

CONTRIBUȚII LA UTILIZAREA TEHNICILOR FUZZY ÎN ANALIZA IMAGINILOR MEDICALE

Teză destinată obținerii
titlului științific de doctor inginer
la
Universitatea "Politehnica" din Timișoara
în domeniul Calculatoare și Tehnologia Informației
de către

Ing. Norbert GAL

Conducător științific:	prof.univ.dr.ing Vasile STOICU-TIVADAR
Referenți științifici:	prof.univ.dr.ing Eugen IANCU prof.univ.dr.ing Diana LUNGEANU prof.univ.dr.ing Ștefan HOLBAN

Ziua susținerii tezei: 14 Decembrie 2012

Seriile Teze de doctorat ale UPT sunt:

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

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

Copyright © Editura Politehnica – Timișoara, 2006

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

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

Cuvânt înainte

Teza de doctorat a fost elaborată pe parcursul activității mele în cadrul Departamentului de Automatică al Universității „Politehnica” din Timișoara în perioada 2009 – 2012

Această lucrare nu s-ar fi realizat fără suportul și ajutorul conducătorului de doctorat prof. dr. ing. Vasile STOICU-TIVADAR. Un om calm, un profesionist bun și cu experiență valoroasă în domeniu care a reușit să mă motiveze și să mă ghideze prin comentariile și întrebările lui mereu pertinente. Pentru toate acestea îi mulțumesc.

Îi mulțumesc logodnicei mele dr. Emanuela Georgiana NĂDĂȘAN pentru tot suportul, încrederea și ajutorul ei. Ea a fost lângă mine pe tot parcursul activității mele din acești ani.

Mulțumesc oamenilor deosebiți de la Clinica de Recuperare, medicină fizică, balneologie și reumatologie din cadrul Spitalului Municipal de Urgență Timișoara: prof. univ. dr. Ion Dan Aurelian NEMES și prep. univ. dr. Dan SURDUCAN pentru ajutorul acordat în validarea metodelor prezentate în această lucrare.

Exprim mulțumiri doamnei conf. dr. ing. Valentina BĂLAȘ din cadrul Universității “Aurel Vlaicu ” din Arad. Ea a fost cea care a avut inițial încredere în mine și m-a ghidat către Timișoara și Universitatea “Politehnica” Timișoara.

Exprim mulțumiri domnului prof. dr. Gheorghe MIHALAȘ, prof. dr. ing. Diana LUNGEANU de la Universitatea de Medicină și Farmacie “Victor Babeș”, Timișoara, Departamentul de Informatică Medicală. Mulțumesc doamnei prof. dr. ing. Lăcrămioara STOICU-TIVADAR, prof. dr. ing. Ioan FILIP, prof. dr. ing. Ștefan HOLBAN și Ș.l. dr. ing. Dorin Berian de la Universitatea “Politehnica” Timișoara, Departamentul de Automatică și Informatică Aplicată pentru suportul și ajutorul acordat.

Aș dori să mulțumesc colegilor mei de birou , dr. ing. Mihaela VIDA, drd. Oana LUPȘE, drd. ing. Dan DRAGU și dr. ing. Valentin Sergiu GOMOI pentru discuțiile interesante și pentru colaborările avute.

În final dar nu în ultimul rând adresez mulțumiri familiei mele pentru tot ajutorul acordat.

This thesis was possible with the partial financial support of the strategic grant POSDRU/88/1.5/S/50783 (2009) of the Ministry of Labor, Family and Social Protection, Romania, co-financed by the European Social Fund – Investing in people.

Ing. Norbert GAL

**CONTRIBUȚII LA UTILIZAREA TEHNICILOR FUZZY ÎN ANALIZA
IMAGINILOR MEDICALE**

Teze de doctorat ale UPT, Seria 14, Nr. 11, Editura Politehnica, 2012,
134 pagini, 67 figuri, 10 tabele.

ISSN: 2069-8216

ISBN: 978-606-554-591-5

Cuvinte cheie: Imagini medicale, sisteme fuzzy, DICOM, algoritmi genetici

Rezumat: Teza de doctorat abordează domeniul interpretării imaginilor medicale și propune o nouă metodă de interpretare a segmentelor de imagine folosind algoritmi fuzzy. Metoda de interpretare propusă analizează datele directe (numerice) ale obiectelor dintr-o subimagine segmentată și metadate care specifică tipul imaginii medicale. Datele directe și metadatele sunt fuzzificate pentru a genera variabile lingvistice utilizate în descrierea obiectului. Folosind reguli de inferență fuzzy sunt inferate rezultate fuzzy care reprezintă denumirea unui organ, țesut, patologie sau recomandare. Pentru generarea automată a regulilor fuzzy a fost dezvoltat un algoritm genetic care utilizând un set minim de date și un set de date de antrenament este capabil să creeze reguli de inferență fuzzy. Au fost realizate unele specifice pentru a putea implementa algoritmi propuși. Utilizând metodele și unele propuse, au fost realizate studii concrete, pe seturi reale de imagini medicale, cu rezultate care validează respectivele metode.

CUPRINS

1. Introducere (imaginile medicale)	- 7 -
1.1. Tipuri de imagini medicale	- 7 -
1.2 Standardul DICOM	- 11 -
1.3 Abstractizarea imaginilor medicale	- 13 -
1.3.1 Nivelul inferior de date	- 14 -
1.3.2 Nivelul superior de date	- 15 -
1.3.3 Metadate	- 15 -
1.4 Structura tezei	- 16 -
1.5 Concluzii	- 18 -
2. Prelucrarea imaginilor medicale	- 20 -
2.1 Metode numerice în imagistica medicală	- 21 -
2.2 Metode fuzzy în imagistica medicală	- 25 -
2.2.1 Sisteme cu inferență fuzzy pentru reducerea zgomotelor	- 25 -
2.3 Sisteme cu inferență fuzzy folosite pentru segmentare	- 31 -
2.4 Postprocesarea fuzzy a imaginilor	- 34 -
2.5 Concluzii	- 36 -
3. Sisteme cu inferență fuzzy	- 41 -
3.1 Sistemul simplu cu inferență fuzzy	- 41 -
3.1.1 Sisteme cu inferență fuzzy paralele	- 43 -
3.1.2 Raționamentul fuzzy silogistic și sisteme fuzzy în cascadă	- 44 -
3.2 Reprezentarea sistemelor cu inferență fuzzy	- 46 -
3.2.1 Reprezentarea pentru <i>MatLab</i>	- 47 -
3.2.2 Reprezentarea pentru <i>FuzzyTech</i>	- 48 -
3.3 Reprezentarea sistemelor cu inferență fuzzy folosind XML	- 49 -
3.3.1 Reprezentarea sistemelor fuzzy cu fișiere DTD	- 49 -
3.3.2 Reprezentarea sistemelor fuzzy cu fișiere XSD	- 51 -
3.4 O reprezentare XML simplificată	- 51 -
3.5 Concluzii	- 56 -
4 Sistemul de interpretare al imaginilor medicale	- 58 -
4.1 Structura logică a sistemului de interpretare	- 58 -
4.2 Procesarea numerică	- 59 -

4.2.1 Segmentarea imaginilor medicale	- 60 -
4.2.2 Reprezentarea segmentelor de imagine	- 62 -
4.2.3 Extragerea datelor numerice din segment	- 64 -
4.2.4 Utilizarea metadatelor	- 65 -
4.3 Interpretarea lingvistică a segmentelor de imagine	- 66 -
4.3.1 Reprezentarea cunoștințelor medicale	- 66 -
4.3.2 Fuzzificarea variabilelor lingvistice	- 67 -
4.3.3 Regulile de inferență fuzzy	- 68 -
4.4 Concluzii	- 68 -
5 Autoperfecționarea regulilor folosind algoritmi genetici	- 71 -
5.1 Metode de generare a regulilor fuzzy folosind algoritmi genetici	- 72 -
5.2 O nouă reprezentare a regulilor fuzzy folosind cromozomi	- 74 -
5.3 Procesul de generare a regulilor de inferență	- 75 -
5.4 Concluzii	- 78 -
6. Implementarea	- 80 -
6.1 Arhitectura programului	- 80 -
6.2 Prezentarea programului	- 83 -
6.3 Editorul de inferență fuzzy	- 85 -
6.4 Generatorul de reguli cu algoritmi genetici	- 90 -
6.5 Concluzii și testarea inițială	- 93 -
7. Rezultate experimentale	- 97 -
7.1 Recunoașterea patologiilor ventriculare și a diferitelor tipuri de țesuturi	- 98 -
7.2 Detectarea osteosclerozei pe radiografii	- 104 -
7.3 Generarea regulilor de inferență fuzzy	- 115 -
7.4 Concluzii	- 121 -
8. Concluzii	- 123 -
9. Bibliografia	- 127 -

1. Introducere (imaginile medicale)

Interiorul corpului uman poate fi reprezentat prin diverse imagini medicale. Imagistica medicală, datorită impactului asupra medicinei și biologiei, este o realizare importantă a secolului 20, în domeniul medical.

Imaginile medicale sunt utilizate pentru investigarea organelor, în scopul depistării anumitor boli congenitale sau dobândite. Imaginile sunt generate de aparate speciale care utilizează diferite unde de scanare.

Tehnicile avansate de procesare și analiză a imaginilor se folosesc pe scară largă în imagistica medicală. Datele care se găsesc în imaginile medicale sunt folosite atât în domeniul medical clinic pentru diagnosticarea diverselor boli cât și în domeniul științific. Informațiile oferite de imaginile medicale au devenit indispensabile pentru îngrijirea corectă a pacientului.

Există trei etape în procesarea și analiza imaginilor medicale[Spi00]:

- Îmbunătățirea calității imaginilor și pregătirea lor pentru procesul de segmentare.
- Segmentarea imaginilor medicale: separarea obiectelor existente în imagine de fundalul imaginii.
- Analiza și interpretarea corectă a obiectelor din imagine extrase prin segmentare.

În această teză autorul propune o metodă de analiză a imaginilor medicale folosind sisteme de inferență fuzzy. Această metodă va analiza datele extrase din segmentele de imagine precum și datele extrase din domeniul metadatelor. În acest capitol se vor prezenta tipurile de imagini medicale utilizate în mod frecvent și standardul DICOM, un standard al imagisticii medicale care impune o codificare unitară a imaginilor medicale și a metadatelor.

1.1. Tipuri de imagini medicale

Prin descoperirea noilor tehnologii au apărut noi metode de generare a imaginilor medicale. Prima metodă de investigare imagistică a fost realizată folosind razele X. Pentru a elimina efectele nocive ale radiografiei s-a dezvoltat tehnologia ecografică, bazată pe ultrasunete.

Împreună cu dezvoltarea sistemelor de calcul, au apărut noi metode de generare a imaginilor medicale. Astfel a luat naștere tomograful computerizat care utilizând raze X direcționate, poate crea imagini 3D ale interiorului corpului uman. Complementar cu această tehnologie a apărut rezonanța magnetică nucleară (RMN) care reproduce cu mare exactitate toate tipurile de țesuturi din corpul uman.

Exemple din cele mai cunoscute tipuri de imagini medicale sunt prezentate în figura 1.1:

- Radiografiile sunt generate folosind un sistem de iradiere cu raze X. Acestea pot fi imagini analogice sau digitale.
- Ecografiile sunt imagini 2D, 3D sau 4D generate prin captarea unor ecouri de ultrasunete emise de un transducer. Acestea pot fi considerate ca și o alternativă a radiografiilor în cazul în care este contraindicată iradierea pacientului. De asemenea prin intermediul ecografiilor se evită iradierea inutilă.

- Imaginile create cu computerul tomograf utilizează raze X de mică energie, direcționate spre zona țintă, astfel se creează o imagine 3D axială a zonei investigate.
- Rezonanța magnetică nucleară utilizează câmpuri electromagnetice, pentru a crea o imagine 3D a pacientului pe fiecare axă. Aceasta nu supune pacientul la radiații ionizante.
- Există și alte metode de investigare imagistică dar acestea în general sunt metode invazive și necesită anestezia pacientului.




Figura 1.1 Exemple de imagini medicale obținute prin:
a) radiografie; b)ecografie; c) computer tomograf; d) rezonanță magnetică nucleară

Radiografia: [Cle90] este cea mai cunoscută și cea mai veche metodă de investigare medicală. Această tehnică se bazează pe utilizarea unor fascicule cu raze X. Aceste raze trec printr-o anumită zonă anatomică a corpului uman și sunt detectate pe partea opusă. Pe măsură ce aceste fascicule traversează corpul uman ele sunt sau absorbite sau împrăștiate. Gardul de atenuare a fasciculelor depinde de grosimea părții anatomice investigate. Ecuația care descrie scăderea de intensitate a fasciculului este următoarea:

$$I = I_c * \exp(-\mu x) \quad (1.1)$$

În ecuația (1.1) I_0 și I reprezintă intensitatea fasciculului înainte și după trecerea prin țesuturile investigate, μ reprezintă coeficientul de atenuare și x reprezintă grosimea părții investigate. Oasele au un coeficient mai mare de atenuare decât țesuturile moi, astfel fasciculele care traversează țesutul osos vor avea o intensitate mai scăzută față de fasciculele care trec prin țesuturile moi. Imaginea creată cu raze X va avea un contrast bun în delimitarea țesuturilor moi de țesuturile osoase. Oasele vor fi reprezentate de obiecte de culoare albă iar țesuturile moi de obiecte în tonuri de gri.



Figura 1.2 Radiografie clasică a articulației genunchiului.

Această metodă de investigare prezintă și dezavantaje:

- doză mare de radiație ionizantă la care este expus pacientul
- obținerea unei imagini 2D a unui obiect tridimensional
- un contrast deseori deficitar al imaginilor

Ecografia: [Ort12] este bazată pe principiul de funcționare al unui aparat radar. Un impuls de ultrasunete cu frecvența între 1–15 MHz este trimis de la transductor și este reflectat la contactul cu marginile țesutului investigat sub formă de ecouri. Măsurarea timpului de la emiterea impulsului până la detectarea ecourilor permite calcularea distanței dintre transductor și organ. Un parametru important este impedanța acustică (Z) a țesutului. Ea reprezintă produsul dintre viteza acustică și densitatea țesutului. Viteza acustică reprezintă viteza de propagare a ultrasunetelor prin țesut. Apariția ecourilor de retur poate fi reprezentată prin două modalități principale. În primul rând, amplitudinea ecoului poate fi afișată ca o deplasare verticală față de axa orizontală a timpului, aceasta are aspectul unui profil similar cu al unui lanț muntos. Acest mod de reprezentare poartă numele de mod amplitudine sau mai simplu, mod A. Cealaltă variantă de reprezentare a imaginilor ecografice este de a scoate în evidență intensitatea ecoului cu ajutorul unor puncte de luminozitate variabilă, tehnică numită mod B (brightness - luminozitate, strălucire). Timpii de detecție ai undei de scanare reflectate sunt transformați în pixeli de imagine. Imagistica 2D folosește un număr mare de linii adiacente de tip B pentru a genera imaginea finală, o scanare de tip B.




Figura 1.3 Ecografie a articulației genunchiului.

Computerul Tomograf [Dem09] este o metodă de investigare care presupune utilizarea unui fascicul îngust de raze X. Cu ajutorul fasciculului se

generează o imagine transversală în regiunea organului investigat. Principiul pe care se bazează funcționarea CT-lui este același ca și al radiografiei tradiționale: măsurarea gradului de atenuare a radiației electromagnetice. Fasciculul de raze X străbate corpul pacientului și reconstruiește imaginea obiectului investigat folosindu-se de diversele proiecții obținute ale secțiunilor transversale. CT-ul are trei avantaje majore față de radiografia clasică pe film sau cea digitală:

- O examinare CT produce un set de imagini transversale 2D în locul unei imagini unice 2D. Din setul de imagini achiziționate se poate genera un plan de imagini 3D.
- Volumul de date achiziționate se poate reconstrui în diferite planuri (sagital, axial, coronal) sau în imagini volumice 3D.
- Sensibilitatea aparatului CT la variațiile de densitate ale țesuturilor investigate este de 16 ori mai mare decât a filmului clasic.



Figura 1.4 CT al articulației genunchiului.

Într-o secvență CT 2D, imaginile sunt achiziționate la o rezoluție de 512x512 pixeli pe 16 biți. Elementul de imagine (pixelul), primește o valoare CT sau Hounsfield Unit (HU) care se definește :

$$CT_number = C * \frac{\mu_p - \mu_w}{\mu_w} \quad (1.2)$$

unde C este o constantă de integrare, standardizată la 1000, μ_p reprezintă valoarea medie a coeficientului de atenuare, iar μ_w este coeficientul de atenuare a razelor X prin apă.

Deoarece imaginile 3D au o adâncime pe axa z , pixelii de imagine sunt considerați ca și element de volum (voxel). Mărimea fizică a pixelului se poate calcula folosind formula [Dem09]:

$$PS = \frac{DFOV}{512} \quad (1.3)$$

unde valorile standard pentru *DFOV* sunt 16 în cazul în care pacientul este un copil – pediatrie, 20 la nivel cranian și 50 la nivelul corpului. Aceste valori corespund mărimilor de 0.31, 0.39 și 0.98mm.

Rezonanța magnetică nucleară: [Dem09] reprezintă imaginea unui nucleu atomic la nivel macro sub influența unui câmp magnetic puternic. Rezonanța magnetică nucleară folosește unde radio astfel se elimină utilizarea radiațiilor ionizante. Un alt avantaj major îl constituie contrastul bun între diferite țesuturi moi. Rezonanța magnetică poate genera imagini 3D volumetrice în toate planurile (axial, sagital, coronal).



Figura 1.5 RMN tip T1 al articulației genunchiului.

Secvența T1 este o secvență standard, capabilă să facă diferența dintre țesutul adipos și lichid, în care lichidul este hipo-intens (mai întunecat) iar țesutul adipos este hiper-intens (mai deschis). În secvența T1 se recurge frecvent la administrarea substanței de contrast (gadolinu) pentru a crește capacitatea de contrastare dintre diferite țesuturi. În acest caz, imaginile se achiziționează înainte și după administrarea substanței de contrast. La realizarea rezonanței magnetice cerebrale, secvența T1 permite o diferențiere excelentă între substanța albă și cea cenușie. Secvența T2 este o altă secvență de bază, la fel ca în T1, se permite diferențierea între țesutul adipos și lichid. În acest caz rezultatele vor fi inversate față de T1: țesutul adipos va fi hipo-intens iar lichidul hiper-intens.

1.2 Standardul DICOM

DICOM este acronimul pentru "Digital Imaging and COmmunications in Medicine". Acesta reprezintă un standard fundamental și universal în imagistica medicală [Pia08]. El pune la dispoziție toate uneltele necesare pentru a reprezenta cât mai corect din punct de vedere medical datele de imagistică medicală. Este un standard proiectat și creat pentru a cuprinde toate aspectele ce țin de transferul, stocarea și afișarea datelor care au legătură cu imagistica medicală. Standardul DICOM a deschis calea către imagistica medicală modernă prin furnizarea:

- unui standard universal medicinei digitale. Toate echipamentele de imagistică curentă creează imaginile în format DICOM. Procesul de imagistică medicală este controlat de multitudinea de reguli DICOM.
- unei calități excelente a imaginilor. DICOM suportă până la 65,535(16 bits) în tonuri de gri pentru imaginile monocrome, astfel se capturează și cele mai mici nuanțe. În comparație cu imaginile JPEG sau BMP care sunt limitate la 256 de tonuri de gri.
- unui suport integral pentru multitudinea de parametri de achiziție a imaginilor medicale și a diferitelor tipuri de date. Standardul DICOM nu doar stochează o imagine ci și înregistrează o multitudine de parametri: poziția 3D a pacientului, mărimea fizică a obiectului din imagine, grosimea feliei de imagine, parametri de expunere a imaginii și așa mai departe. Acești parametri îmbogățesc conținutul informațional al datelor achiziționate și stocate în baza de date.
- unei codificări complete a datelor medicale. Fișierele DICOM folosesc mai mult de 2000 de atribute standardizate pentru a transmite diferite informații medicale de la numele pacientului până la adâncimea de culoare a imaginilor. Aceste date sunt esențiale pentru un diagnostic corect și cuprind toate aspectele imagisticii medicale curente.
- unei clarități în descrierea dispozitivelor medicale și a caracteristicilor acestora. DICOM definește foarte precis caracteristicile fiecărui tip de aparat cu termeni care sunt independenți de marca și modelul aparatului.

Folosind interfața DICOM a echipamentelor medicale procesul de achiziție a datelor devine mai simplu. În acest mod scade rata erorilor.

Fișierele DICOM se mai numesc și media DICOM. Aceste fișiere conțin obiecte de date de tip DICOM sau seturi de date, cel mai frecvent imagini DICOM. Rolul antetului DICOM este de a indica programelor specializate faptul că fișierul conține date DICOM de tip SOP. Antetul DICOM include un preambul, un prefix DICM și o mică parte din atributele fișierelor DICOM. Preambulul este un string de 128 de biți care există în antetul fiecărui fișier DICOM. Preambulul se utilizează în mai multe formate de date și imagini. Standardul DICOM nu are predefinită în mod particular nici o structură pentru preambul, astfel această secțiune a fișierului devine dependentă de aplicație. Pentru a evita acest lucru în fișierele DICOM preambulul este ignorat.

Prefixul DICM care indică formatul de fișier DICOM se află după preambul. Este format simplu din cele patru caractere (D I C M) scrise pe biții 129-139. Folosirea unui prefix este comună în multe formate de fișiere iar DICOM a implementat aceeași convenție. Structura fișierului DICOM se observă în imaginea de mai jos.




Figura 1.6. Structura fișierului DICOM [Pia08].

Informațiile "Meta Information" ale fișierului DICOM, se află imediat după prefixul fișierului, la bit-ul 133. Spre deosebire de preambul și prefix informațiile meta sunt codificate ca și un set de atribute DICOM. Toate atributele din această secțiune aparțin grupului DICOM 0002. Cel mai important element din această secțiune este "Transfer Syntax UID" care definește cum au fost codificate obiectele de date DICOM.

Fiecărui fișier DICOM îi este asociat un identificator unic, un DICOM File IDs, practic numele fișierului. Identificatorii de fișiere au până la 8 componente. În termeni tradiționali, ultima componentă corespunde numelui scurtat al fișierului iar componenta precedentă corespunde folderului în care se află fișierul.

DICOMDIR este un fișier mai special, acesta conține informații despre fișierele aflate în directoriu, iar restul fișierelor conțin date proprii. Se poate considera că are rolul unei mici baze de date locale. DICOMDIR organizează datele din director în patru nivele principale: pacient, studiu, serii și imagini.

Pentru fiecare intrare în secvența din DICOMDIR (0004,1220) se stochează două tipuri de date:

- Chei de selecție, pentru a facilita căutările obiectelor din DICOMDIR
- Informații de bază de tip "DirectoryObject"

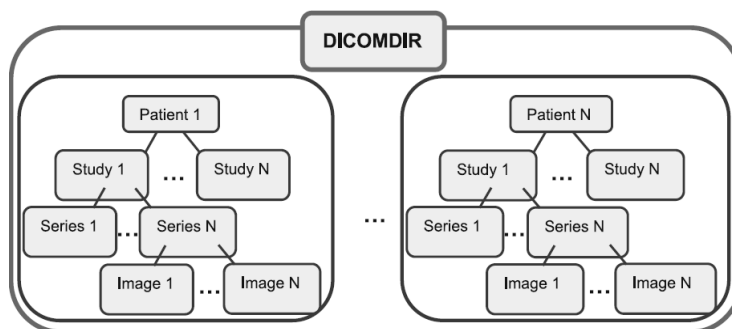


Figura 1.7. Structura fișierului DICOMDIR [Pia08].

1.3 Abstractizarea imaginilor medicale

Imaginile medicale încorporează o multitudine de informații despre starea pacientului. Aceste informații sunt compuse din date numerice și date lingvistice [Chb03]. Datele numerice se referă la proprietățile componentelor de bază care alcătuiesc o imagine. Aceste componente de bază sunt pixeli (pentru imaginile 2D) sau voxeli (pentru imaginile 3D). Grupările de pixeli de același fel formează o subimagine. Subimaginea poate să fie un obiect sau fundal. În imaginile medicale și nu numai cel mai mare interes îl reprezintă obiectul sau obiectele. Aceste obiecte au diverse proprietăți numerice, care definesc date lingvistice utilizate de specialist. Ele sunt prezentate în figura 1.7.

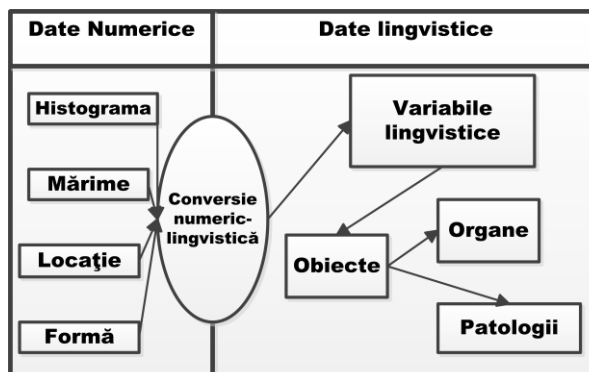


Figura 1.8 Tipurile de date existente în imaginile medicale.

Datele lingvistice sunt folosite de cadrele medicale pentru a descrie un obiect la nivelul cognitiv folosind textul liber. Textul liber permite descrierea obiectului pe înțelesul tuturor dar creează și o oarecare incertitudine.

Astfel putem defini două nivele de date: cel inferior care conține date numerice și cel superior care conține date lingvistice. Figura 1.7 prezintă nivelele de date în imaginile medicale. Datele numerice conțin informații despre pixeli și grupuri de pixeli care pot fi exprimate folosind numere reale. Datele lingvistice conțin informații care descriu datele numerice utilizând limbajul natural. Între aceste două nivele de date există o concordanță naturală care permite conversia variabilelor numerice în variabile lingvistice. Fiecărei variabile numerice i se poate asocia un descriptor lingvistic în funcție de valoarea plăjei de acoperire. Astfel combinând variabilele lingvistice între ele se pot crea diverse reguli care descriu cu o oarecare exactitate diverse obiecte și diverse patologii. Această dispunere pe nivele diferite a informației, asociată cu descrierea lingvistică a diverselor patologii constituie o modalitate de abstractizare a imaginilor medicale.

1.3.1 Nivelul inferior de date

La acest nivel se găsesc informațiile și datele pur numerice care pot fi extrase doar cu ajutorul ecuațiilor și tehnicilor matematice. Aceste date se referă atât la proprietățile pixelilor cât și la obiectele formate din grupuri de pixeli care au aceleași caracteristici. Astfel imaginea se poate diviza în obiecte și fundal. Obiectele din imagine sunt extrase folosind diverse metode de segmentare. Aceste metode de segmentare oferă posibilitatea de a extrage date numerice referitoare la unul sau mai multe obiecte. Proprietățile numerice ale obiectelor din imagine sunt următoarele: forma reprezentată prin contur, histograma, mărimea în unități de pixeli (ex: 1546 de pixeli) și locația în imagine reprezentată prin centrul de greutate al obiectului la coordonatele carteziane tot în unități de pixeli.

Rezultatele obținute prin segmentare sunt reprezentate de matrici și/sau șiruri de numere. Acestea se obțin prin analiza: conturului, intensității pixelilor, șabloanelor de culoare, coordonatelor carteziane la care se află pixelul sau obiectul (în funcție de obiectul de interes), mărimii și orientării obiectului investigat. Acestea sunt cu greu interpretate de un utilizator uman.

1.3.2 Nivelul superior de date

Nivelul superior este reprezentat de informațiile semantice sau lingvistice. Datele lingvistice stau la baza procesului de gândire și asociere a oamenilor. Aceste informații sunt similare informațiilor numerice dar sunt prezentate într-un format mai explicit pentru cadrele medicale. Pentru a obține informațiile lingvistice care se găsesc în imagine va trebui efectuată o conversie numerico-lingvistică. Această conversie este efectuată automat pe nivelul cognitiv de către un cadru medical iar în cazul echipamentelor de calcul vom folosi o unealtă dedicată: mecanismul de fuzzyficare a datelor [Zad65].

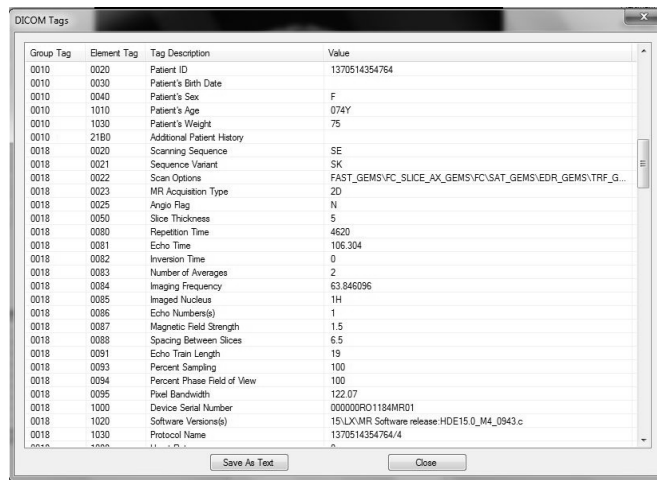
Doar o parte din informațiile semantice se pot obține direct din imagine, deoarece aceste informații sunt legate direct de obiectele care se găsesc în imagine iar restul datelor se obțin din secțiunea de metadate a imaginilor.

Aceste date lingvistice se pot folosi împreună cu un sistem de inferență fuzzy pentru a identifica diferite organe, malformații și a detecta patologii.

1.3.3 Metadate

Metadatele sunt în general „date despre date”, sau altfel spus, date care descriu alte date. Aceste date pot fi atât în format semantic cât și în format numeric. Metadatele imaginii medicale au o legătură indirectă cu imaginea și una directă cu pacientul [Mue 08]. În unele cazuri aceste date sunt necesare pentru a formula un diagnostic corect. Putem considera metadate numerice: rezoluția imaginii și rezoluția celulară a undei de scanare. Aceste date pot facilita determinarea corectă a mărimii obiectului de către sistemul de interpretare în cazul în care aria pixelului este necunoscută. Metadatele nu sunt limitate doar la aceste date numerice. Acestea conțin date legate de pacient: nume, prenume, vârstă, sex și date legate de activitatea medicală: numele medicului curant și instituția unde s-a efectuat investigația. În cazul imaginilor DICOM există o sumedenie de metadate în secțiune de TAG-uri DICOM. În TAG-uri se precizează date demografice, date legate de aparatura folosită și criteriile de formare a imaginii.

TAG-rile DICOM sunt structurate pe adrese. Aceste adrese sunt formate din opt numere hexazecimale grupate câte patru, în forma [hhhh,hhhh]. În aceste TAG-uri se poate preciza inclusiv și zona anatomică investigată sau denumirea organului investigat. Imaginea de mai jos prezintă o listă de TAG-uri DICOM asociate unei imagini medicale.



Group Tag	Element Tag	Tag Description	Value
0010	0020	Patient ID	1370514354764
0010	0030	Patient's Birth Date	
0010	0040	Patient's Sex	F
0010	1010	Patient's Age	074Y
0010	1030	Patient's Weight	75
0010	2180	Additional Patient History	
0018	0020	Scanning Sequence	SE
0018	0021	Sequence Variant	SK
0018	0022	Scan Options	FAST_GEMS'FC_SLICE_AX_GEMS'FC/SAT_GEMS'EDR_GEMS'TRF_G...
0018	0023	MRI Acquisition Type	ZD
0018	0025	Angio Flag	N
0018	0050	Slice Thickness	5
0018	0080	Repetition Time	4620
0018	0081	Echo Time	106.304
0018	0082	Inversion Time	0
0018	0083	Number of Averages	2
0018	0084	Imaging Frequency	63.846096
0018	0085	Imaged Nucleus	1H
0018	0086	Echo Numbers(s)	1
0018	0087	Magnetic Field Strength	1.5
0018	0088	Spacing Between Slices	6.5
0018	0091	Echo Train Length	19
0018	0093	Percent Sampling	100
0018	0094	Percent Phase Field of View	100
0018	0095	Pixel Bandwidth	122.07
0018	1000	Device Serial Number	00000RO1184MR01
0018	1020	Software Versions(s)	15'LX:MR Software release HDE15_0_M4_0943.c
0018	1030	Protocol Name	1370514354764/4

Figura 1.9 TAG-uri DICOM.

1.4 Structura tezei

Teza este structurată în 8 capitole distincte. Primele două capitole prezintă succint imaginile medicale și metodele folosite pentru prelucrarea imaginilor medicale. În capitolele trei-șase sunt prezentate contribuțiile aduse în domeniul imagisticii medicale. Capitolul șapte conține validările metodelor propuse în teză iar capitolul opt însumează concluziile finale.

Capitolul 1 – Prezintă succint cele mai cunoscute tipuri de imagini medicale utilizate în mod curent în imagistica medicală. Aceste tipuri de imagini sunt: radiografia clasică, ultrasonografia sau ecografia, tomograful computerizat și rezonanța magnetică nucleară. Imaginile sunt generate digital, fie nativ, fie scanate, după standardul DICOM. Standardul DICOM este un standard impus pentru imaginile medicale digitale. Acest standard specifică modalitățile de scanare și codificare a imaginilor medicale. DICOM impune codificarea mai multor tipuri de metadata în structura fișierului *.dcm, acesta conține și imaginea medicală. Aceste metadata se pot clasifica în următoarele domenii:

- Date despre pacient: utilizează datele demografice ale pacientului și precizează zona anatomică investigată.
- Date despre formarea imaginii medicale.
- Date pentru decodificarea imaginilor din fișierul *.dcm.

Capitolul 2 – prezintă o sinteză a metodelor de imagistică atât numerice cât și bazate pe tehnici fuzzy. Această sinteză este împărțită în trei părți. Prima parte cuprinde metodele de preprocesare a imaginilor medicale. Aceste metode au fost dezvoltate pentru a elimina zgomotele de imagine existente. Zgomotele de imagine pot fi: de impuls, de frecvență, aditive, multiplicative și Gaussian. Pentru eliminarea lor se folosesc filtre care au fost îmbunătățite cu sisteme de inferență fuzzy. Aceste filtre cu preponderență sunt filtre mediane și filtre mediane adaptive. Se întâlnesc și alte filtre precum filtre anizotropice și filtre Fourier. Segmentarea are rolul de a separa obiectele de fundal. Au fost identificate trei metode de segmentare: clustering fuzzy, algoritmi bazați pe reguli fuzzy și algoritmi bazați pe interpretarea fuzzy a informației. Cea mai utilizată metodă este clusteringul fuzzy.

Această metodă robustă a suferit numeroase modificări pentru a îmbunătăți procesul de segmentare. Ultima parte prezintă metode de interpretare a segmentelor de imagine folosind sisteme de inferență fuzzy. Aceste sisteme analizează datele extrase din pixelii segmentului de imagine pentru a identifica tipul de țesut de care aparțin.

Capitolul 3 – prezintă o sinteză a diferitelor structuri de sisteme cu inferență fuzzy și de asemenea prezintă editoare pentru generarea sistemelor cu inferență fuzzy existente. Sunt prezentate sistemele simple și multiple de sisteme fuzzy. Sistemele multiple sunt sistemele silogistice (cascadate) și ierarhice. Editoarele prezentate sunt editorul din *MatLab* și editorul *FuzzyTech*. Primul salvează sistemul fuzzy într-un fișier text iar celălalt în cod sursă de C. Aceste metode de reprezentare nu permit implementarea rapidă și facilă în sistemele de calcul. În ambele cazuri programul scris sau simulat trebuie oprit, modificat, recompilat și apoi repornit. În acest capitol se propune o reprezentare mai simplă a sistemelor cu inferență fuzzy folosind fișiere XML și o modalitate de a încorpora inferența fuzzy în sistemele de analiză fără recompilarea acestor sisteme.

Capitolul 4 – prezintă un sistem original de interpretare a imaginilor medicale. Sistemul propus ia în considerare atât datele directe obținute din subimagini, cât și metadatele. Aceste metadate sunt informațiile demografice ale pacientului și informațiile legate de crearea imaginii în sine. În acest capitol se prezintă structura logică a sistemului de interpretare, metodele numerice folosite pentru segmentare și extragerea datelor numerice ale segmentului de imagine. Aceste date numerice pot fi: forma, histograma, mărimea și locația segmentului de imagine. De asemenea se prezintă și categoria de metadate utilizate. Informațiile vor fi introduse într-un sistem de inferență fuzzy care va interpreta datele în vederea obținerii unui rezultat. Rezultatele inferenței fuzzy pot fi indicarea (recunoașterea) unor organe sau obiecte de altă natură sau mai important, patologii.

Capitolul 5 – propune o metodă de optimizare a regulilor de inferență fuzzy folosind algoritmi genetici. Se vor prezenta pe scurt metodele utilizate pentru generarea regulilor fuzzy folosind algoritmi genetici. Pe baza soluțiilor existente în literatura de specialitate se propune o structură proprie de cromozomi, originală, care diferă de restul prin tipul genelor. Genele codifică șiruri de caractere și nu numere binare. Genele formează perechi, astfel prima genă codifică variabila numerică iar a doua genă codifică setul fuzzy activ. Pentru a crea o populație viabilă de gene și cromozomi populația inițială va fi formată dintr-un număr de cromozomi egali cu numărul de seturi fuzzy din cea mai complexă variabilă lingvistică. Metodele de permutare sunt modificate pentru a permite puncte de permutare doar în punctele de 2k. Metoda propusă permite generarea de noi reguli iar regulile utilizabile vor fi salvate într-o bază de date separată față baza de date în care se află populația de gene.

Capitolul 6 – prezintă implementarea software a metodelor prezentate în capitolele trei, patru și cinci. Pentru implementarea metodelor de la capitolul trei s-a recurs la utilizarea unui open-source de la Aforge.Net care în varianta sa originală permitea doar hardcodarea sistemului cu inferență fuzzy. Acest open-source a fost extins cu un editor de sisteme cu inferență fuzzy și i s-a adăugat posibilitatea de a importa-exporta o reprezentare a sistemului cu inferență fuzzy în format XML. Implementarea metodelor propuse în capitolul patru s-a realizat utilizând două programe de tip open-source. Primul program are rolul de a decodifica fișierul DICOM și de a separa imaginea medicală propriu zisă de TAG-uri. Aceste TAG-uri sunt introduse într-un buffer de metadate. Al doilea program este platforma open-

source AForge.Net care are rolul de a segmenta și de a interpreta segmentul din imaginea medicală. Procesarea imaginii se realizează folosind metodele modificate din AForge.NET și interpretarea segmentelor de imagine este realizată folosind un sistem cu inferență fuzzy importat dintr-un fișier XML.

Capitolul 7 – descrie studiile de caz efectuate pentru validarea conceptelor prezentate în capitolul patru și capitolul cinci. Aceste experimente implică analiza mai multor tipuri de imagini medicale și identificarea mai multor obiecte și patologii. În primul test au fost analizate obiectele preluate din imagini RMN de tip T1 SE, T2 FSE și T2 Flair ce prezintă o patologie craniană. În imaginile RMN s-a urmărit identificarea tipurilor de țesături și identificarea unui edem cerebral cauzat de o tumoră cerebrală. Acest prim test s-a realizat în condiții de laborator. Al doilea test a fost efectuat pe radiografii digitale pentru identificarea osteosclerozei și s-a desfășurat în condiții clinice pe sistemul dublu orb. Medicul a analizat imaginile în paralel cu programul realizat, ulterior s-au comparat rezultatele. Al treilea experiment va genera reguli de inferență fuzzy pentru experimentele unu și doi, folosind un set minimal de reguli și date de antrenament care reprezintă numeric segmentele de imagine analizate.

Capitolul 8 – prezintă concluziile și contribuțiile pe care autorul le-a adus la îmbunătățirea tehnologiei de clasificare a datelor.

1.5 Concluzii

Cele mai utilizate imagini medicale sunt: radiografiile (generate cu raze X), ecografiile (folosind ultrasunete), imagini create cu computerul tomograf (utilizează raze X direcționate), și imagini create folosind rezonanța magnetică nucleară (utilizează câmpuri electromagnetice).

Datele de natură numerică sunt utilizate de sistemele de calcul. Aceste date numerice sunt obținute din obiectele existente în imagine și separate de fundal prin procesul de segmentare. Obiectele din imagine se definesc după: formă, care este reprezentată de contur, mărime în unități de pixel, valoarea histogramei și locația segmentelor de imagine în imaginea originală definită prin coordonate Carteziane tot în unități de pixel. Originea sau locația (0,0) este colțul din stânga sus. Datele de natură lingvistică sunt utilizate de medici. Valorile lingvistice se referă la proprietățile obiectelor existente în imaginea medicală. În acest caz proprietățile valorilor lingvistice nu sunt definite ci descrise, ceea ce permite o oarecare imprecizie în descrierea propriu zisă. Pentru a utiliza avantajele oferite de această imprecizie în identificarea anumitor semne sau obiecte folosind sisteme de calcul se vor utiliza sistemele cu inferență fuzzy și sisteme care operează cu variabile lingvistice. Metadatele sunt date și informații care se referă atât la pacient cât și la modul în care a fost generată imaginea. Astfel obținem datele demografice ale pacientului, zona investigată și date specifice fiecărei metode de generare. De exemplu în metadate regăsim informații legate de doza de iradiere prin intermediul rezonanței magnetice nucleare și prin intermediul radioscopiei. Se mai găsesc informații care facilitează afișarea corectă (nativă - fără modificarea contrastului și a luminozității). Aceste informații sunt folosite pentru a stabili dacă pacientul suferă sau nu de o patologie benignă sau malignă. Pentru evitarea unui haos în codificarea metadatelor s-a impus utilizarea standardului DICOM.

Pentru analiza automată a imaginilor medicale s-au creat diverse sisteme de prelucrare a imaginilor. Aceste sisteme au în vedere îmbunătățirea calității imaginilor, segmentarea imaginilor pentru a separa obiectele de fundal și

interpretarea acestor segmente utilizând tipurile de date prezentate mai sus. Din cunoștințele noastre cele mai bune și după studierea literaturii de specialitate se observă lipsa studiilor efectuate asupra postprocesării imaginilor medicale folosind algoritme fuzzy pentru identificarea semantică a posibilelor patologii. Această teză aduce contribuții la utilizarea sistemelor fuzzy în imagistica medicală pentru detectarea patologiilor utilizând datele care rezultă direct din subimagini ale imaginilor medicale, respectiv cele care rezultă din metadatele asociate.

2. Prelucrarea imaginilor medicale

Într-un sens general, o imagine descrie o variație a luminozității pe un plan 2D sau 3D. Imaginile medicale se pot considera 'fotografii' ale interiorului corpului uman realizate într-o situație de iluminare mai specială, utilizând aparate specifice. Astfel medicul are o reprezentare grafică a interiorului corpului uman și poate formula un diagnostic corect. Acest diagnostic este formulat pe baza cunoștințelor și a experiențelor acumulate pe o perioadă lungă de timp.

Pentru sistemele de calcul, imaginea medicală este o matrice de pixeli care au o anumită valoare numerică. Pentru extragerea și interpretarea datelor prezente în matricea respectivă se vor utiliza diverși algoritmi specializați. Acești algoritmi au rolul de a pregăti imaginea pentru procesare, de a despărți obiectele prezente în imagine de fundal și de a prelucra în diverse modalități obiectele separate.

În acest capitol se vor prezenta etapele necesare pentru extragerea datelor numerice și se vor prezenta algoritmi actuali cu care se realizează diferite operațiuni asupra datelor numerice.

Prelucrarea imaginilor medicale necesită utilizarea mai multor tipuri de algoritmi pentru extragerea informației dorite. Algoritmii de prelucrare a imaginilor se pot împărți în mai multe categorii: preprocesare, segmentare, procesare și postprocesare.

Preprocesarea imaginilor presupune filtrarea imaginilor folosind filtre liniare și neliniare. Astfel se îmbunătățește calitatea imaginilor prin eliminarea zgomotelor de imagine.

Filtrarea liniară a imaginilor presupune utilizarea filtrelor pentru netezirea zonelor cvasi uniforme [Ana10]. Astfel se elimină micile diferențe dintre valorile pixelilor din aceeași zonă. Pe această metodă se bazează restul metodelor care au ca și efect reducerea zgomotului alb-aditiv Gaussian. Filtrarea liniară de contrastare are ca și efect îmbunătățirea percepției vizuale a conturilor. Aceasta se realizează prin modificarea pixelilor aflați de ambele părți ale conturilor. Filtrarea liniară adaptivă este metoda prin care un filtru liniar își ajustează valorile și comportamentul în funcție de anumite criterii pentru a oferi o procesare de calitate. Procesul de adaptare presupune modificarea filtrului la fiecare punct de prelucrare luând în considerare caracteristicile locale ale zonei prelucrate.

Filtrarea neliniară a imaginilor presupune eliminarea unor componente neliniare din imagine, precum zgomotul de impuls, zgomotul multiplicativ și convolutiv. Filtrele neliniare cele mai cunoscute sunt filtrele mediane [Pal12][Lin10].

Segmentarea imaginilor este metoda prin care se separă obiectele din imagine de fundal. Astfel fiecărui pixel i se atribuie o valoare care specifică zona de apartenență: zona de fundal sau zona de interes. În general segmentarea se efectuează pentru extragerea și recunoașterea unor obiecte din imagine. Regiunile care conțin obiectele și fundalul se numesc segmente de imagine. Metodele de segmentare se pot clasifica în două metode: după regiuni [Bos12] [Yug12] [Tha12] și orientate pe contururi [Chi12].

Metoda de segmentare bazată pe regiuni are rolul de a extrage subimagini ocupate de diversele obiecte existente în imagine. Un obiect este o entitate caracterizată de un set de parametri care nu se modifică în diferitele puncte ale obiectului. Unul dintre cei mai comuni parametri este nivelul de gri al obiectului. Dacă histograma subimaginii caracterizează în mod suficient obiectele din imagine atunci o valoare de histograma va reprezenta câte un obiect.

Metoda de segmentare bazată pe detecția de contururi utilizează variațiile nivelelor de gri ale pixelilor adiacenți. Într-un număr mare de cazuri aceste variațiuni corespund frontierelor regiunilor determinate de obiectele dintr-o imagine.

Procesarea segmentelor de imagine presupune utilizarea unor metode care extrag informațiile utile din segmentul de imagine și a unor metode care efectuează operații de corecție asupra acestor segmente de imagini.

Postprocesarea imaginilor este etapa în care sunt interpretate datele extrase din segmentul de imagine. În general în această categorie găsim metodele de recunoaștere a segmentelor. Din această categorie fac parte metodele de recunoaștere a formelor, a modelelor și alte tipuri de interpretări [Cos06] [Cos05] [Cor11].

Aceste prelucrări se pot realiza folosind atât metode numerice cât și fuzzy. În continuare se vor prezenta atât metode numerice cât și metode bazate pe logica fuzzy pentru prelucrarea imaginilor medicale.

2.1 Metode numerice în imagistica medicală

Metodele de prelucrare numerică sunt acelea care folosesc algoritmi matematici pentru reconstrucția, segmentarea și interpretarea imaginilor. Rezultatele prelucrărilor vor fi în forma numerică, în general o matrice care conține date rezultante. În continuare se vor prezenta câteva metode pentru etapele de pre-, procesare și postprocesare.

Preprocesarea imaginilor presupune pregătirea imaginilor pentru segmentare și alte prelucrări care pot fi compromise de proasta calitate a imaginilor. Zgomotele de imagine creează o problemă în imagistica medicală, o problemă care are soluții multiple în ziua de azi. Cele mai frecvente probleme apar din cauza zgomotelor de imagine care necesită o filtrare adecvată. O filtrare prea puternică poate compromite datele utile din imagine. Astfel au fost create diferite metode de filtrare pentru a elimina zgomotele de imagine. Conform [Hua09] cele mai frecvente zgomote de imagine sunt zgomotele de tip:

- aleator sau de impuls, care apar în momentul în care senzorul de captare codifică imagini supra sau sub saturate ale căror valori de histogramă sunt peste limita maximă sau sub limita minimă a senzorului.
- Gaussian, se manifestă prin variațiuni mici datorită erorilor de cuantificare în momentul digitalizării imaginii.
- de frecvență, se caracterizează prin interferența unui semnal de oarecare frecvență cu semnalele care formează imaginea brută.
- multiplicativ, care apar ca rezultat al multiplicării unui semnal aleatoriu de zgomot cu semnalul imaginii.

În fiecare caz, zgomotele creează o modificare subită în intensitatea imaginilor și se consideră a fi o componentă de frecvență înaltă din imaginea dată.

Metodele numerice de filtrare folosesc:

- Filtrul median, este un filtru non linear folosit în general pentru eliminarea zgomotelor de tip "speckle" care apar sub forma unor picățele foarte mici. Acesta utilizează intensitatea mediană a unei regiuni din jurul pixelului de interes [Zha10].
- Filtrul median adaptiv este un filtru median îmbunătățit care utilizează ponderi pentru calcularea intensității mediane [Lin07]. Acest filtru are

capacitatea de a proteja datele din imagine. Alegerea ponderilor trebuie făcută în așa fel încât să se creeze un compromis între protejarea informațiilor și eliminarea zgomotelor.

- Filtarea Fourier care propune eliminarea componentelor de mare frecvență din transformata Fourier a imaginilor medicale [Lei09].
- Filtarea homomorfică, are rolul de a elimina zgomotul multiplicativ prin transformarea logaritmică a imaginilor pentru transformarea zgomotului multiplicativ în aditiv [Nno08].

Etapele următoare prin care trec imaginile medicale reconstruite sunt cele de segmentare și cele de postprocesare.

Una dintre aplicațiile segmentării și postprocesării este detectarea automată a ficatului într-o imagine medicală [Hir05]. Metoda prezentată se bazează pe combinarea mai multor algoritmi de imagistică. Imaginea este parcursă de algoritmul Peak and Valley pentru a îmbunătăți calitatea acesteia. Această scanare este o scanare neliniară care nu afectează nivelul de gri al imaginii.

Ecuțiile următoare definesc metoda Peak and Valley:

$$P'(i+j) = \min(P(i-1), P(i+k)) \text{ if } P(i+j) < P(i-1) \text{ and } P(i+j) < P(i+k) \quad (2.1)$$

$$P'(i+j) = \max(P(i-1), P(i+k)) \quad (2.2)$$

$$\text{if } P(i+j) > P(i-1) \text{ and } P(i+j) > P(i+k)$$

$$P'(i+j) = P(i+j) \text{ else.} \quad (2.3)$$

$$\forall j = 0, 1, 2, \dots, c, k-1$$

$P(i)$ reprezintă intensitatea originală a pixelului i . $P'(i)$ este noua valoare de intensitate al pixelului i .

Din ecuația (2.1) se obține o valoare de "vale" a unui grup de k pixeli.

Din ecuația (2.2) se obține valoarea de "creastă" a unui grup de k pixeli.

Ecuția (2.3) reprezintă o valoare diferită de valorile anterioare. Dacă valoarea lui k este 1, atunci cele trei ecuații sunt identice cu un filtru median, în caz contrar filtrul Peak and Valley este superior filtrului median.

Pentru a maximiza efectul algoritmului, scanarea se efectuează pe curba lui Hilbert. Pentru a transforma curba într-o curbă cât mai netedă se folosește interpolarea Cubic Spline. Separarea pixelilor care alcătuiesc fundalul, de pixelii care alcătuiesc obiectul de interes este realizată prin convertirea imaginii într-o imagine binară folosind algoritmul Otsu. Se calculează pragul de intensitate între pixelii de fundal și pixelii care alcătuiesc obiectul. Pentru fiecare pixel probabilitatea de a aparține de fundal sau de un obiect este modificată în funcție de opt pixeli înconjurători. Algoritmul "local adaptive threshold" este folosit pentru a reduce zgomotele. Imaginea este divizată în subimagini. Algoritmul Otsu este folosit pentru fiecare subimagine pentru a obține pragurile de intensitate locale. Fiecărui pixel din subimagine care este mai intens decât pragul local, i se atribuie valoarea pragului local. Obiectele găsite se încadrează într-un dreptunghi. Se va selecta dreptunghiul care conține obiectul cu proprietățile adecvate.

O altă abordare a prelucrării imaginilor medicale se realizează prin folosirea rețelelor neuronale și a funcțiilor RBF (radial basis function) [Mas 09]. Această metodă se aplică pentru detecția cancerului hepatic. Rețeaua neuronală RBF are o arhitectură pe 3 straturi: stratul de intrare, stratul ascuns și cel de ieșire. Arhitectura este prezentată în figura 2.1.




Figura 2.1 Rețeaua neuronală RBF.

Stratul de ieșire se poate defini astfel:

$$u_i = x_i \quad (i = 1, 2, \dots, p) \quad (2.4)$$

unde x_i este variabila de intrare și u_i este variabila de ieșire a stratului de neuroni.

În stratul ascuns ieșirea neuronului RBS se calculează folosind relația:

$$h_j = \exp(-z_j^2) \quad (j=1, 2, \dots, g) \quad (2.5)$$

Estimarea parametrului z_j se realizează folosind analiza regresivă a datelor de învățare.

Ieșirea neuronilor de pe ultimul strat se calculează conform ecuației:

$$\phi_i(x) = \sum_{j=1}^q w_j h_j(u) \quad (u=1, 2, \dots, p) \quad (2.6)$$

Ponderile rețelei neuronale sunt $w_j (j=1, 2, \dots, q)$ și q reprezintă numărul de neuroni pe nivelul de ieșire. Rețeaua are zece intrări: patru pentru caracteristicile statice ale imaginii: media, variația, deviația standard și domeniul; patru pentru caracteristicile de textură și două pentru coordonate (x, z) . Imaginea care a fost scanată cu acest algoritm este transformată într-o imagine binară unde pixelii obiectului de interes sunt setați pe unu și restul pe zero ca și în figura 2.2 a,b.



Figura 2.2 a) imaginea originală , b) imaginea binară.

Radiografiile clasice și cele digitale necesită diferite prelucrări pentru detectarea anumitor semne care pot să indice o patologie fie a sistemului osos fie a sistemului respirator.

De exemplu pentru detectarea osteoartritei genunchiului, metoda se bazează pe grade de comparație Kellgren-Lawrence (KL) care corespund diferitelor stadii de severitate a osteoartritei (OA). Analiza se realizează prin următorii pași: se identifică descriptorii de imagine (histograma oaselor și distanța dintre oase) care dețin informații despre OA și se acordă ponderi fiecărui descriptor. Pentru a prezice gradul KL a OA se folosește algoritmul "simple weighted nearest neighbour" [Sha09].

O altă problemă medicală o reprezintă leziunile mici ale osului. Pentru a detecta aceste leziuni în imaginile radiologice, s-a folosit trăsătura fractală multiscalară a imaginii. Astfel s-a analizat valoarea fractală în diferite regiuni și s-a constatat că aceste valori diferă de la regiune la regiune. Fundalul are o valoare între 0,005 și 0,020; regiunea normală este între 0,040 și 0,070 iar în zona lezată este între 0,100 și 0,200 [Xue09] [Flo11]. Din punct de vedere medical fracturile au o clasificare precisă. Pentru a putea clasifica automat aceste fracturi imaginea se segmentează folosind o transformată de tip "watershed marker-controlled" și se aplică modificări de tip "homotopy". Se extrage numărul regiunii, aria, centrul și poligonul protuberant. În pasul următor se extrag liniile principale din poligonul protuberant folosind transformata Hough. Liniile corespunzătoare sunt echivalente cu linia fracturii și paralele liniei de centru. Folosind paralelele obținem linia centrală a regiunii și perpendiculara ei. La final se calculează unghiul de fractură cu perpendiculara centrală, după care se clasifică fractura [Zhe 08].

Imaginile radiologice conțin și alte organe, astfel avem nevoie de o clasificare a imaginilor de radiologie. Pentru ca această clasificare să fie corectă, se poate utiliza o clasificare multi-class folosind frameworkul de învățare "support vector machines" (SVM). Experimentele arată că cea mai bună metodă ca și acuratețe este metoda "local binary pattern" [Jean 08].

Imaginile CT se pot utiliza și pentru investigarea plămânilor. Se folosesc, de exemplu pentru investigarea naturii benigne sau maligne a maselelor tumorale. Aceasta se poate face prin combinarea a două caracteristici fundamentale din imaginea CT brută: orientarea maselelor tumorale folosind un filtru Gabor în regiunea de interes și înregistrarea valorii CT din acea regiune în direcția axului corporal. Îmbinând aceste trăsături cu tehnici de recunoaștere de tipar de ex: rețele neuronale; se pot identifica masele tumorale [Hon 08]. În cazul în care masele tumorale nu sunt izolate corespunzător de peretele plămânului, atunci se poate trasa un contur activ care poate rezolva problema optimului local a conturului. Conturul activ utilizează trăsăturile anatomice ale plămânului [Shim 09]. Tabelul 2.1 sintetizează metodele numerice de imagistică prezentate și precizează în ce etapă de imagistică sunt folosite.

Tabelul 2.1 Metode numerice pentru imagistica medicală

Etapă	Algoritm-tehnologie	Utilizare
Postprocesare	Folosește gradele de comparație Kellgren-Lawrence care corespund stadiilor de severitate a osteoartritei.	Analiza osteoartritei genunchiului.
Procesare-segmentare	Se utilizează trăsătura fractală multiscalară a imaginii radiologice.	Detectarea leziunilor mici din imaginile radiologice.
Preprocesare	Utilizarea framework-ului de învățare SVM cu metoda "local binary pattern."	Clasificarea multi-class a imaginilor radiologice.
Procesare	O metodă complexă folosind liniile atașate axelor dintr-o regiune de interes.	Clasificarea fracturilor din imaginea radiologice.
Postprocesare	Recunoașterea tiparelor folosind valoarea CT și orientarea maselor tumorale din plămân.	Recunoașterea maselor tumorale.
Postprocesare	Folosirea unui contur activ care poate rezolva problema optimului local utilizând trăsături anatomice ale plămânului.	Recunoașterea maselor tumorale nedelimitate de la nivelul plămânului.
Preprocesare	Eliminarea zgomotelor de imagine.	Reconstrucția imaginilor medicale.

Se poate observa că aspectele majore ale imagisticii medicale au fost acoperite de metode de procesare numerice care impun o strictețe matematică. Această strictețe impune un compromis între resursele sistemului și rezultat. Pentru a crește performanțele metodelor de procesare fără a crea un astfel de compromis și a crește flexibilitatea sistemelor s-a propus introducerea sistemelor cu inferență fuzzy. Inferența fuzzy extinde logica booleană și introduce noțiunea de 'probabil' în calculele efectuate.

2.2 Metode fuzzy în imagistica medicală

În imagistica medicală s-a propus o abordare care oferă posibilitatea de a introduce incertitudinile în prelucrarea imaginilor. Aceste metode care folosesc atât formule matematice cât și incertitudine se numesc metode cu inferență fuzzy. Metodele fuzzy au fost folosite cu succes în mai toate etapele imagisticii medicale. Acest subcapitol are rolul de a sumariza metodele curente de imagistică medicală care utilizează metode fuzzy pentru preprocesare, segmentare și postprocesare.

2.2.1 Sisteme cu inferență fuzzy pentru reducerea zgomotelor

Preprocesarea imaginilor presupune pregătirea acestora pentru etapa de segmentare. Această pregătire se realizează în special prin reducerea zgomotelor de imagine. În subcapitolul anterior s-au identificat diferite tipuri de zgomote și mai multe tipuri de filtre pentru eliminarea zgomotelor. Preprocesarea prin metode fuzzy

presupune extinderea acestor filtre numerice cu inferențe care permit utilizarea incertitudinilor.

a) *Filtrarea fuzzy a zgomotului de impuls:*

În [Abd07] se propune folosirea unui filtru median adaptiv bazat pe sisteme de inferență fuzzy pentru a maximiza efectul unui filtru median adaptiv simplu care a fost utilizat înaintea filtrului adaptiv median fuzzy. Filtru median adaptiv extins cu logica fuzzy este alcătuit prin definirea a nouă funcții de membru pentru nouă variabile lingvistice. Astfel intrările în sistemul de inferență vor fi intensitățile pixelilor $p(x,y)$ în formă de variabilă lingvistică care vor defini nivelele de apartenență a seturilor fuzzy: *mf1* pentru pixeli negrii, *mf2* pentru pixeli mai puțin negrii și așa mai departe.

Pentru a procesa imaginea, intensitatea fiecărui pixel trebuie fuzzificată și apoi normalizată pe domeniul $0 - p(x,y) - 1$. Pentru a realiza scanarea se va folosi o matrice de scanare (subimagine) de mărimea 3×3 pe întreaga imagine. Folosind filtrul fuzzy, zgomotele vor fi reduse, iar ieșirea va fi schimbată cu pixelul central al matricei. Se va defini o matrice N_{imp} care va conține valorile intensităților pixelilor de zgomot, astfel matricea 3×3 va reprezenta planul $W[(k,l)]$ (k și l sunt coordonate carteziene), planul scanării curente. La fiecare scanare de tip 3×3 , 9 pixeli vor fi clasificați în funcție de intensitatea nivelelor de gri. De exemplu dacă $p(k,l) \in N_{imp}$, dacă $p(k, l) = \min\{W[k, l]\}$ sau $\max\{W[k, l]\}$. În cazul în care:

$$x_1 = p(k - 1, l - 1), x_2 = p(k - 1, l), x_3 = p(k - 1, l + 1), x_4 = p(k, l - 1), x_5 = p(k, l), x_6 = p(k, l + 1), x_7 = p(k + 1, l - 1), x_8 = p(k + 1, l), x_9 = p(k + 1, l + 1), \quad (2.7)$$

Fiecare element este definit ca și o variabilă fuzzy iar intensitățile pixelilor vor fi funcțiile de membru a fiecărui pixel de intrare.

În ecuația (2.8) se descrie funcția de membru de tip clopot pentru variabilele fuzzy din sistemul de inferență.

$$p_j(x_i) = \frac{1}{1 + \left(\frac{x_j - c_j}{a_j}\right)^{2b_j}} \quad (2.8)$$

Parametrii a_j , x_j , c_j se pot ajusta pentru a obține valori optime. Pentru a deduce dacă valoarea pixelului investigat este o valoare de zgomot sau nu, s-au creat reguli de tip Mamdani. Prin ajustarea parametrilor funcțiilor de membru pentru o subimagine de 9 pixeli se obține valoarea fuzzificată a valorilor de intrare. Valorile normalizate pentru fiecare pixel se calculează folosind ecuația:

$$w_{ij} = \frac{m_j(x_i)}{\sum_{i=1}^9 m_j(x_i)} \quad i = 1, 2, 9, j = 1, 2, 3, \dots, 9. \quad (2.9)$$

Următoarele reguli sunt folosite pentru a detecta pixelii de zgomot într-o subimagine de 3×3 :

Regula 1. Dacă $x_1 = p(k - 1, l - 1) \in mf(1)$ $x_2 = p(k - 1, l) \in mf(1)$ $x_3 = p(k - 1, l + 1) \in mf(1)$ $x_4 = p(k, l - 1) \in mf(1)$ $x_5 = p(k, l) \in mf(1)$ $x_6 = p(k, l + 1) \in mf(1)$ $x_7 = p(k + 1, l - 1) \in mf(1)$ $x_8 = p(k + 1, l) \in mf(1)$ $x_9 = p(k + 1, l + 1) \in mf(1)$ atunci $x_5 = p(k, l) / \in XVblack$.

Regula 2. Dacă $x_1 = p(k-1, l-1) \in mf(1)$ $x_2 = p(k-1, l) \in mf(1)$ $x_3 = p(k-1, l+1) \in mf(1)$ $x_4 = p(k, l-1) \in mf(1)$ $x_5 = p(k, l) \in mf(1)$ $x_6 = p(k, l+1) \in mf(1)$ $x_7 = p(k+1, l-1) \in mf(1)$ $x_8 = p(k+1, l) \in mf(1)$ $x_9 = p(k+1, l+1) \in mf(1)$ atunci $x_5 = p(k, l) / \in XB_{black}$.

Regula 3. Dacă $x_1 = p(k-1, l-1) \in mf(1)$ $x_2 = p(k-1, l) \in mf(1)$ $x_3 = p(k-1, l+1) \in mf(1)$ $x_4 = p(k, l-1) \in mf(1)$ $x_5 = p(k, l) \in mf(1)$ $x_6 = p(k, l+1) \in mf(1)$ $x_7 = p(k+1, l-1) \in mf(1)$ $x_8 = p(k+1, l) \in mf(1)$ $x_9 = p(k+1, l+1) \in mf(1)$ atunci $x_5 = p(k, l) / \in XL_{black}$.

Regula 4. Dacă $x_1 = p(k-1, l-1) \in mf(1)$ $x_2 = p(k-1, l) \in mf(1)$ $x_3 = p(k-1, l+1) \in mf(1)$ $x_4 = p(k, l-1) \in mf(1)$ $x_5 = p(k, l) \in mf(1)$ $x_6 = p(k, l+1) \in mf(1)$ $x_7 = p(k+1, l-1) \in mf(1)$ $x_8 = p(k+1, l) \in mf(1)$ $x_9 = p(k+1, l+1) \in mf(1)$ atunci $x_5 = p(k, l) / \in X_{gray}$.

Regula 5. Dacă $x_1 = p(k-1, l-1) \in mf(1)$ $x_2 = p(k-1, l) \in mf(1)$ $x_3 = p(k-1, l+1) \in mf(1)$ $x_4 = p(k, l-1) \in mf(1)$ $x_5 = p(k, l) \in mf(1)$ $x_6 = p(k, l+1) \in mf(1)$ $x_7 = p(k+1, l-1) \in mf(1)$ $x_8 = p(k+1, l) \in mf(1)$ $x_9 = p(k+1, l+1) \in mf(1)$ atunci $x_5 = p(k, l) / \in X_{gray}$.

Regula 6. Dacă $x_1 = p(k-1, l-1) \in mf(1)$ $x_2 = p(k-1, l) \in mf(1)$ $x_3 = p(k-1, l+1) \in mf(1)$ $x_4 = p(k, l-1) \in mf(1)$ $x_5 = p(k, l) \in mf(1)$ $x_6 = p(k, l+1) \in mf(1)$ $x_7 = p(k+1, l-1) \in mf(1)$ $x_8 = p(k+1, l) \in mf(1)$ $x_9 = p(k+1, l+1) \in mf(1)$ atunci $x_5 = p(k, l) / \in X_{gray}$.

Regula 7. Dacă $x_1 = p(k-1, l-1) \in mf(1)$ $x_2 = p(k-1, l) \in mf(1)$ $x_3 = p(k-1, l+1) \in mf(1)$ $x_4 = p(k, l-1) \in mf(1)$ $x_5 = p(k, l) \in mf(1)$ $x_6 = p(k, l+1) \in mf(1)$ $x_7 = p(k+1, l-1) \in mf(1)$ $x_8 = p(k+1, l) \in mf(1)$ $x_9 = p(k+1, l+1) \in mf(1)$ atunci $x_5 = p(k, l) / \in XL_{white}$.

Regula 8. Dacă $x_1 = p(k-1, l-1) \in mf(1)$ $x_2 = p(k-1, l) \in mf(1)$ $x_3 = p(k-1, l+1) \in mf(1)$ $x_4 = p(k, l-1) \in mf(1)$ $x_5 = p(k, l) \in mf(1)$ $x_6 = p(k, l+1) \in mf(1)$ $x_7 = p(k+1, l-1) \in mf(1)$ $x_8 = p(k+1, l) \in mf(1)$ $x_9 = p(k+1, l+1) \in mf(1)$ atunci $x_5 = p(k, l) / \in X_{white}$.

Regula 9. Dacă $x_1 = p(k-1, l-1) \in mf(1)$ $x_2 = p(k-1, l) \in mf(1)$ $x_3 = p(k-1, l+1) \in mf(1)$ $x_4 = p(k, l-1) \in mf(1)$ $x_5 = p(k, l) \in mf(1)$ $x_6 = p(k, l+1) \in mf(1)$ $x_7 = p(k+1, l-1) \in mf(1)$ $x_8 = p(k+1, l) \in mf(1)$ $x_9 = p(k+1, l+1) \in mf(1)$ atunci $x_5 = p(k, l) / \in XV_{white}$.

Parametrii funcțiilor de membru de tip Gaussian folosiți se pot ajusta conform regulilor de mai sus. Parametrii de ajustare se pot observa mai jos:

Dacă $x_5 = p(k, l) / \in XV$ negru atunci $a_1 = 0.1$, $c_1 = 0.2$, $b = 15$.

Dacă $x_5 = p(k, l) / \in X$ negru atunci $a_1 = 0.2$, $c_1 = 0.3$, $b = 15$.

Dacă $x_5 = p(k, l) / \in XL$ negru atunci $a_1 = 0.2$, $c_1 = 0.4$, $b = 15$.

Dacă $x_5 = p(k, l) / \in X$ gri atunci $a_1 = 0.4$, $c_1 = 0.5$, $b = 15$.

Dacă $x_5 = p(k, l) / \in XL$ alb atunci $a_1 = 0.2$, $c_1 = 0.6$, $b = 15$.

Dacă $x_5 = p(k, l) / \in X$ alb atunci $a_1 = 0.2$, $c_1 = 0.7$, $b = 15$.

Dacă $x_5 = p(k, l) / \in XV$ alb atunci $a_1 = 0.1$, $c_1 = 0.8$, $b = 15$.

Metoda prezentată este combinația a două metode: una numerică alcătuită dintr-un filtru median adaptiv și una reprezentată de filtrul median adaptiv fuzzy.

O altă metodă utilizată pentru reducerea zgomotelor de impuls din imaginile color este aplicarea unui filtru fuzzy neural [Yue2008]. Astfel dacă un pixel este identificat ca și pixel de zgomot rețeaua neuronală elimină valoarea pixelului și o substituie cu o valoare nouă determinată de rețeaua neuronală.

[Tom11] propune introducerea informațiilor temporale și spațiale în detecția și eliminarea zgomotelor de imagine. Filtrarea spațială este determinată de ca și suma ponderată a valorilor nivelelor de gri învecinate, unde ponderea nivelului de gri corespunde cu probabilitatea ca pixelul să fie zgomot sau nu. Filtrarea temporală presupune verificarea pixelului cu corespondenții din imaginile anterioare pentru a analiza dacă corespondenții au fost sau nu zgomotoși. Acest tip de preprocesare este utilă în cazul în care dorim să efectuăm o prelucrare a unor secvențe de imagini medicale.

O metodă hibridă pentru reducerea zgomotelor de impuls este utilizarea sistemelor de tip fuzzy cellular automata [San12]. Cellular automata este un model matematic pentru sisteme cu multiple componente simple care formează un model. Cellular automata este un model discret, descentralizat și autoorganizat care poate crea structuri complexe pornind de la date stohastice. Extinderea modelului folosind sisteme de inferență fuzzy presupune exprimarea tuturor stărilor în care se află o celulă și a tuturor tranzițiilor folosind variabile lingvistice.

Filtrarea zgomotelor de tip impuls se poate realiza generând patru imagini diferite rotite la multipli de 90° și apoi combinând rezultatele folosind un sistem de inferență fuzzy [Yak10]. Filtrarea în sine se realizează folosind filtre mediane iar combinarea imaginilor rezultante se realizează folosind sisteme de inferență de tip Sugeno cu patru intrări și o singură ieșire. Funcțiile de membru ale variabilelor de intrare sunt de tip clopot iar cele de ieșire sunt liniare.

b) Zgomot de tip Gaussian:

O altă metodă de filtrare mediană fuzzy este propusă de [Zih12], acesta este utilizată pentru reducerea zgomotelor de imagine din imaginile CT. Această metodă se poate considera ca și un filtru de difuzie anizotropică generalizată. Funcțiile de membru folosite pentru filtrare sunt descrise de următoarea formulă:

$$g(\nabla f_{i,j}, d_{ij}) = \exp\left(\frac{\nabla f_{i,j}^2}{\beta}\right) \exp\left(\frac{-d_{ij}^2}{2}\right) \quad (2.10)$$

unde $\nabla f_{i,j}$ reprezintă deviația între centrul pixelului i și centrul pixelului adiacent j , d_{ij} este distanța euclidiană între pixelul adiacent j și pixelul i , β reprezintă un parametru de scalare care poate fi calculat folosind următoarea formulă:

$$\beta = \frac{1}{N-1} \sum_{j=1}^N (|\nabla f_{ij}|)^2 \quad (2.11)$$

unde N este vecinătatea pixelului i în spațiul de proiecție.

O valoare mare pentru β indică o regiune neomogenă iar o valoare mică reprezintă o regiune omogenă. După fiecare iterare când $\nabla f_{i,j}$ are o valoare mică, valoarea rezultată pentru funcția de membru este mare, mai precis gradul de apartenență pentru ca centrul pixelului să aparțină de o regiune omogenă este mare. Contrar, dacă valoarea $\nabla f_{i,j}$ este mare, valoarea rezultată pentru funcția de membru este mică și astfel gradul de apartenență pentru ca centrul pixelului să aparțină de o regiune omogenă este mic. În acest context, probabil pixelul aparține de un contur. În acest caz procesul de difuzie este oprit și nivelul de gri al pixelului este păstrat.

Această metodă este folositoare pentru filtrarea zgomotelor în regiunile omogene fără a perturba linia conturului. Totuși în zona conturului zgomotele nu se

pot elimina în totalitate deoarece filtrarea omite zona conturului. Filtrul hibrid fuzzy median nu perturbă intensitățile tonurilor de gri din zonele omogene. La fiecare iterație de difuzie perturbațiile din zonele omogene sunt filtrate iar cele din zonele neomogene sunt neperturbate. Dacă perturbațiile sunt mari acestea sunt generate de vârfuri de zgomote, iar filtrul median va filtra zgomotele datorită sistemului fuzzy care precizează locația pixelului. Dacă perturbațiile sunt create de contururi atunci ele nu vor fi afectate de filtrul median.

Filtrele pentru zgomotul de tip Gaussian se pot extinde folosind sisteme de inferență fuzzy și teoria lui Dempster-Shafer [Tzu2011]. Filtrele create combină sistemele fuzzy de tip mediere (fuzzy averaging) cu un detector de zgomote Dempster-Shafer care are rolul de a determina dacă pixelul analizat este un pixel de zgomot sau nu.

c) Filtrarea zgomotului aditiv

În articolul [Mad2011] se propune eliminarea zgomotului aditiv din imaginea color prin substituirea valorilor de intensitate ale pixelilor din centrul unei subimagine cu valori medii dacă acele valori diferă prea mult de ale vecinilor. Această operațiune se realizează prin execuția mai multor pași iterativi:

- calcularea diferențelor de valoare între un pixel oarecare din imagine și între vecinii lui pentru fiecare componentă de culoare în parte. Se definește o fereastră de $(2K+1) \times (2K+1)$ cu centrul în (i, j) .
- calcularea gradelor de apartenență fuzzy pentru fiecare diferență de valoare din subimaginea dată.

În cazul zgomotului aditiv este important de luat în considerare că zgomotul este prezent pe toată plaja de valori ale pixelilor din subimaginea investigată. Astfel în procesul de restaurare al imaginilor, nu se poate elimina orice valoare de intensitate a pixelilor care sunt deasupra unui prag stabilit empiric, ca și în cazul zgomotelor de tip impuls. Trebuie luată în considerare fiecare valoare prezentă în imagine deoarece poate să aducă informații suplimentare în imagine și informații pentru procesul de restaurare. Astfel fiecărui pixel i se va atașa o pondere non zero care se poate folosi pentru a calcula o medie ponderată. Ponderile sunt calculate în funcție de valorile de apartenență fuzzy care sunt calculate pentru fiecare valoare în parte din subimagine. Pentru calcularea gradului de apartenență se utilizează funcția de membru tip Gaussian, care se exprimă folosind formula matematică:

$$\mu_A^i = e^{\left(\frac{-(x-m_i)^2}{2\sigma_i^2}\right)} \quad (2.12)$$

unde m_i și σ_i sunt centrul și mărimea setului fuzzy.

O funcție de membru de tip Gaussian prezintă următoarele avantaje: este netedă și non-zero în fiecare punct. Utilizând o funcție de membru de tip Gaussian, obținem grade de apartenență nenule, astfel obținem valori pentru fiecare pixel din subimaginea analizată. Valorile diferențelor de intensitate pentru fiecare pixel din subimaginea scanată se calculează folosind formula:

$$\Omega_{i,j,1,r,s} = |C_{i,j,1} - C_{i+r,j+s,1}| \quad (2.13)$$

unde $C_{i+r,j+s,1}$ reprezintă vecinii pixelilor în subimaginea selectată și $r,s \in \{-K, \dots, 0, \dots, +K\}$. Dacă mărimea subimaginii este de 5×5 atunci $r,s \in \{-2, -1, 0, 1, 2\}$. $\bar{\Omega}_{ij,1}$ și $\sigma_{ij,1}$ sunt media și deviația standard a diferențelor de valoare a lui $\Omega_{ij,1,r,s}$.

Pentru a calcula valoarea care exprimă gradul de apartenență a diferenței de valoare $\Omega_{ij,1,r,s}$ se va folosi setul fuzzy *diff*. Dacă diferența de valoare are un grad de apartenență unu în setul fuzzy *diff* atunci diferența este mai aproape de o valoare medie. În cazul în care gradul de apartenență este între zero și unu indică o incertitudine, iar diferența de valoare este mai aproape sau nu de o valoare medie. Valorile gradelor de apartenență pentru fiecare valoare de diferență se pot calcula folosind formula:

$$\mu_{diff(i,j,1,rs)} = e^{-\frac{(\Omega_{i,j,1,r,s} - \bar{\Omega}_{i,j,1})^2}{2\sigma_{i,j,1}^2}} \quad (2.14)$$

Gradele de apartenență $\mu_{diff(i,j,1,rs)}$ calculate se vor folosi pentru a acorda ponderi pentru fiecare pixel din subimaginea analizată.

$$W_{i+r,j+s,1} = \alpha * \mu_{diff(i,j,1,rs)} \quad (2.15)$$

Parametrul de scalare α are rolul de a aloca ponderi mai mari pixelilor care se găsesc pe o poziție a cărei valoare de diferență are un grad de apartenență mai mare. Media ponderată care reprezintă valoarea modificată pentru pixelul central curent se calculează folosind formula:

$$F_{i,j,1} = \frac{\sum_{r=-K}^{+K} \sum_{s=-K}^{+K} W_{i+r,j+s,1} * C_{i+r,j+s,1}}{\sum_{r=-K}^{+K} \sum_{s=-K}^{+K} W_{i+r,j+s,1}} \quad (2.16)$$

F denotă unul din cele trei canale de culoare existente în imaginea color după prima iterație.

Scopul etapei următoare este îmbunătățirea rezultatelor de la partea întâi prin reducerea zgomotelor din componentele de culoare fără a distruge detaliile fine din imagine. Acum diferențele locale din componentele de culoare sunt calculate separat. Aceste diferențe sunt ulterior combinate pentru a calcula valoarea pixelului central și în acest pas se folosește o fereastră de $(2K+1)/(2K+1)$ pentru filtrarea propriu zisă. Diferențele locale pentru fiecare din cele trei componente de culoare sunt calculate folosind:

$$DR_{r,s} = F_{i+r,j+s,1} - F_{i,j,1} \quad r, s \in \{-K, \dots, 0, \dots, +K\}. \quad (2.17)$$

Rezultatele pentru a doua etapă se obțin din formula:

$$F_{i,j,1} = \frac{\sum_{r=-K}^{+K} \sum_{s=-K}^{+K} (F_{i+r,j+s,1} - \varepsilon_{r,s})}{(2K+1)^2} \varepsilon_{r,s} = 1/3 * (DR_{r,s} + DG_{r,s} + DB_{r,s}) \quad (2.18)$$

Pentru reducerea zgomotelor din imaginile de ultrasunete Doppler s-a propus utilizarea unui filtru folosind o rețea neuronală fuzzy adaptivă [Ube10]. Rețeaua neuronală are rolul de a elimina componentele de zgomot introduse de mișcarea peretelui abdominal și de o componentă numită "clutter" care apare ca și o

frecvență mică de mare magnitudine suprapusă semnalului util. Sistemul de inferență fuzzy folosit este de tip Sugeno și are rolul de a extrage semnalul util din semnalul distorsionat. Acesta se realizează folosind un set de 90 de reguli și funcții de membru tip clopot.

2.3 Sisteme cu inferență fuzzy folosite pentru segmentare

Algoritmii care utilizează pentru segmentarea imaginilor logica fuzzy se pot clasifica în următoarele categorii:

1. Gruparea fuzzy sau clustering fuzzy: acest tip de algoritmi pot fi folosiți pentru a forma segmente de imagine, grupând pixelii ce respectă un criteriu de similitudine. Funcția de apartenență a pixelilor la o clasă poate fi interpretată ca și măsura compatibilității cu acel criteriu.
2. Algoritmii bazați pe reguli: conduc la o segmentare a imaginii bazată pe reguli de tip *IF-THEN*. Astfel se poate construi o bază de reguli care să grupeze pixelii în funcție de nivelul de gri al pixelului și în funcție de nivelul de gri al vecinilor.
3. Algoritmi bazați pe interpretarea fuzzy a informației: astfel se pot defini entropii sau divergențe fuzzy care pot fi folosite pentru a segmenta imaginea prin fixarea unei praguri pentru histogramă.

a) Algoritmii de clustering fuzzy:

Algoritmul de clustering fuzzy c-means este cel mai utilizat pentru segmentarea imaginilor medicale [Sel12] [Sai12] și se bazează pe minimizarea iterativă a funcției:

$$J(U, V) = \sum_{j=1}^c \sum_{k=1}^n u_{ik}^m |x_k - v_i|^2 \quad (2.19)$$

unde $x_1 \dots x_n$ sunt vectorii ai setului de antrenare, $v_1 \dots v_c$ sunt centroizii partițiilor și $U = [u_{ik}]$ este o matrice de tip $c \times n$ în care u_{ik} este valoarea de apartenență a vectorului x_k la partiția i .

Funcția $J(U, V)$ reprezintă suma pătratelor distanțelor Euclidiene dintre fiecare vector și centrul partiției corespunzătoare acelui vector. Pentru calculul unei partiții toți vectorii sunt luați în considerare. Pentru fiecare vector, valoarea de apartenență la fiecare clasă depinde de distanța la centroidul corespunzător. Factorul de pondere m reduce influența valorilor de apartenență mici. Cu cât m este mai mare cu atât se reduce influența vectorilor cu valori de apartenență mici.

Algoritmul fuzzy c-means este un algoritm iterativ cu următorii pași:

1. Se inițializează $U^{(0)}$ cu valori pe baza unei aproximări, se inițializează $V^{(0)}$ și se calculează $U^{(0)}$. Se inițializează numărul de iterații a și se alege ponderea m .
2. Se calculează centroizii partițiilor. Pentru $U^{(a)}$ dat se calculează $V^{(a)}$ folosind formula:

$$v_i = \frac{1}{\sum_{k=1}^n u_{ik}^m} \sum_{k=1}^n u_{ik}^m x_{ik} \quad i=1,2,\dots,c \quad (2.20)$$

3. Se actualizează valorile de apartenență. Pentru $V^{(a)}$ dat se calculează $U^{(a)}$ folosind formula:

$$u_{ik} = \frac{\left[\frac{1}{|x_k - v_i|^2} \right]^{\frac{1}{m-1}}}{\sum_{j=1}^c \left[\frac{1}{|x_k - v_j|^2} \right]^{\frac{1}{m-1}}} \quad i=1,2,\dots,c; \quad k=1,2,\dots,n \quad (2.21)$$

4. Se oprește iterația dacă $\left| u_{ik}^{(\infty)} - u_{ik}^{(\infty-1)} \right| \leq \varepsilon$; altfel se trece la iterația următoare și se reia algoritmul de la pasul 2. ε este o valoare predefinită care prezintă cea mai mică modificare acceptabilă pentru valorile lui U.

Astfel la finele ultimei iterări s-au obținut segmentele de imagine grupate corespunzător. Dar acest algoritm este fiabil doar în anumite condiții ideale. Astfel s-au adus mai multe îmbunătățiri pentru a oferi o segmentare cât mai fiabilă.

Una dintre îmbunătățirile propuse este substituirea distanței Euclidiene cu funcții de tip kernel pentru definirea proprietăților spațiale, o altă modificare este reprezentată de folosirea entropiei Tsallis [Kan12] pentru segmentarea imaginilor de rezonanță magnetică nucleară. În algoritmul propus s-a integrat o funcție kernel de tip Gaussian radial basis function [Mul01] iar ecuația devine:

$$J(U, V) = 2 \sum_{k=1}^n \sum_{i=1}^c u_{ik}^m (1 - K(x_k, v_i)) \quad (2.22)$$

O altă modificare adusă metodei este modul în care se inițializează algoritmul. Astfel se implementează un algoritm special pentru inițializarea centroizilor din clustere [Kan10] În locul inițializărilor aproximative inițializarea se rezolvă în patru pași:

1. Se sortează m_i în ordine crescătoare unde m_i este $m_i = (1/p) \sum_{s=1}^p x_{is}$, $i=1,2,\dots,N$ pentru $X = \{X_1, X_2, \dots, X_N\}$ date de p dimensiuni.
2. Se rearanjează matricea de date încât să obținem $X' = [X'_1, X'_2, \dots, X'_N]$. Datele se partiționează în r ($r=(N/C)$) grupe unde C este numărul de partiții ($1 < C < N$), încât grupul de date $(j-1)$ să conțină datele $(j-1)$ din matricea de date X' .
3. Se realizează tabele de decizii (pentru fiecare grup în parte) care indică distanțele inter-elementare între elementele unui grup de tipul $j = [x_{1j}, x_{2j}, \dots, x_{Nj}]$.
4. Din fiecare tabel de decizie se selectează valoarea maximă. Se calculează valoarea medie M_j între elementele maximele din tabelele grupului j . Valoarea M_j este alocată ca și centru pentru clusterul j .

Algoritmul de bază pentru segmentarea de tip fuzzy c-mean devine:

1. Se alege imaginea pentru segmentare
2. Se selectează numărul inițial de clustere și se inițializează prototipurile folosind algoritmul de inițializare a centroizilor.
3. Se inițializează matricea de partiții:

$$u_{ik} = \frac{\left(\frac{1}{2(\beta - K(x_i, v_j)) + \left(\frac{\alpha_i}{\gamma} - 1\right)}\right)^{\frac{1}{\gamma} - 1}}{\left[1 / \sum_{j=1}^c \left(2(\beta - K(x_i, v_j)) + \left(\frac{\alpha_i}{\gamma} - 1\right)\right)\right]^{\frac{1}{\gamma} - 1}} \quad (2.23)$$

4. Se calculează centrozii clusterelor:

$$v_k = \frac{\sum_{i=1}^n u_{ik}^{\gamma} x_i}{\sum_{i=1}^n u_{ik}^{\gamma}} \quad k = 1, 2, \dots, c \quad (2.24)$$

5. Se repetă pasul 3 și 4 până la satisfacerea condițiilor de oprire:

$$\|V(\text{present}) - V(\text{previous})\| < \varepsilon, \quad (2.25)$$

unde $V(\text{present})$ și $V(\text{previous})$ sunt vectorii prototipurilor de clustere la iterația curentă și anterioară.

O altă modificare propusă pentru îmbunătățirea algoritmului de segmentare fuzzy c-mean este eliminarea componentei de spațiu [Ram11]. Pentru a reduce numărul de iterații s-a propus inițializarea componentei centroid folosind algoritmul *dist-max* înainte de a începe iterația algoritmului. Pentru a crește robustețea algoritmului de segmentare s-a propus introducerea unui câmp de "compensare" pentru a compensa intensitățile de neomogenitate introduse de bobinele de inducție. Această neomogenitate induce în eroare metodele de clasificare producând clasificări eronate și suprapuneri de țesuturi. Astfel ecuația principală devine:

$$J(U, V, \beta) = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m \|y_k - \omega_k \beta_k - v_i\|^2 + \check{x} \left(1 + \sum_{i=1}^c u_{ik}^m\right) \quad (2.26)$$

unde $\check{x} = \frac{\sum_k y_k}{n}$, u_{ik} este gradul de apartenență, v_i este centrul clusterului curent și

β_k este compensarea pentru intensitățile de neomogenitate.

Rularea algoritmului se va modifica în felul următor:

1. Se selectează numărul de clustere dorite și se inițializează centrozii clusterelor folosind algoritmul *dist-max*. Se acordă valori foarte mici pentru $\{\omega_k\}_{k=1}^n$ și $\{\beta_k\}_{k=1}^n$.
2. Se calculează funcțiile de apartenență folosind formula:

$$u_{ik}^* = \sum_{j=1}^c \left(\frac{\left(\|y_k - \omega_k \beta_k - v_i\|^2 + \check{x}\right)^{1/m-1}}{\left(\|y_k - \omega_k \beta_k - v_j\|^2 + \check{x}\right)^{1/m-1}} \right)^{-1} \quad c = \text{numărul de clustere alese}, m=2 \quad (2.27)$$

3. Se calculează centrozii clusterelor folosind:

$$v_i^* = \frac{\sum_{k=1}^n u_{ik}^m (y_k - \omega_k \beta_k)}{\sum_{k=1}^n u_{ik}^m} \quad (2.28)$$

4. Se calculează componenta de neomogenitate:

$$\beta_k^* = \frac{1}{\omega_k} \left(y_k - \frac{\sum_{i=1}^c u_{ik}^m v_i}{\sum_{i=1}^c u_{ik}^m} \right) \quad (2.29)$$

5. Se repetă pașii 2-4 până se îndeplinește condiția de finalizare al algoritmului. Condiție care constă din: $\|u_{ik}^{(t+1)} - u_{ik}^{(t)}\| < \varepsilon$ unde $\|\cdot\|$ este o normă Euclidiană și ε este un număr care se setează la începutul procesului de segmentare.

Algoritmul dist-max se va inițializa la începutul segmentării urmărind pașii următori:

1. Se sortează în ordine ascendentă m_i unde $m_k = \frac{1}{p} \sum_{s=1}^p x_{ks}$, $k = 1, 2, \dots, n$ pentru date $X = \{x_1, x_2, \dots, x_n\}$ de date de p dimensiuni.
2. Se reorganizează matricea de date $X' = [x'_1, x'_2, \dots, x'_n]$. Datele se împart în $t(n/c)$ grupe unde c este ($1 < c < n$) numărul de clustere, predefinite, astfel încât grupul de date $(j-1)$ să conțină datele $(j-1)$ din matricea de date X' .
3. Se calculează matricea de date între elementele fiecărui grup creat. Astfel matricea de date pentru grupul $i = [x'_1, x'_2, \dots, x'_N]$ devine $[d_{kj}^i]_{N \times N}$.
4. Se selectează cea mai mare distanță din fiecare grup în parte. Dacă d_{kj}^i este distanța maximă a grupului k atunci se va căuta valoarea medie M_i a elementelor x_i și x_j . Pentru centrul clusterului i se alocă valoarea M_i .

Multe alte modificări au mai fost aduse acestui algoritm popular și performant [Hui09]. Algoritmul fuzzy c-mean surclasează restul metodelor de segmentare care folosesc sistemul de inferență fuzzy. O segmentare bună poate face diferența între o analiză reușită și una eronată a imaginilor medicale. După ce imaginile au fost segmentate, obiectele găsite vor fi supuse unor analize pentru a fi identificate. Obiectele conțin semne care sunt folosite nu doar pentru identificarea lor ci și pentru identificarea patologiilor existente.

2.4 Postprocesarea fuzzy a imaginilor

Postprocesarea imaginilor presupune procesarea segmentelor de imagine în scopul identificării diferitelor semne care la rândul lor permit identificarea obiectelor. Postprocesarea fuzzy presupune folosirea sistemelor de inferență fuzzy în acest scop.

În articolul [Han10] se propune o modalitate de clasificare a țesuturilor combinând segmentarea de tip fuzzy c-mean cu cunoștințe medicale asupra proprietăților geometrice ale țesuturilor investigate. Sistemul este alcătuit din mai multe nivele: inferior, intermediar și superior. Nivelul inferior are rolul de a crea baza de cunoștințe și de a achiziționa de la utilizatori cunoștințele medicale referitoare la imaginea investigată. Nivelul intermediar are rolul de a transforma cunoștințele medicale în reguli de inferență. Nivelul superior are rolul de a controla aplicarea regulilor. Astfel regulile cu prioritate mai mare vor fi aplicate înaintea regulilor cu prioritate mai mică.

Nivelul inferior are rolul de a achiziționa datele necesare pentru crearea regulilor de inferență și de a le introduce în baza de cunoștințe. Această bază de cunoștințe este compusă din șase elemente: poziția relativă între țesuturi, relația de vecinătate între țesuturi, mărimea țesuturilor, numărul de componente conectate între ele, țesuturi ca nivele de gri asemănătoare și forma anumitor țesuturi.

Nivelul intermediar are rol dublu, de a formaliza proprietățile geometrice prezentate și de a crea regulile de inferență. Bazat pe proprietățile formalizate prezentate se creează o regulă pentru fiecare proprietate, astfel fiecare clasă obținută în urma segmentării va avea o valoare semantică atașată.

Formalizarea proprietăților geometrice se face pentru fiecare tip de imagine în parte și înaintea procesului de evaluare se stabilește numărul de țesuturi existente în imagine. Formalizarea proprietăților se realizează prin stabilirea:

(a) poziției relative între țesuturi:

$$PR = \{ _A, T_i, T_j \mid i, j \in \{1, \dots, n\} \text{ and } T_i \neq T_j \}$$

unde A este atributul între două țesuturi și $A \in \{deasupra, sub, st\u00e2nga, dreapta, interior, exterior, \text{ și combina\u0219iile posibile}\}$. De exemplu " $\langle interior, \text{ țesut}_1, \text{ țesut}_2 \rangle$ " înseamnă că țesutul 1 este în interiorul țesutului 2.

(b) relației de vecinătate între țesuturi care este reprezentată de o matrice $n \times n$ ca și $NT = \{nt_{ij} \mid i, j \in \{1, \dots, n\}\}$ unde nt_{ij} sunt elementele de pe poziția (i, j) din matricea $n \times n$. Dacă țesutul i și țesutul j sunt vecini $nt_{ij} = 1$, altfel $nt_{ij} = 0$.

(c) listei țesuturilor care conțin o singură componentă, țesuturile fiind ordonate în funcție de mărimea ariei. $LTA = (Ti_1, Ti_2, \dots, Ti_q)$ unde aria $(Tij) > arie(Tik)$ for $j < k, i, j \in \{1, \dots, n\}$.

(d) numărului de componente în țesuturile investigate. $NC = \{ \langle Ti, nci \rangle \mid i \in \{1, \dots, n\} \}$ unde nc_i este numărul de componente din țesutul T_i .

(e) grupării țesuturilor în funcție de nivelul de gri. $GT = \{GT_i \mid i \in \{1, \dots, p\}\}$ unde p reprezintă numărul total al nivelelor de gri existente în imagine.

(f) setului de forme pentru țesuturile cu o singură componentă $ST = \{ \langle Ti, Si \rangle \mid i \in \{1, \dots, n\} \}$ și $Si \in \{triunghi, cerc, p\u00e2trat, \text{ etc.}\}$. Aceste proprietăți sunt stocate în structuri de date predefinite în matrici bidimensionale. Pe lângă proprietățile prezentate mai sus se iau în considerare încă trei proprietăți: rezultatul segmentării, stadiul în care se află clasificarea țesutului și țesuturile deja clasificate.

(g) rezultatului segmentării care se obține folosind un algoritmul fuzzy c-mean. Structura de date este sub forma unei matrici $n \times m$ care are o m\u00e2rime identică cu imaginea medicală. Înainte de segmentare pentru fiecare tip de țesut se alocă un identificator. După segmentare fiec\u00e2rui pixel îi este alocat un identificator în funcție de apartenența la un tip de țesut. Astfel matricea va conține identificatorii de țesut pentru fiecare din pixelii imaginii medicale.

(h) stadiului de clasificare a fiec\u00e2rui pixel. Structura de date este o matrice binară de forma $1 \times n$ unde n este numărul maxim de țesuturi prezente în imagine. Pentru țesuturile clasificate se acordă 1 iar pentru țesuturile neclasificate se acordă 0.

(i) țesuturilor deja clasificate care au o structură de matrice $n \times m$ care este identică cu m\u00e2rimea imaginii. În momentul în care un țesut oarecare este clasificat se acordă un clasificator pentru fiecare pixel din cadrul țesutului. Acești clasificatori sunt introduși în matrice la locurile corespunzătoare pixelilor care compun segmentul de țesut. Folosind algoritmul de segmentare Fuzzy C-Means, în general obținem câteva țesuturi într-o clasă segmentată și diferite clase pentru un tip de

țesut. Un sistem fuzzy ghidat de cunoștințe obținute la nivelul inferior va despărți clasele de pixeli în țesuturi. Pentru a despărți clasele în țesuturi și pentru a asocia valori lingvistice claselor de pixeli se definesc următoarele reguli:

- (Regula 1) Extragerea fundalului imaginii: Fundalul este singurul obiect din imagine care are o singură componentă și 4 conectări la marginile imaginii.
- (Regula 2) Poziția relativă a țesuturilor: dacă pentru fiecare țesut T_i (țesut identificat) există o relație de poziționare cu un singur țesut T_j (țesut neidentificat) și dacă nivelul de gri diferă între cele două țesuturi atunci țesutul T_j se poate identifica.
- (Regula 3) Vecinii țesuturilor: pentru fiecare țesut neidentificat T_j , dacă toate țesuturile au fost identificate, atunci țesutul T_j se poate identifica folosind analiza de conectivitate raportată la țesuturile învecinate.
- (Regula 4) Țesuturile cu o singură componentă: acestea sunt ordonate în ordine descrescătoare în funcție de aria țesutului. Astfel în orice grup cu țesuturi care au nivelul de gri asemănător (GT_i) un țesut oarecare nu se poate identifica. Se pot ordona clasele neidentificate în funcție de arie și se realizează o echivalență cu țesuturile neidentificate din baza de cunoștințe.
- (Regula 5) Numărul de componente din țesut: dacă există un număr specific de componente într-o clasă unică neidentificată și numărul de țesuturi nealocate este 1, atunci țesutul este echivalent cu clasa neidentificată.
- (Regula 6) Grupurile de țesuturi cu un nivel de gri asemănător: dacă din grupul țesuturilor cu un nivel de gri (GT_i) asemănător obținut de procesul de segmentare există doar un singur tip de țesut care nu a fost identificat, atunci se poate identifica prin eliminarea grupurilor de pixeli deja clasificați.
- (Regula 7) Forma țesuturilor cu o singură componentă: dacă pentru fiecare formă există doar un singur țesut neidentificat și există doar o singură clasă neidentificată, atunci clasa este echivalentă cu țesutul neidentificat.

Clasificarea claselor în țesuturi se realizează aplicând iterativ cele șapte reguli. Pentru a optimiza clasificarea sunt definite priorități. Regula cu cea mai mare prioritate va fi executată la început. Prioritățile regulilor sunt create în conformitate cu numărul de premise. Astfel prioritate maximă au regulile cu puține premise și prioritate minimă au regulile cu multe premise. Prioritățile regulilor se pot acorda și în funcție de numărul de variabile numerice prezente. Regulile cu mai puține variabile au prioritate față de regulile cu mai multe variabile.

2.5 Concluzii

Prelucrarea imaginilor medicale se poate împărți în trei etape prezentate în figura 2.3: preprocesarea, procesarea și postprocesarea imaginilor. Preprocesarea imaginilor are rolul de a pregăti imaginile pentru procesul de segmentare.




Figura 2.3 Stagiile de procesare ale imaginilor medicale.

Cele mai frecvente contaminări ale imaginilor sunt create de zgomotele de imagine. Aceste zgomote sunt de diferite feluri. Cele mai frecvente zgomote care apar în imagine sunt cele de tip impuls, Gaussian, multiplicativ și de frecvență.

Zgomotul aleator sau de impuls apare în momentul în care senzorul de captare codifică imagini supra sau sub saturate și valorile pixelilor sunt peste limita maximă a senzorului sau sub limită. Pentru reducerea zgomotului de impuls s-au utilizat filtrele de tip median extinse cu sisteme de inferență fuzzy. Filtrele mediane clasice și adaptive pot fi îmbunătățite astfel:

- Introducerea unei baze de reguli pentru identificarea pixelului zgomotos dintr-o subimagine [Pal12].
- Implementarea unei rețele neuronale pentru eliminarea pixelului zgomotos [Abd07], [Lei10].
- Identificarea zgomotului utilizând informații spațio-temporale [Tom11].
- Filtrarea imaginilor utilizând metode de tip celular automata [San12].
- Recombinarea a patru imagini identice rotite la 90 grade, folosind sisteme de inferență fuzzy [Yak10].
- Utilizarea unui sistem fuzzy pentru detecția pixelilor zgomotoși [Yue10], [Cho12], [Biz11].
- Implementarea unui filtru fuzzy de tip 2 pentru identificarea și reducerea zgomotelor din imaginile zgomotoase [Yuk12].

Zgomotul Gaussian se manifestă prin variațiuni mici datorită erorilor de cuantificare în momentul digitalizării imaginii. Filtrarea imaginilor contaminate cu acest tip de zgomot se poate realiza aplicând următoarele metode:

- Implementarea unui sistem de filtrare mediană folosind sisteme cu inferență fuzzy de mediere care se bazează pe teoria lui Dempster-Shafer.
- Folosirea unui filtru anizotrop general extins cu un sistem cu inferență fuzzy.

Zgomotul multiplicativ și aditiv este rezultatul multiplicării unui semnal de zgomot cu semnalul imaginii. Zgomotul multiplicativ și aditiv se poate elimina prin:

- Folosirea unui filtru median extins cu sisteme cu inferență fuzzy pentru eliminarea zgomotului aditiv.
- Folosirea unui filtru adaptiv construit dintr-o rețea neuronală pentru eliminarea zgomotelor induse de mișcările peretelui abdominal, în imaginile de ultrasonografie.

Segmentarea imaginilor presupune separarea obiectelor din imagine de fundalul imaginii. Au fost propuse mai multe metode de segmentare care folosesc sisteme cu inferență fuzzy. Aceste metode sunt: clustering fuzzy, algoritmi bazați pe reguli fuzzy, algoritmi bazați pe interpretarea fuzzy a informației. Dintre acestea cea mai utilizată este metoda prin clustering fuzzy. Această metodă prezintă cea mai bună robustețe față de zgomotele de imagine slab filtrate. Cele mai noi modificări aduse acestui algoritm sunt:

- Substituirea distanței Euclidiene cu funcții de tip kernel pentru definirea proprietăților spațiale și folosirea entropiei Tsallis [Kan12].
- Inițializarea centroizilor prin algoritmul *dist-max* [Ram11].

- Combinarea algoritmului c-means cu algoritmul k-mean [Sel12], [Bal11], [Bos12], [Tah12].
- Utilizarea proprietăților de textură pentru segmentarea fuzzy c-mean [Xiu11].
- Extinderea metodei folosind multiple funcții kernel [Yug12].
- Combinarea pragurilor de histogramă setate dinamic cu metoda fuzzy c-mean [Sai12].
- Aplicarea sistemelor genetice pentru îmbunătățirea metodelor fuzzy c-mean [Myl12], [Lei12].

Alte sisteme pentru segmentarea imaginilor medicale care utilizează sisteme fuzzy sunt:

- Un sistem de segmentare bazat pe identificarea densităților de tip Gaussian combinat cu inferență fuzzy [Zex12].
- Un sistem fuzzy pentru aproximarea parametrilor unui sistem de segmentare bazat pe câmpuri Markov multidimensionale [Zhe12].
- Sisteme de segmentare care utilizează date frecvențiale și spațiale implementându-se astfel metode de tip „multihpase fuzzy region competition” [Cho11].
- Sisteme de inferență bistagiare pentru detectarea globulelor roșii din sânge utilizând proprietăți discriminative (forma și textura) [Moh11].
- Sisteme de segmentare bazate pe reprezentarea cunoștințelor folosind sistemele de inferență fuzzy [Cos06] [Cos05].

Sistemele de segmentare permit separarea segmentelor de imagine care conțin obiecte de interes de fundalul imaginii. Aceste obiecte pot fi identificate utilizând sistemul [Hang10] sau vizual de către medici, care se bazează pe un sistem neuronal biologic complex antrenat pe parcursul carierei.

După studierea literaturii de specialitate am remarcat lipsa studiilor efectuate asupra postprocesării imaginilor medicale folosind algoritme fuzzy pentru identificarea semantică a posibilelor patologii.

Obiectivele științifice ale acestei teze, raportate la stadiul actual al cercetărilor din domeniu se pot rezuma astfel:

1. Realizarea unui algoritm de interpretare bazat pe inferență fuzzy pentru imaginile medicale. Pentru ca acest algoritm să fie compatibil cu majoritatea imaginilor medicale va avea următoarele proprietăți:
 - Să fie compatibil cu majoritatea tipurilor de imagini medicale realizate după standardul DICOM.
 - Să utilizeze (după caz) date obținute direct din segmentele de imagine: formă, mărime, histogramă și locație.
 - Să utilizeze diverse metadate prezente în secțiunea de TAG-uri DICOM.
 - Să permită definirea și implementarea rapidă a algoritmilor fuzzy fără utilizarea editoarelor specializate.
2. Realizarea generării regulilor de inferență fuzzy folosind algoritmi genetici cu următoarele proprietăți minimale:
 - Cromozomul să codifice denumirea variabilelor lingvistice și denumirea seturilor fuzzy.
 - Să furnizeze o acoperire de 100% a seturilor de învățare.

Schema prezentată mai jos sintetizează o parte din metodele folosite în cele trei stagii ale imagisticii medicale și prezintă magnitudinea la care sunt efectuate cercetările.

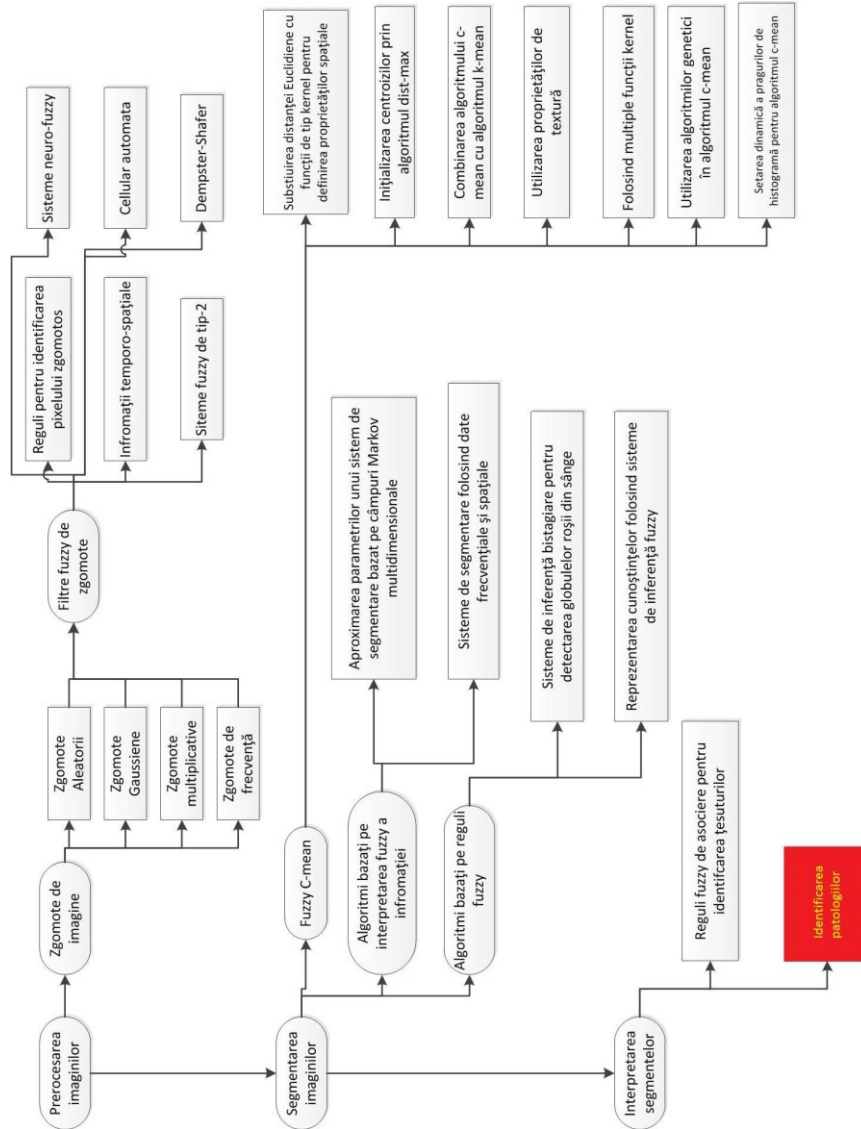


Figura 2.4 Metode de imagistică medicală cu sisteme de inferență fuzzy.

Obiectivele propuse în teză au rolul de a reduce lacunele de cercetare din domeniul abordat. Capitolul următor propune o nouă reprezentare a sistemelor cu inferență fuzzy în fișiere XML. Capitolul patru și cinci prezintă metodele propuse pentru realizarea obiectivelor științifice. S-au realizat programe noi în care au fost implementate metodele de la capitolele patru și cinci. Au fost realizate experimente (capitolul 7) pentru a susține viabilitatea metodelor propuse.

3. Sisteme cu inferență fuzzy

Pentru formularea unui diagnostic medical folosind sisteme informatice este necesară obținerea datelor numerice care descriu obiectele prezente în imagine. Datelor numerice obținute li se vor atașa etichete lingvistice care descriu, folosind limbajul natural, proprietățile obiectelor din imaginea respectivă [Zad65]. Procesul de formulare al unui diagnostic constă în analiza etichetelor asociate datelor numerice. Sistemul informatic care acordă etichetele lingvistice datelor numerice și analizează aceste etichete se numește sistem de inferență fuzzy. Analog, etichetele lingvistice asociate unei proprietăți a segmentului de imagine, se numesc etichete fuzzy sau set-uri fuzzy.

3.1 Sistemul simplu cu inferență fuzzy

Setul clasic de date este definit de logica clasică booleană. Într-un set clasic un obiect oarecare aparține sau nu setului dat. Funcția de membru are rolul de a returna 1 în cazul în care obiectul face parte din setul definit sau 0 în cazul în care nu face parte din acel set. Metoda fuzzy extinde setul clasic prin a permite funcției de membru $F(x)$ să returneze o valoare în domeniul $[0,1]$. O valoare oarecare x , poate aparține unui set într-o măsură definită ca și grad de apartenență. Operatorii fuzzy pot efectua uniuni, intersecții și complementări. Acești operatori sunt echivalenți operatorilor lingvistici 'ȘI', 'SAU', respectiv 'NU' pentru negație. Operatorul 'ȘI' se poate calcula folosind funcția clasei TNorm. Un operator comun ȘI poate fi minimul dintre cele două funcții de membru. Pentru operatorul SAU se poate folosi maximul dintre cele două funcții de membru, care reprezintă o funcție din clasa TConorm.

Variabilele lingvistice reprezintă datele folosite de sistemele cu inferență fuzzy. Ele conțin cuvinte, colecții de cuvinte care descriu diverse proprietăți în locul valorilor numerice. Aceste cuvinte reprezintă o colecție de seturi fuzzy. Fiecare set fuzzy reprezintă o valoare lingvistică care este atribuită unei valori numerice. În general seturile fuzzy se numesc și etichete fuzzy.

Regulile de inferență fuzzy sunt de tipul *IF-THEN* și sunt foarte similare cu comunicarea lingvistică naturală [Per10]. Acestea se pot compara cu niște instrucțiuni clare care provin de la o persoană către o altă persoană. În forma lor generală regulile fuzzy au o antecedentă și o consecință separate de declarația „*THEN*”. Antecedenta este o conjuncție de mai multe clauze fuzzy (folosind declarația *IS*) și operatorii corespunzători (*AND*, *OR*, *NOT*). În figura 3.1 este prezentată arhitectura sistemului cu inferență fuzzy folosit pentru interpretarea obiectelor din imaginea medicală.

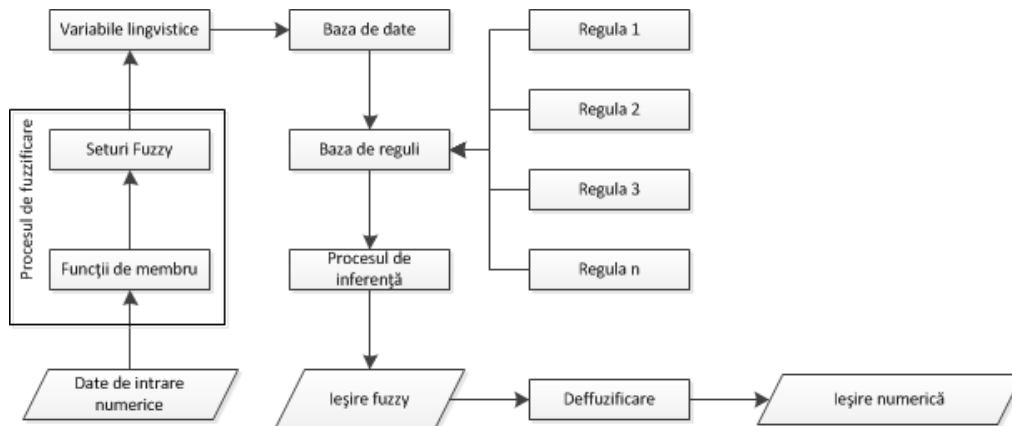


Figura 3.1 Structura logică al sistemului fuzzy.

Consecința regulii fuzzy este reprezentată de acțiunea care trebuie executată de sistem dacă antecedentele sunt valide în orice grad de apartenență. Sistemele fuzzy în general au încorporate un set de reguli fuzzy care reprezintă comportamentul sistemului. Aceste reguli sunt introduse într-o bază de reguli. Variantele extinse ale sistemelor de inferență fuzzy sunt sistemele de tip MIMO și cu inferență silogistică [Lia05], [Wan04], [Kor00], [Wan98]. Sistemele fuzzy se pot implementa cu ușurință în orice sistem, fie hardware fie software. Există o multitudine de aplicații software în domeniul medical pentru a infera un diagnostic sau a manipula numeric imaginea [Ben06], [Ala07], [Inn 04], [Zen08], [Cho08].

În cazul nostru sistemul fuzzy este folosit pentru a deduce un diagnostic. Acesta este posibil doar dacă se iau în considerare următoarele proprietăți care descriu obiectul investigat: forma obiectului, histograma, mărimea și poziția subimaginii în imagine. Dar folosind doar aceste valori nu vom obține un rezultat concret deoarece valorile menționate mai sus sunt influențate în special de tipul imaginii medicale sau datele demografice ale pacientului. Dacă oțitem să luăm în considerare aceste informații care sunt prezente în TAG-uri, atunci riscăm să inferăm un diagnostic greșit. De exemplu: mărimea unui organ diferă de la o vârstă la alta. Dacă mărimea unui organ are valoarea x , atunci această valoare poate fi patologică sau nu. Pentru un copil care are o vârstă între 3 și 5 ani, există o valoare x fiziologică dar aceasta devine patologică pentru un adult.

Sistemele cu inferență fuzzy având o aplicabilitate multilaterală se pot folosi în multe procese de calcul. Ele se pot integra în mai multe tipuri de sisteme informatice: în industrie, în cercetare cât și în medicină. Integrarea sistemului cu inferență fuzzy în sistemele informatice se realizează prin introducerea unor aplicații specifice în sistemul informatic. Acestea conțin metode de fuzzyficare, baza de reguli și metoda de inferență. Această metodă de integrare creează și un impediment referitor la portabilitatea sistemelor cu inferență fuzzy. Astfel portabilitatea sistemului sau doar schimbarea elementelor din sistemele cu inferență fuzzy introduse într-un sistem informatic presupune rescrierea codului sursă. Pentru a evita rescrierea și recompilarea codului sursă care implementează sistemul de inferență fuzzy, se propune o reprezentare a structurii sistemului fuzzy în format XML.

3.1.1 Sisteme cu inferență fuzzy paralele

Teoria de control fuzzy a fost implementată cu succes în multe domenii ale ingineriei. Strategia de control a fost adaptată în special pentru sistemele SISO, în pofida efectelor de cuplare dinamică a sistemelor de control de tip MIMO [Lia05].

În consecință dificultatea în controlul sistemelor de tip MIMO stă în rezolvarea efectelor de cuplare între gradele de libertate. Pentru a surmonta dezavantajul controlerelor utilizate în sistemele de tip MIMO se propune încorporarea unui controler fuzzy de cuplare într-un sistem de control fuzzy tradițional a sistemelor MIMO. Astfel se realizează compensarea efectelor de cuplare dinamică între gradele de libertate. Acest controler fuzzy mixt poate înlătura efectele de cuplare a sistemelor.

Dificultatea în aplicarea teoriei de control fuzzy tradițional în controlarea sistemelor MIMO constă în anularea efectelor de cuplare între gradele de libertate. Astfel a fost dezvoltat un controler de cuplare pentru a îmbunătăți performanțele de control ale sistemelor MIMO. Sistemul MIMO tipic se complică datorită incertitudinilor, astfel sunt folosite strategii de control independente de sistem în proiectarea controlerelor sistemelor MIMO.

Strategia de control al sistemelor MIMO include: un sistem tradițional fuzzy și un controler de cuplare. Diagrama de cuplare se observă în figura 3.2.

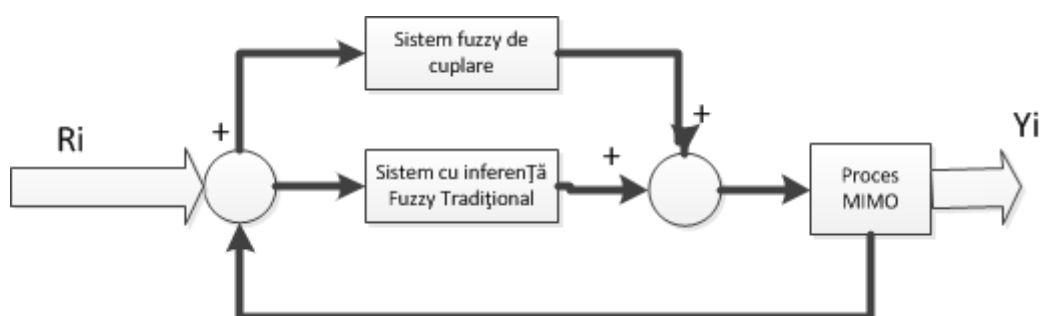


Figura 3.2 Controler fuzzy mixt pentru MIMO [Lia05].

Într-un sistem MIMO ieșirea este influențată de mai multe variabile de intrare:

$$Y_i = P_i(u_1, u_2, \dots, u_m, Y_1, Y_2, \dots, Y_n) \quad (3.1)$$

sau

$$Y_i = P_i(u_i, Y_1, Y_2, \dots, Y_n) \quad (3.2)$$

unde $P_i(\cdot)$ și $P_i(\cdot)$ reprezintă funcții de cuplare complexe care sunt greu de definit și derivat. Conform analizei ecuațiilor dinamice se observă ca u_i este efectul principal și u_j este efectul secundar al ieșirii Y_j . Similar pentru ieșirea Y_i , u_i este efectul principal iar efectul secundar este u_j .

Ieșirea principală a sistemului este controlată folosind un sistem de control fuzzy tradițional. Ieșirea secundară a sistemului de control este controlată de sistemul fuzzy de cuplare. Structura de control a sistemului fuzzy este complexă în situația în care variabila de intrare este multi-graduală iar ieșirea sistemului este mono- sau multi-graduală.

Procesul de proiectare al controlerului de cuplare fuzzy va trebui simplificat încât să reducă încărcarea computațională în timpul implementării. Pentru variabilele de intrare a controlerului de cuplare fuzzy sunt aleși doi factori afectați de cuplare,

pentru a permite crearea regulilor fuzzy corespunzătoare. Totuși, atât variabilele de intrare cât și cele de ieșire depășesc două grade de control al sistemului MIMO. Astfel proiectarea și implementarea controlerului de cuplare devine greoaie. Figura 3.3 prezintă funcțiile de membru ale controlerului de cuplare pentru a permite o compensare mai slabă NB sau una mai puternică PB:




Figura 3.3 Funcții de membru al controlerului de cuplare [Lia05].

Regulile de control fuzzy ale controlerului de cuplare se pot ajusta în funcție de răspunsul sistemului controlat și în funcție de efectele de cuplare între sistemul primar și cel secundar.

Inferența și defuzzificarea sunt similare cu metodele din sistemele fuzzy tradiționale. Pentru fiecare pas există efecte de cuplare diferite, acestea nu au o caracteristică cumulativă. Efectul de cuplare este încorporat în sistemul fuzzy tradițional pentru a crește performanțele și robustețea sistemului.

În consecință toate intrările de control pentru controlul fuzzy mixt se pot reprezenta prin:

$$U_i = u_i + U_{i \rightarrow I}, \quad i \neq I \quad (3.3)$$

unde u_i reprezintă intrarea de control a sistemului tradițional fuzzy de gradul i . U_i reprezintă efectul de cuplare de control de gradul I , care este relativ cu gradul i a controlerului de cuplare fuzzy.

Prin introducerea controlerului de cuplare se compensează efectele necunoscute de cuplare ale sistemelor MIMO. Astfel această strategie de control este independentă de sistemul MIMO controlat.

3.1.2 Raționamentul fuzzy silogistic și sisteme fuzzy în cascadă

În raționamentul silogistic consecința primei reguli apare în premiza următoarei reguli [Wan04]. Astfel de reguli silogistice sunt comune în viața reală. Se prezintă următoarele forme generale pentru regulile silogistice fuzzy:

Stadiul 1:

$$x_1 \text{ is } A_{1,1}^1, \dots, \text{ and } \dots, x_{n1} \text{ is } A_{n1,1}^1 \rightarrow y_{1,1}^{(1)} \text{ is } B_{1,1}^1, \dots, \text{ and } \dots, y_{n2}^{(1)} \text{ is } B_{n2,1}^1 \quad (3.4)$$

$$x_1 \text{ is } A_{1,L1}^1, \dots, \text{ and } \dots, x_{n1} \text{ is } A_{n1,L1}^1 \rightarrow y_{1,1}^{(1)} \text{ is } B_{1,L1}^1, \dots, \text{ and } \dots, y_{n2}^{(1)} \text{ is } B_{n2,L1}^1$$

(3.5)

Stadiul 2:

$$y_1^{(1)} \text{ is } A_{1,1}^2, \dots, \text{ and } \dots, y_{n_2}^{(1)} \text{ is } A_{n_2,1}^2 \rightarrow y_1^{(2)} \text{ is } B_{1,1}^2, \dots, \text{ and } \dots, y_{n_3}^{(2)} \text{ is } B_{n_3,1}^2$$

(3.6)

$$y_1^{(1)} \text{ is } A_{1,L_2}^2, \dots, \text{ and } \dots, y_{n_2}^{(1)} \text{ is } A_{n_2,L_2}^2 \rightarrow y_1^{(2)} \text{ is } B_{1,L_2}^2, \dots, \text{ and } \dots, y_{n_3}^{(2)} \text{ is } B_{n_3,L_2}^2$$
 (3.5)

Analog se pot scrie regulile până la un stadiu M.

Fapt: x_1 este $\overline{A_{1,1}^1}$, ..., și, ..., x_{n_1} este $\overline{A_{n_1,1}^1}$.Consecință: $y_1^{(M)}$ este $\overline{B_{1,LM}^M}$, ..., și, ..., $y_{n_{M+1}}^{(M)}$ este $\overline{B_{n_{M+1},LM}^M}$

unde $A_{i,j}^k, B_{i,j}^k$ ($k=1, \dots, M$; $i=1, \dots, n_k$; $j=1, \dots, L_k$), $\overline{A_{i,j}^k}, \overline{B_{i,j}^k}$ sunt seturi fuzzy și \rightarrow denotă o implicare. $X = [x_1, x_2, \dots, x_m]$ corespunde variabilelor de intrare care apar numai în premiza stadiului 1. Setul intermediar de variabile $Y^{(k)} = [y_1^{(k)}, \dots, y_{n_{M+1}}^{(k)}]$ ($k=1, 2, \dots, M-1$) se regăsește atât în consecința cât și în premiza diferitelor reguli.

Definiție:

Există două reguli fuzzy: dacă x este A și z este B (relații fuzzy $A \rightarrow B$) și dacă y este B' atunci z este C (relații fuzzy $B' \rightarrow C$), unde variabilele lingvistice x, y și z sunt definite în U, V, W , atunci folosind raționamentul silogistic fuzzy, se poate defini o regulă fuzzy:

$$\mu_{A \rightarrow C'}(x, z) = \sup_{\mu \in V} t(\mu_{A \rightarrow B}(x, z), \mu_{B' \rightarrow C}(y, z))$$
 (3.6)

iar μ denotă funcția de membru corespunzătoare, t denotă normele triunghiulare și $\mu_{A \rightarrow B}(x, z)$ se poate regăsi în următoarele forme:

- Implicație Mamdani: $\mu_A(x) \mu_B(y)$ sau $\min(\mu_A(x), \mu_B(y))$
- Implicație Lukasiewicz: $\min[1, 1 - \mu_A(x) + \mu_B(y)]$
- Implicație Dienes-Rescher: $\max[1 - \mu_A(x), \mu_B(y)]$

Folosind definiția 1, maparea intrărilor și a ieșirilor între stagii se poate abrevia într-o formă compactă, de exemplu:

$$\mu_{BM}(Y^{(M)}) = \mu_{A1}(X) \circ R, \quad R = R^1 \circ R^2 \circ \dots \circ R^M$$
 (3.7)

Se poate observa că un sistem fuzzy mono-stagic poate rezolva inferențe fuzzy silogice.

Bazându-ne pe cele prezentate mai sus putem defini un sistem fuzzy cuplat. Sistemul fuzzy cuplat conține un fuzzificator, o bază de reguli silogice, o mașină de inferență silogistică și un defuzzificator. Figura 3.4 ilustrează structura de bază a sistemului fuzzy silogistic. Se poate observa structura ierarhică a sistemului.




Figura 3.4 Controler fuzzy silogistic.

În comparație cu alte sisteme fuzzy silogistice sistemele ierarhice fuzzy [Kor 00], [Wan98] sunt prezentate în figura 3.5 a,b. Primul sistem ierarhic integrează câteva sisteme fuzzy convenționale în paralel, unde fiecare intrare este prelucrată de toate sistemele fuzzy. A doua variantă integrează mai multe sisteme într-o manieră complexă. Se utilizează mai multe variabile de intrare și o variabilă intermediară ca intrare în interiorul ierarhiei.

Sistemele de inferență fuzzy paralele sau cascade sunt utile pentru corelarea mai multor tipuri de date. Pentru realizarea obiectivelor propuse în capitolul 1 vom avea nevoie de mai multe sisteme cu inferență fuzzy, este necesară corelarea metadatelor cu datele directe pentru evitarea unui rezultat fals pozitiv sau fals negativ.

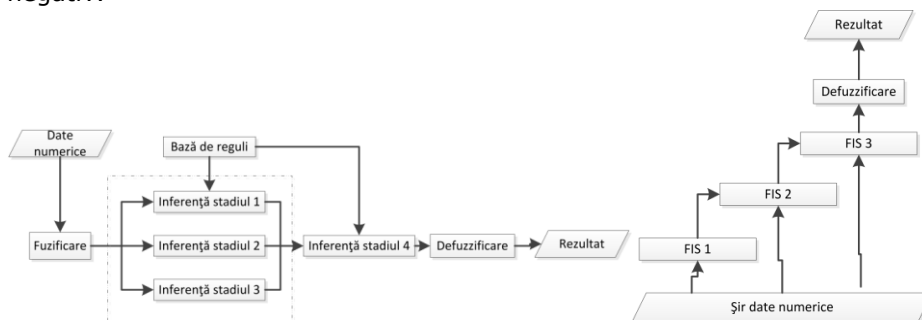


Figura 3.5 a,b Controlere fuzzy ierarhice.

3.2 Reprezentarea sistemelor cu inferență fuzzy

Pentru dezvoltarea sistemelor cu inferență fuzzy cercetătorii au la dispoziție editoare de sisteme cu inferență fuzzy. Aceste unelte permit crearea și definirea seturilor fuzzy, a variabilelor de intrare și ieșire, a funcțiilor de membru, a bazelor de reguli și a altor componente. Editoarele salvează reprezentarea sistemului de inferență creat în formate specifice mediului de dezvoltare.

În acest subcapitol se vor prezenta două editoare cunoscute, similare, dar care salvează sistemul creat în moduri total diferite. Deoarece sistemele cu inferență fuzzy sunt codificate specific mediului în care au fost create, transportarea și implementarea lor directă în alte sisteme decât pentru care au fost create, este dificilă. Astfel s-a pus problema unei codificări universale care să permită integrarea

cu efort minim a sistemului de inferență fuzzy în majoritatea cadrelor de dezvoltare software [Gal11].

3.2.1 Reprezentarea pentru *MatLab*

Acest editor folosește o interfață grafică complexă pentru a permite cercetătorului crearea sistemelor cu inferență fuzzy complexe. Editorul face parte din programul *MatLab*, iar sistemul cu inferență creat se poate integra în diferite simulări. Pe figura 3.6 se poate observa interfața editorului din *MatLab*. Acesta este capabil să creeze reprezentări utilizate în *MatLab* pentru sisteme cu inferență de tip Mamdani sau Sugeno și se pot crea diferite tipuri de funcții de membru, de la trapezoidal până la Gaussian [Mat02].

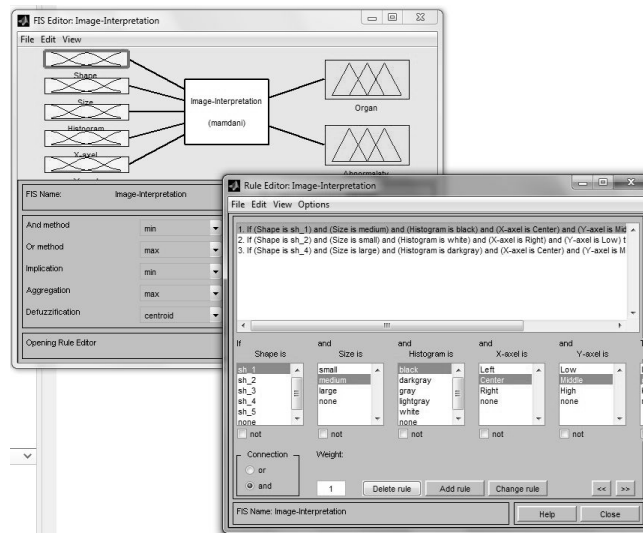


Figura 3.6 Editorul din *MatLab*.

Interfața grafică este echipată cu editor vizual pentru variabilele de intrare și de ieșire, precum și pentru editarea regulilor. Un dezavantaj al acestui editor este că nu permite folosirea mai multor tipuri de operatori logici în antecedentul regulii. Pentru a crea o bază de reguli complexă se vor folosi o multitudine de reguli similare în care doar operatorul logic va fi diferit. Reprezentarea sistemului de inferență creat este exportat într-un fișier txt prezentat în tabelul 3.1.

Tabelul 3.1 Fișierul generat de editorul din *MatLab*.

<pre>[System] Name='Image-Interpretation' Type='mamdani' Version=2.0 NumInputs=5 NumOutputs=2 NumRules=3 AndMethod='min' OrMethod='max' ImpMethod='min'</pre>	<pre>[Input4] Name='X-axel' Range=[0 1] NumMFs=3 MF1='Left':'trapmf',[-0.4 -0.05 0.25 0.4] MF2='Center':'trapmf',[0.2 0.3 0.7 0.8] MF3='Right':'trapmf',[0.6 0.75 1.04 1.36] [Input5]</pre>
---	--

<pre> AggMethod='max' DefuzzMethod='centroid' [Input1] Name='Shape' Range=[0 1] NumMFs=5 MF1='sh_1': 'trapmf',[0 0.1 0.2 0.3] MF2='sh_2': 'trapmf',[0.2 0.3 0.4 0.5] MF3='sh_3': 'trapmf',[0.4 0.5 0.6 0.7] MF4='sh_4': 'trapmf',[0.6 0.7 0.8 0.9] MF5='sh_5': 'trapmf',[0.8 0.9 1 1.1] [Input2] Name='Size' Range=[0 1] NumMFs=3 MF1='small': 'trapmf',[-0.355 -0.0347 0.2 0.4] MF2='medium': 'trapmf',[0.2 0.3 0.7 0.8] MF3='large': 'trapmf',[0.6 0.8 1 1.3] [Input3] Name='Histogram' Range=[0 255] NumMFs=5 MF1='black': 'trapmf',[0 0 45 50] MF2='darkgray': 'trapmf',[35 55 100 115] MF3='gray': 'trapmf',[100 108 150 156] MF4='lightgray': 'trapmf',[150 160 200 215] MF5='white': 'trapmf',[200 211 255 275] </pre>	<pre> Name='Y-axel' Range=[0 1] NumMFs=3 MF1='Low': 'trapmf',[-0.4 -0.045 0.25 0.4] MF2='Middle': 'trapmf',[0.2 0.3 0.7 0.8] MF3='High': 'trapmf',[0.6 0.75 1 1.36] [Output1] Name='Organ' Range=[0 1] NumMFs=3 MF1='liver': 'trapmf',[-0.36 -0.04 0.3 0.3] MF2='gallbladder': 'trapmf',[0.2 0.3 0.7 0.8] MF3='kidney': 'trapmf',[0.7 0.8 1 1.34] [Output2] Name='Abnormalaty' Range=[0 1] NumMFs=3 MF1='Blood': 'trapmf',[-0.346 0 0.2 0.3] MF2='Calcul': 'trapmf',[0.202 0.3 0.7 0.8] MF3='Tissue': 'trapmf',[0.7 0.8 1 1.4] [Rules] 1 2 1 2 2, 2 0 (1) : 1 2 1 5 3 1, 0 2 (1) : 1 4 3 2 2 2, 1 0 (1) : 1 </pre>
--	---

3.2.2 Reprezentarea pentru *FuzzyTech*

Acest software permite crearea sistemelor complexe de inferență fuzzy similar ca și în *MatLab*. Interfața grafică este prezentată în figura 3.7

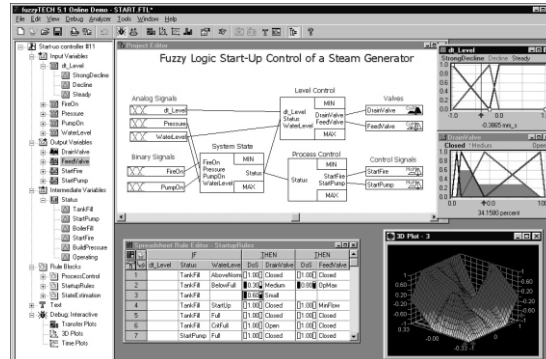


Figura3.7 FuzzyTech GUI.

Acest editor spre deosebire de editorul din *MatLab* exportă sistemul de inferență într-un cod sursă de tip C. Astfel, chiar sistemul cu inferență fuzzy se poate integra prin platforme de programare C/C++ în diferite programe prin hardcodarea codului sursă. După compilarea codului sursă, sistemul de inferență din program nu se mai poate schimba decât prin modificarea și recompilarea codului.

Aceste editoare au anumite lacune cum ar fi: sistemele de inferență create sunt specifice mediului în care au fost dezvoltate și după implementare ele nu mai pot fi editate. Sistemul creat cu editorul din *MatLab* se poate folosi pentru simulări doar în *MatLab*. Pentru implementare ele trebuie definite din nou în mediul de programare. *FuzzyTech* exportă sistemul de inferență într-un cod sursă de tip C/C++. Acesta oferă o compatibilitate mai mare dar nu universală pentru cadrele de dezvoltare software. Totodată, aceste sisteme de inferență după compilare nu mai sunt accesibile. Astfel doar utilizatorii cu abilități avansate de programare mai pot aduce ajustări unui sistem, în vederea îmbunătățirii performanțelor acestuia

3.3 Reprezentarea sistemelor cu inferență fuzzy folosind XML

XML este o metodă de codificare a informațiilor din documente în forme interpretabile și pentru calculatoare [Har99]. S-au efectuat cercetări în privința reprezentării sistemelor fuzzy în XML fiind abordate două metode: o metodă presupune folosirea fișierelor de tip DTD iar a doua metodă se bazează pe schemele XML [Vel07].

3.3.1 Reprezentarea sistemelor fuzzy cu fișiere DTD

DTD este propus [Vel07] pentru a descrie sistemele fuzzy în XML. Un DTD este definit pentru fiecare componentă majoră a sistemului fuzzy. Exemplul de mai jos prezintă componenta 'InputBase' care conține unul sau mai multe elemente de intrare și numărul total al elementelor.

```
<?xml version="1.0" encoding="UTF-8"?>
<!ELEMENT InputBase (Input+, Num_of_inputs)>
<!ATTLIST InputBase
```

3. Sisteme cu inferență fuzzy

```
Name CDATA #REQUIRED
>
<!ELEMENT Input (Linguistic_variable?)>
<!ATTLIST Input
Name CDATA #REQUIRED
>
<!ELEMENT Num_of_inputs (#PCDATA)>
```

Se descriu de asemenea atât funcțiile cât și operatorii predefiniți în fișiere DTD. Fiecare componentă a sistemului fuzzy principal se poate descrie ca și un fișier DTD. Utilizând eticheta <ENTITY> în fișierul DTD, se pot interconecta diferite module DTD în așa fel încât să creeze o schemă DTD XML a întregului sistem fuzzy. Exemplul de mai jos prezintă efectuarea interconectării modulelor DTD. Au fost evidențiate prin îngroșare trimerurile către alte fișiere care conțin date despre componentele sistemului cu inferență fuzzy.

```
<?xml version="1.0" encoding="UTF-8"?>
<ENTITY % InputBase SYSTEM "InputBase.dtd">
<ENTITY % RuleBase SYSTEM "RuleBase.dtd">
<ENTITY % InferenceEngine SYSTEM "InferenceEngine.dtd">
<ENTITY % DefuzMethod SYSTEM "DefuzMethod.dtd">
<ENTITY % OutputBase SYSTEM "OutputBase.dtd">
<ENTITY % Operator_Repository SYSTEM "Operator_Repository.dtd">
<ENTITY % MF_Repository SYSTEM "MF_Repository.dtd">
<ENTITY % Linguistic_variable SYSTEM "Linguistic_variable.dtd">
%Linguistic_variable;
<ENTITY % Linguistic_term SYSTEM "Linguistic_term.dtd">
%Linguistic_term;
<ENTITY % MF SYSTEM "MF.dtd">
%MF;
<ENTITY % user_defined_function SYSTEM "user_defined_function.dtd">
%user_defined_function;
<ENTITY % pre_defined_function SYSTEM "pre_defined_function.dtd">
%pre_defined_function;
<ENTITY % pre_defined_operator SYSTEM "pre_defined_operator.dtd">
%pre_defined_operator;
<ENTITY % Range SYSTEM "Range.dtd">
%Range;
<ENTITY % Operation SYSTEM "Operation.dtd">
%Operation;
<!ELEMENT FuzzySystem (InputBase, InferenceEngine, RuleBase,
DefuzMethod, OutputBase, Operator_Repository, MF_Repository)>
<!ATTLIST FuzzySystem
Name CDATA #REQUIRED
Type CDATA #REQUIRED
>
%InputBase;%InferenceEngine;%RuleBase;%DefuzMethod;%OutputBase;%
Operator_Repository;%MF_Repository;
```

3.3.2 Reprezentarea sistemelor fuzzy cu fișiere XSD

În această secțiune se prezintă o schemă XML care poate fi folosită pentru a defini sisteme fuzzy în XML [Vel07]. Se definesc fișiere XSD pentru fiecare componentă și pentru toate tipurile de date din sistemul fuzzy. Exemplul de mai jos prezintă componenta 'InputBase' definită ca și o schemă XML:

```
<?xml version="1.0" encoding="UTF-8"?>
<xs:schema xmlns:xs="http://www.w3.org/2001/XMLSchema"
elementFormDefault="qualified" attributeFormDefault="unqualified">
<xs:documentation>
Fuzzy system component, that captures all of the input
variables</xs:documentation>
</xs:annotation>
<xs:complexType>
<xs:sequence>
maxOccurs="unbounded"/>
<xs:simpleType>
</xs:restriction>
</xs:simpleType>
</xs:element>
</xs:sequence>
</xs:complexType>
</xs:element>
</xs:schema>
<xs:element name="Input" type="Input"
<xs:element name="Num_of_inputs">
<xs:restriction base="xs:integer">
<xs:minInclusive value="1"/>
<xs:include schemaLocation="Input.xsd"/>
<xs:element name="InputBase">
<xs:annotation>
```

Folosind scheme XML sistemul fuzzy se poate defini mai precis decât prin fișiere DTD. Fișierele XSD se pot folosi și pentru a integra funcțiile și operatorii predefiniți. Un fișier XSD poate indica o cale către un alt fișier XSD folosind sintaxa <xs:include schemaLocation> pentru a crea un sistem fuzzy complet. Aceste abordări sunt complexe și necesită multe fișiere interconectate. Fișierele prezentate mai sus sunt create manual. Astfel pot apărea erori. Un alt dezavantaj major este că aceste fișiere sunt folosite pentru a transmite informații cadrelor de lucru de simulare precum *MatLab* și *FuzzyJess*. Ar fi importantă și o comunicare inversă astfel încât un program oarecare să fie compatibil cu o inferență fuzzy dezvoltată într-un mediu de simulare, de exemplu *MatLab*.

3.4 O reprezentare XML simplificată

Această teză propune o metodă de reprezentare a sistemelor cu inferență fuzzy folosind un singur fișier XML pentru codificarea antetelor, variabilelor lingvistice, a funcțiilor de membru și a regulilor de inferență [Gal11]. Această reprezentare a sistemelor de inferență fuzzy este bazată pe structura fișierelor tip

*.fis (*MatLab*). Principalele componente sunt descriptorii sistemului cu inferență fuzzy, secțiunea variabilelor de intrare, secțiunea variabilelor de ieșire și secțiunea regulilor. Această structură oferă o flexibilitate sporită. Astfel pentru a implementa funcții noi doar o parte a fișierului XML va fi accesat și modificat.

Structura generală a sistemului de inferență fuzzy are patru părți majore:

- i. partea de header în care sunt introduse datele generale despre sistemul de inferență precum: denumirea, tipul de inferență (Mamdani sau Sugeno), numărul variabilelor de intrare, numărul variabilelor de ieșire, numărul total de reguli și metoda de defuzzificare. Un exemplu de header este prezentat mai jos:

```
<FuzzyInference>
<System>
<Name> Osteoscleroza</Name>
<Type>Mamdani</Type>
<NumInputs>4</NumInputs>
<NumOutputs>2</NumOutputs>
<NumRules>25</NumRules>
<DefuzzMethod Value="1000">Centroid</DefuzzMethod>
</System>
```

Exemplul prezentat se referă la codificarea datelor generale despre sistemul cu inferență fuzzy precum: denumirea ("Osteoscleroza"), tipul sistemului, numărul de variabile lingvistice (4 intrări și 2 ieșiri), numărul de reguli (25) și metoda de defuzzificare (Centroid).

- ii. În a doua parte sunt reprezentate variabilele de intrare pentru sistemul de inferență fuzzy. Fiecare variabilă de intrare începe obligatoriu cu un Tag <Input>. Variabilele lingvistice sunt identificate prin nume, au un domeniu de reprezentare și funcții membre care sunt utilizate la procesul de fuzzificare. Funcțiile membre se găsesc în secțiunea <Labels>. În exemplul următor se prezintă variabila lingvistică pentru reprezentarea histogramei și a funcțiilor de membru asociate:

```
<Input>
<Name>Histograma</Name>
<Range MIN="1" MAX="255" />
<Labels>
<Negru v0="10" v1="20" v2="30" v3="40" />
<Închis v0="40" v1="60" v2="80" v3="115" />
<Gri v0="120" v1="130" v2="140" v3="150" />
<Alb v0="190" v1="200" v2="210" v3="220" />
<Deschis v0="150" v1="160" v2="170" v3="180" />
</Labels>
</Input>
```

În TAG-ul <Name> este codificat numele unei variabile lingvistice la care se vor atașa funcțiile de membru care se folosesc pentru fuzzificarea valorilor numerice. TAG-ul <Range MIN = " " MAX = " " /> reprezintă domeniul pe care sunt descrise atributele fuzzy. Astfel pentru exemplul de mai sus care codifică fuzzificarea histogramei domeniul de apartenență este de la 0 la 255 unde 0 este cea mai mică

valoare care va fi fuzzificată iar 255 este cea mai mare valoare care va fuzzificată. Astfel atributele fuzzy vor fi următoarele:

- `<Negru v0="10" v1="20" v2="30" v3="40" />` sunt parametrii care descriu funcția de membru trapezoidală pentru parametrul "Negru".
- `<Închis v0="40" v1="60" v2="80" v3="115" />` sunt parametrii care descriu funcția de membru trapezoidală pentru parametrul "Închis".
- `<Gri v0="120" v1="130" v2="140" v3="150" />` sunt parametrii care descriu funcția de membru trapezoidală pentru parametrul "Gri".
- `<Deschis v0="150" v1="160" v2="170" v3="180" />` sunt parametrii care descriu funcția de membru trapezoidală pentru parametrul "Deschis".
- `<Alb v0="190" v1="200" v2="210" v3="220" />` sunt parametrii care descriu funcția de membru trapezoidală pentru parametrul "Alb".

Valorile pentru domeniul de apartenență și pentru valorile funcțiilor membre sunt codificate folosind atribute iar denumirile sunt codificate prin elemente.

- iii. A treia parte a fișierului XML care codifică sistemul de inferență este secțiunea dedicată variabilelor de ieșire. Variabilele de ieșire au aceeași structură ca și variabilele de intrare cu excepția primului TAG care este `<Output>`. În exemplul următor se prezintă o variabilă lingvistică pentru reprezentarea osteosclerozei și funcțiile de membru asociate:

```
<Output>
<Name>Osteosclerosis</Name>
<Range MIN="0" MAX="10" />
<Labels>
<Pozitive v0="0" v1="1" v2="2" v3="3" />
<Negative v0="2" v1="3" v2="4" v3="5" />
<Possible v0="4" v1="5" v2="6" v3="7" />
<Undefined v0="6" v1="7" v2="8" v3="9" />
</Labels>
</Output>
```

- iv. A patra parte a fișierului XML este secțiunea dedicată regulilor. Regulile sunt în format „IF-THEN-ELSE”. Secțiunea de reguli începe cu TAG-ul "`<Rules>`" și fiecare regulă este numerotată separat. În exemplele de mai jos se pot observa 12 reguli pentru detecția osteosclerozei. Un avantaj obținut față de reprezentarea *MatLab* este folosirea unor operatori logici diferiți în aceeași regulă.

```
<Rule1>IF Zone IS Hand AND RelativeExposure IS Low AND
SensorSensibility IS Low AND Histogram IS White THEN Osteosclerosis IS
Pozitive</Rule1>
<Rule2>IF Zone IS Hand AND RelativeExposure IS Low AND
SensorSensibility IS Low AND Histogram IS Gray THEN Osteosclerosis IS
Possible</Rule2>
```

```
<Rule3>IF Zone IS Hand AND RelativeExposure IS Low AND
SensorSensibility IS Low AND Histogram IS LightGray THEN Osteosclerosis
IS Pozitive</Rule3>
<Rule4>IF Zone IS Hand AND RelativeExposure IS Low AND
SensorSensibility IS Low AND Histogram IS DarkGray THEN Osteosclerosis
IS Negative</Rule4>
<Rule5>IF Zone IS Hand AND RelativeExposure IS Low AND
SensorSensibility IS Low AND Histogram IS Dark THEN Osteosclerosis IS
Negative</Rule5>
<Rule6>IF Zone IS Hand AND RelativeExposure IS Low AND
SensorSensibility IS Low AND Histogram IS Black THEN Osteosclerosis IS
Undefined</Rule6>
<Rule7>IF Zone IS Hand AND RelativeExposure IS Medium AND
SensorSensibility IS Low AND Histogram IS Gray THEN Osteosclerosis IS
Positive</Rule7>
<Rule8>IF Zone IS Hand AND RelativeExposure IS Medium AND
SensorSensibility IS Low AND Histogram IS Black THEN Osteosclerosis IS
Undefined</Rule8>
<Rule9>IF Zone IS Hand AND RelativeExposure IS Medium AND
SensorSensibility IS Low AND Histogram IS Dark THEN Osteosclerosis IS
Possible</Rule9>
<Rule10>IF Zone IS Hand AND RelativeExposure IS Medium AND
SensorSensibility IS Low AND Histogram IS DarkGray THEN Osteosclerosis
IS Possible</Rule10>
<Rule11>IF Zone IS Hand AND RelativeExposure IS Medium AND
SensorSensibility IS Low AND Histogram IS LightGray THEN Osteosclerosis
IS Positive</Rule11>
<Rule12>IF Zone IS Hand AND RelativeExposure IS Medium AND
SensorSensibility IS Low AND Histogram IS White THEN Osteosclerosis IS
Undefined</Rule12>
```

Această reprezentare este una mai simplificată față de reprezentarea sistemelor fuzzy folosind fișiere XSD sau DTD. Acest XML se poate integra cu ușurință în aplicații, prin existența în multe platforme de programare a bibliotecilor care să permită utilizarea fișierelor XML.

Această structură se poate genera inclusiv plecând de la modele existente, prin folosirea unui algoritm de parsare, spre exemplu plecând de la fișierului *.fis creat cu editorul fuzzy din *MatLab*, folosind algoritmul [Gal11] prezentat în imaginea de mai jos :

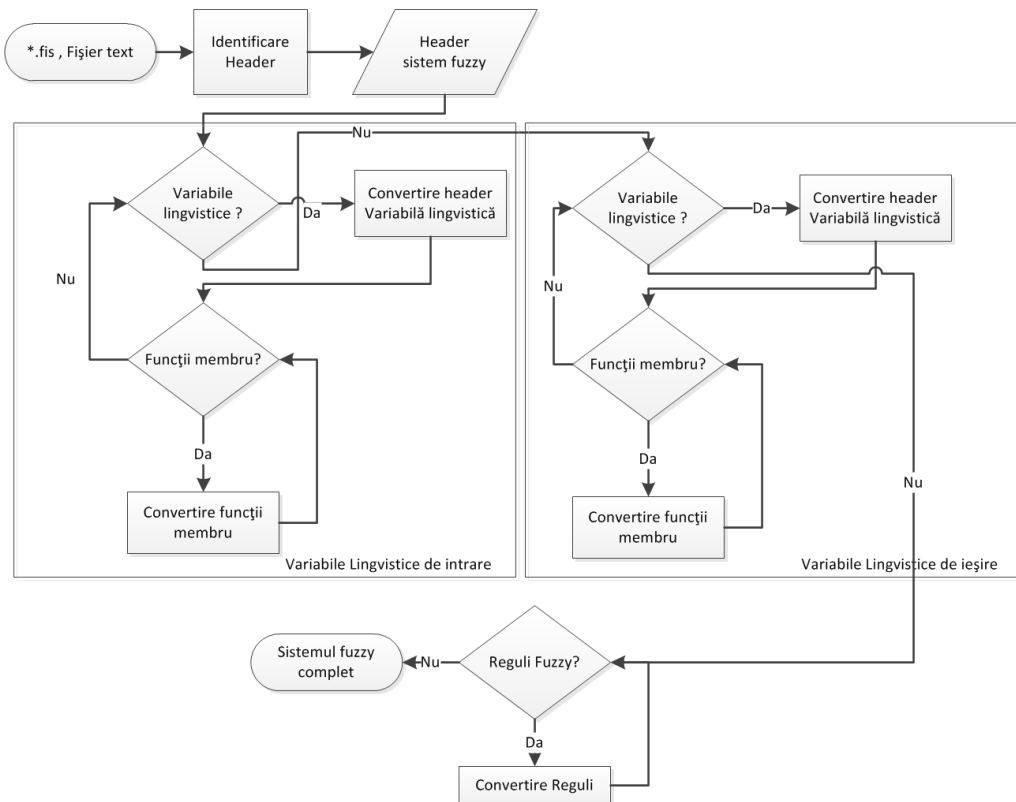


Figura 3.8 Algoritm de parsare a fișierului *.fis.

Această abordare are avantajul de a utiliza puterea și complexitatea editorului avansat din mediul *MatLab*. Primul pas este analiza headerului secțiunii care urmează să fie parsată. Astfel putem identifica headerul ca și '[denumire]'. În fișierul *.fis există patru header: [System], [Input_{nr}], [Output_{nr}] and [Rules]. În primul pas algoritmul parsează secțiunea de "System" pentru a identifica numărul variabilelor de intrare, numărul variabilelor de ieșire și numărul regulilor. În al doilea pas algoritmul intră într-o buclă dublă, bucla exterioară parsează datele despre variabila lingvistică iar apoi bucla interioară parsează funcțiile de membru asociate variabilei lingvistice. În secțiunea regulilor nu există un marker explicit pentru a indica variabila lingvistică și funcțiile de membru prezente în regulă. O regulă este reprezentată de un șir de numere și caractere. De ex: nr nr nr, nr nr (nr) 1. Astfel nr indică funcția membru activă iar poziția la care se află nr indică variabila lingvistică. Înainte de virgule se află variabilele de intrare iar după virgule ieșirile. Ultimul număr poate să fie 1 sau 2, aceștia indică operatorii logici folosiți: ȘI respectiv SAU.

Ca alternativă la soluția de mai sus, dezirabilă mai ales în situația dezvoltării propriului mediu de inferență fuzzy (subcapitolul 6.4) am creat un editor de sisteme cu inferență fuzzy. Acest editor a fost creat în limbajul de programare C# și permite generarea fișierelor XML în care se salvează reprezentarea sistemului cu inferență fuzzy generat. Folosind acest editor se pot modifica sistemele deja existente în fișierele XML. Un avantaj major al codificării sistemelor cu inferență fuzzy este posibilitatea de implementare *on-ty-fly* [Gal11]

3.5 Concluzii

Acest capitol însumează prezentarea celor mai importante aspecte ale sistemelor cu inferență fuzzy. Sistemele cu inferență fuzzy permit utilizarea avantajelor oferite de incertitudini. Logica Booleană care permite doar adevărat sau fals este extinsă cu o incertitudine de un grad oarecare. Această incertitudine se numește grad de apartenență. În general gradul de apartenență este mapat pe domeniul [0...1]. Figura 3.9 prezintă structurat tipurile fuzzy existente și editoarele de sisteme cu inferență fuzzy.

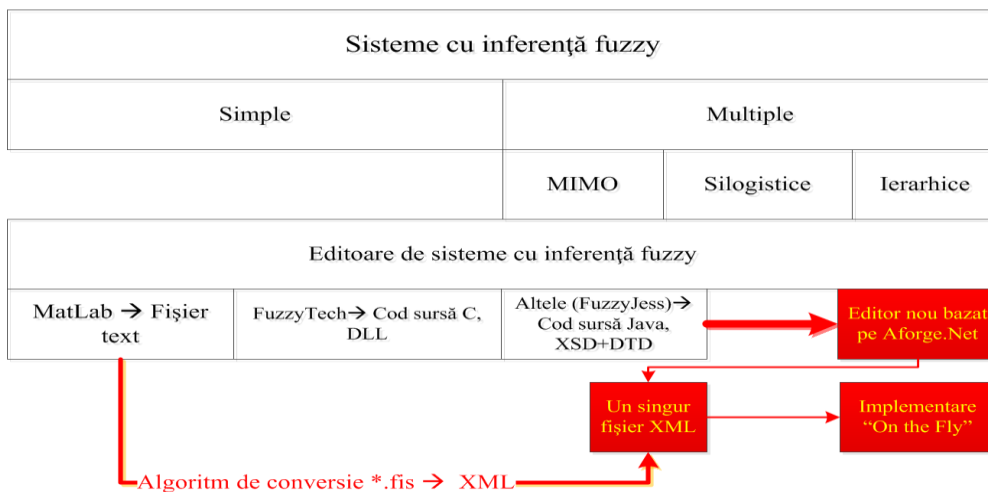


Figura 3.9 Sisteme cu inferență fuzzy și editoarele.

Sistemele cu inferență fuzzy sunt de două tipuri:

- Simple, construite din variabile lingvistice, acestea la rândul lor înglobează mai multe seturi fuzzy. Seturile fuzzy sunt folosite pentru procesul de fuzzificare unde se stabilește gradul de apartenență al unei variabile lingvistice la un set fuzzy oarecare. Folosind variabilele lingvistice împreună cu operatorii logici se formează regulile de inferență fuzzy care returnează o variabilă lingvistică de ieșire. Acea ieșire va fi apoi defuzzificată pentru a obține un rezultat final numeric.
- Complexe, alcătuite din mai multe sisteme simple prin cascada sau ierarhizare.

Sistemele cu inferență fuzzy sunt create folosind editoare specializate. Cele mai cunoscute editoare sunt editorul din *MatLab* care salvează sistemul cu inferență fuzzy într-un fișier text. Sistemul creat cu acest editor se poate utiliza doar în cadrul

de lucru *MatLab*. Alte editoare care creează sisteme cu inferență fuzzy sunt *FuzzyTech* și *FuzzyJess*. *FuzzyTech* oferă posibilitatea de a exporta sistemul creat în cod sursă de tip C++ și *.dll, iar *FuzzyJess* exportă coduri sursă pentru Java și în formatul XML în DTD și XSD. Formatul XSD și DTD utilizează o structură de fișiere complexă compusă din multiple fișiere XSD și DTD, structură mult prea complexă pentru a fi utilizabilă.

În acest capitol s-a propus utilizarea unei reprezentări proprii, folosind un fișier XML simplu, în care sunt codificate toate componentele unui sistem cu inferență fuzzy. Acest XML se poate crea pe două căi:

- utilizând algoritmul de convertire a fișierelor de tip *.fis.
- folosind editorul de sisteme cu inferență fuzzy prezentat în capitolul 6.

Un avantaj major al codificării sistemelor cu inferență fuzzy în fișiere de tip XML este posibilitatea de implementare *on-ty-fly* [Gal11]. În *MatLab* pentru a schimba sistemul cu inferență fuzzy simularea trebuie oprită, iar în cazul codurilor sursă programele trebuie refactorizate. Sistemul propus permite schimbarea sistemului cu inferență fuzzy doar prin câteva click-uri nefiind necesară decompilarea programului. Mai mult, sistemul de inferență fuzzy curent se poate modifica prin editorul care este inclus în sistemul de interpretare al imaginilor medicale.

4 Sistemul de interpretare al imaginilor medicale

Imaginea medicală ilustrează interiorul corpului uman prin obiecte în diferite tonuri de gri. În acest caz sunt utilizate: radiografiile, ecografiile, CT, RMN și imagini color în cazul metodelor de diagnostic invazive: colonoscopie. Obiectele și tonalitățile de culoare oferă date și informații despre starea actuală a pacientului. Pentru descifrarea și interpretarea informațiilor prezente în imagine, un sistem informatic va trebui să recurgă la metode imagistice numerice și lingvistice.

Metodele numerice au rolul de a corecta imaginea brută, de a segmenta imaginea în subimagini care conțin obiectele prezente în imaginea brută și de a extrage informațiile din segmentele de imagine.

Formularea unui diagnostic se realizează folosind metode semantice. Metodele semantice se bazează pe sisteme cu inferență fuzzy care analizează informațiile extrase din segmentele de imagine și metadata iar pe baza acestor investigații, folosind reguli de inferență, furnizează un rezultat.

Acest capitol prezintă un nou sistem de analiză semantică a imaginilor medicale și expune metodele folosite atât pe planul numeric cât și pe planul semantic.

4.1 Structura logică a sistemului de interpretare

Arhitectura sistemului de interpretare este construită în concordanță cu nivelele de informații prezentate anterior [Gal10]. Primul nivel are rolul de a analiza numeric imaginile medicale. Aici sunt detectate caracteristicile fizice ale obiectelor care se regăsesc în imagine. Caracteristicile de interes se referă la forma obiectului, histograma nivelului de gri, mărimea obiectului în pixeli și coordonatele la care se află obiectul. În cazul în care avem mai multe obiecte distincte trebuie să analizăm și poziția relativă a unui obiect față de celălalt obiect.

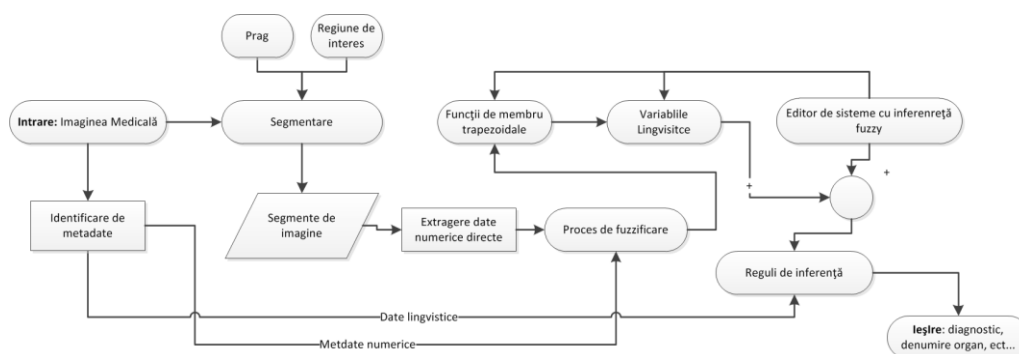


Figura 4.1 Structura logică a sistemului.

Al doilea nivel al sistemului de interpretare are rolul de a interpreta datele de la nivelul numeric. Mai precis, acele date care încă sunt în format numeric vor fi convertite în date semantice folosind metode de fuzzificare. După ce se obțin datele lingvistice, un sistem de inferență formulează un diagnostic medical folosind baza de cunoștințe și regulile de inferență.

Metadatele imaginii (subcap 1.3.3), dacă acestea sunt prezente, atunci sunt extrase și stocate separat de imaginea investigată. Unele metadate se pot obține printr-o simplă analiză a imaginilor, aceste date în general sunt legate direct de imagine și sunt utile pentru o interpretare mai corectă. Metadatele utilizate sunt următoarele: rezoluția imaginii, tipul imaginii medicale, puterea undei de iradiere, etc. Metadatele nu sunt limitate doar la date numerice. Ele mai conțin și numele persoanei, vârsta, sexul și alte date legate de pacient. În cazul imaginilor DICOM metadatele conțin și denumirea organului investigat. Denumirea organului este o informație foarte utilă deoarece permite sistemului de interpretare să deducă doar patologia, iar identificarea organului nu este necesară.

Părțile majore ale sistemului de interpretare sunt:

- Blocul de segmentare și de procesare a imaginilor.
- Blocul de accesare a metadatelor.
- Fuzzificarea.
- Baza de reguli și mașina de inferență.
- Blocul de afișare a rezultatelor.

Blocul responsabil pentru editarea inferențelor fuzzy are rolul de a crea funcțiile de membru care vor fi folosite pentru fuzzificarea valorilor numerice, mașina de inferență și baza de reguli.

4.2 Procesarea numerică

La acest nivel se realizează procesarea numerică a imaginilor. Primul pas în procesarea imaginilor medicale este segmentarea imaginilor, care pentru moment se realizează manual. Scopul segmentării este separarea obiectelor importante de fundal și de restul obiectelor neimportante. Segmentul de imagine se poate considera ca și o subimagine a imaginii principale. După segmentare subimaginea este supusă unei analize numerice folosind algoritmi specializați pentru a obține caracteristicile fizice ale obiectului în format numeric. Caracteristicile utile pentru interpretarea imaginilor sunt:

- Forma obiectului.
- Valoarea histogramei tonurilor de gri, în cazul în care avem imagini în tonuri de gri.
- Mărimea obiectului.
- Locația la care se află obiectul.

Valorile brute ale caracteristicilor specificate sunt codate în modul următor:

- Forma obiectului este o matrice de numere reale.
- Histograma se poate reprezenta folosind atât o matrice cât și o valoare medie.
- Mărimea obiectului este un număr natural care reprezintă în pixeli mărimea obiectului.
- Locația obiectului este reprezentată în coordonate carteziane. Domeniul este definit de rezoluția imaginii în pixeli iar originea este aleatorie.

4.2.1 Segmentarea imaginilor medicale

Segmentarea are rolul principal de a separa obiectele din imagine de fundal [Rog00]. Cea mai simplă metodă de segmentare se bazează pe folosirea unei valori de prag [Wee96]. Separarea pixelilor care compun obiectul de acei pixeli care aparțin de fundal, se realizează prin selectarea unei valori K.

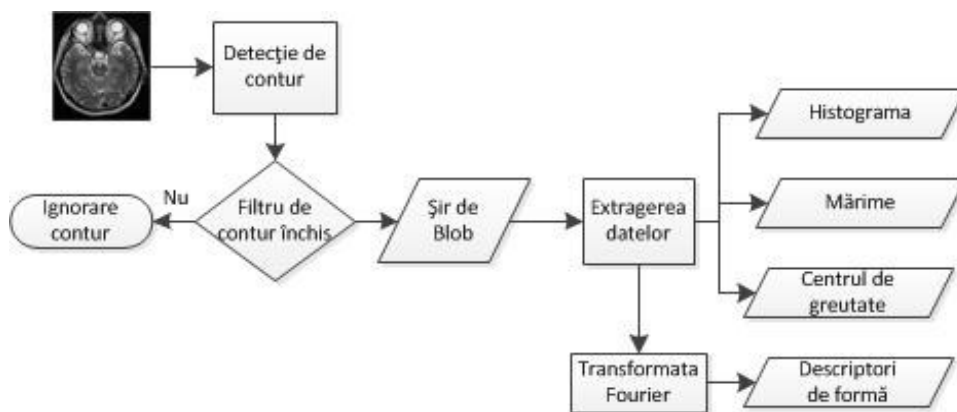


Figura 4.2. Arhitectura segmentării și extragerii informațiilor numerice.

Toți pixelii care aparțin de $f(x,y) > K$ vor fi clasificați ca și pixeli care aparțin obiectului sau obiectelor din imagine. Scopul valorii de prag este de a binariza o imagine în tonuri de gri. Procesul de selectare a valorii de prag este prezentat în ecuația 4.1[Wee96]:

$$g(x,y) = \begin{cases} G_a & f(x,y) \leq K \\ G_b & f(x,y) \geq K \end{cases} \quad (4.1)$$

Acest proces reduce o imagine cu multiple nivele de gri într-o imagine care conține doar două nivele de gri, G_a și G_b . Tipic, o astfel de imagine se numește imagine binarizată.

Histograma imaginii definește distribuția nivelului de gri a fiecărui pixel și este cheia pentru a selecta valoarea de prag. Analizând histograma imaginii complete se poate găsi valoarea adecvată a valorii de prag.

Folosirea mai multor valori de prag reprezintă o metodă mai eficientă pentru a seta valorile de prag ale imaginilor în tonuri de gri. Astfel ecuația (4.2) se poate extinde încât să includă mai multe valori de prag:

$$g(x,y) = \begin{cases} G_a, 0 \leq f(x,y) < K1 \\ G_b, K1 \leq f(x,y) < K2 \\ G_c, K2 \leq f(x,y) \leq G_{\max} \end{cases} \quad (4.2)$$

G_{max} este valoarea maximă a nivelului de gri admisă în imaginea $f(x,y)$. Astfel ecuația (4.2) segmentează imaginea în trei nivele de gri: G_a , G_b , și G_c . Histograma unui obiect care conține trei nivele de gri se poate observa în Figura 3. Astfel de imagini se numesc imagini bimodale.




Figura 4.3 Histograma unei imagini bimodale.

În general histograma unei imagini complexe nu este bimodală. În figura următoare este prezentată o imagine medicală și histograma acesteia. Se poate observa faptul că imaginea este departe de a fi o imagine bimodală. În acest caz la selectarea valorii de prag se va face un compromis între segmentarea diferitelor proprietăți de interes și datele care vor fi șterse. Valoarea de prag depinde de caracteristicile care se doresc a fi scoase în evidență. Predominant se folosește metoda de încercare și eroare. Această metodă implică interpretarea umană a imaginii binarizate. Se evaluează vizual extragerea sau nu a caracteristicii dorite.

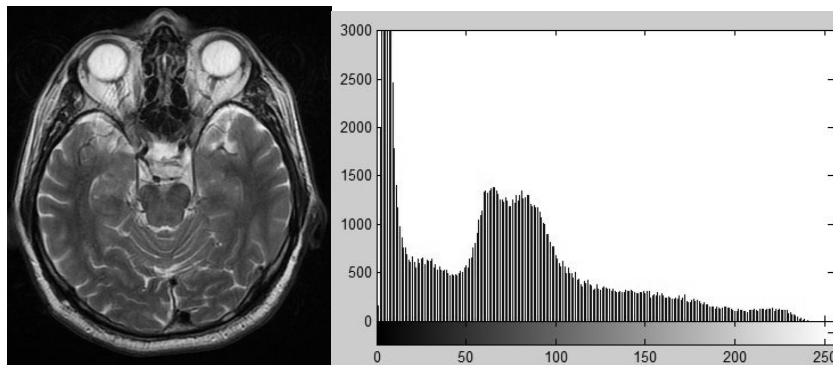


Figura 4.4 RMN de craniu și histograma aferentă.

Segmentarea imaginilor folosind metoda valorilor de prag se efectuează corect dacă nivelele de gri ale pixelilor care compun obiectul sunt bine separate. În aceste condiții histograma imaginii va fi bimodală. Într-o imagine complexă nivelele de gri al obiectului de interes, nu sunt bine separate de fundalul imaginii. În această situație necesită alegerea unei valori adecvate pentru valoarea de prag. Pentru o segmentare cât mai bună se utilizează o combinație de metode [Hir05] [Nar09] [Sha09] [Xue09] [Jun 11]. Tehnicile folosite sunt reprezentate de: detecția de contur și metoda valorilor de prag. Algoritmii pentru detecția de contur se bazează

pe metoda valorilor de prag, aceștia căutând mereu o linie care să separe obiectul de fundal.

În cazul nostru am propus următoarea formulă pentru a identifica valoarea de prag corespunzătoare:

$$T_{sh} = H_{sg} + k \quad (4.3)$$

unde T_{sh} este valoarea de prag, H_{sg} histograma zonei de interes selectată de cadrul medical și k este un ofset determinat empiric prin analiză vizuală.

Procesul de segmentare se poate considera finit și corect în momentul în care s-au separat toate obiectele de fundal. Obiectul trebuie să reprezinte un contur închis și nu unul deschis [Ede11] [Jin11] [Jea09] [Shi09] [Wan07]. Pentru a determina dacă un contur este deschis sau închis, se apelează la metode de reprezentare a conturilor. Un contur este închis dacă punctul final al acestuia coincide cu punctul de origine. Procesul de segmentare este urmat de procesul de extragere a datelor din segmentele de imagine.

4.2.2 Reprezentarea segmentelor de imagine

Este recomandat să se realizeze reprezentarea obiectului folosind alte metode decât coordonatele pixelilor care definesc acel obiect [Shu11] [Sri11] [Hom08]. Pentru mulți algoritmi de recunoaștere a imaginilor este suficient să se cunoască doar forma obiectului. Conturul obiectului se poate folosi pentru a defini obiectul de interes și astfel avem acces la forma și mărimea obiectului. Odată ce conturul a fost asociat cu un obiect, avem la dispoziție mai multe metode pentru a descrie acel contur.



Figura 4.5 Obiect segmentat și extras din imaginea inițială

Prima metodă se bazează pe un cod de orientare sau lanț de orientare, care descrie trasarea conturului de la origine până la final printr-un set de pixeli interconectați. În momentul trasării conturului de la un pixel la altul, direcția mișcării este înregistrată folosind o serie de numere care generează un lanț de orientare de tipul 4 sau 8. Lanțul de orientare tip 4 reprezintă cea mai simplă metodă deoarece sunt necesare doar 4 valori pentru construcția lui. Acest lanț descrie conturul folosind doar 4 direcții: două verticale și două orizontale. Dacă pixelul de origine este la coordonatele (x,y) , atunci pentru o mișcare verticală pozitivă la punctul $(x, y+1)$ codul va conține valoarea `1`. Analog pentru celelalte mișcări se va înregistra în lanț valoarea `2` pentru $x+1$, `3` pentru $y-1$ și `4` pentru $x-1$. Diferența între lanțul de orientare de tipul 4 față de tipul 8, este faptul că lanțul de orientare de tipul 8 permite trasarea mișcării și pe diagonale la 45, 135, 225 și 315 grade.

Codul de tip 4 are avantajul unui caracter compact dar codul de tip 8 permite o descriere mult mai eficientă al conturului. Pe parcursul trasării conturului, un șir de numere este construit dinamic, acesta împreună cu punctul de plecare a conturului reprezintă întregul contur.

Codul final al conturului este influențat drastic de existența pixelilor de zgomot. O metodă de filtrare a zgomotului și de a da o robustețe algoritmului este de a reprezenta conturul pe o rezoluție mai mică.

O altă metodă de reprezentare a conturului obiectului segmentat este aplicarea transformatei Fourier discretă unidimensională [Flo11]. Astfel fiecare pixel din contur poate fi definit folosind coordonatele x_j, y_j . Aceste două coordonate pot fi folosite pentru a genera o funcție complexă de forma:

$$f(r) = x_r + jy_r \text{ pentru } r = 0, 1, 2, \dots, N-1 \text{ pixeli.} \quad (4.4)$$

Transformata Fourier ne furnizează componentele de frecvență care compun conturul. Un avantaj major al acestei reprezentări este reducerea problemei analizei conturului de la 2D la 1D. Transformata Fourier discretă unidimensională a funcției $f(r)$ este:

$$F(n) = \frac{1}{N} \sum_{r=0}^{N-1} f(r) * e^{-j2\pi nr/N} \quad (4.5)$$

Iar inversa ecuației (4.5) se poate scrie ca și:

$$f(r) = \sum_{n=0}^{N-1} F(n) * e^{j2\pi nr/N} \quad (4.6)$$

Componentele Fourier calculate ne oferă câteva proprietăți interesante legate de contur. De exemplu: $F(0)$ ne furnizează centrul de greutate al conturului, unde x este partea reală al lui $F(n)$ iar y reprezintă partea imaginară a funcției $F(n)$. Astfel partea reală a lui $F(n)$, în cazul în care $n=0$, (4.4) devine:

$$x_{centroid} = \frac{1}{N} \sum_{r=0}^{N-1} x_r \quad (4.7)$$

Iar partea imaginară a lui $F(n)$, pentru $n=0$ devine:

$$y_{centroid} = \frac{1}{N} \sum_{r=0}^{N-1} y_r \quad (4.8)$$

Reprezentarea matematică a translației conturului cu x_0, y_0 la o altă locație este:

$$f(r) = (x_r + x_0) + j(y_r + y_0) \text{ pentru } r = 0, 1, 2, \dots, N-1, \quad (4.9)$$

Astfel este influențat doar primul coeficient Fourier, $F(0)$, restul coeficienților rămân neschimbați.

Pentru conturile închise, punctul de pornire al conturului se translatează simplu de la $f(r)$ la $f(r-r_0)$. Proprietatea Fourier bidimensională se poate transcrie în unidimensională și rezultă schimbarea punctului de pornire:

$$e^{-\frac{j2\pi r_0 n}{N}} F(n). \quad (4.10)$$

Schimbarea mărimii obiectului influențează scalar magnitudinea componentelor. Dacă un contur $f(x,y)$ al imaginii furnizează componente Fourier reale și imaginare de tipul $F(n)=Re(n)+jIm(n)$ atunci ulterior se aplică o transformare scalară cu $f(ax, by)$. În urma acestei operațiuni se primesc componente Fourier $F_s(n)$ de tipul:

$$F_s(n) = a \cdot Re(n) + jIm(n) \quad (4.11)$$

Identificarea conturului reprezintă o utilizare comună a componentelor Fourier. Excluzând $F(0)$, componentele Fourier nu depind de locația subimaginii din imagine, astfel se oferă o modalitate eficientă de clasificare a conturilor.

Pentru a produce un contur exact, se poate folosi un filtru 'trece-jos' pe componentele Fourier, pentru a elimina structurile spațiale fine.

Pentru un contur închis, oarecare, se calculează componentele Fourier, se ignoră prima componentă, apoi restul se compară cu componentele conturilor deja cunoscute.

4.2.3 Extragerea datelor numerice din segment

Subimaginea sau segmentul obținut se supune analizei numerice pentru a extrage datele numerice. Datele oferite de o subimagine sunt: histograma locală, coordonatele centrului de greutate și aria în pixeli [Der11] [Fan11] [Cho11] [Lop11] [Bes06] [Esc09]. Folosind tehnici de analiză a conturului putem să identificăm și forma obiectului. Analiza conturului a fost prezentată în subcapitolul anterior.

Analiza histogramei este bazată pe determinarea mediei de luminozitate și a contrastului sau a divergenței fiecărui pixel [Sta07] [Zhe09] [Wan07]. Deoarece majoritatea imaginilor sunt în tonuri de gri, algoritmul a fost modificat astfel încât să ia în considerare doar un singur plan de culori. Caracteristicile de interes sunt nivelul mediu sau luminozitatea pixelului și divergența sau contrastul dintre tonurile de gri. Coordonatele pixelilor din imagine sunt notate cu (x, y) .

Valoarea mediei de luminozitate se poate calcula folosind:

$$G_{ms} = \frac{1}{N} \sum_{(s,t) \in S_{xy}} G(s,t) \quad (4.12)$$

Contrastul dintre tonurile de gri se poate scrie matematic:

$$G_{vs} = \frac{1}{N} \sum_{(s,t) \in S_{xy}} |G_{ms} - G(s,t)| \quad (4.13)$$

N reprezintă numărul total de pixeli din subimaginea analizată. În momentul în care avem toate datele la dispoziție se creează un vector descriptiv cu valorile calculate. Acest vector descriptiv conține mărimea subimaginii, valorile de contrast și de luminozitate.

$$V = [L, W, G_{ms}, G_{vs}] \quad (4.14)$$

L și W reprezintă lungimea și lățimea subimaginii. Vectorul descriptiv conține informații suficiente pentru recunoașterea cu exactitate a diferitelor tonuri de gri.

Consistența obiectelor examinate generează variații ale tonurilor de gri. Obiectele închise sau negre au o rată mai mare de absorbție a undei de scanare iar obiectele albe au o proporție mai mare de reflectare a undei de scanare. Aceasta înseamnă că obiectele închise au o consistență mai scăzută fiind reprezentate de organe parenchimotoase sau de lichide iar cele albe au o consistență mai solidă fiind reprezentate de țesut osos sau de calculi.

Aria subimaginii selectate este înregistrată în această fază. Aria este egală cu numărul pixelilor prezenți în subimagine. Practic mărimea obiectului este egală cu mărimea matricei. În această fază încă nu se știe mărimea în mm sau mm³. Pentru o estimare și o fuzificare corectă a mărimii sunt necesare informații din repertoriul metadatelor care se referă la mărimea imaginii sau la mărimea pixelului.

Locația unde se află centrul obiectului este înregistrată folosind coordonate carteziane, reprezentate în unități de pixeli. În contextul existenței unei relații între obiecte este necesar să verificăm dacă centrul obiectului secund este în interiorul sau în exteriorul primului obiect.

Implementarea software a metodelor de imagistică numerică este realizată folosind limbajul de programare vizual C# și cadrul de programare open source AForge.Net. AForge.Net oferă unelte care au fost adaptate pentru a facilita realizarea obiectivelor propuse.

4.2.4 Utilizarea metadatelor

Metadatele sunt informații despre date. În cazul imaginilor de tip DICOM metadatele se numesc DICOM TAGs. Aceste metadate sunt de două categorii: date despre pacient și date despre imaginea în sine. Utilizând aceste date putem obține o imagine în ansamblu despre obiectele aflate în imaginea medicală. Aceste metadate există atât în format numeric cât și în format lingvistic.

Metadatele despre pacient conțin informații demografice precum: numele, prenumele, vârsta, sexul, greutatea și în multe cazuri organul investigat.

Metadatele legate de imagine ne oferă informații despre metoda cu care a fost creată imagine și implicit tipul imaginii. În cazul imaginilor RMN și CT putem obține informații despre mărimea fizică pixelului în mm², despre grosimea feliei investigate, distanța dintre felii, numărul feliei, metoda de afișare a imaginii și precum alte date mai puțin importante.

În cazul radiografiilor digitale putem identifica alte metadate care ne ajută la afișarea imaginii și la verificarea expunerii. La aceste imagini create cu raze X va trebui să verificăm dacă s-a folosit doza corectă de iradiere, deoarece o iradiere incorectă poate să influențeze negativ analiza datelor numerice directe.

Metadatele introduse în imaginile DICOM sunt identificabile prin adresele lor. Pentru a accesa o metadată oarecare va trebui să cunoaștem adresa la care este localizată. O adresă este formată din 8 cifre hexazecimale grupate câte patru, de ex: 1008,10e4. Fiecare adresă specifică o metadată bine stabilită de standardul DICOM, astfel anume metadate pot lipsi, altele pot fi în plus dar niciodată nu se va găsi la altă adresă indiferent de aparatura folosită.

4.3 Interpretarea lingvistică a segmentelor de imagine

Interpretarea lingvistică a segmentelor de imagine presupune transformarea datelor numerice obținute în date lingvistice. Aceste date lingvistice se obțin prin procesul de fuzzificare. Din datele lingvistice obținute se vor forma regulile de inferență care sunt folosite pentru a infera un diagnostic. Ultimul pas în interpretarea segmentelor de imagine este procesul de defuzificare care presupune convertirea rezultatelor lingvistice obținute în date numerice. Deoarece rezultatele se obțin inițial în formă lingvistică și rezultatele de interes sunt în formă lingvistică, se propune eliminarea procesului de defuzificare. Astfel sistemul va returna un rezultat în limbajul medical.

4.3.1 Reprezentarea cunoștințelor medicale

Găsirea unei metode de a reprezenta cunoștințele umane este primul pas în realizarea unui sistem automat care utilizează date semantice pentru a interpreta imaginile medicale. Reprezentarea cunoștințelor descrie modul în care un sistem informatic automat vede și înțelege imaginea medicală.

Reprezentarea corectă a cunoștințelor medicale determină acuratețea cu care sunt înțelese variabilele lingvistice și sunt formulate diagnosticalele. Cea mai comună reprezentare a cunoștințelor este reprezentarea prin regulile de tip IF-THEN. Regulile de inferență sunt create de cadrele medicale și sunt bazate pe experiența lor acumulată pe parcursul carierei [Gal12]. Regulile specifice recomandări, directive, diagnoze și strategii. În forma computațională regulile se exprimă ca fiind instrucțiuni de tip: "IF < antecedente > Then <consecințe> ". Regulile se pot exprima folosind următoarea ecuație:

$$R(H \wedge S \wedge L \wedge Sh \wedge M) = D \quad (4.15)$$

unde D reprezintă setul de diagnostice, R reprezintă o regulă. H, S, L, Sh seturile de variabile lingvistice care alcătuiesc secțiunea antecedentelor pentru histogramă, mărime, locație și formă. M reprezintă colecția de metadate necesare, fie despre imagine fie despre pacient. Aceste metadate se găsesc în secțiunea de DICOM TAGs a imaginilor medicale.

Antecedente				
Formă	Histogramă	Mărime	Locație	Metadate
Reguli de tip "IF - THEN"				
Consecințe				
Organe, Țesuturi		Patologii	Obiecte Diverse	

Figura 4.6 Structura bazei de cunoștințe.

Baza de cunoștințe propusă este formată din mai multe părți, iar structura se poate vedea în figura 4.5. Părțile principale ale bazei de cunoștințe sunt:

- **antecedentele:**
O parte din antecedente sunt obținute direct din segmentele de imagine și reprezintă caracteristicile fizice ale sub-imaginilor (segmentelor). Celelalte sunt obținute din TAG-rile DICOM și reprezintă metadatele necesare pentru o procesare corectă. Aceste metadate conțin date demografice despre pacient și date tehnice legate de generarea imaginilor. Antecedentele sunt formate din variabile lingvistice și operatori logici.
- **baza de reguli:** aici sunt salvate regulile. Aceste reguli sunt folosite pentru a infera o consecință.
- **consecințele:** pot fi organe, diferite patologii, obiecte uitate în organism și recomandări.

4.3.2 Fuzzificarea variabilelor lingvistice

Valorile proprietăților fizice exprimate în valori numerice se convertesc în valori și variabile lingvistice folosind procesul de fuzzificare.

Fuzzificarea este un proces de descompunere a sistemului de intrare - ieșire în unul sau mai multe grupuri (seturi) fuzzy. Cu toate că se pot folosi mai multe tipuri de curbe, cele mai comune sunt funcțiile de membru trapezoidale. Acestea se pot reprezenta cel mai ușor.

Mai multe seturi fuzzy de același fel formează o variabilă lingvistică. Fiecare variabilă lingvistică este caracterizată prin numele variabilei, seturile fuzzy asociate și domeniul pe care variabila lingvistică este definită.

Figura 4.6 arată un sistem de semnale fuzzy pentru histograma subimaginei segmentate, cu funcții membru de tip trapezoidale. Fiecare semnal fuzzy acoperă o regiune a valorii de intrare reprezentată grafic printr-o asociere. Funcția de membru de tip trapezoidal permite o ajustare fină a procesului de fuzzificare.

Funcțiile membru ar trebui să se suprapună parțial pentru a permite un proces corect de fuzzificare. Procesul de fuzzificare permite intrărilor și ieșirilor sistemului să fie exprimate în termeni lingvistici.




Figura 4.7 Funcțiile de membru pentru variabila lingvistică 'Histogramă'.

În momentul creării funcțiilor de membru există câteva restricții: două funcții membre nu pot să aibă un punct comun de adevăr maxim și în locul suprapunerii valoarea maximă de adevăr nu poate depăși 1. Marsh a propus două valori pentru descrierea cantitativă a suprapunerilor: "overlap ratio" și "overlap robustness" [Mar94].

$$\text{OverlapRatio} = \frac{x_4 - x_3}{x_6 - x_1} \quad (4.16)$$

$$\text{OverlapRobustness} = \frac{\int_{x_3}^{x_4} (u_1 + u_2) dx}{2 * (x_4 - x_3)} \quad (4.17)$$

unde $x_i, i=1 \rightarrow 6$ sunt punctele de maxim și minim adevăr a două funcții membre oarecare trapezoidale. u_1 și u_2 sunt valorile de apartenență a celor două funcții membre la punctul de intersecție.

4.3.3 Regulile de inferență fuzzy

Cea mai generală formă a regulilor de inferență utilizate în sistemele de inferență fuzzy este forma *IF-THEN* : *IF* - un set de condiții impuse în regulă sunt satisfăcute, *THEN*- inferarea unei concluzii. Fiecare regulă fuzzy de tip *IF-THEN* are o parte de premiză care conține mai multe condiții ce necesită să fie satisfăcute pentru validarea concluziilor aflate după cuvântul cheie *THEN*. Concluziile descriu în general o ieșire de tip fuzzy care poate să fie în cazul nostru denumirea unui organ, unui obiect, a unei patologii sau poate fi o recomandare medicală.

Premizele și concluziile regulilor sunt caracterizate de seturi fuzzy sau funcții membru (MFs). În general o regulă de tip fuzzy are forma:

"*IF F₁ IS M_{f1} AND F₂ IS M_{f2} AND...AND F_n IS M_{fn} THEN G_j si M_{fj}*"

unde $F_1...F_M$ și $G_j, j=1...M$,

M - numărul de antecedente existente în sistemul de inferență fuzzy,

F și G reprezintă premisele și antecedentele regulilor,

M_{f_i} reprezintă seturile fuzzy aferente premizelor și concluziilor,

$i=0...n$ unde n este numărul maxim de seturi fuzzy existente în variabila lingvistică.

Regulile de inferență vor fi obținute prin discuții cu medicii de specialitate. Se vor alege imagini reprezentative care să prezinte diferite patologii și organe. Se vor analiza proprietățile numerice ale obiectelor de interes iar medicul specialist va descrie în limbaj natural acele proprietăți. Se va realiza o corelație între cele două exprimări ale proprietăților și se vor forma regulile de inferență.

4.4 Concluzii

În acest capitol s-a propus un nou sistem de analiză a imaginilor medicale folosind sistemele cu inferență fuzzy. Noutatea adusă în acest capitol este chiar sistemul de analiză propus. Acest sistem are capacitatea de a investiga toate tipurile de imagini medicale pentru moment în tonuri de gri, care sunt generate după standardul DICOM. Standardul DICOM fiind un standard impus în imagistica medicală avem siguranța că datele brute care vor fi utilizate sunt nealterate. Sistemul de analiză are capacitatea de a furniza la ieșire nu doar denumirea organului ci și un diagnostic pentru o oarecare patologie sau o recomandare.

Sistemul de analiză este construit pe două nivele:

- Nivelul numeric, permite extragerea datelor numerice din segmentele de imagine. Segmentarea este un proces mixt, în care utilizatorul precizează regiunea de interes, iar apoi sistemul de segmentare va separa obiectele din imagine de fundal. Aceste obiecte sau subimagini sunt descrise de date numerice. Aceste date numerice sunt: conturul, mărimea, histograma și locația. Conturul obiectului este reprezentat prin componentele de frecvență obținute prin transformata Fourier. Componentele de frecvență se pot folosi pentru identificarea formelor. Mărimea obiectului este echivalentă cu numărul de pixeli care formează obiectul. Astfel pentru determinarea mărimii în mm^2 sunt necesare extra informații obținute din metadatele imaginilor. Histograma segmentului de imagine ne indică densitatea obiectului investigat. Locația reprezintă centrul de greutate al obiectului în coordonate Carteziene în unități de pixeli. Obținerea datelor numerice în format brut ne oferă posibilitatea și de a efectua calcule pe valori nealterate. Calculele necesare pentru convertirea datelor din unități de pixel în unități metrice se va efectua utilizând datele furnizate despre imagine de metadatele. În metadate se specifică obligatoriu mărimea pixelului sau raza pixelului în mm.
- Nivelul lingvistic are rolul de a transforma valorile numerice în valori lingvistice pentru a le atașa o valoare semantică. Acest nivel se bazează pe sistemele cu inferență fuzzy și în consecință este compus din următoarele module: modulul de fuzzificare care transformă valorile numerice în valori lingvistice și modulul de inferență care este compus din reguli de inferență. Aceste reguli de tip *IF-THEN* sunt create folosind variabilele lingvistice obținute la fuzzificare, operatori logici și variabile de ieșire care se activează în funcție de regulile de inferență.

Metadatele furnizate de standardul DICOM oferă informații suplimentare utile despre imagine și despre pacient. Una dintre informațiile cele mai utile este informația despre afișarea imaginii medicale. Folosind această informație putem să efectuăm toate operațiunile menționate mai sus pe o imagine care nu a suferit nici o modificare din punct de vedere al contrastului sau al luminozității. În cazul imaginilor de radiografie putem să deducem dacă această imagine a fost expusă corect sau nu.

Reprezentarea cunoștințelor descrie modul în care un sistem informatic automat vede și înțelege imaginea medicală. Cea mai comună reprezentare a cunoștințelor este reprezentarea prin regulile de tip IF-THEN. Regulile de acest tip utilizate în sistemele cu inferență fuzzy codifică cunoștințe în format lingvistic utilizând termeni din limbajul comun sau în acest caz din limbajul medical. Astfel fără mari eforturi un medic experimentat în analiza imaginilor poate să creeze cu ușurință reguli noi. Aceste reguli sunt folosite pentru a infera un rezultat. Rezultatele pot fi: un organ, o patologie sau o recomandare. Aceste reguli de inferență sunt create împreună cu un medic dintr-un domeniu aleator.

Un avantaj major și un aspect de originalitate al sistemului prezentat este că se poate adapta la mai multe tipuri de imagini, organe și patologii doar prin adaptarea sau schimbarea sistemului de inferență. Astfel cu același program se pot analiza mai multe tipuri de imagini medicale și se pot identifica o varietate largă de

4. Sistemul de interpretare al imaginilor medicale

semne care indică diferite patologii, organe, țesuturi sau alte obiecte de altă natură. Extinderea sistemului de inferență se poate realiza facil folosind editorul de sisteme cu inferență fuzzy integrat în sistemul de analiză. Acesta este un editor nou, creat special pentru acest sistem, dar se poate adapta și pentru alte programe dacă se permite introducerea unui schelet de sistem cu inferență fuzzy. Acest schelet definește doar structura logică a sistemului de inferență fără a preciza orice altă informație despre sistemul cu inferență fuzzy folosit. Sisteme noi de inferență se pot introduce în sistem prin fișierele de tip XML prezentate în capitolul anterior.

5 Autoperfecționarea regulilor folosind algoritmi genetici

Algoritmii genetici sunt proceduri de căutare și selecție bazate pe mecanismele prezente în genetica biologică. Aceștia folosesc proceduri și metode întâlnite în genetică pentru a se ghida printr-un spațiu de căutare. Algoritmii genetici ne oferă metode de căutare prin date haotice și greu de înțeles. Datorită robusteții algoritmii genetici sunt utilizați cu succes în diferite domenii pentru optimizarea și învățarea sistemelor.

Procesul care afectează cromozomii pentru a produce noi cromozomi este procesul de evoluție. Evoluția cromozomilor este bazată pe selecția naturală, un proces descris de Darwin [Dar59], care ia în considerare performanțele care sunt codificate în cromozomi. Selecția naturală are ca și efect reproducerea cromozomilor care codifică o oarecare structură de căutare sau învățare. Reproducerea cromozomilor este realizată folosind metode de mutație și recombinare. Procesul de recombinare creează noi cromozomi folosind gene de la doi părinți diferiți. Procesul de mutație creează noi cromozomi folosind gene de la același cromozom.

Algoritmii genetici utilizează aceste procese ale selecției naturale în formă matematică pentru a rezolva probleme dificile. În algoritmica genetică un cromozom codifică un set de variabile. Astfel fiecare cromozom conține o posibilă soluție pentru problema analizată. Evaluarea cromozomului din punctul de vedere al funcționalității pentru a anumită problemă, se realizează prin decodificare [Lar06]. Cromozomul este divizat în gene (componenta de bază a cromozomului) care reprezintă variabilele problemei. Aceste variabile sunt folosite pentru a evalua funcția de cost sau mai precis funcția de fitness.

Algoritmii genetici acordă prioritate cromozomilor cu un fitness ridicat și creează noi cromozomi prin recombinări aleatoare între genele părinților selectați.

Repopularea cu noi cromozomi se poate realiza folosind trei metode: clonarea, crossover-ul și mutația [Gol89].

Selecția cromozomilor se poate face în diverse moduri. Cele mai uzuale sunt:

1. Trunchierea - elimină o parte din cromozomii cu cea mai slabă performanță, iar în locul lor se generează alții, după diferite scheme posibile. De exemplu se alege un nou cromozom x , folosind principiul ruletei. Dacă x diferă de toți ceilalți cromozomi ai populației actuale, atunci el este inclus în populație; în caz contrar, este supus operatorului de "mutație" până ce devine diferit de ceilalți cromozomi și este inclus în populație.
2. Turneul - alege în mod aleatoriu k indivizi iar dintre aceștia doar cei mai buni j sunt selectați pentru supraviețuire. Procedura se repetă până se obține numărul dorit de indivizi. Este cea mai eficientă din punct de vedere al timpului de execuție.
3. Tipul elitist - păstrează în generația următoare, cei mai buni k indivizi ai generației curente. Dacă nu se rețin acești indivizi ei pot să dispară din cauza că nu au fost selectați pentru supraviețuire sau deoarece au fost

distruși prin aplicarea operatorilor. Acest lucru garantează faptul ca cel mai puternic membru al populației din generația următoare nu va fi mai slab decât cel din generația curentă.

Încrucișarea a doi indivizi se poate face într-un singur punct sau în mai multe puncte. Cromozomii noi ai populației sunt obținuți prin combinarea unor părți alternative de material genetic provenind de la părinți.

5.1 Metode de generare a regulilor fuzzy folosind algoritmi genetici

Pentru generarea automată a sistemelor fuzzy s-au propus mai multe metode de codificare a sistemelor cu inferență în cromozomi. Astfel întâlnim codificat în cromozomi atât baze complete de reguli cât și funcții de apartenență. Un astfel de sistem evoluționar pe mai multe stagii a fost creat pentru generarea automată a sistemelor cu inferență [Pim10]. Algoritmii genetici optimizează sisteme de tip 2 [Pim10] cu funcții membre triunghiulare generate cu algoritmul fuzzy c-mean. În primul stadiu algoritmul genetic este folosit pentru a genera regulile din datele obținute de algoritmul fuzzy c-mean. În stadiul doi algoritmul genetic este folosit pentru a optimiza funcțiile membre. Iar în final algoritmul genetic are rolul de a optimiza numărul de reguli din sistemul de inferență.

Un sistem de inferență fuzzy de tipul 2 dacă are p atribute de la x_1 la x_p care pot fi reprezentate pe domeniile X_1, \dots, X_p , având M reguli o regulă se poate defini în felul următor:

$$R^i = \text{Dacă } x_1 \text{ este } F^1 \text{ și } x_2 \text{ este } F^2 \dots \text{ și } x_p \text{ este } F^p \text{ Atunci } r \text{ este } R_i \quad (5.1)$$

unde F^1, F^2, \dots, F^p sunt valorile lingvistice care reprezintă seturi fuzzy de tipul 2 și r este setul rezultatelor. În acest stadiu fiecare cromozom reprezintă o întreagă bază de reguli, iar regulile sunt considerate genele cromozomului. Pentru a determina lungimea cromozomului trebuie stabilit un număr maxim de reguli. Regulile sunt codificate folosind numere întregi care reprezintă indexul setului fuzzy, acesta reprezintă antecedentele și consecințele din domeniul de reprezentare.




Figura 5.1 Codificare de reguli în cromozomi.

Funcția de fitness este calculată pe baza performanțelor obținute de baza de reguli și poate exprima: $fitness(C_i) = CCR(C_i)$ unde $CCR(C_i)$ este rata exemplilor clasificate corect.

În stadiul 2 sunt utilizate cele mai bune baze de reguli generate la stadiul 1. Fiecare cromozom reprezintă partițiile din domeniile tuturor atributelor definite în sistemul de inferență fuzzy. Pentru sistemele fuzzy de tip 1 funcțiile de membru au fost codificate în cromozomi folosind numere reale iar mărimea cromozomului este dată de formula: $3 * nP * nS$ unde 3 este numărul de parametri pentru codificarea

funcțiilor membru de tip triunghiular, nP este numărul partițiilor și nS este numărul seturilor fuzzy în fiecare domeniu.




Figura 5.2 Codificare de reguli în cromozomi.

Pentru cromozomii care codifică sisteme fuzzy de tipul 2 mărimea cromozomului se calculează cu aceeași formula dar în loc de 3 se folosește 5. Astfel punctul maxim al funcției de membru de tip 2 este identic cu cel al funcției de membru de tip 1. Funcția de fitness folosită este identică cu cea din stagiul 1.

Stagiul 3 este stagiul evoluțional în care se dorește reducerea numărului de reguli obținute în stagiul 1 folosind rezultatele din stagiul 2. În acest stagiu cromozomii sunt codificați folosind o secvență binară cu lungimea m , unde m este numărul de reguli generate la stagiul 1. Fiecare genă reprezintă o regulă. Dacă regula este activă atunci va fi menținută, altfel va fi exclusă din setul final de reguli. Populația inițială este generată prin introducerea unui cromozom care conține toate regulile active. Restul cromozomilor sunt generați automat. În acest stagiu funcția fitness evaluează fiecare cromozom. Pentru evaluare, funcția fitness ia în considerare două valori: rata corectă de clasificare $CCR(C_i)$ și numărul de reguli active codificate în cromozom $NR(C_i)$. Funcția fitness are următoarea formă:

$$fitness(C_i) = w_1 * CCR(C_i) - w_2 * NR(C_i) \quad (5.2)$$

Ponderile w_1 și w_2 sunt numere reale pozitive și sunt definite empiric. Obiectivul stagiului 3 este de a maximiza $CCR(C_i)$ și de a minimiza $NR(C_i)$. Pentru fiecare stagiul al arhitecturii evoluționare operatorii genetici utilizați au fost: crossoverul pe un singur punct, selecția ruletei și mutația standard. Soluția finală obținută este cromozomul cu cea mai mare valoare de fitness.

În studiul realizat în [Pin11] s-a propus utilizarea algoritmilor genetici pentru adaptarea principalelor componente al unui sistem cu inferență fuzzy: baza de reguli și baza de date. Codificarea algoritmilor în cromozomi se realizează în felul următor:

- Se identifică variabilele de ieșire și de intrare ale problemei care trebuie rezolvată.
- Se alocă pentru fiecare variabilă de intrare și ieșire un interval pe care se reprezintă variabila care se partiționează conform necesităților (în seturi fuzzy). Fiecărei partiții i se alocă o funcție de membru sau o etichetă lingvistică.
- Se codifică regiunile fuzzy ale variabilelor de intrare și ieșire folosind un șir de biți. Codificarea tipurilor de funcții de membru s-a realizat folosind o codificare 00,01,10 și 11 pentru triunghiular, triunghi dreapta, triunghi stânga și Gaussian.
- Se generează reguli utilizând un algoritm genetic format din două module, unul pentru generarea regulilor fuzzy și altul pentru generarea funcțiilor de membru.

- Se decodifică cromozomul din ambele module pentru a genera regula și pentru a aloca o valoare de fitness.

Astfel fiecare regulă se definește ca și un șir de biți binari. Înainte de evaluare fiecare regulă este transformată în forma de implementare și testare. În urma testării se face o verificare de acuratețe pentru a acorda o valoare de fitness.

Generarea regulilor utilizând această arhitectură cu două module se realizează în felul următor:

- Inițializarea algoritmului se realizează prin generare aleatorie a câtorva perechi de șiruri binare. Primul șir binar codifică regula în sine cu antecedente și rezultate, iar al doilea codifică tipul funcției de membru. Fiecare pereche generată reprezintă o posibilă soluție pentru problema dată.
- Fiecare soluție este evaluată și va primi o valoare de fitness.
- Se aplică un crossover și o mutație pentru fiecare pereche de cromozomi, astfel noi cromozomi vor fi generați.
- Se evaluează noile soluții și se verifică condiția de terminare.
- În cazul în care condiția de terminare este satisfăcută atunci se vor returna perechile de cromozomi cu cele mai bune valori de fitness.

Metodele prezentate mai sus utilizează algoritmi genetici pentru crearea sistemelor cu inferență fuzzy. În cromozomi sunt codificate baze de reguli, seturi fuzzy și metode de fuzzyficare. Metodele prezentate mai sus pot fi adaptate pentru diferite probleme.

5.2 O nouă reprezentare a regulilor fuzzy folosind cromozomi

Pe baza celor prezentate mai sus am propus o altă reprezentare a regulilor cu inferență fuzzy în cromozomi. Diferența între reprezentările existente în domeniu și cea propusă este că reprezentarea propusă folosește denumirile variabilelor lingvistice și denumirile seturilor fuzzy în gene [Gal12]. Astfel dacă o regulă de tip IF-THEN este de forma:

IF V_1 is MF_1 And V_2 is MF_3 and ... V_n is MF_j THEN R is R_m (5.3)
atunci cromozomul va avea următoarea structură:

V_1	MF_1	V_2	MF_3	V_n	MF_j	R	R_m
-------	--------	-------	--------	-------	-------	-------	--------	-----	-------

Figura 5.3 O codificare originală a regulilor.

Lungimea cromozomului se calculează folosind următoarea formulă creată pentru această reprezentare a regulei fuzzy în cromozom:

$$Cl = 2 * (nr_input + nr_output) \quad (5.4)$$

unde Cl reprezintă lungimea cromozomului, nr_input este numărul total al variabilelor de intrare și nr_output este numărul total al variabilelor de ieșire.

Această reprezentare propusă permite ca algoritmul genetic să ofere următoarele posibilități:

- *recalcularea clasei în urma încrucișării.* Un cromozom codifică o regulă. În urma încrucișării cromozomilor, clasa cromozomilor rezultați este posibil să nu fie cea mai potrivită. De aceea a fost dezvoltată o facilitate care permite recalcularea clasei în urma încrucișării.

- *descoperirea de reguli pentru toate seturile de date utilizate pentru învățare.* Algoritmul genetic rulează pentru un număr de generații (iterații) stabilit la începutul ciclului de optimizare. Regulile descoperite se introduc într-o bază de date iar seturile de date pentru care s-a găsit o regulă se elimină din lista seturilor de învățare. În cazul în care algoritmul nu găsește toate regulile în numărul de iterații stabilit la început există posibilitatea rulării până ce toate seturile de învățare au fost acoperite.

- *adăugarea la lista de reguli descoperite doar a celei mai bune reguli obținută după rularea algoritmului pentru numărul de generații stabilit sau a tuturor regulilor descoperite.* După rularea algoritmului pentru numărul de generații stabilit se descoperă mai multe reguli. Utilizatorul poate analiza dacă le consideră valide pe toate sau doar pe cea mai bună dintre ele

- *utilizarea unei funcții de fitness diferită de cele utilizate de alți algoritmi.* Valoarea de fitness acordată este egală cu valoarea rezultatului defuzzificat. În cazul în care cromozomul nu codifică nici o regulă viabilă ea va avea valoarea de fitness 0

Un avantaj oferit de această structură este obținerea unei reguli în forma cvasifinală. Astfel algoritmul de decodificare va trebui să adauge doar cuvintele cheie IF, THEN, IS, și operatorii. În testele realizate pentru validarea procesului de interpretare (vezi subcapitolul 7.1 și 7.2) au fost folosite reguli care aveau doar operatori de tip AND deoarece se caută prezența a mai multor semne și valori numerice de diferite feluri. Chiar dacă sistemul de inferență implementat permite utilizarea a mai multor tipuri de operatori logici se va utiliza doar operatorul AND. În caz de necesitate acest operator se poate schimba manual.

5.3 Procesul de generare a regulilor de inferență

Procesul de generare are rolul de a genera reguli cu inferență fuzzy pentru un anumit set de rezultate (de exemplu: rezultatele din capitolul 7.2). Propunerile lucrării de față pentru acest proces sunt următoarele:

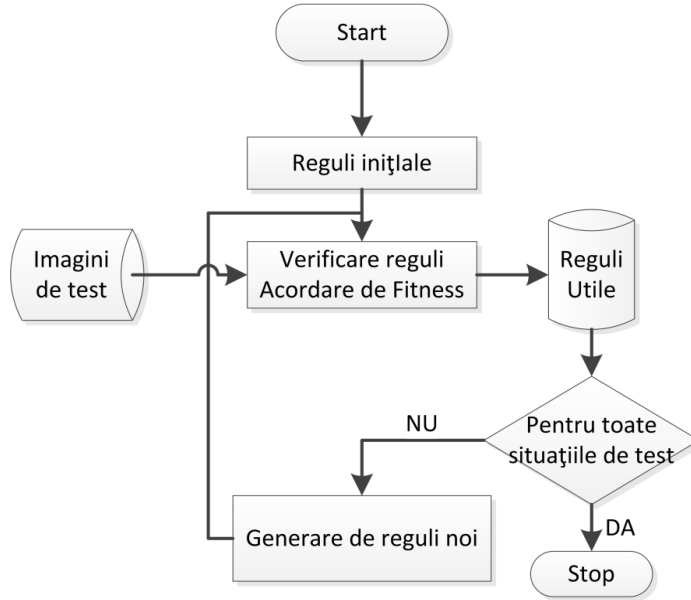


Figura 5.4 Metoda generării regulilor de inferență.

- Generarea de reguli de inferență utilizând toate variabilele lingvistice și toate funcțiile membru existente. De exemplu: dacă ce mai complexă variabilă lingvistică are n seturi fuzzy în acest caz se vor genera n reguli fuzzy pentru a acoperi toată gama de gene existentă. În momentul de față aceste reguli de start sunt generate manual

V_1	MF_1	V_2	MF_1	V_n	MF_1	R	R_1
V_1	MF_2	V_2	MF_2	V_n	MF_2	R	R_2
.....									
V_1	MF_{max}	V_2	MF_m	V_n	MF_j	R	R_t

Cu condiția : $m, j, t < max$

Figura 5.5 Baza inițială de cromozomi.

- Testarea regulilor de inferență generate folosind diverse subimagini medicale de test care conțin rezultatele dorite. Subimaginele utilizate pentru test trebuie alese în așa fel încât să acopere toată gama de rezultate pentru care vor fi utilizate regulile de inferență. În cazul în care apar noi rezultate: patologii, obiecte sau recomandări se generează noi date de test și se reia procesul de optimizare.
- În cazul în care o regulă este validă, i se va acorda o valoare de fitness care este echivalentul rezultatului defuzzificat. Dacă regula nu este corectă se va trece la următoarea regulă din generație. Regula corectă care identifică o imagine este introdusă într-o bază de reguli iar imaginea identificată corect

este eliminată din lista imaginilor de test pentru prevenirea duplicării regulilor.

- Verificarea realizării condiției de oprire. Condiția de oprire este acoperirea tuturor situațiilor folosind o singură regulă. În cazul în care nu este îndeplinită această condiție atunci se va trece la crearea unei noi generații de reguli. Crearea de generații noi se va realiza folosind metoda de crossover. Punctul de crossover este ales aleatoriu cu condiția să se întâmple la punctul $2k$, punct divizibil cu 2 pentru evitarea creării regulilor invalide. În cazul în care punctul de crossover nu este divizibil cu 2 se introduce o valoare de compensare -1 sau +1 ales arbitrar.

V_1	MF_1	V_2	MF_1	V_n	MF_1	R	R_1
V_1	MF_2	V_2	MF_2	V_n	MF_2	R	R_2
V_1	MF_2	V_2	MF_2	V_n	MF_1	R	R_1
V_1	MF_1	V_2	MF_1	V_n	MF_2	R	R_2

Figura 5.6 Metoda de crossover.

Procesul de optimizare și generare a regulilor se poate considera finit în momentul în care nu mai sunt imagini de învățare.

Pseudocodul algoritmului genetic propus este prezentat în continuare:

- Se generează un număr de reguli care să acopere toate seturile fuzzy.
- Se codifică regulile în cromozomi pentru a genera o populație inițială

```
reguli_utile={}
nr_iterații=1;
```

```
do{ //iterația n
  contor_generații=0;

  do{
    - determină valorile fitness ale cromozomilor
    - selectează cromozomi pentru crossover
    - se aplică crossover pentru cromozomii selectați în punctele de 2k
    - recalculează clasa noilor cromozomi
    contor_generații+=1;
  }while (contor_generații < nr_generații);

  -se va afișa o populație finală
  -se adaugă regulile descoperite la reguli_utile
  -se decodifică cromozomii și se afișează regulile descoperite
  - determină și afișează gradul de acoperire al regulilor descoperite pe
  mulțimea de antrenament
  - elimină din mulțimea de antrenament instanțele acoperite de regulile
  descoperite
  - se generează o nouă populație
  contor_iterații+=1;
}while (nr de reguli utile< maxim)
```

- afișează toată lista de reguli utile descoperite
- afișează timpul de execuție al algoritmului

Verificarea calității setului de reguli descoperit se realizează folosind metoda Apriori [Agr94]. Această metodă furnizează doi indici: suportul (reprezintă preponderența obiectelor din regulă) și coeficientul de confidență (reprezintă încrederea în regulă).

Indicele de suport care reprezintă preponderența obiectelor din regulă se calculează folosind formula matematică [Agr94]:

$$\text{Suport} \cong \frac{\text{nr de reguli care conțin pe } x \text{ și } y}{\text{nr total de reguli}} \quad (5.5)$$

Coeficientul de confidență indică puterea unei asocieri și se calculează folosind formula matematică următoare:

$$\text{Confidență} \cong \frac{\text{nr de reguli care conțin } x \text{ și } y}{\text{nr total de reguli care conțin } x} \quad (5.6)$$

Pentru acceptarea regulilor generate în urma rulării metodei prezentate, cei doi indici trebuie să aibă o valoare mai mare decât valoarea setată de utilizator la începutul experimentului. Astfel avem siguranța că regulile generate sunt valide pentru setul de învățare utilizat. Utilizând algoritmi genetici, care se bazează pe selecții succesive în care "supraviețuiește cel mai bun", rezultatul pe care îl obținem este unul adecvat.

5.4 Concluzii

Algoritmii genetici sunt unelte puternice pentru optimizarea soluțiilor existente și pentru a realiza diverse predicții. În acest capitol algoritmii genetici au fost utilizați pentru optimizarea regulilor cu inferență fuzzy care sunt folosite pentru interpretarea segmentului de imagine.

Pentru acesta s-a propus o reprezentare a regulilor în cromozom. Noutatea o reprezintă faptul că s-a folosit utilizarea stringurilor în gene, mai precis: se utilizează denumirile variabilelor lingvistice și a seturilor fuzzy în genele cromozomului. Denumirea variabilei lingvistice și denumirea setului fuzzy vor forma o pereche, obligatoriu. Această reprezentare are atât avantaje cât și dezavantaje.

Avantajele acestei reprezentări sunt prezentate în lista următoare:

- Obținerea regulilor finale cvasi decodificate, decodificarea cromozomului realizându-se prin copierea genelor într-o matrice de reguli.
- Generarea de reguli care să acopere întregul domeniu de interes pornind de la un set minim de reguli.
- Păstrarea de reguli de la o generație la alta, iar cele mai bune se introduc într-un buffer de reguli.
- Un utilizator neexperimentat poate genera reguli cu inferență fuzzy folosind un set minim de reguli aleatorii (care corespund cerințelor) și un set de date de antrenare bine alese.
- Generarea de reguli valide pentru setul de învățare utilizat prin utilizarea indicilor de suport și confidență.

Dezavantajele acestei reprezentări sunt următoarele:

- Se permit puncte de crossover numai în punctele de 2k pentru evitarea generării regulilor eronate.
- Utilizarea momentan doar a operatorilor logici prezenți în setul inițial de reguli.

6. Implementarea

Implementarea metodelor prezentate în capitolele anterioare s-a realizat folosind limbajul de programare C# din Microsoft .NET. Programul creat este bazat pe utilizarea și modificarea a două programe open source, DICOM Decoder [www2] și Aforge.Net [www3]. Primul are rolul de a deschide și accesa imaginea și TAG-rile DICOM codificate în fișiere de tipul *.fis, iar al doilea a fost utilizat pentru implementarea metodelor prezentate.

6.1 Arhitectura programului

Arhitectura programului este concepută astfel încât să permită prelucrarea și interpretarea mai multor tipuri de imagini medicale cu condiția ca aceste imagini să fie de tip DICOM. Prin modalitatea de lucru propusă se pot evita schimbările majore în componentele vitale ale sistemului de interpretare. Astfel sistemul are o adaptabilitate crescută la multiple cerințe de evaluare imagistică [Gal10], [Hal87]. Sistemului de interpretare este realizat prin contopirea și modificarea celor două programe open source menționate mai sus. Aceste programe oferă funcționalități de bază pentru implementarea metodelor de imagistică și a metodelor de interpretare lingvistică a datelor numerice folosite.

Arhitectura programului realizat este prezentată în figura 6.1.

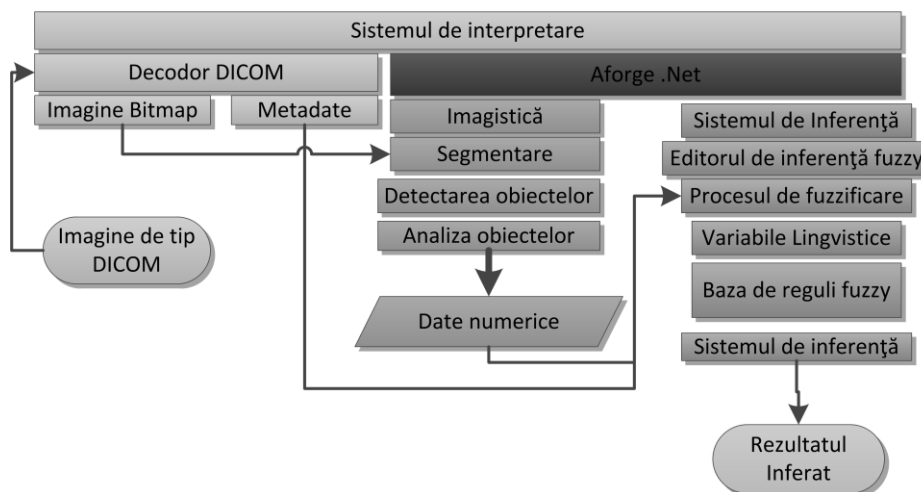


Figura 6.1. Arhitectura generală a programului de interpretare.

Metadatale sunt obținute din secțiunea de TAG-uri DICOM a fișierului *.fis. TAG-rile sunt identificate prin adresa lor, o adresă de 8 numere hexazecimale grupate în două grupuri de patru. Aceste date nu sunt legate direct de conținutul imaginilor, dar oferă informații generale despre pacient și sunt necesare pentru a formula un diagnostic corect. Metadatale pot furniza informații referitoare la

rezoluția imaginii, rezoluția unde de scanare, mărimea pixelului și alte informații legate de imagine. Tag-urile DICOM conțin deseori și informații despre organul investigat, astfel se poate sări un pas în procesul de interpretare, mai precis pasul de identificare a organului.

Componentele principale ale sistemului de interpretare sunt:

- Decodorul pentru fișiere DICOM care desparte fișierul în imagine de tip bitmap și listă de TAG-uri.
- Blocul de segmentare a imaginii bitmap obținute din fișierul DICOM.
- Blocul de extragere a datelor numerice din segmente.
- Blocul de fuzzificare a datelor numerice pentru obținerea valorilor lingvistice.
- Blocul care conține sistemul de inferență și baza de reguli fuzzy.
- Blocul de afișare pentru rezultatele inferate.

Algoritmul de segmentare ales este segmentarea prin folosirea unei valori de prag. Astfel algoritmul de segmentare va lua în considerare fiecare pixel care are histograma mai mare decât valoarea de prag. Un segment de imagine nu poate fi mai mic de 5 pixeli. Astfel oricare grupare mai mare de 5 pixeli va fi luată în considerare și va fi tratată ca și un obiect separat.

Aceste obiecte se numesc blob-uri de imagine. Blob-urile conțin informații numerice despre subimaginea segmentată. Aceste informații sunt: aria segmentului, histograma și centrul de greutate în sistemul de coordonate Carteziene.

Pe baza informațiilor găsite în urma segmentării, blocul de decizii va accesa sau nu metadatele referitoare la imagine. Aceste metadate în majoritatea cazurilor vor fi necesare pentru a determina mărimea fizică a pixelului. Determinând mărimea pixelului se poate calcula metric, cu exactitate mărimea blobului. În cazul fișierelor DICOM există în general un TAG care specifică mărimea pixelului, dar în cazul în care acesta lipsește se utilizează următoarea formulă [Dem09] :

$$PS = \frac{DOFV}{512} \quad (6.1)$$

DFOV (display field of view) are valoarea de 16 pentru pediatrie, 20 pentru craniu și 50 pentru achiziție toracică totală. Rezoluția standard a unei imagini CT este de 512 x 512 pixeli.

În cazul imaginilor DICOM bufferul de metadate este chiar segmentul din fișierul DICOM care conține tag-urile specifice standardului.

Sistemul cu inferență folosit este un sistem de inferență fuzzy. Acesta manipulează imaginea medicală folosind elementele lingvistice directe sau indirecte. Elementele lingvistice directe se obțin prin fuzzificare din datele numerice obținute în urma segmentării. Elementele indirecte sunt metadatele imaginii. Majoritatea metadatelor sunt deja în format lingvistic și se pot introduce direct în sistemul de inferență. Metadatele numerice necesită o fuzzificare înainte de a fi introduse în procesul de inferență a posibilului diagnostic. Procesul de fuzzificare se realizează folosind funcții de membru trapezoidale (subcap 4.3.2). Mașina de inferență și baza de reguli se poate considera ca și un sistem expert cu reguli de tip "IF-THEN". Cadrul de lucru înglobează și un editor de sisteme cu inferență fuzzy. Acesta este capabil să definească funcții de membru pentru fuzzificarea valorilor numerice, variabilelor lingvistice de intrare-ieșire și a bazei de reguli.

Implementarea arhitecturii s-a realizat folosind un program open source 'Dicom Viewer' [www2] care este folosit pentru a accesa fișierele de tip DICOM și pentru a extrage imaginea propriu zisă din fișierul *.dcm. O altă atribuție a acestui program este de a extrage TAG-urile din fișier și de a le introduce în bufferul de metadate.

Group Tag	Element Tag	Tag Description	Value
0020	0060	Laterality	
0028	0000	Private Tag	~#
0028	0002	Samples per Pixel	1
0028	0004	Photometric Interpretation	MONOCHROME1
0028	0010	Rows	2328
0028	0011	Columns	1728
0028	0100	Bits Allocated	16
0028	0101	Bits Stored	12
0028	0102	High Bit	11
0028	0103	Pixel Representation	0
0028	0300	Quality Control Image	NO
0028	0301	Burned In Annotation	YES
0028	1052	Rescale Intercept	0
0028	1053	Rescale Slope	1
0028	1054	Rescale Type	LOG_E_REL
0028	2110	Lossy Image Compression	00
0028	3010	VOI LUT Sequence	
0028	0000	Private Tag	?
0028	3002	LUT Descriptor	1743 2196 16
0028	3003	LUT Explanation	RP1KT
0028	3006	LUT Data	0 1 1 1 2 2 3 3 4 4 4 5 5 6 6 6 7 7 8 8 9 9 10 10 11 11 11 12 12 13 13 13
0040	0000	Private Tag	()
0040	0244	Performed Procedure Step Start Date	20101112
0040	0245	Performed Procedure Step Start Time	175946
0040	0253	Performed Procedure Step ID	1
7FE0	0000	Private Tag	?z
7FE0	0010	Pixel Data	5180

Figura 6.2 TAG-uri DICOM parțiale pentru o radiografie digitală.

Un alt program open source, Aforge.Net a fost folosit pentru implementarea proceselor numerice și lingvistice. Acesta oferă atât metode de imagistică gata implementate cât și metode fuzzy pentru crearea sistemelor cu inferență fuzzy. Partea de imagistică din Aforge.Net are rolul de a segmenta imaginea și de a extrage segmentele din imaginea principală.

În primul pas, programul open source DICOM Viewer accesează informațiile existente în fișierul *.dcm și separă imaginea de metadata. Modulul care realizează această operațiune este DicomDecoder. Metadatale sunt introduse într-un buffer. Imaginea este introdusă într-un buffer care este sub forma unui control de tip pictureBox. În pasul următor metodele din Aforge.Net parsează imaginea pentru a extrage bloburile din imagine. Bloburile sunt subimagini de minim 5 pixeli, a căror histogramă este diferită de histograma globală a imaginii. Pentru a maximiza eficiența algoritmului de căutare de blob-uri, utilizatorul va trebui să facă un zoom asupra zonei de interes. Blob-urile găsite sunt etichetate separat pentru o identificare ulterioară. Proprietățile bloburilor sunt folosite pentru identificarea obiectului. Aceste proprietăți vor fi fuzzificate folosind sistemul cu inferență fuzzy creat cu Aforge.Net.

Blocul de fuzzificare generează etichetele lingvistice pentru o prelucrare fuzzy a datelor. Blocul cu inferență analizează aceste date lingvistice. Sistemul returnează un rezultat fuzzy care prezintă în limbaj natural rezultatul inferat: fie un diagnostic, fie denumirea unui organ, fie alte recomandări.

6.2 Prezentarea programului

Programul creat este împărțit în două părți: partea de procesare numerică și partea de procesare lingvistică. În imaginea următoare este prezentată fereastra principală a cadrului de lucru. Programul permite deschiderea fișierelor de tip DICOM și separarea metadatelor de imaginea propriu zisă. În figura 6.2 se pot observa TAG-urile DICOM, care conțin metadatele despre imaginea afișată.

Nivelul numeric dispune de următoarele metode de analiză numerică:

- Segmentarea hibridă a obiectelor din imaginea brută: în figura 6.3 se observă selecția manuală a regiunii de interes. În fereastra secundară este afișată regiunea de interes. Regiunea de interes este segmentată folosind metoda de segmentare prezentă în capitolul 4 pentru extragerea obiectelor existente.




Figura 6.3 Fereastra principală.

- Introducerea obiectelor extrase într-un buffer care este implementat cu ajutorul unui vector unidimensional. Fiecare subimagine, denumită ca și *blob* este definită prin: mărime, histogramă nivelului de gri, locație și formă.

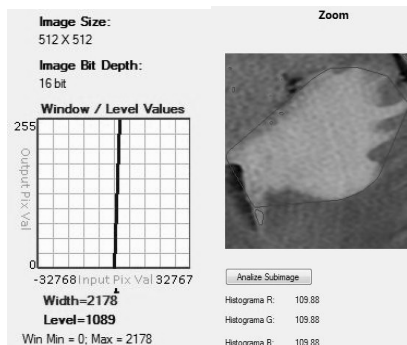


Figura 6.4 a) proprietăți ale imaginii principale; b) un blob selectat.

Mărimea obiectului este definită în unități de pixeli. Astfel rezultatul brut obținut în urma măsurării segmentului de imagine (imaginea 6.4b) va fi: "obiectul selectat are o arie de 3457 de pixeli". Poziționarea obiectelor este realizată folosind coordonatele Carteziene ale centrelor de greutate. Histograma obiectului segmentat se reține ca și o medie a intensității fiecărui pixel, astfel se poate calcula atât un prag local cât și un prag global. Figura 6.4b prezintă o subimagine segmentată cu blob-ul principal scos în evidență. Histograma subimaginii este afișată pe toate cele trei canale chiar dacă subimaginea este în tonuri de gri. Aceasta înseamnă că imaginea este codificată pe 3 canale a câte 16 biți fiecare. Deoarece cele trei canale au o histogramă de valoare egală, la procesul de fuzzificare este suficient să transmitem doar o singură valoare. Aceasta este generic valabilă pentru blob-ul selectat.




Figura 6.5 Proprietățile blobului selectat.

După segmentarea automată, algoritmul ne furnizează câteva date despre blob-ul selectat. Acestea sunt prezentate în imaginea 6.5. Astfel avem acces la histograma obiectului și la aria acestuia care este măsurată în unități de pixel. În exemplul expus, obiectul, prezintă o complicație datorită tumorii maligne. Acesta are o arie de 24179 de pixeli, centrul de greutate la coordonatele la 128,113 și histograma de 149.

Nivelul semantic al programului este construit pe baza logicii sistemelor cu inferență fuzzy. Acest nivel dispune de următoarele funcții:

- Funcția de fuzzificare a datelor numerice care definesc segmentul de imagine. Această fuzzificare este realizată folosind funcții de membru tip trapezoidal. Această formă de funcție de membru a fost aleasă pentru o reglare precisă a procesului de fuzzificare.

- Funcția de inferare a unui rezultat este oferită de baza de reguli. Aceste reguli sunt construite din antecedente care reprezintă datele numerice fuzzificate ale segmentului de imagine și metadatele obținute din TAG-uri DICOM.
- Procesul de defuzificare este eliminat deoarece rezultatele de interes sunt în format lingvistic.
- Acest nivel dispune și de un editor de sisteme cu inferență fuzzy care are posibilitatea de a salva sistemul în format XML.

Rezultatele procesului de inferare sunt afișate conform figurii 6.6 Astfel se pot afișa direct rezultatele obținute de sistemul cu inferență fuzzy, rezultate care specifică natura obiectului investigat. Obiectul investigat poate să reprezinte o patologie, un organ, un tip de țesut sau în alte cazuri o recomandare.

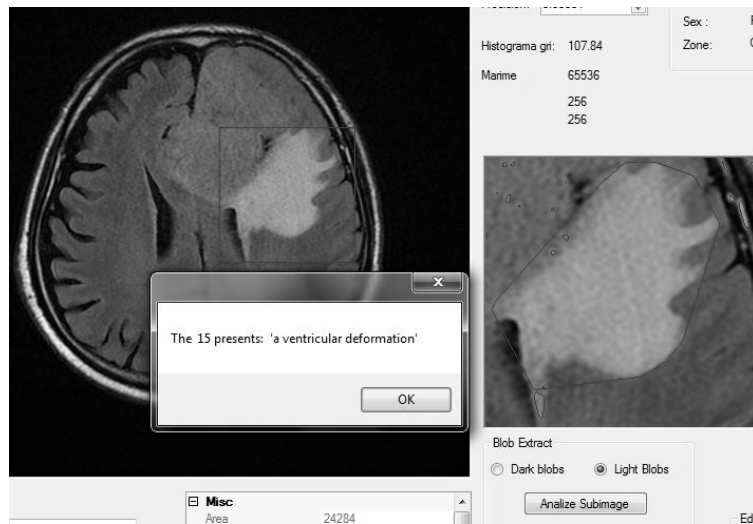


Figura 6.6 Afișarea rezultatului fuzzy.

6.3 Editorul de inferență fuzzy

Editorul de inferență fuzzy a fost creat pe baza codului open source AForge.Net [Gal 11]. Acesta oferă coduri sursă în limbajul C# pentru a crea un sistem cu inferență fuzzy. Nativ AForge .Net permite crearea unui sistem cu inferență fuzzy static, fără posibilitatea de a modifica sistemul de inferență în timpul rulării programului. În acest open source fiecare parte a sistemului de inferență are propria sa clasă. Structura principală a unui sistem cu inferență fuzzy include următoarele:

- o bază de date care conține variabilele de intrare și variabilele de ieșire.
- variabile de intrare și ieșire care codifică lingvistic proprietățile obiectelor.
- o bază de reguli care conține o colecție de reguli de inferență fuzzy.
- regulile de inferență care sunt folosite pentru inferarea unui rezultat.

Din punctul de vedere al implementării software fiecare parte a sistemului de inferență fuzzy este implementată prin clase diferite. Au fost aduse modificări

majore în codul open source pentru a permite generarea dinamică a sistemului de inferență. Pentru acesta s-a creat un schelet al sistemului cu inferență fuzzy care permite adăugarea unui număr oarecare de componente pentru a construi sistemul de inferență fuzzy.

Relativ la codul open source, au fost aduse modificări tuturor claselor, au fost create metode noi de adăugare și diverse contoare, astfel s-a reușit un control mai bun asupra procesului de generare a reprezentării fuzzy. Scheletul UML (Unified Modeling Language) din imaginea 6.7. prezintă clasele care sunt folosite de editorul propus pentru generarea sistemului cu inferență fuzzy. Acest schelet este folosit pentru introducerea sistemelor cu inferență în programul din subcapitolul anterior.

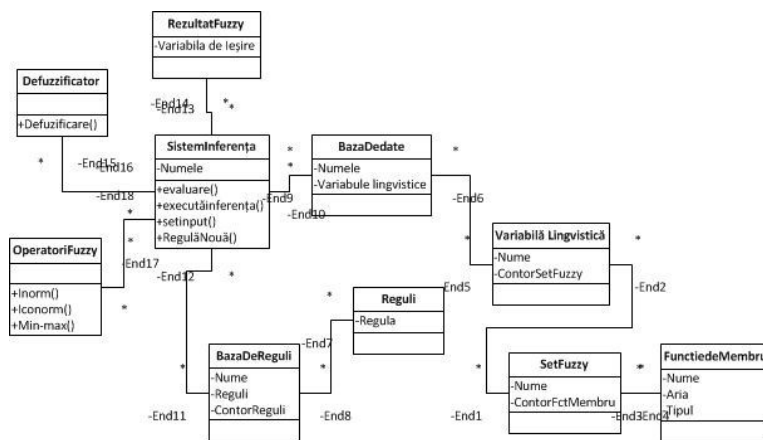


Figura 6.7. Diagrama UML a scheletului sistemului cu inferență fuzzy.

Principalele clase ale scheletului creat sunt:

- Clasa SistemInferența: aceasta are rolul de a stoca sistemul cu inferență fuzzy. Principalele funcții implementate în clasă sunt: adăugarea unei singure baze de date (vezi figura 6.7), introducerea variabilelor numerice pentru fuzzificare (SetInput: setează o valoare numerică pentru fuzzificare), evaluarea intrărilor, executarea inferenței (ExecuteInference: execută inferența și obține un rezultat fuzzy), crearea noilor reguli (newRule: introduce o regulă nouă în baza de reguli) și returnarea unui rezultat fie un rezultat fuzzy fie un rezultat defuzificat.
- Clasa RezultatFuzzy conține rezultatul procesului de inferență în format lingvistic.
- Clasa BazaDeDate are rolul de a stoca variabilele lingvistice. Funcția principală a clasei 'baza de date' este de a introduce și de a scoate variabile din baza de date: addVariable/getVariable.
- Clasa LinguisticVariable care definește variabilele lingvistice are ca proprietăți: numele variabilei lingvistice, aria pe care se definește acea variabilă lingvistică, seturile fuzzy asociate și un contor pentru numărul de seturi fuzzy asociate. Cea mai importantă componentă a clasei este inputul numeric care va fi fuzzificat pentru a obține o valoare lingvistică. Un exemplu de cod pentru crearea variabilelor lingvistice este prezentat mai jos:

```
public LinguisticVariable( string name, double start, double end )
{
```

```

        this.name = name;
        this.start = start;
        this.end = end;

        // instance of the labels list - usually a linguistic variable has no
        more than 10 labels
        this.labels = new Dictionary<string, FuzzySet>( 10 );
    }

    public void AddLabel( FuzzySet label )
    {
        // checking for existing name
        if ( this.labels.ContainsKey( label.Name ) )
            throw new ArgumentException( "The linguistic label name
            already exists in the linguistic variable." );

        // checking ranges
        if ( label.LeftLimit < this.start )
            throw new ArgumentException( "The left limit of the fuzzy set
            can not be lower than the linguistic variable's starting point." );
        if ( label.RightLimit > this.end )
            throw new ArgumentException( "The right limit of the fuzzy set
            can not be greater than the linguistic variable's ending point." );

        // adding label
        this.labels.Add( label.Name, label );
    }

```

- Clasa FuzzySet implementează seturile fuzzy care sunt asociate variabilelor lingvistice. Proprietățile oferite de această clasă sunt: numele setului, punctele unde valoarea este 1 sau 0 și funcțiile de membru care sunt definite folosind o clasă separată. Exemplele de mai jos prezintă constructorul unui set fuzzy și metoda de a adăuga o funcție de membru la setul fuzzy.

```

public FuzzySet( string name, IMembershipFunction function )
{
    this.name = name;
    this.function = function;
}

```

```

TrapezoidalFunction function1 = new TrapezoidalFunction( z1, u1, u2, z2 );
FuzzySet fsCool = new FuzzySet( "Cool", function1 );
TrapezoidalFunction function2 = new TrapezoidalFunction( z1, u1, u2, z2 );
FuzzySet fsWarm = new FuzzySet( "Warm", function2 );

```

- Clasa BazaDeReguli conține regulile de inferență fuzzy care sunt folosite pentru a infera un rezultat. Baza de reguli generează un șir de reguli de tip

'if then'. În prima parte a regulii sunt antecedentele care coincid cu variabilele de intrare, iar în a doua parte se regăsesc rezultatele dintre antecedente și operatorii logici. Contrar editorului de reguli din *MatLab* acest editor permite utilizarea mai multor tipuri de operatori logici în antecedente.

- Clasa *FuzzyRule* conține codurile sursă pentru implementarea regulilor fuzzy și are un sistem de verificare pentru a identifica regulile fuzzy invalide.

Interfața editorului este o interfață grafică care permite o utilizare simplă. Editorul permite crearea bazei de date unde vor fi stocate variabilele lingvistice și regulile de inferență. În figura 6.8 este prezentată fereastra pentru editarea sistemului de inferență. Această fereastră permite vizualizarea întregului sistem cu inferență fuzzy. Pe coloanele din stânga sunt afișate variabilele de intrare cu seturile fuzzy aferente, iar pe coloanele din dreapta sunt afișate variabilele de ieșire cu seturile fuzzy aferente. Editorul permite crearea regulilor de inferență folosind câteva click-uri de mouse. Regulile deja existente se pot modifica fără nici o problemă și se pot adăuga reguli noi între regulile deja existente. Se poate modifica și metoda de evaluare a operatorilor logici. Interfața permite salvarea sistemului de inferență în format XML.

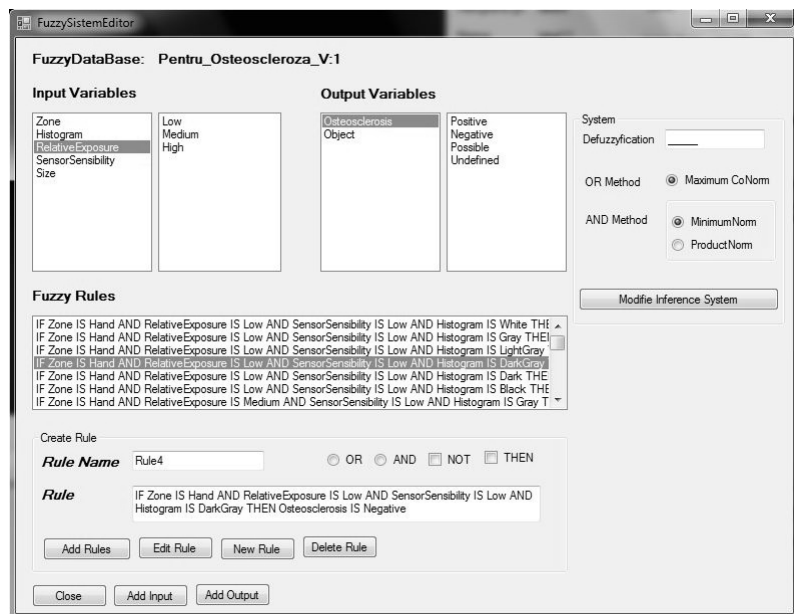


Figura 6.8 Editorul de inferență fuzzy.

Interfața cu utilizatorul este o interfață intuitivă, aceasta permite crearea variabilei de intrare sau de ieșire și permite crearea unei variabile lingvistice cu funcții de membru tip trapezoidal sau tip singleton. Interfața cu utilizatorul este prezentată în figura 6.9 :

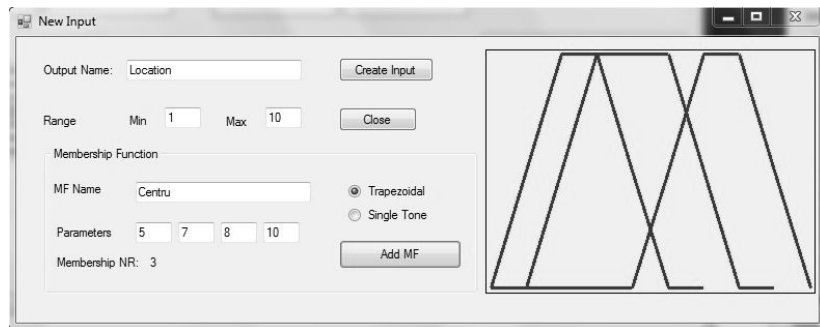


Figura 6.9 interfața editorul de variabile lingvistice.

Primul pas pentru crearea variabilei lingvistice este definirea unui nume și a unui domeniul pe care vor fi reprezentate seturile fuzzy. Al doilea pas este definirea funcțiilor de membru asociate variabilei lingvistice, una câte una. Editorul permite crearea funcțiilor de tip trapezoidal și de tip single tone. Pentru variabile de tip trapezoidal este obligatoriu să se precizeze limitele inferioare și cele superioare.

Editorul de sisteme cu inferență fuzzy permite salvarea reprezentărilor acestora sub formă de fișiere de tip XML. Un schelet al sistemului de inferență salvat în format XML se poate observa mai jos:

```
<?xml version="1.0"?>
<FuzzyInference>
<System>

<Name> name </Name>
<NumInputs>nr</NumInputs>
<NumOutputs>nr</NumOutputs>
<NumRules>nr</NumRules>
<DefuzzMethod Value="nr"> Type </DefuzzMethod>

</System>

<Input>
<Name> Input_Name </Name>
<Range MIN="nr" MAX="nr" />
<Labels>
.....
<Label_Name v0="nr" v1="nr" v2="nr" v3="nr" />
.....
</Labels>
</Input>

<Output>
<Name> Output_Name </Name>
<Range MIN="nr" MAX="nr" />
<Labels>
.....
<Label_Name v0="nr" v1="nr" v2="nr" v3="nr" />
.....
</Labels>
</Output>
</FuzzyInference>
```

```
.....  
</Labels>  
</Output>  
<Rules>  
  
</Rules>  
</FuzzyInference>
```

Folosind scheletul prezentat mai sus se poate genera o reprezentare a sistemului cu inferență fuzzy folosind algoritmul de parsare din figura 3.8. Acest XML permite utilizatorului și întregului program o implementare de tip *on-the-fly*. Acesta înseamnă că nu mai este necesară refactorizarea programului pentru schimbarea sistemului de inferență, acest rezolvându-se prin intermediul câtorva click-uri de mouse.

6.4 Generatorul de reguli cu algoritmi genetici

Pentru implementarea algoritmului genetic prezentat la capitolul 5 am realizat un program în limbajul C# sub tehnologia .NET și codurile open source AForge.Net. Codurile open source au oferit funcționalități de bază pentru algoritmi genetici. Pe baza acestor funcționalități au fost create noi clase care să reprezinte cromozomii în forma propusă și o altă clasă pentru funcția de fitness.

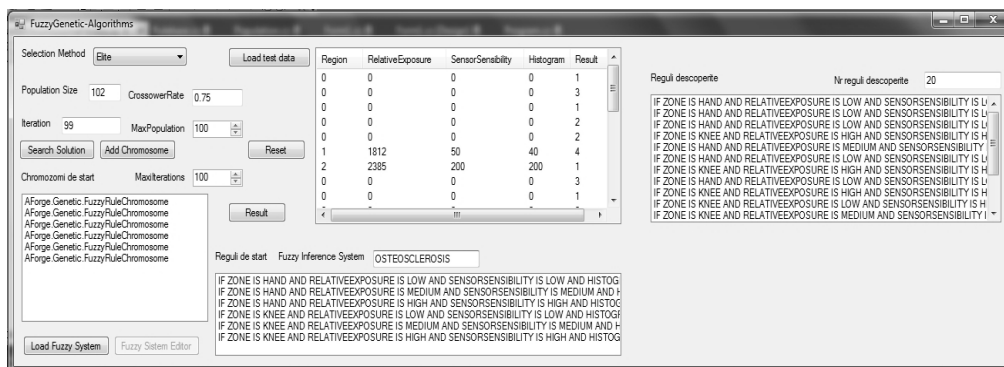


Figura 6.10 Fereastra principală a programului cu algoritmi genetici.

Intrările pentru program sunt următoarele: un set de date de antrenament care să reprezinte segmentele de imagine în formă numerică cu valorile numerice corespunzătoare situației și un sistem de inferență fuzzy care să conțină un set minimal de reguli aleatorii conform cerințelor din capitolul 5.

Regulile sunt codificate în cromozomi astfel s-a creat o populație inițială de cromozomi pentru rularea algoritmilor genetici. Ieșirile obținute sunt regulile valide generate cu algoritmul genetic propus.

Mai jos este prezentat pseudocodul programului:

```
Se introduc datele de antrenament în sistem dintr-un fișier specific  
programului.  
Se introduce în program sistemul cu inferență fuzzy inițial cu regulile inițiale  
aleatorii.
```

Se creează populația inițială.
 Se setează numărul maxim de iterații.
 Se setează numărul maxim de cromozomi în populație.

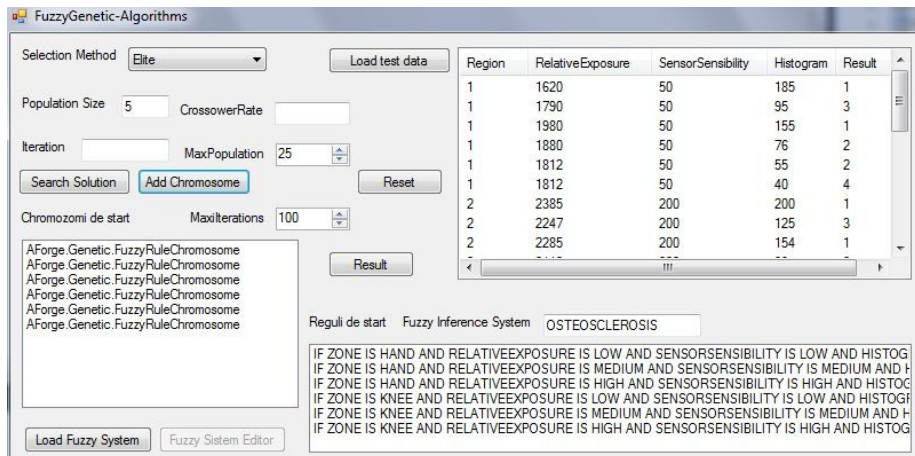


Figura 6.11 Datele de intrare pentru program.

Se pornește procesul de generare a regulilor de inferență.
 La fiecare iterație se realizează un crossover între cromozomi. Metoda de crossover este prezentată mai jos:

```

int crossOverPoint = rand.Next( parent1.Length - 1 );

if ( (crossOverPoint%2) != 0 ) // nu este un index par
{
    crossOverPoint = crossOverPoint + 1;
}

for (int i = 0; i < genes.Length; i++)
{
    if (i <= crossOverPoint)
    {
        child[i] = parent1[i];
    }
    else
    {
        child[i] = parent2[i];
    }
}

```

După crossover cromozomii sunt decodificați în reguli și testați prin aplicare regulii fuzzy obținute pe datele de antrenament. Procesul de decodificare este prezentat mai jos:

```

string[] m_genes = gene;
int nr_genes = m_genes.Length;
bool premiza = true;
string fuzzyRule = "";

```

```
// se reconstruieste regula in forma de tip IF _ IS _ AND _ IS _ THEN _ IS
-
for (int i = 0; i < nr_genes; i++)
{
    if (premiza == true)
    {
        if (i == 0) // se verifica daca suntem la primul element
        {
            fuzzyRule = "IF " + genes[i] + " IS "; // variabila lingvistica
        }
        else
        {
            if ((i % 2) != 0) // suntem la impar
            {
                fuzzyRule = fuzzyRule + genes[i]; // Setul fuzzy
            }
            if ((i % 2) == 0) // suntem la par
            {
                fuzzyRule = fuzzyRule + " AND ";
                fuzzyRule =fuzzyRule+genes[i] +"IS"; // Variabila ingvistica
            }
        }
    }
}
```

Procesul de generare este terminat în momentul în care nu mai există date de antrenament sau dacă s-a realizat un număr de iterații egal cu numărul maxim de iterații.

Programul returnează un set de reguli fuzzy care sunt introduse într-un sistem nou cu inferență fuzzy. Regulile rezultate sunt prezentate în figura 6.12:

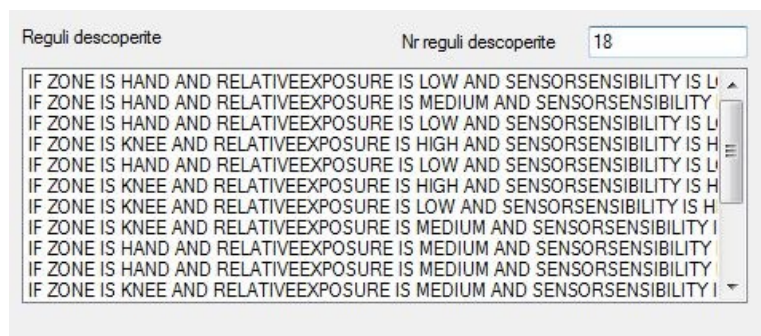


Figura 6.12 Regulile rezultate prin generare cu algoritmi genetici.

6.5 Concluzii și testarea inițială

Implementarea software a metodelor prezentate în capitolul 4 a generat serie de noutăți care au ajutat la extinderea sistemelor open source folosite.

Primul element de noutate prezentat este contopirea a două sisteme open source de imagistică. Aceste sisteme open source au suferit modificări pentru a crea o compatibilitate între ele. Primul sistem este un cititor de imagini DICOM care are rolul de a separa metadatele de imaginea propriu zisă. Al doilea sistem open source este cadrul de lucru AForge.Net care pune la dispoziție unelte de imagistică precum: segmentare, extragere de informații din segment, analiza conturului folosind transformate Fourier, etc. A treia noutate o reprezintă posibilitatea de a introduce sisteme cu inferență fuzzy în program fără refactorizarea programului.

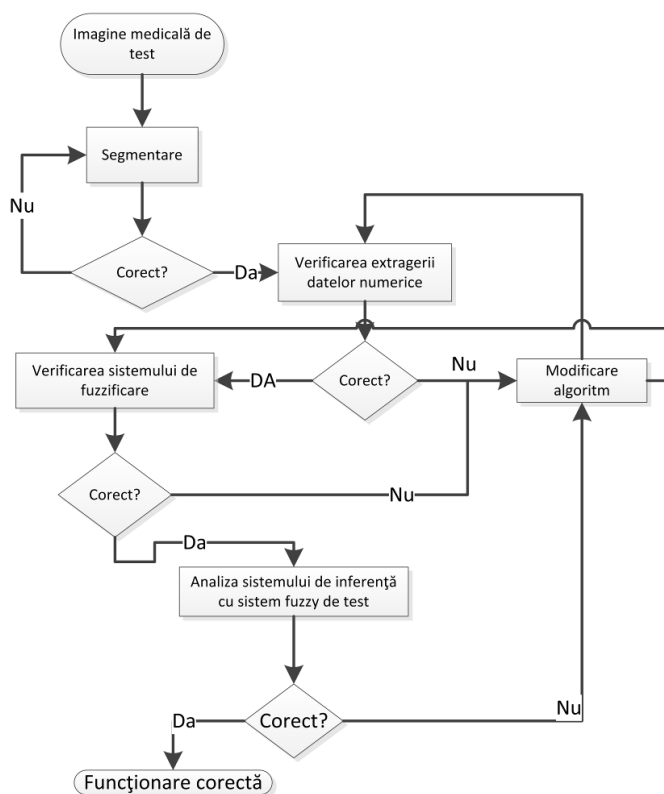


Figura 6.13 Schema de testare a programului.

Folosind acest cadru de lucru AForge și unelte fuzzy, s-a creat un editor de sisteme de inferență fuzzy care salvează sistemul de inferență în fișiere XML. Fișierele XML permit o implementare 'on-the-fly' a sistemului de inferență fuzzy.

Testarea programului s-a realizat după schema din figura 6.10 pentru verificarea metodelor implementate.

Pentru procesul de testare s-au folosit o serie de imagini medicale de tip RMN T1FS, T2FSE care prezintă un edem cerebral și diferite țesuturi din zona craniului.




Figura 6.14 Imagine RMN T2 FSE coronal cu edem cerebral.

Primul modul testat a fost cel de segmentare. Astfel s-a evaluat vizual dacă procesul de segmentare a fost realizat corect sau nu. După aceea au urmat modulele de extracție de date numerice. Aici s-a verificat dacă valorile numerice extrase sunt în formatul necesar pentru procesul de fuzzificare.

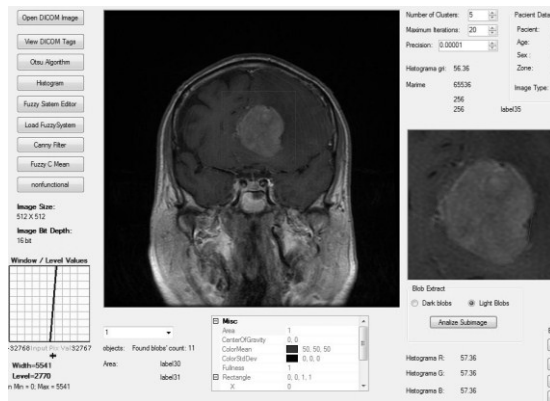


Figura 6.15 Fereastra principală cu imaginea de test.

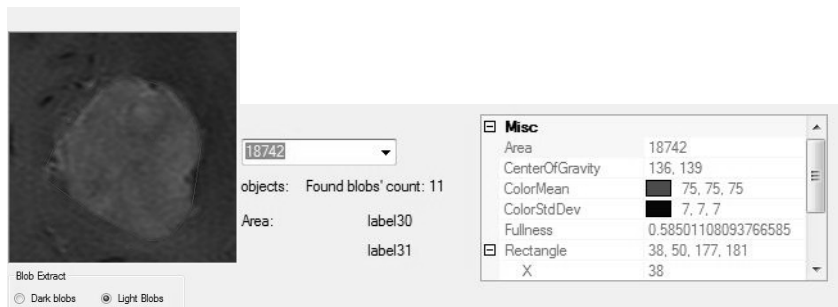


Figura 6.16 Obiectul segmentat și datele numerice ale obiectului.

Dacă se creează doar un modul schelet al sistemului de inferență fuzzy, care nu are valori implicite, într-un limbaj de programare oarecare, acel 'schelet' se poate completa din mers cu valorile din fișierul XML, fără recompilarea softului cu noile valori.

Exemplul următor prezintă un sistem de inferență fuzzy salvat în XML. Acest XML a fost folosit pentru testarea sistemului și are rolul de a determina consistența obiectului investigat, bazându-se pe histograma obiectului investigat din imaginea medicală:

```
<?xml version="1.0"?>
<FuzzyInference>
  <System>
    <Name>Consistentă</Name>
    <NumInputs>1</NumInputs>
    <NumOutputs>1</NumOutputs>
    <NumRules>1</NumRules>
    <DefuzzMethod Value="1000">Centroid</DefuzzMethod>
  </System>
  <Input>
    <Name>Histograma</Name>
    <Range MIN="1" MAX="255" />
    <Labels>
      <Negru v0="10" v1="20" v2="30" v3="40" />
      <Închis v0="40" v1="60" v2="80" v3="115" />
      <Gri v0="120" v1="130" v2="140" v3="150" />
      <Alb v0="190" v1="200" v2="210" v3="220" />
      <Deschis v0="150" v1="160" v2="170" v3="180" />
    </Labels>
  </Input>
  <Output>
    <Name>Natura</Name>
    <Range MIN="1" MAX="10" />
    <Labels>
      <HipoIntens v0="1" v1="2" v2="3" v3="4" />
      <HiperIntens v0="5" v1="6" v2="7" v3="8" />
    </Labels>
  </Output>
  <Rules>
    <Regula1>IF Histograma IS Negru THEN Natura IS HipoIntens</Regula1>
    <Regula2>IF Histograma IS Gri THEN Natura IS HipoIntens</Regula2>
    <Regula3>IF Histograma IS Deschis THEN Natura IS HiperIntens</Regula3>
    <Regula4>IF Histograma IS Închis THEN Natura IS HiperIntens</Regula4>
  </Rules>
</FuzzyInference>
```

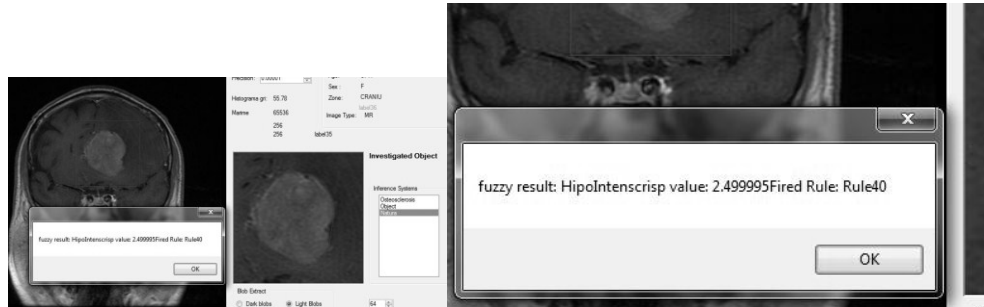


Figura 6.17 Verificarea sistemului de inferență.

Procesul de fuzzificare și sistemul cu inferență au fost verificate prin utilizarea unui sistem de inferență fuzzy prezentat mai sus care determină hiper sau hipo intensitatea obiectului (Figura 6.13). Astfel s-a verificat dacă sistemul cu inferență funcționează corect sau nu.

După încheierea acestor testări, s-a trecut la evaluarea metodei pe cazuri clinice, utilizând radiografiile digitale, imagini RMN și CT.

7. Rezultate experimentale

În acest capitol vor fi prezentate experimente pentru verificarea metodelor propuse în capitolele anterioare. Primele două experimente verifică utilizabilitatea sistemului de inferență fuzzy pentru analiza imaginilor medicale. Vor fi folosite diverse tipuri de imagini medicale, acestea prezintă diverse patologii benigne sau maligne. Al treilea experiment verifică utilizabilitatea algoritmilor genetici pentru realizarea regulilor fuzzy. Aceste reguli vor fi folosite pentru analiza imaginilor medicale pe nivelul semantic.

Pentru primul experiment vom alege imagini medicale care au un diagnostic stabilit. Aceste imagini se numesc imagini de control și vor fi alese de cadrul medical dintr-o bază de imagini medicale. Ele au rol de etalon în testarea aplicației.

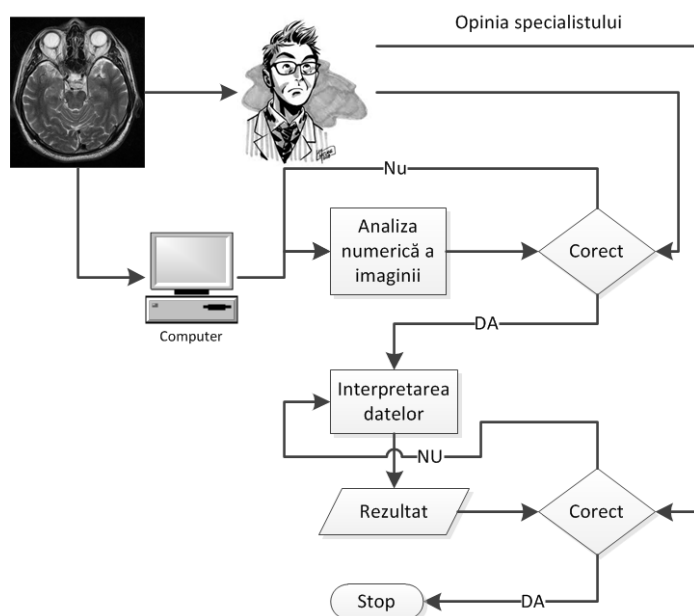


Figura 7.1 Verificarea metodei de analiză pe nivel semantic a imaginilor medicale.

Imaginile de control vor fi analizate folosind programul realizat. Prima parte a analizei este prelucrarea numerică a imaginilor de control. Aici se va pune accent pe segmentarea imaginii. Este important ca segmentarea să se realizeze corect. Medicul va lua parte la validarea metodei pe mai multe tipuri de imagini medicale și patologii. Va analiza rezultatul segmentării prin analiză vizuală. Se vor identifica și datele numerice referitoare la subimagine, datele despre formă, histogramă, mărime, și locație. În momentul în care avem la dispoziție toate datele necesare interpretării vom trece la pasul următor.

Datele numerice obținute direct din subimagine sau din metadate vor fi supuse fuzzificării și apoi folosind o bază de reguli fuzzy de tip IF-THEN se va efectua inferența diagnosticului folosind sistemul cu inferență fuzzy. Tot procesul va

fi supervizat de un medic specialist. Acesta are rolul de a verifica rezultatul fuzzy, în cazul în care coincide cu patologia propusă de algoritmul fuzzy. Dacă metoda furnizează rezultate corecte pe diverse imagini de test, se va trece la analiza imaginilor necunoscute.

7.1 Recunoașterea patologiilor ventriculare și a diferitelor tipuri de țesuturi

Principalul obiectiv al acestui experiment a fost determinarea capacității sistemului de identificare a diferitelor țesuturi și patologii în imaginile medicale. S-a urmărit dacă sistemul propus diferențiază țesuturile normale de cele patologice folosind sisteme cu inferență fuzzy.

Pentru acest test s-au utilizat 160 de imagini RMN de tip T1 și T2 care provin din diferite axe de achiziții și au ca obiectiv prezentarea unei tumori maligne și a unei complicații ventriculare .




Figura 7.2 Exemple de imagini RMN folosite pentru testare.

Imaginile utilizate au fost create nativ la o rezoluție de 512x512 pixeli, în tonuri de gri codificate pe 16 biți. Fiecare imagine din setul de achiziții are o grosime de 5 unități, iar distanța dintre imagini este de 6.5 unități. Pentru calcularea mărimii în mm^2 a ariei obiectului s-a folosit ecuația (6.2).

Au fost utilizate imagini din planul de achiziție:

- Coronal: 54 de imagini RMN T1 SE (spin echo);
- Axial: 22 T2 FSE(fast spin echo), 22 T2 Flair (se utilizează substanță de contrast) și 22 de imagini T1 SE.
- Sagital: 20 de imagini T2 FSE și 20 de imagini T1 SE.

În imaginile de rezonanță magnetică imaginile de tip T1 SE obiectele au următoarele proprietăți:

7.1 Recunoașterea patologiilor ventriculare și a diferitelor tipuri de țesuturi - 99 -

- Obiecte hiperintense: țesutul adipos, methemoglobina, depozitele de minerale, melanina și fluidele superproteice.
- Obiecte hipointense: apa, protoni hipomobili (aer și os cortical), fluxurile rapide de sânge.

În imaginile de RMN de tip T2 FSE obiectele au următoarele proprietăți:

- Obiecte hipointense: hematumul subacut, depozitele de minerale, fluxul rapid de fluide, apa puțină și protonii imobili.
- Obiecte hiperintense: apa, colecții de fluide, edem, demielinizare, țesut adipos.

În imaginile de test folosite s-au identificat următoarele obiecte: ventricul sănătos, edem cerebral, materie cenușie și fragmente osoase. Aceste obiecte au următoarele proprietăți fizice de interes: histogramă, mărime și locație. Cea mai mare diferență în cadrul proprietăților fizice ale obiectelor apare la histogramă. Histograma obiectelor are o valoare diferită în cazul achiziției de tip T1 SE față de valoarea pe care o obținem în cazul achiziției de tip T2 FSE și T2 FLAIR. Tabelul 7.1 însumează proprietățile de hipo sau hiperintensitate a obiectelor de interes la diferite moduri de achiziție.

Tabelul 7.1 Proprietățile de intensitate ale țesuturilor în achiziția RMN de tip T1-SE, T2-FSE, T2-FLAIR

Țesut	Proprietate de intensitate		
	T1-SE	T2-FSE	T2-FLAIR
Ventricul Deformat	suprimat	hiperintens → gri	hiperintens
Ventricul Normal	hipointens	hiperintens	hipointens
Materie Cenușie	gri → hipointens	gri → hipointens	gri normal
Fragmente de os	hiperintens	hiperintens	hiperintens

Aceste proprietăți au fost achiziționate la mijlocul seriei de achiziție, de la imaginile 7 până la imaginile 12-15 din seria de achiziție axială care însumează 20 de imagini. S-au ales aceste imagini deoarece la mijlocul achiziției dispunem de cele mai multe obiecte sau în cazul nostru țesuturi. Tabelul de mai jos însumează restul proprietăților fizice.

Tabelul 7.2 Proprietățile fizice ale obiectelor investigate

Țesut - Obiect	Număr felie etalon	Mărime mm ²
Edem CSF cerebral	6,7,8,9,	6.14, 6.8, 6.8, 5,
Ventricul Normal	6,7,8,9,	2.5, 2.9,-
Materie Cenușie	6,7,8,9,	5.4, 4.8, 7, 3,15
Fragmente de os	6,7,8,9,	4.5, 3.6, 1,25

Pe baza acestor proprietăți fizice s-au construit următoarele variabile lingvistice care codifică în limbaj natural mărimea obiectelor, histograma obiectelor și alte proprietăți de interes din imaginea segmentată. De exemplu pentru histogramă și mărime s-au creat următoarele variabile lingvistice:

```
<Input>
<Name>Histograma</Name>
<Range MIN="0" MAX="255" />
<Labels>
<Black v0="1" v1="25" v2="40" v3="50" />
<Dark v0="40" v1="50" v2="60" v3="70" />
<DarkGray v0="70" v1="80" v2="85" v3="90" />
<Gray v0="90" v1="100" v2="140" v3="150" />
<LightGray v0="150" v1="160" v2="190" v3="200"/>
<White v0="180" v1="200" v2="220" v3="255" />
</Labels>
</Input>
```

Histograma este definită pe un domeniu de la 0 la 255. Între 0 și 50 este definită valoarea lingvistică Negru, între 40 și 70 am definit variabila Închis, între 70 și 90 am definit variabila Gri_Închis, între 90-150 avem valoarea Gri, 150-200 este zona definită pentru Gri_Deschis și 150-200 pentru Alb. În momentul creării regulilor se va ține cont de proprietățile de hipo- sau hiperintensitate.

Hipo- sau hiperintensitatea obiectului variază în funcție de diferitele tipuri de achiziții, astfel accesăm metadata de la adresa (0008, 103E) din lista de DICOM TAG-uri. Această metadata ne furnizează tipul achiziției.

Mărimea este definită pe un domeniu de la 0 la 10. Obiectele *FoarteMici* sunt definite pe domeniul 0-1, obiectele *Mici* sunt definite pe domeniul 1-5, obiectele *Normale* sunt definite pe domeniul 4-7 iar obiectele *Mare* domeniul 6-10. Variabila lingvistică în format XML se poate observa mai jos:

```
<Input>
<Name>Size</Name>
<Range MIN="0" MAX="10" />
<Labels>
<VerySmall v0="0" v1="0.2" v2="0.9" v3="1" />
```

```

<Small v0="1" v1="2" v2="3" v3="5" />
<Normal v0="4" v1="5" v2="6" v3="7" />
<Big v0="6" v1="8" v2="9" v3="10" />
</Labels>
</Input>

```

Pentru codificarea rezultatelor s-a realizat următoarea variabilă lingvistică :

```

<Output>
<Name>Diagnosis</Name>
<Range MIN="0" MAX="10" />
<Labels>
<Ventricle v0="0" v1="1" v2="2" v3="3" />
<GrayMater v0="2" v1="3" v2="4" v3="5" />
<Bone v0="4" v1="5" v2="6" v3="7" />
<Edem v0="6" v1="7" v2="8" v3="9" />
</Labels>
</Output>

```

Folosind aceste variabile lingvistice s-a creat baza de reguli care permite identificarea obiectelor din imaginea segmentată. Regulile au fost obținute prin discuții cu un medic specialist din cadrul Clinicii de Recuperare, medicină fizică, balneologie și reumatologie din cadrul Spitalului Municipal de Urgență Timișoara, urmărind raționamentul acestuia în diverse situații de diagnoză imagistică. Au fost verificate proprietățile obiectelor regăsite în imaginile de etalon și pe baza acestor proprietăți s-au creat reguli de inferență fuzzy. În total s-au creat 39 reguli. Următorul exemplu prezintă 26 reguli din cele 39 care se referă la achiziția de tip T2 FLAIR și T2FSE:

```

<Rule1>IF Mode Is T2Flair AND Histograma IS Gray AND Size IS Big THEN
Diagnosis IS Edem</Rule1>
<Rule2>IF Mode Is T2Flair AND Size IS Small AND Histograma IS Dark THEN
Diagnosis IS GrayMater</Rule2>
<Rule3>IF Mode Is T2Flair AND Size IS Normal AND Histograma IS LightGray
THEN Diagnosis IS Edem</Rule3>
<Rule4>IF Mode Is T2Flair AND Histograma IS Black AND Size IS VerySmall THEN
Diagnosis IS Ventricle</Rule4>
<Rule5>IF Mode Is T2Flair AND Histograma IS Dark AND Size IS Small THEN
Diagnosis IS GrayMater</Rule5>
<Rule6>IF Mode Is T2Flair AND Histograma IS Gray AND Size IS Small THEN
Diagnosis IS Edem</Rule6>
<Rule7>IF Mode Is T2Flair AND Histograma IS Dark AND Size IS VerySmall THEN
Diagnosis IS Fragment</Rule7>
<Rule8>IF Mode Is T2Flair AND Histograma IS Gray AND Size IS VerySmall THEN
Diagnosis IS GrayMater</Rule8>
<Rule9>IF Mode Is T2Flair AND Histograma IS LightGray AND Size IS VerySmall
THEN Diagnosis IS Edem</Rule9>
<Rule10>IF Mode Is T2Flair AND Histograma IS Black AND Size IS Big THEN
Diagnosis IS Ventricle</Rule10>
<Rule11>IF Mode Is T2Flair AND Histograma IS Black AND Size IS Normal THEN
Diagnosis IS Ventricle</Rule11>

```

<Rule12>IF Mode Is T2Flair AND Histograma IS Black AND Size IS Small THEN Diagnosis IS Ventricle</Rule12>
<Rule13>IF Mode Is T2Flair AND Histograma IS Gray AND Size IS Normal THEN Diagnosis IS Edem</Rule13>
<Rule14>IF Mode Is T2FSE AND Histograma IS Gray AND Size IS Big THEN Diagnosis IS Edem</Rule14>
<Rule15>IF Mode Is T2FSE AND Size IS Small AND Histograma IS Dark THEN Diagnosis IS GrayMater</Rule15>
<Rule16>IF Mode Is T2FSE AND Size IS Normal AND Histograma IS LightGray THEN Diagnosis IS Edem</Rule16>
<Rule17>IF Mode Is T2FSE AND Histograma IS White AND Size IS VerySmall THEN Diagnosis IS Ventricle</Rule17>
<Rule18>IF Mode Is T2FSE AND Histograma IS Dark AND Size IS Small THEN Diagnosis IS GrayMater</Rule18>
<Rule19>IF Mode Is T2FSE AND Histograma IS LightGray AND Size IS Small THEN Diagnosis IS Edem</Rule19>
<Rule20>IF Mode Is T2FSE AND Histograma IS Dark AND Size IS VerySmall THEN Diagnosis IS Fragment</Rule20>
<Rule21>IF Mode Is T2FSE AND Histograma IS Gray AND Size IS VerySmall THEN Diagnosis IS GrayMater</Rule21>
<Rule22>IF Mode Is T2FSE AND Histograma IS LightGray AND Size IS VerySmall THEN Diagnosis IS Edem</Rule22>
<Rule23>IF Mode Is T2FSE AND Histograma IS Black AND Size IS Big THEN Diagnosis IS Ventricle</Rule23>
<Rule24>IF Mode Is T2FSE AND Histograma IS LightGray AND Size IS Normal THEN Diagnosis IS Ventricle</Rule24>
<Rule25>IF Mode Is T2FSE AND Histograma IS White AND Size IS Small THEN Diagnosis IS Ventricle</Rule25>
<Rule26>IF Mode Is T2FSE AND Histograma IS Gray AND Size IS Normal THEN Diagnosis IS Edem</Rule26>

Pe imaginile următoare se poate observa recunoașterea următoarelor obiecte: ventricul normal și edem cerebral.

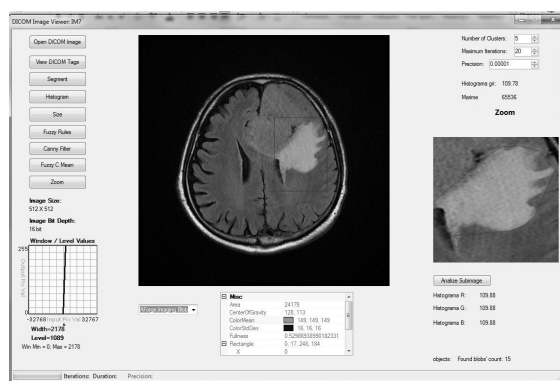


Figura 7.3a Fereastra principală.




Figura 7.3b,c Ventricle normal și edem cerebral cauzat de CSF.

Acest experiment a demonstrat capacitățile sistemului propus pentru identificarea diferitelor țesuturi și patologii pe diferite tipuri de imagini RMN. Chiar dacă acest experiment s-a derulat în condiții de laborator pe un caz clinic deja diagnosticat, sistemul a reușit să identifice: țesutul osos din craniu, materia cenușie care compune creierul dar a reușit să identifice și patologii sau organe sănătoase. Astfel s-a identificat cu succes un ventricul normal și o deformare cauzată de o tumoră care a provocat inundarea creierului cu lichid cerebral provocând un edem cerebral. Tabelul 7.3 prezintă numărul total de imagini dintr-o achiziție oarecare și numărul de imagini în care s-au identificat diverse obiecte de imagine.

Tabelul 7.3 Sinteza identificărilor în diferite tipuri de achiziții

Achiziție		Materie cenușie nr_identificat (nr_total)	Edem cerebral nr_identificat (nr_total)	Ventricul nr_identificat (nr_total)	Fragmente de os nr_identificat (nr_total)
T 1	Coronal	54(54)	40(54)	41(54)	50(54)
	Axial	18(22)	12(22)	12(22)	20(22)
	Sagital	19(20)	11(20)	11(20)	18(20)
T 2	Axial (FSE)	18(22)	12(22)	12(22)	20(22)
	Sagita (FSE)	17(20)	10(20)	10(20)	17(20)
	Axial (FLAIR)	20(22)	12(22)	12(22)	20(22)

Totodată acest test a dovedit flexibilitatea sistemului care permite identificarea obiectelor de pe mai multe tipuri de imagini. Au fost utilizate imagini de pe toate cele 3 axe și toate cele 3 tipuri de achiziții de bază.

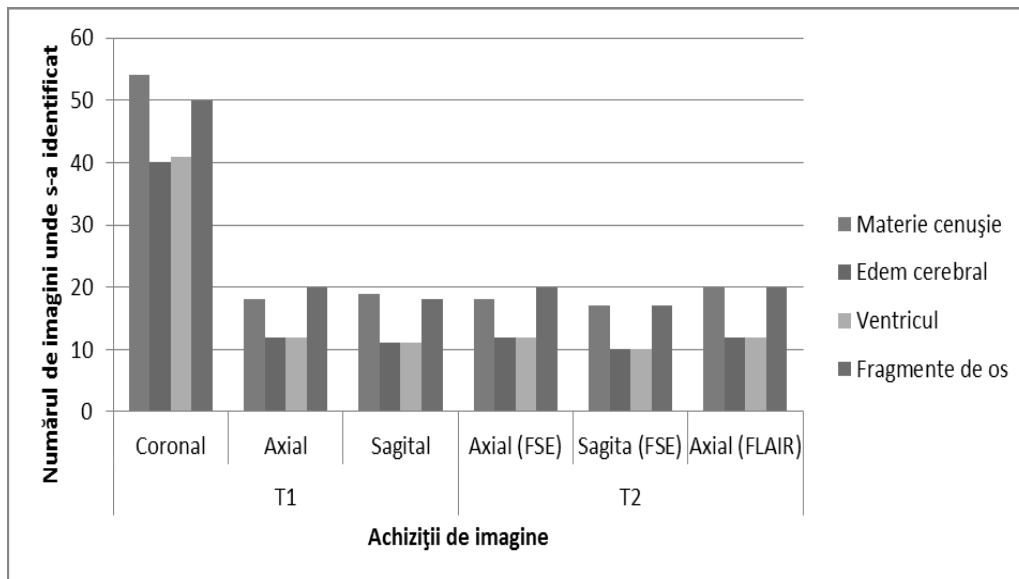


Figura 7.4 Sinteza identificărilor în diferite tipuri de achiziții.

Codificarea valorilor numerice care definesc obiectele în format numeric s-a realizat folosind câte o variabilă lingvistică pentru fiecare. În sistemul cu inferență s-a introdus și o metadată de la adresa (0008,103E) care descriere tipul de achiziție. Aceasta permite identificarea regulilor din baza de reguli care vor fi utilizate pentru o interpretare corectă. Această metadată oferă o siguranță că proprietățile de hipo sau hiperintensitate vor fi luate în considerare corect și se va evita inferarea unui rezultat fals, fie negativ fie pozitiv.

Figura 7.4 sintetizează rezultatele obținute și prezentate în tabelul 7.3. La extremitățile achizițiilor se pot identifica atât materia cenușie cât și fragmente osoase. La mijlocul achizițiilor se poate identifica atât ventriculul sănătos cât și edemul cerebral. Se poate observa că din totalul de imagini analizate doar în 2-3% nu s-a detectat nimic. Datorită anatomiei omului doar în 50 % din totalul imaginilor s-a reușit detectarea edemului și a ventriculului de la nivelul craniului

7.2 Detectarea osteosclerozei pe radiografii

Următorul experiment a fost realizat în condiții clinice folosind radiografii digitale în format DICOM pentru identificarea osteosclerozei.

Acest experiment a fost efectuat în cadrul Clinicii de Recuperare, medicină fizică, balneologie și reumatologie din cadrul Spitalului Municipal de Urgență Timișoara pe un eșantion de 12 pacienți care prezentau diferite simptome la 24 arii anatomice.




Figura 7.5 Ariile anatomice investigate.

Următoarele arii anatomice au fost investigate: primul metacarpian, falangele degetelor, extremitățile ulnei și a radiusului, extremitățile proximale ale tibiei și distale ale femurului. Este important să detectăm la timp osteoscleroza deoarece este primul semn care indică dezvoltarea unei patologii mult mai severe. Radiografiile au fost salvate în format DICOM și create folosind aparatul AGFA cr30x.

Imaginea investigată este afișată pe ecran folosind descriptorul de LUT (Look Up Table) din metadatele imaginii. Acest LUT precizează valoarea nativă pentru fiecare pixel în parte. Astfel avem certitudinea că imaginea a fost afișată corect fără pierderi de date importante. Acest descriptor codifică trei valori utile: prima valoare indică numărul total de intrări în LUT, a doua valoare ne precizează valoarea minimă din LUT iar a treia valoare ne prezintă numărul de biți pe care a fost codificată imaginea. Folosind aceste date și o formulă propusă putem calcula lățimea și centrul valorilor care sunt folosite pentru a afișa imaginea:

$$latime = LutDescriptor[1] \quad (7.1)$$

$$centru = \frac{latime + LutDescriptor[0]}{2} \quad (7.2)$$

Primul pas în identificarea și interpretarea semnelor care indică prezența bolii este segmentarea imaginilor radiologice pentru izolarea zonelor osoase de țesuturile moi. Segmentarea imaginilor s-a efectuat folosind un sistem de segmentare hibrid. Cadrul medical a selectat zona care conține ariile anatomice investigate iar un algoritm de segmentare bazat pe valori de prag a separat regiunile osoase de fundal și țesuturi moi. Această segmentare se poate observa în figura 7.4.

Segmentarea s-a realizat folosind metoda valorilor de prag și s-a folosit formula 4.3 pentru identificarea valorilor de prag.

Valorile de offset acceptate: pentru zona falangelor, o valoare k de 9-10, pentru zona metacarpianelor o valoare de 15-16 iar pentru zona genunchiului o valoare de 17-18.



Figura 7.6 a. segmentarea falangelor b. segmentarea ulnei, radiusului și metacarpianelor.

Osteoscleroza este o boală care afectează densitatea structurii osoase din zona articulațiilor. Pe radiografie oasele apar mai dense decât ar fi normal sau mai precis devin mai albe în unele locuri. Din acest motiv valoarea numerică de interes a zonelor segmentate pentru confirmarea prezenței bolii, este valoarea medie a histogramei a țesutului osos investigat.

Histograma segmentelor de imagine s-a divizat în felul următor: de la 0 la 255 unde 0 reprezintă valoarea lingvistică "Negru" iar 255 reprezintă "Alb".




Figure 7.7 Funcții de membru trapezoidale pentru histogramă.

Deoarece histograma obiectelor care apar în imagine poate să se modifice după operațiile de preprocesare, imaginea medicală va fi afișată conform celor precizate mai sus, luând în considerare și descriptorul LUT din metadata. Pentru a evita diverse erori de interpretare imaginea este supusă unui test care verifică dacă a fost expusă corect sau incorect.

Pentru detectarea osteosclerozei s-a format o bază de reguli care permite identificarea și interpretarea semnelor care indică această boală. Regulile de inferență sunt formate în așa manieră încât iau în considerare nu doar date directe obținute după segmentarea imaginii ci și metadatale importante. Aceste metadata sunt accesibile datorită secțiunii de metadata din imaginile DICOM. Metadatale de interes sunt:

- Valoarea dozei de iradiere relativă, care indică doza de raze x folosită.
- Sensibilitatea senzorului de scanare a sistemului de digitalizare.
- Regiunea anatomică investigată: mână, genunchi sau picior.

Folosind aceste valori s-au creat reguli de inferență fuzzy care verifică dacă aceste imagini au fost sau nu expuse corect. În cazul în care imaginea este sub sau supra expusă se pot pierde informații importante și pot apărea diverse erori de tip fals pozitiv sau fals negativ. Pentru generarea regulilor de inferență fuzzy din setul de imagini au fost alese șase imagini etalon: trei imagini din regiunea mâinii și trei imagini din zona genunchiului. La aceste imagini au fost verificate proprietățile menționate mai sus și prin discuții cu medicii de specialitate și prin corelarea proprietăților s-au obținut următoarele reguli care verifică expunerea imaginilor radiologice digitale:

1. **If region is knee and x-ray_exposure is high and sensor is high then exposure is correct.**
2. **If region is knee and x-ray_exposure is low and sensor is low then exposure is underexposed.**
3. **If region is hand and x-ray_exposure is low and sensor is low then exposure is correct.**
4. **If region is hand and x-ray_exposure is high and sensor is high then exposure is overexposed.**

Dozele de iradiere utilizate în cadrul radiografiilor, au variat pe o plajă de la 1500 până la 2800 de unități. Această plajă a fost împărțită în 3 subplaje: iradiere mică de la 1500 la 2200, iradiere medie de la 2100 la 2500 și o iradiere mare de la 2400 la 2800 de unități.

Sensibilitatea senzorului de scanare are o plajă de sensibilitate de la 0 la 250 de unități. Această plajă se poate împărți în mai multe subplaje astfel: sensibilitate mică de la 0 la 80, sensibilitate medie de la 60 la 140 și o sensibilitate mare de la 140 la 250 de unități. Incluzând în regulă și zona anatomică investigată s-a făcut o corelare între expunerea corectă a imaginilor, a dozei de iradiere și a sensibilității senzorului de scanare.

În total s-au urmărit 24 de reguli pentru identificarea osteosclerozei. S-a efectuat o corelare și între expunerea imaginii și a histogramei analizate. Astfel s-au efectuat și compensări pentru cazurile în care expunerea imaginii nu este corectă dar acest lucru nu periclitează punerea unui diagnostic corect. Regulile formate se pot observa mai jos:

```
<Rule1>IF Zone IS Hand AND RelativeExposure IS Low AND SensorSensitivity IS
Low AND Histogram IS White THEN Osteosclerosis IS Positive</Rule1>
<Rule2>IF Zone IS Hand AND RelativeExposure IS Low AND SensorSensitivity IS
Low AND Histogram IS Gray THEN Osteosclerosis IS Possible</Rule2>
<Rule3>IF Zone IS Hand AND RelativeExposure IS Low AND SensorSensitivity IS
Low AND Histogram IS LightGray THEN Osteosclerosis IS Positive</Rule3>
<Rule4>IF Zone IS Hand AND RelativeExposure IS Low AND SensorSensitivity IS
Low AND Histogram IS DarkGray THEN Osteosclerosis IS Negative</Rule4>
<Rule5>IF Zone IS Hand AND RelativeExposure IS Low AND SensorSensitivity IS
Low AND Histogram IS Dark THEN Osteosclerosis IS Negative</Rule5>
<Rule6>IF Zone IS Hand AND RelativeExposure IS Low AND SensorSensitivity IS
Low AND Histogram IS Black THEN Osteosclerosis IS Undefined</Rule6>
```

<Rule7>IF Zone IS Hand AND RelativeExposure IS Medium AND SensorSensibility IS Low AND Histogram IS Gray THEN Osteosclerosis IS Positive</Rule7>
<Rule8>IF Zone IS Hand AND RelativeExposure IS Medium AND SensorSensibility IS Low AND Histogram IS Black THEN Osteosclerosis IS Undefined</Rule8>
<Rule9>IF Zone IS Hand AND RelativeExposure IS Medium AND SensorSensibility IS Low AND Histogram IS Dark THEN Osteosclerosis IS Possible</Rule9>
<Rule10>IF Zone IS Hand AND RelativeExposure IS Medium AND SensorSensibility IS Low AND Histogram IS DarkGray THEN Osteosclerosis IS Possible</Rule10>
<Rule11>IF Zone IS Hand AND RelativeExposure IS Medium AND SensorSensibility IS Low AND Histogram IS LightGray THEN Osteosclerosis IS Positive</Rule11>
<Rule12>IF Zone IS Hand AND RelativeExposure IS Medium AND SensorSensibility IS Low AND Histogram IS White THEN Osteosclerosis IS Undefined</Rule12>
<Rule26>IF Zone IS Knee AND RelativeExposure IS High AND SensorSensibility IS High AND Histogram IS White THEN Osteosclerosis IS Positive</Rule26>
<Rule27>IF Zone IS Knee AND RelativeExposure IS High AND SensorSensibility IS High AND Histogram IS Gray THEN Osteosclerosis IS Possible</Rule27>
<Rule28>IF Zone IS Knee AND RelativeExposure IS High AND SensorSensibility IS High AND Histogram IS LightGray THEN Osteosclerosis IS Positive</Rule28>
<Rule29>IF Zone IS Knee AND RelativeExposure IS High AND SensorSensibility IS High AND Histogram IS DarkGray THEN Osteosclerosis IS Negative</Rule29>
<Rule30>IF Zone IS Knee AND RelativeExposure IS High AND SensorSensibility IS High AND Histogram IS Dark THEN Osteosclerosis IS Negative</Rule30>
<Rule31>IF Zone IS Knee AND RelativeExposure IS High AND SensorSensibility IS High AND Histogram IS Black THEN Osteosclerosis IS Undefined</Rule31>
<Rule32>IF Zone IS Knee AND RelativeExposure IS Medium AND SensorSensibility IS High AND Histogram IS White THEN Osteosclerosis IS Positive</Rule32>
<Rule33>IF Zone IS Knee AND RelativeExposure IS Medium AND SensorSensibility IS High AND Histogram IS Gray THEN Osteosclerosis IS Possible</Rule33>
<Rule34>IF Zone IS Knee AND RelativeExposure IS Medium AND SensorSensibility IS High AND Histogram IS LightGray THEN Osteosclerosis IS Positive</Rule34>
<Rule35>IF Zone IS Knee AND RelativeExposure IS Medium AND SensorSensibility IS High AND Histogram IS DarkGray THEN Osteosclerosis IS Negative</Rule35>
<Rule36>IF Zone IS Knee AND RelativeExposure IS Medium AND SensorSensibility IS High AND Histogram IS Dark THEN Osteosclerosis IS Negative</Rule36>
<Rule37>IF Zone IS Knee AND RelativeExposure IS Medium AND SensorSensibility IS High AND Histogram IS Black THEN Osteosclerosis IS Undefined</Rule37>

În total au fost analizate 206 arii anatomice, din care 23 de oase metacarpiene, 23 de falange de la degetul mare al mâinii, 23 de falange de la degetele 2,3,4 și 5 ale mâinii, 23 de extremități ale radiusului și ale ulnei și 11 extremități ale femurului și ale tibiei. Câteva exemple sunt prezentate în figurile 7.8, 7.9, 7.10.



Figura 7.8 Analiza falangelor.



Figura 7.9 Analiza articulației mâinii.



Figura 7.10 Analiza articulației genunchiului.

Rezultatele experimentului sunt prezentate în tabelele următoare:

Tabelul 7.4. Rezultatele pentru secțiunea articulației mâinii
 Legenda: "?" posibil, "+" pozitiv și "-" negativ

ID	Side	Sursa	Metacarpian	Falange 1	Falange 2	Falange 3	Falange 4	Falange 5	Radius	Ulna
1	Right	M.D.	?	-	-	-	-	-	?	-
		Fuzzy	?	-	-	-	-	-	-	-
	Left	M.D.	?	-	-	-	-	-	?	-
		Fuzzy	?	-	-	-	-	-	?	-
2	Right	M.D.	+	?	+	+	?	-	+	?
		Fuzzy	+	+	+	+	+	-	+	?
	Left	M.D.	+	?	+	+	?	-	+	?
		Fuzzy	+	?	+	+	?	-	+	?
3	Right	M.D.	+	?	?	?	?	?	+	+
		Fuzzy	+	?	?	?	?	?	+	+
	Left	M.D.	+	?	?	?	?	?	+	+
		Fuzzy	+	?	?	?	?	?	+	+
4	Right	M.D.	+	?	?	?	?	-	+	?
		Fuzzy	+	?	?	?	?	-	+	?
	Left	M.D.	+	?	?	?	?	-	+	?
		Fuzzy	+	?	+	?	+	-	+	?
5	Right	M.D.	?	-	-	-	-	-	?	-
		Fuzzy	?	-	-	-	-	-	?	-
	Left	M.D.	N.A.	N.A.	N.A.	N.A.	N.A.	N.A.	N.A.	N.A.
		Fuzzy	N.A.	N.A.	N.A.	N.A.	N.A.	N.A.	N.A.	N.A.

6	Right	M.D.	+	?	?	?	-	-	+	?
		Fuzzy	+	+	?	?	-	-	+	+
	Left	M.D.	+	?	?	?	-	-	+	?
		Fuzzy	+	+	?	?	-	-	+	?
7	Right	M.D.	+	?	?	?	?	-	+	+
		Fuzzy	+	?	?	?	?	-	+	+
	Left	M.D.	+	?	?	?	?	-	+	+
		Fuzzy	+	?	?	?	?	-	+	+
8	Right	M.D.	?	?	?	?	?	-	?	?
		Fuzzy	?	?	-	-	?	-	?	?
	Left	M.D.	?	?	?	?	?	-	?	?
		Fuzzy	?	?	-	-	?	-	?	?
9	Right	M.D.	+	?	?	?	?	?	+	?
		Fuzzy	+	?	?	?	?	?	+	+
	Left	M.D.	+	?	?	?	?	?	+	?
		Fuzzy	+	?	?	?	?	?	+	+
10	Right	M.D.	?	-	?	?	?	-	?	?
		Fuzzy	?	-	-	-	?	-	?	?
	Left	M.D.	?	-	?	?	?	-	?	?
		Fuzzy	?	-	-	-	?	-	?	?
11	Right	M.D.	+	?	?	?	?	?	+	?
		Fuzzy	+	+	?	?	?	?	+	+
	Left	M.D.	+	?	?	?	?	?	+	?
		Fuzzy	+	+	?	?	?	?	+	+
12	Right	M.D.	+	?	?	?	?	?	+	+

		Fuzzy	+	+	?	?	?	?	+	+
	Left	M.D.	+	?	?	?	?	?	+	+
		Fuzzy	+	+	?	?	?	?	+	+

Tabelul 7.5 Rezultatele pentru secțiunea articulației genunchiului

ID	Entity	Distal Femur	Proximal Tibia	Distal Femur	Proximal Tibia
1	M.D.	-	-	-	-
	Fuzzy	-	-	-	-
2	M.D.	+	+	+	+
	Fuzzy	+	+	+	+
3	M.D.	?	?	?	?
	Fuzzy	?	?	?	?
4	M.D.	?	?	N.A	N.A.
	Fuzzy	?	?	N.A	N.A.
5	M.D.	-	-	-	-
	Fuzzy	-	-	-	-
6	M.D.	?	?	?	?
	Fuzzy	?	?	?	?


În 24 de zone anatomică a fost observată o disconcordanță de 11,65% între rezultatele medicului și rezultatele obținute folosind metoda prezentată. În aceste cazuri, în 15 zone, sistemul fuzzy a prezentat existența bolii la falangele primului deget, celui de-al patrulea deget și la nivelul extremității distale a ulnei. Pentru alte 9 arii (4.38% din total) sistemul fuzzy a infirmat prezența bolii. Zonele de interes au fost falangele de la degetele 2 și 3 și extremitățile radiusului.

Probabilitatea prezenței osteosclerozei s-a întâlnit într-un procent ridicat (78.64%), în cadrul evaluării realizate de către medic, precum și în cazul evaluării realizate prin utilizarea sistemului fuzzy (74.24%).

Rezultatele furnizate de sistemul prezentat sunt foarte apropiate de rezultatele medicului specialist. În numai 1 din 10 zone anatomică a existat o disconcordanță între rezultatele furnizate de cele două evaluări, care sunt prezentate în figura 7.8. Pentru verificarea validității rezultatelor s-a realizat o corelație între rezultatele furnizate de sistemul cu inferență și rezultatul furnizat de medici. Corelația a fost calculată utilizând funcția CORREL din Excel care are următoarea formulă matematică:

$$CORRELL(x, y) = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 (y - \bar{y})^2}} \quad (7.3)$$

unde \bar{x} și \bar{y} sunt mediile vectorilor care vor fi comparați. Coeficientul de corelație minim pentru care se acceptă validitatea rezultatelor a fost ales de 85% sau 0.85. Coeficientul de corelație între cele două rezultate are o valoare bună de 0.886.



În acest test clinic sistemul a prezentat capacitatea de a detecta o altă patologie față de cea din subcapitolul anterior. Folosind imagini 2D de radiografii digitale ale membrilor inferioare și superioare s-a reușit identificarea osteosclerozei în mai multe cazuri clinice.

Pentru realizarea identificării au fost create în totalitate 24 de reguli de inferență fuzzy. În crearea regulilor au fost folosite variabile lingvistice care descriu proprietățile numerice ale obiectului investigat: histograma țesutului osos din zona

articulară, doza de iradiere și sensibilitatea senzorului de scanare. Metadatele au fost utile pentru determinarea expunerii, pentru compensarea sub sau supra expunerii. Regulile sunt construite pe o arhitectura cvasi silogistică. Prima parte din regulă verifică expunerea imaginii iar a doua parte verifică semnele existenței bolii. În cazul în care imaginea este sub sau supra expusă sistemul cu inferență va compensa procesul de inferare pentru returnarea unui diagnostic corect și eliminarea unui diagnostic fals. Rezultatele obținute au avut o corelație de 0.886 cu rezultatele medicilor. Această corelație este o corelație bună și validează sistemul pentru utilizare clinică.

7.3 Generarea regulilor de inferență fuzzy

Acest studiu de caz a fost realizat pentru generarea regulilor de inferență fuzzy folosite în subcapitolele 7.1, 7.2, pentru identificarea obiectelor de pe imagini medicale de tip RMN și respectiv pentru identificarea osteosclerozei în imaginile de tip radiografii digitale. O primă variantă a regulilor utilizate a fost realizată prin discuții cu medicii de specialitate.

Obiectivul acestui experiment este analizarea metodei de optimizare propusă în capitolul 5, folosind algoritmi genetici pentru reducerea timpului necesar în formularea regulilor. Genele cromozomilor codifică în formă lingvistică variabilele lingvistice și seturile fuzzy aferente. Gena variabilei lingvistice cu gena setului fuzzy aferent formează o pereche. În populația inițială de reguli toate seturile fuzzy trebuie să fie prezente. Populația inițială necesită doar un număr minim de reguli care conțin toate seturile fuzzy existente în baza de date a sistemului de inferență fuzzy. Dacă testul este unul reușit atunci timpul necesar formulării regulilor se va reduce de la câteva ore la câteva secunde și acoperirea regulilor va deveni maximală.

Regulile de inferență fuzzy au o structură de tip IF THEN. Regulile care sunt supuse optimizării sunt de tip MISO (Multiple Input Single Output) cu mai multe intrări și cu o singură ieșire. Intrările și ieșirile sunt compuse din variabilele lingvistice și seturile fuzzy care definesc variabilele lingvistice. Astfel structura regulilor fuzzy folosite este:

- În subcapitolul 7.1 pentru identificarea tipurilor de țesuturi s-au folosit reguli de inferență care sunt construite din următoarele variabile lingvistice de intrare: histogramă, mărime, locație (în imagine) și de ieșire: diagnosticul sau tipul țesutului investigat.
- În subcapitolul 7.2 pentru identificarea prezenței osteosclerozei s-au folosit ca și variabile de intrare: sensibilitatea senzorului de scanare, doza de iradiere folosită și histograma zonei de investigat. Ca și variabilă de ieșire s-a folosit o singură variabilă care codifică rezultatele: un diagnostic sau o recomandare adițională.
- Structura regulilor este una silogistică, prima dată se verifică dacă imaginea a fost corect expusă, mai apoi se verifică histograma zonei investigate. Osteoscleroza afectează consistența oaselor care formează articulațiile astfel imaginea devine mai albă afectând histograma zonei.

Lungimea unui cromozom se poate calcula folosind formula (5.6). Astfel pentru regulile din subcapitolul 7.1 vom avea un cromozom de lungimea $2 * (4+1)$

= 10 gene; iar pentru regulile din subcapitolul 7.2 vom avea un cromozom de lungimea $2 * (4+1) = 10$ gene.

Codificarea regulilor s-a realizat după metoda propusă în subcapitolul 5.2:




Figura 7.12 Metoda de codificare.

Punctul de crossover este ales cvasi aleatoriu, indexul punctului de crossover trebuie să fie un punct divizibil cu 2. Acest punct este divizibil cu 2 pentru a se evita crearea regulilor invalide. În cazul în care punctul de crossover nu este divizibil cu 2 se introduce o valoare de compensare -1 sau +1 aleasă arbitrar.

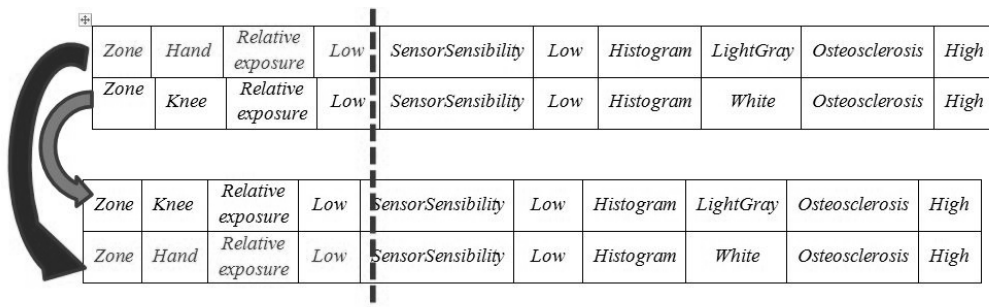


Figura 7.13 Metoda de crossover.

Generarea regulilor de inferență se realizează după schema prezentată în imaginea 5.4 (subcap 5.3). Această generare presupune parcurgerea următorului algoritm:

- Generarea regulilor de inferență de start utilizând toate variabilele lingvistice și toate funcțiile de membru existente. Se va genera un număr de 6 reguli de start, deoarece cea mai complexă variabilă lingvistică, histograma, are 6 seturi fuzzy. Aceste reguli se generează aleatoriu cu condiția să acopere toate seturile fuzzy existente. **Obligatoriu:** toate seturile fuzzy (gene posibile) trebuie să fie prezente în populația inițială de reguli. Exemplul următor prezintă în format XML regulile de pornire pentru generarea regulilor utilizabile la experimentul numărul 2:

```
<Rule1>IF Zone IS Hand AND RelativeExposure IS Low AND SensorSensibility IS Low AND Histogram IS White THEN Osteosclerosis IS Positive</Rule1>
```

<Rule2>IF Zone IS Hand AND RelativeExposure IS Medium AND SensorSensibility IS Medium AND Histogram IS Gray THEN Osteosclerosis IS Possible</Rule2>

<Rule3>IF Zone IS Hand AND RelativeExposure IS High AND SensorSensibility IS High AND Histogram IS LightGray THEN Osteosclerosis IS Positive</Rule3>

<Rule4>IF Zone IS Knee AND RelativeExposure IS Low AND SensorSensibility IS Low AND Histogram IS DarkGray THEN Osteosclerosis IS Negative</Rule4>

<Rule5>IF Zone IS Knee AND RelativeExposure IS Medium AND SensorSensibility IS Medium AND Histogram IS Dark THEN Osteosclerosis IS Negative</Rule5>

<Rule6>IF Zone IS Knee AND RelativeExposure IS High AND SensorSensibility IS High AND Histogram IS Black THEN Osteosclerosis IS Undefined</Rule6>

- Fuzzificarea datelor numerice de antrenament pentru a se găsi echivalentul lor lingvistic. Datele de antrenament sunt compuse din valorile numerice ale segmentelor de imagini medicale analizate în testele anterioare și din metadatele asociate imaginilor aferente. Tabelul 7.6 prezintă date de antrenament pentru generarea regulilor de inferență în cadrul experimentul numărul doi. Acestea ne oferă posibilitatea de a elimina procesul de extragere a datelor numerice din segmentele de imagine, astfel procesul de generare devine mult mai rapid.

Tabelul 7.6 Exemple de date de învățare pentru algoritmi genetici extrase în cadrul experimentul numărul doi.

Nr Crt.	Regiunea anatomică	Expunerea relativă	Sensibilitatea Senzorului	Histograma	Rezultat
1	KNEE	2287	200	203	Positive
2	KNEE	2265	200	82	Negative
3	KNEE	2145	200	112	Possible
4	KNEE	2114	200	60	Undefined
5	KNEE	2345	200	90	Negative
6	KNEE	2435	200	220	Positive
7	HAND	1567	50	178	Positive
8	HAND	1790	50	58	Negative
9	HAND	2478	50	200	Undefine
10	HAND	2356	50	68	Possible
11	HAND	1695	50	42	Negative
12	HAND	2246	50	76	Positive
13	KNEE	2489	200	45	Undefined
14	KNEE	2567	200	190	Positive
15	KNEE	2698	200	60	Negative
16	KNEE	2798	200	103	Possible
17	KNEE	2476	200	180	Positive
18	KNEE	2678	200	70	Negative

- Testarea individuală a regulilor generate pe un set de date de antrenament. Pentru fiecare situație se vor folosi un număr de cinci testări cu mici diferențe între valori. Astfel pentru fiecare set fuzzy va exista o valoare de test atât pentru extremitățile setului fuzzy cât și pentru mijlocul setului. Aceste seturi de date de antrenament conțin datele numerice ale posibilelor segmente de imagine.
- În cazul în care se găsește o corespondență între minim 3 seturi de învățare și o regulă, atunci regula descoperită va fi copiată într-o bază de reguli separată.
- Eliminarea din setul de date de antrenament a datelor de test pentru care s-a găsit o corespondență.
- Acordarea unei valori de fitness regulii descoperite.
- Extinderea populației de cromozomi în cazul în care nu mai avem corespondențe. Metoda de crossover alege cromozomii folosind o metodă hibridă constituită din metoda elitistă și metoda ruletei. Prima metodă alege un cromozom puternic care deja conține o regulă identificată iar a doua metodă alege un cromozom aleatoriu diferit de primul cromozom pentru a oferi gene noi.
- Recombinarea se realizează la punctul 2k pentru a nu se genera cromozomi invalizi. În cazul în care punctul de crossover nu este divizibil cu 2 se introduce o valoare de compensare -1 sau +1 aleasă arbitrar.
- Dacă nu este satisfăcută condiția de oprire se trece la punctul 2 și se reia tot procesul până când toate seturile de învățare au fost eliminate.

Tabelul 7.7 Rezultatele finale pentru optimizare

Reguli Pentru	Nr reguli start GA	Nr reguli start M.D	Generații pentru GA	Generații pentru MD	Timp generare pentru G.A	Timp generare pentru M.D	Nr final
Identif țesut	6	40	100	1	1 minut	4 ore	40(40)
Osteoscleroză	6	24	100	1	1 minut	2 zile	22(24)

În cadrul tabelului 7.7 se însumează rezultatele experimentului pentru generarea regulilor de inferență. Experimentul a fost realizat folosind un software creată pentru acest scop (vezi subcapitolul 6.4) Fereastra principală a programului este prezentată în figura 7.14:

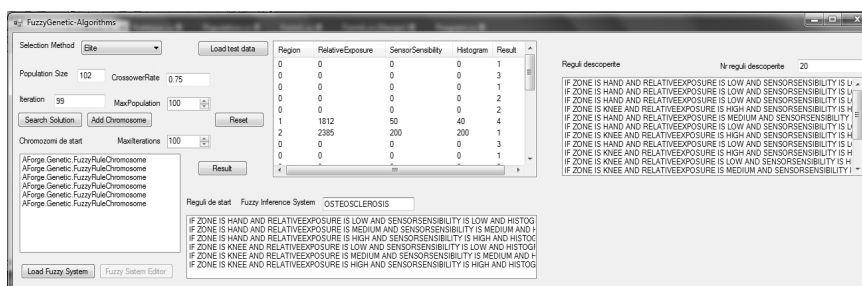


Figura 7.14 Aspect din timpul rularii aplicatiei pentru obtinerea regulilor fuzzy.




Figura 7.15 Numărul de reguli obținute prin algoritmi genetici la diferite valori ale populației și la un număr diferit de iterații.

Figura 7.15 prezintă rezultatele obținute cu programul din figura 7.8 folosind diferite mărimi pentru populația de cromozomi de la 25 de cromozomi la 200 de cromozomi. Algoritmii genetici au fost testați la 100, 200 și respectiv 300 de iterații. S-a observat că pentru o generare reușită este suficientă o populație de 100 - 125 și maxim 200 de iterații.

Verificarea regulilor generate s-a realizat folosind indicii de calitate din subcapitolul 5.3. Acești indici de calitate ne furnizează preponderența cu care apar obiectele în regulă și credibilitatea acestor reguli. În cazul în care aceste valori depășesc pragul impus, atunci regulile generate se acceptă ca și reguli utile pentru setul de învățare folosit.

Pragul minim se poate calcula folosind următoarea formulă matematică propusă pe baza [Agr94]:

$$c_m \% = 100/sr \quad (7.4)$$

unde c_m reprezintă confidența minimă pentru care se acceptă o regulă și sr reprezintă suportul impus pentru un rezultat oarecare.

Testele de acceptanță s-au realizat folosind metoda APRIORI. Pentru suportul unui rezultat s-a optat pentru verificarea preponderenței cu care apare rezultatul dorit împreună cu toate antecedentele sale posibile. S-a procedat identic și pentru verificarea confidenței, astfel s-a evitat acceptarea regulilor eronate.

Prima dată au fost verificate regulile deja existente, folosite în experimentele unu și doi. Rezultatele sunt prezentate în prima parte a tabelului 7.8 și se referă la un singur tip de achiziție în cazul identificărilor de țesut și la o singură zonă anatomică din experimentul pentru identificarea osteosclerozei.

Tabelul 7.8 Teste de acceptanță pentru setul de reguli

Reguli pentru	Suportul pentru reguli existente		Confidența pentru regulile existente		Suportul pentru regulile generate		Confidența pentru regulile generate	
Identificare țesut (un tip de achiziție)	Edem CSF	5	Edem CSF	20	Edem CSF	5	Edem CSF	20
	Ventricul	5	Ventricul	20	Ventricul	5	Ventricul	20
	Materie Cenușie	5	Materie Cenușie	20	Materie Cenușie	5	Materie Cenușie	20
	Oase	5	Oase	20	Oase	4	Oase	25
Osteoscleroză (regiune anatomică)	Pozitiv	4	Pozitiv	25	Pozitiv	6	Pozitiv	16,5
	Negativ	3	Negativ	33	Negativ	6	Negativ	16,5
	Probabil	2,5	Probabil	40	Probabil	6	Probabil	16,5
	Nedefinit	2,5	Nedefinit	40	Nedefinit	3	Nedefinit	32

Din tabelul de mai sus se poate observa că regulile generate folosind algoritmi genetici au un suport mai bun sau egal cu suportul regulilor obținute manual. Algoritmii genetici sunt influențați de mai mulți factori: de numărul cromozomilor din populație, de calitatea datelor de antrenament și de metoda de selecție a cromozomilor pentru următoarea generație. Experimentul realizat a subliniat că metoda propusă în capitolul 5 funcționează. Folosind un set de date de antrenament atent realizat și un număr corespunzător de iterații, obținem reguli de inferență mai bune decât cele realizate manual. Timpul de generare a regulilor este mai scăzut față de generarea manuală și necesită doar un număr minim de reguli generate aleatoriu.

7.4 Concluzii

În acest capitol au fost realizate trei experimente diferite pentru a valida și confirma utilizabilitatea ideilor prezentate în teză. Primul experiment a fost conceput pentru identificarea tipurilor de țesut existente în craniul uman și pentru identificarea unei edem cerebral cauzat de o tumoră malignă. Încercarea a fost realizată folosind imagini RMN de tipul T1 SE, T2 FSE și T2 FLAIR (cu substanță de contrast). Totodată toate cele 3 axe ale planului de achiziție au fost acoperite. Un avantaj în identificarea obiectelor din imagine a fost oferit de existența metadatelor. În acest caz metadatele au făcut parte din antecedentele regulilor de inferență, ele au fost utilizate pentru identificarea tipului de imagine și alegerea corectă a regulilor de inferență. Astfel s-a evitat utilizarea greșită a regulilor de inferență care au fost dezvoltate pentru a fi utilizate pe imaginile de tip T1 SE și pe imaginile de tip T2 FSE.

Testul 2 a fost conceput pentru verificarea capacității sistemului în condiții clinice utilizând radiografiile 2D de tip DICOM. În acest test s-a propus identificarea semnelor de osteoscleroză, aceasta este o boală degenerativă și reprezintă primul semn în cazul unor boli degenerative mult mai serioase. O problemă serioasă care a apărut în timpul testului a fost diferența de expunere de la o imagine la alta. La imaginile de tip RMN tot setul de achiziție este expus identic dar în cazul radiografiilor digitale am depistat diferențe de expunere. Astfel s-a propus verificarea expunerii de imagine folosind un sistem cu inferență fuzzy. Acest sistem are rolul de a determina dacă imaginea este sau nu sub/supra expusă. Rezultatul este folosit pentru compensarea expunerii în antecedentele regulilor care au rolul de a infera diagnosticul. S-a utilizat conceptul de sisteme cu inferență fuzzy silogistice. Pentru implementarea în sine s-a recurs la o logică cvasi silogistică, mai precis cele două sisteme de inferență au fost contopite într-unul singur.

În total au fost analizate 206 arii anatomice. Rezultatele furnizate de sistemul prezentat sunt foarte apropiate de rezultatele medicului specialist, în numai 1 din 10 zone anatomice a existat o disconcordanță între rezultatele furnizate de cele două evaluări prezentate în figura 7.11. Coeficientul de corelație între cele două rezultate are o valoare bună de 0.886. Sistemul poate fi folosit în practica curentă cu un grad de încredere de 88,6 %, deci este util și viabil.

Ultimul test a fost realizat pentru validarea metodei de optimizare și generare a regulilor de inferență fuzzy. Această metodă are scopul de a genera reguli de inferență fuzzy folosite pentru analiza lingvistică a imaginilor medicale. Generarea a fost realizată folosind algoritmi genetici. S-a ales strategia de a codifica o regulă de inferență în cromozom, realizând codificarea prin utilizarea denumirilor variabilelor lingvistice și a seturilor fuzzy. Un dezavantaj care apare este împerecherea genei variabilei lingvistice cu gena setului fuzzy Astfel punctul de recombinare se va alege la punctele de 2k.

Un avantaj al reprezentării propuse îl reprezintă starea de cvazidecodificare a cromozomului care conține regula de inferență pregătită pentru utilizare. Este necesară doar introducerea cuvintelor cheie (*If, operatori logici, is și then*) în regulă.

Deoarece regulile sunt în format If-Then se poate renunța la metoda de mutație, această metodă ar genera reguli redundante prin inversiunea perechilor de gene care alcătuiesc antecedentele.

O condiție necesară (subcap 5.3) pentru o generare corectă o reprezintă necesitatea unui lot minim de cromozomi de start, numărul minim este egal cu

numărul de seturi fuzzy existente în cea mai complexă variabilă lingvistică. Astfel se asigură utilizarea tuturor genelor posibile.

Pentru verificarea regulilor generate folosim un set de date de învățare care imită sub-imaginile segmentate. Regulile sunt încercate pe aceste seturi și în momentul în care un set este acoperit, regula se va salva într-o bază de reguli iar setul de învățare este eliminat.

Generarea de regulilor de inferență s-a realizat în câteva minute față de orele necesare pentru generarea și testarea manuală regulilor de inferență. Metoda asigură o acoperire totală a datelor de test în comparație cu generarea manuală unde au apărut situații în care lipseau reguli.

8. Concluzii

Imaginile medicale sunt utilizate pentru investigarea organelor, în scopul depistării anumitor boli congenitale sau dobândite. Cele mai frecvente imagini medicale non-invazive sunt radiografia, ecografia, tomograful computerizat și rezonanța magnetică nucleară.

Studiul bibliografic a relevat că din cele trei tipuri de procesare aferente imaginilor medicale (preprocesarea, segmentarea și postprocesarea), a treia categorie nu a fost încă suficient abordată. Teza propune abordarea domeniului de interpretare semantică (postprocesarea) a imaginilor medicale și reducerea lacunelor de cercetare din acest domeniu prin utilizarea metodelor de inferență fuzzy.

Teza cuprinde 8 capitole, al căror **conținut** este prezentat în continuare.

Capitolul 1 prezintă succint cele mai populare tipuri de imagini medicale folosite în mod curent în imagistica medicală. Este descris standardul DICOM, cel mai utilizat pentru imaginile medicale digitale. Standardul specifică modalitățile de scanare și de codificare a imaginilor medicale, precum și codificarea mai multor tipuri de metadate în structura fișierului care conține imaginea medicală.

Capitolul 2 prezintă o sinteză a metodelor de prelucrare a imaginilor medicale, inclusiv cele bazate pe tehnici fuzzy, dezvoltate până în prezent. Sunt descrise metodele de preprocesare a imaginilor medicale, folosite pentru eliminarea zgomotului. De asemenea sunt prezentate cele mai uzuale metode de segmentare a imaginilor medicale, cu rol de separare a obiectelor de fundal. În ultima parte sunt descrise metode fuzzy de interpretare a segmentelor de imagine folosind sisteme de inferență fuzzy. Aceste sisteme analizează datele extrase din pixelii segmentului de imagine pentru a identifica tipul de țesut de care aparțin.

Capitolul 3 prezintă o sinteză a diferitelor structuri de aplicații de inferență fuzzy, precum și reprezentările aferente. Sunt descrise și editoare pentru generarea structurilor de reprezentare a sistemelor cu inferență fuzzy. Sunt prezentate sisteme fuzzy simple și multiple. Sistemele multiple sunt sistemele silogistice (cascadate) și ierarhice. În acest capitol se propune o altă reprezentare a sistemelor cu inferență fuzzy folosind fișiere XML și o modalitate proprie de a încorpora noi algoritmi de inferență fuzzy în aplicații, fără să fie necesară refactorizarea acestora.

Capitolul 4 prezintă un sistem original de interpretare a imaginilor medicale. Acest sistem, spre deosebire de cele existente, descrise în capitolul 2, ia în considerare atât datele directe obținute din subimagini cât și metadatele. Rezultatele inferenței fuzzy sunt reprezentate de indicarea (recunoașterea) unor organe, obiecte de altă natură sau mai important prezența unor patologii.

Capitolul 5 prezintă o metodă de optimizare a regulilor de inferență fuzzy folosind algoritmi genetici. Este descrisă o adaptare originală a algoritmilor genetici și sunt propuse câteva metode de optimizare a regulilor de inferență fuzzy folosind acești algoritmi în diverse contexte. Pe baza soluțiilor prezentate este propusă o structură cromozomială care utilizează gene, care codifică șiruri de caractere (*strings*). Metoda propusă permite generarea noilor reguli iar regulile utile vor fi salvate într-o bază de date.

Capitolul 6 descrie implementarea software a metodelor prezentate în capitolele trei și patru. Acest sistem a fost dezvoltat pe baza unui pachet open source existent, prin modificări și adăugări de module originale.

Capitolul 7 cuprinde prezentarea detaliată a studiilor de caz din lumea reală, care au fost efectuate pentru validarea conceptelor prezentate în capitolele anterioare.

Capitolul 8 prezintă concluziile și contribuțiile pe care autorul le-a adus la îmbunătățirea tehnologiei de prelucrare a imaginilor medicale.

Succint, în viziunea mea, teza aduce următoarele contribuții majore în domeniul imagisticii medicale cu aplicații fuzzy pentru interpretarea semantică :

1. Realizarea unui algoritm fuzzy de interpretare a imaginilor medicale pe nivelul semantic.
2. Realizarea unui algoritm genetic pentru generarea regulilor fuzzy.

Contribuțiile aduse prin realizarea unui algoritm de interpretare a imaginilor medicale la nivelul semantic se pot detalia în felul următor:

- Am propus o modalitate originală de reprezentare a cunoștințelor din domeniul imagisticii medicale, folosind structuri specifice sistemelor de inferență fuzzy.
- Am realizat un cadru de lucru nou pentru analiza semantică a imaginilor medicale care sunt realizate conform standardului DICOM, prin modificări și adăugări de module noi la mediul de lucru AForge.
- Am realizat o reprezentare mai simplă a sistemelor cu inferență fuzzy folosind formatul XML.
- Am realizat un algoritm de conversie a reprezentării folosite în *MatLab* pentru sistemele cu inferență fuzzy, în format XML, pentru a permite astfel portarea sistemului fuzzy din *MatLab* în XML.
- Am realizat un editor de reprezentări de algoritmi fuzzy, pe baza codurilor sursă deschise din cadrul de lucru AForge, care salvează reprezentările algoritmilor direct în format XML.
- Am extins cadrul de lucru AForge cu noi clase și noi funcții de membru: Gaussian și triunghiular.
- Am conceput o metodă de implementare on-the-fly pentru a evita refactorizarea sistemului pentru modificarea regulilor de inferență.

Contribuțiile aduse prin realizarea unui nou tip de algoritm genetic pentru optimizarea și generarea regulilor fuzzy se pot detalia în următorul mod:

- Am propus un tip diferit de cromozom față de cromozomii numerici pentru codificarea regulilor de inferență fuzzy în gene, care codifică în gene denumirea variabilelor lingvistice și denumirea seturilor fuzzy active.
- Am utilizat codificarea prin șiruri de caractere a denumirilor în gene, atât pentru variabile lingvistice cât și pentru seturile fuzzy.
- Am propus o metoda de crossover specifică metodei propusă în capitolul 5 pentru a asigura generarea cromozomilor valizi.
- Am creat o metodologie specifică problemei pentru testarea regulilor de inferență generate cu algoritmi genetici.
- Am propus o funcție de fitness specifică situației.

- Am creat date de învățare folosind segmentele de imagini identificate corect la experimentul unu și respectiv experimentul numărul doi. Astfel se elimină procesele de prelucrare a imaginilor din procesul de testare.

Sistemul de interpretare a imaginilor medicale pe nivelul semantic, prezentat în *capitolul 4*, extinde sistemul de postprocesare [Han10] cu posibilitatea de a recunoaște nu numai țesuturile ci și diverse patologii sau corpi străini. Sistemul de postprocesare [Han10] se ghidează după reguli care verifică: histograma țesuturilor, anumite componente de histogramă și poziția din interiorul țesuturilor investigate. Aceste investigații sunt realizate folosind un set de 7 reguli fuzzy într-o buclă repetitivă. Această buclă asigură identificarea tuturor țesuturilor din imagine.

Sistemul de interpretare propus în această teză utilizează mai multe tipuri de informații pentru identificarea patologiilor. Aceste informații se obțin prin analiza numerică directă efectuată asupra zonelor de interes, utilizând și metadate din TAG-uri DICOM. Acestea permit identificarea tipului de achiziție de imagine și a zonelor anatomice investigate pentru a evita erorile de orice tip. Sunt utilizate reguli de inferență fuzzy pentru inferarea unui rezultat din informațiile existente. În comparație cu alte sisteme care utilizează reguli cu inferență fuzzy acesta permite schimbarea regulilor fuzzy fără oprirea și decompilarea programului, metodă denumită "on-the-fly". Metoda "on-the-fly" este posibilă prin utilizarea fișierelor de tip XML în care au fost codificate sistemele cu inferență fuzzy. Prin schimbarea fișierului XML se poate schimba întregul sistem de inferență nu numai regulile de inferență fuzzy.

Validarea contribuțiilor a fost realizată folosind 3 studii de caz. Acestea s-au referit la seturi de imagini RMN și radiografii digitale. S-au efectuat două încercări pe 4 tipuri de imagini medicale: trei tipuri de imagini RMN și radiografii digitale. În imaginile RMN s-a propus identificarea tipurilor de țesuturi și a unui edem cerebral iar în radiografiile digitale s-a propus identificarea osteosclerozei. În al treilea test s-a realizat testarea metodei de îmbunătățire a regulilor fuzzy folosind algoritmi genetici.

Experimentul unu confirmă utilizabilitatea sistemului pe mai multe tipuri de imagini medicale de tip RMN. Imaginile medicale au fost supuse analizei pentru identificarea țesuturilor și a posibilelor patologii. În cadrul testării s-au folosit mai multe tipuri de imagini RMN.

Experimentul numărul doi a fost realizat pentru a confirma utilitatea metodei folosind radiografii digitale ale unor pacienți care suferă de o boală degenerativă artrozică sau reumatismală. Patologia de interes a fost osteoscleroza, o patologie care este primul semn care indică apariția unei boli degenerative. Rezultatele au furnizat un grad de încredere de 88,6%.

Experimentul 3 a fost realizat în vederea generării regulilor de inferență fuzzy folosite în testele 1 și 2. Generarea a fost realizată folosind un algoritm genetic propriu dezvoltat în acest scop. Experimentul realizat a subliniat că metoda propusă în *capitolul 5* funcționează conform așteptărilor.

O direcție de dezvoltare ulterioară este implementarea metodelor de segmentare mai avansate și continuarea studiului de la *capitolul 4* în vederea definirii de noi sisteme cu inferență fuzzy pentru multiple patologii.

Acest studiu are în vedere obținerea unui diagnostic precoce atât în contextul patologiilor benigne cât și a celor maligne. Un diagnostic rapid și corect determină ulterior o mai bună complianță la tratament și o calitate a vieții mai crescută.

Rezultatul final al studiului este o unealtă de investigare, un program care oferă posibilitatea de a analiza mai multe tipuri de imagini medicale și permite detectarea automată a mai multor patologii prin utilizarea a mai multor sisteme de inferență în paralel. De asemenea sistemul permite și modificarea sistemului de inferență. Astfel s-ar putea crea o platformă de investigare care să deschidă noi frontiere în analiza imaginilor pe nivel cognitiv, punând la dispoziția medicilor radiologi un suport de asistență în diagnoză care să le ușureze și îmbunătățească activitatea.

9. Bibliografia

- [Agr94] R. Agrawal, R. Srikant: Fast Algorithms for Mining Association Rules, Proc. of 20th Int'l conf. on VLDB, Septembrie 1994, pp. 487-499
- [Ala07] S. Alayón, R. Robertson, S. K. Warfield, J. R.-Alzola: A fuzzy system for helping medical diagnosis of malformations of cortical development, Journal of Biomedical Informatics, Iunie 2007, pp. 221-235
- [Amo06] S. P. Amol, A. Kakadiaris, Image Segmentation Based on Fuzzy Connectedness Using Dynamic Weights, Ieee Transactions On Image Processing, Iunie 2006, pp. 1555-1562
- [Ana10] D. Anastasia, Y. Andreopoulos: Linear Image Processing Operations With Operational Tight Packing, IEEE Signal Processing Letters, Aprilie 2010 pp. 375-378
- [Bal11] A. Balti, M. Sayadi, F. Fnaiech: Segmentation and enhancement of fingerprint images using K-means, fuzzy C-mean algorithm and statistical features,"Communications, Computing and Control Applications (CCCA), 2011 International Conference on Martie 2011, pp.1-5
- [Bes06] D. Bepalova, W. C. Reglia, A. Shokoufandeha: Local feature extraction and matching partial objects, Computer-Aided Design vol.38, Ianuarie 2006, pp. 1020-1037
- [Ben06] N. Benamrane, A. Aribi, , L. Kraoula: Fuzzy Neural Networks and Genetic Algorithms for Medical Images Interpretation, Geometric Modeling and Imaging--New Trends, 2006, pp. 259 - 264
- [Biz11] N. Bizon, M. Stork: 2D Image pre-processing — Part II: Fuzzy 3D filtering, Applied Electronics (AE), 2011 International Conference on , Septembrie 2011, pp.1-4
- [Bos12] R.S.C. Boss, K. Thangavel, D.A.P Daniel: Mammogram image segmentation using fuzzy clustering, Pattern Recognition, Informatics and Medical Engineering (PRIME), 2012 International Conference on , Martie 2012 pp.290-295
- [Chb03] R. Chbeir, and F. Favetta: A Global Description of Medical Imaging With High Precision, Ieee Transactions On Systems, Man, And Cybernetics—Part B: Cybernetics, Vol. 33, No. 5, Octombrie 2003, pp. 752-757
- [Chi12] Chih-Yu Hsua, Hao-Feng Wangb, Hui-Ching Wangb, Kuo-Kun Tseng: Automatic extraction of face contours in images and videos, Future Generation Computer Systems 28, Octombrie 2012, pp. 322-335
- [Cho08] S.R. Chowdhury, H. Saha: A High-Performance FPGA-Based Fuzzy Processor Architecture for Medical Diagnosis, Micro, IEEE, Sept.-Oct. 2008
- [Cho11] R. Choonwoo, S. G. Kong, H. Kim: Enhancement of feature extraction for low-quality fingerprint images using stochastic resonance, Pattern Recognition Letters 32, Decembrie 2011, pp. 107-113
- [Cho11] S.K. Choy, M.L. Tang, C.S Tong: Image Segmentation Using Fuzzy Region Competition and Spatial/Frequency Information, Image Processing, IEEE Transactions on , Iunie 2011 pp.1473-1484
- [Cho12] H.-H. Chou, L.-Y. Hsu, H.-T. Hu,: Turbulent-PSO-Based Fuzzy Image Filter With No-Reference Measures for High-Density Impulse Noise, Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on , Iulie 2012 , pp.1-12
- [Cle90] M.R. Cleland, C.C. Thompson, M. Strelczyk, D.P. Sloan: Advances in X-ray processing technology, International Journal of Radiation Applications and

Instrumentation. Part C. Radiation Physics and Chemistry, Volume 35, Issues 4–6, 1990, pp. 632-637

[Cos05] H. Costin, Cr. Rotariu: Fuzzy Logic and Knowledge-Based Biomedical Image Segmentation, Proc. of HCMC-2005, The First East European Conference on Health Care Modelling and Computation, Craiova, România, Septembrie 2005, pp.87-98

[Cos06] H. Costin, Cr. Rotariu: Medical image analysis and representation using a fuzzy and rule-based hybrid approach, Int. Journal of Computers, Communications & Control, vol. I, no. 5, 2006, pp. 156-162

[Cor04] C Corsi, E.G Caiani, R.M Lang, A Sarti, R Battani, C Lamberti: A post-processing tool for visualization and quantification of 4D medical images, International Congress Series, Volum 1268, Iunie 2004, pp. 63-68

[Dar59] C Darwin: "On the Origin of Species ", 1859, John Murray.

[Der11] L. Der-Chiang, L. Chiao-Wen, C. H. Susan: A fuzzy-based data transformation for feature extraction to increase classification performance with small medical data sets, Artificial Intelligence in Medicine 52, Iunie 2011, pp 45–52

[Dem09] O. Demirkaya, M. H. Asyali, P. K. Sahoo: " Image Processing with *MatLab*: Applications in Medicine and Biology ", 2009 Taylor & Francis Group,

[Ede11] M. Eder, F. v. Waldenfels, M. Sichtermann, T. Schuster, N. A. Papadopoulos, H-G. Machens, E. Biemer, L. Kovacs Three-dimensional evaluation of breast contour and volume changes following subpectoral augmentation mammoplasty over 6 months, Journal of Plastic, Reconstructive & Aesthetic Surgery 64, Mai 2011 pp. 1152-1160

[Esc 09] S. Escalera, A. Fornés, O. Pujol, P. Radeva, G. Sánchez and J. Lladós, "Blurred Shape Model for binary and grey-level symbol recognition," Pattern Recognition Letters 30, August 2009, pp. 1424–1433

[Fan11] S-Y Fang, J-J. Fang: „Automatic head and facial features extraction based on geometry variations". Computer-Aided Design (2011),

[Flo11] J.B. Florindo, O.M. Bruno: Closed contour fractal dimension estimation by the Fourier transform, Chaos, Solitons & Fractals 10, Octombrie 2011, pp 851, 856

[Gal10] N. Gal, V. Stoicu-Tivadar: Computer Assisted Medical Image Interpretation Using Fuzzy Logic; 4th International Workshop on Soft Computing Applications, July 2010

[Gal11] N. Gal and V. Stoicu-Tivadar, "FIS Editor for On-The-Fly Implementation in Software Environment", 9th IEEE International Symposium On Intelligent Systems And Informatics, SISY2011, , Septembrie, 2011, pp. 141-143 (în curs de indexare ISI; Scopus) (Indexată ISI Proc. în 2009)

[Gal11] N. Gal and V. Stoicu-Tivadar, "XML as a Cross-Platform Representation for Medical Imaging with Fuzzy Algorithms", EFMI Special Topic Conference, EFMI STC, Aprilie 2011, pp. 83-86 (PubMed & Scopus)

[Gal12] N. Gal and V. Stoicu-Tivadar, " Using genetic algorithms to generate inference rules for semantic analysis of medical images", 32th National Conference of Medical Informatics - RoMedInf2012 – Noiembrie 2012

[Gal12] N. Gal and V. Stoicu-Tivadar, "Knowledge Representation for Fuzzy Inference Aided Medical Image Interpretation ", 24th European Medical Informatics Conference - MIE2012 - in Pisa, August 2012, pp. 98-102 (PubMed)

[Har99] E. R. Harold, XML Bible, IDG Books Worldwide Inc., Foster City 1999

[Hal 87] M. H. Halstead. Elements of Software Science. Elsevier, Amsterdam, 1987

- [Hir05] Nualsawat Hiransakolwong: Automated Liver Detection in Ultrasound Images, W.-K. Leow et al. (Eds.): CIVR 2005, LNCS 3568, pp. 619-628
- [Hui09] Z. Huiyu, G. Schaefer: An Overview of Fuzzy C-Means Based Image Clustering Algorithms, Foundations of Computational Intelligence Volume 2, Springer Berlin Heidelberg, Ianuarie 2009, pp. 295-310
- [Hom08] N. Homma, K. Saito, T. Ishibashi, M.M. Gupta, H. Zeng-Guang, A. Solo: Shape features extraction from pulmonary nodules in X-ray CT images; Neural Networks, 2008. IJCNN 2008. (IEEE World Congress on Computational Intelligence). IEEE International Joint Conference on; June 2008, pp 3396 - 3400
- [Inn04] P. R. Innocent, R. I. John: Computer aided fuzzy medical diagnosis; Information Sciences Volume 162, Mai 2004, pp 81-104
- [Jea09] V. Jeanne, D. Unay, V. Jacquet: Automatic detection of body parts in x-ray images; Computer Vision and Pattern Recognition Workshops, 2009. CVPR Workshops 2009. IEEE Computer Society Conference on ; Iunie 2009, pp 25-30
- [Jin11] H. Jinyoung, K. Junmo, H.Yeji, H.W. Park: An automatic cerebellum extraction method in T1-weighted brain MR images using an active contour model with a shape prior, Magnetic Resonance Imaging 29, Septembrie 2011, pp. 1014-1022
- [Jun11] X. Jun, A. Janowczyk, S. Chandran, A. Madabhushi: A high-throughput active contour scheme for segmentation of histopathological imagery Medical Image Analysis 15, Decembrie 2011, pp 851- 856
- [Kar11] S.Z. Karakozoglou , N. Henrich, C. d’Alessandro,Y. Stylianou: Automatic glottal segmentation using local-based active 3 contours and Application to glottovibrography, Speech Communication, 2011 (în curs de publicare)
- [Kan10] S.R. Kannan, R. Pandiyarajan, S, Ramathilagam: Effective weighted bias fuzzy c-means in segmentation of brain MRI, 2010 International Conference on Intelligent and Advanced Systems, ICIAS 2010, Iunie 2010, art. no. 5716256
- [Kan12] S.R. Kannan, S. Ramathilagam, R. Devi, E. Hines: Strong fuzzy c-means in medical image data analysis, Journal of Systems and Software 85, Noiembrie 2012, pp. 2425-2438
- [Kor00] F. L. C. Korris, J. C. Duan: On multistage fuzzy neural network modeling, IEEE Trans. on Fuzzy Systems, 8, Aprilie 2000 , pp. 125-142
- [Lar06] D. Larose: "Data Mining Methods and Models", Wiley-IEEE Press, 2006, pp: 240 -264
- [Lei09] M. Lei, D. Song, Y. Yao, R. Sankar, E. Sheybani, W. Qian: "Chapter 4 - Medical Image Enhancement Using Fourier Descriptors and Hybrid Filters" In: Isaac N. Bankman, PhD, Editor(s), Handbook of Medical Image Processing and Analysis (Second Edition), Academic Press, Burlington, 2009, Pages 59-69
- [Lei10] Z. Lei, X. Mei, M. Jian, S. Hongxun: "A hybrid filter based on an adaptive neuro-fuzzy inference system for efficient removal of impulse noise from corrupted digital images," Environmental Science and Information Application Technology (ESIAT), 2010 International Conference on., Iulie 2010, pp.70-73
- [Lei12] Leila, A.; Abdelouahab, M.: "A fuzzy evolutionary algorithm for medical image segmentation," Information Technology and e-Services (ICITeS), 2012 International Conference on, Martie 2012,pp.1-3
- [Lia05] R.-J. Lian, B.-F Lin: Design of a mixed fuzzy controller for multiple-input multiple-output systems, Mechatronics 15 , Decembrie 2005, pp. 1225-1252
- [Lin07] T.-C. Lin: A new adaptive center weighted median filter for suppressing impulsive noise in images, Information Sciences, Februarie 2007, pp 1073-1087

- [Lin10] Y. Lin, B. Fang, Y. Tang: "Image Restoration Using Fuzzy Impulse Noise Detection and Adaptive Median Filter," Pattern Recognition (CCPR), 2010 Chinese Conference on , v, Octombrie. 2010, pp.1-4
- [Lop11] E. López-Rubio, M. N. Florentín-Núñez: Kernel regression based feature extraction for 3D MR image denoising, Medical Image Analysis ,15 August 2011, pp. 498-513
- [Ma07] Z.M. Ma, Li Yan, Fuzzy XML data modeling with the UML and relational data models, Data & Knowledge Engineering 63,Decembrie 2007, pp. 972-996
- [Mar94] S. Marsh, Y. Wei Huang, J Sibigtroth: Center for Emerging Computer Technologies, Motorola, Inc.: "Fuzzy Logic Program 2.0". 1994
- [Mat 02] The MathWorks, Inc. User's Guide Version 2: Fuzzy Logic Toolbox User's Guide For Use with *MATLAB*®, July 2002 Online only Revised for Version 2.1.2 (Release 13)
- [Moh11] S. Mohapatra, S.S. Samanta, D. Patra, S. Satpathi: "Fuzzy Based Blood Image Segmentation for Automated Leukemia Detection," Devices and Communications (ICDeCom), 2011 International Conference on , Februarie 2011, pp.1-5
- [Mue08] A. Mueen, R. Zainuddin and M. Sapiyan Baba: Automatic Multilevel Medical Image Annotation and Retrieval; Journal of Digital Imaging, Septembrie 2008
- [Myl12] S. K. Mylonas, D. G. Stavrakoudis, J. B. Theocharis: "A GA-based sequential fuzzy segmentation approach for classification of remote sensing images," Fuzzy Systems (FUZZ-IEEE), 2012 IEEE International Conference on , Iunie 2012, pp.1-8
- [Nak09] M. Nakagawa, T. Kondo, T. K. S. Takao, J. Ueno: Three-dimensional medical image recognition of cancer of the liver by a revised radial basis function (RBF) neural network algorithm, Artif Life Robotics 14, Noiembrie 2009, pp. 118-122
- [Nno08] U Nnolim, P. Lee: "Homomorphic Filtering of colour images using a Spatial Filter Kernel in the HSI colour space," Instrumentation and Measurement Technology Conference Proceedings, 2008. IMTC 2008. IEEE , Mai 2008, pp.1738-1743
- [Pal12] T. Palabas, A. Gangal: "Adaptive fuzzy filter combined with median filter for reducing intensive salt and pepper noise in gray level images," Innovations in Intelligent Systems and Applications (INISTA), 2012 International Symposium on , Iulie 2012, pp.1-4
- [Pal12] T. Palabas, A. Gangal: "Salt and pepper noise reduction in images using adaptive fuzzy filter," Signal Processing and Communications Applications Conference (SIU), 2012 20th , Aprilie 2012, pp.1-4
- [Per10] A. Perina, M. Cristani, V. Murino: Learning natural scene categories by selective multi-scale feature extraction, Image and Vision Computing 28 , Iubie 2010, pp. 927-939
- [Pia08] O. S. Pianykh: Digital Imaging and Communications in Medicine (DICOM); 2008 Springer-Verlag Berlin Heidelberg, ISBN 978-3-540-74570-9
- [Pim10] A.H.M. Pimenta, H.A. Camargo: "Interval type-2 fuzzy classifier design using Genetic Algorithms," Fuzzy Systems (FUZZ), 2010 IEEE International Conference on , Iulie 2010, pp.1-7
- [Ort12] S. H. C. Ortiz, T. Chiu, M. D. Fox: „Ultrasound image enhancement: A review“, Biomedical Signal Processing and Control, Volume 7, Septembrie 2012, pp. 419-428

- [Ram11] S. Ramathilagam, R. Pandiyarajan, A. Sathya, R. Devi, S.R. Kannan: Modified fuzzy -means algorithm for segmentation of T1-T2-weighted brain MRI, *Journal of Computational and Applied Mathematics* 235, Ianuarie 2011, pp. 1578-1586
- [Rod09] R.D. Rodrigues, A.J.O. Cruz, R.T. Cavalcante, Aliança: A proposal for a fuzzy database architecture incorporating XML, *Fuzzy Sets and Systems* 160 , Ianuarie 2009, pp. 269-279
- [Rog00] Jadwiga Rogowska, 5 - Overview and Fundamentals of Medical Image Segmentation, In: Isaac N. Bankman, Editor(s), *Handbook of Medical Imaging*, Academic Press, San Diego, 2000, pp 69-85
- [Sai12] T. Saikumar, M. Nagarani, K. Yojana, , B. Shashidhar: "Image segmentation of an adaptive threshold algorithm using watershed transform and fuzzy c-means clustering on level set method," *Advances in Engineering, Science and Management (ICAESM)*, 2012 International Conference on , Martie 2012 pp.33-38
- [Sel12] J. Selvakumar, A. Lakshmi, T. Arivoli, "Brain tumor segmentation and its area calculation in brain MR images using K-mean clustering and Fuzzy C-mean algorithm," *Advances in Engineering, Science and Management (ICAESM)*, 2012 International Conference on , Martie 2012, pp.186-190
- [Sha09] L. Shamir, S.M. Ling, W.W. Scott,A. Bos, N. Orlov, T.J. Macura, D.M. Eckley, L. Ferrucci, I.G. Goldberg: Knee X-Ray Image Analysis Method for Automated Detection of Osteoarthritis; *Biomedical Engineering, IEEE Transactions on*; Februarie . 2009 , pp. 407-415
- [Shi09] S. Shimoyama, N. Homma, M. Sakai, T. Ishibashi, M. Yoshizawa: Auto-detection of non-isolated pulmonary nodules connected to the chest walls in X-ray CT images; *ICCAS-SICE*, 2009; August. 2009, pp 3672 - 3675
- [Shu11] X. Shu, X.-J. Wu: A novel contour descriptor for 2D shape matching and its application to image retrieval, *Image and Vision Computing* 29, Martie 2011, pp. 286-294
- [Spi00] T. S. Spisz, I. N. Bankman: 53 - Medical Image Processing and Analysis Software, In: Isaac N. Bankman, Editor(s), *Handbook of Medical Imaging*, Academic
- [Sri11] V. Srikrishnan, S. Chaudhuri: Adaptive smoothness based robust active contours, *Image and Vision Computing* 29, Aprilie 2011, pp. 317-328
- [Sta07] L. Stanescu, D. Burdescu, A. Ion, E. Georgescu: Using the color ste back-projection algorithm in retrieval and evaluation of endoscopic images. *International Symposium on Intelligent and Distributed Computing IDC'2007*, October 2007
- [Tha12] B. Thamarachelvi, G. Yamuna, U. Vanitha: "An improved method of image segmentation using fuzzy c-means," *Advances in Engineering, Science and Management (ICAESM)*, 2012 International Conference on , Martie 2012, pp.669-672
- [Vel07] J. D. Vela´ squez, V. Palade: A Knowledge Base for the maintenance of knowledge extracted from web data, *Knowledge-Based Systems* 20, Aprilie 2007,pp. 238-248
- [Wan98] L. X. Wang: Universal approximation by hierarchical fuzzy systems, *Fuzzy Sets and Systems*, 93, Ianuarie 1998,pp. 223-230
- [Ube10] E. D. Übeyli: Noise cancellation in Doppler ultrasound signals with adaptive neuro-fuzzy inference system, *Digital Signal Processing* 20, Ianuarei 2010, pp. 63-76

- [Wan04] S. Wan, K. F. L. Chung: Cascaded Fuzzy System And Its Robust Analysis Based On Syllogistic Fuzzy Reasoning, Journal Of Electronics(China) Martie. 2004, pp. 116-126
- [Wan07] N. Wang, G. Wang: Shape Descriptor with Morphology Method for Color-based Tracking. International Journal of Automation and Computing 04(1), Ianuarie 2007, pp. 101-108
- [Wee96] A. R. Weeks Jr: Fundamentals of Electronic Image Processing, Publisher: Wiley-IEEE Press; 1 edition, January 1996
- [www1] <http://www.dicomtags.com/> (9/17/2011)
- [www2] <http://www.codeproject.com/Articles/36014/DICOM-Image-Viewer> (10/06/2010)
- [www3] <http://www.aforgenet.com/> (06/06/2011)
- [Xue09] J. Xuejing, Qi Dawei, W. Haijun, L. Fuxiang: Detection of Small Lesions in Medical X-Ray Image Based on Multi-Scale Fractal Feature; Biomedical Engineering and Informatics, 2009. BMEI '09. 2nd International Conference on; Octombrie. 2009, pp. 1-4
- [Xiu11] Y. Xiufen, L. Wang, T. Wang: "Sonar image segmentation on Fuzzy C-Mean using local texture feature," Complex Medical Engineering (CME), 2011 IEEE/ICME International Conference on , Mai 2011, pp.115-120
- [Yug12] P. Yugander, B.J. Sheshagiri, K. Sunanda, E. Susmitha: "Multiple kernel fuzzy C-means algorithm with ALS method for satellite and medical image segmentation," Devices, Circuits and Systems (ICDCS), 2012 International Conference on , Martie 2012, pp.244-248
- [Yuk12] M.E. Yuksel, A. Basturk: "Application of Type-2 Fuzzy Logic Filtering to Reduce Noise in Color Images," Computational Intelligence Magazine, IEEE , August. 2012, pp.25-35
- [Zad 65] L.A. Zadeh, "Fuzzy sets," Information and Control, vol. 8, pp.338-353, 1965
- [Zah97] S. Zahan, C. Michael, S. Nikolakeas: A fuzzy hierarchical approach to medical diagnosis; Fuzzy Systems, 1997., Proceedings of the Sixth IEEE International Conference on; Iulie 1997
- [Zha10] J. Zhang: "An efficient median filter based method for removing random-valued impulse noise", Digital Signal Processing, Iulie 2010, pp. 1010-1018
- [Zhe09] W. Zheng, M. Na, S. Huisheng, F. Hongqi: Feature Extraction of X-ray Fracture Image and Fracture Classification; Artificial Intelligence and Computational Intelligence, 2009. AICI09. International Conference on; Noiembrie. 2009
- [Zhe12] C. Zheng, Q. Qin, G. Liu, Y. Hu: "Image segmentation based on multiresolution Markov random field with fuzzy constraint in wavelet domain," Image Processing, IET, April 2012, pp.213-221
- [Zen08] Y. Zeng, C. Tu, X. Zhang: Fuzzy-Set Based Fast Edge Detection of Medical Image; Fuzzy Systems and Knowledge Discovery, 2008. FSKD '08. Fifth International Conference on; Octombrie . 2008, pp. 42 - 46
- [Zex12] J. Zexuan, X. Yong, S. Quansen, C. Qiang, X. Deshen, D.D. Feng: "Fuzzy Local Gaussian Mixture Model for Brain MR Image Segmentation," Information Technology in Biomedicine, IEEE Transactions on , Mai 2012, pp.339-347