



(12) CERERE DE BREVET DE INVENȚIE

(21) Nr. cerere: a 2020 00692

(22) Data de depozit: 03/11/2020

(41) Data publicării cererii:
30/05/2022 BOPI nr. 5/2022

(71) Solicitant:
• 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;

• ALEXANDRU ADRIANA, STR.BELGRAD,
NR.6, ET.3, AP.7, SECTOR 1, BUCUREȘTI,
B, RO;
• IANCULESCU MARILENA,
STR.CPT.AVIATOR NICULAE DROSSU,
NR.16, ET.2, AP.5, SECTOR 1,
BUCUREȘTI, B, RO;
• TUDORA ELEONORA, STR.SIBIU, NR.4,
BL.OD2, SC.1, ET.6, AP.28, SECTOR 6,
BUCUREȘTI, B, RO

(54) PROCEDURA PENTRU SEGMENTAREA SEMNALELOR
MULTICANAL ÎN VEDEREA EXTRAGERII
CARACTERISTICILOR

(57) Rezumat:

Invenția se referă la o procedură de segmentare a semnalelor multicanal în vederea extragerii caracteristicilor, cu aplicabilitate în domeniile analizei semnalelor biomedicale, a semnalelor vocale, a semnalelor seismice, detecției schimbărilor și diagnozei proceselor industriale, monitorizării sistemelor de infrastructură, sistemelor de comunicații, sistemelor de transport, etc. Procedura conform invenției utilizează estimatorul de probabilitate maximă a posteriori (MAP), pentru trei ipoteze diferite, furnizând numărul segmentelor de date cvasi-staționare și locațiile producerii schimbărilor în semnalul analizat, pe baza estimărilor celor mai mici pătrate ale parametrilor modelelor și ale matricei de covarianță a acestora, pentru fiecare segment cvasi-staționar, așa cum se prezintă în figura 1.

Revendicări: 1
Figuri: 9

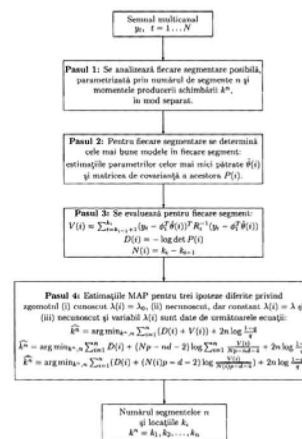



Fig. 1

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 invenție a fost respinsă, retrasă sau considerată ca fiind retrasă. Întinderea protecției conferite de cererea de brevet de invenție este determinată de revendicările conținute în cererea publicată în conformitate cu art.23 alin.(1) - (3).





PROCEDURĂ PENTRU SEGMENTAREA SEMNALELOR MULTICANAL ÎN VEDEREA EXTRAGERII CARACTERISTICILOR

DESCRIEREA INVENȚIEI

Titlul invenției

Procedură pentru segmentarea semnalelor multicanal în vederea extragerii caracteristicilor.

Domeniul tehnic la care se referă invenția

Invenția se referă la o procedură de segmentare a semnalelor multicanal în vederea extragerii caracteristicilor, ce face uz de estimatorul de probabilitate maximă a posteriori (MAP), cu aplicabilitate în domeniile analizei semnalelor biomedicale, semnalelor vocale, semnalelor seismice, detecției schimbărilor și diagnozei proceselor industriale, monitorizării sistemelor de infrastructură, sistemelor de comunicații, sistemelor de transport, etc.

Stadiul tehnicii în domeniu

Semnalelor multicanal, obținute din măsurătorile multisenzor, în inginerie sau în sistemele biomedicale, precum și în alte domenii, reprezintă un domeniu major de utilizare a metodelor de prelucrare numerice. Instrumentele matematice utilizate în analiza acestor semnale includ transformata Fourier, transformata de tip wavelet, precum și metode de eliminarea a zgomotului, urmate de metode de segmentare a semnalelor, extragerea caracteristicilor și clasificare.

Problema segmentării, sau determinarea părților "omogene" ale unui semnal mono- sau multicanal, apare în domeniul menționat anterior, mai mult sau mai puțin explicit. Un astfel de semnal poate fi reprezentat ca o secvență de segmente discrete de lungime finită, care să poată face obiectul extragerii caracteristicilor și clasificării. Există două abordări generale pentru rezolvarea acestei probleme. Prima abordare, implică căutarea momentelor de producere a unor schimbări, în semnalul ce face obiectul analizei. A doua abordare, presupune că fiecare segment al semnalului este generat de un sistem cu parametrii distincți, sugerând cele mai probabile locații ale segmentelor, funcție de acești parametri. În timp ce prima abordare se rezumă la a căuta schimbările produse numai într-o fereastră redusă de timp, cea de a doua, în general, ia în considerare întregul semnal.

Obiectivul segmentării constă în a estima momentele de timp ale producerii unor schimbări în proprietățile sau în dinamica semnalului. Problema se referă la detecția momentelor de producere a schimbării, cât mai rapid posibil, de a izola schimbarea și de a determina cauza producerii acesteia (diagnoza). O cale de segmentare a unui semnal, utilizând o metodă de detecție a schimbării, constă în prelucrarea secvențială a datelor, iar în momentul producerii

unei schimbări se reactivează procedura de detecție. Această abordare reprezintă o metodă naturală pentru lucrul on-line.

Problema ce face obiectul Cererii de brevet este una de largă aplicabilitate în domeniile analizei semnalelor biomedicale, analizei semnalelor vocale, analizei semnalelor seismice, detecției schimbărilor și diagnozei proceselor industriale, monitorizării sistemelor de infrastructură, sistemelor de comunicații, sistemelor de transport, etc.

Astfel de metode de segmentare, bazate pe model, au fost sugerate anterior în lucrările [1], [2], [3], [4], [5], [6], [7], [8], [9], printre altele. Acestea utilizează algoritmi de detecție multiplă, modele Markov, modele multiple AFMM (adaptive forgetting by multiple models), formulează problema segmentării ca o problemă de tipul celor mai mici pătrate cu regularizarea sumei normelor peste spațiul schimbărilor parametrilor, utilizează algoritmi de clasificare, descompunerea timp-frecvență și modelarea statistică, sau optimizarea fragmentelor de segmente, utilizând transformarea wavelet empirică, printre altele.

În cadrul prezentei Cereri de brevet segmentarea presupune prelucrarea off-line sau pe loturi a semnalului, deși soluția este una secvențială și se poate utiliza o abordare recursivă, în aceeași măsură. Modelul de segmentare este cea mai simplă extensie posibilă a modelelor de regresie a semnalelor cu proprietăți de schimbare abruptă, sau liniarizare pe porțiuni a modelelor neliniare. Problema este rezolvată pentru trei ipoteze diferite, furnizând numărul segmentelor de date cvasi-staționare și locațiile producerii schimbărilor în semnalul analizat, pe baza estimățiilor celor mai mici pătrate ale parametrilor modelelor și a matricei de covarianță a acestora, pentru fiecare segment cvasi-staționar, așa cum se prezintă în Figura 1.

Problema tehnică rezolvată de invenție

Problema tehnică rezolvată în cadrul prezentei Cereri de brevet se referă la o procedură de segmentare a semnalelor multicanal în vederea extragerii caracteristicilor, ce face uz de estimatorul de probabilitate maximă a posteriori (MAP). Procedura se prezintă în Figura 1 și implică următoarele etape, care se discută în detaliu în secțiunea următoare:

1. Pentru fiecare segmentare posibilă a semnalului, ce face obiectul analizei, se determină cele mai bune modele în fiecare segment: estimățiile parametrilor modelelor, obținute cu metoda celor mai mici pătrate, $\hat{\theta}(i)$, și matricea de covarianță a acestora, $P(i)$.
2. Pentru fiecare segment cvasi-staționar se evaluează următoarele mărimi:

$$\begin{aligned} V(i) &= \sum_{t=k_{i-1}+1}^{k_i} (y_t - \phi_t^T \hat{\theta}(i))^T R_t^{-1} (y_t - \phi_t^T \hat{\theta}(i)) \\ D(i) &= -\log \det P(i) \\ N(i) &= k_i - k_{i-1} \end{aligned}$$

3. Se determină estimățiile obținute cu estimatorul de probabilitate maximă a posteriori (MAP) pentru trei ipoteze diferite privind zgomotul

- (i) cunoscut $\lambda(i) = \lambda_0$,
- (ii) necunoscut, dar constant $\lambda(i) = \lambda$ și
- (iii) necunoscut și variabil $\lambda(i)$ cu următoarele ecuații:

$$\begin{aligned} \hat{k}^n &= \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + V(i)) + 2n \log \frac{1-q}{q} \\ \hat{k}^n &= \arg \min_{k^n, n} \sum_{i=1}^n D(i) + (Np - nd - 2) \log \sum_{i=1}^n \frac{V(i)}{Np - nd - 4} + 2n \log \frac{1-q}{q} \\ \hat{k}^n &= \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + (N(i)p - d - 2) \log \frac{V(i)}{N(i)p - d - 4}) + 2n \log \frac{1-q}{q}. \end{aligned}$$

4. În urma analizei rezultatelor obținute anterior se determină numărul segmentelor n și locațiile k_i $k^n = k_1, k_2, \dots, k_n$ ale segmentelor qvasi-staționare rezultate.

Expunerea invenției

Principalele etape ale procedurii ce face obiectul Cererii de brevet sunt reprezentate în Figura 1 și se prezintă în cele ce urmează.

Borderou figurii

Figura 1: Procedura de segmentare a semnalelor multicanal utilizând MAP.

Figura 2: Segmentarea semnalului generat de modelul ARX(2,2,1) - Semnalul cu momentele reale ale producerii schimbărilor parametrilor, parametrii modelului reali și estimați, parametrul real și estimat λ ($q = 0.30$)

Figura 3: Rezultatele simulării Monte Carlo (MC) ale segmentării semnalului generat de modelul ARX(2,2,1)($q = 0.30$)

Figura 4: Componenta seismică NS și spectrul de amplitudine Fourier.

Figura 5: Componenta seismică WE și spectrul de amplitudine Fourier.

Figura 6: Componenta seismică NS cu momentele producerii schimbărilor, estimațiile parametrilor modelului și ale dispersiei zgomotului ($q = 0.30$)

Figura 7: Distribuția timp-frecvență de interferență redusă (RID) a componentei seismice NS.

Figura 8: Componenta seismică WE cu momentele producerii schimbărilor, estimațiile parametrilor modelului și ale dispersiei zgomotului ($q = 0.30$).

Figura 9: Distribuția timp-frecvență de interferență redusă (RID) a componentei seismice WE.

1. Formularea problemei

Se consideră următorul model de regresie liniar, cu parametri constanți pe porțiuni,

$$y_t = \phi_t^T \theta_t + e_t, \quad E(e_t^2) = R_t, \quad (1)$$

ca o bună descriere a semnalului multicanal observat, y_t , care face obiectul analizei; θ_t este vectorul parametrilor modelului, d -dimensional, ϕ_t este vectorul regresorilor, iar semnalul multicanal se presupune a fi de dimensiune p , numărul componentelor. Zgomotul e_t se presupune a fi gaussian, cu dispersia variabilă în timp cunoscută, pentru generalitate.

Determinarea vectorului θ_t din semnalul y_t este referită ca estimare, iar detecția schimbării reprezintă estimarea abruptă, sau rapidă, a schimbărilor în vectorul θ_t , la momentul k , referit ca momentul producerii schimbării. Ipotezele de bază care se fac asupra modelului (1) în legătură cu detecția schimbării sunt următoarele:

- Producerea unei schimbări abrupte în componenta θ_t are loc la momentul $t = k$. Immediat ce a fost detectată o astfel de schimbare, procedura de detecție va fi activată din nou pentru detecția următoarei schimbări. Vectorul parametrilor θ_t se consideră constant pe porțiuni și se determină secvența momentelor producerii schimbărilor k_1, k_2, \dots, k_n .

Această secvență este notată cu k^n , unde atât k_i cât și n sunt parametrii de determinat. Problema segmentării este de a determina atât numărul n cât și locațiile momentelor producerii schimbărilor în k^n .

- În cadrul abordărilor statistice, zgomotul se presupune a fi alb și gaussian $e_t \in N(0, R_t)$.

În concluzie, așa cum s-a menționat anterior, scopul segmentării este de a găsi secvența indicilor de timp $k^n = k_1, k_2, \dots, k_n$, unde atât numărul n și locațiile k_i sunt necunoscute, astfel încât un model de regresie liniar, cu parametrii constanți pe porțiuni,

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

unde $k_{i-1} < t \leq k_i$, să reprezinte o bună descriere a semnalului ce face obiectul analizei. Zgomotul e_t se presupune a fi gaussian cu dispersia $\lambda(i) R_t$, unde $\lambda(i)$ reprezintă un factor de scalare al acestuia, posibil dependent de segmentul cvasi-staționar, iar R_t este matricea de covarianță a zgomotului; modelul (2) reprezintă o extensie a modelului (1). λ poate fi considerat fie ca un factor de scalare a dispersiei zgomotului, fie ca însăși dispersia zgomotului ($R_t = 1$). Atât $\theta(i)$ cât și $\lambda(i)$ sunt necunoscuți. Ipoteza de zgomot gaussian a zgomotului este una standard, ea permițând obținerea unor expresii analitice și dovedindu-se a lucra bine în practică. Vom presupune că R_t este cunoscut, iar factorul de scalare un posibil parametru necunoscut. Modelul (2) permite schimbări între modelele de regresie liniare. El se caracterizează prin faptul că schimbările produse în dinamica semnalului divid setul de măsurători într-un număr de segmente independente, deoarece vectorii parametrilor în diferite segmente sunt independenți. Drept cazuri particulare ale modelului (2) pot fi considerate modelul cu valoarea medie variabilă, modelul autoregresiv (AR), modelul autoregresiv cu variabilă exogenă (ARX) și modelul cu răspuns finit la impuls (FIR), etc. unde vectorul ϕ_t are diferite expresii.

În scopul obținerii celei mai bune soluții posibile, vor fi considerate toate segmentările posibile k^n , se va estima câte un model de regresie liniar în fiecare segment și se va alege cea segmentare particulară k^n care minimizează următorul criteriu de optimalitate:

$$\widehat{k}^n = \arg \min_{n \geq 1, 0 < k_1 < \dots < k_n = N} V(k^n) \quad (3)$$

Pentru măsurătorile din segmentul i , $y_{k_{i-1}+1}, \dots, y_{k_i} = y_{k_{i-1}+1}^{k_i}$, estimația de tipul celor mai mici pătrate a vectorului parametrilor și a matricei de covarianță a acestuia sunt de forma:

$$\hat{\theta}(i) = P(i) \sum_{t=k_{i-1}+1}^{k_i} \phi_t R_t^{-1} y_t, \quad (4)$$

$$P(i) = \left(\sum_{t=k_{i-1}+1}^{k_i} \phi_t R_t^{-1} \phi_t^T \right)^{-1}. \quad (5)$$

Următoarele mărimi: V - suma pătratelor reziduurilor, $D = -\log \det(P)$ și N - numărul de date în fiecare segment, sunt date de relațiile:

$$V(i) = \sum_{t=k_{i-1}+1}^{k_i} (y_t - \phi_t^T \hat{\theta}(i))^T R_t^{-1} (y_t - \phi_t^T \hat{\theta}(i)) \quad (6)$$

$$D(i) = -\log \det P(i) \quad (7)$$

$$N(i) = k_i - k_{i-1} \quad (8)$$

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

Menționăm faptul că segmentarea k^n are $n - 1$ grade de libertate.

Table 1: Datele și mărimile utilizate în procedura de segmentare

Date	y_1, y_2, \dots, y_{k_1}	\dots	$y_{k_{n-1}+1}, \dots, y_{k_n}$
Seg.	Segment 1	\dots	Segment n
Prob.	$p(y_1^{k_1})$	\dots	$p(y_{k_{n-1}+1}^{k_n})$
LS est.	$\hat{\theta}(1), P(1)$	\dots	$\hat{\theta}(n), P(n)$
Stat.	$V(1), D(1), N(1)$	\dots	$V(n), D(n), N(n)$

2. Estimatorul de probabilitate maximă a posteriori (MAP)

Fie k^n, θ^n, λ^n seturile reprezentând momentele producerii schimbărilor în semnal, vectorii parametrilor și scalările zgomotului, respectiv, necesare în modelul de segmentare (2). Funcția de verosimilitate pentru datele y^N , cunoscuți fiind toți parametrii, $p(y^N | k^n, \theta^n, \lambda^n)$ și presupunând distribuții independente ale zgomotului gaussian

$$p(e^N) = \prod_{i=1}^n \prod_{t=k_{i-1}+1}^{k_i} (2\pi\lambda(i))^{-p/2} (\det R_t)^{-1/2} \times \exp(-e_t^T R_t^{-1} e_t / (2\lambda(i))) \quad (9)$$

se obține ca:

$$\begin{aligned} -2 \log p(y^N | k^n, \theta^n, \lambda^n) &= Np \log(2\pi) + \sum_{t=1}^N \log \det R_t + \sum_{i=1}^n N(i) \log(\lambda(i)^p) + \\ &+ \sum_{i=1}^n \frac{\sum_{t=k_{i-1}+1}^{k_i} (y_t - \phi_t^T \theta(i))^T R_t^{-1} (y_t - \phi_t^T \theta(i))}{\lambda(i)} \end{aligned} \quad (10)$$

Pentru eliminarea parametrilor θ^n, λ^n se utilizează funcția de verosimilitate marginalizată și (10) este integrată în raport cu distribuția a priori a acestor parametri, rezultând:

$$p(y^N | k^n) = \int_{\theta^n, \lambda^n} p(y^N | k^n, \theta^n, \lambda^n) p(\theta^n | \lambda^n) \times p(\lambda^n) d\theta^n d\lambda^n \quad (11)$$

În (11), valoarea a priori pentru $p(\theta^n | \lambda^n)$ este o funcție de scalarea dispersiei zgomotului λ , care este în mod obișnuit aleasă ca o funcție independentă. Estimatorul de verosimilitate maximă este dat de maximizarea $p(y^N | k^n)$. Probabilitățile a posteriori pot fi calculate din legea Bayes,

$$p(k^n | y^N) = p(y^N | k^n) \frac{p(k^n)}{p(y^N)} \quad (12)$$

unde $p(y^N)$ este o constantă, iar estimăția probabilității maxime a posteriori (MAP) se obține prim maximizare.

Valoarea a priori $p(k^n) = p(k^n | n) p(n)$ sau, echivalent, $p(\delta^N)$ asupra segmentării reprezintă alegerea utilizatorului (singura). Utilizatorul poate presupune probabilitatea fixă q a producerii schimbării la fiecare nou moment de timp, ceea ce înseamnă a considera secvența de producere a schimbărilor δ^N ca variabile independente Bernoulli $\delta_t \in \text{Be}(q)$:

$$\delta_t = \begin{cases} 0 & \text{cu probabilitate } 1 - q \\ 1 & \text{cu probabilitate } q \end{cases}$$

Deoarece există o corespondență între k^n și δ^N , ambele probabilități ale producerii acestora sunt date de

$$p(k^n) = p(\delta^N) = q^n (1 - q)^{N-n} \quad (13)$$

O valoare q mai mică decât 0.50 produce un termen de penalizare crescând liniaritatea în n ; Pentru $q = 0.50$, estimatorul MAP se reduce la estimatorul de verosimilitate maximă (ML). În unele cazuri practice este posibil a avea informații a priori privind semnalul fizic care urmează a fi segmentat și poate fi aleasă o valoare adecvată pentru q , informație ce poate proveni din cunoașterea aprofundată a procesului fizic, sau din experiența anterioară.

Prezentăm în continuare principalele etape de calcul ale estimatorului MAP, pentru datele și mărimile prezentate în Tabelul 1:

1. Se analizează fiecare segmentare posibilă, parametrizată prin numărul de segmente n și momentele producerii schimbării k^n , în mod separat.
2. Pentru fiecare segmentare se determină cele mai bune modele în fiecare segment: estimațiile parametrilor celor mai mici pătrate $\hat{\theta}(i)$ și matricea de covarianță a acestora $P(i)$.
3. Se evaluează pentru fiecare segment suma erorilor de predicție pătrate $V(i) = \sum_{t=k_{i-1}+1}^{k_i} (y_t - \phi_t^T \hat{\theta}(i))^T R_t^{-1} (y_t - \phi_t^T \hat{\theta}(i))$ și $D(i) = -\log \det P(i)$.
4. Estimațiile MAP pentru trei ipoteze diferite privind zgomotul (i) cunoscut $\lambda(i) = \lambda_0$, (ii) necunoscut, dar constant $\lambda(i) = \lambda$ și (iii) necunoscut și variabil $\lambda(i)$ sunt date de următoarele ecuații:

$$\widehat{k}^n = \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + V(i)) + 2n \log \frac{1-q}{q} \quad (14)$$

$$\widehat{k}^n = \arg \min_{k^n, n} \sum_{i=1}^n D(i) + (Np - nd - 2) \times \log \sum_{i=1}^n \frac{V(i)}{Np - nd - 4} + 2n \log \frac{1-q}{q} \quad (15)$$

$$\widehat{k}^n = \arg \min_{k^n, n} \sum_{i=1}^n (D(i) + (N(i)p - d - 2) \times \log \frac{V(i)}{N(i)p - d - 4}) + 2n \log \frac{1-q}{q} \quad (16)$$

respectiv.

Evaluările statisticilor (15) și (16) sunt aproximative. În toate cazurile, constantele în probabilitățile a posteriori au fost eliminate. Diferențele în cele 3 abordări se referă numai la modul în care este tratată suma pătratelor erorilor de predicție. Obținerea relațiilor (14), (15) și (16) este validă numai dacă toți termenii sunt bine definiți. Condiția este ca $P(i)$ să fie de rang complet pentru toate valorile i și ca numitorul lui $V(i)$ să fie pozitiv. Aceasta înseamnă ca $Np - nd - 4 > 0$ și $N(i)p - d - 4 > 0$, în (15) și (16), respectiv. Prin urmare, segmentele rezultate în urma procedurii de segmentare trebuie să fie suficient de lungi.

3. Aspecte de calcul

Problema cheie în procedura de segmentare descrisă o constituie cea a dimensionalității. Se poate observa că numărul de segmentări k^n este 2^N , deoarece se poate produce, sau nu, o schimbare la fiecare moment de timp. Pentru segmentarea MAP se utilizează o tehnică numerică bazată pe programarea dinamică MCMC (Markov Chain Monte Carlo) [10].

Algoritmul de segmentare optimală bazat pe MAP utilizează ca intrări, vectorul de date reprezentând semnalul multicanal, structura modelului (modelul schimbării în valoarea medie, modelul de regresie, modelul AR(na), modelul ARX(na,nb,nk), etc.), ipoteza privind factorul de scalare a zgomotului: (i) cunoscut $\lambda(i) = \lambda_0$, (ii) necunoscut, dar constant $\lambda(i) = \lambda$ și (iii) necunoscut și variabil $\lambda(i)$, probabilitatea ca schimbarea să se producă la fiecare moment, q , și parametrii de proiectare pentru schema de căutare: numărul de filtre utilizat (M), lungimea minimă a unei secvențe de producere a unei schimbări garantate (l) și dimensiunea minimă permisă a unui segment ($mseg$). În practică, dacă nu se dispune de nicio informație privind

alegerea acestor parametri, se recomandă utilizarea următoarelor valori: numărul fitrelor, M , este recomandat a fi ales $\dim(\theta) + 8$, alegerea l este legată de identificabilitatea modelului și urmează a fi aleasă mai mare decât $\dim(\theta) + 2$, iar dimensiunea segmentului minim permis, $mseg$, poate fi ales 0, în ideea că o schimbare în dinamica semnalului se poate produce la orice moment de timp. Probabilitatea de producere a unei schimbări, q , are ca efect numărul de segmente care rezultă în urma segmentării. Așa cum s-a menționat anterior, alegerea sa poate proveni din cunoașterea aprofundată a procesului fizic, sau din experiența anterioară a utilizatorului.

Avantajele invenției în raport cu soluțiile actuale

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

- Analiza semnalelor multicanal ridică probleme majore în practică, în special datorită necesității specificării unor parametri de proiectare. Prezenta procedură necesită un număr minim de astfel de parametri, a căror specificare nu ridică probleme utilizatorului, dovedindu-se suficient de robustă la alegerea acestora.
- Ipoteza de care aceasta face uz, legată de utilizarea modelelor de regresie liniară (2) nu este una restrictivă, având în vedere că multe procese în practică pot fi bine aproximate prin astfel de modele. Procedura nu are în vedere obținerea unor modele precise și de calitate, modelele fiind utilizate numai ca instrumente pentru realizarea detecției producerii schimbării și a segmentării.
- Soluția de segmentare propusă este una necoventțională, originală, care face uz de estimatorul MAP și de o tehnică numerică bazată pe programarea dinamică MCMC.
- Eficiența procedurii de segmentare este pusă în evidență prin simularile Monte Carlo efectuate, pentru diferite modele de semnal, ce includ modele cu schimbarea valorii medii, modele de tip FIR, AR și ARX, precum și prin compararea cu alte metode de detecție a schimbărilor și segmentare, propuse în literatură.
- Procedura de segmentare bazată pe estimatorul MAP și pe tehnici de căutare conduce la soluții de calitate, chiar în cazul în care alte proceduri, bazate pe modele parametric și teste statistice nu sunt capabile să determine toate schimbările în dinamica semnalului analizat; segmentarea MAP pentru $q = 0.50$, când estimatorul MAP se reduce la estimatorul de verosimilitate maximă (ML), nu determină toate schimbările produse în dinamica semnalului, așa cum rezultă din secțiunea privind Modul de realizare și aplicare a invenției.
- Procedura permite realizarea cu efort minim a segmentării semnalelor multicanal, cu aplicații în domeniile analizei semnalelor biomedicale, analizei semnalelor vocale, analizei semnalelor seismice, detecției schimbărilor și diagnozei proceselor industriale, monitorizării sistemelor de infrastructură, sistemelor de comunicații, sistemelor de transport, etc.;
- Utilizarea procedurii asigură noi posibilități de detecție a schimbărilor în dinamica semnalelor și sistemelor, oferind o analiză mai simplă, precum și o interpretare a comportării semnalelor multicanal, furnizând noi elemente asupra caracteristicilor acestora.

Modul de realizare și aplicare a invenției

Modul de realizare și aplicare a invenției este prezentat prin 2 studii de caz, realizate prin simulare și cu semnale reale, reprezentând componentele NS și WE ale cutremurului de pământ produs la Kocaeli, Turcia, în August 1999, înregistrat la stația Arcelik station (ARC) [11], o mișcare seismică moderată spre puternică.

1. Rezultate obținute în simulare

Semnalul care face obiectul analizei, obținut prin simulare, reprezintă ieșirea unui model ARX având următoarea structură:

$$y_t = -\phi_1(i) * y_{t-1} - \phi_2(i) * y_{t-2} + \theta_1(i) * u_{t-1} + \theta_2(i) * u_{t-2} + e_t \quad (17)$$

unde u_t și e_t sunt secvențe aleatoare de medie 0 și dispersie 1, iar $E(e_t^2) = \lambda(i)\sigma_i^2$, cu $\sigma_i^2 = 1$, pentru segmentul i . Parametrii modelului și valorile λ sunt date în Tabelul 2. Schimbările pentru parametrii ϕ , θ și λ , s-au produs la momentele 400 și 700.

Table 2: Parametrii modelului ARX(2,2,1) și valoarea λ

i	1	2	3
Segment i	1-400	401-700	701-1000
$\phi_1(i)$	1.5	1.5	1.5
$\phi_2(i)$	0.8	0.8	0.6
$\theta_1(i)$	2.0	2.0	2.0
$\theta_2(i)$	0.5	1.0	1.0
$\lambda(i)$	0.1	0.3	0.2

Simularea Monte Carlo a constat în simularea modelului (17), cu valorile parametrilor $\theta(i)$ și $\lambda(i)$ date în Tabelul 2, pentru 500 de realizări ale secvenței aleatoare e_t , după care s-a aplicat algoritmul de segmentare pe ieșirile modelului y_t , rezultate pentru cele 500 de realizări ale zgomotului. Valoarea medie a semnalelor y_t rezultată cu momentele producerii schimbărilor 400 și 700, precum și valorile reale și cele mediate ale estimațiilor parametrilor modelului și ale dispersiei zgomotului sunt prezentate în Figura 2. Histogramele momentelor estimate ale producerii schimbărilor rezultate sunt date în Figura 3, în cazul aplicării estimatorului MAP pentru ipoteza de zgomot constant și necunoscut și următoarele valori pentru parametrii de proiectare, $q = 0.30$, $M = 12$, $ll = 8$ and $mseg = 0$.

Prezentăm în Tabelul 3 numărul momentelor de producere a schimbărilor cu întârziere 0, corespunzătoare momentelor reale de producere a schimbărilor, 400 și respectiv 700, pentru diferite valori ale parametrului q .

Table 3: Detecția schimbării în modelul ARX(2,2,1) pentru diferite valori ale lui q

Exp.	q	MAP	
		1st ch.	2nd ch.
1	0.001	170	94
2	0.01	159	74
3	0.05	160	98
4	0.10	174	105
5	0.30	164	101
6	0.50	179	109

Exemplul prezentat precum și alte exemple pentru alte tipuri de modele scot în evidență faptul că momentele estimate ale producerii schimbărilor au fost detectate suficient de precis, cu minimizarea schimbărilor false și a întârzierii detecției. De asemenea, estimațiile parametrilor

modelului și ale dispersiei zgomotului au rezultat suficient de apropiate de valorile reale. Menționăm că performanțe rezonabile au fost obținute pentru aproximativ toate valorile parametrului de proiectare q , ceea ce denota robustețea procedurii de segmentare la acest parametru.

2. Rezultate obținute cu date reale

Segmentarea semnalelor seismice constituie o problemă interesantă și o provocare în același timp. Principala dificultate se referă la faptul că atât proprietățile statistice ale zgomotului seismic, precum și caracteristicile înregistrărilor sunt în general necunoscute.

Unele dintre metodele de segmentare a semnalelor seismice utilizează modelarea autoregresivă a acestora și testul raport de verosimilitate generalizat pentru a detecta schimbările semnificative în undele seismice [12], [13], algoritmi de căutare [14], bazați pe segmentarea binară, propusă de Coifman and Wickerhauser [15], sau fac uz de natura particulară a semnalelor și utilizarea unor proprietăți interesante ale testului statistic [16].

Datele, înregistrate în timpul producerii seismului de la Kocaeli, Turcia, 17 August, 1999, înregistrate de stația Arcelik, au fost eșantionate cu perioada de 0.005 secunde, pentru aproximativ 30 de secunde și au fost corectate pentru eliminarea efectelor zgomotului de măsură. Sursa datelor este <http://peer.berkeley.edu/svbin/GeneralSearch?geo1=B>.

Segmentarea s-a realizat cu estimatorul MAP, cu ipoteza de zgomot constant și necunoscut și cu procedura numerică de căutare MCMC. Rezultatele au fost evaluate folosind analiza timp-frecvență (TF), respectiv distribuția de interferență redusă (RID), pentru componentele orizontale: NS and WE. Rezultatele analizei timp-frecvență pot furniza un criteriu calitativ pentru a confirma eficacitatea procedurii de segmentare, aplicată în premieră în analiza unui semnal seismic.

Semnalul analizat a făcut obiectul unor investigații în multe lucrări științifice care oferă informații asupra modului în care semnalele au fost achiziționate și pre-prelucrate, asupra principalelor componente spectrale, precum și a altor caracteristici specifice [17], [18], [19], etc.

A. Analiza preliminară a semnalelor seismice

Prezenta analiză se va dovedi utilă în interpretarea rezultatelor obținute în segmentarea datelor seismice și în validarea acestora prin analiza timp-frecvență. Prezentăm în Figura 4 componenta seismică NS și spectrul de amplitudine Fourier al acesteia. În cadrul acestei reprezentări se poate constata clar prezența a cel puțin 6 componente de frecvență, localizate la frecvențele de 0.6, 2, 2.6, 2.9, 3.4 și 3.8 Hz, etichetate cu NS1, NS2, NS3, NS4, NS5 și respectiv NS6. Dintre aceste componente de frecvență, dominantă este cea localizată în jurul frecvenței de 2.6 Hz. Dincolo de frecvența de 4 Hz amplitudinile spectrale sunt reduse. Pentru aceeași componentă, reprezentarea în domeniul timp indică localizarea amplitudinii maxime a semnalului la aproximativ 12 s. Frecvențele semnalului se schimbă de la înalte la joase, primele putând fi observate în intervalul de timp de la 8 la 14 secunde. O componentă de joasă frecvență poate fi observată pe tot parcursul înregistrării. Totuși, în anumite intervale de timp poate fi remarcată o componentă de înaltă frecvență.

Același tip de analiză a fost efectuat și pentru componenta seismică WE. În Figura 5 se prezintă componenta seismică WE și spectrul său de amplitudine Fourier.

Se poate constata o comportare similară a acestei componente cu componenta NS. În acest caz, de asemenea, pot fi observate în mod clar cel puțin 6 componente de frecvență localizate la 0.6, 1.4, 1.9, 2.7, 3 și 3.5, etichetate cu WE1, WE2, WE3, WE4, WE5 și respectiv WE6. Dintre acestea, componenta dominantă este localizată în jurul frecvenței de 1.9 Hz. Dincolo de frecvența de 5 Hz, amplitudinile spectrale sunt reduse. Reprezentarea în domeniul timp indică amplitudinea maximă a semnalului seismic localizată în jurul valorii de 9 s. Ca și în cazul anterior, frecvența semnalului se modifică de la înaltă la joasă, iar frecvențele înalte sunt prezente în intervalul de timp de la 8 la 14 s. De asemenea, ca și în cazul anterior, o componentă

de joasă frecvență poate fi observată pe tot parcursul înregistrării, iar în anumite intervale de timp poate fi remarcată o componentă de înaltă frecvență.

B. Segmentarea semnalelor seismice

Segmentarea componentei seismice NS

Analiza vizuală a ambelor semnale menționate anterior, scoate în evidență prezența unor schimbări în conținutul în energie și frecvență al acestora, ceea ce recomandă utilizarea unui model AR pentru procedura de segmentare. Procedura de segmentare a fost aplicată pentru un model AR(1), structura acestuia rezultând după utilizarea mai multor modele AR de diferite ordine.

$$y_t = -\phi_1(i) * y_{t-1} + e_t \quad (18)$$

unde e_t este o secvență aleatoare de medie zero și dispersie $E(e_t^2) = \lambda(i)\sigma_t^2$, cu $\sigma_t^2 = 1$, pentru segmentul i .

Segmentarea optimală utilizând MAP cu ipoteza de zgomot constant, dar necunoscut, și procedura MCMC, pentru diferite valori ale probabilității de producere a schimbării la fiecare moment de timp, q , și următorii parametri de proiectare în schema de căutare: $M = 9$, $l = 5$ și $mseg = 0$, a condus la următoarele secvențe de producere a schimbării în semnalul analizat:

$$\begin{aligned} \widehat{k}_{q=0.01}^n &= (1.80, 8.35, 9.47, 12.28) \\ \widehat{k}_{q=0.03}^n &= (1.80, 8.35, 9.48, 12.13, 12.36, 14.89) \\ \widehat{k}_{q=0.05}^n &= (0.73, 8.35, 9.47, 12.13, 12.36, 14.89) \\ \widehat{k}_{q=0.10}^n &= (0.73, 8.35, 9.47, 12.11, 12.36, 14.89) \\ \widehat{k}_{q=0.20}^n &= (0.73, 8.35, 9.48, 12.12, 12.36, 14.89) \\ \widehat{k}_{q=0.30}^n &= (0.73, 8.35, 9.39, 12.11, 12.36, 14.89) \\ \widehat{k}_{q=0.50}^n &= (0.73, 8.35, 9.40, 12.10) \end{aligned}$$

Rezultatele segmentării, obținute pentru $q = 0.30$ sunt prezentate în Figura 6.

Evaluarea rezultatelor segmentării s-a realizat cu analiza timp-frecvență, respectiv cu calculul distribuției de interferență redusă (RID) [20] (vezi Figura 7). Aceasta a fost calculată utilizând o fereastră Hanning cu $N_f = 4096$, identic cu numărul momentelor de timp, fereastra de netezire în timp, $L_g = 204$, fereastra de netezire în frecvență, $L_h = 512$, și valoarea de prag de 5%. În această reprezentare, pot fi observate cel puțin 5 componente de frecvență bine definite. Cea mai mare amplitudine este localizată la frecvența de 2.9 Hz, iar componenta de cea mai mare durată este localizată la frecvența de 2.6 Hz.

Rezultatele din Figura 6 și Figura 7 scot în evidență faptul că segmentarea MAP este în concordanță cu schimbările în energie și frecvență ale componentei seismice NS. Segmentarea MAP pentru $q = 0.50$, când estimatorul MAP se reduce la estimatorul de verosimilitate maximă (ML), nu determină toate schimbările produse în dinamica semnalului.

Segmentarea componentei seismice WE

Procedura de segmentare a fost aplicată pentru același model ca în cazul anterior, AR(1). Segmentarea s-a realizat în aceleași condiții ca în cazul analizei componentei NS și cu aceiași parametri de proiectare în schema de căutare și a furnizat următoarele rezultate:

$$\widehat{k}_{q=0.01}^n = (0.58, 8.06, 11.93, 12.52)$$

$$\begin{aligned}
\widehat{k}_{q=0.03}^n &= (0.58, 8.06, 11.93, 12.52) \\
\widehat{k}_{q=0.05}^n &= (0.58, 7.65, 11.93) \\
\widehat{k}_{q=0.10}^n &= (0.58, 7.65, 8.48) \\
\widehat{k}_{q=0.20}^n &= (0.58, 7.65, 8.48) \\
\widehat{k}_{q=0.30}^n &= (0.58, 7.65, 8.42, 11.93, 12.52) \\
\widehat{k}_{q=0.50}^n &= (0.58, 7.65, 8.42, 11.98)
\end{aligned}$$

Rezultatele segmentării, pentru componenta seismică WE și $q = 0.30$ sunt date în Figura 8. Rezultatele analizei timp-frecvență pentru componenta seismică WE sunt prezentate în Figura 9 pentru RID, în condițiile utilizării unei ferestre Hanning cu aceeași parametrii ca în cazul analizei componentei seismice NS. Reamintim că frecvențele de interes în cazul componentei WE sunt localizate la frecvențele 0.6, 1.4, 1.9, 2.5, 3 și 3.5 Hz.

Ca și în cazul anterior, se poate observa că rezultatele segmentării, pentru $q = 0.30$, sunt în concordanță cu schimbările în energie și frecvență ale semnalului, rezultate în urma analizei timp-frecvență. Și în acest caz, pentru $q = 0.50$, când estimatorul MAP se reduce la estimatorul ML, nu se determină toate schimbările produse în dinamica semnalului seismic.

Rezultatele segmentării, obținute în ambele cazuri și comparația acestora cu rezultatele furnizate de analiza timp-frecvență scot în evidență eficiența procedurii de segmentare, chiar în cazul utilizării unui model de ordin redus, în ciuda faptului că dinamica semnalului seismic este complexă.

Aplicarea în practică a invenției

În ceea ce privește aplicarea practică a procedurii care face obiectul Cererii de brevet considerăm ca posibil următorul mod de utilizare:

- Pentru un semnal multicanal $y_t, t = 1, \dots, N$, cu p componente și N eșantioane, pentru care se dorește a se efectua segmentarea, urmează a se specifica următorii parametrii ca date de intrare (a se vedea și secțiunea privind Expunerea invenției):
 - Tipul de model utilizat: modelul schimbării în valoarea medie, modelul de regresie, modelul AR(na), modelul ARX(na,nb,nk), etc.;
 - Ipoteza privind factorul de scalare a zgomotului: (i) cunoscut $\lambda(i) = \lambda_0$, (ii) necunoscut, dar constant $\lambda(i) = \lambda$ și (iii) necunoscut și variabil $\lambda(i)$;
 - Probabilitatea ca schimbarea să se producă la fiecare moment, q ;
 - Parametrii de proiectare pentru schema de căutare: numărul de filtre utilizat (M), lungimea minimă a unei secvențe de producere a unei schimbări garantate (ll) și dimensiunea minimă permisă a unui segment ($mseg$). Alegerea acestora poate proveni din cunoașterea aprofundată a procesului fizic, sau din experiența anterioară a utilizatorului. În practică, dacă nu se dispune de nicio informație privind alegerea acestor parametri, se recomandă utilizarea următoarelor valori: numărul fitrelor, M , este recomandat a fi ales $\dim(\theta) + 8$, alegerea ll este legată de identificabilitatea modelului și urmează a fi aleasă mai mare decât $\dim(\theta) + 2$, iar dimensiunea segmentului minim permis, $mseg$, poate fi ales 0, în ideea că o schimbare în dinamica semnalului se poate produce la orice moment de timp;
- Procedura furnizează numărul segmentelor n și locațiile acestora k_i $k^n = k_1, k_2, \dots, k_n$ ale segmentelor quasi-staționare rezultate;

- În scopul validării rezultatelor segmentării, se poate utiliza analiza timp-frecvență a semnalului sau componentelor acestuia, care va evidenția principalele momente ale producerii schimbărilor în energie și frecvență ale semnalului.

Bibliografie

- [1] F. Gustafsson, Adaptive Filtering and Change Detection, Wiley, NJ, 2001.
- [2] M. Basseville, I. V. Nikiforov, Detection of Abrupt Changes: Theory and Applications, Information and System Science Series, Prentice Hall, Englewood Cliffs, NJ., 1993.
- [3] H. Ohlson, L. Ljung, S. Boyd, Segmentation ARX-models using sum-of-norms regularization, Automatica IFAC 46 (6) (2010) 1107-1111.
- [4] P. Hubert, L. Padovese and J. M. Stern, A Sequential Algorithm for Signal Segmentation, Entropy MDPI (2018) 1-20.
- [5] R. Zimroz, M. Madziarz, G. Zak, A. Wylomanska and J. Obuchowski, Seismic signal segmentation procedure using time-frequency decomposition and statistical modeling, Journal of Vibroengineering 17 (2015) 3111-3121.
- [6] D. Wang, K.-L. Tsui and Y. Qin, Optimization of segmentation fragments in empirical wavelet transform and its applications to extracting industrial bearing fault features, Measurement 133 (2019) 328-340.
- [7] J. Segen, A. Sanderson, Detecting changes in a time-series, IEEE Transactions on Information Theory. 26 (2) (1980) 249-255.
- [8] H. Bloom, Y. Bar-Shalom, The interacting multiple model algorithm for systems with Markovian switching coefficients, IEEE Transactions on Automatic Control. 33 (8) (1988) 780-783.
- [9] P. Anderson, Adaptive forgetting in recursive identification through multiple models, International Journal of Control. 42 (5) (1985) 1175-1193.
- [10] W. J. Fitzgerald, J. J. K. Ruanaidh, J. A. Yates, Generalized changepoint detection, Technical Report CUED/F-INFENG/TR 187, Department of Engineering, University of Cambridge, England, 1994.
- [11] A. G. Gillies, D. L. Anderson, D. Mitchell, R. Tinawi, M. Saatcioglu, N. J. Gardner, A. Ghoborah, The August 17, 1000, Kocaeli (Turkey) earthquake - lifeliness and preparedness, Canadian Journal of Civil Engineering 28 (6) (2001) 881-890.
- [12] C. H. Chen, On a segmentation algorithm for seismic signal analysis, Geoexploitation, 23 (1) (1984) 35-40.
- [13] I. V. Nikiforov, I. N. Tikhonov, Application of change detection theory to seismic signal processing. In Detection of Abrupt Changes and Dynamical Systems, Eds. M. Basseville, A. Benveniste, LNCIS 77, Springer, New York (1986) 355-373.
- [14] R. S. Wu, Y. Wang, New flexible segmentation technique in seismic data compression using local cosine transform, Proc. of SPIE 3813, Wavelet Applications in Signal and Image Processing VII, 784, Denver, CO, 1999, 784-794.
- [15] R. R. Coifman, M. V. Wickerhauser, Entropy based algorithms for best basis selection, IEEE Trans. on Information Theory, 38 (2) (1992) 713-718.

- [16] E. Pikoulis, A new automatic methods for seismic signals segmentation, Proc. of IEEE International Conference on Acoustic, Speech and Signal Processing (ICASSP), Kyoto, Japan, 2012, 3973-3976.
- [17] A. G. Gillies, D. L. Anderson, D. Mitchell, R. Tinawi, M. Saatcioglu, N. J. Gardner, A. Ghoborah, The August 17, 1000, Kocaeli (Turkey) earthquake - lifeliness and preparedness, Canadian Journal of Civil Engineering 28 (6) (2001) 881-890.
- [18] B. Teymur, S. P. G. Madablushi, D. E. Newland, Analysis of Earthquake Motions Recorded During the Kocaeli Earthquake, Turkey 1999, CUED/D-Soils/TR312, 2000.
- [19] M. Erdik, Report on 1999 Kocaeli and Düzce (Turkey) earthquake, Dept. of Earthquake Engineering, Istanbul, Turkey, 2000.
- [20] J. Jeong, W. J. Williams, Kernel design for reduced interference distributions, IEEE Transactions on Signal Processing, 40 (2) (1992) 402-4012.

PROCEDURĂ PENTRU SEGMENTAREA SEMNALELOR MULTICANAL ÎN VEDEREA EXTRAGERII CARACTERISTICILOR

REVENDICĂRI

Procedură de segmentare a semnalelor multicanal, în vederea extragerii caracteristicilor, **caracterizată prin aceea că** face uz de estimatorul de probabilitate maximă a posteriori (MAP), pentru trei ipoteze diferite, furnizând numărul segmentelor de date cvasi-staționare și locațiile producerii schimbărilor în semnalul analizat, pe baza estimațiilor celor mai mici pătrate ale parametrilor modelelor și ale matricei de covarianță a acestora, pentru fiecare segment cvasi-staționar, așa cum se prezintă în Figura 1.

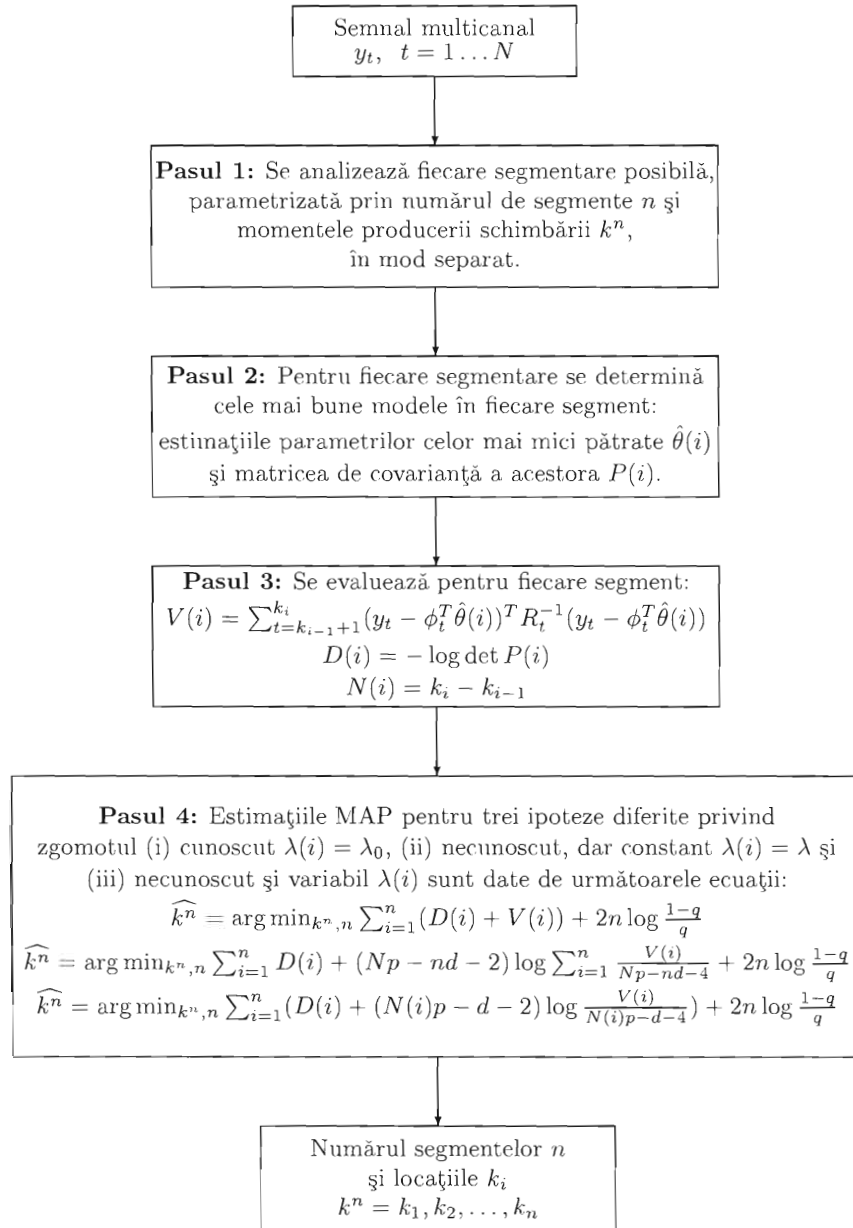


Figura 1: Procedura de segmentare a semnalelor multicanal utilizând MAP.




Figura 2: Segmentarea semnalului generat de modelul ARX(2,2,1) - Semnalul cu momentele reale ale producerii schimbărilor parametrilor, parametrii modelului reali și estimați, parametrul real și estimat λ ($q = 0.30$)




Figura 3: Rezultatele simulării MC ale segmentării semnalului generat de modelul ARX(2,2,1) ($q = 0.30$)

44




Figura 4: Componenta seismică NS și spectrul de amplitudine Fourier.




Figura 5: Componenta seismică WE și spectrul de amplitudine Fourier.




Figura 6: Componenta seismică NS cu momentele producerii schimbărilor, estimațiile parametrilor modelului și ale dispersiei zgomotului ($q = 0.30$).




Figura 7: Distribuția timp-frecvență de interferență redusă (RID) a componentei seismice NS.

42

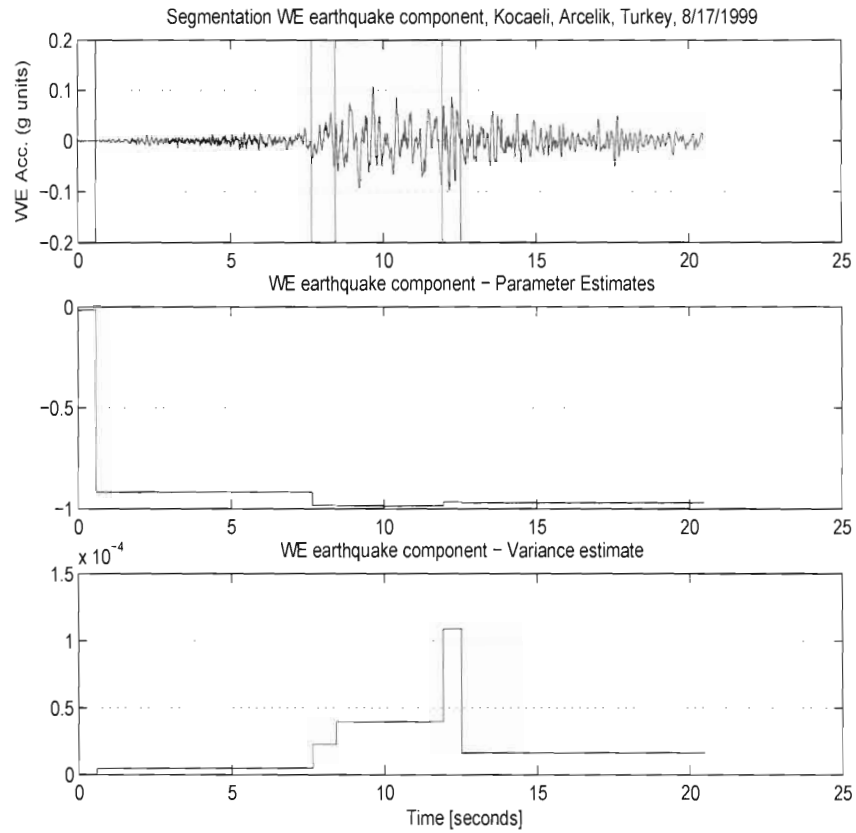


Figura 8: Componenta seismică WE cu momentele producerii schimbărilor, estimațiile parametrilor modelului și ale dispersiei zgomotului ($q = 0.30$).




Figura 9: Distribuția timp-frecvență de interferență redusă (RID) a componentei seismice WE.