

CONTRIBUȚII LA MONITORIZAREA DE LA DISTANȚĂ A ACTIVITĂȚII ELECTRICE A INIMII

Teză destinată obținerii
titlului științific de doctor inginer
la
Universitatea "Politehnica" din Timișoara
în domeniul INGINERIE ELECTRICĂ
de către

Ing. Beatrice Arvinti

Conducător științific: prof.univ.dr.ing Dumitru Toader
Referenți științifici: prof.univ.dr.ing. Marina Țopa
prof.univ.dr.ing. Alexandru Isar
prof.univ.dr. Gheorghe-Ioan Mihalăș

Ziua susținerii tezei: 25.09.2012

Seriile Teze de doctorat ale UPT sunt:

- | | |
|------------------------|---|
| 1. Automatică | 7. Inginerie Electronică și Telecomunicații |
| 2. Chimie | 8. Inginerie Industrială |
| 3. Energetică | 9. Inginerie Mecanică |
| 4. Ingineria Chimică | 10. Știința Calculatoarelor |
| 5. Inginerie Civilă | 11. Știința și Ingineria Materialelor |
| 6. Inginerie Electrică | |

Universitatea „Politehnica” din Timișoara a inițiat seriile de mai sus în scopul diseminării expertizei, cunoștințelor și rezultatelor cercetărilor întreprinse în cadrul școlii doctorale a universității. Seriile conțin, potrivit H.B.Ex.S Nr. 14 / 14.07.2006, tezele de doctorat susținute în universitate începând cu 1 octombrie 2006.

Copyright © Editura Politehnica – Timișoara, 2012

Această publicație este supusă prevederilor legii dreptului de autor. Multiplicarea acestei publicații, în mod integral sau în parte, traducerea, tipărirea, reutilizarea ilustrațiilor, expunerea, radiodifuzarea, reproducerea pe microfilme sau în orice altă formă este permisă numai cu respectarea prevederilor Legii române a dreptului de autor în vigoare și permisiunea pentru utilizare obținută în scris din partea Universității „Politehnica” din Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300159 Timișoara, Bd. Republicii 9,
tel. 0256 403823, fax. 0256 403221
e-mail: editura@edipol.upt.ro

Cuvânt înainte

Teza de doctorat a fost elaborată pe parcursul activității în cadrul Departamentului *Bazele Fizice ale Ingineriei* al Universității „Politehnica” din Timișoara.

Mulțumiri se cuvin domnului conducător de doctorat, prof.dr.ing. Dumitru Toader pentru sprijinul acordat pe durata stagiului doctoral.

Doresc să exprim mulțumiri deosebite domnului prof.dr.ing. Alexandru Isar pentru îndrumarea și încurajarea constantă, care m-au ajutat să finalizez teza de doctorat.

Le mulțumesc domnului prof.dr.ing.habil. Hannes Töpfer de la *Technische Universität Ilmenau*, Germania și în special domnului dr. Ronny Stolz de la *Institut für Photonische Technologien*, Jena, Germania pentru colaborare și pentru ocazia de a lua contact cu tehnica mai puțin răspândită la ora actuală a magnetocardiogramelor, în timpul stagiului doctoral efectuat în Germania.

Totodată, doresc să mulțumesc membrilor comisiei de doctorat, prof.dr.ing. Marina Dana Țopa și prof.dr. Gheorghe-Ioan Mihalăș pentru evaluarea tezei și elaborarea referatelor de specialitate.

Și nu în ultimul rând, doresc să mulțumesc familiei pentru răbdarea și încurajarea din această perioadă.

Timișoara, august 2012

Beatrice Arvinti

Realizarea acestei teze de doctorat a fost parțial sprijinită de grantul strategic POSDRU/88/1.5/S/50783, cofinanțat din Fondul Social European – Investește în Oameni, Programul Operațional Sectorial Dezvoltarea Resurselor Umane 2007-2013, în cadrul proiectului strategic ID 50783(2009) „Prin burse doctorale spre cercetare de nivel european”.

Arvinti, Beatrice

Contribuții la monitorizarea de la distanță a activității electrice a inimii

Teze de doctorat ale UPT, Seria 6, Nr. 31, Editura Politehnica, 2012, 174 pagini, 115 figuri, 14 tabele.

ISSN: 1842-7022

ISBN: 978-606-554-525-0

Cuvinte cheie:

monitorizare de la distanță, electrocardiogramă, magnetocardiogramă, analiză wavelet, reducerea deviației liniei de bază, zgomot de achiziție, compresie

Rezumat,

Necesitățile actuale de supraveghere a situațiilor de risc cardiac, impun studiul și dezvoltarea unui procedeu de monitorizare a activității electrice a inimii. Tema de cercetare aleasă urmărește să ofere un ajutor medicului pentru prediagnosticarea afecțiunilor cardiace în sensul ameliorării sarcinii de interpretare a electrocardiogramei (EKG) sau a magnetocardiogramei (MKG). Analiza wavelet a fost propusă drept o alternativă la analiza Fourier, deoarece transformata wavelet poate fi privită drept o reprezentare timp-frecvență mai utilă în modelarea fenomenelor nestaționare, precum semnalele biomedicale. Prezenta teză de doctorat are drept scop dezvoltarea și testarea unor algoritmi de prelucrare, bazați pe analiza wavelet, pentru principalele etape de achiziție și monitorizare de la distanță: reducerea deviației liniei de bază a semnalelor EKG și MKG, reducerea zgomotului de achiziție și compresia semnalelor în vederea transmisiei la distanță.

CUPRINS

1. INTRODUCERE.....	9
2. SEMNALE BIOMEDICALE	21
2.1. Semnalul EKG	21
2.2. Semnalul MKG.....	21
2.3. Principiul măsurării EKG	24
2.3.1. Undele EKG	26
2.3.2 Tipuri de înregistrare EKG	27
2.3.3. Interpretarea EKG – ului	28
2.3.4. Electrocardiograma patologică	29
2.3.4.1. Aritmii cardiace	29
2.3.4.2. Hipertrofiile atriale.....	32
2.3.4.2.1. Hipertrofia atrială dreaptă	32
2.3.4.2.2. Hipertrofia atrială stângă.....	32
2.3.4.3. Hipertrofiile ventriculare	33
2.3.4.3.1. Hipertrofia ventriculară stângă (HVS)	33
2.3.4.3.2. Hipertrofia ventriculară dreaptă (HVD).....	34
2.3.4.4. Tulburările de conducere intra-cardiacă.....	34
2.3.4.4.1. Blocul sinoatrial	34
2.3.4.4.2. Blocul atrio-ventricular	35
2.3.4.5. Blocurile de ramură	35
2.3.4.5.1. Blocul de ramură stângă (BRS)	35
2.3.4.5.2. Blocul de ramură dreaptă (BRD)	35
2.3.4.6. Angina pectorală	36
2.3.4.7. Infarctul miocardic acut (IMA).....	36
3. METODELE MATEMATICE DE PRELUCRARE A SEMNALELOR BIOMEDICALE	38
3.1. Reprezentări timp – frecvență	38
3.2. Transformata Fourier	39
3.3. Transformata wavelet	41
3.3.1. Definiția și istoria analizei wavelet	41
3.3.2. Aspecte teoretice ale transformatei wavelet.....	41

3.3.3. Transformata Wavelet Continuă (CWT)	57
3.3.4. Transformata Wavelet Discretă (DWT)	58
3.3.5 Analiza multirezoluție	61
4. PRELUCRAREA SEMNALULUI EKG	67
4.1. Reducerea deviației liniei de bază a semnalului EKG.....	67
Rezumat 4.1	82
4.2. Reducerea zgomotului de achiziție al semnalului EKG	83
Rezumat 4.2	92
4.3. Transmiterea la distanță a semnalului EKG	93
4.3.1. Metodă de compresie a electrocardiogramelor	94
Rezumat 4.3.1	101
4.3.2. Metodă adaptivă de compresie a electrocardiogramelor	102
Rezumat 4.3.2	126
4.4. Detecția complexului QRS al electrocardiogramelor.....	127
Rezumat 4.4	134
5. PRELUCRAREA SEMNALULUI MKG	135
5.1. Reducerea deviației liniei de bază a semnalului MKG	135
5.2. Reducerea zgomotului de achiziție a semnalului MKG	145
5.3. Compresia semnalului MKG.....	147
5.4. Semnalul EKG versus semnalul MKG	155
Rezumat 5.....	156
6. CONCLUZII	159
6.1. CONTRIBUȚIILE TEZEI DE DOCTORAT.....	159
6.2. PERSPECTIVE VIITOARE	162
BIBLIOGRAFIE	163

LISTĂ DE TABELE

Nr. crt.	Numărul tabelului	Titlul tabelului
1.	Tabel 2.2.1.	Parametri principali ai electronicii de tip FLL (IPHT, Jena)
2.	Tabelul 4.1.	Rezultate ale primului set de simulări
3.	Tabelul 4.2.	Rezultatele simulărilor efectuate.
4.	Tabel 4.3.	Rezultatele simulării efectuate pentru semnalul EKG 109, utilizând familia de funcții wavelet mamă Daubechies și patru niveluri de descompunere. Coeficienții din secvențele A_4 și d_4 au fost cuantizați pe câte 11 biți, așa că nu au mai fost trecuți în tabel.
5.	Tab 4.4.	Rezultatele simulării efectuate pentru semnalul EKG 109, utilizând familia de funcții wavelet mamă Daubechies și cinci niveluri de descompunere. Coeficienții din secvențele A_5 și d_5 au fost cuantizați pe câte 11 biți, așa că nu au mai fost trecuți în tabel.
6.	Tab. 4.5.	Rezultatele simulării efectuate pentru semnalul EKG 109, utilizând familia de funcții wavelet mamă Daubechies și șase niveluri de descompunere. Coeficienții din secvențele A_6 și d_6 au fost cuantizați pe câte 11 biți, așa că nu au mai fost trecuți în tabel.
7.	Tab. 4.6.	Rezultatele optime obținute în urma aplicării metodei de compresie adaptivă
8.	Tab. 4.7.	Rezultatele optime obținute utilizând familia de funcții wavelet mamă Daubechies în urma aplicării metodei de compresie adaptivă

- | | | |
|-----|------------|--|
| 9. | Tab. 4.8. | Rezultatele simulării realizate pentru semnalul EKG 118em |
| 10. | Tab. 4.9. | Rezultatele simulării realizate pentru semnalul EKG 119em |
| 11. | Tab. 10. | Rezultatele optime obținute utilizând familia de funcții wavelet mamă Villasenor în urma aplicării metodei de compresie adaptivă |
| 12. | Tabel 5.1. | Rezultatele algoritmului de compresie obținute pentru o valoare adaptivă de prag |
| 13. | Tabel 5.2. | Rezultatele algoritmului de compresie testat utilizând mai multe niveluri de descompunere |
| 14. | Tabel 5.3. | Rezultatele algoritmului de compresie testat utilizând mai multe familii de funcții wavelet mamă ortogonale. |

LISTĂ DE FIGURI

Nr. crt.	Numărul figurii	Titlul figurii
1.	Fig. 2.1.	Frontul de undă al excitației electrice a inimii.
2.	Fig.2.2.	Forma standard a electrocardiogramei (EKG).
3.	Fig. 2.3.	Plasarea electrozilor.
4.	Fig. 2.4.	Semnalul EKG .
5.	Fig. 2.5.	Bradycardia sinusală (frecvența sub 60 bătăi/min).
6.	Fig. 2.6.	Tahicardia sinusală (frecvența inimii de 90-120 bătăi/min).
7.	Fig. 2.7.	Fibrilația atrială (tulburări neregulate de ritm).
8.	Fig. 2.8.	Hipertrofia atrială dreaptă.
9.	Fig. 2.9.	Hipertrofia atrială stângă.
10.	Fig. 2. 10.	Hipertrofia ventriculară stângă.
11.	Fig. 2.11.	Hipertrofia ventriculară dreaptă
12.	Fig. 2.12.	Blocul sinoatrial.
13.	Fig. 2.13.	Blocul de ramură stângă (BRS).
14.	Fig. 2.14.	Blocul de ramură dreaptă (BRD).
15.	Fig. 2.15.	Angina pectorală.

16. Fig. 2.16 a). Unda T înaltă – la câteva minute de la debutul IMA.
Fig. 2.16 b). ST supra-denivelat.
17. Fig. 2.17. Unda T coronarian.
18. Figura 3.1. O comparație a reprezentărilor în domeniul timp și în domeniul frecvență ale aceluiași semnal.
19. Figura 3.2. Funcție wavelet de tip Coiflet.
20. Figura 3.3. Funcția wavelet propusă de Haar.
21. Figura 3.4. Funcția wavelet propusă de Daubechies (funcția prezintă 2 momente nule).
22. Figura 3.5. Funcția wavelet Db20 propusă de Daubechies.
23. Figura 3.6. Funcția wavelet Coif5.
24. Figura 3.7. Funcția wavelet Symm4.
25. Figura 3.8. Funcția wavelet Battle-Lemarié2.
26. Figura 3.9. Funcția wavelet biortogonală bior1.3
27. Figura 3.10. Funcția wavelet biortogonală bior2.4
28. Figura 3.11. Funcția wavelet biortogonală bior5.5.
29. Figura 3.12. Structura bancului de filtre care implementează transformarea DWT.
30. Figura 3.13. Partajarea planului timp-frecvență de către descompunerea în serie Fourier.
31. Figura 3.14. Partajarea planului timp-frecvență realizată de STFT cu o localizare temporală (a) sau frecvențială (b) bună.
32. Figura 3.15. Partajarea planului timp-frecvență realizată de Transformata Wavelet Continuă.

33. Fig.4.1. EKG prezentând o deviație a liniei de bază și alte distorsiuni.
34. Fig. 4.2 Procedura de eliminare a deviației liniei de bază.
35. Fig. 4.3. Schema sistemului care calculează SWT
36. Fig. 4.4. Extragerea coeficienților de aproximare ai semnalului EKG (în ordine crescătoare a nivelului de descompunere de la stânga la dreapta și de sus în jos).
37. Fig. 4.5. Extragerea coeficienților de detaliu ai semnalului EKG (în ordine crescătoare a nivelului de descompunere de la stânga la dreapta și de sus în jos).
38. Fig. 4.6a.
Fig. 4.6b. Răspunsul la impuls al filtrului trece-jos echivalent. Amplitudinea normalizată a răspunsului în frecvență al filtrului trece-jos echivalent.
39. Fig. 4.7 a) EKG prezentând o deviație a liniei bază
b) EKG corectat.
40. Fig 4.8. Prima bătaie a inimii a) înainte (linia de bază este reprezentată cu roșu) și b) după aplicarea metodei de corecție a deviației liniei de bază (linia de bază este reprezentată cu verde)
41. Fig 4.9. Primele trei bătăi ale inimii a) înainte (linia de bază este reprezentată cu roșu) și b) după aplicarea metodei de corecție a deviației liniei de bază (linia de bază este reprezentată cu verde)
42. Fig 4.10. Rezultatele simulării obținute pentru EKG-ul 103 a cărui înregistrare începe la momentul 18'20"
43. Fig. 4.11a.
Fig. 4.11b. Semnalul EKG 215 original.
Semnalul EKG 215 corectat.
44. Fig. 4.12a.
Fig. 4.12b. Cinci bătăi ale semnalului EKG având linia de bază estimată cu roșu.

Semnalul după aplicarea metodei de corecție wavelet propusă.
45. Fig.4.13 Semnalul EKG 103, linia de bază fiind marcată cu roșu.
46. Fig.4.14 Semnalul EKG 103 după aplicarea algoritmului de corecție utilizând funcția wavelet mamă Db5, linia de bază fiind marcată cu verde.
47. Fig. 4.15 Zoom asupra zonei cu deviație accentuată a semnalului EKG 103, linia de bază fiind marcată cu roșu.

48. Fig. 4.16 Zoom asupra zonei cu deviație accentuată a semnalul EKG 103 după aplicarea algoritmului de corecție utilizând funcția wavelet mamă Db5
49. Fig.4.17 Semnalul EKG 103 după aplicare algoritmului de corecție utilizând funcția wavelet mamă Db5 pe 10 niveluri de descompunere.
50. Fig. 4.18. Algoritmul propus.
51. Fig. 4.19. Semnalul de intrare: a) întregul semnal, b) primele trei bătăi.
52. Fig.4.20 Semnalul EKG de intrare. În întregime (sus) și primele patru bătăi (jos).
53. Fig. 4.21a.
Fig. 4.21b. Rezultatul metodei de reducere a zgomotului de achiziție propuse pentru întregul semnal (sus) și pentru patru bătăi (jos)
Suprapunerea semnalului achiziționat (albastru) și filtrat (galben).
54. Fig. 4.22. Rezultatul combinat al metodei de filtrare și de reducere a deviației liniei de bază a semnalului EKG.
55. Fig. 4.23. Suprapunerea semnalului EKG original de intrare (albastru) și a semnalului EKG a cărui deviație a liniei de bază a fost corectată (galben)
56. Fig. 4.24. Suprapunerea formei de undă a semnalului EKG original (albastru), filtrat (galben) și cu linie de bază corectată (negru).
57. Fig. 4.25. Forma de undă a zgomotului eliminat.
58. Fig. 4.26. Histograma coeficienților de detaliu ai zgomotului eliminat prin metoda de filtrare wavelet propusă.
59. Fig.4.27 Sistem de monitorizare EKG în timp real.
60. Fig. 4.28. Structura sistemului de achiziție a semnalului EKG.
61. Fig. 4.29. Strategia de compresie pentru primul set de simulări.
62. Fig. 4.30. Arhitectura sistemului de compresie implementat pentru a doua categorie de experimente.

63. Fig. 4.31. Semnalul EKG achiziționat, 102 (sus); semnalul după filtrare (mijloc) și după filtrare și corecția deviației liniei de bază (jos).
64. Fig. 4.32. Selecția caracteristicilor metodei de compresie. Sus: Dependența factorului de calitate (QF) de funcția wavelet mamă (vm) și de prag (Thr). Jos: Dependența factorului de compresie (CR) de funcția wavelet mamă (vm) și de prag (Thr).
65. Fig. 4.33. Efectetele cuantizării pe 7 biți asupra semnalului 102. Semnalul înainte de cuantizare (sus) și după cuantizare (jos).
66. Figura 4.34. Secvența coeficienților wavelet cuantizați, obținuți după filtrarea HT a semnalului EKG 102, utilizând un prag de valoare 1.
67. Figura 4.35. Semnalul EKG original (sus) și reconstruit (jos).
68. Fig. 4.36. Structura bancului de filtre care implementează DWT.
69. Fig. 4.37. Secvența de coeficienți wavelet distribuiți pe subbenzi: secvența coeficienților de aproximare împreună cu cele patru secvențe de coeficienți de detaliu.
70. Fig. 4.38. Semnalul EKG original, semnalul după reducerea zgomotului de achiziție și după corecția deviației liniei de bază.
71. Fig.4.39. Zoom pe șapte bătăi ale electrocardiografei originale (sus), rezultatul obținut după filtrarea zgomotului biologic (la mijloc) și semnalul obținut după corecția liniei de bază (jos).
72. Fig. 4.40. Zoom realizat asupra a șapte bătăi ale semnalului EKG original 102 și ale semnalului reconstruit.
73. Fig. 4.41. Zoom asupra a cinci bătăi ale semnalului EKG original 117 (forma de undă de sus) și semnalul reconstruit după compresie (forma de undă de jos).
74. Fig 4.42. Strategia de optimizare a parametrilor algoritmului adaptiv de compresie.
75. Fig. 4.43. Electrocardiograma originală 109 (sus), semnalul obținut după filtrarea zgomotului de achiziție și corecția liniei de bază (jos).
76. Fig. 4.44. Coeficienții wavelet obținuți prin aplicarea DWT electrocardiografei 109.

77.	Fig. 4.45	Rezultate de simulare pentru electrocardiograma 109.
78.	Fig. 4.46	Detaliu asupra a trei bătăi ale semnalului EKG 109 (a) reconstruit utilizând Db20 și 5 niveluri de descompunere (b) și Db16 și 6 niveluri de descompunere (c).
79.	Fig. 4.47.	Variația valorii de SNR (sus) și de CR (jos) cu numărul de momente nule pentru familia de funcții wavelet mamă Daubechies obținute aplicând algoritmul de compresie adaptiv semnalului EKG 109 folosind cinci niveluri de descompunere ale DWT.
80.	Fig.4.48	Distribuția rezultatelor funcție de familia de funcții wavelet mamă optimă
81.	Fig.4.49	Distribuția rezultatelor funcție de numărul de momente nule.
82.	Fig. 4.50	Semnalul EKG 119m12 (sus) după aplicarea metodei de corecție a liniei de bază bazată pe funcții wavelet biortogonale (jos)
83.	Fig. 4.51	Semnalul EKG 119m12 (sus) după aplicarea metodei de filtrare folosind funcții wavelet biortogonale (jos).
84.	Fig. 4.52.	Coeficienții wavelet rezultați prin aplicarea DWT pe cinci niveluri de descompunere asupra semnalului EKG 119m12.
85.	Fig. 4.53	Semnalul EKG filtrat (sus) și reconstruit după aplicarea metodei de compresie (jos).
86.	Fig. 4.54	Semnalul EKG original (sus, negru), corectat (sus, albastru) și reconstruit după aplicarea metodei de compresie (jos)
87.	Fig. 4.55.	Distribuția rezultatelor obținute funcție de numărul de momente nule.
88.	Fig. 4.56.	Semnal EKG standard
89.	Fig. 4.57	Arhitectura sistemului de detecție a complexului QRS.
90.	Fig. 4.58a) Fig. 4.58b)	Semnalul EKG 113. Semnalul EKG 113 după detecția undei R.
91.	Fig. 4.59a)	O bătaie a semnalului EKG original 113.
	Fig. 4.59b)	Coeficienții wavelet pentru primul nivel de aproximare.
	Fig. 4.59c)	Coeficienții wavelet pentru al doilea nivel de aproximare.
	Fig. 4.59d)	Coeficienții wavelet pentru al treilea nivel de

		aproximare.
92.	Fig. 4.60.	Detectia complexului QRS pentru semnalul EKG 113.
93.	Fig.4.61a Fig. 4.61b.	Rezultatul algoritmului de detectie al complexului QRS pentru semnalul EKG 107. Rezultatul algoritmului de detectie al complexului QRS pentru semnalul EKG 107 utilizand algoritmul completat cu pragul N_g
94.	Fig. 4.62.	Rezultatul algoritmului de detectie al complexului QRS pentru semnalul EKG 117.
95.	Fig.5.1	Măsurare MKG în timp real (IPHT, Jena).
96.	Figura 5.2.	Semnal MKG inițial.
97.	Figura 5.3.	Componentele spectrale ale semnalului MKG.
98.	Figura 5.4.	Rezultatul procedurii de filtrare în domeniul frecvență.
99.	Figura 5.5.	Cinci bătăi ale semnalului MKG filtrat utilizând FFT.
100.	Figura 5.6.	Estimarea liniei de bază utilizând undișoara mamă Daubechies2.
101.	Fig. 5.7.	Schema metodei de corecție a liniei de bază.
102.	Figura 5.8.	Rezultatul metodei de corecție a deviației liniei de bază a semnalului MKG.
103.	Figura 5.9	. Rezultatul procedurii de corecție a liniei de bază utilizând analiza wavelet și 10 niveluri de descompunere.
104.	Figura 5.10.	Cinci bătăi ale semnalului MKG înainte (a) și după corecția liniei de bază (b).
105.	Fig.5.11a) Fig.5.11b .	Rezultatul metodei de reducere a deviației liniei de bază utilizând funcția wavelet mamă Haar Rezultatul metodei de reducere a deviației liniei de bază utilizând funcția wavelet mamă Coiflet4.
106.	Fig.5.12.	Comparație între rezultatele obținute utilizând funcțiile wavelet mamă Haar și Coiflet4.
107.	Figura 5.13.	Rezultatul metodei wavelet de corecție a liniei de bază pentru 12 niveluri de descompunere.
108.	Figura 5.14.	Rezultatul metodei de filtrare a zgomotului de achiziție bazată pe analiza wavelet.
109.	Figura 5.15.	Strategia de optimizare a compresiei semnalelor MKG
110.	Fig. 5.16.	Semnalul MKG original (sus, negru) și semnalul MKG după aplicarea metodei de corecție a deviației liniei de bază (jos, albastru).
111.	Fig.5.17	Distribuția rezultatelor obținute pentru familia de funcții wavelet mamă Daubechies

112. Fig.5.18 Distribuția rezultatelor obținute pentru familia de funcții wavelet mamă Coiflet
113. Fig.5.19 Distribuția rezultatelor obținute pentru familia de funcții wavelet mamă Symmlet
114. Fig. 5.20. Semnalul MKG reconstruit după compresie utilizând funcția wavelet mamă Db20 și 7 niveluri de descompunere.
115. Fig. 5.21. Semnalul MKG fetal original (negru), semnalul MKG obținut după filtrare și corecția liniei de bază (albastru) și semnalul MKG reconstruit după compresie (roșu).

1. INTRODUCERE

Corpul uman este și va fi un subiect important de cercetare științifică, doar în rare situații omul se poate lăuda că posedă suficiente cunoștințe despre sine. Unul din mijloacele specifice de interacțiune cu mediul înconjurător a organismului uman constă în emiterea unor semnale iar aceste semnale trebuie să fie captate și prelucrate pentru a permite emiterea unor ipoteze plauzibile privind posibile defecțiuni ale funcționării organismului. Semnalul biomedical, care poate fi de natură mecanică (unde acustice) sau electrică (cum sunt majoritatea semnalelor emise de către corpul uman) conține informații prețioase despre starea organismului.

În practica medicală actuală, semnale ușor de captat (achiziționat) și de interpretat sunt rareori întâlnite. De regulă, peste semnalul util se suprapune un zgomot dat fie de înșuși sistemul de achiziție, fie cauzat de mișcările sau respirația sacadată a pacientului, fie datorat unor interferențe cu rețele sau aparate electrice apropiate. Deoarece un diagnostic corect poate fi pus doar având la bază informații fiabile, semnalele biomedicale brute și afectate de zgomot trebuie să fie inițial prelucrate.

Printre semnalele biomedicale cele mai utilizate la ora actuală se numără semnalul produs de activitatea cardiacă a inimii. Semnalul în discuție este însă și unul dintre cele mai sensibile la zgomot, peste frecvența specifică a celulelor miocardice suprapunându-se în special activitatea electrică musculară, aceasta fiind de frecvență apropiată. Înțelegem prin semnal orice entitate purtătoare de informație, deci entități care ne pot comunica date noi și relevante într-un anumit context. Sursele de proveniență ale semnalelor pot fi diferite, însă majoritatea semnalelor sunt de natură electrică fie prin origine fie au devenit semnale electrice datorită captorilor și transductorilor (microfoane, membrane, senzori termici, optici, de presiune, de poziție sau de viteză) utilizați pentru achiziție.

O primă clasificare a semnalelor ne ajută să distingem între : semnale analogice – întâlnite în mod uzual în natură; semnale analog-numerice – produse de diverse dispozitive de captare a semnalelor întâlnite în natură, cum ar fi captoare, convertoare sau amplificatoare; sau semnale numerice – produse de dispozitive de conversie a semnalelor analogice în semnale numerice.

Obiectul de studiu al prezentei lucrări este constituit de semnalele emise de corpul uman, numite și semnale biologice, cum este semnalul de tip electrocardiogramă (EKG). Tema propusă se axează pe prelucrarea unor semnale biologice vitale organismului uman, cum este semnalul care ne oferă informații despre organul fără de care nu ar funcționa organismul, inima. Etapa esențială în faza de prediagnosticare, urmând să faciliteze punerea corectă a unui diagnostic, se referă la prelucrarea după achiziție a semnalului EKG. Prin prelucrarea unui semnal

se înțelege analiza, interpretarea și transformarea sa. Studiul propus prevede tehnici de creștere a probabilității diagnosticării corecte.

Tema aleasă este justificată de necesitățile de a preveni bolile cardiace, care apar foarte frecvent conform statisticilor elaborate de instituții acreditate și împuternicite de a interprinde investigații în domeniul medical. Studiile efectuate de organisme competente precum Organizația Mondială a Sănătății (OMS) oferă statistici alarmante privind incidența bolilor cardiovasculare, constatând frecvența decesului datorat unei boli cardiovasculare (infarct miocardic) [1]. OMS este considerată drept inițiatorul unei baze de date cuprinzătoare privind starea de sănătate, cazurile patologice și decesele înregistrate în sistemele de sănătate a fiecărei țări. Conform statisticilor naționale [2], se înregistrează decesul unei persoane la fiecare 10 minute din cauza acestor afecțiuni cardiace, situație care nu mai este o consecință a vârstei înaintate. Deosebit de îngrijorător este și faptul că, în România, vârsta persoanelor pasibile de infarct miocardic a scăzut sub 45 ani. La nivel mondial situația ia aspecte și mai grave, constatându-se decesul anual a 17 milioane de oameni din cauza bolilor cardiovasculare, la fiecare cinci secunde survenind un atac de cord. Se știe că atacurile de cord nu duc în mod necesar și iremediabil la deces, însă s-a constatat că o persoană care a suferit deja de un atac de cord este pasibilă de a mai suferi și alte atacuri, ale căror consecințe nu pot fi estimate dinainte. Conform declarațiilor OMS [3] rata mortalității în România în urma afecțiunilor cardiovasculare este de 61% din numărul total de decese, mare comparativ cu UE unde rata este 37% sau chiar comparativ cu o rată de 53% din numărul total înregistrat de decese în statele care au aderat recent la UE. Conform statisticilor Ministerul Sănătății (MS), în România s-au înregistrat 253.000 decese în anul 2008. Dintre acestea, mai mult de jumătate (mai exact 153.137 decese) au fost consecințele unei boli de inimă. Alte boli cu risc major pentru organismul uman au fost mai slab reprezentate statistic. Putem enumera comparativ, în ordinea frecvenței, afecțiunile cerebrovasculare reprezentate cu 48.582 decese, urmate de cardiopatia ischemică reprezentată cu 31.025 decese și hipertensiunea arterială cu 24.504 decese [4]. Un studiu independent efectuat de o altă asociație cu profil asemănător celor prezentate anterior, *American Heart Association* [5] ajunge la rezultate asemănătoare și alarmante în ceea ce privește incidența bolilor cardiace. Potrivit statisticii realizate de asociația americană, România ocupă locul trei în Europa, după Rusia și Bulgaria, în ceea ce privește frecvența bolilor cardiovasculare. În concluzie, pe plan mondial, o cauză majoră de invaliditate și deces este reprezentată de bolile cardiovasculare. Medicii specialiști sunt de părere că principalele cauze ale numărului mare de bolnavi de inimă sunt obiceiul de a consuma mâncăruri grase și dulciuri, de a fuma și sedentarismul. Dar legăturile directe între cauze și consecințe nu sunt încă univoc definite, etapa de investigații medicale în domeniul prediagnosticării afecțiunilor cardiace nefiind încă încheiată.

O modalitate de a preveni bolile cardiace se referă la monitorizarea activității electrice a inimii cu ajutorul electrocardiografei (monitorizare EKG). Electrocardiografia este o procedură de analiză clinică neinvazivă, larg răspândită la ora actuală și cunoscută nu numai specialiștilor cardiologi ci tuturor medicilor practicieni competenți. EKG-ul este o metodă simplă de diagnosticare a bolilor inimii, fiecare deviație de la forma acceptată drept standard a segmentelor și complexelor componente ale semnalului EKG (unda P, complexul QRS, unda T) – segmente care au rolul de a desemna depolarizările și polarizările consecutive ale atrilor și ventriculelor inimii - indicând posibilitatea existenței unei afecțiuni cardiace. Fiind o metodă neinvazivă de investigație clinică, EKG – ul prezintă un anumit grad de incertitudine și implică un risc de diagnosticare incorectă. Lăsând

Însă la o parte erorile de estimare, este incontestabil faptul că la nivelul actual de cunoștințe medicale, electrocardiografia reprezintă o metodă de o mare importanță în diagnosticul bolilor cardiace, metodă care trebuie să fie foarte bine cunoscută de specialiștii cardiologi și într-o anumită măsură și de către toți medicii practicieni.

Tema de cercetare aleasă urmărește într-o primă etapă să ofere un ajutor medicului pentru prediagnosticarea afecțiunilor cardiace în sensul ameliorării sarcinii de interpretare a electrocardiogramei. Cea de-a doua etapă urmărește să ofere mijloacele tehnice care să ofere posibilitatea de a realiza monitorizarea de la distanță a activității cardiace a inimii. Combinând diferite tehnici de prelucrare a semnalelor, se dorește creșterea probabilității de a pune un diagnostic medical corect. De exemplu, linia de bază a EKG – ului, care ar trebui să urmărească potențialul de 0 V și să precizeze tendința uniformă a EKG–ului, poate fi influențată de respirația sau mișcările pacientului, de interferențe electromiografice (EMG) sau de interferențe cauzate de rețea și poate prezenta o deviație care îngreunează procesul de diagnosticare sau chiar maschează caracteristici importante ale unei afecțiuni cardiace. Prin procedee bazate pe analiza wavelet, această deviație poate fi corectată, EKG–ul devenind mai ușor de interpretat, reducându-se astfel riscul unei diagnosticări incorecte. În practică întâlnim arareori un EKG neafectat de zgomot, perturbațiile fiind datorate fie interferențelor electromagnetice, fie unui contact necorespunzător dintre electrod și corpul uman. Aceste perturbații pot induce distorsionări ale semnalului EKG, lucru pe care dorim să-l evităm. Cercetarea științifică își propune cunoașterea cauzelor care duc la apariția perturbațiilor pentru a putea elabora tehnici de înlăturare a lor, în sprijinul medicului cardiolog. Electrocardiograma, pentru a oferi date cât mai nefalsificate, cât mai apropiate de situația reală a sănătății pacientului, trebuie să fie achiziționată în mediul natural al pacientului și nu într-un mediu artificial creat în clinică, deoarece unele afecțiuni (cum ar fi aritmiile) pot fi descoperite doar în urma unei monitorizări constante.

Recent, tematica propusă spre cercetare, *monitorizarea de la distanță a activității electrice a inimii*, a început să atragă atenția lumii științifice și medicale ([7-9]) și au fost elaborate primele dispozitive de monitorizare EKG la distanță (de exemplu, *CardioBip* propus de firma *NewCardio*™ fiind o tehnologie fără fir pentru monitorizarea de la distanță și de detectare a fibrilației atriale), aflate însă în continuare în faza de studiu și prezentare publică. Tema monitorizării de la distanță este de actualitate, deoarece se pune tot mai des problema accesibilității unei comunități mai mari la mijloacele moderne de diagnosticare. De exemplu, acest tip de diagnosticare ar putea oferi o alternativă zonelor rurale cu infrastructură slab dezvoltată, unde lipsesc mijloacele de diagnosticare timpurie. Din aceleași considerente a fost propus un aparat EKG de monitorizare de la distanță, dezvoltat de un inginer camerunez, A. Zang, pentru a veni în sprijinul comunității rurale africane, unde consulturile medicale pot fi efectuate doar în două orașe mari [6]. Aparatul, denumit *Cardiopad*, este tip tabletă portabilă și permite înregistrarea activității cardiace prin intermediul electrozilor atașați pacientului, rezultatele putând fi transmise la distanță, în format numeric, unui medic spre interpretare [6]. Cu toate că prototipul aparatului a fost conceput în 2010 (relativ recent), articolul din 2012 informează despre căutarea de surse de finanțare care să permită producția în serie la un preț estimat de cca. 1527 € [6]. În concluzie, tematica tezei prezente, începută în 2009, rămâne actuală, existența unor cerințe pe plan mondial întărind necesitatea studiului unor metode de monitorizare de la distanță a activității electrice a inimii. Studiile actuale referitoare la utilitatea dezvoltării unui sistem de monitorizare EKG la distanță se reflectă în numărul crescut de articole despre

module EKG fără fir [7-9]. Descoperirile tehnologice în domeniul comunicațiilor fără fir prevăd utilizarea conexiunilor WiFi sau GSM pentru transmiterea de date, fiind însă necesare investigații viitoare. Necesitățile actuale de supraveghere a situațiilor de risc cardiac, aflate în continuă creștere, impun studiul etapelor punerii în practică a unui procedeu de monitorizare a activității electrice a inimii de la distanță.

Cea de-a doua temă majoră a studiului doctoral întreprins, magnetocardiografia (MKG), reprezintă o tehnică recentă de monitorizare a activității cardiace, aflată încă în stadiu experimental în ceea ce privește achiziția datelor în medii necranate. Semnalele MKG sunt o alternativă a semnalelor EKG clasice, utile în special în cazul monitorizării activității cardiace fetale. Datele utilizate în lucrarea de față au fost furnizate de către institutul de cercetare *Institut fuer Photonische Technologien IPHT*, Jena, Germania în timpul unui stagiu de cercetare întreprins la universitatea *Technische Universitaet Ilmenau*, Germania. Stagiul a vizat dezvoltarea unor metode de prelucrare bazate pe analiza wavelet care să permită achiziția semnalelor MKG în medii necranate cu un raport semnal-zgomot bun.

Analiza wavelet a fost propusă drept o alternativă la analiza Fourier, prezenta teză de doctorat având drept scop de a dezvolta și testa algoritmi de prelucrare pentru principalele etape de achiziție și monitorizare de la distanță: reducerea deviației liniei de bază a semnalelor EKG și MKG, reducerea zgomotului de achiziție, compresia semnalelor în vederea transmisiei la distanță și reconstrucția semnalelor comprimate. Rezultatele obținute sunt exemplificate atât calitativ cât și cantitativ fiind realizate comparații cu alte metode în fiecare capitol.

2. SEMNALE BIOMEDICALE

2.1. Semnalul EKG

Monitorizarea activității electrice a inimii reprezintă o modalitate de a preveni bolile cardiace. Printre metodele de investigație clinică cele mai utilizate la ora actuală este și monitorizarea electrocardiogramei, numită electrocardiografie. Aceasta reprezintă o metodă grafică de înregistrare a biopotențialelor miocardului pe parcursul activității sale ritmice și își datorează popularitatea caracterului său neinvaziv, presupunând înregistrarea activității electrice a inimii cu ajutorul unor electrozi atașați pacientului [10].

Diagnosticarea cu ajutorul EKG-ului se realizează prin comparația formei de undă a semnalului achiziționat, înscrisă pe o hârtie milimetrică, cu forma standard a semnalului EKG. Se poate afirma că metoda de prelevare a semnalului EKG poate produce un anumit grad de incertitudine în interpretare. Semnalul EKG este un semnal sensibil la zgomot, putând fi perturbat atât în etapa de achiziție (prin mișcări ale pacientului sau interferențe cu mediul înconjurător) cât și în etapa de transmisie la distanță. În măsura în care domeniul medical prezintă un interes vital pentru ființa umană, au fost interpretate diverse cercetări de eliminare a neajunsurilor întâmpinate în etapa de analiză a semnalelor EKG achiziționate.

Analiza unui semnal EKG prezintă două aspecte fundamentale [11]:

- *Analiza ritmului cardiac* (stabilirea ritmului de bază, aprecierea eventualelor tulburări ale ritmului, evaluarea frecvenței bătailor cardiace),
- *Analiza morfologică a traseului electric* (conține informații asupra diferitelor particularități sau anomalii ale depolarizării și repolarizării diverselor părți ale inimii).

Modul de achiziție și interpretare a semnalelor EKG va fi discutat mai pe larg în subcapitolele care urmează pentru a genera o idee clară asupra mecanismului de funcționare și interpretare a activității electrice a inimii.

2.2. Semnalul MKG

Magnetocardiografia este un procedeu neinvaziv de analiză a activității cardiace, asemănător cu electrocardiografia în cadrul căruia se măsoară câmpurile biomagnetice generate în timpul activității electrice a inimii, constituind astfel un mediu util de diagnosticare a bolilor cardiace.

Câmpul magnetic, generat de activitatea biomagnetică a inimii, este foarte slab: astfel valorile complexului QRS, în cazul semnalelor MKG prelevate de la adulți sunt de cca. 30 pT, în timp ce valorile complexului QRS din cadrul

magnetocardiogramelor fetușilor (fMKG) atinge valori încă și mai scăzute (în funcție de vârsta gestațională pot fi măsurate valori între 300 fT – 3 pT) [12]. Spre comparație, câmpul magnetic al Pământului atinge valori de cca. 45-50 μ T, fiind de aproximativ 10^6 sau 10^7 ori mai puternic decât câmpul biomagnetic al inimii. Un mediu ecranat ar putea îmbunătăți calitatea semnalelor măsurate, însă o asemenea soluție ar crește considerabil costurile echipamentului, constituind astfel o piedică pentru difuzarea și dezvoltarea tehnicii propuse [13]. Comparația scoate în evidență faptul că, într-un mediu neecranat, vor exista câmpuri magnetice mai puternice decât câmpul magnetic cercetat, în consecință pot cu ușurință apărea interferențe perturbatoare.

Semnalele MKG și semnalele EKG sunt o măsură a aceluiași fenomen electromagnetic și conțin ca atare informații similare. Diferența dintre cele două tehnici este dată în principal de modul de prelevare al semnalelor: semnalele EKG sunt prelevate prin intermediul unor electrozi atașați pe pielea pacientului, în timp ce semnalele MKG sunt prelevate cu ajutorul unor traductori aflați la o distanță de 2-3 cm de corpul uman. Intensitatea câmpurilor magnetice generate de corpul uman fiind foarte mică, se impune utilizarea unei aparaturi ultrasensibile (tehnica MKG dezvoltată la IPHT, Jena utilizează senzori de tip Superconductive Quantum Interference Devices - SQUID) [14 - 16].

Tehnologia sistemului cu ajutorul căruia au fost achiziționate datele analizate și prelucrate în câteva dintre capitolele următoare ale acestei teze a fost dezvoltată la *Institute of Photonic Technology (IPHT)* din Jena, Germania. Datele au fost obținute în urma unui stagiu de cercetare de trei luni întreprins la *Technische Universitaet Ilmenau (TUI)*, Ilmenau, Germania sub coordonarea Prof. Dr. Hannes Toepfer și Prof. Dr. Hartmut Brauer și în colaborare cu Dr. Ing. Ronny Stolz de la IPHT, Jena. Senzorii de tip SQUID, utilizați la detectarea câmpului biomagnetic al corpului uman și dezvoltați de Institutul din Jena, au fost realizați utilizând tehnologia Nb/AIO_x/Nb [14].

Sistemul permite detectarea unor câmpuri electromagnetice slabe, deoarece senzorii receptori operează în stare de superconductivitate, la temperaturi foarte scăzute, în scopul de a limita zgomotul aleator aferent oricărui sistem aflat în echilibru termic și dat de mișcarea browniană a particulelor componente (de exemplu, artefacte induse de un rezistor al circuitului electric sub forma unor tensiuni perturbatoare). Astfel, senzorii sunt menținuți la temperatura de 4 K într-un criostat fabricat de Cryoton Ltd. Moskau [15]. Sistemul de achiziție cuprinde senzorul SQUID și soft-ul de analiză. Senzorii sunt operați prin intermediul electronicii de tip FLL (Flux Locked Loop), controlată de un computer prin intermediul unui port de tip RS232. Câțiva parametri ai sistemului de achiziție de date sunt prezentați în tabelul 2.2.1 [16]. În scopul efectuării în condiții bune a măsurărilor, senzorul magnetic conține trei gradiometri (G1, G2, G3) și trei magnetometri ortogonali.

Doi dintre gradiometri (G1, G2) înregistrează efectiv câmpul magnetic al inimii, fiind aliniați paralel și plasați în partea inferioară a senzorului. G1 și G2 sunt poziționați la cca. 2cm de pieptul sau abdomenul pacientului (în cazul semnalului MKG fetal) și măsoară componenta verticală locală a câmpului magnetic B_z , de-a lungul direcției x ($\partial B_z / \partial x$). Cei doi gradiometri măsoară un semnal compus din semnalul MKG al mamei și al fătului peste care se suprapune zgomot. Gradiometrul G3 este poziționat cu aproximativ 9 cm mai sus de celelalte două traductoare și are rol de referință. G3 măsoară un semnal de intensitate redusă, deoarece gradientul câmpului magnetic descrește pe măsură ce crește distanța față de sursă [17].

Neconsiderând corpul uman drept sursă de zgomot, zgomotul extern va fi înregistrat de gradiometrul G3 și poate fi suprimat prin construcția unui gradiometru de ordinul doi (G1-G3, G2-G3, G1-G2) care măsoară efectiv gradientul magnetic ($\partial B_z^2 / \partial x \cdot \partial z$). Cei trei magnetometri sunt utilizați pentru a măsura cele trei componente ortogonale ale câmpului magnetic.

Semnalele MKG captate de senzori sunt amplificate și transformate din semnale analogice în semnale numerice la o rezoluție de 24 biți, utilizând o frecvență de eșantionare de 1000 Hz și apoi înregistrate pe un computer. Valoarea semnalelor fetale fiind foarte mică, semnalul MKG prezintă o sensibilitate mare la interferențe și zgomote (în special la frecvența de 50 Hz). În scopul prevenirii unei diagnosticări incorecte datorate raportului semnal-zgomot slab, este necesară elaborarea unor proceduri de prelucrare a semnalelor achiziționate.

TABEL 2.2.1. PARAMETRI PRINCIPALI AI ELECTRONICII DE TIP FLL (IPHT, JENA)

PARAMETRU	VALOARE
Zgomot alb	0.33nV/ $\sqrt{\text{Hz}}$
Lățimea benzii	5-7 MHz
Tempertură de intrare	290-350° K
Deviația offset-ului termic	< 30nV/K
Consum de putere	80 mW

Magnetocardiograma fetală (fMKG) constituie o reprezentare grafică a câmpului magnetic, format în urma propagării activității electrice a inimii fătului. Informația conținută este similară cu cea purtată de semnalele EKG, dificultatea principală în interpretarea semnalelor fMKG fiind datorată amplitudinii lor scăzute (cca. 3 pT) și a influenței puternice a zgomotului și al semnalului MKG al mamei asupra semnalului util.

Cu toate acestea, semnalul fMKG oferă avantajul unei metode neinvazive de diagnosticare care poate fi utilizată în situații în care metoda EKG prezintă inconveniente [18], așa cum este cazul analizei activității inimii fătului. Intensitatea semnalelor precum și durata complexului QRS sau a undelor P sau T sunt dependente de vârsta fătului, odată cu dezvoltarea acestuia crescând și masa țesutului miocardic concomitent cu intensitatea semnalelor biologice măsurate. Datele fetale prelevate prin metoda fMKG sunt considerate viabile începând cu săptămâna 20 de sarcină (sau chiar începând cu săptămâna 16 [19]).

Valorile măsurate ale bătăilor inimii fătului au valori mult mai mici decât valorile măsurate ale bătăilor inimii mamei, dar cele două semnale sunt prelevate concomitent, datele urmând să fie ulterior analizate și separate. Acuratețea semnalelor EKG fetale este afectată de formarea unei substanțe albicioase care acoperă pielea fătului denumită vernix caseosa și având rol în protecția fetusului. Aceste inconveniente nu apar în cazul măsurătorilor fMKG.

Informația utilă asupra activității cardiace a fătului este conținută de spectrul său de frecvențe limitat în banda 0.1 – 70 Hz. Teoretic, perturbațiile de frecvență mai mare (100Hz, 200 Hz) pot fi filtrate neinfluențând semnalul util. În cazul unei filtrări liniare a frecvențelor discrete (16,67Hz, 50 Hz) poate însă apărea o distorsionare a semnalului fetal util. Conform părerii lumii medicale, deformări de până la 10% doar sunt acceptabile. Zgomotele sunt cauzate în special de mișcările pacientului (fătului) sau de o respirație neregulată.

2.3. Principiul măsurării EKG

În principiu, inima poate fi considerată un generator de curent electric inclus într-un volum care prezintă proprietăți conductoare (corpul uman). Câmpul electric generat de inimă poate fi evidențiat la suprafața corpului, prin electrozi plasați pe piele. La nivelul țesutului miocardic ce caracterizează inima umană, excitația este inițiată într-un punct și se propagă cu rapiditate de la o celulă la alta. Limita dintre porțiunea activată (devenită electronegativă) și cea neactivată (rămasă electropozitivă) reprezintă o suprafață. Această suprafață poate fi privită drept un front de undă (fig. 2.1), care se deplasează prin inimă în sensul unde de excitație, mărimea și orientarea ei fiind într-o permanentă schimbare [10, 20]. De-o parte și de alta a suprafeței limitante, există sarcini electrice pozitive respectiv negative.




Fig. 2.1. Frontul de undă al excitației electrice a inimii.

În repaus, cardiomiocitele sunt încărcate pozitiv pe versantul extern al membranei și negativ la interior. În timpul depolarizării, potențialul de membrană se inversează. Negativitatea de repaus a interiorului se reduce spre 0 și apoi interiorul devine pozitiv ca urmare a influxului de Na^+ .

Electrocardiografia poate fi considerată drept o procedură de analiză clinică neinvazivă, larg răspândită la ora actuală și cunoscută nu numai specialiștilor cardiologi ci tuturor medicilor practicieni competenți. EKG-ul este o metodă simplă de diagnosticare a bolilor inimii, fiecare deviație de la forma acceptată drept standard (fig. 2.2) a segmentelor și complexelor componente ale semnalului EKG (unda P, complexul QRS, unda T) indicând posibilitatea existenței unei afecțiuni cardiace.

Montarea electrozilor cuprinde plasarea în contact cu pacientul a câte doi electrozi pentru a obține un circuit electric, electrozii fiind conectați la bornele unui aparat de înregistrare a EKG. Conductibilitatea electrică a electrozilor poate fi mărită prin utilizarea unei paste speciale. De regulă, o derivație este formată din doi electrozi care au rolul de a înregistra variațiile de potențial electric produse în cursul unui ciclu cardiac [20]. În mod standard, o electrocardiogramă este achiziționată folosind 12 derivații, doi electrozi fiind plasați pe membrele superioare, doi electrozi pe membrele inferioare și șase în locații standard de pe piept (vezi fig. 2.3). Fiecare derivație descrie activitatea electrică a inimii dintr-un punct de vedere unic. Astfel,

sistemul derivațiilor va forma două plane perpendiculare unul pe celălalt: planul frontal este constituit din cele șase derivații ale membrilor iar planul transversal este format din derivațiile precordiale, fiecare derivație reprezentând o axă cuprinsă într-unul din cele două plane pe care se proiectează vectorul activității electrice a inimii. Derivațiile pot fi *bipolare* dacă se folosesc doi electrozi activi (cele 3 derivații standard ale membrilor DI, DII, DIII) sau *unipolare* atunci când un electrod este activ (explorator) și al doilea electrod este neutru (plasat la un potențial constant).




Fig.2.2. Forma standard a electrocardiogramei (EKG).

În cazul derivațiilor din plan frontal (bipolare - DI, DII, DIII, unipolare - aVL, aVF, aVR) electrozii se pun la mâna stângă, mâna dreaptă și piciorul stâng. Electrozii se pun după cum urmează pentru derivațiile în planul orizontal (V1-V6) [10]:

- V1 - spațiul 4 parasternal drept (roșu),
- V2 - spațiul 4 parasternal stâng (galben),
- V3 - la jumătatea distanței între V2 - V4 (verde),
- V4 - spațiul 5 stâng pe linia medioclaviculară LMC (maro),
- V5 - spațiul 5 stâng pe linia axilară anterioară LAA (negru),
- V6 - spațiul 5 stâng pe linia axilară mijlocie LAM (mov).

Asemenea oricărei alte metode neinvazive de investigație clinică, EKG – ul prezintă un anumit grad de incertitudine în interpretare și implică astfel un risc de diagnosticare incorectă. Greșelile frecvente constau în subestimarea sau supraestimarea metodei. Domeniul medical prezentând un interes vital pentru ființa umană, au fost interpretate diverse cercetări de eliminare a neajunsurilor întâmpinate în etapa de analiză a semnalelor EKG achiziționate. Urmărind scopul de a reduce gradul de incertitudine a interpretării electrocardiogramei, s-a impus un model EKG standard, la care să fie raportate toate celelalte EKG-uri prelevate.

Forma standard a EKG – ului implică următoarele caracteristici [21]:

- pe axa verticală se poate aprecia amplitudinea undelor EKG, 1 mm reprezentând 0,1 mV,
- pe orizontală se poate aprecia durata undelor și a intervalelor dintre două unde consecutive, 1 mm reprezentând 0,04 secunde (la viteza de 25 mm/sec).

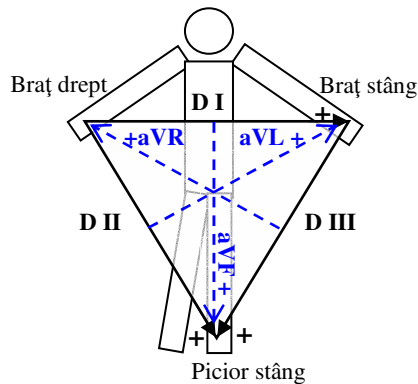


Fig. 2.3. Plasarea electrozilor.

Conceptual, electrocardiografia reprezintă tehnica de înregistrare pe hârtie milimetrică a modificărilor potențialelor electrice produse de activitatea inimii, fiind o tehnică simplă și larg răspândită în lumea medicală. Cu ajutorul unor electrozi care se atașează pacientului, se culeg semnalele electrice generate de cord și se înregistrează pe hârtie milimetrică. În acest mod, evenimentele electrice esențiale ale excitației cardiace sunt reținute și consemnate: ritmul cardiac, ritmul și originea excitației celulelor cardiace, propagarea impulsului. Concomitent, sunt furnizate și informații despre orientarea anatomică a inimii și mărimea relativă a compartimentelor sale. Informații care nu pot fi deduse cu ajutorul electrocardiogrammei se referă la mecanica inimii, nefiind furnizate informații referitor la eficiența contracției și pomparea sângelui [20].

2.3.1. Undele EKG

În mod clasic, EKG se înregistrează pe hârtie milimetrică pentru a permite aprecierea corectă a amplitudinii și duratei undelor în conformitate cu modelul standard stabilit. Astfel, s-a stabilit că un mm pe verticală reprezintă o amplitudine a undei de 0,1 mV în timp ce pe abscisă, un mm reprezintă un interval de timp de 0,04 sec [21]. De regulă, o electrocardiogramă (EKG) normală este alcătuită din mai multe unde și segmente caracteristice, după cum urmează (fig. 2.4):

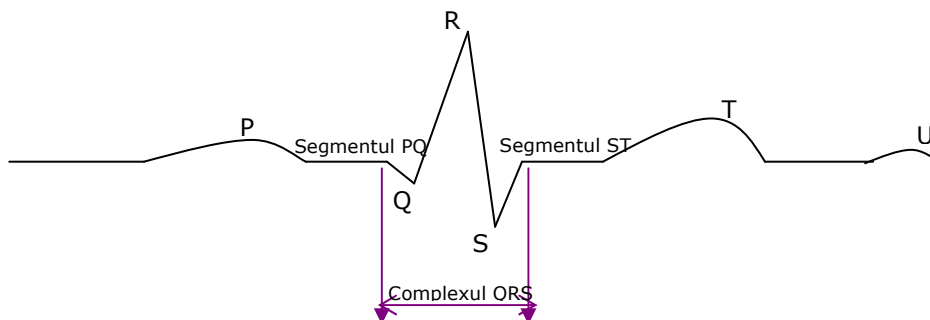


Fig. 2.4. Semnalul EKG.

1. *Unda P*: descrie depolarizarea atriilor și prezintă următoarele caracteristici: rotunjită, simetrică, pozitivă, monofazică, cu amplitudine cuprinsă între 0,1 și 0,2 mV și durată de 0,1 sec [22].
2. *Intervalul PR (PQ)*: descrie depolarizarea atriilor precum și conducția intraatrială și atrioventriculară, fiind alcătuit din unda P și segmentul PR. Durata normală este de 0,12-0,20 sec, dar se scurtează cu creșterea frecvenței cardiace [22].
3. *Complexul QRS*: corespunde depolarizării ventriculare și prezintă trei faze, fiind alcătuit din două unde negative de amplitudine mică și o componentă pozitivă (R) de amplitudine mare. Amplitudinea complexului este de 1-2 mV și durată mai mică sau egală cu 0,1 sec. În cazul în care complexul depolarizării ventriculare este format doar dintr-o deflexiune negativă, se numește QS și prezintă o amplitudine de minimum 0,5 mV în derivațiile standard respectiv minimum 1 mV în derivațiile precordiale și o durată de 0,08-0,10 sec ([20], [22]).
4. *Segmentul ST*: corespunde activării ventriculare complete, porțiunea inițială a repolarizării ventriculare. Durata este relativ lungă, fiind cuprinsă între 0,35-0,4 s. Formal, segmentul este orizontal și izoelectric [22].
5. *Unda T*: reprezintă porțiunea terminală a repolarizării ventriculelor. Drept caracteristici se pot menționa: este rotunjită și asimetrică. Amplitudinea este de aproximativ 1/3 din cea a complexului QRS. Durata este cuprinsă în intervalul 0,15-0,25 s [20], [22].
6. *Intervalul QT*: cuprinde depolarizarea și repolarizarea finală a ventriculelor, durata sa variind invers proporțional cu frecvența cardiacă. Durata maximă a intervalului QT este de 0,45 s [22].
7. *Unda U*: corespunde relaxării ventriculare complete (relaxarea mușchilor papilari) și nu apare de obicei pe EKG. [20].

Cea mai des întâlnită formă a ritmului de bază al bățăilor cardiace numită ritm sinusal, poate fi recunoscută pe EKG pe baza următoarelor criterii [11], [20], [22]:

- unda P este prezentă înaintea fiecărui complex QRS și în toate derivațiile,
- succesiunea undelor P este regulată și ritmică, bățăile cardiace au o frecvența normală de 75-80 băți/minut, cu variații posibile între 60 și 100-120 băți/minut,
- raportul dintre durata undei P și durata complexului QRS este constant, însemnând că în toate derivațiile și în toate bățile cardiace înregistrate se constată aceeași durată a intervalului P-Q,
- timpul de conducție de la atri la ventriculi (durata intervalului P-Q) este cuprins între limitele normale de 0,12 s și 0,21 s, în funcție de frecvența cardiacă [11], [20], [22].

2.3.2 Tipuri de înregistrare EKG

Există mai multe tipuri de înregistrări electrocardiografice dintre care menționăm [21], [23]:

- *EKG standard*: se poate interpreta ritmul cardiac, morfologia undelor de depolarizare și repolarizare atrială și ventriculară. Constatarea unor abateri

de la forma standard a EKG-ului poate fi un indiciu pentru medic pentru a întreprinde o serie mai amănunțită de investigații (alte forme complexe de EKG sau alte investigații paraclinice).

- *EKG cu înregistrare de durată (Holter, 24 ore):* se poate preleva atât ambulator cât și cu pacientul spitalizat pentru a evidenția modificările ischemice, tulburările tranzitorii de ritm sau de conducere .
- *EKG computerizat:* este un EKG standard cu amplificare digitală.
- *Proba de efort EKG:* presupune înregistrarea activității cardiace în timpul unui efort efectuat de pacient (mers pe bicicletă sau covor rulant) până la atingerea frecvenței cardiace de 220-vârsta (în cazul unui test maximal) sau 75% din această frecvență (în cazul unui test submaximal).

2.3.3. Interpretarea EKG – ului

Electrocardiograma reprezintă un mijloc tehnic neinvaziv util pentru a permite o primă diagnosticare a anumitor afecțiuni, dintre care menționăm [24]:

- afecțiuni miocardice și pericardice,
- tulburările de ritm (abatere de la frecvența normală),
- tulburări de conducție (modificarea intervalelor dintre complexe cardinale),
- modificări ale formei complexelor cardinale (QRS, T, p și s-T),
- cardiopatia ischemică,
- hipertrofia atriale și ventriculare secundare valvulopatiilor și cardiopatiilor congenitale.

Modificările menționate mai sus pot apărea izolat sau în combinație, oferind indicații asupra sănătății miocardului, asupra tipului și localizării leziunii. De regulă, opinia medicală este de părere că orice abatere de la forma standard a EKG – ului denotă existența unei afecțiuni cardiace. În acest context este cu atât mai important să acordăm atenție posibilelor cauze care ar putea falsifica un diagnostic pus pe baza interpretării electrocardiografei.

Pentru a interpreta corect o electrocardiogramă, trebuie explicat cum este perceput un semnal EKG normal. În electrocardiograma fără risc cardiac, frecvența cardiacă, care cuprinde în mod normal între 60 și 100 bătăi/minut) și ritmul sunt regulate. Activitatea atriilor este normală, iar valorile parametrilor unde P, complexului QRS și unde T sunt cuprinse între limitele standard. De asemenea, segmentul ST nu este supra- sau sub-denivelat.

Un EKG normal însă nu exclude complet posibilitatea existenței unei afecțiuni cardiace. Din acest motiv, electrocardiograma se interpretează în contextul simptomatologiei, istoricului medical, examenului clinic și, dacă este necesar, a altor investigații. În unele cazuri EKG-ul decelează anomalii numai în timpul efortului fizic sau atunci când apar simptomele.

Interpretarea unui EKG presupune următoarele etape [21]:

- 1) determinarea ritmului cardiac,
- 2) determinarea frecvenței cardiace,
- 3) determinarea axului electric,

- 4) analiza undei P,
- 5) analiza intervalului PR/PQ,
- 6) analiza complexului QRS,
- 7) analiza segmentului ST,
- 8) analiza undei T,
- 9) analiza undei U,
- 10) determinarea duratei intervalului QT.

2.3.4. Electrocardiograma patologică

Semnalul EKG poate oferi informații importante asupra desfășurării activității electrice a inimii, însă pentru a realiza un diagnostic corect, semnalul EKG trebuie să fie corect interpretat. Tehnicile de achiziție și procesare nu trebuie să afecteze conținutul informațional al EKG-ului. În rândurile următoare vor fi prezentate câteva cazuri patologice. Modificările patologice ale electrocardiogramei pot afecta atriograma (unda P, segmentul P-Q) sau ventriculograma (complexul QRS, segmentul ST, unda T).

2.3.4.1. Aritmii cardiace

Ritmul cardiac normal este situat între 60 și 100 bătăi/minut. Valori sub sau peste acest interval desemnează o anomalie denumită aritmie cardiacă. Există mai multe feluri de aritmii cardiace. Câteva dintre acestea sunt prezentate în continuare ([10], [20]).

- ❖ O frecvență cardiacă sub 60 de bătăi/minut poartă denumirea de *bradicardie* (fig. 2.5).



Fig. 2.5. Bradicardia sinusală (frecvența sub 60 bătăi/min).

- ❖ O frecvență cardiacă peste 100 de bătăi / minut este denumită *tahicardie* (fig. 2.6). Tahicardiile includ un ritm rapid, neregulat cu origine în ventriculi

(fibrilație ventriculară), sau un ritm rapid regulat cu pornire în atri (flutter atrial).




Fig. 2.6. Tahicardia sinusală (frecvența inimii de 90-120 bătăi/min).

În ambele cazuri menționate de aritmii este păstrat focarul normal al impulsurilor cardiace: nodul sinusal.

❖ *Aritmii atriale*: își au originea la nivelul atriilor:

- *extrasistolele atriale* – datorită hipertensiunii arteriale este provocată o destindere a atriilor urmată de contracția lor prematură.

- *tahicardia paroxistică atrială*: inima se contractă brusc și bate foarte repede, ajungând până la 140-220 de bătăi pe minut. Durata acestei anomalii cardiace poate fi de câteva secunde sau chiar câteva ore, ea încetând însă la fel de brusc cum a apărut.

- *fibrilația atrială și flutterul atrial* (fig. 2.7): constituie o „furtună electrică” la nivelul atriilor, fiind o problemă care necesită examene medicale și tratament [10].




Fig. 2.7. Fibrilația atrială (tulburări neregulate de ritm).

În timpul fibrilației atriale, inima pierde în jur de 20% din capacitate, neavând loc contracția coordonată a atriilor. Pierderea poate fi compensată pentru moment de către ventricul, dar pe termen lung epuizarea sa poate duce la insuficiență cardiacă. Stările de epuizare resimțite se datorează neregularității pulsului, ce are la bază faptul că ventriculele nu mai sunt antrenate de către nodul sinusal, pulsul având valori uneori foarte ridicate 140 de bătăi/minut și chiar mai

mult, iar altele foarte mici, de numai 50 de bătăi/minut, provocând stări de amețeală. Dilatarea atrilor este de asemenea o complicație a fibrilației atriale. Sângele care stagnează în acestea se poate coagula, trecerea unei mase de sânge coagulat în circulație prezentând riscul de a cauza embolie și deces [10].

❖ *Aritmii ventriculare:*

- *extrasistola ventriculară:* se datorează unei zone din ventricul, care nu se mai sincronizează cu ansamblul cardiac. Există mai multe cauze ale acestui tip de aritmie: un dezechilibru în reținerea sărurilor minerale, febra sau chiar emoția. Aritmia este considerată benignă în aceste cazuri, dar apariția acesteia împreună cu o boala de inimă poate indica o problemă medicală care să necesite tratament [20].

- *tahicardia paroxistică ventriculară:* se produce o desincronizare între bătăile ventriculelor și contracția atrială, consecința fiind diminuarea debitului cardiac. Mușchiul cardiac prezentând o disfuncție majoră în acest caz, fiind în general urmarea unui infarct al miocardului [10, 20].

- *fibrilația și flutterul ventricular:* necesită examene medicale și tratament.

Tot în categoria aritmiilor intră și anomaliile de conducție a impulsurilor electrice ([10], [20], [21], [24]):

- ❖ *Boala coronariană și infarctul miocardic:* dacă arterele coronare ce au rolul de a conduce sângele oxigenat către mușchiul cardiac sunt blocate, acesta primește mai puțin oxigen decât are nevoie, determinând apariția ischemiei sau chiar a necrozei. Această leziune poate fi evidențiată pe electrocardiogramă.
Semnele precoce de ischemie cardiacă (scăderea fluxului sanguin coronarian) sunt reprezentate de sub-denivelarea segmentului ST.
Semnele precoce de infarct miocardic sunt reprezentate de supra-denivelarea segmentului ST. În timp, după infarct, unda Q a complexului QRS apare mai adâncă pe EKG.
- ❖ *Hipertrofia cardiacă (îngroșarea pereților camerelor):* unele modificări ale EKG-ului pot indica îngroșarea mușchiului inimii la nivelul uneia sau a mai multor camere.
Afecțiunile ce pot determina apariția hipertrofiei sunt hipertensiunea arterială, boala coronariană, cardiomiopatia și bolile valvulare.
- ❖ *Inflamarea inimii:* un segment ST supra-denivelat apare și în cazul inflamării mușchiului inimii (miocardita) sau a sacului ce înconjoară inima (pericardita).
- ❖ *Modificări chimice (dezechilibre electrolitice):* activitatea normală a inimii depinde de nivelurile sanguine normale ale unor substanțe chimice, denumite electroliti, cum sunt calciul (Ca) și potasiul (K). Niveluri crescute sau scăzute ale acestor electroliti pot determina apariția anumitor aritmii, precum modificări ale undei P, ale complexului QRS sau a undei T.

2.3.4.2. Hipertrofiile atriale

Cavitatea atrială și peretele atrial se măresc în cazul unei suprasolicitări importante, de lungă durată, fapt care duce la subțierea peretelui și dilatația atrului [21-22]. Modificări ale undei P pot avea loc din condiții fiziologice în funcție de poziția corpului, de respirație, efort fizic sau în următoarele situații patologice: stenoză mitrală, hipertensiune pulmonară, boli pulmonare cronice, emfizem pulmonar, pericardită, ischemie și necroză atrială, defect septal interatrial, hiper și hipotensiunii, etc.

Unda P normală este constituită din juxtapunerea undei P a atrului drept și unda P a atrului stâng. În cazul hipertrofiei unui atriu se ajunge la o creștere a amplitudinii potențialului electric corespunzător acestui atriu, concomitent cu creșterea duratei de depolarizare [10], [20].

2.3.4.2.1. Hipertrofia atrială dreaptă

În figura 2.8 pot fi observate următoarele caracteristici la nivelul derivațiilor EKG-ului: $P2 > P3 > P1$, creșterea amplitudinii părții pozitive în V1 și V2, în urma îngroșării peretelui atrial drept, unda P va avea amplitudine crescută, timpul necesar pentru depolarizare va fi însă normal prin faptul că atrul stâng (AS) are grosime normală, în derivațiile V1-V2, DII, DIII, aVF - undă P mărită și ascuțită [10], [20].




Fig. 2.8. Hipertrofia atrială dreaptă.

2.3.4.2.2. Hipertrofia atrială stângă

În figura 2.9 pot fi observate următoarele caracteristici la nivelul derivațiilor EKG-ului: depolarizarea atrială va necesita mai mult timp datorită îngroșării peretelui AS ducând la creșterea duratei undei P peste 0,12 sec, deflexiunea negativă din V1 va avea o amplitudine peste 1 mm, aspectul unei duble cocoșe în DI, DII, VL, creșterea amplitudinii părții negative în V1 V2, [10], [24].



Fig. 2.9. Hipertrofia atrială stângă.

Hipertrofiile ventriculare

La fel ca și în cazul hipertrofiilor atriale se poate vorbi despre hipertrofii ventriculare stângă și dreaptă.

2.3.4.3.1. Hipertrofia ventriculară stângă (HVS)

Repolarizarea ventriculară este disfuncțională, apărând o întârziere în repolarizarea ventriculului stâng (VS), prin creșterea masei acestuia [10]. HVS duce la deviația axului QRS în plan frontal, spre dreapta, și la creșterea amplitudinii undei R în precordialele drepte [24].

Modificările pot fi observate pe figura 2.10, în derivațiile V1-V2, faza terminală a undei T va fi deasupra liniei izoelectrice, în timp ce la nivelul derivațiilor stângi DI, aVL, V5-V6, faza terminală a undei T va fi sub linia izoelectrică [10], [24].




Fig. 2. 10. Hipertrofia ventriculară stângă.

2.3.4.3.2. Hipertrofia ventriculară dreaptă (HVD)

Determină deviația axului QRS în plan frontal la dreapta și creșterea amplitudinii undei R în precordialele drepte. Depolarizarea ventriculului drept (VD) își mărește durata și se suprapune peste timpul de depolarizare al ventriculului stâng, repolarizarea se va face invers decât normal, astfel unda T va prezenta o deflexiune negativă și asimetrică [20], [21] (fig. 2.11).




Fig. 2.11. Hipertrofia ventriculară dreaptă

2.3.4.4. Tulburările de conducere intra-cardiacă

Din punct de vedere al localizării, blocul cardiac se poate produce la nivelul nodului sinoatrial (SA), a nodului AV sau a fasciculului Hiss și a ramurilor sale.

2.3.4.1. Blocul sinoatrial

Reprezintă o tulburare de conducere intra-cardiacă, care este caracterizată prin întârzierea sau absența unui răspuns atrial provocat de o blocare parțială sau totală a unei de excitație în drumul său de la nodul sinoatrial spre atriu. Pe traseul electric se observă ritm sinusal pe alocuri întrerupt de o pauză totală în care lipsesc unda P și respectiv complexul QRS (fig. 2.12). Distanța P-P este dublul sau multiplul intervalului P-P al ritmului de bază [10], [20], [24].



Fig. 2.12. Blocul sinoatrial.

2.3.4.2. Blocul atrio-ventricular

Reprezintă o deficiență a conducerii stimulului de la atriu la ventricul care poate fi o întârziere sau o întrerupere a acesteia. După gradul tulburărilor de conducere deosebim bloc de gradul I, II, III, sau frust, incomplet și complet. Blocul atrio-ventricular gradul I are drept caracteristică principală alungirea constantă a intervalului PQ peste 0,21 sec [10].

2.3.4.5. Blocurile de ramură

2.3.4.5.1. Blocul de ramură stângă (BRS)

Prin bloc de ramura stîng se înțelege o întrerupere a conductibilității în ramura stîngă a fascicolului Hiss, rezultând un asincronism ventricular în care VD se activează primul și VS ultimul [10]. În figura 2.13 pot fi observate următoarele caracteristici la nivelul derivațiilor EKG-ului: ritm sinusal sau supraventricular, absența undei Q și undă R largă în DI, VL, V6, unda T în opoziție cu unda R, datorită unor tulburări secundare de repolarizare [10], [11].




Fig. 2.13. Blocul de ramură stângă (BRS).

2.3.4.5.2. Blocul de ramură dreaptă (BRD)

Blocul de ramură dreaptă presupune întreruperea conductibilității prin ramura dreaptă a fascicolului lui Hiss, rezultând un asincronism ventricular în care VS se activează primul, VD fiind activat tardiv [10]. În figura 2.14 pot fi observate următoarele caracteristici la nivelul derivațiilor EKG-ului: ritmul este sinusal, durata complexului QRS puțin mărită (0,12 s), unda S largă în DI, VL, V6, unda T negativă în V1-V2, datorate tulburărilor secundare de repolarizare.



Fig. 2.14. Blocul de ramură dreaptă (BRD).

2.3.4.6. Angina pectorală

În timpul crizei de angor sau în timpul unei probe de efort, se remarcă (fig. 2.15) la nivelul EKG-ului o sub-denivelare a segmentului ST, orizontală sau descendentă, mai mare de 1 mm, urmată de unda T ascuțită, simetrică și pozitivă.




Fig. 2.15. Angina pectorală.

2.3.4.7. Infarctul miocardic acut (IMA)

Boala coronariană este principalul factor de deces în țările dezvoltate, boala cea mai frecvent întâlnită fiind arteroscleroza. În peretele vaselor coronariene se acumulează țesut fibros și material lipidic care poate determina chiar și obstrucția completă a vasului. Factorii de risc majori implicați în apariția infarctului sunt: diabetul zaharat, dislipidemia, hipertensiunea arterială, vârsta, fumatul [25]. Din punct de vedere anatomic, termenul de infarct denumește o zonă de necroză a țesutului muscular al inimii, de origine ischemică. Zona infarctată este un teritoriu neirigat, mut din punct de vedere electric și nu poate conduce impulsurile electrice, în timp ce restul inimii (a cărei irigație sanguină este normală) funcționează normal. Electrocardiograma este un examen complementar indispensabil atât pentru a afirma un diagnostic de IMA dar și pentru a-i urmări evoluția. Se pot distinge semne atât directe cât și indirecte de IMA. Semnele directe sunt: *necroza* – unda Q distorsionată, *leziunea* – supra-denivelarea segmentului S-T, *ischemia*– unda T negativă, ascuțită și simetrică [25]. Semnele indirecte sunt : *necroza*- unda R amputată, *leziunea*- segmentul S-T sub-denivelat, *ischemia*- unda T pozitivă, ascuțită și simetrică [10]. Pentru medic este foarte important să poată monitoriza

bolnavul încă de la primele simptome. Din punct de vedere al monitorizării EKG, traseele sunt semnificative apărând semne directe, pe ore (în primele 2 ore, următoarele 6-12 ore, 12-24 ore, 24-48 ore, prima săptămână, prima lună). În primele 2 ore pe EKG apare unda monofazică Pardee (fig. 2.16 a)), supra-denivelarea segmentului RS-T (fig. 2.16 b)), semn de leziune subpericardică [10].




Fig. 2.16 a). Unda T înaltă – la câteva minute de la debutul IMA.




Fig. 2.16 b). ST supra-denivelat.

La 5-6 ore de la debut persistă unda monofazică, unda T pierde în amplitudine și apoi dispare, apare unda Q de necroză. Între 12-24 de ore, unda Q devine tot mai evidentă, segmentul RS-T revenind la linia izoelectrică. În intervalul 24-48 ore, unda Q de necroză este evidentă, leziunea subepicardică este minoră sau absentă și debutează ischemia subepicardică, aparând unda T negativă, simetrică și ascuțită, tot mai profundă, așa-zisul T coronarian (fig. 2.17). La câteva luni de la infarct rămâne vizibilă unda Q de necroză [10], [25].




Fig. 2.17. Unda T coronarian.

3. METODELE MATEMATICE DE PRELUCRARE A SEMNALELOR BIOMEDICALE

Acest capitol se focalizează asupra modalităților în care pot fi utilizate funcțiile wavelet la prelucrarea și reprezentarea semnalelor biologice. Acest subiect este de interes general, înlesnind sarcina de interpretare a electrocardiogramei sau a magnetocardiogramei. Analiza unui semnal este o etapă importantă pentru prelucrarea ulterioară a acestuia. Sunt avute în vedere tehnici de prelucrare care să permită descompunerea liniară în componente elementare a semnalului biologic cu proprietăți utile și ușor de analizat. Teoria funcțiilor wavelet are la bază funcții generatoare asupra cărora se aplică operații de translație și dilatare, principalul avantaj al descompunerilor wavelet constând în posibilitatea de a efectua o analiză multirezoluție. De asemenea, din punctul de vedere al prelucrării semnalelor, bazele ortonormale sunt mai stabile din punct de vedere informațional decât reperele (noțiune care va fi definită în continuare), permițând o reconstrucție mai facilă a semnalului original.

3.1. Reprezentări timp – frecvență

Există mai multe modalități de reprezentare a unui semnal. Cea mai des utilizată este reprezentarea semnalului în domeniul timp. Această reprezentare permite, după eșantionare și cuantizare, înregistrarea semnalului într-o memorie, operație care poate fi apoi urmată de prelucrarea sa digitală. În cazul reprezentării în domeniul timp, o măsură a conținutului de informație purtată de semnalul considerat este numărul de eșantioane înregistrate în memorie. De exemplu, pentru semnalul de pe prima linie din figura 3.1, s-au memorat 256 de eșantioane. Pe cea de a doua linie din figura 3.1 s-a reprezentat modulul spectrului (transformării Fourier) semnalului de pe prima linie. Aceasta este o reprezentare în domeniul frecvență. Se constată, comparând cele două reprezentări din figura 3.1, că pentru cazul semnalului considerat, reprezentarea în domeniul frecvență este mai economică decât reprezentarea în domeniul timp, conținând doar șase coeficienți Fourier având valori nenule.




Figura 3.1. O comparație a reprezentărilor în domeniul timp și în domeniul frecvență ale aceluiași semnal.

Principalul dezavantaj al transformării Fourier este lipsa sa de localizare în timp. Această afirmație este justificată de următorul fragment din articolul "Cables et Transmission" scris de J. Ville în anul 1948:

"Dacă considerăm un fragment de muzică compus din mai multe măsuri și dacă o notă, "la", de exemplu, figurează o dată în acest fragment, analiza Fourier ne va prezenta frecvența corespunzătoare cu o anumită amplitudine și cu o anumită fază, fără a localiza "la" - ul în timp. Ori, este evident că pe parcursul bucății există momente de timp când nu se aude nota "la".

Deci a apărut necesitatea introducerii unor noi transformări. Reprezentările timp-frecvență sunt uneltele necesare pentru analiza semnalelor netaționare. Această analiză presupune identificarea parametrilor acestor semnale. Pe lista acestor parametri trebuie incluși: momentele de timp de începere și terminare a semnalului, energia sau puterea semnalului, amplitudinea instantanee, frecvența instantanee, banda de frecvență instantanee a semnalului, etc.

Există mai multe tipuri de reprezentări timp-frecvență: transformata Fourier scurtă, transformarea wavelet continuă, reprezentarea timp-frecvență de tip Wigner-Ville, etc. În cazul transformării Fourier scurte, localizarea în domeniul timp se realizează cu ajutorul unei ferestre care baleiază forma de undă a semnalului, spectrul porțiunii din fereastră fiind calculat pentru fiecare poziție a ferestrei. Pentru unele semnale netaționare, așa cum sunt majoritatea semnalelor biologice, reprezentările timp-frecvență pot fi mai economice decât reprezentarea în domeniul timp sau reprezentarea în domeniul frecvență.

3.2. Transformata Fourier

Transformata Fourier a fost introdusă de matematicianul Joseph Fourier (sec. 19) [26] în studiul propagării căldurii într-o bară ale cărei capete sunt ținute la temperaturi diferite [27]: ecuația căldurii din joncțiunea celor două zone poate fi descrisă printr-o funcție discontinuă și aproximată mulțumitor cu ajutorul seriilor trigonometrice. Prin extensie, Fourier a demonstrat că orice funcție poate fi descrisă ca o serie infinită de funcții trigonometrice (sinus sau cosinus) [27]. Funcțiile periodice pot fi reprezentate prin serii de funcții trigonometrice, denumite *serii Fourier*.

La ora actuală, analiza Fourier este frecvent utilizată în cazul semnalelor staționare, dând informații referitoare la conținutul frecvențial al unei funcții de timp. Transformarea unei funcții din domeniul timp în domeniul frecvență se realizează cu ajutorul transformatei Fourier. Utilizări ale seriilor Fourier se găsesc în domeniul electrodinamicii, acusticii, opticii [28].

Procese periodice pot fi descrise cu ajutorul seriilor Fourier, menționăm astfel probleme de propagare a impulsului sau de prognoză a mareelor [28]. Forma matematică a seriei Fourier a unei funcții $s(x)$ periodică de perioadă 2π este:

$$s(x) = \frac{a_0}{2} + \sum_{n=1}^{\infty} (a_n \cdot \cos nx + b_n \cdot \sin nx), \quad (3.1)$$

unde coeficienții Fourier a_n și b_n se calculează cu următoarele formule:

$$a_0 = \frac{1}{2\pi} \int_0^{2\pi} s(x) \cdot dx, \quad (3.2)$$

$$a_n = \frac{1}{\pi} \int_0^{2\pi} s(x) \cdot \cos nx \cdot dx, \quad (3.3)$$

$$b_n = \frac{1}{\pi} \int_0^{2\pi} s(x) \cdot \sin nx \cdot dx. \quad (3.4)$$

Seria Fourier descompune un semnal periodic în componente frecvențiale discrete, pentru analiza semnalelor neperiodice utilizându-se transformata Fourier (FT) [29]. Localizarea frecvențială este foarte bună în cazul semnalelor supuse analizei Fourier, însă acest fapt este în defavoarea localizării temporale. Pentru a combate acest dezavantaj, s-a introdus conceptul de *Transformată Fourier pe Termen Scurt* (denumirea în limba engleză *Short Time Fourier Transform - STFT*) care permite o analiză temporală și frecvențială limitată cu ajutorul unei ferestre de analiză fixate între anumite limite. STFT va analiza în același mod toate frecvențele care compun semnalul descompus [30].

$$STFT(t, \omega) = \int_{-\infty}^{\infty} s(\tau) \cdot fr(\tau - t) \cdot e^{-j\omega\tau} d\tau, \quad (3.5)$$

unde $fr(t)$ desemnează fereastra de analiză, ω este pulsația iar t momentul de timp. Fereastra de analiză are rolul de a localiza în timp semnalul luat în considerare, prin modificarea variabilei t între $(-\infty, \infty)$, având de regulă energie unitară:

$$\|fr(t)\|^2 = 1. \quad (3.6)$$

Cea mai bună localizare timp-frecvență este obținută pentru o fereastră de tip Gaussian, transformata Fourier pe termen scurt fiind denumită în acest caz transformată Gabor. Alternativ, proprietățile STFT pot fi exprimate și cu ajutorul produsului scalar [30]:

$$STFT(t, \omega) = \langle s(\tau), fr_{\omega, t}(\tau) \rangle, \quad (3.7)$$

unde fereastra de analiză la momentul t_1 și pulsația ω_1 este:

$$fr_{\omega_1, t_1}(\tau) = e^{j\omega_1\tau} \cdot fr(\tau - t_1). \quad (3.8)$$

Necesitatea de a înlătura dezavantajele generate de lipsa de flexibilitate a ferestrei de analiză a condus la introducerea altor reprezentări timp-frecvență, printre care și transformata wavelet continuă.

3.3. Transformata wavelet

În continuare se vor prezenta principalele caracteristici ale transformării wavelet.

3.3.1. Definiția și istoria analizei wavelet

Funcțiile wavelet sunt funcții matematice folosite pentru descompunerea multirezoluție a unui semnal nestaționar, în scopul de a studia ulterior fiecare componentă cu rezoluția dorită. Funcțiile wavelet pot fi privite drept unde (oscilații) cu o durată limitată în timp și spațiu, care prezintă un mod specific de adaptare la schimbările spectrale și temporale ale unui semnal de intrare, prin translații și dilatări ale unei funcții de bază. Astfel, un semnal poate fi descris printr-o reprezentare timp-frecvență de tip wavelet, adaptând funcția de analiză (fereastra de analiză – denumită funcție wavelet mamă) la cerințele în domeniul timp sau frecvență ale semnalului de analizat [30]. Analiza multirezoluție conferă avantaje analizei wavelet față de analiza Fourier tradițională și a contribuit la dezvoltarea a numeroase aplicații ale funcțiilor wavelet în domeniul prelucrării de semnale (de exemplu, compresia semnalelor și a imaginilor sau reducerea zgomotului perturbator al unei imagini). Astfel, ideea de bază a analizei wavelet constă în prelucrarea datelor utilizând o anumită scară. Semnalul original poate fi descompus într-o serie de coeficienți generați de funcțiile wavelet asupra cărora pot fi efectuate operațiile de prelucrare necesare [31].

Prima funcție wavelet a fost introdusă în 1909, de către Alfred Haar și reprezintă cea mai simplă formă de funcție wavelet mamă cu suport compact. Ulterior, matematicienii G. Weiss și R. Coifman au studiat elementele de bază (cele mai simple) ale unui spațiu vectorial și regulile de reconstrucție a spațiului folosind aceste elemente fundamentale [31].

Forma preliminară a Transformatei wavelet continue a fost introdusă de Georg Zweig în 1975 în urma studiului cochleei, testând reacția la sunet a urechii, însă dezvoltarea actuală a analizei wavelet a avut loc abia în jurul anului 1980, prin definiția dată de Grossman și Morlet și prin teoria construită de Stephane Mallat în 1985 [31]. Inspirat de rezultatele prezentate de St. Mallat, Y. Meyer a construit primele funcții wavelet continuu diferențiabile însă fără suport compact [31]. Câțiva ani mai târziu, în 1988, matematiciana belgiană Ingrid Daubechies [32] a propus un set de funcții wavelet mamă ortogonale și cu suport compact, care stau la baza multor aplicații actuale.

3.3.2. Aspecte teoretice ale transformatei wavelet

Există două modalități de a privi analiza care utilizează funcții wavelet: analiza wavelet poate fi percepută în primul rând drept un *microscop matematic*, ideea fundamentală a funcțiilor wavelet fiind de a analiza semnale folosind scale ("scări") diferite, lucru care nu este posibil la analiza Fourier. În al doilea rând,

transformata wavelet poate fi privită drept o *reprezentare timp-frecvență* utilă în modelarea matematică a fenomenelor netaționare. Transformata reprezintă o funcțională (domeniul și codomeniul sunt mulțimi de funcții), fiind un mod de reprezentare care nu afectează conținutul informațional [33]. De exemplu, în cazul transformatei Fourier, domeniul conține funcții de timp iar codomeniul funcții de frecvență la care se ajunge în urma unui procedeu specific de calcul [33]. Transformata wavelet apelează la funcții wavelet de energie finită, deoarece orice semnal care este generat în practică trebuie să prezinte o durată finită. Energia E a unui semnal $s(t)$ este dată prin următoarea formulă [33]:

$$E = \int_{-\infty}^{\infty} s^2(t) dt, \quad 0 < E < \infty. \quad (3.9)$$

Funcțiile de bază ale analizei wavelet sunt obținute prin dilatarea și translatarea unei funcții de bază, denumită *funcție generatoare* sau *funcție wavelet mamă* (*mother wavelet* – MW).

Fie g o funcție reală, caracterizată prin doi parametri a, b .

$g \in L^2(\mathbb{R})$;

a – parametru de poziție, $a > 0$,

b – parametru de scară.

Se definește operatorul de translatare T_a , aplicat unei funcții $g(t)$:

$$T_a : g(t) \mapsto g(t - a). \quad (3.10)$$

Se definește operatorul de dilatare D_b , aplicat unei funcții $g(t)$:

$$D_b : g(t) \mapsto \frac{1}{b} g\left(\frac{t}{b}\right). \quad (3.11)$$

Compunând cei doi operatori se obține:

$$g_{a,b} = T_a D_b \{g\} = \frac{1}{\sqrt{b}} g\left(\frac{t-a}{b}\right), \quad g_{a,b} \text{ – funcție wavelet de bază.} \quad (3.12)$$

În mod uzual, familia de funcții wavelet $g_{a,b}(t)$ se notează prin:

$$\psi_{a,b}(t) = |b|^{-\frac{1}{2}} \psi\left(\frac{t-a}{b}\right), \quad a, b \in \mathbb{R}, \quad a \neq 0 \quad (3.13)$$

$\psi(t)$ – funcție wavelet generatoare .

De regulă, toate reprezentările timp-frecvență sunt funcții continue de două variabile continue, iar în cazul reprezentării timp-frecvență de tip wavelet, toate variantele scalate și translate în timp ale funcției wavelet mamă, $\psi_{a,b}(t)$ pot fi desemnate drept funcții wavelet fiice (*daughter wavelet*). Produsul scalar dintre semnalul $x(t)$ și funcțiile $\psi_{a,b}(t)$ este o funcție de variabilele a și b și se numește reprezentare timp (a) – factor de scară (b). Având în vedere faptul că $1/b$ are dimensiunea de frecvență, produsul scalar dintre semnalul $x(t)$ și funcțiile $\psi_{a,b}(t)$ se mai numește și reprezentare timp-frecvență de tip wavelet sau Transformata Wavelet Continuă a semnalul $x(t)$.

Discretizând diadic variabilele a și b : $b=2^{-j}$ și $a=bk$, $j, k \in Z$, funcțiile wavelet fiice iau forma:

$$\psi_{j,k}(t) = 2^{\frac{j}{2}} \psi(2^j t - k), \quad (3.14)$$

și pot forma o bază a spațiului semnalelor de energie finită. În figura următoare este prezentat un exemplu de funcție wavelet mamă. Cu ajutorul acestor funcții pot fi efectuate descompuneri în serie de funcții wavelet.




Figura 3.2. Funcție wavelet de tip Coiflet.

În urma discretizării diadice amintite mai sus, reprezentarea timp-frecvență de tip wavelet a unui semnal $x(t)$ se particularizează la o descompunere în serie de funcții wavelet.

O funcție ψ care îndeplinește următoarele condiții poartă denumirea de *undă wavelet analizantă*:

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt = \langle \psi, \psi \rangle < \infty \text{ - unda prezintă o energie finită;} \quad (3.15)$$

$$C_{\psi} = \int_{-\infty}^{\infty} \frac{|\hat{\psi}(f)|^2}{f} df < \infty \text{ - unda descrește înspre limitele intervalului} \quad (3.16)$$

de definiție;

$$\hat{\psi}(0) = 0, \quad \text{medie nulă}, \quad (3.17)$$

Cu $\hat{\psi}$ s-a notat transformata Fourier a funcției ψ . Transformata wavelet continuă a unei funcții este un set de "coeficienți" egali cu produsele scalare dintre semnalul de analizat și funcțiile wavelet dilatate și/sau translatate. Coeficientul

wavelet reprezintă o măsură a variației semnalului analizat proporțională cu factorul de scară b în vecinătatea determinată de factorul de translație a .

Cu ajutorul noțiunii de produs scalar, notat cu $\langle \cdot, \cdot \rangle$, pot fi efectuate operații matematice într-un spațiu vectorial, și se poate defini norma unui vector $\|w\|^2 = \langle w, w \rangle$ și implicit distanța între doi vectori, $d(w_1, w_2) = \|w_1 - w_2\|^2$, noțiuni la care se va face apel în continuare.

Transformata wavelet continuă a unei funcții $s(t) \in L^p(\mathbb{R})$, $1 \leq p \leq \infty$ reprezintă o proiecție a semnalului de analizat $s(t)$ asupra funcției wavelet $\psi_{a,b}(t)$, obținută prin scalarea și translatarea funcției mother wavelets (MW) ψ , proiecție care depinde de caracteristicile semnalului analizat:

$$W_\psi s(a, b) = \langle s(t), \psi_{a,b}(t) \rangle = \int_{-\infty}^{\infty} s(t) \cdot \frac{1}{\sqrt{b}} \psi^*\left(\frac{t-a}{b}\right) dt, \quad a > 0, b \in \mathbb{R}. \quad (3.18)$$

Transformata wavelet continuă poate fi interpretată drept convoluția între semnalul analizat și funcția wavelet fiică și este așadar mulțimea proiecțiilor unui semnal analizat pe o bază constituită dintr-o familie de funcții care sunt translatări și dilatări normalizate ale unei funcții generatoare. După cum s-a amintit deja, prin discretizare diadică, transformata wavelet continuă se particularizează la descompunerea în serie de funcții wavelet. Pentru semnalul $f(t)$ de energie finită, descompunerea sa într-o serie de funcții wavelet are forma:

$$f = \sum_{m,n} \langle f, \psi_{m,n} \rangle \tilde{\psi}_{m,n}. \quad (3.19)$$

Există două structuri de funcții wavelet care permit descompunerea în serie de funcții wavelet: reperele și bazele.

Reperele (*frames*) au fost introduse de către Duffin și Schaefer, în 1952, în contextul discretizării transformatei Fourier scurte [34].

Definim drept *reper* o familie de funcții $(\varphi_j)_{j \in J}$ într-un spațiu Hilbert H , dacă există două constante $A > 0$, $B < \infty$ astfel încât pentru orice funcție $f \in H$ să fie îndeplinită relația:

$$A\|f\|^2 \leq \sum_{j \in J} |\langle f, \varphi_j \rangle|^2 \leq B\|f\|^2, \quad (3.20)$$

$$A > 0, B < \infty$$

Un reper cu $A = B = 1$ poartă denumirea de *reper Parseval*:

$$\|f\|^2 = \sum_{j \in J} |\langle f, \varphi_j \rangle|^2, \quad (3.21)$$

$$A = B = 1$$

Dacă în plus, $\|\varphi_j\| = 1$, atunci reperul Parseval reprezintă o bază ortonormală a spațiului Hilbert considerat.

În cazul în care $A = B$ avem de-a face cu un *reper fixat (tight)* :

$$\sum_{j \in J} |\langle f, \varphi_j \rangle|^2 = A \|f\|^2. \quad (3.22)$$

S-a constatat faptul că, pentru a avea un algoritm stabil de reconstrucție pentru semnalul analizat f , trebuie îndeplinită condiția care impune ca $\psi_{m,n}$ să constituie un reper. Condiția necesară pentru ca funcția $\psi_{m,n}$ să genereze un reper se mai numește și *condiție de admisibilitate*.

PROPOZITIE: Dacă $\psi_{m,n}(x) = a_0^{-\frac{m}{2}} \cdot \psi(a_0^{-m}x - nb_0)$, $m, n \in Z$ constituie un reper în spațiul $L^2(R)$, având constantele A și B , atunci:

$$A \cdot \frac{b_0 \ln a_0}{2\pi} \leq \int_0^{\infty} \frac{1}{\xi} |\hat{\psi}(\xi)|^2 d\xi \leq B \cdot \frac{b_0 \ln a_0}{2\pi} \quad (3.23)$$

și

$$A \cdot \frac{b_0 \ln a_0}{2\pi} \leq \int_{-\infty}^0 \frac{1}{\xi} |\hat{\psi}(\xi)|^2 d\xi \leq B \cdot \frac{b_0 \ln a_0}{2\pi}. \quad (3.24)$$

Se pune problema dacă coeficienții wavelet asociați semnalului f îl caracterizează suficient pe acesta. După cum s-a arătat deja, coeficienții wavelet ai lui f , se exprimă prin produsul scalar între funcția analizată f și funcția wavelet $\psi_{m,n}$:

$$c_{m,n} = \langle f, \psi_{m,n} \rangle, \quad \forall f \in L^2(R). \quad (3.25)$$

Semnalele pot fi caracterizate prin coeficienții wavelet, dacă îndeplinesc condițiile:

$$\langle f_1, \psi_{m,n} \rangle = \langle f_2, \psi_{m,n} \rangle, \quad \forall m, n \in Z \Leftrightarrow f_1 \equiv f_2, \quad (3.26)$$

sau,

$$\langle f, \psi_{m,n} \rangle = 0, \quad \forall m, n \in Z \Rightarrow f = 0. \quad (3.27)$$

Formula de reconstrucție a semnalului amintită mai sus [34]:

$$f = \sum_{m,n} \langle f, \psi_{m,n} \rangle \tilde{\psi}_{m,n}, \quad (3.28)$$

poate fi implementată cu structuri wavelet de tip reper dacă $\tilde{\psi}_{m,n} = S^{-1} \cdot \psi_{m,n}$ unde S este un operator liniar denumit *operatorul reper*: $S: H \rightarrow H$, având proprietatea

$$Sx = \sum_{j=1}^n \langle x, f_j \rangle f_j, \quad \forall x \in H, f \in L^2(R). \quad (3.29)$$

Pentru ca algoritmul de reconstrucție să fie stabil numeric este necesar ca unor secvențe de coeficienți $\langle f_1, \psi_{m,n} \rangle$ și $\langle f_2, \psi_{m,n} \rangle$ "apropiate" să le corespundă

semnale f_1 și f_2 „apropiate”. Distanța dintre cele două secvențe de coeficienți $c_1 = (c_{1m,n})_{m,n \in \mathbb{Z}}$ și $c_2 = (c_{2m,n})_{m,n \in \mathbb{Z}}$ se definește cu formula:

$$\|c_1 - c_2\|^2 = \sum_{m,n \in \mathbb{Z}} |c_{1m,n} - c_{2m,n}|^2. \quad (3.30)$$

Utilizarea acestei formule se bazează pe presupunerea implicită că cele două secvențe sunt semnale în timp discret de energie finită:

$$\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2 < \infty, \quad \forall f \in L^2(\mathbb{R}). \quad (3.31)$$

Această condiție nu pune probleme pentru structura de tip reper, deoarece conform definiției sale:

$$\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2 \leq B \|f\|^2. \quad (3.32)$$

Din cerința de “apropiere” a coeficienților, putem presupune că dacă valoarea $\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2$ este mică atunci și valoarea normei $\|f\|^2$ va fi mică. Putem

deci admite existența unei constante $\alpha < \infty$ astfel încât:

$$\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2 \leq 1 \Rightarrow \|f\|^2 \leq \alpha. \quad (3.33)$$

Se definește funcția:

$$\tilde{f} = \frac{1}{\sqrt{\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2}} f, \quad (3.34)$$

și se calculează următorul produs scalar:

$$\langle \tilde{f}, \psi_{m,n} \rangle = \left\langle \frac{1}{\sqrt{\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2}} f, \psi_{m,n} \right\rangle = \frac{1}{\sqrt{\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2}} \langle f, \psi_{m,n} \rangle. \quad (3.35)$$

În continuare se calculează suma seriei:

$$\begin{aligned} \sum_{m,n} |\langle \tilde{f}, \psi_{m,n} \rangle|^2 &= \sum_{m,n} \frac{1}{\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2} \cdot |\langle f, \psi_{m,n} \rangle|^2 = \\ &= \frac{1}{\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2} \cdot \sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2 = 1 \end{aligned} \quad (3.36)$$

În consecință, funcția \tilde{f} satisface condiția din membrul stâng al relației (3.33). De aceea se poate scrie că:

$$\|\tilde{f}\|^2 \leq \alpha. \quad (3.37)$$

Dar, ținând seama de definiția funcției \tilde{f} :

$$\|\tilde{f}\| = \frac{1}{\sqrt{\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2}} \|f\|, \quad (3.38)$$

în urma ridicării la pătrat, se poate scrie:

$$\Rightarrow \left[\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2 \right]^{-1} \|f\|^2 \leq \alpha \Leftrightarrow \frac{1}{\sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2} \cdot \|f\|^2 \leq \alpha \quad (3.39)$$

sau:

$$\frac{1}{\alpha} \|f\|^2 \leq \sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2, \quad (3.40)$$

adică:

$$A \|f\|^2 \leq \sum_{m,n} |\langle f, \psi_{m,n} \rangle|^2, \quad A = \frac{1}{\alpha} > 0 \quad (3.41)$$

Pe de altă parte, dacă relația (3.41) este verificată de către orice funcție f , atunci distanța $\|f_1 - f_2\|$ nu poate fi oricât de mare dacă

$\sum_{m,n} |\langle f_1, \psi_{m,n} \rangle - \langle f_2, \psi_{m,n} \rangle|^2$ are o valoare mică. În consecință relația (3.41) este

echivalentă cu condiția de reconstrucție numerică stabilă. De aceea, combinând relațiile (3.33) și (3.41), rezultă că structura de repere asigură stabilitatea numerică a algoritmului de reconstrucție.

În prelucrarea de semnale, reperele prezintă anumite dezavantaje, descompunerea corespunzătoare fiind redundantă. Din punct de vedere informațional, fiecare element al unui reper conține pe lângă informația proprie și o parte din informația proprie elementului vecin. Eliminarea unui element al reperului din descompunere produce atât pierderea informației purtate de elementul respectiv cât și o parte din informația purtată de elementele vecine.

Cea de a doua structură care se poate utiliza pentru descompunerea semnalelor analogice în serii de funcții wavelet este cea de bază.

În cazul bazelor ortonormale, fiecare element își poartă propria informație, putând fi considerat independent din punct de vedere informațional față de vecini, datorită relației de ortogonalitate existentă între elemente. Din această cauză, renunțarea la un element nu va afecta informația conținută de elementele învecinate. Operațiile matematice necesare pentru calculul coeficienților wavelet se simplifică de asemenea, nemaifiind redundante [30]:

$$\langle \varphi_j, \varphi_k \rangle = \begin{cases} 1, & j = k \\ 0, & j \neq k \end{cases}. \quad (3.42)$$

Dacă $(\varphi_j)_{j \in J}$ este un reper fixat, având $A = 1$ iar $\|\varphi_j\| = 1, \forall j \in J$ atunci φ_j constituie o *bază ortonormală*.

Se consideră două funcții f și g aparținând spațiului $L^2(\mathbb{R})$ – spațiul de funcții de valori complexe de pătrat al modulului integrabil pe \mathbb{R} și se definește produsul scalar al celor două funcții:

$$\langle f, g \rangle = \int_{-\infty}^{\infty} f(x) \overline{g(x)} dx. \quad (3.43)$$

O familie de funcții $(\varphi_k)_{k \in \mathbb{Z}}$ este numită *familie ortonormală* dacă se respectă următoarea condiție :

$$\int_{-\infty}^{\infty} \varphi_k(x) \overline{\varphi_l(x)} dx = \delta_{k,l}, \quad (3.44)$$

$$\delta_{k,l} = \begin{cases} 1, & k = l \\ 0, & k \neq l \end{cases}. \quad (3.45)$$

Această mulțime este denumită *bază ortonormală* a subspațiului $V \in L^2(\mathbb{R})$ în cazul în care orice funcție f din V se poate exprima ca o combinație liniară de elemente din această mulțime: $f(x) = \sum_{k \in \mathbb{Z}} c_k \varphi_k(x)$, $\forall f \in V$, cu $\sum_{k \in \mathbb{Z}} |c_k|^2 < \infty$.

Orice bază se poate transforma într-o bază ortonormală prin aplicarea procedurii *Gram-Schmidt*.

În prelucrarea semnalelor, transformata wavelet continuă joacă un rol important deoarece permite o bună localizare timp-frecvență folosind o fereastră de analiză de dimensiuni variabile. În mod ideal, funcția MW este de durată limitată și de bandă limitată. În realitate, niciun semnal nu poate fi localizat la fel de bine atât în domeniul timp cât și în domeniul frecvență. Localizarea timp-frecvență a unui semnal analizat poate fi măsurată prin produsul dintre durata efectivă σ_t și a banda de frecvență efectivă a semnalului σ_ω :

$$\sigma_t^2 = \int_{-\infty}^{\infty} t^2 |x(t)|^2 dt, \quad (3.46)$$

$$\sigma_\omega^2 = \int_{-\infty}^{\infty} \omega^2 |X(\omega)|^2 d\omega. \quad (3.47)$$

Conform principiului de incertitudine al lui Heisenberg este adevărată relația:

$$\sigma_t^2 \cdot \sigma_\omega^2 \geq \frac{\pi}{2}. \quad (3.48)$$

Produsul celor două variabile fiind constant, putem interpreta principiul lui Heisenberg în sensul că o localizare temporală mai bună (durata efectivă σ_t scurtă) implică o bandă de frecvență σ_ω mărită (corespunzând unei localizări frecvențiale

mai slabă). Cu toate acestea, funcțiile wavelet conferă avantajul utilizării unei ferestre de analiză de dimensiuni variabile. În cazul transformării wavelet continue, fereastra de analiză se adaptează la forma semnalului de analizat. În cazul semnalelor lente, durata ferestrei de analiză este lungă, spectrul său fiind îngust (localizare frecvențială bună) iar în cazul semnalelor rapide durata ferestrei de analiză este scurtă asigurând o localizare temporală bună [30].

Reprezentarea timp-frecvență de tipul transformare Fourier pe termen scurt *STFT* (*short time Fourier transform*) a unei funcții x (definită în ecuația următoare) face apel la fereastra de analiză g și nu permite în același timp o bună localizare în timp și în frecvență, deoarece fie localizarea în timp σ_t a ferestrei temporale fie localizarea în frecvență σ_ω a funcției g ia valori infinite,

$$STFT_x(t, \omega) = \int_{-\infty}^{\infty} x(\tau)g(t - \tau)e^{-j\omega\tau} d\tau. \quad (3.49)$$

Varianta discretă a STFT este prezentată în ecuația următoare:

$$STFT_x(t, \omega)_{t=n, f=m} = \int_{-\infty}^{\infty} x(\tau)g(n - \tau)e^{-2\pi jm\tau} d\tau, \quad \omega = 2\pi f \quad (3.50)$$

și folosește fereastra $g_{m,n}(\tau)$:

$$g(n - \tau)e^{-2\pi jm\tau} = g_{m,n}(\tau). \quad (3.51)$$

În cazul în care considerăm funcția $g(\tau)$ de tip impuls dreptunghiular de valoare 1 pe intervalul $(0, 1)$, pentru valorile duratei sale efective σ_t și respectiv a benzii sale de frecvență efectivă σ_ω se obține:

$$\sigma_t^2 = \int_{-\infty}^{\infty} x^2(g(x))^2 dx = \int_0^1 x^2 \cdot 1 \cdot dx = \frac{x^3}{3} \Big|_0^1 = \frac{1}{3} \quad (3.52)$$

și:

$$\sigma_\omega^2 = \int_{-\infty}^{\infty} \xi^2 |G(\xi)|^2 d\xi, \quad (3.53)$$

unde intervine spectrul impulsului dreptunghiular, calculat în continuare (3.54):

$$\begin{aligned} G(\xi) &= \int_{-\infty}^{\infty} g(x)e^{-j\xi x} dx = \int_0^1 1 \cdot e^{-j\xi x} dx = -\frac{1}{j\xi} \cdot e^{-j\xi x} \Big|_0^1 = -\frac{1}{j\xi} \cdot (e^{-j\xi} - 1) = \\ &= -\frac{e^{-j\frac{\xi}{2}}}{j\xi} \cdot (e^{-j\frac{\xi}{2}} - e^{j\frac{\xi}{2}}) = \frac{e^{-j\frac{\xi}{2}}}{j\xi} \cdot (e^{j\frac{\xi}{2}} - e^{-j\frac{\xi}{2}}) = \\ &= \frac{2e^{-j\frac{\xi}{2}}}{\xi} \cdot \frac{e^{j\frac{\xi}{2}} - e^{-j\frac{\xi}{2}}}{2j} = 2e^{-j\frac{\xi}{2}} \cdot \frac{\sin \frac{\xi}{2}}{\xi} = e^{-j\frac{\xi}{2}} \cdot \frac{\sin \frac{\xi}{2}}{\frac{\xi}{2}} = e^{-j\frac{\xi}{2}} \cdot \sin c \frac{\xi}{2} \end{aligned}$$

Substituind acest rezultat în expresia benzii de frecvență efectivă se obține (3.55):

$$\begin{aligned}\sigma_{\omega}^2 &= \int_{-\infty}^{\infty} \xi^2 |G(\xi)|^2 d\xi = \int_{-\infty}^{\infty} \xi^2 \cdot \frac{\sin^2 \frac{\xi}{2}}{\frac{\xi^2}{4}} d\xi = 4 \int_{-\infty}^{\infty} 1 \cdot \sin^2 \frac{\xi}{2} d\xi = \\ &= 4 \sum_{k=-\infty}^{\infty} \int_{k \cdot \pi}^{(k+1) \cdot \pi} \sin^2 \frac{\xi}{2} d\xi = 4 \sum_{k=-\infty}^{\infty} \frac{1}{2} \cdot \pi = 2 \sum_{k=-\infty}^{\infty} \pi = 2 \cdot \infty = \infty\end{aligned}$$

deoarece (3.56):

$$\begin{aligned}\int_{k \cdot \pi}^{(k+1) \cdot \pi} \sin^2 \frac{\xi}{2} d\xi &= \int_{k \cdot \pi}^{(k+1) \cdot \pi} \frac{1 - \cos \xi}{2} d\xi = \frac{1}{2} \left[\int_{k \cdot \pi}^{(k+1) \cdot \pi} d\xi - \int_{k \cdot \pi}^{(k+1) \cdot \pi} \cos \xi \cdot d\xi \right] = \frac{1}{2} \cdot \pi - \frac{1}{2} \cdot \sin \xi \Big|_{k \cdot \pi}^{(k+1) \cdot \pi} = \\ &= \frac{1}{2} \cdot \pi - \frac{1}{2} [\sin((k+1) \cdot \pi) - \sin(k \cdot \pi)] = \frac{1}{2} \cdot \pi\end{aligned}$$

În consecință, fereastra de analiză de tip impuls are durată efectivă finită dar are o bandă de frecvență efectivă infinită. Acest exemplu verifică afirmația făcută anterior referitoare la faptul că STFT nu poate asigura simultan localizări temporale și frecvențiale finite.

Funcțiile wavelet, în schimb, asigură valori finite pentru durata efectivă și pentru banda efectivă, permițând astfel atât localizare temporală cât și localizare frecvențială satisfăcătoare. Durata funcției generatoare $\psi(t)$ și valoarea factorului de scară s dau o măsură a duratei efective σ_t și deci a localizării temporale, în timp ce banda de frecvențe σ_{ω} a funcției generatoare $\psi(t)$ și factorul de scară s dau localizarea frecvențială a ferestrei de analiză, celula de rezoluție fiind [30]:

$$[t - \sigma_t / 2s, t + \sigma_t / 2s] \times [\omega - \sigma_{\omega} s / 2, \omega + \sigma_{\omega} s / 2]. \quad (3.57)$$

O caracteristică a funcțiilor wavelet o reprezintă numărul de *momente nule* (*vanishing moments*) care dă o măsură a regularității locale (smoothness) a funcției [35].

De exemplu, pentru funcția de scară propusă de Haar $\phi_H(t)$, avem funcția wavelet generatoare corespunzătoare $\psi_H(t)$,

$$\psi_H(t) = \begin{cases} 1, & 0 \leq t \leq \frac{1}{2} \\ -1, & \frac{1}{2} \leq t \leq 1. \\ 0, & \text{in rest} \end{cases} \quad (3.58)$$

Funcția wavelet Haar este prima funcție wavelet mamă cunoscută și a fost propusă de Alfred Haar în 1909 [36]. Ea are cel mai scurt suport dintre funcțiile wavelet ortogonale. Graficul său este prezentat în figura următoare.

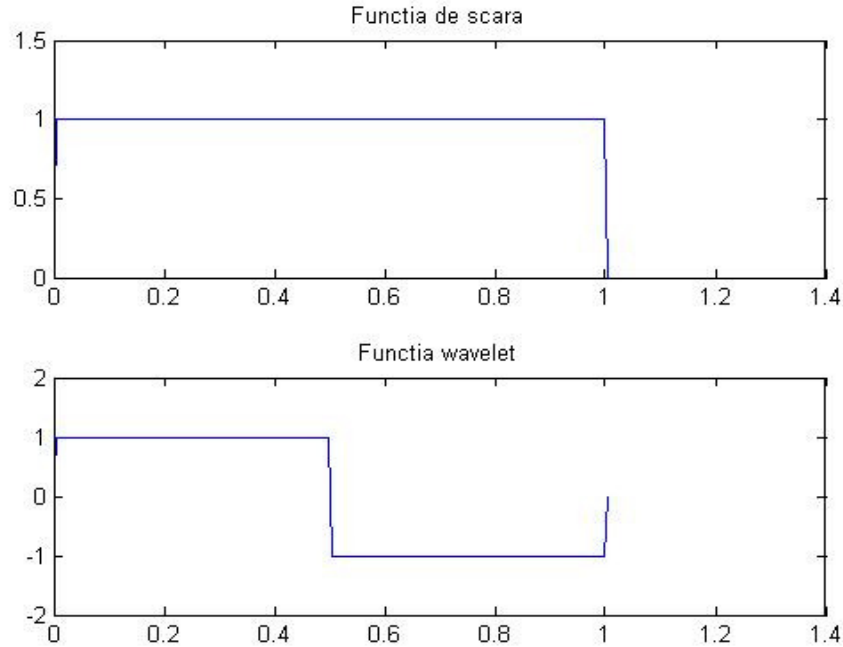


Figura 3.3. Funcția wavelet propusă de Haar.

Funcția ψ are $K+1$ momente nule dacă cea mai mare valoare a lui k pentru care integrala definită în ecuația (3.59) se anulează este egală cu K :

$$k = 0 \dots K \quad \int_{-\infty}^{\infty} t^k \psi(t) dt = 0. \quad (3.59)$$

În continuare se calculează numărul de momente nule pentru funcția wavelet de tip Haar:

$$\text{pentru } k = 0 \quad \int_{-\infty}^{\infty} t^0 \cdot \psi_H(t) dt = \int_0^{\frac{1}{2}} dt + \int_{\frac{1}{2}}^1 (-1) dt = t \Big|_0^{\frac{1}{2}} - t \Big|_{\frac{1}{2}}^1 = \frac{1}{2} - 1 + \frac{1}{2} = 0 \quad (3.60)$$

$$\text{pentru } k = 1 \quad \int_{-\infty}^{\infty} t^1 \cdot \psi_H(t) dt = \int_0^{\frac{1}{2}} t^1 \cdot dt - \int_{\frac{1}{2}}^1 t^1 \cdot dt = \frac{t^2}{2} \Big|_0^{\frac{1}{2}} - \frac{t^2}{2} \Big|_{\frac{1}{2}}^1 = \frac{1}{8} - \frac{1}{4} = -\frac{1}{8} \neq 0 \quad (3.61)$$

În concluzie, funcția wavelet de tip Haar are un singur moment nul. Într-adevăr, această funcție are un grad de regularitate redus, așa cum o arată și graficul său, având trei puncte de discontinuitate. Funcția wavelet de tip Haar este una din puținele funcții wavelet cu expresie analitică explicită. Un alt exemplu de funcție wavelet, având un număr redus de momente nule este prezentat în figura următoare.




Figura 3.4. Funcția wavelet propusă de Daubechies (funcția prezintă 2 momente nule).

Anumite proprietăți ale transformatelor wavelet depind de numărul de momente nule ale funcției MW, lungimea suportului acestei funcții generatoare crescând odată cu creșterea numărului de momente nule. În consecință, un număr redus de momente nule asigură o bună localizare în timp, în timp ce odată cu creșterea numărului de momente nule, se îmbunătățește localizarea în frecvență.

Funcțiile wavelet ortogonale se pot grupa în câteva familii de funcții, fiecare dintre acestea având proprietăți specifice.

1. Familia de *funcții wavelet Daubechies*: a fost propusă de matematicianul belgian Ingrid Daubechies [34] și este compusă din funcții MW asimetrice cu suport minimal pentru un număr dat de momente nule. Fiecărei funcții MW îi corespunde o funcție de scară cu ajutorul căreia se generează analiza multirezoluție. Indexul din dreptul numelui funcției MW dă un indiciu asupra numărului său de momente nule.




Figura 3.5. Funcția wavelet Db20 propusă de Daubechies

2. Familia de *funcții wavelet Coiflet*: funcțiile wavelet Coiflet (notate prescurtat *Coif*) au același număr de momente nule ca și funcțiile de scară corepunzătoare. Această familie de funcții wavelet a fost propusă de I. Daubechies și a fost denumită în cinstea matematicianului Ronald Coifman [34]. Funcțiile wavelet Coifman prezintă suport compact și o simetrie mai puternică decât funcțiile wavelet Daubechies, având pentru o lungime n a suportului, $n-3$ momente nule. Figura 3. 6 prezintă funcția wavelet Coif5.

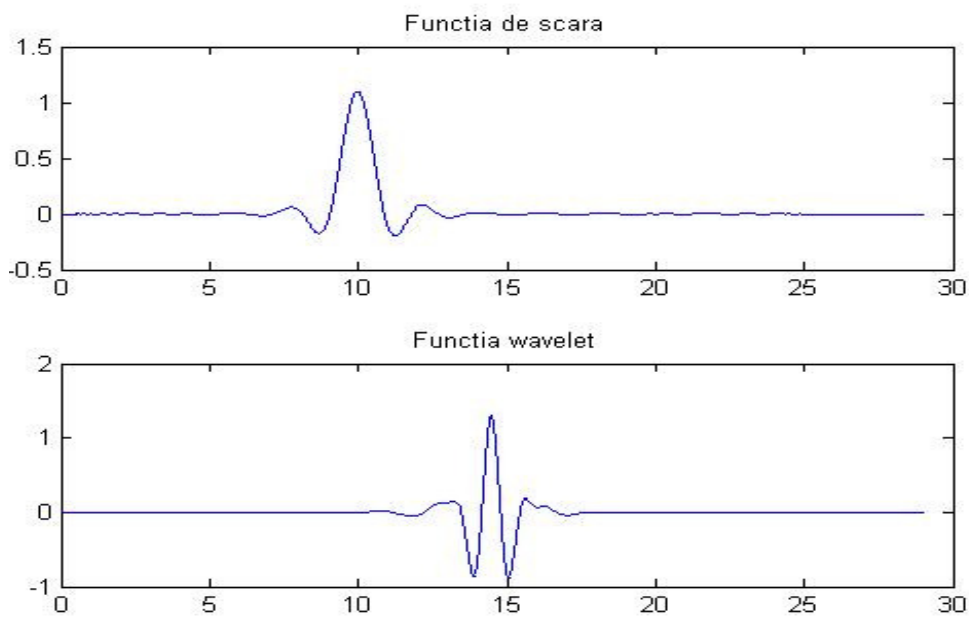


Figura 3.6. Funcția wavelet Coif5.

3. Familia de *funcții wavelet Symmlet*: sunt funcții MW mai simetrice decât elementele familiei de funcții wavelet ortogonale Daubechies, având de asemenea o lungime a suportului minimă pentru un număr de momente nule [34]. Au fost propuse de I. Daubechies pentru a îmbunătăți simetria elementelor familiilor anterioare, construcția lor fiind similară cu cea a funcțiilor wavelet mamă Daubechies. În cazul funcțiilor MW Symmlet (notate prescurtat *Symm*), pentru o lungime n a filtrului de implementare, numărul de momente nule corespunzătoare este de $n/2$, iar lungimea suportului $n-1$. Figura de mai jos prezintă funcția *Symm4*:




Figura 3.7. Funcția wavelet Symm4.

4. Familia de *funcții wavelet Battle-Lemarié*: este o familie de funcții wavelet fără suport compact, studiate de G. Battle și P. Lemarié [37]. Un exemplu este prezentat în figura următoare. Asupra funcției de scară φ trebuie aplicat procedeul Gram-Schmidt de ortogonalizare pentru a obține familia de funcții wavelet Battle-Lemarié ortogonale.




Figura 3.8. Funcția wavelet Battle-Lemarié2.

Asimetria funcțiilor wavelet ortogonale poate crea efecte nedorite în aplicații de prelucrarea imaginilor, prin utilizarea aceluiași set de filtre FIR atât pentru descompunere cât și pentru reconstrucție [38].

Din aceste considerente au fost create funcțiile wavelet biortogonale, care sunt mai simetrice, permițând o reconstrucție mai bună a semnalelor. Elementele bazei sunt ortogonale pe elementele vectorului de expansiune, dar nu sunt ortogonale între ele.

Funcțiile wavelet biortogonale prezintă suport compact, permițând utilizarea de filtre diferite pentru descompunerea și reconstrucția semnalului [38]. În acest sens se introduc două funcții wavelet: ψ (utilizată la analiza semnalului) și ψ' (utilizată la reconstrucția semnalului):

$$c_i' = \int s(t) \cdot \psi_i'(t) dt \quad (3.62)$$

$$rec = \sum_{i=1}^n c_i' \cdot \psi_i \quad (3.63)$$

În figurile următoare se dau exemple de funcții wavelet biortogonale (reprezentate cu verde în partea dreaptă a figurilor) împreună cu funcțiile de scară corespunzătoare (reprezentate cu roșu în partea stângă a figurilor).

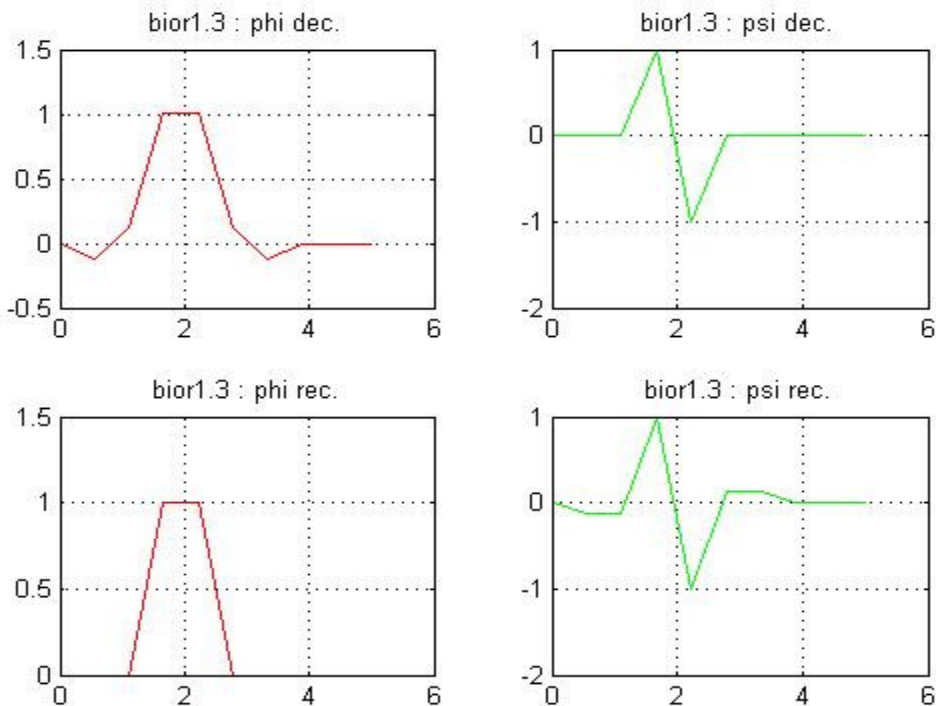


Figura 3.9. Funcția wavelet biortogonală bior1.3




Figura 3.10. Funcția wavelet biortogonală bior2.4




Figura 3.11. Funcția wavelet biortogonală bior5.5.

3.3.3. Transformata Wavelet Continuă (CWT)

Transformata wavelet continuă (CWT) a fost introdusă de Grossmann și Morlet în anul 1984 drept o alternativă menită să înlăture limitările transformatei Fourier scurtă (STFT). CWT este o reprezentare bidimensională a unui semnal și poate fi definită drept produsul scalar dintre semnalul analizat $s(t) \in L^2(\mathbb{R})$ și elementele unei familii de funcții wavelet, altfel spus cu o funcție analizantă calculată la scara b și momentul a , generată pe baza funcției wavelet mamă $\psi(t) \in L^2(\mathbb{R})$:

$$CWT_s(a, b) = \langle s(t), \psi_{a,b}(t) \rangle, \quad a, b \in \mathbb{R}, \quad a \neq 0 \quad (3.64)$$

Luând în considerare natura celor doi parametri, a și b , remarcăm faptul că CWT poate fi percepută drept o reprezentare a semnalului $s(t)$ concomitent dependentă de factori de timp și scară. Interpretând factorul de scară drept inversa unei frecvențe, CWT devine o reprezentare timp-frecvență a semnalului $s(t)$.

În principiu, coeficienții wavelet caracterizează semnalul analizat la o anumită rezoluție (dependentă de factorul de scară, definit drept inversul frecvenței) și la un anumit moment de timp (dependent de factorul de translație). Informațiile obținute descriu comportamentul semnalului la un moment ales de timp și pot fi prelucrate separat pe segmente diferite, eliminând dezavantajul unei ferestre de analiză fixate precum în cazul STFT. În acest mod (utilizând o fereastră de analiză de lungime variabilă) a fost facilitată reprezentarea funcțiilor neperiodice cu discontinuități sau cu variații mari, extinzându-se domeniul de aplicare a metodelor de prelucrare a semnalelor. Variind factorii de translație și de scară, CWT poate furniza simultan informații despre domeniul timp-frecvență, respectând limitările impuse de principiul incertitudinii formulat de Heisenberg.

$$CWT_s(a, b) = \int_{-\infty}^{\infty} s(t) \cdot b^{-\frac{1}{2}} \psi^* \left(\frac{t-a}{b} \right) dt \quad \Leftrightarrow \quad CWT_s(a, b) = (s * \bar{\psi}_b)(a) \quad (3.65)$$

unde $\bar{\psi}_b(a)$ reprezintă conjugata complexă a funcției wavelet ψ_b , dependentă de parametrii de translație a și scară b :

$$\bar{\psi}_b(a) = \frac{1}{\sqrt{b}} \cdot \psi^* \left(\frac{t-a}{b} \right). \quad (3.66)$$

În concluzie, CWT reprezintă o colecție de produse scalare ale căror valori depind de semnalul analizat și familia de funcții wavelet folosită. Calculul numeric al CWT este dificil din cauza naturii continue a variabilelor a și b . Astfel, variabilele a și b trebuie discretizate pentru a face posibilă implementarea CWT cu ajutorul calculatorului numeric.

3.3.4. Transformata Wavelet Discretă (DWT)

În natură întâlnim numeroase semnale în timp continuu (analogice). Funcția wavelet continuă are următoarea definiție:

$$\psi_{a,b}(x) = |b|^{-\frac{1}{2}} \psi\left(\frac{x-a}{b}\right), \quad \psi \in L^2(\mathbb{R}), a \in \mathbb{R}, b \in \mathbb{R}_+, b \neq 0, \quad (3.67)$$

unde parametrul a are semnificația de întârziere iar parametrul b are semnificația de factor de scară (inversul său având semnificația de frecvență). Variabila x are semnificația de timp. Mulțimea produselor scalare dintre un semnal analizat și funcția wavelet continuă este o funcție de două variabile a și b . Această funcție se numește transformată wavelet continuă a semnalului de analizat și are semnificația de reprezentare timp-factor de scară sau reprezentare timp-frecvență.

În scopul de a prelucra prin mijloace moderne de calcul numeric un semnal, acesta trebuie supus operației de discretizare atât în domeniul timp (eșantionare) cât și în domeniul amplitudinii (cuantizare). În același scop trebuie discretizată și transformarea wavelet continuă.

Se va discretiza factorul de scară b , folosind un pas m de discretizare:

$$\begin{aligned} b &= b_0^m, \quad m \in \mathbb{Z} \\ b_0 &\neq 1 - \text{fixat} \end{aligned} \quad (3.68)$$

Pentru a simplifica, se alege $b_0 > 1$.

În cazul $m = 0$, se discretizează și parametrul de translație a cu pasul n ($n \in \mathbb{Z}$), alegând doar multipli pozitivi ai unui a_0 fixat arbitrar (cu condiția $a_0 > 0$).

Funcția wavelet discretizată va avea, în urma notațiilor introduse și a operațiilor efectuate următoarea formă:

$$\psi_{a,b}(x) = |b|^{-\frac{1}{2}} \psi\left(\frac{x-a}{b}\right) \Rightarrow \psi_{m,n}(x) = b_0^{-\frac{m}{2}} \psi\left(\frac{x - na_0 b_0^m}{b_0^m}\right). \quad (3.69)$$

Se constată că și funcțiile wavelet $\psi_{m,n}$ obținute astfel sunt semnale în timp continuu. Folosind această discretizare pentru transformarea wavelet continuă se obțin pentru $b_0=2$ și pentru $a_0=1$, seriile de funcții wavelet, despre care am vorbit deja. Din păcate, nici descompunerea în serii de funcții wavelet nu poate fi implementată pe calculatoare numerice, fiind vorba despre descompunerea unor semnale analogice. Pentru prelucrarea numerică a acestora cu funcții wavelet, este necesară în primul rând eșantionarea lor, urmată de aplicarea transformării wavelet discrete (DWT).

Modalitatea practică de implementare a DWT face apel la algoritmul dezvoltat de Stephane Mallat [39] și utilizează filtre cu răspuns finit la impuls (FIR). Algoritmul poate fi descris după cum urmează [33]: un semnal de intrare, alcătuit de exemplu din 2^7 (128) de eșantioane este trecut prin două filtre FIR conectate în paralel, așa după cum se poate constata din figura 3.12. LP_i sunt filtre trece-jos, modulul răspunsului lor în frecvență fiind mare pentru frecvențe joase și mic pentru frecvențe înalte, în timp ce filtrele HP_i sunt de tip trece-sus, modulul răspunsului lor

în frecvență fiind mic pentru frecvențe joase și mare pentru frecvențe înalte. În consecință, diagramele de modul ale răspunsurilor în frecvență ale celor două filtre vor fi complementare, una dintre aceste diagrame reprezentând imaginea în oglindă a celeilalte, fapt ce a dus la definirea conceptului de *mirror filters* (filtre în oglindă) utilizat în analiza wavelet. Un filtru FIR de ordinul n , $H_0(z)$, formează împreună cu filtrul FIR $H_1(z)$, o pereche de filtre în oglindă QMF (quadrature mirror filters) dacă are următoarea proprietate [33]:

$$H_0(-z) = H_1(z). \quad (3.70)$$

Filtrele $H_0(z)$ și $H_1(z)$ din exemplul următor au proprietatea de a forma o pereche QMF (quadrature mirror filters) [33].

$$H_0(z) = 1 + z^{-1}, \quad (3.71)$$

$$H_1(z) = 1 - z^{-1}. \quad (3.72)$$

Noțiunea de bancă de filtre (filter bank) se referă la un grup de filtre conectate în paralel și legate între ele prin operatori de eșantionare și întârziere [33]. Grupul va fi alcătuit din filtre trece-jos pe una din laturi iar pe cea de-a doua latură vor fi grupate filtre trece-sus, această combinație permițând trecerea componentelor frecvențiale ale semnalului analizat din anumite subbenzi.

Indicele i desemnează numărul iterației curente aplicată semnalului de intrare, în exemplul considerat fiind posibile 7 iterații. Decimarea cu un factor de doi impune utilizarea unui semnal de intrare de lungime care să fie o putere a lui doi. Lungimea semnalului de intrare determină și numărul maxim de iterații posibile. Semnalele de ieșire ale filtrelor trece-jos dintr-o iterație reprezintă secvențe de coeficienți de aproximare $A_i(n)$ iar semnalele de ieșire ale filtrelor trece-sus din aceeași iterație reprezintă secvențe de coeficienți de detaliu $d_i(n)$. Ambele tipuri de secvențe vor fi supuse operației de subeșantionare cu un factor de 2 (operație desemnată prin simbolul $\downarrow 2$), însemnând eliminarea fiecărui al doilea coeficient. În exemplul considerat, $A_1(n)$ va avea după filtrare 64 (2^6) elemente, iar $d_1(n)$ va avea tot 64 (2^6) elemente. În iterația următoare, coeficienții de aproximare $A_1(n)$ vor fi supuși din nou operațiilor de filtrare și subeșantionare pentru a genera următoarele secvențe de coeficienți $A_2(n)$ și $d_2(n)$, care vor conține fiecare câte 32 de elemente (2^5). Algoritmul se va repeta la următoarea iterație, utilizând coeficienții $A_2(n)$ pentru a obține coeficienții de aproximare $A_3(n)$ și de detaliu $d_3(n)$ (conținând 16 elemente). Dacă se vor efectua toate cele 7 iterații posibile, rezultatul aplicării transformării wavelet discrete va conține distribuit același număr de eșantioane ca și semnalul original: $d_1(n)$ - 64 eșantioane, $d_2(n)$ - 32 eșantioane, $d_3(n)$ - 16 eșantioane, $d_4(n)$ - 8 eșantioane, $d_5(n)$ - 4 eșantioane, $d_6(n)$ - 2 eșantioane, $d_7(n)$ - 1 eșantion, $A_7(n)$ - 1 eșantion ($1+1+2+4+8+16+32+64=128$). Un alt mod de notare a coeficienților wavelet, poate mai intuitiv pentru a recunoaște nivelul de descompunere la care se face referire [33], presupune indexarea coeficienților în ordinea inversă a iterațiilor. Astfel, secvențele de coeficienți din exemplul menționat vor conține următoarele numere de elemente: $A_0(n)$ - 2^0 elemente, $d_0(n)$ - 2^0 elemente, $d_1(n)$ - 2^1 elemente, $d_2(n)$ - 2^2 elemente, $d_3(n)$ - 2^3 elemente, $d_4(n)$ - 2^4 elemente, $d_5(n)$ - 2^5 elemente, $d_6(n)$ - 2^6 elemente. În continuare vom face apel la această notație.

Datorită scăderii numărului de eşantioane al secvențelor de aproximări și de detalii, odată cu creșterea numărului de iterații, DWT nu este potrivită pentru orice tip de aplicație. Reconstrucția semnalului se face inversând procedeul (utilizând Transformata Wavelet Discretă Inversă – IDWT). Se va porni de la ultimul nivel de coeficienți, care vor fi supraeșantionați cu un factor de 2 (se va intercala un zero la fiecare al doilea element) și interpolați după trecerea prin cele două filtre FIR conectate în paralel. Procesul face apel la coeficienții rezultați din stagiile anterioare de filtrare și continuă până la reconstrucția semnalului de intrare original $s(n)$.

Operațiile de subeșantionare și supraeșantionare cu un factor de doi, însemnând eliminarea inițială a fiecărui al doilea element din șir și înlocuirea ulterioară cu elementul zero, găsesc o expresie echivalentă în aplicarea transformatei z , $V(z)$ asupra funcției analizate $v(n)$ [33]:

$$(\uparrow 2)(\downarrow 2)v(n) \leftrightarrow 1/2 \cdot [V(z) + V(-z)] \quad (3.73)$$

$$\text{unde, } (\downarrow 2)v(n) \leftrightarrow (-1)^n * v(n) \quad (3.74)$$

$$v(n) \leftrightarrow V(z) \quad (3.75)$$

$$(-1)^n * v(n) \leftrightarrow V(-z) \quad (3.76)$$




Figura 3.12. Structura bancului de filtre care implementează transformarea DWT.

Ca urmare a subeșantionării succesive a semnalului analizat, algoritmul lui Mallat de calcul al DWT nu este redundant, dar lungimea secvenței de coeficienți wavelet (după cum se poate observa și din exemplul prezentat) va descrește odată cu creșterea numărului de niveluri de descompunere. Blocurile de subeșantionare nu sunt invariante la translații. Datorită utilizării lor, nici DWT nu este invariantă la translații. Prin urmare DWT nu este potrivită pentru aplicațiile de prelucrare de semnale care necesită invarianță la translații.

În legătură cu algoritmul lui Mallat, care tocmai a fost prezentat, se poate defini conceptul de Analiză Multirezoluție (Multiresolution Analysis – MRA).

În capitolele următoare ale acestei teze vor fi selectate funcții MW ortogonale pentru descompunerea și analiza semnalului, datorită faptului că proprietatea de ortogonalitate asigură conservarea energiei semnalului în domeniul DWT, proprietate care simplifică reconstrucția ulterioară a semnalului. Funcțiile MW biortogonale oferă o simetrie mai mare decât funcțiile MW ortogonale [40] dar necesită algoritmi mai complecși de reconstrucție, datorită faptului că se utilizează funcții MW duale.

3.3.5 Analiza multirezoluție

Implementarea de tip banc de filtre a devenit o modalitate utilă de calcul a DWT, permițând prelucrarea diferită a frecvențelor diferite. Conceptul a fost introdus în jurul anului 1988 de către Stephane Mallat și Yves Meyer [35].

Definim o funcție de scară $\varphi_{a,b}(t)$, astfel încât să descriem coeficienții de aproximare la nivelul de descompunere i drept produsul scalar între semnalul analizat $s(t)$ și funcția de scară:

$$A_i(n) = \langle s(t), \varphi_{a,b}(t) \rangle, \quad \forall s \in L^2(\mathbb{R}), \quad \varphi_{a,b}(t) = \frac{1}{\sqrt{b^i}} \varphi\left(\frac{t - ab^i n}{b^i}\right), \quad a, b \in \mathbb{Z} \quad (3.77)$$

Conform definițiilor anterioare, putem reformula descrierea matematică a coeficienților de aproximare după cum urmează:

$$A_i(n) = \int_{-\infty}^{\infty} s(t) \cdot \frac{1}{\sqrt{b^i}} \varphi\left(\frac{t - ab^i n}{b^i}\right) dt, \quad a > 0, b \in \mathbb{R} \quad (3.78)$$

În cazul semnalelor discrete, cele mai utilizate valori ale parametrilor de poziție a și de scară b sunt 1 respectiv 2, valori care normalizează funcțiile de scară:

$$A_i(n) = \int_{-\infty}^{\infty} s(t) \cdot \left(2^{-\frac{1}{2} \cdot i}\right) \varphi\left(\frac{t - 2^i n}{2^i}\right) dt, \quad a > 0, b \in \mathbb{R} \quad (3.79)$$

expresie care poate fi echivalată prin:

$$A_i(n) = \int_{-\infty}^{\infty} s(t) \cdot \left(\frac{1}{\sqrt{2^i}}\right) \varphi(2^{-i} t - n) dt, \quad a > 0, b \in \mathbb{R}. \quad (3.80)$$

Spațiile Hilbert generate de bazele ale căror elemente sunt funcțiile $\left\{ \varphi_{i,n}(t) = 2^{-\frac{i}{2}} \varphi\left(\frac{t - 2^i n}{2^i}\right) \right\}$ se notează cu V_i . Funcție de numărul de

descompuneri ale DWT efectuate, se pot defini mai multe subspații de tipul V_i , fiecare corespunzând la o anumită rezoluție a semnalului analizat. Combinând mai multe asemenea subspații, se poate realiza o analiză multirezoluție. Selecția subspațiului potrivit pentru o anumită aplicație este unul din avantajele analizei wavelet, deoarece permite o optimizare a parametrilor analizei semnalului.

Similar se pot defini spațiile $W_i \subset L^2(\mathbb{R})$, ortogonale pe spațiile V_i , drept spațiile generate de bazele ale căror elemente sunt funcțiile $\left\{ \psi_{i,n}(t) = 2^{-\frac{i}{2}} \psi\left(\frac{t - 2^i n}{2^i}\right) \right\}$.

Coefficienții wavelet de detaliu de la cel de al i -ilea nivel de descompunere al DWT se calculează cu ajutorul următoarelor produse scalare:

$$d_i(n) = \langle s(t), \psi_{i,n}(t) \rangle$$

$$d_i(n) = \int_{-\infty}^{\infty} s(t) \frac{1}{\sqrt{2^i}} \psi\left(\frac{t-2^i n}{2^i}\right) dt, \quad \forall s \in L^2(\mathbb{R}), \quad i, n \in \mathbb{Z} \quad (3.81)$$

Fie $V_1 \subset L^2(\mathbb{R})$ un spațiu vectorial iar V_0 un subspațiu $V_0 \subset V_1$. Complementul ortogonal al lui V_0 în V_1 este chiar spațiul $W_0 = V_0^\perp$, în care există un vector $w \in W_0$ astfel încât pentru orice vector v din V_1 :

$$\langle w, v \rangle = 0. \quad (3.82)$$

De asemenea, fiecare vector component al spațiului V_1 poate fi descompus ca și sumă a vectorilor v și w definiți anterior:

$$V_1 = V_0 \oplus W_0. \quad (3.83)$$

Revenind la definiția dată de Meyer și Mallat conceptului de analiză multirezoluție, poate fi formulat următorul enunț [33]:

DEFINIȚIE: Un lanț ascendent de subspații $V_k \subset L^2(\mathbb{R}), k \in \mathbb{Z} : \{0\} \subset \dots \subset \{V_{i-1}\} \subset \{V_i\} \subset \{V_{i+1}\} \subset \dots \subset L^2(\mathbb{R})$ având următoarele proprietăți:

1. $\bigcap_{i \in \mathbb{Z}} V_i = \{0\}$,
2. $f \in V_i : f\left(\frac{t}{2}\right) \in V_{i+1}$,
3. V_0 este un spațiu de eșantionare cu frecvență de eșantionare egală cu unitatea, definește o analiză multirezoluție.

Definiția certifică proprietățile MRA: spațiile sunt ortogonale între ele, spațiul V_{i+1} este o versiune scalată a spațiului anterior V_i , rezultând faptul că funcțiile aparținând spațiului V_{i+1} au în general mai multe detalii (*small scale features*) decât funcțiile aparținând spațiului V_i [41] astfel încât fiecare funcție $f(t)$ poate fi aproximată de o secvență de funcții conținând din ce în ce mai multe detalii. Subspațiile scalate ale spațiului V_i vor fi spații de eșantionare (sampling space) eșantionate cu o frecvență de 2^{-i} . Funcțiile aparținând spațiului V_0 trebuie să fie la o scară cel puțin egală cu 1, acest spațiu având o bază ortonormală invariantă la translație generată de o funcție $\varphi(t) \in V_0$.

De asemenea, pentru fiecare MRA $\{V_j\}$ va exista o funcție unică denumită funcție wavelet $\psi(t)$ astfel încât familia $\{\psi_{a,i} = \sqrt{2^{-i}} \psi(2^i t - a), a, i \in \mathbb{Z}\}$ să formeze o bază

ortonormală aparținând $L^2(\mathbb{R})$. Funcția wavelet $\psi(t)$ poate fi construită explicit utilizând funcția generatoare $\varphi(t)$.

Funcția de scară $\varphi_{a,b}(t)$ poate fi scrisă drept o combinație liniară a unor versiuni scalate și translatare cu factorul 2 [33], $\varphi(2t - a)$:

$$\varphi(t) = \sum_a 2^{-\frac{1}{2}} \cdot h_0(a) \cdot \varphi(2t - a), \quad (3.84)$$

unde h_0 reprezintă răspunsul la impuls al filtrului notat cu LP în figura 3.12.

Mulțimea subspațiilor V_i alcătuiește o analiză multirezoluție a semnalului analizat. Deoarece implementarea DWT propusă de Mallat urmărește obținerea coeficienților wavelet prin filtrare și subșantionare, orice funcție de scară este specificată printr-un filtru discret, denumit *conjugate mirror filter*. Răspunsul la impuls $h[a]$ și răspunsul în frecvență $H(\omega)$ ale unui astfel de filtru au următoarele expresii:

$$h[a] = \left\langle 2^{-\frac{1}{2}} \cdot \varphi(t/2), \varphi(t-a) \right\rangle \quad (3.85)$$

$$H(\omega) = \sum_{a=-\infty}^{\infty} e^{-j\omega a} \cdot h[a]. \quad (3.86)$$

Analog, se pot exprima și funcțiile wavelet ca și combinații liniare ale unor variante scalate și translatare ale funcției de scară φ .

Conform definiției spațiilor ortogonale $V_{i+1} = V_i \oplus W_i$, rezultă că funcția wavelet poate fi descompusă și într-o bază a spațiului V_1 :

$$\psi(t) = \sum_a 2^{-\frac{1}{2}} \cdot h_1(a) \cdot \varphi(2t - a), \quad (3.87)$$

unde h_1 reprezintă răspunsul la impuls al filtrului notat cu HP în figura 3.12.

Relațiile (3.84) și (3.87) pot fi dezvoltate pentru a demonstra interdependența coeficienților situați la niveluri diferite de descompunere. Astfel, se definește [33]:

$$\varphi(2^i t - p) = \sum_a 2^{-\frac{1}{2}} \cdot h_0(a) \cdot \varphi(2 \cdot (2^i t - p) - a) \Leftrightarrow \quad (3.88)$$

$$\Leftrightarrow \varphi(2^i t - p) = \sum_a 2^{-\frac{1}{2}} \cdot h_0(a) \cdot \varphi(2^{i+1} t - 2p - a) \quad (3.89)$$

Înlocuind expresia obținută a funcției de scară dilatată și translatare $\varphi(2^i t - p)$ în expresia de calcul a coeficienților de aproximare și operând schimbarea de variabilă $a = m - 2p$:

$$\begin{aligned}
A_i(p) &= \langle s(t), \varphi(2^i t - p) \rangle = \int_{-\infty}^{\infty} s(t) \cdot 2^{-\frac{1}{2}i} \cdot \sum_a 2^{-\frac{1}{2}} \cdot h_0(m - 2p) \varphi(2^{i+1}t - 2p - m + 2p) dt \Leftrightarrow \\
A_i(p) &= \sum_a h_0(m - 2p) \cdot \int_{-\infty}^{\infty} s(t) \cdot 2^{-\frac{1}{2}(i+1)} \varphi(2^{i+1}t - m) dt \Leftrightarrow \\
&\Leftrightarrow A_i(p) = \sum_a h_0(m - 2p) \cdot A_{i+1}(m)
\end{aligned} \tag{3.90}$$

Astfel, remarcăm existența unei relații de interdependență dintre coeficienții de aproximare de la un nivel și coeficienții de la următorul nivel.

Similar, se poate defini relația de interdependență pentru coeficienții de detaliu:

$$d_i(p) = \sum_a h_1(m - 2p) \cdot A_{i+1}(m). \tag{3.91}$$

Remarcăm faptul că pentru a calcula coeficienții de detaliu de la un nivel de descompunere, se va face apel la coeficienții de aproximare de la nivelul anterior, coeficienții de detaliu de la un nivel fiind conținuți în expresia coeficienților de aproximare.

Ecuția de sinteză, care permite reconstrucția semnalului utilizând coeficienții wavelet de aproximare $A_i(n)$ și de detaliu $d_i(n)$ prezintă următoarea formă:

$$s(t) = \sum_{k=-\infty}^{\infty} A_i(k) \varphi_{ik}(t) + \sum_{i=1}^I \sum_{k=-\infty}^{\infty} d_i(k) \psi_{ik}(t). \tag{3.92}$$

Prin urmare, analiza multirezoluție permite adaptarea rezoluției semnalului analizat, astfel încât este posibilă prelucrarea aproximărilor și detaliilor relevante unui caz specific. Versiunea originală a semnalului este descrisă la rezoluția maximă, în timp ce pentru versiunile succesive se utilizează rezoluții din ce în ce mai slabe.

3.3.6 Transformata wavelet versus transformata Fourier

Reprezentarea timp-frecvență de tipul transformare wavelet continuă oferă informații care rămân mascate prin alte reprezentări, cum ar fi de exemplu transformata Fourier, funcțiile wavelet fiind localizate și în timp nu doar în frecvență. Semnalele periodice nu impun dificultăți de analiză, descompunerea spectrală realizată cu ajutorul transformatei Fourier relevând suficiente informații iar operațiile dificile în domeniul timp fiind transformate în operații simple în domeniul frecvență. Transformata Fourier oferă informații despre conținutul în domeniul frecvență al unui semnal, dar nu și despre modul în care acest conținut se modifică în timp. Partajarea planului timp-frecvență realizată de descompunerea în serie Fourier este prezentată în figura 3.13.




Figura 3.13. Partajarea planului timp-frecvență de către descompunerea în serie Fourier.

În concluzie, analiza Fourier clasică permite caracterizarea unui semnal fie în domeniul timp, fie în domeniul frecvență. *Transformata Fourier pe Termen Scurt (STFT)* a fost introdusă pentru a depăși limitările transformatei Fourier clasice, segmente ale semnalului considerat fiind delimitate cu ajutorul unei ferestre temporale [42]. Un dezavantaj provine însă din faptul că lungimea ferestrei este fixă, pe parcursul întregii analize putând fi alese fie ferestre înguste, fie ferestre temporale mai largi (fig. 3.14): astfel ferestrele înguste oferă o bună localizare în timp, dar o proastă localizare în frecvență, în timp ce ferestrele largi oferă o localizare bună în frecvență, dar slabă în timp. Rezoluția temporală fixă a ferestrei de analiză impune anumite limitări de utilizare în practică a STFT.




Figura 3.14. Partajarea planului timp-frecvență realizată de STFT cu o localizare temporală (a) sau frecvențială (b) bună.

În cazul semnalelor cvasi-periodice și netaționare, cum sunt și semnalele biomedicale, informația conținută este mai dificil de accesat deoarece este important

și momentul de timp la care are loc un eveniment iar modificările au loc într-un ritm rapid. În consecință, teoria clasică a analizei Fourier a fost extinsă pentru a putea cuprinde mai multe domenii de aplicație și au fost elaborate modalități de reprezentare a semnalului analizat atât în domeniul timp cât și în domeniul frecvență. Un astfel de exemplu este analiza wavelet. Reprezentările timp-frecvență de tip wavelet pot oferi simultan informații în domeniul timp și în domeniul frecvență despre semnalul analizat. Segmente ale semnalului care necesită moduri diferite de prelucrare pot fi analizate apelând la atomi timp-frecvență cu suporturi diferite de timp (vezi fig. 3.15) prin alegerea corespunzătoare a funcției MW [43]. În concluzie, proprietățile specifice ale transformatei wavelet (WT), cum ar fi o bună reprezentare timp-frecvență și o implementare rapidă a algoritmului de calcul, recomandă utilizarea analizei wavelet în cazul semnalelor biomedicale de tipul semnalelor EKG sau MKG.




Figura 3.15. Partajarea planului timp-frecvență realizată de Transformata Wavelet Continuă.

4. PRELUCRAREA SEMNALULUI EKG

4.1. Reducerea deviației liniei de bază a semnalului EKG

În practică întâlnim arareori un EKG neperturbat, fie datorită interferențelor electromagnetice, fie din motive biologice: mișcări ale pacientului, respirație; sau din motive de achiziție a semnalului electric: imperfecțiuni ale amplificatorului de intrare (zgomot propriu), precizie limitată a convertorului analog numeric; fie datorită unui contact necorespunzător dintre electrod și corpul uman. Ca urmare a variațiilor de temperatură, umiditate sau a activității musculare, impedanța zonei de piele în contact cu electrodul se modifică în timp. Aceste fenomene pot induce distorsiuni ale semnalului EKG.

În figura 4.1 este prezentată forma de undă a unui semnal EKG real. Se constată diferențe mari față de forma de undă ideală a semnalului EKG reprezentată în capitolul anterior.

Teoria prelucrării semnalelor are ca scop identificarea cauzelor care duc la apariția distorsiunilor și elaborarea de tehnici de înlăturare a lor, în sprijinul medicului cardiolog.




Fig.4.1. EKG prezentând o deviație a liniei de bază și alte distorsiuni.

Cercetările actuale sunt orientate în special asupra problemelor curente ale achiziției semnalului EKG. S-au efectuat studii asupra metodelor de reducere a deviației liniei de bază a electrocardiograamei [44 - 51] sau asupra tehnicilor de eliminare a zgomotului de achiziție a EKG - ului [52 - 54] dar încă nu s-a ajuns la un consens referitor la metoda optimă de prelucrare a acestor semnale biomedicale.

Metode liniare de reducere a deviației liniei de bază întâlnite în literatură utilizează de exemplu [46] un filtru adaptiv format din două blocuri: primul bloc este

un filtru adaptiv oprește bandă destinat suprimării componentei continue, iar cel de al doilea bloc este un filtru adaptiv de tip trece bandă a cărui frecvență centrală urmărește frecvența complexului QRS. La ieșirea sa se obține un semnal care păstrează componentele EKG-ului corelate cu complexul QRS.

În [44] este prezentată o metodă de corecție a deviației liniei de bază utilizând funcții spline cubice, care necesită cunoașterea coordonatelor liniei de bază, fapt care îngreunează aplicarea metodei de corecție.

Alte metode [45] utilizează tehnici diferite de prelucrare de semnale, rezultatul final fiind obținut mai ușor, însă prezentând deficiențe. Metoda propusă în [45] utilizează un filtru de tip FIR cu fază liniară și un număr redus de ponderi, dezavantajul acestei metode constând în faptul că valoarea frecvenței de tăiere a filtrului trece-sus este constantă în timp ce valoarea frecvenței maxime din spectrul liniei de bază diferă de la un semnal EKG la altul, motiv pentru care filtrul trece sus ar trebui să fie adaptiv.

În literatură au fost propuse și metode de corecție a liniei de bază bazate pe sisteme neliniare [47], unde se utilizează filtre morfologice. Algoritmul constă într-o etapă de procesare morfologică, operatorii morfologici având rolul de a estima deviația liniei de bază, care va fi eliminată din semnalul de intrare. Rezultatele experimentale prezentate în [47] demonstrează că metoda propusă este mai puțin sensibilă la mărirea elementului structurant decât alte metode bazate pe filtre morfologice. De regulă, asemenea metode pot fi aplicate în cazuri particulare, având condiții inițiale cunoscute. În prezenta teză de doctorat se urmărește dezvoltarea unor metode mai generale de corecție a liniei de bază, cu un domeniu mai extins de aplicare și care necesită interacțiune minimă cu utilizatorul.

Metoda prezentată în continuare aparține clasei de metode timp-frecvență care utilizează analiza wavelet. În [48] este propusă o metodă bazată pe DWT, principalul motiv pentru utilizarea acestei transformate fiind dat de proprietatea de codare în subbenzi, oferind posibilitatea detecției și eliminării deviației liniei de bază a semnalului EKG din subbenzile de joasă frecvență. DWT este aplicată semnalului EKG analizat, obținându-se cele două secvențe de coeficienți wavelet a_1 și d_1 . Presupunându-se că deviația liniei de bază afectează doar coeficienții de joasă frecvență a_1 [48], se filtrează acești coeficienți cu un filtru de mediere: secvența de coeficienți este inițial segmentată pe bătați, pasul următor constând în identificarea segmentul PQ al fiecărei bătați. Nivelul liniei de bază a fiecărei bătați este estimat prin medierea eșantioanelor corespunzătoare segmentului PQ, astfel încât se obține noua linie de bază calculând diferența între valorile corespunzătoare ale semnalului EKG și nivelul estimat al liniei de bază. Aplicând transformata inversă IDWT asupra cuplului format din noii coeficienți de aproximare a_{1n} și coeficienții de detaliu d_1 , se obține o linie de bază corectată. Mecanismul DWT de codare a semnalului în subbenzi diferite nu este însă foarte flexibil.

Un mecanism mai flexibil de codare este oferit de transformata de tip Wavelet Packets WPT, un astfel de algoritm fiind propus în [49]. Este vorba despre un algoritm de căutare bazat pe analiza wavelet care utilizează energia semnalului EKG de la diferite scări pentru a izola deviația liniei de bază. Se calculează coeficienții wavelet și cu ajutorul valorilor lor se calculează la fiecare scară energia [49]. Comparând aceste energii, este aleasă cea ramură a structurii arborescente de descompunere în pachete de funcții wavelet careia îi corespunde energia cea mai mare.

Discretizarea Transformatei wavelet continue CWT dă naștere la DWT. O generalizare a reprezentării timp-frecvență CWT a dus la obținerea transformatei

Multi-adaptive Bionic Wavelet Transform MABWT, prezentată în [50]. Aceasta a fost aplicată semnalelor EKG pentru a estima linia de bază a semnalului analizat. După cum s-a explicat deja expresia CWT este:

$$CWT_x(\tau, a) = \sqrt{|a^{-1}|} \int_{-\infty}^{\infty} x(t) \cdot \psi^*\left(\frac{t-\tau}{a}\right) dt \quad (4.1)$$

unde a reprezintă un parametru de scară. Prin substituția $\omega = a^{-1}$, CWT devine o reprezentare timp-frecvență. Transformata Wavelet Bionică este definită după cum urmează [50]:

$$BWT_x(\tau, a) = \frac{1}{T\sqrt{a}} \int_{-\infty}^{\infty} x(t) \cdot \tilde{\psi}^*\left(\frac{t-\tau}{aT}\right) \cdot e^{-j\omega_0 \frac{t-\tau}{a}} dt \quad (4.2)$$

unde $\tilde{\psi}$ reprezintă anvelopa funcției wavelet mamă și ω_0 frecvența sa centrală:

$$\psi(t) = \tilde{\psi}(t) \cdot e^{j\omega_0 t} \quad (4.3)$$

O altă clasă de metode destinate reducerii deviației liniei de bază utilizează filtre Kalman KF, precum cel propus în [51]. Metoda se bazează pe un algoritm iterativ, asumându-se caracterizarea semnalului EKG printr-un model autoregresiv. Deviația liniei de bază este estimată printr-o aproximare polinomială, independentă de caracteristicile semnalului, acest model fiind integrat cu KF și apoi se calculează variabilele de stare.

În continuare se propune o metodă originală de eliminare a deviației liniei de bază a electrocardiografei. Combinând diferite tehnici de prelucrare a semnalelor, se dorește creșterea posibilității de a pune un diagnostic medical corect. De exemplu, linia de bază a EKG – ului poate fi influențată de respirația, transpirația sau mișcările pacientului, de interferențe electromiografice (EMG) sau cauzate de rețeaua de alimentare cu energie electrică producându-se deviații care îngreunează procesul de diagnosticare sau chiar maschează caracteristici importante ale unei afecțiuni cardiace. Prin procedee bazate pe analiza wavelet, această deviație poate fi corectată, EKG – ul devenind mai ușor de interpretat și crescând astfel posibilitatea unei diagnosticări corecte.

Reducerea deviației liniei de bază a EKG – ului este o etapă importantă de prediagnosticare, mai ales în cazul în care se dorește implementarea unei automatizări a sistemului de diagnosticare a afecțiunilor cardiace. Tendința generală (long term tendency) a EKG, cum putem numi cu alte cuvinte linia de bază a EKG – ului folosind un limbaj specific pentru analiza seriilor temporale, poate fi estimată prin MRA [55].

Semnalul original este reprezentat la rezoluția maximă, în timp ce semnalul prelucrat reprezintă o variantă a semnalului original cu o rezoluție mai slabă. Procedura studiată cu ajutorul mediului de programare *Matlab* cuprinde doi pași: inițial se estimează deviația liniei de bază, utilizând proceduri echivalente cu filtrarea trece – jos, iar ulterior se elimină această deviație din electrocardiograma originală (fig. 4.2).

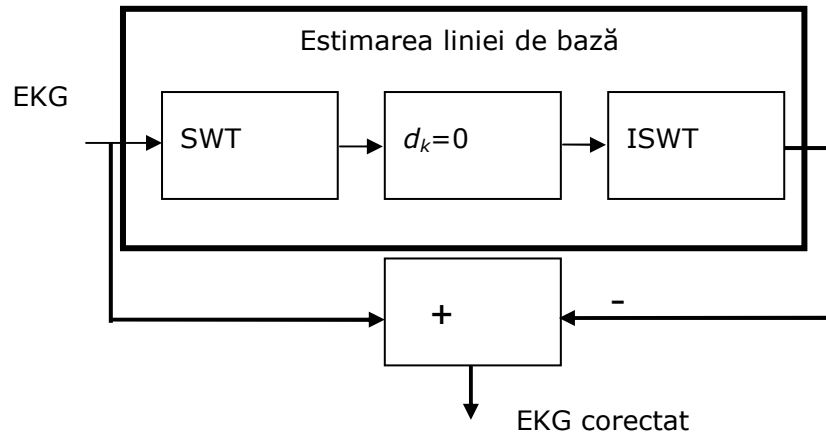


Fig. 4.2 Procedura de eliminare a deviației liniei de bază.

Metoda propusă se bazează pe utilizarea transformatei wavelet staționare (SWT). [56]. Procedul utilizează diverse filtre trece – jos (ale căror răspunsuri la impuls sunt notate cu h_k) precum și diverse filtre trece – sus (ale căror răspunsuri la impuls sunt notate cu g_k) (fig. 4.3).




Fig. 4.3. Schema sistemului care calculează SWT

Răspunsurile la impuls ale filtrelor se construiesc prin interpolare începând cu h_1 și g_1 și continuând până la nivelul K (4.4):

$$f_{k+1}[n] = \begin{cases} f_k\left[\frac{n}{2}\right], & n:2 \\ 0, & \text{dacă nu} \end{cases}$$

unde K reprezintă numărul de niveluri de descompunere al SWT. Răspunsul la impuls echivalent ramurii de sus este:

$$h_e = h_1 * h_2 * \dots * h_K, \quad (4.5)$$

iar răspunsul în frecvență echivalent este:

$$H_e = H_1 \cdot H_2 \cdot \dots \cdot H_K. \quad (4.6)$$

La fiecare nivel de descompunere rezultă o serie de coeficienți. La ieșirile filtrelor trece – jos de pe ramura de sus rezultă coeficienți de aproximare (prezenți în fig. 4.4 pentru un semnal de tip EKG), iar la ieșirile filtrelor trece – sus de pe ramura de jos rezultă coeficienți de detaliu (prezenți în fig. 4.5, pentru același semnal). Semnalul EKG utilizat a fost preluat din baza de date de la MIT [57].

Analizând fig. 4.4 se constată că ultimul semnal reprezintă tendința generală a seriei temporale constituită de primul semnal. De fapt, în fig. 4.4 se prezintă un exemplu de MRA.

Primul semnal are cea mai mare rezoluție temporală (este reprezentat la scara cea mai fină). Cel de al doilea semnal are o rezoluție temporală de două ori mai mică decât primul semnal (este reprezentat la o scară de două ori mai mare). Ultimul semnal are cea mai mică rezoluție temporală, fiind reprezentat la scara cea mai brută. El conține cele mai puține detalii ale seriei temporale inițiale, motiv pentru care poate fi asociat cu tendința generală a acestuia.

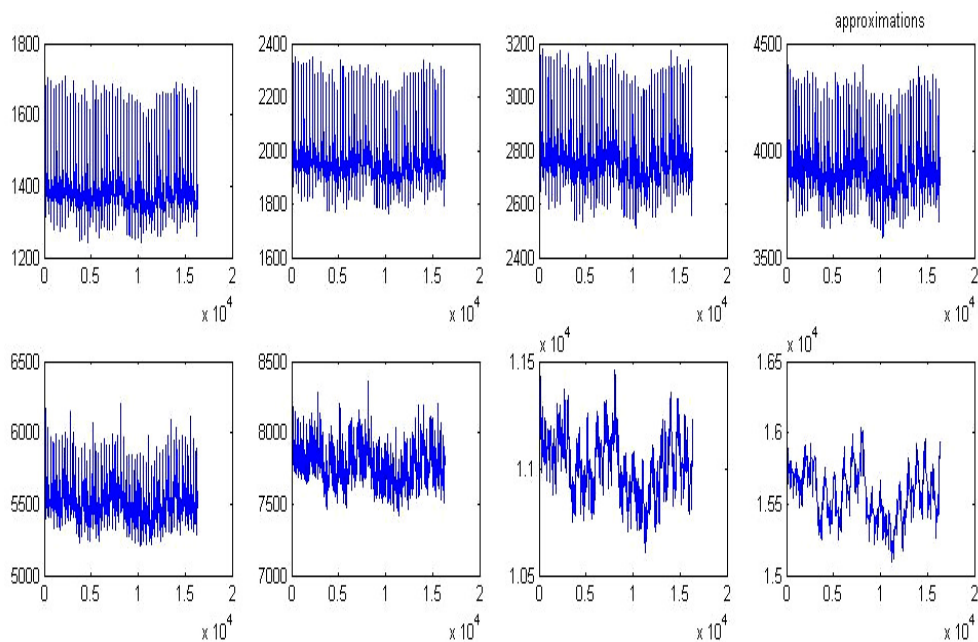


Fig. 4.4. Extragerea coeficienților de aproximare ai semnalului EKG (în ordine crescătoare a nivelului de descompunere de la stânga la dreapta și de sus în jos).

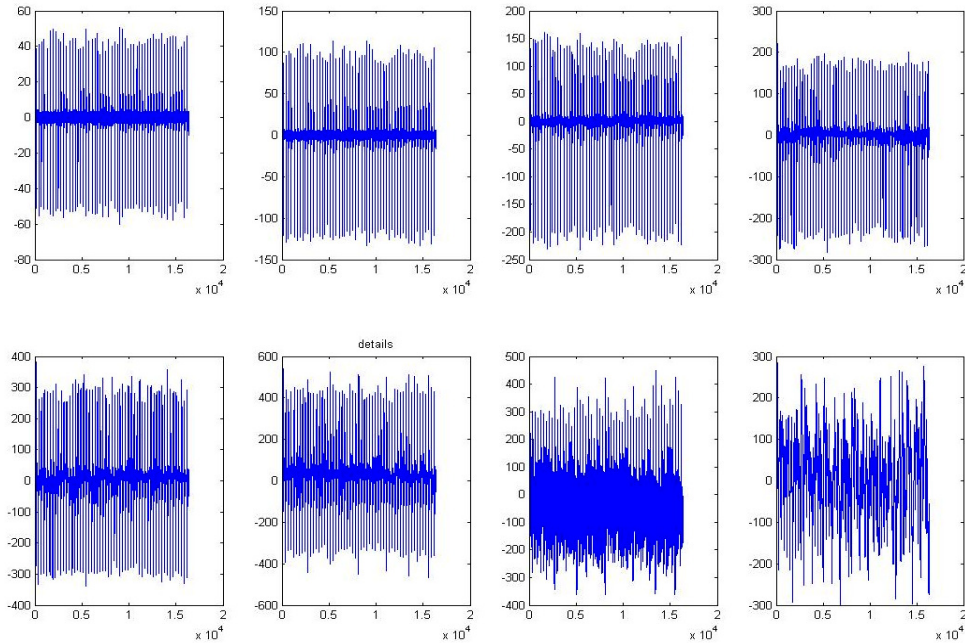


Fig. 4.5. Extragerea coeficienților de detaliu ai semnalului EKG (în ordine crescătoare a nivelului de descompunere de la stânga la dreapta și de sus în jos).

Estimarea liniei de bază a EKG – ului este echivalentă cu o filtrare trece – jos. Se calculează transformata wavelet staționară a EKG – ului, utilizând K niveluri de descompunere. La fiecare nivel de descompunere va rezulta o pereche de secvențe de coeficienți. Coeficienții de aproximare vor fi păstrați în timp ce coeficienții de detaliu vor fi egalați cu zero (eliminați). Apoi se trece înapoi din domeniul wavelet în domeniul timp calculând transformata wavelet staționară inversă (ISWT). În acest mod, se obține o estimare a tendinței generale a liniei de bază. Această estimare va fi scăzută din EKG – ul original, obținându-se un EKG corectat.

Alegerea corectă a caracteristicilor semnificative ale SWT, precum funcția wavelet mamă utilizată la calculul SWT sau numărul K de niveluri de descompunere, asigură performanța metodei propuse. Se recomandă funcții wavelet mamă cu proprietăți timp-frecvență bune, precum funcția wavelet mamă Daubechies 2 [58]. Răspunsul la impuls al primului filtru trece-jos de pe ramura de sus din Fig. 4.3 corespunzător acestei funcții wavelet mamă este:

$$h_1 = \left[\frac{1 + \sqrt{3}}{8} \quad \frac{3 + \sqrt{3}}{8} \quad \frac{3 - \sqrt{3}}{8} \quad \frac{1 - \sqrt{3}}{8} \right]. \quad (4.7)$$

Eliminând coeficienții de detaliu, calculați cu ajutorul algoritmului bazat pe bancul de filtre prezentat mai sus, putem echivala sistemul obținut cu un filtru trece-jos cu o bandă de trecere îngustă. În acest mod a fost creată o metodă nouă de proiectare a unui filtru trece-jos, bazată pe produsul unui răspuns în frecvență prototip cu versiuni scalate ale aceleiași funcții:

$$H_e(\Omega) = \prod_{k=1}^K H_1(2^k \Omega) \quad (4.8)$$

Funcția $H_1(\Omega)$ este o funcție periodică cu perioada 2π (reprezentând o transformată Fourier în timp discret), funcția $H_1(2\Omega)$ este o funcție periodică cu perioada π , funcția $H_1(4\Omega)$ este o funcție periodică cu perioada $\pi/2$, ș.a.m.d. În cazul în care frecvența de tăiere a filtrului cu răspunsul în frecvență $H_1(\Omega)$ este Ω_t atunci frecvența de tăiere a filtrului cu răspunsul în frecvență $H_1(2\Omega)$ este $\Omega_t/2$, etc. Astfel, frecvența de tăiere a filtrului cu răspunsul în frecvență $H_e(\Omega)$ este mai mică decât frecvența de tăiere a filtrului cu răspunsul în frecvență $H_1(2^K \Omega)$ (care este egală cu $\Omega_t/2^K$).

În acest mod, prin metoda propusă se pot elabora filtre foarte selective. Răspunsul la impuls al filtrului echivalent este prezentat în Fig. 4.6a. Acest răspuns conține 766 de coeficienți nenuli și are o formă de undă nesimetrică. De aceea, acesta nu este un filtru cu fază liniară. Amplitudinea răspunsului în frecvență al filtrului echivalent este reprezentată în fig. 4.6b. Se remarcă faptul că acesta este un filtru trece-jos cu bandă îngustă, având o frecvență joasă de tăiere. Utilizând și celelalte funcții wavelet mamă din familia Daubechies, se pot obține filtre trece-jos similare, dar acele filtre vor avea o localizare timp-frecvență mai slabă.




Fig. 4.6a. Răspunsul la impuls al filtrului trece-jos echivalent




Fig. 4.6b. Amplitudinea normalizată a răspunsului în frecvență al filtrului trece-jos echivalent.

Frecvența de eșantionare a EKG – ului, notată în continuare cu f_s , depinde de aparatura utilizată, în cazul semnalului considerat mai sus fiind vorba despre baza de date de la MIT, valoarea frecvenței de eșantionare este de 360 Hz. În ceea ce privește frecvența de tăiere a filtrului trece-jos echivalent, notată în continuare cu f_T , aceasta ar trebui să fie mai mică sau egală cu inversul perioadei fundamentale a EKG – ului, notată în continuare cu T , pentru ca folosirea acestui filtru să nu afecteze componentele spectrale utile medicului în scopul diagnosticării, din structura semnalului achiziționat (care poate fi privit ca și suma dintre o componentă utilă și o perturbație – deviația liniei de bază) se impune condiția:

$$f_T \leq \frac{1}{T}. \quad (4.9)$$

Perioada fundamentalei semnalului EKG poate fi apreciată pe baza măsurării pulsului pacientului. În continuare se va considera pentru simplitate că valoarea perioadei fundamentale a semnalului EKG este de 1 s. Scara temporală de reprezentare la ultimul nivel de descompunere (după K filtrări trece-jos) are valoarea $2^K/f_s$. Aceasta trebuie să aibă o valoare mai mare sau egală cu perioada fundamentalei semnalului EKG, pentru eliminarea completă a componentei utile a semnalului EKG achiziționat din estimata liniei de bază. De aceea, valoarea numărului de niveluri de descompunere al SWT, K , trebuie să satisfacă relația de mai jos:

$$2^K / f_s \geq 1. \quad (4.10)$$

O valoare prea mare a lui K produce atenuări ale formei de undă a deviației liniei făcând imposibilă eliminarea completă a acestei deviații, în timp ce o valoare prea mică a lui K produce distorsiuni ale componentelor utile ale EKG – ului rămase după aplicarea procedurii de corecție a liniei de bază.

Astfel, ținând seama de valoarea frecvenței de eșantionare de 360 Hz, amintită mai sus, numărul nivelurilor de descompunere, K , a fost ales în conformitate cu relația de mai jos:

$$2^K / f_s \geq 1 \Rightarrow K \geq 8 \quad (4.11)$$

Unul dintre avantajele utilizării SWT asupra utilizării DWT constă în invarianța la translație a SWT, sistemul din Fig. 4.3, fiind alcătuit din subsisteme invariante la translație (filtrele h și g sunt invariante la translație). Această proprietate de invarianță este foarte importantă pentru metoda curentă, deoarece estimarea liniei de bază va fi scăzută din EKG-ul original. Un dezavantaj al utilizării SWT ar putea fi numărul crescut de calcule necesar pentru implementarea acestei transformări, lungimea secvenței obținute ca rezultat al SWT fiind mai mare decât lungimea secvenței inițiale (a cărei SWT a fost calculată). Cu toate acestea, SWT oferă un mijloc flexibil de analiză a semnalelor biomedicale.

În continuare se prezintă câteva rezultate de simulare a metodei de corecție a deviațiilor liniei de bază propusă. Simularea a fost realizată făcând apel la mediul de programare *Matlab* și utilizând baza de date *Arrhythmia* de la MIT [57]. În figurile care urmează, estimata liniei de bază a fost reprezentată cu roșu (fig 4.7a.) și se poate remarca că această estimare urmărește îndeaproape fluctuațiile neperiodice ale liniei de bază a EKG – ului.




Fig. 4.7 a) EKG prezentând o deviație a liniei bază

b) EKG corectat.

Un prim rezultat este prezentat în figura 4.7 b.) În urma aplicării metodei bazate pe analiza wavelet, linia de bază (reprezentată cu verde în figurile următoare) este apropiată de valoarea 0. Deci, deviațiile liniei de bază au fost practic eliminate în urma aplicării metodei de corecție propusă. În consecință, EKG – ul rezultat va fi mai ușor interpretat, crescând posibilitatea de a pune un diagnostic corect.

O bună apreciere a performanțelor obținute poate fi făcută printr-un zoom asupra unei bătaii din EKG-ul prezentat în fig. 4.7. Fig. 4.8a prezintă prima bătaie a EKG-ului considerat, estimarea liniei de bază fiind reprezentată cu roșu. Rezultatul metodei propuse este reprezentat în fig. 4.8b, linia de bază fiind reprezentată cu verde. Se remarcă dispariția deviațiilor liniei de bază în urma corecției.




Fig 4.8. Prima bătaie a inimii a) înainte (linia de bază este reprezentată cu roșu) și b) după aplicarea metodei de corecție a deviației liniei de bază (linia de bază este reprezentată cu verde)

Primele patru bătăi ale EKG-ului considerat sunt reprezentate în fig. 4.9a iar rezultatul corespunzător în urma corecției liniei de bază în fig. 4.9b. Se remarcă din nou, lipsa deviației de la potențialul de 0 V a noii linii de bază.

Analizând fig. 4.8 și 4.9, se remarcă de asemenea zgomotul care afectează semnalul EKG analizat. Astfel, următoarea etapă a prelucrării semnalului EKG în scopul monitorizării de la distanță este reducerea zgomotului de achiziție.




Fig 4.9. Primele trei bătăi ale inimii a) înainte (linia de bază este reprezentată cu roșu) și b) după aplicarea metodei de corecție a deviației liniei de bază (linia de bază este reprezentată cu verde)

Rezultatul unei alte simulări realizate pentru a testa performanțele metodei de corecție a deviației liniei de bază propuse este prezentat în Fig. 4.10. A fost aleasă o porțiune din semnalul 103 din baza de date MIT-BIH Arrhythmia, care începe la momentul 18'20". Este un caz „dificil” pentru metoda propusă, înregistrarea prezentând o deviație pronunțată și rapidă a liniei de bază. Semnalul EKG original este reprezentat în fig. 4.10a iar rezultatul corecției liniei de bază în fig. 4.10b. Deoarece deviația este foarte mare și rapidă, rezultatul metodei propuse nu este perfect. Limitările apar datorită frecvenței de tăiere a filtrului trece-jos echivalent, utilizat pentru estimarea liniei de bază care este prea mică, sistemul nereușind să urmărească variațiile rapide ale liniei de bază prezentate. Cu toate acestea, probabilitatea de a pune un diagnostic corect este considerabil îmbunătățită datorită deviației mai mici a liniei de bază obținută după corecție, care facilitează citirea și interpretarea EKG-ului.

De asemenea, metoda permite și transmiterea la distanță a aproximării deviației liniei de bază, pentru cazul în care aceasta prezintă interes în diagnosticare.

Metodele propuse în [44], [45], [46], bazate pe utilizarea a două filtre adaptive în cascadă, corectează mai bine linia de bază în acest caz, dar distorsiunile componentelor utile ale semnalului EKG par să fie mai mici pentru metoda propusă în această teză.





Fig. 4.10a. Înregistrarea originală (albastru) și estimata liniei de bază (roșu).



b. Rezultatul obținut în urma aplicării metodei de corecție a liniei de bază.

Fig 4.10. Rezultatele simulării obținute pentru EKG-ul 103 a cărui înregistrare începe la momentul 18'20"

Performanța algoritmului de reducere a deviației liniei de bază a fost testată și asupra altor semnale EKG provenite din baza de date de la MIT-BIH Arrhythmia. În fig. 4.11 este prezentat un extras din semnalul EKG denumit 215, simularea fiind realizată utilizând funcția wavelet mamă Daubechies5 (Db5) aplicată pe 8 niveluri de descompunere, linia de bază fiind reprezentată cu roșu înainte de corecție respectiv cu verde după aplicarea algoritmului.




Fig. 4.11a. Semnalul EKG 215 original.




Fig. 4.11b. Semnalul EKG 215 corectat.

Rezultatele pot fi apreciate mai bine realizând un zoom asupra a câtorva bătăi. În Fig. 4.12 sunt prezentate cinci bătăi ale semnalului 215. Remarcăm că noua linie de bază este apropiată de potențialul de 0 V la orice moment de timp.




Fig. 4.12a. Cinci bătăi ale semnalului EKG având linia de bază estimată cu roșu.




Fig. 4.12b. Semnalul după aplicarea metodei de corecție wavelet propusă.

S-a remarcat faptul că performanța metodei poate fi îmbunătățită prin alegerea corectă a principalelor caracteristici ale SWT. Numărul de niveluri de descompunere fiind ales prin formula prezentată anterior, prin simulări se pot trage concluzii privind alegerea funcției wavelet mamă. În Fig. 4.13 este reprezentat semnalul EKG 103, la care a fost remarcată anterior o deviație accentuată a liniei de bază, iar în figura următoare sunt prezentate rezultatele obținute utilizând funcția

wavelet mamă Db5. Mijlocul propus pentru validarea metodei este unul vizual, în concordanță cu inspecția vizuală, pe baza căruia medicul pune un diagnostic.




Fig.4.13 Semnalul EKG 103, linia de bază fiind marcată cu roșu.




Fig.4.14 Semnalul EKG 103 după aplicarea algoritmului de corecție utilizând funcția wavelet mamă Db5, linia de bază fiind marcată cu verde.




Fig. 4.15 Zoom asupra zonei cu deviație accentuată a semnalului EKG 103, linia de bază fiind marcată cu roșu.




Fig. 4.16 Zoom asupra zonei cu deviație accentuată a semnalul EKG 103 după aplicarea algoritmului de corecție utilizând funcția wavelet mamă Db5.

Influența alegerii corecte a numărului de niveluri de descompunere SWT este ilustrată în graficul de mai jos, în care s-a utilizat funcția wavelet mamă Db5 (cu care s-au obținut rezultate bune anterior) pe 10 niveluri de descompunere. Se remarcă astfel faptul că deviația nu este complet înlăturată, dacă numărul de niveluri de descompunere nu este ales corect.




Fig.4.17 Semnalul EKG 103 după aplicare algoritmului de corecție utilizând funcția wavelet mamă Db5 pe 10 niveluri de descompunere.

Metoda de corecție a liniei de bază propusă în acest paragraf face parte din clasa de metode neliniare de prelucrare a semnalului, estimarea liniei de bază fiind realizată prin eliminarea coeficienților wavelet de detaliu. Metoda propusă estimează linia de bază a EKG-ului și calculează diferența dintre EKG și estimată. Estimarea realizată utilizează SWT, calculată cu ajutorul unei funcții wavelet mamă aleasă pentru 8 niveluri de descompunere. Acest număr a fost selectat în concordanță cu frecvența de eșantionare utilizată la achiziționarea semnalelor EKG considerate. Astfel, metoda ia în considerare un parametru al semnalului care trebuie prelucrat, din acest motiv putând fi considerată o metodă adaptivă. În urma aplicării SWT rezultă o serie de coeficienți wavelet: secvența $a_8[n]$ reprezintă coeficienții de aproximare, în timp ce secvențele $d_1[n]$, $d_2[n]$, ..., $d_8[n]$ reprezintă coeficienții de detaliu. În urma eliminării coeficienților de detaliu rezultă o nouă secvență de coeficienți reprezentând SWT a estimatei liniei de bază. Deoarece operația de

estimare descrisă este o operație neliniară (datorită eliminării coeficienților de detaliu), metoda de corecție a deviației liniei de bază propusă poate fi considerată neliniară. Metoda poate fi de asemenea considerată o metodă timp-frecvență, deoarece prelucrarea este realizată în domeniul wavelet. Următoarea etapă constă în calculul transformatei inverse, ISWT, pentru a obține estimata liniei de bază. În final se obține EKG-ul corectat, scăzând din EKG-ul original estimata deviației liniei de bază. Metoda propusă este echivalentă cu o filtrare trece-jos a EKG-ului, utilizând un filtru special (filtrul echivalent fiind descris în fig. 4.6).

SWT prezintă două caracteristici: funcția wavelet mamă și numărul de niveluri de descompunere. În exemplificările descrise anterior s-a utilizat una dintre funcțiile wavelet mamă cu localizare timp-frecvență foarte bună și anume funcția wavelet mamă Daubechies 5 (Db5). Etapa cea mai dificilă în implementarea metodei de corecție propuse se referă la selecția numărului potrivit de niveluri de descompunere pentru calculul SWT, acest lucru fiind echivalent cu selecția frecvenței de tăiere a filtrului trece-jos echivalent. Astfel, frecvența trebuie să fie suficient de mică pentru a proteja componentele utile ale EKG-ului împotriva distorsiunilor, dar și suficient de mare pentru a permite estimarea corectă a componentelor de înaltă frecvență ale deviației liniei de bază.

Metoda propusă este eficientă în cazul semnalelor EKG cu deviații moderate ale liniei de bază (a se vedea de exemplu, fig. 4.9), dar pentru semnale EKG care prezintă deviații mari și rapide ale liniei de bază (a se vedea de exemplu, fig. 4.10), metoda prezintă anumite limitări dacă nu se alege corespunzător funcția wavelet mamă utilizată la descompunerea SWT. Acest lucru intervine atunci când algoritmul nu poate urmări variațiile rapide ale liniei de bază. Evaluarea vizuală a performanțelor metodei propusă în acest paragraf este calitativă, dar și diagnosticarea pe baza EKG-ului se face de regulă tot pe baza unui examen vizual. Principalele avantaje ale metodei constă în posibilitatea de a implementa algoritmul într-un mediu nesupervizat, singurul parametru a cărui valoare poate suferi modificări de la o bază de date la alta, fiind parametrul K , dependent de frecvența de eșantionare utilizată la achiziția electrocardiogramelor. Valoarea frecvenței de eșantionare depinde de construcția aparatului EKG utilizat la achiziție astfel încât, odată ales K , metoda poate fi aplicată tuturor EKG-urilor aparținând aceleași baze de date. Din acest motiv, metoda poate fi considerată drept o metodă automată, implementabilă chiar în timp real. Modul de abordare și de evaluare a performanțelor metodei propuse este calitativ, fiind considerat relevant în cazul semnalelor EKG în care diagnosticul este pus pe baza unei inspecții vizuale. Performanțele metodei pot fi comparate cu performanțele altor metode propuse în literatură, deoarece algoritmi sunt aplicați asupra aceleași baze de date MIT-BIH Arrhythmia în majoritatea cazurilor [44 - 50], singura excepție fiind lucrarea [51].

Bazele de date disponibile în mod public au un rol important în evaluarea științifică a unei metode, permițând o comparație directă a rezultatelor obținute. Metoda propusă prezintă rezultate similare cu următoarele metode: metoda bazată pe utilizarea unui filtru FIR trece-jos [45], metoda bazată pe filtre morfologice [47], metoda bazată pe utilizarea WPT [49] și metoda bazată pe utilizarea MABWT [50]. Algoritmul propus este mai robust decât metoda bazată pe utilizarea DWT în estimarea liniei de bază a fiecărei bătăi [48]. Rezultatele prezentate în [51] sunt comparate cu cele prezentate în [44] și concluzia este obținerea unor rezultate mai bune în cazul aplicării filtrului Kalman KF decât în cazul metodei bazate pe funcții spline [44]. Comparativ cu metoda prezentată în acest capitol, efortul computațional este mai mare în cazul KF. În cazul unei monitorizări în timp real, un parametru

important este reprezentat de viteza de prelucrare a semnalului achiziționat. Metoda propusă cere un timp scurt de calcul, fiind mai rapidă decât metodele propuse în [44], [46], [47], [49], [50]. Principalul avantaj al algoritmului bazat pe SWT este faptul că după fixarea parametrilor, metoda propusă nu necesită supervizare. Singurul parametru susceptibil de schimbare de la o bază de date la alta este numărul de niveluri de descompunere K , care depinde de frecvența de eșantionare utilizată la achiziția semnalului EKG. Acest parametru depinzând însă de aparatul de achiziție, poate fi fixat în cazul unei baze de date ale cărei elemente sunt prelevate cu aceeași aparatură. Compararea performanțelor metodei propuse cu metodele întâlnite în literatură [44 - 51] nu este foarte ușor de realizat din cauza rezoluției slabe a graficelor, cum este cazul în lucrarea [44]. Metoda bazată pe filtre adaptive realizează o corecție bună a liniei de bază deși efortul computațional este mai ridicat (datorită aplicării consecutive a algoritmului LMS), însă este posibil să fie introduse distorsiuni ale componentelor utile ale semnalului EKG analizat. O comparație mai bună a metodei propuse poate fi realizată cu metoda prezentată în [45], unde este propus un filtru trece-jos pentru compensația deviației liniei de bază. Filtrul echivalent al algoritmului propus, caracterizat în fig. 4.6, prezintă o tranziție mai mare din banda de trecere în banda de oprire decât în cazul filtrului propus în [45] asigurând o precizie mai bună a metodei concomitent însă cu un efort computațional mai mare datorat unui număr mai mare de coeficienți ai filtrului. La fel ca și în cazul metodei propuse în [47], algoritmul din acest studiu aparține clasei de metode neliniare de prelucrare de semnale. Comparând rezultatele prezentate în fig. 4.7 cu cele prezentate în [47] se remarcă performanțe comparabile, avantajul metodei propuse față de metoda din [47] constând în efortul computațional necesar mai redus și în consecință a unei viteze de prelucrare mai mari. Comparând rezultatele din fig. 4.7 cu cele din lucrarea [48], se remarcă de asemenea rezultate similare pentru zonele distorsionate moderat ale semnalului EKG. Avantajul metodei propuse constă în simplitatea mai mare a algoritmului. Necesitatea de localizare a segmentelor PQ la metoda propusă în [48] poate ridica probleme mai ales în cazul unor semnale EKG cu un raport semnal-zgomot slab. Astfel, se poate afirma că metoda prezentată în acest capitol este mai robustă. Analizând modul de descompunere wavelet (prezentată în fig. 4.3), se poate remarca că doar coeficienții de aproximare sunt reiterati. În cazul WPT, ieșirea filtrelor trece-sus poate fi de asemenea reiterată. Comparând rezultatele din fig. 4.7 cu cele din [49] se remarcă performanțele similare ale metodelor. În [50] este propusă MABWT ca mijloc de prelucrare a semnalului EKG. Comparând rezultatele din fig. 4.7 cu cele din [50] se remarcă performanțele similare ale metodelor, avantajul metodei propuse constând în efortul computațional mai redus. În cazul filtrului Kalman [51], se pot remarca distorsiuni ale segmentului ST în condiții cu deviație pronunțată a liniei de bază [51]. Distorsiunile sunt minime în cazul algoritmului propus datorită alegerii corespunzătoare a parametrilor: funcția wavelet mamă (alegând funcția wavelet mamă Db5 se obțin rezultate mai bune pentru porțiunile cu deviație pronunțată a liniei de bază decât alegând funcția wavelet mamă Db2) și numărul de niveluri de descompunere.

Rezumat 4.1

Scopul studiului prezentat în acest paragraf este de a obține o metodă originală de corecție a deviației liniei de bază a semnalului EKG utilizând avantajele

oferite de analiza wavelet. Inspirată de procedurile utilizate pentru regresia seriilor de timp din domeniul wavelet, metoda estimează deviația liniei de bază și efectuează corecția calculând diferența dintre semnalul EKG și această estimare, realizată cu ajutorul transformatei wavelet staționare SWT. Principalii parametri ai metodei sunt: funcția wavelet mamă și numărul de niveluri de descompunere.

Numărul optim de iterații este ales funcție de frecvența de eșantionare utilizată la achiziția semnalului EKG, astfel metoda ia în considerare un parametru al semnalului analizat, în cazul bazei de date de la MIT-BIH, fiind ales un număr de 8 niveluri de descompunere. Secvența $a_8[n]$ reprezintă estimata liniei de bază, în timp ce secvențele de coeficienți de detaliu $d_1[n], d_2[n], \dots, d_8[n]$ sunt anulate. Astfel se obține o nouă secvență de coeficienți wavelet, pornind de la care, prin aplicarea ISWT, se obține estimarea liniei de bază. Operația descrisă fiind neliniară, metoda propusă poate fi considerată de asemenea drept o metodă neliniară timp-frecvență. În final, este calculată diferența dintre semnalul EKG achiziționat și estimarea liniei de bază realizată și se obține un semnal EKG corectat.

Metoda de estimare propusă este echivalentă unei filtrări trece-jos a semnalului EKG utilizând un filtru special, propunându-se și o metodă specială de construcție a unui asemenea filtru prin produsul unui răspuns în frecvență prototip cu versiuni scalate ale aceleiași funcții.

4.2. Reducerea zgomotului de achiziție al semnalului EKG

Etapa următoare în domeniul prelucrării semnalelor biologice constă în reducerea zgomotului de achiziție ale semnalelor, deoarece un semnal lipsit de perturbații este arareori întâlnit în practică. Așa cum s-a amintit deja, un semnal EKG este supus la mai multe tipuri de perturbații în timpul procesului de înregistrare, dintre care trebuie menționate interferențele cauzate de linia de alimentare cu energie electrică, zgomotul electromiografic cauzat de activitatea musculară, distorsiunile de mișcare și deviația liniei de bază. Toate aceste fenomene sunt nedorite în cazul unei monitorizări de la distanță, îngreunând munca de interpretare a EKG-ului.

Termenul de reducere a zgomotului de achiziție (*denoising*) a fost introdus de David Donoho [59] în legătură cu transformata wavelet discretă. Având în vedere faptul că semnalele EKG sunt nestaționare, pentru prelucrarea lor sunt recomandate metodele de reducere a zgomotului de achiziție bazate pe transformata wavelet. Arhitectura unui sistem de denoising are la bază abilitatea transformatei wavelet de a concentra energia utilă a semnalului într-un număr redus de coeficienți wavelet. Algoritmii introdus de Donoho utilizează DWT și cuprind trei pași:

- DWT este aplicată semnalului cu zgomot de achiziție;
- Coeficienții wavelet sunt filtrați (procedură denumită în limba engleză uneori și *thresholding* sau *shrinkage*). De regulă, unii dintre acești coeficienți pot fi eliminați (considerându-se de valoare 0) deoarece nu conțin informații utile;
- Coeficienții rămași sunt reconvertiți în domeniul timp pentru a estima semnalul util.

De regulă, rezultatele obținute sunt dependente de funcția wavelet mamă utilizată și de procedura de filtrare aleasă. Unele tehnici moderne de reducere a

zgomotului bazate pe analiza wavelet implementează o filtrare Maximum-A-Posteriori (MAP) în etapa a doua a algoritmului prezentat, luând în considerare proprietățile statistice ale coeficienților wavelet. De exemplu, o astfel de metodă, utilizată pentru prelucrarea semnalului EKG în condiții de zgomot, adaptează filtrul Wiener [60], [61] la cazul particular al semnalelor EKG, proprietățile statistice ale coeficienților wavelet fiind estimate cu ajutorul unui semnal pilot. Filtrul Wiener de ordin zero poate fi privit drept un caz particular al unui filtru MAP.

În cadrul perioadei de pregătire prin doctorat s-a elaborat o metodă de denoising a electrocardiogramelor bazată pe utilizarea Transformatei Wavelet Staționare (SWT) și a unui filtru de tip MAP. Filtrul este o variantă îmbunătățită a filtrului Wiener de ordinul zero, care are la bază estimarea statistică a parametrilor coeficienților wavelet.

Cele mai importante caracteristici ale metodei propuse se referă la ipoteze a-priori realiste referitoare la repartițiile statistice ale coeficienților wavelet atât pentru semnalul util cât și pentru zgomot, dar și la o bună estimare a parametrilor acestor repartiții. Astfel, la rezolvarea ecuației filtrului MAP, se ia în considerare dependența interscală între coeficienții wavelet. Contrar filtrului Wiener de ordin zero construit pe baza unei singure funcții de densitate de probabilitate (probability density function - *pdf*), filtrul propus utilizează două funcții *pdf*, modelând diferențiat semnalul util și zgomotul. Cele două funcții *pdf* utilizate la construcția filtrului denumit *bishrink* [62], iau în considerare dependența interscală a coeficienților wavelet și sunt bine adaptate la forma caracteristică a semnalului EKG. În special în domeniul medical în urma reducerii zgomotului de achiziție al semnalului EKG, trebuie să se păstreze informația utilă conținută de undele componente ale EKG-ului.

Uneori se pot introduce distorsiuni prin denoising. Distorsiunile pot fi controlate printr-o selecție corespunzătoare a transformatei wavelet și a caracteristicilor acesteia: funcția wavelet mamă și numărul de niveluri de descompunere, K . Alegerea corespunzătoare a celor două caracteristici asigură performanțele metodei de denoising.

Metoda de denoising prezentată în continuare utilizează funcția wavelet mamă Daubechies2 și opt niveluri de descompunere. Utilizarea unei funcții wavelet mamă cu o bună localizare temporală este recomandată pentru aplicații de filtrare, în scopul prevenirii efectelor cauzate de fenomenul Gibbs (care apare când se folosește o transformată wavelet variantă la translații cum este DWT) și a unei bune redări a zonei din jurul complexului QRS. Însă semnalul EKG conține și regiuni line având un conținut de joasă frecvență, a căror prelucrare necesită o localizare frecvențială bună. Luând în considerare aceste constrângeri, s-a realizat un compromis, alegându-se pentru metoda de denoising propusă funcția wavelet mamă cu cea mai bună localizare timp-frecvență din familia Daubechies.

Numărul de niveluri de descompunere necesare algoritmului wavelet de filtrare a fost ales în concordanță cu frecvența de eșantionare utilizată la achiziția semnalelor EKG, conform procedurii descrise în cap. 4.1, $K \geq 8$.

Metoda de denoising propusă urmărește în special eliminarea zgomotului miografic și a celui produs de contactul electrozilor de achiziție, considerate drept surse de zgomot importante în monitorizarea de lungă durată [63, 64]. Arhitectura sistemului de reducere a zgomotului de achiziție propus este prezentat în fig. 4.18.




Fig. 4.18. Algoritmul propus.

Metoda de reducere a zgomotului de achiziție, bazată pe analiza wavelet pornește de la natura aditivă a zgomotului, caracteristică care se regăsește și la nivelul coeficienților wavelet deoarece SWT este o transformare liniară.

Se diferențiază trei etape de bază ale metodei:

1. Semnalul este convertit în domeniul wavelet: descompunerea semnalului se realizează prin aplicarea unei transformate wavelet asupra datelor de intrare (se utilizează Transformata Wavelet Staționară SWT). Codul Matlab corespunzător este:

$$[swa,swd] = swt(sig,L,'db2'),$$

unde s-au utilizat următoarele notații:

swa: vectorul coeficienților de aproximare,
 swd: vectorul coeficienților de detaliu,
 sig: semnal de intrare,
 L: număr niveluri de descompunere,
 db2: funcția wavelet mamă (Daubechies 2).

2. Elaborarea și utilizarea unui filtru pentru a elimina zgomotele perturbatoare, coeficienții rezultați fiind filtrați (conform blocului denumit *bishrink*, fig.4.18).

3. Reconstrucția semnalului prin aplicarea Transformatei Wavelet Staționare Inverse (ISWT). Codul Matlab corespunzător este:

$$rec=iswt(swa,swdc,'db2');$$

Un exemplu de semnal EKG de intrare este prezentat în fig. 4.19.

Deviația liniei de bază poate fi observată în partea de sus iar zgomotul poate fi observat în partea de jos.

Zgomotul este mai vizibil pentru porțiunile mai line ale EKG-ului, cum sunt cele care corespund undelor P și T.




Fig. 4.19. Semnalul de intrare: a) întregul semnal, b) primele trei bătăi.

SWT a fost preferată la DWT datorită proprietății sale de invarianță la translații (care evită apariția fenomenului Gibbs în zonele de variație rapidă ale semnalului), cu toate că este o transformată redundantă.

Metoda de denoising a semnalului EKG propusă generează două rezultate: estimata EKG-ului lipsit de zgomot și estimata zgomotului, care poate fi obținută calculând diferența dintre semnalul achiziționat și semnalul estimat. Această operație ia în considerare natura aditivă a zgomotului. Astfel, anumite caracteristici ale zgomotului care afectează semnalele EKG pot fi identificate analizând zgomotul eliminat printr-o metodă bună de filtrare.

Filtrul propus în acest paragraf este un filtru de tip Maximum A Posteriori (MAP). În principiu, metoda are la bază o estimare statistică atât a zgomotului (cu pdf- p_n) cât și a compoentei utile a semnalului (cu pdf- p_u). La ieșirea blocului de descompunere SWT, se obțin secvențe de coeficienți wavelet grupate în vectori, după cum urmează:

$$\mathbf{w} = \mathbf{u} + \mathbf{n} \quad (4.12)$$

unde $\mathbf{w} = (w_1, w_2)$; $\mathbf{u} = (u_1, u_2)$ și $\mathbf{n} = (n_1, n_2)$, u_1 și n_1 reprezintă coeficienții utili respectiv coeficienții de zgomot copii, iar u_2 și n_2 reprezintă coeficienții wavelet

părinți (având aceleași coordonate spațiale, dar situați la nivelul următor de descompunere). Astfel, s-a luat în considerare dependența interscală dintre coeficienții wavelet.

Utilizând regula lui Bayes, estimarea coeficienților u_1 poate fi realizată rezolvând ecuația filtrului MAP:

$$\begin{aligned}\hat{\mathbf{u}}(\mathbf{w}) &= \arg \max_{\mathbf{u}} (\log(p_{\mathbf{w}/\mathbf{u}}(\mathbf{w}/\mathbf{u}) \cdot p_{\mathbf{u}}(\mathbf{u}))) = \\ &= \arg \max_{\mathbf{u}} (\log(p_{\mathbf{n}}(\mathbf{w} - \mathbf{u})) + \log(p_{\mathbf{u}}(\mathbf{u})))\end{aligned}\quad (4.13)$$

Filtrul propus a fost construit pornind de la următoarele premize a-priori ale coeficienților utili și coeficienților de zgomot. Pentru funcția pdf p_u s-a considerat o distribuție Gaussiană de două variabile a coeficienților de zgomot cu varianța σ_n^2 :

$$p_{\mathbf{n}}(\mathbf{n}) = \frac{1}{2\pi\sigma_n^2} \cdot e^{-\frac{n_1^2 + n_2^2}{2\sigma_n^2}}. \quad (4.14)$$

Această premiză permite găsirea unei soluții explicite a ecuației (4.13). Se va accepta premiza descrisă în ecuația (4.14) fără verificare, deoarece nu există informații a-priori asupra zgomotului care afectează semnalele EKG. Coeficienții wavelet utili vor fi descriși utilizând o distribuție de tip Laplace de două variabile, care pare adaptată pentru coeficienții wavelet ai semnalului EKG. Această premiză este susținută de lucrări teoretice asupra unor baze de date EKG extinse [65].

Transformata wavelet a semnalului EKG este compusă dintr-un număr redus de coeficienți wavelet de valoare mare, marcând în mod special limitele zonelor de activitate electrică și un număr mare de coeficienți de valoare mică, marcând porțiunile cu evoluție lentă ale semnalului EKG. Distribuția Laplace pare mai indicată în acest caz decât cea Gaussiană (folosită în cazul filtrului Wiener). În consecință funcția pdf a coeficienților wavelet ai componentei utile a semnalului EKG se exprimă cu ecuația:

$$p_{\mathbf{u}}(\mathbf{u}) = \frac{3}{2\pi\sigma^2} \cdot e^{-\frac{\sqrt{3}}{\sigma} \sqrt{u_1^2 + u_2^2}}. \quad (4.15)$$

Substituind (4.14) și (4.15) în (4.13) rezultă [62] următoarea relație intrare-ieșire pentru filtrul bishrink:

$$\hat{u}_1 = \frac{\left(\sqrt{w_1^2 + w_2^2} - \frac{\sqrt{3}\sigma_n^2}{\sigma} \right)_+}{\sqrt{w_1^2 + w_2^2}} w_1 \quad (4.16)$$

unde:

$$X_+ = \begin{cases} X, & \text{dacă } X > 0 \\ 0, & \text{în rest} \end{cases} \quad (4.17)$$

Această soluție poate fi asimilată unei metode de filtrare a coeficienților zgomotoși denumită *soft-thresholding* având o valoare de prag Th optimă. Această valoare apare la numărătorul membrului drept al ecuației (4.16) și poate fi calculată utilizând deviațiile standard estimate ale coeficienților utili și ale coeficienților de zgomot:

$$Th(j,k) = \frac{\sqrt{3}\hat{\sigma}_n^2}{\hat{\sigma}(j,k)}. \quad (4.18)$$

Separarea între coeficienții utili și cei care conțin zgomot se realizează prin compararea modului vectorului \mathbf{w} cu nivelul de prag Th . Valoarea de prag este estimată în mod individual pentru fiecare coeficient $w(j,k)$ aflat pe nivelul j de descompunere și având indicele k în interiorul nivelului. Această prelucrare locală este recomandată deoarece deviația standard a coeficienților utili trebuie estimată local ($\hat{\sigma}$) pentru a putea detecta corect zonele de tranziție accentuată existente în semnal (cum ar fi de exemplu complexul QRS). Acest parametru este estimat separat pentru fiecare coeficient, utilizând o fereastră de analiză (*sliding window*):

$$\hat{\sigma}(j,k) = \sqrt{\left(\frac{\sum_i |w(j,i)|^2}{v} - \sigma_n^2 \right)}, \quad (4.19)$$

$$i = k - \frac{v-1}{2}, \dots, k + \frac{v-1}{2}$$

unde $w(j,i)$ reprezintă coeficienții wavelet ai semnalului achiziționat, parametrul j desemnând nivelul de descompunere, i poziția coeficientului la nivelul de descompunere curent, iar v reprezintă lungimea ferestrei de analiză.

Determinările experimentale au demonstrat că o valoare de $v = 3$ oferă rezultate similare cu cele obținute utilizând lungimi mai mari ale ferestrei de analiză ($v = 11$ sau $v = 21$). În cazul simulărilor prezentate a fost aleasă o valoare $v = 11$.

Varianța coeficienților de zgomot σ_n^2 este estimată separat pentru primul nivel de descompunere $j=1$, utilizând coeficienții wavelet de detaliu $w(1,j)$ corespunzători:

$$\sigma_n^2 = \frac{\text{median}(|w(1,i)|)}{0.6745} \quad (4.20)$$

Semnalele EKG de test au fost selectate dintre semnalele oferite de baza de date MIT-BIH [57]. Eșantioanele acestor semnale sunt cuantizate cu 11 biți/eșantion. Algoritmul propus a fost conceput pentru a filtra semnalele EKG afectate de zgomot real.

Un alt exemplu de astfel de semnal EKG decât cel prezentat în fig. 4.19, este ilustrat în fig. 4.20.




Fig.4.20 Semnalul EKG de intrare. În întregime (sus) și primele patru bătăi (jos).

Rezultatul metodei propuse de reducere a zgomotului de achiziție este prezentat în fig. 4.21a. Efectul metodei de filtrare poate fi apreciat comparând părțile de jos ale figurilor 4.19 și 4.21a. Acest efect poate fi mai bine apreciat vizual suprapunând semnalul de intrare afectat de zgomot cu semnalul filtrat de ieșire. Rezultatul este prezentat în fig. 4.21b. Analizând graficul, remarcăm suprimarea aproape totală a zgomotului fără a distorsiona însă componentele utile ale EKG-ului. Remarcăm însă că deviația liniei de bază nu a fost redusă, motiv pentru care, în paragrafele următoare, vor fi aplicate succesiv ambele metode, așa cum se vede și în fig. 4.22.




Fig. 4.21a. Rezultatul metodei de reducere a zgomotului de achiziție propuse pentru întregul semnal (sus) și pentru patru bătăi (jos)




Fig. 4.21b. Suprapunerea semnalului achiziționat (albastru) și filtrat (galben).




Fig. 4.22. Rezultatul combinat al metodei de filtrare și de reducere a deviației liniei de bază a semnalului EKG.

Rezultatele obținute în urma aplicării metodei de reducere a deviației liniei de bază a semnalului EKG asupra rezultatelor prezentate în fig. 4.21a sunt prezentate în fig. 4.22 și arată eficiența metodei de corecție propusă. Semnalul

original de intrare și cel corectat au fost suprapuse în fig. 4.23, pentru o mai bună vizualizare.




Fig. 4.23. Suprapunerea semnalului EKG original de intrare (albastru) și a semnalului EKG a cărui deviație a liniei de bază a fost corectată (galben).

În fig. 4.24 sunt suprapuse formele de undă din fig. 4.21b și 4.22, pentru a evalua performanța combinării metodelor de denoising și de corecție a deviațiilor liniei de bază propuse. Semnalul EKG reprezentat cu negru nu conține zgomot iar linia sa de bază nu prezintă variații. Astfel, asociind cele două metode, pot fi obținute semnale EKG pe baza cărora medicul să poată pune un diagnostic, pregătite pentru etapa următoare, de segmentare a semnalului, din cadrul unui sistem de diagnosticare automat.




Fig. 4.24. Suprapunerea formei de undă a semnalului EKG original (albastru), filtrat (galben) și cu linie de bază corectată (negru).

Forma de undă a zgomotului înlăturat în ultima efectuării experimentului cu rezultatele din fig. 4.24 este prezentată în fig. 4.25 și a fost obținută calculând diferența dintre formele de undă ale semnalelor EKG de intrare (fig. 4.20) și de ieșire (fig.4.22). Calculând SWT a semnalului din fig. 4.25 și separând coeficienții de detaliu se obține histograma prezentată în fig. 4.26. Aceasta nu este perfect

asemănătoare cu histograma unui zgomot de tip Gaussian, dar este posibil ca zgomotul din fig. 4.25 să satisfacă ecuația (4.14), deoarece această ecuație se referă la o funcție pdf de două variabile iar histograma din fig. 4.26 aproximează o funcție pdf de o singură variabilă.




Fig. 4.25. Forma de undă a zgomotului eliminat.




Fig. 4.26. Histograma coeficienților de detaliu ai zgomotului eliminat prin metoda de filtrare wavelet propusă.

Metoda de denoising propusă a fost testată utilizând mai multe semnale din baza de date MIT-BIH, dintre care unele erau afectate de o componentă parazită de 50 Hz și algoritmul de denoising propus a condus în fiecare caz la rezultate multumitoare.

Rezumat 4.2.

În acest paragraf a fost prezentată o metodă de denoising. Algoritmul acestei metode exploatează proprietatea de invarianță la translații a SWT. Această transformată este calculată utilizând o funcție wavelet mamă cu o localizare timp-frecvență foarte bună. Au fost selectate opt niveluri de descompunere. Algoritmul propus aplică un filtru de tip *bishrink* în domeniul wavelet, acest filtru fiind un filtru de tip MAP care ia în considerare dependența interscală a coeficienților wavelet. Parametrii filtrului sunt aleși pe baza unor ipoteze realiste asupra proprietăților statistice ale coeficienților wavelet. Au fost realizate teste asupra unor semnale EKG afectate de zgomot real, prelevate din baza de date MIT-BIH pentru a evalua performanța metodei propuse.

4.3. Transmiterea la distanță a semnalului EKG

Sistemele de transmitere la distanță a electrocardiogramelor prezintă o dezvoltare accentuată în zilele noastre. Pacienții suferinzi de boli cardiace pot fi astfel monitorizați în mediul de acasă în timp real, în timp ce efectuează activități casnice. Preferințele actuale din lumea medicală, care utilizează rețele izolate pentru aplicații de telemedicină, evoluează înspre constituirea unei rețele heterogene în stare să ruleze concomitent o mare diversitate de aplicații.

Scopul final este de a exploata oportunitățile oferite de tehnologiile Wireless Local Area Network (WLAN) și Wireless Personal Area Network (WPAN), precum și de alte rețele wireless (cum ar fi sistemele de telefonie de generația a treia) de a asista serviciile medicale, oriunde și oricând. În acest scop, pacienții vor fi echipați cu senzori de achiziție a semnalului EKG și cu emițătoare. În figura următoare se prezintă schema unui sistem de monitorizare de la distanță a pacienților cu afecțiuni cardiace.

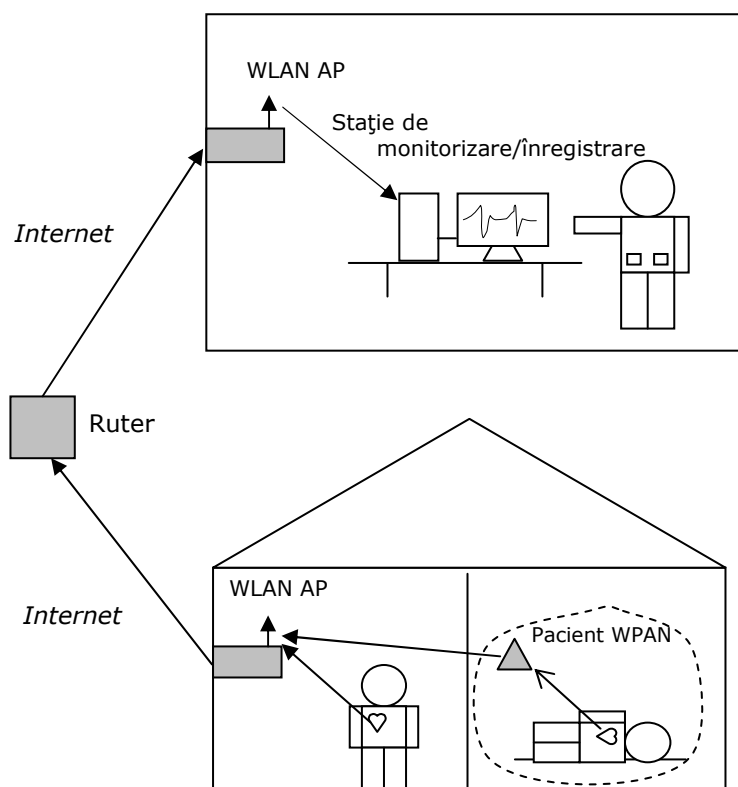


Fig.4.27 Sistem de monitorizare EKG în timp real.

Arhitectura unui emițător este compusă dintr-un bloc de condiționare, un bloc de compresie, un modulator și un amplificator. Funcțiile pe care trebuie să le îndeplinească blocul de condiționare al semnalului sunt: eșantionare, cuantizare, reducere a deviației liniei de bază a EKG-ului și filtrare a zgomotelor de achiziție. Scopul este de a realiza un transfer de date între pacientul aflat acasă și spitalul din regiunea învecinată.

Monitorizarea datelor trebuie să fie realizată de spitalele care pot fi echipate în acest sens cu sisteme de diagnosticare automată. Un asemenea sistem de diagnosticare trebuie să realizeze inițial o segmentare în componente a fiecărei bătăi a EKG-ului analizat, obținând undele P, complexe QRS și undele T. Comparând undele obținute cu unde de referință (corespunzătoare unui pacient sănătos), pot fi identificate diferite boli cardiace. În momentul considerat critic pentru manifestarea unei boli, sistemul ar putea fi programat să transmită un mesaj pacientului de a întrerupe activitatea curentă și de a lua o medicație anume prescrisă pentru acest caz.

Sistemele de monitorizare de la distanță urmăresc activitatea cardiacă a pacientului aflat în mediul său casnic sau de lucru și permit, prin intermediul tehnologiei WLAN sau WPAN, diagnosticarea în situații care nu pot fi create în mediul de lucru al spitalului.

Sistemul de achiziție al semnalului EKG cuprinde mai multe componente: sistemul de eșantionare (simulările au fost realizate asupra datelor preluate de la institutul MIT – frecvența de eșantionare fiind de 360 Hz), convertorul analog-digital (semnalele înregistrate de MIT folosesc un ADC pe 11 biți), sistemul de reducere a deviației liniei de bază a EKG-ului, sistemul de filtrare a zgomotului de achiziție și sistemul de compresie.

4.3.1. Metodă de compresie a electrocardiogramelor

Tehnicile bazate pe analiza wavelet devin o alternativă la tehnicile standard bazate pe analiza Fourier, datorită bunelor proprietăți de reprezentare timp-frecvență a unor semnale netaționare, precum semnalele biomedicale, pe care le au funcțiile wavelet. Funcțiile sinusoidale utilizate la calculul transformatei Fourier sunt înlocuite în analiza wavelet prin funcții wavelet care sunt obținute prin operații de translație și dilatare a unei funcții de bază, denumită funcție wavelet mamă, selectată în funcție de semnalul analizat [41]:

$$\psi_{a,b}(t) = |b|^{-\frac{1}{2}} \psi\left(\frac{t-a}{b}\right), \quad a, b \in R, \quad a \neq 0, \quad (4.21)$$

unde a este un parametru de poziție, b este un parametru de scară iar $\psi(t)$ este funcția wavelet mamă.

Structura sistemului de achiziție propus este prezentată în fig. 4.28.




Fig. 4.28. Structura sistemului de achiziție a semnalului EKG.

Teoria wavelet a fost utilizată anterior pentru compresie de imagini [66] și vorbire [67]. Calitatea compresiei poate fi apreciată utilizând teoria rată-distorsiune [68]. În general, factorul de compresie și factorul de distorsiune sunt invers proporționale. Astfel, la un factor de distorsiune dat, putem considera că o metodă de compresie are rezultate mai bune decât o alta dacă factorul său de compresie este mai mare.

Unele rezultate referitoare la compresia semnalelor EKG în scopul transmiterii lor la distanță sunt decrișe în literatură în lucrările științifice [69], [70]. În toate exemplele menționate [66 - 70] a fost utilizată Transformata Wavelet Discretă DWT.

Transformata wavelet discretă (DWT) este propusă pentru compresia semnalelor EKG datorită proprietății sale de a concentra întreaga energie a semnalului de intrare într-un număr mic de coeficienți wavelet de valoare mare. Ceilalți coeficienți wavelet reprezintă majoritatea și au valori mici. Astfel, se poate obține un factor important de compresie luând în considerare doar coeficienții wavelet de valoare mare.

În acest paragraf se propune un algoritm simplu ca și concept, care este bazat pe DWT și presupune eliminarea coeficienților wavelet cu valori sub o anumită valoare de prag. Această abordare este echivalentă cu filtrarea coeficienților wavelet cu un filtru *hard-thresholding* [71] (HT). DWT prezintă două caracteristici: funcția wavelet mamă utilizată și numărul de niveluri de descompunere. Aceșora li se adaugă o a treia caracteristică a metodei de compresie propusă și anume valoarea de prag. Alegerea optimă a acestor caracteristici poate fi făcută prin simulări.

Factorul de calitate (quality factor) QF al metodei de compresie este definit drept raportul dintre pătratul factorului de compresie (compression ratio) CR și factorul de distorsiune (Percent Root-Mean Square Difference) PRD :

$$QF = CR^2 / PRD . \quad (4.22)$$

Factorul de compresie a fost calculat după cum urmează:

$$CR = \frac{N_{bi}}{N_{bc}} = \frac{M \cdot N_{wcf}}{(M + P) \cdot N_{nnwcf}} , \quad (4.23)$$

unde N_{bi} reprezintă numărul de biți ai semnalului de intrare iar N_{bc} reprezintă numărul de biți ai semnalului comprimat. Prin M a fost desemnat numărul de biți

necesar pentru reprezentarea unui coeficient wavelet, iar prin P a fost desemnat numărul de biți necesar pentru reprezentarea poziției unui coeficient wavelet nenul. Numărul coeficienților wavelet este desemnat prin N_{wcf} iar numărul coeficienților wavelet nenuli prin N_{nnwcf} . Deoarece coeficienții wavelet nenuli nu sunt consecutivi, este necesară și reprezentarea pozițiilor acestora. Pentru o bună selecție a lungimii secvenței de intrare, fiecare din aceste poziții poate fi reprezentată pe un număr de biți inferior sau egal cu numărul de biți necesar pentru reprezentarea valorii corespunzătoare.

Evaluarea distorsiunilor a fost făcută utilizând metoda celor mai mici pătrate, definită în [69] și [70] după cum urmează:

$$PRD = \sqrt{\frac{\sum_{k=1}^N (x[n] - \hat{x}[n])^2}{\sum_{k=1}^N x^2[n]}} \times 100 \quad [\%], \quad (4.24)$$

unde x reprezintă semnalul de intrare având N eșantioane iar \hat{x} reprezintă semnalul reconstruit după compresie.

Strategia de simulare este prezentată în fig. 4.29. Primul set de simulări nu ia în considerare cuantizarea coeficienților wavelet, deoarece această operație mărește factorul de distorsiune.




Fig. 4.29. Strategia de compresie pentru primul set de simulări.

Sistemul de compresie corespunzător celei de a doua categorii de simulări este prezentat în fig. 4.30.




Fig. 4.30. Arhitectura sistemului de compresie implementat pentru a doua categorie de experimente.

Pentru codarea pozițiilor coeficienților wavelet nenuli a fost propusă metoda run-length encoding (RLE) [67]. Acesta este o metodă de codare foarte rapidă bazată pe repetarea unui simbol într-o secvență. Un șir de simboluri identice X este substituit cu numărul de repetiții S_cXC_c , unde S_c reprezintă simbolul special iar C_c reprezintă numărul de repetiții.

Datele utilizate aparțin bazei de date EKG MIT-BIH și poartă denumirea de 102 și 105. În fig. 4.31 este prezentat un exemplu al semnalului EKG de intrare pentru exemplificarea metodei de compresie, semnal asupra căruia au fost aplicați pașii de corecție a deviației liniei de bază și reducere a zgomotului de achiziție.




Fig. 4.31. Semnalul EKG achiziționat, 102 (sus); semnalul după filtrare (mijloc) și după filtrare și corecția deviației liniei de bază (jos).

În cadrul primei categorii de simulări au fost selectate principalele caracteristici ale algoritmului de compresie. În primul rând a fost căutată cea mai potrivită funcție wavelet mamă (mother wavelet - MW). Au fost testate patru familii de funcții wavelet mamă: familia de funcții wavelet mamă cu suport compact propusă de Ingrid Daubechies (Db), compusă din 44 de elemente, familia de funcții wavelet mamă Coiflet (Coif) compusă din 5 elemente, familia de funcții wavelet mamă Symmlet (Sym) compusă din 9 elemente și familia de funcții wavelet mamă biortogonale Battle-Lemarié (BL) compusă din 3 elemente. Diferența dintre elementele aceleiași clase este dată de numărul de momente nule (vanishing moments - vm).

În fig. 4.32 sunt reprezentate, pentru semnalul EKG 102, pe axele orizontale numărul de momente nule vm și valorile pragului (threshold) Thr ale filtrului de tip HT, în timp ce pe axa verticală sunt reprezentate valorile factorului de calitate QF respectiv ale factorului de compresie CR . Au fost considerate 10 valori întregi succesive ale pragului, începând cu valoarea 1.

Analizând fig. 4.32, se poate remarca dependența metodei propuse de valoarea de prag aleasă, QF prezentând valori foarte diferite pentru praguri succesive. Această sensibilitate a algoritmului propus cu valoarea de prag este o consecință a utilizării PRD pentru evaluarea distorsiunilor. Această măsură nu este însă cea mai adecvată pentru evaluarea factorului de distorsiune în cazul electrocardiogramelor. În sprijinul afirmației, vom considera următorul exemplu. De regulă, un calculator nu poate prelucra un semnal continuu, impunându-se discretizarea acestuia prin prelevarea de eșantioane la momente discrete de timp. Luând în considerare modul de lucru al unui calculator numeric, având la bază codificarea binară, se impune de asemenea și o discretizare a valorilor eșantioanelor (operație numită *cuantizare*) [72]. În acest caz o mărime cuantizată poate lua anumite valori, multiplii ai cuantei q . Formula [72] prezentată mai jos definește tranziția dintre două niveluri de cuantizare :

$$(n - 1/2)q < s[k] \leq (n + 1/2)q \Rightarrow s[k] = nq . \quad (4.25)$$

Într-un sistem real de achiziție, operația de cuantizare trebuie urmată de operația de codificare pentru a rezulta un semnal discret sub forma unei secvențe numerice [72]. În fig. 4.33 este prezentată o comparație a formelor de undă ale aceluiași segment al semnalului EKG 102, obținut înainte și după cuantizarea acestuia pe 7 biți. Această cuantizare reprezintă cea mai simplă metodă de compresie. Factorul de compresie pentru acest exemplu este de 16 ($2^{11}/2^7$). Efectele cuantizării sunt vizibile în fig. 4.33. Luând în considerare faptul că diagnosticul este pus în cazul semnalelor EKG pe baza unei analize vizuale, o asemenea compresie nu este acceptabilă.

Valoarea PRD a semnalului cuantizat este de $6,3 \times 10^{-3}$, indicând o compresie de bună calitate. În concluzie, factorul PRD nu este cea mai potrivită măsură de evaluare a distorsiunilor metodei de compresie a semnalelor EKG. Rezultatele primului set de simulări sunt sintetizate în tabelul 4.1.

În prima coloană este specificată denumirea semnalului EKG testat. Pentru primul semnal EKG, cel mai bun QF este obținut cu funcția wavelet mamă Db pentru 3 momente nule. Pentru cel de-al doilea semnal EKG, cel mai bun QF este obținut cu funcția wavelet mamă Db pentru 21 momente nule. Se poate trage concluzia că există o dependență a caracteristicilor metodei de compresie de semnalul EKG de intrare.

Analizând tabelul 4.1, se poate remarca că cele mai bune rezultate pot fi obținute utilizând familia de funcții wavelet mamă Db, însă rezultatele (în special numărul de momente nule vm) diferă foarte mult de la un semnal EKG la altul. Din punctul de vedere al CR , se obțin rezultate similare cu cele obținute cu familia Db pentru familia BL. Pentru familia Coif, numărul de momente nule prezintă valori mai scăzute.




Fig. 4.32. Selecția caracteristicilor metodei de compresie. Sus: Dependența factorului de calitate (QF) de funcția wavelet mamă (v_m) și de prag (Thr). Jos: Dependența factorului de compresie (CR) de funcția wavelet mamă (v_m) și de prag (Thr).




Fig. 4.33. Efectele cuantizării pe 7 biți asupra semnalului 102. Semnalul înainte de cuantizare (sus) și după cuantizare (jos).

Din aceste motive, a fost preferată undișoara mamă Coif cu un singur moment nul pentru cel de-al doilea set de simulări. Comparând rezultatele din tabelul 4.1 cu rezultatele raportate în literatură [69] și [70], se observă faptul că factorul de compresie este de același ordin de mărime.

Din punctul de vedere al factorului *PRD*, rezultatele metodei de compresie propuse sunt mai bune decât rezultatele obținute în [69] și [70]. Comparăția nu este însă foarte concludentă, deoarece în prezenta teză doctorală se utilizează o bază diferită de cea utilizată în lucrările [69] și [70]. O comparație mai bună se poate realiza doar prin utilizarea aceleași baze de date, fapt din care reiese importanța unei baze de date publice.

Tabelul 4.1. Rezultate ale primului set de simulări

EKG	MW	No.	Thr.	<i>CR</i>	<i>PRD</i>	QF
		v.m.				
102	Dau	3	3	5,46	1,4e-3	2,1e4
105	Dau	21	1	1,92	1,6e-5	2,3e5
102	Coif	1	1	3,14	4,1e-3	2,4e3
105	Coif	2	1	1,84	7,8e-4	4,3e3
102	Sym	2	2	4,62	12e-3	1,8e3
105	Sym	4	1	1,88	1,2e-3	2,9e3
102	Bior	2	3	5,34	3,4e-3	8,4e3
105	Bior	2	1	1,89	7,5e-3	479

Cel de-al doilea set de simulări ia în considerare operația de cuantizare a coeficienților wavelet. În scopul menținerii rezoluției inițiale a semnalelor EKG preluate din baza de date MIT-BIH, coeficienții wavelet nenuli au fost cuantizați pe 11 biți. Semnalul reconstruit este obținut aplicând transformata DWT inversă (IDWT) secvenței de coeficienți wavelet cuantizați. Acest semnal a fost de asemenea cuantizat pe 11 biți. În fig. 4.34 este reprezentată secvența de coeficienți wavelet cuantizați, obținuți după compresia unui segment al semnalului EKG denumit 102. Semnalul EKG original și reconstruit sunt reprezentate în fig. 4.35. Se remarcă faptul că metoda de compresie propusă nu produce distorsiuni vizibile.

Factorul de compresie poate fi îmbunătățit prin adăugarea unei metode de compresie de date fără pierderi. De exemplu, este posibilă extragerea pozițiilor coeficienților nenuli din secvența de poziții a coeficienților wavelet.

Transmiterea secvenței de coeficienți nenuli favorizează utilizarea codării RLE (care după cum s-a arătat deja reprezintă o metodă de compresie fără pierderi), deoarece pot fi remarcate numeroase repetiții ale simbolului 0 în fig. 4.34 iar efectul produs este descreșterea termenului $P \cdot N_{nnwcf}$ care apare la numitorul factorului de compresie *CR*.

O altă modalitate posibilă de a crește *CR* este cuantizarea semnalului de intrare sau a semnalului reconstruit pe un număr de biți mai mic decât 11.




Figura 4.34. Secvența coeficienților wavelet cuantizați, obținuți după filtrarea HT a semnalului EKG 102, utilizând un prag de valoare 1.




Figura 4.35. Semnalul EKG original (sus) și reconstruit (jos).

Rezumat 4.3.1

Paragraful prezintă un algoritm simplu de compresie a semnalelor biomedicale utilizând analiza wavelet. Simplitatea concepției permite implementarea facilă și o viteză de lucru bună. S-a demonstrat necesitatea de a lua în considerare cuantizarea coeficienților wavelet, operația de cuantizare influențând rata de distorsiune a metodei de compresie. Coeficienții wavelet au fost cuantizați pe 11 biți

pentru a păstra rezoluția semnalelor EKG originale din baza de date de la MIT-BIH. De asemenea a fost propusă o strategie de selecție a parametrilor metodei bazată pe evaluarea unui factor de calitate, dependent de raportul dintre factorul de compresie CR și factorul PRD . Procedura permite selecția asociației optime între funcția wavelet mamă utilizată la calculul DWT și valoarea de prag (necesară la distingerea coeficienților wavelet utili), astfel încât calitatea compresiei să fie maximizată. S-a demonstrat că factorul PRD nu reprezintă cea mai bună metodă de a măsura distorsiunile semnalului EKG reconstruit după compresie. Factorul PRD poate avea valori mici pentru semnale distorsionate vizibil. Deoarece diagnosticul în cazul semnalelor EKG se pune pe considerente vizuale, un criteriu vizual de apreciere a rezultatelor pare mai indicat în cazul acestor semnale biomedicale.

Algoritmul poate fi dezvoltat în continuare, o direcție importantă de cercetare fiind dezvoltarea unui algoritm adaptiv, care să exploateze proprietățile multi-rezoluție ale DWT.

4.3.2. Metodă adaptivă de compresie a electrocardiogrameelor

Proprietățile analizei wavelet permit o libertate mai mare de prelucrare a semnalelor nestaționare decât o permite analiza Fourier, astfel că a fost elaborată o metodă de compresie a electrocardiogrameelor care să utilizeze proprietatea de codare în subbenzi (subband coding) a analizei wavelet. Contrar reprezentării timp-frecvență de tipul transformării Fourier scurte (Short Time Fourier Transform – STFT), DWT permite modificarea lungimii ferestrei de analiză (constituită de funcția wavelet – a cărei formă se obține prin translații și dilatări ale funcției wavelet mamă), permițând astfel definirea unui factor de compresie diferit pentru componentele de joasă și înaltă frecvență ale semnalului EKG. DWT prezintă caracteristica (desemnată prin denumirea de *sparsity* în limba engleză) de a concentra energia semnalului într-un număr redus de coeficienți cu valori mari, majoritatea coeficienților prezentând valori mici. Prin urmare, luând în considerare doar coeficienții de valoare mare, se poate obține un factor important de compresie, fără a afecta semnificativ informațiile importante din punct de vedere al diagnosticului conținute de EKG. Transformata wavelet discretă DWT este calculată conform algoritmului de descompunere arborescent prezentat în figura 4.36. Analiza semnalului EKG de intrare este realizată utilizând filtrele FIR trece-jos l și filtrele FIR trece-sus h , pentru a calcula coeficienții wavelet de aproximare A_i și de detaliu d_i .




Fig. 4.36. Structura bancului de filtre care implementează DWT.

Spre deosebire de cazul calculului transformatei wavelet staționare (SWT), în cazul DWT se evită redundanța datelor nerelevante din punct de vedere al diagnosticului prin subeșantionarea la fiecare nivel de descompunere cu un factor de doi. Din aceste considerente, DWT este mai potrivită pentru aplicații de compresie a datelor. Au fost selectate patru niveluri de descompunere, realizându-se astfel o analiză multirezoluție MRA a semnalului EKG de intrare.

Spectrul coeficienților de aproximare $A_4(n)$ ocupă o bandă de frecvență joasă, în timp ce spectrele coeficienților de detaliu $d_4(n)-d_1(n)$ ocupă benzi de frecvențe intermediare, așa după cum se vede în figura 4.37. Subbenzile sunt distribuite în următoarea ordine: A_4, d_4, d_3, d_2, d_1 , de la frecvențe joase spre frecvențe înalte, un exemplu fiind prezentat în fig. 4.37. Din aceste motive, se poate afirma că DWT realizează o codare în subbenzi.




Fig. 4.37. Secvența de coeficienți wavelet distribuiți pe subbenzi: secvența coeficienților de aproximare împreună cu cele patru secvențe de coeficienți de detaliu.

Unul dintre avantajele transformatei wavelet asupra transformatei Fourier constă în abilitatea de a efectua o analiză multirezoluție a semnalului de intrare. Parametrii care trebuie definiți în această situație pentru calculul DWT sunt funcția wavelet mamă (generatoare) și numărul de iterații (niveluri de descompunere). Cea mai potrivită funcție wavelet mamă pentru calculul DWT este cea care permite reprezentarea semnalului EKG utilizând numărul cel mai mic de coeficienți wavelet semnificativi. De aceea se preferă funcții wavelet mamă cu o bună localizare în frecvență [73], precum funcția wavelet Daubechies20 (notată prescurtat Db20).

În literatură au fost întâlnite alte tehnici de compresie bazate pe analiza wavelet [74, 75], care pot fi utilizate pentru evaluarea performanțelor deoarece folosesc aceeași bază de date (MIT-BIH Arrhythmia) ca și metoda propusă în acest paragraf. Compresia semnalelor este realizată în [74] utilizând două tipuri de transformare wavelet: wavelet packets (WP) și transformarea cu pachete cosinusoidale bazată pe bancuri de filtre modulate cu funcții cosinusoidale cu reconstrucție aproape perfectă – Nearly-Perfect Reconstruction Cosine Modulated Filter Banks (N-PR CMFB). Algoritmul de compresie de tip ramuri de arbore conținând coeficienți de transformare wavelet neglijabili- Embedded Zerotrees of

Wavelet transforms – EZW, a fost aplicat semnalelor EKG utilizând WP. Semnalul de intrare este descompus utilizând un set de filtre de reconstrucție pe două canale atât la ramura filtrelor trece-jos cât și la cea a filtrelor trece-sus [74]. Arborele binar rezultat este considerat drept o bibliotecă de baze utilizabile pentru a reprezenta semnalul analizat. Cea mai bună bază pentru reprezentarea fiecărui bloc de date este obținută printr-un algoritm de tip pruning de selecție din biblioteca de baze, iar coeficienții wavelet corespunzători vor fi ulterior codați cu algoritmul EZW. Numărul de biți necesari pentru codare este calculat luând în considerare bazele posibile, procesul de codare-decodare încetând în momentul atingerii unui scop predefinit, cum ar fi o anumită valoare a factorului de compresie. În cazul utilizării transformării cu pachete cosinusoidale, N-PR CMFB nu se iau în considerare ramurile de arbore conținând coeficienți neglijabili – zerotrees, când se efectuează compresia.

Metoda de compresie prezentată în [75] se bazează pe transformata wavelet simetrică și utilizează un estimator spectral, sistemul fiind completat de un codificator bazat pe codarea Huffman.

Lucrarea [76] propune o metodă de compresie pentru semnale EKG, bazată pe standardul de codare a imaginilor JPEG2000, construind semnale EKG 2-D pornind de la semnale 1-D. Pentru a permite detectarea complexului QRS necesară pentru compresia bătailor, semnalul este împărțit pe blocuri și normalizat. Rezultatele sunt testate pe baza de date MIT-BIH Arrhythmia și permit astfel o comparație.

În [77] este propusă o metodă de compresie care exploatează corelația dintre bătaii succesive. Semnalul EKG este aproximat printr-o combinație liniară de coeficienți utilizând funcția wavelet mamă Db4. În stadiul de preprocesare se detectează complexul QRS și se face constantă perioada fiecărei bătaii. Compressive sensing [77] se referă la recuperarea lui x din măsurări liniare subeșantioane de tipul $y = \Phi x = \Phi \psi s$, unde ψ este o bază ortogonală iar Φ este matricea de măsurare. Modelul Joint Sparsity Model JSM-2 este utilizat la construcția semnalului din același set de vectori de bază, dar cu coeficienți diferiți, un decodor în punctul de colectare reconstruind semnalul final. Aproximările sunt recuperate printr-un algoritm de tipul Simultaneous Orthogonal Matching Pursuit (SOMP). Parametrii metodei propuse în [77] sunt: funcția wavelet mamă Db4, 4 niveluri de descompunere, patru biți sunt utilizați pentru cuantizarea măsurătorilor, opt biți pentru perioadele bătailor. O altă metodă de compresie este propusă în [78], unde se utilizează transformata Burrows-Wheeler (BWT). Eficiența maximă este obținută atunci când semnalul de intrare este în format text. Datele utilizate sunt furnizate de baza de date MIT-BIH și divizate în blocuri. Aplicând BWT acestor blocuri, caracterele identice sunt adunate iar blocurile sunt comprimate utilizând algoritmi adaptivi locali precum codarea Move-to-Front MTF iar în final codarea Huffman este utilizată datorită stabilității sale computaționale.

În [79] este propusă o metodă de compresie care combină funcții wavelet biortogonale cu un algoritm de tip arbori ierarhici – SPIHT (Set partitioning in hierarchical trees). Semnalul original este descompus utilizând DWT și o structură arborescentă de orientare spațială este utilizată pentru a defini relații părinte-copil dintre subbenzi. O versiune modificată a algoritmului de codare embedded coding este aplicată până când se atinge un nivel de prag specificat. Nivelul de prag reprezintă un parametru care determină factorul de compresie final. Transformata wavelet combinată cu algoritmul SPIHT de codare a fost aplicată semnalelor din baza de date de la MIT-BIH iar rezultatele permit realizarea unor comparații ale

performanțelor putând fi comparate cu rezultatele algoritmului propus în acest paragraf.

Factorul de compresie, CR , se calculează la fel ca mai sus ca raportul dintre numărul de biți ai semnalului de la intrarea sistemului de compresie, B_{iEKG} și numărul de biți ai semnalului comprimat B_{cEKG} . O evaluare a distorsiunilor cauzate de reconstrucția semnalelor comprimate poate fi dată de factorul PRD , definit și utilizat în paragraful anterior. De regulă PRD este utilizat datorită simplității sale matematice [80], însă studiile realizate anterior de către autoarea tezei (capitolul 4.3.1) au arătat faptul că factorul PRD nu este o măsură foarte eficientă a distorsiunilor, deoarece valori mici ale acestui factor pot masca distorsiuni inacceptabile în cazul unei reprezentări medicale pe baza căreia se pune un diagnostic, așa cum s-a arătat în fig. 4.33. Asemenea măsuri preponderent cantitative nu sunt adecvate în cazul EKG-ului [81], având în vedere că medicii pun diagnosticul pe baza unei analize vizuale. Pentru a evalua distorsiunile introduse de metoda de compresie, în continuare se utilizează raportul semnal-zgomot SNR , definit prin următoarea ecuație:

$$SNR = \frac{\sum_{k=1}^n s^2(k)}{\sum_{k=1}^n (s(k) - \hat{s}(k))^2}, \quad (4.26)$$

unde s reprezintă semnalul de intrare având n eșantioane și \hat{s} reprezintă semnalul obținut după compresie și reconstrucție. Metoda de compresie propusă este adaptivă, semnalul $s(t)$ fiind segmentat pentru a aplica algoritmul de compresie pe blocuri de lungime egală. După cum a fost descris anterior, calculând DWT a blocului curent, se obține o secvență de coeficienți asemănătoare cu cea prezentată în fig. 4.37. Se remarcă faptul că valorile coeficienților diferă în funcție de subbanda de care aparțin. Acest fapt permite realizarea unei cuantizări diferențiate a coeficienților din subbenzi diferite. Se definesc valorile coeficienților reprezentative pentru fiecare subbandă, calculând deviația standard sd a secvenței corespunzătoare cu ajutorul formulei de mai jos:

$$sd = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}, \quad (4.27)$$

unde $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ reprezintă media secvenței și n reprezintă numărul de coeficienți

aparținând subbenzii curente.

Algoritmul de compresie adaptivă a electrocardiogramelor cuprinde două etape principale: într-o primă fază se va calcula DWT a semnalului EKG de comprimat. Contrar metodei descrise la paragraful anterior, valoarea de prag nu va fi fixă, ci va fi dependentă de subbanda respectivă. Pentru fiecare dintre subbenzi se va calcula deviația standard a coeficienților wavelet care o definesc și se va fixa valoarea pragului drept o fracțiune a deviației standard. Cea de-a doua fază a algoritmului constă într-o cuantizare adaptivă: astfel, analizând fig. 4.37, se remarcă valorile diferite ale coeficienților aparținând la subbenzi diferite. Cele mai mari valori corespund coeficienților de aproximare A_4 , valorile coeficienților de detaliu descrescând odată cu creșterea indicelui subbenzii: d_4 , d_3 , d_2 , și d_1 . Selectând un nivel de cuantizare care să permită reprezentarea tuturor coeficienților

pe un număr de biți impus, reprezentarea binară a valorilor unora din coeficienții de detaliu d_4, d_3, d_2, d_1 va începe cu zero-uri. Acest dezavantaj poate fi prevenit, dacă se cuantizează valorile acelor coeficienți utilizând un număr redus de biți. Numărul de biți necesari pentru cuantizarea fiecărei secvențe de coeficienți poate fi evaluat împărțind valoarea maximă a secvenței A_4 la valorile maxime ale secvențelor d_4, d_3, d_2, d_1 . Simulările concepute pentru a testa eficiența metodei de compresie adaptivă propusă în acest paragraf au fost realizate utilizând mediul de lucru *Matlab* și semnale EKG puse la dispoziție de baza de date *MIT-BIH ECG Database*. S-a utilizat electrocardiograma denumită 102, pentru a putea realiza o comparație a rezultatelor obținute cu rezultatele obținute cu ajutorul metodei de compresie descrisă în paragraful anterior. Rezultatele sunt ilustrate în graficele de mai jos. În fig. 4.38 sunt prezentate EKG-ul original (primul grafic), semnalul EKG obținut în urma aplicării metodei propuse în paragraful 4.2 de reducere a zgomotului de achiziție (cel de al doilea grafic) și semnalul EKG obținut în urma corecției deviației liniei de bază prin metoda propusă în paragraful 4.1 (al treilea grafic). Fig. 4.39 prezintă un zoom asupra a șapte bătăi din electrocardiograma analizată, pentru a permite o mai bună vizualizare a performanțelor metodelor propuse.




Fig. 4.38. Semnalul EKG original, semnalul după reducerea zgomotului de achiziție și după corecția deviației liniei de bază.




Fig.4.39. Zoom pe șapte bătăi ale electrocardiografei originale (sus), rezultatul obținut după filtrarea zgomotului biologic (la mijloc) și semnalul obținut după corecția liniei de bază (jos).

Prima etapă a algoritmului de compresie propus prevede calculul DWT, având drept semnal de intrare, electrocardiograma pre-procesată (cu o deviație a liniei de bază și zgomot de achiziție reduse). Următorul pas constă în identificarea subbenzilor, fiecare subbandă de detaliu fiind tratată într-un mod diferit și independent. Deviația standard a fiecărei subbenzi $sd_k, k=1, \dots, 4$, este calculată pentru a selecta valorile de prag (threshold level) tk corespunzătoare, valorile de prag fiind selectate după următoarea regulă: $tk=0.25s_{dk}$. Astfel, coeficienții wavelet de detaliu sunt filtrați utilizând filtre de tip hard thresholding cu valori de prag diferite, corespunzătoare subbenzii din care fac parte. Cea de-a doua etapă a algoritmului de compresie propus constă în determinarea numărului de biți necesari pentru fiecare subbandă.

Coeficienții de aproximare și prima subbandă a coeficienților de detaliu au fost cuantizați utilizând 11 biți pentru a păstra rezoluția EKG-ului original din baza de date MIT-BIH. Numărul de biți necesari pentru reprezentarea binară a coeficienților wavelet de detaliu din celelalte subbenzi depinde de funcția wavelet mamă selectată, după cum se poate observa analizând tabelul 4.2.

Funcțiile wavelet mamă selectate aparțin familiei Daubechies cu suport compact și se remarcă variația factorului de compresie CR și a SNR (măsurat în decibeli) cu variația numărului de momente nule al funcției wavelet mamă. Atât CR cât și SNR cresc odată cu creșterea numărului de momente nule. Utilizând funcția wavelet mamă Db20 (având 10 momente nule) distribuția numerelor de biți pe care se exprimă coeficienții wavelet din diferite subbenzi în urma cuantizării adaptive este următoarea: coeficienții A4 și d4 sunt cuantizați pe 11 biți, pentru fiecare dintre coeficienții din cea de-a doua subbandă de detalii d3 sunt necesari 10 biți, pentru fiecare dintre coeficienții din cea de-a treia subbandă de detalii d2 se folosesc câte 9 biți iar pentru fiecare coeficient din ultima subbandă de detalii d1 se folosesc doar

câte 7 biți. În acest mod a fost realizat un factor de compresie de 7,79, mai mare decât factorul de compresie maxim obținut prin metoda de compresie prezentată în paragraful anterior, care a fost de 5,46 pentru același semnal de intrare. Reconstrucția semnalului este obținută prin aplicarea transformatei wavelet inverse, IDWT, asupra secvenței de coeficienți wavelet cuantizați.

În fig. 4.40 a fost reprezentat atât semnalul de intrare cât și semnalul reconstruit după aplicarea algoritmilor de compresie și reconstrucție și nu se constată distorsiuni vizibile. Metoda a fost testată și asupra EKG-ului denumit 117 în baza de date MIT și s-a obținut, utilizând funcția wavelet mamă Db20, un factor de compresie de 7,82 pentru un SNR de 20,60 dB. De asemenea, nu pot fi remarcate distorsiuni vizibile după reconstrucție în fig. 4.41.

Tabelul 4.2. Rezultatele simulărilor efectuate.

MW	CR	SNR [dB]	Nr. biți d3	Nr. biți d2	Nr. biți d1
Db4	7,76	22,87	11	10	8
Db6	7,76	23,09	10	10	8
Db8	7,76	23,20	10	10	8
Db10	7,78	23,60	11	10	7
Db12	7,78	23,46	11	10	7
Db14	7,78	23,69	10	10	7
Db16	7,78	23,97	10	10	7
Db18	7,79	24,20	10	9	7
Db20	7,79	24,36	10	9	7

În scopul realizării unei comparații relevante cu metodele propuse în [74] și [75], algoritmul adaptiv de compresie propus a fost aplicat semnalului EKG 117 din baza de date MIT-BIH Arrhythmia, semnal care apare și în articolele menționate anterior. Utilizând funcția wavelet mamă Db20 pe 4 niveluri de descompunere a fost realizat un factor de compresie CR de 7,82 pentru un raport semnal-zgomot SNR de 20,60 dB, rezultatul compresiei și reconstrucției fiind redat grafic în fig. 4.41. Rezultatele sunt comparabile cu cele prezentate în [74] unde a fost obținut un factor de compresie de 7,7.

Factorul de compresie ia valori între 4,1 și 7,9 în [75], dar distorsiunile cresc de asemenea odată cu creșterea factorului de compresie. În cazul metodei propuse nu pot fi percepute distorsiuni vizibile (a se vedea fig. 4.41).

Avantajul metodei descrise în acest capitol constă în adaptabilitate și în efortul computațional redus. Pentru a realiza comparații pertinente cu celelalte metode descrise au fost întreprinse studii mai aprofundate asupra influenței parametrilor metodei (familia de funcții wavelet mamă, numărul de momente nule, numărul de niveluri de descompunere) asupra performanțelor de compresie.




Fig. 4.40 Zoom realizat asupra a șapte bătăi ale semnalului EKG original 102 și ale semnalului reconstruit.




Fig. 4.41. Zoom asupra a cinci bătăi ale semnalului EKG original 117 (forma de undă de sus) și semnalul reconstruit după compresie (forma de undă de jos).

De regulă, trebuie realizat un compromis între CR și SNR, un factor de compresie prea mare afectând acuratețea semnalului reconstruit. Variația rezultatelor simulărilor realizate asupra unui semnal EKG prezentate în tabelul 4.2, indică posibilitatea de optimizare a metodei de compresie prin alegerea corespunzătoare a

parametrilor algoritmului. De aceea s-a studiat o strategie de optimizare a alegerii valorilor parametrilor, identificându-se mai mulți parametri care pot îmbunătăți performanța algoritmului propus: familia de funcții wavelet mamă utilizate pentru calculul DWT, numărul de momente nule a funcțiilor wavelet mamă selectate, numărul de iterații (niveluri de descompunere) ales și nivelul de cuantizare al fiecărei subbenzi. Strategia de optimizare este prezentată în fig.4.42.

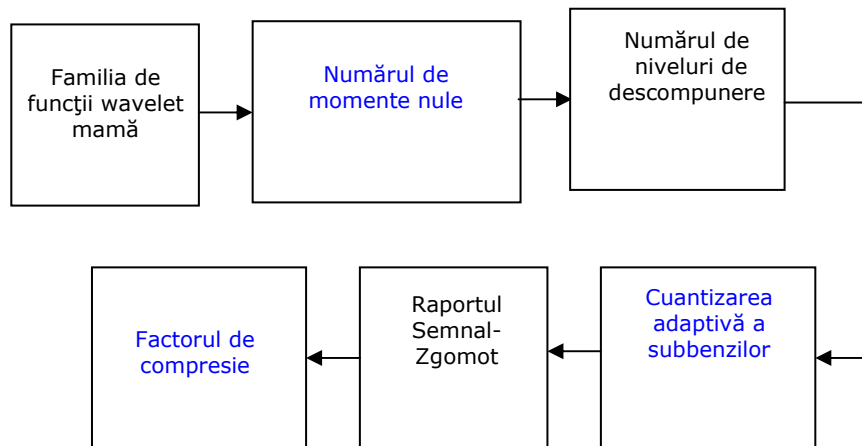


Fig 4.42. Strategia de optimizare a parametrilor algoritmului adaptiv de compresie.

Studiile anterioare (prezentate în cap. 4.3.1) au arătat o dependență a performanțelor de compresie în funcție de funcția wavelet mamă aleasă, astfel a fost evaluată performanța a trei familii importante de funcții wavelet (Daubechies, Coiflet și Symmlet). Familia Daubechies (Db) a fost propusă de matematiciana belgiană Ingrid Daubechies [34] fiind compusă din elemente asimetrice cu suport compact de lungime minimă pentru un număr dat de momente nule. Familia Symmlet (Sym) cuprinde elemente mai simetrice decât funcțiile wavelet mamă Db, având de asemenea suport compact de lungime minimă pentru un număr de momente nule [34]. Funcțiile wavelet mamă Coiflet (Coif) se caracterizează prin faptul că au același număr de momente nule ca și funcțiile de scară corespunzătoare [30]. Următoarea etapă a algoritmului de optimizare constă în selecția proprietăților funcției wavelet mamă, și anume numărul de momente nule. Acestea constituie o măsură a proprietăților de localizare timp-frecvență a funcției wavelet mamă corespunzătoare: un număr redus de momente nule corespunde unei bune localizări în timp, iar un număr crescut de momente nule corespunde unei bune localizări în frecvență. Un studiu extins asupra modalității de compresie a EKG-ului va evidenția dacă localizarea temporală sau cea frecvențială este mai importantă în cazul acestui tip de semnale.

Va fi testată de asemenea și influența numărului nivelurilor de descompunere, numărul coeficienților wavelet descrescând odată cu creșterea numărului de iterații, datorită subeșantionării. În scopul creșterii performanței algoritmului de compresie, subbenzile sunt cuantizate în mod adaptiv. Ultima etapă a strategiei de optimizare vizează stabilirea unui compromis între un raport semnal-zgomot bun și un factor de compresie eficient. Pentru a defini parametrii optimi de funcționare, trebuie efectuat un număr considerabil de simulări înainte de

definitivarea algoritmului propus. Simulările au fost efectuate utilizând baza de date disponibilă în mod public, MIT-BIH Arrhythmia Database [57], permițând astfel o bună comparație a rezultatelor cu rezultatele altor cercetări. Rezultatele simulărilor realizate în scopul definirii unei strategii de optimizare a performanțelor sunt prezentate în următoarele paragrafe. În fig. 4.43 este prezentat semnalul EKG original, denumit 109 în baza de date de la MIT-BIH înainte și după aplicarea metodei de corecție a liniei de bază și a procedurii de reducere a zgomotului. Acest semnal corectat va fi în continuare obiectul metodei de compresie.




Fig. 4.43. Electrocardiograma originală 109 (sus), semnalul obținut după filtrarea zgomotului de achiziție și corecția liniei de bază (jos).

Aplicând DWT pe patru niveluri de descompunere, rezultă secvența de coeficienți wavelet reprezentați în figura de mai jos. Se remarcă distribuția în subbenzi și faptul că energia semnalului este concentrată într-un număr relativ mic de coeficienți de valoare mare (de regulă, coeficienții de aproximare și câțiva coeficienți de detaliu), majoritatea coeficienților având valori mici.




Fig. 4.44. Coeficienții wavelet obținuți prin aplicarea DWT electrocardiogramei 109.

Într-o primă etapă a procedurii de optimizare a parametrilor s-au testat variațiile de performanță produse de familia ortogonală de funcții wavelet mamă aleasă: Db, Sym, Coif. Influența numărului de momente nule al funcției wavelet mamă asupra factorului de compresie și al raportului semnal pe zgomot de reconstrucție este exemplificată în tabele următoare (Tab. 4.3, 4.4 și 4.5) pentru semnalul EKG 109 prelevat din baza de date MIT-BIH Arrhythmia Database.

Tab 4.3. Rezultatele simulării efectuate pentru semnalul EKG 109, utilizând familia de funcții wavelet mamă Daubechies și patru niveluri de descompunere. Coeficienții din secvențele A_4 și d_4 au fost cuantizați pe câte 11 biți, așa că nu au mai fost trecuți în tabel.

MW	CR	SNR [dB]	Nr. biți	Nr. biți	Nr. biți
			d3	d2	d1
Db4	7,82	19,30	8	7	6
Db6	7,81	19,91	9	7	7
Db8	7,81	20,99	9	7	7
Db10	7,83	20,18	8	6	6
Db12	7,84	19,45	7	6	6
Db14	7,83	19,39	8	6	6
Db16	7,82	19,83	8	7	6
Db18	7,82	20,82	8	7	6
Db20	7,83	20,76	7	7	6

Tab 4.4. Rezultatele simulării efectuate pentru semnalul EKG 109, utilizând familia de funcții wavelet mamă Daubechies și cinci niveluri de descompunere. Coeficienții din secvențele A_5 și d_5 au fost cuantizați pe câte 11 biți, așa că nu au mai fost trecuți în tabel.

MW	CR	SNR [dB]	Nr. biți	Nr. biți	Nr. biți	Nr. biți
			d4	d3	d2	d1
Db4	15,14	18,04	10	10	8	7
Db6	15,11	18,41	10	10	9	7
Db8	15,11	19,31	10	10	9	7
Db10	15,14	20,06	10	10	8	7
Db12	15,17	19,44	10	10	7	7
Db14	15,14	18,93	10	10	8	7
Db16	15,17	19,47	10	10	9	6
Db18	15,20	20,55	10	10	8	6
Db20	15,14	20,81	10	10	8	7

Tab. 4.5. Rezultatele simulării efectuate pentru semnalul EKG 109, utilizând familia de funcții wavelet mamă Daubechies și șase niveluri de descompunere. Coeficienții din secvențele A_6 și d_6 au fost cuantizați pe câte 11 biți, așa că nu au mai fost trecuți în tabel.

MW	CR	SNR [dB]	Nr. biți				
			d5	d4	d3	d2	d1
Db4	28,46	17,55	11	11	11	9	7
Db6	28,51	17,67	11	11	10	9	7
Db8	28,51	17,75	11	11	10	9	7
Db10	28,61	18,27	11	11	10	8	7
Db12	28,61	18,32	11	11	10	8	7
Db14	28,61	19,11	11	11	10	8	7
Db16	28,83	19,44	11	11	10	8	6
Db18	28,83	19,22	11	11	10	8	6
Db20	28,61	19,37	11	11	10	8	7

Numărul care urmează după denumirea familiei de funcții wavelet de pe prima coloană a tabelului oferă o indicație asupra numărului de momente nule al funcției wavelet mamă (în cazul familiei de funcții Daubechies, funcția wavelet mamă Db4 are 2 momente nule, Db6 are 3 momente nule, etc.).

Analizând tabelele 4.3, 4.4 și 4.5, remarcăm o variație a factorului de compresie CR și a raportului semnal-zgomot SNR cu numărul de momente nule. Acest fapt poate fi datorat și variației numărului de biți necesari pentru reprezentarea coeficienților wavelet de detaliu din subbenzi diferite (d_1, d_2, d_3, d_4). Rezultatele prezentate în tabelele 4.3, 4.4 și 4.5 prezintă o creștere a factorului de compresie cu creșterea numărului de iterații al DWT. În același timp, remarcăm însă și o scădere a SNR, apărând necesitatea stabilirii unui compromis între CR și SNR. Conform datelor obținute, pentru compresia semnalului EKG 109, se recomandă funcția wavelet mamă Db20 care are 10 momente nule și cinci niveluri de descompunere.

Astfel, a fost obținut un factor de compresie de 15,14 pentru un SNR de 20,81 dB. Coeficienții de aproximare ai primei subbenzi au fost cuantizați pe 11 biți, pentru coeficienții celei de-a doua și de-a treia subbenzi s-au utilizat 10 biți, coeficienții celei de-a patra subbenzi au fost cuantizați pe 8 biți iar pentru ultima subbandă s-au utilizat doar 7 biți. În acest fel s-au luat în considerare valorile coeficienților wavelet specifice fiecărei subbenzi.

Reconstrucția semnalului EKG se obține aplicând transformata wavelet discretă inversă secvenței de coeficienți wavelet cuantizați iar o reprezentare a performanțelor metodei de compresie este realizată în fig. 4.45, pentru o compresie a EKG-ului 109 realizată utilizând funcția wavelet mamă Db20 și cinci niveluri de descompunere. Se remarcă faptul că nu există distorsiuni vizibile ale semnalului EKG reconstruit.




Fig. 4.45 Rezultate de simulare pentru electrocardiograma 109.

Comparația semnalului reconstruit cu semnalul original este un mod viabil de verificare a rezultatelor metodei propuse, deoarece în cazul electrocardiografei diagnosticul este pus pe baza unei inspecții vizuale. O bună asemănare a semnalului reconstruit cu semnalul original, pus la dispoziție de MIT-BIH [57], indică distorsiuni acceptabile și deci păstrarea informațiilor utile din punct de vedere medical conținute de electrocardiogramă.

Raportul semnal-zgomot a fost ales drept măsură a distorsiunilor cauzate de reconstrucția semnalului comprimat iar studiile au demonstrat faptul că un SNR sub 19,50 dB nu este indicat în cazul semnalelor EKG, producând distorsiuni vizibile.

În fig. 4.46a este reprezentat un detaliu (zoom) asupra a trei bătăi ale electrocardiografei reprezentate în fig. 4.45. Rezultatul compresiei este reprezentat în fig. 4.46b (semnalul EKG a fost comprimat utilizând funcția wavelet mamă Db20 și cinci niveluri de descompunere) respectiv în fig. 4.46c (semnalul EKG a fost comprimat utilizând funcția wavelet mamă Db16 și șase niveluri de descompunere).

Reconstrucția din fig. 4.46b (pentru care valoarea de SNR este de 20,81 dB) este mai apropiată de semnalul original comparativ cu reconstrucția din fig. 4.46c (pentru care valoarea de SNR este de 19,44 dB). Elementele deformate au fost marcate cu roșu în fig. 4.46c.




Fig. 4.46 Detaliu asupra a trei bătăi ale semnalului EKG 109 (a) reconstruit utilizând Db20 și 5 niveluri de descompunere (b) și Db16 și 6 niveluri de descompunere (c).

O privire de ansamblu asupra variației factorului de compresie CR și raportului semnal-zgomot SNR cu numărul de momente nule pentru familia de funcții wavelet mamă Daubechies obținute pentru semnalul EKG 109 din baza de date de la MIT-BIH este prezentată în figura de mai jos.

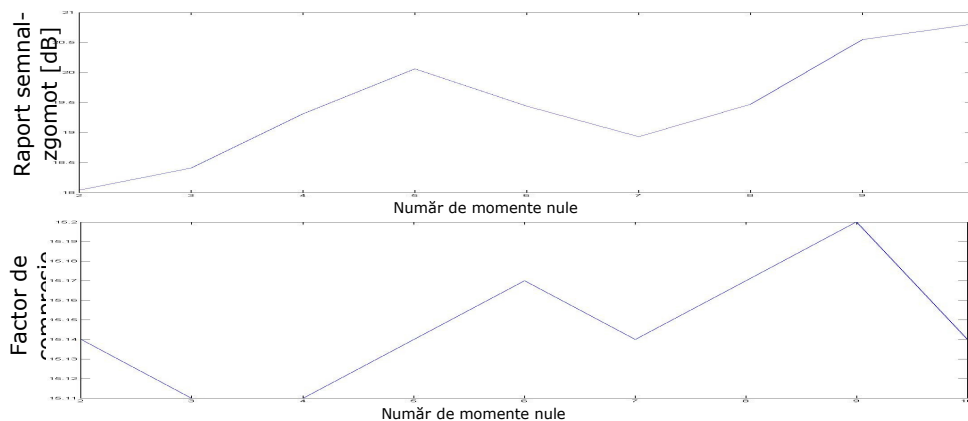


Fig. 4.47. Variația valorii de SNR (sus) și de CR (jos) cu numărul de momente nule pentru familia de funcții wavelet mamă Daubechies obținute aplicând algoritmul de compresie adaptiv semnalului EKG 109 folosind cinci niveluri de descompunere ale DWT.

Se remarcă necesitatea definirii unui compromis între CR și SNR (se observă raportul invers proporțional între cei doi indici de calitate) pentru a identifica parametrii optimi ai metodei adaptive de compresie propusă. Acest lucru a fost îndeplinit realizând simulări asupra unui număr mai mare de electrocardiograme. Metoda a fost testată pe 15 semnale EKG din baza de date MIT-BIH Arrhythmia, compresia semnalului fiind realizată după corecția liniei de bază și după reducerea zgomotului de achiziție. Asupra fiecărei EKG au fost testate cele trei familii de funcții wavelet mamă ortogonale propuse (Daubechies, Coiflet, Symmlet), utilizând mai multe niveluri de descompunere (4, 5 respectiv 6). Tabelul 4.6 oferă o privire de ansamblu asupra rezultatelor optime obținute. Alegerea rezultatelor optime a fost făcută ținând cont de mai mulți parametri.

Tab. 4.6. Rezultatele optime obținute în urma aplicării metodei de compresie adaptivă

EKG	MW	CR	SNR [dB]	Nr.	Nr.	Nr.	Nr.	Nr.	Nr.
				biți d6	biți d5	biți d4	biți d3	biți d2	biți d1
100	Sym8	14,98	19,99	-	11	11	11	11	8
102	Db12	14,97	21,46	-	11	10	10	10	9
103	Db16	28,05	20,79	11	11	11	11	11	8
107	Db18	28,56	20,04	11	11	11	9	9	7
109	Db20	15,14	20,81	-	11	10	10	8	7
113	Coif5	27,84	22,03	11	11	11	11	11	9
114	Db10	7,78	19,83	-	-	11	11	10	7
117	Db14	15,07	20,33	-	11	11	11	10	7
119	Coif1	7,84	20,91	-	-	11	9	7	5
123	Coif1	7,80	20,12	-	-	11	11	9	6
124	Coif2	28,46	20,45	11	11	11	11	9	7
202	Db16	15,10	20,81	-	11	11	11	9	7
213	Db20	28,36	20,97	11	11	11	11	10	7
222	Coif2	7,78	21,46	-	-	11	11	10	7
232	Db14	7,81	20,51	-	-	11	11	8	6

Analizând rezultatele prezentate în tabelul 4.6, se remarcă distribuția principalilor parametri ai algoritmului; astfel, din 15 electrocardiograme testate, pentru 9 semnale EKG, cele mai bune performanțe au fost obținute utilizând funcția wavelet mamă Daubechies, pentru 5 semnale EKG cele mai bune performanțe au fost obținute utilizând funcția wavelet mamă Coiflet și doar pentru o electrocardiogramă, funcția wavelet mamă Symmlet este cea mai indicată (fig. 4.48). În cazul celui de-al doilea parametru, numărul de momente nule, se pot face următoarele observații: majoritatea rezultatelor obținute indică un număr redus de

momente nule, rezultând importanța localizării temporale în cazul electrocardiogramelor.

Rapoartele semnal pe zgomot variază în jurul valorii de 20 dB. Doar în cazul a două semnale EKG s-au obținut valori de SNR sub 20 dB, dar apropiate de această valoare (pentru EKG-100 s-a obținut un SNR de 19,99 dB iar în cazul EKG-114 s-a obținut un SNR de 19,83 dB). Factorul de compresie mediu realizat are valoarea de 15.




Fig.4.48 Distribuția rezultatelor funcție de familia de funcții wavelet mamă optimă

Studiul extins întreprins asupra semnalelor EKG permite comparația rezultatelor cu alte metode menționate în literatură [76 – 79]. În lucrarea științifică [76] sunt menționați factorii de compresie CR obținuți pentru semnalele 100, 117 și 119 din baza de date MIT-BIH Arrhythmia. Dependent de factorul care indică riscul de distorsiune PRD în [76] (care nu a fost propus pentru studiul de față datorită imperfecțiunii, după cum s-a arătat în cap. 4.3.1) sunt propuși mai mulți factori CR pentru același semnal EKG. De exemplu, pentru semnalul 100, se propune un CR de 24 pentru un factor PRD mai mare (3.53) sau un CR de 10 pentru o valoare PRD mai mică (2.12), în timp ce pentru semnalele 117 și 119, factorul CR variază de asemenea între 24 și 8 [76].

Cercetările întreprinse în studiul prezent au încercat să găsească o optimizare a parametrilor, astfel încât au fost propuși factori de compresie intermediari cu valori de 14,98 pentru semnalul EKG 100, 15,07 pentru semnalul EKG 117 și 7,84 pentru semnalul EKG 119.

În [77], metoda este testată pe semnalele 100, 102, 107, 115, 117 și 118. O bună performanță este obținută pentru factori de compresie mai mici de 10, riscul de distorsiune crescând odată cu factorul CR. Lucrarea afirmă că, datorită cuantizării realizate pe patru biți, nu se pot obține valori PRD foarte mici (între 0-2) atunci când numărul de măsurători crește [77]. În [78] au fost comprimate semnalele EKG 102, 103, 104 și 117 iar cele mai bune valori CR obținute sunt între 2,08-2,69 (EKG 102), 1,97-2,64 (EKG 103), 1,93-2,57 (EKG 104) și 1,98-2,68 (EKG 117). Algoritmul adaptiv propus în acest capitol realizează factori de compresie mai buni,

urmărind în același timp și o bună reconstrucție a semnalului original. Rezultatele prezentate în [79] au fost obținute utilizând funcția wavelet mamă biortogonală 9/7 și șase niveluri de descompunere în combinație cu un algoritm de tip SPIHT. Factorii de compresie obținuți sunt în jurul valorii 20, pentru semnalul EKG 100 obținându-se un CR de 18,6, pentru semnalul EKG 107 CR=23,5, pentru semnalul EKG 117 obținându-se un CR = 21,4, pentru semnalul EKG 119 CR=22,1, dar în cazul semnalului EKG 107 valoarea PRD este relativ mare (PRD= 10,8%), crescând riscul de a distorsiona semnalul [79]. Valorile obținute prin metoda descrisă în acest capitol sunt similare (EKG 100, 107), datorită impunerii unui compromis între CR și măsura de evaluare a distorsiunilor, SNR.

Analizând datele prezentate în tabelul 4.6, remarcăm faptul că rezultatele optime au fost obținute utilizând familia de funcții wavelet mamă Daubechies și cinci niveluri de descompunere. Numărul redus de iterații permite un timp de prelucrare redus, creând astfel oportunitatea unei monitorizări de la distanță în timp real a activității electrice a inimii.

Compresia semnalelor transmise la distanță fiind o problemă actuală, a fost efectuat un studiu extins al performanțelor metodei de compresie adaptivă, care s-a dovedit mai performantă decât metoda de compresie prezentată în paragraful 4.3.1, fiind mai adaptabilă caracteristicilor semnalului EKG de prelucrat. S-au efectuat simulări asupra unui volum considerabil de date pentru a putea defini parametrii optimi ai metodei de compresie.

Utilizarea unei baze de date disponibile în mod public permite și comparații cu performanțele obținute de alți cercetători. Asupra fiecărei electrocardiografe din mulțimea aleasă au fost testate mai multe valori de parametri, care în urma optimizării pot fi fixați pentru viitor. Acest studiu desemnează familia de funcții wavelet mamă Daubechies drept cea mai indicată în cazul metodei adaptive de compresie propuse. Un număr redus de niveluri de descompunere pentru calculul DWT reduce timpul de prelucrare și oferă posibilitatea unei monitorizări în timp real a activității electrice a inimii, scopul final fiind de a crea posibilitatea de implementare a metodei de compresie într-un sistem de diagnosticare automată: în cazul semnalelor EKG și a metodei propuse care utilizează DWT sunt propuse cinci niveluri de descompunere.

Studiul indică faptul că pot fi sesizate distorsiuni ale semnalului EKG pentru un SNR sub 19,45 dB. Factorul de compresie obținut este în jurul valorii de 15, pentru un raport semnal-zgomot în jur de 20 dB.

Tabelul 4.7 sintetizează rezultatele obținute utilizând familia de funcții wavelet mamă Daubechies și cinci niveluri de descompunere, cea mai indicată funcție wavelet mamă ortogonală în urma studiului efectuat asupra a 15 semnale EKG. S-a obținut un factor de compresie CR mediu de 15,04 pentru un SNR mediu de 20,25 dB. Majoritatea experimentelor indică drept optim un număr de 14 momente nule, însă există o variație a rezultatelor. Doar pentru două semnale EKG (119 și 123) se recomandă un număr mai mic de niveluri de descompunere pentru a păstra raportul optim între CR și SNR.

Rezultatele obținute au fost reprezentate grafic pentru o mai bună vizualizare în Fig. 4.49. Variația rezultatelor optime funcție de numărul de momente nule ridică problema existenței altor tipuri de funcții wavelet mamă pentru îmbunătățirea rezultatelor. În acest sens au fost considerate funcțiile wavelet biortogonale.

Tab. 4.7. Rezultatele optime obținute utilizând familia de funcții wavelet mamă Daubechies în urma aplicării metodei de compresie adaptivă

EKG	MW	CR	SNR [dB]	Nr. biți A5	Nr. biți d5	Nr. biți d4	Nr. biți d3	Nr. biți d2	Nr. biți d1
100	Db16	14,98	19,91	11	11	11	11	11	8
102	Db12	14,97	21,46	11	11	10	10	10	9
103	Db16	14,98	21,15	11	11	11	11	11	8
107	Db20	15,13	19,96	11	11	9	9	9	7
109	Db20	15,14	20,81	11	11	10	10	8	7
113	Db12	14,95	21,28	11	11	11	11	10	9
114	Db16	14,92	19,46	11	11	11	11	11	9
117	Db14	15,07	20,33	11	11	11	11	10	7
119	Db6	15,17	18,75	11	11	10	10	9	6
123	Db14	15,07	18,84	11	11	11	11	10	7
124	Db14	15,15	20,52	11	11	11	11	9	6
202	Db18	15,09	20,86	11	11	11	11	9	7
213	Db14	15,07	21,26	11	11	11	11	10	7
222	Db16	14,92	19,56	11	11	11	11	11	9
232	Db14	14,98	19,74	11	11	11	11	11	8




Fig.4.49 Distribuția rezultatelor funcție de numărul de momente nule.

Înainte de implementarea unui algoritm nou se recomandă efectuarea a mai multor teste pentru a optimiza parametrii și a obține o performanță cât mai bună. Astfel, performanțele algoritmului de compresie dezvoltat au fost testate de asemenea pe o bază de date conținând semnale EKG afectate de zgomot (cu un raport semnal-zgomot mic) pusă la dispoziție de MIT-BIH (MIT-BIH Noise Stress Test Database [63 – 64]). Baza de date a fost propusă pentru a evalua algoritmul într-o situație limită, care poate apărea uneori în cazul înregistrărilor EKG ambulatorii. Semnalele EKG testate au fost create adăugând zgomot peste două înregistrări curate (EKG 118 și 119) provenite de la baza de date MIT-BIH Arrhythmia [63]. Baza de date conține tipuri diferite de zgomot, precum zgomot electromiografic, deviație a liniei de bază sau distorsiuni cauzate de contactul necorespunzător al electrozilor de achiziție. Contrar simulărilor descrise anterior,

pentru calculul transformatei wavelet au fost selectate funcții wavelet mamă biortogonale. Funcțiile wavelet biortogonale prezintă suport compact, sunt simetrice și permit o bună reconstrucție utilizând filtrele de tip FIR [82].

Au fost luate în considerare mai multe familii de funcții wavelet biortogonale pentru a putea trage o concluzie referitor la parametrii optimi ai metodei. În cazul unui sistem de monitorizare de la distanță sau chiar a unui sistem de diagnosticare automată, parametrii trebuie să fie fixați înaintea achiziției electrocardiogramei. Deoarece se va lucra cu semnale zgomotoase și datorită imperfecțiunii măsurilor cantitative de evaluare precum factorul PRD (după cum a fost arătat în cap. 4.3.1), drept metodă de evaluare a performanței generale a algoritmului este propus factorul de îmbunătățire a raportului semnal-zgomot SNR_{imb} :

$$SNR_{imb} = SNR_{iesire} - SNR_{int rare} \quad (4.28)$$

Prin selecția corespunzătoare a parametrilor algoritmului de compresie, performanțele pot fi îmbunătățite, din această cauză fiind recomandată efectuarea unui număr semnificativ de simulări. Semnalul de intrare al sistemului de compresie va fi constituit de semnalul EKG asupra căruia au fost aplicate metodele de corecție a liniei de bază și de filtrare bazate pe analiza wavelet, metode descrise în cap. 4.1 și 4.2. Prima etapă de prelucrare a bazei de date afectate de zgomot constă în aplicarea metodei de corecție a deviației liniei de bază. Și pentru această etapă a fost testată performanța utilizând funcții wavelet mamă biortogonale. Funcția wavelet mamă bior4.4 a fost aplicată pe șapte niveluri de descompunere, urmărindu-se realizarea unui raport optim între un timp de prelucrare redus și o reconstrucție bună a semnalului analizat. Un exemplu al unei înregistrări EKG de cca. două minute (EKG-ul 119m12, având un raport semnal-zgomot SNR de 12 dB) este prezentat în fig. 4.50. Estimarea liniei de bază este marcată cu roșu în grafice. Analizând fig. 4.50 constatăm că linia de bază a fost corectată în zonele cu deviație pronunțată, noua linie de bază fiind mai apropiată de potențialul de 0 V decât cea originală.




Fig. 4.50 Semnalul EKG 119m12 (sus) după aplicarea metodei de corecție a liniei de bază bazată pe funcții wavelet biortogonale (jos).

Cea de-a doua etapă a algoritmului înaintea compresiei electrocardiogramelor constă în filtrarea EKG-ului pentru a reduce zgomotul de achiziție folosind metoda propusă în paragraful 4.2. Rezultatele obținute sunt prezentate în fig. 4.51.




Fig. 4.51 Semnalul EKG 119m12 (sus) după aplicarea metodei de filtrare folosind funcții wavelet biortogonale (jos).

Remarcăm eliminarea zgomotului electromiografic ca urmare a aplicării metodei de filtrare, fără distorsionarea componentelor utile ale EKG-ului. Cu toate că filtrul necesită îmbunătățiri pentru zone deosebit de afectate de zgomot, este posibilă o interpretare a semnalului EKG. Pentru exemplul considerat a fost utilizată funcția wavelet mamă bior1.3, selectată datorită asemănării sale cu un semnal EKG și aplicată pe șapte niveluri de descompunere. Semnalul de intrare al algoritmului de compresie va fi dat de semnalul EKG filtrat și corectat pentru a reduce erorile și a crește eficiența.




Fig. 4.52. Coeficienții wavelet rezultați prin aplicarea DWT pe cinci niveluri de descompunere asupra semnalului EKG 119m12.

Transformata wavelet discretă DWT va fi aplicată pe cinci niveluri de descompunere (fig. 4.52) și se va păstra rezoluția originală a EKG-urilor de la MIT-BIH. Coeficienții wavelet de aproximare A_5 și coeficienții wavelet de detaliu d_5 sunt cuantizați pe 11 biți. Numărul de biți utilizați pentru următoarele niveluri d_4, d_3, d_2, d_1 , rezultați în urma aplicării unei funcții wavelet mamă biortogonale sunt prezentați în tabelele 4.8 și 4.9.

În fig. 4.53 a fost realizat un zoom asupra unui segment arătând o bătaie ectopică a semnalului EKG, importantă din punct de vedere al diagnosticului pentru a ilustra performanța compresiei și reconstrucției semnalului. Analizând fig. 4.53, nu se remarcă distorsiuni vizibile ale semnalului EKG.




Fig. 4.53 Semnalul EKG filtrat (sus) și reconstruit după aplicarea metodei de compresie (jos).

Deoarece studiile anterioare au indicat o variație a factorului de compresie CR și a raportului semnal-zgomot SNR cu funcția wavelet mamă utilizată, au fost testate mai multe familii de funcții wavelet mamă biortogonale: Deslauriers Desl, funcțiile wavelet mamă biortogonale propuse de Daubechies CDF, Villasenor Vls. Rezultatele obținute sunt prezentate în tabelele 4.8 și 4.9.

Un semnal mai puternic afectat de zgomot este prezentat în fig. 4.54. Remarcăm reducerea deviației liniei de bază și reconstrucția bună a semnalului după compresie.

Tab. 4.8. Rezultatele simulării realizate pentru semnalul EKG 118em

EKG	Biort MW	SNR _{imb} [dB]	CR	Nr. biți D4	Nr. biți D3	Nr. biți D2	Nr. biți D1
118e 12m	Desl	4,44	14,94	11	11	10	9
	CDF1 .3	5,99	15,00	11	11	10	8
	CDF 2.4	5,79	15,11	10	10	9	7
	CDF 4.4	5,63	15,02	10	10	10	8
	V1s1	6,30	15,11	10	10	9	7
	V1s4	5,70	15,11	10	10	9	7
	Desl	9,24	14,89	11	11	10	10
118e 06m	CDF1 .3	9,49	15,05	10	10	9	8
	CDF 2.4	9,99	15,11	10	10	9	7
	CDF 4.4	9,70	15,05	10	10	9	8
	V1s1	10,3	15,05	10	10	9	8
	V1s4	9,95	15,13	10	10	8	7

Tab. 4.9. Rezultatele simulării realizate pentru semnalul EKG 119em

EKG	Biort MW	SNR _{imp} [dB]	CR	Nr. biți D4	Nr. biți D3	Nr. biți D2	Nr. biți D1
119 e12m	Desl	7,23	14,92	11	11	11	9
	CDF1.3	6,13	15,02	10	10	10	8
	CDF 2.4	6,81	15,11	10	10	9	7
	CDF 4.4	6,34	15,11	10	10	9	7
	V1s1	6,76	15,11	10	10	9	7
	V1s4	6,76	15,11	10	10	9	7
	Desl	11,86	14,94	11	11	10	9
119e0 6m	CDF1.3	10,91	15,05	10	10	9	8
	CDF 2.4	10,95	15,11	10	10	9	7
	CDF 4.4	10,80	15,05	10	10	9	8
	V1s1	11,37	15,11	10	10	9	7
	V1s4	11,37	15,11	10	10	9	7




Fig. 4.54 Semnalul EKG original (sus, negru), corectat (sus, albastru) și reconstruit după aplicarea metodei de compresie (jos).

Analizând rezultatele prezentate în tab. 4.8, se constată că algoritmul propus, bazat pe funcții wavelet biortogonale, produce un SNR mediu de 17,60 dB pentru fragmente zgomotoase ale semnalului EKG 118em (118em12, având un SNR de 12 dB) și un raport mediu îmbunătățit SNR_{imb} de 5,60 dB. În cazul fragmentelor puternic afectate de zgomot (EKG 118em06, având un SNR de 6 dB), algoritmul propus produce un SNR mediu de 15,78 dB având astfel un raport mediu îmbunătățit SNR_{imb} de 9,78 dB.

Analizând rezultatele prezentate în tab. 4.9, se constată că algoritmul propus produce un SNR mediu de 18,67 dB pentru fragmente zgomotoase ale semnalului EKG 119em (119em12, având un SNR de 12 dB) și un raport mediu îmbunătățit SNR_{imb} de 6,67 dB. În cazul fragmentelor puternic afectate de zgomot (EKG 119em06, având un SNR de 6 dB), algoritmul propus produce un SNR mediu de 17,21 dB având astfel un raport mediu îmbunătățit SNR_{imb} de 11,21 dB. Rezultatele medii obținute prezintă un factor de compresie de 15, algoritmul fiind mai stabil decât algoritmul care utilizează funcții wavelet mamă ortogonale. Considerând că alegerea celei mai potrivite funcții wavelet mamă trebuie făcută pe baza unui compromis între SNR și CR și analizând rezultatele obținute, se poate indica familia de funcții wavelet Villasenor drept cea mai potrivită. Mica variație a rezultatelor obținută pentru diferite elemente din cadrul acestei familii poate fi atribuită caracteristicilor semnalului de intrare. Aceasta nu trebuie să fie o surpriză deoarece elementele acestei familii au fost selectate cu ocazia concepției standardului de compresie a imaginilor JPEG 2000.

În literatură există lucrări care utilizează baza de date MIT-BIH Noise Stress Test Database pentru exemplificarea performanțelor metodelor de compresie. Astfel, de exemplu, algoritmul bazat pe filtrul Kalman EKF descris anterior în paragraful 4.1 poate fi utilizat și pentru compresia semnalelor [83]. Performanțele de reducere a zgomotului de achiziție a semnalului EKG sunt ilustrate în [83] utilizând baza de date MIT-BIH Noise Stress Test Database (denumită DB2) pentru semnalul 118em24, în timp ce date privind performanțele compresiei sunt furnizate pentru semnale aparținând bazelor de date MIT-BIH Arrhythmia (denumită DB3 în lucrarea [83]) și baza de date MIT-BIH Compression Test (denumită DB4 în [83]). Valorile factorului de compresie CR variază între $13,65 \pm 2,92$ (DB4, EKF17), 18,75 (ECG 231, DB3, EKF20) și 24,49 (ECG 123, DB3, EKF20), în funcție de asemenea de numărul de bătăi [83]. Având în vedere faptul că rezultatele prezentate în tab. 4.8 și 4.9 au fost obținute utilizând semnale EKG de intrare puternic afectate de zgomot pentru a testa limitele algoritmului propus, un factor de compresie CR în jurul valorii de 15 poate fi considerat drept competitiv.

În tabelul de mai jos sunt prezentate rezultatele obținute utilizând familia de funcții wavelet Villasenor asupra celor 15 semnale EKG prezentate anterior, pentru a putea realiza o comparație între utilizarea funcțiilor wavelet mamă ortogonale respectiv a funcțiilor wavelet mamă biortogonale.

Tab. 10. Rezultatele optime obținute utilizând familia de funcții wavelet mamă Villasenor în urma aplicării metodei de compresie adaptivă

EKG	MW	CR	SNR [dB]	Nr.	Nr.	Nr.	Nr.	Nr.
				biți d5	biți d4	biți d3	biți d2	biți d1
100	Vls2	14,98	20,68	11	11	11	11	8
102	Vls2	14,95	21,39	11	11	11	10	9
103	Vls2	14,98	21,45	11	11	11	11	8
107	Vls4	15,11	19,77	11	9	10	9	7
109	Vls2	15,11	20,25	11	10	10	9	7
113	Vls1	14,92	21,73	11	11	11	11	9
114	Vls1	14,92	17,89	11	11	11	11	9
117	Vls2	15,07	18,17	11	11	11	10	7
119	Vls1	15,11	20,12	11	10	10	9	7
123	Vls1	7,82	21,13	-	11	10	8	5
124	Vls2	15,15	21,74	11	11	11	9	6
202	Vls5	15,09	20,35	11	11	11	9	7
213	Vls2	15,07	22,23	11	11	11	10	7
222	Vls2	14,92	19,64	11	11	11	11	9
232	Vls1	7,81	19,54	-	11	10	8	6

În urma testării metodei de compresie asupra celor 15 semnale EKG, s-a obținut un factor de compresie CR mediu de 14,07 pentru un SNR mediu de 20,40 dB. Majoritatea experimentelor indică drept optim un număr de 2 momente nule (fig. 4.55), punând în evidență importanța localizării temporale a semnalelor EKG. Comparând tab. 4.7 cu tab. 4.10, se remarcă obținerea unui factor de compresie mediu mai ridicat în cazul utilizării funcțiilor wavelet mamă ortogonale, deoarece în cazul a două semnale EKG (123 și 232) pentru a păstra un raport bun între CR și SNR au fost utilizate doar patru niveluri de descompunere și nu cinci precum în celelalte cazuri. SNR prezintă valori ridicate în cazuri individuale atunci când sunt utilizate funcțiile wavelet mamă biortogonale (semnalele EKG 113, 124, 213), însă pe ansamblu algoritmul este mai eficient (raportul între factorul de compresie și raportul semnal-zgomot fiind mai bun) în cazul funcțiilor wavelet ortogonale din familia Daubechies.




Fig. 4.55. Distribuția rezultatelor obținute funcție de numărul de momente nule.

Rezumat 4.3.2

Metoda de compresie propusă permite obținerea unui factor de compresie semnificativ fără a distorsiona componentele utile ale semnalului EKG analizat. Metoda de compresie adaptivă propusă utilizează proprietatea de codare în subbenzi a DWT, obținându-se astfel un factor de compresie mai bun decât în cazul metodei propuse în paragraful 4.3.1. Fiecare subbandă de detaliu a fost tratată independent, valoarea de prag fiind stabilită în funcție de deviația standard a subbenzii respective. S-a propus de asemenea un algoritm de optimizare a performanțelor care să țină cont de principalii parametri: funcția wavelet mamă, numărul de momente nule, numărul de niveluri de descompunere.

Metoda a fost testată pe 15 semnale EKG din baza de date MIT-BIH Arrhythmia, fiind testate mai multe familii de funcții wavelet mamă ortogonale și biortogonale. Cele trei proceduri de prelucrare a semnalului EKG, necesare unui sistem de monitorizare de la distanță a activității cardiace a inimii (corecția deviației liniei de bază a EKG-ului, filtrarea zgomotelor de achiziție și compresia semnalului) au fost testate utilizând atât funcții wavelet biortogonale cât și ortogonale. A fost

selectat un număr redus de niveluri de descompunere, pentru a se obține un timp de prelucrare redus și o reconstrucție bună a semnalului.

Algoritmul a fost testat și în situații limită, utilizând electrocardiograme afectate puternic de zgomot. Metoda de corecție a liniei de bază a oferit rezultate bune în cazul utilizării funcțiilor wavelet mamă biortogonale, metoda de denoising a permis înlăturarea zgomotului electromiografic iar rezultatele compresiei au arătat un factor de compresie competitiv, avantajul metodei constând în efortul computațional redus. Deci un algoritm adaptiv de compresie bazat pe analiza wavelet este potrivit în prelucrarea semnalelor EKG.

4.4. Detecția complexului QRS al electrocardiogramelor

Diagnosticul medical poate fi pus în baza unei inspecții vizuale a electrocardiogramei în timpul unei monitorizări EKG. Cu toate acestea, anomalii ale semnalului EKG pot avea loc la orice moment de timp, și nu în mod necesar în timpul unei inspecții scurte de rutină. Astfel, un sistem de monitorizare de la distanță cuplat cu un sistem de diagnosticare automată, ar putea reprezenta o soluție pentru a detecta în timp util bolile cardiace [84]. Ritmul de succesiune și forma segmentelor componente ale semnalului EKG standard (fig. 4.56): unda P, complexul QRS și unda T, conțin informații medicale utile. Șansa de a detecta anomalii în timp util crește pentru pacienții a căror activitate este monitorizată constant în mediul casnic sau la serviciu în timpul efectuării activității, complexul QRS conținând primele informații despre frecvența cardiacă. Deși sistemul de monitorizare de la distanță constituie tema principală a prezentei teze de doctorat, a fost elaborată și propusă și o metodă de detecție a complexului QRS, datele obținute în urma detecției pot fi de asemenea transmise la distanță pentru a facilita munca medicului. În linii mari, metoda este bazată pe un algoritm de detecție iterativă corelat cu trăsăturile caracteristice ale complexului QRS și combinat cu metode wavelet de validare a rezultatelor obținute.

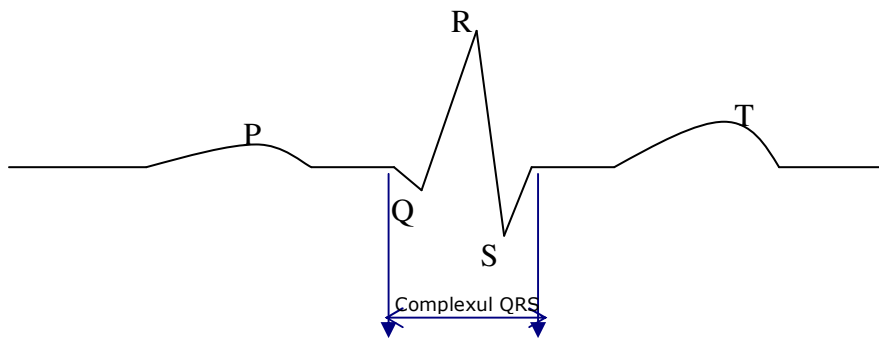


Fig. 4.56. Semnal EKG standard

Trăsăturile caracteristice ale complexului QRS vor sta la baza elaborării unui algoritm de detecție a formei de undă. Complexul QRS caracterizează ritmul de depolarizare a ventriculelor, constituind în același timp și unda cea mai caracteristică a semnalului EKG. Este alcătuit din trei elemente, două unde negative și o componentă pozitivă de mare amplitudine (unda R). Este urmată de segmentul ST, care corespunde la repolarizarea lentă a ventriculelor. Complexul QRS prezintă

cea mai mare amplitudine (1-2 mV) dintr-o bătaie conținută în electrocardiogramă, mascând repolarizarea atriilor. Durata normală este cuprinsă între 0,08 – 0,10 s. Metoda de detecție a complexului QRS propusă a fost dezvoltată în primă fază ținând cont de caracteristicile unui EKG normal, standard. Detecția undei R ar trebui de asemenea să permită determinarea ritmului cardiac. Semnalul original este împărțit în blocuri de lungime egală, care ar trebui să cuprindă o bătaie cardiacă. Astfel, numărul de eșantioane corespunzătoare unei bătaii a fost calculat luând în considerare un puls mediu cuprins în intervalul (60, 80) bătaii/minut raport care ar trebui să corespundă la (0.75, 1) bătaii/secundă. Inversul frecvenței fundamentale a EKG-ului, perioada fundamentală T_{EKG} , poate fi determinată măsurând pulsul pacientului. Vom lua în calcul un puls mediu cu T_{EKG} în jurul valorii de 1s. Frecvența de eșantionare a bazei de date MIT-BIH Arrhythmia Database, pe care va fi testată metoda de detecție propusă este de 360 Hz, astfel: $n = 360$, unde n reprezintă numărul de eșantioane conținut într-o bătaie de inimă standard.

Structura metodei de detecție a complexului QRS este prezentată în fig. 4.57.

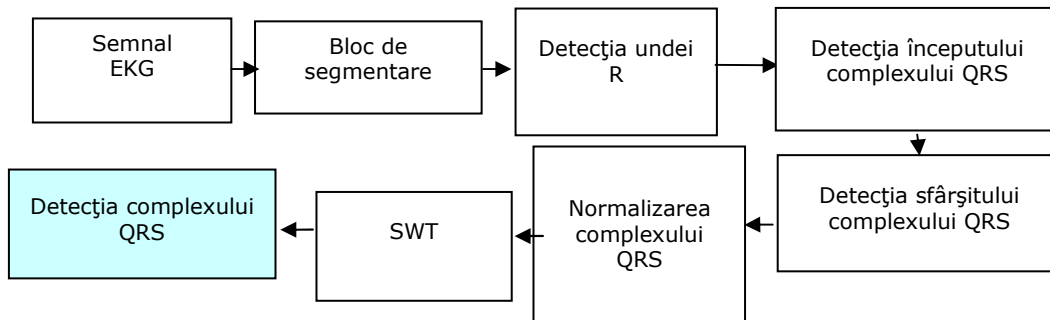


Fig. 4.57 Arhitectura sistemului de detecție a complexului QRS.

Se remarcă faptul că, dintre componentele constituente ale semnalului EKG, complexul QRS prezintă panta cea mai accentuată, metoda propusă detectează maximul local al fiecărui bloc obținut după segmentare, maxim care trebuie să corespundă undei R. De asemenea, deoarece localizarea temporală este importantă în cazul analizei semnalelor EKG, se va detecta astfel și momentul de timp corespunzător vârfului detectat.

Soluția prezentată urmărește o implementare rapidă a algoritmului. Următoarea etapă a metodei propuse, după detecția undei R, constă în realizarea segmentării propriu-zise prin detecția limitelor care mărginesc complexul QRS. Începutul și sfârșitul formei de undă QRS vor fi detectate luând în considerare localizarea vârfului R al complexului. Metoda propusă găsește în mod iterativ începutul complexului QRS:

- Se inițializează valoarea de început cu valoarea vârfului undei R:

$$QRS_{inceput} = val(R_{unda}), \quad (4.29)$$

- Se caută în mod iterativ momentul de început al complexului QRS normal, comparând fiecare valoare cu cea anterioară până când se atinge punctul de minim din stânga vârfului undei R, prima valoare care nu mai corespunde condiției impuse sfârșind iterația:

$$\begin{aligned} \text{dacă } val(R_{unda}) > val(R_{unda} - 1) \\ \text{atunci } QRS_{inceput} = val(R_{unda} - 1) \end{aligned} \quad (4.30)$$

În mod asemănător se procedează și pentru a găsi punctul terminus al complexului QRS:

- Se inițializează valoarea de început cu vârful undei R:

$$QRS_{sfarsit} = val(R_{unda}), \quad (4.31)$$

- Se caută în mod iterativ momentul de sfârșit al complexului QRS comparând fiecare valoare cu cea următoare până se atinge punctul de minim din dreapta vârfului undei R:

$$\begin{aligned} \text{dacă } val(R_{unda} + 1) < val(R_{unda}) \\ \text{atunci } QRS_{sfarsit} = val(R_{unda} + 1) \end{aligned} \quad (4.32)$$

Etapa următoare constă în verificarea duratei de timp a unui complex QRS standard, care, conform datelor prezentate anterior, ar trebui să cuprindă cca. 36 eșantioane în cazul bazei de date de la MIT-BIH Arrhythmia, considerând durata maximă de 0.10 s pentru a elimina posibile erori de detecție. Numărul necesar de eșantioane va fi calculat pentru fiecare bloc de segmentare, scăzând numărul de eșantioane cuprinse între cele două puncte de minim amintite anterior și distribuind simetric între cele două limite detectate eșantioanele calculate. Astfel metoda de detecție a complexului QRS poate fi considerată drept o metodă adaptivă.

Transformata Wavelet Staționară SWT poate reprezenta un mijloc de validare a rezultatelor obținute în urma aplicării metodei de detecție propusă. Structura de descompunere a algoritmului urmează structura propusă de Shensa și a fost descrisă mai detaliat în paragraful. 4.1. Coeficienții wavelet de aproximare A_i rezultați la ieșirea filtrului trece-jos conțin componentele de joasă frecvență ale semnalului EKG, descriind tendința generală și variațiile lente ale semnalului în timp. Expresia coeficienților este redată, pentru cel de al i -ilea nivel de descompunere, prin următoarea formulă:

$$A_i(n) = \langle s_{ECG}(t), \varphi_i(t) \rangle, \quad s_{ECG} \forall \in L^2(R), \quad a, b \in Z, \quad (4.33)$$

unde $\varphi_{a,b}(t)$ este o funcție de scară.

În cazul în care rezultatele obținute în urma metodei de segmentare sunt validate de trei niveluri consecutive de descompunere, detecția complexului QRS se consideră realizată. SWT a fost selectată pentru validare datorită proprietății sale de invarianță la translație. Metodele de detecție a complexului QRS întâlnite în studiile bibliografice întreprinse, utilizează DWT [85], filtrare trece-bandă pentru a izola complexul QRS [86] sau combinații ale analizei wavelet cu modele statistice de tip *Hidden Markov Models* (HMM) [87]. În cazul metodei propuse în acest paragraf se face segmentarea semnalului EKG inițial cu procedura descrisă mai sus și apoi validarea acestei segmentări utilizând Transformata Wavelet Staționară SWT, luând în considerare și un pas de normalizare a complexului QRS detectat pentru a reduce posibile erori, datorate frecvenței mici de eșantionare a electrocardiogramei din baza de date MIT-BIH Arrhythmia [57], [88].

Prima etapă algoritmului de detecție a complexului QRS propus constă în aplicarea algoritmilor de reducere a deviației liniei de bază (paragraful. 4.1) și de reducere a zgomotelor de achiziție (paragraful. 4.2) a electrocardiogramelor. Durata medie a complexului QRS este de 0,10 s și corespunde la un număr de 36 de eșantioane, considerând frecvența de eșantionare de 360 eșantioane/s. În limitele acestui interval trebuie găsit începutul și sfârșitul complexului QRS. Informațiile detectate pot fi transmise la distanță și supuse validării medicului. Fig. 4.58a prezintă trei bătăi ale semnalului EKG original de intrare, 113 din baza de date MIT-BIH Arrhythmia. Semnalul este împărțit în blocuri de lungime egală, fiecare corespunzând unei bătăi. Semnalul EKG este filtrat pentru a reduce zgomotele de achiziție, deviația liniei de bază este redusă și maximul local al fiecărui bloc este detectat. Rezultatul este prezentat cu roșu în fig. 4.58b. Se remarcă faptul că unda R a fost detectată corect. Următorul pas al metodei de segmentare constă în detecția limitelor complexului QRS. Utilizând algoritmul iterativ prezentat, începutul și sfârșitul complexului QRS sunt determinate luând în considerare localizarea temporală a undei R. Punctele de minim fiind astfel localizate, se poate determina numărul de eșantioane dintre aceste valori extreme iar numărul de eșantioane necesar pentru a completa o durată standard a unui complex QRS este distribuit simetric la stânga și la dreapta celor două puncte de minim. Rezultatul este validat în cazul în care metodologia descrisă poate fi aplicată corect pe primele trei niveluri de descompunere ale SWT pentru coeficienții de aproximare. Au fost aleși coeficienții de aproximare datorită capacității lor de a conserva majoritatea energiei semnalului analizat. SWT a fost calculată utilizând funcția wavelet mamă Daubechies1, rezultatele fiind prezentate în fig. 4.59, pentru o bătăie a semnalului EKG 113.




Fig. 4.58a) Semnalul EKG 113.







Fig. 4.58b) Semnalul EKG 113 după detecția undei R.






Fig. 4.59d) Coeficienții wavelet pentru al treilea nivel de aproximare.

Rezultatul final pentru cele trei bătăi prezentate în fig. 4.58a, este prezentat în fig. 4.60, unda R fiind marcată cu roșu iar începutul și sfârșitul complexului QRS cu verde.




Fig. 4.60. Detecția complexului QRS pentru semnalul EKG 113.

Performanța algoritmului de detecție a complexului QRS a fost testată utilizând semnale EKG diferite din baza de date MIT-BIH Arrhythmia, rezultatele obținute fiind prezentate în fig. 4.61 și 4.62, pentru semnalul EKG 107 respectiv 117.

Se remarcă faptul că pentru semnale care diferă de semnalul EKG standard, rezultatele sunt mai puțin clare atunci când sunt comparate cu semnalul EKG standard ilustrat în fig. 4.56.

Pentru a depăși limitările impuse de situația din fig. 4.61a, metoda propusă poate fi în continuare dezvoltată, adăugând un nivel de prag pentru componentele negative Ng ale complexului QRS. În cazul în care acest prag este depășit, se poate calcula minimul local, care ar trebui să corespundă componentei negative și să se găsească în mod iterativ sfârșitul complexului QRS:

$$QRS_{sfarsit} = val(Ng) \quad (4.34)$$

$$\begin{aligned} & \text{dacă } QRS_{sfarsit} < val(Ng + 1) \\ & \text{atunci } QRS_{sfarsit} = val(Ng + 1) \end{aligned} \quad (4.35)$$

Rezultatul obținut aplicând algoritmul completat cu pragul Ng asupra semnalului EKG 107 este prezentat în fig. 4.61b.




Fig.4.61a Rezultatul algoritmului de detecție al complexului QRS pentru semnalul EKG 107.




Fig. 4.61b. Rezultatul algoritmului de detecție al complexului QRS pentru semnalul EKG 107 utilizând algoritmul completat cu pragul Ng .




Fig. 4.62. Rezultatul algoritmului de detecție al complexului QRS pentru semnalul EKG 117.

Rezumat 4.4

Semnalul EKG oferă informații utile despre starea de funcționare a inimii pe baza analizei activității cardiace prin intermediul formei, amplitudinii și intervalelor de timp dintre undele componente ale fiecărei bătăi de inimă. Complexul QRS prezintă cea mai mare pantă, constituind în același timp o undă caracteristică a semnalului EKG. Deși nu reprezintă obiectivul principal al prezentei teze de doctorat, detecția automată a complexului urmărește crearea unei facilități care să ajute munca medicului. Algoritmul propus combină metode clasice iterative cu metode mai recente bazate pe analiza wavelet, prin utilizarea SWT. Semnalul de intrare este inițial corectat din punct de vedere al deviației liniei de bază (utilizând algoritmul prezentat în paragraful 4.1) și filtrat (utilizând algoritmul prezentat în paragraful 4.2). Aceste pre-tratamente sunt importante, deoarece facilitează detecția undei R, utilizând un detector de maxim. Metoda propune detecția undei R utilizând o singură etapă și luând în considerare caracteristicile formei de undă analizate: maximul local al fiecărui bloc de segmentare este detectat, localizarea temporală a vârfului detectat fiind de asemenea reținută pentru aplicații ulterioare ale algoritmului. Localizarea în timp este importantă pentru semnalele biologice, precum semnalul EKG, iar această proprietate este exploatată în detectarea limitelor de început și de sfârșit ale complexului QRS. Atât începutul cât și sfârșitul complexului QRS sunt detectate apelând la localizarea temporală a undei R detectată anterior, metoda de detecție putând fi considerată astfel adaptivă. Numărul de eșantioane necesare pentru o durată standard a complexului QRS este distribuit în mod simetric la stânga și la dreapta celor două puncte de minim care încadrează vârful undei R determinându-se începutul și sfârșitul complexului QRS. Ultima etapă constă în evaluarea rezultatelor metodei utilizând analiza wavelet pentru a evita erori de detecție sau detecții false, rezultatele fiind considerate valide (conform studiului bibliografic [87]) dacă pot fi aplicate pe trei niveluri succesive de descompunere. Rezultatele au fost prezentate în fig. 4.60, 4.61, 4.62 și evaluate prin comparație cu forma standard a semnalului EKG (fig. 4.56).

5. PRELUCRAREA SEMNALULUI MKG

Stagiul de cercetare științifică efectuat la Universitatea Tehnică din Ilmenau, Germania sub coordonarea Univ.Prof. Dr.Ing. habil. Hannes TÖPFER și Dr.Ing. Hartmut BRAUER și în colaborare cu dr. Ronny STOLZ de la IPHT (*Institut fuer Photonische Technologien*), Jena, Germania a oferit posibilitatea de a studia un tip de semnale biologice asemănătoare semnalelor EKG, și anume semnalele MKG.

5.1. Reducerea deviației liniei de bază a semnalului MKG

De regulă, semnalele EKG și MKG sunt afectate de zgomote biologice datorate respirației sau mișcării pacientului (în special în cazul semnalelor prelevate de la făt) sau de interferențe datorate rețelei electrice sau altor aparate electronice. Unul din efectele acestor perturbații va consta în deviația liniei de bază a semnalelor EKG sau MKG, crescând astfel riscul de a pune un diagnostic incorect. Semnalele MKG diferă de cele EKG, nu prin conținutul informațional, ci prin modul de achiziție al datelor: se utilizează senzori plasați la o anumită distanță de corp și nu în contact direct, precum în cazul electrozilor EKG. În acest caz, intensitatea câmpului magnetic generat de activitatea electrică a inimii este foarte mică și trebuie utilizați senzori speciali de tip Superconductive Quantum Interference Devices (SQUID) pentru a capta semnalele.

Principala diferență între semnalele EKG și MKG provine din modul lor diferit de achiziție. În cazul semnalelor EKG, traductorul este în contact cu pielea pacientului și măsoară componenta electrică a câmpului electromagnetic generat de inimă, în timp ce în cazul semnalelor MKG, traductorul nu este în contact cu pielea pacientului și măsoară componenta magnetică a câmpului electromagnetic generat de inimă (fig. 5.1). Datorită lipsei contactului direct, semnalul MKG este mai potrivit decât semnalul EKG pentru analiza activității inimii fătului.

Analizând semnalele MKG (fig. 5.2) se pot remarca interferențe datorate aparatului electronic și rețelei electrice existente în încăperea în care se efectuează măsurătorile. La efectuarea măsurătorilor în medii necranate, sistemul de tip SQUID este sensibil la interferențele magnetice și trebuie dezvoltate proceduri de prelucrare care să îmbunătățească performanța sistemului de achiziție. În cazul semnalelor MKG studiate pe parcursul stagiului de cercetare în Germania, pot fi observate interferențe și perturbații cauzate de influența câmpurilor magnetice exterioare, cum ar fi de exemplu influența exercitată de rețeaua de alimentare cu energie electrică de 50 Hz.

Metoda de reducere a zgomotelor de achiziție dezvoltată de Institutul IPHT din Jena este prezentată pe scurt în continuare. Inițial, un algoritm care face apel la metoda celor mai mici pătrate este utilizat la construcția semnalului de gradiometru de ordin doi, prin scăderea semnalului de la gradiometrul de referință G3 din

semnalele de la gradiometrele de măsură G1 sau G2. Aceași procedură este aplicată și în cazul magnetometrelor.




Fig.5.1 Măsurare MKG în timp real (IPHT, Jena).

Semnalelor rezultate li se aplică transformata Fourier rapidă (Fast Fourier Transform-FFT) în scopul reducerii zgomotului de achiziție prin filtrare în domeniul frecvență [16].

Unul dintre avantajele utilizării FFT constă în posibilitatea de a examina distribuția spectrală a semnalului analizat. În continuare se face referire la semnale MKG fetale, deoarece acestea prezintă un raport semnal – zgomot mai redus, fiind mai potrivite pentru exemplificarea performanțele metodelor de filtrare aplicate. De regulă, este dificilă estimarea poziției exacte a inimii fătului astfel încât semnalele înregistrate să nu fie afectate de zgomot biologic.

În figura 5.2 este prezentată forma de undă a unui semnal de tip MKG, pus la dispoziție de IPHT-Jena, conținând atât semnalul fetal cât și cel matern.




Figura 5.2. Semnal MKG inițial.

În fig. 5.3 este prezentat spectrul zgomotului care perturbă semnalul din figura 5.2. Frecvența fundamentală f_{MKG} a semnalului MKG poate fi estimată

măsurând pulsul matern. Pacienții adulți sănătoși au un puls de cca. 60-80 bătăi/min, feții au un puls un pic mai ridicat. Semnalul analizat fiind mixt, conținând atât semnal fetal cât și matern, vom considera f_{MKG} situată în jurul frecvenței de 1 Hz. În fig. 5.3 putem observa valori foarte mari la frecvența de 50 Hz, sugerând interferențe magnetice serioase din partea rețelei electrice.




Figura 5.3. Componentele spectrale ale semnalului MKG.

După filtrare, spectrul obținut este transformat în domeniul timp prin aplicarea transformatei Fourier rapide inverse. În urma aplicării metodei de filtrare în domeniul frecvență bazată pe analiza Fourier, elaborată de IPHT-Jena se obține semnalul din figura 5.4. Se remarcă faptul că acest rezultat conține deviații ale liniei de bază.




Figura 5.4. Rezultatul procedurii de filtrare în domeniul frecvență.

În figura 5.5 se prezintă primele cinci bătăi ale semnalului MKG filtrat. Se constată că procedura de filtrare în domeniul frecvență nu este perfectă, fiind necesară aplicarea în continuare a unor metode de corecție a liniei de bază și de reducere a zgomotului de achiziție a semnalului MKG.




Figura 5.5. Cinci bătăi ale semnalului MKG filtrat utilizând FFT.

În cazul unui sistem automat de diagnosticare, deviația liniei de bază a semnalului analizat trebuie înlăturată sau redusă pentru a asigura buna desfășurare a etapelor următoare de prelucrare a semnalului MKG, cum ar fi segmentarea automată. În acest paragraf va fi descrisă o metodă bazată pe analiza wavelet, care a fost aplicată anterior la semnale EKG [89].

Această metodă efectuează o analiză multirezoluție (multiresolution analysis - MRA). MRA permite identificarea proprietăților unui semnal $x(t)$ la diferite rezoluții. Procedura este utilă pentru analiza semnalelor biologice afectate de zgomot, precum semnalele MKG și EKG: aspectul general al acestor forme de undă putând fi observat la rezoluții mai grosiere, în timp ce detaliile și caracteristicile distinctive ale acestor forme de undă pot fi observate la rezoluții mai fine. De regulă, implementarea MRA se bazează pe algoritmul lui Mallat (corespunzător calcului transformatei wavelet discrete - DWT), dar utilizarea decimatorilor la fiecare nivel de descompunere produce descreșterea lungimii secvențelor de coeficienți odată cu creșterea numărului de niveluri de descompunere. Acest dezavantaj poate fi înlăturat utilizând algoritmul propus de Shensa, algoritmul care corespunde transformatei wavelet staționare - SWT). SWT este calculată utilizând în mod repetat filtre trece-sus (HP_k) și filtre trece-jos (LP_k) pentru a afla coeficienții care caracterizează un semnal dat, urmărind algoritmul propus de Shensa după cum a fost descris și în capitolul 4.1. La fiecare nivel de descompunere k , se obțin o serie de coeficienți denumiți de aproximare (app_k) și o serie de coeficienți de detaliu (det_k). Aceștia pot fi percepuți drept componentele de joasă frecvență (app_k) respectiv componentele de înaltă frecvență (det_k) ale magnetocardiogramelor.

Deviațiile liniei de bază a semnalelor MKG apar ca urmare a perturbării achiziției acestora. Există mai multe surse ale acestor perturbații.

În primul rând se poate vorbi despre perturbațiile datorate liniei de alimentare cu energie electrică, deoarece traductorul folosit nu este ecranat.

Intensitatea câmpului magnetic produs de aceste perturbații este de multe ori mai mare decât intensitatea câmpului magnetic produs de inima mamei respectiv decât intensitatea câmpului magnetic produs de inima fătului.

În al doilea rând se poate vorbi despre perturbații produse de mișcarea pacientului (analiza semnalului MKG fiind interesantă mai ales cu ocazia nașterilor). Nu există metode neinvazive care să constrângă fătul să nu se miște pe durata achiziției semnalului MKG. În sfârșit se poate vorbi despre perturbațiile specifice pentru orice sistem de achiziții de date, cum ar fi zgomotul propriu al amplificatorului de la ieșirea traductorului, zgomotul de cuantizare, ș.a.m.d.

Linia de bază a semnalelor MKG ar trebui să fie constantă în timp și nu cu variații așa cum se remarcă în cazul semnalelor din fig. 5.6.




Figura 5.6. Estimarea liniei de bază utilizând undișoara mamă Daubechies2.

Semnalul MKG achiziționat și prezentat în fig. 5.6 are o deviație evidentă a liniei de bază, crescând riscul punerii unui diagnostic incorect. În consecință, trebuie dezvoltate metode de a preveni acest risc.

Metoda propusă este prezentată în figura 5.7, utilizează SWT și cuprinde următorii patru pași:

1. Calculul SWT al semnalului MKG;
2. Anularea coeficienților de detaliu rezultați;
3. Aplicarea transformatei wavelet staționare inverse (ISWT), obținându-se astfel o estimare a deviației liniei de bază;
4. Înlăturarea deviației liniei din bază a semnalului MKG prin scăderea estimatei calculate din semnalul original.

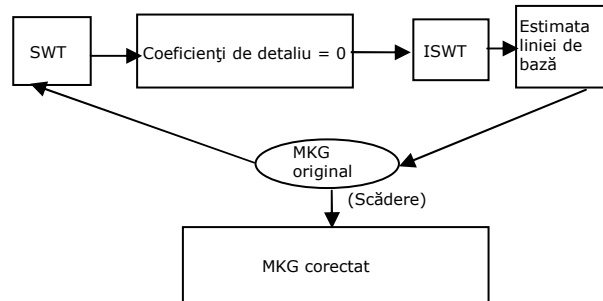


Fig. 5.7. Schema metodei de corecție a liniei de bază.

Rezultatul metodei propuse de reducere a deviației liniei de bază a semnalului MKG din fig. 5.6 este prezentat în fig. 5.8.




Figura 5.8. Rezultatul metodei de corecție a deviației liniei de bază a semnalului MKG.

Această procedură de corecție a liniei de bază poate fi asociată cu o filtrare trece-jos, coeficienții de detaliu rezultați prin filtrare trece-sus fiind eliminați. Metoda de proiectare a acestui filtru trece-jos a fost analizată în [89].

O cerință importantă a sistemului de corecție a liniei de bază este invarianța în timp a sistemului de estimare a liniei de bază, deoarece acest semnal este scăzut din semnalul MKG original. Din acest motiv, SWT (care este invariantă la translații) a fost preferată în locul DWT (care nu este invariantă la translații). Sistemul SWT este invariant în timp reprezentând o colecție de filtre liniare și invariante în timp. Totuși, SWT are și dezavantaje. Numărul de calcule necesar pentru implementarea SWT este mai mare decât numărul de calcule necesar pentru implementarea DWT, lungimea secvenței obținute utilizând SWT fiind mai mare decât lungimea secvenței originale (pe când lungimea secvenței obținute utilizând DWT este egală cu lungimea secvenței originale). Cu toate acestea, SWT constituie o metodă de analiză mai flexibilă decât DWT, metoda de corecție a deviației liniei de bază a semnalelor MKG propusă fiind robustă.

Performanța metodei propuse este asigurată prin selecția corespunzătoare a caracteristicilor principale ale SWT: funcția wavelet mamă și numărul de iterații K .

În cazul metodei de corecție a liniei de bază a semnalelor MKG, cele mai bune rezultate se obțin dacă se folosesc funcții wavelet mamă cu o bună localizare timp-frecvență, cum ar fi de exemplu funcția wavelet mamă Daubechies 2 [58].

Referitor la numărul de niveluri de descompunere K , trebuie îndeplinite două condiții importante. În primul rând, numărul de niveluri de descompunere a semnalului MKG trebuie selectat în concordanță cu frecvența de eșantionare f_s a semnalului MKG astfel încât componentele spectrale ale semnalului util din compoziția semnalului achiziționat să nu fie perturbate. Frecvența de tăiere a filtrului trece-jos echivalent trebuie să fie mai mare sau egală cu frecvența fundamentală a semnalului MKG, pentru a menține integritatea spectrală a componentei utile a semnalului achiziționat. Inversul frecvenței fundamentale a semnalului MKG, perioada fundamentală T_{MKG} , poate fi determinată măsurând pulsul pacientului. Adulții au de regulă un puls între 60-80 bătăi/minut, în cazul fetoșilor pulsul fiind un pic mai mare în funcție de vârsta gestațională. Semnalul fătului și al mamei fiind amestecate în momentul achiziției semnalului, vom considera valoarea T_{MKG} situată în jurul valorii de 1 s.

Rezoluția temporală la nivelul de descompunere K (specifică pentru analiza multirezoluție asociată SWT) trebuie să fie mai mare sau egală cu valoarea T_{MKG} :

$$\frac{2^K}{f_s} \geq T_{MKG}. \quad (5.1)$$

Cea de-a doua condiție de selecție a numărului de iterații K se referă la necesitatea nedistorsionării semnalului constituit de linia de bază. Principala dificultate provine din faptul că banda acestui semnal nu este a priori cunoscută. Așa după cum arată condiția (5.1) ar fi necesară o valoare cât mai mare pentru K . Dar frecvența de tăiere a filtrului trece-jos echivalent scade cu creșterea lui K . Lățimea benzii semnalului constituit de linia de bază nefiind cunoscută, spectrul acestuia ar putea fi afectat de selecția unei valori prea mari pentru K . De aceea, în cazul metodei de corecție a liniei de bază propusă, se folosește cea mai mică valoare a lui K care permite satisfacerea condiției (5.1). Întrucât pentru eșantionarea semnalelor MKG s-a folosit o frecvență de eșantionare de 1 kHz a rezultat în urma aplicării condiției (5.1) un număr de iterații egal cu 10.

Soluția prezentată ia în considerare o valoare medie a lui T_{MKG} , dar o alegere adaptivă a numărului nivelurilor de descompunere K ar putea compensa variațiile posibile ale frecvenței fundamentale a semnalelor MKG.

Metoda de corecție a liniei de bază propusă conduce la construcția unor filtre trece-jos echivalente foarte selective. Rezultate similare cu cel prezentat în figura 5.8 au fost obținute utilizând funcțiile wavelet mamă Symmlet 8 sau Coiflet 4, care au de asemenea o bună localizare timp-frecvență. Pentru a compara metoda de corecție a liniei de bază bazată pe funcții wavelet cu metoda de filtrare în domeniul frecvență propusă la Jena, s-a aplicat metoda propusă în acest paragraf asupra semnalului MKG din figura 5.2, obținându-se rezultatul din figura următoare. Comparând forma de undă din fig. 5.9 cu forma de undă din fig. 5.4, se poate constata superioritatea metodei de corecție a fluctuațiilor liniei de bază a semnalului MKG bazată pe folosirea funcțiilor wavelet. Observăm că linia de bază a semnalului MKG este mai aproape de 0 pentru zonele cu deviație mare, decât în cazul prezentat în fig. 5.4.




Figura 5.9. Rezultatul procedurii de corecție a liniei de bază utilizând analiza wavelet și 10 niveluri de descompunere.

Necesitatea de a prelucra în continuare semnalul, pentru a înlătura și restul zgomotului, poate fi observată în figura următoare. Estimarea liniei de bază a fost reprezentată cu roșu și este ilustrată în fig. 5.10a, în timp ce rezultatul corecției deviației de bază este ilustrat în fig. 5.10b. Observăm că noua linie de bază este apropiată de zero la orice moment de timp.




Figura 5.10. Cinci bătăi ale semnalului MKG înainte (a) și după corecția liniei de bază (b).

Au fost testate mai multe funcții wavelet mamă pentru a studia influența asupra corecției deviației liniei de bază. Rezultate bune au fost obținute și cu funcții wavelet aparținând familiei Coiflet sau Symmlet: Coiflet4 sau Symmlet8.

Deiferențele pot fi observate în special în zonele prezentând o deviație mai pronunțată a liniei de bază. În fig. 5.11 a fost realizată o comparație între rezultatele obținute utilizând funcția wavelet mamă Haar (Daubechies1) și funcția wavelet mamă Coiflet4. Rezultatele pot fi mai bine apreciate printr-o mărire a zonei cu deviație pronunțată, marcată pe graficul din fig. 5.11.

În fig. 5.12, rezultatul obținut folosind funcția wavelet mamă Haar a fost reprezentat cu roșu, iar rezultatul obținut folosind funcția wavelet mamă Coiflet4 cu albatru. Remarcăm faptul că linia de bază corectată utilizând funcția wavelet Haar este mai apropiată de 0, dar a fost preferată funcția wavelet Coiflet4 pentru a reduce riscul introducerii unor discontinuități în semnal.




Fig.5.11a) Rezultatul metodei de reducere a deviației liniei de bază utilizând funcția wavelet mamă Haar




Fig.5.11b) . Rezultatul metodei de reducere a deviației liniei de bază utilizând funcția wavelet mamă Coiflet4.

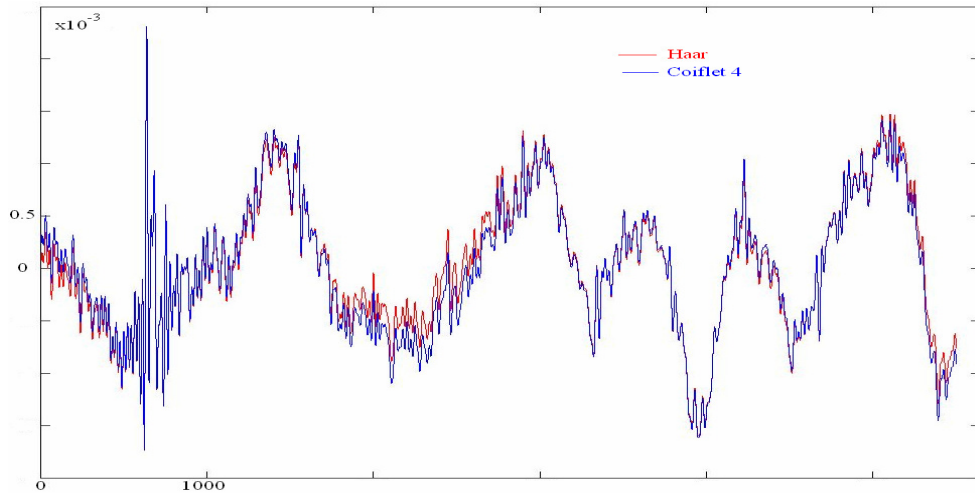


Fig.5.12. Comparație între rezultatele obținute utilizând funcțiile wavelet mamă Haar și Coiflet4.

Funcția wavelet mamă aleasă pentru calculul SWT este Coiflet4, pentru un număr de 10 niveluri de descompunere. În cazul alegerii unui număr mai mic de iterații, pot fi induse perturbări ale componentei utile a semnalului MKG, în timp ce pentru un număr mai mare de niveluri de descompunere, metoda de corecție a liniei de bază va avea rezultate mai slabe (vezi fig. 5.13).




Figura 5.13. Rezultatul metodei wavelet de corecție a liniei de bază pentru 12 niveluri de descompunere.

Timpu de corecție a liniei de bază a semnalului MKG crește odată cu creșterea numărului de iterații, iar pentru o valoare prea mare a acestui număr, abilitatea sistemului de a urmări variațiile rapide ale semnalului MKG va fi afectată.

5.2. Reducerea zgomotului de achiziție al semnalului MKG

După cum s-a amintit deja, obiectivul principal al stagiului științific de cercetare efectuat în Germania a constat în elaborarea și implementarea în mediul de lucru Matlab R2010a a unei tehnici, bazate pe analiza wavelet, de reducere a perturbațiilor care afectează semnalele biomedicale. În paragraful anterior a fost tratat cazul perturbațiilor care produc deviații ale liniei de bază a semnalului MKG. În continuare ne vom referi la celelalte perturbații care afectează acest semnal al căror efect este așa numitul zgomot de achiziție. În continuare se va nota acest semnal cu N_{sig} și se va presupune că este un zgomot aditiv.

Componenta utilă a semnalului MKG achiziționat, s , se va nota cu U_{sig} :

$$s = U_{sig} + N_{sig}. \quad (5.2)$$

Metoda de reducere a zgomotului de achiziție presupune aplicarea a trei pași:

1. Calculul SWT a semnalului MKG de intrare;
2. Filtrarea coeficienților wavelet obținuți;
3. Calculul transformatei SWT inverse, ISWT, reconvertind rezultatul în domeniul timp.

Coeficienții wavelet w rezultați din calculul SWT vor conserva proprietatea de aditivitate a zgomotului, SWT fiind o transformare liniară:

$$w = \text{SWT}\{U_{sig}\} + \text{SWT}\{N_{sig}\} = y + n_0. \quad (5.3)$$

Se obțin coeficienți wavelet utili (y) și coeficienți de zgomot (n_0). Pentru filtrarea coeficienților wavelet se folosește un filtru Maximum A Posteriori (MAP). Pentru construcția filtrelor MAP se folosesc densitățile de probabilitate ale componentelor utilă și de zgomot ale semnalului achiziționat. În cazul în care se folosesc densități de probabilitate unidimensionale se obțin filtre MAP marginale. În cazul semnalelor MKG se ia în considerare o dependență interscală între coeficienți, distingând între coeficienții părinți și coeficienții copii. Coeficienții părinți vor avea aceleași coordonate geometrice ca și coeficienții copii, dar vor fi situați la nivelul de descompunere următor,

$$(w_1, w_2) = (y_1, y_2) + (n_{01}, n_{02}), \quad (5.4)$$

unde s-au notat cu w_1 , y_1 și n_{01} coeficienții copii iar cu indicele 2 au fost notați coeficienții părinți corespunzători. Pentru a lua în considerare dependența interscală a coeficienților wavelet în construcția filtrului MAP este necesar să se lucreze cu densități de probabilitate bidimensionale. Unul dintre cele mai bune filtre MAP cunoscute este filtrul bishrink, [62]. Pentru construcția acestuia se presupune că densitatea de probabilitate a componentei utile a secvenței de coeficienți wavelet este o Laplace-iană bidimensională și că densitatea de probabilitate a componentei de zgomot a secvenței de coeficienți wavelet este o Gauss-iană bidimensională.

Relația intrare-ieșire a filtrului bishrink este:

$$z_1 = (|w| - t)_+ \cdot w_1 / |w|, \quad (5.5)$$

unde $|w| = \sqrt{w_1^2 + w_2^2}$ iar t reprezintă o valoare de prag. Toți coeficienții aflați sub valoarea de prag vor fi considerați drept zgomot și eliminați. S-a utilizat notația:

$$X_+ = \begin{cases} X, & X > 0 \\ 0, & \text{altfel.} \end{cases} \quad (5.6)$$

Spre deosebire de cazul filtrului bishrink, în cazul filtrului propus în acest paragraf, s-a folosit drept valoare de prag, valoarea propusă de D. Donoho [59], dependentă de lungimea secvenței procesate k :

$$t = \sigma_{N_{sig}} \cdot \sqrt{2 \cdot \log(k)}. \quad (5.7)$$

Metoda se bazează pe ipoteze statistice realiste. Deviația standard a zgomotului $\sigma_{N_{sig}}$ poate fi estimată folosind secvența de detalii obținută la primul nivel de descompunere al SWT cu formula:

$$\sigma_{N_{sig}} = \frac{\text{median}(|w(1, i)|)}{0.6745}. \quad (5.8)$$

Magnetocardiogramele studiate au fost înregistrate de Institutul IPHT din Jena, Germania conform unei proceduri dezvoltate de același institut și prelucrate utilizând metoda bazată pe transformata Fourier descrisă în paragraful 3.1. Metoda alternativă, propusă în acest paragraf constituie unul din obiectivele acestei teze de doctorat și se bazează pe analiza wavelet. S-a realizat o comparație a performanțelor celor două metode, rezultatele fiind prezentate în cadrul unei conferințe internaționale [90].

În scopul testării limitelor celor două proceduri diferite de prelucrare a semnalelor MKG, semnalele au fost achiziționate în condiții nefavorabile. Performanțele algoritmilor vor fi examinate pe aceeași bază de date, MKG-uri prelevate de la adulți și feteși puse la dispoziție de institutul IPHT- Jena.

Procedura de eliminare a zgomotului de achiziție este aplicată semnalului cu linia de bază corectată. Flexibilitatea metodei propuse permite selecția separată a funcției wavelet mamă pentru cei doi pași ai procedurii, reducerea deviației liniei de bază și filtrarea zgomotului de achiziție.

În cazul metodei de filtrare a fost aleasă o altă funcție wavelet mamă, și anume Daubechies1 pentru același număr de niveluri de descompunere, $K=10$. Algoritmul de filtrare propus utilizează transformata SWT, iar rezultatul metodei este prezentat în fig. 5.14 pentru cele cinci băți anterior ilustrate în figura 5.10b.




Figura 5.14. Rezultatul metodei de filtrare a zgomotului de achiziție bazată pe analiza wavelet.

Comparând rezultatul procedurii de filtrare bazată pe SWT din fig. 5.14 cu rezultatul procedurii de filtrare bazate pe FFT ilustrat în fig. 5.5, observăm mai puține componente zgomotoase de înaltă frecvență în fig. 5.14. Metoda de filtrare a zgomotului de achiziție bazată pe analiza wavelet, propusă în acest paragraf, înlătură zgomotul biologic, care este un zgomot alb Gaussian, cum este de exemplu zgomotul mioelectric cauzat de activitatea musculară a organismului. Metoda de filtrare a zgomotului de achiziție, care asociază SWT cu filtrul bishrink și-a dovedit eficiența în cazul semnalelor EKG, rezultatele au fost prezentate în cadrul conferinței internaționale IEEE ISETC 2010 [91], însă zgomotul mioelectric nu reprezintă principala componentă a zgomotului de achiziție a semnalului MKG. Principala componentă a zgomotului de achiziție a semnalului MKG este dată de linia de alimentare cu energie electrică, deoarece traductorii folosiți sunt neecranati. În cazul semnalelor MKG trebuie întreprinse în continuare cercetări care să ducă la elaborarea unei metode care să permită eliminarea completă a zgomotului de achiziție.

5.3. Compresia semnalului MKG

Monitorizarea de la distanță reprezintă o modalitate nouă de îmbunătățire a serviciilor medicale, deoarece un serviciu medical de calitate ar trebui să fie disponibil oricărui pacient, oriunde și în orice moment.

Dezvoltarea și difuzarea tehnologiilor de tip wireless permit transmiterea datelor de la locul înregistrării la orice spital unde poate fi pus un diagnostic, crescând astfel numărul de persoane care pot beneficia de îngrijire medicală. În acest fel, crește implicit și șansa de a pune un diagnostic timpuriu (în faza incipientă

a bolii). Pentru a permite clinicilor medicale primirea, stocarea și prelucrarea unei mari cantități de date, se impune dezvoltarea unor algoritmi de compresie.

Magnetocardiogramele (MKG) prezintă informații similare cu cele conținute în electrocardiograme (EKG), diferind însă modul de achiziție al datelor.

Datele prezentate în acest capitol au fost înregistrate de institutul IPHT, Jena în medii neecranate magnetic.

Algoritmul de compresie dezvoltat, urmărește o reducere a volumului de date stocate, fără a distorsiona însă informațiile importante din punct de vedere clinic conținute în magnetocardiograme. Literatura disponibilă referitor la semnalele MKG nu este extinsă, tehnica de investigație fiind recentă, însă monitorizarea de la distanță este o aplicație care ar trebui luată în considerare pentru orice fel de date transmisibile, în special în cazul situațiilor de ordin medical. De exemplu, semnalele MKG ar putea fi înregistrate în laboratoare speciale, în medii ecranate, în care să fie prezent echipamentul de achiziție și să fie transmise în timp real la un spital pentru diagnosticare. Din păcate, deocamdată, o astfel de soluție este prea scumpă.

În continuare se va testa pe cazul semnalelor MKG obținute în medii neecranate aplicabilitatea unui algoritm de compresie bazat pe analiza wavelet, dezvoltat anterior pentru semnale EKG (prezentat în paragraful 4.3).

Algoritmul de compresie cuprinde următoarele etape principale:

- Calculul Transformatei Wavelet Discrete (DWT) a semnalului MKG,
- Filtrarea de tip *Hard-Thresholding* a coeficienților wavelet,
- Cuantizarea secvenței de coeficienți obținuți astfel,
- Aplicarea Transformatei Wavelet Discrete Inverse (IDWT).

Modul de achiziție al semnalelor MKG fiind diferit de modul de înregistrare al semnalelor EKG, neutilizându-se electrozi atașați pacientului, semnalele MKG sunt mai expuse interferențelor decât semnalele EKG iar parametrii de achiziție vor fi diferiți de cei ai EKG-urilor utilizate în simulările anterioare. Astfel, vor fi efectuate modificările necesare pentru a putea aplica și optimiza algoritmul de compresie propus pentru cazul semnalelor de tip MKG. Funcțiile wavelet pot fi percepute drept oscilații limitate în timp, utile descrierii unui semnal prin capacitatea de a se adapta schimbărilor spectrale și temporale ale acestuia.

Algoritmul propus utilizează Transformata Wavelet Discretă (DWT) datorită proprietății funcțiilor wavelet de a concentra energia semnalului într-un număr mic de coeficienți. Deși variantă la translații, în cazul compresiei este preferată DWT, datorită faptului că este neredundantă. Apoi se va utiliza o procedură de tip *hard-thresholding* pentru a elimina coeficienții inferiori unui prag prestabilit, neconsiderându-i drept purtători ai unei informații semnificativă din punct de vedere medical.

Parametrii care influențează performanța algoritmului propus sunt: funcția wavelet mamă MW (mother wavelets) utilizată pentru calculul DWT, numărul de niveluri de descompunere DL (decomposition levels), valoarea de prag pentru filtrul hard-thresholding precum și numărul de niveluri pe care se face cuantizarea coeficienților.

Strategia de optimizare este prezentată în fig. 5.15.

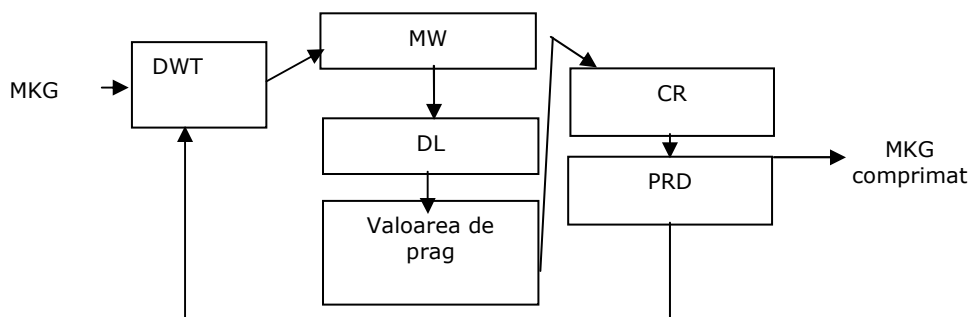


Figura 5.15. Strategia de optimizare a compresiei semnalelor MKG.

Rezultatele obținute în urma aplicării metodei de compresie vor fi apreciate în mod cantitativ prin factorul de compresie CR și prin factorul de distorsiuni, Percent-Root-Mean-Square Difference (PRD). CR se definește drept raportul dintre numărul de biți ai semnalului MKG original și numărul de biți ai semnalului MKG comprimat. PRD este o măsură a distorsiunilor semnalului reconstruit și se recomandă să fie în limitele 6-9 % pentru a fi considerat drept acceptabil [80]:

$$PRD = \sqrt{\frac{\sum_{k=1}^N (x[n] - \hat{x}[n])^2}{\sum_{k=1}^N x^2[n]}} \times 100 \text{ [%]}. \quad (5.9)$$

În paragraful 4.3.1 referitor la compresia electrocardiogramelor, a fost definit un factor de calitate QF (quality factor) al compresiei, drept raportul dintre pătratul factorului de compresie CR și PRD , în scopul selecției funcției wavelet mamă. În continuare, rezultatele compresiei vor fi evaluate atât cantitativ prin CR și QF cât și vizual. Aprecierea vizuală pare să fie criteriul de apreciere a calității compresiei cel mai potrivit deoarece și diagnosticul este pus de medic pe baza unei inspecții vizuale.

Metoda de compresie propusă va fi testată utilizând baza de date furnizată de IPHT Jena și vor fi făcute adaptările necesare algoritmului propus pe baza caracteristicilor specifice ale semnalelor MKG. Algoritmul de compresie a fost testat atât pe MKG-uri materne cât și fetale. Înaintea aplicării sistemului de compresie, semnalul MKG a fost filtrat și corectat din punct de vedere al deviației liniei de bază utilizând metodele de filtrare și corecție prezentate în paragraful 5.2 respectiv 5.1.

Principalii factori care influențează performanța sistemului de compresie propus se referă la funcția wavelet mamă și la numărul de niveluri de descompunere utilizate. Semnalele MKG au fost achiziționate utilizând o frecvență de eșantionare de 1000 Hz, spre deosebire de semnalele EKG furnizate de baza de date de la MIT-BIH care au fost eșantionate cu o frecvență de 360 Hz, acest fapt va influența alegerea numărului de niveluri de descompunere necesare pentru calculul DWT. Au fost testate mai multe familii de funcții wavelet mamă ortogonale, familia Daubechies (Db), Coiflet (Coif) și Symmlet (Sym) ale căror elemente sunt indexate

pe baza numărului de momente nule. Numărul de momente nule VM (vanishing moments) este o măsură a localizării timp-frecvență, un număr ridicat de momente nule indicând o mai bună localizare în frecvență a semnalului analizat.

Simulările care urmează vor demonstra dacă localizarea în timp sau cea în frecvență este mai importantă în cazul semnalelor MKG. Deoarece valorile CR și PRD sunt influențate de nivelul de prag, valoarea acestuia va fi de asemenea luată în considerare. Din considerente comparative, semnalele MKG au fost cuantizate pe 11 biți astfel încât să fie posibilă o comparație a performanțelor cu cele obținute utilizând semnalele EKG, furnizate de baza de date MIT-BIH Arrhythmia. În acest fel se poate trage o concluzie asupra adaptibilității algoritmului de compresie bazat pe analiza wavelet. Contrar metodei descrise în paragraful 4.3.1, valoarea de prag a fost stabilită în mod adaptiv, luând în considerare pasul de cuantizare q utilizat.

În fig. 5.16 (sus) este reprezentat semnalul MKG de intrare, achiziționat utilizând unul dintre semnalele MKG de ordinul II, G1-G3, furnizate de IPHT Jena. Se remarcă o reducere vizibilă a deviației liniei de bază (fig. 5.16 jos, culoare albastră) după aplicarea metodei de corecție descrisă în paragraful 5.1.




Fig. 5.16. Semnalul MKG original (sus, negru) și semnalul MKG după aplicarea metodei de corecție a deviației liniei de bază (jos, albastru).

A fost testată dependența algoritmului de compresie de valoarea de prag (aleasă în mod adaptiv), rezultatele obținute fiind prezentate în tabelul 5.1.

A fost utilizată funcția wavelet mamă Db20 cu 10 momente nule iar descompunerea a fost efectuată pe 7 niveluri. Semnalele au fost cuantizate pe 11 biți, luând în considerare valorile de minim și maxim.

Tabel 5.1. Rezultatele algoritmului de compresie obținute pentru o valoare adaptivă de prag

Valoare de prag	CR	PRD	QF
10*q	3.09	0.14	67.48
20*q	3.90	1.54	9.86
30*q	4.33	0.65	28.91
40*q	4.59	0.48	43.87
50*q	4.81	12.57	1.84
60*q	5.05	12.57	2.02
70*q	5.29	16.25	1.72

Rezultatele indică o valoare de prag de 40*q drept cel mai bun compromis între un factor de compresie *CR* mare și un nivel *PRD* mic. Factorii de compresie obținuți au valori situate între valorile obținute pentru electrocardiografe (de exemplu, pentru EKG-ul 102 a fost obținut un factor de compresie de 5,46, utilizând funcția wavelet mamă Db6, valoarea de prag 3 iar pentru EKG-ul 105 a fost obținut un factor de compresie de 1,92, utilizând funcția wavelet mamă Db42 și valoarea de prag 1).

Rezultatele demonstrează o stabilitate mai bună a evoluției factorului de compresie ca funcție de valoarea de prag, deși valorile de prag alese sunt mai mici decât cele utilizate la compresia semnalelor EKG.

Algoritmul propus a fost în continuare optimizat și testat pentru mai multe familii de funcții wavelet mamă și niveluri de descompunere. Rezultatele obținute sunt prezentate în tabelele 5.2 și 5.3, pentru același semnal MKG.

Tabel 5.2. Rezultatele algoritmului de compresie testat utilizând mai multe niveluri de descompunere

MW	VM	DL	CR	PRD	QF
Db	10	6	4,59	4,99	4,22
		9	4,61	5,67	3,75

Tabel 5.3. Rezultatele algoritmului de compresie testat utilizând mai multe familii de funcții wavelet mamă ortogonale.

MW	VM	CR	PRD	QF
Db	2	3,17	1,65	6,06
Db	4	3,93	0,74	20,72
Db	6	4,19	2,58	6,79
Db	8	4,49	1,85	10,87
MW	VM	CR	PRD	QF
Db	12	4,67	4,89	4,46
Coif	2	3,57	1,07	11,91
Coif	4	3,94	4,80	3,24
Coif	6	4,29	0,68	26,77
Coif	8	4,59	1,82	11,56
Coif	10	4,68	4,09	5,37
Sym	4	3,87	0,43	34,18
Sym	6	4,23	0,53	33,38
Sym	8	4,49	3,67	5,50
Sym	10	4,67	1,42	15,30

Analizând rezultatele prezentate în tabelul 5.2, se remarcă variația valorilor factorului de compresie funcție de numărul de niveluri de descompunere. Factorul de compresie *CR* crește odată cu creșterea numărului de iterații *DL*, dar în același timp crește și riscul de a distorsiona semnalul reconstruit după compresie. Vizualizarea rezultatelor permite o mai bună evaluare a performanțelor metodei de compresie funcție de funcția wavelet mamă utilizată și de numărul corespunzător de momente nule.




Fig.5.17 Distribuția rezultatelor obținute pentru familia de funcții wavelet mamă Daubechies




Fig.5.18 Distribuția rezultatelor obținute pentru familia de funcții wavelet mamă Coiflet




Fig.5.19 Distribuția rezultatelor obținute pentru familia de funcții wavelet mamă Symmlet

Astfel se remarcă necesitatea definirii unui compromis între valorile *CR* și *PRD*. În cazul semnalelor MKG, achiziționate cu o frecvență de eșantionare de 1 kHz, cele mai bune rezultate sunt obținute utilizând 7 niveluri de descompunere.

Asupra semnalului MKG din fig. 5.16, reconstruit după compresie și prezentat în fig. 5.20 nu se remarcă distorsiuni vizibile, comparând cele două figuri.




Fig. 5.20. Semnalul MKG reconstruit după compresie.

În tabelul 5.3 sunt prezentate rezultatele obținute prin testarea mai multor familii de funcții wavelet mamă ortogonale, pentru a stabili care este cea mai indicată funcție wavelet mamă în cazul compresiei magnetocardiogramelor. Cele mai bune rezultate au fost obținute cu funcțiile wavelet mamă aparținând familiei Daubechies având 10 momente nule. Un număr crescut de momente nule conduce la un factor de compresie mai ridicat, însă în același timp crește și valoarea *PRD* în afara limitelor acceptate astfel încât este necesară definirea unui compromis. Comparând rezultatele prezentate cu cele obținute pentru compresia semnalelor EKG (din paragraful. 4.3.1), se remarcă obținerea unui factor de compresie similar dar valorile *PRD* sunt mai mari, încadrându-se încă în limitele considerate acceptabile în literatură [80]. Algoritmul de compresie propus a fost de asemenea testat și pe înregistrări MKG fetale, utilizând aceleași caracteristici, valoare de prag, funcție wavelet mamă și număr de niveluri de descompunere, ca și pentru semnalul precedent, pentru a-i testa stabilitatea și performanțele. Rezultatele obținute pentru acest caz sunt prezentate în fig. 5.21. Semnalele MKG fetale au fost înregistrate la institutul IPHT Jena în condiții nefavorabile într-un mediu necranat. Cu toate acestea, complexe QRS sunt vizibile. Factorul de compresie obținut este de 4,39 pentru o valoare *PRD* de 1,82%. Metoda de compresie elaborată este mai stabilă pentru semnalele MKG decât pentru semnalele EKG, obținându-se performanțe mai apropiate pentru semnale diferite de intrare.




Fig. 5.21. Semnalul MKG fetal original (negru), semnalul MKG obținut după filtrare și corecția liniei de bază (albastru) și semnalul MKG reconstruit după compresie (roșu).

5.4. Semnalul EKG versus semnalul MKG

Dezvoltarea tehnologică din ultimii ani a permis elaborarea a două metode de evaluare a activității electrice a inimii: electrocardiografia (EKG) și magnetocardiografia (MKG). Cele două metode oferă informații similare despre activitatea cardiacă, dar diferă prin modul de achiziție a semnalului: semnalul EKG este prelevat prin intermediul unor electrozi atașați pacientului, în timp ce semnalul MKG este achiziționat prin intermediul unor traductoare aflate la o distanță de câțiva centimetri (2-3 cm) de corp.

Electrocardiograma este o reprezentare grafică care înregistrează în mod direct modificarea biopotențialelor miocardului pe parcursul activității sale ritmice, fiind necesar un bun contact electric între electrozii atașați și piele (problemă rezolvată de regulă prin aplicarea unei paste speciale). Acest fapt însă poate induce riscul unor zgomote de achiziție (denumite în limba engleză *electrode motion artifact* EMA) [63], mai ales în cazul unei monitorizări îndelungate. Magnetocardiograma înregistrează câmpurile magnetice generate de activitatea electrică a inimii, care au însă intensități foarte mici (de cca. 10^6 ori mai mici decât intensitatea câmpului magnetic al Pământului [12]), necesitând aparatură performantă și senzori de achiziție de tip *Superconductive Quantum Interference Devices* SQUID.

În cazul semnalelor MKG, zgomotul de tip EMA, cauzat de un contact incorect al electrozilor de achiziție este eliminat, apărând însă o sensibilitate crescută la interferențele magnetice cu mediul exterior, în cazul achiziției datelor într-un mediu necranat.

Semnalele MKG conferă avantajul înregistrării activității cardiace a fătului în condiții în care achiziția acestor date este dificilă prin EKG (datorită formării membranei de protecție *vernix caseosa*).

Prezenta teză de doctorat permite de asemenea evaluarea modului în care analiza wavelet poate fi adaptată unor semnale de natură diferită. Flexibilitatea funcțiilor wavelet permite adaptarea metodei de reducere a deviației liniei de bază (estimată în ambele cazuri utilizând Transformata Wavelet Staționară SWT) atât la caracteristicile semnalelor EKG cât și la caracteristicile semnalelor MKG. O diferență între cele două tipuri de semnale este generată și de frecvența diferită de eșantionare (1 kHz în cazul semnalelor MKG față de 360 Hz în cazul semnalelor EKG). Acest fapt influențează numărul optim de iterații necesare pentru descompunerea SWT. Formula propusă pentru estimarea numărului necesar de niveluri de descompunere (prezentată în paragraful 4.1 respectiv 5.1) ia în considerare această posibilitate și permite adaptarea algoritmului propus astfel încât să fie obținute rezultate optime: în cazul semnalelor EKG au fost utilizate 8 niveluri de descompunere iar în cazul semnalelor MKG au fost utilizate 10 niveluri de descompunere, existând posibilitatea unui joc de maxim o unitate pentru a nu afecta conținutul informațional al semnalelor păstrând concomitent un raport bun cu viteza de prelucrare.

Cel de-al doilea parametru important, funcția wavelet mamă utilizată la calculul SWT poate diferi în cazul celor două tipuri de semnale biologice: în cazul semnalelor EKG s-au obținut rezultate bune cu funcția wavelet mamă Daubechies5 în timp ce pentru semnalele MKG funcția Symmlet8 sau Coiflet4 este mai indicată pentru porțiunile mai puternic afectate de perturbații, deși s-au obținut rezultate

bune și cu funcția wavelet mamă Daubechies2. Astfel, se remarcă importanța localizării temporale atât în cazul semnalelor EKG cât și MKG, datorită numărului mic de momente nule ale funcțiilor wavelet mamă utilizate. Algoritmii de reducere a deviației liniei de bază a avut rezultate bune în ambele cazuri, remarcându-se corecția zonelor afectate, evaluarea fiind calitativă prin inspecție vizuală așa cum poate fi întâlnită în orice mediu clinic.

Modul diferit de achiziție a celor două tipuri de semnale este vizibil în special la analiza formelor de undă constituite, semnalele MKG achiziționate în medii necranate de către IPHT, Jena fiind mai vizibil afectate de zgomot decât semnalele EKG furnizate de baza de date de la MIT-BIH. Metoda propusă (prezentată în paragrafele 4.2 și 5.2), bazată de asemenea pe SWT, permite alegerea parametrilor filtrului pe baza unor ipoteze realiste asupra proprietăților statistice ale coeficienților wavelet utili, luând de asemenea în considerare relații de interdependență între coeficienți.

Rezultate de filtrare optime au fost obținute utilizând funcții wavelet mamă și valori de prag diferite în cazul semnalelor EKG și MKG: în cazul semnalelor EKG se recomandă funcții wavelet mamă cu o bună localizare timp-frecvență, precum funcția wavelet mamă Db2 cu două momente nule în timp ce pentru semnalele MKG algoritmul a fost mai eficient utilizând funcția wavelet mamă Daubechies1. Metoda de filtrare a zgomotului de achiziție, care asociază SWT cu filtrul bishrink și-a dovedit eficiența în cazul semnalelor EKG, însă nu înlătură toate componentele zgomotului de achiziție de natură magnetică din cazul semnalelor MKG.

În ceea ce privește ultima etapă a unui sistem de monitorizare de la distanță, metodele de compresie propuse sunt bazate pe analiza wavelet și utilizează Transformata Wavelet Discretă DWT, fiind adaptate particularităților semnalelor de intrare. În cazul semnalului EKG a fost propusă o metodă de compresie funcție de organizarea în subbenzi a coeficienților wavelet (paragraful 4.3), metodă prin care s-a obținut un factor de compresie cu o valoare medie de 15. Valorile foarte mici de achiziție a semnalelor MKG în medii necranate (de ordinul 10^{-12} T) au condus la dezvoltarea unei metode adaptive, funcție de nivelul de cuantizare, a unei proceduri de compresie de tip *Hard-thresholding* (descrisă în paragraful 5.3) care, deși a dus la un factor de compresie mai mic (în jurul valorii de 5) decât în cazul semnalelor EKG, constituie totuși un pas în dezvoltarea unei metode încă puțin răspândite la ora actuală.

În cazul ambelor tipuri de semnale biologice, cele mai bune rezultate ale metodei de compresie (însemnând un raport optim între factorul de compresie *CR* și valoarea metodei de evaluare a distorsiunilor *PRD* sau *SNR*) au fost obținute utilizând familia de funcții wavelet mamă Daubechies.

În concluzie, analiza wavelet oferă o bună flexibilitate și permite dezvoltarea unor metode de prelucrare atât a semnalelor EKG cât și a semnalelor MKG, care să țină cont de particularitățile acestora pentru optimizarea parametrilor, contribuind astfel la o monitorizare de la distanță a activității electrice a inimii.

Rezumat 5

O metodă de reducere a deviației liniei de bază a semnalelor EKG, dezvoltată anterior [89] a fost aplicată și optimizată în cazul semnalelor MKG. Caracteristicile metodei, funcția wavelet mamă utilizată și numărul de niveluri de descompunere au fost adaptate particularităților semnalelor MKG. Se poate remarca o reducere a deviației liniei de bază după aplicarea metodei. De asemenea, a fost

dezvoltată o metodă de filtrare a zgomotului de achiziție a semnalelor MKG bazată pe analiză wavelet, facilitând astfel punerea de către medic a unui diagnostic corect. Zgomotul de achiziție a semnalelor EKG, poate fi aproximat cu un zgomot alb, conform [92], [93].

Majoritatea articolelor, ce au putut fi consultate pe durata stagiului de cercetare, care tratează problema metodelor de filtrare aplicate semnalelor biologice, propun metode de denoising drept soluție, motiv pentru care au fost studiate în detaliu aceste metode ([92], [94], [52], [95], [96]). S-a pornit de la premiza că secvența coeficienților wavelet este compusă dintr-o componentă utilă și o componentă de zgomot. În principiu, metoda propusă păstrează doar coeficienții wavelet de detaliu cu valori mai mari decât o valoare de prag stabilită, în timp ce ceilalți coeficienți sunt percepuți drept zgomot și eliminați. În cazul semnalelor MKG s-a constatat că nu mai este dominantă în cadrul zgomotului de achiziție componenta de zgomot alb.

S-au comparat performanțele a două metode diferite de filtrare a zgomotului de achiziție a semnalelor MKG, achiziționate în condiții nefavorabile. O procedură de filtrare bazată pe analiza Fourier, dezvoltată de Institutul IPHT, Jena, Germania a fost comparată cu procedura de filtrare bazată pe analiza wavelet propusă în această lucrare. Metoda de filtrare wavelet cuprinde două etape, prima etapă constând în reducerea deviației liniei de bază, iar cea de-a doua în procedura de filtrare a zgomotului de achiziție.

Tehnica bazată pe analiza Fourier permite vizualizarea spectrului de frecvențe al semnalului de intrare, facilitând în acest fel crearea unei viziuni de ansamblu asupra componentelor spectrale ale semnalului MKG și identificarea posibilelor surse de zgomot. Filtrarea bazată pe analiza Fourier reduce deviația inițială a liniei de bază, fiind eficientă în special pentru zonele cu o deviație moderată a liniei de bază. Pentru zonele cu o deviație mare a liniei de bază, problema nu este rezolvată în întregime, deviația fiind încă vizibilă și după filtrare.

Metoda de corecție a liniei de bază propusă în acest capitol utilizează SWT, undișoara mamă Coiflet4, 10 niveluri de descompunere și tratează problema reducerii deviației liniei de bază într-un mod mai satisfăcător. Linia de bază rezultată în urma aplicării metodei este mai apropiată de valoarea 0 decât linia de bază obținută în urma filtrării în domeniul frecvență, posibilitatea de a pune un diagnostic corect fiind îmbunătățită.

Procedura de filtrare bazată pe analiza Fourier elimină majoritatea, dar nu toate interferențele cauzate de achiziția semnalelor fetale în condiții nefavorabile (o situație posibilă în mediul clinic de achiziție a datelor). Procedura de filtrare bazată pe analiza wavelet reduce doar zgomotul biologic cauzat de activitatea musculară, zgomot care prezintă o sursă principală de perturbații în cazul semnalelor EKG, dar care nu este foarte accentuat în cazul semnalelor MKG, din cauza interferențelor magnetice mult mai puternice existente.

Comparând rezultatele celor două proceduri de filtrare a zgomotului de achiziție, pentru aceleași cinci bătași, se remarcă faptul că acest tip de zgomot rămâne în continuare o problemă în cazul semnalelor MKG fetale, achiziționate în condiții nefavorabile.

Procedura bazată pe analiza Fourier trebuie îmbunătățită astfel încât să elimine deviația liniei de bază și să reducă zgomotul biologic de achiziție iar procedura bazată pe analiza wavelet trebuie să elimine interferențele cauzate de câmpul magnetic. Cu toate acestea, complexul QRS al magnetocardiogramelor este vizibil și permite determinarea pulsului chiar și în medii neecranate magnetic.

Dezvoltarea unei metode wavelet de reducere a interferențelor magnetice la frecvențe discrete, precum frecvența de 50 Hz constituie un subiect de cercetare pentru studii viitoare.

Metoda de compresie bazată pe analiza wavelet este simplă ca și principiu și în consecință rapidă și ușor de implementat. A fost evidențiată în capitolul 4, necesitatea de a lua în considerare cuantizarea coeficienților wavelet în analiza unei metode de compresie destinată transmisiei de date. Pentru a păstra rezoluția semnalelor EKG din baza de date MIT-BIH, semnalele au fost cuantizate pe 11 biți. Cuantizarea introduce anumite distorsiuni în procedura de compresie a datelor. În scopul reducerii acestor distorsiuni, trebuie selectate corect caracteristicile metodei: transformata wavelet utilizată, funcția wavelet mamă folosită la calculul transformatei wavelet și valoarea pragului.

Strategia de selecție a caracteristicilor propusă este bazată pe calculul factorului de calitate, care depinde de factorul de compresie și de factorul *PRD*. Prin această procedură se va selecta asocierea funcției wavelet mamă – valoare de prag care maximizează calitatea compresiei în funcție de semnalul EKG de intrare. S-a demonstrat faptul că factorul *PRD* nu constituie cea mai bună măsură a distorsiunilor existente la reconstrucția semnalului EKG, putând avea valori mici pentru semnale vizibil distorsionate (paragraful 4.3.1). Luând în considerare faptul că analiza electrocardiogramelor este realizată vizual, un criteriu de asemenea vizual pentru aprecierea distorsiunilor cauzate de compresie pare să fie mai indicat.

Cercetarea metodelor de compresie a semnalelor EKG poate fi continuată pe mai multe direcții. O variantă de cercetare viitoare preconizează o metodă de filtrare adaptivă, urmărind exploatarea proprietății multirezoluției a transformatei DWT. O altă direcție posibilă de cercetare constă în înlocuirea transformatei DWT, care nu este invariantă la translație, cu alte tipuri de transformate cum ar fi de exemplu transformata wavelet hiperanalitică [97], mai bine adaptată pentru compresia semnalelor EKG.

Algoritmul de compresie dezvoltat anterior pentru semnale EKG (cap. 4.3.1) a fost adaptat, luând în considerare trăsăturile caracteristice ale magnetocardiogramelor astfel încât să-i fie testate performanțele și în cazul semnalelor MKG. Au fost luate în considerare mai multe caracteristici ale algoritmului de compresie, precum funcția wavelet mamă utilizată la calculul DWT, numărul de momente nule ale funcției MW și numărul de niveluri de descompunere al transformării DWT. Valoarea de prag, necesară pentru a deosebi coeficienții wavelet utili de cei care nu conțin informații utile din punct de vedere medical, a fost stabilită în mod adaptiv funcție de pasul de cuantizare.

Valorile factorului de compresie pentru semnalele MKG sunt în jurul valorii de 4,59, comparabile cu cele obținute cu prima metodă de compresie propusă pentru semnalele EKG, dar algoritmul este mai stabil. Se remarcă că nu pot fi percepute distorsiuni vizibile ale semnalului MKG în urma reconstrucției. În plus, o măsură cantitativă a rezultatelor este redată prin valoarea *PRD*. Valorile obținute sunt mai mari decât cele obținute în cazul semnalelor EKG, dar se încadrează în limitele scrise în literatură.

Metoda de compresie bazată pe analiza wavelet este simplă ca și principiu și în consecință rapidă și ușor de implementat. Magnetocardiogramele sunt rezultatele unei metode neinvazive și oferă informații utile despre activitatea electrică a inimii.

Un sistem de monitorizare cardiacă de la distanță ar trebui luat în considerare și în cazul semnalelor MKG pentru a crește posibilitatea unei diagnosticări în timp util al unui număr cât mai mare de pacienți.

6. CONCLUZII

6.1. CONTRIBUȚIILE TEZEI DE DOCTORAT

Tema de cercetare științifică propusă *Monitorizarea de la distanță a activității electrice a inimii* prezintă un caracter interdisciplinar, aparținând concomitent domeniilor de inginerie electrică și inginerie medicală, domeniul de aplicație vizat fiind un domeniu medical de interes general. Tema a fost aleasă în conformitate cu cerințele înregistrate atât la nivel național cât și internațional de prevenire a afecțiunilor cardiace, o monitorizare de lungă durată a pacientului crescând șansele unei detecții în fază incipientă a bolilor de inimă. Preferințele actuale din lumea medicală evoluează înspre constituirea unei rețele heterogene în stare să ruleze concomitent o mare diversitate de aplicații. Astfel, pacienții suferinzi de boli cardiace pot fi monitorizați în mediul de acasă în timp real, în timp ce efectuează activități casnice. În plus, o monitorizare de la distanță creează noi oportunități de diagnosticare timpurie atât pentru persoane în vârstă cât și în medii rurale, unde accesul la noi tehnologii medicale este relativ limitat.

În **capitolul 1** s-au prezentat principalele motive de alegere a temei propuse spre cercetare și s-a realizat o sinteză a statisticilor privind incidența bolilor cardiace, prezentate de organisme de competență precum Organizația Mondială a Sănătății.

În cadrul **capitolului 2** s-au abordat sistematic principalele metode de investigație clinică a activității electrice a inimii, bazate pe semnale biomedicale. S-a realizat o sinteză asupra principiului funcționării activității cardiace și a modului de prelevare și interpretare a electrocardiografei pentru a permite o viziune de ansamblu asupra tematicii tezei. Capitolul prezintă de asemenea și o modalitate mai puțin răspândită de înregistrare a câmpurilor biomagnetice generate de activitatea electrică a inimii, magnetocardiografele, cu care autoarea a venit în contact în cadrul stagiului efectuat la universitatea *Technische Universitaet Ilmenau*, Germania și în colaborare cu institutul de cercetare *Institut fuer Photonische Technologien*, Jena, Germania.

Capitolul 3 sistematizează aspectele teoretice ale analizei wavelet. S-au prezentat caracteristicile principalelor tipuri de transformate wavelet: transformata wavelet continuă, transformata wavelet discretă și transformata wavelet staționară, pentru a facilita construcția ulterioară a algoritmilor de prelucrare. De asemenea, s-au realizat comparații între transformata wavelet și transformata Fourier în scopul evidențierii avantajelor aplicării analizei wavelet semnalelor biomedicale nestacionare.

În **capitolul 4** au fost dezvoltate și testați o serie de algoritmi, bazați pe analiza wavelet, care cuprind principalele etape ale monitorizării de la distanță cu ajutorul semnalelor EKG: eliminarea deviației liniei de bază, reducerea zgomotului de achiziție, compresia și reconstrucția semnalelor EKG. Aplicațiile concrete au fost implementate în mediul de lucru *Matlab* și testate pe date reale, provenite din baza de date publică de la Michigan Institute of Technology, S.U.A (MIT-BIH), fapt care

a facilitat comparația performanțelor metodelor propuse cu alte metode întâlnite în literatura de specialitate. În paragraful 4.1. s-a propus o metodă originală de corecție a deviației liniei de bază a semnalului EKG, utilizând SWT. Pornind de la structura arborescentă de descompunere SWT, care utilizează un set de filtre trece-jos și trece-sus, se realizează o descompunere în coeficienți wavelet a semnalului EKG analizat. Secvența de coeficienți wavelet de aproximare reprezintă SWT a liniei de bază estimate în timp ce secvențele wavelet de detaliu sunt anulate. Noua secvență de coeficienți wavelet este utilizată la reconstrucția semnalului: prin aplicarea transformatei inverse ISWT rezultă o estimare a liniei de bază. Semnalul EKG corectat a fost obținut prin diferența dintre estimarea realizată și semnalul original. Astfel, metoda de estimare propusă este echivalentă unei filtrări trece-jos a semnalului EKG utilizând un filtru special. A fost propusă o metodă specială de construcție a unui asemenea filtru, prin produsul unui răspuns în frecvență prototip cu versiuni scalate ale aceleiași funcții. Metoda dezvoltată permite fixarea principalilor parametri de calcul: funcția wavelet mamă și numărul de niveluri de descompunere. S-a propus un mod de calcul al numărului optim de iterații, ținând cont de frecvența de eșantionare utilizată la achiziția semnalului EKG și de perioada fundamentală a semnalului EKG, care poate fi apreciată pe baza măsurării pulsului pacientului, metoda luând astfel în considerare un parametru al semnalului analizat. În cazul bazei de date de la MIT-BIH, a fost ales un număr de 8 niveluri de descompunere iar prin simulările realizate s-a demonstrat că rezultate optime pentru eliminarea deviației liniei de bază se obțin în cazul utilizării funcției wavelet mamă Daubechies 5.

În paragraful 4.2 a fost abordată problema influenței zgomotului de achiziție asupra electrocardiografei. O monitorizare de lungă durată a pacientului induce riscul apariției unor perturbații ale semnalului util. S-a dezvoltat o metodă de filtrare a zgomotului de achiziție, care exploatează proprietatea de invarianță la translații a SWT. Algoritmul propus aplică un filtru de tip *bishrink* în domeniul wavelet (un filtru de tip MAP) și se bazează pe estimări realiste ale distribuției coeficienților wavelet utili și a celor de zgomot, luându-se în considerare dependența interscală dintre coeficienți. Această abordare este originală în contextul semnalelor biomedicale. Au fost realizate teste asupra unor semnale EKG afectate de zgomot real, prelevate din baza de date MIT-BIH, pentru a evalua performanța metodei propuse. Simulările întreprinse au avut rezultate foarte bune dacă s-au utilizat funcții wavelet mamă cu o localizare timp-frecvență bună, precum funcția wavelet mamă cu două momente nule, Daubechies 2.

Subcapitolul 4.3. abordează problema transmiterii la distanță a semnalelor EKG, oferind soluții bazate pe analiza wavelet pentru compresia acestor semnale. O monitorizare de lungă durată crește șansa de a detecta în timp util o afecțiune clinică, însă generează în același timp un volum important de informație. Pentru a elimina acest neajuns au fost dezvoltate metode de compresie bazate pe Transformata wavelet Discretă DWT. Primul algoritm propus (prezentat în paragraful 4.3.1) pornește de la o metodă de compresie de tip *hard-thresholding*, eliminând toți coeficienții, percepuți drept zgomot, sub un anumit prag. Simplitatea concepției permite implementarea facilă și o viteză de lucru bună însă nu permite obținerea unor factori de compresie mari. S-a propus o strategie de selecție a asociației optime a parametrilor metodei (funcția wavelet mamă, numărul de momente nule și valoarea de prag) prin evaluarea unui factor de calitate, dependent de raportul dintre factorul de compresie *CR* și factorul Percent Root-Mean Square Difference *PRD*. S-a demonstrat că factorul *PRD* nu reprezintă cea mai bună măsură a distorsiunilor semnalului EKG reconstruit după compresie, deoarece valori mici ale

PRD pot ascunde distorsiuni vizibile ale semnalului. Din moment ce diagnosticul în cazul semnalelor EKG se pune pe considerente vizuale, un criteriu vizual de apreciere a rezultatelor pare mai indicat în cazul acestor semnale biomedicale. În cea de a doua etapă, s-a dezvoltat un algoritm adaptiv original, care să exploateze proprietățile multi-rezoluție ale DWT, pentru a obține factori mai mari de compresie fără a distorsiona componentele utile ale semnalului EKG. Pornind de la observația distribuției în subbenzi a coeficienților wavelet în urma descompunerii DWT, s-a propus o metodă de compresie pentru care valoarea de prag nu va fi fixă, ci va fi dependentă de subbanda respectivă, calculându-se deviația standard a coeficienților wavelet care o compun. S-au realizat studii aprofundate asupra unui număr semnificativ de semnale EKG provenite din baza de date MIT-BIH Arrhythmia pentru a testa influența principalilor parametri ai metodei asupra performanței. S-a studiat influența familiilor de funcții wavelet mamă ortogonale (Daubechies, Coiflet, Symmlet) și biortogonale (Villasenor, Deslauriers, CDF), a numărului de momente nule aferent funcției wavelet mamă, care oferă indicii asupra localizării timp-frecvență și a numărului de niveluri de descompunere. În urma studiilor întreprinse, s-a definitivat un algoritm de optimizare a parametrilor și s-a demonstrat eficiența algoritmului de compresie propus în cazul utilizării funcțiilor wavelet ortogonale din familia Daubechies și a unui număr de cinci niveluri de descompunere. S-au realizat de asemenea comparații ale performanței metodei propuse cu alte metode din literatură, demonstrându-se competitivitatea rezultatelor obținute. Cei trei algoritmi propuși în paragrafele 4.1, 4.2 și 4.3 au fost înglobați într-un tot unitar, flexibilitatea metodelor permițând alegerea separată a parametrilor etapelor, astfel încât să se obțină rezultate optime.

În paragraful 4.4. s-a extins tematica de cercetare referitoare la monitorizarea de la distanță prin abordarea detecției automate a complexului QRS a semnalului EKG. S-a urmărit astfel crearea unei facilități care să ajute munca de diagnosticare a medicului. S-a propus un algoritm bazat pe SWT, metoda realizând detecția undei R într-o singură etapă, luând în considerare caracteristicile formei de undă analizate: s-a detectat maximul local al fiecărui bloc de segmentare. Începutul și sfârșitul complexului QRS sunt detectate apelând la localizarea temporală a undei R detectată anterior, metoda de detecție putând fi considerată astfel adaptivă. Numărul de eșantioane necesare pentru o durată standard a complexului QRS este distribuit în mod simetric la stânga și la dreapta celor două puncte de minim care încadrează vârful undei R determinându-se începutul și sfârșitul complexului QRS. Etapa de validare a rezultatelor metodei utilizând analiza wavelet urmărește evitarea erorilor de detecție sau detecții false.

Capitolul 5 abordează problemele specifice prelucrării magnetocardiogramelor. Metoda de reducere a deviației liniei de bază bazată pe SWT, dezvoltată anterior în cazul semnalelor EKG a fost adaptată pentru cerințele specifice ale semnalelor MKG. S-au testat mai multe funcții wavelet mamă pentru a studia influența acestora asupra corecției deviației liniei de bază, rezultate bune fiind obținute cu funcția wavelet mamă Coiflet4. Parametrii principali au fost optimizați, recalculându-se numărul de niveluri de descompunere SWT necesare funcției de frecvență diferită de eșantionare: s-a ales astfel un număr de 10 niveluri de descompunere. De asemenea studiile întreprinse au demonstrat importanța alegerii numărului corespunzător de iterații. Metoda de corecție a liniei de bază propusă a fost comparată cu metoda de filtrare în domeniul frecvență propusă de IPHT Jena, evidențiându-se rezultate mai bune în cazul analizei wavelet. Semnalele MKG achiziționate în medii neecranate de către IPHT Jena sunt mai vizibil afectate de

zgomot decât semnalele EKG furnizate de baza de date de la MIT-BIH, iar metoda de filtrare care asociază SWT cu filtrul bishrink este mai puțin eficientă în acest caz. De aceea, pentru reducerea zgomotului de achiziție care afectează semnalele MKG, a fost conceput un filtru MAP original în paragraful 5.2.

Studiile întreprinse au demonstrat rezultate de filtrare optime utilizând funcții wavelet mamă și valori de prag diferite în cazul semnalelor MKG (față de cazul semnalelor EKG), pentru semnalele MKG algoritmul fiind mai eficient utilizând funcția wavelet mamă Daubechies1. S-a adaptat și optimizat algoritmul de compresie dezvoltat anterior pentru semnale EKG, luând în considerare trăsăturile caracteristice ale magnetocardiogramelor. Au fost efectuate studii pentru a evalua caracteristicile algoritmului de compresie, precum funcția wavelet mamă utilizată la calculul DWT, numărul de momente nule ale funcției MW și numărul de niveluri de descompunere al transformării DWT. Studiile demonstrând eficiența unor metode adaptive de compresie, s-a stabilit în mod adaptiv funcție de pasul de cuantizare, valoarea de prag. Factorii de compresie obținuți sunt comparabili cu cei obținuți în cazul semnalelor EKG prin prima metodă de compresie propusă. De asemenea, în cadrul acestui capitol a fost realizată o comparație a aplicabilității metodelor wavelet propuse de prelucrare a semnalelor biomedicale, comparând rezultatele obținute în cazul semnalelor EKG cu cele obținute în cazul semnalelor MKG.

6.2. PERSPECTIVE VIITOARE

Prezentul studiu asupra monitorizării de la distanță a activității electrice a inimii poate fi completat printr-un sistem de diagnosticare automată.

Un asemenea sistem ar trebui să cuprindă o segmentare a semnalului EKG sau MKG în undele componente (unda P, complexul QRS și unda T) și o identificare automată a cazurilor patologice pe baza analizei formelor acestor unde componente.

Un prim pas realizat în acest sens este constituit de elaborarea unei prime metode de detecție a complexului QRS (prezentată în paragraful 4.4), care este menită să faciliteze munca medicului și să deschidă noi perspective de cercetare.

BIBLIOGRAFIE

- [1] <http://www.who.int/mediacentre/factsheets/fs317/en/index.html>.
- [2] <http://www.ziare.com/social/romani/interviu-ziare-com-1-din-3-romani-suferade-insuficienta-venoasa-cronica-1042609>.
- [3] <http://meds.wordpress.com/2008/02/23/oms-despre-romania/>
- [4] <http://www.ms.gov.ro/>.
- [5] <http://www.americanheart.org>.
- [6] Rédaction Afrique, „Le cardiopad: une invention africaine pour sauver des vies”, 2012.
- [7] Y. Jasebian, E. Toft, L. Arendt-Nielsen, „Real-time remote monitoring cardiac patients at distance”, http://openmedical.sed.hu/data/openmedical/files/S7.1_PA.pdf.
- [8] C. J. Harland, T. D. Clark, R. J. Prance, „Non-contact ECG monitoring”, *Journal of Measurement Science and Technology*, Volume 13, Number 4, 2002.
- [9] S. Khoór, J. Nieberl, K. Fügedi, E. Kail, *Telemedicine ECG-Telemetry with Bluetooth Technology*, *Computers in Cardiology*, 28, p. 585-588, 2011.
- [10] C. Dudea, „Electrocardiografie teoretică și practică”, Editura Medicală, București, 1981.
- [11] Dale Dublin, „Interpretarea rapida a ECG” – ediția a treia , Editura Medicală, București, 1983.
- [12] T. Menéndez, S. Achenbach, W. Moshage, M. Flüg, E. Beinder, A. Kollert, A. Bittel, K. Bachmann, „Pränatale Registrierung fetaler Herzaktionen mit Magnetokardiographie”, *Z Kardiol* 86:111–118 (1998).
- [13] Y. Seki, A. Kandori, Y. Kumagai, M. Ohnuma, A. Ishiyama, T. Ishii, Y. Nakamura, H. Horigome, T. Chiba, „Demonstration of Unshielded Fetal Magnetocardiography System Using Two-Dimensional Gradiometers”, *IEEE Transactions On Applied Superconductivity*, vol. 19, no. 3, june 2009.
- [14] R. Stolz, L. Fritzsich, and H.-G. Meyer, “LTS SQUID Sensor with a New Configuration”, *Supercond. Sci. Technol.*, 12, 806-808, 1999.
- [15] <http://cryoton.ru/eng/index.htm>.

- [16] Ronny Stolz, V. Zakosarenko, N. Bondarenko, M. Schulz, L. Fritsch, N. Oukhanski, and H.-G. Meyer, "Integrated SQUID-Gradiometer System for Magneto-Cardiography Without Magnetic Shielding", IEEE Transactions on Applied Superconductivity, vol.13, no. 2, June, 2003.
- [17] Yi Zhang, N. Wolters, D. Lomparski, W. Zander, M. Banzet, H. Krause, P. van Leeuwen, "Recording Fetal and Adult Magnetocardiograms Using High-Temperature Superconducting Quantum Interference Device Gradiometers", IEEE Transactions on Applied Superconductivity, vol.13, no. 4, December, 2003.
- [18] M. C. Carter, R. W. Beard, "Fetal Heart Rate Monitoring Using the Abdominal Fetal Electrocardiogram", Br. J. Obstet. Gynaecol., vol. 87, p. 393-401, 1980.
- [19] H. D. Esperer, "Hat die Magnetokardiographie eine Klinische Zukunft?", Herzschrittmachertherapie und Elektrophysiologie, vol.8, Steinkopf Verlag, 1997.
- [20] B. Denis, "Cardiologie", Presses Universitaires de Lyon, Octombrie 2002 - Editat 2005.
- [21] P. Dumitru, "Electrocardiografie practică", Editura medicală, București, 1984.
- [22] R. Barbu, "Explorări funcționale", Editura didactică și pedagogică, București, 1979.
- [23] Gh. Mogoș, "Mică enciclopedie de boli interne", Editura științifică și enciclopedică, București, 1988.
- [24] Denis B., Machecourt J., Vanzetto G., Bertrand B., Defaye P., "Sémiologie et Pathologie Cardiovasculaires", Edité par B. Denis, 1999.
- [25] A. Karassi, "Infarctul miocardic acut", Editura medicală, București, 1979.
- [26] J. Fourier, "Mémoire sur la propagation de la chaleur dans les corps solides", Nouveau Bulletin des sciences par la Société philomatique de Paris. I. Paris: Bernard, pages 112-116, 1808.
- [27] I. Stewart, "Îmblânzirea infinitului. Povestea Matematicii", Editura Humanitas, București, 2011.
- [28] trad. V. Postelnicu, S. Coatu, "Mică Enciclopedie Matematică", Editura Tehnică, București, 1980.
- [29] B. Boulet, "Fundamentals of Signals and Systems", Da Vinci Engineering Press, 1st edition, 2005.
- [30] A. Isar, I. Nafornita, "Reprezentări timp-frecvență", Editura Politehnica, Timisoara, 1998.
- [31] Amara Graps, "An Introduction to Wavelets", IEEE Computational Science and Engineering, vol2, nr.2, pp. 1-18, 1995.

- [32] I. Daubechies, "Orthonormal bases of compactly supported wavelets", *Communications on Pure and Applied Mathematics*, 41 (7):909-996, 1988.
- [33] Dwight F. Mix, Kraig J. Olejniczak, „Elements of Wavelets for Engineers and Scientists”, John Wiley & Sons, Inc., Hoboken, New Jersey, 2003.
- [34] I. Daubechies, „Ten Lectures on Wavelets”, SIAM, 1992.
- [35] St. Mallat, „A Wavelet Tour of Signal Processing”, Academic Press, 1999.
- [36] A. Haar, „Zur theorie der orthogonalen funktionensysteme”, *Mathematische Annalen*, 69 (3):331-371, 1910.
- [37] J. Goswami, Chan A., „Fundamentals of wavelets, Theory, Algorithms and Applications”, Wiley, 1999.
- [38] Cohen, A., "Ondelettes, analyses multirésolution et traitement numérique du signal," Ph. D. Thesis, 1992.
- [39] St. G. Mallat, „A theory for multiresolution signal decomposition: The wavelet representation”, *IEEE Transactions On Pattern Analysis and Machine Intelligence*, 11, no. 7:674-693, 1989.
- [40] R. Rao, A. Bopardikar, „Wavelet Transforms: Introduction to Theory and Applications”, Addison-Wesley, 1998.
- [41] M. Hohlshneider, „Wavelets. An analysis tool”, Ed. Clarendon Press, Oxford, 1995.
- [42] N. Addison, „The Illustrated Wavelet Transform Handbook”, Taylor and Francis, 1st edition, 2002.
- [43] P. Flandrin, „Representation temps-fréquence”, Hermes, 1993.
- [44] R. Jané, P. Laguna, N. V. Thakor and P. Caminal, „Adaptive Baseline Wander Removal in the ECG: Comparative Analysis with Cubic Spline Technique”, *Proceedings of Computers in Cardiology*, p. 143-146, 1992.
- [45] Van Alsté, J.A. Schilder, T.S., „Removal of Base-Line Wander and Power Line Interference from the ECG by an Efficient FIR Filter with a Reduced Number of Taps”, *IEEE Transactions on Biomedical Engineering*, vol. 32, no. 12, p. 1052-1060, december 1985.
- [46] P. Laguna, R. Jané and P. Caminal, „Adaptive Filtering of ECG Baseline Wander”, *Proceedings of the annual International Conference of the IEEE Engineering In Medicine And Biology Society*, Volume 2, p. 508-509, 1992.
- [47] M. H. Sedaaghi, „An Efficient ECG Background Normalization”, 13th European Signal Processing Conference, Antalya, Turkey, September 4-8 2005.

- [48] K. Daqrouq, "ECG baseline wander reduction using discrete wavelet transform", *Asian Journal of Information Technology*, vol. 4, no. 11, p. 989–995, 2005.
- [49] Behzad Mozaffary, Mohammad A. Tinati, "ECG Baseline Wander Elimination using Wavelet Packets", *World academy of science, Engineering and technology*, volume 3, ISSN: 2070-3724, 14-16, march 2005.
- [50] Omid Sayadi and Mohammad B. Shamsollahi, "Multi adaptive Bionic Wavelet Transform: Application to ECG Denoising and Baseline Wandering Reduction", *EURASIP Journal on Advances in Signal Processing*, Article ID 41274, Volume 2007.
- [51] M. A Mneimneh, E. E. Yaz, M. T. Johnson, R. J. Povinelli, "An Adaptive Kalman Filter for Removing Baseline Wandering in ECG Signals", *Proceedings of Computers in Cardiology CinC*, vol. 33, p. 253–256, 2006.
- [52] O. Sayadi, M. Bagher Shamsollahi, "ECG Denoising with Adaptive Bionic Wavelet Transform", http://embc2006.njit.edu/pdf/323_Sayadi.pdf.
- [53] M. Kania, M. Fereniec, R. Maniewski, "Wavelet Denoising for Multi-lead High Resolution ECG Signals", *Measurement Science Review*, Volume 7, Section 2, No. 4, 2007.
- [54] M. Alfaouri, K. Daqrouq, "ECG Signal Denoising By Wavelet Transform Thresholding", *American Journal of Applied Sciences* 5 (3): 276-281, 2008.
- [55] C. Stolojescu, A. Cusnir, S. Moga, A. Isar, "Forecasting WiMAX BS Traffic by Statistical Processing in the Wavelet Domain", *Proceedings of IEEE International Symposium SCS'09, Iasi, Romania, ISBN 1-4244-0968-3*, p. 177-180, July 9-10, 2009.
- [56] M. J. Shensa, "The discrete wavelet transform: wedding the à trous and Mallat algorithms", *IEEE Trans. Sig. Proc.*, Vol. 40, No. 10, p. 2464-2482, 1992.
- [57] <http://www.physionet.org/physiobank/database/mitdb/>.
- [58] M. Oltean, A. Isar, "On the Time-Frequency Localization of the Wavelet Signals with Application to Orthogonal Modulation", *Proceedings of IEEE International Symposium SCS'09, Iasi, Romania, ISBN 1-4244-0968-3*, p. 173-176, July 9-10, 2009.
- [59] D. L. Donoho, "Denoising by Soft-Thresholding", *Symposium on Wavelet Theory, IEEE Transactions on Information Theory*, vol. 41, no.3, p. 613 – 627, May 1995.
- [60] N. Nikolaev and A. Gotchev, "ECG signal denoising using wavelet domain Wiener filtering", *Proceedings of the European Signal Processing Conf. EUSIPCO-2000, Tampere, Finland, 51-54, September 2000*.
- [61] S. Ghael, A. Sayeed and R. Baraniuk, "Improved wavelet denoising via empirical Wiener filtering", *Proceedings of SPIE 3169, San Diego, U.S.A., July 1997*.

- [62] L. Sendur and I. Selesnick, „Bivariate shrinkage functions for wavelet based denoising exploiting interscale dependency”, IEEE Trans. Signal Proc., vol. 50, 2744-2756, Nov. 2002.
- [63] <http://www.physionet.org/physiobank/database/nstadb>.
- [64] Moody G. B., Muldrow W. E., Mark R. G., „A noise stress test for arrhythmia detectors”, Computers in Cardiology; 11:381-384, 1984.
- [65] M. Oltean, J. M. Boucher and A. Isar, „MAP filtering in wavelet domain applied to ECG signal denoising”, ICASSP 2006, Toulouse, France.
- [66] D. Santa-Cruz, T. Ebrahimi, J. Askelof and C. A. Christopoulos, „JPEG 2000 still image coding versus other standards,” Proc. of SPIE, vol. 4472, 267-275, San Diego, CA, USA, 2001.
- [67] A. Isar, A. Cubitchi, M. Nafornta, „Algorithmes et techniques de compression”, Orizonturi universitare, 2002.
- [68] I. Nafornta, A. Isar, „Lossy Data Compression Using Wavelets,” Proceedings of International Conference Communications 2004, Round table under the aegis of the Romanian Academy of Technical Sciences, 28-39, Bucharest, June, 3-4, 2004.
- [69] I. B. Ciocoiu, „ECG Signal Compression Using Wavelet Foveation,” Proceedings of ISSCS 2010, vol. 1, 21-24, Iasi, Romania, 2010.
- [70] M. Fira, L. Goras, „Basis Pursuit for ECG Compression”, Proceedings of ISSCS 2010, vol. 1, 25-28, Iasi, Romania, 2010.
- [71] D. Isar, A. Isar, “A New Best Wavelet’s Mother Searching Algorithm,” Revue roumaine des sciences techniques, serie Électrotechn. et energetique, Tome 47, vol. 3, 2002, 461-467.
- [72] I. Nafornta, C. Gordan, A. Isar, „Semnale, Circuite și Sisteme”, Editura Politehnica, Timișoara, 1995.
- [73] N. Ahuja, S. Lertrattanapanich, N. K. Bose, „Properties Determining Choice of Mother Wavelet”, IEEE Proceedings Vis. Image Signal Process., Vol. 152, No. 5, October 2005.
- [74] M. Blanco-Velasco, F. Cruz-Roldan, E. Moreno-Martinez, J.-I. Godino-Llorente, K. E. Barnerc, „Embedded filter bank-based algorithm for ECG compression”, Signal Processing Journal, Volume 88 Issue 6, June 2008.
- [75] A. Djohan, T. Q. Nguyen, and W. J. Tompkins, „ECG compression using discrete symmetric wavelet transform,” in Proc. of 17th Int. IEEE Med. Biol. Conf., 1995.
- [76] Young-Bok Joo, Gyu-Bong Lee, Kil-Houm Park, „2-D ECG Compression Using Optimal Sorting and Mean Normalization”, International Conference on Machine Learning and Computing IPCSIT vol.3 (2011), IACSIT Press, Singapore.

- [77] L. F. Polania, R. E. Carrillo, M. Blanco-Velasco, K. E. Barner, „Compressed Sensing Based Method For ECG Compression”, Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Prague, 2011.
- [78] S. P. Dakua¹, J. S. Sahambi, „Lossless ECG Compression for Event Recorder Based on Burrows-Wheeler Transformation and Move-To-Front Coder”, International Journal of Recent Trends in Engineering, Vol 1, No. 3, May 2009.
- [79] M. Pooyan, A. Taheri, M. Moazami-Goudarzi, I. Saboori, „Wavelet Compression of ECG Signals Using SPIHT Algorithm”, International Journal of Signal Processing 1 (4) , 2005.
- [80] S. Akhter, M. A. Haque, „ECG Compression Using Run Length Encoding”, 18th European Signal Processing Conference (EUSIPCO-2010), Aalborg, Denmark, pp. 1645-1649, August 23-27, 2010.
- [81] B. Arvinti, C. Nafornita, A. Isar, M. Costache, „ECG signal compression using wavelets. Preliminary results”, 10th International Symposium on Signals, Circuits and Systems (ISSCS), Iasi, Romania, 30 June – 1 July 2011.
- [82] T. Dogaru, L. Carin, „Multiresolution Time-Domain Using CDF Biorthogonal Wavelets”, IEEE Transactions On Microwave Theory And Techniques, Vol. 49, No. 5, May 2001.
- [83] O. Sayadi, M. B. Shamsollahi, „ECG Denoising and Compression Using a Modified Extended Kalman Filter Structure”, IEEE Transactions on Biomedical Engineering, Vol. 55, No. 9, September 2008.
- [84] T. Moulin, J. Joubert, J.-L. Chopard, L. Joubert, E. Medeiros de Bustos, „Telemedicine in Stroke: Potentials, Limitations and Ongoing Issues”, Advances in Telemedicine: Applications in Various Medical Disciplines and Geographical Regions, 2010.
- [85] J. Park, W. Pedrycz, M. Jeon, „Ischemia Episode Detection in ECG using Kernel Density Estimation”, Support Vector Machine and Feature Selection, BioMedical Engineering OnLine, 11:30 doi:10.1186/1475-925X-11-30, p. 1-17, 2012.
- [86] N. Kannathal, U. Rajendra Acharya, P. Joseph, Lim Choo Min, J. S. Suri, „Analysis of Electrocardiograms”, Springer, Berlin Heidelberg, 2010.
- [87] R. Varejão Andreão, J. Boudy, „Combining Wavelet Transform and Hidden Markov Models for ECG Segmentation”, EURASIP Journal on Advances in Signal Processing, Volume 2007, Article ID 56215, p. 1-8, doi: 10.1155/2007/56215, 2007.
- [88] Moody G. B., Mark R. G., „The impact of the MIT-BIH Arrhythmia Database”, IEEE Eng. in Med. and Biol., 20(3):45-50 (May-June 2001). (PMID: 11446209).
- [89] B. Arvinti, D. Toader, M. Costache, A. Isar, „Electrocardiogram Baseline Wander Removal Using Stationary Wavelet Approximations”, Proceedings of the

12th IEEE International Conference Optim 2010, Brasov, Romania, vol. IV., pp. 890-895, May 2010.

[90] B. Arvinti, A. Isar, R. Stolz, M. Costache, „Performance of Fourier versus Wavelet Analysis for Magnetocardiograms using a SQUID–Acquisition System”, Proceedings of the 6th IEEE International Symposium on Applied Computational Intelligence and Informatics, Timișoara, Romania, p. 69-74, May 2011.

[91] B. Arvinti, M. Oltean, A. Isar, D. Toader, M. Costache, „ECG Statistical Denoising in the Wavelet Domain,” 9'th IEEE International Symposium of Electronics and Telecommunications, ISETC 2010, Timisoara, Romania, pp. 307-310, November 2010.

[92] Mikhled Alfaouri, Khaled Daqrouq, „ECG Signal Denoising By Wavelet Transform Thresholding”, American Journal of Applied Sciences 5 (3): 276-281, ISSN 1546-9239, 2008.

[93] http://de.wikipedia.org/wiki/Wei%C3%9Fes_Rauschen.

[94] P M Agante, J P Marques de Sa, „ECG Noise Filtering Using Wavelets with Soft-thresholding Methods”, Computers in Cardiology vol. 26, 535-538, 1999.

[95] A. Phinyomark, C. Limsakul, P. Phukpattaranont, „Optimal Wavelet Functions in Wavelet Denoising for Multifunction Myoelectric Control”, ECTI Transactions on Electrical Engineering, Electronics and Communications, vol. 8, no.1, February 2010.

[96] S. Poornachandra, N. Kumaravel, „A novel method for the elimination of power line frequency in ECG signal using hyper shrinkage function”, Digital Signal Processing 18 (2008) 116–126, Elsevier, 2008.

[97] I. Firoiu, D. Isar, J.-M. Boucher, A. Isar, „Hyperanalytic Wavelet Packets,” Proc. WISP 2009, 6th IEEE International Symposium on Intelligent Signal Processing Budapest, Hungary, p. 67-72, 26–28 August 2009.

LUCRĂRI ȘTIINȚIFICE

I. Lucrări științifice publicate în volumele unor manifestări științifice (Proceedings) indexate ISI Proceedings

1. **Beatrice Arvinti**, D. Toader, M. Costache, A. Isar, "Electrocardiogram Baseline Wander Removal Using Stationary Wavelet Approximations", 12th IEEE International Conference on Optimization of Electrical and Electronic Equipment (OPTIM 2010), Moeciu, jud. Brașov, Romania, ISBN 978-1-4244-7020-4, pp. 890-895, mai 2010.
2. **Beatrice Arvinti**, M. Oltean, A. Isar, D. Toader, M. Costache, "ECG Statistical Denoising in the Wavelet Domain", 9th IEEE International Symposium of Electronics and Telecommunications (ISETC 2010), Timișoara, Romania, ISBN 978-1-4244-8458-4, pp. 307-310, noiembrie 2010.

II. Lucrări științifice publicate în reviste de specialitate indexate BDI

1. I. Luminosu, N. Pop, V. Chiritoiu, **Beatrice Arvinti**, „Formation of Agglomerates in a Complex Diluted Liquid in Absence of the Magnetic Field”, Chemical Bulletin of "Politehnica" University of Timisoara, Romania, Series of Chemistry and Environmental Engineering, Volume 55(69), 2, p. 118-122, 2010.
2. **Beatrice Arvinti**, A. Isar, D. Toader, M. Costache, "Wavelet Theory Applied to Biophysical Signals", Buletinul Științific al Universității "Politehnica" din Timișoara, România – Seria Matematică-Fizică, ISSN 1224-6069, Ed. Politehnica, Timișoara, Romania, Tom 56(70), Fasc. 2, pg. 82-88, 2011.
3. **Beatrice Arvinti**, "A QRS-Complex Detection Algorithm Using the Stationary Wavelet Transform. Preliminary Results", Buletinul Științific al Universității "Politehnica" din Timișoara, România – Seria Matematică-Fizică, ISSN 1224-6069, Ed. Politehnica, Timișoara, Romania, Tom 57(71), Fasc. 1, pg. 73-82, 2012.

III. Lucrări științifice publicate în volumele unor manifestări științifice (Proceedings) indexate BDI

1. **Beatrice Arvinti**, A. Isar, R. Stolz, M. Costache, "Performance of Fourier versus Wavelet Analysis for Magnetocardiograms using a SQUID – Acquisition System", 6th IEEE International Symposium on Applied Computational Intelligence and Informatics (SACI 2011), Timișoara, Romania, ISBN: 978-1-4244-9107-0, pp. 69-74, mai 2011.
– ediția anterioară a conferinței (SACI 2009) este indexată ISI

2. **Beatrice Arvinti**, M. Costache, R. Stolz, C. Nafornta, A. Isar, H. Toepfer, "A Wavelet Based Baseline Drift Correction Method for Fetal Magnetocardiograms", 9th IEEE International New Circuits and Systems Conference (NEWCAS 2011), Bordeaux, Franța, ISBN: 978-1-61284-136-6, p. 109-112, iunie 2011.

3. **Beatrice Arvinti**, C. Nafornta, A. Isar, M. Costache, "ECG Signal Compression Using Wavelets. Preliminary Results", International Symposium on Signals, Circuits and Systems (ISSCS 2011), Iași, Romania, ISBN 978-1-61284-943-0, p.1-4, 30 iunie-1 iulie 2011.

- ediția anterioară a conferinței (ISSCS 2009) este indexată ISI

4. **Beatrice Arvinti**, A. Isar, M. Costache, "An Adaptive Compression Algorithm for ECG Signals", 12th IEEE International Symposium on Computational Intelligence and Informatics (CINTI 2011), Budapesta, Ungaria, ISBN: 978-1-4577-0045-3, p. 91-95 noiembrie 2011.

5. **Beatrice Arvinti**, A. Isar, D. Toader, M. Costache, "Optimization of an Electrocardiogram Compression Technique Based on Wavelets", 13th International Conference on Optimization of Electrical and Electronic Equipment (OPTIM 2012), Cheile Gradistei, jud. Brasov, Romania, ISSN 1842-0133, p. 1140-1145, mai 2012.

- ediția anterioară a conferinței (OPTIM 2010) este indexată ISI

6. I. Căta, **Beatrice Arvinti**, D. Toader, „The Influence of the Steel Core of a Multiple Conductor on the Internal Inductance”, 13th International Conference on Optimization of Electrical and Electronic Equipment (OPTIM 2012), Cheile Gradistei, jud. Brasov, Romania, ISSN 1842-0133, p. 233-238, mai 2012

- ediția anterioară a conferinței (OPTIM 2010) este indexată ISI

7. **Beatrice Arvinti**, M. Costache, A. Isar, "A Three Step Algorithm Based on Biorthogonal Wavelets for an Intelligent Cardiac Remote Monitoring System", IEEE 16th International Conference on Intelligent Engineering Systems (INES 2012), Lisabona, Portugalia, ISSN 978-1-4673-2695-7, p. 549-554, iunie 2012.

IV. Lucrări publicate în volumele unor manifestări științifice

1. **Beatrice Arvinti**, "Wavelet Based Signal Processing Methods for Electrocardiograms", Workshop-ul nr. 2 Interdisciplinaritatea și Managementul Cercetării, Timișoara, România, p. EL27-EL28, noiembrie 2011.