



UNIVERSITATEA "DUNĂREA DE JOS" DIN GALAȚI

Proiect cofinanțat din Fondul Social European prin Programul Operațional Sectorial pentru Dezvoltarea Resurselor Umane 2007 – 2013



TEZĂ DE DOCTORAT

REZUMAT

ABORDĂRI INOVATIVE PRIVIND EXTRAGEREA CONȚINUTULUI INFORMAȚIONAL UTIL DIN IMAGINI DIGITALE

INNOVATIVE APPROACHES FOR USEFUL INFORMATION EXTRACTION FROM DIGITAL IMAGES

Doctorand,
Mirela Pungă (Vișan)

Conducător științific,
Prof. univ. dr. ing. fiz. Luminița Moraru

Seria I4: Inginerie industrială Nr. 32

Galați 2015



Universitatea „Dunărea de Jos” din Galați
Școala doctorală de INGINERIE INDUSTRIALĂ



REZUMATUL

TEZEI DE DOCTORAT

ABORDĂRI INOVATIVE PRIVIND EXTRAGEREA
CONȚINUTULUI INFORMAȚIONAL UTIL DIN
IMAGINI DIGITALE

INNOVATIVE APPROACHES FOR USEFUL
INFORMATION EXTRACTION FROM DIGITAL
IMAGES

Doctorand,
Mirela Pungă (Vișan)

Conducător științific,
Prof. univ. dr. ing. fiz. Luminița Moraru

Seria I 4 Nr 32

GALAȚI

2015

ROMÂNIA
MINISTERUL EDUCAȚIEI ȘI CERCETĂRII ȘTIINȚIFICE
UNIVERSITATEA „DUNĂREA DE JOS” DIN GALAȚI



32306/15.09.2015

Către

Universitatea „Dunărea de Jos” din Galați vă face cunoscut că, în data de **17.10.2015**, ora **11**, în sala **FORINFO** a Facultății de Științe și Mediu, va avea loc susținerea publică a tezei de doctorat intitulată: **„ABORDĂRI INOVATIVE PRIVIND EXTRAGEREA CONȚINUTULUI INFORMAȚIONAL UTIL DIN IMAGINI DIGITALE”**, elaborată de doamna/domnul **PUNGĂ MIRELA (VIȘAN)**, în vederea conferirii titlului științific de doctor în domeniul de doctorat **Inginerie industrială**.

Comisia de doctorat are următoarea componență :

- | | |
|----------------------------------|--|
| 1. Președinte | Conf.dr. Nicolae ȚIGĂU
Universitatea „Dunărea de Jos” din Galați |
| 2. Conducător de doctorat | Prof.dr. Luminița MORARU
Universitatea „Dunărea de Jos” din Galați |
| 3. Referent oficial | Prof.dr. Mircea-Iacob GIURGIU
Universitatea Tehnică de Construcții din București |
| 4. Referent oficial | Prof.dr. Dan CHICEA
Universitatea „Lucian Blaga” din Sibiu |
| 5. Referent oficial | Prof.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, e-mail rectorat@ugal.ro

Rector,

Prof. dr. ing. **Julian Gabriel BIRSAN**



**Proiectul POSDRU – ExcelDOC – Excelență în cercetare prin
burse doctorale și posdoctorale - 159/1.5/S/ 132397**

Perioada de implementare: 8 aprilie 2014 - 7 octombrie 2015

Rezultatele cercetării

Articole publicate în jurnale cotate ISI

1. **Mirela (Vișan) Pungă, R. Gaurav, L. Moraru**, Level set method coupled with Energy Image features for brain MR image segmentation, Biomedical Engineering / Biomedizinische Technik, ISSN: 0013-5585, (IF 2013: 1.227), DOI 10.1515/bmt-2013-0111, Biomed Tech 2014, Volume: 59 Issue: 3 Pages: 219-229

Citat în:

Zhan, T., Zhan, Y., Liu, Z., Xiao, L., Wei, Z., Automatic method for white matter lesion segmentation based on T1-fluid-attenuated inversion recovery images, IET Computer Vision, Volume 9, Issue 4, 1 August 2015, Pages 447-455 (IF 2014: 0.963)

2. **Luminița Moraru, Simona Moldovanu, Mirela (Vișan) Pungă, Stephen Johnson and Anjan Biswas**, Exploiting distance metrics-based similarity for spatial features analysis: Application to brain MR images, Maejo International Journal of Science and Technology, trimis Febr 2015 . Status: Under review

Articole ISI Proceedings

1. **Dorin Bibicu, Luminița Moraru and Mirela Pungă (Vișan)**, Diagnostic accuracy of ovarian cyst segmentation in b-mode ultrasound images, AIP Conference Proceedings 1564, 164-170 (2013); doi: 10.1063/1.4832813, Timișoara, România.

2. **Mirela (Vișan) Pungă, Simona Moldovanu, Luminița Moraru**, Structural similarity analysis for brain MR image quality assessment, AIP Conference Proceedings **1634**, 137-143 (2014); doi: 10.1063/1.4903028.

3. **Simona Moldovanu, Mirela (Vișan) Pungă, Luminița Moraru**, Evaluation of outliers in acquired brain MR images, Journal of Physics: Conference Series 574 (2015) 012121 doi:10.1088/1742-6596/574/1/012121, IOP Publishing, IC-MSQUARE 2014.

4. **Mirela (Vișan) Pungă, Simona Moldovanu, Luminița Moraru**, MR image intensity inhomogeneity correction, Journal of Physics: Conference Series 574 (2015) 012125 doi:10.1088/1742-6596/574/1/012125, IOP Publishing, IC-MSQUARE 2014.

Articole indexate BDI

1. **Emilian Dănilă, Mirela (Vișan) Pungă, Antoaneta Ene, Luminița Moraru, Adriana Dănilă**, Automatisation of the diagnosis of portal and vascular problems of the liver, Annals of "Dunărea De Jos" University of Galati Mathematics, Physics, Theoretical Mechanics Fascicle II, year V(XXXVI) 2013, Nos. 1-2, pp 49-53, 2013.

2. **Simona Moldovanu, Mirela (Vișan) Pungă, Luminița Moraru**- Detection of dementia diseases using histogram in spatial domain, Annals of "Dunărea De Jos" University of Galati Mathematics, Physics, Theoretical Mechanics Fascicle II, year V(XXXVI) 2013, Nos. 1-2, pp 5-10, 2013.

3. **Mirela (Vișan) Pungă, L. Moraru, A. Ene, E. Daniilă**, Performance of boundary detections algorithms on medical images, Annals of "Dunarea de Jos" University of Galati Mathematics, Physics, Theoretical Mechanics Fascicle II, Year V(XXXVI) 2013, Nos. 1-2, 12-16, 2013.

4. *Emilian Dănilă, Antoaneta Ene, Luminița Moraru, Adriana Dănilă, Mirela Pungă (Vișan)*, Land use change studied by means of multifractal geometry, Annals of "Dunarea De Jos" University of Galati Mathematics, Physics, Theoretical Mechanics Fascicle II, Year V(XXXVI) 2013, Nos. 1-2, pp 53-60, 2013.

5. *Simona Moldovanu, Mirela Pungă (Vișan), Luminița Moraru*, Despeckle method of breast images using entropy filter and tissue phantoms simulation, Advanced Science, Engineering and Medicine, Adv. Sci. Eng. Med. 5, 1144-1149 (2013) (www.aspbs.com/asem) 2013, <http://dx.doi.org/10.1166/asem.2013.1416>.

Reviste B+

1. *Luminița Moraru, Simona Moldovanu, Mirela Pungă (Vișan)*, Optimization in breast lesions detection via integrated statistical approach, Journal of Scientific Research & Reports 2(1): 460-473, 2013.

Lucrări comunicate/ susținute la conferințe naționale sau internaționale.

1. *Vișan (Pungă) Mirela, Luminița Moraru, Antoaneta Ene, Emilian Dănilă*, Performance of boundary detections algorithms on medical images, Scientific Conference of Doctorals Schools from „Dunarea de Jos” University of Galati, 16-17 May 2013, Galati

2. *Emilian Danilă, Vișan (Pungă) Mirela, Antoaneta Ene, Luminița Moraru, Adriana Danilă*, Automatisation of the diagnosis of portal and vascular problems of the liver, Scientific Conference of Doctorals Schools from „Dunarea de Jos” University of Galati, 16-17 May 2013, Galati

3. *Emilian Danilă, Antoaneta Ene, Luminița Moraru, Adriana Danilă, Vișan (Pungă) Mirela*, Land use change studied by means of multifractal geometry, Scientific Conference of Doctorals Schools from „Dunarea de Jos” University of Galati, 16-17 May 2013, Galati

4. *Simona Moldovanu, Mirela (Vișan) Pungă, Luminița Moraru*, Detection of Dementia Diseases using Histogram in Spatial Domain, Conferința Științifică a Școlilor Doctorale din UDJ Galați (CSSD-UDJG 2014), 15-16 May 2014, Galati

5. *Emilian Dănilă, Adriana Dănilă, Mirela Pungă, Luminița Moraru*, Automatisation of the diagnosis of hydatid cyst, Conferința Științifică a Școlilor Doctorale din UDJ Galați (CSSD-UDJG 2014), 15-16 May 2014, Galati

6. *Luminița Moraru, Simona Moldovanu, Dorin Bibicu and Mirela Pungă (Vișan)*, Hemorrhage detection in MRI brain images using images features, Physics Conference TIM-12, 27-30 November 2012, Timișoara, România.

7. *Mirela (Vișan) Pungă, Simona Moldovanu, Luminița Moraru*, Structural similarity analysis for brain mr image quality assessment, TIM 2013 Physics Conference, 21st and 24th of November 2013, Timișoara, Romania, www.timconference.com.

8. *Simona Moldovanu, Mirela (Vișan) Pungă, Luminița Moraru*, Evaluation of outliers in acquired brain mr images, International Conference on Mathematical Modeling in Physical Sciences, August 28-31, 2014, Madrid, Spain, <http://www.icmsquare.net>

9. *Mirela (Vișan) Pungă, Simona Moldovanu, Luminița Moraru*, MR image intensity inhomogeneity correction, International Conference on Mathematical Modeling in Physical Sciences, August 28-31, 2014, Madrid, Spain, <http://www.icmsquare.net>.

Mulțumiri

Elaborarea și fundamentarea științifică a unei teze de doctorat este posibilă numai cu condiția unei îndrumări științifice de calitate realizate cu profesionalism și a unor condiții adecvate necesare desfășurării activității de cercetare specifice temei abordate. Sunt conștientă că finalizarea unei teze de doctorat, prin care se încheie o etapă importantă din pregătirea mea profesională, nu reprezintă doar munca și efortul meu, ci se datorează și celor care m-au ajutat și mi-au fost alături, cu care, pot să spun că am format o echipă, o familie pe plan profesional.

Acestor oameni minunați care mi-au dăruit informație și afecțiune, care și-au rupt din timpul lor pentru a-mi fi de ajutor mie, doresc să le aduc recunoștința mea și mă tem că-mi vor fi sărace cuvintele în raport cu efortul domniilor lor.

Mulțumirile mele se îndreaptă către:

- conducătorul științific, doamna prof. dr. ing. fiz. **Luminița Moraru** pentru activitatea de coordonare și îndrumare a activităților de cercetare științifică și de elaborare a tezei de doctorat. Mulțumesc pentru sprijinul, răbdarea și încurajările primite din partea acesteia.
- doamna prof. dr. fiz. **Mirela Praisler** pentru încrederea, susținerea și ajutorul acordate în elaborarea tezei de doctorat.
- domnul prof. dr. **Anjan Biswas**, Department of Mathematical Sciences, Delaware State University Dover SUA, pentru colaborarea privind stabilirea cadrului matematic pentru dezvoltarea algoritmilor.
- doamna medic primar Dr. **Adina-Geanina Nămoianu**, spitalul de Urgență Sfântul Andrei, pentru vasta bază de date cu imagini medicale pusă la dispoziție, pentru informațiile furnizate privind determinarea diverselor stării patologice din imaginile investigate, pentru activitățile “in vivo” de verificare și validarea algoritmilor dezvoltați în cadrul activității doctorale.
- Eng. **Rahul Gaurav**, Advanced Research and Techniques for Multidimensional Imaging Systems, Télécom Sud Paris pentru colaborarea privind implementarea algoritmilor metricilor de calitate folosite în analiza imaginilor digitale.
- întregul colectiv al Facultății de Științe și Mediu din cadrul Universității „Dunărea de Jos” din Galați pentru mediul științific și prietenos creat și în special colegei mele, astăzi doctor în științe, doamna prof. **Simona Moldovanu** pentru strânsa activitate de colaborare privind procesarea, investigarea și diagnosticarea informațiilor din imaginile digitale.
- proiectul **POSDRU ExcelDOC - 159/1.5/S/132397** pentru sprijinul informațional și material acordat în activitățile de cercetare.
- soțul și familia mea pentru suportul moral și înțelegerea acordată pe întreaga perioadă a pregătirii tezei de doctorat.

De aceea pot să spun că succesul meu este și succesul dumneavoastră.

Vă mulțumesc!

Cuprins

	Pagină
Introducere	11 9
1. Motivația alegerii temei de cercetare.....	13 9
2. Importanța și gradul de originalitate al proiectului de cercetare.....	14 9
3. Obiectivele tezei.....	14 10
4. Diseminarea rezultatelor cercetării.....	15 10
5. Structura lucrării științifice.....	15 10
6. Materiale și seturi de date utilizate în studiile proprii.....	16 11
7. Stadiul actual al cercetării.....	17
8. Bibliografie.....	22
Capitolul I	
Tehnici de prelucrare a imaginilor	26 12
1.1. Achiziția și procesarea imaginilor RMN complexe.....	27
1.2. Filtrarea imaginilor.....	33
1.2.1. Filtrarea liniară a imaginilor.....	34
1.2.1.1. <i>Filtrarea liniară de netezire</i>	37
1.2.1.2. <i>Filtrarea liniară de contrastare</i>	37
1.3. Îmbunătățirea contrastului.....	38
1.3.1. Îmbunătățirea liniară a contrastului.....	38
1.4. Analiza histogramei imaginii.....	41
1.5. Descriptori de calitate.....	44
1.6. Modele de caracteristici binare locale LBP (Local Binary Patterns) în analiza texturii imaginii.....	45
1.7. Concluzii parțiale.....	49
1.8. Bibliografie.....	50
Capitolul II	
Metode avansate de analiză a imaginilor digitale utilizate în activitatea experimentală	55 14
2.1. Noțiuni generale privind metodele de analiză.....	55 14
2.2. Metode de segmentare a imaginilor.....	55 14
2.2.1. Segmentarea bazată pe contururi active.....	56 14
2.2.2. Metoda de segmentare SBGFRLS (Selective Binary and Gaussian Filtering Regularized Level Set).....	58 15
2.2.3. Metoda de segmentare bazată pe contururi active folosind o distribuție Gaussiană a energiei ajustată de distribuții locale ale mediei și varianței LGDF (Local Gaussian Distribution fitting energy).....	59 16
2.2.4. Metoda parametrică pentru estimarea câmpului de bias.....	63 16
2.3. Momente ale imaginilor digitale.....	70 17
2.3.1. Momente geometrice.....	70 17
2.3.2. Momente statistice.....	72 17
2.4. Imagini de caracteristici.....	72 18
2.5. Metoda caracteristicii binare locale LBP (Local Binary Pattern) de analiză a imaginilor.....	74 18

2.6.	Metode de analiza privind similaritatea / disimilaritatea imaginilor digitale.....	76	19
2.7.	Concluzii parțiale.....	77	
2.8.	Bibliografie.....	79	
Capitolul III			
Contribuții proprii și rezultate experimentale în analiza imaginilor digitale pentru extragerea conținutului informațional		85	21
3.1.	Extragerea caracteristicilor texturale pentru diferențierea imaginilor digitale.....	85	21
3.2.	Metoda funcției de nivel cuplată cu caracteristica Energie în segmentarea imaginilor.....	89	25
3.3.	Metoda caracteristicii binare locale LBP pentru diferențierea imaginilor digitale folosind conținutul informațional.....	98	33
3.4.	Analiza calitativă a similarității structurale a imaginilor digitale.....	103	37
3.5.	Caracteristicile texturale momente statistice și geometrice folosite la optimizarea detecției obiectelor.....	106	40
3.6.	Concluzii parțiale.....	112	
3.7.	Bibliografie.....	115	
Capitolul IV			
Sinteza rezultatelor studiului privind extragerea conținutului informațional din imaginile digitale și concluzii finale		116	46
4.1.	Concluzii generale.....	116	46
4.2.	Contribuții la realizarea temei de cercetare.....	118	48
4.3.	Direcții viitoare de studiu.....	120	50
Bibliografie selectivă.....			51
Curriculum Vitae.....			121

INTRODUCERE

Procesarea digitală a imaginilor are un rol important în aplicații din domenii extrem de variate.

Imagistica medicală a înregistrat un progres major în ultimele decenii mai ales datorită avansului științific realizat în sectorul militar. Însă, evoluția fulminantă a imagisticii medicale s-a datorat introducerii razelor X și a tomografiei computerizate, dar și a undelor ultrasonore.

Prezenta lucrare aduce ca elemente de noutate metoda imaginilor de caracteristici ca un spațiu nou de analiză și apoi, folosirea acestor imagini de caracteristici (în mod special funcția energia) cuplate cu metoda de segmentare bazată pe nivele stabilite, pentru identificarea diferitelor leziuni cerebrale. Deasemenea, analiza texturală a fost folosită la identificarea anumitor tipuri de leziuni prin apelarea la momentele (geometrice și statistice) specifice imaginilor digitale. Calitatea și eficacitatea operațiilor de segmentare a fost realizată prin analize de similaritate.

1. Motivația alegerii temei de cercetare

Odată cu fenomenul de îmbătrânire a populației, apariția bolilor neuro-degenerative este în continuă creștere. În 2010, la nivel mondial, s-a estimat că un număr de 35,6 milioane de persoane trăiau afectate de demență. În următorii 20 ani acest număr ar putea fi aproape dublu. În 2030, aproximativ 65,7 milioane de persoane vor fi afectate de demență. Demența provoacă pierderea memoriei și altor funcții cognitive, ceea ce duce la un impact major asupra pacienților dar și a familiilor lor și a sistemelor de asistență medicală.

Segmentarea automată a tumorilor cerebrale este un proces complicat și dificil întrucât cele mai multe tumori sunt rareori delimitate clar de țesuturile sănătoase. A fost dezvoltată o nouă metodă de segmentare eficientă a tumorilor din imaginile RMN, pentru a îmbunătăți utilizarea datelor medicale digitale pentru diagnostic. Imaginile sunt mai întâi îmbunătățite, iar dacă este necesar se aplică un filtru de eliminare a zgomotului. M-am oprit asupra segmentării imaginilor deoarece este un domeniu captivant datorită interactivității utilizatorului cu imaginea. În altă etapă a studiului, am corelat segmentarea imaginilor digitale cu momentele statistice și momentele geometrice pentru identificarea celui mai bun set de caracteristici care să permită identificarea eficientă a leziunilor de chist mamar și a nodulilor mamari dar și decelarea clară între aceste formațiuni. Am folosit imagini provenite din domeniul medical deoarece sunt mult mai complexe și au permis studii mult mai aprofundate.

2. Importanța și gradul de originalitate al proiectului de cercetare

Achiziția unei imagini de calitate care să nu fie afectată 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 aplicațiile software realizate, 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.

3. Obiectivele tezei

În conformitate cu titlul tezei de doctorat **Abordări inovative privind extragerea conținutului informațional util din imagini digitale** și a referatelor științifice susținute în perioada stagiului de pregătire, au fost propuse și atinse următoarele obiective majore:

- ✓ Restaurarea imaginilor și evitarea degradării caracteristicilor utile datorate zgomotului și altor artefactelor prin utilizarea filtrelor liniare și neliniare și prin separarea și eliminarea câmpului de bias (sau a erorii de deplasare).
- ✓ Evidențierea unor zone de interes prin realizarea propriilor imagini de caracteristici de ordinul I și de ordinul II, extragerea descriptorilor imaginilor, stabilirea unor relațiile de corelare între imaginile de caracteristici și studii de analiză statistică asupra lor.
- ✓ Segmentarea imaginilor complexe folosind modele de contur activ (snakes) cuplate cu distribuții Gaussiene și metode de regularizare a conturilor.
- ✓ Caracterizarea imaginilor și identificarea informației relevante cu ajutorul momentelor geometrice și statistice.
- ✓ Caracterizarea texturilor cu ajutorul descriptorii extrași din histograma imaginii și cuantificarea performanței segmentării și a calității imaginii cu metrici cantitative ca diferența medie pătratică (MSE), valoarea de vârf a raportului semnal-zgomot (PSNR- Peak Signal to Noise Ratio), dar și calitative precum corelația normalizată (NC), diferența medie (Av Diff), conținutul structural (SC), eroarea absolută normalizată (NAE).

4. Diseminarea rezultatelor cercetării

Rezultatele obținute în urma cercetărilor din cadrul stagiului doctoral efectuat în țară au fost diseminate prin publicarea de către autoare a **2** lucrări indexate în bazele de date ISI Web of Knowledge și **4** indexate ISI Proceedings. Au fost publicate **9** lucrări științifice în volume ale conferințelor naționale și internaționale. Astfel, **9** participări la conferințe dintre care **7** conferințe naționale și **2** conferințe internaționale.

5. Structura lucrării științifice

Pentru îndeplinirea obiectivelor tezei de doctorat **Abordări inovative privind extragerea conținutului informațional util din imagini digitale** s-a recurs la structurarea acesteia în cinci capitole cu un conținut consistent, unitar și bine fundamentat la care s-au adăugat introducerea și concluzii. Lucrarea conține 113 pagini, 43 figuri, 14 tabele, 240 referințe, urmat de un rezumat în limba română și un Curriculum Vitae al autoarei.

Capitolul I 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 a temei de cercetare prin prezentarea pe scurt a stadiului actual al cercetarilor în domeniu dar și detaliile cu privire la structura tezei.

Capitolul 2 prezintă tehnici de prelucrare a imaginilor precum filtrarea imaginilor, îmbunătățirea contrastului, analiza histogramei imaginii, descriptori de calitate și utilizarea modelelor de caracteristici binare locale (Local Binary Patterns LBP) în analiza texturii imaginii.

În **capitolul 3** sunt prezentate metodele de segmentare avansate, bazate pe contururi active (*snake*) pentru extragerea obiectelor de interes, pe segmentare bazată pe nivelul stabilit cu selectare binară și filtrare Gaussiană SBFRLS (Selective Binary and Gaussian Filtering Regularized Level Set), pe segmentarea bazată pe contururi active folosind o distribuție Gaussiană a energiei ajustată de distribuții locale ale mediei și varianței LGDF (Local Gaussian Distribution fitting energy), și pe metoda parametrică de estimare a câmpului de bias. Au fost abordate metode ce aparțin aceluiași grup de interes pentru a verifica eficacitatea acestora. Fiecare metodă este descrisă atât ca principiu teoretic cât și ca structură matematică. Momentele geometrice și statistice sunt utilizate ca metode de clasificare a texturii iar imaginile de caracteristici permit o clasificare fiabilă a diferitelor afecțiunilor cerebrale. Studii privind similaritatea / disimilaritatea imaginilor digitale 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 contribuții proprii și rezultate experimentale în analiza imaginilor digitale pentru extragerea conținutului informațional: extragerea caracteristicilor texturale pentru diferențierea imaginilor digitale, metoda funcției de nivel stabilit cuplată cu caracteristica Energie în segmentarea imaginilor, metoda caracteristicii locale binare LBP pentru diferențierea stărilor patologice ale creierului, analiza calitativă a similarității structurale a imaginilor RMN cerebrale și identificarea obiectelor de interes în imagini digitale folosind momentele imaginii.

Capitolul 5 prezintă concluziile generale ale lucrării, care coroborează concluziile parțiale prezentate în capitolele anterioare, privind extragerea conținutului informațional din imaginile digitale.

Fiecare dintre capitolele prezentate conține concluzii parțiale și lista bibliografică proprie.

6. Materiale și seturi de date utilizate în studiile proprii

Au fost utilizate trei tipuri de imagini cerebrale T1w, T2w și CT care conțin diverse leziuni. Seturile de date folosite sunt disponibile gratuit pentru download din atlasul cu imagini cerebrale "The whole brain atlas" din baza de date a Harvard Medical School (<http://www.med.harvard.edu/AANLIB/home.html>). A fost luată în considerare diversitatea formelor anatomice și au fost analizate următoarele tipuri de leziuni: hemoragie (cod eșantion 018), infarct (cod 012), tumoare (cod 010) și placă de scleroză multiplă (cod 013). S-a testat segmentarea pe diferite imagini MR folosind aceleași seturi de parametri și aceleași setări de inițializare. Seturile de date MRI și CT au avut dimensiuni axiale de 256 × 256 pixeli, cu o rezoluție de 0.86 mm și o grosime de 3 mm.

Capitolul I

Tehnici de prelucrare a imaginilor

Tehnicile de procesare a imaginilor digitale sunt utilizate pentru a rezolva probleme diverse, cum ar fi [1]:

- îmbunătățirea calității imaginilor, prin creșterea contrastului, operație numită îmbunătățirea imaginii,
- pentru a utiliza cât mai puțini biți posibili în reprezentarea imaginii, cu deteriorarea minimă a calității sale, operație numită compresia imaginii,
- pentru a îmbunătăți imaginea prin reducerea încețosării sale, operație numită restaurarea imaginii,
- pentru a utiliza anumite caracteristici ale imaginii, operație numită extragerea caracteristicilor [2].

În prelucrarea imaginilor, sunt parcurse următoarele etape (fig. 1.1):

- achiziționarea imaginii,
- pre-procesarea,
- segmentarea,
- reprezentarea și extragerea caracteristicilor,
- recunoaștere, clasificare și interpretare [1].

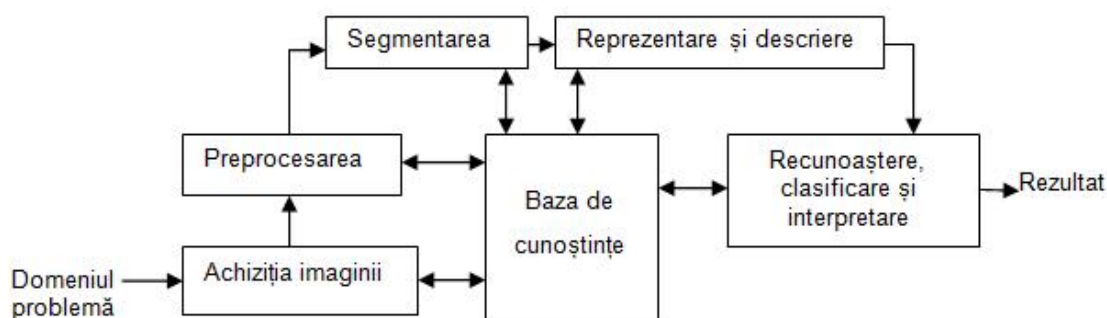


Figura 1.1. Etape fundamentale în prelucrarea imaginilor digitale [1]

Digitizarea reprezintă prelucrarea imaginii cu ajutorul computerului, ce constă în transformarea imaginii naturale în imagine "discretă", exprimată în cod digital [3].

Imaginile folosite în acest studiu au fost achiziționate folosind rezonanța magnetică nucleară (RMN) care este una dintre tehnicile cele mai performante și mai des utilizate în studiul materiei în cele trei stări de agregare: solidă, lichidă și chiar gazoasă. Principalele avantaje ale tehnicilor RMN constau în caracterul complet neinvaziv al acestora și în faptul că, de cele mai multe ori, nu este necesară o pregătire prealabilă a probelor de studiat. Cea mai cunoscută dintre tehnicile RMN este tomografia RMN (sau imagistica RMN), prin aplicațiile sale în medicină. Tehnica RMN nu folosește radiația X ci se bazează pe proprietățile protonilor de hidrogen (H+) din corpul omenesc. După modul în care se realizează achiziția imaginii, am utilizat următoarele tipuri de imagini:

- de tip T1 – care este întunecată, capabilă să diferențieze țesutul adipos de apă; apa este hipointensă (mai întunecată) iar țesutul adipos este hiperintens (mai deschis).

Se mai utilizează în detecția edemelor, tumorilor, infarctului, infecțiilor, hemoragiilor sau calcificărilor. Avantajul acestei secvențe este timpul scurt de achiziționare a imaginilor și permite diferențierea excelentă dintre substanța albă și cea cenușie.

– de tip T2 – care este strălucitoare, permite diferențierea dintre țesutul adipos și apă dar rezultatele vor fi inversate: țesutul adipos va fi hipointens (închis) iar apa hiperintensă (strălucitoare). Acest tip de imagine permite analiza țesutului ce au un conținut crescut de apă ca edeme, tumori, infarct, inflamații, infecții sau colecții subdurale.

În etapa de preprocesare a imaginilor s-au folosit tehnici de filtrare liniară, de îmbunătățire a contrastului, de manevrarea histogramei prin egalizarea acesteia sau prin metode de separare a obiectelor.

În activitatea de dezvoltare a unor tehnici de analiză automată a imaginii care să permită segmentarea și cuantificarea cât mai exactă a leziunii cerebrale s-au propus metodele de segmentare bazate pe funcții de nivel stabilit ce aparțin modelelor deformabile [4]. Acestea sunt printre cele mai performante, precise și robuste. Astfel, contribuțiile principale la dezvoltarea acestor metode de segmentare au fost aduse de către Mumford-Shah [5], Chan și Vese [6] și Osher & Sethian [7]. Chan și Vese [6] au propus metoda “conturului activ fără extracția muchiilor” bazat pe segmentarea funcțională simplificată dezvoltată Mumford-Shah [5]. Pentru a elimina neajunsurile modelului MS, aceștia propun o funcție energia funcțională ce include două funcții de uniformizare definite în două subregiuni exclusive (în interiorul/*inside* curbei C și în exteriorul/*outside* curbei C). Ulterior, Osher & Sethian [7] au propus o metodă bazată pe funcții de nivele stabilite pentru a minimiza funcționala Chan- Vese. Această metodă fundamentală a fost îmbunătățită de către Wang ș.a. [4] care propun regularizarea funcției de nivel stabilit folosind metoda de penalizarea a abaterii în raport cu o funcție distanță și de penalizare a lungimii sale pentru a obține un contur neted în timpul evoluției.

În etapa de post-procesare, s-a realizat analiza cantitativă a imaginilor prelucrate cu ajutorul descriptorilor numerici de calitate. Aceștia sunt calculați în raport cu calitatea imaginii originale. Cei mai frecvenți descriptori sunt raportul semnal-zgomot (SNR- Signal to Noise Ratio), raportul contrast-zgomot (CNR-Contrast to Noise Ratio), eroarea medie pătratică, (MSE- Mean Square Error), radicalul erorii medii pătratice (RMSE- Root Mean Square Error), valoarea de vârf a raportului semnal-zgomot (PSNR- Peak Signal to Noise Ratio), eroarea medie absolută (MAE mean absolute error) și coeficientul de corelație (CoC- correlation coefficient).

Deasemenea, în scopul extragerii informației utile înglobată în imaginile digitale, se utilizează analiza texturii folosind caracteristicile binare locale LBP ce prezintă o putere de discriminare sporită în cazul multor aplicații din domeniul imagisticii. Inițial, LBP a fost utilizat pentru a extrage caracteristici din diferite imagini texturate cum ar fi fibre organice, lemn sau țesături [9]. După câteva decade de dezvoltare, această metodă și-a dovedit utilitatea și în extragerea altor tipuri de caracteristici cum ar fi descriere facială [10], segmentarea imaginilor sau alte aplicații cum ar fi extragere de descriptori morfologici [9]. Recent, LBP a fost folosit pentru a recunoaște sistemul venos al degetului [11], adnotarea imaginii [12], și recuperarea imaginilor medicale [13]. Majoritatea studiilor ce folosesc imagini medicale sau tehnologice folosesc abordarea 2D-LBP pentru extragerea caracteristicilor.

CAPITOLUL II

METODE AVANSATE DE ANALIZĂ A IMAGINILOR DIGITALE UTILIZATE ÎN ACTIVITATEA EXPERIMENTALĂ

2.1. Noțiuni generale privind metodele de analiză

Prin analiza imaginilor se înțelege procesul de extragere de informații din imagini pentru a facilita luarea anumitor decizii. Segmentarea imaginilor reprezintă o tehnică de analiză prin care imaginile sunt descompuse în părțile lor constituente, iar informațiile privitoare la acestea putând fi utilizate ulterior în recunoașterea de obiecte sau pattern-uri imagistice. Existența unor obiecte ce prezintă texturi accentuate poate îngreuna operațiile de analiză deoarece acestea prezintă suprafețe complexe, cu multe contururi și care pot fi interpretate greșit printr-o abordare inadecvată. În acest caz, se apelează la tehnicile de analiză a texturilor, în care sunt analizate regiuni ale imaginilor, sau chiar imagini întregi, cu scopul de extrage informații ce pot fi utilizate ulterior în operații mai complexe.

2.2. Metode de segmentare a imaginilor

Segmentarea imaginii este o sarcină fundamentală în multe aplicații de prelucrarea a imaginilor.

Găsirea obiectelor în imagini este o problemă cu aplicații în medicină, industrie, sau gestionarea teritoriului prin utilizarea imaginilor satelitare. Segmentarea imaginilor joacă un rol important în multe aplicații neuroimagistice inclusiv în planificarea neurochirurgicală, în etapele de diagnostic și de evaluare a condițiilor patologice, precum și în definirea regiunilor anatomice de interes pentru studii de imagistică. Segmentarea imaginilor presupune atribuirea unei etichete pentru fiecare pixel dintr-o imagine, astfel încât toți pixelii dintr-un segment, cu aceeași etichetă, prezintă aceleași caracteristici.

2.2.1. Segmentarea bazată pe contururi active

La ora actuală există o gamă largă de tehnici de segmentare a imaginilor digitale. Dintre acestea, metoda bazată pe contururi active ACM (*Active Contour Model*) este una dintre metodele cele mai de succes. ACM constă în evoluția unei curbe, în limita unor anumite constrângeri, către granițele obiectului cu scopul de a extrage/segmenta obiectul dorit. Principiul metodei bazată pe contururi active constă în evoluția unei curbe închise spre o poziție de echilibru care reprezintă muchiile obiectului căruia se intenționează să i se determine conturul. Curba, în deplasarea ei către conturul obiectului, trece prin mai multe etape. Între două etape consecutive, viteza punctelor care formează curba depinde de forțele aplicate conturului detectat, raportate la normala conturului. Caracteristici ale imaginii, precum intensitatea sau gradientul, pot influența forțele care acționează asupra curbei. Conturul căutat va fi, de fapt, poziția care asigură echilibrul forțelor care au acționat asupra lui.

Cunoscute în literatura de specialitate și sub denumirea de „snakes”, contururile active pot fi folosite pentru segmentarea imaginilor 2D și 3D în vederea extragerii obiectelor de interes. Schematic, conceptul de contur activ este prezentat în figura 2.1. Obiectul este

reprezentat prin culoarea gri închis, punctul/nodul albastru $S(1)$ reprezintă punctul / nodul de start al conturului, iar punctul / nodul roșu reprezintă ultimul punct al conturului marcat prin $S(n)$.




Figura 2.1. Modalitatea de lucru ale metodelor active de contur. [14]

2.2.2. Metoda de segmentare SBFRLS (Selective Binary and Gaussian Filtering Regularized Level Set)

Zgomotul și neomogenitatea intensității sunt considerate dezavantaje ce îngreunează segmentarea imaginilor RMN. În lucrarea [15], am propus o nouă abordare bazată pe *imagini de caracteristici* construite pe baza funcției *energia*, pentru corectarea neomogenității intensității imaginilor RMN și segmentarea obiectelor de interes. Imaginea de caracteristici energia reprezintă o nouă imagine obținută din imaginea inițială, atunci când valorile pixelilor sunt înlocuite cu valorile energiei locale calculate în măști de dimensiune $n \times n$. Performanța și utilitatea imaginii de caracteristici energia au fost testate și comparate prin intermediul a două tipuri diferite de metode de segmentare bazate pe funcții de nivel stabilit: o metodă de ajustare a intensității locale și globale și o metodă de binarizare selectivă bazată pe procesul de filtrare Gaussiană pentru a regulariza funcția de nivel stabilit, în scopul de a extrage eficient limitele/muchiile leziunilor cerebrale. Provoacă ridică de această abordare a venit de la faptul că acest tip de leziuni nu sunt complete decelabile, deoarece intensitățile specifice leziunii variază între valorile caracteristice țesutului nedeteriorat și valori caracteristice lichidului cefalorahidian (ce caracterizează zone complet deteriorate). Zona leziunii prezintă neomogenitate deoarece există regiuni complet distruse și regiuni periferice care prezintă alterări minore. Deoarece neomogenitatea afectează, de cele mai multe ori, acuratețea segmentării și împiedică grav analiza cantitativă, s-au propus soluții de îmbunătățire a performanței segmentării prin construirea imaginii de caracteristici energia. Deși, algoritmi utilizați în cercetarea noastră nu sunt noi, combinarea acestora cu imaginea de caracteristici energia este unică și și-a dovedit eficiența în cazul imaginilor RMN neomogene și afectate de zgomot.

Formularea funcției de nivel stabilit în cadrul modelelor de contururi active bazate pe regiune oferă avantajele inițializării libere a curbei de nivel zero (sau a conturului inițial) și capacitatea de a captura automat limitele căutate pe baza modificărilor topologice. Metoda nivelului stabilit utilizează un set complex de parametri de control, ceea ce conduce la creșterea complexității metodei.

2.2.3. Metoda de segmentare bazată pe contururi active folosind o distribuție Gaussiană a energiei ajustată de distribuții locale ale mediei și varianței LGDF (Local Gaussian Distribution fitting energy)

Li ș.a. [16, 17] au propus un model de segmentare bazat pe regiuni mai eficient, ce folosește informații privind intensitatea locală în imagini RMN cu neomogenități accentuate ale intensității. Ei folosesc binarizarea locală și o funcție de energie ajustată de distribuții locale (LBF local binary fitting). Modelul LBF se bazează pe analiza intensității locale, care să îi permită rezolvarea problemei neomogenității intensității. Acesta este capabil să recupereze cu precizie limitele obiectului. În [18, 19], atât intensitatea locală cât și varianțele sunt folosite pentru a caracteriza distribuția intensității locale în modelele de contur activ propuse.

Ulterior, Li ș.a. [20] propun o nouă metodă de segmentare bazată pe contururi active antrenate de o distribuție Gaussiană a energiei ajustată de distribuții locale ale mediei și varianței. Valorile mediei și varianței caracteristice unei distribuții locale a intensității au fost folosite la determinarea și diminuarea neomogenității intensității, dar și a zgomotului din imagini. Prin utilizarea unei funcții nucleu, aceștia au definit mai întâi o energie locală pentru a caracteriza ajustarea distribuției Gaussiene la datelor locale specifice unei anumite regiuni din imagine, în vecinătatea unui punct. Energia locală ajustată de distribuția Gaussiană locală (LGDF) este definită de autori folosind o integrală dublă: prima integrală este definită pentru un nucleu (kernel) ce permite ajustarea distribuției Gaussiene la datele locale ale imaginii în vecinătatea (nucleul) definit; această energie locală este integrată din nou și furnizează datele căutate. Media intensității locale și varianța, care sunt funcții spațiale diferite, sunt două variabile ale energiei funcționale LGDF. Energia LGDF este apoi încorporată într-o formulare de funcție cu nivel stabilit corelată cu un termen de regularizare. Astfel, aceasta poate fi utilizată în segmentarea imaginilor ce prezintă neomogenități ale intensității și sunt afectate de zgomot. Algoritmul propus, care utilizează varianța ca variabilă, permite identificarea regiunilor cu variații diferite ale intensității. Modelul LGDF are la bază următoarele modelul funcțional Mumford–Shah și modelul Chan–Vese care au fost prezentate în capitolul 2 al prezentei lucrări.

2.2.4. Metoda parametrică pentru estimarea câmpului de bias

Metodele de corecție a modelelor de erori pot fi clasificate în două clase: metode prospective [21, 22] și metode retrospective [23 - 25]. Metodele prospective încearcă să evite neomogenitatea intensității în procesul de achiziție al imaginii folosind hardware special sau secvențe specifice. Aceste metode sunt capabile să corecteze unele neomogenități ale intensității cauzate de scanner-ul RMN. Însă, ele nu pot corecta acele neomogenități ale intensității, care sunt dependente de pacient [26]. Spre deosebire de metodele prospective, metodele retrospective se bazează exclusiv pe informații dobândite din imagine și astfel, pot fi aplicate pentru a elimina efectele dependente de pacient. Una dintre cele mai populare metode de corecție a câmpului de bias este cea aplicată metodelor de segmentare [23, 27 - 29]. În acest caz, sarcinile de corecție ale câmpului de bias și de segmentare sunt intercalate într-un proces iterativ, astfel încât acestea să producă rezultate mai bune. În [23] Wells ș.a., au dezvoltat o abordare bazată pe un algoritm de mediere și

maximizare (EM Expectation Maximization) pentru corecția câmpului de bias intercalată cu segmentare. Această metodă a fost îmbunătățită ulterior de Guillemaud și Brady [28]. Cu toate acestea, metodele bazate pe algoritmul EM necesită o bună inițializare pentru fiecare câmp de bias prin selecții manuale ale punctelor reprezentative pentru fiecare clasă de țesut [30]. Astfel de inițializări sunt subiective și adesea neproductive [27]. În plus, corecția finală și segmentarea sunt sensibile la alegerile specifice ale condițiilor inițiale [30, 31].

Bazat pe cadrul EM dezvoltat în lucrarea [23], Leemput ș.a. [27] au propus un model parametric explicit al câmpului bias. În locul intervenției manuale, ei au folosit un atlas digital cu imagini cerebrale, care oferă hărți *a priori* pentru materia albă (WM), materia cenușie (GM) și fluidul cefalorahidian (CSF). Deși această metodă se pretinde a fi mai solidă decât metoda lui Wells, inițializarea parametrilor rămâne critică [30].

Li ș.a. [32] au propus o nouă abordare de minimizare a energiei pentru estimarea câmpului de bias și segmentarea țesutului. Ei au definit o funcție de energie care depinde de coeficienții funcțiilor de bază, de familia de funcții corespunzătoare țesuturilor din imagine și de constantele ce aproximează semnalul original provenind de respectivele țesuturi. Estimarea câmpului de bias și segmentarea imaginii sunt realizate simultan, ca rezultat al minimizării acestei energii.

2.3. Momente ale imaginilor digitale

Într-o imagine, momentele sunt capabile să descrie informațiile conținute în respectiva imagine. Aceste momente pot fi calculate. Cu toate acestea, accesul la toate informațiile relevante conținute într-o imagine ar necesita o manipulare cu un număr infinit de valori ale momentelor. Provocarea este de a selecta doar un subset semnificativ din mulțimea momentelor caracteristice unei imaginii, care conține informații suficiente pentru o caracterizare unică și completă a acesteia. De obicei, momentele statistice sunt utilizate ca metode de clasificare a texturii [33 - 34].

2.3.1. Momente geometrice

Momentele geometrice sunt utilizate pe scară largă ca și caracteristici de formă a obiectelor biologice în imagini ecografice. Ele prezintă un cost redus de calcul, dar sunt extrem de sensibile la zgomot [35].

2.3.2. Momente statistice

Momentele statistice sunt extrase din nivelurile de gri ale histogramei imaginii sau ale unei regiuni de interes. Fie L este numărul de niveluri de gri distincte ale unei imaginii, z este variabila aleatoare care indică niveluri de gri, și $p(z_i), i = 0, 1, 2, \dots, L - 1$ reprezintă histograma corespunzătoare iar m este valoarea medie a lui z . Momentul de ordin n al lui z față de medie este:

$$\mu_n(z) = \sum_{i=0}^{L-1} (z_i - m)^n p(z_i) \quad (2.35)$$

Se pot defini următoarele tipuri de momente statistice:

Momentul de ordinul întâi este dat de valoarea medie a lui z :

$$m = \sum_{i=0}^{L-1} z_i p(z_i) = \mu_1 \quad (2.36)$$

Momentul de ordinul doi (sau varianța) furnizează gradul de uniformitate a distribuției nivelurilor de gri.

$$\sigma^2(z) = \mu_2(z) \quad (2.37)$$

Momentul de ordinul trei (skewness sau turtire) este o măsură a simetriei histogramei imaginii sau o măsură a gradului de alunecare a histogramei imaginii:

$$\mu_3(z) = \sum_{i=0}^{L-1} (z_i - m)^3 p(z_i) \quad (2.38)$$

Momentul de ordinul patru se numește kurtosis (excesul) și este o măsură a gradului de aplatizare relative a histogramei imaginii:

$$\mu_4(z) = \sum_{i=0}^{L-1} (z_i - m)^4 p(z_i) \quad (2.39)$$

2.4. Imagini de caracteristici

Matricea de co - ocurență a fost utilizată pe scară largă în analiza texturii pentru identificarea anumitor țesuturi sau pentru detectarea anomaliilor din țesuturi și organe, în probleme de segmentare, etc [36 - 38]. În studiile efectuate am folosit caracteristicile texturale ca energie (sau momentul de ordinul doi unghiular) și omogenitatea, deci voi prezenta pe scurt câteva aspecte teoretice ale acestor imagini de caracteristici [39].

Energia măsoară apariția perechilor repetate într-o imagine: $E_n = \sum_i^M \sum_j^N P^2[i, j]$,

unde $P[i, j]$ contorizează numărul de perechi de pixeli având intensitățile i și j . Este de așteptat ca energia să fie mare, în cazul în care apariția perechilor de pixeli repetate este mare.

Omogenitatea $H = \sum_i^M \sum_j^N \frac{P[i, j]}{1 + |i - j|}$ caracterizează omogenitatea locală a unei

perechi de pixeli. Are valoare mare dacă nivelele de gri ale fiecărei perechi de pixeli sunt similare.

2.5. Metoda caracteristicii binare locale LBP (Local Binary Pattern) de analiză a imaginilor

Unul dintre obiectivele principale ale analizei texturale este acela de a oferi o descriere matematică solidă a comportamentului spațial al valorilor intensității specifice oricărei vecinătăți dată. Aceste distribuții locale, numitele texturi, caracterizează suprafețele obiectelor și sunt utilizate pentru identificarea modelului și recunoașterea de obiecte sau de imagini.

Metoda caracteristicilor binare locale LBP a fost propusă de Ojala [40] și se bazează pe ideea că proprietățile texturale din interiorul regiunilor omogene pot fi mapate în modele care reprezintă micro-caracteristici. Modelul LBP propus folosește o mască pătrată 3×3 numită "spectrul texturii", care reprezintă o vecinătate în jurul unui pixelului central, Figura 2.2.(a). Valorile din masca pătrată sunt comparate cu valoarea pixelului central; cele mai mici decât valoarea centrală sunt etichetate cu "0", iar celelalte sunt etichetate cu "1", Figura 2.2.(b). Pixelii etichetați sunt multiplicați de o funcție de ponderare în funcție de pozițiile lor (conform numerotării pixelilor în Figura 2.2.(b)), pentru a forma un „lanț”, Figura 2.2.(c). Apoi valorile celor opt pixeli sunt însumate pentru a obține o etichetă pentru această vecinătate (Figura 2.2.(d)), această metodă produce 2^8 câmpuri posibile.




Figura 2.2. Algoritmul LBP (bazat pe o mască pătrată de (3×3)) calculează o etichetă prin comparații între pixelul central și vecinii săi. Valoarea centrală este $p_c = 10$ și eticheta

$$\text{finală va fi } 27 = 1 \cdot 2^0 + 1 \cdot 2^1 + 0 \cdot 2^2 + 1 \cdot 2^3 + 1 \cdot 2^4 + 0 \cdot 2^5 + 0 \cdot 2^6 + 0 \cdot 2^7 + 1 \cdot 2^8 \quad [41]$$

După ce este finalizat acest proces, pentru întreaga imagine, se realizează histograma astfel încât poate fi interpretată ca o caracteristică a obiectului analizat. Deși această metodă oferă informații despre structurile spațiale locale, aceasta nu este invariantă la rotație și nu include informații asupra contrastului, care s-a demonstrat că este crucial pentru îmbunătățirea deosebirilor dintre texturi.

2.6. Metode de analiză privind similaritatea / disimilaritatea imaginilor digitale

Imaginile RMN achiziționate din zona craniană sunt afectate de artefacte, zgomot, încrețoșare, compresie și neomogenitate.

Performanța operației de pre-procesare este cuantificată prin utilizarea următoarelor metrici de calitate:

- eroarea medie pătratică,
- semnalul de vârf al zgomotului,
- rădăcina erorii medii pătratice,
- raportul semnal zgomot.

Principalul dezavantaj al acestor măsurători este că ele nu iau în considerare fidelitatea structurală a imaginii. Cu aceste metrici doar se măsoară, nu se îmbunătățește sau nu se elimină zgomotul [42].

Informația structurală din imagini vizuale trebuie analizată distinct deoarece există distorsiuni nestructurale (care nu schimbă structura imaginii în nici un fel), dar și distorsiuni

structurale. Variațiile de luminanță și contrastul fac parte din prima categorie, iar zgomotul aditiv Gaussian, neclaritatea și pierderea de informație în timpul compresiei fac parte din cea de a doua. Toate acestea pot denatura, în mod semnificativ, structura unei imagini.

În procesarea imaginilor medicale, prezența zgomotului, rezoluția slabă, contrastul scăzut și neomogenitatea intensității fac dificilă această operație. Neomogenitatea intensității este principala provocare în încercarea de a extrage o caracteristică relevantă sau pentru segmentarea unei imagini în obiecte omogene. Percepția vizuală umană este puternic afectată de distorsiuni structurale și, în același timp, se compensează cu ușurință prin prezența distorsiunilor nestructurale. În cazul imaginilor RMN cerebrale, variabilitatea anatomică a creierului, începând cu parametrul de vârstă și terminând cu țesuturile modificate de diferite patologii ce pot apărea în diferite locații din creier sunt elemente perturbatoare în timpul procesării imaginilor [43]. Metrica de similaritate structurală (SSIM) furnizează informații cu privire la gradul de potrivire între structura imaginilor originale și a noilor imagini, generate prin variația diferiților parametri. Scopul final este evaluarea fidelității structurale a unei imagini prelucrate.

Metrica de similaritate structurală SSIM

Metrica similaritate structurală (SSIM) măsoară similaritatea structurală a unei imagini prelucrate față de o imagine de referință sau gradul de conservare a structurilor relevante. Indicele SSIM are aplicabilitate în clasificarea imaginilor [44 - 47], restaurare și fuziune [48] sau de eliminare a zgomotului [49].

CAPITOLUL III

CONTRIBUȚII PROPRII ȘI REZULTATE EXPERIMENTALE ÎN ANALIZA IMAGINILOR DIGITALE PENTRU EXTRAGEREA CONȚINUTULUI INFORMAȚIONAL

Acest capitol prezintă principalele realizări experimentale pe durata celor trei ani de studii doctorale. Rezultatele acestor studii au fost publicate în reviste indexate în baze de date internaționale (Web of Science și International Data Base) fiind, în acest fel, validate de comunitatea științifică națională și internațională. În ciuda diversității enorme care există între metodele dedicate analizei conținutului informațional util din imaginile digitale, pe durata studiilor doctorale am propus ca metode noi imaginile de caracteristici ca un spațiu nou de analiză și apoi, folosirea acestor imagini de caracteristici (în mod special funcția energia) cuplate cu metoda de segmentare bazată pe nivele stabilite, pentru identificarea diferitelor leziuni cerebrale. Diferențierea între conținutul informațional al diferitelor tipuri de boli degenerative s-a realizat prin apelarea la metoda caracteristicii binare locale. Analiza texturală a fost folosită la identificarea anumitor tipuri de leziuni prin apelarea la momentele (geometrice și statistice) specifice imaginilor digitale. Calitatea și eficacitatea operațiilor de segmentare a fost realizată prin analize de similaritate.

3.1. Extragerea caracteristicilor texturale pentru diferențierea imaginilor digitale

În această secțiune se prezintă metoda propusă și folosită pentru analiza texturală a imaginilor cerebrale RMN cu scopul de a detecta diferite leziuni cerebrale și de a discrimina între o traumă hemoragică sau un accident vascular cerebral. Pentru a detecta regiuni anormale prezente în structura cerebrală folosind imaginile RMN, s-a folosit operația de convoluție a imaginii originile cu un nucleu sau o mască. În timpul colectării datelor, a fost calculată probabilitatea erorii p , pentru toate datele ce privesc parametrii texturali energie și omogenitate. Acești descriptori au fost calculați pentru zone de interes ROI, selectate după anumite reguli, atât pentru imagini originale cât și pentru imaginile de caracteristici.




Figura 3.1. Imagine RMN care prezintă o leziune hemoragică.

- (a) descompunere la nivelul 3 cu ajutorul wavelet-uri Daubechies;
- (b) imagine fără zgomot;
- (c) aspect șablon pentru imaginea RMN T2w a creierului cu indicarea zonelor de interes ROI. Zonele de interes sunt încadrate în dreptunghiuri negre [50]

Evaluarea țesutului cerebral a fost realizată prin explorarea a 120 de zone de interes (ROI) cu dimensiunile între 1500-1600 pixeli. ROI au fost localizate în aceleași zone (pe părțile laterale stânga și dreapta ale țesutului cerebral) atât în cazul creierului sănătos, cât și în cazul imaginilor corespunzătoare unor traume cerebrale (Fig. 3.1.a). Plasarea ROI a fost simetrică față de axa sagitală identificată și au fost rotite cu același unghi cu care sunt înclinate axele planului sagital. S-a folosit expertiza profesională a unui neurolog pentru a plasa regiunile de interes în zonele relevante ale țesutului cerebral [50].

Imaginile RMN cerebrale care alcătuiesc baza de date aleasă au fost transformate în imagini de caracteristici, folosind caracteristicile texturale ce derivă din matricea de co-ocurență: deviația standard, media, skewness, kurtosis și entropia. Deasemenea, s-au folosit dimensiuni diferite al nucleului de convoluție. Studiul de diferențiere și identificare a leziunilor hemoragice în raport cu o imagine RMN cerebrală ce aparține unui pacient sănătos a fost realizat cu ajutorul caracteristicii texturale **energia** (care măsoară apariția perechilor de pixeli repetate într-o imagine) și **omogenitatea** (ce caracterizează omogenitatea locală a unei perechi de pixeli).




Figura 3.2. Exemple de imagini de caracteristici corespunzătoare imaginilor RMN de tip T2w.

(a1, a2, a3) deviația standard Y_{SD} ; (b1, b2, b3) media Y_M ; (c1, c2, c3) skewness Y_S ; (d1, d2, d3) kurtosis Y_K ; și (e1, e2, e3) entropia Y_E .

Codul 1: Prelucrate cu nucleu 3×3 ; Codul 2- Prelucrate cu nucleu 5×5 ; Codul 3- Prelucrate cu nucleu 7×7 . [50]

Figura 3.2 prezintă un exemplu de imagini de caracteristici rezultate. Este utilizat următorul cod: figurile care au indicatorul (1) sunt prelucrate cu nucleu 3×3 ; figurile care au indicatorul (2) sunt prelucrate cu nucleu 5×5 și, în final, figurile care au indicatorul (3) sunt prelucrate cu nucleu 7×7 .

Urmând aceeași procedură, în noile imagini de caracteristici generate a fost localizată fiecare zonă de interes ROI atât în zonele normale cât și în zonele afectate de diferite patologii, pe părțile laterale stânga și dreapta ale țesutului cerebral. A fost investigată capacitatea de discriminare a ambilor parametri de caracteristici texturali (energia și omogenitatea) și analizată capacitatea imaginilor de caracteristici de a detecta și a descrie în mod corect leziunile hemoragice. Ca prelucrare statistică care să permită stabilirea dacă seturile de date analizate sunt statistic diferite, a fost utilizat t-testul care evidențiază diferențele dintre parametrii aparținând zonelor cerebrale normale și zonelor afectate (accident vascular cerebral).

În timpul colectării datelor, parametrii statistici p-valoare au fost calculați pentru parametrii texturali energie și omogenitate. Acești descriptori au fost calculați pentru zone de interes ROI atât pentru imagini originale cât și pentru imagini de caracteristici. Probabilitatea p a fost utilizată ulterior pentru a stabili care sunt parametrii texturali dependenți furnizați de matricea de co-ocurență. În acest caz, s-a renunțat la acești parametri dependenți ca fiind neinformativi pentru scopul cercetării noastre. În analiză s-au păstrat doar acele imagini de caracteristici care permit obținerea unor parametrii texturali independenți, deci relevanți pentru scopul declarat. Apoi, a fost analizată valabilitatea descriptorilor texturali specifici imaginilor de caracteristici pentru obținerea informațiilor texturale. Descriptorii texturali ca energia și omogenitatea au fost calculați pentru fiecare zonă de interes ROI decupată din imaginile de caracteristici.

Tabelul 3.1 rezumă rezultatele t-testului, comparând capacitatea imaginilor de caracteristici de a detecta, în mod corect, leziunile hemoragice cerebrale. Valorile discriminatorii (valorile aberante) ale imaginilor de caracteristici sunt evidențiate cu caractere albine.

Tabelul 3.1. Valorile parametrului statistic p calculat prin metoda t-test pentru parametrii texturali energia și omogenitatea.

Rezultatele care resping ipoteza de nul sunt evidențiate cu caractere normale ($p < 0.05$).

Tipul de imagine	Valoarea p a energiei în patologia normală vs. patologie cu CVA	Valoarea p a omogenității în patologia normală vs. patologie cu CVA
Imaginea originală	0.052	0.208
$Y_{SD(3 \times 3)}$	0.121	0.04
$Y_{SD(5 \times 5)}$	0.864	<0.01
$Y_{SD(7 \times 7)}$	<0.01	0.04
$Y_{M(3 \times 3)}$	0.356	0.003
$Y_{M(5 \times 5)}$	0.718	<0.01
$Y_{M(7 \times 7)}$	0.178	0.05
$Y_{K(3 \times 3)}$	0.26	0.184
$Y_{K(5 \times 5)}$	<0.001	0.512
$Y_{K(7 \times 7)}$	0.172	0.058
$Y_{S(3 \times 3)}$	0.358	<0.01
$Y_{S(5 \times 5)}$	<0.01	<0.01
$Y_{S(7 \times 7)}$	0.697	0.771

$Y_{E(3 \times 3)}$	0.524	<0.01
$Y_{E(5 \times 5)}$	0.331	<0.01
$Y_{E(7 \times 7)}$	0.618	<0.01

În cazul valorilor probabilității $p < 0.05$ am constatat că următoarele imagini de caracteristici sunt relevante, după cum urmează:

- imaginile de caracteristici deviația standard (Y_{SD}): pentru $Y_{SD(3 \times 3)}$, $Y_{SD(5 \times 5)}$ și $Y_{SD(7 \times 7)}$ omogenitate prezintă valori discriminatorii pentru ambele tipuri de țesut cerebral analizate. $Y_{SD(7 \times 7)}$ este relevantă numai pentru energie.
- imaginile de caracteristici medie (Y_M): în detectarea zonelor hemoragice numai omogenitatea este relevantă. Energia este eliminată din această analiză.
- imaginile de caracteristici kurtosis: $Y_{K(3 \times 3)}$ este irelevantă pentru ambii parametri texturali; $Y_{K(5 \times 5)}$ este relevantă pentru energie iar $Y_{K(7 \times 7)}$ pentru omogenitate.
- imaginile de caracteristici skewness: $Y_{S(5 \times 5)}$ este semnificativă atât pentru energie cât și pentru omogenitate, $Y_{S(3 \times 3)}$ este relevantă pentru omogenitate, iar $Y_{S(7 \times 7)}$ este total irelevantă.
- imaginile de caracteristici entropie: $Y_{E(3 \times 3)}$, $Y_{E(5 \times 5)}$, $Y_{E(7 \times 7)}$ sunt relevante doar pentru omogenitate. Energia este eliminată din analiză.

Surprinzător este faptul că, așa cum reiese din Tabelul 3.1, în ciuda faptului că ambii parametri texturali ai matricei de co-ocurență (energie și omogenitate) funcționează bine pentru anumite imagini caracteristici, în cazul imaginilor RMN cerebrale normale, energia și omogenitatea nu sunt parametri texturali relevanți. Considerăm că imaginile de caracteristici reprezintă un spațiu nou de analiză care poate avea un potențial informativ mai ridicat în accelerarea diagnosticării clinice a bolilor neurodegenerative, fiind un potențial instrument de lucru util al specialiștilor din domeniul neurologic.

Menționăm că atât caracteristicile texturale de ordinul I, cât și dimensiunea nucleului sunt factori critici în analiza texturală. Deviația standard este o măsură a variabilității mediei valorilor nivelurilor de gri dintr-o imagine, iar skewness descrie lipsa de simetrie a valorilor nivelurilor de gri într-o imagine.

Din punctul de vedere al semnificației statistice a parametrilor utilizați în studiul nostru, confirmăm semnificația, eficacitatea și utilitatea imaginii de caracteristici deviația standard (nucleu 7×7), a imaginii de caracteristici skewness (nucleu 5×5). Acestea au fost confirmate prin folosirea descriptorilor texturali energia și omogenitatea ca unelte pentru detectarea leziunilor hemoragice de creier.

Precizăm că nu am analizat întreaga imagine, ci s-au decupat doar zone de interes, ceea ce duce la creșterea eficienței analizei și a vitezei de procesare. Acest procedeu este adesea folosit în aplicații de procesare și analiză a imaginilor digitale. Netezirea prin înlocuirea pixelului central al măștii cu media (ponderată) a pixelilor, blurează imaginea, eliminând nu doar zgomotul, ci și informații importante. Acest efect este mai pronunțat în cazul în care dimensiunea măștii crește. Cu toate acestea, în acest moment al studiului nostru, suntem în imposibilitatea de a descrie o relație clară între mărimea măștii și relevanța imaginii de caracteristici în analiza imaginilor RMN cerebrale. Vor fi realizate studii suplimentare bazate pe caracteristici texturale de ordinul al -II-lea.

Rezultatele experimentale raportate în această secțiune au fost comunicate la TIM 2012 Physics Conference 2012 și publicate ca articol de tip ISI Proceedings [50].

3.2. Metoda funcției de nivel cuplată cu caracteristica Energie în segmentarea imaginilor

În această secțiune se prezintă rezultatele folosirii imaginii de caracteristici energia cuplată cu metoda de segmentare bazată pe funcții de nivele stabilite, pentru identificarea diferitelor leziuni cerebrale.

În studiul nostru au fost utilizate trei seturi de imagini, T1w, T2w și CT ce descriu diferite leziuni. Imaginile au fost descărcate gratuit din baza de date 'The whole brain atlas' (<http://www.med.harvard.edu/AANLIB/home.html>). A fost luată în considerare variabilitatea formelor anatomice și au fost analizate următoarele tipuri de leziuni: hemoragie (eșantionul 018), infarct (eșantionul 012), tumoare (eșantionul 010) și scleroză multiplă în plăci (eșantionul 013).

După cum se arată în Figura 3.3, cadrul de lucru cuprinde două etape. Prima etapă reprezintă procesul de segmentare manuală. A doua etapă este procesul de segmentare automată urmată de analiza performanțelor și de un criteriu de optimizare. Am testat segmentarea pe diferite imagini RMN folosind aceleași seturi de parametri și aceeași configurare de inițializare. Seturile de date RMN și CT utilizate au dimensiunile axiale (256 × 256) pixeli, cu o rezoluție în plan de 0.86 mm și o grosime a feliei de 3 mm. În scopul evaluării performanței metodei de segmentare propuse, am utilizat expertiza radiologului pentru segmentarea manuală a leziunilor. Seturile de date au fost etichetate, în prealabil, și segmentate pentru a localiza regiunile de interes anatomice.

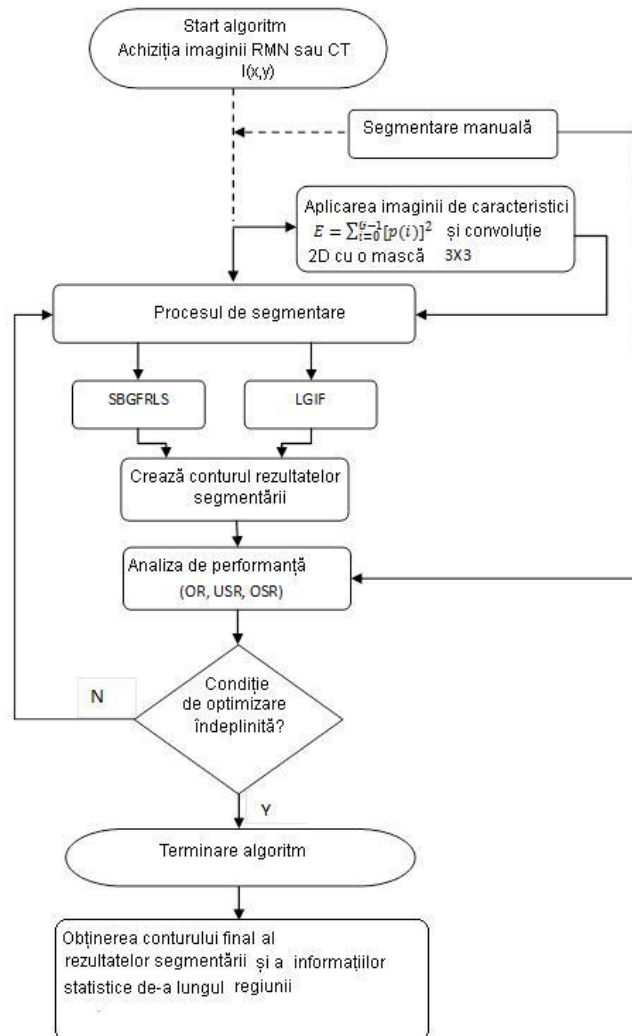


Figura 3.3. Schemă logică explicând pașii implicați în procesul de segmentare [51]

Codurile software cele mai utilizate pe scară largă în analiza neuroimagică cuprind următoarele operații: îndepărtarea scalpului, stratului adipos și a osului cranian (așa numita skull-stripping), eliminarea zgomotului și segmentarea automată. În desfășurarea experimentului propus am folosit următoarele metode: segmentarea bazată pe contururi active împreună cu segmentarea locală sau globală selectivă (SBGFRLS) [8], metoda de segmentare bazată pe distribuția gaussiană (LGIF) [4].

În scopul validării acurateții segmentării, rezultatele obținute au fost comparate cu cele obținute prin segmentarea manuală. Această metodă a fost testată pe imagini RMN cerebrale ce prezintă diferite tipuri de leziuni și răni.

După cum s-a sugerat în [8], parametrii de setare folosiți în metoda SBGFRLS au fost:

- σ variază de la 0.3 la 1.5 în funcție de nivelul de zgomot din imagine și de tipul de leziune analizată,
- $\rho = 1, \varepsilon = 1.5$

- intervalul de timp $\Delta t = 1$ asigură stabilitatea evoluției curbei.

Parametrul σ a avut valori particularizate pentru fiecare experiment de segmentare. Parametrul de viteză sau de evoluție a fost $\alpha = 10$ și 15. Numărul de iterații a variat între 80 și 200. Nivelul zero care este utilizat pentru a iniția conturul activ este în formă pătratică și mărimea și locația sa pot fi modificate în funcție de fiecare obiect de interes în imagine. Codul sursă Matlab a metodei SBGFRLS poate fi găsit la adresa <http://www4.comp.polyu.edu.hk/~cslzhang/>.

Pentru metoda LGIF [53] au fost utilizați următorii parametri de setare:

- σ este 3 sau 5,
- $c_0 = 2$,
- ε este 0.7 și 0.8,
- $\lambda_1 = \lambda_2 = 1$,
- ν variază de la $0.0003 \times 255 \times 255$ la $0.0005 \times 255 \times 255$,
- termenul de regularizare $\mu = 0.1$.

În acest caz, funcția de nivel stabilită inițială este sub forma un cerc. Codul sursă Matlab al metodei LGIF poate fi găsit la adresa <http://www.unc.edu/~liwa/>.

Toți acești parametri setați implicit sunt păstrați nemodificați atunci când metodele de segmentare sunt utilizate în imaginea de caracteristici energie. Acest lucru ne-a permis să evaluăm performanța metodei propusă de noi în raport cu datele raportate în lucrările [52, 53].

Figura 3.4 prezintă unele rezultate ale operației de segmentare prin metodele LGIF și SBGFRLS și, de asemenea, rezultatele segmentării imaginii de caracteristici energie cuplată cu metodele LGIF și SBGFRLS, pentru diverse leziuni cerebrale și diferite tipuri de imagini. În cazul unor imagini rezultatele segmentării sunt bune sau cel puțin satisfăcătoare. Pentru alte imagini se observă discontinuități în delimitarea conturilor deoarece limitele structurilor anatomice existente în aceste imagini sunt neclare. Probele 010CT (SBGFRLS cuplat cu imaginea de caracteristici energie), 013T1 (LGIF cuplat cu imaginea de caracteristici energie), 012T1, T2 și CT (LGIF) și 018T2 (SBGFRLS și SBGFRLS împreună cu imaginea de caracteristici energie) nu au fost segmentate corect.




Figura 3.4. Exemple de imagini segmentate în secțiune.

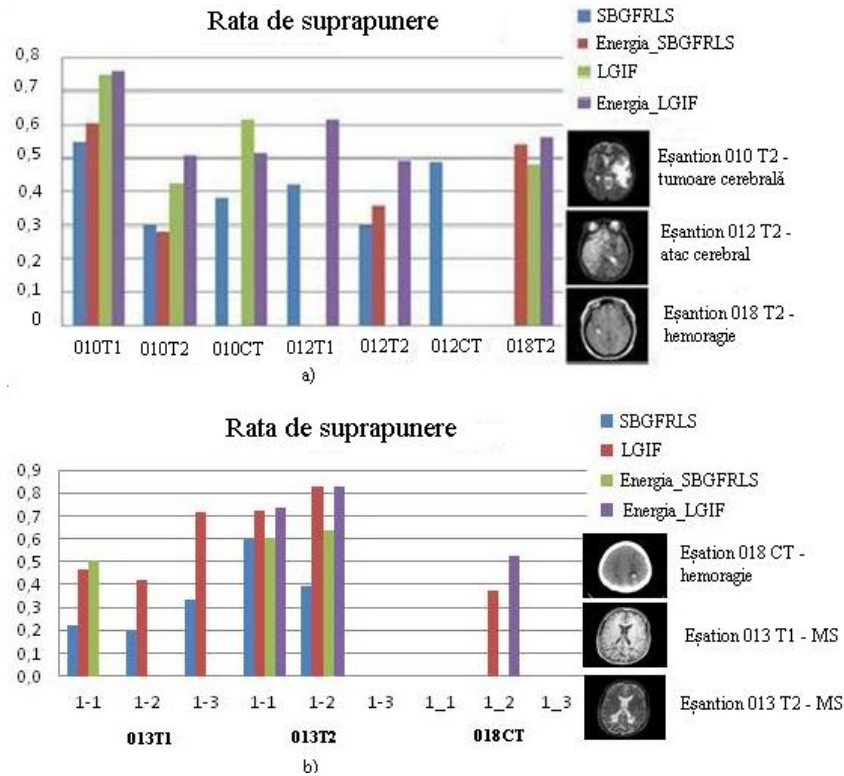
Linii: 1 – tumoare cerebrală T1w (eșantion 010T1); 2 - tumoare cerebrală T2w (eșantion 010T2); 3 - tumoare cerebrală CT (eșantion 010CT; eșantionul din coloana 5 nu este segmentat); 4 - scleroză multiplă în plăci T1w (eșantionul 013T1; eșantionul din coloana 6 nu este segmentat); 5 - scleroză multiplă în plăci T2w (eșantionul 013T2); 6 - hemoragie T2w (eșantionul 018T2; eșantionul din coloanele 3 and 5 nu sunt segmentate)

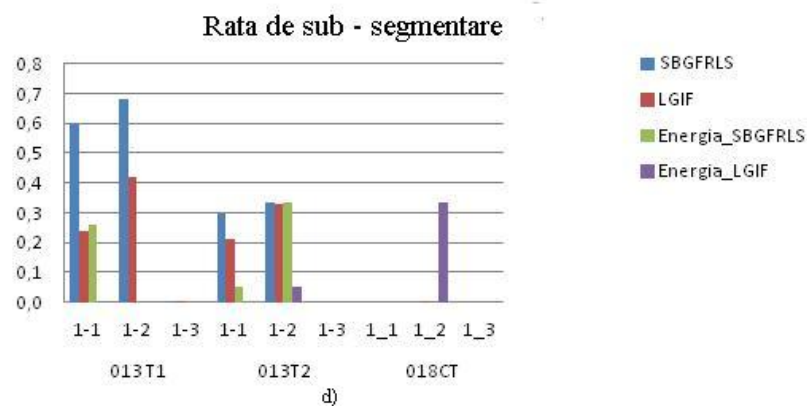
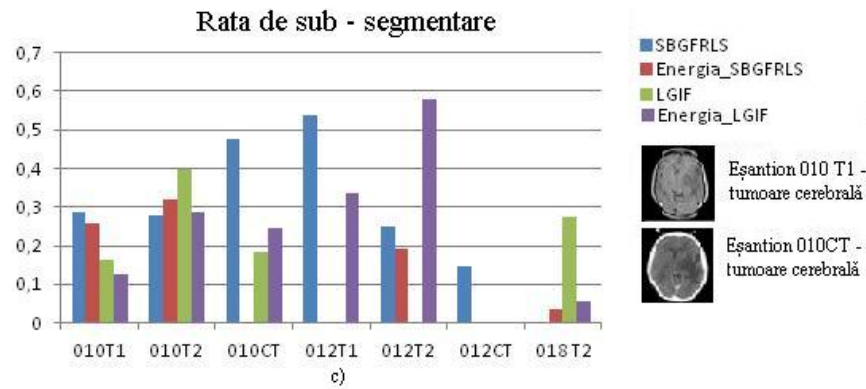
Coloane: 1 – imaginea originală; 2 – segmentare manuală; 3 – SBFRLS; 4 – LGIF; 5 – SBFRLS cuplată cu imaginea de caracteristici energia; 6 – LGIF cuplată imaginea de caracteristici energia.

Imaginile au fost descărcate gratuit din baza de date 'The whole brain atlas'.
(<http://www.med.harvard.edu/AANLIB/home.html>) [51].

În Figura 3.5. este prezentată analiza cantitativă a rezultatelor segmentării prin metodele propuse, pentru eșantioanele reprezentative de leziuni cerebrale MR. Se face o comparație între delimitarea granițelor manuală respectiv automată. S-au determinat valorile ratei de suprapunere, a ratei de sub-segmentare și a ratei de supra-segmentare. Rata de suprapunere (sau coeficientul Jaccard) cuantifică raportul dintre intersecția ariilor leziunii segmentate prin metoda propusă și prin segmentarea manuală și dintre reuniunea acestor arii. Valorile mari ale acestei metrici indică o bună eficacitate a metodei de segmentare propusă. Rata de sub-segmentare cuantifică raportul dintre aria nesegmentată

a leziunii și valoarea segmentării manuale. Acest coeficient trebuie să aibă valori mici pentru o segmentare performantă. Rata de supra-segmentare reprezintă raportul dintre aria segmentată care nu aparține leziunii și aria leziunii segmentate prin metoda propusă. Din nou, și acest coeficient trebuie să aibă valori mici pentru o segmentare performantă.









Figura 3.5. Rezultatele algoritmilor de segmentare pentru zonele cu leziuni cerebrale reprezentative. a) Rata de suprapunere; b) Rata de suprapunere; c) Rata de sub – segmentare; d) Rata de sub – segmentare; e) Rata de supra – segmentare; f) Rata de supra – segmentare [51]

În tabelele 3.2. – 3.4. sunt prezentate mediile rezultatelor segmentării a 320 leziuni ale creierului, pentru ambii algoritmi de segmentare analizați și propuși.

Tabelul 3.2. Valorile mediei și deviației standard a Ratei de suprapunere conform metodei propuse (SBGFRLS și LGIF cuplat cu imaginea de caracteristici energie) și segmentarea bazată pe nivele stabilite (SBGFRLS și LGIF)[51]

Eșantioane	SBGFRLS	LGIF	SBGFRLS cuplat cu imaginea de caracteristici energie	LGIF cuplat cu imaginea de caracteristici energie
010T1	0.522±0.109	0.770±0.058	0.583±0.045	0.791±0.022
010T2	0.319±0.024	0.448±0.071	0.333±0.073	0.548±0.064
010CT	0.402±0.088	0.626±0.102	NS	0.533±0.038
012T1	0.423±0.115	NS	NS	0.646±0.120
012T2	0.320±0.178	NS	0.332±0.110	0.506±0.099

012CT	0.470±0.227	NS	NS	NS
013T1	0.219±0.062	0.585±0.130	0.537±0.124	NS
013T2	0.330±0.103	0.517±0.368	0.619±0.016	0.781±0.047
018T2	NS	0.426±0.068	0.472±0.088	0.524±0.078
018CT	NS	0.370±0.117	NS	0.523±0.173

*NS = imagini nesegmentate

Tabelul 3.3. Valorile mediei și deviației standard a Ratei de sub-segmentare conform metodei propuse (SBGFRLS și LGIF cuplat cu imaginea de caracteristici energia) și segmentarea bazată pe nivele stabilite (SBGFRLS și LGIF) [51]

Eșantioane	SBGFRLS	LGIF	SBGFRLS cuplat cu imaginea de caracteristici energie	LGIF cuplat cu imaginea de caracteristici energie
010T1	0.306±0.065	0.155±0.045	0.268±0.043	0.107±0.014
010T2	0.260±0.070	0.368±0.062	0.328±0.034	0.255±0.042
010CT	0.477±0.110	0.185±0.042	NS	0.247±0.027
012T1	0.502±0.086	NS	NS	0.297±0.052
012T2	0.289±0.081	NS	0.204±0.056	0.541±0.121
012CT	0.188±0.094	NS	NS	NS
013T1	0.589±0.022	0.329±0.039	0.260±0.076	NS
013T2	0.314±0.078	0.268±0.098	0.193±0.060	0.054±0.020
018T2	NS	0.255±0.046	0.036±0.009	0.055±0.010
018CT	NS	NS	NS	0.332±0.066

*NS = imagini nesegmentate

Tabelul 3.4. Valorile mediei și deviației a Ratei de supra-segmentare conform metodei propuse (SBGFRLS și LGIF cuplat cu imaginea de caracteristici energia) și segmentarea bazată pe nivele stabilite (SBGFRLS și LGIF) [51]

Eșantioane	SBGFRLS	LGIF	SBGFRLS cuplat cu imaginea de caracteristici energie	LGIF cuplat cu imaginea de caracteristici energie
010T1	0.364±0.083	0.352±0.056	0.493±0.094	0.263±0.033
010T2	0.672±0.098	0.509±0.075	0.715±0.116	0.489±0.081
010CT	0.456±0.058	0.143±0.031	NS	0.415±0.045
012T1	0.325±0.062	NS	NS	0.307±0.065
012T2	0.648±0.105	NS	0.606±0.110	0.201±0.028
012CT	0.623±0.122	NS	NS	NS
013T1	0.447±0.072	0.313±0.056	0.055±0.020	NS

013T2	0.440±0.084	0.243±0.040	0.240±0.044	0.121±0.026
018T2	NS	0.206±0.019	0.335±0.046	0.251±0.081
018CT	NS	0.523±0.053	NS	0.217±0.031

*NS = imagini nesegmentate

În urma unei analize vizuale atente și a valorilor metricilor de performanță s-au desprins următoarele concluzii:

- Pentru eșantioanele 013T1 and 013T2 care prezintă scleroza în plăci multiple, segmentarea automată a delimitat o zonă mai mare comparativ cu cea delimitată manual de către medic.

- La eșantioanele 012T1, 012T2 și 012CT care prezintă atac cerebral, datorită limitelor neclare a leziunilor specifice, există dificultăți la ambele tehnici (manuală și automată) de delimitare a zonei leziunii.

- Calitatea imaginilor în CT este afectată de artefacte, contrast redus, rezoluție spațială și zgomot mare. În general, eficiența sau viabilitatea practică a metodei de segmentare a imaginilor CT este foarte scăzută.

Rezultatele experimentale raportate în această secțiune au fost publicate în revista Biomedical Engineering, ca articol de tip ISI [51].

3.3. Metoda caracteristicii binare locale LBP pentru diferențierea imaginilor digitale folosind conținutul informațional

În această secțiune sunt prezentate rezultatele obținute prin utilizarea algoritmului de extracție a caracteristicii binare locale LBP, pentru a selecta informațiile utile din imagini RMN cerebrale exemplificând boli degenerative. În acest moment, există baze de date mari și foarte bine documentate pentru boala Alzheimer (ca cea oferită de The Alzheimer's Disease Neuroimaging Initiative ADNI or by National Institute of Aging), dar bolile Huntington și Pick sunt mai puțin reprezentate în bazele de date de imagini RMN.

Este bine cunoscut faptul că în imaginile digitale, regiuni diferite ale creierului sunt caracterizate prin texturi diferite. Prin această metodă s-au căutat diferențe structurale mari în cortexul cerebral în cazul diferitelor patologii. Au fost calculate diferite histograme și, ulterior, informația oferită de acestea a fost analizată. Aceste histograme sunt un descriptor bun pentru compararea modificărilor din imagini. De asemenea, am folosit o histogramă semi-globală pentru a evidenția distribuția spațială a pixelilor imaginilor specifice bolilor analizate vs. cea specifică creierului normal cognitiv (NC).

În Figura 3.6. este prezentată o comparație a histogramelor specifice imaginilor ce descriu bolile analizate (Alzheimer AD, Huntington HD și Pick PD) și a imaginilor specifice creierului normal cognitiv (NC). Analiza s-a realizat pe perechi de imagini dintr-o secvență 2D+timp (un pachet de imagini achiziționate într-o singură etapă), aparținând unui anumit tip de patologie. Imaginile sunt aliniată, centrate și au aceeași dimensiune. Perechile de imagini reprezintă secțiuni similare ca localizare spațială în geometria creierului, deci analiza comparativă urmărește formațiuni fiziologice similare (afectate patologic sau normal cognitive).

Ulterior, sunt calculate histogramele celor 2^P etichete furnizate de algoritmul LBP și ale componentelor RI-LBP și apoi, sunt utilizate ca descriptori texturali și pentru comparație

(Figurile 3.7 și 3.8). Valorile medii ale scorului de similaritate, deviația standard și statisticile asociate cu comparația histogramelor sunt prezentate în tabelele 3.5 - 3.8.

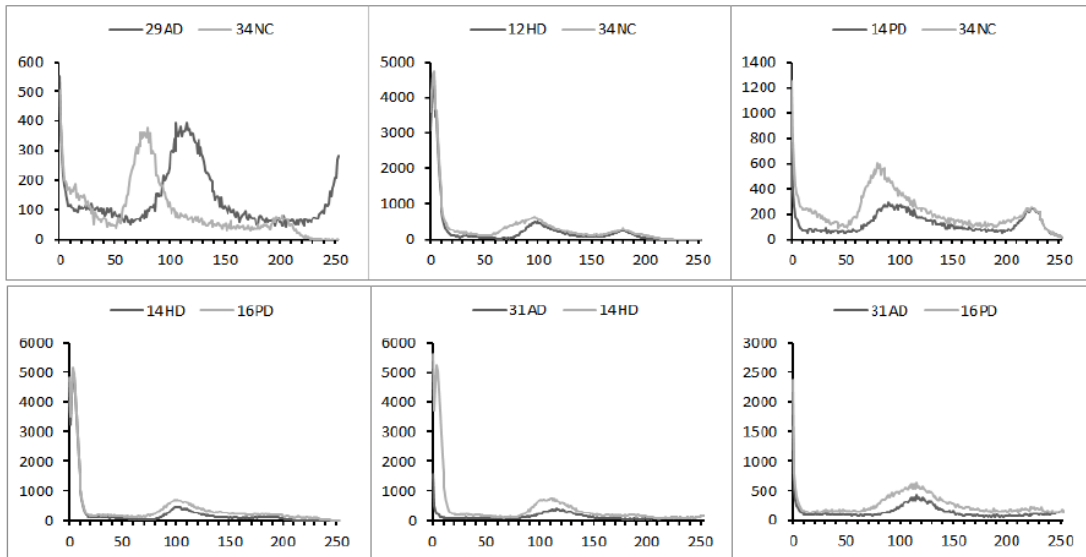


Figura 3.6. Exemple de comparații între histogramele spațiale folosite în descrierea texturii pentru bolile analizate Alzheimer (AD), Huntington (HD) și Pick (PD) și creierului normal cognitiv (NC) [52].




Figura 3.7. Exemple de comparații de histograme RI-LBP folosite în descrierea texturii pentru bolile analizate Alzheimer (AD), Huntington (HD) și Pick (PD) și creierului normal cognitiv (NC) [52]




Figura 3.8. Exemplu de imagini de intrare și de caracteristici de sub-selecție folosind algoritmul LBP. Comparații ale histogramelor RI-LBP pentru intervalele de pixeli 1-35. a) NC; b) AD; c) HD; d) PD. [52]

Pentru corectitudinea analizei, inițial s-a efectuat un studiu referitor la valorile aberante înglobate în imaginile analizate. Doar în cazul HD, au fost găsite și eliminate unele valori aberante. Acestea afectau valorile minime din matricea histogramelor. După eliminarea acestora, s-a efectuat analiza statistică de similaritate între perechile de histogramă luate în studiu. Am notat cu D1 - distanța euclidiană, cu D2 - distanța euclidiană pătratică, cu D3 - distanța Manhattan ca funcții de similaritate metrice. D4 reprezintă vectorul cosinus.

$$\begin{aligned}
 D1(h_{dis}, h_{NC}) &= \sqrt{\sum_i (h_{dis}(i) - h_{NC}(i))^2} \\
 D2(h_{dis}, h_{NC}) &= \sum_i (h_{dis}(i) - h_{NC}(i))^2 \\
 D3(h_{dis}, h_{NC}) &= \sum_i |h_{dis}(i) - h_{NC}(i)| \\
 D4(h_{dis}, h_{NC}) &= \sum_i h_{dis}(i) h_{NC}(i) / \sqrt{\sum_i h_{dis}^2(i)} \cdot \sqrt{\sum_i h_{NC}^2(i)}
 \end{aligned} \tag{3.1}$$

unde h_{dis} sunt histogramele (caracteristicile) imaginilor cu boli de demență și h_{NC} sunt histogramele (caracteristicile) imaginilor creierului normal cognitiv.

Conform datelor prezentate în tabelele 3.5 - 3.7, se ajunge la concluzia că toate bolile de demență au coeficienții de similaritate D1, D3 și D4 diferiți de zero. Coeficientul de similaritate D2 nu funcționează bine și a fost eliminat din analiza noastră. Valorile distanței Manhattan D3 caracterizează cea mai mare diferență între perechile de histogramă analizate. Analiza de regresie liniară, pentru diferite perechi de probe analizate, a condus la variații ale coeficienților de corelație între 0.72 - 0.99. Coeficientul de determinare variază

între valorile 0,53 și 0,97. Dezavantajul coeficienților de corelație este că aceștia iau în considerare doar dependențele liniare între o anumită caracteristică și eticheta de clasă. Gradul de concordanță între cele două măsuri rezultă din coeficientul de intercorelație (Tabelul 3.8).

Tabelul 3.5. Semnificația statistică a corelației histogramei privind scorul similaritate între AD vs NC [52]

Scorul de similaritate	Media		Deviația standard		Coeficientul de corelație		Coeficientul de determinare	
	Spațial	RI-LBP	Spațial	RI-LBP	Spațial	RI-LBP	Spațial	RI-LBP rar
D1	0.913	0.1717	0.01155	0.00406	-0.82443	-0.83707	0.6797	0.7007
D2	0.0373	0.0288	0.00041	0.00230	-0.75511	-0.9741	0.5702	0.9490
D3	0.5810	0.3239	0.04385	0.01327	-0.84196	-0.7944	0.7089	0.6311
D4	0.3328	0.3136	0.02185	0.03591	-0.99874	-0.9889	0.9775	0.9780

Tabelul 3.6. Semnificația statistică a corelației histogramei spațiale privind scorul de similaritate HD vs NC [52]

Rata de similaritate	Media		Deviația standard		Coeficientul de corelație		Coeficientul de determinare	
	Spațial	RI-LBP rar	Spațial	RI-LBP rar	Spațial	RI-LBP rar	Spațial	RI-LBP rar
D1	0.59778	0.55328	0.02010	0.02113	+0.96881	+0.97908	0.9386	0.9586
D2	0.0111	0.30657	0.00091	0.02355	-0.9017	+0.97780	0.8132	0.9561
D3	1.3439	1.0632	0.02581	0.03975	+0.78421	+0.72930	0.6150	0.5320
D4	0.4466	0.4102	0.01138	0.02015	-0.97785	-0.97969	0.9562	0.9598

Tabelul 3.7. Semnificația statistică a corelației histogramei spațiale privind scorul de similaritate PD vs. NC [52]

Rata de similaritate	Media		Deviația standard		Coeficientul de corelație		Coeficientul de determinare	
	Spațial	RI-LBP	Spațial	RI-LBP	Spațial	RI-LBP	Spațial	RI-LBP
D1	0.19801	0.16748	0.02296	0.02166	-0.97534	-0.96788	0.9513	0.9368
D2	0.0131	0.05980	0.00075	0.00996	-0.93316	-0.98203	0.8708	0.9644
D3	0.39896	0.28086	0.05123	0.03877	-0.87435	-0.97923	0.7645	0.9589
D4	0.2500	0.2663	0.00853	0.01871	-0.97867	-0.98376	0.9578	0.9678

Tabelul 3.8. Valorile medii ale coeficientului de intercorelație pentru cazurile analizate [52]

	Histograma	Histograma RI-LBP
NC vs. AD	0.9962	0.9895
NC vs. HD*	0.3051	0.5662
NC vs. PD	0.9992	0.9952
AD vs. PD	0.9964	0.9968
AD vs. HD*	0.3767	0.6944
HD vs. PD*	0.3536	0.6419

* Cazurile în care ipoteza de nul este respinsă

Ipoteza de nul a testului de comparare folosită asumă că imaginile aparținând pacienților cu bolile degenerative AD, NC, PD diferă de imaginile aparținând pacienților vârstnici sănătoși (NC). Datele pentru NC vs. AD, NC vs. PD și AD vs. PD indică faptul că diferențierea este semnificativă, în cazul impus al unui nivel de încredere de 95%. Pentru cazurile NC vs. HD, AD vs. HD și HD vs PD, la orice nivel de încredere rezonabil, ipoteza de nul este respinsă. Există dovezi suficiente pentru a indica imposibilitatea de a distinge între boala Huntington (HD) și restul probelor analizate. HD nu prezintă rezultate semnificative și ipoteza de nul a fost respinsă, chiar dacă rezultatele au fost îmbunătățite în cazul RI-LBP.

O analiză statistică simplă (corelație și intercorelarea) pare a fi suficientă pentru aceste analize RMN comparative.

Rezultatele experimentale raportate în această secțiune au fost propuse spre publicare în revista Maejo International Journal of Science and Technology, în luna februarie 2015, ca articol de tip ISI [52].

3.4. Analiza calitativă a similarității structurale a imaginilor digitale

În această secțiune raportăm rezultatele obținute în urma analizei privind schimbările structurale legate de variația luminozității și a contrastului, corelate cu eliminarea zgomotului printr-o metrică alternativă bazată pe modificări structurale în scopul de a obține cea mai bună calitate a imaginii RMN cerebrale.

S-a explorat metrica de similaritate structurală (SSIM), care măsoară similaritatea structurală a unei imagini prelucrate față de o imagine de referință. Metrica SSIM furnizează informații cu privire la gradul de potrivire între structura imaginilor originale și a noilor imagini, generate prin variația diferiților parametri (noi am folosit variația contrastului și a luminozității) și face parte din indicatorii obiectivi care permit evaluarea calității informației conținute într-o imagine digitală. Scopul final este evaluarea fidelității structurale a unei imagini prelucrate.

În cadrul experimentului, a simulat distorsiuni ale imaginilor reale, care se pot întâlni în practică. Astfel, lumananța fost variată de la 10% la 100% (cu pas de 10), în timp ce contrastul a fost variat, cu un pas de 0,1.

În Figura 3.9, sunt prezentate modificările de lumananță și de contrast asupra unui set de imagini RMN cerebrale care conține mai multe tipuri de boli. Variația indicelui SSIM este prezentată în figura 3.10. Figura 3.11 prezintă rezultatele imaginilor filtrate folosind filtrul de difuzie anizotropică (AD) pentru diferiți parametri (numai pentru afecțiunea de accident vascular cerebral fatal). Filtrarea AD este complet automatizată, însă ecuația de difuzie anizotropică care stă la baza algoritmului de filtrare este discretizată, dar nu într-un mod coerent. Pentru a îmbunătăți rezultatelor filtrării au fost utilizate diferite metode derivate care folosesc aproximații ale funcției de conductivitate. Astfel, au fost folosite variante ale acestei funcții cum ar fi: funcția Perona-Malik, funcția Tukey și estimarea deviației standard a zgomotului. Din setul de imagini este decupată și mărită o regiune a imaginii (Figura 3.12). Se observă în mod clar că în figurile 3.12.(c) și 3.12.(f) se obține o calitate vizuală mai bună decât în figurile 3.12.(b) și 3.12.(g). În figurile 3.12.(b) și 3.12.(g)

marginile sunt menținute, dar neclare. În mod similar, în figura 3.13, variația indicelui SSIM descrie calitatea filtrării AD.

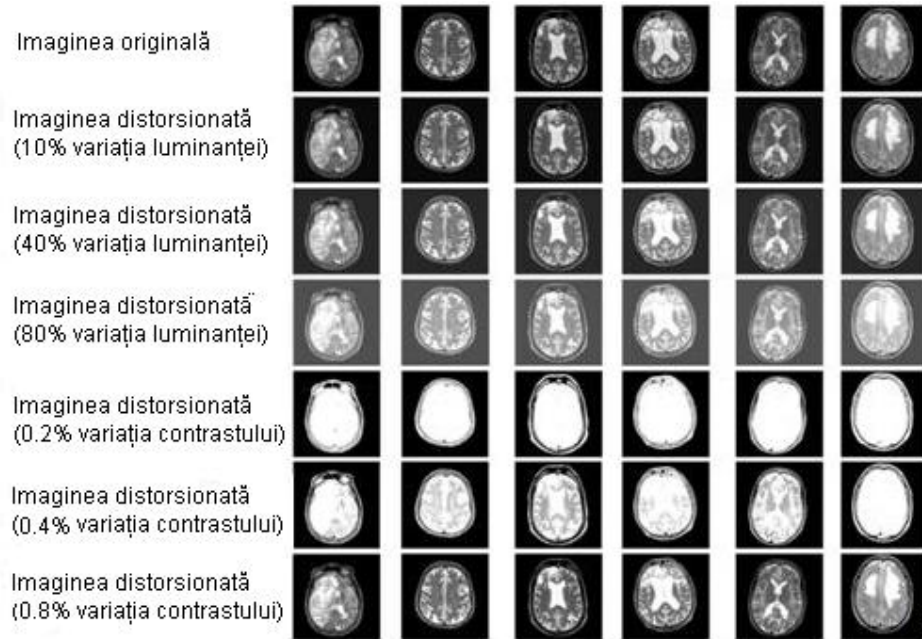


Figura 3.9. Imagini afectate de diferite distorsiuni structurale [53]

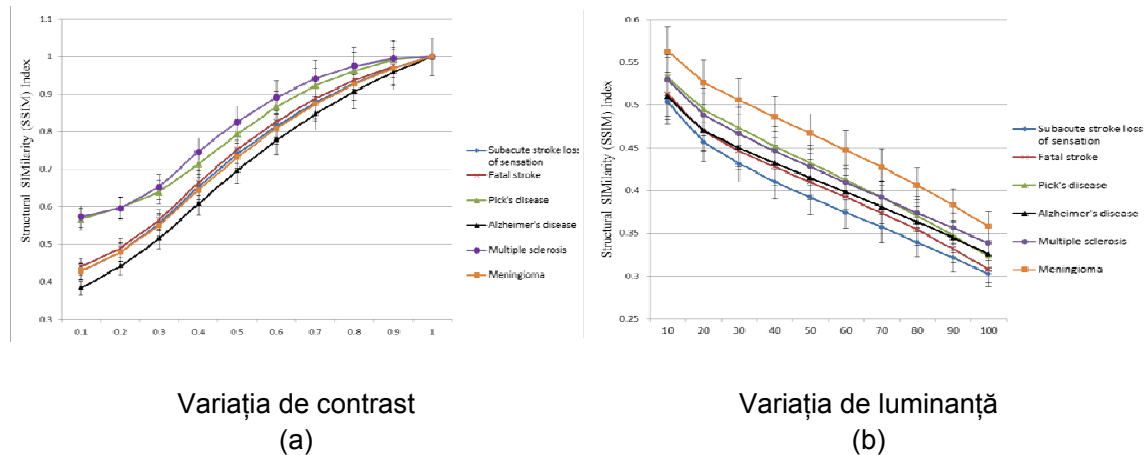


Figura 3.10. Variația indicelui SSIM în funcție de: (a) Variația Contrast; (b) Variația luminozității. Fiecare punct eșantion reprezintă valoarea medie și intervalul de încredere a imaginii testate. [18]




Figura 3.11. (a) Filtrare AD complet automatizată. (b) Funcția Malik Perona (PM); (c) Funcția Tukey; (d) după 10 de iterații; (e) după 30 de iterații; (f) deviația standard a zgomotului imaginii de intrare este cunoscută *a-priori* ($\sigma = 0.002$); (g) deviația standard a zgomotului este estimată automat. [53]




Figura 3.12. Comparația vizuală a calității filtrării AD pentru diferiți parametri utilizați în cazul unei imagini din Figura 7 (a). (a) regiunea luată în considerare are dimensiunea 75×75 pixeli. (b) funcția Perona-Malik (PM); (c) funcția Tukey; (d) după 10 de iterații; (e) după 30 de iterații; (f) deviația standard a zgomotului de imagine de intrare este cunoscută *a-priori* ($\sigma = 0.002$); (g) deviația standard a zgomotului este estimată în mod automat. [53]

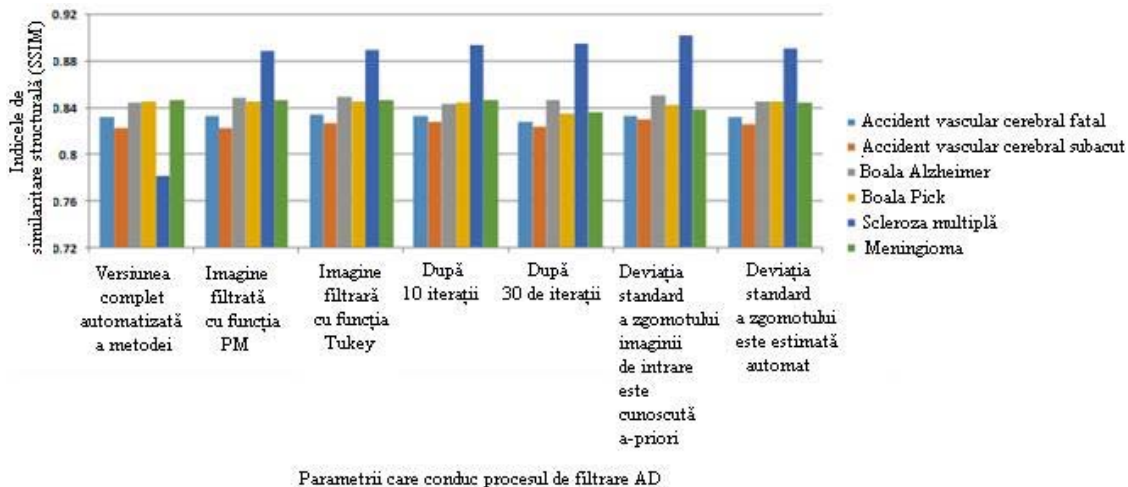


Figura 3.13. Variația indicelui SSIM măsurat între imaginea originală și versiunea filtrată cu ajutorul filtrului AD [53].

De obicei, imaginile medicale digitale sunt afectate în ceea ce privește calitatea lor prin diferite procedee la care sunt supuse, începând chiar cu înregistrarea lor.

Atât luminanța medie cât și contrastul local sunt caracteristici fundamentale ale sistemului vizual uman și variațiile lor afectează performanța vizuală. Micile detalii în imagini medicale ar putea fi mascate și pierdute în timpul evaluării medicale și de diagnostic deoarece performanța vizual uman este împiedicată de diferite distorsiuni nestructurale.

Figura 3.9. ilustrează efectele distorsiunilor structurale (de la un grad minim de distorsiune până la o distorsiune majoră) asupra calității imaginii evaluată în mod subiectiv,

prin analiză vizuală. Se observă că modificările proprietăților structurale ale imaginilor corelează bine cu sistemul vizual uman și indicele SSIM reflectă acest fapt. Astfel, valorile SSIM scad treptat o dată cu reducerea calității vizuale a imaginilor (și anume, pentru un contrast mai mic și variații de luminozitate mai mari așa cum arată Figura 3.9).

Un rezultat important al acestui studiu este faptul că variația de contrast este percepută ca având un impact mai mare asupra calității imaginii în cazul modificărilor mai mici ale contrastului (prin variația mai mare a valorilor SSIM deși, în valoare absolută, acest indice are valori mici ceea ce indică o disimilaritate mare între imaginile analizate). Dimpotrivă, variația luminanței are o influență mai redusă asupra calității imaginii, la valori mici ale acesteia. În acest caz, SSIM are valori mai mari (indicând o similaritate mai mare a imaginilor analizate), dar plaja de variație a indicelui este mai redusă.

De asemenea, am studiat performanța filtrului de difuzie anizotropică. Filtrul AD este dedicat prelucrării imaginilor medicale [54-56]. Imaginile filtrate cu AD care au fost cele mai dificil de îmbunătățit au fost cele care aparțin unui accident vascular cerebral, deoarece acestea prezintă o gamă mai mare de detalii și texturi, iar în imagine lipsesc muchiile bine determinate. Deoarece calitatea muchiilor este direct asociată cu măsurile de calitate asupra imaginii, degradarea sau chiar absența muchiilor conduce la diminuarea performanței filtrării și acest lucru este descris prin valori mici ale indicelui SSIM. În cazurile în care variația zgomotului a fost considerată *a-priori* cunoscută ($\sigma = 0.002$), filtrarea oferă imagini cu SSIM cât mai aproape de valoarea optimă. În cazul imaginilor cu scleroză multiplă am observat o degradare a imaginilor filtrate, când a fost utilizat versiunea automatizată al metodei. Principalul avantaj al filtrului AD constă în capacitatea sa de a închide liniile întrerupte în textura imaginii. Dezavantajul acestui filtru se referă la necesitatea specificării unor parametri de ajustare a procesului.

Rezultatele experimentale raportate în această secțiune au fost publicate în AIP Conference Proceedings, ca articol de tip ISI Proceedings [53].

3.5. Caracteristicile texturale momente statistice și geometrice folosite la optimizarea detecției obiectelor

Studiul a cuprins 52 de pacienți. 28 pacienți au fost diagnosticați cu chisturi mamare și 24 cu noduli de sân solide. Un chist este un săculeț închis care conține fluide, gaze sau substanțe semisolide iar un nodul solid este o masă de țesut care devine vizibil la ultrasunete. Aproape 90% din chisturile din organismul uman sunt benigne, dar șansele ca un nodul să aiba natură canceroasă sunt mai mari. În acest studiu, întrucât obiectele noastre biologice suspecte nu sunt confirmate prin biopsie ca fiind tumori, ne referim la ele ca la "noduli solizi".

Figura 3.14. prezintă anumite exemple ale imaginilor achiziționate. Acestea au fost achiziționate cu ajutorul unui dispozitiv medical ecografic SLE 401 și a unei sonde liniare cu o frecvență de 6,5 - 9 MHz. Acestea sunt imagini bitmap ale căror dimensiuni sunt 524 × 512 pixeli și 8 biți / pixel. Imaginile au fost de prelucrare utilizând software-ul Matlab ver. 2009a și un procesor Intel Core I3 CPU procesor, 4 - GB RAM ca platformă hardware. Analiza statistică a fost realizată folosind software ver. SPSS. 17.





Figura 3.14. Imagini de sân tipice cu ultrasunete; a) chist; b) nodul solid [57]



(a)

(b)

Figura 3.15. Contururi detectate de ACM; a) chist; b) nodul solid [57]



Figura 3.16. Zona de interes ROI decupată folosind analiza momentelor statistice:
a) chist; b) nodul solid [57]

Segmentarea imaginilor s-a realizat pe leziunea suspectată. Figura 3.15 prezintă rezultatele segmentării. Pentru a detecta cu precizie zona de interes ROI, s-au folosit valorile optime $\alpha = 0.4$ și $\beta = 0.2$, precum și numărul de iterații a algoritmului fost $n=50$.

Momentele statistice au fost calculate pentru fiecare probă decupată așa cum arată Fig. 3.16. Valorile lor statistice sunt stocate în Tabelul 3.9. Potrivit criteriului P-valoare, toate momentele statistice propuse sunt semnificative.

După au fost detectate și decupate limitele, următorul pas logic este de a transforma probele din imaginile binare (Fig. 3.17). Mai mult, au fost calculate caracteristicile statistice ale momentelor geometrice.

Testul T a fost realizat ca o modalitate directă de a reduce dimensionalitatea setului de date. Acesta a permis estimarea semnificației statistice a caracteristicilor și a efectuat o filtrare de caracteristici non-informative. De asemenea, notăm că în, afară de valoarea P , valorile statistice ca: media, deviația standard și eroarea medie standard au fost de asemenea calculate (tabelul 3.10).

Tabelul 3.9. Rezultatele testului T corespunzător momentelor statistice ale zonelor de interes ROI detectate

	Clase studiate	95% interval de încredere a diferenței			
		Media	Deviația standard	Eroarea medie standard	Valoarea P
μ_1	Noduli	192.07	27.22	7.97	0.004
	Chisturi	177.42	42.68	13.03	
μ_2	Noduli	97.77	16.78	4.65	<0.002
	Chisturi	112.54	15.22	5.1	
μ_3	Noduli	250.94	28.53	7.99	<0.001
	Chisturi	232.58	43.68	13.32	
μ_4	Noduli	15.51	0.89	0.26	<0.002
	Chisturi	14.64	1.92	0.7	




Figura 3.17. ROI binarizat pentru analiza momentului geometric; a) chist; b) nodul solid [57]

Tabelul 3.10. Rezultatele testului T corespunzător momentelor geometrice ale zonelor de interes ROI detectate

	Clase studiate	95% interval de încredere a diferenței			
		Media	Deviația standard	Eroarea medie standard	Valoarea P
m_{00}	Noduli solizi	1.11e4	6.87e3	1.99e3	0.003
	Chisturi	1.98e4	1.77e4	5.10e3	
OR	Noduli solizi	14.37	33.25	9.58	0.163
	Chisturi	2.78	8.96	2.59	
AR	Noduli solizi	1.54	0.56	0.09	0.988
	Chisturi	0.03	5.08	1.48	
RT	Noduli solizi	1.55	0.71	0.20	<0.002

	Chisturi	90.41	37.66	11.58	
AC	Noduli solizi	1,09e4	6,48e3	1,88e3	0.002
	Chisturi	1.7e4	1.47e4	3.76e3	
PC	Solid nodule	13.51	7.42	2.18	0.141
	Chisturi	23.71	51.6	14.9	
CC	Noduli solizi	0.45	0.18	0.05	<0.001
	Chisturi	0.56	0.23	0.09	
EC	Noduli solizi	0.73	0.12	0.06	<0.002
	Chisturi	0.85	0.09	0.03	
FF	Noduli solizi	0.6	0.15	0.05	<0.001
	Chisturi	0.45	0.18	0.05	

Tabelul 3.10. arată diferențe nesemnificative între caracteristicile AR, OR și PC deci, acestea sunt excluse ca fiind nesemnificative și non-informative. Celelalte caracteristici au fost adecvate pentru clasificare.

Pentru a evalua potențialul de analiză texturală în scopul clasificării, a fost dezvoltată o metodă de selecție prin utilizarea metodei *T-score*. Metoda cuprinde următorii pași:

– A fost stabilit un vector $M = \{\mu_1, \mu_2, \mu_3, \mu_4, m_{00}, OR, AR, RT, AC, PC, CC, EC, FF\}$. Acesta este alcătuit din 13 caracteristici.

– Au fost selectate doar caracteristicile care îndeplinesc criteriile impuse de testul *t*. A fost generat un set redus de caracteristici $M' = \{\mu_1, \mu_2, \mu_3, \mu_4, m_{00}, RT, AC, CC, EC, FF\}$. Acest subset este sortat crescător în funcție de valorile lui P.

– Caracteristicile care aparțin setului M' au fost împărțite în două subseturi aleatoare: unul este etichetat ca “subset de testare”, iar al doilea ca “subset de analiză”

Metoda *t-score* a fost utilizată pentru a măsura capacitatea fiecărui moment în parte (statistic și geometric) și a fiecărei caracteristici în diferențierea între probele cu chist și cele cu nodul și invers. t_{score}^C diferențiază între probele cu chisturi și cele cu noduli și t_{score}^N diferențiază între probele nodului și probele cu chisturi. Valoarea absolută t_{score} indică capacitatea puternic discriminatorie între clase studiate. t_{score}^N și t_{score}^C sunt calculate utilizând următoarele două ecuații:

$$t_{score}^N = \frac{M_N - M_C^*}{\sqrt{\frac{(N_N - 1)\sigma_N^2 + (N_{C^*} - 1)\sigma_{C^*}^2}{N_N + N_{C^*} - 2} \left(\frac{1}{N_N} + \frac{1}{N_{C^*}} \right)}} \quad (3.2)$$

unde M_N și σ_N^2 sunt media și respectiv varianța unei anumite caracteristici, pentru probele cu noduli testate; M_C și $\sigma_{C^*}^2$ sunt media și varianța aceleiași caracteristici, pentru probele cu chisturile utilizate pentru analiză.

$$t_{score}^C = \frac{M_C - M_N^*}{\sqrt{\frac{(N_C - 1)\sigma_N^2 + (N_{N^*} - 1)\sigma_{C^*}^2}{N_C + N_{N^*} - 2} \left(\frac{1}{N_C} + \frac{1}{N_{N^*}} \right)}} \quad (3.3)$$

Într-un mod asemănător, M_C și σ_C^2 sunt media și varianța unei anumite caracteristici pentru testarea probelor cu chisturi, M_N și $\sigma_{N^*}^2$ sunt media și varianța aceleiași caracteristici pentru testarea probelor cu noduli, N_C și N_{N^*} numărul probelor cu chisturi testate și respectiv pentru probe cu noduli. Valorile calculate sunt stocate în tabelul 3.11.

Tabelul 3.11. Valorile procentuale t_{score}^N și t_{score}^C calculate pentru probele cu noduli și chisturi

	μ_1	μ_2	μ_3	μ_4	m_{00}	RT	AC	CC	EC	FF
t_{score}^N	41.6	61.3	37.19	37.14	57.6	86.3	75.1	57.8	59.21	42.5
t_{score}^C	46.39	46.9	46.5	43.55	54.9	53.3	58.35	91.18	61.43	64.9




Figura 3.18. Precizia procedurii de selecție a caracteristicilor; numărul de observații n variază de la 1 la 10. Liniile continui denotă caracteristici valabile și semnificative. Liniile punctate corespund caracteristicilor invalide potrivit rezultatelor T-score.

(a) probe de chisturi, (b) probe de noduli solizi [57]

Selecția caracteristicii a fost efectuată pentru setul M^i . Pentru a elimina toate caracteristicile redundante sau irelevante și pentru a evita supraestimarea rezultatelor

clasificării, s-a impus un prag optim de 50%. Valorile metodei T-score, mai mici de 50% presupun o distribuție anormală în probele studiate și aceste caracteristici au fost eliminate din analiza noastră.

Fiecare set de date a fost împărțit aleator în două subseturi. A fost evaluată rata de descompunere a valorilor T-score din fiecare clasă studiată.

Ratele de clasificare în funcție de numărul de caracteristici n sunt reprezentate grafic în Figura 3.18. n variază succesiv de la 1 la 10.

Așa cum arată datele stocate în tabelul 3.11, leziunile de chist mamar, caracteristica cea mai proeminentă este circularitatea **CC** ($t_{score} = 91.18$). Aceasta denotă circularitatea anatomică a chistului mamar. De obicei, masele chistice sunt de formă rotundă, în timp ce masele nodulare sunt neregulate cu o tendință spre o formă ovală. În cazul nodulului mamar solid, rectangularitatea **RT** ($t_{score} = 86.3$) este o caracteristică importantă. O valoare mare pentru RT denotă o masă mai mare a nodulului comparativ cu zona casetei mult mai mici care înconjoară obiectul biologic.

Aparent, alegerea celui mai bun set de caracteristici pentru a crește performanța clasificării este o procedură consumatoare de timp, dar este mai puțin consumatoare decât metoda propusă de Keyvanfarad ș.a. [58]. Am încercat să echilibrez problema consumatoare de timp cu capacitatea de clasificare și chiar clasificarea constrângerilor de performanță. De asemenea, am investigat modul în care sunt corelate performanța diferențierii dintre caracteristicile alese și mărimea eșantionului analizat. Am analizat 28 de probe cu chisturi mamare și 24 cu noduli solizi mamari. Variațiile mari de performanță în diferențiere sunt în principal rezultatul dimensiunii seturilor de date.

Capitolul IV

SINTEZA REZULTATELOR STUDIULUI PRIVIND EXTRAGEREA CONȚINUTULUI INFORMAȚIONAL DIN IMAGINILE DIGITALE ȘI CONCLUZII FINALE

4.1. Concluzii generale

Analiza și interpretarea imaginilor digitale presupune corelarea caracteristicilor conținute în imagini cu proprietățile țesutului, precum și modul în care aceste caracteristici identifică anumite patologii sau sunt modificate de diferite patologii. Pentru a realiza acest lucru, trebuie parcurși toți pașii care realizează sistemul de achiziție, pre-procesare, segmentare, extragerea caracteristicilor, recunoaștere, clasificare și interpretare.

În cadrul primului capitol s-a prezentat un studiu sintetic privind procesarea digitală a imaginilor care a sintetizat un ansamblu de teorii și tehnici folosind informații privind: modurile de achiziție a imaginilor RMN cu utilitate medicală, metodele de filtrare liniară și neliniară cele mai utilizate, metode diferite de îmbunătățire a contrastului imaginii, histograma imaginii digitale, metricile folosite în evaluarea calității imaginilor prelucrate prin diferite metode de filtrare, îmbunătățire sau restaurare, metoda caracteristicilor binare locale LBP care are o putere discriminativă mai mare în analiza caracteristicilor unei imagini și care se bazează pe histograma imaginii.

În capitolul III s-au prezentat diferite metode de procesare a imaginilor. În mod frecvent, imaginile ce sunt obținute prin achiziție directă de la pacient sunt degradate de zgomot sau alte artefacte ce pot apărea în timpul achiziției, prin natura tehnologiei utilizate și a poziționării pacientului. În textura imaginilor este căutată informația utilă stocată în imagini. Analiza texturală a fost realizată utilizând parametri statistici și geometrici. Cea mai importantă etapă de procesare este segmentarea. Etapa de segmentare a imaginilor se realizează în scopul identificării obiectelor de interes sau pentru găsirea acelor caracteristici locale ce permit distingerea obiectelor de fundalul imaginii sau separarea obiectelor multiple dintr-o imagine. În segmentarea imaginilor RMN s-a folosit metoda bazată pe contururi active, deoarece nu duce la suprasedimentare sau subsegmentare cuplată cu noul concept propus al imaginilor de caracteristici, a căror structură se bazează pe caracteristicile de ordinul I și de ordinul II. Pentru interpretarea imaginii și descrierea formei obiectelor dintr-o imagine s-au folosit analize statistice și geometrice bazate pe momentele imaginii. În evaluarea calității imaginilor s-a folosit cu precădere indicele de similaritate SSIM. Indicele SSIM are aplicabilitate în clasificarea imaginilor, restaurare și fuziune, eliminarea zgomotului.

În capitolul IV, dedicat detectării zonelor afectate de traumatisme cerebrale în imagini MR, am folosit și noul concept introdus al imaginilor de caracteristici. Am dezvoltat o metodă bazată pe imaginile de caracteristici de ordinul I și pe analiza acestora folosind descriptorii texturali de ordinul II, care permit identificarea zonelor hemoragice. Pentru a stabili semnificația statistică a operatorilor texturali folosiți în analiza imaginilor de caracteristici și pentru eliminarea imaginilor de caracteristici irelevante, a fost efectuat testul statistic t-test. Pentru detectarea leziunilor hemoragice în imaginile cerebrale, prin analiză

cu ajutorul descriptorilor texturali energia și omogenitatea, au fost găsite ca fiind relevante pentru scopul declarat al cercetării imaginile de caracteristici deviația standard (mască 7×7) și skewness (mască 5×5). S-a arătat că imaginile MR cerebrale pot fi segmentate folosind conceptul de 'imagini de caracteristici energie'. În cazul imaginilor RMN cerebrale normale, energia și omogenitatea nu sunt parametrii texturali relevanți. Considerăm că imaginile de caracteristici reprezintă un spațiu nou de analiză care poate avea un potențial informativ mai ridicat în accelerarea diagnosticării clinice a bolilor neurodegenerative, fiind un potențial instrument de lucru util al specialiștilor din domeniul neurologic. Pe ansamblu, rezultatele experimentului arată că metoda folosită este utilă pentru procesarea imaginilor medicale și merită cercetări aprofundate.

Pentru caracterizarea imaginilor cerebrale și evidențierea diferențelor texturale ce apar în imagini RMN cerebrale care prezintă diferite forme de demență a fost folosită metoda RI-LBP bazată pe histograme. Au fost folosite metricile distanța Manhattan, distanța euclidiană, distanța euclidiană pătratică și vectorul cosinus în analiza statistică de similaritate între perechile de histograme luate în studiu. Au fost efectuate analize RMN comparative. Pentru un nivel de încredere de 95%, datele pentru NC vs. AD, NC vs. PD și AD vs. PD indică faptul că diferențele sunt semnificative statistic și afecțiunile Alzheimer (AD) și Pick (PD) pot fi decelate prin metoda propusă de imaginile cerebrale normal sănătoase. De asemenea, bolile Alzheimer și Pick pot fi distinse una de cealaltă în mode relevant. Pentru cazurile NC vs. HD, AD vs. HD și HD vs PD, la orice nivel de încredere rezonabil, ipoteza de nul este respinsă. Există dovezi suficiente pentru a indica imposibilitatea de a distinge între boala Huntington (HD) și restul probelor analizate. HD nu prezintă rezultate semnificative și ipoteza de nul a fost respinsă, chiar dacă rezultatele au fost îmbunătățite în cazul folosirii metodei RI-LBP.

În altă etapă a studiului, bazat pe faptul că atât luminanța medie cât și contrastul local sunt caracteristici fundamentale ale sistemului vizual uman și variațiile lor afectează performanța vizuală, s-a analizat eficiența modului în care variațiile luminanței și contrastului local sunt corelate cu eliminarea zgomotului pentru a crește performanța vizuală. Metrica de similaritate SSIM furnizează informații cu privire la gradul de potrivire între structura imaginilor originale și a noilor imagini, generate prin variația contrastului și a luminozității în scopul evaluării fidelității structurale a unei imagini prelucrate. De asemenea, a fost studiată variația parametrilor ce reglementează performanța filtrului de difuzie anizotropică AD și a fost evaluată calitatea rezultatelor. Pentru a îmbunătăți rezultatele filtrării au fost utilizate metode derivate care folosesc aproximații ale funcției de conductivitate. Astfel, au fost folosite variante ale acestei funcții cum ar fi: funcția Perona-Malik, funcția Tukey și estimarea deviației standard a zgomotului. Un rezultat important al acestui studiu este faptul că variația de contrast este percepută ca având un impact mai mare asupra calității imaginii în cazul modificărilor mai mici ale contrastului (prin variația mai mare a valorilor SSIM deși, în valoare absolută, acest indice are valori mici ceea ce indică o disimilaritate mare între imaginile analizate). Dimpotrivă, variația luminanței are o influență mai redusă asupra calității imaginii, la valori mici ale acesteia. În acest caz, SSIM are valori mai mari (indicând o similaritate mai mare a imaginilor analizate), dar plaja de variație a indicelui este mai redusă.

O altă direcție importantă a studiului a corelat segmentarea imaginilor digitale cu momentele statistice și momentele geometrice pentru identificarea celui mai bun set de

caracteristici care să permită identificarea eficientă a leziunilor de chist mamar și a nodulului mamari dar și decelarea clară între aceste formațiuni. Deasemenea, am încercat prin metoda propusă să echilibrez problema consumatoare de timp a alegerii celui mai bun set de caracteristici pentru a crește performanța clasificării cu capacitatea de clasificare și chiar clasificarea constrângerilor de performanță. Apoi, am investigat modul în care sunt corelate performanța diferențierii dintre caracteristicile alese și mărimea eșantionului analizat. Prin acest studiu este consolidată ideea că nu este întotdeauna ușor de a determina *a priori* un set optim de caracteristici adecvate pentru a caracteriza chisturi mamare sau noduli.

4.2. Contribuții la realizarea temei de cercetare

Doresc să precizez că am folosit în studiul prezent imagini cu conținut medical deoarece acestea au un conținut informațional extrem de variat și bogat și constituie un mediu de cercetare extrem de generos și provocator care permite testarea diferitelor metode propuse. Deasemenea nu putem ignora importanța socială a bolilor de demență, datorită faptului că pacienții nu sunt singurele persoane afectate. Aceste boli înaintază lent, pe parcursul mai multor ani și, în progresul bolii lor, pacienții au nevoie de mai mult sprijin pentru a gestiona viața lor de zi cu zi. În acest studiu, am propus diferite metode care să permită distingere între diferite tipuri de tulburări de demență (cum ar fi bolile Alzheimer, Pick și Huntington) și cazul pacienților vârstnici sănătoși (sau normal cognitivi NC).

Din punct de vedere imagistic, îmbătrânirea este asociată cu modificări a intensității și contrastului țesuturilor. Îmbătrânirea duce la atrofierea materiei cenușii (GM) și a materiei albe (WM) și la o creștere a fluidului cefalorahidian (CSC).

Principiul imagisticii MR presupune că fiecare tip de țesut emite o intensitate specifică. În general, acest lucru nu este adevărat, deoarece există zgomotul biologic datorită faptului că țesuturile nu sunt perfect omogene (de exemplu, ele conțin structuri mici și vase de sânge). Datorită zgomotului biologic, intensitățile emise dintr-un țesut nu sunt identic distribuite în jurul unei valori medii cu specifică a țesutului. În acest context, au fost analizate proprietățile discriminatorii ale parametrilor statistici de ordinul doi și apoi, atât parametrii statistici de ordinul I cât și dimensiunea măștii ce se deplasează în interiorul zonei de interes (ROI) selectată, au fost utilizați pentru a analiza distribuția spațială a valorilor nivelelor de gri și de a stabili utilitatea caracteristicilor imaginii ce au fost propuse.

Zgomotul este introdus în mod inevitabil de instrumente și medii înconjurătoare. În prima etapă, a fost realizată eliminarea zgomotului folosind un filtru wavelet. Transformarea wavelet Daubechies permite o bună separare între semnal și zgomot datorită utilizării inerente tehnicilor multi-rezoluție prin care frecvențe diferite sunt analizate cu diferite rezoluții. Strategia de eliminare a zgomotului cuprinde două faze: în primul rând coeficienții wavelet de energie joasă sunt eliminați în mod substanțial, iar în al doilea rând coeficienții de energie înaltă sunt păstrate sau ușor modificați.

Până acum, zgomotul și neomogenitatea intensității sunt considerate unele dintre dezavantajele majore în segmentarea imaginilor cerebrale obținute prin rezonanță magnetică (MR). Am introdus o nouă abordare a imaginii de caracteristici energia pentru corecția neomogenității intensității. Imaginea de caracteristici energia reprezintă o nouă imagine obținută din imaginea originală atunci când valorile pixelilor sunt înlocuite cu

valorile locale de energie, calculate în dimensiunea 3×3 . Performanța și utilitatea imaginii de caracteristici energia au fost testate și comparate prin două variante diferite ale metodei funcției de nivel stabilit. O variantă este metoda de potrivire globală și locală a intensității și cealaltă metodă este cea de filtrare Gaussiană bazată pe funcția de nivel stabilit. Rezultatele raportate demonstrează flexibilitatea imaginii de caracteristici energie de a se adapta la cerințele metodei de segmentare bazate pe funcții de nivel stabilit și pentru a îndeplini sarcina dificilă de segmentare a leziunilor cerebrale într-un mod eficient și exact.

Fiecare imagine MR are o intensitate care reflectă starea fiziologică a țesuturilor și reflectă impactul bolilor. Aparent, tehnica de manevrare și utilizare a histogramei, care măsoară frecvența de apariție a diferitelor modele de gri în întreaga imagine, este o metodă atractivă pentru evaluarea și caracterizarea texturii unei imagini. Practic, numărul de intrări în histogramă este atât de mare, chiar și pentru vecinătăți mici, astfel încât este imposibil să se ia în considerare toate modelele posibile. Cel mai simplu mod de a depăși acest dezavantaj este prin scăderea numărului de niveluri de gri. Metoda caracteristicii binare locale Pattern Binary (LBP) reprezintă o soluție adecvată. Scopul nostru a fost de a detecta diferențele dintre modelele spațiale la pacienții care suferă de boli neurologice degenerative care provoacă demența și de a analiza diferența de textură între creierul sănătos și creierul afectat de demență, în imagini MR. Am folosit descriptorul LBP pentru extragerea texturii și compararea histogramei pentru analiză. Diferențele relative între histograme pot fi cuantificate în funcție de diferite boli patologice și pot fi folosite ca un indicator în diferențierea bolilor de demență sau în depistarea precoce a bolilor neurologice degenerative. Am dezvoltat o metodă calcul de complexitate scăzută și suficient de bună pentru a lucra la fel de eficient pentru diverse imagini MR de creier.

În prelucrarea imaginilor medicale, prezența zgomotului, rezoluția slabă, contrast redus și neomogenitatea intensității reprezintă provocări importante. Neomogenitatea intensității este principala provocare în încercarea de a analiza conținutul informațional sau de a extrage orice caracteristică relevantă sau de a segmenta o imagine în obiecte omogene. Percepția vizuală umană este puternic afectată de distorsiuni structurale și, în același timp, se compensează cu ușurință cu distorsiunile nestructurale. Am explorat metrica similaritate structurală care oferă informații despre gradul de potrivire dintre imaginea originală și noile imagini procesate cu scopul de îmbunătățire a calității lor sau de evidențiere a anumitor caracteristici. Am arătat cum parametrii difuziei anizotropice (AD) sunt implicați în operația de eliminare a zgomotului, precum și modul în care variația de luminanță și contrast pot afecta calitatea imaginilor MR de creier și mai departe, precizia și performanța algoritmilor de procesare a imaginilor medicale.

Cancerul de sân rămâne principala cauză de cazuri nou diagnosticate de cancer și a doua cauză a mortalității legate de cancer la femei. Am dezvoltat o metodă eficientă pentru a extrage caracteristicile texturale cele mai valoroase pentru diferențierea între clasele chist mamar și nodul solid în imagini ecografice de sân. Pentru a reduce costurile de calcul, metoda propusă integrează informațiile furnizate de momentele statistice și geometrice cu capacitatea discriminatorie a testelor T-test, T-scor. A fost testată o nouă tehnică de eliminare secvențială ce permite identificarea și eliminarea caracteristicilor irelevante. Am raportat cinci momente statistice și un moment geometric ca și caracteristici semnificative pentru clasificarea imaginilor. Aceste rezultate conduc la o creștere a performanței de clasificare și permite algoritmilor să funcționeze mai rapid și mai eficient.

4.3. Direcții viitoare de studiu

- Se vor studia noi modalități de procesare digitală a imaginilor cu aplicații în medicină.
- Se vor defini noi filtre de îmbunătățire a calității imaginii.
- Se va demara studiul mediului MATLAB și în special al componentelor aferente procesării digitale a imaginilor (Image Processing) în scopul dezvoltării unei structuri generale a unui sistem de prelucrare a imaginilor.
- Se va continua dezvoltarea sistemului healthcare pentru asistarea la domiciliu a pacienților cu boli neurologice și dezvoltarea de dispozitive de monitorizare la distanță a pacienților cu boala Parkinson.

- [1] S. Annadurai, R. Shanmugalakshmi, Fundamentals of digital image processing, Pearson Education, Dorling Kindersley (India) Pvt. Ltd., 2007.
- [2] M. Petrou, C. Petrou, Image Processing- The fundamentals, John Wiley & Sons Ltd., 2010.
- [3] Florin M. GRIGORAȘ, Procesarea computerizată a imaginii. Fundamente. Programe de aplicație – Iași : Editura ARTES, 2002.
- [4] L. Wang, L. He, A. Mishra, C. Li, Active contours driven by local Gaussian distribution fitting energy, Signal Processing 89, (2009), pp. 2435-2447.
- [5] D. Mumford, J. Shah, Optimal approximations by piecewise smooth functions and associated variational problems, Communications on Pure and Applied Mathematics 42 (5) (1989), pp. 577–685.
- [6] T. Chan, L. Vese, Active contours without edges, IEEE Transaction Image Processing 10 (2) (2001), pp. 266–277.
- [7] S. Osher, J. A. Sethian, Fronts propagating with curvature-dependent speed: algorithms based on Hamilton-Jacobi formulation, Journal Of Computational Physics, 79 Issue 1, 1988, pp. 12-49.
- [8] K. Zhang, L. Zhang, H. Song, W. Zhou, Active contours with selective local or global segmentation: A new formulation and level set method, Image Vision Computing 28, 2010, pp. 668-676.
- [9] T. Ojala, M. Pietikäinen, and D. Harwood, A comparative study of texture measures with classification based on featured distributions, Pattern Recognition 29, 1996, 51–59.
- [10] T. Ahonen, A. Hadid and M. Pietikainen, Face description with local binary patterns: application to face recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 28, 2006, 2037–2041.
- [11] B.A. Rosdi, C.W. Shing and S. A. Suandi, Finger vein recognition using local line binary pattern, Sensors 11, 2011, 11357–11371.
- [12] T. Tommasi and F. Orabona, Idiap on Medical Image Classification, in Image CLEF, Vol.32, eds H.Müller, P.Clough, T.Deselaers, and B.Caputo (Berlin Heidelberg: Springer), 2010, 453–465.
- [13] Y. Qian, X. Gao, M. Loomes, R. Comley, B. Barn, R. Hui and Z.Tian, Content-based retrieval of 3D medical images, in The Third International Conference on Health, Telemedicine and Social Medicine, eTELEMED2011, (Gosier, Guadeloupe, France), (2011), 7–12.
- [14] S. Moldovanu, Metode avansate de procesare și analiză a imaginilor complexe, Teză de doctorat, 2012.
- [15] M. Pungă (Vișan), R. Guarav and L.Moraru, Level set method coupled with Energy Image features for brain MR image segmentation, Biomedical Engineering, 2014; 59(3): 219 - 229.
- [16] C. Li, Active contours with local binary fitting energy, in: IMA Workshop on New Mathematics and Algorithms for 3-Dimage Analysis, 2006.
- [17] C. Li, C. Kao, J. Gore, Z. Ding, Implicit active contours driven by local binary fitting energy, in: Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE Computer Society, Washington, DC, USA, 2007, pp.1–7.
- [18] T. Brox, From pixels to regions: partial differential equations in image analysis, Ph. D. Thesis, Saarland University, Germany, 2005.

- [19] *B. Rosenhahn, T. Brox, J. Weickert*, Three-dimensional shape knowledge for joint image segmentation and pose tracking, *International Journal of Computer Vision* 73(3) (2007) 242–262.
- [20] *L. Wang, L. He, A. Mishra, C. Li*, Active contours driven by local Gaussian distribution fitting, *Signal Processing* 89 (2009) 2435–2447.
- [21] *D. A. G. Wicks, G. J. Barker, and P. S. Tofts*, Correction of intensity nonuniformity in MR images of any orientation, *Magnetic Resonance Imaging*, 1993, 11(2):183–196.
- [22] *M. Tincher, C. R. Meyer, R. Gupta, and D. M. Williams*, Polynomial modeling and reduction of rf body coil spatial inhomogeneity in MRI, *IEEE Transactions on Medical Imaging*, 1993, 12(2):361–365.
- [23] *W. Wells, E. Grimson, R. Kikinis, and F. Jolesz*, Adaptive segmentation of MRI data, *IEEE Transactions on Medical Imaging*, 1996, 15(4):429–442.
- [24] *B. Johnston, M. S. Atkins, B. Mackiewicz, and M. Anderson*, Segmentation of multiple sclerosis lesions in intensity corrected multispectral MRI, *IEEE Transactions on Medical Imaging*, April 1996, 15(2):154–169.
- [25] *J. Sled, A. Zijdenbos, and A. Evans*, A nonparametric method for automatic correction of intensity nonuniformity in MRI data, *IEEE Transactions on Medical Imaging*, 17(1):87–97, January 1998.
- [26] *B. Likar, M. Viergever, and F. Pernus*, Retrospective correction of MR intensity inhomogeneity by information minimization, *IEEE Transactions on Medical Imaging*, December 2001, 20(12):1398–1410.
- [27] *V. Leemput, K. Maes, D. Vandermeulen and P. Suetens*, Automated model-based bias field correction of MR images of the brain, *IEEE Transactions on Medical Imaging*, October 1999, 18(10):885–896.
- [28] *R. Guillemaud and J. Brady*, Estimating the bias field of MR images, *IEEE Transactions on Medical Imaging*, June 1997, 16(3):238–251.
- [29] *C. Li, C. Xu, A. Anderson and J. Gore*, MRI tissue classification and bias field estimation based on coherent local intensity clustering: A unified energy minimization framework, In *Proceedings of Information Processing in Medical Imaging (IPMI)*, Williamsburg, VA on July 5-10, 2009, vol. 5636, pp. 288 - 299.
- [30] *M. Styner, C. Brechbuhler, G. Szekely and G. Gerig*, Parametric estimate of intensity inhomogeneities applied to MRI, *IEEE Transactions on Medical Imaging*, March 2000, 19(3):153–165.
- [31] *U. Vovk, F. Pernus, and B. Likar*, A review of methods for correction of intensity inhomogeneity in MRI, *IEEE Transactions on Medical Imaging*, March 2007, 26(3):405–421.
- [32] *C. Li, C. Gatenby, L. Wang, J.C.Gore*, A Robust Parametric Method for Bias Field Estimation and Segmentation of MR Images, *IEEE Conference on Computer Vision and Pattern Recognition*, 2009, pp: 218-223.
- [33] *A. Ahmadian, A. Mostafa, MD Abolhassani, Y. Salimpour*, A texture classification method for diffused liver diseases using Gabor wavelets, *Proceedings of 27th Annual International Conference Engineering in Medicine and Biology Society IEEE-EMBS Berlin, Germany*. 2005;2:1567-1570.
- [34] *A. Kanakatte, N. Mani, B. Srinivasan, J. Gubbi*, Pulmonary tumor volume detection from positron emission tomography images, *Proceedings of International Conference Biomedical Engineering and Informatics, Sanya, 2008*; 2:213-217.
- [35] *F. Ghorbel, S. Derrode, S. Dhahbi, R. Mezhoud*, Reconstructing with Geometric Moments, *Proceedings of International Conference on Machine Intelligence, Tunisia; 2005*.

- [36] *J. Malone, S. Prabhu and P. Goddard*, The Use of Co-Occurrence Features in Medical Imaging: An Empirical Study, in *Visualization, Imaging, and Image Processing*, edited by J. J. Villanueva, Benidorm, Spain, 2005.
- [37] *S. Hentschel and F. Kruggel*, Segmentation of the Intracranial Compartment: A Registration Approach, in *Medical Imaging and Augmented Reality (Beijing)*, edited by T. Jiang, *Lecture Notes in Computer Science 3150*, Springer, Singapur, 2004, pp. 253-260.
- [38] *P. Maji, M. K. Kundu and B. Chanda*, Segmentation of Brain MR images using Fuzzy sets and modified co-occurrence matrix, in *IET International Conference on Visual Information Engineering*, Bangalore, India, 2006, pp. 327 – 332.
- [39] *R. M. Haralick and L.G. Shapiro*, *Computer and Robot Vision*, Massachusetts: Addison-Wesley Publishing Co, 1992.
- [40] *T. Ojala, M. Pietikainen and D. Harwood*, Performance evaluation of texture measures with classification based on Kullback discrimination of distributions, in *Proceedings of the 12th International Conference on Pattern Recognition - Conference A: Computer Vision Image Processing (IAPR)*, 1, (1994), 582 - 585.
- [41] *R. Nava, G. Cristóbal and B. Escalante-Ramírez*, A comprehensive study of texture analysis based on local binary patterns, In: *Optics, Photonics and Digital Technologies for Multimedia Applications II*, SPIE (2012), 8436, 84360E.
- [42] **M. (Vişan) Punga, S. Moldovanu and L. Moraru**, Structural Similarity Analysis for Brain MR Image Quality Assessment, *AIP Conference Proceedings 1634*, 137 (2014), 137 - 143.
- [43] *B. L. Schlaggar, T. T. Brown, H.L. Lugar, K. M. Visscher, F. M. Miezin and S. E. Petersen*, Functional neuroanatomical differences between adults and school-age children in processing of single words, *Science*, 296, (2002), 1476-1479.
- [44] *Y. Gao, A. Rehman, Z. Wang*, CW-SSIM Based image classification, in *IEEE International Conference on Image Processing (ICIP11)*, Brussels, Belgium, (2011), pp. 1249–1252.
- [45] *S.S. Channappayya, A.C. Bovik, C. Caramanis, R. Heath*, Design of linear equalizers optimized for the structural similarity index, *IEEE Transactions on Image Processing* 17, (2008), 857–872.
- [46] *Z. Wang, Q Li, X Shang*, Perceptual image coding based on a maximum of minimal structural similarity criterion, *IEEE International Conference on Image Processing 2*, (2007), II- 121–II-124.
- [47] *A. Rehman, Z. Wang*, SSIM-based non-local means image denoising, in *IEEE International Conference on Image Processing (ICIP11)*, Brussels, Belgium, (2011), pp. 1–4.
- [48] *G. Piella, H. Heijmans*, A new quality metric for image fusion, in *IEEE International Conference on Image Processing (ICIP)*, Vol. 3. Barcelona, Spain, (2003), pp. 173–176.
- [49] *Z. Wang, A.C. Bovik*, Mean squared error: love it or leave it? A new look at signal fidelity measures, *IEEE Signal Processing Magazine* 26, (2009), 98–117.
- [50] *L. Moraru, S. Moldovanu, D. Bibicu și M. Stratulat (Vişan)*, Hemorrhage detection in MRI brain images using images features, *TIM 2012 Physics Conference, AIP Conference Proceedings, Volume 1564, 1564, Issue 1, 2013*, p.171-177.
- [51] **M. (Vişan) Pungă, R. Gaurav, L. Moraru**, Level set method coupled with Energy Image features for brain MR image segmentation, *Biomedical Engineering / Biomedizinische Technik*, ISSN: 0013-5585, ID BMT.2013.0111, *IMPACT FACTOR 2013: 1.227*, DOI 10.1515/bmt-2013-0111, *Biomed Tech 2014, Volume: 59 Issue: 3 Pages: 219-229*.
energy, *Signal Processing* 89, (2009), pp. 2435-2447.

- [52] *L. Moraru, S. Moldovanu, M. (Vişan) Pungă, A. Biswas*, Distance metrics - based similarity search in spatial features: Application to brain MR images, *trimis la Maejo International Journal of Science and Technology*, februarie 2015.
- [53] *M. (Vişan) Pungă, S. Moldovanu and L. Moraru*, Structural similarity analysis for brain MR image quality assessment, *AIP Conference Proceedings* 1634, 137(2014).
- [54] *D.C. Fernandez, H.M. Salinas, C.A. Puliafito*, Automated detection of retinal layer structures on optical coherence tomography images, *Optics Express* 13, 10200–10216 (2005).
- [55] *R. Manniesing, M.A. Viergever, W.J. Niessen*, Vessel enhancing diffusion: a scale space representation of vessel structures, *Medical Image Analysis* 10, 815–825 (2006).
- [56] *A.S. Frangakis, R. Hegerl*, Noise reduction in electron tomographic reconstructions using non linear anisotropic diffusion, *Journal of Structural Biology* 135, 239–250 (2001).
- [57] *L. Moraru, S. Moldovanu and Mirela Pungă Vişan*, Optimization in Breast Lesions Detection via Integrated Statistical Approach, *Journal Of Scientific Research And Reports* 01/2013; 2(1)(1):460-473.
- [58] *F. Keyvanfard, MA Shoorehdeli, M. Teshnehlab*, Feature selection and classification of breast MRI lesions based on multi classifier, In: *Proceedings of International Symposium on Artificial Intelligence and Signal Processing*. Tehran, Iran. 2011;54-58.

FONDUL SOCIAL EUROPEAN

Programul Operațional Sectorial pentru Dezvoltarea Resurselor Umane 2007-2013

INVESTEȘTE ÎN OAMENI!

Titlul proiectului: „Exelență în cercetare prin burse doctorale și postdoctorale – ExcelDOC”

Axa prioritară 1: „Educația și formarea profesională în sprijinul creșterii economice și dezvoltării societății bazate pe cunoaștere”

Domeniul major de intervenție 1.5: Programe doctorale și postdoctorale în sprijinul cercetării

Numărul de identificare al contractului: POSDRU/159/1.5/S/132397

Data publicării: 2015

www.fonduri-ue.ro

www.fonduri-ue.ro www.upb.ro

Conținutul acestui material nu reprezintă în mod obligatoriu poziția oficială a Uniunii Europene sau a Guvernului României