



UNIVERSITATEA DIN CRAIOVA



Facultatea de Automatică, Calculatoare și Electronică
Școala Doctorală de Calculatoare și tehnologia informației

TEZĂ DOCTORAT

Tehnici de extragere a caracteristicilor pentru diagnosticare si
regasirea imaginilor medicale

*Teză prezentată în vederea îndeplinirii cerințelor
pentru gradul de doctor în cadrul
Facultatea de Automatică, Calculatoare și Electronică,
Universitatea Din Craiova, România*

Autor:
FAIQ SABBAR BAJI

Supervizor:
Prof. Dr. Ing.
MIHAI LUCIAN MOCANU

Craiova, 2018

Rezumat

Odată cu creșterea popularității rețelei și extinderea tehnologiei multimedia, tehnicile tradiționale de extragere a informației nu mai satisfac cerințele utilizatorilor. Recent, extragerea și diagnosticarea imaginilor medicale bazate pe conținutul imaginii (culoarea, textura și forma) au devenit un subiectul important susținut de o mare dezvoltare. În această teză sunt propuse metode noi pentru extragerea și diagnosticarea imaginilor medicale. Prima metodă propusă este rezolvarea problemei regiunilor de interes (ROI – în engleză, Region of Interest) bazate pe extragerea imaginilor. Tehnica regiunilor de interes care se bazează pe segmentarea imaginii în partiții fixe, este costisitoare din punct de vedere computațional. Metoda propusă se bazează pe componentele conectate și pe obiectul de interes pentru generarea vectorilor de histogramă și texturi statistice. Acești vectori au rezultat în extragerea imaginilor dintr-o bază de date mare de imagini. Caracteristicile de culoare și textură ale componentelor conectate sunt calculate prin cuantificarea spațiului de culoare din histogramele HSV (nuanță, saturație, valoare) și din matricea de coocurență a nivelurilor de gri (GLCM). Procesul de potrivire a vectorilor se bazează pe intersecția histogramei. Se observă că datele experimentale arată clar eficiența metodei propuse în comparație cu tehnica tradițională a regiunilor de interes în ceea ce privește efortul computațional.

O varietate de tehnici au fost dezvoltate pentru extragerea imaginii și diagnosticarea imaginii medicale prin utilizarea conținutului de caracteristici de textură. Caracteristicile texturilor s-au dovedit a fi un instrument robust pentru analiza caracteristicilor locale ale unei texturi și sunt larg adoptate în extragerea și diagnosticarea imaginilor medicale. În cadrul acestei cercetări, încercăm să creștem eficiența metodei LBP sugerând o nouă variantă a caracteristicii LBP, așa-numitele modele locale ternare (LTP – în engleză Local Ternary Patterns) pentru detectarea planului mediu de sagital (MSP – în engleză Mid Sagittal Plane) în secțiunile de creier, precum și o nouă adăugire pentru CBIR numită model local ternar uniform extins (UELTP – în engleză Uniform Extended Local Ternary Pattern).

Reprezentarea formei este o problemă esențială în recunoașterea formei și vizualizarea pe calculator. Reprezentarea formei a fost utilizată în multe aplicații ale CBIR. Această cercetare se referă la problemele imaginilor obținute frecvent dintr-o bază de date imensă dedicată

imaginilor, extragerea bazată pe aplicarea conturului unui obiect. Codul histogramic al lanțului (CCH – în engleză Chain Code Histogram) se aplică pentru a crea un vector de trăsături care este utilizat pentru a caracteriza o anumită formă.

Detectarea și analiza tumorilor cerebrale sunt probleme importante pentru prelucrarea imaginilor medicale datorită complexității imaginilor. Deoarece creșterea tumorilor cauzează asimetrie în părțile afectate ale creierului, metoda propusă calculează asimetria bazată pe diferența de intensitate dintre cele două părți ale planului mediu sagital. Una dintre problemele acestei metode apare atunci când obiectul creierului este rotit sau înclinat. Se propune o nouă metodă pentru a rezolva această problemă, prin determinarea planului mediu sagital în secțiunea de imagini de tip T1, bazate pe intensitatea scăzută a regiunii fisurii interemisferice (IF – în engleză Inter-Hemispheric Fissure). În cadrul acestei cercetări, se realizează algoritmul de grupare K-means pentru segmentarea imaginii RMN a creierului și etichetarea componentei conectate pentru a determina localizarea și dimensiunea tumorii. Rezultatul experimental arată în mod clar eficiența metodei propuse în comparație cu sistemele tradiționale în ceea ce privește efortul de calcul și timpul consumat.

Cuprins

Capitolul 1: Introducere.....	1
1.1 Introducere.....	1
1.2 Scopuri și obiective	2
1.3 Structura tezei.....	3
Capitolul 2: Principiile CBIR și ale diagnosticării imaginilor	4
2.1 Tehnici de extragere a caracteristicilor.....	4
2.1.1 Caracteristicile de culoare	4
2.1.2 Caracteristicile de textură.....	4
2.1.2.1 Modelul local binar (LBP)	5
2.1.2.2 Model local ternar (Local Ternary Pattern).....	6
2.1.3 Caracteristicile de formă.....	6
2.1.3.1 Codul lanț (Chain Code)	6
2.1.3.2 Indicele de compactitate.....	7
2.1.3.3 Neregularitatea dispersiei (IR)	7
Capitolul 3: Principii de proiectare a sistemelor medicale pentru diagnosticul bazat pe imagini	8
3.1 Metode și instrumente	8
3.1.1 Preprocesare.....	8
3.1.2 Segmentarea imaginii	9
3.1.2.1 Componente conectate	9
3.1.2.2 Algoritmul de clusterizare K-means	10
3.1.2.3 Modelul contururilor active.....	10
3.1.3 Extragerea caracteristicilor de culoare	11
3.1.4 Extragerea caracteristicilor de textură	12

3.1.4.1	Matricea de coocurență a nivelurilor de gri (GLCM)	12
3.1.4.2	Modele locale ternare extinse (ELTP)	12
3.1.5	Extragerea caracteristicii de formă	13
3.1.5.1	Normalizarea rotației.....	13
3.1.5.2	Extragerea conturilor	14
3.1.5.3	Histograma codului lanț	14
3.1.5.4	Formă răsturnată vertical și orizontal.....	15
3.2	Aplicarea tehnicilor de extragere a caracteristicilor pentru diagnosticul tumorilor cerebrale.....	17
3.2.1	Extragerea caracteristicilor de culoare pentru diagnosticul tumorilor cerebrale .	17
3.2.1.1	Planul mediu sagital (MSP).....	17
3.2.2	Detectarea tumorii cerebrale.....	17
3.2.2.1	Preprocesarea secțiunii cerebrale	18
3.2.2.2	Estimarea înclinării	18
3.2.2.3	Analiza simetriei bilaterale.....	20
3.2.2.4	Segmentarea și extragerea tumorii	20
3.2.3	Extragerea caracteristicilor locale de textură pentru diagnosticul tumorilor cerebrale ²¹	
3.2.3.1	Estimarea unghiului de rotație.....	21
3.2.3.2	Model local ternar bloc (Block-LTP).....	22
3.2.3.3	Detectarea planului mediu sagital	22
3.3	Regula ABCD pentru extragerea caracteristicilor folosită pentru diagnosticarea cancerului de piele melanom	23
3.3.1	Caracteristicile regulii.....	23
3.3.1.1	A: Asimetria	23

3.3.1.2	B: Neregularitatea conturului	24
3.3.1.3	C: Indicele culoare	24
3.3.1.4	D: Diametrul.....	25
3.3.2	Utilizarea caracteristicilor de regulă în clasificarea leziunilor cutanate.....	25
Capitolul 4: Experimente și rezultate		26
4.1	Aplicarea algoritmilor de histogramă de culoare și a caracteristicilor statistice de textură pentru CBIR.....	26
4.2	Aplicarea algoritmului modelului local ternar extins pentru CBIR	28
4.3	Aplicarea algoritmului bazat pe formă pentru CBIR.....	29
4.4	Aplicarea algoritmilor caracteristicilor locale ale texturii pentru localizarea MSP în imaginea secțiunii de creier	32
4.5	Aplicarea algoritmilor de asimetrie și de grupare K-Means pentru detectarea tumorilor cerebrale.....	32
4.6	Aplicarea caracteristicilor de textură locală pentru analiza performanței algoritmului de clusterizare K-Means în detectarea tumorilor cerebrale	33
4.7	Aplicarea caracteristicii statistice de textură și a regulii ABCD pentru diagnosticului cancerului de piele melanom	35
Concluzii și sugestii pentru continuarea activității.....		36
Contribuțiile tezei		38
Bibliografie selectiva.....		39

Capitolul 1: Introducere

1.1 Introducere

Tehnica de extragere a imaginilor bazată pe conținut (CBIR – în engleză Content Based Image Retrieval) este utilizată pentru extragerea imaginilor dintr-o bază de date imensă, în funcție de conținutul celor trei caracteristici principale: culoare, textură și recunoașterea formei. Majoritatea tehnicilor CBIR extrag caracteristicile bazate pe conținut din imagine de interogare și din imaginea din baza de date, aplicând apoi comparația între cele două imagini pentru a identifica diferențele dintre caracteristicile lor în ceea ce privește funcția lor de distanță spațială [1] [2]. Sistemele comerciale de extragere a imaginilor utilizează în majoritatea cazurilor cuvinte cheie sau text cu fiecare imagine pentru procesul de extragere. Acesta este motivul pentru care acestea sunt numite Text Based Image Recovery (TBIR). Un exemplu bun în acest sens ar fi Google Images [3]. Problema poate fi rezumată după cum urmează: rezultatele căutării sunt complet dependente de cuvintele cheie utilizate pentru a descrie imaginea. În plus, este aproape imposibilă căutarea de imagini care nu conțin cuvinte cheie sau descrieri [4].

Căutarea și extragerea imaginii pe baza conținutului în funcție de caracteristica texturii poate fi realizată prin diferite metode dezvoltate. Aceste tehnici sunt construite pe baza comparării valorilor obținute din imaginile de interogare și din cele țintă, cunoscute și ca metoda de ordinul doi. Se utilizează pentru calcularea caracteristicilor texturii imaginii de măsurare, cum ar fi granularitate, direcționitate, moment și GLCM. În această teză, propunem metode noi de extragere a imaginilor, bazate pe trăsături de textură locale. Aceste tehnici pot fi implementate în diverse aplicații, cum ar fi diagnosticul medical [5]. Modelul binar local (LBP) [6] este un instrument de bază pentru a caracteriza proprietatea locală a unei texturi. Multe dintre aplicațiile LBP includ recunoașterea feței, analiza expresiilor faciale, clasificarea texturii și modelarea fundalului [7].

Recunoașterea formei este o problemă principală în CBIR [8]. Forma obiectelor joacă un rol important pentru distingerea informațiile vizuale. Descriptorul de formă al unei

caracteristici a obiectului are o influență mai mare decât alte caracteristici (cum ar fi culoarea și textura) și este puternic legat de funcționalitatea sau identitatea obiectului. Cu toate acestea, procesele de de caracterizare ale formei perceptuale și de măsurarea a asemănării dintre forme sunt sarcini dificile, deoarece formele sunt adesea corupte cu zgomot, ocluzie și distorsiuni. Descriptorii de formă sunt pur și simplu un set de vectori numerici pentru caracteristici care sunt generați pentru a descrie o anumită formă. Ar trebui să fie invariabil modificat, în general, chiar și în cazul translației, rotației și scalării cauzate de modificările unghiului datorită mișcării camerei/obiectului [8]. Majoritatea sistemelor de extragere a imaginilor bazate pe forme extrag informația despre formă pe baza vectorilor de caracteristică din imaginea de interogare și din imaginea din baza de date și calculează măsurarea similitudinii între cele două imagini pe baza funcțiilor distanței spațiale. O valoarea redusă a distanței indică cea mai apropiată similitudine și specifică lista de imagini care urmează a fi extrase pe baza celei mai mari potriviri [9]. Figura 1.1 prezintă diagrama generală a unui sistem CBIR de bază.

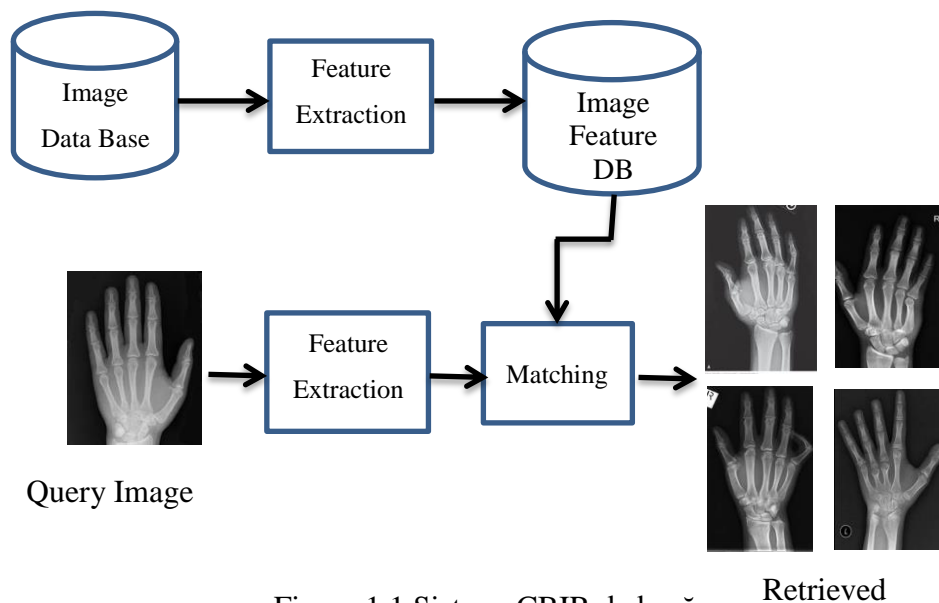


Figura 1.1 Sistem CBIR de bază

1.2 Scopuri și obiective

- Obținerea rapidă de imagini dintr-o bază de date extinsă dedicată imaginilor pe baza relevanței obiectului într-un grup de obiecte segment; calcularea vectorilor histogramei și texturilor statistice pentru a identifica asemănarea.

- Obținerea rapidă unei imagini frecvente dintr-o bază de date extinsă dedicată imaginilor pe baza conturului unui obiect și a calculării CCH, care este folosit pentru a descrie o formă dată.
- Îmbunătățirea LBP-ului inițial prin propunerea unei noi extensii numite model local ternar uniform extins (UELTP) pentru CBIR.
- Identificarea planului mediu sagital în imaginile RMN T1-ponderate folosind proprietățile de intensitate redusă ale regiunii fisurii interemisferice.
- Detectarea unghiului de rotație în secțiunile de creier prin determinarea MSP a obiectului creierului.
- Detectarea regiunii tumorale prin aplicarea clusterizării în K-means și utilizând eticheta de componente conectate.
- Analizarea efectelor diferitelor tipuri de caracteristici locale de textură asupra CBIR și determinarea MSP în secțiunile de creier MR.
- Diagnosticarea cancerului cutanat al melanomului utilizând caracteristicile de textură și regula ABCD

1.3 Structura tezei

Secțiunile acestei teze se compun din cinci capitole care sunt structurate după cum urmează:

Capitolul al doilea: Acest capitol prezintă tehnicile de extragere a caracteristicilor fundamentale pentru CBIR și pentru imaginile de diagnostic medical, precum și măsurători de similitudine și extragere.

Capitolul al treilea: Acest capitol are ca scop descrierea unui set de algoritmi utilizați în extragerea și diagnosticarea imaginilor medicale: algoritm de preprocesare imagine, algoritmi de segmentare a obiectelor, algoritmi de extracție la nivel inferior, algoritmi de caracteristici de textură locală, algoritmi de calcul pentru unghiul de rotație a obiectului și algoritmi de detecția MSP pentru estimarea înclinării obiectului pentru creier.

Capitolul al patrulea: Acest capitol prezintă rezultatele experimentale ale aplicării algoritmilor detaliați în capitolul treilea.

Capitolul al cincilea: acest capitol rezumă principalele realizări ale cercetării, trage concluzii legate de extragerea imaginilor și diagnosticarea patologiilor acestei cercetări; de asemenea, conturează direcțiile viitoare și perspectivele pentru activitatea de cercetare.

Capitolul 2: Principiile CBIR și ale diagnosticării imaginilor

2.1 Tehnici de extragere a caracteristicilor

O caracteristică se poate defini prin capturarea vizuală a unei trăsături specifice a unei imagini complete sau parțiale printr-un grup de pixeli. Extragerea oricărei caracteristici este o modalitate de a obține informații utile din imagini. Această secțiune prezintă trei caracteristici: culoarea, textura și forma. Pentru a atinge un grad înalt de discriminare pentru procesul de comparare, aceste caracteristici ar trebui integrate [10].

2.1.1 Caracteristicile de culoare

Culoarea este cea mai utilizată caracteristică vizuală în extragerea imaginilor. Este relativ predispusă la complicații de fundal și este independentă de dimensiunea și orientarea imaginii. Majoritatea sistemelor CBIR utilizează spațiul de culoare, histograma, momentele și vectorul de coerență a culorii pentru a reprezenta culoarea. Caracteristicile de culoare sunt unele dintre cele mai utilizate caracteristici la nivel scăzut (culoare, textura și forma). Performanța și eficiența funcției de culoare depind foarte mult de spațiul de culoare și de cuantizarea sa [11].

2.1.2 Caracteristicile de textură

Textura imaginii este caracterizată prin reflectarea distribuției spațiale a conținutului gri al imaginii, în plus față de relațiile dintre perechile de pixeli ale imaginii și din jurul acesteia. Textura oferă o măsurare a regularității, rugozității și netezimii unei anumite regiuni. Abordările de extragere pe bază de textură au două direcții: statistice și structurale. În metoda statistică, cele mai simple caracteristici ale texturii sunt utilizate pentru a calcula statisticile de ordinul întâi, cum ar fi măsurătorile medii și variante de la valorile de intensitate gri a imaginii și cele de ordinul doi, cum ar fi matricea de coocurență a nivelurilor de gri GLCM, modelele binare locale (Ojala et al. [6]) și modelul local ternar (Tan și Triggs [12]).

2.1.2.1 Modelul local binar (LBP)

Operatorul LBP original descrie textura din imagine împărțind imaginea în celule. În fiecare celulă, valorile de intensitate ale pixelilor vecini sunt comparate cu valoarea gri a pixelului central și rezultatul este reprezentat ca un cod binar, care de obicei este convertit în număr zecimal pentru comoditate [13]. Figura 2.1 ilustrează un exemplu al procesului de stabilire a pragului binar pentru vecinătatea circulară $((g,r) = (8, 1))$. Histograma imaginii rezultate este utilizată pentru extragerea imaginilor.

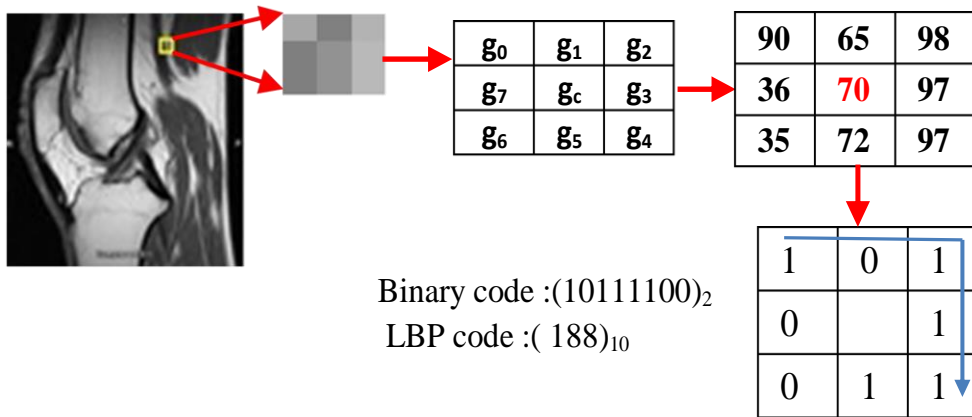


Figure 2.1 Exemplu de operator LBP de bază [14]

Existența unor caracteristici invariabile la rotația imaginii de intrare este recomandată în numeroasele aplicații de analiză a texturii. Ojala et al. [6] prezintă un nou operator numit modele uniforme (ULBP). Numărul de biți variază de la 0 la 1 sau de la 1 la 0 în fiecare model circular al codului LBP, ceea ce oferă măsura uniformității U .

- **Model local binar mediu (ALBP)**

ALBP este o extensie a funcției LBP în descrierea structurii de textură locală. Această metodă se bazează pe compararea fiecărui pixel vecin din jurul pixelului central cu valoarea medie calculată a tuturor pixelilor vecini din jurul centrului [15].

- **Model local binar bloc (BLBP - Block Local Binary Pattern)**

Funcțiile BLBP asigură puterea discriminatorie a caracteristicilor de textură LBP și îmbunătățesc codificarea caracteristicilor de textură LBP și a preciziei de clasificare. Funcția BLBP prezintă diferențe de intensitate între pixelul central și valorile medii ale intensității pixelilor în blocuri, astfel încât valorile mai mari ale intensității pixelilor în blocuri pot fi partajate, conținând informații diferite care nu sunt capturate de caracteristicile LBP originale.

2.1.2.2 Model local ternar (Local Ternary Pattern)

LBP este sensibil la zgomot, deoarece o mică schimbare la gri a pixelului central poate provoca schimbări drastice ale codului LBP. Pentru a rezolva un astfel de defect, LBP-ul de bază a fost extins la o versiune cu coduri de trei valori (-1, 0 și 1), care este mai puțin sensibilă la zgomot și mai discriminatorie în regiunile uniforme. Versiunea aceasta se numește model local ternar (LTP). Codul LTP este generat prin compararea valorilor intensității pixelilor vecini cu valoarea de gri a pixelului central, pragul (t) utilizat pentru îmbunătățirea rezistenței la zgomot.

2.1.3 Caracteristicile de formă

Descriptorii de formă pot fi împărțiți în două categorii principale: metode bazate pe regiuni și contur (bazate pe limite). Metodele bazate pe regiune utilizează pixelii întregi într-o regiune de formă și sunt considerați pentru a obține descrierea formei; în comparație cu metoda bazată pe contur, necesită un efort de calcul mai ridicat și mai mult spațiu de stocare. În această teză am folosit coduri Freeman (coduri lanț) pentru extragerea imaginilor, a indicelui de compactitate și a dispersiei neregularităților pentru diagnosticarea imaginilor.

2.1.3.1 Codul lanț (Chain Code)

Codurile lanț au fost introduse de Freeman [16] și au fost folosite pentru a reprezenta o limită a formei obiectelor separate în imagine prin înregistrarea listei de puncte de margine de-a lungul unui contur și specificarea direcției conturului la fiecare margine din lista numerelor. Direcțiile fiecărei muchii sunt cuantificate într-una din cele patru direcții sau opt direcții. Codul lanț este generat pornind de la determinarea punctului de pornire la prima margine din

lista de contur, mergând în sensul acelor de ceasornic în jurul conturului, transversal de la un pixel la următorul pixel limită.

2.1.3.2 Indicele de compactitate

Indicele de compactitate este una dintre cele mai populare metode utilizate pentru măsurarea și cuantificarea circularității leziunii cutanate. Se bazează pe doi parametri: perimetrul și suprafața. Compactitatea reprezintă proporția dintre aria obiectului A_s și aria cercului A_c ce

poate fi trasat cu același perimetru. $C = A_s/A_c = (\text{aria zonei})/(\text{aria cercului}) A_c = \frac{P^2}{4\pi}$ deci

$C(S) = \frac{4\pi A_s}{P^2}$, unde A_s este numărul de pixeli ai leziunii iar P (circumferința) reprezintă

numărul de pixeli de limită.

Eficiența indicelui de compactitate depinde de limita închisă a formei obiectului. Pentru un obiect circular, valoarea lui $C(S) \approx 1$, ceea ce reprezintă cel mai mare grad al indicelui de compactitate [17].

2.1.3.3 Neregularitatea dispersiei (IR)

Neregularitatea dispersiei (IR) este o altă caracteristică sugerată de Mark și Alberto [17] care tratează un obiect cu formă neregulată, cum ar fi o formă confuză.

Capitolul 3: Principii de proiectare a sistemelor medicale pentru diagnosticul bazat pe imagini

3.1 Metode și instrumente

În general, metoda sugerată urmează trei faze. Primul pas este preprocesarea, utilizând egalizarea histogramei, îmbunătățirea contrastului liniar, filtrul Gaussian, filtrul median și filtrul de ascuțire. Al doilea pas este segmentarea imaginilor prin aplicarea componentelor conectate, a metodelor de grupare K-means și a metodelor snakes. Al treilea pas este extracția caracteristicilor. Figura 3.1 ilustrează sistemul metodei printr-o diagramă bloc.

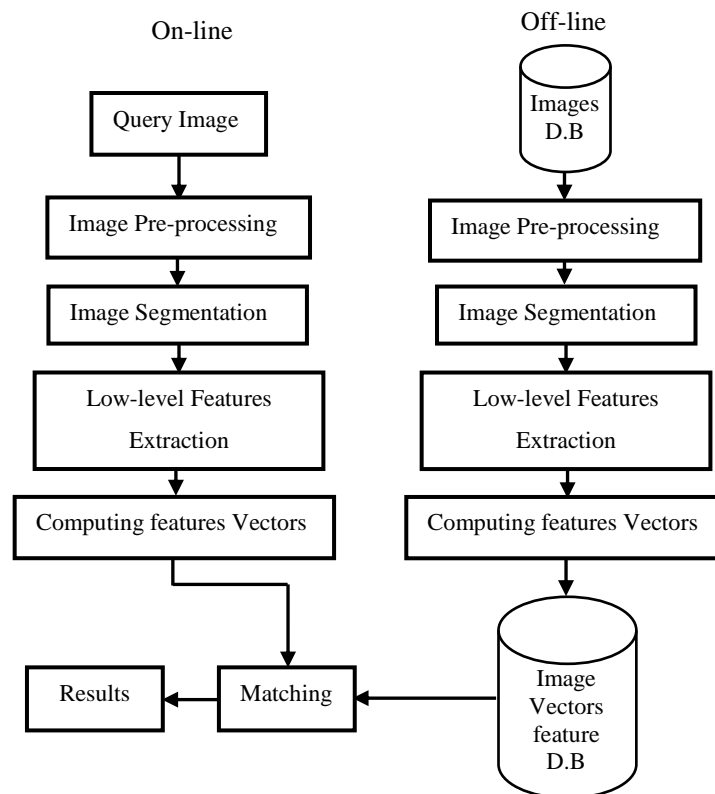


Figura 3.1 Sistem de extragere a imaginii prin utilizarea extragerii de nivel scăzut

3.1.1 Preprocesare

Scopul preprocesării este minimizarea influenței modificării luminozității pixelilor înainte de clasificare. Prin urmare, este necesar să se aplice o îmbunătățire a imaginii înainte de

efectuarea oricărei analize de segmentare a imaginii și a texturii [18]. Preprocesarea propusă în această teză constă în diferite filtre: egalizarea histogramei, îmbunătățirea contrastului liniar, filtrul median, filtrul de ascuțire și filtrul Gaussian [19].

3.1.2 Segmentarea imaginii

3.1.2.1 Componente conectate

Relația dintre doi sau mai mulți pixeli este definită prin conectivitate pixelilor. Există două condiții pentru a realiza conectivitatea pixelilor, luminozitatea pixelilor și apropierea lor în spațiu. Pentru formularea măsurii de apropiere pentru conectivitate, am folosit în primul rând reprezentarea zonei de vecinătate. Figura 3.2 ilustrează o parte dintr-o imagine binară, care are două componente conectate ce se bazează pe conectivitate 4. Dacă aceste două componente conectate sunt combinate într-una, conectivitatea se bazează pe 8 vecini.




Figura 3.2. Două componente conectate bazate pe conectivitate 4

Pentru multe aplicații de analiză automată a imaginilor, este importantă împărțirea imaginii binare în obiecte. Pentru a extrage componentele conectate, să presupunem că A este o imagine binară care conține una sau mai multe componente conectate. Creăm o matrice X_0 care are aceeași dimensiune cu matricea care conține A . Procesul de extracție constă în pornirea cu X_0 și găsirea tuturor pixelilor conectați prin aplicarea următoarei proceduri iterative [20]:

$$X_k = (X_{k-1} \oplus B) \cap A \quad k = 1, 2, 3, \dots \quad (3.1)$$

unde A este o imagine de testare care conține una sau mai multe componente conectate, B este un element de structurare adecvat. Procedura iterativă este terminată când $X_k = X_{k-1}$ și X_k conțin toate componentele conectate ale lui A .

3.1.2.2 Algoritm de clusterizare K-means

Algoritm de grupare K-means este unul dintre algoritmi cei mai utilizați în grupare și segmentare. Este un algoritm de grupare nesupravegheat pentru a segmenta punctele de intrare de date utilizând caracteristicile imaginii în mai multe clase/grupuri K . Algoritm de grupare K-means include, în principiu, următoarele etape [21]:

- Inițializare: se definește numărul de clustere K , așa numitul centroid, și se creează aleator poziția centrelor pentru fiecare cluster,
- Alocarea fiecărui punct de date al setului de date către cel mai apropiat centru de cluster, prin calcularea distanței dintre setul de date și centrul de cluster, aplicând ecuația (3.2) și
- Actualizarea centroidului pentru noile clustere cărora le-au fost alocate noi puncte de date și pentru alte clustere care au pierdut puncte de date. Etapele 2 și 3 se repetă până când nu mai există schimbări semnificative ale punctelor de date între grupurile K , adică atunci când centrul este imobil.

$$F = \sum_{j=1}^K \sum_{i=1}^n (x_i^{(j)} - c_j)^2 \quad (3.2)$$

unde $x_i^{(j)}$ reprezintă punctul de date, c_j este centrul clusterului iar n este numărul punctelor de date.

Calitatea rezultatelor finale de grupare va depinde de selectarea numărului corespunzător de clustere K . În această teză, metoda Silhouette [22] este utilizată pentru a analiza rezultatele clusterelor și pentru a alege cel mai adecvat cluster K .

3.1.2.3 Modelul conturilor active

Modelul conturilor active, numite și șerpi (snakes) a fost prezentat pentru prima oară de Kass et al. [23]. Această metodă este folosită pentru împărțirea imaginii în două părți (obiect, sau prim plan și fundal) a imaginii 2D alb-negru, așa cum este indicat în figura 3.3. Această tehnică necesită un contur inițial drept contur de început pentru segmentarea imaginii. Forma conturului se schimbă și se deplasează spre limitele obiectului drept. Metoda conturului în mișcare se bazează pe ecuația derivată în mod normal din metoda numerică. La final se micșorează complet și se înfășoară în jurul obiectului [24].



Figure 3.3 Exemple de segmente de imagini 2-D alb-negru pentru mână, genunchi și secțiune de creier în prim plan (alb) și fundal (negru) folosind metoda conturilor active [14].

3.1.3 Extragerea caracteristicilor de culoare

Metoda propusă pentru extragerea imaginilor se bazează pe componente conectate și pe interesul obiectelor pentru a genera vectorii caracteristicilor histogramei de culoare. Acești vectori rezultați sunt folosiți pentru a extrage imagini dintr-o bază de date mare de imagini.

Algoritm 3.1 pentru extragerea obiectului componentelor conectate [2]:

- Introducerea imaginii de interogare de la utilizator,
- Convertirea spațiului de culoare RGB în alb-negru prin aplicarea mediei ponderate a componentelor R , G și B : $0.2989 \times R + 0.5870 \times G + 0.1140 \times B$
- Calcularea limitei imaginii alb-negru prin aplicarea metodei Otsu [25],
- Transformarea imaginii alb-negru în imagine binară pe baza limitei,
- Îmbunătățirea imaginii binare rezultate prin eliminarea obiectelor mici (de exemplu cu suprafață sub 50 de pixeli),
- Calcularea componentelor conectate ale obiectelor din imaginea binară prin aplicarea ecuației (3.1),
- Selectarea suprafeței cu numărul maxim de obiecte conectate și identificarea poziției acestora.

Figurile de la 3.4-(c) până la 3.4-(I) ilustrează rezultatele obținute prin segmentarea imaginii binare în obiecte cu componente conectate și suprafața fiecărui obiect. Figura 3.4-(d) reprezintă mărimea maximă a obiectului.

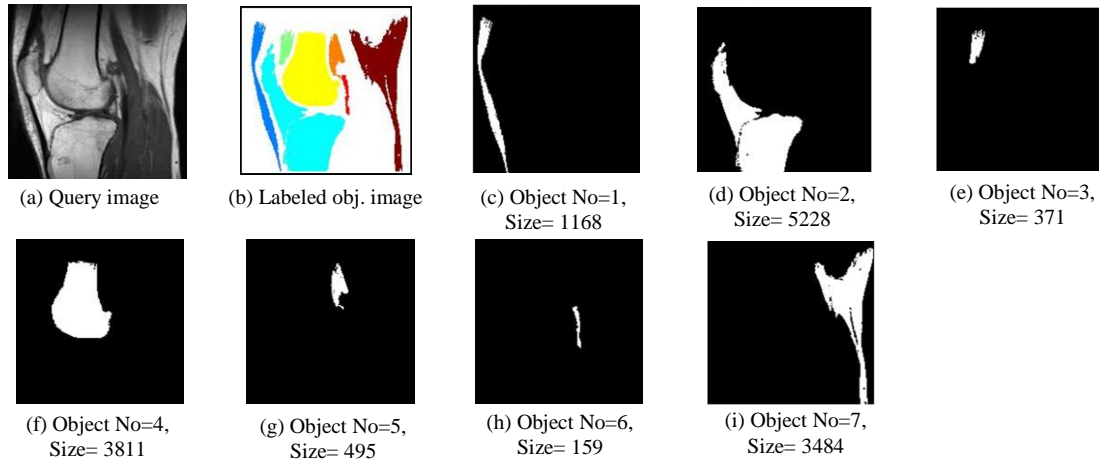


Figura 3.4 (a) Imaginea de interogare, (b) Etichetarea imaginii componentelor conectate, (c-i) Obiectele componentelor conectate din imaginea de interogare și suprafața fiecărui obiect [2].

3.1.4 Extragerea caracteristicilor de textură

În această teză, extragerea imaginilor utilizând funcția de textură se realizează prin două metode:

3.1.4.1 Matricea de coocurență a nivelurilor de gri (GLCM)

Algoritm 3.2 pentru extragerea caracteristicilor de textură:

- Introducerea imaginii de interogare de la utilizator,
- Convertirea imaginii de interogare în imagine alb-negru,
- Obiectul cu suprafața cea mai mare este selectat automat,
- Calcularea a patru matrici GLCM pentru fiecare direcție (0° , 45° , 90° , 135°),
- Calcularea pentru fiecare matrice GLCM a caracteristicilor statistice cum ar fi energie, omogenizare, contrast și corelație,
- Comparare rezultatelor caracteristicilor statistice ale imaginilor din baza de date cu cele ale imaginii de interogare prin folosirea distanței, și extragerea imaginilor pe baza distanței minime.

3.1.4.2 Modele locale ternare extinse (ELTP)

Modelul local ternar extins (ELTP – în engleză Extended Local Ternary Pattern) este diferit de operațiunea menționată din perspectiva independenței de (t) constant. Pragul modelului local

(t) este calculat automat în funcție de caracteristicile locale ale pixelilor vecini ai pixelului curent care sunt calculați statistic [26].

$$ELTP_{p,r} = \begin{cases} 1 & g_p - g_c \geq (\sigma \times \alpha) \\ 0 & |g_p - g_c| < (\sigma \times \alpha) \\ -1 & g_p - g_c \leq -(\sigma \times \alpha) \end{cases} \quad (3.3)$$

unde σ reprezintă deviația standard a punctelor din vecinătatea pixelului curent iar α reprezintă factorul de scalare utilizat, valoarea acestuia fiind între 0 și 1. Calcularea constantei de rotație. Calcularea $ELTP_{p,r}$ a caracteristicilor $ELTPU_{p,r}^{riu2}$ și $ELTPL_{p,r}^{riu2}$ se face prin utilizarea aceluiași operațiuni care sunt în general folosite pentru a transforma $LBP_{p,r}$ în $LBP_{p,r}^{riu2}$.

3.1.5 Extragerea caracteristicii de formă

În această teză ne concentrăm asupra metodelor bazate pe contur pentru a calcula histograma codului lanț (CCH) și pentru a calcula vectorii caracteristicilor de formă în scopul stabilirii similitudinii. Există unele dezavantaje ale metodei codului lanț, cum ar fi sensibilitatea la rotație, schimbări la răsturnare și scalare. În această teză, pentru a rezolva problemele de rotație și de răsturnare a imaginii, se aplică metoda secundară pentru a calcula unghiul de rotație, se analizează datele din direcțiile histogramei codului lanț și se identifică în cele din urmă asemănarea dintre formele răsturnate orizontal/vertical și forma originală.

3.1.5.1 Normalizarea rotației

O margine a oricărui obiect obișnuit sau neregulat după ce se aplică procesul de rotație obține rezultate diferite ale codului lanț. Momentele de imagine joacă un rol foarte important în analiza și discriminarea formei obiectului. Sistemul propus utilizează metoda a doua momente pentru a calcula unghiul dintre axa x și axa principală a elipsei [27]. Centroidul formei este reprezentat de cele două coordonate (x_c , y_c), unghiul θ între axele majore (linia lungă) axa x, w și l axele majore și minore, respectiv, după cum se arată în Figura 3.5.




Figura 3.5 Unghi de rotație a imaginii RMN pentru mână, (a) Imagine originală, (b) imagine binară după procesare și extragerea componentelor conectate ale obiectului, (c) identificarea unghiului de înclinare prin folosirea geometriei analitice pentru elipsa de rotație [28].

3.1.5.2 Extragerea conturilor

Crearea codului lanț se bazează pe extragerea conturilor formei. Fie A reprezentarea imaginii binare cu dimensiunea $N \times M$, pixelii de fundal sunt reprezentați prin valoarea 0 iar prim planul sau forma este reprezentat prin valoarea 1.

Algoritm 3.3 de extragerea a conturilor pentru codul lanț [28]:

- Selectarea obiectului de interes prin aplicarea *Algoritmului 4.1*,
- Identificarea limitei obiectului selectat (A) prin $\beta(A)$,
- Procesarea A prin folosirea elementului de structurarea B ,
- Extragerea conturului prin aplicarea ecuației:

$$\beta(A) = A - (A \ominus B) \quad (3.4)$$

3.1.5.3 Histograma codului lanț

Distribuțiile de frecvență ale apariției diverselor direcții reflectă forma obiectului. **Algoritmul 3.4** de calcul al CCH al obiectului [41]:

- Extragerea conturului obiectului prin aplicarea *algoritmului 3.3*,
- Indicarea poziției pixelului de început pe conturul regiunii de obiect,
- Salvarea poziției punctului de început,
- Testarea fiecărui pixel de pe contururile obiectului în sens invers acelor de ceasornic,
- **For** pentru fiecare pixel poziționat pe conturul obiectului **do**

- Selectarea direcției conturului în funcție de 8 direcții,
- Salvarea rezultatului final într-o mulțime sau o listă,
- **End For**,
- Numărarea frecvențelor care corespund fiecărui număr din codul lanț, de la 0 la 7.

3.1.5.4 Formă răsturnată vertical și orizontal

Se propune o nouă metodă pentru a rezolva problema răsturnării; această metodă se bazează pe analiza datelor CCH și apoi găsirea asemănării dintre forma răsturnată vertical/orizontal și forma inițială conform direcțiilor histogramei. Tabelul 3.1 ilustrează potrivirea direcțiilor CCH ale imaginii obiectului original cu forma obiectelor răsturnate (orizontal și vertical).

Table 3.1 Comparație între direcțiile CCH pentru a identifica asemănările între imaginea de intrare și imaginea răsturnată [28]

Cod lanț 8 direcții	Răsturnare orizontală 8-direcții	Răsturnare verticală 8-direcții
0	0	4
1	7	3
2	6	2
3	5	1
4	4	0
5	3	7
6	2	6
7	1	5

unde valoarea CCH a obiectului original la direcția zero este egală atât cu valoarea CCH a răsturnării orizontale la direcția zero, cât și cu valoarea CCH a răsturnării verticale în 4 direcții.

Algoritm 3.5 de detectare a răsturnării obiectului [28]:

- Calcularea CCH pentru imaginea de interogare și pentru imaginile din baza de date prin aplicarea **algoritmului 3.4**,
- Salvarea rezultatelor CCH în vector1, respectiv vector2,
- Identificarea răsturnării orizontale prin calcularea rezultatului similitudinii între vector1 și vector2 pe baza indicelui de direcție între coloana 1 și coloana 2 din Tabelul 3.1,

- Identificarea răsturnării verticale prin calcularea rezultatului similitudinii între vector1 și vector2 pe baza indicelui de direcție între coloana 1 și coloana 3 din Tabelul 3.1.

De exemplu, Figura 3.6-(a) prezintă forma obiectului și indică numerele diferite ale conturului codului lanț în 8 direcții. Figura 3.6-(b) reprezintă imaginea răsturnată orizontală a conturului din figura 3.6-(a) și conturul din figura 3.6-(c) prezintă imaginea răsturnată vertical a conturului din figura 3.6-(a). Tabelul 3.2 ilustrează rezultatele CCH ale obiectelor din figura 3.6 atunci când se aplică tabelul 3.1 propus, valorile CCH ale obiectului original (de exemplu) în 2 direcții sunt 4 și se potrivesc ambelor răsturnări: răsturnare orizontală în 6 direcții, și verticală în două direcții.




Figura 3.6. Exemple ale metodei de răsturnare; (a) conturul formei indicând cele 8 direcții ale codului lanț; (b) răsturnare orizontală; (c) răsturnare verticală

Tabel 3.2. Rezultate ale CCH în 8 direcții pentru imaginea originală și pentru imaginile răsturnate în Fig. 3.6 [28]

8 direcții ale codului lanț	CCH Obiect original	CCH Răsturnare orizontală	CCH Răsturnare verticală
0	1	1	0
1	1	2	2
2	4	3	4
3	2	2	1
4	0	0	1
5	2	2	2
6	3	4	3
7	2	1	2
Contur total	15	15	15

3.2 Aplicarea tehnicilor de extragere a caracteristicilor pentru diagnosticul tumorilor cerebrale

3.2.1 Extragerea caracteristicilor de culoare pentru diagnosticul tumorilor cerebrale

Caracteristica de intensitate a culorii este o metodă importantă utilizată pentru a diagnostica patologii. Creierul este unul dintre cele mai mari și mai complexe organe ale corpului uman. Țesuturile sănătoase ale creierului uman sunt prezente într-o simetrie aproximativă bilaterală, în timp ce creșterea tumorilor determină asimetrie în părțile afectate ale creierului. Metoda propusă calculează asimetria bazată pe diferența de intensitate dintre cele două laturi ale unui plan mediu sagital (MSP).

3.2.1.1 Planul mediu sagital (MSP)

Planul mediu sagital este o caracteristică importantă utilizată pentru detectarea asimetriei bilaterale a secțiunii creierului, cum ar fi efectele blocului și densitatea tisulară neechilibrată datorate creșterii tumorale sau sângerării, etc. Fisura interemisferică (IF), care este canelura longitudinală întunecată și adâncă situată la limita mediană dintre cele două emisfere cerebrale, se numește plan mediu sagital (MSP – în engleză Mid-sagittal Plane), așa cum se arată în figura 3.7- (a). IF conține fluid cerebral spinal (CSF – în engleză cerebral spinal fluid). Acest lucru conduce la diferențele de intensitate dintre IF și țesutul incintei care dă un semnal slab către RMN pe planul mediu sagital [29], după cum se arată în figura 3.7- (b).




Figura 3.7 Creierul uman; (a) fisura medială interemisferică subliniată cu linie roșie, (b) Secțiune RMN T1-ponderată axială a creierului cu indicarea MSP prin linie roșie punctată

3.2.2 Detectarea tumorii cerebrale

Metoda propusă constă din două secțiuni: în primul rând, detectarea unei regiuni tumorale, prin utilizarea simetriei bilaterale pentru a distinge secțiunea care conține zona tumorii și, în al

doilea rând, detectarea unei regiuni tumorale, prin aplicarea clusterizării cu K-means, urmată de etichetarea componentelor conectate. Figura 3.8 ilustrează sistemul metodei printr-o diagramă bloc.

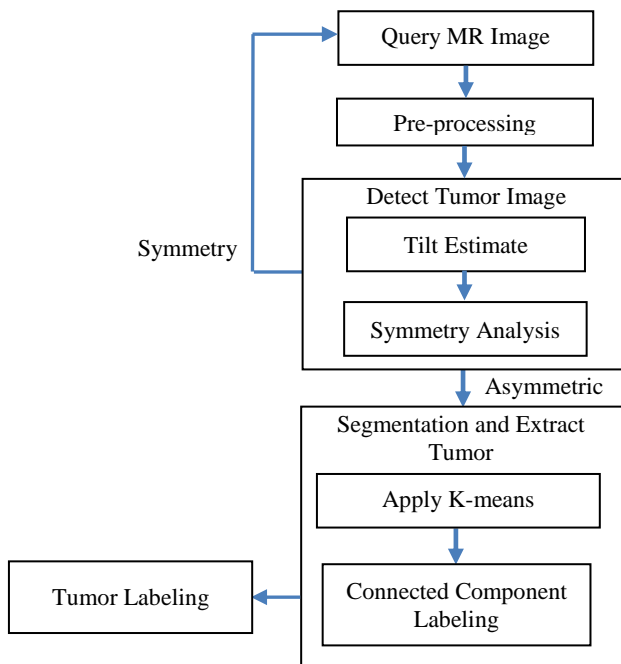


Figura 3.8 Diagrama bloc a detecției tumorii cerebrale [30]

3.2.2.1 Preprocesarea secțiunii cerebrale

Preprocesarea imaginilor este un pas important în diagnosticarea imaginii medicale. Metoda de preprocesare depinde de rezultatele convertirii imaginii de intrare RGB în imagine alb-negru, eliminarea zgomotului și îmbunătățirea imaginii.

3.2.2.2 Estimarea înclinării

Axa de simetrie pe fiecare secțiune a creierului este reprezentată de o linie centrală pentru detectarea asimetriilor bilaterale, cum ar fi efectele tumorale și țesuturile dezechilibrate [31] [4]. Sistemul propus utilizează o metodă pentru a detecta unghiul de rotație în secțiunile creierului, determinând MSP a obiectului creier. Sistemul propus se bazează pe proprietățile unei valori de intensitate scăzută a regiunii IF, așa cum se arată în figura 3.9.

Algoritm 3.6 de identificare a MSP pentru estimările de înclinare a secțiunii obiectului creier [30]:

- Convertirea imaginii RGB în imagini alb-negru și binare,
- Umplerea golurilor imaginii binare prin folosirea unui algoritm bazat pe reconstrucție morfologică,
- Calcularea centroidului secțiunii obiectului creier,
- Generarea unei linii drepte ce trece prin centroid și se rotește de la 0° la 180° incremental cu 1° grad,
- **For** pentru fiecare unghi de rotație θ_o **do**
- Calcularea scorului de intensitate a liniei prin însumarea valorilor binare ale intensității (unu) de-a lungul liniei și ținând cont de unghi,
- Închiderea **For**
- Ordonarea crescătoare a scorurilor de intensitate a liniilor cu unghiuri θ_o ,
- Selectarea unui set de scoruri ale liniilor cu valori ale intensității egale și cu repetiție maximă,
- Alegerea unghiului θ_o și a scorului intensității care reprezintă valoarea media dintr-un set de linii de intensități egale,
- Pe imaginea alb-negru, calcularea intensității liniei L_1 la unghiul θ_o ,
- Pe imaginea alb-negru efectuarea de doua procese de deplasare în jurul θ_o , de la -1 la -10 și de la 1 la 10 și calcularea scorului intensității acestor deplasări respectiv L_2 și L_3 ,
- Calcularea liniei celei mai potrivite prin considerare scorurilor cu cea mai mică intensitate dintre L_1 , L_2 , și L_3 .




Figura 3.9. Extragerea planului mediu sagital dintr-o secțiune cerebrală axială de tipul RMN T1-ponderat; (a) imagine originală; (b) imagine binară cu completarea golurilor, indicând setul de linii mai lungi de intensități egale cu linii roșii; (c) imagine alb-negru indicând un set de linii de intensități mai lungi; (d) linia mediană selectată din setul de linii; (e) poziția îmbunătățită a liniei mediene prin aplicarea deplasării spre stânga sau spre dreapta [30]

3.2.2.3 Analiza simetriei bilaterale

Creierul sănătos prezintă de obicei simetria bilaterală, adică regiunile dintre MSP sunt similare ca formă și locație relativă, în timp ce zonele afectate de tumori sau de patologii nu sunt simetrice [32]. În această teză, simetria bilaterală poate fi calculată prin împărțirea zonei de secțiuni axiale sau coronare a obiectelor în două laturi în funcție de MSP, apoi se calculează valoarea intensității între două laturi așa cum se arată în Figura 3.10.




Figura 3.10. Imagine RMN a unei secțiuni de creier. (a) hemoragie cerebrală, (b) RMN al secțiunii axiale indicând MSP printr-o linie roșie, (c) și (d) asimetrie între cele două părți ale creierului

3.2.2.4 Segmentarea și extragerea tumorii

Algoritm 3.7 de segmentare pentru clusterizarea K-means și extragerea tumorii [30]:

- Convertirea imaginii RGB în imagine alb-negru,
- Introducerea numărului inițial de clustere ca fiind 6,
- Calcularea clusterizării K-means prin aplicarea pașilor din secțiunea 3.1.2.2 [21],

- Analizarea rezultatelor clusterului și a candidaților pentru clusterul K util prin aplicarea metodei Silhouette [22],
- Separarea obiectelor creierului de fundalul imaginii prin abordarea aplicării ecuației componentelor conectate (3.1),
- Etichetarea componentelor conectate pentru detectarea locației tumorii.

3.2.3 Extragerea caracteristicilor locale de textură pentru diagnosticul tumorilor cerebrale

În această teză, extracția MSP se bazează pe calcularea caracteristicilor de textură locală între IF și țesutul înconjurător prin aplicarea tehnicilor LBP [7]. Toate procesele de detectare a MSP sunt prezentate în Figura 3.11.

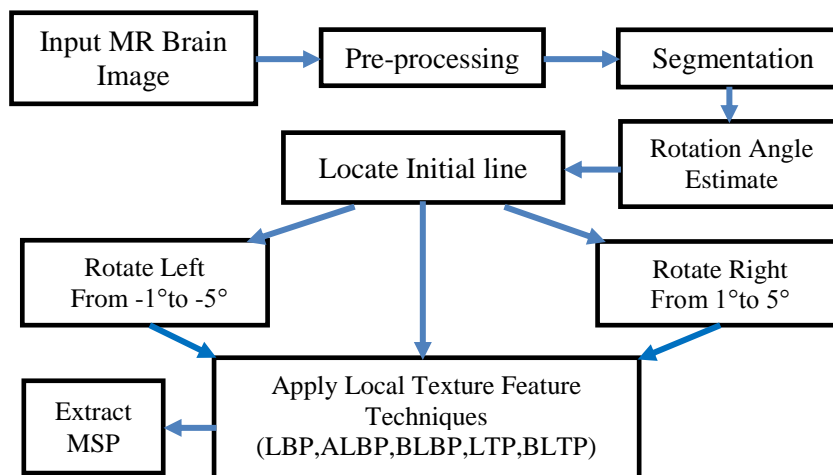


Figura 3.11. Diagrama bloc pentru extragerea MSP [7]

3.2.3.1 Estimarea unghiului de rotație

În unele cazuri, capul pacientului poate fi înclinat în timpul procesului de scanare. MSP este planul care călătorește vertical și împarte creierul în emisfere similare. MSP este folosit pentru a corecta rotația și înclinarea secțiunii creierului [33]. Metoda propusă se bazează pe metoda momentelor de gradul doi pentru a detecta unghiul de înclinare a creierului, prin calcularea unghiului dintre axa x și axa principală a elipsei creierului. Unghiul de rotație rezultat este utilizat pentru a determina linia inițială a MSP [27].

3.2.3.2 Model local ternar bloc (Block-LTP)

Algoritm 3.8 pentru calcularea codului local ternar bloc [7]:

- Introducerea imaginii de învățare din setul de imagini,
- Inițializarea valorilor razelor r_1 și r_2 ,
- Convertirea imaginii RGB a spațiilor colorate în imagine alb-negru,
- **For** fiecare pixel central t_{c1} la raza r_1 **do**
- **For** fiecare pixel învecinat t_{g1} în jurul t_{c1} **do**
- Calcularea valorii medii a tuturor pixelilor învecinați t_{g2} în jurul pixelului central t_{c2} la raza r_2 ,
- Crearea unei ferestre noi cu mărimea (t_{g1}, r_1) ,
- Calcularea codului numeric LTP,
- Împărțirea rezultatelor codului LTP în două părți distincte; pozitive (ridicate) și negative (scăzute)
- **End For**
- **End For**
- Calcularea sumei fiecărei părți din codul LTP separat.

3.2.3.3 Detectarea planului mediu sagital

Algoritmul 3.9 propus pentru detectarea planului mediu sagital este implementat în următorii pași [7]:

- Convertirea imaginii RGB în imagini alb-negru și binare prin aplicarea metodei Otsu [25],
- Calcularea componentelor conectate ale obiectelor imaginii binare prin aplicarea ecuației (3.1) și selectarea suprafeței obiectului cu numărul maxim de componente conectate,
- Generarea unei linii inițiale conform:
 1. Calculului centroidului segmentului imaginii obiectului,
 2. Calcularea valorilor lungimii axei majore,
 3. Calcularea unghiului de rotație a obiectului ϕ ,
- Rotirea liniei inițiale de la 1° la 5° și de la -1° la -5° incremental cu 1° grad,
- **For** fiecare unghi de rotație **do**

- Calcularea tehnicilor LPB și Block-LTP prin aplicarea **algoritmului 3.8** cu urmărirea unghiului,
- **End For**
- Estimarea celei mai potrivite linii prin asumarea sumei minime rezultate dintre valorile mici ale LTP și BLTP; și sumei maxime rezultate dintre valorile mari ale LTP și BLTP.

3.3 Regula ABCD pentru extragerea caracteristicilor folosită pentru diagnosticarea cancerului de piele melanom

Cancerul de piele este o problemă serioasă de sănătate. Este cauzată de dezvoltarea celulelor anormale care au capacitatea de a se răspândi rapid în toate organele corpului uman prin sistemul limfatic sau prin sânge [34]. Melanoamele sunt cele mai agresive și totuși inofensive forme de cancer de piele.

În această teză am folosit metoda automată de diagnosticare a cancerului de piele melanom. Această abordare evoluează în trei etape succesive. Mai întâi, imaginea leziunii este preprocesată folosind filtre low pass, reglare liniară a contrastului și egalizarea histogramei. În al doilea rând, leziunea este segmentată utilizând metoda obiectelor cu componente conectate. În al treilea rând, regula ABCD (Asimetrie, Limită, Culoare și Diametru) și caracteristicile de textură statistică sunt calculate din leziune. Regula ABCD este utilizată pentru a calcula scorul TDV, în timp ce analiza texturii utilizează metode cum ar fi matricea de coocurență a nivelurilor de gri (GLCM) și se extrag patru măsuri statistice: energia, entropia, contrastul și corelația [35].

3.3.1 Caracteristicile regulii

3.3.1.1 A: Asimetria

Asimetria este o caracteristică importantă utilizată pentru realizarea simetriei formei obiectului, care este foarte utilă în analiza modelului. În cazul în care zona aluniței normale este împărțită în două laturi în funcție de axele majore și minore, marginea aluniței pe o parte ar fi perfect similară celeilalte părți. Într-o aluniță asimetrică, cele două laturi de margini nu au o dimensiune sau o formă similare, așa cum se arată în Figura 3.12. În exemplul din Figura 3.12, scorul de asimetrie este 2.




Figura 3.12. (a) Imagine a leziunii cutanate, (b) rezultatul preprocesării și segmentării, (c, d, e și f) diviziuni ale leziunii de-a lungul celor două axe [35]

3.3.1.2 B: Neregularitatea conturului

Neregularitatea conturului este un indicator al creșterii și răspândirii celulei canceroase. Pentru o evaluare, în această teză, leziunea segmentului este divizată în două secțiuni, apoi se calculează distanța euclidiană dintre centrul leziunii și toate limitele pixelilor fiecărei secțiuni separat. În cele din urmă, sumarea diferenței dintre două părți ale leziunii a fost calculată, după cum se arată în Figura 3.13.




Figura 3.13. (a) Imaginea leziunii cutanate; (b) cele două secțiuni ale leziunii în funcție de diviziunea pe axele majore și cele două valori ale distanțelor (D1 și D2) [35]

3.3.1.3 C: Indicele culoare

Un indicator timpuriu al melanomului este dezvoltarea mai multor culori ale zonei leziunii. Deoarece celulele melanomului cresc în pigment, ele sunt adesea colorate în jurul zonelor maro sau negre, în funcție de producerea pigmentului de melanină la diferite adâncimi ale pielii [36]. Indicele de culoare se determină prin conversia imaginii color originale în spațiul de culoare HSV și apoi prin calcularea distanței dintre fiecare valoare a pixelului din leziune și culoarea pe care dorim să o detectăm. Ecuația (3.5) este utilizată pentru a calcula diferența de culori.

$$\Delta E = \sqrt{(h_1 - h_2)^2 + (s_1 - s_2)^2 + (v_1 - v_2)^2} \quad (3.5)$$

unde h_1 , s_1 și v_1 reprezintă spațiul de culoare HSV al culorii solicitate iar h_2 , s_2 și v_2 reprezintă fiecare pixel din imagine. Figura 3.12 arată rezultatele C=4 (roșu, maro deschis, maro închis și roșu închis).

3.3.1.4 D: Diametrul

Există alunițe care își mențin dimensiunea și nu se modifică niciodată, dar altele pot crește sau își pot modifica dimensiunea. Dimensiunea normală este mai mică sau egală cu șase milimetri. Alunițele mai mari pot indica pericol.

3.3.2 Utilizarea caracteristicilor de regulă în clasificarea leziunilor cutanate

Algoritmul Stolz se folosește pentru clasificarea imaginilor pe baza calculării scorului TDV; scorul TDV se calculează pe baza analizei multivariate a celor patru caracteristici și atribuirea unui scor numeric: indicele de asimetrie este (0-2), indicele de contur este (0-8), indicele de culoare este (1-6) și indicele de diametru este (1-5). Fiecare dintre indicii caracteristicilor este scalat de un factor ponderat dat. La final, suma acestor scoruri ponderate este folosită pentru a genera TDV [37].

$$TDV = 1.3 \times A + 0.1 \times B + 0.5 \times C + 0.5 \times D \quad (3.6)$$

Acest rezultat este utilizat pentru a diagnostica leziunile benigne, suspecte sau melanomul, după cum urmează:

$$Diagnosis = \begin{cases} Benign & TDV < 4.75 \\ Suspicious & 4.8 < TDV < 5.45 \\ Melanoma & TDV > 5.45 \end{cases} \quad (3.7)$$

Capitolul 4: Experimente și rezultate

În această teză, toate etapele algoritmilor de extragere a imaginii și diagnosticare medicală sunt implementate în MATLAB R2016A folosind o bază de date care conține 500 de imagini care include patru categorii diferite: genunchi, creier, frunze și mâini. Imaginea creierului este preluată din baza de date în [38]. Rezultatele experimentale ale algoritmilor utilizați în această teză sunt prezentate în secțiunile următoare.

4.1 Aplicarea algoritmilor de histogramă de culoare și a caracteristicilor statistice de textură pentru CBIR

Ne concentrăm asupra selecției automate a regiunilor de interes ale componentelor conectate ale obiectului și asupra calculării histogramei caracteristicilor de culoare ale obiectului și a vectorilor de extragere a texturilor pentru identificarea asemănării. Există cinci categorii diferite, care includ genunchi, creier, dinozauri, mâini și flori. Sistemul este executat cu opt imagini din fiecare dintre cele cinci categorii, iar scorul de similitudine este calculat pentru culoare și textură pentru fiecare imagine. Lista rezultatelor este afișată ca număr de obiecte, dimensiunea maximă a unui obiect și măsurătorile statisticii de coocurenței, așa cum se arată în figura 4.1.

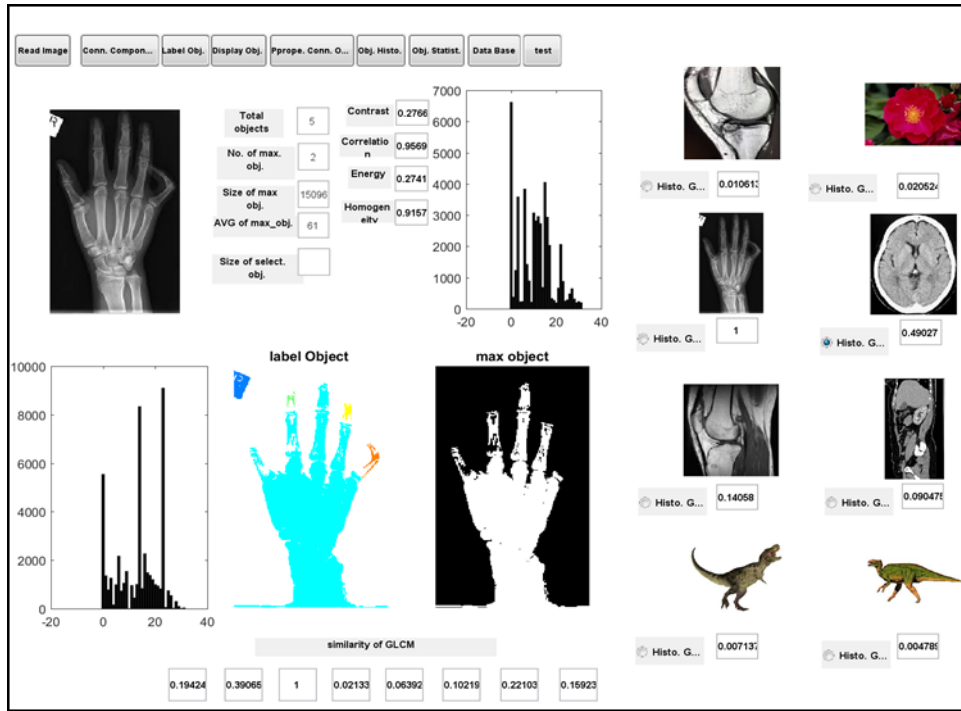


Figura 4.1. Interfața utilizatorului pentru rezultatele de asemănare a culorilor și texturilor între creier și diferite imagini ale creierului

Rezultatele valorilor medii de precizie și ale parametrilor medii de extragere se calculează prin utilizarea histogramelor obiectelor și texturii bazate pe diferite categorii de imagini, așa cum sunt prezentate în tabelul 4.1.

Tabelul 4.1. Analiza de precizie și extragere bazată pe culoare și textură (GLCM)

Categorie	Culoare (Histogramă)		Textură (GLCM)	
	Precizie	Extragere	Precizie	Extragere
Genunchi	0.69	0.20	0.85	0.1
Creier	0.75	0.13	0.60	0.03
Mână	0.79	0.11	0.57	0.03
Flori	0.88	0.28	0.78	0.24
Dinozaur	0.89	0.13	0.93	0.11
Medie	0.80	0.17	0.75	0.10

4.2 Aplicarea algoritmului modelului local ternar extins pentru CBIR

În această teză ne concentrăm pe identificarea automată a obiectului de interes și pe calculul vectorilor caracterelor locale de textură în scopuri comparative. Regiunile de interes sunt identificate aproximativ prin aplicarea metodei de segmentare snakes pentru a produce obiecte independente într-o imagine, segmentând imaginea în prim plan (obiect) și regiuni de fundal, apoi extrăgând caracteristicile locale de texturi (LBP, LTP și ELTP) în fiecare obiect.

Rezultatele experimentale ale performanței sistemului de extragere sunt prezentate pe baza parametrului mediu de precizie și pe calcularea parametrilor de recuperare. Tabelul 4.2 prezintă rezultatele legate de sistemul propus pe baza obiectelor de segmentare pentru diferite categorii de imagini. Tabelul 4.3 ilustrează performanța sistemului de extragere propus prin utilizarea dimensiunilor diferite ale razei r . În acest experiment, comparația dintre metodele propuse ULBP și UELTP este prezentată în Tabelul 4.2. Se demonstrează că $ULBP^{riu2}$ și $UELTP^{riu2}$ ating o medie de precizie cu performanțe mai ridicate decât LBP și LTP clasice. Precizia este cu 13% și 18% mai mare pentru metodele îmbunătățite, $ULBP^{riu2}$ și $UELTP^{riu2}$, comparativ cu versiunile inițiale. GUI-ul propus al sistemului este prezentat în Figura 4.2.

Tabel 4.2. Analiza preciziei și extragerii ULBP și UELTP bazată pe un obiect de segmentare

Categorie	$ULBP_{8,1}^{riu2}$		$UELTP_{8,1}^{riu2}$	
	Precizie	Extragere	Precizie	Extragere
Genunchi	0.80	0.24	0.91	0.18
Secțiune de creier	0.75	0.28	0.88	0.21
Mână	0.79	0.24	0.83	0.25
Medie	0.78	0.25	0.87	0.21

Tabel 4.3. Analiza preciziei ULBP și UELTP bazată pe diferite dimensiuni

Categorie	$ULBP_{p,r}^{riu2}$			$UELTP_{p,r}^{riu2}$		
	(p,r)			(p,r)		
	(8,1)	(8,2)	(8,3)	(8,1)	(8,2)	(8,3)
Genunchi	0.80	0.79	0.77	0.91	0.88	0.90
Secțiune de creier	0.75	0.75	0.73	0.88	0.85	0.86
Mână	0.79	0.77	0.73	0.83	0.83	0.80
Medie	0.78	0.77	0.74	0.87	0.85	0.85

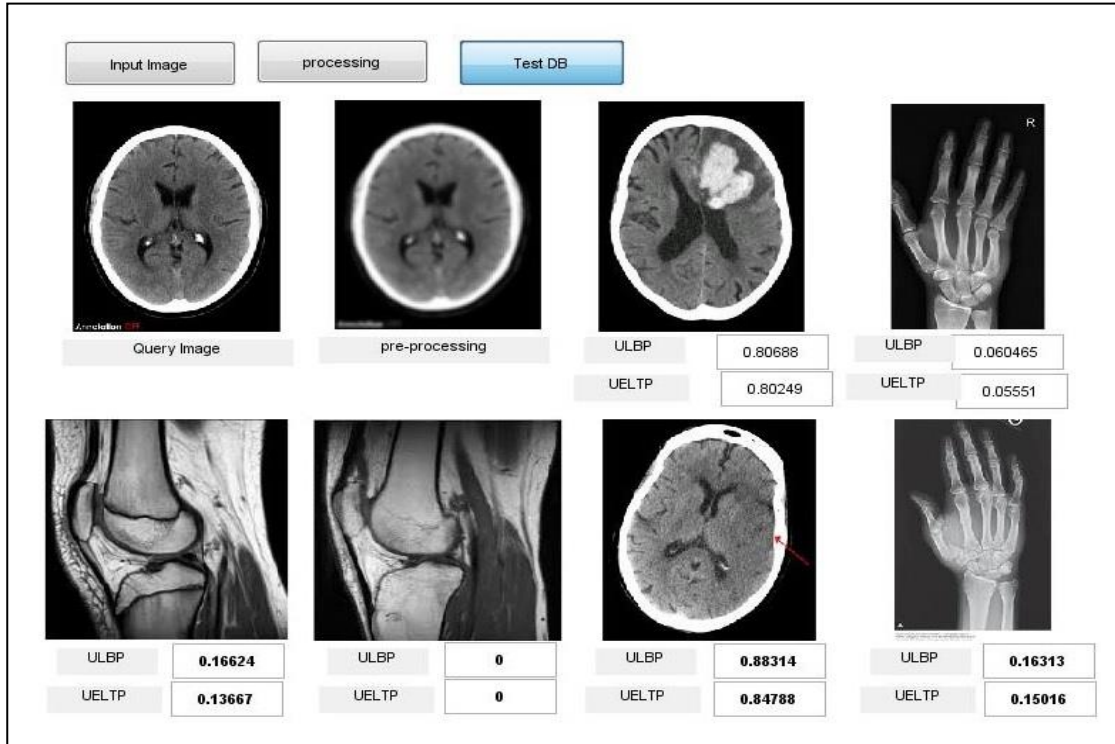


Figura 4.2. Interfața utilizator a rezultatelor ULBP și UELTP pentru găsirea asemănării dintre imaginea creierului și a mâinii, a genunchiului și a creierului

4.3 Aplicarea algoritmului bazat pe formă pentru CBIR

În cadrul acestei cercetări am folosit metodele bazate pe contur pentru a calcula histograma codului lanț (CCH) și pentru a calcula vectorii caracteristicilor de formă pentru scopul similarității, care descrie o formă dată. Pentru testarea răsturnării orizontale și verticale, valorile CCH pentru toate cele trei imagini diferite din Fig. 4.3- (c) și 4.3- (e) sunt calculate folosind algoritmul (3.4). În cele din urmă algoritmul (3.5) este aplicat pentru a găsi indicele de similitudine. Rezultatele experimentale arată că valorile indicelui de similitudine între imaginea interogării și imaginea răsturnată se încadrează în valori mai mari de 0,90, după cum se arată în Figura 4.4.




Figura 4.3. Imagine răsturnată: (a) imagine originală; (b) imagine răsturnată orizontal; (c) limitele de contur ale imaginii răsturnate orizontal; (d) imagine răsturnată vertical; (e) limitele de contur ale imaginii răsturnate vertical




Figura 4.4. CCH pentru imaginea originală și pentru imaginile răsturnate (orizontal și vertical)

Sistemul execută șase imagini din fiecare dintre cele patru categorii și calculează asemănarea atât cu CCH, cât și cu CCH-răsturnat între imaginea de interogare și imaginea din baza de date. Pentru fiecare imagine, sistemul poate afișa unele rezultate ale imaginilor care descriu îmbunătățirea imaginii interogării, a conturului obiectului și histogramă a codului de lanț atât pentru imaginea de interogare, cât și pentru imaginile din baza de date, așa cum se arată în Figurile 4.5.

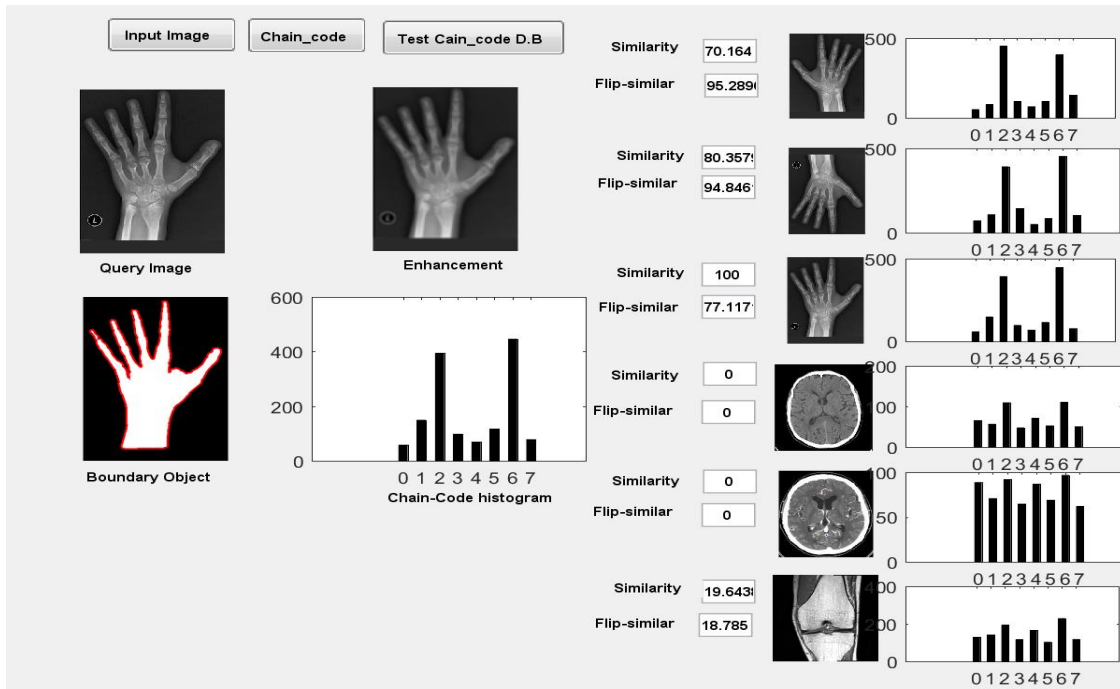


Figura 4.5 Interfața utilizator a rezultatelor similarității CCH și CCH răsturnat între imaginea mâinii și diferite imaginile

Pentru a evalua activitatea sistemului propus, parametrii de precizie și recuperare sunt calculați prin calcularea histogramei atât la codul lanțului, cât și la imaginea răsturnată; patru categorii diferite de imagini medicale sunt prezentate în tabelul 4.4.

Tabel 4.4. Analiza preciziei și extragerii pentru CCH și CCH răsturnat

Categorie	CCH		CCH răsturnat	
	<i>Precizie</i>	<i>Extragere</i>	<i>Precizie</i>	<i>Extragere</i>
Creier	0.62	0.23	0.64	0.19
Mână	0.83	0.22	0.89	0.23
Frunze	0.71	0.20	0.70	0.22
Genunchi	0.65	0.18	0.67	0.20
Medie	0.70	0.21	0.73	0.21

4.4 Aplicarea algoritmilor caracteristicilor locale ale texturii pentru localizarea MSP în imaginea secțiunii de creier

Calculăm caracteristicile locale ale texturilor între MSP inițial și pixelii vecini ai țesutului cerebral prin aplicarea algoritmului 3.8 și a algoritmului 3.9. Sistemul propus constă în patru etape: preprocesarea, segmentarea, estimarea înclinării și aplicarea tehnicilor LBP. Pentru testarea algoritmului de detectare MSP, Figura 4.6 ilustrează un exemplu pentru a detecta linia MSP. Pentru a îmbunătăți precizia detectării MSP, am testat zona vecină în jurul liniei inițiale, aplicând un număr de unghiuri de rotație, de ex. de la 1° la 4° cu un increment de 1° grad, în sensul acelor de ceasornic așa cum se arată în Figura 4.6-e și Figura 4.6-h. Figura 4.6-i până la Figura 4.6-l reprezintă unghiurile de rotație de la -1° la -4° , în sens invers acelor de ceasornic în jurul centrului.




Figura 4.6. Exemple de detectare MSP: (a) imaginea originală a secțiunii de creier; (b) preprocesarea și segmentarea imaginii; (c) detectarea unghiului de înclinare a obiectului creier; (d) linia inițială pe imaginea alb-negru; (e-h) rotația liniei inițiale de la 1° to 4° ; (i-l) rotația liniei inițiale de la -1° to -4°

4.5 Aplicarea algoritmilor de asimetrie și de grupare K-Means pentru detectarea tumorilor cerebrale

Sistemul propus constă în două etape: în primul rând, detectarea secțiunilor tumorale, prin testarea procesului de înclinare și a simetriei bilaterale care clasifică imaginea în două tipuri, imagini tumorale și normale ale creierului. Pentru testarea algoritmului de detectare a MSP,

Fig. 4.7-a prezintă imaginea creierului care conține tumora, Fig.4.7-d prezintă procesul de localizare a unghiului de rotație prin utilizarea valorii de intensitate medie. Numărul maxim de repetiții pentru o linie cu valoarea scorului de intensitate de 192 este de 84 de ori, așa cum este indicat în figura 4.7-d, în consecință unghiul de rotație a liniilor de intensitate medie ($84/2 = 42$) este de 89° . Imaginea prezentată în figura 4.7-e reprezintă rezultatul MSP prin linia roșie. În al doilea rând, detectarea regiunii tumorale, prin aplicarea clusterizării K-means și prin utilizarea etichetării componentelor conectate pentru a detecta localizarea tumorii. Pe baza rezultatului clusterului K, urmată de etichetarea componentelor conectate, tumoarea este extrasă așa cum se arată în figura 4.7-l.




Fig. 4.7. Rezultatele extragerii planului mediu sagital, clusterizare K-means și detectarea leziunii tumorale, (a) Imaginea originală a secțiunii axiale, (b) stabilirea pragurilor, (c) umplerea golurilor imaginii binare, cu indicarea setului de linii mai lungi de intensitate egală prin linii roșii, (d) unghiuri de rotație de la 0° la 180° cu un increment de 1° grad (e) detectarea MSP (f-k) rezultatele clusterizării K-Means de la $K=1$ la $K=6$ clustere, (l) etichetarea tumorii detectate.

4.6 Aplicarea caracteristicilor de textură locală pentru analiza performanței algoritmului de clusterizare K-Means în detectarea tumorilor cerebrale

În acest studiu, am propus segmentarea imaginii MRI a creierului utilizând algoritmul de grupare K-means pentru a genera o listă de imagini de tip cluster. Selectarea automată a imaginii cluster corespunzătoare pentru detectarea tumorii cerebrale se bazează pe caracteristica de textură locală și simetrie bilaterală, care se calculează între cele două părți ale creierului. Metoda propusă constă în două etape: în primul rând, generarea unei liste de

imagini de tip cluster cu regiunile de obiecte de interes prin aplicarea algoritmului de grupare K-means. În a doua etapă, se calculează selecția automată a imaginii cluster corespunzătoare, pe baza asimetriei ULBP și a creierului. Figura 4.8 ilustrează un exemplu pentru detectarea tumorii cerebrale.




Figura 4.8 Exemple de detectare a leziunii tumorale din imaginea RMN T1-ponderat a secțiunii de creier: prima coloana imaginile originale; coloanele de la 2 la 7 rezultatele clusterizării K-Means de la clusterul K_1 la K_6 , cu indicarea rezultatelor valorilor asimetriei pentru fiecare imagine cluster, ultima coloana etichetarea tumorii detectate

4.7 Aplicarea caracteristicii statistice de textură și a regulii ABCD pentru diagnosticul cancerului de piele melanom

În această lucrare, toate etapele sunt implementate în MATLAB R2016A cu un set de 50 de imagini cu leziuni ale pielii, care conțin imagini cu melanom și cu leziuni benigne ale pielii. Figura 4.9-(a) descrie imaginea leziunii pielii; segmentarea și extragerea componentelor conectate ale obiectului leziunii. Așa cum se arată în figura 4.9-(b), au fost aplicate pe imaginea intensității în tonuri de gri. Imaginea segmentată dorită este ilustrată în Figura 4.9-(c). Pentru fiecare imagine, leziunea segmentată este înconjurată de o linie albastră continuă și este determinată de centrul de masă, așa cum se arată în figura 4.9-(d). Segmentul final este folosit pentru a calcula valorile de extracție a caracteristicilor ABCD și a caracteristicilor statistice.




Figura 4.9. (a) Imaginea leziunii de piele; (b) imagine alb-negru; (c) imagine segmentată după aplicarea metodei componentelor conectate; (d) imaginea trasării conturului și a centrului de masă

Concluzii și sugestii pentru continuarea activității

Algoritmii principali aplicați în această teză sunt prezentați în capitolul 3, iar rezultatele lucrărilor propuse sunt prezentate în capitolul 4. Am rezumat următoarele principale constatări și contribuții ale acestei lucrări de cercetare:

- În secțiunea 4.1, discutăm extragerea de nivel inferior a caracteristicilor de culoare și textură pentru CBIR. Experimentele au arătat că metoda propusă este capabilă să extragă obiecte interesante din obiecte neinteresante și o imagine de fundal complexă fără cunoștințe anterioare. Obiectul maxim extras este de așteptat să fie utilizat în mod real în extragerea imaginilor bazate pe obiecte, deoarece reprezintă partea principală a imaginii. Sistemul propus a atins cea mai mare precizie medie, care este de 78%.
- În secțiunea 4.2, studiul de față prezintă metoda LTP uniformă extinsă (UELTP) pentru sistemul CBIR. Se pot extrage mai multe concluzii. Conform primei concluzii, histograma cu caracteristici de textură este o metodă bună de extragere a imaginilor potrivite din baza de date. O altă concluzie indică faptul că rezultatele experimentale arată că $UELTP_{8,1}^{riu2}$ atinge o precizie medie mai mare decât performanțele LBP și LTP clasice. Experimentele arată că performanța $UELTP_{8,1}^{riu2}$ prin utilizarea metodei de segmentare este înaltă pentru creșterea preciziei de extragere, așa cum se arată în Tabelul 4.2 și Tabelul 4.3.
- În secțiunea 4.3, discutăm despre obținerea imaginilor potrivite din baza de date pe baza reprezentării formei utilizând funcțiile CCH. Prima concluzie este că histograma codului lanț este o metodă bună de a recunoaște atât obiectele obișnuite cât și cele neregulate, precum și independența cu privire la punctul de plecare al codului lanțului. O altă concluzie este că experimentele au arătat că metoda propusă este eficientă în creșterea preciziei de regăsire așa cum se arată în Tabelul 4.4. Sistemul propus a atins cea mai mare precizie medie, care este de 73%.
- În secțiunea 4.4 se discută tehnicile caracteristicilor locale ale texturilor aplicate imaginilor axiale RMN T1-ponderate ale creierului pentru a realiza detectarea automată a MSP. Sunt propuse noi variante ale caracteristicilor LTP, BLTP înalt și

BLTP scăzut. Se extrag două concluzii. Prima concluzie este că precizia detecției MSP crește atunci când intensitatea diferențelor dintre IF și țesutul înconjurător este mare. A doua concluzie este că există câteva cazuri de secțiuni ale creierului cu tumori. MSP a fost detectat cu precizie în secțiunile care au tumori mai mici. Comparația dintre performanțele LBP, ALBP, BLBP, LTP și BLTP arată că cel mai bun rezultat este obținut prin utilizarea metodei BLTP care atinge cea mai bună performanță globală.

- În secțiunea 4.5, discutăm detectarea patologiilor creierului, cum ar fi hemoragia craniană sau tumora pornind de la două secțiuni, simetria bilaterală și clusterizarea K-means, urmată de etichetarea componentelor conectate. Segmentarea imaginii RMN este utilizată pentru a detecta localizarea tumorii folosind algoritmul de grupare K-means. Analiza Silhouette este un indicator util pentru evaluarea unui candidat K pentru grupare. Sistemul propus oferă cele mai bune rezultate atunci când se aplică și procesul de etichetare a componentelor conectate. Sistemul propus a atins precizia medie cea mai ridicată de 94%.
- În secțiunea 4.6 discutăm detectarea melanomului în trei faze, regula ABCD pentru dermatoscopie, analiza texturii statistice și simptomele leziunii. Prima concluzie este că neregularitatea conturului este un bun indicator pentru determinarea melanomului. O altă concluzie este că există câteva cazuri de melanom în care calculul indicelui de asimetrie a două secțiuni de conținut diferite nu a fost mare, deoarece această metodă se bazează pe suprafață (numărul total de pixeli ai unei leziuni). Experimentele au arătat că entropia și contrastul sunt măsurători eficiente în caracterizarea neregularității și varianței imaginilor cu piele canceroasă. Precizia sistemului dezvoltat este de 90%.

Ca o sugestie pentru activitatea viitoare se poate trece la aplicarea algoritmilor de învățare a mașinilor pentru a îmbunătăți performanța generală a sistemelor propuse și pentru a detecta MSP și tumorile cerebrale, ceea ce face ca sistemul să devină mai inteligent.

Contribuțiile tezei

- Se propune un nou algoritm pentru detectarea unghiului de rotație în secțiunile de creier. Ideea principală a algoritmului propus se bazează pe intensitatea scăzută a regiunii fisurilor interemisferice (IF) și pe estimarea liniei celei mai potrivite determinate prin luarea scorului minim de intensitate între liniile de procesare cu mai multe treceri. Performanța algoritmului propus în comparație cu alți algoritmi de lucru arată în mod clar eficiența algoritmului propus în termeni de precizie și eforturi de calcul. Rezultatele au fost ilustrate în lucrarea mea publicată [46].
- Se propune o nouă metodă de localizare a MSP în imaginile RMN T1-ponderate, pe baza calculului diferitelor texturi locale între zona fisurii interemisferice (IF) și țesutul înconjurător. Am propus o nouă metodă prin utilizarea modelelor locale ternare bloc. Avantajul acestei metode este folosit pentru a crește puterea discriminatorie a caracteristicilor de textură LBP, îmbunătățind astfel codarea caracteristicilor texturale și crescând acuratețea clasificării. Rezultatele au fost prezentate în lucrarea mea publicată [10].
- Diagnosticarea cancerului melanomului pe baza combinației dintre regula ABCD de dermatoscopie, analiza statistică a texturii și simptomele leziunii este propusă pentru a îmbunătăți ratele de performanță acceptabile ale sistemului de diagnosticare. Rezultatele au fost descrise în lucrarea mea publicată [26].
- Se propune o nouă metodă pentru CBIR. Această metodă se bazează pe tehnicile texturilor locale. Performanța descriptorului local al modelelor binare locale, a modelului local ternar și a modelului ternar extins local sunt evaluate pentru CBIR. Conform rezultatelor, modelul ternar local extins uniform este mai precis decât alți descriptori în ceea ce privește extragerea imaginilor. Rezultatele au fost explicate în lucrarea mea publicată [21].
- Se propune o nouă metodă de recuperare a imaginilor pe baza componentelor conectate și a obiectelor de interes pentru a genera vectorii de histograme și de statistică a caracteristicilor de texturi. Acești vectori rezultați sunt folosiți pentru a prelua imagini dintr-o bază de date mare de imagini. Se observă că datele experimentale arată în mod clar eficiența metodei propuse în comparație cu tehnica tradițională ROI în ceea ce privește efortul de calcul. Rezultatele au fost ilustrate în lucrarea mea publicată [3].

- Se propune o nouă metodă pentru analiza performanței clusterizării K-Means pentru detectarea tumorii cerebrale. Selectarea automată a imaginii cluster corespunzătoare pentru detectarea tumorii cerebrale se bazează pe o caracteristică uniformă de textură locală și o simetrie bilaterală, care se calculează între jumătatea stângă și cea dreaptă a fiecărei imagini de grupare. Rezultatele au fost ilustrate în lucrarea mea publicată [39].

Bibliografie selectiva

- [1] S. Madhu, "Content based Image Retrieval: A Quantitative Comparison between Query by Color and Query by Texture," *Journal of Industrial and Intelligent Information*, vol. 2, no. 2, pp. 108-112, Nov. 2014.
- [2] F. Baji and M. Mocanu , "Connected components objects feature for CBIR," in *2017 18th International Carpathian Control Conference (ICCC)* , Sinaia, Romania, 28-31 May 2017 DOI: 10.1109/CarpathianCC.2017.7970460.
- [3] R. K. Lingadalli, and N. Ramesh, "Content Based Image Retrieval using Color, Shape and Texture," *International Advanced Research Journal in Science, Engineering and Technolog*, vol. 2, no. 6, pp. 40-45, Jun. 2015.
- [4] E. R. Vimina, and K. P. Jacob,, "Content Based Image Retrieval Using Low Level Features of Automatically Extracted Regions of Interest," *Journal of Image and Graphics*,, vol. 1, no. 2, pp. 7-11, Mar. 2013.
- [5] A. Suruliandi and G. Murugeswari, " Empirical Evaluation of LBP and its Derivates For Abnormality Detection In Mammogram Images," *Ictact Journal on Image and Video Proc*, vol. 4, no. 4, pp. 824-830, 2014.
- [6] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971-987, July 2002.

- [7] F. Baji, M. Mocanu and D. Popa, "Detection the Mid-Sagittal Plane in Brain Slice MR Images by Using Local Ternary Pattern," in *2018 International Conference on Development and Application Systems (DAS) 14th Edition*, Suceava - Romania, May 24-26, 2018, DOI: 10.1109/DAAS.2018.8396086.
- [8] A. Khokher and R. Talwar, " Content-based Image Retrieval: Feature Extraction Techniques and Applications," *International Journal of Computer Applications*, vol. 4, pp. 9-14, 2012.
- [9] S. P. Mathew, V. E. Balas, K. Zachariah and P. Samuel, " A Content-based Image Retrieval System Based on Polar Raster Edge Sampling Signature," *Acta Polytechnica Hungarica*, vol. 11, no. 3, pp. 25-36, 2014.
- [10] R. Chaudhari, and A. M. Patil, "Content Based Image Retrieval Using Color and Shape Features," *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, vol. 1, no. 5, pp. 386-392, 2012.
- [11] A. Loredana, and S. Udristoiu, "Study of Medical Image Segmentation using a Statistical Framework," *ANNALS of the university of Craiova*, vol. 9, no. 36, pp. 65-70, 2012.
- [12] X. Tan and B. Triggs, "Enhanced local texture feature sets for face recognition under difficult lighting conditions," in *IEEE Trans. Image Process*, pp. 1635–1650, 2010.
- [13] D. Unay, A. Ekin and R. Jasinschi, "MEDICAL IMAGE SEARCH AND RETRIEVAL USING LOCAL BINARY PATTERNS AND KLT FEATURE POINTS," in *2008 15th IEEE International Conference on Image Processing*, San Diego, CA, USA, pp. 997-1000, Oct. 2008.
- [14] F. Baji and M. Mocanu, "Uniform Extended Local Ternary Pattern for Content Based Image Retrieval," in *22nd International Conference on System Theory, Control and Computing, ICSTCC 2018*, Sinaia, Romania., 2018.
- [15] S. Wan, H. Lee, J.G fujimoto, X. Huang and C. Zhou, " OCM image texture analysis for tissue classification," in *2014 IEEE 11th International Symposium on Biomedical*

- Imaging (ISBI)*, Beijing, China, pp. 93-96, May 2014, .
- [16] H. Freeman and A. Saghri, "Generalized chain codes for planar curves," in *In Proceedings of the 4th International Joint Conference on Pattern Recognition.*, Kyoto, Japan, 701-703, November 7-10 1978.
- [17] S. Mark and S. A. Alberto, *Feature Extraction and Image Processing*; chapter 7, Newnes: Replika Press PVT Ltd., 2002.
- [18] U. C. Maya and K. Meenakshy, " Brain Tumor Segmentation Using Asymmetry Based Histogram Thresholding And K-Means Clustering," *International Journal of Research in Engineering and Technology*, vol. 3, no. 15, pp. 62-65, 2014.
- [19] S. Nadia and B. Souhir, "A developed system for melanoma diagnosis," *International Journal of Computer Vision and Signal Processing*, vol. 3, pp. 10-17, 2013.
- [20] G. V. Tcheslavski, ", (2009). "Morphological Image Processing: Basic concept," *Spring ELEN 4304/5365 DIP*, 2009, available:<http://ee.lamar.edu/gleb/dip/index.htm>.
- [21] H. A. Aslam, T. Ramashri and M.I.A. Ahsan, "A New Approach to Image Segmentation for Brain Tumor detection using Pillar K-means Algorithm," *International Journal of Advanced Research in Computer and Communication Engineering*, vol. 2, no. 3, pp. 1429-1436, 2013.
- [22] P.J. Rousseeuw, "Silhouettes: a graphical aid to the interpretation and validation of cluster analysis," *Journal of Computational and Applied Mathematics.*, vol. 20, pp. 53-65, 1987.
- [23] M. Kass, A. Witkin, and T. Terzopoulous, "Snakes: Active Contour Models," *international Journal of Computer Vision*, pp. 321-331, 1988.
- [24] T. Boonnuk, S. Srisuk, and T. Sripramong, "Texture Segmentation Using Active Contour Model with Edge Flow Vector," *International Journal of Information and Electronics Engineering*, vol. 5, no. 2, pp. 107-111, 2015.

- [25] N. Otsu, " A Threshold Selection Method from Gray-Level Histograms," *IEEE Transactions On Systems, Man, And Cybernetics*, Vols. SMC-9, no. 1, pp. 62-66, Jan. 2008.
- [26] A. A. Mohamed, and R. V. Yampolskiy, "Adaptive Extended Local Ternary Pattern (AELTP) for Recognizing Avatar Faces," in *2012 11th International Conference on Machine Learning and Applications*, Boca Raton, FL, USA, pp. 57-62, Dec. 2012..
- [27] L. Rocha, L. Velho, P. P. Carvalho, "Image Moments-Based Structuring and Tracking of Objects," in *Proc. of IEEE XV Brazilian Symposium on Computer Graphics and Image Processing*, DOI: 10.1109/SIBGRA.2002.1167130, ISBN: 0-7695-1846-X, Fortaleza-CE, Brazil, pp. 1-7, 2002.
- [28] F. Baji and M. Mocanu, "Chain Code Approach for Shape based Image Retrieval," *Indian Journal of Science and Technology*, vol. 11, no. 3, pp. 1-17, Jan. 2018 DOI: 10.17485/ijst/2018/v11i3/119998.
- [29] S. A. Jayasuriya and A. W. Liew, "Symmetry Plane Detection in Neuroimages based on Intensity Profile Analysis," in *International Symposium on Information Technology in Medicine and Education*, Hokkaido, Japa, 2012.
- [30] F. Baji, M. Mocanu and D. Popa, "Brain Tumor Detection Based on Asymmetry and K-Means Clustering MRI Image Segmentation," *Journal of Engineering Science and Technology*, 2018.
- [31] Y. Lium, R. T. Collins and W. E. Rothfus, " Automatic Extraction of the Central Symmetry (MidSagittal) Plane from Neuroradiology Images," The Robotics Institute, Carnegie Mellon University, 1996.
- [32] A. Bianchi, J. V. Miller, E. T. Tan and A. Montillo, "Brain Tumor Segmentation With Symmetric Texture And Symmetric Intensity-Based Decision Forests," in *Proc. IEEE International Symp Biomed Imaging*, Buffalo, USA, 2013.
- [33] M. Mokhomo, "Automatic Detection and Segmentation of Brain Lesions from 3D MR and CT Images," M.S. thesis, Faculty of Engineering, Cape Town University South

Africa, 2014.

- [34] S. R. Nilkamal and V.J. Shweta, "ABCD rule based automatic computer-aided skin cancer detection using MATLAB," *International Journal Computer Technology and Applications*, vol. 4, no. 4, pp. 691-697, 2013.
- [35] F. Baji and M. Mocanu, "Diagnosis Melanoma Skin Cancer Using ABCD Rule, Statistic Texture Feature and Lesion Symptoms," *ANNALS of the University of Craiova*, vol. 13, no. 40, pp. 20-27, 2016.
- [36] C. Sahil, J. Sonika and K. Bhavneet, " Content based Image Retrieval using Selective Region Matching with Region of Interest and SVM," *International Journal of Computer Applications*, vol. 137, pp. 28-33, 2016.
- [37] W. Stolz, A. Riemann, A. B. Cagnetta, L. pillet, et al, "ABCD rule of dermatoscopy: A new practical method for early recognition of malignant melanoma," *European Journal of Dermatology* , vol. 4, p. 521–527, 1994.
- [38] K. A. Johnson and J. Alex Becker , "the Whole Brain Atlas," 1999. [Online]. Available: "<http://www.med.harvard.edu/AANLIB/home.html>".
- [39] F. Baji and M. Mocanu, "Performance Analysis of K-Means Clustering for Brain Tumor Detection," 2018.