



(12)

BREVET DE INVENȚIE

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

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

(45) Data publicării mențiunii acordării brevetului: **30/01/2024** BOPI nr. 1/2024

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

(73) Titular:
• **INSTITUTUL NAȚIONAL DE
CERCETARE-DEZVOLTARE PENTRU
MECATRONICĂ ȘI TEHNICA MĂSURĂRII -
INCDTM 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**

(56) Documente din stadiul tehnicii:
**T. D. POPESCU, B. DUMITRAȘCU, "AN
APPLICATION OF RENYI ENTROPY
SEGMENTATION IN FAULT DETECTION OF
ROTATING MACHINERY", 16 TH
INTERNATIONAL CONFERENCE ON
RESEARCH AND EDUCATION IN
MECHATRONICS (REM), BOCHUM
GERMANY, 2015; T. D. POPESCU, "BLIND
SEPARATION OF VIBRATION SIGNALS
AND SOURCE CHANGE DETECTION -
APPLICATION TO MACHINE
MONITORING", APPLIED MATHEMATICAL
MODELLING, VOL.34, 2010; T. D.
POPESCU, D. AIORDĂCHIOAIE, "SIGNAL
SEGMENTATION IN TIME-FREQUENCY
PLANE USING RENYI ENTROPY -
APPLICATION IN SEISMIC SIGNAL
PROCESSING", CONFERENCE ON
CONTROL AND FAULT-TOLERANT
SYSTEMS (SYSTOL) NICE, FRANCE, 2013**

(54) **PROCEDEU PENTRU MONITORIZAREA MAȘINILOR
ROTATIVE**



RO 133003 B1

1 Invenția se referă la un procedeu de detecție a schimbărilor în semnalele de vibrație,
cu aplicabilitate în monitorizarea stării de funcționare a mașinilor rotative.

3 Pe plan mondial se manifestă o cerință crescută în ceea ce privește înlocuirea
5 procedurilor de întreținere sistematică, clasică, a mașinilor și utilajelor industriale prin
7 strategii de întreținere condițională, bazate pe supravegherea continuă sau prin sondaj a
9 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.

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

23 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
25 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 măsu-
27 rate 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
29 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
31 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
33 sau neparametrice.

35 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
37 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".

39 În prezent în literatură sunt raportate abordări ce folosesc diferite măsuri de tip
"distanță", inteligență artificială, logica fuzzy, recunoașterea formelor, etc. Unele carac-
41 teristici, cum ar fi nivelurile de amplitudine în domeniul timp, sunt extrase și clasificate ușor,
dar sunt susceptibile la efectul zgomotului. Altele, cum ar fi concentrația de energie în
43 domeniul timp-frecvență (a se vedea Stankovic, "**A measure of some time-frequency
distributions concentration**", Signal Processing, 2001), chiar dacă implică mai mult efort,
45 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 utilizați pentru detecția schimbărilor,
47 dacă se dispune de un model destul de precis al semnalului, în spațiul de reprezentare

selectat. În ceea ce privește modelarea semnalelor netaționare, 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 cu cea clasică, formulată în general în domeniul timp, furnizează, în mod obișnuit, o înțelegere și interpretare mai simplă a comportării semnalelor netaționare. Informația din planul timp-frecvență poate fi prelucrată utilizând diferite tehnici, în scopul detecției schimbărilor în semnalele ce fac obiectul analizei.

Începând cu anii 2010, unele din problemele care fac obiectul prezentei cereri de brevet sunt abordate în mai multe lucrări publicate ale autorilor: **Th. D. Popescu, "Blind Separation of Vibration Signals and Source Change Detection - Application to Machine Monitoring", Applied Mathematical Modelling, 2010**; **Th. D. Popescu, D. Aiordăchioaie, "Signal Segmentation in Time-Frequency Plane Using Rényi Entropy - Application in Seismic Signal Processing", Proc. of The 2-nd IEEE International Conference on Control and Fault-Tolerant Systems (SysTol), 2013**; **Th. D. Popescu, B. Dumitrașcu, "An Application of Rényi Entropy Segmentation in Fault Detection of Rotating Machinery", Proc. of The 16th IEEE International Conference on Research and Education in Mechatronics (REM2015), 2015**. Perioada care a urmat publicării acestor articole s-a axat pe studiu, cercetări teoretice și experimentale, care au condus la noi rezultate, inclusiv idei brevetabile, printre care și prezenta cerere de brevet. Între cele 3 articole și cererea de brevet sunt prezente unele intersecții, reduse ca număr. Acestea erau inerente, multe noțiuni și idei regăsindu-se în majoritatea lucrărilor care tratează problema analizei semnalelor de vibrație. Cererea de brevet utilizează același set de date de test, care face obiectul analizei în două din articolele menționate, acest set de date fiind unul de referință în literatura de specialitate. Deși cunoscute și aplicate în analiza vibrațiilor, cele 3 tehnici de procesare avansată a semnalelor de vibrație: separarea surselor de vibrație independente, măsurarea conținutului în informație a reprezentării timp-frecvență, prin estimarea entropiei Rényi, precum și detecția schimbărilor în aceasta, sunt utilizate în mod independent, și nu în mod secvențial, așa cum se prezintă în fig. 1 din prezenta cerere de brevet, idee care reprezintă principala revendicare, cu avantajele acesteia. În esență, problema monitorizării mașinilor rotative se reduce la detecția schimbărilor în semnale măsurate pe mașină (deplasări, viteze, accelerații), care se poate efectua direct, pe semnalele înregistrate, sau pe sursele de vibrație independente estimate. Așa cum s-a menționat anterior, cele 3 tehnici pot fi utilizate independent sau grupate câte 2, așa cum se realizează în lucrările menționate. Rezultatele obținute în acest caz nu sunt întotdeauna pe măsura așteptărilor (a se vedea rezultatele obținute în cazul utilizării separării surselor independente de vibrație și detecția schimbărilor în acestea, utilizând diferite tehnici, în prima lucrare de referință și cele care rezultă în cazul aplicării procedurii, care face obiectul cererii de brevet. Procedura care face obiectul cererii de brevet conduce, în mod evident, la rezultate mai bune în monitorizarea mașinilor rotative.

Procedura propusă spre brevetare nu constă în simpla asociere a celor 3 tehnici menționate, fiecare desfășurându-se în modul cunoscut. Între aceste tehnici există o interdependență strânsă, care permite lucrul pe semnale de vibrație monodimensionale, într-un spațiu de dimensiune redusă, față de cel al semnalelor de vibrație originale, conducând la reducerea efortului de calcul și a timpului de alarmare, în cazul producerii unei avarii. Numai prin aplicarea secvențială a celor 3 tehnici se realizează o pre-procesare a

RO 133003 B1

1 datelor de măsură originale, fapt ce permite evidențierea producerii unor schimbări, în
funcționarea mașinii, dar și o post-procesare a rezultatelor detecției, într-un nou spațiu de
3 decizie, cu efecte benefice în monitorizarea mașinii.

Problema tehnică rezolvată de invenție se referă la monitorizarea mașinilor rotative
5 utilizând analiza semnalelor de vibrație măsurate în timpul funcționării acestora. Soluția
propusă permite rezolvarea problemei tehnice în condițiile unei incertitudini mai mari, privind
7 dinamica mașinii (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
9 neliniare și variante în timp) și efectul zgomotului de intensitate mare, în general necunoscut.

Procedeul pentru monitorizarea mașinilor rotative, bazat pe analiza semnalelor de
11 vibrație, constă în analiza ce se realizează prin detecția schimbărilor în conținutul în infor-
mație al reprezentării timp-frecvență, rezultat prin estimarea entropiei Rényi și segmentarea
13 acesteia, utilizând estimatorul de probabilitate maximă a posteriori (MAP), după estimarea
surselor de vibrație independente. Procedeul include următoarele etape de prelucrare a
15 semnalelor de vibrație:

- separarea oarbă a surselor ce constă în estimarea surselor de vibrație indepen-
17 dente care generează semnalele măsurate de către senzorii amplasați pe carcasa unei
mașini, utilizând Analiza Componentelor Independente (ICA), într-un spațiu de dimensiune
19 redusă, față de cel al semnalelor de vibrație originale, situație în care numărul semnalelor
ce fac obiectul analizei este mai mic, față de cel al semnalelor de vibrație originale, iar
21 analiza se realizează pe semnale monodimensionale;

- analiza timp-frecvență și estimarea entropiei Rényi, pe baza conținutului în
23 informație al reprezentării timp-frecvență, pentru sursele de vibrație independente rezultate;

- detecția schimbărilor în entropia Rényi, pentru fiecare din sursele de vibrație
25 independente, prin utilizarea estimatorului de probabilitate maximă a posteriori (MAP), ceea
ce conduce la detecția robustă a producerii schimbărilor, față de cea a schimbărilor produse
27 în semnalele de vibrație originale.

Avantajele procedurii propus, comparativ cu soluțiile cunoscute în prezent, sunt:

29 - simplificarea problemei detecției întrucât se lucrează pe sursele independente
într-un nou spațiu de dimensiune redusă, față de cel al semnalelor de vibrație originale. În
31 acest caz numărul semnalelor ce fac obiectul analizei este mai mic, și mai mult, analiza se
va realiza pe semnale monodimensionale;

33 - procedura de detecție/segmentare se va aplica pe un semnal monodimensional, iar
entropia Rényi va fi rezultată prin aplicarea unei transformate pe reprezentarea bidimen-
35 sională 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
37 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
39 componente ale acesteia;

- permite realizarea unei fuziuni a informației rezultate în cele 3 etape de prelucrare
41 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
43 de diagnoză;

- realizează și o pre-procesare a datelor de măsură, prin separarea "oarbă" a surselor
45 de vibrație independente, în scopul evidențierii schimbărilor produse în funcționarea mașinii
(acestea apar mult mai vizibile în sursele de vibrație independente, decât în semnalele
47 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.

RO 133003 B1

Se dă în continuare un exemplu de realizare a invenției în legătură cu fig.1...11 care reprezintă:	1
- fig. 1, principalele etape în procedeul de monitorizare a mașinilor rotative ce utilizează separarea "oarbă" a surselor de vibrație și segmentarea entropiei Rényi;	3
- fig. 2, mixarea și separarea semnalelor;	5
- fig. 3, schema de măsurare multicanal: E = electromotor, MC - carcasă mașină, T = tahometru, V = vană alimentare, S1-S7 = poziție senzori 1,7;	7
- fig. 4, accelerațiile măsurate cu senzorii S1-S7;	9
- fig. 5, sursele de vibrație independente rezultate în urma aplicării algoritmului SOBI pentru măsurătorile efectuate pe cele 7 canale;	9
- fig. 6, distribuția timp-frecvență RID pentru sursa S1, în condițiile de funcționare normală și cu producerea unei defecțiuni a mașinii;	11
- fig. 7, distribuția timp-frecvență RID pentru sursa S2, în condițiile de funcționare normală și cu producerea unei defecțiuni a mașinii;	13
- fig. 8, entropia Rényi pe termen scurt pentru sursa S1;	15
- fig. 9, entropia Rényi pe termen scurt pentru sursa S2;	15
- fig. 10, segmentarea MAP a entropiei Rényi pentru sursa S1;	17
- fig. 11, segmentarea MAP a entropiei Rényi pentru sursa S2.	17
Procedeul care face obiectul prezentei cereri de brevet constă în aplicarea succesivă a 3 tehnici de procesare a semnalelor de vibrație, așa cum se prezintă în fig. 1. Totodată aceasta realizează și fuziunea informației rezultate în cele 3 tehnici de procesare, în scopul monitorizării eficiente a mașinii.	19
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 surselor independente. Utilizarea unui test statistic în acest nou spațiu de decizie, ca urmare a aplicării procedurii de detecție a schimbărilor, va permite o înțelegere și interpretare mai simplă a evoluției dinamicii mașinii, cu efecte benefice asupra monitorizării mașinii sau a unor componente ale acesteia.	21
Prin secțiunile care urmează se caută a veni în întâmpinarea unor cercetători și specialiști în domeniu, interesați în aplicarea brevetului. Cele 3 tehnici de procesare, utilizate în cadrul procedurii ce face obiectul invenției, se prezintă în cele ce urmează.	23
A. Separarea "oarbă" a surselor de vibrație	25
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).	27
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: $x_1(t), \dots, x_n(t)$:	29
$x_i(t) = \sum_{j=1}^n a_{ij} s_j(t) + n_i(t) \quad (1)$	31
pentru fiecare $i = 1, n$. Modelul poate fi reprezentat compact prin următoarea ecuație de mixare:	33
$x(t) = As(t) + n(t) \quad (2)$	35
unde $s(t) = [s_1(t), \dots, s_n(t)]^T$ este un vector coloană, $n \times 1$, ce conține semnalele sursă, în timp ce vectorul $x(t)$ conține n semnale observate, iar "matricea de mixare" A, $n \times n$ conține coeficienții de mixare.	37

RO 133003 B1

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

$$\hat{s}(t) = Wx(t) \quad (3)$$

7 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
9 temporal coerente, este posibil a rezolva problema BSS folosind numai statistici de ordinul
doi. În acest caz rezultă un algoritm, SOBI (Second Order Blind Identification), care
11 estimează sursele originale, pe baza autocorelațiilor pentru mai multe valori ale întârzierii și
diagonalizarea aproximativă asociată acestora (a se vedea **Belouchrani ș. a., "A blind
13 source separation technique using second-order statistics"**, IEEE Trans. Signal
Processing, 1997). Această metodă prezintă avantajul că este ușor de implementat și
15 conduce, în multe cazuri, la soluții liniare care necesită un efort de calcul redus, și folosește
tehnici numerice standard.

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

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

21 unde

$$H = [h_1, \dots, h_m]$$

23 și

$$\Delta = \text{diag}[\lambda_1, \dots, \lambda_m]$$

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

27 B. Măsurarea conținutului în informație a reprezentării timp-frecvență folosind
entropia Rényi

a) Analiza timp-frecvență

29 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
31 domeniu timp, t , și frecvență, ω . O astfel de funcție transformă semnalul din domeniul
monodimensional timp într-o reprezentare bidimensională a energiei în raport cu timpul și
33 frecvența.

35 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
37 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

$$TFD_x(t, \omega) = \frac{1}{4\pi^2} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x(u + \frac{1}{2} \tau) \cdot x^*(u - \frac{1}{2} \tau) \phi(\theta, \tau) \exp^{-j\theta t - j\tau\omega + j\theta u} du d\tau d\theta \quad (5)$$

41 unde $\phi(\theta, \tau)$ este o funcție nucleu bidimensională, determinând reprezentarea specifică în
43 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 câteva dintre metodele utilizate pentru obținerea TFD. Distribuția Choi-Williams (CWT) 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.

b) 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 Sejdíć, Djurović 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 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 - *"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 diferiți de zero oscilatorii (care nu se suprapun peste auto-termeni), deoarece pentru valori impare α aceștia nu contribuie la valoarea acestei măsuri. Acestea au fost motivele introducerii măsurilor entropiei Rényi normalizate, 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

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

RO 133003 B1

1 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.

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

$$5 \quad RE_3(n) = -\frac{1}{2} \log_2 \left(\sum_k P_x^3(n, k) \right) \quad (9)$$

7 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 ferestrei de date și se
9 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: $\bar{RE}_3(n) = RE_3(n) / \log_2 N$.

11 C. Segmentarea entropiei Rényi utilizând estimatorul MAP

a) Formularea problemei

13 Segmentarea entropiei Rényi pe termen scurt se va realiza utilizând modele de
regresie liniară cu parametrii constanți pe porțiuni. Aceasta rezultă în urma detecției
15 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
17 necunoscute, astfel încât un model de regresie liniară cu parametrii constanți pe porțiuni,

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

19 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 ,
21 ϕ_t este vectorul regresorilor ce conține valorile entropiei Rényi la momente anterioare, iar h
reprezintă momentele producerii schimbării. Zgomotul e_t se presupune a fi Gaussian, de
23 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
25 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
27 criteriile de optimalitate:

$$29 \quad \hat{k}^n = \arg \min_{n \geq 1, 0 < k_1 < \dots < k_n = N} V(k^n) \quad (11)$$

31 Pentru măsurătorile din segmentul i , adică, $y_{k_{i-1}+1}, \dots, y_{k_i} = y_{k_{i-1}+1}^{k_i}$ vectorul

33 stimațiilor parametrilor modelului cu metoda celor mai mici pătrate (LS) și matricea sa de
covarianță sunt date de:

$$35 \quad \hat{\theta}(i) = P(i) \sum_{t=k_{i-1}+1}^{k_i} \phi_{yt} \quad (12)$$

$$37 \quad P(i) = \left(\sum_{t=k_{i-1}+1}^{k_i} \phi_t \phi_t^T \right)^{-1} \quad (13)$$

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

$$43 \quad V(i) = \sum_{t=k_{i-1}+1}^{k_i} (y_t - \phi_t^T \hat{\theta}(i))^2 \quad (14)$$

$$D(i) - \log \det P(i) \tag{15} \quad 1$$

$$N(i) = k_i - k_{i-1} \tag{16} \quad 3$$

și reprezintă statistici suficiente în fiecare segment. Datele și statisticile utilizate în procedura de segmentare sunt prezentate în Tabelul 1. 5

Datele și statisticile utilizate în procedura de segmentare 7

Tabelul 1

Date	y_1, y_2, \dots, y_{k_1}	...	$y_{k_{n-1}+1}, \dots, y_{k_n}$	9
Segment	Segment 1	...	Segment n	11
Estimație LS	$\hat{\theta}(1), P(1)$...	$\hat{\theta}(n), P(n)$	
Statistici	$V(1), D(1), N(1)$...	$V(n), D(n), N(n)$	13

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: criteriile statistice (verosimilitate maximă (ML) sau probabilitate maximă a posteriori (MAP)) și criteriile 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). 15

b) Estimatorul de probabilitate maximă a posteriori (MAP) 21

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 măsurimile date în Tabelul 1 include următoarele etape de calcul: 23

Pas 1. Se examinează separat fiecare segmentare posibilă, parametrizată prin numărul de schimbări, n , și momentele de producere a acestora, k^n . 25

Pas 2. Pentru fiecare segmentare, se calculează cele mai bune modele în fiecare din segmente, sub forma estimației celor mai mici pătrate a parametrilor, $\theta(i)$, și a matricei de covarianță a acestora, $P(i)$. 27

Pas 3. Se calculează în fiecare segment suma pătratelor erorilor de predicție, $V(i)$ and $D(i) = -\log \det P(i)$. 29

Pas 4. Estimația MAP a structurii modelului 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: 31

$$\hat{k}^n = \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + V(i)) + 2n \log \frac{1-q}{q} \tag{17} \quad 37$$

$$\hat{k}^n = \arg \min_{k^n, n} \sum_{i=1}^n D(i) + (N - nd - 2) \log \frac{\sum_{i=1}^n V(i)}{N - nd - 4} + 2n \log \frac{1-q}{q} \tag{18} \quad 39$$

$$\hat{k}^n = \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + (N(i) - d - 2) \log \frac{V(i)}{N(i) - d - 4}) + 2n \log \frac{1-q}{q} \tag{19} \quad 41$$

unde q este probabilitatea producerii unei schimbări la fiecare moment de timp ($0 < q < 1$). Pentru $q = 0.5$, estimatorul MAP devine estimatorul de verosimilitate maximă (ML). 43

RO 133003 B1

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

3 Calculul verosimilității exacte este greu de efectuat din cauza complexității
exponențiale. În această situație se utilizează algoritmi ce implementează tehnici recursive
5 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
7 Filtering and Change Detection", Willey, NJ, 2001**).

În cele ce urmează se prezintă un studiu de caz pe o mașină rotativă (pompa
9 industrială de mare capacitate), în care se utilizează un set de date de test, de referință în
literatura de specialitate.

11 Aplicarea flecărei tehnici de prelucrare necesită din partea utilizatorului specificarea
unor condiții tehnice și parametrii inițiali care se regăsesc în prezentul studiu de caz. De
13 asemenea, utilizatorul trebuie să dispună de expertiza necesară privind organizarea experi-
mentelor, ce include proceduri de măsurare a datelor, amplasarea senzorilor, alegerea
15 perioadei de eșantionare, etc. precum și expertiză în domeniul prelucrării avansate a
semnalelor: separarea surselor de vibrație independente, măsurarea conținutului în infor-
17 mație a reprezentării timp-frecvență, estimarea entropiei Rényi, detecția schimbărilor în
semnale și sisteme.

19 Condițiile tehnice de aplicare și mijloacele tehnice utilizate impun, de asemenea,
dezvoltarea unui software de calitate care să permită rezolvarea celor 3 tehnici de procesare
21 avansată a semnalelor de vibrație.

A. Datele de măsură

23 O schemă a pompei industriale, cu componentele sale și poziția senzorilor este dată
în fig. 3. Semnalele de vibrație, accelerațiile pe 7 canale, sunt măsurate pe carcasa mașinii.
25 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.
27 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*",
29 realizat de TechnoFysica, The Netherlands.

În cadrul analizei au fost selectate măsurătorile efectuate la înaltă frecvență,
31 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
33 de viteze, ambele la încărcare minimă. Date au fost filtrate trece jos la 5000 Hz. Accelerațiile
măsurate de senzorii S1-S7 sunt reprezentate în fig. 4.

35 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
37 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.
39 Aceasta a permis efectuarea analizei într-un spațiu de dimensiune redusă, iar aplicarea
metodei de detecție/segmentare s-a făcut pe semnale monodimensionale, ceea ce a condus
41 la simplificarea în mare măsură a analizei.

B. Separarea "oarbă" a surselor

43 Măsurătorile accelerațiilor 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
45 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
47 estimare a numărului surselor independente, prezentată anterior a condus la 2 surse
independente. Sursele rezultate sunt reprezentate în fig. 5.

C. Analiza timp-frecvență și calculul entropiei Rényi

Fig. 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 fig. 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.

Rezultatele analizei timp-frecvență pentru sursa S2 sunt prezentate în fig. 7, pentru același tip de distribuție, RID, utilizând o fereastră Hanning și aceiași parametri, 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 indusă 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, se prezintă în fig. 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 fig. 9.

D. Segmentarea MAP a entropiei Rényi

Analiza vizuală a entropiei Rényi pentru ambele surse, scoate în evidență faptul că 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 detecție a schimbărilor în cazul celor două entropii Rényi s-a realizat cu estimatorul MAP, în cazul unui zgomot constant necunoscut, cu următoarele valori ale parametrilor de proiectare: $q = 0.3$, $M = 10$, $l = 8$ și $m_{seg} = 700$ (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:

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

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

Valorile dispersiei zgomotului modelului cu parametri 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.

Invenția poate fi aplicată în mediul industrial în următoarele moduri:

Disponând de o înregistrare de date, semnale de vibrație, acestea pot fi analizate parcurgând cele 3 etape incluse în procedeele ce fac obiectul invenției. Rezultatele obținute oferă o imagine de ansamblu asupra proceselor vibratorii specifice mașinii rotative, sau componentelor acesteia, ce fac obiectul monitorizării.

RO 133003 B1

1 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
3 "martor"), aceasta poate fi concatenată cu o înregistrare curentă din funcționarea mașinii
rotative, sau a componentelor acesteia, semnalul rezultat urmând a fi analizat cu prelucrările
5 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
7 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
9 diagnoză și localizarea posibilei defecțiuni.

11 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 ingineria civilă
(clădiri mari supuse acțiunii vântului și mișcărilor seismice, poduri, baraje, platforme marine),
13 aeronautică (structuri și componente supuse solicitărilor), automobile și sisteme de transport,
etc.

RO 133003 B1

Revendicare

	1
Procedeu pentru monitorizarea mașinilor rotative, bazat pe analiza semnalelor de vibrație, caracterizată prin aceea că include următoarele etape de prelucrare a semnalelor de vibrație:	3
- separarea oarbă a surselor (BSS) ce constă în estimarea surselor de vibrație independente care generează semnalele măsurate de către senzorii amplasați pe carcasa unei mașini, utilizând Analiza Componentelor Independente într-un spațiu de dimensiune redusă, față de cel al semnalelor de vibrație originale, 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;	5
- analiza timp-frecvență și estimarea entropiei Rényi, pe baza conținutului în informație al reprezentării timp-frecvență (TFD), pentru sursele de vibrație independente rezultate;	7
- detecția schimbărilor în entropia Rényi, pentru fiecare din sursele de vibrație independente, prin utilizarea estimatorului de probabilitate maximă a posteriori (MAP), ceea ce conduce la detecția robustă a producerii schimbărilor, față de cea a schimbărilor produse în semnalele de vibrație originale.	9
	11
	13
	15
	17




Fig. 1




Fig. 2




Fig. 3




Fig. 4

(51) Int.Cl.

G01H 17/00 (2006.01);

G06F 17/10 (2006.01)




Fig. 5




Fig. 6

(51) Int.Cl.

G01H 17/00 (2006.01);

G06F 17/10 (2006.01)




Fig. 7




Fig. 8




Fig. 9




Fig. 10




Fig. 11

