

**Universitatea „Dunărea de Jos” din Galați**  
**Școala Doctorală a Facultății de Științe și Mediu**  
**Domeniul: INGINERIE INDUSTRIALĂ**



**METODE AVANSATE DE PROCESARE**  
**ȘI ANALIZĂ A IMAGINILOR COMPLEXE**  
**REZUMATUL TEZEI DE DOCTORAT**

**Conducător de doctorat,**  
**Prof. dr. ing. fiz. Luminița Moraru**

**Doctorand,**  
**Simona Codrescu (căs. Moldovanu)**

**Galați-2012**



ROMÂNIA  
UNIVERSITATEA „DUNĂREA DE JOS”  
DIN GALAȚI



MINISTERUL  
EDUCAȚIEI  
CERCETĂRII  
TINERETULUI  
ȘI SPORTULUI

08842/12.09.2012

Către

Universitatea “ Dunărea de Jos “ din Galați vă face cunoscut că în data de \_\_\_\_\_, ora \_\_\_\_\_, în \_\_\_\_\_, va avea loc susținerea publică a tezei de doctorat intitulată: **“METODE AVANSAȚE DE PROCESARE ȘI ANALIZĂ A IMAGINILOR COMPLEXE”**, elaborată de domnul/doamna **CODRESCU SIMONA(MOLDOVANU)**, în vederea conferirii titlului științific de doctor în Domeniul de doctorat - **Inginerie industrială**.

Comisia de doctorat are următoarea componență :

- 1. Președinte:** **Conf.univ.dr.fiz. Nicolae TIGĂU**  
*Universitatea “Dunărea de Jos” din Galați*
- 2. Conducător de doctorat:** **Prof.univ.dr.fiz. Luminița MORARU**  
*Universitatea “Dunărea de Jos” din Galați*
- 3. Referent oficial:** **Prof.univ.dr. Mircea CURILĂ**  
*Universitatea din Oradea*
- 4. Referent oficial:** **Conf.univ.dr. Mădălin BUNOIU**  
*Universitatea de Vest din Timișoara*
- 5. Referent oficial:** **Prof.univ.dr. Mirela PRAISLER**  
*Universitatea “Dunărea de Jos” din Galați*

Cu această ocazie vă transmitem rezumatul tezei de doctorat și vă invităm să participați la susținerea publică. În cazul în care doriți să faceți eventuale aprecieri sau observații asupra conținutului lucrării, vă rugăm să le transmiteți în scris pe adresa Universității, str. Domnească nr. 47, 800008 - Galați, Fax - 0236 / 461353.

R E C

Prof.univ.dr.ing. Gabriel BÎRSAN



*Murat*

Str. Domnească nr.47, cod poștal 800008, Galați, România, Tel.: +40 336. 130. 109, Fax: +40 236. 461. 353

Web: www.ugal.ro e-mail: rectorat@ugal.ro

## ***Cuvânt înainte***

*Dedic această teză de doctorat tuturor celor care au sădit în mine dragostea și respectul pentru muncă, cunoaștere și corectitudine.*

*Mulțumesc familiei mele, pentru înțelegerea, încurajările și sprijinul necondiționat pe care mi le-au oferit în toți acești ani de muncă susținută.*

*Alese mulțumiri și întreaga mea recunoștință, conducătorului științific, doamnei prof. univ. dr. ing. fiz. Luminița Moraru pentru sprijinul constant și pentru îndrumările susținute pe întreaga perioadă de cercetare și elaborare a prezentei teze de doctorat.*

*Aș vrea să adresez de asemenea mulțumiri domnului prof. dr. Jan D'Hooge de la K.U. Leuven, Belgia și întregului colectiv al Department of Cardiovascular Diseases, Medical Imaging Centre, University Hospital Gasthuisberg pentru ospitalitate și sprijinul acordat de-a lungul stagiului de cercetare efectuat la acest laborator.*

*Mulțumesc tuturor membrilor comisiei de doctorat, doamnei prof. univ. dr. Mirela Praisler, domnului conf. univ. dr. Mădălin Bunoiu, domnului prof. univ. dr. Mircea Curilă precum și președintelui comisiei, domnului conf. univ. dr. fiz. Nicolae Țigău, pentru că au acceptat să facă parte din comisie, pentru răbdarea cu care au analizat lucrarea de față, precum și pentru sugestiile și sfaturile care mi-au fost adresate.*

*Mulțumesc colegilor mei Dorin Bibicu și Elena Răducan care m-au sprijinit și încurajat pe parcursul acestor ani de căutări științifice, în special doamnei doctor dr. Mariana Carmen Nicolae, domnișoarelor doctor Anca Florian și Mihaela Amzulescu pentru sugestiile, răbdarea și sfaturile acordate.*

*Mulțumesc lui Dumnezeu care mi-a dat sănătate, înțelepciune și putere de muncă pentru a finaliza prezenta teză de doctorat.*

*Elaborarea acestei teze a fost realizată cu suportul financiar al proiectului POSDRU cod 88/1.5/S/61445 - Eficientizarea activității studenților din cadrul ciclului de studii doctorale - EFICIENT.*

*Autorul,*

*Galați, Octombrie 2012*

# Rezultatele cercetării

## Articole publicate în jurnale cotate ISI

- 1. S. Moldovanu**, L. Moraru, A. Biswas, Texture Features that Characterize 2D-Echocardiography-A Review, *Advanced Science Letters*, Vol. 5, pp. 1–10, 2012, ISSN 1936-6612, doi: 10.1166/asl.2012.3671, (FI=1.253, SRI=1.16144),  
<http://www.aspbs.com/science/contents-science172012.htm>
- 2. L. Moraru, S. Moldovanu**, Comparative study on the performance of textural image features for active contour segmentation, *Science China Life Science*, 2012, Vol. 55(7), pp.637–644, doi: 10.1007/s11427-012-4344-5, ISSN: 1674-7305, (FI=2.024, SRI=0).  
<http://link.springer.com/article/10.1007%2Fs11427-012-4344-5>
- 3. S. Moldovanu**, L. Moraru, E. Zerrad, A. Biswas, Speckle Noise Reduction Methods in Cardiac Cycles, *International Journal of Physical Sciences*. Vol. 7(5), pp. 797-804, 2012, doi: 10.5897/IJPS11.1701, ISSN 1992-1950, (FI=0.425, SRI=0,20766).  
<http://www.academicjournals.org/ijps/abstracts/abstracts/abstract2012/30Jan/Moldovanu%20et%20al.htm>.
- 4. S. Moldovanu**, L. Moraru, D. Bibicu, Characterization of myocardium muscle biostructure using first order features, *Digest Journal of Nanomaterials and Biostructures*, Vol. 6(3), July - September 2011, pp. 1357-1365, ISSN: 1842-3582, (FI=1.2, SRI=0).  
[http://www.chalcogen.infim.ro/1357\\_Moldovanu.pdf](http://www.chalcogen.infim.ro/1357_Moldovanu.pdf)

## Articole ISI Proceedings

- 1. L. Moraru, S. Moldovanu**, M. C. Nicolae, De-Noising Ultrasound Images of Colon Tumors Using Daubechies Wavelet Transform, *AIP Conf. Proc.* 1387, pp. 294-299 (2011), doi:10.1063/1.3663182, <http://scitation.aip.org/proceedings/confproceed/1387.jsp>
- 2. S. Moldovanu**, D. Bibicu, L. Moraru, M. C. Nicolae, Classification Features of US Images Liver Extracted with Co-occurrence Matrix Using the Nearest Neighbor Algorithm, *AIP Conf. Proc.* 1400, pp. 565-570, 2011, doi:10.1063/1.3663182  
<http://proceedings.aip.org/resource/2/apcpcs/1400/1%26page=5?isAuthorized=no>
- 3. S. Moldovanu**, L. Moraru, D. Bibicu, Comparative study of myocardium tissue based on gradient features, *E-Health and Bioengineering Conference (Ehb)*, 2011, Iași, Romania 24-26 Nov. 2011, pp 1-4, [http://ieeexplore.ieee.org/xpl/freeabs\\_all.jsp?arnumber=6150369](http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=6150369)

4. L. Moraru, D. Bibicu, **S. Moldovanu**; M. C. Nicolae, Automatic system for breast cysts disease investigation based on the textural parameters analysis, E-Health and Bioengineering Conference (EHB), 2011, Iași, România, 24-26 Nov. 2011, pp.1-4,  
[http://ieeexplore.ieee.org/xpl/freeabs\\_all.jsp?arnumber=6150367](http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=6150367)
5. D. Bibicu, L. Moraru, **S. Moldovanu**, Automatic investigation of the thyroid nodules from US images, AIP Conference Proceedings 1472, 2011, 24-27 Nov, pp. 221-229,  
doi:<http://dx.doi.org/10.1063/1.4748092>,  
[http://proceedings.aip.org/resource/2/apcpcs/1472/1/221\\_1?bypassSSO=1](http://proceedings.aip.org/resource/2/apcpcs/1472/1/221_1?bypassSSO=1)
6. **S. Moldovanu**, D. Bibicu, L. Moraru, Liver ultrasound image classification by using fractal dimension of edge, AIP Conference Proceedings, 1472, 24-27 Nov, pp. 238-244;  
doi:<http://dx.doi.org/10.1063/1.4748094>  
[http://proceedings.aip.org/resource/2/apcpcs/1472/1/238\\_1?bypassSSO=1](http://proceedings.aip.org/resource/2/apcpcs/1472/1/238_1?bypassSSO=1)

#### **Articole indexate BDI/B+**

1. **S. Moldovanu**, L. Moraru, D. Bibicu, Left Ventricle Segmentation Using Active Contour Model, The Annals of Dunarea de Jos University, Technologies in Machine Building, Editura Galați University Press, pp. 59-63, 2012, ISSN: 1221-4566,  
[http://www.cmrs.ugal.ro/TMB/2012/V1/L09\\_Moldovanu.pdf](http://www.cmrs.ugal.ro/TMB/2012/V1/L09_Moldovanu.pdf)
2. D. Bibicu, **S. Moldovanu**, L. Moraru, De-noising of Ultrasound Images from Cardiac Cycle Using Complex Wavelet Transform with Dual Tree, Journal of Engineering Studies and Research – Volume 18(1), 2012, pp. 24-30, ISSN: 2068-7559  
<http://pubs.ub.ro/?pg=revues&rev=jesr&num=201201&vol=18&aid=3590>
3. **S. Moldovanu**, L. Moraru, D. Bibicu, Computerized Decision Support in Liver Steatosis Investigation, International Journal of Biology and Biomedical Engineering, Vol. 6 (1), pp. 69-76, 2012, ISSN:1752-6426, <http://www.naun.org/journals/bio>
4. D. Bibicu, **S. Moldovanu**, L. Moraru, Automatic System for Analysis of Metabolic Disease, B+, JOSA, 2011, Vol. 3(16), pp. 347-352, ISSN:1844-9581, [http://www.icstm.ro/DOCS/josa/josa\\_2011\\_3/c.04\\_Dorin\\_Bibicu.pdf](http://www.icstm.ro/DOCS/josa/josa_2011_3/c.04_Dorin_Bibicu.pdf)
5. D. Bibicu, **S. Moldovanu**, L. Moraru, Denoising the Echographic Images using Fourier Transform, Annals of Dunărea de Jos University, Fascicle II, Anul III, nr. 2, pp. 66-72, 2011, ISSN: 1844-9581, [http://www.phys.ugal.ro/Annals\\_Fascicle\\_2/Year2011/Summary%20Annals\\_%20Fasc\\_II\\_2011\\_No\\_1.htm](http://www.phys.ugal.ro/Annals_Fascicle_2/Year2011/Summary%20Annals_%20Fasc_II_2011_No_1.htm)
6. **S. Moldovanu**, L. Morau, D. Bibicu, Monitoring Breast Tumors Using Thresholding and Interpolation Methods in Ultrasound Images, Annals of Dunărea de Jos University, Fascicle

II, Anul III, nr. 2, 2011, pp. 167-174, ISSN: 2067-2071, [http://www.phys.ugal.ro/Annals\\_Fascicle\\_2/Year2011/Summary%20AnnalsFasc\\_II\\_2011\\_No\\_2.htm](http://www.phys.ugal.ro/Annals_Fascicle_2/Year2011/Summary%20AnnalsFasc_II_2011_No_2.htm)

**7. S. Moldovanu**, L. Moraru, Analysis of Small Tumours in Ultrasound Breast Echography, Annals of the University of Craiova, Mathematics and Computer Science Series, pp.138-161, Vol. 37(3), 2010, ISSN:1223-6934, <http://inf.ucv.ro/~ami/index.php/ami/article/view/365>

**8. S. Moldovanu**, Luminita Moraru, De-noising Kidney ultrasound analysis using Haar, Journal of Science and Arts, Vol. 2 (13), pp. 365-370, 2010, ISSN: 1844–9581 <http://www.josa.ro/ro/index.html?http%3A//www.josa.ro/ro/josa.html>.

**9. S. Moldovanu**, L. Moraru, M. C. Nicolae, Comparative Analysis of Ultrasound Image Using Gray Level, Annals of Dunărea de Jos University, Fascicle II, Anul II, nr. 2, pp.145-151, 2010, ISSN: 1844-9581.

[http://www.phys.ugal.ro/Annals\\_Fascicle\\_2/Year2010/index2.htm#L11](http://www.phys.ugal.ro/Annals_Fascicle_2/Year2010/index2.htm#L11)

**10. L. Moraru, S. Moldovanu**, M. C. Nicolae, Segmentation of the Colon Tumors Based on Watershed in Ultrasound Image, Annals of Dunărea de Jos University, Fascicle II, Anul II, nr. 2, pp.152-156, 2010, ISSN:1844–9581, [http://www.phys.ugal.ro/Annals\\_Fascicle\\_2/Year2010/index2.htm#L11](http://www.phys.ugal.ro/Annals_Fascicle_2/Year2010/index2.htm#L11)

**11. S. Moldovanu**, L. Moraru, D. Bibicu, Bio-Structural Analysis of Breast Using Fractal Analysis in Ultrasound Images, Annals of Dunărea de Jos University, Fascicle II, Anul III, nr. 1, pp. 66-72, 2011, ISSN: 2067-2071,

[http://www.phys.ugal.ro/Annals\\_Fascicle\\_2/Year2011/Summary%20Annals%20Fasc\\_II\\_2011\\_No\\_1.htm](http://www.phys.ugal.ro/Annals_Fascicle_2/Year2011/Summary%20Annals%20Fasc_II_2011_No_1.htm)

**12. S. Moldovanu**, L. Moraru, Mass Detection and Classification in Breast Ultrasound Images Using k-means clustering algorithm, Electrical and Electronics Engineering (ISEEE), the 3<sup>rd</sup> International Symposium, pp.197-200, 2010, doi :10.1109/ISEEE.2010.5628516 <http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=5628516&url=http%3A%2F%2Fieeexplore.ieee.org%2Fiel5%2F5610912%2F5628464%2F05628516.pdf%3Farnumber%3D5628516>

**13. S. Moldovanu**, L. Moraru, Biomedical Image processing in Matlab Application, Annals of Dunărea de Jos University, Fascicle II, Anul I, nr 2, pp. 127-133 ,2009, ISSN 1844 – 9581, [http://www.phys.ugal.ro/Annals\\_Fascicle\\_2/Year2009/summary%20Annals%20Fasc%202\\_2009.htm](http://www.phys.ugal.ro/Annals_Fascicle_2/Year2009/summary%20Annals%20Fasc%202_2009.htm)

**Lucrări comunicate/ susținute la conferințe naționale sau internaționale.**

- 1. S. Moldovanu** , L. Moraru, De-noising kidney ultrasound analysis using Haar wavelets, The 2<sup>nd</sup> National Conference and International participation on Applied Sciences in Enviromental and Material Studies, pp. 14, 28-30 Aprilie 2010, Târgoviște, România.
- 2. S. Moldovanu**, L. Moraru, Tumors Investigation in Breast Ultrasound Image using Fractal Analysis, Conferința Națională de Fizică, 23-25 Sept. 2010, Iași, România.
- 3. S. Moldovanu**, D. Bibicu, L. Moraru, Classification Features of US Images Liver Extracted with Co-occurrence Matrix Using the Nearest Neighbor Algorithm, AIP International Conference, 12-15 May 2011, Antalya, Turcia.
- 4. L. Moraru, S. Moldovanu, M. C. Nicolae**, De-noising ultrasound Images of Colon Tumours Usong Daubeches Wavelets Transform, Physics Conference TIM-10, 25-27 Nov. 2010. Timișoara, România.
- 5. S. Moldovanu**, D. Bibicu, L. Moraru, Comparative Study of Density Distribution of Microbules between Frames end-systole and end-diastole inside cavity left ventricle, OPROTEH 2011, 24-26 May 2011, Bacău, România
- 6. D. Bibicu, S. Moldovanu, L. Moraru**, De-noise the Utrasound Images from Cardiac Cycle with Complex Wavelet Transform with Dual Tree, OPROTEH 2011, 24-26 May 2011, Bacău, România.
- 7. D. Bibicu, S. Moldovanu, L. Moraru**, Automatic System for Analysis of Metabolic Disease, JSJR 2011, 24-30 iulie 2011, Târgoviște, România.
- 8. S. Moldovanu**, L. Moraru, D. Bibicu, Automatic System for Investigation the Correlation of Liver Features, WSEAS 2011, 27-29 Oct. 2011, Drobeta Turnu Severin, România.
- 9. S. Moldovanu**, D. Bibicu, L. Moraru, Textural methods for myocardial tissue characterization, Research Quality in Doctoral School Increased Industrial And International Visibility 2011, 13-14 iulie 2011, Galați, România.
- 10. S. Moldovanu**, D. Bibicu, L. Moraru, Liver Ultrasound Classification by Using Fractal Dimension of Edge, Physics Conference, TIM-2011, 24-27 Nov. 2011, Timișoara, România.
- 11. D. Bibicu, L. Moraru, S. Moldovanu**, Automatic Invetigation of the Thyroid Nodules from US Images, Physics Conference, TIM-2011, 24-27 Nov. 2011, Timișoara, România.
- 12. S. Moldovanu**, D. Bibicu, L. Moraru, Comparative study of myocardium tissue based on gradient features, E-Health and Bioengineering Conference (EHB) 24-26 Nov. 2011, Iași, România.

- 13.** D. Bibicu, **S. Moldovanu**, L. Moraru, M. C. Nicolae, Automatic system for breast cysts disease investigation based on the textural parameters analysis, E-Health and Bioengineering Conference (EHB), 24-26 Nov. 2011, Iași, România.
- 14.** **S. Moldovanu**, L. Moraru, D. Bibicu, Engine Number Stamping Characterized by Zernike Moment, International Conference Artcast, 18-19 May 2012, Galati, Romania.
- 15.** L. Moraru, **S.Moldovanu**, D. Bibicu, Mathematical Models used in Segmentation and Fractal Models of 2D Ultrasound Images, International Conference on Mathematical Problem in Engineering, Aerospace and Science, 10-14 July 2012, Vienna University of Technology, Vienna, Austria.
- 16.** L. Moraru, **S. Moldovanu**, A. Ene, Enhancing performance of image segmentation through feature Extraction, The 8<sup>th</sup> General Conference of Balkan Physical Union, 5-7 July, 2012, Constanța, România.



# Cuprinsul tezei de doctorat

	Pagină
<b>Introducere.....</b>	<b>13</b>
1. Motivația alegerii temei de cercetare .....	15
2. Importanța cercetării.....	15
3. Obiectivele tezei.....	17
4. Diseminarea rezultatelor cercetării.....	18
5. Structura lucrării științifice.....	18
<b>Capitolul I</b>	
<b>Reprezentarea imaginilor</b>	
1.1 Introducere.....	20
1.2 Modelul matematic al imaginii.....	21
1.2.1 Modelul continuu al imaginii.....	21
1.2.2 Modelul discret al imaginii.....	23
1.3 Proprietățile imaginilor digitale.....	25
1.3.1 Proprietățile metrice ale imaginilor digitale.....	25
1.3.2 Proprietățile topologice ale imaginilor digitale.....	27
1.4 Reprezentarea spectrală a imaginilor.....	28
1.5 Tipuri de imagini.....	28
1.6 Concluzii.....	31
1.7 Bibliografie.....	32
<b>Capitolul II</b>	
<b>Îmbunătățirea imaginilor complexe</b>	
2.1 Introducere.....	34
2.2 Aspecte teoretice privind îmbunătățirea imaginilor complexe.....	35
2.2.1 Elemente perturbatoare din imaginile digitale.....	35
2.2.1.1 Zgomotul.....	35
2.2.1.2 Zgomotul de tip impuls ( <i>Speckles</i> ).....	37
2.2.2 Filtrarea imaginilor.....	37
2.2.2.1 Filtrarea liniară a imaginilor.....	39
2.2.2.1.1 Filtrul de estompare ( <i>Blur Filter</i> ).....	42
2.2.2.1.2 Filtru de accentuare ( <i>Sharpen Filter</i> ).....	42

2.2.2.1.3 Filtrul Laplacian.....	43
2.2.2.1.4 Filtrul Gaussian ( <i>Gaussian Filter</i> ).....	44
2.2.2.1.5 Filtrul Laplacian&Gaussian ( <i>LoG</i> ).....	44
2.2.2.1.6 Filtrul gradient.....	45
2.2.2.1.7 Filtrul Wiener.....	47
2.2.2.2 Filtrarea neliniară a imaginilor.....	47
2.2.2.2.1 Filtrul median.....	49
2.2.2.2.2 Filtrul de maxim și de minim.....	49
2.2.2.2.3 Filtrul geometric.....	50
2.2.3 Transformate <i>wavelets</i> .....	50
2.2.3.1 <i>Wavelets</i> Haar.....	52
2.2.3.2 <i>Wavelets</i> Daubechies.....	53
2.2.3.3 <i>Wavelets</i> complexe și arborele dual.....	54
2.2.4 Transformata Fourier.....	55
2.2.5 Descriptori de calitate.....	56
2.3 Contribuții personale privind îmbunătățirea imaginilor.....	58
2.3.1 Contribuții personale privind îmbunătățirea imaginilor cu filtre liniare și neliniare.....	59
2.3.1.1 Rezultate experimentale privind eliminarea <i>speckles</i> din imagini ecocardiografice.....	60
2.3.1.2 Clasificarea obiectelor din imaginile obținute cu ultrasunete folosind algoritmul <i>k-mean</i> .....	66
2.3.2 Contribuții personale privind îmbunătățirea imaginilor cu transformate <i>wavelets</i> .....	69
2.3.2.1 Eliminarea zgomotului din ecografiile renale folosind <i>wavelets</i> Haar.....	70
2.3.2.2 Eliminarea zgomotului din imaginile ecografice ale colonului cu <i>wavelets</i> Daubechies.....	72
2.3.2.3 Eliminarea zgomotului dintr-un ciclu cardiac cu <i>wavelets</i> complexe cu arbore dual (CWT-DT).....	77
2.3.3 Contribuții personale privind îmbunătățirea imaginilor ecocardiografice cu transformata Fourier.....	83
2.4 Concluzii.....	90
2.5 Bibliografie.....	91

## Capitolul III

### Descriptori imagistici de formă și textură

3.1 Introducere.....	95
3.2 Aspecte teoretice privind momentele imaginilor.....	97
3.2.1 Momente geometrice.....	98

3.2.2 Momente statistice.....	102
3.2.3 Momente de ordin superior.....	103
3.3 Descriptori de analiza a texturii.....	105
3.3.1 Descrierea texturii prin distribuții de ordinul II.....	106
3.3.2 Matricea de izo-segmente.....	109
3.4 Cuantificarea texturii prin fractali.....	111
3.5 Cercetări experimentale proprii privind extragerea caracteristicilor texturale din imaginile complexe.....	113
3.5.1 Studiu comparativ al țesutului miocardic bazat pe descriptorii gradient.....	114
3.5.2 Caracterizarea structurii miocardului din imaginile ecocardiografice cu caracteristici de ordinul I.....	118
3.5.3 Utilizarea caracteristicilor de ordinul II pentru clasificarea ecografiilor hepatice cu algoritmul <i>nearest neighbor</i> .....	123
3.5.4 Sistem suport de decizie automată în investigația steatozei hepatice.....	127
3.5.5 Caracterizarea imaginilor degradate cu momente Zernike.....	139
3.6 Concluzii.....	142
3.7 Bibliografie.....	144

## Capitolul IV

### Metode de segmentare și analiză fractală

4.1 Introducere.....	150
4.2 Segmentare orientată pe regiuni.....	151
4.2.1 Segmentarea bazată pe histogramă.....	152
4.2.2 Metoda Otsu.....	155
4.3 Segmentarea bazată pe contururi.....	156
4.3.1 Metoda de segmentare <i>watershed</i> .....	156
4.3.2 Segmentarea bazată pe contururi active.....	159
4.4 Metoda „ <i>Box-counting</i> ”.....	161
4.5 Cercetări experimentale proprii asupra imaginilor ecografice cu metodele de segmentare.....	165
4.5.1 Monitorizarea tumorilor la sân prin metode de interpolare și segmentare a histogramei.....	167
4.5.2 Momente statistice și geometrice extrase din imaginile ecografice pentru clasificarea leziunilor la sân.....	171
4.5.3 Exercițiu de segmentare al imaginilor complexe de tipul ecografiei la colon cu metoda <i>watershed</i> .....	181
4.5.4 Metodă test de segmentare a ventriculului stâng din imaginile ecocardiografice cu metoda conturului activ.....	184
4.5.5 Studiu comparativ al performanțelor imaginilor de caracteristici testate cu metoda conturului activ.....	187
4.6 Contribuții personale privind evaluarea imaginilor complexe cu ajutorul	199

dimensiunii fractale.....	
4.6.1 Clasificarea imaginilor ecografice ale ficatului folosind dimensiunea fractală a muchilor.....	200
4.6.2 Utilizarea dimensiunii fractale în analiza bio-structurală a leziunilor la sân din imaginile ecografice.....	204
4.7 Concluzii.....	208
4.8 Bibliografie.....	211
<b>Capitolul V</b>	
<b>Contribuții originale proprii în domeniul prelucrării imaginilor complexe: folosirea imaginilor de caracteristici</b>	
5.1 Introducere.....	217
5.2 Metodă semiautomată de determinare a obiectelor din imaginile complexe în contextul imaginilor de caracteristici.....	219
5.3 Explorarea ecocardiografiilor cu ajutorul imaginilor de caracteristici	250
5.4 Concluzii.....	262
5.5 Bibliografie.....	263
<b>6. Capitolul VI</b>	
<b>Sinteza rezultatelor studiului imaginilor complexe și concluzii finale.....</b>	<b>267</b>
<b>Anexe.....</b>	<b>275</b>
<b>Curriculum Vitae.....</b>	<b>281</b>

**Prezentul rezumat conține o sinteză a celor mai elocvente rezultate experimentale obținute în urma cercetărilor teoretice și practice.**

**Indicatorii capitolelor și subcapitolelor sunt identici cu cei ai tezei de doctorat, iar figurile, tabelele și referințele bibliografice sunt renumerotate.**

## Introducere

Imaginile sunt concepte care au caracter informațional. Acestea sunt percepute de oamenii prin: detecția radiației electromagnetice, proiectarea acesteia pe retină și transmiterea lor centrului optic din creier care le interpretează și le achiziționează. Din punct de vedere mental, imaginea poate fi efectivă sau directă. Imaginea efectivă este imprecisă din punct de vedere cromatic ca urmare a procesului de rememorare a unei imagini anterior văzute, acest tip de imagine nu face subiectul acestei cercetări. Imaginea directă, care se formează ca urmare a procesului perceptiv, este pregnantă, cu detalii structurale și dinamice, este luată în considerație în cercetarea de față. Domeniul de prelucrare și analiză a imaginilor a depășit barierele de percepere a ochiului uman aducând soluții novatoare în ceea ce privește imaginile non-vizibile, precum imaginile acustice sau cele obținute cu ultrasunete.

Din păcate nu sunt mulți ”Homo sapiens”, cum suntem numiți de biologi, care au dotări intelectual interpretante și perceptuale adecvate, care au posibilitatea să rețină în detaliu imagini precise, excepție făcând pictorii. Acest neajuns al speciei umane este înlăturat de instrumente de achiziție și stocare adecvate epocii postindustriale pe care o trăim, în domenii ca: imagistica medicală, inginerie industrială, realitate virtuală, procesarea documentelor, baze de date multimedia, imagistica radar, imagistica satelitară, robotică, etc.

În general, metodele de procesare specifice domeniilor amintite, cuprind ansambluri de tehnici, metode de achiziție, stocare, afișare, modificare, compresie și exploatare a informației vizuale cuprinsă în imagini. Acestea caută soluții la rezolvarea problemelor complexe de proiectare și implementare ale sistemelor software de procesare imagistică cu scopul de a îmbunătăți sau reutiliza soluții deja elaborate.

În particular, procesarea imaginilor complexe se referă la capacitatea de a descrie, înțelege și recunoaște scene, obiecte din scene și legăturile dintre acestea prin intermediul caracteristicilor texturii, fractalilor sau prin metode de segmentare.

Procesarea imaginilor digitale are în vedere o serie de etape importante, care au fost urmărite îndeaproape pe parcursul acestei cercetări :

- ❖ Achiziția imaginii digitale se realizează în general cu un senzor de imagine capabil să digitizeze semnalul și să genereze la ieșirea acestuia o imagine. Această etapă este independentă de scopul cercetării noastre.

- ❖ Îmbunătățirea imaginii sau preprocesarea este o etapă primordială în procesarea imaginilor complexe, deoarece o îmbunătățire adecvată a procesului de prelucrare, mărește șansele de succes ale etapei de segmentare. Această etapă incipientă folosește algoritmi de filtrare liniari, neliniari, wavelets sau transformări Fourier. Aportul propriu adus acestei etape constă în crearea imaginilor de caracteristici cu ajutorul descriptorilor de ordinul I și II.
- ❖ Detaliile imaginilor sunt căutate în texturile acestora. Imagistica are de-a face cu două categorii de texturi, cele generate prin metode fractale, spectrale, statistice și sintetice a cărui șablon de realizare este *a priori* cunoscut și texturi aleatoare care se doresc a fi înțelese prin parametri statistici sau geometrici. Înțelegerea texturii unei imagini conduce la extragerea de cunoștințe utile în orice domeniu unde imagistica și-a găsit utilitatea.
- ❖ Segmentarea imaginilor este cea mai dificilă etapă de procesare, deoarece în cadrul ei are loc descompunerea unei scene (imagini) în componentele sale, iar în urma procesului de segmentare vor fi extrase din imagine obiecte distincte, regiuni ce satisfac anumite criterii de uniformitate sau alte caracteristici de formă. Obiectele sunt interpretate ca regiuni compacte sau numai ca frontiere (contururi). După primitivele de extras, tehnicile de segmentare se împart în trei categorii fundamentale: tehnicile de segmentare orientate pe pixeli, tehnicile de segmentare orientate pe contur și tehnicile de segmentare orientate pe regiuni. Fiecare dintre aceste categorii conține câte o varietate largă de metode, de aceea, în lucrarea de față, s-au selectat doar cele care au la bază algoritmi de segmentare sofisticăți și care totodată oferă șanse majore în selectarea regiunilor de interes.
- ❖ Operațiile de descriere, recunoaștere, clasificare și selecție ale caracteristicilor obiectelor extrase în procesul de segmentare sunt realizate în etapa de analiză. Interpretarea operațiilor enumerate se poate realiza cu diferite metrice de calitate sau cu metode statistice avansate.

Prin etapele de procesare ale imaginilor complexe, coroborate cu tematica tezei de doctorat mi-am adus aportul prin contribuții teoretice și practice, la fiecare etapă dezvoltând metode originale de procesare.

Procesarea imaginilor fiind un domeniu foarte complex, toate etapele premergătoare analizei imaginii trebuie să se realizeze secvențial, avându-se în vedere că la realizarea

fiecărei etape se ține cont de cunoștințele acumulate în etapa anterioară. Pentru stabilitatea cunoștințelor acumulate se fac cercetări continui și se caută algoritmi care să ajusteze permanent problemele noi apărute.

## **1. Motivația alegerii temei de cercetare**

Descrierea, înțelegerea și analiza imaginilor digitale a devenit un subiect de importanță majoră pentru multe domenii datorită noilor tehnologii de achiziție. Legătura interdisciplinară dintre matematică, fizică, informatică și aplicarea acestora în inginerie industrială și medicină, reprezintă o motivație puternică în alegerea temei, iar efectele acestei interdisciplinarității ca: viziunea asistată de calculator, programarea, ultrasonografia, rigurozitatea matematică din domeniul imagisticii, modelarea sistemelor informatice evocă o provocare majoră a cercetării.

Tehnologiile actuale de preluare și procesare a imaginilor au pătruns cu succes în domeniul ingineriei industriale. Aparatele de achiziție ale imaginilor devin din ce în ce mai performante oferind posibilități proprii de reconstrucții sau măsurători. Dezavantajele acestor aparate sunt acelea că, ele pot prelucra numai un anumit tip de imagini iar calitatea imaginilor preluate poate fi distorsionată, influențată de diferiți factori externi, de zgomot sau chiar de trecerea timpului.

În vederea înlăturării acestor dezavantaje am propus diferite metode de preprocesare, care să ofere o mai bună acuratețe a imaginilor prin îmbunătățirea acestora. Din punct de vedere vizual, domeniul preprocesării imaginilor este cel mai atrăgător deoarece efectul metodelor aparținătoare este imediat și vizibil. Totuși, m-am oprit și asupra segmentării imaginilor deoarece este un domeniu captivant prin interactivitatea utilizatorului cu imaginea, iar analiza acestora presupune cuantificarea unei bune practici ale primelor două domenii. Trebuie să precizez că, am folosit preponderent imagini provenite din domeniul medical deoarece sunt mult mai complexe și au permis studii mult mai aprofundate. În acest context, transferul tehnologic către aplicațiile industriale este mult mai facil și eficient.

## **2. Importanța cercetării**

În prezent, în orice ramură a științei există dispozitive de achiziție și stocare al imaginilor. Achiziția unei imagini de calitate neafectată de factori externi, permite ca, prin tehnicile specifice imagisticii, să fie interpretată corect. De aceea, transformarea imaginilor

degradate în imagini cât mai apropiate de original, fără pierderea informației utile și a detaliilor este scopul fundamental al acestei teze de doctorat.

Implementarea unui sistem adiacent la aparatele de achiziție, care să transforme imaginea achiziționată în imagine de caracteristici și interpretarea acesteia cu ajutorul descriptori de calitate adecvați, rămâne o temă extrem de actuală în rândul cercetătorilor.

Rezultatele cercetării noastre furnizate de aplicații software proprii, pot fi utilizate și în scopuri educaționale, ca o oportunitate e-Learning pentru studenți, iar rezultatele științifice obținute pot fi puncte de reper, pentru viitorii cercetători din domeniul imagisticii medicale și industriale.

Pentru obținerea și prelucrarea rezultatelor experimentale, am utilizat următoarele instrumente software de înalt nivel, Matlab R2009a cu următoarele pachete și librării: Image Processing Toolbox, Wavelets, Graphical User Interface, HDF5, Neuronal Network Toolbox; software-ul SPSS versiune 10.0 (SPSS Inc., Chicago, IL); software-ul comercial EchoPAC (GE Healthcare, Horten, Norway) sub licența Department of Cardiovascular Diseases, Medical Imaging Centre, University Hospital Gasthuisberg, K.U. Leuven, Belgium; HarFA (Harmonic and Fractal Image Analysis), aplicație gratuită oferită de Jagiellonian University, Cracovia, Polonia. Ecografele folosite în etapa de achiziție au fost de tipul SLE-40 și de tip VIVID E9, GE HORTEN MOK WAY.

În contextul cercetării literaturii de specialitate, s-a adus un aport la îmbogățirea cunoașterii tipurilor de descriptori în concordanță cu textura imaginilor ecocardiografice iar aplicațiile implementate pot fi baze pentru dezvoltarea tehnologică și a ingineriei industriale.

**Colaborarea internațională dintre autoarea tezei de doctorat, coordonatoarea științifică acesteia și Profesor Dr. Jan D'Hooge de la K.U. Leuven, Belgia și Profesor Dr. Anjan Biswas, Department of Mathematical Sciences, Delaware State University Dover, SUA, a dus la rezolvarea unor probleme științifice ale imagisticii și la stabilirea unui cadru matematic adecvat cercetării.**

Datorită erei postindustriale pe care o trăim, care evoluează spre o eră informatizată, aportul adus societății informaționale prin folosirea software de ultimă generație privind procesarea imaginilor, aduce un plus de cunoaștere domeniului ingineriei industriale.



### 3. Obiectivele tezei

**Scopul investigației** – realizarea de operații de procesare ale imaginilor complexe din sfera ingineriei industriale și imagisticii medicale prin metode de segmentare și analiză fractală, care să conducă la un conținut informațional mai potrivit decât cel al imaginii originale și succedarea acestora de metode avansate de analiză statistică.

În conformitate cu titlul tezei de doctorat „**Metode avansate de procesare și analiză a imaginilor complexe**” și a referatelor științifice susținute în perioada stagiului de pregătire, au fost propuse și atinse următoarele obiective majore:

1. Îmbunătățirea imaginilor prin filtre liniare, neliniare, transformata Fourier și tehnica *wavelets*, prin eliminarea elementelor perturbatoare precum zgomotul continuu sau de tip impuls (*speckle noise*).
2. Evidențierea unor zone de interes prin realizarea propriilor imagini de caracteristici de ordinul I și ordinul II.
3. Analiza parțială sau totală a imaginilor complexe prin segmentarea imaginii.
4. Caracterizarea texturilor cu descriptorii extrași din histograma imaginii, descriptorii matricei de co-ocurență și cei ai matricei de izo-segmente.
5. Detectarea obiectelor dintr-o imagine cu ajutorul descriptorilor fundamentali de detecție a muchiilor.
6. Segmentarea imaginilor complexe cu tehnici moderne reprezentate de modele active de contur (*snakes*) și bazinul hidrografic (*watershed*).
7. Implementarea morfologiilor matematice într-un sistem software, pentru a interpreta imaginea prin momente statistice, momente geometrice sau momente Zernike de ordin superior, reducând-o de la structuri complexe la elemente structurate prin eliminarea caracteristicilor irelevante și păstrarea celor relevante.
8. Cuantificarea performanței segmentării și a calității imaginii cu metrici exprimate de: raportul semnal-zgomot (SNR), raportul contrast-zgomot (CNR), coeficientul de corelație (CoC), diferența medie pătratică (MSE), gradientul de contrast (GC), raportul ratei de erori a ariei (AER), radicalul erorii medii pătratice (RMSE- Root Mean Square Error) și valoarea de vârf a raportului semnal-zgomot (PSNR- Peak Signal to Noise Ratio)

9. Folosirea următoarelor metode statistice în evaluarea metodelor de segmentare și analiză fractală: curba ROC (Receiver Operating Characteristic), *nearest neighbor*, metoda validării încrucișate (*cross validation*), *t-score*, coeficientul Pearson.
10. Realizarea de aplicații software cu scopul de a automatiza: generarea imaginilor de caracteristici, extragerea descriptorilor de textură, relațiile de corelare dintre imaginile de caracteristici prin studii de analiză statistică.

#### 4. Diseminarea rezultatelor cercetării

Rezultatele obținute în urma cercetărilor din cadrul stagiului doctoral efectuat atât în țară cât și în străinătate, au fost diseminate prin publicarea de către autoare a 21 lucrări științifice în volume ale conferințelor naționale, internaționale și în jurnale științifice. Astfel, 10 lucrări indexate în bazele de date ISI Web of Knowledge și IEEE Xplore, 16 participări la conferințe dintre care 5 conferințe naționale și 11 conferințe internaționale.

#### 5. Structura lucrării științifice

Pentru îndeplinirea dezideratelor tezei de doctorat „**Metode avansate de procesare și analiză a imaginilor complexe**”, s-a recurs la structurarea acesteia în șase capitole cu un conținut consistent, unitar și bine fundamentat, la care s-au adăugat introduceri și concluzii, urmate de un rezumat în limba română și un Curriculum Vitae al autoarei. Lucrarea conține 282 pagini, 123 figuri, 47 tabele, 224 referințe și 3 anexe.

**Introducerea** descrie o incursiune în domeniul procesării digitale, dar și etapele realizării cu succes a temei abordate. Tot în acest capitol sunt punctate și motivația alegerii temei de cercetare, importanța și actualitatea științifică dar și detaliile cu privire la structura tezei.

**Capitolul 1** prezintă obiectul acestei cercetări, imaginea, proprietățile și elementele sale constitutive.

**Capitolul 2** fundamentează faptul că îmbunătățirea imaginii este etapa cheie în procesul de prelucrare. Capitolul conține un ansamblu al metodelor de îmbunătățire și aduce completări domeniului. Metodele tratate sunt de actualitate și au fost selectate atât metodele pentru care studiile de specialitate au furnizat rezultate utile, dar și cele care au fost testate în

contribuțiile personale. Robustețea metodelor prezentate este măsurată cu metrici dedicate evaluării filtrelor liniare sau neliniare. Abordările de ordin practic ale filtrelor performante și eficiența folosirii acestora sunt conținute în studii pe categorii de metode de îmbunătățire ale imaginilor.

**Capitolul 3** abordează problematica elementelor de analizare și cuantificare, pe de o parte, și a formelor extrase din imaginile complexe, pe de altă parte. Studiul este prezentat gradual de la momente statistice, momente geometrice (*momente Hu*) până la momente Zernike de ordin superior. Cuantificare texturii unei imagini descrisă în acest capitol este realizată cu ajutorul descriptorilor bazați pe histograma imaginii, descriptorilor de textură *Haralick*, matricea de izo-segmente dar și prin analiză fractală. Studii pe categorii de texturi independente dar și combinații între acestea au fost realizate în cadrul stagiului de cercetare pentru a evidenția caracteristicile texturale cele mai relevante pentru caracterizarea imaginilor complexe.

În **capitolul 4** sunt prezentate metodele de segmentare avansate, bazate pe histogramă, regiuni și contururi active (*snake*) pentru extragerea obiectelor de interes. Au fost abordate metode din același grup de interes, pentru a verifica eficacitatea acestora. Pentru fiecare metodă este descrisă atât forma de principiu cât și structurarea ei matematică. Contribuțiile personale folosind metodele amintite în vederea eficientizării segmentării pe diferite tipuri de imagini, întregesc acest capitol.

**Capitolul 5** prezintă o serie de rezultate experimentale care coroborează metodele prezentate în capitolele anterioare, testate pe imagini de caracteristici și astfel se aduce un plus de cunoștințe domeniului studiat.

**Capitolul 6** concluzionează lucrarea.

Fiecare dintre capitolele prezentate conțin introduceri, concluzii și bibliografii proprii. Finalul lucrării cuprinde o serie de anexe corespunzătoare codurilor sursă folosite în procesarea imaginilor.

# Capitolul I

## Reprezentarea imaginilor

În acest capitol s-a realizat o scurtă introducere cu privire la modul de interpretare al imaginilor, proprietățile și detalizarea informațiilor cu privire la tipurile de imagini care fac subiectul acestui studiu. Tipurile de imagini folosite în studiile realizate sunt: binare, RGB<sup>1</sup>, indexate și multiframe.

Din sinteza teoretică asupra imaginilor, se pot scoate în evidență următoarele:

- ✍ Modurile de interpretare ale imaginii dau flexibilitate în alegerea metodelor adecvate de procesare pentru a atinge dezideratul propus.
- ✍ Proprietățile imaginilor fac ca prin descompunerea acestora elementele esențiale să fie înțelese geometric sau textural.
- ✍ Imaginile pot fi interpretate atât ca sisteme 2D, 3D dar și ierarhic cu fișiere HDF5, așa cum este ilustrat în figura 1.1 [1]. Prelucrarea acestui tip de imagini reprezintă elementul de originalitate al acestei lucrări.

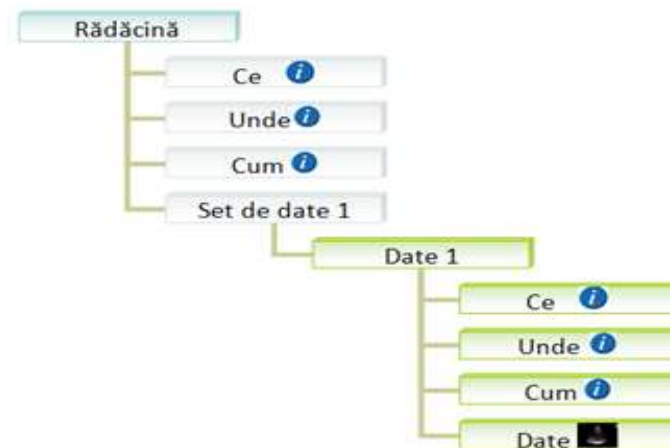


Figura 1.1 Aranjarea ierarhică a metadatelor HDF5

Contribuția autoarei în cadrul acestui capitol, constă în realizarea unei sinteze asupra prezentării imaginilor cu scopul înțelegerii obiectului de studiu al acestei lucrări.

<sup>1</sup> engl. Red, Green, Blue

## Capitolul 2

### Îmbunătățirea imaginilor complexe

#### 2.1 Introducere

Imaginile digitale precum cele satelitare, imagistica medicală, tomografia computerizată, sistemele informaționale, din domeniile geografice și astronomice, influențează zilnic activitățile noastre. Datele colectate de dispozitivele de captare ale imaginii sunt, în cele mai multe cazuri, afectate de zgomot. Imperfecțiunea instrumentelor și problemele care apar în procesul de achiziție pot degrada în mod constant informația utilă din imagine. În plus, zgomotul poate fi introdus și ca urmare a erorilor de transmisie și compresie a imaginilor, iar eliminarea zgomotului este adesea primul pas care trebuie realizat înainte ca imaginile să fie analizate. De aceea, alegerea unei metode eficiente de eliminare a zgomotului compensează înlăturarea elementelor nedorite din imagine.

În ultimul deceniu, s-au dezvoltat foarte mulți algoritmi destinați îmbunătățirii imaginilor complexe prin eliminarea componentelor parazite cum ar fi zgomotul (continuu sau de tip *speckle*) din imaginilor obținute cu ultrasunete. Imaginile pot fi îmbunătățite printr-un ansamblu de metode de prelucrare care au ca scop obținerea unei vizibilități superioare a componentelor imaginii. Generic, îmbunătățirea imaginii intervine în permanență asupra calității imaginii. Termenul de îmbunătățire este strâns legat de percepția vizuală subiectivă a unui expert uman, considerat utilizatorul final al imaginii.

Întrucât nu se pot defini standarde de calitate ale imaginilor, calitatea acestora rămâne un criteriu subiectiv. În plus, este indicat ca îmbunătățirea imaginilor să fie interactivă și iterativă pentru ca utilizatorul să poată interveni în permanență asupra calității lor. Fiecare utilizator o va face într-un mod caracteristic [2].

Pentru a rezolva paradigma calității imaginilor, experții din domeniul procesării au propus diferite metrice cum ar fi metrica de similaritate exprimată de rapoartele semnal-zgomot (SNR) și raportul contrast-zgomot (CNR); sau compararea unei imaginii cu alta de referință prin coeficientul de corelație (CoC) și diferența medie pătratică (MSE). Metodele de îmbunătățire ale imaginilor reprezentate de filtre sau transformări *wavelets* nu generează informații suplimentare despre imaginea originală, ci doar o pune pe cea existentă sub o altă

formă, mai ușor de interpretat. Procesul prin care acționează un filtru asupra unei imagini se numește *convoluție* și se poate aplica atât în domeniul spațial cât și în domeniul frecvenței.

Pentru o viziune globală asupra metodelor de filtrare se prezintă schema lui *Motwani et al.* [3], figura 2.1, îmbunătățită cu metodele actuale de filtrare în domeniul spațial, folosite cu preponderență în îmbunătățirea imaginilor complexe.

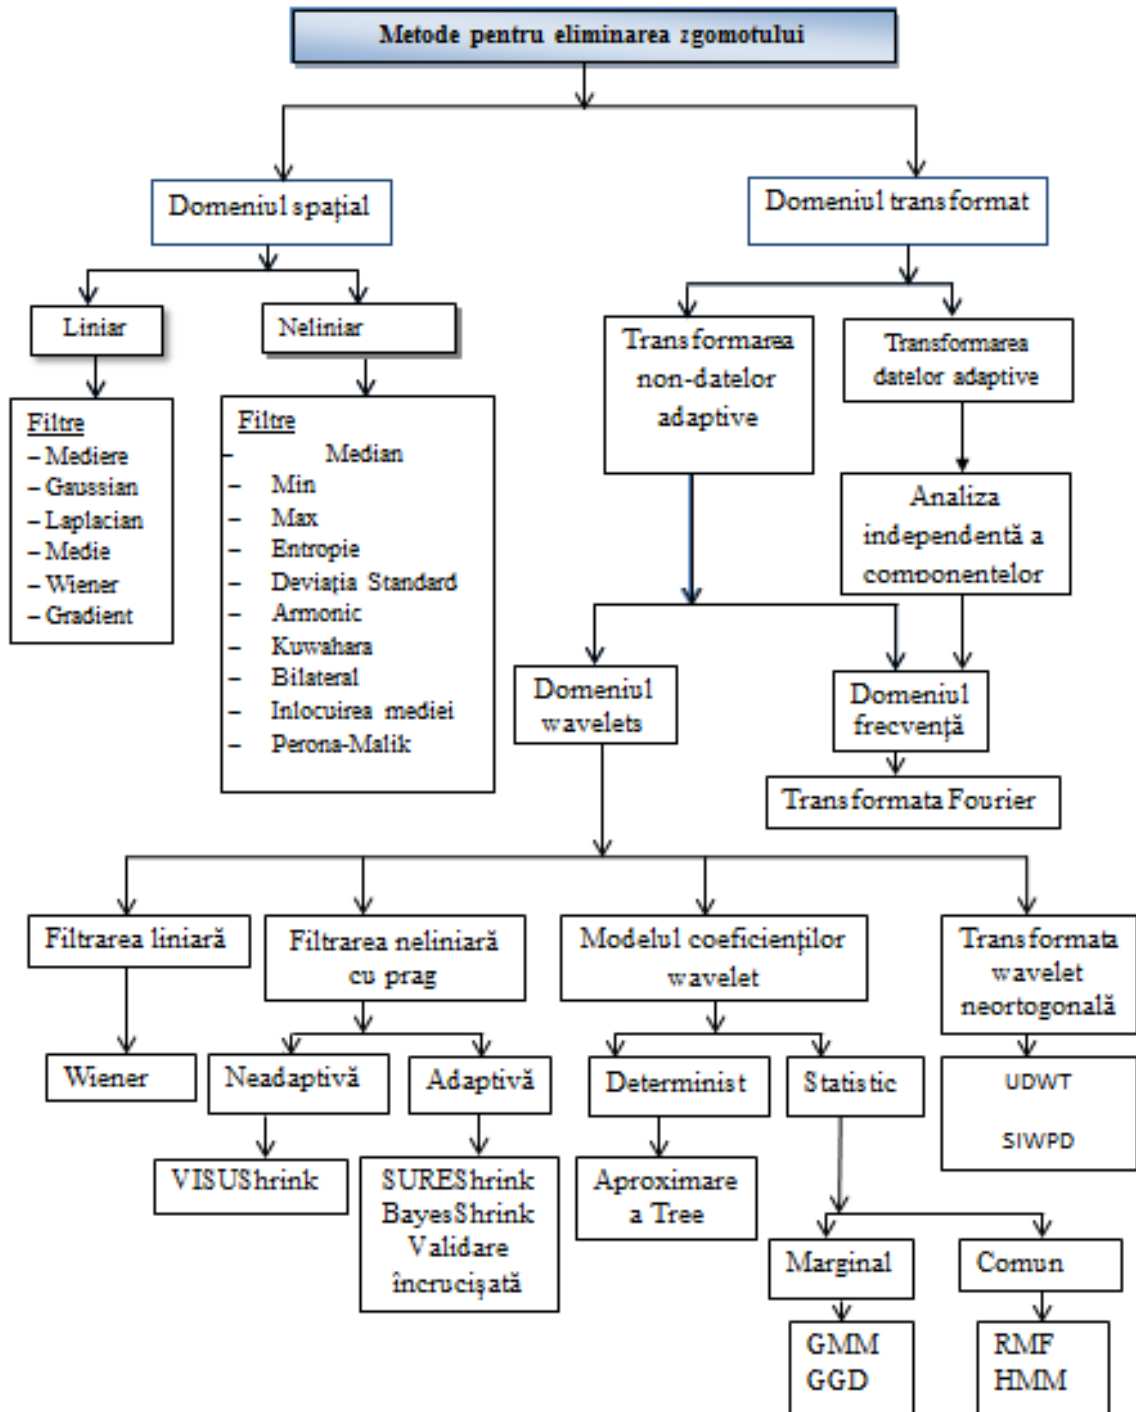


Figura 2.1. Metode de filtrare

Structura capitolului curent este divizată în două subcapitole. Primul subcapitol este dedicat aspectelor teoretice iar la rândul lui este împărțit în două secțiuni, prima parte conține tipurile de elemente perturbatoare care afectează imaginea și în partea a doua sunt prezentate descrierile matematice ale metodelor de îmbunătățire a imaginilor. Al doilea subcapitol este cel mai laborios prin conținut deoarece cuprinde date experimentale, metode, efectele metodelor și imaginile prelucrate.

### 2.3 Contribuții personale privind îmbunătățirea imaginilor

În această secțiune se prezintă rezultatele experimentale privind performanțele filtrelor liniare și neliniare, *wavelets*, și analiza Fourier pentru eliminarea efectelor nedorite din imaginile ecografice. Pentru a scoate în evidență performanța și utilitatea filtrelor s-a aplicat pe rezultatul de ieșire al acestora descriptorii de calitate.

Îmbunătățirea imaginilor fiind etapa premergătoare segmentării acestora, prin studiile realizate am scos în evidență filtrele și *wavelets*, care dau cele mai bune rezultate.

Mediul experimental a fost compus cel prezentat în introducerea acestui rezumat.

Acest subcapitol se ramifică în trei direcții de cercetare independente și interdependente, o direcție de cercetare acoperă filtrele liniare și neliniare, a doua este dedicată *wavelets* iar a treia tratează analiza Fourier. Cele trei direcții de cercetare au cuprins folosirea următoarelor studii asupra imaginilor ecografice sau ecocardiografice cu metode de filtrare: (i) filtrele care pot elimina *speckles* cum sunt filtrul median, Wiener și Gaussian; (ii) clasificarea obiectelor din imaginile ecografice îmbunătățite cu filtrele: de minim, de maxim, median și geometric; (iii) eliminarea zgomotului din imaginile ecografice renale cu *wavelets* Haar; (iv) eliminarea zgomotului din imaginile ecografice ale colonului cu *wavelets* Daubechies; (v) eliminarea zgomotului dintr-un ciclu cardiac cu *wavelets* complexe cu arbore dual; (vi) îmbunătățirea imaginilor ecocardiografice cu transformata Fourier.

#### 2.3.1.1 Rezultate experimentale privind eliminarea *speckles* din imagini ecocardiografice

Pentru un studiu complet și pentru a reliefa filtrul care furnizează cele mai bune rezultate pentru toate modurile de vizualizare dintr-o ecocardiografie: apical două camere,

(*apical two chamber view A2C*), apical patru camere (*apical four chamber view A4C*), parasternal ax lung (*parasternal long axis view, LAX*) și parasternal ax scurt (*parasternal short axis view SAX*) am utilizat filtrele: median, Wiener și Gaussian, de-a lungul unui ciclu cardiac. S-a realizat o analiză secvențială amănunțită, iar între două cadre consecutive a fost calculat coeficientul de corelație (CoC). Pentru a detecta cum este afectată imaginea de zgomot a fost calculat CoC pentru tot ciclul cardiac între cele două faze majore: sistola și diastola.

Alegerea filtrelor menționate se justifică prin faptul că filtrul Wiener este un filtru optim utilizat la restaurarea liniarității unei imagini, filtrul median este considerat ca fiind filtrul care estimează cel mai bine zgomotul unei imagini [4], iar filtrul Gaussian este cel mai indicat pentru netezirea și eliminarea umbrelor din imagini [5].

Exemple de imagini ecocardiografice ale celor patru moduri de vizualizare ale cordului: A2C, A4C, LAX și SAX sunt prezentate în figura 2.2. Imaginile prezentate aparțin unui pacient sănătos cu vârsta de 39 ani și sunt preluare cu ecograful VIVID E9.




Figura 2.2 Modurile de vizualizare: (a) apical două camere (A2C), apical patru camere (A4C), parasternal ax lung (LAX), și parasternal ax scurt (SAX).

Indicațiile referitoare la structura anatomică, a modurilor de vizualizare și a începutului respectiv sfârșitului ciclului cardiac, au fost date de către specialiștii laboratorului, Medical Imaging, Centre Department of Cardiovascular Diseases, University Hospital Gasthuisberg, K.U. Leuven, Belgium.

Pentru un studiu comparativ la începutul experimentului a fost calculat coeficientul CoC, între cadrele unui ciclu cardiac asupra căruia nu s-a intervenit cu niciun filtru. Valorile medii ale coeficientului CoC obținute pentru secvența de imagini nefiltrate sunt prezentate în tabelul 2.1, corespunzătoare modurilor de vizualizare SAX, A2C, LAX, A4C.

Luând în calcul evoluția coeficientului CoC, pentru fiecare mod de vizualizare de-a lungul unui ciclu cardiac și putem afirma că există diferențe semnificative între valorile



obținute pentru imaginile ecocardiografice nefiltrate și cele filtrate cu filtrele Wiener, median și Gaussian. În același timp, sunt diferențe între mediile valorilor CoC pentru imaginile filtrate. Digrama afișată în figura 2.3, reflectă cele mai bune rezultate pentru filtrul Wiener în modul de vizualizare SAX și A2C. Filtrele Wiener și median furnizează rezultate relevante pentru modul de vizualizare A2C. Filtrele Wiener și Gaussian sunt cele mai adecvate pentru modul de vizualizare LAX iar pentru A4C cele mai bune rezultate le dă filtrul Gaussian.

Diagrama afișată în figura 2.4, scoate în evidență că valorile Coc se găsesc cu preponderență în intervalul [0.98; 0.985], aceasta semnificând că filtrele folosite au generat valori în acest interval, mai mult decât atât, cele mai mari valori sunt în intervalul [0.985; 0.99] și aparțin vizualizării SAX [6].

Tabelul 2.1 Media aritmetică a coeficientului de corelație în concordanță cu cele patru moduri de vizualizare.

	SAX	A2C	LAX	A4C
Fără filtrare	0.98	0.9795	0.97	0.9725
Filtru Median	0.98	0.985	0.982	0.983
Filtru Wiener	0.99	0.9835	0.9845	0.9805
Filtru Gaussian	0.983	0.9805	0.985	0.983

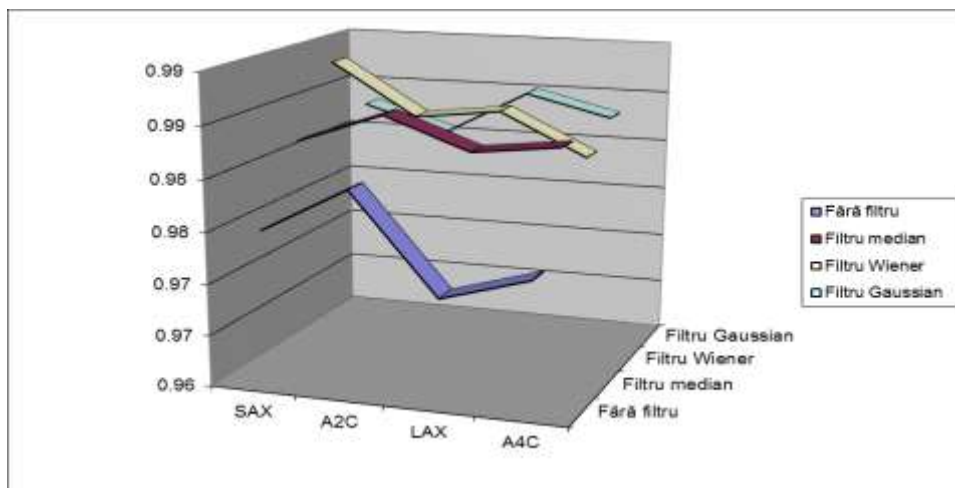


Figura 2.3 Evoluția valorilor CoC pentru cele patru moduri de vizualizare.

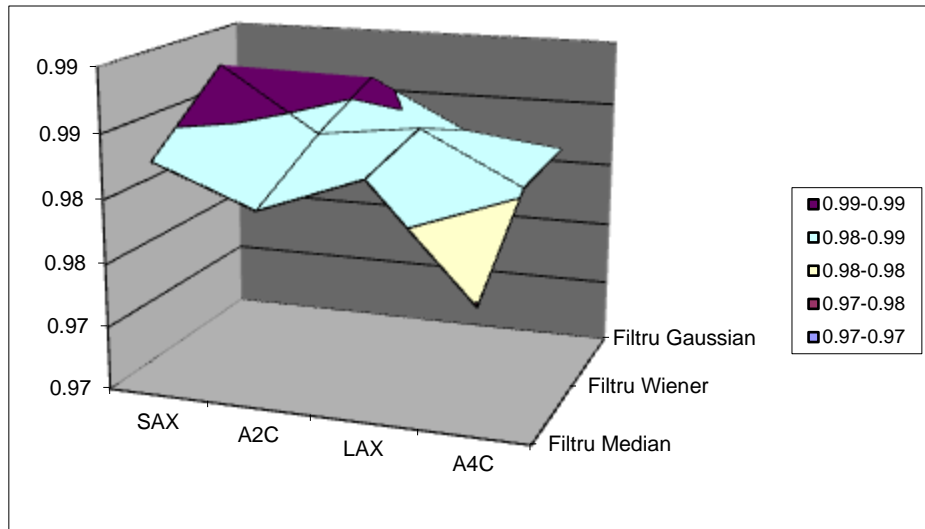


Figura 2.4 Apartenența valorilor CoC pentru fiecare mod de vizualizare

# Capitolul III

## Descriptori imagistici de formă și textură

### 1.1 Introducere

În general, prelucrarea semnalelor multidimensionale este bazată pe exploatarea conceptelor și teoriei sistemelor liniare și a transformatei Fourier [7-9]. Abordările clasice ale semnalelor multidimensionale dau rezultate semnificative în diferite aplicații, dar cele limitate la semnalele bidimensionale (și aici ne referim la imagini) au aplicabilitate redusă datorită modului de reprezentare, texturi sau structurii geometrice ale obiectelor existente pe scena imaginii.

Prelucrarea semnalelor se poate realiza cu morfologii matematice, care simplifică imaginea cu structuri complexe în elemente simple, eliminând din aceasta caracteristicile irelevante. Morfologia matematică face ca obiectele imaginii să fie corelate cu forme geometrice regulate sau neregulate, toate acestea implicând imaginile ca instrumente valide în dezvoltarea tehnicilor inteligente aplicate în ingineria industrială.

Trăsăturile imagistice de formă și textură fac ca imaginea să poată fi transformată în forme mai simple, dintr-un cumul de forme inițial complexe ale imaginii [7], sau să grupeze *pattern*-urile în entități sau *subpattern*-uri cu proprietăți locale cum ar fi: luminozitate, uniformitate, densitate, rugozitate, regularitatea, liniaritate, frecvență, direcționalitate, finețe și granularitate [9].

Textura este una dintre cele mai importante caracteristici utilizate în identificarea obiectelor de interes indiferent de ce natură este: fotomicrografică, ecografică, satelitară, etc.

Analiza texturală a imaginii poate fi realizată pentru următoarele scopuri:

- Extragerea caracteristicilor, printr-o metodă care poate să descrie numeric proprietățile texturii;
- Diferențierea texturii, prin partiționarea imaginii în regiuni, fiecare regiune corespunzând unui nivel perceptual omogen;
- Clasificarea texturii, prin definirea unor zone din imagine, care se pot clasifica ca făcând parte dintr-o clasă cum ar fi, textură omogenă, neomogenă sau textură care

caracterizează imaginile biomedicale cu ajutorul cărora se pot clasifica țesuturile ca fiind normale sau anormale;

- Forma texturii, presupune extragerea de caracteristici geometrice din informațiile texturale.

Analiza texturii se poate realiza structural, statistic sau poate fi bazată pe modele sau transformări. Abordarea statistică a texturii se realizează cu primitive microstructurale (momentele de ordinul I și II) și primitive macrotexturale (aranjamente ierarhice ale texturii). Descrierea texturii prevede definirea primitivelor și reguli de plasare ale acestora. La alegerea unei primitive dintr-un set de primitive se are în vedere ca primitiva aleasă să satisfacă descrierea locală a texturii sau a unui segment din aceasta. Abordările structurale furnizează o bună descriere a imaginii prin simboluri, și sunt mai utile pentru a realiza o sinteză a imaginii decât o analiză a ei. Un instrument puternic folosit în descrierea texturii structurale îl reprezintă morfologia matematică. Analiza texturilor pe baza modelelor se poate realiza în mod stocastic cu ajutorul fractalilor, care interpretează imaginea generând modele recursive. Parametrii determinați din astfel de modele sunt estimați și utilizați la analiza imaginii. Modelul fractal poate fi utilizat pentru modelarea fenomenelor naturale dar și în modelarea și analizarea imaginilor [9].

În contrast cu metodele structurale se află metodele statistice, care nu încearcă să explice structura ierarhică a texturii, în schimb, reprezintă textura în mod indirect prin proprietăți nedeterminate ce guvernează distribuția între nivelurile de gri dintr-o imagine. Descriptorii statistici s-au dovedit a fi mai performanți decât cei bazați pe puterea spectrului și cei structurali. În concordanță cu imaginile cu niveluri de gri, cele mai populare instrumente de caracterizare a texturilor sunt cele de ordinul doi (matricea de co-ocurență). Acestea caracterizează cel mai bine imaginile biomedicale. Cu un efort cognitiv s-au dedus și momente statistice de ordinul trei (matricea de izo-segmente), dar și cele de ordin superior (Zernike și Legendre).

Texturile folosite în majoritatea studiilor sunt: caracteristicile texturale de ordinul I extrase din histograma imaginii, caracteristicile texturale de ordinul II, dezvoltate de Haralick [10] cunoscute și sub numele de matricea de co-ocurență și caracteristicile texturale dezvoltate de Galloway [11], cunoscute și ca matricea de izo-segmente completată de Chu *et al.*[12] și Dasarathy *et al.* [13]. Elemente texturale ca muchii, forme, și poligoane Voronoi au fost cercetate în studiile [14-16]. Law [17,18], a dezvoltat un alt set de caracteristici texturale ca: uniformitatea, densitatea, rugozitatea, regularitatea, liniaritatea și direcția. Numărul mare

de caracteristici texturale dă larghețe în alegerea caracteristicilor potrivite pentru a atinge scopul unui studiu. Toate caracteristicile enumerate sunt dezvoltate în studiul de tip *review* [19] al autoarei tezei, fiind dedicat caracterizării texturii miocardului din imaginile ecocardiografice.

Acest capitol este concentrat pe analiza texturală și divizat în cinci subcapitole, primele patru subcapitole prezintă pe larg descrierea teoretică a texturii. Al cincilea subcapitol conține contribuțiile personale, care implică caracteristicile prezentate în subcapitolele dedicate teoriei.

### **3.5 Cercetări experimentale proprii privind extragerea caracteristicilor texturale din imaginile complexe**

Cercetările întreprinse în acest capitol au constat în: (i) proiectarea unei aplicații software de tip șablon cu ajutorul căreia se pot determina valorile gradientilor magnitudine, direcție și se pot calcula diferențe care apar în modurile de vizualizare: apical două camere (A2C) și parasternal axe scurte (SAX) în segmentul „bazal inferior”; (ii) testarea evoluției parametrilor: deviația standard, skewness, kurtosis și entropia cu scopul de a-i alege pe cei mai semnificativi, care pot face diferențierea țesuturilor miocardice, normale sau anormale reprezentate de ecocardiografii; (iii) împărțirea claselor texturale corespunzătoare imaginilor ultrasonografice ale ficatului sănătos și steatozic în clustere cu algoritmul *k-nn* și analiza caracteristicilor texturale de ordinul II; (iv) combinarea descriptorilor texturali precum dimensiunea fractală, numărul lui Euler și a unui descriptor de izo-segmente în vederea validării unui sistem decizional; (v) reconstruirea cifrelor din imagini degradate cu momentele Zernike.

Rezultatele prezentate în acest capitol au fost diseminate pe parcursul stagiului doctoral în 9 articole publicate în reviste cotate ISI, BDI și volume ale conferințelor internaționale.

În cadrul cercetării, s-au ales descriptorii care aduc elemente justificative de interpretare ale imaginilor, și care pot analiza cele mai fine detalii ale acestora.

#### **3.5.1 Studiu comparativ al țesutului miocardic bazat pe descriptorii gradient**

În continuare vom prezenta caracterizarea țesutului miocardic prin intermediul imaginilor ecocardiografice. Această caracterizare a constituit un subiect de interes pentru

autorii studiilor [20-22], fiind mai ușor de realizat odată cu posibilitatea ca imaginile să fie achiziționate și procesate pe calculatoare personale.

Analiza texturii ecocardiografiei poate interpreta orientarea fibrelor miocardului și poate fi utilizată în stabilirea patologiei. Scopul acestui studiu este explorarea aplicabilității caracteristicilor texturale bazate pe gradient, ca metodă de interpretare a țesutului miocardic, indiferent de modul de vizualizare a acestuia. De aceea, am investigat segmentul „bazal inferior” în modul de vizualizare apical două camere (A2C) și parasternal axe scurte (SAX).

Pentru proiectarea șablonului din figura 3.1 în vederea decupării cu exactitate a fiecărui cadru din ecocardiografie am adaptat la studiul nostru șablonul propus de J. Park *et.al.* [23], în care dimensiunile  $d_1, d_2, d_3, d_4$  au fost alese astfel încât să fie respectate coordonatele segmentului „bazal inferior”.



Figura 3.1 Șabloanele folosite în decuparea regiunilor de interes; (a) Decuparea segmentului bazal inferior din modul de vizualizare SAX; Decuparea segmentului bazal inferior din modul de vizualizare A2C

Clasele studiate A2C și SAX au fost divizate în alte două subclase în funcție de gradientul direcție respectiv, magnitudine astfel: A2C-gradient direcție, A2C-gradient magnitudine, SAX-gradient direcție, SAX- gradient magnitudine.

Cele patru subclase stabilite sunt comparate două câte două cu metoda *t-test* ca eșantioane independente. Valorile *p* furnizate de metoda statistică sunt stocate în tabelul 3.1.

Tabelul 3.1. Eroarea standard a mediilor dintre subclase cu 95% intervalul de încredere.

Subclase	Valoarea p
A2C / SAX gradient magnitudine	0.022
SAX /A2C gradient magnitudine	0.021
A2C / SAX gradient direcție	0.135
SAX / A2C gradient direcție	0.147

### 3.5.2 Caracterizarea structurii miocardului din imaginile ecocardiografice cu caracteristici de ordinul I

Analiza vizuală a ecocardiografiei joacă un rol important în stabilirea corectă a diagnosticului. În studiul nostru propunem o analiză a ecocardiografiei miocardului prin caracteristicile texturale de ordinul I precum: media, deviația standard, skewness, kurtosis, entropia.

Caracteristicile de ordinul I, II și cele de ordin superior au fost aplicate cu succes pentru analiza texturală a ecocardiografiei, pentru a evalua starea de sănătate a miocardului sau pentru a-l clasifica ca normal sau anormal.

Caracterizarea miocardului cu caracteristicile de ordinul I s-a realizat în studiile [24] pentru a diferenția miocardul normal de cel anormal [25] al pacienților cu diabet.

Studiul propus de noi, se axează pe analiza ecocardiografiilor miocardului sănătos și cu infarct. Pentru fiecare pacient studiat a fost analizată evoluția caracteristicilor texturale de ordinul I cunoscute și sub numele de momente statistice.

Ecocardiografiile au fost preluate de la 12 de pacienți dintre care 6 pacienți sănătoși și 6 pacienți care au suferit un infarct miocardic, din acestea s-au decupat în vederea analizei 12 regiuni de interes.

Evaluarea texturii miocardului prin parametrii de ordinul I permite estimarea proprietăților fiecărui pixel care contribuie la realizarea texturii ecocardiografiei. Pentru o evaluare completă am implicat în studiu toți parametrii statistici de ordinul I. Calcularea acestora a fost făcută din cadrele sfârșit sistolă și sfârșit diastolă, iar evoluția lor a fost urmărită pentru fiecare pacient. Motivația studierii ambelor cadre a constat în faptul că

mișcarea cordului fiind foarte complexă este posibil ca analizând același țesut în două cadre diferite ale ecocardiografiei să se obțină valori diferite ale parametrilor.

Tabelul 3.2. Valorile momentelor statistice de ordinul I, pentru cele două categorii de pacienți

	Miocard sănătos		Infarct miocardic	
	Sfârșit diastolă	Sfârșit sistolă	Sfârșit diastolă	Sfârșit sistolă
Media	90.27 ± 41.56	89.52 ± 39.94	116.19 ± 17.36	109.18 ± 12.15
Deviația Standard	119.13 ± 7.01	120.01 ± 6.61	36.73 ± 7.09	34.76 ± 5.16
Skewness	1.86 ± 0.66	1.76 ± 0.44	1.65 ± 0.12	1.95 ± 0.1
Kurtosis	5.6 ± 2.4	5.17 ± 1.62	4.97 ± 0.65	4.86 ± 0.3
Entropia	6.15 ± 0.56	6.23 ± 0.52	9.12 ± 0.29	9.95 ± 0.17

Evoluțiile parametrilor statistici corespunzătorii fiecărei clase de pacienți sunt trasate în diagramele din figurile 3.2 și 3.3 pentru cele două cadre menționate.

Asupra setului exhaustiv de parametri de ordinul I ca: media, deviația standard, skewness, kurtosis și entropia implicați în studiu putem face două tipuri de aprecieri. O primă apreciere asupra diferențelor dintre valorile parametrilor care sunt observabile între cele două tipuri de țesuturi sănătos și infarct și una secundară asupra diferențelor dintre valorile parametrilor extrași din cadrele sfârșit sistolă și sfârșit diastolă.

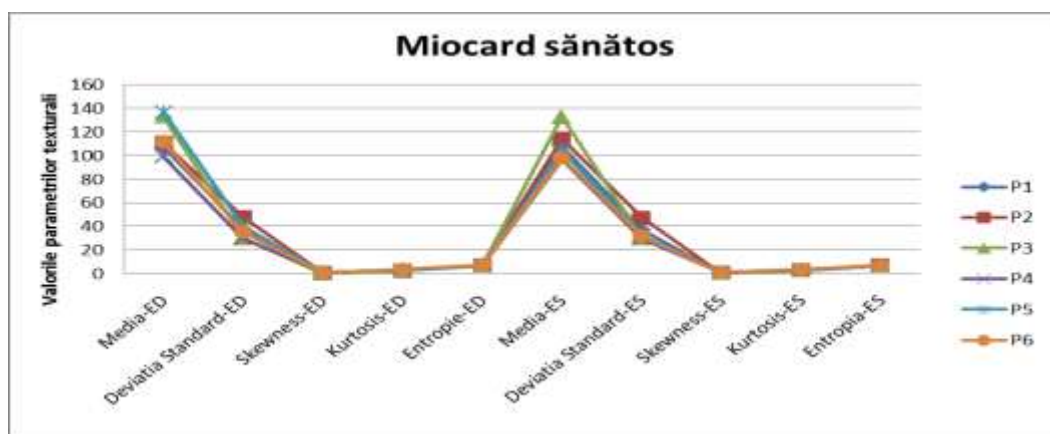


Figura 3.2 Evoluția momentelor statistice de ordinul I pentru pacienții sănătoși P<sub>1</sub>-P<sub>6</sub>



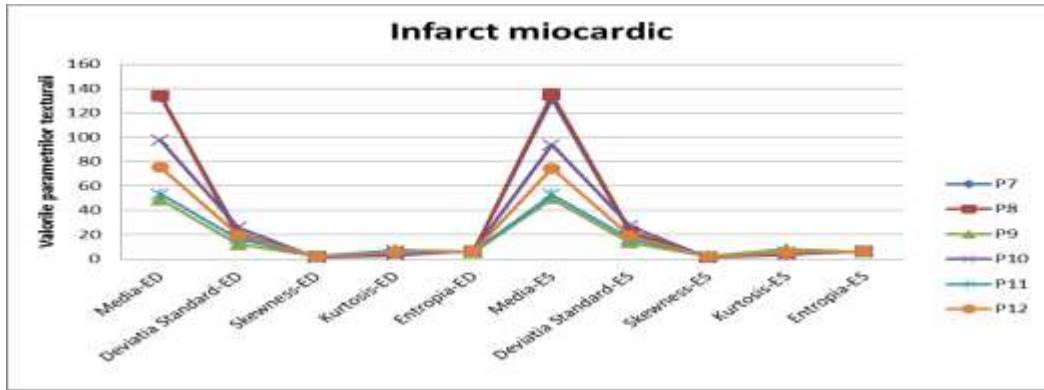


Figura 3.3 Evoluția momentelor statistice de ordinul I, pentru pacienții cu infarct miocardic P7-P12.

### 3.5.4 Sistem suport de decizie automată în investigația steatozei hepatice

Sistemul de diagnoză automată (SDA) a fost conceput pentru a rezolva probabilitatea clasificării imaginilor ecografice ale ficatului sănătos de cel steatozic. Aplicația poate rula atât independent, cât și integrată într-un sistem CAD (*computer-aided diagnosis*) fiind concepută ca o aplicație destinată cercetării texturilor cu descriptori specifici imaginilor binare.

Motivația alegerii descriptorilor a constat în importanța alegerii pragului optim de binarizare, deoarece un prag ales într-un mod aleatoriu ar duce la un rezultat degenerat. Metoda Otsu, bazată pe o analiză discriminatorie, împarte imaginea în clase și generează pragul optim (PO) de binarizare. Dimensiunea fractală (DF) este folosită cu succes în analiza imaginilor biomedicale și este extrasă din imagini binarizate de aceea alegerea PO este o etapă importantă. Valoarea DF a fost calculată cu metoda "box-counting". Un alt descriptor ales este descriptorul topologic numit numărul lui Euler (NE) care este „una dintre cele mai importante caracteristici ale topologiei” [26]. Pentru calcularea NE, în SDA s-au implementat algoritmi care determină concavitățile și convexitățile muchiilor ce compun imaginea. Ultimul descriptor își are apartenența în matricea de izo-segmente și este definit de proporția izo-segmentelor (RF5).

Din imaginile binarizate cu PO se extrag valorile DF, NE și RF5 în vederea stabilirii relațiilor de corelații dintre PO/DF, PO/NE, PO/RF5, cu coeficientul de corelație Pearson (CCP).

Structura fiecărui modul și rolul fiecărui bloc component este descris în cele ce urmează: modulul I, are rolul de a pregăti imaginea pentru procesare, urmărind secvențial blocurile constituente; modulul II, are rolul de a afișa imaginile în aplicație și de binarizare ale acestora; modulul III, este cel mai laborios modul și important deoarece conține cheia aplicației. Acesta

conține module realizate din metode individuale pentru DF, NE, RF5, iar valorile obținute sunt corelate; modulul IV, sau modulul decizional discerne și recunoaște cu ajutorul rețelelor neuronale (ANN) imaginile binare ale ficatului, obținute cu ajutorul modulelor anterioare, ca fiind sănătos, steatozic sau diagnostic incert. Tot în acest modul se antrenează rețelele neuronale cu tipurile de imagini obținute în modulul II.

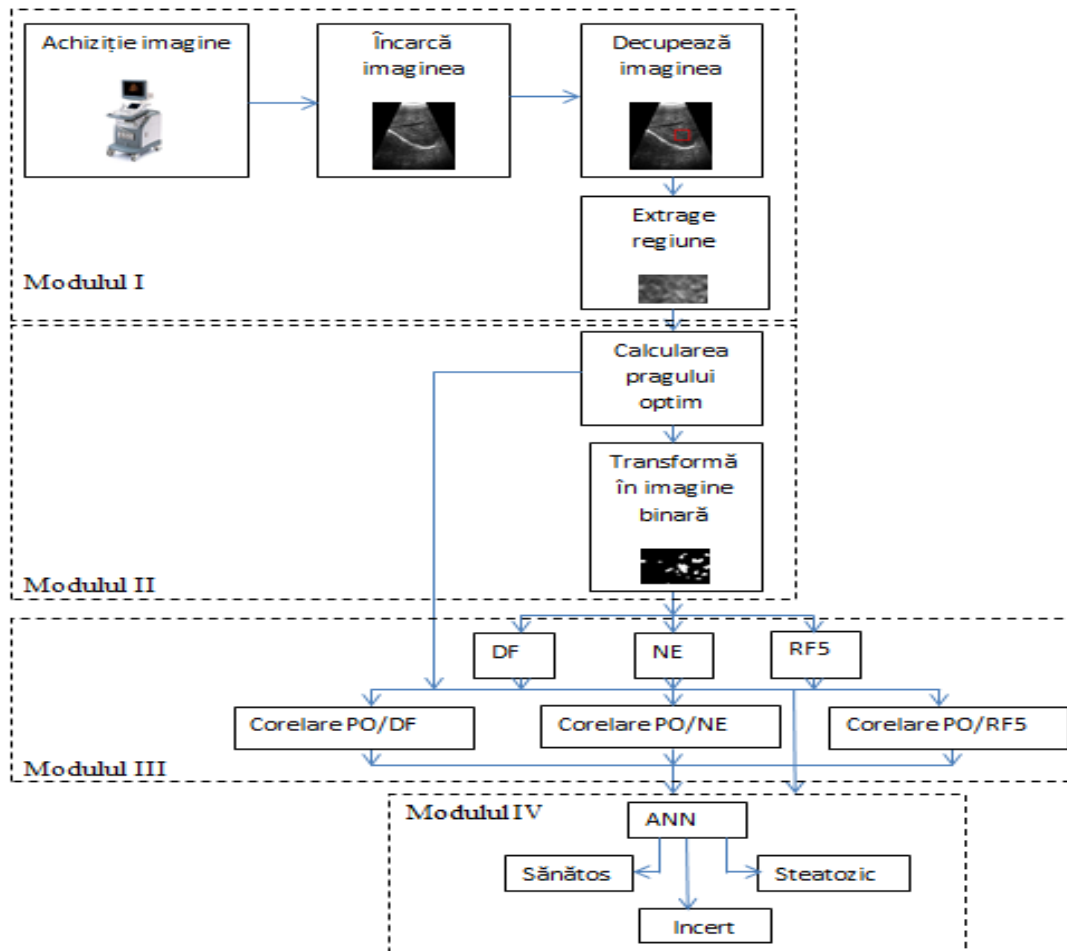


Figura 3.4 Diagrama bloc a sistemului SDA

Tabelul 3.3, prezintă eficacitatea sistemului SDA date de rata de clasificare corectă CCR, sensibilitate și specificitate.

Tabelul 3.3 Performanțele sistemului SDA

CCR	Sensibilitate	Specificitate
94 %	96 %	92 %

Performanțele sistemului SDA depind de corectitudinea cu care se aleg regiunile de interes din imaginea ecografică.

## Capitolul IV

### Metode de segmentare și analiză fractală.

#### 4.1 Introducere

Toate operațiile de procesare ale imaginilor, pentru o mai bună recunoaștere a obiectelor de interes sau pentru găsirea caracteristicilor locale ce permit distingerea obiectelor de fundalul (sau scena) imaginii, trebuie însoțite de operația de segmentare.

Segmentarea este definită de către Ivanovici, în lucrarea [7], ca “împărțirea imaginii în zone de interes, după anumite criterii”. În procesul de prelucrare al imaginilor etapa segmentării este necesară deoarece, așa cum specifică Vertan în lucrarea [27] „În urma procesului de segmentare vor fi extrase din imagine obiecte distincte, regiuni ce satisfac anumite criterii de uniformitate sau alte elemente”. În opinia lui Jähne [28], această etapă nu poate fi omisă deoarece ”segmentarea este considerată etapa intermediară dintre îmbunătățirea imaginii și analiza acesteia”.

După procesul de segmentare se poate verifica dacă fiecare pixel al unei imagini aparține sau nu obiectelor de interes, de asemenea se poate analiza forma obiectelor cu ajutorul momentelor discutate în capitolul anterior.

#### 4.5 Cercetări experimentale proprii asupra imaginilor ecografice cu metodele de segmentare

În acest capitol s-a întreprins șase direcții de cercetare asupra imaginilor ecografice care au constat în: (i) monitorizarea tumorilor la sân prin metode de interpolare și segmentare a histogramei; (ii) segmentarea imaginilor ecografice cu metoda „snake” și analiza obiectelor de tip leziuni la sân, cu momente statistice și geometrice; (iii) segmentarea tumorilor complexe ale colonului cu metoda *watershed*; (iv) realizarea unei metode test de segmentare cu ACM a imaginilor ecocardiografice; (v) combinarea metodelor ACM și *watershed* pentru caracterizarea imaginilor de caracteristici obținute cu momentul statistic numit deviația standard; (vi) metoda de analiză fractală a fost folosită la determinarea dimensiunii fractale și departajarea imaginilor ecografice la ficat și sân.

#### 4.5.2 Momente statistice și geometrice extrase din imaginile ecografice pentru clasificarea leziunilor la sân

Prin acest studiu propunem o nouă metodă, ce ne va permite selecția caracteristicilor statistice și geometrice întâlnite și sub denumirea de momente ale imaginii, cu scopul de a determina caracteristicile texturale cele mai elocvente care pot partaja leziunile sânului de tip chisturi *versus* tumori. În contextul aceluiași standard BI-RADS, care divizează leziunile sânului, am analizat un set de 52 subiecți, dintre care 28 cu chisturi, respectiv 24 cu tumori.

Momentele statistice prezentate au fost calculate și stocate într-o bază de date corespunzătoare programului statistic SPSS. Pentru diferențierea în notație s-a folosit următoarea simbolică:  $\mu_1$  -media,  $\mu_2$  -deviația standard,  $\mu_3$  skewness și  $\mu_4$  kurtosis.

La fel cum s-a procedat pentru momentele statistice, s-a aplicat metoda *t-test* între eșantioanele obținute pentru momentele geometrice. Aceste eșantioane au fost partajate pentru următoarele caracteristici:  $m_{00}$  (momentul zero sau aria regiunii de interes), OR (orientarea), AR (elongația), RT (rectangularitatea), AC (aria de convexitate), PC (perimetrul de convexitate), EC (excentricitatea), CC (circularitatea) și FF (raportul de compacitate).

Evaluarea variabilității scorurilor și stabilitatea caracteristicilor clasificate se realizează astfel: setul de antrenare angajat în validare variază de la 1 la 10; un număr mai mare decât 10 ar da un set de antrenare mai mic și *vice versa*. Pentru seturile de date ale caracteristicilor selectate de algoritmul *greedy* rata de clasificare este dată în figura 4.1.

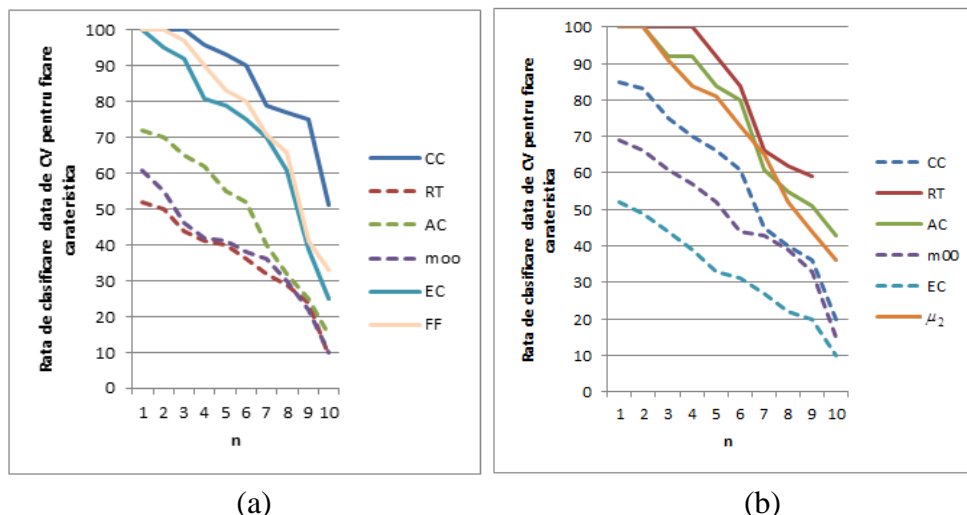


Figura 4.1 Rata de clasificare a caracteristicilor geometrice și statistice validate cu *leave-one-out* în care seturile alocate variază de la 1 la 10. Linia continuă denotă caracteristicile valide iar linia punctată corespunde caracteristicilor invalide. (a) chisturi; (b) tumori;

#### 4.5.5 Studiu comparativ al performanțelor imaginilor de caracteristici testate cu metoda conturului activ

Imaginile de caracteristici se pot obține prin convoluția imaginii originale cu un nucleu cu diferite dimensiuni din care se poate extrage valori ale caracteristicilor de ordinul I (din histograma imaginii) sau de ordinul II (din matricea de co-ocurență), valori care compun pixel cu pixel imaginea de caracteristici. Testarea performanțelor pentru astfel de imagini s-a realizat cu metoda de contur activ și cu metoda *watershed*. Imaginile ecografice folosite au reflectat patologii ca, chisturi la sân și chisturi hepatice. Numărul de subiecți testați au fost de 16 chisturi la sân și 10 polichisturi hepatice.

Valorile AER care au furnizat cele mai mici erori ale imaginilor testate sunt afișate în tabelul 4.1.

Tabelul 4.1 Valorile AER pentru testarea segmentării chisturilor la sân cu ACM

Imagini	AER (%)			
	Imaginea originală	$I_{SD3 \times 3}$	$I_{SD5 \times 5}$	$I_{SD7 \times 7}$
Imaginea sintetică	<b>5.64</b>	<b>12.50</b>	<b>4.79</b>	<b>18.40</b>
Imagini <i>in vivo</i>				
1	13.38	25.00	7.61	16.05
2	12.50	26.85	12.76	12.94
3	13.21	25.98	2.53	15.75
4	14.49	20.85	11.07	10.13
5	16.63	24.02	8.62	13.02
6	19.24	29.83	7.04	11.75
7	20.20	25.26	7.03	16.34
8	14.43	23.84	9.49	13.44
9	17.86	29.62	6.72	13.89
10	15.43	24.48	9.09	14.09
11	14.51	23.57	8.64	17.48
12	11.08	27.16	12.14	9.05
13	10.10	26.58	19.89	17.12
14	17.50	26.75	10.73	15.32
15	14.17	23.55	11.05	7.03
16	13.76	29.07	6.70	15.97
<b>Media aritmetică</b>	<b>14.90</b>	<b>25.77</b>	<b>8.88</b>	<b>13.71</b>

Performanța obținută de ACM o devansează pe cea obținută de *watershed*, rezultat confirmat pentru toate tipurile de imagini sintetice și *in vivo*. Imaginea de caracteristici  $I_{SD5 \times 5}$  furnizează cele mai bune rezultate.

## Capitolul V

### Contribuții originale proprii în domeniul prelucrării imaginilor complexe: folosirea imaginilor de caracteristici

Așa cum s-a prezentat și susținut prin datele experimentale în această lucrare de doctorat, secvența etapelor de procesare trebuie parcursă cu grijă astfel încât la sfârșitul tuturor etapelor să se ajungă la rezultatul scontat.

Etapă de achiziție a imaginilor este prima etapă de procesare, în care se stabilește conținutul informațional al imaginii și necesită cunoștințe de specialitate pentru cel care manevrează sistemul de achiziție. În funcție de tipul de informații se pot selecta metodele succesoare adecvate pentru procesarea imaginilor. În general, imaginile achiziționate cu astfel de sisteme sunt perturbate de zgomot sau artefacte inerente (erori de măsurare, de fosă posterioară sau de coastă) și artefacte de malfuncție (eroare de detectori, de mișcare, efectul de volum parțial). Toate aceste elemente nedorite, îngreunează detectarea structurilor și ulterior analiza acestora, de aceea sunt eliminate în etapa de preprocesare.

Contribuția originală prezentată în această disertație constă în propunerea unei metode noi de transformare a imaginilor inițiale în imagini de caracteristici de ordinul I și II, care permit extragerea eficientă prin segmentarea obiectelor dorite urmată de clasificarea acestora.

Clasificarea caracteristicilor se realizează în funcție de scopul final al procesării. În cele ce urmează, pentru validarea imaginilor de caracteristici s-au folosit următoarele metode statistice, raportul contrast-zgomot (CNR), curba ROC (*Receiver Operating Characteristic*) și raportul ratei de erori a ariei (AER).

#### 5.2 Metodă semiautomată de determinare a obiectelor din imaginile complexe în contextul imaginilor de caracteristici

Identificarea obiectelor din imaginile ecografice printr-o metodă semiautomată presupune ca etapa de preprocesare să fie succedată de o metodă de segmentare manuală sau automată. Pentru compararea celor două metode sunt folosite metode statistice sau de evaluare ale imaginilor prelucrate. Etapele implementate în acest studiu, respectă structura generală de procesare a imaginilor, ilustrate în figura 5.1.

Din punct de vedere al procesării imaginilor, structurile anatomice ale chisturilor și tumorilor la sân le vom privi ca obiecte. Succesiunile de metode propuse vor identifica obiecte de tip leziuni mamare.

Segmentarea pe astfel de imagini este dificilă deoarece presupune necunoașterea în avans a formei exacte care trebuie segmentată și nici dimensiunea acesteia.

Pentru a eficientiza segmentarea obiectelor din imaginile ecografice am realizat un studiu asupra imaginilor de caracteristici.

În contextul metodei propuse, o imagine de caracteristici reprezintă transformarea unei imagini inițiale având la bază diferite caracteristici de ordinul I (extrase din histograma imaginii) sau ordinul II (extrase din matricea de co-ocurență).

Figura 5.1, prezintă schematic transformarea unei imagini originale într-o imagine de caracteristici cu ajutorul unei măști de dimensiuni diferite care glisează peste imaginea originală de la stânga la dreapta și de sus în jos. Se disting două moduri de obținere a imaginilor de caracteristici. În primul mod, masca începe să gliseze peste imaginea originală având coordonatele în interiorul imaginii (figura 5.1(a)) și al doilea mod, coordonatele pixelului central al măștii coincide cu primul pixel al imaginii originale (figura 5.1(b)). Ambele situații redimensionează imaginea originală. Pentru a evita decalajele de dimensiune se preferă al doilea mod, când imaginii originale i se aplică o bordură ce conține pixeli cu valoarea zero, egală cu jumătate din dimensiunea măștii. Din punct de vedere cromatic semnificația imaginilor din figura 5.1 (a) este următoarea: culoarea albastru închis simbolizată imaginea originală, albastru deschis indică imaginea de caracteristici, masca are culoare roșie și este centrată în interiorul imaginii originale. În figura 5.1 (b), bordura adăugată este dată de culoarea gri iar masca este fixată pe primul pixel al imaginii originale. Dacă asupra măștilor se vor aplica diferite caracteristici de ordinul I sau II, iar valoarea obținută se va aloca pixelului central (pătrățelul roșu), care va face parte din imaginea de caracteristici, prin acest proces iterativ obținem imagini de caracteristici.

Pentru o imagine de ansamblu al etapelor parcurse a fost proiectată o diagramă bloc care conține toate etapele necesare procesării imaginilor, figura 5.2.

Cea mai importantă etapă a acestei noi metode dezvoltate în cadrul studiilor doctorale, este realizarea imaginilor de caracteristici. Parcurgerea acestei etape a necesitat realizarea unei aplicații cu ajutorul pachetului *Graphical User Interface*, și presupune mai multe etape de implementare.




Figura 5.1 Schema obținerii imaginilor de caracteristici, (a) imaginea de caracteristici este mai mică decât imaginea originală; (b) imaginea de caracteristici este egală cu imaginea originală

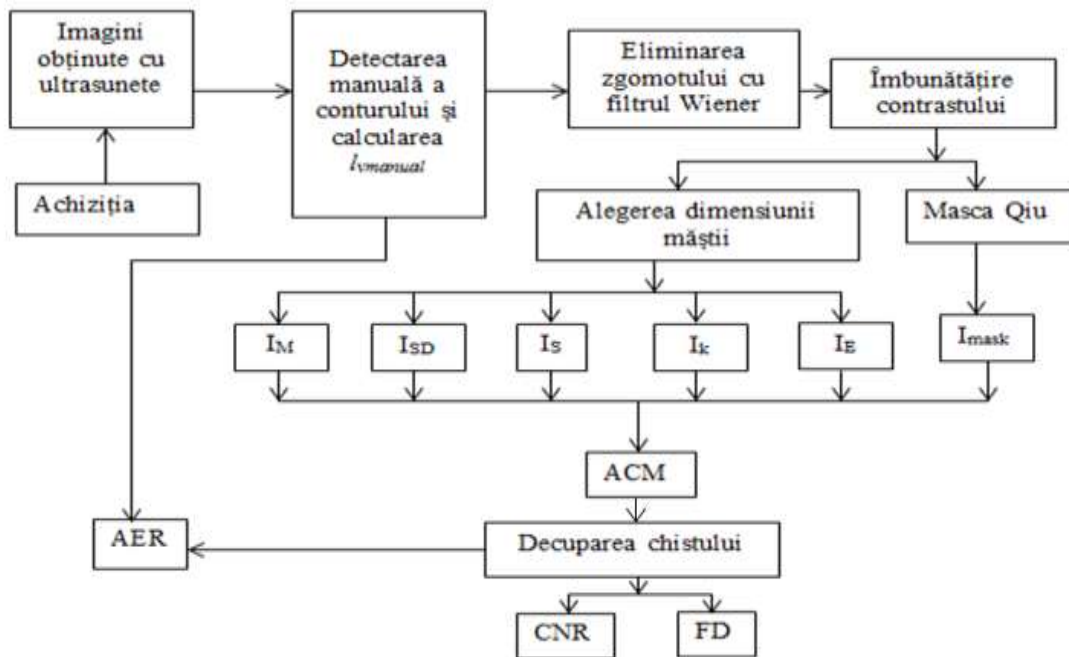


Figura 5.2 Digrama bloc a eficientizării segmentării imaginilor de caracteristici.

Aplicația implementată în software-ul *MatlabR2009a* are interfața grafică din figura 5.3.



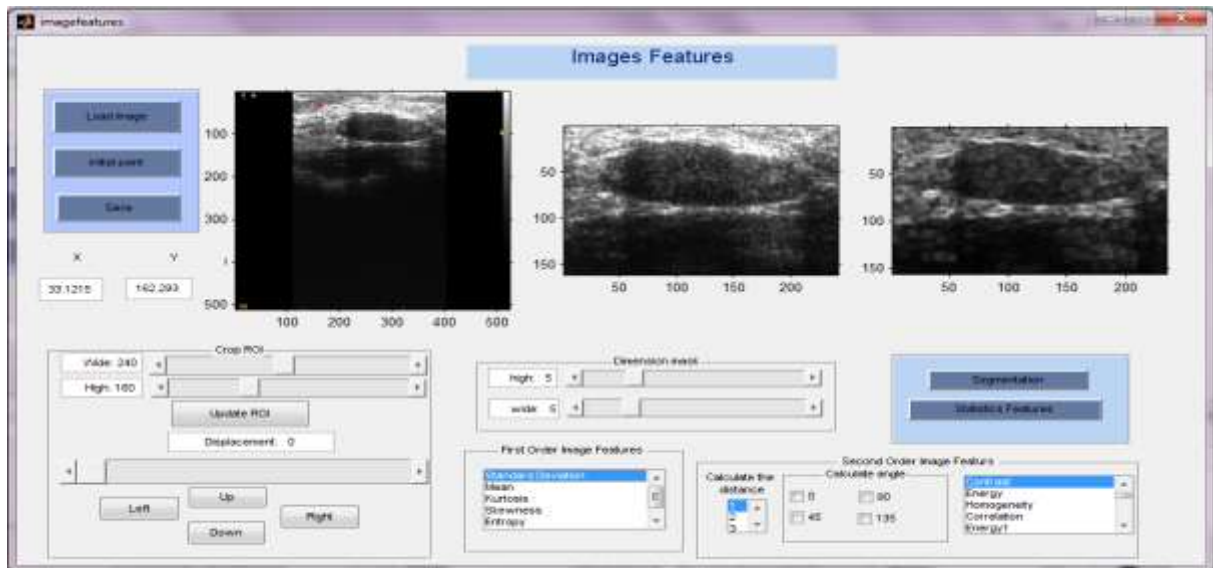


Figura 5.3 Interfață grafică proiectată pentru realizarea imaginilor de caracteristici.

În urma prelucrării ecografiilor cu chist mamar, obținem imagini de caracteristici prezentate în figura: 5.4, pentru deviația standard, în același mod s-au obținut imagini de caracteristici pentru: medie, kurtosis, skewness și entropie.




Figura 5.4 Imagini de caracteristici ale chistului mamar procesate cu descriptorul deviației standard aplicat pe măști de dimensiuni; (a) 3x3; (b) 5x5; (c)7x7;(d) 9x9

Exemple de imagini de caracteristici corespunzătoare tumorii mamare, segmentate cu snake, sunt afișate de figura 5.5 (a)-(d).




Figura 5.5 Imagini de caracteristici corespunzătoare tumorii mamare, obținute pentru descriptorul mediei, aplicat pe măști de dimensiune (a) 3x3; (b) 5x5; (c)7x7;(d) 9x9, cu snake de culoare galben suprapus.

Tabelul 5.4 Interpretarea nivelurilor de influență a măștilor de ordinul I pentru fiecare imagine de caracteristici

Dimensiunea măștii	CNR									
	Clasa chisturi					Clasa tumori				
	I <sub>SD</sub>	I <sub>M</sub>	I <sub>K</sub>	I <sub>S</sub>	I <sub>E</sub>	I <sub>SD</sub>	I <sub>M</sub>	I <sub>K</sub>	I <sub>S</sub>	I <sub>E</sub>
3x3	scăzut	înalt	scăzut	scăzut	înalt	înalt	scăzut	scăzut	înalt	înalt
5x5	înalt	înalt	înalt	scăzut	scăzut	înalt	înalt	scăzut	scăzut	scăzut
7x7	înalt	înalt	înalt	înalt	scăzut	înalt	înalt	înalt	scăzut	scăzut
9x9	înalt	înalt	scăzut	constant	scăzut	înalt	înalt	constant	constant	scăzut
Masca Qiu	înalt					înalt				

### Discuții

Obiectivul principal al acestor cercetări a fost să investigăm utilitatea imaginilor de caracteristici extrase din imaginile ecografice și să evaluăm detectarea corectă a conturilor, chisturilor și tumorilor la sân cu metoda *snake*. În general, acest model nu găsește starea de echilibru a curbei care-l formează dacă imaginea peste care activează nu are muchii clare.

### 5.3 Explorarea ecocardiografiilor cu ajutorul imaginilor de caracteristici

Cunoștințele despre funcționarea normală a ventriculului stâng, mai ales în fazele sfârșit sistola și sfârșit diastola fac ca, evaluarea stării de sănătate să se facă complet și să se depisteze problemele grave de sănătate prin citirea corectă a texturii miocardului afișat de ecocardiografii.

Analiza texturii din ecocardiografiile 2D într-un mod computerizat, permite diferențierea între structura normală și cea anormală a țesutului. Acest deziderat nu este ușor de realizat deoarece caracteristicile texturale ale cordului se schimbă de la o framă la alta, iar mișcarea complexă a cordului face ca o textură corespunzătoare unui segment miocardic dintr-o framă să nu mai corespundă aceluiași segment în altă framă.

Deoarece peretele miocardic este reprezentat în imaginea ecocardiografică printr-o zonă foarte îngustă, se decupează zonele de interes din interiorul celor două cercuri astfel încât acestea să nu fie mai mici decât 1000 de pixeli, pentru ca valorile caracteristicilor: media, kurtosis, skewness, contrast și dimensiunea fractală să reflecte valori valide.

Așa cum sunt prezentate și în studiul anterior imaginile de caracteristici sunt obținute prin pavarea imaginilor originale cu măști de diferite dimensiuni asupra cărora se aplică diferite caracteristici de ordinul I și ordinul II. În acest studiu s-au folosit deviația standard I<sub>SD</sub>

și caracteristicile de ordinul II: omogenitatea,  $I_0$ , corelația  $I_C$  și energia  $I_E$ . Astfel am extins cercetarea la setul exhaustiv al caracteristicile de ordinul I la imagini de caracteristici de ordinul II, creând aplicația dată de interfața grafică din figura 5.6. Măștile au avut dimensiunile 3x3, 5x5, 7x7.

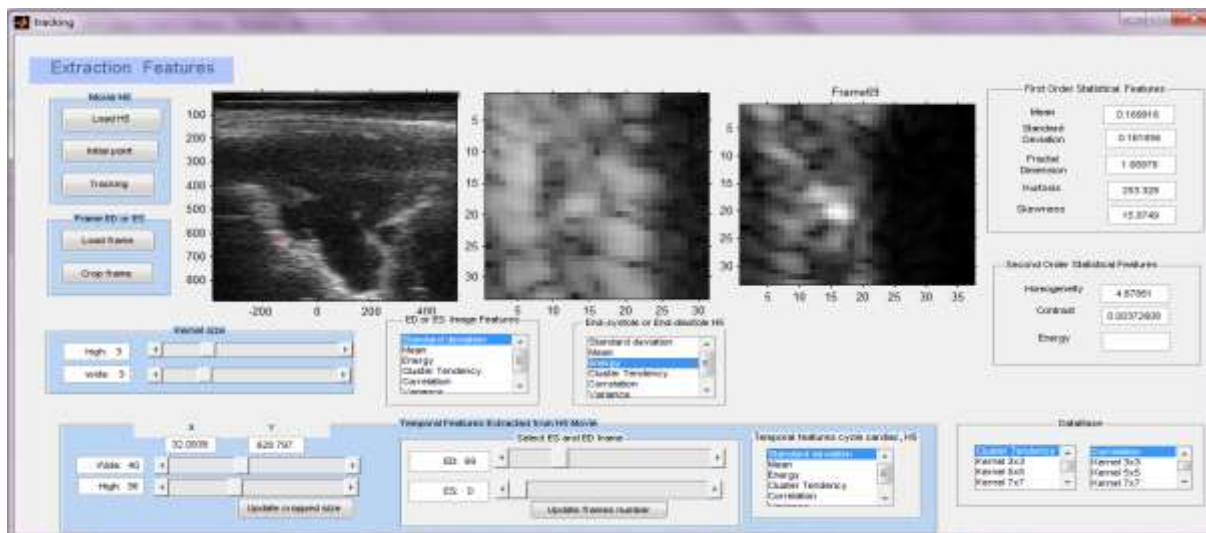


Figura 5.6 Interfață grafică a aplicației care generează imagini de caracteristici de ordinul II.

Tabelul 5.1 Valorile AUC ale parametrilor texturali extrași din imaginile de caracteristici obținute cu caracteristica de ordinul II numită omogenitatea

Caracteristicile texturale	Frama sfârșit sistolă			Frama sfârșit diastolă		
	3x3	5x5	7x7	3x3	5x5	7x7
Media	0.7956	0.704	0.7658	<b>0.8363</b>	0.7776	0.7313
Kurtosis	0.7681	0.7424	0.7776	<b>0.826</b>	0.7664	0.7353
Skewness	0.7788	<b>0.8131</b>	0.7451	<b>0.8228</b>	<b>0.8068</b>	0.7622
Contrast	<b>0.8547</b>	<b>0.8367</b>	<b>0.8727</b>	<b>0.8066</b>	<b>0.8658</b>	<b>0.8735</b>
Dimensiunea fractală	0.7837	<b>0.8128</b>	<b>0.8455</b>	<b>0.8016</b>	<b>0.8039</b>	<b>0.864</b>

Concentrându-ne pe puterea de diferențiere a descriptorilor de ordinul I (media, skewness, kurtosis), de ordinul II (contrastul) și bazate pe modele (dimensiunea fractală), deducem că aceștia pot fi folosiți în distingerea țesutului miocardic sănătos de cel afectat de infarct. Totuși, datorită variațiilor de textură a miocardului în framele sfârșit sistolă și sfârșit diastolă valorile descriptorilor variază. Pentru a face o analiză asupra întregului set de parametri folosim următoarele notații:  $I_{SD}(3x3)$  imaginea de caracteristici obținută cu masca de dimensiune 3x3, pe care s-a aplicat deviația standard, la fel se definesc și imaginile  $I_{SD}(5x5)$  și  $I_{SD}(7x7)$ ; pentru framele sfârșit sistolă și sfârșit diastolă vom nota cu ED respectiv, ES.

## Capitolul 6

### Sinteza rezultatelor studiului imaginilor complexe și concluzii finale

Cercetările realizate pe parcursul a celor 3 ani ai stagiului doctoral dintre care 2 ani și 6 luni în laboratoarele Facultății de Științe și Mediu, Universitatea „Dunărea de Jos”, Galați și 6 luni în laboratorul Department of Cardiovascular Diseases, Medical Imaging Centre, University Hospital Gasthuisberg, Leuven, Belgia, au avut ca scop studiul imaginilor complexe, realizarea imaginilor de caracteristici de ordinul I și ordinul II, și analiza utilității acestora în clasificarea obiectelor aparținătoare imaginilor și/sau în detectarea tipurilor de texturi.

Analiza aprofundată și critică a literaturii de specialitate și a stadiului actual al cercetărilor s-a concretizat într-un articol de tip *review* publicat într-o prestigioasă revistă ISI, și a indus ideea științifică a construirii imaginilor de caracteristici ca instrument de analiză a imaginilor ecografice și ecocardiografice.

Cum procesarea imaginilor este un domeniu vast iar realizarea acestui proces presupune parcurgerea a cel puțin patru etape s-a dovedit în mod riguros că metodele propuse pentru preprocesare, segmentare și clasificare sunt robuste și pot atinge scopul final pentru care au fost proiectate și utilizate.

La realizarea studiilor aplicative s-au luat în considerație o serie de parametri calitativi, cum ar fi: coeficientul de corelație, raportul ratei de erori a ariei, raportul semnal-zgomot, raportul contrast-zgomot, diferența medie pătratică, gradientul de contrast, radicalul erorii medii pătratice, valoarea de vârf a raportului semnal-zgomot, care au permis evaluarea exactă și concretă a experimentelor întreprinse asupra imaginilor de caracteristici.

Metodele de segmentare propuse în această lucrare sunt metode consacrate și acceptate de comunitatea științifică.

Caracterul multidisciplinar al lucrării de față a făcut ca imaginile preluate cu ultrasunete să fie exprimate matricial și, pe baza vecinătăților și regulilor de corelare dintre elementele matricei, să fie implementate imaginile de caracteristici. Transferul de concepție între etapele de prelucrare ale imaginilor s-a realizat cu platforme hardware și software de înaltă performanță: Matlab R2009a (Image Processing Toolbox, Wavelets, Graphical User Interface, HDF5, Neuronal Network Toolbox), SPSS versiune 10.0 (SPSS Inc., Chicago, IL),

EchoPAC (GE Healthcare, Horten, Norway), HarFA – (Harmonic and Fractal Image Analysis), iar pentru de achiziție au fost folosite sistemele hardware de tip ecograf, SLE-40 și VIVID E9.

Metodele și algoritmi implementați pentru realizarea imaginilor de caracteristici au fost riguros validați, testați și acceptați în literatura de specialitate prin lucrările științifice acceptate în diferite jurnale de prestigiu.

Cercetările întreprinse în domeniul procesării imaginilor arată că domeniul are nevoie în continuare de idei noi, atât în ceea ce privește soluțiile software de prelucrare ale imaginilor dar și cele hardware care să achiziționeze imagini complexe fără defecte, artefacte sau zgomot. În ultimul deceniu, s-au dezvoltat o multitudine de metode de prelucrare ale imaginilor avându-și rădăcina în caracteristicile texturale dezvoltate de *Haralick*, *Galloway*, și *Voronoi*. În marea lor majoritate, acestea au folosit caracteristicile texturale ca descriptori și nu ca părți componente ale imaginilor care prin asamblare să formeze imagini de caracteristici corespunzătoare. Plecând de la ideea acestor descriptori, ne-am îndreptat atenția spre înțelegerea imaginii prin părțile sale constitutive, astfel încât acestea să fie mai ușor de interpretat.

În continuare se prezintă o trecere în revistă a contribuțiilor personale din care se extrag concluziile finale.

(i) Din descrierea obiectului principal care face studiul acestei teze și anume imaginea, proprietățile acesteia și tipurile de imagini (cu precădere cele descrise de date ierarhice).

(ii) Pentru etapa de preprocesare s-au adus o serie de îmbunătățiri prin realizarea unui studiu coerent asupra majorității metodelor de filtrare, în ceea ce privește testarea și selectarea celor mai performante filtre și *wavelets* care pot contribui la îmbunătățirea imaginilor de tip ecografic și ecocardiografic. Din studiile realizate conchidem:

- ✎ Îmbunătățirea imaginilor este una dintre cele mai importante etape ale procesării imaginilor, preprocesarea lasă la latitudinea utilizatorului ca prin filtre proprii sau din literatura de specialitate să aleagă metoda optimă, pentru a-și atinge scopul propus.
- ✎ Rezultate experimentale privind eliminarea *speckles* și îmbunătățirea imaginilor ecocardiografice cu filtrele Wiener, median și Gaussian arată că filtrul Wiener este cel mai robust. Verificarea acestei certitudini este dată de coeficientul de corelație aplicat între două cadre consecutive ale ciclului cardiac.

- ✎ O informație utilă este data de ponderea apartenenței valorilor coeficienților de corelație extrași pentru fiecare filtru: Wiener, median și Gaussian. Acestea aparțin intervalului  $[0.98, 0.985]$ , pentru toate modurile de vizualizare a ecocardiografiei (A2C, SAX, LAX, A4C). Cele mai mari valori cuprinse în intervalul  $[0.985, 0.99]$  sunt înregistrate pentru modurile de vizualizare SAX și A2C, valori obținute de filtrele Gaussian și median. În schimb, din evoluția valorilor coeficienților de corelație testate pe fiecare imagine filtrată, face să tragem concluzia că filtrul Wiener elimină cel mai bine zgomotul din imaginile ecocardiografice.
- ✎ Filtrele minimum, maximum, geometric și median folosite în studiul imaginilor obținute cu ultrasunete pentru clasificarea tumorilor la sân au fost testate dacă influențează structura complexă a imaginilor, complexitate fiind dată de dimensiunea fractală și măsurată de metoda „*box-counting*”. Folosind algoritmul de clusterizare *k-mean* se constată că filtrele, geometric și de minim, influențează cel mai puțin complexitatea tumorilor din imaginile ecografice.
- ✎ *Wavelets* Haar pot fi folosite cu succes în eliminarea zgomotului din ecografiile renale ale rinichilor sănătoși sau a celor cu afecțiunea *ochi de bou*. Un element important al calității imaginilor este contrastul, care în acest studiu, acesta este mai bun în cazul rinichiului sănătos în comparație cu cel bolnav.
- ✎ Structura anatomică a colonului poate fi interpretată corect după un examen ecografic numai dacă avem imagini de calitate. De aceea, eliminarea zgomotului din imaginile ecografice a colonului cu *wavelets* Daubechies pe patru nivelului, scoate în evidență informații despre detaliile imaginilor sensibile ochiului uman. Pragurile optime ale *wavelets* trebuie alese cu grijă astfel încât după aplicarea *wavelets* Daubechies, semnalul inițial să nu se distorsioneze și să nu persiste zgomotul după reconstruirea imaginilor.
- ✎ Îmbunătățirea performanțelor de filtrare a imaginilor ecocardiografice cu *wavelets* complex cu arborele dual, are avantajul că în prelucrare intervin două tipuri de *wavelets* una reală și una imaginară. Urmărind evoluția parametrilor: raportul semnal zgomot, diferența medie pătratică, radicalul erorii medii pătratice, valoarea de vârf a raportului semnal-zgomot pentru CWT-DT și filtrul median pentru un prag  $T < 5$ , se constată că, se pot obține imagini de calitate cu CWT-DT pentru pragurile:  $T=9$ ,  $T=10$ ,  $T=11$  și  $T=13$ .



- ✎ Metodele prezentate pentru mărirea calității imaginilor ecocardiografice cu: transformata Fourier rapidă, filtrul Gaussian *trece jos* și „*butterworth*”, pentru parametrul  $D_0$  din intervalul 0.05 și 0.19, furnizează cele mai rentabile rezultate de mărire a calității imaginilor, măsurate de metricile de calitate.
- (iii) Având ca scop mărirea gradul de înțelegere a texturii, s-a recurs la descriptorii statistici, geometrici, bazați pe modele, de ordinul I, II și de ordin superior. Prin extragerea acestora din obiectele detectate prin segmentare, a existat posibilitatea clasificării diferitelor tipuri de texturi extrase din imagini complexe de tip ecografic. Pentru a corela caracteristicile texturale a fost implementat un sistem șablon și un sistem de diagnoză automată. Din rezultatele obținute putem trage următoarele concluzii:
- ✎ Cu descriptorii precum direcția gradientului și magnitudinea s-a realizat un pionierat în studiu comparativ al orientării fibrelor miocardului în două moduri de vizualizare diferite ale cordului. Gradientii magnitudine și direcție au detectat erori de măsurare a texturii în modurile de vizualizare SAX sau A2C, având următoarele grade de semnificație: gradientul magnitudine este semnificativ pentru A2C/SAX și SAX/A2C cu  $p\text{-value} < 0.05$ . Gradientul direcție este nesemnificativ pentru A2C/SAX și SAX/A2C.
  - ✎ Entropia este un parametru care poate fi folosit în clasificarea miocardului ca normal sau anormal, variația valorilor fiind de  $6.15 \pm 0.56$  pentru miocardul sănătos, frama sfârșit diastolă, de  $6.23 \pm 0.52$  pentru miocardul sănătos, frama sfârșit sistolă, de  $9.12 \pm 0.29$ , pentru frama sfârșit diastolă a infarctului miocardic și de  $9.95 \pm 0.17$ , pentru frama sfârșit sistolă a infarctului miocardic.
  - ✎ Descriptorii: dimensiunea fractală, numărul lui Euler și proporția izo-segmentelor, coroborate prin coeficientul de corelație Pearson, pot caracteriza imaginile binare.
  - ✎ Metoda Otsu găsește pragul optim de binarizare al unei imagini ecografice. Coeficientului Pearson este un instrument util în stabilirea corelațiilor dintre pragul optim/dimensiunea fractală, pragul optim/numărul lui Euler, pragul optim/parametrul de proporții al izo-segmentelor, deoarece se poate verifica influențele pragului asupra descriptorilor.
  - ✎ Implementarea metodei Otsu, dimensiunii fractale, numărului lui Euler și parametrului de proporții al izo-segmentelor, într-un sistem de diagnoză automată, face posibilă clasificarea cu rețele neuronale a imaginilor binare obținute din regiuni de interes ale

imaginilor ecografice hepatice. Clasificarea este asociată ca "Negativă" când metoda Otsu stabilește praguri mai mici decât 0.1, iar dacă valoarea de binarizare a pragului este mai mare decât 0.5 avem o clasificare "Pozitivă".

- ✎ Sistemul de diagnoză automată a fost validat cu o rata de clasificare corectă de 94%, sensibilitatea de 96% și specificitatea de 92%.
- ✎ Momentele Zernike pot fi utilizate la reconstruirea cifrelor din imagini degradate furnizând imagini de calitate pentru care raportul de contrast zgomot este de 0.977.

(iv) Imaginile de caracteristici constituie elementul de originalitate a tezei de doctorat. Testarea și compararea metodelor de segmentare pe imagini sintetice, *in vivo* și imagini de caracteristici au stabilit valorile optime ale parametrilor de segmentare. Din rezultatele experimentale asupra metodelor actuale de segmentare bazată pe histogramă, regiuni, contururi și analiză fractală putem trage următoarele concluzii de ordin practic ;

- ✎ Metoda de segmentare bazată pe histograma trasată de-a lungul formațiunilor tumorale, detectează șapte praguri de segmentare. Pentru pragurile de binarizare  $T=208$ ,  $T=178$ ,  $T=163$ ,  $T=126$ ,  $T=65$  și  $T=49$ , s-au obținut în mod constant cinci tumorete, cu dimensiuni crescătoare, iar pentru pragul  $T=18$  s-au obținut doar patru tumorete, prima având ce mai mare dimensiune (2348 pixeli). Prin combinarea metodelor de segmentare bazate pe histogramă și cele de interpolare putem anticipa gradul de interconexiune între tumoretele la sân.
- ✎ Metodele de segmentare dinamice, din categoria cărora face parte metoda *snake*, pot detecta în mod eficient conturul leziunilor la sân. Eficiența metodei *snake* este confirmată de metode statistice precum *t-test*, *t-score*, AER și CNR. Metoda *t-test* a exclus ca fiind caracteristici similare orientarea, elongația și perimetrul de convexitate. Metoda *t-score* corespunzătoare tumorilor a exclus ca nerelevante caracteristicile: media, skewness, kurtosis și raportul de compacitate. Metoda *t-score* corespunzătoare chisturilor a exclus ca nerelevante toate caracteristicile statistice.
- ✎ Soluția optimă, care conține momente ale imaginilor ecografice, ce pot caracteriza leziunile la sân de tip tumoare, generată de algoritmul *greedy*, este formată din  $R_N = \{RT, AC, \mu_2, CC, m_{00}, EC\}$ , adică rectangularitatea, aria de convexitate, deviația standard, aria regiunii de interes, circularitatea și excentricitatea; iar pentru chisturi este mulțimea  $R_C = \{CC, FF, EC, AC, m_{00}, RT\}$  adică circularitatea, raportul de



compacitate, excentricitatea, aria de convexitate, aria regiunii de interes și rectangularitatea.

- ✎ Nu toate caracteristicile clasificate de algoritmul *greedy* au fost validate de metoda *leave-one-out*, ci doar mulțimile  $R'_c = \{CC, FF, EC\}$  pentru chistul la sân și  $R'_N = \{RT, AC, \mu_2\}$  pentru tumori. Acestea rămânând, în final, cele mai relevate caracteristici ale celor două clase.
- ✎ Metoda *snake* folosită în detectarea conturilor structurilor anatomice este performantă, aceasta fiind comparată cu metodele de detecție a conturilor implementate în software-ul *EchoRAC*, pentru parametru de elasticitate  $\alpha \in [0.4, 1.6]$  și rigiditate  $\beta \in [0.2, 9.5]$ .
- ✎ Compararea metodelor *snake* și *watershed* aplicate pe imagini sintetice și *in vivo* transformate ulterior în imagini de caracteristici cu deviația standard, demonstrează că metoda *snake* furnizează rezultate mai bune decât metoda *watershed*. Robuștețea metodei *snake* este confirmată de descriptorul AER, pentru care s-au obținut cele mai mici erori, pentru imaginile sintetice (AER=4.49), pentru clasa chisturi la sân (AER=8.88, pentru dimensiunea măștii de 5x5) și pentru clasa chist la ficat (AER=10.82 pentru dimensiunea măștii de 5x5). Metoda *watershed* a generat erori mai mici pentru imaginea sintetică (AER=1.62), în schimb a infirmat pentru imaginile *in vivo* (AER=21.26) și (AER=30,621), pentru clasa chisturi la sân respectiv, clasa chisturi la ficat, având aceeași dimensiune a măștii.
- ✎ Metoda de analiza fractală *box-counting* a permis clasificarea afecțiunilor ficatului și determinarea gradelor de complexitate ale microcalcificațiilor la sân. Evaluarea ratei de acuratețe a metodei *box-counting* s-a realizat cu descriptorul CNR (raportul de contrast zgomot), care a furnizat valori în intervalul 0.818 și 0.88, pentru ambii detectori Sobel și Canny.
- ✎ Metoda de analiză fractală *box-counting* cu instrumentele sale  $D_{BW}, D_{BBW}, D_{WBW}$  a permis determinarea diferențelor între microcalcificații și fundalul imaginii astfel:  $D_{BW}$  generează diferența de 0.2641 deoarece după extragerea acestora imaginea a avut un grad de complexitate mai mic;  $D_{BBW}$  generează diferența de -0.041 deci complexitatea fundalului de culoare neagră este mai mare în cazul microcalcificațiilor îmbunătățite;

iar  $D_{WBW}$  de 0.2354 indică o complexitate a microcalcificațiilor detectată pe fundal alb mai mare decât cea a fundalului imaginii.

(v) Cercetările au continuat cu studiul imaginilor de caracteristici, analiza și clasificarea acestora. Acestea au scos în evidență utilitatea acestora în procesarea imaginilor ecografice și ecocardiografice.

- ✎ Imaginile de caracteristici sunt alternative ale imaginilor originale când se dorește realizarea de studii ce vizează caracterizarea obiectelor din imaginile originale, în sensul stabilirii apartenenței la o clasă, sau pentru a distinge tipuri de țesuturi prin textura acestora redată de imaginile de tip ecocardiografic.
- ✎ Rezultatele experimentale confirmă utilitatea acestor imagini de caracteristici cu câteva excepții.
- ✎ Metoda statistică *t-test* confirmă diferențe între imaginile de caracteristici cu excepția entropiei, caracteristică de ordinul I.
- ✎ În caracterizarea leziunilor la sân s-a dedus că cea mai mare eficiență pentru imaginile ecografice ale chisturilor care admite eroarea minimă este  $I_{SD(5 \times 5)}$  (imaginea de caracteristici obținută cu deviația standard),  $I_{S(5 \times 5)}$  (imaginea de caracteristici obținută cu skewness) și  $I_{E(3 \times 3)}$  (imaginea de caracteristici obținută cu entropia), pentru leziunile de tip chist. Imaginile de caracteristici  $I_{SD(5 \times 5)}$ ,  $I_{S(5 \times 5)}$ ,  $I_{mask}$  pot clasifica leziunile de tip tumori.
- ✎ Reunind informațiile furnizate de *t-test* și cele de AER rezultă că imaginile de caracteristici obținută cu entropia se elimină din setul de imagini care pot caracteriza leziunile de tip chist.
- ✎ Prin diminuarea contrastului, imaginile de caracteristici corespunzătoare chisturilor și cele produse cu masca Qiu își păstrează calitatea cu excepțiile :  $I_{SD(3 \times 3)}$ ,  $I_{S(3 \times 3)}$ ,  $I_{S(5 \times 5)}$ ,  $I_{S(7 \times 7)}$ ,  $I_{E(3 \times 3)}$ ,  $I_{E(5 \times 5)}$  și  $I_{E(7 \times 7)}$ . Imaginile de caracteristici corespunzătoare tumorilor care își pierd calitatea sunt:  $I_{M(3 \times 3)}$ ,  $I_{K(3 \times 3)}$ ,  $I_{K(5 \times 5)}$ ,  $I_{K(7 \times 7)}$ ,  $I_{S(5 \times 5)}$ ,  $I_{S(7 \times 7)}$ ,  $I_{E(3 \times 3)}$ ,  $I_{E(5 \times 5)}$  și  $I_{E(7 \times 7)}$ .
- ✎ Prin aplicarea *t-test* descriptorul kurtosis este cel care nu poate face diferența între texturile imaginilor de caracteristici ( $p\text{-value} > 0.05$ ). Tot acest descriptor nu poate caracteriza cele două tipuri de texturi, deoarece AUC (aria de sub curba ROC) pentru majoritatea imaginilor de caracteristici are valoare predictivă ca „echitabilă”.
- ✎ Contrastul este cel mai bun parametru care poate discrimina între cele două tipuri de texturi ale miocardului având o valoare predictivă „excelexenă” (AUC=0.902) pentru

imaginea de caracteristici obținute cu deviația standard, având dimensiunea măștii de 5x5. Dintre toți descriptorii: medie, contrast, skewness, kurtosis, și dimensiunea fractală, care au analizat imaginea de caracteristici obținută cu corelația,  $I_C$ , contrastul are o putere de discriminare „bună”, între cele două texturi (valoarea  $AUC > 0.8$ ), urmat de dimensiunea fractală care, pentru patru dintre imaginile de caracteristici au valoarea discriminativă „bună”.

- ✎ Imaginea de caracteristici obținută cu omogenitatea,  $I_O$ , este cel mai bine reprezentată de contrast și dimensiunea fractală, în schimb cel de-al doilea descriptor are o imagine de caracteristici  $I_{O(3 \times 3)}$  clasificată ca „echitabilă”.
- ✎ Imaginea de caracteristici obținută cu energia, dă clasificarea descriptorului contrast ca „bună”, iar toți ceilalți descriptori conțin și clasificarea ca „echitabilă”.

Posibilitățile de continuare a cercetării în domeniul imaginilor de caracteristici realizate din imagini complexe de tip ecografic pentru analiza unor structuri anatomopatologice sau a unor stări patologice așa cum au fost abordate în cadrul studiilor de tipul ficat sănătos/steatozic, miocard sănătos/infarct, leziune la sân de tip chist/tumorare sunt realizabile prin gruparea modulelor de procesare a imaginilor în sisteme de diagnoză automată.

Studiile se pot extinde la imagini de caracteristici obținute din descriptorii texturali bazați pe modele cum sunt fractalii.

### Bibliografie selectivă

- [1] D. B. Michelson, R. Lewandowski, M. Szewczykowski, H. Beekhuis, *Eumetnet Opera weather radar information model for implementation with the HDF5 file format*, Opera, 2011.
- [2] D. Adam, S. Beilin-Nissan, Z. Friedman, V. Behar, *The combined effect of spatial compounding and nonlinear filtering on the speckle reduction in ultrasound images*, Ultrasonics, Vol. 44, pp. 166–81, 2006.
- [3] M. C. Motwani, M. C. Gadiya, R.C. Motwani, *Survey of Image Denoising Techniques*, Proceedings of GSPx, Santa Clara, CA, 2004.
- [4] M. Mohamed, F. Abou-Chadi, B. Ouda, *Denoising Functional MRI: A Comparative Study of Denoising Techniques (2D)*. In: Proceedings of World Congress on Medical Physics and Biomedical Engineering, Seoul, Korea, pp. 913-920, 2007.
- [5] **S. Moldovanu**, Moraru L, *Mass Detection and Classification in Breast Ultrasound Image Using k-means Clustering Algorithm*. In: Proceedings of the 3<sup>rd</sup> International Symposium on Electrical and Electronics Engineering, Galati, pp. 197-201, 2010.
- [6] **S. Moldovanu**, L. Moraru, E. Zerrad, A. Biswas, *Speckle noise reduction methods in cardiac cycles*, International Journal of the Physical Sciences, Vol. 7(5), pp. 797 - 804, 2012.

- [7] M. Ivanovici, *Procesarea Imaginilor - Îndrumar de laborator*, Editura Universității Transilvania, Brașov, 2006.
- [8] D. Bibicu, **S. Moldovanu**, L. Morau, *Denoising the Echocardiographic Images Using Fourier Transform*, Annals of Dunarea de jos University Fascicle II, Anul III, nr 1, pp. 119-126, 2011.
- [9] A. Materka, M. Strzelecki, *Texture Analysis Methods – A Review*, Technical University of Lodz, Institute of Electronics, COST B11 report, Brussels, 1998.
- [10] R. M. Haralick, K. Shanmugam, I. Dinstein, *Textural features for image classification*. IEEE Transactions on Systems, Man and Cybernetics, Vol. 3(6), pp.610–621,1973.
- [11] M. M. Galloway, *Texture analysis using gray level run lengths*, Computational Graphics Image Process, Vol. 4, pp. 172–179, 1975.
- [12] A. Chu, C. M. Sehgal, J. F. Greenleaf, *Use of Gray Level Distribution of Run Lengths for Texture Analysis*, Pattern Recognition Letters, Vol. 11, pp. 415-420, 1990.
- [13] B. R. Dasarathy , E. B. Holder, *Image Characterization based on Joint Gray-level Run-length Distributions*, Pattern Recognition Letters, Vol.12, pp. 497-502, 1991.
- [14] M. Tuceryan, A. K. Jain, *Texture Segmentation Using Voronoi Polygons*, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 12, pp. 211-216, 1990.
- [15] O. Cheong, H. Everett, M. Glisse, J. Gudmundsson, S. Hornus, S. Lazard, M. Lee, H. S. Na, *Farthest-Polygon Voronoi Diagrams*, Computational Geometry, Vol. 44(4), pp. 234-247, 2011.
- [16] Y. Zhu, J. Xu, *Improved Algorithms for Farthest Colored Voronoi Diagram of Segments*, Lecture Notes in Computer Science, Vol. 6831, pp. 372-386, 2011.
- [17] K. Laws, *Rapid texture identification*, In: Proceedings of SPIE, Vol. 238, Image Processing for Missile Guidance, pp. 376-380, 1980.
- [18] G. N. Srinivasan, G. Shobha, *Statistical Texture Analysis*, Proceedings of World Academy of Science, Engineering and Technology , Vol. 36, 2008.
- [19] **S. Moldovanu**, L. Moraru, A. Biswas, *Texture Features that Characterize 2D-Echocardiography—A Review*, Advanced Science Letters Vol. 5, 1–10, 2012
- [20] T. Lindeberg, *Edge detection and ridge detection with automatic scale selection*, Computer Vision, Vol. 30, pp. 117-154,1998
- [21] K. Edmund, K Given, M. Giles, D. Thomas, *Review of Methods for Texture Analysis of Myocardium From Echocardiographic Images*, Echocardiography, Vol.20, pp.727-736, 2003.
- [22] K. Saini, M. L. Dewal, M.K. Rohit, *Comparative Study of Edge Detectors in case of Echocardiographic Images*, In: Proceedings of International Conference on Method and Models in Science and Tehnology ,Vol. 1324, pp. 267-271, 2010.
- [23] J. Park, S. Zhou, B. Georgescu, J. Simopoulos, J. Otsuki, C. Comaniciu, *Automatic cardiac view classification of echocardiogram*, ICCV ,Vol. 11, pp.1-8,2007.
- [24] B. Dagdeviren, O. Akdemirb, M. Eren, O. Bolca, E. Oguza, Y. Gurlertopa, T. Tezela, *Prognostic implication of myocardial texture analysis in idiopathic dilated cardiomyopathy*, European Journal of Heart Failure, Vol. 4, pp.41-48, 2002.
- [25] F. Pizzarelli P. Dattolo, E.M. Ferdeghini, M. A. Morales, *Parameters derived by ultrasonic myocardial characterization in dialysis patients are associated with mortality*, Kidney International, Vol. 68, pp. 1320-1325, 2005
- [26] L. Xiaozhu, S. Yun, J. Junwei, W. Yanmin, *A proof of image Euler Number formula*, Science in China Information Sciences, Vol. 3, pp. 364-371, 2006.
- [27] C. Vertan, M. Ciuc, *Tehnici Fundamentale de Prelucrarea și Analiza Imaginilor*, Editura MatrixROM, București, 2007.
- [28] B. Jahne, *Digital Image Processing*, 5<sup>th</sup> Edition, Springer-Verlag, Berlin, 2002.