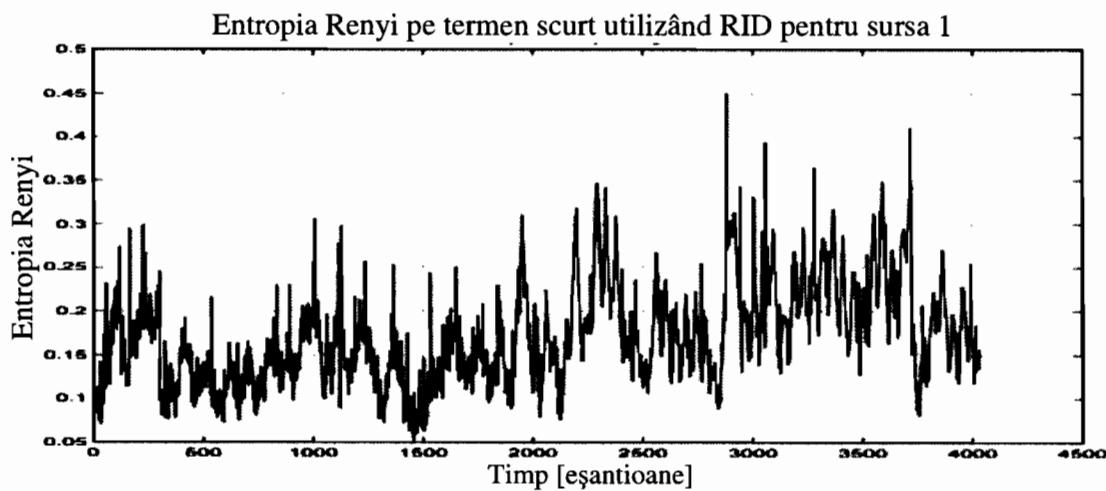
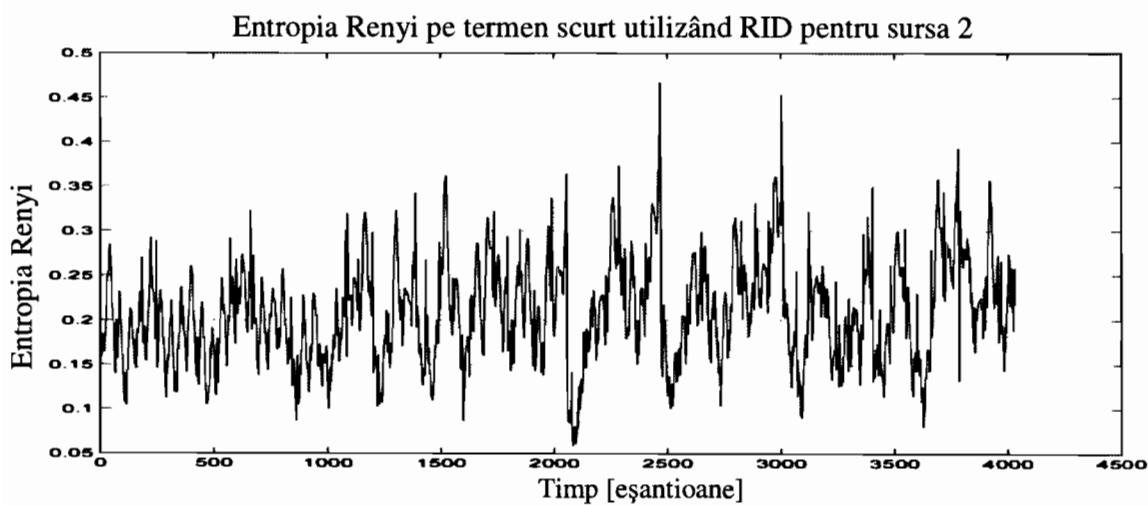


Figura 4

**Figura 5****Figura 6**

**Figura 7****Figura 8****Figura 9**

Entropia Renyi sursa 1- MAP

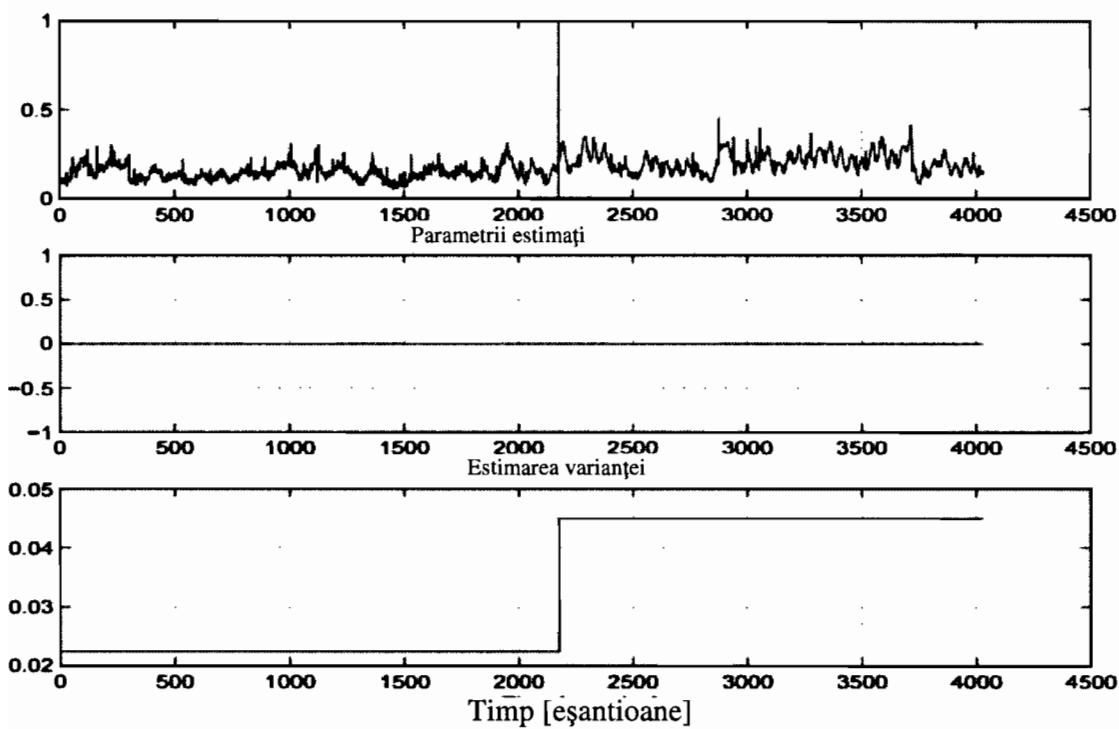


Figura 10

Entropia Renyi sursa 2 -

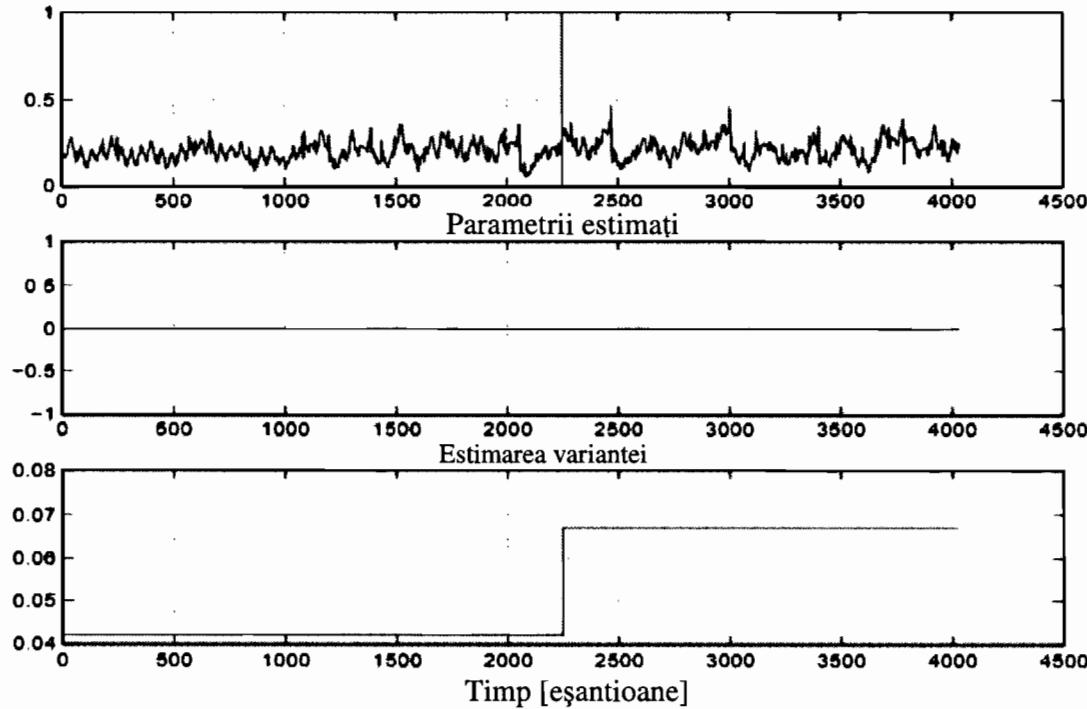


Figura 11

# PROCEDURĂ PENTRU MONITORIZAREA MAȘINILOR ROTATIVE UTILIZÂND SEPARAREA "OARBĂ" A SURSELOR DE VIBRAȚIE ȘI SEGMENTAREA ENTROPIEI RÉNYI

## DESCRIEREA INVENTIEI

### Titlul invenției

Procedură pentru monitorizarea mașinilor rotative utilizând separarea "oarbă" a surselor de vibrație și segmentarea entropiei Rényi

### Domeniul tehnic la care se referă invenția

Invenția se referă la o procedură de detecție a schimbărilor în semnalele de vibrație, cu aplicabilitate în monitorizarea stării de funcționare a mașinilor rotative, bazată pe separarea "oarbă" a surselor de vibrație și prelucrarea informației din planul timp-frecvență.

### Stadiul tehnicii în domeniu

Pe plan mondial se manifestă o cerință crescută în ceea ce privește înlocuirea procedurilor de întreținere sistematică, clasică, a mașinilor și utilajelor industriale prin strategii de întreținere conditională, bazate pe supravegherea continuă sau prin sondaj a comportării acestora, cu scopul de a preveni funcționarea anormală și a evita producerea unor catastrofe de natură economică sau ecologică. În acest context, apare ca soluție necesară, posibilă și eficientă, detecția din timp a functionării anormale a mașinilor și utilajelor industriale, în raport cu o caracterizare a acestora în modul de lucru normal: fără excitare artificială, schimbare a regimului de lucru sau oprire.

Problema detecției și diagnozei schimbărilor produse în mașinile și utilajele industriale, în scopul monitorizării și întreținerii conditionale a acestora, s-a bucurat de o atenție deosebită în ultimele două decenii, atât în cadrul cercetărilor, cât și al aplicațiilor în diferite domenii, aşa cum se specifică în lucrările aparținând lui Basseville și Nikiforov ("Detection of Abrupt Changes: Theory and Applications", Information and System Science Series, Prentice Hall, 1993), Isermann ("Supervision, fault-detection and fault-diagnosis methods - An introduction", Control Engineering Practice, 1997), Gertler ("Fault Detection and Diagnosis in Engineering Systems", Marcel Dekker, 1998), Gustafsson ("Adaptive Filtering and Change Detection", Wiley, NJ, 2001), Lipsett și Mechefske ("Fault detection using transient machine signals", Mechanical Systems and Signal Processing, 2008), printre alții. Din punct de vedere statistic, detecția schimbărilor caută să identifice schimbările în distribuția de probabilitate a unui proces stochastic.

O soluție clasică de rezolvare a acestei probleme constă în detecția incipientă a deviațiilor mici ale unor semnale de vibrație măsurate, în raport cu datele furnizate de o descriere parametrică a unui model, în condiții normale de lucru ale mașinii. Dacă pot fi detectate astfel de schimbări în fază incipientă, în raport cu schimbările în condițiile normale de operare, se poate spera prevenirea apariției unor variații mari ale unor mărimi, ca rezultat al producerii unor defecțiuni sau avarii, sau a stării de oboseală, înaintea producerii funcționării anormale a mașinii, și - în consecință - să crească disponibilitatea acesteia.

Multe soluții fac uz de teorii bazate pe statistică matematică, care furnizează instrumente de rezolvare a problemei detecției incipiente. Un algoritm pentru detecție implică în mod obișnuit două etape: generarea reziduurilor și luarea unei decizii. Reziduurile sunt valori analitice reprezentând diferența dintre comportarea observată, rezultată din măsurători, și comportarea așteptată a mașinii. Instrumentele clasice utilizate pentru generarea reziduurilor sunt filtrele și estimatoarele. În etapa de luare a deciziei, reziduurile sunt analizate și prelucrate utilizând reguli de decizie, pentru a determina starea mașinii sau utilajului, adică prezența sau absența unei schimbări în comportamentul acestora. Procesul de luare a deciziei poate consta într-un simplu "test de prag" sau poate implica utilizarea unui test statistic sistematic.

Există două abordări de bază în rezolvarea problemei detecției, care pot fi succint descrise ca fiind bazate pe modele cantitative, utilizând redundanță analitică, și pe modele calitative. Aceste două abordări pot fi combinate în mod convenabil pentru a crește robustețea generării reziduurilor cantitative. În cazul în care nu se dispune de modele analitice exacte, se poate face uz de modele bazate pe cunoștințe, modele fuzzy sau modele neuronale, în general modele rezultate din instruire. În ceea ce privește metodele de detecție bazate pe modele cantitative, pot fi menționate trei abordări principale, bazate pe identificare (estimarea parametrilor), observare (estimarea stării) și pe spațiul de paritate.

Un element esențial al problemei de detecție se referă la caracterizarea mașinii, sau a unei componente a acesteia, supusă monitorizării, pe perioade scurte de timp, în timpul regimului de funcționare normal. Această caracterizare poate fi obținută, fie prin modelarea mașinii, sau a unei componente a acesteia, fie prin modelarea semnalelor de vibrație măsurate în timpul funcționării mașinii. Variații mari în aceste semnale sunt interpretate ca posibile semne ale unei funcționări anormale a mașinii, datorate producerii unor defecțiuni ale acesteia. În esență, se pune problema găsirii unei descrieri adecvate a dinamicii mașinii, sau a unei componente a acesteia, care să poată fi apoi utilizată pentru detecție. În acest scop se va determina o "semnătură" sau "amprentă" ce va caracteriza mașina, sau o componentă a acesteia, operând în condiții normale de funcționare, prin intermediul modelării parametrice sau neparametrice.

Determinarea "semnături" se realizează în urma procesării semnalelor măsurate sau estimate. Dispunând de astfel de "semnături" și de un set nou de măsurători, se pune problema de a decide dacă măsurătorile sunt descrise adecvat de "semnătură", sau dacă s-a produs o schimbare în comportamentul mașinii, situație în care noile măsurători nu mai pot fi caracterizate de "semnătură". Există două soluții bazate pe evaluarea prin comparare a celor două "semnături", utilizând o funcție "distanță" convenabilă sau prin comparația directă a "semnături" disponibile cu noile măsurători. Soluția asigură construcția unor indicatori care permit măsurarea adecvanței unor "semnături" specifice cu noile măsurători, furnizând astfel și elemente pentru diagnoză.

În prezent în literatură sunt raportate abordări ce folosesc diferite măsuri de tip "distanță", inteligență artificială, logica fuzzy, recunoașterea formelor, etc. Unele caracteristici, cum ar fi nivelurile de amplitudine în domeniul timp, sunt extrase și clasificate ușor, dar sunt susceptibile la efectul zgromotului. Altele, cum ar fi concentrația de energie în domeniul timp-frecvență (a se vedea Stankovic, "A measure of some time-frequency distributions concentration", Signal Processing, 2001), chiar dacă implică mai mult efort, pot conduce în final la o detecție mai robustă în schimbările produse. Algoritmii de prelucrare a semnalelor, ce fac uz de modele

parametrice, pot fi utilizări pentru detecția schimbărilor, dacă se dispune de un model destul de precis al semnalului, în spațiul de reprezentare selectat. În ceea ce privește modelarea semnalelor nestaționare, aceasta este mai dificil de realizat, și nu se dispune de modele parametrice consistente, decât în puține cazuri. Cele mai multe din semnalele întâlnite în practică nu satisfac condițiile de staționaritate, ceea ce explică interesul crescut ce se manifestă în dezvoltarea unor tehnici specifice de prelucrare a acestora. Analiza timp-frecvență (TFA) (a se vedea Cohen, "Time-Frequency Distribution", Prentice Hall, New York, 1995), comparată cea clasică, formulată în general în domeniul timp, furnizează, în mod obișnuit, o înțelegere și interpretare mai simplă a comportării semnalelor nestaționare. Informația din planul timp-frecvență poate fi prelucrată utilizând diferite tehnici, în scopul detecției schimbărilor în semnalele ce fac obiectul analizei.

### Problema tehnică rezolvată de inventie

Cu toate rezultatele și extensiile metodelor de monitorizare a mașinilor rotative, bazate pe detecția schimbărilor în semnalele de vibrație, recent introduse în domeniu, ramân multe probleme deschise. Cea mai mare parte a procedurilor în acest domeniu sunt bazate pe ipoteze tari ("strong assumptions"), care - în mod obișnuit - sunt dificil de îndeplinit în practică. Soluția ce se propune tolerează o incertitudine mai mare privind dinamica sistemului (în cele mai multe cazuri necunoscută), mediul de lucru (nu există o abordare complet satisfăcătoare, care să lucreze în diferite medii de lucru, în general neliniare și variante în timp) și efectul zgomotului de intensitate mare, în general necunoscut. În opinia noastră, printre probleme centrale pe care soluția propusă își propune să le rezolve se numără robustețea, sensibilitatea și versatilitatea procedurii. Lipsa robusteței procedurilor existente se referă la eșecul funcționării acestora, dacă una din ipotezele pentru care au fost proiectate nu se verifică în totalitate în practică. Sensibilitatea se referă la abilitatea procedurilor de a semnala producerea unei schimbări, imediat după producerea acesteia, chiar în condițiile în care unii dintre parametrii procedurii s-au modificat, ca de exemplu anumiți parametri de proiectare sau structura filtrelor de estimare. În sfârșit, versatilitatea se referă la abilitatea metodelor și tehnicielor utilizate de a rezolva mai multe tipuri de probleme de monitorizare cu aceeași procedură. Procedura propusă în cadrul Cererii de brevet de inventie rezolvă parțial sau total problemele menționate anterior. Aceasta combină în premieră 3 tehnici de procesare a semnalelor de vibrație, ce se prezintă în Figura 1:

- Separarea "oarbă" a sursei de vibrație independente
- Măsurarea conținutului în informație a reprezentării timp-frecvență, prin estimarea entropiei Rényi
- Detecția schimbărilor în entropia Rényi și segmentarea acesteia

Totodată aceasta realizează și fuziunea informației rezultate în cele etape de prelucrare menționate anterior, în scopul realizării monitorizării eficiente a mașinii. Lucrul pe sursele independente, într-un nou spațiu de dimensiune redusă, în locul celui generat de semnalele de vibrație originale, simplifică problema de detecție, în acest caz numărul semnalelor ce fac obiectul analizei fiind mai mic, și mai mult, analiza se va realiza pe semnale monodimensionale. Procedura propriu-zisă de detecție se va aplica în final pe un semnal monodimensional, entropia Rényi, rezultată prin aplicarea unei transformate pe reprezentarea în planul timp-frecvență a semnalului analizat. Utilizarea unui test în acest nou spațiu de decizie, ca urmare a aplicării procedurii de detecție, va permite o înțelegere și interpretare mai simplă a comportării semnalelor nestaționare, și va conduce la detecția mai robustă a schimbărilor produse în dinamica semnalelor de vibrație, cu efecte asupra monitorizării mașinii sau a unor componente ale acesteia.

Procedura propusă realizează și o pre-procesare a datelor de măsură, semnalele de vibrație, prin separarea "oarbă" a surselor de vibrație independente, în scopul evidențierii schimbărilor produse în funcționarea mașinii, dar și o post-procesare a rezultatelor detecției, prin calculul implicit al entropiei Rényi, și detecția schimbărilor în parametrii modelului și în dispersia zgomotului.

## Expunerea invenției

Principalele etape ale procedurii ce face obiectul invenției, sunt reprezentate în Figura 1, și se prezintă în cele ce urmează.

### Borderou figurii

Figura 1 Principalele etape în procedura de monitorizare a mașinilor rotative ce utilizează separarea "oarbă" a surselor de vibrație și segmentarea entropiei Rényi

Figura 2 Mixarea și separarea semnalelor

Figura 3 Schema de măsurare multicanal: E = electromotor, MC = carcăsa mașină, T = tachometru, V = vană alimentare, S1-S7 = poziție senzori 1,7

Figura 4 Acceleratiile măsurate cu senzorii S1-S7

Figura 5 Sursele de vibrație independente rezultate în urma aplicării algoritmului SOBI pentru măsurătorile efectuate pe cele 7 canale

Figura 6 Distribuția timp-frecvență RID pentru sursa S1, în condițiile de funcționare normală și cu producerea unei defecțiuni a mașinii

Figura 7 Distribuția timp-frecvență RID pentru sursa S2, în condițiile de funcționare normală și cu producerea unei defecțiuni a mașinii

Figura 8 Entropia Rényi pe termen scurt pentru sursa S1

Figura 9 Entropia Rényi pe termen scurt pentru sursa S2

Figura 10 Segmentarea MAP a entropiei Rényi pentru sursa S1

Figura 11 Segmentarea MAP a entropiei Rényi pentru sursa S2

### Separarea "oarbă" a surselor de vibrație

Separarea "oarbă" a surselor (BSS) constă în estimarea surselor de vibrație independente care generează semnalele măsurate pe carcasa unei mașini, utilizând Analiza Componentelor Independente (ICA) (a se vedea Hyvärinen, Karhunen și Oja, "Independent Component Analysis", John Wiley, 2001).

Modelul presupus pentru BSS presupune existența a  $n$  semnale independente  $s_1(t), \dots, s_n(t)$  și măsurarea mixărilor liniare și instantanee ale acestora:  $x_1(t), \dots, x_n(t)$ :

$$x_i(t) = \sum_{j=1}^n a_{ij} s_j(t) + n_i(t) \quad (1)$$

pentru fiecare  $i = 1, n$ . Modelul poate fi reprezentat compact prin următoarea ecuație de înrixare:

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t) \quad (2)$$

unde  $\mathbf{s}(t) = [s_1(t), \dots, s_n(t)]^T$  este un vector coloană,  $n \times 1$ , ce conține semnalele sursă, în timp ce vectorul  $\mathbf{x}(t)$  conține  $n$  semnale observate, iar "matricea de mixare"  $\mathbf{A}$ ,  $n \times n$ , conține coeficienții de mixare.

BSS constă în estimarea vectorului sursă  $\mathbf{s}(t)$  folosind numai datele observate  $\mathbf{x}(t)$ , ipoteza de independentă a componentelor vectorului  $\mathbf{s}(t)$  și, posibil, unele informații a priori privind distribuția de probabilitate a intrărilor,  $\mathbf{s}(t)$ . Aceasta poate fi formulată ca estimarea unei "matrici de separare"  $\mathbf{W}$ ,  $n \times n$ , ale cărei ieșiri, vectorul  $\hat{\mathbf{s}}(t)$ , reprezintă o estimare a vectorului semnalelor sursă, în cazul unei mixări instantanee, având forma (vezi Figura 2):

$$\hat{\mathbf{s}}(t) = \mathbf{W}\mathbf{x}(t) \quad (3)$$

Elementul cheie în succesul aplicării unei metode de separare, constă în alegerea criteriului statistic în raport cu care se realizează separarea. Astfel, dacă semnalele sunt temporal coerente, este posibil să rezolve problema BSS folosind numai statistici de ordinul doi. În acest caz rezultă un algoritm, SOBI (Second Order Blind Identification), care estimatează sursele originale, pe baza autocorelațiilor pentru mai multe valori ale întârzierii și diagonalizarea aproximativă asociată acestora (a se vedea Belouchrani și alții, "A blind source separation technique using second - order statistics", IEEE Trans. Signal Processing, 1997). Această metodă prezintă avantajul că este ușor de implementat și conduce, în multe cazuri, la soluții liniare care necesită un efort de calcul redus, și folosește tehnici numerice standard.

Numărul surselor independente rezultă în urma descompunerii după valori proprii a matricei de covarianță eșantion,  $\hat{\mathbf{R}}_x(0) = \frac{1}{N} \sum_{t=1}^N \mathbf{x}(t)\mathbf{x}(t)^T$ , a vectorului măsurătorilor  $\mathbf{x}(t)$ .

$$\hat{\mathbf{R}}_x(0) = \mathbf{H}\Delta\mathbf{H}^T \quad (4)$$

unde

$$\mathbf{H} = [\mathbf{h}_1, \dots, \mathbf{h}_m]$$

și

$$\Delta = diag[\lambda_1, \dots, \lambda_m]$$

cu  $\lambda_i \geq \lambda_j$  for  $i < j$ . Numărul surselor independente poate fi estimat pe baza spectrului rezultat  $\Delta$ .

### Măsurarea conținutului în informație a reprezentării timp-frecvență folosind entropia Rényi

#### Analiza timp-frecvență

Obiectivul de bază al analizei timp-frecvență (TFA) este de a dezvolta o funcție care să permită descrierea modului în care densitatea de energie a semnalului este distribuită în domeniul timp,  $t$ , și frecvență,  $\omega$ . O astfel de funcție transformă semnalul din domeniul monodimensional timp într-o reprezentare bidimensională a energiei în raport cu timpul și frecvența.

Reprezentările timp-frecvență (TFR) pot fi clasificate în raport cu abordările de analiză utilizate. O categorie de distribuții timp-frecvență (TFD), frecvent utilizate sunt distribuțiile de clasă Cohen și sunt caracterizate printr-o funcție nucleu. Proprietățile reprezentării sunt reflectate prin simple restricții asupra nucleului care produc TFR cu proprietăți dorite, prescrise. O descriere matematică a acestor TFR poate fi dată de

$$TFD_x(t, \omega) = \frac{1}{4\pi^2} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x(u + \frac{1}{2}\tau) \times \quad (5)$$

$$x^*(u - \frac{1}{2}\tau)\phi(\theta, \tau) \exp^{-j\theta t - j\tau\omega + j\theta u} dud\tau d\theta$$

unde  $\phi(\theta, \tau)$  este o funcție nucleu bidimensională, determinând reprezentarea specifică în această categorie, și prin urmare, proprietățile reprezentării. Distribuția de bază în cadrul acestei abordări este distribuția Wigner (WD).

$$WD_x(t, \omega) = \int_{-\infty}^{+\infty} x(t + \frac{1}{2}\tau)x^*(t - \frac{1}{2}\tau) \exp^{-j\tau\omega} d\tau. \quad (6)$$

Nucleul acesteia este  $\phi(\theta, \tau) = 1$ . De asemenea, spectrograma (SP), distribuția Choi-Williams (CWD) și distribuția binomială (BD) sunt cateva dintre metodele utilizate pentru obținerea TFD. Distribuția Choi-Williams (CWD) și distribuția binomială (BD) suprimă în mare măsură interferența cross-termenilor, dar cu prețul unei pierderi a rezoluției timp-frecvență. Aceste distribuții aparțin așa-numitelor distribuții cu interferență redusă (RID), și aparțin, de asemenea, clasei Cohen. Fiecare membru al clasei generale Cohen poate fi interpretat ca fiind ca o distribuție WD, filtrată bidimensional.

### Entropia Rényi a reprezentării timp-frecvență

Una din cele mai simple proceduri de caracterizare a unui semnal, în TFA, se poate realiza prin intermediul concentrării energiei acestuia. Ideea constă în analiza concentrației energiei semnalului la anumite momente de timp sau benzi de frecvență, sau mai general, în anumite regiuni de timp și frecvență. O astfel de analiza este capabilă să furnizeze mai multă informație în legătură cu un fenomen particular. Analiza reprezentării timp-frecvență, folosind concentrarea energiei, face obiectul mai multor lucrări (a se vedea Sejdic, Djurovic și Jiang, "Time-frequency feature representation using energy concentration: An overview of recent advances", Digital Signal Processing, 2009), care furnizează diferite măsuri pentru energie, fiind utilizate norme cu distribuții la puteri egale sau mai mici decât unitatea (a se vedea Stankovic "A measure of some time-frequency distributions concentration", Signal Processing, 2001). Există mai multe astfel de măsuri bazate pe entropia Rényi, capabile de a realiza analiza cantitativă în descrierea cantității de informație conținută în distribuția timp-frecvență, care să fie utilizată la detecția schimbărilor în semnalele de vibrație.

Odată ce a fost obținut conținutul în frecvență local, utilizând una din distribuțiile timp-frecvență prezентate anterior, poate fi evaluată o nouă măsură a entropiei, pentru o valoare dată a timpului,  $t = n$ .

Clasa măsurilor entropiei Rényi a fost introdusă în analiza timp-frecvență de Sang și Williams ("Rényi information and signal dependent optimal kernel design", Proc. of the ICASSP, 1995). Entropiile generalizate Rényi au inspirat noi măsuri pentru estimarea informației conținută în semnal și complexitatea acestuia în planul timp-frecvență. Aceste măsuri posedă mai multe proprietăți utile și interesante, cum ar fi luarea în considerare a cross-termenilor și a invarianților transformării, ceea ce le face de interes pentru măsurarea conținutului în informație a reprezentării timp-frecvență.

Pentru o distribuție timp-frecvență generică,  $P_x(n, k)$ , măsura entropiei Rényi are forma următoare:

$$RE_\alpha = \frac{1}{1-\alpha} \log_2 \left( \sum_n \sum_k P_x^\alpha(n, k) \right) \quad (7)$$

unde  $n$  este variabila discretă temporală, iar  $k$  variabila discretă frecvență, cu  $\alpha \geq 2$  valori recomandate pentru măsuri ale distribuției timp-frecvență. Pentru cazul  $\alpha = 2$  (energia distribuției) termenii cross vor crește energia, conducând la concluzia falsă privind îmbunătățirea concentrației,

Cazul  $\alpha = 3$  eșuează în a detecta existența cross-termenilor diferenți de zero oscilatorii (care nu se suprapun peste auto-termeni), deoarece pentru valori impare  $\alpha$  aceștia nu contribuie la valoarea acestei măsuri. Acestea au fost motivele introducerii măsurilor entropiei Rényi normalize, care vor fi trecute în revistă în continuare. Normalizarea poate fi făcută în diferite moduri, conducând la o varietate de măsuri posibile.

Eisberg și Resnik ("Quantum Physics", Wiley, 1994) asimilează distribuțiile timp-frecvență la un moment de timp dat,  $t = n$ , cu o funcție de undă și în cazul general, pentru  $\alpha = 3$ , rezultă

$$RE_3 = -\frac{1}{2} \log_2 \left( \sum_n \sum_k P_x^3(n, k) \right) \quad (8)$$

Etapa de normalizare afectează exclusiv indexul  $k$ , când operația este restricționată la o singură poziție  $n$ , pentru a satisface condiția  $\sum_k P_x(n, k) = 1$  într-o astfel de poziție.

Măsura (8) poate fi rescrisă pentru un  $n$  dat astfel:

$$RE_3(n) = -\frac{1}{2} \log_2 \left( \sum_k P_x^3(n, k) \right) \quad (9)$$

Empiric, normalizarea propusă s-a dovedit a fi cea mai potrivită pentru aplicații în analiza semnalelor. Valorile lui  $RE_3(n)$  depind de dimensiunea  $N$  a fereastrării de date și se poate arăta că acestea se situează în intervalul  $0 \leq RE_3(n) \leq \log_2 N$ . Prin urmare, măsura poate fi normalizată aplicând relația:  $\hat{RE}_3(n) = RE_3(n) / \log_2 N$ .

### Segmentarea entropiei Rényi utilizând estimatorul MAP

#### Formularea problemei

Segmentarea entropiei Rényi pe termen scurt se va realiza utilizând modele de regresie liniară cu parametrii constanți pe porțiuni. Aceasta rezultă în urma detecției momentelor producerii unor schimbări în entropia Rényi. Problema constă în a găsi o secvență de indici de timp,  $k^n = k_1, k_2, \dots, k_n$ , unde atât numărul  $n$  cât și locațiile  $k_i$  sunt necunoscute, astfel încât un model de regresie liniară cu parametrii constanți pe porțiuni,

$$y_t = \phi_t^T \theta(i) + e_t, \quad E(e_t^2) = \lambda(i) \quad (10)$$

unde  $k_{i-1} < t \leq k_i$ , să realizeze o bună aproximare a entropiei Rényi,  $y_t$ , presupusă a avea  $N$  eșantioane;  $\theta(i)$  este vectorul parametrilor modelului, de dimensiune  $d$ , pentru segmentul  $i$ ,  $\phi_t$  este vectorul regresorilor ce conține valorile entropiei Rényi la momente anterioare, iar  $k_i$  reprezintă momentele producerii schimbării. Zgomotul  $e_t$  se presupune a fi Gaussian, de dispersie  $\lambda(i)$ , depinzând de segment. Atât  $\theta(i)$ , cât și  $\lambda(i)$  sunt necunoscuți.

O cale de garantare a faptului că a fost găsită cea mai bună soluție posibilă constă în a considera toate segmentările posibile,  $k^n$ , de a estima câte un model de regresie liniară în fiecare segment, și de a alege în final segmentarea particulară  $k^n$  care minimizează criteriile de optimalitate:

$$\widehat{k^n} = \arg \min_{n \geq 1, 0 < k_1 < \dots < k_n = N} V(k^n) \quad (11)$$

Pentru măsurătorile din segmentul  $i$ , adică  $y_{k_{i-1}+1}, \dots, y_{k_i} = y_{k_{i-1}+1}^{k_i}$ , vectorul estimărilor parametrilor modelului cu metoda celor mai mici pătrate (LS) și matricea sa de covarianță sunt date de:

$$\hat{\theta}(i) = P(i) \sum_{t=k_{i-1}+1}^{k_i} \phi_t y_t, \quad (12)$$

$$P(i) = \left( \sum_{t=k_{i-1}+1}^{k_i} \phi_t \phi_t^T \right)^{-1}. \quad (13)$$

Mărimile  $V$  = suma pătratelor reziduurilor,  $D = -\log \det P$  și  $N$  = numărul de date din fiecare segment sunt date de

$$V(i) = \sum_{t=k_{i-1}+1}^{k_i} (y_t - \phi_t^T \hat{\theta}(i))^2 \quad (14)$$

$$D(i) = -\log \det P(i) \quad (15)$$

$$N(i) = k_i - k_{i-1} \quad (16)$$

și reprezintă statistici suficiente în fiecare segment. Datele și statisticile utilizate în procedura de segmentare sunt prezentate în Tabelul 1.

Table 1: Datele și statisticile utilizate în procedura de segmentare

Date	$y_1, y_2, \dots, y_{k_1}$	...	$y_{k_{n-1}+1}, \dots, y_{k_n}$
Segment	Segment 1	...	Segment n
Estimație LS	$\hat{\theta}(1), P(1)$	...	$\hat{\theta}(n), P(n)$
Statistică	$V(1), D(1), N(1)$	...	$V(n), D(n), N(n)$

Se poate observa că segmentarea  $k^n$  are  $n - 1$  grade de libertate. În literatură au fost propuse două tipuri de criterii de optimalitate pentru rezolvarea problemei: criterii statistice (verosimilitate maximă (ML) sau probabilitate maxima a posteriori (MAP)) și criterii bazate de informație. Problema principală în segmentare este cea a dimensionalității. Numărul de posibile segmentări  $k^n$  este  $2^N$  (se poate produce sau nu o schimbare la fiecare moment de timp).

#### Estimatorul de probabilitate maximă a posteriori (MAP)

Descrierea conceptuală a estimatorului de probabilitate maximă a posteriori (MAP) (a se vedea Popescu, "Signal segmentation using changing regression models with application in seismic engineering", Digital Signal Processing, 2014), pentru datele și mărimile date în Tabelul 1 include următoarele etape de calcul:

**Etapa 1.** Se examinează separat fiecare segmentare posibilă, parametrizată prin numărul de schimbări,  $n$ , și momentele de producere a acestora,  $k^n$ .

**Etapa 2.** Pentru fiecare segmentare, se calculează cele mai bune modele în fiecare din segmente, sub forma estimației celor mai mici pătrate a parametrilor,  $\hat{\theta}(i)$ , și a matricei de covarianță a acestora,  $P(i)$ .

**Etapa 3.** Se calculează în fiecare segment suma pătratelor erorilor de predicție,  $V(i)$  și  $D(i) = -\log \det P(i)$ .

**Etapa 4.** Estimația MAP a structurii modelui pentru trei ipoteze privind scalarea zgomotului: (i)  $\lambda(i) = \lambda_0$  cunoscut, (ii)  $\lambda(i) = \lambda$  necunoscut, dar constant, (iii)  $\lambda(i)$  necunoscut și variabil, este dată de următoarele ecuații:

$$\widehat{k^n} = \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + V(i)) + 2n \log \frac{1-q}{q} \quad (17)$$

$$\widehat{k^n} = \arg \min_{k^n, n} \sum_{i=1}^n D(i) + (N - nd - 2) \log \sum_{i=1}^n \frac{V(i)}{N - nd - 4} + 2n \log \frac{1-q}{q} \quad (18)$$

$$\widehat{k^n} = \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + (N(i) - d - 2) \log \frac{V(i)}{N(i) - d - 4}) + 2n \log \frac{1-q}{q} \quad (19)$$

unde  $q$  este probabilitatea producerii unei schimbări la fiecare moment de timp ( $0 < q < 1$ ). Pentru  $q = 0.5$ , estimatorul MAP devine estimatorul de verisimilitate maximă(ML).

Urmează a se va evalua una din ecuațiile (17)-(19), în funcție de ipoteza care se face privind scalarea zgometului (a se vedea **Etapa 4.**).

Calculul verosimilității exacte este greu de efectuat din cauza complexității exponențiale. În această situație se utilizează algoritmi ce implementează tehnici recursive de căutare locale sau tehnici numerice de căutare bazate pe programarea dinamică sau tehnici de tip lanțuri Markov Monte Carlo (MCMC) (a se vedea Gustafsson, "Adaptive Filtering and Change Detection", Wiley, NJ, 2001).

### Avantaje invenție în raport cu stadiul tehnicii

Avantajele pe care soluția propusă le prezintă, comparativ cu soluțiile cunoscute în prezent, sunt:

- Lucrul pe sursele independente încr-un nou spațiu de dimensiune redusă, față de cel al semnalelor de vibrație originale, simplifică problema de detecție. În acest caz numărul semnalelor ce fac obiectul analizei este mai mic, și mai mult, analiza se va realiza pe semnale monodimensionale.
- Aplicarea procedurii propriu-zise de detectie/segmentare se va aplica în final pe un semnal monodimensional, entropia Rényi, rezultată prin aplicarea unei transformate pe reprezentarea bidimensională din planul timp-frecvență. Utilizarea unui test statistic în cadrul procedurii de detectie/segmentare, în acest nou spațiu de decizie, va permite o înțelegere și interpretare mai simplă a comportării semnalelor nestaționare, și va conduce la detecția mai robustă a schimbărilor produse în dinamica semnalelor de vibrație, cu efecte asupra monitorizării mașinii sau a unor componente ale acesteia.
- Procedura ce face obiectul invenției va permite realizarea unei fuziuni a informației rezultate în cele 3 etape de prelucrare menționate anterior, în scopul unei monitorizări eficiente a mașinii, cu evitarea unor alarme false privind necesitatea efectuării unei revizii, și va furniza informații suplimentare în scop de diagnoză.
- Procedura propusă realizează și o pre-procesare a datelor de măsură, prin separarea "oară" a surselor de vibrație independente, în scopul evidențierii schimbărilor produse în funcționarea mașinii (acestea apar mult mai vizibile în sursele de vibrație independente, dacă în semnalele originale), dar și o post-procesare a rezultatelor detecției, prin calculul implicit al entropiei Rényi, și detecția schimbărilor în parametrii modelului și în dispersia zgometului.

### Modul de realizare și aplicare a invenției

Realizarea și aplicarea invenției constă în prelucrarea datelor de măsură, semnale de vibrație măsurate pe mașină sau utilajul tehnologic, conform procedurii descrise în Secțiunea 5, și pentru care a fost dezvoltat suportul software necesar. Realizarea și aplicarea invenției sunt exemplificate printr-un studiu de caz, pentru o mașină rotativă, o pompă industrială de mare capacitate.

### Datele de măsură

O schemă a pompei industriale, cu componente sale și poziția senzorilor este dată în Figura 3. Semnalele de vibrație, accelerăriile pe 7 canale, sunt măsurate pe carcasa mașinii. Măsurările au fost repetate pe două mașini identice, prima aflată în regim de funcționare normal, iar pentru cea de a doua s-a procedat la inducerea unei defecțiuni la cutia de viteze. Măsurările, efectuate în regim de încărcare minimă și maximă, la joasă și înaltă frecvență au fost obținute în cadrul proiectului "Machine diagnostics by neural networks project", realizat de TechnoFysica, The Netherlands.

În cadrul analizei au fost selectate măsurările efectuate la înaltă frecvență, eșantionate cu 12800 Hz, și un segment de date de 4096 valori, 2048 de la pompa aflată în regim de funcționare normal, și 2048 de la pompa la care a fost indusă defecțiunea la cutia de viteze, ambele la încărcare minimă. Date au fost filtrate trece jos la 5000 Hz. Accelerăriile măsurate de senzorii S1-S7 sunt reprezentate în Figura 4.

Din cauza mixării principalelor surse de vibrație, din datele măsurate pe carcasa mașinii este dificil de stabilit momentul producerii unei defecțiuni la mașina ce face obiectul monitorizării. Din acest motiv, s-a procedat, într-o primă etapă, la transferul problemei de monitorizare din spațiul original al măsurătorilor, în spațiul surselor independente de vibrație. Aceasta a permis efectuarea analizei într-un spațiu de dimensiune redusă, iar aplicarea metodei de detecție/segmentare s-a va făcut pe semnale monodimensionale, ceea ce a condus la simplificarea în mare măsură a analizei.

### Separarea "oarbă" a surselor

Măsurările accelerărilor efectuate pe cele 7 canale conținând 4098 valori, de la cele două mașini, una aflată în regim de funcționare normal, iar cealaltă având indusă o defecțiune, au reprezentat datele de intrare pentru algoritmul SOBI de estimarea a surselor independente de vibrație, în cazul modelului de mixare instantaneu; aplicarea procedurii de estimare a numărului surselor independente, prezentată în Secțiunea 2 a condus la 2 surse independente. Sursele rezultate sunt reprezentate în Figura 5.

### Analiza timp-frecvență și calculul entropiei Rényi

Figura 6 prezintă distribuția timp-frecvență RID pentru sursa S1, cu utilizarea unei fereastre Hanning. Aceasta a fost calculată pentru un număr de puncte de frecvență,  $N_f = 4096$ , identic cu momentele de timp utilizate, o fereastră de netezire în timp,  $g(u)$ , de dimensiune  $L_g = 204$ , o fereastră de netezire în frecvență,  $h(\tau)$ , de dimensiune  $L_h = 512$ , și un prag de 5%. În Figura 6, reprezentată la scală liniară, se poate observa producerea unei schimbări în conținutul spectral al sursei S1, în cea de a doua parte a semnalului.

Resultatele analizei timp-frecvență pentru sursa S2 sunt prezentate în Figura 7, pentru același tip de distribuție, RID, utilizând o fereastră Hanning și aceeași parametru, ca în cazul analizei sursei S1. În cazul de față se poate constata o schimbare mai redusă a conținutului spectral al sursei S2, în cea de a doua parte a semnalului, în comparație cu schimbarea de conținut spectral produsă în sursa S1.

O primă concluzie în această etapă a analizei, ar fi că sursa de vibrație S1 a fost indusă de producerea unei defecțiuni în funcționarea mașinii, ținând seama și de valoarea schimbării

în conținutul spectral al acesteia. Deoarece separarea surselor nu este realizată perfect, există posibilitatea ca o schimbare reală produsă într-o din surse să poată fi indușă și în alte surse, în cazul nostru în sursa S2, dar schimbarea în conținutul spectral al acestei surse este de valoare redusă în raport cu sursa S1.

Pentru a evalua rezultatele analizei timp-frecvență pentru sursa S1, prezentăm în Figura 8 entropia Rényi pe termen scurt, ca măsură a concentrației distribuției timp-frecvență, calculată cu RID; s-a utilizat o fereastră alunecătoare de dimensiune  $N = 64$  și o constantă de deviere, adăugată la valoarea semnalului egală cu 1. Entropia Rényi pe termen scurt pentru sursa S2, utilizând aceleași valori pentru fereastra alunecătoare și constantă de deviere, este reprezentată în Figura 9.

### Segmentarea MAP a entropiei Rényi

Analiza vizuală a entropiei Rényi pentru ambele surse, scoate în evidență faptul există un moment de timp în care se produce o schimbare în conținutul de energie și de frecvență. Pe baza experienței anterioare în analiza unor semnale similare, un model cu parametri constanți pe porțiuni poate conduce la un compromis satisfăcător între complexitatea și eficiența algoritmilor de estimare off-line a momentelor producerii unor schimbări în dinamica semnalului. Procedura de detectie a schimbărilor în cazul celor două entropii Rényi s-a realizat cu estimatorul MAP, în cazul unui zgromot constant necunoscut, cu următoarele valori ale parametrilor de proiectare:  $q = 0.3$ ,  $M = 10$ ,  $ll = 8$  și  $mseg = 700$  (a se vedea Popescu, "Signal segmentation using changing regression models with application in seismic engineering", Digital Signal Processing, 2014).

Procedura de segmentare a fost realizată pentru un model autoregresiv AR(1) de forma:

$$y_t = -\phi_1 * y_{t-1} + e_t \quad (20)$$

Estimările parametrilor modelului și ale dispersiei zgromotului rezultate în urma aplicării algoritmului bazat pe estimatorul MAP, pentru entropiile Rényi ale celor două surse sunt prezentate în Figura 10 și respectiv în Figura 11.

Valorile dispersiei zgromotului modelului cu parametrii constanți pe porțiuni, în cazul ambelor surse, prezintă salturi semnificative în cea de a doua parte a semnalului, ceea ce denotă un fenomen de ruptură, datorat inducerii defecțiunii în funcționarea mașinii.

### Aplicarea în mediul industrial a invenției

În ceea ce privește aplicarea în mediul industrial a invenției, considerăm ca posibile următoarele moduri de utilizare:

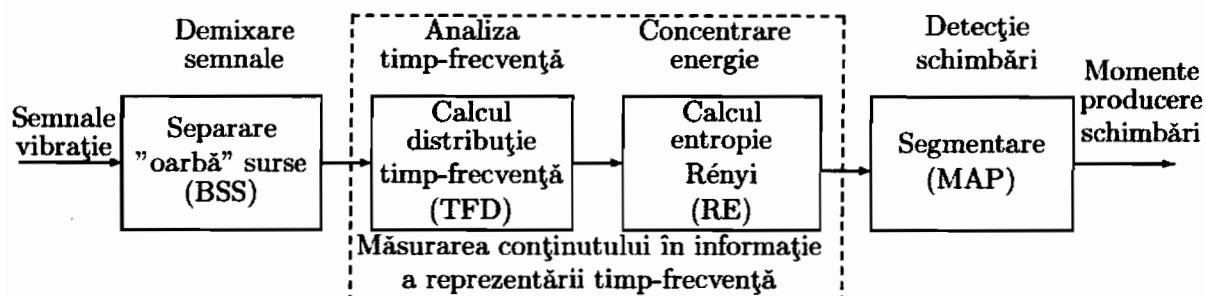
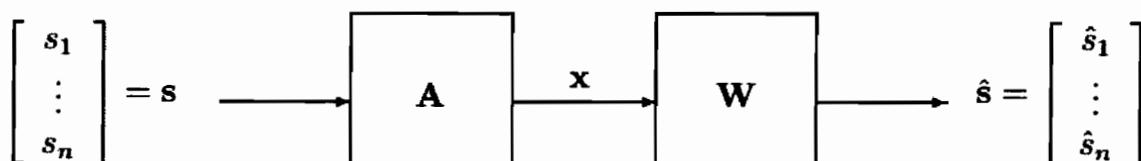
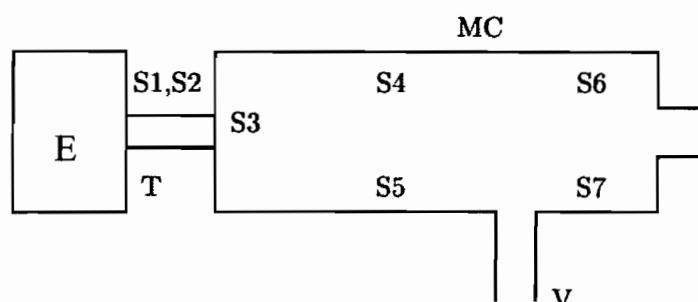
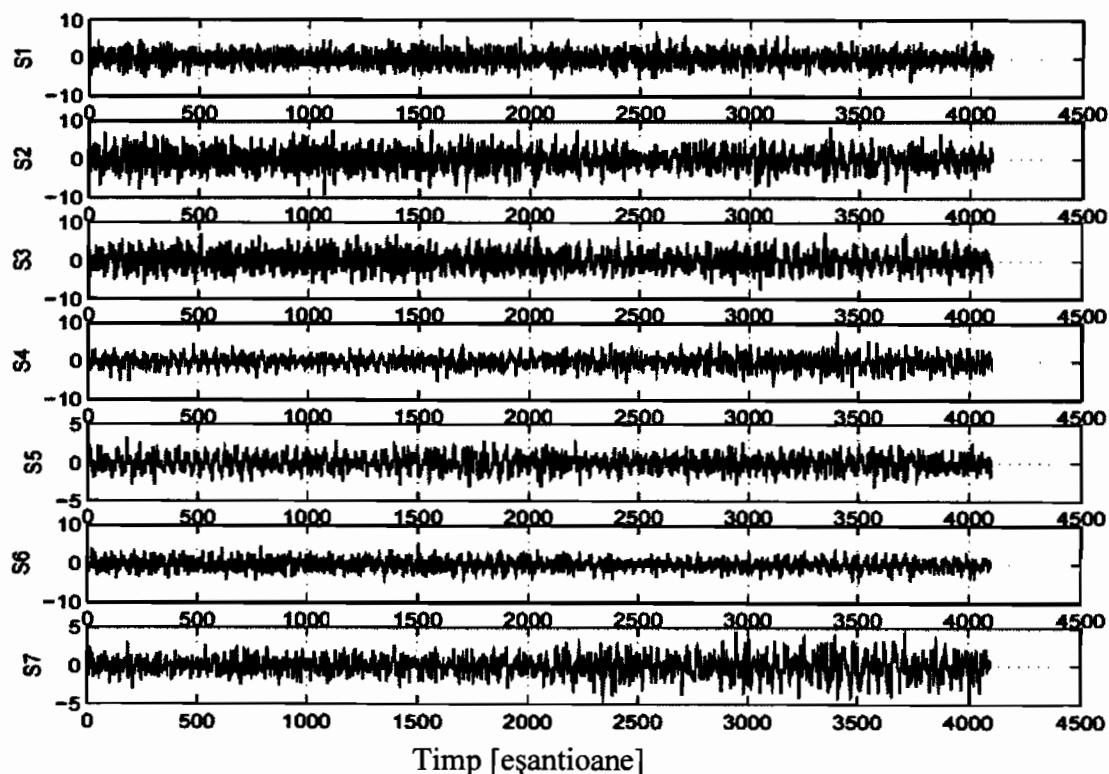
- Dispunând de o înregistrare de date, semnale de vibrație, acestea pot fi analizate utilizând cele 3 etape incluse în procedura ce face obiectul invenției. Rezultatele obținute oferă o imagine de ansamblu asupra proceselor vibratorii specifice mașinii rotative, sau componentelor acesteia, ce fac obiectul monitorizării.
- În cazul în care se dispune de o înregistrare de probă a semnalelor de vibrație din funcționarea normală a mașinii rotative, sau a componentelor acesteia, (înregistrare "martor"), aceasta poate fi concatenată cu o înregistrare curentă din funcționarea mașinii rotative, sau a componentelor acesteia, semnalul rezultat urmând să fie analizat cu prelucrările menționate în cele 3 etape ale procedurii ce face obiectul invenției, în urma analizei rezultând dacă datele celor două înregistrări sunt consistente, sau dacă s-a produs o schimbare în funcționarea mașinii, sau a componentelor acesteia, situație în care pe baza acestor rezultate și a unor informații ce țin de experiența utilizatorului se poate trece la diagnoză și localizarea posibilei defecțiuni.

De menționat faptul că invenția poate fi aplicată nu numai în domeniul monitorizării stării de bună funcționare a mașinilor rotative și a componentelor acestora, ci și în alte domenii cum ar fi: industria energetică (turbine, generatoare, etc.), ingineria civilă (clădiri mari supuse acțiunii vântului și miscările seismice, poduri, baraje, platforme marine), aeronaumatică (structuri și componente supuse solicitărilor), automobile și sisteme de transport, etc.

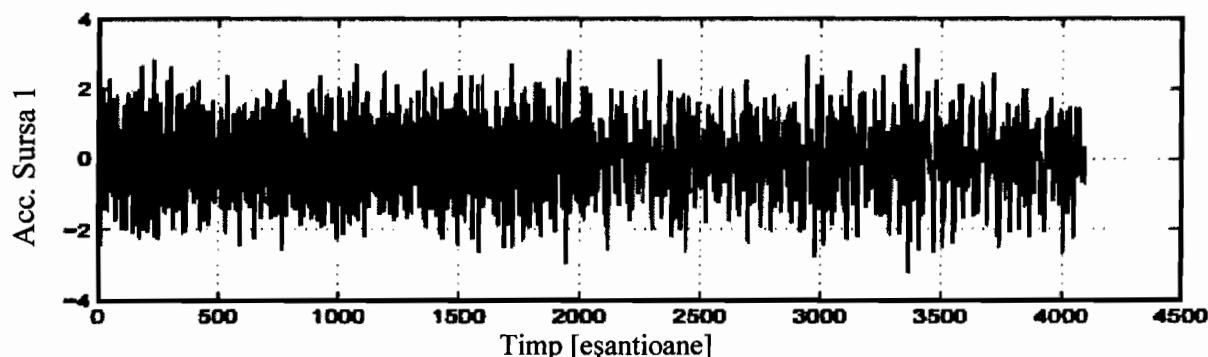
# PROCEDURĂ PENTRU MONITORIZAREA MAŞINIILOR ROTATIVE UTILIZÂND SEPARAREA "OARBĂ" A SURSELOR DE VIBRAȚIE ȘI SEGMENTAREA ENTROPIEI RÉNYI

## REVENDICĂRI

Procedură pentru monitorizarea mașinilor rotative, bazată pe analiza vibrațiilor, caracterizată prin aceea că face uz de procesarea semnalelor de vibrație, așa cum se prezintă în Figura 1, ce combină în premieră separarea "oarbă" a surselor de vibrație independente, măsurarea conținutului în informație a reprezentării timp-frecvență, prin estimarea entropiei Rényi, și detectia schimbărilor în aceasta, printr-o tehnică de segmentare bazată pe estimatorul de probabilitate maximă a posteriori (MAP), fapt ce permite analiza vibratiilor într-un spațiu de decizie de dimensiune redusă și asigură creșterea robusteției procedurii la acțiunea factorilor perturbatori.

**Figura 1****Figura 2****Figura 3****Figura 4**

Sursa 1 - Caz: Fără defecte + Date de defecte



Sursa 2 - Caz: Fără defecte + Date de defecte

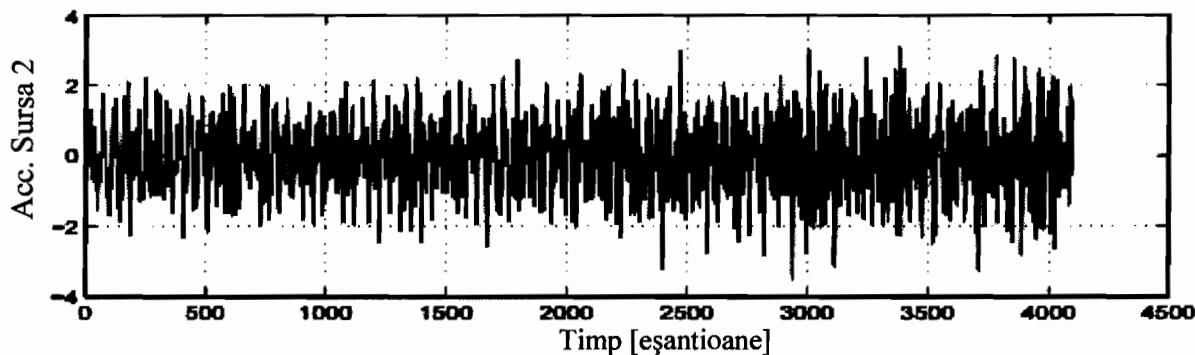


Figura 5

RIDH, Lg=204, Lh=512, Nf=4096, linearitate scală, contur, Prag=5%

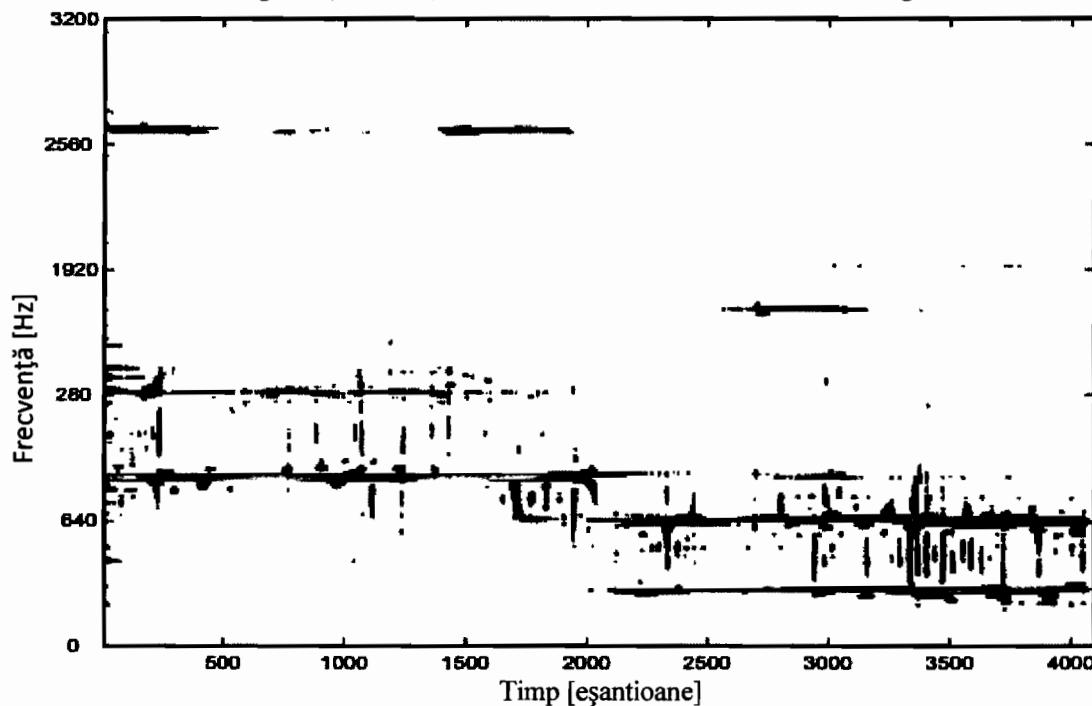
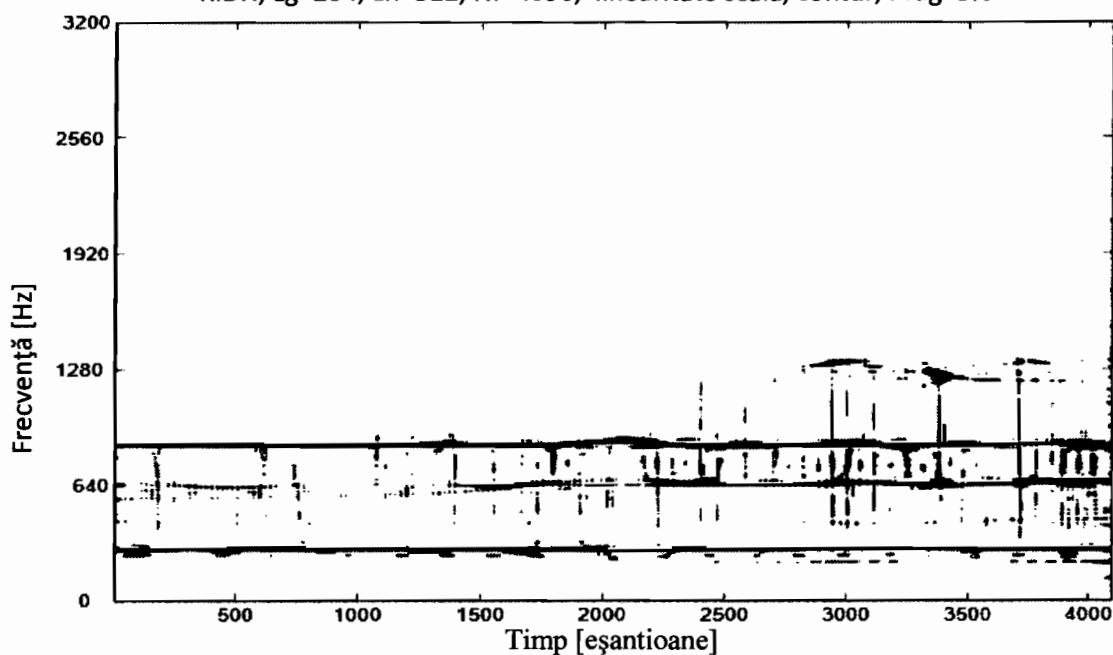


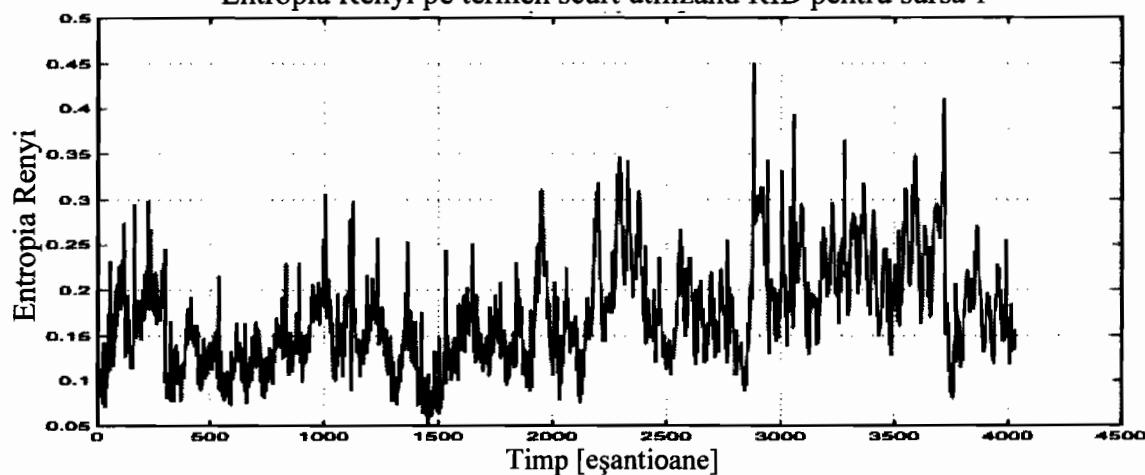
Figura 6

RIDH, Lg=204, Lh=512, Nf=4096, linearitate scală, contur, Prag=5%



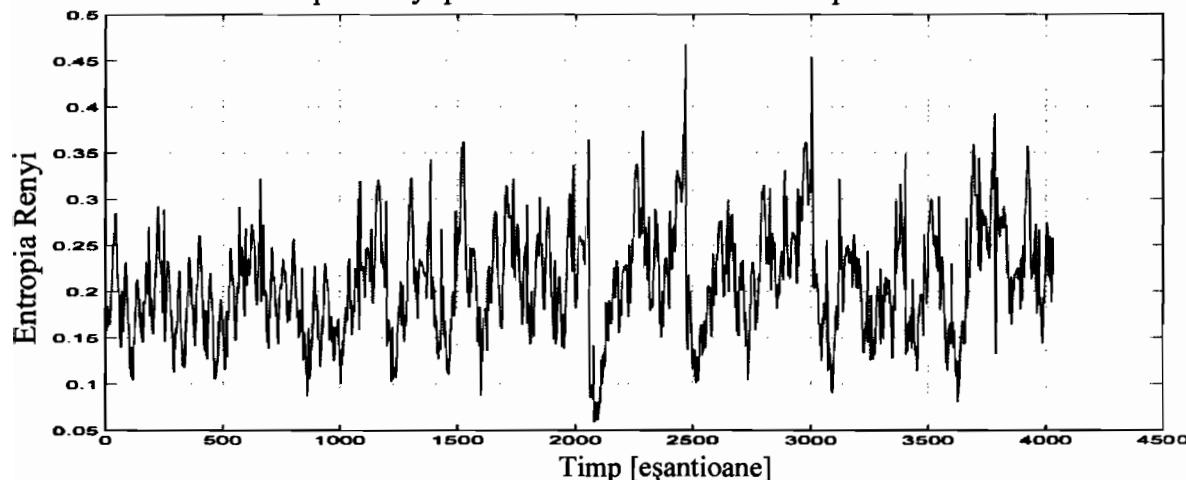
**Figura 7**

Entropia Renyi pe termen scurt utilizând RID pentru sursa 1



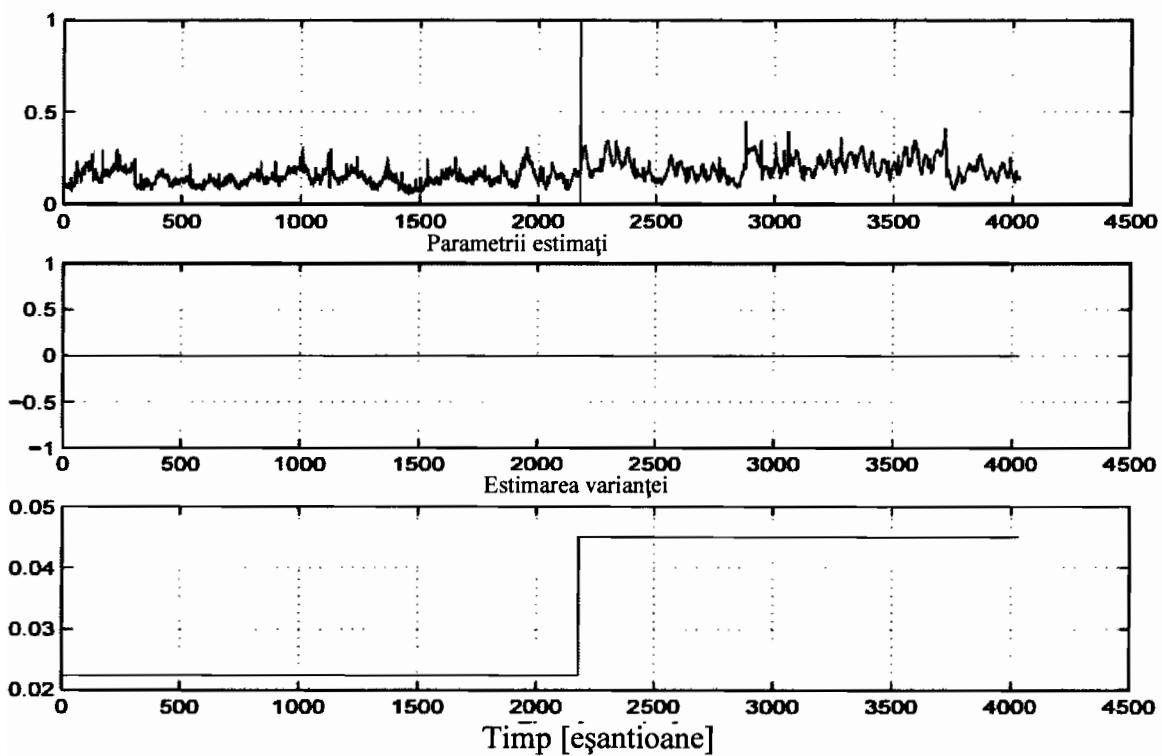
**Figura 8**

Entropia Renyi pe termen scurt utilizând RID pentru sursa 2

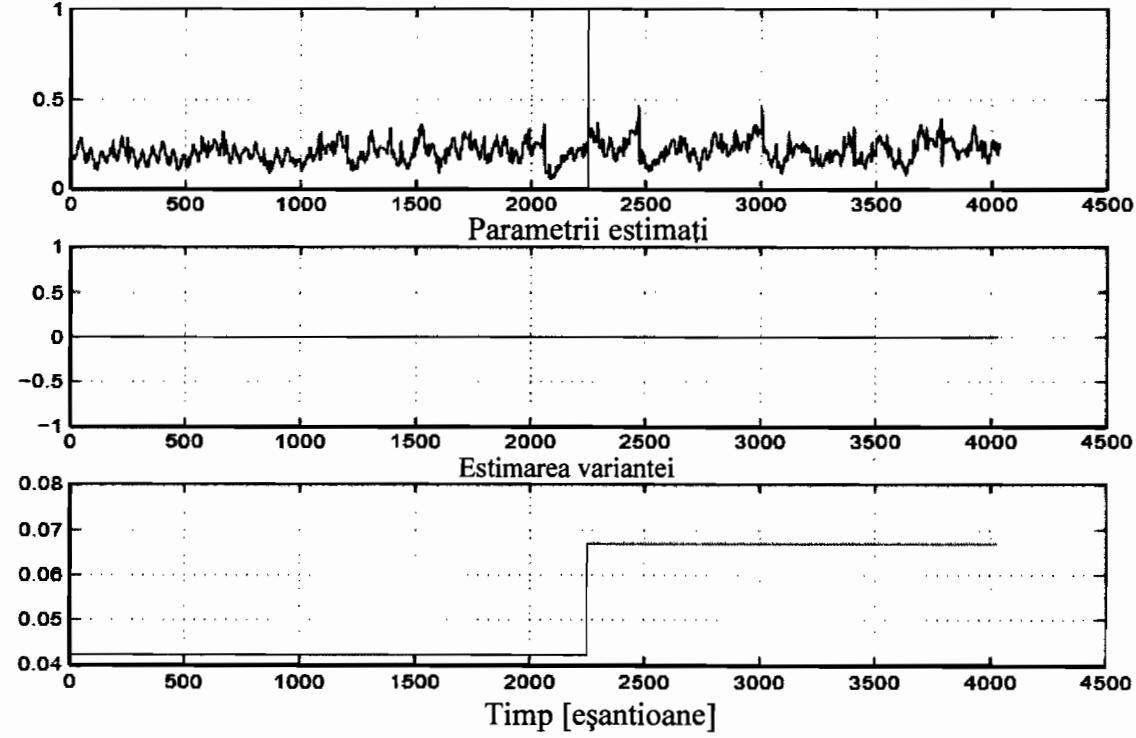


**Figura 9**

## Entropia Renyi sursa 1- MAP

**Figura 10**

## Entropia Renyi sursa 2 -

**Figura 11**